



Apache Doris 2.0 中文手册

归档版本文档

2026-10-29 · 913 篇文档

Source: 52197eda76d3

目录

1. [Apache Doris 简介](#)
2. [快速体验](#)
3. [手动部署](#)
4. [Docker 部署](#)
5. [集群环境要求](#)
6. [部署 Doris Operator](#)
7. [配置 Doris 集群](#)
8. [部署 Doris 集群](#)
9. [访问 Doris 集群](#)
10. [升级基于 Doris Operator 部署的 Apache Doris 集群](#)
11. [Root 用户使用](#)
12. [服务扩缩容](#)
13. [服务 Crash 情况下如何进入容器](#)
14. [Doris on AWS](#)
15. [数据库连接](#)
16. [数据类型](#)
17. [模型概述](#)
18. [明细模型](#)
19. [主键模型](#)
20. [聚合模型](#)
21. [使用注意](#)
22. [行列混存](#)
23. [基本概念](#)
24. [手动分区](#)
25. [动态分区](#)
26. [手动分桶](#)
27. [自动分桶](#)
28. [常见问题](#)
29. [Schema 变更](#)
30. [冷热数据分层](#)
31. [索引概述](#)
32. [前缀索引与排序键](#)
33. [倒排索引](#)
34. [BloomFilter 索引](#)
35. [N-Gram 索引](#)
36. [数据库建表最佳实践](#)
37. [导入概览](#)
38. [Stream Load](#)

- 39. [Broker Load](#)
- 40. [Routine Load](#)
- 41. [Insert Into](#)
- 42. [MySQL Load](#)
- 43. [JSON 数据导入](#)
- 44. [从其他 AP 系统迁移数据](#)
- 45. [导入事务与原子性](#)
- 46. [数据转化](#)
- 47. [最小写入副本数](#)
- 48. [严格模式](#)
- 49. [数据更新概述](#)
- 50. [主键模型的 Update 更新](#)
- 51. [主键模型的导入更新](#)
- 52. [聚合模型的导入更新](#)
- 53. [主键模型的更新并发控制](#)
- 54. [Delete 操作](#)
- 55. [批量删除](#)
- 56. [Truncate 操作](#)
- 57. [表原子替换](#)
- 58. [临时分区](#)
- 59. [通过 Export 导出数据](#)
- 60. [通过 SELECT INTO OUTFILE 导出结果集](#)
- 61. [通过 MySQL Dump 导出表结构和数据](#)
- 62. [MySQL 兼容性](#)
- 63. [Select 查询](#)
- 64. [复杂类型查询](#)
- 65. [子查询](#)
- 66. [公用表表达式 \(CTE\)](#)
- 67. [列转行 \(Lateral View\)](#)
- 68. [分析 \(窗口\) 函数](#)
- 69. [Enrcption and Masking Function](#)
- 70. [变量](#)
- 71. [SQL Mode](#)
- 72. [全新优化器介绍](#)
- 73. [统计信息](#)
- 74. [Pipeline 执行引擎](#)
- 75. [缓存概览](#)
- 76. [SQL Cache](#)
- 77. [Partition Cache](#)
- 78. [逻辑视图](#)
- 79. [同步物化视图](#)
- 80. [Join 优化原理](#)

81. [Bucket Shuffle Join](#)
82. [Colocation Join](#)
83. [Runtime Filter](#)
84. [Join Hint](#)
85. [BITMAP 精准去重](#)
86. [HLL 近似去重](#)
87. [高并发点查](#)
88. [TOPN 查询优化](#)
89. [Query Profile](#)
90. [查询分析](#)
91. [导入分析](#)
92. [Java UDF](#)
93. [Remote UDF](#)
94. [湖仓一体概述](#)
95. [Hive Catalog](#)
96. [Hudi Catalog](#)
97. [Iceberg Catalog](#)
98. [Paimon Catalog](#)
99. [AWS 认证接入](#)
100. [JDBC Catalog](#)
101. [MySQL](#)
102. [PostgreSQL](#)
103. [Oracle](#)
104. [SQL Server](#)
105. [ClickHouse](#)
106. [SAP HANA](#)
107. [OceanBase](#)
108. [Elasticsearch](#)
109. [MaxCompute](#)
110. [分析 S3/HDFS 上的文件](#)
111. [数据缓存](#)
112. [弹性计算节点](#)
113. [外表统计信息](#)
114. [集群升级](#)
115. [弹性扩缩容](#)
116. [负载均衡](#)
117. [时区管理](#)
118. [FQDN](#)
119. [数据备份](#)
120. [数据备份恢复](#)
121. [跨集群数据同步](#)
122. [从回收站恢复](#)

- 123. [主键表数据修复](#)
- 124. [Workload Group](#)
- 125. [Resource Group](#)
- 126. [SQL 拦截](#)
- 127. [Kill Query](#)
- 128. [认证和鉴权](#)
- 129. [MySQL 安全传输](#)
- 130. [HTTP 安全传输](#)
- 131. [基于 LDAP 的用户认证](#)
- 132. [基于 Apache Ranger 的鉴权管理](#)
- 133. [内存跟踪器](#)
- 134. [内存超限错误分析](#)
- 135. [BE OOM 分析](#)
- 136. [监控指标](#)
- 137. [监控和报警](#)
- 138. [磁盘空间管理](#)
- 139. [数据副本管理](#)
- 140. [Tablet 元数据管理工具](#)
- 141. [Tablet 恢复工具](#)
- 142. [Tablet 本地调试](#)
- 143. [元数据运维](#)
- 144. [服务自动拉起](#)
- 145. [如何开启 Debug 日志](#)
- 146. [配置文件目录](#)
- 147. [FE 配置项](#)
- 148. [BE 配置项](#)
- 149. [用户配置项](#)
- 150. [审计日志插件](#)
- 151. [Config Action](#)
- 152. [HA Action](#)
- 153. [Hardware Info Action](#)
- 154. [Help Action](#)
- 155. [Log Action](#)
- 156. [Login Action](#)
- 157. [Logout Action](#)
- 158. [Query Profile Action](#)
- 159. [Session Action](#)
- 160. [System Action](#)
- 161. [Colocate Meta Action](#)
- 162. [Meta Action](#)
- 163. [Cluster Action](#)
- 164. [Node Action](#)

- 165. [Query Profile Action](#)
- 166. [Backends Action](#)
- 167. [Bootstrap Action](#)
- 168. [Cancel Load Action](#)
- 169. [Check Decommission Action](#)
- 170. [Check Storage Type Action](#)
- 171. [Connection Action](#)
- 172. [Extra Basepath Action](#)
- 173. [Fe Version Info Action](#)
- 174. [Get DDL Statement Action](#)
- 175. [Get Load Info Action](#)
- 176. [Get Load State](#)
- 177. [Get FE log file](#)
- 178. [Get Small File Action](#)
- 179. [Health Action](#)
- 180. [Meta Info Action](#)
- 181. [Meta Replay State Action](#)
- 182. [Metrics Action](#)
- 183. [Profile Action](#)
- 184. [Query Schema Action](#)
- 185. [Query Stats Action](#)
- 186. [Row Count Action](#)
- 187. [Set Config Action](#)
- 188. [Show Data Action](#)
- 189. [Show Meta Info Action](#)
- 190. [Show Proc Action](#)
- 191. [Show Runtime Info Action](#)
- 192. [Show Table Data Action](#)
- 193. [Statement Execution Action](#)
- 194. [Table Query Plan Action](#)
- 195. [Table Row Count Action](#)
- 196. [Table Schema Action](#)
- 197. [Upload Action](#)
- 198. [Import Action](#)
- 199. [Meta Info Action](#)
- 200. [代码打桩](#)
- 201. [Statistic Action](#)
- 202. [检查连接缓存](#)
- 203. [重置连接缓存](#)
- 204. [查看 Compaction 状态](#)
- 205. [触发 Compaction](#)
- 206. [查询元信息](#)

- 207. [做快照](#)
- 208. [检查 tablet 文件丢失](#)
- 209. [BE 的配置信息](#)
- 210. [metrics 信息](#)
- 211. [查询 tablet 分布](#)
- 212. [迁移 tablet](#)
- 213. [查询 tablet 信息](#)
- 214. [Checksum](#)
- 215. [下载 load 日志](#)
- 216. [填充坏副本](#)
- 217. [BE 版本信息](#)
- 218. [BE 探活](#)
- 219. [重加载 tablet](#)
- 220. [恢复 tablet](#)
- 221. [插件开发](#)
- 222. [文件管理器](#)
- 223. [Compaction 优化](#)
- 224. [系统表](#)
- 225. [Star Schema Benchmark](#)
- 226. [TPC-H Benchmark](#)
- 227. [TPC-DS Benchmark](#)
- 228. [Spark Doris Connector](#)
- 229. [Flink Doris Connector](#)
- 230. [Doris Kafka Connector](#)
- 231. [Doris Streamloader](#)
- 232. [Apache Superset](#)
- 233. [FineBI](#)
- 234. [Power BI](#)
- 235. [Tableau](#)
- 236. [QuickSight](#)
- 237. [Quick BI](#)
- 238. [Smartbi](#)
- 239. [CloudDM](#)
- 240. [DBeaver](#)
- 241. [DataGrip](#)
- 242. [Logstash](#)
- 243. [Filebeat](#)
- 244. [FluentBit](#)
- 245. [CloudCanal](#)
- 246. [DataX Doriswriter](#)
- 247. [DBT Doris Adapter](#)
- 248. [Seatunnel Doris Sink](#)

249. [Kettle Doris Plugin](#)
250. [Kyuubi](#)
251. [AutoMQ Load](#)
252. [Hive Bitmap UDF](#)
253. [常见运维问题](#)
254. [数据操作问题](#)
255. [常见查询问题](#)
256. [常见数据湖问题](#)
257. [常见BI问题](#)
258. [数据正确性问题](#)
259. [数据类型概览](#)
260. [BOOLEAN](#)
261. [TINYINT](#)
262. [SMALLINT](#)
263. [INT](#)
264. [BIGINT](#)
265. [LARGEINT](#)
266. [FLOAT](#)
267. [DOUBLE](#)
268. [DECIMAL](#)
269. [DATE](#)
270. [TIME](#)
271. [DATETIME](#)
272. [CHAR](#)
273. [VARCHAR](#)
274. [STRING](#)
275. [ARRAY](#)
276. [MAP](#)
277. [STRUCT](#)
278. [JSON](#)
279. [HLL\(HyperLogLog\)](#)
280. [BITMAP](#)
281. [QUANTILE_STATE](#)
282. [AGG_STATE](#)
283. [ARRAY](#)
284. [ARRAY_MAX](#)
285. [ARRAY_MIN](#)
286. [ARRAY_MAP](#)
287. [ARRAY_FILTER](#)
288. [ARRAY_AVG](#)
289. [ARRAY_SUM](#)
290. [ARRAY_SIZE](#)

291. [ARRAY_REMOVE](#)
292. [ARRAY_SLICE](#)
293. [ARRAY_SORT](#)
294. [ARRAY_REVERSE_SORT](#)
295. [ARRAY_SORTBY](#)
296. [ARRAY_POSITION](#)
297. [ARRAY_CONTAINS](#)
298. [ARRAY_EXCEPT](#)
299. [ARRAY_PRODUCT](#)
300. [ARRAY_INTERSECT](#)
301. [ARRAY_RANGE](#)
302. [ARRAY_DISTINCT](#)
303. [ARRAY_DIFFERENCE](#)
304. [ARRAY_UNION](#)
305. [ARRAY_JOIN](#)
306. [ARRAY_WITH_CONSTANT](#)
307. [ARRAY_ENUMERATE](#)
308. [ARRAY_ENUMERATE_UNIQ](#)
309. [ARRAY_POPBACK](#)
310. [ARRAY_POPFRONT](#)
311. [ARRAY_PUSHFRONT](#)
312. [ARRAY_PUSHBACK](#)
313. [ARRAY_COMPACT](#)
314. [ARRAY_CONCAT](#)
315. [ARRAY_ZIP](#)
316. [ARRAY_SHUFFLE](#)
317. [ARRAY_CUM_SUM](#)
318. [ARRAY_EXISTS](#)
319. [ARRAY_FIRST_INDEX](#)
320. [ARRAY_LAST_INDEX](#)
321. [ARRAY_FIRST](#)
322. [ARRAY_LAST](#)
323. [ARRAYS_OVERLAP](#)
324. [ARRAY_COUNT](#)
325. [ARRAY_APPLY](#)
326. [COUNTEQUAL](#)
327. [ELEMENT_AT](#)
328. [CONVERT_TZ](#)
329. [CURDATE,CURRENT_DATE](#)
330. [CURTIME,CURRENT_TIME](#)
331. [CURRENT_TIMESTAMP](#)
332. [LOCALTIME,LOCALTIMESTAMP](#)

333. [NOW](#)
334. [YEAR](#)
335. [QUARTER](#)
336. [MONTH](#)
337. [DAY](#)
338. [DAYOFYEAR](#)
339. [DAYOFMONTH](#)
340. [DAYOFWEEK](#)
341. [WEEK](#)
342. [WEEKDAY](#)
343. [WEEKOFYEAR](#)
344. [YEARWEEK](#)
345. [DAYNAME](#)
346. [MONTHNAME](#)
347. [HOURL](#)
348. [MINUTE](#)
349. [SECOND](#)
350. [FROM_DAYS](#)
351. [LAST_DAY](#)
352. [TO_MONDAY](#)
353. [FROM_SECOND](#)
354. [FROM_UNIXTIME](#)
355. [UNIX_TIMESTAMP](#)
356. [UTC_TIMESTAMP](#)
357. [TO_DATE](#)
358. [TO_DAYS](#)
359. [TIME_TO_SEC](#)
360. [SEC_TO_TIME](#)
361. [EXTRACT](#)
362. [MAKEDATE](#)
363. [STR_TO_DATE](#)
364. [TIME_ROUND](#)
365. [TIMEDIFF](#)
366. [TIMESTAMPADD](#)
367. [TIMESTAMPDIFF](#)
368. [DATE_ADD](#)
369. [DATE_SUB](#)
370. [DATE_TRUNC](#)
371. [DATE_FORMAT](#)
372. [DATEDIFF](#)
373. [SECOND_FLOOR](#)
374. [MINUTE_FLOOR](#)

375. HOURL_FLOOR
376. DAY_FLOOR
377. MONTH_FLOOR
378. YEAR_FLOOR
379. DATE_CEIL
380. SECOND_CEIL
381. MINUTE_CEIL
382. HOURL_CEIL
383. DAY_CEIL
384. MONTH_CEIL
385. YEAR_CEIL
386. MICROSECOND
387. MICROSECONDS_ADD
388. MICROSECONDS_DIFF
389. MICROSECONDS_SUB
390. MILLISECONDS_ADD
391. MILLISECONDS_DIFF
392. MILLISECONDS_SUB
393. MINUTES_ADD
394. MINUTES_DIFF
395. MINUTES_SUB
396. SECONDS_ADD
397. SECONDS_DIFF
398. SECONDS_SUB
399. HOURS_ADD
400. HOURS_DIFF
401. HOURS_SUB
402. DAYS_ADD
403. DAYS_DIFF
404. DAYS_SUB
405. WEEKS_ADD
406. WEEKS_DIFF
407. WEEKS_SUB
408. MONTHS_ADD
409. MONTHS_DIFF
410. MONTHS_SUB
411. YEARS_ADD
412. YEARS_DIFF
413. YEARS_SUB
414. ST_X
415. ST_Y
416. ST_CIRCLE

417. [ST_DISTANCE_SPHERE](#)
418. [ST_ANGLE](#)
419. [ST_AZIMUTH](#)
420. [ST_ANGLE_SPHERE](#)
421. [ST_AREA_SQUARE_METERS](#)
422. [ST_AREA_SQUARE_KM](#)
423. [ST_POINT](#)
424. [ST_POLYGON](#)
425. [ST_ASTEXT](#)
426. [ST_CONTAINS](#)
427. [ST_GEOMETRYFROMTEXT](#)
428. [ST_LINEFROMTEXT](#)
429. [ST_ASBINARY](#)
430. [ST_GEOMETRYFROMWKB](#)
431. [TO_BASE64](#)
432. [FROM_BASE64](#)
433. [ASCII](#)
434. [LENGTH](#)
435. [BIT_LENGTH](#)
436. [CHAR_LENGTH](#)
437. [LPAD](#)
438. [RPAD](#)
439. [LOWER](#)
440. [LCASE](#)
441. [UPPER](#)
442. [UCASE](#)
443. [INITCAP](#)
444. [REPEAT](#)
445. [REVERSE](#)
446. [CHAR](#)
447. [CONCAT](#)
448. [CONCAT_WS](#)
449. [SUBSTR](#)
450. [SUBSTRING](#)
451. [SUB_REPLACE](#)
452. [APPEND_TRAILING_CHAR_IF_ABSENT](#)
453. [ENDS_WITH](#)
454. [STARTS_WITH](#)
455. [TRIM](#)
456. [LTRIM](#)
457. [RTRIM](#)
458. [NULL_OR_EMPTY](#)

459. [NOT NULL OR EMPTY](#)
460. [HEX](#)
461. [UNHEX](#)
462. [ELT](#)
463. [INSTR](#)
464. [LOCATE](#)
465. [FIELD](#)
466. [FIND_IN_SET](#)
467. [REPLACE](#)
468. [LEFT](#)
469. [RIGHT](#)
470. [STRLEFT](#)
471. [STRRIGHT](#)
472. [SPLIT_PART](#)
473. [SPLIT_BY_STRING](#)
474. [SUBSTRING_INDEX](#)
475. [MONEY_FORMAT](#)
476. [PARSE_URL](#)
477. [CONVERT_TO](#)
478. [EXTRACT_URL_PARAMETER](#)
479. [UUID](#)
480. [SPACE](#)
481. [ESQUERY](#)
482. [MULTI_SEARCH_ALL_POSITIONS](#)
483. [MULTI_MATCH_ANY](#)
484. [MASK](#)
485. [MASK_FIRST_N](#)
486. [MASK_LAST_N](#)
487. [LIKE](#)
488. [NOT LIKE](#)
489. [REGEXP](#)
490. [REGEXP_EXTRACT](#)
491. [REGEXP_EXTRACT_ALL](#)
492. [REGEXP_REPLACE](#)
493. [REGEXP_REPLACE_ONE](#)
494. [STRUCT](#)
495. [NAMED_STRUCT](#)
496. [STRUCT_ELEMENT](#)
497. [STATE](#)
498. [MERGE](#)
499. [UNION](#)
500. [COLLECT_SET](#)

501. [MIN](#)
502. [STDDEV_SAMP](#)
503. [AVG](#)
504. [AVG_WEIGHTED](#)
505. [PERCENTILE](#)
506. [PERCENTILE_ARRAY](#)
507. [HLL_UNION_AGG](#)
508. [TOPN](#)
509. [TOPN_ARRAY](#)
510. [TOPN_WEIGHTED](#)
511. [COUNT](#)
512. [SUM](#)
513. [MAX_BY](#)
514. [BITMAP_UNION](#)
515. [GROUP_BITMAP_XOR](#)
516. [GROUP_BIT_AND](#)
517. [GROUP_BIT_OR](#)
518. [GROUP_BIT_XOR](#)
519. [PERCENTILE_APPROX](#)
520. [STDDEV,STDDEV_POP](#)
521. [GROUP_CONCAT](#)
522. [COLLECT_LIST](#)
523. [MIN_BY](#)
524. [MAX](#)
525. [ANY_VALUE](#)
526. [VAR_SAMP,VARIANCE_SAMP](#)
527. [APPROX_COUNT_DISTINCT](#)
528. [VARIANCE,VAR_POP,VARIANCE_POP](#)
529. [RETENTION](#)
530. [SEQUENCE_MATCH](#)
531. [SEQUENCE_COUNT](#)
532. [GROUPING](#)
533. [GROUPING_ID](#)
534. [COUNT_BY_ENUM](#)
535. [HISTOGRAM](#)
536. [MAP_AGG](#)
537. [BITMAP_AGG](#)
538. [TO_BITMAP](#)
539. [BITMAP_HASH](#)
540. [BITMAP_FROM_STRING](#)
541. [BITMAP_TO_STRING](#)
542. [BITMAP_TO_ARRAY](#)

543. [BITMAP FROM ARRAY](#)
544. [BITMAP EMPTY](#)
545. [BITMAP_OR](#)
546. [BITMAP_AND](#)
547. [BITMAP_UNION](#)
548. [BITMAP_XOR](#)
549. [BITMAP_NOT](#)
550. [BITMAP_AND_NOT,BITMAP_ANDNOT](#)
551. [BITMAP_SUBSET_LIMIT](#)
552. [BITMAP_SUBSET_IN_RANGE](#)
553. [SUB_BITMAP](#)
554. [BITMAP_COUNT](#)
555. [BITMAP_AND_COUNT](#)
556. [BITMAP_AND_NOT_COUNT,BITMAP_ANDNOT_COUNT](#)
557. [BITMAP_XOR_COUNT](#)
558. [BITMAP_OR_COUNT](#)
559. [BITMAP_CONTAINS](#)
560. [BITMAP_HAS_ALL](#)
561. [BITMAP_HAS_ANY](#)
562. [BITMAP_MAX](#)
563. [BITMAP_MIN](#)
564. [INTERSECT_COUNT](#)
565. [BITMAP_INTERSECT](#)
566. [BITMAP_HASH64](#)
567. [BITMAP_FROM_BASE64](#)
568. [BITMAP_TO_BASE64](#)
569. [BITMAP_REMOVE](#)
570. [BITAND](#)
571. [BITOR](#)
572. [BITXOR](#)
573. [BITNOT](#)
574. [CASE](#)
575. [COALESCE](#)
576. [IF](#)
577. [IFNULL](#)
578. [NVL](#)
579. [NULLIF](#)
580. [JSON_PARSE](#)
581. [JSON_EXTRACT](#)
582. [JSON_EXISTS_PATH](#)
583. [JSON_TYPE](#)
584. [JSON_ARRAY](#)

585. [JSON_OBJECT](#)
586. [JSON_QUOTE](#)
587. [JSON_UNQUOTE](#)
588. [JSON_VALID](#)
589. [JSON_CONTAINS](#)
590. [JSON_LENGTH](#)
591. [GET_JSON_DOUBLE](#)
592. [GET_JSON_INT](#)
593. [GET_JSON_BIGINT](#)
594. [GET_JSON_STRING](#)
595. [JSON_INSERT](#)
596. [JSON_REPLACE](#)
597. [JSON_SET](#)
598. [MAP](#)
599. [MAP_KEYS](#)
600. [MAP_VALUES](#)
601. [MAP_CONTAINS_KEY](#)
602. [MAP_CONTAINS_VALUE](#)
603. [MURMUR_HASH3_32](#)
604. [MURMUR_HASH3_64](#)
605. [HLL_CARDINALITY](#)
606. [HLL_EMPTY](#)
607. [HLL_HASH](#)
608. [CONV](#)
609. [BIN](#)
610. [SIN](#)
611. [COS](#)
612. [TAN](#)
613. [ASIN](#)
614. [ACOS](#)
615. [ATAN](#)
616. [E](#)
617. [PI](#)
618. [EXP](#)
619. [LOG](#)
620. [LOG2](#)
621. [LOG10](#)
622. [LN](#)
623. [CEIL](#)
624. [FLOOR](#)
625. [PMOD](#)
626. [ROUND](#)

627. [ROUND_BANKERS](#)
628. [TRUNCATE](#)
629. [ABS](#)
630. [SQRT](#)
631. [CBRT](#)
632. [POW](#)
633. [DEGREES](#)
634. [RADIANS](#)
635. [SIGN](#)
636. [POSITIVE](#)
637. [NEGATIVE](#)
638. [GREATEST](#)
639. [LEAST](#)
640. [RANDOM](#)
641. [MOD](#)
642. [RUNNING_DIFFERENCE](#)
643. [UUID_NUMERIC](#)
644. [AES_ENCRYPT](#)
645. [AES_DECRYPT](#)
646. [MD5](#)
647. [MD5SUM](#)
648. [SM4_ENCRYPT](#)
649. [SM4_DECRYPT](#)
650. [SM3](#)
651. [SM3SUM](#)
652. [SHA](#)
653. [SHA2](#)
654. [EXPLODE_JSON_ARRAY](#)
655. [EXPLODE](#)
656. [EXPLODE_SPLIT](#)
657. [EXPLODE_BITMAP](#)
658. [NUMBERS](#)
659. [EXPLODE_NUMBERS](#)
660. [OUTER 组合器](#)
661. [S3](#)
662. [HDFS](#)
663. [LOCAL](#)
664. [ICEBERG_META](#)
665. [BACKENDS](#)
666. [FRONTENDS](#)
667. [FRONTENDS_DISKS](#)
668. [CATALOGS](#)

669. [WORKLOAD_GROUPS](#)
670. [窗口函数概述](#)
671. [WINDOW_FUNCTION_SUM](#)
672. [WINDOW_FUNCTION_MIN](#)
673. [WINDOW_FUNCTION_COUNT](#)
674. [WINDOW_FUNCTION_RANK](#)
675. [WINDOW_FUNCTION_DENSE_RANK](#)
676. [WINDOW_FUNCTION_FIRST_VALUE](#)
677. [WINDOW_FUNCTION_LAST_VALUE](#)
678. [WINDOW_FUNCTION_LEAD](#)
679. [WINDOW_FUNCTION_LAG](#)
680. [WINDOW_FUNCTION_ROW_NUMBER](#)
681. [WINDOW_FUNCTION_WINDOW_FUNNEL](#)
682. [INET_NTOA](#)
683. [COSINE_DISTANCE](#)
684. [INNER_PRODUCT](#)
685. [L1_DISTANCE](#)
686. [L2_DISTANCE](#)
687. [CAST](#)
688. [DIGITAL_MASKING](#)
689. [WIDTH_BUCKET](#)
690. [ALTER-SYSTEM-ADD-FOLLOWER](#)
691. [ALTER-SYSTEM-ADD-OBSERVER](#)
692. [ALTER-SYSTEM-ADD-BACKEND](#)
693. [ALTER-SYSTEM-ADD-BROKER](#)
694. [ALTER-SYSTEM-MODIFY-BACKEND](#)
695. [ALTER-SYSTEM-DECOMMISSION-BACKEND](#)
696. [ALTER-SYSTEM-DROP-FOLLOWER](#)
697. [ALTER-SYSTEM-DROP-OBSERVER](#)
698. [ALTER-SYSTEM-DROP-BACKEND](#)
699. [ALTER-SYSTEM-DROP-BROKER](#)
700. [CANCEL-ALTER-SYSTEM](#)
701. [CREATE-ROLE](#)
702. [CREATE-USER](#)
703. [ALTER-USER](#)
704. [SET-PASSWORD](#)
705. [SET-PROPERTY](#)
706. [LDAP](#)
707. [GRANT](#)
708. [REVOKE](#)
709. [DROP-ROLE](#)
710. [DROP-USER](#)

711. [ADMIN-SHOW-CONFIG](#)
712. [ADMIN-SET-CONFIG](#)
713. [SET-VARIABLE](#)
714. [INSTALL-PLUGIN](#)
715. [UNINSTALL-PLUGIN](#)
716. [ADMIN SET REPLICA STATUS](#)
717. [SHOW REPLICA DISTRIBUTION](#)
718. [SHOW REPLICA STATUS](#)
719. [ADMIN-REPAIR-TABLE](#)
720. [ADMIN-CANCEL-REPAIR](#)
721. [ADMIN CHECK TABLET](#)
722. [ADMIN DIAGNOSE TABLET](#)
723. [ADMIN COPY TABLET](#)
724. [SHOW TABLET STORAGE FORMAT](#)
725. [ADMIN CLEAN TRASH](#)
726. [RECOVER](#)
727. [KILL](#)
728. [ADMIN-REBALANCE-DISK](#)
729. [ADMIN-CANCEL-REBALANCE-DISK](#)
730. [ENABLE-FEATURE](#)
731. [CREATE-CATALOG](#)
732. [CREATE-DATABASE](#)
733. [CREATE-TABLE](#)
734. [CREATE-TABLE-LIKE](#)
735. [CREATE-TABLE-AS-SELECT](#)
736. [CREATE-EXTERNAL-TABLE](#)
737. [CREATE-INDEX](#)
738. [CREATE-VIEW](#)
739. [CREATE-MATERIALIZED-VIEW](#)
740. [CREATE-FUNCTION](#)
741. [CREATE-FILE](#)
742. [CREATE-POLICY](#)
743. [CREATE-ENCRYPT-KEY](#)
744. [CREATE-RESOURCE](#)
745. [CREATE-WORKLOAD-GROUP](#)
746. [CREATE-SQL-BLOCK-RULE](#)
747. [ALTER-CATALOG](#)
748. [ALTER-DATABASE](#)
749. [ALTER-TABLE-COLUMN](#)
750. [ALTER-TABLE-PARTITION](#)
751. [ALTER-TABLE-ROLLUP](#)
752. [ALTER-TABLE-RENAME](#)

753. [ALTER-TABLE-REPLACE](#)
754. [ALTER-TABLE-PROPERTY](#)
755. [ALTER-TABLE-COMMENT](#)
756. [CANCEL-ALTER-TABLE](#)
757. [ALTER-VIEW](#)
758. [ALTER-POLICY](#)
759. [ALTER-RESOURCE](#)
760. [ALTER-COLOCATE-GROUP](#)
761. [ALTER-WORKLOAD-GROUP](#)
762. [ALTER-SQL-BLOCK-RULE](#)
763. [DROP-CATALOG](#)
764. [DROP-DATABASE](#)
765. [DROP-TABLE](#)
766. [DROP-INDEX](#)
767. [DROP-MATERIALIZED-VIEW](#)
768. [DROP-FUNCTION](#)
769. [DROP-FILE](#)
770. [DROP-POLICY](#)
771. [DROP-ENCRYPT-KEY](#)
772. [DROP-RESOURCE](#)
773. [DROP-WORKLOAD-GROUP](#)
774. [DROP-SQL-BLOCK-RULE](#)
775. [TRUNCATE-TABLE](#)
776. [CREATE-REPOSITORY](#)
777. [DROP-REPOSITORY](#)
778. [BACKUP](#)
779. [CANCEL-BACKUP](#)
780. [RESTORE](#)
781. [CANCEL-RESTORE](#)
782. [STREAM-LOAD](#)
783. [MULTI-LOAD](#)
784. [BROKER-LOAD](#)
785. [MYSQL-LOAD](#)
786. [CREATE-ROUTINE-LOAD](#)
787. [ALTER-ROUTINE-LOAD](#)
788. [PAUSE-ROUTINE-LOAD](#)
789. [RESUME-ROUTINE-LOAD](#)
790. [STOP-ROUTINE-LOAD](#)
791. [CREATE-SYNC-JOB](#)
792. [PAUSE SYNC JOB](#)
793. [RESUME-SYNC-JOB](#)
794. [STOP-SYNC-JOB](#)

795. [CANCEL-LOAD](#)
796. [CLEAN-LABEL](#)
797. [INSERT](#)
798. [SELECT](#)
799. [DELETE](#)
800. [UPDATE](#)
801. [EXPORT](#)
802. [CANCEL-EXPORT](#)
803. [INSERT-OVERWRITE](#)
804. [ANALYZE](#)
805. [OUTFILE](#)
806. [SHOW ALTER TABLE MATERIALIZED VIEW](#)
807. [SHOW-ALTER](#)
808. [SHOW-ANALYZE](#)
809. [SHOW-BACKUP](#)
810. [SHOW-BACKENDS](#)
811. [SHOW-BROKER](#)
812. [SHOW-CATALOGS](#)
813. [SHOW-CREATE-TABLE](#)
814. [SHOW-CHARSET](#)
815. [SHOW-CREATE-CATALOG](#)
816. [SHOW-CREATE-DATABASE](#)
817. [SHOW-CREATE-MATERIALIZED-VIEW](#)
818. [SHOW-CREATE-LOAD](#)
819. [SHOW-CREATE-REPOSITORY](#)
820. [SHOW-CREATE-ROUTINE-LOAD](#)
821. [SHOW-CREATE-FUNCTION](#)
822. [SHOW-COLUMNS](#)
823. [SHOW-COLUMN-STATS](#)
824. [SHOW-COLLATION](#)
825. [SHOW-DATABASES](#)
826. [SHOW-DATA-SKEW](#)
827. [SHOW-DATABASE-ID](#)
828. [SHOW-DYNAMIC-PARTITION](#)
829. [SHOW-DELETE](#)
830. [SHOW-DATA](#)
831. [SHOW-ENGINES](#)
832. [SHOW-EVENTS](#)
833. [SHOW-EXPORT](#)
834. [SHOW-ENCRYPT-KEY](#)
835. [SHOW-FUNCTIONS](#)
836. [SHOW-TYPECAST](#)

837. [SHOW-FILE](#)
838. [SHOW-GRANTS](#)
839. [SHOW-LAST-INSERT](#)
840. [SHOW-LOAD-PROFILE](#)
841. [SHOW-LOAD-WARNINGS](#)
842. [SHOW-INDEX](#)
843. [SHOW PARTITION ID](#)
844. [SHOW-SNAPSHOT](#)
845. [SHOW-SQL-BLOCK-RULE](#)
846. [SHOW-ROUTINE-LOAD](#)
847. [SHOW-SYNC-JOB](#)
848. [SHOW-WHITE-LIST](#)
849. [SHOW-WARNING](#)
850. [SHOW TABLET](#)
851. [SHOW TABLETS BELONG](#)
852. [SHOW-VARIABLES](#)
853. [SHOW-PLUGINS](#)
854. [SHOW-ROLES](#)
855. [SHOW-PROCEDURE](#)
856. [SHOW-ROUTINE-LOAD-TASK](#)
857. [SHOW-PROC](#)
858. [SHOW-TABLE-STATS](#)
859. [SHOW-TABLE-STATUS](#)
860. [SHOW-REPOSITORIES](#)
861. [SHOW-QUERY-PROFILE](#)
862. [SHOW-OPEN-TABLES](#)
863. [SHOW-TABLETS](#)
864. [SHOW-LOAD](#)
865. [SHOW-TABLES](#)
866. [SHOW-RESOURCES](#)
867. [SHOW-WORKLOAD-GROUPS](#)
868. [SHOW-PARTITIONS](#)
869. [SHOW-FRONTENDS](#)
870. [SHOW FRONTENDS DISKS](#)
871. [SHOW-RESTORE](#)
872. [SHOW-PROPERTY](#)
873. [SHOW-TRIGGERS](#)
874. [SHOW-PROCESSLIST](#)
875. [SHOW TRASH](#)
876. [SHOW-VIEW](#)
877. [SHOW-TRANSACTION](#)
878. [SHOW-STREAM-LOAD](#)

879. [SHOW-STATUS](#)
880. [SHOW-TABLE-ID](#)
881. [SHOW-SMALL-FILES](#)
882. [SHOW-POLICY](#)
883. [SHOW-STORAGE-POLICY-USING](#)
884. [SHOW-CATALOG-RECYCLE-BIN](#)
885. [SHOW-QUERY-STATS](#)
886. [IN](#)
887. [HELP](#)
888. [USE](#)
889. [DESCRIBE](#)
890. [SWITCH](#)
891. [REFRESH](#)
892. [SYNC](#)
893. [CLEAN-QUERY-STATS](#)
894. [FE 配置项](#)
895. [数据库 CDC 导入](#)
896. [生态概览](#)
897. [日志存储与分析](#)
898. [获取 Profile](#)
899. [SECOND_TIMESTAMP](#)
900. [IPV4_NUM_TO_STRING](#)
901. [WINDOW_FUNCTION_AVG](#)
902. [WINDOW_FUNCTION_MAX](#)
903. [WINDOW_FUNCTION_NTILE](#)
904. [PAUSE-JOB](#)
905. [RESUME-JOB](#)
906. [STOP-JOB](#)
907. [CLEAN-PROFILE](#)
908. [SHOW-CONVERT-LIGHT-SCHEMA-CHANGE-PROCESS](#)
909. [SHOW-DATA-TYPES](#)
910. [SHOW-JOB-TASK](#)
911. [SHOW-MIGRATIONS](#)
912. [REFRESH-LDAP](#)
913. [位图索引](#)

Apache Doris 简介

Apache Doris 的发展


Apache Doris 是一款基于 MPP 架构的高性能、实时的分析型数据库，以高效、简单、统一的特点被人们所熟知，仅需亚秒级响应时间即可返回海量数据下的查询结果，不仅可以支持高并发的点查询场景，也能支持高吞吐的复杂分析场景。基于此，Apache Doris 能够较好的满足报表分析、即席查询、统一数仓构建、湖仓一体等使用场景，用户可以在此之上构建大屏看板、用户行为分析、AB 实验平台、日志检索分析、用户画像分析、订单分析等应用。

Apache Doris 最早是诞生于百度广告报表业务的 Palo 项目，2017 年正式对外开源，2018 年 7 月由百度捐赠给 Apache 基金会进行孵化，之后在 Apache 导师的指导下由孵化器项目管理委员会成员进行孵化和运营。2022 年 6 月，Apache Doris 成功从 Apache 孵化器毕业，正式成为 Apache 顶级项目（Top-Level Project, TLP）。目前 Apache Doris 社区已经聚集了来自不同行业数百家企业的 600 余位贡献者，并且每月活跃贡献者人数也超过 120 位。

Apache Doris 如今在中国乃至全球范围内都拥有着广泛的用户群体，截止目前，Apache Doris 已经在全球超过 5000 家中大型企业的生产环境中得到应用，在中国市值或估值排行前 50 的互联网公司中，有超过 80% 长期使用 Apache Doris，包括百度、美团、小米、京东、字节跳动、阿里巴巴、腾讯、网易、快手、微博等。同时在一些传统行业如金融、消费、电信、工业制造、能源、医疗、政务等领域也有着丰富的应用。在中国几乎所有的云厂商比如阿里云、华为云、天翼云、腾讯云、百度云、火山引擎等都在提供托管的 Apache Doris 的云服务。

Apache Doris 的使用场景

如下图所示，数据源经过各种数据集成和加工处理后，通常会入库到实时数据仓库 Apache Doris 和离线湖仓（Hive, Iceberg, Hudi 中），Apache Doris 被广泛应用在以下场景中。



Apache Doris 的使用场景


- 报表分析
 - 实时看板（Dashboards）；
 - 面向企业内部分析师和管理者的报表；
 - 面向用户或者客户的高并发报表分析（Customer Facing Analytics）。比如面向网站主的站点分析、面向广告主的广告报表，并发通常要求成千上万的 QPS，查询延时要求毫秒级响应。著名的电商公司京东在广告报表中使用 Apache Doris，每天写入 100 亿行数据，查询并发 QPS 上万，99 分位的查询延时 150ms。
- 即席查询（Ad-hoc Query）：面向分析师的自助分析，查询模式不固定，要求较高的吞吐。小米公司基于 Apache Doris 构建了增长分析平台（Growing Analytics，GA），利用用户行为数据对业务进行增长分析，平均查询延时 10s，95 分位的查询延时 30s 以内，每天的 SQL 查询量为数万条。
- 湖仓一体（Data Lakehouse）：通过外表的方式联邦分析位于 Hive、Iceberg、Hudi 等离线湖仓中的数据，在避免数据拷贝的前提下，查询性能大幅提升。
- 日志检索分析：在 Apache Doris 2.0 版本中，支持了倒排索引和全文检索，能够很好的满足日志检索分析的场景，并且依赖其高效的查询引擎和存储引擎，相比传统的日志检索分析的方案可以有 10 倍性价比的优势。
- 统一数仓构建：一个平台满足统一的数据仓库建设需求，简化繁琐的大数据软件栈。海底捞基于 Apache Doris 构建的统一数仓，替换了原来由 Spark、Hive、Kudu、Hbase、Phoenix 组成的旧架构，架构大大简化。

整体架构和技术特点

Apache Doris 的整体架构非常简单，如下图所示，只有两类进程：

- **Frontend (FE)**：主要负责用户请求的接入、查询解析规划、元数据的管理、节点管理相关工作。
- **Backend (BE)**：主要负责数据存储、查询计划的执行。

这两类进程都是可以横向扩展的，单集群可以支持到数百台机器，数十 PB 的存储容量。并且这两类进程通过一致性协议来保证服务的高可用和数据的高可靠。这种高度集成的架构设计极大地降低了一款分布式系统的运维成本。



整体架构和技术特点

使用接口

Apache Doris 采用 MySQL 协议，高度兼容 MySQL 语法，支持标准 SQL，用户可以通过各类客户端工具来访问 Apache Doris，并支持与 BI 工具的无缝对接。Apache Doris 当前支持多种主流的 BI 产品，包括但不限于 Smartbi、DataEase、FineBI、Tableau、Power BI、Apache Superset 等，只要支持 MySQL 协议的 BI 工具，Apache Doris 就可以作为数据源提供查询支持。

存储引擎

在存储引擎方面，Apache Doris 采用列式存储，按列进行数据的编码压缩和读取，能够实现极高的压缩比，同时减少大量非相关数据的扫描，从而更加有效利用 IO 和 CPU 资源。

Apache Doris 也支持比较丰富的索引结构，来减少数据的扫描：

- Sorted Compound Key Index，可以最多指定三个列组成复合排序键，通过该索引，能够有效进行数据裁剪，从而能够更好支持高并发的报表场景
- Min/Max Index：有效过滤数值类型的等值和范围查询
- BloomFilter Index：对高基数列的等值过滤裁剪非常有效
- Inverted Index：能够对任意字段实现快速检索

在存储模型方面，Apache Doris 支持多种存储模型，针对不同的场景做了针对性的优化：


- 聚合模型 (Aggregate Key Model)：相同 Key 的 Value 列合并，通过提前聚合大幅提升性能

- 主键模型 (Unique Key Model)：Key 唯一，相同 Key 的数据覆盖，实现行级别数据更新
- 明细模型 (Duplicate Key Model)：明细数据模型，满足事实表的明细存储

Apache Doris 也支持强一致的物化视图，物化视图的更新和选择都在系统内自动进行，不需要用户手动选择，从而大幅减少了物化视图维护的代价。


查询引擎

在查询引擎方面，Apache Doris 采用 MPP 的模型，节点间和节点内都并行执行，也支持多个大表的分布式 Shuffle Join，从而能够更好应对复杂查询。



查询引擎

Apache Doris 查询引擎是向量化的查询引擎，所有的内存结构能够按照列式布局，能够达到大幅减少虚函数调用、提升 Cache 命中率，高效利用 SIMD 指令的效果。在宽表聚合场景下性能是非向量化引擎的 5-10 倍。



Doris 查询引擎是向量化

Apache Doris 采用了自适应查询执行 (**Adaptive Query Execution**) 技术, 可以根据 Runtime Statistics 来动态调整执行计划, 比如通过 Runtime Filter 技术能够在运行时生成 Filter 推到 Probe 侧, 并且能够将 Filter 自动穿透到 Probe 侧最底层的 Scan 节点, 从而大幅减少 Probe 的数据量, 加速 Join 性能。Apache Doris 的 Runtime Filter 支持 In/Min/Max/Bloom Filter。

在**优化器**方面, Apache Doris 使用 CBO 和 RBO 结合的优化策略, RBO 支持常量折叠、子查询改写、谓词下推等, CBO 支持 Join Reorder。目前 CBO 还在持续优化中, 主要集中在更加精准的统计信息收集和推导, 更加精准的代价模型预估等方面。

快速体验

这个简短的指南将告诉你如何下载 Apache Doris 最新稳定版本，在单节点上安装并运行它，包括创建数据库、数据表、导入数据及查询等。

环境准备

- 选择一个 x86-64 上的主流 Linux 环境，推荐 CentOS 7.1 或者 Ubuntu 16.04 以上版本。更多运行环境请参考安装部署部分。
- Java 8 运行环境（非 Oracle JDK 商业授权用户，建议使用免费的 Oracle JDK 8u202，[立即下载](#)）。
- 建议在 Linux 上新建一个 Doris 用户。请避免使用 Root 用户，以防对操作系统误操作。

下载二进制包

从 doris.apache.org 下载相应的 Apache Doris 安装包，并且解压。

```
# 下载 Apache Doris 二进制安装包
server1:~ doris$ wget https://download.velodb.io/apache-doris-2.0.12-bin-x64.tar.gz

# 解压安装包
server1:~ doris$ tar zxf apache-doris-2.0.12-bin-x64.tar.gz

# 目录重命名为更为简单的 apache-doris
server1:~ doris$ mv apache-doris-2.0.12-bin-x64 apache-doris
```

安装 Doris

配置 FE

FE 的配置文件为 `apache-doris/fe/conf/fe.conf`。下面是一些需要关注的核心配置。除了 `JAVA_HOME`，需要手动增加，并且指向你的 JDK8 运行环境。其它配置，可以使用默认值，即可支持单机快速体验。

```
# 增加 JAVA_HOME 配置，指向 JDK8 的运行环境。假如我们 JDK8 位于 /home/doris/jdk8，则设置如下
JAVA_HOME=/home/doris/jdk8

# FE 监听 IP 的 CIDR 网段。默认设置为空，有 Apache Doris 启动时自动选择一个可用网段。如有多个网段，需要指定一个网段，可以类似
设置 priority_networks=192.168.0.0/24
# priority_networks =

# FE 元数据存放的目录，默认是在 DORIS_HOME 下的 doris-meta 目录。已经创建，可以更改为你的元数据存储路径。
# meta_dir = ${DORIS_HOME}/doris-meta
```

启动 FE

在 `apache-doris/fe` 下，运行下面命令启动 FE。

```
# 将 FE 启动成后台运行模式，这样确保退出终端后，进程依旧运行。
server1:apache-doris/fe doris$ ./bin/start_fe.sh --daemon
```

配置 BE

BE 的配置文件为 `apache-doris/be/conf/be.conf`。下面是一些需要关注的核心配置。除了 `JAVA_HOME`，需要手动增加，并且指向你的 JDK8 运行环境。其它配置，可以使用默认值，即可支持我们的快速体验。

```
# 增加 JAVA_HOME 配置，指向 JDK8 的运行环境。假如我们 JDK8 位于 /home/doris/jdk8，则设置如下
JAVA_HOME=/home/doris/jdk8

# BE 监听 IP 的 CIDR 网段。默认设置为空，有 Apache Doris 启动时自动选择一个可用网段。如有多个网段，需要指定一个网段，可以类似
设置 priority_networks=192.168.0.0/24
# priority_networks =

# BE 数据存放的目录，默认是在 DORIS_HOME 下的 storage 下，默认已经创建，可以更改为你的数据存储路径
# storage_root_path = ${DORIS_HOME}/storage
```

启动 BE

在 `apache-doris/be` 下，运行下面命令启动 BE。

```
# 将 BE 启动成后台运行模式，这样确保退出终端后，进程依旧运行。
server1:apache-doris/be doris$ ./bin/start_be.sh --daemon
```

连接 Apache Doris FE

通过 MySQL 客户端来连接 Apache Doris FE，下载免安装的 [MySQL 客户端](#)。

解压刚才下载的 MySQL 客户端，在 `bin/` 目录下可以找到 `mysql` 命令行工具。然后执行下面的命令连接 Apache Doris。

```
mysql -uroot -P9030 -h127.0.0.1
```

注意

- 这里使用的 Root 用户是 Apache Doris 内置的超级管理员用户，具体的用户权限查看 [认证和鉴权](#)
- P：这里是我们连接 Apache Doris 的查询端口，默认端口是 9030，对应的是 `fe.conf` 里的 `query_port`
- h：这里是我们连接的 FE IP 地址，如果你的客户端和 FE 安装在同一个节点可以使用 127.0.0.1。

将 BE 节点添加到集群

在 MySQL 客户端执行类似下面的 SQL，将 BE 添加到集群中

```
ALTER SYSTEM ADD BACKEND "be_host_ip:heartbeat_service_port";
```

注意

1. be_host_ip: 要添加 BE 的 IP 地址
2. heartbeat_service_port: 要添加 BE 的心跳上报端口, 可以查看 be.conf 里的 heartbeat_service_port, 默认是 9050。
3. 通过 show backends 语句可以查看新添加的 BE 节点。

修改 Root 用户和 Admin 用户的密码

在 MySQL 客户端, 执行类似下面的 SQL, 为 Root 用户和 Admin 用户设置新密码

```
mysql> SET PASSWORD FOR 'root' = PASSWORD('doris-root-password');
Query OK, 0 rows affected (0.01 sec)

mysql> SET PASSWORD FOR 'admin' = PASSWORD('doris-admin-password');
Query OK, 0 rows affected (0.00 sec)
```

Root 用户和 Admin 用户的区别

Root 用户和 Admin 用户都属于 Apache Doris 安装完默认存在的 2 个账户。其中 Root 用户拥有整个集群的超级权限, 可以对集群完成各种管理操作, 比如添加节点, 去除节点。Admin 用户没有管理权限, 是集群中的 Superuser, 拥有除集群管理相关以外的所有权限。建议只有在需要对集群进行运维管理超级权限时才使用 Root 权限。

建库建表

连接 Apache Doris

使用 Admin 账户连接 Apache Doris FE。

```
mysql -uadmin -P9030 -h127.0.0.1
```

如果是在 FE 的同一台机器上的 MySQL 客户端连接 127.0.0.1, 不需要输入密码。

创建数据库和数据表

```
create database demo;

use demo;
create table mytable
(
    k1 TINYINT,
```

```

    k2 DECIMAL(10, 2) DEFAULT "10.05",
    k3 CHAR(10) COMMENT "string column",
    k4 INT NOT NULL DEFAULT "1" COMMENT "int column"
)
COMMENT "my first table"
DISTRIBUTED BY HASH(k1) BUCKETS 1
PROPERTIES ('replication_num' = '1');

```

导入数据

将以下示例数据，保存在本地的 data.csv：

```

1,0.14,a1,20
2,1.04,b2,21
3,3.14,c3,22
4,4.35,d4,23

```

通过 Stream Load 方式将上面保存到文件中的数据导入到刚才创建的表里。

```

curl --location-trusted -u admin:admin_password -T data.csv -H "column_separator:,"
http://127.0.0.1:8030/api/demo/mytable/_stream_load

```

- -T data.csv : 要导入的数据文件名
- -u admin:admin_password : Admin 账户与密码
- 127.0.0.1:8030 : 分别是 FE 的 IP 和 http_port

执行成功之后我们可以看到下面的返回信息：

```

{
  "TxnId": 30,
  "Label": "a56d2861-303a-4b50-9907-238fea904363",
  "Comment": "",
  "TwoPhaseCommit": "false",
  "Status": "Success",
  "Message": "OK",
  "NumberTotalRows": 4,
  "NumberLoadedRows": 4,
  "NumberFilteredRows": 0,
  "NumberUnselectedRows": 0,
  "LoadBytes": 52,
  "LoadTimeMs": 206,
  "BeginTxnTimeMs": 13,
  "StreamLoadPutTimeMs": 141,
  "ReadDataTimeMs": 0,
  "WriteDataTimeMs": 7,
  "CommitAndPublishTimeMs": 42
}

```

- NumberLoadedRows: 表示已经导入的数据记录数
- NumberTotalRows: 表示要导入的总数据量
- Status: Success 表示导入成功

查询数据

在 MySQL 客户端中，执行如下 SQL，可以查询到刚才导入的数据：

```
mysql> select * from mytable;
+-----+-----+-----+-----+
| k1   | k2   | k3   | k4   |
+-----+-----+-----+-----+
| 1    | 0.14 | a1    | 20   |
| 2    | 1.04 | b2    | 21   |
| 3    | 3.14 | c3    | 22   |
| 4    | 4.35 | d4    | 23   |
+-----+-----+-----+-----+
4 rows in set (0.01 sec)
```

停止 Apache Doris

停止 FE

在 apache-doris/fe 下，运行下面命令停止 FE。

```
server1:apache-doris/fe doris$ ./bin/stop_fe.sh
```

停止 BE

在 apache-doris/be 下，运行下面命令停止 BE。

```
server1:apache-doris/be doris$ ./bin/stop_be.sh
```

手动部署

手动部署 Doris 集群，通常要进行四步规划：

1. 软硬件环境检查：检查用户的硬件资源情况及操作系统兼容性
2. 操作系统检查：检查操作系统参数及配置
3. 集群规划：规划集群的 FE、BE 节点，预估使用资源情况
4. 集群部署：根据部署规划进行集群部署操作
5. 部署验证：登录并验证集群正确性

1 软硬件环境检查

硬件检查

CPU

当安装 Doris 时，建议选择支持 AVX2 指令集的机器，以利用 AVX2 的向量化能力实现查询向量化加速。

运行以下命令，有输出结果，及表示机器支持 AVX2 指令集。

```
cat /proc/cpuinfo | grep avx2
```

如果机器不支持 AVX2 指令集，可以使用 no AVX2 的 Doris 安装包进行部署。

内存

Doris 没有强制的内存限制。一般在生产环境中，建议内存至少是 CPU 核数的 4 倍（例如，16 核机器至少配置 64G 内存）。在内存是 CPU 核数 8 倍时，会得到更好的性能。

存储

Doris 部署时数据可以存放在 SSD 或 HDD 硬盘或者对象存储中。

在以下几种场景中建议使用 SSD 作为数据存储：

- 大规模数据量下的高并发点查场景
- 大规模数据量下的高频数据更新场景

文件系统

ext4 和 xfs 文件系统均支持。

网卡

Doris 在进行计算过程涉及将数据分片分发到不同的实例上进行并行处理，会导致一定的网络资源开销。为了最大程度优化 Doris 性能并降低网络资源开销，强烈建议在部署时选用万兆网卡（10 Gigabit Ethernet，即

10GbE) 或者更快网络。

服务器建议配置

Doris 支持运行和部署在 x86-64 架构的服务器平台或 ARM64 架构的服务器上。

开发及测试环境

模块	CPU	内存	磁盘	网络	实例数量 (最低要求)
Frontend	8 核 +	8 GB+	SSD 或 SATA, 10 GB+	千兆/万兆网卡	1
Backend	8 核 +	16 GB+	SSD 或 SATA, 50 GB+	千兆/万兆网卡	1

说明

- 在验证测试环境中, 可以将 FE 与 BE 部署在同一台服务器上
- 一台机器上一般只建议部署一个 **BE** 实例, 同时只能部署一个 **FE**
- 如果需要 3 副本数据, 那么至少需要 3 台机器各部署一个 BE 实例, 而不是 1 台机器部署 3 个 BE 实例
- 多个 **FE** 所在服务器的时钟必须保持一致, 最多允许 5 秒的时钟偏差
- 测试环境也可以仅使用一个 BE 进行测试。实际生产环境, BE 实例数量直接决定了整体查询延迟。

生产环境

模块	CPU	内存	磁盘	网络	实例数量 (最低要求)
Frontend	16 核 +	64 GB+	SSD 或 RAID 卡, 100GB+	万兆网卡	1
Backend	16 核 +	64 GB+	SSD 或 SATA, 100G+	万兆网卡	3

说明

- 在生产环境中, 如果 FE 与 BE 混布, 需要注意资源争用问题, 建议元数据存储与数据存储分盘存放
- BE 节点可以配置多块硬盘存储, 在一个 BE 实例上绑定多块 HDD 或 SSD 盘
- 集群的性能与 BE 节点的资源有关, BE 节点越多, Doris 性能越好。通常情况下在 10 - 100 台机器上可以充分发挥 Doris 的性能

硬盘空间计算

在 Doris 集群中, FE 主要用于元数据存储, 包括元数据 edit log 和 image。BE 的磁盘空间主要用于存放数据, 需要根据业务需求计算。

组件	磁盘空间说明
FE	元数据一般在几百 MB 到几 GB，建议不低于 100GB
BE	Doris 默认 LZ4 压缩方式进行存储，压缩比在 0.3 - 0.5 左右磁盘空间需要按照总数据量 * 3（3 副本）计算需要预留出 40% 空间用作后台 compaction 以及临时数据的存储
Broker	如需部署 Broker，通常情况下可以将 Broker 节点与 FE / BE 节点部署在同一台机器上

Java 版本

Doris 的所有进程都依赖 Java。

在 2.1（含）版本之前，请使用 Java 8，推荐版本：openjdk-8u352-b08-linux-x64。

从 3.0（含）版本之后，请使用 Java 17，推荐版本：jdk-17.0.10_linux-x64_bin.tar.gz。

2 操作系统检查

关闭 swap 分区

在部署 Doris 时，建议关闭 swap 分区。swap 分区是内核发现内存紧张时，会按照自己的策略将部分内存数据移动到配置的 swap 分区，由于内核策略不能充分了解应用的行为，会对数据库性能造成较大影响。所以建议关闭。

通过以下命令可以临时或者永久关闭。

临时关闭，下次机器启动时，swap 还会被打开。

```
swapoff -a
```

永久关闭，使用 Linux root 账户，注释掉 /etc/fstab 中的 swap 分区，然后重启即可彻底关闭 swap 分区。

```
# /etc/fstab
# <file system>      <dir>          <type>         <options>          <dump> <pass>
tmpfs                /tmp           tmpfs          nodev,nosuid        0      0
/dev/sda1             /              ext4           defaults,noatime    0      1
# /dev/sda2            none           swap           defaults             0      0
/dev/sda3             /home          ext4           defaults,noatime    0      2
```

不建议使用设置 `vm.swappiness = 0` 的方式，因为这个参数在不同的 Linux 内核版本会有不同的语义，很多情况下不能完全关闭 swap。

检测和关闭系统防火墙

如果发现端口不通，可以试着关闭防火墙，确认是否是本机防火墙造成。如果是防火墙造成，可以根据配置的 Doris 各组件端口打开相应的端口通信。

```
sudo systemctl stop firewalld.service
```

```
sudo systemctl disable firewalld.service
```

配置 NTP 服务

Doris 的元数据要求时间精度要小于 5000ms，所以所有集群所有机器要进行时钟同步，避免因为时钟问题引发的元数据不一致导致服务出现异常。

通常情况下，可以通过配置 NTP 服务保证各节点时钟同步。

```
sudo systemctl start ntpd.service
sudo systemctl enable ntpd.service
```

设置系统最大打开文件句柄数

Doris 由于依赖大量文件来管理表数据，所以需要将系统对程序打开文件数的限制调高。

```
vi /etc/security/limits.conf
* soft nofile 1000000
* hard nofile 1000000
```

当前用户需要退出当前 **Session**，并重新登录进入才能生效

修改虚拟内存区域数量为

修改虚拟内存区域至少 2000000

```
sysctl -w vm.max_map_count=2000000
```

关闭透明大页

在部署 Doris 时，建议关闭透明大页。

```
echo never > /sys/kernel/mm/transparent_hugepage/enabled
echo never > /sys/kernel/mm/transparent_hugepage/defrag
```

3 集群规划

端口规划

Doris 各个实例直接通过网络进行通讯，其正常运行需要网络环境提供以下的端口。管理员可以根据实际环境自行调整 Doris 的端口：

实例名称	端口名称	默认端口	通信方向	说明
BE	be_port	9060	FE → BE	BE 上 thrift server 的端口，用于接收来自 FE 的请求

实例名称	端口名称	默认端口	通信方向	说明
BE	webserver_port	8040	BE <=> BE	BE 上的 http server 的端口
BE	heartbeat_service_port	9050	FE -> BE	BE 上心跳服务端口 (thrift)，用于接收来自 FE 的心跳
BE	brpc_port	8060	FE <=> BE, BE <=> BE	BE 上的 brpc 端口，用于 BE 之间通讯
FE	http_port	8030	FE <=> FE, Client <=> FE	FE 上的 http server 端口
FE	rpc_port	9020	BE -> FE, FE <=> FE	FE 上的 thrift server 端口，每个 fe 的配置需要保持一致
FE	query_port	9030	Client <=> FE	FE 上的 MySQL server 端口
FE	edit_log_port	9010	FE <=> FE	FE 上的 bdbje 之间通信用的端口
Broker	broker_ipc_port	8000	FE -> Broker, BE -> Broker	Broker 上的 thrift server，用于接收请求

节点数量规划

FE 节点数量

FE 节点主要负责用户请求的接入、查询解析规划、元数据的管理、节点管理相关工作。

对于生产集群，一般至少需要部署 3 节点 FE 的高可用环境。FE 节点分为两种角色：

- Follower 节点参与选举操作，当 Master 节点宕机后，会选择一个可用的 Follower 节点成为新的 Master；
- Observer 节点仅从 Leader 节点同步元数据，不参与选举。可以横向扩展以提供元数据的读服务的扩展性。

通常情况下，建议部署 3 个 Follower 节点。在高并发的场景中，可以通过扩展 Observer 节点提高集群的连接数。

BE 节点数量

BE 节点负责数据的存储与计算。在生产环境中，一般会使用 3 副本存储数据，建议部署至少 3 个 BE 节点。

BE 节点可以横向扩容，通过扩展 BE 节点的数量，可以提高查询的性能与并发能力。

4 安装集群

部署 FE Master 节点

创建元数据路径

FE 元数据通常不超过 10GB，建议与 BE 节点数据存储在不同的硬盘上。

在解压安装包时，会默认附带 doris-meta 目录，建议可以创建独立的元数据目录并创建该目录到 doris-meta 的软连接。生产环境强烈建议单独指定目录不要放在 Doris 安装目录下，最好是单独的磁盘（如果有 SSD 最好），测试开发环境可以使用默认配置

```
## 选择独立于 BE 数据的硬盘，创建 FE 的元数据目录
mkdir -p <doris_meta_created>

## 创建 FE 的元数据目录软连接
rm -rf <doris_meta_original>
ln -s <doris_meta_created> <doris_meta_original>
```

修改 FE 配置文件

FE 的配置文件在 FE 部署路径下的 conf 目录中，启动 FE 节点前需要修改 conf/fe.conf。

1. 修改 FE 元数据目录

在配置文件中，meta_dir 指定元数据的存放位置。meta_dir 默认放在 FE 的安装路径下。

如果创建了 FE 元数据目录的软连接，无需配置该选项。

2. 绑定集群 IP

在多网卡的环境中，需要显示配置 priority_networks 选项。

```
priority_networks = 10.1.3.0/24
```

这是一种 CIDR 的表示方式，该配置会指定 FE 使用的 IP。在配置 FQDN 的环境中，可以忽略该选项。

3. 调整 FE 内存

在 fe.conf 中，默认 Java 最大堆内存为 8GB，建议生产环境调整至 16G 以上。在 JAVA_OPTS 参数中指定 -Xmx 选项可以调整 Java 最大堆内存。

```
JAVA_OPTS="-Xmx16384m -XX:+UseMembar -XX:SurvivorRatio=8 -XX:MaxTenuringThreshold=7 -
XX:+PrintGCDateStamps -XX:+PrintGCDetails -XX:+UseConcMarkSweepGC -XX:+UseParNewGC -
XX:+CMSClassUnloadingEnabled -XX:-CMSParallelRemarkEnabled -XX:CMSInitiatingOccupancyFraction=80 -
XX:SoftRefLRUPolicyMSPerMB=0 -Xloggc:$DORIS_HOME/log/fe.gc.log.$DATE"
```

4. 修改 Doris 大小写敏感参数 lower_case_table_names

在 Doris 中默认表名大小写敏感。如果有对大小写不敏感的需求，需要在集群初始化时进行设置。表名大小写敏感在集群初始化完成后就无法再进行修改。详细参见 [变量](#) 文档中关于 lower_case_table_names 的介绍。

启动 FE 进程

通过以下命令可以启动 FE 进程

```
bin/start_fe.sh --daemon
```

FE 进程启动进入后台执行。日志默认存放在 log/ 目录下。如启动失败，可以通过查看 log/fe.log 或者 log/fe.out 查看错误信息

检查 FE 启动状态

通过 MySQL Client 可以链接 Doris 集群。初始化用户为 root，密码为空。

```
mysql -uroot -P<fe_query_port> -h<fe_ip_address>
```

链接到 Doris 集群后，可以通过 `show frontends` 命令查看 FE 的状态，通常要确认以下几项

- Alive 为 true 表示节点存活
- Join 为 true 表示节点加入到集群中，但不代表当前还在集群内（可能已失联）
- IsMaster 为 true 表示当前节点为 Master 节点

部署 FE 集群（可选）

在生产集群中，建议至少部署 3 个 Follower 节点。在部署过 FE Master 节点后，需要再部署两个 FE Follower 节点。

创建元数据目录

参考部署 FE Master 节点，创建 `doris-meta` 目录

修改 FE Follower 节点配置文件

参考部署 FE Master 节点，修改 FE 配置文件。通常情况下，可以直接复制 FE Master 节点的配置文件。

在 Doris 集群中注册新的 FE Follower 节点

在启动新的 FE 节点前，需要先在 FE 集群中注册新的 FE 节点。

```
## 链接任一存活的 FE 节点
mysql -uroot -P<fe_query_port> -h<fe_ip_address>

## 注册 FE Follower 节点
## fe_edit_log_port 可以从 fe.conf 中查看，默认为 9010
## 在 MySQL Client 中执行 ALTER SYSTEM 语句
ALTER SYSTEM ADD FOLLOWER "<fe_ip_address>:<fe_edit_log_port>"
```

如果要添加 observer 节点，可以使用 `ADD OBSERVER` 命令

```
## 注册 FE observer 节点，在 MySQL Client 中执行 ALTER SYSTEM 语句
ALTER SYSTEM ADD OBSERVER "<fe_ip_address>:<fe_edit_log_port>"
```

注意

1. FE Follower（包括 Master）节点的数量建议为奇数，建议部署 3 个组成高可用模式。
2. 当 FE 处于高可用部署时（1 个 Master，2 个 Follower），我们建议通过增加 Observer FE 来扩展 FE 的读服务能力
3. 通常一个 FE 节点可以应对 10-20 台 BE 节点。建议总的 FE 节点数量在 10 个以下

启动 FE Follower 节点

通过以下命令，可以启动 FE Follower 节点，并自动同步元数据。

```
bin/start_fe.sh --helper <helper_fe_ip>:<fe_edit_log_port> --daemon
```

其中，`helper_fe_ip` 为当前 FE 集群中任一存活的节点。`--heper` 参数只应用于第一次启动 FE 时同步元数据，后续重启 FE 的操作不需要指定。

判断 follower 节点状态

与判断 FE master 节点状态的方式相同，添加注册 FE follower 节点后需要通过 `show frontends` 命令查看 FE 节点状态。与 Master 状态不同，`IsMaster` 的状态应为 `false`。

部署 BE

创建数据目录

BE 进程应用于数据的计算与存储。数据目录默认放在 `be/storage` 下。在生产环境中，通常使用独立的硬盘来存储数据，将 BE 数据与 BE 的部署文件置于不同的硬盘中。BE 支持数据分布在多盘上以更好的利用多块硬盘的 I/O 能力。

```
## 在每一块数据硬盘上创建 BE 数据存储目录
mkdir -p <be_storage_root_path>
```

修改 BE 配置文件

BE 的配置文件在 BE 部署路径下的 `conf` 目录中，启动 FE 节点前需要修改 `conf/be.conf`。

1. 配置 Java 环境

从 1.2 版本开始 Doris 支持 Java UDF 函数，BE 依赖于 Java 环境。需要预先配置操作系统 `JAVA_HOME` 环境变量，或者在 BE 配置文件中指定 Java 环境变量。

```
## 修改 be/conf/be.conf 的 Java 环境变量
JAVA_HOME = <your-java-home-path>
```

2. 配置 BE 存储路径

如需修改 BE 的存储路径，可以修改 `storage_root_path` 参数。在多路径之间使用英文分号；分隔（最后一个目录不要加分号）。

冷热数据分级存储

Doris 支持冷热数据分级存储，将冷数据存储在 HDD 或对象存储中，热数据存储在 SSD 中。

可以通过路径区别节点内的冷热数据存储目录，HDD（冷数据目录）或 SSD（热数据目录）。如果不需要 BE 节点内的冷热机制，那么只需要配置路径即可，无需指定 `medium` 类型；也不需要修改 FE 的默认存储介质配置。

在使用冷热数据分离功能时，需要在 `storage_root_path` 中使用 `medium` 选项。

```
## 在 storage_root_path 中使用 medium 指定磁盘类型
## /home/disk1/doris,medium:HDD: 表示该目录存储冷数据;
```

```
## /home/disk2/doris,medium:SSD: 表示该目录存储热数据;  
storage_root_path=/home/disk1/doris,medium:HDD;/home/disk2/doris,medium:SSD
```

****注意: ****

1. 当指定存储路径的存储类型时, 至少设置一个路径的存储类型为 HDD;
2. 如未显示声明存储路径的存储类型, 则默认全部为 HDD;
3. 指定 HDD 或 SSD 存储类型与物理存储介质无关, 只为区分存储路径的存储类型, 即可以在 HDD 介质的盘上标记某个目录为 SSD;
4. 存储类型 HDD 和 SSD 关键字须大写。

3. 绑定集群 IP

在多网卡的环境中, 需要显示配置 `priority_networks` 选项。在配置 FQDN 的环境中, 可以忽略该选项。

```
priority_networks = 10.1.3.0/24
```

在 Doris 中注册 BE 节点

在启动新的 BE 节点前, 需要先在 FE 集群中注册新的 BE 节点。

```
## 链接任一存活的 FE 节点  
mysql -uroot -P<fe_query_port> -h<fe_ip_address>  
  
## 注册 BE 节点  
## be_heartbeat_service_port 可以从 be.conf 中查看, 默认为 9050  
## 在 MySQL Client 中执行 ALTER SYSTEM 语句  
ALTER SYSTEM ADD BACKEND "<be_ip_address>:<be_heartbeat_service_port>"
```

启动 BE 进程

通过以下命令可以启动 BE 进程

```
bin/start_be.sh --daemon
```

BE 进程启动进入后台执行。日志默认存放在 `log/` 目录下。如启动失败, 可以通过查看 `log/be.log` 或者 `log/be.out` 查看错误信息

查看 BE 启动状态

在链接到 Doris 集群后, 通过 `show backends` 命令查看 BE 的状态。

```
## 链接 Doris 集群  
mysql -uroot -P<fe_query_port> -h<fe_ip_address>  
  
## 查看 BE 状态, 在 MySQL Client 中执行 show 命令  
show backends;
```


通常情况下需要注意以下几项状态：

- Alive 为 true 表示节点存活
- TabletNum 表示该节点上的分片数量，新加入的节点会进行数据均衡，TabletNum 逐渐趋于平均

验证集群正确性

登录数据库

通过 MySQL Client 登录 Doris 集群。

```
## 链接 Doris 集群
mysql -uroot -P<fe_query_port> -h<fe_ip_address>
```

检查 Doris 安装版本

通过 show frontends 与 show backends 命令可以查看数据库版本情况。

```
## 查看 FE 各实例的版本，在 MySQL Client 中执行 show 命令
show frontends \G

## 查看 BE 各实例的版本，在 MySQL Client 中执行 show 命令
show backends \G
```

修改 Doris 集群密码

在创建 Doris 集群后，系统会自动创建 root 用户，并默认密码为空。建议在创建集群后为 root 用户重置一个新密码。

```
## 确认当前用户为 root，在 MySQL Client 中查看当前用户
select user();
+-----+
| user() |
+-----+
| 'root'@'192.168.88.30' |
+-----+

## 修改 root 用户密码，在 MySQL Client 中执行 set password 命令
SET PASSWORD = PASSWORD('doris_new_passwd');
```

创建测试表并插入数据

在新创建的集群中，可以创建表并插入数据以验证集群正确性。

```
## 创建测试数据库，在 MySQL Client 中执行 create database 语句
create database testdb;

## 创建测试表，在 MySQL Client 中执行 create table 语句
CREATE TABLE testdb.table_hash
(
    k1 TINYINT,
    k2 DECIMAL(10, 2) DEFAULT "10.5",
    k3 VARCHAR(10) COMMENT "string column",
    k4 INT NOT NULL DEFAULT "1" COMMENT "int column"
```

```
)  
COMMENT "my first table"  
DISTRIBUTED BY HASH(k1) BUCKETS 32;
```

Doris 兼容 MySQL 协议，可以使用 insert 语句插入数据。

```
## 插入部分测试数据，在 MySQL Client 中执行 insert into 语句  
INSERT INTO testdb.table_hash VALUES  
(1, 10.1, 'AAA', 10),  
(2, 10.2, 'BBB', 20),  
(3, 10.3, 'CCC', 30),  
(4, 10.4, 'DDD', 40),  
(5, 10.5, 'EEE', 50);
```

```
## 验证插入数据正确性，在 MySQL Client 中执行 select 语句  
SELECT * from testdb.table_hash;
```

k1	k2	k3	k4
3	10.30	CCC	30
4	10.40	DDD	40
5	10.50	EEE	50
1	10.10	AAA	10
2	10.20	BBB	20

5 常见问题

什么是 priority_networks?

Doris 进程监听 IP 的 CIDR 格式表示的网段。如果部署的机器只有一个网段，可以不用配置。如果有两个或多个网段，务必做配置。

这个参数主要用于帮助系统选择正确的网卡 IP 作为自己的监听 IP。比如需要监听的 IP 为 192.168.0.1，则可以设置 priority_networks=192.168.0.0/24，系统会自动扫描机器上的所有 IP，只有匹配上 192.168.0.0/24 这个网段的才会去作为服务监听地址。这个参数也可以配置多个 CIDR 网段，比如 priority_networks = 10.10.0.0/16; 192.168.0.0/24。

****为什么采用 priority_networks 来配置监听地址段，为啥不直接在配置文件中设置监听的 IP 地址？****

主要的原因是 Doris 作为一个分布式集群，同样的配置文件会在多个节点上部署，为了部署和更新等维护的方便性，尽量所有节点的配置文件一致。采用这种配置监听地址网段，然后启动的时候，依据这个网段去找到合适的监听 IP，这样就解决了每个机器在这个配置上都可以使用一个值的需求了。

新的 BE 节点需要手动添加到集群

BE 节点启动后，还需要通过 MySQL 协议或者内置的 Web 控制台，向 FE 发送命令，将启动的这个 BE 节点加入到集群。

FE 如何知道这个集群有哪些 BE 节点组成？

Doris 作为一个分布式数据库，一般拥有众多 BE 节点，Doris 采用通过向 FE 发送添加 BE 节点的命令来添加相应的 BE，这个不同于 BE 节点自己知道 FE 节点的地址，然后主动汇报连接的方式。采用主动添加，FE 主动连接 BE 的方式，可以给集群管理带来更多益处，比如确定集群到底有哪些节点组成，比如可以主动下掉一个无法连接上的 BE 节点。

如何快速检测 FE 启动成功

可以通过下面的命令来检查 Doris 是否启动成功


```
# 重试执行下面命令，如果返回"msg":"success"，则说明已经启动成功
server1:apache-doris/fe doris$ curl http://127.0.0.1:8030/api/bootstrap
{"msg":"success","code":0,"data":{"replayedJournalId":0,"queryPort":0,"rpcPort":0,"version":""},"count":0}
```

Doris 提供内置的 Web UI 吗？

Doris FE 内置 Web UI。用户无须安装 MySQL 客户端，即可通过 Web UI 来完成诸如添加 BE/FE 节点，以及运行其它 SQL 查询。

在浏览器中输入 `http://fe_ip:fe_port`，比如 `http://172.20.63.118:8030`，打开 Doris 内置的 Web 控制台。

内置 Web 控制台，主要供集群 root 账户使用，默认安装后 root 账户密码为空。



内置 Web 控制台

比如，在 Playground 中，执行如下语句，可以完成对 BE 节点的添加。

```
ALTER SYSTEM ADD BACKEND "be_host_ip:heartbeat_service_port";
```

 **DORIS**

Playground

SystemLogQueryProfileSessionConfiguration

中文root

Search

default_cluster: __internal_schema

default_cluster: information_schema

default_cluster: mysql

EditorFormat

Clear the editor

Current Database: __internal_schema

1 这里的ip和port, 需要改为你的BE节点的ip和heartbeat_service_port

2 ALTER SYSTEM ADD BACKEND "172.20.63.118:9050";

Execute

Results

Run successfully

ALTER SYSTEM ADD BACKEND "172.20.63.118:9050";

Execution18 ms

Time:

Total 0 items < 1 > 20 / page

Playground

Playground 中执行这种和具体数据库/表没有关系的语句，务必在左侧库栏里随意选择一个数据库，才能执行成功，这个限制，稍后会去掉。

通过 Web UI 无法修改 root 密码

当前内置的 Web 控制台，还不能执行 SET 类型的 SQL 语句，所以，在 Web 控制台，当前还不能通过执行 SET PASSWORD FOR 'root' = PASSWORD('your_password') `类似语句来修改 root 的密码，可以通过 MySQL Client 来修改 root 账户的密码。

Docker 部署

该文档主要介绍了如何通过 Dockerfile 来制作 Apache Doris 的运行镜像，以便于在容器化编排工具或者快速测试过程中可迅速拉取一个 Apache Doris Image 来完成集群的创建和运行。

软硬件要求

概述

Docker 镜像在制作前要提前做好制作机器，该机器的平台架构决定了制作以后的 Docker Image 适用的平台架构，如 X86_64 机器，需要下载 X86_64 的 Doris 二进制程序，制作以后的 Image 仅可在 X86_64 平台上运行。ARM64 平台同理。

硬件要求

推荐配置：4 核 16GB 内存

软件要求

Docker Version：20.10 及以后版本

Image 构建

构建前注意

Dockerfile 脚本编写注意

- 基础父镜像选用经过 Docker-Hub 认证的 OpenJDK 官方镜像，版本用 JDK 1.8 版本，推荐基础父镜像：`openjdk:8u342-jdk`；
- 需要内嵌脚本来完成 FE 的启动、多 FE 注册、状态检查和 BE 的启动、注册 BE 至 FE、状态检查等任务流程；
- 应用程序在 Docker 内启动时不建议使用 `--daemon` 的方式启动，否则在 K8s 等编排工具部署过程中会有异常。

构建方式

编译 Docker Image 的 Dockerfile 脚本中，关于 Apache Doris 程序二进制包的加载方式，有两种：

- 通过 `wget / curl` 在编译时执行下载命令，随后完成 Docker Build 制作过程
- 提前下载二进制包至编译目录，然后通过 `ADD` 或者 `COPY` 命令加载至 Docker Build 过程中

使用前者会让 Docker Image Size 更小，但是如果构建失败的话可能下载操作会重复进行，导致构建时间过长，而后者更适用于网络环境不是很好的构建环境。这里以第二种方式进行示例。

构建 FE 镜像

1. 构建 FE 镜像的环境目录

构建环境目录如下

```
└─ docker-build                                // 构建根目录
  └─ fe                                          // Doris 构建目录
    ├── dockerfile                             // Dockerfile 脚本
    └── resource                               // 资源目录
      ├── init_fe.sh                           // FE 启动及注册脚本
      └── apache-doris-2.0.3-bin.tar.gz        // 二进制程序包
```

2. 下载二进制包

下载[官方二进制包](#)/编译的二进制包，然后覆盖 `./docker-build/fe/resource` 中的 `apache-doris` 安装包。

3. 编写 Dockerfile

```
# 选择基础镜像
FROM openjdk:8u342-jdk

# 设置环境变量
ENV JAVA_HOME="/usr/local/openjdk-8/"
ENV PATH="/opt/apache-doris/fe/bin:$PATH"

# 下载软件至镜像内，可根据需要替换
ADD ./resource/apache-doris-2.0.3-bin.tar.gz /opt/

RUN apt-get update && \
    apt-get install -y default-mysql-client && \
    apt-get clean && \
    mkdir /opt/apache-doris && \
    cd /opt && \
    mv apache-doris-2.0.3-bin/fe /opt/apache-doris/

ADD ./resource/init_fe.sh /opt/apache-doris/fe/bin
RUN chmod 755 /opt/apache-doris/fe/bin/init_fe.sh

ENTRYPOINT ["/opt/apache-doris/fe/bin/init_fe.sh"]
```

- 编写后命名为 `Dockerfile` 并保存至 `./docker-build/fe` 目录下
- FE 的执行脚本 `init_fe.sh` 的内容可以参考 Doris 源码库中的 [init_fe.sh](#) 的内容

4. 执行构建

需要注意的是，`${tagName}` 需替换为你想要打包命名的 tag 名称，如：`apache-doris:2.0.3-fe`

```
cd ./docker-build/fe
docker build . -t ${fe-tagName}
```

构建 BE 镜像

1. 构建环境目录如下：

```
└─ docker-build                                // 构建根目录
  └─ be                                         // BE 构建目录
    ├── dockerfile                             // dockerfile 脚本
    └─ resource                                // 资源目录
      ├── init_be.sh                           // 启动及注册脚本
      └─ apache-doris-2.0.3-bin.tar.gz         // 二进制程序包
```

2. 编写 BE 的 Dockerfile 脚本

```
# 选择基础镜像
FROM openjdk:8u342-jdk

# 设置环境变量
ENV JAVA_HOME="/usr/local/openjdk-8/"
ENV PATH="/opt/apache-doris/be/bin:$PATH"

# 下载软件至镜像内，可根据需要替换
ADD ./resource/apache-doris-2.0.3-bin.tar.gz /opt/

RUN apt-get update && \
    apt-get install -y default-mysql-client && \
    apt-get clean && \
    mkdir /opt/apache-doris && \
    cd /opt && \
    mv apache-doris-2.0.3-bin/be /opt/apache-doris/

ADD ./resource/init_be.sh /opt/apache-doris/be/bin
RUN chmod 755 /opt/apache-doris/be/bin/init_be.sh

ENTRYPOINT ["/opt/apache-doris/be/bin/init_be.sh"]
```

- 编写后命名为 Dockerfile 并保存至 ./docker-build/be 目录下
- 编写 BE 的执行脚本，可参考复制 [init_be.sh](#) 的内容

3. 执行构建

需要注意的是，`${tagName}` 需替换为你想要打包命名的 tag 名称，如：apache-doris:2.0.3-be

```
cd ./docker-build/be
docker build . -t ${be-tagName}
```

推送镜像至 DockerHub 或私有仓库

登录 DockerHub 账号

```
docker login
```

登录成功会提示 Success 相关提示，随后推送至仓库即可

```
docker push ${tagName}
```

部署 Docker 集群

这里将简述如何通过 docker run 或 docker-compose up 命令快速构建一套完整的 Doris 测试集群。

在生产环境上，当前尽量避免使用容器化的方案进行 Doris 部署，在 K8s 中部署 Doris，请采用 Doris Operator 来部署。

前期环境准备

软件环境

软件	版本
Docker	20.0 及以上
docker-compose	20.1 及以上

硬件环境

配置类型	硬件信息	最大运行集群规模
最低配置	2C 4G	1FE 1BE
推荐配置	4C 16G	3FE 3BE

在宿主机执行如下命令

```
sysctl -w vm.max_map_count=2000000
```

Docker Compose

不同平台需要使用不同 Image 镜像，本篇以 X86_64 平台为例。

网络模式说明

Doris Docker 适用的网络模式有两种。

- 适合跨多节点部署的 HOST 模式，这种模式适合每个节点部署 1 FE 1 BE。
- 适合单节点部署多 Doris 进程的子网网桥模式，这种模式适合单节点部署（推荐），若要多节点混部需要做更多组件部署（不推荐）。

为便于展示，本章节仅演示子网网桥模式编写的脚本。

接口说明

从 Apache Doris 2.0.3 Docker Image 版本起，各个进程镜像接口列表如下：

进程名	接口名	接口定义	接口示例
FE	BE	BROKER	FE_SERVERS
FE	FE_ID	FE 节点 ID	1
BE	BE_ADDR	BE 节点主要信息	172.20.80.5:9050

进程名	接口名	接口定义	接口示例
BE	NODE_ROLE	BE 节点类型	computation

注意，以上接口必须填写信息，否则进程无法启动。

- FE_SERVERS 接口规则为：

FE_NAME:FE_HOST:FE_EDIT_LOG_PORT[,FE_NAME:FE_HOST:FE_EDIT_LOG_PORT]

- FE_ID 接口规则为：1-9 的整数，其中 1 号 FE 为 Master 节点。
- BE_ADDR 接口规则为：BE_HOST:BE_HEARTBEAT_SERVICE_PORT
- NODE_ROLE 接口规则为：computation 或为空，其中为空或为其他值时表示节点类型为 mix 类型
- BROKER_ADDR 接口规则为：BROKER_HOST:BROKER_IPC_PORT

脚本模板

1. Docker Run 命令

1 FE & 1 BE 命令模板

注意需要修改 \${当前机器的内网IP} 替换为当前机器的内网 IP

```
docker run -itd \
--name=fe \
--env FE_SERVERS="fe1:${当前机器的内网IP}:9010" \
--env FE_ID=1 \
-p 8030:8030 \
-p 9030:9030 \
-v /data/fe/doris-meta:/opt/apache-doris/fe/doris-meta \
-v /data/fe/log:/opt/apache-doris/fe/log \
--net=host \
apache/doris:2.0.3-fe-x86_64

docker run -itd \
--name=be \
--env FE_SERVERS="fe1:${当前机器的内网IP}:9010" \
--env BE_ADDR="${当前机器的内网IP}:9050" \
-p 8040:8040 \
-v /data/be/storage:/opt/apache-doris/be/storage \
-v /data/be/log:/opt/apache-doris/be/log \
--net=host \
apache/doris:2.0.3-be-x86_64
```

3 FE & 3 BE Run 命令模板如有需要[点击此处](#)访问下载。

2. Docker Compose 脚本

1 FE & 1 BE 模板

注意需要修改 \${当前机器的内网IP} 替换为当前机器的内网 IP

```
version: "3"
services:
  fe:
    image: apache/doris:2.0.3-fe-x86_64
    hostname: fe
    environment:
      - FE_SERVERS=fe1:${当前机器的内网IP}:9010
      - FE_ID=1
    volumes:
      - /data/fe/doris-meta:/opt/apache-doris/fe/doris-meta/
      - /data/fe/log:/opt/apache-doris/fe/log/
    network_mode: host
  be:
    image: apache/doris:2.0.3-be-x86_64
    hostname: be
    environment:
      - FE_SERVERS=fe1:${当前机器的内网IP}:9010
      - BE_ADDR=${当前机器的内网IP}:9050
    volumes:
      - /data/be/storage:/opt/apache-doris/be/storage/
      - /data/be/script:/docker-entrypoint-initdb.d/
    depends_on:
      - fe
    network_mode: host
```

3 FE & 3 BE Docker Compose 脚本模板如有需要[点击此处](#)访问下载。

部署 Doris Docker

部署方式二选一即可：

1. 执行 `docker run` 命令创建集群
2. 保存 `docker-compose.yaml` 脚本，同目录下执行 `docker-compose up -d` 命令创建集群

集群环境要求

软件版本要求

软件	版本要求
Docker	>= 1.20
Kubernetes	>= 1.19
Doris	>= 2.0.0
Helm（可选）	>= 3.7

操作系统要求

防火墙配置

在 Kubernetes 上部署 Doris 集群，建议关闭防火墙配置：

```
systemctl stop firewalld
systemctl disable firewalld
```

如果无法关闭防火墙服务，可以根据规划，打开 FE 与 BE 端口：

提示

如果无法关闭防火墙，需要根据 Kubernetes 映射规则打开 Doris 相应端口的防火墙。具体端口可以参考[Doris 集群端口规划](#)。

禁用和关闭 swap

在部署 Doris 时，建议关闭 swap 分区。

通过以下命令可以永久关闭 swap 分区。

```
echo "vm.swappiness = 0">> /etc/sysctl.conf
swapoff -a && swapon -a
sysctl -p
```

设置系统最大打开文件句柄数

```
vi /etc/security/limits.conf
* soft nfile 65536
* hard nfile 65536
```

修改虚拟内存区域数量

修改虚拟内存区域至少 2000000

```
sysctl -w vm.max_map_count=2000000
```

关闭透明大页

在部署 Doris 时，建议关闭透明大页。

```
echo madvise > /sys/kernel/mm/transparent_hugepage/enabled  
echo madvise > /sys/kernel/mm/transparent_hugepage/defrag
```

部署 Doris Operator

添加 Doris Cluster 资源定义

Doris Operator 使用自定义资源定义 (Custom Resource Definition, CRD) 扩展 Kubernetes。Doris Cluster 的 CRD 中封装了对 Doris 对象的描述，例如对 FE 或 BE 的描述，详细内容可以参考 [doris-operator-api](#)。在部署 Doris 前，需要先创建 Doris Cluster 的 CRD。

通过以下命令可以在 Kubernetes 环境中部署 Doris Cluster CRD：

```
kubectl create -f https://raw.githubusercontent.com/apache/doris-operator/master/config/crd/bases/doris.selectdb.com_dorisclusters.yaml
```

如果没有外网，先将 CRD 文件下载到本地：

```
wget https://raw.githubusercontent.com/apache/doris-operator/master/config/crd/bases/doris.selectdb.com_dorisclusters.yaml
kubectl create -f ./doris.selectdb.com_dorisclusters.yaml
```

以下是期望输出结果：

```
customresourcedefinition.apiextensions.k8s.io/dorisclusters.doris.selectdb.com created
```

在创建了 Doris Cluster CRD 后，可以通过以下命令查看创建的 CRD。

```
kubectl get crd | grep doris
```

以下为期望输出结果：

```
dorisclusters.doris.selectdb.com          2024-02-22T16:23:13Z
```

添加 Doris Operator

方案一：快速部署 Doris Operator

可以直接拉去仓库中的 Doris Operator 模板进行快速部署。

使用以下命令可以在 Kubernetes 集群中部署 Doris Operator：

```
kubectl apply -f https://raw.githubusercontent.com/apache/doris-operator/master/config/operator/operator.yaml
```

以下为期望输出结果：

```
namespace/doris created
role.rbac.authorization.k8s.io/leader-election-role created
```

```
rolebinding.rbac.authorization.k8s.io/leader-election-rolebinding created
clusterrole.rbac.authorization.k8s.io/doris-operator created
clusterrolebinding.rbac.authorization.k8s.io/doris-operator-rolebinding created
serviceaccount/doris-operator created
deployment.apps/doris-operator created
```

方案二：自定义部署 Doris Operator

在创建完 CRD 后，在 Kubernetes 集群上部署 Doris Operator 有两种方式：在线与离线部署。

在 operator.yaml 文件中规范了部署 operator 的服务的最低要求。为了适配复杂的生产环境，可以下载 operator.yaml 文件后，按照期望更新其中配置。

在线安装 Doris Operator

在修改 operator.yaml 文件后，可以使用以下命令部署 Doris Operator 服务：

```
kubectl apply -f ./operator.yaml
```

以下为期望输出结果：

```
namespace/doris created
role.rbac.authorization.k8s.io/leader-election-role created
rolebinding.rbac.authorization.k8s.io/leader-election-rolebinding created
clusterrole.rbac.authorization.k8s.io/doris-operator created
clusterrolebinding.rbac.authorization.k8s.io/doris-operator-rolebinding created
serviceaccount/doris-operator created
deployment.apps/doris-operator created
```

离线安装 Doris Operator

1. 下载 operator 运行所需镜像文件

如果服务器没有连通外网，需要先下载对应的 operator 镜像文件。Doris Operator 用到以下的镜像：

```
selectdb/doris.k8s-operator:latest
```

在可以连通外网的服务器中运行以下的命令，可以将镜像下载下来：

```
## download doris operator image
docker pull selectdb/doris.k8s-operator:latest
## save the doris operator image as a tar package
docker save -o doris.k8s-operator-latest.tar selectdb/doris.k8s-operator:latest
```

将已打包的 tar 文件放置到所有的 Kubernetes node 节点中，运行以下命令上传镜像：

```
docker load -i doris.k8s-operator-latest.tar
```

2. 配置 Doris Operator

下载 operator.yaml 文件后，可以根据生产环境期望修改模板。

Doris Operator 在 Kubernetes 集群中是一个无状态的 Deployment，可以根据需求修改如 limits、replica、label、namespace 等项目。如需要指定某一版本的 doris operator 镜像，可以在上传镜像后对 operator.yaml 文件做如下修改：

```
...
containers:
  - command:
    - /dorisoperator
    args:
    - --leader-elect
    image: selectdb/doris.k8s-operator:v1.0.0
    name: dorisoperator
    securityContext:
      allowPrivilegeEscalation: false
      capabilities:
        drop:
        - "ALL"
    ...
```

3. 安装 Doris Operator

在修改 Doris Operator 模板后，可以使用 apply 命令部署 Operator：

```
kubectl apply -f ./operator.yaml
```

以下为期望输出结果：

```
namespace/doris created
role.rbac.authorization.k8s.io/leader-election-role created
rolebinding.rbac.authorization.k8s.io/leader-election-rolebinding created
clusterrole.rbac.authorization.k8s.io/doris-operator created
clusterrolebinding.rbac.authorization.k8s.io/doris-operator-rolebinding created
serviceaccount/doris-operator created
deployment.apps/doris-operator created
```

方案三：Helm 部署 Doris Operator

Helm Chart 是一系列描述 Kubernetes 相关资源的 YAML 文件的封装。通过 Helm 部署应用时，你可以自定义应用的元数据，以便于分发应用。Chart 是 Helm 的软件包，采用 TAR 格式，用于部署 Kubernetes 原生应用程序。通过 Helm Chart 可以简化部署 Doris 集群的流程。

1. 添加部署仓库

在线添加仓库

通过 repo add 命令添加远程仓库

```
helm repo add doris-repo https://charts.selectdb.com
```

通过 repo update 命令更新最新版本的 chart

```
helm repo update doris-repo
```

2. 安装 Doris Operator

通过 `helm install` 命令可以使用默认配置在 `doris` 的 namespace 中安装 Doris Operator

```
helm install operator doris-repo/doris-operator
```

如果需要自定义装配 [values.yaml](#)，可以参考如下命令：

```
helm install -f values.yaml operator doris-repo/doris-operator
```

通过 `kubectl get pods` 命令查看 Pod 的部署状态。当 Doris Operator 的 Pod 处于 Running 状态且 Pod 内所有容器都已经就绪，即部署成功。

```
kubectl get pod --namespace doris
```

返回结果如下：

NAME	READY	STATUS	RESTARTS	AGE
doris-operator-866bd449bb-zl5mr	1/1	Running	0	18m

离线添加仓库

如果服务器无法连接外网，需要预先下载 Doris Operator 与 Doris Cluster 的 chart 资源。

1. 下载离线 chart 资源

下载 `doris-operator-{chart_version}.tgz` 安装 Doris Operator chart。如需要下载 1.4.0 版本的 Doris Operator 可以使用以下命令：

```
wget https://charts.selectdb.com/doris-operator-1.4.0.tgz
```

2. 安装 Doris Operator

通过 `helm install` 命令可以安装 Doris Operator。

```
helm install operator doris-operator-1.4.0.tgz
```

如果需要自定义装配 [values.yaml](#)，可以参考如下命令：

```
helm install -f values.yaml operator doris-operator-1.4.0.tgz
```

通过 `kubectl get pods` 命令查看 Pod 的部署状态。当 Doris Operator 的 Pod 处于 Running 状态且 Pod 内所有容器都已经就绪，即部署成功。

```
kubectl get pod --namespace doris
```

返回结果如下：

NAME	READY	STATUS	RESTARTS	AGE
doris-operator-866bd449bb-zl5mr	1/1	Running	0	18m

查看服务状态

当部署 Operator 服务后，可以通过以下命令查看服务状态。

```
kubectl get pod -n doris
```

返回结果如下：

NAME	READY	STATUS	RESTARTS	AGE
doris-operator-6f47594455-p5tp7	1/1	Running	0	11s

需要确保 STATUS 状态为 Running，且 pod 中所有容器的状态都为 Ready。

配置 Doris 集群

配置数据及持久化存储

在 Doris 集群中，包括 FE、BE、CN 和监控组件在内的组件都需要将数据持久化到物理存储中。Kubernetes 提供了 [Persistent Volumes](#) 的能力将数据持久化到物理存储中。在 Kubernetes 环境中，主要存在两种类型的 Persistent Volumes：

- 本地 PV 存储 (Local Persistent Volumes)：本地 PV 是 Kubernetes 直接使用宿主机的本地磁盘目录来持久化存储容器的数据。本地 PV 提供更小的网络延迟，在使用 SSD 等高性能硬盘时，可以提供更好的读写能力。由于本地 PV 与宿主机绑定，在宿主机出现故障时，本地 PV 进行故障漂移。
- 网络 PV 存储 (Network Persistent Volumes)：网络 PV 是通过网络访问的存储资源。网络 PV 可以被集群中的任一节点访问，在宿主机出现故障时，网络 PV 可以挂载到其他节点继续使用。

StorageClass 可以用于定义 PV 的类型和行为，通过 StorageClass 可以将磁盘资源与容器解耦，从而实现数据的持久性与可靠性。在 Doris Operator 中，在 Kubernetes 上部署 Doris，可以支持本地 PV 与网络 PV，可以根据业务需求进行选择。

注意

建议在部署时将数据持久化到存储中。如果部署时未配置 PersistentVolumeClaim，Doris Operator 默认会使用 emptyDir 模式来存储元数据、数据以及日志。当 pod 重启时，相关数据会丢失掉。

持久化目录类型

在 Doris 中，建议持久化存储以下目录：

- FE 节点：doris-meta、log
- BE 节点：storage、log
- CN 节点：storage、log
- Broker 节点：log

在 Doris 中存在多种日志类型，如 INFO 日志、OUT 日志、GC 日志以及审计日志。Doris Operator 可以将日志同时输出到 console 与指定目录下。如果用户的 Kubernetes 有完整的日志收集能力，可以通过 console 输出来收集 Doris 的 INFO 日志。建议将 Doris 的所有日志通过 PVC 配置持久化到指定存储中，这将有助于问题的定位与排查。

数据持久化到网络 PV

Doris Operator 使用 Kubernetes 默认的 StorageClass 来支持 FE 与 BE 的存储。在 DorisCluster 的 CR 中，通过修改 StorageClass 指定 persistentVolumeClaimSpec.storageClassName，可以配置指定的网络 PV。

```
persistentVolumes:
- mountPath: /opt/apache-doris/fe/doris-meta
  name: storage0
  persistentVolumeClaimSpec:
```

```
# when use specific storageclass, the storageClassName should reConfig, example as annotation.
storageClassName: ${your_storageclass}
accessModes:
- ReadWriteOnce
resources:
  # notice: if the storage size less 5G, fe will not start normal.
  requests:
    storage: 100Gi
```

FE 配置持久化存储

在部署集群时，建议对 FE 中的 doris-meta 与 log 目录做持久化存储。doris-meta 用户存放元数据，一般在几百 MB 到几十 GB，建议预留 100GB。log 目录用来存放 FE 日志，一般建议预留 50GB。

下例中 FE 使用 StorageClass 挂载了元数据存储与日志存储：

```
feSpec:
  persistentVolumes:
  - name: fe-meta
    mountPath: /opt/apache-doris/fe/doris-meta
    persistentVolumeClaimSpec:
      storageClassName: ${storageClassName}
      accessModes:
      - ReadWriteOnce
      resources:
        requests:
          storage: 50Gi
  - name: fe-log
    mountPath: /opt/apache-doris/fe/log
    persistentVolumeClaimSpec:
      storageClassName: ${storageClassName}
      accessModes:
      - ReadWriteOnce
      resources:
        requests:
          storage: 100Gi
```

其中，需要在 \${storageClassName} 指定 [StorageClass](#) 的名称。可以通过 以下命令查看当前 Kubernetes 集群内支持的 StorageClass：

```
kubectll get sc
```

返回结果如下：

NAME	PROVISIONER	RECLAIMPOLICY	VOLUMEBINDINGMODE
ALLOWVOLUMEEXPANSION AGE			
openebs-hostpath 212d	openebs.io/local	Delete	WaitForFirstConsumer false
openebs-device 212d	openebs.io/local	Delete	WaitForFirstConsumer false
openebs-jiva-csi-default 212d	jiva.csi.openebs.io	Delete	Immediate true
local-storage 149d	kubernetes.io/no-provisioner	Delete	WaitForFirstConsumer false
microk8s-hostpath (default) 219d	microk8s.io/hostpath	Delete	Immediate false
doris-storage 54d	openebs.io/local	Delete	WaitForFirstConsumer false

提示

可以通过配置 [ConfigMap](#) 修改默认的元数据路径与日志路径：1. fe-meta 的 mounthPath 配置需要与 ConfigMap 中的 meta_dir 变量配置路径一致，默认情况下元数据会写入 /opt/apache-doris/fe/doris-meta 目录下；2. fe-log 的 mounthPath 配置需要与 ConfigMap 中的 LOG_DIR 变量路径一致，默认情况下日志数据会写入到 /opt/apache-doris/fe/log 目录下。

BE 配置持久化存储

在部署集群时，建议对 BE 中的 storage 与 log 目录做持久化存储。storage 用户存放数据，需要根据业务数据量衡量。log 目录用来存放 FE 日志，一般建议预留 50GB。

下例中 BE 使用 StorageClass 挂载了数据存储与日志存储：

```
beSpec:
  persistentVolumes:
  - mountPath: /opt/apache-doris/be/storage
    name: be-storage
    persistentVolumeClaimSpec:
      storageClassName: {storageClassName}
      accessModes:
      - ReadWriteOnce
    resources:
      requests:
        storage: 1Ti
  - mountPath: /opt/apache-doris/be/log
    name: belong
    persistentVolumeClaimSpec:
      storageClassName: {storageClassName}
      accessModes:
      - ReadWriteOnce
    resources:
      requests:
        storage: 100Gi
```

集群部署配置

集群名称

可以通过修改 DorisCluster Custom Resource 中的 metadata.name 来配置集群名称。

镜像版本

在部署 Doris 集群时，可以指定集群的版本。部署集群时应该保证集群中的各个组件版本一致。通过修改 spec.{feSpec|beSpec}.image 配置各个组件的版本。

集群拓扑

在部署 Doris 集群前，需要根据业务规划集群的拓扑结构。可以通过修改 spec.{feSpec|beSpec}.replicas 配置各个组件的节点数。基于生产节点的数据高可用原则，Doris Operator 规定集群中 Kubernetes 集群中至少有 3 个节点。同时，为了保证集群的可用性，建议至少部署 3 个 FE 与 BE 节点。

服务配置

Kubernetes 提供不同的 Service 方式暴露 Doris 的对外访问接口，如 ClusterIP、NodePort、LoadBalancer 等。

ClusterIP

ClusterIP 类型的 service 会在集群内部创建虚拟 IP。通过 ClusterIP 只能在 Kubernetes 集群内访问，对外不可见。在 Doris Custom Resource 中，默认使用 ClusterIP 类型的 Service。

NodePort

在没有 LoadBalancer 时，可以通过 NodePort 暴露。NodePort 是通过节点的 IP 和静态端口暴露服务。通过请求 NodeIP + NodePort，可以从集群的外部访问一个 NodePort 服务。

```
...
feSpec:
  replicas: 3
  service:
    type: NodePort
...
beSpec:
  replicas: 3
  service:
    type: NodePort
...
```

集群参数配置

Doris 在 Kubernetes 使用 ConfigMap 实现配置文件和服务解耦。Doris 组件的所有节点在 Kubernetes 使用 ConfigMap 作为统一化配置管理，组件的所有节点都使用相同的配置信息启动。在 ConfigMap 中使用键值对的方式存储 Doris 的系统参数。在部署 doris 集群时，需要提前在相同 namespace 下部署 ConfigMap。

在 Doris Cluster 的 CR 中，提供 ConfigMapInfo 定义给各个组件挂载配置信息。ConfigMapInfo 包含两个变量：

- ConfigMapName 表示想要使用的 ConfigMap 的名称
- ResolveKey 表示对应的配置文件，FE 配置选择 fe.conf，BE 配置选择 be.conf

FE ConfigMap

定义 FE ConfigMap

在使用 ConfigMap 定义 FE 配置时，需要先定义并下发 ConfigMap 到 Kubernetes 集群中。

下例中定义了名为 fe-conf 的 ConfigMap：

```
apiVersion: v1
kind: ConfigMap
metadata:
  name: fe-conf
  labels:
    app.kubernetes.io/component: fe
data:
  fe.conf: |
    CUR_DATE=`date +%Y%m%d-%H%M%S`
```

```

# the output dir of stderr and stdout
LOG_DIR = ${DORIS_HOME}/log

JAVA_OPTS="-Djavax.security.auth.useSubjectCredsOnly=false -Xss4m -Xmx8192m -XX:+UseMembar -
XX:SurvivorRatio=8 -XX:MaxTenuringThreshold=7 -XX:+PrintGCDateStamps -XX:+PrintGCDetails -
XX:+UseConcMarkSweepGC -XX:+UseParNewGC -XX:+CMSClassUnloadingEnabled -XX:-CMSParallelRemarkEnabled -
XX:CMSInitiatingOccupancyFraction=80 -XX:SoftRefLRUPolicyMSPerMB=0 -
Xloggc:${DORIS_HOME}/log/fe.gc.log.$CUR_DATE"

# For jdk 9+, this JAVA_OPTS will be used as default JVM options
JAVA_OPTS_FOR_JDK_9="-Djavax.security.auth.useSubjectCredsOnly=false -Xss4m -Xmx8192m -XX:SurvivorRatio=8
-XX:MaxTenuringThreshold=7 -XX:+CMSClassUnloadingEnabled -XX:-CMSParallelRemarkEnabled -
XX:CMSInitiatingOccupancyFraction=80 -XX:SoftRefLRUPolicyMSPerMB=0 -
Xlog:gc*:${DORIS_HOME}/log/fe.gc.log.$CUR_DATE:time"

# INFO, WARN, ERROR, FATAL
sys_log_level = INFO

# NORMAL, BRIEF, ASYNC
sys_log_mode = NORMAL

# Default dirs to put jdbc drivers,default value is ${DORIS_HOME}/jdbc_drivers
# jdbc_drivers_dir = ${DORIS_HOME}/jdbc_drivers

http_port = 8030
rpc_port = 9020
query_port = 9030
edit_log_port = 9010
enable_fqdn_mode = true

```

其中，在 `metadata.name` 中定义 FE ConfigMap 的名字，在 `data` 中定义 `fe.conf` 中的数据库配置。自己配置的 `fe.conf` 一定要添加 `enable_fqdn_mode = true`

提示

在 ConfigMap 中使用 `data` 字段存储键值对。在上述 FE ConfigMap 中：- `fe.conf` 是键值对中的 key，使用 `|` 表示将保留后续字符串中的换行符和缩进 - 后续配置为键值对中的 value，与 `fe.conf` 文件中的配置相同在 `data` 字段中，由于使用了 `|` 符号保留后续字符串格式，后续的配置中需要保持两个空格缩进。

在定义 FE ConfigMap 后，需要通过 `kubectl apply` 命令下发。

使用 FE ConfigMap

如果需要使用 FE ConfigMap，需要再 Doris Cluster 的 RC 中通过 `spec.feSpec.configMapInfo` 指定定义的 ConfigMap。

```

kind: DorisCluster
metadata:
  name: doriscluster-sample-configmap
spec:
  feSpec:
    configMapInfo:
      configMapName: {feConfigMapName}
      resolveKey: fe.conf
  ...

```

将上例中的 `{feConfigMapName}` 替换为 `fe-conf` 表示使用上例中定义的 FE ConfigMap。对于 FE ConfigMap，需要保持 `resolveKey` 字段固定为 `fe.conf`。

BE ConfigMap

定义 BE ConfigMap

在使用 ConfigMap 定义 BE 配置时，需要先定义并下发 ConfigMap 到 Kubernetes 集群中。

下例中定义了名为 `be-conf` 的 ConfigMap：

```
apiVersion: v1
kind: ConfigMap
metadata:
  name: be-conf
  labels:
    app.kubernetes.io/component: be
data:
  be.conf: |
    CUR_DATE=`date +%Y%m%d-%H%M%S`

    PPROF_TMPDIR="$DORIS_HOME/log/"

    JAVA_OPTS="-Xmx1024m -DlogPath=$DORIS_HOME/log/jni.log -Xloggc:$DORIS_HOME/log/be.gc.log.$CUR_DATE -
Djavax.security.auth.useSubjectCredsOnly=false -Dsun.java.command=DorisBE -XX:-CriticalJNINatives -
DJDBC_MIN_POOL=1 -DJDBC_MAX_POOL=100 -DJDBC_MAX_IDLE_TIME=300000 -DJDBC_MAX_WAIT_TIME=5000"

    # For jdk 9+, this JAVA_OPTS will be used as default JVM options
    JAVA_OPTS_FOR_JDK_9="-Xmx1024m -DlogPath=$DORIS_HOME/log/jni.log -
Xloggc:$DORIS_HOME/log/be.gc.log.$CUR_DATE -Djavax.security.auth.useSubjectCredsOnly=false -
Dsun.java.command=DorisBE -XX:-CriticalJNINatives -DJDBC_MIN_POOL=1 -DJDBC_MAX_POOL=100 -
DJDBC_MAX_IDLE_TIME=300000 -DJDBC_MAX_WAIT_TIME=5000"

    # since 1.2, the JAVA_HOME need to be set to run BE process.
    # JAVA_HOME=/path/to/jdk/

    # https://github.com/apache/doris/blob/master/docs/zh-CN/community/developer-guide/debug-
tool.md#jemalloc-heap-profile
    # https://jemalloc.net/jemalloc.3.html

    JEMALLOC_CONF="percpu_arena:percpu,background_thread:true,metadata_thp:auto,muzzy_decay_ms:15000,dirty_decay_
ms:15000,oversize_threshold:0,lg_tcache_max:20,prof:false,lg_prof_interval:32,lg_prof_sample:19,prof_gdump:fa
lse,prof_accum:false,prof_leak:false,prof_final:false"
    JEMALLOC_PROF_PREFIX=""

    # INFO, WARNING, ERROR, FATAL
    sys_log_level = INFO

    # ports for admin, web, heartbeat service
    be_port = 9060
    webserver_port = 8040
    heartbeat_service_port = 9050
    brpc_port = 8060
```

其中，在 `metadata.name` 中定义 BE ConfigMap 的名字，在 `data` 中定义 `be.conf` 中的数据库配置。

提示

在 ConfigMap 中使用 data 字段存储键值对。在上述 BE ConfigMap 中：- be.conf 是键值对中的 key，使用 | 表示将保留后续字符串中的换行符和缩进 - 后续配置为键值对中的 value，与 be.conf 文件中的配置相同在 data 字段中，由于使用了 | 符号保留后续字符串格式，后续的配置中需要保持两个空格缩进。

在定义 BE ConfigMap 后，需要通过 kubectl apply 命令下发。

使用 BE ConfigMap

如果需要使用 BE ConfigMap，需要再 Doris Cluster 的 RC 中通过 spec.beSpec.configMapInfo 指定定义的 ConfigMap。

```
kind: DorisCluster
metadata:
  name: doriscluster-sample-configmap
spec:
  beSpec:
    configMapInfo:
      configMapName: {beConfigMapName}
      resolveKey: be.conf
  ...
```

将上例中的 \${beConfigMapName} 替换为 be-conf 表示使用上例中定义的 BE ConfigMap。对于 BE ConfigMap，需要保持 resolveKey 字段固定为 be.conf。

为 conf 目录添加外部配置文件

在使用 Catalog 功能访问外部数据源时，需要将相关配置文件添加到 Doris 节点的 conf 目录下，如在访问 hive catalog 时，需要将 core-site.xml，hdfs-site.xml 与 hive-site.xml 文件放到 FE 与 BE 的 conf 目录。

在 Kubernetes 环境中，需要将 catalog 的相关配置文件，以 ConfigMap 的形式加载到 Doris 中。下例展示了将 core-site.xml 文件加载到 BE：

```
apiVersion: v1
kind: ConfigMap
metadata:
  name: be-configmap
  labels:
    app.kubernetes.io/component: be
data:
  be.conf: |
    be_port = 9060
    webserver_port = 8040
    heartbeat_service_port = 9050
    brpc_port = 8060
  core-site.xml: |
    <?xml version="1.0" encoding="UTF-8"?>
    <?xml-stylesheet type="text/xsl" href="configuration.xsl"?>
    <configuration>
      <property>
        <name>hadoop.security.authentication</name>
        <value>kerberos</value>
      </property>
    </configuration>
  ...
```


其中，在 `data` 字段中存储了配置的键值对，在上例中存储了 key 分别为 `be.conf` 与 `core-site.xml` 的键值对。

在 `data` 字段中，需要满足以下的键值结构映射：

```
data:
  filename_1: |
    config_string
  filename_2: |
    config_string
  filename_3: |
    config_string
```

为 BE 配置多盘存储

Doris 支持为 BE 挂载多块 PV。通过配置 BE 参数 `storage_root_path` 可以指定 BE 使用多盘存储。在 Kubernetes 环境中，可以在 DorisCluster CR 中对 pv 进行映射，通过 ConfigMap 为 BE 配置 `storage_root_path` 参数。

为 BE 多盘存储配置 pv 映射

在 DorisCluster CR 文件中，相比于单盘配置，需要添加 `configMapInfo` 与 `persistentVolumeClaimSpec` 的描述：

- 通过 `configMapInfo` 配置可以标识使用相同 namespace 下的指定 ConfigMap，`resolveKey` 固定为 `be.conf`
- 通过 `persistentVolumeClaimSpec` 可以为 BE 存储目录配置多个 pv 映射

下例中为 BE 配置了两块盘的 pv 映射：

```
...
beSpec:
  replicas: 3
  image: selectdb/doris.be-ubuntu:2.0.2
  limits:
    cpu: 8
    memory: 16Gi
  requests:
    cpu: 8
    memory: 16Gi
  configMapInfo:
    configMapName: be-configmap
    resolveKey: be.conf
  persistentVolumes:
  - mountPath: /opt/apache-doris/be/storage1
    name: storage2
    persistentVolumeClaimSpec:
      # when use specific storageclass, the storageClassName should reConfig, example as annotation.
      #storageClassName: openebs-jiva-csi-default
      accessModes:
      - ReadWriteOnce
      resources:
        requests:
          storage: 100Gi
  - mountPath: /opt/apache-doris/be/storage2
    name: storage3
    persistentVolumeClaimSpec:
      # when use specific storageclass, the storageClassName should reConfig, example as annotation.
      #storageClassName: openebs-jiva-csi-default
```

```

    accessModes:
    - ReadWriteOnce
    resources:
      requests:
        storage: 100Gi
  - mountPath: /opt/apache-doris/be/log
    name: storage4
  persistentVolumeClaimSpec:
    # when use specific storageclass, the storageClassName should reConfig, example as annotation.
    #storageClassName: openebs-jiva-csi-default
    accessModes:
    - ReadWriteOnce
    resources:
      requests:
        storage: 100Gi

```

在上例中 Doris 集群指定了多盘存储

- beSpec.persistentVolumes 以数组的方式指定了多块 pv，映射了 /opt/apache-doris/be/storage{1,2} 两个数据存储 pv
- beSpec.configMapInfo 中指定了需要挂载名为 be-configmap 的 ConfigMap

配置 BE ConfigMap 指定 storage_root_path 参数

根据 DorisCluster CR 中指定的 BE ConfigMap 名，需要创建相应的 ConfigMap 并指定 storage_root_path 参数。

下例中在名为 be-configmap 的 ConfigMap 中指定了 storage_root_path 参数使用两块盘：

```

apiVersion: v1
kind: ConfigMap
metadata:
  name: be-configmap
  labels:
    app.kubernetes.io/component: be
data:
  be.conf: |
    CUR_DATE=`date +%Y%m%d-%H%M%S`

    PPROF_TMPDIR="$DORIS_HOME/log/"

    JAVA_OPTS="-Xmx1024m -DlogPath=$DORIS_HOME/log/jni.log -Xloggc:$DORIS_HOME/log/be.gc.log.$CUR_DATE -
Djavax.security.auth.useSubjectCredsOnly=false -Dsun.java.command=DorisBE -XX:-CriticalJNINatives -
DJDBC_MIN_POOL=1 -DJDBC_MAX_POOL=100 -DJDBC_MAX_IDLE_TIME=300000 -DJDBC_MAX_WAIT_TIME=5000"

    # For jdk 9+, this JAVA_OPTS will be used as default JVM options
    JAVA_OPTS_FOR_JDK_9="-Xmx1024m -DlogPath=$DORIS_HOME/log/jni.log -
Xlog:gc:$DORIS_HOME/log/be.gc.log.$CUR_DATE -Djavax.security.auth.useSubjectCredsOnly=false -
Dsun.java.command=DorisBE -XX:-CriticalJNINatives -DJDBC_MIN_POOL=1 -DJDBC_MAX_POOL=100 -
DJDBC_MAX_IDLE_TIME=300000 -DJDBC_MAX_WAIT_TIME=5000"

    # since 1.2, the JAVA_HOME need to be set to run BE process.
    # JAVA_HOME=/path/to/jdk/

    # https://github.com/apache/doris/blob/master/docs/zh-CN/community/developer-guide/debug-
tool.md#jemalloc-heap-profile
    # https://jemalloc.net/jemalloc.3.html

    JEMALLOC_CONF="percpu_arena:percpu,background_thread:true,metadata_thp:auto,muzzy_decay_ms:15000,dirty_decay_
ms:15000,oversize_threshold:0,lg_tcache_max:20,prof:false,lg_prof_interval:32,lg_prof_sample:19,prof_gdump:fa
lse,prof_accum:false,prof_leak:false,prof_final:false"

```

```
JEMALLOC_PROF_PREFIX=""

# INFO, WARNING, ERROR, FATAL
sys_log_level = INFO

# ports for admin, web, heartbeat service
be_port = 9060
webserver_port = 8040
heartbeat_service_port = 9050
brpc_port = 8060

storage_root_path = /opt/apache-doris/be/storage,medium:ssd;/opt/apache-doris/be/storage1,medium:ssd
```

注意

在创建 BE ConfigMap 时，需要注意以下事项： 1. metadata.name 需要与 DorisCluster CR 中 beSpec.configMapInfo.configMapName 相同，表示该集群使用指定的 ConfigMap； 2. ConfigMap 中的 storage_root_path 参数要与 DorisCluster CR 中的 persistentVolume 数据盘一一对应。

部署 Doris 集群

在规划集群拓扑后，可以在 Kubernetes 中部署 Doris 集群。

部署集群

使用 Custom Resource 文件部署

在线部署

在线部署集群需要经过以下步骤：

1. 创建 namespace：

```
kubectl create namespace ${namespace}
```

2. 部署 Doris 集群

```
kubectl apply -f ./${cluster_sample}.yaml -n ${namespace}
```

离线部署

离线部署 Doris 集群需要在有外网的机器上将 Doris 集群用到的 docker 镜像，上传到所有的 node 节点上。然后使用 docker load 将镜像安装到服务器上。离线部署需要经历以下步骤：

1. 下载所需的镜像

部署 Doris 集群需要以下镜像：

```
selectdb/doris.fe-ubuntu:2.0.2  
selectdb/doris.be-ubuntu:2.0.2
```

将镜像下载到本地后打包成 tar 文件

```
## download docker image  
docker pull selectdb/doris.fe-ubuntu:2.0.2  
docker pull selectdb/doris.be-ubuntu:2.0.2  
  
## save docker image as a tar package  
docker save -o doris.fe-ubuntu-v2.0.2.tar selectdb/doris.fe-ubuntu:2.0.2  
docker save -o doris.be-ubuntu-v2.0.2.tar selectdb/doris.be-ubuntu:2.0.2
```

将 image tar 包上传到服务器上，执行 docker load 命令：

```
## load docker image  
docker load -i doris.fe-ubuntu-v2.0.2.tar  
docker load -i doris.be-ubuntu-v2.0.2.tar
```

2. 创建 namespace:

```
kubectl create namespace ${namespace}
```

3. 部署 Doris 集群

```
kubectl apply -f ./${cluster_sample}.yaml -n ${namespace}
```

使用 Helm 部署

在线部署

在安装开始前，需要添加部署仓库，若已经添加则可直接进行 Doris Cluster 的安装，否则请参考添加[部署 Doris Operator](#)时 [添加部署仓库](#) 的操作

1. 安装 Doris Cluster

安装 [doriscluster](#)，使用默认配置此部署仅部署 3 个 FE 和 3 个 BE 组件，使用默认 storageClass 实现 PV 动态供给。

```
helm install doriscluster doris-repo/doris
```

如果需要自定义资源和集群形态，请根据 [values.yaml](#) 的各个资源配置的注解自定义资源配置，并执行如下命令：

```
helm install -f values.yaml doriscluster doris-repo/doris
```

2. 验证 doris 集群安装结果

通过 `kubectl get pods` 命令可以查看 pod 部署状态。当 doriscluster 的 Pod 处于 Running 状态且 Pod 内所有容器都已经就绪，即部署成功。

```
kubectl get pod --namespace doris
```

返回结果如下：

NAME	READY	STATUS	RESTARTS	AGE
doriscluster-helm-fe-0	1/1	Running	0	1m39s
doriscluster-helm-fe-1	1/1	Running	0	1m39s
doriscluster-helm-fe-2	1/1	Running	0	1m39s
doriscluster-helm-be-0	1/1	Running	0	16s
doriscluster-helm-be-1	1/1	Running	0	16s
doriscluster-helm-be-2	1/1	Running	0	16s

离线部署

1. 下载 Doris Cluster Chart 资源

下载 `doris-{chart_version}.tgz` 安装 Doris Cluster chart。如需要下载 1.6.1 版本的 Doris 集群可以使用以下命令：

```
wget https://charts.selectdb.com/doris-1.6.1.tgz
```

2. 安装 Doris 集群

通过 `helm install` 命令可以安装 Doris 集群。

```
helm install doriscluster doris-1.4.0.tgz
```

如果需要自定义装配 [values.yaml](#)，可以参考如下命令：

```
helm install -f values.yaml doriscluster doris-1.4.0.tgz
```

3. 验证 doris 集群安装结果

通过 `kubectl get pods` 命令可以查看 pod 部署状态。当 `doriscluster` 的 Pod 处于 `Running` 状态且 Pod 内所有容器都已经就绪，即部署成功。

```
kubectl get pod --namespace doris
```

返回结果如下：

NAME	READY	STATUS	RESTARTS	AGE
doriscluster-helm-fe-0	1/1	Running	0	1m39s
doriscluster-helm-fe-1	1/1	Running	0	1m39s
doriscluster-helm-fe-2	1/1	Running	0	1m39s
doriscluster-helm-be-0	1/1	Running	0	16s
doriscluster-helm-be-1	1/1	Running	0	16s
doriscluster-helm-be-2	1/1	Running	0	16s

查看集群状态

检查集群状态

集群部署资源下发后，可以通过以下命令检查集群状态。

```
kubectl get pods -n ${namespace}
```

返回结果如下：

NAME	READY	STATUS	RESTARTS	AGE
doriscluster-sample-fe-0	1/1	Running	0	20m
doriscluster-sample-be-0	1/1	Running	0	19m

当所有 pod 的 STATUS 都是 `Running` 状态，且所有组件的 pod 中所有容器都 `READY` 表示整个集群部署正常。

检查部署资源状态

Doris Operator 会收集集群服务的状态显示到下发的资源中。Doris Operator 定义了 DorisCluster 类型资源名称的简写 dcr，在使用资源类型查看集群状态时可用简写替代。

```
kubectl get dcr
```

返回结果如下：

NAME	FESTATUS	BESTATUS	CNSTATUS	BROKERSTATUS
doriscluster-sample	available	available		

当配置的相关服务的 STATUS 都为 available 时，集群部署成功。

访问 Doris 集群

使用 ClusterIP 模式访问

Doris 在 Kubernetes 上默认提供 ClusterIP 访问模式。ClusterIP 访问模式在 Kubernetes 集群内提供了一个内部 IP 地址，通过这个内部 IP 暴露服务。使用 ClusterIP 模式，只能在集群内部访问。

1. 配置使用 ClusterIP 作为 Service 类型

Doris 在 Kubernetes 上默认提供 ClusterIP 访问模式。无需进行修改即可使用 ClusterIP 访问模式。

2. 获取 Service

在部署集群后，通过以下命令可以查看 Doris Operator 暴露的 service：

```
kubectl -n doris get svc
```

返回结果如下：

NAME	TYPE	CLUSTER-IP	EXTERNAL-IP	PORT(S)
AGE				
doriscluster-sample-be-internal 9m	ClusterIP	None	<none>	9050/TCP
doriscluster-sample-be-service 9m	ClusterIP	10.1.68.128	<none>	9060/TCP,8040/TCP,9050/TCP,8060/TCP
doriscluster-sample-fe-internal 14m	ClusterIP	None	<none>	9030/TCP
doriscluster-sample-fe-service 14m	ClusterIP	10.1.118.16	<none>	8030/TCP,9020/TCP,9030/TCP,9010/TCP

在以上结果中，FE 与 BE 有两类 Service，后缀分别为 internal 与 service：

- 以 internal 后缀的 Service 服务只能 Doris 内部通信使用，如心跳，数据交换等操作，不对外使用
- 以 service 后缀的 Service 服务可以提供用户使用

3. 在容器内部访问 Doris

使用以下命令，可以在当前的 Kubernetes 集群中创建一个包含 mysql client 的 pod：

```
kubectl run mysql-client --image=mysql:5.7 -it --rm --restart=Never --namespace=doris -- /bin/bash
```

在集群内的容器中，可以使用对外暴露的后缀为 service 的服务名访问 Doris 集群：

```
## 使用 service 类型 pod name 访问 Doris 集群  
mysql -uroot -P9030 -hdoriscluster-sample-fe-service
```

使用 NodePort 模式访问

如果用户需要再 Kubernetes 集群外部访问 Doris，可以选择使用 NodePort 的模式。

1. 规划 NodePort 模式端口映射

使用与维护 Doris 集群，用户需要访问以下端口：

端口名称	默认端口	端口描述
Query Port	9030	用于通过 MySQL 协议访问 Doris 集群
HTTP Port	8030	FE 上的 http server 端口，用于查看 FE 的信息
Web Server Port	8040	BE 上的 http server 端口，用于查看 BE 的信息

使用 NodePort 有两种端口分配方式：

- 动态分配：如果没有显示设置端口映射，Kubernetes 会在创建 pod 的时候自动分配一个未使用的端口（默认范围为 30000-32767）；
- 静态分配：如果显示指定了端口映射，当端口未被使用无冲突的时候，Kubernetes 固定分配该端口。

在 Kubernetes 中默认使用动态分配端口的方式，如果需要提前规划端口，需要在 Custom Resource 中显示指定。在下例中，将 Doris 端口进行映射：

```
...
spec:
  feSpec:
    replicas: 3
    service:
      type: NodePort
      servicePorts:
        - nodePort: 31001
          targetPort: 8030
        - nodePort: 31002
          targetPort: 8040
        - nodePort: 31003
          targetPort: 9030
  ...
  beSpec:
    replicas: 3
    service:
      type: NodePort
      servicePorts:
        - nodePort: 31005
          targetPort: 9060
        - nodePort: 31006
          targetPort: 8040
        - nodePort: 31007
          targetPort: 9050
        - nodePort: 31008
          targetPort: 8060
  ...
```

2. 配置使用 NodePort 作为 Service 类型

使用 NodePort 访问模式，需要定义 DorisCluster 资源，指定 FE 与 BE 使用 NodePort 模式，具体改动如下：

```
...
spec:
  feSpec:
    replicas: 3
    service:
```

```

    type: NodePort
...
  beSpec:
    replicas: 3
    service:
      type: NodePort
...

```

3. 获取 Service

在部署集群后，通过以下命令可以查看 Doris Operator 暴露的 service：

```
kubectl get service
```

返回结果如下：

NAME	TYPE	CLUSTER-IP	EXTERNAL-IP	PORT(S)
AGE				
kubernetes	ClusterIP	10.152.183.1	<none>	443/TCP
169d				
doriscluster-sample-fe-internal	ClusterIP	None	<none>	9030/TCP
2d				
doriscluster-sample-fe-service	NodePort	10.152.183.58	<none>	8030:31041/TCP,9020:30783/TCP,9030:31545/TCP,9010:31610/TCP
8030:31041/TCP,9020:30783/TCP,9030:31545/TCP,9010:31610/TCP			2d	
doriscluster-sample-be-internal	ClusterIP	None	<none>	9050/TCP
2d				
doriscluster-sample-be-service	NodePort	10.152.183.244	<none>	9060:30940/TCP,8040:32713/TCP,9050:30621/TCP,8060:30926/TCP
9060:30940/TCP,8040:32713/TCP,9050:30621/TCP,8060:30926/TCP			2d	

Doris 的 Query Port 端口默认为 9030，在本地中被映射到本地端口 31545。在访问 Doris 集群时，同时需要获取到对应的 IP 地址，可以通过以下命令查看：

```
kubectl get nodes -owide
```

返回结果如下：

NAME	STATUS	ROLES	AGE	VERSION	INTERNAL-IP	EXTERNAL-IP	OS-IMAGE	KERNEL-
VERSION		CONTAINER-RUNTIME						
r60	Ready	control-plane	14d	v1.28.2	192.168.88.60	<none>	CentOS Stream 8	4.18.0-
294.el8.x86_64		containerd://1.6.22						
r61	Ready	<none>	14d	v1.28.2	192.168.88.61	<none>	CentOS Stream 8	4.18.0-
294.el8.x86_64		containerd://1.6.22						
r62	Ready	<none>	14d	v1.28.2	192.168.88.62	<none>	CentOS Stream 8	4.18.0-
294.el8.x86_64		containerd://1.6.22						
r63	Ready	<none>	14d	v1.28.2	192.168.88.63	<none>	CentOS Stream 8	4.18.0-
294.el8.x86_64		containerd://1.6.22						

在 NodePort 模式下，可以根据任何 node 节点的宿主机 IP 与端口映射访问 Kubernetes 集群内的服务。在本例中可以使用任一的 node 节点 IP，192.168.88.61、192.168.88.62、192.168.88.63 访问 Doris 服务。如在下例中使用了 node 节点 192.168.88.62 与映射出的 query port 端口 31545 访问集群：

```
mysql -h 192.168.88.62 -P 31545 -uroot
```

Stream Load ErrorURL 重定向

[Stream Load](#) 是 Doris 提供的一种同步导入模式，是一种高效导入本地文件到 Doris 的方式。在物理机或虚拟机部署的情况下，直接使用 http 的方式向 FE 发起导入数据请求，FE 通过 301 机制将请求重定向到 BE 服务，执行写入请求。在 Kubernetes 上 FE 和 BE 使用 [Service](#) 作为服务发现的方式。在使用代理屏蔽内部真实地址来提供服务发现的情形下，使用 FE 301 返回的 BE 的地址 (服务内部通信使用的真实的地址) 无法访问。在 Kubernetes 上需要使用 BE 的 Service 地址导入数据。

如下例中，Stream Load ErrorUrl 返回结果 `http://doriscluster-sample-be-2.doriscluster-sample-be-internal.doris.svc.cluster.local:8040/api/_load_error_log?file=__shard_1/error_log_insert_stmt_af474190276a2e9c-49bb9d175b8e968e_af474190276a2e9c_49bb9d175b8e968e`

在容器内部查看 ErrorURL

如果在 Kubernetes 内部进行 Stream Load 可直接使用 Stream Load 返回的错误地址获取详细的错误报告。

在上例返回结果中，可以直接在同一个 Kubernetes 集群内的 Pod 中通过 curl 命令获取返回结果：

```
curl http://doriscluster-sample-be-2.doriscluster-sample-be-internal.doris.svc.cluster.local:8040/api/_load_error_log?file=__shard_1/error_log_insert_stmt_af474190276a2e9c-49bb9d175b8e968e_af474190276a2e9c_49bb9d175b8e968e
```

在容器外部查看 ErrorURL

从 Kubernetes 外部使用 Stream Load 导入数据过程中发生错误，返回的错误地址无法直接在 Kubernetes 外部访问获取详细的错误报告。在 Kubernetes 环境中需要使用定制的 Service 代理发生错误的 pod，将定制的 Service 配置为外部可访问的模式，通过访问代理 Service 来获取详细的错误报告。

定制化 Service 模板如下：

```
apiVersion: v1
kind: Service
metadata:
  labels:
    app.doris.service/role: debug
    app.kubernetes.io/component: be
  name: doriscluster-detail-error
spec:
  externalTrafficPolicy: Cluster
  internalTrafficPolicy: Cluster
  ipFamilies:
    - IPv4
  ipFamilyPolicy: SingleStack
  ports:
    - name: webserver-port
      port: 8040
      protocol: TCP
      targetPort: 8040
  selector:
    app.kubernetes.io/component: be
    statefulset.kubernetes.io/pod-name: ${podName}
  sessionAffinity: None
  type: ${ServiceType}
```

其中：

- `${podName}` 表示当前发生错误的 pod 三级域名，如上例中需要填写 pod 名为 `doriscluster-sample-be-2`
- `${ServiceType}` 为部署的 Service 类型，可以选择 NodePort 或 LoadBalancer

提示

由于每次 stream load 返回的 pod 名可能不同，获取 Stream Load 详细错误信息后，请将定制化的 Service 删除。

NodePort 模式

1. 部署 NodePort Service

按照上例中的 service 将 CR 中的 `${podName}` 替换成 `doriscluster-sample-be-2`，将 `${ServiceType}` 替换为 NodePort。通过 `kubectl apply` 命令，在 `doris` 集群相同的 namespace 中创建 service 服务。

```
kubectl -n {namespace} apply -f stream_load_get_error.yaml
```

2. 构建访问命令

使用以下命令查看上述部署 Service 分配的 NodePort 端口：

```
kubectl get service -n doris doriscluster-detail-error
```

返回结果如下：

NAME	TYPE	CLUSTER-IP	EXTERNAL-IP	PORT(S)	AGE
doriscluster-detail-error	NodePort	10.152.183.35	<none>	8040:31201/TCP	32s

Stream Load 访问的 BE 端口为 8040，上述 Service 中 8040 对应的宿主机端口 (NodePort) 为 31201。

获取 K8s 管控的宿主机地址：

```
kubectl get node -owide
```

返回结果如下：

NAME	STATUS	ROLES	AGE	VERSION	INTERNAL-IP	EXTERNAL-IP	OS-IMAGE
KERNEL-VERSION	CONTAINER-RUNTIME						
vm-10-8-centos	Ready	<none>	226d	v1.28.7	10.16.10.8	<none>	TencentOS Server 3.1 (Final)
5.4.119-19-0009.3	containerd://1.6.28						
vm-10-7-centos	Ready	<none>	19d	v1.28.7	10.16.10.7	<none>	TencentOS Server 3.1 (Final)
5.4.119-19.0009.25	containerd://1.6.28						

使用上述宿主机中任何一个 INTERNAL-IP 和获得宿主机端口构建使用 NodePort 模式获取错误详情的访问地址。NodePort 模式下，获取错误详情的地址拼接为 宿主机 IP:NodePort，则案例可访问地址为 `10.16.10.8:31201`，替换返回错误地址信息中的访问地址，获得可访问错误信息详情的可使用地址：

```
http://10.16.10.8:31201/api/_load_error_log?file=__shard_1/error_log_insert_stmt_af474190276a2e9c-49bb9d175b8e968e_af474190276a2e9c_49bb9d175b8e968e
```

使用上述命令获取 Stream Load 的详细报错信息。

LoadBalancer 模式

1. 部署获取错误详情 Service

假设 Stream Load 范围的错误地址如下：

```
http://doriscluster-sample-be-2.doriscluster-sample-be-internal.doris.svc.cluster.local:8040/api/_load_error_log?file=__shard_1/error_log_insert_stmt_af474190276a2e9c-49bb9d175b8e968e_af474190276a2e9c_49bb9d175b8e968e
```

上述地址的域名地址为 `doriscluster-sample-be-2.doriscluster-sample-be-internal.doris.svc.cluster.local` 在 Kubernetes 上 Doris Operator 部署的 pod 使用的域名中，三级域名为 pod 的名称。将上述模板中 {podName} 替换为真实的 pod 名称，将 {serviceType} 替换为 LoadBalancer，更改后保存到新建的 `stream_load_get_error.yaml` 文件中。使用如下命令部署 service：

```
kubectl -n {namespace} apply -f stream_load_get_error.yaml
```

2. 构建访问命令

使用如下命令查看上述部署 Service 分配的 LoadBalancer 地址 EXTERNAL-IP，以下为在 aws eks 测试实例：

```
kubectl get service -n doris doriscluster-detail-error
```

返回结果如下：

NAME	TYPE	CLUSTER-IP	EXTERNAL-IP
doriscluster-detail-error	LoadBalancer	172.20.183.136	ac4828493dgrftb884g67wg4tb68gyut-1137856348.us-east-1.elb.amazonaws.com
AGE	8040:32003/TCP	14s	

上述 Service 获得由 K8s 集群分配的 LoadBalancer 地址为

`ac4828493dgrftb884g67wg4tb68gyut-1137856348.us-east-1.elb.amazonaws.com`，在使用 LoadBalancer 模式中端口仍然为部署部署监听的端口，LoadBalancer 模式下，获取错误详情的地址拼接为“EXTERNAL-IP:listener-port”。上例中可获取错误详情的地址为 `ac4828493dgrftb884g67wg4tb68gyut-1137856348.us-east-1.elb.amazonaws.com:8040`，获取详细错误信息的地址如下：

```
http://ac4828493dgrftb884g67wg4tb68gyut-1137856348.us-east-1.elb.amazonaws.com:8040/api/_load_error_log?file=__shard_1/error_log_insert_stmt_af474190276a2e9c-49bb9d175b8e968e_af474190276a2e9c_49bb9d175b8e968e
```

升级基于 Doris Operator 部署的 Apache Doris 集群

本文介绍如何使用 更新来升级 基于 Doris Operator 部署的 Apache Doris 集群。

和常规部署的集群升级类似，Doris Operator 部署的 Doris 集群依然需要 BE 到 FE 节点滚动升级，Doris Operator 基于 Kubernetes 的 [滚动更新功能](#) 提供了滚动升级能力。

升级前注意事项

- 升级操作推荐在业务低峰期进行。
- 滚动升级过程中，会导致连接到被关闭节点的连接失效，造成请求失败，对于这类业务，推荐在客户端添加重试能力。
- 升级前可以阅读 [常规升级手册](#)，便于理解升级中的一些原理和注意事项。
- 升级前无法对数据和元数据的兼容性进行验证，因此集群升级一定要避免数据存在 单副本 情况 和 集群单 FE FOLLOWER 节点。
- 升级过程中会有节点重启，所以可能会触发不必要的集群均衡和副本修复逻辑，先通过以下命令关闭

```
admin set frontend config("disable_balance" = "true");
admin set frontend config("disable_colocate_balance" = "true");
admin set frontend config("disable_tablet_scheduler" = "true");
```

- Doris 升级请遵守不要跨两个及以上关键节点版本升级的原则，若要跨多个关键节点版本升级，先升级到最近的关键节点版本，随后再依次往后升级，若是非关键节点版本，则可忽略跳过。具体参考 [升级版本说明](#)

升级操作

升级过程节点类型顺序如下，如果某类型节点不存在则跳过：

```
cn/be -> fe -> broker
```

建议依次修改对应集群组件的 image 然后 应用该配置，待当前类型的组件完全升级成功状态恢复正常后，再进行下一个类型节点的滚动升级。

升级 BE

如果保留了集群的 crd（Doris Operator 定义了 DorisCluster 类型资源名称的简写）文件，则可以通过修改该配置文件并且 kubectl apply 的命令来进行升级。

1. 修改 spec.beSpec.image

将 selectdb/doris.be-ubuntu:2.0.4 变为 selectdb/doris.be-ubuntu:2.1.0

```
$ vim doriscluster-sample.yaml
```

2. 保存修改后应用本次修改进行 BE 升级：

```
$ kubectl apply -f doriscluster-sample.yaml -n doris
```

也可通过 `kubectl edit dcr` 的方式直接修改。

1. 查看 namespace 为 'doris' 下的 dcr 列表，获取需要更新的 cluster_name

```
$ kubectl get dcr -n doris
NAME                FESTATUS    BESTATUS    CNSTATUS
doriscluster-sample available    available
```

2. 修改、保存并生效

```
$ kubectl edit dcr doriscluster-sample -n doris
```

进入文本编辑器后，将找到 `spec.beSpec.image`，将 `selectdb/doris.be-ubuntu:2.0.4` 修改为 `selectdb/doris.be-ubuntu:2.1.0`

3. 查看升级过程和结果：

```
$ kubectl get pod -n doris
```

当所有 Pod 都重建完毕进入 Running 状态后，升级完成。

升级 FE

如果保留了集群的 crd（Doris Operator 定义了 DorisCluster 类型资源名称的简写）文件，则可以通过修改该配置文件并且 `kubectl apply` 的命令来进行升级。

1. 修改 spec.feSpec.image

将 `selectdb/doris.fe-ubuntu:2.0.4` 变为 `selectdb/doris.fe-ubuntu:2.1.0`

```
$ vim doriscluster-sample.yaml
```

2. 保存修改后应用本次修改进行 be 升级：

```
$ kubectl apply -f doriscluster-sample.yaml -n doris
```

也可通过 `kubectl edit dcr` 的方式直接修改。

1. 修改、保存并生效

```
$ kubectl edit dcr doriscluster-sample -n doris
```

进入文本编辑器后，将找到`spec.feSpec.image`，将`selectdb/doris.fe-ubuntu:2.0.4`修改为`selectdb/doris.fe-ubuntu:2.1.0`

2. 查看升级过程和结果

```
$ kubectl get pod -n doris
```

当所有 Pod 都重建完毕进入 Running 状态后，升级完成。

升级完成后

验证集群节点状态

通过 [访问 Doris 集群](#) 文档提供的方式，通过 mysql-client 访问 Doris。

使用 show frontends 和 show backends 等 SQL 查看各个组件的版本 和 状态。

```
mysql> show frontends\G;
***** 1. row *****
      Name: fe_13c132aa_3281_4f4f_97e8_655d01287425
      Host: doriscluster-sample-fe-0.doriscluster-sample-fe-internal.doris.svc.cluster.local
      EditLogPort: 9010
      HttpPort: 8030
      QueryPort: 9030
      RpcPort: 9020
      ArrowFlightSqlPort: -1
      Role: FOLLOWER
      IsMaster: false
      ClusterId: 1779160761
      Join: true
      Alive: true
      ReplayedJournalId: 2422
      LastStartTime: 2024-02-19 06:38:47
      LastHeartbeat: 2024-02-19 09:31:33
      IsHelper: true
      ErrMsg:
      Version: doris-2.1.0
      CurrentConnected: Yes
***** 2. row *****
      Name: fe_f1a9d008_d110_4780_8e60_13d392faa54e
      Host: doriscluster-sample-fe-2.doriscluster-sample-fe-internal.doris.svc.cluster.local
      EditLogPort: 9010
      HttpPort: 8030
      QueryPort: 9030
      RpcPort: 9020
      ArrowFlightSqlPort: -1
      Role: FOLLOWER
      IsMaster: true
      ClusterId: 1779160761
      Join: true
      Alive: true
      ReplayedJournalId: 2423
      LastStartTime: 2024-02-19 06:37:35
      LastHeartbeat: 2024-02-19 09:31:33
      IsHelper: true
      ErrMsg:
      Version: doris-2.1.0
      CurrentConnected: No
```



```

***** 3. row *****
      Name: fe_e42bf9da_006f_4302_b861_770d2c955a47
      Host: doriscluster-sample-fe-1.doriscluster-sample-fe-internal.doris.svc.cluster.local
      EditLogPort: 9010
      HttpPort: 8030
      QueryPort: 9030
      RpcPort: 9020
      ArrowFlightSqlPort: -1
      Role: FOLLOWER
      IsMaster: false
      ClusterId: 1779160761
      Join: true
      Alive: true
      ReplayedJournalId: 2422
      LastStartTime: 2024-02-19 06:38:17
      LastHeartbeat: 2024-02-19 09:31:33
      IsHelper: true
      ErrMsg:
      Version: doris-2.1.0
      CurrentConnected: No
3 rows in set (0.02 sec)

```

若 FE 节点 alive 状态为 true，且 Version 值为新版本，则该 FE 节点升级成功。

```

mysql> show backends\G;
***** 1. row *****
      BackendId: 10002
      Host: doriscluster-sample-be-0.doriscluster-sample-be-internal.doris.svc.cluster.local
      HeartbeatPort: 9050
      BePort: 9060
      HttpPort: 8040
      BrpcPort: 8060
      ArrowFlightSqlPort: -1
      LastStartTime: 2024-02-19 06:37:56
      LastHeartbeat: 2024-02-19 09:32:43
      Alive: true
      SystemDecommissioned: false
      TabletNum: 14
      DataUsedCapacity: 0.000
      TrashUsedCapacity: 0.000
      AvailCapacity: 12.719 GB
      TotalCapacity: 295.167 GB
      UsedPct: 95.69 %
      MaxDiskUsedPct: 95.69 %
      RemoteUsedCapacity: 0.000
      Tag: {"location" : "default"}
      ErrMsg:
      Version: doris-2.1.0
      Status: {"lastSuccessReportTabletsTime":"2024-02-19
09:31:48","lastStreamLoadTime":-1,"isQueryDisabled":false,"isLoadDisabled":false}
      HeartbeatFailureCounter: 0
      NodeRole: mix
***** 2. row *****
      BackendId: 10003
      Host: doriscluster-sample-be-1.doriscluster-sample-be-internal.doris.svc.cluster.local
      HeartbeatPort: 9050
      BePort: 9060
      HttpPort: 8040
      BrpcPort: 8060
      ArrowFlightSqlPort: -1
      LastStartTime: 2024-02-19 06:37:35
      LastHeartbeat: 2024-02-19 09:32:43
      Alive: true

```

```

SystemDecommissioned: false
    TabletNum: 8
    DataUsedCapacity: 0.000
    TrashUsedCapcacity: 0.000
    AvailCapacity: 12.719 GB
    TotalCapacity: 295.167 GB
    UsedPct: 95.69 %
    MaxDiskUsedPct: 95.69 %
    RemoteUsedCapacity: 0.000
    Tag: {"location" : "default"}
    ErrMsg:
    Version: doris-2.1.0
    Status: {"lastSuccessReportTabletsTime":"2024-02-19
09:31:43","lastStreamLoadTime":-1,"isQueryDisabled":false,"isLoadDisabled":false}
HeartbeatFailureCounter: 0
    NodeRole: mix
***** 3. row *****
    BackendId: 11024
    Host: doriscluster-sample-be-2.doriscluster-sample-be-internal.doris.svc.cluster.local
    HeartbeatPort: 9050
    BePort: 9060
    HttpPort: 8040
    BrpcPort: 8060
    ArrowFlightSqlPort: -1
    LastStartTime: 2024-02-19 08:50:36
    LastHeartbeat: 2024-02-19 09:32:43
    Alive: true
SystemDecommissioned: false
    TabletNum: 0
    DataUsedCapacity: 0.000
    TrashUsedCapcacity: 0.000
    AvailCapacity: 12.719 GB
    TotalCapacity: 295.167 GB
    UsedPct: 95.69 %
    MaxDiskUsedPct: 95.69 %
    RemoteUsedCapacity: 0.000
    Tag: {"location" : "default"}
    ErrMsg:
    Version: doris-2.1.0
    Status: {"lastSuccessReportTabletsTime":"2024-02-19
09:32:04","lastStreamLoadTime":-1,"isQueryDisabled":false,"isLoadDisabled":false}
HeartbeatFailureCounter: 0
    NodeRole: mix
3 rows in set (0.01 sec)

```

若 BE 节点 alive 状态为 true，且 Version 值为新版本，则该 BE 节点升级成功

恢复集群副本同步和均衡

在确认各个节点状态无误后，执行以下 SQL 恢复集群均衡和副本修复：

```

admin set frontend config("disable_balance" = "false");
admin set frontend config("disable_colocate_balance" = "false");
admin set frontend config("disable_tablet_scheduler" = "false");

```

Root 用户使用

Doris-Operator 在部署管理相关服务节点使用的是 root 账号无密码的模式。用户名密码只有在部署后才能重新设置。

修改 root 账号及其密码

1. 参阅 [认证和鉴权](#) 文档，修改或创建相应密码或账户名，并在 Doris 中给予该账号管理节点的权限。
2. 在 DorisCluster CRD 文件中的配置添加 spec.adminUser.* 样例如下：

```
apiVersion: doris.selectdb.com/v1
kind: DorisCluster
metadata:
  annotations:
    selectdb/doriscluster: doriscluster-sample
  labels:
    app.kubernetes.io/instance: doris-sample
  name: doris-sample
  namespace: doris
spec:
  adminUser:
    name: root
    password: root_pwd
```

3. 将新的账号和密码更新到部署的 DorisCluster 中，经过 Doris-Operator 下发，让各个节点感知并生效。参考命令：

```
kubectl apply --namespace ${your_namespace} -f ${your_crd_yaml_file}
```

注意事项

- 集群管理账户是 root，默认无密码。
- 用户名密码只有在部署成功后才能重新设置。初次部署，添加 adminUser 可能会导致启动异常。
- 修改用户名和密码并不是必须的操作，只有在 Doris 内修改了当前的集群管理的用户（默认 root）或密码时 需要通过 Doris-Operator 下发。
- 如果修改用户名 spec.adminUser.name 需要给新的用户分配拥有管理 Doris 的节点的权限。
- 此操作会依次重启所有节点。

服务扩缩容

Doris 在 K8S 之上的扩缩容可通过修改 DorisCluster 资源对应组件的 replicas 字段来实现。修改可直接编辑对应的资源，也可通过命令的方式。

获取 DorisCluster 资源

使用命令 `kubectl --namespace {namespace} get doriscluster` 获取已部署 DorisCluster (简称 dcr) 资源的名称。本文中，我们以 doris 为 namespace。

```
$ kubectl --namespace doris get doriscluster
NAME                FESTATUS  BESTATUS  CNSTATUS  BROKERSTATUS
doriscluster-sample available  available
```

扩缩容资源

K8S 所有运维操作通过修改资源为最终状态，由 Operator 服务自动完成运维。扩缩容操作可通过 `kubectl --namespace {namespace} edit doriscluster {dcr_name}` 直接进入编辑模式修改对应 spec 的 replicas 值，保存退出后 Doris-Operator 完成运维，也可以通过如下命令实现不同组件的扩缩容。

FE 扩容

1. 查看当前 FE 服务数量

```
$ kubectl --namespace doris get pods -l "app.kubernetes.io/component=fe"
NAME                READY  STATUS   RESTARTS  AGE
doriscluster-sample-fe-0  1/1    Running  0          10d
```

2. 扩容 FE

```
$ kubectl --namespace doris patch doriscluster doriscluster-sample --type merge --patch '{"spec":{"feSpec":{"replicas":3}}}'
```

3. 检测扩容结果

```
$ kubectl --namespace doris get pods -l "app.kubernetes.io/component=fe"
NAME                READY  STATUS   RESTARTS  AGE
doriscluster-sample-fe-2  1/1    Running  0          9m37s
doriscluster-sample-fe-1  1/1    Running  0          9m37s
doriscluster-sample-fe-0  1/1    Running  0          8m49s
```

BE 扩容

1. 查看当前 BE 服务数量

```
$ kubectl --namespace doris get pods -l "app.kubernetes.io/component=be"
NAME                                READY   STATUS    RESTARTS   AGE
doriscluster-sample-be-0           1/1     Running   0           3d2h
```

2. 扩容 BE

```
$ kubectl --namespace doris patch doriscluster doriscluster-sample --type merge --patch '{"spec":{"beSpec":{"replicas":3}}}'
```

3. 检测扩容结果

```
$ kubectl --namespace doris get pods -l "app.kubernetes.io/component=be"
NAME                                READY   STATUS    RESTARTS   AGE
doriscluster-sample-be-0           1/1     Running   0           3d2h
doriscluster-sample-be-2           1/1     Running   0           12m
doriscluster-sample-be-1           1/1     Running   0           12m
```

节点缩容

关于节点缩容问题，Doris-Operator 目前并不能很好的支持节点安全下线，在这里仍能够通过减少集群组件的 `replicas` 属性来实现减少 FE 或 BE 的目的，这里是直接 `stop` 节点来实现节点下线，当前版本的 Doris-Operator 并未能实现 [decommission](#) 安全转移副本后下线。由此可能引发一些问题及其注意事项如下

- 表存在单副本情况下贸然下线 BE 节点，一定会有数据丢失，尽可能避免此操作。
- FE Follower 节点尽量避免随意下线，可能带来元数据损坏影响服务。
- FE Observer 类型节点可以随意下线，并无风险。
- CN 节点不持有数据副本，可以随意下线，但因此会损失存在于该 CN 节点的远端数据缓存，导致数据查询短时间内存在一定的性能回退。

服务 Crash 情况下如何进入容器

在 k8s 环境中服务因为一些预期之外的事情会进入 CrashLoopBackOff 状态，通过 `kubectl get pod --namespace ${namespace}` 命令可以查看指定 namespace 下的 pod 状态和 pod_name。

在这种状态下，单纯通过 `describe` 和 `logs` 命令无法判定服务出问题的原因。当服务进入 CrashLoopBackOff 状态时，需要有一种机制允许部署服务的 pod 进入 running 状态方便用户通过 `exec` 进入容器内进行 debug。

doris-operator 提供了 debug 的运行模式，本质上是通过 debug 进程占用对应节点的探活端口，绕过 k8s 探活机制，制造一个平稳运行的容器环境来方便用户进入并定位问题。

下面描述了当服务进入 CrashLoopBackOff 时如何进入 debug 模式进行人工 debug，以及解决后如何恢复到正常启动状态。

启动 Debug 模式

当服务一个 pod 进入 CrashLoopBackOff 或者正常运行过程中无法再正常启动时，通过一下步骤让服务进入 debug 模式，进行手动启动服务查找问题。

1.通过以下命令给运行有问题的 pod 进行添加 annotation

```
$ kubectl annotate pod ${pod_name} --namespace ${namespace} selectdb.com.doris/runmode=debug
```

当服务进行下一次重启时候，服务会检测到标识 debug 模式启动的 annotation 就会进入 debug 模式启动，pod 状态为 running。

2.当服务进入 debug 模式，此时服务的 pod 显示为正常状态，用户可以通过如下命令进入 pod 内部

```
$ kubectl --namespace ${namespace} exec -ti ${pod_name} bash
```

3. debug 下手动启动服务，当用户进入 pod 内部，通过修改对应配置文件有关端口进行手动执行 `start_xx.sh` 脚本，脚本目录为 `/opt/apache-doris/xx/bin` 下。

FE 需要修改 `query_port`，BE 需要修改 `heartbeat_service_port` 主要是避免 debug 模式下还能通过 service 访问到 crash 的节点导致误导流。

退出 Debug 模式

当服务定位到问题后需要退出 debug 运行，此时只需要按照如下命令删除对应的 pod，服务就会按照正常的模式启动。

```
$ kubectl delete pod ${pod_name} --namespace ${namespace}
```

注意事项

进入 pod 内部后，需要修改配置文件的端口信息，才能手动启动 相应的 Doris 组件

- FE 需要修改默认路径为: `/opt/apache-doris/fe/conf/fe.conf` 的 `query_port=9030` 配置。
- BE 需要修改默认路径为: `/opt/apache-doris/be/conf/be.conf` 的 `heartbeat_service_port=9050` 配置。

Doris on AWS

为了方便大家在 AWS 上快速体验 Doris，提供了 CloudFormation 模版（CFT），允许快速启动和运行集群。使用模板，只需最少的配置，就可以自动配置 AWS 资源，并启动 Doris 集群。

当然，您也可以自行购买 AWS 资源，采用标准的手动方式进行集群部署。

什么是 AWS CloudFormation?

CloudFormation 允许用户只用一个步骤就可以创建一个“资源堆栈”。资源是指用户所创建的东西（如 EC2 实例、VPC、子网等），一组这样的资源称为堆栈。用户可以编写一个模板，使用它可以很容易地按照用户的意愿通过一个步骤创建一个资源堆栈。这比手动创建并且配置更快，而且可重复，一致性更好。并且可以将模板放入源代码做版本控制，在任何时候根据需要把它用于任何目的。

什么是 Doris on AWS CloudFormation?

当前 Doris 提供了 Doris CloudFormation Template，方便用户直接使用这个模板可以在 AWS 上快速创建 Doris 相关版本的集群，以便体验最新的 Doris 功能。

注意：

基于 CloudFormation 构建 Doris 集群的模板，当前仅支持 us-east-1，us-west-1，us-west-2 区域。

Doris on AWS CloudFormation 主要用于测试或者体验，请不要用于生产环境。

使用前注意

- 确定要部署的 VPC 和 Subnet
- 确定用来登录节点的 key pair
- 部署中会建立 S3 的 VPC Endpoint Interface

开始部署

1. AWS 控制台上，进入 CloudFormation，点击 Create stack

CloudFormation > Stacks > Create stack

Step 1
Create stack

Step 2
Specify stack details

Step 3
Configure stack options

Step 4
Review and create

Create stack

Prerequisite - Prepare template

Prepare template
Every stack is based on a template. A template is a JSON or YAML file that contains configuration information about the AWS resources you want to include in the stack.

☒ Template is ready ☐ Use a sample template ☐ Create template in Designer

Specify template
A template is a JSON or YAML file that describes your stack's resources and properties.

Template source
Selecting a template generates an Amazon S3 URL where it will be stored.

☒ Amazon S3 URL ☐ Upload a template file ☐ Sync from Git - new

Provide an Amazon S3 URL to your template. Upload your template directly to the console. Sync a template from your Git repository.

Amazon S3 URL
https://sdb-cloud-third-party.s3.amazonaws.com/doris-cf/cloudformation_doris.template.yaml

Amazon S3 template URL

S3 URL: https://sdb-cloud-third-party.s3.amazonaws.com/doris-cf/cloudformation_doris.template.yaml [View in Designer](#)

[Cancel](#) [Next](#)

开始部署-AWS 控制台 进入 CloudFormation

选用 Amazon S3 URL Template source，填写 Amazon S3 URL 为下面模板链接：

https://sdb-cloud-third-party.s3.amazonaws.com/doris-cf/cloudformation_doris.template.yaml

2. 配置模板的具体参数

CloudFormation > Stacks > Create stack

Step 1
[Create stack](#)

Step 2
Specify stack details

Step 3
Configure stack options

Step 4
Review and create

Specify stack details

Provide a stack name

Stack name
doris
Stack name can include letters (A-Z and a-z), numbers (0-9), and dashes (-).

Parameters
Parameters are defined in your template and allow you to input custom values when you create or update a stack.

Network configuration

VPC ID
ID of your existing VPC for deployment (e.g., vpc-fd990584)
vpc-01b44727828616981

Public Subnet ID
ID of public subnet in Availability Zone for the ELB load balancer (e.g., subnet-9bc642ac)
subnet-03c8fe3278ec0a2b8

EC2 configuration

Key pair name
Public/private key pairs allow you to securely connect to your instance after it launches.
test-doris

配置模板的具体参数

Environment configuration

Version of Doris
Version of Doris
210

Doris Cluster configuration

Number of Doris Fe
Number of Doris Fe
1

Fe instance type
Amazon EC2 instance type for fe instances.
t3.large

Number of Doris Be
Number of Doris Be
3

Be instance type
Amazon EC2 instance type for be instances.
t3.large

Fe configuration

Sys Log Level
Sys Log Level, please select from the drop-down menu
INFO

Meta data dir
Dir to save meta data, please fill it in the absolute path
feDefaultMetaPath

配置模板的具体参数

BE configuration

Sys Log Level
Sys Log Level, please select from the drop-down menu
INFO

Volume type of Be nodes
EBS volume type (data) to be attached to node in GBs [gp2, gp3, st1], one volume for data storage is mounted automatically by CloudFormation stack.
gp2

Volume size of Be nodes
EBS volume size (data) to be attached to node in GBs.
50

Cancel Previous Next


配置模板的具体参数

主要参数说明如下：

- VPC ID：要部署到的 VPC
- Subnet ID：要部署的子网
- Key pair name：用来连接部署后的 BE 和 FE 节点的 public/private key pairs
- Version of Doris：选择部署的 Doris 版本，比如 2.1.0、2.0.6 等
- Number of Doris FE：FE 的个数，模板默认只能选择 1 个 FE
- Fe instance type: FE 的节点类型，可以采用默认值
- Number of Doris Be：BE 节点的个数，可以选择 1 个或者 3 个
- Be instance type：BE 的节点类型，可以采用默认值
- Meta data dir：FE 节点的元数据目录，可以采用默认值
- Sys log level：设置系统日志的等级，可以使用默认的 info
- Volume type of Be nodes：BE 节点挂载 EBS 的 volume type，每台节点默认挂载一块磁盘。可以使用默认值
- Volume size of Be nodes: BE 节点挂载 EBS 的大小，单位 GB，可以使用默认值。


部署后，如何连接数据库

1. 部署成功后的展示如下




如何连接数据库

2. 依次如下面，找到 FE 的连接地址。这个例子中，从 FE Outputs 里，可以查看到地址为 172.16.0.97。



找到 FE 的连接地址



找到 FE 的连接地址

The screenshot shows the AWS CloudFormation console interface. On the left, a sidebar lists stacks, with 'doris-FeStack-QSE5GA8P774P' selected. The main panel displays the 'Outputs' tab for this stack. A table lists two outputs: 'FeMasterInstance' with value 'i-009136e411beafca1' and 'FeMasterInstancePrivateIp' with value '172.16.0.97'. The value '172.16.0.97' is highlighted with a red rectangular box.

Key	Value	Description	Export name
FeMasterInstance	i-009136e411beafca1	fe master instance	-
FeMasterInstancePrivateIp	172.16.0.97	-	-

找到 FE 的连接地址

3. 连接部署的 Doris Cluster, Doris 的 CloudFormation 部署后的一些默认值:

- FE 的 IP: 按照上面步骤 2 获取 FE 的 IP 地址
- FE 的 MySQL 协议端口: 9030
- FE 的 HTTP 协议端口: 8030
- 默认的 root 密码: 空
- 默认的 admin 密码: 空

数据库连接

Apache Doris 采用 MySQL 网络连接协议，兼容 MySQL 生态的命令行工具、JDBC/ODBC 和各种可视化工具。同时 Apache Doris 也内置了一个简单的 Web UI，方便使用。下面分别介绍如何通过 MySQL Client、MySQL JDBC Connector、DBeaver 和 Doris 内置的 Web UI 来连接 Doris。

MySQL Client

从 MySQL 官方网站下载 MySQL Client，或者下载我们提供的 Linux 上免安装的 [MySQL 客户端](#)。当前 Doris 主要兼容 MySQL 5.7 及其以上的客户端。

解压下载的 MySQL 客户端，在 bin/ 目录下可以找到 mysql 命令行工具。然后执行下面的命令连接 Doris。

```
# FE_IP 为 FE 的监听地址， FE_QUERY_PORT 为 FE 的 MYSQL 协议服务的端口，在 fe.conf 中对应 query_port，默认为 9030。
mysql -h FE_IP -P FE_QUERY_PORT -u USER_NAME
```

登录后，显示如下。

```
Welcome to the MySQL monitor.  Commands end with ; or \g.
Your MySQL connection id is 236
Server version: 5.7.99 Doris version doris-2.0.3-rc06-37d31a5

Copyright (c) 2000, 2018, Oracle and/or its affiliates. All rights reserved.

Oracle is a registered trademark of Oracle Corporation and/or its
affiliates. Other names may be trademarks of their respective
owners.

Type 'help;' or '\h' for help. Type '\c' to clear the current input statement.

mysql>
```

MySQL JDBC Connector

请在 MySQL 官方网站下载相应的 JDBC Connector。

连接代码示例如下：

```
String user = "user_name";
String password = "user_password";
String newUrl = "jdbc:mysql://FE_IP:FE_PORT/demo?
useUnicode=true&characterEncoding=utf8&useTimezone=true&serverTimezone=Asia/Shanghai&useSSL=false&allowPublic
KeyRetrieval=true";
try {
    Connection myCon = DriverManager.getConnection(newUrl, user, password);
    Statement stmt = myCon.createStatement();
    ResultSet result = stmt.executeQuery("show databases");
    ResultSetMetaData metaData = result.getMetaData();
    int columnCount = metaData.getColumnCount();
    while (result.next()) {
        for (int i = 1; i <= columnCount; i++) {
            System.out.println(result.getObject(i));
        }
    }
}
```

```

    }
}
} catch (SQLException e) {
    log.error("get JDBC connection exception.", e);
}
}

```

DBeaver

创建一个到 Apache Doris 的 MySQL 连接：

Connect to a database

Connection Settings
MySQL connection settings

MySQL logo

Main | Driver properties | SSH | SSL | [+ Network configurations...](#)

Server

Connect by: ☒ Host ☐ URL

URL: jdbc:mysql://8.147.106.87:9030/demo

Server Host: 8.147.106.87 Port: 9030

Database: demo

Authentication (Database Native)

Username: admin

Password: ☒ Save password

Advanced


Server Time Zone: Auto-detect

Local Client: /opt/homebrew/Cellar/mysql/8.2.0_1

< Back Next > Cancel Finish

创建到 Apache Doris 的 MySQL 连接

在 DBeaver 中进行查询：




DBeaver Connect

Doris 内置的 Web UI

Doris FE 内置 Web UI。用户无须安装 MySQL 客户端，即可通过内置的 Web UI 进行 SQL 查询和其它相关信息的查看。

在浏览器中输入 `http://fe_ip:fe_port`，比如 `http://172.20.63.118:8030`，打开 Doris 内置的 Web 控制台。


内置 Web 控制台，主要供集群 root 账户使用，默认安装后 root 账户密码为空。



WebUI

比如，在 Playground 中，执行如下语句，可以完成对 BE 节点的添加。

```
ALTER SYSTEM ADD BACKEND "be_host_ip:heartbeat_service_port";
```



Playground

注意

Playground 中执行这种和具体数据库/表没有关系的语句，务必在左侧库栏里随意选择一个数据库，才能执行成功，这个限制，稍后会去掉。

当前内置的 Web 控制台，还不能执行 SET 类型的 SQL 语句，所以，在 Web 控制台，当前还不能通过执行 SET PASSWORD FOR 'user' = PASSWORD('user_password') `类似语句。

数据类型

Apache Doris 已支持的数据类型列表如下：

数值类型

类型名	存储空间 (字节)	描述
BOOLEAN	1	布尔值，0 代表 false，1 代表 true。
TINYINT	1	有符号整数，范围 [-128, 127]。
SMALLINT	2	有符号整数，范围 [-32768, 32767]。
INT	4	有符号整数，范围 [-2147483648, 2147483647]
BIGINT	8	有符号整数，范围 [-9223372036854775808, 9223372036854775807]。
LARGEINT	16	有符号整数，范围 $[-2^{127} + 1 \sim 2^{127} - 1]$ 。
FLOAT	4	浮点数，范围 $[-3.410^{38} \sim 3.410^{38}]$ 。
DOUBLE	8	浮点数，范围 $[-1.7910^{308} \sim 1.7910^{308}]$ 。
DECIMAL	4/8/16	高精度定点数，格式：DECIMAL(M[,D])。其中，M 代表一共有多少个有效数字（precision），D 代表小数位有多少数字（scale）。有效数字 M 的范围是 [1, 38]，小数位数字数量 D 的范围是 [0, precision]。0 < precision <= 9 的场合，占用 4 字节。9 < precision <= 18 的场合，占用 8 字节。16 < precision <= 38 的场合，占用 16 字节。

日期类型

类型名	存储空间（字节）	描述
DATE	16	日期类型，目前的取值范围是 ['0000-01-01', '9999-12-31']，默认的打印形式是 'yyyy-MM-dd'。
DATETIME	16	日期时间类型，格式：DATETIME([P])。可选参数 P 表示时间精度，取值范围是 [0, 6]，即最多支持 6 位小数（微秒）。不设置时为 0。 取值范围是 ['0000-01-01 00:00:00[.000000]', '9999-12-31 23:59:59[.999999]']。打印的形式是 'yyyy-MM-dd HH:mm:ss.SSSSSS'。

字符串类型

类型名	存储空间 (字节)	描述
CHAR	M	定长字符串，M 代表的是定长字符串的字节长度。M 的范围是 1-255。
VARCHAR	不定长	变长字符串，M 代表的是变长字符串的字节长度。M 的范围是 1-65533。变长字符串是以 UTF-8 编码存储的，因此通常英文字符占 1 个字节，中文字符占 3 个字节。
STRING	不定长	变长字符串，默认支持 1048576 字节（1MB），可调大到 2147483643 字节（2GB）。可通过 BE 配置 string_type_length_soft_limit_bytes 调整。String 类型只能用在 Value 列，不能用在 Key 列和分区桶列。

半结构类型

类型名	存储空间 (字节)	描述
ARRAY	不定长	由 T 类型元素组成的数组，不能作为 Key 列使用。目前支持在 Duplicate 和 Unique 模型的表中使用。
MAP	不定长	由 K, V 类型元素组成的 map，不能作为 Key 列使用。目前支持在 Duplicate 和 Unique 模型的表中使用。
STRUCT	不定长	由多个 Field 组成的结构体，也可被理解为多个列的集合。不能作为 Key 使用，目前 STRUCT 仅支持在 Duplicate 模型的表中使用。一个 Struct 中的 Field 的名字和数量固定，总是为 Nullable。
JSON	不定长	二进制 JSON 类型，采用二进制 JSON 格式存储，通过 JSON 函数访问 JSON 内部字段。长度限制和配置方式与 String 相同
VARIANT	不定长	动态可变数据类型，专为半结构化数据如 JSON 设计，可以存入任意 JSON，自动将 JSON 中的字段拆分成子列存储，提升存储效率和查询分析性能。长度限制和配置方式与 String 相同。Variant 类型只能用在 Value 列，不能用在 Key 列和分区分桶列。

聚合类型

类型名	存储空间 (字节)	描述
HLL	不定长	HLL 是模糊去重，在数据量大的情况性能优于 Count Distinct。HLL 的误差通常在 1% 左右，有时能达到 2%。HLL 不能作为 Key 列使用，建表时配合聚合类型为 HLL_UNION。用户不需要指定长度和默认值。长度根据数据的聚合程度系统内控制。HLL 列只能通过配套的 hll_union_agg、hll_raw_agg、hll_cardinality、hll_hash 进行查询或使用。
BITMAP	不定长	Bitmap 类型的列可以在 Aggregate 表、Unique 表或 Duplicate 表中使用。在 Unique 表或 Duplicate 表中使用，其必须作为非 Key 列使用。在 Aggregate 表中使用，其必须作为非 Key 列使用，且建表时配合的聚合类型为 BITMAP_UNION。用户不需要指定长度和默认值。长度根据数据的聚合程度系统内控制。BITMAP 列只能通过配套的 bitmap_union_count、bitmap_union、bitmap_hash、bitmap_hash64 等函数进行查询或使用。
QUANTILE_STATE	不定长	QUANTILE_STATE 是一种计算分位数近似值的类型，在导入时会为相同的 Key，不同 Value 进行预聚合，当 value 数量不超过 2048 时采用明细记录所有数据，当 Value 数量大于 2048 时采用 TDigest 算法，对数据进行聚合（聚类）保存聚类后的质心点。QUANTILE_STATE 不能作为 Key 列使用，建表时配合聚合类型为 QUANTILE_UNION。用户不需要指定长度和默认值。长度根据数据的聚合程度系统内控制。QUANTILE_STATE 列只能通过配套的 QUANTILE_PERCENT、QUANTILE_UNION、TO_QUANTILE_STATE 等函数进行查询或使用。
AGG_STATE	不定长	聚合函数，只能配合 state/merge/union 函数组合器使用。AGG_STATE 不能作为 Key 列使用，建表时需要同时声明聚合函数的签名。用户不需要指定长度和默认值。实际存储的数据大小与函数实现有关。

也可通过 SHOW DATA TYPES; 语句查看 Apache Doris 支持的所有数据类型。

模型概述

本文档主要从逻辑层面，描述 Doris 的数据模型，以帮助用户更好的使用 Doris 应对不同的业务场景。

在 Doris 中，数据以表（Table）的形式进行逻辑上的描述。一张表包括行（Row）和列（Column）。Row 即用户的一行数据，Column 用于描述一行数据中不同的字段。

Column 可以分为两大类：Key 和 Value。从业务角度看，Key 和 Value 可以分别对应维度列和指标列。Doris 的 Key 列是建表语句中指定的列，建表语句中的关键字 unique key 或 aggregate key 或 duplicate key 后面的列就是 Key 列，除了 Key 列剩下的就是 Value 列。

Doris 的数据模型分为 3 类：

- 明细模型（Duplicate Key Model）：允许指定的 Key 列重复，Doris 存储层保留所有写入的数据，适用于必须保留所有原始数据记录的情况。
- 主键模型（Unique Key Model）：每一行的 Key 值唯一，可确保给定的 Key 列不会存在重复行，Doris 存储层对每个 key 只保留最新写入的数据，适用于数据更新的情况。
- 聚合模型（Aggregate Key Model）：可根据 Key 列聚合数据，Doris 存储层保留聚合后的数据，从而可以减少存储空间和提升查询性能；通常用于需要汇总或聚合信息（如总数或平均值）的情况。

明细模型

在某些多维分析场景下，必须保留所有原始数据记录，针对这种需求，可以使用明细数据模型。在明细数据模型中，存储层会保留写入的所有数据。即使两行数据完全相同，也都会保留。建表语句中指定的 Duplicate Key，只是用来指明数据存储按照哪些列进行排序，可以用于优化常用查询。在 Duplicate Key 的选择上，建议选择前 2-4 列即可。

举例如下，一个表有如下的数据列，需要保留所有原始数据记录，有两种方法可以创建明细模型的表，分别为：指定排序列以及默认为明细模型。

ColumnName	Type	Comment
timestamp	DATETIME	日志时间
type	INT	日志类型
error_code	INT	错误码
error_msg	VARCHAR(128)	错误详细信息
op_id	BIGINT	负责人 ID
op_time	DATETIME	处理时间

指定排序列的明细模型

在建表语句中指定 Duplicate Key，用来指明数据存储按照这些 Key 列进行排序。在 Duplicate Key 的选择上，建议选择前 2-4 列即可。

建表语句举例如下，指定了按照 timestamp、type 和 error_code 三列进行排序。

```
CREATE TABLE IF NOT EXISTS example_tbl_duplicate
(
    `timestamp` DATETIME NOT NULL COMMENT "日志时间",
    `type` INT NOT NULL COMMENT "日志类型",
    `error_code` INT COMMENT "错误码",
    `error_msg` VARCHAR(1024) COMMENT "错误详细信息",
    `op_id` BIGINT COMMENT "负责人id",
    `op_time` DATETIME COMMENT "处理时间"
)
DUPLICATE KEY(`timestamp`, `type`, `error_code`)
DISTRIBUTED BY HASH(`type`) BUCKETS 10
PROPERTIES (
    "replication_allocation" = "tag.location.default: 3"
);

MySQL> desc example_tbl_duplicate;
```

Field	Type	Null	Key	Default	Extra
timestamp	datetime	No	true	NULL	
type	int	No	true	NULL	
error_code	int	Yes	true	NULL	
error_msg	varchar(1024)	Yes	false	NULL	NONE
op_id	bigint	Yes	false	NULL	NONE

op_time	datetime	Yes	false	NULL	NONE	
+-----+	+-----+	+-----+	+-----+	+-----+	+-----+	+-----+

默认为明细模型

当创建表的时候没有指定 Unique、Aggregate 或 Duplicate 时，会默认创建一个 Duplicate 模型的表，并自动按照一定规则选定排序列。建表语句举例如下，没有指定任何数据模型，则建立的是明细模型（Duplicate），排序列系统自动选定了前 3 列。

```
CREATE TABLE IF NOT EXISTS example_tbl_by_default
(
    `timestamp` DATETIME NOT NULL COMMENT "日志时间",
    `type` INT NOT NULL COMMENT "日志类型",
    `error_code` INT COMMENT "错误码",
    `error_msg` VARCHAR(1024) COMMENT "错误详细信息",
    `op_id` BIGINT COMMENT "负责人id",
    `op_time` DATETIME COMMENT "处理时间"
)
DISTRIBUTED BY HASH(`type`) BUCKETS 10
PROPERTIES (
    "replication_allocation" = "tag.location.default: 3"
);

MySQL> desc example_tbl_by_default;
```

Field	Type	Null	Key	Default	Extra
timestamp	datetime	No	true	NULL	
type	int	No	true	NULL	
error_code	int	Yes	true	NULL	
error_msg	varchar(1024)	Yes	false	NULL	NONE
op_id	bigint	Yes	false	NULL	NONE
op_time	datetime	Yes	false	NULL	NONE

主键模型

当用户有数据更新需求时，可以选择使用主键数据模型（Unique）。主键模型能够保证 Key（主键）的唯一性，当用户更新一条数据时，新写入的数据会覆盖具有相同 key（主键）的旧数据。

主键模型提供了两种实现方式：

- 读时合并 (Merge-on-Read)。在读时合并实现中，用户在进行数据写入时不会触发任何数据去重相关的操作，所有数据去重的操作都在查询或者 compaction 时进行。因此，读时合并的写入性能较好，查询性能较差，同时内存消耗也较高。
- 写时合并 (Merge-on-Write)。从 1.2 版本中，Doris 引入了写时合并实现，该实现会在数据写入阶段完成所有数据去重的工作，因此能够提供非常好的查询性能。在开启了写时合并选项的 Unique 表上，数据在导入阶段就会去将被覆盖和被更新的数据进行标记删除，同时将新的数据写入新的文件。在查询的时候，所有被标记删除的数据都会在文件级别被过滤掉，读取出来的数据就都是最新的数据，消除掉了读时合并中的数据聚合过程，并且能够在很多情况下支持多种谓词的下推。因此在许多场景都能带来比较大的性能提升，尤其是在有聚合查询的情况下。

下面以一个典型的用户基础信息表，来看看如何建立读时合并和写时合并的主键模型表。这个表数据没有聚合需求，只需保证主键唯一性。（这里的主键为 user_id + username）。

ColumnName	Type	IsKey	Comment
user_id	BIGINT	Yes	用户 id
username	VARCHAR(50)	Yes	用户昵称
city	VARCHAR(20)	No	用户所在城市
age	SMALLINT	No	用户年龄
sex	TINYINT	No	用户性别
phone	LARGEINT	No	用户电话
address	VARCHAR(500)	No	用户住址
register_time	DATETIME	No	用户注册时间

读时合并

读时合并的建表语句如下：

```
CREATE TABLE IF NOT EXISTS example_tbl_unique
(
    `user_id` LARGEINT NOT NULL COMMENT "用户id",
    `username` VARCHAR(50) NOT NULL COMMENT "用户昵称",
    `city` VARCHAR(20) COMMENT "用户所在城市",
    `age` SMALLINT COMMENT "用户年龄",
    `sex` TINYINT COMMENT "用户性别",
    `phone` LARGEINT COMMENT "用户电话",
    `address` VARCHAR(500) COMMENT "用户地址",
    `register_time` DATETIME COMMENT "用户注册时间"
)
```

```
UNIQUE KEY(`user_id`, `username`)
DISTRIBUTED BY HASH(`user_id`) BUCKETS 1
PROPERTIES (
  "replication_allocation" = "tag.location.default: 1"
);
```

写时合并

写时合并建表语句为：

```
CREATE TABLE IF NOT EXISTS example_tbl_unique_merge_on_write
(
  `user_id` LARGEINT NOT NULL COMMENT "用户id",
  `username` VARCHAR(50) NOT NULL COMMENT "用户昵称",
  `city` VARCHAR(20) COMMENT "用户所在城市",
  `age` SMALLINT COMMENT "用户年龄",
  `sex` TINYINT COMMENT "用户性别",
  `phone` LARGEINT COMMENT "用户电话",
  `address` VARCHAR(500) COMMENT "用户地址",
  `register_time` DATETIME COMMENT "用户注册时间"
)
UNIQUE KEY(`user_id`, `username`)
DISTRIBUTED BY HASH(`user_id`) BUCKETS 1
PROPERTIES (
  "replication_allocation" = "tag.location.default: 1",
  "enable_unique_key_merge_on_write" = "true"
);
```

用户需要在建表时添加下面的 property 来开启写时合并。

```
"enable_unique_key_merge_on_write" = "true"
```

注意

在 2.1 版本中，写时合并将会是主键模型的默认方式。所以如果使用 Doris 2.1 版本，务必要阅读相关建表文档。

使用注意

- Unique 表的实现方式只能在建表时确定，无法通过 schema change 进行修改。
- 旧的 Merge-on-Read 的实现无法无缝升级到 Merge-on-Write 的实现（数据组织方式完全不同），如果需要改为使用写时合并的实现版本，需要手动执行 `insert into unique-mow-table select * from source table` 来重新导入。
- 整行更新：Unique 模型默认的更新语义为整行 UPSERT，即 UPDATE OR INSERT，该行数据的 key 如果存在，则进行更新，如果不存在，则进行新数据插入。在整行 UPSERT 语义下，即用户使用 insert into 指定部分列进行写入，Doris 也会在 Planner 中将未提供的列使用 NULL 值或者默认值进行填充
- 部分列更新。如果用户希望更新部分字段，需要使用写时合并实现，并通过特定的参数来开启部分列更新的支持。请查阅文档[部分列更新](#)获取相关使用建议。

聚合模型

聚合数据模型，也称为 Aggregate 数据模型。可根据 Key 列聚合数据，Doris 存储层保留聚合后的数据，从而可以减少存储空间和提升查询性能；通常用于需要汇总或聚合信息（如总数或平均值）的情况。

下面以实际的例子来说明什么是聚合模型，以及如何正确的使用聚合模型。

导入数据聚合

假设业务有如下数据表模式：

ColumnName	Type	AggregationType	Comment
user_id	LARGEINT		用户 id
date	DATE		数据灌入日期
city	VARCHAR(20)		用户所在城市
age	SMALLINT		用户年龄
sex	TINYINT		用户性别
last_visit_date	DATETIME	REPLACE	用户最后一次访问时间
cost	BIGINT	SUM	用户总消费
max_dwell_time	INT	MAX	用户最大停留时间
min_dwell_time	INT	MIN	用户最小停留时间

如果转换成建表语句则如下（省略建表语句中的 Partition 和 Distribution 信息）

```
CREATE TABLE IF NOT EXISTS example_tbl_agg1
(
  `user_id` LARGEINT NOT NULL COMMENT "用户id",
  `date` DATE NOT NULL COMMENT "数据灌入日期时间",
  `city` VARCHAR(20) COMMENT "用户所在城市",
  `age` SMALLINT COMMENT "用户年龄",
  `sex` TINYINT COMMENT "用户性别",
  `last_visit_date` DATETIME REPLACE DEFAULT "1970-01-01 00:00:00" COMMENT "用户最后一次访问时间",
  `cost` BIGINT SUM DEFAULT "0" COMMENT "用户总消费",
  `max_dwell_time` INT MAX DEFAULT "0" COMMENT "用户最大停留时间",
  `min_dwell_time` INT MIN DEFAULT "99999" COMMENT "用户最小停留时间"
)
AGGREGATE KEY(`user_id`, `date`, `city`, `age`, `sex`)
DISTRIBUTED BY HASH(`user_id`) BUCKETS 10
PROPERTIES (
  "replication_allocation" = "tag.location.default: 3"
);
```

这是一个典型的用户信息和访问行为的事实表。在一般星型模型中，用户信息和访问行为一般分别存放在维度表和事实表中。这里为了更加方便的解释 Doris 的数据模型，将两部分信息统一存放在一张表中。

表中的列按照是否设置了 AggregationType，分为 Key (维度列) 和 Value (指标列)。没有设置 AggregationType 的 user_id、date、age、sex 称为 Key，而设置了 AggregationType 的称为 Value。

当导入数据时，对于 Key 列相同的行会聚合成一行，而 Value 列会按照设置的 AggregationType 进行聚合。AggregationType 目前有以下几种聚合方式和 agg_state：

- SUM：求和，多行的 Value 进行累加。
- REPLACE：替代，下一批数据中的 Value 会替换之前导入过的行中的 Value。
- MAX：保留最大值。
- MIN：保留最小值。
- REPLACE_IF_NOT_NULL：非空值替换。和 REPLACE 的区别在于对于 null 值，不做替换。
- HLL_UNION：HLL 类型的列的聚合方式，通过 HyperLogLog 算法聚合。
- BITMAP_UNION：BIMTAP 类型的列的聚合方式，进行位图的并集聚合。

如果这几种聚合方式无法满足需求，则可以选择使用 agg_state 类型。

假设有以下导入数据（原始数据）：

user_id	date	city	age	sex	last_visit_date	cost	max_dwell_time	min_dwell_time
10000	2017/10/1	北京	20	0	2017/10/1 6:00	20	10	10
10000	2017/10/1	北京	20	0	2017/10/1 7:00	15	2	2
10001	2017/10/1	北京	30	1	2017/10/1 17:05	2	22	22
10002	2017/10/2	上海	20	1	2017/10/2 12:59	200	5	5
10003	2017/10/2	广州	32	0	2017/10/2 11:20	30	11	11
10004	2017/10/1	深圳	35	0	2017/10/1 10:00	100	3	3
10004	2017/10/3	深圳	35	0	2017/10/3 10:20	11	6	6

通过 SQL 导入数据：

```
insert into example_tbl_agg1 values
(10000,"2017-10-01","北京",20,0,"2017-10-01 06:00:00",20,10,10),
(10000,"2017-10-01","北京",20,0,"2017-10-01 07:00:00",15,2,2),
(10001,"2017-10-01","北京",30,1,"2017-10-01 17:05:45",2,22,22),
(10002,"2017-10-02","上海",20,1,"2017-10-02 12:59:12",200,5,5),
(10003,"2017-10-02","广州",32,0,"2017-10-02 11:20:00",30,11,11),
(10004,"2017-10-01","深圳",35,0,"2017-10-01 10:00:15",100,3,3),
(10004,"2017-10-03","深圳",35,0,"2017-10-03 10:20:22",11,6,6);
```

这是一张记录用户访问某商品页面行为的表。以第一行数据为例，解释如下：

数据	说明
10000	用户 id，每个用户唯一识别 id

数据	说明
2017/10/1	数据入库时间，精确到日期
北京	用户所在城市
20	用户年龄
0	性别男（1 代表女性）
2017/10/1 6:00	用户本次访问该页面的时间，精确到秒
20	用户本次访问产生的消费
10	用户本次访问，驻留该页面的时间
10	用户本次访问，驻留该页面的时间（冗余）

那么当这批数据正确导入到 Doris 中后，Doris 中最终存储如下：

user_id	date	city	age	sex	last_visit_date	cost	max_dwell_time	min_dwell_time
10000	2017/10/1	北京	20	0	2017/10/1 7:00	35	10	2
10001	2017/10/1	北京	30	1	2017/10/1 17:05	2	22	22
10002	2017/10/2	上海	20	1	2017/10/2 12:59	200	5	5
10003	2017/10/2	广州	32	0	2017/10/2 11:20	30	11	11
10004	2017/10/1	深圳	35	0	2017/10/1 10:00	100	3	3
10004	2017/10/3	深圳	35	0	2017/10/3 10:20	11	6	6

可以看到，用户 10000 只剩下了五行聚合后的数据。而其余用户的数据和原始数据保持一致。对于用户 10000 聚合后的数据，前 5 列没有变化：

- 第 6 列值为 2017-10-01 07:00:00。因为 last_visit_date 列的聚合方式为 REPLACE，所以 2017-10-01 07:00:00 替换了 2017-10-01 06:00:00 保存了下来。注意：在同一个导入批次中的数据，对于 REPLACE 这种聚合方式，替换顺序不做保证，如在这个例子中，最终保存下来的，也有可能是 2017-10-01 06:00:00；而对于不同导入批次中的数据，可以保证，后一批次的数据会替换前一批次。
- 第 7 列值为 35：因为 cost 列的聚合类型为 SUM，所以由 20 + 15 累加获得 35。
- 第 8 列值为 10：因为 max_dwell_time 列的聚合类型为 MAX，所以 10 和 2 取最大值，获得 10。
- 第 9 列值为 2：因为 min_dwell_time 列的聚合类型为 MIN，所以 10 和 2 取最小值，获得 2。

经过聚合，Doris 中最终只会存储聚合后的数据。换句话说，即明细数据会丢失，用户不能够再查询到聚合前的明细数据了。

导入数据与已有数据聚合

假设现在表中已经拥有了前面导入的数据：

user_id	date	city	age	sex	last_visit_date	cost	max_dwell_time	min_dwell_time
10000	2017/10/1	北京	20	0	2017/10/1 7:00	35	10	2

user_id	date	city	age	sex	last_visit_date	cost	max_dwell_time	min_dwell_time
10001	2017/10/1	北京	30	1	2017/10/1 17:05	2	22	22
10002	2017/10/2	上海	20	1	2017/10/2 12:59	200	5	5
10003	2017/10/2	广州	32	0	2017/10/2 11:20	30	11	11
10004	2017/10/1	深圳	35	0	2017/10/1 10:00	100	3	3
10004	2017/10/3	深圳	35	0	2017/10/3 10:20	11	6	6

再导入一批新的数据：

user_id	date	city	age	sex	last_visit_date	cost	max_dwell_time	min_dwell_time
10004	2017/10/3	深圳	35	0	2017/10/3 11:22	44	19	19
10005	2017/10/3	长沙	29	1	2017/10/3 18:11	3	1	1

通过 SQL 导入数据：

```
insert into example_tbl_agg1 values
(10004,"2017-10-03","深圳",35,0,"2017-10-03 11:22:00",44,19,19),
(10005,"2017-10-03","长沙",29,1,"2017-10-03 18:11:02",3,1,1);
```

那么当这批数据正确导入到 Doris 中后，Doris 中最终存储如下：

user_id	date	city	age	sex	last_visit_date	cost	max_dwell_time	min_dwell_time
10000	2017/10/1	北京	20	0	2017/10/1 7:00	35	10	2
10001	2017/10/1	北京	30	1	2017/10/1 17:05	2	22	22
10002	2017/10/2	上海	20	1	2017/10/2 12:59	200	5	5
10003	2017/10/2	广州	32	0	2017/10/2 11:20	30	11	11
10004	2017/10/1	深圳	35	0	2017/10/1 10:00	100	3	3
10004	2017/10/3	深圳	35	0	2017/10/3 11:22	55	19	6
10005	2017/10/3	长沙	29	1	2017/10/3 18:11	3	1	1

可以看到，用户 10004 的已有数据和新导入的数据发生了聚合。同时新增了 10005 用户的数据。

数据的聚合，在 Doris 中有如下三个阶段发生：

1. 每一批次数据导入的 ETL 阶段。该阶段会在每一批次导入的数据内部进行聚合。
2. 底层 BE 进行数据 Compaction 的阶段。该阶段，BE 会对已导入的不同批次的数据进行进一步的聚合。
3. 数据查询阶段。在数据查询时，对于查询涉及到的数据，会进行对应的聚合。

数据在不同时间，可能聚合的程度不一致。比如一批数据刚导入时，可能还未与之前已存在的数据进行聚合。但是对于用户而言，用户只能查询到聚合后的数据。即不同的聚合程度对于用户查询而言是透明的。用户需始终认

为数据以最终的完成的聚合程度存在，而不应假设某些聚合还未发生。（可参阅聚合模型的局限性一节获得更多详情。）

使用注意

建表时列类型建议

- 1. Key 列必须在所有 Value 列之前。
- 2. 尽量选择整型类型。因为整型类型的计算和查找效率远高于字符串。
- 3. 对于不同长度的整型类型的选择原则，遵循够用即可。
- 4. 对于 VARCHAR 和 STRING 类型的长度，遵循够用即可。

聚合模型的局限性

这里针对 Aggregate 模型，来介绍下聚合模型的局限性。

在聚合模型中，模型对外展现的，是最终聚合后的数据。也就是说，任何还未聚合的数据（比如说两个不同导入批次的数据），必须通过某种方式，以保证对外展示的一致性。举例说明。

假设表结构如下：

ColumnName	Type	AggregationType	Comment
user_id	LARGEINT		用户 id
date	DATE		数据灌入日期
cost	BIGINT	SUM	用户总消费

假设存储引擎中有如下两个已经导入完成的批次的数据：

batch 1

user_id	date	cost
10001	2017/11/20	50
10002	2017/11/21	39

batch 2

user_id	date	cost
10001	2017/11/20	1
10001	2017/11/21	5
10003	2017/11/22	22

可以看到，用户 10001 分属在两个导入批次中的数据还没有聚合。但是为了保证用户只能查询到如下最终聚合后的数据：

user_id	date	cost
10001	2017/11/20	51
10001	2017/11/21	5
10002	2017/11/21	39
10003	2017/11/22	22

我们在查询引擎中加入了聚合算子，来保证数据对外的一致性。

另外，在聚合列（Value）上，执行与聚合类型不一致的聚合类查询时，要注意语意。比如在如上示例中执行如下查询：

```
SELECT MIN(cost) FROM table;
```

得到的结果是 5，而不是 1。

同时，这种一致性保证，在某些查询中，会极大地降低查询效率。

以最基本的 count(*) 查询为例：

```
SELECT COUNT(*) FROM table;
```

在其他数据库中，这类查询都会很快地返回结果。因为在实现上，我们可以通过如“导入时对行进行计数，保存 count 的统计信息”，或者在查询时“仅扫描某一列数据，获得 count 值”的方式，只需很小的开销，即可获得查询结果。但是在 Doris 的聚合模型中，这种查询的开销非常大。

以刚才的数据为例：

batch 1

user_id	date	cost
10001	2017/11/20	50
10002	2017/11/21	39

batch 2

user_id	date	cost
10001	2017/11/20	1
10001	2017/11/21	5
10003	2017/11/22	22

因为最终的聚合结果为：

user_id	date	cost
10001	2017/11/20	51
10001	2017/11/21	5

user_id	date	cost
10002	2017/11/21	39
10003	2017/11/22	22

所以，`select count(*) from table;` 的正确结果应该为 4。但如果只扫描 `user_id` 这一列，如果加上查询时聚合，最终得到的结果是 3 (10001, 10002, 10003)。而如果不加查询时聚合，则得到的结果是 5 (两批次一共 5 行数据)。可见这两个结果都是不对的。

为了得到正确的结果，必须同时读取 `user_id` 和 `date` 这两列的数据，再加上查询时聚合，才能返回 4 这个正确的结果。也就是说，在 `count(*)` 查询中，*Doris 必须扫描所有的 AGGREGATE KEY 列 (这里就是 `user_id` `date`)，并且聚合后，才能得到语意正确的结果。* 当聚合列非常多时，`count(*)` 查询需要扫描大量的数据。

因此，当业务上有频繁的 `count(*)` 查询时，建议用户通过增加一个值恒为 1 的，聚合类型为 SUM 的列来模拟 `count(*)`。如刚才的例子中的表结构，我们修改如下：

ColumnName	Type	AggregateType	Comment
user_id	BIGINT		用户 id
date	DATE		数据灌入日期
cost	BIGINT	SUM	用户总消费
count	BIGINT	SUM	用于计算 count

增加一个 `count` 列，并且导入数据中，该列值恒为 1。则 `select count(*) from table;` 的结果等价于 `select sum(count) from table;`。而后者的查询效率将远高于前者。不过这种方式也有使用限制，就是用户需要自行保证，不会重复导入 AGGREGATE KEY 列都相同地行。否则，`select sum(count) from table;` 只能表述原始导入的行数，而不是 `select count(*) from table;` 的语义。

另一种方式，就是将如上的 `count` 列的聚合类型改为 REPLACE，且依然值恒为 1。那么 `select sum(count) from table;` 和 `select count(*) from table;` 的结果将是一致的。并且这种方式，没有导入重复行的限制。

Unique 模型的写时合并实现

Unique 模型的写时合并实现没有聚合模型的局限性，还是以刚才的数据为例，写时合并为每次导入的 rowset 增加了对应的 delete bitmap，来标记哪些数据被覆盖。第一批数据导入后状态如下

batch 1

user_id	date	cost	delete bit
10001	2017/11/20	50	FALSE
10002	2017/11/21	39	FALSE

当第二批数据导入完成后，第一批数据中重复的行就会被标记为已删除，此时两批数据状态如下

batch 1

user_id	date	cost	delete bit
10001	2017/11/20	50	TRUE
10002	2017/11/21	39	FALSE

batch 2

user_id	date	cost	delete bit
10001	2017/11/20	1	FALSE
10001	2017/11/21	5	FALSE
10003	2017/11/22	22	FALSE

在查询时，所有在 delete bitmap 中被标记删除的数据都不会读出来，因此也无需进行做任何数据聚合，上述数据中有效地行数为 4 行，查询出的结果也应该是 4 行，也就可以采取开销最小的方式来获取结果，即前面提到的“仅扫描某一列数据，获得 count 值”的方式。

在测试环境中，count(*) 查询在 Unique 模型的写时合并实现上的性能，相比聚合模型有 10 倍以上的提升。

Duplicate 模型

Duplicate 模型没有聚合模型的这个局限性。因为该模型不涉及聚合语意，在做 count(*) 查询时，任意选择一列查询，即可得到语意正确的结果。

Key 列的不同意义

Duplicate、Aggregate、Unique 模型，都会在建表指定 Key 列，然而实际上是有所区别的：对于 Duplicate 模型，表的 Key 列，可以认为只是“排序列”，并非起到唯一标识的作用。而 Aggregate、Unique 模型这种聚合类型的表，Key 列是兼顾“排序列”和“唯一标识列”，是真正意义上的“Key 列”。

模型选择建议

因为数据模型在建表时就已经确定，且无法修改。所以，选择一个合适的数据模型非常重要。

1. Aggregate 模型可以通过预聚合，极大地降低聚合查询时所需扫描的数据量和查询的计算量，非常适合有固定模式的报表类查询场景。但是该模型对 count(*) 查询很不友好。同时因为固定了 Value 列上的聚合方式，在进行其他类型的聚合查询时，需要考虑语意正确性。
2. Unique 模型针对需要唯一主键约束的场景，可以保证主键唯一性约束。但是无法利用 ROLLUP 等预聚合带来的查询优势。对于聚合查询有较高性能需求的用户，推荐使用自 1.2 版本加入的写时合并实现。
3. Duplicate 适合任意维度的 Ad-hoc 查询。虽然同样无法利用预聚合的特性，但是不受聚合模型的约束，可以发挥列存模型的优势（只读取相关列，而不需要读取所有 Key 列）。
4. 如果有部分列更新的需求，请查阅文档[主键模型部分列更新](#)与[聚合模型部份列更新](#)获取相关使用建议。

行列混存

行列混存介绍

Doris 默认采用列式存储，每个列连续存储，在分析场景（如聚合，过滤，排序等）有很好的性能，因为只需要读取所需要的列减少不必要的 IO。但是在点查场景（比如 SELECT *），需要读取所有列，每个列都需要一次 IO 导致 IOPS 成为瓶颈，特别对列多的宽表（比如上百列）尤为明显。

为了解决点查场景 IOPS 的瓶颈问题，Doris 2.0.0 版本开始支持行列混存，用户建表时指定开启行存后，点查（比如 SELECT *）每一行只需要一次 IO，在宽表列很多的情况下性能有数量级提升。

行存的原理是在存储时增加了一个额外的列，这个列将对应行的所有列拼接起来采用特殊的二进制格式存储。

使用语法

建表时在表的 PROPERTIES 中指定是否开启行存以及其存储单位大小。

参数	默认值	说明
"store_row_column"	false	对所有列开启行存。
"row_store_page_size"	16384（16 KB）	行存 page 大小（字节）。较小的值适合极致点查性能，但占用更多存储。

使用示例

下面的例子创建一个 8 列的表，开启行存。

```
CREATE TABLE `tbl_point_query` (  
  `key` int(11) NULL,  
  `v1` decimal(27, 9) NULL,  
  `v2` varchar(30) NULL,  
  `v3` varchar(30) NULL,  
  `v4` date NULL,  
  `v5` datetime NULL,  
  `v6` float NULL,  
  `v7` datev2 NULL  
) ENGINE=OLAP  
UNIQUE KEY(`key`)  
COMMENT 'OLAP'  
DISTRIBUTED BY HASH(`key`) BUCKETS 1  
PROPERTIES (  
  "enable_unique_key_merge_on_write" = "true",  
  "light_schema_change" = "true",  
  "store_row_column" = "true",  
  "row_store_page_size" = "4096"  
);
```

查询：

```
SELECT * FROM tbl_point_query WHERE key = 100;
```

更多点查的使用请参考 [高并发点查](#)。

注意事项

1. 开启行存后占用的存储空间会增加，存储空间的增加和数据特点有关，一般是原来表的 2 到 10 倍，具体空间占用需要使用实际数据测试。
2. 不支持通过 ALTER TABLE 修改 store_row_column 属性。

基本概念

本文档主要介绍 Doris 的建表和数据划分，以及建表操作中可能遇到的问题和解决方法。

Row & Column

在 Doris 中，数据都以表（Table）的形式进行逻辑上的描述。

一张表包括行（Row）和列（Column）：

- Row：即用户的一行数据；
- Column：用于描述一行数据中不同的字段；
- Column 可以分为两大类：Key 和 Value。从业务角度看，Key 和 Value 可以分别对应维度列和指标列。Doris 的 key 列是建表语句中指定的列，建表语句中的关键字'unique key'或'aggregate key'或'duplicate key'后面的列就是 key 列，除了 key 列剩下的就是 value 列。从聚合模型的角度来说，Key 列相同的行，会聚合成一行。其中 Value 列的聚合方式由用户在建表时指定。关于更多聚合模型的介绍，可以参阅 [Doris 数据模型](#)。

分区和分桶（Partition & Bucket）

Doris 使用分区和分桶的两层划分方式来组织和管理数据。

分区

分区是指根据表中特定列的值进行分段，将表中的数据划分为更小，更易于管理的不相交的子集，每一个数据子集称为一个分区。每一行数据属于且只属于一个特定的分区。分区可以视为最小的逻辑管理单元。

目前 Doris 支持 Range 和 List 的分区划分方式。建表时如果不指定分区，此时 Doris 会生成一个默认的分区包含表中的所有数据，这个分区对用户是透明的。

合理地根据数据分布特征和查询模式进行分区有许多好处：

- 查询性能提升：通过分区，系统可以根据查询的条件裁剪不相关的分区，减少了数据扫描量，显著提高了查询效率。特别是在处理大规模数据集时，分区策略能大幅度降低I/O负担。
- 管理灵活性：分区使得数据可以按时间、地域等逻辑进行分割，方便数据的归档、清理和备份。例如，按时间分区可以有效地管理历史数据和新增数据，支持基于时间的高效数据维护策略。

分桶

分桶是指将一个分区中的数据进一步按照某种规则被划分更小的不相交的数据单元。每一行数据属于且只属于一个特定的分桶。与根据特定列值对数据进行分段的分区不同，分桶尝试将数据均匀分布在预定义的桶中，从而减少数据倾斜的问题。分桶通过确保数据分布均匀并提高数据局部性以提升查询执行的性能。

目前 Doris 支持 Hash 和 Random 的分桶划分方式。

一个分桶在物理上对应一个数据分片（Tablet），数据分片在物理上是独立存储的，它是数据移动、复制等操作的最小物理存储单元。

合理地分桶能够带来许多收益：

- 均匀数据分布：分桶可以将数据均匀地分布在各个桶中，减少了数据集中或倾斜的风险，从而避免了部分节点或存储设备的资源过载问题。
- 减少热点：通过均匀分布数据，分桶有助于减少某些特定节点或分区过度负载的现象，避免热点问题，提升系统的稳定性和处理能力。
- 提高并发性能：分桶帮助提高并发查询的性能，特别是当多个查询请求需要访问相同分区中的不同数据时，分桶的粒度使得系统能够有效地并行处理多个请求，从而提升吞吐量。

建表举例

Doris 的建表是一个同步命令，SQL 执行完成即返回结果，命令返回成功即表示建表成功。具体建表语法可以参考[CREATE TABLE](#)，也可以通过 `HELP CREATE TABLE` 查看更多帮助。

这里给出了一个采用了 Range 分区 和 Hash 分桶的建表举例。

```
-- Range Partition
CREATE TABLE IF NOT EXISTS example_range_tbl
(
  `user_id` LARGEINT NOT NULL COMMENT "用户id",
  `date` DATE NOT NULL COMMENT "数据灌入日期时间",
  `timestamp` DATETIME NOT NULL COMMENT "数据灌入的时间戳",
  `city` VARCHAR(20) COMMENT "用户所在城市",
  `age` SMALLINT COMMENT "用户年龄",
  `sex` TINYINT COMMENT "用户性别",
  `last_visit_date` DATETIME REPLACE DEFAULT "1970-01-01 00:00:00" COMMENT "用户最后一次访问时间",
  `cost` BIGINT SUM DEFAULT "0" COMMENT "用户总消费",
  `max_dwell_time` INT MAX DEFAULT "0" COMMENT "用户最大停留时间",
  `min_dwell_time` INT MIN DEFAULT "99999" COMMENT "用户最小停留时间"
)
ENGINE=OLAP
AGGREGATE KEY(`user_id`, `date`, `timestamp`, `city`, `age`, `sex`)
PARTITION BY RANGE(`date`)
(
  PARTITION `p201701` VALUES [("2017-01-01"), ("2017-02-01")),
  PARTITION `p201702` VALUES [("2017-02-01"), ("2017-03-01")),
  PARTITION `p201703` VALUES [("2017-03-01"), ("2017-04-01"))
)
DISTRIBUTED BY HASH(`user_id`) BUCKETS 16
PROPERTIES
(
  "replication_num" = "1"
);
```

这里以 AGGREGATE KEY 数据模型为例进行说明。AGGREGATE KEY 数据模型中，所有没有指定聚合方式（SUM、REPLACE、MAX、MIN）的列视为 Key 列。而其余则为 Value 列。

在建表语句的最后 PROPERTIES 中，关于 PROPERTIES 中可以设置的相关参数，可以查看[CREATE TABLE](#) 中的详细介绍。

ENGINE 的类型是 OLAP，即默认的 ENGINE 类型。在 Doris 中，只有这个 ENGINE 类型是由 Doris 负责数据管理和存储的。其他 ENGINE 类型，如 MySQL、Broker、ES 等等，本质上只是对外部其他数据库或系统中的表的映射，以保证 Doris 可以读取这些数据。而 Doris 本身并不创建、管理和存储任何非 OLAP ENGINE 类型的表和数据。

IF NOT EXISTS 表示如果没有创建过该表，则创建。注意这里只判断表名是否存在，而不会判断新建表 Schema 是否与已存在的表 Schema 相同。所以如果存在一个同名但不同 Schema 的表，该命令也会返回成功，但并不代表已经创建了新的表和新的 Schema。。

查看分区信息

可以通过 show create table 来查看表的分区信息。

```
> show create table example_range_tbl
+-----+-----+
| Table           | Create Table                                     |
+-----+-----+
| example_range_tbl | CREATE TABLE `example_range_tbl` (
|
|           | `user_id` largeint(40) NOT NULL COMMENT '用户id',
|
|           | `date` date NOT NULL COMMENT '数据灌入日期时间',
|
|           | `timestamp` datetime NOT NULL COMMENT '数据灌入的时间戳',
|
|           | `city` varchar(20) NULL COMMENT '用户所在城市',
|
|           | `age` smallint(6) NULL COMMENT '用户年龄',
|
|           | `sex` tinyint(4) NULL COMMENT '用户性别',
|
|           | `last_visit_date` datetime REPLACE NULL DEFAULT "1970-01-01 00:00:00" COMMENT '用户最
后一次访问时间', |
|           | `cost` bigint(20) SUM NULL DEFAULT "0" COMMENT '用户总消费',
|
|           | `max_dwell_time` int(11) MAX NULL DEFAULT "0" COMMENT '用户最大停留时间',
|
|           | `min_dwell_time` int(11) MIN NULL DEFAULT "99999" COMMENT '用户最小停留时间'
|
|           | ) ENGINE=OLAP
|
|           | AGGREGATE KEY(`user_id`, `date`, `timestamp`, `city`, `age`, `sex`)
|
|           | COMMENT 'OLAP'
|
|           | PARTITION BY RANGE(`date`)
|
|           | (PARTITION p201701 VALUES [('0000-01-01'), ('2017-02-01')),
|
|           | PARTITION p201702 VALUES [('2017-02-01'), ('2017-03-01')),
|
|           | PARTITION p201703 VALUES [('2017-03-01'), ('2017-04-01'))
|
|           | DISTRIBUTED BY HASH(`user_id`) BUCKETS 16
|
|           | PROPERTIES (
```

可以通过 `show partitions from your_table` 来查看表的分区信息。

修改分区信息

121 / 2281

```
ALTER TABLE example_range_tbl ADD PARTITION p201704 VALUES LESS THAN("2020-05-01") DISTRIBUTED BY  
HASH(`user_id`) BUCKETS 5;
```

其它更多分区修改操作，参见 SQL 手册 [ALTER-TABLE-PARTITION](#)。

手动分区

分区列

- 分区列可以指定一列或多列，分区列必须为 KEY 列。多列分区的使用方式在后面多列分区小结介绍。
- 当 `allow_partition_column_nullable` 为 `true` 时，Range 分区支持使用 NULL 分区列。List Partition 始终不支持 NULL 分区列。
- 不论分区列是什么类型，在写分区值时，都需要加双引号。
- 分区数量理论上没有上限。但默认限制每张表 4096 个分区，如果想突破这个限制，可以修改 FE 配置 `max_multi_partition_num` 和 `max_dynamic_partition_num`。
- 当不使用分区建表时，系统会自动生成一个和表名同名的，全值范围的分区。该分区对用户不可见，并且不可删改。
- 创建分区时不可添加范围重叠的分区。

Range 分区

分区列通常为时间列，以方便的管理新旧数据。Range 分区支持的列类型 DATE, DATETIME, TINYINT, SMALLINT, INT, BIGINT, LARGEINT。

分区信息，支持四种写法：

1. FIXED RANGE：定义分区的左闭右开区间。

```
PARTITION BY RANGE(col1[, col2, ...])
(
  PARTITION partition_name1 VALUES [("k1-lower1", "k2-lower1", "k3-lower1",...), ("k1-upper1", "k2-upper1", "k3-upper1", ...)],
  PARTITION partition_name2 VALUES [("k1-lower1-2", "k2-lower1-2", ...), ("k1-upper1-2", MAXVALUE, )])
```

示例如下：

```
PARTITION BY RANGE(`date`)
(
  PARTITION `p201701` VALUES [("2017-01-01"), ("2017-02-01")),
  PARTITION `p201702` VALUES [("2017-02-01"), ("2017-03-01")),
  PARTITION `p201703` VALUES [("2017-03-01"), ("2017-04-01"))
)
```

2. LESS THAN：仅定义分区上界。下界由上一个分区的上界决定。

```
PARTITION BY RANGE(col1[, col2, ...])
(
  PARTITION partition_name1 VALUES LESS THAN MAXVALUE | ("value1", "value2", ...),
```

```
    PARTITION partition_name2 VALUES LESS THAN MAXVALUE | ("value1", "value2", ...)
)
```

示例如下：

```
PARTITION BY RANGE(`date`)
(
    PARTITION `p201701` VALUES LESS THAN ("2017-02-01"),
    PARTITION `p201702` VALUES LESS THAN ("2017-03-01"),
    PARTITION `p201703` VALUES LESS THAN ("2017-04-01"),
    PARTITION `p2018` VALUES [("2018-01-01"), ("2019-01-01")),
    PARTITION `other` VALUES LESS THAN (MAXVALUE)
)
```

List 分区

分区列支持 BOOLEAN, TINYINT, SMALLINT, INT, BIGINT, LARGEINT, DATE, DATETIME, CHAR, VARCHAR 数据类型，分区值为枚举值。只有当数据为目标分区枚举值其中之一时，才可以命中分区。

Partition 支持通过 VALUES IN (...) 来指定每个分区包含的枚举值。

举例如下：

```
PARTITION BY LIST(city)
(
    PARTITION `p_cn` VALUES IN ("Beijing", "Shanghai", "Hong Kong"),
    PARTITION `p_usa` VALUES IN ("New York", "San Francisco"),
    PARTITION `p_jp` VALUES IN ("Tokyo")
)
```

List 分区也支持多列分区，示例如下：

```
PARTITION BY LIST(id, city)
(
    PARTITION p1_city VALUES IN (("1", "Beijing"), ("1", "Shanghai")),
    PARTITION p2_city VALUES IN (("2", "Beijing"), ("2", "Shanghai")),
    PARTITION p3_city VALUES IN (("3", "Beijing"), ("3", "Shanghai"))
)
```

动态分区

动态分区旨在对表级别的分区实现生命周期管理 (TTL)，减少用户的使用负担。

在某些使用场景下，用户会将表按照天进行分区划分，每天定时执行例行任务，这时需要使用方手动管理分区，否则可能由于使用方没有创建分区导致数据导入失败，这给使用方带来了额外的维护成本。

通过动态分区功能，用户可以在建表时设定动态分区的规则。FE 会启动一个后台线程，根据用户指定的规则创建或删除分区。用户也可以在运行时对现有规则进行变更。

动态分区只支持 Range 分区。目前实现了动态添加分区及动态删除分区的功能。

注意：动态分区功能在被 CCR 同步时将会失效。

如果这个表是被 CCR 复制而来的，即 PROPERTIES 中包含 `is_being_synced = true` 时，在 `show create table` 中会显示开启状态，但不会实际生效。当 `is_being_synced` 被设置为 `false` 时，这些功能将会恢复生效，但 `is_being_synced` 属性仅供 CCR 外围模块使用，在 CCR 同步的过程中不要手动设置。

使用方式

动态分区的规则可以在建表时指定，或者在运行时进行修改。当前仅支持对单分区列的分区表设定动态分区规则。

- 建表时指定

```
CREATE TABLE tbl1
(...)
PROPERTIES
(
  "dynamic_partition.prop1" = "value1",
  "dynamic_partition.prop2" = "value2",
  ...
)
```

- 运行时修改

```
ALTER TABLE tbl1 SET
(
  "dynamic_partition.prop1" = "value1",
  "dynamic_partition.prop2" = "value2",
  ...
)
```

规则参数

动态分区的规则参数都以 `dynamic_partition.` 为前缀：

- `dynamic_partition.enable`

是否开启动态分区特性。可指定为 TRUE 或 FALSE。如果不填写，默认为 TRUE。如果为 FALSE，则 Doris 会忽略该表的动态分区规则。

- **dynamic_partition.time_unit (必选参数)**

动态分区调度的单位。可指定为 HOUR、DAY、WEEK、MONTH、YEAR。分别表示按小时、按天、按星期、按月、按年进行分区创建或删除。

当指定为 HOUR 时，动态创建的分区名后缀格式为 yyyyMMddHH，例如 2020032501。小时为单位的分区列数据类型不能为 DATE。

当指定为 DAY 时，动态创建的分区名后缀格式为 yyyyMMdd，例如 20200325。

当指定为 WEEK 时，动态创建的分区名后缀格式为 yyyy_ww。即当前日期属于这一年的第几周，例如 2020-03-25 创建的分区名后缀为 2020_13，表明目前为 2020 年第 13 周。

当指定为 MONTH 时，动态创建的分区名后缀格式为 yyyyMM，例如 202003。

当指定为 YEAR 时，动态创建的分区名后缀格式为 yyyy，例如 2020。

- **dynamic_partition.time_zone**

动态分区的时区，如果不填写，则默认为当前机器的系统的时区，例如 Asia/Shanghai，如果想获取当前支持的时区设置，可以参考

https://en.wikipedia.org/wiki/List_of_tz_database_time_zones。

- **dynamic_partition.start**

动态分区的起始偏移，为负数。根据 time_unit 属性的不同，以当天（星期/月）为基准，分区范围在此偏移之前的分区将会被删除。如果不填写，则默认为 -2147483648，即不删除历史分区。

- **dynamic_partition.end (必选参数)**

动态分区的结束偏移，为正数。根据 time_unit 属性的不同，以当天（星期/月）为基准，提前创建对应范围的分区。

- **dynamic_partition.prefix (必选参数)**

动态创建的分区名前缀。

- **dynamic_partition.buckets**

动态创建的分区所对应的分桶数量。

- **dynamic_partition.replication_num**

动态创建的分区所对应的副本数量，如果不填写，则默认为该表创建时指定的副本数量。

- **dynamic_partition.start_day_of_week**

当 time_unit 为 WEEK 时，该参数用于指定每周的起始点。取值为 1 到 7。其中 1 表示周一，7 表示周日。默认为 1，即表示每周以周一为起始点。

- **dynamic_partition.start_day_of_month**

当 `time_unit` 为 `MONTH` 时，该参数用于指定每月的起始日期。取值为 1 到 28。其中 1 表示每月 1 号，28 表示每月 28 号。默认为 1，即表示每月以 1 号为起始点。暂不支持以 29、30、31 号为起始日，以避免因闰年或闰月带来的歧义。

- `dynamic_partition.create_history_partition`

默认为 `false`。当置为 `true` 时，Doris 会自动创建所有分区，具体创建规则见下文。同时，FE 的参数 `max_dynamic_partition_num` 会限制总分区数量，以避免一次性创建过多分区。当期望创建的分区个数大于 `max_dynamic_partition_num` 值时，操作将被禁止。

当不指定 `start` 属性时，该参数不生效。

- `dynamic_partition.history_partition_num`

当 `create_history_partition` 为 `true` 时，该参数用于指定创建历史分区数量。默认值为 -1，即未设置。

- `dynamic_partition.hot_partition_num`

指定最新的多少个分区为热分区。对于热分区，系统会自动设置其 `storage_medium` 参数为 `SSD`，并且设置 `storage_cooldown_time`。

注意：若存储路径下没有 `SSD` 磁盘路径，配置该参数会导致动态分区创建失败。

`hot_partition_num` 是往前 `n` 天和未来所有分区

我们举例说明。假设今天是 2021-05-20，按天分区，动态分区的属性设置为：`hot_partition_num=2, end=3, start=-3`。则系统会自动创建以下分区，并且设置 `storage_medium` 和 `storage_cooldown_time` 参数：

```
p20210517: ["2021-05-17", "2021-05-18") storage_medium=HDD storage_cooldown_time=9999-12-31 23:59:59
p20210518: ["2021-05-18", "2021-05-19") storage_medium=HDD storage_cooldown_time=9999-12-31 23:59:59
p20210519: ["2021-05-19", "2021-05-20") storage_medium=SSD storage_cooldown_time=2021-05-21 00:00:00
p20210520: ["2021-05-20", "2021-05-21") storage_medium=SSD storage_cooldown_time=2021-05-22 00:00:00
p20210521: ["2021-05-21", "2021-05-22") storage_medium=SSD storage_cooldown_time=2021-05-23 00:00:00
p20210522: ["2021-05-22", "2021-05-23") storage_medium=SSD storage_cooldown_time=2021-05-24 00:00:00
p20210523: ["2021-05-23", "2021-05-24") storage_medium=SSD storage_cooldown_time=2021-05-25 00:00:00
```

- `dynamic_partition.reserved_history_periods`

需要保留的历史分区的时间范围。当 `dynamic_partition.time_unit` 设置为 “`DAY/WEEK/MONTH/YEAR`” 时，需要以 `[yyyy-MM-dd, yyyy-MM-dd], [...]` 格式进行设置。当 `dynamic_partition.time_unit` 设置为 “`HOURL`” 时，需要以 `[yyyy-MM-dd HH:mm:ss, yyyy-MM-dd HH:mm:ss], [...]` 的格式来进行设置。如果不设置，默认为 “`NULL`”。

举例说明。假设今天是 2021-09-06，按天分类，动态分区的属性设置为：

`time_unit="DAY/WEEK/MONTH/YEAR", end=3, start=-3, reserved_history_periods=["2020-06-01, 2020-06-20"], [2020-10-31, 2020-11-15]"`。

则系统会自动保留：

```
["2020-06-01", "2020-06-20"],
["2020-10-31", "2020-11-15"]
```

或者

```
time_unit="HOUR", end=3, start=-3, reserved_history_periods="[2020-06-01 00:00:00,2020-06-01 03:00:00]"
```

则系统会自动保留：

```
["2020-06-01 00:00:00","2020-06-01 03:00:00"]
```

这两个时间段的分区。其中，reserved_history_periods 的每一个 [...,...] 是一对设置项，两者需要同时被设置，且第一个时间不能大于第二个时间。

- dynamic_partition.storage_medium

指定创建的动态分区的默认存储介质。默认是 HDD，可选择 SSD。

注意，当设置为 SSD 时，hot_partition_num 属性将不再生效，所有分区将默认为 SSD 存储介质并且冷却时间为 9999-12-31 23:59:59。

创建历史分区规则

当 create_history_partition 为 true，即开启创建历史分区功能时，Doris 会根据 dynamic_partition.start 和 dynamic_partition.history_partition_num 来决定创建历史分区的个数。

假设需要创建的历史分区数量为 expect_create_partition_num，根据不同的设置具体数量如下：

- create_history_partition = true

dynamic_partition.history_partition_num 未设置，即 -1. expect_create_partition_num = end - start;

dynamic_partition.history_partition_num 已设置 expect_create_partition_num = end - max(start, - history_partition_num);

- create_history_partition = false 不会创建历史分区，expect_create_partition_num = end - 0;

当 expect_create_partition_num 大于 max_dynamic_partition_num（默认 500）时，禁止创建过多分区。

举例说明：

假设今天是 2021-05-20，按天分区，动态分区的属性设置为，create_history_partition=true，end=3，start=-3，则会根据history_partition_num的设置，举例如下。

- history_partition_num=1，则系统会自动创建以下分区：

```
p20210519
p20210520
p20210521
p20210522
p20210523
```

- history_partition_num=5，则系统会自动创建以下分区：

```
p20210517
p20210518
p20210519
p20210520
p20210521
p20210522
p20210523
```

- history_partition_num=-1 即不设置历史分区数量，则系统会自动创建以下分区：

```
p20210517
p20210518
p20210519
p20210520
p20210521
p20210522
p20210523
```

示例

1. 表 tbl1 分区列 k1 类型为 DATE，创建一个动态分区规则。按天分区，只保留最近 7 天的分区，并且预先创建未来 3 天的分区。

```
CREATE TABLE tbl1
(
    k1 DATE,
    ...
)
PARTITION BY RANGE(k1) ()
DISTRIBUTED BY HASH(k1)
PROPERTIES
(
    "dynamic_partition.enable" = "true",
    "dynamic_partition.time_unit" = "DAY",
    "dynamic_partition.start" = "-7",
    "dynamic_partition.end" = "3",
    "dynamic_partition.prefix" = "p",
    "dynamic_partition.buckets" = "32"
);
```

假设当前日期为 2020-05-29。则根据以上规则，tbl1 会产生以下分区：

```
p20200529: ["2020-05-29", "2020-05-30")
p20200530: ["2020-05-30", "2020-05-31")
p20200531: ["2020-05-31", "2020-06-01")
p20200601: ["2020-06-01", "2020-06-02")
```

在第二天，即 2020-05-30，会创建新的分区 p20200602: ["2020-06-02", "2020-06-03")

在 2020-06-06 时，因为 dynamic_partition.start 设置为 7，则将删除 7 天前的分区，即删除分区 p20200529。

2. 表 tbl1 分区列 k1 类型为 DATETIME，创建一个动态分区规则。按星期分区，只保留最近 2 个星期的分区，并且预先创建未来 2 个星期的分区。

```
CREATE TABLE tbl1
(
    k1 DATETIME,
    ...
)
PARTITION BY RANGE(k1) ()
DISTRIBUTED BY HASH(k1)
PROPERTIES
(
    "dynamic_partition.enable" = "true",
    "dynamic_partition.time_unit" = "WEEK",
    "dynamic_partition.start" = "-2",
    "dynamic_partition.end" = "2",
    "dynamic_partition.prefix" = "p",
    "dynamic_partition.buckets" = "8"
);
```

假设当前日期为 2020-05-29，是 2020 年的第 22 周。默认每周起始为星期一。则以上规则，tbl1 会产生以下分区：

```
p2020_22: ["2020-05-25 00:00:00", "2020-06-01 00:00:00")
p2020_23: ["2020-06-01 00:00:00", "2020-06-08 00:00:00")
p2020_24: ["2020-06-08 00:00:00", "2020-06-15 00:00:00")
```

其中每个分区的起始日期为当周的周一。同时，因为分区列 k1 的类型为 DATETIME，则分区值会补全时分秒部分，且皆为 0。

在 2020-06-15，即第 25 周时，会删除 2 周前的分区，即删除 p2020_22。

在上面的例子中，假设用户指定了周起始日为 "dynamic_partition.start_day_of_week" = "3"，即以每周三为起始日。则分区如下：

```
p2020_22: ["2020-05-27 00:00:00", "2020-06-03 00:00:00")
p2020_23: ["2020-06-03 00:00:00", "2020-06-10 00:00:00")
p2020_24: ["2020-06-10 00:00:00", "2020-06-17 00:00:00")
```

即分区范围为当周的周三到下周的周二。

注：2019-12-31 和 2020-01-01 在同一周内，如果分区的起始日期为 2019-12-31，则分区名为 p2019_53，如果分区的起始日期为 2020-01-01，则分区名为 p2020_01。

3. 表 tbl1 分区列 k1 类型为 DATE，创建一个动态分区规则。按月分区，不删除历史分区，并且预先创建未来 2 个月的分区。同时设定以每月 3 号为起始日。

```
CREATE TABLE tbl1
(
    k1 DATE,
    ...
)
PARTITION BY RANGE(k1) ()
DISTRIBUTED BY HASH(k1)
PROPERTIES
(
```



```

    "dynamic_partition.enable" = "true",
    "dynamic_partition.time_unit" = "MONTH",
    "dynamic_partition.end" = "2",
    "dynamic_partition.prefix" = "p",
    "dynamic_partition.buckets" = "8",
    "dynamic_partition.start_day_of_month" = "3"
);

```

假设当前日期为 2020-05-29。则基于以上规则，tbl1 会产生以下分区：

```

p202005: ["2020-05-03", "2020-06-03")
p202006: ["2020-06-03", "2020-07-03")
p202007: ["2020-07-03", "2020-08-03")

```

因为没有设置 dynamic_partition.start，则不会删除历史分区。

假设今天为 2020-05-20，并设置以每月 28 号为起始日，则分区范围为：

```

p202004: ["2020-04-28", "2020-05-28")
p202005: ["2020-05-28", "2020-06-28")
p202006: ["2020-06-28", "2020-07-28")

```

修改动态分区属性

通过如下命令可以修改动态分区的属性：

```

ALTER TABLE tbl1 SET
(
    "dynamic_partition.prop1" = "value1",
    ...
);

```

某些属性的修改可能会产生冲突。假设之前分区粒度为 DAY，并且已经创建了如下分区：

```

p20200519: ["2020-05-19", "2020-05-20")
p20200520: ["2020-05-20", "2020-05-21")
p20200521: ["2020-05-21", "2020-05-22")

```

如果此时将分区粒度改为 MONTH，则系统会尝试创建范围为 ["2020-05-01", "2020-06-01") 的分区，而该分区的分区范围和已有分区冲突，所以无法创建。而范围为 ["2020-06-01", "2020-07-01") 的分区可以正常创建。因此，2020-05-22 到 2020-05-30 时间段的分区，需要自行填补。

查看动态分区表调度情况

通过以下命令可以进一步查看当前数据库下，所有动态分区表的调度情况：

```

> SHOW DYNAMIC PARTITION TABLES;
+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+
| TableName | Enable | TimeUnit | Start      | End  | Prefix | Buckets | StartOf    | LastUpdateTime |
| LastSchedulerTime | State | LastCreatePartitionMsg | LastDropPartitionMsg | ReservedHistoryPeriods |
+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+

```

d3	true	WEEK	-3	3	p	1	MONDAY	N/A	2020-
05-25 14:29:24	NORMAL	N/A		N/A			[2021-12-01,2021-12-31]		
d5	true	DAY	-7	3	p	32	N/A	N/A	2020-
05-25 14:29:24	NORMAL	N/A		N/A			NULL		
d4	true	WEEK	-3	3	p	1	WEDNESDAY	N/A	2020-
05-25 14:29:24	NORMAL	N/A		N/A			NULL		
d6	true	MONTH	-2147483648	2	p	8	3rd	N/A	2020-
05-25 14:29:24	NORMAL	N/A		N/A			NULL		
d2	true	DAY	-3	3	p	32	N/A	N/A	2020-
05-25 14:29:24	NORMAL	N/A		N/A			NULL		
d7	true	MONTH	-2147483648	5	p	8	24th	N/A	2020-
05-25 14:29:24	NORMAL	N/A		N/A			NULL		
+-----+-----+-----+-----+-----+-----+-----+-----+-----+									
7 rows in set (0.02 sec)									

- LastUpdateTime: 最后一次修改动态分区属性的时间
- LastSchedulerTime: 最后一次执行动态分区调度的时间
- State: 最后一次执行动态分区调度的状态
- LastCreatePartitionMsg: 最后一次执行动态添加分区调度的错误信息
- LastDropPartitionMsg: 最后一次执行动态删除分区调度的错误信息

高级操作

FE 配置项

- dynamic_partition_enable

是否开启 Doris 的动态分区功能。默认为 false，即关闭。该参数只影响动态分区表的分区操作，不影响普通表。可以通过修改 fe.conf 中的参数并重启 FE 生效。也可以在运行时执行以下命令生效：

```
# MySQL 协议
ADMIN SET FRONTEND CONFIG ("dynamic_partition_enable" = "true")

# HTTP 协议
curl --location-trusted -u username:password -XGET http://fe_host:fe_http_port/api/_set_config?dynamic_partition_enable=true
```

若要全局关闭动态分区，则设置此参数为 false 即可。

- dynamic_partition_check_interval_seconds

动态分区线程的执行频率，默认为 600(10 分钟)，即每 10 分钟进行一次调度。可以通过修改 fe.conf 中的参数并重启 FE 生效。也可以在运行时执行以下命令修改：

```
# MySQL 协议
ADMIN SET FRONTEND CONFIG ("dynamic_partition_check_interval_seconds" = "7200")

# HTTP 协议
curl --location-trusted -u username:password -XGET http://fe_host:fe_http_port/api/_set_config?dynamic_partition_check_interval_seconds=432000
```

动态分区表与手动分区表相互转换

对于一个表来说，动态分区和手动分区可以自由转换，但二者不能同时存在，有且只有一种状态。

- 手动分区转换为动态分区

如果一个表在创建时未指定动态分区，可以通过 `ALTER TABLE` 在运行时修改动态分区相关属性来转化为动态分区，具体示例可以通过 `HELP ALTER TABLE` 查看。

开启动态分区功能后，Doris 将不再允许用户手动管理分区，会根据动态分区属性来自动管理分区。

注意：如果已设定 `dynamic_partition.start`，分区范围在动态分区起始偏移之前的历史分区将会被删除。

- 动态分区转换为手动分区

通过执行 `ALTER TABLE tbl_name SET ("dynamic_partition.enable" = "false")` 即可关闭动态分区功能，将其转换为手动分区表。

关闭动态分区功能后，Doris 将不再自动管理分区，需要用户手动通过 `ALTER TABLE` 的方式创建或删除分区。

注意事项

动态分区使用过程中，如果因为一些意外情况导致 `dynamic_partition.start` 和 `dynamic_partition.end` 之间的某些分区丢失，那么当前时间与 `dynamic_partition.end` 之间的丢失分区会被重新创建，`dynamic_partition.start` 与当前时间之间的丢失分区不会重新创建。

手动分桶

如果使用了分区，则 `DISTRIBUTED ...` 语句描述的是数据在各个分区内的划分规则。

如果不使用分区，则描述的是对整个表的数据的划分规则。

也可以对每个分区单独指定分桶方式。

分桶列可以是多列，Aggregate 和 Unique 模型必须为 Key 列，Duplicate 模型可以是 key 列和 value 列。分桶列可以和 Partition 列相同或不同。

分桶列的选择，是在 查询吞吐 和 查询并发 之间的一种权衡：

- 如果选择多个分桶列，则数据分布更均匀。如果一个查询条件不包含所有分桶列的等值条件，那么该查询会触发所有分桶同时扫描，这样查询的吞吐会增加，单个查询的延迟随之降低。这个方式适合大吞吐低并发的查询场景。
- 如果仅选择一个或少数分桶列，则对应的点查询可以仅触发一个分桶扫描。此时，当多个点查询并发时，这些查询有较大的概率分别触发不同的分桶扫描，各个查询之间的 IO 影响较小（尤其当不同桶分布在不同磁盘上时），所以这种方式适合高并发的点查询场景。

Bucket 的数量和数据量的建议

- 一个表的 Tablet 总数量等于 $(\text{Partition num} * \text{Bucket num})$ 。
- 一个表的 Tablet 数量，在不考虑扩容的情况下，推荐略多于整个集群的磁盘数量。
- 单个 Tablet 的数据量理论上没有上下界，但建议在 1G - 10G 的范围内。如果单个 Tablet 数据量过小，则数据的聚合效果不佳，且元数据管理压力大。如果数据量过大，则不利于副本的迁移、补齐，且会增加 Schema Change 或者 Rollup 操作失败重试的代价（这些操作失败重试的粒度是 Tablet）。
- 当 Tablet 的数据量原则和数量原则冲突时，建议优先考虑数据量原则。
- 在建表时，每个分区的 Bucket 数量统一指定。但是在动态增加分区时（`ADD PARTITION`），可以单独指定新分区的 Bucket 数量。可以利用这个功能方便的应对数据缩小或膨胀。
- 一个 Partition 的 Bucket 数量一旦指定，不可更改。所以在确定 Bucket 数量时，需要预先考虑集群扩容的情况。比如当前只有 3 台 host，每台 host 有 1 块盘。如果 Bucket 的数量只设置为 3 或更小，那么后期即使再增加机器，也不能提高并发度。
- 举一些例子：假设有 10 台 BE，每台 BE 一块磁盘的情况下。如果一个表总大小为 500MB，则可以考虑 4-8 个分片。5GB：8-16 个分片。50GB：32 个分片。500GB：建议分区，每个分区大小在 50GB 左右，每个分区 16-32 个分片。5TB：建议分区，每个分区大小在 50GB 左右，每个分区 16-32 个分片。

表的数据量可以通过 `SHOW DATA` 命令查看（该命令的统计结果会有延迟），结果除以副本数，即表的数据量。

Random Distribution

- 如果 OLAP 表没有更新类型的字段，将表的数据分桶模式设置为 RANDOM，则可以避免严重的数据倾斜（数据在导入表对应的分区的时候，单次导入作业每个 batch 的数据将随机选择一个 tablet 进行写入）。
- 当表的分桶模式被设置为 RANDOM 时，因为没有分桶列，无法根据分桶列的值仅对几个分桶查询，对表进行查询的时候将对命中分区的全部分桶同时扫描，该设置适合对表数据整体的聚合查询分析而不适合高并发的点查询。
- 如果 OLAP 表的是 Random Distribution 的数据分布，那么在数据导入的时候可以设置单分片导入模式（将 `load_to_single_tablet` 设置为 `true`），那么在大数据量的导入的时候，一个任务在将数据写入对应的分区时将只写入一个分片，这样将能提高数据导入的并发度和吞吐量，减少数据导入和 Compaction 导致的写放大问题，保障集群的稳定性。

自动分桶

用户经常设置不合适的 bucket，导致各种问题，这里提供一种方式，来自动设置分桶数。当前只对 OLAP 表生效。

注意：这个功能在被 CCR 同步时将会失效。如果这个表是被 CCR 复制而来的，即 **PROPERTIES** 中包含 `is_being_synced = true` 时，在 `show create table` 中会显示开启状态，但不会实际生效。当 `is_being_synced` 被设置为 `false` 时，这些功能将会恢复生效，但 `is_being_synced` 属性仅供 CCR 外围模块使用，在 CCR 同步的过程中不要手动设置。

以往创建分桶时需要手动设定分桶数，而自动分桶推算功能是 Apache Doris 可以动态地推算分桶个数，使得分桶数始终保持在一个合适范围内，让用户不再操心桶数的细枝末节。首先说明一点，为了方便阐述该功能，该部分会将桶拆分为两个时期的桶，即初始分桶以及后续分桶；这里的初始和后续只是本文为了描述清楚该功能而采用的术语，Apache Doris 分桶本身没有初始和后续之分。从上文中创建分桶一节我们知道，`BUCKET_DESC` 非常简单，但是需要指定分桶个数；而在自动分桶推算功能上，`BUCKET_DESC` 的语法直接将分桶数改成“Auto”，并新增一个 Properties 配置即可：

```
-- 旧版本指定分桶个数的创建语法
DISTRIBUTED BY HASH(site) BUCKETS 20

-- 新版本使用自动分桶推算的创建语法
DISTRIBUTED BY HASH(site) BUCKETS AUTO
properties("estimate_partition_size" = "2G")
```

新增的配置参数 `estimate_partition_size` 用于指定单个分区的数据量。该参数为可选项，若未设置，Doris 会默认将 `estimate_partition_size` 取值为 10GB。如前文所述，在物理层面上，一个分桶对应一个 Tablet。为了获得最佳性能，建议每个 Tablet 的大小控制在 1GB 至 15GB 之间。

那么自动分桶推算是如何保证 Tablet 大小处于这个范围内的呢？

- 若是整体数据量较小，则分桶数不要设置过多
- 若是整体数据量较大，则应使桶数跟总的磁盘块数相关，充分利用每台 BE 机器和每块磁盘的能力

初始分桶推算

1. 首先根据数据量计算桶数 N。具体做法是将 `estimate_partition_size` 的数值除以 5（因为以文本格式存储时，Doris 通常有 5:1 的数据压缩比），然后根据分区大小估算桶数。在存算一体架构下，默认每 5GB 分区大小对应一个分桶；在存算分离架构下，默认每 10GB 分区大小对应一个分桶。该默认值可通过 FE 配置项 `autobucket_partition_size_per_bucket_gb` 进行调整。最终得到的结果如下：

```
(, 100MB), 则取 N=1
[100MB, 1GB), 则取 N=2
[1GB, ), 则每(autobucket_partition_size_per_bucket_gb) GB 一个分桶
```

2. 根据 BE 节点数以及每个 BE 节点的磁盘容量，计算出桶数 M。

其中每个 BE 节点算 1, 每 50G 的磁盘容量算 1,
M 的计算规则为: $M = \text{BE 节点数} * (\text{一块磁盘块大小} / 50\text{GB}) * \text{磁盘块数}$
举例: 有 3 台 BE, 每台 BE 都有 4 块 500GB 的磁盘, 那么 $M = 3 (500\text{GB} / 50\text{GB}) 4 = 120$

3. 得到最终的分桶个数计算逻辑:

先计算一个中间值 $x = \min(M, N, 128)$,
如果 $x < N$ 并且 $x < \text{BE 节点个数}$, 则最终分桶为 y 即 BE 节点个数;
否则最终分桶数为 x

4. $x = \max(x, \text{autobucket_min_buckets})$, 这里 autobucket_min_buckets 是在 Config 中配置的, 默认是 1

上述过程伪代码表现形式为:

```
int N = 计算 N 值;  
int M = 计算 M 值;  
  
int y = BE 节点个数;  
int x = min(M, N, 128);  
  
if (x < N && x < y) {  
    return y;  
}  
return x;
```

5. 示例: 有了上述算法, 咱们再引入一些例子来更好地理解这部分逻辑。

```
case1:  
数据量 100 MB, 10 台 BE 机器, 2TB *3 块盘  
数据量 N = 1  
BE 磁盘 M = 10* (2TB/50GB) * 3 = 1230  
x = min(M, N, 128) = 1  
最终: 1  
  
case2:  
数据量 1GB, 3 台 BE 机器, 500GB *2 块盘  
数据量 N = 2  
BE 磁盘 M = 3* (500GB/50GB) * 2 = 60  
x = min(M, N, 128) = 2  
最终: 2  
  
case3:  
数据量 100GB, 3 台 BE 机器, 500GB *2 块盘  
数据量 N = 20  
BE 磁盘 M = 3* (500GB/50GB) * 2 = 60  
x = min(M, N, 128) = 20  
最终: 20  
  
case4:  
数据量 500GB, 3 台 BE 机器, 1TB *1 块盘  
数据量 N = 100  
BE 磁盘 M = 3* (1TB /50GB) * 1 = 6060  
x = min(M, N, 128) = 63  
最终: 63  
  
case5:  
数据量 500GB, 10 台 BE 机器, 2TB *3 块盘*3 块盘  
数据量 N = 100  
BE 磁盘 M = 10* (2TB / 50GB) * 3 = 1230
```

```

x = min(M, N, 128) = 100
最终: 100

case 6:
数据量 1TB, 10 台 BE 机器, 2TB *3 块盘
数据量 N = 205
BE 磁盘 M = 10* (2TB / 50GB) * 3 = 1230
x = min(M, N, 128) = 128
最终: 128

case 7:
数据量 500GB, 1 台 BE 机器, 100TB *1 块盘
数据量 N = 100
BE 磁盘 M = 1* (100TB / 50GB) * 1 = 2048
x = min(M, N, 128) = 100
最终: 100

case 8:
数据量 1TB, 200 台 BE 机器, 4TB *7 块盘
数据量 N = 205
BE 磁盘 M = 200* (4TB / 50GB) * 7 = 114800
x = min(M, N, 128) = 128
最终: 200

```

后续分桶推算

上述是关于初始分桶的计算逻辑，后续分桶数因为已经有了一定的分区数据，可以根据已有的分区数据量来进行评估。后续分桶数会根据最多前 7 个分区数据量的 EMA（短期指数移动平均线）值，作为 `estimate_partition_size` 进行评估。此时计算分桶有两种计算方式，假设以天来分区，往前数第一天分区大小为 `S7`，往前数第二天分区大小为 `S6`，依次类推到 `S1`。

- 如果 7 天内的分区数据每日严格递增，则此时会取趋势值

有 6 个 `delta` 值，分别是

```

S7 - S6 = delta1,
S6 - S5 = delta2,
...
S2 - S1 = delta6

```

由此得到 `ema(delta)` 值：那么，今天的 `estimate_partition_size` = `S7 + ema(delta)`。

- 非第一种的情况，此时直接取前几天的 EMA 平均值

今天的 `estimate_partition_size` = `EMA(S1, ..., S7)`。

说明

根据上述算法，初始分桶个数以及后续分桶个数都能被计算出来。跟之前只能指定固定分桶数不同，由于业务数据的变化，有可能前面分区的分桶数和后面分区的分桶数不一样，这对用户是透明的，用户无需关心每一分区具体的分桶数是多少，而这一自动推算的功能会让分桶数更加合理。

开启 `autobucket` 之后，在 `show create table` 的时候看到的 `schema` 也是 `BUCKETS AUTO`。如果想要查看确切的 bucket 数，可以通过 `show partitions from ${table};` 来查看。

常见问题

1. 如果在较长的建表语句中出现语法错误，可能会出现语法错误提示不全的现象。这里罗列可能的语法错误供手动纠错：

- 语法结构错误。请仔细阅读 `HELP CREATE TABLE;`，检查相关语法结构。
- 保留字。当用户自定义名称遇到保留字时，需要用反引号 `` 引起来。建议所有自定义名称使用这个符号引起来。
- 中文字符或全角字符。非 utf8 编码的中文字符，或隐藏的全角字符（空格，标点等）会导致语法错误。建议使用带有显示不可见字符的文本编辑器进行检查。

2. Failed to create partition [xxx] . Timeout

Doris 建表是按照 Partition 粒度依次创建的。当一个 Partition 创建失败时，可能会报这个错误。即使不使用 Partition，当建表出现问题时，也会报 Failed to create partition，因为如前文所述，Doris 会为没有指定 Partition 的表创建一个不可更改的默认的 Partition。

当遇到这个错误是，通常是 BE 在创建数据分片时遇到了问题。可以参照以下步骤排查：

- 在 fe.log 中，查找对应时间点的 Failed to create partition 日志。在该日志中，会出现一系列类似 {10001-10010} 字样的数字对。数字对的第一个数字表示 Backend ID，第二个数字表示 Tablet ID。如上一个数字对，表示 ID 为 10001 的 Backend 上，创建 ID 为 10010 的 Tablet 失败了。
- 前往对应 Backend 的 be.INFO 日志，查找对应时间段内，tablet id 相关的日志，可以找到错误信息。
- 以下罗列一些常见的 tablet 创建失败错误，包括但不限于：
 - BE 没有收到相关 task，此时无法在 be.INFO 中找到 tablet id 相关日志或者 BE 创建成功，但汇报失败。以上问题，请参阅 [安装与部署](#) 检查 FE 和 BE 的连通性。
 - 预分配内存失败。可能是表中一行的字节长度超过了 100KB。
 - Too many open files。打开的文件句柄数超过了 Linux 系统限制。需修改 Linux 系统的句柄数限制。

如果创建数据分片时超时，也可以通过在 fe.conf 中设置 `tablet_create_timeout_second=xxx` 以及 `max_create_table_timeout_second=xxx` 来延长超时时间。其中 `tablet_create_timeout_second` 默认是 1 秒，`max_create_table_timeout_second` 默认是 60 秒，总体的超时时间为 `min(tablet_create_timeout_second * replication_num, max_create_table_timeout_second)`，具体参数设置可参阅 [FE 配置项](#)。

3. 建表命令长时间不返回结果。

- Doris 的建表命令是同步命令。该命令的超时时间目前设置的比较简单，即 `(tablet num * replication num)` 秒。如果创建较多的数据分片，并且其中有分片创建失败，则可能导致等待较长超时后，才会返回错误。

- 正常情况下，建表语句会在几秒或十几秒内返回。如果超过一分钟，建议直接取消掉这个操作，前往 FE 或 BE 的日志查看相关错误。

更多帮助

关于数据划分更多的详细说明，我们可以在 [CREATE TABLE](#) 命令手册中查阅，也可以在 MySQL 客户端下输入 `HELP CREATE TABLE;` 获取更多的帮助信息。

Schema 变更

用户可以通过 Schema Change 操作来修改已存在表的 Schema。表的 Schema，主要包括对列的修改和索引的改动，这里主要介绍列相关的 Scheme 变更，关于索引相关的变更，可以查看数据表设计/表索引来查看每种索引的变更方式。

名词解释

- Base Table：基表。每一个表被创建时，都对应一个基表。
- Rollup：基于基表或者其他 Rollup 创建出来的上卷表。
- Index：物化索引。Rollup 或 Base Table 都被称为物化索引。
- Transaction：事务。每一个导入任务都是一个事务，每个事务有一个唯一递增的 Transaction ID。

原理介绍

Light Schema Change

在正式介绍以前，需要认识一下 Apache Doris 1.2.0 版本之前的 3 种 Schema Change 实现，这三种方式都是异步的：


- Hard Linked Schema Change 主要作用于加减 Value 列，不需要对数据文件有修改。
- Direct Schema Change 主要作用于改变 Value 列的类型，需要对数据进行重写，但不涉及到 Key 列，无需重新排序。
- Sort Schema Change 主要是作用于对 key 列进行的 Schema Change，由于对 Key 列进行加/减/修改类型等操作都会影响到已有数据的排序，所以需要把数据重新读出来，修改后，然后再进行排序。

从 Apache Doris 1.2.0 以后，针对第一种，引入了 Light Schema Change 新特性，新的 Light Schema Change 使得增减 Value 列可以在毫秒级完成。从 Apache Doris 2.0.0 开始，所有的新建表都默认启用了 Light Schema Change。

除了对 Value 列的增加和删除，其它类型的 Schema 变更的主要原理如下

执行 Schema Change 的基本过程，是通过原表/Index 的数据，生成一份新 Schema 的表/Index 数据。其中主要需要进行两部分数据转换，一是已存在的历史数据的转换，二是在 Schema Change 执行过程中，新到达的导入数据的转换。





在开始转换历史数据之前，Doris 会获取一个最新的 Transaction ID。并等待这个 Transaction ID 之前的所有导入事务完成。这个 Transaction ID 成为分水岭。意思是，Doris 保证在分水岭之后的所有导入任务，都会同时为原表 /Index 和新表 /Index 生成数据。这样当历史数据转换完成后，可以保证新的表中的数据是完整的。

创建 Schema Change 的具体语法可以查看帮助 [ALTER TABLE COLUMN](#) 中 Schema Change 部分的说明。

向指定 Index 的指定位置添加一列

语法

```
ALTER TABLE table_name ADD COLUMN column_name column_type [KEY | agg_type] [DEFAULT "default_value"]
[AFTER column_name|FIRST]
[TO rollup_index_name]
[PROPERTIES ("key"="value", ...)]
```

- 聚合模型如果增加 Value 列，需要指定 agg_type
- 非聚合模型（如 DUPLICATE KEY）如果增加 Key 列，需要指定 KEY 关键字
- 不能在 Rollup Index 中增加 Base Index 中已经存在的列（如有需要，可以重新创建一个 Rollup Index）

示例

非聚合模型

建表语句：

```
CREATE TABLE IF NOT EXISTS example_db.my_table(
  col1 int,
  col2 int,
  col3 int,
  col4 int,
  col5 int
) DUPLICATE KEY(col1, col2, col3)
DISTRIBUTED BY RANDOM BUCKETS 1
ROLLUP (
  example_rollup_index (col1, col3, col4, col5)
)
PROPERTIES (
  "replication_num" = "1"
)
```

1. 向 example_rollup_index 的 col1 后添加一个 Key 列 new_col

```
ALTER TABLE example_db.my_table
ADD COLUMN new_col INT KEY DEFAULT "0" AFTER col1
```

```
TO example_rollup_index;
```

2. 向 example_rollup_index 的 col1 后添加一个 Value 列 new_col

```
ALTER TABLE example_db.my_table  
ADD COLUMN new_col INT DEFAULT "0" AFTER col1  
TO example_rollup_index;
```

聚合模型

建表语句：

```
CREATE TABLE IF NOT EXISTS example_db.my_table(  
    col1 int,  
    col2 int,  
    col3 int,  
    col4 int SUM,  
    col5 varchar(32) REPLACE DEFAULT "abc"  
) AGGREGATE KEY(col1, col2, col3)  
DISTRIBUTED BY HASH(col1) BUCKETS 1  
ROLLUP (  
    example_rollup_index (col1, col3, col4, col5)  
)  
PROPERTIES (  
    "replication_num" = "1"  
)
```

3. 向 example_rollup_index 的 col1 后添加一个 Key 列 new_col

```
ALTER TABLE example_db.my_table  
ADD COLUMN new_col INT DEFAULT "0" AFTER col1  
TO example_rollup_index;
```

4. 向 example_rollup_index 的 col1 后添加一个 Value 列 new_col SUM 聚合类型

```
ALTER TABLE example_db.my_table  
ADD COLUMN new_col INT SUM DEFAULT "0" AFTER col1  
TO example_rollup_index;
```

向指定 Index 添加多列

语法

```
ALTER TABLE table_name ADD COLUMN (column_name1 column_type [KEY | agg_type] DEFAULT "default_value", ...)  
[TO rollup_index_name]  
[PROPERTIES ("key"="value", ...)]
```

- 聚合模型如果增加 Value 列，需要指定 agg_type
- 聚合模型如果增加 Key 列，需要指定 KEY 关键字
- 不能在 Rollup Index 中增加 Base Index 中已经存在的列（如有需要，可以重新创建一个 Rollup Index）

示例

向 example_rollup_index 添加多列 (聚合模型)

```
ALTER TABLE example_db.my_table
ADD COLUMN (c1 INT DEFAULT "1", c2 FLOAT SUM DEFAULT "0")
TO example_rollup_index;
```

从指定 Index 中删除一列

语法

```
ALTER TABLE table_name DROP COLUMN column_name
[FROM rollup_index_name]
```

- 不能删除分区列
- 如果是从 Base Index 中删除列，则如果 Rollup Index 中包含该列，也会被删除

示例

从 example_rollup_index 删除一列

```
ALTER TABLE example_db.my_table
DROP COLUMN col3
FROM example_rollup_index;
```

修改指定 Index 的列类型以及列位置

语法

```
ALTER TABLE table_name MODIFY COLUMN column_name column_type [KEY | agg_type] [NULL | NOT NULL] [DEFAULT
"default_value"]
[AFTER column_name|FIRST]
[FROM rollup_index_name]
[PROPERTIES ("key"="value", ...)]
```

- 聚合模型如果修改 Value 列，需要指定 agg_type
- 非聚合类型如果修改 Key 列，需要指定 **KEY** 关键字
- 只能修改列的类型，列的其他属性维持原样（即其他属性需在语句中按照原属性显式的写出，参见 Example 8）
- 分区列和分桶列不能做任何修改
- 目前支持以下类型的转换（精度损失由用户保证）
 - TINYINT/SMALLINT/INT/BIGINT/LARGEINT/FLOAT/DOUBLE 类型向范围更大的数字类型转换

- TINTINT/SMALLINT/INT/BIGINT/LARGEINT/FLOAT/DOUBLE/DECIMAL 转换成 VARCHAR
- VARCHAR 支持修改最大长度
- VARCHAR/CHAR 转换成 TINTINT/SMALLINT/INT/BIGINT/LARGEINT/FLOAT/DOUBLE
- VARCHAR/CHAR 转换成 DATE (目前支持"%Y-%m-%d", "%y-%m-%d", "%Y%m%d", "%y%m%d", "%Y/%m/%d", "%y/%m/%d" 六种格式化格式)
- DATETIME 转换成 DATE (仅保留年 - 月 - 日信息, 例如: 2019-12-09 21:47:05 <=> 2019-12-09)
- DATE 转换成 DATETIME (时分秒自动补零, 例如: 2019-12-09 <=> 2019-12-09 00:00:00)
- FLOAT 转换成 DOUBLE
- INT 转换成 DATE (如果 INT 类型数据不合法则转换失败, 原始数据不变)
- 除 DATE 与 DATETIME 以外都可以转换成 STRING, 但是 STRING 不能转换任何其他类型

示例

建表语句:

```
CREATE TABLE IF NOT EXISTS example_db.my_table(
  col0 int,
  col1 int DEFAULT "1",
  col2 int,
  col3 varchar(32),
  col4 int SUM,
  col5 varchar(32) REPLACE DEFAULT "abc"
) AGGREGATE KEY(col0, col1, col2, col3)
DISTRIBUTED BY HASH(col0) BUCKETS 1
PROPERTIES (
  "replication_num" = "1"
)
```

1. 修改 Base Index 的 Key 列 col1 的类型为 BIGINT, 并移动到 col2 列后面。

```
ALTER TABLE example_db.my_table
MODIFY COLUMN col1 BIGINT KEY DEFAULT "1" AFTER col2;
```

注意: 无论是修改 Key 列还是 Value 列都需要声明完整的 Column 信息

2. 修改 Base Index 的 val5 列最大长度。原 val5 为 (val5 VARCHAR(32) REPLACE DEFAULT "abc")

```
ALTER TABLE example_db.my_table
MODIFY COLUMN col5 VARCHAR(64) REPLACE DEFAULT "abc";
```

注意: 只能修改列的类型, 列的其他属性维持原样

3. 修改 Duplicate Key 表 Key 列的某个字段的长度

```
ALTER TABLE example_db.my_table
MODIFY COLUMN col3 varchar(50) KEY NULL comment 'to 50'
```

对指定 Index 的列进行重新排序

语法

```
ALTER TABLE table_name ORDER BY (column_name1, column_name2, ...)
[FROM rollup_index_name]
[PROPERTIES ("key"="value", ...)]
```

- Index 中的所有列都要写出来
- Value 列在 Key 列之后

示例

```
CREATE TABLE IF NOT EXISTS example_db.my_table(
  k1 int DEFAULT "1",
  k2 int,
  k3 varchar(32),
  k4 date,
  v1 int SUM,
  v2 int MAX,
) AGGREGATE KEY(k1, k2, k3, k4)
DISTRIBUTED BY HASH(k1) BUCKETS 1
ROLLUP (
  example_rollup_index(k1, k2, k3, v1, v2)
)
PROPERTIES (
  "replication_num" = "1"
)
```

重新排序 example_rollup_index 中的列（设原列顺序为：k1, k2, k3, v1, v2）

```
ALTER TABLE example_db.my_table
ORDER BY (k3,k1,k2,v2,v1)
FROM example_rollup_index;
```

一次提交进行多种变更

Schema Change 可以在一个作业中，对多个 Index 进行不同的修改。

示例 1

源 Schema：

```
CREATE TABLE IF NOT EXISTS example_db.tbl1(
  k1 int,
  k2 int,
  k3 int
) AGGREGATE KEY(k1, k2, k3)
```



```
DISTRIBUTED BY HASH(k1) BUCKETS 1
ROLLUP (
  rollup1 (k1, k2),
  rollup2 (k2)
)
PROPERTIES (
  "replication_num" = "1"
)
```

可以通过以下命令给 rollup1 和 rollup2 都加入一列 k4，并且再给 rollup2 加入一列 k5：

```
ALTER TABLE tbl1
ADD COLUMN k4 INT default "1" to rollup1,
ADD COLUMN k4 INT default "1" to rollup2,
ADD COLUMN k5 INT default "1" to rollup2;
```

完成后，Schema 变为：

IndexName	Field	Type	Null	Key	Default	Extra
tbl1	k1	INT	No	true	N/A	
	k2	INT	No	true	N/A	
	k3	INT	No	true	N/A	
	k4	INT	No	true	1	
	k5	INT	No	true	1	
rollup2	k2	INT	No	true	N/A	
	k4	INT	No	true	1	
	k5	INT	No	true	1	
rollup1	k1	INT	No	true	N/A	
	k2	INT	No	true	N/A	
	k4	INT	No	true	1	

可以看到，Base 表 tbl1 也自动加入了 k4, k5 列。即给任意 Rollup 增加的列，都会自动加入到 Base 表中。

同时，不允许向 Rollup 中加入 Base 表已经存在的列。如果用户需要这样做，可以重新建立一个包含新增列的 Rollup，之后再删除原 Rollup。

示例 2

建表语句

```
CREATE TABLE IF NOT EXISTS example_db.my_table(
  k1 int DEFAULT "1",
  k2 int,
  k3 varchar(32),
  k4 date,
  v1 int SUM,
) AGGREGATE KEY(k1, k2, k3, k4)
DISTRIBUTED BY HASH(k1) BUCKETS 1
ROLLUP (
  example_rollup_index(k1, k3, k2, v1)
)
PROPERTIES (
```

```
"replication_num" = "1"
)
```

```
ALTER TABLE example_db.my_table
ADD COLUMN v2 INT MAX DEFAULT "0" TO example_rollup_index,
ORDER BY (k3,k1,k2,v2,v1) FROM example_rollup_index;
```

修改列名称

语法

```
ALTER TABLE RENAME COLUMN old_column_name new_column_name;
```

查看作业

Schema Change 的创建是一个异步过程，作业提交成功后，用户需要通过 `SHOW ALTER TABLE COLUMN` 命令来查看作业进度。

`SHOW ALTER TABLE COLUMN` 可以查看当前正在执行或已经完成的 Schema Change 作业。当一次 Schema Change 作业涉及到多个 Index 时，该命令会显示多行，每行对应一个 Index。举例如下：

```
mysql > SHOW ALTER TABLE COLUMN\G;
***** 1. row *****
      JobId: 20021
      TableName: tbl1
      CreateTime: 2019-08-05 23:03:13
      FinishTime: 2019-08-05 23:03:42
      IndexName: tbl1
      IndexId: 20022
      OriginIndexId: 20017
      SchemaVersion: 2:792557838
      TransactionId: 10023
      State: FINISHED
      Msg:
      Progress: NULL
      Timeout: 86400
1 row in set (0.00 sec)
```

- JobId: 每个 Schema Change 作业的唯一 ID。
- TableName: Schema Change 对应的基表的表名。
- CreateTime: 作业创建时间。
- FinishedTime: 作业结束时间。如未结束，则显示“N/A”。
- IndexName: 本次修改所涉及的某一个 Index 的名称。
- IndexId: 新的 Index 的唯一 ID。
- OriginIndexId: 旧的 Index 的唯一 ID。

- SchemaVersion: 以 M:N 的格式展示。其中 M 表示本次 Schema Change 变更的版本, N 表示对应的 Hash 值。每次 Schema Change, 版本都会递增。
- TransactionId: 转换历史数据的分水岭 Transaction ID。
- State: 作业所在阶段。
 - PENDING: 作业在队列中等待被调度。
 - WAITING_TXN: 等待分水岭 Transaction ID 之前的导入任务完成。
 - RUNNING: 历史数据转换中。
 - FINISHED: 作业成功。
 - CANCELLED: 作业失败。
- Msg: 如果作业失败, 这里会显示失败信息。
- Progress: 作业进度。只有在 RUNNING 状态才会显示进度。进度是以 M/N 的形式显示。其中 N 为 Schema Change 涉及的总副本数。M 为已完成历史数据转换的副本数。
- Timeout: 作业超时时间。单位秒。

取消作业

在作业状态不为 FINISHED 或 CANCELLED 的情况下, 可以通过以下命令取消 Schema Change 作业:

```
CANCEL ALTER TABLE COLUMN FROM tbl_name;
```

注意事项

- 一张表在同一时间只能有一个 Schema Change 作业在运行。
- Schema Change 操作不阻塞导入和查询操作。
- 分区列和分桶列不能修改。
- 如果 Schema 中有 REPLACE 方式聚合的 Value 列, 则不允许删除 Key 列。
- 如果删除 Key 列, Doris 无法决定 REPLACE 列的取值。
- Unique 数据模型表的所有非 Key 列都是 REPLACE 聚合方式。
- 在新增聚合类型为 SUM 或者 REPLACE 的 Value 列时, 该列的默认值对历史数据没有含义。
- 因为历史数据已经失去明细信息, 所以默认值的取值并不能实际反映聚合后的取值。
- 当修改列类型时, 除 Type 以外的字段都需要按原列上的信息补全。
- 如修改列 k1 INT SUM NULL DEFAULT "1" 类型为 BIGINT, 则需执行命令如下:
- ALTER TABLE tbl1 MODIFY COLUMN k1 BIGINT SUM NULL DEFAULT "1";

- 注意，除新的列类型外，如聚合方式，Nullable 属性，以及默认值都要按照原信息补全。
- 不支持修改列名称、聚合类型、Nullable 属性、默认值以及列注释。

常见问题

Schema Change 的执行速度

Light Schema Change，即如果是增加和删除 Value 列，则可以毫秒级返回。其它的 Schema Change 执行速度按照最差效率估计约为 10MB/s。保守起见，用户可以根据这个速率来设置作业的超时时间。

提交作业报错 Table xxx is not stable. ...

Schema Change 只有在表数据完整且非均衡状态下才可以开始。如果表的某些数据分片副本不完整，或者某些副本正在进行均衡操作，则提交会被拒绝。数据分片副本是否完整，可以通过以下命令查看：

```
SHOW REPLICA STATUS FROM tbl WHERE STATUS != "OK";
```

如果有返回结果，则说明有副本有问题。通常系统会自动修复这些问题，用户也可以通过以下命令优先修复这个表：

```
ADMIN REPAIR TABLE tbl1;
```

用户可以通过以下命令查看是否有正在运行的均衡任务：

```
SHOW PROC "/cluster_balance/pending_tablets";
```

可以等待均衡任务完成，或者通过以下命令临时禁止均衡操作：

```
ADMIN SET FRONTEND CONFIG ("disable_balance" = "true");
```

相关配置

FE 配置

- alter_table_timeout_second：作业默认超时时间，86400 秒。

BE 配置

- alter_tablet_worker_count：在 BE 端用于执行历史数据转换的线程数。默认为 3。如果希望加快 Schema Change 作业的速度，可以适当调大这个参数后重启 BE。但过多的转换线程可能会导致 IO 压力增加，影响其他操作。该线程和 Rollup 作业共用。
- alter_index_worker_count：在 BE 端用于执行历史数据构建索引的线程数（注：当前只支持倒排索引）。默认为 3。如果希望加快 Index Change 作业的速度，可以适当调大这个参数后重启 BE。但过多的线程可能会导致 IO 压力增加，影响其他操作。

更多参考

关于 Schema Change 使用的更多详细语法及最佳实践，请参阅 [ALTER TABLE COLUMN](#) 命令手册，你也可以在 MySQL 客户端命令行下输入 `HELP ALTER TABLE COLUMN` 获取更多帮助信息。

冷热数据分层

需求场景

未来一个很大的使用场景是类似于 ES 日志存储，日志场景下通常会按照日期来切割数据，很多数据是冷数据，查询很少，需要降低这类数据的存储成本。从节约存储成本角度考虑：

- 各云厂商普通云盘的价格都比对象存储贵
- 在 Doris 集群实际线上使用中，普通云盘的利用率无法达到 100%
- 云盘不是按需付费，而对象存储可以做到按需付费
- 基于普通云盘做高可用，需要实现多副本，某副本异常要做副本迁移。而将数据放到对象存储上则不存在此类问题，因为对象存储是共享的。

解决方案

在 Partition 级别上设置 Freeze time，表示多久这个 Partition 会被 Freeze，并且定义 Freeze 之后存储的 Remote storage 的位置。在 BE 上 daemon 线程会周期性的判断表是否需要 freeze，若 freeze 后会将数据上传到兼容 S3 协议的对象存储和 HDFS 上。

冷热分层支持几乎所有 Doris 功能，只是把部分数据放到对象存储上，以节省成本，不牺牲功能。因此有如下特点：

- 冷数据放到对象存储上，用户无需担心数据一致性和数据安全性问题
- 灵活的 Freeze 策略，冷却远程存储 Property 可以应用到表和 Partition 级别
- 用户查询数据，无需关注数据分布位置，若数据不在本地，会拉取对象上的数据，并 cache 到 BE 本地
- 副本 clone 优化，若存储数据在对象上，则副本 clone 的时候不用去拉取存储数据到本地
- 远程对象空间回收 recycler，若表、分区被删除，或者冷热分层过程中异常情况产生的空间浪费，则会有 recycler 线程周期性的回收，节约存储资源
- cache 优化，将访问过的冷数据 cache 到 BE 本地，达到非冷热分层的查询性能
- BE 线程池优化，区分数据来源是本地还是对象存储，防止读取对象延时影响查询性能

Storage policy 的使用

存储策略是使用冷热分层功能的入口，用户只需要在建表或使用 Doris 过程中，给表或分区关联上 Storage policy，即可以使用冷热分层的功能。

创建 S3 RESOURCE 的时候，会进行 S3 远端的链接校验，以保证 RESOURCE 创建的正确。

下面演示如何创建 S3 RESOURCE：

```
CREATE RESOURCE "remote_s3"
PROPERTIES
(
    "type" = "s3",
    "s3.endpoint" = "bj.s3.com",
    "s3.region" = "bj",
    "s3.bucket" = "test-bucket",
    "s3.root.path" = "path/to/root",
    "s3.access_key" = "bbb",
    "s3.secret_key" = "aaaa",
    "s3.connection.maximum" = "50",
    "s3.connection.request.timeout" = "3000",
    "s3.connection.timeout" = "1000"
);

CREATE STORAGE POLICY test_policy
PROPERTIES(
    "storage_resource" = "remote_s3",
    "cooldown_ttl" = "1d"
);

CREATE TABLE IF NOT EXISTS create_table_use_created_policy
(
    k1 BIGINT,
    k2 LARGEINT,
    v1 VARCHAR(2048)
)
UNIQUE KEY(k1)
DISTRIBUTED BY HASH (k1) BUCKETS 3
PROPERTIES(
    "enable_unique_key_merge_on_write" = "false",
    "storage_policy" = "test_policy"
);
```

注意

UNIQUE 表如果设置了 "enable_unique_key_merge_on_write" = "true" 的话，无法使用此功能。

以及如何创建 HDFS RESOURCE：

```
CREATE RESOURCE "remote_hdfs" PROPERTIES (
    "type"="hdfs",
    "fs.defaultFS"="fs_host:default_fs_port",
    "hadoop.username"="hive",
    "hadoop.password"="hive",
    "root_path"="/my/root/path",
    "dfs.nameservices" = "my_ha",
    "dfs.ha.namenodes.my_ha" = "my_namenode1, my_namenode2",
    "dfs.namenode.rpc-address.my_ha.my_namenode1" = "nn1_host:rpc_port",
    "dfs.namenode.rpc-address.my_ha.my_namenode2" = "nn2_host:rpc_port",
    "dfs.client.failover.proxy.provider.my_ha" =
"org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider"
);

CREATE STORAGE POLICY test_policy PROPERTIES (
    "storage_resource" = "remote_hdfs",
    "cooldown_ttl" = "300"
```

```

)

CREATE TABLE IF NOT EXISTS create_table_use_created_policy (
  k1 BIGINT,
  k2 LARGEINT,
  v1 VARCHAR(2048)
)
UNIQUE KEY(k1)
DISTRIBUTED BY HASH (k1) BUCKETS 3
PROPERTIES(
  "enable_unique_key_merge_on_write" = "false",
  "storage_policy" = "test_policy"
);

```

注意

UNIQUE 表如果设置了 "enable_unique_key_merge_on_write" = "true" 的话，无法使用此功能。

或者对一个已存在的表，关联 Storage policy

```
ALTER TABLE create_table_not_have_policy set ("storage_policy" = "test_policy");
```

或者对一个已存在的 partition，关联 Storage policy

```
ALTER TABLE create_table_partition MODIFY PARTITION (*) SET("storage_policy"="test_policy");
```

注意，如果用户在建表时给整张 Table 和部分 Partition 指定了不同的 Storage Policy，Partition 设置的 Storage policy 会被无视，整张表的所有 Partition 都会使用 table 的 Policy. 如果您需要让某个 Partition 的 Policy 和别的不同，则可以使用上文中对一个已存在的 Partition，关联 Storage policy 的方式修改。

具体可以参考 Docs 目录下[RESOURCE](#)、[POLICY](#)、[CREATE TABLE](#)、[ALTER TABLE](#)等文档，里面有详细介绍。

一些限制

- 单表或单 Partition 只能关联一个 Storage policy，关联后不能 Drop 掉 Storage policy，需要先解除二者的关联。
- Storage policy 关联的对象信息不支持修改数据存储 path 的信息，比如 bucket、endpoint、root_path 等信息
- Storage policy 支持创建 和修改和支持删除，删除前需要先保证没有表引用此 Storage policy。
- Unique 模型在开启 Merge-on-Write 特性时，不支持设置 Storage policy。

冷数据占用对象大小

方式一：通过 `show proc '/backends'` 可以查看到每个 BE 上传到对象的大小，`RemoteUsedCapacity` 项，此方式略有延迟。

方式二：通过 `show tablets from tableName` 可以查看到表的每个 tablet 占用的对象大小，`RemoteDataSize` 项。

冷数据的 cache

上文提到冷数据为了优化查询的性能和对象存储资源节省，引入了 cache 的概念。在冷却后首次命中，Doris 会将已经冷却的数据又重新加载到 BE 的本地磁盘，cache 有以下特性：

- cache 实际存储于 BE 磁盘，不占用内存空间。
- cache 可以限制膨胀，通过 LRU 进行数据的清理
- cache 的实现和联邦查询 Catalog 的 cache 是同一套实现，文档参考[此处](#)

冷数据的 Compaction

冷数据传入的时间是数据 rowset 文件写入本地磁盘时刻起，加上冷却时间。由于数据并不是一次性写入和冷却的，因此避免在对象存储内的小文件问题，Doris 也会进行冷数据的 Compaction。但是，冷数据的 Compaction 的频次和资源占用的优先级并不是很高，也推荐本地热数据 compaction 后再执行冷却。具体可以通过以下 BE 参数调整：

- BE 参数 `cold_data_compaction_thread_num` 可以设置执行冷数据的 Compaction 的并发，默认是 2。
- BE 参数 `cold_data_compaction_interval_sec` 可以设置执行冷数据的 Compaction 的时间间隔，默认是 1800，单位：秒，即半个小时。。

冷数据的 Schema Change

数据冷却后支持 Schema Change 类型如下：

- 增加、删除列
- 修改列类型
- 调整列顺序
- 增加、修改索引

冷数据的垃圾回收

冷数据的垃圾数据是指没有被任何 Replica 使用的数据，对象存储上可能会有如下情况产生的垃圾数据：

1. 上传 rowset 失败但是有部分 segment 上传成功。
2. FE 重新选 CooldownReplica 后，新旧 CooldownReplica 的 rowset version 不一致，FollowerReplica 都去同步新 CooldownReplica 的 CooldownMeta，旧 CooldownReplica 中 version 不一致的 rowset 没有

Replica 使用成为垃圾数据。

3. 冷数据 Compaction 后，合并前的 rowset 因为还可能被其他 Replica 使用不能立即删除，但是最终 FollowerReplica 都使用了最新的合并后的 rowset，合并前的 rowset 成为垃圾数据。

另外，对象上的垃圾数据并不会立即清理掉。BE 参数 `remove_unused_remote_files_interval_sec` 可以设置冷数据的垃圾回收的时间间隔，默认是 21600，单位：秒，即 6 个小时。

未尽事项

- 一些远端占用指标更新获取不够完善

常见问题

1. ERROR 1105 (HY000): errCode = 2, detailMessage = Failed to create repository: connect to s3 failed: Unable to marshall request to JSON: host must not be null.

S3 SDK 默认使用 virtual-hosted style 方式。但某些对象存储系统 (如：minio) 可能没开启或没支持 virtual-hosted style 方式的访问，此时我们可以添加 `use_path_style` 参数来强制使用 path style 方式：

```
CREATE RESOURCE "remote_s3"
PROPERTIES
(
  "type" = "s3",
  "s3.endpoint" = "bj.s3.com",
  "s3.region" = "bj",
  "s3.bucket" = "test-bucket",
  "s3.root.path" = "path/to/root",
  "s3.access_key" = "bbb",
  "s3.secret_key" = "aaaa",
  "s3.connection.maximum" = "50",
  "s3.connection.request.timeout" = "3000",
  "s3.connection.timeout" = "1000",
  "use_path_style" = "true"
);
```

索引概述

数据库索引是用于查询加速的，为了加速不同的查询场景，Apache Doris 支持了多种丰富的索引。

索引分类和原理

从加速的查询和原理来看，Apache Doris 的索引分为点查索引和跳数索引两大类。

- 点查索引：常用于加速点查，原理是通过索引定位到满足 WHERE 条件的有哪些行，直接读取那些行。点查索引在满足条件的行比较少时效果很好。Apache Doris 的点查索引包括前缀索引和倒排索引。
- 前缀索引：Apache Doris 按照排序键以有序的方式存储数据，并每隔 1024 行数据创建一个稀疏前缀索引。索引中的 Key 是当前 1024 行中第一行中排序列的值。如果查询涉及已排序列，系统将找到相关 1024 行组的第一行并从那里开始扫描。
- 倒排索引：对创建了倒排索引的列，建立每个值到对应行号集合的倒排表。对于等值查询，先从倒排表中查到行号集合，然后直接读取对应行的数据，而不用逐行扫描匹配数据，从而减少 I/O 加速查询。倒排索引还能加速范围过滤、文本关键词匹配，算法更加复杂但是基本原理类似。（备注：之前的 BITMAP 索引已经被更强的倒排索引取代）
- 跳数索引：常用于加速分析，原理是通过索引确定不满足 WHERE 条件的数据块，跳过这些不满足条件的数据块，只读取可能满足条件的数据块并再进行一次逐行过滤，最终得到满足条件的行。跳数索引在满足条件的行比较多时效果较好。Apache Doris 的跳数索引包括 ZoneMap 索引、BloomFilter 索引、NGram BloomFilter 索引。
- ZoneMap 索引：自动维护每一列的统计信息，为每一个数据文件（Segment）和数据块（Page）记录最大值、最小值、是否有 NULL。对于等值查询、范围查询、IS NULL，可以通过最大值、最小值、是否有 NULL 来判断数据文件和数据块是否可以包含满足条件的数据，如果没有则跳过不读对应的文件或数据块减少 I/O 加速查询。
- BloomFilter 索引：将索引对应列的可能取值存入 BloomFilter 数据结构中，它可以快速判断一个值是否在 BloomFilter 里面，并且 BloomFilter 存储空间占用很低。对于等值查询，如果判断这个值不在 BloomFilter 里面，就可以跳过对应的数据文件或者数据块减少 I/O 加速查询。
- NGram BloomFilter 索引：用于加速文本 LIKE 查询，基本原理与 BloomFilter 索引类似，只是存入 BloomFilter 的不是原始文本的值，而是对文本进行 NGram 分词，每个词作为值存入 BloomFilter。对于 LIKE 查询，将 LIKE 的 pattern 也进行 NGram 分词，判断每个词是否在 BloomFilter 中，如果某个词不在则对应的数据文件或者数据块就不满足 LIKE 条件，可以跳过这部分数据减少 I/O 加速查询。

上述索引中，前缀索引和 ZoneMap 索引是 Apache Doris 自动维护的内建智能索引，无需用户管理，而倒排索引、BloomFilter 索引、NGram BloomFilter 索引则需要用户自己根据场景选择，手动创建、删除。

- 各种类型索引特点对比

类型	索引	优点	局限
点查索引	前缀索引	内置索引，性能最好	一个表只有一组前缀索引
点查索引	倒排索引	支持分词和关键词匹配，任意列可建索引，多条件组合，持续增加函数加速	索引存储空间较大，与原始数据相当
跳数索引	ZoneMap 索引	内置索引，索引存储空间小	支持的查询类型少，只支持等于、范围
跳数索引	BloomFilter 索引	比 ZoneMap 更精细，索引空间中等	支持的查询类型少，只支持等于
跳数索引	NGram BloomFilter 索引	支持 LIKE 加速，索引空间中等	支持的查询类型少，只支持 LIKE 加速

- 索引加速的运算符和函数列表

运算符 / 函数	前缀索引	倒排索引	ZoneMap 索引	BloomFilter 索引	NGram BloomFilter 索引
=	YES	YES	YES	YES	NO
!=	YES	YES	NO	NO	NO
IN	YES	YES	YES	YES	NO
NOT IN	YES	YES	NO	NO	NO
>, >=, <, <=, BETWEEN	YES	YES	YES	NO	NO
IS NULL	YES	YES	YES	NO	NO
IS NOT NULL	YES	YES	NO	NO	NO
LIKE	NO	NO	NO	NO	YES
MATCH, MATCH_*	NO	YES	NO	NO	NO

索引设计指南

数据库表的索引设计和优化跟数据特点和查询很相关，需要根据实际场景测试和优化。虽然没有“银弹”，Apache Doris 仍然不断努力降低用户使用索引的难度，用户可以根据下面的简单建议原则进行索引选择和测试。

1. 最频繁使用的过滤条件指定为 Key 自动建前缀索引，因为它的过滤效果最好，但是一个表只能有一个前缀索引，因此要用在最频繁的过滤条件上
2. 对非 Key 字段如有过滤加速需求，首选建倒排索引，因为它的适用面广，可以多条件组合，次选下面两种索引：
 - 有字符串 LIKE 匹配需求，再加一个 NGram BloomFilter 索引
 - 对索引存储空间很敏感，将倒排索引换成 BloomFilter 索引
3. 如果性能不及预期，通过 QueryProfile 分析索引过滤掉的数据量和消耗的时间，具体参考各个索引的详细文档

前缀索引与排序键

索引原理

Doris 的数据存储在类似 SSTable (Sorted String Table) 的数据结构中。该结构是一种有序的数据结构，可以按照指定的一个或多个列进行排序存储。在这种数据结构上，以排序列的全部或者前面几个作为条件进行查找，会非常的高效。

在 Aggregate、Unique 和 Duplicate 三种数据模型中。底层的数据存储，是按照各自建表语句中，Aggregate Key、Unique Key 和 Duplicate Key 中指定的列进行排序存储的。这些 Key，称为排序键 (Sort Key)。借助排序键，在查询时，通过给排序列指定条件，Doris 不需要扫描全表即可快速找到需要处理的数据，降低搜索的复杂度，从而加速查询。

在排序键的基础上，又引入了前缀索引 (Prefix Index)。前缀索引是一种稀疏索引。表中按照相应的行数的数据构成一个逻辑数据块 (Data Block)。每个逻辑数据块在前缀索引表中存储一个索引项，索引项的长度不超过 36 字节，其内容为数据块中第一行数据的排序列组成的前缀，在查找前缀索引表时可以帮助确定该行数据所在逻辑数据块的起始行号。由于前缀索引比较小，所以，可以全量在内存缓存，快速定位数据块，大大提升了查询效率。

数据块一行数据的前 36 个字节作为这行数据的前缀索引。当遇到 **VARCHAR** 类型时，前缀索引会直接截断。如果第一列即为 **VARCHAR**，那么即使没有达到 36 字节，也会直接截断，后面的列不再加入前缀索引。

使用场景

前缀索引可以加速等值查询和范围查询。

管理索引

前缀索引没有专门的语法去定义，建表时自动取表的 Key 的前 36 字节作为前缀索引。

前缀索引选择建议

因为一个表的 Key 定义是唯一的，所以一个表只有一组前缀索引，因此设计表结构时选择合适的前缀索引很重要，可以参考下面的建议：

1. 选择查询中最常用于 WHERE 过滤条件的字段作为 Key。
2. 越常用的字段越放在前面，因为前缀索引只对 WHERE 条件中字段在 Key 的前缀中才有效。

使用其他不能命中前缀索引的列作为条件进行的查询来说，效率上可能无法满足需求，有两种解决方案：

1. 对需要加速查询的条件列创建倒排索引，由于一个表的倒排索引可以有多个。
2. 对于 Duplicate 表可

以通过创建相应的调整了列顺序的单表强一致物化视图来间接实现多种前缀索引，详情可参考查询加速/物化视图。

使用索引

前缀索引用于加速 WHERE 条件中的等值和范围查询，能加速时自动生效，没有特殊语法。

可以通过 Query Profile 中的下面几个指标分析前缀索引的加速效果。 - RowsKeyRangeFiltered 前缀索引过滤掉的行数，可以与其他几个 Rows 值对比分析索引过滤效果

使用示例

- 假如表的排序列为如下 5 列，那么前缀索引为：user_id(8 Bytes) + age(4 Bytes) + message(prefix 20 Bytes)。

ColumnName	Type
user_id	BIGINT
age	INT
message	VARCHAR(100)
max_dwell_time	DATETIME
min_dwell_time	DATETIME

- 假如表的排序列为如下 5 列，则前缀索引为 user_name(20 Bytes)。即使没有达到 36 个字节，因为遇到 VARCHAR，所以直接截断，不再往后继续。

ColumnName	Type
user_name	VARCHAR(20)
age	INT
message	VARCHAR(100)
max_dwell_time	DATETIME
min_dwell_time	DATETIME

- 当我们的查询条件，是前缀索引的前缀时，可以极大地加快查询速度。比如在第一个例子中，执行如下查询：

```
SELECT * FROM table WHERE user_id=1829239 and age=20;
```

该查询的效率会远高于如下查询：

```
SELECT * FROM table WHERE age=20;
```

所以在建表时，正确选择列顺序，能够极大地提高查询效率。

倒排索引

索引原理

倒排索引，是信息检索领域常用的索引技术，将文本分成一个个词，构建 词 -> 文档编号 的索引，可以快速查找一个词在哪些文档出现。

从 2.0.0 版本开始，Doris 支持倒排索引，可以用来进行文本类型的全文检索、普通数值日期类型的等值范围查询，快速从海量数据中过滤出满足条件的行。

在 Doris 的倒排索引实现中，Table 的一行对应一个文档、一列对应文档中的一个字段，因此利用倒排索引可以根据关键词快速定位包含它的行，达到 WHERE 子句加速的目的。

与 Doris 中其他索引不同的是，在存储层倒排索引使用独立的文件，跟数据文件一一对应、但物理存储上文件相互独立。这样的好处是可以做到创建、删除索引不用重写数据文件，大幅降低处理开销。

使用场景

倒排索引的使用范围很广泛，可以加速等值、范围、全文检索（关键词匹配、短语系列匹配等）。一个表可以有多个倒排索引，查询时多个倒排索引的条件可以任意组合。

倒排索引的功能简要介绍如下：

1. 加速字符串类型的全文检索

- 支持关键词检索，包括同时匹配多个关键字 MATCH_ALL、匹配任意一个关键字 MATCH_ANY
- 支持短语查询 MATCH_PHRASE
 - 支持指定词距 slop
 - 支持短语 + 前缀 MATCH_PHRASE_PREFIX
- 支持分词正则查询 MATCH_REGEXP
- 支持英文、中文以及 Unicode 多种分词

2. 加速普通等值、范围查询，覆盖原来 BITMAP 索引的功能，代替 BITMAP 索引

- 支持字符串、数值、日期时间类型的 =, !=, >, >=, <, <= 快速过滤
- 支持字符串、数字、日期时间数组类型的 =, !=, >, >=, <, <=

3. 支持完善的逻辑组合

- 不仅支持 AND 条件加速，还支持 OR NOT 条件加速
- 支持多个条件的任意 AND OR NOT 逻辑组合

4. 灵活高效的索引管理

- 支持在创建表上定义倒排索引

- 支持在已有的表上增加倒排索引，而且支持增量构建倒排索引，无需重写表中的已有数据
- 支持删除已有表上的倒排索引，无需重写表中的已有数据

倒排索引的使用有下面一些限制：

1. 存在精度问题的浮点数类型 FLOAT 和 DOUBLE 不支持倒排索引，原因是浮点数精度不准确。解决方案是使用精度准确的定点数类型 DECIMAL，DECIMAL 支持倒排索引。
2. 部分复杂数据类型还不支持倒排索引，包括：MAP、STRUCT、JSON、HLL、BITMAP、QUANTILE_STATE、AGG_STATE。
3. DUPLICATE 和 开启 Merge-on-Write 的 UNIQUE 表模型支持任意列建倒排索引。但是 AGGREGATE 和 未开启 Merge-on-Write 的 UNIQUE 模型仅支持 Key 列建倒排索引，非 Key 列不能建倒排索引，这是因为这两个模型需要读取所有数据后做合并，因此不能利用索引做提前过滤。

管理索引

建表时定义倒排索引

在建表语句中 COLUMN 的定义之后是索引定义：

```
CREATE TABLE table_name
(
  column_name1 TYPE1,
  column_name2 TYPE2,
  column_name3 TYPE3,
  INDEX idx_name1(column_name1) USING INVERTED [PROPERTIES(...)] [COMMENT 'your comment'],
  INDEX idx_name2(column_name2) USING INVERTED [PROPERTIES(...)] [COMMENT 'your comment']
)
table_properties;
```

语法说明如下：

1. `idx_column_name(column_name)` 是必须的，`column_name` 是建索引的列名，必须是前面列定义中出现过的，`idx_column_name` 是索引名字，必须表级别唯一，建议命名规范：列名前面加前缀 `idx_`
2. `USING INVERTED` 是必须的，用于指定索引类型是倒排索引
3. `PROPERTIES` 是可选的，用于指定倒排索引的额外属性，目前支持的属性如下：

parser 指定分词器

- 默认不指定代表不分词
 - `english` 是英文分词，适合被索引列是英文的情况，用空格和标点符号分词，性能高
 - `chinese` 是中文分词，适合被索引列主要是中文的情况，性能比 `English` 分词低
 - `unicode` 是多语言混合类型分词，适用于中英文混合、多语言混合的情况。它能够对邮箱前缀和后缀、IP 地址以及字符数字混合进行分词，并且可以对中文按字符分词。

分词的效果可以通过 `TOKENIZE SQL` 函数进行验证，具体参考后续章节。

parser_mode

用于指定分词的模式，目前 `parser = chinese` 时支持如下几种模式：

- `fine_grained`：细粒度模式，倾向于分出比较短、较多的词，比如‘武汉市长江大桥’会分成‘武汉’，‘武汉市’，‘市长’，‘长江’，‘长江大桥’，‘大桥’6 个词
 - `coarse_grained`：粗粒度模式，倾向于分出比较长、较少的词，比如‘武汉市长江大桥’会分成‘武汉市’，‘长江大桥’2 个词
 - 默认 `coarse_grained`

support_phrase

用于指定索引是否支持 `MATCH_PHRASE` 短语查询加速

- `true` 为支持，但是索引需要更多的存储空间
 - `false` 为不支持，更省存储空间，可以用 `MATCH_ALL` 查询多个关键字
 - 从 2.0.14, 2.1.5 和 3.0.1 版本开始，如果指定了 `parser` 则默认为 `true`，否则默认为 `false`

例如下面的例子指定中文分词，粗粒度模式，支持短语查询加速。

```
INDEX idx_name(column_name) USING INVERTED PROPERTIES("parser" = "chinese", "parser_mode" = "coarse_grained", "support_phrase" = "true")
```

char_filter

用于指定在分词前对文本进行预处理，通常用于影响分词行为

- `char_filter_type`：指定使用不同功能的 `char_filter`（目前仅支持 `char_replace`）

`char_replace` 将 `pattern` 中每个 `char` 替换为一个 `replacement` 中的 `char`

- `char_filter_pattern`：需要被替换掉的字符数
 - `char_filter_replacement`：替换后的字符数组，可以不用配置，默认为一个空格字符

例如下面的例子将点和下划线替换成空格，达到将点和下划线作为单词分隔符的目的，影响分词行为。

```
INDEX idx_name(column_name) USING INVERTED PROPERTIES("parser" = "unicode", "char_filter_type" = "char_replace", "char_filter_pattern" = "._", "char_filter_replacement" = " ")
```

ignore_above

用于指定不分词字符串索引（没有指定 `parser`）的长度限制

- 长度超过 `ignore_above` 设置的字符串不会被索引。对于字符串数组，`ignore_above` 将分别应用于每个数组元素，长度超过 `ignore_above` 的字符串元素将不被索引。

- 默认为 256，单位是字节

lower_case

是否将分词进行小写转换，从而在匹配的时候实现忽略大小写

- true：转换小写
 - false：不转换小写
 - 从 2.0.7 版本开始默认为 true，自动转小写，之前的版本默认为 false

stopwords

指明使用的停用词表，会影响分词器的行为

默认的内置停用词表包含一些无意义的词：'is'、'the'、'a' 等。在写入或者查询时，分词器会忽略停用词表中的词。

- none：使用空的停用词表

4. COMMENT 是可选的，用于指定索引注释

已有表增加倒排索引

1. ADD INDEX

支持CREATE INDEX 和 ALTER TABLE ADD INDEX 两种语法，参数跟建表时索引定义相同

```
-- 语法 1
CREATE INDEX idx_name ON table_name(column_name) USING INVERTED [PROPERTIES(...)] [COMMENT 'your comment'];
-- 语法 2
ALTER TABLE table_name ADD INDEX idx_name(column_name) USING INVERTED [PROPERTIES(...)] [COMMENT 'your comment'];
```

2. BUILD INDEX

CREATE / ADD INDEX 操作只是新增了索引定义，这个操作之后的新写入数据会生成倒排索引，而存量数据需要使用 BUILD INDEX 触发：

```
-- 语法 1，默认给全表的所有分区 BUILD INDEX
BUILD INDEX index_name ON table_name;
-- 语法 2，可指定 Partition，可指定一个或多个
BUILD INDEX index_name ON table_name PARTITIONS(partition_name1, partition_name2);
```

通过 SHOW BUILD INDEX 查看 BUILD INDEX 进度：

```
SHOW BUILD INDEX [FROM db_name];
-- 示例 1，查看所有的 BUILD INDEX 任务进展
SHOW BUILD INDEX;
-- 示例 2，查看指定 table 的 BUILD INDEX 任务进展
SHOW BUILD INDEX where TableName = "table1";
```

通过 CANCEL BUILD INDEX 取消 BUILD INDEX：

```
CANCEL BUILD INDEX ON table_name;
CANCEL BUILD INDEX ON table_name (job_id1,job_id2,...);
```

BUILD INDEX 会生成一个异步任务执行，在每个 BE 上有多个线程执行索引构建任务，通过 BE 参数 alter_index_worker_count 可以设置，默认值是 3。

2.0.12 之前的版本 BUILD INDEX 会一直重试直到成功，从这个版本开始通过失败和超时机制避免一直重试。

1. 一个 tablet 的多数副本 BUILD INDEX 失败后，整个 BUILD INDEX 失败结束
2. 时间超过 alter_table_timeout_second(), BUILD INDEX 超时结束
3. 用户可以多次触发 BUILD INDEX，已经 BUILD 成功的索引不会重复 BUILD

已有表删除倒排索引

```
-- 语法 1
DROP INDEX idx_name ON table_name;
-- 语法 2
ALTER TABLE table_name DROP INDEX idx_name;
```

DROP INDEX 会删除索引定义，新写入数据不会再写索引，同时会生成一个异步任务执行索引删除操作，在每个 BE 上有多个线程执行索引删除任务，通过 BE 参数 alter_index_worker_count 可以设置，默认值是 3。

查看倒排索引

```
-- 语法 1, 表的 schema 中 INDEX 部分 USING INVERTED 是倒排索引
SHOW CREATE TABLE table_name;

-- 语法 2, IndexType 为 INVERTED 的是倒排索引
SHOW INDEX FROM table_name;
```

使用索引

利用倒排索引加速查询

```
-- 1. 全文检索关键词匹配，通过 MATCH_ANY MATCH_ALL 完成
SELECT * FROM table_name WHERE column_name MATCH_ANY | MATCH_ALL 'keyword1 ...';

-- 1.1 content 列中包含 keyword1 的行
SELECT * FROM table_name WHERE content MATCH_ANY 'keyword1';

-- 1.2 content 列中包含 keyword1 或者 keyword2 的行，后面还可以添加多个 keyword
SELECT * FROM table_name WHERE content MATCH_ANY 'keyword1 keyword2';

-- 1.3 content 列中同时包含 keyword1 和 keyword2 的行，后面还可以添加多个 keyword
SELECT * FROM table_name WHERE content MATCH_ALL 'keyword1 keyword2';
```

```

-- 2. 全文检索短语匹配, 通过 MATCH_PHRASE 完成
-- 2.1 content 列中同时包含 keyword1 和 keyword2 的行, 而且 keyword2 必须紧跟在 keyword1 后面
-- 'keyword1 keyword2', 'wordx keyword1 keyword2', 'wordx keyword1 keyword2 wordy' 能匹配, 因为他们都包含 keyword1
keyword2, 而且 keyword2 紧跟在 keyword1 后面
-- 'keyword1 wordx keyword2' 不能匹配, 因为 keyword1 keyword2 之间隔了一个词 wordx
-- 'keyword2 keyword1' 不能匹配, 因为 keyword1 keyword2 的顺序反了
SELECT * FROM table_name WHERE content MATCH_PHRASE 'keyword1 keyword2';

-- 2.2 content 列中同时包含 keyword1 和 keyword2 的行, 而且 keyword1 keyword2 的 `词距` (slop) 不超过 3
-- 'keyword1 keyword2', 'keyword1 a keyword2', 'keyword1 a b c keyword2' 都能匹配, 因为 keyword1 keyword2 中间隔
的词分别是 0 1 3 都不超过 3
-- 'keyword1 a b c d keyword2' 不能匹配, 因为 keyword1 keyword2 中间隔的词有 4 个, 超过 3
-- 'keyword2 keyword1', 'keyword2 a keyword1', 'keyword2 a b c keyword1' 也能匹配, 因为指定 slop > 0 时不再要求
keyword1 keyword2 的顺序。这个行为参考了 ES, 与直觉的预期不一样, 因此 Doris 提供了在 slop 后面指定正数符号 (+) 表示需要保持
keyword1 keyword2 的先后顺序
SELECT * FROM table_name WHERE content MATCH_PHRASE 'keyword1 keyword2 ~3';
-- slop 指定正号, 'keyword1 a b c keyword2' 能匹配, 而 'keyword2 a b c keyword1' 不能匹配
SELECT * FROM table_name WHERE content MATCH_PHRASE 'keyword1 keyword2 ~3+';

-- 2.3 在保持词顺序的前提下, 对最后一个词 keyword2 做前缀匹配, 默认找 50 个前缀词 (session 变量
inverted_index_max_expansions 控制)
-- 需要保证 keyword1, keyword2 在原文分词后也是相邻的, 不能中间有其他词
-- 'keyword1 keyword2abc' 能匹配, 因为 keyword1 完全一样, 最后一个 keyword2abc 是 keyword2 的前缀
-- 'keyword1 keyword2' 也能匹配, 因为 keyword2 也是 keyword2 的前缀
-- 'keyword1 keyword3' 不能匹配, 因为 keyword3 不是 keyword2 的前缀
-- 'keyword1 keyword3abc' 也不能匹配, 因为 keyword3abc 也不是 keyword2 的前缀
SELECT * FROM table_name WHERE content MATCH_PHRASE_PREFIX 'keyword1 keyword2';

-- 2.4 如果只填一个词会退化为前缀查询, 默认找 50 个前缀词 (session 变量 inverted_index_max_expansions 控制)
SELECT * FROM table_name WHERE content MATCH_PHRASE_PREFIX 'keyword1';

-- 2.5 对分词后的词进行正则匹配, 默认匹配 50 个 (session 变量 inverted_index_max_expansions 控制)
-- 类似 MATCH_PHRASE_PREFIX 的匹配规则, 只是前缀变成了正则
SELECT * FROM table_name WHERE content MATCH_REGEXP 'key.*';

-- 3. 普通等值、范围、IN、NOT IN, 正常的 SQL 语句即可, 例如
SELECT * FROM table_name WHERE id = 123;
SELECT * FROM table_name WHERE ts > '2023-01-01 00:00:00';
SELECT * FROM table_name WHERE op_type IN ('add', 'delete');

```

通过profile分析索引加速效果

倒排查询加速可以通过 session 变量 enable_inverted_index_query 开关, 默认是 true 打开, 有时为了验证索引加速效果可以设置为 false 关闭。

可以通过 Query Profile 中的下面几个指标分析倒排索引的加速效果。 - RowsInvertedIndexFiltered 倒排过滤掉的行数, 可以与其他几个 Rows 值对比分析索引过滤效果 - InvertedIndexFilterTime 倒排索引消耗的时间 - InvertedIndexSearcherOpenTime 倒排索引打开索引的时间 - InvertedIndexSearcherSearchTime 倒排索引内部查询的时间

用分词函数验证分词效果

如果想检查分词实际效果或者对一段文本进行分词行为, 可以使用 TOKENIZE 函数进行验证。

TOKENIZE 函数的第一个参数是待分词的文本, 第二个参数是创建索引指定的分词参数。

```
mysql> SELECT TOKENIZE('武汉长江大桥','parser="chinese","parser_mode="fine_grained"');
+-----+
| tokenize('武汉长江大桥', '"parser="chinese","parser_mode="fine_grained"') |
+-----+
| ["武汉", "武汉长江大桥", "长江", "长江大桥", "大桥"] |
+-----+
1 row in set (0.02 sec)

mysql> SELECT TOKENIZE('武汉市长江大桥','parser="chinese","parser_mode="fine_grained"');
+-----+
| tokenize('武汉市长江大桥', '"parser="chinese","parser_mode="fine_grained"') |
+-----+
| ["武汉", "武汉市", "市长", "长江", "长江大桥", "大桥"] |
+-----+
1 row in set (0.02 sec)

mysql> SELECT TOKENIZE('武汉市长江大桥','parser="chinese","parser_mode="coarse_grained"');
+-----+
| tokenize('武汉市长江大桥', '"parser="chinese","parser_mode="coarse_grained"') |
+-----+
| ["武汉市", "长江大桥"] |
+-----+
1 row in set (0.02 sec)

mysql> SELECT TOKENIZE('I love Doris','parser="english"');
+-----+
| tokenize('I love Doris', '"parser="english"') |
+-----+
| ["i", "love", "doris"] |
+-----+
1 row in set (0.02 sec)

mysql> SELECT TOKENIZE('I love CHINA 我爱我的祖国','parser="unicode"');
+-----+
| tokenize('I love CHINA 我爱我的祖国', '"parser="unicode"') |
+-----+
| ["i", "love", "china", "我", "爱", "我", "的", "祖", "国"] |
+-----+
1 row in set (0.02 sec)
```

使用示例

用 HackerNews 100 万条数据展示倒排索引的创建、全文检索、普通查询，包括跟无索引的查询性能进行简单对比。

建表

```
CREATE DATABASE test_inverted_index;

USE test_inverted_index;

-- 创建表的同时创建了 comment 的倒排索引 idx_comment
-- USING INVERTED 指定索引类型是倒排索引
-- PROPERTIES("parser" = "english") 指定采用 "english" 分词，还支持 "chinese" 中文分词和 "unicode" 中英文多语言混合分词，如果不指定 "parser" 参数表示不分词

CREATE TABLE hackernews_1m
(
  `id` BIGINT,
```

```

    `deleted` TINYINT,
    `type` String,
    `author` String,
    `timestamp` DateTimeV2,
    `comment` String,
    `dead` TINYINT,
    `parent` BIGINT,
    `poll` BIGINT,
    `children` Array<BIGINT>,
    `url` String,
    `score` INT,
    `title` String,
    `parts` Array<INT>,
    `descendants` INT,
    INDEX idx_comment (`comment`) USING INVERTED PROPERTIES("parser" = "english") COMMENT 'inverted index for
comment'
)
DUPLICATE KEY(`id`)
DISTRIBUTED BY HASH(`id`) BUCKETS 10
PROPERTIES ("replication_num" = "1");

```

导入数据

通过 Stream Load 导入数据

```

wget https://qa-build.oss-cn-beijing.aliyuncs.com/regression/index/hacknernews_1m.csv.gz

curl --location-trusted -u root: -H "compress_type:gz" -T hacknernews_1m.csv.gz -XPUT
http://127.0.0.1:8030/api/test_inverted_index/hacknernews_1m/_stream_load
{
  "TxnId": 2,
  "Label": "a8a3e802-2329-49e8-912b-04c800a461a6",
  "TwoPhaseCommit": "false",
  "Status": "Success",
  "Message": "OK",
  "NumberTotalRows": 1000000,
  "NumberLoadedRows": 1000000,
  "NumberFilteredRows": 0,
  "NumberUnselectedRows": 0,
  "LoadBytes": 130618406,
  "LoadTimeMs": 8988,
  "BeginTxnTimeMs": 23,
  "StreamLoadPutTimeMs": 113,
  "ReadDataTimeMs": 4788,
  "WriteDataTimeMs": 8811,
  "CommitAndPublishTimeMs": 38
}

```

SQL 运行 count() 确认导入数据成功

```

mysql> SELECT count() FROM hackernews_1m;
+-----+
| count() |
+-----+
| 1000000 |
+-----+
1 row in set (0.02 sec)

```

查询

01 全文检索

- 用 LIKE 匹配计算 comment 中含有 'OLAP' 的行数，耗时 0.18s

```
mysql> SELECT count() FROM hackernews_1m WHERE comment LIKE '%OLAP%';
+-----+
| count() |
+-----+
|      34 |
+-----+
1 row in set (0.18 sec)
```

- 用基于倒排索引的全文检索 MATCH_ANY 计算 comment 中含有 'OLAP' 的行数，耗时 0.02s，加速 9 倍，在更大的数据集上效果会更加明显

这里结果条数的差异，是因为倒排索引对 comment 分词后，还会对词进行统一成小写等归一化处理，因此 MATCH_ANY 比 LIKE 的结果多一些

```
mysql> SELECT count() FROM hackernews_1m WHERE comment MATCH_ANY 'OLAP';
+-----+
| count() |
+-----+
|      35 |
+-----+
1 row in set (0.02 sec)
```

- 同样的对比统计 'OLTP' 出现次数的性能，0.07s vs 0.01s，由于缓存的原因 LIKE 和 MATCH_ANY 都有提升，倒排索引仍然有 7 倍加速

```
mysql> SELECT count() FROM hackernews_1m WHERE comment LIKE '%OLTP%';
+-----+
| count() |
+-----+
|      48 |
+-----+
1 row in set (0.07 sec)

mysql> SELECT count() FROM hackernews_1m WHERE comment MATCH_ANY 'OLTP';
+-----+
| count() |
+-----+
|      51 |
+-----+
1 row in set (0.01 sec)
```

- 同时出现 'OLAP' 和 'OLTP' 两个词，0.13s vs 0.01s，13 倍加速

要求多个词同时出现时（AND 关系）使用 MATCH_ALL 'keyword1 keyword2 ...'

```
mysql> SELECT count() FROM hackernews_1m WHERE comment LIKE '%OLAP%' AND comment LIKE '%OLTP%';
+-----+
| count() |
+-----+
|      14 |
+-----+
```

```

+-----+
1 row in set (0.13 sec)

mysql> SELECT count() FROM hackernews_1m WHERE comment MATCH_ALL 'OLAP OLTP';
+-----+
| count() |
+-----+
|      15 |
+-----+
1 row in set (0.01 sec)

```

- 任意出现 'OLAP' 和 'OLTP' 其中一个词, 0.12s vs 0.01s, 12 倍加速

只要求多个词任意一个或多个出现时 (OR 关系) 使用 MATCH_ANY 'keyword1 keyword2 ...'

```

mysql> SELECT count() FROM hackernews_1m WHERE comment LIKE '%OLAP%' OR comment LIKE '%OLTP%';
+-----+
| count() |
+-----+
|      68 |
+-----+
1 row in set (0.12 sec)

mysql> SELECT count() FROM hackernews_1m WHERE comment MATCH_ANY 'OLAP OLTP';
+-----+
| count() |
+-----+
|      71 |
+-----+
1 row in set (0.01 sec)

```

02 普通等值、范围查询

- DateTime 类型的列范围查询

```

mysql> SELECT count() FROM hackernews_1m WHERE timestamp > '2007-08-23 04:17:00';
+-----+
| count() |
+-----+
| 999081 |
+-----+
1 row in set (0.03 sec)

```

- 为 timestamp 列增加一个倒排索引

```

-- 对于日期时间类型 USING INVERTED, 不用指定分词
-- CREATE INDEX 是第一种建索引的语法, 另外一种在后面展示
mysql> CREATE INDEX idx_timestamp ON hackernews_1m(timestamp) USING INVERTED;
Query OK, 0 rows affected (0.03 sec)

```

```

mysql> BUILD INDEX idx_timestamp ON hackernews_1m;
Query OK, 0 rows affected (0.01 sec)

```

- 查看索引创建进度, 通过 FinishTime 和 CreateTime 的差值, 可以看到 100 万条数据对 timestamp 列建倒排索引只用了 1s


```
mysql> SHOW ALTER TABLE COLUMN;
```

JobId	TableName	CreateTime	FinishTime	IndexName	IndexId
10030	hackernews_1m	2023-02-10 19:44:12.929	2023-02-10 19:44:13.938	hackernews_1m	10031
10008		1:1994690496	3	FINISHED	NULL
					2592000

```
1 row in set (0.00 sec)
```

```
-- 若 table 没有分区, PartitionName 默认就是 TableName
mysql> SHOW BUILD INDEX;
```

JobId	TableName	PartitionName	AlterInvertedIndexes	CreateTime	FinishTime	TransactionId	State	Msg	Progress
10191	hackernews_1m	hackernews_1m	[ADD INDEX idx_timestamp (`timestamp`) USING INVERTED],	2023-06-26 15:32:33.894	2023-06-26 15:32:34.847	3	FINISHED	NULL	

```
1 row in set (0.04 sec)
```

- 索引创建后, 范围查询用同样的查询方式, Doris 会自动识别索引进行优化, 但是这里由于数据量小性能差别不大

```
mysql> SELECT count() FROM hackernews_1m WHERE timestamp > '2007-08-23 04:17:00';
```

count()
999081

```
1 row in set (0.01 sec)
```

- 在数值类型的列 Parent 进行类似 timestamp 的操作, 这里查询使用等值匹配

```
mysql> SELECT count() FROM hackernews_1m WHERE parent = 11189;
```

count()
2

```
1 row in set (0.01 sec)
```

```
-- 对于数值类型 USING INVERTED, 不用指定分词
-- ALTER TABLE t ADD INDEX 是第二种建索引的语法
mysql> ALTER TABLE hackernews_1m ADD INDEX idx_parent(parent) USING INVERTED;
Query OK, 0 rows affected (0.01 sec)
```

```
-- 执行 BUILD INDEX 给存量数据构建倒排索引
mysql> BUILD INDEX idx_parent ON hackernews_1m;
Query OK, 0 rows affected (0.01 sec)
```

```
mysql> SHOW ALTER TABLE COLUMN;
```

JobId	TableName	CreateTime	FinishTime	IndexName	IndexId
-------	-----------	------------	------------	-----------	---------

```

+-----+-----+-----+-----+-----+-----+-----+
| JobId | TableName | CreateTime | FinishTime | IndexName | IndexId |
| OriginIndexId | SchemaVersion | TransactionId | State | Msg | Progress | Timeout |
+-----+-----+-----+-----+-----+-----+-----+
| 10030 | hackernews_1m | 2023-02-10 19:44:12.929 | 2023-02-10 19:44:13.938 | hackernews_1m | 10031 | | |
| 10008 | | 1:1994690496 | 3 | FINISHED | | NULL | 2592000 |
| 10053 | hackernews_1m | 2023-02-10 19:49:32.893 | 2023-02-10 19:49:33.982 | hackernews_1m | 10054 |
| 10008 | | 1:378856428 | 4 | FINISHED | | NULL | 2592000 |
+-----+-----+-----+-----+-----+-----+-----+

mysql> SHOW BUILD INDEX;
+-----+-----+-----+-----+-----+-----+-----+
| JobId | TableName | PartitionName | AlterInvertedIndexes |
| CreateTime | FinishTime | TransactionId | State | Msg | Progress |
+-----+-----+-----+-----+-----+-----+-----+
| 11005 | hackernews_1m | hackernews_1m | [ADD INDEX idx_parent (`parent`) USING INVERTED], | 2023-
06-26 16:25:10.167 | 2023-06-26 16:25:10.838 | 1002 | FINISHED | | NULL |
+-----+-----+-----+-----+-----+-----+-----+

1 row in set (0.01 sec)

mysql> SELECT count() FROM hackernews_1m WHERE parent = 11189;
+-----+
| count() |
+-----+
| 2 |
+-----+
1 row in set (0.01 sec)

```

- 对字符串类型的 author 建立不分词的倒排索引，等值查询也可以利用索引加速

```

mysql> SELECT count() FROM hackernews_1m WHERE author = 'faster';
+-----+
| count() |
+-----+
| 20 |
+-----+
1 row in set (0.03 sec)

-- 这里只用了 USING INVERTED, 不对 author 分词, 整个当做一个词处理
mysql> ALTER TABLE hackernews_1m ADD INDEX idx_author(author) USING INVERTED;
Query OK, 0 rows affected (0.01 sec)

-- 执行 BUILD INDEX 给存量数据加上倒排索引:
mysql> BUILD INDEX idx_author ON hackernews_1m;
Query OK, 0 rows affected (0.01 sec)

-- 100 万条 author 数据增量建索引仅消耗 1.5s
mysql> SHOW ALTER TABLE COLUMN;
+-----+-----+-----+-----+-----+-----+-----+
| JobId | TableName | CreateTime | FinishTime | IndexName | IndexId |
| OriginIndexId | SchemaVersion | TransactionId | State | Msg | Progress | Timeout |
+-----+-----+-----+-----+-----+-----+-----+
| 10030 | hackernews_1m | 2023-02-10 19:44:12.929 | 2023-02-10 19:44:13.938 | hackernews_1m | 10031 | | |
| 10008 | | 1:1994690496 | 3 | FINISHED | | NULL | 2592000 |
| 10053 | hackernews_1m | 2023-02-10 19:49:32.893 | 2023-02-10 19:49:33.982 | hackernews_1m | 10054 |
| 10008 | | 1:378856428 | 4 | FINISHED | | NULL | 2592000 |
+-----+-----+-----+-----+-----+-----+-----+

```

10076	hackernews_1m	2023-02-10 19:54:20.046	2023-02-10 19:54:21.521	hackernews_1m	10077
10008		1:1335127701	5	FINISHED	NULL
					2592000

```
mysql> SHOW BUILD INDEX order by CreateTime desc limit 1;
```

JobId	TableName	PartitionName	AlterInvertedIndexes	CreateTime	FinishTime	TransactionId	State	Msg	Progress
13006	hackernews_1m	hackernews_1m	[ADD INDEX idx_author (`author`) USING INVERTED],	2023-06-26 17:23:02.610	2023-06-26 17:23:03.755	3004	FINISHED	NULL	

1 row in set (0.01 sec)

-- 创建索引后，字符串等值匹配也有明显加速

```
mysql> SELECT count() FROM hackernews_1m WHERE author = 'faster';
```

count()
20

1 row in set (0.01 sec)

BloomFilter 索引

索引原理


BloomFilter 索引是基于 BloomFilter 的一种跳数索引。它的原理是利用 BloomFilter 跳过等值查询指定条件不满足的数据块，达到减少 I/O 查询加速的目的。

BloomFilter 是由 Bloom 在 1970 年提出的一种多哈希函数映射的快速查找算法。通常应用在一些需要快速判断某个元素是否属于集合，但是并不严格要求 100% 正确的场合，BloomFilter 有以下特点：

- 空间效率高的概率型数据结构，用来检查一个元素是否在一个集合中。
- 对于一个元素检测是否存在的调用，BloomFilter 会告诉调用者两个结果之一：可能存在或者一定不存在。

BloomFilter 是由一个超长的二进制位数组和一系列的哈希函数组成。二进制位数组初始全部为 0，当给定一个待查询的元素时，这个元素会被一系列哈希函数计算映射出一系列的值，所有的值在位数组的偏移量处置为 1。

下图所示出一个 $m=18$, $k=3$ (m 是该 Bit 数组的大小， k 是 Hash 函数的个数) 的 BloomFilter 示例。集合中的 x 、 y 、 z 三个元素通过 3 个不同的哈希函数散列到位数组中。当查询元素 w 时，通过 Hash 函数计算之后只要有一个位为 0，因此 w 不在该集合中。但是反过来全部都是 1 只能说明可能在集合中、不能肯定一定在集合中，因为 Hash 函数可能出现 Hash 碰撞。



Bloom_filter.svg

反过来如果某个元素经过哈希函数计算后得到所有的偏移位置，若这些位置全都为 1，只能说明可能在集合中、不能肯定一定在集合中，因为 Hash 函数可能出现 Hash 碰撞。这就是 BloomFilter“假阳性”，因此基于 BloomFilter 的索引只能跳过不满足条件的数据，不能精确定位满足条件的数据。

Doris BloomFilter 索引以数据块 (page) 为单位构建，每个数据块存储一个 BloomFilter。写入时，对于数据块中的每个值，经过 Hash 存入数据块对应的 BloomFilter。查询时，根据等值条件的值，判断每个数据块对应的 BloomFilter 是否包含这个值，不包含则跳过对应的数据块不读取，达到减少 I/O 查询加速的目的。

使用场景

BloomFilter 索引能够对等值查询（包括 = 和 IN）加速，对高基数字段效果较好，比如 userid 等唯一 ID 字段。

BloomFilter 的使用有下面一些限制：

- 对 IN 和 = 之外的查询没有效果，比如 !=, NOT IN, >, < 等
- 不支持对 Tinyint、Float、Double 类型的列建 BloomFilter 索引。
- 对低基数字段的加速效果很有限，比如“性别”字段仅有两种值，几乎每个数据块都会包含所有取值，导致 BloomFilter 索引失去意义。

如果要查看某个查询 BloomFilter 索引效果，可以通过 Query Profile 中的相关指标进行分析。

- BlockConditionsFilteredBloomFilterTime 是 BloomFilter 索引消耗的时间
- RowsBloomFilterFiltered 是 BloomFilter 过滤掉的行数，可以与其他几个 Rows 值对比分析 BloomFilter 索引过滤效果

管理索引

建表时创建 BloomFilter 索引

由于历史原因，BloomFilter 索引定义的语法与倒排索引等通用 INDEX 语法不一样。BloomFilter 索引通过表的 PROPERTIES “bloom_filter_columns” 指定哪些字段建 BloomFilter 索引，可以指定一个或者多个字段。

```
PROPERTIES (  
  "bloom_filter_columns" = "column_name1,column_name2"  
);
```

查看 BloomFilter 索引

```
SHOW CREATE TABLE table_name;
```

已有表增加、删除 BloomFilter 索引

通过 ALTER TABLE 修改表的 bloom_filter_columns 属性来完成。

为 column_name3 增加 BloomFilter 索引

```
ALTER TABLE table_name SET ("bloom_filter_columns" = "column_name1,column_name2,column_name3");
```

删除 column_name1 的 BloomFilter 索引

```
ALTER TABLE table_name SET ("bloom_filter_columns" = "column_name2,column_name3");
```

使用索引

BloomFilter 索引用于加速 WHERE 条件中的等值查询，能加速时自动生效，没有特殊语法。

可以通过 Query Profile 中的下面几个指标分析 BloomFilter 索引的加速效果。 - RowsBloomFilterFiltered

BloomFilter 索引过滤掉的行数，可以与其他几个 Rows 值对比分析索引过滤效果 -

BlockConditionsFilteredBloomFilterTime BloomFilter 倒排索引消耗的时间

使用示例

下面通过实例来看看 Doris 怎么创建 BloomFilter 索引。

Doris BloomFilter 索引的创建是通过在建表语句的 PROPERTIES 里加上 “bloom_filter_columns”=“k1,k2,k3”，这个属性，k1,k2,k3 是要创建的 BloomFilter 索引的 Key 列名称，例如下面对表里的 saler_id,category_id 创建了 BloomFilter 索引。

```
CREATE TABLE IF NOT EXISTS sale_detail_bloom (
  sale_date date NOT NULL COMMENT "销售时间",
  customer_id int NOT NULL COMMENT "客户编号",
  saler_id int NOT NULL COMMENT "销售员",
  sku_id int NOT NULL COMMENT "商品编号",
  category_id int NOT NULL COMMENT "商品分类",
  sale_count int NOT NULL COMMENT "销售数量",
  sale_price DECIMAL(12,2) NOT NULL COMMENT "单价",
  sale_amt DECIMAL(20,2) COMMENT "销售总金额"
)
Duplicate KEY(sale_date, customer_id,saler_id,sku_id,category_id)
DISTRIBUTED BY HASH(saler_id) BUCKETS 10
PROPERTIES (
  "replication_num" = "1",
  "bloom_filter_columns"="saler_id,category_id"
);
```

N-Gram 索引

索引原理

NGram BloomFilter 索引和 BloomFilter 索引类似，也是基于 BloomFilter 的跳数索引。

与 BloomFilter 索引不同的是，NGram BloomFilter 索引用于加速文本 LIKE 查询，它存入 BloomFilter 的不是原始文本的值，而是对文本进行 NGram 分词，每个词作为值存入 BloomFilter。对于 LIKE 查询，将 LIKE '%pattern%' 的 pattern 也进行 NGram 分词，判断每个词是否在 BloomFilter 中，如果某个词不在则对应的数据块就不满足 LIKE 条件，可以跳过这部分数据减少 IO 加速查询。

使用场景

NGram BloomFilter 索引只能加速字符串 LIKE 查询，而且 LIKE pattern 中的连续字符个数要大于等于索引定义的 NGram 中的 N。

- **NGram BloomFilter** 只支持字符串列，只能加速 **LIKE** 查询。

- NGram BloomFilter 索引和 BloomFilter 索引为互斥关系，即同一个列只能设置两者中的一个。
- NGram BloomFilter 索引的效果分析，跟 BloomFilter 索引类似。

管理索引

创建 NGram BloomFilter 索引

在建表语句中 COLUMN 的定义之后是索引定义：

```
INDEX `idx_column_name` (`column_name`) USING NGRAM_BF PROPERTIES("gram_size"="3", "bf_size"="1024")  
COMMENT 'username ngram_bf index'
```

语法说明如下：

1. `idx_column_name(column_name)` 是必须的，`column_name` 是建索引的列名，必须是前面列定义中出现过的，`idx_column_name` 是索引名字，必须表级别唯一，建议命名规范：列名前面加前缀 `idx_`

2. `USING NGRAM_BF` 是必须的，用于指定索引类型是 **NGram BloomFilter** 索引

3. `PROPERTIES` 是可选的，用于指定 **NGram BloomFilter** 索引的额外属性，目前支持的属性如下：

- `gram_size`：NGram 中的 N，指定 N 个连续字符分词一个词，比如 'an ngram example' 在 N = 3 的时候分成 'an', 'n n', 'ng', 'ngr', 'gra', 'ram' 6 个词。
- `bf_size`：BloomFilter 的大小，单位是 Bit。`bf_size` 决定每个数据块对应的索引大小，这个值越大占用存储空间越大，同时 Hash 碰撞的概率也越低。

- `gram_size` 建议取 LIKE 查询的字符串最小长度，但是不建议低于 2。一般建议设置 `"gram_size"="3"`，`"bf_size"="1024"`，然后根据 Query Profile 调优。

4. COMMENT 是可选的，用于指定索引注释

查看 NGram BloomFilter 索引

```
-- 语法 1, 表的 schema 中 INDEX 部分 USING NGRAM_BF 是倒排索引
SHOW CREATE TABLE table_name;

-- 语法 2, IndexType 为 NGRAM_BF 的是倒排索引
SHOW INDEX FROM table_name;
```

删除 NGram BloomFilter 索引

```
ALTER TABLE table_ngrambf DROP INDEX idx_ngrambf;
```

修改 NGram BloomFilter 索引

```
CREATE INDEX idx_column_name2(column_name2) ON table_ngrambf USING NGRAM_BF PROPERTIES("gram_size"="3",
"bf_size"="1024") COMMENT 'username ngram_bf index';

ALTER TABLE table_ngrambf ADD INDEX idx_column_name2(column_name2) USING NGRAM_BF PROPERTIES("gram_size"="3",
"bf_size"="1024") COMMENT 'username ngram_bf index';
```

使用索引

使用 NGram BloomFilter 索引需设置如下参数 (`enable_function_pushdown` 默认为 `false`):

```
SET enable_function_pushdown = true;
```

NGram BloomFilter 索引用于加速 LIKE 查询，比如：

```
SELECT count() FROM table1 WHERE message LIKE '%error%';
```

可以通过 Query Profile 中的下面几个指标分析 BloomFilter 索引（包括 NGram）的加速效果。 -
RowsBloomFilterFiltered BloomFilter 索引过滤掉的行数，可以与其他几个 Rows 值对比分析索引过滤效果 -
BlockConditionsFilteredBloomFilterTime BloomFilter 倒排索引消耗的时间

使用示例

以亚马逊产品的用户评论信息的数据集 `amazon_reviews` 为例展示 NGram BloomFilter 索引的使用和效果。

建表

```
CREATE TABLE `amazon_reviews` (
  `review_date` int(11) NULL,
```



```

`marketplace` varchar(20) NULL,
`customer_id` bigint(20) NULL,
`review_id` varchar(40) NULL,
`product_id` varchar(10) NULL,
`product_parent` bigint(20) NULL,
`product_title` varchar(500) NULL,
`product_category` varchar(50) NULL,
`star_rating` smallint(6) NULL,
`helpful_votes` int(11) NULL,
`total_votes` int(11) NULL,
`vine` boolean NULL,
`verified_purchase` boolean NULL,
`review_headline` varchar(500) NULL,
`review_body` string NULL
) ENGINE=OLAP
DUPLICATE KEY(`review_date`)
COMMENT 'OLAP'
DISTRIBUTED BY HASH(`review_date`) BUCKETS 16
PROPERTIES (
"replication_allocation" = "tag.location.default: 1",
"compression" = "ZSTD"
);

```

导入数据

用 **wget** 或者其他工具从下面的地址下载数据集

```

https://datasets-documentation.s3.eu-west-3.amazonaws.com/amazon_reviews/amazon_reviews_2010.snappy.parquet
https://datasets-documentation.s3.eu-west-3.amazonaws.com/amazon_reviews/amazon_reviews_2011.snappy.parquet
https://datasets-documentation.s3.eu-west-3.amazonaws.com/amazon_reviews/amazon_reviews_2012.snappy.parquet
https://datasets-documentation.s3.eu-west-3.amazonaws.com/amazon_reviews/amazon_reviews_2013.snappy.parquet
https://datasets-documentation.s3.eu-west-3.amazonaws.com/amazon_reviews/amazon_reviews_2014.snappy.parquet
https://datasets-documentation.s3.eu-west-3.amazonaws.com/amazon_reviews/amazon_reviews_2015.snappy.parquet

```

用 stream load 导入数据

```

curl --location-trusted -u root: -T amazon_reviews_2010.snappy.parquet -H "format:parquet"
http://127.0.0.1:8030/api/${DB}/amazon_reviews/_stream_load
curl --location-trusted -u root: -T amazon_reviews_2011.snappy.parquet -H "format:parquet"
http://127.0.0.1:8030/api/${DB}/amazon_reviews/_stream_load
curl --location-trusted -u root: -T amazon_reviews_2012.snappy.parquet -H "format:parquet"
http://127.0.0.1:8030/api/${DB}/amazon_reviews/_stream_load
curl --location-trusted -u root: -T amazon_reviews_2013.snappy.parquet -H "format:parquet"
http://127.0.0.1:8030/api/${DB}/amazon_reviews/_stream_load
curl --location-trusted -u root: -T amazon_reviews_2014.snappy.parquet -H "format:parquet"
http://127.0.0.1:8030/api/${DB}/amazon_reviews/_stream_load
curl --location-trusted -u root: -T amazon_reviews_2015.snappy.parquet -H "format:parquet"
http://127.0.0.1:8030/api/${DB}/amazon_reviews/_stream_load

```

上面的文件可能超过 10 GB，您可能需要调整 **be.conf** 的 **streaming_load_max_mb** 防止超过 **stream load** 文件上传大小的限制，可以通过下面方式动态调整

```
curl -X POST http://{be_ip}:{be_http_port}/api/update_config?streaming_load_max_mb=32768
```

需要每台 be 都执行上述命令。

SQL 运行 count() 确认导入数据成功

```
mysql> SELECT COUNT(*) FROM amazon_reviews;
+-----+
| count(*) |
+-----+
| 135589433 |
+-----+
```

查询

首先在没有索引的时候运行查询，WHERE 条件中有 LIKE，耗时7.60s

```
SELECT
  product_id,
  any(product_title),
  AVG(star_rating) AS rating,
  COUNT(*) AS count
FROM
  amazon_reviews
WHERE
  review_body LIKE '%is super awesome%'
GROUP BY
  product_id
ORDER BY
  count DESC,
  rating DESC,
  product_id
LIMIT 5;
```

product_id	any_value(product_title)	rating	count
B00992CF6W	Minecraft	4.8235294117647056	17
B009UX2YAC	Subway Surfers	4.777777777777777	9
B00DJFIMW6	Minion Rush: Despicable Me Official Game	4.875	8
B0086700CM	Temple Run	5	6
B00KWVZ750	Angry Birds Epic RPG	5	6

5 rows in set (7.60 sec)

然后添加 NGram BloomFilter 索引，再次运行相同的查询耗时0.93s，性能提升了8倍

```
ALTER TABLE amazon_reviews ADD INDEX review_body_ngram_idx(review_body) USING NGRAM_BF
PROPERTIES("gram_size"="10", "bf_size"="10240");
```

product_id	any_value(product_title)	rating	count
B00992CF6W	Minecraft	4.8235294117647056	17
B009UX2YAC	Subway Surfers	4.777777777777777	9
B00DJFIMW6	Minion Rush: Despicable Me Official Game	4.875	8
B0086700CM	Temple Run	5	6

B00KWVZ750	Angry Birds Epic RPG		5		6	
+-----+-----+-----+-----+						
5 rows in set (0.93 sec)						

数据库建表最佳实践

1 数据表模型

Doris 数据表模型上目前分为三类：DUPLICATE KEY, UNIQUE KEY, AGGREGATE KEY。

****推荐规约****

因为数据模型在建表时就已经确定，且**无法修改**。所以，选择一个合适的**数据模型非常重要**。

1. Duplicate 适合任意维度的 Ad-hoc 查询。虽然同样无法利用预聚合的特性，但是不受聚合模型的约束，可以发挥列存模型的优势（只读取相关列，而不需要读取所有 Key 列）。
2. Aggregate 模型可以通过预聚合，极大地降低聚合查询时所需扫描的数据量和查询的计算量，非常适合有固定模式的报表类查询场景。但是该模型对 count(*) 查询很不友好。同时因为固定了 Value 列上的聚合方式，在进行其他类型的聚合查询时，需要考虑语意正确性。
3. Unique 模型针对需要唯一主键约束的场景，可以保证主键唯一性约束。但是无法利用物化等预聚合带来的查询优势。对于聚合查询有较高性能需求的用户，推荐使用自 1.2 版本加入的写时合并实现。
4. 如果有部分列更新的需求，可以选择：
 - a. Unique 模型的 Merge-on-Write 模式
 - b. Aggregate 模型的 REPLACE_IF_NOT_NULL 聚合方式

01 DUPLICATE KEY 表模型

Insert Data

Key		Value
ID	City	PV
1	100	10
2	100	20

Original Data

Key		Value
ID	City	PV
1	100	1
1	200	2
2	100	3
2	200	5

Divide by
Primary Keys

1	100	1	Old
1	100	1	New
1	200	2	Old
2	100	3	Old
2	100	3	New
2	200	5	Old

Duplicate Key Model

1	100	1	Old
1	100	10	New
1	200	2	Old
2	100	3	Old
2	100	20	New
2	200	5	Old

Key		Value
ID	City	PV
1	100	1
1	100	10
1	200	2
2	100	3
2	100	20
2	200	5

```
CREATE TABLE tbl_duplicate(  
    siteid INT,  
    city SMALLINT,  
    pv BIGINT  
)  
  
DUPLICATE KEY(siteid, city)  
DISTRIBUTED BY HASH(siteid) BUCKETS 10;  
  
INSERT INTO tbl_duplicate VALUES  
(10, 100, 1), (10, 100, 1),  
(10, 200, 2), (10, 200, 2),  
(20, 100, 1), (20, 100, 2);  
  
SELECT * FROM tbl_duplicate;  
  
+-----+-----+-----+  
| siteid | city | pv |  
+-----+-----+-----+  
| 10 | 100 | 1 |  
| 10 | 100 | 1 |  
| 10 | 200 | 2 |  
| 10 | 200 | 2 |  
| 20 | 100 | 1 |  
| 20 | 100 | 2 |  
+-----+-----+-----+
```

DUPLICATE KEY 表模型

只指定排序列，相同的 KEY 行不会合并。

适用于数据无需提前聚合的分析业务：

- 原始数据分析
- 仅追加新数据的日志或时序数据分析

最佳实践

```
-- 例如 允许 KEY 重复仅追加新数据的日志数据分析  
CREATE TABLE session_data  
(  
    visitorid SMALLINT,  
    sessionid BIGINT,  
    visittime DATETIME,  
    city CHAR(20),  
    province CHAR(20),  
    ip VARCHAR(32),  
    browser CHAR(20),  
    url VARCHAR(1024)  
)  
DUPLICATE KEY(visitorid, sessionid) -- 只用于指定排序列，相同的 KEY 行不会合并  
DISTRIBUTED BY HASH(sessionid, visitorid) BUCKETS 10;
```

02 AGGREGATE KEY 表模型

Insert Data

Key		Value
ID	City	PV
1	100	10
2	100	20

Insert

Original Data

Key		Value
ID	City	PV
1	100	1
1	200	2
2	100	3
2	200	5

Divide by
Primary Keys

1	100	1	Old
1	100	1	New
1	200	2	Old
2	100	3	Old
2	100	3	New
2	200	5	Old

Aggregate Key Model

1	100	1+10
1	200	2
2	100	3+20
2	200	5

→

Key		Value
ID	City	PV
1	100	11
1	200	2
2	100	23
2	200	5

```
CREATE TABLE tbl_aggregate(  
    siteid INT,  
    city SMALLINT,  
    pv BIGINT SUM DEFAULT '0'  
)  
  
AGGREGATE KEY (siteid, city)  
DISTRIBUTED BY HASH(siteid) BUCKETS 10;  
  
INSERT INTO tbl_aggregate VALUES  
(10, 100, 1), (10, 100, 1),  
(10, 200, 2), (10, 200, 2),  
(20, 100, 1), (20, 100, 2);  
  
SELECT * FROM tbl_aggregate;
```

siteid	city	pv
10	100	2
10	200	4
20	100	3

AGGREGATE KEY 表模型

AGGREGATE KEY 相同时，新旧记录进行聚合，目前支持的聚合方式：

- 1. SUM：求和，多行的 Value 进行累加。
- 2. REPLACE：替代，下一批数据中的 Value 会替换之前导入过的行中的 Value。
- 3. MAX：保留最大值。
- 4. MIN：保留最小值。
- 5. REPLACE_IF_NOT_NULL：非空值替换。和 REPLACE 的区别在于对于 null 值，不做替换。
- 6. HLL_UNION：HLL 类型的列的聚合方式，通过 HyperLogLog 算法聚合。
- 7. BITMAP_UNION：BIMTAP 类型的列的聚合方式，进行位图的并集聚合。

适合报表和多维分析业务：

- 网站流量分析
- 数据报表多维分析

最佳实践

— 例如 网站流量分析

```
CREATE TABLE site_visit  
(  
    siteid INT,  
    city SMALLINT,
```

```
username    VARCHAR(32),
pv BIGINT    SUM DEFAULT '0' -- PV 浏览量计算
)
AGGREGATE KEY(siteid, city, username) -- 相同的 KEY 行会合并，非 KEY 列会根据指定的聚合函数进行聚合
DISTRIBUTED BY HASH(siteid) BUCKETS 10;
```

03 UNIQUE KEY 表模型

UNIQUE KEY 相同时，新记录覆盖旧记录。在 1.2 版本之前，UNIQUE KEY 实现上和 AGGREGATE KEY 的 REPLACE 聚合方法一样，二者本质上相同，自 1.2 版本我们给 UNIQUE KEY 引入了 merge on write 实现，该实现有更好的聚合查询性能。

适用于有更新需求的分析业务：

- 订单去重分析
- 实时增删改同步

最佳实践

```
-- 例如 订单去重分析
CREATE TABLE sales_order
(
    orderid    BIGINT,
    status     TINYINT,
    username   VARCHAR(32),
    amount     BIGINT DEFAULT '0'
)
UNIQUE KEY(orderid) -- 相同的 KEY 行会合并
DISTRIBUTED BY HASH(orderid) BUCKETS 10;
```

2 索引

索引用于帮助快速过滤或查找数据。目前主要支持两类索引：

1. 内建自动创建的智能索引，包括前缀索引和 ZoneMap 索引。
2. 用户手动创建的二级索引，包括倒排索引、bloomfilter 索引、ngram bloomfilter 索引 和 bitmap 索引。

01 前缀索引

在 Aggregate、Unique 和 Duplicate 三种数据模型中。底层的数据存储，是按照各自建表语句中，AGGREGATE KEY、UNIQUE KEY 和 DUPLICATE KEY 中指定的列进行排序存储的。而前缀索引，即在排序的基础上，实现的一种根据给定前缀列，快速查询数据的索引方式。

前缀索引是稀疏索引，不能精确定位到 Key 所在的行，只能粗粒度地定位出 Key 可能存在的范围，然后使用二分查找算法精确地定位 Key 的位置。

****推荐规约****

1. 建表时，正确的选择列顺序，能够极大地提高查询效率。

因为建表时已经指定了列顺序，所以一个表只有一种前缀索引。这对于使用其他不能命中前缀索引的列作为条件进行的查询来说，效率上可能无法满足需求，这种情况，我们可以通过创建物化视图来人为的调整列顺序。

2. 前缀索引的第一个字段一定是最常查询的字段，并且需要是高基数字段：

- a. 分桶字段注意事项：这个一般是数据分布比较均衡的，也是经常使用的字段，最好是高基数字段
- b. Int (4) + Int (4) + varchar(50)，前缀索引长度只有 28
- c. Int (4) + varchar(50) + Int (4)，前缀索引长度只有 24
- d. varchar(10) + varchar(50) ，前缀索引长度只有 30
- e. 前缀索引 (36 位)：第一个字段查询性能最好，前缀索引碰见 varchar 类型的字段，会自动截断前 20 个字符
- f. 最常用的查询字段如果能放到前缀索引里尽可能放到前前缀索引里，如果不能，可以放到分桶字段里

3. 前缀索引中的字段长度尽可能明确，因为 Doris 只有前 36 个字节能走前缀索引。

4. 如果某个范围数据在分区分桶和前缀索引中都不好设计，可以考虑引入倒排索引加速。

02 ZoneMap 索引

ZoneMap 索引是在列存格式上，对每一列自动维护的索引信息，包括 Min/Max，null 值个数等等。在数据查询时，会根据范围条件过滤的字段按照 ZoneMap 统计信息选取扫描的数据范围。

例如对 age 字段进行过滤，查询语句如下：

```
SELECT * FROM table WHERE age > 0 and age < 51;
```

在没有命中 Short Key Index 的情况下，会根据条件语句中 age 的查询条件，利用 ZoneMap 索引找到应该扫描的数据 ordinary 范围，减少要扫描的 page 数量。

03 倒排索引

从 2.0.0 版本开始，Doris 支持倒排索引，可以用来进行文本类型的全文检索、普通数值日期类型的等值范围查询，快速从海量数据中过滤出满足条件的行。

最佳实践

-- 创建示例：可以表创建时指定或者创建后新增，如下创建表时指定

```
CREATE TABLE table_name
(
    columns_definition,
    INDEX idx_name1(column_name1) USING INVERTED [PROPERTIES("parser" = "english|unicode|chinese")] [COMMENT 'your comment']
    INDEX idx_name2(column_name2) USING INVERTED [PROPERTIES("parser" = "english|unicode|chinese")] [COMMENT
```



```
'your comment']
  INDEX idx_name3(column_name3) USING INVERTED [PROPERTIES("parser" = "chinese", "parser_mode" =
"fine_grained|coarse_grained")] [COMMENT 'your comment']
  INDEX idx_name4(column_name4) USING INVERTED [PROPERTIES("parser" = "english|unicode|chinese",
"support_phrase" = "true|false")] [COMMENT 'your comment']
  INDEX idx_name5(column_name4) USING INVERTED [PROPERTIES("char_filter_type" = "char_replace",
"char_filter_pattern" = ". _"), "char_filter_replacement" = " "] [COMMENT 'your comment']
  INDEX idx_name5(column_name4) USING INVERTED [PROPERTIES("char_filter_type" = "char_replace",
"char_filter_pattern" = ". _")] [COMMENT 'your comment']
)
table_properties;
```

-- 使用示例：全文检索关键词匹配，通过 MATCH_ANY MATCH_ALL 完成
SELECT * FROM table_name WHERE column_name MATCH_ANY | MATCH_ALL 'keyword1 ...';

****推荐规约****

1. 如果某个范围数据在分区分桶和前缀索引中都不好设计，可以考虑引入倒排索引加速。

****强制规约****

1. 倒排索引在不同数据模型中有不同的使用限制：
 - a. Aggregate KEY 表模型：只能为 Key 列建立倒排索引。
 - b. Unique KEY 表模型：需要开启 merge on write 特性，开启后，可以为任意列建立倒排索引。
 - c. Duplicate KEY 表模型：可以为任意列建立倒排索引。

04 BloomFilter 索引

Doris 支持用户对取值区分度比较大的字段添加 BloomFilter 索引，适合在基数较高的列上进行等值查询的场景。

最佳实践

```
-- 创建示例：通过在建表语句的 PROPERTIES 里加上"bloom_filter_columns"="k1,k2,k3"
-- 例如下面我们对表里的 saler_id,category_id 创建了 BloomFilter 索引。
CREATE TABLE IF NOT EXISTS sale_detail_bloom (
  sale_date date NOT NULL COMMENT "销售时间",
  customer_id int NOT NULL COMMENT "客户编号",
  saler_id int NOT NULL COMMENT "销售员",
  sku_id int NOT NULL COMMENT "商品编号",
  category_id int NOT NULL COMMENT "商品分类",
  sale_count int NOT NULL COMMENT "销售数量",
  sale_price DECIMAL(12,2) NOT NULL COMMENT "单价",
  sale_amt DECIMAL(20,2) COMMENT "销售总金额"
)
Duplicate KEY(sale_date, customer_id,saler_id,sku_id,category_id)
DISTRIBUTED BY HASH(saler_id) BUCKETS 10
PROPERTIES (
  "bloom_filter_columns"="saler_id,category_id"
);
```

****强制规约****

1. 不支持对 Tinyint、Float、Double 类型的列建 BloomFilter 索引。
2. BloomFilter 索引只对 in 和 = 过滤查询有加速效果。
3. BloomFilter 索引必须在查询条件是 in 或者 =，并且是高基数（5000 以上）列上构建。
 - a. 首先 BloomFilter 适用于非前缀过滤
 - b. 查询会根据该列高频过滤，而且查询条件大多是 in 和 = 过滤
 - c. 不同于 Bitmap, BloomFilter 适用于高基数列。比如 UserID。因为如果创建在低基数的列上，比如“性别”列，则每个 Block 几乎都会包含所有取值，导致 BloomFilter 索引失去意义
 - d. 数据基数在一半左右
 - e. 类似身份证号这种基数特别高并且查询是等值（=）查询，使用 BloomFilter 索引能极大加速

05 NGram BloomFilter 索引

从 2.0.0 版本开始，Doris 为了提升**LIKE**的查询性能，增加了 NGram BloomFilter 索引。

最佳实践

```
-- 创建示例：表创建时指定
CREATE TABLE `nb_table` (
  `siteid` int(11) NULL DEFAULT "10" COMMENT "",
  `citycode` smallint(6) NULL COMMENT "",
  `username` varchar(32) NULL DEFAULT "" COMMENT "",
  INDEX idx_ngrambf (`username`) USING NGRAM_BF PROPERTIES("gram_size"="3", "bf_size"="256") COMMENT
'username ngram_bf index'
) ENGINE=OLAP
AGGREGATE KEY(`siteid`, `citycode`, `username`) COMMENT "OLAP"
DISTRIBUTED BY HASH(`siteid`) BUCKETS 10;
```

-- PROPERTIES("gram_size"="3", "bf_size"="256"), 分别表示 gram 的个数和 bloom filter 的字节数。
-- gram 的个数跟实际查询场景相关，通常设置为大部分查询字符串的长度，bloom filter 字节数，可以通过测试得出，通常越大过滤效果越好，可以从 256 开始进行验证测试看看效果。当然字节数越大也会带来索引存储、内存 cost 上升。
-- 如果数据基数比较高，字节数可以不用设置过大，如果基数不是很高，可以通过增加字节数来提升过滤效果。

****强制规约****

1. NGram BloomFilter 只支持字符串列
2. NGram BloomFilter 索引和 BloomFilter 索引为互斥关系，即同一个列只能设置两者中的一个
3. NGram 大小和 BloomFilter 的字节数，可以根据实际情况调优，如果 NGram 比较小，可以适当增加 BloomFilter 大小
4. 亿级别以上数据，如果有模糊匹配，使用倒排索引或者是 NGram Bloomfilter

6 Bitmap 索引

为了加速数据查询，Doris 支持用户为某些字段添加 Bitmap 索引，适合在基数较低的列上进行等值查询或范围查询的场景。

最佳实践

```
-- 创建示例：在 bitmap_table 上为 siteid 创建 Bitmap 索引
CREATE INDEX [IF NOT EXISTS] bitmap_index_name ON
bitmap_table (siteid)
USING BITMAP COMMENT 'bitmap_siteid';
```

****强制规约****

1. Bitmap 索引仅在单列上创建。
2. Bitmap 索引能够应用在 Duplicate、Uniq 数据模型的所有列和 Aggregate 模型的 key 列上。
3. Bitmap 索引支持的数据类型如下：
 - TINYINT
 - SMALLINT
 - INT
 - BIGINT
 - CHAR
 - VARCHAR
 - DATE
 - DATETIME
 - LARGEINT
 - DECIMAL
 - BOOL
4. Bitmap 索引仅在 Segment V2 下生效。当创建 Index 时，表的存储格式将默认转换为 V2 格式。
5. Bitmap 索引必须在一定基数范围内构建，太高或者太低的基数都不合适
 - a. 适用于低基数的列上，建议在 100 到 100,000 之间，如：职业、地市等。重复度过高则对比其他类型索引没有明显优势；重复度过低，则空间效率和性能会大大降低。特定类型的查询例如 COUNT, OR, AND 等逻辑操作因为只需要进行位运算
 - b. 该索引更多的适合正交查询

3 字段类型

Doris 支持多种字段类型，例如精确去重 BITMAP、模糊去重 HLL、半结构化 ARRAY/MAP/JSON 和常见的数字、字符串和时间类型等。

****推荐规约****

1. VARCHAR

- 变长字符串，长度范围为：1-65533 字节长度，以 UTF-8 编码存储的，因此通常英文字符占 1 个字节，中文字符占 3 个字节。
- 这里存在一个误区，即 `varchar(255)` 和 `varchar(65533)` 的性能问题，这二者如果存的数据是一样的，性能也是一样的，建表时如果不确定这个字段最大有多长，建议直接使用 65533 即可，防止由于字符串过长导致的导入问题。

2. STRING

- 变长字符串，默认支持 1048576 字节（1MB），可调大到 2147483643 字节（2G），以 UTF-8 编码存储的，因此通常英文字符占 1 个字节，中文字符占 3 个字节。
- 只能用在 Value 列，不能用在 Key 列和分区分桶列。
- 适用于一些比较大的文本存储，一般如果没有这种需求的话，建议使用 VARCHAR，STRING 列无法用在 Key 列和分桶列，局限性比较大。

3. 数值型字段：按照精度选择对应的数据类型即可，没有过于特殊的注意。

4. 时间字段：这里需要注意的是，如果有高精度（毫秒值时间戳）需求，需要指明使用 `datetime(6)`，否则默认是不支持毫秒值时间戳的。

5. 建议使用 JSON 数据类型代替字符串类型存放 JSON 数据的使用方式。

4 数据表创建

Data	Site	City	User	PV
0322	1	100	Jack	30
0322	1	200	Mary	28
0322	2	100	Tom	76
0322	3	200	Peter	28
0323	1	100	Alex	12
0323	2	200	Dylan	66
0323	2	200	Justin	66
0323	3	300	Daniel	19
0324	1	100	Alex	28
0324	2	100	Tom	65
0324	3	300	Daniel	23
0324	3	200	May	86

Level 1 – Partition

P20200323				
Data	Site	City	User	PV
0322	1	100	Jack	30
0322	1	200	Mary	28
0322	2	100	Tom	76
0322	3	200	Peter	28

→

P20200324				
Data	Site	City	User	PV
0323	1	100	Alex	12
0323	2	200	Dylan	66
0323	2	200	Justin	66
0323	3	300	Daniel	19

→

P20200325				
Data	Site	City	User	PV
0324	1	100	Alex	28
0324	2	100	Tom	65
0324	3	300	Daniel	23
0324	3	200	May	86

Level 2 – Bucket

0323	1	100	Alex	12	Bucket_1
0323	2	200	Dylan	66	Bucket_2
0323	2	200	Justin	66	
0323	3	300	Daniel	19	Bucket_3

→

0324	1	100	Alex	28	Bucket_1
0324	2	100	Tom	65	Bucket_2
0324	3	300	Daniel	23	
0324	3	200	Daniel	86	Bucket_3

→

0322	1	100	Jack	30	Bucket_1
0322	1	200	May	28	Bucket_2
0322	2	100	Tom	76	
0322	3	200	Peter	28	Bucket_3

Creat Table

```
CREATE TABLE demo.test_tbl(  
    date_id      DATE,  
    site_id      INT          DEFAULT 10,  
    city_code    SMALLINT,  
    user_name    VARCHAR(32)  DEFAULT "",  
    pv           BIGINT       DEFAULT 0  
)  
DUPLICATE KEY(date_id, site_id, city_code)  
PARTITION BY RANGE(date_id)(  
    PARTITION p20200321 VALUES LESS THAN("2020-03-22"),  
    PARTITION p20200322 VALUES LESS THAN("2020-03-23"),  
    PARTITION p20200323 VALUES LESS THAN("2020-03-24"),  
    PARTITION p20200324 VALUES LESS THAN("2020-03-25")  
)  
DISTRIBUTED BY HASH(site_id) BUCKETS 10
```

数据表创建

建表时除了要注意数据表模型、索引和字段类型的选择还需要注意分区分桶的设置。

最佳实践

```
-- 以 Unique 模型的 Merge-on-Write 表为例
-- Unique 模型的写时合并实现，与聚合模型就是完全不同的两种模型了，查询性能更接近于 duplicate 模型，
-- 在有主键约束需求的场景上相比聚合模型有较大的查询性能优势，尤其是在聚合查询以及需要用索引过滤大量数据的查询中。

-- 非分区表
CREATE TABLE IF NOT EXISTS tbl_unique_merge_on_write
(
    `user_id` LARGEINT NOT NULL COMMENT "用户id",
    `username` VARCHAR(50) NOT NULL COMMENT "用户昵称",
    `register_time` DATE COMMENT "用户注册时间",
    `city` VARCHAR(20) COMMENT "用户所在城市",
    `age` SMALLINT COMMENT "用户年龄",
    `sex` TINYINT COMMENT "用户性别",
    `phone` LARGEINT COMMENT "用户电话",
    `address` VARCHAR(500) COMMENT "用户地址"
)
UNIQUE KEY(`user_id`, `username`)
-- 3-5G 的数据量
DISTRIBUTED BY HASH(`user_id`) BUCKETS 10
PROPERTIES (
    -- 在 1.2.0 版本中，作为一个新的 feature，写时合并默认关闭，用户可以通过添加下面的 property 来开启
    "enable_unique_key_merge_on_write" = "true"
);

-- 分区表
CREATE TABLE IF NOT EXISTS tbl_unique_merge_on_write_p
(
    `user_id` LARGEINT NOT NULL COMMENT "用户id",
    `username` VARCHAR(50) NOT NULL COMMENT "用户昵称",
    `register_time` DATE COMMENT "用户注册时间",
    `city` VARCHAR(20) COMMENT "用户所在城市",
    `age` SMALLINT COMMENT "用户年龄",
    `sex` TINYINT COMMENT "用户性别",
    `phone` LARGEINT COMMENT "用户电话",
    `address` VARCHAR(500) COMMENT "用户地址"
)
UNIQUE KEY(`user_id`, `username`, `register_time`)
PARTITION BY RANGE(`register_time`) (
    PARTITION p00010101_1899 VALUES [('0001-01-01'), ('1900-01-01')),
    PARTITION p19000101 VALUES [('1900-01-01'), ('1900-01-02')),
    PARTITION p19000102 VALUES [('1900-01-02'), ('1900-01-03')),
    PARTITION p19000103 VALUES [('1900-01-03'), ('1900-01-04')),
    PARTITION p19000104_1999 VALUES [('1900-01-04'), ('2000-01-01')),
    FROM ("2000-01-01") TO ("2022-01-01") INTERVAL 1 YEAR,
    PARTITION p30001231 VALUES [('3000-12-31'), ('3001-01-01')),
    PARTITION p99991231 VALUES [('9999-12-31'), (MAXVALUE))
)
-- 默认 3-5G 的数据量
DISTRIBUTED BY HASH(`user_id`) BUCKETS 10
PROPERTIES (
    -- 在 1.2.0 版本中，作为一个新的 feature，写时合并默认关闭，用户可以通过添加下面的 property 来开启
    "enable_unique_key_merge_on_write" = "true",
    -- 动态分区调度的单位。可指定为 HOUR、DAY、WEEK、MONTH、YEAR。分别表示按小时、按天、按星期、按月、按年进行分区创建或删除。
    "dynamic_partition.time_unit" = "MONTH",
    -- 动态分区的起始偏移，为负数。根据 time_unit 属性的不同，以当天（星期/月）为基准，分区范围在此偏移之前的分区将会被删除（TTL）。
    如果不填写，则默认为 -2147483648，即不删除历史分区。
    "dynamic_partition.start" = "-3000",
    -- 动态分区的结束偏移，为正数。根据 time_unit 属性的不同，以当天（星期/月）为基准，提前创建对应范围的分区。
    "dynamic_partition.end" = "10",
    -- 动态创建的分区名前缀（可选）。
    "dynamic_partition.prefix" = "p",
    -- 动态创建的分区所对应的分桶数量。
```

```

"dynamic_partition.buckets" = "10",
"dynamic_partition.enable" = "true",
-- 动态创建的分区所对应的副本数量，如果不填写，则默认为该表创建时指定的副本数量 3。
"dynamic_partition.replication_num" = "3",
"replication_num" = "3"
);

-- 分区创建查看
-- 实际创建的分区数需要结合 dynamic_partition.start、end 以及 PARTITION BY RANGE 的设置共同决定
show partitions from tbl_unique_merge_on_write_p;

```

****强制规约****

1. 数据库字符集指定 UTF-8，并且只支持 UTF-8。
2. 表的副本数必须为 3（未指定副本数时，默认为 3）。
3. 单个 Tablet（**Tablet 数 = 分区数 * 桶数 * 副本数**）的数据量理论上没有上下界，除小表（百兆维表）外需确保在 **1G - 10G** 的范围内：
 - a. 如果单个 Tablet 数据量过小，则数据的聚合效果不佳，且元数据管理压力大。
 - b. 如果数据量过大，则不利于副本的迁移、补齐，且会增加 Schema Change 或者 物化 操作失败重试的代价（这些操作失败重试的粒度是 Tablet）。
4. 5 亿以上的数据必须设置**分区分桶策略**：
 - a. **bucket 设置建议**：
 - i. 大表的单个 Tablet 存储数据大小在 1G-10G 区间，可防止过多的小文件产生。
 - ii. 百兆左右的维表 Tablet 数量控制在 3-5 个，保证一定的并发数也不会产生过多的小文件。
 - b. 没有办法分区的，数据又较快增长的，没办法按照时间动态分区，可以适当放大一下你的 Bucket 数量，按照你的数据保存周期（180 天）数据总量，来估算你的 Bucket 数量应该是多少，建议还是单个 Bucket 大小在 1-10G。
 - c. 对分桶字段进行加盐处理，业务上查询的时候也是要同样的加盐策略，这样能利用到分桶数据剪裁能力。
 - d. 数据随机分桶：
 - i. 如果 OLAP 表没有更新类型的字段，将表的数据分桶模式设置为 RANDOM，则可以避免严重的数据倾斜（数据在导入表对应的分区的时候，单次导入作业每个 Batch 的数据将随机选择一个 Tablet 进行写入）。
 - ii. 当表的分桶模式被设置为 RANDOM 时，因为没有分桶列，无法根据分桶列的值仅对几个分桶查询，对表进行查询的时候将对命中分区的全部分桶同时扫描，该设置适合对表数据整体的聚合查询分析而不适合高并发的点查询。
 - iii. 如果 OLAP 表的是 Random Distribution 的数据分布，那么在数据导入的时候可以设置单分片导入模式（将 load_to_single_tablet 设置为 true），那么在大数据量的导入的时候，一个任务在将数据写入对应的分区时将只写入一个分片，这样将能提高数据

导入的并发度和吞吐量，减少数据导入和 Compaction 导致的写放大问题，保障集群的稳定性。

e. 维度表：缓慢增长的，可以使用单分区，在分桶策略上使用常用查询条件（这个字段数据分布相对均衡）分桶。

f. 事实表：推荐使用date/datetime类型作为分区字段，一般每日一个分区即可；分桶策略上使用常用查询条件（这个字段数据分布相对均衡）作为分桶。

5. 对于有大量历史分区数据，但是历史数据比较少，或者不均衡，或者查询概率的情况，使用如下方式将数据放在特殊分区。

对于历史数据，如果数据量比较小我们可以创建历史分区（比如年分区，月分区），将所有历史数据放到对应分区里创建历史分区方式例如：FROM ("2000-01-01") TO ("2022-01-01") INTERVAL 1 YEAR，具体参考：

```
(
  PARTITION p00010101_1899 VALUES [('0001-01-01'), ('1900-01-01')),
  PARTITION p19000101 VALUES [('1900-01-01'), ('1900-01-02')),
  ...
  PARTITION p19000104_1999 VALUES [('1900-01-04'), ('2000-01-01')),
  FROM ("2000-01-01") TO ("2022-01-01") INTERVAL 1 YEAR,
  PARTITION p30001231 VALUES [('3000-12-31'), ('3001-01-01')),
  PARTITION p99991231 VALUES [('9999-12-31'), (MAXVALUE))
)
```

导入概览

支持的数据源

Doris 提供多种数据导入方案，可以针对不同的数据源进行选择不同的数据导入方式。

按场景划分

数据源	导入方式
对象存储 (s3) ,HDFS	使用 Broker 导入数据
本地文件	Stream Load , MySQL Load
Kafka	订阅 Kafka 数据
Mysql、PostgreSQL、Oracle、SQLServer	通过外部表同步数据
通过 JDBC 导入	使用 JDBC 同步数据
导入 JSON 格式数据	JSON 格式数据导入
AutoMQ	订阅 AutoMQ 数据

按导入方式划分

导入方式名称	使用方式
Broker Load	通过 Broker 导入外部存储数据
Stream Load	流式导入数据 (本地文件及内存数据)
Routine Load	导入 Kafka 数据
Insert Into	外部表通过 INSERT 方式导入数据
S3 Load	S3 协议的对象存储数据导入
MySQL Load	MySQL 客户端导入本地数据

支持的数据格式

不同的导入方式支持的数据格式略有不同。

导入方式	支持的格式
Broker Load	parquet、orc、csv、gzip
Stream Load	csv、json、parquet、orc
Routine Load	csv、json
MySQL Load	csv

导入说明

Apache Doris 的数据导入实现有以下共性特征，这里分别介绍，以帮助大家更好的使用数据导入功能

导入的原子性保证

Doris 的每一个导入作业，不论是使用 Broker Load 进行批量导入，还是使用 INSERT 语句进行单条导入，都是一个完整的事务操作。导入事务可以保证一批次内的数据原子生效，不会出现部分数据写入的情况。

同时，一个导入作业都会有一个 Label。这个 Label 是在一个数据库（Database）下唯一的，用于唯一标识一个导入作业。Label 可以由用户指定，部分导入功能也会由系统自动生成。

Label 是用于保证对应的导入作业，仅能成功导入一次。一个被成功导入的 Label，再次使用时，会被拒绝并报错 Label already used。通过这个机制，可以在 Doris 侧做到 At-Most-Once 语义。如果结合上游系统的 At-Least-Once 语义，则可以实现导入数据的 Exactly-Once 语义。

关于原子性保证的最佳实践，可以参阅 导入事务和原子性。

同步及异步导入

导入方式分为同步和异步。对于同步导入方式，返回结果即表示导入成功还是失败。而对于异步导入方式，返回成功仅代表作业提交成功，不代表数据导入成功，需要使用对应的命令查看导入作业的运行状态。

导入 Array 类型

例如以下导入，需要先将列 b14 和列 a13 先 cast 成 array<string>类型，再运用 array_union 函数。

```
LOAD LABEL label_03_14_49_34_898986_19090452100 (
  DATA INFILE("hdfs://test.hdfs.com:9000/user/test/data/sys/load/array_test.data")
  INTO TABLE `test_array_table`
  COLUMNS TERMINATED BY "|" (`k1`, `a1`, `a2`, `a3`, `a4`, `a5`, `a6`, `a7`, `a8`, `a9`, `a10`, `a11`, `a12`,
`a13`, `b14`)
  SET(a14=array_union(cast(b14 as array<string>), cast(a13 as array<string>))) WHERE size(a2) > 270)
  WITH BROKER "hdfs" ("username"="test_array", "password"="")
  PROPERTIES( "max_filter_ratio"="0.8" );
```

使用的执行引擎

导入时默认关闭 Pipeline 引擎，通过以下两个变量开启：

1. [FE CONFIG](#) 中的 enable_pipeline_load，开启后 Streamload 等导入任务将尝试使用 Pipeline 引擎执行。
2. Session Variable 中的 enable_nereids_dml_with_pipeline，开启后 insert into 将尝试使用 Pipeline 引擎执行。

以上变量开启后，具体是否使用 Pipeline 引擎，仍然取决于 Session Variables enable_pipeline_engine。如果该值为 false，即使以上变量被设置为 true，导入依然不会使用 Pipeline 引擎执行。

Stream Load

Stream Load 支持通过 HTTP 协议将本地文件或数据流导入到 Doris 中。Stream Load 是一个同步导入方式，执行导入后返回导入结果，可以通过请求的返回判断导入是否成功。一般来说，可以使用 Stream Load 导入 10GB 以下的文件，如果文件过大，建议将文件进行切分后使用 Stream Load 进行导入。Stream Load 可以保证一批导入任务的原子性，要么全部导入成功，要么全部导入失败。

提示

相比于直接使用 curl 的单并发导入，更推荐使用专用导入工具 Doris Streamloader 该工具是一款用于将数据导入 Doris 数据库的专用客户端工具，可以提供**多并发导入**的功能，降低大数据量导入的耗时。拥有以下功能：

- 并发导入，实现 Stream Load 的多并发导入。可以通过 workers 值设置并发数。
- 多文件导入，一次导入可以同时导入多个文件及目录，支持设置通配符以及会自动递归获取文件夹下的所有文件。
- 断点续传，在导入过程中可能出现部分失败的情况，支持在失败点处进行继续传输。
- 自动重传，在导入出现失败的情况后，无需手动重传，工具会自动重传默认的次数，如果仍然不成功，打印出手动重传的命令。

点击 [Doris Streamloader 文档](#) 了解使用方法与实践详情。

使用场景

支持格式

Stream Load 支持导入 CSV、JSON、Parquet 与 ORC 格式的数据。

使用限制


在导入 CSV 文件时，需要明确区分空值（null）与空字符串：

- 空值（null）需要用 \N 表示，a,\N,b 数据表示中间列是一个空值（null）
- 空字符串直接将数据置空，a ,b 数据表示中间列是一个空字符串

基本原理

在使用 Stream Load 时，需要通过 HTTP 协议发起导入作业给 FE 节点，FE 会以轮询方式，重定向（redirect）请求给一个 BE 节点以达到负载均衡的效果。也可以直接发送 HTTP 请求作业给指定的 BE 节点。在 Stream Load 中，Doris 会选定一个节点做为 Coordinator 节点。Coordinator 节点负责接受数据并分发数据到其他节点上。

下图展示了 Stream Load 的主要流程：



Stream Load 基本原理

1. Client 向 FE 提交 Stream Load 导入作业请求
2. FE 会随机选择一台 BE 作为 Coordinator 节点，负责导入作业调度，然后返回给 Client 一个 HTTP 重定向
3. Client 连接 Coordinator BE 节点，提交导入请求
4. Coordinator BE 会分发数据给相应 BE 节点，导入完成后会返回导入结果给 Client
5. Client 也可以直接通过指定 BE 节点作为 Coordinator，直接分发导入作业

快速上手

Stream Load 通过 HTTP 协议提交和传输。下例以 curl 工具为例，演示通过 Stream Load 提交导入作业。

详细语法可以参见 [STREAM LOAD](#)

前置检查

Stream Load 需要对目标表的 INSERT 权限。如果没有 INSERT 权限，可以通过 [GRANT](#) 命令给用户授权。

创建导入作业

导入 CSV 数据

1. 创建导入数据

创建 csv 文件 streamload_example.csv 文件。具体内容如下

```
1,Emily,25
2,Benjamin,35
3,Olivia,28
4,Alexander,60
```

```
5,Ava,17
6,William,69
7,Sophia,32
8,James,64
9,Emma,37
10,Liam,64
```

2. 创建导入 Doris 表

在 Doris 中创建被导入的表，具体语法如下

```
CREATE TABLE testdb.test_streamload(
  user_id      BIGINT      NOT NULL COMMENT "用户 ID",
  name         VARCHAR(20) COMMENT "用户姓名",
  age          INT          COMMENT "用户年龄"
)
DUPLICATE KEY(user_id)
DISTRIBUTED BY HASH(user_id) BUCKETS 10;
```

3. 启用导入作业

通过 curl 命令可以提交 Stream Load 导入作业。

```
curl --location-trusted -u <doris_user>:<doris_password> \
-H "Expect:100-continue" \
-H "column_separator:," \
-H "columns:user_id,name,age" \
-T streamload_example.csv \
-XPUT http://<fe_ip>:<fe_http_port>/api/testdb/test_streamload/_stream_load
```

Stream Load 是一种同步导入方式，导入结果会直接返回给用户。

```
{
  "TxnId": 3,
  "Label": "123",
  "Comment": "",
  "TwoPhaseCommit": "false",
  "Status": "Success",
  "Message": "OK",
  "NumberTotalRows": 10,
  "NumberLoadedRows": 10,
  "NumberFilteredRows": 0,
  "NumberUnselectedRows": 0,
  "LoadBytes": 118,
  "LoadTimeMs": 173,
  "BeginTxnTimeMs": 1,
  "StreamLoadPutTimeMs": 70,
  "ReadDataTimeMs": 2,
  "WriteDataTimeMs": 48,
  "CommitAndPublishTimeMs": 52
}
```

4. 查看导入数据

```
mysql> select count(*) from testdb.test_streamload;
+-----+
| count(*) |
+-----+
```

```
|      10 |
+-----+
```

导入 JSON 数据

1. 创建导入数据

创建 JSON 文件 streamload_example.json。具体内容如下

```
[
  {"userid":1,"username":"Emily","userage":25},
  {"userid":2,"username":"Benjamin","userage":35},
  {"userid":3,"username":"Olivia","userage":28},
  {"userid":4,"username":"Alexander","userage":60},
  {"userid":5,"username":"Ava","userage":17},
  {"userid":6,"username":"William","userage":69},
  {"userid":7,"username":"Sophia","userage":32},
  {"userid":8,"username":"James","userage":64},
  {"userid":9,"username":"Emma","userage":37},
  {"userid":10,"username":"Liam","userage":64}
]
```

2. 创建导入 Doris 表

在 Doris 中创建被导入的表，具体语法如下

```
CREATE TABLE testdb.test_streamload(
  user_id          BIGINT      NOT NULL COMMENT "用户 ID",
  name             VARCHAR(20) COMMENT "用户姓名",
  age             INT          COMMENT "用户年龄"
)
DUPLICATE KEY(user_id)
DISTRIBUTED BY HASH(user_id) BUCKETS 10;
```

3. 启用导入作业

通过 curl 命令可以提交 Stream Load 导入作业。

```
curl --location-trusted -u <doris_user>:<doris_password> \
-H "label:124" \
-H "Expect:100-continue" \
-H "format:json" -H "strip_outer_array:true" \
-H "jsonpaths:[\"$.userid\", \"$.username\", \"$.userage\"]" \
-H "columns:user_id,name,age" \
-T streamload_example.json \
-XPUT http://<fe_ip>:<fe_http_port>/api/testdb/test_streamload/_stream_load
```

:::info 备注 若 JSON 文件内容不是 JSON Array，而是每行一个 JSON 对象，添加 Header -H "strip_outer_array:false" -H "read_json_by_line:true"。:::

Stream Load 是一种同步导入方式，导入结果会直接返回给用户。

```
{
  "TxnId": 7,
  "Label": "125",
  "Comment": "",
```

```

    "TwoPhaseCommit": "false",
    "Status": "Success",
    "Message": "OK",
    "NumberTotalRows": 10,
    "NumberLoadedRows": 10,
    "NumberFilteredRows": 0,
    "NumberUnselectedRows": 0,
    "LoadBytes": 471,
    "LoadTimeMs": 52,
    "BeginTxnTimeMs": 0,
    "StreamLoadPutTimeMs": 11,
    "ReadDataTimeMs": 0,
    "WriteDataTimeMs": 23,
    "CommitAndPublishTimeMs": 16
}

```

查看导入作业

默认情况下，Stream Load 是同步返回给 Client，所以系统模式是不记录 Stream Load 历史作业的。如果需要记录，则在 be.conf 中添加配置 `enable_stream_load_record=true`。具体配置可以参考 [BE 配置项](#)。

配置后，可以通过 `show stream load` 命令查看已完成的 Stream Load 任务。

```
mysql> show stream load from testdb;
```

Label	Db	Table	ClientIp	Status	Message	Url	TotalRows	LoadedRows	FilteredRows	UnselectedRows	LoadBytes	StartTime	FinishTime	User	Comment
12356	testdb	test_streamload	192.168.88.31	Success	OK	N/A	10	10	0	0	118	2023-11-29 08:53:00.594	2023-11-29 08:53:00.650	root	

1 row in set (0.00 sec)

取消导入作业

用户无法手动取消 Stream Load，Stream Load 在超时或者导入错误后会被系统自动取消。

参考手册

导入命令

Stream Load 导入语法如下：

```

curl --location-trusted -u <doris_user>:<doris_password> \
-H "Expect:100-continue" [-H "..."] \
-T <file_path> \
-XPUT http://fe_host:http_port/api/{db}/{table}/_stream_load

```

Stream Load 操作支持 HTTP 分块导入（HTTP chunked）与 HTTP 非分块导入方式。对于非分块导入方式，必须要有 Content-Length 来标示上传内容的长度，这样能保证数据的完整性。

导入配置参数

FE 配置

1. stream_load_default_timeout_second

- 默认值：259200 (s)
- 动态配置：是
- FE Master 独有配置：是

参数描述：Stream Load 默认的超时时间。导入任务的超时时间（以秒为单位），导入任务在设定的 timeout 时间内未完成则会被系统取消，变成 CANCELLED。如果导入的源文件无法在规定时间内完成导入，用户可以在 Stream Load 请求中设置单独的超时时间。或者调整 FE 的参数 stream_load_default_timeout_second 来设置全局的默认超时时间。

2. enable_pipeline_load

是否开启 Pipeline 引擎执行 Streamload 任务。详见[导入文档](#)。

BE 配置

1. streaming_load_max_mb

- 默认值：10240 (MB)
- 动态配置：是
- 参数描述：Stream load 的最大导入大小。如果用户的原始文件超过这个值，则需要调整 BE 的参数 streaming_load_max_mb。

2. Header 参数

可以通过 HTTP 的 Header 部分来传入导入参数。具体参数介绍如下：

标签	参数说明
label	用于指定 Doris 该次导入的标签，标签相同的数据无法多次导入。如果不指定 label，Doris 会自动生成一个标签。用户可以通过指定 label 的方式来避免一份数据重复导入的问题。Doris 默认保留三天内的导入作业标签，可以 label_keep_max_second 调整保留时长。例如，指定本次导入 label 为 123，需要指定命令 -H "label:123"。label 的使用，可以防止用户重复导入相同的数据。强烈推荐用户同一批次数据使用相同的 label。这样同一批次数据的重复请求只会被接受一次，保证了 At-Most-Once 当 label 对应的导入作业状态为 CANCELLED 时，该 label 可以再次被使用。
column_separator	用于指定导入文件中的列分隔符，默认为\t。如果是不可见字符，则需要加\x作为前缀，使用十六进制来表示分隔符。可以使用多个字符的组合作为列分隔符。例如，hive 文件的分隔符，需要指定命令 -H "column_separator:\x01"。
line_delimiter	用于指定导入文件中的换行符，默认为\n。可以使用多个字符的组合作为换行符。例如，指定换行符为\n，需要指定命令 -H "line_delimiter:\n"。
columns	用于指定导入文件中的列和 table 中的列的对应关系。如果源文件中的列正好对应表中的内容，那么是不需要指定这个字段的内容的。如果源文件与表 schema 不对应，那么需要这个字段进行一些数据转换。有两种形式 column：直接对应导入文件中的字段，直接使用字段名表示衍生列，语法为 column_name = expression 详细案例参考 导入过程中数据转换 。

标签	参数说明
where	用于抽取部分数据。用户如果有需要将不需要的数据过滤掉，那么可以通过设定这个选项来达到。例如，只导入大于 k1 列等于 20180601 的数据，那么可以在导入时候指定 -H "where: k1 = 20180601"。
max_filter_ratio	最大容忍可过滤（数据不规范等原因）的数据比例，默认零容忍。取值范围是 0~1。当导入的错误率超过该值，则导入失败。数据不规范不包括通过 where 条件过滤掉的行。例如，最大程度保证所有正确的数据都可以导入（容忍度 100%），需要指定命令 -H "max_filter_ratio:1"。
partitions	用于指定这次导入所涉及的 partition。如果用户能够确定数据对应的 partition，推荐指定该项。不满足这些分区的数据将被过滤掉。例如，指定导入到 p1, p2 分区，需要指定命令 -H "partitions: p1, p2"。
timeout	指定导入的超时时间。单位秒。默认是 600 秒。可设置范围为 1 秒 ~ 259200 秒。例如，指定导入超时时间为 1200s，需要指定命令 -H "timeout:1200"。
strict_mode	用户指定此次导入是否开启严格模式，默认为关闭。例如，指定开启严格模式，需要指定命令 -H "strict_mode:true"。
timezone	指定本次导入所使用的时区。默认为东八区。该参数会影响所有导入涉及的和时区有关的函数结果。例如，指定导入时区为 Africa/Abidjan，需要指定命令 -H "timezone:Africa/Abidjan"。
exec_mem_limit	导入内存限制。默认为 2GB。单位为字节。
format	指定导入数据格式，默认是 CSV 格式。目前支持以下格式：csvjsoncsv_with_names（支持 csv 文件行首过滤）csv_with_names_and_types（支持 csv 文件前两行过滤）parquetorc 例如，指定导入数据格式为 json，需要指定命令 -H "format:json"。
jsonpaths	导入 JSON 数据格式有两种方式：简单模式：没有指定 jsonpaths 为简单模式，这种模式要求 JSON 数据是对象类型匹配模式：用于 JSON 数据相对复杂，需要通过 jsonpaths 参数匹配对应的 value 在简单模式下，要求 JSON 中的 key 列与表中的列名是一一对应的，如 JSON 数据 {"k1":1, "k2":2, "k3":"hello"}，其中 k1、k2 及 k3 分别对应表中的列。
strip_outer_array	指定 strip_outer_array 为 true 时表示 JSON 数据以数组对象开始且将数组对象中进行展平，默认为 false。在 JSON 数据的最外层是 [] 表示的数组时，需要设置 strip_outer_array 为 true。如以下示例数据，在设置 strip_outer_array 为 true 后，导入 Doris 中生成两行数据 [{"k1" : 1, "v1" : 2},{ "k1" : 3, "v1" : 4}]
json_root	json_root 为合法的 jsonpath 字符串，用于指定 json document 的根节点，默认值为 ""。
merge_type	数数据的合并类型，一共支持三种类型 APPEND、DELETE、MERGE；APPEND 是默认值，表示这批数据全部需要追加到现有数据中；DELETE 表示删除与这批数据 key 相同的所有行 MERGE 语义 需要与 DELETE 条件联合使用，表示满足 DELETE 条件的数据按照 DELETE 语义处理其余的按照 APPEND 语义处理例如，指定合并模式为 MERGE，需要指定命令 -H "merge_type: MERGE" -H "delete: flag=1"。
delete	仅在 MERGE 下有意义，表示数据的删除条件
function_column.sequence_col	只适用于 UNIQUE KEYS 模型，相同 Key 列下，保证 Value 列按照 source_sequence 列进行 REPLACE。source_sequence 可以是数据源中的列，也可以是表结构中的一列。
fuzzy_parse	布尔类型，为 true 表示 JSON 将以第一行为 schema 进行解析。开启这个选项可以提高 json 导入效率，但是要求所有 json 对象的 key 的顺序和第一行一致，默认为 false，仅用于 JSON 格式
num_as_string	布尔类型，为 true 表示在解析 JSON 数据时会将数字类型转为字符串，确保不会出现精度丢失的情况下进行导入。
read_json_by_line	布尔类型，为 true 表示支持每行读取一个 json 对象，默认值为 false。

标签	参数说明
send_batch_parallelism	整型，用于设置发送批处理数据的并行度，如果并行度的值超过 BE 配置中的 max_send_batch_parallelism_per_job，那么作为协调点的 BE 将使用 max_send_batch_parallelism_per_job 的值。
hidden_columns	用于指定导入数据中包含的隐藏列，在 Header 中不包含 Columns 时生效，多个 hidden column 用逗号分割。系统会使用用户指定的数据导入数据。在下例中，导入数据中最后一列数据为 __DORIS_SEQUENCE_COL__。hidden_columns: __DORIS_DELETE_SIGN__, __DORIS_SEQUENCE_COL__
load_to_single_tablet	布尔类型，为 true 表示支持一个任务只导入数据到对应分区的一个 Tablet，默认值为 false。该参数只允许在对带有 random 分桶的 OLAP 表导数的时候设置。
compress_type	指定文件的压缩格式。目前只支持 CSV 文件的压缩。支持 gz, lzo, bz2, lz4, lzop, deflate 压缩格式。
trim_double_quotes	布尔类型，默认值为 false，为 true 时表示裁剪掉 CSV 文件每个字段最外层的双引号。
skip_lines	整数类型，默认值为 0，含义为跳过 CSV 文件的前几行。当设置 format 设置为 csv_with_names或csv_with_names_and_types时，该参数会失效。
comment	字符串类型，默认值为空。给任务增加额外的信息。
enclose	指定包围符。当 CSV 数据字段中含有行分隔符或列分隔符时，为防止意外截断，可指定单字节字符作为包围符起到保护作用。例如列分隔符为“;”，包围符为“'”，数据为“a;b;c”，则“b,c”会被解析为一个字段。注意：当 enclose 设置为“'”时，trim_double_quotes 一定要设置为 true。
escape	指定转义符。用于转义在字段中出现的与包围符相同的字符。例如数据为“a;b,'c'”，包围符为“'”，希望“b,'c’被作为一个字段解析，则需要指定单字节转义符，例如 \，将数据修改为 a,'b,\'c'。

导入返回值

Stream Load 是一种同步的导入方式，导入结果会通过创建导入的返回值直接给用户，如下所示：

```
{
  "TxnId": 1003,
  "Label": "b6f3bc78-0d2c-45d9-9e4c-faa0a0149bee",
  "Status": "Success",
  "ExistingJobStatus": "FINISHED", // optional
  "Message": "OK",
  "NumberTotalRows": 1000000,
  "NumberLoadedRows": 1000000,
  "NumberFilteredRows": 1,
  "NumberUnselectedRows": 0,
  "LoadBytes": 40888898,
  "LoadTimeMs": 2144,
  "BeginTxnTimeMs": 1,
  "StreamLoadPutTimeMs": 2,
  "ReadDataTimeMs": 325,
  "WriteDataTimeMs": 1933,
  "CommitAndPublishTimeMs": 106,
  "ErrorURL": "http://192.168.1.1:8042/api/_load_error_log?
file=__shard_0/error_log_insert_stmt_db18266d4d9b4ee5-abb00ddd64bdf005_db18266d4d9b4ee5-abb00ddd64bdf005"
}
```

其中，返回结果参数如下表说明：

参数名称	说明
TxnId	导入事务的 ID
Label	导入作业的 label，通过 -H "label:" 指定
Status	导入的最终状态
	- Success：表示导入成功
	- Publish Timeout：该状态也表示导入已经完成，但数据可能会延迟可见，无需重试
	- Label Already Exists：Label 重复，需要更换 label
	- Fail：导入失败
ExistingJobStatus	已存在的 Label 对应的导入作业的状态。这个字段只有在当 Status 为 "Label Already Exists" 时才会显示。用户可以通过这个状态，知晓已存在 Label 对应的导入作业的状态。“RUNNING”表示作业还在执行，“FINISHED”表示作业成功。
Message	导入错误信息
NumberTotalRows	导入总处理的行数
NumberLoadedRows	成功导入的行数
NumberFilteredRows	数据质量不合格的行数
NumberUnselectedRows	被 where 条件过滤的行数
LoadBytes	导入的字节数
LoadTimeMs	导入完成时间。单位毫秒
BeginTxnTimeMs	向 FE 请求开始一个事务所花费的时间，单位毫秒
StreamLoadPutTimeMs	向 FE 请求获取导入数据执行计划所花费的时间，单位毫秒
ReadDataTimeMs	读取数据所花费的时间，单位毫秒
WriteDataTimeMs	执行写入数据操作所花费的时间，单位毫秒
CommitAndPublishTimeMs	向 FE 请求提交并且发布事务所花费的时间，单位毫秒
ErrorURL	如果有数据质量问题，通过访问这个 URL 查看具体错误行

通过 ErrorURL 可以查看因为数据质量不佳导致的导入失败数据。使用命令 `curl "<ErrorURL>"` 命令直接查看错误数据的信息。

导入举例

设置导入超时时间与最大导入

导入任务的超时时间（以秒为单位），导入任务在设定的 timeout 时间内未完成则会被系统取消，变成 CANCELLED。通过指定参数 timeout 或者在 fe.conf 中添加参数 stream_load_default_timeout_second，可以调整 Stream Load 的导入超时时间。

在导入前需要根据文件大小计算导入的超时时间，如 100GB 的文件，预估 50MB/s 的性能导入：

导入时间 $\approx 100\text{GB} / 50\text{MB/s} \approx 2048\text{s}$

通过以下命令可以指定 timeout 3000s 创建 stream load 导入任务：

```
curl --location-trusted -u <doris_user>:<doris_password> \
-H "Expect:100-continue" \
-H "timeout:3000" \
-H "column_separator:," \
-H "columns:user_id,name,age" \
-T streamload_example.csv \
-XPUT http://<fe_ip>:<fe_http_port>/api/testdb/test_streamload/_stream_load
```

设置导入最大容错率

Doris 的导入任务可以容忍一部分格式错误的的数据。容忍率通过 max_filter_ratio 设置。默认为 0，即表示当有一条错误数据时，整个导入任务将会失败。如果用户希望忽略部分有问题的数据行，可以将该参数设置为 0~1 之间的数值，Doris 会自动跳过哪些数据格式不正确的行。关于容忍率的一些计算方式，可以参阅 [数据转换](#) 文档。

通过以下命令可以指定 max_filter_ratio 容忍度为 0.4 创建 stream load 导入任务：

```
curl --location-trusted -u <doris_user>:<doris_password> \
-H "Expect:100-continue" \
-H "max_filter_ratio:0.4" \
-H "column_separator:," \
-H "columns:user_id,name,age" \
-T streamload_example.csv \
-XPUT http://<fe_ip>:<fe_http_port>/api/testdb/test_streamload/_stream_load
```

设置导入过滤条件

导入过程中可以通过 WHERE 参数对导入的数据进行条件过滤。被过滤的数据不会参与到 filter ratio 的计算中，不影响 max_filter_ratio 的设置。在导入结束后，可以通过查看 num_rows_unselected 获取过滤的行数。

通过以下命令可以指定 WHERE 过滤条件创建 Stream Load 导入任务：

```
curl --location-trusted -u <doris_user>:<doris_password> \
-H "Expect:100-continue" \
-H "where:age>=35" \
-H "column_separator:," \
-H "columns:user_id,name,age" \
-T streamload_example.csv \
-XPUT http://<fe_ip>:<fe_http_port>/api/testdb/test_streamload/_stream_load
```

导入指定分区数据

将本地文件中的数据导入到表中的 p1, p2 分区，允许 20% 的错误率。

```
curl --location-trusted -u <doris_user>:<doris_password> \
-H "label:123" \
-H "Expect:100-continue" \
-H "max_filter_ratio:0.2" \
-H "column_separator:," \
-H "columns:user_id,name,age" \
-H "partitions: p1, p2" \
```

```
-T streamload_example.csv \  
-XPUT http://<fe_ip>:<fe_http_port>/api/testdb/test_streamload/_stream_load
```

指定导入时区

由于 Doris 目前没有内置时区的时间类型，所有 DATETIME 相关类型均只表示绝对的时间点，而不包含时区信息，不因 Doris 系统时区变化而发生变化。因此，对于带时区数据的导入，我们统一的处理方式为将其转换为特定目标时区下的数据。在 Doris 系统中，即 session variable time_zone 所代表的时区。

而在导入中，我们的目标时区通过参数 timezone 指定，该变量在发生时区转换、运算时区敏感函数时将会替代 session variable time_zone。因此，如果没有特殊情况，在导入事务中应当设定 timezone 与当前 Doris 集群的 time_zone 一致。此时意味着所有带时区的时间数据，均会发生向该时区的转换。

例如，Doris 系统时区为 “+08:00”，导入数据中的时间列包含两条数据，分别为 “2012-01-01 01:00:00+00:00” 和 “2015-12-12 12:12:12-08:00”，则我们在导入时通过 -H "timezone: +08:00" 指定导入事务的时区后，这两条数据都会向该时区发生转换，从而得到结果 “2012-01-01 09:00:00” 和 “2015-12-13 04:12:12”。

更多关于时区解读可参考文档 [时区](#)。

使用 Streaming 方式导入

Stream Load 是基于 HTTP 的协议进行导入，所以是支持使用程序，比如 Java、Go 或者 Python 等程序来流式写入，这也是为什么起名叫 Stream Load 的原因。

下面通过 bash 的命令管道来举例这种使用方式，这种导入的数据就是程序流式生成的，而不是本地文件。

```
seq 1 10 | awk '{OFS="\t"}{print $1, $1 * 10}' | curl --location-trusted -u root -T -  
http://host:port/api/testDb/testTbl/_stream_load
```

设置 CSV 首行过滤导入

文件数据：

```
id,name,age  
1,doris,20  
2,flink,10
```

通过指定 format=csv_with_names 过滤首行导入

```
curl --location-trusted -u root -T test.csv -H "label:1" -H "format:csv_with_names" -H "column_separator:,"  
http://host:port/api/testDb/testTbl/_stream_load
```

指定 merge_type 进行 Delete 操作

在 Stream Load 中有三种导入类型：APPEND、DELETE 与 MERGE。可以通过指定参数 merge_type 进行调整。如想指定将与导入数据 Key 相同的数据全部删除，可以使用以下命令：

```
curl --location-trusted -u <doris_user>:<doris_password> \  
-H "Expect:100-continue" \  
-H "merge_type:DELETE"
```

```
-H "merge_type: DELETE" \
-H "column_separator:," \
-H "columns:user_id,name,age" \
-T streamload_example.csv \
-XPUT http://<fe_ip>:<fe_http_port>/api/testdb/test_streamload/_stream_load
```

如导入数据前表中数据为：

siteid	citycode	username	pv
3	2	tom	2
4	3	bush	3
5	3	helen	3

导入数据为：

```
3,2,tom,0
```

导入后会删除原表数据，变成以下结果集

siteid	citycode	username	pv
4	3	bush	3
5	3	helen	3

指定 merge_type 进行 Merge 操作

指定 merge_type 为 MERGE，可以将导入的数据 MERGE 到表中。MERGE 语义需要结合 DELETE 条件联合使用，表示满足 DELETE 条件的数据按照 DELETE 语义处理，其余按照 APPEND 语义添加到表中，如下面操作表示删除 siteid 为 1 的行，其余数据添加到表中：

```
curl --location-trusted -u <doris_user>:<doris_password> \
-H "Expect:100-continue" \
-H "merge_type: MERGE" \
-H "delete: siteid=1" \
-H "column_separator:," \
-H "columns:user_id,name,age" \
-T streamload_example.csv \
-XPUT http://<fe_ip>:<fe_http_port>/api/testdb/test_streamload/_stream_load
```

如导入前的数据为：

siteid	citycode	username	pv
4	3	bush	3
5	3	helen	3
1	1	jim	2

导入的数据为：

```
2,1,grace,2
3,2,tom,2
1,1,jim,2
```

导入后，将按照条件删除 siteid = 1 的行，siteid 为 2 与 3 的行会添加到表中：

siteid	citycode	username	pv
4	3	bush	3
2	1	grace	2
3	2	tom	2
5	3	helen	3

指定导入需要 Merge 的 Sequence 列

当 Unique Key 表设置了 Sequence 列时，在相同 Key 列下，Sequence 列的值会作为 REPLACE 聚合函数替换顺序的依据，较大值可以替换较小值。当对这种表基于 DORIS_DELETE_SIGN 进行删除标记时，需要保证 Key 相同和 Sequence 列值要大于等于当前值。通过制定 function_column.sequence_col 参数可以结合 merge_type: DELETE 进行删除操作：

```
curl --location-trusted -u <doris_user>:<doris_password> \
-H "Expect:100-continue" \
-H "merge_type: DELETE" \
-H "function_column.sequence_col: age" \
-H "column_separator:," \
-H "columns: name, gender, age" \
-T streamload_example.csv \
-XPUT http://<fe_ip>:<fe_http_port>/api/testdb/test_streamload/_stream_load
```

如有以下表结构：

```
mysql> SET show_hidden_columns=true;
Query OK, 0 rows affected (0.00 sec)

mysql> DESC table1;
```

Field	Type	Null	Key	Default	Extra
name	VARCHAR(100)	No	true	NULL	
gender	VARCHAR(10)	Yes	false	NULL	REPLACE
age	INT	Yes	false	NULL	REPLACE
__DORIS_DELETE_SIGN__	TINYINT	No	false	0	REPLACE
__DORIS_SEQUENCE_COL__	INT	Yes	false	NULL	REPLACE

```
4 rows in set (0.00 sec)
```

假设原表中数据为：

name	gender	age
------	--------	-----

li	male	10
wang	male	14
zhang	male	12

1. Sequence 参数生效，导入 Sequence 列大于等于表中原有数据

导入数据为：

```
li,male,10
```

由于指定了 `function_column.sequence_col: age`，并且 `age` 大于等于表中原有的列，原表数据被删除，表中数据变为：

name	gender	age
wang	male	14
zhang	male	12

2. Sequence 参数未生效，导入 Sequence 列小于等于表中原有数据：

导入数据为：

```
li,male,9
```

由于指定了 `function_column.sequence_col: age`，但 `age` 小于表中原有的列，DELETE 操作并未生效，表中数据不变，依然会看到主键为 `li` 的列：

name	gender	age
li	male	10
wang	male	14
zhang	male	12

并没有被删除，这是因为在底层的依赖关系上，会先判断 Key 相同的情况，对外展示 Sequence 列的值大的行数据，然后在看该行的 `DORIS_DELETE_SIGN` 值是否为 1，如果为 1 则不会对外展示，如果为 0，则仍会读出来。

导入包含包围符的数据

当 CSV 中的数据包含了分隔符或者分列符，为了防止截断，可以指定单字节字符作为包围符起到保护的作用。

如下列数据中，列中包含了分隔符，：

```
张三,30,'上海市，黄浦区，大沽路'
```

通过制定包围符'，可以将“上海市，黄浦区，大沽路”指定为一个字段：

```
curl --location-trusted -u <doris_user>:<doris_password> \
-H "Expect:100-continue" \
-H "column_separator:," \
-H "enclose:''" \
-H "columns:username,age,address" \
-T streamload_example.csv \
-XPUT http://<fe_ip>:<fe_http_port>/api/testdb/test_streamload/_stream_load
```

如果包围字符也出现在字段中，如希望将“上海市，黄浦区，'大沽路’”作为一个字段，需要先在列中进行字符串转义：

```
张三,30,'上海市，黄浦区，\'大沽路'
```

可以通过 `escape` 参数可以指定单字节转义字符，如下例中 \：

```
curl --location-trusted -u <doris_user>:<doris_password> \
-H "Expect:100-continue" \
-H "column_separator:," \
-H "enclose:''" \
-H "escape:\\" \
-H "columns:username,age,address" \
-T streamload_example.csv \
-XPUT http://<fe_ip>:<fe_http_port>/api/testdb/test_streamload/_stream_load
```

导入包含 **DEFAULT CURRENT_TIMESTAMP** 类型的字段

下面给出导入数据到表字段含有 **DEFAULT CURRENT_TIMESTAMP** 的表中的例子：

表结构：

```
`id` bigint(30) NOT NULL,
`order_code` varchar(30) DEFAULT NULL COMMENT '',
`create_time` datetimev2(3) DEFAULT CURRENT_TIMESTAMP
```

JSON 数据格式：

```
{"id":1,"order_Code":"avc"}
```

导入命令：

```
curl --location-trusted -u root -T test.json -H "label:1" -H "format:json" -H 'columns: id, order_code,
create_time=CURRENT_TIMESTAMP()' http://host:port/api/testDb/testTbl/_stream_load
```

简单模式导入 **JSON** 格式数据

在 JSON 字段和表中的列名一一对应时，可以通过指定参数 `"strip_outer_array:true"` 与 `"format:json"` 将 JSON 数据格式导入到表中。

如表定义如下：


```
CREATE TABLE testdb.test_streamload(
  user_id      BIGINT      NOT NULL COMMENT "用户 ID",
  name         VARCHAR(20)      COMMENT "用户姓名",
  age          INT          COMMENT "用户年龄"
)
DUPLICATE KEY(user_id)
DISTRIBUTED BY HASH(user_id) BUCKETS 10;
```

导入数据字段名与表中的字段名一一对应：

```
[
{"user_id":1,"name":"Emily","age":25},
{"user_id":2,"name":"Benjamin","age":35},
{"user_id":3,"name":"Olivia","age":28},
{"user_id":4,"name":"Alexander","age":60},
{"user_id":5,"name":"Ava","age":17},
{"user_id":6,"name":"William","age":69},
{"user_id":7,"name":"Sophia","age":32},
{"user_id":8,"name":"James","age":64},
{"user_id":9,"name":"Emma","age":37},
{"user_id":10,"name":"Liam","age":64}
]
```

通过以下命令，可以将 JSON 数据导入到表中：

```
curl --location-trusted -u <doris_user>:<doris_password> \
-H "Expect:100-continue" \
-H "format:json" \
-H "strip_outer_array:true" \
-T streamload_example.json \
-XPUT http://<fe_ip>:<fe_http_port>/api/testdb/test_streamload/_stream_load
```

匹配模式导入复杂的 JSON 格式数据

在 JSON 数据较为复杂，无法与表中的列名一一对应，或者有多余的列时，可以通过指定参数 `jsonpaths` 完成列名映射，进行数据匹配导入。如下列数据：

```
[
{"userid":1,"hudi":"lala","username":"Emily","userage":25,"userhp":101},
{"userid":2,"hudi":"kpkp","username":"Benjamin","userage":35,"userhp":102},
{"userid":3,"hudi":"ji","username":"Olivia","userage":28,"userhp":103},
{"userid":4,"hudi":"popo","username":"Alexander","userage":60,"userhp":103},
{"userid":5,"hudi":"uio","username":"Ava","userage":17,"userhp":104},
{"userid":6,"hudi":"lkj","username":"William","userage":69,"userhp":105},
{"userid":7,"hudi":"komf","username":"Sophia","userage":32,"userhp":106},
{"userid":8,"hudi":"mki","username":"James","userage":64,"userhp":107},
{"userid":9,"hudi":"hjk","username":"Emma","userage":37,"userhp":108},
{"userid":10,"hudi":"hua","username":"Liam","userage":64,"userhp":109}
]
```

通过指定 `jsonpaths` 参数可以匹配指定的列：

```
curl --location-trusted -u <doris_user>:<doris_password> \
-H "Expect:100-continue" \
-H "format:json" \
-H "strip_outer_array:true" \
```

```
-H "jsonpaths:[\"$.userid\", \"$.username\", \"$.userage\"]" \
-H "columns:user_id,name,age" \
-T streamload_example.json \
-XPUT http://<fe_ip>:<fe_http_port>/api/testdb/test_streamload/_stream_load
```

指定 JSON 根节点导入数据

如果 JSON 数据包含了嵌套 JSON 字段，需要指定导入 json 的根节点。默认值为“”。

如下列数据，期望将 comment 列中的数据导入到表中：

```
[
  {"user":1,"comment":{"userid":101,"username":"Emily","userage":25}},
  {"user":2,"comment":{"userid":102,"username":"Benjamin","userage":35}},
  {"user":3,"comment":{"userid":103,"username":"Olivia","userage":28}},
  {"user":4,"comment":{"userid":104,"username":"Alexander","userage":60}},
  {"user":5,"comment":{"userid":105,"username":"Ava","userage":17}},
  {"user":6,"comment":{"userid":106,"username":"William","userage":69}},
  {"user":7,"comment":{"userid":107,"username":"Sophia","userage":32}},
  {"user":8,"comment":{"userid":108,"username":"James","userage":64}},
  {"user":9,"comment":{"userid":109,"username":"Emma","userage":37}},
  {"user":10,"comment":{"userid":110,"username":"Liam","userage":64}}
]
```

首先需要通过 json_root 参数指定根节点为 comment，然后根据 jsonpaths 参数完成列名映射：

```
curl --location-trusted -u <doris_user>:<doris_password> \
-H "Expect:100-continue" \
-H "format:json" \
-H "strip_outer_array:true" \
-H "json_root: $.comment" \
-H "jsonpaths:[\"$.userid\", \"$.username\", \"$.userage\"]" \
-H "columns:user_id,name,age" \
-T streamload_example.json \
-XPUT http://<fe_ip>:<fe_http_port>/api/testdb/test_streamload/_stream_load
```

导入 Array 数据类型

如下列数据中包含了数组类型：

```
1|Emily|[1,2,3,4]
2|Benjamin|[22,45,90,12]
3|Olivia|[23,16,19,16]
4|Alexander|[123,234,456]
5|Ava|[12,15,789]
6|William|[57,68,97]
7|Sophia|[46,47,49]
8|James|[110,127,128]
9|Emma|[19,18,123,446]
10|Liam|[89,87,96,12]
```

将数据导入以下的表结构中：

```
CREATE TABLE testdb.test_streamload(
  typ_id      BIGINT      NOT NULL COMMENT "ID",
  name        VARCHAR(20)  NULL    COMMENT "名称",
```

```

    arr          ARRAY<int(10)>  NULL    COMMENT "数组"
)
DUPLICATE KEY(typ_id)
DISTRIBUTED BY HASH(typ_id) BUCKETS 10;

```

通过 Stream Load 任务作业，可以直接将文本文件中的 ARRAY 类型导入到表中：

```

curl --location-trusted -u <doris_user>:<doris_password> \
-H "Expect:100-continue" \
-H "column_separator:|" \
-H "columns:typ_id,name,arr" \
-T streamload_example.csv \
-XPUT http://<fe_ip>:<fe_http_port>/api/testdb/test_streamload/_stream_load

```

导入 map 数据类型

当导入数据中包含 map 类型，如以下的例子中：

```

[
{"user_id":1,"namemap":{"Emily":101,"age":25}},
{"user_id":2,"namemap":{"Benjamin":102,"age":35}},
{"user_id":3,"namemap":{"Olivia":103,"age":28}},
{"user_id":4,"namemap":{"Alexander":104,"age":60}},
{"user_id":5,"namemap":{"Ava":105,"age":17}},
{"user_id":6,"namemap":{"William":106,"age":69}},
{"user_id":7,"namemap":{"Sophia":107,"age":32}},
{"user_id":8,"namemap":{"James":108,"age":64}},
{"user_id":9,"namemap":{"Emma":109,"age":37}},
{"user_id":10,"namemap":{"Liam":110,"age":64}}
]

```

将数据导入以下表结构中：

```

CREATE TABLE testdb.test_streamload(
  user_id          BIGINT      NOT NULL COMMENT "ID",
  namemap          Map<STRING, INT>  NULL    COMMENT "名称"
)
DUPLICATE KEY(user_id)
DISTRIBUTED BY HASH(user_id) BUCKETS 10;

```

通过 Stream Load 任务作业，可以直接将文本文件中的 map 类型导入到表中：

```

curl --location-trusted -u <doris_user>:<doris_password> \
-H "Expect:100-continue" \
-H "format: json" \
-H "strip_outer_array:true" \
-T streamload_example.json \
-XPUT http://<fe_ip>:<fe_http_port>/api/testdb/test_streamload/_stream_load

```

导入 Bitmap 类型数据

在导入过程中，遇到 Bitmap 类型的数据，可以通过 to_bitmap 将数据转换成 Bitmap，或者通过 bitmap_empty 函数填充 Bitmap。

如导入数据如下：

```
1|koga|17723
2|nijg|146285
3|lojn|347890
4|lofn|489871
5|jfin|545679
6|kon|676724
7|nhga|767689
8|nfubg|879878
9|huang|969798
10|buag|97997
```

将数据导入到以下包含 Bitmap 类型的表中：

```
CREATE TABLE testdb.test_streamload(
  typ_id      BIGINT      NULL    COMMENT "ID",
  hou        VARCHAR(10)  NULL    COMMENT "one",
  arr        BITMAP  BITMAP_UNION NOT NULL    COMMENT "two"
)
AGGREGATE KEY(typ_id,hou)
DISTRIBUTED BY HASH(typ_id,hou) BUCKETS 10;
```

通过以 to_bitmap 可以将数据转换成 Bitmap 类型：

```
curl --location-trusted -u <doris_user>:<doris_password> \
-H "Expect:100-continue" \
-H "columns:typ_id,hou,arr,arr=to_bitmap(arr)"
-T streamload_example.csv \
-XPUT http://<fe_ip>:<fe_http_port>/api/testdb/test_streamload/_stream_load
```

导入 HLL 数据类型

通过 hll_hash 函数可以将数据转换成 hll 类型，如下数据：

```
1001|koga
1002|nijg
1003|lojn
1004|lofn
1005|jfin
1006|kon
1007|nhga
1008|nfubg
1009|huang
1010|buag
```

导入下列表中：

```
CREATE TABLE testdb.test_streamload(
  typ_id      BIGINT      NULL    COMMENT "ID",
  typ_name    VARCHAR(10)  NULL    COMMENT "NAME",
  pv          hll hll_union NOT NULL    COMMENT "hll"
)
AGGREGATE KEY(typ_id,typ_name)
DISTRIBUTED BY HASH(typ_id) BUCKETS 10;
```

通过 hll_hash 命令进行导入：

```
curl --location-trusted -u <doris_user>:<doris_password> \
-H "column_separator:|" \
-H "columns:typ_id,typ_name,pv=hll_hash(typ_id)" \
-T streamload_example.csv \
-XPUT http://<fe_ip>:<fe_http_port>/api/testdb/test_streamload/_stream_load
```

Label、导入事务、多表原子性

Doris 中所有导入任务都是原子生效的。并且在同一个导入任务中对多张表的导入也能够保证原子性。同时，Doris 还可以通过 Label 的机制来保证数据导入的不丢不重。具体说明可以参阅 [导入事务和原子性](#) 文档。

列映射、衍生列和过滤

Doris 可以在导入语句中支持非常丰富的列转换和过滤操作。支持绝大多数内置函数和 UDF。关于如何正确的使用这个功能，可参阅 [数据转换](#) 文档。

启用严格模式导入

strict_mode 属性用于设置导入任务是否运行在严格模式下。该属性会对列映射、转换和过滤的结果产生影响，它同时也将控制部分列更新的行为。关于严格模式的具体说明，可参阅 [严格模式](#) 文档。

导入时进行部分列更新

关于导入时，如何表达部分列更新，可以参考 [数据操作/数据更新](#) 文档

更多帮助

关于 Stream Load 使用的更多详细语法及最佳实践，请参阅 [Stream Load](#) 命令手册，你也可以在 MySQL 客户端命令行下输入 HELP STREAM LOAD 获取更多帮助信息。

Broker Load

为什么引入 Broker Load?

Stream Load 是一种推的方式，即导入的数据依靠客户端读取，并推送到 Doris。Broker Load 则是将导入请求发送给 Doris，由 Doris 主动拉取数据，所以如果数据存储在类似 HDFS 或者 对象存储中，则使用 Broker Load 是最方便的。这样，数据就不需要经过客户端，而由 Doris 直接读取导入。


从 HDFS 或者 S3 直接读取，也可以通过 [湖仓一体/TVF](#) 中的 HDFS TVF 或者 S3 TVF 进行导入。基于 TVF 的 Insert Into 当前为同步导入，Broker Load 是一个异步的导入方式。

Broker Load 适合源数据存储在远程存储系统，比如 HDFS，并且数据量比较大的场景。

基本原理

用户在提交导入任务后，FE 会生成对应的 Plan 并根据目前 BE 的个数和文件的大小，将 Plan 分给 多个 BE 执行，每个 BE 执行一部分导入数据。

BE 在执行的过程中会从 Broker 拉取数据，在对数据 transform 之后将数据导入系统。所有 BE 均完成导入，由 FE 最终决定导入是否成功。



Broker Load 基本原理

从上图中可以看到，BE 会依赖 Broker 进程来读取相应远程存储系统的数据。之所以引入 Broker 进程，主要是用来针对不同的远程存储系统，用户可以按照 Broker 进程的标准开发其相应的 Broker 进程，Broker 进程可以使用 Java 程序开发，更好的兼容大数据生态中的各类存储系统。由于 broker 进程和 BE 进程的分离，也确保了两个进程的错误隔离，提升 BE 的稳定性。

当前 BE 内置了对 HDFS 和 S3 两个 Broker 的支持，所以如果从 HDFS 和 S3 中导入数据，则不需要额外启动 Broker 进程。如果有自己定制的 Broker 实现，则需要部署相应的 Broker 进程。

导入语法

```
LOAD LABEL load_label
(
  data_desc1[, data_desc2, ...]
)
WITH [HDFS|S3|BROKER broker_name]
[broker_properties]
[load_properties]
[COMMENT "comments"];
```

具体的使用语法，请参考 SQL 手册中的 [Broker Load](#)。

查看导入状态

Broker load 是一个异步的导入方式，具体导入结果可以通过 [SHOW LOAD](#) 命令查看

```
mysql> show load order by createtime desc limit 1\G;
***** 1. row *****
      JobId: 41326624
      Label: broker_load_2022_04_15
      State: FINISHED
      Progress: ETL:100%; LOAD:100%
      Type: BROKER
      EtlInfo: unselected.rows=0; dpp.abnorm.ALL=0; dpp.norm.ALL=27
      TaskInfo: cluster:N/A; timeout(s):1200; max_filter_ratio:0.1
      ErrorMsg: NULL
      CreateTime: 2022-04-01 18:59:06
      EtlStartTime: 2022-04-01 18:59:11
      EtlFinishTime: 2022-04-01 18:59:11
      LoadStartTime: 2022-04-01 18:59:11
      LoadFinishTime: 2022-04-01 18:59:11
      URL: NULL
      JobDetails: {"Unfinished backends":{"5072bde59b74b65-8d2c0ee5b029adc0":
[]},"ScannedRows":27,"TaskNumber":1,"All backends":{"5072bde59b74b65-8d2c0ee5b029adc0":
[36728051]},"FileName":1,"FileSize":5540}
1 row in set (0.01 sec)
```

取消导入

当 Broker load 作业状态不为 CANCELLED 或 FINISHED 时，可以被用户手动取消。取消时需要指定待取消导入任务的 Label。取消导入命令语法可执行 [CANCEL LOAD](#) 查看。

例如：撤销数据库 DEMO 上，label 为 broker_load_2022_03_23 的导入作业

```
CANCEL LOAD FROM demo WHERE LABEL = "broker_load_2022_03_23";
```

HDFS Load

简单认证

简单认证即 Hadoop 配置 `hadoop.security.authentication` 为 `simple`。

```
(
  "username" = "user",
  "password" = ""
);
```

`username` 配置为要访问的用户，密码置空即可。

Kerberos 认证

该认证方式需提供以下信息：

- `hadoop.security.authentication`：指定认证方式为 Kerberos。
- `hadoop.kerberos.principal`：指定 Kerberos 的 principal。
- `hadoop.kerberos.keytab`：指定 Kerberos 的 keytab 文件路径。该文件必须为 Broker 进程所在服务器上的文件的绝对路径。并且可以被 Broker 进程访问。
- `kerberos_keytab_content`：指定 Kerberos 中 keytab 文件内容经过 base64 编码之后的内容。这个跟 `kerberos_keytab` 配置二选一即可。

示例如下：

```
(
  "hadoop.security.authentication" = "kerberos",
  "hadoop.kerberos.principal" = "doris@YOUR.COM",
  "hadoop.kerberos.keytab" = "/home/doris/my.keytab"
)
(
  "hadoop.security.authentication" = "kerberos",
  "hadoop.kerberos.principal" = "doris@YOUR.COM",
  "kerberos_keytab_content" = "ASDOWHDLAWIDJHWLDKSALDJSDIWALD"
)
```

采用 Kerberos 认证方式，需要 [krb5.conf \(opens new window\)](#) 文件，`krb5.conf` 文件包含 Kerberos 的配置信息，通常，应该将 `krb5.conf` 文件安装在目录 `/etc` 中。可以通过设置环境变量 `KRB5_CONFIG` 覆盖默认位置。`krb5.conf` 文件的内容示例如下：

```
[libdefaults]
    default_realm = DORIS.HADOOP
    default_tkt_enctypes = des3-hmac-sha1 des-cbc-crc
    default_tgs_enctypes = des3-hmac-sha1 des-cbc-crc
    dns_lookup_kdc = true
    dns_lookup_realm = false

[realms]
    DORIS.HADOOP = {
```



```
kdc = kerberos-doris.hadoop.service:7005
}
```

HDFS HA 模式

这个配置用于访问以 HA 模式部署的 HDFS 集群。

- `dfs.nameservices`: 指定 HDFS 服务的名字, 自定义, 如: “`dfs.nameservices`” = “`my_ha`”。
- `dfs.ha.namenodes.xxx`: 自定义 namenode 的名字, 多个名字以逗号分隔。其中 xxx 为 `dfs.nameservices` 中自定义的名字, 如: “`dfs.ha.namenodes.my_ha`” = “`my_nn`”。
- `dfs.namenode.rpc-address.xxx.nn`: 指定 namenode 的 rpc 地址信息。其中 nn 表示 `dfs.ha.namenodes.xxx` 中配置的 namenode 的名字, 如: “`dfs.namenode.rpc-address.my_ha.my_nn`” = “`host:port`”。
- `dfs.client.failover.proxy.provider.[nameservice ID]`: 指定 client 连接 namenode 的 provider, 默认为: `org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider`。

示例如下:

```
(
  "fs.defaultFS" = "hdfs://my_ha",
  "dfs.nameservices" = "my_ha",
  "dfs.ha.namenodes.my_ha" = "my_namenode1, my_namenode2",
  "dfs.namenode.rpc-address.my_ha.my_namenode1" = "nn1_host:rpc_port",
  "dfs.namenode.rpc-address.my_ha.my_namenode2" = "nn2_host:rpc_port",
  "dfs.client.failover.proxy.provider.my_ha" =
  "org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider"
)
```

HA 模式可以和前面两种认证方式组合, 进行集群访问。如通过简单认证访问 HA HDFS:

```
(
  "username"="user",
  "password"="passwd",
  "fs.defaultFS" = "hdfs://my_ha",
  "dfs.nameservices" = "my_ha",
  "dfs.ha.namenodes.my_ha" = "my_namenode1, my_namenode2",
  "dfs.namenode.rpc-address.my_ha.my_namenode1" = "nn1_host:rpc_port",
  "dfs.namenode.rpc-address.my_ha.my_namenode2" = "nn2_host:rpc_port",
  "dfs.client.failover.proxy.provider.my_ha" =
  "org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider"
)
```

导入示例

- 导入 HDFS 上的 TXT 文件

```
LOAD LABEL demo.label_20220402
(
  DATA INFILE("hdfs://host:port/tmp/test_hdfs.txt")
  INTO TABLE `load_hdfs_file_test`
  COLUMNS TERMINATED BY "\t"
  (id,age,name)
```

```

)
with HDFS
(
  "fs.defaultFS"="hdfs://host:port",
  "hadoop.username" = "user"
)
PROPERTIES
(
  "timeout"="1200",
  "max_filter_ratio"="0.1"
);

```

- HDFS 需要配置 NameNode HA 的情况

```

LOAD LABEL demo.label_20220402
(
  DATA INFILE("hdfs://hafs/tmp/test_hdfs.txt")
  INTO TABLE `load_hdfs_file_test`
  COLUMNS TERMINATED BY "\t"
  (id,age,name)
)
with HDFS
(
  "hadoop.username" = "user",
  "fs.defaultFS"="hdfs://hafs",
  "dfs.nameservices" = "hafs",
  "dfs.ha.namenodes.hafs" = "my_namenode1, my_namenode2",
  "dfs.namenode.rpc-address.hafs.my_namenode1" = "nn1_host:rpc_port",
  "dfs.namenode.rpc-address.hafs.my_namenode2" = "nn2_host:rpc_port",
  "dfs.client.failover.proxy.provider.hafs" =
"org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider"
)
PROPERTIES
(
  "timeout"="1200",
  "max_filter_ratio"="0.1"
);

```

- 从 HDFS 导入数据，使用通配符匹配两批文件，分别导入到两个表中

```

LOAD LABEL example_db.label2
(
  DATA INFILE("hdfs://host:port/input/file-10*")
  INTO TABLE `my_table1`
  PARTITION (p1)
  COLUMNS TERMINATED BY ","
  (k1, tmp_k2, tmp_k3)
  SET (
    k2 = tmp_k2 + 1,
    k3 = tmp_k3 + 1
  ),
  DATA INFILE("hdfs://host:port/input/file-20*")
  INTO TABLE `my_table2`
  COLUMNS TERMINATED BY ","
  (k1, k2, k3)
)
with HDFS
(
  "fs.defaultFS"="hdfs://host:port",
  "hadoop.username" = "user"
);

```

使用通配符匹配导入两批文件 file-10* 和 file-20*。分别导入到 my_table1 和 my_table2 两张表中。其中 my_table1 指定导入到分区 p1 中，并且将导入源文件中第二列和第三列的值 +1 后导入。

- 使用通配符从 HDFS 导入一批数据

```
LOAD LABEL example_db.label3
(
  DATA INFILE("hdfs://host:port/user/doris/data/*/*")
  INTO TABLE `my_table`
  COLUMNS TERMINATED BY "\\x01"
)
with HDFS
(
  "fs.defaultFS"="hdfs://host:port",
  "hadoop.username" = "user"
);
```

指定分隔符为 Hive 经常用的默认分隔符 \\x01，并使用通配符 * 指定 data 目录下所有目录的所有文件。

- 导入 Parquet 格式数据，指定 FORMAT 为 parquet

```
LOAD LABEL example_db.label4
(
  DATA INFILE("hdfs://host:port/input/file")
  INTO TABLE `my_table`
  FORMAT AS "parquet"
  (k1, k2, k3)
)
with HDFS
(
  "fs.defaultFS"="hdfs://host:port",
  "hadoop.username" = "user"
);
```

默认是通过文件后缀判断。

- 导入数据，并提取文件路径中的分区字段

```
LOAD LABEL example_db.label5
(
  DATA INFILE("hdfs://host:port/input/city=beijing/*/*")
  INTO TABLE `my_table`
  FORMAT AS "csv"
  (k1, k2, k3)
  COLUMNS FROM PATH AS (city, utc_date)
)
with HDFS
(
  "fs.defaultFS"="hdfs://host:port",
  "hadoop.username" = "user"
);
```

my_table 表中的列为 k1, k2, k3, city, utc_date。

其中 hdfs://hdfs_host:hdfs_port/user/doris/data/input/dir/city=beijing 目录下包括如下文件：

```
hdfs://hdfs_host:hdfs_port/input/city=beijing/utc_date=2020-10-01/0000.csv
hdfs://hdfs_host:hdfs_port/input/city=beijing/utc_date=2020-10-02/0000.csv
hdfs://hdfs_host:hdfs_port/input/city=tianji/utc_date=2020-10-03/0000.csv
hdfs://hdfs_host:hdfs_port/input/city=tianji/utc_date=2020-10-04/0000.csv
```

文件中只包含 k1, k2, k3 三列数据, city, utc_date 这两列数据会从文件路径中提取。

- 对导入数据进行过滤

```
LOAD LABEL example_db.label6
(
  DATA INFILE("hdfs://host:port/input/file")
  INTO TABLE `my_table`
  (k1, k2, k3)
  SET (
    k2 = k2 + 1
  )
  PRECEDING FILTER k1 = 1
  WHERE k1 > k2
)
with HDFS
(
  "fs.defaultFS"="hdfs://host:port",
  "hadoop.username" = "user"
);
```

只有原始数据中, k1 = 1, 并且转换后, k1 > k2 的行才会被导入。

- 导入数据, 提取文件路径中的时间分区字段

```
LOAD LABEL example_db.label7
(
  DATA INFILE("hdfs://host:port/user/data/*/test.txt")
  INTO TABLE `tbl12`
  COLUMNS TERMINATED BY ","
  (k2,k3)
  COLUMNS FROM PATH AS (data_time)
  SET (
    data_time=str_to_date(data_time, '%Y-%m-%d %H%3A%i%3A%s')
  )
)
with HDFS
(
  "fs.defaultFS"="hdfs://host:port",
  "hadoop.username" = "user"
);
```

时间包含 %3A。在 hdfs 路径中, 不允许有 ':', 所有 ':' 会由 %3A 替换。

路径下有如下文件:

```
/user/data/data_time=2020-02-17 00%3A00%3A00/test.txt
/user/data/data_time=2020-02-18 00%3A00%3A00/test.txt
```

表结构为:

```
CREATE TABLE IF NOT EXISTS tbl12 (
  data_time DATETIME,
  k2        INT,
  k3        INT
) DISTRIBUTED BY HASH(data_time) BUCKETS 10
PROPERTIES (
  "replication_num" = "3"
);
```

- 使用 Merge 方式导入

```
LOAD LABEL example_db.label8
(
  MERGE DATA INFILE("hdfs://host:port/input/file")
  INTO TABLE `my_table`
  (k1, k2, k3, v2, v1)
  DELETE ON v2 > 100
)
with HDFS
(
  "fs.defaultFS"="hdfs://host:port",
  "hadoop.username"="user"
)
PROPERTIES
(
  "timeout" = "3600",
  "max_filter_ratio" = "0.1"
);
```

使用 Merge 方式导入。my_table 必须是一张 Unique Key 的表。当导入数据中的 v2 列的值大于 100 时，该行会被认为是一个删除行。导入任务的超时时间是 3600 秒，并且允许错误率在 10% 以内。

- 导入时指定 source_sequence 列，保证替换顺序

```
LOAD LABEL example_db.label9
(
  DATA INFILE("hdfs://host:port/input/file")
  INTO TABLE `my_table`
  COLUMNS TERMINATED BY ","
  (k1,k2,source_sequence,v1,v2)
  ORDER BY source_sequence
)
with HDFS
(
  "fs.defaultFS"="hdfs://host:port",
  "hadoop.username"="user"
);
```

my_table 必须是 Unique Key 模型表，并且指定了 Sequence 列。数据会按照源数据中 source_sequence 列的值来保证顺序性。

- 导入指定文件格式为 json，并指定 json_root、jsonpaths

```
LOAD LABEL example_db.label10
(
  DATA INFILE("hdfs://host:port/input/file.json")
  INTO TABLE `my_table`
  FORMAT AS "json"
```

```

    PROPERTIES(
      "json_root" = "$.item",
      "jsonpaths" = "[\"$.id\", \"$.city\", \"$.code\"]"
    )
  )
  with HDFS
  (
    "fs.defaultFS"="hdfs://host:port",
    "hadoop.username"="user"
  );

```

jsonpaths 也可以与 column list 及 SET (column_mapping)配合使用:

```

LOAD LABEL example_db.label10
(
  DATA INFILE("hdfs://host:port/input/file.json")
  INTO TABLE `my_table`
  FORMAT AS "json"
  (id, code, city)
  SET (id = id * 10)
  PROPERTIES(
    "json_root" = "$.item",
    "jsonpaths" = "[\"$.id\", \"$.city\", \"$.code\"]"
  )
)
with HDFS
(
  "fs.defaultFS"="hdfs://host:port",
  "hadoop.username"="user"
);

```

S3 Load

Doris 支持通过 S3 协议直接从支持 S3 协议的对象存储系统导入数据。这里主要介绍如何导入 AWS S3 中存储的数据, 支持导入其他支持 S3 协议的对象存储系统可以参考 [AWS S3](#)。

准备工作

- AK 和 SK: 首先需要找到或者重新生成 AWS Access keys, 可以在 AWS console 的 My Security Credentials 找到生成方式。
- REGION 和 ENDPOINT: REGION 可以在创建桶的时候选择也可以在桶列表中查看到。每个 REGION 的 S3 ENDPOINT 可以通过如下页面查到 [AWS 文档](#)。

导入示例

```

LOAD LABEL example_db.example_label_1
(
  DATA INFILE("s3://your_bucket_name/your_file.txt")
  INTO TABLE load_test
  COLUMNS TERMINATED BY ","
)
WITH S3
(
  "AWS_ENDPOINT" = "AWS_ENDPOINT",
  "AWS_ACCESS_KEY" = "AWS_ACCESS_KEY",

```

```

    "AWS_SECRET_KEY"="AWS_SECRET_KEY",
    "AWS_REGION" = "AWS_REGION"
)
PROPERTIES
(
    "timeout" = "3600"
);

```

常见问题

- S3 SDK 默认使用 virtual-hosted style 方式。但某些对象存储系统可能没开启或没支持 virtual-hosted style 方式的访问，此时我们可以添加 use_path_style 参数来强制使用 path style 方式：

```

WITH S3
(
    "AWS_ENDPOINT" = "AWS_ENDPOINT",
    "AWS_ACCESS_KEY" = "AWS_ACCESS_KEY",
    "AWS_SECRET_KEY"="AWS_SECRET_KEY",
    "AWS_REGION" = "AWS_REGION",
    "use_path_style" = "true"
)

```

- 支持使用临时密钥 (TOKEN) 访问所有支持 S3 协议的对象存储，用法如下：

```

WITH S3
(
    "AWS_ENDPOINT" = "AWS_ENDPOINT",
    "AWS_ACCESS_KEY" = "AWS_TEMP_ACCESS_KEY",
    "AWS_SECRET_KEY" = "AWS_TEMP_SECRET_KEY",
    "AWS_TOKEN" = "AWS_TEMP_TOKEN",
    "AWS_REGION" = "AWS_REGION"
)

```

其他 Broker 导入

其他远端存储系统的 Broker 是 Doris 集群中一种可选进程，主要用于支持 Doris 读写远端存储上的文件和目录。目前提供了如下存储系统的 Broker 实现。

- 阿里云 OSS
- 百度云 BOS
- 腾讯云 CHDFS
- 腾讯云 GFS
- 华为云 OBS
- JuiceFS
- GCS

Broker 通过提供一个 RPC 服务端口来提供服务，是一个无状态的 Java 进程，负责为远端存储的读写操作封装一些类 POSIX 的文件操作，如 open, pread, pwrite 等等。除此之外，Broker 不记录任何其他信息，所以包括

远端存储的连接信息、文件信息、权限信息等等，都需要通过参数在 RPC 调用中传递给 Broker 进程，才能使得 Broker 能够正确读写文件。

Broker 仅作为一个数据通路，并不参与任何计算，因此仅需占用较少的内存。通常一个 Doris 系统中会部署一个或多个 Broker 进程。并且相同类型的 Broker 会组成一个组，并设定一个名称（Broker name）。

这里主要介绍 Broker 在访问不同远端存储时需要的参数，如连接信息、权限认证信息等等。

Broker 信息

Broker 的信息包括 名称（Broker name）和 认证信息 两部分。通常的语法格式如下：

```
WITH BROKER "broker_name"
(
  "username" = "xxx",
  "password" = "yyy",
  "other_prop" = "prop_value",
  ...
);
```

名称

通常用户需要通过操作命令中的 WITH BROKER "broker_name" 子句来指定一个已经存在的 Broker Name。Broker Name 是用户通过 ALTER SYSTEM ADD BROKER 命令添加 Broker 进程时指定的一个名称。一个名称通常对应一个或多个 Broker 进程。Doris 会根据名称选择可用的 Broker 进程。用户可以通过 SHOW BROKER 命令查看当前集群中已经存在的 Broker。

备注

Broker Name 只是一个用户自定义名称，不代表 Broker 的类型。

认证信息

不同的 Broker 类型，以及不同的访问方式需要提供不同的认证信息。认证信息通常在 WITH BROKER "broker_name" 之后的 Property Map 中以 Key-Value 的方式提供。

Broker 举例

- 阿里云 OSS

```
(
  "fs.oss.accessKeyId" = "",
  "fs.oss.accessKeySecret" = "",
  "fs.oss.endpoint" = ""
)
```

- 百度云 BOS

当前使用 BOS 时需要下载相应的 SDK 包，具体配置与使用，可以参考 [BOS HDFS 官方文档](#)。在下载完成并解压后将 jar 包放到 broker 的 lib 目录下。


```
(
  "fs.bos.access.key" = "xx",
  "fs.bos.secret.access.key" = "xx",
  "fs.bos.endpoint" = "xx"
)
```

- 华为云 OBS

```
(
  "fs.obs.access.key" = "xx",
  "fs.obs.secret.key" = "xx",
  "fs.obs.endpoint" = "xx"
)
```

- JuiceFS

```
(
  "fs.defaultFS" = "jfs://xxx/",
  "fs.jfs.impl" = "io.juicefs.JuiceFileSystem",
  "fs.AbstractFileSystem.jfs.impl" = "io.juicefs.JuiceFS",
  "juicefs.meta" = "xxx",
  "juicefs.access-log" = "xxx"
)
```

- GCS

在使用 Broker 访问 GCS 时，Project ID 是必须的，其他参数可选，所有参数配置请参考 [GCS Config](#)

```
(
  "fs.gs.project.id" = "你的 Project ID",
  "fs.AbstractFileSystem.gs.impl" = "com.google.cloud.hadoop.fs.gcs.GoogleHadoopFS",
  "fs.gs.impl" = "com.google.cloud.hadoop.fs.gcs.GoogleHadoopFileSystem",
)
```

相关配置

下面几个配置属于 Broker load 的系统级别配置，也就是作用于所有 Broker load 导入任务的配置。主要通过修改 `fe.conf` 来调整配置值。

min_bytes_per_broker_scanner

- 默认 64MB。
- 一个 Broker Load 作业中单 BE 处理的数据量的最小值

max_bytes_per_broker_scanner

- 默认 500GB。
- 一个 Broker Load 作业中单 BE 处理的数据量的最大值

通常一个导入作业支持的最大数据量为 `max_bytes_per_broker_scanner * BE 节点数`。如果需要导入更大数据量，则需要适当调整 `max_bytes_per_broker_scanner` 参数的大小。

max_broker_concurrency

- 默认 10。
- 限制了一个作业的最大的导入并发数。
- 最小处理的数据量，最大并发数，源文件的大小和当前集群 BE 的个数共同决定了本次导入的并发数。

```
本次导入并发数 = Math.min(源文件大小/min_bytes_per_broker_scanner, max_broker_concurrency, 当前BE节点个数 * load_parallelism)
本次导入单个BE的处理量 = 源文件大小/本次导入的并发数
```

常见问题

1. 导入报错: Scan bytes per broker scanner exceed limit:xxx

请参照文档中最佳实践部分，修改 FE 配置项 max_bytes_per_broker_scanner 和 max_broker_concurrency

2. 导入报错: failed to send batch 或 TabletWriter add batch with unknown id

适当修改 query_timeout 和 streaming_load_rpc_max_alive_time_sec。

3. 导入报错: LOAD_RUN_FAIL; msg:Invalid Column Name:xxx

如果是 PARQUET 或者 ORC 格式的数据，则文件头的列名需要与 doris 表中的列名保持一致，如：

```
(tmp_c1,tmp_c2)
SET
(
    id=tmp_c2,
    name=tmp_c1
)
```

代表获取在 parquet 或 orc 中以 (tmp_c1, tmp_c2) 为列名的列，映射到 doris 表中的 (id, name) 列。如果没有设置 set, 则以 column 中的列作为映射。

注：如果使用某些 hive 版本直接生成的 orc 文件，orc 文件中的表头并非 hive meta 数据，而是 (_col0, _col1, _col2, ...)，可能导致 Invalid Column Name 错误，那么则需要使用 set 进行映射

4. 导入报错: Failed to get S3 FileSystem for bucket is null/empty

bucket 信息填写不正确或者不存在。或者 bucket 的格式不受支持。使用 GCS 创建带_的桶名时，比如：s3://gs_bucket/load_tbl, S3 Client 访问 GCS 会报错，建议创建 bucket 路径时不使用_。

5. 导入超时

导入的 timeout 默认超时时间为 4 小时。如果超时，不推荐用户将导入最大超时时间直接改大来解决问题。单个导入时间如果超过默认的导入超时时间 4 小时，最好是通过切分待导入文件并且分多次导入来解决问题。因为超时时间设置过大，那么单次导入失败后重试的时间成本很高。

可以通过如下公式计算出 Doris 集群期望最大导入文件数据量：

```
期望最大导入文件数据量 = 14400s * 10M/s * BE 个数
比如：集群的 BE 个数为 10个
```

期望最大导入文件数据量 = $14400s * 10M/s * 10 = 1440000M \approx 1440G$

注意：一般用户的环境可能达不到 $10M/s$ 的速度，所以建议超过 $500G$ 的文件都进行文件切分，再导入。

更多帮助

关于 Broker Load 使用的更多详细语法及最佳实践，请参阅 [Broker Load](#) 命令手册，你也可以在 MySQL 客户端命令行下输入 `HELP BROKER LOAD` 获取更多帮助信息。

Routine Load

Doris 可以通过 Routine Load 导入方式持续消费 Kafka Topic 中的数据。在提交 Routine Load 作业后，Doris 会持续运行该导入作业，实时生成导入任务不断消费 Kafka 集群中指定 Topic 中的消息。

Routine Load 是一个流式导入作业，支持 Exactly-Once 语义，保证数据不丢不重。

使用场景

支持数据文件格式

Routine Load 支持从 Kafka 中消费 CSV 及 JSON 格式的数据。

在导入 CSV 格式时，需要明确区分空值 (null) 与空字符串 ("")：

- 空值 (null) 需要用 \n 表示，a,\n,b 数据表示中间列是一个空值 (null)
- 空字符串 (") 直接将数据置空，a,,b 数据表示中间列是一个空字符串 (")

使用限制

在使用 Routine Load 消费 Kafka 中数据时，有以下限制：

- 支持无认证的 Kafka 访问，以及通过 SSL 方式认证的 Kafka 集群；
- 支持的消息格式为 CSV 及 JSON 文本格式。CSV 每一个 message 为一行，且行尾**不包含**换行符；
- 默认支持 Kafka 0.10.0.0（含）以上版本。如果要使用 Kafka 0.10.0.0 以下版本（0.9.0, 0.8.2, 0.8.1, 0.8.0），需要修改 BE 的配置，将 kafka_broker_version_fallback 的值设置为要兼容的旧版本，或者在创建 Routine Load 的时候直接设置 property.broker.version.fallback 的值为要兼容的旧版本，使用旧版本的代价是 Routine Load 的部分新特性可能无法使用，如根据时间设置 Kafka 分区的 offset。


基本原理

Routine Load 会持续消费 Kafka Topic 中的数据，写入 Doris 中。

在 Doris 中，创建 Routine Load 作业后会生成一个常驻的导入作业和若干个导入任务：

- 导入作业 (load job)：一个 Routine Load 对应一个导入作业，导入作业是一个常驻的任务，会持续不断地消费 Kafka Topic 中的数据；
- 导入任务 (load task)：一个导入作业会被拆解成若干个导入任务，作为一个独立的导入基本单位，以 Stream Load 的方式写入到 BE 中。

Routine Load 的导入具体流程如下图所示：



Routine Load

1. Client 向 FE 提交 Routine Load 常驻 Routine Load Job
2. FE 通过 Job Scheduler 将 Routine Load Job 拆分成若干个 Routine Load Task
3. 在 BE 上，一个 Routine Load Task 会被视为 Stream Load 任务进行导入，导入完成后向 FE 汇报
4. FE 中的 Job Scheduler 根据汇报结果，继续生成新的 Task，或对失败的 Task 进行重试
5. Routine Load Job 会不断产生新的 Task，来完成数据的不间断导入

快速上手

创建导入作业

在 Doris 内可以通过 CREATE ROUTINE LOAD 命令创建常驻 Routine Load 导入任务。详细语法可以参考 [CREATE ROUTINE LOAD](#)。Routine Load 可以消费 CSV 和 JSON 的数据。

导入 CSV 数据

1. 导入数据样本

在 Kafka 中，有以下样本数据

```
kafka-console-consumer.sh --bootstrap-server localhost:9092 --topic test-routine-load-csv --from-beginnin
1,Emily,25
2,Benjamin,35
3,Olivia,28
4,Alexander,60
5,Ava,17
6,William,69
7,Sophia,32
8,James,64
9,Emma,37
10,Liam,64
```

2. 创建需要导入的表

在 Doris 中，创建被导入的表，具体语法如下

```
CREATE TABLE testdb.test_streamload(  
  user_id          BIGINT      NOT NULL COMMENT "用户 ID",  
  name             VARCHAR(20) COMMENT "用户姓名",  
  age              INT         COMMENT "用户年龄"  
)  
DUPLICATE KEY(user_id)  
DISTRIBUTED BY HASH(user_id) BUCKETS 10;
```

3. 创建 Routine Load 导入作业

在 Doris 中，使用 CREATE ROUTINE LOAD 命令，创建导入作业

```
CREATE ROUTINE LOAD testdb.example_routine_load_csv ON test_routineload_tbl  
COLUMNS TERMINATED BY ",",  
COLUMNS(user_id, name, age)  
FROM KAFKA(  
  "kafka_broker_list" = "192.168.88.62:9092",  
  "kafka_topic" = "test-routine-load-csv",  
  "property.kafka_default_offsets" = "OFFSET_BEGINNING"  
);
```

导入 JSON 数据

1. 导入样本数据

在 Kafka 中，有以下样本数据

```
kafka-console-consumer.sh --bootstrap-server localhost:9092 --topic test-routine-load-json --from-beginning  
{ "user_id":1,"name":"Emily","age":25}  
{ "user_id":2,"name":"Benjamin","age":35}  
{ "user_id":3,"name":"Olivia","age":28}  
{ "user_id":4,"name":"Alexander","age":60}  
{ "user_id":5,"name":"Ava","age":17}  
{ "user_id":6,"name":"William","age":69}  
{ "user_id":7,"name":"Sophia","age":32}  
{ "user_id":8,"name":"James","age":64}  
{ "user_id":9,"name":"Emma","age":37}  
{ "user_id":10,"name":"Liam","age":64}
```

2. 创建需要导入的表

在 Doris 中，创建被导入的表，具体语法如下

```
CREATE TABLE testdb.test_streamload(  
  user_id          BIGINT      NOT NULL COMMENT "用户 ID",  
  name             VARCHAR(20) COMMENT "用户姓名",  
  age              INT         COMMENT "用户年龄"  
)  
DUPLICATE KEY(user_id)  
DISTRIBUTED BY HASH(user_id) BUCKETS 10;
```

3. 创建 Routine Load 导入作业

在 Doris 中，使用 CREATE ROUTINE LOAD 命令，创建导入作业

```
CREATE ROUTINE LOAD testdb.example_routine_load_json ON test_routineload_tbl
COLUMNS(user_id,name,age)
PROPERTIES(
  "format"="json",
  "jsonpaths"=["\"$.user_id\"\",\"$.name\"\",\"$.age\""]
)
FROM KAFKA(
  "kafka_broker_list" = "192.168.88.62:9092",
  "kafka_topic" = "test-routine-load-json",
  "property.kafka_default_offsets" = "OFFSET_BEGINNING"
);
```

查看导入状态

在 Doris 中，可以查看 Routine Load 的导入作业情况和导入任务情况：

- 导入作业：主要用于查看导入任务目标表、子任务数量、导入延迟状态、导入配置与导入结果等信息；
- 导入任务：主要用于查看导入的子任务状态、消费进度以及下发的 BE 节点。

01 查看导入运行任务

可以通过 [SHOW ROUTINE LOAD](#) 命令查看导入作业情况。SHOW ROUTINE LOAD 描述了当前作业的基本情况，如导入目标表、导入延迟状态、导入配置信息、导入错误信息等。

如通过以下命令可以查看 testdb.example_routine_load_csv 的任务情况：

```
mysql> SHOW ROUTINE LOAD FOR testdb.example_routine_load\G
***** 1. row *****
      Id: 12025
     Name: example_routine_load
  CreateTime: 2024-01-15 08:12:42
   PauseTime: NULL
    EndTime: NULL
     DbName: default_cluster:testdb
   TableName: test_routineload_tbl
 IsMultiTable: false
       State: RUNNING
 DataSourceType: KAFKA
 CurrentTaskNum: 1
   JobProperties:
{"max_batch_rows":"20000","timezone":"America/New_York","send_batch_parallelism":"1","load_to_single_tablet":
:"false","column_separator":"","","line_delimiter":"\n","current_concurrent_number":"1","delete":"*","partial
_columns":"false","merge_type":"APPEND","exec_mem_limit":"2147483648","strict_mode":"false","jsonpaths":"","m
ax_batch_interval":"10","max_batch_size":"104857600","fuzzy_parse":"false","partitions":"*","columnToColumnEx
pr":"user_id,name,age","whereExpr":"*","desired_concurrent_number":"5","precedingFilter":"*","format":"csv","
max_error_number":"0","max_filter_ratio":"1.0","json_root":"","strip_outer_array":"false","num_as_string":"fa
lse"}
 DataSourceProperties: {"topic":"test-topic","currentKafkaPartitions":"0","brokerList":"192.168.88.62:9092"}
   CustomProperties: {"kafka_default_offsets":"OFFSET_BEGINNING","group.id":"example_routine_load_73daf600-
884e-46c0-a02b-4e49fdf3b4dc"}
      Statistic: {"receivedBytes":28,"runningTxns":
[],"errorRows":0,"committedTaskNum":3,"loadedRows":3,"loadRowsRate":0,"abortedTaskNum":0,"errorRowsAfterResum
ed":0,"totalRows":3,"unselectedRows":0,"receivedBytesRate":0,"taskExecuteTimeMs":30069}
        Progress: {"0":"2"}
          Lag: {"0":0}
 ReasonOfStateChanged:
```

```
ErrorLogUrls:
  OtherMsg:
    User: root
    Comment:
1 row in set (0.00 sec)
```

02 查看导入运行作业

可以通过 [SHOW ROUTINE LOAD TASK](#) 命令查看导入子任务情况。SHOW ROUTINE LOAD TASK 描述了当前作业下的子任务信息，如子任务状态，下发 BE id 等信息。

如通过以下命令可以查看 testdb.example_routine_load_csv 的任务情况：

```
mysql> SHOW ROUTINE LOAD TASK WHERE jobname = 'example_routine_load_csv';
+-----+-----+-----+-----+-----+-----+-----+-----+
+-----+-----+-----+-----+-----+-----+-----+-----+
| TaskId | TxnId | TxnStatus | JobId | CreateTime | ExecuteStartTime |
+-----+-----+-----+-----+-----+-----+-----+-----+
| 8cf47e6a68ed4da3-8f45b431db50e466 | 195 | PREPARE | 12177 | 2024-01-15 12:20:41 | 2024-01-15 12:21:01 |
20 | 10429 | {"4":1231,"9":2603} |
| f2d4525c54074aa2-b6478cf8daaeb393 | 196 | PREPARE | 12177 | 2024-01-15 12:20:41 | 2024-01-15 12:21:01 |
20 | 12109 | {"1":1225,"6":1216} |
| cb870f1553864250-975279875a25fab6 | -1 | NULL | 12177 | 2024-01-15 12:20:52 | NULL |
20 | -1 | {"2":7234,"7":4865} |
| 68771fd8a1824637-90a9dac2a7a0075e | -1 | NULL | 12177 | 2024-01-15 12:20:52 | NULL |
20 | -1 | {"3":1769,"8":2982} |
| 77112dfea5e54b0a-a10eab3d5b19e565 | 197 | PREPARE | 12177 | 2024-01-15 12:21:02 | 2024-01-15 12:21:02 |
20 | 12098 | {"0":3000,"5":2622} |
+-----+-----+-----+-----+-----+-----+-----+-----+
+-----+-----+-----+-----+-----+-----+-----+-----+
```

暂停导入作业

可以通过 [PAUSE ROUTINE LOAD](#) 命令暂停导入作业。暂停导入作业后，会进入 PAUSED 状态，但导入作业并未终止，可以通过 RESUME ROUTINE LOAD 命令重启导入作业。

如通过以下命令可以暂停 testdb.example_routine_load_csv 导入作业：

```
PAUSE ROUTINE LOAD FOR testdb.example_routine_load_csv;
```

恢复导入作业

可以通过 [RESUME ROUTINE LOAD](#) 命令恢复导入作业。

如通过以下命令可以恢复 testdb.example_routine_load_csv 导入作业：

```
RESUME ROUTINE LOAD FOR testdb.example_routine_load_csv;
```


修改导入作业

可以通过 [ALTER ROUTINE LOAD](#) 命令修改已创建的导入作业。在修改导入作业前，需要使用 PAUSE ROUTINE LOAD 暂停导入作业，修改后需要使用 RESUME ROUTINE LOAD 恢复导入作业。

如通过以下命令可以修改期望导入任务并行度参数 desired_concurrent_number，并修改 Kafka Topic 信息：

```
ALTER ROUTINE LOAD FOR testdb.example_routine_load_csv
PROPERTIES(
    "desired_concurrent_number" = "3"
)
FROM KAFKA(
    "kafka_broker_list" = "192.168.88.60:9092",
    "kafka_topic" = "test-topic"
);
```

取消导入作业

可以通过 [STOP ROUTINE LOAD](#) 命令停止并删除 Routine Load 导入作业。删除后的导入作业无法被恢复，也无法通过 SHOW ROUTINE LOAD 命令查看。

可以通过以下命令停止并删除导入作业 testdb.example_routine_load_csv：

```
STOP ROUTINE LOAD FOR testdb.example_routine_load_csv;
```

参考手册

导入命令

创建一个 Routine Load 常驻导入作业语法如下：

```
CREATE ROUTINE LOAD [<db_name>.<job_name> [ON <tbl_name>]
[merge_type]
[load_properties]
[job_properties]
FROM KAFKA [data_source_properties]
[COMMENT "<comment>"]
```

创建导入作业模块说明如下：

模块	说明
db_name	指定创建导入任务的数据库。
job_name	指定创建的导入任务名称，同一个 database 不能有名字相同的任务。
tbl_name	指定需要导入的表的名称，可选参数，如果不指定，则采用动态表的方式，这个时候需要 Kafka 中的数据包含表名的信息。
merge_type	数据合并类型。默认值为 APPEND。 merge_type 有三种选项： - APPEND：追加导入方式； - MERGE：合并导入方式； - DELETE：导入的数据皆为需要删除的数据。

模块	说明
load_properties	导入描述模块，包括以下组成部分： - colum_spearator 子句 - columns_mapping 子句 - preceding_filter 子句 - where_predicates 子句 - partitions 子句 - delete_on 子句 - order_by 子句
job_properties	用于指定 Routine Load 的通用导入参数。
data_source_properties	用于描述 Kafka 数据源属性。
comment	用于描述导入作业的备注信息。

导入参数说明

01 FE 配置参数

max_routine_load_task_concurrent_num

- 默认值：256
- 动态配置：是
- FE Master 独有配置：是
- 参数描述：限制 Routine Load 的导入作业最大子并发数量。建议维持在默认值。如果设置过大，可能导致并发任务数过多，占用集群资源。

max_routine_load_task_num_per_be

- 默认值：1024
- 动态配置：是
- FE Master 独有配置：是
- 参数描述：每个 BE 限制的最大并发 Routine Load 任务数。max_routine_load_task_num_per_be 应该小 routine_load_thread_pool_size 于参数。

max_routine_load_job_num

- 默认值：100
- 动态配置：是
- FE Master 独有配置：是
- 参数描述：限制最大 Routine Load 作业数，包括 NEED_SCHEDULED, RUNNING, PAUSE

max_tolerable_backend_down_num

- 默认值：0

- 动态配置：是
- FE Master 独有配置：是
- 参数描述：只要有一个 BE 宕机，Routine Load 就无法自动恢复。在满足某些条件时，Doris 可以将 PAUSED 的任务重新调度，转换为 RUNNING 状态。该参数为 0 表示只有所有 BE 节点都是 alive 状态才允许重新调度。

period_of_auto_resume_min

- 默认值：5（分钟）
- 动态配置：是
- FE Master 独有配置：是
- 参数描述：自动恢复 Routine Load 的周期

02 BE 配置参数

max_consumer_num_per_group

- 默认值：3
- 动态配置：是
- 描述：一个子任务重最多生成几个 consumer 消费数据。对于 Kafka 数据源，一个 consumer 可能消费一个或多个 Kafka Partition。假设一个任务需要消费 6 个 Kafka Partitio，则会生成 3 个 consumer，每个 consumer 消费 2 个 partition。如果只有 2 个 partition，则只会生成 2 个 consumer，每个 consumer 消费 1 个 partition。

03 导入配置参数

在创建 Routine Load 作业时，可以通过 CREATE ROUTINE LOAD 命令指定不同模块的导入配置参数。

tbl_name 子句

指定需要导入的表的名称，可选参数。

如果不指定，则采用动态表的方式，这个时候需要 Kafka 中的数据包含表名的信息。目前仅支持从 Kafka 的 Value 中获取动态表名，且需要符合这种格式：以 json 为例：table_name|{"col1": "val1", "col2": "val2"}，其中 tbl_name 为表名，以 | 作为表名和表数据的分隔符。csv 格式的数据也是类似的，如：table_name|val1,val2,val3。注意，这里的 table_name 必须和 Doris 中的表名一致，否则会导致导入失败。注意，动态表不支持后面介绍的 column_mapping 配置。

merge_type 子句

可以通过 merge_type 模块指定数据合并的类型。merge_type 有三种选项：

- APPEND：追加导入方式
- MERGE：合并导入方式。仅适用于 Unique Key 模型。需要配合 [DELETE ON] 模块，以标注 Delete Flag 列
- DELETE：导入的数据皆为需要删除的数据

load_properties 子句

可以通过 load_properties 模块描述导入数据的属性，具体语法如下

```
[COLUMNS TERMINATED BY <column_separator>],  
[COLUMNS (<column1_name>[, <column2_name>, <column_mapping>, ...]),]  
[WHERE <where_expr>],  
[PARTITION(<partition1_name>, [<partition2_name>, <partition3_name>, ...]),]  
[DELETE ON <delete_expr>],  
[ORDER BY <order_by_column1>[, <order_by_column2>, <order_by_column3>, ...]]
```

具体模块对应参数如下：

子模块	参数	说明
COLUMNS TERMINATED BY		用于指定列分隔符，默认为 \t。例如需要指定逗号为分隔符，可以使用以下命令：COLUMNS TERMINATED BY "," 对于空值处理，需要注意以下事项： - 空值 (null) 需要用 \n 表示，a,\n,b 数据表示中间列是一个空值 (null) - 空字符串 (") 直接将数据置空，a,,b 数据表示中间列是一个空字符串 (")
COLUMNS		用于指定对应的列名例如需要指定导入列 (k1, k2, k3)，可以使用以下命令：COLUMNS(k1, k2, k3)在以下情况下可以缺省 COLUMNS 子句： - CSV 中的列与表中的列一一对应 - JSON 中的 key 列与表中的列名相同
		在导入过程中，可以通过列映射进行列的过滤和转换。如在导入的过程中，目标列需要基于数据源的某一列进行衍生计算，目标列 k4 基于 k3 列使用公式 $k3+1$ 计算得出，需要可以使用以下命令：COLUMNS(k1, k2, k3, k4 = k3 + 1)详细内容可以参考 数据转换
WHERE		指定 where_expr 可以根据条件过滤导入的数据源。如只希望导入 age > 30 的数据源，可以使用以下命令：WHERE age > 30
PARTITION		指定导入目标表中的哪些 partition。如果不指定，会自动导入对应的 partition 中。如希望导入目标表 p1 与 p2 分区，可以使用以下命令：PARTITION(p1, p2)
DELETE ON		在 MERGE 导入模式下，使用 delete_expr 标记哪些列需要被删除。如需要在 MERGE 时删除 age > 30 的列，可以使用，可以使用以下命令：DELETE ON age > 30
ORDER BY		针对 Unique Key 模型生效。用于指定导入数据中的 Sequence Column 列，以保证数据的顺序。如在 Unique Key 表导入时，需要指定导入的 Sequence Column 为 create_time，可以使用以下命令：ORDER BY create_time 针对与 Unique Key 模型 Sequence Column 列的描述，可以参考文档 数据更新/Sequence 列

job_properties 子句

在创建 Routine Load 导入作业时，可以指定 job_properties 子句以指定导入作业的属性。语法如下：

```
PROPERTIES ("<key1>" = "<value1>"[, "<key2>" = "<value2>" ...])
```

job_properties 子句具体参数选项如下：

参数	说明
desired_concurrent_number	<p>默认值：256</p> <p>参数描述：单个导入子任务（load task）期望的并发度，修改 Routine Load 导入作业切分的期望导入子任务数量。在导入过程中，期望的子任务并发度可能不等于实际并发度。实际的并发度会根据集群的节点数、负载情况，以及数据源的情况综合考虑，使用公式以下可以计算出实际的导入子任务数：</p> $\min(\text{topic_partition_num}, \text{desired_concurrent_number}, \text{max_routine_load_task_concurrent_num})$ <p>其中：</p> <ul style="list-style-type: none">- topic_partition_num 表示 Kafka Topic 的 partition 数量- desired_concurrent_number 表示设置的参数大小- max_routine_load_task_concurrent_num 为 FE 中设置 Routine Load 最大任务并行度的参数
max_batch_interval	<p>每个子任务的最大运行时间，单位是秒，必须大于 0，默认值为 60(s)。</p> <p>max_batch_interval/max_batch_rows/max_batch_size 共同形成子任务执行阈值。任一参数达到阈值，导入子任务结束，并生成新的导入子任务。</p>
max_batch_rows	<p>每个子任务最多读取的行数。必须大于等于 200000。默认是 200000(2.0.13 及更高版本为 20000000)。max_batch_interval/max_batch_rows/max_batch_size 共同形成子任务执行阈值。任一参数达到阈值，导入子任务结束，并生成新的导入子任务。</p>
max_batch_size	<p>每个子任务最多读取的字节数。单位是字节，范围是 100MB 到 10GB。默认是 100MB(2.0.13 及更高版本为 1G)。max_batch_interval/max_batch_rows/max_batch_size 共同形成子任务执行阈值。任一参数达到阈值，导入子任务结束，并生成新的导入子任务。</p>
max_error_number	<p>采样窗口内，允许的最大错误行数。必须大于等于 0。默认是 0，即不允许有错误行。采样窗口为 max_batch_rows * 10。即如果在采样窗口内，错误行数大于 max_error_number，则会导致例行作业被暂停，需要人工介入检查数据质量问题，通过 SHOW ROUTINE LOAD 命令中 ErrorLogUrls 检查数据的质量问题。被 where 条件过滤掉的行不算错误行。</p>
strict_mode	<p>是否开启严格模式，默认为关闭。严格模式表示对于导入过程中的列类型转换进行严格过滤。如果开启后，非空原始数据的列类型变换如果结果为 NULL，则会被过滤。</p> <p>严格模式过滤策略如下：</p> <ul style="list-style-type: none">- 某衍生列（由函数转换生成而来），Strict Mode 对其不产生影响- 当列类型需要转换，错误的数据类型将被过滤掉，在 SHOW ROUTINE LOAD 的 ErrorLogUrls 中查看因为数据类型错误而被过滤掉的列- 对于导入的某列类型包含范围限制的，如果原始数据能正常通过类型转换，但无法通过范围限制的，strict mode 对其也不产生影响。例如：如果类型是 decimal(1,0)，原始数据为 10，则属于可以通过类型转换但不在列声明的范围内。这种数据 strict 对其不产生影响。详细内容参考严格模式。
timezone	<p>指定导入作业所使用的时区。默认为使用 Session 的 timezone 参数。该参数会影响所有导入涉及的和时区有关的函数结果。</p>
format	<p>指定导入数据格式，默认是 csv，支持 json 格式。</p>
jsonpaths	<p>当导入数据格式为 JSON 时，可以通过 jsonpaths 指定抽取 Json 数据中的字段。例如通过以下命令指定导入 jsonpaths: "jsonpaths" = "[\"\$.userid\", \"\$.username\", \"\$.age\", \"\$.city\"]"</p>
json_root	<p>当导入数据格式为 json 时，可以通过 json_root 指定 Json 数据的根节点。Doris 将通过 json_root 抽取根节点的元素进行解析。默认为空。例如通过一下命令指定导入 Json 根节点: "json_root" = "\$.RECORDS"</p>

参数	说明
strip_outer_array	当导入数据格式为 json 时，strip_outer_array 为 true 表示 Json 数据以数组的形式展现，数据中的每一个元素将被视为一行数据。默认值是 false。通常情况下，Kafka 中的 Json 数据可能以数组形式表示，即在最外层中包含中括号 []，此时，可以指定 "strip_outer_array" = "true"，以数组模式消费 Topic 中的数据。如以下数据会被解析成两行： [{"user_id":1,"name":"Emily","age":25}, {"user_id":2,"name":"Benjamin","age":35}]
send_batch_parallelism	用于设置发送批量数据的并行度。如果并行度的值超过 BE 配置中的 max_send_batch_parallelism_per_job，那么作为协调点的 BE 将使用 max_send_batch_parallelism_per_job 的值。
load_to_single_tablet	支持一个任务只导入数据到对应分区的一个 tablet，默认值为 false，该参数只允许在对带有 random 分桶的 olap 表导数的时候设置。
partial_columns	指定是否开启部分列更新功能。默认值为 false。该参数只允许在表模型为 Unique 且采用 Merge on Write 时设置。一流多表不支持此参数。具体参考文档 部分列更新
max_filter_ratio	采样窗口内，允许的最大过滤率。必须在大于等于 0 到小于等于 1 之间。默认值是 1.0，表示可以容忍任何错误行。采样窗口为 max_batch_rows * 10。即如果在采样窗口内，错误行数/总行数大于 max_filter_ratio，则会导致例行作业被暂停，需要人工介入检查数据质量问题。被 where 条件过滤掉的行不算错误行。
enclose	指定包围符。当 csv 数据字段中含有行分隔符或列分隔符时，为防止意外截断，可指定单字节字符作为包围符起到保护作用。例如列分隔符为“;”，包围符为“””，数据为"a,b,c”，则“b,c”会被解析为一个字段。
escape	指定转义符。用于转义在字段中出现的与包围符相同的字符。例如数据为"a,b,'c'”，包围符为“””，希望“b,'c’被作为一个字段解析，则需要指定单字节转义符，例如\，将数据修改为 a,'b,\'c'。

04 data_source_properties 子句

在创建 Routine Load 导入作业时，可以指定 data_source_properties 子句以指定 Kafka 数据源的属性。语法如下：

```
FROM KAFKA ("<key1>" = "<value1>"[, "<key2>" = "<value2>" ...])
```

data_source_properties 子句具体参数选项如下：

参数	说明
kafka_broker_list	指定 Kafka 的 broker 连接信息。格式为 <kafka_broker_ip>:<kafka port>。多个 broker 之间以逗号分隔。例如在 Kafka Broker 中默认端口号为 9092，可以使用以下命令指定 Broker List: "kafka_broker_list" = "<broker1_ip>:9092,<broker2_ip>:9092"
kafka_topic	指定要订阅的 Kafka 的 topic。一个导入作业仅能消费一个 Kafka Topic。
kafka_partitions	指定需要订阅的 Kafka Partition。如果不指定，则默认消费所有分区。

参数	说明
kafka_offsets	待消费的 Kafka Partition 中起始消费点 (offset)。如果指定时间，则会从大于等于该时间的最近一个 offset 处开始消费。offset 可以指定从大于等于 0 的具体 offset，也可以使用以下格式： - OFFSET_BEGINNING: 从有数据的位置开始订阅。 - OFFSET_END: 从末尾开始订阅。 - 时间格式，如：“2021-05-22 11:00:00” 如果没有指定，则默认从 OFFSET_END 开始订阅 topic 下的所有 partition。 可以指定多个起始消费点，使用逗号分隔，如：“kafka_offsets” = "101,0,OFFSET_BEGINNING,OFFSET_END"或者"kafka_offsets" = "2021-05-22 11:00:00,2021-05-22 11:00:00" 注意，时间格式不能和 OFFSET 格式混用。
property	指定自定义 kafka 参数。功能等同于 kafka shell 中“-property”参数。当参数的 Value 为一个文件时，需要在 Value 前加上关键词：“FILE:”。创建文件可以参考 CREATE FILE 命令文档。更多支持的自定义参数，可以参考 librdkafka 的官方 CONFIGURATION 文档中，client 端的配置项。如：“property.client.id” = “12345”“property.group.id” = “group_id_0”“property.ssl.ca.location” = “FILE:ca.pem”

通过配置 data_source_properties 中的 kafka property 参数，可以配置安全访问选项。目前 Doris 支持多种 Kafka 安全协议，如 plaintext（默认）、SSL、PLAIN、Kerberos 等。

导入状态

通过 SHOW ROUTINE LOAD 命令可以查看导入作业的状态，具体语法如下：

```
SHOW [ALL] ROUTINE LOAD [FOR jobName];
```

如通过 SHOW ROUTINE LOAD 会返回以下结果集示例：

```
mysql> SHOW ROUTINE LOAD FOR testdb.example_routine_load\G
***** 1. row *****
      Id: 12025
      Name: example_routine_load
    CreateTime: 2024-01-15 08:12:42
      PauseTime: NULL
      EndTime: NULL
      DbName: default_cluster:testdb
      TableName: test_routineload_tbl
    IsMultiTable: false
        State: RUNNING
    DataSourceType: KAFKA
    CurrentTaskNum: 1
      JobProperties:
{"max_batch_rows":"200000","timezone":"America/New_York","send_batch_parallelism":"1","load_to_single_tablet":
:"false","column_separator":",","line_delimiter":"\n","current_concurrent_number":"1","delete":"*","partial
_columns":"false","merge_type":"APPEND","exec_mem_limit":"2147483648","strict_mode":"false","jsonpaths":"","m
ax_batch_interval":"10","max_batch_size":"104857600","fuzzy_parse":"false","partitions":"*","columnToColumnEx
pr":"user_id,name,age","whereExpr":"*","desired_concurrent_number":"5","precedingFilter":"*","format":"csv","
max_error_number":"0","max_filter_ratio":"1.0","json_root":"","strip_outer_array":"false","num_as_string":"fa
lse"}
DataSourceProperties: {"topic":"test-topic","currentKafkaPartitions":"0","brokerList":"192.168.88.62:9092"}
  CustomProperties: {"kafka_default_offsets":"OFFSET_BEGINNING","group.id":"example_routine_load_73daf600-
884e-46c0-a02b-4e49fdf3b4dc"}
      Statistic: {"receivedBytes":28,"runningTxns":
[],"errorRows":0,"committedTaskNum":3,"loadedRows":3,"loadRowsRate":0,"abortedTaskNum":0,"errorRowsAfterResum
ed":0,"totalRows":3,"unselectedRows":0,"receivedBytesRate":0,"taskExecuteTimeMs":30069}
      Progress: {"0":"2"}
```

```
Lag: {"0":0}
ReasonOfStateChanged:
  ErrorLogUrls:
    OtherMsg:
      User: root
      Comment:
1 row in set (0.00 sec)
```

具体显示结果说明如下：

结果列	列说明
Id	作业 ID。由 Doris 自动生成。
Name	作业名称。
CreateTime	作业创建时间。
PauseTime	最近一次作业暂停时间。
EndTime	作业结束时间。
DbName	对应数据库名称
TableName	对应表名称。多表的情况下由于是动态表，因此不显示具体表名，会显示 multi-table。
IsMultiTbl	是是否为多表
State	作业运行状态，有 5 种状态 - NEED_SCHEDULE：作业等待被调度。在 CREATE ROUTINE LOAD 或 RESUME ROUTINE LOAD 后，作业会先进入到 NEED_SCHEDULE 状态； - RUNNING：作业运行中； - PAUSED：作业被暂停，可以通过 RESUME ROUTINE LOAD 恢复导入作业； - STOPPED：作业已结束，无法被重启； - CANCELLED：作业已取消。
DataSourceType	数据源类型：KAFKA。
CurrentTaskNum	当前子任务数量。
JobProperties	作业配置详情。
DataSourceProperties	数据源配置详情。
CustomProperties	自定义配置。
Statistic	作业运行状态统计信息。
Progress	作业运行进度。对于 Kafka 数据源，显示每个分区当前已消费的 offset。如 {"0":2"} 表示 Kafka 分区 0 的消费进度为 2。
Lag	作业延迟状态。对于 Kafka 数据源，显示每个分区的消费延迟。如 {"0":10} 表示 Kafka 分区 0 的消费延迟为 10。
ReasonOfStateChanged	作业状态变更的原因
ErrorLogUrls	被过滤的质量不合格的数据的查看地址
OtherMsg	其他错误信息

导入示例

CSV 格式导入

设置导入最大容错率

1. 导入数据样例

```
1,Benjamin,18
2,Emily,20
3,Alexander,22
```

2. 建表结构

```
CREATE TABLE demo.routine_test01 (
  id      INT          NOT NULL COMMENT "用户 id",
  name    VARCHAR(30)  NOT NULL COMMENT "名字",
  age     INT          COMMENT "年纪"
)
DUPLICATE KEY(`id`)
DISTRIBUTED BY HASH(`id`) BUCKETS 1;
```

3. 导入命令

```
CREATE ROUTINE LOAD demo.kafka_job01 ON routine_test01
  COLUMNS TERMINATED BY ",",
  COLUMNS(id, name, age)
  PROPERTIES
  (
    "desired_concurrent_number"="1",
    "max_filter_ratio"="0.5",
    "strict_mode" = "false"
  )
FROM KAFKA
(
  "kafka_broker_list" = "10.16.10.6:9092",
  "kafka_topic" = "routineLoad01",
  "property.group.id" = "kafka_job01",
  "property.kafka_default_offsets" = "OFFSET_BEGINNING"
);
```

4. 导入结果

```
mysql> select * from routine_test01;
+-----+-----+-----+
| id  | name    | age |
+-----+-----+-----+
| 1   | Benjamin | 18  |
| 2   | Emily    | 20  |
| 3   | Alexander | 22  |
+-----+-----+-----+
3 rows in set (0.01 sec)
```

从指定消费点消费数据

1. 导入数据样例

```
1,Benjamin,18
2,Emily,20
3,Alexander,22
4,Sophia,24
5,William,26
6,Charlotte,28
```

2. 建表结构

```
CREATE TABLE demo.routine_test02 (
  id      INT      NOT NULL COMMENT "用户 id",
  name    VARCHAR(30) NOT NULL COMMENT "名字",
  age     INT
)
DUPLICATE KEY(`id`)
DISTRIBUTED BY HASH(`id`) BUCKETS 1;
```

3. 导入命令

```
CREATE ROUTINE LOAD demo.kafka_job02 ON routine_test02
  COLUMNS TERMINATED BY ",",
  COLUMNS(id, name, age)
  PROPERTIES
  (
    "desired_concurrent_number"="1",
    "strict_mode" = "false"
  )
FROM KAFKA
(
  "kafka_broker_list" = "10.16.10.6:9092",
  "kafka_topic" = "routineLoad02",
  "property.group.id" = "kafka_job",
  "kafka_partitions" = "0",
  "kafka_offsets" = "3"
);
```

4. 导入结果

```
mysql> select * from routine_test02;
+-----+-----+-----+
| id  | name      | age |
+-----+-----+-----+
| 4   | Sophia    | 24  |
| 5   | William   | 26  |
| 6   | Charlotte | 28  |
+-----+-----+-----+
3 rows in set (0.01 sec)
```

指定 Consumer Group 的 group.id 与 client.id

1. 导入数据样例

```
1,Benjamin,18
2,Emily,20
3,Alexander,22
```

2. 建表结构

```
CREATE TABLE demo.routine_test03 (  
  id      INT      NOT NULL  COMMENT "用户 id",  
  name    VARCHAR(30) NOT NULL COMMENT "名字",  
  age     INT  
)  
DUPLICATE KEY(`id`)  
DISTRIBUTED BY HASH(`id`) BUCKETS 1;
```

3. 导入命令

```
CREATE ROUTINE LOAD demo.kafka_job03 ON routine_test03  
  COLUMNS TERMINATED BY ",",  
  COLUMNS(id, name, age)  
  PROPERTIES  
  (  
    "desired_concurrent_number"="1",  
    "strict_mode" = "false"  
  )  
FROM KAFKA  
(  
  "kafka_broker_list" = "10.16.10.6:9092",  
  "kafka_topic" = "routineLoad01",  
  "property.group.id" = "kafka_job03",  
  "property.client.id" = "kafka_client_03",  
  "property.kafka_default_offsets" = "OFFSET_BEGINNING"  
);
```

4. 导入结果

```
mysql> select * from routine_test03;  
+-----+-----+-----+  
| id  | name    | age |  
+-----+-----+-----+  
|  1  | Benjamin | 18  |  
|  2  | Emily   | 20  |  
|  3  | Alexander | 22  |  
+-----+-----+-----+  
3 rows in set (0.01 sec)
```

设置导入过滤条件

1. 导入数据样例

```
1,Benjamin,18  
2,Emily,20  
3,Alexander,22  
4,Sophia,24  
5,William,26  
6,Charlotte,28
```

2. 建表结构

```
CREATE TABLE demo.routine_test04 (  
  id      INT      NOT NULL  COMMENT "用户 id",  
  name    VARCHAR(30) NOT NULL COMMENT "名字",
```

```

        age      INT      COMMENT "年纪"
    )
    DUPLICATE KEY(`id`)
    DISTRIBUTED BY HASH(`id`) BUCKETS 1;

```

3. 导入命令

```

CREATE ROUTINE LOAD demo.kafka_job04 ON routine_test04
    COLUMNS TERMINATED BY ",",
    COLUMNS(id, name, age),
    WHERE id >= 3
    PROPERTIES
    (
        "desired_concurrent_number"="1",
        "strict_mode" = "false"
    )
    FROM KAFKA
    (
        "kafka_broker_list" = "10.16.10.6:9092",
        "kafka_topic" = "routineLoad04",
        "property.group.id" = "kafka_job04",
        "property.kafka_default_offsets" = "OFFSET_BEGINNING"
    );

```

4. 导入结果

```

mysql> select * from routine_test04;
+-----+-----+-----+
| id  | name      | age |
+-----+-----+-----+
| 4   | Sophia    | 24  |
| 5   | William   | 26  |
| 6   | Charlotte | 28  |
+-----+-----+-----+
3 rows in set (0.01 sec)

```

导入指定分区数据

1. 导入数据样例

```

1,Benjamin,18,2024-02-04 10:00:00
2,Emily,20,2024-02-05 11:00:00
3,Alexander,22,2024-02-06 12:00:00

```

2. 建表结构

```

CREATE TABLE demo.routine_test05 (
    id      INT      NOT NULL COMMENT "id",
    name    VARCHAR(30) NOT NULL COMMENT "名字",
    age     INT      COMMENT "年纪",
    date    DATETIME COMMENT "时间"
)
PARTITION BY RANGE(date) ()
DISTRIBUTED BY HASH(date)
PROPERTIES
(
    "replication_num" = "1",
    "dynamic_partition.enable" = "true",

```

```

        "dynamic_partition.time_unit" = "DAY",
        "dynamic_partition.start" = "-2",
        "dynamic_partition.end" = "3",
        "dynamic_partition.prefix" = "p",
        "dynamic_partition.buckets" = "1"
    );

```

3. 导入命令

```

CREATE ROUTINE LOAD demo.kafka_job05 ON routine_test05
    COLUMNS TERMINATED BY ",",
    COLUMNS(id, name, age,date),
    PARTITION(p20240205)
    PROPERTIES
    (
        "desired_concurrent_number"="1",
        "strict_mode" = "false"
    )
FROM KAFKA
(
    "kafka_broker_list" = "10.16.10.6:9092",
    "kafka_topic" = "routineLoad05",
    "property.group.id" = "kafka_job05",
    "property.kafka_default_offsets" = "OFFSET_BEGINNING"
);

```

4. 导入结果

```

mysql> select * from routine_test05;
+-----+-----+-----+-----+
| id   | name  | age  | date                |
+-----+-----+-----+-----+
| 2    | Emily | 20   | 2024-02-05 11:00:00 |
+-----+-----+-----+-----+
3 rows in set (0.01 sec)

```

设置导入时区

1. 导入数据样例

```

1,Benjamin,18,2024-02-04 10:00:00
2,Emily,20,2024-02-05 11:00:00
3,Alexander,22,2024-02-06 12:00:00

```

2. 建表结构

```

CREATE TABLE demo.routine_test06 (
    id      INT      NOT NULL COMMENT "id",
    name    VARCHAR(30) NOT NULL COMMENT "名字",
    age     INT      COMMENT "年纪",
    date    DATETIME COMMENT "时间"
)
DUPLICATE KEY(id)
DISTRIBUTED BY HASH(id) BUCKETS 1;

```

3. 导入命令

```
CREATE ROUTINE LOAD demo.kafka_job06 ON routine_test06
  COLUMNS TERMINATED BY ",",
  COLUMNS(id, name, age, date)
  PROPERTIES
  (
    "desired_concurrent_number"="1",
    "strict_mode" = "false",
    "timezone"="Asia/Shanghai"
  )
FROM KAFKA
(
  "kafka_broker_list" = "10.16.10.6:9092",
  "kafka_topic" = "routineLoad06",
  "property.group.id" = "kafka_job06",
  "property.kafka_default_offsets" = "OFFSET_BEGINNING"
);
```

4. 导入结果

```
mysql> select * from routine_test06;
+-----+-----+-----+-----+
| id  | name      | age | date           |
+-----+-----+-----+-----+
| 1   | Benjamin  | 18  | 2024-02-05 10:00:00 |
| 2   | Emily     | 20  | 2024-02-05 11:00:00 |
| 3   | Alexander | 22  | 2024-02-05 12:00:00 |
+-----+-----+-----+-----+
3 rows in set (0.00 sec)
```

指定 merge_type 进行 delete 操作

1. 导入数据样例

```
3,Alexander,22
5,William,26
```

导入前表中数据如下

```
mysql> SELECT * FROM routine_test07;
+-----+-----+-----+
| id  | name      | age |
+-----+-----+-----+
| 1   | Benjamin  | 18  |
| 2   | Emily     | 20  |
| 3   | Alexander | 22  |
| 4   | Sophia    | 24  |
| 5   | William   | 26  |
| 6   | Charlotte | 28  |
+-----+-----+-----+
```

2. 建表结构

```
CREATE TABLE demo.routine_test07 (
  id      INT      NOT NULL COMMENT "id",
  name    VARCHAR(30) NOT NULL COMMENT "名字",
  age     INT      COMMENT "年纪",
)
```

```
DUPLICATE KEY(id)
DISTRIBUTED BY HASH(id) BUCKETS 1;
```

3. 导入命令

```
CREATE ROUTINE LOAD demo.kafka_job07 ON routine_test07
WITH DELETE
COLUMNS TERMINATED BY ",",
COLUMNS(id, name, age)
PROPERTIES
(
    "desired_concurrent_number"="1",
    "max_filter_ratio"="0.5",
    "strict_mode" = "false"
)
FROM KAFKA
(
    "kafka_broker_list" = "10.16.10.6:9092",
    "kafka_topic" = "routineLoad07",
    "property.group.id" = "kafka_job07",
    "property.kafka_default_offsets" = "OFFSET_BEGINNING"
);
```

4. 导入结果

```
mysql> SELECT * FROM routine_test07;
```

id	name	age
1	Benjamin	18
2	Emily	20
4	Sophia	24
6	Charlotte	28

指定 merge_type 进行 merge 操作

1. 导入数据样例

```
1,xiaoxiaoli,28
2,xiaoxiaowang,30
3,xiaoxiaoliu,32
4,dadali,34
5,dadawang,36
6,dadaliu,38
```

导入前表中数据如下：

```
mysql> SELECT * FROM routine_test08;
```

id	name	age
1	Benjamin	18
2	Emily	20
3	Alexander	22
4	Sophia	24
5	William	26
6	Charlotte	28

```
+-----+-----+-----+
6 rows in set (0.01 sec)
```

2. 建表结构

```
CREATE TABLE demo.routine_test08 (
  id      INT          NOT NULL COMMENT "id",
  name    VARCHAR(30)  NOT NULL COMMENT "名字",
  age     INT           COMMENT "年纪",
)
DUPLICATE KEY(id)
DISTRIBUTED BY HASH(id) BUCKETS 1;
```

3. 导入命令

```
CREATE ROUTINE LOAD demo.kafka_job08 ON routine_test08
  WITH MERGE
  COLUMNS TERMINATED BY ",",
  COLUMNS(id, name, age),
  DELETE ON id = 2
  PROPERTIES
  (
    "desired_concurrent_number"="1",
    "strict_mode" = "false"
  )
FROM KAFKA
(
  "kafka_broker_list" = "10.16.10.6:9092",
  "kafka_topic" = "routineLoad08",
  "property.group.id" = "kafka_job08",
  "property.kafka_default_offsets" = "OFFSET_BEGINNING"
);
```

4. 导入结果

```
mysql> SELECT * FROM routine_test08;
+-----+-----+-----+
| id | name       | age |
+-----+-----+-----+
| 1  | xiaoxiaoli | 28  |
| 3  | xiaoxiaoliu | 32  |
| 4  | dadali     | 34  |
| 5  | dadawang   | 36  |
| 6  | dadaliu    | 38  |
+-----+-----+-----+
5 rows in set (0.00 sec)
```

指定导入需要 merge 的 sequence 列

1. 导入数据样例

```
1,xiaoxiaoli,28
2,xiaoxiaowang,30
3,xiaoxiaoliu,32
4,dadali,34
5,dadawang,36
6,dadaliu,38
```


导入前表中数据如下：

```
mysql> SELECT * FROM routine_test09;
+-----+-----+-----+
| id | name      | age |
+-----+-----+-----+
| 1 | Benjamin | 18 |
| 2 | Emily    | 20 |
| 3 | Alexander| 22 |
| 4 | Sophia   | 24 |
| 5 | William  | 26 |
| 6 | Charlotte| 28 |
+-----+-----+-----+
6 rows in set (0.01 sec)
```

2. 建表结构

```
CREATE TABLE demo.routine_test08 (
  id      INT      NOT NULL COMMENT "id",
  name    VARCHAR(30) NOT NULL COMMENT "名字",
  age     INT      COMMENT "年纪",
)
DUPLICATE KEY(id)
DISTRIBUTED BY HASH(id) BUCKETS 1
PROPERTIES (
  "function_column.sequence_col" = "age"
);
```

3. 导入命令

```
CREATE ROUTINE LOAD demo.kafka_job09 ON routine_test09
WITH MERGE
COLUMNS TERMINATED BY ",",
COLUMNS(id, name, age),
DELETE ON id = 2,
ORDER BY age
PROPERTIES
(
  "desired_concurrent_number"="1",
  "strict_mode" = "false"
)
FROM KAFKA
(
  "kafka_broker_list" = "10.16.10.6:9092",
  "kafka_topic" = "routineLoad09",
  "property.group.id" = "kafka_job09",
  "property.kafka_default_offsets" = "OFFSET_BEGINNING"
);
```

4. 导入结果

```
mysql> SELECT * FROM routine_test09;
+-----+-----+-----+
| id | name      | age |
+-----+-----+-----+
| 1 | xiaoxiaoli | 28 |
| 3 | xiaoxiaoliu | 32 |
| 4 | dadali     | 34 |
| 5 | dadawang   | 36 |
+-----+-----+-----+
```

```
| 6 | dadaliu | 38 |
+-----+-----+
5 rows in set (0.00 sec)
```

导入完成列影射与衍生列计算

1. 导入数据样例

```
1,Benjamin,18
2,Emily,20
3,Alexander,22
```

2. 建表结构

```
CREATE TABLE demo.routine_test10 (
  id      INT          NOT NULL COMMENT "id",
  name    VARCHAR(30)  NOT NULL COMMENT "名字",
  age     INT          COMMENT "年纪",
  num     INT          COMMENT "数量"
)
DUPLICATE KEY(`id`)
DISTRIBUTED BY HASH(`id`) BUCKETS 1;
```

3. 导入命令

```
CREATE ROUTINE LOAD demo.kafka_job10 ON routine_test10
  COLUMNS TERMINATED BY ",",
  COLUMNS(id, name, age, num=age*10)
  PROPERTIES
  (
    "desired_concurrent_number"="1",
    "max_filter_ratio"="0.5",
    "strict_mode" = "false"
  )
  FROM KAFKA
  (
    "kafka_broker_list" = "10.16.10.6:9092",
    "kafka_topic" = "routineLoad10",
    "property.group.id" = "kafka_job10",
    "property.kafka_default_offsets" = "OFFSET_BEGINNING"
  );
```

4. 导入结果

```
mysql> SELECT * FROM routine_test10;
+-----+-----+-----+-----+
| id | name      | age | num |
+-----+-----+-----+-----+
| 1 | Benjamin  | 18 | 180 |
| 2 | Emily     | 20 | 200 |
| 3 | Alexander | 22 | 220 |
+-----+-----+-----+-----+
3 rows in set (0.01 sec)
```

导入包含包围符的数据

1. 导入数据样例

```
1,"Benjamin",18
2,"Emily",20
3,"Alexander",22
```

2. 建表结构

```
CREATE TABLE demo.routine_test11 (
  id      INT      NOT NULL COMMENT "id",
  name    VARCHAR(30) NOT NULL COMMENT "名字",
  age     INT      COMMENT "年纪",
  num     INT      COMMENT "数量"
)
DUPLICATE KEY(`id`)
DISTRIBUTED BY HASH(`id`) BUCKETS 1;
```

3. 导入命令

```
CREATE ROUTINE LOAD demo.kafka_job12 ON routine_test12
  PROPERTIES
  (
    "desired_concurrent_number"="1",
    "enclose" = "\""
  )
FROM KAFKA
(
  "kafka_broker_list" = "10.16.10.6:9092",
  "kafka_topic" = "routineLoad12",
  "property.group.id" = "kafka_job12",
  "property.kafka_default_offsets" = "OFFSET_BEGINNING"
);
```

4. 导入结果

```
mysql> SELECT * FROM routine_test12;
+-----+-----+-----+-----+
| id  | name      | age  | num  |
+-----+-----+-----+-----+
| 1   | Benjamin  | 18   | 180  |
| 2   | Emily     | 20   | 200  |
| 3   | Alexander | 22   | 220  |
+-----+-----+-----+-----+
3 rows in set (0.02 sec)
```

JSON 格式导入

以简单模式导入 JSON 格式数据

1. 导入数据样例

```
{ "id" : 1, "name" : "Benjamin", "age":18 }
{ "id" : 2, "name" : "Emily", "age":20 }
{ "id" : 3, "name" : "Alexander", "age":22 }
```

2. 建表结构

```
CREATE TABLE demo.routine_test12 (
  id      INT      NOT NULL COMMENT "id",
  name    VARCHAR(30) NOT NULL COMMENT "名字",
  age     INT      COMMENT "年纪",
)
DUPLICATE KEY(`id`)
DISTRIBUTED BY HASH(`id`) BUCKETS 1;
```

3. 导入命令

```
CREATE ROUTINE LOAD demo.kafka_job12 ON routine_test12
  PROPERTIES
  (
    "desired_concurrent_number"="1",
    "format" = "json",
    "strict_mode" = "false"
  )
FROM KAFKA
(
  "kafka_broker_list" = "10.16.10.6:9092",
  "kafka_topic" = "routineLoad12",
  "property.group.id" = "kafka_job12",
  "property.kafka_default_offsets" = "OFFSET_BEGINNING"
);
```

4. 导入结果

```
mysql> select * from routine_test12;
+-----+-----+-----+
| id  | name      | age |
+-----+-----+-----+
| 1  | Benjamin  | 18 |
| 2  | Emily     | 20 |
| 3  | Alexander | 22 |
+-----+-----+-----+
3 rows in set (0.02 sec)
```

匹配模式导入复杂的 JSON 格式数据

1. 导入数据样例

```
{ "name" : "Benjamin", "id" : 1, "num":180 , "age":18 }
{ "name" : "Emily", "id" : 2, "num":200 , "age":20 }
{ "name" : "Alexander", "id" : 3, "num":220 , "age":22 }
```

2. 建表结构

```
CREATE TABLE demo.routine_test13 (
  id      INT      NOT NULL COMMENT "id",
  name    VARCHAR(30) NOT NULL COMMENT "名字",
  age     INT      COMMENT "年纪",
  num     INT      COMMENT "数字"
)
DUPLICATE KEY(`id`)
DISTRIBUTED BY HASH(`id`) BUCKETS 1;
```

3. 导入命令

```
CREATE ROUTINE LOAD demo.kafka_job13 ON routine_test13
  COLUMNS(name, id, num, age)
  PROPERTIES
  (
    "desired_concurrent_number"="1",
    "format" = "json",
    "strict_mode" = "false",
    "jsonpaths" = "[\"$.name\", \"$.id\", \"$.num\", \"$.age\"]"
  )
FROM KAFKA
(
  "kafka_broker_list" = "10.16.10.6:9092",
  "kafka_topic" = "routineLoad13",
  "property.group.id" = "kafka_job13",
  "property.kafka_default_offsets" = "OFFSET_BEGINNING"
);
```

4. 导入结果

```
mysql> select * from routine_test13;
+-----+-----+-----+-----+
| id | name      | age | num |
+-----+-----+-----+-----+
| 1  | Benjamin  | 18  | 180 |
| 2  | Emily     | 20  | 200 |
| 3  | Alexander | 22  | 220 |
+-----+-----+-----+-----+
3 rows in set (0.01 sec)
```

指定 JSON 根节点导入数据

1. 导入数据样例

```
{"id": 1231, "source" :{ "id" : 1, "name" : "Benjamin", "age":18 }}
{"id": 1232, "source" :{ "id" : 2, "name" : "Emily", "age":20 }}
{"id": 1233, "source" :{ "id" : 3, "name" : "Alexander", "age":22 }}
```

2. 建表结构

```
CREATE TABLE demo.routine_test14 (
  id      INT      NOT NULL COMMENT "id",
  name    VARCHAR(30) NOT NULL COMMENT "名字",
  age     INT      COMMENT "年纪",
)
DUPLICATE KEY(`id`)
DISTRIBUTED BY HASH(`id`) BUCKETS 1;
```

3. 导入命令

```
CREATE ROUTINE LOAD demo.kafka_job14 ON routine_test14
  PROPERTIES
  (
    "desired_concurrent_number"="1",
    "format" = "json",
    "strict_mode" = "false",
```

```

        "json_root" = "$.source"
    )
FROM KAFKA
(
    "kafka_broker_list" = "10.16.10.6:9092",
    "kafka_topic" = "routineLoad14",
    "property.group.id" = "kafka_job14",
    "property.kafka_default_offsets" = "OFFSET_BEGINNING"
);

```

4. 导入结果

```

mysql> select * from routine_test14;
+-----+-----+-----+
| id  | name      | age  |
+-----+-----+-----+
| 1   | Benjamin  | 18   |
| 2   | Emily     | 20   |
| 3   | Alexander | 22   |
+-----+-----+-----+
3 rows in set (0.01 sec)

```

导入完成列影射与衍生列计算

1. 导入数据样例

```

{ "id" : 1, "name" : "Benjamin", "age":18 }
{ "id" : 2, "name" : "Emily", "age":20 }
{ "id" : 3, "name" : "Alexander", "age":22 }

```

2. 建表结构

```

CREATE TABLE demo.routine_test15 (
    id      INT          NOT NULL COMMENT "id",
    name    VARCHAR(30)  NOT NULL COMMENT "名字",
    age     INT           COMMENT "年纪",
    num     INT           COMMENT "数字"
)
DUPLICATE KEY(`id`)
DISTRIBUTED BY HASH(`id`) BUCKETS 1;

```

3. 导入命令

```

CREATE ROUTINE LOAD demo.kafka_job15 ON routine_test15
COLUMNS(id, name, age, num=age*10)
PROPERTIES
(
    "desired_concurrent_number"="1",
    "format" = "json",
    "strict_mode" = "false"
)
FROM KAFKA
(
    "kafka_broker_list" = "10.16.10.6:9092",
    "kafka_topic" = "routineLoad15",
    "property.group.id" = "kafka_job15",

```

```
        "property.kafka_default_offsets" = "OFFSET_BEGINNING"
    );
```

4. 导入结果

```
mysql> select * from routine_test15;
+-----+-----+-----+-----+
| id  | name      | age  | num  |
+-----+-----+-----+-----+
| 1   | Benjamin  | 18   | 180  |
| 2   | Emily     | 20   | 200  |
| 3   | Alexander | 22   | 220  |
+-----+-----+-----+-----+
3 rows in set (0.01 sec)
```

导入复杂类型

导入 Array 数据类型

1. 导入数据样例

```
{ "id" : 1, "name" : "Benjamin", "age":18, "array":[1,2,3,4,5]}
{ "id" : 2, "name" : "Emily", "age":20, "array":[6,7,8,9,10]}
{ "id" : 3, "name" : "Alexander", "age":22, "array":[11,12,13,14,15]}
```

2. 建表结构

```
CREATE TABLE demo.routine_test16
(
    id      INT          NOT NULL COMMENT "id",
    name    VARCHAR(30)  NOT NULL COMMENT "名字",
    age     INT           COMMENT "年纪",
    array   ARRAY<int(11)> NULL    COMMENT "测试数组列"
)
DUPLICATE KEY(`id`)
DISTRIBUTED BY HASH(`id`) BUCKETS 1;
```

3. 导入命令

```
CREATE ROUTINE LOAD demo.kafka_job16 ON routine_test16
PROPERTIES
(
    "desired_concurrent_number"="1",
    "format" = "json",
    "strict_mode" = "false"
)
FROM KAFKA
(
    "kafka_broker_list" = "10.16.10.6:9092",
    "kafka_topic" = "routineLoad16",
    "property.group.id" = "kafka_job16",
    "property.kafka_default_offsets" = "OFFSET_BEGINNING"
);
```

4. 导入结果

```
mysql> select * from routine_test16;
```

id	name	age	array
1	Benjamin	18	[1, 2, 3, 4, 5]
2	Emily	20	[6, 7, 8, 9, 10]
3	Alexander	22	[11, 12, 13, 14, 15]

```
3 rows in set (0.00 sec)
```

导入 Map 数据类型

1. 导入数据样例

```
{ "id" : 1, "name" : "Benjamin", "age":18, "map":{"a": 100, "b": 200}}
{ "id" : 2, "name" : "Emily", "age":20, "map":{"c": 300, "d": 400}}
{ "id" : 3, "name" : "Alexander", "age":22, "map":{"e": 500, "f": 600}}
```

2. 建表结构

```
CREATE TABLE demo.routine_test17 (
  id      INT          NOT NULL COMMENT "id",
  name    VARCHAR(30)  NOT NULL COMMENT "名字",
  age     INT          COMMENT "年纪",
  map     Map<STRING, INT> NULL COMMENT "测试列"
)
DUPLICATE KEY(`id`)
DISTRIBUTED BY HASH(`id`) BUCKETS 1;
```

3. 导入命令

```
CREATE ROUTINE LOAD demo.kafka_job17 ON routine_test17
PROPERTIES
(
  "desired_concurrent_number"="1",
  "format" = "json",
  "strict_mode" = "false"
)
FROM KAFKA
(
  "kafka_broker_list" = "10.16.10.6:9092",
  "kafka_topic" = "routineLoad17",
  "property.group.id" = "kafka_job17",
  "property.kafka_default_offsets" = "OFFSET_BEGINNING"
);
```

4. 导入结果

```
mysql> select * from routine_test17;
```

id	name	age	map
1	Benjamin	18	{"a":100, "b":200}
2	Emily	20	{"c":300, "d":400}
3	Alexander	22	{"e":500, "f":600}


```
+-----+-----+-----+-----+
3 rows in set (0.01 sec)
```

导入 Bitmap 数据类型

1. 导入数据样例

```
{ "id" : 1, "name" : "Benjamin", "age":18, "bitmap_id":243}
{ "id" : 2, "name" : "Emily", "age":20, "bitmap_id":28574}
{ "id" : 3, "name" : "Alexander", "age":22, "bitmap_id":8573}
```

2. 建表结构

```
CREATE TABLE demo.routine_test18 (
  id          INT          NOT NULL      COMMENT "id",
  name        VARCHAR(30)  NOT NULL      COMMENT "名字",
  age         INT          COMMENT "年纪",
  bitmap_id   INT          COMMENT "测试",
  device_id   BITMAP       BITMAP_UNION  COMMENT "测试列"
)
AGGREGATE KEY (`id`,`name`,`age`,`bitmap_id`)
DISTRIBUTED BY HASH(`id`) BUCKETS 1;
```

3. 导入命令

```
CREATE ROUTINE LOAD demo.kafka_job18 ON routine_test18
  COLUMNS(id, name, age, bitmap_id, device_id=to_bitmap(bitmap_id))
  PROPERTIES
  (
    "desired_concurrent_number"="1",
    "format" = "json",
    "strict_mode" = "false"
  )
FROM KAFKA
(
  "kafka_broker_list" = "10.16.10.6:9092",
  "kafka_topic" = "routineLoad18",
  "property.group.id" = "kafka_job18",
  "property.kafka_default_offsets" = "OFFSET_BEGINNING"
);
```

4. 导入结果

```
mysql> select id, BITMAP_UNION_COUNT(pv) over(order by id) uv from(
->   select id, BITMAP_UNION(device_id) as pv
->   from routine_test18
-> group by id
-> ) final;
+-----+-----+
| id  | uv  |
+-----+-----+
| 1   | 1   |
| 2   | 2   |
| 3   | 3   |
+-----+-----+
3 rows in set (0.00 sec)
```

导入 HLL 数据类型

1. 导入数据样例

```
2022-05-05,10001, 测试 01, 北京, windows
2022-05-05,10002, 测试 01, 北京, linux
2022-05-05,10003, 测试 01, 北京, macos
2022-05-05,10004, 测试 01, 河北, windows
2022-05-06,10001, 测试 01, 上海, windows
2022-05-06,10002, 测试 01, 上海, linux
2022-05-06,10003, 测试 01, 江苏, macos
2022-05-06,10004, 测试 01, 陕西, windows
```

2. 建表结构

```
create table demo.routine_test19 (
  dt      DATE,
  id      INT,
  name    VARCHAR(10),
  province VARCHAR(10),
  os      VARCHAR(10),
  pv      hll hll_union
)
Aggregate KEY (dt,id,name,province,os)
distributed by hash(id) buckets 10;
```

3. 导入命令

```
CREATE ROUTINE LOAD demo.kafka_job19 ON routine_test19
  COLUMNS TERMINATED BY ",",
  COLUMNS(dt, id, name, province, os, pv=hll_hash(id))
  PROPERTIES
  (
    "desired_concurrent_number"="1",
    "strict_mode" = "false"
  )
FROM KAFKA
(
  "kafka_broker_list" = "10.16.10.6:9092",
  "kafka_topic" = "routineLoad19",
  "property.group.id" = "kafka_job19",
  "property.kafka_default_offsets" = "OFFSET_BEGINNING"
);
```

4. 导入结果

```
mysql> select * from routine_test19;
+-----+-----+-----+-----+-----+-----+
| dt      | id    | name  | province | os      | pv      |
+-----+-----+-----+-----+-----+-----+
| 2022-05-05 | 10001 | 测试 01 | 北京     | windows | NULL    |
| 2022-05-06 | 10001 | 测试 01 | 上海     | windows | NULL    |
| 2022-05-05 | 10002 | 测试 01 | 北京     | linux   | NULL    |
| 2022-05-06 | 10002 | 测试 01 | 上海     | linux   | NULL    |
| 2022-05-05 | 10004 | 测试 01 | 河北     | windows | NULL    |
| 2022-05-06 | 10004 | 测试 01 | 陕西     | windows | NULL    |
| 2022-05-05 | 10003 | 测试 01 | 北京     | macos   | NULL    |
| 2022-05-06 | 10003 | 测试 01 | 江苏     | macos   | NULL    |
+-----+-----+-----+-----+-----+-----+
```

```

8 rows in set (0.01 sec)

mysql> SELECT HLL_UNION_AGG(pv) FROM routine_test19;
+-----+
| hll_union_agg(pv) |
+-----+
|                    4 |
+-----+
1 row in set (0.01 sec)

```

Kafka 安全认证

导入 SSL 认证的 Kafka 数据

1. 导入数据样例

```

{ "id" : 1, "name" : "Benjamin", "age":18 }
{ "id" : 2, "name" : "Emily", "age":20 }
{ "id" : 3, "name" : "Alexander", "age":22 }

```

2. 建表结构

```

CREATE TABLE demo.routine_test20 (
  id      INT      NOT NULL COMMENT "id",
  name    VARCHAR(30) NOT NULL COMMENT "名字",
  age     INT      COMMENT "年纪",
)
DUPLICATE KEY(`id`)
DISTRIBUTED BY HASH(`id`) BUCKETS 1;

```

3. 导入命令

```

CREATE ROUTINE LOAD demo.kafka_job20 ON routine_test20
  PROPERTIES
  (
    "desired_concurrent_number"="1",
    "format" = "json",
    "strict_mode" = "false"
  )
FROM KAFKA
(
  "kafka_broker_list" = "192.168.100.129:9092",
  "kafka_topic" = "routineLoad21",
  "property.group.id" = "kafka_job21",
  "property.kafka_default_offsets" = "OFFSET_BEGINNING",
  "property.security.protocol" = "ssl",
  "property.ssl.ca.location" = "FILE:ca.pem",
  "property.ssl.certificate.location" = "FILE:client.pem",
  "property.ssl.key.location" = "FILE:client.key",
  "property.ssl.key.password" = "ssl_passwd"
);

```

4. 导入结果

```

mysql> select * from routine_test20;
+-----+-----+-----+
| id  | name      | age  |
+-----+-----+-----+

```

```

+-----+-----+-----+
| 1 | Benjamin | 18 |
| 2 | Emily    | 20 |
| 3 | Alexander | 22 |
+-----+-----+-----+
3 rows in set (0.01 sec)

```

导入 Kerberos 认证的 Kafka 数据

1. 导入数据样例

```

{ "id" : 1, "name" : "Benjamin", "age":18 }
{ "id" : 2, "name" : "Emily", "age":20 }
{ "id" : 3, "name" : "Alexander", "age":22 }

```

2. 建表结构

```

CREATE TABLE demo.routine_test21 (
  id      INT      NOT NULL COMMENT "id",
  name    VARCHAR(30) NOT NULL COMMENT "名字",
  age     INT      COMMENT "年纪",
)
DUPLICATE KEY(`id`)
DISTRIBUTED BY HASH(`id`) BUCKETS 1;

```

3. 导入命令

```

CREATE ROUTINE LOAD demo.kafka_job21 ON routine_test21
  PROPERTIES
  (
    "desired_concurrent_number"="1",
    "format" = "json",
    "strict_mode" = "false"
  )
FROM KAFKA
(
  "kafka_broker_list" = "192.168.100.129:9092",
  "kafka_topic" = "routineLoad21",
  "property.group.id" = "kafka_job21",
  "property.kafka_default_offsets" = "OFFSET_BEGINNING",
  "property.security.protocol" = "SASL_PLAINTEXT",
  "property.sasl.kerberos.service.name" = "kafka",
  "property.sasl.kerberos.keytab" = "/etc/krb5.keytab",
  "property.sasl.kerberos.keytab" = "/opt/third/kafka/kerberos/kafka_client.keytab",
  "property.sasl.kerberos.principal" = "clients/stream.dt.local@EXAMPLE.COM"
);

```

4. 导入结果

```

mysql> select * from routine_test21;
+-----+-----+-----+
| id | name    | age |
+-----+-----+-----+
| 1 | Benjamin | 18 |
| 2 | Emily    | 20 |
| 3 | Alexander | 22 |

```

```
+-----+-----+-----+
3 rows in set (0.01 sec)
```

导入 PLAIN 认证的 Kafka 集群

1. 导入数据样例

```
{ "id" : 1, "name" : "Benjamin", "age":18 }
{ "id" : 2, "name" : "Emily", "age":20 }
{ "id" : 3, "name" : "Alexander", "age":22 }
```

2. 建表结构

```
CREATE TABLE demo.routine_test22 (
  id      INT          NOT NULL COMMENT "id",
  name    VARCHAR(30)  NOT NULL COMMENT "名字",
  age     INT          COMMENT "年纪",
)
DUPLICATE KEY(`id`)
DISTRIBUTED BY HASH(`id`) BUCKETS 1;
```

3. 导入命令

```
CREATE ROUTINE LOAD demo.kafka_job22 ON routine_test22
  PROPERTIES
  (
    "desired_concurrent_number"="1",
    "format" = "json",
    "strict_mode" = "false"
  )
FROM KAFKA
(
  "kafka_broker_list" = "192.168.100.129:9092",
  "kafka_topic" = "routineLoad22",
  "property.group.id" = "kafka_job22",
  "property.kafka_default_offsets" = "OFFSET_BEGINNING",
  "property.security.protocol"="SASL_PLAINTEXT",
  "property.sasl.mechanism"="PLAIN",
  "property.sasl.username"="admin",
  "property.sasl.password"="admin"
);
```

4. 导入结果

```
mysql> select * from routine_test22;
+-----+-----+-----+
| id  | name      | age |
+-----+-----+-----+
| 1  | Benjamin  | 18  |
| 2  | Emily     | 20  |
| 3  | Alexander | 22  |
+-----+-----+-----+
3 rows in set (0.02 sec)
```

一流多表导入

为 example_db 创建一个名为 test1 的 Kafka 例行动态多表导入任务。指定列分隔符和 group.id 和 client.id，并且自动默认消费所有分区，且从有数据的位置（OFFSET_BEGINNING）开始订阅。

这里假设需要将 Kafka 中的数据导入到 example_db 中的 tbl1 以及 tbl2 表中，我们创建了一个名为 test1 的例行导入任务，同时将名为 my_topic 的 Kafka 的 Topic 数据同时导入到 tbl1 和 tbl2 中的数据中，这样就可以通过一个例行导入任务将 Kafka 中的数据导入到两个表中。

```
CREATE ROUTINE LOAD example_db.test1
PROPERTIES
(
  "desired_concurrent_number"="3",
  "max_batch_interval" = "20",
  "max_batch_rows" = "300000",
  "max_batch_size" = "209715200",
  "strict_mode" = "false"
)
FROM KAFKA
(
  "kafka_broker_list" = "broker1:9092,broker2:9092,broker3:9092",
  "kafka_topic" = "my_topic",
  "property.group.id" = "xxx",
  "property.client.id" = "xxx",
  "property.kafka_default_offsets" = "OFFSET_BEGINNING"
);
```

这个时候需要 Kafka 中的数据包含表名的信息。目前仅支持从 Kafka 的 Value 中获取动态表名，且需要符合这种格式：以 json 为例：table_name|{"col1": "val1", "col2": "val2"}，其中 tbl_name 为表名，以 | 作为表名和表数据的分隔符。csv 格式的数据也是类似的，如：table_name|val1,val2,val3。注意，这里的 table_name 必须和 Doris 中的表名一致，否则会导致导入失败。注意，动态表不支持后面介绍的 column_mapping 配置。

严格模式导入

为 example_db 的 example_tbl 创建一个名为 test1 的 Kafka 例行导入任务。导入任务为严格模式。

```
CREATE ROUTINE LOAD example_db.test1 ON example_tbl
COLUMNS(k1, k2, k3, v1, v2, v3 = k1 * 100),
PRECEDING FILTER k1 = 1,
WHERE k1 < 100 and k2 like "%doris%"
PROPERTIES
(
  "desired_concurrent_number"="3",
  "max_batch_interval" = "20",
  "max_batch_rows" = "300000",
  "max_batch_size" = "209715200",
  "strict_mode" = "true"
)
FROM KAFKA
(
  "kafka_broker_list" = "broker1:9092,broker2:9092,broker3:9092",
  "kafka_topic" = "my_topic",
  "kafka_partitions" = "0,1,2,3",
  "kafka_offsets" = "101,0,0,200"
);
```

更多帮助

参考 SQL 手册 [Routine Load](#)。也可以在客户端命令行下输入 `HELP ROUTINE LOAD` 获取更多帮助信息。

Insert Into

INSERT INTO 支持将 Doris 查询的结果导入到另一个表中。INSERT INTO 是一个同步导入方式，执行导入后返回导入结果。可以通过请求的返回判断导入是否成功。INSERT INTO 可以保证导入任务的原子性，要么全部导入成功，要么全部导入失败。

主要的 Insert Into 命令包含以下两种：

- INSERT INTO tbl SELECT ...
- INSERT INTO tbl (col1, col2, ...) VALUES (1, 2, ...), (1,3, ...)

使用场景

1. 用户希望仅导入几条假数据，验证一下 Doris 系统的功能。此时适合使用 INSERT INTO VALUES 的语法，语法和 MySQL 一样。不建议在生产环境中使用 INSERT INTO VALUES。
2. 用户希望将已经在 Doris 表中的数据进行 ETL 转换并导入到一个新的 Doris 表中，此时适合使用 INSERT INTO SELECT 语法。
3. 与 Multi-Catalog 外部表机制进行配合，如通过 Multi-Catalog 映射 MySQL 或者 Hive 系统中的表，然后通过 INSERT INTO SELECT 语法将外部表中的数据导入到 Doris 表中存储。
4. 通过 Table Value Function（TVF）功能，可以直接将对象存储或 HDFS 上的文件作为 Table 进行查询，并且支持自动的列类型推断。然后，通过 INSERT INTO SELECT 语法将外部表中的数据导入到 Doris 表中存储。

基本原理

在使用 INSERT INTO 时，需要通过 MySQL 协议发起导入作业给 FE 节点，FE 会生成执行计划，执行计划中前部是查询相关的算子，最后一个是 OlapTableSink 算子，用于将查询结果写到目标表中。执行计划会被发送给 BE 节点执行，Doris 会选定一个节点做为 Coordinator 节点，Coordinator 节点负责接受数据并分发数据到其他节点上。

快速上手

INSERT INTO 通过 MySQL 协议提交和传输。下例以 MySQL 命令行为例，演示通过 INSERT INTO 提交导入作业。

详细语法可以参见 [INSERT INTO](#)。

前置检查

INSERT INTO 需要对目标表的 INSERT 权限。如果没有 INSERT 权限，可以通过 [GRANT](#) 命令给用户授权。

创建导入作业

INSERT INTO VALUES

1. 创建源表

```
CREATE TABLE testdb.test_table(  
  user_id      BIGINT      NOT NULL COMMENT "用户 ID",  
  name         VARCHAR(20)          COMMENT "用户姓名",  
  age          INT           COMMENT "用户年龄"  
)  
DUPLICATE KEY(user_id)  
DISTRIBUTED BY HASH(user_id) BUCKETS 10;
```

2. 使用 INSERT INTO VALUES 向源表导入数据（不推荐在生产环境中使用）

```
INSERT INTO testdb.test_table (user_id, name, age)  
VALUES (1, "Emily", 25),  
      (2, "Benjamin", 35),  
      (3, "Olivia", 28),  
      (4, "Alexander", 60),  
      (5, "Ava", 17);
```

INSERT INTO 是一种同步导入方式，导入结果会直接返回给用户。

```
Query OK, 5 rows affected (0.308 sec)  
{'label': 'label_3e52da787aab4222_9126d2fce8f6d1e5', 'status': 'VISIBLE', 'txnId': '9081'}
```

3. 查看导入数据

```
MySQL> SELECT COUNT(*) FROM testdb.test_table;  
+-----+  
| count(*) |  
+-----+  
|      5 |  
+-----+  
1 row in set (0.179 sec)
```

INSERT INTO SELECT

1. 在上述操作的基础上，创建一个新表作为目标表（其 schema 与源表相同）

```
CREATE TABLE testdb.test_table2 LIKE testdb.test_table;
```

2. 使用 INSERT INTO SELECT 导入到新表

```
INSERT INTO testdb.test_table2  
SELECT * FROM testdb.test_table WHERE age < 30;  
Query OK, 3 rows affected (0.544 sec)  
{'label': 'label_9c2bae970023407d_b2c5b78b368e78a7', 'status': 'VISIBLE', 'txnId': '9084'}
```

3. 查看导入数据

```
MySQL> SELECT COUNT(*) FROM testdb.test_table2;
+-----+
| count(*) |
+-----+
|          3 |
+-----+
1 row in set (0.071 sec)
```

查看导入作业

可以通过 show load 命令查看已完成的 INSERT INTO 任务。

```
MySQL> SHOW LOAD FROM testdb;
```

JobId	Label	State	Progress	Type	EtlInfo
TaskInfo			ErrorMsg	CreateTime	
EtlStartTime	EtlFinishTime	LoadStartTime	LoadFinishTime	URL	JobDetails
TransactionId	ErrorTablets	User	Comment		
376416	label_3e52da787aab4222_9126d2fce8f6d1e5	FINISHED	Unknown id: 376416	INSERT	NULL
cluster:N/A; timeout(s):26200; max_filter_ratio:0.0; priority:NORMAL NULL 2024-02-27 01:22:17 2024-02-27 01:22:17 2024-02-27 01:22:17 2024-02-27 01:22:18 {"Unfinished backends":{}, "ScannedRows":0, "TaskNumber":0, "LoadBytes":0, "All backends":{}, "FileName":0, "FileSize":0} 9081 {} root					
376664	label_9c2bae970023407d_b2c5b78b368e78a7	FINISHED	Unknown id: 376664	INSERT	NULL
cluster:N/A; timeout(s):26200; max_filter_ratio:0.0; priority:NORMAL NULL 2024-02-27 01:39:37 2024-02-27 01:39:37 2024-02-27 01:39:37 2024-02-27 01:39:38 {"Unfinished backends":{}, "ScannedRows":0, "TaskNumber":0, "LoadBytes":0, "All backends":{}, "FileName":0, "FileSize":0} 9084 {} root					

取消导入作业

用户可以通过 Ctrl-C 取消当前正在执行的 INSERT INTO 作业。

参考手册

导入命令

INSERT INTO 导入语法如下：

1. INSERT INTO SELECT

INSERT INTO SELECT 一般用于将查询结果保存到目标表中。

```
INSERT INTO target_table SELECT ... FROM source_table;
```

其中 SELECT 语句同一般的 SELECT 查询语句，可以包含 WHERE JOIN 等操作。

2. INSERT INTO VALUES

INSERT INTO VALUES 一般仅用于 Demo，不建议在生产环境使用。

```
INSERT INTO target_table (col1, col2, ...)
VALUES (val1, val2, ...), (val3, val4, ...), ...;
```

导入配置参数

01 FE 配置

insert_load_default_timeout_second

- 默认值：14400（4 小时）
- 参数描述：导入任务的超时时间，单位：秒。导入任务在该超时时间内未完成则会被系统取消，变成 CANCELLED。

02 环境变量

insert_timeout

- 默认值：14400（4 小时）
- 参数描述：INSERT INTO 作为 SQL 语句的的超时时间，单位：秒。

enable_insert_strict

- 默认值：true
- 参数描述：如果设置为 true，当 INSERT INTO 遇到不合格数据时导入会失败。如果设置为 false，INSERT INTO 会忽略不合格的行，只要有一条数据被正确导入，导入就会成功。
- 解释：INSERT INTO 无法控制错误率，只能通过该参数设置为严格检查数据质量或完全忽略错误数据。常见的数据不合格的原因有：源数据列长度超过目的数据列长度、列类型不匹配、分区不匹配、列顺序不匹配等。

enable_nereids_dml_with_pipeline

设置为 true 后，insert into 语句将尝试通过 Pipeline 引擎执行。详见[导入](#)文档。

导入返回值

INSERT INTO 是一个 SQL 语句，其返回结果会根据查询结果的不同，分为以下几种：

结果集为空

如果 INSERT INTO 中的 SELECT 语句的查询结果集为空，则返回如下：

```
mysql> INSERT INTO tbl1 SELECT * FROM empty_tbl;
Query OK, 0 rows affected (0.02 sec)
```

Query OK 表示执行成功。0 rows affected 表示没有数据被导入。

结果集不为空且 INSERT 执行成功

```
mysql> INSERT INTO tbl1 SELECT * FROM tbl2;
Query OK, 4 rows affected (0.38 sec)
{'label':'INSERT_8510c568-9eda-4173-9e36-6adc7d35291c', 'status':'visible', 'txnId':'4005'}

mysql> INSERT INTO tbl1 WITH LABEL my_label1 SELECT * FROM tbl2;
Query OK, 4 rows affected (0.38 sec)
{'label':'my_label1', 'status':'visible', 'txnId':'4005'}

mysql> INSERT INTO tbl1 SELECT * FROM tbl2;
Query OK, 2 rows affected, 2 warnings (0.31 sec)
{'label':'INSERT_f0747f0e-7a35-46e2-affa-13a235f4020d', 'status':'visible', 'txnId':'4005'}

mysql> INSERT INTO tbl1 SELECT * FROM tbl2;
Query OK, 2 rows affected, 2 warnings (0.31 sec)
{'label':'INSERT_f0747f0e-7a35-46e2-affa-13a235f4020d', 'status':'committed', 'txnId':'4005'}
```

Query OK 表示执行成功。4 rows affected 表示总共有 4 行数据被导入。2 warnings 表示被过滤的行数。

同时会返回一个 JSON 串：

```
{'label':'my_label1', 'status':'visible', 'txnId':'4005'}
{'label':'INSERT_f0747f0e-7a35-46e2-affa-13a235f4020d', 'status':'committed', 'txnId':'4005'}
{'label':'my_label1', 'status':'visible', 'txnId':'4005', 'err':'some other error'}
```

其中，返回结果参数如下表说明：

参数名称	说明
TxnId	导入事务的 ID
Label	导入作业的 label，通过 INSERT INTO tbl WITH LABEL label ... 指定
Status	表示导入数据是否可见。如果可见，显示 visible，如果不可见，显示 committed
Err	导入错误信息

当需要查看被过滤的行时，用户可以通过[SHOW LOAD](#)语句

```
SHOW LOAD WHERE label="xxx";
```

返回结果中的 URL 可以用于查询错误的数据，具体见后面 查看错误行 小结。

数据不可见是一个临时状态，这批数据最终是一定可见的

可以通过[SHOW TRANSACTION](#)语句查看这批数据的可见状态：

```
SHOW TRANSACTION WHERE id=4005;
```

返回结果中的 TransactionStatus 列如果为 visible，则表述数据可见。

```
{'label':'my_label1', 'status':'visible', 'txnId':'4005'}
{'label':'INSERT_f0747f0e-7a35-46e2-affa-13a235f4020d', 'status':'committed', 'txnId':'4005'}
{'label':'my_label1', 'status':'visible', 'txnId':'4005', 'err':'some other error'}
```

结果集不为空但 INSERT 执行失败

执行失败表示没有任何数据被成功导入，并返回如下：

```
mysql> INSERT INTO tbl1 SELECT * FROM tbl2 WHERE k1 = "a";
ERROR 1064 (HY000): all partitions have no load data. url: http://10.74.167.16:8042/api/_load_error_log?
file=_shard_2/error_loginsert_stmt_ba8bb9e158e4879-ae8de8507c0bf8a2_ba8bb9e158e4879-ae8de8507c0bf8a2
```

其中 ERROR 1064 (HY000): all partitions have no load data 显示失败原因。后面的 url 可以用于查询错误的信息，具体见后面 查看错误行 小结。

导入最佳实践

数据量

INSERT INTO 对数据量没有限制，大数据量导入也可以支持。但如果导入数据量过大，就需要通过以下配置修改系统的 INSERT INTO 导入超时时间，确保导入超时 $\geq$ 数据量 / 预估导入速度。

1. FE 配置参数 insert_load_default_timeout_second。
2. 环境变量 insert_timeout。

查看错误行

当 INSERT INTO 返回结果中提供了 url 字段时，可以通过以下命令查看错误行：

```
SHOW LOAD WARNINGS ON "url";
```

示例：

```
SHOW LOAD WARNINGS ON "http://ip:port/api/_load_error_log?
file=_shard_13/error_loginsert_stmt_d2cac0a0a16d482d-9041c949a4b71605_d2cac0a0a16d482d-9041c949a4b71605";
```

常见的错误的原因有：源数据列长度超过目的数据列长度、列类型不匹配、分区不匹配、列顺序不匹配等。

可以通过环境变量 enable_insert_strict 来控制 INSERT INTO 是否忽略错误行。

通过外部表 Multi-Catalog 导入数据

Doris 可以创建外部表。创建完成后，可以通过 INSERT INTO SELECT 的方式导入外部表的数据，当然也可以通过 SELECT 语句直接查询外部表的数据，

Doris 通过多源数据目录（Multi-Catalog）功能，支持了包括 Apache Hive、Apache Iceberg、Apache Hudi、Apache Paimon(Incubating)、Elasticsearch、MySQL、Oracle、SQL Server 等主流数据湖、数据库的连接访问

问。

Multi-Catalog 相关功能，请查看湖仓一体文档。

这里以通过构建 Hive 外部表，导入其数据到 Doris 内部表来举例说明。

创建 Hive Catalog

```
CREATE CATALOG hive PROPERTIES (  
  'type'='hms',  
  'hive.metastore.uris' = 'thrift://172.0.0.1:9083',  
  'hadoop.username' = 'hive',  
  'dfs.nameservices'='your-nameservice',  
  'dfs.ha.namenodes.your-nameservice'='nn1,nn2',  
  'dfs.namenode.rpc-address.your-nameservice.nn1'='172.21.0.2:8088',  
  'dfs.namenode.rpc-address.your-nameservice.nn2'='172.21.0.3:8088',  
  'dfs.client.failover.proxy.provider.your-  
nameservice'='org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider'  
);
```

导入数据

1. 创建一张 Doris 的导入目标表

```
CREATE TABLE `target_tbl` (  
  `k1` decimal(9, 3) NOT NULL COMMENT "",  
  `k2` char(10) NOT NULL COMMENT "",  
  `k3` datetime NOT NULL COMMENT "",  
  `k5` varchar(20) NOT NULL COMMENT "",  
  `k6` double NOT NULL COMMENT ""  
)  
COMMENT "Doris Table"  
DISTRIBUTED BY HASH(k1) BUCKETS 2  
PROPERTIES (  
  "replication_num" = "1"  
);
```

2. 关于创建 Doris 表的详细说明，请参阅 [CREATE-TABLE](#) 语法帮助。

3. 导入数据 (从 hive.db1.source_tbl 表导入到 target_tbl 表)

```
INSERT INTO target_tbl SELECT k1,k2,k3 FROM  hive.db1.source_tbl limit 100;
```

INSERT 命令是同步命令，返回成功，即表示导入成功。

注意事项

- 必须保证外部数据源与 Doris 集群是可以互通，包括 BE 节点和外部数据源的网络是互通的。

通过 TVF 导入数据

通过 Table Value Function 功能，Doris 可以直接将对象存储或 HDFS 上的文件作为 Table 进行查询分析、并且支持自动的列类型推断。详细介绍，请参考 湖仓一体/TVF 文档。

自动推断文件列类型

```
DESC FUNCTION s3 (
  "URI" = "http://127.0.0.1:9312/test2/test.snappy.parquet",
  "s3.access_key"= "ak",
  "s3.secret_key" = "sk",
  "format" = "parquet",
  "use_path_style"="true"
);
```

Field	Type	Null	Key	Default	Extra
p_partkey	INT	Yes	false	NULL	NONE
p_name	TEXT	Yes	false	NULL	NONE
p_mfgr	TEXT	Yes	false	NULL	NONE
p_brand	TEXT	Yes	false	NULL	NONE
p_type	TEXT	Yes	false	NULL	NONE
p_size	INT	Yes	false	NULL	NONE
p_container	TEXT	Yes	false	NULL	NONE
p_retailprice	DECIMAL(9,0)	Yes	false	NULL	NONE
p_comment	TEXT	Yes	false	NULL	NONE

这里给出了一个 s3 TVF 的例子。这个例子中指定了文件的路径、连接信息、认证信息等。

之后，通过 DESC FUNCTION 语法可以查看这个文件的 Schema。

可以看到，对于 Parquet 文件，Doris 会根据文件内的元信息自动推断列类型。

目前支持对 Parquet、ORC、CSV、Json 格式进行分析和列类型推断。

配合 INSERT INTO SELECT 语法，可以方便将文件导入到 Doris 表中进行更快速的分析：

```
// 1. 创建doris内部表
CREATE TABLE IF NOT EXISTS test_table
(
  id int,
  name varchar(50),
  age int
)
DISTRIBUTED BY HASH(id) BUCKETS 4
PROPERTIES("replication_num" = "1");

// 2. 使用 S3 Table Value Function 插入数据
INSERT INTO test_table (id,name,age)
SELECT cast(id as INT) as id, name, cast (age as INT) as age
FROM s3(
  "uri" = "http://127.0.0.1:9312/test2/test.snappy.parquet",
  "s3.access_key"= "ak",
  "s3.secret_key" = "sk",
  "format" = "parquet",
  "use_path_style" = "true");
```

注意事项

- 如果 S3 / hdfs TVF 指定的 uri 匹配不到文件，或者匹配到的所有文件都是空文件，那么 S3 / hdfs TVF 将会返回空结果集。在这种情况下使用DESC FUNCTION查看这个文件的 Schema，会得到一列虚假的列__dummy_col，可忽略这一列。

- 如果指定 TVF 的 format 为 CSV The first line is empty, can not parse column numbers, 这因为无法通过该文件的第一行解析出 Schema。

更多帮助

关于 Insert Into 使用的更多详细语法，请参阅 [INSERT INTO](#) 命令手册，也可以在 MySQL 客户端命令行下输入 `HELP INSERT` 获取更多帮助信息。

MySQL Load

Doris 兼容 MySQL 协议，可以使用 MySQL 标准的 [LOAD DATA](#) 语法导入本地文件。MySQL Load 是一种同步导入方式，执行导入后即返回导入结果。可以通过 LOAD DATA 语句的返回结果判断导入是否成功。一般来说，可以使用 MySQL Load 导入 10GB 以下的文件，如果文件过大，建议将文件进行切分后使用 MySQL Load 进行导入。MySQL Load 可以保证一批导入任务的原子性，要么全部导入成功，要么全部导入失败。

使用场景

支持格式

MySQL Load 主要适用于导入客户端本地 CSV 文件，或通过程序导入数据流中的数据。

使用限制

在导入 CSV 文件时，需要明确区分空值（null）与空字符串（"）：

- 空值（null）需要用 \N 表示，a,\N,b 数据表示中间列是一个空值（null）
- 空字符串直接将数据置空，a, ,b 数据表示中间列是一个空字符串

基本原理

MySQL Load 与 Stream Load 功能相似，都是导入本地文件到 Doris 集群中。因此 MySQL Load 的实现复用了 Stream Load 的基本导入能力。

下图展示了 MySQL Load 的主要流程：

1. 用户向 FE 提交 LOAD DATA 请求，FE 完成解析工作，并将请求封装成 Stream Load；
2. FE 会选择一个 BE 节点发送 Stream Load 请求；
3. 发送请求的同时，FE 会异步且流式的从 MySQL 客户端读取本地文件数据，并实时的发送到 Stream Load 的 HTTP 请求中；
4. MySQL 客户端数据传输完毕，FE 等待 Stream Load 完成，并展示导入成功或者失败的信息给客户端。

快速上手

前置检查

MySQL Load 需要对目标表的 INSERT 权限。如果没有 INSERT 权限，可以通过 GRANT 命令给用户授权。

创建导入作业

1. 准备测试数据

创建名为 client_local.csv 的文件，样例数据如下：

```
1,10
2,20
3,30
4,40
5,50
6,60
```

2. 链接客户端

在执行 LOAD DATA 命令前，需要先链接 MySQL 客户端。

```
mysql --local-infile -h <fe_ip> -P <fe_query_port> -u root -D testdb
```

执行 MySQL Load，在连接时需要使用指定参数选项：

1. 在链接 mysql 客户端时，必须使用 --local-infile 选项，否则可能会报错。
2. 通过 JDBC 链接，需要在 URL 中指定配置 allowLoadLocalInfile=true

3. 创建测试用表

在 Doris 中创建以下表：

```
CREATE TABLE testdb.t1 (
  pk      INT,
  v1      INT SUM
) AGGREGATE KEY (pk)
DISTRIBUTED BY hash (pk);
```

4. 运行 LOAD DATA 导入命令

链接 MySQL Client 后，创建导入作业，命令如下：

```
LOAD DATA LOCAL
INFILE 'client_local.csv'
INTO TABLE testdb.t1
COLUMNS TERMINATED BY ','
LINES TERMINATED BY '\n';
```

查看导入作业结果

MySQL Load 是一种同步的导入方式，导入后结果会在命令行中返回给用户。如果导入执行失败，会展示具体的报错信息。

如下是导入成功的结果显示，会返回导入的行数：

```
Query OK, 6 row affected (0.17 sec)
Records: 6  Deleted: 0  Skipped: 0  Warnings: 0
```

当导入有异常时，会在客户端显示相应异常：

```
ERROR 1105 (HY000): errCode = 2, detailMessage = [DATA_QUALITY_ERROR]too many filtered rows with load id
b612907c-ccf4-4ac2-82fe-107ece655f0f
```

在异常信息中，可以捕捉到导入的 loadId，通过 show load warnings 命令可以查看到具体信息：

```
show load warnings where label='b612907c-ccf4-4ac2-82fe-107ece655f0f';
```

取消导入作业

用户无法手动取消 MySQL Load，MySQL Load 在超时或者导入错误后会被系统自动取消。

参考手册

导入语法

LOAD DATA 语法如下：

```
LOAD DATA LOCAL
INFILE '<load_data_file>'
INTO TABLE [<db_name>.<table_name>
[PARTITION (partition_name [, partition_name] ...)]
[COLUMNS TERMINATED BY '<column_terminated_operator>']
[LINES TERMINATED BY '<line_terminated_operator>']
[IGNORE <ignore_lines> LINES]
[(col_name_or_user_var[, col_name_or_user_var] ...)]
[SET col_name={expr | DEFAULT}[, col_name={expr | DEFAULT}] ...]
[PROPERTIES (key1 = value1 [, key2=value2]) ]
```

创建导入作业的模块说明如下：

模块	说明
INFILE	指定本地文件路径，可以是相对路径，也可以是绝对路径。目前 load_data_file 只支持单个文件，不支持。
INTO TABLE	指定数据库名与表名，可以省略数据库名。
PARTITION	指定导入的分区。如果用户能够确定数据对应的 partition，推荐指定该项。不满足这些分区的数据将被过滤掉。
COLUMNS TERMINATED BY	指定导入的列分隔符。
LINE TERMINATED BY	指定导入的行分隔符。
IGNORE num LINES	指定导入的 CSV 跳过行数，通常指定 1 来跳过表头。
col_name_or_user_var	指定列映射语法，数据转换详见 列映射 章节。
PROPERTIES	导入参数。

导入参数

通过 PROPERTIES (key1 = value1 [, key2=value2]) 语法可以指定导入的参数配置：

参数	说明
max_filter_ratio	允许的最大过滤率。必须在大于等于 0 到小于等于 1 之间。默认值是 0，表示不容忍任何错误行。
timeout	指定导入的超时时间，单位秒。默认是 600 秒。可设置范围为 1s ~ 259200s。
strict_mode	用户指定此次导入是否开启严格模式，默认为关闭。
timezone	指定本次导入所使用的时区。默认为东八区。该参数会影响所有导入涉及的和时区有关的函数结果。
exec_mem_limit	导入内存限制。默认为 2GB。单位为字节。
trim_double_quotes	布尔类型，默认值为 false，为 true 时表示裁剪掉导入文件每个字段最外层的双引号。
enclose	指定包围符。当 csv 数据字段中含有行分隔符或列分隔符时，为防止意外截断，可指定单字节字符作为包围符起到保护作用。例如列分隔符为 “.”，包围符为 “””，数据为 “a,b,c””，则 “b,c” 会被解析为一个字段。
escape	指定转义符。用于转义在字段中出现的与包围符相同的字符。例如数据为 “a,b,c””，包围符为 “””，希望 “b,c 被作为一个字段解析，则需要指定单字节转义符，例如 \，将数据修改为 a,'b,\'c'”。

导入举例

指定导入超时时间

通过制定 PROPERTIES 参数 timeout 可以调整导入超时时间。在以下案例中将超时时间设置为 100s：

```
LOAD DATA LOCAL
INFILE 'testData'
INTO TABLE testDb.testTbl
PROPERTIES ("timeout"="100");
```

指定导入允许误差率

通过指定 PROPERTIES 参数 max_filter_ratio 可以调整导入超时时间。在以下案例中将错误容忍率设置为 20%：

```
LOAD DATA LOCAL
INFILE 'testData'
INTO TABLE testDb.testTbl
PROPERTIES ("max_filter_ratio"="0.2");
```

映射导入列

在以下案例中调整了 CSV 中列的顺序：

```
LOAD DATA LOCAL
INFILE 'testData'
INTO TABLE testDb.testTbl
(k2, k1, v1);
```

指定导入列分隔符与行分隔符

通过 COLUMNS TERMINATED BY 与 LINES TERMINATED BY 子句可以指定导入的列与行分隔符。在以下案例中使用逗号 (,) 与换行符 (\n) 作为列与行分隔符：

```
LOAD DATA LOCAL
INFILE 'testData'
INTO TABLE testDb.testTbl
COLUMNS TERMINATED BY ','
LINES TERMINATED BY '\n';
```

指定导入分区

通过 PARTITION 子句可以指定导入分区。在以下案例中将数据导入指定分区 p1 与 p2，如果数据不属于 p1 与 p2 分区，会被过滤掉：

```
LOAD DATA LOCAL
INFILE 'testData'
INTO TABLE testDb.testTbl
PARTITION (p1, p2);
```

指定导入时区

通过 PROPERTIES 参数 timezone 可以指定时区。在以下案例中设置时区为 Africa/Abidjan：

```
LOAD DATA LOCAL
INFILE 'testData'
INTO TABLE testDb.testTbl
PROPERTIES ("timezone"="Africa/Abidjan");
```

限制导入内存

通过 PROPERTIES 参数 exec_mem_limit 可以指定导入的内存限制。在以下案例中设置导入的内存限制为 10G：

```
LOAD DATA LOCAL
INFILE 'testData'
INTO TABLE testDb.testTbl
PROPERTIES ("exec_mem_limit"="10737418240");
```

更多帮助

关于 MySQL Load 使用的更多详细语法及最佳实践，请参阅 [MySQL Load](#) 命令手册。

JSON 数据导入

Doris 支持导入 JSON 格式的数据。本文档主要说明在进行 JSON 格式数据导入时的注意事项。

支持的导入方式

目前只有以下导入方式支持 JSON 格式的数据导入：

- 通过 [S3 表函数](#) 导入语句：insert into table select * from S3();
- 将本地 JSON 格式的文件通过 [STREAM LOAD](#) 方式导入。
- 通过 [ROUTINE LOAD](#) 订阅并消费 Kafka 中的 JSON 格式消息。

暂不支持其他方式的 JSON 格式数据导入。

支持的 JSON 格式

当前仅支持以下两种 JSON 格式：

1. 以 Array 表示的多行数据

以 Array 为根节点的 JSON 格式。Array 中的每个元素表示要导入的一行数据，通常是一个 Object。示例如下：

```
[
  { "id": 123, "city" : "beijing"},
  { "id": 456, "city" : "shanghai"},
  ...
]
```

```
[
  { "id": 123, "city" : { "name" : "beijing", "region" : "haidian"}},
  { "id": 456, "city" : { "name" : "beijing", "region" : "chaoyang"}},
  ...
]
```

这种方式通常用于 Stream Load 导入方式，以便在一批导入数据中表示多行数据。

这种方式必须配合设置 strip_outer_array=true 使用。Doris 在解析时会将数组展开，然后依次解析其中的每一个 Object 作为一行数据。

2. 以 Object 表示的单行数据

以 Object 为根节点的 JSON 格式。整个 Object 即表示要导入的一行数据。示例如下：

```
{ "id": 123, "city" : "beijing"}
```

```
{ "id": 123, "city" : { "name" : "beijing", "region" : "haidian" }}
```

这种方式通常用于 Routine Load 导入方式，如表示 Kafka 中的一条消息，即一行数据。

3. 以固定分隔符分隔的多行 Object 数据

Object 表示的一行数据即表示要导入的一行数据，示例如下：

```
{ "id": 123, "city" : "beijing"}  
{ "id": 456, "city" : "shanghai"}  
...
```

这种方式通常用于 Stream Load 导入方式，以便在一批导入数据中表示多行数据。

这种方式必须配合设置 `read_json_by_line=true` 使用，特殊分隔符还需要指定 `line_delimiter` 参数，默认 `\n`。Doris 在解析时会按照分隔符分隔，然后解析其中的每一行 Object 作为一行数据。

streaming_load_json_max_mb 参数

一些数据格式，如 JSON，无法进行拆分处理，必须读取全部数据到内存后才能开始解析，因此，这个值用于限制此类格式数据单次导入最大数据量。

默认值为 100，单位 MB，可参考[BE 配置项](#)修改这个参数

fuzzy_parse 参数

在 [STREAM LOAD](#) 中，可以添加 `fuzzy_parse` 参数来加速 JSON 数据的导入效率。

这个参数通常用于导入以 **Array** 表示的多行数据 这种格式，所以一般要配合 `strip_outer_array=true` 使用。

这个功能要求 Array 中的每行数据的字段顺序完全一致。Doris 仅会根据第一行的字段顺序做解析，然后以下标的形式访问之后的数据。该方式可以提升 3-5X 的导入效率。

JSON Path

Doris 支持通过 JSON Path 抽取 JSON 中指定的数据。

注：因为对于 **Array** 类型的数据，Doris 会先进行数组展开，最终按照 **Object** 格式进行单行处理。所以本文档之后的示例都以单个 **Object** 格式的 **Json** 数据进行说明。

- 不指定 JSON Path

如果没有指定 JSON Path，则 Doris 会默认使用表中的列名查找 Object 中的元素。示例如下：

表中包含两列：id, city

JSON 数据如下：

```
{ "id": 123, "city" : "beijing"}
```

则 Doris 会使用 id, city 进行匹配，得到最终数据 123 和 beijing。

如果 JSON 数据如下：

```
{ "id": 123, "name" : "beijing"}
```

则使用 id, city 进行匹配，得到最终数据 123 和 null。

- 指定 JSON Path

通过一个 JSON 数据的形式指定一组 JSON Path。数组中的每个元素表示一个要抽取的列。示例如下：

```
["$id", "$name"]
```

```
["$id.sub_id", "$name[0]", "$city[0]"]
```

Doris 会使用指定的 JSON Path 进行数据匹配和抽取。

- 匹配非基本类型

前面的示例最终匹配到的数值都是基本类型，如整型、字符串等。Doris 当前暂不支持复合类型，如 Array、Map 等。所以当匹配到一个非基本类型时，Doris 会将该类型转换为 JSON 格式的字符串，并以字符串类型进行导入。示例如下：

JSON 数据为：

```
{ "id": 123, "city" : { "name" : "beijing", "region" : "haidian" }}
```

JSON Path 为 ["\$.city"]。则匹配到的元素为：

```
{ "name" : "beijing", "region" : "haidian" }
```

该元素会被转换为字符串进行后续导入操作：

```
"{'name':'beijing','region':'haidian'}"
```

- 匹配失败

当匹配失败时，将会返回 null。示例如下：

JSON 数据为：

```
{ "id": 123, "name" : "beijing"}
```

JSON Path 为 ["\$.id", "\$info"]。则匹配到的元素为 123 和 null。

Doris 当前不区分 JSON 数据中表示的 null 值，和匹配失败时产生的 null 值。假设 JSON 数据为：

```
{ "id": 123, "name" : null }
```

则使用以下两种 JSON Path 会获得相同的结果：123 和 null。

```
["$id", "$name"]
```

```
["$id", "$info"]
```

- 完全匹配失败

为防止一些参数设置错误导致的误操作。Doris 在尝试匹配一行数据时，如果所有列都匹配失败，则会认为这个是一个错误行。假设 JSON 数据为：

```
{ "id": 123, "city" : "beijing" }
```

如果 JSON Path 错误的写为（或者不指定 JSON Path 时，表中的列不包含 id 和 city）：

```
["$ad", "$info"]
```

则会导致完全匹配失败，则该行会标记为错误行，而不是产出 null，null。

JSON Path 和 Columns

JSON Path 用于指定如何对 JSON 格式中的数据进行抽取，而 Columns 指定列的映射和转换关系。两者可以配合使用。

换句话说，相当于通过 JSON Path，将一个 JSON 格式的数据，按照 JSON Path 中指定的列顺序进行了列的重排。之后，可以通过 Columns，将这个重排后的源数据和表的列进行映射。举例如下：

数据内容：

```
{"k1" : 1, "k2": 2}
```

表结构：

```
k2 int, k1 int
```

导入语句 1（以 Stream Load 为例）：

```
curl -v --location-trusted -u root: -H "format: json" -H "jsonpaths: [\"$.k2\", \"$.k1\"]" -T example.json  
http://127.0.0.1:8030/api/db1/tbl1/_stream_load
```

导入语句 1 中，仅指定了 JSON Path，没有指定 Columns。其中 JSON Path 的作用是将 JSON 数据按照 JSON Path 中字段的顺序进行抽取，之后会按照表结构的顺序进行写入。最终导入的数据结果如下：

k1	k2
2	1

会看到，实际的 k1 列导入了 JSON 数据中的“k2”列的值。这是因为，JSON 中字段名称并不等同于表结构中字段的名称。我们需要显式的指定这两者之间的映射关系。

导入语句 2：

```
curl -v --location-trusted -u root: -H "format: json" -H "jsonpaths: [\"$.k2\", \"$.k1\"]" -H "columns: k2, k1" -T example.json http://127.0.0.1:8030/api/db1/tbl1/_stream_load
```

相比如导入语句 1，这里增加了 Columns 字段，用于描述列的映射关系，按 k2，k1 的顺序。即按 JSON Path 中字段的顺序抽取后，指定第一列为表中 k2 列的值，而第二列为表中 k1 列的值。最终导入的数据结果如下：

k1	k2
1	2

当然，如其他导入一样，可以在 Columns 中进行列的转换操作。示例如下：

```
curl -v --location-trusted -u root: -H "format: json" -H "jsonpaths: [\"$.k2\", \"$.k1\"]" -H "columns: k2, tmp_k1, k1 = tmp_k1 * 100" -T example.json http://127.0.0.1:8030/api/db1/tbl1/_stream_load
```

上述示例会将 k1 的值乘以 100 后导入。最终导入的数据结果如下：

k1	k2
100	2

JSON root

Doris 支持通过 JSON root 抽取 JSON 中指定的数据。

注：因为对于 Array 类型的数据，Doris 会先进行数组展开，最终按照 Object 格式进行单行处理。所以本文档之后的示例都以单个 Object 格式的 Json 数据进行说明。

- 不指定 JSON root

如果没有指定 JSON root，则 Doris 会默认使用表中的列名查找 Object 中的元素。示例如下：

表中包含两列：id, city

JSON 数据为：

```
{ "id": 123, "name" : { "id" : "321", "city" : "shanghai" }}
```

则 Doris 会使用 id, city 进行匹配，得到最终数据 123 和 null。

- 指定 JSON root

通过 json_root 指定 JSON 数据的根节点。Doris 将通过 json_root 抽取根节点的元素进行解析。默认为空。

指定 JSON root -H "json_root: \$.name"。则匹配到的元素为：

```
{ "id" : "321", "city" : "shanghai" }
```

该元素会被当作新 JSON 进行后续导入操作，得到最终数据 321 和 shanghai

NULL 和 Default 值

示例数据如下：

```
[
  {"k1": 1, "k2": "a"},
  {"k1": 2},
  {"k1": 3, "k2": "c"}
]
```

表结构为：k1 int null, k2 varchar(32) null default "x"

导入语句如下：

```
curl -v --location-trusted -u root: -H "format: json" -H "strip_outer_array: true" -T example.json
http://127.0.0.1:8030/api/db1/tbl1/_stream_load
```

用户可能期望的导入结果如下，即对于缺失的列，填写默认值。

k1	k2
1	a
2	x
3	c

但实际的导入结果如下，即对于缺失的列，补上了 NULL。

k1	k2
1	a

2	NULL
3	c

这是因为通过导入语句中的信息，Doris 并不知道“缺失的列是表中的 k2 列”。如果要对以上数据按照期望结果导入，则导入语句如下：

```
curl -v --location-trusted -u root: -H "format: json" -H "strip_outer_array: true" -H "jsonpaths: [\"$.k1\", \"$.k2\"]" -H "columns: k1, tmp_k2, k2 = ifnull(tmp_k2, 'x')" -T example.json http://127.0.0.1:8030/api/db1/tbl1/_stream_load
```

应用示例

Stream Load

因为 JSON 格式的不可拆分特性，所以在使用 Stream Load 导入 JSON 格式的文件时，文件内容会被全部加载到内存后，才开始处理。因此，如果文件过大的话，可能会占用较多的内存。

假设表结构为：

id	INT	NOT NULL,
city	VARHCHAR	NULL,
code	INT	NULL

1. 导入单行数据 1

```
{"id": 100, "city": "beijing", "code" : 1}
```

- 不指定 JSON Path

```
curl --location-trusted -u user:passwd -H "format: json" -T data.json http://localhost:8030/api/db1/tbl1/_stream_load
```

导入结果：

100	beijing	1
-----	---------	---

- 指定 JSON Path

```
curl --location-trusted -u user:passwd -H "format: json" -H "jsonpaths: [\"$.id\", \"$.city\", \"$.code\"]" -T data.json http://localhost:8030/api/db1/tbl1/_stream_load
```

导入结果：

100	beijing	1
-----	---------	---

2. 导入单行数据 2

```
{ "id": 100, "content": { "city": "beijing", "code" : 1} }
```

- 指定 JSON Path

```
curl --location-trusted -u user:passwd -H "format: json" -H "jsonpaths:
[\"$.id\", \"$.content.city\", \"$.content.code\"]" -T data.json
http://localhost:8030/api/db1/tbl1/_stream_load
```

导入结果:

100	beijing	1
-----	---------	---

3. 以 Array 形式导入多行数据

```
[
  { "id": 100, "city": "beijing", "code" : 1},
  { "id": 101, "city": "shanghai"},
  { "id": 102, "city": "tianjin", "code" : 3},
  { "id": 103, "city": "chongqing", "code" : 4},
  { "id": 104, "city": ["zhejiang", "guangzhou"], "code" : 5},
  {
    "id": 105,
    "city": {
      "order1": ["guangzhou"]
    },
    "code" : 6
  }
]
```

- 指定 JSON Path

```
curl --location-trusted -u user:passwd -H "format: json" -H "jsonpaths:
[\"$.id\", \"$.city\", \"$.code\"]" -H "strip_outer_array: true" -T data.json
http://localhost:8030/api/db1/tbl1/_stream_load
```

导入结果:

100	beijing	1
101	shanghai	NULL
102	tianjin	3
103	chongqing	4
104	["zhejiang", "guangzhou"]	5
105	{"order1": ["guangzhou"]}	6

4. 以多行 Object 形式导入多行数据

```
```json
{ "id": 100, "city": "beijing", "code" : 1}
{ "id": 101, "city": "shanghai"}
{ "id": 102, "city": "tianjin", "code" : 3}
{ "id": 103, "city": "chongqing", "code" : 4}
```
```

- StreamLoad 导入：

```
curl --location-trusted -u user:passwd -H "format: json" -H "read_json_by_line: true" -T data.json
http://localhost:8030/api/db1/tbl1/_stream_load
```

导入结果：

| | | |
|-----|-----------|------|
| 100 | beijing | 1 |
| 101 | shanghai | NULL |
| 102 | tianjin | 3 |
| 103 | chongqing | 4 |

5. 对导入数据进行转换

数据依然是示例 3 中的多行数据，现需要对导入数据中的 code 列加 1 后导入。

```
curl --location-trusted -u user:passwd -H "format: json" -H "jsonpaths: [\"$.id\", \"$.city\", \"$.code\"]" -H
"strip_outer_array: true" -H "columns: id, city, tmpc, code=tmpc+1" -T data.json
http://localhost:8030/api/db1/tbl1/_stream_load
```

导入结果：

| | | |
|-----|---------------------------|------|
| 100 | beijing | 2 |
| 101 | shanghai | NULL |
| 102 | tianjin | 4 |
| 103 | chongqing | 5 |
| 104 | ["zhejiang", "guangzhou"] | 6 |
| 105 | {"order1": ["guangzhou"]} | 7 |

6. 使用 JSON 导入 Array 类型 由于 RapidJSON 处理 decimal 和 largeint 数值会导致精度问题，所以我们建议使用 JSON 字符串来导入数据到 array<decimal> 或 array<largeint> 列。

```
{"k1": 39, "k2": ["-818.2173181"]}
```

```
{"k1": 40, "k2": ["1000000000000000000.111111122222222"]}
```

```
curl --location-trusted -u root: -H "max_filter_ratio:0.01" -H "format:json" -H "timeout:300" -T
test_decimal.json http://localhost:8035/api/example_db/array_test_decimal/_stream_load
```

导入结果：

```
MySQL > select * from array_test_decimal;
+-----+-----+
| k1 | k2 |
+-----+-----+
| 39 | [-818.2173181] |
| 40 | [1000000000000000000.001111111] |
+-----+-----+
```

```
{"k1": 999, "k2": ["76959836937749932879763573681792701709", "26017042825937891692910431521038521227"]}
```

```
curl --location-trusted -u root: -H "max_filter_ratio:0.01" -H "format:json" -H "timeout:300" -T
test_largeint.json http://localhost:8035/api/example_db/array_test_largeint/_stream_load
```

导入结果：

```
MySQL > select * from array_test_largeint;
```

| k1 | k2 |
|-----|--|
| 999 | [76959836937749932879763573681792701709, 26017042825937891692910431521038521227] |

Routine Load

Routine Load 对 JSON 数据的处理原理和 Stream Load 相同。在此不再赘述。

对于 Kafka 数据源，每个 Message 中的内容被视作一个完整的 JSON 数据。如果一个 Message 中是以 Array 格式的表示的多行数据，则会导入多行，而 Kafka 的 offset 只会增加 1。而如果一个 Array 格式的 JSON 表示多行数据，但是因为 JSON 格式错误导致解析 JSON 失败，则错误行只会增加 1（因为解析失败，实际上 Doris 无法判断其中包含多少行数据，只能按一行错误数据记录）

从其他 AP 系统迁移数据

从其他 AP 系统迁移数据到 Doris，可以有多种方式：

- Hive/Iceberg/Hudi等，可以使用Multi-Catalog来映射为外表，然后使用Insert Into，来将数据导入
- 也可以从原来 AP 系统中导出数据为 CSV 等数据格式，然后再将导出的数据导入到 Doris
- 可以使用 Spark / Flink 系统，利用 AP 系统的 Connector 来读取数据，然后调用 Doris Connector 写入 Doris

导入事务与原子性

使用场景

Doris 中所有导入任务都是原子性的，即一个导入作业要么全部成功，要么全部失败，不会出现仅部分数据导入成功的情况，并且在同一个导入任务中对多张表的导入也能够保证原子性。同时，Doris 还可以通过 Label 的机制来保证数据导入的不丢不重。对于简单的导入任务，用户无需做额外配置或操作。对于表所附属的物化视图，也同时保证和基表的原子性和一致性。对于以下情形，Doris 为用户提供了更多的事务控制。

1. 如果用户需要将对于同一个目标表的多个 INSERT INTO 导入组合成一个事务，可以使用 BEGIN 和 COMMIT 命令。
2. 如果用户需要将多个 Stream Load 导入组合成一个事务，可以使用 Stream Load 的两阶段事务提交模式。
3. Broker Load 多表导入的原子性，

基本原理

Doris 导入任务中，BE 会提交写入成功的 Tablet ID 到 FE。FE 会根据 tablet 成功副本数判断导入是否成功，如果成功，该导入的事务被 commit，导入数据可见。如果失败，该导入的事务会被 rollback，相应的 tablet 也会被清理。

Label 机制

Doris 的导入作业都可以设置一个 Label。这个 Label 通常是用户自定义的、具有一定业务逻辑属性的字符串。

Label 的主要作用是唯一标识一个导入任务，并且能够保证相同的 Label 仅会被成功导入一次。

Label 机制可以保证导入数据的不丢不重。如果上游数据源能够保证 At-Least-Once 语义，则配合 Doris 的 Label 机制，能够保证 Exactly-Once 语义。

Label 在一个数据库下具有唯一性。Label 的保留期限默认是 3 天。即 3 天后，已完成的 Label 会被自动清理，之后 Label 可以被重复使用。

快速上手

Insert Into

1. 建表

```
CREATE TABLE testdb.test_table(  
  user_id      BIGINT      NOT NULL COMMENT "用户 ID",  
  name         VARCHAR(20) NOT NULL COMMENT "用户姓名",  
  age          INT         COMMENT "用户年龄"  
)  
DUPLICATE KEY(user_id)  
DISTRIBUTED BY HASH(user_id) BUCKETS 10;
```

创建一个同样 Schema 的表用于失败的例子

```
CREATE TABLE testdb.test_table2 LIKE testdb.test_table;
```

2. 导入成功的例子

```
BEGIN;

-- INSERT #1
INSERT INTO testdb.test_table (user_id, name, age)
VALUES (1, "Emily", 25),
       (2, "Benjamin", 35),
       (3, "Olivia", 28),
       (4, "Alexander", 60),
       (5, "Ava", 17);

-- INSERT #2
INSERT INTO testdb.test_table (user_id, name, age)
VALUES (6, "William", 69),
       (7, "Sophia", 32),
       (8, "James", 64),
       (9, "Emma", 37),
       (10, "Liam", 64);

COMMIT;
```

导入结果，导入任务的状态先是 PREPARE，直到 COMMIT 后才是 VISIBLE。

```
// BEGIN
Query OK, 0 rows affected (0.001 sec)
{'label':'txn_insert_2aeac5519bd549a1-a72fe4001c56e10c', 'status':'PREPARE', 'txnId':''}

// INSERT #1
Query OK, 5 rows affected (0.017 sec)
{'label':'txn_insert_2aeac5519bd549a1-a72fe4001c56e10c', 'status':'PREPARE', 'txnId':'10060'}

// INSERT #2
Query OK, 5 rows affected (0.007 sec)
{'label':'txn_insert_2aeac5519bd549a1-a72fe4001c56e10c', 'status':'PREPARE', 'txnId':'10060'}

// COMMIT
Query OK, 0 rows affected (1.013 sec)
{'label':'txn_insert_2aeac5519bd549a1-a72fe4001c56e10c', 'status':'VISIBLE', 'txnId':'10060'}
```

验证数据

```
MySQL [testdb]> SELECT * FROM testdb.test_table;
```

| user_id | name | age |
|---------|-----------|-----|
| 5 | Ava | 17 |
| 10 | Liam | 64 |
| 1 | Emily | 25 |
| 4 | Alexander | 60 |
| 7 | Sophia | 32 |
| 9 | Emma | 37 |
| 2 | Benjamin | 35 |
| 3 | Olivia | 28 |
| 6 | William | 69 |

```
|      8 | James      | 64 |
+-----+-----+
10 rows in set (0.110 sec)
```

3. 导入失败的例子

```
BEGIN;

-- INSERT #1
INSERT INTO testdb.test_table2 (user_id, name, age)
VALUES (1, "Emily", 25),
       (2, "Benjamin", 35),
       (3, "Olivia", 28),
       (4, "Alexander", 60),
       (5, "Ava", 17);

-- INSERT #2
INSERT INTO testdb.test_table2 (user_id, name, age)
VALUES (6, "William", 69),
       (7, "Sophia", 32),
       (8, NULL, 64),
       (9, "Emma", 37),
       (10, "Liam", 64);

COMMIT;
```

导入结果，因为第二个 INSERT INTO 存在 NULL，导致整个事务 COMMIT 失败。

```
// BEGIN
Query OK, 0 rows affected (0.001 sec)
{'label':'txn_insert_f3ecb2285edf42e2-92988ee97d74fbb0', 'status':'PREPARE', 'txnId':''}

// INSERT #1
Query OK, 5 rows affected (0.012 sec)
{'label':'txn_insert_f3ecb2285edf42e2-92988ee97d74fbb0', 'status':'PREPARE', 'txnId':'10062'}

// INSERT #2
{'label':'txn_insert_f3ecb2285edf42e2-92988ee97d74fbb0', 'status':'PREPARE', 'txnId':'10062'}

// COMMIT
ERROR 1105 (HY000): errCode = 2, detailMessage = errCode = 2, detailMessage = [DATA_QUALITY_ERROR]too many
filtered rows
```

验证结果，没有数据被导入。

```
MySQL [testdb]> SELECT * FROM testdb.test_table2;
Empty set (0.019 sec)
```

Stream Load

1. 在 HTTP Header 中设置 two_phase_commit:true 启用两阶段提交。

```
curl --location-trusted -u user:passwd -H "two_phase_commit:true" -T test.txt
http://fe_host:http_port/api/{db}/{table}/_stream_load
{
  "TxnId": 18036,
  "Label": "55c8ffc9-1c40-4d51-b75e-f2265b3602ef",
}
```

```

    "TwoPhaseCommit": "true",
    "Status": "Success",
    "Message": "OK",
    "NumberTotalRows": 100,
    "NumberLoadedRows": 100,
    "NumberFilteredRows": 0,
    "NumberUnselectedRows": 0,
    "LoadBytes": 1031,
    "LoadTimeMs": 77,
    "BeginTxnTimeMs": 1,
    "StreamLoadPutTimeMs": 1,
    "ReadDataTimeMs": 0,
    "WriteDataTimeMs": 58,
    "CommitAndPublishTimeMs": 0
}

```

2. 对事务触发 commit 操作（请求发往 FE 或 BE 均可）

- 可以使用事务 id 指定事务

```

curl -X PUT --location-trusted -u user:passwd -H "txn_id:18036" -H "txn_operation:commit"
http://fe_host:http_port/api/{db}/{table}/stream_load2pc
{
  "status": "Success",
  "msg": "transaction [18036] commit successfully."
}

```

- 也可以使用 label 指定事务

```

curl -X PUT --location-trusted -u user:passwd -H "label:55c8ffc9-1c40-4d51-b75e-f2265b3602ef" -H
"txn_operation:commit" http://fe_host:http_port/api/{db}/{table}/_stream_load_2pc
{
  "status": "Success",
  "msg": "label [55c8ffc9-1c40-4d51-b75e-f2265b3602ef] commit successfully."
}

```

3. 对事务触发 abort 操作（请求发往 FE 或 BE 均可）

- 可以使用事务 id 指定事务

```

curl -X PUT --location-trusted -u user:passwd -H "txn_id:18037" -H "txn_operation:abort"
http://fe_host:http_port/api/{db}/{table}/stream_load2pc
{
  "status": "Success",
  "msg": "transaction [18037] abort successfully."
}

```

- 也可以使用 label 指定事务

```

curl -X PUT --location-trusted -u user:passwd -H "label:55c8ffc9-1c40-4d51-b75e-f2265b3602ef" -H
"txn_operation:abort" http://fe_host:http_port/api/{db}/{table}/stream_load2pc
{
  "status": "Success",
  "msg": "label [55c8ffc9-1c40-4d51-b75e-f2265b3602ef] abort successfully."
}

```

Broker Load

所有 Broker Load 导入任务都是原子生效的。并且在同一个导入任务中对多张表的导入也能够保证原子性。还可以通过 Label 的机制来保证数据导入的不丢不重。

下面例子是从 HDFS 导入数据，使用通配符匹配两批文件，分别导入到两个表中。

```
LOAD LABEL example_db.label2
(
  DATA INFILE("hdfs://hdfs_host:hdfs_port/input/file-10*")
  INTO TABLE `my_table1`
  PARTITION (p1)
  COLUMNS TERMINATED BY ","
  (k1, tmp_k2, tmp_k3)
  SET (
    k2 = tmp_k2 + 1,
    k3 = tmp_k3 + 1
  )
  DATA INFILE("hdfs://hdfs_host:hdfs_port/input/file-20*")
  INTO TABLE `my_table2`
  COLUMNS TERMINATED BY ","
  (k1, k2, k3)
)
WITH BROKER hdfs
(
  "username"="hdfs_user",
  "password"="hdfs_password"
);
```

使用通配符匹配导入两批文件 file-10* 和 file-20*。分别导入到 my_table1 和 my_table2 两张表中。其中 my_table1 指定导入到分区 p1 中，并且将导入源文件中第二列和第三列的值 +1 后导入。

最佳实践

Label 通常被设置为 业务逻辑+时间 的格式。如 my_business1_20220330_125000。

这个 Label 通常用于表示：业务 my_business1 这个业务在 2022-03-30 12:50:00 产生的一批数据。通过这种 Label 设定，业务上可以通过 Label 查询导入任务状态，来明确的获知该时间点批次的数据是否已经导入成功。如果没有成功，则可以使用这个 Label 继续重试导入。

INSERT INTO 支持将 Doris 查询的结果导入到另一个表中。INSERT INTO 是一个同步导入方式，执行导入后返回导入结果。可以通过请求的返回判断导入是否成功。INSERT INTO 可以保证导入任务的原子性，要么全部导入成功，要么全部导入失败。

数据转化

使用场景

在导入过程中，Doris 支持对源数据进行一些变换，具体有：映射、转换、前置过滤和后置过滤。

- 映射：把源数据中的 A 列导入到目标表中的 B 列。
- 变换：以源数据中的列为参数，通过一个表达式计算出目标列中的值，表达式中支持自定义函数。
- 前置过滤：过滤源数据中的行，只导入符合过滤条件的行。
- 后置过滤：过滤结果中的行，只导入符合过滤条件的行。

快速上手

BROKER LOAD

```
LOAD LABEL example_db.label1
(
  DATA INFILE("bos://bucket/input/file")
  INTO TABLE `my_table`
  (k1, k2, tmpk3)
  PRECEDING FILTER k1 = 1
  SET (
    k3 = tmpk3 + 1
  )
  WHERE k1 > k2
)
WITH BROKER bos
(
  ...
);
```

STREAM LOAD

```
curl
--location-trusted
-u user:passwd
-H "columns: k1, k2, tmpk3, k3 = tmpk3 + 1"
-H "where: k1 > k2"
-T file.txt
http://host:port/api/testDb/testTbl/_stream_load
```

ROUTINE LOAD

```
CREATE ROUTINE LOAD example_db.label1 ON my_table
COLUMNS(k1, k2, tmpk3, k3 = tmpk3 + 1),
PRECEDING FILTER k1 = 1,
```

```
WHERE k1 > k2
...
```

参考手册

导入语法

Stream Load

在 HTTP header 中增加 columns 和 where 参数

- columns 指定列映射和值变换。
- where 指定后置过滤。

Stream load 不支持前置过滤。

示例：

```
curl
--location-trusted
-u user:passwd
-H "columns: k1, k2, tmpk3, k3 = tmpk3 + 1"
-H "where: k1 > k2"
-T file.txt
http://host:port/api/testDb/testTbl/_stream_load
```

Broker Load

在 SQL 语句中定义数据变换，其中：

- (k1, k2, tmpk3) 指定列映射。
- PRECEDING FILTER 指定前置过滤。
- SET 指定列变换。
- WHERE 指定后置过滤。

```
LOAD LABEL example_db.label1
(
  DATA INFILE("bos://bucket/input/file")
  INTO TABLE `my_table`
  (k1, k2, tmpk3)
  PRECEDING FILTER k1 = 1
  SET (
    k3 = tmpk3 + 1
  )
  WHERE k1 > k2
)
WITH BROKER bos
(
  ...
);
```

Routine Load

在 SQL 语句中定义数据变换，其中：

- COLUMNS 指定列映射和列变换。
- PRECEDING FILTER 指定前置过滤。
- WHERE 指定后置过滤。

```
CREATE ROUTINE LOAD example_db.label1 ON my_table
COLUMNS(k1, k2, tmpk3, k3 = tmpk3 + 1),
PRECEDING FILTER k1 = 1,
WHERE k1 > k2
...
```

Insert Into

Insert Into 可以直接在 SELECT 语句中完成数据变换，增加 WHERE 子句完成数据过滤。

列映射

列映射的目的主要是描述导入文件中各个列的信息，相当于为源数据中的列定义名称。通过描述列映射关系，我们可以将表中列顺序不同、列数量不同的源文件导入到 Doris 中。下面我们通过示例说明：

假设源文件有 4 列，内容如下（表头列名仅为方便表述，实际并无表头）：

| 列 1 | 列 2 | 列 3 | 列 4 |
|-----|-----|-----------|-----|
| 1 | 100 | beijing | 1.1 |
| 2 | 200 | shanghai | 1.2 |
| 3 | 300 | guangzhou | 1.3 |
| 4 | \N | chongqing | 1.4 |

注：\N 在源文件中表示 null。

1. 调整映射顺序
2. 假设表中有 k1,k2,k3,k4 4 列。我们希望的导入映射关系如下：

```
列1 -> k1
列2 -> k3
列3 -> k2
列4 -> k4
```

3. 则列映射的书写顺序应如下：

```
(k1, k3, k2, k4)
```

4. 源文件中的列数量多于表中的列
5. 假设表中有 k1,k2,k3 3 列。我们希望的导入映射关系如下：


```
列1 -> k1  
列2 -> k3  
列3 -> k2
```

6. 则列映射的书写顺序应如下：

```
(k1, k3, k2, tmpk4)
```

7. 其中 tmpk4 为一个自定义的、表中不存在的列名。Doris 会忽略这个不存在的列名。

8. 源文件中的列数量少于表中的列，使用默认值填充

9. 假设表中有 k1,k2,k3,k4,k5 5 列。我们希望的导入映射关系如下：

```
列1 -> k1  
列2 -> k3  
列3 -> k2
```

10. 这里我们仅使用源文件中的前 3 列。k4,k5 两列希望使用默认值填充。

11. 则列映射的书写顺序应如下：

```
(k1, k3, k2)
```

12. 如果 k4,k5 列有默认值，则会填充默认值。否则如果是 nullable 的列，则会填充 null 值。否则，导入作业会报错。

前置过滤

前置过滤是对读取到的原始数据进行一次过滤。目前仅支持 BROKER LOAD 和 ROUTINE LOAD。

前置过滤有以下应用场景：

1. 转换前做过滤
2. 希望在列映射和转换前做过滤的场景。能够先行过滤掉部分不需要的数据。
3. 过滤列不存在于表中，仅作为过滤标识
4. 比如源数据中存储了多张表的数据（或者多张表的数据写入了同一个 Kafka 消息队列）。数据中每行有一列表名来标识该行数据属于哪个表。用户可以通过前置过滤条件来筛选对应的表数据进行导入。

列转换

列转换功能允许用户对源文件中列值进行变换。目前 Doris 支持使用绝大部分内置函数、用户自定义函数进行转换。

注：自定义函数隶属于某一数据库下，在使用自定义函数进行转换时，需要用户对这个数据库有读权限。

转换操作通常是和列映射一起定义的。即先对列进行映射，再进行转换。下面我们通过示例说明：

假设源文件有 4 列，内容如下（表头列名仅为方便表述，实际并无表头）：

| 列 1 | 列 2 | 列 3 | 列 4 |
|-----|-----|-----------|-----|
| 1 | 100 | beijing | 1.1 |
| 2 | 200 | shanghai | 1.2 |
| 3 | 300 | guangzhou | 1.3 |
| \N | 400 | chongqing | 1.4 |

- 1. 将源文件中的列值经转换后导入表中
- 2. 假设表中有 k1,k2,k3,k4 4 列。我们希望的导入映射和转换关系如下：

| | |
|----------|-------|
| 列1 | -> k1 |
| 列2 * 100 | -> k3 |
| 列3 | -> k2 |
| 列4 | -> k4 |

- 3. 则列映射的书写顺序应如下：

| |
|---------------------------------------|
| (k1, tmpk3, k2, k4, k3 = tmpk3 * 100) |
|---------------------------------------|

- 4. 这里相当于我们将源文件中的第 2 列命名为 tmpk3，同时指定表中 k3 列的值为 tmpk3 * 100。最终表中的数据如下：

| k1 | k2 | k3 | k4 |
|------|-----------|-------|-----|
| 1 | beijing | 10000 | 1.1 |
| 2 | shanghai | 20000 | 1.2 |
| 3 | guangzhou | 30000 | 1.3 |
| null | chongqing | 40000 | 1.4 |

- 5. 通过 case when 函数，有条件的进行列转换。
- 6. 假设表中有 k1,k2,k3,k4 4 列。我们希望对于源数据中的 beijing, shanghai, guangzhou, chongqing 分别转换为对应的地区 id 后导入：

| | |
|--------------|-------|
| 列1 | -> k1 |
| 列2 | -> k2 |
| 列3 进行地区id转换后 | -> k3 |
| 列4 | -> k4 |

- 7. 则列映射的书写顺序应如下：

| |
|---|
| (k1, k2, tmpk3, k4, k3 = case tmpk3 when "beijing" then 1 when "shanghai" then 2 when "guangzhou" then 3 when "chongqing" then 4 else null end) |
|---|

8. 最终表中的数据如下：

| k1 | k2 | k3 | k4 |
|------|-----|----|-----|
| 1 | 100 | 1 | 1.1 |
| 2 | 200 | 2 | 1.2 |
| 3 | 300 | 3 | 1.3 |
| null | 400 | 4 | 1.4 |

9. 将源文件中的 null 值转换成 0 导入。同时也进行示例 2 中的地区 id 转换。

10. 假设表中有 k1,k2,k3,k4 4 列。在对地区 id 转换的同时，我们也希望对于源数据中 k1 列的 null 值转换成 0 导入：

```
列1 如果为null 则转换成0    -> k1
列2                            -> k2
列3                            -> k3
列4                            -> k4
```

11. 则列映射的书写顺序应如下：

```
(tmpk1, k2, tmpk3, k4, k1 = ifnull(tmpk1, 0), k3 = case tmpk3 when "beijing" then 1 when "shanghai" then 2
when "guangzhou" then 3 when "chongqing" then 4 else null end)
```

12. 最终表中的数据如下：

| k1 | k2 | k3 | k4 |
|----|-----|----|-----|
| 1 | 100 | 1 | 1.1 |
| 2 | 200 | 2 | 1.2 |
| 3 | 300 | 3 | 1.3 |
| 0 | 400 | 4 | 1.4 |

后置过滤

经过列映射和转换后，我们可以通过过滤条件将不希望导入到 Doris 中的数据进行过滤。下面我们通过示例说明：

假设源文件有 4 列，内容如下（表头列名仅为方便表述，实际并无表头）：

| 列 1 | 列 2 | 列 3 | 列 4 |
|------|-----|-----------|-----|
| 1 | 100 | beijing | 1.1 |
| 2 | 200 | shanghai | 1.2 |
| 3 | 300 | guangzhou | 1.3 |
| null | 400 | chongqing | 1.4 |

1. 在列映射和转换缺省的情况下，直接过滤

2. 假设表中有 k1,k2,k3,k4 4 列。我们可以在缺省列映射和转换的情况下，直接定义过滤条件。如我们希望只导入源文件中第 4 列为大于 1.2 的数据行，则过滤条件如下：

```
where k4 > 1.2
```

3. 最终表中的数据如下：

| k1 | k2 | k3 | k4 |
|------|-----|-----------|-----|
| 3 | 300 | guangzhou | 1.3 |
| null | 400 | chongqing | 1.4 |

4. 缺省情况下，Doris 会按照顺序进行列映射，因此源文件中的第 4 列自动被映射到表中的 k4 列。

5. 对经过列转换的数据进行过滤

6. 假设表中有 k1,k2,k3,k4 4 列。在 列转换 示例中，我们将省份名称转换成了 id。这里我们想过滤掉 id 为 3 的数据。则转换、过滤条件如下：

```
(k1, k2, tmpk3, k4, k3 = case tmpk3 when "beijing" then 1 when "shanghai" then 2 when "guangzhou" then 3 when "chongqing" then 4 else null end)  
where k3 != 3
```

7. 最终表中的数据如下：

| k1 | k2 | k3 | k4 |
|------|-----|----|-----|
| 1 | 100 | 1 | 1.1 |
| 2 | 200 | 2 | 1.2 |
| null | 400 | 4 | 1.4 |

8. 这里我们看到，执行过滤时的列值，为经过映射和转换后的最终列值，而不是原始数据。

9. 多条件过滤

10. 假设表中有 k1,k2,k3,k4 4 列。我们想过滤掉 k1 列为 null 的数据，同时过滤掉 k4 列小于 1.2 的数据，则过滤条件如下：

```
where k1 is not null and k4 >= 1.2
```

11. 最终表中的数据如下：

| k1 | k2 | k3 | k4 |
|----|-----|----|-----|
| 2 | 200 | 2 | 1.2 |
| 3 | 300 | 3 | 1.3 |

最佳实践

数据质量问题和过滤阈值

导入作业中被处理的数据行可以分为如下三种：

- Filtered Rows 因数据质量不合格而被过滤掉的数据。数据质量不合格包括类型错误、精度错误、字符串长度超长、文件列数不匹配等数据格式问题，以及因没有对应的分区而被过滤掉的数据行。
- Unselected Rows 这部分为因 preceding filter 或 where 列过滤条件而被过滤掉的数据行。
- Loaded Rows 被正确导入的数据行。

Doris 的导入任务允许用户设置最大错误率（max_filter_ratio）。如果导入的数据的错误率低于阈值，则这些错误行将被忽略，其他正确的数据将被导入。

错误率的计算方式为：

```
#Filtered Rows / (#Filtered Rows + #Loaded Rows)
```

也就是说 Unselected Rows 不会参与错误率的计算。

最小写入副本数

默认情况下，数据导入要求至少有超过半数的副本写入成功，导入才算成功。然而，这种方式不够灵活，在某些场景会带来不便。

举个例子，对于两副本情况，按上面的多数派原则，要想导入数据，则需要这两个副本都写入成功。这意味着，在导入数据过程中，不允许任意一个副本不可用。这极大影响了集群的可用性。

为了解决以上问题，Doris 允许用户设置最小写入副本数 (Min Load Replica Num)。对导入数据任务，当它成功写入的副本数大于或等于最小写入副本数时，导入即成功。

用法

单个表的最小写入副本数

可以对单个 OLAP 表，设置最小写入副本数，并用表属性 `min_load_replica_num` 来表示。该属性的有效值要求大于 0 且不超过表的副本数。其默认值为 -1，表示不启用该属性。

可以在创建表时设置表的 `min_load_replica_num`。

```
CREATE TABLE test_table1
(
    k1 INT,
    k2 INT
)
DUPLICATE KEY(k1)
DISTRIBUTED BY HASH(k1) BUCKETS 5
PROPERTIES
(
    'replication_num' = '2',
    'min_load_replica_num' = '1'
);
```

对一个已存在的表，可以使用语句 `ALTER TABLE` 来修改它的 `min_load_replica_num`。

```
ALTER TABLE test_table1
SET ( 'min_load_replica_num' = '1');
```

可以使用语句 `SHOW CREATE TABLE` 来查看表的属性 `min_load_replica_num`。

```
SHOW CREATE TABLE test_table1;
```

输出结果的 `PROPERTIES` 中将包含 `min_load_replica_num`。例如：

```
Create Table: CREATE TABLE `test_table1` (
  `k1` int(11) NULL,
  `k2` int(11) NULL
) ENGINE=OLAP
DUPLICATE KEY(`k1`)
COMMENT 'OLAP'
```

```
DISTRIBUTED BY HASH(`k1`) BUCKETS 5
PROPERTIES (
  "replication_allocation" = "tag.location.default: 2",
  "min_load_replica_num" = "1",
  "storage_format" = "V2",
  "light_schema_change" = "true",
  "disable_auto_compaction" = "false",
  "enable_single_replica_compaction" = "false"
);
```

全局最小写入副本数

可以对所有 OLAP 表，设置全局最小写入副本数，并用 FE 的配置项 `min_load_replica_num` 来表示。该配置项的有效值要求大于 0。其默认值为 -1，表示不开启全局最小写入副本数。

对一个表，如果表属性 `min_load_replica_num` 有效（即大于 0），那么该表将会忽略全局配置 `min_load_replica_num`。否则，如果全局配置 `min_load_replica_num` 有效（即大于 0），那么该表的最小写入副本数将等于 $\min(\text{FE.conf.min_load_replica_num}, \text{table.replication_num}/2 + 1)$ 。

对于 FE 配置项的查看和修改，可以参考[这里](#)。

其余情况

如果没有开启表属性 `min_load_replica_num`（即小于或者等于 0），也没有设置全局配置 `min_load_replica_num`（即小于或等于 0），那么数据的导入仍需多数派副本写入成功才算成功。此时，表的最小写入副本数等于 $\text{table.replication_num}/2 + 1$ 。

严格模式

严格模式（strict_mode）为导入操作中的一个参数配置。该参数会影响某些数值的导入行为和最终导入的数据。

本文档主要说明如何设置严格模式，以及严格模式产生的影响。

如何设置

严格模式默认情况下都为 False，即关闭状态。

不同的导入方式设置严格模式的方式不尽相同。

1. [BROKER LOAD](#)

```
LOAD LABEL example_db.label1
(
  DATA INFILE("bos://my_bucket/input/file.txt")
  INTO TABLE `my_table`
  COLUMNS TERMINATED BY ","
)
WITH BROKER bos
(
  "bos_endpoint" = "http://bj.bcebos.com",
  "bos_accesskey" = "xxxxxxxxxxxxxxxxxxxxxxxxxxxx",
  "bos_secret_accesskey"="yyyyyyyyyyyyyyyyyyyyyyyyyyyyyy"
)
PROPERTIES
(
  "strict_mode" = "true"
)
```

2. [STREAM LOAD](#)

```
curl --location-trusted -u user:passwd \
-H "strict_mode: true" \
-T 1.txt \
http://host:port/api/example_db/my_table/_stream_load
```

3. [ROUTINE LOAD](#)

```
CREATE ROUTINE LOAD example_db.test_job ON my_table
PROPERTIES
(
  "strict_mode" = "true"
)
FROM KAFKA
(
  "kafka_broker_list" = "broker1:9092,broker2:9092,broker3:9092",
  "kafka_topic" = "my_topic"
);
```

4. [INSERT](#)

通过[会话变量](#)设置：

```
SET enable_insert_strict = true;
INSERT INTO my_table ...;
```

严格模式的作用

对于导入过程中的列类型转换进行严格过滤。

严格过滤的策略如下：

对于列类型转换来说，如果开启严格模式，则错误的的数据将被过滤。这里的错误数据是指：原始数据并不为 null，而在进行列类型转换后结果为 null 的这一类数据。

这里说指的 列类型转换，并不包括用函数计算得出的 null 值。

对于导入的某列类型包含范围限制的，如果原始数据能正常通过类型转换，但无法通过范围限制的，严格模式对其也不产生影响。例如：如果类型是 decimal(1,0)，原始数据为 10，则属于可以通过类型转换但不在列声明的范围内。这种数据 strict 对其不产生影响。

1. 以列类型为 TinyInt 来举例：

| 原始数据类型 | 原始数据举例 | 转换为 TinyInt 后的值 | 严格模式 | 结果 |
|--------|---------------|-----------------|-------|----------|
| 空值 | \N | NULL | 开启或关闭 | NULL |
| 非空值 | “abc” or 2000 | NULL | 开启 | 非法值（被过滤） |
| 非空值 | “abc” | NULL | 关闭 | NULL |
| 非空值 | 1 | 1 | 开启或关闭 | 正确导入 |

说明：

- 1. 表中的列允许导入空值
- 2. abc 及 2000 在转换为 TinyInt 后，会因类型或精度问题变为 NULL。在严格模式开启的情况下，这类数据将会被过滤。而如果是关闭状态，则会导入 null。

2. 以列类型为 Decimal(1,0) 举例

| 原始数据类型 | 原始数据举例 | 转换为 Decimal 后的值 | 严格模式 | 结果 |
|--------|---------|-----------------|-------|----------|
| 空值 | \N | null | 开启或关闭 | NULL |
| 非空值 | aaa | NULL | 开启 | 非法值（被过滤） |
| 非空值 | aaa | NULL | 关闭 | NULL |
| 非空值 | 1 or 10 | 1 or 10 | 开启或关闭 | 正确导入 |

说明：

1. 表中的列允许导入空值

2. abc 在转换为 Decimal 后，会因类型问题变为 NULL。在严格模式开启的情况下，这类数据将会被过滤。而如果是关闭状态，则会导入 null。

3. 10 虽然是一个超过范围的值，但是因为其类型符合 decimal 的要求，所以严格模式对其不产生影响。10 最后会在其他导入处理流程中被过滤。但不会被严格模式过滤。

限定部分列更新只能更新已有的列

在严格模式下，部分列更新插入的每一行数据必须满足该行数据的 Key 在表中已经存在。而在而非严格模式下，进行部分列更新时可以更新 Key 已经存在的行，也可以插入 Key 不存在的新行。

例如有表结构如下：

```
mysql> desc user_profile;
+-----+-----+-----+-----+-----+-----+
| Field          | Type          | Null | Key  | Default | Extra |
+-----+-----+-----+-----+-----+-----+
id	INT	Yes	true	NULL	
name	VARCHAR(10)	Yes	false	NULL	NONE
age	INT	Yes	false	NULL	NONE
city	VARCHAR(10)	Yes	false	NULL	NONE
balance	DECIMALV3(9, 0)	Yes	false	NULL	NONE
last_access_time	DATETIME	Yes	false	NULL	NONE
+-----+-----+-----+-----+-----+-----+
```

表中有一条数据如下：

```
1,"kevin",18,"shenzhen",400,"2023-07-01 12:00:00"
```

当用户使用非严格模式的 Stream Load 部分列更新向表中插入如下数据时

```
1,500,2023-07-03 12:00:01
3,23,2023-07-03 12:00:02
18,9999999,2023-07-03 12:00:03
```

```
curl --location-trusted -u root -H "partial_columns:true" -H "strict_mode:false" -H "column_separator:," -H
"columns:id,balance,last_access_time" -T /tmp/test.csv http://host:port/api/db1/user_profile/_stream_load
```

表中原有的一条数据将会被更新，此外还向表中插入了两条新数据。对于插入的数据中用户没有指定的列，如果该列有默认值，则会以默认值填充；否则，如果该列可以为 NULL，则将以 NULL 值填充；否则本次插入不成功。

而当用户使用严格模式的 Stream Load 部分列更新向表中插入上述数据时

```
curl --location-trusted -u root -H "partial_columns:true" -H "strict_mode:true" -H "column_separator:," -H
"columns:id,balance,last_access_time" -T /tmp/test.csv http://host:port/api/db1/user_profile/_stream_load
```

此时，由于开启了严格模式且第二、三行的数据的 key((3),(18)) 不在原表中，所以本次导入会失败。

数据更新概述

数据更新是指对具有相同 key 的数据记录中的 value 列进行修改。对于不同的数据模型，数据更新的处理方式有所不同：

- **主键（Unique）模型：**主键模型是专门为数据更新设计的一种数据模型。Doris 支持两种存储方式：Merge-on-Read（MoR）和 Merge-on-Write（MoW）。MoR 优化了写入性能，而 MoW 则提供了更好的分析性能。在 Doris 2.0 版本中，默认存储方式为 MoR。主键模型支持使用 UPDATE 语句进行少量数据更新，也支持通过导入方式进行批量更新。导入方式包括 Stream Load、Broker Load、Routine Load 和 Insert Into 等，所有导入操作都遵循“UPSERT”语义，即如果记录不存在则插入，存在则更新。更新操作支持整行更新和部分列更新，默认为整行更新。
- **聚合（Aggregate）模型：**在聚合模型中，数据更新是一种特殊用法。当聚合函数设置为 REPLACE 或 REPLACE_IF_NOT_NULL 时，可以实现数据更新。聚合模型仅支持基于导入方式的更新，不支持使用 UPDATE 语句。通过设置聚合函数为 REPLACE_IF_NOT_NULL，可以实现部分列更新的能力。

通过对不同模型的数据更新方式的理解，可以更好地选择适合的更新策略，以满足具体的业务需求。

不同模型/实现的更新能力对比

性能对比

| | Unique Key MoW | Unique Key MoR | Aggregate Key |
|------|---|--------------------|--------------------|
| 导入速度 | 导入过程中进行数据去重，小批量实时写入相比 MoR 约有 10%-20% 的性能损失，大批量导入（例如千万级/亿级数据）相比 MoR 约有 30%-50% 的性能损失 | 与 Duplicate Key 接近 | 与 Duplicate Key 接近 |

| | Unique Key MoW | Unique Key MoR | A
g
g
r
e
g
a
t
e
K
e
y |
|------------------|--------------------|---------------------------------|--|
| 查
询
速
度 | 与 Duplicate Key 接近 | 需要在查询期间进行去重，查询耗时约为 MoW 的 3-10 倍 | 如果聚合函数为 REPLACE / REPLACE - IF - NOT - NULL，查询速度与 MoR 接近 |

| | Unique Key MoW | Unique Key MoR | Aggregate Key |
|------|---|---|---------------------|
| 谓词下推 | 支持 | 不支持 | 不支持 |
| 资源消耗 | - 导入资源消耗：相比 Duplicate Key/Unique Key MoR，约额外消耗 10%-30% 的 CPU。
- 查询资源消耗：与 Duplicate Key 接近，无额外资源消耗。
- Compaction 资源消耗：相比 Duplicate Key，消耗更多内存和 CPU，具体取决于数据特征和数据量。 | - 导入资源消耗：与 Duplicate Key 相近，无额外资源消耗。
- 查询资源消耗：相比 Duplicate Key/Unique Key MoW，查询时额外消耗更多的 CPU 和内存。
- Compaction 资源消耗：相比 Duplicate Key，需更多内存和 CPU，具体数值取决于数据特征和数据量。 | 与 Unique Key MoR 相同 |

功能支持对比

| | Unique Key MoW | Unique Key MoR | Aggregate Key |
|-------------|----------------|----------------|------------------|
| UPDATE | 支持 | 支持 | 不支持 |
| DELETE | 支持 | 支持 | 不支持 |
| sequence 列 | 支持 | 支持 | 不支持 |
| delete_sign | 支持 | 支持 | 不支持 |
| 部分列更新 | 支持 | 不支持 | 支持(但无法更新 null 值) |
| 倒排索引 | 支持 | 不支持 | 不支持 |

主键（Unique）模型的更新

Doris 主键 (unique) 模型，从 Doris 2.0 开始，除了原来的 Merge-on-Read (MoR)，也引入了 Merge-on-Write (MoW) 的存储方式，MoR 是为了写入做优化，而 MoW 是为了更快的分析性能做优化。在实际测试中，MoW 存储方式的典型表，分析性能可以是 MoR 方式的 5-10 倍。

在 Doris 2.0，默认创建的 unique 模型依旧是 MoR 的，如果要创建 MoW 的，需要通过参数 “enable_unique_key_merge_on_write” = “true” 手动指定，如下示例：

```
CREATE TABLE IF NOT EXISTS example_tbl_unique_merge_on_write
(
  `user_id` LARGEINT NOT NULL,
  `username` VARCHAR(50) NOT NULL ,
  `city` VARCHAR(20),
  `age` SMALLINT,
  `sex` TINYINT,
  `phone` LARGEINT,
  `address` VARCHAR(500),
  `register_time` DATETIME
)
UNIQUE KEY(`user_id`, `username`)
DISTRIBUTED BY HASH(`user_id`) BUCKETS 1
PROPERTIES (
  "replication_allocation" = "tag.location.default: 1",
  "enable_unique_key_merge_on_write" = "true"
);
```

从 Doris 2.1 版本开始，写时合并是主键模型的默认方式。所以如果使用 Doris 2.1 及以上版本，务必要阅读相关建表文档。

主键模型的两种更新方式

使用 UPDATE 语句更新

无论是 MoR 还是 MoW，语义都是完成对指定列的更新。单次 UPDATE 的耗时会随着被更新的数据量的增加而增长。

基于导入的批量更新

Doris 支持多种数据导入方式，包括 Stream Load、Broker Load、Routine Load 以及 Insert Into 等。对于主键表，所有导入操作默认采用“UPSERT”语义：当相同主键的记录不存在时执行插入操作，若记录已存在则进行更新操作。更新方式包括整行更新和部分列更新：

- **整行更新**：Unique Key 表的更新默认为整行更新。在导入数据时，用户可以选择提供所有字段，或仅提供部分字段。当用户只提供部分字段时，Doris 会用默认值填充缺失的字段，生成完整记录并进行更新。
- **部分列更新**：Unique Key MoW 支持部分列更新。用户可以通过设置会话变量 `enable_unique_key_partial_update = true` 或在 HTTP Header 中指定 `partial_columns:true` 来启用此功能。开启后，若导入数据的主键已存在，则仅更新指定的部分字段；若主键不存在，则使用默认值填充缺失字段。

我们会分别在文档 [主键模型的 Update 更新](#) 和 [主键模型的导入更新](#) 详细介绍两种更新方式。

主键模型的更新并发控制

使用 UPDATE 语句更新数据

默认情况下，Doris 不允许在同一时间对同一张表进行多个 UPDATE 操作。UPDATE 语句通过表级锁来确保隔离性。

用户可以通过修改 FE 配置 `enable_concurrent_update=true` 来调整并发限制。当放宽并发限制时，多个 UPDATE 语句如果更新同一行数据，结果将是未定义的。

基于导入的批量更新

Doris 对所有导入更新操作提供原子性保障，即每次导入数据要么全部成功应用，要么全部失败回滚。

对于并发导入更新，Doris 基于系统内部版本控制（按照导入完成提交的顺序进行分配），使用 MVCC 机制确定并发更新的顺序。

由于多个并发导入更新的提交顺序可能无法预期，若这些并发导入涉及相同主键的更新，则其生效顺序也无法预知，最终的可见结果会因此存在不确定性。为解决此问题，Doris 提供了 `sequence` 列机制，允许用户在并发导入更新时为每一行数据指定版本，以便明确控制并发更新的结果顺序，实现确定性。

我们将在文档 [主键模型的更新并发控制](#) 中对事务机制进行详细介绍。

聚合（Aggregate）模型的更新

聚合模型的更新，主要是指用新的列值和旧的聚合值按照聚合函数的要求产出新的聚合值。

$$\text{New Agg Value} = \text{Agg Func}(\text{Old Agg Value}, \text{New Column Value})$$

聚合模型只支持基于导入方式的更新，不支持使用 Update 语句更新。在定义聚合模型表的时候，如果把 value 列的聚合函数定义为 `REPLACE_IF_NOT_NULL`，也可以间接实现类似主键表的部分列更新能力。更多内容，请查看 [聚合模型的导入更新](#)。

主键模型和聚合模型的选择建议

- 大部分有数据更新需求的场景，都建议**首选主键模型**。例如从 TP 数据库 CDC 同步到 Doris，用户画像，人群圈选等。
- 下面两类场景，建议使用聚合模型
 - 部分字段需要做指标聚合，部分字段需要进行更新
 - 对部分列更新有需求，同时对写入性能非常敏感，对查询延迟要求不高的场景，建议使用聚合表 + `REPLACE_IF_NOT_NULL` 聚合函数

主键模型的 Update 更新

主要讲述如何使用 Update 命令来更新 Doris 中的数据。Update 命令只能在 Unique 数据模型的表中执行。

适用场景

- 对满足某些条件的行，修改其取值
- 适合少量数据，不频繁的更新

基本原理

利用查询引擎自身的 where 过滤逻辑，从待更新表中筛选出需要被更新的行。再利用 Unique 模型自带的 Value 列新数据替换旧数据的逻辑，将待更新的行变更后，再重新插入到表中，从而实现行级别更新。

同步

Update 语法在 Doris 中是一个同步语法，即 Update 语句执行成功，更新操作也就完成了，数据是可见的。

性能

Update 语句的性能和待更新的行数以及查询条件的检索效率密切相关。

- 待更新的行数：待更新的行数越多，Update 语句的速度就会越慢。Update 更新比较适合偶发更新的场景，比如修改个别行的值。Update 并不适合大批量的修改数据。
- 查询条件的检索效率：Update 实现原理是先将满足查询条件的行做读取处理，所以如果查询条件的检索效率高，则 Update 的速度也会快。条件列最好能命中索引或者分区分桶裁剪，这样 Doris 就不需要扫全表，可以快速定位到需要更新的行，从而提升更新效率。强烈不推荐条件列中包含 value 列。

使用示例

假设在金融风控场景中，存在如下结构的交易明细表：

```
CREATE TABLE transaction_details (
  transaction_id BIGINT NOT NULL,      -- 唯一交易编号
  user_id BIGINT NOT NULL,            -- 用户编号
  transaction_date DATE NOT NULL,      -- 交易日期
  transaction_time DATETIME NOT NULL,  -- 交易时间
  transaction_amount DECIMAL(18, 2),  -- 交易金额
  transaction_device STRING,          -- 交易设备
  transaction_region STRING,          -- 交易地区
  average_daily_amount DECIMAL(18, 2), -- 最近3个月日均交易金额
  recent_transaction_count INT,        -- 最近7天交易次数
  has_dispute_history BOOLEAN,        -- 是否有拒付记录
  risk_level STRING                   -- 风险等级
)
UNIQUE KEY(transaction_id)
DISTRIBUTED BY HASH(transaction_id) BUCKETS 16
PROPERTIES (
```



```
"replication_num" = "3",          -- 副本数量，默认3
"enable_unique_key_merge_on_write" = "true" -- 启用MOW模式，支持合并更新
);
```

存在如下交易数据：

| transaction_id | user_id | transaction_date | transaction_time | transaction_amount | transaction_device | transaction_region | average_daily_amount | recent_transaction_count | has_dispute_history | risk_level |
|----------------|---------|------------------|---------------------|--------------------|--------------------|--------------------|----------------------|--------------------------|---------------------|------------|
| 1001 | 5001 | 2024-11-24 | 2024-11-24 14:30:00 | 100.00 | iPhone 12 | New York | 100.00 | 10 | 0 | NULL |
| 1002 | 5002 | 2024-11-24 | 2024-11-24 03:30:00 | 120.00 | iPhone 12 | New York | 100.00 | 15 | 0 | NULL |
| 1003 | 5003 | 2024-11-24 | 2024-11-24 10:00:00 | 150.00 | Samsung S21 | Los Angeles | 100.00 | 30 | 0 | NULL |
| 1004 | 5004 | 2024-11-24 | 2024-11-24 16:00:00 | 300.00 | MacBook Pro | high_risk_region1 | 200.00 | 5 | 0 | NULL |
| 1005 | 5005 | 2024-11-24 | 2024-11-24 11:00:00 | 1100.00 | iPad Pro | Chicago | 200.00 | 10 | 0 | NULL |

按照如下风控规则来更新每日所有交易记录的风险等级：1. 有拒付记录，风险为 high。2. 在高风险地区，风险为 high。3. 交易金额异常（超过日均 5 倍），风险为 high。4. 最近 7 天交易频繁：a. 交易次数 > 50，风险为 high。b. 交易次数在 20-50 之间，风险为 medium。5. 非工作时间交易（凌晨 2 点到 4 点），风险为 medium。6. 默认风险为 low。

```
UPDATE transaction_details
SET risk_level = CASE
  -- 有拒付记录或在高风险地区的交易
  WHEN has_dispute_history = TRUE THEN 'high'
  WHEN transaction_region IN ('high_risk_region1', 'high_risk_region2') THEN 'high'

  -- 突然异常交易金额
  WHEN transaction_amount > 5 * average_daily_amount THEN 'high'

  -- 最近7天交易频率很高
  WHEN recent_transaction_count > 50 THEN 'high'
  WHEN recent_transaction_count BETWEEN 20 AND 50 THEN 'medium'

  -- 非工作时间交易
  WHEN HOUR(transaction_time) BETWEEN 2 AND 4 THEN 'medium'

  -- 默认风险
  ELSE 'low'
END
WHERE transaction_date = '2024-11-24';
```

更新之后的数据为

| transaction_id | user_id | transaction_date | transaction_time | transaction_amount | transaction_device | transaction_region | average_daily_amount | recent_transaction_count | has_dispute_history | risk_level |
|----------------|---------|------------------|---------------------|--------------------|--------------------|--------------------|----------------------|--------------------------|---------------------|------------|
| 1001 | 5001 | 2024-11-24 | 2024-11-24 14:30:00 | 100.00 | iPhone 12 | New York | 100.00 | 10 | 0 | NULL |
| 1002 | 5002 | 2024-11-24 | 2024-11-24 03:30:00 | 120.00 | iPhone 12 | New York | 100.00 | 15 | 0 | NULL |
| 1003 | 5003 | 2024-11-24 | 2024-11-24 10:00:00 | 150.00 | Samsung S21 | Los Angeles | 100.00 | 30 | 0 | NULL |
| 1004 | 5004 | 2024-11-24 | 2024-11-24 16:00:00 | 300.00 | MacBook Pro | high_risk_region1 | 200.00 | 5 | 0 | NULL |
| 1005 | 5005 | 2024-11-24 | 2024-11-24 11:00:00 | 1100.00 | iPad Pro | Chicago | 200.00 | 10 | 0 | NULL |

| | | | | | | |
|---|------|------|------------|---------------------|---------|-------------|
| | 1001 | 5001 | 2024-11-24 | 2024-11-24 14:30:00 | 100.00 | iPhone 12 |
| New York | | | 100.00 | 10 | 0 | low |
| | 1002 | 5002 | 2024-11-24 | 2024-11-24 03:30:00 | 120.00 | iPhone 12 |
| New York | | | 100.00 | 15 | 0 | medium |
| | 1003 | 5003 | 2024-11-24 | 2024-11-24 10:00:00 | 150.00 | Samsung S21 |
| Los Angeles | | | 100.00 | 30 | 0 | medium |
| | 1004 | 5004 | 2024-11-24 | 2024-11-24 16:00:00 | 300.00 | MacBook Pro |
| high_risk_region1 | | | 200.00 | 5 | 0 | high |
| | 1005 | 5005 | 2024-11-24 | 2024-11-24 11:00:00 | 1100.00 | iPad Pro |
| Chicago | | | 200.00 | 10 | 0 | high |
| +-----+-----+-----+-----+-----+-----+-----+ | | | | | | |
| +-----+-----+-----+-----+-----+-----+-----+ | | | | | | |

更多帮助

关于数据更新使用的更多详细语法，请参阅 [UPDATE](#) 命令手册，也可以在 MySQL 客户端命令行下输入 `HELP UPDATE` 获取更多帮助信息。

主键模型的导入更新

这篇文档主要介绍 Doris 主键模型上基于导入的更新。

所有列更新

使用 Doris 支持的 Stream Load, Broker Load, Routine Load, Insert Into 等导入方式, 往主键模型 (Unique 模型) 中进行数据导入时, 如果没有相应主键的数据行, 就执行插入新的数据, 如果有相应主键的数据行, 就进行更新。也就是说, Doris 主键模型的导入是一种“upsert”模式。基于导入, 对已有记录的更新, 默认和导入一个新记录是完全一样的, 所以, 这里可以参考数据导入的文档部分。

部分列更新

部分列更新, 主要是指直接更新表中某些字段值, 而不是全部的字段值。可以采用 Update 语句来进行更新, 这种 Update 语句一般采用先将整行数据读出, 然后再更新部分字段值, 再写回。这种读写事务非常耗时, 并且不适合大批量数据写入。Doris 在主键模型的导入更新, 提供了可以直接插入或者更新部分列数据的功能, 不需要先读取整行数据, 这样更新效率就大幅提升了。

注意

1. 2.0 版本仅在 Unique Key 的 Merge-on-Write 实现中支持了部分列更新能力
2. 从 2.0.2 版本开始, 支持使用 INSERT INTO 进行部分列更新
3. 不支持在有同步物化视图的表上进行部分列更新
4. 不支持在进行 Schema Change 的表上进行部分列更新

适用场景

- 实时的动态列更新, 需要在表中实时的高频更新某些字段值。例如用户标签表中有一些关于用户最新行为信息的字段需要实时的更新, 以实现广告/推荐等系统能够据其进行实时的分析和决策。
- 将多张源表拼接成一张大宽表
- 数据修正

使用方式

建表

建表时需要指定如下 property, 以开启 Merge-on-Write 实现

```
enable_unique_key_merge_on_write = true
```

StreamLoad/BrokerLoad/RoutineLoad

如果使用的是 Stream Load/Broker Load/Routine Load, 在导入时添加如下 header

```
partial_columns:true
```

同时在columns中指定要导入的列（必须包含所有 key 列，不然无法更新）

Flink Connector

如果使用 Flink Connector, 需要添加如下配置：

```
'sink.properties.partial_columns' = 'true',
```

同时在sink.properties.column中指定要导入的列（必须包含所有 key 列，不然无法更新）

INSERT INTO

在所有的数据模型中，INSERT INTO 给定一部分列时默认行为都是整行写入，为了防止误用，在 Merge-on-Write 实现中，INSERT INTO默认仍然保持整行 UPSERT 的语意，如果需要开启部分列更新的语意，需要设置如下 session variable

```
set enable_unique_key_partial_update=true
```

需要注意的是，控制 insert 语句是否开启严格模式的会话变量enable_insert_strict的默认值为 true，即 insert 语句默认开启严格模式，而在严格模式下进行部分列更新不允许更新不存在的 key。所以，在使用 insert 语句进行部分列更新的时候如果希望能插入不存在的 key，需要在enable_unique_key_partial_update设置为 true 的基础上同时将enable_insert_strict设置为 false。

示例

假设 Doris 中存在一张订单表 order_tbl，其中订单 id 是 Key 列，订单状态，订单金额是 Value 列。数据状态如下：

| 订单 id | 订单金额 | 订单状态 |
|-------|------|------|
| 1 | 100 | 待付款 |

```
+-----+-----+-----+
| order_id | order_amount | order_status |
+-----+-----+-----+
| 1        | 100         | 待付款       |
+-----+-----+-----+
1 row in set (0.01 sec)
```

这时候，用户点击付款后，Doris 系统需要将订单 id 为 '1' 的订单状态变更为 '待发货'。

若使用 StreamLoad 可以通过如下方式进行更新：

```
$ cat update.csv

1,待发货

$ curl --location-trusted -u root: -H "partial_columns:true" -H "column_separator:;" -H
"columns:order_id,order_status" -T /tmp/update.csv http://127.0.0.1:8030/api/db1/order_tbl/_stream_load
```

若使用INSERT INTO可以通过如下方式进行更新：

```
set enable_unique_key_partial_update=true;
INSERT INTO order_tbl (order_id, order_status) values (1,'待发货');
```

更新后结果如下

```
+-----+-----+-----+
| order_id | order_amount | order_status |
+-----+-----+-----+
| 1        | 100         | 待发货       |
+-----+-----+-----+
1 row in set (0.01 sec)
```

使用注意

由于 Merge-on-Write 实现需要在数据写入的时候，进行整行数据的补齐，以保证最优的查询性能，因此使用 Merge-on-Write 实现进行部分列更新会有部分导入性能下降。

写入性能优化建议：

- 使用配备了 NVMe 的 SSD，或者极速 SSD 云盘。因为补齐数据时会大量的读取历史数据，产生较高的读 IOPS，以及读吞吐
- 开启行存将能够大大减少补齐数据时产生的 IOPS，导入性能提升明显，用户可以在建表时通过如下 property 来开启行存：

```
"store_row_column" = "true"
```

目前，同一批次数据写入任务（无论是导入任务还是INSERT INTO）的所有行只能更新相同的列，如果需要更新不同列的数据，则需要分不同的批次进行写入。

在未来版本中，将支持灵活的列更新，用户可以在同一批导入中，每一行更新不同的列。

聚合模型的导入更新

这篇文档主要介绍 Doris 聚合模型上基于导入的更新。

所有列更新

使用 Doris 支持的 Stream Load, Broker Load, Routine Load, Insert Into 等导入方式, 往聚合模型 (Agg 模型) 中进行数据导入时, 都会将新的值与旧的聚合值, 根据列的聚合函数产出新的聚合值, 这个值可能是插入时产出, 也可能是异步 Compaction 时产出, 但是用户查询时, 都会得到一样的返回值。

聚合模型的部分列更新

Aggregate 表主要在预聚合场景使用而非数据更新的场景使用, 但也可以通过将聚合函数设置为 REPLACE_IF_NOT_NULL 来实现部分列更新效果。

建表

将需要进行列更新的字段对应的聚合函数设置为 REPLACE_IF_NOT_NULL

```
CREATE TABLE order_tbl (
  order_id int(11) NULL,
  order_amount int(11) REPLACE_IF_NOT_NULL NULL,
  order_status varchar(100) REPLACE_IF_NOT_NULL NULL
) ENGINE=OLAP
AGGREGATE KEY(order_id)
COMMENT 'OLAP'
DISTRIBUTED BY HASH(order_id) BUCKETS 1
PROPERTIES (
  "replication_allocation" = "tag.location.default: 1"
);
```

| order_id | order_amount | order_status |
|----------|--------------|--------------|
| 1 | 100 | 待付款 |

1 row in set (0.01 sec)

数据写入

无论是 Stream Load、Broker Load、Routine Load 还是 INSERT INTO, 直接写入要更新的字段的数据即可

示例

与前面例子相同, 对应的 Stream Load 命令为 (不需要额外的 header):

```
$ cat update.csv

1,To be shipped

curl --location-trusted -u root: -H "column_separator:," -H "columns:order_id,order_status" -T
/tmp/update.csv http://127.0.0.1:8030/api/db1/order_tbl/_stream_load
```

对应的INSERT INTO语句为（不需要额外设置 session variable）：

```
INSERT INTO order_tbl (order_id, order_status) values (1,'待发货');
```

部分列更新使用注意

Aggregate Key 模型在写入过程中不做任何额外处理，所以写入性能不受影响，与普通的数据导入相同。但是在查询时进行聚合的代价较大，典型的聚合查询性能相比 Unique Key 模型的 Merge-on-Write 实现会有 5-10 倍的下降。

用户无法通过将某个字段由非 NULL 设置为 NULL，写入的 NULL 值在REPLACE_IF_NOT_NULL聚合函数的处理中会自动忽略。

主键模型的更新并发控制

概览

Doris 采用多版本并发控制机制（MVCC - Multi-Version Concurrency Control）来管理并发更新。每次数据写入操作均会分配一个写入事务，该事务确保数据写入的原子性（即写入操作要么完全成功，要么完全失败）。在写入事务提交时，系统会为其分配一个版本号。当用户使用 Unique Key 模型并多次导入数据时，如果存在重复主键，Doris 会根据版本号确定覆盖顺序：版本号较高的数据会覆盖版本号较低的数据。

在某些场景中，用户可能需要通过在建表语句中指定 `sequence` 列来灵活调整数据的生效顺序。例如，当通过多线程并发同步数据到 Doris 时，不同线程的数据可能会乱序到达。这种情况下，可能出现旧数据因较晚到达而错误覆盖新数据的情况。为解决这一问题，用户可以为旧数据指定较低的 `sequence` 值，为新数据指定较高的 `sequence` 值，从而让 Doris 根据用户提供的 `sequence` 值来正确确定数据的更新顺序。

此外，UPDATE 语句与通过导入实现更新在底层机制上存在较大差异。UPDATE 操作涉及两个步骤：从数据库中读取待更新的数据，以及写入更新后的数据。默认情况下，UPDATE 语句通过表级锁提供了 Serializable 隔离级别的事务能力，即多个 UPDATE 操作只能串行执行。用户也可以通过调整配置绕过这一限制，具体方法请参阅以下章节的详细说明。

UPDATE 并发控制

默认情况下，并不允许同一时间对同一张表并发进行多个 UPDATE 操作。

主要原因是，Doris 目前支持的是行更新，这意味着，即使用户声明的是 `SET v2 = 1`，实际上，其他所有的 Value 列也会被覆盖一遍（尽管值没有变化）。

这就会存在一个问题，如果同时有两个 UPDATE 操作对同一行进行更新，那么其行为可能是不确定的，也就是可能存在脏数据。

但在实际应用中，如果用户自己可以保证即使并发更新，也不会同时对同一行进行操作的话，就可以手动打开并发限制。通过修改 FE 配置 `enable_concurrent_update`，当该配置值设置为 `true` 时，更新命令将不再提供事务保证。

注意：

开启 `enable_concurrent_update` 配置后，会有一定的性能风险

Sequence 列

Unique 模型主要针对需要唯一主键的场景，可以保证主键唯一性约束，在同一批次中导入或者不同批次中导入的数据，替换顺序不做保证。替换顺序无法保证则无法确定最终导入到表中的具体数据，存在了不确定性。

为了解决这个问题，Doris 支持了 `sequence` 列，通过用户在导入时指定 `sequence` 列，相同 key 列下，按照 `sequence` 列的值进行替换，较大值可以替换较小值，反之则无法替换。该方法将顺序的确定交给了用户，由用户控制替换顺序。

sequence 列目前只支持 **Unique** 模型。

基本原理

通过增加一个隐藏列 **DORIS_SEQUENCE_COL** 实现，该列的类型由用户在建表时指定，在导入时确定该列具体值，并依据该值决定相同 Key 列下，哪一行生效。

建表

创建 Unique 表时，将按照用户指定类型自动添加一个隐藏列 **__DORIS_SEQUENCE_COL__**。

导入

导入时，fe 在解析的过程中将隐藏列的值设置成 order by 表达式的值 (broker load 和 routine load)，或者 function_column.sequence_col 表达式的值 (stream load)，value 列将按照该值进行替换。隐藏列 **__DORIS_SEQUENCE_COL__** 的值既可以设置为数据源中一列，也可以是表结构中的一列。

使用语法

Sequence 列建表时有两种方式，一种是建表时设置 sequence_col 属性，一种是建表时设置 sequence_type 属性。

1. 设置 sequence_col (推荐)

创建 Unique 表时，指定 sequence 列到表中其他 column 的映射

```
PROPERTIES (  
    "function_column.sequence_col" = 'column_name',  
);
```

sequence_col 用来指定 sequence 列到表中某一列的映射，该列可以为整型和时间类型 (DATE、DATETIME)，创建后不能更改该列的类型。

导入方式和没有 sequence 列时一样，使用相对比较简单，推荐使用。

2. 设置 sequence_type

创建 Unique 表时，指定 sequence 列类型

```
PROPERTIES (  
    "function_column.sequence_type" = 'Date',  
);
```

sequence_type 用来指定 sequence 列的类型，可以为整型和时间类型 (DATE、DATETIME)。

导入时需要指定 **sequence** 列到其他列的映射。

1. Stream Load

stream load 的写法是在 header 中的function_column.sequence_col字段添加隐藏列对应的source_sequence 的映射，示例

```
curl --location-trusted -u root -H "columns: k1,k2,source_sequence,v1,v2" -H "function_column.sequence_col:source_sequence" -T testData http://host:port/api/testDb/testTbl/_stream_load
```

2. Broker Load

在ORDER BY 处设置隐藏列映射的 source_sequence 字段

```
LOAD LABEL db1.label1
(
  DATA INFILE("hdfs://host:port/user/data/*/test.txt")
  INTO TABLE `tbl1`
  COLUMNS TERMINATED BY ","
  (k1,k2,source_sequence,v1,v2)
  ORDER BY source_sequence
)
WITH BROKER 'broker'
(
  "username"="user",
  "password"="pass"
)
PROPERTIES
(
  "timeout" = "3600"
);
```

3. Routine Load

映射方式同上，示例如下

```
CREATE ROUTINE LOAD example_db.test1 ON example_tbl
[WITH MERGE|APPEND|DELETE]
COLUMNS(k1, k2, source_sequence, v1, v2),
WHERE k1 100 and k2 like "%doris%"
[ORDER BY source_sequence]
PROPERTIES
(
  "desired_concurrent_number"="3",
  "max_batch_interval" = "20",
  "max_batch_rows" = "300000",
  "max_batch_size" = "209715200",
  "strict_mode" = "false"
)
FROM KAFKA
(
  "kafka_broker_list" = "broker1:9092,broker2:9092,broker3:9092",
  "kafka_topic" = "my_topic",
  "kafka_partitions" = "0,1,2,3",
  "kafka_offsets" = "101,0,0,200"
);
```

启用 sequence column 支持

在新建表时如果设置了function_column.sequence_col或者function_column.sequence_type，则新建表将支持 sequence column。

对于一个不支持 sequence column 的表，如果想要使用该功能，可以使用如下语句：ALTER TABLE example_db.my_table ENABLE FEATURE "SEQUENCE_LOAD" WITH PROPERTIES ("function_column.sequence_type" = "Date") 来启用。

如果不确定一个表是否支持 sequence column，可以通过设置一个 session variable 来显示隐藏列 SET show_hidden_columns=true，之后使用 desc tablename，如果输出中有 __DORIS_SEQUENCE_COL__ 列则支持，如果没有则不支持。

使用示例

下面以 Stream Load 为例为示例来展示使用方式：

1. 创建支持 sequence col 的表

创建 unique 模型的 test_table 数据表，并指定 sequence 列映射到表中的 modify_date 列。

```
CREATE TABLE test.test_table
(
    user_id bigint,
    date date,
    group_id bigint,
    modify_date date,
    keyword VARCHAR(128)
)
UNIQUE KEY(user_id, date, group_id)
DISTRIBUTED BY HASH (user_id) BUCKETS 32
PROPERTIES(
    "function_column.sequence_col" = 'modify_date',
    "replication_num" = "1",
    "in_memory" = "false"
);
```

表结构如下：

```
MySQL> desc test_table;
+-----+-----+-----+-----+-----+-----+
| Field      | Type      | Null | Key  | Default | Extra |
+-----+-----+-----+-----+-----+-----+
user_id	BIGINT	No	true	NULL	
date	DATE	No	true	NULL	
group_id	BIGINT	No	true	NULL	
modify_date	DATE	No	false	NULL	REPLACE
keyword	VARCHAR(128)	No	false	NULL	REPLACE
+-----+-----+-----+-----+-----+-----+
```

2. 正常导入数据：

导入如下数据

```
1  2020-02-22  1  2020-02-21  a
1  2020-02-22  1  2020-02-22  b
1  2020-02-22  1  2020-03-05  c
1  2020-02-22  1  2020-02-26  d
1  2020-02-22  1  2020-02-23  e
1  2020-02-22  1  2020-02-24  b
```

此处以 stream load 为例

```
curl --location-trusted -u root: -T testData http://host:port/api/test/test_table/_stream_load
```

结果为

```
MySQL> select * from test_table;
+-----+-----+-----+-----+-----+
| user_id | date       | group_id | modify_date | keyword |
+-----+-----+-----+-----+-----+
| 1 | 2020-02-22 | 1 | 2020-03-05 | c |
+-----+-----+-----+-----+-----+
```

在这次导入中，因 sequence column 的值（也就是 modify_date 中的值）中'2020-03-05'为最大值，所以 keyword 列中最终保留了 c。

3. 替换顺序的保证

上述步骤完成后，接着导入如下数据

```
1 2020-02-22 1 2020-02-22 a
1 2020-02-22 1 2020-02-23 b
```

查询数据

```
MySQL [test]> select * from test_table;
+-----+-----+-----+-----+-----+
| user_id | date       | group_id | modify_date | keyword |
+-----+-----+-----+-----+-----+
| 1 | 2020-02-22 | 1 | 2020-03-05 | c |
+-----+-----+-----+-----+-----+
```

在这次导入的数据中，会比较所有已导入数据的 sequence column (也就是 modify_date)，其中'2020-03-05'为最大值，所以 keyword 列中最终保留了 c。

4. 再尝试导入如下数据

```
1 2020-02-22 1 2020-02-22 a
1 2020-02-22 1 2020-03-23 w
```

查询数据

```
MySQL [test]> select * from test_table;
+-----+-----+-----+-----+-----+
| user_id | date       | group_id | modify_date | keyword |
+-----+-----+-----+-----+-----+
| 1 | 2020-02-22 | 1 | 2020-03-23 | w |
+-----+-----+-----+-----+-----+
```

此时就可以替换表中原有的数据。综上，在导入过程中，会比较所有批次的 sequence 列值，选择值最大的记录导入 Doris 表中。

注意

1. 为防止误用，在 StreamLoad/BrokerLoad 等导入任务以及行更新 insert 语句中，用户必须显示指定 sequence 列 (除非 sequence 列的默认值为 CURRENT_TIMESTAMP)，不然会收到以下报错信息：

```
Table test_tbl has sequence column, need to specify the sequence column
```

2. 自版本 2.0 起，Doris 对 Unique Key 表的 Merge-on-Write 实现支持了部分列更新能力，在部分列更新导入中，用户每次可以只更新一部分列，因此并不是必须要包含 sequence 列。若用户提交的导入任务中，包含 sequence 列，则行为无影响；若用户提交的导入任务不包含 sequence 列，Doris 会使用匹配的历史数据中的 sequence 列作为更新后该行的 sequence 列的值。如果历史数据中不存在相同 key 的列，则会自动用 null 或默认值填充。
3. 当出现并发导入时，Doris 会利用 MVCC 机制来保证数据的正确性。如果两批数据导入都更新了一个相同 key 的不同列，则其中系统版本较高的导入任务会在版本较低的导入任务成功后，使用版本较低的导入任务写入的相同 key 的数据行重新进行补齐。

Delete 操作

Delete 操作语句通过 MySQL 协议，对指定的 table 或者 partition 中的数据进行按条件删除。Delete 删除操作不同于基于导入的批量删除，它类似 Insert into 语句，是一个同步过程。所有的 Delete 操作在 Doris 中是一个独立的导入作业，一般 Delete 语句需要指定表和分区以及删除的条件来筛选要删除的数据，并将会同时删除 base 表和 rollup 表的数据。

Delete 操作的语法详见 [DELETE](#) 语法。不同于 Insert into 命令，delete 不能手动指定 label，有关 label 的概念可以查看 [Insert Into](#) 文档。

通过指定过滤谓词来删除

```
DELETE FROM table_name [table_alias]
    [PARTITION partition_name | PARTITIONS (partition_name [, partition_name])]
    WHERE column_name op { value | value_list } [ AND column_name op { value | value_list } ...];
```

必须的参数

- table_name: 指定需要删除数据的表
- column_name: 属于 table_name 的列
- op: 逻辑比较操作符，可选类型包括：=, >, <, >=, <=, !=, in, not in
- value | value_list: 做逻辑比较的值或值列表

可选的参数

- PARTITION partition_name | PARTITIONS (partition_name [, partition_name]): 指定执行删除数据的分区名，如果表不存在此分区，则报错
- table_alias: 表的别名

注意事项

- 使用表模型 Aggregate 时，只能指定 Key 列上的条件。
- 当选定的 Key 列不存在于某个 Rollup 中时，无法进行 Delete。
- 条件之间只能是“与”的关系。若希望达成“或”的关系，需要将条件分写在两个 DELETE 语句中；
- 如果为分区表，需要指定分区，如果不指定，Doris 会从条件中推断出分区。两种情况下，Doris 无法从条件中推断出分区：1) 条件中不包含分区列；2) 分区列的 op 为 not in。当分区表未指定分区，或者无法从条件中推断分区的时候，需要设置会话变量 delete_without_partition 为 true，此时 Delete 会应用到所有分区。
- 该语句可能会降低执行后一段时间内的查询效率。影响程度取决于语句中指定的删除条件的数量。指定的条件越多，影响越大。

使用示例

1. 删除 my_table partition p1 中 k1 列值为 3 的数据行

```
DELETE FROM my_table PARTITION p1
WHERE k1 = 3;
```

2. 删除 my_table partition p1 中 k1 列值大于等于 3 且 k2 列值为 “abc” 的数据行

```
DELETE FROM my_table PARTITION p1
WHERE k1 = 3 AND k2 = "abc";
```

3. 删除 my_table partition p1, p2 中 k1 列值大于等于 3 且 k2 列值为 “abc” 的数据行

```
DELETE FROM my_table PARTITIONS (p1, p2)
WHERE k1 = 3 AND k2 = "abc";
```

通过使用 Using 子句来删除

```
DELETE FROM table_name [table_alias]
[PARTITION partition_name | PARTITIONS (partition_name [, partition_name])]
[USING additional_tables]
WHERE condition
```

必须的参数

- table_name: 指定需要删除数据的表
- WHERE condition: 指定一个用于选择删除行的条件

可选的参数

- PARTITION partition_name | PARTITIONS (partition_name [, partition_name]): 指定执行删除数据的分区名，如果表不存在此分区，则报错
- table_alias: 表的别名

注意事项

此种形式只能在 UNIQUE KEY 模型表上使用

- 只能在表模型 UNIQUE Key 表模型上使用，只能指定 key 列上的条件。

使用示例

使用t2和t3表连接的结果，删除t1中的数据，删除的表只支持 unique 模型

```
-- 创建t1, t2, t3三张表
CREATE TABLE t1
```

```

(id INT, c1 BIGINT, c2 STRING, c3 DOUBLE, c4 DATE)
UNIQUE KEY (id)
DISTRIBUTED BY HASH (id)
PROPERTIES('replication_num'='1', "function_column.sequence_col" = "c4");

CREATE TABLE t2
(id INT, c1 BIGINT, c2 STRING, c3 DOUBLE, c4 DATE)
DISTRIBUTED BY HASH (id)
PROPERTIES('replication_num'='1');

CREATE TABLE t3
(id INT)
DISTRIBUTED BY HASH (id)
PROPERTIES('replication_num'='1');

-- 插入数据
INSERT INTO t1 VALUES
(1, 1, '1', 1.0, '2000-01-01'),
(2, 2, '2', 2.0, '2000-01-02'),
(3, 3, '3', 3.0, '2000-01-03');

INSERT INTO t2 VALUES
(1, 10, '10', 10.0, '2000-01-10'),
(2, 20, '20', 20.0, '2000-01-20'),
(3, 30, '30', 30.0, '2000-01-30'),
(4, 4, '4', 4.0, '2000-01-04'),
(5, 5, '5', 5.0, '2000-01-05');

INSERT INTO t3 VALUES
(1),
(4),
(5);

-- 删除 t1 中的数据
DELETE FROM t1
USING t2 INNER JOIN t3 ON t2.id = t3.id
WHERE t1.id = t2.id;

```

预期结果为，删除了t1表id为1的列

| id | c1 | c2 | c3 | c4 |
|----|----|----|-----|------------|
| 2 | 2 | 2 | 2.0 | 2000-01-02 |
| 3 | 3 | 3 | 3.0 | 2000-01-03 |

结果返回

Delete 命令是一个 SQL 命令，返回结果是同步的，分为以下几种：

执行成功

如果 Delete 顺利执行完成并可见，将返回下列结果，Query OK表示成功

```

mysql> delete from test_tbl PARTITION p1 where k1 = 1;
Query OK, 0 rows affected (0.04 sec)
{'label': 'delete_e7830c72-eb14-4cb9-bbb6-eebd4511d251', 'status': 'VISIBLE', 'txnId': '4005'}

```


提交成功，但未可见

Doris 的事务提交分为两步：提交和发布版本，只有完成了发布版本步骤，结果才对用户是可见的。若已经提交成功了，那么就可以认为最终一定会发布成功，Doris 会尝试在提交完后等待发布一段时间，如果超时后即使发布版本还未完成也会优先返回给用户，提示用户提交已经完成。若如果 Delete 已经提交并执行，但是仍未发布版本和可见，将返回下列结果

```
mysql> delete from test_tbl PARTITION p1 where k1 = 1;
Query OK, 0 rows affected (0.04 sec)
{'label':'delete_e7830c72-eb14-4cb9-bbb6-eebd4511d251', 'status':'COMMITTED', 'txnId':'4005', 'err':'delete job is committed but may be taking effect later' }
```

结果会同时返回一个 json 字符串：

- affected rows：表示此次删除影响的行，由于 Doris 的删除目前是逻辑删除，因此对于这个值是恒为 0；
- label：自动生成的 label，是该导入作业的标识。每个导入作业，都有一个在单 Database 内部唯一的 Label；
- status：表示数据删除是否可见，如果可见则显示VISIBLE，如果不可见则显示COMMITTED；
- txnId：这个 Delete job 对应的事务 id；
- err：字段会显示一些本次删除的详细信息。

提交失败，事务取消

如果 Delete 语句没有提交成功，将会被 Doris 自动中止，返回下列结果

```
mysql> delete from test_tbl partition p1 where k1 > 80;
ERROR 1064 (HY000): errCode = 2, detailMessage = {错误原因}
```

比如说一个超时的删除，将会返回 timeout 时间和未完成的(tablet=replica)

```
mysql> delete from test_tbl partition p1 where k1 > 80;
ERROR 1064 (HY000): errCode = 2, detailMessage = failed to delete replicas from job: 4005, Unfinished
replicas:10000=60000, 10001=60000, 10002=60000
```

总结

对于 Delete 操作返回结果的正确处理逻辑为：

- 如果返回结果为ERROR 1064 (HY000)，则表示删除失败；
- 如果返回结果为Query OK，则表示删除执行成功；
 - 如果status为COMMITTED，表示数据仍不可见，用户可以稍等一段时间再用show delete命令查看结果；
 - 如果status为VISIBLE，表示数据删除成功。

相关 FE 配置

TIMEOUT 配置

总体来说，Doris 的删除作业的超时时间计算规则为如下（单位：秒）：

```
TIMEOUT = MIN(delete_job_max_timeout_second, MAX(30, tablet_delete_timeout_second * tablet_num))
```

- tablet_delete_timeout_second

Delete 自身的超时时间是受指定分区下 Tablet 的数量弹性改变的，此项配置为平均一个 Tablet 所贡献的 timeout 时间，默认值为 2。

假设此次删除所指定分区下有 5 个 tablet，那么可提供给 delete 的 timeout 时间为 10 秒，由于低于最低超时时间 30 秒，因此最终超时时间为 30 秒。

- query_timeout

因为 Delete 本身是一个 SQL 命令，因此删除语句也会受 Session 限制，timeout 还受 Session 中的 query_timeout 值影响，可以通过 SET query_timeout = xxx 来增加超时时间，单位是秒。

IN 谓词配置

- max_allowed_in_element_num_of_delete

如果用户在使用 in 谓词时需要占用的元素比较多，用户可以通过此项调整允许携带的元素上限，默认值为 1024。

查看历史记录

用户可以通过 show delete 语句查看历史上已执行完成的删除记录。

语法如下

```
SHOW DELETE [FROM db_name]
```

使用示例

```
mysql> show delete from test_db;
+-----+-----+-----+-----+-----+
| TableName | PartitionName | CreateTime          | DeleteCondition | State      |
+-----+-----+-----+-----+-----+
| empty_tbl | p3             | 2020-04-15 23:09:35 | k1 EQ "1"       | FINISHED  |
| test_tbl  | p4             | 2020-04-15 23:09:53 | k1 GT "80"      | FINISHED  |
+-----+-----+-----+-----+-----+
2 rows in set (0.00 sec)
```

批量删除

有了 Delete 操作为什么还要引入基于导入的批量删除？

Delete 操作的局限性

使用 Delete 语句的方式删除时，每执行一次 Delete 都会生成一个空的 rowset 来记录删除条件，并产生一个新的数据版本。每次读取都要对删除条件进行过滤，如果频繁删除或者删除条件过多时，都会严重影响查询性能。

Insert 数据和 Delete 数据穿插出现

对于类似于从事务数据库中，通过 CDC 进行数据导入的场景，数据中 Insert 和 Delete 一般是穿插出现的，面对这种场景当前 Delete 操作也是无法实现。

导入数据时有几种合并方式：

1. APPEND: 数据全部追加到现有数据中。
2. DELETE: 删除所有与导入数据 key 列值相同的行 (当表存在 sequence 列时，需要同时满足主键相同以及 sequence 列的大小逻辑才能正确删除，详见下边用例 4)。
3. MERGE: 根据 DELETE ON 的决定 APPEND 还是 DELETE。

批量删除只工作在 Unique 模型上。

基本原理

通过在 Unique 表上增加一个隐藏列 __DORIS_DELETE_SIGN__ 来实现。

FE 解析查询时，遇到 * 等扩展时去掉 __DORIS_DELETE_SIGN__，并且默认加上 __DORIS_DELETE_SIGN__ != true 的条件，BE 读取时都会加上一列进行判断，通过条件确定是否删除。

- 导入

导入时在 FE 解析时将隐藏列的值设置成 DELETE ON 表达式的值。

- 读取

读取时在所有存在隐藏列的上增加 __DORIS_DELETE_SIGN__ != true 的条件，be 不感知这一过程，正常执行。

- Cumulative Compaction

Cumulative Compaction 时将隐藏列看作正常的列处理，Compaction 逻辑没有变化。

- Base Compaction

Base Compaction 时要将标记为删除的行的删掉，以减少数据占用的空间。

启用批量删除支持

启用批量删除支持有以下两种形式：

1. 通过在 FE 配置文件中增加 `enable_batch_delete_by_default=true` 重启 fe 后新建表的都支持批量删除，此选项默认为 true；
2. 对于没有更改上述 FE 配置或对于已存在的不支持批量删除功能的表，可以使用如下语句：`ALTER TABLE tablename ENABLE FEATURE "BATCH_DELETE"` 来启用批量删除。本操作本质上是一个 schema change 操作，操作立即返回，可以通过 `show alter table column` 来确认操作是否完成。

那么如何确定一个表是否支持批量删除，可以通过设置一个 session variable 来显示隐藏列 `SET show_hidden_columns=true`，之后使用 `desc tablename`，如果输出中有 `__DORIS_DELETE_SIGN__` 列则支持，如果没有则不支持。

语法说明

导入的语法设计方面主要是增加一个指定删除标记列的字段的 column 映射，并且需要在导入的数据中增加一列，各种导入方式设置的语法如下

Stream Load

Stream Load 的写法在 header 中的 columns 字段增加一个设置删除标记列的字段，示例 `-H "columns: k1, k2, label_c3" -H "merge_type: [MERGE|APPEND|DELETE]" -H "delete: label_c3=1"`。

Broker Load

Broker Load 的写法在 PROPERTIES 处设置删除标记列的字段，语法如下：

```
LOAD LABEL db1.label1
(
  [MERGE|APPEND|DELETE] DATA INFILE("hdfs://abc.com:8888/user/palo/test/ml/file1")
  INTO TABLE tbl1
  COLUMNS TERMINATED BY ","
  (tmp_c1,tmp_c2, label_c3)
  SET
  (
    id=tmp_c2,
    name=tmp_c1,
  )
  [DELETE ON label_c3=true]
)
WITH BROKER 'broker'
(
  "username"="user",
  "password"="pass"
)
PROPERTIES
(
  "timeout" = "3600"
);
```

Routine Load

Routine Load的写法在 columns字段增加映射，映射方式同上，语法如下：

```
CREATE ROUTINE LOAD example_db.test1 ON example_tbl
[WITH MERGE|APPEND|DELETE]
COLUMNS(k1, k2, k3, v1, v2, label),
WHERE k1 100 and k2 like "%doris%"
[DELETE ON label=true]
PROPERTIES
(
    "desired_concurrent_number"="3",
    "max_batch_interval" = "20",
    "max_batch_rows" = "300000",
    "max_batch_size" = "209715200",
    "strict_mode" = "false"
)
FROM KAFKA
(
    "kafka_broker_list" = "broker1:9092,broker2:9092,broker3:9092",
    "kafka_topic" = "my_topic",
    "kafka_partitions" = "0,1,2,3",
    "kafka_offsets" = "101,0,0,200"
);
```

注意事项

1. 由于除Stream Load 外的导入操作在 doris 内部有可能乱序执行，因此在使用MERGE 方式导入时如果不是 Stream Load，需要与 load sequence 一起使用，具体的语法可以参照sequence列 相关的文档；
2. DELETE ON 条件只能与 MERGE 一起使用。

如果在执行导入作业前按上文所述开启了SET show_hidden_columns = true的 session variable 来查看表是否支持批量删除，按示例完成 DELETE/MERGE 的导入作业后，如果在同一个 session 中执行select count(*) from xxx等语句时，需要执行SET show_hidden_columns = false或者开启新的 session, 避免查询结果中包含那些被批量删除的记录，导致结果与预期不符。

使用示例

查看是否启用批量删除支持

```
mysql> CREATE TABLE IF NOT EXISTS table1 (
->     siteid INT,
->     citycode INT,
->     username VARCHAR(64),
->     pv BIGINT
-> ) UNIQUE KEY (siteid, citycode, username)
-> DISTRIBUTED BY HASH(siteid) BUCKETS 10
-> PROPERTIES (
->     "replication_num" = "3"
-> );
Query OK, 0 rows affected (0.34 sec)

mysql> SET show_hidden_columns=true;
Query OK, 0 rows affected (0.00 sec)
```

```
mysql> DESC table1;
```

| Field | Type | Null | Key | Default | Extra |
|-----------------------|-------------|------|-------|---------|-------|
| siteid | int | Yes | true | NULL | |
| citycode | int | Yes | true | NULL | |
| username | varchar(64) | Yes | true | NULL | |
| pv | bigint | Yes | false | NULL | NONE |
| __DORIS_DELETE_SIGN__ | tinyint | No | false | 0 | NONE |
| __DORIS_VERSION_COL__ | bigint | No | false | 0 | NONE |

6 rows in set (0.01 sec)

Stream Load 使用示例

请查阅[Stream Load使用手册](#)中“指定 merge_type 进行 Delete 操作”和“指定 merge_type 进行 Merge 操作”章节的内容。

Truncate 操作

该语句用于清空指定表和分区的数据。

语法

```
TRUNCATE TABLE [db.]tbl[ PARTITION(p1, p2, ...)];
```

- 该语句清空数据，但保留表或分区。
- 不同于 DELETE，该语句只能整体清空指定的表或分区，不能添加过滤条件。
- 不同于 DELETE，使用该方式清空数据不会对查询性能造成影响。
- 该操作删除的数据不可恢复。
- 使用该命令时，表状态需为 NORMAL，即不允许正在进行 SCHEMA CHANGE 等操作。
- 该命令可能会导致正在进行的导入失败。

示例

1. 清空 example_db 下的表 tbl

```
TRUNCATE TABLE example_db.tbl;
```

2. 清空表 tbl 的 p1 和 p2 分区

```
TRUNCATE TABLE tbl PARTITION(p1, p2);
```

表原子替换

Doris 支持对两个表进行原子的替换操作。该操作仅适用于 OLAP 表。

适用场景

- 原子的覆盖写操作
- 某些情况下，用户希望能够重写某张表的数据，但如果采用先删除再导入的方式进行，在中间会有一段时间无法查看数据。这时，用户可以先使用 CREATE TABLE LIKE 语句创建一个相同结构的新表，将新的数据导入到新表后，通过替换操作，原子的替换旧表，以达到目的。分区级别的原子覆盖写操作，请参阅 [临时分区文档](#)。

语法说明

```
ALTER TABLE [db.]tbl1 REPLACE WITH TABLE tbl2
[PROPERTIES('swap' = 'true')];
```

将表 tbl1 替换为表 tbl2。

如果 swap 参数为 true，则替换后，名称为 tbl1 表中的数据为原 tbl2 表中的数据。而名称为 tbl2 表中的数据为原 tbl1 表中的数据。即两张表数据发生了互换。

如果 swap 参数为 false，则替换后，名称为 tbl1 表中的数据为原 tbl2 表中的数据。而名称为 tbl2 表被删除。

原理

替换表功能，实际上是将以下操作集合变成一个原子操作。

假设要将表 A 替换为表 B，且 swap 为 true，则操作如下：

1. 将表 B 重名为表 A。
2. 将表 A 重名为表 B。

如果 swap 为 false，则操作如下：

1. 删除表 A。
2. 将表 B 重名为表 A。

注意事项

- swap 参数默认为 true。即替换表操作相当于将两张表数据进行交换。
- 如果设置 swap 参数为 false，则被替换的表（表 A）将被删除，且无法恢复。

- 替换操作仅能发生在两张 OLAP 表之间，且不会检查两张表的表结构是否一致。
- 替换操作不会改变原有的权限设置。因为权限检查以表名称为准。

临时分区

Doris 支持在分区表中添加临时分区，临时分区和正式分区不同的是，临时分区不会被正式查询查询到，只有通过特殊的查询语句才能查询。

- 临时分区的分区列和正式分区相同，且不可修改。
- 一张表所有临时分区之间的分区范围不可重叠，但临时分区的范围和正式分区范围可以重叠。
- 临时分区的分区名称不能和正式分区以及其他临时分区重复。

临时分区主要用到如下场景：

- 原子的覆盖写操作

某些情况下，用户希望能够重写某一分区的数据，但如果采用先删除再导入的方式进行，在中间会有一段无法查看数据。这时，用户可以先创建一个对应的临时分区，将新的数据导入到临时分区后，通过替换操作，原子的替换原有分区，以达到目的。对于非分区表的原子覆盖写操作，请参阅[替换表文档](#)。

- 修改分桶数

某些情况下，用户在创建分区时使用了不合适的分桶数。则用户可以先创建一个对应分区范围的临时分区，并指定新的分桶数。然后通过 `INSERT INTO` 命令将正式分区的数据导入到临时分区中，通过替换操作，原子的替换原有分区，以达到目的。

- 合并或分割分区

某些情况下，用户希望对分区的范围进行修改，比如合并两个分区，或将一个大分区分割成多个小分区。则用户可以先建立对应合并或分割后范围的临时分区，然后通过 `INSERT INTO` 命令将正式分区的数据导入到临时分区中，通过替换操作，原子的替换原有分区，以达到目的。

添加临时分区

可以通过 `ALTER TABLE ADD TEMPORARY PARTITION` 语句对一个表添加临时分区：

```
ALTER TABLE tbl1 ADD TEMPORARY PARTITION tp1 VALUES LESS THAN("2020-02-01");

ALTER TABLE tbl2 ADD TEMPORARY PARTITION tp1 VALUES [("2020-01-01"), ("2020-02-01"));

ALTER TABLE tbl1 ADD TEMPORARY PARTITION tp1 VALUES LESS THAN("2020-02-01")
("replication_num" = "1")
DISTRIBUTED BY HASH(k1) BUCKETS 5;

ALTER TABLE tbl3 ADD TEMPORARY PARTITION tp1 VALUES IN ("Beijing", "Shanghai");

ALTER TABLE tbl4 ADD TEMPORARY PARTITION tp1 VALUES IN ((1, "Beijing"), (1, "Shanghai"));

ALTER TABLE tbl3 ADD TEMPORARY PARTITION tp1 VALUES IN ("Beijing", "Shanghai")
("replication_num" = "1")
DISTRIBUTED BY HASH(k1) BUCKETS 5;
```

通过 `HELP ALTER TABLE`；查看更多帮助和示例。

添加操作的一些说明：

- 临时分区的添加和正式分区的添加操作相似。临时分区的分区范围独立于正式分区。
- 临时分区可以独立指定一些属性。包括分桶数、副本数、存储介质等信息。

删除临时分区

可以通过 `ALTER TABLE DROP TEMPORARY PARTITION` 语句删除一个表的临时分区：

```
ALTER TABLE tbl1 DROP TEMPORARY PARTITION tp1;
```

通过 `HELP ALTER TABLE`；查看更多帮助和示例。

删除操作的一些说明：

- 删除临时分区，不影响正式分区的数据。

替换正式分区

可以通过 `ALTER TABLE REPLACE PARTITION` 语句将一个表的正式分区替换为临时分区。

```
ALTER TABLE tbl1 REPLACE PARTITION (p1) WITH TEMPORARY PARTITION (tp1);

ALTER TABLE tbl1 REPLACE PARTITION (p1, p2) WITH TEMPORARY PARTITION (tp1, tp2, tp3);

ALTER TABLE tbl1 REPLACE PARTITION (p1, p2) WITH TEMPORARY PARTITION (tp1, tp2)
PROPERTIES (
    "strict_range" = "false",
    "use_temp_partition_name" = "true"
);
```

通过 `HELP ALTER TABLE`；查看更多帮助和示例。

替换操作有两个特殊的可选参数：

1. strict_range

默认为 `true`。

对于 Range 分区，当该参数为 `true` 时，表示要被替换的所有正式分区的范围并集需要和替换的临时分区的范围并集完全相同。当置为 `false` 时，只需要保证替换后，新的正式分区间的范围不重叠即可。

对于 List 分区，该参数恒为 `true`。要被替换的所有正式分区的枚举值必须和替换的临时分区枚举值完全相同。

示例 1

```
待替换的分区 p1, p2, p3 的范围 (=> 并集):
[10, 20), [20, 30), [40, 50) => [10, 30), [40, 50)

替换分区 tp1, tp2 的范围 (=> 并集):
[10, 30), [40, 45), [45, 50) => [10, 30), [40, 50)

范围并集相同，则可以使用 tp1 和 tp2 替换 p1, p2, p3。
```

示例 2

待替换的分区 p1 的范围 (=> 并集):

[10, 50) => [10, 50)

替换分区 tp1, tp2 的范围 (=> 并集):

[10, 30), [40, 50) => [10, 30), [40, 50)

范围并集不相同, 如果 strict_range 为 true, 则不可以使用 tp1 和 tp2 替换 p1。如果为 false, 且替换后的两个分区范围 [10, 30), [40, 50) 和其他正式分区不重叠, 则可以替换。

示例 3

待替换的分区 p1, p2 的枚举值 (=> 并集):

(1, 2, 3), (4, 5, 6) => (1, 2, 3, 4, 5, 6)

替换分区 tp1, tp2, tp3 的枚举值 (=> 并集):

(1, 2, 3), (4), (5, 6) => (1, 2, 3, 4, 5, 6)

枚举值并集相同, 可以使用 tp1, tp2, tp3 替换 p1, p2

示例 4

待替换的分区 p1, p2, p3 的枚举值 (=> 并集):

((("1","beijing"), ("1", "shanghai")), (("2","beijing"), ("2", "shanghai")), (("3","beijing"), ("3", "shanghai"))) => ((("1","beijing"), ("1", "shanghai"), ("2","beijing"), ("2", "shanghai"), ("3","beijing"), ("3", "shanghai")))

替换分区 tp1, tp2 的枚举值 (=> 并集):

((("1","beijing"), ("1", "shanghai")), (("2","beijing"), ("2", "shanghai"), ("3","beijing"), ("3", "shanghai"))) => ((("1","beijing"), ("1", "shanghai"), ("2","beijing"), ("2", "shanghai"), ("3","beijing"), ("3", "shanghai")))

枚举值并集相同, 可以使用 tp1, tp2 替换 p1, p2, p3

2. use_temp_partition_name

默认为 false。

当该参数为 false, 并且待替换的分区和替换分区的个数相同时, 则替换后的正式分区名称维持不变。

如果为 true, 则替换后, 正式分区的名称为替换分区的名称。下面举例说明:

示例 1

```
ALTER TABLE tbl1 REPLACE PARTITION (p1) WITH TEMPORARY PARTITION (tp1);
```

- use_temp_partition_name 默认为 false, 则在替换后, 分区的名称依然为 p1, 但是相关的数据和属性都替换为 tp1 的。
- 如果 use_temp_partition_name 默认为 true, 则在替换后, 分区的名称为 tp1。p1 分区不再存在。

示例 2

```
ALTER TABLE tbl1 REPLACE PARTITION (p1, p2) WITH TEMPORARY PARTITION (tp1);
```

- `use_temp_partition_name` 默认为 `false`，但因为待替换分区的个数和替换分区的个数不同，则该参数无效。替换后，分区名称为 `tp1`，`p1` 和 `p2` 不再存在。

****替换操作的一些说明：****

分区替换成功后，被替换的分区将被删除且不可恢复。

导入临时分区

根据导入方式的不同，指定导入临时分区的语法稍有差别。这里通过示例进行简单说明

```
INSERT INTO tbl TEMPORARY PARTITION(tp1, tp2, ...) SELECT ....
curl --location-trusted -u root: -H "label:123" -H "temporary_partitions: tp1, tp2, ..." -T testData
http://host:port/api/testDb/testTbl/_stream_load
LOAD LABEL example_db.label1
(
  DATA INFILE("hdfs://hdfs_host:hdfs_port/user/palo/data/input/file")
  INTO TABLE my_table
  TEMPORARY PARTITION (tp1, tp2, ...)
  ...
)
WITH BROKER hdfs ("username"="hdfs_user", "password"="hdfs_password");
CREATE ROUTINE LOAD example_db.test1 ON example_tbl
COLUMNS(k1, k2, k3, v1, v2, v3 = k1 * 100),
TEMPORARY PARTITIONS(tp1, tp2, ...),
WHERE k1 > 100
PROPERTIES
(...)
FROM KAFKA
(...);
```

查询临时分区

```
SELECT ... FROM
tbl1 TEMPORARY PARTITION(tp1, tp2, ...)
JOIN
tbl2 TEMPORARY PARTITION(tp1, tp2, ...)
ON ...
WHERE ...;
```

和其他操作的关系

DROP

- 使用 `Drop` 操作直接删除数据库或表后，可以通过 `Recover` 命令恢复数据库或表（限定时间内），但临时分区不会被恢复。
- 使用 `Alter` 命令删除正式分区后，可以通过 `Recover` 命令恢复分区（限定时间内）。操作正式分区和临时分区无关。

- 使用 Alter 命令删除临时分区后，无法通过 Recover 命令恢复临时分区。

TRUNCATE

- 使用 Truncate 命令清空表，表的临时分区会被删除，且不可恢复。
- 使用 Truncate 命令清空正式分区时，不影响临时分区。
- 不可使用 Truncate 命令清空临时分区。

ALTER

- 当表存在临时分区时，无法使用 Alter 命令对表进行 Schema Change、Rollup 等变更操作。
- 当表在进行变更操作时，无法对表添加临时分区。

通过 Export 导出数据

异步导出（Export）是 Doris 提供的一种将数据异步导出的功能。该功能可以将用户指定的表或分区的数据，以指定的文件格式，通过 Broker 进程或 S3 协议/HDFS 协议 导出到远端存储上，如 对象存储 / HDFS 等。

当前，EXPORT 支持导出 Doris 本地表 / View 视图 / 外表，支持导出到 Parquet / ORC / CSV / csv_with_names / csv_with_names_and_types 文件格式。

本文档主要介绍 Export 的基本原理、使用方式、最佳实践以及注意事项。

原理

用户提交一个 Export 作业后。Doris 会统计这个作业涉及的所有 Tablet。然后根据parallelism参数（由用户指定）对这些 Tablet 进行分组。每个线程负责一组 tablets，生成若干个SELECT INTO OUTFILE查询计划。该查询计划会读取所包含的 Tablet 上的数据，然后通过 S3 协议 / HDFS 协议 / Broker 将数据写到远端存储指定的路径中。

总体的执行流程如下：

1. 用户提交一个 Export 作业到 FE。
2. FE 会统计要导出的所有 Tablets，然后根据parallelism参数将所有 Tablets 分组，每一组再根据 maximum_number_of_export_partitions参数生成若干个SELECT INTO OUTFILE查询计划
3. 根据parallelism参数，生成相同个数的ExportTaskExecutor，每一个ExportTaskExecutor由一个线程负责，线程由 FE 的 Job 调度框架去调度执行。
4. FE 的 Job 调度器会去调度ExportTaskExecutor并执行，每一个ExportTaskExecutor会串行地去执行由它负责的若干个SELECT INTO OUTFILE查询计划。

开始导出

Export 的详细用法可参考 [EXPORT](#)。

导出到 HDFS

```
EXPORT TABLE db1.tbl1
PARTITION (p1,p2)
[WHERE [expr]]
TO "hdfs://host/path/to/export/"
PROPERTIES
(
  "label" = "mylabel",
  "column_separator"=",",
  "columns" = "col1,col2",
  "parallelism" = "3"
)
WITH BROKER "hdfs"
(
  "username" = "user",
```

```
"password" = "passwd"
);
```

- label: 本次导出作业的标识。后续可以使用这个标识查看作业状态。
- column_separator: 列分隔符。默认为 \t。支持不可见字符, 比如 \x07。
- columns: 要导出的列, 使用英文状态逗号隔开, 如果不填这个参数默认是导出表的所有列。
- line_delimiter: 行分隔符。默认为 \n。支持不可见字符, 比如 \x07。
- parallelism: 并发 3 个线程去导出。

导出到对象存储

通过 S3 协议直接将数据导出到指定的存储。

```
EXPORT TABLE test TO "s3://bucket/path/to/export/dir/"
WITH S3 (
    "s3.endpoint" = "http://host",
    "s3.access_key" = "AK",
    "s3.secret_key"="SK",
    "s3.region" = "region"
);
```

- s3.access_key/s3.secret_key: 是您访问对象存储的 ACCESS_KEY/SECRET_KEY
- s3.endpoint: Endpoint 表示对象存储对外服务的访问域名。
- s3.region: 表示对象存储数据中心所在的地域。

查看导出状态

提交作业后, 可以通过 [SHOW EXPORT](#) 命令查询导出作业状态。结果举例如下:

```
mysql> show EXPORT\G;
***** 1. row *****
  JobId: 14008
   State: FINISHED
Progress: 100%
TaskInfo: {"partitions":
[], "max_file_size": "", "delete_existing_files": "", "columns": "", "format": "csv", "column_separator": "\t", "line_delimiter": "\n", "db": "default_cluster:demo", "tbl": "student4", "tablet_num": 30}
   Path: hdfs://host/path/to/export/
CreateTime: 2019-06-25 17:08:24
  StartTime: 2019-06-25 17:08:28
FinishTime: 2019-06-25 17:08:34
   Timeout: 3600
  ErrorMsg: NULL
OutfileInfo: [
[
{
  "fileNumber": "1",
  "totalRows": "4",
  "fileSize": "34bytes",
  "url": "file:///127.0.0.1/Users/fangtiewei/tmp_data/export/f1ab7dcc31744152-bbb4cda2f5c88eac_"
}
]
```



```
]
]
1 row in set (0.01 sec)
```

- JobId: 作业的唯一 ID
- State: 作业状态:
 - PENDING: 作业待调度
 - EXPORTING: 数据导出中
 - FINISHED: 作业成功
 - CANCELLED: 作业失败
- Progress: 作业进度。该进度以查询计划为单位。假设一共 10 个线程, 当前已完成 3 个, 则进度为 30%。
- TaskInfo: 以 JSON 格式展示的作业信息:
 - db: 数据库名
 - tbl: 表名
 - partitions: 指定导出的分区。空列表 表示所有分区。
 - column_separator: 导出文件的列分隔符。
 - line_delimiter: 导出文件的行分隔符。
 - tablet num: 涉及的总 Tablet 数量。
 - broker: 使用的 Broker 的名称。
 - coord num: 查询计划的个数。
 - max_file_size: 一个导出文件的最大大小。
 - delete_existing_files: 是否删除导出目录下已存在的文件及目录。
 - columns: 指定需要导出的列名, 空值代表导出所有列。
 - format: 导出的文件格式
- Path: 远端存储上的导出路径。
- CreateTime/StartTime/FinishTime: 作业的创建时间、开始调度时间和结束时间。
- Timeout: 作业超时时间。单位是秒。该时间从 CreateTime 开始计算。
- ErrorMsg: 如果作业出现错误, 这里会显示错误原因。
- OutfileInfo: 如果作业导出成功, 这里会显示具体的SELECT INTO OUTFILE结果信息。

取消导出任务

备注

CANCEL EXPORT 命令自 Doris 1.2.2 版本起支持。

提交作业后，可以通过 [CANCEL EXPORT](#) 命令取消导出作业。取消命令举例如下：

```
CANCEL EXPORT
FROM example_db
WHERE LABEL like "%example%";
```

最佳实践

并发导出

一个 Export 作业可以设置parallelism参数来并发导出数据。parallelism参数实际就是指定执行 EXPORT 作业的线程数量。每一个线程会负责导出表的部分 Tablets。

一个 Export 作业的底层执行逻辑实际上是SELECT INTO OUTFILE语句，parallelism参数设置的每一个线程都会去执行独立的SELECT INTO OUTFILE语句。

Export 作业拆分成多个SELECT INTO OUTFILE的具体逻辑是：将该表的所有 Tablets 平均的分给所有 Parallel 线程，如：

- num(tablets) = 40, parallelism = 3，则这 3 个线程各自负责的 tablets 数量分别为 14, 13, 13 个。
- num(tablets) = 2, parallelism = 3，则 Doris 会自动将 parallelism 设置为 2，每一个线程负责一个 tablets。

当一个线程负责的 Tablets 超过 maximum_tablets_of_outfile_in_export 数值（默认为 10，可在 fe.conf 中添加maximum_tablets_of_outfile_in_export参数来修改该值）时，该线程就会拆分为多个 SELECT INTO OUTFILE语句，如：

- 一个线程负责的 Tablets 数量分别为 14, maximum_tablets_of_outfile_in_export = 10，则该线程负责两个SELECT INTO OUTFILE语句，第一个SELECT INTO OUTFILE语句导出 10 个 tablets，第二个 SELECT INTO OUTFILE语句导出 4 个 tablets，两个SELECT INTO OUTFILE语句由该线程串行执行。
- 当所要导出的数据量很大时，可以考虑适当调大parallelism参数来增加并发导出。若机器核数紧张，无法再增加parallelism 而导出表的 Tablets 又较多时，可以考虑调大 maximum_tablets_of_outfile_in_export来增加一个SELECT INTO OUTFILE语句负责的 Tablets 数量，也可以加快导出速度。

exec_mem_limit

通常一个 Export 作业的查询计划只有 扫描-导出 两部分，不涉及需要太多内存的计算逻辑。所以通常 2GB 的默认内存限制可以满足需求。

但在某些场景下，比如一个查询计划，在同一个 BE 上需要扫描的 Tablet 过多，或者 Tablet 的数据版本过多时，可能会导致内存不足。可以调整 Session 变量 `exec_mem_limit` 来调大内存使用限制。

注意事项

- 不建议一次性导出大量数据。一个 Export 作业建议的导出数据量最大在几十 GB。过大的导出会导致更多的垃圾文件和更高的重试成本。
- 如果表数据量过大，建议按照分区导出。
- 在 Export 作业运行过程中，如果 FE 发生重启或切主，则 Export 作业会失败，需要用户重新提交。
- 如果 Export 作业运行失败，已经生成的文件不会被删除，需要用户手动删除。
- Export 作业可以导出 Base 表 / View 视图表 / 外表 的数据，不会导出 Rollup Index 的数据。
- Export 作业会扫描数据，占用 IO 资源，可能会影响系统的查询延迟。
- 在使用 EXPORT 命令时，请确保目标路径是已存在的目录，否则导出可能会失败。
- 在并发导出时，请注意合理地配置线程数量和并行度，以充分利用系统资源并避免性能瓶颈。
- 导出到本地文件时，要注意文件权限和路径，确保有足够的权限进行写操作，并遵循适当的文件系统路径。
- 在导出过程中，可以实时监控进度和性能指标，以便及时发现问题并进行优化调整。
- 导出操作完成后，建议验证导出的数据是否完整和正确，以确保数据的质量和完整性。

相关配置

FE

- `maximum_tablets_of_outfile_in_export`: ExportExecutorTask 任务中一个 OutFile 语句允许的最大 tablets 数量。

更多帮助

关于 EXPORT 使用的更多详细语法及最佳实践，请参阅 [Export 命令手册](#)，你也可以在 MySQL 客户端命令行下输入 `HELP EXPORT` 获取更多帮助信息。

EXPORT 命令底层实现是 `SELECT INTO OUTFILE` 语句，有关 `SELECT INTO OUTFILE` 可以参阅 [同步导出](#) 和 [SELECT INTO OUTFILE 命令手册](#)。

通过 SELECT INTO OUTFILE 导出结果集

本文档介绍如何使用 [SELECT INTO OUTFILE](#) 命令进行查询结果的导出操作。

SELECT INTO OUTFILE 是一个同步命令，命令返回即表示操作结束，同时会返回一行结果来展示导出的执行结果。

示例

导出到 HDFS

将简单查询结果导出到文件 `hdfs://path/to/result.txt`，指定导出格式为 CSV。

```
SELECT * FROM tbl
INTO OUTFILE "hdfs://path/to/result_"
FORMAT AS CSV
PROPERTIES
(
    "broker.name" = "my_broker",
    "column_separator" = ",",
    "line_delimiter" = "\n"
);
```

导出到本地文件

导出到本地文件时需要先在 `fe.conf` 中配置 `enable_outfile_to_local=true`

```
select * from tbl1 limit 10
INTO OUTFILE "file:///home/work/path/result_";
```

更多用法可查看[OUTFILE 文档](#)。

并发导出

默认情况下，查询结果集的导出是非并发的，也就是单点导出。如果用户希望查询结果集可以并发导出，需要满足以下条件：

1. Session variable 'enable_parallel_outfile' 开启并发导出： `set enable_parallel_outfile = true;`
2. 导出方式为 S3，或者 HDFS，而不是使用 broker
3. 查询可以满足并发导出的需求，比如顶层不包含 sort 等单点节点。（后面会举例说明，哪种属于不可并发导出结果集的查询）

满足以上三个条件，就能触发并发导出查询结果集了。并发度 = `be_instance_num * parallel_fragment_exec_instance_num`

如何验证结果集被并发导出

用户通过 Session 变量设置开启并发导出后，如果想验证当前查询是否能进行并发导出，则可以通过下面这个方法。

```
explain select xxx from xxx where xxx into outfile "s3://xxx" format as csv properties ("AWS_ENDPOINT" = "xxx", ...);
```

对查询进行 explain 后，Doris 会返回该查询的规划，如果你发现 RESULT FILE SINK 出现在 PLAN FRAGMENT 1 中，就说明导出并发开启成功了。

如果 RESULT FILE SINK 出现在 PLAN FRAGMENT 0 中，则说明当前查询不能进行并发导出 (当前查询不同时满足并发导出的三个条件)。

并发导出的规划示例：

```
+-----+
| Explain String |
+-----+
| PLAN FRAGMENT 0 |
| OUTPUT EXPRS:<slot 2> | <slot 3> | <slot 4> | <slot 5> |
| PARTITION: UNPARTITIONED |
| |
| RESULT SINK |
| |
| 1:EXCHANGE |
| |
| PLAN FRAGMENT 1 |
| OUTPUT EXPRS:`k1` + `k2` |
| PARTITION: HASH_PARTITIONED: `default_cluster:test`.`multi_tablet`.`k1` |
| |
| RESULT FILE SINK |
| FILE PATH: s3://ml-bd-repo/bpit_test/outfile_1951_ |
| STORAGE TYPE: S3 |
| |
| 0:0lapScanNode |
| TABLE: multi_tablet |
+-----+
```

返回结果

导出命令为同步命令。命令返回，即表示操作结束。同时会返回一行结果来展示导出的执行结果。

如果正常导出并返回，则结果如下：

```
mysql> select * from tbl1 limit 10 into outfile "file:///home/work/path/result_";
+-----+
| FileNumber | TotalRows | FileSize | URL |
+-----+
| 1 | 2 | 8 | file:///192.168.1.10/home/work/path/result_{fragment_instance_id}_ |
+-----+
1 row in set (0.05 sec)
```

- FileNumber：最终生成的文件个数。
- TotalRows：结果集行数。

- **FileSize**: 导出文件总大小。单位字节。
- **URL**: 如果是导出到本地磁盘, 则这里显示具体导出到哪个 **Compute Node**。

如果进行了并发导出, 则会返回多行数据。

```
+-----+-----+-----+-----+
| FileNumber | TotalRows | FileSize | URL |
+-----+-----+-----+-----+
|          1 |          3 |          7 | file:///192.168.1.10/home/work/path/result_{fragment_instance_id}_ |
|          1 |          2 |          4 | file:///192.168.1.11/home/work/path/result_{fragment_instance_id}_ |
+-----+-----+-----+-----+
2 rows in set (2.218 sec)
```

如果执行错误, 则会返回错误信息, 如:

```
mysql> SELECT * FROM tbl INTO OUTFILE ...
ERROR 1064 (HY000): errCode = 2, detailMessage = Open broker writer failed ...
```

注意事项

- 当前版本 **neredeids** 优化器不支持并发 **Outfile**, 若开启了 **neredeids** 优化器, 并发 **Outfile** 将直接回退老优化器, 由老优化器来进行并发 **Outfile** 导出。同时, 当前版本 **pipeline** 引擎也不支持并发 **Outfile**, 若开启了 **pipeline** 引擎, 并发 **Outfile** 将回退到单并发导出。
- 如果不开启并发导出, 查询结果是由单个 **BE** 节点, 单线程导出的。因此导出时间和导出结果集大小正相关。开启并发导出可以降低导出的时间。
- 导出命令不会检查文件及文件路径是否存在。是否会自动创建路径、或是否会覆盖已存在文件, 完全由远端存储系统的语义决定。
- 如果在导出过程中出现错误, 可能会有导出文件残留在远端存储系统上。**Doris** 不会清理这些文件。需要用户手动清理。
- 导出命令的超时时间同查询的超时时间。可以通过 **SET query_timeout=xxx** 进行设置。
- 对于结果集为空的查询, 依然会产生一个文件。
- 文件切分会保证一行数据完整的存储在单一文件中。因此文件的大小并不严格等于 **max_file_size**。
- 对于部分输出为非可见字符的函数, 如 **BITMAP**、**HLL** 类型, 输出为 **\N**, 即 **NULL**。
- 目前部分地理信息函数, 如 **ST_Point** 的输出类型为 **VARCHAR**, 但实际输出值为经过编码的二进制字符。当前这些函数会输出乱码。对于地理函数, 请使用 **ST_AsText** 进行输出。

更多帮助

关于 **OUTFILE** 使用的更多详细语法及最佳实践, 请参阅 [OUTFILE](#) 命令手册, 你也可以在 **MySQL** 客户端命令行下输入 **HELP OUTFILE** 获取更多帮助信息。

通过 MySQL Dump 导出表结构和数据

Doris 在 0.15 之后的版本已经支持通过 mysqldump 工具导出数据或者表结构

使用示例

导出

1. 导出 test 数据库中的 table1 表: `mysqldump -h127.0.0.1 -P9030 -uroot --no-tablespaces --databases test --tables table1`
2. 导出 test 数据库中的 table1 表结构: `mysqldump -h127.0.0.1 -P9030 -uroot --no-tablespaces --databases test --tables table1 --no-data`
3. 导出 test1, test2 数据库中所有表: `mysqldump -h127.0.0.1 -P9030 -uroot --no-tablespaces --databases test1 test2`
4. 导出所有数据库和表 `mysqldump -h127.0.0.1 -P9030 -uroot --no-tablespaces --all-databases`

更多的使用参数可以参考mysqldump 的使用手册

导入

mysqldump导出的结果可以重定向到文件中，之后可以通过 source 命令导入到 Doris 中 `source filename.sql`

注意

1. 由于 Doris 中没有 MySQL 里的 tablespace 概念，因此在使用 MySQL Dump 时要加上 `--no-tablespaces` 参数
2. 使用 MySQL Dump 导出数据和表结构仅用于开发测试或者数据量很小的情况，请勿用于大数据量的生产环境

MySQL 兼容性

Doris 是高度兼容 MySQL 语法，支持标准 SQL。但是 Doris 与 MySQL 还是有很多不同的地方，下面给出了他们的差异点介绍。

数据类型

数字类型

| 类型 | MySQL | Doris |
|-----------|--|--|
| Boolean | <ul style="list-style-type: none">- 支持- 范围：0 代表 false，1 代表 true | <ul style="list-style-type: none">- 支持- 关键字：Boolean- 范围：0 代表 false，1 代表 true |
| Bit | <ul style="list-style-type: none">- 支持- 范围：1 ~ 64 | 不支持 |
| Tinyint | <ul style="list-style-type: none">- 支持- 支持 signed,unsigned- 范围：<ul style="list-style-type: none">- signed: -128 ~ 127- unsigned: 0 ~ 255 | <ul style="list-style-type: none">- 支持- 只支持 signed- 范围：-128 ~ 127 |
| Smallint | <ul style="list-style-type: none">- 支持- 支持 signed,unsigned- 范围：<ul style="list-style-type: none">- signed: $-2^{15} \sim 2^{15}-1$- unsigned: $0 \sim 2^{16}-1$ | <ul style="list-style-type: none">- 支持- 只支持 signed- 范围：-32768 ~ 32767 |
| Mediumint | <ul style="list-style-type: none">- 支持- 支持 signed,unsigned- 范围：<ul style="list-style-type: none">- signed: $-2^{23} \sim 2^{23}-1$- unsigned: $0 \sim 2^{24}-1$ | - 不支持 |
| int | <ul style="list-style-type: none">- 支持- 支持 signed,unsigned- 范围：<ul style="list-style-type: none">- signed: $-2^{31} \sim 2^{31}-1$- unsigned: $0 \sim 2^{32}-1$ | <ul style="list-style-type: none">- 支持- 只支持 signed- 范围：-2147483648~2147483647 |
| Bigint | <ul style="list-style-type: none">- 支持- 支持 signed,unsigned- 范围：<ul style="list-style-type: none">- signed: $-2^{63} \sim 2^{63}-1$- unsigned: $0 \sim 2^{64}-1$ | <ul style="list-style-type: none">- 支持- 只支持 signed- 范围： $-2^{63} \sim 2^{63}-1$ |
| Largeint | - 不支持 | <ul style="list-style-type: none">- 支持- 只支持 signed- 范围： $-2^{127} \sim 2^{127}-1$ |
| Decimal | <ul style="list-style-type: none">- 支持- 支持 signed,unsigned（8.0.17 以前支持，以后被标记为 deprecated）- 默认值：Decimal(10, 0) | <ul style="list-style-type: none">- 支持- 只支持 signed- 默认值：Decimal(9, 0) |

| 类型 | MySQL | Doris |
|--------------|---|--|
| Float/Double | <ul style="list-style-type: none"> - 支持 - 支持 signed,unsigned (8.0.17 以前支持, 以后被标记为 deprecated) | <ul style="list-style-type: none"> - 支持 - 只支持 signed |

日期类型

| 类型 | MySQL | Doris |
|-----------|---|--|
| Date | <ul style="list-style-type: none"> - 支持 - 范围: ['1000-01-01','9999-12-31'] - 格式: YYYY-MM-DD | <ul style="list-style-type: none"> - 支持 - 范围: ['0000-01-01', '9999-12-31'] - 格式: YYYY-MM-DD |
| Date Time | <ul style="list-style-type: none"> - 支持 - DATETIME([P]), 可选参数 P 表示精度 - 范围: '1000-01-01 00:00:00.000000', '9999-12-31 23:59:59.999999' - 格式: YYYY-MM-DD hh:mm:ss[.fraction] | <ul style="list-style-type: none"> - 支持 - DATETIME([P]), 可选参数 P 表示精度 - 范围: ['0000-01-01 00:00:00[.000000]', '9999-12-31 23:59:59[.999999]'] - 格式: YYYY-MM-DD hh:mm:ss[.fraction] |
| Timestamp | <ul style="list-style-type: none"> - 支持 - Timestamp([p]), 可选参数 P 表示精度 - 范围: ['1970-01-01 00:00:01.000000' UTC, '2038-01-19 03:14:07.999999' UTC] - 格式: YYYY-MM-DD hh:mm:ss[.fraction] | <ul style="list-style-type: none"> - 不支持 |
| Time | <ul style="list-style-type: none"> - 支持 - Time([p]) - 范围: ['-838:59:59.000000' to '838:59:59.000000'] - 格式: hh:mm:ss[.fraction] | <ul style="list-style-type: none"> - 不支持 |
| Year | <ul style="list-style-type: none"> - 支持 - 范围: 1901 to 2155, or 0000 - 格式: yyyy | <ul style="list-style-type: none"> - 不支持 |

字符串类型

| 类型 | MySQL | Doris |
|-----------|--|---|
| Char | <ul style="list-style-type: none"> - 支持 - CHAR(M), M 为字符长度, 缺省表示长度为 1 - 定长 - 范围: [0,255], 字节大小 | <ul style="list-style-type: none"> - 支持 - CHAR(M), M 为字节长度 - 可变 - 范围: [1,255] |
| Varchar | <ul style="list-style-type: none"> - 支持 - VARCHAR(M), M 为字符长度 - 范围: [0,65535], 字节大小 | <ul style="list-style-type: none"> - 支持 - VARCHAR(M), M 为字节长度。 - 范围: [1, 65533] |
| String | <ul style="list-style-type: none"> - 不支持 | <ul style="list-style-type: none"> - 支持 - 1048576 字节 (1MB), 可调大到 2147483643 字节 (2G) |
| Binary | <ul style="list-style-type: none"> - 支持 - 类似于 Char | <ul style="list-style-type: none"> - 不支持 |
| Varbinary | <ul style="list-style-type: none"> - 支持 - 类似于 Varchar | <ul style="list-style-type: none"> - 不支持 |

| 类型 | MySQL | Doris |
|------|---|-------|
| Blob | - 支持
- TinyBlob、Blob、MediumBlob、LongBlob | - 不支持 |
| Text | - 支持
- TinyText、Text、MediumText、LongText | - 不支持 |
| Enum | - 支持
- 最多支持 65535 个 elements | - 不支持 |
| Set | - 支持
- 最多支持 64 个 elements | - 不支持 |

JSON 数据类型

| 类型 | MySQL | Doris |
|------|-------|-------|
| JSON | - 支持 | - 支持 |

Doris 特有的数据类型

• HyperLogLog

HLL 不能作为 key 列使用，支持在 Aggregate 模型、Duplicate 模型和 Unique 模型的表中使用。在 Aggregate 模型表中使用，建表时配合的聚合类型为 HLL_UNION。用户不需要指定长度和默认值。长度根据数据的聚合程度系统内控制。并且 HLL 列只能通过配套的 hll_union_agg、hll_raw_agg、hll_cardinality、hll_hash 进行查询或使用。

HLL 是模糊去重，在数据量大的情况性能优于 Count Distinct。HLL 的误差通常在 1% 左右，有时能达到 2%。

• Bitmap

BITMAP 类型的列可以在 Aggregate 表、Unique 表或 Duplicate 表中使用。在 Unique 表或 duplicate 表中使用，其必须作为非 key 列使用。在 Aggregate 表中使用，其必须作为非 key 列使用，且建表时配合的聚合类型为 BITMAP_UNION。用户不需要指定长度和默认值。长度根据数据的聚合程度系统内控制。并且 BITMAP 列只能通过配套的 bitmap_union_count、bitmap_union、bitmap_hash、bitmap_hash64 等函数进行查询或使用。

离线场景下使用 BITMAP 会影响导入速度，在数据量大的情况下查询速度会慢于 HLL，并优于 Count Distinct。注意：实时场景下 BITMAP 如果不使用全局字典，使用了 bitmap_hash() 可能会导致有千分之一左右的误差。如果这个误差不可接受，可以使用 bitmap_hash64。

• QUANTILE_PERCENT

QUANTILE_STATE 不能作为 key 列使用，支持在 Aggregate 模型、Duplicate 模型和 Unique 模型的表中使用。在 Aggregate 模型表中使用，建表时配合的聚合类型为 QUANTILE_UNION。用户不需要指定长度和默认值。长度根据数据的聚合程度系统内控制。并且 QUANTILE_STATE 列只能通过配套的 QUANTILE_PERCENT、QUANTILE_UNION、TO_QUANTILE_STATE 等函数进行查询或使用。

QUANTILE_STATE 是一种计算分位数近似值的类型，在导入时会对相同的 key，不同 value 进行预聚合，当 value 数量不超过 2048 时采用明细记录所有数据，当 value 数量大于 2048 时采用 [TDigest](#) 算

法，对数据进行聚合（聚类）保存聚类后的质心点。

- **Array<T>**

由 T 类型元素组成的数组，不能作为 key 列使用。目前支持在 Duplicate 模型的表中使用，也支持在 Unique 模型的表中非 key 列使用。

T 类型：BOOLEAN, TINYINT, SMALLINT, INT, BIGINT, LARGEINT, FLOAT, DOUBLE, DECIMAL, DATE, DATETIME, CHAR, VARCHAR, STRING

- **MAP<K, V>**

由 K, V 类型元素组成的 map，不能作为 key 列使用。目前支持在 Duplicate, Unique 模型的表中使用。

K,V 支持的类型有：BOOLEAN, TINYINT, SMALLINT, INT, BIGINT, LARGEINT, FLOAT, DOUBLE, DECIMAL, DATE, DATETIME, CHAR, VARCHAR, STRING

- **STRUCT<field_name:field_type, ... >**

由多个 Field 组成的结构体，也可被理解为多个列的集合。不能作为 Key 使用，目前 STRUCT 仅支持在 Duplicate 模型的表中使用。

一个 Struct 中的 Field 的名字和数量固定，总是为 Nullable，一个 Field 通常由下面部分组成。

- field_name: Field 的标识符，不可重复
- field_type: Field 的类型

当前可支持的类型有：BOOLEAN, TINYINT, SMALLINT, INT, BIGINT, LARGEINT, FLOAT, DOUBLE, DECIMAL, DATE, DATETIME, CHAR, VARCHAR, STRING

- **AGG_STATE**

AGG_STATE 不能作为 key 列使用，建表时需要同时声明聚合函数的签名。

用户不需要指定长度和默认值。实际存储的数据大小与函数实现有关。

AGG_STATE 只能配合[state](#) /[merge](#)/[union](#)函数组合器使用。

语法区别

DDL

Create-Table

01 Doris 建表语法

```
CREATE TABLE [IF NOT EXISTS] [database.]table
(
    column_definition_list
    [, index_definition_list]
)
[engine_type]
[keys_type]
[table_comment]
```

```
[partition_info]
distribution_desc
[rollup_list]
[properties]
[extra_properties]
```

02 与 MySQL 的不同之处

- column_definition_list
 - 字段列表定义，基本语法与 MySQL 类似，会多出一个聚合类型的操作
 - 聚合类型的操作，主要支持数据模型为 AGGREGATE, Duplicate
 - MySQL 可以在建表定义字段列表的时候，还可以在字段后面加上 Index 等约束，例如 primary key, unique key 等，但是 Doris 是通过定义数据模型来约束和计算的。
- index_definition_list
 - 索引列表定义，基本语法与 MySQL 类似，支持位图索引、倒排索引和 N-Gram 索引，但是布隆过滤器索引是通过属性设置。
 - 而 MySQL 支持的 index 有 B+Tree, Hash。
- engine_type
 - 表引擎类型，可选
 - 目前支持的表引擎主要是 olap 这种原生引擎。
 - MySQL 支持的存储引擎有：Innodb, MyISAM 等
- keys_type
 - 数据模型，可选
 - 支持的类型
 - DUPLICATE KEY（默认）：其后指定的列为排序列。
 - AGGREGATE KEY：其后指定的列为维度列。
 - UNIQUE KEY：其后指定的列为主键列。
 - MySQL 则没有数据模型的概念。
- table_comment
 - 表注释
- partition_info
 - 分区算法，可选
 - 支持的分区算法
 - LESS THAN：仅定义分区上界。下界由上一个分区的上界决定。

- FIXED RANGE：定义分区的左闭右开区间。
 - MULTI RANGE：批量创建 RANGE 分区，定义分区的左闭右开区间，设定时间单位和步长，时间单位支持年、月、日、周和小时。
 - MULTI RANGE：批量创建数字类型的 RANGE 分区，定义分区的左闭右开区间，设定步长。
- MySQL 支持的算法：Hash，Range，List，并且还支持子分区，子分区支持的算法只有 Hash。
- distribution_desc
 - 分桶算法，必选
 - 分桶算法
 - Hash 分桶语法：DISTRIBUTED BY HASH (k1[,k2 ...]) [BUCKETS num|auto] 说明：使用指定的 key 列进行哈希分桶。
 - Random 分桶语法：DISTRIBUTED BY RANDOM [BUCKETS num|auto] 说明：使用随机数进行分桶。
 - MySQL 没有分桶算法
- rollup_list
 - 建表的同时可以创建多个物化视图，可选
 - rollup_name (col1[, col2, ...]) [DUPLICATE KEY(col1[, col2, ...])] [PROPERTIES("key" = "value")]
 - MySQL 不支持
- properties:
 - 表属性
 - 表属性与 MySQL 的表属性不一致，定义表属性的语法也与 MySQL 不一致

03 Create-Index

```
CREATE INDEX [IF NOT EXISTS] index_name ON table_name (column [, ...],) [USING BITMAP];
```

- 目前支持：位图索引、倒排索引和 N-Gram 索引，布隆过滤器索引（单独的语法设置）
- MySQL 支持的索引算法有：B+Tree，Hash

04 Create-View

```
CREATE VIEW [IF NOT EXISTS]
[db_name.]view_name
(column1[ COMMENT "col comment"][, column2, ...])
AS query_stmt

CREATE MATERIALIZED VIEW (IF NOT EXISTS)? mvName=multipartIdentifier
(LEFT_PAREN cols=simpleColumnDefs RIGHT_PAREN)? buildMode?
```

```

(REFRESH refreshMethod? refreshTrigger?)?
(KEY keys=identifierList)?
(COMMENT STRING_LITERAL)?
(PARTITION BY LEFT_PAREN partitionKey = identifier RIGHT_PAREN)?
(DISTRIBUTED BY (HASH hashKeys=identifierList | RANDOM) (BUCKETS (INTEGER_VALUE | AUTO))?)?
propertyClause?
AS query

```

- 基本语法与 MySQL 一致
- Doris 支持两种物化视图，同步物化视图和异步物化视图（从 v2.1 开始支持异步物化视图功能）。Doris 的异步物化视图更加强大。
- MySQL 仅支持异步物化视图

05 Alter-Table/Alter-Index

Doris Alter 的语法与 MySQL 的基本一致。

Drop-Table/Drop-Index

Doris Drop 的语法与 MySQL 的基本一致

DML

Insert

```

INSERT INTO table_name
  [ PARTITION (p1, ...) ]
  [ WITH LABEL label]
  [ (column [, ...]) ]
  [ [ hint [, ...] ] ]
  { VALUES ( { expression | DEFAULT } [, ...] ) [, ...] | query }

```

Doris Insert 语法与 MySQL 的基本一致。

Update

```

UPDATE target_table [table_alias]
  SET assignment_list
  WHERE condition

assignment_list:
  assignment [, assignment] ...

assignment:
  col_name = value

value:
  {expr | DEFAULT}

```

Doris Update 语法与 MySQL 基本一致，但需要注意的是必须加上 **where** 条件。

Delete

```
DELETE FROM table_name [table_alias]
    [PARTITION partition_name | PARTITIONS (partition_name [, partition_name])]
WHERE column_name op { value | value_list } [ AND column_name op { value | value_list } ...];
```

Doris 该语法只能指定过滤谓词

```
DELETE FROM table_name [table_alias]
    [PARTITION partition_name | PARTITIONS (partition_name [, partition_name])]
    [USING additional_tables]
WHERE condition
```

Doris 该语法只能在 UNIQUE KEY 模型表上使用。

Doris Delete 语法与 MySQL 基本一致。但是由于 Doris 是一个分析数据库，所以删除不能过于频繁。

Select

```
SELECT
    [hint_statement, ...]
    [ALL | DISTINCT | DISTINCTROW | ALL EXCEPT ( col_name1 [, col_name2, col_name3, ...] )]
    select_expr [, select_expr ...]
    [FROM table_references
        [PARTITION partition_list]
        [TABLET tabletid_list]
        [TABLESAMPLE sample_value [ROWS | PERCENT]
            [REPEATABLE pos_seek]]
    [WHERE where_condition]
    [GROUP BY [GROUPING SETS | ROLLUP | CUBE] {col_name | expr | position}]
    [HAVING where_condition]
    [ORDER BY {col_name | expr | position}
        [ASC | DESC], ...]
    [LIMIT {[offset,] row_count | row_count OFFSET offset}]
    [INTO OUTFILE 'file_name']
```

Doris Select 语法与 MySQL 基本一致

SQL Function

Doris Function 基本覆盖绝大部分 MySQL Function。

Select 查询

Select 语法

```
SELECT
    [hint_statement, ...]
    [ALL | DISTINCT | DISTINCTROW | ALL EXCEPT ( col_name1 [, col_name2, col_name3, ...] )]
    select_expr [, select_expr ...]
    [FROM table_references
        [PARTITION partition_list]
        [TABLET tabletid_list]
        [TABLESAMPLE sample_value [ROWS | PERCENT]
            [REPEATABLE pos_seek]]
    [WHERE where_condition]
    [GROUP BY [GROUPING SETS | ROLLUP | CUBE] {col_name | expr | position}]
    [HAVING where_condition]
    [ORDER BY {col_name | expr | position}
        [ASC | DESC], ...]
    [LIMIT {[offset,] row_count | row_count OFFSET offset}]
    [INTO OUTFILE 'file_name']
```

语法说明

- select_expr, ...

检索并在结果中显示的列，使用别名时，as 为自选。

- table_references

检索的目标表，一个或者多个表（包括子查询产生的临时表）

- where_definition

检索条件（表达式），如果存在 WHERE 子句，其中的条件对行数据进行筛选。where_condition 是一个表达式，对于要选择的每一行，其计算结果为 true。如果没有 WHERE 子句，该语句将选择所有行。在 WHERE 表达式中，您可以使用除聚合函数之外的任何 MySQL 支持的函数和运算符

- ALL | DISTINCT

对结果集进行刷选，all 为全部，distinct/distinctrow 将刷选出重复列，默认为 all

- ALL EXCEPT

对全部（all）结果集进行筛选，except 指定要从全部结果集中排除的一个或多个列的名称。输出中将忽略所有匹配的列名称。

- INTO OUTFILE 'file_name'

保存结果至新文件（之前不存在）中，区别在于保存的格式。

- Group by having

对结果集进行分组，having 出现则对 group by 的结果进行筛选。Grouping Sets、Rollup、Cube 为 group by 的扩展，详细可参考 [GROUPING SETS 设计文档](#)。

- Order by

对最后的结果进行排序，Order by 通过比较一列或者多列的大小来对结果集进行排序。

Order by 是比较耗时耗资源的操作，因为所有数据都需要发送到 1 个节点后才能排序，排序操作相比不排序操作需要更多的内存。

如果需要返回前 N 个排序结果，需要使用 LIMIT 从句；为了限制内存的使用，如果用户没有指定 LIMIT 从句，则默认返回前 65535 个排序结果。

- Limit n

限制输出结果中的行数，limit m,n 表示从第 m 行开始输出 n 条记录，使用 limit m,n 的时候要加上 order by 才有意义，否则每次执行的数据可能会不一致

- Having

Having 从句不是过滤表中的行数据，而是过滤聚合函数产出的结果。

通常来说 having 要和聚合函数（例如 :COUNT(), SUM(), AVG(), MIN(), MAX()）以及 group by 从句一起使用。

- SELECT 支持使用 PARTITION 显式分区选择，其中包含 table_reference 中表的名称后面的分区或子分区（或两者）列表

- [TABLET tids] TABLESAMPLE n [ROWS | PERCENT] [REPEATABLE seek]

在 FROM 子句中限制表的读取行数，根据指定的行数或百分比从表中伪随机的选择数个 Tablet，REPEATABLE 指定种子数可使选择的样本再次返回，此外也可手动指定 TableID，注意这只能用于 OLAP 表。

- hint_statement

在 selectlist 前面使用 hint 表示可以通过 hint 去影响优化器的行为以期得到想要的执行计划，详情可参考 [joinHint 使用文档](#)

语法约束

- SELECT 也可用于检索计算的行而不引用任何表。
- 所有的子句必须严格地按照上面格式排序，一个 HAVING 子句必须位于 GROUP BY 子句之后，并位于 ORDER BY 子句之前。
- 别名关键词 AS 自选。别名可用于 group by，order by 和 having
- Where 子句：执行 WHERE 语句以确定哪些行应被包含在 GROUP BY 部分中，而 HAVING 用于确定应使用结果集中的哪些行。
- HAVING 子句可以引用总计函数，而 WHERE 子句不能引用，如 count,sum,max,min,avg，同时，where 子句可以引用除总计函数外的其他函数。Where 子句中不能使用列别名来定义条件。

- Group by 后跟 with rollup 可以对结果进行一次或者多次统计。

联接查询

Doris 支持以下 JOIN 语法

```
JOIN
table_references:
    table_reference [, table_reference] ...
table_reference:
    table_factor
    | join_table
table_factor:
    tbl_name [[AS] alias]
        [{USE|IGNORE|FORCE} INDEX (key_list)]
    | ( table_references )
    | { OJ table_reference LEFT OUTER JOIN table_reference
        ON conditional_expr }
join_table:
    table_reference [INNER | CROSS] JOIN table_factor [join_condition]
    | table_reference LEFT [OUTER] JOIN table_reference join_condition
    | table_reference NATURAL [LEFT [OUTER]] JOIN table_factor
    | table_reference RIGHT [OUTER] JOIN table_reference join_condition
    | table_reference NATURAL [RIGHT [OUTER]] JOIN table_factor
join_condition:
    ON conditional_expr
```

UNION 语法：

```
SELECT ...
UNION [ALL| DISTINCT] SELECT .....
[UNION [ALL| DISTINCT] SELECT ...]
```

UNION 用于将多个 SELECT 语句 的结果组合 到单个结果集中。

第一个 SELECT 语句中的列名称用作返回结果的列名称。在每个 SELECT 语句的 相应位置列出的选定列 应具有相同的数据类型。（例如，第一个语句选择的第一列应该与其他语句选择的第一列具有相同的类型。）

默认行为 UNION 是从结果中删除重复的行。可选 DISTINCT 关键字除了默认值之外没有任何效果，因为它还指定了重复行删除。使用可选 ALL 关键字，不会发生重复行删除，结果包括所有 SELECT 语句中的 所有匹配行

INTERSECT 语法：

```
SELECT ...
INTERSECT [DISTINCT] SELECT .....
[INTERSECT [DISTINCT] SELECT ...]
```

INTERSECT 用于返回多个 SELECT 语句的结果之间的交集，并对结果进行去重。INTERSECT 效果等同于 INTERSECT DISTINCT。不支持 ALL 关键字。每条 SELECT 查询返回的列数必须相同，且当列类型不一致时，会 CAST 到相同类型。

EXCEPT/MINUS 语法：

```
SELECT ...
EXCEPT [DISTINCT] SELECT .....
```

```
[EXCEPT [DISTINCT] SELECT ...]
```

EXCEPT 子句用于返回多个查询结果之间的补集，即返回左侧查询中在右侧查询中不存在的数据，并对结果集去重。EXCEPT 和 MINUS 功能对等。EXCEPT 效果等同于 EXCEPT DISTINCT。不支持 ALL 关键字。每条 SELECT 查询返回的列数必须相同，且当列类型不一致时，会 CAST 到相同类型。

WITH 语句：

要指定公用表表达式，请使用 WITH 具有一个或多个逗号分隔子句的子句。每个子条款都提供一个子查询，用于生成结果集，并将名称与子查询相关联。下面的示例定义名为的 CTE cte1 和 cte2 中 WITH 子句，并且是指在其顶层 SELECT 下面的 WITH 子句：

```
WITH
  cte1 AS (SELECT a, b FROM table1),
  cte2 AS (SELECT c, d FROM table2)
SELECT b, d FROM cte1 JOIN cte2
WHERE cte1.a = cte2.c;
```

在包含该 WITH 子句 的语句中，可以引用每个 CTE 名称以访问相应的 CTE 结果集。

CTE 名称可以在其他 CTE 中引用，从而可以基于其他 CTE 定义 CTE。

目前不支持递归的 CTE。

使用举例

- 查询年龄分别是 18,20,25 的学生姓名

```
select Name from student where age in (18,20,25);
```

- ALL EXCEPT 示例

```
-- 查询除了学生年龄的所有信息
select * except(age) from student;
```

- GROUP BY 示例

```
--查询 tb_book 表，按照 type 分组，求每类图书的平均价格，
select type,avg(price) from tb_book group by type;
```

- DISTINCT 使用

```
--查询tb_book表，除去重复的type数据
select distinct type from tb_book;
```

- ORDER BY 示例

对查询结果进行升序（默认）或降序（DESC）排列。升序 NULL 在最前面，降序 NULL 在最后面

```
--查询 tb_book 表中的所有记录,按照 id 降序排列,显示三条记录
select * from tb_book order by id desc limit 3;
```

- LIKE 模糊查询

可实现模糊查询,它有两种通配符: %和_, %可以匹配一个或多个字符, _可以匹配一个字符

```
--查找所有第二个字符是h的图书
select * from tb_book where name like('_h%');
```

- LIMIT 限定结果行数

```
--1.降序显示 3 条记录
select * from tb_book order by price desc limit 3;

--2.从 id=1 显示 4 条记录
select * from tb_book where id limit 1,4;
```

- CONCAT 联合多列

```
--把 name 和 price 合并成一个新的字符串输出
select id,concat(name,":",price) as info,type from tb_book;
```

- 使用函数和表达式

```
--计算 tb_book 表中各类图书的总价格
select sum(price) as total,type from tb_book group by type;

--price 打八折
select *,(price * 0.8) as "八折" from tb_book;
```

- UNION 示例

```
SELECT a FROM t1 WHERE a = 10 AND B = 1 ORDER by a LIMIT 10
UNION
SELECT a FROM t2 WHERE a = 11 AND B = 2 ORDER by a LIMIT 10;
```

- INTERSECT 示例

```
SELECT a FROM t1 WHERE a = 10 AND B = 1 ORDER by a LIMIT 10
INTERSECT
SELECT a FROM t2 WHERE a = 11 AND B = 2 ORDER by a LIMIT 10;
```

- EXCEPT 示例

```
SELECT a FROM t1 WHERE a = 10 AND B = 1 ORDER by a LIMIT 10
EXCEPT
SELECT a FROM t2 WHERE a = 11 AND B = 2 ORDER by a LIMIT 10;
```

- WITH 子句示例

```
WITH cte AS
(
  SELECT 1 AS col1, 2 AS col2
  UNION ALL
  SELECT 3, 4
)
SELECT col1, col2 FROM cte;
```

- JOIN 示例

```
SELECT * FROM t1 LEFT JOIN (t2, t3, t4)
      ON (t2.a = t1.a AND t3.b = t1.b AND t4.c = t1.c)
```

- 等同于

```
SELECT * FROM t1 LEFT JOIN (t2 CROSS JOIN t3 CROSS JOIN t4)
      ON (t2.a = t1.a AND t3.b = t1.b AND t4.c = t1.c)
```

- INNER JOIN

```
SELECT t1.name, t2.salary
  FROM employee AS t1 INNER JOIN info AS t2 ON t1.name = t2.name;

SELECT t1.name, t2.salary
  FROM employee t1 INNER JOIN info t2 ON t1.name = t2.name;
```

- LEFT JOIN

```
SELECT left_tbl.*
  FROM left_tbl LEFT JOIN right_tbl ON left_tbl.id = right_tbl.id
 WHERE right_tbl.id IS NULL;
```

- RIGHT JOIN

```
mysql SELECT * FROM t1 RIGHT JOIN t2 ON (t1.a = t2.a);
```

| a | b | a | c |
|------|------|---|---|
| 2 | y | 2 | z |
| NULL | NULL | 3 | w |

- TABLESAMPLE

--在 t1 中伪随机的抽样 1000 行。注意实际是根据表的统计信息选择若干 Tablet，被选择的 Tablet 总行数可能大于 1000，所以若想明确返回 1000 行需要加上 Limit。

```
SELECT * FROM t1 TABLET(10001) TABLESAMPLE(1000 ROWS) REPEATABLE 2 limit 1000;
```

最佳实践

- 关于 SELECT 子句的一些附加知识

- 可以使用 AS alias_name 为 select_expr 指定别名。别名用作表达式的列名，可用于 GROUP BY，ORDER BY 或 HAVING 子句。
- FROM 后的 table_references 指示参与查询的一个或者多个表。如果列出了多个表，就会执行 JOIN 操作。而对于每一个指定表，都可以为其定义别名
- SELECT 后被选择的列，可以在 ORDER BY 和 GROUP BY 中，通过列名、列别名或者代表列位置的整数（从 1 开始）来引用

```
SELECT college, region, seed FROM tournament
ORDER BY region, seed;

SELECT college, region AS r, seed AS s FROM tournament
ORDER BY r, s;

SELECT college, region, seed FROM tournament
ORDER BY 2, 3;
```

- 如果 ORDER BY 出现在子查询中，并且也应用于外部查询，则最外层的 ORDER BY 优先。
- 如果使用了 GROUP BY，被分组的列会自动按升序排列（就好像有一个 ORDER BY 语句后面跟了同样的列）。如果要避免 GROUP BY 因为自动排序生成的开销，添加 ORDER BY NULL 可以解决：
 - *SELECT a, COUNT(b) FROM test_table GROUP BY a ORDER BY NULL;*
- 当使用 ORDER BY 或 GROUP BY 对 SELECT 中的列进行排序时，服务器仅使用 max_sort_length 系统变量指示的初始字节数对值进行排序。
- Having 子句一般应用在最后，恰好在结果集被返回给客户端前，且没有进行优化。（而 LIMIT 应用在 HAVING 后）
- SQL 标准要求：HAVING 必须引用在 GROUP BY 列表中或者聚合函数使用的列。然而，MySQL 对此进行了扩展，它允许 HAVING 引用 Select 子句列表中的列，还有外部子查询的列。
- 如果 HAVING 引用的列具有歧义，会有警告产生。下面的语句中，col2 具有歧义：

```
SELECT COUNT(col1) AS col2 FROM t GROUP BY col2 HAVING col2 = 2;
```

- 切记不要在该使用 WHERE 的地方使用 HAVING。HAVING 是和 GROUP BY 搭配的。
- HAVING 子句可以引用聚合函数，而 WHERE 不能。

```
SELECT user, MAX(salary) FROM users
GROUP BY user HAVING MAX(salary) > 10;
```

- LIMIT 子句可用于约束 SELECT 语句返回的行数。LIMIT 可以有一个或者两个参数，都必须为非负整数。

```
/*取回结果集中的 6~15 行*/
SELECT * FROM tbl LIMIT 5,10;
/*那如果要取回一个设定某个偏移量之后的所有行，可以为第二参数设定一个非常大的常量。以下查询取回从第 96 行起的所有数据*/
```

```
SELECT * FROM tbl LIMIT 95,18446744073709551615;  
/*若 LIMIT 只有一个参数，则参数指定应该取回的行数，偏移量默认为 0，即从第一行起*/
```

- SELECT...INTO 可以让查询结果写入到文件中
- SELECT 关键字的修饰符
 - 主要是用来去重
 - ALL 和 DISTINCT 修饰符指定是否对结果集中的行（应该不是某个列）去重。
 - ALL 是默认修饰符，即满足要求的所有行都要被取回来。
 - DISTINCT 删除重复的行。
- 子查询的主要优势
 - 子查询允许结构化的查询，这样就可以把一个语句的每个部分隔离开。
 - 有些操作需要复杂的联合和关联。子查询提供了其它的方法来执行这些操作
- 加速查询
 - 尽可能利用 Doris 的分区分桶作为数据过滤条件，减少数据扫描范围
 - 充分利用 Doris 的前缀索引字段作为数据过滤条件加速查询速度
- UNION

只使用 union 关键词和使用 union disitnct 的效果是相同的。由于去重工作是比较耗费内存的，因此使用 union all 操作查询速度会快些，耗费内存会少些。如果用户想对返回结果集进行 order by 和 limit 操作，需要将 union 操作放在子查询中，然后 select from subquery，最后把 subquery 和 order by 放在子查询外面。

```
select * from (select age from student_01 union all select age from student_02) as t1  
order by age limit 4;
```

```
+-----+  
|   age   |  
+-----+  
|    18   |  
|    19   |  
|    20   |  
|    21   |  
+-----+  
4 rows in set (0.01 sec)
```

- JOIN
 - 在 inner join 条件里除了支持等值 join，还支持不等值 join，为了性能考虑，推荐使用等值 join。
 - 其它 join 只支持等值 join

复杂类型查询

Doris 支持 Array, Map, Struct, JSON 等复杂类型。

Doris 提供了针对以上复杂类型的各类函数。

详细的函数支持，请查看 SQL 手册 / SQL 函数 下的 [数组函数](#)、[Struct 函数](#) 和 [JSON 函数](#)，Map 函数支持情况，直接查看 SQL 手册 / 数据类型 / [MAP](#)。

子查询

子查询是一种嵌套在其他 SELECT 语句中的 SELECT 语句。嵌套子查询通常称为查询内语句，而包含查询通常称为查询语句或外查询块。子查询返回外查询用作条件的数据，以确定需要检索哪些数据。您可以创建的嵌套子查询的数量没有限制。

与任何查询一样，子查询返回（单列单记录、单列多记录或多列多记录）表中的记录。

Where 子句中的子查询举例

```
SELECT * FROM sub_query_correlated_subquery1 WHERE k1 > (SELECT AVG(k1) FROM sub_query_correlated_subquery3)
OR k1 < 10 order by k1, k2;
select * from sub_query_correlated_subquery1 where sub_query_correlated_subquery1.k1 not in (select
sub_query_correlated_subquery3.k3 from sub_query_correlated_subquery3 where sub_query_correlated_subquery3.v2
= sub_query_correlated_subquery1.k2) or k1 < 10 order by k1, k2
```

Join 子句中的子查询举例

```
select t1.* from t1 left join t2 on t1.k2 = t2.k3 and t1.k1 in ( select t3.k1 from t3 where t1.k2 = t3.k2 )
or t1.k1 < 10 order by t1.k1, t1.k2;
select t1.* from t1 left join t2 on t1.k2 = t2.k3 and exists ( select t3.k1 from t3 where t1.k2 = t3.k2 ) or
t1.k1 < 10 order by t1.k1, t1.k2;
```

公用表表达式（CTE）

描述

公用表表达式（Common Table Expression）定义一个临时结果集，你可以在 SQL 语句的范围内多次引用。CTE 主要用于 SELECT 语句中。

要指定公用表表达式，请使用 WITH 具有一个或多个逗号分隔子句的子句。每个子句都提供一个子查询，用于生成结果集，并将名称与子查询相关联。

Doris 支持嵌套 CTE。在包含该 WITH 子句的语句中，可以引用每个 CTE 名称以访问相应的 CTE 结果集。CTE 名称可以在其他 CTE 中引用，从而可以基于其他 CTE 定义 CTE。

Doris 不支持 递归 CTE。有关递归 CTE 的详细解释，可以参考 [MySQL 递归 CTE 手册](#)

示例

简单示例

下面的示例定义名为 CTE cte1 和 cte2 的 WITH 子句，并且是指它们在顶层 SELECT 下面的 WITH 子句：

```
WITH
  cte1 AS (SELECT a, b FROM table1),
  cte2 AS (SELECT c, d FROM table2)
SELECT b, d FROM cte1 JOIN cte2
WHERE cte1.a = cte2.c;
```

嵌套 CTE

```
WITH
  cte1 AS (SELECT a, b FROM table1),
  cte2 AS (SELECT c, d FROM cte1)
SELECT b, d FROM cte1 JOIN cte2
WHERE cte1.a = cte2.c;
```

递归 CTE（Doris 不支持）

```
```sql WITH r_cte AS ( SELECT 1 AS user_id, 2 as manager_id UNION ALL SELECT user_id, manager_id
FROM r_cte INNER JOIN (SELECT 1 AS user_id, 2 as manager_id) t ON r_cte.manager_id = t.user_id)
SELECT * FROM r_cte
```



id	name	age	class	address	c_age
100	John	30	1	Street 1	30
100	John	30	1	Street 1	60
200	Mary	NULL	1	Street 2	30
200	Mary	NULL	1	Street 2	60
300	Mike	80	3	Street 3	30
300	Mike	80	3	Street 3	60
400	Dan	50	4	Street 4	30
400	Dan	50	4	Street 4	60

8 rows in set (0.12 sec)

# 分析 (窗口) 函数

分析函数是一类特殊的内置函数。和聚合函数类似，分析函数也是对于多个输入行做计算得到一个数据值。不同的是，分析函数是在一个特定的窗口内对输入数据做处理，而不是按照 `group by` 来分组计算。每个窗口内的数据可以用 `over()` 从句进行排序和分组。分析函数会对结果集的每一行计算出一个单独的值，而不是每个 `group by` 分组计算一个值。这种灵活的方式允许用户在 `select` 从句中增加额外的列，给用户提供了更多的机会来对结果集进行重新组织和过滤。分析函数只能出现在 `select` 列表和最外层的 `order by` 从句中。在查询过程中，分析函数会在最后生效，就是说，在执行完 `join`，`where` 和 `group by` 等操作之后再执行。分析函数在金融和科学计算领域经常被使用到，用来分析趋势、计算离群值以及对大量数据进行分桶分析等。

分析函数的语法：

```
function(args) OVER(partition_by_clause order_by_clause [window_clause])
partition_by_clause ::= PARTITION BY expr [, expr ...]
order_by_clause ::= ORDER BY expr [ASC | DESC] [, expr [ASC | DESC] ...]
```

## Function

目前支持的 Function 包括 `AVG()`，`COUNT()`，`DENSE_RANK()`，`FIRST_VALUE()`，`LAG()`，`LAST_VALUE()`，`LEAD()`，`MAX()`，`MIN()`，`RANK()`，`ROW_NUMBER()`，`SUM()` 和所有聚合函数。

## PARTITION BY 从句

Partition By 从句和 Group By 类似。它把输入行按照指定的一列或多列分组，相同值的行会被分到一组。

## ORDER BY 从句

Order By 从句和外层的 Order By 基本一致。它定义了输入行的排列顺序，如果指定了 Partition By，则 Order By 定义了每个 Partition 分组内的顺序。与外层 Order By 的唯一不同点是，OVER 从句中的 Order By `n` (`n` 是正整数) 相当于不做任何操作，而外层的 Order By `n` 表示按照第 `n` 列排序。

举例：

这个例子展示了在 `select` 列表中增加一个 `id` 列，它的值是 1, 2, 3 等等，顺序按照 `events` 表中的 `date_and_time` 列排序。

```
SELECT
row_number() OVER (ORDER BY date_and_time) AS id,
c1, c2, c3, c4
FROM events;
```

## Window 从句

Window 从句用来为分析函数指定一个运算范围，以当前行为准，前后若干行作为分析函数运算的对象。

Window 从句支持的方法有：`AVG()`，`COUNT()`，`FIRST_VALUE()`，`LAST_VALUE()` 和 `SUM()`。对于 `MAX()` 和 `MIN()`，window 从句可以指定开始范围 `UNBOUNDED PRECEDING`

语法:

```
ROWS BETWEEN [{ m | UNBOUNDED } PRECEDING | CURRENT ROW] [AND [CURRENT ROW | { UNBOUNDED | n } FOLLOWING]]
```

## 举例

假设我们有如下的股票数据，股票代码是 JDR，closing price 是每天的收盘价。

```
create table stock_ticker (stock_symbol string, closing_price decimal(8,2), closing_date datetime);
...load some data...
select * from stock_ticker order by stock_symbol, closing_date
```

stock_symbol	closing_price	closing_date
JDR	12.86	2014-10-02 00:00:00
JDR	12.89	2014-10-03 00:00:00
JDR	12.94	2014-10-04 00:00:00
JDR	12.55	2014-10-05 00:00:00
JDR	14.03	2014-10-06 00:00:00
JDR	14.75	2014-10-07 00:00:00
JDR	13.98	2014-10-08 00:00:00

这个查询使用分析函数产生 `moving_average` 这一列，它的值是 3 天的股票均价，即前一天、当前以及后一天三天的均价。第一天没有前一天的值，最后一天没有后一天的值，所以这两行只计算了两天的均值。这里 `Partition By` 没有起到作用，因为所有的数据都是 JDR 的数据，但如果还有其他股票信息，`Partition By` 会保证分析函数值作用在本 `Partition` 之内。

```
select stock_symbol, closing_date, closing_price,
avg(closing_price) over (partition by stock_symbol order by closing_date
rows between 1 preceding and 1 following) as moving_average
from stock_ticker;
```

stock_symbol	closing_date	closing_price	moving_average
JDR	2014-10-02 00:00:00	12.86	12.87
JDR	2014-10-03 00:00:00	12.89	12.89
JDR	2014-10-04 00:00:00	12.94	12.79
JDR	2014-10-05 00:00:00	12.55	13.17
JDR	2014-10-06 00:00:00	14.03	13.77
JDR	2014-10-07 00:00:00	14.75	14.25
JDR	2014-10-08 00:00:00	13.98	14.36

## 更多帮助

更多窗口函数，参见 [SQL 手册 / SQL 函数 / 分析（窗口）函数](#)。

# Encription and Masking Function

---

Doris 内置了如下加密和脱敏函数。详细使用，请参考 SQL 手册。

- [AES\\_ENCRYPT](#)
- [AES\\_DECRYPT](#)
- [SM4\\_ENCRYPT](#)
- [SM4\\_DECRYPT](#)
- [MD5](#)
- [MD5SUM](#)
- [SM3](#)
- [SM3SUM](#)
- [SHA](#)
- [SHA2](#)
- [DIGITAL\\_MASKING](#)

# 变量

本文档主要介绍当前支持的变量（Variables）。

Doris 中的变量参考 MySQL 中的变量设置。但部分变量仅用于兼容一些 MySQL 客户端协议，并不产生其在 MySQL 数据库中的实际意义。

## 变量设置与查看

### 查看

可以通过 `SHOW VARIABLES [LIKE 'xxx'];` 查看所有或指定的变量。如：

```
SHOW VARIABLES;
SHOW VARIABLES LIKE '%time_zone%';
```

### 设置

部分变量可以设置全局生效或仅当前会话生效。

注意，在 1.1 版本之前，设置全局生效后，后续新的会话连接中会沿用设置值，但当前会话中的值不变。而在 1.1 版本（含）之后，设置全局生效后，后续新的会话连接中会沿用设置值，当前会话中的值也会改变。

仅当前会话生效，通过 `SET var_name=xxx;` 语句来设置。如：

```
SET exec_mem_limit = 137438953472;
SET forward_to_master = true;
SET time_zone = "Asia/Shanghai";
```

全局生效，通过 `SET GLOBAL var_name=xxx;` 设置。如：

```
SET GLOBAL exec_mem_limit = 137438953472
```

**注 1：**只有 **ADMIN** 用户可以设置变量的全局生效。

既支持当前会话生效又支持全局生效的变量包括：

- `time_zone`
- `wait_timeout`
- `sql_mode`
- `enable_profile`
- `query_timeout`



- `exec_mem_limit`
- `batch_size`
- `allow_partition_column_nullable`
- `insert_visible_timeout_ms`
- `enable_fold_constant_by_be`

只支持全局生效的变量包括：

- `default_rowset_type`
- `default_password_lifetime`
- `password_history`
- `validate_password_policy`

同时，变量设置也支持常量表达式。如：

```
SET exec_mem_limit = 10 * 1024 * 1024 * 1024;
SET forward_to_master = concat('tr', 'u', 'e');
```

## 在查询语句中设置变量

在一些场景中，我们可能需要对某些查询有针对性的设置变量。通过使用 `SET_VAR` 提示可以在查询中设置会话变量（在单个语句内生效）。例子：

```
SELECT /*+ SET_VAR(exec_mem_limit = 8589934592) */ name FROM people ORDER BY name;
SELECT /*+ SET_VAR(query_timeout = 1, enable_partition_cache=true) */ sleep(3);
```

注意注释必须以 `/*+` 开头，并且只能跟随在 `SELECT` 之后。

## 支持的变量

- `SQL_AUTO_IS_NULL`

用于兼容 JDBC 连接池 C3P0。无实际作用。

- `auto_increment_increment`

用于兼容 MySQL 客户端。无实际作用。虽然 Doris 已经有了 [AUTO\\_INCREMENT](#) 功能，但这个参数并不会对 `AUTO_INCREMENT` 的行为产生影响。`auto_increment_offset` 也是如此。

- `autocommit`

用于兼容 MySQL 客户端。无实际作用。

- `auto_broadcast_join_threshold`

执行连接时将向所有节点广播的表的最大字节大小，通过将此值设置为 -1 可以禁用广播。

系统提供了两种 Join 的实现方式，broadcast join 和 shuffle join。

broadcast join 是指将小表进行条件过滤后，将其广播到大表所在的各个节点上，形成一个内存 Hash 表，然后流式读出大表的数据进行 Hash Join。

shuffle join 是指将小表和大表都按照 Join 的 key 进行 Hash，然后进行分布式的 Join。

当小表的数据量较小时，broadcast join 拥有更好的性能。反之，则 shuffle join 拥有更好的性能。

系统会自动尝试进行 Broadcast Join，也可以显式指定每个 join 算子的实现方式。系统提供了可配置的参数 auto\_broadcast\_join\_threshold，指定使用 broadcast join 时，hash table 使用的内存占整体执行内存比例的上限，取值范围为 0 到 1，默认值为 0.8。当系统计算 hash table 使用的内存会超过此限制时，会自动转换为使用 shuffle join

这里的整体执行内存是：查询优化器做估算的一个比例

注意：

不建议用这个参数来调整，如果必须要使用某一种 join，建议使用 hint，比如 join[shuffle]

- batch\_size

用于指定在查询执行过程中，各个节点传输的单个数据包的行数。默认一个数据包的行数为 1024 行，即源端节点每产生 1024 行数据后，打包发给目的节点。

较大的行数，会在扫描大数据量场景下提升查询的吞吐，但可能会在小查询场景下增加查询延迟。同时，也会增加查询的内存开销。建议设置范围 1024 至 4096。

- character\_set\_client

用于兼容 MySQL 客户端。无实际作用。

- character\_set\_connection

用于兼容 MySQL 客户端。无实际作用。

- character\_set\_results

用于兼容 MySQL 客户端。无实际作用。

- character\_set\_server

用于兼容 MySQL 客户端。无实际作用。

- codegen\_level

用于设置 LLVM codegen 的等级。（当前未生效）。

- collation\_connection

用于兼容 MySQL 客户端。无实际作用。

- collation\_database

用于兼容 MySQL 客户端。无实际作用。

- `collation_server`

用于兼容 MySQL 客户端。无实际作用。

- `have_query_cache`

用于兼容 MySQL 客户端。无实际作用。

- `default_order_by_limit`

用于控制 OrderBy 以后返回的默认条数。默认值为 -1，默认返回查询后的最大条数，上限为 long 数据类型的 MAX\_VALUE 值。

- `delete_without_partition`

设置为 true 时。当使用 delete 命令删除分区表数据时，可以不指定分区。delete 操作将会自动应用到所有分区。

但注意，自动应用到所有分区可能导致 delete 命令耗时触发大量子任务导致耗时较长。如无必要，不建议开启。

- `disable_colocate_join`

控制是否启用 [Colocation Join](#) 功能。默认为 false，表示启用该功能。true 表示禁用该功能。当该功能被禁用后，查询规划将不会尝试执行 Colocation Join。

- `enable_bucket_shuffle_join`

控制是否启用 [Bucket Shuffle Join](#) 功能。默认为 true，表示启用该功能。false 表示禁用该功能。当该功能被禁用后，查询规划将不会尝试执行 Bucket Shuffle Join。

- `disable_streaming_preaggregations`

控制是否开启流式预聚合。默认为 false，即开启。当前不可设置，且默认开启。

- `enable_insert_strict`

用于设置通过 INSERT 语句进行数据导入时，是否开启 strict 模式。默认为 false，即不开启 strict 模式。关于该模式的介绍，可以参阅 [这里](#)。

- `enable_spilling`

用于设置是否开启大数据量落盘排序。默认为 false，即关闭该功能。当用户未指定 ORDER BY 子句的 LIMIT 条件，同时设置 enable\_spilling 为 true 时，才会开启落盘排序。该功能启用后，会使用 BE 数据目录下 doris-scratch/ 目录存放临时的落盘数据，并在查询结束后，清空临时数据。

该功能主要用于使用有限的内存进行大数据量的排序操作。

注意，该功能为实验性质，不保证稳定性，请谨慎开启。

- `exec_mem_limit`

用于设置单个查询的内存限制。默认为 2GB，单位为 B/K/KB/M/MB/G/GB/T/TB/P/PB，默认为 B。

该参数用于限制一个查询计划中，单个查询计划的实例所能使用的内存。一个查询计划可能有多个实例，一个 BE 节点可能执行一个或多个实例。所以该参数并不能准确限制一个查询在整个集群的内存使用，也不能准确限制一个查询在单一 BE 节点上的内存使用。具体需要根据生成的查询计划判断。

通常只有在一些阻塞节点（如排序节点、聚合节点、Join 节点）上才会消耗较多的内存，而其他节点（如扫描节点）中，数据为流式通过，并不会占用较多的内存。

当出现 Memory Exceed Limit 错误时，可以尝试指数级增加该参数，如 4G、8G、16G 等。

需要注意的是，这个值可能有几 MB 的浮动。

- `forward_to_master`

用户设置是否将一些 show 类命令转发到 Master FE 节点执行。默认为 true，即转发。Doris 中存在多个 FE 节点，其中一个为 Master 节点。通常用户可以连接任意 FE 节点进行全功能操作。但部分信息查看指令，只有从 Master FE 节点才能获取详细信息。

如 SHOW BACKENDS; 命令，如果不转发到 Master FE 节点，则仅能看到节点是否存活等一些基本信息，而转发到 Master FE 则可以获取包括节点启动时间、最后一次心跳时间等更详细的信息。

当前受该参数影响的命令如下：

1. SHOW FRONTENDS;

转发到 Master 可以查看最后一次心跳信息。

2. SHOW BACKENDS;

转发到 Master 可以查看启动时间、最后一次心跳信息、磁盘容量信息。

3. SHOW BROKER;

转发到 Master 可以查看启动时间、最后一次心跳信息。

4. SHOW TABLET;/ADMIN SHOW REPLICA DISTRIBUTION;/ADMIN SHOW REPLICA STATUS;

转发到 Master 可以查看 Master FE 元数据中存储的 tablet 信息。正常情况下，不同 FE 元数据中 tablet 信息应该是一致的。当出现问题时，可以通过这个方法比较当前 FE 和 Master FE 元数据的差异。

5. SHOW PROC;

转发到 Master 可以查看 Master FE 元数据中存储的相关 PROC 的信息。主要用于元数据比对。

- `init_connect`

用于兼容 MySQL 客户端。无实际作用。

- `interactive_timeout`

用于兼容 MySQL 客户端。无实际作用。

- `enable_profile`

用于设置是否需要查看查询的 profile。默认为 false，即不需要 profile。

默认情况下，只有在查询发生错误时，BE 才会发送 profile 给 FE，用于查看错误。正常结束的查询不会发送 profile。发送 profile 会产生一定的网络开销，对高并发查询场景不利。当用户希望对一个查询的 profile 进行分析时，可以将这个变量设为 true 后，发送查询。查询结束后，可以通过在当前连接的 FE 的 web 页面查看到 profile：

fe\_host:fe\_http\_port/query

其中会显示最近 100 条，开启 enable\_profile 的查询的 profile。

- language

用于兼容 MySQL 客户端。无实际作用。

- license

显示 Doris 的 License。无其他作用。

- lower\_case\_table\_names

用于控制用户表表名大小写是否敏感。

值为 0 时，表名大小写敏感。默认为 0。

值为 1 时，表名大小写不敏感，doris 在存储和查询时会将表名转换为小写。优点是在一条语句中可以使用表名的任意大小写形式，下面的 sql 是正确的：

```
mysql> show tables;
+-----+
| Tables_in_testdb |
+-----+
| cost |
+-----+

mysql> select * from COST where C0st.id < 100 order by cost.id;
```

缺点是建表后无法获得建表语句中指定的表名，show tables 查看的表名为指定表名的小写。

值为 2 时，表名大小写不敏感，doris 存储建表语句中指定的表名，查询时转换为小写进行比较。优点是 show tables 查看的表名为建表语句中指定的表名；缺点是同一语句中只能使用表名的一种大小写形式，例如对 cost 表使用表名 COST 进行查询：

```
mysql> select * from COST where COST.id < 100 order by COST.id;
```

该变量兼容 MySQL。需在集群初始化时通过 fe.conf 指定 lower\_case\_table\_names=进行配置，集群初始化完成后无法通过 set 语句修改该变量，也无法通过重启、升级集群修改该变量。

information\_schema 中的系统视图表名不区分大小写，当 lower\_case\_table\_names 值为 0 时，表现为 2。

- max\_allowed\_packet

用于兼容 JDBC 连接池 C3P0。对 Doris 本身无实际作用。如遇到 Packet for query is too large (1,514,085 > 1,048,576)。You can change this value on the server by setting the

'max\_allowed\_packet' variable. 错误, 可使用 `set GLOBAL max_allowed_packet = 1548576` 调大。

- max\_pushdown\_conditions\_per\_column

该变量的具体含义请参阅 [BE 配置项](#) 中 max\_pushdown\_conditions\_per\_column 的说明。该变量默认置为 -1, 表示使用 be.conf 中的配置值。如果设置大于 0, 则当前会话中的查询会使用该变量值, 而忽略 be.conf 中的配置值。

- max\_scan\_key\_num

该变量的具体含义请参阅 [BE 配置项](#) 中 doris\_max\_scan\_key\_num 的说明。该变量默认置为 -1, 表示使用 be.conf 中的配置值。如果设置大于 0, 则当前会话中的查询会使用该变量值, 而忽略 be.conf 中的配置值。

- net\_buffer\_length

用于兼容 MySQL 客户端。无实际作用。

- net\_read\_timeout

用于兼容 MySQL 客户端。无实际作用。

- net\_write\_timeout

用于兼容 MySQL 客户端。无实际作用。

- parallel\_exchange\_instance\_num

用于设置执行计划中, 一个上层节点接收下层节点数据所使用的 exchange node 数量。默认为 -1, 即表示 exchange node 数量等于下层节点执行实例的个数 (默认行为)。当设置大于 0, 并且小于下层节点执行实例的个数, 则 exchange node 数量等于设置值。

在一个分布式的查询执行计划中, 上层节点通常有一个或多个 exchange node 用于接收来自下层节点在不同 BE 上的执行实例的数据。通常 exchange node 数量等于下层节点执行实例数量。

在一些聚合查询场景下, 如果底层需要扫描的数据量较大, 但聚合之后的数据量很小, 则可以尝试修改此变量为一个较小的值, 可以降低此类查询的资源开销。如在 DUPLICATE KEY 明细模型上进行聚合查询的场景。

- parallel\_fragment\_exec\_instance\_num

针对扫描节点, 设置其在每个 BE 节点上, 执行实例的个数。默认为 1。

一个查询计划通常会产一组 scan range, 即需要扫描的数据范围。这些数据分布在多个 BE 节点上。一个 BE 节点会有一个或多个 scan range。默认情况下, 每个 BE 节点的一组 scan range 只由一个执行实例处理。当机器资源比较充裕时, 可以将增加该变量, 让更多的执行实例同时处理一组 scan range, 从而提升查询效率。

而 scan 实例的数量决定了上层其他执行节点, 如聚合节点, join 节点的数量。因此相当于增加了整个查询计划执行的并发度。修改该参数会对大查询效率提升有帮助, 但较大数值会消耗更多的机器资源, 如 CPU、内存、磁盘 IO。

- query\_cache\_size

用于兼容 MySQL 客户端。无实际作用。

- `query_cache_type`

用于兼容 JDBC 连接池 C3P0。无实际作用。

- `query_timeout`

用于设置查询超时。该变量会作用于当前连接中所有的查询语句，对于 INSERT 语句推荐使用 `insert_timeout`。默认为 15 分钟，单位为秒。

- `insert_timeout` 用于设置针对 INSERT 语句的超时。该变量仅作用于 INSERT 语句，建议在 INSERT 行为易持续较长时间的场景下设置。默认为 4 小时，单位为秒。由于旧版本用户会通过延长 `query_timeout` 来防止 INSERT 语句超时，`insert_timeout` 在 `query_timeout` 大于自身的情况下将会失效，以兼容旧版本用户的习惯。

- `resource_group`

暂不使用。

- `send_batch_parallelism`

用于设置执行 `InsertStmt` 操作时发送批处理数据的默认并行度，如果并行度的值超过 BE 配置中的 `max_send_batch_parallelism_per_job`，那么作为协调点的 BE 将使用 `max_send_batch_parallelism_per_job` 的值。

- `sql_mode`

用于指定 SQL 模式，以适应某些 SQL 方言，关于 SQL 模式，可参阅[这里](#)。

- `sql_safe_updates`

用于兼容 MySQL 客户端。无实际作用。

- `sql_select_limit`

用于设置 select 语句的默认返回行数，包括 insert 语句的 select 从句。默认不限制。

- `system_time_zone`

集群初始化时设置为当前系统时区。不可更改。

- `time_zone`

用于设置当前会话的时区。默认值为 `system_time_zone` 的值。时区会对某些时间函数的结果产生影响。关于时区，可以参阅 [时区](#) 文档。

- `tx_isolation`

用于兼容 MySQL 客户端。无实际作用。

- `tx_read_only`

用于兼容 MySQL 客户端。无实际作用。

- `transaction_read_only`  
用于兼容 MySQL 客户端。无实际作用。
- `transaction_isolation`  
用于兼容 MySQL 客户端。无实际作用。
- `version`  
用于兼容 MySQL 客户端。无实际作用。
- `performance_schema`  
用于兼容 8.0.16 及以上版本的 MySQL JDBC。无实际作用。
- `version_comment`  
用于显示 Doris 的版本。不可更改。
- `wait_timeout`  
用于设置空闲连接的连接时长。当一个空闲连接在该时长内与 Doris 没有任何交互，则 Doris 会主动断开这个链接。默认为 8 小时，单位为秒。
- `default_rowset_type`  
用于设置计算节点存储引擎默认的存储格式。当前支持的存储格式包括：alpha/beta。
- `use_v2_rollup`  
用于控制查询使用 segment v2 存储格式的 rollup 索引获取数据。该变量用于上线 segment v2 的时候，进行验证使用；其他情况，不建议使用。
- `rewrite_count_distinct_to_bitmap_hll`  
是否将 bitmap 和 hll 类型的 count distinct 查询重写为 bitmap\_union\_count 和 hll\_union\_agg。
- `prefer_join_method`  
在选择 join 的具体实现方式是 broadcast join 还是 shuffle join 时，如果 broadcast join cost 和 shuffle join cost 相等时，优先选择哪种 join 方式。  
  
目前该变量的可选值为“broadcast”或者“shuffle”。
- `allow_partition_column_nullable`  
建表时是否允许分区列为 NULL。默认为 true，表示允许为 NULL。false 表示分区列必须被定义为 NOT NULL
- `insert_visible_timeout_ms`  
在执行 insert 语句时，导入动作 (查询和插入) 完成后，还需要等待事务提交，使数据可见。此参数控制等待数据可见的超时时间，默认为 10000，最小为 1000。
- `enable_exchange_node_parallel_merge`



在一个排序的查询之中，一个上层节点接收下层节点有序数据时，会在 exchange node 上进行对应的排序来保证最终的数据是有序的。但是单线程进行多路数据归并时，如果数据量过大，会导致 exchange node 的节点的归并瓶颈。

Doris 在这部分进行了优化处理，如果下层的数据节点过多。exchange node 会启动多线程进行并行归并来加速排序过程。该参数默认为 False，即表示 exchange node 不采取并行的归并排序，来减少额外的 CPU 和内存消耗。

- `extract_wide_range_expr`

用于控制是否开启「宽泛公因式提取」的优化。取值有两种：true 和 false。默认情况下开启。

- `enable_fold_constant_by_be`

用于控制常量折叠的计算方式。默认是 false，即在 FE 进行计算；若设置为 true，则通过 RPC 请求经 BE 计算。

- `cpu_resource_limit`

用于限制一个查询的资源开销。这是一个实验性质的功能。目前的实现是限制一个查询在单个节点上的 scan 线程数量。限制了 scan 线程数，从底层返回的数据速度变慢，从而限制了查询整体的计算资源开销。假设设置为 2，则一个查询在单节点上最多使用 2 个 scan 线程。

该参数会覆盖 `parallel_fragment_exec_instance_num` 的效果。即假设 `parallel_fragment_exec_instance_num` 设置为 4，而该参数设置为 2。则单个节点上的 4 个执行实例会共享最多 2 个扫描线程。

该参数会被 user property 中的 `cpu_resource_limit` 配置覆盖。

默认 -1，即不限制。

- `disable_join_reorder`

用于关闭所有系统自动的 join reorder 算法。取值有两种：true 和 false。默认行况下关闭，也就是采用系统自动的 join reorder 算法。设置为 true 后，系统会关闭所有自动排序的算法，采用 SQL 原始的表顺序，执行 join

- `return_object_data_as_binary` 用于标识是否在 select 结果中返回 bitmap/hll 结果。在 select into outfile 语句中，如果导出文件格式为 csv 则会将 bitmap/hll 数据进行 base64 编码，如果是 parquet 文件格式 将会把数据作为 byte array 存储。下面将展示 Java 的例子，更多的示例可查看[samples](#)。

```
try (Connection conn = DriverManager.getConnection("jdbc:mysql://127.0.0.1:9030/test?user=root");
 Statement stmt = conn.createStatement()) {
 stmt.execute("set return_object_data_as_binary=true"); // IMPORTANT!!!
 ResultSet rs = stmt.executeQuery("select uids from t_bitmap");
 while(rs.next()){
 byte[] bytes = rs.getBytes(1);
 RoaringBitmap bitmap32 = new RoaringBitmap();
 switch(bytes[0]) {
 case 0: // for empty bitmap
 break;
 case 1: // for only 1 element in bitmap32
 bitmap32.add(ByteBuffer.wrap(bytes,1,bytes.length-1)
 .order(ByteOrder.LITTLE_ENDIAN))
 }
 }
}
```

```

 .getInt());
 break;
 case 2: // for more than 1 elements in bitmap32
 bitmap32.deserialize(ByteBuffer.wrap(bytes,1,bytes.length-1));
 break;
 // for more details, see https://github.com/apache/doris/tree/master/samples/read_bitmap
}
}
}

```

- `block_encryption_mode` 可以通过该参数控制块加密模式，默认值为空。当为空时，使用 AES 算法加密相当于使用 AES\_128\_ECB, 当使用 SM4 算法加密时相当于 SM4\_128\_ECB。

可选值：

```

AES_128_ECB,
AES_192_ECB,
AES_256_ECB,
AES_128_CBC,
AES_192_CBC,
AES_256_CBC,
AES_128_CFB,
AES_192_CFB,
AES_256_CFB,
AES_128_CFB1,
AES_192_CFB1,
AES_256_CFB1,
AES_128_CFB8,
AES_192_CFB8,
AES_256_CFB8,
AES_128_CFB128,
AES_192_CFB128,
AES_256_CFB128,
AES_128_CTR,
AES_192_CTR,
AES_256_CTR,
AES_128_OFB,
AES_192_OFB,
AES_256_OFB,
SM4_128_ECB,
SM4_128_CBC,
SM4_128_CFB128,
SM4_128_OFB,
SM4_128_CTR,

```

- `enable_infer_predicate`

用于控制是否进行谓词推导。取值有两种：`true` 和 `false`。默认情况下关闭，系统不在进行谓词推导，采用原始的谓词进行相关操作。设置为 `true` 后，进行谓词扩展。

- `trim_tailing_spaces_for_external_table_query`

用于控制查询 Hive 外表时是否过滤掉字段末尾的空格。默认为 `false`。

- `skip_storage_engine_merge`

用于调试目的。在向量化执行引擎中，当发现读取 Aggregate Key 模型或者 Unique Key 模型的数据结果有问题的时候，把此变量的值设置为 `true`，将会把 Aggregate Key 模型或者 Unique Key 模型的数据当成 Duplicate Key 模型读取。

- skip\_delete\_predicate

用于调试目的。在向量化执行引擎中，当发现读取表的数据结果有误的时候，把此变量的值设置为true，将会把被删除的数据当成正常数据读取。

- skip\_delete\_bitmap

用于调试目的。在 Unique Key MoW 表中，当发现读取表的数据结果有误的时候，把此变量的值设置为true，将会把被 delete bitmap 标记删除的数据当成正常数据读取。

- skip\_missing\_version

有些极端场景下，表的 Tablet 下的所有的所有副本都有版本缺失，使得这些 Tablet 没有办法被恢复，导致整张表都不能查询。这个变量可以用来控制查询的行为，打设置为true时，查询会忽略 FE partition 中记录的 visibleVersion，使用 replica version。如果 Be 上的 Replica 有缺失的版本，则查询会直接跳过这些缺失的版本，只返回仍存在版本的数据。此外，查询将会总是选择所有存活的 BE 中所有 Replica 里 lastSuccessVersion 最大的那一个，这样可以尽可能的恢复更多的数据。这个变量应该只在上述紧急情况下才被设置为true，仅用于临时让表恢复查询。注意，此变量与 use\_fix\_replica 变量冲突，当 use\_fix\_replica 变量不等于 -1 时，此变量会不起作用

- default\_password\_lifetime

默认密码过期时间。默认值为 0，即表示不过期。单位为天。该参数只有当用户的密码过期属性为 DEFAULT 值时，才启用。如：

```
CREATE USER user1 IDENTIFIED BY "12345" PASSWORD_EXPIRE DEFAULT;
ALTER USER user1 PASSWORD_EXPIRE DEFAULT;
```

- password\_history

默认的历史密码次数。默认值为 0，即不做限制。该参数只有当用户的历史密码次数属性为 DEFAULT 值时，才启用。如：

```
CREATE USER user1 IDENTIFIED BY "12345" PASSWORD_HISTORY DEFAULT;
ALTER USER user1 PASSWORD_HISTORY DEFAULT;
```

- validate\_password\_policy

密码强度校验策略。默认为 NONE 或 0，即不做校验。可以设置为 STRONG 或 2。当设置为 STRONG 或 2 时，通过 ALTER USER 或 SET PASSWORD 命令设置密码时，密码必须包含“大写字母”，“小写字母”，“数字”和“特殊字符”中的3项，并且长度必须大于等于8。特殊字符包括：~!@#\$%^&\*()\_+|<>,.?/:;'[]{}"。

- group\_concat\_max\_len

为了兼容某些 BI 工具能正确获取和设置该变量，变量值实际并没有作用。

- rewrite\_or\_to\_in\_predicate\_threshold

默认改写 OR to IN 的 OR 数量阈值。默认值为 2，即表示有 2 个 OR 的时候，如果可以合并，则会改写成 IN。

- group\_by\_and\_having\_use\_alias\_first

指定 group by 和 having 语句是否优先使用列的别名，而非从 From 语句里寻找列的名字。默认为 false。

- enable\_file\_cache

控制是否启用 block file cache，默认 false。该变量只有在 be.conf 中 enable\_file\_cache=true 时才有效，如果 be.conf 中 enable\_file\_cache=false，该 BE 节点的 block file cache 处于禁用状态。

- file\_cache\_base\_path

指定 block file cache 在 BE 上的存储路径，默认 'random'，随机选择 BE 配置的存储路径。

- enable\_inverted\_index\_query

控制是否启用 inverted index query，默认 true。

- topn\_opt\_limit\_threshold

设置 topn 优化的 limit 阈值 (例如: SELECT \* FROM t ORDER BY k LIMIT n). 如果 limit 的 n 小于等于阈值，topn 相关优化（动态过滤下推、两阶段获取结果、按 key 的顺序读数据）会自动启用，否则会禁用。默认值是 1024。

- drop\_table\_if\_ctas\_failed

控制 create table as select 在写入发生错误时是否删除已创建的表，默认为 true。

- show\_user\_default\_role

控制是否在 show roles 的结果里显示每个用户隐式对应的角色。默认为 false。

- use\_fix\_replica

使用固定 replica 进行查询。replica 从 0 开始，如果 use\_fix\_replica 为 0，则使用最小的，如果 use\_fix\_replica 为 1，则使用第二个最小的，依此类推。默认值为 -1，表示未启用。

- dry\_run\_query

如果设置为 true，对于查询请求，将不再返回实际结果集，而仅返回行数。对于导入和 insert，Sink 丢掉了数据，不会有实际的写发生。默认值为 false。

该参数可以用于测试返回大量数据集时，规避结果集传输的耗时，重点关注底层查询执行的耗时。

```
mysql> select * from bigtable;
+-----+
| ReturnedRows |
+-----+
| 10000000 |
+-----+
```

- enable\_parquet\_lazy\_materialization

控制 parquet reader 是否启用延迟物化技术。默认为 true。

- enable\_orc\_lazy\_materialization

控制 orc reader 是否启用延迟物化技术。默认为 true。

- `enable_strong_consistency_read`

用以开启强一致读。Doris 默认支持同一个会话内的强一致性，即同一个会话内对数据的变更操作是实时可见的。如需要会话间的强一致读，则需将此变量设置为 `true`。

- `truncate_char_or_varchar_columns`

是否按照表的 schema 来截断 char 或者 varchar 列。默认为 `false`。

因为外表会存在表的 schema 中 char 或者 varchar 列的最大长度和底层 parquet 或者 orc 文件中的 schema 不一致的情况。此时开启该选项，会按照表的 schema 中的最大长度进行截断。

- `jdbc_clickhouse_query_final`

是否在使用 JDBC Catalog 功能查询 ClickHouse 时增加 `final` 关键字，默认为 `false`

用于 ClickHouse 的 ReplacingMergeTree 表引擎查询去重

- `enable_unique_key_partial_update`

:::info 备注 该参数自 2.0.2 版本起支持。 :::

是否在对 `insert into` 语句启用部分列更新的语义，默认为 `false`。需要注意的是，控制 `insert` 语句是否开启严格模式的会话变量 `enable_insert_strict` 的默认值为 `true`，即 `insert` 语句默认开启严格模式，而在严格模式下进行部分列更新不允许更新不存在的 `key`。所以，在使用 `insert` 语句进行部分列更新的时候如果希望能插入不存在的 `key`，需要在 `enable_unique_key_partial_update` 设置为 `true` 的基础上同时将 `enable_insert_strict` 设置为 `false`。

- `enable_cooldown_replica_affinity`

用户可以选择是否首先使用冷却副本进行扫描,默认为`true`

---

## 关于语句执行超时控制的补充说明

- 控制手段

目前 `doris` 支持通过 `variable` 和 `user property` 两种体系来进行超时控制。其中均包含 `query_timeout` 和 `insert_timeout`。

- 优先次序

超时生效的优先级次序是：`session variable` > `user property` > `global variable` > `default value`

较高优先级的变量未设置时，会自动采用下一个优先级的数值。

- 相关语义

`query_timeout` 用于控制所有语句的超时，`insert_timeout` 特定用于控制 `INSERT` 语句的超时，在执行 `INSERT` 语句时，超时时间会取

`query_timeout` 和 `insert_timeout` 中的最大值。

`user property`中的`query_timeout`和`insert_timeout`只能由 `ADMIN` 用户对目标用户予以指定，其语义在于改变被指定用户的默认超时时间，

并且不具备`quota`语义。

- 注意事项

`user property`设置的超时时间需要客户端重连后触发。

# SQL Mode

Doris 新支持的 SQL Mode 参照了 Mysql 的 SQL Mode 管理机制，每个客户端都能设置自己的 SQL Mode，拥有 Admin 权限的数据库管理员可以设置全局 SQL Mode。

## SQL Mode 介绍

SQL Mode 使用户能在不同风格的 sql 语法和数据校验严格度间做切换，使 Doris 对其他数据库有更好的兼容性。例如在一些数据库里，'||' 符号是一个字符串连接符，但在 Doris 里却是与 'or' 等价的，这时用户只需要使用 SQL Mode 切换到自己想要的风格。每个客户端都能设置 SQL Mode，并在当前对话中有效，只有拥有 Admin 权限的用户可以设置全局 SQL Mode。

## 原理

SQL Mode 用一个 64 位的 Long 型存储在 SessionVariables 中，这个地址的每一位都代表一个 mode 的开启/禁用 (1 表示开启，0 表示禁用) 状态，只要知道每一种 mode 具体是在哪一位，我们就可以通过位运算方便快速的对 SQL Mode 进行校验和操作。

每一次对 SQL Mode 的查询，都会对此 Long 型进行一次解析，变成用户可读的字符串形式，同理，用户发送给服务器的 SQL Mode 字符串，会被解析成能够存储在 SessionVariables 中的 Long 型。

已被设置好的全局 SQL Mode 会被持久化，因此对全局 SQL Mode 的操作总是只需一次，即使程序重启后仍可以恢复上一次的全局 SQL Mode。

## 操作方式

### 1. 设置 SQL Mode

```
set global sql_mode = "DEFAULT"
set session sql_mode = "DEFAULT"
```

- 目前 Doris 的默认 SQL Mode 是 DEFAULT（但马上会在后续修改中会改变）。

- 设置 global SQL Mode 需要 Admin 权限，并会影响所有在此后连接的客户端。
- 设置 session SQL Mode 只会影响当前对话客户端，默认为 session 方式。

### 2. 查询 SQL Mode

```
select @@global.sql_mode
select @@session.sql_mode
```

除了这种方式，你还可以通过下面方式返回所有 **session variables** 来查看当前 **sql mode**

```
show global variables
show session variables
```

## 已支持 **mode**

### 1. PIPES\_AS\_CONCAT

在此模式下, '||' 符号是一种字符串连接符号 (同 `CONCAT()` 函数), 而不是 'OR' 符号的同义词。 (e.g.,  
'a' || 'b' = 'ab', `1 || 0` = '10')

## 复合 **mode**

(后续补充)



# 全新优化器介绍

## 研发背景

现代查询优化器面临更加复杂的查询语句、更加多样的查询场景等挑战。同时，用户也越来越迫切的希望尽快获得查询结果。旧优化器的陈旧架构，难以满足今后快速迭代的需要。基于此，我们开始着手研发现代架构的全新查询优化器。在更高效的处理当前 Doris 场景的查询请求的同时，提供更好的扩展性，为处理今后 Doris 所需面临的更复杂的需求打下良好的基础。


## 新优化器的优势

### 更智能

新优化器将每个 RBO 和 CBO 的优化点以规则的形式呈现。对于每一个规则，新优化器都提供了一组用于描述查询计划形状的模式，可以精确的匹配可优化的查询计划。基于此，新优化器可以更好的支持诸如多层子查询嵌套等更为复杂的查询语句。

同时新优化器的 CBO 基于先进的 Cascades 框架，使用了更为丰富的数据统计信息，并应用了维度更科学的代价模型。这使得新优化器在面对多表 Join 的查询时，更加得心应手。

TPC-H SF100 查询速度比较。环境为 3BE，新优化器使用原始 SQL，执行 SQL 前收集了统计信息。旧优化器使用手工调优 SQL。可以看到，新优化器在无需手工优化查询的情况下，总体查询时间与旧优化器手工优化后的查询时间相近。



execution time comparison

### 更健壮

新优化器的所有优化规则，均在逻辑执行计划树上完成。当查询语法语义解析完成后，变转换为一棵树状结构。相比于旧优化器的内部数据结构更为合理、统一。以子查询处理为例，新优化器基于新的数据结构，避免了旧优化器中众多规则对子查询的单独处理。进而减少了优化规则出现逻辑错误的可能。

## 更灵活

新优化器的架构设计更合理，更现代。可以方便地扩展优化规则和处理阶段。能够更为迅速的响应用户的需求。

## 使用方法

开启新优化器

```
SET enable_nereids_planner=true;
```

开启自动回退到旧优化器

```
SET enable_fallback_to_original_planner=true;
```

为了能够充分利用新优化器的 CBO 能力，强烈建议对关注性能查询所以来的表，执行 `analyze` 语句，以收集列统计信息

## 已知问题和暂不支持的功能

### 暂不支持的功能

如果开启了自动回退，则会自动回退到旧优化器执行

- Json、Array、Map、Struct 类型：查询的表含有以上类型，或者查询中的函数会输出以上类型
- DML：仅支持如下 DML：Insert Into Select, Update, Delete
- 带过滤条件的物化视图
- 别名函数
- Java UDF 和 HDFS UDF
- 高并发点查询优化

### 已知问题

- 不支持命中 Partition Cache

# 统计信息

通过收集统计信息有助于优化器了解数据分布特性，在进行 CBO（基于成本优化）时优化器会利用这些统计信息来计算谓词的选择性，并估算每个执行计划的成本。从而选择更优的计划以大幅提升查询效率。

当前收集列的如下信息：

信息	描述
row_count	总行数
data_size	总数据量
avg_size_byte	值的平均长度
ndv	不同值数量
min	最小值
max	最大值
null_count	空值数量

## 1. 收集统计信息

### 1.1 使用 ANALYZE 语句手动收集

Doris 支持用户通过提交 ANALYZE 语句来手动触发统计信息的收集和更新。

语法：

```
ANALYZE < TABLE | DATABASE table_name | db_name >
 [(column_name [, ...])]
 [[WITH SYNC] [WITH SAMPLE PERCENT | ROWS]];
```

其中：

- table\_name: 指定的目标表。可以是 db\_name.table\_name 形式。
- column\_name: 指定的目标列。必须是 table\_name 中存在的列，多个列名称用逗号分隔。
- sync: 同步收集统计信息。收集完后返回。若不指定则异步执行并返回 JOB ID。
- sample percent | rows: 抽样收集统计信息。可以指定抽样比例或者抽样行数。

默认情况下（不指定 WITH SAMPLE），会对一张表全量采样。对于比较大的表（5GiB 以上），从集群资源的角度出发，一般情况下我们建议采样收集，采样的行数建议不低于 400 万行。下面是一些例子

对一张表全量收集统计信息：

```
ANALYZE TABLE lineitem;
```

对一张表按照 10% 的比例采样收集统计数据：

```
ANALYZE TABLE lineitem WITH SAMPLE PERCENT 10;
```

对一张表按采样 10 万行收集统计数据

```
ANALYZE TABLE lineitem WITH SAMPLE ROWS 100000;
```

## 1.2 自动收集

此功能从 2.0.3 开始正式支持，默认为全天开启状态。下面对其基本运行逻辑进行阐述，在每次导入事务提交后，Doris 将记录本次导入事务更新的表行数用以估算当前已有表的统计数据的健康度（对于没有收集过统计数据的表，其健康度为 0）。当表的健康度低于 60（可通过参数 `table_stats_health_threshold` 调节）时，Doris 会认为该表的统计信息已经过时，并在之后触发对该表的统计信息收集作业。而对于统计信息健康度高于 60 的表，则不会重复进行收集。

统计信息的收集作业本身需要占用一定的系统资源，为了尽可能降低开销，Doris 会使用采样的方式去收集，自动采样默认采样  $4194304(2^{22})$  行，以尽可能降低对系统造成的负担并尽快完成收集作业。如果希望采样更多的行以获得更准确的数据分布信息，可通过调整参数 `huge_table_default_sample_rows` 增大采样行数。用户还可以通过参数控制小表全量收集，大表收集时间间隔等行为。详细配置请参考详[3.1](#)。

如果担心自动收集作业对业务造成干扰，可结合自身需求通过设置参数 `auto_analyze_start_time` 和参数 `auto_analyze_end_time` 指定自动收集作业在业务负载较低的时间段执行。也可以通过设置参数 `enable_auto_analyze` 为 `false` 来彻底关闭本功能。

External catalog 默认不参与自动收集。因为 external catalog 往往包含海量历史数据，如果参与自动收集，可能占用过多资源。可以通过设置 catalog 的 property 来打开和关闭 external catalog 的自动收集。

```
ALTER CATALOG external_catalog SET PROPERTIES ('enable.auto.analyze'='true'); // 打开自动收集
ALTER CATALOG external_catalog SET PROPERTIES ('enable.auto.analyze'='false'); // 关闭自动收集
```

## 2. 作业管理

### 2.1 查看统计作业

通过 SHOW ANALYZE 来查看统计信息收集作业的信息。

语法如下：

```
SHOW [AUTO] ANALYZE < table_name | job_id >
[WHERE [STATE = ["PENDING" | "RUNNING" | "FINISHED" | "FAILED"]]];
```

- **AUTO**：仅仅展示自动收集历史作业信息。需要注意的是默认只保存过去 20000 个执行完毕的自动收集作业的状态。
- **table\_name**：表名，指定后可查看该表对应的统计作业信息。可以是 `db_name.table_name` 形式。不指定时返回所有统计作业信息。

- `job_id`: 统计信息作业 ID，执行 `ANALYZE` 异步收集时得到。不指定 `id` 时此命令返回所有统计作业信息。

输出：

列名	说明
<code>job_id</code>	统计作业 ID
<code>catalog_name</code>	catalog 名称
<code>db_name</code>	数据库名称
<code>tbl_name</code>	表名称
<code>col_name</code>	列名称列表
<code>job_type</code>	作业类型
<code>analysis_type</code>	统计类型
<code>message</code>	作业信息
<code>last_exec_time_in_ms</code>	上次执行时间
<code>state</code>	作业状态
<code>schedule_type</code>	调度方式

下面是一个例子：

```
mysql> show analyze 245073\G;
***** 1. row *****
 job_id: 245073
 catalog_name: internal
 db_name: default_cluster:tpch
 tbl_name: lineitem
 col_name:
[l_returnflag,l_receiptdate,l_tax,l_shipmode,l_suppkey,l_shipdate,l_commitdate,l_partkey,l_orderkey,l_quantity,
l_linestatus,l_comment,l_extendedprice,l_linenum, l_discount,l_shipinstruct]
 job_type: MANUAL
 analysis_type: FUNDAMENTALS
 message:
last_exec_time_in_ms: 2023-11-07 11:00:52
 state: FINISHED
 progress: 16 Finished | 0 Failed | 0 In Progress | 16 Total
 schedule_type: ONCE
```

## 2.2 查看每列统计信息收集情况

每个收集作业中可以包含一到多个任务，每个任务对应一列的收集。用户可通过如下命令查看具体每列的统计信息收集完成情况。

语法：

```
SHOW ANALYZE TASK STATUS [job_id]
```

下面是一个例子：

```
mysql> show analyze task status 20038 ;
```

task_id	col_name	message	last_exec_time_in_ms	state
20039	col4		2023-06-01 17:22:15	FINISHED
20040	col2		2023-06-01 17:22:15	FINISHED
20041	col3		2023-06-01 17:22:15	FINISHED
20042	col1		2023-06-01 17:22:15	FINISHED

## 2.3 查看列统计信息

通过 SHOW COLUMN STATS 来查看列的各项统计数据。

语法如下：

```
SHOW COLUMN [cached] STATS table_name [(column_name [, ...])];
```

其中：

- cached: 展示当前 FE 内存缓存中的统计信息。
- table\_name: 收集统计信息的目标表。可以是 db\_name.table\_name 形式。
- column\_name: 指定的目标列，必须是 table\_name 中存在的列，多个列名称用逗号分隔。

下面是一个例子：

```
mysql> show column stats lineitem(l_tax)\G;
***** 1. row *****
column_name: l_tax
 count: 6001215.0
 ndv: 9.0
 num_null: 0.0
data_size: 4.800972E7
avg_size_byte: 8.0
 min: 0.00
 max: 0.08
 method: FULL
 type: FUNDAMENTALS
 trigger: MANUAL
query_times: 0
updated_time: 2023-11-07 11:00:46
```

## 2.4 表收集概况

通过 SHOW TABLE STATS 查看表的统计信息收集概况。

语法如下：

```
SHOW TABLE STATS table_name;
```

其中：

- `table_name`: 目标表表名。可以是 `db_name.table_name` 形式。

输出：

列名	说明
<code>updated_rows</code>	自上次 ANALYZE 以来该表的更新行数
<code>query_times</code>	保留列，后续版本用以记录该表查询次数
<code>row_count</code>	行数（不反映命令执行时的准确行数）
<code>updated_time</code>	上次更新时间
<code>columns</code>	收集过统计信息的列
<code>trigger</code>	触发方式

下面是一个例子：

```
mysql> show table stats lineitem \G;
***** 1. row *****
updated_rows: 0
query_times: 0
row_count: 6001215
updated_time: 2023-11-07
columns: [l_returnflag, l_receiptdate, l_tax, l_shipmode, l_suppkey, l_shipdate, l_commitdate,
l_partkey, l_orderkey, l_quantity, l_linestatus, l_comment, l_extendedprice, l_linenum, l_discount,
l_shipinstruct]
trigger: MANUAL
```

2.5 终止统计作业

通过 `KILL ANALYZE` 来终止正在运行的统计作业。

语法如下：

```
KILL ANALYZE job_id;
```

其中：

- `job_id`: 统计信息作业 ID。执行 ANALYZE 异步收集统计信息时所返回的值，也可以通过 `SHOW ANALYZE` 语句获取。

示例：

- 终止 ID 为 52357 的统计作业。

```
mysql> KILL ANALYZE 52357;
```

### 3. 会话变量及配置项

#### 3.1 会话变量

会话变量	说明	默认值
auto_analyze_start_time	自动统计信息收集开始时间	00:00:00
auto_analyze_end_time	自动统计信息收集结束时间	23:59:59
enable_auto_analyze	开启自动收集功能	true
huge_table_default_sample_rows	对大表的采样行数	4194304
huge_table_lower_bound_size_in_bytes	大小超过该值的表，在自动收集时将会自动通过采样收集统计信息	0
huge_table_auto_analyze_interval_in_millis	控制对大表的自动 ANALYZE 的最小时间间隔，在该时间间隔内大小超过 huge_table_lower_bound_size_in_bytes * 5 的表仅 ANALYZE 一次	0
table_stats_health_threshold	取值在 0-100 之间，当自上次统计信息收集操作之后，数据更新量达到 (100 - table_stats_health_threshold)%，认为该表的统计信息已过时	60
analyze_timeout	控制 ANALYZE 超时时间，单位为秒	43200
auto_analyze_table_width_threshold	控制自动统计信息收集处理的最大表宽度，列数大于该值的表不会参与自动统计信息收集	100

#### 3.2 FE 配置项

下面的 FE 配置项通常情况下，无需关注

FE 配置项	说明	默认值
analyze_record_limit	控制统计信息作业执行记录的持久化行数	20000
stats_cache_size	FE 侧统计信息缓存条数	500000
statistics_simultaneously_running_task_num	可同时执行的异步作业数量	3
statistics_sql_mem_limit_in_bytes	控制每个统计信息 SQL 可占用的 BE 内存	2L * 1024 * 1024 * 1024 (2GiB)

### 4. 常见问题

#### 4.1 ANALYZE 提交报错：Stats table not available...

执行 ANALYZE 时统计数据会被写入到内部表\_\_internal\_schema.column\_statistics中，FE 会在执行 ANALYZE 前检查该表 tablet 状态，如果存在不可用的 tablet 则拒绝执行作业。出现该报错请检查 BE 集群状态。



用户可通过SHOW BACKENDS\G，确定 BE 状态是否正常。如果 BE 状态正常，可使用命令ADMIN SHOW REPLICA STATUS FROM \_\_internal\_schema.[tbl\_in\_this\_db]，检查该库下 tablet 状态，确保 tablet 状态正常。

## 4.2 大表 ANALYZE 失败

由于 ANALYZE 能够使用的资源受到比较严格的限制，对一些大表的 ANALYZE 操作有可能超时或者超出 BE 内存限制。这些情况下，建议使用 ANALYZE ... WITH SAMPLE...

# Pipeline 执行引擎

Pipeline 执行引擎 是 Doris 在 2.0 版本加入的实验性功能。目标是为了替换当前 Doris 的火山模型的执行引擎，充分释放多核 CPU 的计算能力，并对 Doris 的查询线程的数目进行限制，解决 Doris 的执行线程膨胀的问题。

它的具体设计、实现和效果可以参阅 [DSIP-027](#)。

## 原理

当前的 Doris 的 SQL 执行引擎是基于传统的火山模型进行设计，在单机多核的场景下存在下面的一些问题：

- 无法充分利用多核计算能力，提升查询性能，多数场景下进行性能调优时需要手动设置并行度，在生产环境中几乎很难进行设定。
- 单机查询的每个 Instance 对应线程池的一个线程，这会带来额外的两个问题。
  - 线程池一旦打满。**Doris 的查询引擎会进入假性死锁**，对后续的查询无法响应。同时有一定概率进入**逻辑死锁**的情况：比如所有的线程都在执行一个 Instance 的 Probe 任务。
  - 阻塞的算子会占用线程资源，而阻塞的线程资源无法让渡给能够调度的 Instance，整体资源利用率上不去。
- 阻塞算子依赖操作系统的线程调度机制，线程切换开销较大（尤其在系统混布的场景中）

由此带来的一系列问题驱动 Doris 需要实现适应现代多核 CPU 的体系结构的执行引擎。

而如下图所示（引用自[Push versus pull-based loop fusion in query engines](#)），Pipeline 执行引擎基于多核 CPU 的特点，重新设计由数据驱动的执行引擎：




image.png

- 将传统 Pull 拉取的逻辑驱动的执行流程改造为 Push 模型的数据驱动的执行引擎
- 阻塞操作异步化，减少了线程切换，线程阻塞导致的执行开销，对于 CPU 的利用更为高效

3. 控制了执行线程的数目，通过时间片的切换的控制，在混合负载的场景中，减少大查询对于小查询的资源挤占问题

从而提高了 CPU 在混合负载 SQL 上执行时的效率，提升了 SQL 查询的性能。

## 使用方式

### 查询

#### 1. enable\_pipeline\_engine

将 session 变量 enable\_pipeline\_engine 设置为 true，则 BE 在进行查询执行时将会使用 Pipeline 执行引擎。

```
set enable_pipeline_engine = true;
```

#### 2. parallel\_pipeline\_task\_num

parallel\_pipeline\_task\_num 代表了 SQL 查询进行查询并发的 Pipeline Task 数目。Doris 默认的配置为 0，此时 Pipeline Task 数目将自动设置为当前集群机器中最少的 CPU 数量的一半。用户也可以根据自己的实际情况进行调整。

```
set parallel_pipeline_task_num = 0;
```

可以通过设置 max\_instance\_num 来限制自动设置的并发数 (默认为 64)

### 导入

导入的引擎选择设置，详见[导入](#)文档。

# 缓存概览

---

## 需求场景

大部分数据分析场景是写少读多，数据写入一次，多次频繁读取，比如一张报表涉及的维度和指标，数据在凌晨一次性计算好，但每天有数百甚至数千次的页面访问，因此非常适合把结果集缓存起来。在数据分析或 BI 应用中，存在下面的业务场景：

- **高并发场景**，Doris 可以较好的支持高并发，但单台服务器无法承载太高的 QPS
- **复杂图表的看板**，复杂的 Dashboard 或者大屏类应用，数据来自多张表，每个页面有数十个查询，虽然每个查询只有数十毫秒，但是总体查询时间会在数秒
- **趋势分析**，给定日期范围的查询，指标按日显示，比如查询最近 7 天内的用户数的趋势，这类查询数据量大，查询范围广，查询时间往往需要数十秒
- **用户重复查询**，如果产品没有防重刷机制，用户因手误或其他原因重复刷新页面，导致提交大量的重复的 SQL

以上四种场景，在应用层的解决方案，把查询结果放到 Redis 中，周期性的更新缓存或者用户手工刷新缓存，但是这个方案有如下问题：

- **数据不一致**，无法感知数据的更新，导致用户经常看到旧的数据
- **命中率低**，缓存整个查询结果，如果数据实时写入，缓存频繁失效，命中率低且系统负载较重
- **额外成本**，引入外部缓存组件，会带来系统复杂度，增加额外成本

## 解决方案

本分区缓存策略可以解决上面的问题，优先保证数据一致性，在此基础上细化缓存粒度，提升命中率，因此有如下特点：

- 用户无需担心数据一致性，通过版本来控制缓存失效，缓存的数据和从 BE 中查询的数据是一致的
- 没有额外的组件和成本，缓存结果存储在 BE 的内存中，用户可以根据需要调整缓存内存大小
- 实现了两种缓存策略，SQLCache 和 PartitionCache，后者缓存粒度更细
- 用一致性哈希解决 BE 节点上下线的问题，BE 中的缓存算法是改进的 LRU

## 使用场景

当前支持 SQL Cache 和 Partition Cache 两种方式，支持 OlapTable 内表 和 Hive 外表。

SQL Cache: 只有 SQL 语句完全一致才会命中缓存，详情见：[sql-cache-manual.md](#)

Partition Cache: 多个 SQL 使用相同的表分区即可命中缓存，所以相比 SQL Cache 有更高的命中率，详情见：[partition-cache-manual.md](#)

## 监控

FE 的监控项：

```
query_table //Query 中有表的数量
query_olap_table //Query 中有 Olap 表的数量
cache_mode_sql //识别缓存模式为 sql 的 Query 数量
cache_hit_sql //模式为 sql 的 Query 命中 Cache 的数量
query_mode_partition //识别缓存模式为 Partition 的 Query 数量
cache_hit_partition //通过 Partition 命中的 Query 数量
partition_all //Query 中扫描的所有分区
partition_hit //通过 Cache 命中的分区数量

Cache 命中率 = (cache_hit_sql + cache_hit_partition) / query_olap_table
Partition 命中率 = partition_hit / partition_all
```

BE 的监控项：

```
query_cache_memory_total_byte //Cache 内存大小
query_query_cache_sql_total_count //Cache 的 SQL 的数量
query_cache_partition_total_count //Cache 分区数量

SQL 平均数据大小 = cache_memory_total / cache_sql_total
Partition 平均数据大小 = cache_memory_total / cache_partition_total
```

其他监控：可以从 Grafana 中查看 BE 节点的 CPU 和内存指标，Query 统计中的 Query Percentile 等指标，配合 Cache 参数的调整来达成业务目标。

## 相关参数

### 1. cache\_result\_max\_row\_count

查询结果集放入缓存的最大行数，默认 3000。

```
vim fe/conf/fe.conf
cache_result_max_row_count=3000
```

### 2. cache\_result\_max\_data\_size

查询结果集放入缓存的最大数据大小，默认 30M，可以根据实际情况调整，但建议不要设置过大，避免过多占用内存，超过这个大小的结果集不会被缓存。

```
vim fe/conf/fe.conf
cache_result_max_data_size=31457280
```

### 3. cache\_last\_version\_interval\_second

缓存的查询分区最新版本离现在的最小时间间隔，只有大于这个间隔没有被更新的分区的查询结果才会被缓存，默认 30，单位秒。

```
vim fe/conf/fe.conf
cache_last_version_interval_second=30
```

#### 4. query\_cache\_max\_size\_mb 和 query\_cache\_elasticity\_size

query\_cache\_max\_size\_mb 缓存的内存上限，query\_cache\_elasticity\_size 缓存可拉伸的内存大小，BE 上的缓存总大小超过 query\_cache\_max\_size + cache\_elasticity\_size 后会开始清理，并把内存控制到 query\_cache\_max\_size 以下。

可以根据 BE 节点数量，节点内存大小，和缓存命中率来设置这两个参数。计算方法：假如缓存 10000 个 Query，每个 Query 缓存 1000 行，每行是 128 个字节，分布在 10 台 BE 上，则每个 BE 需要约 128M 内存 ( $10000 * 1000 * 128 / 10$ )。

```
vim be/conf/be.conf
query_cache_max_size_mb=256
query_cache_elasticity_size_mb=128
```

#### 5. cache\_max\_partition\_count

Partition Cache 独有的参数。BE 最大分区数量，指每个 SQL 对应的最大分区数，如果是按日期分区，能缓存 2 年多的数据，假如想保留更长时间的缓存，请把这个参数设置得更大，同时修改参数 cache\_result\_max\_row\_count 和 cache\_result\_max\_data\_size。

```
vim be/conf/be.conf
cache_max_partition_count=1024
```

# SQL Cache

SQL 语句完全一致时将命中缓存。

## 需求场景 & 解决方案

见 [缓存概览](#) 文档。

## 设计原理

SQLCache 按 SQL 的签名、查询的表的分区 ID、分区最新版本来存储和获取缓存。三者组合确定一个缓存数据集，任何一个变化了，如 SQL 有变化，如查询字段或条件不一样，或数据更新后版本变化了，会导致命中不了缓存。

如果多张表 Join，使用最近更新的分区 ID 和最新的版本号，如果其中一张表更新了，会导致分区 ID 或版本号不一样，也一样命中不了缓存。

SQLCache，更适合 T+1 更新的场景，凌晨数据更新，首次查询从 BE 中获取结果放入到缓存中，后续相同查询从缓存中获取。实时更新数据也可以使用，但是可能存在命中率低的问题。

当前支持 OlapTable 内表 和 Hive 外表。

## 使用方式

确保 fe.conf 的 cache\_enable\_sql\_mode=true（默认是 true）

```
vim fe/conf/fe.conf
cache_enable_sql_mode=true
```

在 MySQL 命令行中设置变量

```
MySQL [(none)]> set [global] enable_sql_cache=true;
```

注：global 是全局变量，不加指当前会话变量

## 缓存条件

第一次查询后，如果满足下面三个条件，查询结果就会被缓存。

1. (当前时间 - 查询的分区最后更新时间) 大于 fe.conf 中的 cache\_last\_version\_interval\_second。
2. 查询结果行数 小于 fe.conf 中的 cache\_result\_max\_row\_count。
3. 查询结果 bytes 小于 fe.conf 中的 cache\_result\_max\_data\_size。

具体参数介绍和未尽事项见 query-cache.md。

## 未尽事项

- SQL 中包含产生随机值的函数，比如 `random()`，使用 QueryCache 会导致查询结果失去随机性，每次执行将得到相同的结果。
- 类似的 SQL，之前查询了 2 个指标，现在查询 3 个指标，是否可以利用 2 个指标的缓存？目前不支持



# Partition Cache

多个 SQL 使用相同的表分区时可命中缓存。

**Partition Cache** 是试验性功能，没有得到很好的维护，将在2.1版本中删除，请谨慎使用。

## 需求场景 & 解决方案

见 [缓存概览](#) 文档。

## 设计原理

1. SQL 可以并行拆分， $Q = Q1 \cup Q2 \dots \cup Qn$ ， $R = R1 \cup R2 \dots \cup Rn$ ，Q 为查询语句，R 为结果集
2. SQL 只使用 DATE、INT、BIGINT 类型的分区字段聚合，且只扫描一个分区，因此不支持按天分区，只支持按年、月分区。
3. 将查询结果集中部分日期的结果缓存，然后缩减 SQL 中扫描的日期范围，本质 PartitionCache 并没有减少扫描的分区数量，而且缩减扫描的日期范围，从而减少扫描数据量。

此外一些限制：

- 只支持按分区字段分组，不支持按其他字段分组，按其他字段分组，该分组数据都有可能被更新，会导致缓存都失效
- 只支持结果集的前半部分、后半部分以及全部命中缓存，不支持结果集被缓存数据分割成几个部分，且结果集的日期必须连续，如果某一天在结果集中没有数据，那只有这一天之前的日期会被缓存。
- 如果 predicate 有分区之外的列，那么必须给分区 predicate 加上括号 where  $k1 = 1$  and ( $key \geq "2023-10-18"$  and  $key \leq "2021-12-01"$ )
- 查询的天数必须大于 1，小于 `cache_result_max_row_count`，否则无法使用 partition cache。
- 分区字段的 predicate 只能是  $key \geq a$  and  $key \leq b$  或者  $key = a$  or  $key = b$  或者  $key$  in(a,b,c)。

## 使用方式

确保 fe.conf 的 `cache_enable_partition_mode=true` (默认是 true)

```
vim fe/conf/fe.conf
cache_enable_partition_mode=true
```

在 MySQL 命令行中设置变量

```
MySQL [(none)]> set [global] enable_partition_cache=true;
```

如果同时开启了两个缓存策略，下面的参数，需要注意一下：

```
cache_last_version_interval_second=30
```

如果分区的最新版本的时间离现在的间隔，大于 `cache_last_version_interval_second`，则会优先把整个查询结果缓存。如果小于这个间隔，如果符合 `PartitionCache` 的条件，则按 `PartitionCache` 数据。

具体参数介绍和未尽事项见 `query-cache.md`。

## 未尽事项

拆分为只读分区和可更新分区，只读分区缓存，更新分区不缓存

如查询最近 7 天的每天用户数，如按日期分区，数据只写当天分区，当天之外的其他分区的数据，都是固定不变的，在相同的查询 SQL 下，查询某个不更新分区的指标都是固定的。如下，在 2020-03-09 当天查询前 7 天的用户数，2020-03-03 至 2020-03-07 的数据来自缓存，2020-03-08 第一次查询来自分区，后续的查询来自缓存，2020-03-09 因为当天在不停写入，所以来自分区。

因此，查询 N 天的数据，数据更新最近的 D 天，每天只是日期范围不一样相似的查询，只需要查询 D 个分区即可，其他部分都来自缓存，可以有效降低集群负载，减少查询时间。

实现原理示例：

```
MySQL [(none)]> SELECT eventdate,count(userid) FROM testdb.appevent WHERE eventdate>="2020-03-03" AND
eventdate<="2020-03-09" GROUP BY eventdate ORDER BY eventdate;
+-----+-----+
| eventdate | count(`userid`) |
+-----+-----+
| 2020-03-03 | 15 |
| 2020-03-04 | 20 |
| 2020-03-05 | 25 |
| 2020-03-06 | 30 |
| 2020-03-07 | 35 |
| 2020-03-08 | 40 | //第一次来自分区，后续来自缓存
| 2020-03-09 | 25 | //来自分区
+-----+-----+
7 rows in set (0.02 sec)
```

在 `PartitionCache` 中，缓存第一级 Key 是去掉了分区条件后的 SQL 的 128 位 MD5 签名，下面是改写后的待签名的 SQL：

```
SELECT eventdate,count(userid) FROM testdb.appevent GROUP BY eventdate ORDER BY eventdate;
```

缓存的第二级 Key 是查询结果集的分区字段的内容，比如上面查询结果的 `eventdate` 列的内容，二级 Key 的附属信息是分区的版本号和版本更新时间。

下面演示上面 SQL 在 2020-03-09 当天第一次执行的流程：

### 1. 从缓存中获取数据

```
+-----+-----+
| 2020-03-03 | 15 |
| 2020-03-04 | 20 |
```

2020-03-05	25
2020-03-06	30
2020-03-07	35
+-----+	-----+

## 2. 从 BE 中获取数据的 SQL 和数据

```
SELECT eventdate,count(userid) FROM testdb.appevent WHERE eventdate>="2020-03-08" AND eventdate<="2020-03-09"
GROUP BY eventdate ORDER BY eventdate;
```

2020-03-08	40
+-----+	-----+
2020-03-09	25
+-----+	-----+

## 3. 最后发送给终端的数据

+-----+	-----+
eventdate	count(`userid`)
+-----+	-----+
2020-03-03	15
2020-03-04	20
2020-03-05	25
2020-03-06	30
2020-03-07	35
2020-03-08	40
2020-03-09	25
+-----+	-----+

## 4. 发送给缓存的数据

+-----+	-----+
2020-03-08	40
+-----+	-----+

Partition 缓存，适合按日期分区，部分分区实时更新，查询 SQL 较为固定。

分区字段也可以是其他字段，但是需要保证只有少量分区更新。

# 逻辑视图

视图（逻辑视图）是封装一个或多个 SELECT 语句的存储查询。视图在执行时动态访问并计算数据库数据。视图是只读的，可以引用表和其他视图的任意组合。

可以使用视图实现以下用途：

- 出于简化访问或安全访问的目的，让用户看不到复杂的 SELECT 语句。例如，可以创建仅显示用户所需的各表中数据的视图，同时隐藏这些表中的敏感数据。
- 将可能随时间而改变的表结构的详细信息封装在一致的用户界面后。

与物化视图不同，视图不实体化，也就是说，它们不在磁盘上存储数据。因此，存在以下限制：

- 当底层表数据发生变更时，Doris 不需要刷新视图数据。但是，访问和计算数据时，视图也会产生一些开销。
- 视图不支持插入、删除或更新操作。

## 创建视图

用于创建一个逻辑视图的语法如下：

```
CREATE VIEW [IF NOT EXISTS]
 [db_name.]view_name
 (column1[COMMENT "col comment"][, column2, ...])
AS query_stmt
```

说明：

- 视图为逻辑视图，没有物理存储。所有在视图上的查询相当于在视图对应的子查询上进行。
- query\_stmt 为任意支持的 SQL

## 举例

- 在 example\_db 上创建视图 example\_view

```
CREATE VIEW example_db.example_view (k1, k2, k3, v1)
AS
SELECT c1 as k1, k2, k3, SUM(v1) FROM example_table
WHERE k1 = 20160112 GROUP BY k1,k2,k3;
```

- 创建一个包含 comment 的 view

```
CREATE VIEW example_db.example_view
(
 k1 COMMENT "first key",
 k2 COMMENT "second key",
 k3 COMMENT "third key",
```

```
 v1 COMMENT "first value"
)
 COMMENT "my first view"
 AS
 SELECT c1 as k1, k2, k3, SUM(v1) FROM example_table
 WHERE k1 = 20160112 GROUP BY k1,k2,k3;
```

# 同步物化视图

物化视图是将预先计算（根据定义好的 SELECT 语句）好的数据集，存储在 Doris 中的一个特殊的表。

物化视图的出现主要是为了满足用户，既能对原始明细数据的任意维度分析，也能快速的对固定维度进行分析查询。

## 适用场景

- 分析需求覆盖明细数据查询以及固定维度查询两方面。
- 查询仅涉及表中的很小一部分列或行。
- 查询包含一些耗时处理操作，比如：时间很久的聚合操作等。
- 查询需要匹配不同前缀索引。

## 优势

- 对于那些经常重复的使用相同的子查询结果的查询性能大幅提升。
- Doris 自动维护物化视图的数据，无论是新的导入，还是删除操作都能保证 Base 表和物化视图表的数据一致性，无需任何额外的人工维护成本。
- 查询时，会自动匹配到最优物化视图，并直接从物化视图中读取数据。

*自动维护物化视图的数据会造成一些维护开销，会在后面的物化视图的局限性中展开说明。*

## 物化视图 VS Rollup

在没有物化视图功能之前，用户一般都是使用 Rollup 功能通过预聚合方式提升查询效率的。但是 Rollup 具有一定的局限性，他不能基于明细模型做预聚合。

物化视图则在覆盖了 Rollup 的功能的同时，还能支持更丰富的聚合函数。所以物化视图其实是 Rollup 的一个超集。

也就是说，之前 [ALTER TABLE ADD ROLLUP](#) 语法支持的功能现在均可以通过 [CREATE MATERIALIZED VIEW](#) 实现。

## 使用物化视图

Doris 系统提供了一整套对物化视图的 DDL 语法，包括创建，查看，删除。DDL 的语法和 PostgreSQL, Oracle 都是一致的。

## 创建物化视图

这里首先你要根据你的查询语句的特点来决定创建一个什么样的物化视图。这里并不是说你的物化视图定义和你的某个查询语句一模一样就最好。这里有两个原则：

1. 从查询语句中**抽象**出，多个查询共有的分组和聚合方式作为物化视图的定义。
2. 不需要给所有维度组合都创建物化视图。

首先第一个点，一个物化视图如果抽象出来，并且多个查询都可以匹配到这张物化视图。这种物化视图效果最好。因为物化视图的维护本身也需要消耗资源。

如果物化视图只和某个特殊的查询很贴合，而其他查询均用不到这个物化视图。则会导致这张物化视图的性价比不高，既占用了集群的存储资源，还不能为更多的查询服务。

所以用户需要结合自己的查询语句，以及数据维度信息去抽象出一些物化视图的定义。

第二点就是，在实际的分析查询中，并不会覆盖到所有的维度分析。所以给常用的维度组合创建物化视图即可，从而到达一个空间和时间上的平衡。

创建物化视图是一个异步的操作，也就是说用户成功提交创建任务后，Doris 会在后台对存量的数据进行计算，直到创建成功。

具体的语法可查看[CREATE MATERIALIZED VIEW](#)。

### 自 Doris 2.0 版本起支持以下功能

在Doris 2.0版本中我们对物化视图的做了一些增强 (在本文的最佳实践4中有具体描述)。我们建议用户在正式的生产环境中使用物化视图前，先在测试环境中确认是预期中的查询能否命中想要创建的物化视图。

如果不清楚如何验证一个查询是否命中物化视图，可以阅读本文的最佳实践1。

与此同时，我们不建议用户在同一张表上建多个形态类似的物化视图，这可能会导致多个物化视图之间的冲突使得查询命中失败 (在新优化器中这个问题会有所改善)。建议用户先在测试环境中验证物化视图和查询是否满足需求并能正常使用。

## 支持聚合函数

目前物化视图创建语句支持的聚合函数有：

- SUM, MIN, MAX (Version 0.12)
- COUNT, BITMAP\_UNION, HLL\_UNION (Version 0.13)

## 更新策略

为保证物化视图表和 Base 表的数据一致性，Doris 会将导入，删除等对 Base 表的操作都同步到物化视图表中。并且通过增量更新的方式来提升更新效率。通过事务方式来保证原子性。

比如如果用户通过 INSERT 命令插入数据到 Base 表中，则这条数据会同步插入到物化视图中。当 Base 表和物化视图表均写入成功后，INSERT 命令才会成功返回。

### 查询自动匹配

物化视图创建成功后，用户的查询不需要发生任何改变，也就是还是查询的 Base 表。Doris 会根据当前查询的语句去自动选择一个最优的物化视图，从物化视图中读取数据并计算。

用户可以通过 EXPLAIN 命令来检查当前查询是否使用了物化视图。

物化视图中的聚合和查询中聚合的匹配关系：

物化视图聚合	查询中聚合
sum	sum
min	min
max	max
count	count
bitmap_union	bitmap_union, bitmap_union_count, count(distinct)
hll_union	hll_raw_agg, hll_union_agg, ndv, approx_count_distinct

其中 bitmap 和 hll 的聚合函数在查询匹配到物化视图后，查询的聚合算子会根据物化视图的表结构进行改写。详见实例 2。

### 查询物化视图

查看当前表都有哪些物化视图，以及他们的表结构都是什么样的。通过下面命令：

MySQL [test]> desc mv\_test all;

IndexName	IndexKeysType	Field	Type	Null	Key	Default	Extra
mv_test	DUP_KEYS	k1	INT	Yes	true	NULL	
		k2	BIGINT	Yes	true	NULL	
		k3	LARGEINT	Yes	true	NULL	
		k4	SMALLINT	Yes	false	NULL	NONE
mv_2	AGG_KEYS	k2	BIGINT	Yes	true	NULL	
		k4	SMALLINT	Yes	false	NULL	MIN
		k1	INT	Yes	false	NULL	MAX
mv_3	AGG_KEYS	k1	INT	Yes	true	NULL	
		to_bitmap(`k2`)	BITMAP	No	false		BITMAP_UNION
mv_1	AGG_KEYS	k4	SMALLINT	Yes	true	NULL	
		k1	BIGINT	Yes	false	NULL	SUM
		k3	LARGEINT	Yes	false	NULL	SUM
		k2	BIGINT	Yes	false	NULL	MIN

可以看到当前 mv\_test 表一共有三张物化视图：mv\_1, mv\_2 和 mv\_3，以及他们的表结构。



## 删除物化视图

如果用户不再需要物化视图，则可以通过命令删除物化视图。

具体的语法可查看[DROP MATERIALIZED VIEW](#)

## 查看已创建的物化视图

用户可以通过命令查看已创建的物化视图的

具体的语法可查看[SHOW CREATE MATERIALIZED VIEW](#)

## 取消创建物化视图

```
CANCEL ALTER TABLE MATERIALIZED VIEW FROM db_name.table_name
```

## 最佳实践 1

使用物化视图一般分为以下几个步骤：

1. 创建物化视图
2. 异步检查物化视图是否构建完成
3. 查询并自动匹配物化视图

### 首先是第一步：创建物化视图

假设用户有一张销售记录明细表，存储了每个交易的交易 id，销售员，售卖门店，销售时间，以及金额。建表语句和插入数据语句为：

```
create table sales_records(record_id int, seller_id int, store_id int, sale_date date, sale_amt bigint)
distributed by hash(record_id) properties("replication_num" = "1");
insert into sales_records values(1,1,1,"2020-02-02",1);
```

这张 sales\_records 的表结构如下：

```
MySQL [test]> desc sales_records;
+-----+-----+-----+-----+-----+-----+
| Field | Type | Null | Key | Default | Extra |
+-----+-----+-----+-----+-----+-----+
| record_id | INT | Yes | true | NULL | |
| seller_id | INT | Yes | true | NULL | |
| store_id | INT | Yes | true | NULL | |
| sale_date | DATE | Yes | false | NULL | NONE |
| sale_amt | BIGINT | Yes | false | NULL | NONE |
+-----+-----+-----+-----+-----+-----+
```

这时候如果用户经常对不同门店的销售量进行分析查询，则可以给这个 sales\_records 表创建一张以售卖门店分组，对相同售卖门店的销售额求和的一个物化视图。创建语句如下：

```
MySQL [test]> create materialized view store_amt as select store_id, sum(sale_amt) from sales_records group by store_id;
```

后端返回下图，则说明创建物化视图任务提交成功。

```
Query OK, 0 rows affected (0.012 sec)
```

## 第二步：检查物化视图是否构建完成

由于创建物化视图是一个异步的操作，用户在提交完创建物化视图任务后，需要异步的通过命令检查物化视图是否构建完成。命令如下：

```
SHOW ALTER TABLE ROLLUP FROM db_name; (Version 0.12)
SHOW ALTER TABLE MATERIALIZED VIEW FROM db_name; (Version 0.13)
```

这个命令中 db\_name 是一个参数，你需要替换成自己真实的 db 名称。命令的结果是显示这个 db 的所有创建物化视图的任务。结果如下：

```

| JobId | TableName | CreateTime | FinishedTime | BaseIndexName | RollupIndexName | RollupId |
TransactionId | State | Msg | Progress | Timeout |

| 22036 | sales_records | 2020-07-30 20:04:28 | 2020-07-30 20:04:57 | sales_records | store_amt | 22037
| 5008 | FINISHED | | NULL | 86400 |

```

其中 TableName 指的是物化视图的数据来自于哪个表，RollupIndexName 指的是物化视图的名称叫什么。其中比较重要的指标是 State。

当创建物化视图任务的 State 已经变成 FINISHED 后，就说明这个物化视图已经创建成功了。这就意味着，查询的时候有可能自动匹配到这张物化视图了。

## 第三步：查询

当创建完成物化视图后，用户再查询不同门店的销售量时，就会直接从刚才创建的物化视图 store\_amt 中读取聚合好的数据。达到提升查询效率的效果。

用户的查询依旧指定查询 sales\_records 表，比如：

```
SELECT store_id, sum(sale_amt) FROM sales_records GROUP BY store_id;
```

上面查询就能自动匹配到 store\_amt。用户可以通过下面命令，检验当前查询是否匹配到了合适的物化视图。

```
EXPLAIN SELECT store_id, sum(sale_amt) FROM sales_records GROUP BY store_id;
```

```

| Explain String |

| PLAN FRAGMENT 0 |
| OUTPUT EXPRS: |

```

```

| <slot 4> `default_cluster:test`.`sales_records`.`mv_store_id`
| <slot 5> sum(`default_cluster:test`.`sales_records`.`mva_SUM__`sale_amt`)
| PARTITION: UNPARTITIONED
|
| VRESULT SINK
|
| 4:VEXCHANGE
| offset: 0
|
| PLAN FRAGMENT 1
|
| PARTITION: HASH_PARTITIONED: <slot 4> `default_cluster:test`.`sales_records`.`mv_store_id`
|
| STREAM DATA SINK
| EXCHANGE ID: 04
| UNPARTITIONED
|
| 3:VAGGREGATE (merge finalize)
| | output: sum(<slot 5> sum(`default_cluster:test`.`sales_records`.`mva_SUM__`sale_amt`))
| | group by: <slot 4> `default_cluster:test`.`sales_records`.`mv_store_id`
| | cardinality=-1
| |
| 2:VEXCHANGE
| offset: 0
|
| PLAN FRAGMENT 2
|
| PARTITION: HASH_PARTITIONED: `default_cluster:test`.`sales_records`.`record_id`
|
| STREAM DATA SINK
| EXCHANGE ID: 02
| HASH_PARTITIONED: <slot 4> `default_cluster:test`.`sales_records`.`mv_store_id`
|
| 1:VAGGREGATE (update serialize)
| | STREAMING
| | output: sum(`default_cluster:test`.`sales_records`.`mva_SUM__`sale_amt`)
| | group by: `default_cluster:test`.`sales_records`.`mv_store_id`
| | cardinality=-1
| |
| 0:V0lapScanNode
| TABLE: default_cluster:test.sales_records(store_amt), PREAGGREGATION: ON
| partitions=1/1, tablets=10/10, tabletList=50028,50030,50032 ...
| cardinality=1, avgRowSize=1520.0, numNodes=1
|

```

从最底部的test.sales\_records(store\_amt)可以表明这个查询命中了store\_amt这个物化视图。值得注意的是，如果表中没有数据，那么可能不会命中物化视图。

## 最佳实践 2 (UV, PV)

业务场景：计算广告的 UV, PV。

假设用户的原始广告点击数据存储在 Doris，那么针对广告 PV, UV 查询就可以通过创建 bitmap\_union 的物化视图来提升查询速度。

通过下面语句首先创建一个存储广告点击数据明细的表，包含每条点击的点击时间，点击的是什么广告，通过什么渠道点击，以及点击的用户是谁。

```

create table advertiser_view_record(time date, advertiser varchar(10), channel varchar(10), user_id int)
distributed by hash(time) properties("replication_num" = "1");

```

```
insert into advertiser_view_record values("2020-02-02",'a','a',1);
```

原始的广告点击数据表结构为：

```
MySQL [test]> desc advertiser_view_record;
+-----+-----+-----+-----+-----+-----+
| Field | Type | Null | Key | Default | Extra |
+-----+-----+-----+-----+-----+-----+
| time | DATE | Yes | true | NULL | |
| advertiser | VARCHAR(10)| Yes | true | NULL | |
| channel | VARCHAR(10)| Yes | false| NULL | NONE |
| user_id | INT | Yes | false| NULL | NONE |
+-----+-----+-----+-----+-----+-----+
4 rows in set (0.001 sec)
```

## 1. 创建物化视图

由于用户想要查询的是广告的 UV 值，也就是需要对相同广告的用户进行一个精确去重，则查询一般为：

```
SELECT advertiser, channel, count(distinct user_id) FROM advertiser_view_record GROUP BY advertiser, channel;
```

针对这种求 UV 的场景，我们就可以创建一个带 bitmap\_union 的物化视图从而达到一个预先精确去重的效果。

在 Doris 中，count(distinct) 聚合的结果和 bitmap\_union\_count 聚合的结果是完全一致的。而 bitmap\_union\_count 等于 bitmap\_union 的结果求 count，所以如果查询中涉及到 count(distinct) 则通过创建带 bitmap\_union 聚合的物化视图方可加快查询。

针对这个 Case，则可以创建一个根据广告和渠道分组，对 user\_id 进行精确去重的物化视图。

```
MySQL [test]> create materialized view advertiser_uv as select advertiser, channel,
bitmap_union(to_bitmap(user_id)) from advertiser_view_record group by advertiser, channel;
Query OK, 0 rows affected (0.012 sec)
```

**注意：**因为本身 user\_id 是一个 INT 类型，所以在 Doris 中需要先将字段通过函数 to\_bitmap 转换为 bitmap 类型然后才可以进行 bitmap\_union 聚合。

创建完成后，广告点击明细表和物化视图表的表结构如下：

```
MySQL [test]> desc advertiser_view_record all;

| IndexName | IndexKeyType | Field | Type | Null | Key | Default |
| Extra |

| advertiser_view_record | DUP_KEYS | time | DATE | Yes | true | NULL |
| | | advertiser | VARCHAR(10)| Yes | true | NULL |
| | | channel | VARCHAR(10)| Yes | false| NULL | NONE
| | | user_id | INT | Yes | false| NULL | NONE
| |
```

advertiser_uv	AGG_KEYS	advertiser	VARCHAR(10)	Yes	true	NULL	
		channel	VARCHAR(10)	Yes	true	NULL	
		to_bitmap(`user_id`)	BITMAP	No	false		
BITMAP_UNION							
-----							
-----							

## 2. 查询自动匹配

当物化视图表创建完成后，查询广告 UV 时，Doris 就会自动从刚才创建好的物化视图 advertiser\_uv 中查询数据。比如原始的查询语句如下：

```
SELECT advertiser, channel, count(distinct user_id) FROM advertiser_view_record GROUP BY advertiser, channel;
```

在选中物化视图后，实际的查询会转化为：

```
SELECT advertiser, channel, bitmap_union_count(to_bitmap(user_id)) FROM advertiser_uv GROUP BY advertiser, channel;
```

通过 EXPLAIN 命令可以检验到 Doris 是否匹配到了物化视图：

```
mysql [test]>explain SELECT advertiser, channel, count(distinct user_id) FROM advertiser_view_record GROUP BY advertiser, channel;

| Explain String
|

| PLAN FRAGMENT 0
|
| OUTPUT EXPRS:
|
| <slot 9> `default_cluster:test`.`advertiser_view_record`.`mv_advertiser`
|
| <slot 10> `default_cluster:test`.`advertiser_view_record`.`mv_channel`
|
| <slot 11>
| bitmap_union_count(`default_cluster:test`.`advertiser_view_record`.`mva_BITMAP_UNION__to_bitmap_with_check(`u
| ser_id`)`) |
| PARTITION: UNPARTITIONED
|
|
|
| VRESULT SINK
|
|
|
| 4:VEXCHANGE
|
| offset: 0
|
|
|
| PLAN FRAGMENT 1
```

```

PARTITION: HASH_PARTITIONED:

 <slot 6> `default_cluster:test`.`advertiser_view_record`.`mv_advertiser`,

 <slot 7> `default_cluster:test`.`advertiser_view_record`.`mv_channel`

STREAM DATA

SINK

 EXCHANGE ID: 04

 UNPARTITIONED

3:VAGGREGATE (merge finalize)

 | output: bitmap_union_count(
 <slot 8>
 bitmap_union_count(`default_cluster:test`.`advertiser_view_record`.`mva_BITMAP_UNION__to_bitmap_with_check(`u
 ser_id`)`))|
 | group by:
 <slot 6> `default_cluster:test`.`advertiser_view_record`.`mv_advertiser`,
 <slot 7> `default_cluster:test`.`advertiser_view_record`.`mv_channel`

 | cardinality=-1

 |

2:VEXCHANGE

 offset: 0

PLAN FRAGMENT 2

PARTITION: HASH_PARTITIONED: `default_cluster:test`.`advertiser_view_record`.`time`

STREAM DATA SINK

 EXCHANGE ID: 02

 HASH_PARTITIONED:

 <slot 6> `default_cluster:test`.`advertiser_view_record`.`mv_advertiser`,

 <slot 7> `default_cluster:test`.`advertiser_view_record`.`mv_channel`

1:VAGGREGATE (update serialize)

 | STREAMING

```

```

| | output:
bitmap_union_count(`default_cluster:test`.`advertiser_view_record`.`mva_BITMAP_UNION__to_bitmap_with_check(`u
ser_id`)`) |
| | group by: `default_cluster:test`.`advertiser_view_record`.`mv_advertiser`,
`default_cluster:test`.`advertiser_view_record`.`mv_channel` |
| | cardinality=-1
|
| |
|
| 0:V0lapScanNode
|
| TABLE: default_cluster:test.advertiser_view_record(advertiser_uv), PREAGGREGATION: ON
|
| partitions=1/1, tablets=10/10, tabletList=50075,50077,50079 ...
|
| cardinality=0, avgRowSize=48.0, numNodes=1
|


```

在 EXPLAIN 的结果中，首先可以看到 V0lapScanNode 命中了 advertiser\_uv。也就是说，查询会直接扫描物化视图的数据。说明匹配成功。

其次对于 user\_id 字段求 count(distinct) 被改写为求 bitmap\_union\_count(to\_bitmap)。也就是通过 Bitmap 的方式来达到精确去重的效果。

## 最佳实践 3

业务场景：匹配更丰富的前缀索引

用户的原始表有 (k1, k2, k3) 三列。其中 k1, k2 为前缀索引列。这时候如果用户查询条件中包含 where k1=1 and k2=2 就能通过索引加速查询。

但是有些情况下，用户的过滤条件无法匹配到前缀索引，比如 where k3=3。则无法通过索引提升查询速度。

创建以 k3 作为第一列的物化视图就可以解决这个问题。

### 1. 创建物化视图

```
CREATE MATERIALIZED VIEW mv_1 as SELECT k3, k2, k1 FROM tableA ORDER BY k3;
```

通过上面语法创建完成后，物化视图中既保留了完整的明细数据，且物化视图的前缀索引为 k3 列。表结构如下：

```
MySQL [test]> desc tableA all;
```

IndexName	IndexKeysType	Field	Type	Null	Key	Default	Extra
tableA	DUP_KEYS	k1	INT	Yes	true	NULL	
		k2	INT	Yes	true	NULL	
		k3	INT	Yes	true	NULL	
mv_1	DUP_KEYS	k3	INT	Yes	true	NULL	
		k2	INT	Yes	false	NULL	NONE
		k1	INT	Yes	false	NULL	NONE

## 2. 查询匹配

这时候如果用户的查询存在 k3 列的过滤条件是，比如：

```
select k1, k2, k3 from table A where k3=3;
```

这时候查询就会直接从刚才创建的 mv\_1 物化视图中读取数据。物化视图对 k3 是存在前缀索引的，查询效率也会提升。

## 最佳实践 4

在Doris 2.0中，我们对物化视图所支持的表达式做了一些增强，本示例将主要体现新版本物化视图对各种表达式的支持和提前过滤。

1. 创建一个 Base 表并插入一些数据。

```
create table d_table (
 k1 int null,
 k2 int not null,
 k3 bigint null,
 k4 date null
)
duplicate key (k1,k2,k3)
distributed BY hash(k1) buckets 3
properties("replication_num" = "1");

insert into d_table select 1,1,1,'2020-02-20';
insert into d_table select 2,2,2,'2021-02-20';
insert into d_table select 3,-3,null,'2022-02-20';
```

2. 创建一些物化视图。

```
create materialized view k1a2p2ap3ps as select abs(k1)+k2+1,sum(abs(k2+2)+k3+3) from d_table group by
abs(k1)+k2+1;
create materialized view kynd as select year(k4),month(k4) from d_table where year(k4) = 2020; // 提前用where
表达式过滤以减少物化视图中的数据量。
```

3. 用一些查询测试是否成功命中物化视图。

```
select abs(k1)+k2+1,sum(abs(k2+2)+k3+3) from d_table group by abs(k1)+k2+1; // 命中k1a2p2ap3ps
select bin(abs(k1)+k2+1),sum(abs(k2+2)+k3+3) from d_table group by bin(abs(k1)+k2+1); // 命中k1a2p2ap3ps
select year(k4),month(k4) from d_table; // 无法命中物化视图，因为where条件不匹配
select year(k4)+month(k4) from d_table where year(k4) = 2020; // 命中kynd
```

## 局限性

1. 如果删除语句的条件列，在物化视图中存在，则不能进行删除操作。如果一定要删除数据，则需要先将物化视图删除，然后方可删除数据。
2. 单表上过多的物化视图会影响导入的效率：导入数据时，物化视图和 Base 表数据是同步更新的，如果一张表的物化视图表超过 10 张，则有可能导致导入速度很慢。这就像单次导入需要同时导入 10 张表数据是一样的。



3. 物化视图针对 Unique Key 数据模型，只能改变列顺序，不能起到聚合的作用，所以在 Unique Key 模型上不能通过创建物化视图的方式对数据进行粗粒度聚合操作
4. 目前一些优化器对 sql 的改写行为可能会导致物化视图无法被命中，例如 `k1+1-1` 被改写成 `k1`，`between` 被改写成 `<=`和`>=`，`day` 被改写成 `dayofmonth`，遇到这种情况需要手动调整下查询和物化视图的语句。

## 异常错误

### 1. DATA\_QUALITY\_ERROR: “The data quality does not satisfy, please check your data”

由于数据质量问题或者 Schema Change 内存使用超出限制导致物化视图创建失败。如果是内存问题，调大 `memory_limitation_per_thread_for_schema_change_bytes`参数即可。

注意：to\_bitmap 的参数仅支持正整型，如果原始数据中存在负数，会导致物化视图创建失败。String 类型的字段可使用 bitmap\_hash 或 bitmap\_hash64 计算 Hash 值，并返回 Hash 值的 bitmap。

## 更多帮助

关于物化视图使用的更多详细语法及最佳实践，请参阅 [CREATE MATERIALIZED VIEW](#) 和 [DROP MATERIALIZED VIEW](#) 命令手册，你也可以在 MySQL 客户端命令行下输入 `HELP CREATE MATERIALIZED VIEW` 和 `HELP DROP MATERIALIZED VIEW` 获取更多帮助信息。

# Join 优化原理

Doris 支持两种物理算子，一类是 **Hash Join**，另一类是 **Nest Loop Join**。

- Hash Join：在右表上根据等值 Join 列建立哈希表，左表流式的利用哈希表进行 Join 计算，它的限制是只能适用于等值 Join。
- Nest Loop Join：通过两个 for 循环，很直观。然后它适用的场景就是不等值的 Join，例如：大于小于或者是需要求笛卡尔积的场景。它是一个通用的 Join 算子，但是性能表现差。

作为分布式的 MPP 数据库，在 Join 的过程中是需要进行数据的 Shuffle。数据需要进行拆分调度，才能保证最终的 Join 结果是正确的。举个简单的例子，假设关系 S 和 R 进行 Join，N 表示参与 Join 计算的节点的数量；T 则表示关系的 Tuple 数目。


## Doris Shuffle 方式

Doris 支持 4 种 Shuffle 方式

### 1. Broadcast Join

它要求把右表全量的数据都发送到左表上，即每一个参与 Join 的节点，它都拥有右表全量的数据，也就是  $T(R)$ 。

它适用的场景是比较通用的，同时能够支持 Hash Join 和 Nest loop Join，它的网络开销  $N * T(R)$ 。




### BroadCast Join

左表数据不移动，右表数据发送到左表数据的扫描节点。

### 2. Shuffle Join

当进行 Hash Join 时候，可以通过 Join 列计算对应的 Hash 值，并进行 Hash 分桶。

它的网络开销则是： $T(S) + T(R)$ ，但它只能支持 Hash Join，因为它根据 Join 的条件也去做计算分桶的。




### Shuffle Join

左右表数据根据分区，计算的结果发送到不同的分区节点上。

### 3. Bucket Shuffle Join

Doris 的表数据本身是通过 Hash 计算分桶的，所以就可以利用表本身的分桶列的性质来进行 Join 数据的 Shuffle。假如两张表需要做 Join，并且 Join 列是左表的分桶列，那么左表的数据其实可以不用去移动右表通过左表的数据分桶发送数据就可以完成 Join 的计算。

它的网络开销则是： $T(R)$  相当于只 Shuffle 右表的数据就可以了。




### Bucket Shuffle Join

左表数据不移动，右表数据根据分区计算的结果发送到左表扫表的节点

### 4. Colocate

它与 Bucket Shuffle Join 相似，相当于在数据导入的时候，根据预设的 Join 列的场景已经做好了数据的 Shuffle。那么实际查询的时候就可以直接进行 Join 计算而不需要考虑数据的 Shuffle 问题了。



## Colocation Join

数据已经预先分区，直接在本地进行 Join 计算

## 四种 Shuffle 方式对比

Shuffle 方式	网络开销	物理算子	适用场景
BroadCast	$N * T(R)$	Hash Join / Nest Loop Join	通用
Shuffle	$T(S) + T(R)$	Hash Join	通用
Bucket Shuffle	$T(R)$	Hash Join	Join 条件中存在左表的分布式列，且左表执行时为单分区
Colocate	0	Hash Join	Join 条件中存在左表的分布式列，且左右表同属于一个 Colocate Group

N: 参与 Join 计算的 Instance 个数

T(关系): 关系的 Tuple 数目

上面这 4 种方式灵活度是从高到低的，它对这个数据分布的要求是越来越严格，但 Join 计算的性能也是越来越好的。

## Runtime Filter Join 优化

Doris 在进行 Hash Join 计算时会在右表构建一个哈希表，左表流式的通过右表的哈希表从而得出 Join 结果。而 RuntimeFilter 就是充分利用了右表的 Hash 表，在右表生成哈希表的时候，同时生成一个基于哈希表数据的一个过滤条件，然后下推到左表的数据扫描节点。通过这样的方式，Doris 可以在运行时进行数据过滤。

假如左表是一张大表，右表是一张小表，那么利用右表生成的过滤条件就可以把绝大多数在 Join 层要过滤的数据在数据读取时就提前过滤，这样就能大幅度的提升 Join 查询的性能。

当前 Doris 支持三种类型 RuntimeFilter

- 一种是 IN，很好理解，将一个 hashset 下推到数据扫描节点。
- 第二种就是 BloomFilter，就是利用哈希表的数据构造一个 BloomFilter，然后把这个 BloomFilter 下推到查询数据的扫描节点。
- 最后一种就是 MinMax，就是个 Range 范围，通过右表数据确定 Range 范围之后，下推给数据扫描节点。

Runtime Filter 适用的场景有两个要求：

- 第一个要求就是左表大右表小，因为构建 Runtime Filter 是需要承担计算成本的，包括一些内存的开销。
- 第二个要求就是左右表 Join 出来的结果很少，说明这个 Join 可以过滤掉左表的绝大部分数据。

当符合上面两个条件的情况下，开启 Runtime Filter 就能收获比较好的效果

当 Join 列为左表的 Key 列时，RuntimeFilter 会下推到存储引擎。Doris 本身支持延迟物化，

延迟物化简单来说是这样的：假如需要扫描 A、B、C 三列，在 A 列上有一个过滤条件：A 等于 2，要扫描 100 行的话，可以先把 A 列的 100 行扫描出来，再通过 A = 2 这个过滤条件过滤。之后通过过滤完成后的结果，再去读取 B、C 列，这样就能极大的降低数据的读取 IO。所以说 Runtime Filter 如果在 Key 列上生成，同时利用 Doris 本身的延迟物化来进一步提升查询的性能。

## Runtime Filter 类型


Doris 提供了三种不同的 Runtime Filter 类型：

- **IN** 的优点是过滤效果明显，且快速。它的缺点首先第一个它只适用于 BroadCast，第二，它右表超过一定数据量的时候就失效了，当前 Doris 目前配置的是 1024，即右表如果大于 1024，IN 的 Runtime Filter 就直接失效了。
- **MinMax** 的优点是开销比较小。它的缺点就是对数值列还有比较好的效果，但对于非数值列，基本上就没什么效果。
- **Bloom Filter** 的特点就是通用，适用于各种类型、效果也比较好。缺点就是它的配置比较复杂并且计算较高。

## Join Reorder

数据库一旦涉及到多表 Join，Join 的顺序对整个 Join 查询的性能是影响很大的。假设有三张表 Join，参考下面这张图，左边是 a 表跟 b 表先做 Join，中间结果的有 2000 行，然后与 c 表再进行 Join 计算。

接下来看右图，把 Join 的顺序调整了一下。把 a 表先与 c 表 Join，生成的中间结果只有 100，然后最终再与 b 表 Join 计算。最终的 Join 结果是一样的，但是它生成的中间结果有 20 倍的差距，这就会产生一个很大的性能 Diff 了。



## Join Reorder

Doris 目前支持基于规则的 Join Reorder 算法。它的逻辑是：

- 让大表、跟小表尽量做 Join，它生成的中间结果是尽可能小的。
- 把有条件的 Join 表往前放，也就是说尽量让有条件的 Join 表进行过滤
- Hash Join 的优先级高于 Nest Loop Join，因为 Hash join 本身是比 Nest Loop Join 快很多的。

## Doris Join 调优方法

Doris Join 调优的方法：

- 利用 Doris 本身提供的 Profile，去定位查询的瓶颈。Profile 会记录 Doris 整个查询当中各种信息，这是进行性能调优的一手资料。
- 了解 Doris 的 Join 机制，这也是第二部分跟大家分享的内容。知其然知其所以然、了解它的机制，才能分析它为什么比较慢。
- 利用 Session 变量去改变 Join 的一些行为，从而实现 Join 的调优。
- 查看 Query Plan 去分析这个调优是否生效。

上面的 4 步基本上完成了一个标准的 Join 调优流程，接着就是实际去查询验证它，看看效果到底怎么样。

如果前面 4 种方式串联起来之后，还是不奏效。这时候可能就需要去做 Join 语句的改写，或者是数据分布的调整、需要重新去 Recheck 整个数据分布是否合理，包括查询 Join 语句，可能需要做一些手动的调整。当然这种方式是心智成本是比较高的，也就是说要在尝试前面方式不奏效的情况下，才需要去做进一步的分析。

## 调优案例实战

### 案例一

一个四张表 Join 的查询，通过 Profile 的时候发现第二个 Join 耗时很高，耗时 14 秒。

HASH\_JOIN\_NODE (id=8):(Active: 14s252ms, % non-child: 27.91%)

- ExecOption: Hash Table Built Asynchronously
- BuildBuckets: 32 768K (32768)
- BuildRows: 25.00008M (25000080)
- BuildTime: 9s24ms
- HashTableMaxList: 1.6K (1600)
- HashTableMinList: 1.52K (1520)
- LoadFactor: 4602678819172646900.00
- PeakMemoryUsage: 1.20 GB
- ProbeRows: 12.351K (12351)
- ProbeTime: 5s222ms
- PushDownComputeTime: 57.945ms
- PushDownTime: 100ns
- RowsReturned: 988.08K (988080)
- RowsReturnedRate: 69.326K /sec

image-20220523153600797

进一步分析 Profile 之后，发现 BuildRows，就是右表的数据量是大概 2500 万。而 ProbeRows（ProbeRows 是左表的数据量）只有 1 万多。这种场景下右表是远远大于左表，这显然是个不合理的情况。这显然说明 Join 的顺序出现了一些问题。这时候尝试改变 Session 变量，开启 Join Reorder。

```
set enable_cost_based_join_reorder = true
```

这次耗时从 14 秒降到了 4 秒，性能提升了 3 倍多。

此时再 Check Profile 的时候，左右表的顺序已经调整正确，即右表是小表，左表是大表。基于小表去构建哈希表，开销是很小的，这就是典型的一个利用 Join Reorder 去提升 Join 性能的一个场景

**HASH\_JOIN\_NODE** (id=10):(Active: 4s912ms, % non-child: 41.02%)

- ExecOption: Hash Table Built Asynchronously
- BuildBuckets: 524.288K (524288)
- BuildRows: 400.511K (400511)
- BuildTime: 175.115ms
- HashTableMaxList: 8
- HashTableMinList: 1
- LoadFactor: 4603045145523257300.00
- PeakMemoryUsage: 21.70 MB
- ProbeRows: 25.0M (25000000)
- ProbeTime: 4s274ms
- PushDownComputeTime: 855.600us
- PushDownTime: 100ns
- RowsReturned: 1.001833M (1001833)
- RowsReturnedRate: 203.938K /sec

image-20220523153757607

## 案例二

存在一个慢查询，查看 Profile 之后，整个 Join 节点耗时大概 44 秒。它的右表有 1000 万，左表有 6000 万，最终返回的结果也只有 6000 万。

**HASH\_JOIN\_NODE** (id=9):(Active: 44s162ms, % non-child: 16.31%)

- ExecOption: Hash Table Built Asynchronously
- BuildBuckets: 16.777216M (16777216)
- BuildRows: 10.0M (10000000)
- BuildTime: 4s901ms
- HashTableMaxList: 1
- HashTableMinList: 1
- LoadFactor: 4603543928665276400.00
- PeakMemoryUsage: 601.43 MB
- ProbeRows: 60.011555M (60011555)
- ProbeTime: 37s614ms
- PushDownComputeTime: 20.258ms
- PushDownTime: 551ns
- RowsReturned: 60.011555M (60011555)
- RowsReturnedRate: 1.358889M /sec

image-20220523153913059



这里可以大致的估算出过滤率是很高的，那为什么 Runtime Filter 没有生效呢？通过 Query Plan 去查看它，发现它只开启了 IN 的 Runtime Filter。

```
9:HASH JOIN
|
| join op: INNER JOIN (BROADCAST)
|
| hash predicates:
|
| colocate: false, reason: Tables are not in the same group
|
| equal join conjunct: `l_suppkey` = `s_suppkey`
| runtime filters: RF006[in] <- `s_suppkey`
| cardinality=5999989709
|
```

image-20220523153958828

当右表超过 1024 行的话，IN 是不生效的，所以根本起不到什么过滤的效果，所以尝试调整 RuntimeFilter 的类型。

这里改为了 BloomFilter，左表的 6000 万条数据过滤了 5900 万条。基本上 99% 的数据都被过滤掉了，这个效果是很显著的。查询也从原来的 44 秒降到了 13 秒，性能提升了大概也是三倍多。

### 案例三

下面是一个比较极端的 Case，通过一些环境变量调优也没有办法解决，因为它涉及到 SQL Rewrite，所以这里列出来了原始的 SQL。

```
select 100.00 * sum (case
 when P_type like 'PROMOS'
 then 1 extendedprice * (1 - 1 discount)
 else 0
end) / sum(1 extendedprice * (1 - 1 discount)) as promo revenue
from lineitem, part
where
 1_partkey = p_partkey
 and 1_shipdate >= date '1997-06-01'
 and 1 shipdate < date '1997-06-01' + interval '1' month
```

这个 Join 查询是很简单的，单纯的一个左右表的 Join。当然它上面有一些过滤条件，打开 Profile 的时候，发现整个查询 Hash Join 执行了三分多钟，它是一个 Broadcast 的 Join，它的右表有 2 亿条，左表只有 70 万。在这种情况下选择了 Broadcast Join 是不合理的，这相当于要把 2 亿条做一个 Hash Table，然后用 70 万条遍历两亿条的 Hash Table，这显然是不合理的。




image-20220523154712519

为什么会产生不合理的 Join 顺序呢？其实这个左表是一个 10 亿条级别的大表，它上面加了两个过滤条件，加完这两个过滤条件之后，10 亿条的数据就剩 70 万条了。但 Doris 目前没有一个好的统计信息收集的框架，所以它不知道这个过滤条件的过滤率到底怎么样。所以这个 Join 顺序安排的时候，就选择了错误的 Join 的左右表顺序，导致它的性能是极其低下的。

下图是改写完成之后的一个 SQL 语句，在 Join 后面添加了一个 Join Hint，在 Join 后面加一个方括号，然后把需要的 Join 方式写入。这里选择了 Shuffle Join，可以看到右边它实际查询计划里面看到这个数据确实是做了 Partition，原先 3 分钟的耗时通过这样的改写完之后只剩下 7 秒，性能提升明显

```
2:HASH JOIN
```

```
| join op: INNER JOIN (PARTITIONED)
```

```
| hash predicates:
```

```
| colocate: false, reason: Has join hint
```

```
| equal join conjunct: 'p_partkey' = 'l_partkey'
```

```
| runtime filters: RF000[bloom] <- 'l_partkey'
```

```
| cardinality=199999999
```

```
HASH_JOIN_NODE (id=2):(Active: 7s573ms, % non-child: 10.24%)
```

```
- ExecOption: Hash Table Built Asynchronously
```

```
- BuildBuckets: 524.288K (524288)
```

```
- BuildRows: 747.852K (747852)
```

```
- BuildTime: 5s695ms
```

```
- HashTableMaxList: 12
```

```
- HashTableMinList: 1
```

```
- LoadFactor: 4604454238393729000.00
```

```
- PeakMemoryUsage: 76.56 MB
```

```
- ProbeRows: 1.999985M (1999985)
```

```
- ProbeTime: 788.654ms
```

```
- PushDownComputeTime: Ons
```

```
- PushDownTime: Ons
```

```
- RowsReturned: 747.852K (747852)
```

```
- RowsReturnedRate: 98.745K /sec
```

image-20220523160915229

## Doris Join 调优建议

最后我们总结 Doris Join 优化调优的四点建议：

- 第一点：在做 Join 的时候，要尽量选择同类型或者简单类型的列，同类型的话就减少它的数据 Cast，简单类型本身 Join 计算就很快。
- 第二点：尽量选择 Key 列进行 Join，原因前面在 Runtime Filter 的时候也介绍了，Key 列在延迟物化上能起到一个比较好的效果。
- 第三点：大表之间的 Join，尽量让它 Colocation，因为大表之间的网络开销是很大的，如果需要去做 Shuffle 的话，代价是很高的。

- 第四点：合理的使用 Runtime Filter，它在 Join 过滤率高的场景下效果是非常显著的。但是它并不是万灵药，而是有一定副作用的，所以需要根据具体的 SQL 的粒度做开关。
- 最后：要涉及到多表 Join 的时候，需要去判断 Join 的合理性。尽量保证左表为大表，右表为小表，然后 Hash Join 会优于 Nest Loop Join。必要的时可以通过 SQL Rewrite，利用 Hint 去调整 Join 的顺序。

# Bucket Shuffle Join

---

## Bucket Shuffle Join

Bucket Shuffle Join 是在 Doris 0.14 版本中正式加入的新功能。旨在为某些 Join 查询提供本地性优化，来减少数据在节点间的传输耗时，来加速查询。

它的设计、实现和效果可以参阅 [ISSUE 4394](#)。

### 名词解释

- 左表：Join 查询时，左边的表。进行 Probe 操作。可被 Join Reorder 调整顺序。
- 右表：Join 查询时，右边的表。进行 Build 操作。可被 Join Reorder 调整顺序。


### 原理

Doris 支持的常规分布式 Join 方式包括了 shuffle join 和 broadcast join。这两种 join 都会导致不小的网络开销：

举个例子，当前存在 A 表与 B 表的 Join 查询，它的 Join 方式为 HashJoin，不同 Join 类型的开销如下：

- **Broadcast Join:** 如果根据数据分布，查询规划出 A 表有 3 个执行的 HashJoinNode，那么需要将 B 表全量的发送到 3 个 HashJoinNode，那么它的网络开销是 3B，它的内存开销也是 3B。
- **Shuffle Join:** Shuffle Join 会将 A, B 两张表的数据根据哈希计算分散到集群的节点之中，所以它的网络开销为 A + B，内存开销为 B。

在 FE 之中保存了 Doris 每个表的数据分布信息，如果 join 语句命中了表的数据分布列，我们应该使用数据分布信息来减少 join 语句的网络与内存开销，这就是 Bucket Shuffle Join 的思路来源。



Shuffle Join.png

上面的图片展示了 Bucket Shuffle Join 的工作原理。SQL 语句为 A 表 join B 表，并且 join 的等值表达式命中了 A 的数据分布列。而 Bucket Shuffle Join 会根据 A 表的数据分布信息，将 B 表的数据发送到对应的 A 表的数据存储计算节点。Bucket Shuffle Join 开销如下：

- 网络开销：  $B < \min(3B, A + B)$
- 内存开销：  $B \leq \min(3B, B)$

可见，相比于 Broadcast Join 与 Shuffle Join，Bucket Shuffle Join 有着较为明显的性能优势。减少数据在节点间的传输耗时和 Join 时的内存开销。相对于 Doris 原有的 Join 方式，它有着下面的优点

- 首先，Bucket-Shuffle-Join 降低了网络与内存开销，使一些 Join 查询具有了更好的性能。尤其是当 FE 能够执行左表的分区裁剪与桶裁剪时。
- 其次，同时与 Colocate Join 不同，它对于表的数据分布方式并没有侵入性，这对于用户来说是透明的。对于表的数据分布没有强制性的要求，不容易导致数据倾斜的问题。
- 最后，它可以为 Join Reorder 提供更多可能的优化空间。

## 使用方式

### 设置 Session 变量

将 session 变量 `enable_bucket_shuffle_join` 设置为 `true`，则 FE 在进行查询规划时就会默认将能够转换为 Bucket Shuffle Join 的查询自动规划为 Bucket Shuffle Join。

```
set enable_bucket_shuffle_join = true;
```

在 FE 进行分布式查询规划时，优先选择的顺序为 Colocate Join -> Bucket Shuffle Join -> Broadcast Join -> Shuffle Join。但是如果用户显式 hint 了 Join 的类型，如：

```
select * from test join [shuffle] baseall on test.k1 = baseall.k1;
```

则上述的选择优先顺序则不生效。

该 session 变量在 0.14 版本默认为true, 而 0.13 版本需要手动设置为true。

## 查看 Join 的类型

可以通过explain命令来查看 Join 是否为 Bucket Shuffle Join：

```
| 2:HASH JOIN
|
| | join op: INNER JOIN (BUCKET_SHUFFLE)
|
| | hash predicates:
|
| | colocate: false, reason: table not in the same group
|
| | equal join conjunct: `test`.`k1` = `baseall`.`k1`
```

在 Join 类型之中会指明使用的 Join 方式为：BUCKET\_SHUFFLE。

## Bucket Shuffle Join 的规划规则

在绝大多数场景之中，用户只需要默认打开 session 变量的开关就可以透明的使用这种 Join 方式带来的性能提升，但是如果了解 Bucket Shuffle Join 的规划规则，可以帮助我们利用它写出更加高效的 SQL。

- Bucket Shuffle Join 只生效于 Join 条件为等值的场景，原因与 Colocate Join 类似，它们都依赖 hash 来计算确定的数据分布。
- 在等值 Join 条件之中包含两张表的分桶列，当左表的分桶列为等值的 Join 条件时，它有很大概率会被规划为 Bucket Shuffle Join。
- 由于不同的数据类型的 hash 值计算结果不同，所以 Bucket Shuffle Join 要求左表的分桶列的类型与右表等值 join 列的类型需要保持一致，否则无法进行对应的规划。
- Bucket Shuffle Join 只作用于 Doris 原生的 OLAP 表，对于 ODBC，MySQL，ES 等外表，当其作为左表时是无法规划生效的。
- 对于分区表，由于每一个分区的数据分布规则可能不同，所以 Bucket Shuffle Join 只能保证左表为单分区时生效。所以在 SQL 执行之中，需要尽量使用where条件使分区裁剪的策略能够生效。
- 假如左表为 Colocate 的表，那么它每个分区的数据分布规则是确定的，Bucket Shuffle Join 能在 Colocate 表上表现更好。

# Colocation Join

Colocation Join 是在 Doris 0.9 版本中引入的新功能。旨在为某些 Join 查询提供本地性优化，来减少数据在节点间的传输耗时，加速查询。

最初的设计、实现和效果可以参阅 [ISSUE 245](#)。

Colocation Join 功能经过一次改版，设计和使用方式和最初设计稍有不同。本文档主要介绍 Colocation Join 的原理、实现、使用方式和注意事项。

注意：这个属性不会被 CCR 同步，如果这个表是被 CCR 复制而来的，即 PROPERTIES 中包含 `is_being_synced = true` 时，这个属性将会在这个表中被擦除。

## 名词解释

- Colocation Group (CG)：一个 CG 中会包含一张及以上的 Table。在同一个 Group 内的 Table 有着相同的 Colocation Group Schema，并且有着相同的数据分片分布。
- Colocation Group Schema (CGS)：用于描述一个 CG 中的 Table，和 Colocation 相关的通用 Schema 信息。包括分桶列类型，分桶数以及副本数等。

## 原理

Colocation Join 功能，是将一组拥有相同 CGS 的 Table 组成一个 CG。并保证这些 Table 对应的数据分片会落在同一个 BE 节点上。使得当 CG 内的表进行分桶列上的 Join 操作时，可以通过直接进行本地数据 Join，减少数据在节点间的传输耗时。

一个表的数据，最终会根据分桶列值 Hash、对桶数取模的后落在某一个分桶内。假设一个 Table 的分桶数为 8，则共有 [0, 1, 2, 3, 4, 5, 6, 7] 8 个分桶 (Bucket)，我们称这样一个序列为一个 BucketsSequence。每个 Bucket 内会有一个或多个数据分片 (Tablet)。当表为单分区表时，一个 Bucket 内仅有一个 Tablet。如果是多分区表，则会有多个。

为了使得 Table 能够有相同的数据分布，同一 CG 内的 Table 必须保证以下属性相同：

### 1. 分桶列和分桶数

分桶列，即在建表语句中 `DISTRIBUTED BY HASH(col1, col2, ...)` 中指定的列。分桶列决定了一张表的数据通过哪些列的值进行 Hash 划分到不同的 Tablet 中。同一 CG 内的 Table 必须保证分桶列的类型和数量完全一致，并且桶数一致，才能保证多张表的数据分片能够一一对应的进行分布控制。

### 2. 副本数

同一个 CG 内所有表的所有分区 (Partition) 的副本数必须一致。如果不一致，可能出现某一个 Tablet 的某一个副本，在同一个 BE 上没有其他的表分片的副本对应。

同一个 CG 内的表，分区的个数、范围以及分区列的类型不要求一致。

在固定了分桶列和分桶数后，同一个 CG 内的表会拥有相同的 BucketsSequence。而副本数决定了每个分桶内的 Tablet 的多个副本，存放在哪些 BE 上。假设 BucketsSequence 为 [0, 1, 2, 3, 4, 5, 6, 7]，BE 节点



有 [A, B, C, D] 4 个。则一个可能的数据分布如下：

0	1	2	3	4	5	6	7
A	B	C	D	A	B	C	D
B	C	D	A	B	C	D	A
C	D	A	B	C	D	A	B

CG 内所有表的数据都会按照上面的规则进行统一分布，这样就保证了，分桶列值相同的数据都在同一个 BE 节点上，可以进行本地数据 Join。

## 使用方式

### 建表

建表时，可以在 PROPERTIES 中指定属性 "colocate\_with" = "group\_name"，表示这个表是一个 Colocation Join 表，并且归属于一个指定的 Colocation Group。

示例：

```
CREATE TABLE tbl (k1 int, v1 int sum)
DISTRIBUTED BY HASH(k1)
BUCKETS 8
PROPERTIES(
 "colocate_with" = "group1"
);
```

如果指定的 Group 不存在，则 Doris 会自动创建一个只包含当前这张表的 Group。如果 Group 已存在，则 Doris 会检查当前表是否满足 Colocation Group Schema。如果满足，则会创建该表，并将该表加入 Group。同时，表会根据已存在的 Group 中的数据分布规则创建分片和副本。Group 归属于一个 Database，Group 的名字在一个 Database 内唯一。在内部存储是 Group 的全名为 dbId\_groupName，但用户只感知 groupName。

### 2.0 版本中，Doris 支持了跨 Database 的 Group。

在建表时，需使用关键词 \_\_global\_\_ 作为 Group 名称的前缀。如：

```
CREATE TABLE tbl (k1 int, v1 int sum)
DISTRIBUTED BY HASH(k1)
BUCKETS 8
PROPERTIES(
 "colocate_with" = "__global__group1"
);
```

\_\_global\_\_ 前缀的 Group 不再归属于一个 Database，其名称也是全局唯一的。

通过创建 Global Group，可以实现跨 Database 的 Colocate Join。

## 删表

当 Group 中最后一张表彻底删除后（彻底删除是指从回收站中删除。通常，一张表通过 DROP TABLE 命令删除后，会在回收站默认停留一天的时间后，再删除），该 Group 也会被自动删除。

## 查看 Group

以下命令可以查看集群内已存在的 Group 信息。

```
SHOW PROC '/colocation_group';
```

GroupId	GroupName	TableIds	BucketsNum	ReplicationNum	DistCols	IsStable
10005.10008	10005_group1	10007, 10040	10	3	int(11)	true

- GroupId：一个 Group 的全集群唯一标识，前半部分为 db id，后半部分为 group id。
- GroupName：Group 的全名。
- TableIds：该 Group 包含的 Table 的 id 列表。
- BucketsNum：分桶数。
- ReplicationNum：副本数。
- DistCols：Distribution columns，即分桶列类型。
- IsStable：该 Group 是否稳定（稳定的定义，见 Colocation 副本均衡和修复 一节）。

通过以下命令可以进一步查看一个 Group 的数据分布情况：

```
SHOW PROC '/colocation_group/10005.10008';
```

BucketIndex	BackendIds
0	10004, 10002, 10001
1	10003, 10002, 10004
2	10002, 10004, 10001
3	10003, 10002, 10004
4	10002, 10004, 10003
5	10003, 10002, 10001
6	10003, 10004, 10001
7	10003, 10004, 10002

- BucketIndex：分桶序列的下标。
- BackendIds：分桶中数据分片所在的 BE 节点 id 列表。

以上命令需要 **ADMIN** 权限。暂不支持普通用户查看。

## 修改表 Colocate Group 属性

可以对一个已经创建的表，修改其 Colocation Group 属性。示例：

```
ALTER TABLE tbl SET ("colocate_with" = "group2");
```

- 如果该表之前没有指定过 Group，则该命令检查 Schema，并将该表加入到该 Group（Group 不存在则会创建）。
- 如果该表之前有指定其他 Group，则该命令会先将该表从原有 Group 中移除，并加入新 Group（Group 不存在则会创建）。

也可以通过以下命令，删除一个表的 Colocation 属性：

```
ALTER TABLE tbl SET ("colocate_with" = "");
```

## 其他相关操作

当对一个具有 Colocation 属性的表进行增加分区（ADD PARTITION）、修改副本数时，Doris 会检查修改是否会违反 Colocation Group Schema，如果违反则会拒绝。

## Colocation 副本均衡和修复

Colocation 表的副本分布需要遵循 Group 中指定的分布，所以在副本修复和均衡方面和普通分片有所区别。

Group 自身有一个 Stable 属性，当 Stable 为 true 时，表示当前 Group 内的表的所有分片没有正在进行变动，Colocation 特性可以正常使用。当 Stable 为 false 时（Unstable），表示当前 Group 内有部分表的分片正在做修复或迁移，此时，相关表的 Colocation Join 将退化为普通 Join。

### 副本修复

副本只能存储在指定的 BE 节点上。所以当某个 BE 不可用时（宕机、Decommission 等），需要寻找一个新的 BE 进行替换。Doris 会优先寻找负载最低的 BE 进行替换。替换后，该 Bucket 内的所有在旧 BE 上的数据分片都要做修复。迁移过程中，Group 被标记为 Unstable。

### 副本均衡

Doris 会尽力将 Colocation 表的分片均匀分布在所有 BE 节点上。对于普通表的副本均衡，是以单副本为粒度的，即单独为每一个副本寻找负载较低的 BE 节点即可。而 Colocation 表的均衡是 Bucket 级别的，即一个 Bucket 内的所有副本都会一起迁移。我们采用一个简单的均衡算法，即在不考虑副本实际大小，而只根据副本数量，将 BucketsSequence 均匀的分布在所有 BE 上。具体算法可以参阅 ColocateTableBalancer.java 中的代码注释。

- 注 1：当前的 Colocation 副本均衡和修复算法，对于异构部署的 Doris 集群效果可能不佳。所谓异构部署，即 BE 节点的磁盘容量、数量、磁盘类型（SSD 和 HDD）不一致。在异构部署情况下，可能出现小容量的 BE 节点和大容量的 BE 节点存储了相同的副本数量。

- 注 2：当一个 Group 处于 Unstable 状态时，其中的表的 Join 将退化为普通 Join。此时可能会极大降低集群的查询性能。如果不希望系统自动均衡，可以设置 FE 的配置项 `disable_colocate_balance` 来禁止自动均衡。然后在合适的时间打开即可。（具体参阅 高级操作 一节）

## 查询

对 Colocation 表的查询方式和普通表一样，用户无需感知 Colocation 属性。如果 Colocation 表所在的 Group 处于 Unstable 状态，将自动退化为普通 Join。

举例说明：

表 1：

```
CREATE TABLE `tbl1` (
 `k1` date NOT NULL COMMENT "",
 `k2` int(11) NOT NULL COMMENT "",
 `v1` int(11) SUM NOT NULL COMMENT ""
) ENGINE=OLAP
AGGREGATE KEY(`k1`, `k2`)
PARTITION BY RANGE(`k1`)
(
 PARTITION p1 VALUES LESS THAN ('2019-05-31'),
 PARTITION p2 VALUES LESS THAN ('2019-06-30')
)
DISTRIBUTED BY HASH(`k2`) BUCKETS 8
PROPERTIES (
 "colocate_with" = "group1"
);
```

表 2：

```
CREATE TABLE `tbl2` (
 `k1` datetime NOT NULL COMMENT "",
 `k2` int(11) NOT NULL COMMENT "",
 `v1` double SUM NOT NULL COMMENT ""
) ENGINE=OLAP
AGGREGATE KEY(`k1`, `k2`)
DISTRIBUTED BY HASH(`k2`) BUCKETS 8
PROPERTIES (
 "colocate_with" = "group1"
);
```

查看查询计划：

```
DESC SELECT * FROM tbl1 INNER JOIN tbl2 ON (tbl1.k2 = tbl2.k2);

+-----+
| Explain String |
+-----+
| PLAN FRAGMENT 0 |
| OUTPUT EXPRS: `tbl1`.`k1` |
| PARTITION: RANDOM |
| |
| RESULT SINK |
| |
```

```

| 2:HASH JOIN
| | join op: INNER JOIN
| | hash predicates:
| | colocate: true
| | `tbl1`.`k2` = `tbl2`.`k2`
| | tuple ids: 0 1
| |
| |----1:OlapScanNode
| | TABLE: tbl2
| | PREAGGREGATION: OFF. Reason: null
| | partitions=0/1
| | rollup: null
| | buckets=0/0
| | cardinality=-1
| | avgRowSize=0.0
| | numNodes=0
| | tuple ids: 1
| |
| 0:OlapScanNode
| TABLE: tbl1
| PREAGGREGATION: OFF. Reason: No AggregateInfo
| partitions=0/2
| rollup: null
| buckets=0/0
| cardinality=-1
| avgRowSize=0.0
| numNodes=0
| tuple ids: 0
+-----+

```

如果 Colocation Join 生效，则 Hash Join 节点会显示 colocate: true。

如果没有生效，则查询计划如下：

```

+-----+
| Explain String
+-----+
| PLAN FRAGMENT 0
| OUTPUT EXPRS: `tbl1`.`k1` |
| PARTITION: RANDOM
|
| RESULT SINK
|
| 2:HASH JOIN
| | join op: INNER JOIN (BROADCAST)
| | hash predicates:
| | colocate: false, reason: group is not stable
| | `tbl1`.`k2` = `tbl2`.`k2`
| | tuple ids: 0 1
| |
| |----3:EXCHANGE
| | tuple ids: 1
| |
| 0:OlapScanNode
| TABLE: tbl1
| PREAGGREGATION: OFF. Reason: No AggregateInfo
| partitions=0/2
| rollup: null
| buckets=0/0
| cardinality=-1
| avgRowSize=0.0
| numNodes=0
| tuple ids: 0

```

```

| PLAN FRAGMENT 1
| OUTPUT EXPRS:
| PARTITION: RANDOM
|
| STREAM DATA SINK
| EXCHANGE ID: 03
| UNPARTITIONED
|
| 1:0lapScanNode
| TABLE: tbl2
| PREAGGREGATION: OFF. Reason: null
| partitions=0/1
| rollup: null
| buckets=0/0
| cardinality=-1
| avgRowSize=0.0
| numNodes=0
| tuple ids: 1
+-----+

```

HASH JOIN 节点会显示对应原因: `colocate: false, reason: group is not stable`。同时会有一个 EXCHANGE 节点生成。

## 高级操作

### FE 配置项

- `disable_colocate_relocate`

是否关闭 Doris 的自动 Colocation 副本修复。默认为 `false`，即不关闭。该参数只影响 Colocation 表的副本修复，不影响普通表。

- `disable_colocate_balance`

是否关闭 Doris 的自动 Colocation 副本均衡。默认为 `false`，即不关闭。该参数只影响 Colocation 表的副本均衡，不影响普通表。

以上参数可以动态修改，设置方式请参阅 `HELP ADMIN SHOW CONFIG;` 和 `HELP ADMIN SET CONFIG;`。

- `disable_colocate_join`

是否关闭 Colocation Join 功能。在 0.10 及之前的版本，默认为 `true`，即关闭。在之后的某个版本中将默认为 `false`，即开启。

- `use_new_tablet_scheduler`

在 0.10 及之前的版本中，新的副本调度逻辑与 Colocation Join 功能不兼容，所以在 0.10 及之前版本，如果 `disable_colocate_join = false`，则需设置 `use_new_tablet_scheduler = false`，即关闭新的副本调度器。之后的版本中，`use_new_tablet_scheduler` 将默认为 `true`。

### HTTP Restful API

Doris 提供了几个和 Colocation Join 有关的 HTTP Restful API，用于查看和修改 Colocation Group。

该 API 实现在 FE 端，使用 `fe_host:fe_http_port` 进行访问。需要 ADMIN 权限。

### 1. 查看集群的全部 Colocation 信息

```
GET /api/colocate
```

返回以 Json 格式表示内部 Colocation 信息。

```
{
 "msg": "success",
 "code": 0,
 "data": {
 "infos": [
 ["10003.12002", "10003_group1", "10037, 10043", "1", "1", "int(11)", "true"]
],
 "unstableGroupIds": [],
 "allGroupIds": [{
 "dbId": 10003,
 "grpId": 12002
 }]
 },
 "count": 0
}
```

### 2. 将 Group 标记为 Stable 或 Unstable

#### ◦ 标记为 Stable

```
POST /api/colocate/group_stable?db_id=10005&group_id=10008
```

返回: 200

#### ◦ 标记为 Unstable

```
DELETE /api/colocate/group_stable?db_id=10005&group_id=10008
```

返回: 200

### 3. 设置 Group 的数据分布

该接口可以强制设置某一 Group 的数分布。

```
POST /api/colocate/bucketseq?db_id=10005&group_id=10008
```

Body:

```
[[10004,10002],[10003,10002],[10002,10004],[10003,10002],[10002,10004],[10003,10002],[10003,10004],
[10003,10004],[10003,10004],[10002,10004]]
```

返回 200

其中 Body 是以嵌套数组表示的 BucketsSequence 以及每个 Bucket 中分片分布所在 BE 的 id。

注意，使用该命令，可能需要将 FE 的配置 `disable_colocate_relocate` 和 `disable_colocate_balance` 设为 true。即关闭系统自动的 Colocation 副本修复和均衡。否则可能在修改后，会被系统自动重置。

# Runtime Filter

## Runtime Filter

Runtime Filter 是在 Doris 0.15 版本中正式加入的新功能。旨在为某些 Join 查询在运行时动态生成过滤条件，来减少扫描的数据量，避免不必要的 I/O 和网络传输，从而加速查询。

它的设计、实现和效果可以参阅 [ISSUE 6116](#)。

### 名词解释

- 左表：Join 查询时，左边的表。进行 Probe 操作。可被 Join Reorder 调整顺序。
- 右表：Join 查询时，右边的表。进行 Build 操作。可被 Join Reorder 调整顺序。
- Fragment：FE 会将具体的 SQL 语句的执行转化为对应的 Fragment 并下发到 BE 进行执行。BE 上执行对应 Fragment，并将结果汇聚返回给 FE。
- Join on clause: A join B on A.a=B.b 中的 A.a=B.b，在查询规划时基于此生成 join conjuncts，包含 join Build 和 Probe 使用的 expr，其中 Build expr 在 Runtime Filter 中称为 src expr，Probe expr 在 Runtime Filter 中称为 target expr。


### 原理

Runtime Filter 在查询规划时生成，在 HashJoinNode 中构建，在 ScanNode 中应用。


举个例子，当前存在 T1 表与 T2 表的 Join 查询，它的 Join 方式为 HashJoin，T1 是一张事实表，数据行数为 100000，T2 是一张维度表，数据行数为 2000，Doris join 的实际情况是：



显而易见对 T2 扫描数据要远远快于 T1，如果我们主动等待一段时间再扫描 T1，等 T2 将扫描的数据记录交给 HashJoinNode 后，HashJoinNode 根据 T2 的数据计算出一个过滤条件，比如 T2 数据的最大和最小值，或者构建一个 Bloom Filter，接着将这个过滤条件发给等待扫描 T1 的 ScanNode，后者应用这个过滤条件，将过滤后的数据交给 HashJoinNode，从而减少 probe hash table 的次数和网络开销，这个过滤条件就是 Runtime Filter，效果如下：







如果能将过滤条件（Runtime Filter）下推到存储引擎，则某些情况下可以利用索引来直接减少扫描的数据量，从而大大减少扫描耗时，效果如下：



可见，和谓词下推、分区裁剪不同，Runtime Filter 是在运行时动态生成的过滤条件，即在查询运行时解析 join on clause 确定过滤表达式，并将表达式广播给正在读取左表的 ScanNode，从而减少扫描的数据量，进而减少 probe hash table 的次数，避免不必要的 I/O 和网络传输。

Runtime Filter 主要用于大表 join 小表的优化，如果左表的数据量太小，或者右表的数据量太大，则 Runtime Filter 可能不会取得预期效果。

## 使用方式

### Runtime Filter 查询选项

与 Runtime Filter 相关的查询选项信息，请参阅以下部分：

- 第一个查询选项是调整使用的 Runtime Filter 类型，大多数情况下，您只需要调整这一个选项，其他选项保持默认即可。
  - runtime\_filter\_type: 包括 Bloom Filter、MinMax Filter、IN predicate、IN Or Bloom Filter、Bitmap Filter，默认会使用 IN Or Bloom Filter，部分情况下同时使用 Bloom Filter、MinMax Filter、IN predicate 时性能更高。
- 其他查询选项通常仅在某些特定场景下，才需进一步调整以达到最优效果。通常只在性能测试后，针对资源密集型、运行耗时足够长且频率足够高的查询进行优化。
  - runtime\_filter\_mode: 用于调整 Runtime Filter 的下推策略，包括 OFF、LOCAL、GLOBAL 三种策略，默认设置为 GLOBAL 策略
  - runtime\_filter\_wait\_time\_ms: 左表的 ScanNode 等待每个 Runtime Filter 的时间，默认 1000ms
  - runtime\_filters\_max\_num: 每个查询可应用的 Runtime Filter 中 Bloom Filter 的最大数量，默认 10
  - runtime\_bloom\_filter\_min\_size: Runtime Filter 中 Bloom Filter 的最小长度，默认 1048576 (1M)

- `runtime_bloom_filter_max_size`: Runtime Filter 中 Bloom Filter 的最大长度, 默认 16777216 (16M)
- `runtime_bloom_filter_size`: Runtime Filter 中 Bloom Filter 的默认长度, 默认 2097152 (2M)
- `runtime_filter_max_in_num`: 如果 join 右表数据行数大于这个值, 我们将不生成 IN predicate, 默认 1024

下面对查询选项做进一步说明。

## 1. runtime\_filter\_type

使用的 Runtime Filter 类型。

**类型:** 数字 (1, 2, 4, 8, 16) 或者相对应的助记符字符串 (IN, BLOOM\_FILTER, MIN\_MAX, IN\_OR\_BLOOM\_FILTER, BITMAP\_FILTER), 默认 8(IN\_OR\_BLOOM\_FILTER), 使用多个时用逗号分隔, 注意需要加引号, 或者将任意多个类型的数字相加, 例如:

```
set runtime_filter_type="BLOOM_FILTER,IN,MIN_MAX";
```

等价于:

```
set runtime_filter_type=7;
```

## 使用注意事项

- **IN or Bloom Filter:** 根据右表在执行过程中的真实行数, 由系统自动判断使用 IN predicate 还是 Bloom Filter
  - 默认在右表数据行数少于 102400 时会使用 IN predicate (可通过 session 变量中的 `runtime_filter_max_in_num` 调整), 否则使用 Bloom filter。
- **Bloom Filter:** 有一定的误判率, 导致过滤的数据比预期少一点, 但不会导致最终结果不准确, 在大部分情况下 Bloom Filter 都可以提升性能或对性能没有显著影响, 但在部分情况下会导致性能降低。
  - Bloom Filter 构建和应用的开销较高, 所以当过滤率较低时, 或者左表数据量较少时, Bloom Filter 可能会导致性能降低。
  - 目前只有左表的 Key 列应用 Bloom Filter 才能下推到存储引擎, 而测试结果显示 Bloom Filter 不下推到存储引擎时往往会导致性能降低。
  - 目前 Bloom Filter 仅在 ScanNode 上使用表达式过滤时有短路 (short-circuit) 逻辑, 即当假阳性率过高时, 不继续使用 Bloom Filter, 但当 Bloom Filter 下推到存储引擎后没有短路逻辑, 所以当过滤率较低时可能导致性能降低。
- **MinMax Filter:** 包含最大值和最小值, 从而过滤小于最小值和大于最大值的数据, MinMax Filter 的过滤效果与 join on clause 中 Key 列的类型和左右表数据分布有关。
  - 当 join on clause 中 Key 列的类型为 int/bigint/double 等时, 极端情况下, 如果左右表的最大最小值相同则没有效果, 反之右表最大值小于左表最小值, 或右表最小值大于左表最大值, 则效果最好。

- 当 join on clause 中 Key 列的类型为 varchar 等时，应用 MinMax Filter 往往会导致性能降低。
- **IN predicate:** 根据 join on clause 中 Key 列在右表上的所有值构建 IN predicate，使用构建的 IN predicate 在左表上过滤，相比 Bloom Filter 构建和应用的开销更低，在右表数据量较少时往往性能更高。
  - 目前 IN predicate 已实现合并方法。
  - 当同时指定 In predicate 和其他 filter，并且 in 的过滤数值没达到 runtime\_filter\_max\_in\_num 时，会尝试把其他 filter 去除掉。原因是 In predicate 是精确的过滤条件，即使没有其他 filter 也可以高效过滤，如果同时使用则其他 filter 会做无用功。目前仅在 Runtime filter 的生产者和消费者处于同一个 fragment 时才会有去除非 in filter 的逻辑。
- **Bitmap Filter:**
  - 当前仅当 [in subquery](#) 操作中的子查询返回 bitmap 列时会使用 bitmap filter。

## 2. runtime\_filter\_mode

用于控制 Runtime Filter 在 instance 之间传输的范围。

类型: 数字 (0, 1, 2) 或者相对应的助记符字符串 (OFF, LOCAL, GLOBAL)，默认 2(GLOBAL)。

### 使用注意事项

LOCAL: 相对保守，构建的 Runtime Filter 只能在同一个 instance（查询执行的最小单元）上同一个 Fragment 中使用，即 Runtime Filter 生产者（构建 Filter 的 HashJoinNode）和消费者（使用 RuntimeFilter 的 ScanNode）在同一个 Fragment，比如 broadcast join 的一般场景；

GLOBAL: 相对激进，除满足 LOCAL 策略的场景外，还可以将 Runtime Filter 合并后通过网络传输到不同 instance 上的不同 Fragment 中使用，比如 Runtime Filter 生产者和消费者在不同 Fragment，比如 shuffle join。

大多数情况下 GLOBAL 策略可以在更广泛的场景对查询进行优化，但在有些 shuffle join 中生成和合并 Runtime Filter 的开销超过给查询带来的性能优势，可以考虑更改为 LOCAL 策略。

如果集群中涉及的 join 查询不会因为 Runtime Filter 而提高性能，您可以将设置更改为 OFF，从而完全关闭该功能。

在不同 Fragment 上构建和应用 Runtime Filter 时，需要合并 Runtime Filter 的原因和策略可参阅 [ISSUE 6116\(opens new window\)](#)。

## 3. runtime\_filter\_wait\_time\_ms

Runtime Filter 的等待耗时。

类型: 整数，默认 1000，单位 ms

### 使用注意事项

在开启 Runtime Filter 后，左表的 ScanNode 会为每一个分配给自己的 Runtime Filter 等待一段时间再扫描数据，即如果 ScanNode 被分配了 3 个 Runtime Filter，那么它最多会等待 3000ms。

因为 Runtime Filter 的构建和合并均需要时间，ScanNode 会尝试将等待时间内到达的 Runtime Filter 下推到存储引擎，如果超过等待时间后，ScanNode 会使用已经到达的 Runtime Filter 直接开始扫描数据。

如果 Runtime Filter 在 ScanNode 开始扫描之后到达，则 ScanNode 不会将该 Runtime Filter 下推到存储引擎，而是对已经从存储引擎扫描上来的数据，在 ScanNode 上基于该 Runtime Filter 使用表达式过滤，之前已经扫描的数据则不会应用该 Runtime Filter，这样得到的中间数据规模会大于最优解，但可以避免严重的裂化。

如果集群比较繁忙，并且集群上有许多资源密集型或长耗时的查询，可以考虑增加等待时间，以避免复杂查询错过优化机会。如果集群负载较轻，并且集群上有许多只需要几秒的小查询，可以考虑减少等待时间，以避免每个查询增加 1s 的延迟。

#### 4. runtime\_filters\_max\_num

每个查询生成的 Runtime Filter 中 Bloom Filter 数量的上限。

**类型:** 整数，默认 10

**使用注意事项** 目前仅对 Bloom Filter 的数量进行限制，因为相比 MinMax Filter 和 IN predicate，Bloom Filter 构建和应用的代价更高。

如果生成的 Bloom Filter 超过允许的最大数量，则保留选择性大的 Bloom Filter，选择性大意味着预期可以过滤更多的行。这个设置可以防止 Bloom Filter 耗费过多的内存开销而导致潜在的问题。

选择性=(HashJoinNode Cardinality / HashJoinNode left child Cardinality)  
-- 因为目前 FE 拿到 Cardinality 不准，所以这里 Bloom Filter 计算的选择性与实际不准，因此最终可能只是随机保留了部分 Bloom Filter。

仅在对涉及大表间 join 的某些长耗时查询进行调优时，才需要调整此查询选项。

#### 5. Bloom Filter 长度相关参数

包括runtime\_bloom\_filter\_min\_size、runtime\_bloom\_filter\_max\_size、runtime\_bloom\_filter\_size，用于确定 Runtime Filter 使用的 Bloom Filter 数据结构的大小（以字节为单位）。

**类型:** 整数

**使用注意事项** 因为需要保证每个 HashJoinNode 构建的 Bloom Filter 长度相同才能合并，所以目前在 FE 查询规划时计算 Bloom Filter 的长度。

如果能拿到 join 右表统计信息中的数据行数 (Cardinality)，会尝试根据 Cardinality 估计 Bloom Filter 的最佳大小，并四舍五入到最接近的 2 的幂 (以 2 为底的 log 值)。如果无法拿到右表的 Cardinality，则会使用默认的 Bloom Filter 长度runtime\_bloom\_filter\_size。runtime\_bloom\_filter\_min\_size和runtime\_bloom\_filter\_max\_size用于限制最终使用的 Bloom Filter 长度最小和最大值。

更大的 Bloom Filter 在处理高基数的输入集时更有效，但需要消耗更多的内存。假如查询中需要过滤高基数列（比如含有数百万个不同的取值），可以考虑增加runtime\_bloom\_filter\_size的值进行一些基准测试，这有助于使 Bloom Filter 过滤的更加精准，从而获得预期的性能提升。

Bloom Filter 的有效性取决于查询的数据分布，因此通常仅对一些特定查询额外调整其 Bloom Filter 长度，而不是全局修改，一般仅在对涉及大表间 join 的某些长耗时查询进行调优时，才需要调整此查询选项。

## 查看 query 生成的 Runtime Filter

explain命令可以显示的查询计划中包括每个 Fragment 使用的 join on clause 信息，以及 Fragment 生成和使用 Runtime Filter 的注释，从而确认是否将 Runtime Filter 应用到了期望的 join on clause 上。

- 生成 Runtime Filter 的 Fragment 包含的注释例如runtime filters: filter\_id[type] <- table.column。
- 使用 Runtime Filter 的 Fragment 包含的注释例如runtime filters: filter\_id[type] -> table.column。

下面例子中的查询使用了一个 ID 为 RF000 的 Runtime Filter。

```
CREATE TABLE test (t1 INT) DISTRIBUTED BY HASH (t1) BUCKETS 2 PROPERTIES("replication_num" = "1");
INSERT INTO test VALUES (1), (2), (3), (4);

CREATE TABLE test2 (t2 INT) DISTRIBUTED BY HASH (t2) BUCKETS 2 PROPERTIES("replication_num" = "1");
INSERT INTO test2 VALUES (3), (4), (5);
```

```
EXPLAIN SELECT t1 FROM test JOIN test2 where test.t1 = test2.t2;
```

```
+-----+
| Explain String |
+-----+
| PLAN FRAGMENT 0 |
| OUTPUT EXPRS: `t1` |
| | |
| 4:EXCHANGE |
| | |
| PLAN FRAGMENT 1 |
| OUTPUT EXPRS: |
| PARTITION: HASH_PARTITIONED: `default_cluster:ssb`.`test`.`t1` |
| | |
| 2:HASH JOIN |
| | join op: INNER JOIN (BUCKET_SHUFFLE) |
| | equal join conjunct: `test`.`t1` = `test2`.`t2` |
| | runtime filters: RF000[in] <- `test2`.`t2` |
| | |
| |-----3:EXCHANGE |
| | |
| 0:OlapScanNode |
| TABLE: test |
| runtime filters: RF000[in] -> `test`.`t1` |
| | |
| PLAN FRAGMENT 2 |
| OUTPUT EXPRS: |
| PARTITION: HASH_PARTITIONED: `default_cluster:ssb`.`test2`.`t2` |
| | |
| 1:OlapScanNode |
| TABLE: test2 |
+-----+
```

```
-- 上面`runtime filters`的行显示了`PLAN FRAGMENT 1`的`2:HASH JOIN`生成了 ID 为 RF000 的 IN predicate,
-- 其中`test2`.`t2`的 key values 仅在运行时可知,
-- 在`0:OlapScanNode`使用了该 IN predicate 用于在读取`test`.`t1`时过滤不必要的数据库。
```

```
SELECT t1 FROM test JOIN test2 where test.t1 = test2.t2;
```

```
-- 返回 2 行结果 [3, 4];
```

```
-- 通过 query 的 profile (set enable_profile=true;) 可以查看查询内部工作的详细信息,
```

```
-- 包括每个 Runtime Filter 是否下推、等待耗时、以及 OLAP_SCAN_NODE 从 prepare 到接收到 Runtime Filter 的总时长。
```

```
RuntimeFilter:in:
```

```
- HasPushDownToEngine: true
```

```
- AwaitTimeCost: 0ns
- EffectTimeCost: 2.76ms
```

-- 此外, 在 profile 的 OLAP\_SCAN\_NODE 中还可以查看 Runtime Filter 下推后的过滤效果和耗时。

```
- RowsVectorPredFiltered: 9.320008M (9320008)
- VectorPredEvalTime: 364.39ms
```

## Runtime Filter 的规划规则

1. 只支持对 join on clause 中的等值条件生成 Runtime Filter, 不包括 Null-safe 条件, 因为其可能会过滤掉 join 左表的 null 值。
2. 不支持将 Runtime Filter 下推到 left outer、full outer、anti join 的左表;
3. 不支持 src expr 或 target expr 是常量;
4. 不支持 src expr 和 target expr 相等;
5. 不支持 src expr 的类型等于 HLL 或者 BITMAP;
6. 目前仅支持将 Runtime Filter 下推给 OlapScanNode;
7. 不支持 target expr 包含 NULL-checking 表达式, 比如 COALESCE/IFNULL/CASE, 因为当 outer join 上层其他 join 的 join on clause 包含 NULL-checking 表达式并生成 Runtime Filter 时, 将这个 Runtime Filter 下推到 outer join 的左表时可能导致结果不正确;
8. 不支持 target expr 中的列 (slot) 无法在原始表中找到某个等价列;
9. 不支持列传导, 这包含两种情况:
  - 一是例如 join on clause 包含  $A.k = B.k$  and  $B.k = C.k$  时, 目前  $C.k$  只可以下推给  $B.k$ , 而不可以下推给  $A.k$ ;
  - 二是例如 join on clause 包含  $A.a + B.b = C.c$ , 如果  $A.a$  可以列传导到  $B.a$ , 即  $A.a$  和  $B.a$  是等价的列, 那么可以用  $B.a$  替换  $A.a$ , 然后可以尝试将 Runtime Filter 下推给  $B$  (如果  $A.a$  和  $B.a$  不是等价列, 则不能下推给  $B$ , 因为 target expr 必须与唯一一个 join 左表绑定);
10. Target expr 和 src expr 的类型必须相等, 因为 Bloom Filter 基于 hash, 若类型不等则会尝试将 target expr 的类型转换为 src expr 的类型;
11. 不支持 PlanNode.Conjuncts 生成的 Runtime Filter 下推, 与 HashJoinNode 的 eqJoinConjuncts 和 otherJoinConjuncts 不同, PlanNode.Conjuncts 生成的 Runtime Filter 在测试中发现可能会导致错误的结果, 例如 IN 子查询转换为 join 时, 自动生成的 join on clause 将保存在 PlanNode.Conjuncts 中, 此时应用 Runtime Filter 可能会导致结果缺少一些行。

# Join Hint

## Doris 2.0.4 版本之后支持 Join Hint 功能

### 背景

在数据库中，“Hint”是一种用于指导查询优化器执行计划的指令。通过在 SQL 语句中嵌入 Hint，可以影响优化器的决策，以选中期望的执行路径。以下是一个使用 Hint 的背景示例：假设有一个包含大量数据的表，而你知道在某些特定情况下，在一个查询中，表的连接顺序可能会影响查询性能。Leading Hint 允许你指定希望优化器遵循的表连接的顺序。

例如，考虑以下 SQL 查询：

```
mysql> explain shape plan select * from t1 join t2 on t1.c1 = c2;
+-----+
| Explain String |
+-----+
| PhysicalResultSink |
| --PhysicalDistribute |
| ----PhysicalProject |
| -----hashJoin[INNER_JOIN] (t1.c1 = t2.c2) |
| -----PhysicalOlapScan[t2] |
| -----PhysicalDistribute |
| -----PhysicalOlapScan[t1] |
+-----+
7 rows in set (0.06 sec)
```

在上述例子里面，在执行效率不理想的时候，我们希望调整下 join 顺序而不改变原始 sql 以免影响到用户原始场景且能达到调优的目的。我们可以使用 leading 任意改变 t1 和 t2 的 join 顺序。例如可以写成：

```
mysql> explain shape plan select /*+ leading(t2 t1) */ * from t1 join t2 on c1 = c2;
+-----+
| Explain String(Nereids Planner) |
+-----+
| PhysicalResultSink |
| --PhysicalDistribute |
| ----PhysicalProject |
| -----hashJoin[INNER_JOIN] hashCondition=((t1.c1 = t2.c2)) otherCondition=() build RFs:RF0 c1->[c2] |
| -----PhysicalOlapScan[t2] apply RFs: RF0 |
| -----PhysicalDistribute |
| -----PhysicalOlapScan[t1] |
| |
| Hint log: |
| Used: leading(t2 t1) |
| Unused: |
| SyntaxError: |
+-----+
12 rows in set (0.06 sec)
```

在这个例子中，使用了 `/+ leading(t2 t1) /` 这个 Hint。这个 Hint 告诉优化器在执行计划中使用指定表（t2）作为驱动表，并置于（t1）之前。本文主要阐述如何在 Doris 里面使用 join 相关的 hint：leading hint、ordered hint 和 distribute hint

## Leading hint 使用说明

Leading Hint 用于指导优化器确定查询计划的连接顺序。在一个查询中，表的连接顺序可能会影响查询性能。

Leading Hint 允许你指定希望优化器遵循的表连接的顺序。

在 doris 里面，其语法为 `/+LEADING( tablespec [ tablespec ]... ) /`，leading 由 `"/+“和”/“` 包围并置于 select 语句里面 select 的正后方。

注意，leading 后方的 `'` 和 selectlist 需要隔开至少一个分割符例如空格。至少需要写两个以上的表才认为这个 leadinghint 是合理的。且任意的 join 里面可以用大括号括号起来，来显式地指定 joinTree 的形状。例：

```
mysql> explain shape plan select /*+ leading(t2 t1) */ * from t1 join t2 on c1 = c2;
+-----+
| Explain String(Nereids Planner) |
+-----+
| PhysicalResultSink |
| --PhysicalDistribute[DistributionSpecGather] |
| ----PhysicalProject |
| -----hashJoin[INNER_JOIN] hashCondition=((t1.c1 = t2.c2)) otherCondition=() |
| -----PhysicalOlapScan[t2] |
| -----PhysicalDistribute[DistributionSpecHash] |
| -----PhysicalOlapScan[t1] |
| |
| Hint log: |
| Used: leading(t2 t1) |
| Unused: |
| SyntaxError: |
+-----+
12 rows in set (0.01 sec)
```

- 当 leadinghint 不生效的时候会走正常的流程生成计划，explain 会显示使用的 hint 是否生效，主要分三种来显示：
  - Used：leading hint 正常生效
  - Unused：这里不支持的情况包含 leading 指定的 join order 与原 sql 不等价或本版本暂不支持特性
  - SyntaxError：指 leading hint 语法错误，如找不到对应的表等
- leading hint 语法默认造出来左深树，例：select `/+ leading(t1 t2 t3) /` \* from t1 join t2 on...默认指定出来

```
 join
 / \
 join t3
 / \
 t1 t2
```

```
mysql> explain shape plan select /*+ leading(t1 t2 t3) */ * from t1 join t2 on c1 = c2 join t3 on c2=c3;
+-----+
| Explain String(Nereids Planner) |
+-----+
| PhysicalResultSink |
```



```

| --PhysicalDistribute[DistributionSpecGather]
| ----PhysicalProject
| -----hashJoin[INNER_JOIN] hashCondition=((t2.c2 = t3.c3)) otherCondition=()
| -----hashJoin[INNER_JOIN] hashCondition=((t1.c1 = t2.c2)) otherCondition=()
| -----PhysicalOlapScan[t1]
| -----PhysicalDistribute[DistributionSpecHash]
| -----PhysicalOlapScan[t2]
| -----PhysicalDistribute[DistributionSpecHash]
| -----PhysicalOlapScan[t3]
|
| Hint log:
| Used: leading(t1 t2 t3)
| UnUsed:
| SyntaxError:
+-----+
15 rows in set (0.00 sec)

```

- 同时允许使用大括号指定 join 树形状。例：`/*+ leading(t1 {t2 t3}) */ join /`  
`t1 join /`  
`t2 t3`

```

mysql> explain shape plan select /*+ leading(t1 {t2 t3}) */ * from t1 join t2 on c1 = c2 join t3 on c2=c3;
+-----+
| Explain String(Nereids Planner)
+-----+
| PhysicalResultSink
| --PhysicalDistribute[DistributionSpecGather]
| ----PhysicalProject
| -----hashJoin[INNER_JOIN] hashCondition=((t1.c1 = t2.c2)) otherCondition=()
| -----PhysicalOlapScan[t1]
| -----PhysicalDistribute[DistributionSpecHash]
| -----hashJoin[INNER_JOIN] hashCondition=((t2.c2 = t3.c3)) otherCondition=()
| -----PhysicalOlapScan[t2]
| -----PhysicalDistribute[DistributionSpecHash]
| -----PhysicalOlapScan[t3]
|
| Hint log:
| Used: leading(t1 { t2 t3 })
| UnUsed:
| SyntaxError:
+-----+
15 rows in set (0.02 sec)

```

- 当有 view 作为别名参与 joinReorder 的时候可以指定对应的 view 作为 leading 的参数。例：

```

mysql> explain shape plan select /*+ leading(alias t1) */ count(*) from t1 join (select c2 from t2 join t3 on
t2.c2 = t3.c3) as alias on t1.c1 = alias.c2;
+-----+
| Explain String(Nereids Planner)
+-----+
| PhysicalResultSink
| --hashAgg[GLOBAL]
| ----PhysicalDistribute[DistributionSpecGather]
| -----hashAgg[LOCAL]
| -----PhysicalProject
| -----hashJoin[INNER_JOIN] hashCondition=((t1.c1 = alias.c2)) otherCondition=()
| -----PhysicalProject
| -----hashJoin[INNER_JOIN] hashCondition=((t2.c2 = t3.c3)) otherCondition=()
| -----PhysicalProject
| -----PhysicalOlapScan[t2]
| -----PhysicalDistribute[DistributionSpecHash]

```

```

| -----PhysicalProject
| -----PhysicalOlapScan[t3]
| -----PhysicalDistribute[DistributionSpecHash]
| -----PhysicalProject
| -----PhysicalOlapScan[t1]
|
| Hint log:
| Used: leading(alias t1)
| Unused:
| SyntaxError:
+-----+
21 rows in set (0.06 sec)

```

## 基本用例

注意这里列命名和表命名相关，例：只有 **t1** 中有 **c1** 字段，后续例子为了简化会将 **t1.c1** 直接写成 **c1**

```

CREATE DATABASE testleading;
USE testleading;

create table t1 (c1 int, c11 int) distributed by hash(c1) buckets 3 properties('replication_num' = '1');
create table t2 (c2 int, c22 int) distributed by hash(c2) buckets 3 properties('replication_num' = '1');
create table t3 (c3 int, c33 int) distributed by hash(c3) buckets 3 properties('replication_num' = '1');
create table t4 (c4 int, c44 int) distributed by hash(c4) buckets 3 properties('replication_num' = '1');

```

举个简单的例子，当我们需要交换 **t1** 和 **t2** 的 join 顺序的时候只需要在前面加上 **leading(t2 t1)** 即可，**explain** 的时候会显示是否用上了这个 hint。

## 原始 plan

```

mysql> explain shape plan select * from t1 join t2 on t1.c1 = c2;
+-----+
| Explain String
+-----+
| PhysicalResultSink
| --PhysicalDistribute
| ----PhysicalProject
| -----hashJoin[INNER_JOIN](t1.c1 = t2.c2)
| -----PhysicalOlapScan[t2]
| -----PhysicalDistribute
| -----PhysicalOlapScan[t1]
+-----+
7 rows in set (0.06 sec)

```

## Leading plan

```

mysql> explain shape plan select /*+ leading(t2 t1) */ * from t1 join t2 on c1 = c2;
+-----+
| Explain String(Nereids Planner)
+-----+
| PhysicalResultSink
| --PhysicalDistribute[DistributionSpecGather]
| ----PhysicalProject
| -----hashJoin[INNER_JOIN] hashCondition=((t1.c1 = t2.c2)) otherCondition=()
| -----PhysicalOlapScan[t2]

```

```

| -----PhysicalDistribute[DistributionSpecHash]
| -----PhysicalOlapScan[t1]
|
| Hint log:
| Used: leading(t2 t1)
| UnUsed:
| SyntaxError:
+-----+
12 rows in set (0.00 sec)

```

## hint 效果展示 (Used unused)

若 leading hint 有语法错误，explain 的时候会在 syntax error 里面显示相应的信息，但是计划能照常生成，只不过没有使用 leading 而已

```

mysql> explain shape plan select /*+ leading(t2 t3) */ * from t1 join t2 on t1.c1 = c2;
+-----+
| Explain String
+-----+
| PhysicalResultSink
| --PhysicalDistribute
| ----PhysicalProject
| -----hashJoin[INNER_JOIN](t1.c1 = t2.c2)
| -----PhysicalOlapScan[t1]
| -----PhysicalDistribute
| -----PhysicalOlapScan[t2]
|
| Used:
| UnUsed:
| SyntaxError: leading(t2 t3) Msg:can not find table: t3
+-----+
11 rows in set (0.01 sec)

```

## 扩展场景

### 左深树

当我们不使用任何括号的情况下 leading 会默认生成左深树

```

mysql> explain shape plan select /*+ leading(t1 t2 t3) */ * from t1 join t2 on t1.c1 = c2 join t3 on c2 = c3;
+-----+
| Explain String(Nereids Planner)
+-----+
| PhysicalResultSink
| --PhysicalDistribute[DistributionSpecGather]
| ----PhysicalProject
| -----hashJoin[INNER_JOIN] hashCondition=((t2.c2 = t3.c3)) otherCondition=()
| -----hashJoin[INNER_JOIN] hashCondition=((t1.c1 = t2.c2)) otherCondition=()
| -----PhysicalOlapScan[t1]
| -----PhysicalDistribute[DistributionSpecHash]
| -----PhysicalOlapScan[t2]
| -----PhysicalDistribute[DistributionSpecHash]
| -----PhysicalOlapScan[t3]
|
| Hint log:
| Used: leading(t1 t2 t3)
| UnUsed:
| SyntaxError:

```

```

+-----+
15 rows in set (0.10 sec)

```

## 右深树

当我们想将计划的形状做成右深树或者 bushy 树或者 zigzag 树的时候，只需要加上大括号来限制 plan 的形状即可，不需要像 oracle 一样用 swap 从左深树一步步调整。

```

mysql> explain shape plan select /*+ leading(t1 {t2 t3}) */ * from t1 join t2 on t1.c1 = c2 join t3 on c2 = c3;
+-----+
| Explain String |
+-----+
| PhysicalResultSink |
| --PhysicalDistribute |
| ----PhysicalProject |
| -----hashJoin[INNER_JOIN](t1.c1 = t2.c2) |
| -----PhysicalOlapScan[t1] |
| -----PhysicalDistribute |
| -----hashJoin[INNER_JOIN](t2.c2 = t3.c3) |
| -----PhysicalOlapScan[t2] |
| -----PhysicalDistribute |
| -----PhysicalOlapScan[t3] |
| |
| Used: leading(t1 { t2 t3 }) |
| Unused: |
| SyntaxError: |
+-----+
14 rows in set (0.02 sec)

```

## Bushy 树

```

mysql> explain shape plan select /*+ leading({t1 t2} {t3 t4}) */ * from t1 join t2 on t1.c1 = c2 join t3 on c2 = c3 join t4 on c3 = c4;
+-----+
| Explain String |
+-----+
| PhysicalResultSink |
| --PhysicalDistribute |
| ----PhysicalProject |
| -----hashJoin[INNER_JOIN](t2.c2 = t3.c3) |
| -----hashJoin[INNER_JOIN](t1.c1 = t2.c2) |
| -----PhysicalOlapScan[t1] |
| -----PhysicalDistribute |
| -----PhysicalOlapScan[t2] |
| -----PhysicalDistribute |
| -----hashJoin[INNER_JOIN](t3.c3 = t4.c4) |
| -----PhysicalOlapScan[t3] |
| -----PhysicalDistribute |
| -----PhysicalOlapScan[t4] |
| |
| Used: leading({ t1 t2 } { t3 t4 }) |
| Unused: |
| SyntaxError: |
+-----+
17 rows in set (0.02 sec)

```

## Zig-Zag 树

```
mysql> explain shape plan select /*+ leading(t1 {t2 t3} t4) */ * from t1 join t2 on t1.c1 = c2 join t3 on c2
= c3 join t4 on c3 = c4;
+-----+
| Explain String(Nereids Planner) |
+-----+
| PhysicalResultSink |
| --PhysicalDistribute[DistributionSpecGather] |
| ----PhysicalProject |
| -----hashJoin[INNER_JOIN] hashCondition=((t3.c3 = t4.c4)) otherCondition=() |
| -----PhysicalDistribute[DistributionSpecHash] |
| -----hashJoin[INNER_JOIN] hashCondition=((t1.c1 = t2.c2)) otherCondition=() |
| -----PhysicalOlapScan[t1] |
| -----PhysicalDistribute[DistributionSpecHash] |
| -----hashJoin[INNER_JOIN] hashCondition=((t2.c2 = t3.c3)) otherCondition=() |
| -----PhysicalOlapScan[t2] |
| -----PhysicalDistribute[DistributionSpecHash] |
| -----PhysicalOlapScan[t3] |
| -----PhysicalDistribute[DistributionSpecHash] |
| -----PhysicalOlapScan[t4] |
| |
| Hint log: |
| Used: leading(t1 { t2 t3 } t4) |
| Unused: |
| SyntaxError: |
+-----+
19 rows in set (0.02 sec)
```

## Non-inner join:

当遇到非 inner-join 的时候，例如 Outer join 或者 semi/anti join 的时候，leading hint 会根据原始 sql 语义自动推导各个 join 的 join 方式。若遇到与原始 sql 语义不同的 leading hint 或者生成不了的情况则会放到 unused 里面，但是不影响计划正常流程的生成。下面是不能交换的例子：

—— test outer join which can not swap

– t1 leftjoin (t2 join t3 on (P23)) on (P12) != (t1 leftjoin t2 on (P12)) join t3 on (P23)

```
mysql> explain shape plan select /*+ leading(t1 {t2 t3}) */ * from t1 left join t2 on c1 = c2 join t3 on c2 =
c3;
+-----+
| Explain String(Nereids Planner) |
+-----+
| PhysicalResultSink |
| --PhysicalDistribute[DistributionSpecGather] |
| ----PhysicalProject |
| -----hashJoin[INNER_JOIN] hashCondition=((t2.c2 = t3.c3)) otherCondition=() |
| -----hashJoin[INNER_JOIN] hashCondition=((t1.c1 = t2.c2)) otherCondition=() |
| -----PhysicalOlapScan[t1] |
| -----PhysicalDistribute[DistributionSpecHash] |
| -----PhysicalOlapScan[t2] |
| -----PhysicalDistribute[DistributionSpecHash] |
| -----PhysicalOlapScan[t3] |
| |
| Hint log: |
| Used: |
| Unused: leading(t1 { t2 t3 }) |
| SyntaxError: |
+-----+
15 rows in set (0.01 sec)
```

下面是一些可以交换的例子和不能交换的例子，读者可自行验证

```
----- test outer join which can swap
-- (t1 leftjoin t2 on (P12)) innerjoin t3 on (P13) = (t1 innerjoin t3 on (P13)) leftjoin t2 on (P12)
explain shape plan select * from t1 left join t2 on c1 = c2 join t3 on c1 = c3;
explain shape plan select /*+ leading(t1 t3 t2) */ * from t1 left join t2 on c1 = c2 join t3 on c1 = c3;

-- (t1 leftjoin t2 on (P12)) leftjoin t3 on (P13) = (t1 leftjoin t3 on (P13)) leftjoin t2 on (P12)
explain shape plan select * from t1 left join t2 on c1 = c2 left join t3 on c1 = c3;
explain shape plan select /*+ leading(t1 t3 t2) */ * from t1 left join t2 on c1 = c2 left join t3 on c1 = c3;

-- (t1 leftjoin t2 on (P12)) leftjoin t3 on (P23) = t1 leftjoin (t2 leftjoin t3 on (P23)) on (P12)
select /*+ leading(t2 t3 t1) SWAP_INPUT(t1) */ * from t1 left join t2 on c1 = c2 left join t3 on c2 = c3;
explain shape plan select /*+ leading(t1 {t2 t3}) */ * from t1 left join t2 on c1 = c2 left join t3 on c2 = c3;
explain shape plan select /*+ leading(t1 {t2 t3}) */ * from t1 left join t2 on c1 = c2 left join t3 on c2 = c3;

----- test outer join which can not swap
-- t1 leftjoin (t2 join t3 on (P23)) on (P12) != (t1 leftjoin t2 on (P12)) join t3 on (P23)
-- eliminated to inner join
explain shape plan select /*+ leading(t1 {t2 t3}) */ * from t1 left join t2 on c1 = c2 join t3 on c2 = c3;
explain graph select /*+ leading(t1 t2 t3) */ * from t1 left join (select * from t2 join t3 on c2 = c3) on c1 = c2;

-- test semi join
explain shape plan select * from t1 where c1 in (select c2 from t2);
explain shape plan select /*+ leading(t2 t1) */ * from t1 where c1 in (select c2 from t2);

-- test anti join
explain shape plan select * from t1 where exists (select c2 from t2);
```

## View

遇到别名的情况，可以将别名作为一个完整的子树进行指定，子树里面的 joinOrder 由文本序生成。

```
mysql> explain shape plan select /*+ leading(alias t1) */ count(*) from t1 join (select c2 from t2 join t3
on t2.c2 = t3.c3) as alias on t1.c1 = alias.c2;
+-----+
| Explain String(Nereids Planner) |
+-----+
| PhysicalResultSink |
| --hashAgg[GLOBAL] |
| ----PhysicalDistribute[DistributionSpecGather] |
| -----hashAgg[LOCAL] |
| -----PhysicalProject |
| -----hashJoin[INNER_JOIN] hashCondition=((t1.c1 = alias.c2)) otherCondition=() |
| -----PhysicalProject |
| -----hashJoin[INNER_JOIN] hashCondition=((t2.c2 = t3.c3)) otherCondition=() |
| -----PhysicalProject |
| -----PhysicalOlapScan[t2] |
| -----PhysicalDistribute[DistributionSpecHash] |
| -----PhysicalProject |
| -----PhysicalOlapScan[t3] |
| -----PhysicalDistribute[DistributionSpecHash] |
| -----PhysicalProject |
| -----PhysicalOlapScan[t1] |
| |
| Hint log: |
| Used: leading(alias t1) |
| Unused: |
```

```
| SyntaxError: |
+-----+
21 rows in set (0.02 sec)
```

## 与 ordered 混合使用

当与 ordered hint 混合使用的时候以 ordered hint 为主，即 ordered hint 生效优先级高于 leading hint。例：

```
mysql> explain shape plan select /*+ ORDERED LEADING(t1 t2 t3) */ t1.c1 from t2 join t1 on t1.c1 = t2.c2
join t3 on c2 = c3;
+-----+
| Explain String(Nereids Planner) |
+-----+
| PhysicalResultSink |
| --PhysicalDistribute[DistributionSpecGather] |
| ----PhysicalProject |
| -----hashJoin[INNER_JOIN] hashCondition=((t2.c2 = t3.c3)) otherCondition=() |
| -----hashJoin[INNER_JOIN] hashCondition=((t1.c1 = t2.c2)) otherCondition=() |
| -----PhysicalProject |
| -----PhysicalOlapScan[t2] |
| -----PhysicalDistribute[DistributionSpecHash] |
| -----PhysicalProject |
| -----PhysicalOlapScan[t1] |
| -----PhysicalDistribute[DistributionSpecHash] |
| -----PhysicalProject |
| -----PhysicalOlapScan[t3] |
| |
| Hint log: |
| Used: ORDERED |
| UnUsed: leading(t1 t2 t3) |
| SyntaxError: |
+-----+
18 rows in set (0.02 sec)
```

## 使用限制

- 当前版本只支持使用一个 leadingHint。若和子查询同时使用 leadinghint 的话则查询会报错。例（这个例子 explain 会报错，但是会走正常的路径生成计划）：

```
mysql> explain shape plan select /*+ leading(alias t1) */ count(*) from t1 join (select /*+ leading(t3 t2)
*/ c2 from t2 join t3 on t2.c2 = t3.c3) as alias on t1.c1 = alias.c2;
+-----+
| Explain String(Nereids Planner) |
+-----+
| PhysicalResultSink |
| --hashAgg[GLOBAL] |
| ----PhysicalDistribute[DistributionSpecGather] |
| -----hashAgg[LOCAL] |
| -----PhysicalProject |
| -----hashJoin[INNER_JOIN] hashCondition=((t1.c1 = alias.c2)) otherCondition=() |
| -----PhysicalProject |
| -----PhysicalOlapScan[t1] |
| -----PhysicalDistribute[DistributionSpecHash] |
| -----PhysicalProject |
| -----hashJoin[INNER_JOIN] hashCondition=((t2.c2 = t3.c3)) otherCondition=() |
| -----PhysicalProject |
| -----PhysicalOlapScan[t2] |
| -----PhysicalDistribute[DistributionSpecHash] |
| -----PhysicalProject |
+-----+
```

```

| -----PhysicalOlapScan[t3]
|
| Hint log:
| Used:
| Unused: leading(alias t1)
| SyntaxError: leading(t3 t2) Msg:one query block can only have one leading clause
+-----+
21 rows in set (0.01 sec)

```

## OrderedHint 使用说明

- 使用 ordered hint 会让 join tree 的形状固定下来，按照文本序来显示
- 语法为 `/+ ORDERED /`, leading 由 `"/+“和”/“` 包围并置于 select 语句里面 select 的正后方，例：explain shape plan select `/+ ORDERED /` t1.c1 from t2 join t1 on t1.c1 = t2.c2 join t3 on c2 = c3; join / join t3 / t2 t1

```

mysql> explain shape plan select /*+ ORDERED */ t1.c1 from t2 join t1 on t1.c1 = t2.c2 join t3 on c2 = c3;
+-----+
| Explain String(Nereids Planner)
+-----+
| PhysicalResultSink
| --PhysicalDistribute[DistributionSpecGather]
| ----PhysicalProject
| -----hashJoin[INNER_JOIN] hashCondition=((t2.c2 = t3.c3)) otherCondition=()
| -----hashJoin[INNER_JOIN] hashCondition=((t1.c1 = t2.c2)) otherCondition=()
| -----PhysicalProject
| -----PhysicalOlapScan[t2]
| -----PhysicalDistribute[DistributionSpecHash]
| -----PhysicalProject
| -----PhysicalOlapScan[t1]
| -----PhysicalDistribute[DistributionSpecHash]
| -----PhysicalProject
| -----PhysicalOlapScan[t3]
|
| Hint log:
| Used: ORDERED
| Unused:
| SyntaxError:
+-----+
18 rows in set (0.02 sec)

```

- 当 ordered hint 和 leading hint 同时使用时以 ordered hint 为准，leading hint 会失效

```

mysql> explain shape plan select /*+ ORDERED LEADING(t1 t2 t3) */ t1.c1 from t2 join t1 on t1.c1 = t2.c2 join
t3 on c2 = c3;
+-----+
| Explain String(Nereids Planner)
+-----+
| PhysicalResultSink
| --PhysicalDistribute[DistributionSpecGather]
| ----PhysicalProject
| -----hashJoin[INNER_JOIN] hashCondition=((t2.c2 = t3.c3)) otherCondition=()
| -----hashJoin[INNER_JOIN] hashCondition=((t1.c1 = t2.c2)) otherCondition=()
| -----PhysicalProject
| -----PhysicalOlapScan[t2]
| -----PhysicalDistribute[DistributionSpecHash]
| -----PhysicalProject

```



```

| -----PhysicalOlapScan[t1]
| -----PhysicalDistribute[DistributionSpecHash]
| -----PhysicalProject
| -----PhysicalOlapScan[t3]
|
| Hint log:
| Used: ORDERED
| UnUsed: leading(t1 t2 t3)
| SyntaxError:
+-----+
18 rows in set (0.02 sec)

```

## DistributeHint 使用说明

- 目前只能指定右表的 distribute Type 而且只有[shuffle] 和 [broadcast]两种，写在 join 右表前面且允许中括号和/+ /两种写法
- 目前能使用任意个 DistributeHint
- 当遇到无法正确生成计划的 DistributeHint，没有显示，按最大努力生效，最后以 explain 显示的 distribute 方式为主
- 当前版本暂不与 leading 混用，且当 distribute 指定的表位于 join 右边才可生效。
- 多与 ordered 混用，利用文本序把 join 顺序固定下来，然后再指定相应的 join 里面我们预期使用什么样的 distribute 方式。例：

使用前：

```

mysql> explain shape plan select count(*) from t1 join t2 on t1.c1 = t2.c2;
+-----+
| Explain String(Nereids Planner)
+-----+
| PhysicalResultSink
| --hashAgg[GLOBAL]
| ----PhysicalDistribute[DistributionSpecGather]
| -----hashAgg[LOCAL]
| -----PhysicalProject
| -----hashJoin[INNER_JOIN] hashCondition=((t1.c1 = t2.c2)) otherCondition=()
| -----PhysicalProject
| -----PhysicalOlapScan[t1]
| -----PhysicalDistribute[DistributionSpecHash]
| -----PhysicalProject
| -----PhysicalOlapScan[t2]
+-----+
11 rows in set (0.01 sec)

```

使用后：

```

mysql> explain shape plan select /*+ ordered */ count(*) from t2 join[broadcast] t1 on t1.c1 = t2.c2;
+-----+
| Explain String(Nereids Planner)
+-----+
| PhysicalResultSink
| --hashAgg[GLOBAL]
| ----PhysicalDistribute[DistributionSpecGather]
| -----hashAgg[LOCAL]
| -----PhysicalProject

```

```

| -----hashJoin[INNER_JOIN] hashCondition=((t1.c1 = t2.c2)) otherCondition=() |
| -----PhysicalProject |
| -----PhysicalOlapScan[t2] |
| -----PhysicalDistribute[DistributionSpecReplicated] |
| -----PhysicalProject |
| -----PhysicalOlapScan[t1] |
| |
| Hint log: |
| Used: ORDERED |
| Unused: |
| SyntaxError: |
+-----+
16 rows in set (0.01 sec)

```

- Explain shape plan 里面会显示 distribute 算子相关的信息，其中 DistributionSpecReplicated 表示该算子将对应的数据变成所有 be 节点复制一份，DistributionSpecGather 表示将数据 gather 到 fe 节点，DistributionSpecHash 表示将数据按照特定的 hashKey 以及算法打散到不同的 be 节点。

## 待支持

- leadingHint 待支持子查询解嵌套指定，当前和子查询提升以后不能混用，需要有 hint 来控制是否可以解嵌套
- 需要新的 distributeHint 来更好且更全面地控制 distribute 算子
- 混合使用 leadingHint 与 distributeHint 来共同确定 join 的形状

# BITMAP 精准去重

## 背景

Doris 原有的 Bitmap 聚合函数设计比较通用，但对亿级别以上 bitmap 大基数的交并集计算性能较差。排查后端 be 的 bitmap 聚合函数逻辑，发现主要有两个原因。一是当 bitmap 基数较大时，如 bitmap 大小超过 1g，网络/磁盘 IO 处理时间比较长；二是后端 be 实例在 scan 数据后全部传输到顶层节点进行求交和并运算，给顶层单节点带来压力，成为处理瓶颈。

解决思路是将 bitmap 列的值按照 range 划分，不同 range 的值存储在不同的分桶中，保证了不同分桶的 bitmap 值是正交的。当查询时，先分别对不同分桶中的正交 bitmap 进行聚合计算，然后顶层节点直接将聚合计算后的值合并汇总，并输出。如此会大大提高计算效率，解决了顶层单节点计算瓶颈问题。

## 使用指南

1. 建表，增加 hid 列，表示 bitmap 列值 id 范围，作为 hash 分桶列
2. 使用场景

### Create table

建表时需要使用聚合模型，数据类型是 bitmap，聚合函数是 bitmap\_union

```
CREATE TABLE `user_tag_bitmap` (
 `tag` bigint(20) NULL COMMENT "用户标签",
 `hid` smallint(6) NULL COMMENT "分桶id",
 `user_id` bitmap BITMAP_UNION NULL COMMENT ""
) ENGINE=OLAP
AGGREGATE KEY(`tag`, `hid`)
COMMENT "OLAP"
DISTRIBUTED BY HASH(`hid`) BUCKETS 3
```

表 schema 增加 hid 列，表示 id 范围，作为 hash 分桶列。

**注：hid 数和 BUCKETS 要设置合理，hid 数设置至少是 BUCKETS 的 5 倍以上，以使数据 hash 分桶尽量均衡**

### Data Load

```
LOAD LABEL user_tag_bitmap_test
(
 DATA INFILE('hdfs://abc')
 INTO TABLE user_tag_bitmap
 COLUMNS TERMINATED BY ','
 (tmp_tag, tmp_user_id)
 SET (
 tag = tmp_tag,
```

```
hid = ceil(tmp_user_id/5000000),
user_id = to_bitmap(tmp_user_id)
)
)
注意：5000000这个数不固定，可按需调整
...
```

数据格式：

```
11111111,1
11111112,2
11111113,3
11111114,4
...
```

注：第一列代表用户标签，由中文转换成数字

load 数据时，对用户 bitmap 值 range 范围纵向切割，例如，用户 id 在 1-5000000 范围内的 hid 值相同，hid 值相同的行会分配到一个分桶内，如此每个分桶内到的 bitmap 都是正交的。可以利用桶内 bitmap 值正交特性，进行交并集计算，计算结果会被 shuffle 至 top 节点聚合。

注：正交 bitmap 函数不能用在分区表，因为分区表分区内正交，分区之间的数据是无法保证正交的，则计算结果也是无法预估的。

## bitmap\_orthogonal\_intersect

求 bitmap 交集函数

- 语法：

orthogonal\_bitmap\_intersect(bitmap\_column, column\_to\_filter, filter\_values)

- 参数：

第一个参数是 Bitmap 列，第二个参数是用来过滤的维度列，第三个参数是变长参数，含义是过滤维度列的不同取值

- 说明：

查询规划上聚合分 2 层，在第一层 be 节点（update、serialize）先按 filter\_values 为 key 进行 hash 聚合，然后对所有 key 的 bitmap 求交集，结果序列化后发送至第二层 be 节点（merge、finalize），在第二层 be 节点对所有来源于第一层节点的 bitmap 值循环求并集

样例：

```
select BITMAP_COUNT(orthogonal_bitmap_intersect(user_id, tag, 13080800, 11110200)) from user_tag_bitmap
where tag in (13080800, 11110200);
```

## orthogonal\_bitmap\_intersect\_count

求 bitmap 交集 count 函数，语法同原版 intersect\_count，但实现不同

- 语法：

orthogonal\_bitmap\_intersect\_count(bitmap\_column, column\_to\_filter, filter\_values)

- 参数：

第一个参数是 Bitmap 列，第二个参数是用来过滤的维度列，第三个参数开始是变长参数，含义是过滤维度列的不同取值

- 说明：

查询规划聚合上分 2 层，在第一层 be 节点（update、serialize）先按 filter\_values 为 key 进行 hash 聚合，然后对所有 key 的 bitmap 求交集，再对交集结果求 count，count 值序列化后发送至第二层 be 节点（merge、finalize），在第二层 be 节点对所有来源于第一层节点的 count 值循环求 sum

- 样例：

```
select orthogonal_bitmap_intersect_count(members, tag_group, 1150000, 1150001, 390006) from tag_map
where tag_group in (1150000, 1150001, 390006);
```

### orthogonal\_bitmap\_union\_count

求 bitmap 并集 count 函数，语法同原版 bitmap\_union\_count，但实现不同。

- 语法：

orthogonal\_bitmap\_union\_count(bitmap\_column)

- 参数：

参数类型是 bitmap，是待求并集 count 的列

- 说明：

查询规划上分 2 层，在第一层 be 节点（update、serialize）对所有 bitmap 求并集，再对并集的结果 bitmap 求 count，count 值序列化后发送至第二层 be 节点（merge、finalize），在第二层 be 节点对所有来源于第一层节点的 count 值循环求 sum

- 样例：

```
select ORTHOGONAL_BITMAP_UNION_COUNT(members) from tag_map where tag_group in (1150000, 1150001,
390006);
```

### orthogonal\_bitmap\_expr\_calculate

求表达式 bitmap 交并差集合计算函数。

- 语法：

orthogonal\_bitmap\_expr\_calculate(bitmap\_column, filter\_column, input\_string)

- 参数：

第一个参数是 Bitmap 列，第二个参数是用来过滤的维度列，即计算的 key 列，第三个参数是计算表达式字符串，含义是依据 key 列进行 bitmap 交并差集表达式计算

表达式支持的运算符：& 代表交集计算，| 代表并集计算，- 代表差集计算，^ 代表异或计算，~ 代表转义字符

- 说明：

查询规划上聚合分 2 层，第一层 be 聚合节点计算包括 init、update、serialize 步骤，第二层 be 聚合节点计算包括 merge、finalize 步骤。在第一层 be 节点，init 阶段解析 input\_string 字符串，转换为后缀表达式（逆波兰式），解析出计算 key 值，并在 map<key, bitmap>结构中初始化；update 阶段，底层内核 scan 维度列

(filter\_column) 数据后回调 update 函数，然后以计算 key 为单位对上一步的 map 结构中的 bitmap 进行聚合；serialize 阶段，根据后缀表达式，解析出计算 key 列的 bitmap，利用栈结构先进后出原则，进行 bitmap 交并差集合计算，然后对最终的结果 bitmap 序列化后发送至第二层聚合 be 节点。在第二层聚合 be 节点，对所有来源于第一层节点的 bitmap 值求并集，并返回最终 bitmap 结果

### orthogonal\_bitmap\_expr\_calculate\_count

求表达式 bitmap 交并差集合计算 count 函数，语法和参数同 orthogonal\_bitmap\_expr\_calculate。

- 语法：

orthogonal\_bitmap\_expr\_calculate\_count(bitmap\_column, filter\_column, input\_string)

- 说明：

查询规划上聚合分 2 层，第一层 be 聚合节点计算包括 init、update、serialize 步骤，第二层 be 聚合节点计算包括 merge、finalize 步骤。在第一层 be 节点，init 阶段解析 input\_string 字符串，转换为后缀表达式（逆波兰式），解析出计算 key 值，并在 map<key, bitmap>结构中初始化；update 阶段，底层内核 scan 维度列

(filter\_column) 数据后回调 update 函数，然后以计算 key 为单位对上一步的 map 结构中的 bitmap 进行聚合；serialize 阶段，根据后缀表达式，解析出计算 key 列的 bitmap，利用栈结构先进后出原则，进行 bitmap 交并差集合计算，然后对最终的结果 bitmap 的 count 值序列化后发送至第二层聚合 be 节点。在第二层聚合 be 节点，对所有来源于第一层节点的 count 值求加和，并返回最终 count 结果。

## 使用场景

符合对 bitmap 进行正交计算的场景，如在用户行为分析中，计算留存，漏斗，用户画像等。

人群圈选：

```
select orthogonal_bitmap_intersect_count(user_id, tag, 13080800, 11110200) from user_tag_bitmap where tag in (13080800, 11110200);
```

注：13080800、11110200代表用户标签

计算 user\_id 的去重值：

```
select orthogonal_bitmap_union_count(user_id) from user_tag_bitmap where tag in (13080800, 11110200);
```

bitmap 交并差集合混合计算：

```
select orthogonal_bitmap_expr_calculate_count(user_id, tag, '(833736|999777)&(1308083|231207)&(1000|20000-30000)') from user_tag_bitmap where tag in (833736,999777,130808,231207,1000,20000,30000);
```

注：1000、20000、30000等整形tag，代表用户不同标签

```
select orthogonal_bitmap_expr_calculate_count(user_id, tag, '(A:a/b|B:2\\-4)&(C:1-D:12)&E:23') from
user_str_tag_bitmap where tag in ('A:a/b', 'B:2-4', 'C:1', 'D:12', 'E:23');
```

注：'A:a/b'，'B:2-4'等是字符串类型tag，代表用户不同标签，其中'B:2-4'需要转义成'B:2\\-4'

# HLL 近似去重

## HLL 近似去重

在实际的业务场景中，随着业务数据量越来越大，对数据去重的压力也越来越大，当数据达到一定规模之后，使用精准去重的成本也越来越高，在业务可以接受的情况下，通过近似算法来实现快速去重降低计算压力是一个非常好的方式，本文主要介绍 Doris 提供的 HyperLogLog（简称 HLL）是一种近似去重算法。

HLL 的特点是具有非常优异的空间复杂度  $O(m \log \log n)$ ，时间复杂度为  $O(n)$ ，并且计算结果的误差可控制在 1%—2% 左右，误差与数据集大小以及所采用的哈希函数有关。

## 什么是 HyperLogLog

它是 LogLog 算法的升级版，作用是能够提供不精确的去重计数。其数学基础为伯努利试验。

假设硬币拥有正反两面，一次的上抛至落下，最终出现正反面的概率都是 50%。一直抛硬币，直到它出现正面为止，我们记录为一次完整的试验。

那么对于多次的伯努利试验，假设这个多次为  $n$  次。就意味着出现了  $n$  次的正面。假设每次伯努利试验所经历了的抛掷次数为  $k$ 。第一次伯努利试验，次数设为  $k_1$ ，以此类推，第  $n$  次对应的是  $k_n$ 。

其中，对于这  $n$  次伯努利试验中，必然会有一个最大的抛掷次数  $k$ ，例如抛了 12 次才出现正面，那么称这个为  $k_{\max}$ ，代表抛了最多的次数。

伯努利试验容易得出有以下结论：

- $n$  次伯努利过程的投掷次数都不大于  $k_{\max}$ 。
- $n$  次伯努利过程，至少有一次投掷次数等于  $k_{\max}$

最终结合极大似然估算的方法，发现在  $n$  和  $k_{\max}$  中存在估算关联： $n = 2^{k_{\max}}$ 。当我们只记录了  $k_{\max}$  时，即可估算总共有多少条数据，也就是基数。

假设试验结果如下：

- 第 1 次试验：抛了 3 次才出现正面，此时  $k=3$ ， $n=1$
- 第 2 次试验：抛了 2 次才出现正面，此时  $k=2$ ， $n=2$
- 第 3 次试验：抛了 6 次才出现正面，此时  $k=6$ ， $n=3$
- 第  $n$  次试验：抛了 12 次才出现正面，此时我们估算， $n = 2^{12}$

取上面例子中前三组试验，那么  $k_{\max} = 6$ ，最终  $n=3$ ，我们放进估算公式中去，明显： $3 \neq 2^6$ 。也即是说，当试验次数很小的时候，这种估算方法的误差是很大的。

这三组试验，我们称为一轮的估算。如果只是进行一轮的话，当  $n$  足够大的时候，估算的误差率会相对减少，但仍然不够小。



## Doris HLL 函数

HLL 是基于 HyperLogLog 算法的工程实现，用于保存 HyperLogLog 计算过程的中间结果，它只能作为表的 value 列类型、通过聚合来不断的减少数据量，以此

来实现加快查询的目的，基于它得到的是一个估算结果，误差大概在 1% 左右，hll 列是通过其它列或者导入数据里面的数据生成的，导入的时候通过 hll\_hash 函数

来指定数据中哪一列用于生成 hll 列，它常用于替代 count distinct，通过结合 rollup 在业务上用于快速计算 uv 等

### HLL\_UNION\_AGG(hll)

此函数为聚合函数，用于计算满足条件的所有数据的基数估算。

### HLL\_CARDINALITY(hll)

此函数用于计算单条 hll 列的基数估算

### HLL\_HASH(column\_name)

生成 HLL 列类型，用于 insert 或导入的时候，导入的使用见相关说明

## 如何使用 Doris HLL

1. 使用 HLL 去重的时候，需要在建表语句中将目标列类型设置成 HLL，聚合函数设置成 HLL\_UNION
2. HLL 类型的列不能作为 Key 列使用
3. 用户不需要指定长度及默认值，长度根据数据聚合程度系统内控制

## 创建一张含有 hll 列的表

```
create table test_hll(
 dt date,
 id int,
 name char(10),
 province char(10),
 os char(10),
 pv hll hll_union
)
Aggregate KEY (dt,id,name,province,os)
distributed by hash(id) buckets 10
PROPERTIES(
 "replication_num" = "1",
 "in_memory"="false"
);
```

## 导入数据

1. Stream load 导入

```
curl --location-trusted -u root: -H "label:label_test_hll_load" \
-H "column_separator:," \

```

```
-H "columns:dt,id,name,province,os, pv=hll_hash(id)" -T test_hll.csv
http://fe_IP:8030/api/demo/test_hll/_stream_load
```

示例数据如下 (test\_hll.csv) :

```
2022-05-05,10001, 测试 01, 北京, windows
2022-05-05,10002, 测试 01, 北京, linux
2022-05-05,10003, 测试 01, 北京, macos
2022-05-05,10004, 测试 01, 河北, windows
2022-05-06,10001, 测试 01, 上海, windows
2022-05-06,10002, 测试 01, 上海, linux
2022-05-06,10003, 测试 01, 江苏, macos
2022-05-06,10004, 测试 01, 陕西, windows
```

导入结果如下

```
curl --location-trusted -u root: -H "label:label_test_hll_load" -H "column_separator:," -H
"columns:dt,id,name,province,os, pv=hll_hash(id)" -T test_hll.csv
http://127.0.0.1:8030/api/demo/test_hll/_stream_load

{
 "TxnId": 693,
 "Label": "label_test_hll_load",
 "TwoPhaseCommit": "false",
 "Status": "Success",
 "Message": "OK",
 "NumberTotalRows": 8,
 "NumberLoadedRows": 8,
 "NumberFilteredRows": 0,
 "NumberUnselectedRows": 0,
 "LoadBytes": 320,
 "LoadTimeMs": 23,
 "BeginTxnTimeMs": 0,
 "StreamLoadPutTimeMs": 1,
 "ReadDataTimeMs": 0,
 "WriteDataTimeMs": 9,
 "CommitAndPublishTimeMs": 11
}
```

## 2. Broker Load

```
LOAD LABEL demo.test_hlllabel
(
 DATA INFILE("hdfs://hdfs_host:hdfs_port/user/doris_test_hll/data/input/file")
 INTO TABLE `test_hll`
 COLUMNS TERMINATED BY ","
 (dt,id,name,province,os)
 SET (
 pv = HLL_HASH(id)
)
);
```

## 查询数据

HLL 列不允许直接查询原始值，只能通过 HLL 的聚合函数进行查询。

### 1. 求总的 PV

```
mysql> select HLL_UNION_AGG(pv) from test_hll;
+-----+
| hll_union_agg(`pv`) |
+-----+
| 4 |
+-----+
1 row in set (0.00 sec)
```

等价于：

```
mysql> SELECT COUNT(DISTINCT pv) FROM test_hll;
+-----+
| count(DISTINCT `pv`) |
+-----+
| 4 |
+-----+
1 row in set (0.01 sec)
```

## 2. 求每一天的 PV

```
mysql> select HLL_UNION_AGG(pv) from test_hll group by dt;
+-----+
| hll_union_agg(`pv`) |
+-----+
| 4 |
| 4 |
+-----+
2 rows in set (0.01 sec)
```

# 高并发点查

高并发点查功能自 Doris 2.0 版本起具有重大性能提升

## 背景

Doris 基于列存格式引擎构建，在高并发服务场景中，用户总是希望从系统中获取整行数据。但是，当表宽时，列存格式将大大放大随机读取 IO。Doris 查询引擎和计划对于某些简单的查询（如点查询）来说太重了。需要一个在 FE 的查询规划中规划短路径来处理这样的查询。FE 是 SQL 查询的访问层服务，使用 Java 编写，分析和解析 SQL 也会导致高并发查询的高 CPU 开销。为了解决上述问题，我们在 Doris 中引入了行存、短查询路径、PreparedStatement 来解决上述问题，下面是开启这些优化的指南。

## 行存

用户可以在 Olap 表中开启行存模式，但是需要额外的空间来存储行存。目前的行存实现是将行存编码后存在单独的一列中，这样做是用于简化行存的实现。行存模式仅支持在建表的时候开启，需要在建表语句的 property 中指定如下属性：

```
"store_row_column" = "true"
```

## 在 Unique 模型下的点查优化

上述的行存用于在 Unique 模型下开启 Merge-On-Write 策略是减少点查时的 IO 开销。当 enable\_unique\_key\_merge\_on\_write 与 store\_row\_column 在建 Unique 表开启时，对于主键的点查会走短路径来对 SQL 执行进行优化，仅需要执行一次 RPC 即可执行完成查询。下面是点查结合行存在 Unique 模型下开启 Merge-On-Write 策略的一个例子：

```
CREATE TABLE `tbl_point_query` (
 `k1` int(11) NULL,
 `v1` decimal(27, 9) NULL,
 `v2` varchar(30) NULL,
 `v3` varchar(30) NULL,
 `v4` date NULL,
 `v5` datetime NULL,
 `v6` float NULL,
 `v7` datev2 NULL
) ENGINE=OLAP
UNIQUE KEY(`k1`)
COMMENT 'OLAP'
DISTRIBUTED BY HASH(`k1`) BUCKETS 1
PROPERTIES (
 "replication_allocation" = "tag.location.default: 1",
 "enable_unique_key_merge_on_write" = "true",
 "light_schema_change" = "true",
 "store_row_column" = "true"
);
```

**注意：** 1. `enable_unique_key_merge_on_write`应该被开启，存储引擎需要根据主键来快速点查

2. 当条件只包含主键时，如 `select * from tbl_point_query where k1 = 123`，类似的查询会走短路径来优化查询
3. `light_schema_change`应该被开启，因为主键点查的优化依赖了轻量级 Schema Change 中的 `column unique id`来定位列
4. 只支持单表 key 列等值查询不支持 join、嵌套子查询，**where** 条件里需要有且仅有 **key** 列的等值，可以认为是一种 key value 查询

## 使用 PreparedStatement

为了减少 SQL 解析和表达式计算的开销，我们在 FE 端提供了与 MySQL 协议完全兼容的 PreparedStatement 特性（目前只支持主键点查）。当 PreparedStatement 在 FE 开启，SQL 和其表达式将被提前计算并缓存到 Session 级别的内存缓存中，后续的查询直接使用缓存对象即可。当 CPU 成为主键点查的瓶颈，在开启 PreparedStatement 后，将会有 4 倍 + 的性能提升。下面是在 JDBC 中使用 PreparedStatement 的例子

1. 设置 JDBC url 并在 Server 端开启 prepared statement

```
url = jdbc:mysql://127.0.0.1:9030/yccb?useServerPrepStmts=true
```

2. 使用 PreparedStatement

```
// use `?` for placement holders, readStatement should be reused
PreparedStatement readStatement = conn.prepareStatement("select * from tbl_point_query where k1 = ?");
...
readStatement.setInt(1,1234);
ResultSet resultSet = readStatement.executeQuery();
...
readStatement.setInt(1,1235);
resultSet = readStatement.executeQuery();
...
```

## 开启行缓存

Doris 中有针对 Page 级别的 Cache，每个 Page 中存的是某一列的数据，所以 Page cache 是针对列的缓存，对于前面提到的行存，一行里包括了多列数据，缓存可能被大查询给刷掉，为了增加行缓存命中率，单独引入了行存缓存，行缓存复用了 Doris 中的 LRU Cache 机制来保障内存的使用，通过指定下面的 BE 配置来开启

- `disable_storage_row_cache`是否开启行缓存，默认不开启
- `row_cache_mem_limit`指定 Row cache 占用内存的百分比，默认 20% 内存

## 性能优化

1. 通常，通过增加 Observer 数量来提升处理 query 能力是有效的
2. query 负载均衡：点查中如果发现接受点查请求的 fe cpu 使用过高，或请求响应变慢，可使用 `jdbc load balance` 进行负载均衡，将请求分散到多个节点，分担压力（同时也可以使用其他方式进行 query 负载均衡配置，如 Nginx, proxySQL）

3. 通过将点查请求定向发送至 Observer 角色来分担高并发点查的请求压力，减少向 fe master 发送点查请求，通常可以解决 Fe Master 节点查询耗时上下浮动问题，以获得更好性能与稳定性

## Q&A

### 1. 如何确定配置无误使用了并发点查的短路径优化

A: explain sql, 当执行计划中出现 SHORT-CIRCUIT, 证明使用了短路径优化

```
mysql> explain select * from tbl_point_query where k1 = -2147481418 ;
+-----+
| Explain String(Old Planner) |
+-----+
| PLAN FRAGMENT 0 |
| OUTPUT EXPRS: |
| `test`.`tbl_point_query`.`k1` |
| `test`.`tbl_point_query`.`v1` |
| `test`.`tbl_point_query`.`v2` |
| `test`.`tbl_point_query`.`v3` |
| `test`.`tbl_point_query`.`v4` |
| `test`.`tbl_point_query`.`v5` |
| `test`.`tbl_point_query`.`v6` |
| `test`.`tbl_point_query`.`v7` |
| PARTITION: UNPARTITIONED |
| |
| HAS_COLO_PLAN_NODE: false |
| |
| VRESULT SINK |
| MYSQL_PROTOCOL |
| |
| 0:V0lapScanNode |
| TABLE: test.tbl_point_query(tbl_point_query), PREAGGREGATION: ON |
| PREDICATES: `k1` = -2147481418 AND `test`.`tbl_point_query`.`__DORIS_DELETE_SIGN__` = 0 |
| partitions=1/1 (tbl_point_query), tablets=1/1, tabletList=360065 |
| cardinality=9452868, avgRowSize=833.31323, numNodes=1 |
| pushAggOp=NONE |
| SHORT-CIRCUIT |
+-----+
```

### 2. 如何确定 prepared statement 生效

A: 当发送请求到 Doris 之后, 在 fe.audit.log 中找到相应的 query 请求, 发现 Stmt=EXECUTE(), 说明 prepared statement 生效

```
2024-01-02 11:15:51,248 [query]
|Client=192.168.1.82:53450|User=root|Db=test|State=E0F|ErrorCode=0|ErrorMessage=|Time(ms)=49|ScanBytes=0|Scan
Rows=0|ReturnRows=1|StmtId=51|QueryId=b63d30b908f04dad-ab4a

3ba21d2c776b|IsQuery=true|isNereids=false|feIp=10.16.10.6|Stmt=EXECUTE(-2147481418)|CpuTimeMS=0|SqlHash=eee20
fa2ac13a4f93bd4503a87921024|peakMemoryBytes=0|SqlDigest=|TraceId=|WorkloadGroup=|FuzzyVaria
bles=
```

### 3. 非主键查询能否使用到高并发点查的特殊优化

A: 不能, 高并发点查只针对于 key 列的等值查询, 且查询中不能包含 join, 嵌套子查询

### 4. useServerPrepStmts 在普通查询中是否有用

A: Prepared Statement 目前只在主键点查的情况下生效

## 5. 优化器选择需要进行全局设置吗

A: 在使用 prepared statement 进行查询时, Doris 会选择性能最好的查询方式, 不需要手动设置优化器

## 6. FE 成为瓶颈怎么处理?

A: 如果占用过高 cpu, %CPU 过高, 则在 jdbc url 开启以下配置

```
jdbc:mysql:loadbalance://[host1][:port],[host2][:port],[host3][:port]]/${tbl_name}?
useServerPrepStmts=true&cachePrepStmts=true&prepStmtCacheSize=500&prepStmtCacheSqlLimit=1024
```

- 打开 loadbalance 确保多个 FE 都能提供服务, 并且 FE 数量越多越好 (每个实例都部署一个)
- 打开 useServerPrepStmts, 减少 fe 解析、规划开销
- 打开 cachePrepStmts 客户端缓存 prepared statement, 不用频繁向 FE 发送 prepared 请求
- 调整 prepStmtCacheSize, 设置最大可缓存的查询模版数量 ()
- 调整 prepStmtCacheSqlLimit, 设置单条缓存的 SQL 模版的最大长度

## 7. 存算分离下怎么优化查询性能?

A:

- set global enable\_snapshot\_point\_query = false, 点查从 meta service 获取 version 会多一次额外的 RPC, 并且 meta service 在高 QPS 场景下容易成为瓶颈, 设置成 false 可以加速查询但是会降低数据可见性 (需权衡性能和可见性)
- 配置 BE 参数 enable\_file\_cache\_keep\_base\_compaction\_output=1, 使得 Base Compact 后的结果数据放入缓存, 避免远程访问导致的查询抖动。

# TOPN 查询优化

TOPN 查询是指下面这种 ORDER BY LIMIT 查询，在日志检索等明细查询场景中很常见，Doris 会自动对这种类型的查询进行优化。

```
SELECT * FROM tablex WHERE xxx ORDER BY c1,c2 ... LIMIT n
```

## TOPN 查询优化的优化点

1. 执行过程中动态对排序列构建范围过滤条件（比如  $c1 \geq 10000$ ），读数据时自动带上前面的条件，利用 zonemap 索引过滤掉一些数据甚至文件。
2. 如果排序字段  $c1, c2$  正好是 table key 的前缀，则更进一步优化，读数据的时候只用读数据文件的头部或者尾部  $n$  行。
3. SELECT \* 延迟物化，读数据和排序过程中只读排序列不读其它列，得到符合条件的行号后，再去读那  $n$  行需要的全部列数据，大幅减少读取和排序的列。

## TOPN 查询优化的限制

1. 只能用于 duplicate 表和 unique mow 表，因为 mor 表用这个优化可能有结果错误。
2. 对于过大的  $n$ ，优化内存消耗会很大，所以超过 `topn_opt_limit_threshold` session 变量的  $n$  不会使用优化。

## 配置参数和查询分析

下面两个参数都是 session variable，可以针对某个 SQL 或者全局设置。1. `topn_opt_limit_threshold`，LIMIT  $n$  小于这个值才会有优化，默认值 1024，将它设置为 0 可以关闭 TOPN 查询优化。2. `enable_two_phase_read_opt`，是否开启优化 3，默认为 true，可以调为 false 关闭这个优化。

## 检查 TOPN 查询优化是否启用

explain SQL 拿到 query plan 可以确认这个 sql 是否启用 TOPN 查询优化，以下面的为例：- TOPN OPT 代表有优化 1 - VOlapScanNode 下面有 SORT LIMIT 代表有优化 2 - OPT TWO PHRASE 代表有优化 3

```
1:VTOP-N(137)
| order by: @timestamp18 DESC
| TOPN OPT
| OPT TWO PHRASE
| offset: 0
| limit: 10
| distribute expr lists: applicationName5
|
0:VOlapScanNode(106)
 TABLE: log_db.log_core_all_no_index(log_core_all_no_index), PREAGGREGATION: ON
 SORT INFO:
 @timestamp18
 SORT LIMIT: 10
 TOPN OPT:1
 PREDICATES: ZYCFC-TRACE-ID4 like '%flowId-1720055220933%'
```



```
partitions=1/8 (p20240704), tablets=250/250, tabletList=1727094,1727096,1727098 ...
cardinality=345472780, avgRowSize=0.0, numNodes=1
pushAggOp=NONE
```

## 检查 TOPN 查询优化执行时是否有效果

首先，可以将 `topn_opt_limit_threshold` 设置为 0 关闭 TOPN 查询优化，对比开启和关闭优化的 SQL 执行时间。

开启 TOPN 查询优化后，在 query profile 中搜索 RuntimePredicate，关注下面几个指标： -

RowsZonemapRuntimePredicateFiltered 这个代表过滤掉的行数，越大越好 - NumSegmentFiltered 这个代表过滤掉的数据文件个数，越大越好 - BlockConditionsFilteredZonemapRuntimePredicateTime 代表过滤数据的耗时，越小越好

2.0.3 之前的版本 RuntimePredicate 的指标没有独立出来，可以通过 Zonamap 指标大致观察。

```
SegmentIterator:
- BitmapIndexFilterTimer: 46.54us
- BlockConditionsFilteredBloomFilterTime: 10.352us
- BlockConditionsFilteredDictTime: 7.299us
- BlockConditionsFilteredTime: 202.23ms
- BlockConditionsFilteredZonemapRuntimePredicateTime: 0ns
- BlockConditionsFilteredZonemapTime: 402.917ms
- BlockInitSeekCount: 399
- BlockInitSeekTime: 11.309ms
- BlockInitTime: 215.59ms
- BlockLoadTime: 7s567ms
- BlocksLoad: 392.97K (392970)
- CachedPagesNum: 0
- CollectIteratorMergeTime: 0ns
- CollectIteratorNormalTime: 0ns
- CompressedBytesRead: 29.76 MB
- DecompressorTimer: 427.713ms
- ExprFilterEvalTime: 3s930ms
- FirstReadSeekCount: 392.921K (392921)
- FirstReadSeekTime: 528.287ms
- FirstReadTime: 1s134ms
- IOTimer: 51.286ms
- InvertedIndexFilterTime: 49.457us
- InvertedIndexQueryBitmapCopyTime: 0ns
- InvertedIndexQueryBitmapOpTime: 0ns
- InvertedIndexQueryCacheHit: 0
- InvertedIndexQueryCacheMiss: 0
- InvertedIndexQueryTime: 0ns
- InvertedIndexSearcherOpenTime: 0ns
- InvertedIndexSearcherSearchTime: 0ns
- LazyReadSeekCount: 0
- LazyReadSeekTime: 0ns
- LazyReadTime: 106.952us
- NumSegmentFiltered: 0
- NumSegmentTotal: 50
- OutputColumnTime: 61.987ms
- OutputIndexResultColumnTimer: 12.345ms
- RawRowsRead: 3.929151M (3929151)
- RowsBitmapIndexFiltered: 0
- RowsBloomFilterFiltered: 0
- RowsConditionsFiltered: 6.38976M (6389760)
- RowsDictFiltered: 0
- RowsInvertedIndexFiltered: 0
- RowsKeyRangeFiltered: 0
```

- RowsShortCircuitPredFiltered: 0
- RowsShortCircuitPredInput: 0
- RowsStatsFiltered: 6.38976M (6389760)
- RowsVectorPredFiltered: 0
- RowsVectorPredInput: 0
- RowsZonemapRuntimePredicateFiltered: 6.38976M (6389760)
- SecondReadTime: 0ns
- ShortPredEvalTime: 0ns
- TotalPagesNum: 2.301K (2301)
- UncompressedBytesRead: 137.99 MB
- VectorPredEvalTime: 0ns

# Query Profile

本文档主要介绍 Doris 在查询执行的统计结果。利用这些统计的信息，可以更好的帮助我们了解 Doris 的执行情况，并针对性的进行相应 **Debug 与调优** 工作。

也可以参考如下语法在命令行中查看导入和查询的 Profile：

- [SHOW QUERY PROFILE](#)
- [SHOW LOAD PROFILE](#)

## 名词解释

- FE：Frontend，Doris 的前端节点。负责元数据管理和请求接入。
- BE：Backend，Doris 的后端节点。负责查询执行和数据存储。
- Fragment：FE 会将具体的 SQL 语句的执行转化为对应的 Fragment 并下发到 BE 进行执行。BE 上执行对应 Fragment，并将结果汇聚返回给 FE。

## 基本原理


FE 将查询计划拆分为 Fragment 下发到 BE 进行任务执行。BE 在执行 Fragment 时记录了 **运行状态时的统计值**，并将 Fragment 执行的统计信息输出到日志之中。FE 也可以通过开关将各个 Fragment 记录的这些统计值进行搜集，并在 FE 的 Web 页面上打印结果。

## 操作流程

通过 Mysql 命令，将 FE 上的 Report 的开关打开

```
mysql> set enable_profile=true;
```

之后执行对应的 SQL 语句之后（旧版本为 `is_report_success`），在 FE 的 Web 页面就可以看到对应 SQL 语句执行的 Report 信息：



DORIS	Playground	System	Log	QueryProfile	Session	Configuration	中文	root
Finished Queries								
This table lists the latest 100 queries								
Profile ID	Task Type	Start Time	End Time	Total	Task State	User	Default Db	Sql Statement
578cb4ac275b48a1-98c4f00e0816edea	QUERY	2023-05-30 15:58:09	2023-05-30 15:58:09	22ms	EOF	root		select 1
1-1 of 1 items < 1 > 30 / page								

这里会列出最新执行完成的 **100 条** 语句，我们可以通过 Profile 查看详细的统计信息。

```
Query:
 Summary:
 Query ID: 9664061c57e84404-85ae111b8ba7e83a
 Start Time: 2020-05-02 10:34:57
 End Time: 2020-05-02 10:35:08
 Total: 10s323ms
 Query Type: Query
 Query State: EOF
 Doris Version: trunk
 User: root
 Default Db: default_cluster:test
 Sql Statement: select max(Bid_Price) from quotes group by Symbol
```

这里详尽的列出了查询的 ID，执行时间，执行语句等等的总结信息。接下来内容是打印从 BE 收集到的各个 Fragment 的详细信息。

```
Fragment 0:
 Instance 9664061c57e84404-85ae111b8ba7e83d (host=TNetworkAddress(hostname:192.168.0.1, port:9060)):
 (Active: 10s270ms, % non-child: 0.14%)
 - MemoryLimit: 2.00 GB
 - BytesReceived: 168.08 KB
 - PeakUsedReservation: 0.00
 - SendersBlockedTimer: 0ns
 - DeserializeRowBatchTimer: 501.975us
 - PeakMemoryUsage: 577.04 KB
 - RowsProduced: 8.322K (8322)
 EXCHANGE_NODE (id=4):(Active: 10s256ms, % non-child: 99.35%)
 - ConvertRowBatchTime: 180.171us
 - PeakMemoryUsage: 0.00
 - RowsReturned: 8.322K (8322)
 - MemoryUsed: 0.00
 - RowsReturnedRate: 811
```

这里列出了 Fragment 的 ID；hostname指的是执行 Fragment 的 BE 节点；Active: 10s270ms表示该节点的执行总时间；non-child: 0.14%表示执行节点自身的执行时间（不包含子节点的执行时间）占总时间的百分比；

PeakMemoryUsage表示EXCHANGE\_NODE内存使用的峰值；RowsReturned表示EXCHANGE\_NODE结果返回的行数；RowsReturnedRate=RowsReturned/ActiveTime；这三个统计信息在其他NODE中的含义相同。

后续依次打印子节点的统计信息，这里可以通过缩进区分节点之间的父子关系。

## Profile 参数解析

BE 端收集的统计信息较多，下面列出了各个参数的对应含义：

Fragment

- AverageThreadTokens: 执行 Fragment 使用线程数目，不包含线程池的使用情况
- Buffer Pool PeakReservation: Buffer Pool 使用的内存的峰值
- MemoryLimit: 查询时的内存限制
- PeakMemoryUsage: 整个 Instance 在查询时内存使用的峰值
- RowsProduced: 处理列的行数

## BlockMgr

- BlocksCreated: BlockMgr 创建的 Blocks 数目
- BlocksRecycled: 重用的 Blocks 数目
- BytesWritten: 总的落盘写数据量
- MaxBlockSize: 单个 Block 的大小
- TotalReadBlockTime: 读 Block 的总耗时

## DataStreamSender

- BytesSent: 发送的总数据量 = 接受者 \* 发送数据量
- IgnoreRows: 过滤的行数
- LocalBytesSent: 数据在 Exchange 过程中, 记录本机节点的自发自收数据量
- OverallThroughput: 总的吞吐量 = BytesSent / 时间
- SerializeBatchTime: 发送数据序列化消耗的时间
- UncompressedRowBatchSize: 发送数据压缩前的 RowBatch 的大小

## ODBC\_TABLE\_SINK - NumSentRows: 写入外表的总行数

- TupleConvertTime: 发送数据序列化为 Insert 语句的耗时
- ResultSendTime: 通过 ODBC Driver 写入的耗时

## EXCHANGE\_NODE - BytesReceived: 通过网络接收的数据量大小

- MergeGetNext: 当下层节点存在排序时, 会在 EXCHANGE NODE 进行统一的归并排序, 输出有序结果。该指标记录了 Merge 排序的总耗时, 包含了 MergeGetNextBatch 耗时。
- MergeGetNextBatch: Merge 节点取数据的耗时, 如果为单层 Merge 排序, 则取数据的对象为网络队列。若为多层 Merge 排序取数据对象为 Child Merger。
- ChildMergeGetNext: 当下层的发送数据的 Sender 过多时, 单线程的 Merge 会成为性能瓶颈, Doris 会启动多个 Child Merge 线程并行归并排序。记录了 Child Merge 的排序耗时 该数值是多个线程的累加值。
- ChildMergeGetNextBatch: Child Merge 节点从取数据的耗时, 如果耗时过大, 可能的瓶颈为下层的数据发送节点。
- DataArrivalWaitTime: 等待 Sender 发送数据的总时间
- FirstBatchArrivalWaitTime: 等待第一个 batch 从 Sender 获取的时间
- DeserializeRowBatchTimer: 反序列化网络数据的耗时
- SendersBlockedTotalTimer(\*): DataStreamRecv 的队列的内存被打满, Sender 端等待的耗时
- ConvertRowBatchTime: 接收数据转为 RowBatch 的耗时

- RowsReturned: 接收行的数目
- RowsReturnedRate: 接收行的速率

**Sort\_Node - InMemorySortTime:** 内存之中的排序耗时

- InitialRunsCreated: 初始化排序的趟数（如果内存排序的话，该数为 1）
- SortDataSize: 总的排序数据量
- MergeGetNext: MergeSort 从多个 sort\_run 获取下一个 batch 的耗时 (仅在落盘时计时)
- MergeGetNextBatch: MergeSort 提取下一个 sort\_run 的 batch 的耗时 (仅在落盘时计时)
- TotalMergesPerformed: 进行外排 merge 的次数

**Aggregation\_Node - PartitionsCreated:** 聚合查询拆分成 Partition 的个数

- GetResultsTime: 从各个 partition 之中获取聚合结果的时间
- HTResizeTime: HashTable 进行 resize 消耗的时间
- HTResize: HashTable 进行 resize 的次数
- HashBuckets: HashTable 中 Buckets 的个数
- HashBucketsWithDuplicate: HashTable 有 DuplicateNode 的 Buckets 的个数
- HashCollisions: HashTable 产生哈希冲突的次数
- HashDuplicateNodes: HashTable 出现 Buckets 相同 DuplicateNode 的个数
- HashFailedProbe: HashTable Probe 操作失败的次数
- HashFilledBuckets: HashTable 填入数据的 Buckets 数目
- HashProbe: HashTable 查询的次数
- HashTravelLength: HashTable 查询时移动的步数

**Hash\_Join\_Node - ExecOption:** 对右孩子构造 HashTable 的方式（同步 or 异步），Join 中右孩子可能是表或子查询，左孩子同理

- BuildBuckets: HashTable 中 Buckets 的个数
- BuildRows: HashTable 的行数
- BuildTime: 构造 HashTable 的耗时
- LoadFactor: HashTable 的负载因子（即非空 Buckets 的数量）
- ProbeRows: 遍历左孩子进行 Hash Probe 的行数
- ProbeTime: 遍历左孩子进行 Hash Probe 的耗时，不包括对左孩子 RowBatch 调用 GetNext 的耗时
- PushDownComputeTime: 谓词下推条件计算耗时

- PushDownTime: 谓词下推的总耗时, Join 时对满足要求的右孩子, 转为左孩子的 in 查询

## CROSS\_JOIN\_NODE

- ExecOption: 对右孩子构造 RowBatchList 的方式 (同步 or 异步)
- BuildRows: RowBatchList 的行数 (即右孩子的行数)
- BuildTime: 构造 RowBatchList 的耗时
- LeftChildRows: 左孩子的行数
- LeftChildTime: 遍历左孩子, 和右孩子求笛卡尔积的耗时, 不包括对左孩子 RowBatch 调用 GetNext 的耗时

## UNION\_NODE

- MaterializeExprsEvaluateTime: Union 两端字段类型不一致时, 类型转换表达式计算及物化结果的耗时

## ANALYTIC\_EVAL\_NODE - EvaluationTime: 分析函数 (窗口函数) 计算总耗时

- GetNewBlockTime: 初始化时申请一个新的 Block 的耗时, Block 用来缓存 Rows 窗口或整个分区, 用于分析函数计算
- PinTime: 后续申请新的 Block 或将写入磁盘的 Block 重新读取回内存的耗时
- UnpinTime: 对暂不需要使用的 Block 或当前操作符内存压力大时, 将 Block 的数据刷入磁盘的耗时

## OLAP\_SCAN\_NODE

OLAP\_SCAN\_NODE 节点负责具体的数据扫描任务。一个 OLAP\_SCAN\_NODE 会生成一个或多个 OlapScanner。每个 Scanner 线程负责扫描部分数据。

查询中的部分或全部谓词条件会推送给 OLAP\_SCAN\_NODE。这些谓词条件中一部分会继续下推给存储引擎, 以便利用存储引擎的索引进行数据过滤。另一部分会保留在 OLAP\_SCAN\_NODE 中, 用于过滤从存储引擎中返回的数据。

OLAP\_SCAN\_NODE 节点的 Profile 通常用于分析数据扫描的效率, 依据调用关系分为 OLAP\_SCAN\_NODE、OlapScanner、SegmentIterator 三层。

一个典型的 OLAP\_SCAN\_NODE 节点的 Profile 如下。部分指标会因存储格式的不同 (V1 或 V2) 而有不同含义。

```
OLAP_SCAN_NODE (id=0):(Active: 1.2ms, % non-child: 0.00%)
- BytesRead: 265.00 B # 从数据文件中读取到的数据量。假设读取到了是10个32位整型, 则数据量为 10 * 4B = 40 Bytes。这个数据仅表示数据在内存中全展开的大小, 并不代表实际的 IO 大小。
- NumDiskAccess: 1 # 该 ScanNode 节点涉及到的磁盘数量。
- NumScanners: 20 # 该 ScanNode 生成的 Scanner 数量。
- PeakMemoryUsage: 0.00 # 查询时内存使用的峰值, 暂未使用
- RowsRead: 7 # 从存储引擎返回到 Scanner 的行数, 不包括经 Scanner 过滤的行数。
- RowsReturned: 7 # 从 ScanNode 返回给上层节点的行数。
- RowsReturnedRate: 6.979K /sec # RowsReturned/ActiveTime
- TabletCount : 20 # 该 ScanNode 涉及的 Tablet 数量。
- TotalReadThroughput: 74.70 KB/sec # BytesRead除以该节点运行的总时间 (从Open到Close), 对于IO受限的查询, 接近磁盘的总吞吐量。
- ScannerBatchWaitTime: 426.886us # 用于统计transfer 线程等待scanner 线程返回rowbatch的时间。在Pipeline调度中, 此值无意义。
- ScannerWorkerWaitTime: 17.745us # 用于统计scanner thread 等待线程池中可用工作线程的时间。
```

```

OlapScanner:
- BlockConvertTime: 8.941us # 将向量化Block转换为行结构的 RowBlock 的耗时。向量化 Block 在 V1 中为
VectorizedRowBatch, V2中为 RowBlockV2。
- BlockFetchTime: 468.974us # Rowset Reader 获取 Block 的时间。
- ReaderInitTime: 5.475ms # OlapScanner 初始化 Reader 的时间。V1 中包括组建 MergeHeap 的时间。V2 中包
括生成各级 Iterator 并读取第一组Block的时间。
- RowsDelFiltered: 0 # 包括根据 Tablet 中存在的 Delete 信息过滤掉的行数, 以及 unique key 模型下对
被标记的删除行过滤的行数。
- RowsPushedCondFiltered: 0 # 根据传递下推的谓词过滤掉的条件, 比如 Join 计算中从 BuildTable 传递给
ProbeTable 的条件。该数值不准确, 因为如果过滤效果差, 就不再过滤了。
- ScanTime: 39.24us # 从 ScanNode 返回给上层节点的时间。
- ShowHintsTime_V1: 0ns # V2 中无意义。V1 中读取部分数据来进行 ScanRange 的切分。
SegmentIterator:
- BitmapIndexFilterTimer: 779ns # 利用 bitmap 索引过滤数据的耗时。
- BlockLoadTime: 415.925us # SegmentReader(V1) 或 SegmentIterator(V2) 获取 block 的时间。
- BlockSeekCount: 12 # 读取 Segment 时进行 block seek 的次数。
- BlockSeekTime: 222.556us # 读取 Segment 时进行 block seek 的耗时。
- BlocksLoad: 6 # 读取 Block 的数量
- CachedPagesNum: 30 # 仅 V2 中, 当开启 PageCache 后, 命中 Cache 的 Page 数量。
- CompressedBytesRead: 0.00 # V1 中, 从文件中读取的解压前的数据大小。V2 中, 读取到的没有命中 PageCache 的
Page 的压缩前的大小。
- DecompressorTimer: 0ns # 数据解压耗时。
- IOTimer: 0ns # 实际从操作系统读取数据的 IO 时间。
- IndexLoadTime_V1: 0ns # 仅 V1 中, 读取 Index Stream 的耗时。
- NumSegmentFiltered: 0 # 在生成 Segment Iterator 时, 通过列统计信息和查询条件, 完全过滤掉的 Segment
数量。
- NumSegmentTotal: 6 # 查询涉及的所有 Segment 数量。
- RawRowsRead: 7 # 存储引擎中读取的原始行数。详情见下文。
- RowsBitmapIndexFiltered: 0 # 仅 V2 中, 通过 Bitmap 索引过滤掉的行数。
- RowsBloomFilterFiltered: 0 # 仅 V2 中, 通过 BloomFilter 索引过滤掉的行数。
- RowsKeyRangeFiltered: 0 # 仅 V2 中, 通过 SortkeyIndex 索引过滤掉的行数。
- RowsStatsFiltered: 0 # V2 中, 通过 ZoneMap 索引过滤掉的行数, 包含删除条件。V1 中还包含通过
BloomFilter 过滤掉的行数。
- RowsConditionsFiltered: 0 # 仅 V2 中, 通过各种列索引过滤掉的行数。
- RowsVectorPredFiltered: 0 # 通过向量化条件过滤操作过滤掉的行数。
- TotalPagesNum: 30 # 仅 V2 中, 读取的总 Page 数量。
- UncompressedBytesRead: 0.00 # V1 中为读取的数据文件解压后的大小 (如果文件无需解压, 则直接统计文件大小)。V2
中, 仅统计未命中 PageCache 的 Page 解压后的大小 (如果Page无需解压, 直接统计Page大小)
- VectorPredEvalTime: 0ns # 向量化条件过滤操作的耗时。
- ShortPredEvalTime: 0ns # 短路谓词过滤操作的耗时。
- PredColumnReadTime: 0ns # 谓词列读取的耗时。
- LazyReadTime: 0ns # 非谓词列读取的耗时。
- OutputColumnTime: 0ns # 物化列的耗时。

```

通过 Profile 中数据行数相关指标可以推断谓词条件下推和索引使用情况。以下仅针对 Segment V2 格式数据读取流程中的 Profile 进行说明。Segment V1 格式中, 这些指标的含义略有不同。

1. 当读取一个 V2 格式的 Segment 时, 若查询存在 key\_ranges (前缀 key 组成的查询范围), 首先通过 SortkeyIndex 索引过滤数据, 过滤的行数记录在 RowsKeyRangeFiltered。
2. 之后, 对查询条件中含有 bitmap 索引的列, 使用 Bitmap 索引进行精确过滤, 过滤的行数记录在 RowsBitmapIndexFiltered。
3. 之后, 按查询条件中的等值 (eq, in, is) 条件, 使用 BloomFilter 索引过滤数据, 记录在 RowsBloomFilterFiltered。RowsBloomFilterFiltered 的值是 Segment 的总行数 (而不是 Bitmap 索引过滤后的行数) 和经过 BloomFilter 过滤后剩余行数的差值, 因此 BloomFilter 过滤的数据可能会和 Bitmap 过滤的数据有重叠。
4. 之后, 按查询条件和删除条件, 使用 ZoneMap 索引过滤数据, 记录在 RowsStatsFiltered。



5. RowsConditionsFiltered 是各种索引过滤的行数，包含了 RowsBloomFilterFiltered 和 RowsStatsFiltered 的值。

6. 至此 Init 阶段完成，Next 阶段删除条件过滤的行数，记录在 RowsDelFiltered。因此删除条件实际过滤的行数，分别记录在 RowsStatsFiltered 和 RowsDelFiltered 中。

7. RawRowsRead 是经过上述过滤后，最终需要读取的行数。

8. RowsRead 是最终返回给 Scanner 的行数。RowsRead 通常小于 RawRowsRead，是因为从存储引擎返回到 Scanner，可能会经过一次数据聚合。如果 RawRowsRead 和 RowsRead 差距较大，则说明大量的行被聚合，而聚合可能比较耗时。

9. RowsReturned 是 ScanNode 最终返回给上层节点的行数。RowsReturned 通常也会小于 RowsRead。因为在 Scanner 上会有一些没有下推给存储引擎的谓词条件，会进行一次过滤。如果 RowsRead 和 RowsReturned 差距较大，则说明很多行在 Scanner 中进行了过滤。这说明很多选择度高的谓词条件并没有推送给存储引擎。而在 Scanner 中的过滤效率会比在存储引擎中过滤效率差。

通过以上指标，可以大致分析出存储引擎处理的行数以及最终过滤后的结果行数大小。通过 RowsFiltered 这组指标，也可以分析查询条件是否下推到了存储引擎，以及不同索引的过滤效果。此外还可以通过以下几个方面进行简单的分析。

1. OlapScanner 下的很多指标，如 IOTimer，BlockFetchTime 等都是所有 Scanner 线程指标的累加，因此数值可能会比较大。并且因为 Scanner 线程是异步读取数据的，所以这些累加指标只能反映 Scanner 累加的工作时间，并不直接代表 ScanNode 的耗时。ScanNode 在整个查询计划中的耗时占比为 Active 字段记录的值。有时会出现比如 IOTimer 有几十秒，而 Active 实际只有几秒钟。这种情况通常因为：

- IOTimer 为多个 Scanner 的累加时间，而 Scanner 数量较多。
- 上层节点比较耗时。比如上层节点耗时 100 秒，而底层 ScanNode 只需 10 秒。则反映在 Active 的字段可能只有几毫秒。因为在上层处理数据的同时，ScanNode 已经异步的进行了数据扫描并准备好了数据。当上层节点从 ScanNode 获取数据时，可以获取到已经准备好的数据，因此 Active 时间很短。

2. NumScanners 表示 Scanner 提交到线程池的 Task 个数，由 RuntimeState 中的线程池调度，doris\_scanner\_thread\_pool\_thread\_num 和 doris\_scanner\_thread\_pool\_queue\_size 两个参数分别控制线程池的大小和队列长度。线程数过多或过少都会影响查询效率。同时可以用一些汇总指标除以线程数来大致估算每个线程的耗时。

- TabletCount 表示需要扫描的 tablet 数量。数量过多可能意味着需要大量的随机读取和数据合并操作。
- UncompressedBytesRead 间接反映了读取的数据量。如果该数值较大，说明可能有大量的 IO 操作。
- CachedPagesNum 和 TotalPagesNum 可以查看命中 PageCache 的情况。命中率越高，说明 IO 和解压操作耗时越少。

## Buffer pool

- AllocTime: 内存分配耗时
- CumulativeAllocationBytes: 累计内存分配的量
- CumulativeAllocations: 累计的内存分配次数
- PeakReservation: Reservation 的峰值

- PeakUnpinnedBytes: unpin 的内存数据量
- PeakUsedReservation: Reservation 的内存使用量
- ReservationLimit: BufferPool 的 Reservation 的限制量

# 查询分析


Doris 提供了一个图形化的命令以帮助用户更方便的分析一个具体的查询或导入。本文介绍如何使用该功能。

## 查询计划树


SQL 是一个描述性语言，用户通过一个 SQL 来描述想获取的数据。而一个 SQL 的具体执行方式依赖于数据库的实现。而查询规划器就是用来决定数据库如何具体执行一个 SQL 的。


比如用户指定了一个 Join 算子，则查询规划器需要决定具体的 Join 算法，比如是 Hash Join，还是 Merge Sort Join；是使用 Shuffle 还是 Broadcast；Join 顺序是否需要调整以避免笛卡尔积；以及确定最终的在哪些节点执行等等。

Doris 的查询规划过程是先将一个 SQL 语句转换成一个单机执行计划树。



之后，查询规划器会根据具体的算子执行方式、数据的具体分布，将单机查询计划转换为分布式查询计划。分布式查询计划是由多个 Fragment 组成的，每个 Fragment 负责查询计划的一部分，各个 Fragment 之间会通过 ExchangeNode 算子进行数据的传输。





如上图，我们将单机计划分成了两个 Fragment：F1 和 F2。两个 Fragment 之间通过一个 ExchangeNode 节点传输数据。

而一个 Fragment 会进一步的划分为多个 Instance。Instance 是最终具体的执行实例。划分成多个 Instance 有助于充分利用机器资源，提升一个 Fragment 的执行并发度。

## 查看查询计划

可以通过以下三种命令查看一个 SQL 的执行计划。


- `EXPLAIN GRAPH select ...;` 或者 `DESC GRAPH select ...;`：这些命令提供了执行计划的图形表示。它们帮助我们可视化查询执行的流程，包括关联路径和数据访问方法。
- `EXPLAIN select ...;`：这个命令显示指定 SQL 查询的执行计划的文本表示形式。它提供了有关查询优化步骤的信息，例如操作的顺序、执行算法和访问方法等。
- `EXPLAIN VERBOSE select ...;`：与前一个命令类似，这个命令提供了更详细的输出结果。
- `EXPLAIN PARSED PLAN select ...;`：这个命令返回 SQL 查询的解析后的执行计划。它显示了计划树和查询处理中涉及的逻辑操作符的信息。
- `EXPLAIN ANALYZED PLAN select ...;`：这个命令返回 SQL 查询的分析后的执行计划。
- `EXPLAIN REWRITTEN PLAN select ...;`：这个命令在数据库引擎对查询进行任何查询转换或优化后显示了重写后的执行计划。它提供了查询为了提高性能而进行的修改的见解。
- `EXPLAIN OPTIMIZED PLAN select ...;`：这个命令返回了 CBO 中得到的最优计划
- `EXPLAIN SHAPE PLAN select ...;`：这个命令以查询的形状和结构为重点，呈现了简化后的最优执行计划。


其中第一个命令以图形化的方式展示一个查询计划，这个命令可以比较直观的展示查询计划的树形结构，以及 Fragment 的划分情况：


```

mysql> explain graph select tbl1.k1, sum(tbl1.k2) from tbl1 join tbl2 on tbl1.k1 = tbl2.k1 group by tbl1.k1
order by tbl1.k1;
+-----+
+-----+
| Explain String
|
+-----+
+-----+
|
|
|
+-----+

```







从图中可以看出，查询计划树被分为了 5 个 Fragment：0、1、2、3、4。如 OlapScanNode 节点上的 [Fragment：0] 表示这个节点属于 Fragment 0。每个 Fragment 之间都通过 DataStreamSink 和 ExchangeNode 进行数据传输。

图形命令仅展示简化后的节点信息，如果需要查看更具体的节点信息，如下推到节点上的过滤条件等，则需要通过第二个命令查看更详细的文字版信息：

```
mysql> explain select tbl1.k1, sum(tbl1.k2) from tbl1 join tbl2 on tbl1.k1 = tbl2.k1 group by tbl1.k1 order
by tbl1.k1;
+-----+
| Explain String |
+-----+
| PLAN FRAGMENT 0 |
| OUTPUT EXPRS:<slot 5> <slot 3> `tbl1`.`k1` | <slot 6> <slot 4> sum(`tbl1`.`k2`) |
| PARTITION: UNPARTITIONED |
| |
| RESULT SINK |
| |
| 9:MERGING-EXCHANGE |
| limit: 65535 |
| |
| PLAN FRAGMENT 1 |
| OUTPUT EXPRS: |
| PARTITION: HASH_PARTITIONED: <slot 3> `tbl1`.`k1` |
| |
| STREAM DATA SINK |
| EXCHANGE ID: 09 |
| UNPARTITIONED |
| |
| 4:TOP-N |
| | order by: <slot 5> <slot 3> `tbl1`.`k1` ASC |
| | offset: 0 |
| | limit: 65535 |
| |
| 8:AGGREGATE (merge finalize) |
| | output: sum(<slot 4> sum(`tbl1`.`k2`)) |
| | group by: <slot 3> `tbl1`.`k1` |
| | cardinality=-1 |
| |
| 7:EXCHANGE |
| |
| PLAN FRAGMENT 2 |
| OUTPUT EXPRS: |
| PARTITION: HASH_PARTITIONED: `tbl1`.`k1` |
| |
| STREAM DATA SINK |
```

```

| EXCHANGE ID: 07
| HASH_PARTITIONED: <slot 3> `tbl1`.`k1`
|
| 3:AGGREGATE (update serialize)
| | STREAMING
| | output: sum(`tbl1`.`k2`)
| | group by: `tbl1`.`k1`
| | cardinality=-1
| |
| 2:HASH JOIN
| | join op: INNER JOIN (PARTITIONED)
| | runtime filter: false
| | hash predicates:
| | colocate: false, reason: table not in the same group
| | equal join conjunct: `tbl1`.`k1` = `tbl2`.`k1`
| | cardinality=2
| |
| |----6:EXCHANGE
| |
| 5:EXCHANGE
|
| PLAN FRAGMENT 3
| OUTPUT EXPRS:
| PARTITION: RANDOM
|
| STREAM DATA SINK
| EXCHANGE ID: 06
| HASH_PARTITIONED: `tbl2`.`k1`
|
| 1:0lapScanNode
| TABLE: tbl2
| PREAGGREGATION: ON
| partitions=1/1
| rollup: tbl2
| tabletRatio=3/3
| tabletList=105104776,105104780,105104784
| cardinality=1
| avgRowSize=4.0
| numNodes=6
|
| PLAN FRAGMENT 4
| OUTPUT EXPRS:
| PARTITION: RANDOM
|
| STREAM DATA SINK
| EXCHANGE ID: 05
| HASH_PARTITIONED: `tbl1`.`k1`
|
| 0:0lapScanNode
| TABLE: tbl1
| PREAGGREGATION: ON
| partitions=1/1
| rollup: tbl1
| tabletRatio=3/3
| tabletList=105104752,105104763,105104767
| cardinality=2
| avgRowSize=8.0
| numNodes=6
|
+-----+

```

第三个命令EXPLAIN VERBOSE select ...;相比第二个命令可以查看更详细的执行计划信息。



```
mysql> explain verbose select tbl1.k1, sum(tbl1.k2) from tbl1 join tbl2 on tbl1.k1 = tbl2.k1 group by tbl1.k1
order by tbl1.k1;
```

```
+-----+
| Explain String
|
+-----+
| PLAN FRAGMENT 0
|
| OUTPUT EXPRS:<slot 5> <slot 3> `tbl1`.`k1` | <slot 6> <slot 4> sum(`tbl1`.`k2`)
|
| PARTITION: UNPARTITIONED
|
|
| VRESULT SINK
|
|
| 6:VMERGING-EXCHANGE
|
| limit: 65535
|
| tuple ids: 3
|
|
| PLAN FRAGMENT 1
|
|
| PARTITION: HASH_PARTITIONED: `default_cluster:test`.`tbl1`.`k2`
|
|
| STREAM DATA SINK
|
| EXCHANGE ID: 06
|
| UNPARTITIONED
|
|
| 4:VTOP-N
|
| | order by: <slot 5> <slot 3> `tbl1`.`k1` ASC
|
| | offset: 0
|
| | limit: 65535
|
| | tuple ids: 3
|
| |
|
| 3:VAGGREGATE (update finalize)
|
| | output: sum(<slot 8>)
|
| | group by: <slot 7>
|
| | cardinality=-1
|
```

```

| | tuple ids: 2
|
|
| 2:VHASH JOIN
|
| join op: INNER JOIN(BROADCAST)[Tables are not in the same group]
|
| equal join conjunct: CAST(`tbl1`.`k1` AS DATETIME) = `tbl2`.`k1`
|
| runtime filters: RF000[in_or_bloom] <- `tbl2`.`k1`
|
| cardinality=0
|
| vec output tuple id: 4 | tuple ids: 0 1
|
|
| ----5:VEXCHANGE
|
| tuple ids: 1
|
|
| 0:VOverlapScanNode
|
| TABLE: tbl1(null), PREAGGREGATION: OFF. Reason: the type of agg on StorageEngine's Key column should
only be MAX or MIN.agg expr: sum(`tbl1`.`k2`) |
| runtime filters: RF000[in_or_bloom] -> CAST(`tbl1`.`k1` AS DATETIME)
|
| partitions=0/1, tablets=0/0, tabletList=
|
| cardinality=0, avgRowSize=20.0, numNodes=1
|
| tuple ids: 0
|
|
| PLAN FRAGMENT 2
|
|
| PARTITION: HASH_PARTITIONED: `default_cluster:test`.`tbl2`.`k2`
|
|
| STREAM DATA SINK
|
| EXCHANGE ID: 05
|
| UNPARTITIONED
|
|
| 1:VOverlapScanNode
|
| TABLE: tbl2(null), PREAGGREGATION: OFF. Reason: null
|
| partitions=0/1, tablets=0/0, tabletList=
|
| cardinality=0, avgRowSize=16.0, numNodes=1
|
| tuple ids: 1
|
|

```

Tuples:

TupleDescriptor{id=0, tbl=tbl1, byteSize=32, materialized=true}

SlotDescriptor{id=0, col=k1, type=DATE}

parent=0

materialized=true

byteSize=16

byteOffset=16

nullIndicatorByte=0

nullIndicatorBit=-1

slotIdx=1

SlotDescriptor{id=2, col=k2, type=INT}

parent=0

materialized=true

byteSize=4

byteOffset=0

nullIndicatorByte=0

nullIndicatorBit=-1

slotIdx=0

TupleDescriptor{id=1, tbl=tbl2, byteSize=16, materialized=true}

SlotDescriptor{id=1, col=k1, type=DATETIME}

parent=1

materialized=true

byteSize=16

byteOffset=0

nullIndicatorByte=0

nullIndicatorBit=-1

slotIdx=0

```
| TupleDescriptor{id=2, tbl=null, byteSize=32, materialized=true}
```

```
| SlotDescriptor{id=3, col=null, type=DATE}
```

```
| parent=2
```

```
| materialized=true
```

```
| byteSize=16
```

```
| byteOffset=16
```

```
| nullIndicatorByte=0
```

```
| nullIndicatorBit=-1
```

```
| slotIdx=1
```

```
| SlotDescriptor{id=4, col=null, type=BIGINT}
```

```
| parent=2
```

```
| materialized=true
```

```
| byteSize=8
```

```
| byteOffset=0
```

```
| nullIndicatorByte=0
```

```
| nullIndicatorBit=-1
```

```
| slotIdx=0
```

```
| TupleDescriptor{id=3, tbl=null, byteSize=32, materialized=true}
```

```
| SlotDescriptor{id=5, col=null, type=DATE}
```

```
| parent=3
```

```
| materialized=true
```

```
| byteSize=16
```

```
| byteOffset=16
```

```
| nullIndicatorByte=0
```

```
| nullIndicatorBit=-1
```

```
| slotIdx=1
```

```
| SlotDescriptor{id=6, col=null, type=BIGINT}
```

```
| parent=3
```

```
| materialized=true
```

```
byteSize=8
byteOffset=0
nullIndicatorByte=0
nullIndicatorBit=-1
slotIdx=0
```

```
TupleDescriptor{id=4, tbl=null, byteSize=48, materialized=true}
```

```
SlotDescriptor{id=7, col=k1, type=DATE}
parent=4
materialized=true
byteSize=16
byteOffset=16
nullIndicatorByte=0
nullIndicatorBit=-1
slotIdx=1
```

```
SlotDescriptor{id=8, col=k2, type=INT}
parent=4
materialized=true
byteSize=4
byteOffset=0
nullIndicatorByte=0
nullIndicatorBit=-1
slotIdx=0
```

```
SlotDescriptor{id=9, col=k1, type=DATETIME}
parent=4
materialized=true
byteSize=16
byteOffset=32
nullIndicatorByte=0
```

```

| nullIndicatorBit=-1
|
| slotIdx=2
|
+-----+
-----+
160 rows in set (0.00 sec)

```

查询计划中显示的信息还在不断规范和完善中，我们将在后续的文章中详细介绍。

## 查看查询 Profile

用户可以通过以下命令打开会话变量 `is_report_success`:

```
SET is_report_success=true;
```

然后执行查询，则 Doris 会产生该查询的一个 Profile。Profile 包含了一个查询各个节点的具体执行情况，有助于我们分析查询瓶颈。

执行完查询后，我们可以通过如下命令先获取 Profile 列表：

```
mysql> show query profile "/"\G
***** 1. row *****
QueryId: c257c52f93e149ee-ace8ac14e8c9fef9
User: root
DefaultDb: default_cluster:db1
SQL: select tbl1.k1, sum(tbl1.k2) from tbl1 join tbl2 on tbl1.k1 = tbl2.k1 group by tbl1.k1 order by
tbl1.k1
QueryType: Query
StartTime: 2021-04-08 11:30:50
EndTime: 2021-04-08 11:30:50
TotalTime: 9ms
QueryState: EOF
```

这个命令会列出当前保存的所有 Profile。每行对应一个查询。我们可以选择我们想看的 Profile 对应的 QueryId，查看具体情况。


查看一个 Profile 分为 3 个步骤:

### 1. 查看整体执行计划树

这一步主要用于从整体分析执行计划，并查看每个 Fragment 的执行耗时。

```
mysql> show query profile "/c257c52f93e149ee-ace8ac14e8c9fef9"\G
***** 1. row *****
Fragments:

 [-1: DataBufferSender]
 |Fragment: 0
 |MaxActiveTime: 6.626ms|
 |
 | [9: EXCHANGE_NODE]
```



```
1 row in set (0.02 sec)
```

如上图，每个节点都标注了自己所属的 Fragment，并且在每个 Fragment 的 Sender 节点，标注了该 Fragment 的执行耗时。这个耗时，是 Fragment 下所有 Instance 执行耗时中最长的一个。这个有助于我们从整体角度发现最耗时的 Fragment。

## 2. 查看具体 Fragment 下的 Instance 列表

比如我们发现 Fragment 1 耗时最长，则可以继续查看 Fragment 1 的 Instance 列表：

```
mysql> show query profile "/c257c52f93e149ee-ace8ac14e8c9fef9/1";
```

Instances	Host	ActiveTime
c257c52f93e149ee-ace8ac14e8c9ff03	10.200.00.01:9060	5.449ms
c257c52f93e149ee-ace8ac14e8c9ff05	10.200.00.02:9060	5.367ms
c257c52f93e149ee-ace8ac14e8c9ff04	10.200.00.03:9060	5.358ms

这里展示了 Fragment 1 上所有的 3 个 Instance 所在的执行节点和耗时。

## 3. 查看具体 Instance

我们可以继续查看某一个具体的 Instance 上各个算子的详细 Profile：

```
mysql> show query profile "/c257c52f93e149ee-ace8ac14e8c9fef9/1/c257c52f93e149ee-ace8ac14e8c9ff03"\G
***** 1. row *****
Instance:
```

```
[9: DataStreamSender]
(Active: 37.222us, non-child: 0.40)
- Counters:
 - BytesSent: 0.00
 - IgnoreRows: 0
 - OverallThroughput: 0.0 /sec
 - PeakMemoryUsage: 8.00 KB
 - SerializeBatchTime: 0ns
 - UncompressedRowBatchSize: 0.00
```


```
└─┘
 |
```

```
[4: SORT_NODE]
(Active: 5.421ms, non-child: 0.71)
- Counters:
 - PeakMemoryUsage: 12.00 KB
 - RowsReturned: 0
 - RowsReturnedRate: 0
```

```
└─┘
 |
```

```
[8: AGGREGATION_NODE]
(Active: 5.355ms, non-child: 10.68)
- Counters:
 - BuildTime: 3.701us
 - GetResultsTime: 0ns
 - HTRresize: 0
 - HTRresizeTime: 1.211us
```





上图展示了 Fragment 1 中，Instance c257c52f93e149ee-ace8ac14e8c9ff03 的各个算子的具体 Profile。

通过以上 3 个步骤，我们可以逐步排查一个 SQL 的性能瓶颈。

# 导入分析


Doris 提供了一个图形化的命令以帮助用户更方便的分析一个具体的导入。本文介绍如何使用该功能。

该功能目前仅针对 **Broker Load** 的分析。

## 导入计划树

如果你对 Doris 的查询计划树还不太了解，请先阅读之前的文章 [Doris 查询分析](#)。

一个 [Broker Load](#) 请求的执行过程，也是基于 Doris 的查询框架的。一个 Broker Load 作业会根据导入请求中 DATA INFILE 子句的个数将作业拆分成多个子任务。每个子任务可以视为是一个独立的导入执行计划。一个导入计划的组成只会有一个 Fragment，其组成如下：



BrokerScanNode 主要负责去读源数据并发送给 OlapTableSink，而 OlapTableSink 负责将数据按照分区分桶规则发送到对应的节点，由对应的节点负责实际的数据写入。

而这个导入执行计划的 Fragment 会根据导入源文件的数量、BE 节点的数量等参数，划分成一个或多个 Instance。每个 Instance 负责一部分数据导入。

多个子任务的执行计划是并发执行的，而一个执行计划的多个 Instance 也是并行执行。

## 查看导入 Profile

用户可以通过以下命令打开会话变量 is\_report\_success：

```
SET is_report_success=true;
```

然后提交一个 Broker Load 导入请求，并等到导入执行完成。Doris 会产生该导入的一个 Profile。Profile 包含了一个导入各个子任务、Instance 的执行详情，有助于我们分析导入瓶颈。

目前不支持查看未执行成功的导入作业的 Profile。

我们可以通过如下命令先获取 Profile 列表：

```
mysql> show load profile "/"\G
***** 1. row *****
 JobId: 20010
 QueryId: 980014623046410a-af5d36f23381017f
 User: root
 DefaultDb: default_cluster:test
 SQL: LOAD LABEL xxx
 QueryType: Load
 StartTime: 2023-03-07 19:48:24
 EndTime: 2023-03-07 19:50:45
 TotalTime: 2m21s
 QueryState: N/A
 TraceId:
 AnalysisTime: NULL
 PlanTime: NULL
 ScheduleTime: NULL
 FetchResultTime: NULL
 WriteResultTime: NULL
 WaitAndFetchResultTime: NULL
***** 2. row *****
 JobId: N/A
 QueryId: 7cc2d0282a7a4391-8dd75030185134d8
 User: root
 DefaultDb: default_cluster:test
 SQL: insert into xxx
 QueryType: Load
 StartTime: 2023-03-07 19:49:15
 EndTime: 2023-03-07 19:49:15
 TotalTime: 102ms
 QueryState: OK
 TraceId:
 AnalysisTime: 825.277us
 PlanTime: 4.126ms
 ScheduleTime: N/A
 FetchResultTime: 0ns
 WriteResultTime: 0ns
 WaitAndFetchResultTime: N/A
```

这个命令会列出当前保存的所有导入 Profile。每行对应一个导入。其中 QueryId 列为导入作业的 ID。这个 ID 也可以通过 SHOW LOAD 语句查看拿到。我们可以选择我们想看的 Profile 对应的 QueryId，查看具体情况。

**查看一个 Profile 分为 3 个步骤：**

## 1. 查看子任务总览

通过以下命令查看有导入作业的子任务概况：

```
mysql> show load profile "/980014623046410a-af5d36f23381017f";
+-----+-----+
| TaskId | ActiveTime |
+-----+-----+
| 980014623046410a-af5d36f23381017f | 3m14s |
+-----+-----+
```

如上图，表示 980014623046410a-af5d36f23381017f 这个导入作业总共有一个子任务，其中 ActiveTime 表示这个子任务中耗时最长的 Instance 的执行时间。

## 2. 查看指定子任务的 Instance 概况

当我们发现一个子任务耗时较长时，可以进一步查看该子任务的各个 Instance 的执行耗时：

```
mysql> show load profile "/980014623046410a-af5d36f23381017f/980014623046410a-af5d36f23381017f";
```

Instances	Host	ActiveTime
980014623046410a-88e260f0c43031f2	10.81.85.89:9067	3m7s
980014623046410a-88e260f0c43031f3	10.81.85.89:9067	3m6s
980014623046410a-88e260f0c43031f4	10.81.85.89:9067	3m10s
980014623046410a-88e260f0c43031f5	10.81.85.89:9067	3m14s

这里展示了 980014623046410a-af5d36f23381017f 这个子任务的四个 Instance 耗时，并且还展示了 Instance 所在的执行节点。

### 3. 查看具体 Instance

我们可以继续查看某一个具体的 Instance 上各个算子的详细 Profile：

```
mysql> show load profile "/980014623046410a-af5d36f23381017f/980014623046410a-af5d36f23381017f/980014623046410a-88e260f0c43031f5"\G
```

```
***** 1. row *****
Instance:
```

```
[{-1: OlapTableSink]
(Active: 2m17s, non-child: 70.91)
- Counters:
 - CloseWaitTime: 1m53s
 - ConvertBatchTime: 0ns
 - MaxAddBatchExecTime: 1m46s
 - NonBlockingSendTime: 3m11s
 - NumberBatchAdded: 782
 - NumberNodeChannels: 1
 - OpenTime: 743.822us
 - RowsFiltered: 0
 - RowsRead: 1.599729M (1599729)
 - RowsReturned: 1.599729M (1599729)
 - SendDataTime: 11s761ms
 - TotalAddBatchExecTime: 1m46s
 - ValidateDataTime: 9s802ms
```

```
[{0: BROKER_SCAN_NODE]
(Active: 56s537ms, non-child: 29.06)
- Counters:
 - BytesDecompressed: 0.00
 - BytesRead: 5.77 GB
 - DecompressTime: 0ns
 - FileReadTime: 34s263ms
 - MaterializeTupleTime(*): 45s54ms
 - NumDiskAccess: 0
 - PeakMemoryUsage: 33.03 MB
 - RowsRead: 1.599729M (1599729)
 - RowsReturned: 1.599729M (1599729)
 - RowsReturnedRate: 28.295K /sec
 - TotalRawReadTime(*): 1m20s
 - TotalReadThroughput: 30.39858627319336 MB/sec
 - WaitScannerTime: 56s528ms
```

上图展示了子任务 980014623046410a-af5d36f23381017f 中，Instance 980014623046410a-88e260f0c43031f5 的各个算子的具体 Profile。

通过以上 3 个步骤，我们可以逐步排查一个导入任务的执行瓶颈。

# Java UDF

Java UDF 功能自 Doris 1.2 版本开始支持

## Java UDF 介绍

Java UDF 为用户提供 UDF 编写的 Java 接口，以方便用户使用 Java 语言进行自定义函数的执行。

Doris 支持使用 JAVA 编写 UDF、UDAF 和 UDTF。下文如无特殊说明，使用 UDF 统称所有用户自定义函数。

## 创建 UDF

实现的 jar 包可以放在本地也可以存放在远程服务端通过 HTTP 下载，但必须让每个 FE 和 BE 节点都能获取到 jar 包。

否则将会返回错误状态信息 `Couldn't open file .....`。

更多语法帮助可参阅 [CREATE FUNCTION](#)。

## UDF

```
CREATE FUNCTION java_udf_add_one(int) RETURNS int PROPERTIES (
 "file"="file:///path/to/java-udf-demo-jar-with-dependencies.jar",
 "symbol"="org.apache.doris.udf.AddOne",
 "always_nullable"="true",
 "type"="JAVA_UDF"
);
```

## UDAF

```
CREATE AGGREGATE FUNCTION middle_quantiles(DOUBLE,INT) RETURNS DOUBLE PROPERTIES (
 "file"="file:///pathTo/java-udaf.jar",
 "symbol"="org.apache.doris.udf.demo.MiddleNumberUDAF",
 "always_nullable"="true",
 "type"="JAVA_UDF"
);
```

## UDTF

UDTF 自 Doris 3.0 版本开始支持

# 使用 UDF

用户使用 UDF 必须拥有对应数据库的 SELECT 权限。

UDF 的使用与普通的函数方式一致，唯一的区别在于，内置函数的作用域是全局的，而 UDF 的作用域是 DB 内部。

当链接 session 位于数据内部时，直接使用 UDF 名字会在当前 DB 内部查找对应的 UDF。否则用户需要显示的指定 UDF 的数据库名字，例如 dbName.funcName。

# 删除 UDF

当你不再需要 UDF 函数时，你可以通过下述命令来删除一个 UDF 函数，可以参考 [DROP FUNCTION](#)

# 类型对应关系

Type	UDF Argument Type
Bool	Boolean
TinyInt	Byte
SmallInt	Short
Int	Integer
BigInt	Long
LargeInt	BigInteger
Float	Float
Double	Double
Date	LocalDate
Datetime	LocalDateTime
String	String
Decimal	BigDecimal
array<Type>	ArrayList<Type> 支持嵌套
map<Type1,Type2>	HashMap<Type1,Type2> 支持嵌套
struct<Type...>	ArrayList<Object> 3.0.0 版本开始支持

array/map/struct 类型可以嵌套其它类型，例如 Doris: array<array<int>>对应 JAVA UDF Argument Type: ArrayList<ArrayList<Integer>>, 其他依此类推

## Warning

在创建函数的时候，不要使用 varchar 代替 string，否则函数可能执行失败。

## UDF 的编写

本小节主要介绍如何开发一个 Java UDF。在 `samples/doris-demo/java-udf-demo/` 下提供了示例，可供参考，查看[点击这里](#)

使用 Java 代码编写 UDF，UDF 的主入口必须为 `evaluate` 函数。这一点与 Hive 等其他引擎保持一致。在本示例中，我们编写了 `AddOne` UDF 来完成对整型输入进行加一的操作。

值得一提的是，本例不只是 Doris 支持的 Java UDF，同时还是 Hive 支持的 UDF，也就是说，对于用户来讲，Hive UDF 是可以直接迁移至 Doris 的。

另外，如果定义的 UDF 中需要加载很大的资源文件，或者希望可以定义全局的 `static` 变量，可以参照文档下方的 `static` 变量加载方式。

### UDF

```
public class AddOne extends UDF {
 public Integer evaluate(Integer value) {
 return value == null ? null : value + 1;
 }
}
```

### UDAF

在使用 Java 代码编写 UDAF 时，有一些必须实现的函数 (标记 `required`) 和一个内部类 `State`，下面将以一个具体的实例来说明。

#### 示例1

下面的 `SimpleDemo` 将实现一个类似的 `sum` 的简单函数，输入参数 `INT`，输出参数是 `INT`。

```
package org.apache.doris.udf.demo;

import java.io.DataInputStream;
import java.io.DataOutputStream;
import java.io.IOException;
import java.util.logging.Logger;

public class SimpleDemo {

 Logger log = Logger.getLogger("SimpleDemo");

 //Need an inner class to store data
 /*required*/
 public static class State {
 /*some variables if you need */
 public int sum = 0;
 }

 /*required*/
 public State create() {
 /* here could do some init work if needed */
 return new State();
 }
}
```



```

/*required*/
public void destroy(State state) {
 /* here could do some destroy work if needed */
}

/*Not Required*/
public void reset(State state) {
 /*if you want this udaf function can work with window function.*/
 /*Must impl this, it will be reset to init state after calculate every window frame*/
 state.sum = 0;
}

/*required*/
//first argument is State, then other types your input
public void add(State state, Integer val) throws Exception {
 /* here doing update work when input data*/
 if (val != null) {
 state.sum += val;
 }
}

/*required*/
public void serialize(State state, DataOutputStream out) {
 /* serialize some data into buffer */
 try {
 out.writeInt(state.sum);
 } catch (Exception e) {
 /* Do not throw exceptions */
 log.info(e.getMessage());
 }
}

/*required*/
public void deserialize(State state, DataInputStream in) {
 /* deserialize get data from buffer before you put */
 int val = 0;
 try {
 val = in.readInt();
 } catch (Exception e) {
 /* Do not throw exceptions */
 log.info(e.getMessage());
 }
 state.sum = val;
}

/*required*/
public void merge(State state, State rhs) throws Exception {
 /* merge data from state */
 state.sum += rhs.sum;
}

/*required*/
//return Type you defined
public Integer getValue(State state) throws Exception {
 /* return finally result */
 return state.sum;
}
}

```

## 示例2

```
package org.apache.doris.udf.demo;

import java.io.DataInputStream;
import java.io.DataOutputStream;
import java.math.BigDecimal;
import java.util.Arrays;
import java.util.logging.Logger;

/*UDAF 计算中位数*/
public class MedianUDAF {
 Logger log = Logger.getLogger("MedianUDAF");

 //状态存储
 public static class State {
 //返回结果的精度
 int scale = 0;
 //是否是某一个 tablet 下的某个聚合条件下的数据第一次执行 add 方法
 boolean isFirst = true;
 //数据存储
 public StringBuilder stringBuilder;
 }

 //状态初始化
 public State create() {
 State state = new State();
 //根据每个 tablet 下的聚合条件需要聚合的数据量大小, 预先初始化, 增加性能
 state.stringBuilder = new StringBuilder(1000);
 return state;
 }

 //处理执行单位处理各自 tablet 下的各自聚合条件下的每个数据
 public void add(State state, Double val, int scale) {
 try {
 if (val != null && state.isFirst) {
 state.stringBuilder.append(scale).append(",").append(val).append(",");
 state.isFirst = false;
 } else if (val != null) {
 state.stringBuilder.append(val).append(",");
 }
 } catch (Exception e) {
 //如果不能保证一定不会异常, 建议每个方法都最大化捕获异常, 因为目前不支持处理 java 抛出的异常
 log.info("获取数据异常: " + e.getMessage());
 }
 }

 //处理数据完需要输出等待聚合
 public void serialize(State state, DataOutputStream out) {
 try {
 //目前暂时只提供 DataOutputStream, 如果需要序列化对象可以考虑拼接字符串, 转换 json, 序列化成字节数组等方式
 //如果要序列化 State 对象, 可能需要自己将 State 内部类实现序列化接口
 //最终都是要通过 DataOutputStream 传输
 out.writeUTF(state.stringBuilder.toString());
 } catch (Exception e) {
 log.info("序列化异常: " + e.getMessage());
 }
 }

 //获取处理数据执行单位输出的数据
 public void deserialize(State state, DataInputStream in) {
```

```

 try {
 String string = in.readUTF();
 state.scale = Integer.parseInt(String.valueOf(string.charAt(0)));
 StringBuilder stringBuilder = new StringBuilder(string.substring(2));
 state.stringBuilder = stringBuilder;
 } catch (Exception e) {
 log.info("反序列化异常: " + e.getMessage());
 }
 }

 //聚合执行单位按照聚合条件合并某一个键下数据的处理结果 ,每个键第一次合并时, state1 参数是初始化的实例
 public void merge(State state1, State state2) {
 try {
 state1.scale = state2.scale;
 state1.stringBuilder.append(state2.stringBuilder.toString());
 } catch (Exception e) {
 log.info("合并结果异常: " + e.getMessage());
 }
 }

 //对每个键合并后的数据进行并输出最终结果
 public Double getValue(State state) {
 try {
 String[] strings = state.stringBuilder.toString().split(",");
 double[] doubles = new double[strings.length + 1];
 doubles = Arrays.stream(strings).mapToDouble(Double::parseDouble).toArray();

 Arrays.sort(doubles);
 double n = doubles.length - 1;
 double index = n * 0.5;

 int low = (int) Math.floor(index);
 int high = (int) Math.ceil(index);

 double value = low == high ? (doubles[low] + doubles[high]) * 0.5 : doubles[high];

 BigDecimal decimal = new BigDecimal(value);
 return decimal.setScale(state.scale, BigDecimal.ROUND_HALF_UP).doubleValue();
 } catch (Exception e) {
 log.info("计算异常: " + e.getMessage());
 }
 return 0.0;
 }

 //每个执行单位执行完都会执行
 public void destroy(State state) {
 }
}

```

## 最佳实践

### static 变量加载

当前在 Doris 中, 执行一个 UDF 函数, eg: select udf(col) from table, 每一个并发instance会加载一次 udf.jar包, 在该instance结束时卸载掉udf.jar包。所以当 udf.jar 文件中需要加载一个几百 MB的文件时, 会因为并发的原因, 使得占据的内存急剧增大, 容易OOM。

解决方法是可以将资源加载代码拆分开, 单独生成一个 jar 包文件, 其他包直接引用该资源jar包。

假设已经拆分为了 DictLibrary 和 FunctionUdf 两个文件。

1. 单独编译 DictLibrary 文件，使其生成一个独立的 jar 包,这样可以得到一个资源文件 DictLibrary.jar:

```
javac ./DictLibrary.java
jar -cf ./DictLibrary.jar ./DictLibrary.class
```

2. 然后编译 FunctionUdf 文件，可以直接引用上一步的到的资源包, 这样可以得到 udf 的 FunctionUdf.jar 包。

```
javac -cp ./DictLibrary.jar ./FunctionUdf.java
jar -cvf ./FunctionUdf.jar ./FunctionUdf.class
```

3. 经过上面两步之后，会得到两个 jar 包，由于想让资源 jar 包被所有的并发引用，所以需要将它放到 BE 的部署路径 be/lib/java\_extensions/java-udf下面，BE重启之后就可以随着 JVM 的启动加载进来。
4. 最后利用 create function 语句创建一个 UDF 函数，其中 file 的路径指向 FunctionUdf.jar 包, 这样资源包会随着 BE 启动而加载，停止而释放。FunctionUdf.jar 的加载与释放则是跟随 SQL 的执行周期。

```
public class DictLibrary {
 private static HashMap<String, String> res = new HashMap<>();

 static {
 // suppose we built this dictionary from a certain local file.
 res.put("key1", "value1");
 res.put("key2", "value2");
 res.put("key3", "value3");
 res.put("0", "value4");
 res.put("1", "value5");
 res.put("2", "value6");
 }

 public static String evaluate(String key) {
 if (key == null) {
 return null;
 }
 return res.get(key);
 }
}
```

```
public class FunctionUdf {
 public String evaluate(String key) {
 String value = DictLibrary.evaluate(key);
 return value;
 }
}
```

## 使用须知

1. 不支持复杂数据类型（HLL，Bitmap）。
2. 当前允许用户自己指定JVM最大堆大小，配置项是 be.conf 中的 JAVA\_OPTS 的 -Xmx 部分。默认 1024m，如果需要聚合数据，建议调大一些，增加性能，减少内存溢出风险。
3. Char 类型的 UDF 在 create function 时需要使用 String 类型。

4. 由于 jvm 加载同名类的问题，不要同时使用多个同名类作为 udf 实现，如果想更新某个同名类的 udf，需要重启 be 重新加载 classpath。

# Remote UDF

---

## Remote UDF

Remote UDF Service 支持通过 RPC 的方式访问用户提供的 UDF Service，以实现用户自定义函数的执行。相比于 Native 的 UDF 实现，Remote UDF Service 有如下优势和限制：

### 1. 优势

- 跨语言：可以用 Protobuf 支持的各类语言编写 UDF Service。
- 安全：UDF 执行失败或崩溃，仅会影响 UDF Service 自身，而不会导致 Doris 进程崩溃。
- 灵活：UDF Service 中可以调用任意其他服务或程序库类，以满足更多样的业务需求。

### 2. 使用限制

- 性能：相比于 Native UDF，UDF Service 会带来额外的网络开销，因此性能会远低于 Native UDF。同时，UDF Service 自身的实现也会影响函数的执行效率，用户需要自行处理高并发、线程安全等问题。
- 单行模式和批处理模式：Doris 原先的基于行存的查询执行框架会对每一行数据执行一次 UDF RPC 调用，因此执行效率非常差，而在新的向量化执行框架下，会对每一批数据（默认 2048 行）执行一次 UDF RPC 调用，因此性能有明显提升。实际测试中，基于向量化和批处理方式的 Remote UDF 性能和基于行存的 Native UDF 性能相当，可供参考。

## 编写 UDF 函数

本小节主要介绍如何开发一个 Remote RPC service。在 `samples/doris-demo/udf-demo/` 下提供了 Java 版本的示例，可供参考。

### 拷贝 proto 文件

拷贝 `gensrc/proto/function_service.proto` 和 `gensrc/proto/types.proto` 到 Rpc 服务中

#### `function_service.proto`

- `PFunctionCallRequest`
  - `function_name`：函数名称，对应创建函数时指定的 symbol
  - `args`：方法传递的参数
  - `context`：查询上下文信息
- `PFunctionCallResponse`
  - `result`：结果
  - `status`：状态，0 代表正常

- PCheckFunctionRequest
  - function: 函数相关信息
  - match\_type: 匹配类型
- PCheckFunctionResponse
  - status: 状态, 0 代表正常

## 生成接口

通过 protoc 生成代码, 具体参数通过 `protoc -h` 查看

## 实现接口

共需要实现以下三个方法

- fnCall: 用于编写计算逻辑
- checkFn: 用于创建 UDF 时校验, 校验函数名/参数/返回值等是否合法
- handShake: 用于接口探活

## 创建 UDF

目前暂不支持 UDTF

```
CREATE FUNCTION
name ([,...])
[RETURNS] rettype
PROPERTIES (["key"="value"][,...])
```

说明:

1. PROPERTIES 中symbol表示的是 rpc 调用传递的方法名, 这个参数是必须设定的。
2. PROPERTIES 中object\_file表示的 rpc 服务地址, 目前支持单个地址和 brpc 兼容格式的集群地址, 集群连接方式 参考 [格式说明](#)。
3. PROPERTIES 中type表示的 UDF 调用类型, 默认为 Native, 使用 Rpc UDF 时传 RPC。
4. name: 一个 function 是要归属于某个 DB 的, name 的形式为dbName.funcName。当dbName没有明确指定的时候, 就是使用当前 session 所在的 db 作为dbName。

示例:

```
CREATE FUNCTION rpc_add_two(INT,INT) RETURNS INT PROPERTIES (
 "SYMBOL"="add_int_two",
 "OBJECT_FILE"="127.0.0.1:9114",
 "TYPE"="RPC"
);
CREATE FUNCTION rpc_add_one(INT) RETURNS INT PROPERTIES (
 "SYMBOL"="add_int_one",
```

```

"OBJECT_FILE"="127.0.0.1:9114",
"TYPE"="RPC"
);
CREATE FUNCTION rpc_add_string(varchar(30)) RETURNS varchar(30) PROPERTIES (
 "SYMBOL"="add_string",
 "OBJECT_FILE"="127.0.0.1:9114",
 "TYPE"="RPC"
);

```

## 使用 UDF

用户使用 UDF 必须拥有对应数据库的 SELECT 权限。

UDF 的使用与普通的函数方式一致，唯一的区别在于，内置函数的作用域是全局的，而 UDF 的作用域是 DB 内部。当链接 session 位于数据内部时，直接使用 UDF 名字会在当前 DB 内部查找对应的 UDF。否则用户需要显示的指定 UDF 的数据库名字，例如 dbName.funcName。

## 删除 UDF

当你不再需要 UDF 函数时，你可以通过下述命令来删除一个 UDF 函数，可以参考 DROP FUNCTION。

## 示例

在 samples/doris-demo/ 目录中提供和 cpp/java/python 语言的 rpc server 实现示例。具体使用方法见每个目录下的 README.md 例如 rpc\_add\_string

```

mysql >select rpc_add_string('doris');
+-----+
| rpc_add_string('doris') |
+-----+
| doris_rpc_test |
+-----+

```

日志会显示

```

INFO: fnCall request=function_name: "add_string"
args {
 type {
 id: STRING
 }
 has_null: false
 string_value: "doris"
}
INFO: fnCall res=result {
 type {
 id: STRING
 }
 has_null: false
 string_value: "doris_rpc_test"
}
status {
 status_code: 0
}

```



# 湖仓一体概述

---

湖仓一体之前，数据分析经历了数据库、数据仓库和数据湖分析三个时代。

- 首先是数据库，它是一个最基础的概念，主要负责联机事务处理，也提供基本的数据分析能力。
- 随着数据量的增长，出现了数据仓库，它存储的是经过清洗、加工以及建模后的高价值的数据，供业务人员进行数据分析。
- 数据湖的出现，主要是为了满足企业对原始数据的存储、管理和再加工的需求。这里的需求主要包括两部分，首先要有一个低成本的存储，用于存储结构化、半结构化，甚至非结构化的数据；另外，就是希望有一套包括数据处理、数据管理以及数据治理在内的一体化解决方案。

数据仓库解决了数据快速分析的需求，数据湖解决了数据的存储和管理的需求，而湖仓一体要解决的就是如何让数据能够在数据湖和数据仓库之间进行无缝的集成和自由的流转，从而帮助用户直接利用数据仓库的能力来解决数据湖中的数据分析问题，同时又能充分利用数据湖的数据管理能力来提升数据的价值。


## 适用场景

Doris 在设计湖仓一体时，主要考虑如下四个应用场景：

- 湖仓查询加速：Doris 作为一个非常高效的 OLAP 查询引擎，有着非常好的 MPP 向量化的分布式的查询层，可以直接利用 Doris 非常高效的查询引擎，对湖上数据进行加速分析。
- 统一数据分析网关：提供各类异构数据源的查询和写入能力，支持用户将这些外部数据源统一到 Doris 的元数据映射结构上，当用户通过 Doris 查询这些外部数据源时，能够提供一致的查询体验。
- 统一数据集成：首先通过数据湖的数据源连接能力，能够让多数据源的数据以增量或全量的方式同步到 Doris，并且利用 Doris 的数据处理能力对这些数据进行加工。加工完的数据一方面可以直接通过 Doris 对外提供查询，另一方面也可以通过 Doris 的数据导出能力，继续为下游提供全量或增量数据服务。通过 Doris 可以减少对外部工具的依赖，可以直接将上下游数据，以及包括同步、加工、处理在内的整条链路打通。
- 更加开放的数据平台：众多数据仓库有着各自的存储格式，用户如果想要使用一个数据仓库，第一步就需要把外部数据通过某种方式导入到数据仓库中才能进行查询。这样就是一个比较封闭的生态，数据仓库中数据除了数仓自己本身可以查询以外，其它外部工具是无法进行直接访问的。一些企业在使用包括 Doris 在内的一些数仓产品的时候就会有一些顾虑，比如数据是否会被锁定到某一个数据仓库里，是否还有便捷的方式进行导出。通过湖仓一体生态的接入，可以用更加开放的数据格式来管理数据，比如可以用 Parquet/ORC 格式来去存储数据，这样开放开源的数据格式可以被很多外部系统去访问。另外，Iceberg, Hudi 等都提供了开放式的元数据管理能力，不管元数据是存储在 Doris 本身，还是存储在 Hive Meta store，或者存储在其它统一元数据中心，都可以通过一些对外公开的 API 对这些数据进行管理。通过更加开放的数据生态，可以帮助企业更快地接入一个新的数据管理系统，降低企业数据迁移的成本和风险。

## 基于 Doris 的湖仓一体架构

Doris 通过多源数据目录（Multi-Catalog）功能，支持了包括 Apache Hive、Apache Iceberg、Apache Hudi、Apache Paimon(Incubating)、Elasticsearch、MySQL、Oracle、SQL Server 等主流数据湖、数据库的连接访问。以及可以通过 Apache Ranger 等进行统一的权限管理，具体架构如下：



基于 Doris 的湖仓一体架构

其数据湖的主要对接流程为：

1. 创建元数据映射：Doris 通过 Catalog 获取数据湖元数据并缓存在 Doris 中，用于数据湖元数据的管理。在元数据映射过程中 Doris 除了支持传统 JDBC 的用户名密码认证外，还支持基于 Kerberos 和 Ranger 的权限认证，基于 KMS 的数据加密。
2. 发起查询操作：当用户从 FE 发起数据湖查询时，Doris 使用自身存储的数据湖元数生成造查询计划，利用 Native 的 Reader 组件从外部存储（HDFS、S3）上获取数据进行数据计算和分析。在数据查询过程中 Doris 会将数据湖热点数据缓存在本地，当下次相同查询到来时数据缓存能很好起到查询加速的效果。
3. 结果返回：当查询完成后将查询结果通过 FE 返回给用户。
4. 计算结果入湖：当用户并不想将计算结果返回，而是需要将计算结果进一步写入数据湖时可以通过 export 的方式以标准数据格式（CSV、Parquet、ORC）将数据写回数据湖。


## 核心技术

在多源数据连接上 Doris 通过可扩展连接器读取外部数据。同时通过元数据缓存、数据缓存、Native Reader、IO 优化、统计信息优化等一些措施，极大加速了数据湖分析能力。

### 可扩展的连接框架

在数据的对接中包括元数据的对接和数据的读取。

- 元数据对接：元数据对接在 FE 完成，通过 FE 的 MetaData 管理器来实现基于 HiveMetastore、JDBC 和文件的元数据对接和管理工作。
- 数据读取：通过 NativeReader 可以高效的读取存放在 HDFS、对象存储上的 Parquet、ORC、Text 格式数据。也可以通过 JniConnector 对接 Java 大数据生态。




可扩展的连接框架

## 高效缓存策略

Doris 通过元数据缓存、数据缓存和查询结果缓存来提升查询性能。

### 元数据缓存


Doris 提供了手动同步元数据、定期自动同步元数据、元数据订阅（只支持 HiveMetastore）三种方式来同步数据湖的元数据信息到 Doris，并将元数据存储在 Doris 的 FE 的内存中。当用户发起查询后 Doris 直接从内存中获取元数据并快速生成查询规划。保障了元数据的实时和高效。在元数据同步上 Doris 通过并发的元数据事件合并实现高效的元数据同步，其每秒可以处理 100 个以上的元数据事件。



## 元数据缓存

### 高效的数据缓存


- 文件缓存：Doris 通过将数据湖中的热点数据存储在本机磁盘上，减少数据扫描过程中网络数据的传输，提高数据访问的性能。
- 缓存分布策略：在数据缓存中 Doris 通过一致性哈希将数据分布在各个 BE 节点上，尽量避免节点扩缩容带来的缓存失效问题。
- 缓存淘汰（更新）策略：同时当 Doris 发现数据文件对应的元数据更新后，会及时淘汰缓存以保障数据的一致性。



## 元数据缓存

### 查询结果缓存和分区缓存


- 查询结果缓存：Doris 根据 SQL 语句将之前查询的结果缓存起来，当下次相同的查询再次发起时可以直接从缓存中获取数据返回到客户端，极大的提高了查询的效率和并发。
- 分区缓存：Doris 还支持将部分分区数据缓存在 BE 端提升查询效率。比如查询最近 7 天的数据，可以将前 6 天的计算后的缓存结果，和当天的事实计算结果进行合并，得到最终查询结果，最大限度减少实时计算的数据量，提升查询效率。



查询结果缓存和分区缓存


## 高效的 Native Reader

- 自研 Native Reader 避免数据转换：Doris 在数据分析时有其自身的列存方式，同时 Parquet、ORC 也有自身的列存格式。如果直接使用开源的 Parquet 或者 ORC Reader 的话就会存在一个 Doris 列存和 Parquet/ORC 列存的转换过程。这样的话就会多一次格式转换的开销，为了解决这个问题 我们自研了一套 Parquet/ORC NativeReader，直接读取 Parquet、ORC 文件来提高查询效率。
- 延迟物化：同时我们实现的 Native Reader 还能很好的利用智能索引和过滤器提高数据读取效率。比如说在某些场景下我可能只针对 ID 列去做一个过滤。我们的优化做法是首先第一步我会把 ID 列单独读出来。然后在这一列上做完过滤以后，我会把这个过滤后的剩余下来的这个行号记录下来。拿这个行号再去读剩下两列，这样来进一步的减少数据扫描，加速文件的分析性能。



## 高效的 Native Reader

- 向量化读取数据：同时在文件数据的读取过程中我们引入向量化的方式读取数据，极大加速了数据读取效率。



向量化读取数据

## Merge IO


在网络中难免会出现大量小文件的网络 IO 请求影响 IO 性能，在这种情况下我们采用 IO 合并去优化这种情况。

比如我们设置一个策略将小于 3MB 的 IO 请求合并（Merge IO）在一次请求中处理。那么之前可能是有 8 次的小的 IO 请求，我们可以把 8 次合并成 5 次 IO 请求去读取数据。这样减少了网络 IO 请求的速度，提高了网络访问数据的效率。


Merge IO 的确定是它可能会读取一些不必要的数据，因为它把中间可能不必要读取的数据合并起来一块读过来了。但是从整体的吞吐上来讲其性能有很大的提高，在碎文件（比如：1KB - 1MB）较多的场景优化效果很明显。同时我们通过控制 Merge IO 的大小来达到整体的平衡。




#### Before Merging: 8 IO Operations



#### After Merging: 5 IO Operations



#### Small File Merging: 4→1 IO Operation



## Merge IO


### 统计信息提高查询规划效果

Doris 通过收集统计信息有助于优化器了解数据分布特性，在进行 CBO（基于成本优化）时优化器会利用这些统计信息来计算谓词的选择性，并估算每个执行计划的成本。从而选择更优的计划以大幅提升查询效率。在数据湖场景我们可以通过收集外表的统计信息来提升查询规划器的效果。

统计信息的收集方式包括手动收集和自动收集。

同时为了保证收集统计信息不会对 BE 产生压力，我们支持了采样收集统计信息。

在一些场景下用户历史数据可能很少查找，但是热数据会被经常访问，因此我们也提供了基于分区的统计信息收集在保障热数据高效的查询效率和统计信息收集对 BE 产生负载的中间取得平衡。



统计信息提高查询规划效果

## 多源数据目录

多源数据目录（Multi-Catalog）功能，旨在能够更方便对接外部数据目录，以增强 Doris 的数据湖分析和联邦数据查询能力。

在之前的 Doris 版本中，用户数据只有两个层级：Database 和 Table。当我们需要连接一个外部数据目录时，我们只能在 Database 或 Table 层级进行对接。比如通过 `create external table` 的方式创建一个外部数据目录中的表的映射，或通过 `create external database` 的方式映射一个外部数据目录中的 Database。如果外部数据目录中的 Database 或 Table 非常多，则需要用户手动进行一一映射，使用体验不佳。

而新的 Multi-Catalog 功能在原有的元数据层级上，新增一层 Catalog，构成 Catalog -> Database -> Table 的三层元数据层级。

该功能将作为之前外表连接方式（External Table）的补充和增强，帮助用户进行快速的多数据目录联邦查询。

### 基础概念

- Internal Catalog

Doris 原有的 Database 和 Table 都将归属于 Internal Catalog。Internal Catalog 是内置的默认 Catalog，用户不可修改或删除。

- External Catalog

可以通过 [CREATE CATALOG](#) 命令创建一个 External Catalog。创建后，可以通过 [SHOW CATALOGS](#) 命令查看已创建的 Catalog。

- 切换 Catalog

用户登录 Doris 后，默认进入 Internal Catalog，因此默认的使用和之前版本并无差别，可以直接使用 SHOW DATABASES, USE DB 等命令查看和切换数据库。

用户可以通过 [SWITCH](#) 命令切换 Catalog。如：

```
SWITCH internal;
SWITCH hive_catalog;
```

切换后，可以直接通过 SHOW DATABASES, USE DB 等命令查看和切换对应 Catalog 中的 Database。Doris 会自动通过 Catalog 中的 Database 和 Table。用户可以像使用 Internal Catalog 一样，对 External Catalog 中的数据进行查看和访问。

- 删除 Catalog

可以通过 [DROP CATALOG](#) 命令删除一个 External Catalog，Internal Catalog 无法删除。该操作仅会删除 Doris 中该 Catalog 的映射信息，并不会修改或变更任何外部数据目录的内容。

## 连接示例

### 连接 Hive

这里我们通过连接一个 Hive 集群说明如何使用 Catalog 功能。

更多关于 Hive 的说明，请参阅：[Hive Catalog](#)

#### 1. 创建 Catalog

```
CREATE CATALOG hive PROPERTIES (
 'type'='hms',
 'hive.metastore.uris' = 'thrift://172.21.0.1:7004'
);
```

更多查看：[CREATE CATALOG 语法帮助](#)

#### 2. 查看 Catalog

#### 3. 创建后，可以通过 SHOW CATALOGS 命令查看 catalog：

```
mysql> SHOW CATALOGS;
+-----+-----+-----+-----+-----+-----+-----+
| CatalogId | CatalogName | Type | IsCurrent | CreateTime | LastUpdateTime | Comment |
+-----+-----+-----+-----+-----+-----+-----+
| 10024 | hive | hms | yes | 2023-12-25 16:11:41.687 | 2023-12-25 20:43:18 | NULL |
| 0 | internal | internal | | UNRECORDED | NULL | Doris |
internal catalog |
```

- [SHOW CATALOGS 语法帮助](#)
- 可以通过 [SHOW CREATE CATALOG](#) 查看创建 Catalog 的语句。
- 可以通过 [ALTER CATALOG](#) 修改 Catalog 的属性。

#### 4. 切换 Catalog

通过 SWITCH 命令切换到 hive catalog，并查看其中的数据库：

```
mysql> SWITCH hive;
Query OK, 0 rows affected (0.00 sec)

mysql> SHOW DATABASES;
+-----+
| Database |
+-----+
| default |
| random |
| ssb100 |
| tpch1 |
| tpch100 |
| tpch1_orc|
+-----+
```

查看更多：[SWITCH 语法帮助](#)

#### 5. 使用 Catalog

切换到 Catalog 后，则可以正常使用内部数据源的功能。

如切换到 tpch100 数据库，并查看其中的表：

```
mysql> USE tpch100;
Database changed

mysql> SHOW TABLES;
+-----+
| Tables_in_tpch100 |
+-----+
| customer |
| lineitem |
| nation |
| orders |
| part |
| partsupp |
| region |
| supplier |
+-----+
```

查看 lineitem 表的 schema：

```
mysql> DESC lineitem;
+-----+
| Field | Type | Null | Key | Default | Extra |
+-----+
| Part | int(11) | YES | | | |
| Supp | int(11) | YES | | | |
| Partsupp | int(11) | YES | | | |
| Region | int(11) | YES | | | |
| Nation | int(11) | YES | | | |
| Orders | int(11) | YES | | | |
| Part | int(11) | YES | | | |
| Partsupp | int(11) | YES | | | |
| Lineitem | int(11) | YES | | | |
| Customer | int(11) | YES | | | |
| Supplier | int(11) | YES | | | |
| Partsupp | int(11) | YES | | | |
| Region | int(11) | YES | | | |
| Nation | int(11) | YES | | | |
| Orders | int(11) | YES | | | |
| Part | int(11) | YES | | | |
| Partsupp | int(11) | YES | | | |
| Lineitem | int(11) | YES | | | |
| Customer | int(11) | YES | | | |
| Supplier | int(11) | YES | | | |
+-----+
```

l_shipdate	DATE	Yes	true	NULL		
l_orderkey	BIGINT	Yes	true	NULL		
l_linenum	INT	Yes	true	NULL		
l_partkey	INT	Yes	true	NULL		
l_suppkey	INT	Yes	true	NULL		
l_quantity	DECIMAL(15,2)	Yes	true	NULL		
l_extendedprice	DECIMAL(15,2)	Yes	true	NULL		
l_discount	DECIMAL(15,2)	Yes	true	NULL		
l_tax	DECIMAL(15,2)	Yes	true	NULL		
l_returnflag	TEXT	Yes	true	NULL		
l_linestatus	TEXT	Yes	true	NULL		
l_commitdate	DATE	Yes	true	NULL		
l_receiptdate	DATE	Yes	true	NULL		
l_shipinstruct	TEXT	Yes	true	NULL		
l_shipmode	TEXT	Yes	true	NULL		
l_comment	TEXT	Yes	true	NULL		

查询示例：

```
mysql> SELECT l_shipdate, l_orderkey, l_partkey FROM lineitem limit 10;
```

l_shipdate	l_orderkey	l_partkey	
1998-01-21	66374304	270146	
1997-11-17	66374304	340557	
1997-06-17	66374400	6839498	
1997-08-21	66374400	11436870	
1997-08-07	66374400	19473325	
1997-06-16	66374400	8157699	
1998-09-21	66374496	19892278	
1998-08-07	66374496	9509408	
1998-10-27	66374496	4608731	
1998-07-14	66374592	13555929	

也可以和其他数据目录中的表进行关联查询：

```
mysql> SELECT l.l_shipdate FROM hive.tpch100.lineitem l WHERE l.l_partkey IN (SELECT p_partkey FROM internal.db1.part) LIMIT 10;
```

l_shipdate	
1993-02-16	
1995-06-26	
1995-08-19	
1992-07-23	
1998-05-23	
1997-07-12	
1994-03-06	
1996-02-07	
1997-06-01	
1996-08-23	

- 这里我们通过 catalog.database.table 这种全限定的方式标识一张表，如：internal.db1.part。
- 其中 catalog 和 database 可以省略，缺省使用当前 SWITCH 和 USE 后切换的 Catalog 和 Database。

- 可以通过 INSERT INTO 命令，将 Hive Catalog 中的表数据，插入到 Internal Catalog 中的内部表，从而达到导入外部数据目录数据的效果：

```
mysql> SWITCH internal;
Query OK, 0 rows affected (0.00 sec)

mysql> USE db1;
Database changed

mysql> INSERT INTO part SELECT * FROM hive.tpch100.part limit 1000;
Query OK, 1000 rows affected (0.28 sec)
{'label':'insert_212f67420c6444d5_9bfc184bf2e7edb8', 'status':'VISIBLE', 'txnId':'4'}
```

## 列类型映射

用户创建 Catalog 后，Doris 会自动同步数据目录的数据库和表，针对不同的数据目录和数据表格式，Doris 会进行以下列映射关系。

对于当前无法映射到 Doris 列类型的外表类型，如 UNION, INTERVAL 等。Doris 会将列类型映射为 UNSUPPORTED 类型。对于 UNSUPPORTED 类型的查询，示例如下：

假设同步后的表 schema 为：

```
k1 INT,
k2 INT,
k3 UNSUPPORTED,
k4 INT
select * from table; // Error: Unsupported type 'UNSUPPORTED_TYPE' in 'k3
select * except(k3) from table; // Query OK.
select k1, k3 from table; // Error: Unsupported type 'UNSUPPORTED_TYPE' in 'k3
select k1, k4 from table; // Query OK.
```

不同的数据源的列映射规则，请参阅不同数据源的文档。

## 权限管理

使用 Doris 对 External Catalog 中库表进行访问时，默认情况下，依赖 Doris 自身的权限访问管理功能。

Doris 的权限管理功能提供了对 Catalog 层级的扩展，具体可参阅 [认证和鉴权](#) 文档。

用户也可以通过 access\_controller.class 属性指定自定义的鉴权类。如通过指定：

```
"access_controller.class" =
"org.apache.doris.catalog.authorizer.ranger.hive.RangerHiveAccessControllerFactory"
```

则可以使用 Apache Ranger 对 Hive Catalog 进行鉴权管理。详细信息请参阅：[Hive Catalog](#)

## 指定需要同步的数据库

通过在 Catalog 配置中设置 include\_database\_list 和 exclude\_database\_list 可以指定需要同步的数据库。

include\_database\_list: 支持只同步指定的多个 database，以 , 分隔。默认同步所有 database。db 名称是大小写敏感的。

exclude\_database\_list: 支持指定不需要同步的多个 database，以 , 分割。默认不做任何过滤，同步所有 database。db 名称是大小写敏感的。

- 当 include\_database\_list 和 exclude\_database\_list 有重合的 database 配置时，exclude\_database\_list 会优先生效。

- 连接 JDBC 时，上述 2 个配置需要和配置 only\_specified\_database 搭配使用，详见 [JDBC](#)

# Hive Catalog

通过连接 Hive Metastore，Doris 可以自动获取 Hive 的库表信息，进行数据查询、分析。除了 Hive 外，例如 Iceberg、Hudi 等其他系统也会使用 Hive Metastore 存储元数据。通过 Hive Catalog，能轻松集成 Hive 及使用 Hive Metastore 作为元数据存储的系统。

## 注意事项

- 支持 Hive1、Hive2、Hive3 版本。
- 支持 Managed Table 和 External Table，支持部分 Hive View。
- 支持识别 Hive Metastore 中存储的 Hive、Iceberg、Hudi 元数据。
- 将 core-site.xml，hdfs-site.xml 和 hive-site.xml 放到 FE 和 BE 的 conf 目录下。优先读取 conf 目录下的 Hadoop 配置文件，再读取环境变量 HADOOP\_CONF\_DIR 的相关配置文件。
- 如果 Hadoop 节点配置了 hostname，请确保添加对应的映射关系到 /etc/hosts 文件。

## 创建 Catalog

### Hive On HDFS

```
CREATE CATALOG hive PROPERTIES (
 'type'='hms',
 'hive.metastore.uris' = 'thrift://172.0.0.1:9083',
 'hadoop.username' = 'hive',
 'dfs.nameservices'='your-nameservice',
 'dfs.ha.namenodes.your-nameservice'='nn1,nn2',
 'dfs.namenode.rpc-address.your-nameservice.nn1'='172.21.0.2:8088',
 'dfs.namenode.rpc-address.your-nameservice.nn2'='172.21.0.3:8088',
 'dfs.client.failover.proxy.provider.your-
nameservice'='org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider'
);
```

除了 type 和 hive.metastore.uris 两个必须参数外，还可以通过更多参数来传递连接所需要的信息。

如提供 HDFS HA 信息，示例如下：

```
CREATE CATALOG hive PROPERTIES (
 'type'='hms',
 'hive.metastore.uris' = 'thrift://172.0.0.1:9083',
 'hadoop.username' = 'hive',
 'dfs.nameservices'='your-nameservice',
 'dfs.ha.namenodes.your-nameservice'='nn1,nn2',
 'dfs.namenode.rpc-address.your-nameservice.nn1'='172.21.0.2:8088',
 'dfs.namenode.rpc-address.your-nameservice.nn2'='172.21.0.3:8088',
 'dfs.client.failover.proxy.provider.your-
nameservice'='org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider'
);
```



## Hive On VIEWFS

```
CREATE CATALOG hive PROPERTIES (
 'type'='hms',
 'hive.metastore.uris' = 'thrift://172.0.0.1:9083',
 'hadoop.username' = 'hive',
 'dfs.nameservices'='your-nameservice',
 'dfs.ha.namenodes.your-nameservice'='nn1,nn2',
 'dfs.namenode.rpc-address.your-nameservice.nn1'='172.21.0.2:8088',
 'dfs.namenode.rpc-address.your-nameservice.nn2'='172.21.0.3:8088',
 'dfs.client.failover.proxy.provider.your-
nameservice'='org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider',
 'fs.defaultFS' = 'viewfs://your-cluster',
 'fs.viewfs.mounttable.your-cluster.link./ns1' = 'hdfs://your-nameservice/',
 'fs.viewfs.mounttable.your-cluster.homedir' = '/ns1'
);
```

VIEWFS 相关参数可以如上面一样添加到 Catalog 配置中，也可以添加到 conf/core-site.xml 中。

VIEWFS 工作原理和参数配置可以参考 Hadoop 相关文档，比如

<https://hadoop.apache.org/docs/stable/hadoop-project-dist/hadoop-hdfs/ViewFs.html>

## Hive On JuiceFS

数据存储 JuiceFS，示例如下：

(需要把 juicefs-hadoop-x.x.x.jar 放在 fe/lib/ 和 apache\_hdfs\_broker/lib/ 下)

```
CREATE CATALOG hive PROPERTIES (
 'type'='hms',
 'hive.metastore.uris' = 'thrift://172.0.0.1:9083',
 'hadoop.username' = 'root',
 'fs.jfs.impl' = 'io.juicefs.JuiceFileSystem',
 'fs.AbstractFileSystem.jfs.impl' = 'io.juicefs.JuiceFS',
 'juicefs.meta' = 'xxx'
);
```

## Doris 访问腾讯云 DLC

### Doris 2.0 版本自 2.0.13 后支持该功能

腾讯云 [DLC](#) 采用HMS管理元数据，因此可用 Hive catalog 进行联邦分析。DLC 可基于 LakeFS 或 COSN 进行数据存储。以下 catalog 创建方法对两种 FS 都适用。

```
CREATE CATALOG dlc PROPERTIES (
 'type' = 'hms',
 'hive.metastore.uris' = 'thrift://<dlc_metastore_ip>:<dlc_metastore_port>',
 's3.access_key' = 'xxxxx',
 's3.secret_key' = 'xxxxx',
 's3.region' = 'ap-xxx',
 's3.endpoint' = 'cos.ap-xxx.myqcloud.com',
 'fs.cosn.bucket.region' = 'ap-xxx',
 'fs ofs.user.appid' = '<your_tencent_cloud_appid>',
```

```
'fs.ofs.tmp.cache.dir' = '<tmp_cache_dir>'
);
```

创建完 catalog 后需要对 catalog 绑定的 appid 进行[授权](#)。

## Hive On S3

```
CREATE CATALOG hive PROPERTIES (
 "type"="hms",
 "hive.metastore.uris" = "thrift://172.0.0.1:9083",
 "s3.endpoint" = "s3.us-east-1.amazonaws.com",
 "s3.region" = "us-east-1",
 "s3.access_key" = "ak",
 "s3.secret_key" = "sk",
 "use_path_style" = "true"
);
```

可选属性：

- s3.connection.maximum: s3 最大连接数，默认 50
- s3.connection.request.timeout: s3 请求超时时间，默认 3000ms
- s3.connection.timeout: s3 连接超时时间，默认 1000ms

## Hive On OSS

```
CREATE CATALOG hive PROPERTIES (
 "type"="hms",
 "hive.metastore.uris" = "thrift://172.0.0.1:9083",
 "oss.endpoint" = "oss.oss-cn-beijing.aliyuncs.com",
 "oss.access_key" = "ak",
 "oss.secret_key" = "sk"
);
```

## Hive On OBS

```
CREATE CATALOG hive PROPERTIES (
 "type"="hms",
 "hive.metastore.uris" = "thrift://172.0.0.1:9083",
 "obs.endpoint" = "obs.cn-north-4.myhuaweicloud.com",
 "obs.access_key" = "ak",
 "obs.secret_key" = "sk"
);
```

## Hive On COS

```
CREATE CATALOG hive PROPERTIES (
 "type"="hms",
 "hive.metastore.uris" = "thrift://172.0.0.1:9083",
 "cos.endpoint" = "cos.ap-beijing.myqcloud.com",
 "cos.access_key" = "ak",
```

```
"cos.secret_key" = "sk"
);
```

## Hive With AWS Glue

连接 Glue 时，如果是在非 EC2 环境，需要将 EC2 环境里的 `~/.aws` 目录拷贝到当前环境里。也可以下载[AWS Cli](#)工具进行配置，这种方式也会在当前用户目录下创建 `.aws` 目录。

现在 Doris 访问 AWS 服务时，支持两种类型的身份认证。

### 使用 Catalog 属性认证

Catalog 支持填写基本的 Credentials 属性，比如：

- 访问 S3 时，可以使用 `s3.endpoint`, `s3.access_key`, `s3.secret_key`。
- 访问 Glue 时，可以使用 `glue.endpoint`, `glue.access_key`, `glue.secret_key`。

以 Iceberg Catalog 访问 Glue 为例，我们可以填写以下属性访问在 Glue 上托管的表：

```
CREATE CATALOG glue PROPERTIES (
 "type"="iceberg",
 "iceberg.catalog.type" = "glue",
 "glue.endpoint" = "https://glue.us-east-1.amazonaws.com",
 "glue.access_key" = "ak",
 "glue.secret_key" = "sk"
);
```

### 使用系统属性认证

用于运行在 AWS 资源 (如 EC2 实例) 上的应用程序。可以避免硬编码写入 Credentials，能够增强数据安全性。

当我们在创建 Catalog 时，未填写 Credentials 属性，那么此时会使用 `DefaultAWSCredentialsProviderChain`，它能够读取系统环境变量或者 instance profile 中配置的属性。

配置环境变量和系统属性的方式可以参考：[AWS CLI](#)。

- 可以选择的配置的环境变量有：`AWS_ACCESS_KEY_ID`、`AWS_SECRET_ACCESS_KEY`、`AWS_SESSION_TOKEN`、`AWS_ROLE_ARN`、`AWS_WEB_IDENTITY_TOKEN_FILE`等
- 另外，还可以使用[aws configure](#)直接配置 Credentials 信息，同时在 `~/.aws` 目录下生成 `credentials` 文件。

## Hive with 阿里云 DLF

阿里云 Data Lake Formation(DLF) 是阿里云上的统一元数据管理服务，兼容 Hive Metastore 协议，因此也可以和访问 Hive Metastore 一样，连接并访问 DLF。可以参考 [什么是 Data Lake Formation](#)。

### 创建 DLF Catalog

```
CREATE CATALOG dlf PROPERTIES (
 "type"="hms",
 "hive.metastore.type" = "dlf",
 "dlf.proxy.mode" = "DLF_ONLY",
```

```

"dlf.endpoint" = "datalake-vpc.cn-beijing.aliyuncs.com",
"dlf.region" = "cn-beijing",
"dlf.uid" = "uid",
"dlf.catalog.id" = "catalog_id", //可选
"dlf.access_key" = "ak",
"dlf.secret_key" = "sk"
);

```

其中 type 固定为 hms。如果需要公网访问阿里云对象存储的数据，可以设置 "dlf.access.public"="true"

- dlf.endpoint: DLF Endpoint, 参阅: [DLF Region 和 Endpoint 对照表](#)
- dlf.region: DLF Region, 参阅: [DLF Region 和 Endpoint 对照表](#)
- dlf.uid: 阿里云账号。即阿里云控制台右上角个人信息的“云账号 ID”。
- dlf.catalog.id(可选): Catalog Id。用于指定数据目录，如果不填，使用默认的 Catalog ID。
- dlf.access\_key: AccessKey。可以在 [阿里云控制台](#) 中创建和管理。
- dlf.secret\_key: SecretKey。可以在 [阿里云控制台](#) 中创建和管理。

其他配置项为固定值，无需改动。

之后，可以像正常的 Hive MetaStore 一样，访问 DLF 下的元数据。

同 Hive Catalog 一样，支持访问 DLF 中的 Hive/Iceberg/Hudi 的元数据信息。

### 使用开启了 HDFS 服务的 OSS 存储数据

1. 确认 OSS 开启了 HDFS 服务。 [开通并授权访问 OSS-HDFS 服务](#)。
2. 下载 SDK。 [JindoData SDK 下载](#)。如果集群上已有 SDK 目录，忽略这一步。
3. 解压下载后的 jindosdk.tar.gz 或者在集群上找到 Jindo SDK 的目录，将其 lib 目录下的 jindo-core.jar、jindo-sdk.jar 放到 \${DORIS\_HOME}/fe/lib 和 \${DORIS\_HOME}/be/lib/java\_extensions/preload-extensions 目录下。
4. 创建 DLF Catalog，并配置 oss.hdfs.enabled 为 true:

```

CREATE CATALOG dlf_oss_hdfs PROPERTIES (
 "type"="hms",
 "hive.metastore.type" = "dlf",
 "dlf.proxy.mode" = "DLF_ONLY",
 "dlf.endpoint" = "datalake-vpc.cn-beijing.aliyuncs.com",
 "dlf.region" = "cn-beijing",
 "dlf.uid" = "uid",
 "dlf.catalog.id" = "catalog_id", //可选
 "dlf.access_key" = "ak",
 "dlf.secret_key" = "sk",
 "oss.hdfs.enabled" = "true"
);

```

当 Jindo SDK 版本与 EMR 集群上所用的版本不一致时，会出现 Plugin not found 的问题，需更换到对应版本。

### 访问 DLF Iceberg 表

```
CREATE CATALOG dlf_iceberg PROPERTIES (
 "type"="iceberg",
 "iceberg.catalog.type" = "dlf",
 "dlf.proxy.mode" = "DLF_ONLY",
 "dlf.endpoint" = "datalake-vpc.cn-beijing.aliyuncs.com",
 "dlf.region" = "cn-beijing",
 "dlf.uid" = "uid",
 "dlf.catalog.id" = "catalog_id", //可选
 "dlf.access_key" = "ak",
 "dlf.secret_key" = "sk"
);
```

## 列类型映射

和 Hive Catalog 一致，可参阅 [Hive Catalog](#) 中 列类型映射 一节。

## 元数据缓存与刷新

针对 Hive Catalog，在 Doris 中会缓存 4 种元数据：

- 表结构：缓存表的列信息等。
- 分区值：缓存一个表的所有分区的分区值信息。
- 分区信息：缓存每个分区的信息，如分区数据格式，分区存储位置、分区值等。
- 文件信息：缓存每个分区所对应的文件信息，如文件路径位置等。

以上缓存信息不会持久化到 Doris 中，所以在 Doris 的 FE 节点重启、切主等操作，都可能导致缓存失效。缓存失效后，Doris 会直接访问 Hive MetaStore 获取信息，并重新填充缓存。

元数据缓存可以根据用户的需要，进行自动、手动，或配置 TTL（Time-to-Live）的方式进行更新。

### 默认行为和 TTL

默认情况下，元数据缓存会在第一次被填充后的 10 分钟后失效。该时间由 fe.conf 的配置参数 `external_cache_expire_time_minutes_after_access` 决定。（注意，在 2.0.1 及以前的版本中，该参数默认值为 1 天）。

例如，用户在 10:00 第一次访问表 A 的元数据，那么这些元数据会被缓存，并且到 10:10 后会自动失效，如果用户在 10:11 再次访问相同的元数据，则会直接访问 Hive MetaStore 获取信息，并重新填充缓存。

`external_cache_expire_time_minutes_after_access` 会影响 Catalog 下的所有 4 种缓存。

针对 Hive 中常用的 `INSERT INTO OVERWRITE PARTITION` 操作，也可以通过配置 文件信息缓存 的 TTL，来及时的更新 文件信息缓存：

```
CREATE CATALOG hive PROPERTIES (
 'type'='hms',
 'hive.metastore.uris' = 'thrift://172.0.0.1:9083',
 'file.meta.cache.ttl-second' = '60'
);
```

上面的例子中，`file.meta.cache.ttl-second` 设置为 60 秒，则缓存会在 60 秒后失效。这个参数，只会影响文件信息缓存。

也可以将该值设置为 0 来禁用分区文件缓存，每次都会从 Hive MetaStore 直接获取文件信息。

## 手动刷新

用户需要通过 [REFRESH](#) 命令手动刷新元数据。

### REFRESH CATALOG: 刷新指定 Catalog。

```
REFRESH CATALOG ctl1 PROPERTIES("invalid_cache" = "true");
```

- 该命令会刷新指定 Catalog 的库列表，表列名以及所有缓存信息等。
- `invalid_cache` 表示是否要刷新缓存。默认为 `true`。如果为 `false`，则只会刷新 Catalog 的库、表列表，而不会刷新缓存信息。该参数适用于，用户只想同步新增删的库表信息时。

### REFRESH DATABASE: 刷新指定 Database。

```
REFRESH DATABASE [ctl.]db1 PROPERTIES("invalid_cache" = "true");
```

- 该命令会刷新指定 Database 的表列名以及 Database 下的所有缓存信息等。
- `invalid_cache` 属性含义同上。默认为 `true`。如果为 `false`，则只会刷新 Database 的表列表，而不会刷新缓存信息。该参数适用于，用户只想同步新增删的表信息时。

### REFRESH TABLE: 刷新指定 Table。

```
REFRESH TABLE [ctl.][db.]tbl1;
```

- 该命令会刷新指定 Table 下的所有缓存信息等。

## 定时刷新

用户可以在创建 Catalog 时，设置该 Catalog 的定时刷新。

```
CREATE CATALOG hive PROPERTIES (
 'type'='hms',
 'hive.metastore.uris' = 'thrift://172.0.0.1:9083',
 'metadata_refresh_interval_sec' = '600'
);
```

在上例中，`metadata_refresh_interval_sec` 表示每 600 秒刷新一次 Catalog。相当于每隔 600 秒，自动执行一次如下操作：

```
REFRESH CATALOG ctl1 PROPERTIES("invalid_cache" = "true");
```

注意：定时刷新闻隔不得小于 5 秒。

## 自动刷新

自动刷新目前仅支持 Hive Metastore 元数据服务。通过让 FE 节点定时读取 HMS 的 notification event 来感知 Hive 表元数据的变更情况，目前支持处理如下 event：

事件	事件行为和对应的动作
CREATE DATABASE	在对应数据目录下创建数据库。
DROP DATABASE	在对应数据目录下删除数据库。
ALTER DATABASE	此事件的影响主要有更改数据库的属性信息，注释及默认存储位置等，这些改变不影响 doris 对外部数据目录的查询操作，因此目前会忽略此 event。
CREATE TABLE	在对应数据库下创建表。
DROP TABLE	在对应数据库下删除表，并失效表的缓存。
ALTER TABLE	如果是重命名，先删除旧名字的表，再用新名字创建表，否则失效该表的缓存。
ADD PARTITION	在对应表缓存的分区列表里添加分区。
DROP PARTITION	在对应表缓存的分区列表里删除分区，并失效该分区的缓存。
ALTER PARTITION	如果是重命名，先删除旧名字的分区，再用新名字创建分区，否则失效该分区的缓存。

当导入数据导致文件变更，分区表会走 ALTER PARTITION event 逻辑，不分区表会走 ALTER TABLE event 逻辑。

如果绕过 HMS 直接操作文件系统的话，HMS 不会生成对应事件，doris 因此也无法感知

该特性在 fe.conf 中有如下参数：

- enable\_hms\_events\_incremental\_sync: 是否开启元数据自动增量同步功能，默认关闭。
- hms\_events\_polling\_interval\_ms: 读取 event 的间隔时间，默认值为 10000，单位：毫秒。
- hms\_events\_batch\_size\_per\_rpc: 每次读取 event 的最大数量，默认值为 500。

如果想使用该特性 (华为 MRS 除外)，需要更改 HMS 的 hive-site.xml 并重启 HMS 和 HiveServer2：

```
<property>
 <name>hive.metastore.event.db.notification.api.auth</name>
 <value>false</value>
</property>
<property>
 <name>hive.metastore.dml.events</name>
 <value>true</value>
</property>
<property>
 <name>hive.metastore.transactional.event.listeners</name>
 <value>org.apache.hive.hcatalog.listener.DbNotificationListener</value>
</property>
```

华为的 MRS 需要更改 hivemetastore-site.xml 并重启 HMS 和 HiveServer2：

```
<property>
 <name>metastore.transactional.event.listeners</name>
```

```
<value>org.apache.hive.hcatalog.listener.DbNotificationListener</value>
</property>
```

## Hive 版本

Doris 可以正确访问不同 Hive 版本中的 Hive Metastore。在默认情况下, Doris 会以 Hive 2.3 版本的兼容接口访问 Hive Metastore。

如在查询时遇到如 Invalid method name: 'get\_table\_req' 类似错误, 说明 hive 版本不匹配。

你可以在创建 Catalog 时指定 Hive 的版本。如访问 Hive 1.1.0 版本:

```
CREATE CATALOG hive PROPERTIES (
 'type'='hms',
 'hive.metastore.uris' = 'thrift://172.0.0.1:9083',
 'hive.version' = '1.1.0'
);
```

## 列类型映射

适用于 Hive/Iceberge/Hudi

HMS Type	Doris Type	Comment
boolean	boolean	
tinyint	tinyint	
smallint	smallint	
int	int	
bigint	bigint	
date	date	
timestamp	datetime	
float	float	
double	double	
char	char	
varchar	varchar	
decimal	decimal	
array<type>	array<type>	支持嵌套, 如 array<map<string, int>>
map<KeyType, ValueType>	map<KeyType, ValueType>	支持嵌套, 如 map<string, array<int>>
struct<col1: Type1, col2: Type2, ...>	struct<col1: Type1, col2: Type2, ...>	支持嵌套, 如 struct<col1: array<int>, col2: map<int, date>>
other	unsupported	

\*\*\*\*是否按照 hive 表的 schema 来截断 char 或者 varchar 列\*\*\*\*



如果变量 `truncate_char_or_varchar_columns` 开启，则当 Hive 表的 Schema 中 Char 或者 Varchar 列的最大长度和底层 Parquet 或者 ORC 文件中的 Schema 不一致时会按照 Hive 表列的最大长度进行截断。

该变量默认为 `false`。

## 使用 Broker 访问 HMS

创建 HMS Catalog 时增加如下配置，Hive 外表文件分片和文件扫描将会由名为 `test_broker` 的 Broker 完成

```
"broker.name" = "test_broker"
```

Doris 基于 Iceberg FileIO 接口实现了 Broker 查询 HMS Catalog Iceberg 的支持。如有需求，可以在创建 HMS Catalog 时增加如下配置。

```
"io-impl" = "org.apache.doris.datasource.iceberg.broker.IcebergBrokerIO"
```

## 集成 Apache Ranger

Apache Ranger 是一个用来在 Hadoop 平台上进行监控，启用服务，以及全方位数据安全访问管理的安全框架。

Doris 支持为指定的 External Hive Catalog 使用 Apache Ranger 进行鉴权。

目前支持 Ranger 的库、表、列的鉴权，暂不支持加密、行权限、Data Mask 等功能。

如需使用 Apache Ranger 为整个 Doris 集群服务进行鉴权，请参阅 [使用 Apache Ranger 鉴权](#)

### 环境配置

连接开启 Ranger 权限校验的 Hive Metastore 需要增加配置 & 配置环境：

#### 1. 创建 Catalog 时增加：

```
"access_controller.properties.ranger.service.name" = "hive",
"access_controller.class" = "org.apache.doris.catalog.authorizer.RangerHiveAccessControllerFactory",
```

**注意：**`access_controller.properties.ranger.service.name` 指的是 **service** 的类型，例如 `hive`，`hdfs` 等。并不是配置文件中 `ranger.plugin.hive.service.name` 的值。

#### 2. 配置所有 FE 环境：

1. 将 HMS conf 目录下的配置文件 `ranger-hive-audit.xml`, `ranger-hive-security.xml`, `ranger-policymgr-ssl.xml` 复制到 FE 的 conf 目录下。
2. 修改 `ranger-hive-security.xml` 的属性，参考配置如下：

```
<?xml version="1.0" encoding="UTF-8"?>
<?xml-stylesheet type="text/xsl" href="configuration.xsl"?>
```

```

<configuration>
 #The directory for caching permission data, needs to be writable
 <property>
 <name>ranger.plugin.hive.policy.cache.dir</name>
 <value>/mnt/datadisk0/zhangdong/rangerdata</value>
 </property>
 #The time interval for periodically pulling permission data
 <property>
 <name>ranger.plugin.hive.policy.pollIntervalMs</name>
 <value>30000</value>
 </property>

 <property>
 <name>ranger.plugin.hive.policy.rest.client.connection.timeoutMs</name>
 <value>60000</value>
 </property>

 <property>
 <name>ranger.plugin.hive.policy.rest.client.read.timeoutMs</name>
 <value>60000</value>
 </property>

 <property>
 <name>ranger.plugin.hive.policy.rest.ssl.config.file</name>
 <value></value>
 </property>

 <property>
 <name>ranger.plugin.hive.policy.rest.url</name>
 <value>http://172.21.0.32:6080</value>
 </property>

 <property>
 <name>ranger.plugin.hive.policy.source.impl</name>
 <value>org.apache.ranger.admin.client.RangerAdminRESTClient</value>
 </property>

 <property>
 <name>ranger.plugin.hive.service.name</name>
 <value>hive</value>
 </property>

 <property>
 <name>xasecure.hive.update.xapolicies.on.grant.revoke</name>
 <value>true</value>
 </property>
</configuration>

```

3. 为获取到 Ranger 鉴权本身的日志，可在 <doris\_home>/conf 目录下添加配置文件 log4j.properties。

4. 重启 FE。

## 最佳实践

1. 在 ranger 端创建用户 user1 并授权 db1.table1.col1 的查询权限
2. 在 ranger 端创建角色 role1 并授权 db1.table1.col2 的查询权限
3. 在 Doris 创建同名用户 user1，user1 将直接拥有 db1.table1.col1 的查询权限

4. 在 Doris 创建同名角色 role1，并将 role1 分配给 user1，user1 将同时拥有 db1.table1.col1 和 col2 的查询权限
5. Admin 和 Root 用户的权限不受 Apache Ranger 的权限控制

## 使用 Kerberos 进行认证

Kerberos 是一种身份验证协议。它的设计目的是通过使用私钥加密技术为应用程序提供强身份验证。

### 环境配置

#### 1. 当集群中的服务配置了 Kerberos 认证，配置 Hive Catalog 时需要获取它们的认证信息。

- `hadoop.kerberos.keytab`: 记录了认证所需的 principal，Doris 集群中的 keytab 必须是同一个。
- `hadoop.kerberos.principal`: Doris 集群上找对应 hostname 的 principal，如 `doris/hostname@HADOOP.COM`，用 `klist -kt` 检查 keytab。
- `yarn.resourcemanager.principal`: 到 Yarn Resource Manager 节点，从 `yarn-site.xml` 中获取，用 `klist -kt` 检查 Yarn 的 keytab。
- `hive.metastore.kerberos.principal`: 到 Hive 元数据服务节点，从 `hive-site.xml` 中获取，用 `klist -kt` 检查 Hive 的 keytab。
- `hadoop.security.authentication`: 开启 Hadoop Kerberos 认证。

在所有的 BE、FE 节点下放置 `krb5.conf` 文件和 keytab 认证文件，keytab 认证文件路径和配置保持一致，`krb5.conf` 文件默认放置在 `/etc/krb5.conf` 路径。同时需确认 JVM 参数 `-Djava.security.krb5.conf` 和环境变量 `KRB5_CONFIG` 指向了正确的 `krb5.conf` 文件的路径。

#### 2. 当配置完成后，如在 FE、BE 日志中无法定位到问题，可以开启 Kerberos 调试。

- 在所有的 FE、BE 节点下，找到部署路径下的 `conf/fe.conf` 以及 `conf/be.conf`。
- 找到配置文件后，在 `JAVA_OPTS` 变量中设置 JVM 参数 `-Dsun.security.krb5.debug=true` 开启 Kerberos 调试。
- FE 节点的日志路径 `log/fe.out` 可查看 FE Kerberos 认证调试信息，BE 节点的日志路径 `log/be.out` 可查看 BE Kerberos 认证调试信息。
- 相关错误解决方法请参阅：[常见问题](#)

### 最佳实践

示例如下：

```
CREATE CATALOG hive_krb PROPERTIES (
 'type'='hms',
 'hive.metastore.uris' = 'thrift://172.0.0.1:9083',
 'hive.metastore.sasl.enabled' = 'true',
 'hive.metastore.kerberos.principal' = 'your-hms-principal',
 'hadoop.security.authentication' = 'kerberos',
 'hadoop.kerberos.keytab' = '/your-keytab-filepath/your.keytab',
```

```
'hadoop.kerberos.principal' = 'your-principal@YOUR.COM',
'yarn.resourcemanager.principal' = 'your-rm-principal'
);
```

同时提供 HDFS HA 信息和 Kerberos 认证信息，示例如下：

```
CREATE CATALOG hive_krb_ha PROPERTIES (
 'type'='hms',
 'hive.metastore.uris' = 'thrift://172.0.0.1:9083',
 'hive.metastore.sasl.enabled' = 'true',
 'hive.metastore.kerberos.principal' = 'your-hms-principal',
 'hadoop.security.authentication' = 'kerberos',
 'hadoop.kerberos.keytab' = '/your-keytab-filepath/your.keytab',
 'hadoop.kerberos.principal' = 'your-principal@YOUR.COM',
 'yarn.resourcemanager.principal' = 'your-rm-principal',
 'dfs.nameservices'='your-nameservice',
 'dfs.ha.namenodes.your-nameservice'='nn1,nn2',
 'dfs.namenode.rpc-address.your-nameservice.nn1'='172.21.0.2:8088',
 'dfs.namenode.rpc-address.your-nameservice.nn2'='172.21.0.3:8088',
 'dfs.client.failover.proxy.provider.your-
nameservice'='org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider'
);
```

## Hive Transactional 表

Hive transactional 表是 Hive 中支持 ACID 语义的表。详情可见：

<https://cwiki.apache.org/confluence/display/Hive/Hive+Transactions>

### Hive Transactional 表支持情况

表类型	在 Hive 中支持的操作	Hive 表属性	支持的 Hive 版本
Full-ACID Transactional Table	支持 Insert, Update, Delete 操作	'transactional'='true', 'transactional_properties'='insert_only'	3.x, 2.x, 其中 2.x 需要在 Hive 中执行完 major compaction 才可以加载
Insert-Only Transactional Table	只支持 Insert 操作	'transactional'='true'	3.x, 2.x

### 当前限制

目前不支持 Original Files 的场景。当一个表转换成 Transactional 表之后，后续新写的文件会使用 Hive Transactional 表的 schema，但是已经存在的数据文件是不会转化成 Transactional 表的 schema，这样的文件称为 Original Files。

# Hudi Catalog

## 使用限制

1. Hudi 表支持的查询类型如下，后续将支持 Incremental Query。

表类型	支持的查询类型
Copy On Write	Snapshot Query + Time Travel
Merge On Read	Snapshot Queries + Read Optimized Queries + Time Travel

1. 目前支持 Hive Metastore 和兼容 Hive Metastore 类型，例如[AWS Glue](#)/Alibaba DLF 的 Catalog。

## 创建 Catalog

和 Hive Catalog 基本一致，这里仅给出简单示例。其他示例可参阅 [Hive Catalog](#)。

```
CREATE CATALOG hudi PROPERTIES (
 'type'='hms',
 'hive.metastore.uris' = 'thrift://172.21.0.1:7004',
 'hadoop.username' = 'hive',
 'dfs.nameservices'='your-nameservice',
 'dfs.ha.namenodes.your-nameservice'='nn1,nn2',
 'dfs.namenode.rpc-address.your-nameservice.nn1'='172.21.0.2:4007',
 'dfs.namenode.rpc-address.your-nameservice.nn2'='172.21.0.3:4007',
 'dfs.client.failover.proxy.provider.your-
nameservice'='org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider'
);
```

可选配置参数：

参数名	说明	默认值
use_hive_sync_partition	使用 hms 已同步的分区数据	false

## 列类型映射

和 Hive Catalog 一致，可参阅 [Hive Catalog](#) 中 **列类型映射** 一节。

## Skip Merge

Spark 在创建 hudi mor 表的时候，会创建 \_ro 后缀的 read optimize 表，doris 读取 read optimize 表会跳过 log 文件的合并。doris 判定一个表是否为 read optimize 表并不是通过 \_ro 后缀，而是通过 hive inputformat，用户可以通过 SHOW CREATE TABLE 命令观察 cow/mor/read optimize 表的 inputformat 是否相同。

此外 doris 支持在 catalog properties 添加 hoodie 相关的配置，配置项兼容 [Spark Datasource Configs](#)。所以用户可以在 catalog properties 中添加 hoodie.datasource.merge.type=skip\_merge 跳过合并 log 文件。

## 查询优化

Doris 使用 parquet native reader 读取 COW 表的数据文件，使用 Java SDK(通过 JNI 调用 hudi-bundle) 读取 MOR 表的数据文件。在 Upsert 场景下，MOR 依然会有数据文件没有被更新，这部分文件可以通过 parquet native reader 读取，用户可以通过 [explain](#) 命令查看 Hudi scan 的执行计划，hudiNativeReadSplits 表示有多少 split 文件通过 parquet native reader 读取。

```
|0:VHUDI_SCAN_NODE|
| table: minbatch_mor_rt |
| predicates: `o_orderkey` = 100030752 |
| inputSplitNum=810, totalFileSize=5645053056, scanRanges=810 |
| partition=80/80 |
| numNodes=6 |
| hudiNativeReadSplits=717/810 |
```

用户可以通过 [profile](#) 查看 Java SDK 的性能，例如：

```
- HudiJniScanner: 0ns
- FillBlockTime: 31.29ms
- GetRecordReaderTime: 1m5s
- JavaScanTime: 35s991ms
- OpenScannerTime: 1m6s
```

1. OpenScannerTime: 创建并初始化 JNI Reader 的时间
2. JavaScanTime: Java SDK 读取数据的时间
3. FillBlockTime: Java 数据拷贝为 C++ 数据的时间
4. GetRecordReaderTime: 调用 Java SDK 并创建 Hudi Record Reader 的时间

## Time Travel

支持读取 Hudi 表指定的 Snapshot。

每一次对 Hudi 表的写操作都会产生一个新的快照。

默认情况下，查询请求只会读取最新版本的快照。

可以使用 FOR TIME AS OF 语句，根据快照的时间 ([时间格式](#)和 Hudi 官网保持一致) 读取历史版本的数据。示例如下：

```
SELECT * FROM hudi_tbl FOR TIME AS OF "2022-10-07 17:20:37";
```

```
SELECT * FROM hudi_tbl FOR TIME AS OF "20221007172037";
```

Hudi 表不支持 FOR VERSION AS OF 语句，使用该语法查询 Hudi 表将抛错。

# Iceberg Catalog

## 使用限制

1. 支持 Iceberg V1/V2 表格式。
2. V2 格式仅支持 Position Delete 方式，不支持 Equality Delete。
3. 支持 Parquet 文件格式。

## 创建 Catalog

### 基于 Hive Metastore 创建 Catalog

和 Hive Catalog 基本一致，这里仅给出简单示例。其他示例可参阅 [Hive Catalog](#)。

```
CREATE CATALOG iceberg PROPERTIES (
 'type'='hms',
 'hive.metastore.uris' = 'thrift://172.21.0.1:7004',
 'hadoop.username' = 'hive',
 'dfs.nameservices'='your-nameservice',
 'dfs.ha.namenodes.your-nameservice'='nn1,nn2',
 'dfs.namenode.rpc-address.your-nameservice.nn1'='172.21.0.2:4007',
 'dfs.namenode.rpc-address.your-nameservice.nn2'='172.21.0.3:4007',
 'dfs.client.failover.proxy.provider.your-
nameservice'='org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider'
);
```

### 基于 Iceberg API 创建 Catalog

使用 Iceberg API 访问元数据的方式，支持 Hadoop File System、Hive、REST、Glue、DLF 等服务作为 Iceberg 的 Catalog。

### Hadoop Catalog

```
CREATE CATALOG iceberg_hadoop PROPERTIES (
 'type'='iceberg',
 'iceberg.catalog.type' = 'hadoop',
 'warehouse' = 'hdfs://your-host:8020/dir/key'
);
```

```
CREATE CATALOG iceberg_hadoop_ha PROPERTIES (
 'type'='iceberg',
 'iceberg.catalog.type' = 'hadoop',
 'warehouse' = 'hdfs://your-nameservice/dir/key',
 'dfs.nameservices'='your-nameservice',
 'dfs.ha.namenodes.your-nameservice'='nn1,nn2',
 'dfs.namenode.rpc-address.your-nameservice.nn1'='172.21.0.2:4007',
 'dfs.namenode.rpc-address.your-nameservice.nn2'='172.21.0.3:4007',
 'dfs.client.failover.proxy.provider.your-
nameservice'='org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider'
);
```

## Hive Metastore

```
CREATE CATALOG iceberg PROPERTIES (
 'type'='iceberg',
 'iceberg.catalog.type'='hms',
 'hive.metastore.uris' = 'thrift://172.21.0.1:7004',
 'hadoop.username' = 'hive',
 'dfs.nameservices'='your-nameservice',
 'dfs.ha.namenodes.your-nameservice'='nn1,nn2',
 'dfs.namenode.rpc-address.your-nameservice.nn1'='172.21.0.2:4007',
 'dfs.namenode.rpc-address.your-nameservice.nn2'='172.21.0.3:4007',
 'dfs.client.failover.proxy.provider.your-
nameservice'='org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider'
);
```

## AWS Glue

```
CREATE CATALOG glue PROPERTIES (
 "type"="iceberg",
 "iceberg.catalog.type" = "glue",
 "glue.endpoint" = "https://glue.us-east-1.amazonaws.com",
 "glue.access_key" = "ak",
 "glue.secret_key" = "sk"
);
```

Iceberg 属性详情参见 [Iceberg Glue Catalog](#)

## 阿里云 DLF

参见[阿里云 DLF Catalog 配置](#)

## REST Catalog

该方式需要预先提供 REST 服务，用户需实现获取 Iceberg 元数据的 REST 接口。

```
CREATE CATALOG iceberg PROPERTIES (
 'type'='iceberg',
 'iceberg.catalog.type'='rest',
 'uri' = 'http://172.21.0.1:8181'
);
```

如果使用 HDFS 存储数据，并开启了高可用模式，还需在 Catalog 中增加 HDFS 高可用配置：

```
CREATE CATALOG iceberg PROPERTIES (
 'type'='iceberg',
 'iceberg.catalog.type'='rest',
 'uri' = 'http://172.21.0.1:8181',
 'dfs.nameservices'='your-nameservice',
 'dfs.ha.namenodes.your-nameservice'='nn1,nn2',
 'dfs.namenode.rpc-address.your-nameservice.nn1'='172.21.0.1:8020',
 'dfs.namenode.rpc-address.your-nameservice.nn2'='172.21.0.2:8020',
 'dfs.client.failover.proxy.provider.your-
nameservice'='org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider'
);
```

## Google Dataproc Metastore



```
CREATE CATALOG iceberg PROPERTIES (
 "type"="iceberg",
 "iceberg.catalog.type"="hms",
 "hive.metastore.uris" = "thrift://172.21.0.1:9083",
 "gs.endpoint" = "https://storage.googleapis.com",
 "gs.region" = "us-east-1",
 "gs.access_key" = "ak",
 "gs.secret_key" = "sk",
 "use_path_style" = "true"
);
```

hive.metastore.uris: Dataproc Metastore 服务开放的接口，在 Metastore 管理页面获取：[Dataproc Metastore Services](#).

## Iceberg On Object Storage

若数据存放在 S3 上，properties 中可以使用以下参数：

```
"s3.access_key" = "ak"
"s3.secret_key" = "sk"
"s3.endpoint" = "s3.us-east-1.amazonaws.com"
"s3.region" = "us-east-1"
```

数据存放在阿里云 OSS 上：

```
"oss.access_key" = "ak"
"oss.secret_key" = "sk"
"oss.endpoint" = "oss-cn-beijing-internal.aliyuncs.com"
"oss.region" = "oss-cn-beijing"
```

数据存放在腾讯云 COS 上：

```
"cos.access_key" = "ak"
"cos.secret_key" = "sk"
"cos.endpoint" = "cos.ap-beijing.myqcloud.com"
"cos.region" = "ap-beijing"
```

数据存放在华为云 OBS 上：

```
"obs.access_key" = "ak"
"obs.secret_key" = "sk"
"obs.endpoint" = "obs.cn-north-4.myhuaweicloud.com"
"obs.region" = "cn-north-4"
```

## 列类型映射

Iceberg Type	Doris Type
boolean	boolean
int	int
long	bigint

Iceberg Type	Doris Type
float	float
double	double
decimal(p,s)	decimal(p,s)
date	date
uuid	string
timestamp (Timestamp without timezone)	datetime(6)
timestampz (Timestamp with timezone)	datetime(6)
string	string
fixed(L)	char(L)
binary	string
list	array
struct	不支持
map	不支持
time	不支持

## Time Travel

支持读取 Iceberg 表指定的 Snapshot。

每一次对 iceberg 表的写操作都会产生一个新的快照。

默认情况下，读取请求只会读取最新版本的快照。

可以使用 FOR TIME AS OF 和 FOR VERSION AS OF 语句，根据快照 ID 或者快照产生的时间读取历史版本的数据。示例如下：

```
SELECT * FROM iceberg_tbl FOR TIME AS OF "2022-10-07 17:20:37";
```

```
SELECT * FROM iceberg_tbl FOR VERSION AS OF 868895038966572;
```

另外，可以使用 [iceberg\\_meta](#) 表函数查询指定表的 snapshot 信息。

# Paimon Catalog

## 使用须知

1. 数据放在 hdfs 时，需要将 core-site.xml，hdfs-site.xml 和 hive-site.xml 放到 FE 和 BE 的 conf 目录下。  
优先读取 conf 目录下的 hadoop 配置文件，再读取环境变量 HADOOP\_CONF\_DIR 的相关配置文件。
2. 当前最新适配的 Paimon 版本为 0.7。

## 创建 Catalog

Paimon Catalog 当前支持两种类型的 Metastore 创建 Catalog:

- filesystem（默认），同时存储元数据和数据在 filesystem。
- Hive Metastore，它还将元数据存储存储在 Hive Metastore 中。用户可以直接从 Hive 访问这些表。

### 基于 FileSystem 创建 Catalog

#### HDFS

```
CREATE CATALOG `paimon_hdfs` PROPERTIES (
 "type" = "paimon",
 "warehouse" = "hdfs://HDFS8000871/user/paimon",
 "dfs.nameservices" = "HDFS8000871",
 "dfs.ha.namenodes.HDFS8000871" = "nn1,nn2",
 "dfs.namenode.rpc-address.HDFS8000871.nn1" = "172.21.0.1:4007",
 "dfs.namenode.rpc-address.HDFS8000871.nn2" = "172.21.0.2:4007",
 "dfs.client.failover.proxy.provider.HDFS8000871" =
 "org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider",
 "hadoop.username" = "hadoop"
);
```

#### MINIO

##### 注意：

用户需要手动下载[paimon-s3-0.6.0-incubating.jar](#)

放在 \${DORIS\_HOME}/be/lib/java\_extensions/preload-extensions 目录下并重启 BE

从 2.0.2 版本起，可以将这个文件放置在 BE 的 custom\_lib/ 目录下（如不存在，手动创建即可），以防止升级集群时因为 lib 目录被替换而导致文件丢失。

```
CREATE CATALOG `paimon_s3` PROPERTIES (
 "type" = "paimon",
 "warehouse" = "s3://bucket_name/paimons3",
 "s3.endpoint" = "http://<ip>:<port>",
 "s3.access_key" = "ak",
```

```
"s3.secret_key" = "sk"
);
```

## OBS

### 注意：

用户需要手动下载[paimon-s3-0.6.0-incubating.jar](#)

放在 \${DORIS\_HOME}/be/lib/java\_extensions/preload-extensions 目录下并重启 BE

从 2.0.2 版本起，可以将这个文件放置在 BE 的 custom\_lib/ 目录下（如不存在，手动创建即可），以防止升级集群时因为 lib 目录被替换而导致文件丢失。

```
CREATE CATALOG `paimon_obs` PROPERTIES (
 "type" = "paimon",
 "warehouse" = "obs://bucket_name/paimon",
 "obs.endpoint"="obs.cn-north-4.myhuaweicloud.com",
 "obs.access_key"="ak",
 "obs.secret_key"="sk"
);
```

## COS

```
CREATE CATALOG `paimon_s3` PROPERTIES (
 "type" = "paimon",
 "warehouse" = "cosn://paimon-1308700295/paimoncos",
 "cos.endpoint" = "cos.ap-beijing.myqcloud.com",
 "cos.access_key" = "ak",
 "cos.secret_key" = "sk"
);
```

## OSS

```
CREATE CATALOG `paimon_oss` PROPERTIES (
 "type" = "paimon",
 "warehouse" = "oss://paimon-zd/paimonoss",
 "oss.endpoint" = "oss-cn-beijing.aliyuncs.com",
 "oss.access_key" = "ak",
 "oss.secret_key" = "sk"
);
```

## 基于 Hive Metastore 创建 Catalog

```
CREATE CATALOG `paimon_hms` PROPERTIES (
 "type" = "paimon",
 "paimon.catalog.type" = "hms",
 "warehouse" = "hdfs://HDFS8000871/user/zhangdong/paimon2",
 "hive.metastore.uris" = "thrift://172.21.0.44:7004",
 "dfs.nameservices" = "HDFS8000871",
 "dfs.ha.namenodes.HDFS8000871" = "nn1,nn2",
 "dfs.namenode.rpc-address.HDFS8000871.nn1" = "172.21.0.1:4007",
 "dfs.namenode.rpc-address.HDFS8000871.nn2" = "172.21.0.2:4007",
```

```
"dfs.client.failover.proxy.provider.HDFS8000871" =
"org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider",
"hadoop.username" = "hadoop"
);
```

## 列类型映射

Paimon Data Type	Doris Data Type	Comment
BooleanType	Boolean	
TinyIntType	TinyInt	
SmallIntType	SmallInt	
IntType	Int	
FloatType	Float	
BigIntType	BigInt	
DoubleType	Double	
VarCharType	VarChar	
CharType	Char	
VarBinaryType, BinaryType	Binary	
DecimalType(precision, scale)	Decimal(precision, scale)	
TimestampType, LocalZonedTimestampType	DateTime	
DateType	Date	
ArrayType	Array	支持 Array 嵌套
MapType	Map	支持 Map 嵌套
RowType	Struct	支持 Struct 嵌套 (2.0.10 版本开始支持)

## 常见问题

### 1. Kerberos 问题

- 确保 principal 和 keytab 配置正确。
- 需在 BE 节点启动定时任务（如 crontab），每隔一定时间（如 12 小时），执行一次 `kinit -kt your_principal your_keytab` 命令。

### 2. Unknown type value: UNSUPPORTED

这是 Doris 2.0.2 版本和 Paimon 0.5 版本的一个兼容性问题，需要升级到 2.0.3 或更高版本解决，或自行 [patch](#)

### 3. 访问对象存储（OSS、S3 等）报错文件系统不支持

在 2.0.5（含）之前的版本，用户需手动下载以下 jar 包并放置在  
\${DORIS\_HOME}/be/lib/java\_extensions/preload-extensions 目录下，重启 BE。

- 访问 OSS: [paimon-oss-0.6.0-incubating.jar](#)
- 访问其他对象存储: [paimon-s3-0.6.0-incubating.jar](#)

2.0.6 之后的版本不再需要用户手动放置。

# AWS 认证接入

当访问云上的服务时，我们需要提供访问服务所需要的凭证，以便服务能够通过各云厂商 IAM 的认证。

现在 Doris 访问 AWS 服务时，能够支持两种类型的身份认证。

## 使用 Catalog 属性认证

Catalog 支持填写基本的 Credentials 属性，比如：

1. 访问 S3 时，可以使用 `s3.endpoint`, `s3.access_key`, `s3.secret_key`。
2. 访问 Glue 时，可以使用 `glue.endpoint`, `glue.access_key`, `glue.secret_key`。

以 Iceberg Catalog 访问 Glue 为例，我们可以填写以下属性访问在 Glue 上托管的表：

```
CREATE CATALOG glue PROPERTIES (
 "type"="iceberg",
 "iceberg.catalog.type" = "glue",
 "glue.endpoint" = "https://glue.us-east-1.amazonaws.com",
 "glue.access_key" = "ak",
 "glue.secret_key" = "sk"
);
```

## 使用系统属性认证

用于运行在 AWS 资源 (如 EC2 实例) 上的应用程序。可以避免硬编码写入 Credentials，能够增强数据安全性。

当我们在创建 Catalog 时，未填写 Credentials 属性，那么此时会使用 `DefaultAWSCredentialsProviderChain`，它能够读取系统环境变量或者 instance profile 中配置的属性。

配置环境变量和系统属性的方式可以参考：[AWS CLI](#)。

- 可以选择的配置的环境变量有：`AWS_ACCESS_KEY_ID`、`AWS_SECRET_ACCESS_KEY`、`AWS_SESSION_TOKEN`、`AWS_ROLE_ARN`、`AWS_WEB_IDENTITY_TOKEN_FILE`等
- 另外，还可以使用[aws configure](#)直接配置 Credentials 信息，同时在 `~/.aws` 目录下生成 credentials 文件。

# JDBC Catalog

Doris JDBC Catalog 支持通过标准 JDBC 接口连接不同支持 JDBC 协议的数据库。本文档介绍 JDBC Catalog 的通用配置和使用方法。

## 支持的数据库

Doris JDBC Catalog 支持连接以下数据库：

数据库	说明
<a href="#">MySQL</a>	
<a href="#">PostgreSQL</a>	
<a href="#">Oracle</a>	
<a href="#">SQL Server</a>	
<a href="#">ClickHouse</a>	
<a href="#">SAP HANA</a>	
<a href="#">OceanBase</a>	

## 配置

### 基本属性

参数	说明
type	固定为 jdbc
user	数据源用户名
password	数据源密码
jdbc_url	数据源连接 URL
driver_url	数据源 JDBC 驱动程序的路径
driver_class	数据源 JDBC 驱动程序的类名

### 可选属性

参数	默认值	说明
lower_case_table_names	“false”	是否以小写的形式同步 jdbc 外部数据源的库名和表名
only_specified_database	“false”	是否只同步 JDBC URL 中指定的数据源的 Database（此处的 Database 为映射到 Doris 的 Database 层级）
include_database_list	“”	当 only_specified_database=true 时，指定同步多个 Database，以','分隔。Database 名称是大小写敏感的。



参数	默认值	说明
exclude_database_list	""	当 only_specified_database=true 时，指定不需要同步的多个 Database，以','分割。Database 名称是大小写敏感的。

## 连接池属性

参数	默认值	说明
connection_pool_min_size	1	定义连接池的最小连接数，用于初始化连接池并保证在启用保活机制时至少有该数量的连接处于活跃状态。
connection_pool_max_size	30	定义连接池的最大连接数，每个 Catalog 对应的每个 FE 或 BE 节点最多可持有此数量的连接。
connection_pool_max_wait_time	5000	如果连接池中沒有可用连接，定义客户端等待连接的最大毫秒数。
connection_pool_max_life_time	1800000	设置连接在连接池中保持活跃的最大时长（毫秒）。超时的连接将被回收。同时，此值的一半将作为连接池的最小逐出空闲时间，达到该时间的连接将成为逐出候选对象。
connection_pool_keep_alive	false	仅在 BE 节点上有效，用于决定是否保持达到最小逐出空闲时间但未到最大生命周期的连接活跃。默认关闭，以减少不必要的资源使用。

## 属性须知

### 驱动包路径与安全性

driver\_url 可以通过以下三种方式指定：

1. 文件名。如 mysql-connector-j-8.3.0.jar。需将 Jar 包预先存放在 FE 和 BE 部署目录下的 jdbc\_drivers/ 目录下。系统会自动在这个目录下寻找。该目录的位置，也可以由 fe.conf 和 be.conf 中的 jdbc\_drivers\_dir 配置修改。
2. 本地绝对路径。如 file:///path/to/mysql-connector-j-8.3.0.jar。需将 Jar 包预先存放在所有 FE/BE 节点指定的路径下。
3. Http 地址。如：http://repo1.maven.org/maven2/com/mysql/mysql-connector-j/8.3.0/mysql-connector-j-8.3.0.jar 系统会从这个 Http 地址下载 Driver 文件。仅支持无认证的 Http 服务。

### 驱动包安全性

为了防止在创建 Catalog 时使用了未允许路径的 Driver Jar 包，Doris 会对 Jar 包进行路径管理和校验和检查。

1. 针对上述方式 1，Doris 默认用户配置的 jdbc\_drivers\_dir 和其目录下的所有 Jar 包都是安全的，不会对其进行路径检查。
2. 针对上述方式 2、3，Doris 会对 Jar 包的来源进行检查，检查规则如下：
  - 通过 FE 配置项 jdbc\_driver\_secure\_path 来控制允许的驱动包路径，该配置项可配置多个路径，以分号分隔。当配置了该项时，Doris 会检查 Catalog properties 中 driver\_url 的路径是的部分前缀是否在 jdbc\_driver\_secure\_path 中，如果不在其中，则会拒绝创建 Catalog。

- 此参数默认为 \*，表示允许所有路径的 Jar 包。
- 如果配置 jdbc\_driver\_secure\_path 为空，也表示允许所有路径的 Jar 包。

:::info 备注 如配置 jdbc\_driver\_secure\_path =  
"file:///path/to/jdbc\_drivers;http:///path/to/jdbc\_drivers" :

则只允许以 file:///path/to/jdbc\_drivers 或 http:///path/to/jdbc\_drivers 开头的驱动包路径。  
:::

3. 在创建 Catalog 时，可以通过 checksum 参数来指定驱动包的校验和，Doris 会在加载驱动包后，对驱动包进行校验，如果校验失败，则会拒绝创建 Catalog。

## 备注

上述的校验只会在创建 Catalog 时进行，对于已经创建的 Catalog，不会再次进行校验。

## 小写名称同步

当 lower\_case\_table\_names 设置为 true 时，Doris 通过维护小写名称到远程系统中实际名称的映射，能够查询非小写的数据库和表

### 注意：

1. 在 Doris 2.0.3 之前的版本，仅对 Oracle 数据库有效，在查询时，会将所有的库名和表名转换为大写，再去查询 Oracle，例如：

Oracle 在 TEST 空间下有 TEST 表，Doris 创建 Catalog 时设置 lower\_case\_table\_names 为 true，则 Doris 可以通过 select \* from oracle\_catalog.test.test 查询到 TEST 表，Doris 会自动将 test.test 格式化成 TEST.TEST 下发到 Oracle，需要注意的是这是个默认行为，也意味着不能查询 Oracle 中小写的表名。

对于其他数据库，仍需要在查询时指定真实的库名和表名。

2. 在 Doris 2.0.3 及之后的 2.0.x 版本，对所有的数据库都有效，在查询时，会将所有的库名和表名转换为真实的名称，再去查询，如果是从老版本升级到 2.0.3，需要 Refresh <catalog\_name> 才能生效。

但是，如果数据库或者表名只有大小写不同，例如 Doris 和 doris，则 Doris 由于歧义而无法查询它们。

3. 当 FE 参数的 lower\_case\_table\_names 设置为 1 或 2 时，JDBC Catalog 的 lower\_case\_table\_names 参数必须设置为 true。如果 FE 参数的 lower\_case\_table\_names 设置为 0，则 JDBC Catalog 的参数可以为 true 或 false，默认为 false。这确保了 Doris 在处理内部和外部表配置时的一致性和可预测性。

## 指定同步数据库

only\_specified\_database: 是否只同步 JDBC URL 中指定的数据源的 Database。默认值为 false，表示同步 JDBC URL 中所有的 Database。

include\_database\_list: 仅在 only\_specified\_database=true 时生效，指定需要同步的 PostgreSQL 的 Schema，以','分隔。Schema 名称是大小写敏感的。

`exclude_database_list`: 仅在`only_specified_database=true`时生效, 指定不需要同步的 PostgreSQL 的 Schema, 以','分隔。Schema 名称是大小写敏感的。

#### 备注

- 上述三个参数中提到的 Database 是指 Doris 中的 Database 层级, 而不是外部数据源的 Database 层级, 具体的映射关系可以参考各个数据源文档。
- 当 `include_database_list` 和 `exclude_database_list` 有重合的 database 配置时, `exclude_database_list` 会优先生效。

## 连接池配置

在 Doris 中, 每个 FE 和 BE 节点都会维护一个连接池, 这样可以避免频繁地打开和关闭单独的数据源连接。连接池中的每个连接都可以用来与数据源建立连接并执行查询。任务完成后, 这些连接会被归还到池中以便重复使用, 这不仅提高了性能, 还减少了建立连接时的系统开销, 并帮助防止达到数据源的连接数上限。

可以根据实际情况调整连接池的大小, 以便更好地适应您的工作负载。通常情况下, 连接池的最小连接数应该设置为 1, 以确保在启用保活机制时至少有一个连接处于活跃状态。连接池的最大连接数应该设置为一个合理的值, 以避免过多的连接占用资源。

同时为了避免在 BE 上累积过多的未使用的连接池缓存, 可以通过设置 BE 的 `jdbc_connection_pool_cache_clear_time_sec` 参数来指定清理缓存的时间间隔。默认值为 28800 秒 (8 小时), 此间隔过后, BE 将强制清理所有超过该时间未使用的连接池缓存。

#### 使用 Doris JDBC Catalog 连接外部数据源时, 需谨慎更新数据库凭证。

Doris 通过连接池维持活跃连接以快速响应查询。但凭证变更后, 连接池可能会继续使用旧凭证尝试建立新连接并失败。由于系统试图保持一定数量的活跃连接, 这种错误尝试会重复执行, 且在某些数据库系统中, 频繁的失败可能导致账户被锁定。建议在必须更改凭证时, 同步更新 Doris JDBC Catalog 配置, 并重启 Doris 集群, 以确保所有节点使用最新凭证, 防止连接失败和潜在的账户锁定。

可能遇到的账户锁定如下:

MySQL: account is locked

Oracle: ORA-28000: the account is locked

SQL Server: Login is locked out

## Insert 事务

Doris 的数据是由一组 batch 的方式写入 JDBC Catalog 的, 如果中途导入中断, 之前写入数据可能需要回滚。所以 JDBC Catalog 支持数据写入时的事务, 事务的支持需要通过设置 session variable: `enable_odbc_transcation`。

```
set enable_odbc_transcation = true;
```

事务保证了 JDBC Catalog 数据写入的原子性，但是一定程度上会降低数据写入的性能，可以考虑酌情开启该功能。

## 示例

此处以 MySQL 为例，展示如何创建一个 MySQL Catalog 并查询其中的数据。

创建一个名为 mysql 的 Catalog：

```
CREATE CATALOG mysql PROPERTIES (
 "type"="jdbc",
 "user"="root",
 "password"="secret",
 "jdbc_url" = "jdbc:mysql://example.net:3306",
 "driver_url" = "mysql-connector-j-8.3.0.jar",
 "driver_class" = "com.mysql.cj.jdbc.Driver"
)
```

通过运行 SHOW DATABASES 查看此 Catalog 所有数据库：

```
SHOW DATABASES FROM mysql;
```

如果您有一个名为 test 的 MySQL 数据库，您可以通过运行 SHOW TABLES 查看该数据库中的表：

```
SHOW TABLES FROM mysql.test;
```

最后，您可以访问 MySQL 数据库中的表：

```
SELECT * FROM mysql.test.table;
```

## 连接池问题排查

1. 在小于 2.0.5 的版本，连接池相关配置只能在 BE conf 的 JAVA\_OPTS 中配置，参考 2.0.4 版本的 [be.conf](#)。
2. 在 2.0.5 及之后的版本，连接池相关配置可以在 Catalog 属性中配置，参考 [连接池属性](#)。
3. Doris 使用的连接池在 2.0.10 (2.0 Release) 和 2.1.3 (2.1 Release) 开始从 Druid 换为 HikariCP，故连接池相关报错以及原因排查方式有所不同，参考如下

### Druid 连接池版本

**Initialize datasource failed: CAUSED BY: GetConnectionTimeoutException: wait millis 5006, active 10, maxActive 10, creating 1** \* 原因 1：查询太多导致连接个数超出配置 \* 原因 2：连接池计数异常导致活跃计数未下降 \* 解决方法 \* alter catalog set properties ('connection\_pool\_max\_size' = '100'); 暂时通过调整连接数来增大连接池容量，且可以通过这种方式刷新连接池缓存 \* 升级到更换连接池到 Hikari 版本

**Initialize datasource failed: CAUSED BY: GetConnectionTimeoutException: wait millis 5006, active 10, maxActive 0, creating 1** \* 原因 1：网络不通 \* 原因 2：网络延迟高，导致创建连接超过 5s \* 解决方法 \* 检查网络 \* alter catalog set properties ('connection\_pool\_max\_wait' = '10000'); 调大超时时间

## HikariCP 连接池版本

Connection is not available, request timed out after 5000ms

### 可能的原因：

- **原因 1：**网络问题（例如，服务器不可达）
- **原因 2：**身份认证问题，例如无效的用户名或密码
- **原因 3：**网络延迟过高，导致创建连接超过 5 秒超时时间
- **原因 4：**并发查询过多，超过了连接池配置的最大连接数

### 解决方案：

- 如果只有 **“Connection is not available, request timed out after 5000ms”** 这一类错误，请检查 **原因 3** 和 **原因 4**：

- 检查是否存在网络延迟过高或资源耗尽的情况。
- 调大连接池的最大连接数：

```
ALTER CATALOG <catalog_name> SET PROPERTIES ('connection_pool_max_size' = '100');
```

- 调大连接超时时间：

```
ALTER CATALOG <catalog_name> SET PROPERTIES ('connection_pool_max_wait_time' = '10000');
```

- 如果除了 **“Connection is not available, request timed out after 5000ms”** 之外还有其他错误信息，请检查这些附加错误：
  - **网络问题**（例如，服务器不可达）可能导致连接失败。请检查网络连接是否正常。
  - **身份认证问题**（例如，用户名或密码无效）也可能导致连接失败。请检查配置中使用的数据库凭证，确保用户名和密码正确无误。
  - 根据具体错误信息，调查与网络、数据库或身份认证相关的问题，找出根本原因。

# MySQL

Doris JDBC Catalog 支持通过标准 JDBC 接口连接 MySQL 数据库。本文档介绍如何配置 MySQL 数据库连接。

## 使用须知

要连接到 MySQL 数据库，您需要

- MySQL 5.7, 8.0 或更高版本
- MySQL 数据库的 JDBC 驱动程序，您可以从 [Maven 仓库](#) 下载最新或指定版本的 MySQL JDBC 驱动程序。推荐使用 **MySQL Connector/J 8.0.31** 及以上版本。
- Doris 每个 FE 和 BE 节点和 MySQL 服务器之间的网络连接，默认端口为 3306。

## 连接 MySQL

```
CREATE CATALOG mysql PROPERTIES (
 "type"="jdbc",
 "user"="root",
 "password"="secret",
 "jdbc_url" = "jdbc:mysql://example.net:3306",
 "driver_url" = "mysql-connector-j-8.3.0.jar",
 "driver_class" = "com.mysql.cj.jdbc.Driver"
)
```

### 备注

jdbc\_url 定义要传递给 MySQL JDBC 驱动程序的连接信息和参数。支持的 URL 的参数可在 [MySQL 开发指南](#) 中找到。

## 连接安全

如果您使用数据源上安装的全局信任证书配置了 TLS，则可以通过将参数附加到在 jdbc\_url 属性中设置的 JDBC 连接字符串来启用集群和数据源之间的 TLS。

例如，对于 MySQL Connector/J 8.0 版，使用 sslMode 参数通过 TLS 保护连接。默认情况下，该参数设置为 PREFERRED，如果服务器启用，它可以保护连接。您还可以将此参数设置为 REQUIRED，如果未建立 TLS，则会导致连接失败。

您可以在通过在 jdbc\_url 中添加 sslMode 参数来配置它：

```
"jdbc_url"="jdbc:mysql://example.net:3306/?sslMode=REQUIRED"
```

有关 TLS 配置选项的更多信息，请参阅 [MySQL JDBC 安全文档](#)。

## 层级映射

映射 MySQL 时，Doris 的一个 Database 对应于 MySQL 中的一个 Database。而 Doris 的 Database 下的 Table 则对应于 MySQL 中，该 Database 下的 Tables。即映射关系如下：

Doris	MySQL
Catalog	MySQL Server
Database	Database
Table	Table

## 类型映射

### MySQL 到 Doris 类型映射

MYSQL Type	Doris Type	Comment
BOOLEAN	TINYINT	
TINYINT	TINYINT	
SMALLINT	SMALLINT	
MEDIUMINT	INT	
INT	INT	
BIGINT	BIGINT	
UNSIGNED TINYINT	SMALLINT	
UNSIGNED MEDIUMINT	INT	
UNSIGNED INT	BIGINT	
UNSIGNED BIGINT	LARGEINT	
FLOAT	FLOAT	
DOUBLE	DOUBLE	
DECIMAL	DECIMAL	
UNSIGNED DECIMAL(p,s)	DECIMAL(p+1,s) / STRING	
DATE	DATE	
TIMESTAMP	DATETIME	
DATETIME	DATETIME	
YEAR	SMALLINT	
TIME	STRING	
CHAR	CHAR	
VARCHAR	VARCHAR	
JSON	STRING	

MYSQL Type	Doris Type	Comment
SET	STRING	
ENUM	STRING	
BIT	BOOLEAN/STRING	
TINYTEXT,TEXT,MEDIUMTEXT,LONGTEXT	STRING	
BLOB,MEDIUMBLOB,LONGBLOB,TINYBLOB	STRING	
BINARY,VARBINARY	STRING	
Other	UNSUPPORTED	

- Doris 不支持 UNSIGNED 数据类型，所以 UNSIGNED 数据类型会被映射为 Doris 对应大一个数量级的数据类型。

- UNSIGNED DECIMAL(p,s) 会被映射为 DECIMAL(p+1,s) 或 STRING。注意在此类型被映射为 String 时，只能支持查询，不能对 MySQL 进行写入操作。
- 为了更好的读取与计算性能均衡，Doris 会将 JSON 类型映射为 STRING 类型。
- Doris 不支持 BIT 类型，BIT 类型会在 BIT(1) 时被映射为 BOOLEAN，其他情况下映射为 STRING。
- Doris 不支持 YEAR 类型，YEAR 类型会被映射为 SMALLINT。
- Doris 不支持 TIME 类型，TIME 类型会被映射为 STRING。

## 时间戳类型处理

在 JDBC 类型 Catalog 读取数据时，BE 的 Java 部分使用 JVM 时区。JVM 时区默认为 BE 部署机器的时区，这会影响 JDBC 读取数据时的时区转换。

为了确保时区一致性，建议在 be.conf 的 JAVA\_OPTS 中设置 JVM 时区与 Doris session 的 time\_zone 一致。

读取 MySQL 的 TIMESTAMP 类型时，请在 JDBC URL 中添加参数：connectionTimeZone=LOCAL 和 forceConnectionTimeZoneToSession=true。这些参数适用于 MySQL Connector/J 8 以上版本，可确保读取的时间为 Doris BE JVM 时区，而非 MySQL session 时区。

## 查询优化

### 谓词下推

1. 当执行类似于 where dt = '2022-01-01' 这样的查询时，Doris 能够将这些过滤条件下推到外部数据源，从而直接在数据源层面排除不符合条件的数据，减少了不必要的数据获取和传输。这大大提高了查询性能，同时也降低了对外部数据源的负载。
2. 当 FE conf enable\_func\_pushdown 设置为 true，会将 where 之后的函数条件也下推到外部数据源，Doris 会自动识别部分 MySQL 不支持的函数，可通过 explain sql 查看。

当前 Doris 默认不会下推到 MySQL 的函数如下



Function
DATE_TRUNC
MONEY_FORMAT

## 行数限制

如果在查询中带有 limit 关键字，Doris 会将 limit 下推到 MySQL，以减少数据传输量。

## 转义字符

Doris 会在下发到 MySQL 的查询语句中，自动在字段名与表名上加上转义符：(``)，以避免字段名与表名与 MySQL 内部关键字冲突。

## 连接异常排查

- Communications link failure The last packet successfully received from the server was 7 milliseconds ago.
  - 原因：
    - 网络问题：
      - 网络不稳定或连接中断。
      - 客户端和服务端之间的网络延迟过高。
    - MySQL 服务器设置
      - MySQL 服务器可能配置了连接超时参数，例如 wait\_timeout 或 interactive\_timeout，导致连接超时被关闭。
    - 防火墙设置
      - 防火墙规则可能阻止了客户端与服务端之间的通信。
    - 连接池设置
      - 连接池中的配置 connection\_pool\_max\_life\_time 可能导致连接被关闭或回收，或者未及时探活
    - 服务器资源问题
      - MySQL 服务器可能资源不足，无法处理新的连接请求。
    - 客户端配置
      - 客户端 JDBC 驱动配置错误，例如 autoReconnect 参数未设置或设置不当。
  - 解决
    - 检查网络连接：
      - 确认客户端和服务端之间的网络连接稳定，避免网络延迟过高。
    - 检查 MySQL 服务器配置：
      - 查看并调整 MySQL 服务器的 wait\_timeout 和 interactive\_timeout 参数，确保它们设置合理。
    - 检查防火墙配置：
      - 确认防火墙规则允许客户端与服务端之间的通信。
    - 调整连接池设置：
      - 检查并调整连接池的配置参数 connection\_pool\_max\_life\_time,确保小于 MySQL 的 wait\_timeout 和 interactive\_timeout 参数并大于执行时间最长的 SQL
    - 监控服务器资源：
      - 监控 MySQL 服务器的资源使用情况，确保有足够的资源处理连接请求。

- 优化客户端配置：
  - 确认 JDBC 驱动的配置参数正确，例如 `autoReconnect=true`，确保连接能在中断后自动重连。
- java.io.EOFException MESSAGE: Can not read response from server. Expected to read 819 bytes, read 686 bytes before connection was unexpectedly lost.
  - 原因：连接被 MySQL Kill 或者 MySQL 宕机
  - 解决：检查 MySQL 是否有主动 kill 连接的机制，或者是否因为查询过大查崩 MySQL

## 常见问题

### 1. 读写 MySQL 的 emoji 表情出现乱码

Doris 进行 MySQL Catalog 查询时，由于 MySQL 之中默认的 utf8 编码为 utf8mb3，无法表示需要 4 字节编码的 emoji 表情。这里需要将 MySQL 的编码修改为 utf8mb4，以支持 4 字节编码。

可全局修改配置项

```
修改mysql目录下的my.ini文件（linux系统为etc目录下的my.cnf文件）
[client]
default-character-set=utf8mb4

[mysql]
设置mysql默认字符集
default-character-set=utf8mb4

[mysqld]
设置mysql字符集服务器
character-set-server=utf8mb4
collation-server=utf8mb4_unicode_ci
init_connect='SET NAMES utf8mb4'

修改对应表与列的类型
ALTER TABLE table_name MODIFY column_name VARCHAR(100) CHARACTER SET utf8mb4 COLLATE
utf8mb4_unicode_ci;
ALTER TABLE table_name CHARSET=utf8mb4;
SET NAMES utf8mb4
```

### 2. 读取 MySQL DATE/DATETIME 类型出现异常

```
ERROR 1105 (HY000): errCode = 2, detailMessage = (10.16.10.6)[INTERNAL_ERROR]UdfRuntimeException: get
next block failed:
CAUSED BY: SQLException: Zero date value prohibited
CAUSED BY: DataReadException: Zero date value prohibited
```

这是因为 JDBC 中对于该非法的 DATE/DATETIME 默认处理为抛出异常，可以通过参数 `zeroDateTimeBehavior` 控制该行为。

可选参数为: `exception, convertToNull, round`, 分别为：异常报错，转为 NULL 值，转为 "0001-01-01 00:00:00";

需要在创建 Catalog 的 `jdbc_url` 把 JDBC 连接串最后增加 `zeroDateTimeBehavior=convertToNull`，如 "`jdbc_url`" = "`jdbc:mysql://127.0.0.1:3306/test?zeroDateTimeBehavior=convertToNull`" 这种情况下，JDBC 会把 0000-00-00 或者 0000-00-00 00:00:00 转换成 null，然后 Doris 会把当前 Catalog 的所有 Date/DateTime 类型的列按照可空类型处理，这样就可以正常读取了。

### 3. 读取 MySQL Catalog 或其他 JDBC Catalog 时，出现加载类失败

如以下异常：

```
failed to load driver class com.mysql.cj.jdbc.driver in either of hikariconfig class loader
```

这是因为在创建 Catalog 时，填写的 driver\_class 不正确，需要正确填写，如上方例子为大小写问题，应填写为 "driver\_class" = "com.mysql.cj.jdbc.Driver"

### 4. 读取 MySQL 出现通信链路异常

如果出现如下报错：

```
ERROR 1105 (HY000): errCode = 2, detailMessage = PoolInitializationException: Failed to initialize pool: Communications link failure

The last packet successfully received from the server was 7 milliseconds ago. The last packet sent successfully to the server was 4 milliseconds ago.
CAUSED BY: CommunicationsException: Communications link failure

The last packet successfully received from the server was 7 milliseconds ago. The last packet sent successfully to the server was 4 milliseconds ago.
CAUSED BY: SSLHandshakeExcepti
```

可查看 be 的 be.out 日志

如果包含以下信息：

```
WARN: Establishing SSL connection without server's identity verification is not recommended.
According to MySQL 5.5.45+, 5.6.26+ and 5.7.6+ requirements SSL connection must be established by default if explicit option isn't set.
For compliance with existing applications not using SSL the verifyServerCertificate property is set to 'false'.
You need either to explicitly disable SSL by setting useSSL=false, or set useSSL=true and provide truststore for server certificate verification.
```

可在创建 Catalog 的 jdbc\_url 把 JDBC 连接串最后增加 ?useSSL=false, 如 "jdbc\_url" = "jdbc:mysql://127.0.0.1:3306/test?useSSL=false"

### 5. 查询 MySQL 大数据量时，如果查询偶尔能够成功，偶尔会报如下错误，且出现该错误时 MySQL 的连接被全部断开，无法连接到 MySQL Server，过段时间后 MySQL 又恢复正常，但是之前的连接都没了：

```
ERROR 1105 (HY000): errCode = 2, detailMessage = [INTERNAL_ERROR]UdfRuntimeException: JDBC executor sql has error:
CAUSED BY: CommunicationsException: Communications link failure
The last packet successfully received from the server was 4,446 milliseconds ago. The last packet sent successfully to the server was 4,446 milliseconds ago.
```

出现上述现象时，可能是 MySQL Server 自身的内存或 CPU 资源被耗尽导致 MySQL 服务不可用，可以尝试增大 MySQL Server 的内存或 CPU 配置。

### 6. 查询 MySQL 的过程中，如果发现和在 MySQL 库的查询结果不一致的情况

首先要先排查下查询字段中是字符串否存在有大小写情况。比如，Table 中有一个字段 c\_1 中有“aaa”和“AAA”两条数据，如果在初始化 MySQL 数据库时未指定区分字符串大小写，那么 MySQL 默认是不区分字符串大小写的，但是在 Doris 中是严格区分大小写的，所以会出现以下情况：

```
MySQL行为：
select count(c_1) from table where c_1 = "aaa"; 未区分字符串大小，所以结果为：2

Doris行为：
select count(c_1) from table where c_1 = "aaa"; 严格区分字符串大小，所以结果为：1
```

如果出现上述现象，那么需要按照需求来调整，方式如下：

在 MySQL 中查询时添加“BINARY”关键字来强制区分大小写：select count(c\_1) from table where BINARY c\_1 = "aaa";

或者在 MySQL 中建表时候指定：CREATE TABLE table (c\_1 VARCHAR(255) CHARACTER SET binary);

或者在初始化 MySQL 数据库时指定校对规则来区分大小写：[mysqld] character-set-server=utf8 collation-server=utf8\_bin [client] default-character-set=utf8 [mysql] default-character-set=utf8

7. 查询 MySQL 的时候，出现长时间卡住没有返回结果，或者卡住很长时间并且 fe.warn.log 中出现大量 write lock 日志，可以尝试在 URL 添加 socketTimeout，例如：

jdbc:mysql://host:port/database?socketTimeout=30000，防止 JDBC 客户端 在被 MySQL 关闭连接后无限等待。

8. 在使用 MySQL Catalog 的过程中发现 FE 的 JVM 内存或 Threads 数持续增长不减少，并可能同时出现 Forward to master connection timed out 报错

打印 FE 线程堆栈 jstack fe\_pid > fe.js，如果出现大量 mysql-cj-abandoned-connection-cleanup 线程，说明是 MySQL JDBC 驱动的问题。

按照如下方式处理：

1. 升级 MySQL JDBC 驱动到 8.0.31 及以上版本
2. 在 FE 和 BE conf 文件的 JAVA\_OPTS 中增加 -Dcom.mysql.cj.disableAbandonedConnectionCleanup=true 参数，禁用 MySQL JDBC 驱动的连接清理功能，并重启集群

**注意：**如果 Doris 的版本在 2.0.13 及以上（2.0 Release），或 2.1.5 及以上（2.1 Release）则无需增加该参数，因为 Doris 已经默认禁用了 MySQL JDBC 驱动的连接清理功能。只需更换 MySQL JDBC 驱动版本即可。但是需要重启 Doris 集群来清理掉之前的 Threads。

# PostgreSQL

Doris JDBC Catalog 支持通过标准 JDBC 接口连接 PostgreSQL 数据库。本文档介绍如何配置 PostgreSQL 数据库连接。

## 使用须知

要连接到 PostgreSQL 数据库，您需要

- PostgreSQL 11.x 或更高版本
- PostgreSQL 数据库的 JDBC 驱动程序，您可以从 [Maven 仓库](#) 下载最新或指定版本的 PostgreSQL JDBC 驱动程序。推荐使用 **PostgreSQL JDBC Driver 42.5.x** 及以上版本。
- Doris 每个 FE 和 BE 节点和 PostgreSQL 服务器之间的网络连接，默认端口为 5432。

## 连接 PostgreSQL

```
CREATE CATALOG postgresql PROPERTIES (
 "type"="jdbc",
 "user"="root",
 "password"="secret",
 "jdbc_url" = "jdbc:postgresql://example.net:5432/postgres",
 "driver_url" = "postgresql-42.5.6.jar",
 "driver_class" = "org.postgresql.Driver"
)
```

### 备注

`jdbc_url` 定义要传递给 PostgreSQL JDBC 驱动程序的连接信息和参数。支持的 URL 的参数可在 [PostgreSQL JDBC 驱动程序文档](#) 中找到。

## 连接安全

如果您使用数据源上安装的全局信任证书配置了 TLS，则可以通过将参数附加到在 `jdbc_url` 属性中设置的 JDBC 连接字符串来启用集群和数据源之间的 TLS。

例如，对于版本 42 的 PostgreSQL JDBC 驱动程序，通过将 `ssl=true` 参数添加到 `jdbc_url` 配置属性中启用 TLS：

```
"jdbc_url"="jdbc:postgresql://example.net:5432/database?ssl=true"
```

有关 TLS 配置选项的更多信息，请参阅 [PostgreSQL JDBC 驱动程序文档](#)。

## 层级映射

映射 PostgreSQL 时，Doris 的一个 Database 对应于 PostgreSQL 中指定 database 下的一个 Schema（如示例中 jdbc\_url 参数中 postgres 下的 schemas）。而 Doris 的 Database 下的 Table 则对应于 PostgreSQL 中，该 Schema 下的 Tables。即映射关系如下：

Doris	PostgreSQL
Catalog	Database
Database	Schema
Table	Table

## 类型映射

### PostgreSQL 到 Doris 类型映射

PostgreSQL Type	Doris Type	Comment
boolean	BOOLEAN	
smallint/int2	SMALLINT	
integer/int4	INT	
bigint/int8	BIGINT	
decimal/numeric	DECIMAL	
real/float4	FLOAT	
double precision	DOUBLE	
smallserial	SMALLINT	
serial	INT	
bigserial	BIGINT	
char	CHAR	
varchar/text	STRING	
timestamp/timestampz	DATETIME	
date	DATE	
json/jsonb	STRING	
time	STRING	
interval	STRING	
point/line/lseg/box/path/polygon/circle	STRING	
cidr/inet/macaddr	STRING	
bit	BOOLEAN/STRING	
uuid	STRING	

PostgreSQL Type	Doris Type	Comment
Other	UNSUPPORTED	

- 无精度 numeric 会被映射为 String 类型，进行数值计算时需要先转换为 DECIMAL 类型，且不支持回写。

- 为了更好的读取与计算性能均衡，Doris 会将 JSON 类型映射为 STRING 类型。
- Doris 不支持 BIT 类型，BIT 类型会在 BIT(1) 时被映射为 BOOLEAN，其他情况下映射为 STRING。
- Doris 不支持 time 类型，TIME 类型会被映射为 STRING。

## 时间戳类型处理

由于 Doris 不支持带时区的时间戳类型，所以在读取 PostgreSQL 的 timestampz 类型时，Doris 会将其映射为 DATETIME 类型，且会在读取时转换成本地时区的时间。

且由于在 JDBC 类型 Catalog 读取数据时，BE 的 Java 部分使用 JVM 时区。JVM 时区默认为 BE 部署机器的时区，这会影响 JDBC 读取数据时的时区转换。

为了确保时区一致性，建议在 be.conf 的 JAVA\_OPTS 中设置 JVM 时区与 Doris session 的 time\_zone 一致。

## 查询优化

### 谓词下推

当执行类似于 where dt = '2022-01-01' 这样的查询时，Doris 能够将这些过滤条件下推到外部数据源，从而直接在数据源层面排除不符合条件的数据，减少了不必要的数据获取和传输。这大大提高了查询性能，同时也降低了对外部数据源的负载。

### 行数限制

如果在查询中带有 limit 关键字，Doris 会将 limit 下推到 PostgreSQL，以减少数据传输量。

### 转义字符

Doris 会在下发到 PostgreSQL 的查询语句中，自动在字段名与表名上加上转义符：(“”), 以避免字段名与表名与 PostgreSQL 内部关键字冲突。

# Oracle

Apache Doris JDBC Catalog 支持通过标准 JDBC 接口连接 Oracle 数据库。本文档介绍如何配置 Oracle 数据库连接。

## 使用须知

要连接到 Oracle 数据库，您需要

- Oracle 19c, 18c, 12c, 11g 或 10g。
- Oracle 数据库的 JDBC 驱动程序，您可以从 [Maven 仓库](#) 下载最新或指定版本的 Oracle JDBC 驱动程序。
- Apache Doris 每个 FE 和 BE 节点和 Oracle 服务器之间的网络连接，默认端口为 1521；如果 Oracle RAC 启用 ONS，还需开通 6200 端口。

## 连接 Oracle

```
CREATE CATALOG oracle PROPERTIES (
 "type"="jdbc",
 "user"="root",
 "password"="secret",
 "jdbc_url" = "jdbc:oracle:thin:@example.net:1521:orcl",
 "driver_url" = "ojdbc8.jar",
 "driver_class" = "oracle.jdbc.driver.OracleDriver"
)
```

### 备注

jdbc\_url 定义要传递给 JDBC 驱动程序的连接信息和参数。使用 Oracle JDBC Thin 驱动程序时，URL 的语法可能会有所不同，具体取决于您的 Oracle 配置。例如，如果您要连接到 Oracle SID 或 Oracle 服务名称，则连接 URL 会有所不同。有关更多信息，请参阅 [Oracle 数据库 JDBC 驱动程序文档](#)。以上示例 URL 连接到名为 orcl 的 Oracle SID。

## 层级映射

映射 Oracle 时，Apache Doris 的一个 Database 对应于 Oracle 中的一个 User。而 Apache Doris 的 Database 下的 Table 则对应于 Oracle 中，该 User 下的有权限访问的 Table。即映射关系如下：

Apache Doris	Oracle
Catalog	Database
Database	User
Table	Table



# 类型映射

## Oracle 到 Apache Doris 类型映射

Oracle Type	Apache Doris Type	Comment
number(p) / number(p,0)	TINYINT/SMALLINT/ INT/BIGINT/LARGEI NT	Doris会根据p的大小来选择对应的类型： p < 3 -> TINYINT; p < 5 -> SMALLINT; p < 10 -> INT; p < 19 -> BIGINT; p > 19 -> LARGEINT
number(p,s), [ if(s>0 && p>s) ]	DECIMAL(p,s)	
number(p,s), [ if(s>0 && p < s) ]	DECIMAL(s,s)	
number(p,s), [ if(s<0) ]	TINYINT/SMALLINT/ INT/BIGINT/LARGEI NT	s<0的情况下, Doris会将p设置为 p+ s , 并进行和number(p) / number(p,0)一样的映射
number		Doris目前不支持未指定p和s的oracle类型
decimal	DECIMAL	
float/real	DOUBLE	
DATE	DATETIME	
TIMESTAMP	DATETIME	
CHAR/NCHAR	STRING	
VARCHAR2/NVAR CHAR2	STRING	
LONG/ RAW/ LONG RAW/ INTERVAL	STRING	
Other	UNSUPPORTED	

# 查询优化

## 谓词下推

1. 当执行类似于 where dt = '2022-01-01' 这样的查询时, Apache Doris 能够将这些过滤条件下推到外部数据源, 从而直接在数据源层面排除不符合条件的数据, 减少了不必要的获取和传输。这大大提高了查询性能, 同时也降低了对外部数据源的负载。
2. 当变量 enable\_ext\_func\_pred\_pushdown 设置为true, 会将 where 之后的函数条件也下推到外部数据源。

目前支持下推到 Oracle 的函数有：

Function
NVL

## 行数限制

如果在查询中带有 limit 关键字，Apache Doris 会将 limit 转义为 Oracle 的 rownum 语法，以减少数据传输量。

## 转义字符

Apache Doris 会在下发到 Oracle 的查询语句中，自动在字段名与表名上加上转义符：(“”), 以避免字段名与表名与 Oracle 内部关键字冲突。

## 常见问题

1. 创建或查询 Oracle Catalog 时出现 ORA-01950: configuration failed

在 be.conf 的 JAVA\_OPTS 增加 -Doracle.jdbc.fanEnabled=false 并且升级driver到  
<https://repo1.maven.org/maven2/com/oracle/database/jdbc/ojdbc8/19.23.0.0/ojdbc8-19.23.0.0.jar>

2. 创建或查询 Oracle Catalog 时出现 Non supported character set (add orai18n.jar in your classpath): ZHS16GBK 异常

下载 [orai18n.jar](#) 并放到 每个 FE 和 BE 的目录下的 custom\_lib/ 目录下（如不存在，手动创建即可）并重启每个 FE 和 BE。

# SQL Server

Doris JDBC Catalog 支持通过标准 JDBC 接口连接 SQL Server 数据库。本文档介绍如何配置 SQL Server 数据库连接。

## 使用须知

要连接到 SQL Server 数据库，您需要

- SQL Server 2012 或更高版本，或 Azure SQL 数据库。
- SQL Server 数据库的 JDBC 驱动程序，您可以从 [Maven 仓库](#) 下载最新或指定版本的 SQL Server JDBC 驱动程序。**推荐使用 SQL Server JDBC Driver 11.2.x 及以上版本。**
- Doris 每个 FE 和 BE 节点和 SQL Server 服务器之间的网络连接，默认端口为 1433。

## 连接 SQL Server

```
CREATE CATALOG sqlserver PROPERTIES (
 "type"="jdbc",
 "user"="root",
 "password"="secret",
 "jdbc_url" = "jdbc:sqlserver://<host>:<port>;databaseName=<databaseName>;encrypt=false",
 "driver_url" = "mssql-jdbc-11.2.3.jre8.jar",
 "driver_class" = "com.microsoft.sqlserver.jdbc.SQLServerDriver"
)
```

### 备注

jdbc\_url 定义要传递给 SQL Server JDBC 驱动程序的连接信息和参数。[SQL Server JDBC 驱动程序文档](#)中提供了 URL 支持的参数。

## 连接安全

JDBC 驱动程序以及连接器自动使用传输层安全性 (TLS) 加密和证书验证。这需要在 SQL Server 数据库主机上配置合适的 TLS 证书。

如果您没有建立必要的配置，您可以使用 encrypt 属性禁用连接字符串中的加密：

```
"jdbc_url"="jdbc:sqlserver://<host>:<port>;databaseName=<databaseName>;encrypt=false"
```

[SQL Server JDBC 驱动程序文档的 TLS 部分](#)详细介绍了 trustServerCertificate、hostNameInCertificate、trustStore 和 trustStorePassword 等其他参数。

## 层级映射

映射 SQLServer 时，Doris 的一个 Database 对应于 SQL Server 中指定 Database（jdbc\_url 参数中的 <databaseName>）下的一个 Schema。而 Doris 的 Database 下的 Table 则对应于 SQLServer 中，Schema 下的 Tables。即映射关系如下：

Doris	SQLServer
Catalog	Database
Database	Schema
Table	Table

## 类型映射

### SQL Server 到 Doris 类型映射

SQL Server Type	Doris Type	Comment
bit	BOOLEAN	
tinyint	SMALLINT	SQLServer 的 tinyint 是无符号数，所以映射为 Doris 的 SMALLINT
smallint	SMALLINT	
int	INT	
bigint	BIGINT	
real	FLOAT	
float	DOUBLE	
money	DECIMAL(19, 4)	
smallmoney	DECIMAL(10, 4)	
decimal/numeric	DECIMAL	
date	DATE	
datetime/datetime2/smalldatetime	DATETIMEV2	
char/varchar/text/nchar/nvarchar/ntext	STRING	
time/datetimeoffset	STRING	
timestamp	STRING	读取二进制数据的十六进制显示，无实际意义
Other	UNSUPPORT ED	

## 查询优化

### 谓词下推

当执行类似于 `where dt = '2022-01-01'` 这样的查询时，Doris 能够将这些过滤条件下推到外部数据源，从而直接在数据源层面排除不符合条件的数据，减少了不必要的获取和传输。这大大提高了查询性能，同时也降低了对外部数据源的负载。

### 行数限制

如果在查询中带有 `limit` 关键字，Doris 会将 `limit` 转义为 SQL Server 的 `TOP` 语法，以减少数据传输量。

### 转义字符

Doris 会在下发到 SQL Server 的查询语句中，自动在字段名与表名上加上转义符：(`[]`)，以避免字段名与表名与 SQL Server 内部关键字冲突。

## 常见问题

### 1. 连接 SQL Server 出现证书认证异常

```
SQLServerException: The driver could not establish a secure connection to SQL Server by using Secure
Sockets Layer (SSL) encryption.
Error: "sun.security.validator.ValidatorException: PKIX path building failed:
sun.security.provider.certpath.SunCertPathBuilderException:
unable to find valid certification path to requested target". ClientConnectionId:a92f3817-e8e6-4311-
bc21-7c66
```

可在创建 Catalog 的 `jdbc_url` 把 JDBC 连接串最后增加 `encrypt=false`，如 `"jdbc_url" = "jdbc:sqlserver://127.0.0.1:1433;DataBaseName=doris_test;encrypt=false"`

### 2. 连接 SQL Server 出现 TLS 异常

```
The server selected protocol version TLS10 is not accepted by client preferences [TLS13, TLS12]
```

这是因为 SQL Server 与 JDBC 客户端之间的 TLS 协议版本不匹配。连接的 SQL Server 仅支持 TLS 1.0，而 JDBC 客户端所在 JAVA 环境默认禁用了 TLS 1.0。

解决方式如下：

1. 在 SQL Server 上启用 TLS 1.2。参考：[SQL Server TLS 1.2 支持](#)
2. 启用 JDK 的 TLS 1.0。

```
vim ${JAVA_HOME}/lib/security/java.security
#找到这段
jdk.tls.disabledAlgorithms=SSLv3, TLSv1, TLSv1.1, RC4, DES, MD5withRSA, \
DH keySize < 1024, EC keySize < 224, 3DES_EDE_CBC, anon, NULL, \
include jdk.disabled.namedCurves

#删掉其中的TLSv1, TLSv1.1，改成下面这样即可
jdk.tls.disabledAlgorithms=SSLv3, RC4, DES, MD5withRSA, \
```

```
DH keySize < 1024, EC keySize < 224, anon, NULL, \
include jdk.disabled.namedCurves
```

# ClickHouse

Doris JDBC Catalog 支持通过标准 JDBC 接口连接 ClickHouse 数据库。本文档介绍如何配置 ClickHouse 数据库连接。

## 使用须知

要连接到 ClickHouse 数据库，您需要

- ClickHouse 23.x 或更高版本(低于此版本未经充分测试)。
- ClickHouse 数据库的 JDBC 驱动程序，您可以从 [Maven 仓库](#) 下载最新或指定版本的 ClickHouse JDBC 驱动程序。**推荐使用 ClickHouse JDBC Driver 0.4.6 版本。**
- Doris 每个 FE 和 BE 节点和 ClickHouse 服务器之间的网络连接，默认端口为 8123。

## 连接 ClickHouse

```
CREATE CATALOG clickhouse PROPERTIES (
 "type"="jdbc",
 "user"="default",
 "password"="password",
 "jdbc_url" = "jdbc:clickhouse://example.net:8123/",
 "driver_url" = "clickhouse-jdbc-0.4.6-all.jar",
 "driver_class" = "com.clickhouse.jdbc.ClickHouseDriver"
)
```

### 备注

`jdbc_url` 定义要传递给 ClickHouse JDBC 驱动程序的连接信息和参数。支持的 URL 的参数可在 [ClickHouse JDBC 驱动配置](#) 中找到。

## 连接安全

如果您使用数据源上安装的全局信任证书配置了 TLS，则可以通过将参数附加到在 `jdbc_url` 属性中设置的 JDBC 连接字符串来启用集群和数据源之间的 TLS。

例如，通过将 `ssl=true` 参数添加到 `jdbc_url` 配置属性来启用 TLS：

```
"jdbc_url"="jdbc:clickhouse://example.net:8123/db?ssl=true"
```

有关 TLS 配置选项的更多信息，请参阅 [Clickhouse JDBC 驱动程序文档 SSL 配置部分](#)

## 层级映射

映射 ClickHouse 时，Doris 的一个 Database 对应于 ClickHouse 中的一个 Database。而 Doris 的 Database 下的 Table 则对应于 ClickHouse 中，该 Database 下的 Tables。即映射关系如下：

Doris	ClickHouse
Catalog	ClickHouse Server
Database	Database
Table	Table

## 类型映射

### ClickHouse 到 Doris 类型映射

ClickHouse Type	Doris Type	Comment
Bool	BOOLEAN	
String	STRING	
Date/Date32	DATE	
DateTime/DateTime64	DATETIME	
Float32	FLOAT	
Float64	DOUBLE	
Int8	TINYINT	
Int16/UInt8	SMALLINT	Doris 没有 UNSIGNED 数据类型，所以扩大一个数量级
Int32/UInt16	INT	Doris 没有 UNSIGNED 数据类型，所以扩大一个数量级
Int64/UInt32	BIGINT	Doris 没有 UNSIGNED 数据类型，所以扩大一个数量级
Int128/UInt64	LARGEINT	Doris 没有 UNSIGNED 数据类型，所以扩大一个数量级
Int256/UInt128/UInt256	STRING	Doris 没有这个数量级的数据类型，采用 STRING 处理
DECIMAL	DECIMALV3/STRING	将根据 DECIMAL 字段的 (precision, scale) 选择用何种类型
Enum/IPv4/IPv6/UUID	STRING	
Array	ARRAY	Array 内部类型适配逻辑参考上述类型，不支持嵌套 Array
Other	UNSUPPORTED	

## 查询优化

### 谓词下推

1. 当执行类似于 where dt = '2022-01-01' 这样的查询时，Doris 能够将这些过滤条件下推到外部数据源，从而直接在数据源层面排除不符合条件的数据，减少了不必要的数据获取和传输。这大大提高了查询性能，同时也降低了对外部数据源的负载。



2. 当 FE conf enable\_func\_pushdown 设置为 true，会将 where 之后的函数条件也下推到外部数据源。

目前支持下推到 ClickHouse 的函数有：

Function
FROM_UNIXTIME
UNIX_TIMESTAMP

## 行数限制

如果在查询中带有 limit 关键字，Doris 会将 limit 下推到 ClickHouse，以减少数据传输量。

## 转义字符

Doris 会在下发到 ClickHouse 的查询语句中，自动在字段名与表名上加上转义符：(``)，以避免字段名与表名与 ClickHouse 内部关键字冲突。

## 常见问题

1. 通过 ClickHouse Catalog 读取 Clickhouse 数据出现NoClassDefFoundError：  
net/jpountz/lz4/LZ4Factory 错误信息

可以先下载[lz4-1.3.0.jar](#)包并放到每个 FE 和 BE 的目录下的 custom\_lib/ 目录下（如不存在，手动创建即可）。

# SAP HANA

Doris JDBC Catalog 支持通过标准 JDBC 接口连接 SAP HANA 数据库。本文档介绍如何配置 SAP HANA 数据库连接。

## 使用须知

要连接到 SAP HANA 数据库，您需要

- SAP HANA 2.0 或更高版本。
- SAP HANA 数据库的 JDBC 驱动程序，您可以从 [Maven 仓库](#) 下载最新或指定版本的 SAP HANA JDBC 驱动程序。**推荐使用 ngdbc 2.4.51 以上的版本。**
- Doris 每个 FE 和 BE 节点和 SAP HANA 服务器之间的网络连接，默认端口为 30015。

## 连接 SAP HANA

```
CREATE CATALOG saphana PROPERTIES (
 "type"="jdbc",
 "user"="USERNAME",
 "password"="PASSWORD",
 "jdbc_url" = "jdbc:sap://Hostname:Port/?optionalparameters",
 "driver_url" = "ngdbc-2.4.51.jar",
 "driver_class" = "com.sap.db.jdbc.Driver"
)
```

### 备注

有关 SAP HANA JDBC 驱动程序支持的 JDBC URL 格式和参数的更多信息，请参阅 [SAP HANA](#)。

## 层级映射

映射 SAP HANA 时，Doris 的 Database 对应于 SAP HANA 中指定 DataBase（jdbc\_url 参数中的“DATABASE”）下的一个 Schema。而 Doris 的 Database 下的 Table 则对应于 SAP HANA 中 Schema 下的 Tables。即映射关系如下：

Doris	SAP HANA
Catalog	Database
Database	Schema
Table	Table

## 类型映射

### SAP HANA 到 Doris 类型映射

SAP HANA Type	Doris Type	Comment
BOOLEAN	BOOLEAN	
TINYINT	TINYINT	
SMALLINT	SMALLINT	
INTERGER	INT	
BIGINT	BIGINT	
SMALLDECIMAL	DECIMAL	
DECIMAL	DECIMAL/STRING	将根据Doris DECIMAL字段的（precision, scale）选择用何种类型
REAL	FLOAT	
DOUBLE	DOUBLE	
DATE	DATE	
TIME	STRING	
TIMESTAMP	DATETIME	
SECONDDATE	DATETIME	
VARCHAR	STRING	
NVARCHAR	STRING	
ALPHANUM	STRING	
SHORTTEXT	STRING	
CHAR	CHAR	
NCHAR	CHAR	

## 查询优化

### 谓词下推

当执行类似于 `where dt = '2022-01-01'` 这样的查询时，Doris 能够将这些过滤条件下推到外部数据源，从而直接在数据源层面排除不符合条件的数据，减少了不必要的数据获取和传输。这大大提高了查询性能，同时也降低了对外部数据源的负载。

### 行数限制

如果在查询中带有 `limit` 关键字，Doris 会将 `limit` 下推到 SAP HANA 数据库，以减少数据传输量。

## 转义字符

Doris 会在下发到 SAP HANA 的查询语句中，自动在字段名与表名上加上转义符：(``)，以避免字段名与表名与 SAP HANA 内部关键字冲突。

# OceanBase

Doris JDBC Catalog 支持通过标准 JDBC 接口连接 OceanBase 数据库。本文档介绍如何配置 OceanBase 数据库连接。

## 使用须知

要连接到 OceanBase 数据库，您需要

- OceanBase 3.1.0 或更高版本
- OceanBase 数据库的 JDBC 驱动程序，您可以从 [Maven 仓库](#) 下载最新或指定版本的 OceanBase JDBC 驱动程序。**推荐使用 OceanBase Connector/J 2.4.8 或以上版本。**
- Doris 每个 FE 和 BE 节点和 OceanBase 服务器之间的网络连接。

## 连接 OceanBase

```
CREATE CATALOG oceanbase PROPERTIES (
 "type"="jdbc",
 "user"="root",
 "password"="password",
 "jdbc_url" = "jdbc:oceanbase://host:port/db",
 "driver_url" = "oceanbase-client-2.4.8.jar",
 "driver_class" = "com.oceanbase.jdbc.Driver"
)
```

### 备注

jdbc\_url 定义要传递给 OceanBase JDBC 驱动程序的连接信息和参数。支持的 URL 的参数可在 [OceanBase JDBC 驱动配置](#) 中找到。

## 模式兼容

Doris 会在创建 OceanBase Catalog 时，自动识别 OceanBase 处于 MySQL 或 Oracle 模式下，以便正确解析元数据。

不同模式下的层级映射、类型映射、查询优化，与 MySQL 或 Oracle 数据库的 Catalog 处理方式相同，可参考文档

- [MySQL Catalog](#)
- [Oracle Catalog](#)

# Elasticsearch

Elasticsearch Catalog 除了支持自动映射 ES 元数据外，也可以利用 Doris 的分布式查询规划能力和 ES(Elasticsearch) 的全文检索能力相结合，提供更完善的 OLAP 分析场景解决方案：

- 1. ES 中的多 index 分布式 Join 查询。
- 2. Doris 和 ES 中的表联合查询，更复杂的全文检索过滤。

## 使用限制

支持 Elasticsearch 5.x 及以上版本。

## 创建 Catalog

```
CREATE CATALOG es PROPERTIES (
 "type"="es",
 "hosts"="http://127.0.0.1:9200"
);
```

因为 Elasticsearch 没有 Database 的概念，所以连接 ES 后，会自动生成一个唯一的 Database：default\_db。并且在通过 SWITCH 命令切换到 ES Catalog 后，会自动切换到 default\_db。无需再执行 USE default\_db 命令。

## 参数说明

参数	是否必须	默认值	说明
hosts	是		ES 地址，可以是一个或多个，也可以是 ES 的负载均衡地址
user	否	空	ES 用户名
password	否	空	对应用户的密码信息
doc_value_scan	否	true	是否开启通过 ES/Lucene 列式存储获取查询字段的值
keyword_sniff	否	true	是否对 ES 中字符串分词类型 text.fields 进行探测，通过 keyword 进行查询。设置为 false 会按照分词后的内容匹配
nodes_discovery	否	true	是否开启 ES 节点发现，默认为 true，在网络隔离环境下设置为 false，只连接指定节点
ssl	否	false	ES 是否开启 https 访问模式，目前在 fe/be 实现方式为信任所有
mapping_es_id	否	false	是否映射 ES 索引中的 _id 字段
like_push_down	否	true	是否将 like 转化为 wildchard 下推到 ES，会增加 ES cpu 消耗
include_hidden_index	否	false	是否包含隐藏的索引，默认为 false。

1. 认证方式目前仅支持 **Http Basic** 认证，并且需要确保该用户有访问： `/_cluster/state/`、`_nodes/http` 等路径和 **Index** 的读权限；集群未开启安全认证，用户名和密码不需要设置。
2. 5.x 和 6.x 中一个 Index 中的多个 type 默认取第一个。

## 列类型映射

ES Type	Doris Type	Comment
null	null	
boolean	boolean	
byte	tinyint	
short	smallint	
integer	int	
long	bigint	
unsigned_long	largeint	
float	float	
half_float	float	
double	double	
scaled_float	double	
date	date	仅支持 default/yyyy-MM-dd HH:mm:ss/yyyy-MM-dd/epoch_millis 格式
keyword	string	
text	string	
ip	string	
constant_keyword	string	
wildcard	string	
nested	json	
object	json	
other	unsupported	

## Array 类型

Elasticsearch 没有明确的数组类型，但是它的某个字段可以含有 [0 个或多个值](#)。

为了表示一个字段是数组类型，可以在索引映射的 [\\_meta](#) 部分添加特定的doris结构注释。

对于 Elasticsearch 6.x 及之前版本，请参考 [\\_meta](#)。

举例说明，假设有一个索引 doc 包含以下的数据结构：

```
{
 "array_int_field": [1, 2, 3, 4],
 "array_string_field": ["doris", "is", "the", "best"],
 "id_field": "id-xxx-xxx",
 "timestamp_field": "2022-11-12T12:08:56Z",
 "array_object_field": [
 {
 "name": "xxx",
 "age": 18
 }
]
}
```

该结构的数组字段可以通过使用以下命令将字段属性定义添加到目标索引映射的`_meta.doris`属性来定义。

```
ES 7.x and above
curl -X PUT "localhost:9200/doc/_mapping?pretty" -H 'Content-Type:application/json' -d '
{
 "_meta": {
 "doris":{
 "array_fields":[
 "array_int_field",
 "array_string_field",
 "array_object_field"
]
 }
 }
}'

ES 6.x and before
curl -X PUT "localhost:9200/doc/_mapping/_doc?pretty" -H 'Content-Type: application/json' -d '
{
 "_meta": {
 "doris":{
 "array_fields":[
 "array_int_field",
 "array_string_field",
 "array_object_field"
]
 }
 }
}'
```

`array_fields`：用来表示是数组类型的字段。

## 最佳实践

### 过滤条件下推

ES Catalog 支持过滤条件的下推：过滤条件下推给 ES，这样只有真正满足条件的数据才会被返回，能够显著的提高查询性能和降低 Doris 和 Elasticsearch 的 CPU、memory、IO 使用量

下面的操作符 (Operators) 会被优化成如下 ES Query:

SQL syntax	ES 5.x+ syntax
=	term query



SQL syntax	ES 5.x+ syntax
in	terms query
> , < , >= , <=	range query
and	bool.filter
or	bool.should
not	bool.must_not
not in	bool.must_not + terms query
is_not_null	exists query
is_null	bool.must_not + exists query
esquery	ES 原生 json 形式的 QueryDSL

## 启用列式扫描优化查询速度 (enable\_docvalue\_scan=true)

设置 "enable\_docvalue\_scan" = "true"

开启后 Doris 从 ES 中获取数据会遵循以下两个原则：

- **尽力而为**: 自动探测要读取的字段是否开启列式存储 (doc\_value: true), 如果获取的字段全部有列存, Doris 会从列式存储中获取所有字段的值
- **自动降级**: 如果要获取的字段只要有一个字段没有列存, 所有字段的值都会从行存 \_source 中解析获取

## 优势

默认情况下, Doris On ES 会从行存也就是 \_source 中获取所需的所有列, \_source 的存储采用的行式+json 的形式存储, 在批量读取性能上要劣于列式存储, 尤其在只需要少数列的情况下尤为明显, 只获取少数列的情况下, docvalue 的性能大约是 \_source 性能的十几倍

## 注意

1. text 类型的字段在 ES 中是没有列式存储, 因此如果要获取的字段值有 text 类型字段会自动降级为从 \_source 中获取
2. 在获取的字段数量过多的情况下 (>= 25), 从 docvalue 中获取字段值的性能会和从 \_source 中获取字段值基本一样
3. keyword 类型字段由于 [ignore\\_above](#) 参数的限制, 对于超过该限制的长文本字段会忽略, 所以可能会出现结果为空的情况。此时需要关闭 enable\_docvalue\_scan, 从 \_source 中获取结果。

## 探测 Keyword 类型字段

设置 "enable\_keyword\_sniff" = "true"

在 ES 中可以不建立 index 直接进行数据导入, 这时候 ES 会自动创建一个新的索引, 针对字符串类型的字段 ES 会创建一个既有 text 类型的字段又有 keyword 类型的字段, 这就是 ES 的 multi fields 特性, mapping 如下:

```

"k4": {
 "type": "text",
 "fields": {
 "keyword": {
 "type": "keyword",
 "ignore_above": 256
 }
 }
}

```

对 k4 进行条件过滤时比如=, Doris On ES 会将查询转换为 ES 的 TermQuery

SQL 过滤条件:

```
k4 = "Doris On ES"
```

转换成 ES 的 query DSL 为:

```

"term" : {
 "k4": "Doris On ES"
}

```

因为 k4 的第一字段类型为text, 在数据导入的时候就会根据 k4 设置的分词器 (如果没有设置, 就是 standard 分词器) 进行分词处理得到 doris、on、es 三个 Term, 如下 ES analyze API 分析:

```

POST /_analyze
{
 "analyzer": "standard",
 "text": "Doris On ES"
}

```

分词的结果是:

```

{
 "tokens": [
 {
 "token": "doris",
 "start_offset": 0,
 "end_offset": 5,
 "type": "<ALPHANUM>",
 "position": 0
 },
 {
 "token": "on",
 "start_offset": 6,
 "end_offset": 8,
 "type": "<ALPHANUM>",
 "position": 1
 },
 {
 "token": "es",
 "start_offset": 9,
 "end_offset": 11,
 "type": "<ALPHANUM>",
 "position": 2
 }
]
}

```

```
]
}
```

查询时使用的是：

```
"term" : {
 "k4": "Doris On ES"
}
```

Doris On ES这个 term 匹配不到词典中的任何 term，不会返回任何结果，而启用enable\_keyword\_sniff:true会自动将k4 = "Doris On ES"转换成k4.keyword = "Doris On ES"来完全匹配 SQL 语义，转换后的 ES query DSL 为：

```
"term" : {
 "k4.keyword": "Doris On ES"
}
```

k4.keyword 的类型是keyword，数据写入 ES 中是一个完整的 term，所以可以匹配

## 开启节点自动发现，默认为 true(nodes\_discovery=true)

设置 "nodes\_discovery" = "true"

当配置为 true 时，Doris 将从 ES 找到所有可用的相关数据节点 (在上面分配的分片)。如果 ES 数据节点的地址没有被 Doris BE 访问，则设置为 false。ES 集群部署在与公共 Internet 隔离的内网，用户通过代理访问

## ES 集群是否开启 HTTPS 访问模式

设置 "ssl" = "true"

目前会 FE/BE 实现方式为信任所有，这是临时解决方案，后续会使用真实的用户配置证书

## 查询用法

完成在 Doris 中建立 ES 外表后，除了无法使用 Doris 中的数据模型 (Rollup、预聚合、物化视图等) 外并无区别

### 基本查询

```
select * from es_table where k1 > 1000 and k3 ='term' or k4 like 'fu*z_'
```

## 扩展的 esquery(field, QueryDSL)

通过esquery(field, QueryDSL)函数将一些无法用 sql 表述的 query 如 match\_phrase、geoshape 等下推给 ES 进行过滤处理，esquery的第一个列名参数用于关联index，第二个参数是 ES 的基本Query DSL的 json 表述，使用花括号{}包含，json 的root key有且只能有一个，如 match\_phrase、geo\_shape、bool 等

match\_phrase 查询：

```
select * from es_table where esquery(k4, '{
 "match_phrase": {
 "k4": "doris on es"
 }
}
```

```
}
}');
```

geo 相关查询:

```
select * from es_table where esquery(k4, '{
 "geo_shape": {
 "location": {
 "shape": {
 "type": "envelope",
 "coordinates": [
 [
 13,
 53
],
 [
 14,
 52
]
]
 },
 "relation": "within"
 }
 }
}');
```

bool 查询:

```
select * from es_table where esquery(k4, '{
 "bool": {
 "must": [
 {
 "terms": {
 "k1": [
 11,
 12
]
 }
 },
 {
 "terms": {
 "k2": [
 100
]
 }
 }
]
 }
}');
```

## 时间类型字段使用建议

仅 ES 外表适用, ES Catalog 中自动映射日期类型为 **Date** 或 **Datetime**

在 ES 中, 时间类型的字段使用十分灵活, 但是在 ES 外表中如果对时间类型字段的类型设置不当, 则会造成过滤条件无法下推

创建索引时对时间类型格式的设置做最大程度的格式兼容：

```
"dt": {
 "type": "date",
 "format": "yyyy-MM-dd HH:mm:ss||yyyy-MM-dd||epoch_millis"
}
```

在 Doris 中建立该字段时建议设置为date或datetime,也可以设置为varchar类型，使用如下 SQL 语句都可以直接将过滤条件下推至 ES：

```
select * from doe where k2 > '2020-06-21';

select * from doe where k2 < '2020-06-21 12:00:00';

select * from doe where k2 < 1593497011;

select * from doe where k2 < now();

select * from doe where k2 < date_format(now(), '%Y-%m-%d');
```

注意：

- 在 ES 中如果不对时间类型的字段设置format, 默认的时间类型字段格式为

```
strict_date_optional_time||epoch_millis
```

- 导入到 ES 的日期字段如果是时间戳需要转换成ms, ES 内部处理时间戳都是按照ms进行处理的，否则 ES 外表会出现显示错误

## 获取 ES 元数据字段 ID

导入文档在不指定 \_id 的情况下，ES 会给每个文档分配一个全局唯一的 \_id 即主键，用户也可以在导入时为文档指定一个含有特殊业务意义的 \_id;

如果需要在 ES 外表中获取该字段值，建表时可以增加类型为varchar的\_id字段：

```
CREATE EXTERNAL TABLE `doe` (
 `_id` varchar COMMENT "",
 `city` varchar COMMENT ""
) ENGINE=ELASTICSEARCH
PROPERTIES (
 "hosts" = "http://127.0.0.1:8200",
 "user" = "root",
 "password" = "root",
 "index" = "doe"
}
```

如果需要在 ES Catalog 中获取该字段值，请设置 "mapping\_es\_id" = "true"

注意：

- \_id 字段的过滤条件仅支持=和in两种
- \_id 字段必须为 varchar 类型

## 获取全局有序的查询结果

在相关性排序、优先展示重要内容等场景中 ES 查询结果按照 score 来排序非常有用。Doris 查询 ES 为了充分利用 MPP 的架构优势，是按照 ES 索引的 shard 的分布情况来拉取数据。

为了得到全局有序的排序结果，需要对 ES 进行单点查询。可以通过 session 变量 `enable_es_parallel_scroll`（默认为 true）来控制。

当设置 `enable_es_parallel_scroll=false` 时，Doris 将会向 ES 集群发送不带 `shard_preference` 和 `sort` 信息的 `scroll` 查询，从而得到全局有序的结果。

**注意：** 在查询结果集较大时，谨慎使用。

## 修改 scroll 请求的 batch 大小


scroll 请求的 batch 默认为 4064。可以通过 session 变量 `batch_size` 来修改。


## 常见问题

- 1. 是否支持 X-Pack 认证的 ES 集群  
支持所有使用 HTTP Basic 认证方式的 ES 集群
- 2. 一些查询比请求 ES 慢很多  
是，比如 `_count` 相关的 query 等，ES 内部会直接读取满足条件的文档个数相关的元数据，不需要对真实的数据进行过滤
- 3. 聚合操作是否可以下推  
目前 Doris On ES 不支持聚合操作如 `sum`, `avg`, `min/max` 等下推，计算方式是批量流式的从 ES 获取所有满足条件的文档，然后在 Doris 中进行计算

## 附录

### Doris 查询 ES 原理





1. FE 会请求建表指定的主机，获取所有节点的 HTTP 端口信息以及 index 的 shard 分布信息等，如果请求失败会顺序遍历 host 列表直至成功或完全失败
2. 查询时会根据 FE 得到的一些节点信息和 index 的元数据信息，生成查询计划并发给对应的 BE 节点
3. BE 节点会根据就近原则即优先请求本地部署的 ES 节点，BE 通过 HTTP Scroll 方式流式的从 ES index 的每个分片中并发的从 \_source 或 docvalue 中获取数据
4. Doris 计算完结果后，返回给用户

# MaxCompute

MaxCompute 是阿里云上的企业级 SaaS（Software as a Service）模式云数据仓库。

## 什么是 MaxCompute

## 连接 MaxCompute

```
CREATE CATALOG mc PROPERTIES (
 "type" = "max_compute",
 "mc.region" = "cn-beijing",
 "mc.default.project" = "your-project",
 "mc.access_key" = "ak",
 "mc.secret_key" = "sk"
);
```

- mc.region: MaxCompute 开通的地域。可以从 Endpoint 中找到对应的 Region，参阅[Endpoints](#)。
- mc.default.project: MaxCompute 项目。可以在[MaxCompute 项目列表](#)中创建和管理。
- mc.access\_key: AccessKey。可以在 [阿里云控制台](#) 中创建和管理。
- mc.secret\_key: SecretKey。可以在 [阿里云控制台](#) 中创建和管理。
- mc.public\_access: 当配置了"mc.public\_access"="true"，可以开启公网访问，建议测试时使用。

## 限额

连接 MaxCompute 时，按量付费的 Quota 查询并发和使用量有限，如需增加资源，请参照 MaxCompute 文档。参见[配额管理](#)。

## 列类型映射

和 Hive Catalog 一致，可参阅 [Hive Catalog](#) 中 [列类型映射](#) 一节。

## 自定义服务地址

默认情况下，MaxCompute Catalog 根据 region 去默认生成公网的 endpoint。

除了默认的 endpoint 地址外，MaxCompute Catalog 也支持在属性中自定义服务地址。

使用以下两个属性：\*mc.odps\_endpoint: MaxCompute Endpoint。

- mc.tunnel\_endpoint: Tunnel Endpoint，MaxCompute Catalog 使用 Tunnel SDK 获取数据。

MaxCompute Endpoint 和 Tunnel Endpoint 的配置请参见[各地域及不同网络连接方式下的 Endpoint](#)



示例：

```
CREATE CATALOG mc PROPERTIES (
 "type" = "max_compute",
 "mc.region" = "cn-beijing",
 "mc.default.project" = "your-project",
 "mc.access_key" = "ak",
 "mc.secret_key" = "sk"
 "mc.odps_endpoint" = "http://service.cn-beijing.maxcompute.aliyun-inc.com/api",
 "mc.tunnel_endpoint" = "http://dt.cn-beijing.maxcompute.aliyun-inc.com"
);
```

# 分析 S3/HDFS 上的文件

通过 Table Value Function 功能，Doris 可以直接将对象存储或 HDFS 上的文件作为 Table 进行查询分析。并且支持自动的列类型推断。

\*\*\*\*使用方式\*\*\*\*

更多使用方式可参阅 Table Value Function 文档：

- [S3](#)：支持 S3 兼容的对象存储上的文件分析。
- [HDFS](#)：支持 HDFS 上的文件分析。

这里我们通过 S3 Table Value Function 举例说明如何进行文件分析。

## 自动推断文件列类型

```
> DESC FUNCTION s3 (
 "URI" = "http://127.0.0.1:9312/test2/test.snappy.parquet",
 "s3.access_key"= "ak",
 "s3.secret_key" = "sk",
 "format" = "parquet",
 "use_path_style"="true"
);
```

Field	Type	Null	Key	Default	Extra
p_partkey	INT	Yes	false	NULL	NONE
p_name	TEXT	Yes	false	NULL	NONE
p_mfgr	TEXT	Yes	false	NULL	NONE
p_brand	TEXT	Yes	false	NULL	NONE
p_type	TEXT	Yes	false	NULL	NONE
p_size	INT	Yes	false	NULL	NONE
p_container	TEXT	Yes	false	NULL	NONE
p_retailprice	DECIMAL(9,0)	Yes	false	NULL	NONE
p_comment	TEXT	Yes	false	NULL	NONE

这里我们定义了一个 S3 Table Value Function：

```
s3(
 "URI" = "http://127.0.0.1:9312/test2/test.snappy.parquet",
 "s3.access_key"= "ak",
 "s3.secret_key" = "sk",
 "format" = "parquet",
 "use_path_style"="true")
```

其中指定了文件的路径、连接信息、认证信息等。

之后，通过 DESC FUNCTION 语法可以查看这个文件的 Schema。

可以看到，对于 Parquet 文件，Doris 会根据文件内的元信息自动推断列类型。

目前支持对 Parquet、ORC、CSV、JSON 格式进行分析和列类型推断。

CSV Schema

在默认情况下，对 CSV 格式文件，所有列类型均为 String。可以通过 csv\_schema 属性单独指定列名和列类型。Doris 会使用指定的列类型进行文件读取。格式如下：

name1:type1;name2:type2;...

对于格式不匹配的列（比如文件中为字符串，用户定义为 int），或缺失列（比如文件中有 4 列，用户定义了 5 列），则这些列将返回 null。

当前支持的列类型为：

名称	映射类型
tinyint	tinyint
smallint	smallint
int	int
bigint	bigint
largeint	largeint
float	float
double	double
decimal(p,s)	decimalv3(p,s)
date	datev2
datetime	datetimev2
char	string
varchar	string
string	string
boolean	boolean

示例：

```
s3 (
 "URI" = "https://bucket1/inventory.dat",
 "s3.access_key"= "ak",
 "s3.secret_key" = "sk",
 "format" = "csv",
 "column_separator" = "|",
 "csv_schema" = "k1:int;k2:int;k3:int;k4:decimal(38,10)",
 "use_path_style"="true"
)
```

# 查询分析

你可以使用任意的 SQL 语句对这个文件进行分析

```
SELECT * FROM s3(
 "URI" = "http://127.0.0.1:9312/test2/test.snappy.parquet",
 "s3.access_key"= "ak",
 "s3.secret_key" = "sk",
 "format" = "parquet",
 "use_path_style"="true")
LIMIT 5;
```

p_partkey	p_name	p_mfgr	p_brand	p_type
1	goldenrod lavender spring chocolate lace	Manufacturer#1	Brand#13	PROMO BURNISHED COPPER
7	JUMBO PKG	901	ly. slyly ironi	
2	blush thistle blue yellow saddle	Manufacturer#1	Brand#13	LARGE BRUSHED BRASS
1	LG CASE	902	lar accounts amo	
3	spring green yellow purple cornsilk	Manufacturer#4	Brand#42	STANDARD POLISHED BRASS
21	WRAP CASE	903	egular deposits hag	
4	cornflower chocolate smoke green pink	Manufacturer#3	Brand#34	SMALL PLATED BRASS
14	MED DRUM	904	p furiously r	
5	forest brown coral puff cream	Manufacturer#3	Brand#32	STANDARD POLISHED TIN
15	SM PKG	905	wake carefully	

Table Value Function 可以出现在 SQL 中，Table 能出现的任意位置。如 CTE 的 WITH 子句中，FROM 子句中。

这样，你可以把文件当做一张普通的表进行任意分析。

你也可以用过 CREATE VIEW 语句为 Table Value Function 创建一个逻辑视图。这样，你可以想其他视图一样，对这个 Table Value Function 进行访问、权限管理等操作，也可以让其他用户访问这个 Table Value Function。

```
CREATE VIEW v1 AS
SELECT * FROM s3(
 "URI" = "http://127.0.0.1:9312/test2/test.snappy.parquet",
 "s3.access_key"= "ak",
 "s3.secret_key" = "sk",
 "format" = "parquet",
 "use_path_style"="true");

DESC v1;

SELECT * FROM v1;

GRANT SELECT_PRIV ON db1.v1 TO user1;
```

# 数据导入

配合 INSERT INTO SELECT 语法，我们可以方便将文件导入到 Doris 表中进行更快速的分析：

```
// 1. 创建doris内部表
CREATE TABLE IF NOT EXISTS test_table
(
 id int,
 name varchar(50),
 age int
)
DISTRIBUTED BY HASH(id) BUCKETS 4
PROPERTIES("replication_num" = "1");

// 2. 使用 S3 Table Value Function 插入数据
INSERT INTO test_table (id,name,age)
SELECT cast(id as INT) as id, name, cast (age as INT) as age
FROM s3(
 "uri" = "http://127.0.0.1:9312/test2/test.snappy.parquet",
 "s3.access_key"= "ak",
 "s3.secret_key" = "sk",
 "format" = "parquet",
 "use_path_style" = "true");
```

## 注意事项

1. 如果 S3 / hdfs tvf 指定的 uri 匹配不到文件，或者匹配到的所有文件都是空文件，那么 S3 / hdfs tvf 将会返回空结果集。在这种情况下使用DESC FUNCTION查看这个文件的 Schema，会得到一列虚假的列\_\_dummy\_col，可忽略这一列。
2. 如果指定 tvf 的 format 为 csv，所读文件不为空文件但文件第一行为空，则会提示错误The first line is empty, can not parse column numbers, 这因为无法通过该文件的第一行解析出 schema。

# 数据缓存

数据缓存 (File Cache) 通过缓存最近访问的远端存储系统 (HDFS 或对象存储) 的数据文件，加速后续访问相同数据的查询。在频繁访问相同数据的查询场景中，File Cache 可以避免重复的远端数据访问开销，提升热点数据的查询分析性能和稳定性。

## 原理

File Cache 将访问的远程数据缓存到本地的 BE 节点。原始的数据文件会根据访问的 IO 大小切分为 Block，Block 被存储到本地文件 `cache_path/hash(filepath).substr(0, 3)/hash(filepath)/offset` 中，并在 BE 节点中保存 Block 的元信息。

当访问相同的远程文件时，doris 会检查本地缓存中是否存在该文件的缓存数据，并根据 Block 的 offset 和 size，确认哪些数据从本地 Block 读取，哪些数据从远程拉起，并缓存远程拉取的新数据。BE 节点重启的时候，扫描 `cache_path` 目录，恢复 Block 的元信息。当缓存大小达到阈值上限的时候，按照 LRU 原则清理长久未访问的 Block。

## 使用方式

File Cache 默认关闭，需要在 FE 和 BE 中设置相关参数进行开启。

### FE 配置

单个会话中开启 File Cache:

```
SET enable_file_cache = true;
```

全局开启 File Cache:

```
SET GLOBAL enable_file_cache = true;
```

**File Cache 功能仅作用于针对文件的外表查询（如 Hive、Hudi）。对内表查询，或非文件的外表查询（如 JDBC、Elasticsearch）等无影响。**

### BE 配置

添加参数到 BE 节点的配置文件 `conf/be.conf` 中，并重启 BE 节点让配置生效。

参数	说明
<code>enable_file_cache</code>	是否启用 File Cache，默认 false

参数	说明
file_cache_path	缓存目录的相关配置，json 格式，例子：[{"path": "/path/to/file_cache1", "total_size": 53687091200, "query_limit": "10737418240"}, {"path": "/path/to/file_cache2", "total_size": 53687091200, "query_limit": "10737418240"}, {"path": "/path/to/file_cache3", "total_size": 53687091200, "query_limit": "10737418240"}]。path 是缓存的保存路径，total_size 是缓存的大小上限，query_limit 是单个查询能够使用的最大缓存大小。
file_cache_min_file_segment_size	单个 Block 的大小下限，默认 1MB，需要大于 4096
file_cache_max_file_segment_size	单个 Block 的大小上限，默认 4MB，需要大于 4096
enable_file_cache_query_limit	是否限制单个 query 使用的缓存大小，默认 false
clear_file_cache	BE 重启时是否删除之前的缓存数据，默认 false

## 查看 File Cache 命中情况

执行 `set enable_profile=true` 打开会话变量，可以在 FE 的 web 页面的 Queris 标签中查看到作业的 Profile。File Cache 相关的指标如下：

```
- FileCache:
- IOHitCacheNum: 552
- IOTotalNum: 835
- ReadFromFileCacheBytes: 19.98 MB
- ReadFromWriteCacheBytes: 0.00
- ReadTotalBytes: 29.52 MB
- WriteInFileCacheBytes: 915.77 MB
- WriteInFileCacheNum: 283
```

- IOTotalNum: 远程访问的次数
- IOHitCacheNum: 命中缓存的次数
- ReadFromFileCacheBytes: 从缓存文件中读取的数据量
- ReadTotalBytes: 总共读取的数据量
- SkipCacheBytes: 创建缓存文件失败，或者缓存文件被删，需要再次从远程读取的数据量
- WriteInFileCacheBytes: 保存到缓存文件中的数据量
- WriteInFileCacheNum: 保存的 Block 数量，所以  $\text{WriteInFileCacheBytes} / \text{WriteInFileCacheNum}$  为 Block 的平均大小
- $\text{IOHitCacheNum} / \text{IOTotalNum}$  等于 1，表示缓存完全命中
- $\text{ReadFromFileCacheBytes} / \text{ReadTotalBytes}$  等于 1，表示缓存完全命中

# 弹性计算节点

自 1.2.1 版本开始，Doris 支持了计算节点（Compute Node）功能。

从这个版本开始，BE 节点可以分为两类：

- Mix

混合节点。即 BE 节点的默认类型。该类型的节点既可以参与计算，也负责 Doris 数据的存储。

- Computation

计算节点。不负责数据的存储，只负责数据计算。

计算节点作为一种特殊类型的 BE 节点，没有数据存储能力，只负责数据计算。因此，可以将计算节点看做是无状态的 BE 节点，可以方便的进行节点的增加和删除。

在湖仓一体解决方案中，计算节点可以作为弹性节点，用于查询外部数据源，如 Hive、Iceberg、JDBC 等。Doris 不负责外部数据源数据的存储，因此，可以使用计算节点方便的扩展对外部数据源的计算能力。同时，计算节点也可以配置缓存目录，用于缓存外部数据源的热点数据，进一步加速数据读取。

计算节点适用于在 Doris 存算一体的部署方式，进行弹性资源控制。在 Doris 3.0 版本的存算分离架构下，BE 节点都是无状态的，因此不再需要单独的计算节点。

## 计算节点的使用

### 添加计算节点

在 BE 的 `be.conf` 配置文件中增加配置：

```
be_node_role=computation
```

之后启动 BE 节点，该节点就会以 计算节点 类型运行。

之后可以通过 MySQL 客户端链接 Doris 并执行：

```
ALTER SYSTEM ADD BACKEND
```

添加这个 BE 节点。添加成功后，在 `SHOW BACKENDS` 的 `NodeRole` 列可以看到节点类型为 `computation`。

### 使用计算节点

如需使用计算节点，需要满足以下条件：

- 集群内包含 计算节点。
- `fe.conf` 中添加了配置项：`prefer_compute_node_for_external_table = true`

同时，以下 FE 配置项，会影响计算节点的使用策略：



- `min_backend_num_for_external_table`

在 Doris 2.0（含）版本之前，该参数的默认值为 3。2.1 版本之后，默认参数为 -1。

该参数表示：期望可参与外表数据查询的 BE 节点的最小数量。-1 表示该值等同于当前集群内计算节点的数量。

举例说明。假设集群内有 3 个计算节点，5 个混合节点。

如果 `min_backend_num_for_external_table` 设置小于等于 3。则外表查询只会使用 3 个计算节点。如果设置大于 3，假设为 6，则外表查询除了使用 3 个计算节点外，还会额外选择 3 个混合节点参与计算。

综上，该参数主要用于可参与外表计算的最少 BE 节点数量，并且会优先选择计算节点。

注：

1. 2.1 版本之后，才支持 `min_backend_num_for_external_table` 设置为 -1。之前的版本，该参数必须为正数。且该参数只有在 `prefer_compute_node_for_external_table = true` 的情况下才生效。
2. 如果 `prefer_compute_node_for_external_table` 为 `false`。则外表查询会选择任意 BE 节点。
3. 如果集群中没有计算节点，则以上参数均不生效。
4. 如果 `min_backend_num_for_external_table` 值大于总的 BE 节点数量，则最多只会选择全部的 BE。
5. 以上参数可以通过 `ADMIN SET FRONTEND CONFIG` 命令动态修改，不需要重启 FE 节点。且所有 FE 节点都需配置。或者在 `fe.conf` 中添加配置并重启 FE 节点。

## 最佳实践

### 联邦查询的负载隔离和弹性伸缩

在联邦查询场景下，用户可以专门部署一组计算节点，用于外表数据的查询。这样可以将外表的查询负载（如在 hive 上进行大数量分析）和内表的查询负载（如低延迟的快速数据分析）进行隔离。

同时，计算节点作为无状态的 BE 节点，可以方便的进行扩容和缩容。比如可以使用 k8s 部署一组弹性计算节点集群，在业务高峰期利用更多的计算节点进行数据湖分析，低谷期可以进行快速缩容以降低成本。

## 常见问题

### 1. 混合节点和计算节点能否相互转换

计算节点可以转换为混合节点。但混合节点不可以转换为计算节点。

- 计算节点转混合节点

1. 停止 BE 节点
2. 删除 `be.conf` 中的 `be_node_role` 配置，或配置为 `be_node_role=mix`

3. 配置正确的 `storage_root_path` 数据存储目录。

4. 启动 BE 节点。

- 混合节点转计算节点

原则上不支持这种操作，因为混合节点本身存储了数据。如需转换，请先执行节点安全下线 (Decommission) 后，在以新节点的方式设置为计算节点。

## 2. 计算节点是否需要配置数据存储目录

需要。计算节点的数据存储目录不会存放用户数据，只会存放一些 BE 节点自身的信息文件，如 `cluster_id` 等。以及一些运行过程中的临时文件等。

计算节点的存储目录只需要很少的磁盘空间即可 (MB 级别)，并且可以随时和节点一起销毁，不会对用户数据造成影响。

## 3. 计算节点和混合节点是否可以配置文件缓存目录

[文件缓存](#) 通过缓存最近访问的远端存储系统 (HDFS 或对象存储) 的数据文件，加速后续访问相同数据的查询。

计算节点和混合节点均可设置文件缓存目录。文件缓存目录需事先创建。

同时，Doris 也采用了一致性哈希等策略来尽可能降低在节点扩缩容情况下的缓存失效的概率。

## 4. 计算节点是否需要通过 DECOMMISSION 操作下线

不需要。计算节点可以直接通过 `DROP BACKEND` 操作删除。

# 外表统计信息

外表统计信息的收集方式和收集内容与内表基本一致，目前支持对 Hive，Iceberg 和 Hudi 等外部表的收集。

外表暂不支持的功能包括

- 1. 暂不支持直方图收集
- 2. 暂不支持分区的增量收集和更新
- 3. 暂不支持自动收集 (with auto)，用户可以使用周期性收集 (with period) 来代替
- 4. 暂不支持抽样收集

下面主要介绍一下外表统计信息收集的示例和实现原理。

## 使用示例

这里主要展示在 Doris 中通过执行 analyze 命令收集外表统计信息的相关示例。除了上文提到的外表暂不支持的 4 个功能，其余和内表使用方式相同。下面以 hive.tpch100 数据库为例进行展示。tpch100 数据库中包含 lineitem, orders, region 等 8 张表。

## 信息收集

外表支持手动一次性收集和周期性收集两种收集方式。

### 手动一次性收集

- 收集 lineitem 表的表信息以及全部列的信息：

```
mysql> ANALYZE TABLE hive.tpch100.lineitem;
+-----+-----+-----+-----+
| Catalog_Name | DB_Name | Table_Name | Columns |
| Job_Id |
+-----+-----+-----+-----+
| hive | default_cluster:tpch100 | lineitem | [l_returnflag,l_receiptdate,l_tax,l_shipmode,l_suppkey,l_shipdate,l_commitdate,l_partkey,l_orderkey,l_quantity,l_linestatus,l_comment,l_extendedprice,l_linenumbe,l_discount,l_shipinstruct] | 16990 |
+-----+-----+-----+-----+
1 row in set (0.06 sec)
```

此操作是异步执行，会在后台创建收集任务，可以通过 job\_id 查看任务进度。

```
mysql> SHOW ANALYZE 16990;
+-----+-----+-----+-----+
| Job_Id |
+-----+-----+-----+-----+
```

```

+-----+-----+-----+-----+-----+
| job_id | catalog_name | db_name | tbl_name | col_name |
| job_type | analysis_type | message | last_exec_time_in_ms | state | progress |
| schedule_type |
+-----+-----+-----+-----+-----+
+-----+-----+-----+-----+-----+
| 16990 | hive | default_cluster:tpch100 | lineitem |
[l_returnflag,l_receiptdate,l_tax,l_shipmode,l_suppkey,l_shipdate,l_commitdate,l_partkey,l_orderkey,l_
quantity,l_linestatus,l_comment,l_extendedprice,l_linenumner,l_discount,l_shipinstruct] | MANUAL |
FUNDAMENTALS | | 2023-07-27 16:01:52 | RUNNING | 2 Finished/0 Failed/15 In Progress/17 Total
| ONCE |
+-----+-----+-----+-----+-----+
+-----+-----+-----+-----+-----+
1 row in set (0.00 sec)

```

以及查看每一列的 Task 状态。

```

mysql> SHOW ANALYZE TASK STATUS 16990;
+-----+-----+-----+-----+-----+-----+
| task_id | col_name | message | last_state_change_time | time_cost_in_ms | state |
+-----+-----+-----+-----+-----+-----+
| 16991 | l_receiptdate | | 2023-07-27 16:01:29 | 0 | PENDING |
| 16992 | l_returnflag | | 2023-07-27 16:01:44 | 14394 | FINISHED |
| 16993 | l_tax | | 2023-07-27 16:01:52 | 7975 | FINISHED |
| 16994 | l_shipmode | | 2023-07-27 16:02:11 | 18961 | FINISHED |
| 16995 | l_suppkey | | 2023-07-27 16:02:17 | 6684 | FINISHED |
| 16996 | l_shipdate | | 2023-07-27 16:02:26 | 8518 | FINISHED |
| 16997 | l_commitdate | | 2023-07-27 16:02:26 | 0 | RUNNING |
| 16998 | l_partkey | | 2023-07-27 16:01:29 | 0 | PENDING |
| 16999 | l_quantity | | 2023-07-27 16:01:29 | 0 | PENDING |
| 17000 | l_orderkey | | 2023-07-27 16:01:29 | 0 | PENDING |
| 17001 | l_comment | | 2023-07-27 16:01:29 | 0 | PENDING |
| 17002 | l_linestatus | | 2023-07-27 16:01:29 | 0 | PENDING |
| 17003 | l_extendedprice | | 2023-07-27 16:01:29 | 0 | PENDING |
| 17004 | l_linenumner | | 2023-07-27 16:01:29 | 0 | PENDING |
| 17005 | l_shipinstruct | | 2023-07-27 16:01:29 | 0 | PENDING |
| 17006 | l_discount | | 2023-07-27 16:01:29 | 0 | PENDING |
| 17007 | TableRowCount | | 2023-07-27 16:01:29 | 0 | PENDING |
+-----+-----+-----+-----+-----+-----+
17 rows in set (0.00 sec)

```

- 收集 tpch100 数据库所有表的信息

```

mysql> ANALYZE DATABASE hive.tpch100;
+-----+-----+-----+-----+
| Catalog_Name | DB_Name | Table_Name | Columns |
| Job_Id |
+-----+-----+-----+-----+
+-----+-----+-----+-----+
| hive | tpch100 | supplier |
[s_comment,s_phone,s_nationkey,s_name,s_address,s_acctbal,s_suppkey]
| 17018 |
| hive | tpch100 | nation | [n_comment,n_nationkey,n_regionkey,n_name]
| 17027 |

```

```

| hive | tpch100 | region | [r_regionkey,r_comment,r_name]
| 17033 |
| hive | tpch100 | partsupp | [ps_suppkey,ps_availqty,ps_comment,ps_partkey,ps_supplycost]
| 17038 |
| hive | tpch100 | orders |
[o_orderstatus,o_clerk,o_orderdate,o_shippriority,o_custkey,o_totalprice,o_orderkey,o_comment,o_orderp
riority] | 17045 |
| hive | tpch100 | lineitem |
[l_returnflag,l_receiptdate,l_tax,l_shipmode,l_suppkey,l_shipdate,l_commitdate,l_partkey,l_orderkey,l_
quantity,l_linestatus,l_comment,l_extendedprice,l_linenumbe,r_l_discount,l_shipinstruct] | 17056 |
| hive | tpch100 | part |
[p_partkey,p_container,p_name,p_comment,p_brand,p_type,p_retailprice,p_mfgr,p_size]
| 17074 |
| hive | tpch100 | customer |
[c_custkey,c_phone,c_acctbal,c_mktsegment,c_address,c_nationkey,c_name,c_comment]
| 17085 |
+-----+-----+-----+-----+
-----+
8 rows in set (0.29 sec)

```

此操作会批量提交 TPCH-100 数据库下所有表的收集任务，也是异步执行，会给每个表创建一个 job\_id，也可以通过 job\_id 查看每张表的任务进度。

- 同步收集

可以使用 with sync 同步收集表或数据库的统计信息。这时不会创建后台任务，客户端在收集完成之前会 block 住，直到收集任务执行完成再返回。

```

mysql> analyze table hive.tpch100.orders with sync;
Query OK, 0 rows affected (33.19 sec)

```

需要注意的是，同步收集受 query\_timeout session 变量影响，如果超时失败，需要调大该变量后重试。比如：set query\_timeout=3600 (超时时间设置为 1 小时)

## 周期性收集

使用 with period 可以设置周期性的执行收集任务：

```
analyze table hive.tpch100.orders with period 86400;
```

这条语句创建一个周期性收集的任务，周期是 1 天，每天自动收集和更新 orders 表的统计信。

## 任务管理

任务管理的方式也和内表相同，主要包括查看 job，查看 task，删除 job 等功能。请参考[内表统计信息任务管理](#)部分。

- 查看所有 job 状态

```

mysql> SHOW ANALYZE;
+-----+-----+-----+-----+-----+-----+
| job_id | catalog_name | db_name | tbl_name | col_name |
| job_type | analysis_type | message | last_exec_time_in_ms | state | progress |

```

schedule_type										
+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+										
+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+										
+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+										
16990	hive	default_cluster:tpch100		lineitem						
[l_returnflag,l_receiptdate,l_tax,l_shipmode,l_suppkey,l_shipdate,l_commitdate,l_partkey,l_orderkey,l_quantity,l_linestatus,l_comment,l_extendedprice,l_linenummer,l_discount,l_shipinstruct]										
MANUAL										
FUNDAMENTALS										
2023-07-27 16:05:02   FINISHED   17 Finished/0 Failed/0 In Progress/17										
Total	ONCE									
+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+										
+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+										
+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+										

- 查看一个 job 的所有 task 状态

```
mysql> SHOW ANALYZE TASK STATUS 16990;
```

task_id	col_name	message	last_state_change_time	time_cost_in_ms	state
16991	l_receiptdate		2023-07-27 16:05:02	9560	FINISHED
16992	l_returnflag		2023-07-27 16:01:44	14394	FINISHED
16993	l_tax		2023-07-27 16:01:52	7975	FINISHED
16994	l_shipmode		2023-07-27 16:02:11	18961	FINISHED
16995	l_suppkey		2023-07-27 16:02:17	6684	FINISHED
16996	l_shipdate		2023-07-27 16:02:26	8518	FINISHED
16997	l_commitdate		2023-07-27 16:02:34	8380	FINISHED
16998	l_partkey		2023-07-27 16:02:40	6060	FINISHED
16999	l_quantity		2023-07-27 16:02:50	9768	FINISHED
17000	l_orderkey		2023-07-27 16:02:57	7200	FINISHED
17001	l_comment		2023-07-27 16:03:36	38468	FINISHED
17002	l_linestatus		2023-07-27 16:03:51	15226	FINISHED
17003	l_extendedprice		2023-07-27 16:04:00	8713	FINISHED
17004	l_linenummer		2023-07-27 16:04:06	6659	FINISHED
17005	l_shipinstruct		2023-07-27 16:04:36	29777	FINISHED
17006	l_discount		2023-07-27 16:04:45	9212	FINISHED
17007	TableRowCount		2023-07-27 16:04:52	6974	FINISHED

- 终止未完成的 job

```
KILL ANALYZE [job_id]
```

- 删除周期性收集 job

```
DROP ANALYZE JOB [JOB_ID]
```

## 信息查看

信息的查看包括表的统计信息（表的行数）查看和列统计信息查看，请参考[内表统计信息](#)查看统计信息部分。

## 表统计信息

```
SHOW TABLE [cached] stats TABLE_NAME;
```

查看 `statistics` 表中指定 `table` 的行数，如果指定 `cached` 参数，则展示的是指定表已加载到缓存中的行数信息。

```
mysql> SHOW TABLE STATS hive.tpch100.orders;
+-----+-----+-----+
| row_count | update_time | last_analyze_time |
+-----+-----+-----+
| 150000000 | 2023-07-11 23:01:49 | 2023-07-11 23:01:44 |
+-----+-----+-----+
```

列统计信息

```
SHOW COLUMN [cached] stats TABLE_NAME;
```

查看 `Statistics` 表中指定 `Table` 的列统计信息，如果指定 `Cached` 参数，则展示的是指定表已加载到缓存中的列信息。

```
mysql> SHOW COLUMN stats hive.tpch100.orders;
+-----+-----+-----+-----+-----+-----+-----+
| column_name | count | ndv | num_null | data_size | avg_size_byte | min
| max
+-----+-----+-----+-----+-----+-----+-----+
| o_orderstatus | 1.5E8 | 3.0 | 0.0 | 1.50000001E8 | 1.0 | 'F'
| 'P'
| o_clerk | 1.5E8 | 100836.0 | 0.0 | 2.250000015E9 | 15.0 |
| 'Clerk#000000001' | 'Clerk#000100000'
| o_orderdate | 1.5E8 | 2417.0 | 0.0 | 6.00000004E8 | 4.0 | '1992-01-01'
| '1998-08-02'
| o_shippriority | 1.5E8 | 1.0 | 0.0 | 6.00000004E8 | 4.0 | 0
| 0
| o_custkey | 1.5E8 | 1.0023982E7 | 0.0 | 6.00000004E8 | 4.0 | 1
| 14999999
| o_totalprice | 1.5E8 | 3.4424096E7 | 0.0 | 1.200000008E9 | 8.0 | 811.73
| 591036.15
| o_orderkey | 1.5E8 | 1.51621184E8 | 0.0 | 1.200000008E9 | 8.0 | 1
| 600000000
| o_comment | 1.5E8 | 1.10204136E8 | 0.0 | 7.275038757500258E9 | 48.50025806 | ' Tiresias about
the' | 'zzle? unusual requests w'
| o_orderpriority | 1.5E8 | 5.0 | 0.0 | 1.2600248124001656E9 | 8.40016536 | '1-URGENT'
| '5-LOW'
+-----+-----+-----+-----+-----+-----+-----+
```

信息修改

修改信息支持用户手动修改列统计信息。可以修改指定列的 `row_count`, `ndv`, `num_nulls`, `min_value`, `max_value`, `data_size` 等信息。 请参考[内表统计信息](#)修改统计信息部分。

```
mysql> ALTER TABLE hive.tpch100.orders MODIFY COLUMN o_orderstatus SET STATS ('row_count'='6001215');
Query OK, 0 rows affected (0.03 sec)

mysql> SHOW COLUMN stats hive.tpch100.orders;
+-----+-----+-----+-----+-----+-----+-----+
| column_name | count | ndv | num_null | data_size | avg_size_byte | min
| max
+-----+-----+-----+-----+-----+-----+-----+
```

o_orderstatus	6001215.0	0.0	0.0	0.0	0.0	'NULL'
'NULL'						
o_clerk	1.5E8	100836.0	0.0	2.250000015E9	15.0	
'Clerk#000000001'	'Clerk#000100000'					
o_orderdate	1.5E8	2417.0	0.0	6.00000004E8	4.0	'1992-01-01'
'1998-08-02'						
o_shippriority	1.5E8	1.0	0.0	6.00000004E8	4.0	0
0						
o_custkey	1.5E8	1.0023982E7	0.0	6.00000004E8	4.0	1
14999999						
o_totalprice	1.5E8	3.4424096E7	0.0	1.200000008E9	8.0	811.73
591036.15						
o_orderkey	1.5E8	1.51621184E8	0.0	1.200000008E9	8.0	1
600000000						
o_comment	1.5E8	1.10204136E8	0.0	7.275038757500258E9	48.50025806	'Tiresias about the'
'zzle? unusual requests w'						
o_orderpriority	1.5E8	5.0	0.0	1.2600248124001656E9	8.40016536	'1-URGENT'
'5-LOW'						

## 信息删除

删除外表统计信息支持用户删除一张表的表行数信息和列统计信息。如果用户指定了删除的列名，则只删除这些列的信息。如果不指定，则删除整张表所有列的统计信息以及表行数信息。请参考[内表统计信息](#) 删除统计信息部分。

- 删除整张表的信息

```
DROP STATS hive.tpch100.orders
```

- 删除表中某几列的信息

```
DROP STATS hive.tpch100.orders (o_orderkey, o_orderdate)
```

## 实现原理

### 统计信息数据来源

优化器（Nereids）通过 Cache 读取统计信息，cache 的数据来源有两个。

第一个是内部的 statistics 表，statistics 表的数据通过用户执行 analyze 语句收集而来。这一部分的架构与内表相同，用户可以像分析内表一样，对外表执行 analyze 语句来收集统计信息。

与内表不同的是，外表 cache 的数据还有第二个来源 stats collector。stats collector 定义了一些接口，用来从外部数据源获取统计信息。比如目前已经支持的 hive metastore 和 Iceberg 两种数据源，这些接口可以获取外部数据源中已有的统计信息。以 hive 为例，如果用户在 hive 中执行过 analyze 操作，那么在 Doris 中查询的时候，Doris 可以直接从 hive metastore 中加载已有的统计信息到缓存中，包括表的行数、列的最大最小值等。如果外部数据源也没有统计信息，stats connector 会根据表中数据文件的大小和表的 schema，大致估算一个行数提供给优化器，在这种情况下，列的统计信息是缺失的，可能导致优化器生成比较低效的执行计划。



Stats collector 在 statistics 表中无数据时自动执行，对用户透明，用户无需执行命令或进行设置。

## 缓存的加载

缓存的加载顺序是，首先通过 Statistics 表加载，如果 Statistics 表中有信息，说明用户在 Doris 中执行过 analyze 操作，这样收集上来的统计信息是最准确的，所以我们优先从 Statistics 表中加载。如果发现 Statistics 表中没有当前所需表的信息，再通过 Stats Collector 从外部数据源获取。如果外部数据源也没有，Stats Collector 会估算一个行数。

由于缓存是异步加载的，第一次 Query 的时候可能没法利用到任何统计信息，因为这时候刚刚触发缓存加载。但一般情况下，可以保证第二次查询某张表的时候，优化器可以从缓存中获取到它的统计信息。

# 集群升级

---

## 概述

升级请使用本章节中推荐的步骤进行集群升级，Doris 集群升级可使用**滚动升级**的方式进行升级，无需集群节点全部停机升级，极大程度上降低对上层应用的影响。

## Doris 版本说明

Doris 升级请遵守不要跨两个二位版本升级的原则，依次往后升级。

比如从 0.15.x 升级到 2.0.x 版本，则建议先升级至 1.1 最新版本，然后升级到最新的 1.2 版本，最后升级到最新的 2.0 版本。

## 升级步骤

### 升级说明

1. 在升级过程中，由于 Doris 的 RoutineLoad、Flink-Doris-Connector、Spark-Doris-Connector 都已在代码中实现了重试机制，所以在多 BE 节点的集群中，滚动升级不会导致任务失败。
2. StreamLoad 任务需要您在自己的代码中实现重试机制，否则会导致任务失败。
3. 集群副本修复和均衡功能在单次升级任务中务必要前置关闭和结束后打开，无论您集群节点是否全部升级完成。

### 升级流程概览

1. 元数据备份
2. 关闭集群副本修复和均衡功能
3. 兼容性测试
4. 升级 BE
5. 升级 FE
6. 打开集群副本修复和均衡功能

### 升级前置工作

请按升级流程顺次执行升级

#### 01 元数据备份（重要）

将 **FE-Master** 节点的 `doris-meta` 目录进行完整备份！

#### 02 关闭集群副本修复和均衡功能

升级过程中会有节点重启，所以可能会触发不必要的集群均衡和副本修复逻辑，先通过以下命令关闭：

```
admin set frontend config("disable_balance" = "true");
admin set frontend config("disable_colocate_balance" = "true");
admin set frontend config("disable_tablet_scheduler" = "true");
```

### 03 兼容性测试

\*\*\*\*元数据兼容非常重要，如果因为元数据不兼容导致的升级失败，那可能会导致数据丢失！建议每次升级前都进行元数据兼容性测试！\*\*\*\*

#### 1. FE 兼容性测试

\*\*\*\*重要\*\*\*\*

1. 建议在自己本地的开发机，或者 BE 节点做 FE 兼容性测试。
2. 不建议在 Follower 或者 Observer 节点上测试，避免出现链接异常
3. 如果一定在 Follower 或者 Observer 节点上，需要停止已启动的 FE 进程

##### a. 单独使用新版本部署一个测试用的 FE 进程

```
sh ${DORIS_NEW_HOME}/bin/start_fe.sh --daemon
```

##### b. 修改测试用的 FE 的配置文件 fe.conf

```
vi ${DORIS_NEW_HOME}/conf/fe.conf
```

修改以下端口信息，将所有端口设置为与线上不同

```
...
http_port = 18030
rpc_port = 19020
query_port = 19030
arrow_flight_sql_port = 19040
edit_log_port = 19010
...
```

保存并退出

##### c. 修改 fe.conf

- 在 fe.conf 添加 ClusterID 配置

```
echo "cluster_id=123456" >> ${DORIS_NEW_HOME}/conf/fe.conf
```

- 添加元数据故障恢复配置（2.0.2 + 版本无需进行此操作）

```
echo "metadata_failure_recovery=true" >> ${DORIS_NEW_HOME}/conf/fe.conf
```

d. 拷贝线上环境 Master FE 的元数据目录 doris-meta 到测试环境

```
cp ${DORIS_OLD_HOME}/fe/doris-meta/* ${DORIS_NEW_HOME}/fe/doris-meta
```

e. 将拷贝到测试环境中的 VERSION 文件中的 cluster\_id 修改为 123456（即与第 3 步中相同）

```
vi ${DORIS_NEW_HOME}/fe/doris-meta/image/VERSION
clusterId=123456
```

f. 在测试环境中，运行启动 FE（请按照版本选择启动 FE 的方式）

- 2.0.2(包含 2.0.2) + 版本

```
sh ${DORIS_NEW_HOME}/bin/start_fe.sh --daemon --metadata_failure_recovery
```

- 2.0.1（包含 2.0.1）以前的版本

```
sh ${DORIS_NEW_HOME}/bin/start_fe.sh --daemon
```

g. 通过 FE 日志 fe.log 观察是否启动成功

```
tail -f ${DORIS_NEW_HOME}/log/fe.log
```

h. 如果启动成功，则代表兼容性没有问题，停止测试环境的 FE 进程，准备升级

```
sh ${DORIS_NEW_HOME}/bin/stop_fe.sh
```

## 2. BE 兼容性测试

可利用灰度升级方案，先升级单个 BE，无异常和报错情况下即视为兼容性正常，可执行后续升级动作

## 升级流程

### 先升级 BE，后升级 FE

一般而言，Doris 只需要升级 FE 目录下的 /bin 和 /lib 以及 BE 目录下的 /bin 和 /lib

在 2.0.2 及之后的版本，FE 和 BE 部署路径下新增了 custom\_lib/ 目录（如没有可以手动创建）。custom\_lib/ 目录用于存放一些用户自定义的第三方 jar 包，如 hadoop-lzo-\*.jar, orai18n.jar 等。

这个目录在升级时不需要替换。

但是在大批量升级时，可能会有新的特性增加或者老功能的重构，这些修改可能会需要升级时替换/新增更多的目录来保证所有新功能的可用性，请大批量升级时密切关注该版本的 Release-Note，以免出现升级故障

## 04 升级 BE

为了保证您的数据安全，请使用 3 副本来存储您的数据，以避免升级误操作或失败导致的数据丢失问题

1. 在多副本的前提下，选择一台 BE 节点停止运行，进行灰度升级

```
sh ${DORIS_OLD_HOME}/be/bin/stop_be.sh
```

2. 重命名 BE 目录下的 /bin, /lib 目录

```
mv ${DORIS_OLD_HOME}/be/bin ${DORIS_OLD_HOME}/be/bin_back
mv ${DORIS_OLD_HOME}/be/lib ${DORIS_OLD_HOME}/be/lib_back
```

3. 复制新版本的 /bin, /lib 目录到原 BE 目录下

```
cp -r ${DORIS_NEW_HOME}/be/bin ${DORIS_OLD_HOME}/be/bin
cp -r ${DORIS_NEW_HOME}/be/lib ${DORIS_OLD_HOME}/be/lib
```

4. 启动该 BE 节点

```
sh ${DORIS_OLD_HOME}/be/bin/start_be.sh --daemon
```

5. 链接集群，查看该节点信息

```
show backends\G
```

若该 BE 节点 alive 状态为 true，且 Version 值为新版本，则该节点升级成功

6. 依次完成其他 BE 节点升级

## 05 升级 FE

先升级非 Master 节点，后升级 Master 节点。

1. 多个 FE 节点情况下，选择一个非 Master 节点进行升级，先停止运行

```
sh ${DORIS_OLD_HOME}/fe/bin/stop_fe.sh
```

2. 重命名 FE 目录下的 /bin, /lib, /mysql\_ssl\_default\_certificate 目录

```
mv ${DORIS_OLD_HOME}/fe/bin ${DORIS_OLD_HOME}/fe/bin_back
mv ${DORIS_OLD_HOME}/fe/lib ${DORIS_OLD_HOME}/fe/lib_back
mv ${DORIS_OLD_HOME}/fe/mysql_ssl_default_certificate
${DORIS_OLD_HOME}/fe/mysql_ssl_default_certificate_back
```

### 3. 复制新版本的 /bin, /lib, /mysql\_ssl\_default\_certificate 目录到原 FE 目录下

```
cp -r ${DORIS_NEW_HOME}/fe/bin ${DORIS_OLD_HOME}/fe/bin
cp -r ${DORIS_NEW_HOME}/fe/lib ${DORIS_OLD_HOME}/fe/lib
cp -r ${DORIS_NEW_HOME}/fe/mysql_ssl_default_certificate
${DORIS_OLD_HOME}/fe/mysql_ssl_default_certificate
```

### 4. 启动该 FE 节点

```
sh ${DORIS_OLD_HOME}/fe/bin/start_fe.sh --daemon
```

### 5. 链接集群，查看该节点信息

```
show frontends\G
```

若该 FE 节点 alive 状态为 true，且 Version 值为新版本，则该节点升级成功

### 6. 依次完成其他 FE 节点升级，最后完成 Master 节点的升级

## 06 打开集群副本修复和均衡功能

升级完成，并且所有 BE 节点状态变为 Alive 后，打开集群副本修复和均衡功能：

```
admin set frontend config("disable_balance" = "false");
admin set frontend config("disable_colocate_balance" = "false");
admin set frontend config("disable_tablet_scheduler" = "false");
```

# 弹性扩缩容

---

Doris 可以很方便的扩容和缩容 FE、BE、Broker 实例。

## FE 扩容和缩容

可以通过将 FE 扩容至 3 个以上节点来实现 FE 的高可用。

用户可以通过 MySQL 客户端登陆 Master FE。通过：

```
SHOW PROC '/frontends';
```

来查看当前 FE 的节点情况。

也可以通过前端页面连接：[http://fe\\_hostname:fe\\_http\\_port/frontend](http://fe_hostname:fe_http_port/frontend) 或者 [http://fe\\_hostname:fe\\_http\\_port/system?path=/frontends](http://fe_hostname:fe_http_port/system?path=/frontends) 来查看 FE 节点的情况。

以上方式，都需要 Doris 的 root 用户权限。

FE 节点的扩容和缩容过程，不影响当前系统运行。

## 增加 FE 节点

FE 分为 Follower 和 Observer 两种角色，其中 Follower 角色会选举出一个 Follower 节点作为 Master。默认一个集群，只能有一个 Master 状态的 Follower 角色，可以有多个 Follower 和 Observer，同时需保证 Follower 角色为奇数个。其中所有 Follower 角色组成一个选举组，如果 Master 状态的 Follower 宕机，则剩下的 Follower 会自动选出新的 Master，保证写入高可用。Observer 同步 Master 的数据，但是不参加选举。如果只部署一个 FE，则 FE 默认就是 Master。

第一个启动的 FE 自动成为 Master。在此基础上，可以添加若干 Follower 和 Observer。

## 配置及启动 Follower 或 Observer

这里 Follower 和 Observer 的配置同 Master 的配置。

首先第一次启动时，需执行以下命令：

```
./bin/start_fe.sh --helper leader_fe_host:edit_log_port --daemon
```

其中 leader\_fe\_host 为 Master 所在节点 ip, edit\_log\_port 在 Master 的配置文件 fe.conf 中。--helper 参数仅在 follower 和 observer 第一次启动时才需要。

## 将 Follower 或 Observer 加入到集群

添加 Follower 或 Observer。使用 mysql-client 连接到已启动的 FE，并执行：

```
ALTER SYSTEM ADD FOLLOWER "follower_host:edit_log_port";
```

或

```
ALTER SYSTEM ADD OBSERVER "observer_host:edit_log_port";
```

其中 follower\_host 和 observer\_host 为 Follower 或 Observer 所在节点 ip，edit\_log\_port 在其配置文件 fe.conf 中。

查看 Follower 或 Observer 运行状态。使用 mysql-client 连接到任一已启动的 FE，并执行：SHOW PROC 'frontends'；可以查看当前已加入集群的 FE 及其对应角色。

#### FE 扩容注意事项：

1. Follower FE（包括 Master）的数量必须为奇数，建议最多部署 3 个组成高可用（HA）模式即可。
2. 当 FE 处于高可用部署时（1 个 Master，2 个 Follower），我们建议通过增加 Observer FE 来扩展 FE 的读服务能力。当然也可以继续增加 Follower FE，但几乎是不必要的。
3. 通常一个 FE 节点可以应对 10-20 台 BE 节点。建议总的 FE 节点数量在 10 个以下。而通常 3 个即可满足绝大部分需求。
4. helper 不能指向 FE 自身，必须指向一个或多个已存在并且正常运行中的 Master/Follower FE。

## 删除 FE 节点

使用以下命令删除对应的 FE 节点：

```
ALTER SYSTEM DROP FOLLOWER[OBSERVER] "fe_host:edit_log_port";
```

#### FE 缩容注意事项：

1. 删除 Follower FE 时，确保最终剩余的 Follower（包括 Master）节点为奇数。

## BE 扩容和缩容

用户可以通过 mysql-client 登陆 Master FE。通过：

```
SHOW PROC '/backends';
```

来查看当前 BE 的节点情况。

也可以通过前端页面连接：[http://fe\\_hostname:fe\\_http\\_port/backend](http://fe_hostname:fe_http_port/backend) 或者 [http://fe\\_hostname:fe\\_http\\_port/system?path=/backends](http://fe_hostname:fe_http_port/system?path=/backends) 来查看 BE 节点的情况。

以上方式，都需要 Doris 的 root 用户权限。

BE 节点的扩容和缩容过程，不影响当前系统运行以及正在执行的任务，并且不会影响当前系统的性能。数据均衡会自动进行。根据集群现有数据量的大小，集群会在几个小时到 1 天不等的时间内，恢复到负载均衡的状态。集群负载情况，可以参见 [Tablet 负载均衡文档](#)。

## 增加 BE 节点

BE 节点的增加方式同 **BE 部署** 一节中的方式，通过 ALTER SYSTEM ADD BACKEND 命令增加 BE 节点。



### BE 扩容注意事项:

1. BE 扩容后, Doris 会自动根据负载情况, 进行数据均衡, 期间不影响使用。

## 删除 BE 节点

删除 BE 节点有两种方式: DROP 和 DECOMMISSION

DROP 语句如下:

```
ALTER SYSTEM DROP BACKEND "be_host:be_heartbeat_service_port";
```

**注意: DROP BACKEND 会直接删除该 BE, 并且其上的数据将不能再恢复!!! 所以我们强烈不推荐使用 DROP BACKEND 这种方式删除 BE 节点。当你使用这个语句时, 会有对应的防误操作提示。**

DECOMMISSION 语句如下:

```
ALTER SYSTEM DECOMMISSION BACKEND "be_host:be_heartbeat_service_port";
```

### DECOMMISSION 命令说明:

1. 该命令用于安全删除 BE 节点。命令下发后, Doris 会尝试将该 BE 上的数据向其他 BE 节点迁移, 当所有数据都迁移完成后, Doris 会自动删除该节点。
2. 该命令是一个异步操作。执行后, 可以通过 SHOW PROC '/backends'; 看到该 BE 节点的 SystemDecommissioned 状态为 true。表示该节点正在进行下线。
3. 该命令**不一定执行成功**。比如剩余 BE 存储空间不足以容纳下线 BE 上的数据, 或者剩余机器数量不满足最小副本数时, 该命令都无法完成, 并且 BE 会一直处于 SystemDecommissioned 为 true 的状态。
4. DECOMMISSION 的进度, 可以通过 SHOW PROC '/backends'; 中的 TabletNum 查看, 如果正在进行, TabletNum 将不断减少。
5. 该操作可以通过:

```
CANCEL DECOMMISSION BACKEND "be_host:be_heartbeat_service_port";
```

命令取消。取消后, 该 BE 上的数据将维持当前剩余的数据量。后续 Doris 重新进行负载均衡

对于多租户部署环境下, BE 节点的扩容和缩容, 请参阅 [多租户设计文档](#)。

## Broker 扩容缩容

Broker 实例的数量没有硬性要求。通常每台物理机部署一个即可。Broker 的添加和删除可以通过以下命令完成:

```
ALTER SYSTEM ADD BROKER broker_name "broker_host:broker_ipc_port"; ALTER SYSTEM DROP BROKER broker_name "broker_host:broker_ipc_port"; ALTER SYSTEM DROP ALL BROKER broker_name;
```

Broker 是无状态的进程，可以随意启停。当然，停止后，正在其上运行的作业会失败，重试即可。

# 负载均衡

当部署多个 FE 节点时，用户可以在多个 FE 之上部署负载均衡层来实现 Doris 的高可用。

## 代码实现

自己在应用层代码进行重试和负载均衡。比如发现一个连接挂掉，就自动在其他连接上进行重试。应用层代码重试需要应用自己配置多个 doris 前端节点地址。

## JDBC Connector

如果使用 mysql jdbc connector 来连接 Doris，可以使用 jdbc 的自动重试机制：

```
jdbc:mysql:loadbalance://[host:port],[host:port].../[database][?propertyName1]=[propertyValue1]
[&propertyName2]=[propertyValue
```

详细可以参考[MySQL 官网文档](#)

## ProxySQL 方式

ProxySQL 是灵活强大的 MySQL 代理层，是一个能实实在在用在生产环境的 MySQL 中间件，可以实现读写分离，支持 Query 路由功能，支持动态指定某个 SQL 进行 Cache，支持动态加载配置、故障切换和一些 SQL 的过滤功能。

Doris 的 FE 进程负责接收用户连接和查询请求，其本身是可以横向扩展且高可用的，但是需要用户在多个 FE 上架设一层 proxy，来实现自动的连接负载均衡。

## 安装 ProxySQL (yum 方式)

```
配置yum源
vim /etc/yum.repos.d/proxysql.repo

[proxysql_repo]
name= ProxySQL YUM repository
baseurl=http://repo.proxysql.com/ProxySQL/proxysql-1.4.x/centos/$releasever
gpgcheck=1
gpgkey=http://repo.proxysql.com/ProxySQL/repo_pub_key

执行安装
yum clean all
yum makecache
yum -y install proxysql

查看版本
proxysql --version
ProxySQL version 1.4.13-15-g69d4207, codename Truls

设置开机自启动
systemctl enable proxysql
systemctl start proxysql
systemctl status proxysql
```

启动后会监听两个端口，默认为6032和6033。6032端口是ProxySQL的管理端口，6033是ProxySQL对外提供服务的端口（即连接到转发后端的真正数据库的转发端口）。

```
netstat -tunlp
```

Active Internet connections (only servers)

Proto	Recv-Q	Send-Q	Local Address	Foreign Address	State	PID/Program name
tcp	0	0	0.0.0.0:6032	0.0.0.0:*	LISTEN	23940/proxysql
tcp	0	0	0.0.0.0:6033	0.0.0.0:*	LISTEN	

## ProxySQL 配置

ProxySQL 有配置文件 `/etc/proxysql.cnf` 和配置数据库文件 `/var/lib/proxysql/proxysql.db`。这里需要特别注意：如果存在“proxysql.db”文件（在 `/var/lib/proxysql` 目录下），则 ProxySQL 服务只有在第一次启动时才会去读取 `proxysql.cnf` 文件并解析；后面启动就不会读取 `proxysql.cnf` 文件了！如果想要让 `proxysql.cnf` 文件里的配置在重启 proxysql 服务后生效（即想要让 proxysql 重启时读取并解析 `proxysql.cnf` 配置文件），则需要先删除 `/var/lib/proxysql/proxysql.db` 数据库文件，然后再重启 proxysql 服务。这样就相当于初始化启动 proxysql 服务了，会再次生产一个纯净的 `proxysql.db` 数据库文件（如果之前配置了 proxysql 相关路由规则等，则就会被抹掉）

## 查看及修改配置文件

这里主要是几个参数，在下面已经注释出来了，可以根据自己的需要进行修改

```
egrep -v "^#|^$" /etc/proxysql.cnf
datadir="/var/lib/proxysql" #数据目录
admin_variables=
{
 admin_credentials="admin:admin" #连接管理端的用户名与密码
 mysql_ifaces="0.0.0.0:6032" #管理端口，用来连接proxysql的管理数据库
}
mysql_variables=
{
 threads=4 #指定转发端口开启的线程数量
 max_connections=2048
 default_query_delay=0
 default_query_timeout=36000000
 have_compress=true
 poll_timeout=2000
 interfaces="0.0.0.0:6033" #指定转发端口，用于连接后端mysql数据库的，相当于代理作用
 default_schema="information_schema"
 stacksize=1048576
 server_version="5.5.30" #指定后端mysql的版本
 connect_timeout_server=3000
 monitor_username="monitor"
 monitor_password="monitor"
 monitor_history=600000
 monitor_connect_interval=60000
 monitor_ping_interval=10000
 monitor_read_only_interval=1500
 monitor_read_only_timeout=500
 ping_interval_server_msec=120000
 ping_timeout_server=500
 commands_stats=true
 sessions_sort=true
 connect_retries_on_failure=10
}
mysql_servers =
(
)
```

```
mysql_users:
(
)
mysql_query_rules:
(
)
scheduler=
(
)
mysql_replication_hostgroups=
(
)
```

## 连接 ProxySQL 管理端口测试

```
mysql -uadmin -padmin -P6032 -hdoris01
// 查看main库（默认登陆后即在此库）的global_variables表信息

MySQL [(none)]> show databases;
+-----+-----+-----+
| seq | name | file |
+-----+-----+-----+
| 0 | main | |
| 2 | disk | /var/lib/proxysql/proxysql.db |
| 3 | stats | |
| 4 | monitor | |
| 5 | stats_history | /var/lib/proxysql/proxysql_stats.db |
+-----+-----+-----+
5 rows in set (0.000 sec)

MySQL [(none)]> use main;
Reading table information for completion of table and column names
You can turn off this feature to get a quicker startup with -A

Database changed
MySQL [main]> show tables;
+-----+
| tables |
+-----+
| global_variables |
| mysql_collations |
| mysql_group_replication_hostgroups |
| mysql_query_rules |
| mysql_query_rules_fast_routing |
| mysql_replication_hostgroups |
| mysql_servers |
| mysql_users |
| proxysql_servers |
| runtime_checksums_values |
| runtime_global_variables |
| runtime_mysql_group_replication_hostgroups |
| runtime_mysql_query_rules |
| runtime_mysql_query_rules_fast_routing |
| runtime_mysql_replication_hostgroups |
| runtime_mysql_servers |
| runtime_mysql_users |
| runtime_proxysql_servers |
| runtime_scheduler |
| scheduler |
+-----+
20 rows in set (0.000 sec)
```

## ProxySQL 配置后端 Doris FE

使用 insert 语句添加主机到 mysql\_servers 表中，其中：hostgroup\_id 为 10 表示写组，为 20 表示读组，我们这里不需要读写分离，无所谓随便设置哪一个都可以。

```
[root@mysql-proxy ~]# mysql -uadmin -padmin -P6032 -h127.0.0.1
.....
MySQL [(none)]> insert into mysql_servers(hostgroup_id,hostname,port) values(10,'192.168.9.211',9030);
Query OK, 1 row affected (0.000 sec)

MySQL [(none)]> insert into mysql_servers(hostgroup_id,hostname,port) values(10,'192.168.9.212',9030);
Query OK, 1 row affected (0.000 sec)

MySQL [(none)]> insert into mysql_servers(hostgroup_id,hostname,port) values(10,'192.168.9.213',9030);
Query OK, 1 row affected (0.000 sec)

//如果在插入过程中，出现报错：
ERROR 1045 (#2800): UNIQUE constraint failed: mysql_servers.hostgroup_id, mysql_servers.hostname,
mysql_servers.port

//说明可能之前就已经定义了其他配置，可以清空这张表 或者 删除对应host的配置
MySQL [(none)]> select * from mysql_servers;
MySQL [(none)]> delete from mysql_servers;
Query OK, 6 rows affected (0.000 sec)

//查看这 3 个节点是否插入成功，以及它们的状态。
MySQL [(none)]> select * from mysql_servers\G;
***** 1. row *****
 hostgroup_id: 10
 hostname: 192.168.9.211
 port: 9030
 status: ONLINE
 weight: 1
 compression: 0
 max_connections: 1000
max_replication_lag: 0
 use_ssl: 0
 max_latency_ms: 0
 comment:
***** 2. row *****
 hostgroup_id: 10
 hostname: 192.168.9.212
 port: 9030
 status: ONLINE
 weight: 1
 compression: 0
 max_connections: 1000
max_replication_lag: 0
 use_ssl: 0
 max_latency_ms: 0
 comment:
***** 3. row *****
 hostgroup_id: 10
 hostname: 192.168.9.213
 port: 9030
 status: ONLINE
 weight: 1
 compression: 0
 max_connections: 1000
max_replication_lag: 0
 use_ssl: 0
 max_latency_ms: 0
 comment:
6 rows in set (0.000 sec)

ERROR: No query specified
```

```
如上修改后，加载到RUNTIME，并保存到disk，下面两步非常重要，不然退出以后你的配置信息就没了，必须保存
MySQL [(none)]> load mysql servers to runtime;
Query OK, 0 rows affected (0.006 sec)

MySQL [(none)]> save mysql servers to disk;
Query OK, 0 rows affected (0.348 sec)
```

## 监控 Doris FE 节点配置

添 Doris FE 节点之后，还需要监控这些后端节点。对于后端多个 FE 高可用负载均衡环境来说，这是必须的，因为 ProxySQL 需要通过每个节点的 `read_only` 值来自动调整

它们是属于读组还是写组。

首先在后端 master 主数据节点上创建一个用于监控的用户名

```
//在 Doris FE master 主数据库节点行执行：
mysql -P9030 -uroot -p
mysql> create user monitor@'192.168.9.%' identified by 'P@ssword1!';
Query OK, 0 rows affected (0.03 sec)
mysql> grant ADMIN_PRIV on *.* to monitor@'192.168.9.%;
Query OK, 0 rows affected (0.02 sec)

//然后回到mysql-proxy代理层节点上配置监控
mysql -uadmin -padmin -P6032 -h127.0.0.1
MySQL [(none)]> set mysql-monitor_username='monitor';
Query OK, 1 row affected (0.000 sec)

MySQL [(none)]> set mysql-monitor_password='P@ssword1!';
Query OK, 1 row affected (0.000 sec)

//修改后，加载到 RUNTIME，并保存 disk
MySQL [(none)]> load mysql variables to runtime;
Query OK, 0 rows affected (0.001 sec)

MySQL [(none)]> save mysql variables to disk;
Query OK, 94 rows affected (0.079 sec)

//验证监控结果：ProxySQL监控模块的指标都保存在monitor库的log表中。

//以下是连接是否正常的监控(对connect指标的监控)：

//注意：可能会有很多connect_error，这是因为没有配置监控信息时的错误，配置后如果connect_error的结果为NULL则表示正常。

MySQL [(none)]> select * from mysql_server_connect_log;
+-----+-----+-----+-----+-----+
| hostname | port | time_start_us | connect_success_time_us | connect_error |
+-----+-----+-----+-----+-----+
| 192.168.9.211 | 9030 | 1548665195883957 | 762 | NULL |
| 192.168.9.212 | 9030 | 1548665195894099 | 399 | NULL |
| 192.168.9.213 | 9030 | 1548665195904266 | 483 | NULL |
| 192.168.9.211 | 9030 | 1548665255883715 | 824 | NULL |
| 192.168.9.212 | 9030 | 1548665255893942 | 656 | NULL |
| 192.168.9.211 | 9030 | 1548665495884125 | 615 | NULL |
| 192.168.9.212 | 9030 | 1548665495894254 | 441 | NULL |
| 192.168.9.213 | 9030 | 1548665495904479 | 638 | NULL |
| 192.168.9.211 | 9030 | 1548665512917846 | 487 | NULL |
| 192.168.9.212 | 9030 | 1548665512928071 | 994 | NULL |
| 192.168.9.213 | 9030 | 1548665512938268 | 613 | NULL |
+-----+-----+-----+-----+-----+
20 rows in set (0.000 sec)
```

```
//以下是对心跳信息的监控(对ping指标的监控)

MySQL [(none)]> select * from mysql_server_ping_log;
+-----+-----+-----+-----+-----+
| hostname | port | time_start_us | ping_success_time_us | ping_error |
+-----+-----+-----+-----+-----+
| 192.168.9.211 | 9030 | 1548665195883407 | 98 | NULL |
| 192.168.9.212 | 9030 | 1548665195885128 | 119 | NULL |
| | | | | |
| 192.168.9.213 | 9030 | 1548665415889362 | 106 | NULL |
| 192.168.9.213 | 9030 | 1548665562898295 | 97 | NULL |
+-----+-----+-----+-----+-----+
110 rows in set (0.001 sec)

//read_only日志此时也为空(正常来说,新环境配置时,这个只读日志是为空的)

MySQL [(none)]> select * from mysql_server_read_only_log;
Empty set (0.000 sec)

//3个节点都在hostgroup_id=10的组中。

//现在,将刚才 mysql_replication_hostgroups 表的修改加载到RUNTIME生效。

MySQL [(none)]> load mysql servers to runtime;
Query OK, 0 rows affected (0.003 sec)

MySQL [(none)]> save mysql servers to disk;
Query OK, 0 rows affected (0.361 sec)

//现在看结果

MySQL [(none)]> select hostgroup_id,hostname,port,status,weight from mysql_servers;
+-----+-----+-----+-----+-----+
| hostgroup_id | hostname | port | status | weight |
+-----+-----+-----+-----+-----+
| 10 | 192.168.9.211 | 9030 | ONLINE | 1 |
| 20 | 192.168.9.212 | 9030 | ONLINE | 1 |
| 20 | 192.168.9.213 | 9030 | ONLINE | 1 |
+-----+-----+-----+-----+-----+
3 rows in set (0.000 sec)
```

## 配置 Doris 用户

上面的所有配置都是关于后端 Doris FE 节点的,现在可以配置关于 SQL 语句的,包括:发送 SQL 语句的用户、SQL 语句的路由规则、SQL 查询的缓存、SQL 语句的重写等等。

本小节是 SQL 请求所使用的用户配置,例如 root 用户。这要求我们需要先在后端 Doris FE 节点添加好相关用户。这里以 root 和 doris 两个用户名为例。

```
//首先,在Doris FE master主数据库节点上执行:

mysql -P9030 -uroot -p
.....
mysql> create user doris@%' identified by 'P@ssword1!';
Query OK, 0 rows affected, 1 warning (0.04 sec)

mysql> grant ADMIN_PRIV on *.* to doris@%';
Query OK, 0 rows affected, 1 warning (0.03 sec)

//然后回到 mysql-proxy 代理层节点,配置 mysql_users 表,将刚才的两个用户添加到该表中。
```



```

admin> insert into mysql_users(username,password,default_hostgroup) values('root','',10);
Query OK, 1 row affected (0.001 sec)

admin> insert into mysql_users(username,password,default_hostgroup) values('doris','P@ssword1!',10);
Query OK, 1 row affected (0.000 sec)

加载用户到运行环境中, 并将用户信息保存到磁盘
admin> load mysql users to runtime;
Query OK, 0 rows affected (0.001 sec)

admin> save mysql users to disk;
Query OK, 0 rows affected (0.108 sec)

// mysql_users 表有不少字段, 最主要的三个字段为 username、password 和default_hostgroup:

//- username: 前端连接ProxySQL, 以及ProxySQL将SQL语句路由给MySQL所使用的用户名。
//- password: 用户名对应的密码。可以是明文密码, 也可以是hash密码。如果想使用hash密码, 可以先在某个MySQL节点上执行

 select password(PASSWORD), 然后将加密结果复制到该字段。

//- default_hostgroup: 该用户名默认的路由目标。例如, 指定root用户的该字段值为10时, 则使用root用户发送的SQL语句默认
// 情况下将路由到hostgroup_id=10组中的某个节点。

admin> select * from mysql_users\G
***** 1. row *****
 username: root
 password:
 active: 1
 use_ssl: 0
 default_hostgroup: 10
 default_schema: NULL
 schema_locked: 0
transaction_persistent: 1
 fast_forward: 0
 backend: 1
 frontend: 1
 max_connections: 10000
***** 2. row *****
 username: doris
 password: P@ssword1!
 active: 1
 use_ssl: 0
 default_hostgroup: 10
 default_schema: NULL
 schema_locked: 0
transaction_persistent: 1
 fast_forward: 0
 backend: 1
 frontend: 1
 max_connections: 10000
2 rows in set (0.000 sec)

//虽然这里没有详细介绍mysql_users表, 但只有active=1的用户才是有效的用户。

MySQL [(none)]> load mysql users to runtime;
Query OK, 0 rows affected (0.001 sec)

MySQL [(none)]> save mysql users to disk;
Query OK, 0 rows affected (0.123 sec)

//这样就可以通过sql客户端, 使用doris的用户名密码去连接了ProxySQL了

```

## 通过 ProxySQL 连接 Doris 进行测试

下面，分别使用 root 用户和 doris 用户测试下它们是否能路由到默认的 hostgroup\_id=10 (它是一个写组) 读取数据。下面是通过转发端口 6033 连接的，连接的是转发到后端真正的数据库！

```
#mysql -uroot -p -P6033 -hdoris01 -e "show databases;"
Enter password:
ERROR 9001 (HY000) at line 1: Max connect timeout reached while reaching hostgroup 10 after 10000ms

//这个时候发现出错，并没有转发到后端真正的 Doris FE上

//通过日志看到有set autocommit=0 这样开启事务

//检查配置发现：
mysql-forward_autocommit=false
mysql-autocommit_false_is_transaction=false

//我们这里不需要读写分离，只需要将这两个参数通过下面语句直接搞成true就可以了

mysql> UPDATE global_variables SET variable_value='true' WHERE variable_name='mysql-forward_autocommit';
Query OK, 1 row affected (0.00 sec)

mysql> UPDATE global_variables SET variable_value='true' WHERE variable_name='mysql-
autocommit_false_is_transaction';
Query OK, 1 row affected (0.01 sec)

mysql> LOAD MYSQL VARIABLES TO RUNTIME;
Query OK, 0 rows affected (0.00 sec)

mysql> SAVE MYSQL VARIABLES TO DISK;
Query OK, 98 rows affected (0.12 sec)

//然后我们在重新试一下，显示成功

[root@doris01 ~]# mysql -udoris -pPassword1! -P6033 -h192.168.9.211 -e "show databases;"
Warning: Using a password on the command line interface can be insecure.
+-----+
| Database |
+-----+
| doris_audit_db |
| information_schema |
| retail |
+-----+
```

OK，到此就结束了，你就可以用 Mysql 客户端，JDBC 等任何连接 MySQL 的方式连接 ProxySQL 去操作你的 Doris 了

## Nginx TCP 反向代理方式

### 概述

Nginx 能够实现 HTTP、HTTPS 协议的负载均衡，也能够实现 TCP 协议的负载均衡。那么，问题来了，可不可以通过 Nginx 实现 Apache Doris 数据库的负载均衡呢？答案是：可以。接下来，就让我们一起探讨下如何使用 Nginx 实现 Apache Doris 的负载均衡。

### 环境准备

注意：使用 Nginx 实现 Apache Doris 数据库的负载均衡，前提是要搭建 Apache Doris 的环境，Apache Doris FE 的 IP 和端口分别如下所示，这里我是用一个 FE 来做演示的，多个 FE 只需要在配置里添加多个 FE

的 IP 地址和端口即可

通过 Nginx 访问 MySQL 的 Apache Doris 和端口如下所示。

```
IP: 172.31.7.119
端口: 9030
```

## 安装依赖

```
sudo apt-get install build-essential
sudo apt-get install libpcre3 libpcre3-dev
sudo apt-get install zlib1g-dev
sudo apt-get install openssl libssl-dev
```

## 安装 Nginx

```
sudo wget http://nginx.org/download/nginx-1.18.0.tar.gz
sudo tar zxvf nginx-1.18.0.tar.gz
cd nginx-1.18.0
sudo ./configure --prefix=/usr/local/nginx --with-stream --with-http_ssl_module --with-
http_gzip_static_module --with-http_stub_status_module
sudo make && make install
```

## 配置反向代理

这里是新建了一个配置文件

```
vim /usr/local/nginx/conf/default.conf
```

然后在里面加上下面的内容

```
events {
worker_connections 1024;
}
stream {
 upstream mysqld {
 hash $remote_addr consistent;
 server 172.31.7.119:9030 weight=1 max_fails=2 fail_timeout=60s;
 ##注意这里如果是多个FE，加载这里就行了
 }
 ###这里是配置代理的端口，超时时间等
 server {
 listen 6030;
 proxy_connect_timeout 300s;
 proxy_timeout 300s;
 proxy_pass mysqld;
 }
}
```

## 启动 Nginx

指定配置文件启动

```
cd /usr/local/nginx
/usr/local/nginx/sbin/nginx -c conf.d/default.conf
```

## 验证

```
mysql -uroot -P6030 -h172.31.7.119
```

参数解释： -u 指定 Doris 用户名

- -p 指定 Doris 密码，我这里密码是空，所以没有
- -h 指定 Nginx 代理服务器 IP
- -P 指定端口

```
mysql -uroot -P6030 -h172.31.7.119
Welcome to the MySQL monitor. Commands end with ; or \g.
Your MySQL connection id is 13
Server version: 5.1.0 Doris version 0.15.1-rc09-Unknown

Copyright (c) 2000, 2022, Oracle and/or its affiliates.

Oracle is a registered trademark of Oracle Corporation and/or its
affiliates. Other names may be trademarks of their respective
owners.

Type 'help;' or '\h' for help. Type '\c' to clear the current input statement.

mysql> show databases;
+-----+
| Database |
+-----+
| information_schema |
| test |
+-----+
2 rows in set (0.00 sec)

mysql> use test;
Reading table information for completion of table and column names
You can turn off this feature to get a quicker startup with -A

Database changed
mysql> show tables;
+-----+
| Tables_in_test |
+-----+
| dwd_product_live |
+-----+
1 row in set (0.00 sec)
mysql> desc dwd_product_live;
+-----+-----+-----+-----+-----+-----+
| Field | Type | Null | Key | Default | Extra |
+-----+-----+-----+-----+-----+-----+
| dt | DATE | Yes | true | NULL | |
| proId | BIGINT | Yes | true | NULL | |
| authorId | BIGINT | Yes | true | NULL | |
| roomId | BIGINT | Yes | true | NULL | |
| proTitle | VARCHAR(1024) | Yes | false | NULL | REPLACE |
| proLogo | VARCHAR(1024) | Yes | false | NULL | REPLACE |
```

shopId	BIGINT	Yes	false	NULL	REPLACE	
shopTitle	VARCHAR(1024)	Yes	false	NULL	REPLACE	
profrom	INT	Yes	false	NULL	REPLACE	
proCategory	BIGINT	Yes	false	NULL	REPLACE	
proPrice	DECIMAL(18,2)	Yes	false	NULL	REPLACE	
couponPrice	DECIMAL(18,2)	Yes	false	NULL	REPLACE	
livePrice	DECIMAL(18,2)	Yes	false	NULL	REPLACE	
volume	BIGINT	Yes	false	NULL	REPLACE	
addedTime	BIGINT	Yes	false	NULL	REPLACE	
offTimeUnix	BIGINT	Yes	false	NULL	REPLACE	
offTime	BIGINT	Yes	false	NULL	REPLACE	
createTime	BIGINT	Yes	false	NULL	REPLACE	
createTimeUnix	BIGINT	Yes	false	NULL	REPLACE	
amount	DECIMAL(18,2)	Yes	false	NULL	REPLACE	
views	BIGINT	Yes	false	NULL	REPLACE	
commissionPrice	DECIMAL(18,2)	Yes	false	NULL	REPLACE	
proCostPrice	DECIMAL(18,2)	Yes	false	NULL	REPLACE	
proCode	VARCHAR(1024)	Yes	false	NULL	REPLACE	
proStatus	INT	Yes	false	NULL	REPLACE	
status	INT	Yes	false	NULL	REPLACE	
maxPrice	DECIMAL(18,2)	Yes	false	NULL	REPLACE	
liveView	BIGINT	Yes	false	NULL	REPLACE	
firstCategory	BIGINT	Yes	false	NULL	REPLACE	
secondCategory	BIGINT	Yes	false	NULL	REPLACE	
thirdCategory	BIGINT	Yes	false	NULL	REPLACE	
fourCategory	BIGINT	Yes	false	NULL	REPLACE	
minPrice	DECIMAL(18,2)	Yes	false	NULL	REPLACE	
liveVolume	BIGINT	Yes	false	NULL	REPLACE	
liveClick	BIGINT	Yes	false	NULL	REPLACE	
extensionId	VARCHAR(128)	Yes	false	NULL	REPLACE	
beginTime	BIGINT	Yes	false	NULL	REPLACE	
roomTitle	TEXT	Yes	false	NULL	REPLACE	
beginTimeUnix	BIGINT	Yes	false	NULL	REPLACE	
nickname	TEXT	Yes	false	NULL	REPLACE	
+-----+-----+-----+-----+-----+-----+						
40 rows in set (0.06 sec)						

## Haproxy 方式

HAProxy是一个使用C语言编写的自由及开放源代码软件，其提供高可用性、负载均衡，以及基于TCP和HTTP的应用程序代理。

### 安装

#### 1. 下载 HAProxy

下载地址：<https://src.fedoraproject.org/repo/pkgs/haproxy/>

#### 2. 解压

```
tar -zxvf haproxy-2.6.15.tar.gz -C /opt/
mv haproxy-2.6.15 haproxy
```

#### 3. 编译

进入到 haproxy 目录中

```
yum install gcc gcc-c++ -y

make TARGET=linux-glibc PREFIX=/usr/local/haproxy

make install PREFIX=/usr/local/haproxy
```

## 配置

### 1. 配置 haproxy.conf 文件

```
vim /etc/rsyslog.d/haproxy.conf
```

```
$ModLoad imudp
$UDPServerRun 514
local0.* /usr/local/haproxy/logs/haproxy.log
&~
```

### 2. 开启远程日志

```
vim /etc/sysconfig/rsyslog
```

```
SYSLOGD_OPTIONS="-c 2 -r -m 0"
```

参数解析：

- -c 2 使用兼容模式，默认是 -c 5。-r 开启远程日志
- -m 0 标记时间戳。单位是分钟，为0时，表示禁用该功能

### 3. 使修改生效

```
systemctl restart rsyslog
```

### 4. 编辑负载均衡文件

```
vim /usr/local/haproxy/haproxy.cfg
```

```
#
haproxy 部署在 172.16.0.3, 这台机器上, 用来代理 172.16.0.8,172.16.0.6,172.16.0.4 这三台部署 fe 的机器
#

global
 maxconn 2000
 ulimit-n 40075
 log 127.0.0.1 local0 info
 uid 200
 gid 200
 chroot /var/empty
 daemon
 group haproxy
 user haproxy

defaults
 # 应用全局的日志配置
 log global
 mode http
```

```

retries 3 # 健康检查。3次连接失败就认为服务器不可用，主要通过后面的check检查
option redispatch # 服务不可用后重定向到其他健康服务器
超时配置
timeout connect 5000
timeout client 5000
timeout server 5000
timeout check 2000

frontend agent-front
bind *:9030 # 代理机器上的转换端口
mode tcp
default_backend forward-fe

backend forward-fe
mode tcp
balance roundrobin
server fe-1 172.16.0.8:9030 weight 1 check inter 3000 rise 2 fall 3
server fe-2 172.16.0.4:9030 weight 1 check inter 3000 rise 2 fall 3
server fe-3 172.16.0.6:9030 weight 1 check inter 3000 rise 2 fall 3

listen http_front # haproxy的客户页面
bind *:8888 # HAProxy WEB 的IP地址
mode http
log 127.0.0.1 local0 err
option httplog
stats uri /haproxy # 自定义页面的 url (即访问时地址为: 172.16.0.3:8888/haproxy)
stats auth admin:admin # 控制面板账号密码 账号: admin
stats refresh 10s
stats enable

```

## 启动

### 1. 启动服务

```
/opt/haproxy/haproxy -f /usr/local/haproxy/haproxy.cfg
```

### 2. 查看服务状态

```
netstat -lnatp | grep -i haproxy
```

### 3. WEB 访问

ip:8888/haproxy

登陆密码: admin : admin

注意: WEB 登陆的端口、账户、密码需要在 haproxy.cfg 文件中配置

### 4. 测试端口是否转换成功

```
mysql -h 172.16.0.3 -uroot -P3307 -p
```

# 时区管理

---

Doris 支持自定义时区设置

## 基本概念

Doris 内部存在以下两个时区相关参数：

- `system_time_zone`：当服务器启动时，会根据机器设置时区自动设置，设置后不可修改。
- `time_zone`：集群当前时区，可以修改。集群启动时，该变量会设置为与 `system_time_zone` 相同，之后不再变动，除非用户手动修改。

## 具体操作

```
1. show variables like '%time_zone%'
```

查看当前时区相关配置

```
2. SET [global] time_zone = 'Asia/Shanghai'
```

该命令可以设置 Session 级别的时区，如使用 `global` 关键字，则 Doris FE 会将参数持久化，之后对所有新 Session 生效。

## 数据来源

时区数据包含时区名、对应时间偏移量、夏令时变化情况等。在 BE 所在机器上，其数据来源为 `TZDIR` 命令返回的目录，如不支持该命令，则为 `/usr/share/zoneinfo` 目录。

## 时区的影响

### 1. 函数

包括 `NOW()` 或 `CURTIME()` 等时间函数显示的值，也包括 `show load`, `show backends` 中的时间值。

但不会影响 `create table` 中时间类型分区列的 `less than` 值，也不会影响存储为 `date/datetime` 类型的值的显示。

受时区影响的函数：

- `FROM_UNIXTIME`：给定一个 UTC 时间戳，返回其在 Doris Session `time_zone` 指定时区的日期时间，如 `time_zone` 为 CST 时 `FROM_UNIXTIME(0)` 返回 `1970-01-01 08:00:00`。
- `UNIX_TIMESTAMP`：给定一个日期时间，返回其在 Doris Session `time_zone` 指定时区下的 UTC 时间戳，如 `time_zone` 为 CST 时 `UNIX_TIMESTAMP('1970-01-01 08:00:00')` 返回 `0`。
- `CURTIME`：返回当前 Doris Session `time_zone` 指定时区的时间。



- NOW: 返回当前 Doris Session time\_zone 指定时区的日期时间。
- CONVERT\_TZ: 将一个日期时间从一个指定时区转换到另一个指定时区。

## 2. 时间类型的值

对于DATE、DATETIME类型，我们支持导入数据时对时区进行转换。

- 如果数据带有时区，如“2020-12-12 12:12:12+08:00”，而 Stream Load 指定的 header timezone 为 +00:00，则数据导入 Doris 得到实际值为“2020-12-12 04:12:12”。
- 如果数据不带有时区，如“2020-12-12 12:12:12”，则认为该时间为绝对时间，不发生任何转换。

## 3. 夏令时

夏令时的本质是具名时区的实际时间偏移量，在一定日期内发生改变。

例如，America/Los\_Angeles时区包含一次夏令时调整，起止时间为约为每年3月至11月。即，三月份夏令时开始时，America/Los\_Angeles实际时区偏移由-08:00变为-07:00，11月夏令时结束时，又从-07:00变为-08:00。如果不希望开启夏令时，则应设定 time\_zone 为 -08:00 而非 America/Los\_Angeles。

## 使用方式

时区值可以使用多种格式给出，以下是 Doris 中完善支持的标准格式：

1. 标准具名时区格式，如“Asia/Shanghai”，“America/Los\_Angeles”。此类格式来源于[本机所带时区数据](#)，如“Etc/GMT+3”等亦属此列。
2. 标准偏移格式，如“+02:30”，“-10:00”（不支持诸如“+12:03”等特殊偏移）
3. 缩写时区格式，当前仅支持：

1. “GMT”，“UTC”，等同于“+00:00”时区
2. “CST”，等同于“Asia/Shanghai”时区
4. 单字母 Z，代表 Zulu 时区，等同于“+00:00”时区

此外，对任何字母的解析不区分大小写。

注意：由于实现方式的不同，当前 Doris 存在部分其他格式在部分导入方式中得到了支持。生产环境不应当依赖这些未列于此的格式，它们的行为随时可能发生变化，请关注版本更新时的相关 changelog。

## 最佳实践

### 时区敏感数据

时区问题主要涉及三个影响因素：

1. Session Variable time\_zone —— 集群时区
2. Stream Load、Broker Load 等导入时指定的 header timezone —— 导入时区

### 3. 时区类型字面量 “2023-12-12 08:00:00+08:00” 中的 “+08:00” —— 数据时区

我们可以做如下理解：

Doris 目前兼容各时区下的数据向 Doris 中进行导入。而由于 Doris 自身 DATETIME 等各个时间类型本身不内含时区信息，且数据在导入后不会随时区变化而变更，因此时间数据导入 Doris 时，可分为如下两类：

#### 1. 绝对时间

绝对时间是指，它所关联的数据场景与时区无关。对于这类数据，在导入时应该不带有任何时区后缀，它们将被原样存储。

#### 2. 特定时区下的时间

某个特定时区下的时间是指，它所关联的数据场景与时区有关。对于这类数据，在导入时应该带有具体时区后缀，导入时它们将被转化至 Doris 集群 time\_zone 时区或 Stream Load/Broker Load 中指定的 header timezone。

这类数据在导入后即被转化至导入时指定时区下的绝对时间存储，故后续导入和查询应当保持此时区，以免数据意义发生紊乱。

- 对于 Insert 语句，我们可以通过以下例子来说明：

```
Doris > select @@time_zone;
+-----+
| @@time_zone |
+-----+
| Asia/Shanghai |
+-----+

Doris > insert into dt values('2020-12-12 12:12:12+02:00'); --- 导入的数据中指定了时区为 +02:00

Doris > select * from dt;
+-----+
| dt |
+-----+
| 2020-12-12 18:12:12 | --- 被转换为 Doris 集群时区 Asia/Shanghai，后续导入和查询应当保持此时区。
+-----+

Doris > set time_zone = 'America/Los_Angeles';

Doris > select * from dt;
+-----+
| dt |
+-----+
| 2020-12-12 18:12:12 | --- 如果修改 time_zone，时间值不会随之改变，其查询时的意义发生紊乱。
+-----+
```

- 对于 Stream Load、Broker Load 等导入方式，我们可以通过指定 Header timezone 来实现。例如，对于 Stream Load，我们可以通过以下例子来说明：

```
cat dt.csv
2020-12-12 12:12:12+02:00

curl --location-trusted -u root: \
-H "Expect:100-continue" \
-H "strict_mode: true" \
-H "timezone: Asia/Shanghai" \
```

```
-T dt.csv -XPUT \
http://127.0.0.1:8030/api/test/dt/_stream_load
```

```
Doris > select @@time_zone;
+-----+
| @@time_zone |
+-----+
| Asia/Shanghai |
+-----+

Doris > select * from dt;
+-----+
| dt |
+-----+
| 2020-12-12 18:12:12 | --- 被转换为 Doris 集群时区 Asia/Shanghai, 后续导入和查询应当保持此时区。
+-----+
```

- Stream Load、Broker Load 等导入方式中，header timezone 会覆盖 Doris 集群 time\_zone，因此在此导入时应当保持一致。
- Stream Load、Broker Load 等导入方式中，header timezone 会影响导入转换中使用的函数。
- 如果导入时未指定 header timezone，则默认使用东八区。

综上所述，处理时区问题最佳的实践是：

### 最佳实践

1. 在使用前确认该集群所表征的时区并设置 time\_zone，在此之后不再更改。
2. 在导入时设定 header timezone 同集群 time\_zone 一致。
3. 对于绝对时间，导入时不带时区后缀；对于有时区的时间，导入时带具体时区后缀，导入后将被转化至 Doris time\_zone 时区。

## 夏令时

夏令时的起讫时间来自[当前时区数据源](#)，不一定与当年度时区所在地官方实际确认时间完全一致。该数据由 ICANN 进行维护。如果需要确保夏令时表现与当年度实际规定一致，请保证 Doris 所选择的数据源为最新的 ICANN 所公布时区数据，下载途径见下文。

## 信息更新

真实世界中的时区与夏令时相关数据，将会因各种原因而不定期发生变化。IANA 会定期记录这些变化并更新相应时区文件。如果希望 Doris 中的时区信息与最新的 IANA 数据保持一致，请采取下列方式进行更新：

1. 使用包管理器更新

根据当前操作系统使用的包管理器，用户可以使用对应的命令直接更新时区数据：

```
yum
> sudo yum update tzdata
```

```
apt
> sudo apt update tzdata
```

该方式更新的数据位于系统 \$TZDIR 下（一般为 usr/share/zoneinfo）。

## 2. 直接拉取 IANA 时区数据库（推荐）

大多数 Linux 发行版的包管理器，tzdata 的同步并不及时。如果对时区数据准确性要求较高，可以直接拉取 IANA 定期公布的数据：

```
wget https://www.iana.org/time-zones/repository/tzdb-latest.tar.gz
```

然后根据解压后文件夹中的 README 文件，生成具体的 zoneinfo 数据。生成的数据应当拷贝并覆盖 \$TZDIR 目录。

请注意，以上所有操作在 BE 所在机器上完成后，都必须重启对应 BE 才能生效。

## 拓展阅读

- 时区格式列表：[List of tz database time zones](#)
- IANA 时区数据库：[IANA Time Zone Database](#)
- ICANN 时区数据库：[The tz-announce Archives](#)

# FQDN

---

本文介绍如何启用基于 FQDN（Fully Qualified Domain Name，完全限定域名）使用 Apache Doris。FQDN 是 Internet 上特定计算机或主机的完整域名。

Doris 支持 FQDN 之后，各节点之间通信完全基于 FQDN。添加各类节点时应直接指定 FQDN，例如添加 BE 节点的命令为 ALTER SYSTEM ADD BACKEND "be\_host:heartbeat\_service\_port",

“be\_host”此前是 BE 节点的 IP，启动 FQDN 后，be\_host 应指定 BE 节点的 FQDN。

## 前置条件

1. fe.conf 文件 设置 enable\_fqdn\_mode = true。
2. 集群中的所有机器都必须配置有主机名。
3. 必须在集群中每台机器的 /etc/hosts 文件中指定集群中其他机器对应的 IP 地址和 FQDN。
4. /etc/hosts 文件中不能有重复的 IP 地址。

## 最佳实践

### 新集群启用 FQDN

1. 准备机器，例如想部署 3FE 3BE 的集群，可以准备 6 台机器。
2. 每台机器执行 host 返回结果都唯一，假设六台机器的执行结果分别为 fe1,fe2,fe3,be1,be2,be3。
3. 在 6 台机器的 /etc/hosts 中配置 6 个 FQDN 对应的真实 IP，例如：

```
172.22.0.1 fe1
172.22.0.2 fe2
172.22.0.3 fe3
172.22.0.4 be1
172.22.0.5 be2
172.22.0.6 be3
```

4. 验证：可以在 FE1 上 ping fe2 等，能解析出正确的 IP 并且能 Ping 通，代表网络环境可用。
5. 每个 FE 节点的 fe.conf 设置 enable\_fqdn\_mode = true。
6. 参考[手动部署](#)
7. 按需在六台机器上选择几台机器部署 broker，执行 ALTER SYSTEM ADD BROKER broker\_name "fe1:8000","be1:8000",...;。

## K8s 部署 Doris

Pod 意外重启后，K8s 不能保证 Pod 的 IP 不发生变化，但是能保证域名不变，基于这一特性，Doris 开启 FQDN 时，能保证 Pod 意外重启后，还能正常提供服务。

K8s 部署 Doris 的方法请参考[K8s 部署 Doris](#)

## 服务器变更 IP

按照'新集群启用 FQDN'部署好集群后，如果想变更机器的 IP，无论是切换网卡，或者是更换机器，只需要更改各机器的/etc/hosts即可。

## 旧集群启用 FQDN

前提条件：当前程序支持ALTER SYSTEM MODIFY FRONTEND "<fe\_ip>:<edit\_log\_port>" HOSTNAME "<fe\_hostname>"语法， 如果不支持，需要升级到支持该语法的版本

### 注意：

至少有三台 follower 才能进行如下操作，否则会造成集群无法正常启动

接下来按照如下步骤操作：

### 1. 逐一对 Follower、Observer 节点进行以下操作 (最后操作 Master 节点)：

1. 停止节点。
2. 检查节点是否停止。通过 MySQL 客户端执行show frontends，查看该 FE 节点的 Alive 状态直至变为 false
3. 为节点设置 FQDN: ALTER SYSTEM MODIFY FRONTEND "<fe\_ip>:<edit\_log\_port>" HOSTNAME "<fe\_hostname>"（停掉 master 后，会选举出新的 master 节点，用新的 master 节点来执行 sql 语句）
4. 修改节点配置。修改 FE 根目录中的conf/fe.conf文件，添加配置：enable\_fqdn\_mode = true。如果在刚停止的节点对应 fe.config 添加了配置后无法正常启动，请在所有 fe.config 中添加配置 enable\_fqdn\_mode = true后再启动刚刚停止的 fe 节点
5. 启动节点。

### 2. BE 节点启用 FQDN 只需要通过 MySQL 执行以下命令，不需要对 BE 执行重启操作。

ALTER SYSTEM MODIFY BACKEND "<backend\_ip>:<HeartbeatPort>" HOSTNAME "<be\_hostname>", 如果你不知道端口 HeartbeatPort 是多少，请使用 show backends 命令来帮助寻找此端口；

## 常见问题

- 配置项 enable\_fqdn\_mode 可以随意更改么？

不能随意更改，更改该配置要按照'旧集群启用 FQDN'进行操作。

# 数据备份

## 数据备份

Doris 支持将当前数据以文件的形式备份到 HDFS 和对象存储。之后可以通过恢复命令，从远端存储系统中将数据恢复到任意 Doris 集群。通过这个功能，Doris 可以支持将数据定期地进行快照备份。也可以通过这个功能，在不同集群间进行数据迁移，集群间无损迁移可以使用 CCR (ccr.md)。

该功能需要 Doris 版本 0.8.2+

## 原理说明

备份操作是将指定表或分区的数据，直接以 Doris 存储的文件的形式，上传到远端仓库中进行存储。当用户提交 Backup 请求后，系统内部会做如下操作：

### 1. 快照及快照上传

快照阶段会对指定的表或分区数据文件进行快照。之后，备份都是对快照进行操作。在快照之后，对表进行的更改、导入等操作都不再影响备份的结果。快照只是对当前数据文件产生一个硬链，耗时很少。快照完成后，会开始对这些快照文件进行逐一上传。快照上传由各个 Backend 并发完成。

### 2. 元数据准备及上传

数据文件快照上传完成后，Frontend 会首先将对应元数据写成本地文件，然后通过 broker 将本地元数据文件上传到远端仓库。完成最终备份作业

### 3. 动态分区表说明

如果该表是动态分区表，备份之后会自动禁用动态分区属性，在做恢复的时候需要手动将该表的动态分区属性启用，命令如下：

```
ALTER TABLE tbl1 SET ("dynamic_partition.enable"="true")
```

### 4. 备份和恢复操作都不会保留表的 colocate\_with 属性。

## 开始备份

### 1. 创建一个 HDFS 的远程仓库 example\_repo (S3 存储请参考 2)：

```
CREATE REPOSITORY `example_repo`
WITH HDFS
ON LOCATION "hdfs://hadoop-name-node:54310/path/to/repo/"
PROPERTIES
(
 "fs.defaultFS"="hdfs://hdfs_host:port",
 "hadoop.username" = "hadoop"
);
```

## 2. 创建一个 s3 的远程仓库 : s3\_repo (HDFS 存储请参考 1)

```
CREATE REPOSITORY `s3_repo`
WITH S3
ON LOCATION "s3://bucket_name/test"
PROPERTIES
(
 "AWS_ENDPOINT" = "http://xxxx.xxx.com",
 "AWS_ACCESS_KEY" = "xxxx",
 "AWS_SECRET_KEY"="xxx",
 "AWS_REGION" = "xxx"
);
```

注意:

ON LOCATION 这里后面跟的是 Bucket Name

## 3. 全量备份 example\_db 下的表 example\_tbl 到仓库 example\_repo 中:

```
BACKUP SNAPSHOT example_db.snapshot_label1
TO example_repo
ON (example_tbl)
PROPERTIES ("type" = "full");
```

## 4. 全量备份 example\_db 下, 表 example\_tbl 的 p1, p2 分区, 以及表 example\_tbl2 到仓库 example\_repo 中:

```
BACKUP SNAPSHOT example_db.snapshot_label2
TO example_repo
ON
(
 example_tbl PARTITION (p1,p2),
 example_tbl2
);
```

## 5. 查看最近 backup 作业的执行情况:

```
mysql> show BACKUP\G;
***** 1. row *****
 JobId: 17891847
 SnapshotName: snapshot_label1
 DbName: example_db
 State: FINISHED
 BackupObjs: [default_cluster:example_db.example_tbl]
 CreateTime: 2022-04-08 15:52:29
SnapshotFinishedTime: 2022-04-08 15:52:32
UploadFinishedTime: 2022-04-08 15:52:38
 FinishedTime: 2022-04-08 15:52:44
UnfinishedTasks:
 Progress:
 TaskErrMsg:
 Status: [OK]
 Timeout: 86400
1 row in set (0.01 sec)
```



## 6. 查看远端仓库中已存在的备份

```
mysql> SHOW SNAPSHOT ON example_repo WHERE SNAPSHOT = "snapshot_label1";
+-----+-----+-----+
| Snapshot | Timestamp | Status |
+-----+-----+-----+
| snapshot_label1 | 2022-04-08-15-52-29 | OK |
+-----+-----+-----+
1 row in set (0.15 sec)
```

BACKUP 的更多用法可参考 [这里](#)。

## 最佳实践

### 备份

当前我们支持最小分区（Partition）粒度的全量备份（增量备份有可能在未来版本支持）。如果需要对数据进行定期备份，首先需要在建表时，合理的规划表的分区及分桶，比如按时间进行分区。然后在之后的运行过程中，按照分区粒度进行定期的数据备份。

### 数据迁移

用户可以先将数据备份到远端仓库，再通过远端仓库将数据恢复到另一个集群，完成数据迁移。因为数据备份是通过快照的形式完成的，所以，在备份作业的快照阶段之后的新的导入数据，是不会备份的。因此，在快照完成后，到恢复作业完成这期间，在原集群上导入的数据，都需要在新集群上同样导入一遍。

建议在迁移完成后，对新旧两个集群并行导入一段时间。完成数据和业务正确性校验后，再将业务迁移到新的集群。

## 说明

1. 备份恢复相关的操作目前只允许拥有 ADMIN 权限的用户执行。
2. 一个 Database 内，只允许有一个正在执行的备份或恢复作业。
3. 备份和恢复都支持最小分区（Partition）级别的操作，当表的数据量很大时，建议按分区分别执行，以降低失败重试的代价。
4. 因为备份恢复操作，操作的都是实际的数据文件。所以当表的分片过多，或者一个分片有过小的小版本时，可能即使总数据量很小，依然需要备份或恢复很长时间。用户可以通过 `SHOW PARTITIONS FROM table_name;` 和 `SHOW TABLETS FROM table_name;` 来查看各个分区的分片数量，以及各个分片的文件版本数量，来预估作业执行时间。文件数量对作业执行的时间影响非常大，所以建议在建表时，合理规划分区分桶，以避免过多的分片。
5. 当通过 `SHOW BACKUP` 或者 `SHOW RESTORE` 命令查看作业状态时。有可能会在 TaskErrMsg 一列中看到错误信息。但只要 State 列不为 CANCELLED，则说明作业依然在继续。这些 Task 有可能会重试成功。当然，有些 Task 错误，也会直接导致作业失败。常见的 TaskErrMsg 错误如下：Q1：备份到 HDFS，状态显示 UPLOADING，TaskErrMsg 错误信息：[13333: Close broker writer failed, broker:TNetworkAddress(hostname=10.10.0.0,port=8000) msg:errors while close file output stream, cause by: DataStreamer Exception: ] 这个一般是网络通信问题，查看broker日志，看某个ip 或者端口不通，如果是云服务，则需要查看是否访问了内网，如果是，则可以在borker/conf文件夹下添加hdfs-site.xml，还需在hdfs-site.xml配置文件下添加dfs.client.use.datanode.hostname=true，并在broker节点上配置HADOOP集群的主机名映射。

6. 如果恢复作业是一次覆盖操作（指定恢复数据到已经存在的表或分区中），那么从恢复作业的 COMMIT 阶段开始，当前集群上被覆盖的数据有可能不能再被还原。此时如果恢复作业失败或被取消，有可能造成之前的数据已损坏且无法访问。这种情况下，只能通过再次执行恢复操作，并等待作业完成。因此，我们建议，如无必要，尽量不要使用覆盖的方式恢复数据，除非确认当前数据已不再使用。

## 相关命令

和备份恢复功能相关的命令如下。以下命令，都可以通过 `mysql-client` 连接 Doris 后，使用 `help cmd;` 的方式查看详细帮助。

### 1. CREATE REPOSITORY

创建一个远端仓库路径，用于备份或恢复。具体参考 [创建远程仓库文档](#)。

### 2. BACKUP

执行一次备份操作。具体参考 [备份文档](#)。

### 3. SHOW BACKUP

查看最近一次 backup 作业的执行情况。具体参考 [查看备份作业文档](#)。

### 4. SHOW SNAPSHOT

查看远端仓库中已存在的备份。具体参考 [查看备份文档](#)。

### 5. CANCEL BACKUP

取消当前正在执行的备份作业。具体参考[取消备份作业文档](#)。

### 6. DROP REPOSITORY

删除已创建的远端仓库。删除仓库，仅仅是删除该仓库在 Doris 中的映射，不会删除实际的仓库数据。具体参考 [删除远程仓库文档](#)。

# 数据备份恢复

Doris 支持将当前数据以文件的形式，通过 broker 备份到远端存储系统中。之后可以通过 恢复 命令，从远端存储系统中将数据恢复到任意 Doris 集群。通过这个功能，Doris 可以支持将数据定期的进行快照备份。也可以通过这个功能，在不同集群间进行数据迁移。

该功能需要 Doris 版本 0.8.2+

使用该功能，需要部署对应远端存储的 broker。如 BOS、HDFS 等。可以通过 SHOW BROKER; 查看当前部署的 broker。

## 简要原理说明

恢复操作需要指定一个远端仓库中已存在的备份，然后将这个备份的内容恢复到本地集群中。当用户提交 Restore 请求后，系统内部会做如下操作：

### 1. 在本地创建对应的元数据

这一步首先会在本地集群中，创建恢复对应的表分区等结构。创建完成后，该表可见，但是不可访问。

### 2. 本地 snapshot

这一步是将上一步创建的表做一个快照。这其实是一个空快照（因为刚创建的表是没有数据的），其目的主要是在 Backend 上产生对应的快照目录，用于之后接收从远端仓库下载的快照文件。

### 3. 下载快照

远端仓库中的快照文件，会被下载到对应的上一步生成的快照目录中。这一步由各个 Backend 并发完成。

### 4. 生效快照

快照下载完成后，我们要将各个快照映射为当前本地表的元数据。然后重新加载这些快照，使之生效，完成最终的恢复作业。

## 开始恢复

1. 从 example\_repo 中恢复备份 snapshot\_1 中的表 backup\_tbl 到数据库 example\_db1，时间版本为“2018-05-04-16-45-08”。恢复为 1 个副本：

```
RESTORE SNAPSHOT example_db1.`snapshot_1`
FROM `example_repo`
ON (`backup_tbl`)
PROPERTIES
(
 "backup_timestamp"="2022-04-08-15-52-29",
 "replication_num" = "1"
);
```

2. 从 example\_repo 中恢复备份 snapshot\_2 中的表 backup\_tbl 的分区 p1,p2, 以及表 backup\_tbl2 到数据库 example\_db1, 并重命名为 new\_tbl, 时间版本为 “2018-05-04-17-11-01”。默认恢复为 3 个副本:

```
RESTORE SNAPSHOT example_db1.`snapshot_2`
FROM `example_repo`
ON
(
 `backup_tbl` PARTITION (`p1`, `p2`),
 `backup_tbl2` AS `new_tbl`
)
PROPERTIES
(
 "backup_timestamp"="2022-04-08-15-55-43"
);
```

3. 查看 restore 作业的执行情况:

```
mysql> SHOW RESTORE\G;
***** 1. row *****
 JobId: 17891851
 Label: snapshot_label1
 Timestamp: 2022-04-08-15-52-29
 DbName: default_cluster:example_db1
 State: FINISHED
 AllowLoad: false
 ReplicationNum: 3
 RestoreObjs: {
 "name": "snapshot_label1",
 "database": "example_db",
 "backup_time": 1649404349050,
 "content": "ALL",
 "olap_table_list": [
 {
 "name": "backup_tbl",
 "partition_names": [
 "p1",
 "p2"
]
 }
],
 "view_list": [],
 "odbc_table_list": [],
 "odbc_resource_list": []
 }
 CreateTime: 2022-04-08 15:59:01
 MetaPreparedTime: 2022-04-08 15:59:02
 SnapshotFinishedTime: 2022-04-08 15:59:05
 DownloadFinishedTime: 2022-04-08 15:59:12
 FinishedTime: 2022-04-08 15:59:18
 UnfinishedTasks:
 Progress:
 TaskErrMsg:
 Status: [OK]
 Timeout: 86400
1 row in set (0.01 sec)
```

RESTORE 的更多用法可参考 [这里](#)。

## 相关命令

和备份恢复功能相关的命令如下。以下命令，都可以通过 `mysql-client` 连接 Doris 后，使用 `help cmd;` 的方式查看详细帮助。

### 1. CREATE REPOSITORY

创建一个远端仓库路径，用于备份或恢复。该命令需要借助 Broker 进程访问远端存储，不同的 Broker 需要不同的参数，具体请参阅 [Broker 文档](#)，也可以直接通过 S3 协议备份到支持 AWS S3 协议的远程存储上去，也可以直接备份到 HDFS，具体参考 [创建远程仓库文档](#)

### 2. RESTORE

执行一次恢复操作。

#### 3. SHOW RESTORE

查看最近一次 restore 作业的执行情况，包括：

- JobId：本次恢复作业 id。
- Label：用户指定的仓库中备份的名称（Label）。
- Timestamp：用户指定的仓库中备份的时间戳。
- DbName：恢复作业对应的 Database。
- State：恢复作业当前所在阶段：
  - PENDING：作业初始状态。
  - SNAPSHOTING：正在进行本地新建表的快照操作。
  - DOWNLOAD：正在发送下载快照任务。
  - DOWNLOADING：快照正在下载。
  - COMMIT：准备生效已下载的快照。
  - COMMITTING：正在生效已下载的快照。
  - FINISHED：恢复完成。
  - CANCELLED：恢复失败或被取消。
- AllowLoad：恢复期间是否允许导入。
- ReplicationNum：恢复指定的副本数。
- RestoreObjs：本次恢复涉及的表和分区的清单。
- CreateTime：作业创建时间。
- MetaPreparedTime：本地元数据生成完成时间。
- SnapshotFinishedTime：本地快照完成时间。

- DownloadFinishedTime: 远端快照下载完成时间。
- FinishedTime: 本次作业完成时间。
- UnfinishedTasks: 在 SNAPSHOTTING, DOWNLOADING, COMMITTING 等阶段, 会有多个子任务在同时 进行, 这里展示的当前阶段, 未完成的子任务的 task id。
- TaskErrMsg: 如果有子任务执行出错, 这里会显示对应子任务的错误信息。
- Status: 用于记录在整个作业过程中, 可能出现的一些状态信息。
- Timeout: 作业的超时时间, 单位是秒。

#### 4. CANCEL RESTORE

取消当前正在执行的恢复作业。

#### 5. DROP REPOSITORY

删除已创建的远端仓库。删除仓库, 仅仅是删除该仓库在 Doris 中的映射, 不会删除实际的仓库数据。

### 常见错误

#### 1. RESTORE 报错: [20181: invalid md5 of downloaded

file:/data/doris.HDD/snapshot/20220607095111.862.86400/19962/668322732/19962.hdr, expected: f05b63cca5533ea0466f62a9897289b5, get: d41d8cd98f00b204e9800998ecf8427e]

备份和恢复的表的副本数不一致导致的, 执行恢复命令时需指定副本个数, 具体命令请参阅[RESTORE](#) 命令手册

#### 2. RESTORE 报错: [COMMON\_ERROR, msg: Could not set meta version to 97 since it is lower than minimum required version 100]

备份和恢复不是同一个版本导致的, 使用指定的 meta\_version 来读取之前备份的元数据。注意, 该参数作为临时方案, 仅用于恢复老版本 Doris 备份的数据。最新版本的备份数据中已经包含 meta version, 无需再指定, 针对上述错误具体解决方案指定 meta\_version = 100, 具体命令请参阅[RESTORE](#) 命令手册

### 更多帮助

关于 RESTORE 使用的更多详细语法及最佳实践, 请参阅 [RESTORE](#) 命令手册, 你也可以在 MySQL 客户端命令行下输入 HELP RESTORE 获取更多帮助信息。

# 跨集群数据同步

---

## 概览

CCR(Cross Cluster Replication) 是跨集群数据同步，能够在库/表级别将源集群的数据变更同步到目标集群，可用于在线服务的数据可用性、隔离在离线负载、建设两地三中心。

CCR 通常被用于容灾备份、读写分离、集团与公司间数据传输和隔离升级等场景。

- 容灾备份：通常是将企业的数据备份到另一个集群与机房中，当突发事件导致业务中断或丢失时，可以从备份中恢复数据或快速进行主备切换。一般在对 SLA 要求比较高的场景中，都需要进行容灾备份，比如在金融、医疗、电子商务等领域中比较常见。
- 读写分离：读写分离是将数据的查询操作和写入操作进行分离，目的是降低读写操作的相互影响并提升资源的利用率。比如在数据库写入压力过大或在高并发场景中，采用读写分离可以将读/写操作分散到多个地域的只读/只写的数据库案例上，减少读写间的互相影响，有效保证数据库的性能及稳定性。
- 集团与分公司间数据传输：集团总部为了对集团内数据进行统一管控和分析，通常需要分布在各地域的分公司及时将数据传输同步到集团总部，避免因数据不一致而引起的管理混乱和决策错误，有利于提高集团的管理效率和决策质量。
- 隔离升级：当在对系统集群升级时，有可能因为某些原因需要进行版本回滚，传统的升级模式往往会因为元数据不兼容的原因无法回滚。而使用 CCR 可以解决该问题，先构建一个备用的集群进行升级并双跑验证，用户可以依次升级各个集群，同时 CCR 也不依赖特定版本，使版本的回滚变得可行。

## 原理

### 名词解释


源集群：源头集群，业务数据写入的集群，需要 2.0 版本

目标集群：跨集群同步的目标集群，需要 2.0 版本

binlog：源集群的变更日志，包括 schema 和数据变更

syncer：一个轻量级的进程

## 架构说明



### ccr 架构说明

CCR 工具主要依赖一个轻量级进程：Syncers。Syncers 会从源集群获取 binlog，直接将元数据应用于目标集群，通知目标集群从源集群拉取数据。从而实现全量和增量迁移。

## 使用

使用非常简单，只需把 Syncers 服务启动，给他发一个命令，剩下的交给 Syncers 完成就行。

### 1. 部署源 Doris 集群

### 2. 部署目标 Doris 集群

3. 首先源集群和目标集群都需要打开 binlog，在源集群和目标集群的 `fe.conf` 和 `be.conf` 中配置如下信息：

```
enable_feature_binlog=true
```

### 4. 部署 syncers

#### 1. 构建 CCR syncer

```
git clone https://github.com/selectdb/ccr-syncer
cd ccr-syncer

bash build.sh <--j NUM_OF_THREAD> <---output SYNCER_OUTPUT_DIR>

cd SYNCER_OUTPUT_DIR# 联系相关同学免费获取 ccr 二进制包
```

#### 2. 启动和停止 syncer

```
启动
cd bin && sh start_syncer.sh --daemon

停止
sh stop_syncer.sh
```

### 5. 打开源集群中同步库/表的 Binlog



```
-- 如果是整库同步，可以执行如下脚本，使得该库下面所有的表都要打开 binlog.enable
vim shell/enable_db_binlog.sh
修改源集群的 host、port、user、password、db
或者 ./enable_db_binlog.sh --host $host --port $port --user $user --password $password --db $db

-- 如果是单表同步，则只需要打开 table 的 binlog.enable，在源集群上执行：
ALTER TABLE enable_binlog SET ("binlog.enable" = "true");
```

## 6. 向 syncer 发起同步任务

```
curl -X POST -H "Content-Type: application/json" -d '{
 "name": "ccr_test",
 "src": {
 "host": "localhost",
 "port": "9030",
 "thrift_port": "9020",
 "user": "root",
 "password": "",
 "database": "your_db_name",
 "table": "your_table_name"
 },
 "dest": {
 "host": "localhost",
 "port": "9030",
 "thrift_port": "9020",
 "user": "root",
 "password": "",
 "database": "your_db_name",
 "table": "your_table_name"
 }
}' http://127.0.0.1:9190/create_ccr
```

同步任务的参数说明：

name: CCR同步任务的名称，唯一即可  
host、port: 对应集群 Master FE的host和mysql(jdbc) 的端口  
user、password: syncer以何种身份去开启事务、拉取数据等  
database、table:  
如果是db级别的同步，则填入your\_db\_name, your\_table\_name为空  
如果是表级别同步，则需要填入your\_db\_name, your\_table\_name  
向syncer发起同步任务中的name只能使用一次

## Syncer 详细操作手册

### 启动 Syncer 说明

根据配置选项启动 Syncer，并且在默认或指定路径下保存一个 pid 文件，pid 文件的命名方式为 host\_port.pid。

### 输出路径下的文件结构

在编译完成后的输出路径下，文件结构大致如下所示：

```
output_dir
 bin
 ccr_syncer
```

```
enable_db_binlog.sh
start_syncer.sh
stop_syncer.sh
db
[ccr.db] # 默认配置下运行后生成
log
[ccr_syncer.log] # 默认配置下运行后生成
```

\*\*\*\*后文中的 start\_syncer.sh 指的是该路径下的 start\_syncer.sh!!! \*\*\*\*

## 启动选项

### 1. -daemon

后台运行 Syncer，默认为 false

```
bash bin/start_syncer.sh --daemon
```

### 2. -db\_type

Syncer 目前能够使用两种数据库来保存自身的元数据，分别为sqlite3（对应本地存储）和mysql（本地或远端存储）

```
bash bin/start_syncer.sh --db_type mysql
```

默认值为 sqlite3

在使用 mysql 存储元数据时，Syncer 会使用CREATE IF NOT EXISTS来创建一个名为ccr的库，ccr 相关的元数据表都会保存在其中

### 3. -db\_dir

这个选项仅在 **db** 使用sqlite3时生效

可以通过此选项来指定 sqlite3 生成的 db 文件名及路径。

```
bash bin/start_syncer.sh --db_dir /path/to/ccr.db
```

默认路径为SYNCER\_OUTPUT\_DIR/db，文件名为ccr.db

### 4. -db\_host & db\_port & db\_user & db\_password

这个选项仅在 **db** 使用mysql时生效

```
bash bin/start_syncer.sh --db_host 127.0.0.1 --db_port 3306 --db_user root --db_password "qwe123456"
```

db\_host、db\_port 的默认值如例子中所示，db\_user、db\_password 默认值为空

### 5. -log\_dir

日志的输出路径

```
bash bin/start_syncer.sh --log_dir /path/to/ccr_syncer.log
```

默认路径为SYNCER\_OUTPUT\_DIR/log，文件名为ccr\_syncer.log

#### 6. -log\_level

用于指定 Syncer 日志的输出等级。

```
bash bin/start_syncer.sh --log_level info
```

日志的格式如下，其中 hook 只会在log\_level > info的时候打印：

#	time	level	msg	hooks
	[2023-07-18 16:30:18]	TRACE	This is trace type. ccrName=xxx line=xxx	
	[2023-07-18 16:30:18]	DEBUG	This is debug type. ccrName=xxx line=xxx	
	[2023-07-18 16:30:18]	INFO	This is info type. ccrName=xxx line=xxx	
	[2023-07-18 16:30:18]	WARN	This is warn type. ccrName=xxx line=xxx	
	[2023-07-18 16:30:18]	ERROR	This is error type. ccrName=xxx line=xxx	
	[2023-07-18 16:30:18]	FATAL	This is fatal type. ccrName=xxx line=xxx	

在-daemon 下，log\_level 默认值为info

在前台运行时，log\_level 默认值为trace，同时日志会通过 tee 来保存到 log\_dir

#### 6. -host && -port

用于指定 Syncer 的 host 和 port，其中 host 只起到在集群中的区分自身的作用，可以理解为 Syncer 的 name，集群中 Syncer 的名称为host:port

```
bash bin/start_syncer.sh --host 127.0.0.1 --port 9190
```

host 默认值为 127.0.0.1，port 的默认值为 9190

#### 7. -pid\_dir

用于指定 pid 文件的保存路径

pid 文件是 stop\_syncer.sh 脚本用于关闭 Syncer 的凭据，里面保存了对应 Syncer 的进程号，为了方便 Syncer 的集群化管理，可以指定 pid 文件的保存路径

```
bash bin/start_syncer.sh --pid_dir /path/to/pids
```

默认值为SYNCER\_OUTPUT\_DIR/bin

## Syncer 停止说明

根据默认或指定路径下 pid 文件中的进程号关闭对应 Syncer，pid 文件的命名方式为host\_port.pid。

输出路径下的文件结构

在编译完成后的输出路径下，文件结构大致如下所示：

```
output_dir
 bin
 ccr_syncer
 enable_db_binlog.sh
 start_syncer.sh
 stop_syncer.sh
 db
 [ccr.db] # 默认配置下运行后生成
 log
 [ccr_syncer.log] # 默认配置下运行后生成
```

\*\*\*\*后文中的 stop\_syncer.sh 指的是该路径下的 stop\_syncer.sh!!! \*\*\*\*

## 停止选项

有三种关闭方法：

### 1. 关闭目录下单个 Syncer

指定要关闭 Syncer 的 host && port，注意要与 start\_syncer 时指定的 host 一致

### 2. 批量关闭目录下指定 Syncer

指定要关闭的 pid 文件名，以空格分隔，用" "包裹

### 3. 关闭目录下所有 Syncer

默认即可

#### 1. --pid\_dir

指定 pid 文件所在目录，上述三种关闭方法都依赖于 pid 文件的所在目录执行

```
bash bin/stop_syncer.sh --pid_dir /path/to/pids
```

例子中的执行效果就是关闭/path/to/pids下所有 pid 文件对应的 Syncers（方法 3），--pid\_dir可与上面三种关闭方法组合使用。

默认值为SYNCER\_OUTPUT\_DIR/bin

#### 2. --host && --port

关闭 pid\_dir 路径下 host:port 对应的 Syncer

```
bash bin/stop_syncer.sh --host 127.0.0.1 --port 9190
```

host 的默认值为 127.0.0.1，port 默认值为空

即，单独指定 host 时方法 1不生效，会退化为方法 3。

host 与 port 都不为空时**方法 1**才能生效

### 3. -files

关闭 pid\_dir 路径下指定 pid 文件名对应的 Syncer

```
bash bin/stop_syncer.sh --files "127.0.0.1_9190.pid 127.0.0.1_9191.pid"
```

文件之间用空格分隔，整体需要用" "包裹住

## Syncer 操作列表

### 请求的通用模板

```
curl -X POST -H "Content-Type: application/json" -d {json_body}
http://ccr_syncer_host:ccr_syncer_port/operator
```

json\_body: 以 json 的格式发送操作所需信息

operator: 对应 Syncer 的不同操作

所以接口返回都是 json, 如果成功则是其中 success 字段为 true, 类似, 错误的时候, 是 false, 然后存在 ErrMsgs 字段

```
{"success":true}

or

{"success":false,"error_msg":"job ccr_test not exist"}
```

## operators

- create\_ccr

### 创建 CCR 任务

```
```shell  
curl -X POST -H "Content-Type: application/json" -d '{  
  "name": "ccr_test",  
  "src": {  
    "host": "localhost",  
    "port": "9030",  
    "thrift_port": "9020",  
    "user": "root",  
    "password": "",  
    "database": "demo",  
    "table": "example_tbl"  
  },  
  "dest": {  
    "host": "localhost",  
    "port": "9030",  
    "thrift_port": "9020",  
    "user": "root",  
    "password": "",  
    "database": "ccrt",  
  }  
}'
```

```
    "table": "copy"
  }
}' http://127.0.0.1:9190/create_ccr
```
```

- name: CCR 同步任务的名称，唯一即可
- host、port: 对应集群 master 的 host 和 mysql(jdbc) 的端口
- thrift\_port: 对应 FE 的 rpc\_port
- user、password: syncer 以何种身份去开启事务、拉取数据等
- database、table:
  - 如果是 db 级别的同步，则填入 dbName，tableName 为空
  - 如果是表级别同步，则需要填入 dbName、tableName
- get\_lag

#### 查看同步进度

```
```shell
curl -X POST -H "Content-Type: application/json" -d '{
  "name": "job_name"
}' http://ccr_syncer_host:ccr_syncer_port/get_lag
```
```

其中 job\_name 是 create\_ccr 时创建的名称

- pause

#### 暂停同步任务

```
```shell
curl -X POST -H "Content-Type: application/json" -d '{
  "name": "job_name"
}' http://ccr_syncer_host:ccr_syncer_port/pause
```
```

- resume

#### 恢复同步任务

```
```shell
curl -X POST -H "Content-Type: application/json" -d '{
  "name": "job_name"
}' http://ccr_syncer_host:ccr_syncer_port/resume
```
```

- delete

#### 删除同步任务

```
```shell
curl -X POST -H "Content-Type: application/json" -d '{
  "name": "job_name"
}' http://ccr_syncer_host:ccr_syncer_port/delete
```
```

- version

获取版本信息

```
curl http://ccr_syncer_host:ccr_syncer_port/version

> return
{"version": "2.0.1"}
```

- job status

查看 job 的状态

```
curl -X POST -H "Content-Type: application/json" -d '{
 "name": "job_name"
}' http://ccr_syncer_host:ccr_syncer_port/job_status

{
 "success": true,
 "status": {
 "name": "ccr_db_table_alias",
 "state": "running",
 "progress_state": "TableIncrementalSync"
 }
}
```

- desync job

不做 sync，此时用户可以将源和目的集群互换

```
curl -X POST -H "Content-Type: application/json" -d '{
 "name": "job_name"
}' http://ccr_syncer_host:ccr_syncer_port/desync
```

- list\_jobs

展示已经创建的所有任务

```
curl http://ccr_syncer_host:ccr_syncer_port/list_jobs

{"success":true,"jobs":["ccr_db_table_alias"]}
```

## 开启库中所有表的 binlog

### 输出路径下的文件结构

在编译完成后的输出路径下，文件结构大致如下所示：

```
output_dir
 bin
 ccr_syncer
 enable_db_binlog.sh
 start_syncer.sh
 stop_syncer.sh
 db
 [ccr.db] # 默认配置下运行后生成
 log
 [ccr_syncer.log] # 默认配置下运行后生成
```

\*\*\*\*后文中的 enable\_db\_binlog.sh 指的是该路径下的 enable\_db\_binlog.sh!!! \*\*\*\*

## 使用说明

```
bash bin/enable_db_binlog.sh -h host -p port -u user -P password -d db
```

## Syncer 高可用

Syncer 高可用依赖 mysql，如果使用 mysql 作为后端存储，Syncer 可以发现其它 syncer，如果一个 crash 了，其他会分担他的任务

## 权限要求

1. Select\_priv 对数据库、表的只读权限。
2. Load\_priv 对数据库、表的写权限。包括 Load、Insert、Delete 等。
3. Alter\_priv 对数据库、表的更改权限。包括重命名 库/表、添加/删除/变更 列、添加/删除 分区等操作。
4. Create\_priv 创建数据库、表、视图的权限。
5. Drop\_priv 删除数据库、表、视图的权限。

加上 Admin 权限 (之后考虑彻底移除), 这个是用来检测 enable binlog config 的, 现在需要 admin

## 使用限制

### 网络约束

- 需要 Syncer 与上下游的 FE 和 BE 都是通的
- 下游 BE 与上游 BE 是通的
- 对外 IP 和 Doris 内部 IP 是一样的，也就是说show frontends/backends看到的，和能直接连的 IP 是一致的，要是直连，不能是 IP 转发或者 nat



## ThriftPool 限制

开大 thrift thread pool 大小，最好是超过一次 commit 的 bucket 数目大小

## 版本要求

版本最低要求：v2.0.3

## 不支持的操作

- rename table 支持有点问题
- 不支持一些 trash 的操作，比如 table 的 drop-recovery 操作
- 和 rename table 有关的，replace partition 与
- 不能发生在同一个 db 上同时 backup/restore

## Feature

### 限速

BE 端配置参数：

```
download_binlog_rate_limit_kbs=1024 # 限制单个 BE 节点从源集群拉取 Binlog（包括 Local Snapshot）的速度为 1 MB/s
```

详细参数加说明：

1. download\_binlog\_rate\_limit\_kbs 参数在源集群 BE 节点配置，通过设置该参数能够有效限制数据拉取速度。
2. download\_binlog\_rate\_limit\_kbs 参数主要用于设置单个 BE 节点的速度，若计算集群整体速率一般需要参数值乘以集群个数。

## IS\_BEING\_SYNCED 属性

从 Doris v2.0 “is\_being\_synced” = “true”

CCR 功能在建立同步时，会在目标集群中创建源集群同步范围中表（后称源表，位于源集群）的副本表（后称目标表，位于目标集群），但是在创建副本表时需要失效或者擦除一些功能和属性以保证同步过程中的正确性。

如：

- 源表中包含了可能没有被同步到目标集群的信息，如storage\_policy等，可能会导致目标表创建失败或者行为异常。
- 源表中可能包含一些动态功能，如动态分区等，可能导致目标表的行为不受 syncer 控制导致 partition 不一致。

在被复制时因失效而需要擦除的属性有：

- `storage_policy`
- `colocate_with`

在被同步时需要失效的功能有：

- 自动分桶
- 动态分区

## 实现

在创建目标表时，这条属性将会由 `syncer` 控制添加或者删除，在 CCR 功能中，创建一个目标表有两个途径：

1. 在表同步时，`syncer` 通过 `backup/restore` 的方式对源表进行全量复制来得到目标表。
2. 在库同步时，对于存量表而言，`syncer` 同样通过 `backup/restore` 的方式来得到目标表，对于增量表而言，`syncer` 会通过携带有 `CreateTableRecord` 的 `binlog` 来创建目标表。

综上，对于插入 `is_being_synced` 属性有两个切入点：全量同步中的 `restore` 过程和增量同步时的 `getDdlStmt`。

在全量同步的 `restore` 过程中，`syncer` 会通过 `rpc` 发起对原集群中 `snapshot` 的 `restore`，在这个过程中会为 `RestoreStmt` 添加 `is_being_synced` 属性，并在最终的 `restoreJob` 中生效，执行 `isBeingSynced` 的相关逻辑。在增量同步时的 `getDdlStmt` 中，为 `getDdlStmt` 方法添加参数 `boolean getDdlForSync`，以区分是否为受控转化为目标表 `ddl` 的操作，并在创建目标表时执行 `isBeingSynced` 的相关逻辑。

对于失效属性的擦除无需多言，对于上述功能的失效需要进行说明：

- 自动分桶 自动分桶会在创建表时生效，计算当前合适的 `bucket` 数量，这就可能导致源表和目的表的 `bucket` 数目不一致。因此在同步时需要获得源表的 `bucket` 数目，并且也要获得源表是否为自动分桶表的信息以便结束同步后恢复功能。当前的做法是在获取 `distribution` 信息时默认 `autobucket` 为 `false`，在恢复表时通过检查 `_auto_bucket` 属性来判断源表是否为自动分桶表，如是则将目标表的 `autobucket` 字段设置为 `true`，以此来达到跳过计算 `bucket` 数量，直接应用源表 `bucket` 数量的目的。
- 动态分区 动态分区则是通过将 `olapTable.isBeingSynced()` 添加到是否执行 `add/drop partition` 的判断中来实现的，这样目标表在被同步的过程中就不会周期性的执行 `add/drop partition` 操作。

## 注意

在未出现异常时，`is_being_synced` 属性应该完全由 `syncer` 控制开启或关闭，用户不要自行修改该属性。

# 从回收站恢复

## 数据生命周期

1. 用户执行命令`drop database/table/partition`之后，Doris 会把删除的数据库/表/分区放到回收站，可以使用命令`recover`来恢复整个数据库/表/分区的所有数据从回收站里恢复，把它们从不可见状态，重新变回可见。
2. BE 侧删除一个 `tablet` 时，默认会把 `tablet` 的数据放进 BE 回收站。因为某些误操作或者线上 `bug`，导致 BE 上部分 `tablet` 被删除，通过运维工具把这些 `tablet` 从 BE 回收站中抢救回来。

上面两个，前者针对的是数据库/表/分区在 FE 上已经不可见，且数据库/表/分区的元数据尚保留在 FE 的回收站里。而后者针对的是数据库/表/分区在 FE 上可见，但部分 BE `tablet` 数据被删除。

下面分别阐述这两种恢复。

## 从 FE 回收站恢复

Doris 为了避免误操作造成的灾难，支持对误删除的数据库/表/分区进行数据恢复，在 `drop table` 或者 `drop database` 或者 `drop partition` 之后，Doris 不会立刻对数据进行物理删除，而是在 FE 的 `catalog` 回收站中保留一段时间（默认 1 天，可通过 `fe.conf` 中 `catalog_trash_expire_second` 参数配置），管理员可以通过 `RECOVER` 命令对误删除的数据进行恢复。

注意，如果是使用 `drop force` 进行删除的，则是直接删除，无法再恢复。

### 查看可恢复数据

查看 FE 上哪些数据可恢复

```
SHOW CATALOG RECYCLE BIN [WHERE NAME [= "name" | LIKE "name_matcher"]]
```

这里 `name` 可以是数据库/表/分区名。

关于该命令使用的更多详细语法及最佳实践，请参阅 [SHOW-CATALOG-RECYCLE-BIN](#) 命令手册，你也可以在 MySQL 客户端命令行下输入 `help SHOW CATALOG RECYCLE BIN` 获取更多帮助信息。

### 开始数据恢复

1. 恢复名为 `example_db` 的 database

```
RECOVER DATABASE example_db;
```

2. 恢复名为 `example_tbl` 的 table

```
RECOVER TABLE example_db.example_tbl;
```

3. 恢复表 `example_tbl` 中名为 `p1` 的 partition

```
RECOVER PARTITION p1 FROM example_tbl;
```

执行RECOVER命令之后，原来的数据将恢复可见。

关于 RECOVER 使用的更多详细语法及最佳实践，请参阅 [RECOVER](#) 命令手册，你也可以在 MySQL 客户端命令行下输入 `help RECOVER` 获取更多帮助信息。

## 从 BE 回收站中恢复 Tablet

### 从 BE 回收站中恢复数据

用户在使用 Doris 的过程中，可能会发生因为一些误操作或者线上 bug，导致一些有效的 tablet 被删除（包括元数据和数据）。

为了防止在这些异常情况出现数据丢失，Doris 提供了回收站机制，来保护用户数据。

用户删除的 tablet 数据在 BE 端不会被直接删除，会被放在回收站中存储一段时间，在一段时间之后会有定时清理机制将过期的数据删除。默认情况下，在磁盘空间占用不超过 81%（BE 配置 `config.storage_flood_stage_usage_percent * 0.9 * 100%`）时，BE 回收站中的数据最长保留 3 天（见 BE 配置 `config.trash_file_expire_time_sec`）。

BE 回收站中的数据包括：tablet 的 data 文件 (.dat)，tablet 的索引文件 (.idx) 和 tablet 的元数据文件 (.hdr)。数据将会存放在如下格式的路径：

```
/root_path/trash/time_label/tablet_id/schema_hash/
```

- `root_path`：对应 BE 节点的某个数据根目录。
- `trash`：回收站的目录。
- `time_label`：时间标签，为了回收站中数据目录的唯一性，同时记录数据时间，使用时间标签作为子目录。

当用户发现线上的数据被误删除，需要从回收站中恢复被删除的 tablet，需要用到这个 tablet 数据恢复功能。

BE 提供 http 接口和 `restore_tablet_tool.sh` 脚本实现这个功能，支持单 tablet 操作（single mode）和批量操作模式（batch mode）。

- 在 single mode 下，支持单个 tablet 的数据恢复。
- 在 batch mode 下，支持批量 tablet 的数据恢复。

另外，用户可以使用命令 `show trash` 查看 BE 中的 trash 数据，可以使用命令 `admin clean trash` 来清除 BE 的 trash 数据。

### 操作

#### 1. single mode

- http 请求方式

BE 中提供单个 tablet 数据恢复的 http 接口，接口如下：

```
curl -X POST "http://be_host:be_webserver_port/api/restore_tablet?tablet_id=11111&schema_hash=12345"
```

成功的结果如下：

```
{"status": "Success", "msg": "OK"}
```

失败的话，会返回相应的失败原因，一种可能的结果如下：

```
{"status": "Failed", "msg": "create link path failed"}
```

- 脚本方式

restore\_tablet\_tool.sh 可用来实现单 tablet 数据恢复的功能。

```
sh tools/restore_tablet_tool.sh -b "http://127.0.0.1:8040" -t 12345 -s 11111
sh tools/restore_tablet_tool.sh --backend "http://127.0.0.1:8040" --tablet_id 12345 --schema_hash 11111
```

## 2. batch mode

批量恢复模式用于实现恢复多个 tablet 数据的功能。

使用的时候需要预先将恢复的 tablet id 和 schema hash 按照逗号分隔的格式放在一个文件中，一个 tablet 一行。

格式如下：

```
12345,11111
12346,11111
12347,11111
```

然后如下的命令进行恢复 (假设文件名为：tablets.txt)：

```
sh restore_tablet_tool.sh -b "http://127.0.0.1:8040" -f tablets.txt
sh restore_tablet_tool.sh --backend "http://127.0.0.1:8040" --file tablets.txt
```

## 修复缺失或损坏的 Tablet

在某些极特殊情况下，如代码 BUG、或人为误操作等，可能导致部分分片的全部副本都丢失。这种情况下，数据已经实质性的丢失。但是在某些场景下，业务依然希望能够在即使有数据丢失的情况下，保证查询正常不报错，降低用户层的感知程度。此时，我们可以通过使用空白 Tablet 填充丢失副本的功能，来保证查询能够正常执行。

\*\*\*\*注：该操作仅用于规避查询因无法找到可查询副本导致报错的问题，无法恢复已经实质性丢失的数据\*\*\*\*

### 1. 查看 Master FE 日志 fe.log

如果出现数据丢失的情况，则日志中会有类似如下日志：

```
backend [10001] invalid situation. tablet[20000] has few replica[1], replica num setting is [3]
```

这个日志表示，Tablet 20000 的所有副本已损坏或丢失。

## 2. 使用空白副本填补缺失副本

当确认数据已经无法恢复后，可以通过执行以下命令，生成空白副本。

```
ADMIN SET FRONTEND CONFIG ("recover_with_empty_tablet" = "true");
```

注：可以先通过 ADMIN SHOW FRONTEND CONFIG; 命令查看当前版本是否支持该参数。

## 3. 设置完成几分钟后，应该会在 Master FE 日志 fe.log 中看到如下日志：

```
tablet 20000 has only one replica 20001 on backend 10001 and it is lost. create an empty replica to recover it.
```

该日志表示系统已经创建了一个空白 Tablet 用于填补缺失副本。

## 4. 通过查询来判断是否已经修复成功。

## 5. 全部修复成功后，通过以下命令关闭 recover\_with\_empty\_tablet 参数：

```
ADMIN SET FRONTEND CONFIG ("recover_with_empty_tablet" = "false");
```

# 主键表数据修复

---

## 数据恢复

对于 Unique Key Merge on Write 表，在某些 Doris 的版本中存在 bug，可能会导致系统在计算 delete bitmap 时出现错误，导致出现重复主键，此时可以利用 full compaction 功能进行数据的修复。本功能对于非 Unique Key Merge on Write 表无效。

该功能需要 Doris 版本 2.0+。

使用该功能，需要尽可能停止导入，否则可能会出现导入超时等问题。

## 简要原理说明

执行 full compaction 后，会对 delete bitmap 进行重新计算，将错误的 delete bitmap 数据删除，以完成数据的修复。

## 使用说明

POST /api/compaction/run?tablet\_id={int}&compact\_type=full

或

POST /api/compaction/run?table\_id={int}&compact\_type=full

注意，tablet\_id 和 table\_id 只能指定一个，不能够同时指定，指定 table\_id 后会自动对此 table 下所有 tablet 执行 full\_compaction。

## 使用例子

```
curl -X POST "http://127.0.0.1:8040/api/compaction/run?tablet_id=10015&compact_type=full"
curl -X POST "http://127.0.0.1:8040/api/compaction/run?table_id=10104&compact_type=full"
```

# Workload Group

Workload Group 可限制组内任务在单个 BE 节点上的计算资源和内存资源的使用。当前支持 Query 绑定到 Workload Group。

## Workload Group 属性

- **cpu\_share**: 必选，用于设置 Workload Group 获取 CPU 时间的多少，可以实现 CPU 资源软隔离。  
cpu\_share 是相对值，表示正在运行的 Workload Group 可获取 cpu 资源的权重。例如，用户创建了 3 个 Workload Group g-a、g-b 和 g-c，cpu\_share 分别为 10、30、40，某一时刻 g-a 和 g-b 正在跑任务，而 g-c 没有任务，此时 g-a 可获得 25% ( $10 / (10 + 30)$ ) 的 cpu 资源，而 g-b 可获得 75% 的 cpu 资源。如果系统只有一个 Workload Group 正在运行，则不管其 cpu\_share 的值为多少，它都可获取全部的 cpu 资源。
- **memory\_limit**: 必选，用于设置 Workload Group 可以使用 be 内存的百分比。Workload Group 内存限制的绝对值为：物理内存 \* mem\_limit \* memory\_limit，其中 mem\_limit 为 be 配置项。系统所有 Workload Group 的 memory\_limit 总合不可超过 100%。Workload Group 在绝大多数情况下保证组内任务可使用 memory\_limit 的内存，当 Workload Group 内存使用超出该限制后，组内内存占用较大的任务可能会被 cancel 以释放超出的内存，参考 enable\_memory\_overcommit。
- **enable\_memory\_overcommit**: 可选，用于开启 Workload Group 内存软隔离，默认为 false。如果设置为 false，则该 Workload Group 为内存硬隔离，系统检测到 Workload Group 内存使用超出限制后将立即 cancel 组内内存占用最大的若干个任务，以释放超出的内存；如果设置为 true，则该 Workload Group 为内存软隔离，如果系统有空闲内存资源则该 Workload Group 在超出 memory\_limit 的限制后可继续使用系统内存，在系统总内存紧张时会 cancel 组内内存占用最大的若干个任务，释放部分超出的内存以缓解系统内存压力。建议在有 Workload Group 开启该配置时，所有 Workload Group 的 memory\_limit 总和低于 100%，剩余部分用于 Workload Group 内存超发。

## Workload Group 使用

1. 手动创建名为normal的Workload Group，该Group不可删除。也可以在打开Workload Group开关后重启 FE，会自动创建这个Group。

```
create workload group if not exists normal
properties (
 "cpu_share"="10",
 "memory_limit"="30%",
 "enable_memory_overcommit"="true"
);
```

2. 开启 experimental\_enable\_workload\_group 配置项，在 fe.conf 中设置：

```
experimental_enable_workload_group=true
```

3. 创建 Workload Group：



```
create workload group if not exists g1
properties (
 "cpu_share"="10",
 "memory_limit"="30%",
 "enable_memory_overcommit"="true"
);
```

创建 workload group 详细可参考：[CREATE-WORKLOAD-GROUP](#)，另删除 Workload Group 可参考[DROP-WORKLOAD-GROUP](#)；修改 Workload Group 可参考：[ALTER-WORKLOAD-GROUP](#)；查看 Workload Group 可参考：[WORKLOAD\\_GROUPS\(\)](#)和[SHOW-WORKLOAD-GROUPS](#)。

4. 开启 Pipeline 执行引擎，Workload Group CPU 隔离基于 Pipeline 执行引擎实现，因此需开启 Session 变量：

```
set experimental_enable_pipeline_engine = true;
```

5. 绑定 Workload Group。

- 通过设置 user property 将 user 默认绑定到 workload group，默认为normal:

```
set property 'default_workload_group' = 'g1';
```

当前用户的查询将默认使用'g1'。

- 通过 session 变量指定 workload group, 默认为空：

```
set workload_group = 'g2';
```

session 变量workload\_group优先于 user property default\_workload\_group, 在workload\_group为空时，查询将绑定到default\_workload\_group, 在 session 变量workload\_group不为空时，查询将绑定到 workload\_group。

如果是非 Admin 用户，需要先执行[SHOW-WORKLOAD-GROUPS](#) 确认下当前用户能否看到该 workload group，不能看到的 workload group 可能不存在或者当前用户没有权限，执行查询时会报错。给 worklaod group 授权参考：[grant 语句](#)。

6. 执行查询，查询将关联到指定的 Workload Group。

## 查询排队功能

```
create workload group if not exists test_group
properties (
 "cpu_share"="10",
 "memory_limit"="30%",
 "max_concurrency" = "10",
 "max_queue_size" = "20",
 "queue_timeout" = "3000"
);
```

目前的 workload group 支持查询排队的功能，可以在新建 group 时进行指定，需要以下三个参数：

- `max_concurrency`, 当前 group 允许的最大查询数;超过最大并发的查询到来时会进入排队逻辑
- `max_queue_size`, 查询排队的长度;当队列满了之后, 新来的查询会被拒绝
- `queue_timeout`, 查询在队列中等待的时间, 如果查询等待时间超过这个值, 那么查询会被拒绝, 时间单位为毫秒

需要注意的是, 目前的排队设计是不感知 FE 的个数的, 排队的参数只在单 FE 粒度生效, 例如:

- 一个 Doris 集群配置了一个 Workload Group, 设置 `max_concurrency = 1`
- 如果集群中有 1FE, 那么这个 Workload Group 在 Doris 集群视角看同时只会运行一个 SQL
- 如果有 3 台 FE, 那么在 Doris 集群视角看最大可运行的 SQL 个数为 3

# Resource Group

## 多租户和资源划分

Doris 的多租户和资源隔离方案，主要目的是为了多用户在同一 Doris 集群内进行数据操作时，减少相互之间的干扰，能够将集群资源更合理的分配给各用户。

该方案主要分为两部分，一是集群内节点级别的资源组划分，二是针对单个查询的资源限制。

## Doris 中的节点

首先先简单介绍一下 Doris 的节点组成。一个 Doris 集群中有两类节点：Frontend(FE) 和 Backend(BE)。

FE 主要负责元数据管理、集群管理、用户请求的接入和查询计划的解析等工作。

BE 主要负责数据存储、查询计划的执行等工作。

FE 不参与用户数据的处理计算等工作，因此是一个资源消耗较低的节点。而 BE 负责所有的数据计算、任务处理，属于资源消耗型的节点。因此，本文所介绍的资源划分及资源限制方案，都是针对 BE 节点的。FE 节点因为资源消耗相对较低，并且还可以横向扩展，因此通常无需做资源上的隔离和限制，FE 节点由所有用户共享即可。

## 节点资源划分

节点资源划分，是指将一个 Doris 集群内的 BE 节点设置标签 (Tag)，标签相同的 BE 节点组成一个资源组 (Resource Group)。资源组可以看作是数据存储和计算的一个管理单元。下面我们通过一个具体示例，来介绍资源组的使用方式。

### 1. 为 BE 节点设置标签

假设当前 Doris 集群有 6 个 BE 节点。分别为 host[1-6]。在初始情况下，所有节点都属于一个默认资源组 (Default)。

我们可以使用以下命令将这 6 个节点划分成 3 个资源组：group\_a、group\_b、group\_c：

```
alter system modify backend "host1:9050" set ("tag.location" = "group_a");
alter system modify backend "host2:9050" set ("tag.location" = "group_a");
alter system modify backend "host3:9050" set ("tag.location" = "group_b");
alter system modify backend "host4:9050" set ("tag.location" = "group_b");
alter system modify backend "host5:9050" set ("tag.location" = "group_c");
alter system modify backend "host6:9050" set ("tag.location" = "group_c");
```

这里我们将 host[1-2] 组成资源组 group\_a，host[3-4] 组成资源组 group\_b，host[5-6] 组成资源组 group\_c。

**注：一个 BE 只支持设置一个 Tag。**


## 2. 按照资源组分配数据分布

资源组划分好后。我们可以将用户数据的不同副本分布在不同资源组内。假设一张用户表 `UserTable`。我们希望在 3 个资源组内各存放一个副本，则可以通过如下建表语句实现：

```
create table UserTable
(k1 int, k2 int)
distributed by hash(k1) buckets 1
properties(
 "replication_allocation"="tag.location.group_a:1, tag.location.group_b:1, tag.location.group_c:1"
)
```

这样一来，表 `UserTable` 中的数据，将会以 3 副本的形式，分别存储在资源组 `group_a`、`group_b`、`group_c` 所在的节点中。

下图展示了当前的节点划分和数据分布：



为了方便设置 table 的数据分布策略，可以在 database 层面设置统一的数据分布策略，但是 table 设置的优先级高于 database

```
CREATE DATABASE db_name PROPERTIES (
 "replication_allocation" = "tag.location.group_a:1, tag.location.group_b:1"
)
```

### 3. 使用不同资源组进行数据查询

在前两步执行完成后，我们就可以通过设置用户的资源使用权限，来限制某一用户的查询，只能使用指定资源组中的节点来执行。

比如我们可以通过以下语句，限制 user1 只能使用 group\_a 资源组中的节点进行数据查询，user2 只能使用 group\_b 资源组，而 user3 可以同时使用 3 个资源组：

```
set property for 'user1' 'resource_tags.location' = 'group_a';
set property for 'user2' 'resource_tags.location' = 'group_b';
set property for 'user3' 'resource_tags.location' = 'group_a, group_b, group_c';
```

设置完成后，user1 在发起对 UserTable 表的查询时，只会访问 group\_a 资源组内节点上的数据副本，并且查询仅会使用 group\_a 资源组内的节点计算资源。而 user3 的查询可以使用任意资源组内的副本和计算资源。

注：默认情况下，用户的 resource\_tags.location 属性为空，在 2.0.2（含）之前的版本中，默认情况下，用户不受 tag 的限制，可以使用任意资源组。在 2.0.3 版本之后，默认情况下，普通用户只能使用 default 资源组。root 和 admin 用户可以使用任意资源组。

需要注意的是，属性 resource\_tags.location 每次修改完成之后，用户需要重新建立连接才能使变更生效。

这样，我们通过对节点的划分，以及对用户的资源使用限制，实现了不同用户查询上的物理资源隔离。更进一步，我们可以给不同的业务部门创建不同的用户，并限制每个用户使用不同的资源组。以避免不同业务部分之间使用资源干扰。比如集群内有一张业务表需要共享给所有 9 个业务部门使用，但是希望能够尽量避免不同部门之间的资源抢占。则我们可以为这张表创建 3 个副本，分别存储在 3 个资源组中。接下来，我们为 9 个业务部门创建 9 个用户，每 3 个用户限制使用一个资源组。这样，资源的竞争程度就由 9 降低到了 3。

另一方面，针对在线和离线任务的隔离。我们可以利用资源组的方式实现。比如我们可以将节点划分为 Online 和 Offline 两个资源组。表数据依然以 3 副本的方式存储，其中 2 个副本存放在 Online 资源组，1 个副本存放在 Offline 资源组。Online 资源组主要用于高并发低延迟的在线数据服务，而一些大查询或离线 ETL 操作，则可以使用 Offline 资源组中的节点执行。从而实现在统一集群内同时提供在线和离线服务的能力。

### 4. 导入作业的资源组分配

导入作业（包括 insert、broker load、routine load、stream load 等）的资源使用可以分为两部分：

1. 计算资源：负责读取数据源、数据转换和分发。
2. 写入资源：负责数据编码、压缩并写入磁盘。

其中写入资源必须是数据副本所在的节点，而计算资源理论上可以选择任意节点完成。所以对于导入作业的资源组的分配分成两个步骤：

1. 使用用户级别的 resource tag 来限定计算资源所能使用的资源组。
2. 使用副本的 resource tag 来限定写入资源所能使用的资源组。

所以如果希望导入操作所使用的全部资源都限定在数据所在的资源组的话，只需将用户级别的 resource tag 设置为和副本的 resource tag 相同即可。

## 单查询资源限制

前面提到的资源组方法是节点级别的资源隔离和限制。而在资源组内，依然可能发生资源抢占问题。比如前文提到的将 3 个业务部门安排在同一资源组内。虽然降低了资源竞争程度，但是这 3 个部门的查询依然有可能相互影响。

因此，除了资源组方案外，Doris 还提供了对单查询的资源限制功能。

目前 Doris 对单查询的资源限制主要分为 CPU 和 内存限制两方面。

### 1. 内存限制

Doris 可以限制一个查询被允许使用的最大内存开销。以保证集群的内存资源不会被某一个查询全部占用。我们可以通过以下方式设置内存限制：

```
设置会话变量 exec_mem_limit。则之后该会话内（连接内）的所有查询都使用这个内存限制。
set exec_mem_limit=1G;
设置全局变量 exec_mem_limit。则之后所有新会话（新连接）的所有查询都使用这个内存限制。
set global exec_mem_limit=1G;
在 SQL 中设置变量 exec_mem_limit（单位：字节）。则该变量仅影响这个 SQL。
select /*+ SET_VAR(exec_mem_limit=1073741824) */ id, name from tbl where xxx;
```

因为 Doris 的查询引擎是基于全内存的 MPP 查询框架。因此当一个查询的内存使用超过限制后，查询会被终止。因此，当一个查询无法在合理的内存限制下运行时，我们就需要通过一些 SQL 优化手段，或者集群扩容的方式来解决。

### 2. CPU 限制

用户可以通过以下方式限制查询的 CPU 资源：

```
设置会话变量 cpu_resource_limit。则之后该会话内（连接内）的所有查询都使用这个 CPU 限制。
set cpu_resource_limit = 2
设置用户的属性 cpu_resource_limit，则所有该用户的查询情况都使用这个 CPU 限制。该属性的优先级高于会话变量
cpu_resource_limit
set property for 'user1' 'cpu_resource_limit' = '3';
```

cpu\_resource\_limit 的取值是一个相对值，取值越大则能够使用的 CPU 资源越多。但一个查询能使用的 CPU 上限也取决于表的分区桶数。原则上，一个查询的最大 CPU 使用量和查询涉及到的 tablet 数量正相关。极端情况下，假设一个查询仅涉及到一个 tablet，则即使 cpu\_resource\_limit 设置一个较大值，也仅能使用 1 个 CPU 资源。

通过内存和 CPU 的资源限制。我们可以在一个资源组内，将用户的查询进行更细粒度的资源划分。比如我们可以让部分时效性要求不高，但是计算量很大的离线任务使用更少的 CPU 资源和更多的内存资源。而部分延迟敏感的在线任务，使用更多的 CPU 资源以及合理的内存资源。

## 最佳实践和向前兼容

**Tag 划分和 CPU 限制**是 0.15 版本中的新功能。为了保证可以从老版本平滑升级，Doris 做了如下的向前兼容：

1. 每个 BE 节点会有一个默认的 Tag: "tag.location": "default"。
2. 通过 alter system add backend 语句新增的 BE 节点也会默认设置 Tag: "tag.location": "default"。
3. 所有表的副本分布默认修改为: "tag.location.default:xx。其中 xx 为原副本数量。
4. 用户依然可以通过 "replication\_num" = "xx" 在建表语句中指定副本数，这种属性将会自动转换成: "tag.location.default:xx。从而保证无需修改原建表语句。
5. 默认情况下，单查询的内存限制为单节点 2GB，CPU 资源无限制，和原有行为保持一致。且用户的 resource\_tags.location 属性为空，即默认情况下，用户可以访问任意 Tag 的 BE，和原有行为保持一致。

这里我们给出一个从原集群升级到 0.15 版本后，开始使用资源划分功能的步骤示例：

### 1. 关闭数据修复与均衡逻辑

因为升级后，BE 的默认 Tag 为 "tag.location": "default"，而表的默认副本分布为: "tag.location.default:xx。所以如果直接修改 BE 的 Tag，系统会自动检测到副本分布的变化，从而开始数据重分布。这可能会占用部分系统资源。所以我们可以先在修改 Tag 前，先关闭数据修复与均衡逻辑，以保证我们在规划资源时，不会有副本重分布的操作。

```
ADMIN SET FRONTEND CONFIG ("disable_balance" = "true");
ADMIN SET FRONTEND CONFIG ("disable_tablet_scheduler" = "true");
```

### 2. 设置 Tag 和表副本分布

接下来可以通过 alter system modify backend 语句进行 BE 的 Tag 设置。以及通过 alter table 语句修改表的副本分布策略。示例如下：

```
alter system modify backend "host1:9050, 1212:9050" set ("tag.location" = "group_a");
alter table my_table modify partition p1 set ("replication_allocation" = "tag.location.group_a:2");
```

### 3. 开启数据修复与均衡逻辑

在 Tag 和副本分布都设置完毕后，我们可以开启数据修复与均衡逻辑来触发数据的重分布了。

```
ADMIN SET FRONTEND CONFIG ("disable_balance" = "false");
ADMIN SET FRONTEND CONFIG ("disable_tablet_scheduler" = "false");
```

该过程根据涉及到的数据量会持续一段时间。并且会导致部分 colocation table 无法进行 colocation 规划（因为副本在迁移中）。可以通过 show proc "/cluster\_balance/" 来查看进度。也可以通过 show proc "/statistic" 中 UnhealthyTabletNum 的数量来判断进度。当 UnhealthyTabletNum 降为 0 时，则代表数据重分布完毕。

#### 4. 设置用户的资源标签权限。

等数据重分布完毕后。我们就可以开始设置用户的资源标签权限了。因为默认情况下，用户的 `resource_tags.location` 属性为空，即可以访问任意 Tag 的 BE。所以在前面步骤中，不会影响到已有用户的正常查询。当 `resource_tags.location` 属性非空时，用户将被限制访问指定 Tag 的 BE。

通过以上 4 步，我们可以较为平滑的在原有集群升级后，使用资源划分功能。

#### table 数量很多时如何方便的设置副本分布策略

比如有一个 db1,db1 下有四个 table，table1 需要的副本分布策略为 `group_a:1,group_b:2`，table2，table3，table4 需要的副本分布策略为 `group_c:1,group_b:2`

那么可以使用如下语句创建 db1：

```
CREATE DATABASE db1 PROPERTIES (
 "replication_allocation" = "tag.location.group_c:1, tag.location.group_b:2"
)
```

使用如下语句创建 table1：

```
CREATE TABLE table1
(k1 int, k2 int)
distributed by hash(k1) buckets 1
properties(
 "replication_allocation"="tag.location.group_a:1, tag.location.group_b:2"
)
```

table2，table3,table4 的建表语句无需再指定 `replication_allocation`。

注意事项：更改 database 的副本分布策略不会对已有的 table 产生影响。



# SQL 拦截

该功能用于限制执行 sql 语句（DDL / DML 都可限制）。支持按用户配置 SQL 黑名单：

1. 通过正则匹配的方式拒绝指定 SQL
2. 通过设置 `partition_num`, `tablet_num`, `cardinality`, 检查一个查询是否达到其中一个限制
  - `partition_num`, `tablet_num`, `cardinality` 可以一起设置，一旦一个查询达到其中一个限制，查询将会被拦截

## 规则

对 SQL 规则增删改查

- 创建 SQL 阻止规则，更多创建语法请参阅[CREATE SQL BLOCK RULE](#)
  - `sql`: 匹配规则 (基于正则匹配，特殊字符需要转译)，可选，默认值为 “NULL”
  - `sqlHash`: sql hash 值，用于完全匹配，我们会在 `fe.audit.log` 打印这个值，可选，这个参数和 SQL 只能二选一，默认值为 “NULL”
  - `partition_num`: 一个扫描节点会扫描的最大 Partition 数量，默认值为 0L
  - `tablet_num`: 一个扫描节点会扫描的最大 Tablet 数量，默认值为 0L
  - `cardinality`: 一个扫描节点粗略的扫描行数，默认值为 0L
  - `global`: 是否全局 (所有用户) 生效，默认为 false
  - `enable`: 是否开启阻止规则，默认为 true

```
CREATE SQL_BLOCK_RULE test_rule
PROPERTIES(
 "sql"="select * from order_analysis",
 "global"="false",
 "enable"="true",
 "sqlHash"=""
)
```

### 注意：

这里 SQL 语句最后不要带分号

当我们去执行刚才我们定义在规则里的 SQL 时就会返回异常错误，示例如下：

```
mysql> select * from order_analysis;
ERROR 1064 (HY000): errCode = 2, detailMessage = sql match regex sql block rule: order_analysis_rule
```

- 创建 `test_rule2`，将最大扫描的分区数量限制在 30 个，最大扫描基数限制在 100 亿行，示例如下：

```
CREATE SQL_BLOCK_RULE test_rule2 PROPERTIES("partition_num" = "30",
"cardinality"="10000000000", "global"="false", "enable"="true")
```

- 查看已配置的 SQL 阻止规则，不指定规则名则为查看所有规则，具体语法请参阅 [SHOW SQL BLOCK RULE](#)

```
SHOW SQL_BLOCK_RULE [FOR RULE_NAME]
```

- 修改 SQL 阻止规则，允许对 sql/sqlHash/partition\_num/tablet\_num/cardinality/global/enable 等每一项进行修改，具体语法请参阅[ALTER SQL BLOCK RULE](#)
  - sql 和 sqlHash 不能同时被设置。这意味着，如果一个 rule 设置了 sql 或者 sqlHash，则另一个属性将无法被修改
  - sql/sqlHash 和 partition\_num/tablet\_num/cardinality 不能同时被设置。举个例子，如果一个 rule 设置了 partition\_num，那么 sql 或者 sqlHash 将无法被修改

```
ALTER SQL_BLOCK_RULE test_rule PROPERTIES("sql"="select * from test_table", "enable"="true")
```

```
ALTER SQL_BLOCK_RULE test_rule2 PROPERTIES("partition_num" = "10", "tablet_num"="300", "enable"="true")
```

- 删除 SQL 阻止规则，支持多规则，以, 隔开，具体语法请参阅 [DROP SQL BLOCK RULE](#)

```
DROP SQL_BLOCK_RULE test_rule1, test_rule2
```

## 用户规则绑定

如果配置 global=false，则需要配置指定用户的规则绑定，多个规则使用, 分隔

```
SET PROPERTY [FOR 'jack'] 'sql_block_rules' = 'test_rule1, test_rule2'
```

# Kill Query

## Kill 连接

每个 Doris 的连接都在一个单独的线程中运行。您可以使用 KILL processlist\_id 语句终止线程。

线程进程列表标识符可以从 SHOW PROCESSLIST 输出的 Id 列查询 或者 SELECT CONNECTION\_ID() 来查询当前 Connection ID。

语法：

```
KILL [CONNECTION] processlist_id
```

## Kill 查询

除此之外，您还可以使用 processlist\_id 或者 query\_id 终止正在执行的查询命令

语法：

```
KILL QUERY processlist_id | query_id
```

## 举例

### 1. 查看当前连接的 Connection ID。

```
mysql select connection_id();
+-----+
| connection_id() |
+-----+
| 48 |
+-----+
1 row in set (0.00 sec)
```

### 2. 查看所有连接的 Connection ID。

```
mysql SHOW PROCESSLIST;
+-----+-----+-----+-----+-----+-----+-----+-----+
| CurrentConnected | Id | User | Host | LoginTime | Catalog | Db | Command |
Time | State | QueryId | Info | | | | |
+-----+-----+-----+-----+-----+-----+-----+-----+
| Yes | 48 | root | 10.16.xx.xx:44834 | 2023-12-29 16:49:47 | internal | test | Query |
0 | OK | e6e4ce9567b04859-8eeab8d6b5513e38 | SHOW PROCESSLIST | | | | |
+-----+-----+-----+-----+-----+-----+-----+-----+
| | 50 | root | 192.168.xx.xx:52837 | 2023-12-29 16:51:34 | internal | | Sleep |
1837 | EOF | deaf13c52b3b4a3b-b25e8254b50ff8cb | SELECT @@session.transaction_isolation | | | | |
+-----+-----+-----+-----+-----+-----+-----+-----+
```

```

|
| | 51 | root | 192.168.xx.xx:52843 | 2023-12-29 16:51:35 | internal | | Sleep |
907 | EOF | 437f219addc0404f-9befe7f6acf9a700 | /* ApplicationName=DBeaver Ultimate 23.1.3 - Metadata */
SHOW STATUS
|
| | 55 | root | 192.168.xx.xx:55533 | 2023-12-29 17:09:32 | internal | test | Sleep |
271 | EOF | f02603dc163a4da3-beebbb5d1ced760c | /* ApplicationName=DBeaver Ultimate 23.1.3 - SQLEditor
<Console> */ SELECT DATABASE() |
|
| | 47 | root | 10.16.xx.xx:35678 | 2023-12-29 16:21:56 | internal | test | Sleep |
3528 | EOF | f4944c543dc34a99-b0d0f3986c8f1c98 | select * from test
|
+-----+-----+-----+-----+-----+-----+-----+-----+
+-----+-----+-----+-----+-----+-----+-----+-----+
+-----+-----+-----+-----+-----+-----+-----+-----+
5 rows in set (0.00 sec)

```

### 3. 终止正在运行的查询，正在运行的查询会显示被取消。

```

mysql kill query 55;
Query OK, 0 rows affected (0.01 sec)

```

# 认证和鉴权

## 权限管理

Doris 新的权限管理系统参照了 Mysql 的权限管理机制，做到了行级别细粒度的权限控制，基于角色的权限访问控制，并且支持白名单机制。

### 名词解释

#### 1. 用户标识 user\_identity

在权限系统中，一个用户被识别为一个 User Identity（用户标识）。用户标识由两部分组成：username 和 userhost。其中 username 为用户名，由英文大小写组成。userhost 表示该用户链接来自的 IP。user\_identity 以 username@'userhost' 的方式呈现，表示来自 userhost 的 username。

user\_identity 的另一种表现方式为 username@[domain]，其中 domain 为域名，可以通过 DNS 或 BNS（百度名字服务）解析为一组 ip。最终表现为一组 username@'userhost'，所以后面我们统一使用 username@'userhost' 来表示。

#### 2. 权限 Privilege

权限作用的对象是节点、数据目录、数据库或表。不同的权限代表不同的操作许可。

#### 3. 角色 Role

Doris 可以创建自定义命名的角色。角色可以被看做是一组权限的集合。新创建的用户可以被赋予某一角色，则自动被赋予该角色所拥有的权限。后续对角色的权限变更，也会体现在所有属于该角色的用户权限上。

#### 4. 用户属性 user\_property

用户属性直接附属于某一用户，而不是用户标识。即 cmy@'192.%' 和 cmy@[domain] 都拥有同一组用户属性，该属性属于用户 cmy，而不是 cmy@'192.%' 或 cmy@[domain]。

用户属性包括但不限于：用户最大连接数、导入集群配置等等。

## 权限框架


Doris 权限设计基于 RBAC(Role-Based Access Control) 的权限管理模型，用户和角色关联，角色和权限关联，用户通过角色间接和权限关联。

当角色被删除时，用户自动失去该角色的所有权限。

当用户和角色取消关联，用户自动失去角色的所有权限。

当角色的权限被增加或删除，用户的权限也会随之变更。





如上图所示：

user1 和 user2 都是通过 role1 拥有了 priv1 的权限。

userN 通过 role3 拥有了 priv1 的权限，通过 roleN 拥有了 priv2 和 privN 的权限，因此 userN 同时拥有 priv1, priv2 和 privN 的权限。

为了方便用户操作，是可以直接给用户授权的，底层实现上，是为每个用户创建了一个专属于该用户的默认角色，当给用户授权时，实际上是在给该用户的默认角色授权。

默认角色不能被删除，不能被分配给其他人，删除用户时，默认角色也自动删除。

## 支持的操作

1. 创建用户： [CREATE USER](#)
2. 修改用户： [ALTER USER](#)
3. 删除用户： [DROP USER](#)
4. 授权/分配角色： [GRANT](#)
5. 撤权/撤销角色： [REVOKE](#)
6. 创建角色： [CREATE ROLE](#)
7. 删除角色： [DROP ROLE](#)
8. 查看当前用户权限和角色： [SHOW GRANTS](#)
9. 查看所有用户权限和角色： [SHOW ALL GRANTS](#)
10. 查看已创建的角色： [SHOW ROLES](#)
11. 设置用户属性： [SET PROPERTY](#)
12. 查看用户属性： [SHOW PROPERTY](#)
13. 修改密码： [SET PASSWORD](#)

关于以上命令的详细帮助，可以通过 mysql 客户端连接 Doris 后，使用 help + command 获取帮助。如 HELP CREATE USER。

## 权限类型

Doris 目前支持以下几种权限

### 1. Node\_priv

节点变更权限。包括 FE、BE、BROKER 节点的添加、删除、下线等操作。

Root 用户默认拥有该权限。同时拥有 Grant\_priv 和 Node\_priv 的用户，可以将该权限赋予其他用户。

该权限只能赋予 Global 级别。

### 2. Grant\_priv

权限变更权限。允许执行包括授权、撤权、添加/删除/变更 用户/角色 等操作。

但拥有该权限的用户能不赋予其他用户 node\_priv 权限，除非用户本身拥有 node\_priv 权限。

### 3. Select\_priv

对数据库、表的只读权限。

### 4. Load\_priv

对数据库、表的写权限。包括 Load、Insert、Delete 等。

### 5. Alter\_priv

对数据库、表的更改权限。包括重命名 库/表、添加/删除/变更 列、添加/删除 分区等操作。

### 6. Create\_priv

创建数据库、表、视图的权限。

### 7. Drop\_priv

删除数据库、表、视图的权限。

### 8. Usage\_priv

资源的使用权限和 Workload Group 权限。

## 权限层级

同时，根据权限适用范围的不同，我们将库表的权限分为以下四个层级：

1. GLOBAL LEVEL：全局权限。即通过 GRANT 语句授予的 \*.\*.\* 上的权限。被授予的权限适用于任意数据库中的任意表。
2. CATALOG LEVEL：数据目录（Catalog）级权限。即通过 GRANT 语句授予的 ctl.\*.\* 上的权限。被授予的权限适用于指定 Catalog 中的任意库表。

3. DATABASE LEVEL：数据库级权限。即通过 GRANT 语句授予的 `ctl.db.*` 上的权限。被授予的权限适用于指定数据库中的任意表。
4. TABLE LEVEL：表级权限。即通过 GRANT 语句授予的 `ctl.db.tbl` 上的权限。被授予的权限适用于指定数据库中的指定表。

将资源的权限分为以下两个层级：

1. GLOBAL LEVEL：全局权限。即通过 GRANT 语句授予的 `*` 上的权限。被授予的权限适用于资源。
2. RESOURCE LEVEL：资源级权限。即通过 GRANT 语句授予的 `resource_name` 上的权限。被授予的权限适用于指定资源。

#### 此功能为实验版本

Workload Group 只有一个层级：

1. WORKLOAD GROUP LEVEL：可以通过 GRANT 语句授予 `workload_group_name` 上的权限。被授予的权限适用于指定 workload group。workload\_group\_name 支持 `%` 和 `_` 匹配符，`%` 可匹配任意字符串，`_` 匹配任意单个字符。

## ADMIN/GRANT 权限说明

ADMIN\_PRIV 和 GRANT\_PRIV 权限同时拥有授予权限的权限，较为特殊。这里对和这两个权限相关的操作逐一说明。

### 1. CREATE USER

- 拥有 ADMIN 权限，或 GLOBAL 和 DATABASE 层级的 GRANT 权限的用户可以创建新用户。

### 2. DROP USER

- 拥有 ADMIN 权限或全局层级的 GRANT 权限的用户可以删除用户。

3. CREATE/DROP ROLE - 拥有 ADMIN 权限或全局层级的 GRANT 权限的用户可以创建角色。

### 4. GRANT/REVOKE

- 拥有 ADMIN 权限，或者 GLOBAL 层级 GRANT 权限的用户，可以授予或撤销任意用户的权限。
- 拥有 CATALOG 层级 GRANT 权限的用户，可以授予或撤销任意用户对指定 CATALOG 的权限。
- 拥有 DATABASE 层级 GRANT 权限的用户，可以授予或撤销任意用户对指定数据库的权限。
- 拥有 TABLE 层级 GRANT 权限的用户，可以授予或撤销任意用户对指定数据库中指定表的权限。

### 5. SET PASSWORD

- 拥有 ADMIN 权限，或者 GLOBAL 层级 GRANT 权限的用户，可以设置任意用户的密码。
- 普通用户 can 设置自己对应的 UserIdentity 的密码。自己对应的 UserIdentity 可以通过 `SELECT CURRENT_USER()`；命令查看。



- 拥有非 GLOBAL 层级 GRANT 权限的用户，不可以设置已存在用户的密码，仅能在创建用户时指定密码。

## 一些说明

### 1. Doris 初始化时，会自动创建如下用户和角色：

1. operator 角色：该角色拥有 Node\_priv 和 Admin\_priv，即对 Doris 的所有权限。
2. admin 角色：该角色拥有 Admin\_priv，即除节点变更以外的所有权限。
3. root@'%': root 用户，允许从任意节点登陆，角色为 operator。
4. admin@'%': admin 用户，允许从任意节点登陆，角色为 admin。

### 2. 不支持删除或更改默认创建的角色或用户的权限。

### 3. operator 角色的用户有且只有一个，即 Root。admin 角色的用户可以创建多个。

### 4. 一些可能产生冲突的操作说明

#### 1. 域名与 ip 冲突：

假设创建了如下用户：

```
CREATE USER cmy@['domain'];
```

并且授权：

```
GRANT SELECT_PRIV ON . TO cmy@['domain']
```

该 domain 被解析为两个 ip：ip1 和 ip2

假设之后，我们对 cmy@'ip1' 进行一次单独授权：

```
GRANT ALTER_PRIV ON . TO cmy@'ip1';
```

则 cmy@'ip1' 的权限会被修改为 SELECT\_PRIV, ALTER\_PRIV。并且当我们再次变更 cmy@[ 'domain'] 的权限时，cmy@'ip1' 也不会跟随改变。

#### 2. 重复 ip 冲突：

假设创建了如下用户：

```
CREATE USER cmy@'%' IDENTIFIED BY "12345";
```

```
CREATE USER cmy@'192.%' IDENTIFIED BY "abcde";
```

在优先级上，'192.%' 优先于 '%'，因此，当用户 cmy 从 192.168.1.1 这台机器尝试使用密码 '12345' 登陆 Doris 会被拒绝。

### 5. 忘记密码

如果忘记了密码无法登陆 Doris，可以在 FE 的 config 文件中添加 skip\_localhost\_auth\_check 参数，并且重启 FE，从而无密码在本机通过 localhost 登陆 Doris：

```
skip_localhost_auth_check = true
```

登陆后，可以通过 SET PASSWORD 命令重置密码。

6. 任何用户都不能重置 root 用户的密码，除了 root 用户自己。

7. ADMIN\_PRIV 权限只能在 GLOBAL 层级授予或撤销。

8. 拥有 GLOBAL 层级 GRANT\_PRIV 其实等同于拥有 ADMIN\_PRIV，因为该层级的 GRANT\_PRIV 有授予任意权限的权限，请谨慎使用。

9. current\_user() 和 user()

用户可以通过 SELECT current\_user(); 和 SELECT user(); 分别查看 current\_user 和 user。其中 current\_user 表示当前用户是以哪种身份通过认证系统的，而 user 则是用户当前实际的 user\_identity。举例说明：

假设创建了 user1@'192.%' 这个用户，然后以为来自 192.168.10.1 的用户 user1 登陆了系统，则此时的 current\_user 为 user1@'192.%'，而 user 为 user1@'192.168.10.1'。

所有的权限都是赋予某一个 current\_user 的，真实用户拥有对应的 current\_user 的所有权限。

## 10. 密码强度

在 1.2 版本中，新增了对用户密码强度的校验功能。该功能由全局变量 validate\_password\_policy 控制。默认为 NONE/0，即不检查密码强度。如果设置为 STRONG/2，则密码必须包含“大写字母”，“小写字母”，“数字”和“特殊字符”中的 3 项，并且长度必须大于等于 8。

## 行级权限

从 1.2 版本开始，可以通过 [CREATE ROW POLICY](#) 命令创建行级权限。

## 最佳实践

这里举例一些 Doris 权限系统的使用场景。

### 1. 场景一

Doris 集群的使用者分为管理员（Admin）、开发工程师（RD）和用户（Client）。其中管理员拥有整个集群的所有权限，主要负责集群的搭建、节点管理等。开发工程师负责业务建模，包括建库建表、数据的导入和修改等。用户访问不同的数据库和表来获取数据。

在这种场景下，可以为管理员赋予 ADMIN 权限或 GRANT 权限。对 RD 赋予对任意或指定数据库表的 CREATE、DROP、ALTER、LOAD、SELECT 权限。对 Client 赋予对任意或指定数据库表 SELECT 权限。同时，也可以通过创建不同的角色，来简化对多个用户的授权操作。

### 2. 场景二

一个集群内有多个业务，每个业务可能使用一个或多个数据。每个业务需要管理自己的用户。在这种场景下。管理员用户可以为每个数据库创建一个拥有 DATABASE 层级 GRANT 权限的用户。该用户仅可以对用户进行指定的数据库的授权。

### 3. 黑名单

Doris 本身不支持黑名单，只有白名单功能，但我们可以通过某些方式来模拟黑名单。假设先创建了名为 `user@'192.%'` 的用户，表示允许来自 `192.*` 的用户登录。此时如果想禁止来自 `192.168.10.1` 的用户登录。则可以再创建一个用户 `cmy@'192.168.10.1'` 的用户，并设置一个新的密码。因为 `192.168.10.1` 的优先级高于 `192.%`，所以来自 `192.168.10.1` 将不能再使用旧密码进行登录。

## 更多帮助

关于 权限管理 使用的更多详细语法及最佳实践，请参阅 [GRANTS](#) 命令手册，你也可以在 MySQL 客户端命令行下输入 `HELP GRANTS` 获取更多帮助信息。

# MySQL 安全传输

## 加密连接 FE

Doris支持基于SSL的加密连接，当前支持TLS1.2，TLS1.3协议，可以通过以下配置开启Doris的SSL模式：修改FE配置文件conf/fe.conf，添加enable\_ssl = true即可。

接下来通过mysql客户端连接Doris，mysql支持三种SSL模式：

1.mysql -uroot -P9030 -h127.0.0.1与mysql --ssl-mode=PREFERRED -uroot -P9030 -h127.0.0.1一样，都是一开始试图建立SSL加密连接，如果失败，则尝试使用普通连接。

2.mysql --ssl-mode=DISABLE -uroot -P9030 -h127.0.0.1，不使用SSL加密连接，直接使用普通连接。

3.mysql --ssl-mode=REQUIRED -uroot -P9030 -h127.0.0.1，强制使用SSL加密连接。

注意：--ssl-mode参数是mysql5.7.11版本引入的，低于此版本的mysql客户端请参考[这里](#)。Doris开启SSL加密连接需要密钥证书文件验证，默认的密钥证书文件位于Doris/fe/mysql\_ssl\_default\_certificate/certificate.p12，默认密码为doris，您可以通过修改FE配置文件conf/fe.conf，添加mysql\_ssl\_default\_certificate = /path/to/your/certificate修改密钥证书文件，同时也可以通过mysql\_ssl\_default\_certificate\_password = your\_password添加对应您自定义密钥书文件的密码。

Doris还支持mTLS：修改FE配置文件conf/fe.conf，添加ssl\_force\_client\_auth=true即可。

接下来可以通过mysql客户端连接Doris：

```
mysql --ssl-mode=VERIFY_CA -uroot -P9030 -h127.0.0.1 --tls-version=TLSv1.2 --ssl-ca=/path/to/your/ca --ssl-cert=/path/to/your/cert --ssl-key=/path/to/your/key
```

默认的ca，cert，key文件位于Doris/conf/mysql\_ssl\_default\_certificate/client\_certificate/，分别叫做ca.pem，client-cert.pem，client-key.pem。

你也可以通过openssl或者keytool生成自己的证书文件。

## SSL密钥证书配置

Doris 开启 SSL 功能需要配置 CA 密钥证书和 Server 端密钥证书，如需开启双向认证，还需生成 Client 端密钥证书：

- 默认的 CA 密钥证书文件位于Doris/fe/mysql\_ssl\_default\_certificate/ca\_certificate.p12，默认密码为doris，您可以通过修改 FE 配置文件conf/fe.conf，添加mysql\_ssl\_default\_ca\_certificate = /path/to/your/certificate修改 CA 密钥证书文件，同时也可以通过mysql\_ssl\_default\_ca\_certificate\_password = your\_password添加对应您自定义密钥证书文件的密码。

- 默认的 Server 端密钥证书文件位于 Doris/fe/mysql\_ssl\_default\_certificate/server\_certificate.p12，默认密码为doris，您可以通过修改 FE 配置文件conf/fe.conf，添加mysql\_ssl\_default\_server\_certificate = /path/to/your/certificate修改 Server 端密钥证书文件，同时也可以通过 mysql\_ssl\_default\_server\_certificate\_password = your\_password添加对应您自定义密钥证书文件的密码。
- 默认生成了一份 Client 端的密钥证书，分别存放在 Doris/fe/mysql\_ssl\_default\_certificate/client-key.pem和 Doris/fe/mysql\_ssl\_default\_certificate/client\_certificate/。

## 自定义密钥证书文件

除了 Doris 默认的证书文件，您也可以通过openssl生成自定义的证书文件。步骤参考[MySQL 生成 SSL 证书](#) 具体如下：

### 1. 生成 CA、Server 端和 Client 端的密钥和证书

```
生成 CA certificate
openssl genrsa 2048 > ca-key.pem
openssl req -new -x509 -nodes -days 3600 \
 -key ca-key.pem -out ca.pem

生成 server certificate, 并用上述 CA 签名
server-cert.pem = public key, server-key.pem = private key
openssl req -newkey rsa:2048 -days 3600 \
 -nodes -keyout server-key.pem -out server-req.pem
openssl rsa -in server-key.pem -out server-key.pem
openssl x509 -req -in server-req.pem -days 3600 \
 -CA ca.pem -CAkey ca-key.pem -set_serial 01 -out server-cert.pem

生成 client certificate, 并用上述 CA 签名
client-cert.pem = public key, client-key.pem = private key
openssl req -newkey rsa:2048 -days 3600 \
 -nodes -keyout client-key.pem -out client-req.pem
openssl rsa -in client-key.pem -out client-key.pem
openssl x509 -req -in client-req.pem -days 3600 \
 -CA ca.pem -CAkey ca-key.pem -set_serial 01 -out client-cert.pem
```

### 2. 验证创建的证书。

```
openssl verify -CAfile ca.pem server-cert.pem client-cert.pem
```

3. 将您的 CA 密钥和证书和 Server 端密钥和证书分别合并到 PKCS#12 (P12) 包中。您也可以指定某个证书格式，默认 PKCS12，可以通过修改 conf/fe.conf 配置文件，添加参数 ssl\_trust\_store\_type 指定证书格式

```
打包 CA 密钥和证书
openssl pkcs12 -inkey ca-key.pem -in ca.pem -export -out ca_certificate.p12

打包 Server 端密钥和证书
openssl pkcs12 -inkey server-key.pem -in server-cert.pem -export -out server_certificate.p12
```

**Note**

[参考文档](#)

# HTTP 安全传输

---

从 2.0 版本开始，Doris 支持 SSL 密钥证书配置

Doris FE 接口开启 SSL 功能需要配置密钥证书，步骤如下：

1. 购买或生成自签名 SSL 证书，生产环境建议使用 CA 颁发的证书
2. 将 SSL 证书复制到指定路径下，默认路径为 `${DORIS_HOME}/conf/ssl/`，用户也可以自己指定路径
3. 修改 FE 配置文件 `conf/fe.conf`，注意以下参数与购买或生成的 SSL 证书保持一致
  - 设置 `enable_https = true` 开启 https 功能，默认为 `false`
  - 设置证书路径 `key_store_path`，默认为 `${DORIS_HOME}/conf/ssl/doris_ssl_certificate.keystore`
  - 设置证书密码 `key_store_password`，默认为空
  - 设置证书类型 `key_store_type`，默认为 `JKS`
  - 设置证书别名 `key_store_alias`，默认为 `doris_ssl_certificate`

# 基于 LDAP 的用户认证

---

接入第三方 LDAP 服务为 Doris 提供验证登录和组授权服务。

LDAP 验证登录指的是接入 LDAP 服务的密码验证来补充 Doris 的验证登录。Doris 优先使用 LDAP 验证用户密码，如果 LDAP 服务中不存在该用户则继续使用 Doris 验证密码，如果 LDAP 密码正确但是 Doris 中没有对应账户则创建临时用户登录 Doris。

LDAP 组授权是将 LDAP 中的 group 映射到 Doris 中的 Role，如果用户在 LDAP 中属于多个用户组，登录 Doris 后用户将获得所有组对应 Role 的权限，要求组名与 Role 名字相同。

## 名词解释

- LDAP：轻量级目录访问协议，能够实现账号密码的集中管理。
- 权限 Privilege：权限作用的对象是节点、数据库或表。不同的权限代表不同的操作许可。
- 角色 Role：Doris 可以创建自定义命名的角色。角色可以被看做是一组权限的集合。

## LDAP 相关概念

在 LDAP 中，数据是按照树型结构组织的。

示例（下文的介绍都将根据这个例子进行展开）

- dc=example,dc=com
- ou = ou1
  - cn = group1
  - cn = user1
- ou = ou2
  - cn = group2
    - cn = user2
- cn = user3

## LDAP 名词解释

- dc(Domain Component): 可以理解为一个组织的域名，作为树的根结点
- dn(Distinguished Name): 相当于唯一名称，例如 user1 的 dn 为 cn=user1,ou=ou1,dc=example,dc=com  
user2 的 dn 为 cn=user2,cn=group2,ou=ou2,dc=example,dc=com



- rdn(Relative Distinguished Name): dn 的一部分，user1 的四个 rdn 为 cn=user1 ou=ou1 dc=example 和 dc=com
- ou(Organization Unit): 可以理解为子组织，user 可以放在 ou 中，也可以直接放在 example.com 域中
- cn(common name):名字
- group: 组，可以理解为 doris 的角色
- user: 用户，和 doris 的用户等价
- objectClass: 可以理解为每行数据的类型，比如怎么区分 group1 是 group 还是 user，每种类型的数据下面要求有不同的属性，比如 group 要求有 cn 和 member (user 列表)，user 要求有 cn,password,uid 等

## 启用 LDAP 认证

### server 端配置

需要在 fe/conf/ldap.conf 文件中配置 LDAP 基本信息，另有 LDAP 管理员密码需要使用 sql 语句进行设置。

配置 fe/conf/ldap.conf 文件：

- ldap\_authentication\_enabled = false

设置值为“true”启用 LDAP 验证；当值为“false”时，不启用 LDAP 验证，该配置文件的其他配置项都无效。

- ldap\_host = 127.0.0.1

LDAP 服务 ip。

- ldap\_port = 389

LDAP 服务端口，默认明文传输端口为 389，目前 Doris 的 LDAP 功能仅支持明文密码传输。

- ldap\_admin\_name = cn=admin,dc=domain,dc=com

LDAP 管理员账户“Distinguished Name”。当用户使用 LDAP 验证登录 Doris 时，Doris 会绑定该管理员账户在 LDAP 中搜索用户信息。

- ldap\_user\_basedn = ou=people,dc=domain,dc=com

Doris 在 LDAP 中搜索用户信息时的 base dn，例如只允许上例中的 user2 登陆 doris，此处配置为 ou=ou2,dc=example,dc=com 如果允许上例中的 user1,user2,user3 都能登陆 doris，此处配置为 dc=example,dc=com

- ldap\_user\_filter = (&(uid={login}))

- Doris 在 LDAP 中搜索用户信息时的过滤条件，占位符“{login}”会被替换为登录用户名。必须保证通过该过滤条件搜索的用户唯一，否则 Doris 无法通过 LDAP 验证密码，登录时会出现“ERROR 5081 (42000): user is not unique in LDAP server.”的错误信息。

例如使用 LDAP 用户节点 uid 属性作为登录 Doris 的用户名可以配置该项为：ldap\_user\_filter = (&(uid={login})); 使用 LDAP 用户邮箱前缀作为用户名可配置该项：ldap\_user\_filter = (&(mail=

{login}@baidu.com))。

- ldap\_group\_basedn = ou=group,dc=domain,dc=com

Doris 在 LDAP 中搜索组信息时的 base dn。如果不配置该项，将不启用 LDAP 组授权。同 ldap\_user\_basedn 类似，限制 doris 搜索 group 时的范围。

### 设置 LDAP 管理员密码：

配置好 ldap.conf 文件后启动 fe，使用 root 或 admin 账号登录 Doris，执行 sql：

```
set ldap_admin_password = password('ldap_admin_password');
```

## Client 端配置

### MySQL Client

客户端使用 LDAP 验证需要启用 MySQL 客户端明文验证插件，使用命令行登录 Doris 可以使用下面两种方式之一启用 MySQL 明文验证插件：

- 设置环境变量 LIBMYSQL\_ENABLE\_CLEARTEXT\_PLUGIN 值 1。

例如在 linux 或者 mac 环境中可以使用：

```
echo "export LIBMYSQL_ENABLE_CLEARTEXT_PLUGIN=1" >> ~/.bash_profile && source ~/.bash_profile
```

- 每次登录 Doris 时添加参数“--enable-cleartext-plugin”：

```
mysql -hDORIS_HOST -PDORIS_PORT -u user -p --enable-cleartext-plugin
```

输入 ldap 密码

### JDBC Client

使用 JDBC Client 登录 Doris 时，需要自定义 Plugin。

首先，创建一个名为 MysqlClearPasswordPluginWithoutSSL 的类，继承自 MysqlClearPasswordPlugin。在该类中，重写 requiresConfidentiality() 方法，并返回 false。

```
public class MysqlClearPasswordPluginWithoutSSL extends MysqlClearPasswordPlugin {
 @Override
 public boolean requiresConfidentiality() {
 return false;
 }
}
```

在获取数据库连接时，需要将自定义的 plugin 配置到属性中

即 (xxx 为自定义类的包名)

- authenticationPlugins=xxx.xxx.xxx.MysqlClearPasswordPluginWithoutSSL

- defaultAuthenticationPlugin=xxx.xxx.xxx.MysqlClearPasswordPluginWithoutSSL
- disabledAuthenticationPlugins=com.mysql.jdbc.authentication.MysqlClearPasswordPlugin

eg:

```
jdbcUrl = "jdbc:mysql://localhost:9030/mydatabase?
authenticationPlugins=xxx.xxx.xxx.MysqlClearPasswordPluginWithoutSSL&defaultAuthenticationPlugin=xxx.xxx.xxx.
MysqlClearPasswordPluginWithoutSSL&disabledAuthenticationPlugins=com.mysql.jdbc.authentication.MysqlClearPass
wordPlugin";
```

## LDAP 认证详解

LDAP 密码验证和组授权是 Doris 密码验证和授权的补充，开启 LDAP 功能并不能完全替代 Doris 的密码验证和授权，而是与 Doris 密码验证和授权并存。

### LDAP 验证登录详解

开启 LDAP 后，用户在 Doris 和 LDAP 中存在以下几种情况：

| LDAP 用户 | Doris 用户 | 密码       | 登录情况 | 登录 Doris 的用户 |
|---------|----------|----------|------|--------------|
| 存在      | 存在       | LDAP 密码  | 登录成功 | Doris 用户     |
| 存在      | 存在       | Doris 密码 | 登录失败 | 无            |
| 不存在     | 存在       | Doris 密码 | 登录成功 | Doris 用户     |
| 存在      | 不存在      | LDAP 密码  | 登录成功 | Ldap 临时用户    |

开启 LDAP 后，用户使用 mysql client 登录时，Doris 会先通过 LDAP 服务验证用户密码，如果 LDAP 存在用户且密码正确，Doris 则使用该用户登录；此时 Doris 若存在对应账户则直接登录该账户，如果不存在对应账户则为用户创建临时账户并登录该账户。临时账户具有具有相应对权限（参见 LDAP 组授权），仅对当前连接有效，doris 不会创建该用户，也不会产生创建用户对元数据。如果 LDAP 服务中不存在登录用户，则使用 Doris 进行密码认证。

以下假设已开启 LDAP 认证，配置 ldap\_user\_filter = (&(uid={login})), 且其他配置项都正确，客户端设置环境变量 LIBMYSQL\_ENABLE\_CLEARTEXT\_PLUGIN=1

例如：

#### 1: Doris 和 LDAP 中都存在账户：

存在 Doris 账户：jack@'172.10.1.10'，密码：123456 LDAP 用户节点存在属性：uid: jack 用户密码：abcdef 使用以下命令登录 Doris 可以登录 jack@'172.10.1.10'账户：

```
mysql -hDoris_HOST -PDoris_PORT -ujack -p abcdef
```

使用以下命令将登录失败：

```
mysql -hDoris_HOST -PDoris_PORT -ujack -p 123456
```

2: LDAP 中存在用户，Doris 中不存在对应账户：

LDAP 用户节点存在属性：uid: jack 用户密码：abcdef 使用以下命令创建临时用户并登录 jack@‘%’，临时用户具有基本权限 DatabasePrivs: Select\_priv，用户退出登录后 Doris 将删除该临时用户：

```
mysql -hDoris_HOST -PDoris_PORT -ujack -p abcdef
```

3: LDAP 不存在用户：

存在 Doris 账户：jack@‘172.10.1.10’，密码：123456 使用 Doris 密码登录账户，成功：

```
mysql -hDoris_HOST -PDoris_PORT -ujack -p 123456
```

LDAP 组授权详解

LDAP 用户 dn 是 LDAP 组节点的“member”属性则 Doris 认为用户属于该组。LDAP 组授权是将 LDAP 中的 group 映射到 Doris 中的 role，并将所有对应的 role 权限授予登录用户，用户退出登录后 Doris 会撤销对应的 role 权限。在使用 LDAP 组授权前应该在 Doris 中创建相应对 role，并为 role 授权。

登录用户权限跟 Doris 用户和组权限有关，见下表：

| LDAP 用户 | Doris 用户 | 登录用户的权限               |
|---------|----------|-----------------------|
| 存在      | 存在       | LDAP 组权限 + Doris 用户权限 |
| 不存在     | 存在       | Doris 用户权限            |
| 存在      | 不存在      | LDAP 组权限              |

如果登录的用户为临时用户，且不存在组权限，则该用户默认具有 information\_schema 的 select\_priv 权限

举例：LDAP 用户 dn 是 LDAP 组节点的“member”属性则认为用户属于该组，Doris 会截取组 dn 的第一个 Rdn 作为组名。例如用户 dn 为“uid=jack,ou=aidp,dc=domain,dc=com”，组信息如下：

```
dn: cn=doris_rd,ou=group,dc=domain,dc=com
objectClass: groupOfNames
member: uid=jack,ou=aidp,dc=domain,dc=com
```

则组名为 doris\_rd。

假如 jack 还属于 LDAP 组 doris\_qa、doris\_pm；Doris 存在 role: doris\_rd、doris\_qa、doris\_pm，在使用 LDAP 验证登录后，用户不但具有该账户原有的权限，还将获得 role doris\_rd、doris\_qa 和 doris\_pm 的权限。

注意：

- user 属于哪个 group 和 LDAP 树的组织结构无关，示例部分的 user2 并不一定属于 group2
- 若想让 user2 属于 group2，需要在 group2 的 member 属性中添加 user2

## LDAP 信息缓存

为了避免频繁访问 LDAP 服务，Doris 会将 LDAP 信息缓存到内存中，可以通过 `ldap.conf` 中的 `ldap_user_cache_timeout_s` 配置项指定 LDAP 用户的缓存时间，默认为 12 小时；在修改了 LDAP 服务中的信息或者修改了 Doris 中 LDAP 用户组对应的 Role 权限后，可能因为缓存而没有及时生效，可以通过 `refresh ldap` 语句刷新缓存，详细查看[REFRESH-LDAP](#)。

## LDAP 验证的局限

- 目前 Doris 的 LDAP 功能只支持明文密码验证，即用户登录时，密码在 client 与 fe 之间、fe 与 LDAP 服务之间以明文的形式传输。

## 常见问题

### 1. 怎么判断 LDAP 用户在 doris 中有哪些角色？

使用 LDAP 用户在 doris 中登陆，`show grants;` 能查看当前用户有哪些角色。其中 `ldapDefaultRole` 是每个 ldap 用户在 doris 中都有的默认角色。

### 2. LDAP 用户在 doris 中的角色比预期少怎么排查？

1. 通过 `show roles;` 查看预期的角色在 doris 中是否存在，如果不存在，需要通过 `CREATE ROLE rol_name;` 创建角色。
2. 检查预期的 group 是否在 `ldap_group_basedn` 对应的组织结构下。
3. 检查预期 group 是否包含 member 属性。
4. 检查预期 group 的 member 属性是否包含当前用户。

# 基于 Apache Ranger 的鉴权管理

---

对 Apache Ranger 的集成在 Doris 2.1 开始支持，请参考 Doris 2.1 文档。

# 内存跟踪器

内存跟踪器（Memory Tracker）记录了 Doris BE 进程内存使用，包括查询、导入、Compaction、Schema Change 等任务生命周期中使用的内存，以及各项缓存，用于内存控制和分析。

自 Doris 1.2 版本开始支持内存跟踪器（Memory Tracker）

## 原理

系统中每个查询、导入等任务初始化时都会创建自己的 Memory Tracker，在执行过程中将 Memory Tracker 放入 TLS（Thread Local Storage）中，BE 进程的每次内存申请和释放，都将在 Mem Hook 中消费 Memory Tracker，并最终汇总后展示。


详细设计实现可以参阅：<https://cwiki.apache.org/confluence/display/DORIS/DSIP-002%3A+Refactor+memory+tracker+on+BE> <https://shimo.im/docs/DT6JXDRkdTvdyV3G>

有关 Memory Tracker 更多介绍参考文档：[Say-Goodbye-to-OOM-Crashes-en](#)，[Say-Goodbye-to-OOM-Crashes-zh-CN](#)

## 查看统计结果

实时的内存统计结果通过 Doris BE 的 Web 页面查看 `http://{be_host}:{be_web_server_port}/mem_tracker`。（webserver\_port默认8040） 历史查询的内存统计结果可以查看 `fe/log/fe.audit.log` 中每个查询的 `peakMemoryBytes`，或者在 `be/log/be.INFO` 中搜索 `Deregister query/load memory tracker, queryId` 查看单个 BE 上每个查询的内存峰值。

## 首页 /mem\_tracker



image

### 1. Type: 将 Doris BE 使用的内存分为如下几类

- process: 进程总内存，所有其他 type 的总和。

- global: 生命周期和进程相同的全局 Memory Tracker，例如各个 Cache、Tablet Manager、Storage Engine 等。
- query: 所有查询的内存总和。
- load: 所有导入的内存总和。
- tc/jemalloc\_cache: 通用内存分配器 TCMalloc 或 Jemalloc 的缓存，在 `http://{be_host}:{be_web_server_port}/memz` 可以实时查看到内存分配器原始的 profile。
- compaction、schema\_change、consistency、batch\_load、clone: 分别对应所有 Compaction、Schema Change、Consistency、Batch Load、Clone 任务的内存总和。

- 2. Current Consumption(Bytes): 当前内存值，单位 B。
- 3. Current Consumption(Normalize): 当前内存值的 .G.M.K 格式化输出。
- 4. Peak Consumption(Bytes): BE 进程启动后的内存峰值，单位 B，BE 重启后重置。
- 5. Peak Consumption(Normalize): BE 进程启动后内存峰值的 .G.M.K 格式化输出，BE 重启后重置。

Global Type /mem\_tracker?type=global

← → ↻ ⚠ 不安全 /mem\_tracker?type=global 🔍 🏠 ☆ ⚙️ 🌐 更新

CPU Profile Heap Profile MemTracker Memory Tablets Threads Configs

Memory usage by subsystem

Search

| Type   | Label                              | Parent Label | Limit      | Current Consumption(Bytes) | Current Consumption(Normalize) | Peak Consumption(Bytes) | Peak Consumption(Normalize) |
|--------|------------------------------------|--------------|------------|----------------------------|--------------------------------|-------------------------|-----------------------------|
| global | Orphan                             |              | none       | 938669870                  | 895M.189K                      | 948186644               | 904M.267K                   |
|        | BufferAllocator                    | Orphan       | none       | 0                          | 0K                             | 0                       | 0K                          |
|        | LoadChannelMgr                     | Orphan       | none       | 0                          | 0K                             | 0                       | 0K                          |
|        | StorageEngine                      | Orphan       | none       | 483637736                  | 461M.238K                      | 487832272               | 469M.238K                   |
|        | SegCompaction                      | Orphan       | none       | 0                          | 0K                             | 0                       | 0K                          |
|        | SegmentMeta                        | Orphan       | none       | 1072420                    | 1047K                          | 1067266                 | 1042K                       |
|        | TabletManager                      | Orphan       | none       | 640                        | 640K                           | 782344                  | 764K                        |
|        | RuntimeFilterMergeControllerEntity | Orphan       | none       | 23808                      | 23K                            | 0                       | 0K                          |
| global | DataPageCache                      |              | none       | 237888610                  | 226M.888K                      | 236780132               | 225M.830K                   |
| global | IndexPageCache                     |              | none       | 1048965                    | 1024K                          | 0                       | 0K                          |
| global | SegmentCache                       |              | none       | 0                          | 0K                             | 0                       | 0K                          |
| global | DiskIO                             |              | 1268M.209K | 0                          | 0K                             | 0                       | 0K                          |
| global | ChunkAllocator                     |              | none       | 132521984                  | 126M.392K                      | 131473408               | 125M.392K                   |
| global | LatestSuccessfulChannelCache       |              | none       | 0                          | 0K                             | 0                       | 0K                          |
| global | DeleteStrip AggCache               |              | none       | 0                          | 0K                             | 0                       | 0K                          |

Showing 1 to 15 of 15 rows 25 rows per page

image

- 1. Label: Memory Tracker 名称
- 2. Parent Label:


用于表明两个 Memory Tracker 的父子关系，Child Tracker 记录的内存是 Parent Tracker 的子集，Parent 相同的不同 Tracker 记录的内存可能存在交集。

- Orphan: 默认消费的 Tracker，没有单独指定 Tracker 的内存将默认记录到 Orphan，Orphan 中除了下述细分的 Child Tracker 外，还包括 BRPC 在内的一些不方便准确细分统计的内存。
  - LoadChannelMgr: 所有导入的 Load Channel 阶段内存总和，用于将 Scan 后的数据写入到磁盘的 Segment 文件中，Orphan 的子集。
  - StorageEngine:，存储引擎加载数据目录过程中消耗的内存，Orphan 的子集。



- SegCompaction: 所有 SegCompaction 任务的内存总和, Orphan 的子集。
- SegmentMeta: memory use by segment meta data such as footer or index page, Orphan 的子集。
- TabletManager: 存储引擎 get、add、delete Tablet 过程中消耗的内存, Orphan 的子集。
- BufferAllocator: 仅用于非向量化 Partitioned Agg 过程中的内存复用, Orphan 的子集。
- DataPageCache: 用于缓存数据 Page, 用于加速 Scan。
- IndexPageCache: 用于缓存数据 Page 的索引, 用于加速 Scan。
- SegmentCache: 用于缓存已打开的 Segment, 如索引信息。
- ChunkAllocator: 用于缓存 2 的幂大小的内存块, 在应用层内存复用。
- LastestSuccessChannelCache: 用于缓存导入接收端的 LoadChannel。
- DeleteBitmap AggCache: Gets aggregated delete\_bitmap on rowset\_id and version。

## Query Type /mem\_tracker?type=query



The screenshot shows the MemTracker web interface. At the top, there's a navigation bar with tabs: CPU Profile, Heap Profile, MemTracker (selected), Memory, Tablets, Threads, and Configs. Below the navigation bar, the title "Memory usage by subsystem" is displayed. A search bar is located in the top right corner. The main content is a table with 8 columns: Type, Label, Parent Label, Limit, Current Consumption(Bytes), Current Consumption(Normalize), Peak Consumption(Bytes), and Peak Consumption(Normalize). The table lists various memory subsystems for a specific query, including Scanner, ExecNode, RuntimeFilterMgr, and VDataStream. The query ID is 1fbde3a88d704598-acf8566be5cc0443.

| Type  | Label                                               | Parent Label                               | Limit      | Current Consumption(Bytes) | Current Consumption(Normalize) | Peak Consumption(Bytes) | Peak Consumption(Normalize) |
|-------|-----------------------------------------------------|--------------------------------------------|------------|----------------------------|--------------------------------|-------------------------|-----------------------------|
| query | Query#Id=1fbde3a88d704598-acf8566be5cc0443          |                                            | 1266M,209K | 247560493                  | 236M,94K                       | 247723898               | 236M,253K                   |
|       | Scanner#QueryId=1fbde3a88d704598-acf8566be5cc0443   | Query#Id=1fbde3a88d704598-acf8566be5cc0443 | none       | 232873352                  | 222M,87K                       | 232714264               | 221M,956K                   |
|       | ExecNode:VHASH_JOIN_NODE (id=6)                     | Query#Id=1fbde3a88d704598-acf8566be5cc0443 | none       | 22457000                   | 21M,426K                       | 23785464                | 22M,699K                    |
|       | ExecNode:VNewOlapScanNode(lineorder) (id=0)         | Query#Id=1fbde3a88d704598-acf8566be5cc0443 | none       | 17350024                   | 16M,559K                       | 17226928                | 16M,439K                    |
|       | ExecNode:VAGGREGATION_NODE (id=7)                   | Query#Id=1fbde3a88d704598-acf8566be5cc0443 | none       | 6452224                    | 6M,157K                        | 6452224                 | 6M,157K                     |
|       | ExecNode:VSORT_NODE (id=8)                          | Query#Id=1fbde3a88d704598-acf8566be5cc0443 | none       | 813920                     | 794K                           | 813920                  | 794K                        |
|       | ExecNode:VAGGREGATION_NODE (id=13)                  | Query#Id=1fbde3a88d704598-acf8566be5cc0443 | none       | 811744                     | 792K                           | 811744                  | 792K                        |
|       | RuntimeFilterMgr                                    | Query#Id=1fbde3a88d704598-acf8566be5cc0443 | none       | 20416                      | 19K                            | 0                       | 0K                          |
|       | ExecNode:VEXCHANGE_NODE (id=14)                     | Query#Id=1fbde3a88d704598-acf8566be5cc0443 | none       | 5536                       | 5K                             | 6112                    | 5K                          |
|       | VDataStreamRecv:1fbde3a88d704598-acf8566be5cc0449   | Query#Id=1fbde3a88d704598-acf8566be5cc0443 | none       | 5536                       | 5K                             | 6112                    | 5K                          |
|       | AggregationNode:Data                                | Query#Id=1fbde3a88d704598-acf8566be5cc0443 | none       | 4840                       | 4K                             | 4456                    | 4K                          |
|       | ExecNode:VEXCHANGE_NODE (id=12)                     | Query#Id=1fbde3a88d704598-acf8566be5cc0443 | none       | 4432                       | 4K                             | 5360                    | 5K                          |
|       | VDataStreamRecv:1fbde3a88d704598-acf8566be5cc0448   | Query#Id=1fbde3a88d704598-acf8566be5cc0443 | none       | 4432                       | 4K                             | 5360                    | 5K                          |
|       | VDataStreamSender:1fbde3a88d704598-acf8566be5cc0444 | Query#Id=1fbde3a88d704598-acf8566be5cc0443 | none       | 2528                       | 2K                             | 0                       | 0K                          |

## image

1. Limit: 单个查询使用的内存上限, show session variables查看和修改exec\_mem\_limit。
2. Label: 单个查询的 Tracker 的 Label 命名规则为Query#Id=xxx。
3. Parent Label: Parent 是 Query#Id=xxx 的 Tracker 记录查询不同算子执行过程使用的内存。

Load Type /mem\_tracker?type=load

← → ↻ ⚠ 不安全 /mem\_tracker?type=load 🔍 📄 ☆ ⚙ 🖨 🔄 更新

CPU Profile Heap Profile MemTracker Memory Tablets Threads Configs

Memory usage by subsystem

Search

| Type | Label                                                                                       | Parent Label             | Limit | Current Consumption(Bytes) | Current Consumption(Normalize) | Peak Consumption(Bytes) | Peak Consumption(Normalize) |
|------|---------------------------------------------------------------------------------------------|--------------------------|-------|----------------------------|--------------------------------|-------------------------|-----------------------------|
|      | LoadChannel#senderIp=172.24.47.117#loadID=8447da9b15159c3c-92aa42cc2d60babf                 | LoadChannelMgrTrackerSet | none  | 165015552                  | 157M,380K                      | 597983368               | 570M,288K                   |
|      | MemTableManualInsert:TabletId=46007:MemTableNum=65#loadID=8447da9b15159c3c-92aa42cc2d60babf | LoadChannelMgrTrackerSet | none  | 110850048                  | 105M,732K                      | 110325760               | 105M,220K                   |
| load | LoadChannelMgrTrackerSet                                                                    |                          | none  | 0                          | 0K                             | 0                       | 0K                          |
|      | MemTableManualInsert:TabletId=46007:MemTableNum=1#loadID=8447da9b15159c3c-92aa42cc2d60babf  | LoadChannelMgrTrackerSet | none  | 0                          | 0K                             | 208138240               | 198M,508K                   |
|      | MemTableHookFlush:TabletId=46007:MemTableNum=1#loadID=8447da9b15159c3c-92aa42cc2d60babf     | LoadChannelMgrTrackerSet | none  | 0                          | 0K                             | 289829056               | 276M,412K                   |
|      | MemTableManualInsert:TabletId=46007:MemTableNum=2#loadID=8447da9b15159c3c-92aa42cc2d60babf  | LoadChannelMgrTrackerSet | none  | 0                          | 0K                             | 208138240               | 198M,508K                   |
|      | MemTableHookFlush:TabletId=46007:MemTableNum=2#loadID=8447da9b15159c3c-92aa42cc2d60babf     | LoadChannelMgrTrackerSet | none  | 0                          | 0K                             | 289087520               | 275M,712K                   |
|      | MemTableManualInsert:TabletId=46007:MemTableNum=3#loadID=8447da9b15159c3c-92aa42cc2d60babf  | LoadChannelMgrTrackerSet | none  | 0                          | 0K                             | 208138240               | 198M,508K                   |
|      | MemTableHookFlush:TabletId=46007:MemTableNum=3#loadID=8447da9b15159c3c-92aa42cc2d60babf     | LoadChannelMgrTrackerSet | none  | 0                          | 0K                             | 289087400               | 275M,711K                   |
|      | MemTableManualInsert:TabletId=46007:MemTableNum=4#loadID=8447da9b15159c3c-92aa42cc2d60babf  | LoadChannelMgrTrackerSet | none  | 0                          | 0K                             | 208138240               | 198M,508K                   |
|      | MemTableHookFlush:TabletId=46007:MemTableNum=4#loadID=8447da9b15159c3c-92aa42cc2d60babf     | LoadChannelMgrTrackerSet | none  | 0                          | 0K                             | 289087320               | 275M,711K                   |
|      | MemTableManualInsert:TabletId=46007:MemTableNum=5#loadID=8447da9b15159c3c-92aa42cc2d60babf  | LoadChannelMgrTrackerSet | none  | 0                          | 0K                             | 208138240               | 198M,508K                   |
|      | MemTableHookFlush:TabletId=46007:MemTableNum=5#loadID=8447da9b15159c3c-92aa42cc2d60babf     | LoadChannelMgrTrackerSet | none  | 0                          | 0K                             | 289087496               | 275M,712K                   |
|      | MemTableManualInsert:TabletId=46007:MemTableNum=6#loadID=8447da9b15159c3c-92aa42cc2d60babf  | LoadChannelMgrTrackerSet | none  | 0                          | 0K                             | 208138240               | 198M,508K                   |
|      | MemTableHookFlush:TabletId=46007:MemTableNum=6#loadID=8447da9b15159c3c-92aa42cc2d60babf     | LoadChannelMgrTrackerSet | none  | 0                          | 0K                             | 289087512               | 275M,712K                   |

image

1. Limit: 导入分为 Fragment Scan 和 Load Channel 写 Segment 到磁盘两个阶段。Scan 阶段的内存上限通过show session variables查看和修改load\_mem\_limit；Segment 写磁盘阶段每个导入没有单独的内存上限，而是所有导入的总上限，对应 be.conf 中的 load\_process\_max\_memory\_limit\_percent。
2. Label: 单个导入 Scan 阶段 Tracker 的 Label 命名规则为Load#Id=xxx；单个导入 Segment 写磁盘阶段 Tracker 的 Label 命名规则为LoadChannel#senderIp=xxx#loadID=xxx。
3. Parent Label: Parent 是 Load#Id=xxx 的 Tracker 记录导入 Scan 阶段不同算子执行过程使用的内存；Parent 是 LoadChannelMgrTrackerSet 的 Tracker 记录 Segment 写磁盘阶段每个中间数据结构 MemTable 的 Insert 和 Flush 磁盘过程使用的内存，用 Label 最后的 loadID 关联 Segment 写磁盘阶段 Tracker。

# 内存超限错误分析

当查询或导入报错Memory limit exceeded时，可能的原因：进程内存超限、系统剩余可用内存不足、超过单次查询执行的内存上限。

```
ERROR 1105 (HY000): errCode = 2, detailMessage = Memory limit exceeded:<consuming tracker:<xxx>, xxx. backend 172.1.1.1 process memory used xxx GB, limit xxx GB. If query tracker exceed, `set exec_mem_limit=8G` to change limit, details mem usage see be.INFO.
```

自 Doris 1.2 版本开始支持该功能

有关内存管理的更多介绍参考文档：[Say-Goodbye-to-OOM-Crashes-en](#)，[Say-Goodbye-to-OOM-Crashes-zh-CN](#)

## 进程内存超限 OR 系统剩余可用内存不足

当返回如下报错时，说明进程内存超限，或者系统剩余可用内存不足，具体原因看内存统计值。

```
ERROR 1105 (HY000): errCode = 2, detailMessage = Memory limit exceeded:<consuming tracker:
<Query#Id=3c88608cf35c461d-95fe88969aa6fc30>, process memory used 2.68 GB exceed limit 2.47 GB or sys mem
available 50.95 GB less than low water mark 3.20 GB, failed alloc size 2.00 MB>, executing msg:<execute:
<ExecNode:VAGGREGATION_NODE (id=7)>>. backend 172.1.1.1 process memory used 2.68 GB, limit 2.47 GB. If query
tracker exceed, `set exec_mem_limit=8G` to change limit, details mem usage see be.INFO
```

## 错误信息分析

错误信息分为三部分：1.Memory limit exceeded:<consuming tracker:<Query#Id=3c88608cf35c461d-95fe88969aa6fc30>：当前正在执行 query 3c88608cf35c461d-95fe88969aa6fc30的内存申请过程中发现内存超限。

2.process memory used 2.68 GB exceed limit 2.47 GB or sys mem available 50.95 GB less than low water mark 3.20 GB, failed alloc size 2.00 MB：超限的原因是 BE 进程使用的内存 2.68GB 超过了 2.47GB 的 limit，limit 的值来自 be.conf 中的 mem\_limit \* system MemTotal，默认等于操作系统总内存的 80%，当前操作系统剩余可用内存 50.95 GB 仍高于最低水位 3.2GB，本次尝试申请 2MB 的内存。

3. executing msg:<execute:<ExecNode:VAGGREGATION\_NODE (id=7)>>, backend 172.24.47.117 process memory used 2.68 GB, limit 2.47 GB：本次内存申请的位置是 ExecNode:VAGGREGATION\_NODE (id=7)>，当前 BE 节点的 IP 是 172.1.1.1，以及再次打印 BE 节点的内存统计。

## 日志分析

同时可以在 log/be.INFO 中找到如下日志，确认当前进程内存使用是否符合预期，日志同样分为三部分：

1. Process Memory Summary: 进程内存统计。
2. Alloc Stacktrace: 触发内存超限检测的栈, 这不一定是大内存申请的位置。
3. Memory Tracker Summary: 进程 memory tracker 统计, 参考 [Memory Tracker](#) 分析使用内存的位置。

#### 注意:

1. 进程内存超限日志的打印间隔是 1s, 进程内存超限后, BE 大多数位置的内存申请都会感知, 并尝试做出预定的回调方法, 并打印进程内存超限日志, 所以如果日志中 Try Alloc 的值很小, 则无须关注 Alloc Stacktrace, 直接分析 Memory Tracker Summary 即可。
2. 当进程内存超限后, BE 会触发内存 GC。

```
W1127 17:23:16.372572 19896 mem_tracker_limiter.cpp:214] System Mem Exceed Limit Check Failed, Try Alloc: 1062688
```

#### Process Memory Summary:

```
process memory used 2.68 GB limit 2.47 GB, sys mem available 50.95 GB min reserve 3.20 GB, tc/jemalloc allocator cache 51.97 MB
```

#### Alloc Stacktrace:

```
@ 0x50028e8 doris::MemTrackerLimiter::try_consume()
@ 0x50027c1 doris::ThreadMemTrackerMgr::flush_untracked_mem<>()
@ 0x595f234 malloc
@ 0xb888c18 operator new()
@ 0x8f316a2 google::LogMessage::Init()
@ 0x5813fef doris::FragmentExecState::coordinator_callback()
@ 0x58383dc doris::PlanFragmentExecutor::send_report()
@ 0x5837ea8 doris::PlanFragmentExecutor::update_status()
@ 0x58355b0 doris::PlanFragmentExecutor::open()
@ 0x5815244 doris::FragmentExecState::execute()
@ 0x5817965 doris::FragmentMgr::_exec_actual()
@ 0x581fffb std::_Function_handler<::M_invoke()
@ 0x5a6f2c1 doris::ThreadPool::dispatch_thread()
@ 0x5a6843f doris::Thread::supervise_thread()
@ 0x7feb54f931ca start_thread
@ 0x7feb5576add3 __GI__clone
@ (nil) (unknown)
```

#### Memory Tracker Summary:

```
Type=consistency, Used=0(0 B), Peak=0(0 B)
Type=batch_load, Used=0(0 B), Peak=0(0 B)
Type=clone, Used=0(0 B), Peak=0(0 B)
Type=schema_change, Used=0(0 B), Peak=0(0 B)
Type=compaction, Used=0(0 B), Peak=0(0 B)
Type=load, Used=0(0 B), Peak=0(0 B)
Type=query, Used=206.67 MB(216708729 B), Peak=565.26 MB(592723181 B)
Type=global, Used=930.42 MB(975614571 B), Peak=1017.42 MB(1066840223 B)
Type=tc/jemalloc_cache, Used=51.97 MB(54494616 B), Peak=-1.00 B(-1 B)
Type=process, Used=1.16 GB(1246817916 B), Peak=-1.00 B(-1 B)
MemTrackerLimiter Label=Orphan, Type=global, Limit=-1.00 B(-1 B), Used=474.20 MB(497233597 B),
Peak=649.18 MB(680718208 B)
MemTracker Label=BufferAllocator, Parent Label=Orphan, Used=0(0 B), Peak=0(0 B)
MemTracker Label=LoadChannelMgr, Parent Label=Orphan, Used=0(0 B), Peak=0(0 B)
MemTracker Label=StorageEngine, Parent Label=Orphan, Used=320.56 MB(336132488 B), Peak=322.56
MB(338229824 B)
MemTracker Label=SegCompaction, Parent Label=Orphan, Used=0(0 B), Peak=0(0 B)
MemTracker Label=SegmentMeta, Parent Label=Orphan, Used=948.64 KB(971404 B), Peak=943.64 KB(966285 B)
MemTracker Label=TabletManager, Parent Label=Orphan, Used=0(0 B), Peak=0(0 B)
MemTrackerLimiter Label=DataPageCache, Type=global, Limit=-1.00 B(-1 B), Used=455.22 MB(477329882 B),
```

```
Peak=454.18 MB(476244180 B)
 MemTrackerLimiter Label=IndexPageCache, Type=global, Limit=-1.00 B(-1 B), Used=1.00 MB(1051092 B),
Peak=0(0 B)
 MemTrackerLimiter Label=SegmentCache, Type=global, Limit=-1.00 B(-1 B), Used=0(0 B), Peak=0(0 B)
 MemTrackerLimiter Label=DiskIO, Type=global, Limit=2.47 GB(2655423201 B), Used=0(0 B), Peak=0(0 B)
 MemTrackerLimiter Label=ChunkAllocator, Type=global, Limit=-1.00 B(-1 B), Used=0(0 B), Peak=0(0 B)
 MemTrackerLimiter Label=LastestSuccessChannelCache, Type=global, Limit=-1.00 B(-1 B), Used=0(0 B),
Peak=0(0 B)
 MemTrackerLimiter Label=DeleteBitmap AggCache, Type=global, Limit=-1.00 B(-1 B), Used=0(0 B), Peak=0(0 B)
```

## 系统剩余可用内存计算

当错误信息中系统可用内存小于低水位线时，同样当作进程内存超限处理，其中系统可用内存的值来自于 `/proc/meminfo` 中的 `MemAvailable`，当 `MemAvailable` 不足时继续内存申请可能返回 `std::bad_alloc` 或者导致 BE 进程 OOM，因为刷新进程内存统计和 BE 内存 GC 都具有一定的滞后性，所以预留小部分内存 buffer 作为低水位线，尽可能避免 OOM。

其中 `MemAvailable` 是操作系统综合考虑当前空闲的内存、buffer、cache、内存碎片等因素给出的一个在尽可能不触发 swap 的情况下可以提供给用户进程使用的内存总量，一个简单的计算公式： $\text{MemAvailable} = \text{MemFree} - \text{LowWaterMark} + (\text{PageCache} - \min(\text{PageCache} / 2, \text{LowWaterMark}))$ ，和 `cmd free` 看到的 `available` 值相同，具体可参考：<https://serverfault.com/questions/940196/why-is-memavailable-a-lot-less-than-memfreebufferscached> <https://git.kernel.org/pub/scm/linux/kernel/git/torvalds/linux.git/commit/?id=34e431b0ae398fc54ea69ff85ec700722c9da773>

低水位线默认最大 1.6G，根据 `MemTotal`、`vm/min_free_kbytes`、`config::mem_limit`、`config::max_sys_mem_available_low_water_mark_bytes` 共同算出，并避免浪费过多内存。其中 `MemTotal` 是系统总内存，取值同样来自 `/proc/meminfo`；`vm/min_free_kbytes` 是操作系统给内存 GC 过程预留的 buffer，取值通常在 0.4% 到 5% 之间，某些云服务器上 `vm/min_free_kbytes` 可能为 5%，这会导致直观上系统可用内存比真实值少；调大 `config::max_sys_mem_available_low_water_mark_bytes` 将在大于 16G 内存的机器上，为 Full GC 预留更多的内存 buffer，反之调小将尽可能充分使用内存。

## 查询或导入单次执行内存超限

当返回如下报错时，说明超过单次执行内存限制。

```
ERROR 1105 (HY000): errCode = 2, detailMessage = Memory limit exceeded:<consuming tracker:
<Query#Id=f78208b15e064527-a84c5c0b04c04fcf>, failed alloc size 1.03 MB, exceeded tracker:
<Query#Id=f78208b15e064527-a84c5c0b04c04fcf>, limit 100.00 MB, peak used 99.29 MB, current used 99.25 MB>,
executing msg:<execute:<ExecNode:VHASH_JOIN_NODE (id=4)>>. backend 172.24.47.117 process memory used 1.13 GB,
limit 98.92 GB. If query tracker exceed, `set exec_mem_limit=8G` to change limit, details mem usage see
log/be.INFO.
```

## 错误信息分析

错误信息分为三部分：1. `Memory limit exceeded:<consuming tracker:<Query#Id=f78208b15e064527-a84c5c0b04c04fcf>`：当前正在执行 query `f78208b15e064527-a84c5c0b04c04fcf` 的内存申请过程中发现内存超限。

2. `failed alloc size 1.03 MB, exceeded tracker:<Query#Id=f78208b15e064527-a84c5c0b04c04fcf>`，`limit 100.00 MB`，`peak used 99.29 MB`，`current used 99.25 MB`：本次尝试申请 1.03MB 的内存，但此时 query `f78208b15e064527-a84c5c0b04c04fcf` memory tracker 的当前

consumption 为 99.28MB 加上 1.03MB 后超过了 100MB 的 limit, limit 的值来自 session variables 中的 exec\_mem\_limit, 默认 4G。

3. executing msg:<execute:<ExecNode:VHASH\_JOIN\_NODE (id=4)>>. backend 172.24.47.117 process memory used 1.13 GB, limit 98.92 GB. If query tracker exceed, set exec\_mem\_limit=8G to change limit, details mem usage see be.INFO.: 本次内存申请的位置是 VHASH\_JOIN\_NODE (id=4), 并提示可通过 set exec\_mem\_limit 来调高单次查询的内存上限。

## 日志分析

set global enable\_profile=true后, 可以在单次查询内存超限时, 在 log/be.INFO 中打印日志, 用于确认当前查询内存使用是否符合预期。同时可以在 log/be.INFO 中找到如下日志, 确认当前查询内存使用是否符合预期, 日志同样分为三部分:

1. Process Memory Summary: 进程内存统计。
2. Alloc Stacktrace: 触发内存超限检测的栈, 这不一定是大内存申请的位置。
3. Memory Tracker Summary: 当前查询的 memory tracker 统计, 可以看到查询每个算子当前使用的内存和峰值, 具体可参考 [Memory Tracker](#)。注意: 一个查询在内存超限后只会打印一次日志, 此时查询的多个线程都会感知, 并尝试等待内存释放, 或者 cancel 当前查询, 如果日志中 Try Alloc 的值很小, 则无须关注 Alloc Stacktrace, 直接分析 Memory Tracker Summary 即可。

```
W1128 01:34:11.016165 357796 mem_tracker_limiter.cpp:191] Memory limit exceeded:<consuming tracker:
<Query#Id=78208b15e064527-a84c5c0b04c04fcf>, failed alloc size 4.00 MB, exceeded tracker:
<Query#Id=78208b15e064527-a84c5c0b04c04fcf>, limit 100.00 MB, peak used 98.59 MB,
current used 96.88 MB>, executing msg:<execute:<ExecNode:VHASH_JOIN_NODE (id=2)>>. backend 172.24.47.117
process memory used 1.13 GB, limit 98.92 GB. If query tracker exceed, `set exec_mem_limit=8G` to change
limit, details mem usage see be.INFO.
Process Memory Summary:
 process memory used 1.13 GB limit 98.92 GB, sys mem available 45.15 GB min reserve 3.20 GB, tc/jemalloc
allocator cache 27.62 MB
Alloc Stacktrace:
 @ 0x66cf73a doris::vectorized::HashJoinNode::_materialize_build_side()
 @ 0x69cb1ee doris::vectorized::VJoinNodeBase::open()
 @ 0x66ce27a doris::vectorized::HashJoinNode::open()
 @ 0x5835dad doris::PlanFragmentExecutor::open_vectorized_internal()
 @ 0x58351d2 doris::PlanFragmentExecutor::open()
 @ 0x5815244 doris::FragmentExecState::execute()
 @ 0x5817965 doris::FragmentMgr::_exec_actual()
 @ 0x581ffff std::_Function_handler<>::_M_invoke()
 @ 0x5a6f2c1 doris::ThreadPool::dispatch_thread()
 @ 0x5a6843f doris::Thread::supervise_thread()
 @ 0x7f6faa94a1ca start_thread
 @ 0x7f6fab121dd3 __GI___clone
 @ (nil) (unknown)

Memory Tracker Summary:
 MemTrackerLimiter Label=Query#Id=78208b15e064527-a84c5c0b04c04fcf, Type=query, Limit=100.00 MB(104857600
B), Used=64.75 MB(67891182 B), Peak=104.70 MB(109786406 B)
 MemTracker Label=Scanner#QueryId=78208b15e064527-a84c5c0b04c04fcf, Parent Label=Query#Id=78208b15e064527-
a84c5c0b04c04fcf, Used=0(0 B), Peak=0(0 B)
 MemTracker Label=RuntimeFilterMgr, Parent Label=Query#Id=78208b15e064527-a84c5c0b04c04fcf, Used=2.09
KB(2144 B), Peak=0(0 B)
 MemTracker Label=BufferedBlockMgr2, Parent Label=Query#Id=78208b15e064527-a84c5c0b04c04fcf, Used=0(0 B),
Peak=0(0 B)
 MemTracker Label=ExecNode:VHASH_JOIN_NODE (id=2), Parent Label=Query#Id=78208b15e064527-a84c5c0b04c04fcf,
Used=-61.44 MB(-64426656 B), Peak=290.33 KB(297296 B)
```

MemTracker Label=ExecNode:VEXCHANGE\_NODE (id=9), Parent Label=Query#Id=78208b15e064527-a84c5c0b04c04fcf, Used=6.12 KB(6264 B), Peak=5.84 KB(5976 B)

MemTracker Label=VDataStreamRecv:78208b15e064527-a84c5c0b04c04fd2, Parent Label=Query#Id=78208b15e064527-a84c5c0b04c04fcf, Used=6.12 KB(6264 B), Peak=5.84 KB(5976 B)

MemTracker Label=ExecNode:VEXCHANGE\_NODE (id=10), Parent Label=Query#Id=78208b15e064527-a84c5c0b04c04fcf, Used=-41.20 MB(-43198024 B), Peak=1.46 MB(1535656 B)

MemTracker Label=VDataStreamRecv:78208b15e064527-a84c5c0b04c04fd2, Parent Label=Query#Id=78208b15e064527-a84c5c0b04c04fcf, Used=-41.20 MB(-43198024 B), Peak=1.46 MB(1535656 B)

MemTracker Label=VDataStreamSender:78208b15e064527-a84c5c0b04c04fd2, Parent Label=Query#Id=78208b15e064527-a84c5c0b04c04fcf, Used=2.34 KB(2400 B), Peak=0(0 B)

MemTracker Label=Scanner#QueryId=78208b15e064527-a84c5c0b04c04fcf, Parent Label=Query#Id=78208b15e064527-a84c5c0b04c04fcf, Used=58.12 MB(60942224 B), Peak=57.41 MB(60202848 B)

MemTracker Label=RuntimeFilterMgr, Parent Label=Query#Id=78208b15e064527-a84c5c0b04c04fcf, Used=0(0 B), Peak=0(0 B)

MemTracker Label=BufferedBlockMgr2, Parent Label=Query#Id=78208b15e064527-a84c5c0b04c04fcf, Used=0(0 B), Peak=0(0 B)

MemTracker Label=ExecNode:VNewOlapScanNode(customer) (id=1), Parent Label=Query#Id=78208b15e064527-a84c5c0b04c04fcf, Used=9.55 MB(10013424 B), Peak=10.20 MB(10697136 B)

MemTracker Label=VDataStreamSender:78208b15e064527-a84c5c0b04c04fd1, Parent Label=Query#Id=78208b15e064527-a84c5c0b04c04fcf, Used=59.80 MB(62701880 B), Peak=59.16 MB(62033048 B)

MemTracker Label=Scanner#QueryId=78208b15e064527-a84c5c0b04c04fcf, Parent Label=Query#Id=78208b15e064527-a84c5c0b04c04fcf, Used=0(0 B), Peak=0(0 B)

MemTracker Label=RuntimeFilterMgr, Parent Label=Query#Id=78208b15e064527-a84c5c0b04c04fcf, Used=13.62 KB(13952 B), Peak=0(0 B)

MemTracker Label=BufferedBlockMgr2, Parent Label=Query#Id=78208b15e064527-a84c5c0b04c04fcf, Used=0(0 B), Peak=0(0 B)

MemTracker Label=ExecNode:VNewOlapScanNode(lineorder) (id=0), Parent Label=Query#Id=78208b15e064527-a84c5c0b04c04fcf, Used=6.03 MB(6318064 B), Peak=4.02 MB(4217664 B)

MemTracker Label=VDataStreamSender:78208b15e064527-a84c5c0b04c04fd0, Parent Label=Query#Id=78208b15e064527-a84c5c0b04c04fcf, Used=2.34 KB(2400 B), Peak=0(0 B)



# BE OOM 分析

自 Doris 1.2 版本开始支持 BE OOM 分析

理想情况下，在 [Memory Limit Exceeded Analysis](#) 中我们定时检测操作系统剩余可用内存，并在内存不足时及时响应，如触发内存 GC 释放缓存或 cancel 内存超限的查询，但因为刷新进程内存统计和内存 GC 都具有一定的滞后性，同时我们很难完全 catch 所有大内存申请，在集群压力过大时仍有 OOM 风险。

## 解决方法

参考 [BE 配置项](#) 在 be.conf 中调小 mem\_limit，调大 max\_sys\_mem\_available\_low\_water\_mark\_bytes。

## 内存分析

若希望进一步了解 OOM 前 BE 进程的内存使用位置，减少进程内存使用，可参考如下步骤分析。

1. dmesg -T 确认 OOM 的时间和 OOM 时的进程内存。
2. 查看 be/log/be.INFO 的最后是否有 Memory Tracker Summary 日志，如果有说明 BE 已经检测到内存超限，则继续步骤 3，否则继续步骤 8

Memory Tracker Summary:

```
Type=consistency, Used=0(0 B), Peak=0(0 B)
Type=batch_load, Used=0(0 B), Peak=0(0 B)
Type=clone, Used=0(0 B), Peak=0(0 B)
Type=schema_change, Used=0(0 B), Peak=0(0 B)
Type=compaction, Used=0(0 B), Peak=0(0 B)
Type=load, Used=0(0 B), Peak=0(0 B)
Type=query, Used=206.67 MB(216708729 B), Peak=565.26 MB(592723181 B)
Type=global, Used=930.42 MB(975614571 B), Peak=1017.42 MB(1066840223 B)
Type=tc/jemalloc_cache, Used=51.97 MB(54494616 B), Peak=-1.00 B(-1 B)
Type=process, Used=1.16 GB(1246817916 B), Peak=-1.00 B(-1 B)
MemTrackerLimiter Label=Orphan, Type=global, Limit=-1.00 B(-1 B), Used=474.20 MB(497233597 B),
Peak=649.18 MB(680718208 B)
MemTracker Label=BufferAllocator, Parent Label=Orphan, Used=0(0 B), Peak=0(0 B)
MemTracker Label=LoadChannelMgr, Parent Label=Orphan, Used=0(0 B), Peak=0(0 B)
MemTracker Label=StorageEngine, Parent Label=Orphan, Used=320.56 MB(336132488 B), Peak=322.56
MB(338229824 B)
MemTracker Label=SegCompaction, Parent Label=Orphan, Used=0(0 B), Peak=0(0 B)
MemTracker Label=SegmentMeta, Parent Label=Orphan, Used=948.64 KB(971404 B), Peak=943.64 KB(966285 B)
MemTracker Label=TabletManager, Parent Label=Orphan, Used=0(0 B), Peak=0(0 B)
MemTrackerLimiter Label=DataPageCache, Type=global, Limit=-1.00 B(-1 B), Used=455.22 MB(477329882 B),
Peak=454.18 MB(476244180 B)
MemTrackerLimiter Label=IndexPageCache, Type=global, Limit=-1.00 B(-1 B), Used=1.00 MB(1051092 B),
Peak=0(0 B)
MemTrackerLimiter Label=SegmentCache, Type=global, Limit=-1.00 B(-1 B), Used=0(0 B), Peak=0(0 B)
MemTrackerLimiter Label=DiskIO, Type=global, Limit=2.47 GB(2655423201 B), Used=0(0 B), Peak=0(0 B)
MemTrackerLimiter Label=ChunkAllocator, Type=global, Limit=-1.00 B(-1 B), Used=0(0 B), Peak=0(0 B)
MemTrackerLimiter Label=LastestSuccessChannelCache, Type=global, Limit=-1.00 B(-1 B), Used=0(0 B),
Peak=0(0 B)
MemTrackerLimiter Label=DeleteBitmap AggCache, Type=global, Limit=-1.00 B(-1 B), Used=0(0 B), Peak=0(0 B)
```



3. 当 OOM 前 be/log/be.INFO 的最后包含系统内存超限的日志时，参考 [Memory Limit Exceeded Analysis](#) 中的日志分析方法，查看进程每个类别的内存使用情况。若当前是 type=query 内存使用较多，若已知 OOM 前的查询继续步骤 4，否则继续步骤 5；若当前是 type=load 内存使用多继续步骤 6，若当前是 type=global 内存使用多继续步骤 7。
4. type=query 查询内存使用多，且已知 OOM 前的查询时，比如测试集群或定时任务，重启 BE 节点，参考 [Memory Tracker](#) 查看实时 memory tracker 统计，set global enable\_profile=true 后重试查询，观察具体算子的内存使用位置，确认查询内存使用是否合理，进一步考虑优化 SQL 内存使用，比如调整 join 顺序。
5. type=query 查询内存使用多，且未知 OOM 前的查询时，比如位于线上集群，则在 be/log/be.INFO 从后向前搜 Deregister query/load memory tracker, queryId 和 Register query/load memory tracker, query/load id, 同一个 query id 若同时打出上述两行日志则表示查询或导入成功，若只有 Register 没有 Deregister，则这个查询或导入在 OOM 前仍在运行，这样可以得到 OOM 前所有正在运行的查询和导入，按照步骤 4 的方法对可疑大内存查询分析其内存使用。
6. type=load 导入内存使用多时。
7. type=global 内存使用多时，继续查看 Memory Tracker Summary 日志后半部分已经打出得 type=global 详细统计。当 DataPageCache、IndexPageCache、SegmentCache、ChunkAllocator、LastestSuccessChannelCache 等内存使用多时，参考 [BE 配置项](#) 考虑修改 cache 的大小；当 Orphan 内存使用过多时，如下继续分析。
  - 若 Parent Label=Orphan 的 tracker 统计值相加只占 Orphan 内存的小部分，则说明当前有大量内存没有准确统计，比如 brpc 过程的内存，此时可以考虑借助 heap profile [Memory Tracker](#) 中的方法进一步分析内存位置。
  - 若 Parent Label=Orphan 的 tracker 统计值相加占 Orphan 内存的大部分，当 Label=TabletManager 内存使用多时，进一步查看集群 Tablet 数量，若 Tablet 数量过多则考虑删除过时不会被使用的表或数据；当 Label=StorageEngine 内存使用过多时，进一步查看集群 Segment 文件个数，若 Segment 文件个数过多则考虑手动触发 compaction；
8. 若 be/log/be.INFO 没有在 OOM 前打印出 Memory Tracker Summary 日志，说明 BE 没有及时检测出内存超限，观察 Grafana 内存监控确认 BE 在 OOM 前的内存增长趋势，若 OOM 可复现，考虑在 be.conf 中增加 memory\_debug=true，重启集群后会每秒打印集群内存统计，观察 OOM 前的最后一次 Memory Tracker Summary 日志，继续步骤 3 分析

# 监控指标

Doris 的 FE 进程和 BE 进程都提供了完备的监控指标。监控指标可以分为两类：

- 1. 进程监控：主要展示 Doris 进程本身的一些监控值。
- 2. 节点监控：主要展示 Doris 进程所在节点机器本身的监控，如 CPU、内存、IO、网络等等。

可以通过访问 FE 或 BE 节点的 http 端口获取当前监控。如：

```
curl http://fe_host:http_port/metrics
curl http://be_host:webserver_port/metrics
```

默认返回 Prometheus 兼容格式的监控指标，如：

```
doris_fe_cache_added{type="partition"} 0
doris_fe_cache_added{type="sql"} 0
doris_fe_cache_hit{type="partition"} 0
doris_fe_cache_hit{type="sql"} 0
doris_fe_connection_total 2
```

如需获取 JSON 格式的监控指标，请访问：

```
curl http://fe_host:http_port/metrics?type=json
curl http://be_host:webserver_port/metrics?type=json
```

## 监控等级和最佳实践

表格中的最后一列标注了监控项的重要等级。**P0** 表示最重要，数值越大，重要性越低。

绝大多数监控指标类型为 Counter。即累计值。你可通过间隔采集（如每 15 秒）监控值，并计算单位时间的斜率，来获得有效信息。

如可以通过计算 doris\_fe\_query\_err 的斜率来获取查询错误率（error per second）。

欢迎完善此表格以提供更全面有效的监控指标。

## FE 监控指标

### 进程监控

| 名称                       | 标签                 | 单位  | 含义                           | 说明 | 等级 |
|--------------------------|--------------------|-----|------------------------------|----|----|
| doris_fe_cache_a<br>dded | {type="partition"} | Num | 新增的 Partition<br>Cache 数量累计值 |    |    |

| 名称                                  | 标签                         | 单位  | 含义                                                | 说明                           | 等级 |
|-------------------------------------|----------------------------|-----|---------------------------------------------------|------------------------------|----|
|                                     | {type="sql"}               | Num | 新增的 SQL Cache 数量累计值                               |                              |    |
| doris_fe_cache_hit                  | {type="partition"}         | Num | 命中 Partition Cache 的计数                            |                              |    |
|                                     | {type="sql"}               | Num | 命中 SQL Cache 的计数                                  |                              |    |
| doris_fe_connection_total           |                            | Num | 当前 FE 的 MySQL 端口连接数                               | 用于监控查询连接数。如果连接数超限，则新的连接将无法接入 | P0 |
| doris_fe_counter_hit_sql_block_rule |                            | Num | 被 SQL BLOCK RULE 拦截的查询数量                          |                              |    |
| doris_fe_edit_log_clean             | {type="failed"}            | Num | 清理历史元数据日志失败的次数                                    | 不应失败，如失败，需人工介入               | P0 |
|                                     | {type="success"}           | Num | 清理历史元数据日志成功的次数                                    |                              |    |
| doris_fe_edit_log                   | {type="accumulated_bytes"} | 字节  | 元数据日志写入量的累计值                                      | 通过计算斜率可以获得写入速率，来观察是否元数据写入有延迟 | P0 |
|                                     | {type="current_bytes"}     | 字节  | 元数据日志当前值                                          | 用于监控 editlog 大小。如果大小超限，需人工介入 | P0 |
|                                     | {type="read"}              | Num | 元数据日志读取次数的计数                                      | 通过斜率观察元数据读取频率是否正常            | P0 |
|                                     | {type="write"}             | Num | 元数据日志写入次数的计数                                      | 通过斜率观察元数据写入频率是否正常            | P0 |
|                                     | {type="current"}           | Num | 元数据日志当前数量                                         | 用于监控 editlog 数量。如果数量超限，需人工介入 | P0 |
| doris_fe_editlog_write_latency_ms   |                            | 毫秒  | 元数据日志写入延迟的百分位统计。如 {quantile="0.75"} 表示 75 分位的写入延迟 |                              |    |
| doris_fe_image_clean                | {type="failed"}            | Num | 清理历史元数据镜像文件失败的次数                                  | 不应失败，如失败，需人工介入               | P0 |
|                                     | {type="success"}           | Num | 清理历史元数据镜像文件成功的次数                                  |                              |    |
| doris_fe_image_push                 | {type="failed"}            | Num | 将元数据镜像文件推送给其他 FE 节点的失败的次数                         |                              |    |

| 名称                                   | 标签               | 单位      | 含义                                                                                                       | 说明                                                     | 等级 |
|--------------------------------------|------------------|---------|----------------------------------------------------------------------------------------------------------|--------------------------------------------------------|----|
|                                      | {type="success"} | Num     | 将元数据镜像文件推送给其他 FE 节点的成功次数                                                                                 |                                                        |    |
| doris_fe_image_write                 | {type="failed"}  | Num     | 生成元数据镜像文件失败的次数                                                                                           | 不应失败，如失败，需人工介入                                         | P0 |
|                                      | {type="success"} | Num     | 生成元数据镜像文件成功的次数                                                                                           |                                                        |    |
| doris_fe_job                         |                  | Num     | 当前不同作业类型以及不同作业状态的计数。如 {job="load", type="INSERT", state="LOADING"} 表示类型为 INSERT 的导入作业，处于 LOADING 状态的作业个数 | 可以根据需要，观察不同类型的作业在集群中的数量                                | P0 |
| doris_fe_max_journal_id              |                  | Num     | 当前 FE 节点最大元数据日志 ID。如果是 Master FE，则是当前写入的最大 ID，如果是非 Master FE，则代表当前回放的元数据日志最大 ID                          | 用于观察多个 FE 之间的 id 是否差距过大。过大则表示元数据同步出现问题                 | P0 |
| doris_fe_max_tablet_compaction_score |                  | Num     | 所有 BE 节点中最大的 compaction score 值。                                                                         | 该值可以观测当前集群最大的 compaction score，以判断是否过高。如过高则可能出现查询或写入延迟 | P0 |
| doris_fe_qps                         |                  | Num/Sec | 当前 FE 每秒查询数量（仅统计查询请求）                                                                                    | QPS                                                    | P0 |
| doris_fe_query_err                   |                  | Num     | 错误查询的累积值                                                                                                 |                                                        |    |
| doris_fe_query_err_rate              |                  | Num/Sec | 每秒错误查询数                                                                                                  | 观察集群是否出现查询错误                                           | P0 |
| doris_fe_query_latency_ms            |                  | 毫秒      | 查询请求延迟的百分位统计。如 {quantile="0.75"} 表示 75 分位的查询延迟                                                           | 详细观察各分位查询延迟                                            | P0 |
| doris_fe_query_latency_ms_db         |                  | 毫秒      | 各个 DB 的查询请求延迟的百分位统计。如 {quantile="0.75",db="test"} 表示 DB test 75 分位的查询延迟                                  | 详细观察各 DB 各分位查询延迟                                       | P0 |

| 名称                                   | 标签 | 单位  | 含义                                                                                            | 说明                                              | 等级 |
|--------------------------------------|----|-----|-----------------------------------------------------------------------------------------------|-------------------------------------------------|----|
| doris_fe_query_olap_table            |    | Num | 查询内部表 (OlapTable) 的请求个数统计                                                                     |                                                 |    |
| doris_fe_query_total                 |    | Num | 所有查询请求的累积计数                                                                                   |                                                 |    |
| doris_fe_report_queue_size           |    | Num | BE 的各种定期汇报任务在 FE 端的队列长度                                                                       | 该值反映了汇报任务在 Master FE 节点上的阻塞程度，数值越大，表示 FE 处理能力不足 | P0 |
| doris_fe_request_total               |    | Num | 所有通过 MySQL 端口接收的操作请求（包括查询和其他语句）                                                               |                                                 |    |
| doris_fe_routine_load_error_rows     |    | Num | 统计集群内所有 Routine Load 作业的错误行数总和                                                                |                                                 |    |
| doris_fe_routine_load_receive_bytes  |    | 字节  | 统计集群内所有 Routine Load 作业接收的数据量大小                                                               |                                                 |    |
| doris_fe_routine_load_rows           |    | Num | 统计集群内所有 Routine Load 作业接收的数据行数                                                                |                                                 |    |
| doris_fe_rps                         |    | Num | 当前 FE 每秒请求数量（包含查询以及其他各类语句）                                                                    | 和 QPS 配合来查看集群处理请求的量                             | P0 |
| doris_fe_scheduled_tablet_num        |    | Num | Master FE 节点正在调度的 tablet 数量。包括正在修复的副本和正在均衡的副本                                                 | 该数值可以反映当前集群，正在迁移的 tablet 数量。如果长时间有值，说明集群不稳定     | P0 |
| doris_fe_tablet_max_compaction_score |    | Num | 各个 BE 节点汇报的 compaction core。<br>如 {backend="172.21.0.1:9556"} 表示 "172.21.0.1:9556" 这个 BE 的汇报值 |                                                 |    |
| doris_fe_tablet_num                  |    | Num | 各个 BE 节点当前 tablet 总数。如 {backend="172.21.0.1:9556"} 表示 "172.21.0.1:9556" 这个 BE 的当前 tablet 数量   | 可以查看 tablet 分布是否均匀以及绝对值是否合理                     | P0 |
| doris_fe_tablet_status_count         |    | Num | 统计 Master FE 节点 Tablet 调度器所调度的 tablet 数量的累计值。                                                 |                                                 |    |

| 名称                   | 标签                                     | 单位  | 含义                                                                                               | 说明                                         | 等级 |
|----------------------|----------------------------------------|-----|--------------------------------------------------------------------------------------------------|--------------------------------------------|----|
|                      | {type="added"}                         | Num | 统计 Master FE 节点 Tablet 调度器所调度的 tablet 数量的累计值。“added”表示被调度过的 tablet 数量                            |                                            |    |
|                      | {type="in_sched"}                      | Num | 同上。表示被重复调度的 tablet 数量                                                                            | 该值如果增长较快，则说明有 tablet 长时间处于不健康状态，导致被调度器反复调度 |    |
|                      | {type="not_ready"}                     | Num | 同上。表示尚未满足调度触发条件的 tablet 数量。                                                                      | 该值如果增长较快，说明有大量 tablet 处于不健康状态但又无法被调度       |    |
|                      | {type="total"}                         | Num | 同上。表示累积的被检查过（但不一定被调度）的 tablet 数量。                                                                |                                            |    |
|                      | {type="unhealthy"}                     | Num | 同上。表示累积的被检查过的不健康的 tablet 数量。                                                                     |                                            |    |
| doris_fe_thread_pool |                                        | Num | 统计各类线程池的工作线程数和排队情况。“active_thread_num”表示正在执行的任务数。“pool_size”表示线程池总线程数量。“task_in_queue”表示正在排队的任务数 |                                            |    |
|                      | {name="agent-task-pool"}               | Num | Master FE 用于发送 Agent Task 到 BE 的线程池                                                              |                                            |    |
|                      | {name="connect-scheduler-check-timer"} | Num | 用于检查 MySQL 空闲连接是否超时的线程池                                                                          |                                            |    |
|                      | {name="connect-scheduler-pool"}        | Num | 用于接收 MySQL 连接请求的线程池                                                                              |                                            |    |
|                      | {name="mysql-nio-pool"}                | Num | NIO MySQL Server 用于处理任务的线程池                                                                      |                                            |    |
|                      | {name="export-exporting-job-pool"}     | Num | exporting 状态的 export 作业的调度线程池                                                                    |                                            |    |
|                      | {name="export-pending-job-pool"}       | Num | pending 状态的 export 作业的调度线程池                                                                      |                                            |    |

| 名称                            | 标签                                   | 单位  | 含义                                                                                 | 说明                        | 等级 |
|-------------------------------|--------------------------------------|-----|------------------------------------------------------------------------------------|---------------------------|----|
|                               | {name="heartbeat-mgr-pool"}          | Num | Master FE 用于处理各个节点心跳的线程池                                                           |                           |    |
|                               | {name="loading-load-task-scheduler"} | Num | Master FE 用于调度 Broker Load 作业中，loading task 的调度线程池                                 |                           |    |
|                               | {name="pending-load-task-scheduler"} | Num | Master FE 用于调度 Broker Load 作业中，pending task 的调度线程池                                 |                           |    |
|                               | {name="schema-change-pool"}          | Num | Master FE 用于调度 schema change 作业的线程池                                                |                           |    |
|                               | {name="thrift-server-pool"}          | Num | FE 端 ThriftServer 的工作线程池。对应 fe.conf 中 rpc_port。用于和 BE 进行交互。                        |                           |    |
| doris_fe_txn_counter          |                                      | Num | 统计各个状态的导入事务的数量的累计值                                                                 | 可以观测导入事务的执行情况。            | P0 |
|                               | {type="begin"}                       | Num | 提交的事务数量                                                                            |                           |    |
|                               | {type="failed"}                      | Num | 失败的事务数量                                                                            |                           |    |
|                               | {type="reject"}                      | Num | 被拒绝的事务数量。<br>(如当前运行事务数大于阈值，则新的事务会被拒绝)                                              |                           |    |
|                               | {type="succes"}                      | Num | 成功的事务数量                                                                            |                           |    |
| doris_fe_txn_status           |                                      | Num | 统计当前处于各个状态的导入事务的数量。如 {type="committed"} 表示处于 committed 状态的事务的数量                    | 可以观测各个状态下导入事务的数量，来判断是否有堆积 | P0 |
| doris_fe_query_instance_num   |                                      | Num | 指定用户当前正在请求的 fragment instance 数目。如 {user="test_u"} 表示用户 test_u 当前正在请求的 instance 数目 | 该数值可以用于观测指定用户是否占用过多查询资源   | P0 |
| doris_fe_query_instance_begin |                                      | Num | 指定用户请求开始的 fragment instance 数目。如 {user="test_u"} 表示用户 test_u 开始请求的 instance 数目     | 该数值可以用于观测指定用户是否提交了过多查询    | P0 |

| 名称                              | 标签 | 单位  | 含义                                                                              | 说明                                  | 等级 |
|---------------------------------|----|-----|---------------------------------------------------------------------------------|-------------------------------------|----|
| doris_fe_query_rpc_total        |    | Num | 发往指定 BE 的 RPC 次数。如 {be="192.168.10.1"} 表示发往 ip 为 192.168.10.1 的 BE 的 RPC 次数     | 该数值可以观测是否向某个 BE 提交了过多 RPC           |    |
| doris_fe_query_rpc_failed       |    | Num | 发往指定 BE 的 RPC 失败次数。如 {be="192.168.10.1"} 表示发往 ip 为 192.168.10.1 的 BE 的 RPC 失败次数 | 该数值可以观测某个 BE 是否存在 RPC 问题            |    |
| doris_fe_query_rpc_size         |    | Num | 指定 BE 的 RPC 数据大小。如 {be="192.168.10.1"} 表示发往 ip 为 192.168.10.1 的 BE 的 RPC 数据字节数  | 该数值可以观测是否向某个 BE 提交了过大的 RPC          |    |
| doris_fe_txn_exec_latency_ms    |    | 毫秒  | 事务执行耗时的百分位统计。如 {quantile="0.75"} 表示 75 分位的事务执行耗时                                | 详细观察各分位事务执行耗时                       | P0 |
| doris_fe_txn_publish_latency_ms |    | 毫秒  | 事务 publish 耗时的百分位统计。如 {quantile="0.75"} 表示 75 分位的事务 publish 耗时                  | 详细观察各分位事务 publish 耗时                | P0 |
| doris_fe_txn_num                |    | Num | 指定 DB 正在执行的事务数。如 {db="test"} 表示 DB test 当前正在执行的事务数                              | 该数值可以观测某个 DB 是否提交了大量事务              | P0 |
| doris_fe_publish_txn_num        |    | Num | 指定 DB 正在 publish 的事务数。如 {db="test"} 表示 DB test 当前正在 publish 的事务数                | 该数值可以观测某个 DB 的 publish 事务数量         | P0 |
| doris_fe_txn_replica_num        |    | Num | 指定 DB 正在执行的事务打开的副本数。如 {db="test"} 表示 DB test 当前正在执行的事务打开的副本数                    | 该数值可以观测某个 DB 是否打开了过多的副本，可能会影响其他事务执行 | P0 |
| doris_fe_thrift_rpc_total       |    | Num | FE thrift 接口各个方法接收的 RPC 请求次数。如 {method="report"} 表示 report 方法接收的 RPC 请求次数       | 该数值可以观测某个 thrift rpc 方法的负载          |    |



| 名称                             | 标签                       | 单位  | 含义                                                                        | 说明                         | 等级 |
|--------------------------------|--------------------------|-----|---------------------------------------------------------------------------|----------------------------|----|
| doris_fe_thrift_rpc_latency_ms |                          | 毫秒  | FE thrift 接口各个方法接收的 RPC 请求耗时。如 {method="report"} 表示 report 方法接收的 RPC 请求耗时 | 该数值可以观测某个 thrift rpc 方法的负载 |    |
| doris_fe_external_schema_cache | {catalog="hive"}         | Num | 指定 External Catalog 对应的 schema cache 的数量                                  |                            |    |
| doris_fe_hive_metastore_cache  | {catalog="hive"}         | Num |                                                                           |                            |    |
|                                | {type="partition_value"} | Num | 指定 External Hive Metastore Catalog 对应的 partition value cache 的数量          |                            |    |
|                                | {type="partition"}       | Num | 指定 External Hive Metastore Catalog 对应的 partition cache 的数量                |                            |    |
|                                | {type="file"}            | Num | 指定 External Hive Metastore Catalog 对应的 file cache 的数量                     |                            |    |

## JVM 监控

| 名称                      | 标签             | 单位  | 含义                                                      | 说明                | 等级 |
|-------------------------|----------------|-----|---------------------------------------------------------|-------------------|----|
| jvm_heap_size_bytes     |                | 字节  | JVM 内存监控。标签包含 max, used, committed, 分别对应最大值, 已使用和已申请的内存 | 观测 JVM 内存使用情况     | P0 |
| jvm_non_heap_size_bytes |                | 字节  | JVM 堆外内存统计                                              |                   |    |
| jvm_old_gc              |                |     | 老年代 GC 监控。                                              | 观测是否出现长时间的 FullGC | P0 |
|                         | {type="count"} | Num | 老年代 GC 次数累计值                                            |                   |    |
|                         | {type="time"}  | 毫秒  | 老年代 GC 耗时累计值                                            |                   |    |
| jvm_old_size_bytes      |                | 字节  | JVM 老年代内存统计                                             |                   | P0 |
| jvm_thread              |                | Num | JVM 线程数统计                                               | 观测 JVM 线程数是否合理    | P0 |
| jvm_young_gc            |                |     | 新生代 GC 监控                                               |                   |    |

| 名称                   | 标签             | 单位  | 含义           | 说明 | 等级 |
|----------------------|----------------|-----|--------------|----|----|
|                      | {type="count"} | Num | 新生代 GC 次数累计值 |    |    |
|                      | {type="time"}  | 毫秒  | 新生代 GC 耗时累计值 |    |    |
| jvm_young_size_bytes |                | 字节  | JVM 新生代内存统计  |    | P0 |

## 机器监控

| 名称             | 标签                        | 单位                               | 含义                                                                                             | 说明 | 等级 |
|----------------|---------------------------|----------------------------------|------------------------------------------------------------------------------------------------|----|----|
| system_meminfo |                           | 字节                               | FE 节点机器的内存监控。采集自 /proc/meminfo。包括 buffers, cached, memory_available, memory_free, memory_total |    |    |
| system_snmp    |                           | FE 节点机器的网络监控。采集自 /proc/net/snmp。 |                                                                                                |    |    |
|                | {name="tcp_in_errors"}    | Num                              | tcp 包接收错误的次数                                                                                   |    |    |
|                | {name="tcp_in_segs"}      | Num                              | tcp 包发送的个数                                                                                     |    |    |
|                | {name="tcp_out_segs"}     | Num                              | tcp 包发送的个数                                                                                     |    |    |
|                | {name="tcp_retrans_segs"} | Num                              | tcp 包重传的个数                                                                                     |    |    |

## BE 监控指标

### 进程监控

| 名称                                 | 标签 | 单位  | 含义                       | 说明                     | 等级 |
|------------------------------------|----|-----|--------------------------|------------------------|----|
| doris_be_active_scan_context_count |    | Num | 展示当前由外部直接打开的 scanner 的个数 |                        |    |
| doris_be_add_batch_task_queue_size |    | Num | 记录导入时，接收 batch 的线程池的队列大小 | 如果大于 0，则表示导入任务的接收端出现积压 | P0 |

| 名称                                         | 标签                                  | 单位  | 含义                                                                      | 说明                | 等级 |
|--------------------------------------------|-------------------------------------|-----|-------------------------------------------------------------------------|-------------------|----|
| agent_task_queue_size                      |                                     | Num | 展示各个 Agent Task 处理队列的长度，如 {type="CREATE_TABLE"} 表示 CREATE_TABLE 任务队列的长度 |                   |    |
| doris_be_brpc_endpoint_stub_count          |                                     | Num | 已创建的 brpc stub 的数量，这些 stub 用于 BE 之间的交互                                  |                   |    |
| doris_be_brpc_function_endpoint_stub_count |                                     | Num | 已创建的 brpc stub 的数量，这些 stub 用于和 Remote RPC 之间交互                          |                   |    |
| doris_be_cache_capacity                    |                                     |     | 记录指定 LRU Cache 的容量                                                      |                   |    |
| doris_be_cache_usage                       |                                     |     | 记录指定 LRU Cache 的使用量                                                     | 用于观测内存占用情况        | P0 |
| doris_be_cache_usage_ratio                 |                                     |     | 记录指定 LRU Cache 的使用率                                                     |                   |    |
| doris_be_cache_lookup_count                |                                     |     | 记录指定 LRU Cache 被查找的次数                                                   |                   |    |
| doris_be_cache_hit_count                   |                                     |     | 记录指定 LRU Cache 的命中次数                                                    |                   |    |
| doris_be_cache_hit_ratio                   |                                     |     | 记录指定 LRU Cache 的命中率                                                     | 用于观测 cache 是否有效   | P0 |
|                                            | {name="DataPageCache"}              | Num | DataPageCache 用于缓存数据的 Data Page                                         | 数据 Cache，直接影响查询效率 | P0 |
|                                            | {name="IndexPageCache"}             | Num | IndexPageCache 用于缓存数据的 Index Page                                       | 索引 Cache，直接影响查询效率 | P0 |
|                                            | {name="LastestSuccessChannelCache"} | Num | LastestSuccessChannelCache 用于缓存导入接收端的 LoadChannel                       |                   |    |
|                                            | {name="SegmentCache"}               | Num | SegmentCache 用于缓存已打开的 Segment，如索引信息                                     |                   |    |
| doris_be_chunk_pool_local_core_alloc_count |                                     | Num | ChunkAllocator 中，从绑定的 core 的内存队列中分配内存的次数                                |                   |    |

| 名称                                         | 标签                  | 单位  | 含义                                                                  | 说明                                                                    | 等级 |
|--------------------------------------------|---------------------|-----|---------------------------------------------------------------------|-----------------------------------------------------------------------|----|
| doris_be_chunk_pool_other_core_alloc_count |                     | Num | ChunkAllocator 中, 从其他的 core 的内存队列中分配内存的次数                           |                                                                       |    |
| doris_be_chunk_pool_reserved_bytes         |                     | 字节  | ChunkAllocator 中预留的内存大小                                             |                                                                       |    |
| doris_be_chunk_pool_system_alloc_cost_ns   |                     | 纳秒  | SystemAllocator 申请内存的耗时累计值                                          | 通过斜率可以观测内存分配的耗时                                                       | P0 |
| doris_be_chunk_pool_system_alloc_count     |                     | Num | SystemAllocator 申请内存的次数                                             |                                                                       |    |
| doris_be_chunk_pool_system_free_cost_ns    |                     | 纳秒  | SystemAllocator 释放内存的耗时累计值                                          | 通过斜率可以观测内存释放的耗时                                                       | P0 |
| doris_be_chunk_pool_system_free_count      |                     | Num | SystemAllocator 释放内存的次数                                             |                                                                       |    |
| doris_be_compaction_bytes_total            |                     | 字节  | compaction 处理的数据量的累计值                                               | 记录的是 compaction 任务中, input rowset 的 disk size。通过斜率可以观测 compaction 的速率 | P0 |
|                                            | {type="base"}       | 字节  | Base Compaction 的数据量累计                                              |                                                                       |    |
|                                            | {type="cumulative"} | 字节  | Cumulative Compaction 的数据量累计                                        |                                                                       |    |
| doris_be_compaction_deltas_total           |                     | Num | compaction 处理的 rowset 个数的累计值                                        | 记录的是 compaction 任务中, input rowset 的个数                                 |    |
|                                            | {type="base"}       | Num | Base Compaction 处理的 rowset 个数累计                                     |                                                                       |    |
|                                            | {type="cumulative"} | Num | Cumulative Compaction 处理的 rowset 个数累计                               |                                                                       |    |
| doris_be_disks_compaction_num              |                     | Num | 指定数据目录上正在执行的 compaction 任务数。如 {path="/path1/"} 表示/path1 目录上正在执行的任务数 | 用于观测各个磁盘上的 compaction 任务数是否合理                                         | P0 |

| 名称                                  | 标签                                        | 单位  | 含义                                                                   | 说明                                                        | 等级 |
|-------------------------------------|-------------------------------------------|-----|----------------------------------------------------------------------|-----------------------------------------------------------|----|
| doris_be_disks_compaction_score     |                                           | Num | 指定数据目录上正在执行的 compaction 令牌数。如 {path="/path1/"} 表示 /path1 目录上正在执行的令牌数 |                                                           |    |
| doris_be_compaction_used_permits    |                                           | Num | Compaction 任务已使用的令牌数量                                                | 用于反映 Compaction 的资源消耗量                                    |    |
| doris_be_compaction_waiting_permits |                                           | Num | 正在等待 Compaction 令牌的数量                                                |                                                           |    |
| doris_be_data_stream_receiver_count |                                           | Num | 数据接收端 Receiver 的数量                                                   | FIXME: 向量化引擎此指标缺失                                         |    |
| doris_be_disks_available_capacity   |                                           | 字节  | 指定数据目录所在磁盘的剩余空间。如 {path="/path1/"} 表示 /path1 目录所在磁盘的剩余空间             |                                                           | P0 |
| doris_be_disks_local_used_capacity  |                                           | 字节  | 指定数据目录所在磁盘的本地已使用空间                                                   |                                                           |    |
| doris_be_disks_remote_used_capacity |                                           | 字节  | 指定数据目录所在磁盘的对应的远端目录的已使用空间                                             |                                                           |    |
| doris_be_disks_state                |                                           | 布尔  | 指定数据目录的磁盘状态。1 表示正常。0 表示异常                                            |                                                           |    |
| doris_be_disks_total_capacity       |                                           | 字节  | 指定数据目录所在磁盘的总容量                                                       | 配合 doris_be_disks_available_capacity 计算磁盘使用率              | P0 |
| doris_be_engine_requests_total      |                                           | Num | BE 上各类任务执行状态的累计值                                                     |                                                           |    |
|                                     | {status="failed",type="xxx"}              | Num | xxx 类型的任务的失败次数的累计值                                                   |                                                           |    |
|                                     | {status="total",type="xxx"}               | Num | xxx 类型的任务的总次数的累计值。                                                   | 可以按需监控各类任务的失败次数                                           | P0 |
|                                     | {status="skip",type="report_all_tablets"} | Num | xxx 类型任务被跳过执行的次数的累计值                                                 |                                                           |    |
| doris_be_fragment_endpoint_count    |                                           | Num | 同                                                                    | FIXME: 同 doris_be_data_stream_receiver_count 数目。并且向量化引擎缺失 |    |

| 名称                                    | 标签 | 单位  | 含义                                                          | 说明                                                                                               | 等级 |
|---------------------------------------|----|-----|-------------------------------------------------------------|--------------------------------------------------------------------------------------------------|----|
| doris_be_fragment_request_duration_us |    | 微秒  | 所有 fragment instance 的执行时间累计                                | 通过斜率观测 instance 的执行耗时                                                                            | P0 |
| doris_be_fragment_requests_total      |    | Num | 执行过的 fragment instance 的数量累计                                |                                                                                                  |    |
| doris_be_load_channel_count           |    | Num | 当前打开的 load channel 个数                                       | 数值越大，说明当前正在执行的导入任务越多                                                                             | P0 |
| doris_be_local_bytes_read_total       |    | 字节  | 由 LocalFileReader 读取的字节数                                    |                                                                                                  | P0 |
| doris_be_local_bytes_written_total    |    | 字节  | 由 LocalFileWriter 写入的字节数                                    |                                                                                                  | P0 |
| doris_be_local_file_reader_total      |    | Num | 打开的 LocalFileReader 的累计计数                                   |                                                                                                  |    |
| doris_be_local_file_open_reading      |    | Num | 当前打开的 LocalFileReader 个数                                    |                                                                                                  |    |
| doris_be_local_file_writer_total      |    | Num | 打开的 LocalFileWriter 的累计计数。                                  |                                                                                                  |    |
| doris_be_memory_consumption           |    | 字节  | 指定模块的当前内存开销。如 {type="compaction"} 表示 compaction 模块的当前总内存开销。 | 值取自相同 type 的 MemTracker。FIXME                                                                    |    |
| doris_be_memory_allocated_bytes       |    | 字节  | BE 进程物理内存大小，取自 /proc/self/status/VmRSS                      |                                                                                                  | P0 |
| doris_be_memory_jemalloc              |    | 字节  | Jemalloc stats, 取自 je_mallctl。                              | 含义参考：<br><a href="https://jemalloc.net/jemalloc.3.html">https://jemalloc.net/jemalloc.3.html</a> | P0 |
| doris_be_memory_pool_bytes_total      |    | 字节  | 所有 MemPool 当前占用的内存大小。统计值，不代表真实内存使用。                         |                                                                                                  |    |
| doris_be_memtable_flush_duration_us   |    | 微秒  | memtable 写入磁盘的耗时累计值                                         | 通过斜率可以观测写入延迟                                                                                     | P0 |
| doris_be_memtable_flush_total         |    | Num | memtable 写入磁盘的个数累计值                                         | 通过斜率可以计算写入文件的频率                                                                                  | P0 |

| 名称                                         | 标签             | 单位   | 含义                                     | 说明                 | 等级 |
|--------------------------------------------|----------------|------|----------------------------------------|--------------------|----|
| doris_be_meta_request_duration             |                | 微秒   | 访问 RocksDB 中的 meta 的耗时累计               | 通过斜率观测 BE 元数据读写延迟  | P0 |
|                                            | {type="read"}  | 微秒   | 读取耗时                                   |                    |    |
|                                            | {type="write"} | 微秒   | 写入耗时                                   |                    |    |
| doris_be_meta_request_total                |                | Num  | 访问 RocksDB 中的 meta 的次数累计               | 通过斜率观测 BE 元数据访问频率  | P0 |
|                                            | {type="read"}  | Num  | 读取次数                                   |                    |    |
|                                            | {type="write"} | Num  | 写入次数                                   |                    |    |
| doris_be_fragment_instance_count           |                | Num  | 当前已接收的 fragment instance 的数量           | 观测是否出现 instance 堆积 | P0 |
| doris_be_process_fd_num_limit_hard         |                | Num  | BE 进程的文件句柄数硬限。通过 /proc/pid/limits 采集   |                    |    |
| doris_be_process_fd_num_limit_soft         |                | Num  | BE 进程的文件句柄数软限。通过 /proc/pid/limits 采集   |                    |    |
| doris_be_process_fd_num_used               |                | Num  | BE 进程已使用的文件句柄数。通过 /proc/pid/limits 采集  |                    |    |
| doris_be_process_thread_num                |                | Num  | BE 进程线程数。通过 /proc/pid/task 采集          |                    | P0 |
| doris_be_query_cache_memory_total_byte     |                | 字节   | Query Cache 占用字节数                      |                    |    |
| doris_be_query_cache_partition_total_count |                | Num  | 当前 Partition Cache 缓存个数                |                    |    |
| doris_be_query_cache_sql_total_count       |                | Num  | 当前 SQL Cache 缓存个数                      |                    |    |
| doris_be_query_scan_bytes                  |                | 字节   | 读取数据量的累计值。这里只统计读取 Olap 表的数据量           |                    |    |
| doris_be_query_scan_bytes_per_second       |                | 字节/秒 | 根据 doris_be_query_scan_bytes 计算得出的读取速率 | 观测查询速率             | P0 |

| 名称                                         | 标签                          | 单位  | 含义                                                                           | 说明                                                        | 等级 |
|--------------------------------------------|-----------------------------|-----|------------------------------------------------------------------------------|-----------------------------------------------------------|----|
| doris_be_query_scan_rows                   |                             | Num | 读取行数的累计值。这里只统计读取 Olap 表的数据量。并且是 RawRowsRead（部分数据行可能被索引跳过，并没有真正读取，但仍会记录到这个值中） | 通过斜率观测查询速率                                                | P0 |
| doris_be_result_block_queue_count          |                             | Num | 当前查询结果缓存中的 fragment instance 个数                                              | 该队列仅用于被外部系统直接读取时使用。如 Spark on Doris 通过 external scan 查询数据 |    |
| doris_be_result_buffer_block_count         |                             | Num | 当前查询结果缓存中的 query 个数                                                          | 该数值反映当前 BE 中有多少查询的结果正在等待 FE 消费                            | P0 |
| doris_be_routine_load_task_count           |                             | Num | 当前正在执行的 routine load task 个数                                                 |                                                           |    |
| doris_be_rowset_count_generated_and_in_use |                             | Num | 自上次启动后，新增的并且正在使用的 rowset id 个数。                                              |                                                           |    |
| doris_be_s3_bytes_read_total               |                             | Num | S3FileReader 的打开累计次数                                                         |                                                           |    |
| doris_be_s3_file_open_reading              |                             | Num | 当前打开的 S3FileReader 个数                                                        |                                                           |    |
| doris_be_s3_bytes_read_total               |                             | 字节  | S3FileReader 读取字节数累计值                                                        |                                                           |    |
| doris_be_scanner_thread_pool_queue_size    |                             | Num | 用于 OlapScanner 的线程池的当前排队数量                                                   | 大于零则表示 Scanner 开始堆积                                       | P0 |
| doris_be_segment_read                      | {type="segment_read_total"} | Num | 读取的 segment 的个数累计值                                                           |                                                           |    |
| doris_be_segment_read                      | {type="segment_row_total"}  | Num | 读取的 segment 的行数累计值                                                           | 该数值也包含了被索引过滤的行数。相当于读取的 segment 个数 * 每个 segment 的总行数       |    |
| doris_be_send_batch_thread_pool_queue_size |                             | Num | 导入时用于发送数据包的线程池的排队个数                                                          | 大于 0 则表示有堆积                                               | P0 |
| doris_be_send_batch_thread_pool_thread_num |                             | Num | 导入时用于发送数据包的线程池的线程数                                                           |                                                           |    |
| doris_be_small_file_cache_count            |                             | Num | 当前 BE 缓存的小文件数量                                                               |                                                           |    |



| 名称                                              | 标签                     | 单位  | 含义                                                        | 说明                                                        | 等级 |
|-------------------------------------------------|------------------------|-----|-----------------------------------------------------------|-----------------------------------------------------------|----|
| doris_be_streaming_load_current_processing      |                        | Num | 当前正在运行的 stream load 任务数                                   | 仅包含 curl 命令发送的任务                                          |    |
| doris_be_streaming_load_duration_ms             |                        | 毫秒  | 所有 stream load 任务执行时间的耗时累计值                               |                                                           |    |
| doris_be_streaming_load_requests_total          |                        | Num | stream load 任务数的累计值                                       | 通过斜率可观测任务提交频率                                             | P0 |
| doris_be_stream_load_pipe_count                 |                        | Num | 当前 stream load 数据管道的个数                                    | 包括 stream load 和 routine load 任务                          |    |
| doris_be_stream_load                            | {type="load_rows"}     | Num | stream load 最终导入的行数累计值                                    | 包括 stream load 和 routine load 任务                          | P0 |
| doris_be_stream_load                            | {type="receive_bytes"} | 字节  | stream load 接收的字节数累计值                                     | 包括 stream load 从 http 接收的数据，以及 routine load 从 kafka 读取的数据 | P0 |
| doris_be_tablet_base_max_compaction_score       |                        | Num | 当前最大的 Base Compaction Score                               | 该数值实时变化，有可能丢失峰值数据。数值越高，表示 compaction 堆积越严重                | P0 |
| doris_be_tablet_cumulative_max_compaction_score |                        | Num | 同上。当前最大的 Cumulative Compaction Score                      |                                                           |    |
| doris_be_tablet_version_num_distribution        |                        | Num | tablet version 数量的直方。                                     | 用于反映 tablet version 数量的分布                                 | P0 |
| doris_be_thrift_connections_total               |                        | Num | 创建过的 thrift 连接数的累计值。如 {name="heartbeat"} 表示心跳服务的连接数累计     | 此数值为 BE 作为服务端的 thrift server 的连接                          |    |
| doris_be_thrift_current_connections             |                        | Num | 当前 thrift 连接数。如 {name="heartbeat"} 表示心跳服务的当前连接数。          | 同上                                                        |    |
| doris_be_thrift_opened_clients                  |                        | Num | 当前已打开的 thrift 客户端的数量。如 {name="frontend"} 表示访问 FE 服务的客户端数量 |                                                           |    |

| 名称                                       | 标签                | 单位  | 含义                                                             | 说明                                       | 等级 |
|------------------------------------------|-------------------|-----|----------------------------------------------------------------|------------------------------------------|----|
| doris_be_thrift_used_clients             |                   | Num | 当前正在使用的 thrift 客户端的数量。如 {name="frontend"} 表示正在用于访问 FE 服务的客户端数量 |                                          |    |
| doris_be_timeout_canceled_fragment_count |                   | Num | 因超时而被取消的 fragment instance 数量累计值                               | 这个值可能会被重复记录。比如部分 fragment instance 被多次取消 | P0 |
| doris_be_stream_load_txn_request         | {type="begin"}    | Num | stream load 开始事务数的累计值                                          | 包括 stream load 和 routine load 任务         |    |
| doris_be_stream_load_txn_request         | {type="commit"}   | Num | stream load 执行成功的事务数的累计值                                       | 同上                                       |    |
| doris_be_stream_load_txn_request         | {type="rollback"} |     | stream load 执行失败的事务数的累计值                                       | 同上                                       |    |
| doris_be_unused_rowsets_count            |                   | Num | 当前已废弃的 rowset 的个数                                              | 这些 rowset 正常情况下会被定期删除                    |    |
| doris_be_upload_fail_count               |                   | Num | 冷热分层功能，上传到远端存储失败的 rowset 的次数累计值                                |                                          |    |
| doris_be_upload_rowset_count             |                   | Num | 冷热分层功能，上传到远端存储成功的 rowset 的次数累计值                                |                                          |    |
| doris_be_upload_total_byte               |                   |     | 字节                                                             | 冷热分层功能，上传到远端存储成功的 rowset 数据量累计值          |    |
| doris_be_load_bytes                      |                   | 字节  | 通过 tablet sink 发送的数量累计                                         | 可观测导入数据量                                 | P0 |
| doris_be_load_rows                       |                   | Num | 通过 tablet sink 发送的行数累计                                         | 可观测导入数据量                                 | P0 |
| fragment_thread_pool_queue_size          |                   | Num | 当前查询执行线程池等待队列的长度                                               | 如果大于零，则说明查询线程已耗尽，查询会出现堆积                 | P0 |
| doris_be_all_rowsets_num                 |                   | Num | 当前所有 rowset 的个数                                                |                                          | P0 |
| doris_be_all_segments_num                |                   | Num | 当前所有 segment 的个数                                               |                                          | P0 |
| doris_be_heavy_work_max_threads          |                   | Num | brpc heavy 线程池线程个数                                             |                                          | p0 |
| doris_be_light_work_max_threads          |                   | Num | brpc light 线程池线程个数                                             |                                          | p0 |

| 名称                                  | 标签 | 单位  | 含义                                | 说明 | 等级 |
|-------------------------------------|----|-----|-----------------------------------|----|----|
| doris_be_heavy_work_pool_queue_size |    | Num | brpc heavy 线程池队列最大长度，超过则阻塞提交 work |    | p0 |
| doris_be_light_work_pool_queue_size |    | Num | brpc light 线程池队列最大长度，超过则阻塞提交 work |    | p0 |
| doris_be_heavy_work_active_threads  |    | Num | brpc heavy 线程池活跃线程数               |    | p0 |
| doris_be_light_work_active_threads  |    | Num | brpc light 线程池活跃线程数               |    | p0 |

## 机器监控

| 名称                             | 标签 | 单位  | 含义                                                                                         | 说明            | 等级 |
|--------------------------------|----|-----|--------------------------------------------------------------------------------------------|---------------|----|
| doris_be_cpu                   |    | Num | CPU 相关监控指标，从 /proc/stat 采集。会分别采集每个逻辑核的各项数值。如 {device="cpu0", mode="nice"} 表示 cpu0 的 nice 值 | 可计算得出 CPU 使用率 | P0 |
| doris_be_disk_bytes_read       |    | 字节  | 磁盘读取量累计值。从 /proc/diskstats 采集。会分别采集每块磁盘的数值。如 {device="vdd"} 表示 vdd 盘的数值                    |               |    |
| doris_be_disk_bytes_written    |    | 字节  | 磁盘写入量累计值。采集方式同上                                                                            |               |    |
| doris_be_disk_io_time_ms       |    | 字节  | 采集方式同上                                                                                     | 可计算得出 IO Util | P0 |
| doris_be_disk_io_time_weighted |    | 字节  | 采集方式同上                                                                                     |               |    |
| doris_be_disk_reads_completed  |    | 字节  | 采集方式同上                                                                                     |               |    |
| doris_be_disk_read_time_ms     |    | 字节  | 采集方式同上                                                                                     |               |    |
| doris_be_disk_writes_completed |    | 字节  | 采集方式同上                                                                                     |               |    |
| doris_be_disk_write_time_ms    |    | 字节  | 采集方式同上                                                                                     |               |    |

| 名称                                      | 标签 | 单位   | 含义                                                         | 说明                                        | 等级 |
|-----------------------------------------|----|------|------------------------------------------------------------|-------------------------------------------|----|
| doris_be_fd_num_limit                   |    | Num  | 系统文件句柄限制上限。从<br>/proc/sys/fs/file-nr 采集                    |                                           |    |
| doris_be_fd_num_used                    |    | Num  | 系统已使用文件句柄数。从<br>/proc/sys/fs/file-nr 采集                    |                                           |    |
| doris_be_file_created_total             |    | Num  | 本地文件创建次数累计                                                 | 所有调用<br>local_file_writer 并最终 close 的文件计数 |    |
| doris_be_load_average                   |    | Num  | 机器 Load Avg 指标监控。如<br>{mode="15_minutes"} 为 15 分钟 Load Avg | 观测整机负载                                    | P0 |
| doris_be_max_disk_io_util_percent       |    | 百分比  | 计算得出的所有磁盘中，最大的 IO UTIL 的磁盘的数值                              |                                           | P0 |
| doris_be_max_network_receive_bytes_rate |    | 字节/秒 | 计算得出的所有网卡中，最大的接收速率                                         |                                           | P0 |
| doris_be_max_network_send_bytes_rate    |    | 字节/秒 | 计算得出的所有网卡中，最大的发送速率                                         |                                           | P0 |
| doris_be_memory_pgpgin                  |    | 字节   | 系统从磁盘写到内存页的数据量                                             |                                           |    |
| doris_be_memory_pgpgout                 |    | 字节   | 系统内存页写入磁盘的数据量                                              |                                           |    |
| doris_be_memory_pswpin                  |    | 字节   | 系统从磁盘换入到内存的数量                                              | 通常情况下，swap 应该关闭，因此这个数值应该是 0               |    |
| doris_be_memory_pswpout                 |    | 字节   | 系统从内存换入到磁盘的数量                                              | 通常情况下，swap 应该关闭，因此这个数值应该是 0               |    |
| doris_be_network_receive_bytes          |    | 字节   | 各个网卡的接收字节累计。采集自<br>/proc/net/dev                           |                                           |    |
| doris_be_network_receive_packets        |    | Num  | 各个网卡的接收包个数累计。采集自<br>/proc/net/dev                          |                                           |    |
| doris_be_network_send_bytes             |    | 字节   | 各个网卡的发送字节累计。采集自<br>/proc/net/dev                           |                                           |    |

| 名称                             | 标签                     | 单位  | 含义                                 | 说明                              | 等级 |
|--------------------------------|------------------------|-----|------------------------------------|---------------------------------|----|
| doris_be_network_send_packets  |                        | Num | 各个网卡的发送包个数累计。采集自 /proc/net/dev     |                                 |    |
| doris_be_proc                  | {mode="ctxt_switch"}   | Num | CPU 上下文切换的累计值。采集自 /proc/stat       | 观测是否有异常的上下文切换                   | P0 |
| doris_be_proc                  | {mode="interrupt"}     | Num | CPU 中断次数的累计值。采集自 /proc/stat        |                                 |    |
| doris_be_proc                  | {mode="procs_blocked"} | Num | 系统当前被阻塞的进程数（如等待 IO）。采集自 /proc/stat |                                 |    |
| doris_be_proc                  | {mode="procs_running"} | Num | 系统当前正在执行的进程数。采集自 /proc/stat        |                                 |    |
| doris_be_snmp_tcp_in_errs      |                        | Num | tcp 包接收错误的次数。采集自 /proc/net/snmp    | 可观测网络错误如重传、丢包等。需和其他 snmp 指标配合使用 | P0 |
| doris_be_snmp_tcp_in_segs      |                        | Num | tcp 包发送的个数。采集自 /proc/net/snmp      |                                 |    |
| doris_be_snmp_tcp_out_segs     |                        | Num | tcp 包发送的个数。采集自 /proc/net/snmp      |                                 |    |
| doris_be_snmp_tcp_retrans_segs |                        | Num | tcp 包重传的个数。采集自 /proc/net/snmp      |                                 |    |

# 监控和报警

本文档主要介绍 Doris 的监控项及如何采集、展示监控项。以及如何配置报警（TODO）

Dashboard 模板点击下载


| Doris 版本 | Dashboard 版本               |
|----------|----------------------------|
| 1.2.x    | <a href="#">revision 5</a> |

Dashboard 模板会不定期更新。更新模板的方式见最后一小节。

欢迎提供更优的 dashboard。

## 组件

Doris 使用 [Prometheus](#) 和 [Grafana](#) 进行监控项的采集和展示。



## 组件

### 1. Prometheus

Prometheus 是一款开源的系统监控和报警套件。它可以通过 Pull 或 Push 采集被监控系统的监控项，存入自身的时序数据库中。并且通过丰富的多维数据查询语言，满足用户的不同数据展示需求。

### 2. Grafana

Grafana 是一款开源的数据分析和展示平台。支持包括 Prometheus 在内的多个主流时序数据库源。通过对应的数据库查询语句，从数据源中获取展现数据。通过灵活可配置的 Dashboard，快速的将这些数据以图表的形式展示给用户。

注：本文档仅提供一种使用 **Prometheus** 和 **Grafana** 进行 **Doris** 监控数据采集和展示的方式。原则上不开发、维护这些组件。更多关于这些组件的详细介绍，请移步对应官方文档进行查阅。

## 监控数据

Doris 的监控数据通过 Frontend 和 Backend 的 http 接口向外暴露。监控数据以 Key-Value 的文本形式对外展现。每个 Key 还可能有不同的 Label 加以区分。当用户搭建好 Doris 后，可以在浏览器，通过以下接口访问到节点的监控数据：

- Frontend: fe\_host:fe\_http\_port/metrics
- Backend: be\_host:be\_web\_server\_port/metrics
- Broker: 暂不提供

用户将看到如下监控项结果（示例为 FE 部分监控项）：

```
HELP jvm_heap_size_bytes jvm heap stat
TYPE jvm_heap_size_bytes gauge
jvm_heap_size_bytes{type="max"} 8476557312
jvm_heap_size_bytes{type="committed"} 1007550464
jvm_heap_size_bytes{type="used"} 156375280
HELP jvm_non_heap_size_bytes jvm non heap stat
TYPE jvm_non_heap_size_bytes gauge
jvm_non_heap_size_bytes{type="committed"} 194379776
jvm_non_heap_size_bytes{type="used"} 188201864
HELP jvm_young_size_bytes jvm young mem pool stat
TYPE jvm_young_size_bytes gauge
jvm_young_size_bytes{type="used"} 40652376
jvm_young_size_bytes{type="peak_used"} 277938176
jvm_young_size_bytes{type="max"} 907345920
HELP jvm_old_size_bytes jvm old mem pool stat
TYPE jvm_old_size_bytes gauge
jvm_old_size_bytes{type="used"} 114633448
jvm_old_size_bytes{type="peak_used"} 114633448
jvm_old_size_bytes{type="max"} 7455834112
HELP jvm_young_gc jvm young gc stat
TYPE jvm_young_gc gauge
jvm_young_gc{type="count"} 247
jvm_young_gc{type="time"} 860
HELP jvm_old_gc jvm old gc stat
TYPE jvm_old_gc gauge
jvm_old_gc{type="count"} 3
jvm_old_gc{type="time"} 211
HELP jvm_thread jvm thread stat
TYPE jvm_thread gauge
jvm_thread{type="count"} 162
jvm_thread{type="peak_count"} 205
jvm_thread{type="new_count"} 0
jvm_thread{type="runnable_count"} 48
jvm_thread{type="blocked_count"} 1
jvm_thread{type="waiting_count"} 41
jvm_thread{type="timed_waiting_count"} 72
jvm_thread{type="terminated_count"} 0
...
```


这是一个以 [Prometheus 格式](#) 呈现的监控数据。我们以其中一个监控项为例进行说明：

```
HELP jvm_heap_size_bytes jvm heap stat
TYPE jvm_heap_size_bytes gauge
jvm_heap_size_bytes{type="max"} 8476557312
jvm_heap_size_bytes{type="committed"} 1007550464
jvm_heap_size_bytes{type="used"} 156375280
```

- 1. “#” 开头的行为注释行。其中 HELP 为该监控项的描述说明；TYPE 表示该监控项的数据类型，示例中为 Gauge，即标量数据。还有 Counter、Histogram 等数据类型。具体可见 [Prometheus 官方文档](#)。
- 2. jvm\_heap\_size\_bytes 即监控项的名称 (Key)；type="max" 即为一个名为 type 的 Label，值为 max。一个监控项可以有多个 Label。
- 3. 最后的数字，如 8476557312，即为监控数值。

### 监控架构

整个监控架构如下图所示：



监控架构

- 1. 黄色部分为 Prometheus 相关组件。Prometheus Server 为 Prometheus 的主进程，目前 Prometheus 通过 Pull 的方式访问 Doris 节点的监控接口，然后将时序数据存入时序数据库 TSDB 中（TSDB 包含在 Prometheus 进程中，无需单独部署）。Prometheus 也支持通过搭建 [Push Gateway](#) 的方式，允许被监控系统将监控数据通过 Push 的方式推到 Push Gateway, 再由 Prometheus Server 通过 Pull 的方式从 Push Gateway 中获取数据。
- 2. [Alert Manager](#) 为 Prometheus 报警组件，需单独部署（暂不提供方案，可参照官方文档自行搭建）。通过 Alert Manager，用户可以配置报警策略，接收邮件、短信等报警。



3. 绿色部分为 Grafana 相关组件。Grafana Server 为 Grafana 的主进程。启动后，用户可以通过 Web 页面对 Grafana 进行配置，包括数据源的设置、用户设置、Dashboard 绘制等。这里也是最终用户查看监控数据的地方。

## 开始搭建

请在完成 Doris 的部署后，开始搭建监控系统。

### Prometheus

1. 在 [Prometheus 官网](#) 下载最新版本的 Prometheus。这里我们以 2.43.0-linux-amd64 版本为例。
2. 在准备运行监控服务的机器上，解压下载后的 tar 文件。
3. 打开配置文件 prometheus.yml。这里我们提供一个示例配置并加以说明（配置文件为 yml 格式，一定要注意统一的缩进和空格）：

这里我们使用最简单的静态文件的方式进行监控配置。Prometheus 支持多种 [服务发现](#) 方式，可以动态的感知节点的加入和删除。

```
my global config
global:
 scrape_interval: 15s # 全局的采集间隔，默认是 1m，这里设置为 15s
 evaluation_interval: 15s # 全局的规则触发间隔，默认是 1m，这里设置 15s

Alertmanager configuration
alerting:
 alertmanagers:
 - static_configs:
 - targets:
 # - alertmanager:9093

A scrape configuration containing exactly one endpoint to scrape:
Here it's Prometheus itself.
scrape_configs:
 # The job name is added as a label `job=<job_name>` to any timeseries scraped from this config.
 - job_name: 'DORIS_CLUSTER' # 每一个 Doris 集群，我们称为一个 job。这里可以给 job 取一个名字，作为 Doris 集群
 # 在监控系统中的名字。
 metrics_path: '/metrics' # 这里指定获取监控项的 restful api。配合下面的 targets 中的 host:port，
 # Prometheus 最终会通过 host:port/metrics_path 来采集监控项。
 static_configs: # 这里开始分别配置 FE 和 BE 的目标地址。所有的 FE 和 BE 都分别写入各自的 group 中。
 - targets: ['fe_host1:8030', 'fe_host2:8030', 'fe_host3:8030']
 labels:
 group: fe # 这里配置了 fe 的 group，该 group 中包含了 3 个 Frontends

 - targets: ['be_host1:8040', 'be_host2:8040', 'be_host3:8040']
 labels:
 group: be # 这里配置了 be 的 group，该 group 中包含了 3 个 Backends

 - job_name: 'DORIS_CLUSTER_2' # 我们可以在一个 Prometheus 中监控多个 Doris 集群，这里开始另一个 Doris 集群的
 # 配置。配置同上，以下略。
 metrics_path: '/metrics'
 static_configs:
 - targets: ['fe_host1:8030', 'fe_host2:8030', 'fe_host3:8030']
 labels:
 group: fe

 - targets: ['be_host1:8040', 'be_host2:8040', 'be_host3:8040']
```

```
labels:
 group: be
```

#### 4. 启动 Prometheus

通过以下命令启动 Prometheus：

```
nohup ./prometheus --web.listen-address="0.0.0.0:8181" &
```

该命令将后台运行 Prometheus，并指定其 web 端口为 8181。启动后，即开始采集数据，并将数据存放在 data 目录中。

#### 5. 停止 Prometheus

目前没有发现正式的进程停止方式，直接 kill -9 即可。当然也可以将 Prometheus 设为一种 service，以 service 的方式启停。

#### 6. 访问 Prometheus

Prometheus 可以通过 web 页面进行简单的访问。通过浏览器打开 8181 端口，即可访问 Prometheus 的页面。点击导航栏中，Status -> Targets，可以看到所有分组 Job 的监控主机节点。正常情况下，所有节点都应 UP，表示数据采集正常。点击某一个 Endpoint，即可看到当前的监控数值。如果节点状态不为 UP，可以先访问 Doris 的 metrics 接口（见前文）检查是否可以访问，或查询 Prometheus 相关文档尝试解决。

#### 7. 至此，一个简单的 Prometheus 已经搭建、配置完毕。更多高级使用方式，请参阅 [官方文档](#)

### Grafana

1. 在 [Grafana 官网](#) 下载最新版本的 Grafana。这里我们以 8.5.22.linux-amd64 版本为例。
2. 在准备运行监控服务的机器上，解压下载后的 tar 文件。
3. 打开配置文件 conf/defaults.ini。这里我们仅列举需要改动的配置项，其余配置可使用默认。

```
Path to where grafana can store temp files, sessions, and the sqlite3 db (if that is used)
data = data

Directory where grafana can store logs
logs = data/log

Protocol (http, https, socket)
protocol = http

The ip address to bind to, empty will bind to all interfaces
http_addr =

The http port to use
http_port = 8182
```

#### 4. 启动 Grafana

通过以下命令启动 Grafana

```
nohup ./bin/grafana-server &
```

该命令将后台运行 Grafana，访问端口为上面配置的 8182

## 5. 停止 Grafana

目前没有发现正式的进程停止方式，直接 kill -9 即可。当然也可以将 Grafana 设为一种 service，以 service 的方式启停。

## 6. 访问 Grafana

通过浏览器，打开 8182 端口，可以开始访问 Grafana 页面。默认用户名密码为 admin。

## 7. 配置 Grafana

初次登陆，需要根据提示设置数据源（data source）。我们这里的数据源，即上一步配置的 Prometheus。

数据源配置的 Setting 页面说明如下：


1. Name: 数据源的名称，自定义，比如 doris\_monitor\_data\_source
2. Type: 选择 Prometheus
3. URL: 填写 Prometheus 的 web 地址，如 http://host:8181
4. Access: 这里我们选择 Server 方式，即通过 Grafana 进程所在服务器，访问 Prometheus。
5. 其余选项默认即可。
6. 点击最下方 Save & Test，如果显示 Data source is working，即表示数据源可用。
7. 确认数据源可用后，点击左边导航栏的 + 号，开始添加 Dashboard。这里我们已经准备好了 Doris 的 Dashboard 模板（本文档开头）。下载完成后，点击上方的 New dashboard->Import dashboard->Upload .json File，将下载的 json 文件导入。
8. 导入后，可以命名 Dashboard，默认是 Doris Overview。同时，需要选择数据源，这里选择之前创建的 doris\_monitor\_data\_source
9. 点击 Import，即完成导入。之后，可以看到 Doris 的 Dashboard 展示。

8. 至此，一个简单的 Grafana 已经搭建、配置完毕。更多高级使用方式，请参阅 [官方文档](#)

## Dashboard 说明

这里我们简要介绍 Doris Dashboard。Dashboard 的内容可能会随版本升级，不断变化，本文档不保证是最新的 Dashboard 说明。

### 1. 顶栏




顶栏

- 左上角为 Dashboard 名称。

- 右上角显示当前监控时间范围，可以下拉选择不同的时间范围，还可以指定定时刷新页面间隔。
- `cluster_name`: 即 Prometheus 配置文件中的各个 `job_name`，代表一个 Doris 集群。选择不同的 `cluster`，下方的图表将展示对应集群的监控信息。
- `fe_master`: 对应集群的 Master Frontend 节点。
- `fe_instance`: 对应集群的所有 Frontend 节点。选择不同的 Frontend，下方的图表将展示对应 Frontend 的监控信息。
- `be_instance`: 对应集群的所有 Backend 节点。选择不同的 Backend，下方的图表将展示对应 Backend 的监控信息。
- `interval`: 有些图表展示了速率相关的监控项，这里可选择以多大间隔进行采样计算速率（注：15s 间隔可能导致一些图表无法显示）。

## 2. Row




### Row

Grafana 中，Row 的概念，即一组图表的集合。如上图中的 Overview、Cluster Overview 即两个不同的 Row。可以通过点击 Row，对 Row 进行折叠。当前 Dashboard 有如下 Rows（持续更新中）：

- Overview: 所有 Doris 集群的汇总展示。
- Cluster Overview: 选定集群的汇总展示。
- Query Statistic: 选定集群的查询相关监控。
- FE JVM: 选定 Frontend 的 JVM 监控。
- BE: 选定集群的 Backends 的汇总展示。
- BE Task: 选定集群的 Backends 任务信息的展示。

## 3. 图表



图表

一个典型的图标分为以下几部分：

- 鼠标悬停左上角的 i 图标，可以查看该图表的说明。
- 点击下方的图例，可以单独查看某一监控项。再次点击，则显示所有。
- 在图表中拖拽可以选定时间范围。
- 标题的 [ ] 中显示选定的集群名称。
- 一些数值对应左边的 Y 轴，一些对应右边的，可以通过图例末尾的 -right 区分。
- 点击图表名称->Edit，可以对图表进行编辑。

## Dashboard 更新

1. 点击 Grafana 左边栏的 +，点击 Dashboard。
2. 点击左上角的 New dashboard，在点击右侧出现的 Import dashboard。
3. 点击 Upload .json File，选择最新的模板文件。
4. 选择数据源
5. 点击 Import(Overwrite)，完成模板更新。

# 磁盘空间管理

本文档主要介绍和磁盘存储空间有关的系统参数和处理策略。

Doris 的数据磁盘空间如果不加以控制，会因磁盘写满而导致进程挂掉。因此我们监测磁盘的使用率和剩余空间，通过设置不同的警戒水位，来控制 Doris 系统中的各项操作，尽量避免发生磁盘被写满的情况。

## 名词解释

- Data Dir：数据目录，在 BE 配置文件 `be.conf` 的 `storage_root_path` 中指定的各个数据目录。通常一个数据目录对应一个磁盘、因此下文中 **磁盘** 也指代一个数据目录。

## 基本原理

BE 定期（每隔一分钟）会向 FE 汇报一次磁盘使用情况。FE 记录这些统计值，并根据这些统计值，限制不同的操作请求。

在 FE 中分别设置了 **高水位（High Watermark）** 和 **危险水位（Flood Stage）** 两级阈值。危险水位高于高水位。当磁盘使用率高于高水位时，Doris 会限制某些操作的执行（如副本均衡等）。而如果高于危险水位，则会禁止某些操作的执行（如导入）。

同时，在 BE 上也设置了 **危险水位（Flood Stage）**。考虑到 FE 并不能完全及时的检测到 BE 上的磁盘使用情况，以及无法控制某些 BE 自身运行的操作（如 Compaction）。因此 BE 上的危险水位用于 BE 主动拒绝和停止某些操作，达到自我保护的目的。

## FE 参数

高水位：

```
storage_high_watermark_usage_percent 默认 85（85%）。
storage_min_left_capacity_bytes 默认 2GB。
```

当磁盘空间使用率大于 `storage_high_watermark_usage_percent`，或者磁盘空间剩余大小小于 `storage_min_left_capacity_bytes` 时，该磁盘不会再被作为以下操作的目的路径：

- Tablet 均衡操作（Balance）
- Colocation 表数据分片的重分布（Relocation）
- Decommission

危险水位：

```
storage_flood_stage_usage_percent 默认 95（95%）。
storage_flood_stage_left_capacity_bytes 默认 1GB。
```

当磁盘空间使用率大于 `storage_flood_stage_usage_percent`，并且 磁盘空间剩余大小小于 `storage_flood_stage_left_capacity_bytes` 时，该磁盘不会再被作为以下操作的目的路径，并禁止某些操作：

- Tablet 均衡操作（Balance）
- Colocation 表数据分片的重分布（Relocation）
- 副本补齐
- 恢复操作（Restore）
- 数据导入（Load/Insert）

## BE 参数

危险水位：

```
storage_flood_stage_usage_percent 默认 90（90%）。
storage_flood_stage_left_capacity_bytes 默认 1GB。
```

当磁盘空间使用率大于 `storage_flood_stage_usage_percent`，并且 磁盘空间剩余大小小于 `storage_flood_stage_left_capacity_bytes` 时，该磁盘上的以下操作会被禁止：

- Base/Cumulative Compaction。
- 数据写入。包括各种导入操作。
- Clone Task。通常发生于副本修复或均衡时。
- Push Task。发生在 Hadoop 导入的 Loading 阶段，下载文件。
- Alter Task。Schema Change 或 Rollup 任务。
- Download Task。恢复操作的 Downloading 阶段。

## 磁盘空间释放

当磁盘空间高于高水位甚至危险水位后，很多操作都会被禁止。此时可以尝试通过以下方式减少磁盘使用率，恢复系统。

- 删除表或分区

通过删除表或分区的方式，能够快速降低磁盘空间使用率，恢复集群。**注意：只有 DROP 操作可以达到快速降低磁盘空间使用率的目的，DELETE 操作不可以。**

```
DROP TABLE tbl;
ALTER TABLE tbl DROP PARTITION p1;
```

- 扩容 BE

扩容后，数据分片会自动均衡到磁盘使用率较低的 BE 节点上。扩容操作会根据数据量及节点数量不同，在数小时或数天后使集群到达均衡状态。

- 修改表或分区的副本

可以将表或分区的副本数降低。比如默认 3 副本可以降低为 2 副本。该方法虽然降低了数据的可靠性，但是能够快速降低磁盘使用率，使集群恢复正常。该方法通常用于紧急恢复系统。请在恢复后，通过扩容或删除数据等方式，降低磁盘使用率后，将副本数恢复为 3。

修改副本操作为瞬间生效，后台会自动异步删除多余的副本。

```
ALTER TABLE tbl MODIFY PARTITION p1 SET("replication_num" = "2");
```

- 删除多余文件

当 BE 进程已经因为磁盘写满而挂掉并无法启动时（此现象可能因 FE 或 BE 检测不及时而发生）。需要通过删除数据目录下的一些临时文件，保证 BE 进程能够启动。以下目录中的文件可以直接删除：

- log/：日志目录下的日志文件。
- snapshot/：快照目录下的快照文件。
- trash/：回收站中的文件。

这种操作会对 [从 BE 回收站中恢复数据](#) 产生影响。

如果 BE 还能够启动，则可以使用 `ADMIN CLEAN TRASH ON(BackendHost:BackendHeartBeatPort);` 来主动清理临时文件，会清理所有 trash 文件和过期 snapshot 文件，这将影响从回收站恢复数据的操作。

如果不手动执行 `ADMIN CLEAN TRASH`，系统仍将会在几分钟至几十分钟内自动执行清理，这里分为两种情况：

- 如果磁盘占用未达到 **危险水位 (Flood Stage)** 的 90%，则会清理过期 trash 文件和过期 snapshot 文件，此时会保留一些近期文件而不影响恢复数据。
- 如果磁盘占用已达到 **危险水位 (Flood Stage)** 的 90%，则会清理所有 trash 文件和过期 snapshot 文件，此时会影响从回收站恢复数据的操作。自动执行的时间间隔可以通过配置项中的 `max_garbage_sweep_interval` 和 `min_garbage_sweep_interval` 更改。

出现由于缺少 trash 文件而导致恢复失败的情况时，可能返回如下结果：

```
{"status": "Fail", "msg": "can find tablet path in trash"}
```

- 删除数据文件（危险！！！）

当以上操作都无法释放空间时，需要通过删除数据文件来释放空间。数据文件在指定数据目录的 `data/` 目录下。删除数据分片（Tablet）必须先确保该 Tablet 至少有一个副本是正常的，否则删除唯一副本会导致数据丢失。假设我们要删除 id 为 12345 的 Tablet：

- 找到 Tablet 对应的目录，通常位于 `data/shard_id/tablet_id/` 下。如：

`data/0/12345/`



- 记录 tablet id 和 schema hash。其中 schema hash 为上一步目录的下一级目录名。如下为 352781111：

```
data/0/12345/352781111
```

- 删除数据目录：

```
rm -rf data/0/12345/
```

- 删除 Tablet 元数据（具体参考 [Tablet 元数据管理工具](#)）

```
./lib/meta_tool --operation=delete_header --root_path=/path/to/root_path --
tablet_id=12345 --schema_hash= 352781111
```


# 数据副本管理

从 0.9.0 版本开始，Doris 引入了优化后的副本管理策略，同时支持了更为丰富的副本状态查看工具。本文档主要介绍 Doris 数据副本均衡、修复方面的调度策略，以及副本管理的运维方法。帮助用户更方便的掌握和管理集群中的副本状态。

Colocation 属性的表的副本修复和均衡可以参阅[这里](#)

## 名词解释

- 1. Tablet：Doris 表的逻辑分片，一个表有多个分片。
- 2. Replica：分片的副本，默认一个分片有 3 个副本。
- 3. Healthy Replica：健康副本，副本所在 Backend 存活，且副本的版本完整。
- 4. TabletChecker (TC)：是一个常驻的后台线程，用于定期扫描所有的 Tablet，检查这些 Tablet 的状态，并根据检查结果，决定是否将 tablet 发送给 TabletScheduler。
- 5. TabletScheduler (TS)：是一个常驻的后台线程，用于处理由 TabletChecker 发来的需要修复的 Tablet。同时也会进行集群副本均衡的工作。
- 6. TabletSchedCtx (TSC)：是一个 tablet 的封装。当 TC 选择一个 tablet 后，会将其封装为一个 TSC，发送给 TS。
- 7. Storage Medium：存储介质。Doris 支持对分区粒度指定不同的存储介质，包括 SSD 和 HDD。副本调度策略也是针对不同的存储介质分别调度的。



上图是一个简化的工作流程。

## 副本状态

一个 Tablet 的多个副本，可能因为某些情况导致状态不一致。Doris 会尝试自动修复这些状态不一致的副本，让集群尽快从错误状态中恢复。

一个 Replica 的健康状态有以下几种：

### 1. BAD

即副本损坏。包括但不限于磁盘故障、BUG 等引起的副本不可恢复的损毁状态。

### 2. VERSION\_MISSING

版本缺失。Doris 中每一批次导入都对应一个数据版本。而一个副本的数据由多个连续的版本组成。而由于导入错误、延迟等原因，可能导致某些副本的数据版本不完整。

### 3. HEALTHY

健康副本。即数据正常的副本，并且副本所在的 BE 节点状态正常（心跳正常且不处于下线过程中）

一个 **Tablet** 的健康状态由其所有副本的状态决定，有以下几种：

#### 1. REPLICA\_MISSING

副本缺失。即存活副本数小于期望副本数。

#### 2. VERSION\_INCOMPLETE

存活副本数大于等于期望副本数，但其中健康副本数小于期望副本数。

#### 3. REPLICA\_RELOCATING

拥有等于 replication num 的版本完整的存活副本数，但是部分副本所在的 BE 节点处于 unavailable 状态（比如 decommission 中）

#### 4. REPLICA\_MISSING\_IN\_CLUSTER

当使用多 cluster 方式时，健康副本数大于等于期望副本数，但在对应 cluster 内的副本数小于期望副本数。

#### 5. REDUNDANT

副本冗余。健康副本都在对应 cluster 内，但数量大于期望副本数。或者有多余的 unavailable 副本。

#### 6. FORCE\_REDUNDANT

这是一个特殊状态。只会出现在当已存在副本数大于等于可用节点数，可用节点数大于等于期望副本数，并且存活的副本数小于期望副本数。这种情况下，需要先删除一个副本，以保证有可用节点用于创建新副本。

#### 7. COLOCATE\_MISMATCH

针对 Colocation 属性的表的分片状态。表示分片副本与 Colocation Group 的指定的分布不一致。

#### 8. COLOCATE\_REDUNDANT

针对 Colocation 属性的表的分片状态。表示 Colocation 表的分片副本冗余。

#### 9. HEALTHY

健康分片，即条件[1-8]都不满足。

## 副本修复

TabletChecker 作为常驻的后台进程，会定期检查所有分片的状态。对于非健康状态的分片，将会交给 TabletScheduler 进行调度和修复。修复的实际操作，都由 BE 上的 clone 任务完成。FE 只负责生成这些 clone 任务。

- 注 1：副本修复的主要思想是先通过创建或补齐使得分片的副本数达到期望值，然后再删除多余的副本。

- 注 2：一个 clone 任务就是完成从一个指定远端 BE 拷贝指定数据到指定目的端 BE 的过程。

针对不同的状态，我们采用不同的修复方式：

### 1. REPLICA\_MISSING/REPLICA\_RELOCATING

选择一个低负载的，可用的 BE 节点作为目的端。选择一个健康副本作为源端。clone 任务会从源端拷贝一个完整的副本到目的端。对于副本补齐，我们会直接选择一个可用的 BE 节点，而不考虑存储介质。

### 2. VERSION\_INCOMPLETE

选择一个相对完整的副本作为目的端。选择一个健康副本作为源端。clone 任务会从源端尝试拷贝缺失的版本到目的端的副本。

### 3. REPLICA\_MISSING\_IN\_CLUSTER

这种状态处理方式和 REPLICA\_MISSING 相同。

### 4. REDUNDANT

通常经过副本修复后，分片会有冗余的副本。我们选择一个冗余副本将其删除。冗余副本的选择遵从以下优先级：

1. 副本所在 BE 已经下线
2. 副本已损坏
3. 副本所在 BE 失联或在下线中
4. 副本处于 CLONE 状态（该状态是 clone 任务执行过程中的一个中间状态）
5. 副本有版本缺失
6. 副本所在 cluster 不正确
7. 副本所在 BE 节点负载高

### 5. FORCE\_REDUNDANT

不同于 REDUNDANT，因为此时虽然存活的副本数小于期望副本数，但是因为已经没有额外的可用节点用于创建新的副本了。所以此时必须先删除一个副本，以腾出一个可用节点用于创建新的副本。删除副本的顺序同 REDUNDANT。

### 6. COLOCATE\_MISMATCH

从 Colocation Group 中指定的副本分布 BE 节点中选择一个作为目的节点进行副本补齐。

## 7. COLOCATE\_REDUNDANT

删除一个非 Colocation Group 中指定的副本分布 BE 节点上的副本。

Doris 在选择副本节点时，不会将同一个 Tablet 的副本部署在同一个 host 的不同 BE 上。保证了即使同一个 host 上的所有 BE 都挂掉，也不会造成全部副本丢失。

## 调度优先级

TabletScheduler 里等待被调度的分片会根据状态不同，赋予不同的优先级。优先级高的分片将会被优先调度。目前有以下几种优先级。

### 1. VERY\_HIGH

- REDUNDANT。对于有副本冗余的分片，我们优先处理。虽然逻辑上来讲，副本冗余的紧急程度最低，但是因为这种情况处理起来最快且可以快速释放资源（比如磁盘空间等），所以我们优先处理。
- FORCE\_REDUNDANT。同上。

### 2. HIGH

- REPLICA\_MISSING 且多数副本缺失（比如 3 副本丢失了 2 个）
- VERSION\_INCOMPLETE 且多数副本的版本缺失
- COLOCATE\_MISMATCH 我们希望 Colocation 表相关的分片能够尽快修复完成。
- COLOCATE\_REDUNDANT

### 3. NORMAL

- REPLICA\_MISSING 但多数存活（比如 3 副本丢失了 1 个）
- VERSION\_INCOMPLETE 但多数副本的版本完整
- REPLICA\_RELOCATING 且多数副本需要 relocate（比如 3 副本有 2 个）

### 4. LOW

- REPLICA\_MISSING\_IN\_CLUSTER
- REPLICA\_RELOCATING 但多数副本 stable

## 手动优先级

系统会自动判断调度优先级。但是有些时候，用户希望某些表或分区的分片能够更快的被修复。因此我们提供一个命令，用户可以指定某个表或分区的分片被优先修复：

```
ADMIN REPAIR TABLE tbl [PARTITION (p1, p2, ...)];
```

这个命令，告诉 TC，在扫描 Tablet 时，对需要优先修复的表或分区中的有问题的 Tablet，给予 VERY\_HIGH 的优先级。

注：这个命令只是一个 hint，并不能保证一定能修复成功，并且优先级也会随 TS 的调度而发生变化。并且当 Master FE 切换或重启后，这些信息都会丢失。

可以通过以下命令取消优先级：

```
ADMIN CANCEL REPAIR TABLE tbl [PARTITION (p1, p2, ...)];
```

## 优先级调度

优先级保证了损坏严重的分片能够优先被修复，提高系统可用性。但是如果高优先级的修复任务一直失败，则会导致低优先级的任务一直得不到调度。因此，我们会根据任务的运行状态，动态的调整任务的优先级，保证所有任务都有机会被调度到。

- 连续 5 次调度失败（如无法获取资源，无法找到合适的源端或目的端等），则优先级会被下调。
- 持续 30 分钟未被调度，则上调优先级。
- 同一 tablet 任务的优先级至少间隔 5 分钟才会被调整一次。

同时为了保证初始优先级的权重，我们规定，初始优先级为 VERY\_HIGH 的，最低被下调到 NORMAL。而初始优先级为 LOW 的，最多被上调为 HIGH。这里的优先级调整，也会调整用户手动设置的优先级。

## 副本均衡

Doris 会自动进行集群内的副本均衡。目前支持两种均衡策略，负载/分区。负载均衡适合需要兼顾节点磁盘使用率和节点副本数量的场景；而分区均衡会使每个分区的副本都均匀分布在各个节点，避免热点，适合对分区读写要求比较高的场景。但是，分区均衡不考虑磁盘使用率，使用分区均衡时需要注意磁盘的使用情况。策略只能在 fe 启动前配置 `tablet_rebalancer_type`，不支持运行时切换。

## 负载均衡

负载均衡的主要思想是，对某些分片，先在低负载的节点上创建一个副本，然后再删除这些分片在高负载节点上的副本。同时，因为不同存储介质的存在，在同一个集群内的不同 BE 节点上，可能存在一种或两种存储介质。我们要求存储介质为 A 的分片在均衡后，尽量依然存储在存储介质 A 中。所以我们根据存储介质，对集群的 BE 节点进行划分。然后针对不同的存储介质的 BE 节点集合，进行负载均衡调度。

同样，副本均衡会保证不会将同一个 Tablet 的副本部署在同一个 host 的 BE 上。

## BE 节点负载

我们用 ClusterLoadStatistics (CLS) 表示一个 cluster 中各个 Backend 的负载均衡情况。TabletScheduler 根据这个统计值，来触发集群均衡。我们当前通过 **磁盘使用率** 和 **副本数量** 两个指标，为每个 BE 计算一个 loadScore，作为 BE 的负载分数。分数越高，表示该 BE 的负载越重。

磁盘使用率和副本数量各有一个权重系数，分别为 **capacityCoefficient** 和 **replicaNumCoefficient**，其和恒为 1。其中 capacityCoefficient 会根据实际磁盘使用率动态调整。当一个 BE 的总体磁盘使用率在 50% 以下，则

capacityCoefficient 值为 0.5，如果磁盘使用率在 75%（可通过 FE 配置项 capacity\_used\_percent\_high\_water 配置）以上，则值为 1。如果使用率介于 50% ~ 75% 之间，则该权重系数平滑增加，公式为：

$$\text{capacityCoefficient} = 2 * \text{磁盘使用率} - 0.5$$

该权重系数保证当磁盘使用率过高时，该 Backend 的负载分数会更高，以保证尽快降低这个 BE 的负载。

TabletScheduler 会每隔 20s 更新一次 CLS。

## 分区均衡

分区均衡的主要思想是，将每个分区的在各个 Backend 上的 replica 数量差（即 partition skew），减少到最小。因此只考虑副本个数，不考虑磁盘使用率。为了尽量少的迁移次数，分区均衡使用二维贪心的策略，优先均衡 partition skew 最大的分区，均衡分区时会尽量选择，可以使整个 cluster 的在各个 Backend 上的 replica 数量差（即 cluster skew/total skew）减少的方向。

### skew 统计

skew 统计信息由 ClusterBalanceInfo 表示，其中，partitionInfoBySkew 以 partition skew 为 key 排序，便于找到 max partition skew；beByTotalReplicaCount 则是以 Backend 上的所有 replica 个数为 key 排序。ClusterBalanceInfo 同样保持在 CLS 中，同样 20s 更新一次。

max partition skew 的分区可能有多个，采用随机的方式选择一个分区计算。

## 均衡策略

TabletScheduler 在每轮调度时，都会通过 LoadBalancer 来选择一定数目的健康分片作为 balance 的候选分片。在下一次调度时，会尝试根据这些候选分片，进行均衡调度。

## 资源控制

无论是副本修复还是均衡，都是通过副本在各个 BE 之间拷贝完成的。如果同一台 BE 同一时间执行过多的任务，则会带来不小的 IO 压力。因此，Doris 在调度时控制了每个节点上能够执行的任务数目。最小的资源控制单位是磁盘（即在 be.conf 中指定的一个数据路径）。我们默认为每块磁盘配置两个 slot 用于副本修复。一个 clone 任务会占用源端和目的端各一个 slot。如果 slot 数目为零，则不会再对这块磁盘分配任务。该 slot 个数可以通过 FE 的 schedule\_slot\_num\_per\_path 参数配置。

另外，我们默认为每块磁盘提供 2 个单独的 slot 用于均衡任务。目的是防止高负载的节点因为 slot 被修复任务占用，而无法通过均衡释放空间。

## 副本状态查看

副本状态查看主要是查看副本的状态，以及副本修复和均衡任务的运行状态。这些状态大部分都仅存在于 Master FE 节点中。因此，以下命令需直连到 Master FE 执行。

### 副本状态

#### 1. 全局状态检查

通过 SHOW PROC '/cluster\_health/tablet\_health'; 命令可以查看整个集群的副本状态。

| DbId  | DbName                         | TabletNum | HealthyNum | ReplicaMissingNum | VersionIncompleteNum | ReplicaRelocatingNum | RedundantNum | ReplicaMissingInClusterNum | ReplicaMissingForTagNum | ForceRedundantNum | ColocateMismatchNum | ColocateRedundantNum | NeedFurtherRepairNum | UnrecoverableNum | ReplicaCompactionTooSlowNum | InconsistentNum | OversizeNum | CloningNum |
|-------|--------------------------------|-----------|------------|-------------------|----------------------|----------------------|--------------|----------------------------|-------------------------|-------------------|---------------------|----------------------|----------------------|------------------|-----------------------------|-----------------|-------------|------------|
| 10005 | default_cluster:doris_audit_db | 84        | 84         | 0                 | 0                    | 0                    | 0            | 0                          | 0                       | 0                 | 0                   | 0                    | 0                    | 0                | 0                           | 0               | 0           | 0          |
| 13402 | default_cluster:ssb1           | 709       | 708        | 1                 | 0                    | 0                    | 0            | 0                          | 0                       | 0                 | 0                   | 0                    | 0                    | 0                | 0                           | 0               | 0           | 0          |
| 10108 | default_cluster:tpch1          | 278       | 278        | 0                 | 0                    | 0                    | 0            | 0                          | 0                       | 0                 | 0                   | 0                    | 0                    | 0                | 0                           | 0               | 0           | 0          |
| Total | 3                              | 1071      | 1070       | 1                 | 0                    | 0                    | 0            | 0                          | 0                       | 0                 | 0                   | 0                    | 0                    | 0                | 0                           | 0               | 0           | 0          |

其中 HealthyNum 列显示了对应的 Database 中，有多少 Tablet 处于健康状态。

ReplicaCompactionTooSlowNum 列显示了对应的 Database 中，有多少 Tablet 处于副本版本数过多的状态，InconsistentNum 列显示了对应的 Database 中，有多少 Tablet 处于副本不一致的状态。最后一行 Total 行对整个集群进行了统计。正常情况下 TabletNum 和 HealthNum 应该相等。如果不相等，可以进一步查看具体有哪些 Tablet。如上图，ssb1 数据库有 1 个 Tablet 状态不健康，则可以使用以下命令查看具体是哪一个 Tablet。

SHOW PROC '/cluster\_health/tablet\_health/13402';

其中 13402 为对应的 DbId。

| ReplicaMissingTablets | VersionIncompleteTablets | ReplicaRelocatingTablets | RedundantTablets | ReplicaMissingInClusterTablets | ReplicaMissingForTagTablets | ForceRedundantTablets | ColocateMismatchTablets | ColocateRedundantTablets | NeedFurtherRepairTablets | UnrecoverableTablets | ReplicaCompactionTooSlowTablets | InconsistentTablets | OversizeTablets |
|-----------------------|--------------------------|--------------------------|------------------|--------------------------------|-----------------------------|-----------------------|-------------------------|--------------------------|--------------------------|----------------------|---------------------------------|---------------------|-----------------|
| 14679                 |                          |                          |                  |                                |                             |                       |                         |                          |                          |                      |                                 |                     |                 |





|                                                           |
|-----------------------------------------------------------|
| 29502429   29502432   10006   1421156361   2   0   2   0  |
| -1   0   N/A   784   0   NORMAL   N/A                     |
| -1   -1   2   -5822326203532286804   url                  |
| url                                                       |
| 29502429   36885996   10002   1421156361   2   0   -1   0 |
| -1   0   N/A   784   0   NORMAL   N/A                     |
| -1   -1   2   -1441285706148429853   url                  |
| url                                                       |
| 29502429   48100551   10007   1421156361   2   0   -1   0 |
| -1   0   N/A   784   0   NORMAL   N/A                     |
| -1   -1   2   -4784691547051455525   url                  |
| url                                                       |
| +-----+-----+-----+-----+-----+-----+-----+-----+         |
| +-----+-----+-----+-----+-----+-----+-----+-----+         |
| +-----+-----+-----+-----+-----+-----+-----+-----+         |
| +-----+-----+-----+-----+-----+-----+-----+-----+         |

上图展示了包括副本大小、行数、版本数量、所在数据路径等一些额外的信息。

:::tip 注：这里显示的 State 列的内容不代表副本的健康状态，而是副本处于某种任务下的状态，比如 CLONE、SCHEMA\_CHANGE、ROLLUP 等。:::

此外，用户也可以通过以下命令，查看指定表或分区的副本分布情况，来检查副本分布是否均匀。

ADMIN SHOW REPLICA DISTRIBUTION FROM tbl1;

| BackendId | ReplicaNum | Graph | Percent |
|-----------|------------|-------|---------|
| 10000     | 7          |       | 7.29 %  |
| 10001     | 9          |       | 9.38 %  |
| 10002     | 7          |       | 7.29 %  |
| 10003     | 7          |       | 7.29 %  |
| 10004     | 9          |       | 9.38 %  |
| 10005     | 11         | >     | 11.46 % |
| 10006     | 18         | >     | 18.75 % |
| 10007     | 15         | >     | 15.62 % |
| 10008     | 13         | >     | 13.54 % |

这里分别展示了表 tbl1 的副本在各个 BE 节点上的个数、百分比，以及一个简单的图形化显示。

### 3. Tablet 级别状态检查

当我们要定位到某个具体的 Tablet 时，可以使用如下命令来查看一个具体的 Tablet 的状态。如查看 ID 为 29502553 的 tablet：

SHOW TABLET 29502553;

| DbName               | TableName | PartitionName                                                             | IndexName | DbId     | TableId  | PartitionId |
|----------------------|-----------|---------------------------------------------------------------------------|-----------|----------|----------|-------------|
| IndexId              | IsSync    | DetailCmd                                                                 |           |          |          |             |
| default_cluster:test | test      | test                                                                      | test      | 29502391 | 29502428 | 29502427    |
| 29502428             | true      | SHOW PROC '/dbs/29502391/29502428/partitions/29502427/29502428/29502553'; |           |          |          |             |

|  |
|--|
|  |
|  |

上图显示了这个 tablet 所对应的数据库、表、分区、上卷表等信息。用户可以复制 DetailCmd 命令中的命令继续执行：

SHOW PROC '/dbs/29502391/29502428/partitions/29502427/29502428/29502553';

| ReplicaId            | BackendId | Version | VersionHash | LstSuccessVersion | LstSuccessVersionHash | LstFailedVersion | LstFailedVersionHash | LstFailedTime | SchemaHash | DataSize | RowCount | State | IsBad | VersionCount | PathHash | MetaUrl | CompactionStatus |
|----------------------|-----------|---------|-------------|-------------------|-----------------------|------------------|----------------------|---------------|------------|----------|----------|-------|-------|--------------|----------|---------|------------------|
| 43734060             | 10004     | 2       | 0           | -1                | 0                     |                  |                      |               |            |          |          | -1    |       |              |          |         |                  |
| 0                    |           | N/A     | -1          | 784               | 0                     |                  |                      |               |            | NORMAL   | false    | 2     |       |              |          |         |                  |
| -8566523878520798656 | url       |         | url         |                   |                       |                  |                      |               |            |          |          |       |       |              |          |         |                  |
| 29502555             | 10002     | 2       | 0           | 2                 | 0                     |                  |                      |               |            |          |          | -1    |       |              |          |         |                  |
| 0                    |           | N/A     | -1          | 784               | 0                     |                  |                      |               |            | NORMAL   | false    | 2     |       |              |          |         |                  |
| 1885826196444191611  | url       |         | url         |                   |                       |                  |                      |               |            |          |          |       |       |              |          |         |                  |
| 39279319             | 10007     | 2       | 0           | -1                | 0                     |                  |                      |               |            |          |          | -1    |       |              |          |         |                  |
| 0                    |           | N/A     | -1          | 784               | 0                     |                  |                      |               |            | NORMAL   | false    | 2     |       |              |          |         |                  |
| 1656508631294397870  | url       |         | url         |                   |                       |                  |                      |               |            |          |          |       |       |              |          |         |                  |

上图显示了对应 Tablet 的所有副本情况。这里显示的内容和 SHOW TABLETS FROM tbl1; 的内容相同。但这里可以清楚的知道，一个具体的 Tablet 的所有副本的状态。

# 副本调度任务

## 1. 查看等待被调度的任务

SHOW PROC '/cluster\_balance/pending\_tablets';

| TabletId | Type   | Status          | State   | OrigPrio | DynmPrio | SrcBe | SrcPath | DestBe | DestPath | Timeout | Create              | LstSched            | LstVisit            | Finished | Rate | FailedSched | FailedRunning       | LstAdjPrio | VisibleVer | VisibleVerHash | CmtVer | CmtVerHash                    | ErrMsg |
|----------|--------|-----------------|---------|----------|----------|-------|---------|--------|----------|---------|---------------------|---------------------|---------------------|----------|------|-------------|---------------------|------------|------------|----------------|--------|-------------------------------|--------|
| 4203036  | REPAIR | REPLICA_MISSING | PENDING | HIGH     | LOW      | -1    | -1      | -1     | -1       | 0       | 2019-02-21 15:00:20 | 2019-02-24 11:18:41 | 2019-02-24 11:18:41 | N/A      | 2    | 0           | 2019-02-21 15:00:43 | 1          | 0          | 2              | 0      | unable to find source replica |        |



```
SHOW PROC '/cluster_balance/history_tablets';
```

我们默认只保留最近 1000 个完成的任务。其结果中各列的含义和 pending\_tablets 相同。如果 State 列为 FINISHED，则说明任务正常完成。如果为其他，则可以根据 ErrMsg 列的错误信息查看具体原因。

## 集群负载及调度资源查看

### 1. 集群负载

通过以下命令可以查看集群当前的负载情况：

```
SHOW PROC '/cluster_balance/cluster_load_stat/location_default';
```

首先看到的是对不同存储介质的划分：

```
+-----+
| StorageMedium |
+-----+
| HDD |
| SSD |
+-----+
```

点击某一种存储介质，可以看到包含该存储介质的 BE 节点的均衡状态：

```
SHOW PROC '/cluster_balance/cluster_load_stat/location_default/HDD';
```

```
+-----+-----+-----+-----+-----+-----+-----+
| BeId | Cluster | Available | UsedCapacity | Capacity | UsedPercent | ReplicaNum |
| CapCoeff | ReplCoeff | Score | Class | | | |
+-----+-----+-----+-----+-----+-----+-----+
10003	default_cluster	true	3477875259079	19377459077121	17.948	493477
0.5	0.5	0.9284678149967587	MID			
10002	default_cluster	true	3607326225443	19377459077121	18.616	496928
0.5	0.5	0.948660871419998	MID			
10005	default_cluster	true	3523518578241	19377459077121	18.184	545331
0.5	0.5	0.9843539990641831	MID			
10001	default_cluster	true	3535547090016	19377459077121	18.246	558067
0.5	0.5	0.9981869446537612	MID			
10006	default_cluster	true	3636050364835	19377459077121	18.764	547543
0.5	0.5	1.0011489897614072	MID			
10004	default_cluster	true	3506558163744	15501967261697	22.620	468957
0.5	0.5	1.0228319835582569	MID			
10007	default_cluster	true	4036460478905	19377459077121	20.831	551645
0.5	0.5	1.057279369420761	MID			
10000	default_cluster	true	4369719923760	19377459077121	22.551	547175
0.5	0.5	1.0964036415787461	MID			
+-----+-----+-----+-----+-----+-----+-----+
```

其中一些列的含义如下：

- Available：为 true 表示 BE 心跳正常，且没有处于下线中
- UsedCapacity：字节，BE 上已使用的磁盘空间大小

- Capacity: 字节, BE 上总的磁盘空间大小
- UsedPercent: 百分比, BE 上的磁盘空间使用率
- ReplicaNum: BE 上副本数量
- CapCoeff/ReplCoeff: 磁盘空间和副本数的权重系数
- Score: 负载分数。分数越高, 负载越重
- Class: 根据负载情况分类, LOW/MID/HIGH。均衡调度会将高负载节点上的副本迁往低负载节点

用户可以进一步查看某个 BE 上各个路径的使用率, 比如 ID 为 10001 这个 BE:

```
SHOW PROC '/cluster_balance/cluster_load_stat/location_default/HDD/10001';
```

| RootPath         | DataUsedCapacity | AvailCapacity | TotalCapacity | UsedPct | State  | PathHash             |
|------------------|------------------|---------------|---------------|---------|--------|----------------------|
| /home/disk4/palo | 498.757 GB       | 3.033 TB      | 3.525 TB      | 13.94 % | ONLINE | 4883406271918338267  |
| /home/disk3/palo | 704.200 GB       | 2.832 TB      | 3.525 TB      | 19.65 % | ONLINE | -5467083960906519443 |
| /home/disk1/palo | 512.833 GB       | 3.007 TB      | 3.525 TB      | 14.69 % | ONLINE | -7733211489989964053 |
| /home/disk2/palo | 881.955 GB       | 2.656 TB      | 3.525 TB      | 24.65 % | ONLINE | 4870995507205544622  |
| /home/disk5/palo | 694.992 GB       | 2.842 TB      | 3.525 TB      | 19.36 % | ONLINE | 1916696897889786739  |

这里显示了指定 BE 上, 各个数据路径的磁盘使用率情况。

## 2. 调度资源

用户可以通过以下命令, 查看当前各个节点的 slot 使用情况:

```
SHOW PROC '/cluster_balance/working_slots';
```

| BeId  | PathHash             | AvailSlots | TotalSlots | BalanceSlot | AvgRate              |
|-------|----------------------|------------|------------|-------------|----------------------|
| 10000 | 8110346074333016794  | 2          | 2          | 2           | 2.459007474009069E7  |
| 10000 | -5617618290584731137 | 2          | 2          | 2           | 2.4730105014001578E7 |
| 10001 | 4883406271918338267  | 2          | 2          | 2           | 1.6711402709780257E7 |
| 10001 | -5467083960906519443 | 2          | 2          | 2           | 2.7540126380326536E7 |
| 10002 | 9137404661108133814  | 2          | 2          | 2           | 2.417217089806745E7  |
| 10002 | 1885826196444191611  | 2          | 2          | 2           | 1.6327378456676323E7 |

这里以数据路径为粒度, 展示了当前 slot 的使用情况。其中 AvgRate 为历史统计的该路径上 clone 任务的拷贝速率, 单位是字节/秒。

## 3. 优先修复查看

以下命令，可以查看通过 ADMIN REPAIR TABLE 命令设置的优先修复的表或分区。

```
SHOW PROC '/cluster_balance/priority_repair';
```

其中 RemainingTimeMs 表示，这些优先修复的内容，将在这个时间后，被自动移出优先修复队列。以防止优先修复一直失败导致资源被占用。

## 调度器统计状态查看

我们收集了 TabletChecker 和 TabletScheduler 在运行过程中的一些统计信息，可以通过以下命令查看：

```
SHOW PROC '/cluster_balance/sched_stat';
```

| Item                                              | Value       |
|---------------------------------------------------|-------------|
| num of tablet check round                         | 12041       |
| cost of tablet check(ms)                          | 7162342     |
| num of tablet checked in tablet checker           | 18793506362 |
| num of unhealthy tablet checked in tablet checker | 7043900     |
| num of tablet being added to tablet scheduler     | 1153        |
| num of tablet schedule round                      | 49538       |
| cost of tablet schedule(ms)                       | 49822       |
| num of tablet being scheduled                     | 4356200     |
| num of tablet being scheduled succeeded           | 320         |
| num of tablet being scheduled failed              | 4355594     |
| num of tablet being scheduled discard             | 286         |
| num of tablet priority upgraded                   | 0           |
| num of tablet priority downgraded                 | 1096        |
| num of clone task                                 | 230         |
| num of clone task succeeded                       | 228         |
| num of clone task failed                          | 2           |
| num of clone task timeout                         | 2           |
| num of replica missing error                      | 4354857     |
| num of replica version missing error              | 967         |
| num of replica relocating                         | 0           |
| num of replica redundant error                    | 90          |
| num of replica missing in cluster error           | 0           |
| num of balance scheduled                          | 0           |

各行含义如下：

- num of tablet check round：Tablet Checker 检查次数
- cost of tablet check(ms)：Tablet Checker 检查总耗时
- num of tablet checked in tablet checker：Tablet Checker 检查过的 tablet 数量
- num of unhealthy tablet checked in tablet checker：Tablet Checker 检查过的不健康的 tablet 数量
- num of tablet being added to tablet scheduler：被提交到 Tablet Scheduler 中的 tablet 数量
- num of tablet schedule round：Tablet Scheduler 运行次数
- cost of tablet schedule(ms)：Tablet Scheduler 运行总耗时
- num of tablet being scheduled：被调度的 Tablet 总数量

- num of tablet being scheduled succeeded: 被成功调度的 Tablet 总数量
- num of tablet being scheduled failed: 调度失败的 Tablet 总数量
- num of tablet being scheduled discard: 调度失败且被抛弃的 Tablet 总数量
- num of tablet priority upgraded: 优先级上调次数
- num of tablet priority downgraded: 优先级下调次数
- num of clone task: 生成的 clone 任务数量
- num of clone task succeeded: clone 任务成功的数量
- num of clone task failed: clone 任务失败的数量
- num of clone task timeout: clone 任务超时的数量
- num of replica missing error: 检查的状态为副本缺失的 tablet 的数量
- num of replica version missing error: 检查的状态为版本缺失的 tablet 的数量 (该统计值包括了 num of replica relocating 和 num of replica missing in cluster error)
- num of replica relocating: 检查的状态为 replica relocating 的 tablet 的数量
- num of replica redundant error: 检查的状态为副本冗余的 tablet 的数量
- num of replica missing in cluster error: 检查的状态为不在对应 cluster 的 tablet 的数量
- num of balance scheduled: 均衡调度的次数

注：以上状态都只是历史累加值。我们也在 FE 的日志中，定期打印了这些统计信息，其中括号内的数值表示自上次统计信息打印依赖，各个统计值的变化数量。

::

## 相关配置说明

### 可调整参数

以下可调整参数均为 fe.conf 中可配置参数。

- use\_new\_tablet\_scheduler
  - 说明：是否启用新的副本调度方式。新的副本调度方式即本文档介绍的副本调度方式。
  - 默认值：true
  - 重要性：高
- tablet\_repair\_delay\_factor\_second
  - 说明：对于不同的调度优先级，我们会延迟不同的时间后开始修复。以防止因为例行重启、升级等过程中，产生大量不必要的副本修复任务。此参数为一个基准系数。对于 HIGH 优先



级，延迟为 基准系数 \* 1；对于 NORMAL 优先级，延迟为 基准系数 \* 2；对于 LOW 优先级，延迟为 基准系数 \* 3。即优先级越低，延迟等待时间越长。如果用户想尽快修复副本，可以适当降低该参数。

- 默认值：60 秒
- 重要性：高
- `schedule_slot_num_per_path`
  - 说明：默认分配给每块磁盘用于副本修复的 slot 数目。该数目表示一块磁盘能同时运行的副本修复任务数。如果想以更快的速度修复副本，可以适当调高这个参数。单数值越高，可能对 IO 影响越大。
  - 默认值：2
  - 重要性：高
- `balance_load_score_threshold`
  - 说明：集群均衡的阈值。默认为 0.1，即 10%。当一个 BE 节点的 load score，不高于或不低于平均 load score 的 10% 时，我们认为这个节点是均衡的。如果想让集群负载更加平均，可以适当调低这个参数。
  - 默认值：0.1
  - 重要性：中
- `storage_high_watermark_usage_percent` 和 `storage_min_left_capacity_bytes`
  - 说明：这两个参数，分别表示一个磁盘的最大空间使用率上限，以及最小的空间剩余下限。当一块磁盘的空间使用率大于上限，或者剩余空间小于下限时，该磁盘将不再作为均衡调度的目的地址。
  - 默认值：0.85 和 2097152000 (2GB)
  - 重要性：中
- `disable_balance`
  - 说明：控制是否关闭均衡功能。当副本处于均衡过程中时，有些功能，如 ALTER TABLE 等将会被禁止。而均衡可能持续很长时间。因此，如果用户希望尽快进行被禁止的操作。可以将该参数设为 true，以关闭均衡调度。
  - 默认值：false
  - 重要性：中

以下可调整参数均为 `be.conf` 中可配置参数。

- `clone_worker_count`
  - 说明：影响副本均衡的速度。在磁盘压力不大的情况下，可以通过调整该参数来加快副本均衡。

- 默认值：3
- 重要性：中

## 不可调整参数

以下参数暂不支持修改，仅作参考。

- TabletChecker 调度间隔

TabletChecker 每 20 秒进行一次检查调度。

- TabletScheduler 调度间隔

TabletScheduler 每 5 秒进行一次调度

- TabletScheduler 每批次调度个数

TabletScheduler 每次调度最多 50 个 tablet。

- TabletScheduler 最大等待调度和运行中任务数

最大等待调度任务数和运行中任务数为 2000。当超过 2000 后，TabletChecker 将不再产生新的调度任务给 TabletScheduler。

- TabletScheduler 最大均衡任务数

最大均衡任务数为 500。当超过 500 后，将不再产生新的均衡任务。

- 每块磁盘用于均衡任务的 slot 数目

每块磁盘用于均衡任务的 slot 数目为 2。这个 slot 独立于用于副本修复的 slot。

- 集群均衡情况更新间隔

TabletScheduler 每隔 20 秒会重新计算一次集群的 load score。

- Clone 任务的最小和最大超时时间

一个 clone 任务超时时间范围是 3min ~ 2hour。具体超时时间通过 tablet 的大小计算。计算公式为 (tablet size) / (5MB/s)。当一个 clone 任务运行失败 3 次后，该任务将终止。

- 动态优先级调整策略

优先级最小调整间隔为 5min。当一个 tablet 调度失败 5 次后，会调低优先级。当一个 tablet 30min 未被调度时，会调高优先级。

## 相关问题

- 在某些情况下，默认的副本修复和均衡策略可能会导致网络被打满（多发生在千兆网卡，且每台 BE 的磁盘数量较多的情况下）。此时需要调整一些参数来减少同时进行的均衡和修复任务数。
- 目前针对 Colocate Table 的副本的均衡策略无法保证同一个 Tablet 的副本不会分布在同一个 host 的 BE 上。但 Colocate Table 的副本的修复策略会检测到这种分布错误并校正。但可能会出现，校正

后，均衡策略再次认为副本不均衡而重新均衡。从而导致在两种状态间不停交替，无法使 Colocate Group 达成稳定。针对这种情况，我们建议在使用 Colocate 属性时，尽量保证集群是同构的，以减小副本分布在同一个 host 上的概率。

## 最佳实践

### 控制并管理集群的副本修复和均衡进度

在大多数情况下，通过默认的参数配置，Doris 都可以自动的进行副本修复和集群均衡。但是某些情况下，我们需要通过人工介入调整参数，来达到一些特殊的目的。如优先修复某个表或分区、禁止集群均衡以降低集群负载、优先修复非 colocation 的表数据等等。

本小节主要介绍如何通过修改参数，来控制并管理集群的副本修复和均衡进度。

#### 1. 删除损坏副本

某些情况下，Doris 可能无法自动检测某些损坏的副本，从而导致查询或导入在损坏的副本上频繁报错。此时我们需要手动删除已损坏的副本。该方法可以适用于：删除版本数过高导致 -235 错误的副本、删除文件已损坏的副本等等。

首先，找到副本对应的 tablet id，假设为 10001。通过 `show tablet 10001;` 并执行其中的 `show proc` 语句可以查看对应的 tablet 的各个副本详情。

假设需要删除的副本的 backend id 是 20001。则执行以下语句将副本标记为 bad：

```
ADMIN SET REPLICA STATUS PROPERTIES("tablet_id" = "10001", "backend_id" = "20001", "status" = "bad");
```

此时，再次通过 `show proc` 语句可以看到对应的副本的 `IsBad` 列值为 `true`。

被标记为 bad 的副本不会再参与导入和查询。同时副本修复逻辑会自动补充一个新的副本。

#### 2. 优先修复某个表或分区

`help admin repair table;` 查看帮助。该命令会尝试优先修复指定表或分区的 tablet。

#### 3. 停止均衡任务

均衡任务会占用一定的网络带宽和 IO 资源。如果希望停止新的均衡任务的产生，可以通过以下命令：

```
ADMIN SET FRONTEND CONFIG ("disable_balance" = "true");
```

#### 4. 停止所有副本调度任务

副本调度任务包括均衡和修复任务。这些任务都会占用一定的网络带宽和 IO 资源。可以通过以下命令停止所有副本调度任务（不包括已经在运行的，包括 colocation 表和普通表）：

```
ADMIN SET FRONTEND CONFIG ("disable_tablet_scheduler" = "true");
```

#### 5. 停止所有 colocation 表的副本调度任务。

colocation 表的副本调度和普通表是分开独立运行的。某些情况下，用户可能希望先停止对 colocation 表的均衡和修复工作，而将集群资源用于普通表的修复，则可以通过以下命令：

```
ADMIN SET FRONTEND CONFIG ("disable_colocate_balance" = "true");
```

## 6. 使用更保守的策略修复副本

Doris 在检测到副本缺失、BE 宕机等情况下，会自动修复副本。但为了减少一些抖动导致的错误（如 BE 短暂宕机），Doris 会延迟触发这些任务。

- tablet\_repair\_delay\_factor\_second 参数。默认 60 秒。根据修复任务优先级的不同，会推迟 60 秒、120 秒、180 秒后开始触发修复任务。可以通过以下命令延长这个时间，这样可以容忍更长的异常时间，以避免触发不必要的修复任务：

```
ADMIN SET FRONTEND CONFIG ("tablet_repair_delay_factor_second" = "120");
```

## 7. 使用更保守的策略触发 colocation group 的重分布

colocation group 的重分布可能伴随着大量的 tablet 迁移。

colocate\_group\_relocate\_delay\_second 用于控制重分布的触发延迟。默认 1800 秒。如果某台 BE 节点可能长时间下线，可以尝试调大这个参数，以避免不必要的重分布：

```
ADMIN SET FRONTEND CONFIG ("colocate_group_relocate_delay_second" = "3600");
```

## 8. 更快速的副本均衡

Doris 的副本均衡逻辑会先增加一个正常副本，然后在删除老的副本，已达到副本迁移的目的。而在删除老副本时，Doris 会等待这个副本上已经开始执行的导入任务完成，以避免均衡任务影响导入任务。但这样会降低均衡逻辑的执行速度。此时可以通过修改以下参数，让 Doris 忽略这个等待，直接删除老副本：

```
ADMIN SET FRONTEND CONFIG ("enable_force_drop_redundant_replica" = "true");
```

这种操作可能会导致均衡期间部分导入任务失败（需要重试），但会显著加速均衡速度。

总体来讲，当我们需要将集群快速恢复到正常状态时，可以考虑按照以下思路处理：

1. 找到导致高优任务报错的 tablet，将有问题的副本置为 bad。
2. 通过 admin repair 语句高优修复某些表。
3. 停止副本均衡逻辑以避免占用集群资源，等集群恢复后，再开启即可。
4. 使用更保守的策略触发修复任务，以应对 BE 频繁宕机导致的雪崩效应。
5. 按需关闭 colocation 表的调度任务，集中集群资源修复其他高优数据。

# Tablet 元数据管理工具

---

## 背景

在最新版本的代码中，我们在 BE 端引入了 RocksDB，用于存储 tablet 的元信息，以解决之前通过 header 文件的方式存储元信息，带来的各种功能和性能方面的问题。当前每一个数据目录（root\_path），都会有一个对应的 RocksDB 实例，其中以 key-value 的方式，存放对应 root\_path 上的所有 tablet 的元数据。

为了方便进行这些元数据的维护，我们提供了在线的 http 接口方式和离线的 meta\_tool 工具以完成相关的管理操作。

其中 http 接口仅用于在线的查看 tablet 的元数据，可以在 BE 进程运行的状态下使用。

而 meta\_tool 工具则仅用于离线的各类元数据管理操作，必须先停止 BE 进程后，才可使用。

meta\_tool 工具存放在 BE 的 lib/ 目录下。

## 操作

### 查看 Tablet Meta

查看 Tablet Meta 信息可以分为在线方法和离线方法

#### 在线

访问 BE 的 http 接口，获取对应的 Tablet Meta 信息：

api：

`http://{host}:{port}/api/meta/header/{tablet_id}`

- host: BE 的 hostname

- port: BE 的 http 端口
- tablet\_id: tablet id

举例：

`http://be_host:8040/api/meta/header/14156`

最终查询成功的话，会将 Tablet Meta 以 json 形式返回。

#### 离线

基于 meta\_tool 工具获取某个盘上的 Tablet Meta。

命令：

```
./lib/meta_tool --root_path=/path/to/root_path --operation=get_meta --tablet_id=xxx --schema_hash=xxx
```

**root\_path:** 在 **be.conf** 中配置的对应的 **root\_path** 路径。

结果也是按照 json 的格式展现 Tablet Meta。

## 加载 header

加载 header 的功能是为了完成实现 tablet 人工迁移而提供的。该功能是基于 json 格式的 Tablet Meta 实现的，所以如果涉及 shard 字段、version 信息的更改，可以直接在 Tablet Meta 的 json 内容中更改。然后使用以下的命令进行加载。

命令：

```
./lib/meta_tool --operation=load_meta --root_path=/path/to/root_path --json_meta_path=path
```

## 删除 header

为了实现从某个 be 的某个盘中删除某个 tablet 元数据的功能。可以单独删除一个 tablet 的元数据，或者批量删除一组 tablet 的元数据。

删除单个 tablet 元数据：

```
./lib/meta_tool --operation=delete_meta --root_path=/path/to/root_path --tablet_id=xxx --schema_hash=xxx
```

删除一组 tablet 元数据：

```
./lib/meta_tool --operation=batch_delete_meta --tablet_file=/path/to/tablet_file.txt
```

其中 **tablet\_file.txt** 中的每一行表示一个 tablet 的信息。格式为：

**root\_path,tablet\_id,schema\_hash**

每一行各个列用逗号分隔。

**tablet\_file** 文件示例：

```
/output/be/data/,14217,352781111
/output/be/data/,14219,352781111
/output/be/data/,14223,352781111
/output/be/data/,14227,352781111
/output/be/data/,14233,352781111
/output/be/data/,14239,352781111
```

批量删除会跳过 **tablet\_file** 中 tablet 信息格式不正确的行。并在执行完成后，显示成功删除的数量和错误数量。

## 展示 pb 格式的 TabletMeta

这个命令是为了查看旧的基于文件的管理的 PB 格式的 Tablet Meta，以 json 的格式展示 Tablet Meta。

命令：

```
./lib/meta_tool --operation=show_meta --root_path=/path/to/root_path --pb_header_path=path
```

## 展示 pb 格式的 Segment meta

这个命令是为了查看 SegmentV2 的 segment meta 信息，以 json 形式展示出来

命令：

```
``shell ./meta_tool --operation=show_segment_footer --file=/path/to/segment/file
```

# Tablet 恢复工具

## 从 BE 回收站中恢复数据

用户在使用 Doris 的过程中，可能会发生因为一些误操作或者线上 bug，导致一些有效的 tablet 被删除（包括元数据和数据）。为了防止在这些异常情况出现数据丢失，Doris 提供了回收站机制，来保护用户数据。用户删除的 tablet 数据不会被直接删除，会被放在回收站中存储一段时间，在一段时间之后会有定时清理机制将过期的数据删除。回收站中的数据包括：tablet 的 data 文件 (.dat)，tablet 的索引文件 (.idx) 和 tablet 的元数据文件 (.hdr)。数据将会存放在如下格式的路径：

```
/root_path/trash/time_label/tablet_id/schema_hash/
```

- root\_path：对应 BE 节点的某个数据根目录。
- trash：回收站的目录。
- time\_label：时间标签，为了回收站中数据目录的唯一性，同时记录数据时间，使用时间标签作为子目录。

当用户发现线上的数据被误删除，需要从回收站中恢复被删除的 tablet，需要用到这个 tablet 数据恢复功能。

BE 提供 http 接口和 restore\_tablet\_tool.sh 脚本实现这个功能，支持单 tablet 操作（single mode）和批量操作模式（batch mode）。

- 在 single mode 下，支持单个 tablet 的数据恢复。
- 在 batch mode 下，支持批量 tablet 的数据恢复。

## 操作

### single mode

#### 1. http 请求方式

BE 中提供单个 tablet 数据恢复的 http 接口，接口如下：

```
curl -X POST "http://be_host:be_webserver_port/api/restore_tablet?tablet_id=11111&schema_hash=12345"
```

成功的结果如下：

```
{"status": "Success", "msg": "OK"}
```

失败的话，会返回相应的失败原因，一种可能的结果如下：

```
{"status": "Failed", "msg": "create link path failed"}
```

#### 2. 脚本方式



restore\_tablet\_tool.sh 可用来实现单 tablet 数据恢复的功能。

```
sh tools/restore_tablet_tool.sh -b "http://127.0.0.1:8040" -t 12345 -s 11111
sh tools/restore_tablet_tool.sh --backend "http://127.0.0.1:8040" --tablet_id 12345 --schema_hash 11111
```

## batch mode

批量恢复模式用于实现恢复多个 tablet 数据的功能。

使用的时候需要预先将恢复的 tablet id 和 schema hash 按照逗号分隔的格式放在一个文件中，一个 tablet 一行。

格式如下：

```
12345,11111
12346,11111
12347,11111
```

然后如下的命令进行恢复 (假设文件名为：tablets.txt)：

```
sh restore_tablet_tool.sh -b "http://127.0.0.1:8040" -f tablets.txt
sh restore_tablet_tool.sh --backend "http://127.0.0.1:8040" --file tablets.txt
```

## 修复缺失或损坏的 Tablet

在某些极特殊情况下，如代码 BUG、或人为误操作等，可能导致部分分片的全部副本都丢失。这种情况下，数据已经实质性的丢失。但是在某些场景下，业务依然希望能够在即使有数据丢失的情况下，保证查询正常不报错，降低用户层的感知程度。此时，我们可以通过使用空白 Tablet 填充丢失副本的功能，来保证查询能够正常执行。

**注：该操作仅用于规避查询因无法找到可查询副本导致报错的问题，无法恢复已经实质性丢失的数据**

### 1. 查看 Master FE 日志 fe.log

如果出现数据丢失的情况，则日志中会有类似如下日志：

```
backend [10001] invalid situation. tablet[20000] has few replica[1], replica num setting is [3]
```

这个日志表示，Tablet 20000 的所有副本已损坏或丢失。

### 2. 使用空白副本填补缺失副本

当确认数据已经无法恢复后，可以通过执行以下命令，生成空白副本。

```
ADMIN SET FRONTEND CONFIG ("recover_with_empty_tablet" = "true");
```

- 注：可以先通过 ADMIN SHOW FRONTEND CONFIG; 命令查看当前版本是否支持该参数。

### 3. 设置完成几分钟后，应该会在 Master FE 日志 fe.log 中看到如下日志：

```
tablet 20000 has only one replica 20001 on backend 10001 and it is lost. create an empty replica to recover it.
```

该日志表示系统已经创建了一个空白 Tablet 用于填补缺失副本。

4. 通过查询来判断是否已经修复成功。
5. 全部修复成功后，通过以下命令关闭 `recover_with_empty_tablet` 参数：

```
ADMIN SET FRONTEND CONFIG ("recover_with_empty_tablet" = "false");
```

# Tablet 本地调试

Doris 线上运行过程中，因为各种原因，可能出现各种各样的 bug。例如：副本不一致，数据存在版本 diff 等。

这时候需要将线上的 tablet 的副本数据拷贝到本地环境进行复现，然后进行问题定位。

## 1. 获取有问题的 Tablet 的信息

可以通过 BE 日志确认 tablet id，然后通过以下命令获取信息（假设 tablet id 为 10020）。

获取 tablet 所在的 DbId/TableId/PartitionId 等信息。

```
mysql> show tablet 10020\G
***** 1. row *****
 DbName: default_cluster:db1
 TableName: tbl1
 PartitionName: tbl1
 IndexName: tbl1
 DbId: 10004
 TableId: 10016
 PartitionId: 10015
 IndexId: 10017
 IsSync: true
 Order: 1
 DetailCmd: SHOW PROC '/dbs/10004/10016/partitions/10015/10017/10020';
```

执行上一步中的 DetailCmd 获取 BackendId/SchemaHash 等信息。

```
mysql> SHOW PROC '/dbs/10004/10016/partitions/10015/10017/10020'\G
***** 1. row *****
 ReplicaId: 10021
 BackendId: 10003
 Version: 3
 LstSuccessVersion: 3
 LstFailedVersion: -1
 LstFailedTime: NULL
 SchemaHash: 785778507
 LocalDataSize: 780
 RemoteDataSize: 0
 RowCount: 2
 State: NORMAL
 IsBad: false
 VersionCount: 3
 PathHash: 7390150550643804973
 MetaUrl: http://192.168.10.1:8040/api/meta/header/10020
 CompactionStatus: http://192.168.10.1:8040/api/compaction/show?tablet_id=10020
```

创建 tablet 快照并获取建表语句

```
mysql> admin copy tablet 10020 properties("backend_id" = "10003", "version" = "2")\G
***** 1. row *****
 TabletId: 10020
 BackendId: 10003
 Ip: 192.168.10.1
```

```

Path: /path/to/be/storage/snapshot/20220830101353.2.3600
ExpirationMinutes: 60
CreateTableStmt: CREATE TABLE `tbl1` (
 `k1` int(11) NULL,
 `k2` int(11) NULL
) ENGINE=OLAP
DUPLICATE KEY(`k1`, `k2`)
DISTRIBUTED BY HASH(k1) BUCKETS 1
PROPERTIES (
 "replication_num" = "1",
 "version_info" = "2"
);

```

admin copy tablet 命令可以为指定的 tablet 生成对应副本和版本的快照文件。快照文件存储在 Ip 字段所示节点的 Path 目录下。

该目录下会有一个 tablet id 命名的目录，将这个目录整体打包后备用。（注意，该目录最多保留 60 分钟，之后会自动删除）。

```

cd /path/to/be/storage/snapshot/20220830101353.2.3600
tar czf 10020.tar.gz 10020/

```

该命令还会同时生成这个 tablet 对应的建表语句。注意，这个建表语句并不是原始的建表语句，他的分桶数和副本数都是 1，并且指定了 versionInfo 字段。该建表语句是用于之后在本地加载 tablet 时使用的。

至此，我们已经获取到所有必要的信息，清单如下：

1. 打包好的 tablet 数据，如 10020.tar.gz。
2. 建表语句。

## 2. 本地加载 Tablet

### 1. 搭建本地调试环境

在本地部署一个单节点的 Doris 集群（1FE、1BE），部署版本和线上集群保持一致。如线上部署的版本是 DORIS-1.1.1，本地环境也同样部署 DORIS-1.1.1 的版本。

### 2. 建表

使用上一步中得到的建表语句，在本地环境中创建一张表。

### 3. 获取新建的表的 tablet 的信息

因为新建表的分桶数和副本数都为 1，所以只会有一副本的 tablet：

```

mysql> show tablets from tbl1\G
***** 1. row *****
 TabletId: 10017
 ReplicaId: 10018
 BackendId: 10003
 SchemaHash: 44622287
 Version: 1
 LstSuccessVersion: 1
 LstFailedVersion: -1
 LstFailedTime: NULL

```

```
LocalDataSize: 0
RemoteDataSize: 0
RowCount: 0
State: NORMAL
LstConsistencyCheckTime: NULL
CheckVersion: -1
VersionCount: -1
PathHash: 7390150550643804973
MetaUrl: http://192.168.10.1:8040/api/meta/header/10017
CompactionStatus: http://192.168.10.1:8040/api/compaction/show?tablet_id=10017
```

```
mysql> show tablet 10017\G
***** 1. row *****
 DbName: default_cluster:db1
 TableName: tbl1
 PartitionName: tbl1
 IndexName: tbl1
 DbId: 10004
 TableId: 10015
 PartitionId: 10014
 IndexId: 10016
 IsSync: true
 Order: 0
 DetailCmd: SHOW PROC '/dbs/10004/10015/partitions/10014/10016/10017';
```

这里我们要记录如下信息：

- TableId
- PartitionId
- TabletId
- SchemaHash

同时，我们还需要到调试环境 BE 节点的数据目录下，确认新的 tablet 所在的 shard id：

```
cd /path/to/storage/data/*/10017 && pwd
```

这个命令会进入 10017 这个 tablet 所在目录并展示路径。这里我们会看到类似如下的路径：

```
/path/to/storage/data/0/10017
```

其中 0 既是 shard id。

#### 4. 修改 Tablet 数据

解压第一步中获取到的 tablet 数据包。编辑器打开其中的 10017.hdr.json 文件，并修改以下字段为上一步中获取到的信息：

```
"table_id":10015
"partition_id":10014
"tablet_id":10017
"schema_hash":44622287
"shard_id":0
```

## 5. 加载新 tablet

首先，停止调试环境的 BE 进程（./bin/stop\_be.sh）。然后将 10017.hdr.json 文件同级目录所在的所有 .dat 文件，拷贝到 /path/to/storage/data/0/10017/44622287 目录下。这个目录既是在第 3 步中，我们获取到的调试环境 tablet 所在目录。10017/44622287 分别是 tablet id 和 schema hash。

通过 meta\_tool 工具删除原来的 tablet meta。该工具位于 be/lib 目录下。

```
./lib/meta_tool --root_path=/path/to/storage --operation=delete_meta --tablet_id=10017 --
schema_hash=44622287
```

其中 /path/to/storage 为 BE 的数据根目录。如删除成功，会出现 delete successfully 日志。

通过 meta\_tool 工具加载新的 tablet meta。

```
./lib/meta_tool --root_path=/path/to/storage --operation=load_meta --
json_meta_path=/path/to/10017.hdr.json
```

如加载成功，会出现 load successfully 日志。

## 6. 验证

重新启动调试环境的 BE 进程（./bin/start\_be.sh）。对表进行查询，如果正确，则可以查询出加载的 tablet 的数据，或复现线上问题。

# 元数据运维

## 注意

除非绝对必要，否则请避免使用 `metadata_failure_recovery`，使用可能会导致元数据截断、元数据丢失以及元数据 Split-brains 的发生。强烈建议谨慎使用此功能，以防止由于不规范的操作程序导致数据不可恢复的损坏。

本文档主要介绍在实际生产环境中，如何对 Doris 的元数据进行管理。包括 FE 节点建议的部署方式、一些常用的操作方法、以及常见错误的解决方法。

在阅读本文当前，请先阅读 [Doris 元数据设计文档](#) 了解 Doris 元数据的工作原理。

## 重要提示

- 当前元数据的设计是无法向后兼容的。即如果新版本有新增的元数据结构变动（可以查看 FE 代码中的 `FeMetaVersion.java` 文件中是否有新增的 `VERSION`），那么在升级到新版本后，通常是无法再回滚到旧版本的。所以，在升级 FE 之前，请务必按照 [升级文档](#) 中的操作，测试元数据兼容性。

## 元数据目录结构

我们假设在 `fe.conf` 中指定的 `meta_dir` 的路径为 `/path/to/doris-meta`。那么一个正常运行中的 Doris 集群，元数据的目录结构应该如下：

```
/path/to/doris-meta/
|-- bdb/
| |-- 00000000.jdb
| |-- je.config.csv
| |-- je.info.0
| |-- je.info.0.lck
| |-- je.lck
| |-- je.stat.csv
|-- image/
| |-- ROLE
| |-- VERSION
|-- image.xxxx
```

### 1. bdb 目录

我们将 [bdbje](#) 作为一个分布式的 kv 系统，存放元数据的 journal。这个 bdb 目录相当于 bdbje 的“数据目录”。

其中 `.jdb` 后缀的是 bdbje 的数据文件。这些数据文件会随着元数据 journal 的不断增多而越来越多。当 Doris 定期做完 `image` 后，旧的日志就会被删除。所以正常情况下，这些数据文件的总大小从几 MB 到几 GB 不等（取决于使用 Doris 的方式，如导入频率等）。当数据文件的总大小大于 10GB，则可能需要怀疑是否是因为 `image` 没有成功，或者分发 `image` 失败导致的历史 journal 一直无法删除。

je.info.0 是 bdbje 的运行日志。这个日志中的时间是 UTC+0 时区的。我们可能在后面的某个版本中修复这个问题。通过这个日志，也可以查看一些 bdbje 的运行情况。

## 2. image 目录

image 目录用于存放 Doris 定期生成的元数据镜像文件。通常情况下，你会看到有一个 image.xxxxx 的镜像文件。其中 xxxxx 是一个数字。这个数字表示该镜像包含 xxxxx 号之前的所有元数据 journal。而这个文件的生成时间（通过 `ls -al` 查看即可）通常就是镜像的生成时间。

你也可能会看到一个 image.ckpt 文件。这是一个正在生成的元数据镜像。通过 `du -sh` 命令应该可以看到这个文件大小在不断变大，说明镜像内容正在写入这个文件。当镜像写完后，会自动重名为一个新的 image.xxxxx 并替换旧的 image 文件。

只有角色为 Master 的 FE 才会主动定期生成 image 文件。每次生成完后，都会推送给其他非 Master 角色的 FE。当确认其他所有 FE 都收到这个 image 后，Master FE 会删除 bdbje 中旧的元数据 journal。所以，如果 image 生成失败，或者 image 推送给其他 FE 失败时，都会导致 bdbje 中的数据不断累积。

ROLE 文件记录了 FE 的类型（FOLLOWER 或 OBSERVER），是一个文本文件。

VERSION 文件记录了这个 Doris 集群的 cluster id，以及用于各个节点之间访问认证的 token，也是一个文本文件。

ROLE 文件和 VERSION 文件只可能同时存在，或同时不存在（如第一次启动时）。

## 基本操作

### 启动单节点 FE

单节点 FE 是最基本的一种部署方式。一个完整的 Doris 集群，至少需要一个 FE 节点。当只有一个 FE 节点时，这个节点的类型为 Follower，角色为 Master。

#### 1. 第一次启动

1. 假设在 fe.conf 中指定的 meta\_dir 的路径为 /path/to/doris-meta。
2. 确保 /path/to/doris-meta 已存在，权限正确，且目录为空。
3. 直接通过 `sh bin/start_fe.sh` 即可启动。
4. 启动后，你应该可以在 fe.log 中看到如下日志：

- Palo FE starting...
- image does not exist: /path/to/doris-meta/image/image.0
- transfer from INIT to UNKNOWN
- transfer from UNKNOWN to MASTER
- the very first time to open bdb, dbname is 1
- start fencing, epoch number is 1
- finish replay in xxx msec
- QE service start
- thrift server started

以上日志不一定严格按照这个顺序，但基本类似。



5. 单节点 FE 的第一次启动通常不会遇到问题。如果你没有看到以上日志，一般来说是没有仔细按照文档步骤操作，请仔细阅读相关 wiki。

## 2. 重启

1. 直接使用 `sh bin/start_fe.sh` 可以重新启动已经停止的 FE 节点。

2. 重启后，你应该可以在 `fe.log` 中看到如下日志：

- Palo FE starting...
- finished to get cluster id: xxxx, role: FOLLOWER and node name: xxxx
- 如果重启前还没有 image 产生，则会看到：
  - image does not exist: /path/to/doris-meta/image/image.0
- 如果重启前有 image 产生，则会看到：
  - start load image from /path/to/doris-meta/image/image.xxx. is ckpt: false
  - finished load image in xxx ms
- transfer from INIT to UNKNOWN
- replayed journal id is xxxx, replay to journal id is yyyy
- transfer from UNKNOWN to MASTER
- finish replay in xxx msec
- master finish replay journal, can write now.
- begin to generate new image: image.xxxx
- start save image to /path/to/doris-meta/image/image.ckpt. is ckpt: true
- finished save image /path/to/doris-meta/image/image.ckpt in xxx ms. checksum is xxxx
- push image.xxx to other nodes. totally xx nodes, push succeeded xx nodes
- QE service start
- thrift server started

以上日志不一定严格按照这个顺序，但基本类似。

## 3. 常见问题

对于单节点 FE 的部署，启停通常不会遇到什么问题。如果有问题，请先参照相关 wiki，仔细核对你的操作步骤。

## 添加 FE

添加 FE 流程在 [弹性扩缩容](#) 有详细介绍，不再赘述。这里主要说明一些注意事项，以及常见问题。

## 1. 注意事项

- 在添加新的 FE 之前，一定先确保当前的 Master FE 运行正常（连接是否正常，JVM 是否正常，image 生成是否正常，bdbje 数据目录是否过大等等）
- 第一次启动新的 FE，一定确保添加了 `--helper` 参数指向 Master FE。再次启动时可不用添加 `--helper`。（如果指定了 `--helper`，FE 会直接询问 helper 节点自己的角色，如果没有指定，FE 会尝试从 `doris-meta/image/` 目录下的 `ROLE` 和 `VERSION` 文件中获取信息）。
- 第一次启动新的 FE，一定确保这个 FE 的 `meta_dir` 已经创建、权限正确且为空。
- 启动新的 FE，和执行 `ALTER SYSTEM ADD FOLLOWER/OBSERVER` 语句在元数据添加 FE，这两个操作的顺序没有先后要求。如果先启动了新的 FE，而没有执行语句，则新的 FE 日志中会一直滚动 `current node is not added to the group. please add it first.` 字样。当执行语句后，则会进入正常流程。
- 请确保前一个 FE 添加成功后，再添加下一个 FE。
- 建议直接连接到 MASTER FE 执行 `ALTER SYSTEM ADD FOLLOWER/OBSERVER` 语句。

## 2. 常见问题

### 1. this node is DETACHED

当第一次启动一个待添加的 FE 时，如果 Master FE 上的 `doris-meta/bdb` 中的数据很大，则可能在待添加的 FE 日志中看到 `this node is DETACHED.` 字样。这时，bdbje 正在复制数据，你可以看到待添加的 FE 的 `bdb/` 目录正在变大。这个过程通常会在数分钟不等（取决于 bdbje 中的数据量）。之后，`fe.log` 中可能会有一些 bdbje 相关的错误堆栈信息。如果最终日志中显示 `QE service start` 和 `thrift server started`，则通常表示启动成功。可以通过 `mysql-client` 连接这个 FE 尝试操作。如果没有出现这些字样，则可能是 bdbje 复制日志超时等问题。这时，直接再次重启这个 FE，通常即可解决问题。

### 2. 各种原因导致添加失败

- 如果添加的是 OBSERVER，因为 OBSERVER 类型的 FE 不参与元数据的多数写，理论上可以随意启停。因此，对于添加 OBSERVER 失败的情况。可以直接杀死 OBSERVER FE 的进程，清空 OBSERVER 的元数据目录后，重新进行一遍添加流程。
- 如果添加的是 FOLLOWER，因为 FOLLOWER 是参与元数据多数写的。所以有可能 FOLLOWER 已经加入 bdbje 选举组内。如果这时只有两个 FOLLOWER 节点（包括 MASTER），那么停掉一个 FE，可能导致另一个 FE 也因无法进行多数写而退出。此时，我们应该先通过 `ALTER SYSTEM DROP FOLLOWER` 命令，从元数据中删除新添加的 FOLLOWER 节点，然后再杀死 FOLLOWER 进程，清空元数据，重新进行一遍添加流程。

## 删除 FE

通过 `ALTER SYSTEM DROP FOLLOWER/OBSERVER` 命令即可删除对应类型的 FE。以下几点注意事项：

- 对于 OBSERVER 类型的 FE，直接 DROP 即可，无风险。
- 对于 FOLLOWER 类型的 FE。首先，应保证在有奇数个 FOLLOWER 的情况下（3 个或以上），开始删除操作。

1. 如果删除非 MASTER 角色的 FE，建议连接到 MASTER FE，执行 DROP 命令，再杀死进程即可。
2. 如果要删除 MASTER FE，先确认有奇数个 FOLLOWER FE 并且运行正常。然后先杀死 MASTER FE 的进程。这时会有某一个 FE 被选举为 MASTER。在确认剩下的 FE 运行正常后，连接到新的 MASTER FE，执行 DROP 命令删除之前老的 MASTER FE 即可。

## 高级操作

### 故障恢复

FE 有可能因为某些原因出现无法启动 bdbje、FE 之间无法同步等问题。现象包括无法进行元数据写操作、没有 MASTER 等等。这时，我们需要手动操作来恢复 FE。手动恢复 FE 的大致原理，是先通过当前 meta\_dir 中的元数据，启动一个新的 MASTER，然后再逐台添加其他 FE。请严格按照如下步骤操作：

1. 首先，**停止所有 FE 进程，同时停止一切业务访问**。保证在元数据恢复期间，不会因为外部访问导致其他不可预期的问题。(如果没有停止所有 FE 进程，后续流程可能出现脑裂现象)
2. 确认哪个 FE 节点的元数据是最新：
  - 首先，**务必先备份所有 FE 的 meta\_dir 目录**。
  - 通常情况下，Master FE 的元数据是最新的。可以查看 meta\_dir/image 目录下，image.xxxx 文件的后缀，数字越大，则表示元数据越新。
  - 通常，通过比较所有 FOLLOWER FE 的 image 文件，找出最新的元数据即可。
  - 之后，我们要使用这个拥有最新元数据的 FE 节点，进行恢复。
  - 如果使用 OBSERVER 节点的元数据进行恢复会比较麻烦，建议尽量选择 FOLLOWER 节点。
3. 以下操作都在由第 2 步中选择出来的 FE 节点上进行。
  1. 修改 fe.conf
    - 如果该节点是一个 OBSERVER，先将 meta\_dir/image/ROLE 文件中的 role=OBSERVER 改为 role=FOLLOWER。
    - 如果 FE 版本 < 2.0.2，则还需要在 fe.conf 中添加配置：metadata\_failure\_recovery=true。
  2. 执行 sh bin/start\_fe.sh --metadata\_failure\_recovery --daemon 启动这个 FE。(如果是从 OBSERVER 节点恢复，执行完这一步后跳转到后续的 OBSERVER 文档)
  3. 如果正常，这个 FE 会以 MASTER 的角色启动，类似于前面 启动单节点 FE 一节中的描述。在 fe.log 应该会看到 transfer from XXXX to MASTER 等字样。
  4. 启动完成后，先连接到这个 FE，执行一些查询导入，检查是否能够正常访问。如果不正常，有可能是操作有误，建议仔细阅读以上步骤，用之前备份的元数据再试一次。如果还是不行，问题可能就比较严重了。
  5. 如果成功，通过 show frontends; 命令，应该可以看到之前所添加的所有 FE，并且当前 FE 是 master。
  6. 后重启这个 FE (**重要**)。

7. 如果 FE 版本 < 2.0.2, 将 fe.conf 中的 metadata\_failure\_recovery=true 配置项删除, 或者设置为 false, 然后重启这个 FE (重要)。

:::tip 如果你是从一个 OBSERVER 节点的元数据进行恢复的, 那么完成上述第二步后, 通过 show frontends; 语句你会发现, 当前这个 FE 的角色为 OBSERVER, 但是 IsMaster 显示为 true。这是因为, 这里看到的“OBSERVER”是记录在 Doris 的元数据中的, 而是否是 master, 是记录在 bdbje 的元数据中的。因为我们是从一个 OBSERVER 节点恢复的, 所以这里出现了不一致。请按如下步骤修复这个问题 (这个问题我们会在之后的某个版本修复):

1. 先把除了这个“OBSERVER”以外的所有 FE 节点 DROP 掉。
2. 通过 ADD FOLLOWER 命令, 添加一个新的 FOLLOWER FE, 假设在 hostA 上。
3. 在 hostA 上启动一个全新的 FE, 通过 --helper 的方式加入集群。
4. 启动成功后, 通过 show frontends; 语句, 你应该能看到两个 FE, 一个是之前的 OBSERVER, 一个是新添加的 FOLLOWER, 并且 OBSERVER 是 master。
5. 确认这个新的 FOLLOWER 是可以正常工作之后, 用这个新的 FOLLOWER 的元数据, 重新执行一遍故障恢复操作。
6. 以上这些步骤的目的, 其实就是人为的制造出一个 FOLLOWER 节点的元数据, 然后用这个元数据, 重新开始故障恢复。这样就避免了从 OBSERVER 恢复元数据所遇到的不一致的问题。

metadata\_failure\_recovery 的含义是, 清空 “bdbje” 的元数据。这样 bdbje 就不会再联系之前的其他 FE 了, 而作为一个独立的 FE 启动。这个参数只有在恢复启动时才需要设置为 true。恢复完成后, 一定要设置为 false, 否则一旦重启, bdbje 的元数据又会被清空, 导致其他 FE 无法正常工作。:::

4. 第 3 步执行成功后, 我们再通过 ALTER SYSTEM DROP FOLLOWER/OBSERVER 命令, 将之前的其他的 FE 从元数据删除后, 按加入新 FE 的方式, 重新把这些 FE 添加一遍。
5. 如果以上操作正常, 则恢复完毕。

## FE 类型变更

如果你需要将当前已有的 FOLLOWER/OBSERVER 类型的 FE, 变更为 OBSERVER/FOLLOWER 类型, 请先按照前面所述的方式删除 FE, 再添加对应类型的 FE 即可

## FE 迁移

如果你需要将一个 FE 从当前节点迁移到另一个节点, 分以下几种情况。

1. 非 MASTER 节点的 FOLLOWER, 或者 OBSERVER 迁移

直接添加新的 FOLLOWER/OBSERVER 成功后, 删除旧的 FOLLOWER/OBSERVER 即可。

2. 单节点 MASTER 迁移

当只有一个 FE 时, 参考 故障恢复 一节。将 FE 的 doris-meta 目录拷贝到新节点上, 按照 故障恢复 一节中, 步骤 3 的方式启动新的 MASTER

3. 一组 FOLLOWER 从一组节点迁移到另一组新的节点

在新的节点上部署 FE，通过添加 FOLLOWER 的方式先加入新节点。再逐台 DROP 掉旧节点即可。在逐台 DROP 的过程中，MASTER 会自动选择在新的 FOLLOWER 节点上。

## 更换 FE 端口

FE 目前有以下几个端口

- edit\_log\_port: bdbje 的通信端口
- http\_port: http 端口，也用于推送 image
- rpc\_port: FE 的 thrift server port
- query\_port: Mysql 连接端口
- arrow\_flight\_sql\_port: Arrow Flight SQL 连接端口

### 1. edit\_log\_port

如果需要更换这个端口，则需要参照 故障恢复 一节中的操作，进行恢复。因为该端口已经被持久化到 bdbje 自己的元数据中（同时也记录在 Doris 自己的元数据中），需要启动 FE 时通过指定 `--metadata_failure_recovery` 来清空 bdbje 的元数据。

### 2. http\_port

所有 FE 的 http\_port 必须保持一致。所以如果要修改这个端口，则所有 FE 都需要修改并重启。修改这个端口，在多 FOLLOWER 部署的情况下会比较复杂（涉及到鸡生蛋蛋生鸡的问题...），所以不建议有这种操作。如果必须，直接按照 故障恢复 一节中的操作吧。

### 3. rpc\_port

修改配置后，直接重启 FE 即可。Master FE 会通过心跳将新的端口告知 BE。只有 Master FE 的这个端口会被使用。但仍然建议所有 FE 的端口保持一致。

### 4. query\_port

修改配置后，直接重启 FE 即可。这个只影响到 mysql 的连接目标。

### 5. arrow\_flight\_sql\_port

修改配置后，直接重启 FE 即可。这个只影响到 Arrow Flight SQL 的连接目标。

## 从 FE 内存中恢复元数据

在某些极端情况下，磁盘上 image 文件可能会损坏，但是内存中的元数据是完好的，此时我们可以先从内存中 dump 出元数据，再替换掉磁盘上的 image 文件，来恢复元数据，整个**不停查询服务**的操作步骤如下： 1. 集群停止所有 Load,Create,Alter 操作

### 2. 执行以下命令，从 Master FE 内存中 dump 出元数据：(下面称为 image\_mem)

```
curl -u $root_user:$password http://$master_hostname:8030/dump
```

3. 用 image\_mem 文件替换掉 OBSERVER FE 节点上 meta\_dir/image 目录下的 image 文件，重启 OBSERVER FE 节点，验证 image\_mem 文件的完整性和正确性（可以在 FE Web 页面查看 DB 和 Table 的元数据是否正常，查看 fe.log 是否有异常，是否在正常 replayed journal）

自 1.2.0 版本起，推荐使用以下功能验证 image\_mem 文件：

```
sh start_fe.sh --image path_to_image_mem
```

**注意：**path\_to\_image\_mem 是 image\_mem 文件的路径。

- 如果文件有效会输出 Load image success. Image file /absolute/path/to/image.xxxxxx is valid。
- 如果文件无效会输出 Load image failed. Image file /absolute/path/to/image.xxxxxx is invalid。

4. 依次用 image\_mem 文件替换掉 FOLLOWER FE 节点上 meta\_dir/image 目录下的 image 文件，重启 FOLLOWER FE 节点，确认元数据和查询服务都正常
5. 用 image\_mem 文件替换掉 Master FE 节点上 meta\_dir/image 目录下的 image 文件，重启 Master FE 节点，确认 FE Master 切换正常，Master FE 节点可以通过 checkpoint 正常生成新的 image 文件
6. 集群恢复所有 Load,Create,Alter 操作

\*\*\*\*注意：\*\*\*\*

如果 Image 文件很大，整个操作过程耗时可能会很长，所以在此期间，要确保 Master FE 不会通过 checkpoint 生成新的 image 文件。

当观察到 Master FE 节点上 meta\_dir/image 目录下的 image.ckpt 文件快和 image.xxx 文件一样大时，可以直接删除掉 image.ckpt 文件。

## 查看 BDBJE 中的数据

FE 的元数据日志以 Key-Value 的方式存储在 BDBJE 中。某些异常情况下，可能因为元数据错误而无法启动 FE。在这种情况下，Doris 提供一种方式可以帮助用户查询 BDBJE 中存储的数据，以方便进行问题排查。

首先需在 fe.conf 中增加配置：enable\_bdbje\_debug\_mode=true，之后通过 sh start\_fe.sh --daemon 启动 FE。

此时，FE 将进入 debug 模式，仅会启动 http server 和 MySQL server，并打开 BDBJE 实例，但不会进行任何元数据的加载及后续其他启动流程。

这时，我们可以通过访问 FE 的 web 页面，或通过 MySQL 客户端连接到 Doris 后，通过 show proc "/bdbje"；来查看 BDBJE 中存储的数据。

```
mysql> show proc "/bdbje";
```

| DbNames  | JournalNumber | Comment |
|----------|---------------|---------|
| 110589   | 4273          |         |
| epochDB  | 4             |         |
| metricDB | 430694        |         |

第一级目录会展示 BDBJE 中所有的 database 名称，以及每个 database 中的 entry 数量。

```
mysql> show proc "/bdbje/110589";
```

| JournalId |
|-----------|
| 1         |
| 2         |
| ...       |
| 114858    |
| 114859    |
| 114860    |
| 114861    |

4273 rows in set (0.06 sec)

进入第二级，则会罗列指定 database 下的所有 entry 的 key。

```
mysql> show proc "/bdbje/110589/114861";
```

| JournalId | OpType       | Data                                        |
|-----------|--------------|---------------------------------------------|
| 114861    | OP_HEARTBEAT | org.apache.doris.persist.HbPackage@6583d5fb |

1 row in set (0.05 sec)

第三级则可以展示指定 key 的 value 信息。

## 最佳实践

FE 的部署推荐，在 [安装与部署文档](#) 中有介绍，这里再做一些补充。

- 如果你并不十分了解 FE 元数据的运行逻辑，或者没有足够 FE 元数据的运维经验，我们强烈建议在实际使用中，只部署一个 **FOLLOWER** 类型的 FE 作为 **MASTER**，其余 FE 都是 **OBSERVER**，这样可以减少很多复杂的运维问题！不用过于担心 MASTER 单点故障导致无法进行元数据写操作。首先，如果你配置合理，FE 作为 java 进程很难挂掉。其次，如果 MASTER 磁盘损坏（概率非常低），我们也可以用 OBSERVER 上的元数据，通过 故障恢复 的方式手动恢复。
- FE 进程的 JVM 一定要保证足够的内存。我们强烈建议 FE 的 JVM 内存至少在 10GB 以上，推荐 32GB 至 64GB。并且部署监控来监控 JVM 的内存使用情况。因为如果 FE 出现 OOM，可能导致元数据写入失败，造成一些无法恢复的故障！
- FE 所在节点要有足够的磁盘空间，以防止元数据过大导致磁盘空间不足。同时 FE 日志也会占用十几 G 的磁盘空间。



## 其他常见问题

1. fe.log 中一直滚动 meta out of date. current time: xxx, synchronized time: xxx, has log: xxx, fe type: xxx

这个通常是因为 FE 无法选举出 Master。比如配置了 3 个 FOLLOWER，但是只启动了一个 FOLLOWER，则这个 FOLLOWER 会出现这个问题。通常，只要把剩余的 FOLLOWER 启动起来就可以了。如果启动起来后，仍然没有解决问题，那么可能需要按照 故障恢复 一节中的方式，手动进行恢复。

2. Clock delta: xxxx ms. between Feeder: xxxx and this Replica exceeds max permissible delta: xxxx ms.

bdbje 要求各个节点之间的时钟误差不能超过一定阈值。如果超过，节点会异常退出。我们默认设置的阈值为 5000 ms，由 FE 的参数 max\_bdbje\_clock\_delta\_ms 控制，可以酌情修改。但我们建议使用 ntp 等时钟同步方式保证 Doris 集群各主机的时钟同步。

3. image/ 目录下的镜像文件很久没有更新

Master FE 会默认每 50000 条元数据 journal，生成一个镜像文件。在一个频繁使用的集群中，通常每隔半天到几天的时间，就会生成一个新的 image 文件。如果你发现 image 文件已经很久没有更新了（比如超过一个星期），则可以顺序的按照如下方法，查看具体原因：

1. 在 Master FE 的 fe.log 中搜索 memory is not enough to do checkpoint. Committed memory xxxx Bytes, used memory xxxx Bytes. 字样。如果找到，则说明当前 FE 的 JVM 内存不足以用于生成镜像（通常我们需要预留一半的 FE 内存用于 image 的生成）。那么需要增加 JVM 的内存并重启 FE 后，再观察。每次 Master FE 重启后，都会直接生成一个新的 image。也可用这种重启方式，主动地生成新的 image。注意，如果是多 FOLLOWER 部署，那么当你重启当前 Master FE 后，另一个 FOLLOWER FE 会变成 MASTER，则后续的 image 生成会由新的 Master 负责。因此，你可能需要修改所有 FOLLOWER FE 的 JVM 内存配置。
2. 在 Master FE 的 fe.log 中搜索 begin to generate new image: image.xxxx。如果找到，则说明开始生成 image 了。检查这个线程的后续日志，如果出现 checkpoint finished save image.xxxx，则说明 image 写入成功。如果出现 Exception when generate new image file，则生成失败，需要查看具体的错误信息。

4. bdb/ 目录的大小非常大，达到几个 G 或更多

如果在排除无法生成新的 image 的错误后，bdb 目录在一段时间内依然很大。则可能是因为 Master FE 推送 image 不成功。可以在 Master FE 的 fe.log 中搜索 push image.xxxx to other nodes. totally xx nodes, push succeeded yy nodes。如果 yy 比 xx 小，则说明有的 FE 没有被推送成功。可以在 fe.log 中查看到具体的错误 Exception when pushing image file. url = xxx。

同时，你也可以在 FE 的配置文件中添加配置：edit\_log\_roll\_num=xxxx。该参数设定了每多少条元数据 journal，做一次 image。默认是 50000。可以适当改小这个数字，使得 image 更加频繁，从而加速删除旧的 journal。

5. FOLLOWER FE 接连挂掉

因为 Doris 的元数据采用多数写策略，即一条元数据 journal 必须至少写入多数个 FOLLOWER FE 后（比如 3 个 FOLLOWER，必须写成功 2 个），才算成功。而如果写入失败，FE 进程会主动退出。那么假设有



A、B、C 三个 FOLLOWER，C 先挂掉，然后 B 再挂掉，那么 A 也会跟着挂掉。所以如 最佳实践 一节中所述，如果你没有丰富的元数据运维经验，不建议部署多 FOLLOWER。

6. fe.log 中出现 get exception when try to close previously opened bdb database. ignore it

如果后面有 ignore it 字样，通常无需处理。如果你有兴趣，可以在 BDBEnvironment.java 搜索这个错误，查看相关注释说明。

7. 从 show frontends; 看，某个 FE 的 Join 列为 true，但是实际该 FE 不正常

通过 show frontends; 查看到的 Join 信息。该列如果为 true，仅表示这个 FE 曾经加入过 集群。并不能表示当前仍然正常的存在于集群中。如果为 false，则表示这个 FE 从未加入过 集群。

8. 关于 FE 的配置 master\_sync\_policy, replica\_sync\_policy 和 txn\_rollback\_limit

master\_sync\_policy 用于指定当 Leader FE 写元数据日志时，是否调用 fsync(), replica\_sync\_policy 用于指定当 FE HA 部署时，其他 Follower FE 在同步元数据时，是否调用 fsync()。在早期的 Doris 版本中，这两个参数默认是 WRITE\_NO\_SYNC，即都不调用 fsync()。在最新版本的 Doris 中，默认已修改为 SYNC，即都调用 fsync()。调用 fsync() 会显著降低元数据写盘的效率。在某些环境下，IOPS 可能降至几百，延迟增加到 2-3ms（但对于 Doris 元数据操作依然够用）。因此我们建议以下配置：

1. 对于单 Follower FE 部署，master\_sync\_policy 设置为 SYNC，防止 FE 系统宕机导致元数据丢失。
2. 对于多 Follower FE 部署，可以将 master\_sync\_policy 和 replica\_sync\_policy 设为 WRITE\_NO\_SYNC，因为我们认为多个系统同时宕机的概率非常低。

如果在单 Follower FE 部署中，master\_sync\_policy 设置为 WRITE\_NO\_SYNC，则可能出现 FE 系统宕机导致元数据丢失。这时如果有其他 Observer FE 尝试重启时，可能会报错：

```
Node xxx must rollback xx total commits(numPassedDurableCommits of which were durable) to the earliest point indicated by transaction xxxx in order to rejoin the replication group, but the transaction rollback limit of xxx prohibits this.
```

意思有部分已经持久化的事务需要回滚，但条数超过上限。这里我们的默认上限是 100，可以通过设置 txn\_rollback\_limit 改变。该操作仅用于尝试正常启动 FE，但已丢失的元数据无法恢复。

# 服务自动拉起

本文档主要介绍如何配置 Doris 集群的自动拉起，保证生产环境中出现特殊情况导致服务宕机后能及时拉起服务从而影响到业务的正常运行。

Doris 集群必须完全搭建完成后再配置 FE 和 BE 的自动拉起服务。

## Systemd 配置 Doris 服务

systemd 具体使用以及参数解析可以参考[这里](#)

### sudo 权限控制

在使用 systemd 控制 doris 服务时，需要有 sudo 权限。为了保证最小粒度的 sudo 权限分配，可以将 doris-fe 与 doris-be 服务的 systemd 控制权限分配给指定的非 root 用户。在 visudo 来配置 doris-fe 与 doris-be 的 systemctl 管理权限。

```
Cmnd_Alias DORISCTL=/usr/bin/systemctl start doris-fe,/usr/bin/systemctl stop doris-fe,/usr/bin/systemctl start doris-be,/usr/bin/systemctl stop doris-be
```

```
Allow root to run any commands anywhere
```

```
root ALL=(ALL) ALL
```

```
doris ALL=(ALL) NOPASSWD:DORISCTL
```

### 配置步骤

1. 分别在 fe.conf 和 be.conf 中添加 JAVA\_HOME 变量配置，否则使用 systemctl start 将无法启动服务  
echo "JAVA\_HOME=your\_java\_home" >> /home/doris/fe/conf/fe.conf  
echo "JAVA\_HOME=your\_java\_home" >> /home/doris/be/conf/be.conf
2. 下载 doris-fe.service 文件：[doris-fe.service](#)
3. doris-fe.service 具体内容如下：

```
Licensed to the Apache Software Foundation (ASF) under one
or more contributor license agreements. See the NOTICE file
distributed with this work for additional information
regarding copyright ownership. The ASF licenses this file
to you under the Apache License, Version 2.0 (the
"License"); you may not use this file except in compliance
with the License. You may obtain a copy of the License at
#
http://www.apache.org/licenses/LICENSE-2.0
#
Unless required by applicable law or agreed to in writing,
software distributed under the License is distributed on an
"AS IS" BASIS, WITHOUT WARRANTIES OR CONDITIONS OF ANY
KIND, either express or implied. See the License for the
specific language governing permissions and limitations
under the License.
```

```
[Unit]
Description=Doris FE
After=network-online.target
Wants=network-online.target

[Service]
Type=forking
User=root
Group=root
LimitCORE=infinity
LimitNOFILE=200000
Restart=on-failure
RestartSec=30
StartLimitInterval=120
StartLimitBurst=3
KillMode=none
ExecStart=/home/doris/fe/bin/start_fe.sh --daemon
ExecStop=/home/doris/fe/bin/stop_fe.sh

[Install]
WantedBy=multi-user.target
```

### :::caution 注意事项

- ExecStart、ExecStop 根据实际部署的 fe 的路径进行配置 :::

#### 4. 下载 doris-be.service 文件: [doris-be.service](#)

#### 5. doris-be.service 具体内容如下:

```
Licensed to the Apache Software Foundation (ASF) under one
or more contributor license agreements. See the NOTICE file
distributed with this work for additional information
regarding copyright ownership. The ASF licenses this file
to you under the Apache License, Version 2.0 (the
"License"); you may not use this file except in compliance
with the License. You may obtain a copy of the License at
#
http://www.apache.org/licenses/LICENSE-2.0
#
Unless required by applicable law or agreed to in writing,
software distributed under the License is distributed on an
"AS IS" BASIS, WITHOUT WARRANTIES OR CONDITIONS OF ANY
KIND, either express or implied. See the License for the
specific language governing permissions and limitations
under the License.

[Unit]
Description=Doris BE
After=network-online.target
Wants=network-online.target

[Service]
Type=forking
User=root
Group=root
LimitCORE=infinity
LimitNOFILE=200000
Restart=on-failure
RestartSec=30
StartLimitInterval=120
StartLimitBurst=3
```

```
KillMode=none
ExecStart=/home/doris/be/bin/start_be.sh --daemon
ExecStop=/home/doris/be/bin/stop_be.sh

[Install]
WantedBy=multi-user.target
```

### :::caution 注意事项

- ExecStart、ExecStop 根据实际部署的 be 的路径进行配置 :::

## 6. 服务配置

将 doris-fe.service、doris-be.service 两个文件放到 /usr/lib/systemd/system 目录下

## 7. 设置自启动

添加或修改配置文件后，需要重新加载

```
systemctl daemon-reload
```

设置自启动，实质就是在 /etc/systemd/system/multi-user.target.wants/ 添加服务文件的链接

```
systemctl enable doris-fe
systemctl enable doris-be
```

## 8. 服务启动

```
systemctl start doris-fe
systemctl start doris-be
```

# Supervisor 配置 Doris 服务

Supervisor 具体使用以及参数解析可以参考[这里](#)

Supervisor 配置自动拉起可以使用 yum 命令直接安装，也可以通过 pip 手工安装，pip 手工安装流程比较复杂，只展示 yum 方式部署，手工部署请参考[这里](#)进行安装部署。

## 配置步骤

### 1. yum 安装 supervisor

```
yum install epel-release
yum install -y supervisor
```

### 2. 启动服务并查看状态

```
systemctl enable supervisord # 开机自启动
systemctl start supervisord # 启动 supervisord 服务
systemctl status supervisord # 查看 supervisord 服务状态
ps -ef|grep supervisord # 查看是否存在 supervisord 进程
```

### 3. 配置 BE 进程管理

修改 start\_be.sh 脚本, 去掉最后的 & 符号

```
vim /path/doris/be/bin/start_be.sh
将 nohup $LIMIT ${DORIS_HOME}/lib/palo_be "$@" >> $LOG_DIR/be.out 2>&1 </dev/null &
修改为 nohup $LIMIT ${DORIS_HOME}/lib/palo_be "$@" >> $LOG_DIR/be.out 2>&1 </dev/null
```

#### 创建 BE 的 supervisor 进程管理配置文件

```
vim /etc/supervisord.d/doris-be.ini

[program:doris_be]
process_name=%(program_name)s
directory=/path/doris/be/be
command=sh /path/doris/be/bin/start_be.sh
autostart=true
autorestart=true
user=root
numprocs=1
startretries=3
stopasgroup=true
killasgroup=true
startsecs=5
#redirect_stderr = true
#stdout_logfile_maxbytes = 20MB
#stdout_logfile_backups = 10
#stdout_logfile=/var/log/supervisor-palo_be.log
```

### 4. 配置 FE 进程管理

修改 start\_fe.sh 脚本, 去掉最后的 & 符号

```
vim /path/doris/fe/bin/start_fe.sh
将 nohup $LIMIT $JAVA $final_java_opt org.apache.doris.PaloFe ${HELPER} "$@" >> $LOG_DIR/fe.out 2>&1
</dev/null &
修改为 nohup $LIMIT $JAVA $final_java_opt org.apache.doris.PaloFe ${HELPER} "$@" >> $LOG_DIR/fe.out
2>&1 </dev/null
```

#### 创建 FE 的 supervisor 进程管理配置文件

```
vim /etc/supervisord.d/doris-fe.ini

[program:PaloFe]
environment = JAVA_HOME="/path/jdk8"
process_name=PaloFe
directory=/path/doris/fe
command=sh /path/doris/fe/bin/start_fe.sh
autostart=true
autorestart=true
user=root
numprocs=1
startretries=3
stopasgroup=true
killasgroup=true
startsecs=10
#redirect_stderr=true
#stdout_logfile_maxbytes=20MB
```

```
#stdout_logfile_backups=10
#stdout_logfile=/var/log/supervisor-PaloFe.log
```

## 5. 配置 Broker 进程管理

修改 start\_broker.sh 脚本, 去掉最后的 & 符号

```
vim /path/apache_hdfs_broker/bin/start_broker.sh
将 nohup $LIMIT $JAVA $JAVA_OPTS org.apache.doris.broker.hdfs.BrokerBootstrap "$@" >>
$BROKER_LOG_DIR/apache_hdfs_broker.out 2>&1 </dev/null &
修改为 nohup $LIMIT $JAVA $JAVA_OPTS org.apache.doris.broker.hdfs.BrokerBootstrap "$@" >>
$BROKER_LOG_DIR/apache_hdfs_broker.out 2>&1 </dev/null
```

### 创建 Broker 的 supervisor 进程管理配置文件

```
vim /etc/supervisord.d/doris-broker.ini

[program:BrokerBootstrap]
environment = JAVA_HOME="/usr/local/java"
process_name=%(program_name)s
directory=/path/apache_hdfs_broker
command=sh /path/apache_hdfs_broker/bin/start_broker.sh
autostart=true
autorestart=true
user=root
numprocs=1
startretries=3
stopasgroup=true
killasgroup=true
startsecs=5
#redirect_stderr=true
#stdout_logfile_maxbytes=20MB
#stdout_logfile_backups=10
#stdout_logfile=/var/log/supervisor-BrokerBootstrap.log
```

## 6. 首先确定 Doris 服务是停止状态, 然后使用 supervisor 将 Doris 自动拉起, 然后确定进程是否正常启动

```
supervisorctl reload # 重新加载 Supervisor 中的所有配置文件
supervisorctl status # 查看 supervisor 状态, 验证 Doris 服务进程是否正常启动
```

其他命令 :

```
supervisorctl start all # supervisorctl start 可以开启进程
supervisorctl stop doris-be # 通过 supervisorctl stop, 停止进程
```

### 注意事项:

- 如果使用 yum 安装的 supervisor 启动报错 : pkg\_resources.DistributionNotFound: The 'supervisor==3.4.0' distribution was not found

这个是 python 版本不兼容问题, 通过 yum 命令直接安装的 supervisor 只支持 python2 版本, 所以需要将 /usr/bin/supervisord 和 /usr/bin/supervisorctl 中文件内容开头 #!/usr/bin/python 改为 #!/usr/bin/python2, 前提是要装 python2 版本

- 如果配置了 supervisor 对 Doris 进程进行自动拉起, 此时如果 Doris 出现非正常因素导致 BE 节点宕机, 那么此时本来应该输出到 be.out 中的错误堆栈信息会被 supervisor 拦截, 需要在 supervisor 的

log 中查找来进一步分析。

# 如何开启 Debug 日志

Doris 的 FE 和 BE 节点的系统运行日志默认为 INFO 级别。通常可以满足对系统行为的分析和基本问题的定位。但是某些情况下，可能需要开启 DEBUG 级别的日志来进一步排查问题。本文档主要介绍如何开启 FE、BE 节点的 DEBUG 日志级别。

- 不建议将日志级别调整为 **WARN** 或更高级别，这不利于系统行为的分析和问题的定位。
- 开启 DEBUG 日志可能会导致大量日志产生，生产环境请谨慎开启。

## 开启 FE Debug 日志

FE 的 Debug 级别日志可以通过修改配置文件开启，也可以通过界面或 API 在运行时打开。

### 1. 通过配置文件开启

在 fe.conf 中添加配置项 sys\_log\_verbose\_modules。举例如下：

```
仅开启类 org.apache.doris.catalog.Catalog 的 Debug 日志
sys_log_verbose_modules=org.apache.doris.catalog.Catalog

开启包 org.apache.doris.catalog 下所有类的 Debug 日志
sys_log_verbose_modules=org.apache.doris.catalog

开启包 org 下所有类的 Debug 日志
sys_log_verbose_modules=org
```

添加配置项并重启 FE 节点，即可生效。

### 2. 通过 FE UI 界面

通过 UI 界面可以在运行时修改日志级别。无需重启 FE 节点。在浏览器打开 FE 节点的 http 端口（默认为 8030），并登陆 UI 界面。之后点击上方导航栏的 Log 标签。

# Log Configuration

Level: org

Verbose Names:org

Audit Names: slow\_query,query,load

image.png



我们在 Add 输入框中可以输入包名或者具体的类名，可以打开对应的 Debug 日志。如输入 `org.apache.doris.catalog.Catalog` 则可以打开 Catalog 类的 Debug 日志：

# Log Configuration

Level: `org,org.apache.doris.catalog.Catalog`

Verbose Names: `org,org.apache.doris.catalog.Catalog`

Audit Names: `slow_query,query,load`

|                                                       |                                    |                                               |                                       |
|-------------------------------------------------------|------------------------------------|-----------------------------------------------|---------------------------------------|
| <input type="text" value="org.apache.doris.catalog"/> | <input type="button" value="Add"/> | <input type="text" value="del verbose name"/> | <input type="button" value="Delete"/> |
|-------------------------------------------------------|------------------------------------|-----------------------------------------------|---------------------------------------|

image.png

你也可以在 Delete 输入框中输入包名或者具体的类名，来关闭对应的 Debug 日志。

这里的修改只会影响对应的 FE 节点的日志级别。不会影响其他 FE 节点的日志级别。

## 3. 通过 API 修改

通过以下 API 也可以在运行时修改日志级别。无需重启 FE 节点。

```
curl -X POST -uuser:passwd fe_host:http_port/rest/v1/log?add_verbose=org.apache.doris.catalog.Catalog
```

其中用户名密码为登陆 Doris 的 root 或 admin 用户。add\_verbose 参数指定要开启 Debug 日志的包名或类名。若成功则返回：

```
{
 "msg": "success",
 "code": 0,
 "data": {
 "LogConfiguration": {
 "VerboseNames": "org,org.apache.doris.catalog.Catalog",
 "AuditNames": "slow_query,query,load",
 "Level": "INFO"
 }
 },
 "count": 0
}
```

也可以通过以下 API 关闭 Debug 日志：

```
curl -X POST -uuser:passwd fe_host:http_port/rest/v1/log?del_verbose=org.apache.doris.catalog.Catalog
```

del\_verbose 参数指定要关闭 Debug 日志的包名或类名。

## 开启 BE Debug 日志

BE 的 Debug 日志目前仅支持通过配置文件修改并重启 BE 节点以生效。

```
sys_log_verbose_modules=plan_fragment_executor,olap_scan_node
sys_log_verbose_level=3
```

`sys_log_verbose_modules` 指定要开启的文件名，可以通过通配符 \* 指定。比如：

```
sys_log_verbose_modules=*
```

表示开启所有 DEBUG 日志。

`sys_log_verbose_level` 表示 DEBUG 的级别。数字越大，则 DEBUG 日志越详细。取值范围在 1-10。

# 配置文件目录

---

FE 和 BE 的配置文件目录为 `conf/`。这个目录除了存放默认的 `fe.conf`, `be.conf` 等文件外，也被用于公用的配置文件存放目录。

用户可以在其中存放一些配置文件，系统会自动读取。

自 Doris 1.2 版本后支持该功能

## `hdfs-site.xml` 和 `hive-site.xml`

在 Doris 的一些功能中，需要访问 HDFS 上的数据，或者访问 Hive metastore。

我们可以通过在功能相应的语句中，手动的填写各种 HDFS/Hive 的参数。

但这些参数非常多，如果全部手动填写，非常麻烦。

因此，用户可以将 HDFS 或 Hive 的配置文件 `hdfs-site.xml`/`hive-site.xml` 直接放置在 `conf/` 目录下。Doris 会自动读取这些配置文件。

而用户在命令中填写的配置，会覆盖配置文件中的配置项。

这样，用户仅需填写少量的配置，即可完成对 HDFS/Hive 的访问。

# FE 配置项

---

该文档主要介绍 FE 的相关配置项。

FE 的配置文件 `fe.conf` 通常存放在 FE 部署路径的 `conf/` 目录下。而在 0.14 版本中会引入另一个配置文件 `fe_custom.conf`。该配置文件用于记录用户在运行时动态配置并持久化的配置项。

FE 进程启动后，会先读取 `fe.conf` 中的配置项，之后再读取 `fe_custom.conf` 中的配置项。`fe_custom.conf` 中的配置项会覆盖 `fe.conf` 中相同的配置项。

`fe_custom.conf` 文件的位置可以在 `fe.conf` 通过 `custom_config_dir` 配置项配置。

## 查看配置项

FE 的配置项有两种方式进行查看：

### 1. FE 前端页面查看

在浏览器中打开 FE 前端页面 `http://fe_host:fe_http_port/variable`。在 `Configure Info` 中可以看到当前生效的 FE 配置项。

### 2. 通过命令查看

FE 启动后，可以在 MySQL 客户端中，通过以下命令查看 FE 的配置项，具体语法参照[ADMIN-SHOW-CONFIG](#)：

```
ADMIN SHOW FRONTEND CONFIG;
```

结果中各列含义如下：

- **Key**：配置项名称。
- **Value**：当前配置项的值。
- **Type**：配置项值类型，如整型、字符串。
- **IsMutable**：是否可以动态配置。如果为 `true`，表示该配置项可以在运行时进行动态配置。如果 `false`，则表示该配置项只能在 `fe.conf` 中配置并且重启 FE 后生效。
- **MasterOnly**：是否为 Master FE 节点独有的配置项。如果为 `true`，则表示该配置项仅在 Master FE 节点有意义，对其他类型的 FE 节点无意义。如果为 `false`，则表示该配置项在所有 FE 节点中均有意义。
- **Comment**：配置项的描述。

## 设置配置项

FE 的配置项有两种方式进行配置：

### 1. 静态配置

在 `conf/fe.conf` 文件中添加和设置配置项。`fe.conf` 中的配置项会在 FE 进程启动时被读取。没有在 `fe.conf` 中的配置项将使用默认值。

## 2. 通过 MySQL 协议动态配置

FE 启动后，可以通过以下命令动态设置配置项。该命令需要管理员权限。

```
ADMIN SET FRONTEND CONFIG ("fe_config_name" = "fe_config_value");
```

不是所有配置项都支持动态配置。可以通过 `ADMIN SHOW FRONTEND CONFIG;` 命令结果中的 `IsMutable` 列查看是否支持动态配置。

如果是修改 `MasterOnly` 的配置项，则该命令会直接转发给 Master FE 并且仅修改 Master FE 中对应的配置项。

**通过该方式修改的配置项将在 FE 进程重启后失效。**

更多该命令的帮助，可以通过 `HELP ADMIN SET CONFIG;` 命令查看。

## 3. 通过 HTTP 协议动态配置

具体请参阅 [Set Config Action](#)

该方式也可以持久化修改后的配置项。配置项将持久化在 `fe_custom.conf` 文件中，在 FE 重启后仍会生效。

# 应用举例

## 1. 修改 `async_pending_load_task_pool_size`

通过 `ADMIN SHOW FRONTEND CONFIG;` 可以查看到该配置项不能动态配置 (`IsMutable` 为 `false`)。则需要 在 `fe.conf` 中添加：

```
async_pending_load_task_pool_size=20
```

之后重启 FE 进程以生效该配置。

## 2. 修改 `dynamic_partition_enable`

通过 `ADMIN SHOW FRONTEND CONFIG;` 可以查看到该配置项可以动态配置 (`IsMutable` 为 `true`)。并且是 Master FE 独有配置。则首先我们可以连接到任意 FE，执行如下命令修改配置：

```
ADMIN SET FRONTEND CONFIG ("dynamic_partition_enable" = "true");`
```

之后可以通过如下命令查看修改后的值：

```
set forward_to_master=true;
ADMIN SHOW FRONTEND CONFIG;
```

通过以上方式修改后，如果 Master FE 重启或进行了 Master 切换，则配置将失效。可以通过在 `fe.conf` 中直接添加配置项，并重启 FE 后，永久生效该配置项。

## 3. 修改 `max_distribution_pruner_recursion_depth`

通过 `ADMIN SHOW FRONTEND CONFIG`；可以查看到该配置项可以动态配置（IsMutable 为 true）。并且不是 Master FE 独有配置。

同样，我们可以通过动态修改配置的命令修改该配置。因为该配置不是 Master FE 独有配置，所以需要单独连接到不同的 FE，进行动态修改配置的操作，这样才能保证所有 FE 都使用了修改后的配置值

## 配置项列表

### 元数据与集群管理

`meta_dir`

默认值：DorisFE.DORIS\_HOME\_DIR + "/doris-meta"

Doris 元数据将保存在这里。强烈建议将此目录的存储为：

1. 高写入性能（SSD）
2. 安全（RAID）

`catalog_try_lock_timeout_ms`

默认值：5000（ms）

是否可以动态配置：true

元数据锁的 tryLock 超时配置。通常它不需要改变，除非你需要测试一些东西。

`enable_bdbje_debug_mode`

默认值：false

如果设置为 true，FE 将在 BDBJE 调试模式下启动，在 Web 页面 System->bdbje 可以查看相关信息，否则不可以查看

`max_bdbje_clock_delta_ms`

默认值：5000（5 秒）

设置非主 FE 到主 FE 主机之间的最大可接受时钟偏差。每当非主 FE 通过 BDBJE 建立到主 FE 的连接时，都会检查该值。如果时钟偏差大于此值，则放弃连接。

`metadata_failure_recovery`

默认值：false

如果为 true，FE 将重置 bdbje 复制组（即删除所有可选节点信息）并应该作为 Master 启动。如果所有可选节点都无法启动，我们可以将元数据复制到另一个节点并将此配置设置为 true 以尝试重新启动 FE。

`txn_rollback_limit`

默认值：100

尝试重新加入组时 bdbje 可以回滚的最大 txn 数

`bdbje_replica_ack_timeout_second`

默认值：10

元数据会同步写入到多个 Follower FE，这个参数用于控制 Master FE 等待 Follower FE 发送 ack 的超时时间。当写入的数据较大时，可能 ack 时间较长，如果超时，会导致写元数据失败，FE 进程退出。此时可以适当调大这个参数。

`grpc_threadmgr_threads_nums`

默认值：4096

在 `grpc_threadmgr` 中处理 grpc events 的线程数量。

`bdbje_lock_timeout_second`

默认值：5

bdbje 操作的 lock timeout 如果 FE WARN 日志中有很多 LockTimeoutException，可以尝试增加这个值

`bdbje_heartbeat_timeout_second`

默认值：30

master 和 follower 之间 bdbje 的心跳超时。默认为 30 秒，与 bdbje 中的默认值相同。如果网络遇到暂时性问题，一些意外的长 Java GC 使您烦恼，您可以尝试增加此值以减少错误超时的机会

`replica_ack_policy`

默认值：SIMPLE\_MAJORITY

选项：ALL, NONE, SIMPLE\_MAJORITY

bdbje 的副本 ack 策略。更多信息，请参见：

[http://docs.oracle.com/cd/E17277\\_02/html/java/com/sleepycat/je/Durability.ReplicaAckPolicy.html](http://docs.oracle.com/cd/E17277_02/html/java/com/sleepycat/je/Durability.ReplicaAckPolicy.html)

`replica_sync_policy`

默认值：SYNC

选项：SYNC, NO\_SYNC, WRITE\_NO\_SYNC

bdbje 的 Follower FE 同步策略。

`master_sync_policy`

默认值：SYNC

选项：SYNC, NO\_SYNC, WRITE\_NO\_SYNC

Master FE 的 bdbje 同步策略。如果您只部署一个 Follower FE，请将其设置为“SYNC”。如果你部署了超过 3 个 Follower FE，你可以将这个和下面的 `replica_sync_policy` 设置为 WRITE\_NO\_SYNC。更多信息，参见：

[http://docs.oracle.com/cd/E17277\\_02/html/java/com/sleepycat/je/Durability.SyncPolicy.html](http://docs.oracle.com/cd/E17277_02/html/java/com/sleepycat/je/Durability.SyncPolicy.html)

`bdbje_reserved_disk_bytes`

用于限制 bdbje 能够保留的文件的最大磁盘空间。

默认值：1073741824

是否可以动态配置：false

是否为 Master FE 节点独有的配置项：false

ignore\_meta\_check

默认值：false

是否可以动态配置：true

如果为 true，非主 FE 将忽略主 FE 与其自身之间的元数据延迟间隙，即使元数据延迟间隙超过 meta\_delay\_toleration\_second。非主 FE 仍将提供读取服务。当您出于某种原因尝试停止 Master FE 较长时间，但仍希望非 Master FE 可以提供读取服务时，这会很有帮助。

meta\_delay\_toleration\_second

默认值：300（5 分钟）

如果元数据延迟间隔超过 meta\_delay\_toleration\_second，非主 FE 将停止提供服务

edit\_log\_port

默认值：9010

bdbje 端口

edit\_log\_type

默认值：BDB

编辑日志类型。BDB：将日志写入 bdbje LOCAL：已弃用。

edit\_log\_roll\_num

默认值：50000

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

Master FE will save image every edit\_log\_roll\_num meta journals.

force\_do\_metadata\_checkpoint

默认值：false

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

如果设置为 true，则无论 jvm 内存使用百分比如何，检查点线程都会创建检查点



`metadata_checkpoint_memory_threshold`

默认值：60（60%）

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

如果 jvm 内存使用百分比（堆或旧内存池）超过此阈值，则检查点线程将无法工作以避免 OOM。

`max_same_name_catalog_trash_num`

用于设置回收站中同名元数据的最大个数，超过最大值时，最早删除的元数据将被彻底删除，不能再恢复。0 表示不保留同名对象。< 0 表示不做限制。

注意：同名元数据的判断会局限在一定的范围内。比如同名 `database` 的判断会限定在相同 `cluster` 下，同名 `table` 的判断会限定在相同 `database`（指相同 `database id`）下，同名 `partition` 的判断会限定在相同 `database`（指相同 `database id`）并且相同 `table`（指相同 `table id`）下。

默认值：3

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

`cluster_id`

默认值：-1

如果节点（FE 或 BE）具有相同的集群 id，则将认为它们属于同一个 Doris 集群。Cluster id 通常是主 FE 首次启动时生成的随机整数。您也可以指定一个。

`heartbeat_mgr_blocking_queue_size`

默认值：1024

是否为 Master FE 节点独有的配置项：true

在 `heartbeat_mgr` 中存储心跳任务的阻塞队列大小。

`heartbeat_mgr_threads_num`

默认值：8

是否为 Master FE 节点独有的配置项：true

`heartbeat_mgr` 中处理心跳事件的线程数。

`disable_cluster_feature`

默认值：true

是否可以动态配置：true

多集群功能将在 0.12 版本中弃用，将此配置设置为 true 将禁用与集群功能相关的所有操作，包括：

1. 创建/删除集群
2. 添加、释放 BE/将 BE 添加到集群/停用集群 balance
3. 更改集群的后端数量
4. 链接/迁移数据库

`enable_fqdn_mode`

此配置用于 k8s 部署环境。当 `enable_fqdn_mode` 为 `true` 时，将允许更改 be 的重建 pod 的 ip。

默认值：`false`

是否可以动态配置：`false`

是否为 Master FE 节点独有的配置项：`true`

`enable_token_check`

默认值：`true`

为了向前兼容，稍后将被删除。下载 image 文件时检查令牌。

`enable_multi_tags`

默认值：`false`

是否可以动态配置：`false`

是否为 Master FE 节点独有的配置项：`true`

是否开启单 BE 的多标签功能

`initial_root_password`

设置 root 用户初始化 2 阶段 SHA-1 加密密码，默认为”，即不设置 root 密码。后续 root 用户的 `set password` 操作会将 root 初始化密码覆盖。

示例：如要配置密码的明文是 `root@123`，可在 Doris 执行 SQL `select password('root@123')` 获取加密密码 `*A00C34073A26B40AB4307650BFB9309D6BFA6999`。

默认值：空字符串

是否可以动态配置：`false`

是否为 Master FE 节点独有的配置项：`true`

## 服务

`query_port`

默认值：`9030`

Doris FE 通过 `mysql` 协议查询连接端口

arrow\_flight\_sql\_port

默认值: -1

Doris FE 通过 Arrow Flight SQL 协议查询连接端口

frontend\_address

状态: 已弃用, 不建议使用。

类型:string

描述: 显式配置 FE 的 IP 地址, 不使用 *InetAddress*。 *getByName* 获取 IP 地址。通常在 *InetAddress* 中。*getByName* 当无法获得预期结果时。只支持 IP 地址, 不支持主机名。

默认值:0.0.0.0

priority\_networks

默认值: 空

为那些有很多 ip 的服务器声明一个选择策略。请注意, 最多应该有一个 ip 与此列表匹配。这是一个以分号分隔格式的列表, 用 CIDR 表示法, 例如 10.10.10.0/24。如果没有匹配这条规则的 ip, 会随机选择一个。

http\_port

默认值: 8030

FE http 端口, 当前所有 FE http 端口都必须相同

https\_port

默认值: 8050

FE https 端口, 当前所有 FE https 端口都必须相同

enable\_https

默认值: false

FE https 使能标志位, false 表示支持 http, true 表示同时支持 http 与 https, 并且会自动将 http 请求重定向到 https 如果 enable\_https 为 true, 需要在 fe.conf 中配置 ssl 证书信息

enable\_ssl

默认值: true

如果设置为 true, doris 将与 mysql 服务 建立基于 SSL 协议的加密通道。

qe\_max\_connection

默认值: 1024

每个 FE 的最大连接数

check\_java\_version

默认值: true

Doris 将检查已编译和运行的 Java 版本是否兼容, 如果不兼容将抛出 Java 版本不匹配的异常信息, 并终止启动

rpc\_port

默认值: 9020

FE Thrift Server 的端口

thrift\_server\_type

该配置表示 FE 的 Thrift 服务使用的服务模型, 类型为 string, 大小写不敏感。

若该参数为 SIMPLE, 则使用 TSimpleServer 模型, 该模型一般不适用于生产环境, 仅限于测试使用。

若该参数为 THREADED, 则使用 TThreadedSelectorServer 模型, 该模型为非阻塞式 I/O 模型, 即主从 Reactor 模型, 该模型能及时响应大量的并发连接请求, 在多数场景下有较好的表现。

若该参数为 THREAD\_POOL, 则使用 TThreadPoolServer 模型, 该模型为阻塞式 I/O 模型, 使用线程池处理用户连接, 并发连接数受限于线程池的数量, 如果能提前预估并发请求的数量, 并且能容忍足够多的线程资源开销, 该模型会有较好的性能表现, 默认使用该服务模型

thrift\_server\_max\_worker\_threads

默认值: 4096

Thrift Server 最大工作线程数

thrift\_backlog\_num

默认值: 1024

thrift 服务器的 backlog\_num 当你扩大这个 backlog\_num 时, 你应该确保它的值大于 linux /proc/sys/net/core/somaxconn 配置

thrift\_client\_timeout\_ms

默认值: 0

thrift 服务器的连接超时和套接字超时配置

thrift\_client\_timeout\_ms 的默认值设置为零以防止读取超时

thrift\_max\_message\_size

默认值: 100MB

thrift 服务器接收请求消息的大小 (字节数) 上限。如果客户端发送的消息大小超过该值, 那么 thrift 服务器会拒绝该请求并关闭连接, 这种情况下, client 会遇到错误: "connection has been closed by peer", 使用者可以尝试增大该参数以绕过上述限制。

use\_compact\_thrift\_rpc

默认值: true

是否使用压缩格式发送查询计划结构体。开启后，可以降低约 50% 的查询计划结构体大小，从而避免一些“send fragment timeout”错误。但是在某些高并发小查询场景下，可能会降低约 10% 的并发度。

`grpc_max_message_size_bytes`

默认值：1G

用于设置 GRPC 客户端通道的初始流窗口大小，也用于设置最大消息大小。当结果集较大时，可能需要增大该值。

`max_mysql_service_task_threads_num`

默认值：4096

mysql 中处理任务的最大线程数。

`mysql_service_io_threads_num`

默认值：4

mysql 中处理 io 事件的线程数。

`mysql_nio_backlog_num`

默认值：1024

mysql nio server 的 backlog\_num 当你放大这个 backlog\_num 时，你应该同时放大 linux /proc/sys/net/core/somaxconn 文件中的值

`broker_timeout_ms`

默认值：10000（10 秒）

Broker rpc 的默认超时时间

`backend_rpc_timeout_ms`

FE 向 BE 的 BackendService 发送 rpc 请求时的超时时间，单位：毫秒。

默认值：60000

是否可以动态配置：false

是否为 Master FE 节点独有的配置项：true

`drop_backend_after_decommission`

默认值：false

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

该配置用于控制系统在成功下线（Decommission）BE 后，是否 Drop 该 BE。如果为 true，则在 BE 成功下线后，会删除掉该 BE 节点。如果为 false，则在 BE 成功下线后，该 BE 会一直处于 DECOMMISSION 状态，但不会被删除。

该配置在某些场景下可以发挥作用。假设一个 Doris 集群的初始状态为每个 BE 节点有一块磁盘。运行一段时间后，系统进行了纵向扩容，即每个 BE 节点新增 2 块磁盘。因为 Doris 当前还不支持 BE 内部各磁盘间的数据均衡，所以会导致初始磁盘的数据量可能一直远高于新增磁盘的数据量。此时我们可以通过以下操作进行人工的磁盘间均衡：

1. 将该配置项置为 false。
2. 对某一个 BE 节点，执行 decommission 操作，该操作会将该 BE 上的数据全部迁移到其他节点中。
3. decommission 操作完成后，该 BE 不会被删除。此时，取消掉该 BE 的 decommission 状态。则数据会开始从其他 BE 节点均衡回这个节点。此时，数据将会均匀的分布到该 BE 的所有磁盘上。
4. 对所有 BE 节点依次执行 2, 3 两个步骤，最终达到所有节点磁盘均衡的目的。

`max_backend_down_time_second`

默认值：3600（1 小时）

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

如果 BE 关闭了 `max_backend_down_time_second`，将触发 BACKEND\_DOWN 事件。

`disable_backend_black_list`

用于禁止 BE 黑名单功能。禁止该功能后，如果向 BE 发送查询请求失败，也不会将这个 BE 添加到黑名单。该参数适用于回归测试环境，以减少偶发的错误导致大量回归测试失败。

默认值：false

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：false

`max_backend_heartbeat_failure_tolerance_count`

最大可容忍的 BE 节点心跳失败次数。如果连续心跳失败次数超过这个值，则会将 BE 状态置为 dead。该参数适用于回归测试环境，以减少偶发的心跳失败导致大量回归测试失败。

默认值：1

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

`enable_access_file_without_broker`

默认值：false

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

此配置用于在通过代理访问 bos 或其他云存储时尝试跳过代理

`agent_task_resend_wait_time_ms`

默认值：5000

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

当代理任务的创建时间被设置的时候，此配置将决定是否重新发送代理任务，当且仅当当前时间减去创建时间大于 `agent_task_task_resend_wait_time_ms` 时，ReportHandler 可以重新发送代理任务。

该配置目前主要用来解决 PUBLISH\_VERSION 代理任务的重复发送问题，目前该配置的默认值是 5000，是个实验值。

由于把代理任务提交到代理任务队列和提交到 BE 存在一定的时间延迟，所以调大该配置的值可以有效解决代理任务的重复发送问题，

但同时会导致提交失败或者执行失败的代理任务再次被执行的时间延长。

`max_agent_task_threads_num`

默认值：4096

是否为 Master FE 节点独有的配置项：true

代理任务线程池中处理代理任务的最大线程数。

`remote_fragment_exec_timeout_ms`

默认值：30000 (ms)

是否可以动态配置：true

异步执行远程 fragment 的超时时间。在正常情况下，异步远程 fragment 将在短时间内执行。如果系统处于高负载状态，请尝试将此超时设置更长的时间。

`auth_token`

默认值：空

用于内部身份验证的集群令牌。

`enable_http_server_v2`

默认值：从官方 0.14.0 release 版之后默认是 true，之前默认 false

HTTP Server V2 由 SpringBoot 实现，并采用前后端分离的架构。只有启用 httpv2，用户才能使用新的前端 UI 界面

`http_api_extra_base_path`

基本路径是所有 API 路径的 URL 前缀。一些部署环境需要配置额外的基本路径来匹配资源。此 Api 将返回在 `Config.http_api_extra_base_path` 中配置的路径。默认为空，表示未设置。

`jetty_server_acceptors`

默认值：2

`jetty_server_selectors`

默认值：4

`jetty_server_workers`

默认值：0

Jetty 的线程数量由以上三个参数控制。Jetty 的线程架构模型非常简单，分为 `acceptors`、`selectors` 和 `workers` 三个线程池。`acceptors` 负责接受新连接，然后交给 `selectors` 处理 HTTP 消息协议的解包，最后由 `workers` 处理请求。前两个线程池采用非阻塞模型，一个线程可以处理很多 socket 的读写，所以线程池数量较小。

大多数项目，`acceptors` 线程只需要 1~2 个，`selectors` 线程配置 2~4 个足矣。`workers` 是阻塞性的业务逻辑，往往有较多的数据库操作，需要的线程数量较多，具体数量随应用程序的 QPS 和 IO 事件占比而定。QPS 越高，需要的线程数量越多，IO 占比越高，等待的线程数越多，需要的总线程数也越多。

`workers` 线程池默认不做设置，根据自己需要进行设置

`jetty_server_max_http_post_size`

默认值：100 \* 1024 \* 1024 (100MB)

这个是 put 或 post 方法上传文件的最大字节数，默认值：100MB

`jetty_server_max_http_header_size`

默认值：1048576 (1M)

http header size 配置参数

`http_sql_submitter_max_worker_threads`

默认值：2

http 请求处理/api/query 中 sql 任务的最大线程池



`http_load_submitter_max_worker_threads`

默认值：2

http 请求处理/api/upload 任务的最大线程池

## 查询引擎

`default_max_query_instances`

默认值：-1

用户属性 `max_query_instances` 小于等于 0 时，使用该配置，用来限制单个用户同一时刻可使用的查询 instance 个数。该参数小于等于 0 表示无限制。

`max_query_retry_time`

默认值：3

是否可以动态配置：true

查询重试次数。如果我们遇到 RPC 异常并且没有将结果发送给用户，则可能会重试查询。您可以减少此数字以避免雪崩灾难。

`max_dynamic_partition_num`

默认值：500

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

用于限制创建动态分区表时可以创建的最大分区数，避免一次创建过多分区。数量由动态分区参数中的“开始”和“结束”决定。

`dynamic_partition_enable`

默认值：true

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

是否启用动态分区调度，默认启用

`dynamic_partition_check_interval_seconds`

默认值：600 秒，10 分钟

是否可以动态配置：true

是否为 Master FE 节点独有的配置项: true

检查动态分区的频率

max\_multi\_partition\_num

默认值: 4096

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

用于限制批量创建分区表时可以创建的最大分区数，避免一次创建过多分区。

multi\_partition\_name\_prefix

默认值: p\_

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

使用此参数设置 multi partition 的分区名前缀，仅仅 multi partition 生效，不作用于动态分区，默认前缀是“p\_”。

partition\_in\_memory\_update\_interval\_secs

默认值: 300 (s)

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

更新内存中全局分区信息的时间

enable\_concurrent\_update

默认值: false

是否可以动态配置: false

是否为 Master FE 节点独有的配置项: true

是否启用并发更新

lower\_case\_table\_names

默认值: 0

是否可以动态配置: false

是否为 Master FE 节点独有的配置项: true

用于控制用户表表名大小写是否敏感。该配置只能在集群初始化时配置，初始化完成后集群重启和升级时不能修改。

0：表名按指定存储，比较区分大小写。1：表名以小写形式存储，比较不区分大小写。2：表名按指定存储，但以小写形式进行比较。

table\_name\_length\_limit

默认值：64

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

用于控制最大的表名长度

cache\_enable\_sql\_mode

默认值：true

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：false

如果设置为 true，SQL 查询结果集将被缓存。如果查询中所有表的所有分区最后一次访问版本时间的间隔大于 cache\_last\_version\_interval\_second，且结果集行数小于 cache\_result\_max\_row\_count，且数据大小小于 cache\_result\_max\_data\_size，则结果集会被缓存，下一条相同的 SQL 会命中缓存

如果设置为 true，FE 会启用 sql 结果缓存，该选项适用于离线数据更新场景

|                        | case1 | case2 | case3 | case4 |
|------------------------|-------|-------|-------|-------|
| enable_sql_cache       | false | true  | true  | false |
| enable_partition_cache | false | false | true  | true  |

cache\_enable\_partition\_mode

默认值：true

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：false

如果设置为 true，FE 将从 BE cache 中获取数据，该选项适用于部分分区的实时更新。

cache\_result\_max\_row\_count

默认值：3000

是否可以动态配置：true

是否为 Master FE 节点独有的配置项: false

设置可以缓存的最大行数, 详细的原理可以参考官方文档: 操作手册->分区缓存

cache\_result\_max\_data\_size

默认值: 31457280

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: false

设置可以缓存的最大数据大小, 单位 Bytes

cache\_last\_version\_interval\_second

默认值: 900

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: false

缓存结果时上一版本的最小间隔, 该参数区分离线更新和实时更新

enable\_batch\_delete\_by\_default

默认值: false

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

创建唯一表时是否添加删除标志列, 具体原理参照官方文档: 操作手册->数据导入->批量删除

max\_allowed\_in\_element\_num\_of\_delete

默认值: 1024

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

用于限制 delete 语句中 Predicate 的元素个数

max\_running\_rollup\_job\_num\_per\_table

默认值: 1

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

控制 Rollup 作业并发限制

`max_distribution_pruner_recursion_depth`

默认值：100

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：false

这将限制哈希分布修剪器的最大递归深度。例如：其中 a in (5 个元素) 和 b in (4 个元素) 和 c in (3 个元素) 和 d in (2 个元素)。a/b/c/d 是分布式列，所以递归深度为  $5 \times 4 \times 3 \times 2 = 120$ ，大于 100，因此该分发修剪器将不起作用，只会返回所有 buckets。增加深度可以支持更多元素的分布修剪，但可能会消耗更多的 CPU

通过 `ADMIN SHOW FRONTEND CONFIG`；可以查看到该配置项可以动态配置 (IsMutable 为 true)。并且不是 Master FE 独有配置。

同样，我们可以通过动态修改配置的命令修改该配置。因为该配置不是 Master FE 独有配置，所以需要单独连接到不同的 FE，进行动态修改配置的操作，这样才能保证所有 FE 都使用了修改后的配置值

`enable_local_replica_selection`

默认值：false

是否可以动态配置：true

如果设置为 true，Planner 将尝试在与此前端相同的主机上选择 tablet 的副本。在以下情况下，这可能会减少网络传输：

1. N 个主机，部署了 N 个 BE 和 N 个 FE。
2. 数据有 N 个副本。
3. 高并发查询均匀发送到所有 Frontends

在这种情况下，所有 Frontends 只能使用本地副本进行查询。如果想当本地副本不可用时，使用非本地副本服务查询，请将 `enable_local_replica_selection_fallback` 设置为 true

`enable_local_replica_selection_fallback`

默认值：false

是否可以动态配置：true

与 `enable_local_replica_selection` 配合使用，当本地副本不可用时，使用非本地副本服务查询。

`expr_depth_limit`

默认值：3000

是否可以动态配置：true

限制 expr 树的深度。超过此限制可能会导致在持有 db read lock 时分析时间过长。

expr\_children\_limit

默认值：10000

是否可以动态配置：true

限制 expr 树的 expr 子节点的数量。超过此限制可能会导致在持有数据库读锁时分析时间过长。

be\_exec\_version

用于定义 fragment 之间传递 block 的序列化格式。

有时我们的一些代码改动会改变 block 的数据格式，为了使得 BE 在滚动升级的过程中能够相互兼容数据格式，我们需要从 FE 下发一个数据版本来决定以什么格式发送数据。

具体的来说，例如集群中有 2 个 BE，其中一台经过升级能够支持最新的  $v_1$ ，而另一台只支持  $v_0$ ，此时由于 FE 还未升级，所以统一下发  $v_0$ ，BE 之间以旧的数据格式进行交互。待 BE 都升级完成，我们再升级 FE，此时新的 FE 会下发  $v_1$ ，集群统一切换到新的数据格式。

默认值为 max\_be\_exec\_version，如果有特殊需要，我们可以手动设置将格式版本降低，但不应低于 min\_be\_exec\_version。

需要注意的是，我们应该始终保持该变量的值处于所有 BE 的 BeExecVersionManager::min\_be\_exec\_version 和 BeExecVersionManager::max\_be\_exec\_version 之间。（也就是说如果一个已经完成更新的集群如果需要降级，应该保证先降级 FE 再降级 BE 的顺序，或者手动在设置中将该变量调低再降级 BE）

max\_be\_exec\_version

目前支持的最新数据版本，不可修改，应与配套版本的 BE 中的 BeExecVersionManager::max\_be\_exec\_version 一致。

min\_be\_exec\_version

目前支持的最旧数据版本，不可修改，应与配套版本的 BE 中的 BeExecVersionManager::min\_be\_exec\_version 一致。

max\_query\_profile\_num

用于设置保存查询的 profile 的最大个数。

默认值：100

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：false

`publish_version_interval_ms`

默认值: 10 (ms)

两个发布版本操作之间的最小间隔

`publish_version_timeout_second`

默认值: 30 (s)

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

一个事务的所有发布版本任务完成的最大等待时间

`query_colocate_join_memory_limit_penalty_factor`

默认值: 1

是否可以动态配置: true

colocate join PlanFragment instance 的  $\text{memory\_limit} = \text{exec\_mem\_limit} / \min(\text{query\_colocate\_join\_memory\_limit\_penalty\_factor}, \text{instance\_num})$

`rewrite_count_distinct_to_bitmap_hll`

默认值: true

该变量为 session variable, session 级别生效。

- 类型: boolean
- 描述: 仅对于 **AGG** 模型的表来说, 当变量为 true 时, 用户查询时包含 `count(distinct c1)` 这类聚合函数时, 如果 c1 列本身类型为 bitmap, 则 `count distinct` 会改写为 `bitmap_union_count(c1)`。当 c1 列本身类型为 hll, 则 `count distinct` 会改写为 `hll_union_agg(c1)` 如果变量为 false, 则不发生任何改写。

## 导入与导出

`enable_pipeline_load`

默认值: false

是否可以动态配置: true

是否开启 Pipeline 引擎执行 Streamload 等导入任务。

`enable_vectorized_load`

默认值: true

是否开启向量化导入

`enable_new_load_scan_node`

默认值: `true`

是否开启新的 file scan node

`default_max_filter_ratio`

默认值: 0

是否可以动态配置: `true`

是否为 Master FE 节点独有的配置项: `true`

可过滤数据（由于数据不规则等原因）的最大百分比。默认值为 0，表示严格模式，只要数据有一条被过滤掉整个导入失败

`max_running_txn_num_per_db`

默认值: 1000

是否可以动态配置: `true`

是否为 Master FE 节点独有的配置项: `true`

这个配置主要是用来控制同一个 DB 的并发导入个数的。

当集群中有过多的导入任务正在运行时，新提交的导入任务可能会报错：

```
current running txns on db xxx is xx, larger than limit xx
```

该遇到该错误时，说明当前集群内正在运行的导入任务超过了该配置值。此时建议在业务侧进行等待并重试导入任务。

如果使用 Connector 方式写入，该参数的值可以适当调大，上千也没有问题

`using_old_load_usage_pattern`

默认值: `false`

是否可以动态配置: `true`

是否为 Master FE 节点独有的配置项: `true`

如果设置为 `true`，处理错误的 insert stmt 仍将返回一个标签给用户。用户可以使用此标签来检查导入作业的状态。默认值为 `false`，表示插入操作遇到错误，不带导入标签，直接抛出异常给用户客户端。



`disable_load_job`

默认值: `false`

是否可以动态配置: `true`

是否为 Master FE 节点独有的配置项: `true`

不禁用, 如果这设置为 `true`

- 调用开始 `txn api` 时, 所有挂起的导入作业都将失败
- 调用 `commit txn api` 时, 所有准备导入作业都将失败
- 所有提交的导入作业将等待发布

`commit_timeout_second`

默认值: 30

是否可以动态配置: `true`

是否为 Master FE 节点独有的配置项: `true`

在提交一个事务之前插入所有数据的最大等待时间 这是命令“`commit`”的超时秒数

`max_unfinished_load_job`

默认值: 1000

是否可以动态配置: `true`

是否为 Master FE 节点独有的配置项: `true`

最大加载任务数, 包括 `PENDING`、`ETL`、`LOADING`、`QUORUM_FINISHED`。如果超过此数量, 则不允许提交导入作业。

`db_used_data_quota_update_interval_secs`

默认值: 300 (s)

是否可以动态配置: `true`

是否为 Master FE 节点独有的配置项: `true`

一个主守护线程将每 `db_used_data_quota_update_interval_secs` 更新数据库 `txn` 管理器的数据库使用数据配额

为了更好的数据导入性能, 在数据导入之前的数据库已使用的数据量是否超出配额的检查中, 我们并不实时计算数据库已经使用的数据量, 而是获取后台线程周期性更新的值。

该配置用于设置更新数据库使用的数据量的值的时间间隔

`disable_show_stream_load`

默认值: `false`

是否可以动态配置: `true`

是否为 Master FE 节点独有的配置项: `true`

是否禁用显示 stream load 并清除内存中的 stream load 记录。

`max_stream_load_record_size`

默认值: `5000`

是否可以动态配置: `true`

是否为 Master FE 节点独有的配置项: `true`

可以存储在内存中的最近 stream load 记录的默认最大数量

`fetch_stream_load_record_interval_second`

默认值: `120`

是否可以动态配置: `true`

是否为 Master FE 节点独有的配置项: `true`

获取 stream load 记录间隔

`max_bytes_per_broker_scanner`

默认值: `500 * 1024 * 1024 * 1024L` (500G)

是否可以动态配置: `true`

是否为 Master FE 节点独有的配置项: `true`

broker scanner 程序可以在一个 broker 加载作业中处理的最大字节数。通常, 每个 BE 都有一个 broker scanner 程序。

`default_load_parallelism`

默认值: `1`

是否可以动态配置: `true`

是否为 Master FE 节点独有的配置项: `true`

单个节点 broker load 导入的默认并发度。如果用户在提交 broker load 任务时, 在 properties 中自行指定了并发度, 则采用用户自定义的并发度。此参数将与`max_broker_concurrency`、`min_bytes_per_broker_scanner`等多个配置共同决定导入任务的并发度。

`max_broker_concurrency`

默认值：10

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

broker scanner 的最大并发数。

`min_bytes_per_broker_scanner`

默认值：67108864L (64M)

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

单个 broker scanner 将读取的最小字节数。

`period_of_auto_resume_min`

默认值：5 (s)

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

自动恢复 Routine load 的周期

`max_tolerable_backend_down_num`

默认值：0

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

只要有一个 BE 宕机，Routine Load 就无法自动恢复

`max_routine_load_task_num_per_be`

默认值：1024

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

每个 BE 的最大并发例 Routine Load 任务数。这是为了限制发送到 BE 的 Routine Load 任务的数量，并且它也应该小于 BE config `max_routine_load_thread_pool_size`（默认 1024），这是 BE 上的 Routine Load 任务线程池大小。在 2.0 版本中，该默认值从 2.0.13 版本开始为 1024。在此之前默认值是 5。

`max_routine_load_task_concurrent_num`

默认值：256

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

单个 Routine Load 作业的最大并发任务数。在2.0版本中，该默认值从2.0.13版本开始为256。在此之前默认值是5。

`max_routine_load_job_num`

默认值：100

最大 Routine Load 作业数，包括 NEED\_SCHEDULED, RUNNING, PAUSE

`desired_max_waiting_jobs`

默认值：100

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

routine load V2 版本加载的默认等待作业数，这是一个理想的数字。在某些情况下，例如切换 master，当前数量可能超过desired\_max\_waiting\_jobs

`disable_hadoop_load`

默认值：false

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

默认不禁用，将来不推荐使用 hadoop 集群 load。设置为 true 以禁用这种 load 方式。

`enable_spark_load`

默认值：false

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

是否临时启用 spark load，默认不启用

**注意：** 这个参数在 1.2 版本中已经删除，默认开启 spark\_load

`spark_load_checker_interval_second`

默认值：60

Spark 负载调度程序运行间隔，默认 60 秒

`async_loading_load_task_pool_size`

默认值：10

是否可以动态配置：false

是否为 Master FE 节点独有的配置项：true

loading\_load任务执行程序池大小。该池大小限制了正在运行的最大 loading\_load任务数。

当前，它仅限制 broker load的 loading\_load任务的数量。

`async_pending_load_task_pool_size`

默认值：10

是否可以动态配置：false

是否为 Master FE 节点独有的配置项：true

pending\_load任务执行程序池大小。该池大小限制了正在运行的最大 pending\_load任务数。

当前，它仅限制 broker load和 spark load的 pending\_load任务的数量。

它应该小于 max\_running\_txn\_num\_per\_db的值

`async_load_task_pool_size`

默认值：10

是否可以动态配置：false

是否为 Master FE 节点独有的配置项：true

此配置只是为了兼容旧版本，此配置已被 async\_loading\_load\_task\_pool\_size取代，以后会被移除。

`enable_single_replica_load`

默认值：false

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

是否启动单副本数据导入功能。

`min_load_timeout_second`

默认值: 1 (1 秒)

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

最小超时时间, 适用于所有类型的 load

`max_stream_load_timeout_second`

默认值: 259200 (3 天)

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

stream load 和 mini load 最大超时时间

`max_load_timeout_second`

默认值: 259200 (3 天)

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

load 最大超时时间, 适用于除 stream load 之外的所有类型的加载

`stream_load_default_timeout_second`

默认值:  $86400 * 3$  (3 天)

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

默认 stream load 和 mini load 超时时间

`stream_load_default_precommit_timeout_second`

默认值: 3600 (s)

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

默认 stream load 预提交超时时间

`insert_load_default_timeout_second`

默认值: 3600 (1 小时)

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

默认 insert load 超时时间

`mini_load_default_timeout_second`

默认值: 3600 (1 小时)

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

默认非 stream load 类型的 mini load 的超时时间

`broker_load_default_timeout_second`

默认值: 14400 (4 小时)

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

Broker load 的默认超时时间

`spark_load_default_timeout_second`

默认值: 86400 (1 天)

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

默认 Spark 导入超时时间

`hadoop_load_default_timeout_second`

默认值:  $86400 * 3$  (3 天)

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

Hadoop 导入超时时间

`load_running_job_num_limit`

默认值：0

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

Load 任务数量限制，默认 0，无限制

`load_input_size_limit_gb`

默认值：0

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

Load 作业输入的数据大小，默认是 0，无限制

`load_etl_thread_num_normal_priority`

默认值：10

NORMAL 优先级 etl 加载作业的并发数。

`load_etl_thread_num_high_priority`

默认值：3

高优先级 etl 加载作业的并发数。

`load_pending_thread_num_normal_priority`

默认值：10

NORMAL 优先级挂起加载作业的并发数。

`load_pending_thread_num_high_priority`

默认值：3

高优先级挂起加载作业的并发数。加载作业优先级定义为 HIGH 或 NORMAL。所有小批量加载作业都是 HIGH 优先级，其他类型的加载作业是 NORMAL 优先级。设置优先级是为了避免慢加载作业长时间占用线程。这只是内部优化的调度策略。目前，您无法手动指定作业优先级。

`load_checker_interval_second`

默认值：5 (s)



负载调度器运行间隔。加载作业将其状态从 PENDING 转移到 LOADING 到 FINISHED。加载调度程序将加载作业从 PENDING 转移到 LOADING 而 txn 回调会将加载作业从 LOADING 转移到 FINISHED。因此，当并发未达到上限时，加载作业最多需要一个时间间隔才能完成。

`label_keep_max_second`

默认值：3 24 3600 (3 天)

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

`label_keep_max_second`后将删除已完成或取消的加载作业的标签，

1. 去除的标签可以重复使用。
2. 设置较短的时间会降低 FE 内存使用量（因为所有加载作业的信息在被删除之前都保存在内存中）

在高并发写的情况下，如果出现大量作业积压，出现 `call frontend service failed`的情况，查看日志如果是元数据写占用锁的时间太长，可以将这个值调成 12 小时，或者更小 6 小时

`streaming_label_keep_max_second`

默认值：43200 (12 小时)

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

对于一些高频负载工作，例如：INSERT、STREAMING LOAD、ROUTINE\_LOAD\_TASK。如果过期，则删除已完成的作业或任务。

`label_clean_interval_second`

默认值：1 \* 3600 (1 小时)

load 标签清理器将每隔 `label_clean_interval_second` 运行一次以清理过时的作业。

`label_regex_length`

默认值: 128 (字符)

导入 label 的最大字符长度，默认128个字符。

`transaction_clean_interval_second`

默认值：30

如果事务 visible 或者 aborted 状态，事务将在 `transaction_clean_interval_second` 秒后被清除，我们应该让这个间隔尽可能短，每个清洁周期都尽快

## sync\_commit\_interval\_second

提交事务的最大时间间隔。若超过了这个时间 channel 中还有数据没有提交，consumer 会通知 channel 提交事务。

默认值：10（秒）

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

## sync\_checker\_interval\_second

数据同步作业运行状态检查

默认值：10（秒）

## max\_sync\_task\_threads\_num

数据同步作业线程池中的最大线程数量。

默认值：10

## min\_sync\_commit\_size

提交事务需满足的最小 event 数量。若 Fe 接收到的 event 数量小于它，会继续等待下一批数据直到时间超过了 sync\_commit\_interval\_second 为止。默认值是 10000 个 events，如果你想修改此配置，请确保此值小于 canal 端的 canal.instance.memory.buffer.size 配置（默认 16384），否则在 ack 前 Fe 会尝试获取比 store 队列长度更多的 event，导致 store 队列阻塞至超时为止。

默认值：10000

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

## min\_bytes\_sync\_commit

提交事务需满足的最小数据大小。若 Fe 接收到的数据大小小于它，会继续等待下一批数据直到时间超过了 sync\_commit\_interval\_second 为止。默认值是 15 MB，如果你想修改此配置，请确保此值小于 canal 端的 canal.instance.memory.buffer.size 和 canal.instance.memory.buffer.memunit 的乘积（默认 16 MB），否则在 ack 前 Fe 会尝试获取比 store 空间更大的数据，导致 store 队列阻塞至超时为止。

默认值：15 \* 1024 \* 1024 (15M)

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

`max_bytes_sync_commit`

数据同步作业线程池中的最大线程数量。此线程池整个 FE 中只有一个，用于处理 FE 中所有数据同步作业向 BE 发送数据的任务 task，线程池的实现在 SyncTaskPool 类。

默认值：10

是否可以动态配置：false

是否为 Master FE 节点独有的配置项：false

`enable_outfile_to_local`

默认值：false

是否允许 outfile 函数将结果导出到本地磁盘

`export_tablet_num_per_task`

默认值：5

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

每个导出查询计划的 tablet 数量

`export_task_default_timeout_second`

默认值：2 \* 3600（2 小时）

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

导出作业的默认超时时间

`export_running_job_num_limit`

默认值：5

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

运行导出作业的并发限制，默认值为 5，0 表示无限制

`export_checker_interval_second`

默认值：5

导出检查器的运行间隔

## 日志

`log_roll_size_mb`

默认值：1024（1G）

一个系统日志和审计日志的最大大小

`sys_log_dir`

默认值：DorisFE.DORIS\_HOME\_DIR + “/log”

这指定了 FE 日志目录。FE 将产生 2 个日志文件：

1. fe.log：FE 进程的所有日志。
2. fe.warn.log FE 进程的所有警告和错误日志。

`sys_log_level`

默认值：INFO

日志级别，可选项：INFO, WARNING, ERROR, FATAL

`sys_log_roll_num`

默认值：10

要保存在 `sys_log_roll_interval` 内的最大 FE 日志文件。默认为 10，表示一天最多有 10 个日志文件

`sys_log_verbose_modules`

默认值：{}

详细模块。VERBOSE 级别由 log4j DEBUG 级别实现。

例如：`sys_log_verbose_modules = org.apache.doris.catalog` 这只会打印包 `org.apache.doris.catalog` 及其所有子包中文件的调试日志。

`sys_log_roll_interval`

默认值：DAY

可选项：

- DAY: log 前缀是 yyyyMMdd
- HOUR: log 前缀是 yyyyMMddHH

## sys\_log\_delete\_age

默认值：7d

默认为 7 天，如果日志的最后修改时间为 7 天前，则将其删除。

支持格式：

- 7d: 7 天
- 10h: 10 小时
- 60m: 60 分钟
- 120s: 120 秒

## sys\_log\_roll\_mode

默认值：SIZE-MB-1024

日志拆分的大小，每 1G 拆分一个日志文件

## sys\_log\_enable\_compress

默认值：false

控制是否压缩 fe log, 包括 fe.log 及 fe.warn.log。如果开启，则使用 gzip 算法进行压缩。

## audit\_log\_dir

默认值：DorisFE.DORIS\_HOME\_DIR + “/log”

审计日志目录：这指定了 FE 审计日志目录。审计日志 fe.audit.log 包含所有请求以及相关信息，如 user, host, cost, status 等。

## audit\_log\_roll\_num

默认值：90

保留在 audit\_log\_roll\_interval 内的最大 FE 审计日志文件。

## audit\_log\_modules

默认值：{“slow\_query”, “query”, “load”, “stream\_load”}

慢查询包含所有开销超过 *qe\_slow\_log\_ms* 的查询

## qe\_slow\_log\_ms

默认值：5000（5 秒）

如果查询的响应时间超过此阈值，则会在审计日志中记录为 slow\_query。

`audit_log_roll_interval`

默认值: DAY

DAY: log 前缀是: yyyyMMdd HOUR: log 前缀是: yyyyMMddHH

`audit_log_delete_age`

默认值: 30d

默认为 30 天, 如果日志的最后修改时间为 30 天前, 则将其删除。

支持格式:

- 7d 7 天
- 10 小时 10 小时
- 60m 60 分钟
- 120s 120 秒

`audit_log_enable_compress`

默认值: false

控制是否压缩 fe.audit.log。如果开启, 则使用 gzip 算法进行压缩。

## 存储

`min_replication_num_per_tablet`

默认值: 1

用于设置单个 tablet 的最小 replication 数量。

`max_replication_num_per_tablet`

默认值: 32767

用于设置单个 tablet 的最大 replication 数量。

`default_db_data_quota_bytes`

默认值: 1PB

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

用于设置默认数据库数据配额大小, 设置单个数据库的配额大小可以使用:

```
设置数据库数据量配额，单位为B/K/KB/M/MB/G/GB/T/TB/P/PB
ALTER DATABASE db_name SET DATA QUOTA quota;
查看配置
show data （其他用法：HELP SHOW DATA）
```

default\_db\_replica\_quota\_size

默认值：1073741824

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

用于设置默认数据库 Replica 数量配额大小，设置单个数据库配额大小可以使用：

```
设置数据库Replica数量配额
ALTER DATABASE db_name SET REPLICA QUOTA quota;
查看配置
show data （其他用法：HELP SHOW DATA）
```

recover\_with\_empty\_tablet

默认值：false

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

在某些情况下，某些 tablet 可能会损坏或丢失所有副本。此时数据已经丢失，损坏的 tablet 会导致整个查询失败，无法查询剩余的健康 tablet。

在这种情况下，您可以将此配置设置为 true。系统会将损坏的 tablet 替换为空 tablet，以确保查询可以执行。（但此时数据已经丢失，所以查询结果可能不准确）

min\_clone\_task\_timeout\_sec 和 max\_clone\_task\_timeout\_sec

默认值：最小 3 分钟，最大两小时

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

min\_clone\_task\_timeout\_sec 和 max\_clone\_task\_timeout\_sec 用于限制克隆任务的最小和最大超时时间。一般情况下，克隆任务的超时时间是通过数据量和最小传输速度（5MB/s）来估计的。但在特殊情况下，您可能需要手动设置这两个配置，以确保克隆任务不会因超时而失败。

disable\_storage\_medium\_check

默认值：false

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

如果 `disable_storage_medium_check` 为 true，ReportHandler 将不会检查 tablet 的存储介质，并使得存储冷却功能失效，默认值为 false。当您不关心 tablet 的存储介质是什么时，可以将值设置为 true。

`decommission_tablet_check_threshold`

默认值：5000

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

该配置用于控制 FE 是否执行检测（Decommission）BE 上 Tablets 状态的阈值。如果（Decommission）BE 上的 Tablets 个数大于 0 但小于该阈值，FE 会定时对该 BE 开启一项检测，

如果该 BE 上的 Tablets 数量大于 0 但是所有 Tablets 均处于被回收的状态，那么 FE 会立即下线该（Decommission）BE。注意，不要把该值配置的太大，不然在 Decommission 阶段可能会对 FE 造成性能压力。

`partition_rebalance_max_moves_num_per_selection`

默认值：10

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

仅在使用 PartitionRebalancer 时有效，

`partition_rebalance_move_expire_after_access`

默认值：600 (s)

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

仅在使用 PartitionRebalancer 时有效。如果更改，缓存的移动将被清除

**`tablet_rebalancer_type`**

默认值：BeLoad

是否为 Master FE 节点独有的配置项：true

rebalancer 类型（忽略大小写）：BeLoad、Partition。如果类型解析失败，默认使用 BeLoad

`max_balancing_tablets`

默认值：100



是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

如果 TabletScheduler 中的 balance tablet 数量超过 max\_balancing\_tablets, 则不再进行 balance 检查

max\_scheduling\_tablets

默认值: 2000

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

如果 TabletScheduler 中调度的 tablet 数量超过 max\_scheduling\_tablets, 则跳过检查。

disable\_balance

默认值: false

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

如果设置为 true, TabletScheduler 将不会做 balance

disable\_disk\_balance

默认值: true

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

如果设置为 true, TabletScheduler 将不会做单个 BE 上磁盘之间的 balance

balance\_load\_score\_threshold

默认值: 0.1 (10%)

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

集群 balance 百分比的阈值, 如果一个 BE 的负载分数比平均分数低 10%, 这个后端将被标记为低负载, 如果负载分数比平均分数高 10%, 将被标记为高负载。

capacity\_used\_percent\_high\_water

默认值: 0.75 (75%)

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

磁盘容量的高水位使用百分比。这用于计算后端的负载分数

clone\_distribution\_balance\_threshold

默认值: 0.2

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

BE 副本数的平衡阈值。

clone\_capacity\_balance\_threshold

默认值: 0.2

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

- BE 中数据大小的平衡阈值。

平衡算法为:

1. 计算整个集群的平均使用容量 (AUC) (总数据大小/BE 数)
2. 高水位为  $(AUC * (1 + clone\_capacity\_balance\_threshold))$
3. 低水位为  $(AUC * (1 - clone\_capacity\_balance\_threshold))$
4. 克隆检查器将尝试将副本从高水位 BE 移动到低水位 BE。

disable\_colocate\_balance

默认值: false

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

此配置可以设置为 true 以禁用自动 colocate 表的重新定位和平衡。如果 disable\_colocate\_balance' 设置为 true, 则 ColocateTableBalancer 将不会重新定位和平衡并置表。

注意:

1. 一般情况下, 根本不需要关闭平衡。
2. 因为一旦关闭平衡, 不稳定的 colocate 表可能无法恢复
3. 最终查询时无法使用 colocate 计划。

`balance_slot_num_per_path`

默认值：1

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

balance 时每个路径的默认 slot 数量

`disable_tablet_scheduler`

默认值：false

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

如果设置为 true，将关闭副本修复和均衡逻辑。

`enable_force_drop_redundant_replica`

默认值：false

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

如果设置为 true，系统会在副本调度逻辑中，立即删除冗余副本。这可能导致部分正在对对应副本写入的导入作业失败，但是会加速副本的均衡和修复速度。当集群中有大量等待被均衡或修复的副本时，可以尝试设置此参数，以牺牲部分导入成功率为代价，加速副本的均衡和修复。

`colocate_group_relocate_delay_second`

默认值：1800

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

重分布一个 Colocation Group 可能涉及大量的 tablet 迁移。因此，我们需要一个更保守的策略来避免不必要的 Colocation 重分布。重分布通常发生在 Doris 检测到有 BE 节点宕机后。这个参数用于推迟对 BE 宕机的判断。如默认参数下，如果 BE 节点能够在 1800 秒内恢复，则不会触发 Colocation 重分布。

`allow_replica_on_same_host`

默认值：false

是否可以动态配置：false

是否为 Master FE 节点独有的配置项：false

是否允许同一个 tablet 的多个副本分布在同一个 host 上。这个参数主要用于本地测试是，方便搭建多个 BE 已测试某些多副本情况。不要用于非测试环境。

`repair_slow_replica`

默认值: `false`

是否可以动态配置: `true`

是否为 Master FE 节点独有的配置项: `true`

如果设置为 `true`，会自动检测 compaction 比较慢的副本，并将迁移到其他机器，检测条件是 最慢副本的版本计数超过 `min_version_count_indicate_replica_compaction_too_slow` 的值，且与最快副本的版本计数差异所占比例超过 `valid_version_count_delta_ratio_between_replicas` 的值

`min_version_count_indicate_replica_compaction_too_slow`

默认值: `200`

是否可以动态配置: `true`

是否为 Master FE 节点独有的配置项: `false`

版本计数阈值，用来判断副本做 compaction 的速度是否太慢

`skip_compaction_slower_replica`

默认值: `true`

是否可以动态配置: `true`

是否为 Master FE 节点独有的配置项: `false`

如果设置为 `true`，则在选择可查询副本时，将跳过 compaction 较慢的副本

`valid_version_count_delta_ratio_between_replicas`

默认值: `0.5`

是否可以动态配置: `true`

是否为 Master FE 节点独有的配置项: `true`

最慢副本的版本计数与最快副本的差异有效比率阈值，如果设置 `repair_slow_replica` 为 `true`，则用于判断是否修复最慢的副本

`min_bytes_indicate_replica_too_large`

默认值: `2 * 1024 * 1024 * 1024 (2G)`

是否可以动态配置: `true`

是否为 Master FE 节点独有的配置项: true

数据大小阈值, 用来判断副本的数据量是否太大

`schedule_slot_num_per_path`

默认值: 2

tablet 调度程序中每个路径的默认 slot 数量

`tablet_repair_delay_factor_second`

默认值: 60 (s)

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

决定修复 tablet 前的延迟时间因素。

1. 如果优先级为 VERY\_HIGH, 请立即修复。
2. HIGH, 延迟 `tablet_repair_delay_factor_second * 1`;
3. 正常: 延迟 `tablet_repair_delay_factor_second * 2`;
4. 低: 延迟 `tablet_repair_delay_factor_second * 3`;

`tablet_stat_update_interval_second`

默认值: 300, (5 分钟)

tablet 状态更新间隔 所有 FE 将在每个时间间隔从所有 BE 获取 tablet 统计信息

`storage_flood_stage_usage_percent`

默认值: 95 (95%)

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

`storage_flood_stage_left_capacity_bytes`

默认值:  $1\ 1024\ 1024 * 1024$  (1GB)

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

如果磁盘容量达到 `storage_flood_stage_usage_percent` 和 `storage_flood_stage_left_capacity_bytes` 以下操作将被拒绝:

1. load 作业

## 2. restore 工作

`storage_high_watermark_usage_percent`

默认值：85 (85%)

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

`storage_min_left_capacity_bytes`

默认值：2 \* 1024 \* 1024 \* 1024 (2GB)

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

`storage_high_watermark_usage_percent` 限制 BE 端存储路径使用最大容量百的占比。

`storage_min_left_capacity_bytes` 限制 BE 端存储路径的最小剩余容量。如果达到这两个限制，则不能选择此存储路径作为 tablet 存储目的地。但是对于 tablet 恢复，我们可能会超过这些限制以尽可能保持数据完整性。

`catalog_trash_expire_second`

默认值：86400L (1 天)

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

删除数据库（表/分区）后，您可以使用 RECOVER stmt 恢复它。这指定了最大数据保留时间。一段时间后，数据将被永久删除。

`storage_cooldown_second`

默认值：30 \* 24 \* 3600L (30 天)

创建表（或分区）时，可以指定其存储介质（HDD 或 SSD）。如果设置为 SSD，这将指定 tablet 在 SSD 上停留的默认时间。之后，tablet 将自动移动到 HDD。您可以在 CREATE TABLE stmt 中设置存储冷却时间。

`default_storage_medium`

默认值：HDD

创建表（或分区）时，可以指定其存储介质（HDD 或 SSD）。如果未设置，则指定创建时的默认介质。

`enable_storage_policy`

是否开启 Storage Policy 功能。该功能用户冷热数据分离功能。

默认值：false。即不开启

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

`check_consistency_default_timeout_second`

默认值：600（10 分钟）

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

单个一致性检查任务的默认超时。设置足够长以适合您的 tablet 大小。

`consistency_check_start_time`

默认值：23

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

一致性检查开始时间

一致性检查器将从 `consistency_check_start_time` 运行到 `consistency_check_end_time`。

如果两个时间相同，则不会触发一致性检查。

`consistency_check_end_time`

默认值：23

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

一致性检查结束时间

一致性检查器将从 `consistency_check_start_time` 运行到 `consistency_check_end_time`。

如果两个时间相同，则不会触发一致性检查。

`replica_delay_recovery_second`

默认值：0

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

副本之间的最小延迟秒数失败，并且尝试使用克隆来恢复它。

## tablet\_create\_timeout\_second

默认值：1 (s)

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

创建单个副本的最长等待时间。

例如。如果您为每个表创建一个包含  $m$  个 tablet 和  $n$  个副本的表，创建表请求将在超时前最多运行 ( $m \cdot n \cdot \text{tablet\_create\_timeout\_second}$ )。

## tablet\_delete\_timeout\_second

默认值：2

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

与 tablet\_create\_timeout\_second 含义相同，但在删除 tablet 时使用

## alter\_table\_timeout\_second

默认值：86400 \* 30 (1 月)

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

ALTER TABLE 请求的最大超时时间。设置足够长以适合您的表格数据大小

## max\_replica\_count\_when\_schema\_change

OlapTable 在做 schema change 时，允许的最大副本数，副本数过大会导致 FE OOM。

默认值：100000

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

## history\_job\_keep\_max\_second

默认值：7 \* 24 \* 3600 (7 天)

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

某些作业的最大保留时间。像 schema 更改和 Rollup 作业。



max\_create\_table\_timeout\_second

默认值：1 \* 3600（1 小时）

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

为了在创建表（索引）不等待太久，设置一个最大超时时间

## 外部表

file\_scan\_node\_split\_num

默认值：128

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：false

multi catalog 并发文件扫描线程数

file\_scan\_node\_split\_size

默认值：256 1024 1024

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：false

multi catalog 并发文件扫描大小

enable\_odbc\_table

默认值：false

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

是否启用 ODBC 表，默认不启用，在使用的时候需要手动配置启用，该参数可以通过：

ADMIN SET FRONTEND CONFIG("key"="value")方式进行设置

**注意：**这个参数在 1.2 版本中已经删除，默认启用 ODBC 外表，并且会在以后的某个版本中删除 ODBC 外表，推荐使用 JDBC 外表

disable\_iceberg\_hudi\_table

默认值：true

是否可以动态配置：true

是否为 Master FE 节点独有的配置项: false

从 1.2 版本开始, 我们不再支持创建 hudi 和 iceberg 外表。请改用 multi catalog 功能。

iceberg\_table\_creation\_interval\_second

默认值: 10 (s)

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: false

fe 将每隔 iceberg\_table\_creation\_interval\_second 创建 iceberg table

iceberg\_table\_creation\_strict\_mode

默认值: true

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

如果设置为 true, iceberg 表和 Doris 表的列定义必须一致。如果设置为 false, Doris 只创建支持的数据类型的列。

max\_iceberg\_table\_creation\_record\_size

内存中可以存储的最近 iceberg 库表创建记录的默认最大数量

默认值: 2000

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

max\_hive\_partition\_cache\_num

hive partition 的最大缓存数量。

默认值: 100000

是否可以动态配置: false

是否为 Master FE 节点独有的配置项: false

hive\_metastore\_client\_timeout\_second

hive metastore 的默认超时时间

默认值: 10

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

max\_external\_cache\_loader\_thread\_pool\_size

用于 external 外部表的 meta 缓存加载线程池的最大线程数。

默认值: 10

是否可以动态配置: false

是否为 Master FE 节点独有的配置项: false

max\_external\_file\_cache\_num

用于 external 外部表的 meta 缓存文件数量。

默认值: 100000

是否可以动态配置: false

是否为 Master FE 节点独有的配置项: false

max\_external\_schema\_cache\_num

用于 external 外部表的 schema 缓存数量。

默认值: 10000

是否可以动态配置: false

是否为 Master FE 节点独有的配置项: false

external\_cache\_expire\_time\_minutes\_after\_access

设置缓存中的数据, 在最后一次访问后多久失效。单位为分钟。适用于 External Schema Cache 以及 Hive Partition Cache.

默认值: 1440

是否可以动态配置: false

是否为 Master FE 节点独有的配置项: false

es\_state\_sync\_interval\_second

默认值: 10

FE 会在每隔 es\_state\_sync\_interval\_secs 调用 es api 获取 es 索引分片信息

## 外部资源

dpp\_hadoop\_client\_path

默认值: /lib/hadoop-client/hadoop/bin/hadoop

dpp\_bytes\_per\_reduce

默认值: 100 1024 1024L (100M)

dpp\_default\_cluster

默认值: palo-dpp

dpp\_default\_config\_str

默认值: { hadoop\_configs :  
'mapred.job.priority=NORMAL;mapred.job.map.capacity=50;mapred.job.reduce.capacity=50;mapred.hce.replace.streaming=false;abaci.long.stored.job=true;dce.shuffle.enable=false;dfs.client.authserver.force\_stop=true;dfs.client.auth.method=0' }

dpp\_config\_str

默认值: { palo-dpp : { hadoop\_palo\_path : '/dir', hadoop\_configs :  
'fs.default.name=hdfs://host:port;mapred.job.tracker=host:port;hadoop.job.ugi=user,password' } }

yarn\_config\_dir

默认值: DorisFE.DORIS\_HOME\_DIR + "/lib/yarn-config"

默认的 Yarn 配置文件目录每次运行 Yarn 命令之前, 我们需要检查一下这个路径下是否存在 config 文件, 如果不存在, 则创建它们。

yarn\_client\_path

默认值: DorisFE.DORIS\_HOME\_DIR + "/lib/yarn-client/hadoop/bin/yarn"

默认 Yarn 客户端路径

spark\_launcher\_log\_dir

默认值: sys\_log\_dir + "/spark\_launcher\_log"

指定的 Spark 启动器日志目录

`spark_resource_path`

默认值：空

默认值的 Spark 依赖路径

`spark_home_default_dir`

默认值：DorisFE.DORIS\_HOME\_DIR + “/lib/spark2x”

默认的 Spark home 路径

`spark_dpp_version`

默认值：1.0.0

Spark 默认版本号

## 其他参数

`tmp_dir`

默认值：DorisFE.DORIS\_HOME\_DIR + “/temp\_dir”

temp dir 用于保存某些过程的中间结果，例如备份和恢复过程。这些过程完成后，将清除此目录中的文件。

`custom_config_dir`

默认值：DorisFE.DORIS\_HOME\_DIR + “/conf”

自定义配置文件目录

配置 `fe_custom.conf` 文件的位置。默认为 `conf/` 目录下。

在某些部署环境下，`conf/` 目录可能因为系统的版本升级被覆盖掉。这会导致用户在运行是持久化修改的配置项也被覆盖。这时，我们可以将 `fe_custom.conf` 存储在另一个指定的目录中，以防止配置文件被覆盖。

`plugin_dir`

默认值：DORIS\_HOME + “/plugins

插件安装目录

`plugin_enable`

默认值:true

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

插件是否启用，默认启用

`small_file_dir`

默认值：DORIS\_HOME\_DIR + “/small\_files”

保存小文件的目录

`max_small_file_size_bytes`

默认值：1M

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

SmallFileMgr 中单个文件存储的最大大小

`max_small_file_number`

默认值：100

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

SmallFileMgr 中存储的最大文件数

`enable_metric_calculator`

默认值：true

如果设置为 true，指标收集器将作为守护程序计时器运行，以固定间隔收集指标

`report_queue_size`

默认值：100

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

这个阈值是为了避免在 FE 中堆积过多的报告任务，可能会导致 OOM 异常等问题。

并且每个 BE 每 1 分钟会报告一次 tablet 信息，因此无限制接收报告是不可接受的。以后我们会优化 tablet 报告的处理速度

**不建议修改这个值**

`backup_job_default_timeout_ms`

默认值：86400 \* 1000 (1 天)

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

备份作业的默认超时时间

`max_backup_restore_job_num_per_db`

默认值：10

此配置用于控制每个 DB 能够记录的 backup/restore 任务的数量

`max_backup_tablets_per_job`

默认值：300000

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

此配置用于控制每个 backup job 最大涉及的 tablets 数量，以避免因保存过多元数据导致 FE OOM。

#### 提示

从 Apache Doris 2.0.15 开始支持该配置

`enable_quantile_state_type`

默认值：false

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

是否开启 quantile\_state 数据类型

`enable_date_conversion`

默认值：true

是否可以动态配置：true

是否为 Master FE 节点独有的配置项：true

FE 会自动将 Date/Datetime 转换为 DateV2/DatetimeV2(0)。

enable\_decimal\_conversion

默认值: true

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

FE 将自动将 DecimalV2 转换为 DecimalV3。

proxy\_auth\_magic\_prefix

默认值: x@8

proxy\_auth\_enable

默认值: false

enable\_func\_pushdown

默认值: true

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: false

在 ODBC、JDBC 的 MYSQL 外部表查询时, 是否将带函数的过滤条件下推到 MYSQL 中执行

jdbc\_drivers\_dir

默认值: \${DORIS\_HOME}/jdbc\_drivers;

是否可以动态配置: false

是否为 Master FE 节点独有的配置项: false

用于存放默认的 jdbc drivers

max\_error\_tablet\_of\_broker\_load

默认值: 3;

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

broker load job 保存的失败 tablet 信息的最大数量



default\_db\_max\_running\_txn\_num

默认值: -1

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: true

用于设置默认数据库事务配额大小。

默认值设置为 -1 意味着使用 max\_running\_txn\_num\_per\_db 而不是 default\_db\_max\_running\_txn\_num。

设置单个数据库的配额大小可以使用:

```
设置数据库事务量配额
ALTER DATABASE db_name SET TRANSACTION QUOTA quota;
查看配置
show data (其他用法: HELP SHOW DATA)
```

prefer\_compute\_node\_for\_external\_table

默认值: false

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: false

如果设置为 true, 对外部表的查询将优先分配给计算节点。计算节点的最大数量由 min\_backend\_num\_for\_external\_table 控制。如果设置为 false, 对外部表的查询将分配给任何节点。

min\_backend\_num\_for\_external\_table

默认值: 3

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: false

仅在 prefer\_compute\_node\_for\_external\_table 为 true 时生效。如果计算节点数小于此值, 则对外部表的查询将尝试使用一些混合节点, 让节点总数达到这个值。如果计算节点数大于这个值, 外部表的查询将只分配给计算节点。

infodb\_support\_ext\_catalog

默认值: false

是否可以动态配置: true

是否为 Master FE 节点独有的配置项: false

当设置为 false 时, 查询 information\_schema 中的表时, 将不再返回 external catalog 中的表的信息。

这个参数主要用于避免因 external catalog 无法访问、信息过多等原因导致的查询 information\_schema 超时的  
问题。

`enable_query_hit_stats`

默认值: `false`

是否可以动态配置: `true`

是否为 Master FE 节点独有的配置项: `false`

控制是否启用查询命中率统计。默认为 `false`。

`div_precision_increment`

默认值: `4`

此变量表示增加与/运算符执行的除法操作结果规模的位数。默认为 `4`。

`enable_convert_light_weight_schema_change`

默认值: `true`

暂时性配置项，开启后会启动后台线程自动将所有的 olap 表修改为可 light schema change，修改结果可通过命令 `show convert_light_schema_change [from db]` 来查看，将会展示所有非 light schema change 表的转换结果

`disable_local_deploy_manager_drop_node`

默认值: `true`

禁止 LocalDeployManager 删除节点，防止 cluster.info 文件有误导致节点被删除。

`mysqlldb_replace_name`

默认值: `mysql`

Doris 为了兼用 mysql 周边工具生态，会内置一个名为 mysql 的数据库，如果该数据库与用户自建数据库冲突，请修改这个字段，为 doris 内置的 mysql database 更换一个名字

`max_auto_partition_num`

默认值: `2000`

对于自动分区表，防止用户意外创建大量分区，每个 OLAP 表允许的分区数量为 `max_auto_partition_num`。默认 `2000`。

`fe_thrift_max_pkg_bytes`

默认值：20000000

是否可以动态配置：false

是否为 Master FE 节点独有的配置项：false

用于限制 fe 节点 thrift 端口可以接收的最大包长度，避免接收到过大或者错误的包导致 OOM

# BE 配置项

---

该文档主要介绍 BE 的相关配置项。

BE 的配置文件 `be.conf` 通常存放在 BE 部署路径的 `conf/` 目录下。而在 0.14 版本中会引入另一个配置文件 `be_custom.conf`。该配置文件用于记录用户在运行时动态配置并持久化的配置项。

BE 进程启动后，会先读取 `be.conf` 中的配置项，之后再读取 `be_custom.conf` 中的配置项。`be_custom.conf` 中的配置项会覆盖 `be.conf` 中相同的配置项。

## 查看配置项

用户可以通过访问 BE 的 Web 页面查看当前配置项：

`http://be_host:be_webserver_port/varz`

## 设置配置项

BE 的配置项有两种方式进行配置：

### 1. 静态配置

在 `conf/be.conf` 文件中添加和设置配置项。`be.conf` 中的配置项会在 BE 进行启动时被读取。没有在 `be.conf` 中的配置项将使用默认值。

### 2. 动态配置

BE 启动后，可以通过以下命令动态设置配置项。

```
curl -X POST http://{be_ip}:{be_http_port}/api/update_config?{key}={value}
```

在 0.13 版本及之前，通过该方式修改的配置项将在 BE 进程重启后失效。在 0.14 及之后版本中，可以通过以下命令持久化修改后的配置。修改后的配置项存储在 `be_custom.conf` 文件中。

```
curl -X POST http://{be_ip}:{be_http_port}/api/update_config?{key}={value}&persist=true
```

## 应用举例

### 1. 静态方式修改 `max_base_compaction_threads`

通过在 `be.conf` 文件中添加：

```
max_base_compaction_threads=5
```

之后重启 BE 进程以生效该配置。

### 2. 动态方式修改 `streaming_load_max_mb`

BE 启动后，通过下面命令动态设置配置项 streaming\_load\_max\_mb:

```
curl -X POST http://{be_ip}:{be_http_port}/api/update_config?streaming_load_max_mb=1024
```

返回值如下，则说明设置成功。

```
{
 "status": "OK",
 "msg": ""
}
```

BE 重启后该配置将失效。如果想持久化修改结果，使用如下命令：

```
curl -X POST http://{be_ip}:{be_http_port}/api/update_config?streaming_load_max_mb=1024&persist=true
```

## 配置项列表

### 服务

be\_port

- 类型：int32
- 描述：BE 上 thrift server 的端口号，用于接收来自 FE 的请求
- 默认值：9060

heartbeat\_service\_port

- 类型：int32
- 描述：BE 上心跳服务端口（thrift），用于接收来自 FE 的心跳
- 默认值：9050

webserver\_port

- 类型：int32
- 描述：BE 上的 http server 的服务端口
- 默认值：8040

brpc\_port

- 类型：int32
- 描述：BE 上的 brpc 的端口，用于 BE 之间通讯
- 默认值：8060

arrow\_flight\_sql\_port

- 类型：int32
- 描述：FE 上的 Arrow Flight SQL server 的端口，用于从 Arrow Flight Client 和 BE 之间通讯
- 默认值：-1

## enable\_https

- 类型: bool
- 描述: 是否支持 https. 如果是, 需要在 be.conf 中配置ssl\_certificate\_path和ssl\_private\_key\_path
- 默认值: false

## priority\_networks

- 描述: 为那些有很多 ip 的服务器声明一个选择策略。请注意, 最多应该有一个 ip 与此列表匹配。这是一个以分号分隔格式的列表, 用 CIDR 表示法, 例如 10.10.10.0/24, 如果没有匹配这条规则的 ip, 会随机选择一个。
- 默认值: 空

## storage\_root\_path

- 类型: string
- 描述: BE 数据存储的目录, 多目录之间用英文状态的分号;分隔。可以通过路径区别存储目录的介质, HDD 或 SSD。可以添加容量限制在每个路径的末尾, 通过英文状态逗号, 隔开。如果用户不是 SSD 和 HDD 磁盘混合使用的情况, 不需要按照如下示例一和示例二的配置方法配置, 只需指定存储目录即可; 也不需要修改 FE 的默认存储介质配置

示例 1 如下:

**注意: 如果是 SSD 磁盘要在目录后面加上.SSD,HDD 磁盘在目录后面加.HDD**

```
storage_root_path=/home/disk1/doris.HDD;/home/disk2/doris.SSD;/home/disk2/doris
```

### 说明

- /home/disk1/doris.HDD, 表示存储介质是HDD;
- /home/disk2/doris.SSD, 表示存储介质是SSD;
- /home/disk2/doris, 存储介质默认为HDD

示例 2 如下:

**注意: 不论 HDD 磁盘目录还是 SSD 磁盘目录, 都无需添加后缀, storage\_root\_path 参数里指定 medium 即可**

```
storage_root_path=/home/disk1/doris,medium:hdd;/home/disk2/doris,medium:ssd
```

### 说明

- /home/disk1/doris,medium:hdd, 表示存储介质是HDD;
- /home/disk2/doris,medium:ssd, 表示存储介质是SSD;
- 默认值: \${DORIS\_HOME}/storage

## heartbeat\_service\_thread\_count

- 类型: int32

- 描述：执行 BE 上心跳服务的线程数，默认为 1，不建议修改
- 默认值：1

## ignore\_broken\_disk

- 类型：bool
- 描述：当 BE 启动时，会检查storage\_root\_path 配置下的所有路径。
  - ignore\_broken\_disk=true

如果路径不存在或路径下无法进行读写文件 (坏盘)，将忽略此路径，如果有其他可用路径则不中断启动。

- ignore\_broken\_disk=false

如果路径不存在或路径下无法进行读写文件 (坏盘)，将中断启动失败退出。

- 默认值：false

## mem\_limit

- 类型：string
- 描述：限制 BE 进程使用服务器最大内存百分比。用于防止 BE 内存挤占太多的机器内存，该参数必须大于 0，当百分大于 100% 之后，该值会默认为 100%。
- 默认值：80%

## cluster\_id

- 类型：int32
- 描述：配置 BE 的所属于的集群 id。
  - 该值通常由 FE 通过心跳向 BE 下发，不需要额外进行配置。当确认某 BE 属于某一个确定的 Drois 集群时，可以进行配置，同时需要修改数据目录下的 cluster\_id 文件，使二者相同。
- 默认值：-1

## custom\_config\_dir

- 描述：配置 be\_custom.conf 文件的位置。默认为 conf/ 目录下。
  - 在某些部署环境下，conf/目录可能因为系统的版本升级被覆盖掉。这会导致用户在运行是持久化修改的配置项也被覆盖。这时，我们可以将 be\_custom.conf 存储在另一个指定的目录中，以防止配置文件被覆盖。
- 默认值：空

## trash\_file\_expire\_time\_sec

- 描述：回收站清理的间隔，72 个小时，当磁盘空间不足时，trash 下的文件保存期可不遵守这个参数
- 默认值：259200

## es\_http\_timeout\_ms

- 描述：通过 http 连接 ES 的超时时间，默认是 5 秒

- 默认值：5000 (ms)

#### es\_scroll\_keepalive

- 描述：es scroll Keeplive 保持时间，默认 5 分钟
- 默认值：5 (m)

#### external\_table\_connect\_timeout\_sec

- 类型：int32
- 描述：和外部表建立连接的超时时间。
- 默认值：5 秒

#### status\_report\_interval

- 描述：配置文件报告之间的间隔；单位：秒
- 默认值：5

#### brpc\_max\_body\_size

- 描述：这个配置主要用来修改 brpc 的参数 max\_body\_size。
  - 有时查询失败，在 BE 日志中会出现 body\_size is too large 的错误信息。这可能发生在 SQL 模式为 multi distinct + 无 group by + 超过 1T 数据量的情况下。这个错误表示 brpc 的包大小超过了配置值。此时可以通过调大该配置避免这个错误。

#### brpc\_socket\_max\_unwritten\_bytes

- 描述：这个配置主要用来修改 brpc 的参数 socket\_max\_unwritten\_bytes。
  - 有时查询失败，BE 日志中会出现 The server is overcrowded 的错误信息，表示连接上有过多的未发送数据。当查询需要发送较大的 bitmap 字段时，可能会遇到该问题，此时可能通过调大该配置避免该错误。

#### transfer\_large\_data\_by\_brpc

- 类型：bool
- 描述：该配置用来控制是否在 Tuple/Block data 长度大于 1.8G 时，将 protoBuf request 序列化后和 Tuple/Block data 一起嵌入到 controller attachment 后通过 http brpc 发送。为了避免 protoBuf request 的长度超过 2G 时的错误：Bad request, error\_text=[E1003]Fail to compress request。在过去的版本中，曾将 Tuple/Block data 放入 attachment 后通过默认的 baidu\_std brpc 发送，但 attachment 超过 2G 时将被截断，通过 http brpc 发送不存在 2G 的限制。
- 默认值：true

#### brpc\_num\_threads

- 描述：该配置主要用来修改 brpc 中 bthreads 的数量。该配置的默认值被设置为 256



- 用户可以将该配置的值调大来获取更好的 QPS 性能。更多的信息可以参考 <https://github.com/apache/brpc/blob/master/docs/cn/benchmark.md>。

- 默认值：256

#### thrift\_rpc\_timeout\_ms

- 描述：thrift 默认超时时间
- 默认值：60000

#### thrift\_client\_retry\_interval\_ms

- 类型：int64
- 描述：用来为 be 的 thrift 客户端设置重试间隔，避免 fe 的 thrift server 发生雪崩问题，单位为 ms。
- 默认值：1000

#### thrift\_connect\_timeout\_seconds

- 描述：默认 thrift 客户端连接超时时间
- 默认值：3 (m)

#### thrift\_server\_type\_of\_fe

- 类型：string
- 描述：该配置表示 FE 的 Thrift 服务使用的服务模型，类型为 string, 大小写不敏感，该参数需要和 fe 的 thrift\_server\_type 参数的设置保持一致。目前该参数的取值有两个，THREADED和THREAD\_POOL。
  - 若该参数为THREADED, 该模型为非阻塞式 I/O 模型，
  - 若该参数为THREAD\_POOL, 该模型为阻塞式 I/O 模型。

#### thrift\_max\_message\_size

:::info 备注 该参数自 2.0.12 版本起支持。 :::

默认值：100MB

thrift 服务器接收请求消息的大小（字节数）上限。如果客户端发送的消息大小超过该值，那么 thrift 服务器会拒绝该请求并关闭连接，这种情况下，client 会遇到错误：“connection has been closed by peer”，使用者可以尝试增大该参数以绕过上述限制。

#### txn\_commit\_rpc\_timeout\_ms

- 描述：txn 提交 rpc 超时
- 默认值：60000 (ms)

#### txn\_map\_shard\_size

- 描述：txn\_map\_lock 分片大小，取值为  $2^n$ ,  $n=0,1,2,3,4$ 。这是一项增强功能，可提高管理 txn 的性能

- 默认值：128

#### txn\_shard\_size

- 描述：txn\_lock 分片大小，取值为  $2^n$ ， $n=0,1,2,3,4$ ，这是一项增强功能，可提高提交和发布 txn 的性能
- 默认值：1024

#### unused\_rowset\_monitor\_interval

- 描述：清理过期 Rowset 的时间间隔
- 默认值：30 (s)

#### max\_client\_cache\_size\_per\_host

- 描述：每个主机的最大客户端缓存数，BE 中有多种客户端缓存，但目前我们使用相同的缓存大小配置。如有必要，使用不同的配置来设置不同的客户端缓存。
- 默认值：10

#### string\_type\_length\_soft\_limit\_bytes

- 类型：int32
- 描述：String 类型最大长度的软限，单位是字节
- 默认值：1048576

#### big\_column\_size\_buffer

- 类型：int64
- 描述：当使用 odbc 外表时，如果 odbc 源表的某一列类型为 HLL, CHAR 或者 VARCHAR，并且列值长度超过该值，则查询报错'column value length longer than buffer length'. 可增大该值
- 默认值：65535

#### small\_column\_size\_buffer

- 类型：int64
- 描述：当使用 odbc 外表时，如果 odbc 源表的某一列类型不是 HLL, CHAR 或者 VARCHAR，并且列值长度超过该值，则查询报错'column value length longer than buffer length'. 可增大该值
- 默认值：100

#### jsonb\_type\_length\_soft\_limit\_bytes

- 类型：int32
- 描述：JSONB 类型最大长度的软限，单位是字节
- 默认值：1048576

## 查询

### fragment\_pool\_queue\_size

- 描述：单节点上能够处理的查询请求上限
- 默认值：4096

### fragment\_pool\_thread\_num\_min

- 描述：查询线程数，默认最小启动 64 个线程。
- 默认值：64

### fragment\_pool\_thread\_num\_max

- 描述：后续查询请求动态创建线程，最大创建 512 个线程。
- 默认值：2048

### doris\_max\_pushdown\_conjuncts\_return\_rate

- 类型：int32
- 描述：BE 在进行 HashJoin 时，会采取动态分区裁剪的方式将 join 条件下推到 OlapScanner 上。当 OlapScanner 扫描的数据大于 32768 行时，BE 会进行过滤条件检查，如果该过滤条件的过滤率低于该配置，则 Doris 会停止使用动态分区裁剪的条件进行数据过滤。
- 默认值：90

### doris\_max\_scan\_key\_num

- 类型：int
- 描述：用于限制一个查询请求中，scan node 节点能拆分的最大 scan key 的个数。当一个带有条件的查询请求到达 scan node 节点时，scan node 会尝试将查询条件中 key 列相关的条件拆分成多个 scan key range。之后这些 scan key range 会被分配给多个 scanner 线程进行数据扫描。较大的数值通常意味着可以使用更多的 scanner 线程来提升扫描操作的并行度。但在高并发场景下，过多的线程可能会带来更大的调度开销和系统负载，反而会降低查询响应速度。一个经验数值为 50。该配置可以单独进行会话级别的配置，具体可参阅 [变量](#) 中 max\_scan\_key\_num 的说明。
  - 当在高并发场景下发下并发度无法提升时，可以尝试降低该数值并观察影响。
- 默认值：48

### doris\_scan\_range\_row\_count

- 类型：int32
- 描述：BE 在进行数据扫描时，会将同一个扫描范围拆分为多个 ScanRange。该参数代表了每个 ScanRange 代表扫描数据范围。通过该参数可以限制单个 OlapScanner 占用 io 线程的时间。
- 默认值：524288

### doris\_scanner\_row\_num

- 描述：每个扫描线程单次执行最多返回的数据行数
- 默认值：16384

## doris\_scanner\_row\_bytes

- 描述：每个扫描线程单次执行最多返回的数据字节
  - 说明：如果表的列数太多，遇到 `select *` 卡主，可以调整这个配置
- 默认值：10485760

## doris\_scanner\_thread\_pool\_queue\_size

- 类型：int32
- 描述：Scanner 线程池的队列长度。在 Doris 的扫描任务之中，每一个 Scanner 会作为一个线程 task 提交到线程池之中等待被调度，而提交的任务数目超过线程池队列的长度之后，后续提交的任务将阻塞直到队列之中有新的空缺。
- 默认值：102400

## doris\_scanner\_thread\_pool\_thread\_num

- 类型：int32
- 描述：Scanner 线程池线程数目。在 Doris 的扫描任务之中，每一个 Scanner 会作为一个线程 task 提交到线程池之中等待被调度，该参数决定了 Scanner 线程池的大小。
- 默认值：48

## doris\_max\_remote\_scanner\_thread\_pool\_thread\_num

- 类型：int32
- 描述：Remote scanner thread pool 的最大线程数。Remote scanner thread pool 用于除内表外的所有 scan 任务的执行。
- 默认值：512

## enable\_prefetch

- 类型：bool
- 描述：当使用 PartitionedHashTable 进行聚合和 join 计算时，是否进行 HashBuket 的预取，推荐设置为 true。
- 默认值：true

## enable\_quadratic\_probing

- 类型：bool
- 描述：当使用 PartitionedHashTable 时发生 Hash 冲突时，是否采用平方探测法来解决 Hash 冲突。该值为 false 的话，则选用线性探测法来解决 Hash 冲突。关于平方探测法可参考：[quadratic\\_probing](#)
- 默认值：true

## exchg\_node\_buffer\_size\_bytes

- 类型：int32
- 描述：ExchangeNode 节点 Buffer 队列的大小，单位为 byte。来自 Sender 端发送的数据量大于 ExchangeNode 的 Buffer 大小之后，后续发送的数据将阻塞直到 Buffer 腾出可写入的空间。
- 默认值：10485760

## max\_pushdown\_conditions\_per\_column

- 类型: int
- 描述: 用于限制一个查询请求中, 针对单个列, 能够下推到存储引擎的最大条件数量。在查询计划执行的过程中, 一些列上的过滤条件可以下推到存储引擎, 这样可以利用存储引擎中的索引信息进行数据过滤, 减少查询需要扫描的数据量。比如等值条件、IN 谓词中的条件等。这个参数在绝大多数情况下仅影响包含 IN 谓词的查询。如 WHERE colA IN (1,2,3,4,...)。较大的数值意味值 IN 谓词中更多的条件可以推送给存储引擎, 但过多的条件可能会导致随机读的增加, 某些情况下可能会降低查询效率。该配置可以单独进行会话级别的配置, 具体可参阅 [变量](#) 中 max\_pushdown\_conditions\_per\_column 的说明。
- 默认值: 1024
- 示例
  - 表结构为 id INT, col2 INT, col3 varchar(32), ...。
  - 查询请求为 ... WHERE id IN (v1, v2, v3, ...)
  - 如果 IN 谓词中的条件数量超过了该配置, 则可以尝试增加该配置值, 观察查询响应是否有所改善。

## max\_send\_batch\_parallelism\_per\_job

- 类型: int
- 描述: OlapTableSink 发送批处理数据的最大并行度, 用户为 send\_batch\_parallelism 设置的值不允许超过 max\_send\_batch\_parallelism\_per\_job, 如果超过, send\_batch\_parallelism 将被设置为 max\_send\_batch\_parallelism\_per\_job 的值。
- 默认值: 5

## doris\_scan\_range\_max\_mb

- 类型: int32
- 描述: 每个 OlapScanner 读取的最大数据量
- 默认值: 1024

## compaction

### disable\_auto\_compaction

- 类型: bool
- 描述: 关闭自动执行 compaction 任务
  - 一般需要为关闭状态, 当调试或测试环境中想要手动操作 compaction 任务时, 可以对该配置进行开启
- 默认值: false

### enable\_vertical\_compaction

- 类型: bool
- 描述: 是否开启列式 compaction
- 默认值: true

`vertical_compaction_num_columns_per_group`

- 类型: int32
- 描述: 在列式 compaction 中, 组成一个合并组的列个数
- 默认值: 5

`vertical_compaction_max_row_source_memory_mb`

- 类型: int32
- 描述: 在列式 compaction 中, row\_source\_buffer 能使用的最大内存, 单位是 MB。
- 默认值: 200

`vertical_compaction_max_segment_size`

- 类型: int32
- 描述: 在列式 compaction 中, 输出的 segment 文件最大值, 单位是 m 字节。
- 默认值: 268435456

`enable_ordered_data_compaction`

- 类型: bool
- 描述: 是否开启有序数据的 compaction
- 默认值: true

`ordered_data_compaction_min_segment_size`

- 类型: int32
- 描述: 在有序数据 compaction 中, 满足要求的最小 segment 大小, 单位是 m 字节。
- 默认值: 10485760

`max_base_compaction_threads`

- 类型: int32
- 描述: Base Compaction 线程池中线程数量的最大值。
- 默认值: 4

`generate_compaction_tasks_interval_ms`

- 描述: 生成 compaction 作业的最小间隔时间
- 默认值: 10 (ms)

`base_compaction_min_rowset_num`

- 描述: BaseCompaction 触发条件之一: Cumulative 文件数目要达到的限制, 达到这个限制之后会触发 BaseCompaction
- 默认值: 5

## base\_compaction\_min\_data\_ratio

- 描述：BaseCompaction 触发条件之一：Cumulative 文件大小达到 Base 文件的比例。
- 默认值：0.3 (30%)

## total\_permits\_for\_compaction\_score

- 类型：int64
- 描述：被所有的 compaction 任务所能持有的“permits”上限，用来限制 compaction 占用的内存。
- 默认值：10000
- 可动态修改：是

## compaction\_promotion\_size\_mbytes

- 类型：int64
- 描述：cumulative compaction 的输出 rowset 总磁盘大小超过了此配置大小，该 rowset 将用于 base compaction。单位是 m 字节。
  - 一般情况下，配置在 2G 以内，为了防止 cumulative compaction 时间过长，导致版本积压。
- 默认值：1024

## compaction\_promotion\_ratio

- 类型：double
- 描述：cumulative compaction 的输出 rowset 总磁盘大小超过 base 版本 rowset 的配置比例时，该 rowset 将用于 base compaction。
  - 一般情况下，建议配置不要高于 0.1，低于 0.02。
- 默认值：0.05

## compaction\_promotion\_min\_size\_mbytes

- 类型：int64
- 描述：Cumulative compaction 的输出 rowset 总磁盘大小低于此配置大小，该 rowset 将不进行 base compaction，仍然处于 cumulative compaction 流程中。单位是 m 字节。
  - 一般情况下，配置在 512m 以内，配置过大会导致 base 版本早期的大小过小，一直不进行 base compaction。
- 默认值：64

## compaction\_min\_size\_mbytes

- 类型：int64
- 描述：cumulative compaction 进行合并时，选出的要进行合并的 rowset 的总磁盘大小大于此配置时，才按级别策略划分合并。小于这个配置时，直接执行合并。单位是 m 字节。
  - 一般情况下，配置在 128m 以内，配置过大会导致 cumulative compaction 写放大较多。
- 默认值：64

## default\_rowset\_type

- 类型：string

- 描述：标识 BE 默认选择的存储格式，可配置的参数为：“**ALPHA**”，“**BETA**”。主要起以下两个作用
  - 当建表的 storage\_format 设置为 Default 时，通过该配置来选取 BE 的存储格式。
  - 进行 Compaction 时选择 BE 的存储格式
- 默认值：BETA

#### cumulative\_compaction\_min\_deltas

- 描述：cumulative compaction 策略：最小增量文件的数量
- 默认值：5

#### cumulative\_compaction\_max\_deltas

- 描述：cumulative compaction 策略：最大增量文件的数量
- 默认值：1000

#### base\_compaction\_trace\_threshold

- 类型：int32
- 描述：打印 base compaction 的 trace 信息的阈值，单位秒
- 默认值：10

base compaction 是一个耗时较长的后台操作，为了跟踪其运行信息，可以调整这个阈值参数来控制 trace 日志的打印。打印信息如下：

```
W0610 11:26:33.804431 56452 storage_engine.cpp:552] execute base compaction cost 0.00319222
BaseCompaction:546859:
- filtered_rows: 0
- input_row_num: 10
- input_rowsets_count: 10
- input_rowsets_data_size: 2.17 KB
- input_segments_num: 10
- merge_rowsets_latency: 100000.510ms
- merged_rows: 0
- output_row_num: 10
- output_rowset_data_size: 224.00 B
- output_segments_num: 1
0610 11:23:03.727535 (+ 0us) storage_engine.cpp:554] start to perform base compaction
0610 11:23:03.728961 (+ 1426us) storage_engine.cpp:560] found best tablet 546859
0610 11:23:03.728963 (+ 2us) base_compaction.cpp:40] got base compaction lock
0610 11:23:03.729029 (+ 66us) base_compaction.cpp:44] rowsets picked
0610 11:24:51.784439 (+108055410us) compaction.cpp:46] got concurrency lock and start to do compaction
0610 11:24:51.784818 (+ 379us) compaction.cpp:74] prepare finished
0610 11:26:33.359265 (+101574447us) compaction.cpp:87] merge rowsets finished
0610 11:26:33.484481 (+125216us) compaction.cpp:102] output rowset built
0610 11:26:33.484482 (+ 1us) compaction.cpp:106] check correctness finished
0610 11:26:33.513197 (+ 28715us) compaction.cpp:110] modify rowsets finished
0610 11:26:33.513300 (+ 103us) base_compaction.cpp:49] compaction finished
0610 11:26:33.513441 (+ 141us) base_compaction.cpp:56] unused rowsets have been moved to GC queue
```

#### cumulative\_compaction\_trace\_threshold

- 类型：int32
- 描述：打印 cumulative compaction 的 trace 信息的阈值，单位秒
  - 与 base\_compaction\_trace\_threshold 类似。



- 默认值: 2

#### compaction\_task\_num\_per\_disk

- 类型: int32
- 描述: 每个磁盘 (HDD) 可以并发执行的 compaction 任务数量。
- 默认值: 4

#### compaction\_task\_num\_per\_fast\_disk

- 类型: int32
- 描述: 每个高速磁盘 (SSD) 可以并发执行的 compaction 任务数量。
- 默认值: 8

#### cumulative\_compaction\_rounds\_for\_each\_base\_compaction\_round

- 类型: int32
- 描述: Compaction 任务的生产者每次连续生产多少轮 cumulative compaction 任务后生产一轮 base compaction。
- 默认值: 9

#### cumulative\_compaction\_policy

- 类型: string
- 描述: 配置 cumulative compaction 阶段的合并策略, 目前实现了两种合并策略, num\_based 和 size\_based
  - 详细说明, ordinary, 是最初版本的 cumulative compaction 合并策略, 做一次 cumulative compaction 之后直接 base compaction 流程。size\_based, 通用策略是 ordinary 策略的优化版本, 仅当 rowset 的磁盘体积在相同数量级时才进行版本合并。合并之后满足条件的 rowset 进行晋升到 base compaction 阶段。能够做到在大量小批量导入的情况下: 降低 base compact 的写入放大率, 并在读取放大率和空间放大率之间进行权衡, 同时减少了文件版本的数据。
- 默认值: size\_based

#### max\_cumu\_compaction\_threads

- 类型: int32
- 描述: Cumulative Compaction 线程池中线程数量的最大值。
- 默认值: 10

#### enable\_segcompaction

- 类型: bool
- 描述: 在导入时进行 segment compaction 来减少 segment 数量, 以避免出现写入时的 -238 错误
- 默认值: true

#### segcompaction\_batch\_size

- 类型: int32

- 描述：当 segment 数量超过此阈值时触发 segment compaction，该配置也限制了单个 segment compaction 任务中的最大原始 segment 数量。
- 默认值：10

#### segcompaction\_candidate\_max\_rows

- 类型：int32
- 描述：当 segment 的行数超过此大小时则会在 segment compaction 时被 compact，否则跳过
- 默认值：1048576

#### segcompaction\_candidate\_max\_rows

- 类型：int32
- 描述：segment compaction 任务中允许的单个原始 segment 行数，过大的 segment 将被跳过。
- 默认值：1048576

#### segcompaction\_candidate\_max\_bytes

- 类型：int64
- 描述：segment compaction 任务中允许的单个原始 segment 大小（字节），过大的 segment 将被跳过。
- 默认值：104857600

#### segcompaction\_task\_max\_rows

- 类型：int32
- 描述：单个 segment compaction 任务中允许的原始 segment 总行数。
- 默认值：1572864

#### segcompaction\_task\_max\_bytes

- 类型：int64
- 描述：单个 segment compaction 任务中允许的原始 segment 总大小（字节）。
- 默认值：157286400

#### segcompaction\_num\_threads

- 类型：int32
- 描述：segment compaction 线程池大小。
- 默认值：5

#### disable\_compaction\_trace\_log

- 类型：bool
- 描述：关闭 compaction 的 trace 日志
  - 如果设置为 true，cumulative\_compaction\_trace\_threshold 和 base\_compaction\_trace\_threshold 将不起作用。并且 trace 日志将关闭。
- 默认值：true

`pick_rowset_to_compact_interval_sec`

- 类型: int64
- 描述: 选取 rowset 去合并的时间间隔, 单位为秒
- 默认值: 86400

`max_single_replica_compaction_threads`

- 类型: int32
- 描述: Single Replica Compaction 线程池中线程数量的最大值。
- 默认值: 10

`update_replica_infos_interval_seconds`

- 描述: 更新 peer replica infos 的最小间隔时间
- 默认值: 60 (s)

## 导入

`enable_stream_load_record`

- 类型: bool
- 描述: 是否开启 stream load 操作记录, 默认是不启用
- 默认值: false

`load_data_reserve_hours`

- 描述: 用于 mini load。mini load 数据文件将在此时间后被删除
- 默认值: 4 (h)

`push_worker_count_high_priority`

- 描述: 导入线程数, 用于处理 HIGH 优先级任务
- 默认值: 3

`push_worker_count_normal_priority`

- 描述: 导入线程数, 用于处理 NORMAL 优先级任务
- 默认值: 3

`enable_single_replica_load`

- 描述: 是否启动单副本数据导入功能
- 默认值: true

`load_error_log_reserve_hours`

- 描述: load 错误日志将在此时间后删除

- 默认值：48 (h)

#### load\_process\_max\_memory\_limit\_percent

- 描述：单节点上所有的导入线程占据的内存上限比例
  - 将这些默认值设置得很大，因为我们不想在用户升级 Doris 时影响负载性能。如有必要，用户应正确设置这些配置。
- 默认值：50 (%)

#### load\_process\_soft\_mem\_limit\_percent

- 描述：soft limit 是指站单节点导入内存上限的比例。例如所有导入任务导入的内存上限是 20GB，则 soft limit 默认为该值的 50%，即 10GB。导入内存占用超过 soft limit 时，会挑选占用内存最大的作业进行下刷以提前释放内存空间。
- 默认值：50 (%)

#### routine\_load\_thread\_pool\_size

- 描述：routine load 任务的线程池大小。这应该大于 FE 配置 'max\_concurrent\_task\_num\_per\_be'
- 默认值：10

#### slave\_replica\_writer\_rpc\_timeout\_sec

- 类型：int32
- 描述：单副本数据导入功能中，Master 副本和 Slave 副本之间通信的 RPC 超时时间。
- 默认值：60

#### max\_segment\_num\_per\_rowset

- 类型：int32
- 描述：用于限制导入时，新产生的 rowset 中的 segment 数量。如果超过阈值，导入会失败并报错 -238。过多的 segment 会导致 compaction 占用大量内存引发 OOM 错误。
- 默认值：200

#### high\_priority\_flush\_thread\_num\_per\_store

- 类型：int32
- 描述：每个存储路径所分配的用于高优导入任务的 flush 线程数量。
- 默认值：1

#### routine\_load\_consumer\_pool\_size

- 类型：int32
- 描述：routine load 所使用的 data consumer 的缓存数量。
- 默认值：10

## multi\_table\_batch\_plan\_threshold

- 类型: int32
- 描述: 一流多表使用该配置, 表示攒多少条数据再进行规划。过小的值会导致规划频繁, 多大的值会增加内存压力和导入延迟。
- 默认值: 200

## single\_replica\_load\_download\_num\_workers

- 类型: int32
- 描述: 单副本数据导入功能中, Slave 副本通过 HTTP 从 Master 副本下载数据文件的工作线程数。导入并发增大时, 可以适当调大该参数来保证 Slave 副本及时同步 Master 副本数据。必要时也应相应地调大 webserver\_num\_workers 来提高 IO 效率。
- 默认值: 64

## load\_task\_high\_priority\_threshold\_second

- 类型: int32
- 描述: 当一个导入任务的超时时间小于这个阈值是, Doris 将认为他是一个高优任务。高优任务会使用独立的 flush 线程池。
- 默认: 120

## min\_load\_rpc\_timeout\_ms

- 类型: int32
- 描述: load 作业中各个 rpc 的最小超时时间。
- 默认: 20

## kafka\_api\_version\_request

- 类型: bool
- 描述: 如果依赖的 kafka 版本低于 0.10.0.0, 该值应该被设置为 false。
- 默认: true

## kafka\_broker\_version\_fallback

- 描述: 如果依赖的 kafka 版本低于 0.10.0.0, 当 kafka\_api\_version\_request 值为 false 的时候, 将使用回退版本 kafka\_broker\_version\_fallback 设置的值, 有效值为: 0.9.0.x、0.8.x.y。
- 默认: 0.10.0

## max\_consumer\_num\_per\_group

- 描述: 一个数据消费者组中的最大消费者数量, 用于 routine load。
- 默认: 3

## streaming\_load\_max\_mb

- 类型: int64

- 描述：用于限制数据格式为 csv 的一次 Stream load 导入中，允许的最大数据量。
  - Stream Load 一般适用于导入几个 GB 以内的数据，不适合导入过大的数据。
- 默认值：10240 (MB)
- 可动态修改：是

streaming\_load\_json\_max\_mb

- 类型：int64
- 描述：用于限制数据格式为 json 的一次 Stream load 导入中，允许的最大数据量。单位 MB。
  - 一些数据格式，如 JSON，无法进行拆分处理，必须读取全部数据到内存后才能开始解析，因此，这个值用于限制此类格式数据单次导入最大数据量。
- 默认值：100
- 可动态修改：是

## 线程

delete\_worker\_count

- 描述：执行数据删除任务的线程数
- 默认值：3

clear\_transaction\_task\_worker\_count

- 描述：用于清理事务的线程数
- 默认值：1

clone\_worker\_count

- 描述：用于执行克隆任务的线程数
- 默认值：3

be\_service\_threads

- 类型：int32
- 描述：BE 上 thrift server service 的执行线程数，代表可以用于执行 FE 请求的线程数。
- 默认值：64

download\_worker\_count

- 描述：下载线程数
- 默认值：1

drop\_tablet\_worker\_count

- 描述：删除 tablet 的线程数
- 默认值：3

#### flush\_thread\_num\_per\_store

- 描述：每个 store 用于刷新内存表的线程数
- 默认值：2

#### num\_threads\_per\_core

- 描述：控制每个内核运行工作的线程数。通常选择 2 倍或 3 倍的内核数量。这使核心保持忙碌而不会导致过度抖动
- 默认值：3

#### num\_threads\_per\_disk

- 描述：每个磁盘的最大线程数也是每个磁盘的最大队列深度
- 默认值：0

#### number\_slave\_replica\_download\_threads

- 描述：每个 BE 节点上 slave 副本同步 Master 副本数据的线程数，用于单副本数据导入功能。
- 默认值：64

#### publish\_version\_worker\_count

- 描述：生效版本的线程数
- 默认值：8

#### upload\_worker\_count

- 描述：上传文件最大线程数
- 默认值：1

#### webserver\_num\_workers

- 描述：webserver 默认工作线程数
- 默认值：48

#### send\_batch\_thread\_pool\_thread\_num

- 类型：int32
- 描述：SendBatch 线程池线程数目。在 NodeChannel 的发送数据任务之中，每一个 NodeChannel 的 SendBatch 操作会作为一个线程 task 提交到线程池之中等待被调度，该参数决定了 SendBatch 线程池的大小。
- 默认值：64

#### send\_batch\_thread\_pool\_queue\_size

- 类型：int32

- 描述：SendBatch 线程池的队列长度。在 NodeChannel 的发送数据任务之中，每一个 NodeChannel 的 SendBatch 操作会作为一个线程 task 提交到线程池之中等待被调度，而提交的任务数目超过线程池队列的长度之后，后续提交的任务将阻塞直到队列之中有新的空缺。
- 默认值：102400

make\_snapshot\_worker\_count

- 描述：制作快照的线程数
- 默认值：5

release\_snapshot\_worker\_count

- 描述：释放快照的线程数
- 默认值：5

## 内存

disable\_mem\_pools

- 类型：bool
- 描述：是否禁用内存缓存池
- 默认值：false

buffer\_pool\_clean\_pages\_limit

- 描述：清理可能被缓冲池保存的 Page
- 默认值：50%

buffer\_pool\_limit

- 类型：string
- 描述：buffer pool 之中最大的可分配内存
  - BE 缓存池最大的内存可用量，buffer pool 是 BE 新的内存管理结构，通过 buffer page 来进行内存管理，并能够实现数据的落盘。并发的所有查询的内存申请都会通过 buffer pool 来申请。当前 buffer pool 仅作用在 **AggregationNode** 与 **ExchangeNode**。
- 默认值：20%

chunk\_reserved\_bytes\_limit

- 描述：Chunk Allocator 的 reserved bytes 限制，通常被设置为 mem\_limit 的百分比。默认单位字节，值必须是 2 的倍数，且必须大于 0，如果大于物理内存，将被设置为物理内存大小。增加这个变量可以提高性能，但是会获得更多其他模块无法使用的空闲内存。
- 默认值：20%

madvise\_huge\_pages

- 类型：bool



- 描述：是否使用 linux 内存大页
- 默认值：false

#### max\_memory\_sink\_batch\_count

- 描述：最大外部扫描缓存批次计数，表示缓存 max\_memory\_cache\_batch\_count \* batch\_size row，默认为 20，batch\_size 的默认值为 1024，表示将缓存 20 \* 1024 行
- 默认值：20

#### memory\_max\_alignment

- 描述：最大校对内存
- 默认值：16

#### mmap\_buffers

- 描述：是否使用 mmap 分配内存
- 默认值：false

#### memtable\_mem\_tracker\_refresh\_interval\_ms

- 描述：memtable 主动下刷时刷新内存统计的周期（毫秒）
- 默认值：100

#### download\_cache\_buffer\_size

- 类型：int64
- 描述：下载缓存时用于接收数据的 buffer 的大小。
- 默认值：10485760

#### zone\_map\_row\_num\_threshold

- 类型：int32
- 描述：如果一个 page 中的行数小于这个值就不会创建 zonemap，用来减少数据膨胀
- 默认值：20

#### enable\_tcmalloc\_hook

- 类型：bool
- 描述：是否 Hook Tcmalloc new/delete，目前在Hook中统计thread local MemTracker。
- 默认值：true

#### memory\_mode

- 类型：string
- 描述：控制 tcmalloc 的回收。如果配置为 performance，内存使用超过 mem\_limit 的 90% 时，doris 会释放 tcmalloc cache 中的内存，如果配置为 compact，内存使用超过 mem\_limit 的 50% 时，doris 会释放 tcmalloc cache 中的内存。

- 默认值: performance

#### max\_sys\_mem\_available\_low\_water\_mark\_bytes

- 类型: int64
- 描述: 系统/proc/meminfo/MemAvailable 的最大低水位线, 单位字节, 默认 1.6G, 实际低水位线 =  $\min(1.6G, \text{MemTotal} * 10\%)$ , 避免在大于 16G 的机器上浪费过多内存。调大 max, 在大于 16G 内存的机器上, 将为 Full GC 预留更多的内存 buffer; 反之调小 max, 将尽可能充分使用内存。
- 默认值: 1717986918

#### memory\_limitation\_per\_thread\_for\_schema\_change\_bytes

- 描述: 单个 schema change 任务允许占用的最大内存
- 默认值: 2147483648 (2GB)

#### mem\_tracker\_consume\_min\_size\_bytes

- 类型: int32
- 描述: TCMalloc Hook consume/release MemTracker 时的最小长度, 小于该值的 consume size 会持续累加, 避免频繁调用 MemTracker 的 consume/release, 减小该值会增加 consume/release 的频率, 增大该值会导致 MemTracker 统计不准, 理论上一个 MemTracker 的统计值与真实值相差 =  $(\text{mem\_tracker\_consume\_min\_size\_bytes} * \text{这个 MemTracker 所在的 BE 线程数})$ 。
- 默认值: 1048576

#### cache\_clean\_interval

- 描述: 文件句柄缓存清理的间隔, 用于清理长期不用的文件句柄。同时也是 Segment Cache 的清理间隔时间。
- 默认值: 1800 (s)

#### min\_buffer\_size

- 描述: 最小读取缓冲区大小
- 默认值: 1024 (byte)

#### write\_buffer\_size

- 描述: 刷写前缓冲区的大小
  - 导入数据在 BE 上会先写入到一个内存块, 当这个内存块达到阈值后才会写回磁盘。默认大小是 100MB。过小的阈值可能导致 BE 上存在大量的小文件。可以适当提高这个阈值减少文件数量。但过大的阈值可能导致 RPC 超时
- 默认值: 104857600

#### remote\_storage\_read\_buffer\_mb

- 类型: int32
- 描述: 读取 hdfs 或者对象存储上的文件时, 使用的缓存大小。
  - 增大这个值, 可以减少远端数据读取的调用次数, 但会增加内存开销。

- 默认值：16MB

#### file\_cache\_type

- 类型：string
- 描述：缓存文件的类型。whole\_file\_cache：将 segment 文件整个下载，sub\_file\_cache：将 segment 文件按大小切分成多个文件。设置为“”，则不缓存文件，需要缓存的时候请设置此参数。
- 默认值：“”

#### file\_cache\_alive\_time\_sec

- 类型：int64
- 描述：缓存文件的保存时间，单位：秒
- 默认值：604800（1 个星期）

#### file\_cache\_max\_size\_per\_disk

- 类型：int64
- 描述：缓存占用磁盘大小，一旦超过这个设置，会删除最久未访问的缓存，为 0 则不限制大小。单位字节
- 默认值：0

#### max\_sub\_cache\_file\_size

- 类型：int64
- 描述：缓存文件使用 sub\_file\_cache 时，切分文件的最大大小，单位 B
- 默认值：104857600（100MB）

#### download\_cache\_thread\_pool\_thread\_num

- 类型：int32
- 描述：DownloadCache 线程池线程数目。在 FileCache 的缓存下载任务之中，缓存下载操作会作为一个线程 task 提交到线程池之中等待被调度，该参数决定了 DownloadCache 线程池的大小。
- 默认值：48

#### download\_cache\_thread\_pool\_queue\_size

- Type: int32
- 描述：DownloadCache 线程池线程数目。在 FileCache 的缓存下载任务之中，缓存下载操作会作为一个线程 task 提交到线程池之中等待被调度，而提交的任务数目超过线程池队列的长度之后，后续提交的任务将阻塞直到队列之中有新的空缺。
- 默认值：102400

#### generate\_cache\_cleaner\_task\_interval\_sec

- 类型：int64
- 描述：缓存文件的清理间隔，单位：秒
- 默认值：43200（12 小时）

path\_gc\_check

- 类型: bool
- 描述: 是否启用回收扫描数据线程检查
- 默认值: true

path\_gc\_check\_interval\_second

- 描述: 回收扫描数据线程检查时间间隔
- 默认值: 86400 (s)

path\_gc\_check\_step

- 默认值: 1000

path\_gc\_check\_step\_interval\_ms

- 默认值: 10 (ms)

path\_scan\_interval\_second

- 默认值: 86400

scan\_context\_gc\_interval\_min

- 描述: 此配置用于上下文 gc 线程调度周期
- 默认值: 5 (分钟)

## 存储

default\_num\_rows\_per\_column\_file\_block

- 类型: int32
- 描述: 配置单个 RowBlock 之中包含多少行的数据。
- 默认值: 1024

disable\_storage\_page\_cache

- 类型: bool
- 描述: 是否进行使用 page cache 进行 index 的缓存, 该配置仅在 BETA 存储格式时生效
- 默认值: false

disk\_stat\_monitor\_interval

- 描述: 磁盘状态检查时间间隔
- 默认值: 5 (s)

#### max\_free\_io\_buffers

- 描述：对于每个 io 缓冲区大小，IoMgr 将保留的最大缓冲区数从 1024B 到 8MB 的缓冲区，最多约为 2GB 的缓冲区。
- 默认值：128

#### max\_garbage\_sweep\_interval

- 描述：磁盘进行垃圾清理的最大间隔
- 默认值：3600 (s)

#### max\_percentage\_of\_error\_disk

- 类型：int32
- 描述：存储引擎允许存在损坏硬盘的百分比，损坏硬盘超过改比例后，BE 将会自动退出。
- 默认值：0

#### read\_size

- 描述：读取大小是发送到 os 的读取大小。在延迟和整个过程之间进行权衡，试图让磁盘保持忙碌但不引入寻道。对于 8 MB 读取，随机 io 和顺序 io 的性能相似
- 默认值：8388608

#### min\_garbage\_sweep\_interval

- 描述：磁盘进行垃圾清理的最小间隔
- 默认值：180 (s)

#### pprof\_profile\_dir

- 描述：pprof profile 保存目录
- 默认值：\${DORIS\_HOME}/log

#### small\_file\_dir

- 描述：用于保存 SmallFileMgr 下载的文件目录
- 默认值：\${DORIS\_HOME}/lib/small\_file/

#### user\_function\_dir

- 描述：udf 函数目录
- 默认值：\${DORIS\_HOME}/lib/udf

#### storage\_flood\_stage\_left\_capacity\_bytes

- 描述：数据目录应该剩下的最小存储空间，默认 1G
- 默认值：1073741824

## storage\_flood\_stage\_usage\_percent

- 描述: storage\_flood\_stage\_usage\_percent 和 storage\_flood\_stage\_left\_capacity\_bytes 两个配置限制了数据目录的磁盘容量的最大使用。如果这两个阈值都达到, 则无法将更多数据写入该数据目录。数据目录的最大已用容量百分比
- 默认值: 90 (90%)

## storage\_medium\_migrate\_count

- 描述: 要克隆的线程数
- 默认值: 1

## storage\_page\_cache\_limit

- 描述: 缓存存储页大小
- 默认值: 20%

## storage\_page\_cache\_shard\_size

- 描述: StoragePageCache 的分片大小, 值为  $2^n$  ( $n=0,1,2,\dots$ )。建议设置为接近 BE CPU 核数的值, 可减少 StoragePageCache 的锁竞争。
- 默认值: 16

## index\_page\_cache\_percentage

- 类型: int32
- 描述: 索引页缓存占总页面缓存的百分比, 取值为[0, 100]。
- 默认值: 10

## segment\_cache\_capacity

- Type: int32
- Description: segment 元数据缓存 (以 rowset id 为 key) 的最大 rowset 个数。-1 代表向后兼容取值为  $fd\_number * 2/5$
- Default value: -1

## storage\_strict\_check\_incompatible\_old\_format

- 类型: bool
- 描述: 用来检查不兼容的旧版本格式时是否使用严格的验证方式
  - 配置用来检查不兼容的旧版本格式时是否使用严格的验证方式, 当含有旧版本的 hdr 格式时, 使用严谨的方式时, 程序会打出 fatal log 并且退出运行; 否则, 程序仅打印 warn log.
- 默认值: true
- 可动态修改: 否

## sync\_tablet\_meta

- 描述: 存储引擎是否开 sync 保留到磁盘上

- 默认值: false

#### pending\_data\_expire\_time\_sec

- 描述: 存储引擎保留的未生效数据的最大时长
- 默认值: 1800 (s)

#### ignore\_rowset\_stale\_inconsistent\_delete

- 类型: bool
- 描述: 用来决定当删除过期的合并过的 rowset 后无法构成一致的版本路径时, 是否仍要删除。
  - 合并的过期 rowset 版本路径会在半个小时后进行删除。在异常下, 删除这些版本会出现构造不出查询一致路径的问题, 当配置为 false 时, 程序检查比较严格, 程序会直接报错退出。当配置为 true 时, 程序会正常运行, 忽略这个错误。一般情况下, 忽略这个错误不会对查询造成影响, 仅会在 fe 下发了合并过的版本时出现 -230 错误。
- 默认值: false

#### create\_tablet\_worker\_count

- 描述: BE 创建 tablet 的工作线程数
- 默认值: 3

#### check\_consistency\_worker\_count

- 描述: 计算 tablet 的校验和 (checksum) 的工作线程数
- 默认值: 1

#### max\_tablet\_version\_num

- 类型: int
- 描述: 限制单个 tablet 最大 version 的数量。用于防止导入过于频繁, 或 compaction 不及时导致的大量 version 堆积问题。当超过限制后, 导入任务将被拒绝。
- 默认值: 500

#### number\_tablet\_writer\_threads

- 描述: tablet 写线程数
- 默认值: 16

#### tablet\_map\_shard\_size

- 描述: tablet\_map\_lock 分片大小, 值为  $2^n$ ,  $n=0,1,2,3,4$ , 这是为了更好地管理 tablet
- 默认值: 4

#### tablet\_meta\_checkpoint\_min\_interval\_secs

- 描述: TabletMeta Checkpoint 线程轮询的时间间隔
- 默认值: 600 (s)

#### tablet\_meta\_checkpoint\_min\_new\_rowsets\_num

- 描述: TabletMeta Checkpoint 的最小 Rowset 数目
- 默认值: 10

#### tablet\_stat\_cache\_update\_interval\_second

- 描述: tablet 状态缓存的更新间隔
- 默认值: 300 (s)

#### tablet\_rowset\_stale\_sweep\_time\_sec

- 类型: int64
- 描述: 用来表示清理合并版本的过期时间, 当当前时间 now() 减去一个合并的版本路径中 rowset 最近创建时间大于 tablet\_rowset\_stale\_sweep\_time\_sec 时, 对当前路径进行清理, 删除这些合并过的 rowset, 单位为 s。
  - 当写入过于频繁, 可能会引发 fe 查询不到已经合并过的版本, 引发查询 -230 错误。可以通过调大该参数避免该问题。
- 默认值: 300

#### tablet\_writer\_open\_rpc\_timeout\_sec

- 描述: 在远程 BE 中打开 tablet writer 的 rpc 超时。操作时间短, 可设置短超时时间
  - 导入过程中, 发送一个 Batch (1024 行) 的 RPC 超时时间。默认 60 秒。因为该 RPC 可能涉及多个分片内存块的写盘操作, 所以可能会因为写盘导致 RPC 超时, 可以适当调整这个超时时间来减少超时错误 (如 send batch fail 错误)。同时, 如果调大 write\_buffer\_size 配置, 也需要适当调大这个参数
- 默认值: 60

#### tablet\_writer\_ignore\_eovercrowded

- 类型: bool
- 描述: 写入时可忽略 brpc 的 '[E1011]The server is overcrowded' 错误。
  - 当遇到 '[E1011]The server is overcrowded' 的错误时, 可以调整配置项 brpc\_socket\_max\_unwritten\_bytes, 但这个配置项不能动态调整。所以可通过设置此项为 true 来临时避免写失败。注意, 此配置项只影响写流程, 其他的 rpc 请求依旧会检查是否 overcrowded。
- 默认值: false

#### streaming\_load\_rpc\_max\_alive\_time\_sec

- 描述: TabletsChannel 的存活时间。如果此时通道没有收到任何数据, 通道将被删除。
- 默认值: 1200

#### alter\_tablet\_worker\_count

- 描述: 进行 schema change 的线程数
- 默认值: 3



## alter\_index\_worker\_count

- 描述：进行 index change 的线程数
- 默认值：3

## ignore\_load\_tablet\_failure

- 类型：bool
- 描述：用来决定在有 tablet 加载失败的情况下是否忽略错误，继续启动 be
- 默认值：false

BE 启动时，会对每个数据目录单独启动一个线程进行 tablet header 元信息的加载。默认配置下，如果某个数据目录有 tablet 加载失败，则启动进程会终止。同时会在 be.INFO 日志中看到如下错误信息：

```
load tablets from header failed, failed tablets size: xxx, path=xxx
```

表示该数据目录共有多少 tablet 加载失败。同时，日志中也会有加载失败的 tablet 的具体信息。此时需要人工介入来对错误原因进行排查。排查后，通常有两种方式进行恢复：

1. tablet 信息不可修复，在确保其他副本正常的情况下，可以通过 meta\_tool 工具将错误的 tablet 删除。
2. 将 ignore\_load\_tablet\_failure 设置为 true，则 BE 会忽略这些错误的 tablet，正常启动。

## report\_disk\_state\_interval\_seconds

- 描述：代理向 FE 报告磁盘状态的间隔时间
- 默认值：60 (s)

## result\_buffer\_cancelled\_interval\_time

- 描述：结果缓冲区取消时间
- 默认值：300 (s)

## snapshot\_expire\_time\_sec

- 描述：快照文件清理的间隔
- 默认值：172800 (48 小时)

## compress\_rowbatches

- 类型：bool
- 描述：序列化 RowBatch 时是否使用 Snappy 压缩算法进行数据压缩
- 默认值：true

## jvm\_max\_heap\_size

- 类型：string
- 描述：BE 使用 JVM 堆内存的最大值，即 JVM 的 -Xmx 参数
- 默认值：1024M

## 日志

### sys\_log\_dir

- 类型: string
- 描述: BE 日志数据的存储目录
- 默认值: \${DORIS\_HOME}/log

### sys\_log\_level

- 描述: 日志级别, INFO < WARNING < ERROR < FATAL
- 默认值: INFO

### sys\_log\_roll\_mode

- 描述: 日志拆分的大小, 每 1G 拆分一个日志文件
- 默认值: SIZE-MB-1024

### sys\_log\_roll\_num

- 描述: 日志文件保留的数目
- 默认值: 10

### sys\_log\_verbose\_level

- 描述: 日志显示的级别, 用于控制代码中 VLOG 开头的日志输出
- 默认值: 10

### sys\_log\_verbose\_modules

- 描述: 日志打印的模块, 写 olap 就只打印 olap 模块下的日志
- 默认值: 空

### aws\_log\_level

- 类型: int32
- 描述: AWS SDK 的日志级别

```
Off = 0,
Fatal = 1,
Error = 2,
Warn = 3,
Info = 4,
Debug = 5,
Trace = 6
```

- 默认值: 3

## log\_buffer\_level

- 描述：日志刷盘的策略，默认保持在内存中
- 默认值：空

## 其他

### report\_tablet\_interval\_seconds

- 描述：代理向 FE 报告 olap 表的间隔时间
- 默认值：60 (s)

### report\_task\_interval\_seconds

- 描述：代理向 FE 报告任务签名的间隔时间
- 默认值：10 (s)

### periodic\_counter\_update\_period\_ms

- 描述：更新速率计数器和采样计数器的周期
- 默认值：500 (ms)

### enable\_metric\_calculator

- 描述：如果设置为 true，metric calculator 将运行，收集 BE 相关指标信息，如果设置成 false 将不运行
- 默认值：true

### enable\_system\_metrics

- 描述：用户控制打开和关闭系统指标
- 默认值：true

### enable\_token\_check

- 描述：用于向前兼容，稍后将被删除
- 默认值：true

### max\_runnings\_transactions\_per\_txn\_map

- 描述：txn 管理器中每个 txn\_partition\_map 的最大 txns 数，这是一种自我保护，以避免在管理器中保存过多的 txns
- 默认值：2000

### max\_download\_speed\_kbps

- 描述：最大下载速度限制

- 默认值: 50000 (kb/s)

`download_low_speed_time`

- 描述: 下载时间限制
- 默认值: 300 (s)

`download_low_speed_limit_kbps`

- 描述: 下载最低限速
- 默认值: 50 (KB/s)

`doris_cgroups`

- 描述: 分配给 doris 的 cgroups
- 默认值: 空

`priority_queue_remaining_tasks_increased_frequency`

- 描述: BlockingPriorityQueue 中剩余任务的优先级频率增加
- 默认值: 512

`jdbc_drivers_dir`

- 描述: 存放 jdbc driver 的默认目录。
- 默认值: \${DORIS\_HOME}/jdbc\_drivers

`enable_parse_multi_dimension_array`

- 描述: 在动态表中是否解析多维数组, 如果是 false 遇到多维数组则会报错。
- 默认值: true

`enable_simdjson_reader`

- 描述: 是否在导入 json 数据时用 simdjson 来解析。
- 默认值: true

`enable_query_memory_overcommit`

- 描述: 如果为 true, 则当内存未超过 `exec_mem_limit` 时, 查询内存将不受限制; 当进程内存超过 `exec_mem_limit` 且大于 2GB 时, 查询会被取消。如果为 false, 则在使用的内存超过 `exec_mem_limit` 时取消查询。
- 默认值: true

## user\_files\_secure\_path

- 描述: local 表函数查询的文件的存储目录。
- 默认值: \${DORIS\_HOME}

## brpc\_streaming\_client\_batch\_bytes

- 描述: brpc streaming 客户端发送数据时的攒批大小 (字节)
- 默认值: 262144

## grace\_shutdown\_wait\_seconds

- 描述: 在云原生的部署模式下, 为了节省资源一个 BE 可能会被频繁的加入集群或者从集群中移除。如果在这个 BE 上有正在运行的 Query, 那么这个 Query 会失败。用户可以使用 stop\_be.sh -grace 的方式来关闭一个 BE 节点, 此时 BE 会等待当前正在这个 BE 上运行的所有查询都结束才会退出。同时, 在这个时间范围内 FE 也不会分发新的 query 到这个机器上。如果超过 grace\_shutdown\_wait\_seconds 这个阈值, 那么 BE 也会直接退出, 防止一些查询长期不退出导致节点没法快速下掉的情况。
- 默认值: 120

## enable\_java\_support

- Description: BE 是否开启使用 java-jni, 开启后允许 c++ 与 java 之间的相互调用。目前已经支持 hudi、java-udf、jdbc、max-compute、paimon、preload、avro
- Default value: true

## be\_thrift\_max\_pkg\_bytes

- 描述: be 节点 thrift 端口最大接收包大小 (字节)
- 默认值: 20000000

## default\_tzfiles\_path

- 描述: Doris 自带的时区数据库。如果系统目录下未找到时区文件, 则启用该目录下的数据。
- 默认值: "\${DORIS\_HOME}/zoneinfo"

# 用户配置项

该文档主要介绍了 User 级别的相关配置项。User 级别的配置生效范围为单个用户。每个用户都可以设置自己的 User property。相互不影响。

## 查看配置项

FE 启动后，在 MySQL 客户端，通过下面命令查看 User 的配置项：

```
SHOW PROPERTY [FOR user] [LIKE key pattern]
```

具体语法可通过命令：help show property; 查询。

## 设置配置项

FE 启动后，在 MySQL 客户端，通过下面命令修改 User 的配置项：

```
SET PROPERTY [FOR 'user'] 'key' = 'value' [, 'key' = 'value']
```

具体语法可通过命令：help set property; 查询。

User 级别的配置项只会对指定用户生效，并不会影响其他用户的配置。

## 应用举例

### 1. 修改用户 Billie 的 max\_user\_connections

通过 SHOW PROPERTY FOR 'Billie' LIKE '%max\_user\_connections%'; 查看 Billie 用户当前的最大连接数为 100。

通过 SET PROPERTY FOR 'Billie' 'max\_user\_connections' = '200'; 修改 Billie 用户的当前最大连接数到 200。

## 配置项列表

### max\_user\_connections

用户最大的连接数，默认值为100。一般情况不需要更改该参数，除非查询的并发数超过了默认值。

### max\_query\_instances

用户同一时间点可使用的instance个数，默认是-1，小于等于0将会使用配置default\_max\_query\_instances。

**resource**

**quota**

**default\_load\_cluster**

**load\_cluster**

# 审计日志插件

Doris 的审计日志插件是在 FE 的插件框架基础上开发的。是一个可选插件。用户可以在运行时安装或卸载这个插件。

该插件可以将 FE 的审计日志定期的导入到指定 Doris 集群中，以方便用户通过 SQL 对审计日志进行查看和分析。

## 编译、配置和部署

### FE 配置

审计日志插件框架在 Doris 中是默认开启的，由 FE 的配置 `plugin_enable` 控制

### AuditLoader 配置

#### 1. 下载 Audit Loader 插件

Audit Loader 插件在 Doris 的发行版中默认提供，通过 [DOWNLOAD](#) 下载 Doris 安装包解压并进入目录后即可在 `extensions/audit_loader` 子目录下找到 `auditloader.zip` 文件。

#### 2. 解压安装包

```
unzip auditloader.zip
```

解压生成以下文件：

- `auditloader.jar`：插件代码包。
- `plugin.properties`：插件属性文件。
- `plugin.conf`：插件配置文件。

您可以将这个文件放置在一个 http 服务器上，或者拷贝 `auditloader.zip` (或者解压 `auditloader.zip`) 到所有 FE 的指定目录下。这里我们使用后者。

该插件的安装可以参阅 [INSTALL](#)

执行 `install` 后会自动生成 AuditLoader 目录

#### 3. 修改 plugin.conf

以下配置可供修改：

- `frontend_host_port`：FE 节点 IP 地址和 HTTP 端口，格式为 `:<端口>`。默认值为 `127.0.0.1:8030`。
- `database`：审计日志库名。
- `audit_log_table`：审计日志表名。
- `slow_log_table`：慢查询日志表名。



- `enable_slow_log`: 是否开启慢查询日志导入功能。默认值为 `false`。
- `user`: 集群用户名。该用户必须具有对应表的 `INSERT` 权限。
- `password`: 集群用户密码。

#### 4. 重新打包 Audit Loader 插件

```
zip -r -q -m auditloader.zip auditloader.jar plugin.properties plugin.conf
```

### 创建库表

在 Doris 中，需要创建审计日志的库和表，表结构如下：

若需开启慢查询日志导入功能，还需要额外创建慢表 `doris_slow_log_tbl__`，其表结构与 `doris_audit_log_tbl__` 一致。

其中 `dynamic_partition` 属性根据自己的需要，选择审计日志保留的天数。

```
create database doris_audit_db__;

create table doris_audit_db__.doris_audit_log_tbl__
(
 query_id varchar(48) comment "Unique query id",
 `time` datetime not null comment "Query start time",
 client_ip varchar(32) comment "Client IP",
 user varchar(64) comment "User name",
 catalog varchar(128) comment "Catalog of this query",
 db varchar(96) comment "Database of this query",
 state varchar(8) comment "Query result state. EOF, ERR, OK",
 error_code int comment "Error code of failing query.",
 error_message string comment "Error message of failing query.",
 query_time bigint comment "Query execution time in millisecond",
 scan_bytes bigint comment "Total scan bytes of this query",
 scan_rows bigint comment "Total scan rows of this query",
 return_rows bigint comment "Returned rows of this query",
 stmt_id int comment "An incremental id of statement",
 is_query tinyint comment "Is this statemt a query. 1 or 0",
 frontend_ip varchar(32) comment "Frontend ip of executing this statement",
 cpu_time_ms bigint comment "Total scan cpu time in millisecond of this query",
 sql_hash varchar(48) comment "Hash value for this query",
 sql_digest varchar(48) comment "Sql digest for this query",
 peak_memory_bytes bigint comment "Peak memory bytes used on all backends of this query",
 stmt string comment "The original statement, trimmed if longer than 2G"
) engine=OLAP
duplicate key(query_id, `time`, client_ip)
partition by range(`time`) ()
distributed by hash(query_id) buckets 1
properties(
 "dynamic_partition.time_unit" = "DAY",
 "dynamic_partition.start" = "-30",
 "dynamic_partition.end" = "3",
 "dynamic_partition.prefix" = "p",
 "dynamic_partition.buckets" = "1",
 "dynamic_partition.enable" = "true",
 "replication_num" = "3"
);

create table doris_audit_db__.doris_slow_log_tbl__
```

```
(
 query_id varchar(48) comment "Unique query id",
 `time` datetime not null comment "Query start time",
 client_ip varchar(32) comment "Client IP",
 user varchar(64) comment "User name",
 catalog varchar(128) comment "Catalog of this query",
 db varchar(96) comment "Database of this query",
 state varchar(8) comment "Query result state. EOF, ERR, OK",
 error_code int comment "Error code of failing query.",
 error_message string comment "Error message of failing query.",
 query_time bigint comment "Query execution time in millisecond",
 scan_bytes bigint comment "Total scan bytes of this query",
 scan_rows bigint comment "Total scan rows of this query",
 return_rows bigint comment "Returned rows of this query",
 stmt_id int comment "An incremental id of statement",
 is_query tinyint comment "Is this statemt a query. 1 or 0",
 frontend_ip varchar(32) comment "Frontend ip of executing this statement",
 cpu_time_ms bigint comment "Total scan cpu time in millisecond of this query",
 sql_hash varchar(48) comment "Hash value for this query",
 sql_digest varchar(48) comment "Sql digest for this query",
 peak_memory_bytes bigint comment "Peak memory bytes used on all backends of this query",
 stmt string comment "The original statement, trimmed if longer than 2G "
) engine=OLAP
duplicate key(query_id, `time`, client_ip)
partition by range(`time`) ()
distributed by hash(query_id) buckets 1
properties(
 "dynamic_partition.time_unit" = "DAY",
 "dynamic_partition.start" = "-30",
 "dynamic_partition.end" = "3",
 "dynamic_partition.prefix" = "p",
 "dynamic_partition.buckets" = "1",
 "dynamic_partition.enable" = "true",
 "replication_num" = "3"
);
```

上面表结构中：**stmt string**，这个只能在 0.15 及之后版本中使用，之前版本，字段类型使用 **varchar**

## 部署

您可以将 打包好的 auditloader.zip 放置在一个 http 服务器上，或者拷贝auditloader.zip 到所有 FE 的相同指定目录下。

## 安装

通过以下语句安装 Audit Loader 插件：

```
INSTALL PLUGIN FROM [source] [PROPERTIES ("key"="value", ...)]
```

详细命令参考：[INSTALL](#)

安装成功后，可以通过 SHOW PLUGINS 看到已经安装的插件，并且状态为 INSTALLED。

完成后，插件会不断的以指定的时间间隔将审计日志插入到这个表中。

# Config Action

---

## Request

```
GET /rest/v1/config/fe/
```

## Description

Config Action 用于获取当前 FE 的配置信息

## Path parameters

无

## Query parameters

- conf\_item

可选参数。返回 FE 的配置信息中的指定项。

## Request body

无

## Response

```
{
 "msg": "success",
 "code": 0,
 "data": {
 "column_names": ["Name", "Value"],
 "rows": [{
 "Value": "DAY",
 "Name": "sys_log_roll_interval"
 }, {
 "Value": "23",
 "Name": "consistency_check_start_time"
 }, {
 "Value": "4096",
 "Name": "max_mysql_service_task_threads_num"
 }, {
 "Value": "1000",
 "Name": "max_unfinished_load_job"
 }, {
 "Value": "100",
 "Name": "max_routine_load_job_num"
 }, {
 "Value": "SYNC",
 "Name": "master_sync_policy"
 }
]
}
```

```
 },
 "count": 0
}
```

返回结果同 System Action。是一个表格的描述。

# HA Action

---

## Request

```
GET /rest/v1/ha
```

## Description

HAAction 用于获取 FE 集群的高可用组信息。

## Path parameters

无

## Query parameters

无

## Request body

无

## Response

```
{
 "msg": "success",
 "code": 0,
 "data": {
 "Observernodes": [],
 "CurrentJournalId": [{
 "Value": 433648,
 "Name": "FrontendRole"
 }],
 "Electablenodes": [{
 "Value": "host1",
 "Name": "host1"
 }],
 "allowedFrontends": [{
 "Value": "name: 192.168.1.1_9213_1597652404352, role: FOLLOWER, 192.168.1.1:9213",
 "Name": "192.168.1.1_9213_1597652404352"
 }],
 "removedFrontends": [],
 "CanRead": [{
 "Value": true,
 "Name": "Status"
 }],
 "databaseNames": [{
 "Value": "433436 ",
 "Name": "DatabaseNames"
 }],
 "FrontendRole": [{
```

```
 "Value": "MASTER",
 "Name": "FrontendRole"
 }},
 "CheckpointInfo": [{
 "Value": 433435,
 "Name": "Version"
 }, {
 "Value": "2020-09-03T02:07:37.000+0000",
 "Name": "lastCheckPointTime"
 }]
},
"count": 0
}
```

# Hardware Info Action

---

## Request

```
GET /rest/v1/hardware_info/fe/
```

## Description

Hardware Info Action 用于获取当前 FE 的硬件信息。

## Path parameters

无

## Query parameters

无

## Request body

无

## Response

```
{
 "msg": "success",
 "code": 0,
 "data": {
 "VersionInfo": {
 "Git": "git://host/core@5bc28f4c36c20c7b424792df662fc988436e679e",
 "Version": "trunk",
 "BuildInfo": "cmy@192.168.1",
 "BuildTime": "二, 05 9月 2019 11:07:42 CST"
 },
 "HarewareInfo": {
 "NetworkParameter": "...",
 "Processor": "...",
 "OS": "...",
 "Memory": "...",
 "FileSystem": "...",
 "NetworkInterface": "...",
 "Processes": "...",
 "Disk": "..."
 }
 },
 "count": 0
}
```

- 其中 HarewareInfo 字段中的各个值的内容，都是以 html 格式展现的硬件信息文本。

# Help Action

---

## Request

GET /rest/v1/help

## Description

用于通过模糊查询获取帮助。

## Path parameters

无

## Query parameters

- query

需要进行匹配的关键词，如 array、select 等。

## Request body

无

## Response

```
{
 "msg": "success",
 "code": 0,
 "data": {"fuzzy": "No Fuzzy Matching Topic", "matching": "No Matching Category"},
 "count": 0
}
```



# Log Action

---

## Request

```
GET /rest/v1/log
```

## Description

GET 用于获取 Doris 最新的一部分 WARNING 日志，POST 方法用于动态设置 FE 的日志级别。

## Path parameters

无

## Query parameters

- add\_verbose

POST 方法可选参数。开启指定 Package 的 DEBUG 级别日志。

- del\_verbose

POST 方法可选参数。关闭指定 Package 的 DEBUG 级别日志。

## Request body

无

## Response

```
GET /rest/v1/log
```

```
{
 "msg": "success",
 "code": 0,
 "data": {
 "LogContents": {
 "logPath": "/home/disk1/cmy/git/doris/core-for-ui/output/fe/log/fe.warn.log",
 "log": "<pre>2020-08-26 15:54:30,081 WARN (UNKNOWN 10.81.85.89_9213_1597652404352(-1)|1)
[Catalog.notifyNewFETypeTransfer():2356] notify new FE type transfer: UNKNOWN</br>2020-08-26 15:54:32,089
WARN (RepNode 10.81.85.89_9213_1597652404352(-1)|61) [Catalog.notifyNewFETypeTransfer():2356] notify new FE
type transfer: MASTER</br>2020-08-26 15:54:35,121 WARN (stateListener|73) [Catalog.replayJournal():2510]
replay journal cost too much time: 2975 replayedJournalId: 232383</br>2020-08-26 15:54:48,117 WARN
(leaderCheckpoint|75) [Catalog.replayJournal():2510] replay journal cost too much time: 2812
replayedJournalId: 232383</br></pre>",
 "showingLast": "603 bytes of log"
 },
 "LogConfiguration": {
 "VerboseNames": "org",
 "AuditNames": "slow_query,query",
```

```
 "Level": "INFO"
 },
 "count": 0
}
```

其中 `data.LogContents.log` 表示最新一部分 `fe.warn.log` 中的日志内容。

```
POST /rest/v1/log?add_verbose=org

{
 "msg": "success",
 "code": 0,
 "data": {
 "LogConfiguration": {
 "VerboseNames": "org",
 "AuditNames": "slow_query,query",
 "Level": "INFO"
 }
 },
 "count": 0
}
```

# Login Action

---

## Request

POST /rest/v1/login

## Description

用于登录服务。

## Path parameters

无

## Query parameters

无

## Request body

无

## Response

- 登录成功

```
{
 "msg": "Login success!",
 "code": 200
}
```

- 登录失败

```
{
 "msg": "Error msg...",
 "code": xxx,
 "data": "Error data...",
 "count": 0
}
```

# Logout Action

---

## Request

```
POST /rest/v1/logout
```

## Description

Logout Action 用于退出当前登录。

## Path parameters

无

## Query parameters

无

## Request body

无

## Response

```
{
 "msg": "OK",
 "code": 0
}
```

# Query Profile Action

---

## Request

```
GET /rest/v1/query_profile/<query_id>
```

## Description

Query Profile Action 用于获取 Query 的 profile

## Path parameters

- <query\_id>

可选参数。当不指定时，返回最新的 query 列表。当指定时，返回指定 query 的 profile。

## Query parameters

无

## Request body

无

## Response

- Not specify <query\_id>

```
GET /rest/v1/query_profile/
{
 "msg": "success",
 "code": 0,
 "data": {
 "href_column": ["Query ID"],
 "column_names": ["Query ID", "User", "Default Db", "Sql Statement", "Query Type", "Start Time", "End Time", "Total", "Query State"],
 "rows": [{
 "User": "root",
 "__hrefPath": ["/query_profile/d73a8a0b004f4b2f-b4829306441913da"],
 "Query Type": "Query",
 "Total": "5ms",
 "Default Db": "default_cluster:db1",
 "Sql Statement": "select * from tbl1",
 "Query ID": "d73a8a0b004f4b2f-b4829306441913da",
 "Start Time": "2020-09-03 10:07:54",
 "Query State": "EOF",
 "End Time": "2020-09-03 10:07:54"
 }, {
 "User": "root",
 "__hrefPath": ["/query_profile/fd706dd066824c21-9d1a63af9f5cb50c"],
```

```

 "Query Type": "Query",
 "Total": "6ms",
 "Default Db": "default_cluster:db1",
 "Sql Statement": "select * from tbl1",
 "Query ID": "fd706dd066824c21-9d1a63af9f5cb50c",
 "Start Time": "2020-09-03 10:07:54",
 "Query State": "EOF",
 "End Time": "2020-09-03 10:07:54"
 }
},
"count": 3
}

```

The returned result is the same as `System.Action`, which is a table description.

- Specify <query\_id>

```
GET /rest/v1/query_profile/<query_id>
```

```
{
 "msg": "success",
 "code": 0,
 "data": "Query:</br> &~Summary:</br>...",
 "count": 0
}
```

data is the text content of the profile.

# Session Action

---

## Request

GET /rest/v1/session

GET /rest/v1/session/all

## Description

Session Action 用于获取当前的会话信息。

## Path parameters

无

## Query parameters

无

## Request body

无

## 获取当前 FE 的会话信息

GET /rest/v1/session

## Response

```
{
 "msg": "success",
 "code": 0,
 "data": {
 "column_names": ["Id", "User", "Host", "Cluster", "Db", "Command", "Time", "State", "Info"],
 "rows": [{
 "User": "root",
 "Command": "Sleep",
 "State": "",
 "Cluster": "default_cluster",
 "Host": "10.81.85.89:31465",
 "Time": "230",
 "Id": "0",
 "Info": "",
 "Db": "db1"
 }]
 },
 "count": 2
}
```

## 获取所有 FE 的会话信息

GET /rest/v1/session/all

### Response

```
{
 "msg": "success",
 "code": 0,
 "data": {
 "column_names": ["FE", "Id", "User", "Host", "Cluster", "Db", "Command", "Time", "State", "Info"],
 "rows": [{
 "FE": "10.14.170.23",
 "User": "root",
 "Command": "Sleep",
 "State": "",
 "Cluster": "default_cluster",
 "Host": "10.81.85.89:31465",
 "Time": "230",
 "Id": "0",
 "Info": "",
 "Db": "db1"
 },
 {
 "FE": "10.14.170.24",
 "User": "root",
 "Command": "Sleep",
 "State": "",
 "Cluster": "default_cluster",
 "Host": "10.81.85.88:61465",
 "Time": "460",
 "Id": "1",
 "Info": "",
 "Db": "db1"
 }
],
 "count": 2
}
```

返回结果同 System Action。是一个表格的描述。



# System Action

## Request

```
GET /rest/v1/system
```

## Description

System Action 用于 Doris 内置的 Proc 系统的相关信息。

## Path parameters

无

## Query parameters

- path

可选参数，指定 proc 的 path

## Request body

无

## Response

以 /dbs/10003/10054/partitions/10053/10055 为例：

```
{
 "msg": "success",
 "code": 0,
 "data": {
 "href_columns": ["TabletId", "MetaUrl", "CompactionStatus"],
 "column_names": ["TabletId", "ReplicaId", "BackendId", "SchemaHash", "Version", "VersionHash",
 "LstSuccessVersion", "LstSuccessVersionHash", "LstFailedVersion", "LstFailedVersionHash", "LstFailedTime",
 "DataSize", "RowCount", "State", "LstConsistencyCheckTime", "CheckVersion", "CheckVersionHash",
 "VersionCount", "PathHash", "MetaUrl", "CompactionStatus"],
 "rows": [{
 "SchemaHash": "1294206575",
 "LstFailedTime": "\\N",
 "LstFailedVersion": "-1",
 "MetaUrl": "URL",
 "__hrefPaths": ["http://192.168.100.100:8030/rest/v1/system?
path=/dbs/10003/10054/partitions/10053/10055/10056", "http://192.168.100.100:8043/api/meta/header/10056",
"http://192.168.100.100:8043/api/compaction/show?tablet_id=10056"],
 "CheckVersionHash": "-1",
 "ReplicaId": "10057",
 "VersionHash": "4611804212003004639",
 "LstConsistencyCheckTime": "\\N",
 "LstSuccessVersionHash": "4611804212003004639",
```

```
 "CheckVersion": "-1",
 "Version": "6",
 "VersionCount": "2",
 "State": "NORMAL",
 "BackendId": "10032",
 "DataSize": "776",
 "LstFailedVersionHash": "0",
 "LstSuccessVersion": "6",
 "CompactionStatus": "URL",
 "TabletId": "10056",
 "PathHash": "-3259732870068082628",
 "RowCount": "21"
 }
},
"count": 1
}
```

其中 `data` 部分的 `column_names` 是表头信息，`href_columns` 表示表中的哪些列是超链接列。`rows` 数组中的每个元素表示一行。其中 `__hrefPaths` 不是表数据，而是超链接列的链接 URL，和 `href_columns` 中的列一一对应。

# Colocate Meta Action

---

## Request

GET /api/colocate POST/DELETE /api/colocate/group\_stable POST /api/colocate/bucketseq

## Description

获取/修改 colocate group 信息。

## Path parameters

无

## Query parameters

- db\_id  
指定数据库 id
- group\_id  
指定组 id

## Request body

无

## Response

TO DO

# Meta Action

---

```
GET /image
GET /info
GET /version
GET /put
GET /journal_id
GET /role
GET /check
GET /dump
```

## Description

这是一组 FE 元数据相关的 API，除了 /dump 以外，都为 FE 节点之间内部通讯用。

## Path parameters

TODO

## Query parameters

TODO

## Request body

TODO

## Response

TODO

# Cluster Action

---

## Request

GET /rest/v2/manager/cluster/cluster\_info/conn\_info

## 集群连接信息

GET /rest/v2/manager/cluster/cluster\_info/conn\_info

## 描述

用于获取集群 http、mysql 连接信息。

## Path parameters

无

## Query parameters

无

## Request body

无

## Response

```
{
 "msg": "success",
 "code": 0,
 "data": {
 "http": [
 "fe_host:http_ip"
],
 "mysql": [
 "fe_host:query_ip"
]
 },
 "count": 0
}
```

## 举例s

```
GET /rest/v2/manager/cluster/cluster_info/conn_info

Response:
{
```

```
"msg": "success",
"code": 0,
"data": {
 "http": [
 "127.0.0.1:8030"
],
 "mysql": [
 "127.0.0.1:9030"
]
},
"count": 0
}
```

# Node Action

---

## Request

GET /rest/v2/manager/node/frontends

GET /rest/v2/manager/node/backends

GET /rest/v2/manager/node/brokers

GET /rest/v2/manager/node/configuration\_name

GET /rest/v2/manager/node/node\_list

POST /rest/v2/manager/node/configuration\_info

POST /rest/v2/manager/node/set\_config/fe

POST /rest/v2/manager/node/set\_config/be

POST /rest/v2/manager/node/{action}/be

POST /rest/v2/manager/node/{action}/fe

## 获取 fe, be, broker 节点信息

GET /rest/v2/manager/node/frontends

GET /rest/v2/manager/node/backends

GET /rest/v2/manager/node/brokers

## 描述

用于获取集群获取 fe, be, broker 节点信息。

## Response

```
frontends:
{
 "msg": "success",
 "code": 0,
 "data": {
 "column_names": [
 "Name",
 "IP",
 "HostName",
 "EditLogPort",
 "HttpPort",
 "QueryPort",
 "RpcPort",
 "ArrowFlightSqlPort",
```

```

 "Role",
 "IsMaster",
 "ClusterId",
 "Join",
 "Alive",
 "ReplayedJournalId",
 "LastHeartbeat",
 "IsHelper",
 "ErrMsg",
 "Version"
],
 "rows": [
 [
 ...
]
]
},
"count": 0
}

```

```

backends:
{
 "msg": "success",
 "code": 0,
 "data": {
 "column_names": [
 "BackendId",
 "Cluster",
 "IP",
 "HostName",
 "HeartbeatPort",
 "BePort",
 "HttpPort",
 "BrpcPort",
 "LastStartTime",
 "LastHeartbeat",
 "Alive",
 "SystemDecommissioned",
 "ClusterDecommissioned",
 "TabletNum",
 "DataUsedCapacity",
 "AvailCapacity",
 "TotalCapacity",
 "UsedPct",
 "MaxDiskUsedPct",
 "ErrMsg",
 "Version",
 "Status"
],
 "rows": [
 [
 ...
]
]
 },
 "count": 0
}

```

```

brokers:
{
 "msg": "success",
 "code": 0,

```



```

 "data": {
 "column_names": [
 "Name",
 "IP",
 "HostName",
 "Port",
 "Alive",
 "LastStartTime",
 "LastUpdateTime",
 "ErrMsg"
],
 "rows": [
 [
 ...
]
]
 },
 "count": 0
 }
}

```

## 获取节点配置信息

GET /rest/v2/manager/node/configuration\_name

GET /rest/v2/manager/node/node\_list

POST /rest/v2/manager/node/configuration\_info

## 描述

configuration\_name 用于获取节点配置项名称。

node\_list 用于获取节点列表。

configuration\_info 用于获取节点配置详细信息。

## Query parameters

GET /rest/v2/manager/node/configuration\_name

无

GET /rest/v2/manager/node/node\_list

无

POST /rest/v2/manager/node/configuration\_info

- type 值为 fe 或 be，用于指定获取 fe 的配置信息或 be 的配置信息。

## Request body

GET /rest/v2/manager/node/configuration\_name

无

GET /rest/v2/manager/node/node\_list

无

POST /rest/v2/manager/node/configuration\_info

```
{
 "conf_name": [
 ""
],
 "node": [
 ""
]
}
```

若不带body，body中的参数都使用默认值。

conf\_name 用于指定返回哪些配置项的信息，默认返回所有配置项信息；

node 用于指定返回哪些节点的配置项信息，默认为全部fe节点或be节点配置项信息。

## Response

GET /rest/v2/manager/node/configuration\_name

```
{
 "msg": "success",
 "code": 0,
 "data": {
 "backend": [
 ""
],
 "frontend": [
 ""
]
 },
 "count": 0
}
```

GET /rest/v2/manager/node/node\_list

```
{
 "msg": "success",
 "code": 0,
 "data": {
 "backend": [
 ""
],
 "frontend": [
 ""
]
 },
 "count": 0
}
```

POST /rest/v2/manager/node/configuration\_info?type=fe

```
{
 "msg": "success",
 "code": 0,
 "data": {
 "column_names": [
 "配置项",
 "节点",
]
 }
}
```

```

 "节点类型",
 "配置值类型",
 "MasterOnly",
 "配置值",
 "可修改"
],
 "rows": [
 [
 ""
]
]
},
"count": 0
}

```

POST /rest/v2/manager/node/configuration\_info?type=be

```

{
 "msg": "success",
 "code": 0,
 "data": {
 "column_names": [
 "配置项",
 "节点",
 "节点类型",
 "配置值类型",
 "配置值",
 "可修改"
],
 "rows": [
 [
 ""
]
]
 },
 "count": 0
}

```

## 举例s

1. 获取 fe agent\_task\_resend\_wait\_time\_ms 配置项信息：

POST /rest/v2/manager/node/configuration\_info?type=fe

body: { "conf\_name": [ "agent\_task\_resend\_wait\_time\_ms" ] }

Response: { "msg": "success", "code": 0, "data": { "column\_names": [ "配置项", "节点", "节点类型", "配置值类型", "MasterOnly", "配置值", "可修改" ], "rows": [ [ "agent\_task\_resend\_wait\_time\_ms", "127.0.0.1:8030", "FE", "long", "true", "50000", "true" ] ] }, "count": 0 }

## 修改配置值

POST /rest/v2/manager/node/set\_config/fe

POST /rest/v2/manager/node/set\_config/be

## 描述

用于修改 fe 或 be 节点配置值

### Request body

```
{
 "config_name":{
 "node":[
 ""
],
 "value": "",
 "persist":
 }
}
```

config\_name为对应的配置项;

node为关键字, 表示要修改的节点列表;

value为配置的值;

persist为 true 表示永久修改, false 表示临时修改。永久修改重启后能生效, 临时修改重启后失效。

### Response

GET /rest/v2/manager/node/configuration\_name

```
{
 "msg": "",
 "code": 0,
 "data": {
 "failed": [
 {
 "config_name": "name",
 "value": "",
 "node": "",
 "err_info": ""
 }
]
 },
 "count": 0
}
```

failed 表示修改失败的配置信息。

## 举例s

1. 修改 fe 127.0.0.1:8030 节点中 agent\_task\_resend\_wait\_time\_ms 和 alter\_table\_timeout\_second 配置值:

```
POST /rest/v2/manager/node/set_config/fe body: { "agent_task_resend_wait_time_ms":{ "node":
["127.0.0.1:8030"], "value":"10000", "persist":"true" },
"alter_table_timeout_second":{ "node":["127.0.0.1:8030"], "value":"true",
"persist":"true" } }
```

Response: `` { "msg": "success", "code": 0, "data": { "failed": [ { "config\_name":  
"alter\_table\_timeout\_second", "node": "10.81.85.89:8837", "err\_info": "Unsupported configuration value

```
type.", "value": "true" }] }, "count": 0 }
```

agent\_task\_resend\_wait\_time\_ms 配置值修改成功, alter\_table\_timeout\_second 修改失败。 ``

## 操作 be 节点

POST /rest/v2/manager/node/{action}/be

## 描述

用于添加/删除/下线 be 节点

action: ADD/DROP/DECOMMISSION

## Request body

```
{
 "hostPorts": ["127.0.0.1:9050"],
 "properties": {
 "tag.location": "test"
 }
}
```

hostPorts 需要操作的一组 be 节点地址 ip:heartbeat\_port

properties 添加节点时传入的配置, 目前只用于配置 tag, 不传使用默认 tag

## Response

```
{
 "msg": "Error",
 "code": 1,
 "data": "errCode = 2, detailMessage = Same backend already exists[127.0.0.1:9050]",
 "count": 0
}
```

msg Success/Error

code 0/1

data ""/报错信息

## 举例s

### 1. 添加 be 节点

post /rest/v2/manager/node/ADD/be Request body { "hostPorts": ["127.0.0.1:9050"] }

Response { "msg": "success", "code": 0, "data": null, "count": 0 }

### 2. 删除 be 节点

post /rest/v2/manager/node/DROP/be Request body { "hostPorts": ["127.0.0.1:9050"] }

Response { "msg": "success", "code": 0, "data": null, "count": 0 }

### 3. 下线 be 节点

```
post /rest/v2/manager/node/DECOMMISSION/be Request body { "hostPorts":
["127.0.0.1:9050"] }
```

```
Response { "msg": "success", "code": 0, "data": null, "count": 0 }
```

## 操作 fe 节点

POST /rest/v2/manager/node/{action}/fe

## 描述

用于添加/删除 fe 节点

action: ADD/DROP

## Request body

```
{
 "role": "FOLLOWER",
 "hostPort": "127.0.0.1:9030"
}

role FOLLOWER/OBSERVER
hostPort 需要操作的 fe 节点地址 ip:edit_log_port
```

## Response

```
{
 "msg": "Error",
 "code": 1,
 "data": "errCode = 2, detailMessage = frontend already exists name: 127.0.0.1:9030_1670495889415, role:
FOLLOWER, 127.0.0.1:9030",
 "count": 0
}

msg Success/Error
code 0/1
data ""/报错信息
```

## 举例s

### 1. 添加 FOLLOWER 节点

```
post /rest/v2/manager/node/ADD/fe Request body { "role": "FOLLOWER", "hostPort":
"127.0.0.1:9030" }
```

```
Response { "msg": "success", "code": 0, "data": null, "count": 0 }
```

### 2. 删除 FOLLOWER 节点

```
post /rest/v2/manager/node/DROP/fe Request body { "role": "FOLLOWER", "hostPort":
"127.0.0.1:9030" }
```

```
Response { "msg": "success", "code": 0, "data": null, "count": 0 }
```

# Query Profile Action

---

## Request

GET /rest/v2/manager/query/query\_info

GET /rest/v2/manager/query/trace/{trace\_id}

GET /rest/v2/manager/query/sql/{query\_id}

GET /rest/v2/manager/query/profile/text/{query\_id}

GET /rest/v2/manager/query/profile/graph/{query\_id}

GET /rest/v2/manager/query/profile/json/{query\_id}

GET /rest/v2/manager/query/profile/fragments/{query\_id}

GET /rest/v2/manager/query/current\_queries

GET /rest/v2/manager/query/kill/{query\_id}

## 获取查询信息

GET /rest/v2/manager/query/query\_info

## 描述

可获取集群所有 fe 节点 select 查询信息。

## Query parameters

- query\_id

可选，指定返回查询的 queryID，默认返回所有查询的信息。

- search

可选，指定返回包含字符串的查询信息，目前仅进行字符串匹配。

- is\_all\_node

可选，若为 true 则返回所有 fe 节点的查询信息，若为 false 则返回当前 fe 节点的查询信息。默认为 true。

## Response

```
{
 "msg": "success",
 "code": 0,
```



```

 "data": {
 "column_names": [
 "Query ID",
 "FE节点",
 "查询用户",
 "执行数据库",
 "Sql",
 "查询类型",
 "开始时间",
 "结束时间",
 "执行时长",
 "状态"
],
 "rows": [
 [
 ...
]
]
 },
 "count": 0
 }
}

```

Admin 和 Root 用户可以查看所有 Query。普通用户仅能查看自己发送的 Query。

## 举例s

GET /rest/v2/manager/query/query\_info

```

{
 "msg": "success",
 "code": 0,
 "data": {
 "column_names": [
 "Query ID",
 "FE节点",
 "查询用户",
 "执行数据库",
 "Sql",
 "查询类型",
 "开始时间",
 "结束时间",
 "执行时长",
 "状态"
],
 "rows": [
 [
 "d7c93d9275334c35-9e6ac5f295a7134b",
 "127.0.0.1:8030",
 "root",
 "default_cluster:testdb",
 "select c.id, c.name, p.age, p.phone, c.date, c.cost from cost c join people p on c.id = p.id
where p.age > 20 order by c.id",
 "Query",
 "2021-07-29 16:59:12",
 "2021-07-29 16:59:12",
 "109ms",
 "EOF"
]
]
 },
}

```

```
"count": 0
}
```

## 通过 Trace Id 获取 Query Id

GET /rest/v2/manager/query/trace\_id/{trace\_id}

### 描述

通过 Trace Id 获取 Query Id.

在执行一个 Query 前, 先设置一个唯一的 trace id:

```
set session_context="trace_id:your_trace_id";
```

在同一个 Session 链接内执行 Query 后, 可以通过 trace id 获取 query id.

### Path parameters

- {trace\_id}

用户设置的 trace id.

### Query parameters

### Response

```
{
 "msg": "success",
 "code": 0,
 "data": "fb1d9737de914af1-a498d5c5dec638d3",
 "count": 0
}
```

Admin 和 Root 用户可以查看所有 Query。普通用户仅能查看自己发送的 Query。若指定 trace id 不存在或无权限, 则返回 Bad Request:

```
{
 "msg": "Bad Request",
 "code": 403,
 "data": "error messages",
 "count": 0
}
```

## 获取指定查询的 sql 和文本 profile

GET /rest/v2/manager/query/sql/{query\_id}

GET /rest/v2/manager/query/profile/text/{query\_id}

## 描述

用于获取指定 query id 的 sql 和 profile 文本。

### Path parameters

- query\_id  
query id.

### Query parameters

- is\_all\_node

可选，若为 true 则在所有 fe 节点中查询指定 query id 的信息，若为 false 则在当前连接的 fe 节点中查询指定 query id 的信息。默认为 true。

## Response

```
{
 "msg": "success",
 "code": 0,
 "data": {
 "sql": ""
 },
 "count": 0
}
```

```
{
 "msg": "success",
 "code": 0,
 "data": {
 "profile": ""
 },
 "count": 0
}
```

Admin 和 Root 用户可以查看所有 Query。普通用户仅能查看自己发送的 Query。若指定 query id 不存在或无权限，则返回 Bad Request：

```
{
 "msg": "Bad Request",
 "code": 403,
 "data": "error messages",
 "count": 0
}
```

## 举例s

1. 获取 sql：

```
GET /rest/v2/manager/query/sql/d7c93d9275334c35-9e6ac5f295a7134b
```

Response:

```
{
 "msg": "success",
 "code": 0,
 "data": {
 "sql": "select c.id, c.name, p.age, p.phone, c.date, c.cost from cost c join people p on c.id
= p.id where p.age > 20 order by c.id"
 },
 "count": 0
}
```

## 获取指定查询 fragment 和 instance 信息

```
GET /rest/v2/manager/query/profile/fragments/{query_id}
```

### 描述

用于获取指定 query id 的 fragment 名称, instance id、主机 IP 及端口和执行时长。

### Path parameters

- query\_id

query id.

### Query parameters

- is\_all\_node

可选, 若为 true 则在所有 fe 节点中查询指定 query id 的信息, 若为 false 则在当前连接的 fe 节点中查询指定 query id 的信息。默认为 true。

### Response

```
{
 "msg": "success",
 "code": 0,
 "data": [
 {
 "fragment_id": "",
 "time": "",
 "instance_id": {
 "": {
 "host": "",
 "active_time": ""
 }
 }
 }
],
 "count": 0
}
```

Admin 和 Root 用户可以查看所有 Query。普通用户仅能查看自己发送的 Query。若指定 query id 不存在或无权限，则返回 Bad Request：

```
{
 "msg": "Bad Request",
 "code": 403,
 "data": "error messages",
 "count": 0
}
```

## 举例s

GET /rest/v2/manager/query/profile/fragments/d7c93d9275334c35-9e6ac5f295a7134b

Response:

```
{
 "msg": "success",
 "code": 0,
 "data": [
 {
 "fragment_id": "0",
 "time": "36.169ms",
 "instance_id": {
 "d7c93d9275334c35-9e6ac5f295a7134e": {
 "host": "172.19.0.4:9060",
 "active_time": "36.169ms"
 }
 }
 },
 {
 "fragment_id": "1",
 "time": "20.710ms",
 "instance_id": {
 "d7c93d9275334c35-9e6ac5f295a7134c": {
 "host": "172.19.0.5:9060",
 "active_time": "20.710ms"
 }
 }
 },
 {
 "fragment_id": "2",
 "time": "7.83ms",
 "instance_id": {
 "d7c93d9275334c35-9e6ac5f295a7134d": {
 "host": "172.19.0.6:9060",
 "active_time": "7.83ms"
 },
 "d7c93d9275334c35-9e6ac5f295a7134f": {
 "host": "172.19.0.7:9060",
 "active_time": "10.873ms"
 }
 }
 }
],
 "count": 0
}
```

## 获取指定 query id 树状 profile 信息

GET /rest/v2/manager/query/profile/graph/{query\_id}

### 描述

获取指定 query id 树状 profile 信息，同 show query profile 指令。

### Path parameters

- query\_id  
query id.

### Query parameters

- fragment\_id 和 instance\_id

可选，这两个参数需同时指定或同时不指定。

同时不指定则返回 profile 简易树形图，相当于show query profile '/query\_id';

同时指定则返回指定 instance 详细 profile 树形图，相当于show query profile '/query\_id/fragment\_id/instance\_id'.

- is\_all\_node

可选，若为 true 则在所有 fe 节点中查询指定 query id 的信息，若为 false 则在当前连接的 fe 节点中查询指定 query id 的信息。默认为 true。

### Response

```
{
 "msg": "success",
 "code": 0,
 "data": {
 "graph":""
 },
 "count": 0
}
```

Admin 和 Root 用户可以查看所有 Query。普通用户仅能查看自己发送的 Query。若指定 query id 不存在或无权限，则返回 Bad Request:

```
{
 "msg": "Bad Request",
 "code": 403,
 "data": "error messages",
 "count": 0
}
```

## 正在执行的 query

GET /rest/v2/manager/query/current\_queries

### 描述

同 show proc "/current\_query\_stmts", 返回当前正在执行的 query

### Path parameters

### Query parameters

- is\_all\_node

可选, 若为 true 则返回所有 FE 节点当前正在执行的 query 信息。默认为 true。

### Response

```
{
 "msg": "success",
 "code": 0,
 "data": {
 "columnNames": ["Frontend", "QueryId", "ConnectionId", "Database", "User", "ExecTime", "SqlHash",
"Statement"],
 "rows": [
 ["172.19.0.3", "108e47ab438a4560-ab1651d16c036491", "2", "", "root", "6074",
"1a35f62f4b14b9d7961b057b77c3102f", "select sleep(60)"],
 ["172.19.0.11", "3606cad4e34b49c6-867bf6862cacc645", "3", "", "root", "9306",
"1a35f62f4b14b9d7961b057b77c3102f", "select sleep(60)"]
]
 },
 "count": 0
}
```

## 取消 query

POST /rest/v2/manager/query/kill/{query\_id}

### 描述

取消执行连接中正在执行的 query

### Path parameters

- {query\_id}

query id. 你可以通过 trace\_id 接口, 获取 query id。

## Query parameters

## Response

```
{
 "msg": "success",
 "code": 0,
 "data": null,
 "count": 0
}
```



# Backends Action

---

## Request

```
GET /api/backends
```

## Description

Backends Action 返回 Backends 列表，包括 Backend 的 IP、PORT 等信息。

## Path parameters

无

## Query parameters

- `is_alive`

可选参数。是否返回存活的 BE 节点。默认为 `false`，即返回所有 BE 节点。

## Request body

无

## Response

```
{
 "msg": "success",
 "code": 0,
 "data": {
 "backends": [
 {
 "ip": "192.1.1.1",
 "http_port": 8040,
 "is_alive": true
 }
]
 },
 "count": 0
}
```

# Bootstrap Action

---

## Request

GET /api/bootstrap

## Description

用于判断 FE 是否启动完成。当不提供任何参数时，仅返回是否启动成功。如果提供了 token 和 cluster\_id，则返回更多详细信息。

## Path parameters

无

## Query parameters

- cluster\_id  
集群 id。可以在 doris-meta/image/VERSION 文件中查看。
- token  
集群 token。可以在 doris-meta/image/VERSION 文件中查看。

## Request body

无

## Response

- 不提供参数

```
{
 "msg": "OK",
 "code": 0,
 "data": null,
 "count": 0
}
```

code 为 0 表示 FE 节点启动成功。非 0 的错误码表示其他错误。

- 提供 token 和 cluster\_id

```
{
 "msg": "OK",
 "code": 0,
 "data": {
```

```
 "queryPort": 9030,
 "rpcPort": 9020,
 "arrowFlightSqlPort": 9040,
 "maxReplayedJournal": 17287
 },
 "count": 0
}
```

- queryPort 是 FE 节点的 MySQL 协议端口。
- rpcPort 是 FE 节点的 thrift RPC 端口。
- maxReplayedJournal 表示 FE 节点当前回放的最大元数据日志 id。
- arrowFlightSqlPort 是 FE 节点的 Arrow Flight SQL 协议端口。

## Examples

### 1. 不提供参数

```
GET /api/bootstrap
```

```
Response:
{
 "msg": "OK",
 "code": 0,
 "data": null,
 "count": 0
}
```

### 2. 提供 token 和 cluster\_id

```
GET /api/bootstrap?cluster_id=935437471&token=ad87f6dd-c93f-4880-bcdb-8ca8c9ab3031
```

```
Response:
{
 "msg": "OK",
 "code": 0,
 "data": {
 "queryPort": 9030,
 "rpcPort": 9020,
 "arrowFlightSqlPort": 9040,
 "maxReplayedJournal": 17287
 },
 "count": 0
}
```

# Cancel Load Action

---

## Request

POST /api/<db>/\_cancel

## Description

用于取消掉指定 label 的导入任务。执行完成后，会以 Json 格式返回这次导入的相关内容。当前包括以下字段  
Status: 是否成功 cancel Success: 成功 cancel 事务 其他: cancel 失败 Message: 具体的失败信息

## Path parameters

- <db>  
指定数据库名称

## Query parameters

- <label>  
指定导入 label

## Request body

无

## Response

- 取消成功

```
{
 "msg": "OK",
 "code": 0,
 "data": null,
 "count": 0
}
```

- 取消失败

```
{
 "msg": "Error msg...",
 "code": 1,
 "data": null,
 "count": 0
}
```

## Examples

### 1. 取消指定 label 的导入事务

```
POST /api/example_db/_cancel?label=my_label1
```

Response:

```
{
 "msg": "OK",
 "code": 0,
 "data": null,
 "count": 0
}
```

# Check Decommission Action

---

## Request

GET /api/check\_decommission

## Description

用于判断指定的 BE 是否能够被下线。比如判断节点下线后，剩余的节点是否能够满足空间要求和副本数要求等。

## Path parameters

无

## Query parameters

- host\_ports

指定一个或多个 BE，由逗号分隔。如：ip1:port1,ip2:port2,...。

其中 port 为 BE 的 heartbeat port。

## Request body

无

## Response

返回可以被下线的节点列表

```
{
 "msg": "OK",
 "code": 0,
 "data": ["192.168.10.11:9050", "192.168.10.11:9050"],
 "count": 0
}
```

## Examples

1. 查看指定 BE 节点是否可以下线

```
GET /api/check_decommission?host_ports=192.168.10.11:9050,192.168.10.11:9050
```

Response:

```
{
 "msg": "OK",
 "code": 0,
```

```
"data": ["192.168.10.11:9050"],
"count": 0
}
```

# Check Storage Type Action

---

## Request

GET /api/\_check\_storagetype

## Description

用于检查指定数据库下的表的存储格式是否是行存格式。（行存格式已废弃）

## Path parameters

无

## Query parameters

- db  
指定数据库

## Request body

无

## Response

```
{
 "msg": "success",
 "code": 0,
 "data": {
 "tbl2": {},
 "tbl1": {}
 },
 "count": 0
}
```

如果表名后有内容，则会显示存储格式为行存的 base 或者 rollup 表。

## Examples

1. 检查指定数据库下表的存储格式是否为行存

```
GET /api/_check_storagetype
```

Response:

```
{
 "msg": "success",
 "code": 0,
```



```
"data": {
 "tbl2": {},
 "tbl1": {}
},
"count": 0
}
```

# Connection Action

---

## Request

GET /api/connection

## Description

给定一个 connection id，返回这个连接当前正在执行的，或最后一次执行完成的 query id。

connection id 可以通过 MySQL 命令 `show processlist;` 中的 id 列查看。

## Path parameters

无

## Query parameters

- connection\_id  
指定的 connection id

## Request body

无

## Response

```
{
 "msg": "OK",
 "code": 0,
 "data": {
 "query_id": "b52513ce3f0841ca-9cb4a96a268f2dba"
 },
 "count": 0
}
```

## Examples

1. 获取指定 connection id 的 query id

```
GET /api/connection?connection_id=101
```

Response:

```
{
 "msg": "OK",
 "code": 0,
 "data": {
```

```
 "query_id": "b52513ce3f0841ca-9cb4a96a268f2dba"
 },
 "count": 0
}
```

# Extra Basepath Action

---

## Request

GET /api/basepath

## Description

获取 http 的 basepath。

## Path parameters

无

## Query parameters

无

## Request body

无

## Response

```
{
 "msg": "success",
 "code": 0,
 "data": {"enable": false, "path": ""},
 "count": 0
}
```

# Fe Version Info Action

---

## Request

GET /api/fe\_version\_info

## Description

用于获取 fe 节点的版本信息。

## Path parameters

无

## Query parameters

无

## Request body

无

## Response

```
...
{
 "msg": "success",
 "code": 0,
 "data": {
 "feVersionInfo": {
 "dorisBuildVersionPrefix": "doris",
 "dorisBuildVersionMajor": 0,
 "dorisBuildVersionMinor": 0,
 "dorisBuildVersionPatch": 0,
 "dorisBuildVersionRcVersion": "trunk",
 "dorisBuildVersion": "doris-0.0.0-trunk",

 "dorisBuildHash": "git://4b7b503d1cb3/data/doris/doris/be/..@a04f9814fe5a09c0d9e9399fe71cc4d765f8bff1",
 "dorisBuildShortHash": "a04f981",
 "dorisBuildTime": "Fri, 09 Sep 2022 07:57:02 UTC",
 "dorisBuildInfo": "root@4b7b503d1cb3",
 "dorisJavaCompileVersion": "openjdk full version \"1.8.0_332-b09\""
 }
 },
 "count": 0
}
...
```

## Examples

```
```\nGET /api/fe_version_info\n\nResponse:\n{\n  \"msg\":\"success\",\n  \"code\":0,\n  \"data\":{\n    \"feVersionInfo\":{\n      \"dorisBuildVersionPrefix\":\"doris\",\n      \"dorisBuildVersionMajor\":0,\n      \"dorisBuildVersionMinor\":0,\n      \"dorisBuildVersionPatch\":0,\n      \"dorisBuildVersionRcVersion\":\"trunk\",\n      \"dorisBuildVersion\":\"doris-0.0.0-trunk\",\n\n      \"dorisBuildHash\":\"git://4b7b503d1cb3/data/doris/doris/be/./@a04f9814fe5a09c0d9e9399fe71cc4d765f8bff1\",\n      \"dorisBuildShortHash\":\"a04f981\",\n      \"dorisBuildTime\":\"Fri, 09 Sep 2022 07:57:02 UTC\",\n      \"dorisBuildInfo\":\"root@4b7b503d1cb3\",\n      \"dorisJavaCompileVersion\":\"openjdk full version \\\"1.8.0_332-b09\\\"\"\n    }\n  },\n  \"count\":0\n}\n```\n
```

Get DDL Statement Action

Request

GET /api/_get_ddl

Description

用于获取指定表的建表语句、建分区语句和建 rollup 语句。

Path parameters

无

Query parameters

- db
指定数据库
- table
指定表

Request body

无

Response

```
{
  "msg": "OK",
  "code": 0,
  "data": {
    "create_partition": ["ALTER TABLE `tbl1` ADD PARTITION ..."],
    "create_table": ["CREATE TABLE `tbl1` ..."],
    "create_rollup": ["ALTER TABLE `tbl1` ADD ROLLUP ..."]
  },
  "count": 0
}
```

Examples

1. 获取指定表的 DDL 语句

```
GET GET /api/_get_ddl?db=db1&table=tbl1
```

Response

```

{
  "msg": "OK",
  "code": 0,
  "data": {
    "create_partition": [],
    "create_table": ["CREATE TABLE `tbl1` (\n `k1` int(11) NULL COMMENT \"\", \n `k2` int(11) NULL COMMENT \"\"\n) ENGINE=OLAP\nDUPLICATE KEY(`k1`, `k2`)\nCOMMENT \"OLAP\"\nDISTRIBUTED BY HASH(`k1`) BUCKETS 1\nPROPERTIES (\n\"replication_num\" = \"1\", \n\"version_info\" = \"1,0\", \n\"in_memory\" = \"false\", \n\"storage_format\" = \"DEFAULT\"\n);"],
    "create_rollback": []
  },
  "count": 0
}

```


Get Load Info Action

Request

GET /api/<db>/_load_info

Description

用于获取指定 label 的导入作业的信息。

Path parameters

- <db>
指定数据库

Query parameters

- label
指定导入 Label

Request body

无

Response

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "dbName": "default_cluster:db1",
    "tblNames": ["tbl1"],
    "label": "my_label",
    "clusterName": "default_cluster",
    "state": "FINISHED",
    "failMsg": "",
    "trackingUrl": ""
  },
  "count": 0
}
```

Examples

1. 获取指定 label 的导入作业信息

```
GET /api/example_db/_load_info?label=my_label
```

Response

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "dbName": "default_cluster:db1",
    "tblNames": ["tbl1"],
    "label": "my_label",
    "clusterName": "default_cluster",
    "state": "FINISHED",
    "failMsg": "",
    "trackingUrl": ""
  },
  "count": 0
}
```

Get Load State

Request

GET /api/<db>/get_load_state

Description

返回指定 label 的导入事务的状态 执行完毕后，会以 Json 格式返回这次导入的相关内容。当前包括以下字段：
Label: 本次导入的 label，如果没有指定，则为一个 uuid Status: 此命令是否成功执行，Success 表示成功执行
Message: 具体的执行信息 State: 只有在 Status 为 Success 时才有意义 UNKNOWN: 没有找到对应的 Label
PREPARE: 对应的事务已经 prepare，但尚未提交 COMMITTED: 事务已经提交，不能被 cancel VISIBLE: 事务提交，并且数据可见，不能被 cancel ABORTED: 事务已经被 ROLLBACK，导入已经失败

Path parameters

- <db>
指定数据库

Query parameters

- label
指定导入 label

Request body

无

Response

```
{
  "msg": "success",
  "code": 0,
  "data": "VISIBLE",
  "count": 0
}
```

如 label 不存在，则返回：

```
{
  "msg": "success",
  "code": 0,
  "data": "UNKNOWN",
  "count": 0
}
```

Examples

1. 获取指定 label 的导入事务的状态。

```
GET /api/example_db/get_load_state?label=my_label
```

```
{  
  "msg": "success",  
  "code": 0,  
  "data": "VISIBLE",  
  "count": 0  
}
```

Get FE log file

Request

HEAD /api/get_log_file

GET /api/get_log_file

Description

用户可以通过该 HTTP 接口获取 FE 的日志文件。

其中 HEAD 请求用于获取指定日志类型的日志文件列表。GET 请求用于下载指定的日志文件。

Path parameters

无

Query parameters

- type

指定日志类型，支持如下类型：

- fe.audit.log: FE 审计日志

- file

指定的文件名。

Request body

无

Response

- HEAD

```
HTTP/1.1 200 OK
file_infos: {"fe.audit.log":24759,"fe.audit.log.20190528.1":132934}
content-type: text/html
connection: keep-alive
```

返回的 header 中罗列出了当前所有指定类型的日志文件，以及每个文件的大小。

- GET

以文本形式下载指定日志文件

Examples

1. 获取对应类型的日志文件列表

```
HEAD /api/get_log_file?type=fe.audit.log

Response:

HTTP/1.1 200 OK
file_infos: {"fe.audit.log":24759,"fe.audit.log.20190528.1":132934}
content-type: text/html
connection: keep-alive
```

在返回的 header 中，file_infos 字段以 json 格式展示文件列表以及对应文件大小（单位字节）

2. 下载日志文件

```
GET /api/get_log_file?type=fe.audit.log&file=fe.audit.log.20190528.1

Response:

< HTTP/1.1 200
< Vary: Origin
< Vary: Access-Control-Request-Method
< Vary: Access-Control-Request-Headers
< Content-Disposition: attachment;fileName=fe.audit.log
< Content-Type: application/octet-stream;charset=UTF-8
< Transfer-Encoding: chunked

... File Content ...
```

Get Small File Action

Request

GET /api/get_small_file

Description

通过文件 id，下载在文件管理器中的文件。

Path parameters

无

Query parameters

- token

集群的 token。可以在 `doris-meta/image/VERSION` 文件中查看。

- file_id

文件管理器中显示的文件 id。文件 id 可以通过 `SHOW FILE` 命令查看。

Request body

无

Response

```
< HTTP/1.1 200
< Vary: Origin
< Vary: Access-Control-Request-Method
< Vary: Access-Control-Request-Headers
< Content-Disposition: attachment;fileName=ca.pem
< Content-Type: application/json;charset=UTF-8
< Transfer-Encoding: chunked

... File Content ...
```

如有错误，则返回：

```
{
  "msg": "File not found or is not content",
  "code": 1,
  "data": null,
  "count": 0
}
```

Examples

1. 下载指定 id 的文件

```
GET /api/get_small_file?token=98e8c0a6-3a41-48b8-a72b-0432e42a7fe5&file_id=11002
```

Response:

```
< HTTP/1.1 200
< Vary: Origin
< Vary: Access-Control-Request-Method
< Vary: Access-Control-Request-Headers
< Content-Disposition: attachment;fileName=ca.pem
< Content-Type: application/json;charset=UTF-8
< Transfer-Encoding: chunked
```

```
... File Content ...
```


Health Action

Request

GET /api/health

Description

返回集群当前存活的 BE 节点数和宕机的 BE 节点数。

Path parameters

无

Query parameters

无

Request body

无

Response

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "online_backend_num": 10,
    "total_backend_num": 10
  },
  "count": 0
}
```

Meta Info Action

Meta Info Action 用于获取集群内的元数据信息。如数据库列表，表结构等。

数据库列表

Request

```
GET /api/meta/namespaces/<ns_name>/databases
```

描述

获取所有数据库名称列表，按字母序排列。

Path parameters

无

Query parameters

- limit
限制返回的结果行数
- offset
分页信息，需要和 limit 一起使用

Request body

无

Response

```
{
  "msg": "OK",
  "code": 0,
  "data": [
    "db1", "db2", "db3", ...
  ],
  "count": 3
}
```

- data 字段返回数据库名列表。

表列表

Request

```
GET /api/meta/namespaces/<ns_name>/databases/<db_name>/tables
```

描述

获取指定数据库中的表列表，按字母序排列。

Path parameters

- <db_name>
指定数据库名称

Query parameters

- limit
限制返回的结果行数
- offset
分页信息，需要和 limit 一起使用

Request body

无

Response

```
{
  "msg": "OK",
  "code": 0,
  "data": [
    "tbl1", "tbl2", "tbl3", ...
  ],
  "count": 0
}
```

- data 字段返回表名称列表。

表结构信息

Request

```
GET /api/meta/namespaces/<ns_name>/databases/<db_name>/tables/<tbl_name>/schema
```

描述

获取指定数据库中，指定表的表结构信息。

Path parameters

- <db_name>
指定数据库名称
- <tbl_name>
指定表名称

Query parameters

- with_mv
可选项，如果未指定，默认返回 base 表的表结构。如果指定，则还会返回所有 rollup 的信息。

Request body

无

Response

```
GET /api/meta/namespaces/default/databases/db1/tables/tbl1/schema
```

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "tbl1": {
      "schema": [{
        "Field": "k1",
        "Type": "INT",
        "Null": "Yes",
        "Extra": "",
        "Default": null,
        "Key": "true"
      },
      {
        "Field": "k2",
        "Type": "INT",
        "Null": "Yes",
        "Extra": "",
        "Default": null,
        "Key": "true"
      }
    ],
    "is_base": true
  }
},
"count": 0
}
```

GET /api/meta/namespaces/default/databases/db1/tables/tbl1/schema?with_mv?=1

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "tbl1": {
      "schema": [{
        "Field": "k1",
        "Type": "INT",
        "Null": "Yes",
        "Extra": "",
        "Default": null,
        "Key": "true"
      },
      {
        "Field": "k2",
        "Type": "INT",
        "Null": "Yes",
        "Extra": "",
        "Default": null,
        "Key": "true"
      }
    ],
    "is_base": true
  },
  "rollup1": {
    "schema": [{
      "Field": "k1",
      "Type": "INT",
      "Null": "Yes",
      "Extra": "",
      "Default": null,
      "Key": "true"
    }],
    "is_base": false
  }
},
  "count": 0
}
```

- data 字段返回 base 表或 rollup 表的表结构信息。

Meta Replay State Action

(未实现)

Request

GET /api/_meta_replay_state

Description

获取 FE 节点元数据回放的状态。

Path parameters

无

Query parameters

无

Request body

无

Response

TODO

Examples

TODO

Metrics Action

Request

GET /api/metrics

Description

获取 doris metrics 信息。

Path parameters

无

Query parameters

- type

可选参数。默认输出全部 metrics 信息，有以下取值：

- core 输出核心 metrics 信息
- json 以 json 格式输出 metrics 信息

Request body

无

Response

TO DO

Profile Action

Request

GET /api/profile

Description

用于获取指定 query id 的 query profile 如果 query_id 不存在，直接返回 404 NOT FOUND 错误 如果 query_id 存在，返回下列文本的 profile:

```
Query:
Summary:
  - Query ID: a0a9259df9844029-845331577440a3bd
  - Start Time: 2020-06-15 14:10:05
  - End Time: 2020-06-15 14:10:05
  - Total: 8ms
  - Query Type: Query
  - Query State: EOF
  - Doris Version: trunk
  - User: root
  - Default Db: default_cluster:test
  - Sql Statement: select * from table1
Execution Profile a0a9259df9844029-845331577440a3bd:(Active: 7.315ms, % non-child: 100.00%)
  Fragment 0:
    Instance a0a9259df9844029-845331577440a3be (host=TNetworkAddress(hostname:172.26.108.176, port:9560)):
      (Active: 1.523ms, % non-child: 0.24%)
        - MemoryLimit: 2.00 GB
        - PeakUsedReservation: 0.00
        - PeakMemoryUsage: 72.00 KB
        - RowsProduced: 5
        - AverageThreadTokens: 0.00
        - PeakReservation: 0.00
      BlockMgr:
        - BlocksCreated: 0
        - BlockWritesOutstanding: 0
        - BytesWritten: 0.00
        - TotalEncryptionTime: 0ns
        - BufferedPins: 0
        - TotalReadBlockTime: 0ns
        - TotalBufferWaitTime: 0ns
        - BlocksRecycled: 0
        - TotalIntegrityCheckTime: 0ns
        - MaxBlockSize: 8.00 MB
      DataBufferSender (dst_fragment_instance_id=a0a9259df9844029-845331577440a3be):
        - AppendBatchTime: 9.23us
        - ResultSendTime: 956ns
        - TupleConvertTime: 5.735us
        - NumSentRows: 5
      OLAP_SCAN_NODE (id=0):(Active: 1.506ms, % non-child: 20.59%)
        - TotalRawReadTime: 0ns
        - CompressedBytesRead: 6.47 KB
        - PeakMemoryUsage: 0.00
        - RowsPushedCondFiltered: 0
        - ScanRangesComplete: 0
        - ScanTime: 25.195us
        - BitmapIndexFilterTimer: 0ns
```



```

- BitmapIndexFilterCount: 0
- NumScanners: 65
- RowsStatsFiltered: 0
- VectorPredEvalTime: 0ns
- BlockSeekTime: 1.299ms
- RawRowsRead: 1.91K (1910)
- ScannerThreadsVoluntaryContextSwitches: 0
- RowsDelFiltered: 0
- IndexLoadTime: 911.104us
- NumDiskAccess: 1
- ScannerThreadsTotalWallClockTime: 0ns
  - MaterializeTupleTime: 0ns
  - ScannerThreadsUserTime: 0ns
  - ScannerThreadsSysTime: 0ns
- TotalPagesNum: 0
- RowsReturnedRate: 3.319K /sec
- BlockLoadTime: 539.289us
- CachedPagesNum: 0
- BlocksLoad: 384
- UncompressedBytesRead: 0.00
- RowsBloomFilterFiltered: 0
- TabletCount : 1
- RowsReturned: 5
- ScannerThreadsInvoluntaryContextSwitches: 0
- DecompressorTimer: 0ns
- RowsVectorPredFiltered: 0
- ReaderInitTime: 6.498ms
- RowsRead: 5
- PerReadThreadRawHdfsThroughput: 0.0 /sec
- BlockFetchTime: 4.318ms
- ShowHintsTime: 0ns
- TotalReadThroughput: 0.0 /sec
- IOTimer: 1.154ms
- BytesRead: 48.49 KB
- BlockConvertTime: 97.539us
- BlockSeekCount: 0

```

Path parameters

无

Query parameters

- query_id

指定的 query id

Request body

无

Response

```

{
  "msg": "success",
  "code": 0,
  "data": {
    "profile": "query profile ..."
  }
}

```

```
},  
  "count": 0  
}
```

Examples

1. 获取指定 query_id 的 query profile

```
GET /api/profile?query_id=f732084bc8e74f39-8313581c9c3c0b58
```

Response:

```
{  
  "msg": "success",  
  "code": 0,  
  "data": {  
    "profile": "query profile ..."  
  },  
  "count": 0  
}
```

Query Schema Action

Request

```
POST /api/query_schema/<ns_name>/<db_name>
```

Description

Query Schema Action 可以返回给定的 SQL 有关的表的建表语句。可以用于本地测试一些查询场景。该 API 在 1.2 版本中发布。

Path parameters

- <db_name>

指定数据库名称。该数据库会被视为当前 session 的默认数据库，如果在 SQL 中的表名没有限定数据库名称的话，则使用该数据库。

Query parameters

无

Request body

```
text/plain
```

```
sql
```

- sql 字段为具体的 SQL

Response

- 返回结果集

```
CREATE TABLE `tbl1` (  
  `k1` int(11) NULL,  
  `k2` int(11) NULL  
) ENGINE=OLAP  
DUPLICATE KEY(`k1`, `k2`)  
COMMENT 'OLAP'  
DISTRIBUTED BY HASH(`k1`) BUCKETS 3  
PROPERTIES (  
  "replication_allocation" = "tag.location.default: 1",  
  "in_memory" = "false",  
  "storage_format" = "V2",  
  "disable_auto_compaction" = "false"  
);
```

```
CREATE TABLE `tbl2` (  
  `k1` int(11) NULL,  
  `k2` int(11) NULL  
) ENGINE=OLAP  
DUPLICATE KEY(`k1`, `k2`)  
COMMENT 'OLAP'  
DISTRIBUTED BY HASH(`k1`) BUCKETS 3  
PROPERTIES (  
  "replication_allocation" = "tag.location.default: 1",  
  "in_memory" = "false",  
  "storage_format" = "V2",  
  "disable_auto_compaction" = "false"  
);
```

Example

1. 在本地文件 1.sql 中写入 SQL

```
select tbl1.k2 from tbl1 join tbl2 on tbl1.k1 = tbl2.k1;
```

2. 使用 curl 命令获取建表语句

```
curl -X POST -H 'Content-Type: text/plain' -uroot:  
http://127.0.0.1:8030/api/query_schema/internal/db1 -d@1.sql
```

Query Stats Action

Request

```
查看
get api/query_stats/<catalog_name>
get api/query_stats/<catalog_name>/<db_name>
get api/query_stats/<catalog_name>/<db_name>/<tbl_name>

清空
delete api/query_stats/<catalog_name>/<db_name>
delete api/query_stats/<catalog_name>/<db_name>/<tbl_name>
```

Description

获取或者删除指定的 catalog 数据库或者表中的统计信息，如果是 doris catalog 可以使用 default_cluster

Path parameters

- <catalog_name>
指定的 catalog 名称
- <db_name>
指定的数据库名称
- <tbl_name>
指定的表名称

Query parameters

- summary 如果为 true 则只返回 summary 信息，否则返回所有的表的详细统计信息，只在 get 时使用

Request body

```
GET /api/query_stats/default_cluster/test_query_db/baseall?summary=false
{
  "msg": "success",
  "code": 0,
  "data": {
    "summary": {
      "query": 2
    },
    "detail": {
      "baseall": {
        "summary": {
          "query": 2
        }
      }
    }
  }
}
```

```
    }  
  },  
  "count": 0  
}
```

Response

- 返回结果集

Example

2. 使用 curl 命令获取统计信息

```
curl --location -u root: 'http://127.0.0.1:8030/api/query_stats/default_cluster/test_query_db/baseall?  
summary=false'
```

Row Count Action

Request

GET /api/rowcount

Description

用于手动更新指定表的行数统计信息。在更新行数统计信息的同时，也会以 JSON 格式返回表以及对应 rollup 的行数

Path parameters

无

Query parameters

- db
指定的数据库
- table
指定的表名

Request body

无

Response

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "tbl1": 10000
  },
  "count": 0
}
```

Examples

1. 更新并获取指定 Table 的行数

```
GET /api/rowcount?db=example_db&table=tbl1

Response:
{
```

```
"msg": "success",  
"code": 0,  
"data": {  
  "tbl1": 10000  
},  
"count": 0  
}
```


Set Config Action

Request

GET /api/_set_config

Description

用于动态设置 FE 的参数。该命令等同于通过 ADMIN SET FRONTEND CONFIG 命令。但该命令仅会设置对应 FE 节点的配置。并且不会自动转发 MasterOnly 配置项给 Master FE 节点。

Path parameters

无

Query parameters

- confkey1=confvalue1

指定要设置的配置名称，其值为要修改的配置值。

- persist

是否要将修改的配置持久化。默认为 false，即不持久化。如果为 true，这修改后的配置项会写入 fe_custom.conf 文件中，并在 FE 重启后仍会生效。

- reset_persist

是否要清空原来的持久化配置，只在 persist 参数为 true 时生效。为了兼容原来的版本，reset_persist 默认为 true。

如果 persist 设为 true，不设置 reset_persist 或 reset_persist 为 true，将先清空 fe_custom.conf 文件中的配置再将本次修改的配置写入 fe_custom.conf；

如果 persist 设为 true，reset_persist 为 false，本次修改的配置项将会增量添加到 fe_custom.conf。

Request body

无

Response

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "set": {
      "key": "value"
    },
    "err": [
```

```

        {
            "config_name": "",
            "config_value": "",
            "err_info": ""
        }
    ],
    "persist": ""
},
"count": 0
}

```

set 字段表示设置成功的配置。err 字段表示设置失败的配置。persist 字段表示持久化信息。

Examples

1. 设置 storage_min_left_capacity_bytes 、 replica_ack_policy 和 agent_task_resend_wait_time_ms 三个配置的值。

```

GET /api/_set_config?
storage_min_left_capacity_bytes=1024&replica_ack_policy=SIMPLE_MAJORITY&agent_task_resend_wait_time_ms
=true

Response:
{
  "msg": "success",
  "code": 0,
  "data": {
    "set": {
      "storage_min_left_capacity_bytes": "1024"
    },
    "err": [
      {
        "config_name": "replica_ack_policy",
        "config_value": "SIMPLE_MAJORITY",
        "err_info": "Not support dynamic modification."
      },
      {
        "config_name": "agent_task_resend_wait_time_ms",
        "config_value": "true",
        "err_info": "Unsupported configuration value type."
      }
    ],
    "persist": ""
  },
  "count": 0
}

storage_min_left_capacity_bytes 设置成功;
replica_ack_policy 设置失败, 原因是该配置项不支持动态修改;
agent_task_resend_wait_time_ms 设置失败, 因为该配置项类型为 long, 设置 boolean 类型失败。

```

2. 设置 max_bytes_per_broker_scanner 并持久化 `` GET /api/_set_config?
 max_bytes_per_broker_scanner=21474836480&persist=true&reset_persist=false

```

Response: { "msg": "success", "code": 0, "data": { "set": { "max_bytes_per_broker_scanner":
"21474836480" }, "err": [], "persist": "ok" }, "count": 0 } ``

```

fe/conf 目录生成 fe_custom.conf: #THIS IS AN AUTO GENERATED CONFIG FILE. #You can modify this file manually, and the configurations in this file #will overwrite the

configurations in fe.conf #Wed Jul 28 12:43:14 CST 2021
max_bytes_per_broker_scanner=21474836480

Show Data Action

Request

GET /api/show_data

Description

用于获取集群的总数据量，或者指定数据库的数据量。单位字节。

Path parameters

无

Query parameters

- db

可选。如果指定，则获取指定数据库的数据量。

Request body

无

Response

1. 指定数据库的数据量。

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "default_cluster:db1": 381
  },
  "count": 0
}
```

2. 总数据量

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "__total_size": 381
  },
  "count": 0
}
```

Examples

1. 获取指定数据库的数据量

```
GET /api/show_data?db=db1
```

Response:

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "default_cluster:db1": 381
  },
  "count": 0
}
```

2. 获取集群总数据量

```
GET /api/show_data
```

Response:

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "__total_size": 381
  },
  "count": 0
}
```

Show Meta Info Action

Request

GET /api/show_meta_info

Description

用于显示一些元数据信息

Path parameters

无

Query parameters

- action

指定要获取的元数据信息类型。目前支持如下：

- SHOW_DB_SIZE

获取指定数据库的数据量大小，单位为字节。

- SHOW_HA

获取 FE 元数据日志的回放情况，以及可选举组的情况。

Request body

无

Response

- SHOW_DB_SIZE

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "default_cluster:information_schema": 0,
    "default_cluster:db1": 381
  },
  "count": 0
}
```

- SHOW_HA

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "can_read": "true",
    "role": "MASTER",
    "is_ready": "true",
    "last_checkpoint_version": "1492",
    "last_checkpoint_time": "1596465109000",
    "current_journal_id": "1595",
    "electable_nodes": "",
    "observer_nodes": "",
    "master": "10.81.85.89"
  },
  "count": 0
}
```

Examples

1. 查看集群各个数据库的数据量大小

```
GET /api/show_meta_info?action=show_db_size

Response:
{
  "msg": "success",
  "code": 0,
  "data": {
    "default_cluster:information_schema": 0,
    "default_cluster:db1": 381
  },
  "count": 0
}
```

2. 查看 FE 选举组情况

```
GET /api/show_meta_info?action=show_ha

Response:
{
  "msg": "success",
  "code": 0,
  "data": {
    "can_read": "true",
    "role": "MASTER",
    "is_ready": "true",
    "last_checkpoint_version": "1492",
    "last_checkpoint_time": "1596465109000",
    "current_journal_id": "1595",
    "electable_nodes": "",
    "observer_nodes": "",
    "master": "10.81.85.89"
  },
  "count": 0
}
```

Show Proc Action

Request

GET /api/show_proc

Description

用于获取 PROC 信息。

Path parameters

无

Query parameters

- path
指定的 Proc Path
- forward
是否转发给 Master FE 执行

Request body

无

Response

```
{
  "msg": "success",
  "code": 0,
  "data": [
    proc infos ...
  ],
  "count": 0
}
```

Examples

1. 查看 /statistic 信息

```
GET /api/show_proc?path=/statistic

Response:
{
  "msg": "success",
```



```
"code": 0,
"data": [
  ["10003", "default_cluster:db1", "2", "3", "3", "3", "3", "0", "0", "0"],
  ["10013", "default_cluster:doris_audit_db__", "1", "4", "4", "4", "4", "0", "0", "0"],
  ["Total", "2", "3", "7", "7", "7", "7", "0", "0", "0"]
],
"count": 0
}
```

2. 转发到 Master 执行

```
GET /api/show_proc?path=/statistic&forward=true

Response:
{
  "msg": "success",
  "code": 0,
  "data": [
    ["10003", "default_cluster:db1", "2", "3", "3", "3", "3", "0", "0", "0"],
    ["10013", "default_cluster:doris_audit_db__", "1", "4", "4", "4", "4", "0", "0", "0"],
    ["Total", "2", "3", "7", "7", "7", "7", "0", "0", "0"]
  ],
  "count": 0
}
```

Show Runtime Info Action

Request

GET /api/show_runtime_info

Description

用于获取 FE JVM 的 Runtime 信息

Path parameters

无

Query parameters

无

Request body

无

Response

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "free_mem": "855642056",
    "total_mem": "1037959168",
    "thread_cnt": "98",
    "max_mem": "1037959168"
  },
  "count": 0
}
```

Examples

1. 获取当前 FE 节点的 JVM 信息

```
GET /api/show_runtime_info
```

Response:

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "free_mem": "855642056",
    "total_mem": "1037959168",
```

```
        "thread_cnt": "98",  
        "max_mem": "1037959168"  
    },  
    "count": 0  
}
```

Show Table Data Action

Request

GET /api/show_table_data

Description

用于获取所有 internal 源下所有数据库所有表的数据量，或者指定数据库或指定表的数据量。单位字节。

Path parameters

无

Query parameters

- db
可选。如果指定，则获取指定数据库下表的数据量。
- table
可选。如果指定，则获取指定表的数据量。
- single_replica
可选。如果指定，则获取表单副本所占用的数据量。

Request body

无

Response

1. 指定数据库所有表的数据量。

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "tpch": {
      "partsupp": 9024548244,
      "revenue0": 0,
      "customer": 1906421482
    }
  },
  "count": 0
}
```

2. 指定数据库指定表的数据量。

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "tpch": {
      "partsupp": 9024548244
    }
  },
  "count": 0
}
```

3. 指定数据库指定表单副本的数据量。

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "tpch": {
      "partsupp": 3008182748
    }
  },
  "count": 0
}
```

Examples

1. 获取指定数据库的数据量

```
GET /api/show_table_data?db=tpch
```

Response:

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "tpch": {
      "partsupp": 9024548244,
      "revenue0": 0,
      "customer": 1906421482
    }
  },
  "count": 0
}
```

2. 指定数据库指定表的数据量。

```
GET /api/show_table_data?db=tpch&table=partsupp
```

Response:

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "tpch": {
      "partsupp": 9024548244
    }
  }
}
```

```
    },  
    "count":0  
  }  
}
```

3. 指定数据库指定表单副本的数据量。

```
GET /api/show_table_data?db=tpch&table=partsupp&single_replica=true
```

Response:

```
{  
  "msg":"success",  
  "code":0,  
  "data":{  
    "tpch":{  
      "partsupp":3008182748  
    }  
  },  
  "count":0  
}
```

Statement Execution Action

Request

```
POST /api/query/<ns_name>/<db_name>
```

Description

Statement Execution Action 用于执行语句并返回结果。

Path parameters

- <db_name>

指定数据库名称。该数据库会被视为当前 session 的默认数据库，如果在 SQL 中的表名没有限定数据库名称的话，则使用该数据库。

Query parameters

无

Request body

```
{
  "stmt" : "select * from tbl1"
}
```

- sql 字段为具体的 SQL

Response

- 返回结果集

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "type": "result_set",
    "data": [
      [1],
      [2]
    ],
    "meta": [{
      "name": "k1",
      "type": "INT"
    }],
    "status": {},
    "time": 10
  }
}
```

```
},  
"count": 0  
}
```

- `type` 字段为 `result_set` 表示返回结果集。需要根据 `meta` 和 `data` 字段获取并展示结果。`meta` 字段描述返回的列信息。`data` 字段返回结果行。其中每一行的中的列类型，需要通过 `meta` 字段内容判断。`status` 字段返回 MySQL 的一些信息，如告警行数，状态码等。`time` 字段返回语句执行时间，单位毫秒。
- 返回执行结果

```
{  
  "msg": "success",  
  "code": 0,  
  "data": {  
    "type": "exec_status",  
    "status": {},  
    "time": 10  
  },  
  "count": 0  
}
```

- `type` 字段为 `exec_status` 表示返回执行结果。目前收到该返回结果，则都表示语句执行成功。

Table Query Plan Action

Request

POST /api/<db>/<table>/_query_plan

Description

给定一个 SQL，用于获取该 SQL 对应的查询计划。

该接口目前用于 Spark-Doris-Connector 中，Spark 获取 Doris 的查询计划。

Path parameters

- <db>
指定数据库
- <table>
指定表

Query parameters

无

Request body

```
{
  "sql": "select * from db1.tbl1;"
}
```

Response

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "partitions": {
      "10039": {
        "routings": ["10.81.85.89:9062"],
        "version": 2,
        "versionHash": 982459448378619656,
        "schemaHash": 1294206575
      }
    },
    "opaqued_query_plan":
    "DAABDAACDwABDAAAAEIAAEAAAAACAACAAAAAgAAwAAAAKAAT////////w8ABQgAAAAABAAAAA8ABgIAAAABAAIACAAMABIIAAEAAAA
DwACCwAAAAIAAAACazEAAACazIPAAMIAAAAgAAAAUAAAFAgAEAQAAAA8ABwAAAAACDwABDAAAAEIAAEAAAAQDAACDwABDAAAAEIAEEA
AAADAACCAABAAABQAAAAGABAAAAA8IAAEAAAAACAACAAAAAIABT////CAAX////wAADwABDAAAAEIAAEAAAAQDAACDwABDAAAA
```

```

EIAAEAAAAADAACCAABAAAABQAAAAgABAAAAAAMA8IAAEAAAABCAACAAAAAAIABT/////CAAX/////wAADAAFCABAAAABgwACAAADAAGCAA
BAAAAA8AAgWAAAAAAABwAAAAAAAACgAIAAAAAAAAADQACCgWAAAABAAAAAAAJzcKAAEAAAAAAANwOAAgAAAAAAAACgADDaJl
qbrVdwgIAARNJAZvAAwAAw8AAQwAAAAACCAABAAAAAAgAAgAAAAAMAAMPAAEMAAAAQgAAQAAAAMAAIIAAEAAAAFAAAACAAE/////wgABQAAA
AQIAAYAAAAACAAHAAAAAASACAAAAAJrMQgACQAAAAACAAoBAAGAAQAAAAEIAAIAAAAAADAADDwABDAAAAEIAEAAAAADAACCAABAAAABQAAAA
gABP///8IAAUAAAAICAAGAAAAAAGABwAAAAELAAgAAAAACazIIAAkAAAAABAgAKAQAPAAIMAAAAQgAAQAAAAIAAIAAAAMCAADAAAAAQoABAA
AAAAAACc1CAAFAAAAAGAPAAAMMAAAAAQoAAQAAAAAACc1CAACAAAAAQgAAwAAAAIIAAQAAAAACwAHAAAAABHRibDELAAGAAAAADAALCwABAAAA
BHRibDEAAAAAAQKAFFl5rpxl1I4goAAArgS6f+h6eMxAAA=",
  "status": 200
},
"count": 0
}

```

其中 `opaqued_query_plan` 为查询计划的二进制格式。

Examples

1. 获取指定 sql 的查询计划

```

POST /api/db1/tbl1/_query_plan
{
  "sql": "select * from db1.tbl1;"
}

Response:
{
  "msg": "success",
  "code": 0,
  "data": {
    "partitions": {
      "10039": {
        "routings": ["192.168.1.1:9060"],
        "version": 2,
        "versionHash": 982459448378619656,
        "schemaHash": 1294206575
      }
    },
    "opaqued_query_plan": "DAABDAACDwABD...",
    "status": 200
  },
  "count": 0
}

```

Table Row Count Action

Request

GET /api/<db>/<table>/_count

Description

用于获取指定表的行数统计信息。该接口目前用于 Spark-Doris-Connector 中，Spark 获取 Doris 的表统计信息。

Path parameters

- <db>
指定数据库
- <table>
指定表

Query parameters

无

Request body

无

Response

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "size": 1,
    "status": 200
  },
  "count": 0
}
```

其中 data.size 字段表示指定表的行数。

Examples

1. 获取指定表的行数。

```
GET /api/db1/tbl1/_count
```

Response:

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "size": 1,
    "status": 200
  },
  "count": 0
}
```

Table Schema Action

Request

GET /api/<db>/<table>/_schema

Description

用于获取指定表的表结构信息。该接口目前用于 Spark/Flink Doris Connector 中，获取 Doris 的表结构信息。

Path parameters

- <db>
指定数据库
- <table>
指定表

Query parameters

无

Request body

无

Response

- http 接口返回如下：

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "properties": [{
      "type": "INT",
      "name": "k1",
      "comment": "",
      "aggregation_type":""
    }, {
      "type": "INT",
      "name": "k2",
      "comment": "",
      "aggregation_type":"MAX"
    }],
    "keysType":UNIQUE_KEYS,
    "status": 200
  },
}
```

```
    "count": 0
}
```

- http v2 接口返回如下:

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "properties": [{
      "type": "INT",
      "name": "k1",
      "comment": ""
    }, {
      "type": "INT",
      "name": "k2",
      "comment": ""
    }],
    "keysType": UNIQUE_KEYS,
    "status": 200
  },
  "count": 0
}
```

注意: 区别为http方式比http v2方式多返回aggregation_type字段, http v2开启是通过enable_http_server_v2进行设置, 具体参数说明详见[fe 参数设置](#)

Examples

1. 通过 http 获取指定表的表结构信息。

```
GET /api/db1/tbl1/_schema

Response:
{
  "msg": "success",
  "code": 0,
  "data": {
    "properties": [{
      "type": "INT",
      "name": "k1",
      "comment": "",
      "aggregation_type":""
    }, {
      "type": "INT",
      "name": "k2",
      "comment": "",
      "aggregation_type":"MAX"
    }],
    "keysType":UNIQUE_KEYS,
    "status": 200
  },
  "count": 0
}
```

2. 通过 http v2 获取指定表的表结构信息。

GET /api/db1/tbl1/_schema

Response:

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "properties": [{
      "type": "INT",
      "name": "k1",
      "comment": ""
    }, {
      "type": "INT",
      "name": "k2",
      "comment": ""
    }],
    "keysType": UNIQUE_KEYS,
    "status": 200
  },
  "count": 0
}
```

Upload Action

Upload Action 目前主要服务于 FE 的前端页面，用于用户导入一些测试性质的小文件。

上传导入文件

用于将文件上传到 FE 节点，可在稍后用于导入该文件。目前仅支持上传最大 100MB 的文件。

Request

```
POST /api/<namespace>/<db>/<tbl>/upload
```

Path parameters

- <namespace>
命名空间，目前仅支持 default_cluster
- <db>
指定的数据库
- <tbl>
指定的表

Query parameters

- column_separator
可选项，指定文件的分隔符。默认为 \t
- preview
可选项，如果设置为 true，则返回结果中会显示最多 10 行根据 column_separator 切分好的数据行。

Request body

要上传的文件内容，Content-type 为 multipart/form-data

Response

```
{
  "msg": "success",
  "code": 0,
  "data": {
    "id": 1,
    "uuid": "b87824a4-f6fd-42c9-b9f1-c6d68c5964c2",
  }
}
```



```
    "originFileName": "data.txt",
    "fileSize": 102400,
    "absPath": "/path/to/file/data.txt"
    "maxColNum" : 5
  },
  "count": 1
}
```

导入已上传的文件

Request

```
PUT /api/<namespace>/<db>/<tbl>/upload
```

Path parameters

- <namespace>
命名空间，目前仅支持 default_cluster
- <db>
指定的数据库
- <tbl>
指定的表

Query parameters

- file_id
指定导入的文件 id，文件 id 由上传导入文件的 API 返回。
- file_uuid
指定导入的文件 uuid，文件 uuid 由上传导入文件的 API 返回。

Header

Header 中的可选项同 Stream Load 请求中 header 的可选项。

Request body

要上传的文件内容，Content-type 为 multipart/form-data

Response

```
{
  "msg": "success",
  "code": 0,
```

```
"data": {  
  "TxnId": 7009,  
  "Label": "9dbdfb0a-120b-47a2-b078-4531498727cb",  
  "Status": "Success",  
  "Message": "OK",  
  "NumberTotalRows": 3,  
  "NumberLoadedRows": 3,  
  "NumberFilteredRows": 0,  
  "NumberUnselectedRows": 0,  
  "LoadBytes": 12,  
  "LoadTimeMs": 71,  
  "BeginTxnTimeMs": 0,  
  "StreamLoadPutTimeMs": 1,  
  "ReadDataTimeMs": 0,  
  "WriteDataTimeMs": 13,  
  "CommitAndPublishTimeMs": 53  
},  
"count": 1  
}
```

举例

```
PUT /api/default_cluster/db1/tbl1/upload?file_id=1&file_uuid=b87824a4-f6fd-42c9-b9f1-c6d68c5964c2
```

Import Action

Request

POST /api/import/file_review

Description

查看格式为 CSV 或 PARQUET 的文件内容。

Path parameters

无

Query parameters

无

Request body

TO DO

Response

TO DO

Meta Info Action

Request

GET /api/meta/namespaces/<ns>/databases GET /api/meta/namespaces/<ns>/databases/<db>/tables
GET /api/meta/namespaces/<ns>/databases/<db>/tables/<tbl>/schema

Description

获取集群内的元数据信息，包括数据库列表、表列表以及表结构等。

Path parameters

- ns
指定集群名。
- db
指定数据库。
- tbl
指定数据表。

Query parameters

无

Request body

无

Response

```
{  
  "msg": "success",  
  "code": 0,  
  "data": ["数据库列表" / "数据表列表" / "表结构"],  
  "count": 0  
}
```

代码打桩

代码打桩是代码测试使用的。激活木桩后，可以执行木桩代码。木桩的名字是任意取的。

FE 和 BE 都支持代码打桩。

木桩代码示例

FE 桩子示例代码

```
private Status foo() {
    // dbug_fe_foo_do_nothing 是一个木桩名字,
    // 打开这个木桩之后, DebugPointUtil.isEnabled("dbug_fe_foo_do_nothing") 将会返回 true
    if (DebugPointUtil.isEnabled("dbug_fe_foo_do_nothing")) {
        return Status.Nothing;
    }

    do_foo_action();

    return Status.Ok;
}
```

BE 桩子示例代码

```
void Status foo() {

    // dbug_be_foo_do_nothing 是一个木桩名字,
    // 打开这个木桩之后, DEBUG_EXECUTE_IF 将会执行宏参数中的代码块
    DEBUG_EXECUTE_IF("dbug_be_foo_do_nothing", { return Status.Nothing; });

    do_foo_action();

    return Status.Ok;
}
```

总开关

需要把木桩总开关 enable_debug_points 打开之后，才能激活木桩。默认情况下，木桩总开关是关闭的。

总开关enable_debug_points 分别在 FE 的 fe.conf 和 BE 的 be.conf 中配置。

打开木桩

API

```
POST /api/debug_point/add/{debug_point_name}[?timeout=<int>&execute=<int>]
```

参数

- debug_point_name 木桩名字。必填。
- timeout 超时时间，单位为秒。超时之后，木桩失活。默认值 -1 表示永远不超时。可填。
- execute 木桩最大激活次数。默认值 -1 表示不限激活次数。可填。

Request body

无

Response

```
```\n{\n  msg: "OK",\n  code: 0\n}\n```
```

## 举例s

打开木桩 foo，最多激活 5 次。

```
```\ncurl -X POST "http://127.0.0.1:8030/api/debug_point/add/foo?execute=5"\n```
```

关闭木桩

API

```
POST /api/debug_point/remove/{debug_point_name}
```

参数

- debug_point_name 木桩名字。必填。

Request body

无

Response

```
{\n  msg: "OK",
```

```
    code: 0
  }
```

举例s

关闭木桩foo。

```
```\ncurl -X POST "http://127.0.0.1:8030/api/debug_point/remove/foo"\n```\n
```

## 清除所有木桩

### API

```
POST /api/debug_point/clear
```

### Request body

无

### Response

```
```\n{\n  msg: "OK",\n  code: 0\n}\n```\n
```

举例s

清除所有木桩。

```
```\ncurl -X POST "http://127.0.0.1:8030/api/debug_point/clear"\n```\n
```

# Statistic Action

---

## Request

GET /rest/v2/api/cluster\_overview

## Description

获取集群统计信息、库表数量等。

## Path parameters

无

## Query parameters

无

## Request body

无

## Response

```
{
 "msg": "success",
 "code": 0,
 "data": {"diskOccupancy": 0, "remainDisk": 5701197971457, "feCount": 1, "tblCount": 27, "beCount": 1, "dbCount": 2},
 "count": 0
}
```



# 检查连接缓存

---

## Request

GET /api/check\_rpc\_channel/{host\_to\_check}/{remot\_brpc\_port}/{payload\_size}

## Description

该功能用于检查 brpc 的连接缓存。

## Path parameters

- host\_to\_check  
需要查检的 IP。
- remot\_brpc\_port  
需要查检的端口。
- payload\_size  
负载大小，单位 B，取值范围 1~1024000。

## Request body

无

## Response

```
{}
{
 "msg": "success",
 "code": 0,
 "data": "open brpc connection to {host_to_check}:{remot_brpc_port} success.",
 "count": 0
}
```

## Examples

```
curl http://127.0.0.1:8040/api/check_rpc_channel/127.0.0.1/8060/1024000
```

# 重置连接缓存

---

## Request

GET /api/reset\_rpc\_channel/{endpoints}

## Description

该功能用于重置 brpc 的连接缓存。

## Path parameters

- endpoints 支持如下形式：
  - all
  - host1:port1,host2:port2

## Request body

无

## Response

```
```json
{
  "msg": "success",
  "code": 0,
  "data": "no cached channel.",
  "count": 0
}
```
```

## Examples

```
```shell
curl http://127.0.0.1:8040/api/reset_rpc_channel/all
```

```shell
curl http://127.0.0.1:8040/api/reset_rpc_channel/1.1.1.1:8080,2.2.2.2:8080
```
```

# 查看 Compaction 状态

---

## Request

GET /api/compaction/run\_status GET /api/compaction/show?tablet\_id={int}

## Description

用于查看某个 BE 节点总体的 compaction 状态，或者指定 tablet 的 compaction 状态。

## Query parameters

- tablet\_id
  - tablet 的 id

## Request body

无

## Response

### 整体 Compaction 状态

```
{
 "CumulativeCompaction": {
 "/home/disk1" : [10001, 10002],
 "/home/disk2" : [10003]
 },
 "BaseCompaction": {
 "/home/disk1" : [10001, 10002],
 "/home/disk2" : [10003]
 }
}
```

该结构表示某个数据目录下，正在执行 compaction 任务的 tablet 的 id，以及 compaction 的类型。

### 指定 tablet 的 Compaction 状态

```
{
 "cumulative policy type": "SIZE_BASED",
 "cumulative point": 50,
 "last cumulative failure time": "2019-12-16 18:13:43.224",
 "last base failure time": "2019-12-16 18:13:23.320",
 "last cumu success time": ,
 "last base success time": "2019-12-16 18:11:50.780",
 "rowsets": [
 "[0-48] 10 DATA OVERLAPPING 574.00 MB",
 "[49-49] 2 DATA OVERLAPPING 574.00 B",
]
}
```

```

 "[50-50] 0 DELETE NONOVERLAPPING 574.00 B",
 "[51-51] 5 DATA OVERLAPPING 574.00 B"
],
 "missing_rowsets": [],
 "stale version path": [
 {
 "path id": "2",
 "last create time": "2019-12-16 18:11:15.110 +0800",
 "path list": "2-> [0-24] -> [25-48]"
 },
 {
 "path id": "1",
 "last create time": "2019-12-16 18:13:15.110 +0800",
 "path list": "1-> [25-40] -> [40-48]"
 }
]
}

```

结果说明：

- cumulative policy type：当前 tablet 所使用的 cumulative compaction 策略。
- cumulative point：base 和 cumulative compaction 的版本分界线。在 point（不含）之前的版本由 base compaction 处理。point（含）之后的版本由 cumulative compaction 处理。
- last cumulative failure time：上一次尝试 cumulative compaction 失败的时间。默认 10min 后才会再次尝试对该 tablet 做 cumulative compaction。
- last base failure time：上一次尝试 base compaction 失败的时间。默认 10min 后才会再次尝试对该 tablet 做 base compaction。
- rowsets：该 tablet 当前的 rowset 集合。如 [0-48] 表示 0-48 版本。第二位数字表示该版本中 segment 的数量。DELETE 表示 delete 版本。DATA 表示数据版本。OVERLAPPING 和 NONOVERLAPPING 表示 segment 数据是否重叠。
- missing\_rowsets: 缺失的版本。
- stale version path：该 table 当前被合并 rowset 集合的合并版本路径，该结构是一个数组结构，每个元素表示一个合并路径。每个元素中包含了三个属性：path id 表示版本路径 id，last create time 表示当前路径上最近的 rowset 创建时间，默认在这个时间半个小时之后这条路径上的所有 rowset 会被过期删除。

## Examples

```
curl http://192.168.10.24:8040/api/compaction/show?tablet_id=10015
```

# 触发 Compaction

---

## Request

POST /api/compaction/run?tablet\_id={int}&compact\_type={enum} POST /api/compaction/run?table\_id={int}&compact\_type=full 注意，table\_id=xxx 只有在 compact\_type=full 时指定才会生效。GET /api/compaction/run\_status?tablet\_id={int}

## Description

用于手动触发 Compaction 以及状态查询。

## Query parameters

- tablet\_id
  - tablet 的 id
- table\_id
  - table 的 id。注意，table\_id=xxx 只有在 compact\_type=full 时指定才会生效，并且 tablet\_id 和 table\_id 只能指定一个，不能够同时指定，指定 table\_id 后会自动对此 table 下所有 tablet 执行 full\_compaction。
- compact\_type
  - 取值为base或cumulative或full。full\_compaction 的使用场景请参考[数据恢复](#)。

## Request body

无

## Response

### 触发 Compaction

若 tablet 不存在，返回 JSON 格式的错误：

```
{
 "status": "Fail",
 "msg": "Tablet not found"
}
```

若 compaction 执行任务触发失败时，返回 JSON 格式的错误：

```
{
 "status": "Fail",
```

```
 "msg": "fail to execute compaction, error = -2000"
}
```

若 compaction 执行触发成功时，则返回 JSON 格式的结果：

```
{
 "status": "Success",
 "msg": "compaction task is successfully triggered."
}
```

结果说明：

- status：触发任务状态，当成功触发时为 Success；当因某些原因（比如，没有获取到合适的版本）时，返回 Fail。
- msg：给出具体的成功或失败的信息。

## 查询状态

若 tablet 不存在，返回 JSON 格式：

```
{
 "status": "Fail",
 "msg": "Tablet not found"
}
```

若 tablet 存在并且 tablet 不在正在执行 compaction，返回 JSON 格式：

```
{
 "status" : "Success",
 "run_status" : false,
 "msg" : "this tablet_id is not running",
 "tablet_id" : 11308,
 "schema_hash" : 700967178,
 "compact_type" : ""
}
```

若 tablet 存在并且 tablet 正在执行 compaction，返回 JSON 格式：

```
{
 "status" : "Success",
 "run_status" : true,
 "msg" : "this tablet_id is running",
 "tablet_id" : 11308,
 "schema_hash" : 700967178,
 "compact_type" : "cumulative"
}
```

结果说明：

- run\_status：获取当前手动 compaction 任务执行状态

## 举例s

```
curl -X POST "http://127.0.0.1:8040/api/compaction/run?tablet_id=10015&compact_type=cumulative"
```

# 查询元信息

---

## Request

GET /api/meta/header/{tablet\_id}?byte\_to\_base64={bool}

## Description

查询 tablet 元信息

## Path parameters

- tablet\_id table 的 id

## Query parameters

- byte\_to\_base64 是否按 base64 编码，选填，默认false。

## Request body

无

## Response

```
```json
{
  "table_id": 148107,
  "partition_id": 148104,
  "tablet_id": 148193,
  "schema_hash": 2090621954,
  "shard_id": 38,
  "creation_time": 1673253868,
  "cumulative_layer_point": -1,
  "tablet_state": "PB_RUNNING",
  ...
}
```

Examples

```
```shell
curl "http://127.0.0.1:8040/api/meta/header/148193&byte_to_base64=true"

```
```


做快照

Request

GET /api/snapshot?tablet_id={int}&schema_hash={int}"

Description

该功能用于 tablet 做快照。

Query parameters

- tablet_id 需要做快照的 table 的 id
- schema_hash schema hash

Request body

无

Response

```
```\n/path/to/snapshot\n```
```

## Examples

```
```shell\ncurl "http://127.0.0.1:8040/api/snapshot?tablet_id=123456&schema_hash=1111111"\n```
```

检查 tablet 文件丢失

Request

GET /api/check_tablet_segment_lost?repair={bool}

Description

在 BE 节点上，可能会因为一些异常情况导致数据文件丢失，但是元数据显示正常，这种副本异常不会被 FE 检测到，也不能被修复。当用户查询时，会报错failed to initialize storage reader。该接口的功能是检测出当前 BE 节点上所有存在文件丢失的 tablet。

Query parameters

- repair
 - 设置为true时，存在文件丢失的 tablet 都会被设为SHUTDOWN状态，该副本会被作为坏副本处理，进而能够被 FE 检测和修复。
 - 设置为false时，只会返回所有存在文件丢失的 tablet，并不做任何处理。

Request body

无

Response

返回值是当前BE节点上所有存在文件丢失的tablet

```
...
{
  status: "Success",
  msg: "Succeed to check all tablet segment",
  num: 3,
  bad_tablets: [
    11190,
    11210,
    11216
  ],
  set_bad: true,
  host: "172.3.0.101"
}
...
```

Examples

```
```shell
curl http://127.0.0.1:8040/api/check_tablet_segment_lost?repair=false
```



# BE 的配置信息

---

## Request

GET /api/show\_config POST /api/update\_config?{key}={val}

## Description

查询/更新 BE 的配置信息

## Query parameters

- persist 是否持久化，选填，默认false。
- key 配置项名。
- val 配置项值。

## Request body

无

## Response

### 查询

```
[["agent_task_trace_threshold_sec","int32_t","2","true"], ...]
```

### 更新

```
[
 {
 "config_name": "agent_task_trace_threshold_sec",
 "status": "OK",
 "msg": ""
 }
]
```

```
[
 {
 "config_name": "agent_task_trace_threshold_sec",
 "status": "OK",
 "msg": ""
 },
 {
 "config_name": "enable_segcompaction",
 "status": "BAD",
 "msg": "set enable_segcompaction=false failed, reason: [NOT_IMPLEMENTED_ERROR]'enable_segcompaction'"
 }
]
```

```
is not support to modify."
 },
 {
 "config_name": "enable_time_lut",
 "status": "BAD",
 "msg": "set enable_time_lut=false failed, reason: [NOT_IMPLEMENTED_ERROR]'enable_time_lut' is not
support to modify."
 }
]
```

## Examples

```
curl "http://127.0.0.1:8040/api/show_config"
```

```
curl -X POST "http://127.0.0.1:8040/api/update_config?agent_task_trace_threshold_sec=2&persist=true"
```

```
curl -X POST "http://127.0.0.1:8040/api/update_config?
agent_task_trace_threshold_sec=2&enable_merge_on_write_correctness_check=true&persist=true"
```

# metrics 信息

---

## Request

GET /metrics?type={enum}&with\_tablet={bool}

## Description

prometheus 监控采集接口

## Query parameters

- type 输出方式，选填，默认全部输出，另有以下取值：
  - core: 只输出核心采集项
  - json: 以 json 格式输出
- with\_tablet 是否输出 tablet 相关的采集项，选填，默认false。

## Request body

无

## Response

```
```json
doris_be__max_network_receive_bytes_rate LONG 60757
doris_be__max_network_send_bytes_rate LONG 16232
doris_be_process_thread_num LONG 1120
doris_be_process_fd_num_used LONG 336
```
```

## Examples

```
```shell
curl "http://127.0.0.1:8040/metrics?type=json&with_tablet=true"
```
```

# 查询 tablet 分布

---

## Request

GET /api/tablets\_distribution?group\_by={enum}&partition\_id={int}

## Description

获取 BE 节点上每一个 partition 下的 tablet 在不同磁盘上的分布情况

## Query parameters

- group\_by 分组，当前只支持partition
- partition\_id 指定 partition 的 id，选填，默认返回所有 partition。

## Request body

无

## Response

```
```json
{
  msg: "OK",
  code: 0,
  data: {
    host: "***",
    tablets_distribution: [
      {
        partition_id:***,
        disks:[
          {
            disk_path:"***",
            tablets_num:***,
            tablets:[
              {
                tablet_id:***,
                schema_hash:***,
                tablet_size:***
              },
              ...
            ]
          },
          ...
        ]
      },
      ...
    ]
  }
},
...
],
},
},
},
```

```
count: ***  
}  
...
```

Examples

```
```shell  
curl "http://127.0.0.1:8040/api/tablets_distribution?group_by=partition&partition_id=123"
...`
```



# 迁移 tablet

---

## Request

GET /api/tablet\_migration?goal={enum}&tablet\_id={int}&schema\_hash={int}&disk={string}

## Description

在 BE 节点上迁移单个 tablet 到指定磁盘

## Query parameters

- goal
  - run: 提交迁移任务
  - status: 查询任务的执行状态
- tablet\_id 需要迁移的 tablet 的 id
- schema\_hash schema hash
- disk 目标磁盘。

## Request body

无

## Response

### 提交结果

```
{
 status: "Success",
 msg: "migration task is successfully submitted."
}
```

或

```
{
 status: "Fail",
 msg: "Migration task submission failed"
}
```

### 执行状态

```
{
 status: "Success",
```

```
 msg: "migration task is running",
 dest_disk: "xxxxxx"
}
```

或

```
{
 status: "Success",
 msg: "migration task has finished successfully",
 dest_disk: "xxxxxx"
}
```

或

```
{
 status: "Success",
 msg: "migration task failed.",
 dest_disk: "xxxxxx"
}
```

## Examples

```
```shell  
curl "http://127.0.0.1:8040/api/tablet_migration?goal=run&tablet_id=123&schema_hash=333&disk=/disk1"  
```
```

# 查询 tablet 信息

---

## Request

GET /tablets\_json?limit={int}

## Description

获取特定 BE 节点上指定数量的 tablet 的 tablet id 和 schema hash 信息

## Query parameters

- limit 返回的 tablet 数量，选填，默认 1000 个，可填all返回全部 tablet。

## Request body

无

## Response

```
```json
{
  msg: "OK",
  code: 0,
  data: {
    host: "10.38.157.107",
    tablets: [
      {
        tablet_id: 11119,
        schema_hash: 714349777
      },
      ...
      {
        tablet_id: 11063,
        schema_hash: 714349777
      }
    ]
  },
  count: 30
}
```
```

## Examples

```
```shell
curl http://127.0.0.1:8040/tablets_json?limit=123
```
```

# Checksum

---

## Request

GET /api/checksum?tablet\_id={int}&version={int}&schema\_hash={int}

## Description

checksum

## Query parameters

- tablet\_id 需要校验的 tablet 的 id
- version 需要校验的 tablet 的 version
- schema\_hash schema hash

## Request body

无

## Response

```
```\n1843743562\n```
```

Examples

```
```\ncurl "http://127.0.0.1:8040/api/checksum?tablet_id=1&version=1&schema_hash=-1"\n```
```

# 下载 load 日志

---

## Request

GET /api/\_load\_error\_log?token={string}&file={string}

## Description

下载 load 错误日志文件。

## Query parameters

- file 文件路径
- token token

## Request body

无

## Response

文件

## Examples

```
```shell
curl "http://127.0.0.1:8040/api/_load_error_log?file=a&token=1"
```
```

# 填充坏副本

---

## Request

POST /api/pad\_rowset?tablet\_id={int}&start\_version={int}&end\_version={int}

## Description

该功能用于使用一个空的 rowset 填充损坏的副本。

## Query parameters

- tablet\_id table 的 id
- start\_version 起始版本
- end\_version 终止版本

## Request body

无

## Response

```
```json
{
  msg: "OK",
  code: 0
}
```
```

## Examples

```
```shell
curl -X POST "http://127.0.0.1:8040/api/pad_rowset?
tablet_id=123456&start_version=1111111&end_version=1111112"

```
```

# BE 版本信息

---

## Request

GET /api/be\_version\_info

## Description

用于获取 be 节点版本信息。

## Path parameters

无

## Query parameters

无

## Request body

无

## Response

```
```json
{
  "msg": "success",
  "code": 0,
  "data": {
    "beVersionInfo": {
      "dorisBuildVersionPrefix": "doris",
      "dorisBuildVersionMajor": 0,
      "dorisBuildVersionMinor": 0,
      "dorisBuildVersionPatch": 0,
      "dorisBuildVersionRcVersion": "trunk",
      "dorisBuildVersion": "doris-0.0.0-trunk",

      "dorisBuildHash": "git://4b7b503d1cb3/data/doris/doris/be/..@a04f9814fe5a09c0d9e9399fe71cc4d765f8bff1",
      "dorisBuildShortHash": "a04f981",
      "dorisBuildTime": "Fri, 09 Sep 2022 07:57:02 UTC",
      "dorisBuildInfo": "root@4b7b503d1cb3"
    }
  },
  "count": 0
}
```
```

## Examples

```
```\ncurl http://127.0.0.1:8040/api/be_version_info\n```\n
```


BE 探活

Request

GET /api/health

Description

给监控服务提供的探活接口，请求能响应代表 BE 状态正常。

Query parameters

无

Request body

无

Response

```
```json
{"status": "OK", "msg": "To Be Added"}
```
```

Examples

```
```shell
curl http://127.0.0.1:8040/api/health
```
```

重加载 tablet

Request

GET /api/reload_tablet?tablet_id={int}&schema_hash={int}&path={string}"

Description

该功能用于重加载 tablet 数据。

Query parameters

- tablet_id 需要重加载的 table 的 id
- schema_hash schema hash
- path 文件路径

Request body

无

Response

```
```shell
load header succeed
```
```

Examples

```
```shell
curl "http://127.0.0.1:8040/api/reload_tablet?tablet_id=123456&schema_hash=1111111&path=/abc"

```
```

恢复 tablet

Request

POST /api/restore_tablet?tablet_id={int}&schema_hash={int}"

Description

该功能用于恢复 trash 目录中被误删的 tablet 数据。

Query parameters

- tablet_id 需要恢复的 table 的 id
- schema_hash schema hash

Request body

无

Response

```
```json
{
 msg: "OK",
 code: 0
}
```
```

Examples

```
```
curl -X POST "http://127.0.0.1:8040/api/restore_tablet?tablet_id=123456&schema_hash=1111111"
```
```

插件开发

介绍

Doris 的插件框架支持在运行时添加/卸载自定义插件，而不需要重启服务，用户可以通过开发自己的插件来扩展 Doris 的功能。

例如，审计插件作用于 Doris 请求执行后，可以获取到一次请求相关的信息（访问用户，请求 IP，SQL 等...），并将信息写入到指定的表中。

与 UDF 的区别：

- UDF 是函数，用于在 SQL 执行时进行数据计算。插件是附加功能，用于为 Doris 扩展自定义的功能，例如：支持不同的存储引擎，支持不同的导入方式，插件并不会参与执行 SQL 时的数据计算。
- UDF 的执行周期仅限于一次 SQL 执行。插件的执行周期可能与 Doris 进程相同。
- 使用场景不同。如果您需要执行 SQL 时支持特殊的数据算法，那么推荐使用 UDF，如果您需要在 Doris 上运行自定义的功能，或者是启动一个后台线程执行任务，那么推荐使用插件。

目前插件框架仅支持审计类插件。

注意：

- Doris 的插件框架是实验性功能，目前只支持 FE 插件，且默认是关闭的，可以通过 FE 配置 `plugin_enable=true` 打开

插件

一个 FE 的插件可以使一个 **zip 压缩包** 或者是一个 **目录**。其内容至少包含两个文件：`plugin.properties` 和 `.jar` 文件。`plugin.properties` 用于描述插件信息。

文件结构如下：

```
# plugin .zip
auditdemo.zip:
  -plugin.properties
  -auditdemo.jar
  -xxx.config
  -data/
  -test_data/

# plugin local directory
auditdemo/:
  -plugin.properties
  -auditdemo.jar
  -xxx.config
  -data/
  -test_data/
```

plugin.properties 内容示例:

```
### required:
#
# the plugin name
name = audit_plugin_demo
#
# the plugin type
type = AUDIT
#
# simple summary of the plugin
description = just for test
#
# Doris's version, like: 0.11.0
version = 0.11.0

### FE-Plugin optional:
#
# version of java the code is built against
# use the command "java -version" value, like 1.8.0, 9.0.1, 13.0.4
java.version = 1.8.31
#
# the name of the class to load, fully-qualified.
classname = AuditPluginDemo

### BE-Plugin optional:
# the name of the so to load
soName = example.so
```

编写插件

插件的开发环境依赖 Doris 的开发编译环境。所以请先确保 Doris 的开发编译环境运行正常。

fe_plugins 目录是 FE 插件的根模块。这个根模块统一管理插件所需的依赖。添加一个新的插件，相当于在这个根模块添加一个子模块。

创建插件模块

我们可以通过以下命令在 fe_plugins 目录创建一个子模块用户实现创建和创建工程。其中 doris-fe-test 为插件名称。

```
mvn archetype:generate -DarchetypeCatalog = internal -DgroupId = org.apache -DartifactId = doris-fe-test -DinteractiveMode = false
```

这个命令会创建一个新的 maven 工程，并且自动向 fe_plugins/pom.xml 中添加一个子模块:

```
.....
<groupId>org.apache</groupId>
<artifactId>doris-fe-plugins</artifactId>
<packaging>pom</packaging>
<version>1.0-SNAPSHOT</version>
<modules>
  <module>auditdemo</module>
  # new plugin module
  <module>doris-fe-test</module>
```

```
</modules>
.....
```

新的工程目录结构如下：

```
-doris-fe-test/
-pom.xml
-src/
  ---- main/java/org/apache/
  ----- App.java # mvn auto generate, ignore
  ---- test/java/org/apache
```

接下来我们在 main 目录下添加一个 assembly 目录来存放 plugin.properties 和 zip.xml。最终的工程目录结构如下：

```
-doris-fe-test/
-pom.xml
-src/
  ---- main/
  ----- assembly/
  ----- plugin.properties
  ----- zip.xml
  ----- java/org/apache/
  ----- App.java # mvn auto generate, ignore
  ---- test/java/org/apache
```

添加 zip.xml

zip.xml 用于描述最终生成的 zip 压缩包中的文件内容。（如 .jar file, plugin.properties 等等）

```
<assembly>
  <id>plugin</id>
  <formats>
    <format>zip</format>
  </formats>
  <!--IMPORTANT: must be false-->
  <includeBaseDirectory>false</includeBaseDirectory>
  <fileSets>
    <fileSet>
      <directory>target</directory>
      <includes>
        <include>*.jar</include>
      </includes>
      <outputDirectory>../outputDirectory</outputDirectory>
    </fileSet>

    <fileSet>
      <directory>src/main/assembly</directory>
      <includes>
        <include>plugin.properties</include>
      </includes>
      <outputDirectory>../outputDirectory</outputDirectory>
    </fileSet>
  </fileSets>
</assembly>
```

更新 pom.xml

接下来我们需要更新子模块的 pom.xml 文件，添加 doris-fe 依赖：

```
<?xml version="1.0" encoding="UTF-8"?>
<project xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"
  xmlns="http://maven.apache.org/POM/4.0.0"
  xsi:schemaLocation="http://maven.apache.org/POM/4.0.0 http://maven.apache.org/xsd/maven-4.0.0.xsd">
  <parent>
    <groupId>org.apache</groupId>
    <artifactId>doris-fe-plugins</artifactId>
    <version>1.0-SNAPSHOT</version>
  </parent>
  <modelVersion>4.0.0</modelVersion>

  <artifactId>auditloader</artifactId>
  <packaging>jar</packaging>

  <dependencies>
    <!-- doris-fe dependencies -->
    <dependency>
      <groupId>org.apache</groupId>
      <artifactId>doris-fe</artifactId>
    </dependency>

    <!-- other dependencies -->
    <dependency>
      ...
    </dependency>
  </dependencies>

  <build>
    <finalName>auditloader</finalName>
    <plugins>
      <plugin>
        <artifactId>maven-assembly-plugin</artifactId>
        <version>2.4.1</version>
        <configuration>
          <appendAssemblyId>false</appendAssemblyId>
          <descriptors>
            <descriptor>src/main/assembly/zip.xml</descriptor>
          </descriptors>
        </configuration>
        <executions>
          <execution>
            <id>make-assembly</id>
            <phase>package</phase>
            <goals>
              <goal>single</goal>
            </goals>
          </execution>
        </executions>
      </plugin>
    </plugins>
  </build>
</project>
```

实现插件

之后我们就可以开始进行插件功能的开发了。插件需要实现 Plugin 接口。具体可以参阅 Doris 自带的 auditdemo 插件示例代码。

编译

在编译插件之前，需要先执行 `sh build.sh --fe` 进行 Doris FE 代码的编译，并确保编译成功。

之后，执行 `sh build_plugin.sh` 编译所有插件。最终的产出会存放在 `fe_plugins/output` 目录中。

或者也可以执行 `sh build_plugin.sh --plugin your_plugin_name` 来仅编译指定的插件。

另一种开发方式

您可以直接通过修改自带的 auditdemo 插件示例代码进行开发。

部署

插件可以通过以下三种方式部署。

- 将 .zip 文件放在 Http 或 Https 服务器上。如：http://xxx.xxx.com/data/my_plugin.zip, Doris 会下载这个文件。同时需要在 properties 中设置 md5sum 的值，或者放置一个和 .zip 文件同名的 md5 文件，如 http://xxx.xxxxxx.com/data/my_plugin.zip.md5。其中内容为 .zip 文件的 MD5 值。
- 本地 .zip 文件。如：/home/work/data/plugin.zip。如果该插件仅用于 FE，则需部署在所有 FE 节点相同的目录下。否则，需要在所有 FE 和 BE 节点部署。
- 本地目录。如：/home/work/data/plugin/。相当于 .zip 文件解压后的目录。如果该插件仅用于 FE，则需部署在所有 FE 节点相同的目录下。否则，需要在所有 FE 和 BE 节点部署。

注意：需保证部署路径在整个插件生命周期内有效。

安装和卸载插件

通过如下命令安装和卸载插件。更多帮助请参阅 `HELP INSTALL PLUGIN`; `HELP UNINSTALL PLUGIN`; `HELP SHOW PLUGINS`;

```
mysql> install plugin from "/home/users/doris/auditloader.zip";
Query OK, 0 rows affected (0.09 sec)

mysql> show plugins\G
***** 1. row *****
      Name: auditloader
      Type: AUDIT
Description: load audit log to olap load, and user can view the statistic of queries
      Version: 0.12.0
JavaVersion: 1.8.31
      ClassName: AuditLoaderPlugin
      SoName: NULL
      Sources: /home/users/doris/auditloader.zip
      Status: INSTALLED
      Properties: {}
***** 2. row *****
```



```
Name: AuditLogBuilder
Type: AUDIT
Description: builtin audit logger
Version: 0.12.0
JavaVersion: 1.8.31
ClassName: org.apache.doris.qe.AuditLogBuilder
SoName: NULL
Sources: Builtin
Status: INSTALLED
Properties: {}
2 rows in set (0.00 sec)

mysql> uninstall plugin auditloader;
Query OK, 0 rows affected (0.05 sec)

mysql> show plugins;
Empty set (0.00 sec)
```

文件管理器

Doris 中的一些功能需要使用一些用户自定义的文件。比如用于访问外部数据源的公钥、密钥文件、证书文件等等。文件管理器提供这样一个功能，能够让用户预先上传这些文件并保存在 Doris 系统中，然后可以在其他命令中引用或访问。

名词解释

- BDBJE：Oracle Berkeley DB Java Edition。FE 中用于持久化元数据的分布式嵌入式数据库。
- SmallFileMgr：文件管理器。负责创建并维护用户的文件。

基本概念

文件是指用户创建并保存在 Doris 中的文件。

一个文件由 数据库名称 (database)、分类 (catalog) 和 文件名 (file_name) 共同定位。同时每个文件也有一个全局唯一的 id (file_id)，作为系统内的标识。

文件的创建和删除只能由拥有 admin 权限的用户进行操作。一个文件隶属于一个数据库。对某一数据库拥有访问权限（查询、导入、修改等等）的用户都可以使用该数据库下创建的文件。

具体操作

文件管理主要有三个命令：CREATE FILE，SHOW FILE 和 DROP FILE，分别为创建、查看和删除文件。这三个命令的具体语法可以通过连接到 Doris 后，执行 HELP cmd; 的方式查看帮助。

CREATE FILE

该语句用于创建并上传一个文件到 Doris 集群，具体操作可查看 [CREATE FILE](#)。

Examples:

1. 创建文件 ca.pem，分类为 kafka

```
CREATE FILE "ca.pem"
PROPERTIES
(
    "url" = "https://test.bj.bcebos.com/kafka-key/ca.pem",
    "catalog" = "kafka"
);
```

2. 创建文件 client.key，分类为 my_catalog

```
CREATE FILE "client.key"
IN my_database
PROPERTIES
(
    "url" = "https://test.bj.bcebos.com/kafka-key/client.key",
    "catalog" = "my_catalog",
```

```
"md5" = "b5bb901bf10f99205b39a46ac3557dd9"
);
```

SHOW FILE

该语句可以查看已经创建成功的文件，具体操作可查看 [SHOW FILE](#)。

Examples:

1. 查看数据库 my_database 中已上传的文件

```
SHOW FILE FROM my_database;
```

DROP FILE

该语句可以查看可以删除一个已经创建的文件，具体操作可查看 [DROP FILE](#)。

Examples:

1. 删除文件 ca.pem

```
DROP FILE "ca.pem" properties("catalog" = "kafka");
```

实现细节

创建和删除文件

当用户执行 CREATE FILE 命令后，FE 会从给定的 URL 下载文件。并将文件的内容以 Base64 编码的形式直接保存在 FE 的内存中。同时会将文件内容以及文件相关的元信息持久化在 BDBJE 中。所有被创建的文件，其元信息和文件内容都会常驻于 FE 的内存中。如果 FE 宕机重启，也会从 BDBJE 中加载元信息和文件内容到内存中。当文件被删除时，会直接从 FE 内存中删除相关信息，同时也从 BDBJE 中删除持久化的信息。

文件的使用

如果是 FE 端需要使用创建的文件，则 SmallFileMgr 会直接将 FE 内存中的数据保存为本地文件，存储在指定的目录中，并返回本地的文件路径供使用。

如果是 BE 端需要使用创建的文件，BE 会通过 FE 的 http 接口 /api/get_small_file 将文件内容下载到 BE 上指定的目录中，供使用。同时，BE 也会在内存中记录当前已经下载过的文件的信息。当 BE 请求一个文件时，会先查看本地文件是否存在并校验。如果校验通过，则直接返回本地文件路径。如果校验失败，则会删除本地文件，重新从 FE 下载。当 BE 重启时，会预先加载本地的文件到内存中。

使用限制

因为文件元信息和内容都存储于 FE 的内存中。所以默认仅支持上传大小在 1MB 以内的文件。并且总文件数量限制为 100 个。可以通过下一小节介绍的配置项进行修改。

相关配置

1. FE 配置

- `small_file_dir`: 用于存放上传文件的路径, 默认为 FE 运行目录的 `small_files/` 目录下。
- `max_small_file_size_bytes`: 单个文件大小限制, 单位为字节。默认为 1MB。大于该配置的文件创建将会被拒绝。
- `max_small_file_number`: 一个 Doris 集群支持的总文件数量。默认为 100。当创建的文件数超过这个值后, 后续的创建将会被拒绝。

如果需要上传更多文件或提高单个文件的大小限制, 可以通过 `ADMIN SET CONFIG` 命令修改 `max_small_file_size_bytes` 和 `max_small_file_number` 参数。但文件数量和大小的增加, 会导致 FE 内存使用量的增加。

2. BE 配置

- `small_file_dir`: 用于存放从 FE 下载的文件的路径, 默认为 BE 运行目录的 `lib/small_files/` 目录下。

更多帮助

关于文件管理器使用的更多详细语法及最佳实践, 请参阅 [CREATE FILE](#)、[DROP FILE](#) 和 [SHOW FILE](#) 命令手册, 你也可以在 MySQL 客户端命令行下输入 `HELP CREATE FILE`、`HELP DROP FILE` 和 `HELP SHOW FILE` 获取更多帮助信息。

Compaction 优化

Doris 通过类似 LSM-Tree 的结构写入数据，在后台通过 Compaction 机制不断将小文件合并成有序的大文件，同时也会处理数据的删除、更新等操作。适当的调整 Compaction 的策略，可以极大地提升导入效率和查询效率。Doris 提供如下几种 compaction 方式进行调优：

Vertical compaction

自 Doris 1.2.2 版本起支持 Vertical compaction

Vertical compaction 是 Doris 1.2.2 版本中实现的新的 Compaction 算法，用于解决大宽表场景下的 Compaction 执行效率和资源开销问题。可以有效降低 Compaction 的内存开销，并提升 Compaction 的执行速度。

实际测试中，Vertical compaction 使用内存仅为原有 compaction 算法的 1/10，同时 compaction 速率提升 15%。

Vertical compaction 中将按行合并的方式改变为按列组合并，每次参与合并的粒度变成列组，降低单次 compaction 内部参与的数据量，减少 compaction 期间的内存使用。

开启和配置方法 (BE 配置): `-enable_vertical_compaction = true` 可以开启该功能

- `vertical_compaction_num_columns_per_group = 5` 每个列组包含的列个数，经测试，默认 5 列一组 compaction 的效率及内存使用较友好
- `vertical_compaction_max_segment_size` 用于配置 vertical compaction 之后落盘文件的大小，默认值 268435456(字节)

Segment compaction

Segment compaction 主要应对单批次大数据量的导入场景。和 Vertical compaction 的触发机制不同，Segment compaction 是在导入过程中，针对一批次数据内，多个 Segment 进行的合并操作。这种机制可以有效减少最终生成的 Segment 数量，避免 -238 (OLAP_ERR_TOO_MANY_SEGMENTS) 错误的出现。Segment compaction 有以下特点：

- 可以减少导入产生的 segment 数量
- 合并过程与导入过程并行，不会额外增加导入时间
- 导入过程中的内存和计算资源的使用量会有增加，但因为平摊在整个导入过程中所以涨幅较低
- 经过 Segment compaction 后的数据在进行后续查询以及标准 compaction 时会有资源和性能上的优势

开启和配置方法 (BE 配置):

- `enable_segcompaction = true` 可以使能该功能

- `segcompaction_batch_size` 用于配置合并的间隔。默认 10 表示每生成 10 个 segment 文件将会进行一次 segment compaction。一般设置为 10 - 30，过大的值会增加 segment compaction 的内存用量。

如有以下场景或问题，建议开启此功能：

- 导入大量数据触发 `OLAP_ERR_TOO_MANY_SEGMENTS` (errcode -238) 错误导致导入失败。此时建议打开 segment compaction 的功能，在导入过程中对 segment 进行合并控制最终的数量。
- 导入过程中产生大量的小文件：虽然导入数据量不大，但因为低基数数据，或因为内存紧张触发 memtable 提前下刷，产生大量小 segment 文件也可能会触发 `OLAP_ERR_TOO_MANY_SEGMENTS` 导致导入失败。此时建议打开该功能。
- 导入大量数据后立即进行查询：刚导入完成、标准 compaction 还没有完成工作时，此时 segment 文件过多会影响后续查询效率。如果用户有导入后立即查询的需求，建议打开该功能。
- 导入后标准 compaction 压力大：segment compaction 本质上是把标准 compaction 的一部分压力放在了导入过程中进行处理，此时建议打开该功能。

不建议使用的情况：- 导入操作本身已经耗尽了内存资源时，不建议使用 segment compaction 以免进一步增加内存压力使导入失败。

关于 segment compaction 的实现和测试结果可以查阅[此链接](#)。

单副本 compaction

默认情况下，多个副本的 compaction 是独立进行的，每个副本在都需要消耗 CPU 和 IO 资源。开启单副本 compaction 后，在一个副本进行 compaction 后，其他几个副本拉取 compaction 后的文件，因此 CPU 资源只需要消耗 1 次，节省了 $N - 1$ 倍 CPU 消耗（ N 是副本数）。

单副本 compaction 在表的 PROPERTIES 中通过参数 `enable_single_replica_compaction` 指定，默认为 false 不开启，设置为 true 开启。

该参数可以在建表时指定，或者通过 `ALTER TABLE table_name SET("enable_single_replica_compaction" = "true")` 来修改。

Compaction 策略

Compaction 策略决定什么时候将哪些小文件合并成大文件。Doris 当前提供了 2 种 compaction 策略，通过表属性的 `compaction_policy` 参数指定。

size_based compaction 策略

size_based compaction 策略是默认策略，对大多数场景适用。

```
"compaction_policy" = "size_based"
```

time_series compaction 策略

time_series compaction 策略是为日志、时序等场景优化的策略。它利用时序数据具有时间局部性的特点，将相邻时间写入的小文件合并成大文件，每个文件只会参与一次 compaction 就合并成比较大的文件，减少反复

compaction 带来的写放大。

```
"compaction_policy" = "time_series"
```

time_series compaction 策略在下面 3 个条件任意一个满足的时候触发小文件合并： - 未合并的文件大小超过 time_series_compaction_goal_size_mbytes (默认 1GB) - 未合并的文件个数超过 time_series_compaction_file_count_threshold (默认 2000) - 距离上次合并的时间超过 time_series_compaction_time_threshold_seconds (默认 1小时)

上述参数在表的 PROPERTIES 中设置，可以在建表时指定，或者通过 ALTER TABLE table_name SET("name" = "value") 修改。

Compaction 并发控制

Compaction 在后台执行需要消耗 CPU 和 IO 资源，可以通过控制 compaction 并发线程数来控制资源消耗。

compaction 并发线程数在 BE 的配置文件中配置，包括下面几个： - max_base_compaction_threads: base compaction 的线程数，默认是 4 - max_cumu_compaction_threads: cumulative compaction 的线程数，默认是 10 - max_single_replica_compaction_threads: 单副本 compaction 拉取数据文件的线程数，默认是 10

系统表

自 Doris 1.2 版本起支持 rowset

描述

rowsets 是 Doris 内置的一张系统表，存放在information_schema数据库下。通过 rowsets 系统表可以查看各个BE 当前 rowsets 情况。

rowsets 表结构为：

```
MySQL [(none)]> desc information_schema.rowsets;
```

Field	Type	Null	Key	Default	Extra
BACKEND_ID	BIGINT	Yes	false	NULL	
ROWSET_ID	VARCHAR(*)	Yes	false	NULL	
TABLET_ID	BIGINT	Yes	false	NULL	
ROWSET_NUM_ROWS	BIGINT	Yes	false	NULL	
TXN_ID	BIGINT	Yes	false	NULL	
NUM_SEGMENTS	BIGINT	Yes	false	NULL	
START_VERSION	BIGINT	Yes	false	NULL	
END_VERSION	BIGINT	Yes	false	NULL	
INDEX_DISK_SIZE	BIGINT	Yes	false	NULL	
DATA_DISK_SIZE	BIGINT	Yes	false	NULL	
CREATION_TIME	BIGINT	Yes	false	NULL	
NEWEST_WRITE_TIMESTAMP	BIGINT	Yes	false	NULL	

Example

```
select * from information_schema.rowsets where BACKEND_ID = 10004 limit 10;
```

BACKEND_ID	ROWSET_ID	TABLET_ID	ROWSET_NUM_ROWS	TXN_ID	NUM_SEGMENTS	START_VERSION	END_VERSION	INDEX_DISK_SIZE	DATA_DISK_SIZE	CREATION_TIME	OLDEST_WRITE_TIMESTAMP	NEWEST_WRITE_TIMESTAMP
10004	02000000000000994847fbd41a42297d7c7a57d3bcb46f8c	10771	66850	6	3	3	2894	688855	1659964582	1659964581	1659964581	1659964581
10004	020000000000008d4847fbd41a42297d7c7a57d3bcb46f8c	10771	66850	2	2	2	2894	688855	1659964575	1659964574	1659964574	1659964574
10004	02000000000000894847fbd41a42297d7c7a57d3bcb46f8c	10771	0	0	0	1	0	0	1659964567	1659964567	1659964567	1659964567
10004	020000000000009a4847fbd41a42297d7c7a57d3bcb46f8c	10773	66639	6	3	3	2897	686828	1659964582	1659964581	1659964581	1659964581

[illegible]

KeyWords

rowsets, information_schema

Star Schema Benchmark

Star Schema Benchmark

[Star Schema Benchmark\(SSB\)](#) 是一个轻量级的数仓场景下的性能测试集。SSB 基于 [TPC-H](#) 提供了一个简化版的星型模型数据集，主要用于测试在星型模型下，多表关联查询的性能表现。另外，业界内通常也会将 SSB 打平为宽表模型（以下简称：SSB flat），来测试查询引擎的性能，参考[Clickhouse](#)。

本文档主要介绍 Apache Doris 在 SSB 1000G 测试集上的性能表现。

在 SSB 标准测试数据集上的 13 个查询上，我们基于 Apache Doris 2.0.15.1 版本进行了测试。

1. 硬件环境

硬件	配置说明
机器数量	4 台阿里云主机（1 个 FE，3 个 BE）
CPU	Intel Xeon (Ice Lake) Platinum 8369B 32核
内存	128G
磁盘	阿里云 ESSD (PL0)

2. 软件环境

- Doris 部署 3BE 1FE
- 内核版本：Linux version 5.15.0-101-generic
- 操作系统版本：Ubuntu 20.04 LTS (Focal Fossa)
- Doris 软件版本：Apache Doris 2.0.15.1
- JDK：openjdk version “1.8.0_352-352”

3. 测试数据量

SSB 表名	行数	备注
lineorder	5,999,989,709	商品订单明细表表
customer	30,000,000	客户信息表
part	2,000,000	零件信息表
supplier	2,000,000	供应商信息表
dates	2,556	日期表
lineorder_flat	5,999,989,709	数据展平后的宽表

4. SSB 宽表测试结果

使用 Apache Doris 2.0.15.1 版本进行测试结果如下：

Query	Doris 2.0.15.1 (ms)
q1.1	80
q1.2	10
q1.3	110
q2.1	1680
q2.2	1210
q2.3	1060
q3.1	2010
q3.2	1560
q3.3	600
q3.4	10
q4.1	2380
q4.2	190
q4.3	120
Total	11020

5. 标准 SSB 测试结果

使用 Apache Doris 2.0.15.1 版本进行测试结果如下：

Query	Doris 2.0.15.1 (ms)
q1.1	330
q1.2	80
q1.3	80
q2.1	1780
q2.2	1970
q2.3	1510
q3.1	4000
q3.2	1720
q3.3	1510
q3.4	160
q4.1	4010
q4.2	840
q4.3	400
Total	19390

6. 环境准备

请先参照 [官方文档](#) 进行 Apache Doris 的安装部署，以获得一个正常运行中的 Doris 集群（至少包含 1 FE 1 BE，推荐 1 FE 3 BE）。

7. 数据准备

7.1 下载安装 SSB 数据生成工具。

执行以下脚本下载并编译 [ssb-tools](#) 工具。

```
sh bin/build-ssb-dbggen.sh
```

安装成功后，将在 ssb-dbggen/ 目录下生成 dbggen 二进制文件。

7.2 生成 SSB 测试集

执行以下脚本生成 SSB 数据集：

```
sh bin/gen-ssb-data.sh -s 1000
```

注 1：通过 `sh gen-ssb-data.sh -h` 查看脚本帮助。

注 2：数据会以 .tbl 为后缀生成在 ssb-data/ 目录下。文件总大小约 600GB。生成时间可能在数分钟到 1 小时不等。

注 3：默认生成 100G 的标准测试数据集

7.3 建表

7.3.1 准备 doris-cluster.conf 文件

在调用导入脚本前，需要将 FE 的 ip 端口等信息写在 doris-cluster.conf 文件中。

文件位置在 \${DORIS_HOME}/tools/ssb-tools/conf/ 目录下。

文件内容包括 FE 的 ip，HTTP 端口，用户名，密码以及待导入数据的 DB 名称：

```
# Any of FE host
export FE_HOST='127.0.0.1'
# http_port in fe.conf
export FE_HTTP_PORT=8030
# query_port in fe.conf
export FE_QUERY_PORT=9030
# Doris username
export USER='root'
# Doris password
export PASSWORD=''
```

```
# The database where SSB tables located
export DB='ssb'
```

7.3.2 执行以下脚本生成创建 SSB 表

```
sh bin/create-ssb-tables.sh -s 1000
```

或者复制 [create-ssb-tables.sql](#) 和 [create-ssb-flat-table.sql](#) 中的建表语句，在 MySQL 客户端中执行。

7.4 导入数据

我们使用以下命令完成 SSB 测试集所有数据导入及 SSB FLAT 宽表数据合成并导入到表里。

```
sh bin/load-ssb-data.sh
```

7.5 检查导入数据

```
select count(*) from part;
select count(*) from customer;
select count(*) from supplier;
select count(*) from dates;
select count(*) from lineorder;
select count(*) from lineorder_flat;
```

7.6 查询测试

SSB-FIAT 查询语句: [ssb-flat-queries](#)

标准 SSB 查询语句: [ssb-queries](#)

7.6.1 SSB FLAT 测试 SQL

```
--Q1.1
SELECT SUM(LO_EXTENDEDPRICE * LO_DISCOUNT) AS revenue
FROM lineorder_flat
WHERE
    LO_ORDERDATE >= 19930101
    AND LO_ORDERDATE <= 19931231
    AND LO_DISCOUNT BETWEEN 1 AND 3
    AND LO_QUANTITY < 25;

--Q1.2
SELECT SUM(LO_EXTENDEDPRICE * LO_DISCOUNT) AS revenue
FROM lineorder_flat
WHERE
    LO_ORDERDATE >= 19940101
    AND LO_ORDERDATE <= 19940131
    AND LO_DISCOUNT BETWEEN 4 AND 6
    AND LO_QUANTITY BETWEEN 26 AND 35;

--Q1.3
SELECT SUM(LO_EXTENDEDPRICE * LO_DISCOUNT) AS revenue
```

```

FROM lineorder_flat
WHERE
    weekofyear(LO_ORDERDATE) = 6
    AND LO_ORDERDATE >= 19940101
    AND LO_ORDERDATE <= 19941231
    AND LO_DISCOUNT BETWEEN 5 AND 7
    AND LO_QUANTITY BETWEEN 26 AND 35;

--Q2.1
SELECT
    SUM(LO_REVENUE), (LO_ORDERDATE DIV 10000) AS YEAR,
    P_BRAND
FROM lineorder_flat
WHERE P_CATEGORY = 'MFGR#12' AND S_REGION = 'AMERICA'
GROUP BY YEAR, P_BRAND
ORDER BY YEAR, P_BRAND;

--Q2.2
SELECT
    SUM(LO_REVENUE), (LO_ORDERDATE DIV 10000) AS YEAR,
    P_BRAND
FROM lineorder_flat
WHERE
    P_BRAND >= 'MFGR#2221'
    AND P_BRAND <= 'MFGR#2228'
    AND S_REGION = 'ASIA'
GROUP BY YEAR, P_BRAND
ORDER BY YEAR, P_BRAND;

--Q2.3
SELECT
    SUM(LO_REVENUE), (LO_ORDERDATE DIV 10000) AS YEAR,
    P_BRAND
FROM lineorder_flat
WHERE
    P_BRAND = 'MFGR#2239'
    AND S_REGION = 'EUROPE'
GROUP BY YEAR, P_BRAND
ORDER BY YEAR, P_BRAND;

--Q3.1
SELECT
    C_NATION,
    S_NATION, (LO_ORDERDATE DIV 10000) AS YEAR,
    SUM(LO_REVENUE) AS revenue
FROM lineorder_flat
WHERE
    C_REGION = 'ASIA'
    AND S_REGION = 'ASIA'
    AND LO_ORDERDATE >= 19920101
    AND LO_ORDERDATE <= 19971231
GROUP BY C_NATION, S_NATION, YEAR
ORDER BY YEAR ASC, revenue DESC;

--Q3.2
SELECT
    C_CITY,
    S_CITY, (LO_ORDERDATE DIV 10000) AS YEAR,
    SUM(LO_REVENUE) AS revenue
FROM lineorder_flat
WHERE
    C_NATION = 'UNITED STATES'
    AND S_NATION = 'UNITED STATES'
    AND LO_ORDERDATE >= 19920101
    AND LO_ORDERDATE <= 19971231

```

```

GROUP BY C_CITY, S_CITY, YEAR
ORDER BY YEAR ASC, revenue DESC;

--Q3.3
SELECT
    C_CITY,
    S_CITY, (LO_ORDERDATE DIV 10000) AS YEAR,
    SUM(LO_REVENUE) AS revenue
FROM lineorder_flat
WHERE
    C_CITY IN ('UNITED KI1', 'UNITED KI5')
    AND S_CITY IN ('UNITED KI1', 'UNITED KI5')
    AND LO_ORDERDATE >= 19920101
    AND LO_ORDERDATE <= 19971231
GROUP BY C_CITY, S_CITY, YEAR
ORDER BY YEAR ASC, revenue DESC;

--Q3.4
SELECT
    C_CITY,
    S_CITY, (LO_ORDERDATE DIV 10000) AS YEAR,
    SUM(LO_REVENUE) AS revenue
FROM lineorder_flat
WHERE
    C_CITY IN ('UNITED KI1', 'UNITED KI5')
    AND S_CITY IN ('UNITED KI1', 'UNITED KI5')
    AND LO_ORDERDATE >= 19971201
    AND LO_ORDERDATE <= 19971231
GROUP BY C_CITY, S_CITY, YEAR
ORDER BY YEAR ASC, revenue DESC;

--Q4.1
SELECT (LO_ORDERDATE DIV 10000) AS YEAR,
    C_NATION,
    SUM(LO_REVENUE - LO_SUPPLYCOST) AS profit
FROM lineorder_flat
WHERE
    C_REGION = 'AMERICA'
    AND S_REGION = 'AMERICA'
    AND P_MFGR IN ('MFGR#1', 'MFGR#2')
GROUP BY YEAR, C_NATION
ORDER BY YEAR ASC, C_NATION ASC;

--Q4.2
SELECT (LO_ORDERDATE DIV 10000) AS YEAR,
    S_NATION,
    P_CATEGORY,
    SUM(LO_REVENUE - LO_SUPPLYCOST) AS profit
FROM lineorder_flat
WHERE
    C_REGION = 'AMERICA'
    AND S_REGION = 'AMERICA'
    AND LO_ORDERDATE >= 19970101
    AND LO_ORDERDATE <= 19981231
    AND P_MFGR IN ('MFGR#1', 'MFGR#2')
GROUP BY YEAR, S_NATION, P_CATEGORY
ORDER BY
    YEAR ASC,
    S_NATION ASC,
    P_CATEGORY ASC;

--Q4.3
SELECT (LO_ORDERDATE DIV 10000) AS YEAR,
    S_CITY,
    P_BRAND,

```

```

        SUM(LO_REVENUE - LO_SUPPLYCOST) AS profit
FROM lineorder_flat
WHERE
    S_NATION = 'UNITED STATES'
    AND LO_ORDERDATE >= 19970101
    AND LO_ORDERDATE <= 19981231
    AND P_CATEGORY = 'MFGR#14'
GROUP BY YEAR, S_CITY, P_BRAND
ORDER BY YEAR ASC, S_CITY ASC, P_BRAND ASC;

```

7.6.2 SSB 标准测试 SQL

```

--Q1.1
SELECT SUM(lo_extendedprice * lo_discount) AS REVENUE
FROM lineorder, dates
WHERE
    lo_orderdate = d_datekey
    AND d_year = 1993
    AND lo_discount BETWEEN 1 AND 3
    AND lo_quantity < 25;

--Q1.2
SELECT SUM(lo_extendedprice * lo_discount) AS REVENUE
FROM lineorder, dates
WHERE
    lo_orderdate = d_datekey
    AND d_yearmonth = 'Jan1994'
    AND lo_discount BETWEEN 4 AND 6
    AND lo_quantity BETWEEN 26 AND 35;

--Q1.3
SELECT
    SUM(lo_extendedprice * lo_discount) AS REVENUE
FROM lineorder, dates
WHERE
    lo_orderdate = d_datekey
    AND d_weeknuminyear = 6
    AND d_year = 1994
    AND lo_discount BETWEEN 5 AND 7
    AND lo_quantity BETWEEN 26 AND 35;

--Q2.1
SELECT SUM(lo_revenue), d_year, p_brand
FROM lineorder, dates, part, supplier
WHERE
    lo_orderdate = d_datekey
    AND lo_partkey = p_partkey
    AND lo_suppkey = s_suppkey
    AND p_category = 'MFGR#12'
    AND s_region = 'AMERICA'
GROUP BY d_year, p_brand
ORDER BY p_brand;

--Q2.2
SELECT SUM(lo_revenue), d_year, p_brand
FROM lineorder, dates, part, supplier
WHERE
    lo_orderdate = d_datekey
    AND lo_partkey = p_partkey
    AND lo_suppkey = s_suppkey
    AND p_brand BETWEEN 'MFGR#2221' AND 'MFGR#2228'
    AND s_region = 'ASIA'

```



```

GROUP BY d_year, p_brand
ORDER BY d_year, p_brand;

--Q2.3
SELECT SUM(lo_revenue), d_year, p_brand
FROM lineorder, dates, part, supplier
WHERE
    lo_orderdate = d_datekey
    AND lo_partkey = p_partkey
    AND lo_suppkey = s_suppkey
    AND p_brand = 'MFGR#2239'
    AND s_region = 'EUROPE'
GROUP BY d_year, p_brand
ORDER BY d_year, p_brand;

--Q3.1
SELECT
    c_nation,
    s_nation,
    d_year,
    SUM(lo_revenue) AS REVENUE
FROM customer, lineorder, supplier, dates
WHERE
    lo_custkey = c_custkey
    AND lo_suppkey = s_suppkey
    AND lo_orderdate = d_datekey
    AND c_region = 'ASIA'
    AND s_region = 'ASIA'
    AND d_year >= 1992
    AND d_year <= 1997
GROUP BY c_nation, s_nation, d_year
ORDER BY d_year ASC, REVENUE DESC;

--Q3.2
SELECT
    c_city,
    s_city,
    d_year,
    SUM(lo_revenue) AS REVENUE
FROM customer, lineorder, supplier, dates
WHERE
    lo_custkey = c_custkey
    AND lo_suppkey = s_suppkey
    AND lo_orderdate = d_datekey
    AND c_nation = 'UNITED STATES'
    AND s_nation = 'UNITED STATES'
    AND d_year >= 1992
    AND d_year <= 1997
GROUP BY c_city, s_city, d_year
ORDER BY d_year ASC, REVENUE DESC;

--Q3.3
SELECT
    c_city,
    s_city,
    d_year,
    SUM(lo_revenue) AS REVENUE
FROM customer, lineorder, supplier, dates
WHERE
    lo_custkey = c_custkey
    AND lo_suppkey = s_suppkey
    AND lo_orderdate = d_datekey
    AND (
        c_city = 'UNITED KI1'
        OR c_city = 'UNITED KI5'

```

```

    )
    AND (
        s_city = 'UNITED KI1'
        OR s_city = 'UNITED KI5'
    )
    AND d_year >= 1992
    AND d_year <= 1997
GROUP BY c_city, s_city, d_year
ORDER BY d_year ASC, REVENUE DESC;

--Q3.4
SELECT
    c_city,
    s_city,
    d_year,
    SUM(lo_revenue) AS REVENUE
FROM customer, lineorder, supplier, dates
WHERE
    lo_custkey = c_custkey
    AND lo_suppkey = s_suppkey
    AND lo_orderdate = d_datekey
    AND (
        c_city = 'UNITED KI1'
        OR c_city = 'UNITED KI5'
    )
    AND (
        s_city = 'UNITED KI1'
        OR s_city = 'UNITED KI5'
    )
    AND d_yearmonth = 'Dec1997'
GROUP BY c_city, s_city, d_year
ORDER BY d_year ASC, REVENUE DESC;

--Q4.1
SELECT
    d_year,
    c_nation,
    SUM(lo_revenue - lo_supplycost) AS PROFIT
FROM dates, customer, supplier, part, lineorder
WHERE
    lo_custkey = c_custkey
    AND lo_suppkey = s_suppkey
    AND lo_partkey = p_partkey
    AND lo_orderdate = d_datekey
    AND c_region = 'AMERICA'
    AND s_region = 'AMERICA'
    AND (
        p_mfgr = 'MFGR#1'
        OR p_mfgr = 'MFGR#2'
    )
GROUP BY d_year, c_nation
ORDER BY d_year, c_nation;

--Q4.2
SELECT
    d_year,
    s_nation,
    p_category,
    SUM(lo_revenue - lo_supplycost) AS PROFIT
FROM dates, customer, supplier, part, lineorder
WHERE
    lo_custkey = c_custkey
    AND lo_suppkey = s_suppkey
    AND lo_partkey = p_partkey
    AND lo_orderdate = d_datekey

```

```

AND c_region = 'AMERICA'
AND s_region = 'AMERICA'
AND (
    d_year = 1997
    OR d_year = 1998
)
AND (
    p_mfgr = 'MFGR#1'
    OR p_mfgr = 'MFGR#2'
)
GROUP BY d_year, s_nation, p_category
ORDER BY d_year, s_nation, p_category;

--Q4.3
SELECT
    d_year,
    s_city,
    p_brand,
    SUM(lo_revenue - lo_supplycost) AS PROFIT
FROM dates, customer, supplier, part, lineorder
WHERE
    lo_custkey = c_custkey
AND lo_suppkey = s_suppkey
AND lo_partkey = p_partkey
AND lo_orderdate = d_datekey
AND s_nation = 'UNITED STATES'
AND (
    d_year = 1997
    OR d_year = 1998
)
AND p_category = 'MFGR#14'
GROUP BY d_year, s_city, p_brand
ORDER BY d_year, s_city, p_brand;

```


TPC-H Benchmark

TPC-H Benchmark

TPC-H 是一个决策支持基准（Decision Support Benchmark），它由一套面向业务的特别查询和并发数据修改组成。查询和填充数据库的数据具有广泛的行业相关性。这个基准测试演示了检查大量数据、执行高度复杂的查询并回答关键业务问题的决策支持系统。TPC-H 报告的性能指标称为 TPC-H 每小时复合查询性能指标 (QphH@Size)，反映了系统处理查询能力的多个方面。这些方面包括执行查询时所选择的数据库大小，由单个流提交查询时的查询处理能力，以及由多个并发用户提交查询时的查询吞吐量。

本文档主要介绍 Doris 在 TPC-H 1000G 测试集上的性能表现。

在 TPC-H 标准测试数据集上的 22 个查询上，我们基于 Apache Doris 2.1.7-rc03 和 Apache Doris 2.0.15.1 版本进行了对比测试。



TPCDS_1000G

1. 硬件环境

硬件	配置说明
机器数量	4 台阿里云主机（1 个 FE，3 个 BE）
CPU	Intel Xeon (Ice Lake) Platinum 8369B 32核
内存	128G
磁盘	阿里云 ESSD (PL0)

2. 软件环境

- Doris 部署 3BE 1FE
- 内核版本：Linux version 5.15.0-101-generic
- 操作系统版本：Ubuntu 20.04 LTS (Focal Fossa)
- Doris 软件版本：Apache Doris 2.1.7-rc03、Apache Doris 2.0.15.1
- JDK：openjdk version “1.8.0_352-352”

3. 测试数据量

整个测试模拟生成 TPC-H 1000G 的数据分别导入到 Apache Doris 2.1.7-rc03 和 Apache Doris 2.0.15.1 版本进行测试，下面是表的相关说明及数据量。

TPC-H 表名	行数	备注
REGION	5	区域表
NATION	25	国家表
SUPPLIER	1000 万	供应商表
PART	2 亿	零部件表
PARTSUPP	8 亿	零部件供应表
CUSTOMER	1.5 亿	客户表
ORDERS	15 亿	订单表
LINEITEM	60 亿	订单明细表

4. 测试 SQL

TPC-H 22 个测试查询语句：[TPCH-Query-SQL](#)

5. 测试结果

这里我们使用 Apache Doris 2.1.7-rc03 和 Apache Doris 2.0.15.1 版本进行对比测试，测试结果如下：

Query	Apache Doris 2.1.7-rc03 (ms)	Apache Doris 2.0.15.1-rc01 (ms)
Q1	11880	12270
Q2	280	290
Q3	3890	4610
Q4	2570	3040
Q5	6630	8450
Q6	170	180
Q7	2420	4870
Q8	3730	3850
Q9	15910	25860
Q10	7880	8650
Q11	560	490
Q12	500	660
Q13	9540	9920
Q14	590	740
Q15	1170	1150

Query	Apache Doris 2.1.7-rc03 (ms)	Apache Doris 2.0.15.1-rc01 (ms)
Q16	910	1520
Q17	1920	1770
Q18	17700	18760
Q19	2370	3240
Q20	560	830
Q21	9150	10150
Q22	1130	1390
Total	101460	122690

6. 环境准备

请先参照 [官方文档](#) 进行 Doris 的安装部署，以获得一个正常运行中的 Doris 集群（至少包含 1 FE 1 BE，推荐 1 FE 3 BE）。

7. 数据准备

7.1 下载安装 TPC-H 数据生成工具

执行以下脚本下载并编译 [tpch-tools](#) 工具。

```
sh bin/build-tpch-dbggen.sh
```

安装成功后，将在 TPC-H_Tools_v3.0.0/ 目录下生成 dbgen 二进制文件。

7.2 生成 TPC-H 测试集

执行以下脚本生成 TPC-H 数据集：

```
sh bin/gen-tpch-data.sh -s 1000
```

注 1：通过 `sh gen-tpch-data.sh -h` 查看脚本帮助。

注 2：数据会以 .tbl 为后缀生成在 tpch-data/ 目录下。文件总大小约 1000GB。生成时间可能在数分钟到 1 小时不等。

注 3：默认生成 100G 的标准测试数据集

7.3 建表

7.3.1 准备 doris-cluster.conf 文件

在调用导入脚本前，需要将 FE 的 ip 端口等信息写在 doris-cluster.conf 文件中。

文件位置在 \${DORIS_HOME}/tools/tpch-tools/conf/ 目录下。

文件内容包括 FE 的 ip，HTTP 端口，用户名，密码以及待导入数据的 DB 名称：

```
# Any of FE host
export FE_HOST='127.0.0.1'
# http_port in fe.conf
export FE_HTTP_PORT=8030
# query_port in fe.conf
export FE_QUERY_PORT=9030
# Doris username
export USER='root'
# Doris password
export PASSWORD=''
# The database where TPC-H tables located
export DB='tpch'
```

7.3.2 执行以下脚本生成创建 TPC-H 表

```
sh bin/create-tpch-tables.sh -s 1000
```

或者复制 [create-tpch-tables.sql](#) 中的建表语句，在 Doris 中执行。

7.4 导入数据

通过下面的命令执行数据导入：

```
sh bin/load-tpch-data.sh
```

7.5 检查导入数据

执行下面的 SQL 语句检查导入的数据与上面的数据量一致。

```
select count(*) from lineitem;
select count(*) from orders;
select count(*) from partsupp;
select count(*) from part;
select count(*) from customer;
select count(*) from supplier;
select count(*) from nation;
select count(*) from region;
select count(*) from revenue0;
```

7.6 查询测试

7.6.1 执行查询脚本

执行上面的测试 SQL 或者 执行下面的命令

```
sh bin/run-tpch-queries.sh -s 1000
```

7.6.2 单个 SQL 执行

下面是测试时使用的 SQL 语句，你也可以从代码库里获取最新的 SQL。最新测试查询语句地址：[TPC-H 测试查询语句](#)

```
--Q1
select
  l_returnflag,
  l_linestatus,
  sum(l_quantity) as sum_qty,
  sum(l_extendedprice) as sum_base_price,
  sum(l_extendedprice * (1 - l_discount)) as sum_disc_price,
  sum(l_extendedprice * (1 - l_discount) * (1 + l_tax)) as sum_charge,
  avg(l_quantity) as avg_qty,
  avg(l_extendedprice) as avg_price,
  avg(l_discount) as avg_disc,
  count(*) as count_order
from
  lineitem
where
  l_shipdate <= date '1998-12-01' - interval '90' day
group by
  l_returnflag,
  l_linestatus
order by
  l_returnflag,
  l_linestatus;

--Q2
select
  s_acctbal,
  s_name,
  n_name,
  p_partkey,
  p_mfgr,
  s_address,
  s_phone,
  s_comment
from
  part,
  supplier,
  partsupp,
  nation,
  region
where
  p_partkey = ps_partkey
  and s_suppkey = ps_suppkey
  and p_size = 15
  and p_type like '%BRASS'
  and s_nationkey = n_nationkey
  and n_regionkey = r_regionkey
```



```

and r_name = 'EUROPE'
and ps_supplycost = (
    select
        min(ps_supplycost)
    from
        partsupp,
        supplier,
        nation,
        region
    where
        p_partkey = ps_partkey
        and s_suppkey = ps_suppkey
        and s_nationkey = n_nationkey
        and n_regionkey = r_regionkey
        and r_name = 'EUROPE'
)
order by
    s_acctbal desc,
    n_name,
    s_name,
    p_partkey
limit 100;

--Q3
select
    l_orderkey,
    sum(l_extendedprice * (1 - l_discount)) as revenue,
    o_orderdate,
    o_shippriority
from
    customer,
    orders,
    lineitem
where
    c_mktsegment = 'BUILDING'
    and c_custkey = o_custkey
    and l_orderkey = o_orderkey
    and o_orderdate < date '1995-03-15'
    and l_shipdate > date '1995-03-15'
group by
    l_orderkey,
    o_orderdate,
    o_shippriority
order by
    revenue desc,
    o_orderdate
limit 10;

--Q4
select
    o_orderpriority,
    count(*) as order_count
from
    orders
where
    o_orderdate >= date '1993-07-01'
    and o_orderdate < date '1993-07-01' + interval '3' month
    and exists (
        select
            *
        from
            lineitem
        where
            l_orderkey = o_orderkey
            and l_commitdate < l_receiptdate
    )

```

```

    )
group by
    o_orderpriority
order by
    o_orderpriority;

--Q5
select
    n_name,
    sum(l_extendedprice * (1 - l_discount)) as revenue
from
    customer,
    orders,
    lineitem,
    supplier,
    nation,
    region
where
    c_custkey = o_custkey
    and l_orderkey = o_orderkey
    and l_suppkey = s_suppkey
    and c_nationkey = s_nationkey
    and s_nationkey = n_nationkey
    and n_regionkey = r_regionkey
    and r_name = 'ASIA'
    and o_orderdate >= date '1994-01-01'
    and o_orderdate < date '1994-01-01' + interval '1' year
group by
    n_name
order by
    revenue desc;

--Q6
select
    sum(l_extendedprice * l_discount) as revenue
from
    lineitem
where
    l_shipdate >= date '1994-01-01'
    and l_shipdate < date '1994-01-01' + interval '1' year
    and l_discount between .06 - 0.01 and .06 + 0.01
    and l_quantity < 24;

--Q7
select
    supp_nation,
    cust_nation,
    l_year,
    sum(volume) as revenue
from
    (
        select
            n1.n_name as supp_nation,
            n2.n_name as cust_nation,
            extract(year from l_shipdate) as l_year,
            l_extendedprice * (1 - l_discount) as volume
        from
            supplier,
            lineitem,
            orders,
            customer,
            nation n1,
            nation n2
        where
            s_suppkey = l_suppkey

```

```

        and o_orderkey = l_orderkey
        and c_custkey = o_custkey
        and s_nationkey = n1.n_nationkey
        and c_nationkey = n2.n_nationkey
        and (
            (n1.n_name = 'FRANCE' and n2.n_name = 'GERMANY')
            or (n1.n_name = 'GERMANY' and n2.n_name = 'FRANCE')
        )
        and l_shipdate between date '1995-01-01' and date '1996-12-31'
    ) as shipping
group by
    supp_nation,
    cust_nation,
    l_year
order by
    supp_nation,
    cust_nation,
    l_year;

```

--Q8

```

select
    o_year,
    sum(case
        when nation = 'BRAZIL' then volume
        else 0
    end) / sum(volume) as mkt_share
from
    (
        select
            extract(year from o_orderdate) as o_year,
            l_extendedprice * (1 - l_discount) as volume,
            n2.n_name as nation
        from
            part,
            supplier,
            lineitem,
            orders,
            customer,
            nation n1,
            nation n2,
            region
        where
            p_partkey = l_partkey
            and s_suppkey = l_suppkey
            and l_orderkey = o_orderkey
            and o_custkey = c_custkey
            and c_nationkey = n1.n_nationkey
            and n1.n_regionkey = r_regionkey
            and r_name = 'AMERICA'
            and s_nationkey = n2.n_nationkey
            and o_orderdate between date '1995-01-01' and date '1996-12-31'
            and p_type = 'ECONOMY ANODIZED STEEL'
    ) as all_nations
group by
    o_year
order by
    o_year;

```

--Q9

```

select
    nation,
    o_year,
    sum(amount) as sum_profit
from

```

```

(
    select
        n_name as nation,
        extract(year from o_orderdate) as o_year,
        l_extendedprice * (1 - l_discount) - ps_supplycost * l_quantity as amount
    from
        part,
        supplier,
        lineitem,
        partsupp,
        orders,
        nation
    where
        s_suppkey = l_suppkey
        and ps_suppkey = l_suppkey
        and ps_partkey = l_partkey
        and p_partkey = l_partkey
        and o_orderkey = l_orderkey
        and s_nationkey = n_nationkey
        and p_name like '%green%'
    ) as profit
group by
    nation,
    o_year
order by
    nation,
    o_year desc;

--Q10
select
    c_custkey,
    c_name,
    sum(l_extendedprice * (1 - l_discount)) as revenue,
    c_acctbal,
    n_name,
    c_address,
    c_phone,
    c_comment
from
    customer,
    orders,
    lineitem,
    nation
where
    c_custkey = o_custkey
    and l_orderkey = o_orderkey
    and o_orderdate >= date '1993-10-01'
    and o_orderdate < date '1993-10-01' + interval '3' month
    and l_returnflag = 'R'
    and c_nationkey = n_nationkey
group by
    c_custkey,
    c_name,
    c_acctbal,
    c_phone,
    n_name,
    c_address,
    c_comment
order by
    revenue desc
limit 20;

--Q11
select

```

```

        ps_partkey,
        sum(ps_supplycost * ps_availqty) as value
from
    partsupp,
    supplier,
    nation
where
    ps_suppkey = s_suppkey
    and s_nationkey = n_nationkey
    and n_name = 'GERMANY'
group by
    ps_partkey having
    sum(ps_supplycost * ps_availqty) > (
        select
            sum(ps_supplycost * ps_availqty) * 0.000002
        from
            partsupp,
            supplier,
            nation
        where
            ps_suppkey = s_suppkey
            and s_nationkey = n_nationkey
            and n_name = 'GERMANY'
    )
order by
    value desc;

--Q12
select
    l_shipmode,
    sum(case
        when o_orderpriority = '1-URGENT'
            or o_orderpriority = '2-HIGH'
        then 1
        else 0
    end) as high_line_count,
    sum(case
        when o_orderpriority <> '1-URGENT'
            and o_orderpriority <> '2-HIGH'
        then 1
        else 0
    end) as low_line_count
from
    orders,
    lineitem
where
    o_orderkey = l_orderkey
    and l_shipmode in ('MAIL', 'SHIP')
    and l_commitdate < l_receiptdate
    and l_shipdate < l_commitdate
    and l_receiptdate >= date '1994-01-01'
    and l_receiptdate < date '1994-01-01' + interval '1' year
group by
    l_shipmode
order by
    l_shipmode;

--Q13
select
    c_count,
    count(*) as custdist
from
    (
        select
            c_custkey,

```

```

        count(o_orderkey) as c_count
    from
        customer left outer join orders on
            c_custkey = o_custkey
            and o_comment not like '%special%requests%'
    group by
        c_custkey
    ) as c_orders
group by
    c_count
order by
    custdist desc,
    c_count desc;

--Q14
select
    100.00 * sum(case
        when p_type like 'PROMO%'
            then l_extendedprice * (1 - l_discount)
        else 0
    end) / sum(l_extendedprice * (1 - l_discount)) as promo_revenue
from
    lineitem,
    part
where
    l_partkey = p_partkey
    and l_shipdate >= date '1995-09-01'
    and l_shipdate < date '1995-09-01' + interval '1' month;

--Q15
select
    s_suppkey,
    s_name,
    s_address,
    s_phone,
    total_revenue
from
    supplier,
    revenue0
where
    s_suppkey = supplier_no
    and total_revenue = (
        select
            max(total_revenue)
        from
            revenue0
    )
order by
    s_suppkey;

--Q16
select
    p_brand,
    p_type,
    p_size,
    count(distinct ps_suppkey) as supplier_cnt
from
    partsupp,
    part
where
    p_partkey = ps_partkey
    and p_brand <> 'Brand#45'
    and p_type not like 'MEDIUM POLISHED%'
    and p_size in (49, 14, 23, 45, 19, 3, 36, 9)
    and ps_suppkey not in (

```

```

        select
            s_suppkey
        from
            supplier
        where
            s_comment like '%Customer%Complaints%'
    )
group by
    p_brand,
    p_type,
    p_size
order by
    supplier_cnt desc,
    p_brand,
    p_type,
    p_size;

```

```

--Q17
select
    sum(l_extendedprice) / 7.0 as avg_yearly
from
    lineitem,
    part
where
    p_partkey = l_partkey
    and p_brand = 'Brand#23'
    and p_container = 'MED BOX'
    and l_quantity < (
        select
            0.2 * avg(l_quantity)
        from
            lineitem
        where
            l_partkey = p_partkey
    );

```

```

--Q18
select
    c_name,
    c_custkey,
    o_orderkey,
    o_orderdate,
    o_totalprice,
    sum(l_quantity)
from
    customer,
    orders,
    lineitem
where
    o_orderkey in (
        select
            l_orderkey
        from
            lineitem
        group by
            l_orderkey having
                sum(l_quantity) > 300
    )
    and c_custkey = o_custkey
    and o_orderkey = l_orderkey
group by
    c_name,
    c_custkey,
    o_orderkey,
    o_orderdate,

```

```

        o_totalprice
order by
        o_totalprice desc,
        o_orderdate
limit 100;

--Q19
select
        sum(l_extendedprice* (1 - l_discount)) as revenue
from
        lineitem,
        part
where
        (
                p_partkey = l_partkey
                and p_brand = 'Brand#12'
                and p_container in ('SM CASE', 'SM BOX', 'SM PACK', 'SM PKG')
                and l_quantity >= 1 and l_quantity <= 1 + 10
                and p_size between 1 and 5
                and l_shipmode in ('AIR', 'AIR REG')
                and l_shipinstruct = 'DELIVER IN PERSON'
        )
        or
        (
                p_partkey = l_partkey
                and p_brand = 'Brand#23'
                and p_container in ('MED BAG', 'MED BOX', 'MED PKG', 'MED PACK')
                and l_quantity >= 10 and l_quantity <= 10 + 10
                and p_size between 1 and 10
                and l_shipmode in ('AIR', 'AIR REG')
                and l_shipinstruct = 'DELIVER IN PERSON'
        )
        or
        (
                p_partkey = l_partkey
                and p_brand = 'Brand#34'
                and p_container in ('LG CASE', 'LG BOX', 'LG PACK', 'LG PKG')
                and l_quantity >= 20 and l_quantity <= 20 + 10
                and p_size between 1 and 15
                and l_shipmode in ('AIR', 'AIR REG')
                and l_shipinstruct = 'DELIVER IN PERSON'
        );

--Q20
select
        s_name,
        s_address
from
        supplier,
        nation
where
        s_suppkey in (
                select
                        ps_suppkey
                from
                        partsupp
                where
                        ps_partkey in (
                                select
                                        p_partkey
                                from
                                        part
                                where
                                        p_name like 'forest%'

```



```

        )
        and ps_availqty > (
            select
                0.5 * sum(l_quantity)
            from
                lineitem
            where
                l_partkey = ps_partkey
                and l_suppkey = ps_suppkey
                and l_shipdate >= date '1994-01-01'
                and l_shipdate < date '1994-01-01' + interval '1' year
        )
    )
    and s_nationkey = n_nationkey
    and n_name = 'CANADA'
order by
    s_name;

--Q21
select
    s_name,
    count(*) as numwait
from
    supplier,
    lineitem l1,
    orders,
    nation
where
    s_suppkey = l1.l_suppkey
    and o_orderkey = l1.l_orderkey
    and o_orderstatus = 'F'
    and l1.l_receiptdate > l1.l_commitdate
    and exists (
        select
            *
        from
            lineitem l2
        where
            l2.l_orderkey = l1.l_orderkey
            and l2.l_suppkey <> l1.l_suppkey
    )
    and not exists (
        select
            *
        from
            lineitem l3
        where
            l3.l_orderkey = l1.l_orderkey
            and l3.l_suppkey <> l1.l_suppkey
            and l3.l_receiptdate > l3.l_commitdate
    )
    and s_nationkey = n_nationkey
    and n_name = 'SAUDI ARABIA'
group by
    s_name
order by
    numwait desc,
    s_name
limit 100;

--Q22
select
    cntrycode,
    count(*) as numcust,
    sum(c_acctbal) as totacctbal

```

```

from
(
    select
        substring(c_phone, 1, 2) as centrycode,
        c_acctbal
    from
        customer
    where
        substring(c_phone, 1, 2) in
        ('13', '31', '23', '29', '30', '18', '17')
        and c_acctbal > (
            select
                avg(c_acctbal)
            from
                customer
            where
                c_acctbal > 0.00
                and substring(c_phone, 1, 2) in
                ('13', '31', '23', '29', '30', '18', '17')
        )
        and not exists (
            select
                *
            from
                orders
            where
                o_custkey = c_custkey
        )
    ) as custsale
group by
    centrycode
order by
    centrycode;

```

TPC-DS Benchmark


TPC-DS Benchmark

TPC-DS（Transaction Processing Performance Council Decision Support Benchmark）是一个以决策支持为重点的基准测试，旨在评估数据仓库和分析系统的性能。它是由 TPC（Transaction Processing Performance Council）组织开发的，用于比较不同系统在处理复杂查询和大规模数据分析方面的能力。

TPC-DS 的设计目标是模拟现实世界中的复杂决策支持工作负载。它通过一系列复杂的查询和数据操作来测试系统的性能，包括联接、聚合、排序、过滤、子查询等。这些查询模式涵盖了从简单到复杂的各种场景，如报表生成、数据挖掘、OLAP（联机分析处理）等。

本文档主要介绍 Doris 在 TPC-DS 1000G 测试集上的性能表现。

在 TPC-DS 标准测试数据集上的 99 个查询上，我们基于 Apache Doris 2.1.7-rc03 和 Apache Doris 2.0.15.1 版本进行了对比测试。



TPCDS_1000G

1. 硬件环境

硬件	配置说明
机器数量	4 台阿里云主机（1 个 FE，3 个 BE）
CPU	Intel Xeon (Ice Lake) Platinum 8369B 32核
内存	128G
磁盘	阿里云 ESSD (PL0)

2. 软件环境

- Doris 部署 3BE 1FE
- 内核版本：Linux version 5.15.0-101-generic
- 操作系统版本：Ubuntu 20.04 LTS (Focal Fossa)
- Doris 软件版本：Apache Doris 2.1.7-rc03、Apache Doris 2.0.15.1
- JDK：openjdk version “1.8.0_352-352”

3. 测试数据量

整个测试模拟生成 TPC-DS 1000G 的数据分别导入到 Apache Doris 2.1.7-rc03 和 Apache Doris 2.0.15.1 版本进行测试，下面是表的相关说明及数据量。

TPC-DS 表名	行数
customer_demographics	1,920,800
reason	65
warehouse	20
date_dim	73,049
catalog_sales	1,439,980,416
call_center	42
inventory	783,000,000
catalog_returns	143,996,756
household_demographics	7,200
customer_address	6,000,000
income_band	20
catalog_page	30,000
item	300,000
web_returns	71,997,522
web_site	54
promotion	1,500
web_sales	720,000,376
store	1,002
web_page	3,000
time_dim	86,400
store_returns	287,999,764
store_sales	2,879,987,999
ship_mode	20
customer	12,000,000

4. 测试 SQL

TPC-DS 99 个测试查询语句：[TPC-DS-Query-SQL](#)

5. 测试结果

这里我们使用 Apache Doris 2.1.7-rc03 和 Apache Doris 2.0.15.1 版本进行对比测试，测试结果如下：(由于缺少最新的内存优化，Apache Doris 2.0.15.1 q78 q79无法执行，在计算总和时被删除)

Query	Apache Doris 2.1.7-rc03 (ms)	Apache Doris 2.0.15.1-rc01 (ms)
query01	630	890

Query	Apache Doris 2.1.7-rc03 (ms)	Apache Doris 2.0.15.1-rc01 (ms)
query02	4930	6930
query03	360	460
query04	11070	42320
query05	620	15360
query06	220	1020
query07	550	750
query08	330	670
query09	6830	7550
query10	370	2900
query11	6960	27380
query12	100	80
query13	790	2860
query14	13470	42340
query15	510	940
query16	520	550
query17	1310	2650
query18	560	820
query19	200	400
query20	100	190
query21	80	80
query22	2300	3070
query23	38240	75260
query24	8340	26580
query25	780	1190
query26	200	220
query27	530	750
query28	5940	7400
query29	940	1250
query30	270	490
query31	1890	2530
query32	60	70
query33	350	450
query34	750	1380

Query	Apache Doris 2.1.7-rc03 (ms)	Apache Doris 2.0.15.1-rc01 (ms)
query35	1370	8970
query36	530	570
query37	60	60
query38	7520	8710
query39	560	1010
query40	150	180
query41	50	40
query42	100	140
query43	1150	1960
query44	2020	3220
query45	430	960
query46	1250	2760
query47	2660	5790
query48	630	2570
query49	730	800
query50	1640	2200
query51	6430	6270
query52	110	160
query53	250	490
query54	1280	7790
query55	110	160
query56	290	410
query57	1480	3510
query58	240	550
query59	7760	11870
query60	380	490
query61	540	670
query62	740	1560
query63	210	460
query64	5790	6840
query65	4900	7960
query66	480	810
query67	27320	46110

Query	Apache Doris 2.1.7-rc03 (ms)	Apache Doris 2.0.15.1-rc01 (ms)
query68	1600	2380
query69	380	800
query70	3480	5330
query71	460	790
query72	3160	5390
query73	660	1250
query74	5990	16450
query75	4610	8410
query76	1590	2950
query77	300	480
query78	17970	x
query79	3040	x
query80	570	910
query81	460	760
query82	270	330
query83	220	290
query84	130	110
query85	520	470
query86	760	1220
query87	800	8760
query88	5560	9690
query89	430	750
query90	150	400
query91	150	120
query92	40	40
query93	2440	2670
query94	340	310
query95	350	1810
query96	660	1680
query97	5020	14990
query98	190	330
query99	1560	3230
Total	261320	507380

6. 环境准备

请先参照 [官方文档](#) 进行 Doris 的安装部署，以获得一个正常运行中的 Doris 集群（至少包含 1 FE 1 BE，推荐 1 FE 3 BE）。

7. 数据准备

7.1 下载安装 TPC-DS 数据生成工具

执行以下脚本下载并编译 [tpcds-tools](#) 工具。

```
sh bin/build-tpcds-tools.sh
```

7.2 生成 TPC-DS 测试集

执行以下脚本生成 TPC-DS 数据集：

```
sh bin/gen-tpcds-data.sh -s 1000
```

注 1：通过 `sh gen-tpcds-data.sh -h` 查看脚本帮助。

注 2：数据会以 `.dat` 为后缀生成在 `tpcds-data/` 目录下。文件总大小约 1000GB。生成时间可能在数分钟到 1 小时不等。

注 3：默认生成 100G 的标准测试数据集

7.3 建表

7.3.1 准备 `doris-cluster.conf` 文件

在调用导入脚本前，需要将 FE 的 ip 端口等信息写在 `doris-cluster.conf` 文件中。

文件位置在 `${DORIS_HOME}/tools/tpcds-tools/conf/` 目录下。

文件内容包括 FE 的 ip，HTTP 端口，用户名，密码以及待导入数据的 DB 名称：

```
# Any of FE host
export FE_HOST='127.0.0.1'
# http_port in fe.conf
export FE_HTTP_PORT=8030
# query_port in fe.conf
export FE_QUERY_PORT=9030
# Doris username
export USER='root'
# Doris password
export PASSWORD=''
# The database where TPC-DS tables located
export DB='tpcds'
```


7.3.2 执行以下脚本生成创建 TPC-DS 表

```
sh bin/create-tpcds-tables.sh -s 1000
```

或者复制 [create-tpcds-tables.sql](#) 中的建表语句，在 Doris 中执行。

7.4 导入数据

通过下面的命令执行数据导入：

```
sh bin/load-tpcds-data.sh
```

7.5 查询测试

7.5.1 执行查询脚本

单个 SQL 执行 或者 执行下面的命令

```
sh bin/run-tpcds-queries.sh -s 1000
```

7.5.2 单个 SQL 执行

你也可以从代码库里获取最新的 SQL。最新测试查询语句地址：[TPC-DS 测试查询语句](#)

Spark Doris Connector

Spark Doris Connector

Spark Doris Connector 可以支持通过 Spark 读取 Doris 中存储的数据，也支持通过 Spark 写入数据到 Doris。

代码库地址：<https://github.com/apache/doris-spark-connector>

- 支持从Doris中读取数据
- 支持Spark DataFrame批量/流式 写入Doris
- 可以将Doris表映射为DataFrame或者RDD，推荐使用DataFrame。
- 支持在Doris端完成数据过滤，减少数据传输量。

版本兼容

Connector	Spark	Doris	Java	Scala
1.3.1	3.4 ~ 3.1, 2.4, 2.3	1.0 +	8	2.12, 2.11
1.2.0	3.2, 3.1, 2.3	1.0 +	8	2.12, 2.11
1.1.0	3.2, 3.1, 2.3	1.0 +	8	2.12, 2.11
1.0.1	3.1, 2.3	0.12 - 0.15	8	2.12, 2.11

使用

Maven

```
<dependency>
  <groupId>org.apache.doris</groupId>
  <artifactId>spark-doris-connector-3.4_2.12</artifactId>
  <version>1.3.2</version>
</dependency>
```

备注

1. 请根据不同的 Spark 和 Scala 版本替换相应的 Connector 版本。
2. 也可从[这里](#)下载相关版本 jar 包。

编译

编译时，可直接运行 `sh build.sh`，具体可参考[这里](#)。

编译成功后，会在 `dist` 目录生成目标 jar 包，如：`spark-doris-connector-3.2_2.12-1.2.0-SNAPSHOT.jar`。将此文件复制到 Spark 的 `ClassPath` 中即可使用 Spark-Doris-Connector。例如，Local 模式运行的 Spark，将此文件放入 `jars/` 文件夹下。Yarn 集群模式运行的 Spark，则将此文件放入预部署包中。也可以

2. 在源码目录下执行： `sh build.sh` 根据提示输入你需要的 Scala 与 Spark 版本进行编译。

编译成功后，会在 `dist` 目录生成目标 jar 包，如： `spark-doris-connector-3.2_2.12-1.2.0-SNAPSHOT.jar`。将此文件复制到 Spark 的 ClassPath 中即可使用 Spark-Doris-Connector。

例如，Local 模式运行的 Spark，将此文件放入 `jars/` 文件夹下。Yarn 集群模式运行的 Spark，则将此文件放入预部署包中。

例如将 `spark-doris-connector-3.2_2.12-1.2.0-SNAPSHOT.jar` 上传到 hdfs 并在 `spark.yarn.jars` 参数上添加 hdfs 上的 Jar 包路径

```
1. 上传 `spark-doris-connector-3.2_2.12-1.2.0-SNAPSHOT.jar` 到 hdfs。

hdfs dfs -mkdir /spark-jars/
hdfs dfs -put /your_local_path/spark-doris-connector-3.2_2.12-1.2.0-SNAPSHOT.jar /spark-jars/

2. 在集群中添加 `spark-doris-connector-3.2_2.12-1.2.0-SNAPSHOT.jar` 依赖。
spark.yarn.jars=hdfs:///spark-jars/spark-doris-connector-3.2_2.12-1.2.0-SNAPSHOT.jar
```

使用示例

读取

SQL

```
CREATE
TEMPORARY VIEW spark_doris
USING doris
OPTIONS(
  "table.identifier"="$YOUR_DORIS_DATABASE_NAME.$YOUR_DORIS_TABLE_NAME",
  "fenodes"="$YOUR_DORIS_FE_HOSTNAME:$YOUR_DORIS_FE_RESFUL_PORT",
  "user"="$YOUR_DORIS_USERNAME",
  "password"="$YOUR_DORIS_PASSWORD"
);

SELECT *
FROM spark_doris;
```

DataFrame

```
val dorisSparkDF = spark.read.format("doris")
  .option("doris.table.identifier", "$YOUR_DORIS_DATABASE_NAME.$YOUR_DORIS_TABLE_NAME")
  .option("doris.fenodes", "$YOUR_DORIS_FE_HOSTNAME:$YOUR_DORIS_FE_RESFUL_PORT")
  .option("user", "$YOUR_DORIS_USERNAME")
  .option("password", "$YOUR_DORIS_PASSWORD")
  .load()

dorisSparkDF.show(5)
```

RDD

```
import org.apache.doris.spark._

val dorisSparkRDD = sc.dorisRDD(
  tableIdentifier = Some("$YOUR_DORIS_DATABASE_NAME.$YOUR_DORIS_TABLE_NAME"),
  cfg = Some(Map(
    "doris.fenodes" -> "$YOUR_DORIS_FE_HOSTNAME:$YOUR_DORIS_FE_RESFUL_PORT",
    "doris.request.auth.user" -> "$YOUR_DORIS_USERNAME",
    "doris.request.auth.password" -> "$YOUR_DORIS_PASSWORD"
  ))
)

dorisSparkRDD.collect()
```

pySpark

```
dorisSparkDF = spark.read.format("doris")
  .option("doris.table.identifier", "$YOUR_DORIS_DATABASE_NAME.$YOUR_DORIS_TABLE_NAME")
  .option("doris.fenodes", "$YOUR_DORIS_FE_HOSTNAME:$YOUR_DORIS_FE_RESFUL_PORT")
  .option("user", "$YOUR_DORIS_USERNAME")
  .option("password", "$YOUR_DORIS_PASSWORD")
  .load()
// show 5 lines data
dorisSparkDF.show(5)
```

写入

SQL

```
CREATE
TEMPORARY VIEW spark_doris
USING doris
OPTIONS(
  "table.identifier"="$YOUR_DORIS_DATABASE_NAME.$YOUR_DORIS_TABLE_NAME",
  "fenodes"="$YOUR_DORIS_FE_HOSTNAME:$YOUR_DORIS_FE_RESFUL_PORT",
  "user"="$YOUR_DORIS_USERNAME",
  "password"="$YOUR_DORIS_PASSWORD"
);

INSERT INTO spark_doris
VALUES ("VALUE1", "VALUE2", ...);
# or
INSERT INTO spark_doris
SELECT *
FROM YOUR_TABLE
# or
INSERT OVERWRITE
SELECT *
FROM YOUR_TABLE
```

DataFrame(batch/stream)

```
// batch sink
val mockDataDF = List(
  (3, "440403001005", "21.cn"),
  (1, "4404030013005", "22.cn"),
  (33, null, "23.cn")
).toDF("id", "mi_code", "mi_name")
mockDataDF.show(5)

mockDataDF.write.format("doris")
  .option("doris.table.identifier", "$YOUR_DORIS_DATABASE_NAME.$YOUR_DORIS_TABLE_NAME")
  .option("doris.fenodes", "$YOUR_DORIS_FE_HOSTNAME:$YOUR_DORIS_FE_RESFUL_PORT")
  .option("user", "$YOUR_DORIS_USERNAME")
  .option("password", "$YOUR_DORIS_PASSWORD")
  //其它选项
  //指定你要写入的字段
  .option("doris.write.fields", "$YOUR_FIELDS_TO_WRITE")
  // 支持设置 Overwrite 模式来覆盖数据
  // .option("save_mode", SaveMode.Overwrite)
  .save()

// stream sink(StructuredStreaming)

// 结果 DataFrame 和 doris 表相同的结构化数据，配置方式和批量模式一致。
val sourceDf = spark.readStream
  .format("your_own_stream_source")
  .load()

val resultDf = sourceDf.<transformations>

resultDf.writeStream
  .format("doris")
  .option("checkpointLocation", "$YOUR_CHECKPOINT_LOCATION")
  .option("doris.table.identifier", "$YOUR_DORIS_DATABASE_NAME.$YOUR_DORIS_TABLE_NAME")
  .option("doris.fenodes", "$YOUR_DORIS_FE_HOSTNAME:$YOUR_DORIS_FE_RESFUL_PORT")
  .option("user", "$YOUR_DORIS_USERNAME")
  .option("password", "$YOUR_DORIS_PASSWORD")
  .start()
  .awaitTermination()

// 结果 DataFrame 中存在某一列的数据可以直接写入的，比如符合导入规范的 Kafka 消息中的 value 值

val kafkaSource = spark.readStream
  .format("kafka")
  .option("kafka.bootstrap.servers", "$YOUR_KAFKA_SERVERS")
  .option("startingOffsets", "latest")
  .option("subscribe", "$YOUR_KAFKA_TOPICS")
  .load()
kafkaSource.selectExpr("CAST(value as STRING)")
  .writeStream
  .format("doris")
  .option("checkpointLocation", "$YOUR_CHECKPOINT_LOCATION")
  .option("doris.table.identifier", "$YOUR_DORIS_DATABASE_NAME.$YOUR_DORIS_TABLE_NAME")
  .option("doris.fenodes", "$YOUR_DORIS_FE_HOSTNAME:$YOUR_DORIS_FE_RESFUL_PORT")
  .option("user", "$YOUR_DORIS_USERNAME")
  .option("password", "$YOUR_DORIS_PASSWORD")
  // 设置该选项可以将 Kafka 消息中的 value 列不经过处理直接写入
  .option("doris.sink.streaming.passthrough", "true")
  .option("doris.sink.properties.format", "json")
  // 其他选项
  .start()
  .awaitTermination()
```

Java 示例

`samples/doris-demo/spark-demo/` 下提供了 Java 版本的示例，可供参考，[这里](#)

配置

通用配置项

Key	Default Value	Comment
<code>doris.fenodes</code>	–	Doris FE http 地址，支持多个地址，使用逗号分隔
<code>doris.table.identifier</code>	–	Doris 表名，如：db1.tbl1
<code>doris.request.retries</code>	3	向 Doris 发送请求的重试次数
<code>doris.request.connect.timeout.ms</code>	30000	向 Doris 发送请求的连接超时时间
<code>doris.request.read.timeout.ms</code>	30000	向 Doris 发送请求的读取超时时间
<code>doris.request.query.timeout.s</code>	3600	查询 doris 的超时时间，默认值为 1 小时，-1 表示无超时限制
<code>doris.request.tablet.size</code>	Integer.MAX_VALUE	一个 RDD Partition 对应的 Doris Tablet 个数。 此数值设置越小，则会生成越多的 Partition。从而提升 Spark 侧的并行度，但同时会对 Doris 造成更大的压力。
<code>doris.read.field</code>	–	读取 Doris 表的列名列表，多列之间使用逗号分隔
<code>doris.batch.size</code>	4064	一次从 BE 读取数据的最大行数。增大此数值可减少 Spark 与 Doris 之间建立连接的次数。从而减轻网络延迟所带来的额外时间开销。
<code>doris.exec.mem.limit</code>	2147483648	单个查询的内存限制。默认为 2GB，单位为字节
<code>doris.deserialize.arrow.async</code>	false	是否支持异步转换 Arrow 格式到 spark-doris-connector 迭代所需的 RowBatch
<code>doris.deserialize.queue.size</code>	64	异步转换 Arrow 格式的内部处理队列，当 <code>doris.deserialize.arrow.async</code> 为 true 时生效

Key	Default Value	Comment
doris.write.fields	—	指定写入 Doris 表的字段或者字段顺序，多列之间使用逗号分隔。 默认写入时要按照 Doris 表字段顺序写入全部字段。
doris.sink.batch.size	100000	单次写 BE 的最大行数
doris.sink.max-retries	0	写 BE 失败之后的重试次数，从 1.3.0 版本开始，默认值为 0，即默认不进行重试。当设置该参数大于 0 时，会进行批次级别的失败重试，会在 Spark Executor 内存中缓存 doris.sink.batch.size 所配置大小的数据，可能需要适当增大内存分配。
doris.sink.properties.format	csv	Stream Load 的数据格式。 共支持 3 种格式：csv, json, arrow 更多参数详情
doris.sink.properties.*	—	Stream Load 的导入参数。 例如： 指定列分隔符：'doris.sink.properties.column_separator' = ',' 等 更多参数详情
doris.sink.task.partition.size	—	Doris 写入任务对应的 Partition 个数。Spark RDD 经过过滤等操作，最后写入的 Partition 数可能会比较大，但每个 Partition 对应的记录数比较少，导致写入频率增加和计算资源浪费。 此数值设置越小，可以降低 Doris 写入频率，减少 Doris 合并压力。该参数配合 doris.sink.task.use.repartition 使用。
doris.sink.task.use.repartition	false	是否采用 repartition 方式控制 Doris 写入 Partition 数。默认值为 false，采用 coalesce 方式控制（注意：如果在写入之前没有 Spark action 算子，可能会导致整个计算并行度降低）。 如果设置为 true，则采用 repartition 方式（注意：可设置最后 Partition 数，但会额外增加 shuffle 开销）。
doris.sink.batch.interval.ms	50	每个批次 sink 的间隔时间，单位 ms。
doris.sink.enable-2pc	false	是否开启两阶段提交。开启后将会在作业结束时提交事务，而部分任务失败时会将所有预提交状态的事务会滚。
doris.sink.auto-redirect	true	是否重定向 StreamLoad 请求。开启后 StreamLoad 将通过 FE 写入，不再显式获取 BE 信息。

SQL 和 Dataframe 专有配置

Key	Default Value	Comment
user	—	访问 Doris 的用户名
password	—	访问 Doris 的密码
doris.filter.query.in.max.count	100	谓词下推中，in 表达式 value 列表元素最大数量。超过此数量，则 in 表达式条件过滤在 Spark 侧处理。
doris.ignore-type	—	指在临时视图中，读取 schema 时要忽略的字段类型。 例如，'doris.ignore-type'='bitmap,hll'

Structured Streaming 专有配置

Key	Default Value	Comment
doris.sink.streaming.passthrough	false	将第一列的值不经过处理直接写入。

RDD 专有配置

Key	Default Value	Comment
doris.request.auth.user	–	访问 Doris 的用户名
doris.request.auth.password	–	访问 Doris 的密码
doris.filter.query	–	过滤读取数据的表达式，此表达式透传给 Doris。Doris 使用此表达式完成源端数据过滤。

Doris 和 Spark 列类型映射关系

Doris Type	Spark Type
NULL_TYPE	DataTypes.NullType
BOOLEAN	DataTypes.BooleanType
TINYINT	DataTypes.ByteType
SMALLINT	DataTypes.ShortType
INT	DataTypes.IntegerType
BIGINT	DataTypes.LongType
FLOAT	DataTypes.FloatType
DOUBLE	DataTypes.DoubleType
DATE	DataTypes.DateType
DATETIME	DataTypes.StringType ¹
DECIMAL	DecimalType
CHAR	DataTypes.StringType
LARGEINT	DecimalType
VARCHAR	DataTypes.StringType
TIME	DataTypes.DoubleType
HLL	Unsupported datatype
Bitmap	Unsupported datatype

- 注：Connector 中，将DATETIME映射为String。由于Doris底层存储引擎处理逻辑，直接使用时间类型时，覆盖的时间范围无法满足需求。所以使用 String 类型直接返回对应的时间可读文本。

常见问题

1. 如何写入 Bitmap 类型?

在 Spark SQL 中, 通过 insert into 方式写入数据时, 如果 doris 的目标表中包含 BITMAP 或 HLL 类型的数据时, 需要设置参数 doris.ignore-type 为对应类型, 并通过 doris.write.fields 对列进行映射转换, 使用方式如下:

```
> BITMAP > sql > CREATE TEMPORARY VIEW spark_doris > USING doris > OPTIONS( >
"table.identifier"="$YOUR_DORIS_DATABASE_NAME.$YOUR_DORIS_TABLE_NAME", >
"fenodes"="$YOUR_DORIS_FE_HOSTNAME:$YOUR_DORIS_FE_RESFUL_PORT", >
"user"="$YOUR_DORIS_USERNAME", > "password"="$YOUR_DORIS_PASSWORD" > "doris.ignore-
type"="bitmap", >
"doris.write.fields"="col1,col2,col3,bitmap_col2=to_bitmap(col2),bitmap_col3=bitmap_hash(c
ol3)" > ); >> HLL > sql > CREATE TEMPORARY VIEW spark_doris > USING doris > OPTIONS( >
"table.identifier"="$YOUR_DORIS_DATABASE_NAME.$YOUR_DORIS_TABLE_NAME", >
"fenodes"="$YOUR_DORIS_FE_HOSTNAME:$YOUR_DORIS_FE_RESFUL_PORT", >
"user"="$YOUR_DORIS_USERNAME", > "password"="$YOUR_DORIS_PASSWORD" > "doris.ignore-
type"="hll", > "doris.write.fields"="col1,hll_col1=hll_hash(col1)" > ); >
```

2. 如何使用overwrite写入?

从 1.3.0 版本开始, 支持 overwrite 模式写入 (只支持全表级别的数据覆盖), 具体使用方式如下 > DataFrame > java > resultDf.format("doris") >

```
.option("doris.fenodes","$YOUR_DORIS_FE_HOSTNAME:$YOUR_DORIS_FE_RESFUL_PORT") > // your
own options > .option("save_mode", SaveMode.Overwrite) > .save() >>> SQL > sql > INSERT
OVERWRITE your_target_table > SELECT * FROM your_source_table >
```

Flink Doris Connector

Flink Doris Connector

[Flink Doris Connector](#) 可以支持通过 Flink 操作（读取、插入、修改、删除）Doris 中存储的数据。本文档介绍 Flink 如何通过 Datastream 和 SQL 操作 Doris。

注意：

- 1. 修改和删除只支持在 Unique Key 模型上
- 2. 目前的删除是支持 Flink CDC 的方式接入数据实现自动删除，如果是其他数据接入的方式删除需要自己实现。Flink CDC 的数据删除使用方式参照本文档最后一节

版本兼容

Connector Version	Flink Version	Doris Version	Java Version	Scala Version
1.0.3	1.11,1.12,1.13,1.14	0.15+	8	2.11,2.12
1.1.1	1.14	1.0+	8	2.11,2.12
1.2.1	1.15	1.0+	8	-
1.3.0	1.16	1.0+	8	-
1.4.0	1.15,1.16,1.17	1.0+	8	-
1.5.2	1.15,1.16,1.17,1.18	1.0+	8	-
1.6.2	1.15,1.16,1.17,1.18,1.19	1.0+	8	-
24.0.1	1.15,1.16,1.17,1.18,1.19,1.20	1.0+	8	-

使用

Maven

添加 flink-doris-connector

```
<!-- flink-doris-connector -->
<dependency>
  <groupId>org.apache.doris</groupId>
  <artifactId>flink-doris-connector-1.16</artifactId>
  <version>24.0.1</version>
</dependency>
```

备注

1.请根据不同的 Flink 版本替换对应的 Connector 和 Flink 依赖版本。

2.也可从[这里](#)下载相关版本 jar 包。

编译

编译时，可直接运行`sh build.sh`，具体可参考[这里](#)。

编译成功后，会在 `dist` 目录生成目标 jar 包，如：`flink-doris-connector-24.0.0-SNAPSHOT.jar`。将此文件复制到 Flink 的 `classpath` 中即可使用 Flink-Doris-Connector。例如，Local 模式运行的 Flink，将此文件放入 `lib/` 文件夹下。Yarn 集群模式运行的 Flink，则将此文件放入预部署包中。

使用方法

读取

SQL

```
-- doris source
CREATE TABLE flink_doris_source (
  name STRING,
  age INT,
  price DECIMAL(5,2),
  sale DOUBLE
)
WITH (
  'connector' = 'doris',
  'fenodes' = 'FE_IP:HTTP_PORT',
  'table.identifier' = 'database.table',
  'username' = 'root',
  'password' = 'password'
);
```

备注

Flink Connector 24.0.0 版本之后支持使用[Arrow Flight SQL](#) 读取数据

```
CREATE TABLE doris_source (
  name STRING,
  age int
)
WITH (
  'connector' = 'doris',
  'fenodes' = 'FE_IP:HTTP_PORT',
  'table.identifier' = 'database.table',
  'source.use-flight-sql' = 'true',
  'source.flight-sql-port' = '{fe.conf:arrow_flight_sql_port}',
  'username' = 'root',
  'password' = ''
)
```

DataStream

```
DorisOptions.Builder builder = DorisOptions.builder()
    .setFenodes("FE_IP:HTTP_PORT")
    .setTableIdentifier("db.table")
    .setUsername("root")
    .setPassword("password");

DorisSource<List<?>> dorisSource = DorisSource.<List<?>>builder()
    .setDorisOptions(builder.build())
    .setDorisReadOptions(DorisReadOptions.builder().build())
    .setDeserializer(new SimpleListDeserializationSchema())
    .build();

env.fromSource(dorisSource, WatermarkStrategy.noWatermarks(), "doris source").print();
```

写入

SQL

```
-- enable checkpoint
SET 'execution.checkpointing.interval' = '10s';

-- doris sink
CREATE TABLE flink_doris_sink (
    name STRING,
    age INT,
    price DECIMAL(5,2),
    sale DOUBLE
)
WITH (
    'connector' = 'doris',
    'fenodes' = 'FE_IP:HTTP_PORT',
    'table.identifier' = 'db.table',
    'username' = 'root',
    'password' = 'password',
    'sink.label-prefix' = 'doris_label'
);

-- submit insert job
INSERT INTO flink_doris_sink select name,age,price,sale from flink_doris_source
```

DataStream

DorisSink 是通过 StreamLoad 向 Doris 写入数据，DataStream 写入时，支持不同的序列化方法

String 数据流 (SimpleStringSerializer)

```
// enable checkpoint
env.enableCheckpointing(10000);
// using batch mode for bounded data
env.setRuntimeMode(RuntimeExecutionMode.BATCH);

DorisSink.Builder<String> builder = DorisSink.builder();
DorisOptions.Builder dorisBuilder = DorisOptions.builder();
dorisBuilder.setFenodes("FE_IP:HTTP_PORT")
```

```

        .setTableIdentifier("db.table")
        .setUsername("root")
        .setPassword("password");

Properties properties = new Properties();
// 上游是 json 写入时, 需要开启配置
//properties.setProperty("format", "json");
//properties.setProperty("read_json_by_line", "true");
DorisExecutionOptions.Builder executionBuilder = DorisExecutionOptions.builder();
executionBuilder.setLabelPrefix("label-doris") //streamload label prefix
                .setDeletable(false)
                .setStreamLoadProp(properties);

builder.setDorisReadOptions(DorisReadOptions.builder().build())
        .setDorisExecutionOptions(executionBuilder.build())
        .setSerializer(new SimpleStringSerializer()) //serialize according to string
        .setDorisOptions(dorisBuilder.build());

//mock csv string source
List<Tuple2<String, Integer>> data = new ArrayList<>();
data.add(new Tuple2<>("doris",1));
DataStreamSource<Tuple2<String, Integer>> source = env.fromCollection(data);
source.map((MapFunction<Tuple2<String, Integer>, String>) t -> t.f0 + "\t" + t.f1)
        .sinkTo(builder.build());

//mock json string source
//env.fromElements("{\"name\":\"zhangsan\",\"age\":1}").sinkTo(builder.build());

```

RowData 数据流 (RowDataSerializer)

```

// enable checkpoint
env.enableCheckpointing(10000);
// using batch mode for bounded data
env.setRuntimeMode(RuntimeExecutionMode.BATCH);

//doris sink option
DorisSink.Builder<RowData> builder = DorisSink.builder();
DorisOptions.Builder dorisBuilder = DorisOptions.builder();
dorisBuilder.setFenodes("FE_IP:HTTP_PORT")
        .setTableIdentifier("db.table")
        .setUsername("root")
        .setPassword("password");

// json format to streamload
Properties properties = new Properties();
properties.setProperty("format", "json");
properties.setProperty("read_json_by_line", "true");
DorisExecutionOptions.Builder executionBuilder = DorisExecutionOptions.builder();
executionBuilder.setLabelPrefix("label-doris") //streamload label prefix
                .setDeletable(false)
                .setStreamLoadProp(properties); //streamload params

//flink rowdata's schema
String[] fields = {"city", "longitude", "latitude", "destroy_date"};
DataType[] types = {DataTypes.VARCHAR(256), DataTypes.DOUBLE(), DataTypes.DOUBLE(), DataTypes.DATE()};

builder.setDorisReadOptions(DorisReadOptions.builder().build())
        .setDorisExecutionOptions(executionBuilder.build())
        .setSerializer(RowDataSerializer.builder() //serialize according to rowdata
                .setFieldNames(fields)
                .setType("json") //json format
                .setFieldType(types).build())

```

```

        .setDorisOptions(dorisBuilder.build());

//mock rowdata source
DataStream<RowData> source = env.fromElements("")
    .map(new MapFunction<String, RowData>() {
        @Override
        public RowData map(String value) throws Exception {
            GenericRowData genericRowData = new GenericRowData(4);
            genericRowData.setField(0, StringData.fromString("beijing"));
            genericRowData.setField(1, 116.405419);
            genericRowData.setField(2, 39.916927);
            genericRowData.setField(3, LocalDate.now().toEpochDay());
            return genericRowData;
        }
    });

source.sinkTo(builder.build());

```

CDC 数据流 (JsonDebeziumSchemaSerializer)

备注

上游数据必须符合 Debezium 数据格式。

```

// enable checkpoint
env.enableCheckpointing(10000);

Properties props = new Properties();
props.setProperty("format", "json");
props.setProperty("read_json_by_line", "true");
DorisOptions dorisOptions = DorisOptions.builder()
    .setFenodes("127.0.0.1:8030")
    .setTableIdentifier("test.t1")
    .setUsername("root")
    .setPassword(" ").build();

DorisExecutionOptions.Builder executionBuilder = DorisExecutionOptions.builder();
executionBuilder.setLabelPrefix("label-prefix")
    .setStreamLoadProp(props).setDeletable(true);

DorisSink.Builder<String> builder = DorisSink.builder();
builder.setDorisReadOptions(DorisReadOptions.builder().build())
    .setDorisExecutionOptions(executionBuilder.build())
    .setDorisOptions(dorisOptions)
    .setSerializer(JsonDebeziumSchemaSerializer.builder().setDorisOptions(dorisOptions).build());

env.fromSource(mysqlSource, WatermarkStrategy.noWatermarks(), "MySQL Source")
    .sinkTo(builder.build());

```

完整代码参考：[CDCSchemaChangeExample](#)

Lookup Join

```

CREATE TABLE fact_table (
  `id` BIGINT,
  `name` STRING,
  `city` STRING,

```

```

`process_time` as proctime()
) WITH (
  'connector' = 'kafka',
  ...
);

create table dim_city(
  `city` STRING,
  `level` INT ,
  `province` STRING,
  `country` STRING
) WITH (
  'connector' = 'doris',
  'fenodes' = '127.0.0.1:8030',
  'jdbc-url' = 'jdbc:mysql://127.0.0.1:9030',
  'table.identifier' = 'dim.dim_city',
  'username' = 'root',
  'password' = ''
);

SELECT a.id, a.name, a.city, c.province, c.country,c.level
FROM fact_table a
LEFT JOIN dim_city FOR SYSTEM_TIME AS OF a.process_time AS c
ON a.city = c.city

```

配置

通用配置项

Key	Default Value	Required	Comment
fenodes	—	Y	Doris FE http 地址，支持多个地址，使用逗号分隔
benodes	—	N	Doris BE http 地址，支持多个地址，使用逗号分隔，参考 #187
jdbc-url	—	N	jdbc 连接信息，如：jdbc:mysql://127.0.0.1:9030
table.identifier	—	Y	Doris 表名，如：db.tbl
username	—	Y	访问 Doris 的用户名
password	—	Y	访问 Doris 的密码
auto-redirect	true	N	是否重定向 StreamLoad 请求。开启后 StreamLoad 将通过 FE 写入，不再显示获取 BE 信息
doris.request.retries	3	N	向 Doris 发送请求的重试次数
doris.request.connect.timeout	30s	N	向 Doris 发送请求的连接超时时间
doris.request.read.timeout	30s	N	向 Doris 发送请求的读取超时时间

Source 配置项

Key	Default Value	Required	Comment
doris.request.query.timeout	21600s	N	查询 Doris 的超时时间，默认值为 6 小时

Key	Default Value	Required	Comment
doris.request.tablet.size	1	N	一个 Partition 对应的 Doris Tablet 个数。此数值设置越小，则会生成越多的 Partition。从而提升 Flink 侧的并行度，但同时会对 Doris 造成更大的压力。
doris.batch.size	1024	N	一次从 BE 读取数据的最大行数。增大此数值可减少 Flink 与 Doris 之间建立连接的次数。从而减轻网络延迟所带来的额外时间开销。
doris.exec.mem.limit	8192mb	N	单个查询的内存限制。默认为 8GB，单位为字节
doris.deserialize.arrow.async	FALSE	N	是否支持异步转换 Arrow 格式到 flink-doris-connector 迭代所需的 RowBatch
doris.deserialize.queue.size	64	N	异步转换 Arrow 格式的内部处理队列，当 doris.deserialize.arrow.async 为 true 时生效
source.use-flight-sql	FALSE	N	是否使用 Arrow Flight SQL 读取
source.flight-sql-port	-	N	使用 Arrow Flight SQL 读取时，FE 的 arrow_flight_sql_port

DataStream 专有配置项

Key	Default Value	Required	Comment
doris.read.field	—	N	读取 Doris 表的列名列表，多列之间使用逗号分隔
doris.filter.query	—	N	过滤读取数据的表达式，此表达式透传给 Doris。Doris 使用此表达式完成源端数据过滤。比如 age=18。

Sink 配置项

Key	Default Value	Required	Comment
sink.label-prefix	—	Y	Stream load 导入使用的 label 前缀。2pc 场景下要求全局唯一，用来保证 Flink 的 EOS 语义。

Key	D e f a u l t V a l u e	R e q u i r e d	Comment
sink.properties.*	–	N	<p>Stream Load 的导入参数。</p> <p>例如：'sink.properties.column_separator' = ',' 定义列分隔符，'sink.properties.escape_delimiters' = 'true' 特殊字符作为分隔符，\x01会被转换为二进制的 0x01。</p> <p>JSON 格式导入 'sink.properties.format' = 'json' 'sink.properties.read_json_by_line' = 'true' 详细参数参考这里。</p> <p>Group Commit 模式 例如：'sink.properties.group_commit' = 'sync_mode' 设置 group commit 为同步模式。flink connector 从 1.6.2 开始支持导入配置 group commit，详细使用和限制参考 group_commit 。</p>
sink.enable-delete	T R U E	N	是否启用删除。此选项需要 Doris 表开启批量删除功能 (Doris0.15+ 版本默认开启)，只支持 Unique 模型。
sink.enable-2pc	T R U E	N	是否开启两阶段提交 (2pc)，默认为 true，保证 Exactly-Once 语义。关于两阶段提交可参考 这里 。
sink.buffer-size	1 M B	N	写数据缓存 buffer 大小，单位字节。不建议修改，默认配置即可
sink.buffer-count	3	N	写数据缓存 buffer 个数。不建议修改，默认配置即可
sink.max-retries	3	N	Commit 失败后的最大重试次数，默认 3 次
sink.use-cache	f a l s e	N	异常时，是否使用内存缓存进行恢复，开启后缓存中会保留 Checkpoint 期间的数据
sink.enable.batch-mode	f a l s e	N	<p>是否使用攒批模式写入 Doris，开启后写入时机不依赖 Checkpoint，通过 sink.buffer-flush.max-rows/sink.buffer-flush.max-bytes/sink.buffer-flush.interval 参数来控制写入时机。</p> <p>同时开启后将不保证 Exactly-once 语义，可借助 Uniq 模型做到幂等</p>
sink.flush.queue-size	2	N	攒批模式下，缓存的队列大小。

Key	Default Value	Required	Comment
sink.buffer-flush.max-rows	50000	N	攒批模式下，单个批次最多写入的数据行数。
sink.buffer-flush.max-bytes	10MB	N	攒批模式下，单个批次最多写入的字节数。
sink.buffer-flush.interval	10s	N	攒批模式下，异步刷新缓存的间隔
sink.ignore.update-before	true	N	是否忽略 update-before 事件，默认忽略。

Lookup Join 配置项

Key	Default Value	Required	Comment
lookup.cache.max-rows	-1	N	lookup 缓存的最大行数，默认值 -1，不开启缓存
lookup.cache.ttl	10s	N	lookup 缓存的最大时间，默认 10s
lookup.max-retries	1	N	lookup 查询失败后的重试次数
lookup.jdbc.async	false	N	是否开启异步的 lookup，默认 false
lookup.jdbc.read.batch.size	128	N	异步 lookup 下，每次查询的最大批次大小
lookup.jdbc.read.batch.queue-size	256	N	异步 lookup 时，中间缓冲队列的大小
lookup.jdbc.read.thread-size	3	N	每个 task 中 lookup 的 jdbc 线程数

Doris 和 Flink 列类型映射关系

Doris Type	Flink Type
NULL_TYPE	NULL

Doris Type	Flink Type
BOOLEAN	BOOLEAN
TINYINT	TINYINT
SMALLINT	SMALLINT
INT	INT
BIGINT	BIGINT
FLOAT	FLOAT
DOUBLE	DOUBLE
DATE	DATE
DATETIME	TIMESTAMP
DECIMAL	DECIMAL
CHAR	STRING
LARGEINT	STRING
VARCHAR	STRING
STRING	STRING
DECIMALV2	DECIMAL
ARRAY	ARRAY
MAP	MAP
JSON	STRING
VARIANT	STRING
IPV4	STRING
IPV6	STRING

自 connector-1.6.1 开始支持读取 Variant,IPV6,IPV4 三种数据类型，其中读取 IPV6，Variant 需 Doris 版本 2.1.1 及以上。

Flink 写入指标

其中 Counter 类型的指标值为导入任务从开始到当前的累加值，可以在 Flink Webui metrics 中观察各表的各项指标。

Name	Metric Type	Description
totalFlushLoadBytes	Counter	已经刷新导入的总字节数
flushTotalNumberRows	Counter	已经导入处理的总行数
totalFlushLoadedRows	Counter	已经成功导入的总行数
totalFlushTimeMs	Counter	已经成功导入完成的总时间

Name	Metric Type	Description
totalFlushSucceededNumber	Counter	已经成功导入的次数
totalFlushFailedNumber	Counter	失败导入 的次数
totalFlushFilteredRows	Counter	数据质量不合格的总行数
totalFlushUnselectedRows	Counter	被 where 条件过滤的总行数
beginTxnTimeMs	Histogram	向 Fe 请求开始一个事务所花费的时间，单位毫秒
putDataTimeMs	Histogram	向 Fe 请求获取导入数据执行计划所花费的时间
readDataTimeMs	Histogram	读取数据所花费的时间
writeDataTimeMs	Histogram	执行写入数据操作所花费的时间
commitAndPublishTimeMs	Histogram	向 Fe 请求提交并且发布事务所花费的时间
loadTimeMs	Histogram	导入完成的时间

使用 FlinkSQL 通过 CDC 接入 Doris 示例

```

-- enable checkpoint
SET 'execution.checkpointing.interval' = '10s';

CREATE TABLE cdc_mysql_source (
  id int
  ,name VARCHAR
  ,PRIMARY KEY (id) NOT ENFORCED
) WITH (
  'connector' = 'mysql-cdc',
  'hostname' = '127.0.0.1',
  'port' = '3306',
  'username' = 'root',
  'password' = 'password',
  'database-name' = 'database',
  'table-name' = 'table'
);

-- 支持同步 insert/update/delete 事件
CREATE TABLE doris_sink (
  id INT,
  name STRING
)
WITH (
  'connector' = 'doris',
  'fenodes' = '127.0.0.1:8030',
  'table.identifier' = 'database.table',
  'username' = 'root',
  'password' = '',
  'sink.properties.format' = 'json',
  'sink.properties.read_json_by_line' = 'true',
  'sink.enable-delete' = 'true', -- 同步删除事件
  'sink.label-prefix' = 'doris_label'
);

insert into doris_sink select id,name from cdc_mysql_source;

```

使用 FlinkSQL 通过 CDC 接入并实现部分列更新示例

```
-- enable checkpoint
SET 'execution.checkpointing.interval' = '10s';

CREATE TABLE cdc_mysql_source (
  id int
  ,name STRING
  ,bank STRING
  ,age int
  ,PRIMARY KEY (id) NOT ENFORCED
) WITH (
  'connector' = 'mysql-cdc',
  'hostname' = '127.0.0.1',
  'port' = '3306',
  'username' = 'root',
  'password' = 'password',
  'database-name' = 'database',
  'table-name' = 'table'
);

CREATE TABLE doris_sink (
  id INT,
  name STRING,
  bank STRING,
  age int
)
WITH (
  'connector' = 'doris',
  'fenodes' = '127.0.0.1:8030',
  'table.identifier' = 'database.table',
  'username' = 'root',
  'password' = '',
  'sink.properties.format' = 'json',
  'sink.properties.read_json_by_line' = 'true',
  'sink.properties.columns' = 'id,name,bank,age',
  'sink.properties.partial_columns' = 'true' -- 开启部分列更新
);

insert into doris_sink select id,name,bank,age from cdc_mysql_source;
```

使用 Flink CDC 接入多表或整库 (支持 MySQL,Oracle,PostgreSQL,SQLServer,MongoDB)

语法

```
<FLINK_HOME>bin/flink run \
  -c org.apache.doris.flink.tools.cdc.CdcTools \
  lib/flink-doris-connector-1.16-1.6.1.jar \
  <mysql-sync-database|oracle-sync-database|postgres-sync-database|sqlserver-sync-database|mongodb-sync-
database> \
  --database <doris-database-name> \
  [--job-name <flink-job-name>] \
  [--table-prefix <doris-table-prefix>] \
  [--table-suffix <doris-table-suffix>] \
  [--including-tables <mysql-table-name|name-regular-expr>] \
  [--excluding-tables <mysql-table-name|name-regular-expr>] \
  --mysql-conf <mysql-cdc-source-conf> [--mysql-conf <mysql-cdc-source-conf> ...] \
  --oracle-conf <oracle-cdc-source-conf> [--oracle-conf <oracle-cdc-source-conf> ...] \
```

```

--postgres-conf <postgres-cdc-source-conf> [--postgres-conf <postgres-cdc-source-conf> ...] \
--sqlserver-conf <sqlserver-cdc-source-conf> [--sqlserver-conf <sqlserver-cdc-source-conf> ...] \
--sink-conf <doris-sink-conf> [--table-conf <doris-sink-conf> ...] \
[--table-conf <doris-table-conf> [--table-conf <doris-table-conf> ...]]

```

Key	Comment
-job-name	Flink 任务名称，非必需
-database	同步到 Doris 的数据库名
-table-prefix	Doris 表前缀名，例如 -table-prefix ods_。
-table-suffix	同上，Doris 表的后缀名。
-including-tables	需要同步的 MySQL 表，可以使用 \ 分隔多个表，并支持正则表达式。比如-including-tables table1
-excluding-tables	不需要同步的表，用法同上。
-mysql-conf	MySQL CDCSource 配置，例如-mysql-conf hostname=127.0.0.1，您可以在 这里 查看所有配置 MySQL-CDC，其中 hostname/username/password/database-name 是必需的。同步的库表中含有非主键表时，必须设置 scan.incremental.snapshot.chunk.key-column，且只能选择非空类型的一个字段。 例如：scan.incremental.snapshot.chunk.key-column=database.table:column,database.table1:column...，不同的库表列之间用,隔开。
-oracle-conf	Oracle CDCSource 配置，例如-oracle-conf hostname=127.0.0.1，您可以在 这里 查看所有配置 Oracle-CDC，其中 hostname/username/password/database-name/schema-name 是必需的。
-postgres-conf	Postgres CDCSource 配置，例如-postgres-conf hostname=127.0.0.1，您可以在 这里 查看所有配置 Postgres-CDC，其中 hostname/username/password/database-name/schema-name/slot.name 是必需的。
-sqlserver-conf	SQLServer CDCSource 配置，例如-sqlserver-conf hostname=127.0.0.1，您可以在 这里 查看所有配置 SQLServer-CDC，其中 hostname/username/password/database-name/schema-name 是必需的。
-db2-conf	SQLServer CDCSource 配置，例如-db2-conf hostname=127.0.0.1，您可以在 这里 查看所有配置 DB2-CDC，其中 hostname/username/password/database-name/schema-name 是必需的。

Key	Comment
<code>-sink-conf</code>	Doris Sink 的所有配置，可以在 这里 查看完整的配置项。
<code>-mongodb-conf</code>	MongoDB CDCSource 配置，例如 <code>-mongodb-conf hosts=127.0.0.1:27017</code> ，您可以在 这里 查看所有配置 Mongo-CDC，其中 <code>hosts/username/password/database</code> 是必须的。其中 <code>-mongodb-conf schema.sample-percent</code> 为自动采样 mongodb 数据为 Doris 建表的配置，默认为 0.2
<code>-table-conf</code>	Doris 表的配置项，即 properties 中包含的内容（其中 table-buckets 例外，非 properties 属性）。例如 <code>--table-conf replication_num=1</code> ，而 <code>--table-conf table-buckets="tbl1:10,tbl2:20,a.*:30,b.*:40,.*:50"</code> 表示按照正则表达式顺序指定不同表的 buckets 数量，如果没有匹配到则采用 BUCKETS AUTO 建表。
<code>-ignore-default-value</code>	关闭同步 MySQL 表结构的默认值。适用于同步 MySQL 数据到 Doris 时，字段有默认值，但实际插入数据为 null 情况。参考 #152
<code>-use-new-schema-change</code>	是否使用新的 schema change，支持同步 MySQL 多列变更、默认值，1.6.0 开始该参数默认为 true。参考 #167
<code>-schema-change-mode</code>	解析 schema change 的模式，支持 <code>debezium_structure</code> 、 <code>sql_parser</code> 两种解析模式，默认采用 <code>debezium_structure</code> 模式。 <code>debezium_structure</code> 解析上游 CDC 同步数据时所使用的数据结构，通过解析该结构判断 DDL 变更操作。 <code>sql_parser</code> 通过解析上游 CDC 同步数据时的 DDL 语句，从而判断 DDL 变更操作，因此该解析模式更加准确。 使用例子： <code>--schema-change-mode debezium_structure</code> 本功能将在 1.6.2.1 后的版本中提供
<code>-single-sink</code>	是否使用单个 Sink 同步所有表，开启后也可自动识别上游新创建的表，自动创建表。
<code>-multi-to-one-origin</code>	将上游多张表写入同一张表时，源表的配置，比如： <code>--multi-to-one-origin "a_.*\ b_.*"</code> ，具体参考 #208
<code>-multi-to-one-target</code>	与 <code>multi-to-one-origin</code> 搭配使用，目标表的配置，比如： <code>--multi-to-one-target "a\</code>

Key	Comment
-create-table-only	是否只同步表的结构

备注

1. 同步时需要在 `$FLINK_HOME/lib` 目录下添加对应的 Flink CDC 依赖，比如 `flink-sql-connector-mysql-cdc-version.jar`, `flink-sql-connector-oracle-cdc-{version}.jar`, `flink-sql-connector-mongodb-cdc-{version}.jar`
2. Connector 24.0.0 之后依赖的 Flink CDC 版本需要在 3.1 以上，如果需使用 Flink CDC 同步 MySQL 和 Oracle，还需要在 `$FLINK_HOME/lib` 下增加相关的 JDBC 驱动。

MySQL 多表同步示例

```
<FLINK_HOME>bin/flink run \
-Dexecution.checkpointing.interval=10s \
-Dparallelism.default=1 \
-c org.apache.doris.flink.tools.cdc.CdcTools \
lib/flink-doris-connector-1.16-24.0.1.jar \
mysql-sync-database \
--database test_db \
--mysql-conf hostname=127.0.0.1 \
--mysql-conf port=3306 \
--mysql-conf username=root \
--mysql-conf password=123456 \
--mysql-conf database-name=mysql_db \
--including-tables "tbl1|test.*" \
--sink-conf fenodes=127.0.0.1:8030 \
--sink-conf username=root \
--sink-conf password=123456 \
--sink-conf jdbc-url=jdbc:mysql://127.0.0.1:9030 \
--sink-conf sink.label-prefix=label \
--table-conf replication_num=1
```

Oracle 多表同步示例

```
<FLINK_HOME>bin/flink run \
-Dexecution.checkpointing.interval=10s \
-Dparallelism.default=1 \
-c org.apache.doris.flink.tools.cdc.CdcTools \
./lib/flink-doris-connector-1.16-24.0.1.jar \
oracle-sync-database \
--database test_db \
--oracle-conf hostname=127.0.0.1 \
--oracle-conf port=1521 \
--oracle-conf username=admin \
--oracle-conf password="password" \
--oracle-conf database-name=XE \
--oracle-conf schema-name=ADMIN \
--including-tables "tbl1|tbl2" \
```



```
--sink-conf fenodes=127.0.0.1:8030 \
--sink-conf username=root \
--sink-conf password=\
--sink-conf jdbc-url=jdbc:mysql://127.0.0.1:9030 \
--sink-conf sink.label-prefix=label \
--table-conf replication_num=1
```

PostgreSQL 多表同步示例

```
<FLINK_HOME>/bin/flink run \
-Dexecution.checkpointing.interval=10s \
-Dparallelism.default=1 \
-c org.apache.doris.flink.tools.cdc.CdcTools \
./lib/flink-doris-connector-1.16-24.0.1.jar \
postgres-sync-database \
--database db1 \
--postgres-conf hostname=127.0.0.1 \
--postgres-conf port=5432 \
--postgres-conf username=postgres \
--postgres-conf password="123456" \
--postgres-conf database-name=postgres \
--postgres-conf schema-name=public \
--postgres-conf slot.name=test \
--postgres-conf decoding.plugin.name=pgoutput \
--including-tables "tbl1|tbl2" \
--sink-conf fenodes=127.0.0.1:8030 \
--sink-conf username=root \
--sink-conf password=\
--sink-conf jdbc-url=jdbc:mysql://127.0.0.1:9030 \
--sink-conf sink.label-prefix=label \
--table-conf replication_num=1
```

SQLServer 多表同步示例

```
<FLINK_HOME>/bin/flink run \
-Dexecution.checkpointing.interval=10s \
-Dparallelism.default=1 \
-c org.apache.doris.flink.tools.cdc.CdcTools \
./lib/flink-doris-connector-1.16-24.0.1.jar \
sqlserver-sync-database \
--database db1 \
--sqlserver-conf hostname=127.0.0.1 \
--sqlserver-conf port=1433 \
--sqlserver-conf username=sa \
--sqlserver-conf password="123456" \
--sqlserver-conf database-name=CDC_DB \
--sqlserver-conf schema-name=dbo \
--including-tables "tbl1|tbl2" \
--sink-conf fenodes=127.0.0.1:8030 \
--sink-conf username=root \
--sink-conf password=\
--sink-conf jdbc-url=jdbc:mysql://127.0.0.1:9030 \
--sink-conf sink.label-prefix=label \
--table-conf replication_num=1
```

DB2 多表同步示例

```
<FLINK_HOME>bin/flink run \  
-Dexecution.checkpointing.interval=10s \  
-Dparallelism.default=1 \  
-c org.apache.doris.flink.tools.cdc.CdcTools \  
lib/flink-doris-connector-1.16-24.0.1.jar \  
db2-sync-database \  
--database db2_test \  
--db2-conf hostname=127.0.0.1 \  
--db2-conf port=50000 \  
--db2-conf username=db2inst1 \  
--db2-conf password=doris123456 \  
--db2-conf database-name=testdb \  
--db2-conf schema-name=DB2INST1 \  
--including-tables "FULL_TYPES|CUSTOMERS" \  
--single-sink true \  
--use-new-schema-change true \  
--sink-conf fenodes=127.0.0.1:8030 \  
--sink-conf username=root \  
--sink-conf password=123456 \  
--sink-conf jdbc-url=jdbc:mysql://127.0.0.1:9030 \  
--sink-conf sink.label-prefix=label \  
--table-conf replication_num=1
```

MongoDB 多表同步示例

```
<FLINK_HOME>/bin/flink run \  
-Dexecution.checkpointing.interval=10s \  
-Dparallelism.default=1 \  
-c org.apache.doris.flink.tools.cdc.CdcTools \  
./lib/flink-doris-connector-1.18-24.0.1.jar \  
mongodb-sync-database \  
--database doris_db \  
--schema-change-mode debezium_structure \  
--mongodb-conf hosts=127.0.0.1:27017 \  
--mongodb-conf username=flinkuser \  
--mongodb-conf password=flinkpwd \  
--mongodb-conf database=test \  
--mongodb-conf scan.startup.mode=initial \  
--mongodb-conf schema.sample-percent=0.2 \  
--including-tables "tbl1|tbl2" \  
--sink-conf fenodes=127.0.0.1:8030 \  
--sink-conf username=root \  
--sink-conf password= \  
--sink-conf jdbc-url=jdbc:mysql://127.0.0.1:9030 \  
--sink-conf sink.label-prefix=label \  
--sink-conf sink.enable-2pc=false \  
--table-conf replication_num=1
```

使用 Flink CDC 更新 Key 列

一般在业务数据库中，会使用编号来作为表的主键，比如 Student 表，会使用编号 (id) 来作为主键，但是随着业务的发展，数据对应的编号有可能是会发生变化的。在这种场景下，使用 Flink CDC + Doris Connector 同步数据，便可以自动更新 Doris 主键列的数据。#### 原理 Flink CDC 底层的采集工具是 Debezium，Debezium 内部使用 op 字段来标识对应的操作：op 字段的取值分别为 c、u、d、r，分别对应 create、update、delete 和

read。而对于主键列的更新，Flink CDC 会向下游发送 DELETE 和 INSERT 事件，同时数据同步到 Doris 中后，就会自动更新主键列的数据。

使用

Flink 程序可参考上面 CDC 同步的示例，成功提交任务后，在 MySQL 侧执行 Update 主键列的语句 (update student set id = '1002' where id = '1001')，即可修改 Doris 中的数据。

使用 Flink 根据指定列删除数据

一般 Kafka 中的消息会使用特定字段来标记操作类型，比如{"op_type":"delete",data:{...}}。针对这类数据，希望将 op_type=delete 的数据删除掉。

DorisSink 默认会根据 RowKind 来区分事件的类型，通常这种在 cdc 情况下可以直接获取到事件类型，对隐藏列 __DORIS_DELETE_SIGN__ 进行赋值达到删除的目的，而 Kafka 则需要根据业务逻辑判断，显示的传入隐藏列的值。

使用

```
-- 比如上游数据: {"op_type":"delete",data:{"id":1,"name":"zhangsan"}}
CREATE TABLE KAFKA_SOURCE(
  data STRING,
  op_type STRING
) WITH (
  'connector' = 'kafka',
  ...
);

CREATE TABLE DORIS_SINK(
  id INT,
  name STRING,
  __DORIS_DELETE_SIGN__ INT
) WITH (
  'connector' = 'doris',
  'fenodes' = '127.0.0.1:8030',
  'table.identifier' = 'db.table',
  'username' = 'root',
  'password' = '',
  'sink.enable-delete' = 'false',          -- false 表示不从 RowKind 获取事件类型
  'sink.properties.columns' = 'id, name, __DORIS_DELETE_SIGN__' -- 显示指定 streamload 的导入列
);

INSERT INTO DORIS_SINK
SELECT json_value(data,'$.id') as id,
       json_value(data,'$.name') as name,
       if(op_type='delete',1,0) as __DORIS_DELETE_SIGN__
from KAFKA_SOURCE;
```

Java 示例

samples/doris-demo/ 下提供了 Java 版本的示例，可供参考，查看[点击这里](#)

最佳实践

应用场景

使用 Flink Doris Connector 最适合的场景就是实时/批次同步源数据（MySQL，Oracle，PostgreSQL 等）到 Doris，使用 Flink 对 Doris 中的数据和其他数据源进行联合分析，也可以使用 Flink Doris Connector。

其他

1. Flink Doris Connector 主要是依赖 Checkpoint 进行流式写入，所以 Checkpoint 的间隔即为数据的可见延迟时间。
2. 为了保证 Flink 的 Exactly Once 语义，Flink Doris Connector 默认开启两阶段提交，Doris 在 1.1 版本后默认开启两阶段提交。1.0 可通过修改 BE 参数开启，可参考[two_phase_commit](#)。

常见问题

1. Doris Source 在数据读取完成后，流为什么就结束了？

目前 Doris Source 是有界流，不支持 CDC 方式读取。

2. Flink 读取 Doris 可以进行条件下推吗？

通过配置 `doris.filter.query` 参数，详情参考配置小节。

3. 如何写入 Bitmap 类型？

```
CREATE TABLE bitmap_sink (  
  dt int,  
  page string,  
  user_id int  
)  
WITH (  
  'connector' = 'doris',  
  'fenodes' = '127.0.0.1:8030',  
  'table.identifier' = 'test.bitmap_test',  
  'username' = 'root',  
  'password' = '',  
  'sink.label-prefix' = 'doris_label',  
  'sink.properties.columns' = 'dt,page,user_id,user_id=to_bitmap(user_id)'  
)
```

4. `errCode = 2, detailMessage = Label [label_0_1] has already been used, relate to txn [19650]`

Exactly-Once 场景下，Flink Job 重启时必须从最新的 Checkpoint/Savepoint 启动，否则会报如上错误。不要求 Exactly-Once 时，也可通过关闭 2PC 提交（`sink.enable-2pc=false`）或更换不同的 `sink.label-prefix` 解决。

5. `errCode = 2, detailMessage = transaction [19650] not found`

发生在 Commit 阶段，checkpoint 里面记录的事务 ID，在 FE 侧已经过期，此时再次 commit 就会出现上述错误。此时无法从 checkpoint 启动，后续可通过修改 `fe.conf` 的 `streaming_label_keep_max_second` 配置来延长过期时间，默认 12 小时。Doris 2.0 版本后还会受到 `fe.conf` 中 `label_num_threshold` 配置的限制（默认 2000），可以调大或者改为 -1（-1 表示只受时间限制）。

6. `errCode = 2, detailMessage = current running txns on db 10006 is 100, larger than limit 100`

这是因为同一个库并发导入超过了 100，可通过调整 `fe.conf` 的参数 `max_running_txn_num_per_db` 来解决，具体可参考 [max_running_txn_num_per_db](#)。

同时，一个任务频繁修改 label 重启，也可能会导致这个错误。2pc 场景下 (Duplicate/Aggregate 模型)，每个任务的 label 需要唯一，并且从 checkpoint 重启时，flink 任务才会主动 abort 掉之前已经 precommit 成功，没有 commit 的 txn，频繁修改 label 重启，会导致大量 precommit 成功的 txn 无法被 abort，占用事务。在 Unique 模型下也可关闭 2pc，可以实现幂等写入。

7. Flink 写入 Uniq 模型时，如何保证一批数据的有序性？

可以添加 sequence 列配置来保证，具体可参考 [sequence](#)

8. Flink 任务没报错，但是无法同步数据？

Connector1.1.0 版本以前，是攒批写入的，写入均是由数据驱动，需要判断上游是否有数据写入。1.1.0 之后，依赖 Checkpoint，必须开启 Checkpoint 才能写入。

9. `tablet writer write failed, tablet_id=190958, txn_id=3505530, err=-235`

通常发生在 Connector1.1.0 之前，是由于写入频率过快，导致版本过多。可以通过设置 `sink.batch.size` 和 `sink.batch.interval` 参数来降低 Streamload 的频率。在 Connector1.1.0 之后，默认写入时机是由 Checkpoint 控制，可以通过增加 Checkpoint 间隔来降低写入频率。

10. Flink 导入有脏数据，如何跳过？

Flink 在数据导入时，如果有脏数据，比如字段格式、长度等问题，会导致 StreamLoad 报错，此时 Flink 会不断的重试。如果需要跳过，可以通过禁用 StreamLoad 的严格模式 (`strict_mode=false,max_filter_ratio=1`) 或者在 Sink 算子之前对数据做过滤。

11. 源表和 Doris 表应如何对应？

使用 Flink Connector 导入数据时，要注意两个方面，第一是源表的列和类型跟 flink sql 中的列和类型要对应上；第二个是 flink sql 中的列和类型要跟 Doris 表的列和类型对应上，具体可以参考上面的“Doris 和 Flink 列类型映射关系”

12. `TApplicationException: get_next failed: out of sequence response: expected 4 but got 3`

这是由于 Thrift 框架存在并发 bug 导致的，建议你使用尽可能新的 connector 以及与之兼容的 flink 版本。

13. `**DorisRuntimeException: Fail to abort transaction 26153 with url http://192.168.0.1:8040/api/table_name/_stream_load_2pc**`

你可以在 TaskManager 中搜索日志 `abort transaction response`，根据 http 返回码确定是 client 的问题还是 server 的问题。

14. 使用 `doris.filter.query` 出现 `org.apache.flink.table.api.SqlParserException: SQL parse failed. Encountered “xx” at line x, column xx`

出现这个问题主要是条件 `varchar/string` 类型，需要加引号导致的，正确写法是 `xxx = "xxx"`，这样 Flink SQL 解析器会将两个连续的单引号解释为一个单引号字符，而不是字符串的结束，并将拼接后的字符串作为属性的值。比如说：`t1 >= '2024-01-01'`，可以写成 `'doris.filter.query' = 't1 >= '2024-01-01''`。

Connector1.6.0 之后 FlinkSQL 可以实现自动谓词和投影下推。

15. 如果出现 **Failed to connect to backend: http://host:webserver_port**, 并且 **Be** 还是活着的

可能是因为你配置的 be 的 ip, 外部的 Flink 集群无法访问。这主要是因为当连接 fe 时, 会通过 fe 解析出 be 的地址。例如, 当你添加的 be 地址为 127.0.0.1, 那么 Flink 通过 fe 获取的 be 地址就为 127.0.0.1:webserver_port, 此时 Flink 就会去访问这个地址。当出现这个问题时, 可以通过在 with 属性中增加实际对应的 be 外部 ip 地 'benodes' = "be_ip:webserver_port, be_ip:webserver_port...", 整库同步则可增加 --sink-conf benodes=be_ip:webserver,be_ip:webserver...。

16. 如果使用整库同步 **MySQL** 数据到 **Doris**, 出现 **timestamp** 类型与源数据相差多个小时

整库同步默认 timezone="UTC+8", 如果你同步的数据不是该时区, 可以尝试如下设置相对应的时区, 例如: --mysql-conf debezium.date.format.timestamp.zone="UTC+3" 来解决。

17. 攒批写入和流式写入有什么区别

Connector1.5.0 之后支持攒批写入, 攒批写入不依赖 Checkpoint, 将数据缓存在内存中, 根据 sink.buffer-flush.max-rows/sink.buffer-flush.max-bytes/sink.buffer-flush.interval 参数来控制写入时机。流式写入必须开启 Checkpoint, 在整个 Checkpoint 期间持续的将上游数据写入到 Doris 中, 不会一直将数据缓存在内存中。

Doris Kafka Connector

[Kafka Connect](#) 是一款可扩展、可靠的在 Apache Kafka 和其他系统之间进行数据传输的工具，可以定义 Connectors 将大量数据迁入迁出 Kafka。

Doris 社区提供了 [doris-kafka-connector](#) 插件，可以将 Kafka topic 中的数据写入到 Doris 中。

Doris Kafka Connector 使用

下载

[doris-kafka-connector](#)

maven 依赖

```
<dependency>
  <groupId>org.apache.doris</groupId>
  <artifactId>doris-kafka-connector</artifactId>
  <version>25.0.0</version>
</dependency>
```

Standalone 模式启动

在 \$KAFKA_HOME 下创建 plugins 目录，将下载好的 doris-kafka-connector jar 包放入其中

配置 config/connect-standalone.properties

```
# 修改 kafka server 地址
bootstrap.servers=127.0.0.1:9092

# 修改为创建的 plugins 目录
# 注意：此处请填写 Kafka 的直接路径。例如：plugin.path=/opt/kafka/plugins
plugin.path=$KAFKA_HOME/plugins

# 建议将 Kafka 的 max.poll.interval.ms 时间调大到 30 分钟以上，默认 5 分钟
# 避免 Stream Load 导入数据消费超时，消费者被踢出消费群组
max.poll.interval.ms=1800000
consumer.max.poll.interval.ms=1800000
```

配置 doris-connector-sink.properties

在 config 目录下创建 doris-connector-sink.properties，并配置如下内容：

```
name=test-doris-sink
connector.class=org.apache.doris.kafka.connector.DorisSinkConnector
topics=topic_test
doris.topic2table.map=topic_test:test_kafka_tbl
buffer.count.records=10000
buffer.flush.time=120
buffer.size.bytes=5000000
doris.urls=10.10.10.1
```

```
doris.http.port=8030
doris.query.port=9030
doris.user=root
doris.password=
doris.database=test_db
key.converter=org.apache.kafka.connect.storage.StringConverter
value.converter=org.apache.kafka.connect.json.JsonConverter
```

启动 Standalone

```
$KAFKA_HOME/bin/connect-standalone.sh -daemon $KAFKA_HOME/config/connect-standalone.properties
$KAFKA_HOME/config/doris-connector-sink.properties
```

注意：一般不建议在生产环境中使用 **standalone** 模式

Distributed 模式启动

在 \$KAFKA_HOME 下创建 plugins 目录，将下载好的 doris-kafka-connector jar 包放入其中

配置 config/connect-distributed.properties

```
# 修改 broker 地址
bootstrap.servers=127.0.0.1:9092

# 修改 group.id, 同一集群的需要一致
group.id=connect-cluster

# 修改为创建的 plugins 目录
# 注意：此处请填写 Kafka 的直接路径。例如：plugin.path=/opt/kafka/plugins
plugin.path=$KAFKA_HOME/plugins

# 建议将 Kafka 的 max.poll.interval.ms 时间调大到 30 分钟以上，默认 5 分钟
# 避免 Stream Load 导入数据消费超时，消费者被踢出消费群组
max.poll.interval.ms=1800000
consumer.max.poll.interval.ms=1800000
```

启动 Distributed

```
$KAFKA_HOME/bin/connect-distributed.sh -daemon $KAFKA_HOME/config/connect-distributed.properties
```

增加 Connector

```
curl -i http://127.0.0.1:8083/connectors -H "Content-Type: application/json" -X POST -d '{
  "name":"test-doris-sink-cluster",
  "config":{
    "connector.class":"org.apache.doris.kafka.connector.DorisSinkConnector",
    "topics":"topic_test",
    "doris.topic2table.map": "topic_test:test_kafka_tbl",
    "buffer.count.records":"10000",
    "buffer.flush.time":"120",
    "buffer.size.bytes":"5000000",
    "doris.urls":"10.10.10.1",
    "doris.user":"root",
    "doris.password":"","
```



```

    "doris.http.port":"8030",
    "doris.query.port":"9030",
    "doris.database":"test_db",
    "key.converter":"org.apache.kafka.connect.storage.StringConverter",
    "value.converter":"org.apache.kafka.connect.json.JsonConverter"
  }
}'

```

操作 Connector

```

# 查看 connector 状态
curl -i http://127.0.0.1:8083/connectors/test-doris-sink-cluster/status -X GET
# 删除当前 connector
curl -i http://127.0.0.1:8083/connectors/test-doris-sink-cluster -X DELETE
# 暂停当前 connector
curl -i http://127.0.0.1:8083/connectors/test-doris-sink-cluster/pause -X PUT
# 重启当前 connector
curl -i http://127.0.0.1:8083/connectors/test-doris-sink-cluster/resume -X PUT
# 重启 connector 内的 tasks
curl -i http://127.0.0.1:8083/connectors/test-doris-sink-cluster/tasks/0/restart -X POST

```

参考: [Connect REST Interface](#)

注意 **kafka-connect** 首次启动时, 会往 **kafka** 集群中创建 `config.storage.topic` `offset.storage.topic` `status.storage.topic` 三个 **topic** 用于记录 **kafka-connect** 的共享连接器配置、偏移数据和状态更新。 [How to Use Kafka Connect - Get Started](#)

访问 SSL 认证的 Kafka 集群

通过 **kafka-connect** 访问 SSL 认证的 **Kafka** 集群需要用户提供用于认证 **Kafka Broker** 公钥的证书文件 (`client.truststore.jks`)。您可以在 `connect-distributed.properties` 文件中增加以下配置:

```

# Connect worker
security.protocol=SSL
ssl.truststore.location=/var/ssl/private/client.truststore.jks
ssl.truststore.password=test1234

# Embedded consumer for sink connectors
consumer.security.protocol=SSL
consumer.ssl.truststore.location=/var/ssl/private/client.truststore.jks
consumer.ssl.truststore.password=test1234

```

关于通过 **Kafka-Connect** 连接 SSL 认证的 **Kafka** 集群配置说明可以参考: [Configure Kafka Connect](#)

死信队列

默认情况下, 转换过程中或转换过程中遇到的任何错误都会导致连接器失败。每个连接器配置还可以通过跳过它们来容忍此类错误, 可选择将每个错误和失败操作的详细信息以及有问题的记录 (具有不同级别的详细信息) 写入死信队列以便记录。

```

errors.tolerance=all
errors.deadletterqueue.topic.name=test_error_topic

```

```
errors.deadletterqueue.context.headers.enable=true
errors.deadletterqueue.topic.replication.factor=1
```

配置项

Key	Enum	Default Value	Required	Description
name	-	-	Y	Connect 应用名称，必须是在 Kafka Connect 环境中唯一
connector.class	-	-	Y	org.apache.doris.kafka.connector.DorisSinkConnector
topics	-	-	Y	订阅的 topic 列表，逗号分隔：topic1,topic2
doris.urls	-	-	Y	Doris FE 连接地址。如果有多个，中间用逗号分割：10.20.30.1,10.20.30.2,10.20.30.3
doris.http.port	-	-	Y	Doris HTTP 协议端口
doris.query.port	-	-	Y	Doris MySQL 协议端口
doris.user	-	-	Y	Doris 用户名
doris.password	-	-	Y	Doris 密码

Key	Enum	Default Value	Required	Description
doris.database	-	-	Y	要写入的数据库。多个库时可以为空，同时在 topic2table.map 需要配置具体的库名称
doris.topic2table.map	-	-	Y	topic 和 table 表的对应关系，例：topic1:tb1,topic2:tb2 如果留空，默认将 topic 名称作为写入的 table。 多个库的格式为 topic1:db1.tbl1,topic2:db2.tbl2
buffer.count.records	-	50000	N	在 flush 到 doris 之前，每个 Kafka 分区在内存中缓冲的记录数。默认 50000 条记录
buffer.flush.time	-	120	N	buffer 刷新间隔，单位秒，默认 120 秒
buffer.size.bytes	-	10485760(100MB)	N	每个 Kafka 分区在内存中缓冲的记录的累积大小，单位字节，默认 100MB
jmx	-	true	N	通过 JMX 获取 Connector 内部监控指标，请参考： Doris-Connector-JMX
enable2pc	-	true	N	是否开启 Stream Load 的两阶段提交 (TwoPhaseCommit)，默认为 true。
enable.delete	-	false	N	是否同步删除记录，默认 false

Key	Enum	Default Value	Required	Description
label.prefix	-	\${name}	N	Stream load 导入数据时的 label 前缀。默认为 Connector 应用名称。
auto.redirect	-	true	N	是否重定向 StreamLoad 请求。开启后 StreamLoad 将通过 FE 重定向到需要写入数据的 BE，并且不再显示获取 BE 信息
load.model	stream_load, copy_into	stream_load	N	导入数据的方式。支持 stream_load 直接数据导入到 Doris 中；同时支持 copy_into 的方式导入数据至对象存储中，然后将数据加载至 Doris 中
sink.properties.*	-	'sink.properties.format':'json', 'sink.properties.read_json_by_line':'true'	N	Stream Load 的导入参数。 例如：定义列分隔符'sink.properties.column_separator':',' 详细参数参考 这里 。 开启 Group Commit ，例如开启 sync_mode 模式的 group commit: "sink.properties.group_commit":"sync_mode"。Group Commit 可以配置 off_mode、sync_mode、async_mode 三种模式，具体使用参考： Group-Commit 开启部分列更新 ，例如开启更新指定 col2 的部分列: "sink.properties.partial_columns":"true", "sink.properties.columns": "col2",
delivery.guarantee	at_least_once, exactly_once	at_least_once	N	消费 Kafka 数据导入至 doris 时，数据一致性的保障方式。支持 at_least_once exactly_once，默认为 at_least_once。Doris 需要升级至 2.1.0 以上，才能保障数据的 exactly_once
converter.debezium_mode	normal, debezium_ingestion	normal	N	使用 Connector 消费 Kafka 数据时，上游数据的类型转换模式。 normal表示正常消费 Kafka 中的数据，不经过任何类型转换。 debezium_ingestion表示当 Kafka 上游的数据通过 Debezium 等 CDC（Changelog Data Capture，变更数据捕获）工具采集时，上游数据需要经过特殊的类型转换才能支持。

Key	Enum	Default Value	Required	Description
debezium.schema evolution	none, basic	none	N	<p>通过 Debezium 采集上游数据库系统（如 MySQL），发生结构变更时，可以将增加的字段同步到 Doris 中。</p> <p>none表示上游数据库系统发生结构变更时，不同步变更后的结构到 Doris 中。</p> <p>basic表示同步上游数据库的数据变更操作。由于列结构变更是一个危险操作（可能会导致误删 Doris 表结构的列），目前仅支持同步上游增加列的操作。当列被重命名后，则旧列保持原样，Connector 会在目标表中新增一列，将重命名后的新增数据 Sink 到新列中。</p>
datetime_timezone	-	UTC	N	<p>当 converter.mode 为非 normal 模式时，对于日期数据类型（如 datetime, date, timestamp 等等）提供指定时区转换的方式，默认为 UTC 时区。</p>
avro.topic2schema_filepath	-	-	N	<p>通过读取本地提供的 Avro Schema 文件，来解析 Topic 中的 Avro 文件内容，实现与 Confluent 提供 Schema 注册中心解耦。</p> <p>此配置需要与 key.converter 或 value.converter 前缀一起使用，例如配置 avro-user、avro-product Topic 的本地 Avro Schema 文件如下： "value.converter.avro.topic2schema.filepath":"avro-user:file:///opt/avro_user.avsc, avro-product:file:///opt/avro_product.avsc"</p> <p>具体使用可以参考：#32</p>
recordable_name_field	-	-	N	<p>开启该参数后，可实现一个 Topic 的数据流向多个 Doris 表。配置详情参考：#58</p>
enable_combiner_flush	true, false	false	N	<p>是否将所有分区的数据合并在一起写入。默认值为false。仅支持主键模型的表启用此选项（设置为true）。如果topic包含大量分区，启用此功能可以减少资源消耗。</p>

Key	Enum	Default Value	Required	Description
max.retries	-	10	N	任务失败前重试错误的最大次数。
retry.interval.ms	-	6000	N	发生错误后，尝试重试之前的等待时间，单位为毫秒，默认6000毫秒。
be.handle.null.values	ignore, fail	ignore	N	如何处理null值的记录，默认跳过不处理。

其他Kafka Connect Sink通用配置项可参考：[connect_configuring](#)

类型映射

Doris-kafka-connector 使用逻辑或原始类型映射来解析列的数据类型。

原始类型是指使用 Kafka connect 的 Schema 表示的简单数据类型。逻辑数据类型通常是采用 Struct 结构表示复杂类型，或者日期时间类型。

Kafka 原始类型	Doris 类型
INT8	TINYINT
INT16	SMALLINT
INT32	INT
INT64	BIGINT
FLOAT32	FLOAT
FLOAT64	DOUBLE
BOOLEAN	BOOLEAN
STRING	STRING
BYTES	STRING

Kafka 逻辑类型	Doris 类型
org.apache.kafka.connect.data.Decimal	DECIMAL
org.apache.kafka.connect.data.Date	DATE
org.apache.kafka.connect.data.Time	STRING
org.apache.kafka.connect.data.Timestamp	DATETIME

Debezium 逻辑类型	Doris 类型
io.debezium.time.Date	DATE
io.debezium.time.Time	String
io.debezium.time.MicroTime	DATETIME
io.debezium.time.NanoTime	DATETIME
io.debezium.time.ZonedDateTime	DATETIME
io.debezium.time.Timestamp	DATETIME
io.debezium.time.MicroTimestamp	DATETIME
io.debezium.time.NanoTimestamp	DATETIME
io.debezium.time.ZonedTimestamp	DATETIME
io.debezium.data.VariableScaleDecimal	DOUBLE

最佳实践

同步普通 JSON 数据

1. 导入数据样本

在 Kafka 中，有以下样本数据

```
kafka-console-consumer.sh --bootstrap-server localhost:9092 --topic test-data-topic --from-beginning
{"user_id":1,"name":"Emily","age":25}
{"user_id":2,"name":"Benjamin","age":35}
{"user_id":3,"name":"Olivia","age":28}
{"user_id":4,"name":"Alexander","age":60}
{"user_id":5,"name":"Ava","age":17}
{"user_id":6,"name":"William","age":69}
{"user_id":7,"name":"Sophia","age":32}
{"user_id":8,"name":"James","age":64}
{"user_id":9,"name":"Emma","age":37}
{"user_id":10,"name":"Liam","age":64}
```

2. 创建需要导入的表

在 Doris 中，创建被导入的表，具体语法如下 sql CREATE TABLE

```
test_db.test_kafka_connector_tbl( user_id BIGINT NOT NULL COMMENT "user id", name
VARCHAR(20) COMMENT "name", age INT COMMENT "age" ) DUPLICATE KEY(user_id)
DISTRIBUTED BY HASH(user_id) BUCKETS 12;
```

3. 创建导入任务

在部署 Kafka-connect 的机器上, 通过 curl 命令提交如下导入任务 shell curl -i http://127.0.0.1:8083/connectors -H "Content-Type: application/json" -X POST -d '{
"name":"test-doris-sink-cluster", "config":{
"connector.class":"org.apache.doris.kafka.connector.DorisSinkConnector",
"tasks.max":"10", "topics":"test-data-topic", "doris.topic2table.map": "test-data-topic:test_kafka_connector_tbl", "buffer.count.records":"10000",
"buffer.flush.time":"120", "buffer.size.bytes":"5000000", "doris.urls":"10.10.10.1",
"doris.user":"root", "doris.password":""," "doris.http.port":"8030",
"doris.query.port":"9030", "doris.database":"test_db",
"key.converter":"org.apache.kafka.connect.storage.StringConverter",
"value.converter":"org.apache.kafka.connect.storage.StringConverter" } }'

同步 Debezium 组件采集的数据

1. MySQL 数据库中有如下表

```
CREATE TABLE test.test_user (  
  user_id int NOT NULL ,  
  name varchar(20),  
  age int,  
  PRIMARY KEY (user_id)  
) ENGINE=InnoDB DEFAULT CHARSET=utf8mb4 COLLATE=utf8mb4_0900_ai_ci;  
  
insert into test.test_user values(1,'zhangsan',20);  
insert into test.test_user values(2,'lisi',21);  
insert into test.test_user values(3,'wangwu',22);
```

2. 在 Doris 创建被导入的表

```
CREATE TABLE test_db.test_user(  
  user_id          BIGINT          NOT NULL COMMENT "user id",  
  name             VARCHAR(20)      COMMENT "name",  
  age              INT              COMMENT "age"  
)  
UNIQUE KEY(user_id)  
DISTRIBUTED BY HASH(user_id) BUCKETS 12;
```

3. 部署 Debezium connector for MySQL 组件, 参考: [Debezium connector for MySQL](#)

4. 创建 doris-kafka-connector 导入任务

假设通过 Debezium 采集到的 MySQL 表数据在 mysql_debezium.test.test_user Topic 中

```
curl -i http://127.0.0.1:8083/connectors -H "Content-Type: application/json" -X POST -d '{  
"name":"test-debezium-doris-sink",  
"config":{  
"connector.class":"org.apache.doris.kafka.connector.DorisSinkConnector",  
"tasks.max":"10",  
"topics":"mysql_debezium.test.test_user",  
"doris.topic2table.map": "mysql_debezium.test.test_user:test_user",  
"buffer.count.records":"10000",  
"buffer.flush.time":"120",  
"buffer.size.bytes":"5000000",  
"doris.urls":"10.10.10.1",  
"doris.user":"root",
```



```
"doris.password":"","
"doris.http.port":"8030",
"doris.query.port":"9030",
"doris.database":"test_db",
"converter.mode":"debezium_ingestion",
"enable.delete":"true",
"key.converter":"org.apache.kafka.connect.json.JsonConverter",
"value.converter":"org.apache.kafka.connect.json.JsonConverter"
}
}'
```

同步 Avro 序列化数据

```
curl -i http://127.0.0.1:8083/connectors -H "Content-Type: application/json" -X POST -d '{
  "name":"doris-avro-test",
  "config":{
    "connector.class":"org.apache.doris.kafka.connector.DorisSinkConnector",
    "topics":"avro_topic",
    "tasks.max":"10",
    "doris.topic2table.map": "avro_topic:avro_tab",
    "buffer.count.records":"100000",
    "buffer.flush.time":"120",
    "buffer.size.bytes":"10000000",
    "doris.urls":"127.0.0.1",
    "doris.user":"root",
    "doris.password":"","
    "doris.http.port":"8030",
    "doris.query.port":"9030",
    "doris.database":"test",
    "load.model":"stream_load",
    "key.converter":"io.confluent.connect.avro.AvroConverter",
    "key.converter.schema.registry.url":"http://127.0.0.1:8081",
    "value.converter":"io.confluent.connect.avro.AvroConverter",
    "value.converter.schema.registry.url":"http://127.0.0.1:8081"
  }
}'
```

同步 Protobuf 序列化数据

```
curl -i http://127.0.0.1:8083/connectors -H "Content-Type: application/json" -X POST -d '{
  "name":"doris-protobuf-test",
  "config":{
    "connector.class":"org.apache.doris.kafka.connector.DorisSinkConnector",
    "topics":"proto_topic",
    "tasks.max":"10",
    "doris.topic2table.map": "proto_topic:proto_tab",
    "buffer.count.records":"100000",
    "buffer.flush.time":"120",
    "buffer.size.bytes":"10000000",
    "doris.urls":"127.0.0.1",
    "doris.user":"root",
    "doris.password":"","
    "doris.http.port":"8030",
    "doris.query.port":"9030",
    "doris.database":"test",
    "load.model":"stream_load",
    "key.converter":"io.confluent.connect.protobuf.ProtobufConverter",
    "key.converter.schema.registry.url":"http://127.0.0.1:8081",
    "value.converter":"io.confluent.connect.protobuf.ProtobufConverter",
    "value.converter.schema.registry.url":"http://127.0.0.1:8081"
  }
}'
```

```
}  
}'
```

使用 Kafka Connect SMT 转换数据

数据样例如下:

```
{  
  "registertime": 1513885135404,  
  "userid": "User_9",  
  "regionid": "Region_3",  
  "gender": "MALE"  
}
```

假设需要在 Kafka 消息中硬编码新增一个列, 可以使用 InsertField。另外, 也可以使用 TimestampConverter 将 Bigint 类型 timestamp 转换成时间字符串。

```
curl -i http://127.0.0.1:8083/connectors -H "Content-Type: application/json" -X POST -d '{  
  "name": "insert_field_tranform",  
  "config": {  
    "connector.class": "org.apache.doris.kafka.connector.DorisSinkConnector",  
    "tasks.max": "1",  
    "topics": "users",  
    "doris.topic2table.map": "users:kf_users",  
    "buffer.count.records": "10",  
    "buffer.flush.time": "11",  
    "buffer.size.bytes": "5000000",  
    "doris.urls": "127.0.0.1:8030",  
    "doris.user": "root",  
    "doris.password": "123456",  
    "doris.http.port": "8030",  
    "doris.query.port": "9030",  
    "doris.database": "testdb",  
    "key.converter": "org.apache.kafka.connect.storage.StringConverter",  
    "value.converter": "org.apache.kafka.connect.json.JsonConverter",  
    "value.converter.schemas.enable": "false",  
    "transforms": "InsertField,TimestampConverter",  
    // Insert Static Field  
    "transforms.InsertField.type": "org.apache.kafka.connect.transforms.InsertField$Value",  
    "transforms.InsertField.static.field": "repo",  
    "transforms.InsertField.static.value": "Apache Doris",  
    // Convert Timestamp Format  
    "transforms.TimestampConverter.type": "org.apache.kafka.connect.transforms.TimestampConverter$Value",  
    "transforms.TimestampConverter.field": "registertime",  
    "transforms.TimestampConverter.format": "yyyy-MM-dd HH:mm:ss.SSS",  
    "transforms.TimestampConverter.target.type": "string"  
  }  
}'
```

样例数据经过 SMT 的处理之后, 变成如下所示:

```
{  
  "userid": "User_9",  
  "regionid": "Region_3",  
  "gender": "MALE",  
  "repo": "Apache Doris", // Static field added  
  "registertime": "2017-12-21 03:38:55.404" // Unix timestamp converted to string  
}
```

更多关于 Kafka Connect Single Message Transforms (SMT) 使用案例, 可以参考文档 [SMT documentation](#).

常见问题

1. 读取 JSON 类型的数据报如下错误:

```
Caused by: org.apache.kafka.connect.errors.DataException: JsonConverter with schemas.enable requires "schema"
and "payload" fields and may not contain additional fields. If you are trying to deserialize plain JSON data,
set schemas.enable=false in your converter configuration.
    at org.apache.kafka.connect.json.JsonConverter.toConnectData(JsonConverter.java:337)
    at org.apache.kafka.connect.storage.Converter.toConnectData(Converter.java:91)
    at
org.apache.kafka.connect.runtime.WorkerSinkTask.lambda$convertAndTransformRecord$4(WorkerSinkTask.java:536)
    at
org.apache.kafka.connect.runtime.errors.RetryWithToleranceOperator.execAndRetry(RetryWithToleranceOperator.java:180)
    at
org.apache.kafka.connect.runtime.errors.RetryWithToleranceOperator.execAndHandleError(RetryWithToleranceOperator.java:214)
```

原因: 是因为使用 `org.apache.kafka.connect.json.JsonConverter` 转换器需要匹配 “schema” 和 “payload” 字段。

两种解决方案, 任选其一: 1. 将 `org.apache.kafka.connect.json.JsonConverter` 更换为 `org.apache.kafka.connect.storage.StringConverter` 2. 启动模式为 **Standalone** 模式, 则将 `config/connect-standalone.properties` 中 `value.converter.schemas.enable` 或 `key.converter.schemas.enable` 改成 `false`; 启动模式为 **Distributed** 模式, 则将 `config/connect-distributed.properties` 中 `value.converter.schemas.enable` 或 `key.converter.schemas.enable` 改成 `false`

2. 消费超时, 消费者被踢出消费群组:

```
org.apache.kafka.clients.consumer.CommitFailedException: Offset commit cannot be completed since the consumer
is not part of an active group for auto partition assignment; it is likely that the consumer was kicked out
of the group.
    at
org.apache.kafka.clients.consumer.internals.ConsumerCoordinator.sendOffsetCommitRequest(ConsumerCoordinator.java:1318)
    at
org.apache.kafka.clients.consumer.internals.ConsumerCoordinator.doCommitOffsetsAsync(ConsumerCoordinator.java:1127)
    at
org.apache.kafka.clients.consumer.internals.ConsumerCoordinator.commitOffsetsAsync(ConsumerCoordinator.java:1093)
    at org.apache.kafka.clients.consumer.KafkaConsumer.commitAsync(KafkaConsumer.java:1590)
    at org.apache.kafka.connect.runtime.WorkerSinkTask.doCommitAsync(WorkerSinkTask.java:361)
    at org.apache.kafka.connect.runtime.WorkerSinkTask.doCommit(WorkerSinkTask.java:376)
    at org.apache.kafka.connect.runtime.WorkerSinkTask.commitOffsets(WorkerSinkTask.java:467)
    at org.apache.kafka.connect.runtime.WorkerSinkTask.commitOffsets(WorkerSinkTask.java:381)
    at org.apache.kafka.connect.runtime.WorkerSinkTask.iteration(WorkerSinkTask.java:221)
    at org.apache.kafka.connect.runtime.WorkerSinkTask.execute(WorkerSinkTask.java:206)
    at org.apache.kafka.connect.runtime.WorkerTask.doRun(WorkerTask.java:204)
    at org.apache.kafka.connect.runtime.WorkerTask.run(WorkerTask.java:259)
    at org.apache.kafka.connect.runtime.isolation.Plugins.lambda$withClassLoader$1(Plugins.java:181)
    at java.base/java.util.concurrent.Executors$RunnableAdapter.call(Executors.java:539)
    at java.base/java.util.concurrent.FutureTask.run(FutureTask.java:264)
    at java.base/java.util.concurrent.ThreadPoolExecutor.runWorker(ThreadPoolExecutor.java:1136)
    at java.base/java.util.concurrent.ThreadPoolExecutor$Worker.run(ThreadPoolExecutor.java:635)
    at java.base/java.lang.Thread.run(Thread.java:833)
```

解决方案：

将 Kafka 中 `max.poll.interval.ms` 根据场景进行调大，默认值是 `300000` - 如果是 Standalone 模式启动，则在 `config/connect-standalone.properties` 的配置文件中增加 `max.poll.interval.ms` 和 `consumer.max.poll.interval.ms` 参数，并配置参数值。 - 如果是 Distributed 模式启动，则在 `config/connect-distributed.properties` 的配置文件中增加 `max.poll.interval.ms` 和 `consumer.max.poll.interval.ms` 参数，并配置参数值。

调整参数后，重启 kafka-connect

3. Doris-kafka-connector 从 1.0.0 或 1.1.0 升级到 24.0.0 版本报错

```
org.apache.kafka.common.config.ConfigException: Topic 'connect-status' supplied via the
'status.storage.topic' property is required to have 'cleanup.policy=compact' to guarantee consistency and
durability of connector and task statuses, but found the topic currently has 'cleanup.policy=delete'.
Continuing would likely result in eventually losing connector and task statuses and problems restarting this
Connect cluster in the future. Change the 'status.storage.topic' property in the Connect worker
configurations to use a topic with 'cleanup.policy=compact'.
    at org.apache.kafka.connect.util.TopicAdmin.verifyTopicCleanupPolicyOnlyCompact(TopicAdmin.java:581)
    at
org.apache.kafka.connect.storage.KafkaTopicBasedBackingStore.lambda$topicInitializer$0(KafkaTopicBasedBacking
Store.java:47)
    at org.apache.kafka.connect.util.KafkaBasedLog.start(KafkaBasedLog.java:247)
    at org.apache.kafka.connect.util.KafkaBasedLog.start(KafkaBasedLog.java:231)
    at org.apache.kafka.connect.storage.KafkaStatusBackingStore.start(KafkaStatusBackingStore.java:228)
    at org.apache.kafka.connect.runtime.AbstractHerder.startServices(AbstractHerder.java:164)
    at org.apache.kafka.connect.runtime.distributed.DistributedHerder.run
```

解决方案：调整 connect-configs connect-status Topic 的清除策略为 compact

```
$KAFKA_HOME/bin/kafka-configs.sh --alter --entity-type topics --entity-name connect-configs --add-config
cleanup.policy=compact --bootstrap-server 127.0.0.1:9092
$KAFKA_HOME/bin/kafka-configs.sh --alter --entity-type topics --entity-name connect-status --add-config
cleanup.policy=compact --bootstrap-server 127.0.0.1:9092
```

4. debezium_ingestion 转换模式下，表结构变更失败

```
[2025-01-07 14:26:20,474] WARN [doris-normal_test_sink-connector|task-0] Table 'test_sink' cannot be altered
because schema evolution is disabled. (org.apache.doris.kafka.connector.converter.RecordService:183)
[2025-01-07 14:26:20,475] ERROR [doris-normal_test_sink-connector|task-0] WorkerSinkTask{id=doris-
normal_test_sink-connector-0} Task threw an uncaught and unrecoverable exception. Task is being killed and
will not recover until manually restarted. Error: Cannot alter table
org.apache.doris.kafka.connector.model.TableDescriptor@67cd8027 because schema evolution is disabled
(org.apache.kafka.connect.runtime.WorkerSinkTask:612)
org.apache.doris.kafka.connector.exception.SchemaChangeException: Cannot alter table
org.apache.doris.kafka.connector.model.TableDescriptor@67cd8027 because schema evolution is disabled
    at org.apache.doris.kafka.connector.converter.RecordService.alterTableIfNeeded(RecordService.java:186)
    at
org.apache.doris.kafka.connector.converter.RecordService.checkAndApplyTableChangesIfNeeded(RecordService.java
:150)
    at org.apache.doris.kafka.connector.converter.RecordService.processStructRecord(RecordService.java:100)
    at org.apache.doris.kafka.connector.converter.RecordService.getProcessedRecord(RecordService.java:305)
    at org.apache.doris.kafka.connector.writer.DorisWriter.putBuffer(DorisWriter.java:155)
    at org.apache.doris.kafka.connector.writer.DorisWriter.insertRecord(DorisWriter.java:124)
    at org.apache.doris.kafka.connector.writer.StreamLoadWriter.insert(StreamLoadWriter.java:151)
    at
org.apache.doris.kafka.connector.service.DorisDefaultSinkService.insert(DorisDefaultSinkService.java:154)
    at
```

```
org.apache.doris.kafka.connector.service.DorisDefaultSinkService.insert(DorisDefaultSinkService.java:135)
  at org.apache.doris.kafka.connector.DorisSinkTask.put(DorisSinkTask.java:97)
  at org.apache.kafka.connect.runtime.WorkerSinkTask.deliverMessages(WorkerSinkTask.java:583)
  at org.apache.kafka.connect.runtime.WorkerSinkTask.poll(WorkerSinkTask.java:336)
  at org.apache.kafka.connect.runtime.WorkerSinkTask.iteration(WorkerSinkTask.java:237)
  at org.apache.kafka.connect.runtime.WorkerSinkTask.execute(WorkerSinkTask.java:206)
  at org.apache.kafka.connect.runtime.WorkerTask.doRun(WorkerTask.java:202)
  at org.apache.kafka.connect.runtime.WorkerTask.run(WorkerTask.java:257)
  at org.apache.kafka.connect.runtime.isolation.Plugins.lambda$withClassLoader$1(Plugins.java:177)
  at java.base/java.util.concurrent.Executors$RunnableAdapter.call(Executors.java:515)
  at java.base/java.util.concurrent.FutureTask.run(FutureTask.java:264)
  at java.base/java.util.concurrent.ThreadPoolExecutor.runWorker(ThreadPoolExecutor.java:1128)
  at java.base/java.util.concurrent.ThreadPoolExecutor$Worker.run(ThreadPoolExecutor.java:628)
  at java.base/java.lang.Thread.run(Thread.java:829)
```

解决方案：

在 `debezium_ingestion` 转换模式下，默认表结构变更是关闭的，需要配置 `debezium.schema.evolution` 为 `basic` 以便开启表结构变更。

需要注意的是：开启表结构变更并不能准确的保持此变更列为 Doris 表中的唯一列（详见 `debezium.schema.evolution` 参数说明）。如需要保持上下游只存在唯一列，最好是手动添加变更列到 Doris 表中，再重新启动 Connector 任务，Connector 将会接着未消费的 `offset` 继续消费，保持数据的一致性。

Doris Streamloader

概述

[Doris Streamloader](#) 是一款用于将数据导入 Doris 数据库的专用客户端工具。相比于直接使用 curl 的单并发导入，该工具可以提供多并发导入的功能，降低大数据量导入的耗时。拥有以下功能：

- 并发导入，实现 Stream Load 的多并发导入。可以通过 workers 值设置并发数。
- 多文件导入，一次导入可以同时导入多个文件及目录，支持设置通配符以及会自动递归获取文件夹下的所有文件。
- 断点续传，在导入过程中可能出现部分失败的情况，支持在失败点处进行继续传输。
- 自动重传，在导入出现失败的情况后，无需手动重传，工具会自动重传默认的次数，如果仍然不成功，打印出手动重传的命令。

获取与安装

源代码：<https://github.com/apache/doris-streamloader> 二进制文件：<https://doris.apache.org/zh-CN/download>

获取结果即为可执行二进制。

使用方法

```
doris-streamloader --source_file={FILE_LIST} --url={FE_OR_BE_SERVER_URL}:{PORT} --header={STREAMLOAD_HEADER}
--db={TARGET_DATABASE} --table={TARGET_TABLE}
```

1. FILE_LIST 支持：

- 单个文件

例如：导入单个文件 file.csv

```
doris-streamloader --source_file="dir" --url="http://localhost:8330" --header="column_separator:|?
columns:col1,col2" --db="testdb" --table="testtbl"
```

- 单个目录

例如：导入单个目录 dir

```
doris-streamloader --source_file="dir" --url="http://localhost:8330" --header="column_separator:|?
columns:col1,col2" --db="testdb" --table="testtbl"
```

- 带通配符的文件名（需要用引号包围）

例如：导入 file0.csv, file1.csv, file2.csv

```
doris-streamloader --source_file="file*" --url="http://localhost:8330" --header="column_separator:|?columns:col1,col2" --db="testdb" --table="testtbl"
```

- 逗号分隔的文件名列表

例如：导入 file0.csv, file1.csv file2.csv

```
doris-streamloader --source_file="file0.csv,file1.csv,file2.csv" --url="http://localhost:8330" --header="column_separator:|?columns:col1,col2" --db="testdb" --table="testtbl"
```

- 逗号分隔的目录列表

例如：导入 dir1, dir2,dir3

```
doris-streamloader --source_file="dir1,dir2,dir3" --url="http://localhost:8330" --header="column_separator:|?columns:col1,col2" --db="testdb" --table="testtbl"
```

2. STREAMLOAD_HEADER 支持 Stream Load 的所有参数，多个参数之间用 ‘?’ 分隔。

用法举例：

```
doris-streamloader --source_file="data.csv" --url="http://localhost:8330" --header="column_separator:|?columns:col1,col2" --db="testdb" --table="testtbl"
```

上述参数均为必要参数，下面介绍可选参数：

参数名	含义	默认值	建议
-u	数据库用户名	root	
-p	数据库用户对应的密码	空字符串	
-compress	导入数据是否在 HTTP 传输时压缩	false	保持默认，打开后压缩解压会分别增加工具和 Doris BE 的 CPU 压力，所以仅在数据源所在机器网络带宽瓶颈时打开
-timeout	向 Doris 发送 HTTP 请求的超时时间，单位：秒	60*60*10	保持默认
-batch	文件批量读取和发送的粒度，单位：行	4096	保持默认
-batch_byte	文件批量读取和发送的粒度，单位：byte	943718400 (900MB)	保持默认
-workers	导入的并发数	0	设置成 0 为自动模式，会根据导入数据的大小，磁盘的吞吐量，Stream Load 导入速度计算一个值。也可以手动设置，性能好的集群可以设置大点，最好不要超过 10。如果观察到导入内存过高（通过观察 Memtracker 或者 Exceed 日志），则可适当降低 worker 数量

参数名	含义	默认值	建议
-disk_throughput	磁盘的吞吐量，单位 MB/s	800	通常保持默认即可。该值参与 -workers 的自动推算过程。如果希望通过工具能计算出一个适当的 workers 数，可以根据实际磁盘吞吐设置。
-streamload_throughput	Stream Load 导入实际的吞吐大小，单位 MB/s	100	通常保持默认即可。该值参与 -workers 的自动推算过程。默认值是通过每日性能测试环境给出的 Stream Load 吞吐量以及性能可预测性得出的。如果希望通过工具能计算出一个适当的 workers 数，可以设置实测的 Stream Load 的吞吐，即： $(LoadBytes * 1000) / (LoadTimeMs * 1024 * 1024)$ 计算出实际的吞吐量
-max_byte_per_task	每个导入任务数据量的最大大小，超过这个值剩下的数据会被拆分到一个新的导入任务中。	107374182400 (100G)	建议设置一个很大的值来减少导入的版本数。但如果遇到 body exceed max size 错误且不想调整 streaming_load_max_mb 参数（需重启 be），或是遇到 -238 TOO MANY SEGMENT 错误，可以临时调小这个配置
-check_utf8		true	保持默认
-debug	打印 Debug 日志	false	保持默认
-auto_retry	自动重传失败的 worker 序号和 task 序号的列表	空字符串	仅导入失败时重传使用，正常导入无需关心。失败时会提示具体参数内容，复制执行即可。例：如果 -auto_retry="1,1,2,1" 则表示：需要重传的 task 为：第一个 worker 的第一个 task，第二个 worker 的第一个 task。
-auto_retry_times	自动重传的次数	3	保持默认，如果不想重传需要把这个值设置为 0
-auto_retry_interval	自动重传的间隔	60	保持默认，如果 Doris 因宕机导致失败，建议根据实际 Doris 重启的时间间隔来设置该值
-log_filename	日志存储的位置	""	默认将日志打印到控制台上，如果要打印到日志文件中，可以设置存储日志文件的路径，如 -log_filename = "/var/log"

结果说明

无论成功与失败，都会显示最终的结果，结果参数说明：

参数名	描述
Status	导入成功（Success）与否（Failed）

参数名	描述
TotalRows	想要导入文件中所有的行数
FailLoadRows	想要导入文件中没有导入的行数
LoadedRows	实际导入 Doris 的行数
FilteredRows	实际导入过程中被 Doris 过滤的行数
UnselectedRows	实际导入过程中被 Doris 忽略的行数
LoadBytes	实际导入的 byte 大小
LoadTimeMs	实际导入的时间
LoadFiles	实际导入的文件列表

具体例子如下：

- 导入成功，成功信息如下：

```
Load Result: {
  "Status": "Success",
  "TotalRows": 120,
  "FailLoadRows": 0,
  "LoadedRows": 120,
  "FilteredRows": 0,
  "UnselectedRows": 0,
  "LoadBytes": 40632,
  "LoadTimeMs": 971,
  "LoadFiles": [
    "basic.csv",
    "basic_data1.csv",
    "basic_data2.csv",
    "dir1/basic_data.csv",
    "dir1/basic_data.csv.1",
    "dir1/basic_data1.csv"
  ]
}
```

- 导入失败：如果导入过程中部分数据没有导入失败了，会给出重传信息，如：

```
load has some error, and auto retry failed, you can retry by :
./doris-streamloader --source_file /mnt/disk1/laihui/doris/tools/tpch-tools/bin/tpch-
data/lineitem.tbl.1 --url="http://127.0.0.1:8239" --header="column_separator:|?columns: l_orderkey,
l_partkey, l_suppkey, l_linenum, l_quantity, l_extendedprice, l_discount, l_tax,
l_returnflag, l_linestatus,
l_shipdate, l_commitdate, l_receiptdate, l_shipinstruct, l_shipmode, l_comment, temp" --db="db" --
table="lineitem1" -u root -p "" --compress=false --timeout=36000 --workers=3 --batch=4096 --
batch_byte=943718400 --max_byte_per_task=1073741824 --check_utf8=true --report_duration=1 --
auto_retry="2,1;1,1;0,1" --auto_retry_times=0 --auto_retry_interval=60
```

只需复制运行该命令即可，auto_retry 说明可参考，并给出失败的结果信息：

```
Load Result: {
  "Status": "Failed",
  "TotalRows": 1,
  "FailLoadRows": 1,
  "LoadedRows": 0,
```

```

    "FilteredRows": 0,
    "UnselectedRows": 0,
    "LoadBytes": 0,
    "LoadTimeMs": 104,
    "LoadFiles": [
        "/mnt/disk1/laihui/doris/tools/tpch-tools/bin/tpch-data/lineitem.tbl.1"
    ]
}

```

最佳实践

1. 参数推荐

1. 必要参数，一定要配置： `--source_file=FILE_LIST --url=FE_OR_BE_SERVER_URL_WITH_PORT --header=STREAMLOAD_HEADER --db=TARGET_DATABASE --table=TARGET_TABLE`，如果需要导入多个文件时，推荐使用 `source_file` 方式。
2. `workers`，默认值为 CPU 核数，在 CPU 核数过多的场景（比如 96 核）会产生太多的并发，需要减少这个值，推荐一般设置为 8 即可。
3. `max_byte_per_task`，可以设置一个很大的值来减少导入的 version 数。但如果遇到 `body exceed max size` 错误且不想调整 `streaming_load_max_mb` 参数（需重启 BE），又或是遇到 `-238 T00 MANY SEGMENT` 错误，可以临时调小这个配置，一般使用默认即可。
4. 影响 version 数的两个参数：
 - `workers`：worker 数越多，版本号越多，并发越高，一般使用 8 即可。
 - `max_byte_per_task`：`max_byte_per_task` 越大，单个 version 数据量越大，version 数越少，但是这个值过大可能会遇到 `-238 T00 MANY SEGMENT` 的问题。一般使用默认值即可。

2. 推荐命令

设置必要参数以及设置 `workers=8` 即可。

```

./doris-streamloader --source_file="demo.csv,demoFile*.csv,demoDir" --url="http://127.0.0.1:8030" --header="column_separator:;" --db="demo" --table="test_load" --u="root" --workers=8

```

3. FAQ

- 在导入过程中，遇到了部分子任务失败的问题，当时没有断点续传的功能，导入失败后重新删表导入，如果遇到这个问题，工具会进行自动重传，如果重传失败会打印出重传命令，复制后可以手动重传。
- 该工具的默认单个导入是 100G，超过了 BE 默认的 `streaming_load_max_mb` 阈值如果不希望重启 BE，可以减少 `max_byte_per_task` 这个参数的大小。

查看 `streaming_load_max_mb` 大小的方法：

```

-curl "http://127.0.0.1:8040/api/show_config"

```

- 导入过程如果遇到 `-238 T00 MANY SEGMENT` 的问题，可以减少 `max_byte_per_task` 的大小。

Apache Superset

介绍


Apache Superset 是一个开源的数据挖掘平台，支持丰富的数据源连接，多种可视化方式，并能够对用户实现细粒度的权限控制。该工具主要特点是可自助分析、自定义仪表盘、分析结果可视化（导出）、用户/角色权限控制，还集成了一个 SQL 编辑器，可以进行 SQL 编辑查询等。

在 Apache Superset 3.1 版本中正式支持了 Apache Doris 的内部数据和外部数据进行查询和可视化处理。###前置条件 确保您已完成如下工具安装： 1. 在 Apache Superset 服务器上安装 Apache Doris 的 Python 客户端。
pip install pydoris

2. 安装 Apache Superset 3.1 及其以上的版本。具体参见 [安装 Superset 从 PyPI 库](#) 或者 [通过 Docker 容器的方式安装](#)。


添加数据源

1. 通过对应的启动端口对 Apache Superset 进行访问。




login page

2. 登陆后选择添加数据库连接。




add databases

3. 在连接的弹窗页面中选择 Apache Doris。



select databases

4. 在连接信息中填写 SQLAlchemy URI，并进行相关的连接验证。



test connection

当你在 Apache Superset 中创建数据源时，需要注意以下两点：

- 在 SUPPORTED DATABASES 里选择 Apache Doris 作为数据源。
- 在 SQLAlchemy URI 里，按如下 Apache Doris SQLAlchemy URI 格式填写 URI：

`doris://<User>:<Password>@<Host>:<Port>/<Catalog>.<Database>`

- URI 参数说明如下：
 - User：用于登录 Apache Doris 集群的用户名，如 Admin。
 - Password：用于登录 Apache Doris 集群的用户密码。
 - Host：Apache Doris 集群的 FE 主机 IP 地址。
 - Port：Apache Doris 集群的 FE 查询端口，如 9030。
 - Catalog：Apache Doris 集群中的目标 Catalog。Internal Catalog 和 External Catalog 均支持。
 - Database：Apache Doris 集群中的目标数据库。内部数据库和外部数据库均支持。

1. 当你使用最新的 Docker 镜像部署 Superset 时，如果发现找不到 Apache Doris 数据源，这个可能是因 Apache Superset Docker Image 默认只包含基本的数据源构建，需要手动将 pydoris 包安装进来，您可以参考 [Superset Docker 教程](#) 中的 How to extend this image 步骤进行 Apache Superset 的部署。

2. 推荐使用 Apache Doris 2.0.4 及以上版本。

FineBI

FineBI 介绍

FineBI 是一款商业智能产品，其具有数据处理、即时分析、多维度分析Dashboard 等多种功能系统架构，FineBI 支持丰富的数据源连接、多种视图对表的分析管理。FineBI 可以顺利支持Apache Doris 的内部数据和外部数据的建模与可视化处理。

前置条件

安装FineBI 5.0及以上版本，下载链接：<https://www.finebi.com/>

登录与连接

1. 创建登录的账户，并使用该账户登录FineBI



FineBI Business Intelligence



please enter user name



Please enter your password



Keep me logged in


Log in

login page

2. 这里选择内置数据库，若需要选择外部数据库配置文档可参考：<https://help.fanruan.com/finebi/doc-view-437.html>


:::info Note 这里建议选择内置数据库作为帆软BI 的信息存储库，这里选择的数据库类型不是查询分析数据的目标库，而是存储维护帆软BI 模型、仪表盘等信息的数据库，帆软需要对其进行增删改查的操作。

...




select database

3. 点击管理系统按钮之后选择数据连接中的数据库连接，进而创建一个新的数据库连接



data connection

4. 在新数据库连接选择界面选择MySQL



select connection

5. 填写Doris数据库的相关连接信息

参数说明如下：

- Username：用于登录 Doris 集群的用户名，如 admin。
- Password：用于登录 Doris 集群的用户密码。
- Host：Doris 集群的 FE 主机 IP 地址。
- Port：Doris 集群的 FE 查询端口，如 9030。

- Coding: Doris 集群中的编码格式。
- Name Database: Doris 集群中的目标数据库。

MySQL

Data connection name	Doris_connection			
drive	default	▼	com.mysql.jdbc.Driver	▼
Name database	tpch			
Host	<div></div>			
port	9030			
username	root			
password				
coding	default			▼

Data Connection URL	jdbc:mysql:; <div></div> tpch			
Maximum number of ...	50			
Get pre-connection ve...	yes			▼
Periodic check of idle ...	yes			▼
Verification Statement	<div>Use default statement if empty</div>			

Maximum waiting time	10000	millisecond
----------------------	-------	-------------

- ▶ SSH Setup
- ▶ SSL Settings
- ▶ More settings

connection information

6. 点击测试链接。如果输入的连接信息正确则会弹出连接成功




connection succeeded

connection test


创建数据模型

1. 在公共数据中点击创建一个新的数据集，添加Doris 数据集时可点击数据库表




new dataset

2. 选择已有数据库连接下需要导入的表




select table

3. 导入表后需要对每个导入的表进行刷新，只有刷新后才可以在主题中对该表进行数据分析



refresh table

4. 在编辑的主题中添加导入的公共数据，然后即可按照业务逻辑进行罗盘分析与配置。



data analysis

Power BI

Power BI 介绍

Power BI 是软件服务、应用连接器的集合，其可以连接到多种数据源，包括 Excel、SQL Server、Azure、Google Analytics 等，以便用户可以轻松地整合和清洗数据。通过 Power BI 的数据建模，用户可以创建关系模型、数据分析表达式和数据关系，以支持高级的数据分析和可视化。Power BI 提供了丰富的可视化选项，包括图标、地图、仪表盘和自定义可视化工具，以帮助用户更直观地理解数据。

Apache Doris 高度兼容 MySQL 协议，可以通过 MySQL 驱动器连接 Power BI，当前 Power BI 中已经正式支持了 Apache Doris 的内部数据建模以及数据查询与可视化处理。

前置条件

未安装 Power BI Desktop 可以访问 <https://www.microsoft.com/zh-cn/power-platform/products/power-bi/desktop> 下载安装 Power BI。

Power BI 与 Doris 的 Connector 配置

Note


选择 8.0.26 版本的 MySQL JDBC Connector

MySQL Connector 下载

下载链接: <https://downloads.mysql.com/archives/c-net/>


本地加载数据与创建模型

1. 启动 Power BI Desktop
2. 在 Power BI Desktop 打开界面点击新建报表。若已有本地报表可以选择打开已有报表



start page

3. 点击获取数据，在弹出窗口中选择 MySQL 数据库



get data


4. 配置数据库连接信息，在服务器输入框中输入 ip:port。Doris 默认的端口号为 9030



A dialog box titled "MySQL database" with a close button (X) in the top right corner. It contains two input fields: "Server" with the placeholder text "ip:port" in red, and "Database". Below the "Database" field is a link "Advanced options" with a right-pointing triangle. At the bottom right are two buttons: "OK" (green) and "Cancel" (white with a grey border).

connection information

5. 上一步点击确定后在新的连接窗口处选择“数据库”连接，并在用户名与密码处填写 Doris 的连接信息。



A dialog box titled "MySQL database" with a close button (X) in the top right corner. On the left is a dark sidebar with two items: "Windows" and "Database", where "Database" is highlighted with a red rectangle. The main area contains a blurred icon, a "User name" input field, a "Password" input field, and a dropdown menu labeled "Select which level to apply these settings to". At the bottom are three buttons: "Back" (white with a grey border), "Connect" (green), and "Cancel" (white with a grey border).

uname and pwd

6. 加载选中的表，使其表中数据至 Power BI Desktop

Navigator

demo.tbl2

id	name	age
-2147402211	mlsKj4n	-356259186
-2146386705	nj	-1775983815
-2144040486	gLY2C	-97476796
-2143878888	C2Zl	-12081112
-2143866872		1960409215
-2143391134	V3IO	-2095040412
-2143179619	gbrT	-1762753603
-2142322149	NE	-1068833622
-2141413929	null	812557797
-2141023768	9YHg11	878016196
-2139685708	jihA2	-5986385
-2139188477	Ej	-1427506342
-2138684240	LnX	602228005
-2133613091	U00ED	-1237572070
-2133452059	COAYWH17xY	-1133267872
-2133259218	cfD4	-436198012
-2133153349	null	692914641
-2132876626		1906447445
-2131414427		181718712
-2130883673	kjxFP9B8w7	-37835699
-2130203735	h	413755537
-2129178327	m5YzSk8LP	73584423
-2129064271	0	1845292630
-2128450687	IXF9	937520863

Select Related Tables Load Transform Data Cancel

load data

7. 配置需要的统计罗盘

Untitled - Power BI Desktop

File Home Insert Modeling View Optimize Help Format Data / Drill

Clipboard Copy Paste Format painter

Get data Excel OneLake SQL Server Enter data Data Warehouse Recent sources

Transform Refresh data Queries

New visual Text box More visuals Insert

New measure measure Calculations

Sensitivity Sensitivity Publish Copilot

Share Copilot

Sum of age

Filters

Search

Filters on this visual

Sum of age is (All)

Add data fields here

Filters on this page

Add data fields here

Filters on all pages

Add data fields here

Visualizations

Build visual

demo.tbl2

Σ age

Σ id

name

X-axis

Add data fields here

Y-axis

Sum of age

Legend

Add data fields here

Small multiples

Add data fields here


Page 1

Page 1 of 1

54%

create compass


8. 把创建好的统计罗盘保存至本地



save file


设置数据自动刷新

1. 下载 On-premises data gateway。下载地址：<https://learn.microsoft.com/en-us/power-bi/connect-data/service-gateway-personal-mode>
2. 安装 On-premises data gateway



gateway install

3. 登陆 Power BI Online，在个人的工作区中把刚保存的本地模型进行导入



upload

4. 点击模型配置自动刷新时间

<div> <div>+ New</div> <div> <div>↑</div> <div>Upload</div> </div> <div>Workspace settings</div> </div>			
	Name	Type	Owner
	doris	Report	
☐	doris	Semantic model	
	doris.pbix	Dashboard	

click module

- 数据刷新的配置需要有 gateway 连接，本地开启网关后可以在网关连接中看到本地启动的网关，选取本地的网关即可。更多关于 gateway: <https://learn.microsoft.com/zh-cn/power-bi/connect-data/service-gateway-onprem>

now you connect. [Learn more](#)

Gateway connections

Use an On-premises or VNet data gateway

☒ On

Gateway	Department	Contact information	Status	Actions
gateway_test			Running on LAPTOP-D967TF8G	
Data sources included in this semantic model:				
<div> MySQL{"server": "...", "database": "demo"} Maps to: <div></div> </div>				

Cloud connections

Data sources included in this semantic model:				
<div> MySQL{"server": "...", "database": "demo"} Maps to: <div></div> </div>				
<div> <div>Apply</div> <div>Discard</div> </div>				

Data source credentials

demo-... (admin has granted access, credentials are not required) [Show in lineage view](#)

config gateway

- 配置相关刷新计划即可完成 Power BI 自动数据刷新

Refresh

Configure a refresh schedule

Define a data refresh schedule to import data from the data source into the semantic model. [Learn more](#)

☒ On

Refresh frequency

Daily

Time zone

(UTC+08:00) Beijing, Chongqing, Hor

Time

[Add another time](#)

Send refresh failure notifications to

☒ Semantic model owner

☐ These contacts:

Enter email addresses

Apply Discard

make plan

Tableau

介绍

Tableau 是一款轻量级数据可视化分析平台，它将数据运算与美观的图表完美地结合在一起，不要求用户编写代码，仅仅通过拖拽的方式就可以快速洞察数据；探索不同的视图，甚至可以轻松地将多个数据源组合在一起，完成数据展示、探索和分析工作。### 前置条件 无论你的 Mac 采用 Intel 还是 Apple Silicon 架构，Tableau Desktop Mac 版需下载安装 Intel 版本，这是为了保证与 MySQL 驱动的兼容性。可通过 [Support Releases](#) 页面选择并下载 Intel 版本。


驱动安装

1. iODBC 安装

1. 关闭 Tableau Desktop
2. 从 [iODBC 官网](#) 下载最新的 Driver Manager (mxkozzz.dmg)
3. 安装下载好的 dmg 文件

选择 MySQL 5.x 的 ODBC 驱动安装，最新的 MySQL 驱动连接 Doris 会报错 Unsupported command 错误。

连接配置与使用 1. 点击 Tableau Desktop 主页，在连接数据源处选择MySQL



main page

2. 填写 Doris 服务器地址，端口等相关信息，正确填写后点击登录即可。

MySQL

×

General

Initial SQL

Server

Port

9030

Database

Optional

Username

Optional

Password

Optional

☐ Require SSL

Sign In

sign in page

3. 进入 Tableau 后选择对应的库表即可进行相关的罗盘处理。


QuickSight

QuickSight 介绍


QuickSight 是一个强大的数据可视化分析平台，致力于将数据计算与美观的图表完美融合。它不要求用户具备编程技能，仅需通过拖放操作，就能迅速获取数据洞察。QuickSight 提供了多种视图选项，方便用户从不同角度探索数据。此外，它还支持轻松整合多个数据源，使得数据展示、探索和分析变得更加简单高效。这个平台不仅让数据处理变得快捷，还使分析过程更加直观和易于理解，极大地提升了用户的工作效率和分析能力。

数据配置

1. 注册账号后登录 QuickSight，然后选择数据集。



2. 在数据集选择的页面中选择 MySQL。



database select

3. 在数据连接页面中填写对应 Doris 的 IP、端口、数据库名称、登录的用户名和密码。填写后点击连接测试，测试成功后创建链接。

New MySQL Data Source

×

Data Source Name

Enter a name for the data source

Connection Type

Public Network

✓

Database Server

Enter the host name or IP address

port

port

Name database

Enter the database name

username

username

password

password

Verify the connection

☒ Enable SSL

Create a data source

connection information

4. 创建数据源之后选择需要产生看板的表。

Select your table

Table: Contains data that can be visualized.

students

Edit/Preview Data

Using Custom SQL

choose

jdbc connector download

5. QuickSight 有两种导入表的方式，可以根据自己的需求选择对应的导入方式。

Complete dataset creation

surface : students

Estimated table size: 3.7KB

SPICE

data source:

Import to SPICE for faster analysis

SPICE

Query your data directly

☒ When refresh fails, the email owner

Edit/Preview Data

Scaling with SageMaker

Visualize

table select

1150 / 2281

6. 导入表之后，即可以创建所需要的看板。




table import


Quick BI

Quick BI介绍

Quick BI 是一款基于数据仓库的商业智能工具，它可以帮助企业快速搭建起酷炫的可视化分析罗盘。Quick BI 支持多种数据源，包括 MySQL、Oracle、SQL Server、Apache Doris 等数据库，以及 Excel、CSV、JSON 等文件格式。它提供了丰富的可视化组件，如表格、图表、地图等，用户可以通过简单的拖拽操作，轻松实现数据的可视化分析。

数据连接与应用

1. 登录 Quick BI 并建立一个工作区。
2. 在当前的工作区下点击新建数据源



create workspace

3. 在新建的数据源中选择 Apache Doris ，并填写对应 Doris 的连接信息。

Apache Doris

💡 Tip: Support version 1.2.4

* display name	<input type="text" value="Doris"/>
* Database address	<input type="text" value=""/>
* port	<input type="text" value="9030"/>
* database	<input type="text" value="tpch"/>
* username	<input type="text" value="root"/>
* password	<input type="password" value="....."/>

Doris information

4. 连接成功后，可在数据源列表中看到我们创建的数据源。



Doris

Owner: 

data source

5. 在创建的数据源中创建一个数据集，此处以 TPC-H 数据集为例。创建数据集后即可设置对应的报表。

Data Table

Select Data Source

 Doris

▼

Data Tab...

Upload Fi...

Q

↺

SQL

Create table using SQL code

 lineitem OLAP

 revenue0 VIEW

 part OLAP

 orders OLAP

 partsupp OLAP

 nation OLAP

 supplier OLAP

 region OLAP

 customer OLAP

nation

⋮

Preview

Batch Configuration

▼ Dimension

 n_name

Str. n_comment

▼ Measure

No n_nationkey

No n_regionkey

Doris table


Smartbi

Smartbi 介绍

Smartbi 是软件服务、应用连接器的集合，其可以连接到多种数据源，包括 Oracle、SQL Server、MySQL 和 Doris 等，以使用户可以轻松地整合和清洗数据。借助 Smartbi 的数据建模功能，用户不仅可以创建复杂的关系模型，还能编写数据分析表达式并建立数据关系，从而为高级的数据分析和可视化奠定基础。Smartbi 提供了丰富多样的可视化选项，包括各种类型的图表、地理地图、交互式仪表盘，以及支持用户自定义的可视化工具。这些功能强大的工具帮助用户更直观、更全面地理解和展示他们的数据，提升数据分析的效果和效率。

数据连接与应用

1. 登录 Smartbi 之后点击数据连接。



main page

2. 在数据连接页面中可以看到各个待连接的数据库列表，选择 Doris 数据库。



selectdb

3. 在选择数据库之后，填写 Doris 数据库的连接信息。

Create Relational Datasources

Name*

Can only contain letters, numbers, or underscores and do not start with a number!

Alias

Driver Type*

SelectDB

☐ Allow Excel data to be loaded ☐ 通过网关连接

ChooseDriver

☒ Built-in Product ☐ Custom

Driver Class*

com.mysql.jdbc.Driver

Connection String*

jdbc:mysql://<servername>:<port>/<database>?useOldAliasMetadataBehavior=true&useUnicode=true&characterEncod

LoginVerifyMethod*

UsernamePassword

Authentication Type ☒ Static ☐ Dynamic

Username

Password

Advanced >


Test Connection(T)

Save(S)

Close(C)


data source connection

4. 若填写信息无误，且连接成功后会显示测试通过。



test passed

5. 连接成功后，在数据分析模块电子服务看板，可以自定义设置所需要的报表信息。



data analysis

- >  Large screen visualization
- ✓  Demo
- ✓  Self-service dashboard
 - >  graph analysis
 - >  Table Analysis
 - >  Interaction Analysis
 - >  Calculation
 - >  Alarm Analysis
 - >  Other components
- >  Data Exploration
- >  spreadsheet
- >  WEB Spreadsheet
- >  analysis report

CloudDM

介绍

CloudDM 由 Clougence 研发，是一款为团队和个人用户而设计的跨平台数据库工具，帮助实现安全、高效、合规的数据库变更与管理。

CloudDM 针对 Apache Doris 的一些特性提供专项适配，并为 Apache Doris 提供数据访问、数据脱敏、可视化编辑、数据库CI/CD 能力。

前置条件

已安装 CloudDM。可以访问 <https://www.cdmgr.com/> 下载并安装 CloudDM。

添加数据源

备注

当前验证使用 CloudDM 2.8.0.0 版本。

- 1. 登录 CloudDM。
- 2. 在导航栏点击 数据源管理 > 新增数据源。
- 3. 选择 Doris 数据源。

Cloud DM

数据查询 项目 工单 查询设置 数据源管理 配置

v2.8.0.0 社区版 已激活， 还剩 89 天 17 小时 中文 Trial

* 数据库类型

Db2

Db2Fori

GaussDB

OpenGauss

MariaDB

MySQL

ObForOracle

OceanBase

Oracle

PolarDB-X

PostgreSQL

SQLServer

TiDB

Doris

Greenplum

SelectDB

环境

nnn

Doris 数据源设置

Client地址

内网

192.168.0.154:9030

FAQ

认证方式

账号密码

* 账号

admin

* 密码

.....

?

描述

?

* 物理位置

不限

返回数据源管理

新增数据源

添加数据源

4. 在添加数据源页面中，配置以下连接信息：

- Client 地址：Doris 集群机器的 FE 查询端口，如 hostID:9030。
- 账号：用于登录 Doris 集群的用户名，如 admin。
- 密码：用于登录 Doris 集群的用户密码。:::tip Doris 分为 internal catalog 和 external catalog，CloudDM 可以同时管理它们。:::

:::info 备注 通过 catalog.db 的 Database 形式来管理连接 Doris 的 external catalog 需要 Doris 版本在 2.1.0 及以上。:::

5. 在上方点击 **查询设置 > 查询配置**，为 Doris 实例启用数据管理，并测试连接。

Cloud DM

数据查询 项目 工单 查询设置 数据源管理 配置

v2.8.0.0 社区版 绿色，还剩 89 天 17 小时 ? 中文 Trial

查询配置

数据源 环境


类型 全部 查询

数据源ID	类型	数据管理	CI/CD	Host	环境	操作
drs-h259f6251dmw478 mode-mac-doris		☐	☐	内 192.168.0.156:9030	nnn	修改参数配置
my-45glsz30918bh8f mysql-101-不要乱动		☒	☒	内 192.168.0.101:3306	nnn	修改参数配置
ob-ze8ahuosob1tl4h No description		☐	☐	内 121.41.67.207:2881	nnn	修改参数配置
my-w645mzrl82s23x5 mysql-101		☒	☐	内 192.168.0.101:3306	nnn	修改参数配置
ms-e61g0x43q624b3l mssql-110		☒	☐	内 192.168.0.110:50502	nnn	修改参数配置
gsog-hmin6o243xw973i No description		☐	☐	内 121.40.179.209:25400	nnn	修改参数配置
gs-2hqprjz0hio41mz aliyun-GaussDB		☒	☒	内 121.40.179.209:25400	nnn	修改参数配置

启用数据源

6. 访问数据

数据库连接建立以后，可以在左侧的数据库连接导航看到已连接的数据源，并且可以通过 CloudDM 连接并管理数据库。



建立连接

功能支持

- 查询客户端
 - 可视化管理 Doris 中的数据库对象
 - 控制台编写 SQL 操作 Doris
 - 查询结果导出
- 团队化使用
 - 语句级授权，粒度表级别
 - 工单审批
 - 数据库 CI/CD
 - 敏感数据脱敏
 - SQL 审核规则

DBeaver

介绍

DBeaver 是一款跨平台数据库工具，适用于开发人员、数据库管理员、分析师和所有处理数据的人。

Apache Doris 高度兼容 MySQL 协议，可以使用 DBeaver 的 MySQL 驱动器连接 Apache Doris，并查询 internal catalog 和 external catalog 中的数据。

前置条件


已安装 Dbeaver 可以访问 <https://dbeaver.io> 下载安装 DBeaver

添加数据源


备注

当前验证使用 DBeaver 24.0.0 版本

1. 启动 DBeaver
2. 在 DBeaver 窗口左上角单击加号 (+) 图标，或者在菜单栏选择 **Database > New Database Connection**，打开 **Connect to a database** 界面。



添加连接 1



添加连接 2

3. 选择 MySQL 驱动器

在 **Select your database** 窗口，选择 **MySQL** 。



选择驱动

4. 配置 Doris 连接

在 **Connection Settings** 窗口的 **main** 标签页，配置以下连接信息：

- Server Host: Doris 集群的 FE 主机 IP 地址。
- Port: Doris 集群的 FE 查询端口，如 9030。
- Database: Doris 集群中的目标数据库。
- Username: 用于登录 Doris 集群的用户名，如 admin。
- Password: 用于登录 Doris 集群的用户密码。

Database 可以用于区别 internal catalog 和 external catalog，如仅填写 Database 名称，则当前数据源默认连接 internal catalog，如填写格式为 catalog.db，则当前数据源默认连接 Database 中所填写的 catalog，DBeaver 中展示的库表也为所连接 catalog 中的库表，因此可以使用 DBeaver 的 MySQL 驱动器来创建多个 Doris 数据源来管理 Doris 中不同的 Catalog。

:::info 备注 通过 catalog.db 的 Database 形式来管理连接 Doris 的 external catalog 需要 Doris 版本在 2.1.0 及以上 :::

- internal catalog

Connect to a database

Connection Settings

MySQL connection settings

Main | Driver properties | SSH | SSL | + Network configurations...

Server

Connect by: ☒ Host ☐ URL

URL: jdbc:mysql://127.0.0.1:9030/test

Server Host: 127.0.0.1 Port: 9030

Database: test

Authentication (Database Native)

Username: admin

Password: ☒ Save password

Advanced

Server Time Zone: Auto-detect

[You can use variables in connection parameters.](#) Connection details (name, type, ...)

Driver name: MySQL Driver Settings Driver license

Test Connection ... < Back Next > Cancel Finish

连接 internal catalog

- external catalog

Connect to a database

Connection Settings

MySQL connection settings

Main Driver properties SSH SSL + Network configurations...

Server

Connect by: ☒ Host ☐ URL

URL: jdbc:mysql://127.0.0.1:9030/mysql.test

Server Host: 127.0.0.1 Port: 9030

Database: mysql.test

Authentication (Database Native)

Username: admin

Password: ☒ Save password

Advanced

Server Time Zone: Auto-detect

[You can use variables in connection parameters.](#) Connection details (name, type, ...)


Driver name: MySQL Driver Settings Driver license

Test Connection ... < Back Next > Cancel Finish

连接 external catalog

5. 测试数据源连接


在填写完连接信息后，单击左下角 Test Connection 验证数据库连接信息的准确性。DBeaver 返回如下对话框，确认配置连接信息。单击 OK 即确认配置连接信息无误。然后单击右下角 Finish 完成连接配置。



测试连接

6. 连接数据库

数据库连接建立以后，可以在左侧的数据库连接导航看到已创建的数据源连接，并且可以通过 DBeaver 连接并管理数据库。



建立连接

功能支持

- 完全支持
 - 可视化查看类
 - Databases
 - Tables
 - Views
 - Users
 - Administer
 - Session Manager
 - System Info
 - Session Variables
 - Global Variables
 - Engines
 - Charsets
 - User Privileges
 - Plugin
 - 操作类
 - SQL 编辑器
 - SQL 控制台
- 基本支持

基本支持的部分意为可以点击查看不会报错，但由于存在协议兼容问题，可能存在显示不全

- 可视化查看类
 - 仪表盘

- Users/user/properties
 - Session Status
 - Global Status
- 不支持

不支持部分意为使用 DBeaver 管理 Doris 进行某些可视化操作时可能会报错，或者某些可视化操作未经验证 如可视化创建库表、schema change、增删改数据等

DataGrip

介绍

DataGrip 是 JetBrains 出品的适用于关系数据库和 NoSQL 数据库的强大跨平台数据库工具。

Apache Doris 高度兼容 MySQL 协议，可以使用 DataGrip 的 MySQL 数据源连接 Apache Doris，并查询 internal catalog 和 external catalog 中的数据。

前置条件


已安装 DataGrip 可以访问 www.jetbrains.com/datagrip/ 下载安装 DataGrip

添加数据源

备注

当前验证使用 DataGrip 2023.3.4 版本

1. 启动 DataGrip
2. 在 DataGrip 窗口左上角单击加号 (+) 图标，选择 MySQL 数据源



添加数据源

3. 配置 Doris 连接


在 Data Sources and Drivers 窗口的 General 标签页，配置以下连接信息：

- Host: Doris 集群的 FE 主机 IP 地址。
- Port: Doris 集群的 FE 查询端口，如 9030。
- Database: Doris 集群中的目标数据库。
- User: 用于登录 Doris 集群的用户名，如 admin。
- Password: 用于登录 Doris 集群的用户密码。

Database 可以用于区别 internal catalog 和 external catalog，如仅填写 Database 名称，则当前数据源默认连接 internal catalog，如填写格式为 catalog.db，则当前数据源默认连接 Database 中所填写的 catalog，DataGrip 中展示的库表也为所连接 catalog 中的库表，以此可以使用 DataGrip 的 MySQL 数据源来创建多个 Doris 数据源来管理 Doris 中不同的 Catalog。


:::info 备注 通过 catalog.db 的 Database 形式来管理连接 Doris 的 external catalog 需要 Doris 版本在 2.1.0 及以上 :::

- internal catalog



连接 internal catalog


- external catalog



连接 external catalog

5. 测试数据源连接


在填写完连接信息后，单击左下角 Test Connection 验证数据库连接信息的准确性。DataGrip 返回如下对话框则测试连接成功。然后单击右下角 OK 完成连接配置。



测试连接

6. 连接数据库

数据库连接建立以后，可以在左侧的数据库连接导航看到已创建的数据源连接，并且可以通过 DataGrip 连接并管理数据库。



建立连接

功能支持

基本支持大部分可视化查看操作，以及 SQL 控制台编写 SQL 操作 Doris，不支持或未经验证各种创建库表、schema change、增删改数据操作。

Logstash

Logstash Doris output plugin

介绍

Logstash 是一个日志 ETL 框架（采集，预处理，发送到存储系统），它支持自定义输出插件将数据写入存储系统，Logstash Doris output plugin 是输出到 Doris 的插件。

Logstash Doris output plugin 调用 [Doris Stream Load](#) HTTP 接口将数据实时写入 Doris，提供多线程并发，失败重试，自定义 Stream Load 格式和参数，输出写入速度等能力。

使用 Logstash Doris output plugin 主要有三个步骤： 1. 将插件安装到 Logstash 中 2. 配置 Doris 输出地址和其他参数 3. 启动 Logstash 将数据实时写入 Doris

安装

获取插件

可以从官网下载或者自行从源码编译 Logstash Doris output plugin。

- 从官网下载

```
# 包含依赖的安装包
wget https://apache-doris-releases.oss-cn-beijing.aliyuncs.com/extension/logstash-output-doris-1.2.0-java.gem
```

- 从源码编译

```
cd extension/logstash/

gem build logstash-output-doris.gemspec
```

安装插件

- 普通安装

`${LOGSTASH_HOME}` 是 Logstash 的安装目录，运行它下面的 `bin/logstash-plugin` 命令安装插件

```
${LOGSTASH_HOME}/bin/logstash-plugin install logstash-output-doris-1.2.0.gem

Validating logstash-output-doris-1.2.0.gem
Installing logstash-output-doris
Installation successful
```

普通安装模式会自动安装插件依赖的 ruby 模块，对于网络不通的情况会卡住无法完成，这种情况下可以下载包含依赖的 zip 安装包进行完全离线安装，注意需要用 `file://` 指定本地文件系统。

- 离线安装

```
export JARS_SKIP="true"

${LOGSTASH_HOME}/bin/logstash-plugin install logstash-output-doris-1.2.0.gem
```

参数配置

Logstash Doris output plugin 的配置如下：

配置	说明
http_hosts	Stream Load HTTP 地址，格式是字符串数组，可以有一个或者多个元素，每个元素是 host:port。例如：["http://fe1:8030", "http://fe2:8030"]
user	Doris 用户名，该用户需要有 doris 对应库表的导入权限
password	Doris 用户的密码
db	要写入的 Doris 库名
table	要写入的 Doris 表名
label_prefix	Doris Stream Load Label 前缀，最终生成的 Label 为 <code>{label_prefix}{db}{table}{yyyymmdd_hhmmss}{uuid}</code> ，默认值是 logstash
headers	Doris Stream Load 的 headers 参数，语法格式为 ruby map，例如： <code>headers => { "format" => "json" "read_json_by_line" => "true" }</code>
mapping	Logstash 字段到 Doris 表字段的映射，参考后续章节的使用示例
message_only	一种特殊的 mapping 形式，只将 Logstash 的 @message 字段输出到 Doris，默认为 false
max_retries	Doris Stream Load 请求失败重试次数，默认为 -1 无限重试保证数据可靠性
log_request	日志中是否输出 Doris Stream Load 请求和响应元数据，用于排查问题，默认为 false
log_speed_interval	日志中输出速度的时间间隔，单位是秒，默认为 10，设置为 0 可以关闭这种日志

使用示例

TEXT 日志采集示例

该示例以 Doris FE 的日志为例展示 TEXT 日志采集。

1. 数据

FE 日志文件一般位于 Doris 安装目录下的 fe/log/fe.log 文件，是典型的 Java 程序日志，包括时间戳，日志级别，线程名，代码位置，日志内容等字段。不仅有正常的日志，还有带 stacktrace 的异常日志，stacktrace 是跨行的，日志采集存储需要把主日志和 stacktrace 组合成一条日志。

```

2024-07-08 21:18:01,432 INFO (Statistics Job Appender|61) [StatisticsJobAppender.runAfterCatalogReady():70]
Stats table not available, skip
2024-07-08 21:18:53,710 WARN (STATS_FETCH-0|208) [StmtExecutor.executeInternalQuery():3332] Failed to run
internal SQL: OriginStatement{originStmt='SELECT * FROM __internal_schema.column_statistics WHERE part_id is
NULL ORDER BY update_time DESC LIMIT 500000', idx=0}
org.apache.doris.common.UserException: errCode = 2, detailMessage = tablet 10031 has no queryable replicas.
err: replica 10032's backend 10008 does not exist or not alive
    at org.apache.doris.planner.OlapScanNode.addScanRangeLocations(OlapScanNode.java:931) ~[doris-
fe.jar:1.2-SNAPSHOT]
    at org.apache.doris.planner.OlapScanNode.computeTabletInfo(OlapScanNode.java:1197) ~[doris-
fe.jar:1.2-SNAPSHOT]

```

2. 建表

表结构包括日志的产生时间，采集时间，主机名，日志文件路径，日志类型，日志级别，线程名，代码位置，日志内容等字段。

```

CREATE TABLE `doris_log` (
  `log_time` datetime NULL COMMENT 'log content time',
  `collect_time` datetime NULL COMMENT 'log agent collect time',
  `host` text NULL COMMENT 'hostname or ip',
  `path` text NULL COMMENT 'log file path',
  `type` text NULL COMMENT 'log type',
  `level` text NULL COMMENT 'log level',
  `thread` text NULL COMMENT 'log thread',
  `position` text NULL COMMENT 'log code position',
  `message` text NULL COMMENT 'log message',
  INDEX idx_host (`host`) USING INVERTED COMMENT '',
  INDEX idx_path (`path`) USING INVERTED COMMENT '',
  INDEX idx_type (`type`) USING INVERTED COMMENT '',
  INDEX idx_level (`level`) USING INVERTED COMMENT '',
  INDEX idx_thread (`thread`) USING INVERTED COMMENT '',
  INDEX idx_position (`position`) USING INVERTED COMMENT '',
  INDEX idx_message (`message`) USING INVERTED PROPERTIES("parser" = "unicode", "support_phrase" = "true")
COMMENT ''
) ENGINE=OLAP
DUPLICATE KEY(`log_time`)
COMMENT 'OLAP'
PARTITION BY RANGE(`log_time`) ()
DISTRIBUTED BY RANDOM BUCKETS 10
PROPERTIES (
  "replication_num" = "1",
  "dynamic_partition.enable" = "true",
  "dynamic_partition.time_unit" = "DAY",
  "dynamic_partition.start" = "-7",
  "dynamic_partition.end" = "1",
  "dynamic_partition.prefix" = "p",
  "dynamic_partition.buckets" = "10",
  "dynamic_partition.create_history_partition" = "true",
  "compaction_policy" = "time_series"
);

```

3. Logstash 配置

Logstash 主要有两类配置文件，一类是整个 Logstash 的配置文件，另一类是某个日志采集的配置文件。

整个 Logstash 的配置文件通常在 config/logstash.yml，为了提升写入 Doris 的性能需要修改 batch 大小和攒批时间，对于平均每条几百字节的日志，推荐 100 万行和 10s。

```
pipeline.batch.size: 1000000
pipeline.batch.delay: 10000
```

某个日志采集的配置文件如 `logstash_doris_log.conf` 主要由 3 部分组成，分别对应 ETL 的各个部分：1. input 负责读取原始数据 2. filter 负责做数据转换 3. output 负责将数据输出

1. input 负责读取原始数据

file input 是一个 input plugin，可以配置读取的日志文件路径，通过 multiline codec 将非时间开头的行拼接到上一行后面，实现 stacktrace 和主日志合并的效果。file input 会将日志内容保存在 @message 字段中，另外还有一些元数据字段比如 host，log.file.path，这里我们还通过 add_field 手动添加了一个字段 type，它的值为 fe.log。

```
input {
  file {
    path => "/mnt/disk2/xiaokang/opt/doris_master/fe/log/fe.log"
    add_field => {"type" => "fe.log"}
    codec => multiline {
      # valid line starts with timestamp
      pattern => "^{TIMESTAMP_ISO8601} "
      # any line not starting with a timestamp should be merged with the previous line
      negate => true
      what => "previous"
    }
  }
}
```

2. filter 部分负责数据转换

grok 是一个常用的数据转换插件，它内置了一些常见的pattern 比如 TIMESTAMP_ISO8601 解析时间戳，还支持写正则表达式提取字段。

```
filter {
  grok {
    match => {
      # parse log_time, level, thread, position fields from message
      "message" => "%{TIMESTAMP_ISO8601:log_time} (?<level>[A-Z]+) \((?<thread>[^\[]*)\) \[(?<position>[^\]]*)\]"
    }
  }
}
```

3. output 部分负责数据输出

doris output 将数据输出到 Doris，使用的是 Stream Load HTTP 接口。通过 headers 参数指定了 Stream Load 的数据格式为 JSON，通过 mapping 参数指定 Logstash 字段到 JSON 字段的映射。由于 headers 指定了 "format" => "json"，Stream Load 会自动解析 JSON 字段写入对应的 Doris 表的字段。

```
output {
  doris {
    http_hosts => ["http://localhost:8630"]
    user => "root"
    password => ""
    db => "log_db"
    table => "doris_log"
    headers => {
      "format" => "json"
      "read_json_by_line" => "true"
      "load_to_single_tablet" => "true"
    }
    mapping => {
      "log_time" => "%{log_time}"
      "collect_time" => "%{@timestamp}"
      "host" => "%{[host][name]}"
      "path" => "%{[log][file][path]}"
      "type" => "%{type}"
      "level" => "%{level}"
      "thread" => "%{thread}"
      "position" => "%{position}"
    }
  }
}
```

```

        "message" => "%{message}"
    }
    log_request => true
}
}

```

4. 运行 Logstash

```

${LOGSTASH_HOME}/bin/logstash -f config/logstash_doris_log.conf

# log_request 为 true 时日志会输出每次 Stream Load 的请求参数和响应结果

[2024-07-08T22:35:34,772][INFO ][logstash.outputs.doris ][main]
[e44d2a24f17d764647ce56f5fed24b9bbf08d3020c7fddcc3298800daface80a] doris stream load response:
{
  "TxnId": 45464,
  "Label": "logstash_log_db_doris_log_20240708_223532_539_6c20a0d1-dcab-4b8e-9bc0-76b46a929bd1",
  "Comment": "",
  "TwoPhaseCommit": "false",
  "Status": "Success",
  "Message": "OK",
  "NumberTotalRows": 452,
  "NumberLoadedRows": 452,
  "NumberFilteredRows": 0,
  "NumberUnselectedRows": 0,
  "LoadBytes": 277230,
  "LoadTimeMs": 1797,
  "BeginTxnTimeMs": 0,
  "StreamLoadPutTimeMs": 18,
  "ReadDataTimeMs": 9,
  "WriteDataTimeMs": 1758,
  "CommitAndPublishTimeMs": 18
}

# 默认每隔 10s 会日志输出速度信息, 包括自启动以来的数据量 (MB 和 ROWS), 总速度 (MB/s 和 R/S), 最近 10s 速度
[2024-07-08T22:35:38,285][INFO ][logstash.outputs.doris ][main] total 11 MB 18978 ROWS, total speed 0 MB/s
632 R/s, last 10 seconds speed 1 MB/s 1897 R/s

```

JSON 日志采集示例

该样例以 github events archive 的数据为例展示 JSON 日志采集。

1. 数据

github events archive 是 github 用户操作事件的归档数据, 格式是 JSON, 可以从 <https://www.gharchive.org/> 下载, 比如下载 2024 年 1 月 1 日 15 点的数据。

```
wget https://data.gharchive.org/2024-01-01-15.json.gz
```

下面是一条数据样例, 实际一条数据一行, 这里为了方便展示进行了格式化。

```

{
  "id": "37066529221",
  "type": "PushEvent",
  "actor": {
    "id": 46139131,
    "login": "Bard89",

```



```

    "display_login": "Bard89",
    "gravatar_id": "",
    "url": "https://api.github.com/users/Bard89",
    "avatar_url": "https://avatars.githubusercontent.com/u/46139131?"
  },
  "repo": {
    "id": 780125623,
    "name": "Bard89/talk-to-me",
    "url": "https://api.github.com/repos/Bard89/talk-to-me"
  },
  "payload": {
    "repository_id": 780125623,
    "push_id": 17799451992,
    "size": 1,
    "distinct_size": 1,
    "ref": "refs/heads/add_mvcs",
    "head": "f03baa2de66f88f5f1754ce3fa30972667f87e81",
    "before": "85e6544ede4ae3f132fe2f5f1ce0ce35a3169d21"
  },
  "public": true,
  "created_at": "2024-04-01T23:00:00Z"
}

```

2. Doris 建表

```

CREATE DATABASE log_db;
USE log_db;

CREATE TABLE github_events
(
  `created_at` DATETIME,
  `id` BIGINT,
  `type` TEXT,
  `public` BOOLEAN,
  `actor.id` BIGINT,
  `actor.login` TEXT,
  `actor.display_login` TEXT,
  `actor.gravatar_id` TEXT,
  `actor.url` TEXT,
  `actor.avatar_url` TEXT,
  `repo.id` BIGINT,
  `repo.name` TEXT,
  `repo.url` TEXT,
  `payload` TEXT,
  `host` TEXT,
  `path` TEXT,
  INDEX `idx_id` (`id`) USING INVERTED,
  INDEX `idx_type` (`type`) USING INVERTED,
  INDEX `idx_actor.id` (`actor.id`) USING INVERTED,
  INDEX `idx_actor.login` (`actor.login`) USING INVERTED,
  INDEX `idx_repo.id` (`repo.id`) USING INVERTED,
  INDEX `idx_repo.name` (`repo.name`) USING INVERTED,
  INDEX `idx_host` (`host`) USING INVERTED,
  INDEX `idx_path` (`path`) USING INVERTED,
  INDEX `idx_payload` (`payload`) USING INVERTED PROPERTIES("parser" = "unicode", "support_phrase" = "true")
)
ENGINE = OLAP
DUPLICATE KEY(`created_at`)
PARTITION BY RANGE(`created_at`) ( )
DISTRIBUTED BY RANDOM BUCKETS 10
PROPERTIES (
  "replication_num" = "1",

```

```

"compaction_policy" = "time_series",
"enable_single_replica_compaction" = "true",
"dynamic_partition.enable" = "true",
"dynamic_partition.create_history_partition" = "true",
"dynamic_partition.time_unit" = "DAY",
"dynamic_partition.start" = "-30",
"dynamic_partition.end" = "1",
"dynamic_partition.prefix" = "p",
"dynamic_partition.buckets" = "10",
"dynamic_partition.replication_num" = "1"
);

```

3. Logstash 配置

这个配置文件和之前 TEXT 日志采集不同的有下面几点：

1. file input 的 codec 参数是 json，Logstash 会将每一行文本当作 JSON 格式解析，解析出来的字段用于后续处理
2. 没有用 filter plugin，因为不需要额外的处理转换

```

input {
  file {
    path => "/tmp/github_events/2024-04-01-23.json"
    codec => json
  }
}

output {
  doris {
    http_hosts => ["http://fe1:8630", "http://fe2:8630", "http://fe3:8630"]
    user => "root"
    password => ""
    db => "log_db"
    table => "github_events"
    headers => {
      "format" => "json"
      "read_json_by_line" => "true"
      "load_to_single_tablet" => "true"
    }
    mapping => {
      "created_at" => "%{created_at}"
      "id" => "%{id}"
      "type" => "%{type}"
      "public" => "%{public}"
      "actor.id" => "%{[actor][id]}"
      "actor.login" => "%{[actor][login]}"
      "actor.display_login" => "%{[actor][display_login]}"
      "actor.gravatar_id" => "%{[actor][gravatar_id]}"
      "actor.url" => "%{[actor][url]}"
      "actor.avatar_url" => "%{[actor][avatar_url]}"
      "repo.id" => "%{[repo][id]}"
      "repo.name" => "%{[repo][name]}"
      "repo.url" => "%{[repo][url]}"
      "payload" => "%{[payload]}"
      "host" => "%{[host][name]}"
      "path" => "%{[log][file][path]}"
    }
    log_request => true
  }
}

```

4. 运行 Logstash

```
${LOGSTASH_HOME}/bin/logstash -f logstash_github_events.conf
```

Filebeat

Beats Doris output plugin

[Beats](#) 是一个数据采集 Agent，它支持自定义输出插件将数据写入存储系统，Beats Doris output plugin 是输出到 Doris 的插件。

Beats Doris output plugin 支持 [Filebeat](#), [Metricbeat](#), [Packetbeat](#), [Winlogbeat](#), [Auditbeat](#), [Heartbeat](#) 。

Beats Doris output plugin 调用 [Doris Stream Load](#) HTTP 接口将数据实时写入 Doris，提供多线程并发，失败重试，自定义 Stream Load 格式和参数，输出写入速度等能力。

使用 Beats Doris output plugin 主要有三个步骤：1. 下载或编译包含 Doris output plugin 的 Beats 二进制程序 2. 配置 Beats 输出地址和其他参数 3. 启动 Beats 将数据实时写入 Doris

安装

从官网下载

<https://download.velodb.io/extension/filebeat-doris-2.1.1>

从源码编译

在 extension/beats/ 目录下执行

```
cd doris/extension/beats

go build -o filebeat-doris filebeat/filebeat.go
go build -o metricbeat-doris metricbeat/metricbeat.go
go build -o winlogbeat-doris winlogbeat/winlogbeat.go
go build -o packetbeat-doris packetbeat/packetbeat.go
go build -o auditbeat-doris auditbeat/auditbeat.go
go build -o heartbeat-doris heartbeat/heartbeat.go
```

参数配置

Beats Doris output plugin 的配置如下：

配置	说明
http_hosts	Stream Load HTTP 地址，格式是字符串数组，可以有一个或者多个元素，每个元素是 host:port。例如：["http://fe1:8030", "http://fe2:8030"]
user	Doris 用户名，该用户需要有 doris 对应库表的导入权限
password	Doris 用户的密码
database	要写入的 Doris 库名

配置	说明
table	要写入的 Doris 表名
label_prefix	Doris Stream Load Label 前缀，最终生成的 Label 为 <code>{label_prefix}{db}{table}{yyyymmdd_hhmmss}{uuid}</code> ，默认值是 beats
headers	Doris Stream Load 的 headers 参数，语法格式为 YAML map
codec_format_string	输出到 Doris Stream Load 的 format string， <code>%[a][b]</code> 代表输入中的 a.b 字段，参考后续章节的使用示例
bulk_max_size	Doris Stream Load 的 batch size，默认为 100000
max_retries	Doris Stream Load 请求失败重试次数，默认为 -1 无限重试保证数据可靠性
log_request	日志中是否输出 Doris Stream Load 请求和响应元数据，用于排查问题，默认为 true
log_progress_interval	日志中输出速度的时间间隔，单位是秒，默认为 10，设置为 0 可以关闭这种日志

使用示例

TEXT 日志采集示例

该示例以 Doris FE 的日志为例展示 TEXT 日志采集。

1. 数据

FE 日志文件一般位于 Doris 安装目录下的 `fe/log/fe.log` 文件，是典型的 Java 程序日志，包括时间戳，日志级别，线程名，代码位置，日志内容等字段。不仅有正常的日志，还有带 `stacktrace` 的异常日志，`stacktrace` 是跨行的，日志采集存储需要把主日志和 `stacktrace` 组合成一条日志。

```
2024-07-08 21:18:01,432 INFO (Statistics Job Appender|61) [StatisticsJobAppender.runAfterCatalogReady():70]
Stats table not available, skip
2024-07-08 21:18:53,710 WARN (STATS_FETCH-0|208) [StmtExecutor.executeInternalQuery():3332] Failed to run
internal SQL: OriginStatement{originStmt='SELECT * FROM __internal_schema.column_statistics WHERE part_id is
NULL ORDER BY update_time DESC LIMIT 500000', idx=0}
org.apache.doris.common.UserException: errCode = 2, detailMessage = tablet 10031 has no queryable replicas.
err: replica 10032's backend 10008 does not exist or not alive
    at org.apache.doris.planner.OlapScanNode.addScanRangeLocations(OlapScanNode.java:931) ~[doris-
fe.jar:1.2-SNAPSHOT]
    at org.apache.doris.planner.OlapScanNode.computeTabletInfo(OlapScanNode.java:1197) ~[doris-
fe.jar:1.2-SNAPSHOT]
```

2. 建表

表结构包括日志的产生时间，采集时间，主机名，日志文件路径，日志类型，日志级别，线程名，代码位置，日志内容等字段。

```
CREATE TABLE `doris_log` (
  `log_time` datetime NULL COMMENT 'log content time',
  `collect_time` datetime NULL COMMENT 'log agent collect time',
  `host` text NULL COMMENT 'hostname or ip',
  `path` text NULL COMMENT 'log file path',
  `type` text NULL COMMENT 'log type',
```

```

`level` text NULL COMMENT 'log level',
`thread` text NULL COMMENT 'log thread',
`position` text NULL COMMENT 'log code position',
`message` text NULL COMMENT 'log message',
INDEX idx_host (`host`) USING INVERTED COMMENT '',
INDEX idx_path (`path`) USING INVERTED COMMENT '',
INDEX idx_type (`type`) USING INVERTED COMMENT '',
INDEX idx_level (`level`) USING INVERTED COMMENT '',
INDEX idx_thread (`thread`) USING INVERTED COMMENT '',
INDEX idx_position (`position`) USING INVERTED COMMENT '',
INDEX idx_message (`message`) USING INVERTED PROPERTIES("parser" = "unicode", "support_phrase" = "true")
COMMENT ''
) ENGINE=OLAP
DUPLICATE KEY(`log_time`)
COMMENT 'OLAP'
PARTITION BY RANGE(`log_time`) ()
DISTRIBUTED BY RANDOM BUCKETS 10
PROPERTIES (
"replication_num" = "1",
"dynamic_partition.enable" = "true",
"dynamic_partition.time_unit" = "DAY",
"dynamic_partition.start" = "-7",
"dynamic_partition.end" = "1",
"dynamic_partition.prefix" = "p",
"dynamic_partition.buckets" = "10",
"dynamic_partition.create_history_partition" = "true",
"compaction_policy" = "time_series"
);

```

3. 配置

filebeat 日志采集的配置文件如 filebeat_doris_log.yml 是 YAML 格式，主要由 4 部分组成，分别对应 ETL 的各个部分：1. input 负责读取原始数据 2. processor 负责做数据转换 3. queue.mem 配置 filebeat 内部的缓冲队列 4. output 负责将数据输出

```

# 1. input 负责读取原始数据
# type: log 是一个 log input plugin, 可以配置读取的日志文件路径, 通过 multiline 功能将非时间开头的行拼接到上一行后面, 实现
# stacktrace 和主日志合并的效果。log input 会将日志内容保存在 message 字段中, 另外还有一些元数据字段比如 agent.host,
# log.file.path。
filebeat.inputs:
- type: log
  enabled: true
  paths:
    - /path/to/your/log
  # multiline 可以将跨行的日志 (比如Java stacktrace) 拼接起来
  multiline:
    type: pattern
    # 效果: 以 yyyy-mm-dd HH:MM:SS 开头的行认为是一条新的日志, 其他都拼接到上一条日志
    pattern: '^[0-9]{4}-[0-9]{2}-[0-9]{2} [0-9]{2}:[0-9]{2}:[0-9]{2}'
    negate: true
    match: after
    skip_newline: true

# 2. processors 部分负责数据转换
processors:
# 用 js script 插件将日志中的 \t 替换成空格, 避免JSON解析报错
- script:
    lang: javascript
    source: >
      function process(event) {
        var msg = event.Get("message");
        msg = msg.replace(/\t/g, " ");

```

```

        event.Put("message", msg);
    }
# 用 dissect 插件做简单的日志解析
- dissect:
    # 2024-06-08 18:26:25,481 INFO (report-thread|199) [ReportHandler.cpuReport():617] begin to handle
    tokenizer: "%{day} %{time} %{log_level} (%{thread}) [%{position}] %{content}"
    target_prefix: ""
    ignore_failure: true
    overwrite_keys: true

# 3. 内部的缓冲队列总条数, flush batch 条数, flush 时间间隔
queue.mem:
    events: 1000000
    flush.min_events: 100000
    flush.timeout: 10s

# 4. output 部分负责数据输出
# doris output 将数据输出到 Doris, 使用的是 Stream Load HTTP 接口。通过 headers 参数指定了 Stream Load 的数据格式为
JSON, 通过 codec_format_string 参数用类似 printf 的方式格式化输出到 Doris 的数据。比如下面的例子基于 filebeat 内部的字段
format 出一个 JSON, 这些字段可以是 filebeat 内置字段如 agent.hostname, 也可以是 processor 比如 dissect 生产的字段如
day, 通过 %{[a][b]} 的方式引用, Stream Load 会自动将 JSON 字段写入对应的 Doris 表的字段。
output.doris:
    fenodes: [ "http://fehost1:http_port", "http://fehost2:http_port", "http://fehost3:http_port" ]
    user: "your_username"
    password: "your_password"
    database: "your_db"
    table: "your_table"
    # output string format
    ## %{[agent][hostname]} %{[log][file][path]} 是filebeat自带的metadata
    ## 常用的 filebeat metadata 还是有采集时间戳 %{[@timestamp]}
    ## %{[day]} %{[time]} 是上面 dissect 解析得到字段
    codec_format_string: '{"ts": "%{[day]} %{[time]}", "host": "%{[agent][hostname]}", "path": "%{[log][file]
[path]}"', "message": "%{[message]}"}'
    headers:
        format: "json"
        read_json_by_line: "true"
        load_to_single_tablet: "true"

```

4. 运行 Filebeat

```

./filebeat-doris -f config/filebeat_doris_log.yml

# log_request 为 true 时日志会输出每次 Stream Load 的请求参数和响应结果

doris stream load response:
{
    "TxnId": 45464,
    "Label": "logstash_log_db_doris_log_20240708_223532_539_6c20a0d1-dcab-4b8e-9bc0-76b46a929bd1",
    "Comment": "",
    "TwoPhaseCommit": "false",
    "Status": "Success",
    "Message": "OK",
    "NumberTotalRows": 452,
    "NumberLoadedRows": 452,
    "NumberFilteredRows": 0,
    "NumberUnselectedRows": 0,
    "LoadBytes": 277230,
    "LoadTimeMs": 1797,
    "BeginTxnTimeMs": 0,
    "StreamLoadPutTimeMs": 18,
    "ReadDataTimeMs": 9,
    "WriteDataTimeMs": 1758,

```

```
"CommitAndPublishTimeMs": 18
}

# 默认每隔 10s 会日志输出速度信息, 包括自启动以来的数据量 (MB 和 ROWS), 总速度 (MB/s 和 R/S), 最近 10s 速度
total 11 MB 18978 ROWS, total speed 0 MB/s 632 R/s, last 10 seconds speed 1 MB/s 1897 R/s
```

JSON 日志采集示例

该样例以 github events archive 的数据为例展示 JSON 日志采集。

1. 数据

github events archive 是 github 用户操作事件的归档数据, 格式是 JSON, 可以从 <https://www.gharchive.org/> 下载, 比如下载 2024 年 1 月 1 日 15 点的数据。

```
wget https://data.gharchive.org/2024-01-01-15.json.gz
```

下面是一条数据样例, 实际一条数据一行, 这里为了方便展示进行了格式化。

```
{
  "id": "37066529221",
  "type": "PushEvent",
  "actor": {
    "id": 46139131,
    "login": "Bard89",
    "display_login": "Bard89",
    "gravatar_id": "",
    "url": "https://api.github.com/users/Bard89",
    "avatar_url": "https://avatars.githubusercontent.com/u/46139131?"
  },
  "repo": {
    "id": 780125623,
    "name": "Bard89/talk-to-me",
    "url": "https://api.github.com/repos/Bard89/talk-to-me"
  },
  "payload": {
    "repository_id": 780125623,
    "push_id": 17799451992,
    "size": 1,
    "distinct_size": 1,
    "ref": "refs/heads/add_mvcs",
    "head": "f03baa2de66f88f5f1754ce3fa30972667f87e81",
    "before": "85e6544ede4ae3f132fe2f5f1ce0ce35a3169d21"
  },
  "public": true,
  "created_at": "2024-04-01T23:00:00Z"
}
```

2. Doris 建表

```
CREATE DATABASE log_db;
USE log_db;

CREATE TABLE github_events
(
  `created_at` DATETIME,
  `id` BIGINT,
```



```

`type` TEXT,
`public` BOOLEAN,
`actor` VARIANT,
`repo` VARIANT,
`payload` TEXT,
INDEX `idx_id` (`id`) USING INVERTED,
INDEX `idx_type` (`type`) USING INVERTED,
INDEX `idx_actor` (`actor`) USING INVERTED,
INDEX `idx_host` (`repo`) USING INVERTED,
INDEX `idx_payload` (`payload`) USING INVERTED PROPERTIES("parser" = "unicode", "support_phrase" = "true")
)
ENGINE = OLAP
DUPLICATE KEY(`created_at`)
PARTITION BY RANGE(`created_at`) ()
DISTRIBUTED BY RANDOM BUCKETS 10
PROPERTIES (
"replication_num" = "1",
"compaction_policy" = "time_series",
"enable_single_replica_compaction" = "true",
"dynamic_partition.enable" = "true",
"dynamic_partition.create_history_partition" = "true",
"dynamic_partition.time_unit" = "DAY",
"dynamic_partition.start" = "-30",
"dynamic_partition.end" = "1",
"dynamic_partition.prefix" = "p",
"dynamic_partition.buckets" = "10",
"dynamic_partition.replication_num" = "1"
);

```

3. Filebeat 配置

这个配置文件和之前 TEXT 日志采集不同的有下面几点：

1. 没有用 processors，因为不需要额外的处理转换
2. output 中的 codec_format_string 很简单，直接输出整个 message，也就是原始内容

```

# input
filebeat.inputs:
- type: log
  enabled: true
  paths:
    - /path/to/your/log

# queue and batch
queue.mem:
  events: 1000000
  flush.min_events: 100000
  flush.timeout: 10s

# output
output.doris:
  fenodes: [ "http://fehost1:http_port", "http://fehost2:http_port", "http://fehost3:http_port" ]
  user: "your_username"
  password: "your_password"
  database: "your_db"
  table: "your_table"
# output string format
## 直接把原始文件每一行的 message 原样输出，由于 headers 指定了 format: "json", Stream Load 会自动解析 JSON 字段写入对
应的 Doris 表的字段。
codec_format_string: '%{[message]}'
headers:
  format: "json"

```

```
read_json_by_line: "true"  
load_to_single_tablet: "true"
```

4. 运行 Filebeat

```
./filebeat-doris -f config/filebeat_github_events.yml
```

FluentBit

Fluent Bit 是一个快速的日志处理器和转发器，它支持自定义输出插件将数据写入存储系统，Fluent Bit Doris Output Plugin 是输出到 Doris 的插件。

Fluent Bit Doris Output Plugin 调用 Doris Stream Load HTTP 接口将数据实时写入 Doris，提供多线程并发，失败重试，自定义 Stream Load 格式和参数，输出写入速度等能力。

使用 Fluent Bit Doris Output Plugin 主要有三个步骤：1. 下载或编译包含 Doris Output Plugin 的 Fluent Bit 二进制程序 2. 配置 Fluent Bit 输出地址和其他参数 3. 启动 Fluent Bit 将数据实时写入 Doris

安装（alpha 版本）

从官网下载

<https://download.velodb.io/integrations/fluent-bit-doris-3.1.9>

从源码编译

克隆 <https://github.com/joker-star-l/fluent-bit> 的 dev 分支，在 build/ 目录下执行

```
cmake -DFLB_RELEASE=ON ..
make
```

编译产物为 build/bin/fluent-bit。

参数配置

Fluent Bit Doris output plugin 的配置如下：

配置	说明
host	Stream Load HTTP host
port	Stream Load HTTP port
user	Doris 用户名，该用户需要有 doris 对应库表的导入权限
password	Doris 用户的密码
database	要写入的 Doris 库名
table	要写入的 Doris 表名
label_prefix	Doris Stream Load Label 前缀，最终生成的 Label 为 {label_prefix}_{timestamp}_{uuid}，默认值是 fluentbit，如果设置为 false 则不会添加 Label
time_key	数据中要添加的时间戳列的名称，默认值是 date，如果设置为 false 则不会添加该列
header	Doris Stream Load 的 header 参数，可以设置多个

配置	说明
log_request	日志中是否输出 Doris Stream Load 请求和响应元数据，用于排查问题，默认为 true
log_progress_interval	日志中输出速度的时间间隔，单位是秒，默认为 10，设置为 0 可以关闭这种日志
retry_limit	Doris Stream Load 请求失败重试次数，默认为 1，如果设置为 false 则不限制重试次数
workers	执行 Doris Stream Load 的 worker 数量，默认为 2

使用示例

TEXT 日志采集示例

该示例以 Doris FE 的日志为例展示 TEXT 日志采集。

1. 数据

FE 日志文件一般位于 Doris 安装目录下的 fe/log/fe.log 文件，是典型的 Java 程序日志，包括时间戳，日志级别，线程名，代码位置，日志内容等字段。不仅有正常的日志，还有带 stacktrace 的异常日志，stacktrace 是跨行的，日志采集存储需要把主日志和 stacktrace 组合成一条日志。

```
2024-07-08 21:18:01,432 INFO (Statistics Job Appender|61) [StatisticsJobAppender.runAfterCatalogReady():70]
Stats table not available, skip
2024-07-08 21:18:53,710 WARN (STATS_FETCH-0|208) [StmtExecutor.executeInternalQuery():3332] Failed to run
internal SQL: OriginStatement{originStmt='SELECT * FROM __internal_schema.column_statistics WHERE part_id is
NULL ORDER BY update_time DESC LIMIT 500000', idx=0}
org.apache.doris.common.UserException: errCode = 2, detailMessage = tablet 10031 has no queryable replicas.
err: replica 10032's backend 10008 does not exist or not alive
    at org.apache.doris.planner.OlapScanNode.addScanRangeLocations(OlapScanNode.java:931) ~[doris-
fe.jar:1.2-SNAPSHOT]
    at org.apache.doris.planner.OlapScanNode.computeTabletInfo(OlapScanNode.java:1197) ~[doris-
fe.jar:1.2-SNAPSHOT]
```

2. 建表

表结构包括日志的产生时间，采集时间，主机名，日志文件路径，日志类型，日志级别，线程名，代码位置，日志内容等字段。

```
CREATE TABLE `doris_log` (
  `log_time` datetime NULL COMMENT 'log content time',
  `collect_time` datetime NULL COMMENT 'log agent collect time',
  `host` text NULL COMMENT 'hostname or ip',
  `path` text NULL COMMENT 'log file path',
  `type` text NULL COMMENT 'log type',
  `level` text NULL COMMENT 'log level',
  `thread` text NULL COMMENT 'log thread',
  `position` text NULL COMMENT 'log code position',
  `message` text NULL COMMENT 'log message',
  INDEX idx_host (`host`) USING INVERTED COMMENT '',
  INDEX idx_path (`path`) USING INVERTED COMMENT '',
  INDEX idx_type (`type`) USING INVERTED COMMENT '',
  INDEX idx_level (`level`) USING INVERTED COMMENT '',
  INDEX idx_thread (`thread`) USING INVERTED COMMENT '',
  INDEX idx_position (`position`) USING INVERTED COMMENT '',
```

```

    INDEX idx_message (`message`) USING INVERTED PROPERTIES("parser" = "unicode", "support_phrase" = "true")
COMMENT ''
) ENGINE=OLAP
DUPLICATE KEY(`log_time`)
COMMENT 'OLAP'
PARTITION BY RANGE(`log_time`) ()
DISTRIBUTED BY RANDOM BUCKETS 10
PROPERTIES (
"replication_num" = "1",
"dynamic_partition.enable" = "true",
"dynamic_partition.time_unit" = "DAY",
"dynamic_partition.start" = "-7",
"dynamic_partition.end" = "1",
"dynamic_partition.prefix" = "p",
"dynamic_partition.buckets" = "10",
"dynamic_partition.create_history_partition" = "true",
"compaction_policy" = "time_series"
);

```

3. 配置

Fluent Bit 日志采集的配置文件如下，`doris_log.conf` 用于定义 ETL 的各个部分组件，`parsers.conf` 用于定义不同的日志解析器。

`doris_log.conf`:

```

# config for Fluent Bit service
[SERVICE]
    log_level info
    # parsers file
    parsers_file parsers.conf

# use input tail
[INPUT]
    name tail
    path /path/to/your/log
    # add log file name to the record, key is 'path'
    path_key path
    # set multiline parser
    multiline.parser multiline_java

# parse log
[FILTER]
    match *
    name parser
    key_name log
    parser fe_log
    reserve_data true

# add host info
[FILTER]
    name sysinfo
    match *
    # add hostname to the record, key is 'host'
    hostname_key host

# output to doris
[OUTPUT]
    name doris
    match *
    host fehost
    port feport

```

```

user your_username
password your_password
database your_db
table your_table
# add 'collect_time' to the record
time_key collect_time
# 'collect_time' is timestamp, change it to datetime
header columns collect_time=from_unixtime(collect_time)
log_request true
log_progress_interval 10

```

parsers.conf:

```

[MULTILINE_PARSER]
name      multiline_java
type      regex
flush_timeout 1000
# Regex rules for multiline parsing
# -----
#
# configuration hints:
#
# - first state always has the name: start_state
# - every field in the rule must be inside double quotes
#
# rules | state name | regex pattern | next state name
# -----|-----|-----|-----
rule    "start_state"  "/(^([0-9]{4}-[0-9]{2}-[0-9]{2}) [0-9]{2}: [0-9]{2}: [0-9]{2})(.*)/" "cont"
rule    "cont"         "/(^(?!([0-9]{4}-[0-9]{2}-[0-9]{2})))(.*)/" "cont"

[PARSER]
name      fe_log
format    regex
# parse and add 'log_time', 'level', 'thread', 'position', 'message' to the record
regex     ^(?<log_time>[0-9]{4}-[0-9]{2}-[0-9]{2} [0-9]{2}: [0-9]{2}: [0-9]{2}, [0-9]{3}) (?<level>[^\s]+)
          \((?<thread>[^\s]+)\) \((?<position>[^\s]+)\) (?<message>(\n|.)*)\n$

```

4. 运行 Fluent Bit

```

fluent-bit -c doris_log.conf

# log stream load response

[2024/10/31 18:39:55] [ info] [output:doris:doris.1] 127.0.0.1:8040, HTTP status=200
{
  "TxnId": 32155,
  "Label": "fluentbit_1730371195_91cca1aa-c15f-45d2-b503-fe7d2e839c2a",
  "Comment": "",
  "TwoPhaseCommit": "false",
  "Status": "Success",
  "Message": "OK",
  "NumberTotalRows": 1,
  "NumberLoadedRows": 1,
  "NumberFilteredRows": 0,
  "NumberUnselectedRows": 0,
  "LoadBytes": 836,
  "LoadTimeMs": 298,
  "BeginTxnTimeMs": 0,
  "StreamLoadPutTimeMs": 3,
  "ReadDataTimeMs": 0,
  "WriteDataTimeMs": 268,

```

```
"CommitAndPublishTimeMs": 25
}

# log speed info

[2024/10/31 18:40:13] [ info] [output:doris:doris.1] total 0 MB 2 ROWS, total speed 0 MB/s 0 R/s, last 10
seconds speed 0 MB/s 0 R/s
```

JSON 日志采集示例

该样例以 github events archive 的数据为例展示 JSON 日志采集。

1. 数据

github events archive 是 github 用户操作事件的归档数据，格式是 JSON，可以从 <https://www.gharchive.org/> 下载，比如下载 2024 年 1 月 1 日 15 点的数据。

```
wget https://data.gharchive.org/2024-01-01-15.json.gz
```

下面是一条数据样例，实际一条数据一行，这里为了方便展示进行了格式化。

```
{
  "id": "37066529221",
  "type": "PushEvent",
  "actor": {
    "id": 46139131,
    "login": "Bard89",
    "display_login": "Bard89",
    "gravatar_id": "",
    "url": "https://api.github.com/users/Bard89",
    "avatar_url": "https://avatars.githubusercontent.com/u/46139131?"
  },
  "repo": {
    "id": 780125623,
    "name": "Bard89/talk-to-me",
    "url": "https://api.github.com/repos/Bard89/talk-to-me"
  },
  "payload": {
    "repository_id": 780125623,
    "push_id": 17799451992,
    "size": 1,
    "distinct_size": 1,
    "ref": "refs/heads/add_mvcs",
    "head": "f03baa2de66f88f5f1754ce3fa30972667f87e81",
    "before": "85e6544ede4ae3f132fe2f5f1ce0ce35a3169d21"
  },
  "public": true,
  "created_at": "2024-04-01T23:00:00Z"
}
```

2. 建表

```
CREATE TABLE github_events
(
  `created_at` DATETIME,
  `id` BIGINT,
  `type` TEXT,
  `public` BOOLEAN,
```

```

`actor` VARIANT,
`repo` VARIANT,
`payload` TEXT,
INDEX `idx_id` (`id`) USING INVERTED,
INDEX `idx_type` (`type`) USING INVERTED,
INDEX `idx_actor` (`actor`) USING INVERTED,
INDEX `idx_host` (`repo`) USING INVERTED,
INDEX `idx_payload` (`payload`) USING INVERTED PROPERTIES("parser" = "unicode", "support_phrase" = "true")
)
ENGINE = OLAP
DUPLICATE KEY(`created_at`)
PARTITION BY RANGE(`created_at`) ()
DISTRIBUTED BY RANDOM BUCKETS 10
PROPERTIES (
"replication_num" = "1",
"compaction_policy" = "time_series",
"enable_single_replica_compaction" = "true",
"dynamic_partition.enable" = "true",
"dynamic_partition.create_history_partition" = "true",
"dynamic_partition.time_unit" = "DAY",
"dynamic_partition.start" = "-30",
"dynamic_partition.end" = "1",
"dynamic_partition.prefix" = "p",
"dynamic_partition.buckets" = "10",
"dynamic_partition.replication_num" = "1"
);

```

3. 配置

和之前 TEXT 日志采集相比，该配置文件没有使用 FILTER，因为不需要额外的处理转换。

github_events.conf:

```

[SERVICE]
    log_level info
    parsers_file github_parsers.conf

[INPUT]
    name tail
    parser github
    path /path/to/your/log

[OUTPUT]
    name doris
    match *
    host fehost
    port feport
    user your_username
    password your_password
    database your_db
    table your_table
    time_key false
    log_request true
    log_progress_interval 10

```

github_parsers.conf:

```

[PARSER]
    name github
    format json

```


4. 运行 Fluent Bit

```
fluent-bit -c github_events.conf
```

CloudCanal

CloudCanal 是一款全自研、可视化、自动化的数据迁移、同步工具，支持 30+ 款流行关系型数据库、实时数仓、消息中间件、缓存数据库和搜索引擎之间的数据互通，具备实时高效、精确互联、稳定可拓展、一站式、混合部署、复杂数据转换等优点。

功能说明

CloudCanal 提供可视化的界面，可轻松实现数据的结构迁移、全量迁移、增量同步、校验与订正等，此外还可以通过设置参数，完成更多精细化、自定义的数据同步配置。目前支持从以下数据源集成数据到 Doris。

源端数据源	结构迁移	全量迁移	增量同步	校验订正
MySQL/MariaDB/AuroraMySQL	支持	支持	支持	支持
Oracle	支持	支持	支持	支持
PostgreSQL/AuroraPostgreSQL	支持	支持	支持	支持
SQL Server	支持	支持	支持	支持
Kafka	不支持	不支持	支持	不支持
AutoMQ	不支持	不支持	支持	不支持
TiDB	支持	支持	支持	支持
Hana	支持	支持	支持	支持
PolarDB-X	支持	支持	支持	支持

更多功能及参数设置，请参考 [CloudCanal 数据链路说明](#)。

下载安装

请参考 [全新安装\(Docker Linux/macOS\)](#)，前往 [CloudCanal 官网](#) 下载安装私有部署版本。


使用示例

以下以 MySQL 为例，演示如何实现 MySQL 到 Doris 的数据迁移同步。


添加数据源

1. 登录 CloudCanal 控制台，点击 **数据源管理 > 新增数据源**。

2. 分别选择 MySQL 和 Doris 数据源，并填写相应信息。




3. 点击 测试连接，连接成功后，点击 新增数据源，完成数据源添加。



创建任务

1. 点击 同步任务 > 创建任务。

2. 选择源和目标数据源，并分别点击 测试连接。



3. 选择 数据同步 并勾选 全量初始化。

CloudCanal 同步任务 同步设置 数据源管理 系统设置 v4.4.1.0 社区版 100% 中文 帮助

同步任务 / 创建任务

源A目标设置 功能配置 表&action过滤 数据处理 创建确认

* 任务类型 全量注册 增量同步 校验与订正 结构迁移

☒ 全量初始化

* 任务规格 增量增强型 全量增强型 平衡型

	全量	增量	校验	描述
☐	1G	1G	1G	1 KB/record, record count < 20 m, incre tps < 0.5k
☒	2G	2G	2G	1 KB/record, record count < 200 m, incre tps < 1k
☐	3G	3G	3G	1 KB/record, record count < 500 m, incre tps < 2k
☐	4G	4G	4G	1 KB/record, record count < 2 b, incre tps < 10k
☐	0.5G	0.5G	0.5G	1 KB/record, record count < 10 m, incre tps < 0.2k

*任务运行内存

全量内存: 20, 增量内存: 20, 校验内存20, 描述: 1 KB/record, record count < 200 m, incre tps < 1k

任务描述

是否同步 DDL: ☒ 是 ☐ 否

是否开启校验: ☒ 不开启校验 ☐ 开启一次性校验 ☐ 开启周期性校验

全量前滚空目标数据: ☐

重建目标表: ☐

自动启动任务: ☒

上一步 下一步

4. 选择需要同步的表。

CloudCanal 同步任务 同步设置 数据源管理 系统设置 v4.4.1.0 社区版 100% 中文 帮助

同步任务 / 创建任务

源A目标设置 功能配置 表&action过滤 数据处理 创建确认

目标表选择 批量修改目标名称 action数量勾选

目标种类限制: ☒ INSERT ☒ UPDATE ☒ DELETE ☒ CREATE ☒ ALTER ☒ RENAME ☒ TRUNCATE


源表	目标表	action过滤
☒ ACC_RECORD	ACC_RECORD (待创建)	☒ INSERT ☒ UPDATE ☒ DELETE ☒ CREATE
☐ AFANQIE_REVISk (待创建)		☒ ALTER ☒ RENAME ☒ TRUNCATE
☒ A_3372	A_3372 (待创建)	☒ INSERT ☒ UPDATE ☒ DELETE ☒ CREATE
☒ A_3373	A_3373 (待创建)	☒ ALTER ☒ RENAME ☒ TRUNCATE
☐ A_3374		☒ INSERT ☒ UPDATE ☒ DELETE ☒ CREATE
☐ A_3375		☒ ALTER ☒ RENAME ☒ TRUNCATE
☐ A_3376		☒ INSERT ☒ UPDATE ☒ DELETE ☒ CREATE
☐ A_3377		☒ ALTER ☒ RENAME ☒ TRUNCATE
☐ A_3378		☒ INSERT ☒ UPDATE ☒ DELETE ☒ CREATE
☐ A_3379		☒ ALTER ☒ RENAME ☒ TRUNCATE
☐ A_3380		☒ INSERT ☒ UPDATE ☒ DELETE ☒ CREATE
☐ A_3381		☒ ALTER ☒ RENAME ☒ TRUNCATE
☐ A_3382		☒ INSERT ☒ UPDATE ☒ DELETE ☒ CREATE
☐ A_3383		☒ ALTER ☒ RENAME ☒ TRUNCATE
☐ A_3384		☒ INSERT ☒ UPDATE ☒ DELETE ☒ CREATE
☐ A_3385		☒ ALTER ☒ RENAME ☒ TRUNCATE
☐ A_3386		☒ INSERT ☒ UPDATE ☒ DELETE ☒ CREATE
☐ A_3387		☒ ALTER ☒ RENAME ☒ TRUNCATE

全部选中 已选中10项, 总共57项

1 2 3 > 20条/页 筛选 1 页

刷新数据 上一步 下一步

5. 选择需要同步的列。



6. 确认创建任务。

7. 任务自动运行。CloudCanal 会自动进行任务流转，其中的步骤包括：

- 结构迁移: 将源端的表结构迁移到对端，如果同名表在对端已存在，则忽略。
- 全量数据迁移: 已存在的存量数据将会完整迁移到对端，支持断点续传。
- 增量数据同步: 增量数据将会持续地同步到对端数据库，并且保持实时（秒级别延迟）。



DataX Doriswriter

DataX doriswriter

[DataX](#) Doriswriter 插件，支持将 MySQL、Oracle、SqlServer 等多种数据源中的数据通过 Stream Load 的方式同步到 Doris 中。

注意

1. 需要配合 DataX 服务一起使用。
2. DataX 支持多种数据源，可参考[这里](#)。

使用

直接下载 DataX 安装包

DataX 官方提供了安装包，已经包含了 DataX 可直接下载使用，可参考[这里](#)

自行编译 DorisWriter 插件

下载 DorisWriter 的插件[源码](#)

1. 运行 init-env.sh
2. 编译 doriswriter:

单独编译 doriswriter 插件:

```
`mvn clean install -pl plugin-rdbms-util,doriswriter -DskipTests`
```

如需编译整个 DataX 项目可参考[这里](#)

编译错误

如遇到如下编译错误:

```
...  
Could not find artifact com.alibaba.datax:datax-all:pom:0.0.1-SNAPSHOT ...  
...
```

可尝试以下方式解决：

1. 下载 [alibaba-datax-maven-m2-20210928.tar.gz](https://doris-thirdparty-repo.bj.bcebos.com/thirdparty/alibaba-datax-maven-m2-20210928.tar.gz)
2. 解压后，将得到的 `alibaba/datax/` 目录，拷贝到所使用的 maven 对应的 `.m2/repository/com/alibaba/` 下，再次尝试编译。

Datax DorisWriter 参数介绍：

- **jdbcUrl**

- 描述：Doris 的 JDBC 连接串，用户执行 preSql 或 postSQL。
- 必选：是
- 默认值：无

- **loadUrl**

- 描述：作为 Stream Load 的连接目标。格式为 “ip:port”。其中 IP 是 FE 节点 IP，port 是 FE 节点的 http_port。可以填写多个，多个之间使用英文状态的逗号隔开：,，doriswriter 将以轮询的方式访问。
- 必选：是
- 默认值：无

- **username**

- 描述：访问 Doris 数据库的用户名
- 必选：是
- 默认值：无

- **password**

- 描述：访问 Doris 数据库的密码
- 必选：否
- 默认值：空

- **connection.selectedDatabase**

- 描述：需要写入的 Doris 数据库名称。
- 必选：是
- 默认值：无

- **connection.table**

- 描述：需要写入的 Doris 表名称。
 - 必选：是
 - 默认值：无

- **flushInterval**

- 描述：数据写入批次的时间间隔。如果这个时间间隔设置的太小会造成 Doris 写阻塞问题，错误代码 -235，同时如果你这个时间设置太小，maxBatchRows 和 batchSize 参数设置的有很大，那么很可能达不到你这设置的数据量大小，也会执行导入。

- 必选：否
- 默认值：30000 (ms)
- **column**
 - 描述：目的表需要写入数据的字段，这些字段将作为生成的 Json 数据的字段名。字段之间用英文逗号分隔。例如：“column”: [“id”, “name”, “age”]。
 - 必选：是
 - 默认值：否
- **preSql**
 - 描述：写入数据到目的表前，会先执行这里的标准语句。
 - 必选：否
 - 默认值：无
- **postSql**
 - 描述：写入数据到目的表后，会执行这里的标准语句。
 - 必选：否
 - 默认值：无
- **maxBatchRows**
 - 描述：每批次导入数据的最大行数。和 **batchSize** 共同控制每批次的导入记录行数。每批次数据达到两个阈值之一，即开始导入这一批次的数据。
 - 必选：否
 - 默认值：500000
- **batchSize**
 - 描述：每批次导入数据的最大数据量。和 **maxBatchRows** 共同控制每批次的导入数量。每批次数据达到两个阈值之一，即开始导入这一批次的数据。
 - 必选：否
 - 默认值：94371840
- **maxRetries**
 - 描述：每批次导入数据失败后的重试次数。
 - 必选：否
 - 默认值：3
- **labelPrefix**
 - 描述：每批次导入任务的 label 前缀。最终的 label 将有 labelPrefix + UUID 组成全局唯一的 label，确保数据不会重复导入
 - 必选：否
 - 默认值：datax_doris_writer_
- **loadProps**
 - 描述：StreamLoad 的请求参数，详情参照 StreamLoad 介绍页面。[Stream load](#)

这里包括导入的数据格式：format 等，导入数据格式默认我们使用 csv，支持 JSON，具体可以参照下面类型转换部分，也可以参照上面 Stream load 官方信息

- 必选：否
- 默认值：无

示例

1.Stream 读取数据后导入至 Doris

该示例插件的使用说明请参阅 [这里](#)

2.Mysql 读取数据后导入至 Doris

1.Mysql 表结构

```
CREATE TABLE `t_test`(  
  `id` bigint(30) NOT NULL,  
  `order_code` varchar(30) DEFAULT NULL COMMENT '',  
  `line_code` varchar(30) DEFAULT NULL COMMENT '',  
  `remark` varchar(30) DEFAULT NULL COMMENT '',  
  `unit_no` varchar(30) DEFAULT NULL COMMENT '',  
  `unit_name` varchar(30) DEFAULT NULL COMMENT '',  
  `price` decimal(12,2) DEFAULT NULL COMMENT '',  
  PRIMARY KEY(`id`) USING BTREE  
)ENGINE=InnoDB DEFAULT CHARSET=utf8mb4 ROW_FORMAT=DYNAMIC COMMENT='';
```

2.Doris 表结构

```
CREATE TABLE `ods_t_test` (
  `id` bigint(30) NOT NULL,
  `order_code` varchar(30) DEFAULT NULL COMMENT '',
  `line_code` varchar(30) DEFAULT NULL COMMENT '',
  `remark` varchar(30) DEFAULT NULL COMMENT '',
  `unit_no` varchar(30) DEFAULT NULL COMMENT '',
  `unit_name` varchar(30) DEFAULT NULL COMMENT '',
  `price` decimal(12,2) DEFAULT NULL COMMENT ''
) ENGINE=OLAP
UNIQUE KEY(`id`, `order_code`)
DISTRIBUTED BY HASH(`order_code`) BUCKETS 1
PROPERTIES (
  "replication_allocation" = "tag.location.default: 3",
  "in_memory" = "false",
  "storage_format" = "V2"
);
```

3.创建 datax 脚本

my_import.json

```
{
  "job": {
    "content": [
      {
        "id": 1,
        "text": "The first job is to create a new user."
      },
      {
        "id": 2,
        "text": "The second job is to create a new user."
      }
    ]
  }
}
```

```

    "reader": {
      "name": "mysqlreader",
      "parameter": {
        "column": ["id", "order_code", "line_code", "remark", "unit_no", "unit_name", "price"],
        "connection": [
          {
            "jdbcUrl": ["jdbc:mysql://localhost:3306/demo"],
            "table": ["employees_1"]
          }
        ],
        "username": "root",
        "password": "xxxxx",
        "where": ""
      }
    },
    "writer": {
      "name": "doriswriter",
      "parameter": {
        "loadUrl": ["127.0.0.1:8030"],
        "column": ["id", "order_code", "line_code", "remark", "unit_no", "unit_name", "price"],
        "username": "root",
        "password": "xxxxxx",
        "postSql": ["select count(1) from all_employees_info"],
        "preSql": [],
        "flushInterval": 30000,
        "connection": [
          {
            "jdbcUrl": "jdbc:mysql://127.0.0.1:9030/demo",
            "selectedDatabase": "demo",
            "table": ["all_employees_info"]
          }
        ],
        "loadProps": {
          "format": "json",
          "strip_outer_array": "true",
          "line_delimiter": "\\x02"
        }
      }
    }
  ],
  "setting": {
    "speed": {
      "channel": "1"
    }
  }
}

```

备注：

```

"loadProps": {
  "format": "json",
  "strip_outer_array": "true",
  "line_delimiter": "\\x02"
}

```

1. 这里我们使用了 JSON 格式导入数据
2. line_delimiter 默认是换行符，可能会和数据中的值冲突，我们可以使用一些特殊字符或者不可见字符，避免导入错误

3. `strip_outer_array`: 在一批导入数据中表示多行数据, Doris 在解析时会将数组展开, 然后依次解析其中的每一个 Object 作为一行数据
4. 更多 Stream load 参数请参照 [Stream load 文档](#)
5. 如果是 CSV 格式我们可以这样使用

```
"loadProps": {
  "format": "csv",
  "column_separator": "\\x01",
  "line_delimiter": "\\x02"
}
```

CSV 格式要特别注意行列分隔符, 避免和数据中的特殊字符冲突, 这里建议使用隐藏字符, 默认列分隔符是: \t, 行分隔符: \n

4. 执行 DataX 任务, 具体参考 [DataX 官网](#)

```
python bin/datax.py my_import.json
```

执行之后我们可以看到下面的信息

```
2022-11-16 14:28:54.012 [job-0] INFO JobContainer - jobContainer starts to do prepare ...
2022-11-16 14:28:54.012 [job-0] INFO JobContainer - DataX Reader.Job [mysqlreader] do prepare work .
2022-11-16 14:28:54.013 [job-0] INFO JobContainer - DataX Writer.Job [doriswriter] do prepare work .
2022-11-16 14:28:54.020 [job-0] INFO JobContainer - jobContainer starts to do split ...
2022-11-16 14:28:54.020 [job-0] INFO JobContainer - Job set Channel-Number to 1 channels.
2022-11-16 14:28:54.023 [job-0] INFO JobContainer - DataX Reader.Job [mysqlreader] splits to [1] tasks.
2022-11-16 14:28:54.023 [job-0] INFO JobContainer - DataX Writer.Job [doriswriter] splits to [1] tasks.
2022-11-16 14:28:54.033 [job-0] INFO JobContainer - jobContainer starts to do schedule ...
2022-11-16 14:28:54.036 [job-0] INFO JobContainer - Scheduler starts [1] taskGroups.
2022-11-16 14:28:54.037 [job-0] INFO JobContainer - Running by standalone Mode.
2022-11-16 14:28:54.041 [taskGroup-0] INFO TaskGroupContainer - taskGroupId=[0] start [1] channels for [1] tasks.
2022-11-16 14:28:54.043 [taskGroup-0] INFO Channel - Channel set byte_speed_limit to -1, No bps activated.
2022-11-16 14:28:54.043 [taskGroup-0] INFO Channel - Channel set record_speed_limit to -1, No tps activated.
2022-11-16 14:28:54.049 [taskGroup-0] INFO TaskGroupContainer - taskGroup[0] taskId[0] attemptCount[1] is started
2022-11-16 14:28:54.052 [0-0-0-reader] INFO CommonRdbmsReader$Task - Begin to read record by Sql: [select taskid,projectid,taskflowid,templateid,template_name,status_task from dwd_universal_tb_task] jdbcUrl:[jdbc:mysql://localhost:3306/demo?yearIsDateType=false&zeroDateTimeBehavior=convertToNull&tinyInt1isBit=false&rewriteBatchedStatements=true].
Wed Nov 16 14:28:54 GMT+08:00 2022 WARN: Establishing SSL connection without server's identity verification is not recommended. According to MySQL 5.5.45+, 5.6.26+ and 5.7.6+ requirements SSL connection must be established by default if explicit option isn't set. For compliance with existing applications not using SSL the verifyServerCertificate property is set to 'false'. You need either to explicitly disable SSL by setting useSSL=false, or set useSSL=true and provide truststore for server certificate verification.
2022-11-16 14:28:54.071 [0-0-0-reader] INFO CommonRdbmsReader$Task - Finished read record by Sql: [select taskid,projectid,taskflowid,templateid,template_name,status_task from dwd_universal_tb_task] jdbcUrl:[jdbc:mysql://localhost:3306/demo?yearIsDateType=false&zeroDateTimeBehavior=convertToNull&tinyInt1isBit=false&rewriteBatchedStatements=true].
2022-11-16 14:28:54.104 [Thread-1] INFO DorisStreamLoadObserver - Start to join batch data: rows[2] bytes[438] label[datax_doris_writer_c4e08cb9-c157-4689-932f-db34acc45b6f].
2022-11-16 14:28:54.104 [Thread-1] INFO DorisStreamLoadObserver - Executing stream load to: 'http://127.0.0.1:8030/api/demo/dwd_universal_tb_task/_stream_load', size: '441'
2022-11-16 14:28:54.224 [Thread-1] INFO DorisStreamLoadObserver - StreamLoad response : {"Status":"Success","BeginTxnTimeMs":0,"Message":"OK","NumberUnselectedRows":0,"CommitAndPublishTimeMs":17,"Label":"datax_doris_writer_c4e08cb9-c157-4689-932f-db34acc45b6f","LoadBytes":441,"StreamLoadPutTimeMs":1,"NumberTotalRows":2,"WriteDataTimeMs":11,"TxnId":217056}
```

```

,"LoadTimeMs":31,"TwoPhaseCommit":"false","ReadDataTimeMs":0,"NumberLoadedRows":2,"NumberFilteredRows":0}
2022-11-16 14:28:54.225 [Thread-1] INFO DorisWriterManager - Async stream load finished:
label[datax_doris_writer_c4e08cb9-c157-4689-932f-db34acc45b6f].
2022-11-16 14:28:54.249 [taskGroup-0] INFO TaskGroupContainer - taskGroup[0] taskId[0] is succeeded,
used[201]ms
2022-11-16 14:28:54.250 [taskGroup-0] INFO TaskGroupContainer - taskGroup[0] completed it's tasks.
2022-11-16 14:29:04.048 [job-0] INFO StandAloneJobContainerCommunicator - Total 2 records, 214 bytes | Speed
21B/s, 0 records/s | Error 0 records, 0 bytes | All Task WaitWriterTime 0.000s | All Task WaitReaderTime
0.000s | Percentage 100.00%
2022-11-16 14:29:04.049 [job-0] INFO AbstractScheduler - Scheduler accomplished all tasks.
2022-11-16 14:29:04.049 [job-0] INFO JobContainer - DataX Writer.Job [doriswriter] do post work.
Wed Nov 16 14:29:04 GMT+08:00 2022 WARN: Establishing SSL connection without server's identity verification
is not recommended. According to MySQL 5.5.45+, 5.6.26+ and 5.7.6+ requirements SSL connection must be
established by default if explicit option isn't set. For compliance with existing applications not using SSL
the verifyServerCertificate property is set to 'false'. You need either to explicitly disable SSL by setting
useSSL=false, or set useSSL=true and provide truststore for server certificate verification.
2022-11-16 14:29:04.187 [job-0] INFO DorisWriter$Job - Start to execute preSqls:[select count(1) from
dwd_universal_tb_task]. context info:jdbc:mysql://172.16.0.13:9030/demo.
2022-11-16 14:29:04.204 [job-0] INFO JobContainer - DataX Reader.Job [mysqlreader] do post work.
2022-11-16 14:29:04.204 [job-0] INFO JobContainer - DataX jobId [0] completed successfully.
2022-11-16 14:29:04.204 [job-0] INFO HookInvoker - No hook invoked, because base dir not exists or is a
file: /data/datax/hook
2022-11-16 14:29:04.205 [job-0] INFO JobContainer -
    [total cpu info] =>
        averageCpu          | maxDeltaCpu          | minDeltaCpu
        -1.00%              | -1.00%               | -1.00%

    [total gc info] =>
        NAME                | totalGCCount          | maxDeltaGCCount       | minDeltaGCCount       |
totalGCTime                | maxDeltaGCTime        | minDeltaGCTime        |
        PS MarkSweep        | 1                     | 1                     | 1                     | 0.017s
| 0.017s                    | 0.017s                |
        PS Scavenge         | 1                     | 1                     | 1                     | 0.007s
| 0.007s                    | 0.007s                |

2022-11-16 14:29:04.205 [job-0] INFO JobContainer - PerfTrace not enable!
2022-11-16 14:29:04.206 [job-0] INFO StandAloneJobContainerCommunicator - Total 2 records, 214 bytes | Speed
21B/s, 0 records/s | Error 0 records, 0 bytes | All Task WaitWriterTime 0.000s | All Task WaitReaderTime
0.000s | Percentage 100.00%
2022-11-16 14:29:04.206 [job-0] INFO JobContainer -
任务启动时刻                : 2022-11-16 14:28:53
任务结束时刻                : 2022-11-16 14:29:04
任务总计耗时                : 10s
任务平均流量                : 21B/s
记录写入速度                : 0rec/s
读出记录总数                : 2
读写失败总数                : 0

```

DBT Doris Adapter

[DBT\(Data Build Tool\)](#) 是专注于做 ELT（提取、加载、转换）中的 T（Transform）——“转换数据”环节的组件 dbt-doris adapter 是基于dbt-core 1.5.0 开发，依赖于mysql-connector-python驱动对 doris 进行数据转换。

代码仓库：<https://github.com/apache/doris/tree/master/extension/dbt-doris>

版本支持

doris	python	dbt-core
>=1.2.5	>=3.8,<=3.10	>=1.5.0

dbt-doris adapter 使用

dbt-doris adapter 安装

使用 pip 安装：

```
pip install dbt-doris
```

安装行为会默认安装所有 dbt 运行的依赖，可以使用如下命令查看验证：

```
dbt --version
```

如果系统未识别 dbt 这个命令，可以创建一条软连接：

```
ln -s /usr/local/python3/bin/dbt /usr/bin/dbt
```

dbt-doris adapter 初始化

```
dbt init
```

会出现询问式命令行，输入相应配置如下即可初始化一个 dbt 项目：

名称	默认值	含义
project		项目名
database		输入对应编号选择适配器
host		doris 的 host
port	9030	doris 的 MySQL Protocol Port
schema		在 dbt-doris 中，等同于 database，库名

名称	默认值	含义
username		doris 的 username
password		doris 的 password
threads	1	dbt-doris 中并行度（设置与集群能力不匹配的并行度会增加 dbt 运行失败风险）

dbt-doris adapter 运行

相关 dbt 运行文档，可参考[此处](#)。进入到刚刚创建的项目目录下面，执行默认的 dbt 模型：

```
dbt run
```

可以看到运行了两个 model：my_first_dbt_model 和 my_second_dbt_model

他们分别是物化表 table 和视图 view。

可以登陆 doris，查看 my_first_dbt_model 和 my_second_dbt_model 的数据结果及建表语句。

dbt-doris adapter 物化方式

dbt-doris 的 物化方式（Materialization）支持以下三种：

1. view
2. table
3. incremental

View

使用view作为物化模式，在 Models 每次运行时都会通过 create view as 语句重新构建为视图。(默认情况下，dbt 的物化方式为 view)

优点：没有存储额外的数据，源数据之上的视图将始终包含最新的记录。

缺点：执行较大转换或嵌套在其他view之上的view查询速度很慢。

建议：通常从模型的视图开始，只有当存在性能问题时才更改为另一个物化方式。view最适合不进行重大转换的模型，例如重命名，列变更。

配置项：

```
models:
  <resource-path>:
    +materialized: view
```

或者在 model 文件里面写

```
{{ config(materialized = "view") }}
```

Table

使用 table 物化模式时，您的模型在每次运行时都会通过 create table as select 语句重建为表。对于 dbt 的 tablet 物化，dbt-doris 采用以下步骤保证数据更迭时候的原子性：

- 1.create table this_table_temp as {{ model sql}}, 首先创建临时表。
- 2. 判断 this_table 是否不存在，即是首次创建，执行rename，将临时表变更为最终表。
- 3. 若已经存在，则 alter table this_table REPLACE WITH TABLE this_table_temp PROPERTIES('swap' = 'False'), 此操作可以交换表名并且删除this_table_temp临时表，[此过程](#)通过 Doris 内核的事务机制保证本次操作原子性。

优点：table查询速度会比view快。

缺点：table需要较长时间才能构建或重建，会额外存储数据，而且不能够做增量数据同步。

建议：建议对 BI 工具查询的model或下游查询、转换等操作较慢的model使用table物化方式。

配置项：

```
models:
  <resource-path>:
    +materialized: table
    +duplicate_key: [ <column-name>, ... ],
    +replication_num: int,
    +partition_by: [ <column-name>, ... ],
    +partition_type: <engine-type>,
    +partition_by_init: [<pertition-init>, ... ]
    +distributed_by: [ <column-name>, ... ],
    +buckets: int | 'auto',
    +properties: {<key>:<value>,...}
```

或者在 model 文件里面写

```
{{ config(
  materialized = "table",
  duplicate_key = [ "<column-name>", ... ],
  replication_num = "<int>"
  partition_by = [ "<column-name>", ... ],
  partition_type = "<engine-type>",
  partition_by_init = ["<pertition-init>", ... ]
  distributed_by = [ "<column-name>", ... ],
  buckets = "<int>" | "auto",
  properties = {"<key>":"<value>","...}
  ...
)]
)}}
```

上述配置项详情如下：

配置项	描述	Required?
materialized	该表的物化形式（对应创建表模型为明细模型（Duplicate））	Required
duplicate_key	明细模型的排序列	Optional
replication_num	表副本数	Optional
partition_by	表分区列	Optional

配置项	描述	Required?
partition_type	表分区类型, range 或 list .(default: RANGE)	Optional
partition_by_init	初始化的表分区	Optional
distributed_by	表桶区列	Optional
buckets	分桶数量	Optional
properties	建表的其他配置	Optional

Incremental

以上次运行 dbt 的 incremental model 结果为基准，增量的将记录插入或更新到表中。doris 的增量实现有两种方式，此项设计两种增量（incremental_strategy 设置）的策略：

- insert_overwrite: 依赖于 unique 模型，如果有增量需求，在初始化该模型的数据时就指定物化为 incremental，通过指定聚合列进行聚合，实现增量数据的覆盖。
- append: 依赖于duplicate模型，仅仅对增量数据做追加，不涉及修改任何历史数据。因此不需要指定 unique_key。

优点：只需转换新记录，可显著减少构建时间。

缺点：incremental模式需要额外的配置，是 dbt 的高级用法，需要复杂场景的支持和对应组件的适配。

建议：增量模型最适合基于事件相关的场景或 dbt 运行变得太慢时使用增量模型

配置项：

```
models:
  <resource-path>:
    +materialized: incremental
    +incremental_strategy: <strategy>
    +unique_key: [ <column-name>, ... ],
    +replication_num: int,
    +partition_by: [ <column-name>, ... ],
    +partition_type: <engine-type>,
    +partition_by_init: [<partition-init>, ... ]
    +distributed_by: [ <column-name>, ... ],
    +buckets: int | 'auto',
    +properties: {<key>:<value>,...}
```

或者在 model 文件里面写

```
{{ config(
  materialized = "incremental",
  incremental_strategy = "<strategy>"
  unique_key = [ "<column-name>", ... ],
  replication_num = "<int>"
  partition_by = [ "<column-name>", ... ],
  partition_type = "<engine-type>",
  partition_by_init = [<partition-init>", ... ]
  distributed_by = [ "<column-name>", ... ],
  buckets = "<int>" | "auto",
  properties = {"<key>":"<value>",...}
  ...
})
```



```
)  
}}
```

上述配置项详情如下：

配置项	描述	Required?
materialized	该表的物化形式	Required
incremental_strategy	增量策略	Optional
unique_key	unique 表的 key 列	Optional
replication_num	表副本数	Optional
partition_by	表分区列	Optional
partition_type	表分区类型，range 或 list (default: RANGE)	Optional
partition_by_init	初始化的表分区	Optional
distributed_by	表桶区列	Optional
buckets	分桶数量	Optional
properties	建表的其他配置	Optional

dbt-doris adapter seed

[seed](#) 是用于加载 csv 等数据文件时的功能模块，它是一种加载文件入库参与模型构建的一种方式，但有以下注意事项：

- 1. seed 不应用于加载原始数据（例如，从生产数据库导出大型 CSV 文件）。
- 2. 由于 seed 是受版本控制的，因此它们最适合包含特定于业务的逻辑的文件，例如国家/地区代码列表或员工的用户 ID。
- 3. 对于大文件，使用 dbt 的 seed 功能加载 CSV 的性能不佳。应该考虑使用 streamload 等方式将这些 CSV 加载到 doris 中。

用户可以在 dbt project 的目录下面看到 seeds 的目录，在里面上传 csv 文件和 seed 配置文件并运行

```
dbt seed --select seed_name
```

常见 seed 配置文件写法，支持对列类型的定义：

```
seeds:  
  seed_name: # 种子名称，在 seed 构建后，会作为表名  
  config:  
    schema: demo_seed # 在 seed 构建后，会作为 database 的一部分  
    full_refresh: true  
    replication_num: 1  
    column_types:  
      id: bigint  
      phone: varchar(32)  
      ip: varchar(15)
```

```
name: varchar(20)
cost: DecimalV3(19,10)
```

使用示例

视图模型样例参考

```
{{ config(materialized='view') }}

select
    u.user_id,
    max(o.create_time) as create_time,
    sum (o.cost) as balance
from {{ ref('sell_order') }} as o
left join {{ ref('sell_user') }} as u
on u.account_id=o.account_id
group by u.user_id
order by u.user_id
```

表模型样例参考

```
{{ config(materialized='table') }}

select
    u.user_id,
    max(o.create_time) as create_time,
    sum (o.cost) as balance
from {{ ref('sell_order') }} as o
left join {{ ref('sell_user') }} as u
on u.account_id=o.account_id
group by u.user_id
order by u.user_id
```

增量模型样例参考(duplicate 模式)

建表为 duplicate 模式，无数据聚合，不需要指定 unique_key

```
{{ config(
    materialized='incremental',
    replication_num=1
) }}

with source_data as (
    select
        *
    from {{ ref('sell_order2') }}
)

select * from source_data
```

增量模型样例参考(unique 模式)

建表为 unique 模式，数据聚合，必须指定 unique_key

```

{{ config(
  materialized='incremental',
  unique_key=['account_id','create_time']
) }}

with source_data as (
  select
    *
    from {{ ref('sell_order2') }}
)

select * from source_data

```

增量模型全量刷新样例参考

```

{{ config(
  materialized='incremental',
  full_refresh = true
)}}

select * from
  {{ source('dbt_source', 'sell_user') }}

```

设置分桶规则样例参考

此处 buckets 可以填 auto 或者正整数， 分别代表自动分桶和设置固定分桶数

```

{{ config(
  materialized='incremental',
  unique_key=['account_id',"create_time"],
  distributed_by=['account_id'],
  buckets='auto'
) }}

with source_data as (
  select
    *
    from {{ ref('sell_order') }}
)

select
  *
  from source_data

{% if is_incremental() %}
  where
    create_time > (select max(create_time) from {{this}})
{% endif %}

```

设置副本数样例参考

```

{{ config(
  materialized='table',
  replication_num=1
)}}

```

```

with source_data as (
    select
        *
    from {{ ref('sell_order2') }}
)

select * from source_data

```

动态分区样例参考

```

{{ config(
    materialized='incremental',
    partition_by = 'create_time',
    partition_type = 'range',
    -- 这里的 properties 是 create table 语句中的 properties，这里面写了动态分区的相关配置
    properties = {
        "dynamic_partition.time_unit":"DAY",
        "dynamic_partition.end":"8",
        "dynamic_partition.prefix":"p",
        "dynamic_partition.buckets":"4",
        "dynamic_partition.create_history_partition":"true",
        "dynamic_partition.history_partition_num":"3"
    }
) }}

with source_data as (
    select
        *
    from {{ ref('sell_order2') }}
)

select
    *
    from source_data

{% if is_incremental() %}
    where
        create_time = DATE_SUB(CURDATE(), INTERVAL 1 DAY)
{% endif %}

```

常规分区样例参考

```

{{ config(
    materialized='incremental',
    partition_by = 'create_time',
    partition_type = 'range',
    -- 这里的 partition_by_init 是指的 创建分区表的历史分区，当前 doris 版本的历史分区需要手动指定
    partition_by_init = [
        "PARTITION `p20240601` VALUES [(\`2024-06-01\`), (\`2024-06-02\`))",
        "PARTITION `p20240602` VALUES [(\`2024-06-02\`), (\`2024-06-03\`))"
    ]
) }}

with source_data as (
    select
        *
    from {{ ref('sell_order2') }}
)

select

```

```

*
from source_data

{% if is_incremental() %}
  where
    -- 如果提供了my_date变量, 则使用该通路 (通过 dbt run --vars '{"my_date": "\"2024-06-03\""}' 命令) 如果没有提供
my_date 变量(直接 dbt run ), 则使用当前日期的前一天 , 这里的增量选择建议直接使用 doris 的 CURDATE() 函数, 这个通路也是生产环
境经常走的。
    create_time = {{ var('my_date' , 'DATE_SUB(CURDATE(), INTERVAL 1 DAY)') }}

{% endif %}

```

批处理日期设置参数样例参考

```

{{ config(
  materialized='incremental',
  partition_by = 'create_time',
  partition_type = 'range',
  ...
)}}

with source_data as (
  select
    *
    from {{ ref('sell_order2') }}
)

select
  *
  from source_data

{% if is_incremental() %}
  where
    -- 如果提供了my_date变量, 则使用该通路 (通过 dbt run --vars '{"my_date": "\"2024-06-03\""}' 命令) 如果没有提供
my_date 变量(直接 dbt run ), 则使用当前日期的前一天 , 这里的增量选择建议直接使用 doris 的 CURDATE() 函数, 这个通路也是生产环
境经常走的。
    create_time = {{ var('my_date' , 'DATE_SUB(CURDATE(), INTERVAL 1 DAY)') }}

{% endif %}

```

Seatunnel Doris Sink

SeaTunnel 是一个非常简单易用的超高性能分布式数据集成平台，支持海量数据的实时同步。每天稳定高效地同步数百亿数据

Connector-V2

2.3.1 版本的 [Apache SeaTunnel Connector-V2](#) 支持了 Doris Sink，并且支持 exactly-once 的精准一次写入和 CDC 数据同步

插件代码

SeaTunnel Doris Sink [插件代码](#)

参数列表

name	type	required	default value
fenodes	string	yes	-
username	string	yes	-
password	string	yes	-
table.identifier	string	yes	-
sink.label-prefix	string	yes	-
sink.enable-2pc	bool	no	true
sink.enable-delete	bool	no	false
doris.config	map	yes	-

fenodes [string]

Doris 集群 FE 节点地址，格式为 "fe_ip:fe_http_port,..."

username [string]

Doris 用户名

password [string]

Doris 用户密码

table.identifier [string]

Doris 表名称，格式为 DBName.TableName

sink.label-prefix [string]

Stream Load 导入使用的标签前缀。在 2pc 场景下，需要全局唯一性来保证 SeaTunnel 的 EOS 语义

`sink.enable-2pc [bool]`

是否启用两阶段提交 (2pc), 默认为 true, 以确保 exact - once 语义。关于两阶段提交, 请参考[这里](#)

`sink.enable-delete [bool]`

是否启用删除。该选项需要 Doris 表开启批量删除功能 (默认开启 0.15+ 版本), 且只支持 Unique 表模型。你可以在[这个链接](#)获得更多细节:

[批量删除](#)

`doris.config [map]`

Stream Load data_desc 的参数, 你可以在[这个链接](#)获得更多细节:

[更多 Stream Load 参数](#)

使用示例

使用 JSON 格式导入数据

```
sink {
  Doris {
    fenodes = "doris_fe:8030"
    username = root
    password = ""
    table.identifier = "test.table_sink"
    sink.enable-2pc = "true"
    sink.label-prefix = "test_json"
    doris.config = {
      format="json"
      read_json_by_line="true"
    }
  }
}
```

使用 CSV 格式导入数据

```
sink {
  Doris {
    fenodes = "doris_fe:8030"
    username = root
    password = ""
    table.identifier = "test.table_sink"
    sink.enable-2pc = "true"
    sink.label-prefix = "test_csv"
    doris.config = {
      format = "csv"
      column_separator = ","
      line_delimiter = "\n"
    }
  }
}
```

Connector-V1

2.1.0 的 Apache SeaTunnel 支持 Doris 的连接器，SeaTunnel 可以通过 Spark 引擎和 Flink 引擎同步数据至 Doris 中。

Flink Doris Sink

插件代码

Seatunnel Flink Sink Doris [插件代码](#)

参数列表

配置项	类型	必填	默认值	支持引擎
fenodes	string	yes	-	Flink
database	string	yes	-	Flink
table	string	yes	-	Flink
user	string	yes	-	Flink
password	string	yes	-	Flink
batch_size	int	no	100	Flink
interval	int	no	1000	Flink
max_retries	int	no	1	Flink
doris.*	-	no	-	Flink

fenodes [string]

Doris Fe Http 访问地址，eg: 127.0.01:8030

database [string]

写入 Doris 的库名

table [string]

写入 Doris 的表名

user [string]

Doris 访问用户

password [string]

Doris 访问用户密码

batch_size [int]

单次写 Doris 的最大行数，默认值 100

interval [int]

flush 间隔时间 (毫秒), 超过该时间后异步线程将 缓存中数据写入 Doris。设置为 0 表示关闭定期写入。

max_retries [int]

写 Doris 失败之后的重试次数

doris.* [string]

Stream load 的导入参数。例如:'doris.column_separator' = ','等

[更多 Stream Load 参数配置](#)

Examples

Socket 数据写入 Doris

```
env {
  execution.parallelism = 1
}
source {
  SocketStream {
    host = 127.0.0.1
    port = 9999
    result_table_name = "socket"
    field_name = "info"
  }
}
transform {
}
sink {
  DorisSink {
    fenodes = "127.0.0.1:8030"
    user = root
    password = 123456
    database = test
    table = test_tbl
    batch_size = 5
    max_retries = 1
    interval = 5000
  }
}
```

启动命令

```
sh bin/start-seatunnel-flink.sh --config config/flink.streaming.conf
```

Spark Sink Doris

插件代码

Spark Sink Doris 的插件代码在[这里](#)

参数列表

参数名	参数类型	是否必要	默认值	引擎类型
fenodes	string	yes	-	Spark

参数名	参数类型	是否必要	默认值	引擎类型
database	string	yes	-	Spark
table	string	yes	-	Spark
user	string	yes	-	Spark
password	string	yes	-	Spark
batch_size	int	yes	100	Spark
doris.*	string	no	-	Spark

fenodes [string]

Doris Fe 节点地址:8030

database [string]

写入 Doris 的库名

table [string]

写入 Doris 的表名

user [string]

Doris 访问用户

password [string]

Doris 访问用户密码

batch_size [string]

Spark 通过 Stream Load 方式写入，每个批次提交条数

doris. [string]

Stream Load 方式写入的 Http 参数优化，在官网参数前加上'Doris.'前缀

[更多 Stream Load 参数配置](#)

Examples

Hive 迁移数据至 Doris

```
env{
  spark.app.name = "hive2doris-template"
}

spark {
  spark.sql.catalogImplementation = "hive"
}

source {
  hive {
    preSql = "select * from tmp.test"
```

```
    result_table_name = "test"
  }
}

transform {

}

sink {

  Console {

  }

  Doris {
    fenodes="xxxx:8030"
    database="tmp"
    table="test"
    user="root"
    password="root"
    batch_size=1000
    doris.column_separator="\t"
    doris.columns="date_key,date_value,day_in_year,day_in_month"
  }
}
```

启动命令

```
sh bin/start-waterdrop-spark.sh --master local[4] --deploy-mode client --config ./config/spark.conf
```

Kettle Doris Plugin

Kettle Doris Plugin

[Kettle](#) Doris的插件，用于在Kettle中通过 Stream Load 将其他数据源的数据写入到 Doris 中。

这个插件是利用 Doris 的 Stream Load 功能进行数据导入的。需要配合 Kettle 服务一起使用。

关于 Kettle

Kettle 是一款开源的ETL（Extract, Transform, Load）工具，最早由 Pentaho 公司开发，Kettle 是 Pentaho 产品套件中的核心组件之一，主要用于数据集成和数据处理，能够轻松完成从各种来源提取数据、对数据进行清洗和转换，并将其加载到目标系统中的任务。

更多信息请参阅：<https://pentaho.com/>

使用手册

下载Kettle安装

Kettle 下载地址：<https://pentaho.com/download/#download-pentaho> 下载后解压，运行spoon.sh即可启动kettle 也可以自行编译，参考[编译章节](#)

编译Kettle Doris Plugin


```
cd doris/extension/kettle
mvn clean package -DskipTests
```

编译完成后，将插件包解压后拷贝到kettle的plugins目录下


```
cd assemblies/plugin/target
unzip doris-stream-loader-plugins-9.4.0.0-343.zip
cp -r doris-stream-loader ${KETTLE_HOME}/plugins/
mvn clean package -DskipTests
```

构建作业

在Kettle中的批量加载中找到Doris Stream Loader，构建作业



点击开始运行作业即可完成数据同步



参数说明

Key	Default Value	Required	Comment
Step name	—	Y	步骤名称
fenodes	—	Y	Doris FE http 地址，支持多个地址，使用逗号分隔
数据库	—	Y	Doris 的写入数据库
目标表	—	Y	Doris 的写入表
用户名	—	Y	访问 Doris 的用户名
密码	—	N	访问 Doris 的密码
单次导入最大行数	10000	N	单次导入的最大行数
单次导入最大字节	10485760(10MB)	N	单次导入的最大字节大小
导入重试次数	3	N	导入失败之后的重试次数
Stream Load属性	—	N	Stream Load的请求头
删除模式	N	N	是否开启删除模式。默认情况下，Stream Load执行插入操作，开启删除模式后，Stream Load写入均为删除操作

Kyuubi

介绍

[Apache Kyuubi](#) 是一个分布式和多租户网关，用于在 Lakehouse 上提供 Serverless SQL，可连接包括 Spark、Flink、Hive、JDBC 等引擎，并对外提供 Thrift、Trino 等接口协议供灵活对接。其中 Apache Kyuubi 实现了 JDBC Engine 并支持 Doris 方言，并可用于对接 Doris 作为数据源。Apache Kyuubi 可提供高可用、服务发现、租户隔离、统一认证、生命周期管理等一系列特性。

下载 Apache Kyuubi

配置方法

下载 Apache Kyuubi

从官网下载 Apache Kyuubi 1.6.0 或以上版本的安装包后解压。

Apache Kyuubi 下载地址：<https://kyuubi.apache.org/zh/releases.html>

配置 Doris 作为 Kyuubi 数据源

- 修改配置文件 `$KYUUBI_HOME/conf/kyuubi-defaults.conf`

```
kyuubi.engine.type=jdbc
kyuubi.engine.jdbc.type=doris
kyuubi.engine.jdbc.driver.class=com.mysql.cj.jdbc.Driver
kyuubi.engine.jdbc.connection.url=jdbc:mysql://xxx:xxx
kyuubi.engine.jdbc.connection.user=***
kyuubi.engine.jdbc.connection.password=***
```

配置项	说明
kyuubi.engine.type	引擎类型。请使用 jdbc
kyuubi.engine.jdbc.type	JDBC 服务类型。这里请指定为 doris
kyuubi.engine.jdbc.driver.class	连接 JDBC 服务使用的驱动类名。请使用 com.mysql.cj.jdbc.Driver
kyuubi.engine.jdbc.connection.url	JDBC 服务连接。这里请指定 Doris FE 上的 mysql server 连接地址
kyuubi.engine.jdbc.connection.user	JDBC 服务用户名
kyuubi.engine.jdbc.connection.password	JDBC 服务密码

- 其他相关配置参考 [Apache Kyuubi 配置说明](#)。

添加 MySQL 驱动

添加 Mysql JDB C 驱动 `mysql-connector-j-8.X.X.jar` 到 `$KYUUBI_HOME/externals/engines/jdbc` 目录下。

启动 Kyuubi 服务

\$KYUUBI_HOME/bin/kyuubi start 启动后，Kyuubi 默认监听 10009 端口提供 Thrift 协议。

使用方法

以下例子展示通过 Apache Kyuubi 的 beeline 工具经 Thrift 协议查询 Doris。

建立连接

```
$ $KYUUBI_HOME/bin/beeline -u "jdbc:hive2://xxxx:10009/"
```

执行查询


执行查询语句 select * from demo.expamle_tbl; 并得到结果。

```
0: jdbc:hive2://xxxx:10009/> select * from demo.example_tbl;

2023-03-07 09:29:14.771 INFO org.apache.kyuubi.operation.ExecuteStatement: Processing anonymous's
query[bdc59dd0-ceea-4c02-8c3a-23424323f5db]: PENDING_STATE -> RUNNING_STATE, statement:
select * from demo.example_tbl
2023-03-07 09:29:14.786 INFO org.apache.kyuubi.operation.ExecuteStatement: Query[bdc59dd0-ceea-4c02-8c3a-
23424323f5db] in FINISHED_STATE
2023-03-07 09:29:14.787 INFO org.apache.kyuubi.operation.ExecuteStatement: Processing anonymous's
query[bdc59dd0-ceea-4c02-8c3a-23424323f5db]: RUNNING_STATE -> FINISHED_STATE, time taken: 0.015 seconds
+-----+
+-----+
| user_id | date | city | age | sex | last_visit_date | cost | max_dwell_time |
min_dwell_time |
+-----+
+-----+
| 10000 | 2017-10-01 | 北京 | 20 | 0 | 2017-10-01 07:00:00.0 | 70 | 10 | 2 |
|
| 10001 | 2017-10-01 | 北京 | 30 | 1 | 2017-10-01 17:05:45.0 | 4 | 22 | 22 |
|
| 10002 | 2017-10-02 | 上海 | 20 | 1 | 2017-10-02 12:59:12.0 | 400 | 5 | 5 |
|
| 10003 | 2017-10-02 | 广州 | 32 | 0 | 2017-10-02 11:20:00.0 | 60 | 11 | 11 |
|
| 10004 | 2017-10-01 | 深圳 | 35 | 0 | 2017-10-01 10:00:15.0 | 200 | 3 | 3 |
|
| 10004 | 2017-10-03 | 深圳 | 35 | 0 | 2017-10-03 10:20:22.0 | 22 | 6 | 6 |
|
+-----+
+-----+
6 rows selected (0.068 seconds)
```


AutoMQ Load

[AutoMQ](#) 是基于云重新设计的云原生 Kafka。通过将存储分离至对象存储，在保持和 Apache Kafka 100% 兼容的前提下，为用户提供高达 10 倍的成本优势以及百倍的弹性优势。通过其创新的共享存储架构，在保证高吞吐、低延迟的性能指标下实现了秒级分区迁移、流量自平衡、秒级自动弹性等能力。



AutoMQ Storage Architecture

环境准备

准备 Apache Doris 和测试数据

确保当前已准备好可用的 Apache Doris 集群。为了便于演示，我们参考 [Docker 部署 Doris](#) 文档在 Linux 上部署了一套测试用的 Apache Doris 环境。创建库和测试表：

```
create database automq_db;
CREATE TABLE automq_db.users (
    id bigint NOT NULL,
    name string NOT NULL,
    timestamp string NULL,
    status string NULL
) DISTRIBUTED BY hash (id) PROPERTIES ('replication_num' = '1');
```

准备 Kafka 命令行工具

从 [AutoMQ Releases](#) 下载最新的 TGZ 包并解压。假设解压目录为 \$AUTOMQ_HOME，在本文中将会使用 \$AUTOMQ_HOME/bin 下的工具命令来创建主题和生成测试数据。

准备 AutoMQ 和测试数据

参考 AutoMQ [官方部署文档](#)部署一套可用的集群，确保 AutoMQ 与 Apache Doris 之间保持网络连通。在 AutoMQ 中快速创建一个名为 example_topic 的主题，并向其中写入一条测试 JSON 数据，按照以下步骤操作。

创建 Topic

使用 Apache Kafka 命令行工具创建主题，需要确保当前拥有 Kafka 环境的访问权限并且 Kafka 服务正在运行。以下是创建主题的命令示例：

```
$AUTOMQ_HOME/bin/kafka-topics.sh --create --topic example_topic --bootstrap-server 127.0.0.1:9092 --
partitions 1 --replication-factor 1
```

在执行命令时，需要将 topic 和 bootstrap-server 替换为实际使用的 AutoMQ Bootstrap Server 地址。创建完主题后，可以使用以下命令来验证主题是否已成功创建。

```
$AUTOMQ_HOME/bin/kafka-topics.sh --describe example_topic --bootstrap-server 127.0.0.1:9092
```

生成测试数据

生成一条 JSON 格式的测试数据，和前文的表需要对应。

```
{
  "id": 1,
  "name": "测试用户",
  "timestamp": "2023-11-10T12:00:00",
  "status": "active"
}
```

写入测试数据

通过 Kafka 的命令行工具或编程方式将测试数据写入到名为 `example_topic` 的主题中。下面是一个使用命令行工具的示例：

```
echo '{"id": 1, "name": "测试用户", "timestamp": "2023-11-10T12:00:00", "status": "active"}' | sh kafka-console-producer.sh --broker-list 127.0.0.1:9092 --topic example_topic
```

使用如下命令可以查看刚写入的 topic 数据：

```
sh $AUTOMQ_HOME/bin/kafka-console-consumer.sh --bootstrap-server 127.0.0.1:9092 --topic example_topic --from-beginning
```

注意：在执行命令时，需要将 topic 和 bootstrap-server 替换为实际使用的 AutoMQ Bootstarp Server 地址。

创建 Routine Load 导入作业

在 Apache Doris 的命令行中创建一个接收 JSON 数据的 Routine Load 作业，用来持续导入 AutoMQ Kafka topic 中的数据。具体 Routine Load 的参数说明请参考 [Doris Routine Load](#)。

```
CREATE ROUTINE LOAD automq_example_load ON users
COLUMNS(id, name, timestamp, status)
PROPERTIES
(
  "format" = "json",
  "jsonpaths" = "[\"$.id\", \"$.name\", \"$.timestamp\", \"$.status\"]"
)
FROM KAFKA
(
  "kafka_broker_list" = "127.0.0.1:9092",
  "kafka_topic" = "example_topic",
  "property.kafka_default_offsets" = "OFFSET_BEGINNING"
);
```

注意：在执行命令时，需要将 kafka_broker_list 替换为实际使用的 AutoMQ Bootstarp Server 地址。

验证数据导入

首先，检查 Routine Load 导入作业的状态，确保任务正在运行中。

```
show routine load\G;
```

然后查询 Apache Doris 数据库中的相关表，可以看到数据已经被成功导入。

```
select * from users;
+-----+-----+-----+-----+
| id   | name      | timestamp          | status |
+-----+-----+-----+-----+
```

	1	测试用户	2023-11-10T12:00:00	active	
	2	测试用户	2023-11-10T12:00:00	active	
+-----+-----+-----+-----+					

2 rows in set (0.01 sec)

Hive Bitmap UDF

Hive Bitmap UDF 提供了在 Hive 表中生成 bitmap、bitmap 运算等 UDF，Hive 中的 bitmap 与 Doris bitmap 完全一致，Hive 中的 bitmap 可以直接导入 doris。

主要目的： 1. 减少数据导入 doris 时间，除去了构建字典、bitmap 预聚合等流程；

2. 节省 Hive 存储，使用 bitmap 对数据压缩，减少了存储成本；

3. 提供在 Hive 中 bitmap 的灵活运算，比如：交集、并集、差集运算，计算后的 bitmap 也可以直接导入 doris；

使用方法

在 Hive 中创建 Bitmap 类型表

```
-- 例子: 创建 Hive Bitmap 表
CREATE TABLE IF NOT EXISTS `hive_bitmap_table` (
  `k1` int COMMENT '',
  `k2` String COMMENT '',
  `k3` String COMMENT '',
  `uuid` binary COMMENT 'bitmap'
) comment 'comment'

-- 例子: 创建普通 Hive 表
CREATE TABLE IF NOT EXISTS `hive_table` (
  `k1` int COMMENT '',
  `k2` String COMMENT '',
  `k3` String COMMENT '',
  `uuid` int COMMENT ''
) comment 'comment'
```

Hive Bitmap UDF 使用:

Hive Bitmap UDF 需要在 Hive/Spark 中使用，首先需要编译 fe 得到 hive-udf-jar-with-dependencies.jar。编译准备工作：如果进行过 ldb 源码编译可直接编译 fe，如果没有进行过 ldb 源码编译，则需要手动安装 thrift，可参考：[FE 开发环境搭建](#) 中的编译与安装

```
--clone doris 源码
git clone https://github.com/apache/doris.git
cd doris
git submodule update --init --recursive
--安装 thrift
--进入 fe 目录
cd fe
--执行 maven 打包命令 (fe 的子 module 会全部打包)
mvn package -Dmaven.test.skip=true
--也可以只打 hive-udf module
mvn package -pl hive-udf -am -Dmaven.test.skip=true
```

打包编译完成进入 hive-udf 目录会有 target 目录，里面就会有打包完成的 hive-udf.jar 包

```
-- 加载 hive bitmap udf jar 包 （需要将编译好的 hive-udf jar 包上传至 HDFS）
add jar hdfs://node:9001/hive-udf-jar-with-dependencies.jar;

-- 创建 UDAF 函数
create temporary function to_bitmap as 'org.apache.doris.udf.ToBitmapUDAF' USING JAR 'hdfs://node:9001/hive-udf-jar-with-dependencies.jar';
create temporary function bitmap_union as 'org.apache.doris.udf.BitmapUnionUDAF' USING JAR 'hdfs://node:9001/hive-udf-jar-with-dependencies.jar';

-- 创建 UDF 函数
create temporary function bitmap_count as 'org.apache.doris.udf.BitmapCountUDF' USING JAR 'hdfs://node:9001/hive-udf-jar-with-dependencies.jar';
create temporary function bitmap_and as 'org.apache.doris.udf.BitmapAndUDF' USING JAR 'hdfs://node:9001/hive-udf-jar-with-dependencies.jar';
create temporary function bitmap_or as 'org.apache.doris.udf.BitmapOrUDF' USING JAR 'hdfs://node:9001/hive-udf-jar-with-dependencies.jar';
create temporary function bitmap_xor as 'org.apache.doris.udf.BitmapXorUDF' USING JAR 'hdfs://node:9001/hive-udf-jar-with-dependencies.jar';

-- 例子: 通过 to_bitmap 生成 bitmap 写入 Hive Bitmap 表
insert into hive_bitmap_table
select
    k1,
    k2,
    k3,
    to_bitmap(uuid) as uuid
from
    hive_table
group by
    k1,
    k2,
    k3

-- 例子: bitmap_count 计算 bitmap 中元素个数
select k1,k2,k3,bitmap_count(uuid) from hive_bitmap_table

-- 例子: bitmap_union 用于计算分组后的 bitmap 并集
select k1,bitmap_union(uuid) from hive_bitmap_table group by k1
```

Hive bitmap 导入 doris

创建 Hive 表指定为 TEXT 格式，此时，对于 Binary 类型，Hive 会以 bash64 编码的字符串形式保存，此时可以通过 Hive Catalog 的形式，直接将位图数据通过 bitmap_from_bash64 函数插入到 Doris 内部。

以下是一个完整的例子：

1. 在 Hive 中创建 Hive 表

```
CREATE TABLE IF NOT EXISTS `test`.`hive_bitmap_table` (
  `k1` int COMMENT '',
  `k2` String COMMENT '',
  `k3` String COMMENT '',
  `uuid` binary COMMENT 'bitmap'
) stored as textfile
```

2. 在 Doris 中创建 Catalog

```
CREATE CATALOG hive PROPERTIES (  
    'type'='hms',  
    'hive.metastore.uris' = 'thrift://127.0.0.1:9083'  
);
```

3. 创建 Doris 内表

```
CREATE TABLE IF NOT EXISTS `test`.`doris_bitmap_table`(  
    `k1`    int                COMMENT '',  
    `k2`    String             COMMENT '',  
    `k3`    String             COMMENT '',  
    `uuid`  BITMAP BITMAP_UNION COMMENT 'bitmap'  
)  
AGGREGATE KEY(k1, k2, k3)  
DISTRIBUTED BY HASH(`user_id`) BUCKETS 1  
PROPERTIES (  
    "replication_allocation" = "tag.location.default: 1"  
);
```

4. 从 Hive 插入数据到 Doris 中

```
insert into doris_bitmap_table select k1, k2, k3, bitmap_from_base64(uuid) from hive.test.hive_bitmap_table;
```

常见运维问题

本文档主要用于记录 Doris 使用过程中的运维常见问题。会不定期更新。

文中的出现的 BE 二进制文件名称 `doris_be`，在之前的版本中为 `palo_be`。

Q1. 通过 DECOMMISSION 下线 BE 节点时，为什么总会有部分 tablet 残留？

在下线过程中，通过 `show backends` 查看下线节点的 `tabletNum`，会观察到 `tabletNum` 数量在减少，说明数据分片正在从这个节点迁移走。当数量减到 0 时，系统会自动删除这个节点。但某些情况下，`tabletNum` 下降到一定数值后就不变化。这通常可能有以下两种原因：

1. 这些 `tablet` 属于刚被删除的表、分区或物化视图。而刚被删除的对象会保留在回收站中。而下线逻辑不会处理这些分片。可以通过修改 FE 的配置参数 `catalog_trash_expire_second` 来修改对象在回收站中驻留的时间。当对象从回收站中被删除后，这些 `tablet` 就会被处理了。
2. 这些 `tablet` 的迁移任务出现了问题。此时需要通过 `show proc "/cluster_balance"` 来查看具体任务的错误了。

对于以上情况，可以先通过 `show proc "/cluster_health/tablet_health"`；查看集群是否还有 `unhealthy` 的分片，如果为 0，则可以直接通过 `drop backend` 语句删除这个 BE。否则，还需要具体查看不健康分片的副本情况。

Q2. `priority_networks` 应该如何设置？

`priority_networks` 是 FE、BE 都有的配置参数。这个参数主要用于帮助系统选择正确的网卡 IP 作为自己的 IP。建议任何情况下，都显式的设置这个参数，以防止后续机器增加新网卡导致 IP 选择不正确的问题。

`priority_networks` 的值是 CIDR 格式表示的。分为两部分，第一部分是点分十进制的 IP 地址，第二部分是一个前缀长度。比如 `10.168.1.0/8` 会匹配所有 `10.xx.xx.xx` 的 IP 地址，而 `10.168.1.0/16` 会匹配所有 `10.168.xx.xx` 的 IP 地址。

之所以使用 CIDR 格式而不是直接指定一个具体 IP，是为了保证所有节点都可以使用统一的配置值。比如有两个节点：`10.168.10.1` 和 `10.168.10.2`，则我们可以使用 `10.168.10.0/24` 来作为 `priority_networks` 的值。

Q3. FE 的 Master、Follower、Observer 都是什么？

首先明确一点，FE 只有两种角色：Follower 和 Observer。而 Master 只是一组 Follower 节点中选择出来的一个 FE。Master 可以看成是一种特殊的 Follower。所以当我们被问及一个集群有多少 FE，都是什么角色时，正确的回答当时应该是所有 FE 节点的个数，以及 Follower 角色的个数和 Observer 角色的个数。

所有 Follower 角色的 FE 节点会组成一个可选择组，类似 Paxos 一致性协议里的组概念。组内会选举出一个 Follower 作为 Master。当 Master 挂了，会自动选择新的 Follower 作为 Master。而 Observer 不会参与选举，因此 Observer 也不会成为 Master。

一条元数据日志需要在多数 Follower 节点写入成功，才算成功。比如 3 个 FE，2 个写入成功才可以。这也是为什么 Follower 角色的个数需要是奇数的原因。

Observer 角色和这个单词的含义一样，仅仅作作为观察者来同步已经成功写入的元数据日志，并且提供元数据读服务。他不会参与多数写的逻辑。

通常情况下，可以部署 1 Follower + 2 Observer 或者 3 Follower + N Observer。前者运维简单，几乎不会出现 Follower 之间的一致性协议导致这种复杂错误情况（企业大多使用这种方式）。后者可以保证元数据写的高可用，如果是高并发查询场景，可以适当增加 Observer。

Q4. 节点新增加了新的磁盘，为什么数据没有均衡到新的磁盘上？

当前 Doris 的均衡策略是以节点为单位的。也就是说，是按照节点整体的负载指标（分片数量和总磁盘利用率）来判断集群负载。并且将数据分片从高负载节点迁移到低负载节点。如果每个节点都增加了一块磁盘，则从节点整体角度看，负载并没有改变，所以无法触发均衡逻辑。

此外，Doris 目前并不支持单个节点内部，各个磁盘间的均衡操作。所以新增磁盘后，不会将数据均衡到新的磁盘。

但是，数据在节点之间迁移时，Doris 会考虑磁盘的因素。比如一个分片从 A 节点迁移到 B 节点，会优先选择 B 节点中，磁盘空间利用率较低的磁盘。

这里我们提供 3 种方式解决这个问题：

1. 重建新表

通过 `create table like` 语句建立新表，然后使用 `insert into select` 的方式将数据从老表同步到新表。因为创建新表时，新表的数据分片会分布在新的磁盘中，从而数据也会写入新的磁盘。这种方式适用于数据量较小的情况（几十 GB 以内）。

2. 通过 Decommission 命令

`decommission` 命令用于安全下线一个 BE 节点。该命令会先将该节点上的数据分片迁移到其他节点，然后在删除该节点。前面说过，在数据迁移时，会优先考虑磁盘利用率低的磁盘，因此该方式可以“强制”让数据迁移到其他节点的磁盘上。当数据迁移完成后，我们在 `cancel` 掉这个 `decommission` 操作，这样，数据又会重新均衡回这个节点。当我们对所有 BE 节点都执行一遍上述步骤后，数据将会均匀的分布在所有节点的所有磁盘上。

注意，在执行 `decommission` 命令前，先执行以下命令，以避免节点下线完成后被删除。

```
admin set frontend config("drop_backend_after_decommission" = "false");
```

3. 使用 API 手动迁移数据

Doris 提供了[HTTP API](#)，可以手动指定一个磁盘上的数据分片迁移到另一个磁盘上。

Q5. 如何正确阅读 FE/BE 日志？

很多情况下我们需要通过日志来排查问题。这里说明一下 FE/BE 日志的格式和查看方式。

1. FE

FE 日志主要有：

- `fe.log`：主日志。包括除 `fe.out` 外的所有内容。

- fe.warn.log: 主日志的子集, 仅记录 WARN 和 ERROR 级别的日志。
- fe.out: 标准/错误输出的日志 (stdout 和 stderr)。
- fe.audit.log: 审计日志, 记录这个 FE 接收的所有 SQL 请求。

一条典型的 FE 日志如下:

```
2021-09-16 23:13:22,502 INFO (tablet scheduler|43)
[BeLoadRebalancer.selectAlternativeTabletsForCluster():85] cluster is balance: default_cluster with
medium: HDD. skip
```

- 2021-09-16 23:13:22,502: 日志时间。
- INFO: 日志级别, 默认是INFO。
- (tablet scheduler|43): 线程名称和线程 id。通过线程 id, 就可以查看这个线程上下文信息, 方面排查这个线程发生的事情。
- BeLoadRebalancer.selectAlternativeTabletsForCluster():85: 类名、方法名和代码行号。
- cluster is balance xxx: 日志内容。

通常情况下我们主要查看 fe.log 日志。特殊情况下, 有些日志可能输出到了 fe.out 中。

2. BE

BE 日志主要有:

- be.INFO: 主日志。这其实是个软连, 连接到最新的一个 be.INFO.xxxx 上。
- be.WARNING: 主日志的子集, 仅记录 WARN 和 FATAL 级别的日志。这其实是个软连, 连接到最新的一个 be.WARN.xxxx 上。
- be.out: 标准/错误输出的日志 (stdout 和 stderr)。

一条典型的 BE 日志如下:

```
I0916 23:21:22.038795 28087 task_worker_pool.cpp:1594] finish report TASK. master host: 10.10.10.10,
port: 9222
```

- I0916 23:21:22.038795: 日志等级和日期时间。大写字母 I 表示 INFO, W 表示 WARN, F 表示 FATAL。
- 28087: 线程 id。通过线程 id, 就可以查看这个线程上下文信息, 方面排查这个线程发生的事情。
- task_worker_pool.cpp:1594: 代码文件和行号。
- finish report TASK xxx: 日志内容。

通常情况下我们主要查看 be.INFO 日志。特殊情况下, 如 BE 宕机, 则需要查看 be.out。

Q6. FE/BE 节点挂了应该如何排查原因?

1. BE

BE 进程是 C/C++ 进程，可能会因为一些程序 Bug（内存越界，非法地址访问等）或 Out Of Memory (OOM) 导致进程挂掉。此时我们可以通过以下几个步骤查看错误原因：

1. 查看 be.out

BE 进程实现了在程序因异常情况退出时，会打印当前的错误堆栈到 be.out 里（注意是 be.out，不是 be.INFO 或 be.WARNING）。通过错误堆栈，通常能够大致获悉程序出错的位置。

注意，如果 be.out 中出现错误堆栈，通常情况下是因为程序 bug，普通用户可能无法自行解决，欢迎前往微信群、github discussion 或 dev 邮件组寻求帮助，并贴出对应的错误堆栈，以便快速排查问题。

2. dmesg

如果 be.out 没有堆栈信息，则大概率是因为 OOM 被系统强制 kill 掉了。此时可以通过 dmesg -T 这个命令查看 linux 系统日志，如果最后出现 Memory cgroup out of memory: Kill process 7187 (doris_be) score 1007 or sacrifice child 类似的日志，则说明是 OOM 导致的。

内存问题可能有多方面原因，如大查询、导入、compaction 等。Doris 也在不断优化内存使用。欢迎前往微信群、github discussion 或 dev 邮件组寻求帮助。

3. 查看 be.INFO 中是否有 F 开头的日志。

F 开头的日志是 Fatal 日志。如 F0916，表示 9 月 16 号的 Fatal 日志。Fatal 日志通常表示程序断言错误，断言错误会直接导致进程退出（说明程序出现了 Bug）。欢迎前往微信群、github discussion 或 dev 邮件组寻求帮助。

2. FE

FE 是 java 进程，健壮程度要优于 C/C++ 程序。通常 FE 挂掉的原因可能是 OOM（Out-of-Memory）或者是元数据写入失败。这些错误通常在 fe.log 或者 fe.out 中有错误堆栈。需要根据错误堆栈信息进一步排查。

Q7. 关于数据目录 SSD 和 HDD 的配置，建表有时候会遇到报错Failed to find enough host with storage medium and tag

Doris 支持一个 BE 节点配置多个存储路径。通常情况下，每块盘配置一个存储路径即可。同时，Doris 支持指定路径的存储介质属性，如 SSD 或 HDD。SSD 代表高速存储设备，HDD 代表低速存储设备。

如果集群只有一种介质比如都是 HDD 或者都是 SSD，最佳实践是不用在 be.conf 中显式指定介质属性。如果遇到上述报错Failed to find enough host with storage medium and tag，一般是因为 be.conf 中只配置了 SSD 的介质，而建表阶段中显式指定了properties {"storage_medium" = "hdd"}；同理如果 be.conf 只配置了 HDD 的介质，而而建表阶段中显式指定了properties {"storage_medium" = "ssd"}也会出现上述错误。解决方案可以修改建表的 properties 参数与配置匹配；或者将 be.conf 中 SSD/HDD 的显式配置去掉即可。

通过指定路径的存储介质属性，我们可以利用 Doris 的冷热数据分区存储功能，在分区级别将热数据存储在 SSD 中，而冷数据会自动转移到 HDD 中。

需要注意的是，Doris 并不会自动感知存储路径所在磁盘的实际存储介质类型。这个类型需要用户在路径配置中显式的表示。比如路径 “/path/to/data1.SSD” 即表示这个路径是 SSD 存储介质。而 “data1.SSD” 就是实际的目录名称。Doris 是根据目录名称后面的 “.SSD” 后缀来确定存储介质类型的，而不是实际的存储介质类型。也就是说，用户可以指定任意路径为 SSD 存储介质，而 Doris 仅识别目录后缀，不会去判断存储介质是否匹配。如果不写后缀，则默认为 HDD。

换句话说，“.HDD” 和 “.SSD” 只是用于标识存储目录“相对”的“低速”和“高速”之分，而并不是标识实际的存储介质类型。所以如果 BE 节点上的存储路径没有介质区别，则无需填写后缀。

Q8. 多个 FE，在使用 Nginx 实现 web UI 负载均衡时，无法登录

Doris 可以部署多个 FE，在访问 Web UI 的时候，如果使用 Nginx 进行负载均衡，因为 Session 问题会出现不停的提示要重新登录，这个问题其实是 Session 共享的问题，Nginx 提供了集中 Session 共享的解决方案，这里我们使用的是 nginx 中的 ip_hash 技术，ip_hash 能够将某个 ip 的请求定向到同一台后端，这样一来这个 ip 下的某个客户端和某个后端就能建立起稳固的 session，ip_hash 是在 upstream 配置中定义的：

```
upstream doris.com {
    server 172.22.197.238:8030 weight=3;
    server 172.22.197.239:8030 weight=4;
    server 172.22.197.240:8030 weight=4;
    ip_hash;
}
```

完整的 Nginx 示例配置如下：

```
user nginx;
worker_processes auto;
error_log /var/log/nginx/error.log;
pid /run/nginx.pid;

# Load dynamic modules. See /usr/share/doc/nginx/README.dynamic.
include /usr/share/nginx/modules/*.conf;

events {
    worker_connections 1024;
}

http {
    log_format main '$remote_addr - $remote_user [$time_local] "$request" '
        '$status $body_bytes_sent "$http_referer" '
        '"$http_user_agent" "$http_x_forwarded_for"';

    access_log /var/log/nginx/access.log main;

    sendfile on;
    tcp_nopush on;
    tcp_nodelay on;
    keepalive_timeout 65;
    types_hash_max_size 2048;

    include /etc/nginx/mime.types;
    default_type application/octet-stream;

    # Load modular configuration files from the /etc/nginx/conf.d directory.
    # See http://nginx.org/en/docs/nginx_core_module.html#include
    # for more information.
    include /etc/nginx/conf.d/*.conf;
    #include /etc/nginx/custom/*.conf;
```

```

upstream doris.com {
    server 172.22.197.238:8030 weight=3;
    server 172.22.197.239:8030 weight=4;
    server 172.22.197.240:8030 weight=4;
    ip_hash;
}

server {
    listen 80;
    server_name gaia-pro-bigdata-fe02;
    if ($request_uri ~ _load) {
        return 307 http://$host$request_uri ;
    }

    location / {
        proxy_pass http://doris.com;
        proxy_redirect default;
    }
    error_page 500 502 503 504 /50x.html;
    location = /50x.html {
        root html;
    }
}
}

```

Q9. FE 启动失败，fe.log 中一直滚动 “wait catalog to be ready. FE type UNKNOWN”

这种问题通常有两个原因：

1. 本次 FE 启动时获取到的本机 IP 和上次启动不一致，通常是因为没有正确设置 priority_network 而导致 FE 启动时匹配到了错误的 IP 地址。需修改 priority_network 后重启 FE。
2. 集群内多数 Follower FE 节点未启动。比如有 3 个 Follower，只启动了一个。此时需要将另外至少一个 FE 也启动，FE 可选举组方能选举出 Master 已提供服务。

如果以上情况都不能解决，可以按照 Doris 官网文档中的[元数据运维文档](#)进行恢复。

Q10. Lost connection to MySQL server at ‘reading initial communication packet’, system error: 0

如果使用 MySQL 客户端连接 Doris 时出现如下问题，这通常是因为编译 FE 时使用的 jdk 版本和运行 FE 时使用的 jdk 版本不同导致的。注意使用 docker 编译镜像编译时，默认的 JDK 版本是 openjdk 11，可以通过命令切换到 openjdk 8（详见编译文档）。

Q11. recoveryTracker should overlap or follow on disk last VLSN of 4,422,880 recoveryFirst=4,422,882 UNEXPECTED_STATE_FATAL

有时重启 FE，会出现如上错误（通常只会出现在多 Follower 的情况下）。并且错误中的两个数值相差 2。导致 FE 启动失败。

这是 bdbje 的一个 bug，尚未解决。遇到这种情况，只能通过[元数据运维文档](#)中的 故障恢复 进行操作来恢复元数据了。

Q12. Doris 编译安装 JDK 版本不兼容问题

在自己使用 Docker 编译 Doris 的时候，编译完成安装以后启动 FE，出现 `java.lang.NoSuchMethodError: java.nio.ByteBuffer.limit(I)Ljava/nio/ByteBuffer;` 异常信息，这是因为 Docker 里默认是 JDK 11，如果你的安装环境是使用 JDK8，需要在 Docker 里 JDK 环境切换成 JDK8，具体切换方法参照[编译文档](#)

Q13. 本地启动 FE 或者启动单元测试报错 `Cannot find external parser table action_table.dat`

执行如下命令

```
cd fe && mvn clean install -DskipTests
```

如果还报同样的错误，手动执行如下命令

```
cp fe-core/target/generated-sources/cup/org/apache/doris/analysis/action_table.dat fe-core/target/classes/org/apache/doris/analysis
```

Q14. Doris 升级到 1.0 以后版本通过 ODBC 访问 MySQL 外表报错 `Failed to set ciphers to use (2026)`

这个问题出现在 doris 升级到 1.0 版本以后，且使用 Connector/ODBC 8.0.x 以上版本，Connector/ODBC 8.0.x 有多种获取方式，比如通过 yum 安装的方式获取的 `/usr/lib64/libmyodbc8w.so` 依赖的是 `libssl.so.10` 和 `libcrypto.so.10` 而 doris 1.0 以后版本中 openssl 已经升级到 1.1 且内置在 doris 二进制包中，因此会导致 openssl 的冲突进而出现 类似 如下的错误

```
ERROR 1105 (HY000): errCode = 2, detailMessage = driver connect Error: HY000 [MySQL][ODBC 8.0(w) Driver]SSL connection error: Failed to set ciphers to use (2026)
```

解决方式是使用 Connector/ODBC 8.0.28 版本的 ODBC Connector，并且在操作系统处选择 Linux - Generic, 这个版本的 ODBC Driver 使用 openssl 1.1 版本。或者使用低版本的 ODBC Connector，比如 [Connector/ODBC 5.3.14](#)。具体使用方式见 [ODBC 外表使用文档](#)。

可以通过如下方式验证 MySQL ODBC Driver 使用的 openssl 版本

```
ldd /path/to/libmyodbc8w.so |grep libssl.so
```

如果输出包含 `libssl.so.10` 则使用过程中可能出现问题，如果包含 `libssl.so.1.1` 则与 doris 1.0 兼容

Q15. 升级到 1.2 版本，BE `NoClassDefFoundError` 问题启动失败

Java UDF 依赖错误从 Doris 1.2 版本后开始支持

如果升级后启动 be 出现下面这种 `Java NoClassDefFoundError` 错误

```
Exception in thread "main" java.lang.NoClassDefFoundError: org/apache/doris/udf/JniUtil
```

```
Caused by: java.lang.ClassNotFoundException: org.apache.doris.udf.JniUtil
```

需要从官网下载 `apache-doris-java-udf-jar-with-dependencies-1.2.0` 的 Java UDF 函数依赖包，放到 BE 安装目录下的 `lib` 目录，然后重新启动 BE

Q16. 升级到 1.2 版本，BE 启动显示 Failed to initialize JNI 问题

Java 环境问题从 Doris 1.2 版本后开始支持

如果升级后启动 BE 出现下面这种 Failed to initialize JNI 错误

```
Failed to initialize JNI: Failed to find the library libjvm.so.
```

需要在系统设置 `JAVA_HOME` 环境变量，或者在 `be.conf` 中设置 `JAVA_HOME` 变量，然后重新启动 BE 节点。

数据操作问题

数据操作问题

本文档主要用于记录 Doris 使用过程中的数据操作常见问题。会不定期更新。

Q1. 使用 Stream Load 访问 FE 的公网地址导入数据，被重定向到内网 IP？

当 stream load 的连接目标为 FE 的 http 端口时，FE 仅会随机选择一台 BE 节点做 http 307 redirect 操作，因此用户的请求实际是发送给 FE 指派的某一个 BE 的。而 redirect 返回的是 BE 的 ip，也即内网 IP。所以如果你是通过 FE 的公网 IP 发送的请求，很有可能因为 redirect 到内网地址而无法连接。

通常的做法，一种是确保自己能够访问内网 IP 地址，或者是给所有 BE 上层架设一个负载均衡，然后直接将 stream load 请求发送到负载均衡器上，由负载均衡将请求透传到 BE 节点。

Q2. Doris 是否支持修改列名？

在 1.2.0 版本之后，开启 "light_schema_change"="true" 选项时，可以支持修改列名。

在 1.2.0 版本之前或未开启 "light_schema_change"="true" 选项时，不支持修改列名，原因如下：

Doris 支持修改数据库名、表名、分区名、物化视图（Rollup）名称，以及列的类型、注释、默认值等等。但遗憾的是，目前不支持修改列名。

因为一些历史原因，目前列名称是直接写入到数据文件中的。Doris 在查询时，也是通过列名查找到对应的列的。所以修改列名不仅是简单的元数据修改，还会涉及到数据的重写，是一个非常重的操作。

我们不排除后续通过一些兼容手段来支持轻量化的列名修改操作。

Q3. Unique Key 模型的表是否支持创建物化视图？

不支持。

Unique Key 模型的表是一个对业务比较友好的表，因为其特有的按照主键去重的功能，能够很方便的同步数据频繁变更的业务数据库。因此，很多用户在将数据接入到 Doris 时，会首先考虑使用 Unique Key 模型。

但遗憾的是，Unique Key 模型的表是无法建立物化视图的。原因在于，物化视图的本质，是通过预计算来将数据“预先算好”，这样在查询时直接返回已经计算好的数据，来加速查询。在物化视图中，“预计算”的数据通常是一些聚合指标，比如求和、求 count。这时，如果数据发生变更，如 update 或 delete，因为预计算的数据已经丢失了明细信息，因此无法同步的进行更新。比如一个求和值 5，可能是 1+4，也可能是 2+3。因为明细信息的丢失，我们无法区分这个求和值是如何计算出来的，因此也就无法满足更新的需求。

Q4. tablet writer write failed, tablet_id=27306172, txn_id=28573520, err=-235 or -238

这个错误通常发生在数据导入操作中。错误码为 -235。这个错误的含义是，对应 tablet 的数据版本超过了最大限制（默认 500，由 BE 参数 max_tablet_version_num 控制），后续写入将被拒绝。比如问题中这个错误，即表示 27306172 这个 tablet 的数据版本超过了限制。

这个错误通常是因为导入的频率过高，大于后台数据的 compaction 速度，导致版本堆积并最终超过了限制。此时，我们可以先通过 `show tablet 27306172` 语句，然后执行结果中的 `show proc` 语句，查看 tablet 各个副本的情况。结果中的 `versionCount` 即表示版本数量。如果发现某个副本的版本数量过多，则需要降低导入频率或停止导入，并观察版本数是否有下降。如果停止导入后，版本数依然没有下降，则需要去对应的 BE 节点查看 `be.INFO` 日志，搜索 `tablet id` 以及 `compaction` 关键词，检查 `compaction` 是否正常运行。关于 `compaction` 调优相关，可以参阅 ApacheDoris 公众号文章：[Doris 最佳实践-Compaction 调优 \(3\)](#)

-238 错误通常出现在同一批导入数据量过大的情况，从而导致某一个 tablet 的 Segment 文件过多（默认是 200，由 BE 参数 `max_segment_num_per_rowset` 控制）。此时建议减少一批次导入的数据量，或者适当提高 BE 配置参数值来解决。在 2.0 版本及以后，可以通过打开 `segment compaction` 功能来减少 Segment 文件数量（BE config 中 `enable_segcompaction=true`）。

Q5. tablet 110309738 has few replicas: 1, alive backends: [10003]

这个错误可能发生在查询或者导入操作中。通常意味着对应 tablet 的副本出现了异常。

此时，可以先通过 `show backends` 命令检查 BE 节点是否有宕机，如 `isAlive` 字段为 `false`，或者 `LastStartTime` 是最近的某个时间（表示最近重启过）。如果 BE 有宕机，则需要去 BE 对应的节点，查看 `be.out` 日志。如果 BE 是因为异常原因宕机，通常 `be.out` 中会打印异常堆栈，帮助排查问题。如果 `be.out` 中没有错误堆栈。则可以通过 `linux` 命令 `dmesg -T` 检查是否是因为 OOM 导致进程被系统 kill 掉。

如果没有 BE 节点宕机，则需要通过 `show tablet 110309738` 语句，然后执行结果中的 `show proc` 语句，查看 tablet 各个副本的情况，进一步排查。

Q6. disk xxxxx on backend xxx exceed limit usage

通常出现在导入、Alter 等操作中。这个错误意味着对应 BE 的对应磁盘的使用量超过了阈值（默认 95%）此时可以先通过 `show backends` 命令，其中 `MaxDiskUsedPct` 展示的是对应 BE 上，使用率最高的那块磁盘的使用率，如果超过 95%，则会报这个错误。

此时需要前往对应 BE 节点，查看数据目录下的使用量情况。其中 `trash` 目录和 `snapshot` 目录可以手动清理以释放空间。如果是 `data` 目录占用较大，则需要考虑删除部分数据以释放空间了。具体可以参阅[磁盘空间管理](#)。

Q7. 通过 Java 程序调用 stream load 导入数据，在一批次数据量较大时，可能会报错 Broken Pipe

除了 Broken Pipe 外，还可能出现一些其他的奇怪的错误。

这个情况通常出现在开启 `httpv2` 后。因为 `httpv2` 是使用 `spring boot` 实现的 `http` 服务，并且使用 `tomcat` 作为默认内置容器。但是 `tomcat` 对 307 转发的处理似乎有些问题，所以后面将内置容器修改为了 `jetty`。此外，在 `java` 程序中的 `apache http client` 的版本需要使用 4.5.13 以后的版本。之前的版本，对转发的处理也存在一些问题。

所以这个问题可以有两种解决方式：

1. 关闭 httpv2

在 `fe.conf` 中添加 `enable_http_server_v2=false` 后重启 FE。但是这样无法再使用新版 UI 界面，并且之后的一些基于 `httpv2` 的新接口也无法使用。（正常的导入查询不受影响）。

2. 升级

可以升级到 Doris 0.15 及之后的版本，已修复这个问题。

Q8. 执行导入、查询时报错 -214

在执行导入、查询等操作时，可能会遇到如下错误：

```
failed to initialize storage reader. tablet=63416.1050661139.aa4d304e7a7aff9c-f0fa7579928c85a0, res=-214, backend=192.168.100.10
```

-214 错误意味着对应 tablet 的数据版本缺失。比如如上错误，表示 tablet 63416 在 192.168.100.10 这个 BE 上的副本的数据版本有缺失。（可能还有其他类似错误码，都可以用如下方式进行排查和修复）。

通常情况下，如果你的数据是多副本的，那么系统会自动修复这些有问题的副本。可以通过以下步骤进行排查：

首先通过 `show tablet 63416` 语句并执行结果中的 `show proc xxx` 语句来查看对应 tablet 的各个副本情况。通常我们需要关心 Version 这一列的数据。

正常情况下，一个 tablet 的多个副本的 Version 应该是相同的。并且和对应分区的 VisibleVersion 版本相同。

你可以通过 `show partitions from tblx` 来查看对应的分区版本（tablet 对应的分区可以在 `show tablet` 语句中获取。）

同时，你也可以访问 `show proc` 语句中的 `CompactionStatus` 列中的 URL（在浏览器打开即可）来查看更具体的版本信息，来检查具体丢失的是哪些版本。

如果长时间没有自动修复，则需要通过 `show proc "/cluster_balance"` 语句，查看当前系统正在执行的 tablet 修复和调度任务。可能是因为有大量的 tablet 在等待被调度，导致修复时间较长。可以关注 `pending_tablets` 和 `running_tablets` 中的记录。

更进一步的，可以通过 `admin repair` 语句来指定优先修复某个表或分区，具体可以参阅 `help admin repair`；

如果依然无法修复，那么多副本的情况下，我们使用 `admin set replica status` 命令强制将有问题的副本下线。具体可参阅 `help admin set replica status` 中将副本状态置为 `bad` 的示例。（置为 `bad` 后，副本将不会再被访问。并且会后续自动修复。但在操作前，应先确保其他副本是正常的）

Q9. Not connected to 192.168.100.1:8060 yet, server_id=384

在导入或者查询时，我们可能遇到这个错误。如果你去对应的 BE 日志中查看，也可能会找到类似错误。

这是一个 RPC 错误，通常有两种可能：1. 对应的 BE 节点宕机。2. rpc 拥塞或其他错误。

如果是 BE 节点宕机，则需要查看具体的宕机原因。这里只讨论 rpc 拥塞的问题。

一种情况是 `OVERCROWDED`，即表示 rpc 源端有大量未发送的数据超过了阈值。BE 有两个参数与之相关：

1. `brpc_socket_max_unwritten_bytes`：默认 1GB，如果未发送数据超过这个值，则会报错。可以适当修改这个值以避免 `OVERCROWDED` 错误。（但这个治标不治本，本质上还是有拥塞发生）。
2. `tablet_writer_ignore_eovercrowded`：默认为 `false`。如果设为 `true`，则 Doris 会忽略导入过程中出现的 `OVERCROWDED` 错误。这个参数主要为了避免导入失败，以提高导入的稳定性。

第二种是 rpc 的包大小超过 `max_body_size`。如果查询中带有超大 String 类型，或者 bitmap 类型时，可能出现这个问题。可以通过修改以下 BE 参数规避：

```
brpc_max_body_size: 默认 3GB.
```

Q10. [Broker load] org.apache.thrift.transport.TTransportException: java.net.SocketException: Broken pipe

出现这个问题的原因可能是到从外部存储（例如 HDFS）导入数据的时候，因为目录下文件太多，列出文件目录的时间太长，这里 Broker RPC Timeout 默认是 10 秒，这里需要适当调整超时时间。

修改 fe.conf 配置文件，添加下面的参数：

```
broker_timeout_ms = 10000
##这里默认是10秒，需要适当加大这个参数
```

这里添加参数，需要重启 FE 服务。

Q11.[Routine load] ReasonOfStateChanged: ErrorReason{code=errCode = 104, msg='be 10004 abort task with reason: fetch failed due to requested offset not available on the broker: Broker: Offset out of range'}

出现这个问题的原因是因为 kafka 的清理策略默认为 7 天，当某个 routine load 任务因为某种原因导致任务暂停，长时间没有恢复，当重新恢复任务的时候 routine load 记录了消费的 offset，而 kafka 的清理策略已经清理了对应的 offset，就会出现这个问题

所以这个问题可以用 alter routine load 解决方式：

查看 kafka 最小的 offset ,使用 ALTER ROUTINE LOAD 命令修改 offset，重新恢复任务即可

```
ALTER ROUTINE LOAD FOR db.tb
FROM kafka
(
  "kafka_partitions" = "0",
  "kafka_offsets" = "xxx",
  "property.group.id" = "xxx"
);
```

Q12. ERROR 1105 (HY000): errCode = 2, detailMessage = (192.168.90.91)[CANCELLED] [INTERNAL_ERROR]error setting certificate verify locations: CAfile: /etc/ssl/certs/ca-certificates.crt CApath: none

```
yum install -y ca-certificates
ln -s /etc/pki/ca-trust/extracted/openssl/ca-bundle.trust.crt /etc/ssl/certs/ca-certificates.crt
```

Q13. create partition failed. partition numbers will exceed limit variable max_auto_partition_num

对自动分区表导入数据时，为防止意外创建过多分区，我们使用了 FE 配置项max_auto_partition_num管控此类表自动创建时的最大分区数。如果确需创建更多分区，请修改 FE master 节点的该配置项。

Q14. Doris 在使用 Select Into Outfile 导出文件到本地时，是否可以导出到指定 BE 所在服务器？

不可以。使用 Select Into Outfile 导出文件到本地时，会随机导出到某个本地路径，不支持导出到指定路径。更多关于 Select Into Outfile 的信息，可参考 [Select Into Outfile](#)。

常见查询问题

SQL 问题

Q1. 查询报错: Failed to get scan range, no queryable replica found in tablet: xxxx

这种情况是因为对应的 tablet 没有找到可以查询的副本，通常原因可能是 BE 宕机、副本缺失等。可以先通过 `show tablet tablet_id` 语句，然后执行后面的 `show proc` 语句，查看这个 tablet 对应的副本信息，检查副本是否完整。同时还可以通过 `show proc "/cluster_balance"` 信息来查询集群内副本调度和修复的进度。

关于数据副本管理相关的命令，可以参阅 [数据副本管理](#)。

Q2. show backends/frontends 查看到的信息不完整

在执行如 `show backends/frontends` 等某些语句后，结果中可能会发现有部分列内容不全。比如 `show backends` 结果中看不到磁盘容量信息等。

通常这个问题会出现在集群有多个 FE 的情况下，如果用户连接到非 Master FE 节点执行这些语句，就会看到不完整的信息。这是因为，部分信息仅存在于 Master FE 节点。比如 BE 的磁盘使用量信息等。所以只有在直连 Master FE 后，才能获得完整信息。

当然，用户也可以在执行这些语句前，先执行 `set forward_to_master=true`；这个会话变量设置为 `true` 后，后续执行的一些信息查看类语句会自动转发到 Master FE 获取结果。这样，不论用户连接的是哪个 FE，都可以获取到完整结果了。

Q3. invalid cluster id: xxxx

这个错误可能会在 `show backends` 或 `show frontends` 命令的结果中出现。通常出现在某个 FE 或 BE 节点的错误信息列中。这个错误的含义是，Master FE 向这个节点发送心跳信息后，该节点发现心跳信息中携带的 `cluster id` 和本地存储的 `cluster id` 不同，所以拒绝回应心跳。

Doris 的 Master FE 节点会主动发送心跳给各个 FE 或 BE 节点，并且在心跳信息中会携带一个 `cluster_id`。`cluster_id` 是在一个集群初始化时，由 Master FE 生成的唯一集群标识。当 FE 或 BE 第一次收到心跳信息后，则会将 `cluster_id` 以文件的形式保存在本地。FE 的该文件在元数据目录的 `image/` 目录下，BE 则在所有数据目录下都有一个 `cluster_id` 文件。之后，每次节点收到心跳后，都会用本地 `cluster_id` 的内容和心跳中的内容作比对，如果不一致，则拒绝响应心跳。

该机制是一个节点认证机制，以防止接收到集群外的节点发送来的错误的心跳信息。

如果需要恢复这个错误。首先要先确认所有节点是否都是正确的集群中的节点。之后，对于 FE 节点，可以尝试修改元数据目录下的 `image/VERSION` 文件中的 `cluster_id` 值后重启 FE。对于 BE 节点，则可以删除所有数据目录下的 `cluster_id` 文件后重启 BE。

Q4. Unique Key 模型查询结果不一致

某些情况下，当用户使用相同的 SQL 查询一个 Unique Key 模型的表时，可能会出现多次查询结果不一致的现象。并且查询结果总在 2-3 种之间变化。

这可能是因为，在同一批导入数据中，出现了 key 相同但 value 不同的数据，这会导致，不同副本间，因数据覆盖的先后顺序不确定而产生的结果不一致的问题。

比如表定义为 k1, v1。一批次导入数据如下：

```
1, "abc"
1, "def"
```

那么可能副本 1 的结果是 1, "abc"，而副本 2 的结果是 1, "def"。从而导致查询结果不一致。

为了确保不同副本之间的数据先后顺序唯一，可以参考 [Sequence Column](#) 功能。

Q5. 查询 bitmap/hll 类型的数据返回 NULL 的问题

在 1.1.x 版本中，在开启向量化的情况下，执行查询数据表中 bitmap 类型字段返回结果为 NULL 的情况下，

1. 首先你要 set return_object_data_as_binary=true;
2. 关闭向量化 set enable_vectorized_engine=false;
3. 关闭 SQL 缓存 set [global] enable_sql_cache = false;

这里是因为 bitmap / hll 类型在向量化执行引擎中：输入均为 NULL，则输出的结果也是 NULL 而不是 0

Q6. 访问对象存储时报错：curl 77: Problem with the SSL CA cert

如果 be.INFO 日志中出现 curl 77: Problem with the SSL CA cert 错误。可以尝试通过以下方式解决：

1. 在 <https://curl.se/docs/caextract.html> 下载证书：cacert.pem
2. 拷贝证书到指定位置：sudo cp /tmp/cacert.pem /etc/ssl/certs/ca-certificates.crt
3. 重启 BE 节点。

Q7. 导入报错：“Message”：“[INTERNAL_ERROR]single replica load is disabled on BE.”

1. be.conf 中增加 enable_single_replica_load = true
2. 重启 BE 节点。

常见数据湖问题

证书问题

1. 查询时报错 `curl 77: Problem with the SSL CA cert.`。说明当前系统证书过旧，需要更新本地证书。
 - 可以从 <https://curl.haxx.se/docs/caextract.html> 下载最新的 CA 证书。
 - 将下载后的 `cacert-xxx.pem` 放到 `/etc/ssl/certs/` 目录，例如：`sudo cp cacert-xxx.pem /etc/ssl/certs/ca-certificates.crt`。
2. 查询时报错：`ERROR 1105 (HY000): errCode = 2, detailMessage = (x.x.x.x)[CANCELLED][INTERNAL_ERROR]error setting certificate verify locations: CAfile: /etc/ssl/certs/ca-certificates.crt CApath: none.`

```
yum install -y ca-certificates
ln -s /etc/pki/ca-trust/extracted/openssl/ca-bundle.trust.crt /etc/ssl/certs/ca-certificates.crt
```

Kerberos

1. 连接 Kerberos 认证的 Hive Metastore 报错：`GSS initiate failed`

通常是因为 Kerberos 认证信息填写不正确导致的，可以通过以下步骤排查：

1. 1.2.1 之前的版本中，Doris 依赖的 `libhdfs3` 库没有开启 `gsasl`。请更新至 1.2.2 之后的版本。
 2. 确认对各个组件，设置了正确的 `keytab` 和 `principal`，并确认 `keytab` 文件存在于所有 FE、BE 节点上。
 1. `hadoop.kerberos.keytab/hadoop.kerberos.principal`：用于 Hadoop hdfs 访问，填写 hdfs 对应的值。
 2. `hive.metastore.kerberos.principal`：用于 hive metastore。
 3. 尝试将 `principal` 中的 `ip` 换成域名（不要使用默认的 `_HOST` 占位符）
 4. 确认 `/etc/krb5.conf` 文件存在于所有 FE、BE 节点上。
2. 通过 Hive Catalog 连接 Hive 数据库报错：`RemoteException: SIMPLE authentication is not enabled. Available:[TOKEN, KERBEROS]`。

如果在 `show databases` 和 `show tables` 都是没问题的情况下，查询的时候出现上面的错误，我们需要进行下面两个操作：

- `fe/conf`、`be/conf` 目录下需放置 `core-site.xml` 和 `hdfs-site.xml`
 - BE 节点执行 Kerberos 的 `kinit` 然后重启 BE，然后再去执行查询即可。
3. 查询配置了 Kerberos 的外表，遇到该报错：`GSSException: No valid credentials provided (Mechanism level: Failed to find any Kerberos Ticket)`，一般重启 FE 和 BE 能够解决该问题。

- 重启所有节点前可在"\${DORIS_HOME}/be/conf/be.conf"中的 JAVA_OPTS 参数里配置-Djavax.security.auth.useSubjectCredsOnly=false，通过底层机制去获取 JAAS credentials 信息，而不是应用程序。
- 在[JAAS Troubleshooting](#)中可获取更多常见 JAAS 报错的解决方法。

4. 在 Catalog 中配置 Kerberos 时，报错Unable to obtain password from user的解决方法：

- 用到的 principal 必须在 klist 中存在，使用klist -kt your.keytab检查。
- 检查 catalog 配置是否正确，比如漏配yarn.resourcemanager.principal。
- 若上述检查没问题，则当前系统 yum 或者其他包管理软件安装的 JDK 版本存在不支持的加密算法，建议自行安装 JDK 并设置JAVA_HOME环境变量。
- Kerberos 默认使用 AES-256 来进行加密。如果使用 Oracle JDK，则必须安装 JCE。如果是 OpenJDK，OpenJDK 的某些发行版会自动提供无限强度的 JCE，因此不需要安装 JCE。
- JCE 与 JDK 版本是对应的，需要根据 JDK 的版本来选择 JCE 版本，下载 JCE 的 zip 包并解压到 \$JAVA_HOME/jre/lib/security目录下：
 - JDK6: [JCE6](#)
 - JDK7: [JCE7](#)
 - JDK8: [JCE8](#)

5. 使用 KMS 访问 HDFS 时报错：java.security.InvalidKeyException: Illegal key size

升级 JDK 版本到 >= Java 8 u162 的版本。或者下载安装 JDK 相应的 JCE Unlimited Strength Jurisdiction Policy Files。

6. 在 Catalog 中配置 Kerberos 时，如果报错SIMPLE authentication is not enabled. Available: [TOKEN, KERBEROS]，那么需要将core-site.xml文件放到"\${DORIS_HOME}/be/conf"目录下。

如果访问 HDFS 报错No common protection layer between client and server，检查客户端和服务端的hadoop.rpc.protection属性，使他们保持一致。

```
<?xml version="1.0" encoding="UTF-8"?>
<?xml-stylesheet type="text/xsl" href="configuration.xsl"?>

<configuration>

  <property>
    <name>hadoop.security.authentication</name>
    <value>kerberos</value>
  </property>

</configuration>
```

7. 在使用 Broker Load 时，配置了 Kerberos，如果报错Cannot locate default realm.。

将-Djava.security.krb5.conf=/your-path 配置项添加到 Broker Load 启动脚本的 start_broker.sh 的 JAVA_OPTS里。

8. 当在 Catalog 里使用 Kerberos 配置时，不能同时使用hadoop.username属性。

9. 使用 JDK 17 访问 Kerberos

如果使用 JDK 17 运行 Doris 并访问 Kerberos 服务，可能会出现因使用已废弃的加密算法而导致无法访问的现象。需要在 krb5.conf 中添加 allow_weak_crypto=true 属性。或升级 Kerberos 的加密算法。

详情参阅: <https://seanjmullan.org/blog/2021/09/14/jdk17#kerberos>

JDBC Catalog

1. 通过 JDBC Catalog 连接 SQLServer 报错: unable to find valid certification path to requested target

请在 jdbc_url 中添加 trustServerCertificate=true 选项。

2. 通过 JDBC Catalog 连接 MySQL 数据库, 中文字符乱码, 或中文字符条件查询不正确

请在 jdbc_url 中添加 useUnicode=true&characterEncoding=utf-8

注: 1.2.3 版本后, 使用 JDBC Catalog 连接 MySQL 数据库, 会自动添加这些参数。

3. 通过 JDBC Catalog 连接 MySQL 数据库报错: Establishing SSL connection without server's identity verification is not recommended

请在 jdbc_url 中添加 useSSL=true

4. 使用 JDBC Catalog 将 MySQL 数据同步到 Doris 中, 日期数据同步错误。需要校验下 MySQL 的版本是否与 MySQL 的驱动包是否对应, 比如 MySQL8 以上需要使用驱动 com.mysql.cj.jdbc.Driver。

5. 单个字段过大, 查询时 BE 侧 Java 内存 OOM

Jdbc Scanner 在通过 jdbc 读取时, 由 session variable batch_size 决定每批次数据在 JVM 中处理的数量, 如果单个字段过大, 导致 字段大小 * batch_size(近似值, 由于 JVM 中 static 以及数据 copy 占用) 超过 JVM 内存限制, 就会出现 OOM。

解决方法:

- 减小 batch_size 的值, 可以通过 set batch_size = 512; 来调整, 默认值为 4064。
- 增大 BE 的 JVM 内存, 通过修改 JAVA_OPTS 参数中的 -Xmx 来调整 JVM 最大堆内存大小。例如: "-Xmx8g。

Hive Catalog

1. 通过 Hive Metastore 访问 Iceberg 表报错: failed to get schema 或 Storage schema reading not supported

在 Hive 的 lib/ 目录放上 iceberg 运行时有关的 jar 包。

在 hive-site.xml 配置:

```
metastore.storage.schema.reader.impl=org.apache.hadoop.hive.metastore.SerdeStorageSchemaReader
```

配置完成后需要重启 Hive Metastore。

2. 连接 Hive Catalog 报错: Caused by: java.lang.NullPointerException

如 fe.log 中有如下堆栈：

```
Caused by: java.lang.NullPointerException
    at
    org.apache.hadoop.hive.ql.security.authorization.plugin.AuthorizationMetaStoreFilterHook.getFilteredOb
jects(AuthorizationMetaStoreFilterHook.java:78) ~[hive-exec-3.1.3-core.jar:3.1.3]
    at
    org.apache.hadoop.hive.ql.security.authorization.plugin.AuthorizationMetaStoreFilterHook.filterDatabas
es(AuthorizationMetaStoreFilterHook.java:55) ~[hive-exec-3.1.3-core.jar:3.1.3]
    at
    org.apache.hadoop.hive.metastore.HiveMetaStoreClient.getAllDatabases(HiveMetaStoreClient.java:1548) ~
[doris-fe.jar:3.1.3]
    at
    org.apache.hadoop.hive.metastore.HiveMetaStoreClient.getAllDatabases(HiveMetaStoreClient.java:1542) ~
[doris-fe.jar:3.1.3]
    at sun.reflect.NativeMethodAccessorImpl.invoke0(Native Method) ~[?:1.8.0_181]
```

可以尝试在 create catalog 语句中添加 "metastore.filter.hook" =
"org.apache.hadoop.hive.metastore.DefaultMetaStoreFilterHookImpl" 解决。

3. 如果创建 Hive Catalog 后能正常 show tables，但查询时报 java.net.UnknownHostException: xxxxxx

可以在 CATALOG 的 PROPERTIES 中添加

```
'fs.defaultFS' = 'hdfs://<your_nameservice_or_actually_HDFS_IP_and_port>'
```

4. Hive 1.x 的 orc 格式的表可能会遇到底层 orc 文件 schema 中列名为 _col0, _col1, _col2... 这类系统列名，此时需要在 catalog 配置中添加 hive.version 为 1.x.x，这样就会使用 hive 表中的列名进行映射。

```
CREATE CATALOG hive PROPERTIES (
    'hive.version' = '1.x.x'
);
```

5. 使用 Catalog 查询表数据时发现与 Hive Metastore 相关的报错：Invalid method name，需要设置 hive.version 参数。

```
CREATE CATALOG hive PROPERTIES (
    'hive.version' = '2.x.x'
);
```

6. 查询 ORC 格式的表，FE 报错 Could not obtain block 或 Caused by:
java.lang.NoSuchFieldError: types

对于 ORC 文件，在默认情况下，FE 会访问 HDFS 获取文件信息，进行文件切分。部分情况下，FE 可能无法访问到 HDFS。可以通过添加以下参数解决：

```
"hive.exec.orc.split.strategy" = "BI"
```

其他选项：HYBRID（默认），ETL。

7. 在 hive 上可以查到 hudi 表分区字段的值，但是在 doris 查不到。

doris 和 hive 目前查询 hudi 的方式不一样，doris 需要在 hudi 表结构的 avsc 文件里添加上分区字段，如果没加，就会导致 doris 查询 partition_val 为空（即使设置了 hoodie.datasource.hive_sync.partition_fields=partition_val 也不可以）

```
{
  "type": "record",
  "name": "record",
  "fields": [{
    "name": "partition_val",
    "type": [
      "null",
      "string"
    ],
    "doc": "Preset partition field, empty string when not partitioned",
    "default": null
  },
  {
    "name": "name",
    "type": "string",
    "doc": "Name"
  },
  {
    "name": "create_time",
    "type": "string",
    "doc": "Creation time"
  }
]
}
```

8. 查询 hive 外表，遇到该报错：java.lang.ClassNotFoundException: Class com.hadoop.compression.lzo.LzoCodec not found

去 hadoop 环境搜索hadoop-lzo-*.jar放在"\${DORIS_HOME}/fe/lib/"目录下并重启 fe。

从 2.0.2 版本起，可以将这个文件放置在 FE 的 custom_lib/ 目录下（如不存在，手动创建即可），以防止升级集群时因为 lib 目录被替换而导致文件丢失。

9. 创建 hive 表指定 serde 为 org.apache.hadoop.hive.contrib.serde2.MultiDelimitserDe，访问表时报错：storage schema reading not supported

在 hive-site.xml 文件中增加以下配置，并重启 hms 服务：

```
<property>
  <name>metastore.storage.schema.reader.impl</name>
  <value>org.apache.hadoop.hive.metastore.SerDeStorageSchemaReader</value>
</property>
```

10. 报错：java.security.InvalidAlgorithmParameterException: the trustAnchors parameter must be non-empty

FE 日志中完整报错信息如下：

```
org.apache.doris.common.UserException: errCode = 2, detailMessage = S3 list path failed.
path=s3://bucket/part-*,msg=errors while get file status listStatus on s3://bucket:
com.amazonaws.SdkClientException: Unable to execute HTTP request: Unexpected error:
java.security.InvalidAlgorithmParameterException: the trustAnchors parameter must be non-empty: Unable
to execute HTTP request: Unexpected error: java.security.InvalidAlgorithmParameterException: the
```

```
trustAnchors parameter must be non-empty
org.apache.doris.common.UserException: errCode = 2, detailMessage = S3 list path exception.
path=s3://bucket/part-*, err: errCode = 2, detailMessage = S3 list path failed. path=s3://bucket/part-
*,msg=errors while get file status listStatus on s3://bucket: com.amazonaws.SdkClientException: Unable
to execute HTTP request: Unexpected error: java.security.InvalidAlgorithmParameterException: the
trustAnchors parameter must be non-empty: Unable to execute HTTP request: Unexpected error:
java.security.InvalidAlgorithmParameterException: the trustAnchors parameter must be non-empty
org.apache.hadoop.fs.s3a.AWSClietIOException: listStatus on s3://bucket:
com.amazonaws.SdkClientException: Unable to execute HTTP request: Unexpected error:
java.security.InvalidAlgorithmParameterException: the trustAnchors parameter must be non-empty: Unable
to execute HTTP request: Unexpected error: java.security.InvalidAlgorithmParameterException: the
trustAnchors parameter must be non-empty
Caused by: com.amazonaws.SdkClientException: Unable to execute HTTP request: Unexpected error:
java.security.InvalidAlgorithmParameterException: the trustAnchors parameter must be non-empty
Caused by: javax.net.ssl.SSLException: Unexpected error:
java.security.InvalidAlgorithmParameterException: the trustAnchors parameter must be non-empty
Caused by: java.lang.RuntimeException: Unexpected error:
java.security.InvalidAlgorithmParameterException: the trustAnchors parameter must be non-empty
Caused by: java.security.InvalidAlgorithmParameterException: the trustAnchors parameter must be non-
empty
```

尝试更新FE节点CA证书，使用 update-ca-trust (CentOS/RockyLinux)，然后重启FE进程即可。

11. BE 报错：java.lang.InternalError

如果在 be.INFO 中看到类似如下错误：

```
W20240506 15:19:57.553396 266457 jni-util.cpp:259] java.lang.InternalError
    at org.apache.hadoop.io.compress.zlib.ZlibDecompressor.init(Native Method)
    at org.apache.hadoop.io.compress.zlib.ZlibDecompressor.<init>(ZlibDecompressor.java:114)
    at org.apache.hadoop.io.compress.GzipCodec$GzipZlibDecompressor.<init>(GzipCodec.java:229)
    at org.apache.hadoop.io.compress.GzipCodec.createDecompressor(GzipCodec.java:188)
    at org.apache.hadoop.io.compress.CodecPool.getDecompressor(CodecPool.java:183)
    at org.apache.parquet.hadoop.CodecFactory$HeapBytesDecompressor.<init>(CodecFactory.java:99)
    at org.apache.parquet.hadoop.CodecFactory.createDecompressor(CodecFactory.java:223)
    at org.apache.parquet.hadoop.CodecFactory.getDecompressor(CodecFactory.java:212)
    at org.apache.parquet.hadoop.CodecFactory.getDecompressor(CodecFactory.java:43)
```

是因为 Doris 自带的 libz.a 和系统环境中的 libz.so 冲突了。

为了解决这个问题，需要先执行 `export LD_LIBRARY_PATH=/path/to/be/lib:$LD_LIBRARY_PATH` 然后重启 BE 进程。

HDFS

1. 访问 HDFS 3.x 时报错：java.lang.VerifyError: xxx

1.2.1 之前的版本中，Doris 依赖的 Hadoop 版本为 2.8。需更新至 2.10.2。或更新 Doris 至 1.2.2 之后的版本。

2. 使用 Hedged Read 优化 HDFS 读取慢的问题。

在某些情况下，HDFS 的负载较高可能导致读取某个 HDFS 上的数据副本的时间较长，从而拖慢整体的查询效率。HDFS Client 提供了 Hedged Read 功能。该功能可以在一个读请求超过一定阈值未返回时，启动另一个读线程读取同一份数据，哪个先返回就是用哪个结果。

注意：该功能可能会增加 HDFS 集群的负载，请酌情使用。

可以通过以下两种方式开启这个功能：

- 在创建 Catalog 的参数中指定：

```
create catalog regression properties (  
  'type'='hms',  
  'hive.metastore.uris' = 'thrift://172.21.16.47:7004',  
  'dfs.client.hedged.read.threadpool.size' = '128',  
  'dfs.client.hedged.read.threshold.millis' = "500"  
);
```

`dfs.client.hedged.read.threadpool.size` 表示用于 Hedged Read 的线程数，这些线程由一个 HDFS Client 共享。通常情况下，针对一个 HDFS 集群，BE 节点会共享一个 HDFS Client。

`dfs.client.hedged.read.threshold.millis` 是读取阈值，单位毫秒。当一个读请求超过这个阈值未返回时，会触发 Hedged Read。

开启后，可以在 Query Profile 中看到相关参数：

TotalHedgedRead: 发起 Hedged Read 的次数。

HedgedReadWins: Hedged Read 成功的次数（发起并且比原请求更快返回的次数）

注意，这里的值是单个 HDFS Client 的累计值，而不是单个查询的数值。同一个 HDFS Client 会被多个查询复用。

3. Couldn't create proxy provider class

`org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider`

在 FE 和 BE 的 start 脚本中，会将环境变量 `HADOOP_CONF_DIR` 加入 `CLASSPATH`。如果 `HADOOP_CONF_DIR` 设置错误，比如指向了不存在的路径或错误路径，则可能加载到错误的 `xxx-site.xml` 文件，从而读取到错误的信息。

需检查 `HADOOP_CONF_DIR` 是否配置正确，或将这个环境变量删除。

4. BlockMissingExcetpion: Could not obtain block: BP-XXXXXXXXX No live nodes contain current block

可能的处理方式有：

- 通过 `hdfs fsck file -files -blocks -locations` 来查看具体该文件是否健康。
- 通过 `telnet` 来检查与 `datanode` 的连通性。
- 查看 `datanode` 日志。

如果出现以下错误：

`org.apache.hadoop.hdfs.server.datanode.DataNode: Failed to read expected SASL data transfer protection handshake from client at /XXX.XXX.XXX.XXX:XXXXX. Perhaps the client is running an older version of Hadoop which does not support SASL data transfer protection` 则为当前 `hdfs` 开启了加密传输方式，而客户端未开启导致的错误。

使用下面的任意一种解决方案即可：

- 拷贝 `hdfs-site.xml` 以及 `core-site.xml` 到 `be/conf` 和 `fe/conf` 目录。(推荐)

- 在 `hdfs-site.xml` 找到相应的配置 `dfs.data.transfer.protection`，并且在 `catalog` 里面设置该参数。

DLF Catalog

1. 使用 DLF Catalog 时，BE 读在取 JindoFS 数据出现 `Invalid address`，需要在 `/etc/hosts` 中添加日志中出现的域名到 IP 的映射。
2. 读取数据无权限时，使用 `hadoop.username` 属性指定有权限的用户。
3. DLF Catalog 中的元数据和 DLF 保持一致。当使用 DLF 管理元数据时，Hive 新导入的分区，可能未被 DLF 同步，导致出现 DLF 和 Hive 元数据不一致的情况，对此，需要先保证 Hive 元数据被 DLF 完全同步。

其他问题

1. Binary 类型映射到 Doris 后，查询乱码

Doris 原生不支持 Binary 类型，所以各类数据湖或数据库中的 Binary 类型映射到 Doris 中，通常使用 String 类型进行映射。String 类型只能展示可打印字符。如果需要查询 Binary 的内容，可以使用 `T0_BASE64()` 函数转换为 Base64 编码后，在进行下一步处理。

2. 分析 Parquet 文件

在查询 Parquet 文件时，由于不同系统生成的 Parquet 文件格式可能有所差异，比如 RowGroup 的数量，索引的值等，有时需要检查 Parquet 文件的元数据进行问题定位或性能分析。这里提供一个工具帮助用户更方便的分析 Parquet 文件：

1. 下载并解压 [Apache Parquet Cli 1.14.0](#)
2. 将需要分析的 Parquet 文件下载到本地，假设路径为 `/path/to/file.parquet`
3. 使用如下命令分析 Parquet 文件元信息：

```
./parquet-tools meta /path/to/file.parquet
```
4. 更多功能，可参阅 [Apache Parquet Cli 文档](#)

常见BI问题

Power BI

Q1. JDBC 拉取表到 Desktop Power BI 时报错 Timeout expired. The timeout period elapsed prior to completion of the operation or the server is not responding.

通常这是 Power BI 在拉取数据源的时间超时，在填写数据源服务器和数据库时点击高级选项，其中有个超时时间，把该时间配置的较高。

Q2. 2.1.x 版本 JDBC 连接 Power BI 时报错读取数据时报错，给定的关键字目前不在字典中。

先在数据库中执行 show collation，一般情况下会只有 utf8mb4_900_bin，charset 为 utf8mb4 这一行结果。该报错的主要原因是在连接 Power BI 时需要找33号 ID，即需要该表中有33 ID 的行，需要升级至2.1.5版本以上。

Q3. 连接时报错从提供程序读取数据时出错：索引和计数必须引用该字符串内的位置。

该问题原因是连接过程会加载全局参数，该 SQL 出现了列名和 values 相同的情况

```
SELECT
@@max_allowed_packet as max_allowed_packet, @@character_set_client ,@@character_set_connection ,
@@license,@@sql_mode ,@@lower_case_table_names , @@autocommit ;
```

可以在当前版本关闭新优化器也可以升级到2.0.7或者2.1.6及以上版本。

Q4. JDBC 连接2.1.x 版本报错从提供读取数据时出错：“Character set ‘utf8mb3’ is not supported by .Net.Framework”。

该问题易在2.1.x 版本遇到，如果遇到该问题则需要把 JDBC Driver 升级到8.0.32。

Tableau

Q1. 2.0.x报错Tableau无法连接到数据源，错误代码：37CE01A3。

在当前版本关闭新优化器或者升级至2.0.7及以上版本。

Q2. 报错 SSL connection error:protocol version mismatch 无法连接到 MySQL 服务器。

该报错原因是 Doris 开启了 SSL 验证，但是连接过程中未使用 SSL 连接，需要在 fe.conf 里面关闭 enable_ssl 变量。

Q3. 连接时报错 Unsupported command (COM_STMT_PREPARED)。

MySQL 驱动版本安装不恰当，需要改安装为 MySQL5.1.x 版本的连接驱动。

数据正确性问题

数据正确性问题

本文档主要用于记录 Doris 使用过程中关于数据正确性的常见问题。会不定期更新。

表格中的“表出现重复 key 数据”均指在 merge-on-write Unique 表中出现重复 key 数据。merge-on-write Unique 表上的重复 key 问题都可以通过[触发full compaction](#)来进行修复，其他类型的正确性问题可能需要根据情况来确定修复方案，如有需要，请联系社区支持。

问题现象	发生条件	影响版本	Fix 版本	影响范围	Fix PR
使用 Stream Load 向 merge-on-write Unique 导入数据时，对于满足 delete 参数所指定的删除条件的数据，导入后没有被删除掉	使用 Stream Load 导入数据时，设置了 merge_type: MERGE, partial_columns: true 和 delete 参数	<2.0.15	>=2.0.15	部分列更新	#40730
表出现重复 key 数据	用户使用 ALTER TABLE tbl ENABLE FEATURE "SEQUENCE_LOAD" WITH ... 语句给一个不支持 sequence 列的 merge-on-write Unique 表添加了 sequence 列功能并且之后有新的导入	<2.0.15	>=2.0.15		#39958
使用部分列更新导入后，merge-on-write Unique 表中部分数据错乱	merge-on-write Unique 表上有并发的部分列更新导入，并且导入过程中有 BE 重启	<2.0.15	>=2.0.15	部分列更新	#38331
表出现重复 key 数据	merge-on-write Unique 表上有 sequence 列，表上存在单次数据量很大的导入，且触发了 segment compaction	<2.0.15	>=2.0.15		#38369
表出现重复 key 数据	存算一体模式下 merge-on-write Unique 表上有失败的 full clone	<2.0.13	>=2.0.13		#37001

问题现象	发生条件	影响版本	Fix 版本	影响范围	Fix PR
merge-on-write Unique 表上多副本 数据不一致	merge-on-write Unique 表上有过指定了 __DORIS_DELETE_S IGN__列的部分列更新导入，且在导入的时候不同副本上 Base Compaction 进度不一致	<2.0.15	>=2.0.15	部分列更新	#36210
表出现重复 key 数据	merge-on-write Unique 表上有并发的部分列更新导入，并且导入过程中有 BE 重启	<2.0.11	>=2.0.11	部分列更新	#35739

数据类型概览

数值类型

包括以下 4 种：

1. BOOLEAN 类型：

两种取值，0 代表 false，1 代表 true。更多信息参考 [BOOLEAN 文档](#)。

2. 整数类型：

都是有符号整数，xxINT 的差异是占用字节数和表示范围

- TINYINT 占 1 字节，范围 [-128, 127]，更多信息参考 [TINYINT 文档](#)。
- SMALLINT 占 2 字节，范围 [-32768, 32767]，更多信息参考 [SMALLINT 文档](#)。
- INT 占 4 字节，范围 [-2147483648, 2147483647]，更多信息参考 [INT 文档](#)。
- BIGINT 占 8 字节，范围 [-9223372036854775808, 9223372036854775807]，更多信息参考 [BIGINT 文档](#)。
- LARGEINT 占 16 字节，范围 $[-2^{127}, 2^{127} - 1]$ ，更多信息参考 [LARGEINT 文档](#)。

3. 浮点数类型：

不精确的浮点数类型 FLOAT 和 DOUBLE，和常见编程语言中的 float 和 double 对应。更多信息参考 [FLOAT](#)、[DOUBLE](#) 文档。

4. 定点数类型：

精确的定点数类型 DECIMAL，用于金融等精度要求严格准确的场景。更多信息参考 [DECIMAL 文档](#)。

日期类型

日期类型包括 DATE、TIME 和 DATETIME，DATE 类型只存储日期精确到天，DATETIME 类型存储日期和时间，可以精确到微秒。TIME 类型只存储时间，且暂时不支持建表存储，只能在查询过程中使用。

对日期类型进行计算，或将其转换为数字，请使用类似 [TIME_TO_SEC](#)、[DATE_DIFF](#)、[UNIX_TIMESTAMP](#) 等函数，直接将其 CAST 为数字类型的结果不受保证。在未来的版本中，此类 CAST 行为将会被禁止。

更多信息参考 [DATE](#)、[TIME](#) 和 [DATETIME](#) 文档。

字符串类型

字符串类型支持定长和不定长，总共有以下 3 种：

1. [CHAR\(M\)](#)：定长字符串，固定长度 M 字节，M 的范围是 [1, 255]。

2. **STRING**: 不定长字符串, 默认最长 1048576 字节 (1MB), 可调大到 2147483643 字节 (2GB), BE 配置 `string_type_length_soft_limit_bytes`。

半结构化类型

针对 JSON 半结构化数据, 支持 3 类不同场景的半结构化数据类型:

1. 支持嵌套的固定 schema, 适合分析的数据类型 **ARRAY**、**MAP STRUCT**: 常用于用户行为和画像分析, 湖仓一体查询数据湖中 Parquet 等格式的数据等场景。由于 schema 相对固定, 没有动态 schema 推断的开销, 写入和分析性能很高。
2. 支持嵌套的不固定 schema, 适合分析的数据类型 **VARIANT**: 常用于 Log, Trace, IoT 等分析场景, schema 灵活可以写入任何合法的 JSON 数据, 并自动展开成子列采用列式存储, 存储压缩率高, 聚合过滤排序等分析性能很好。
3. 支持嵌套的不固定 schema, 适合点查的数据类型 **JSON**: 常用于高并发点查场景, schema 灵活可以写入任何合法的 JSON 数据, 采用二进制格式存储, 提取字段的性能比普通 JSON String 快 2 倍以上。

聚合类型

聚合类型存储聚合的结果或者中间状态, 用于加速聚合查询, 包括下面几种:

1. **BITMAP**: 用于精确去重, 如 UV 统计, 人群圈选等场景。配合 `bitmap_union`、`bitmap_union_count`、`bitmap_hash`、`bitmap_hash64` 等 BITMAP 函数使用。
2. **HLL**: 用于近似去重, 性能优于 COUNT DISTINCT。配合 `hll_union_agg`、`hll_raw_agg`、`hll_cardinality`、`hll_hash` 等 HLL 函数使用。
3. **QUANTILE STATE**: 用于分位数近似计算, 性能优于 PERCENTILE。配合 `QUANTILE_PERCENT`、`QUANTILE_UNION`、`TO_QUANTILE_STATE` 等函数使用。
4. **AGG STATE**: 用于聚合计算加速, 配合 `state/merge/union` 聚合函数组合器使用。

BOOLEAN

描述

BOOL, BOOLEAN
与TINYINT一样, 0代表false, 1代表true

TINYINT

描述

<div>TINYINT</div> <div>1字节有符号整数，范围[-128，127]</div>

SMALLINT

描述

<div><div>SMALLINT</div><div>2字节有符号整数，范围[-32768, 32767]</div></div>

INT

描述

<div>INT</div> <div>4字节有符号整数，范围[-2147483648, 2147483647]</div>
--

BIGINT

描述

<div><div>BIGINT</div><div>8字节有符号整数，范围[-9223372036854775808, 9223372036854775807]</div></div>

LARGEINT

描述

<div><div>LARGEINT</div><div>16字节有符号整数，范围 $[-2^{127} + 1 \sim 2^{127} - 1]$</div></div>
--

FLOAT

描述

<div><div>FLOAT</div><div>4字节浮点数</div></div>
--

DOUBLE

描述

DOUBLE 8字节浮点数

DECIMAL

描述

DECIMAL(M,D)

高精度定点数，M 代表一共有多少个有效数字(precision)，D 代表小数位有多少数字(scale)，有效数字 M 的范围是 [1, 38]，小数位数字数量 D 的范围是 [0, precision]。

默认值为 DECIMAL(9, 0)。

精度推演

DECIMAL 有一套很复杂的类型推演规则，针对不同的表达式，会应用不同规则进行精度推断。

四则运算

- 加法 / 减法：DECIMAL(a, b) + DECIMAL(x, y) -> DECIMAL(max(a - b, x - y) + max(b, y) + 1, max(b, y))。
- 乘法：DECIMAL(a, b) * DECIMAL(x, y) -> DECIMAL(a + x, b + y)。
- 除法：DECIMAL(p1, s1) / DECIMAL(p2, s2) -> DECIMAL(p1 + s2 + div_precision_increment, s1 + div_precision_increment)。div_precision_increment 默认为 4。值得注意的是，除法计算的过程是 DECIMAL(p1, s1) / DECIMAL(p2, s2) 先转换成 DECIMAL(p1 + s2 + div_precision_increment, s1 + s2) / DECIMAL(p2, s2) 然后再进行计算，所以可能会出现 DECIMAL(p1 + s2 + div_precision_increment, s1 + div_precision_increment) 是满足 DECIMAL 的范围，但是由于先转换成了 DECIMAL(p1 + s2 + div_precision_increment, s1 + s2) 导致超出范围，目前 Doris 的处理是转成 Double 进行计算

聚合运算

- SUM / MULTI_DISTINCT_SUM: SUM(DECIMAL(a, b)) -> DECIMAL(38, b)。
- AVG: AVG(DECIMAL(a, b)) -> DECIMAL(38, max(b, 4))。

默认规则

除上述提到的函数外，其余表达式都使用默认规则进行精度推演。即对于表达式 `expr(DECIMAL(a, b))`，结果类型同样也是 DECIMAL(a, b)。

调整结果精度

不同用户对 DECIMAL 的精度要求各不相同，上述规则为当前 Doris 的默认行为，如果用户有不同的精度需求，可以通过以下方式进行精度调整：1. 如果期望的结果精度大于默认精度，可以通过调整入参精度来调整结果精度。例如用户期望计算 `AVG(col)` 得到 DECIMAL(x, y) 作为结果，其中 col 的类型为 DECIMAL(a, b)，则可以改写表达式为 `AVG(CAST(col as DECIMAL(x, y)))`。2. 如果期望的结果精度小于默认精度，可以通过对输出结果求近似得到想要的精度。例如用户期望计算 `AVG(col)` 得到 DECIMAL(x, y) 作为结果，其中 col 的类型为 DECIMAL(a, b)，则可以改写表达式为 `ROUND(AVG(col), y)`。

为什么需要 DECIMAL

Doris 中的 DECIMAL 是真正意义上的高精度定点数，Decimal 有以下核心优势： 1. 可表示范围更大。DECIMAL 中 precision 和 scale 的取值范围都进行了明显扩充。 2. 性能更高。老版本的 DECIMAL 在内存中需要占用 16 bytes，在存储中占用 12 bytes，而 DECIMAL 进行了自适应调整（如下表格）。

precision	占用空间（内存/磁盘）
0 < precision <= 9	4 bytes
9 < precision <= 18	8 bytes
18 < precision <= 38	16 bytes

3. 更完备的精度推演。对于不同的表达式，应用不同的精度推演规则对结果的精度进行推演。

DATE

描述

DATE类型
日期类型，目前的取值范围是['0000-01-01', '9999-12-31']，默认的打印形式是'yyyy-MM-dd'

举例

```
SELECT DATE('2003-12-31 01:02:03');
+-----+
| DATE('2003-12-31 01:02:03') |
+-----+
| 2003-12-31                  |
+-----+
```

TIME

描述

TIME 类型 时间类型，可以作为查询结果出现，暂时不支持建表存储。表示范围为 [-838:59:59, 838:59:59]。当前 Doris 中，TIME 作为计算结果的正确性是有保证的（如 timediff 等函数），但不推荐手动 CAST 产生 TIME 类型。TIME 类型不会在常量折叠中进行计算。

举例

```
mysql> select timediff('2020-01-01 12:05:03', '2020-01-01 08:02:15');
+-----+
| timediff(cast('2020-01-01 12:05:03' as DATETIMEV2(0)), cast('2020-01-01 08:02:15' as DATETIMEV2(0))) |
+-----+
| 04:02:48 |
+-----+
1 row in set (0.12 sec)

mysql> select timediff('2020-01-01', '2000-01-01');
+-----+
| timediff(cast('2020-01-01' as DATETIMEV2(0)), cast('2000-01-01' as DATETIMEV2(0))) |
+-----+
| 838:59:59 |
+-----+
1 row in set (0.11 sec)
```

DATETIME

描述

DATETIME([P]) 日期时间类型，可选参数 P 表示时间精度，取值范围是[0, 6]，即最多支持 6 位小数（微秒）。不设置时为 0。取值范围是['0000-01-01 00:00:00[.000000]', '9999-12-31 23:59:59[.999999]']。打印的形式是'yyyy-MM-dd HH:mm:ss.SSSSSS'

note

DATETIME 支持了最多到微秒的时间精度。在使用 BE 端解析导入的 DATETIME 类型数据时（如使用 Stream load、Spark load 等），或开启[新优化器](#)后在 FE 端解析 DATETIME 类型数据时，将会对超出当前精度的小数进行四舍五入。将带有小数秒部分的 DATETIME 值插入到具有较少小数位的相同类型的列中会导致四舍五入。

DATETIME 读入时支持解析时区，格式为原本 DATETIME 字面量后紧贴时区：

```
<date> <time>[<timezone>]
```

关于<timezone>的具体支持格式，请见[时区](#)。需要注意的是，DATE, DATEV2, DATETIME, DATETIMEV2 类型均不包含时区信息。例如，一个输入的时间字符串“2012-12-12 08:00:00+08:00”经解析并转换至当前时区“+02:00”，得到实际值“2012-12-12 02:00:00”后存储于 DATETIME 列中，则之后无论本集群环境变量如何改变，该值本身都不会发生变化。

举例

```
mysql> select @@time_zone;
+-----+
| @@time_zone |
+-----+
| Asia/Hong_Kong |
+-----+
1 row in set (0.11 sec)

mysql> insert into dtv23 values ("2020-12-12 12:12:12Z"), ("2020-12-12 12:12:12GMT"), ("2020-12-12 12:12:12+02:00"), ("2020-12-12 12:12:12America/Los_Angeles");
Query OK, 4 rows affected (0.17 sec)

mysql> select * from dtv23;
+-----+
| k0 |
+-----+
| 2020-12-12 20:12:12.000 |
| 2020-12-12 20:12:12.000 |
| 2020-12-13 04:12:12.000 |
| 2020-12-12 18:12:12.000 |
+-----+
4 rows in set (0.15 sec)
```


CHAR

description

CHAR(M)

定长字符串，M 代表的是定长字符串的字节长度。M 的范围是 1-255

VARCHAR

description

VARCHAR(M)

变长字符串，M 代表的是变长字符串的字节长度。M 的范围是 1-65533。

注意：变长字符串是以 UTF-8 编码存储的，因此通常英文字符占 1 个字节，中文字符占 3 个字节。

STRING

description

STRING

变长字符串，默认支持 1048576 字节（1MB），可调大到 2147483643 字节（2G），可通过 `be` 配置 `string_type_length_soft_limit_bytes` 调整。String 类型只能用在 `value` 列，不能用在 `key` 列和分区 分桶列
String 类型只能用在 `value` 列，不能用在 `key` 列和分区分桶列。

注意：变长字符串是以 UTF-8 编码存储的，因此通常英文字符占 1 个字节，中文字符占 3 个字节。

ARRAY

描述

ARRAY<T>

由 T 类型元素组成的数组，不能作为 key 列使用。目前支持在 Duplicate 和 Unique 模型的表中使用。

2.0 版本之后支持在 Unique 模型的表中非 key 列使用。

T 支持的类型有：

```
BOOLEAN, TINYINT, SMALLINT, INT, BIGINT, LARGEINT, FLOAT, DOUBLE, DECIMAL, DATE,
DATEV2, DATETIME, DATETIMEV2, CHAR, VARCHAR, STRING
```

举例

建表示例如下：

```
mysql> CREATE TABLE `array_test` (
  `id` int(11) NULL COMMENT "",
  `c_array` ARRAY<int(11)> NULL COMMENT ""
) ENGINE=OLAP
DUPLICATE KEY(`id`)
COMMENT "OLAP"
DISTRIBUTED BY HASH(`id`) BUCKETS 1
PROPERTIES (
"replication_allocation" = "tag.location.default: 1",
"in_memory" = "false",
"storage_format" = "V2"
);
```

插入数据示例：

```
mysql> INSERT INTO `array_test` VALUES (1, [1,2,3,4,5]);
mysql> INSERT INTO `array_test` VALUES (2, [6,7,8]), (3, []), (4, null);
```

查询数据示例：

```
mysql> SELECT * FROM `array_test`;
+-----+-----+
| id  | c_array          |
+-----+-----+
| 1   | [1, 2, 3, 4, 5] |
| 2   | [6, 7, 8]        |
| 3   | []               |
| 4   | NULL             |
+-----+-----+
```

MAP

描述

MAP<K, V>

由 K, V 类型元素组成的 map，不能作为 key 列使用。目前支持在 Duplicate，Unique 模型的表中使用。

K,V 支持的类型有：

```
BOOLEAN, TINYINT, SMALLINT, INT, BIGINT, LARGEINT, FLOAT, DOUBLE, DECIMAL, DECIMALV3, DATE,
DATEV2, DATETIME, DATETIMEV2, CHAR, VARCHAR, STRING
```

举例

建表示例如下：

```
CREATE TABLE IF NOT EXISTS test.simple_map (
  `id` INT(11) NULL COMMENT '',
  `m` Map<STRING, INT> NULL COMMENT ''
) ENGINE=OLAP
DUPLICATE KEY(`id`)
DISTRIBUTED BY HASH(`id`) BUCKETS 1
PROPERTIES (
  "replication_allocation" = "tag.location.default: 1",
  "storage_format" = "V2"
);
```

插入数据示例：

```
mysql> INSERT INTO simple_map VALUES(1, {'a': 100, 'b': 200});
```

stream_load 示例： 更多详细 stream_load 用法见 [STREAM LOAD](#)

```
# load the map data from json file
curl --location-trusted -u root: -T events.json -H "format: json" -H "read_json_by_line: true"
http://fe_host:8030/api/test/simple_map/_stream_load
# 返回结果
{
  "TxnId": 106134,
  "Label": "5666e573-9a97-4dfc-ae61-2d6b61fdffd2",
  "Comment": "",
  "TwoPhaseCommit": "false",
  "Status": "Success",
  "Message": "OK",
  "NumberTotalRows": 10293125,
  "NumberLoadedRows": 10293125,
  "NumberFilteredRows": 0,
  "NumberUnselectedRows": 0,
  "LoadBytes": 2297411459,
  "LoadTimeMs": 66870,
  "BeginTxnTimeMs": 1,
```

```

    "StreamLoadPutTimeMs": 80,
    "ReadDataTimeMs": 6415,
    "WriteDataTimeMs": 10550,
    "CommitAndPublishTimeMs": 38
}

```

查询数据示例：

```

mysql> SELECT * FROM simple_map;
+-----+-----+
| id | m |
+-----+-----+
| 1 | {'a':100, 'b':200} |
| 2 | {'b':100, 'c':200, 'd':300} |
| 3 | {'a':10, 'd':200} |
+-----+-----+

```

查询 map 列示例：

```

mysql> SELECT m FROM simple_map;
+-----+
| m |
+-----+
| {'a':100, 'b':200} |
| {'b':100, 'c':200, 'd':300} |
| {'a':10, 'd':200} |
+-----+

```

map 取值示例：

```

mysql> SELECT m['a'] FROM simple_map;
+-----+
| %element_extract%(`m`, 'a') |
+-----+
| 100 |
| NULL |
| 10 |
+-----+

```

map 支持的 functions 示例：

```

# map construct

mysql> SELECT map('k11', 1000, 'k22', 2000)['k11'];
+-----+
| %element_extract%(map('k11', 1000, 'k22', 2000), 'k11') |
+-----+
| 1000 |
+-----+

mysql> SELECT map('k11', 1000, 'k22', 2000)['nokey'];
+-----+
| %element_extract%(map('k11', 1000, 'k22', 2000), 'nokey') |
+-----+
| NULL |
+-----+

1 row in set (0.06 sec)

```

map_size

```
mysql> SELECT map_size(map('k11', 1000, 'k22', 2000));
```

map_size(map('k11', 1000, 'k22', 2000))
2

```
mysql> SELECT id, m, map_size(m) FROM simple_map ORDER BY id;
```

id	m	map_size(`m`)
1	{ "a":100, "b":200 }	2
2	{ "b":100, "c":200, "d":300 }	3
2	{ "a":10, "d":200 }	2

3 rows in set (0.04 sec)

map_contains_key

```
mysql> SELECT map_contains_key(map('k11', 1000, 'k22', 2000), 'k11');
```

map_contains_key(map('k11', 1000, 'k22', 2000), 'k11')
1

1 row in set (0.08 sec)

```
mysql> SELECT id, m, map_contains_key(m, 'k1') FROM simple_map ORDER BY id;
```

id	m	map_contains_key(`m`, 'k1')
1	{ "a":100, "b":200 }	0
2	{ "b":100, "c":200, "d":300 }	0
2	{ "a":10, "d":200 }	0

3 rows in set (0.10 sec)

```
mysql> SELECT id, m, map_contains_key(m, 'a') FROM simple_map ORDER BY id;
```

id	m	map_contains_key(`m`, 'a')
1	{ "a":100, "b":200 }	1
2	{ "b":100, "c":200, "d":300 }	0
2	{ "a":10, "d":200 }	1

3 rows in set (0.17 sec)

map_contains_value

```
mysql> SELECT map_contains_value(map('k11', 1000, 'k22', 2000), NULL);
```

map_contains_value(map('k11', 1000, 'k22', 2000), NULL)
0

1 row in set (0.04 sec)

```
mysql> SELECT id, m, map_contains_value(m, '100') FROM simple_map ORDER BY id;
```

id	m	map_contains_value(`m`, 100)
1	{ "a":100, "b":200 }	1
2	{ "b":100, "c":200, "d":300 }	1

```

| 2 | {"a":10, "d":200} | 0 |
+-----+-----+
3 rows in set (0.11 sec)

# map_keys

mysql> SELECT map_keys(map('k11', 1000, 'k22', 2000));
+-----+
| map_keys(map('k11', 1000, 'k22', 2000)) |
+-----+
| ["k11", "k22"] |
+-----+
1 row in set (0.04 sec)

mysql> SELECT id, map_keys(m) FROM simple_map ORDER BY id;
+-----+-----+
| id | map_keys(`m`) |
+-----+-----+
| 1 | ["a", "b"] |
| 2 | ["b", "c", "d"] |
| 2 | ["a", "d"] |
+-----+-----+
3 rows in set (0.19 sec)

# map_values

mysql> SELECT map_values(map('k11', 1000, 'k22', 2000));
+-----+
| map_values(map('k11', 1000, 'k22', 2000)) |
+-----+
| [1000, 2000] |
+-----+
1 row in set (0.03 sec)

mysql> SELECT id, map_values(m) FROM simple_map ORDER BY id;
+-----+-----+
| id | map_values(`m`) |
+-----+-----+
| 1 | [100, 200] |
| 2 | [100, 200, 300] |
| 2 | [10, 200] |
+-----+-----+
3 rows in set (0.18 sec)

```


STRUCT

描述

`STRUCT<field_name:field_type [COMMENT 'comment_string'], ... >`

由多个 Field 组成的结构体，也可被理解为多个列的集合。不能作为 Key 使用，目前 STRUCT 仅支持在 Duplicate 模型的表中使用。

一个 Struct 中的 Field 的名字和数量固定，总是为 Nullable，一个 Field 通常由下面部分组成。

- field_name: Field 的标识符，不可重复
- field_type: Field 的类型
- COMMENT: Field 的注释，可选 (暂不支持)

当前可支持的类型有：

```
BOOLEAN, TINYINT, SMALLINT, INT, BIGINT, LARGEINT, FLOAT, DOUBLE, DECIMAL, DECIMALV3, DATE,
DATEV2, DATETIME, DATETIMEV2, CHAR, VARCHAR, STRING
```

在将来的版本我们还将完善：

```
TOD0:支持嵌套 STRUCT 或其他的复杂类型
```

举例

建表示例如下：

```
mysql> CREATE TABLE `struct_test` (
  `id` int(11) NULL,
  `s_info` STRUCT<s_id:int(11), s_name:string, s_address:string> NULL
) ENGINE=OLAP
DUPLICATE KEY(`id`)
COMMENT 'OLAP'
DISTRIBUTED BY HASH(`id`) BUCKETS 1
PROPERTIES (
  "replication_allocation" = "tag.location.default: 1",
  "storage_format" = "V2",
  "light_schema_change" = "true",
  "disable_auto_compaction" = "false"
);
```

插入数据示例：

Insert:

```
INSERT INTO `struct_test` VALUES (1, {1, 'sn1', 'sa1'});
INSERT INTO `struct_test` VALUES (2, struct(2, 'sn2', 'sa2'));
INSERT INTO `struct_test` VALUES (3, named_struct('s_id', 3, 's_name', 'sn3', 's_address', 'sa3'));
```

Stream load:

test.csv:

```
1|{"s_id":1, "s_name":"sn1", "s_address":"sa1"}
2|{s_id:2, s_name:sn2, s_address:sa2}
3|{"s_address":"sa3", "s_name":"sn3", "s_id":3}
```

示例:

```
curl --location-trusted -u root -T test.csv -H "label:test_label"
http://host:port/api/test/struct_test/_stream_load
```

查询数据示例:

```
mysql> select * from struct_test;
+-----+-----+
| id | s_info |
+-----+-----+
| 1 | {1, 'sn1', 'sa1'} |
| 2 | {2, 'sn2', 'sa2'} |
| 3 | {3, 'sn3', 'sa3'} |
+-----+-----+
3 rows in set (0.02 sec)
```

JSON

JSON 数据类型，用二进制格式高效存储 [JSON](#) 数据，通过 JSON 函数访问其内部字段。

默认支持 1048576 字节（1 MB），可调大到 2147483643 字节（2 GB），可通过 BE 配置 `string_type_length_soft_limit_bytes` 调整。

与普通 String 类型存储的 JSON 字符串相比，JSON 类型有两点优势

1. 数据写入时进行 JSON 格式校验
2. 二进制存储格式更加高效，通过 `json_extract` 等函数可以高效访问 JSON 内部字段，比 `get_json_xx` 函数快几倍

:::caution 注意

在 1.2.x 版本中，JSON 类型的名字是 JSONB，为了尽量跟 MySQL 兼容，从 2.0.0 版本开始改名为 JSON，老的表仍然可以使用。

:::

语法

定义

```
json_column_name JSON
```

写入 - INSERT INTO VALUE 格式是引号包围的字符串。例如：

```
INSERT INTO table_name(id, json_column_name) VALUES (1, '{"k1": "100"}')
```

- STREAM LOAD 对应列的格式是字符串，不需要额外引号包围。例如：

```
12 {"k1": "v31", "k2": 300}
13 []
14 [123, 456]
```

查询 - 直接将整个 JSON 列 SELECT 出来

```
SELECT json_column_name FROM table_name;
```

- 从 JSON 中提取需要的字段，或者其他信息，参考 JSON 函数，例如：

```
SELECT json_extract(json_column_name, '$.k1') FROM table_name;
```

- JSON 类型可以与整数、字符串、BOOLEAN、ARRAY、MAP 进行类型转换 CAST，例如：

```
SELECT CAST('{"k1": "100"}' AS JSON)
SELECT CAST(json_column_name AS String) FROM table_name;
SELECT CAST(json_extract(json_column_name, '$.k1') AS INT) FROM table_name;
```

JSON 类型暂时不能用于 GROUP BY, ORDER BY, 比较大小

使用示例

用一个从建表、导数据、查询全周期的例子说明JSON数据类型的功能和用法。

创建库表

```
CREATE DATABASE testdb;

USE testdb;

CREATE TABLE test_json (
  id INT,
  j JSON
)
DUPLICATE KEY(id)
DISTRIBUTED BY HASH(id) BUCKETS 10
PROPERTIES("replication_num" = "1");
```

导入数据

stream load 导入 test_json.csv 测试数据

- 测试数据有 2 列，第一列 ID，第二列是 JSON
- 测试数据有 25 行，其中前 18 行的 JSON 是合法的，后 7 行的 JSON 是非法的

```
1  \N
2  null
3  true
4  false
5  100
6  10000
7  10000000000
8  1152921504606846976
9  6.18
10 "abcd"
11 {}
12 {"k1":"v31", "k2": 300}
13 []
14 [123, 456]
15 ["abc", "def"]
16 [null, true, false, 100, 6.18, "abc"]
17 [{"k1":"v41", "k2": 400}, 1, "a", 3.14]
18 {"k1":"v31", "k2": 300, "a1": [{"k1":"v41", "k2": 400}, 1, "a", 3.14]}
19 ''
20 'abc'
21 abc
22 100x
23 6.a8
```

```
24 {x
25 [123, abc]
```

- 由于有 28% 的非法数据，默认会失败报错 “too many filtered rows”

```
curl --location-trusted -u root: -T test_json.csv http://127.0.0.1:8840/api/testdb/test_json/_stream_load
{
  "TxnId": 12019,
  "Label": "744d9821-9c9f-43dc-bf3b-7ab048f14e32",
  "TwoPhaseCommit": "false",
  "Status": "Fail",
  "Message": "too many filtered rows",
  "NumberTotalRows": 25,
  "NumberLoadedRows": 18,
  "NumberFilteredRows": 7,
  "NumberUnselectedRows": 0,
  "LoadBytes": 380,
  "LoadTimeMs": 48,
  "BeginTxnTimeMs": 0,
  "StreamLoadPutTimeMs": 1,
  "ReadDataTimeMs": 0,
  "WriteDataTimeMs": 45,
  "CommitAndPublishTimeMs": 0,
  "ErrorURL": "http://172.21.0.5:8840/api/_load_error_log?
file=__shard_2/error_log_insert_stmt_95435c4bf5f156df-426735082a9296af_95435c4bf5f156df_426735082a9296af"
}
```

- 设置容错率参数 ‘max_filter_ratio: 0.3’

```
curl --location-trusted -u root: -H 'max_filter_ratio: 0.3' -T test_json.csv
http://127.0.0.1:8840/api/testdb/test_json/_stream_load
{
  "TxnId": 12017,
  "Label": "f37a50c1-43e9-4f4e-a159-a3db6abe2579",
  "TwoPhaseCommit": "false",
  "Status": "Success",
  "Message": "OK",
  "NumberTotalRows": 25,
  "NumberLoadedRows": 18,
  "NumberFilteredRows": 7,
  "NumberUnselectedRows": 0,
  "LoadBytes": 380,
  "LoadTimeMs": 68,
  "BeginTxnTimeMs": 0,
  "StreamLoadPutTimeMs": 2,
  "ReadDataTimeMs": 0,
  "WriteDataTimeMs": 45,
  "CommitAndPublishTimeMs": 19,
  "ErrorURL": "http://172.21.0.5:8840/api/_load_error_log?
file=__shard_0/error_log_insert_stmt_a1463f98a7b15caf-c79399b920f5bfa3_a1463f98a7b15caf_c79399b920f5bfa3"
}
```

- 查看 stream load 导入的数据，JSON 类型的列 j 会自动转成 JSON String 展示

```
mysql> SELECT * FROM test_json ORDER BY id;
+-----+-----+
| id | j |
+-----+-----+
| 1 | NULL |
| 2 | null |
```

3	true
4	false
5	100
6	10000
7	1000000000
8	1152921504606846976
9	6.18
10	"abcd"
11	{}
12	{"k1":"v31","k2":300}
13	[]
14	[123,456]
15	["abc","def"]
16	[null,true,false,100,6.18,"abc"]
17	[{"k1":"v41","k2":400},1,"a",3.14]
18	{"k1":"v31","k2":300,"a1":[{"k1":"v41","k2":400},1,"a",3.14]}

18 rows in set (0.03 sec)

insert into 插入数据

- insert 1 条数据，总数据从 18 条增加到 19 条

```
mysql> INSERT INTO test_json VALUES(26, '{"k1":"v1", "k2": 200}');
Query OK, 1 row affected (0.09 sec)
{'label':'insert_4ece6769d1b42fd_ac9f25b3b8f3dc02', 'status':'VISIBLE', 'txnId':'12016'}
```

```
mysql> SELECT * FROM test_json ORDER BY id;
```

id	j
1	NULL
2	null
3	true
4	false
5	100
6	10000
7	1000000000
8	1152921504606846976
9	6.18
10	"abcd"
11	{}
12	{"k1":"v31","k2":300}
13	[]
14	[123,456]
15	["abc","def"]
16	[null,true,false,100,6.18,"abc"]
17	[{"k1":"v41","k2":400},1,"a",3.14]
18	{"k1":"v31","k2":300,"a1":[{"k1":"v41","k2":400},1,"a",3.14]}
26	{"k1":"v1","k2":200}

19 rows in set (0.03 sec)

查询

用 json_extract 取 json 内的某个字段

1. 获取整个 json, \$ 在 json path 中代表 root, 即整个 json

id	j	json_extract(`j`, '\$')
1	NULL	NULL
2	null	null
3	true	true
4	false	false
5	100	100
6	10000	10000
7	1000000000	1000000000
8	1152921504606846976	1152921504606846976
9	6.18	6.18
10	"abcd"	"abcd"
11	{}	{}
12	{"k1":"v31","k2":300}	{"k1":"v31","k2":300}
13	[]	[]
14	[123,456]	[123,456]
15	["abc","def"]	["abc","def"]
16	[null,true,false,100,6.18,"abc"]	[null,true,false,100,6.18,"abc"]
17	[{"k1":"v41","k2":400},1,"a",3.14]	[{"k1":"v41","k2":400},1,"a",3.14]
18	[{"k1":"v31","k2":300,"a1":[{"k1":"v41","k2":400},1,"a",3.14]}]	[{"k1":"v31","k2":300,"a1":[{"k1":"v41","k2":400},1,"a",3.14]}]
26	{"k1":"v1","k2":200}	{"k1":"v1","k2":200}

19 rows in set (0.03 sec)

1. 获取 k1 字段, 没有 k1 字段的行返回 NULL

```
mysql> SELECT id, j, json_extract(j, '$.k1') FROM test_json ORDER BY id;
```

id	j	json_extract(`j`, '\$.k1')
----	---	----------------------------

1	NULL	NULL
2	null	NULL
3	true	NULL
4	false	NULL
5	100	NULL
6	10000	NULL
7	1000000000	NULL
8	1152921504606846976	NULL
9	6.18	NULL
10	"abcd"	NULL
11	{}	NULL
12	{"k1": "v31", "k2": 300}	"v31"
13	[]	NULL
14	[123, 456]	NULL
15	["abc", "def"]	NULL
16	[null, true, false, 100, 6.18, "abc"]	NULL
17	[{"k1": "v41", "k2": 400}, 1, "a", 3.14]	NULL
18	{"k1": "v31", "k2": 300, "a1": [{"k1": "v41", "k2": 400}, 1, "a", 3.14]}	"v31"
26	{"k1": "v1", "k2": 200}	"v1"

19 rows in set (0.03 sec)

1. 获取顶层数组的第 0 个元素

```
mysql> SELECT id, j, json_extract(j, '$[0]') FROM test_json ORDER BY id;
```

id	j	json_extract(`j`, '\$[0]')
1	NULL	NULL
2	null	NULL
3	true	NULL
4	false	NULL
5	100	NULL
6	10000	NULL
7	1000000000	NULL
8	1152921504606846976	NULL
9	6.18	NULL
10	"abcd"	NULL
11	{}	NULL
12	{"k1": "v31", "k2": 300}	NULL
13	[]	NULL
14	[123, 456]	123
15	["abc", "def"]	"abc"
16	[null, true, false, 100, 6.18, "abc"]	null
17	[{"k1": "v41", "k2": 400}, 1, "a", 3.14]	{"k1": "v41", "k2": 400}
18	{"k1": "v31", "k2": 300, "a1": [{"k1": "v41", "k2": 400}, 1, "a", 3.14]}	NULL
26	{"k1": "v1", "k2": 200}	NULL

19 rows in set (0.03 sec)

1. 获取整个 json array

```
mysql> SELECT id, j, json_extract(j, '$.a1') FROM test_json ORDER BY id;
```

id	j	json_extract(`j`, '\$.a1')
1	NULL	NULL
2	null	NULL
3	true	NULL
4	false	NULL
5	100	NULL
6	10000	NULL

7	1000000000	NULL
8	1152921504606846976	NULL
9	6.18	NULL
10	"abcd"	NULL
11	{}	NULL
12	{"k1":"v31","k2":300}	NULL
13	[]	NULL
14	[123,456]	NULL
15	["abc","def"]	NULL
16	[null,true,false,100,6.18,"abc"]	NULL
17	[{"k1":"v41","k2":400},1,"a",3.14]	NULL
18	{"k1":"v31","k2":300,"a1":[{"k1":"v41","k2":400},1,"a",3.14]}	[{"k1":"v41","k2":400},1,"a",3.14]
26	{"k1":"v1","k2":200}	NULL

19 rows in set (0.02 sec)

1. 获取 json array 中嵌套 object 的字段

```
mysql> SELECT id, j, json_extract(j, '$.a1[0]'), json_extract(j, '$.a1[0].k1') FROM test_json ORDER BY id;
```

id	j	json_extract(j, '\$.a1[0]')	json_extract(j, '\$.a1[0].k1')
1	NULL	NULL	NULL
2	NULL	null	NULL
3	NULL	true	NULL
4	NULL	false	NULL
5	NULL	100	NULL
6	NULL	10000	NULL
7	NULL	1000000000	NULL
8	NULL	1152921504606846976	NULL
9	NULL	6.18	NULL
10	NULL	"abcd"	NULL
11	NULL	{}	NULL
12	NULL	{"k1":"v31","k2":300}	NULL
13	NULL	[]	NULL
14	NULL	[123,456]	NULL
15	NULL	["abc","def"]	NULL
16	NULL	[null,true,false,100,6.18,"abc"]	NULL
17	NULL	[{"k1":"v41","k2":400},1,"a",3.14]	NULL
18	NULL	{"k1":"v31","k2":300,"a1":[{"k1":"v41","k2":400},1,"a",3.14]}	["v41", {"k1":"v41","k2":400}]
26	NULL	{"k1":"v1","k2":200}	NULL

```
19 rows in set (0.02 sec)
```

1. 获取具体类型的

- `json_extract_string` 获取 String 类型字段, 非 String 类型转成 String

```
mysql> SELECT id, j, json_extract_string(j, '$') FROM test_json ORDER BY id;
```

id	j	json_extract_string(`j`, '\$')
1	NULL	NULL
2	null	null
3	true	true
4	false	false
5	100	100
6	10000	10000
7	10000000000	10000000000
8	1152921504606846976	1152921504606846976
9	6.18	6.18
10	"abcd"	abcd
11	{}	{}
12	{"k1": "v31", "k2": 300}	{"k1": "v31", "k2": 300}
13	[]	[]
14	[123, 456]	[123, 456]
15	["abc", "def"]	["abc", "def"]
16	[null, true, false, 100, 6.18, "abc"]	[null, true, false, 100, 6.18, "abc"]
17	[{"k1": "v41", "k2": 400}, 1, "a", 3.14]	[{"k1": "v41", "k2": 400}, 1, "a", 3.14]
18	{"k1": "v31", "k2": 300, "a1": [{"k1": "v41", "k2": 400}, 1, "a", 3.14]} {"k1": "v31", "k2": 300, "a1": [{"k1": "v41", "k2": 400}, 1, "a", 3.14]}	
26	{"k1": "v1", "k2": 200}	{"k1": "v1", "k2": 200}

```
19 rows in set (0.02 sec)
```

```
mysql> SELECT id, j, json_extract_string(j, '$.k1') FROM test_json ORDER BY id;
```

id	j	json_extract_string(`j`, '\$.k1')
1		NULL
2		null

3	true	NULL
4	false	NULL
5	100	NULL
6	10000	NULL
7	1000000000	NULL
8	1152921504606846976	NULL
9	6.18	NULL
10	"abcd"	NULL
11	{}	NULL
12	{"k1":"v31","k2":300}	v31
13	[]	NULL
14	[123,456]	NULL
15	["abc","def"]	NULL
16	[null,true,false,100,6.18,"abc"]	NULL
17	[{"k1":"v41","k2":400},1,"a",3.14]	NULL
18	{"k1":"v31","k2":300,"a1":[{"k1":"v41","k2":400},1,"a",3.14]}	v31
26	{"k1":"v1","k2":200}	v1

19 rows in set (0.03 sec)

- `json_extract_int` 获取 int 类型字段, 非 int 类型返回 NULL

```
mysql> SELECT id, j, json_extract_int(j, '$') FROM test_json ORDER BY id;
```

id	j	json_extract_int(`j`, '\$')
1	NULL	NULL
2	null	NULL
3	true	NULL
4	false	NULL
5	100	100
6	10000	10000
7	1000000000	1000000000
8	1152921504606846976	NULL
9	6.18	NULL
10	"abcd"	NULL
11	{}	NULL
12	{"k1":"v31","k2":300}	NULL
13	[]	NULL
14	[123,456]	NULL
15	["abc","def"]	NULL
16	[null,true,false,100,6.18,"abc"]	NULL
17	[{"k1":"v41","k2":400},1,"a",3.14]	NULL
18	{"k1":"v31","k2":300,"a1":[{"k1":"v41","k2":400},1,"a",3.14]}	NULL
26	{"k1":"v1","k2":200}	NULL

19 rows in set (0.02 sec)

```
mysql> SELECT id, j, json_extract_int(j, '$.k2') FROM test_json ORDER BY id;
```

id	j	json_extract_int(`j`, '\$.k2')
1	NULL	NULL
2	null	NULL
3	true	NULL
4	false	NULL
5	100	NULL
6	10000	NULL
7	1000000000	NULL
8	1152921504606846976	NULL
9	6.18	NULL
10	"abcd"	NULL
11	{}	NULL

12	{ "k1": "v31", "k2": 300 }	300
13	[]	NULL
14	[123, 456]	NULL
15	["abc", "def"]	NULL
16	[null, true, false, 100, 6.18, "abc"]	NULL
17	[{ "k1": "v41", "k2": 400 }, 1, "a", 3.14]	NULL
18	{ "k1": "v31", "k2": 300, "a1": [{ "k1": "v41", "k2": 400 }, 1, "a", 3.14] }	300
26	{ "k1": "v1", "k2": 200 }	200

19 rows in set (0.03 sec)

- `json_extract_bigint` 获取 bigint 类型字段，非 bigint 类型返回 NULL

```
mysql> SELECT id, j, json_extract_bigint(j, '$') FROM test_json ORDER BY id;
```

id	j	json_extract_bigint(`j`, '\$')
1	NULL	NULL
2	null	NULL
3	true	NULL
4	false	NULL
5	100	100
6	10000	10000
7	1000000000	1000000000
8	1152921504606846976	1152921504606846976
9	6.18	NULL
10	"abcd"	NULL
11	{ }	NULL
12	{ "k1": "v31", "k2": 300 }	NULL
13	[]	NULL
14	[123, 456]	NULL
15	["abc", "def"]	NULL
16	[null, true, false, 100, 6.18, "abc"]	NULL
17	[{ "k1": "v41", "k2": 400 }, 1, "a", 3.14]	NULL
18	{ "k1": "v31", "k2": 300, "a1": [{ "k1": "v41", "k2": 400 }, 1, "a", 3.14] }	NULL
26	{ "k1": "v1", "k2": 200 }	NULL

19 rows in set (0.03 sec)

```
mysql> SELECT id, j, json_extract_bigint(j, '$.k2') FROM test_json ORDER BY id;
```

id	j	json_extract_bigint(`j`, '\$.k2')
1	NULL	NULL
2	null	NULL
3	true	NULL
4	false	NULL
5	100	NULL
6	10000	NULL
7	1000000000	NULL
8	1152921504606846976	NULL
9	6.18	NULL
10	"abcd"	NULL
11	{ }	NULL
12	{ "k1": "v31", "k2": 300 }	300
13	[]	NULL
14	[123, 456]	NULL
15	["abc", "def"]	NULL
16	[null, true, false, 100, 6.18, "abc"]	NULL
17	[{ "k1": "v41", "k2": 400 }, 1, "a", 3.14]	NULL
18	{ "k1": "v31", "k2": 300, "a1": [{ "k1": "v41", "k2": 400 }, 1, "a", 3.14] }	300
26	{ "k1": "v1", "k2": 200 }	200

```

+-----+
19 rows in set (0.02 sec)

```

- `json_extract_double` 获取 double 类型字段，非 double 类型返回 NULL

```

mysql> SELECT id, j, json_extract_double(j, '$') FROM test_json ORDER BY id;
+-----+
| id | j | json_extract_double(`j`, '$') |
+-----+
| 1 | | NULL |
| 2 | | null |
| 3 | | true |
| 4 | | false |
| 5 | | 100 |
| 6 | | 10000 |
| 7 | | 1000000000 |
| 8 | 1152921504606846976 | 1.152921504606847e+18 |
| 9 | 6.18 | 6.18 |
| 10 | "abcd" | NULL |
| 11 | {} | NULL |
| 12 | {"k1":"v31","k2":300} | NULL |
| 13 | [] | NULL |
| 14 | [123,456] | NULL |
| 15 | ["abc","def"] | NULL |
| 16 | [null,true,false,100,6.18,"abc"] | NULL |
| 17 | [{"k1":"v41","k2":400},1,"a",3.14] | NULL |
| 18 | {"k1":"v31","k2":300,"a1":[{"k1":"v41","k2":400},1,"a",3.14]} | NULL |
| 26 | {"k1":"v1","k2":200} | NULL |
+-----+
19 rows in set (0.02 sec)

```

```

mysql> SELECT id, j, json_extract_double(j, '$.k2') FROM test_json ORDER BY id;
+-----+
| id | j | json_extract_double(`j`, '$.k2') |
+-----+
| 1 | | NULL |
| 2 | | null |
| 3 | | true |
| 4 | | false |
| 5 | | 100 |
| 6 | | 10000 |
| 7 | | 1000000000 |
| 8 | 1152921504606846976 | NULL |
| 9 | 6.18 | NULL |
| 10 | "abcd" | NULL |
| 11 | {} | NULL |
| 12 | {"k1":"v31","k2":300} | 300 |
| 13 | [] | NULL |
| 14 | [123,456] | NULL |
| 15 | ["abc","def"] | NULL |
| 16 | [null,true,false,100,6.18,"abc"] | NULL |
| 17 | [{"k1":"v41","k2":400},1,"a",3.14] | NULL |
| 18 | {"k1":"v31","k2":300,"a1":[{"k1":"v41","k2":400},1,"a",3.14]} | 300 |
| 26 | {"k1":"v1","k2":200} | 200 |
+-----+
19 rows in set (0.03 sec)

```

- `json_extract_bool` 获取 bool 类型字段，非 bool 类型返回 NULL

```

mysql> SELECT id, j, json_extract_bool(j, '$') FROM test_json ORDER BY id;
+-----+
| id | j | json_extract_bool(`j`, '$') |
+-----+

```

1	NULL	NULL
2	null	NULL
3	true	1
4	false	0
5	100	NULL
6	10000	NULL
7	1000000000	NULL
8	1152921504606846976	NULL
9	6.18	NULL
10	"abcd"	NULL
11	{}	NULL
12	{"k1":"v31","k2":300}	NULL
13	[]	NULL
14	[123,456]	NULL
15	["abc","def"]	NULL
16	[null,true,false,100,6.18,"abc"]	NULL
17	[{"k1":"v41","k2":400},1,"a",3.14]	NULL
18	{"k1":"v31","k2":300,"a1":[{"k1":"v41","k2":400},1,"a",3.14]}	NULL
26	{"k1":"v1","k2":200}	NULL

19 rows in set (0.01 sec)

mysql> SELECT id, j, json_extract_bool(j, '\$[1]') FROM test_json ORDER BY id;

id	j	json_extract_bool(`j`, '\$[1]')
1	NULL	NULL
2	null	NULL
3	true	NULL
4	false	NULL
5	100	NULL
6	10000	NULL
7	1000000000	NULL
8	1152921504606846976	NULL
9	6.18	NULL
10	"abcd"	NULL
11	{}	NULL
12	{"k1":"v31","k2":300}	NULL
13	[]	NULL
14	[123,456]	NULL
15	["abc","def"]	NULL
16	[null,true,false,100,6.18,"abc"]	1
17	[{"k1":"v41","k2":400},1,"a",3.14]	NULL
18	{"k1":"v31","k2":300,"a1":[{"k1":"v41","k2":400},1,"a",3.14]}	NULL
26	{"k1":"v1","k2":200}	NULL

19 rows in set (0.01 sec)

- json_extract_isnull 获取 JSON NULL 类型字段，null 返回 1，非 null 返回 0
- 需要注意的是 JSON NULL 和 SQL NULL 不一样，SQL NULL 表示某个字段的值不存在，而 JSON 表示值存在但是是一个特殊值 NULL

mysql> SELECT id, j, json_extract_isnull(j, '\$') FROM test_json ORDER BY id;

id	j	json_extract_isnull(`j`, '\$')
1	NULL	NULL
2	null	1
3	true	0
4	false	0
5	100	0
6	10000	0

7	1000000000	0
8	1152921504606846976	0
9	6.18	0
10	"abcd"	0
11	{}	0
12	{"k1":"v31","k2":300}	0
13	[]	0
14	[123,456]	0
15	["abc","def"]	0
16	[null,true,false,100,6.18,"abc"]	0
17	[{"k1":"v41","k2":400},1,"a",3.14]	0
18	{"k1":"v31","k2":300,"a1":[{"k1":"v41","k2":400},1,"a",3.14]}	0
26	{"k1":"v1","k2":200}	0

19 rows in set (0.03 sec)

用 json_exists_path 检查 json 内的某个字段是否存在

```
mysql> SELECT id, j, json_exists_path(j, '$') FROM test_json ORDER BY id;
```

id	j	json_exists_path(`j`, '\$')
1	NULL	NULL
2	null	1
3	true	1
4	false	1
5	100	1
6	10000	1
7	1000000000	1
8	1152921504606846976	1
9	6.18	1
10	"abcd"	1
11	{}	1
12	{"k1":"v31","k2":300}	1
13	[]	1
14	[123,456]	1
15	["abc","def"]	1
16	[null,true,false,100,6.18,"abc"]	1
17	[{"k1":"v41","k2":400},1,"a",3.14]	1
18	{"k1":"v31","k2":300,"a1":[{"k1":"v41","k2":400},1,"a",3.14]}	1
26	{"k1":"v1","k2":200}	1

19 rows in set (0.02 sec)

```
mysql> SELECT id, j, json_exists_path(j, '$.k1') FROM test_json ORDER BY id;
```

id	j	json_exists_path(`j`, '\$.k1')
1	NULL	NULL
2	null	0
3	true	0
4	false	0
5	100	0
6	10000	0
7	1000000000	0
8	1152921504606846976	0
9	6.18	0
10	"abcd"	0
11	{}	0
12	{"k1":"v31","k2":300}	1
13	[]	0

```

+-----+-----+-----+-----+
| 14 | | [123,456] | | 0 |
| 15 | | ["abc","def"] | | 0 |
| 16 | | [null,true,false,100,6.18,"abc"] | | 0 |
| 17 | | [{"k1":"v41","k2":400},1,"a",3.14] | | 0 |
| 18 | | {"k1":"v31","k2":300,"a1":[{"k1":"v41","k2":400},1,"a",3.14]} | | 1 |
| 26 | | {"k1":"v1","k2":200} | | 1 |
+-----+-----+-----+-----+
19 rows in set (0.03 sec)

mysql> SELECT id, j, json_exists_path(j, '$[2]') FROM test_json ORDER BY id;
+-----+-----+-----+-----+
| id | j | json_exists_path(`j`, '$[2]') |
+-----+-----+-----+-----+
| 1 | NULL | NULL |
| 2 | null | 0 |
| 3 | true | 0 |
| 4 | false | 0 |
| 5 | 100 | 0 |
| 6 | 10000 | 0 |
| 7 | 1000000000 | 0 |
| 8 | 1152921504606846976 | 0 |
| 9 | 6.18 | 0 |
| 10 | "abcd" | 0 |
| 11 | {} | 0 |
| 12 | {"k1":"v31","k2":300} | 0 |
| 13 | [] | 0 |
| 14 | [123,456] | 0 |
| 15 | ["abc","def"] | 0 |
| 16 | [null,true,false,100,6.18,"abc"] | 1 |
| 17 | [{"k1":"v41","k2":400},1,"a",3.14] | 1 |
| 18 | {"k1":"v31","k2":300,"a1":[{"k1":"v41","k2":400},1,"a",3.14]} | 0 |
| 26 | {"k1":"v1","k2":200} | 0 |
+-----+-----+-----+-----+
19 rows in set (0.02 sec)

```

用 json_type 获取 JSON 内的某个字段的类型

- 返回 json path 对应的 JSON 字段类型，如果不存在返回 NULL

```

mysql> SELECT id, j, json_type(j, '$') FROM test_json ORDER BY id;
+-----+-----+-----+-----+
| id | j | json_type(`j`, '$') |
+-----+-----+-----+-----+
| 1 | NULL | NULL |
| 2 | null | null |
| 3 | true | bool |
| 4 | false | bool |
| 5 | 100 | int |
| 6 | 10000 | int |
| 7 | 1000000000 | int |
| 8 | 1152921504606846976 | bigint |
| 9 | 6.18 | double |
| 10 | "abcd" | string |
| 11 | {} | object |
| 12 | {"k1":"v31","k2":300} | object |
| 13 | [] | array |
| 14 | [123,456] | array |
| 15 | ["abc","def"] | array |
| 16 | [null,true,false,100,6.18,"abc"] | array |
| 17 | [{"k1":"v41","k2":400},1,"a",3.14] | array |

```



```

+-----+-----+-----+-----+
| 18 | {"k1":"v31","k2":300,"a1":[{"k1":"v41","k2":400},1,"a",3.14]} | object |
| 26 | {"k1":"v1","k2":200} | object |
+-----+-----+-----+-----+
19 rows in set (0.02 sec)

mysql> select id, j, json_type(j, '$.k1') from test_json order by id;
+-----+-----+-----+-----+
| id | j | json_type(`j`, '$.k1') |
+-----+-----+-----+-----+
| 1 | | NULL | NULL |
| 2 | | null | NULL |
| 3 | | true | NULL |
| 4 | | false | NULL |
| 5 | | 100 | NULL |
| 6 | | 10000 | NULL |
| 7 | | 1000000000 | NULL |
| 8 | | 1152921504606846976 | NULL |
| 9 | | 6.18 | NULL |
| 10 | | "abcd" | NULL |
| 11 | | {} | NULL |
| 12 | | {"k1":"v31","k2":300} | string |
| 13 | | [] | NULL |
| 14 | | [123,456] | NULL |
| 15 | | ["abc","def"] | NULL |
| 16 | | [null,true,false,100,6.18,"abc"] | NULL |
| 17 | | [{"k1":"v41","k2":400},1,"a",3.14] | NULL |
| 18 | {"k1":"v31","k2":300,"a1":[{"k1":"v41","k2":400},1,"a",3.14]} | string |
| 26 | {"k1":"v1","k2":200} | string |
+-----+-----+-----+-----+
19 rows in set (0.03 sec)

```

FAQ

1. JSON类型中的null和SQL中的NULL(IS NULL)有区别吗

是的，JSON中的null例如 {"key1" : null} 表示key1这个JSON键存在，并且值为null (作为一个特殊类型会被编码到JSON binary中)，而SQL中的NULL是指没有这个JSON键。例如

```

mysql> SELECT JSON_EXTRACT_STRING('{"key1" : null}', "$.key1") IS NULL;
+-----+
| JSON_EXTRACT_STRING('{"key1" : null}', "$.key1") IS NULL |
+-----+
| 0 |
+-----+
1 row in set (0.00 sec)

mysql> SELECT JSON_EXTRACT_STRING('{"key1" : null}', "$.key_not_exist") IS NULL;
+-----+
| JSON_EXTRACT_STRING('{"key1" : null}', "$.key_not_exist") IS NULL |
+-----+
| 1 |
+-----+
1 row in set (0.01 sec)

```

2. GET_JSON_XXX 函数和 JSON_EXTRACT_XXX 函数的区别，以及怎么选择

GET_JSON_XXX 是针对字符串类型设计的函数，是直接在本原生字符串上做提取操作，而 JSON_EXTRACT_XXX 是针对 JSON 类型实现的函数，针对 JSON 类型有特殊优化。一般建议使用 JSON_EXTRACT_XXX 性能会更好。

HLL(HyperLogLog)

描述

HLL HLL 不能作为 key 列使用，支持在 Aggregate 模型、Duplicate 模型和 Unique 模型的表中使用。在 Aggregate 模型表中使用时，建表时配合的聚合类型为 HLL_UNION。用户不需要指定长度和默认值。长度根据数据的聚合程度系统内控制。并且 HLL 列只能通过配套的 hll_union_agg、hll_raw_agg、hll_cardinality、hll_hash 进行查询或使用。

HLL 是模糊去重，在数据量大的情况性能优于 Count Distinct。HLL 的误差通常在 1% 左右，有时能达到 2%。

举例

```
select hour, HLL_UNION_AGG(pv) over(order by hour) uv from(
  select hour, HLL_RAW_AGG(device_id) as pv
  from metric_table -- 查询每小时的累计UV
  where datekey=20200622
  group by hour order by 1
) final;
```

BITMAP

描述

BITMAP

BITMAP 类型的列可以在 Aggregate 表、Unique 表或 Duplicate 表中使用。在 Unique 表或 duplicate 表中使用时，其必须作为非 key 列使用。在 Aggregate 表中使用时，其必须作为非 key 列使用，且建表时配合的聚合类型为 BITMAP_UNION。用户不需要指定长度和默认值。长度根据数据的聚合程度系统内控制。并且 BITMAP 列只能通过配套的 bitmap_union_count、bitmap_union、bitmap_hash、bitmap_hash64 等函数进行查询或使用。

离线场景下使用 BITMAP 会影响导入速度，在数据量大的情况下查询速度会慢于 HLL，并优于 Count Distinct。注意：实时场景下 BITMAP 如果不使用全局字典，使用了 bitmap_hash() 可能会导致有千分之一左右的误差。如果这个误差不可接受，可以使用 bitmap_hash64。

举例

建表示例如下：

```
create table metric_table (  
  datekey int,  
  hour int,  
  device_id bitmap BITMAP_UNION  
)  
aggregate key (datekey, hour)  
distributed by hash(datekey, hour) buckets 1  
properties(  
  "replication_num" = "1"  
);
```

插入数据示例：

```
insert into metric_table values  
(20200622, 1, to_bitmap(243)),  
(20200622, 2, bitmap_from_array([1,2,3,4,5,434543])),  
(20200622, 3, to_bitmap(287667876573));
```

查询数据示例：

```
select hour, BITMAP_UNION_COUNT(pv) over(order by hour) uv from(  
  select hour, BITMAP_UNION(device_id) as pv  
  from metric_table -- 查询每小时的累计UV  
  where datekey=20200622  
  group by hour order by 1  
) final;
```

在查询时，可以设置[会话变量](#)return_object_data_as_binary为 true，这样 bitmap 会以二进制的形式返回。

QUANTILE_STATE

描述

QUANTILE_STATE

在 2.0 中我们支持了 [agg_state](#) 功能，推荐使用 `agg_state quantile_union(quantile_state not null)` 来代替本类型。

QUANTILE_STATE 不能作为 key 列使用，支持在 Aggregate 模型、Duplicate 模型和 Unique 模型的表中使用。在 Aggregate 模型表中使用时，建表时配合的聚合类型为 QUANTILE_UNION。用户不需要指定长度和默认值。长度根据数据的聚合程度系统内控制。并且 QUANTILE_STATE 列只能通过配套的 QUANTILE_PERCENT、QUANTILE_UNION、TO_QUANTILE_STATE 等函数进行查询或使用。

QUANTILE_STATE 是一种计算分位数近似值的类型，在导入时会对相同的 key，不同 value 进行预聚合，当 value 数量不超过 2048 时采用明细记录所有数据，当 value 数量大于 2048 时采用 [TDigest](#) 算法，对数据进行聚合（聚类）保存聚类后的质心点。

相关函数：

QUANTILE_UNION(QUANTILE_STATE): 此函数为聚合函数，用于将不同的分位数计算中间结果进行聚合操作。此函数返回的结果仍是 QUANTILE_STATE

TO_QUANTILE_STATE(DOUBLE raw_data [,FLOAT compression]): 此函数将数值类型转化成 QUANTILE_STATE 类型 compression 参数是可选项，可设置范围是[2048, 10000]，值越大，后续分位数近似计算的精度越高，内存消耗越大，计算耗时越长。compression 参数未指定或设置的值在[2048, 10000]范围外，以 2048 的默认值运行

QUANTILE_PERCENT(QUANTILE_STATE, percent): 此函数将分位数计算的中间结果变量（QUANTILE_STATE）转化为具体的分位数数值

举例

```
select QUANTILE_PERCENT(QUANTILE_UNION(v1), 0.5) from test_table group by k1, k2, k3;
```

注意事项

使用前可以通过如下命令打开 QUANTILE_STATE 开关：

```
$ mysql-client > admin set frontend config("enable_quantile_state_type"="true");
```

这种方式下 QUANTILE_STATE 开关会在 Fe 进程重启后重置，或者在 fe.conf 中添加 enable_quantile_state_type=true 配置项可永久生效。

AGG_STATE

描述

AGG_STATE不能作为key列使用，建表时需要同时声明聚合函数的签名。
用户不需要指定长度和默认值。实际存储的数据大小与函数实现有关。

AGG_STATE 只能配合[state](#) /[merge](#)/[union](#)函数组合器使用。

需要注意的是，聚合函数的签名也是类型的一部分，不同签名的 `agg_state` 无法混合使用。比如如果建表声明的签名为`max_by(int,int)`,那就无法插入`max_by(bigint,int)`或者`group_concat(varchar)`。此处 `nullable` 属性也是签名的一部分，如果能确定不会输入 `null` 值，可以将参数声明为 `not null`，这样可以获得更小的存储大小和减少序列化/反序列化开销。

注意：因为`agg_state`存储的是聚合函数的中间结果，所以读写过程都强依赖于聚合函数的具体实现，如果在 **Doris** 版本升级时对聚合函数实现做了修改，则可能会造成不兼容的情况。如果出现不兼容的情况，使用到对应 `agg_state` 的物化视图需要`drop`并重新创建，另外涉及到的基础聚合表则会直接不可用，所以需要慎重使用 `agg_state`。

举例

建表示例如下：`sql create table a_table( k1 int null, k2 agg_state<max_by(int not null,int)> generic, k3 agg_state<group_concat(string)> generic ) aggregate key (k1) distributed BY hash(k1) buckets 3 properties("replication_num" = "1");` 这里的 `k2` 和 `k3` 分别以 `max_by` 和 `group_concat` 为聚合类型。

插入数据示例：`sql insert into a_table values(1,max_by_state(3,1),group_concat_state('a')); insert into a_table values(1,max_by_state(2,2),group_concat_state('bb')); insert into a_table values(2,max_by_state(1,3),group_concat_state('ccc'));` 对于 `agg_state` 列，插入语句必须用[state](#)函数来生成对应的 `agg_state` 数据，这里的函数和入参类型都必须跟 `agg_state` 完全对应。

查询数据示例：

```
mysql [test]>select k1,max_by_merge(k2),group_concat_merge(k3) from a_table group by k1 order by k1;
```

k1	max_by_merge(`k2`)	group_concat_merge(`k3`)
1	2	bb,a
2	1	ccc

如果需要获取实际结果，则要用对应的[merge](#)函数。

```
mysql [test]>select max_by_merge(u2),group_concat_merge(u3) from (
  select k1,max_by_union(k2) as u2,group_concat_union(k3) u3 from a_table group by k1 order by k1
) t;
```

max_by_merge(`u2`)	group_concat_merge(`u3`)
--------------------	--------------------------

	1		ccc,bb,a	
+	-----	+	-----	+

如果想要在过程中只聚合 `agg_state` 而不获取实际结果，可以使用[union](#)函数。

更多的例子参见[datatype_p0/agg_state](#)

ARRAY

array()

array() ### 描述

语法

ARRAY<T> array(T, ...) 根据参数构造并返回array, 参数可以是多列或者常量

举例

```
mysql> select array("1", 2, 1.1);
+-----+
| array('1', 2, '1.1') |
+-----+
| ['1', '2', '1.1']    |
+-----+
1 row in set (0.00 sec)

mysql> select array(null, 1);
+-----+
| array(NULL, 1) |
+-----+
| [NULL, 1]      |
+-----+
1 row in set (0.00 sec)

mysql> select array(1, 2, 3);
+-----+
| array(1, 2, 3) |
+-----+
| [1, 2, 3]      |
+-----+
1 row in set (0.00 sec)

mysql> select array(qid, creationDate, null) from nested limit 4;
+-----+
| array(`qid`, `creationDate`, NULL) |
+-----+
| [1000038, 20090616074056, NULL] |
| [1000069, 20090616075005, NULL] |
| [1000130, 20090616080918, NULL] |
| [1000145, 20090616081545, NULL] |
+-----+
4 rows in set (0.01 sec)
```

keywords

ARRAY,ARRAY,CONSTRUCTOR

ARRAY_MAX

array_max

array_max

描述

语法

T array_max(ARRAY<T> array1)

返回数组中最大的元素，数组中的NULL值会被跳过。空数组以及元素全为NULL值的数组，结果返回NULL值。

举例

```
mysql> create table array_type_table(k1 INT, k2 Array<int>) duplicate key (k1)
      -> distributed by hash(k1) buckets 1 properties('replication_num' = '1');
mysql> insert into array_type_table values (0, []), (1, [NULL]), (2, [1, 2, 3]), (3, [1, NULL, 3]);
mysql> select k2, array_max(k2) from array_type_table;
```

k2	array_max(`k2`)
[]	NULL
[NULL]	NULL
[1, 2, 3]	3
[1, NULL, 3]	3

4 rows in set (0.02 sec)

keywords

ARRAY,MAX,ARRAY_MAX

ARRAY_MIN

array_min

array_min

描述

语法

T array_min(ARRAY<T> array1)

返回数组中最小的元素，数组中的NULL值会被跳过。空数组以及元素全为NULL值的数组，结果返回NULL值。

举例

```
mysql> create table array_type_table(k1 INT, k2 Array<int>) duplicate key (k1)
      -> distributed by hash(k1) buckets 1 properties('replication_num' = '1');
mysql> insert into array_type_table values (0, []), (1, [NULL]), (2, [1, 2, 3]), (3, [1, NULL, 3]);
mysql> select k2, array_min(k2) from array_type_table;
```

k2	array_min(`k2`)
[]	NULL
[NULL]	NULL
[1, 2, 3]	1
[1, NULL, 3]	1

4 rows in set (0.02 sec)

keywords

ARRAY,MIN,ARRAY_MIN

ARRAY_MAP

array_map

array_map(lambda,array1,array2....)

描述

语法

ARRAY<T> array_map(lambda, ARRAY<T> array1, ARRAY<T> array2)

使用一个 lambda 表达式作为输入参数，对其他的输入 ARRAY 参数的内部数据做对应表达式计算。在 lambda 表达式中输入的参数为 1 个或多个，必须和后面的输入 array 列数量一致。在 lambda 中可以执行合法的标量函数，不支持聚合函数等。

```
array_map(x->x, array1);
array_map(x->(x+2), array1);
array_map(x->(abs(x)-2), array1);

array_map((x,y)->(x = y), array1, array2);
array_map((x,y)->(power(x,2)+y), array1, array2);
array_map((x,y,z)->(abs(x)+y*z), array1, array2, array3);
```

举例

```
mysql [test]>select *, array_map(x->x,[1,2,3]) from array_test2 order by id;
```

id	c_array1	c_array2	array_map([x] -> x(0), ARRAY(1, 2, 3))
1	[1, 2, 3, 4, 5]	[10, 20, -40, 80, -100]	[1, 2, 3]
2	[6, 7, 8]	[10, 12, 13]	[1, 2, 3]
3	[1]	[-100]	[1, 2, 3]
4	NULL	NULL	[1, 2, 3]

4 rows in set (0.02 sec)

```
mysql [test]>select *, array_map(x->x+2,[1,2,3]) from array_test2 order by id;
```

id	c_array1	c_array2	array_map([x] -> x(0) + 2, ARRAY(1, 2, 3))
1	[1, 2, 3, 4, 5]	[10, 20, -40, 80, -100]	[3, 4, 5]
2	[6, 7, 8]	[10, 12, 13]	[3, 4, 5]
3	[1]	[-100]	[3, 4, 5]
4	NULL	NULL	[3, 4, 5]

4 rows in set (0.02 sec)

```
mysql [test]>select c_array1, c_array2, array_map(x->x,[1,2,3]) from array_test2 order by id;
```

c_array1	c_array2	array_map([x] -> x(0), ARRAY(1, 2, 3))
----------	----------	--

[1, 2, 3, 4, 5]	[10, 20, -40, 80, -100]	[1, 2, 3]	
[6, 7, 8]	[10, 12, 13]	[1, 2, 3]	
[1]	[-100]	[1, 2, 3]	
NULL	NULL	[1, 2, 3]	

-----+

4 rows in set (0.01 sec)

mysql [test]>select c_array1, c_array2, array_map(x->power(x,2),[1,2,3]) from array_test2 order by id;

c_array1	c_array2	array_map([x] -> power(x(0), 2.0), ARRAY(1, 2, 3))	
[1, 2, 3, 4, 5]	[10, 20, -40, 80, -100]	[1, 4, 9]	
[6, 7, 8]	[10, 12, 13]	[1, 4, 9]	
[1]	[-100]	[1, 4, 9]	
NULL	NULL	[1, 4, 9]	

mysql [test]>select c_array1, c_array2, array_map((x,y)->x+y,c_array1,c_array2) from array_test2 order by id;

c_array1	c_array2	array_map([x, y] -> x(0) + y(1), `c_array1`, `c_array2`)	
[1, 2, 3, 4, 5]	[10, 20, -40, 80, -100]	[11, 22, -37, 84, -95]	
[6, 7, 8]	[10, 12, 13]	[16, 19, 21]	
[1]	[-100]	[-99]	
NULL	NULL	NULL	

4 rows in set (0.02 sec)

mysql [test]>select c_array1, c_array2, array_map((x,y)->power(x,2)+y,c_array1, c_array2) from array_test2 order by id;

c_array1	c_array2	array_map([x, y] -> power(x(0), 2.0) + y(1), `c_array1`, `c_array2`)	
[1, 2, 3, 4, 5]	[10, 20, -40, 80, -100]	[11, 24, -31, 96, -75]	
[6, 7, 8]	[10, 12, 13]	[46, 61, 77]	
[1]	[-100]	[-99]	
NULL	NULL	NULL	

-----+

-----+

[1, 2, 3, 4, 5]	[10, 20, -40, 80, -100]	[11, 24, -31, 96, -75]	
-----------------	-------------------------	------------------------	--

[6, 7, 8]	[10, 12, 13]	[46, 61, 77]	
-----------	--------------	--------------	--

[1]	[-100]	[-99]	
-----	--------	-------	--

NULL	NULL	NULL	
------	------	------	--

-----+

-----+

4 rows in set (0.03 sec)

mysql [test]>select *,array_map(x->x=3,c_array1) from array_test2 order by id;

id	c_array1	c_array2	array_map([x] -> x(0) = 3, `c_array1`)	
1	[1, 2, 3, 4, 5]	[10, 20, -40, 80, -100]	[0, 0, 1, 0, 0]	
2	[6, 7, 8]	[10, 12, 13]	[0, 0, 0]	
3	[1]	[-100]	[0]	
4	NULL	NULL	NULL	

4 rows in set (0.02 sec)

mysql [test]>select *,array_map(x->x>3,c_array1) from array_test2 order by id;

id	c_array1	c_array2	array_map([x] -> x(0) > 3, `c_array1`)	
1	[1, 2, 3, 4, 5]	[10, 20, -40, 80, -100]	[0, 0, 0, 1, 1]	
2	[6, 7, 8]	[10, 12, 13]	[1, 1, 1]	

```

+-----+-----+-----+-----+
| 3 | [1] | [-100] | [0] |
| 4 | NULL | NULL | NULL |
+-----+-----+-----+-----+
4 rows in set (0.02 sec)

mysql [test]>select *,array_map((x,y)->x>y,c_array1,c_array2) from array_test2 order by id;
+-----+-----+-----+-----+
--+
| id | c_array1 | c_array2 | array_map([x, y] -> x(0) > y(1), `c_array1`, `c_array2`) |
+-----+-----+-----+-----+
--+
| 1 | [1, 2, 3, 4, 5] | [10, 20, -40, 80, -100] | [0, 0, 1, 0, 1] |
| 2 | [6, 7, 8] | [10, 12, 13] | [0, 0, 0] |
| 3 | [1] | [-100] | [1] |
| 4 | NULL | NULL | NULL |
+-----+-----+-----+-----+
--+
4 rows in set (0.02 sec)

mysql [test]>select array_map(x->cast(x as string), c_array1) from test_array_map_function;
+-----+-----+-----+
| c_array1 | array_map([x] -> CAST(x(0) AS CHARACTER), `c_array1`) |
+-----+-----+-----+
| [1, 2, 3, 4, 5] | ['1', '2', '3', '4', '5'] |
| [6, 7, 8] | ['6', '7', '8'] |
| [] | [] |
| NULL | NULL |
+-----+-----+-----+
4 rows in set (0.01 sec)

```

keywords

ARRAY,MAP,ARRAY_MAP

ARRAY_FILTER

array_filter

array_filter(lambda,array)

提示

该功能自 Apache Doris 2.0.2 版本起支持

array array_filter(array arr, array_bool filter_column)

描述

语法

```
ARRAY<T> array_filter(lambda, ARRAY<T> arr)
ARRAY<T> array_filter(ARRAY<T> arr, ARRAY<Bool> filter_column)
```

使用 lambda 表达式作为输入参数，计算筛选另外的输入参数 ARRAY 列的数据。并过滤掉在结果中 0 和 NULL 的值。

```
array_filter(x->x>0, array1);
array_filter(x->(x+2)=10, array1);
array_filter(x->(abs(x)-2)>0, array1);
array_filter(c_array,[0,1,0]);
```

举例

```
mysql [test]>select c_array,array_filter(c_array,[0,1,0]) from array_test;
```

c_array	array_filter(`c_array`, ARRAY(FALSE, TRUE, FALSE))
[1, 2, 3, 4, 5]	[2]
[6, 7, 8]	[7]
[]	[]
NULL	NULL

```
mysql [test]>select array_filter(x->(x > 1), [1,2,3,0,null]);
```

array_filter(ARRAY(1, 2, 3, 0, NULL), array_map([x] -> (x(0) > 1), ARRAY(1, 2, 3, 0, NULL)))
[2, 3]

```
mysql [test]>select *, array_filter(x->x>0,c_array2) from array_test2;
```

```

-----+
| id | c_array1 | c_array2 | array_filter(`c_array2`, array_map([x] -> x(0) > 0,
`c_array2`)) |
-----+
| 1 | [1, 2, 3, 4, 5] | [10, 20, -40, 80, -100] | [10, 20, 80]
|
| 2 | [6, 7, 8] | [10, 12, 13] | [10, 12, 13]
|
| 3 | [1] | [-100] | []
|
| 4 | NULL | NULL | NULL
|
-----+
4 rows in set (0.01 sec)

mysql [test]>select *, array_filter(x->x%2=0,c_array2) from array_test2;
-----+
| id | c_array1 | c_array2 | array_filter(`c_array2`, array_map([x] -> x(0) % 2 = 0,
`c_array2`)) |
-----+
| 1 | [1, 2, 3, 4, 5] | [10, 20, -40, 80, -100] | [10, 20, -40, 80, -100]
|
| 2 | [6, 7, 8] | [10, 12, 13] | [10, 12]
|
| 3 | [1] | [-100] | [-100]
|
| 4 | NULL | NULL | NULL
|
-----+

mysql [test]>select *, array_filter(x->(x*(-10)>0),c_array2) from array_test2;
-----+
| id | c_array1 | c_array2 | array_filter(`c_array2`, array_map([x] -> (x(0) * (-10)
> 0), `c_array2`)) |
-----+
| 1 | [1, 2, 3, 4, 5] | [10, 20, -40, 80, -100] | [-40, -100]
|
| 2 | [6, 7, 8] | [10, 12, 13] | []
|
| 3 | [1] | [-100] | [-100]
|
| 4 | NULL | NULL | NULL
|
-----+

mysql [test]>select *, array_filter(x->x>0, array_map((x,y)->(x>y), c_array1,c_array2)) as res from
array_test2;
-----+
| id | c_array1 | c_array2 | res |
-----+
| 1 | [1, 2, 3, 4, 5] | [10, 20, -40, 80, -100] | [1, 1] |
| 2 | [6, 7, 8] | [10, 12, 13] | [] |
| 3 | [1] | [-100] | [1] |
| 4 | NULL | NULL | NULL |
-----+

```

keywords

ARRAY,FILTER,ARRAY_FILTER

ARRAY_AVG

array_avg

array_avg

描述

返回数组中所有元素的平均值，数组中的NULL值会被跳过。空数组以及元素全为NULL值的数组，结果返回NULL值。

语法

Array<T> array_avg(arr)

举例

```
mysql> create table array_type_table(k1 INT, k2 Array<int>) duplicate key (k1)
      -> distributed by hash(k1) buckets 1 properties('replication_num' = '1');
mysql> insert into array_type_table values (0, []), (1, [NULL]), (2, [1, 2, 3]), (3, [1, NULL, 3]);
mysql> select k2, array_avg(k2) from array_type_table;
```

k2	array_avg(`k2`)
[]	NULL
[NULL]	NULL
[1, 2, 3]	2
[1, NULL, 3]	2

4 rows in set (0.01 sec)

keywords

ARRAY,AVG,ARRAY_AVG

ARRAY_SUM

array_sum

array_sum

描述

语法

```
T array_sum(ARRAY<T> src, Array<T> key)
T array_sum(lambda, Array<T> arr1, Array<T> arr2 ....)
```

返回数组中所有元素之和，数组中的NULL值会被跳过。空数组以及元素全为NULL值的数组，结果返回NULL值。

举例

```
mysql> create table array_type_table(k1 INT, k2 Array<int>) duplicate key (k1)
-> distributed by hash(k1) buckets 1 properties('replication_num' = '1');
mysql> insert into array_type_table values (0, []), (1, [NULL]), (2, [1, 2, 3]), (3, [1, NULL, 3]);
mysql> select k2, array_sum(k2) from array_type_table;
+-----+-----+
| k2      | array_sum(`k2`) |
+-----+-----+
| []      | NULL           |
| [NULL]  | NULL           |
| [1, 2, 3] | 6              |
| [1, NULL, 3] | 4              |
+-----+-----+
4 rows in set (0.01 sec)
```

keywords

ARRAY,SUM,ARRAY_SUM

ARRAY_SIZE

array_size (size, cardinality)

array_size (size, cardinality) ### 描述

语法

```
BIGINT size(ARRAY<T> arr)
BIGINT array_size(ARRAY<T> arr)
BIGINT cardinality(ARRAY<T> arr)
```

返回数组中元素数量，如果输入数组为NULL，则返回NULL

举例

```
mysql> select k1,k2,size(k2) from array_test;
```

k1	k2	size(`k2`)
1	[1, 2, 3]	3
2	[]	0
3	NULL	NULL

```
mysql> select k1,k2,array_size(k2) from array_test;
```

k1	k2	array_size(`k2`)
1	[1, 2, 3]	3
2	[]	0
3	NULL	NULL

```
mysql> select k1,k2,cardinality(k2) from array_test;
```

k1	k2	cardinality(`k2`)
1	[1, 2, 3]	3
2	[]	0
3	NULL	NULL

keywords

ARRAY_SIZE, SIZE, CARDINALITY

ARRAY_REMOVE

array_remove

array_remove

描述

语法

ARRAY<T> array_remove(ARRAY<T> arr, T val)

返回移除所有的指定元素后的数组，如果输入参数为NULL，则返回NULL

举例

```
mysql> select array_remove(['test', NULL, 'value'], 'value');
```

array_remove(ARRAY('test', NULL, 'value'), 'value')	
[test, NULL]	

```
mysql> select k1, k2, array_remove(k2, 1) from array_type_table_1;
```

k1	k2	array_remove(`k2`, 1)
1	[1, 2, 3]	[2, 3]
2	[1, 3]	[3]
3	NULL	NULL
4	[1, 3]	[3]
5	[NULL, 1, NULL, 2]	[NULL, NULL, 2]

```
mysql> select k1, k2, array_remove(k2, k1) from array_type_table_1;
```

k1	k2	array_remove(`k2`, `k1`)
1	[1, 2, 3]	[2, 3]
2	[1, 3]	[1, 3]
3	NULL	NULL
4	[1, 3]	[1, 3]
5	[NULL, 1, NULL, 2]	[NULL, 1, NULL, 2]

```
mysql> select k1, k2, array_remove(k2, date('2022-10-10')) from array_type_table_date;
```

k1	k2	array_remove(`k2`, date('2022-10-10 00:00:00'))
1	[2021-10-10, 2022-10-10]	[2021-10-10]
2	[NULL, 2022-05-14]	[NULL, 2022-05-14]

```
mysql> select k1, k2, array_remove(k2, k1) from array_type_table_nullable;
```

k1	k2	array_remove(`k2`, `k1`)
NULL	[1, 2, 3]	NULL
1	NULL	NULL
NULL	[NULL, 1]	NULL
1	[NULL, 1]	[NULL]

keywords

ARRAY,REMOVE,ARRAY_REMOVE

ARRAY_SLICE

array_slice

array_slice

描述

语法

ARRAY<T> array_slice(ARRAY<T> arr, BIGINT off, BIGINT len)

返回一个子数组，包含所有从指定位置开始的指定长度的元素，如果输入参数为NULL，则返回NULL

如果off是正数，则表示从左侧开始的偏移量

如果off是负数，则表示从右侧开始的偏移量

当指定的off不在数组的实际范围内，返回空数组

如果len是负数，则表示长度为0

举例

```
mysql> select k2, k2[2:2] from array_type_table_nullable;
```

k2	array_slice(`k2`, 2, 2)
[1, 2, 3]	[2, 3]
[1, NULL, 3]	[NULL, 3]
[2, 3]	[3]
NULL	NULL

```
mysql> select k2, array_slice(k2, 2, 2) from array_type_table_nullable;
```

k2	array_slice(`k2`, 2, 2)
[1, 2, 3]	[2, 3]
[1, NULL, 3]	[NULL, 3]
[2, 3]	[3]
NULL	NULL

```
mysql> select k2, k2[2:2] from array_type_table_nullable_varchar;
```

k2	array_slice(`k2`, 2, 2)
['hello', 'world', 'c++']	['world', 'c++']
['a1', 'equals', 'b1']	['equals', 'b1']
['hasnull', NULL, 'value']	[NULL, 'value']
['hasnull', NULL, 'value']	[NULL, 'value']

```
mysql> select k2, array_slice(k2, 2, 2) from array_type_table_nullable_varchar;
```

k2	array_slice(`k2`, 2, 2)
----	-------------------------

['hello', 'world', 'c++']	['world', 'c++']	
['a1', 'equals', 'b1']	['equals', 'b1']	
['hasnull', NULL, 'value']	[NULL, 'value']	
['hasnull', NULL, 'value']	[NULL, 'value']	

当指定off为负数:

```
mysql> select k2, k2[-2:1] from array_type_table_nullable;
```

k2	array_slice(`k2`, -2, 1)
[1, 2, 3]	[2]
[1, 2, 3]	[2]
[2, 3]	[2]
[2, 3]	[2]

```
mysql> select k2, array_slice(k2, -2, 1) from array_type_table_nullable;
```

k2	array_slice(`k2`, -2, 1)
[1, 2, 3]	[2]
[1, 2, 3]	[2]
[2, 3]	[2]
[2, 3]	[2]

```
mysql> select k2, k2[-2:2] from array_type_table_nullable_varchar;
```

k2	array_slice(`k2`, -2, 2)
['hello', 'world', 'c++']	['world', 'c++']
['a1', 'equals', 'b1']	['equals', 'b1']
['hasnull', NULL, 'value']	[NULL, 'value']
['hasnull', NULL, 'value']	[NULL, 'value']

```
mysql> select k2, array_slice(k2, -2, 2) from array_type_table_nullable_varchar;
```

k2	array_slice(`k2`, -2, 2)
['hello', 'world', 'c++']	['world', 'c++']
['a1', 'equals', 'b1']	['equals', 'b1']
['hasnull', NULL, 'value']	[NULL, 'value']
['hasnull', NULL, 'value']	[NULL, 'value']

```
mysql> select k2, array_slice(k2, 0) from array_type_table;
```

k2	array_slice(`k2`, 0)
[1, 2, 3]	[]

```
mysql> select k2, array_slice(k2, -5) from array_type_table;
```

k2	array_slice(`k2`, -5)
----	-----------------------

| [1, 2, 3] | [] |
+-----+-----+

keywords

ARRAY,SLICE,ARRAY_SLICE

ARRAY_SORT

array_sort

array_sort

描述

语法

ARRAY<T> array_sort(ARRAY<T> arr)

返回按升序排列后的数组，如果输入数组为NULL，则返回NULL。如果数组元素包含NULL，则输出的排序数组会将NULL放在最前面。

举例

```
mysql> select k1, k2, array_sort(k2) from array_test; +-----+-----+
+-----+ | k1 | k2 | array_sort(k2) | +-----+
+-----+ | 1 | [1, 2, 3, 4, 5] | [1, 2, 3, 4, 5] | | 2 | [6, 7, 8] | [6, 7, 8] | | 3 | [] | [] | | 4 | NULL | NULL | |
5 | [1, 2, 3, 4, 5, 4, 3, 2, 1] | [1, 1, 2, 2, 3, 3, 4, 4, 5] | | 6 | [1, 2, 3, NULL] | [NULL, 1, 2, 3] | | 7 | [1, 2, 3, NULL,
NULL] | [NULL, NULL, 1, 2, 3] | | 8 | [1, 1, 2, NULL, NULL] | [NULL, NULL, 1, 1, 2] | | 9 | [1, NULL, 1, 2, NULL,
NULL] | [NULL, NULL, NULL, 1, 1, 2] | +-----+
mysql> select k1, k2, array_sort(k2) from array_test01; +-----+-----+
+-----+ | k1 | k2 | array_sort(k2) | +-----+
+-----+ | 1 | ['a', 'b', 'c', 'd', 'e'] | ['a', 'b', 'c', 'd', 'e'] | | 2 | ['f', 'g', 'h'] | ['f', 'g', 'h'] | | 3 | ['']
| [''] | | 3 | [NULL] | [NULL] | | 5 | ['a', 'b', 'c', 'd', 'e', 'a', 'b', 'c'] | ['a', 'a', 'b', 'b', 'c', 'c', 'd', 'e'] | | 6 | NULL | NULL | |
7 | ['a', 'b', NULL] | [NULL, 'a', 'b'] | | 8 | ['a', 'b', NULL, NULL] | [NULL, NULL, 'a', 'b'] | +-----+
+-----+
```

keywords

ARRAY, SORT, ARRAY_SORT

ARRAY_REVERSE_SORT

array_reverse_sort

array_reverse_sort

描述

语法

ARRAY<T> array_reverse_sort(ARRAY<T> arr)

返回按降序排列后的数组，如果输入数组为 NULL，则返回 NULL。如果数组元素包含 NULL，则输出的排序数组会将 NULL 放在最后面。

举例

```
`mysql> select k1, k2, array_reverse_sort(k2) from array_test; +-----+-----+
+-----+-----+ | k1 | k2 | array_reverse_sort(k2)` | +-----+
+-----+-----+ | 1 | [1, 2, 3, 4, 5] | [5, 4, 3, 2, 1] | | 2 | [6, 7, 8] | [8, 7, 6] | | 3 | [] | []
| | 4 | NULL | NULL | | 5 | [1, 2, 3, 4, 5, 4, 3, 2, 1] | [5, 4, 4, 3, 3, 2, 2, 1, 1] | | 6 | [1, 2, 3, NULL] | [3, 2, 1, NULL] |
| 7 | [1, 2, 3, NULL, NULL] | [3, 2, 1, NULL, NULL] | | 8 | [1, 1, 2, NULL, NULL] | [2, 1, 1, NULL, NULL] | | 9 | [1,
NULL, 1, 2, NULL, NULL] | [2, 1, 1, NULL, NULL, NULL] | +-----+-----+
mysql> select k1, k2, array_reverse_sort(k2) from array_test01; +-----+-----+
+-----+-----+ | k1 | k2 | array_reverse_sort(k2) | +-----+
+-----+-----+ | 1 | ['a', 'b', 'c', 'd', 'e'] | ['e', 'd', 'c', 'b', 'a'] | | 2 | ['f', 'g', 'h'] | ['h', 'g', 'f'] | | 3 | ['']
| [''] | | 3 | [NULL] | [NULL] | | 5 | ['a', 'b', 'c', 'd', 'e', 'a', 'b', 'c'] | ['e', 'd', 'c', 'c', 'b', 'b', 'a', 'a'] | | 6 | NULL | NULL | |
7 | ['a', 'b', NULL] | ['b', 'a', NULL] | | 8 | ['a', 'b', NULL, NULL] | ['b', 'a', NULL, NULL] | +-----+
+-----+-----+`
```

keywords

ARRAY, SORT, REVERSE, ARRAY_SORT, ARRAY_REVERSE_SORT

ARRAY_SORTBY

array_sortby

array_sortby

描述

语法

```
ARRAY<T> array_sortby(ARRAY<T> src,Array<T> key)
ARRAY<T> array_sortby(lambda,array,...)
```

首先将 key 列升序排列，然后将 src 列按此顺序排序后的对应列做为结果返回; 如果输入数组 src 为 NULL，则返回 NULL。如果输入数组 key 为 NULL，则直接返回 src 数组。如果输入数组 key 元素包含 NULL, 则输出的排序数组会将 NULL 放在最前面。

举例

```
mysql [test]>select array_sortby(['a','b','c'],[3,2,1]);
+-----+
| array_sortby(ARRAY('a', 'b', 'c'), ARRAY(3, 2, 1)) |
+-----+
| ['c', 'b', 'a']                                     |
+-----+

mysql [test]>select array_sortby([1,2,3,4,5],[10,5,1,20,80]);
+-----+
| array_sortby(ARRAY(1, 2, 3, 4, 5), ARRAY(10, 5, 1, 20, 80)) |
+-----+
| [3, 2, 1, 4, 5]                                           |
+-----+

mysql [test]>select *,array_sortby(c_array1,c_array2) from test_array_sortby order by id;
+-----+-----+-----+-----+
| id | c_array1 | c_array2 | array_sortby(`c_array1`, `c_array2`) |
+-----+-----+-----+-----+
| 0 | NULL | [2] | NULL |
| 1 | [1, 2, 3, 4, 5] | [10, 20, -40, 80, -100] | [5, 3, 1, 2, 4] |
| 2 | [6, 7, 8] | [10, 12, 13] | [6, 7, 8] |
| 3 | [1] | [-100] | [1] |
| 4 | NULL | NULL | NULL |
| 5 | [3] | NULL | [3] |
| 6 | [1, 2] | [2, 1] | [2, 1] |
| 7 | [NULL] | [NULL] | [NULL] |
| 8 | [1, 2, 3] | [3, 2, 1] | [3, 2, 1] |
+-----+-----+-----+-----+

mysql [test]>select *, array_map((x,y)->(y+x),c_array1,c_array2) as arr_sum,array_sortby((x,y)->(y+x),c_array1,c_array2) as arr_sort from array_test2;
+-----+-----+-----+-----+
| id | c_array1 | c_array2 | arr_sum | arr_sort |
+-----+-----+-----+-----+
```

	1		[1, 2, 3]		[10, 11, 12]		[11, 13, 15]		[1, 2, 3]	
	2		[4, 3, 5]		[10, 20, 30]		[14, 23, 35]		[4, 3, 5]	
	3		[-40, 30, -100]		[30, 10, 20]		[-10, 40, -80]		[-100, -40, 30]	
+-----+-----+-----+-----+-----+										

keywords

ARRAY, SORT, ARRAY_SORTBY

ARRAY_POSITION

array_position

array_position

描述

语法

BIGINT array_position(ARRAY<T> arr, T value)

返回value在数组中第一次出现的位置/索引。

position

- value在array中的位置（从1开始计算）；

0

- 如果value在array中不存在；

NULL

- 如果数组为NULL。

举例

mysql> SELECT id,c_array,array_position(c_array, 5) FROM `array\_test`;

id	c_array	array_position(`c_array`, 5)
1	[1, 2, 3, 4, 5]	5
2	[6, 7, 8]	0
3	[]	0
4	NULL	NULL

mysql> select array_position([1, null], null);

array_position(ARRAY(1, NULL), NULL)
2

1 row in set (0.01 sec)

keywords

ARRAY,POSITION,ARRAY_POSITION

ARRAY_CONTAINS

array_contains

array_contains

描述

语法

BOOLEAN array_contains(ARRAY<T> arr, T value)

判断数组中是否包含value。返回结果如下：

```
1    - value在数组arr中存在；
0    - value不存在数组arr中；
NULL - arr为NULL时。
```

举例

```
mysql> SELECT id,c_array,array_contains(c_array, 5) FROM `array_test`;
```

id	c_array	array_contains(`c_array`, 5)
1	[1, 2, 3, 4, 5]	1
2	[6, 7, 8]	0
3	[]	0
4	NULL	NULL

```
mysql> select array_contains([null, 1], null);
```

array_contains(ARRAY(NULL, 1), NULL)
1

```
1 row in set (0.00 sec)
```

keywords

ARRAY,CONTAIN,CONTAINS,ARRAY_CONTAINS

ARRAY_EXCEPT

array_except

array_except

描述

语法

ARRAY<T> array_except(ARRAY<T> array1, ARRAY<T> array2)

返回一个数组，包含所有在array1内但不在array2内的元素，不包含重复项，如果输入参数为NULL，则返回NULL

举例

```
mysql> select k1,k2,k3,array_except(k2,k3) from array_type_table;
+-----+-----+-----+-----+
| k1 | k2          | k3          | array_except(`k2`, `k3`) |
+-----+-----+-----+-----+
| 1 | [1, 2, 3]   | [2, 4, 5]   | [1, 3]                   |
| 2 | [2, 3]      | [1, 5]      | [2, 3]                   |
| 3 | [1, 1, 1]   | [2, 2, 2]   | [1]                      |
+-----+-----+-----+-----+

mysql> select k1,k2,k3,array_except(k2,k3) from array_type_table_nullable;
+-----+-----+-----+-----+
| k1 | k2          | k3          | array_except(`k2`, `k3`) |
+-----+-----+-----+-----+
| 1 | [1, NULL, 3] | [1, 3, 5]   | [NULL]                   |
| 2 | [NULL, NULL, 2] | [2, NULL, 4] | []                       |
| 3 | NULL         | [1, 2, 3]   | NULL                     |
+-----+-----+-----+-----+

mysql> select k1,k2,k3,array_except(k2,k3) from array_type_table_varchar;
+-----+-----+-----+-----+
| k1 | k2          | k3          | array_except(`k2`, `k3`) |
+-----+-----+-----+-----+
| 1 | ['hello', 'world', 'c++'] | ['I', 'am', 'c++'] | ['hello', 'world']       |
| 2 | ['a1', 'equals', 'b1']    | ['a2', 'equals', 'b2'] | ['a1', 'b1']             |
| 3 | ['hasnull', NULL, 'value'] | ['nohasnull', 'nonnull', 'value'] | ['hasnull', NULL]        |
| 3 | ['hasnull', NULL, 'value'] | ['hasnull', NULL, 'value'] | []                       |
+-----+-----+-----+-----+

mysql> select k1,k2,k3,array_except(k2,k3) from array_type_table_decimal;
+-----+-----+-----+-----+
| k1 | k2          | k3          | array_except(`k2`, `k3`) |
+-----+-----+-----+-----+
| 1 | [1.1, 2.1, 3.44] | [2.1, 3.4, 5.4] | [1.1, 3.44]              |
| 2 | [NULL, 2, 5]     | [NULL, NULL, 5.4] | [2, 5]                   |
| 1 | [1, NULL, 2, 5]  | [1, 3.1, 5.4]   | [NULL, 2, 5]             |
+-----+-----+-----+-----+
```

keywords

ARRAY,EXCEPT,ARRAY_EXCEPT

ARRAY_PRODUCT

array_product

array_product

描述

语法

T array_product(ARRAY<T> arr)

返回数组中所有元素的乘积，数组中的NULL值会被跳过。空数组以及元素全为NULL值的数组，结果返回NULL值。

举例

```
mysql> create table array_type_table(k1 INT, k2 Array<int>) duplicate key (k1)
-> distributed by hash(k1) buckets 1 properties('replication_num' = '1');
mysql> insert into array_type_table values (0, []), (1, [NULL]), (2, [1, 2, 3]), (3, [1, NULL, 3]);
mysql> select k2, array_product(k2) from array_type_table;
```

k2	array_product(`k2`)
[]	NULL
[NULL]	NULL
[1, 2, 3]	6
[1, NULL, 3]	3

4 rows in set (0.01 sec)

keywords

ARRAY,PRODUCT,ARRAY_PRODUCT

ARRAY_INTERSECT

array_intersect

array_intersect

描述

语法

ARRAY<T> array_intersect(ARRAY<T> array1, ARRAY<T> array2)

返回一个数组，包含array1和array2的交集中的所有元素，不包含重复项，如果输入参数为NULL，则返回NULL

举例

```
mysql> select k1,k2,k3,array_intersect(k2,k3) from array_type_table;
+-----+-----+-----+-----+
| k1 | k2          | k3          | array_intersect(`k2`, `k3`) |
+-----+-----+-----+-----+
| 1 | [1, 2, 3]   | [2, 4, 5]   | [2]                          |
| 2 | [2, 3]      | [1, 5]      | []                           |
| 3 | [1, 1, 1]   | [2, 2, 2]   | []                           |
+-----+-----+-----+-----+

mysql> select k1,k2,k3,array_intersect(k2,k3) from array_type_table_nullable;
+-----+-----+-----+-----+
| k1 | k2          | k3          | array_intersect(`k2`, `k3`) |
+-----+-----+-----+-----+
| 1 | [1, NULL, 3] | [1, 3, 5]   | [1, 3]                      |
| 2 | [NULL, NULL, 2] | [2, NULL, 4] | [NULL, 2]                   |
| 3 | NULL         | [1, 2, 3]   | NULL                        |
+-----+-----+-----+-----+

mysql> select k1,k2,k3,array_intersect(k2,k3) from array_type_table_varchar;
+-----+-----+-----+-----+
| k1 | k2          | k3          | array_intersect(`k2`, `k3`) |
+-----+-----+-----+-----+
| 1 | ['hello', 'world', 'c++'] | ['I', 'am', 'c++'] | ['c++']                     |
| 2 | ['a1', 'equals', 'b1']    | ['a2', 'equals', 'b2'] | ['equals']                   |
| 3 | ['hasnull', NULL, 'value'] | ['nohasnull', 'nonull', 'value'] | [NULL, 'value']             |
| 3 | ['hasnull', NULL, 'value'] | ['hasnull', NULL, 'value'] | ['hasnull', 'value']        |
+-----+-----+-----+-----+

mysql> select k1,k2,k3,array_intersect(k2,k3) from array_type_table_decimal;
+-----+-----+-----+-----+
| k1 | k2          | k3          | array_intersect(`k2`, `k3`) |
+-----+-----+-----+-----+
| 1 | [1.1, 2.1, 3.44] | [2.1, 3.4, 5.4] | [2.1]                       |
| 2 | [NULL, 2, 5]     | [NULL, NULL, 5.4] | [NULL]                      |
| 3 | [1, NULL, 2, 5]  | [1, 3.1, 5.4]   | [1]                         |
+-----+-----+-----+-----+
```

keywords

ARRAY,INTERSECT,ARRAY_INTERSECT

ARRAY_RANGE

array_range

array_range

描述

语法

```
ARRAY<Int> array_range(Int end)
ARRAY<Int> array_range(Int start, Int end)
ARRAY<Int> array_range(Int start, Int end, Int step)
```

参数均为正整数 start 默认为 0, step 默认为 1。最终返回一个数组，从start 到 end - 1, 步长为 step。

举例

```
mysql> select array_range(10);
+-----+
| array_range(10) |
+-----+
| [0, 1, 2, 3, 4, 5, 6, 7, 8, 9] |
+-----+

mysql> select array_range(10,20);
+-----+
| array_range(10, 20) |
+-----+
| [10, 11, 12, 13, 14, 15, 16, 17, 18, 19] |
+-----+

mysql> select array_range(0,20,2);
+-----+
| array_range(0, 20, 2) |
+-----+
| [0, 2, 4, 6, 8, 10, 12, 14, 16, 18] |
+-----+
```

keywords

ARRAY, RANGE, ARRAY_RANGE

ARRAY_DISTINCT

array_distinct

array_distinct

描述

语法

ARRAY<T> array_distinct(ARRAY<T> arr)

返回去除了重复元素的数组，如果输入数组为NULL，则返回NULL。

举例

mysql> select k1, k2, array_distinct(k2) from array_test;

k1	k2	array_distinct(k2)
1	[1, 2, 3, 4, 5]	[1, 2, 3, 4, 5]
2	[6, 7, 8]	[6, 7, 8]
3	[]	[]
4	NULL	NULL
5	[1, 2, 3, 4, 5, 4, 3, 2, 1]	[1, 2, 3, 4, 5]
6	[1, 2, 3, NULL]	[1, 2, 3, NULL]
7	[1, 2, 3, NULL, NULL]	[1, 2, 3, NULL]

mysql> select k1, k2, array_distinct(k2) from array_test01;

k1	k2	array_distinct(`k2`)
1	['a', 'b', 'c', 'd', 'e']	['a', 'b', 'c', 'd', 'e']
2	['f', 'g', 'h']	['f', 'g', 'h']
3	['']	['']
3	[NULL]	[NULL]
5	['a', 'b', 'c', 'd', 'e', 'a', 'b', 'c']	['a', 'b', 'c', 'd', 'e']
6	NULL	NULL
7	['a', 'b', NULL]	['a', 'b', NULL]
8	['a', 'b', NULL, NULL]	['a', 'b', NULL]

keywords

ARRAY, DISTINCT, ARRAY_DISTINCT

ARRAY_DIFFERENCE

array_difference

array_difference

描述

语法

ARRAY<T> array_difference(ARRAY<T> arr)

计算相邻数组元素之间的差异。返回一个数组，其中第一个元素将为0，第二个元素是a[1]-a[0]之间的差值。注意若 NULL 值存在，返回结果为NULL

举例

```
mysql> select *,array_difference(k2) from array_type_table;
```

k1	k2	array_difference(`k2`)
0	[]	[]
1	[NULL]	[NULL]
2	[1, 2, 3]	[0, 1, 1]
3	[1, NULL, 3]	[0, NULL, NULL]
4	[0, 1, 2, 3, NULL, 4, 6]	[0, 1, 1, 1, NULL, NULL, 2]
5	[1, 2, 3, 4, 5, 4, 3, 2, 1]	[0, 1, 1, 1, 1, -1, -1, -1, -1]
6	[6, 7, 8]	[0, 1, 1]

keywords

ARRAY, DIFFERENCE, ARRAY_DIFFERENCE

ARRAY_UNION

array_union

array_union

描述

语法

ARRAY<T> array_union(ARRAY<T> array1, ARRAY<T> array2)

返回一个数组，包含array1和array2的并集中的所有元素，不包含重复项，如果输入参数为NULL，则返回NULL

举例

```
mysql> select k1,k2,k3,array_union(k2,k3) from array_type_table;
+-----+-----+-----+-----+
| k1 | k2          | k3          | array_union(`k2`, `k3`) |
+-----+-----+-----+-----+
| 1 | [1, 2, 3]   | [2, 4, 5]   | [1, 2, 3, 4, 5]        |
| 2 | [2, 3]      | [1, 5]      | [2, 3, 1, 5]           |
| 3 | [1, 1, 1]   | [2, 2, 2]   | [1, 2]                  |
+-----+-----+-----+-----+

mysql> select k1,k2,k3,array_union(k2,k3) from array_type_table_nullable;
+-----+-----+-----+-----+
| k1 | k2          | k3          | array_union(`k2`, `k3`) |
+-----+-----+-----+-----+
| 1 | [1, NULL, 3] | [1, 3, 5]   | [1, NULL, 3, 5]         |
| 2 | [NULL, NULL, 2] | [2, NULL, 4] | [NULL, 2, 4]            |
| 3 | NULL         | [1, 2, 3]   | NULL                     |
+-----+-----+-----+-----+

mysql> select k1,k2,k3,array_union(k2,k3) from array_type_table_varchar;
+-----+-----+-----+-----+
| k1 | k2          | k3          | array_union(`k2`, `k3`) |
+-----+-----+-----+-----+
| 1 | ['hello', 'world', 'c++'] | ['I', 'am', 'c++'] | ['hello', 'world', 'c++', 'I', 'am'] |
| 2 | ['a1', 'equals', 'b1'] | ['a2', 'equals', 'b2'] | ['a1', 'equals', 'b1', 'a2', 'b2'] |
| 3 | ['hasnull', NULL, 'value'] | ['nohasnull', 'nonnull', 'value'] | ['hasnull', NULL, 'value', 'nohasnull', 'nonnull'] |
| 4 | ['hasnull', NULL, 'value'] | ['hasnull', NULL, 'value'] | ['hasnull', NULL, 'value'] |
+-----+-----+-----+-----+

mysql> select k1,k2,k3,array_union(k2,k3) from array_type_table_decimal;
+-----+-----+-----+-----+
| k1 | k2          | k3          | array_union(`k2`, `k3`) |
+-----+-----+-----+-----+
```


ARRAY_JOIN

array_join

array_join

描述

语法

VARCHAR array_join(ARRAY<T> arr, VARCHAR sep[, VARCHAR null_replace])

根据分隔符(sep)和替换NULL的字符串(null_replace), 将数组中的所有元素组合成一个新的字符串。若sep为NULL, 则返回值为NULL。若null_replace为NULL, 则返回值也为NULL。若sep为空字符串, 则不应用任何分隔符。若null_replace为空字符串或者不指定, 则直接丢弃数组中的NULL元素。

举例

```
mysql> select k1, k2, array_join(k2, '_', 'null') from array_test order by k1;
```

k1	k2	array_join(`k2`, '_', 'null')
1	[1, 2, 3, 4, 5]	1_2_3_4_5
2	[6, 7, 8]	6_7_8
3	[]	
4	NULL	NULL
5	[1, 2, 3, 4, 5, 4, 3, 2, 1]	1_2_3_4_5_4_3_2_1
6	[1, 2, 3, NULL]	1_2_3_null
7	[4, 5, 6, NULL, NULL]	4_5_6_null_null


```
mysql> select k1, k2, array_join(k2, '_', 'null') from array_test01 order by k1;
```

k1	k2	array_join(`k2`, '_', 'null')
1	['a', 'b', 'c', 'd']	a_b_c_d
2	['e', 'f', 'g', 'h']	e_f_g_h
3	[NULL, 'a', NULL, 'b', NULL, 'c']	null_a_null_b_null_c
4	['d', 'e', NULL, ' ']	d_e_null_
5	[' ', NULL, 'f', 'g']	_null_f_g


```
mysql> select k1, k2, array_join(k2, '_') from array_test order by k1;
```

k1	k2	array_join(`k2`, '_')
1	[1, 2, 3, 4, 5]	1_2_3_4_5
2	[6, 7, 8]	6_7_8
3	[]	
4	NULL	NULL
5	[1, 2, 3, 4, 5, 4, 3, 2, 1]	1_2_3_4_5_4_3_2_1
6	[1, 2, 3, NULL]	1_2_3
7	[4, 5, 6, NULL, NULL]	4_5_6


```

+-----+-----+-----+
mysql> select k1, k2, array_join(k2, '_') from array_test01 order by k1;
+-----+-----+-----+
| k1 | k2 | array_join(`k2`, '_') |
+-----+-----+-----+
| 1 | ['a', 'b', 'c', 'd'] | a_b_c_d |
| 2 | ['e', 'f', 'g', 'h'] | e_f_g_h |
| 3 | [NULL, 'a', NULL, 'b', NULL, 'c'] | a_b_c |
| 4 | ['d', 'e', NULL, ' ' ] | d_e_ |
| 5 | [' ', NULL, 'f', 'g'] | _f_g |
+-----+-----+-----+

```

keywords

ARRAY, JOIN, ARRAY_JOIN

ARRAY_WITH_CONSTANT

array_with_constant

提示

该功能自 Apache Doris 1.2 版本起支持

array_with_constant array_repeat

描述

语法

```
ARRAY<T> array_with_constant(n, T)
ARRAY<T> array_repeat(T, n)
```

返回一个数组，包含 n 个重复的 T 常量。array_repeat 与 array_with_constant 功能相同，用来兼容 hive 语法格式。

举例

```
mysql> select array_with_constant(2, "hello"), array_repeat("hello", 2);
```

array_with_constant(2, 'hello') array_repeat('hello', 2)	
['hello', 'hello'] ['hello', 'hello']	

1 row in set (0.04 sec)

```
mysql> select array_with_constant(3, 12345), array_repeat(12345, 3);
```

array_with_constant(3, 12345) array_repeat(12345, 3)	
[12345, 12345, 12345] [12345, 12345, 12345]	

1 row in set (0.01 sec)

```
mysql> select array_with_constant(3, null), array_repeat(null, 3);
```

array_with_constant(3, NULL) array_repeat(NULL, 3)	
[NULL, NULL, NULL] [NULL, NULL, NULL]	

1 row in set (0.01 sec)

```
mysql> select array_with_constant(null, 3), array_repeat(3, null);
```

array_with_constant(NULL, 3) array_repeat(3, NULL)	

[]	[]	
+-----+-----+		
1 row in set (0.01 sec)		

keywords

ARRAY,WITH_CONSTANT,ARRAY_WITH_CONSTANT,ARRAY_REPEAT

ARRAY_ENUMERATE

array_enumerate

array_enumerate

描述

语法

ARRAY<T> array_enumerate(ARRAY<T> arr)

返回数组下标, 例如 [1, 2, 3, ..., length (arr)]

举例

```
mysql> create table array_type_table(k1 INT, k2 Array<STRING>) duplicate key (k1)
-> distributed by hash(k1) buckets 1 properties('replication_num' = '1');
mysql> insert into array_type_table values (0, []), ("1", [NULL]), ("2", ["1", "2", "3"]), ("3", ["1", NULL, "3"]), ("4", NULL);
mysql> select k2, array_enumerate(k2) from array_type_table;
```

k2	array_enumerate(`k2`)
[]	[]
[NULL]	[1]
['1', '2', '3']	[1, 2, 3]
['1', NULL, '3']	[1, 2, 3]
NULL	NULL

5 rows in set (0.01 sec)

keywords

ARRAY,ENUMERATE,ARRAY_ENUMERATE

ARRAY_ENUMERATE_UNIQ

array_enumerate_uniq

array_enumerate_uniq

描述

语法

ARRAY<T> array_enumerate_uniq(ARRAY<T> arr)

返回与源数组大小相同的数组，指示每个元素在具有相同值的元素中的位置，例如 `array_enumerate_uniq([1, 2, 1, 4]) = [1, 1, 2, 1]` 该函数也可接受多个大小相同的数组作为参数，这种情况下，返回的是数组中相同位置的元素组成的元组在具有相同值的元组中的位置。例如 `array_enumerate_uniq([1, 2, 1, 1, 2], [2, 1, 2, 2, 1]) = [1, 1, 2, 3, 2]`

举例

```
mysql> select k2, array_enumerate_uniq([1, 2, 3, 1, 2, 3]);
+-----+
| array_enumerate_uniq(ARRAY(1, 2, 3, 1, 2, 3)) |
+-----+
| [1, 1, 1, 2, 2, 2] |
+-----+
mysql> select array_enumerate_uniq([1, 1, 1, 1, 1], [2, 1, 2, 1, 2], [3, 1, 3, 1, 3]);
+-----+
| array_enumerate_uniq(ARRAY(1, 1, 1, 1, 1), ARRAY(2, 1, 2, 1, 2), ARRAY(3, 1, 3, 1, 3)) |
+-----+
| [1, 1, 2, 1, 3] |
+-----+
```

keywords

ARRAY,ENUMERATE_UNIQ,ARRAY_ENUMERATE_UNIQ

ARRAY_POPBACK

array_popback

array_popback

描述

语法

ARRAY<T> array_popback(ARRAY<T> arr)

返回移除最后一个元素后的数组，如果输入参数为NULL，则返回NULL

举例

```
mysql> select array_popback(['test', NULL, 'value']);
+-----+
| array_popback(ARRAY('test', NULL, 'value')) |
+-----+
| [test, NULL]                                |
+-----+
```

keywords

ARRAY,POPBACK,ARRAY_POPBACK

ARRAY_POPFRONT

array_popfront

array_popfront

描述

语法

ARRAY<T> array_popfront(ARRAY<T> arr)

返回移除第一个元素后的数组，如果输入参数为 NULL，则返回 NULL

举例

```
mysql> select array_popfront(['test', NULL, 'value']);
+-----+
| array_popfront(ARRAY('test', NULL, 'value')) |
+-----+
| [NULL, value]                                |
+-----+
```

keywords

ARRAY,POPFRONT,ARRAY_POPFRONT

ARRAY_PUSHFRONT

array_pushfront

array_pushfront

描述

语法

Array<T> array_pushfront(Array<T> arr, T value) 将 value 添加到数组的开头。

返回值

返回添加 value 后的数组

类型：Array.

举例

```
mysql> select array_pushfront([1, 2], 3);
+-----+
| array_pushfront(ARRAY(1, 2), 3) |
+-----+
| [3, 1, 2]                        |
+-----+

mysql> select col3, array_pushfront(col3, 6) from array_test;
+-----+-----+
| col3      | array_pushfront(`col3`, 6) |
+-----+-----+
| [3, 4, 5] | [6, 3, 4, 5]              |
| [NULL]    | [6, NULL]                  |
| NULL      | NULL                        |
| []        | [6]                         |
+-----+-----+

mysql> select col1, col3, array_pushfront(col3, col1) from array_test;
+-----+-----+-----+
| col1 | col3      | array_pushfront(`col3`, `col1`) |
+-----+-----+-----+
| 0    | [3, 4, 5] | [0, 3, 4, 5]                     |
| 1    | [NULL]    | [1, NULL]                         |
| 2    | NULL      | NULL                             |
| 3    | []        | [3]                              |
+-----+-----+-----+
```

keywords

ARRAY,PUSHFRONT,ARRAY_PUSHFRONT

ARRAY_PUSHBACK

array_pushback

array_pushback

描述

语法

Array<T> array_pushback(Array<T> arr, T value)

将 value 添加到数组的尾部。

返回值

返回添加 value 后的数组

类型：Array.

举例

```
mysql> select array_pushback([1, 2], 3);
+-----+
| array_pushback(ARRAY(1, 2), 3) |
+-----+
| [1, 2, 3]                       |
+-----+

mysql> select col3, array_pushback(col3, 6) from array_test;
+-----+-----+
| col3      | array_pushback(`col3`, 6) |
+-----+-----+
| [3, 4, 5] | [3, 4, 5, 6]              |
| [NULL]    | [NULL, 6]                 |
| NULL      | NULL                      |
| []        | [6]                       |
+-----+-----+

mysql> select col1, col3, array_pushback(col3, col1) from array_test;
+-----+-----+-----+
| col1 | col3      | array_pushback(`col3`, `col1`) |
+-----+-----+-----+
| 0    | [3, 4, 5] | [3, 4, 5, 0]                   |
| 1    | [NULL]    | [NULL, 1]                      |
| 2    | NULL      | NULL                           |
| 3    | []        | [3]                            |
+-----+-----+-----+
```

keywords

ARRAY,PUSHBACK,ARRAY_PUSHBACK

ARRAY_COMPACT

array_compact

array_compact

描述

从数组中删除连续的重复元素，结果值的顺序由源数组中的顺序决定。

语法

Array<T> array_compact(arr)

参数

arr — 需要处理的数组。

返回值

不存在连续重复元素的数组。

Type: Array.

举例

```
select array_compact([1, 2, 3, 3, null, null, 4, 4]);

+-----+
| array_compact(ARRAY(1, 2, 3, 3, NULL, NULL, 4, 4)) |
+-----+
| [1, 2, 3, NULL, 4]                                |
+-----+

select array_compact(['aaa','aaa','bbb','ccc','ccccc',null, null,'dddd']);

+-----+
| array_compact(ARRAY('aaa', 'aaa', 'bbb', 'ccc', 'ccccc', NULL, NULL, 'dddd')) |
+-----+
| ['aaa', 'bbb', 'ccc', 'ccccc', NULL, 'dddd']                                |
+-----+

select array_compact(['2015-03-13','2015-03-13']);

+-----+
| array_compact(ARRAY('2015-03-13', '2015-03-13')) |
+-----+
| ['2015-03-13']                                |
+-----+
```

keywords

ARRAY,COMPACT,ARRAY_COMPACT

ARRAY_CONCAT

array_concat

array_concat

描述

将输入的所有数组拼接为一个数组

语法

Array<T> array_concat(Array<T>, ...)

返回值

拼接好的数组

类型: Array.

举例

```
mysql> select array_concat([1, 2], [7, 8], [5, 6]);
+-----+
| array_concat(ARRAY(1, 2), ARRAY(7, 8), ARRAY(5, 6)) |
+-----+
| [1, 2, 7, 8, 5, 6] |
+-----+
1 row in set (0.02 sec)
```

```
mysql> select col2, col3, array_concat(col2, col3) from array_test;
+-----+-----+-----+
| col2      | col3      | array_concat(`col2`, `col3`) |
+-----+-----+-----+
| [1, 2, 3]  | [3, 4, 5] | [1, 2, 3, 3, 4, 5] |
| [1, NULL, 2] | [NULL]    | [1, NULL, 2, NULL] |
| [1, 2, 3]  | NULL      | NULL |
| []         | []        | [] |
+-----+-----+-----+
```

keywords

ARRAY,CONCAT,ARRAY_CONCAT

ARRAY_ZIP

array_zip

array_zip

描述

将所有数组合并成一个单一的数组。结果数组包含源数组中按参数列表顺序分组的相应元素。

语法

`Array<Struct<T1, T2,...>> array_zip(Array<T1>, Array<T2>, ...)`

返回值

将来自源数组的元素分组为结构体的数组。结构体中的数据类型与输入数组的类型相同，并按照传递数组的顺序排列。

举例

```
mysql> select array_zip(['a', 'b', 'c'], [1, 2, 3]);
+-----+
| array_zip(ARRAY('a', 'b', 'c'), ARRAY(1, 2, 3)) |
+-----+
| [{ 'a', 1}, { 'b', 2}, { 'c', 3}]                |
+-----+
1 row in set (0.01 sec)
```

keywords

ARRAY,ZIP,ARRAY_ZIP

ARRAY_SHUFFLE

array_shuffle

array_shuffle shuffle

描述

语法

```
ARRAY<T> array_shuffle(ARRAY<T> array1, [INT seed])
ARRAY<T> shuffle(ARRAY<T> array1, [INT seed])
```

将数组中元素进行随机排列。其中，参数 array1 为要进行随机排列的数组，可选参数 seed 是设定伪随机数生成器用于生成伪随机数的初始数值。shuffle 与 array_shuffle 功能相同。

```
array_shuffle(array1);
array_shuffle(array1, 0);
shuffle(array1);
shuffle(array1, 0);
```

举例

```
mysql [test]> select c_array1, array_shuffle(c_array1) from array_test;
+-----+-----+
| c_array1          | array_shuffle(`c_array1`) |
+-----+-----+
| [1, 2, 3, 4, 5, NULL] | [2, NULL, 5, 3, 4, 1]      |
| [6, 7, 8, NULL]      | [7, NULL, 8, 6]           |
| [1, NULL]            | [1, NULL]                 |
| NULL                | NULL                      |
+-----+-----+
4 rows in set (0.01 sec)

MySQL [test]> select c_array1, array_shuffle(c_array1, 0) from array_test;
+-----+-----+
| c_array1          | array_shuffle(`c_array1`, 0) |
+-----+-----+
| [1, 2, 3, 4, 5, NULL] | [1, 3, 2, NULL, 4, 5]        |
| [6, 7, 8, NULL]      | [6, 8, 7, NULL]             |
| [1, NULL]            | [1, NULL]                   |
| NULL                | NULL                        |
+-----+-----+
4 rows in set (0.01 sec)
```

keywords

ARRAY,ARRAY_SHUFFLE,SHUFFLE

ARRAY_CUM_SUM

array_cum_sum

array_cum_sum

描述

返回数组的累计和。数组中的NULL值会被跳过，并在结果数组的相同位置设置NULL。

语法

```
Array<T> array_cum_sum(Array<T>)
```

举例

```
mysql> create table array_type_table(k1 INT, k2 Array<int>) duplicate key (k1) distributed by hash(k1)
buckets 1 properties('replication_num' = '1');
mysql> insert into array_type_table values (0, []), (1, [NULL]), (2, [1, 2, 3, 4]), (3, [1, NULL, 3, NULL,
5]);
mysql> select k2, array_cum_sum(k2) from array_type_table;
```

k2	array_cum_sum(`k2`)
[]	[]
[NULL]	[NULL]
[1, 2, 3, 4]	[1, 3, 6, 10]
[1, NULL, 3, NULL, 5]	[1, NULL, 4, NULL, 9]

4 rows in set
Time: 0.122s

keywords

ARRAY,CUM_SUM,ARRAY_CUM_SUM

ARRAY_EXISTS

array_exists

array_exists(lambda,array1,array2....) array_exists(array1)

描述

语法

```
BOOLEAN array_exists(lambda, ARRAY<T> arr1, ARRAY<T> arr2, ... )
BOOLEAN array_exists(ARRAY<T> arr)
```

使用一个可选 lambda 表达式作为输入参数，对其他的输入 ARRAY 参数的内部数据做对应表达式计算。当计算返回非 0 时，返回 1；否则返回 0。在 lambda 表达式中输入的参数为 1 个或多个，必须和后面的输入 array 列数量一致。在 lambda 中可以执行合法的标量函数，不支持聚合函数等。在没有使用 lambda 作为参数时，array1 作为计算结果。

```
array_exists(x->x, array1);
array_exists(x->(x%2 = 0), array1);
array_exists(x->(abs(x)-1), array1);
array_exists((x,y)->(x = y), array1, array2);
array_exists(array1);
```

举例

```
mysql [test]>select *, array_exists(x->x>1,[1,2,3]) from array_test2 order by id;
+-----+-----+-----+-----+
| id | c_array1 | c_array2 | array_exists([x] -> x(0) > 1, ARRAY(1, 2, 3)) |
+-----+-----+-----+-----+
| 1 | [1, 2, 3, 4, 5] | [10, 20, -40, 80, -100] | [0, 1, 1] |
| 2 | [6, 7, 8] | [10, 12, 13] | [0, 1, 1] |
| 3 | [1] | [-100] | [0, 1, 1] |
| 4 | NULL | NULL | [0, 1, 1] |
+-----+-----+-----+-----+
4 rows in set (0.02 sec)

mysql [test]>select c_array1, c_array2, array_exists(x->x%2=0,[1,2,3]) from array_test2 order by id;
+-----+-----+-----+-----+
| c_array1 | c_array2 | array_exists([x] -> x(0) % 2 = 0, ARRAY(1, 2, 3)) |
+-----+-----+-----+-----+
| [1, 2, 3, 4, 5] | [10, 20, -40, 80, -100] | [0, 1, 0] |
| [6, 7, 8] | [10, 12, 13] | [0, 1, 0] |
| [1] | [-100] | [0, 1, 0] |
| NULL | NULL | [0, 1, 0] |
+-----+-----+-----+-----+
4 rows in set (0.02 sec)

mysql [test]>select c_array1, c_array2, array_exists(x->abs(x)-1,[1,2,3]) from array_test2 order by id;
+-----+-----+-----+-----+
```

c_array1	c_array2	array_exists([x] -> abs(x(0)) - 1, ARRAY(1, 2, 3))
[1, 2, 3, 4, 5]	[10, 20, -40, 80, -100]	[0, 1, 1, 1, 1]
[6, 7, 8]	[10, 12, 13]	[1, 1, 1]
[1, NULL]	[-100]	[0, NULL]
NULL	NULL	NULL

4 rows in set (0.02 sec)

```
mysql [test]>select c_array1, c_array2, array_exists((x,y)->x>y,c_array1,c_array2) from array_test2 order by id;
```

c_array1	c_array2	array_exists([x, y] -> x(0) > y(1), `c_array1`, `c_array2`)
[1, 2, 3, 4, 5]	[10, 20, -40, 80, -100]	[0, 0, 1, 0, 1]
[6, 7, 8]	[10, 12, 13]	[0, 0, 0]
[1]	[-100]	[1]
NULL	NULL	NULL

4 rows in set (0.02 sec)

```
mysql [test]>select *, array_exists(c_array1) from array_test2 order by id;
```

id	c_array1	c_array2	array_exists(`c_array1`)
1	[1, 2, 3, 0, 5]	[10, 20, -40, 80, -100]	[1, 1, 1, 0, 1]
2	[6, 7, 8]	[10, 12, 13]	[1, 1, 1]
3	[0, NULL]	[-100]	[0, NULL]
4	NULL	NULL	NULL

4 rows in set (0.02 sec)

keywords

ARRAY,ARRAY_EXISTS

ARRAY_FIRST_INDEX

array_first_index

array_first_index

描述

语法

ARRAY<T> array_first_index(lambda, ARRAY<T> array1, ...)

使用 lambda 表达式作为输入参数，对其他输入 ARRAY 参数的内部数据进行相应的表达式计算。返回第一个使得 lambda(array1[i], ...) 返回值不为 0 的索引。如果没找到满足此条件的索引，则返回 0。

在 lambda 表达式中输入的参数为 1 个或多个，所有输入的 array 的元素数量必须一致。在 lambda 中可以执行合法的标量函数，不支持聚合函数等。

```
array_first_index(x->x>1, array1);
array_first_index(x->(x%2 = 0), array1);
array_first_index(x->(abs(x)-1), array1);
array_first_index((x,y)->(x = y), array1, array2);
```

举例

```
mysql> select array_first_index(x->x+1>3, [2, 3, 4]);
+-----+
| array_first_index(array_map([x] -> x(0) + 1 > 3, ARRAY(2, 3, 4))) |
+-----+
|                                                                    2 |
+-----+

mysql> select array_first_index(x -> x is null, [null, 1, 2]);
+-----+
| array_first_index(array_map([x] -> x(0) IS NULL, ARRAY(NULL, 1, 2))) |
+-----+
|                                                                    1 |
+-----+

mysql> select array_first_index(x->power(x,2)>10, [1, 2, 3, 4]);
+-----+
| array_first_index(array_map([x] -> power(x(0), 2.0) > 10.0, ARRAY(1, 2, 3, 4))) |
+-----+
|                                                                    4 |
+-----+

mysql> select col2, col3, array_first_index((x,y)->x>y, col2, col3) from array_test;
+-----+-----+-----+
| col2      | col3      | array_first_index(array_map([x, y] -> x(0) > y(1), `col2`, `col3`)) |
+-----+-----+-----+
| [1, 2, 3]  | [3, 4, 5]  | 0 |
| [1, NULL, 2] | [NULL, 3, 1] | 3 |
| [1, 2, 3]  | [9, 8, 7]  | 0 |
```

NULL	NULL		0
+	+	+	+

keywords

ARRAY,FIRST_INDEX,ARRAY_FIRST_INDEX

ARRAY_LAST_INDEX

array_last_index

array_last_index

描述

语法

```
ARRAY<T> array_last_index(lambda, ARRAY<T> array1, ...)
```

使用 lambda 表达式作为输入参数，对其他输入 ARRAY 参数的内部数据进行相应的表达式计算。返回最后一个使得 lambda(array1[i], ...) 返回值不为 0 的索引。如果没找到满足此条件的索引，则返回 0。

在 lambda 表达式中输入的参数为 1 个或多个，所有输入的 array 的元素数量必须一致。在 lambda 中可以执行合法的标量函数，不支持聚合函数等。

```
array_last_index(x->x>1, array1);
array_last_index(x->(x%2 = 0), array1);
array_last_index(x->(abs(x)-1), array1);
array_last_index((x,y)->(x = y), array1, array2);
```

举例

```
mysql> select array_last_index(x->x+1>3, [2, 3, 4]);
+-----+
| array_last_index(array_map([x] -> x(0) + 1 > 3, ARRAY(2, 3, 4))) |
+-----+
|                                                                    3 |
+-----+

mysql> select array_last_index(x -> x is null, [null, 1, 2]);
+-----+
| array_last_index(array_map([x] -> x(0) IS NULL, ARRAY(NULL, 1, 2))) |
+-----+
|                                                                    1 |
+-----+

mysql> select array_last_index(x->power(x,2)>10, [1, 2, 3, 4]);
+-----+
| array_last_index(array_map([x] -> power(x(0), 2.0) > 10.0, ARRAY(1, 2, 3, 4))) |
+-----+
|                                                                    4 |
+-----+

mysql> select c_array1, c_array2, array_last_index((x,y)->x>y, c_array1, c_array2) from array_index_table
order by id;
+-----+-----+-----+
| c_array1 | c_array2 | array_last_index(array_map([x, y] -> x > y, `c_array1`, `c_array2`)) |
+-----+-----+-----+
```

```

-----+
| [1, 2, 3, 4, 5] | [10, 20, -40, 80, -100] |
5 |
| [6, 7, 8]      | [10, 12, 13]      |
0 |
| [1]            | [-100]              |
1 |
| [1, NULL, 2]   | [NULL, 3, 1]        |
3 |
| []             | []                  |
0 |
| NULL           | NULL                |
0 |
+-----+-----+-----+
-----+

```

keywords

ARRAY,FIRST_INDEX,array_last_index

ARRAY_FIRST

array_first

array_first

描述

返回数组中的第一个 func(arr1[i]) 值不为 0 的元素。当数组中所有元素进行 func(arr1[i]) 都为 0 时，结果返回 NULL 值。

语法

```
T array_first(lambda, ARRAY<T>)
```

使用一个 lambda 表达式和一个 ARRAY 作为输入参数，lambda 表达式为布尔型，用于对 ARRAY 中的每个元素进行判断返回值。

举例

```
mysql> select array_first(x->x>2, [1,2,3,0]) ;
+-----+
| array_first(array_filter(ARRAY(1, 2, 3, 0), array_map([x] -> x(0) > 2, ARRAY(1, 2, 3, 0))), -1) |
+-----+
|                                                                                                     3 |
+-----+

mysql> select array_first(x->x>4, [1,2,3,0]) ;
+-----+
| array_first(array_filter(ARRAY(1, 2, 3, 0), array_map([x] -> x(0) > 4, ARRAY(1, 2, 3, 0))), -1) |
+-----+
|                                                                                                     NULL |
+-----+

mysql> select array_first(x->x>1, [1,2,3,0]) ;
+-----+
| array_first(array_filter(ARRAY(1, 2, 3, 0), array_map([x] -> x > 1, ARRAY(1, 2, 3, 0))), 1) |
+-----+
|                                                                                                     2 |
+-----+
```

keywords

ARRAY, LAST, array_first

ARRAY_LAST

array_last

array_last

描述

返回数组中的最后一个 func(arr1[i]) 值不为 0 的元素。当数组中所有元素进行 func(arr1[i]) 都为 0 时，结果返回 NULL 值。

语法

```
T array_last(lambda, ARRAY<T>)
```

使用一个 lambda 表达式和一个 ARRAY 作为输入参数，lambda 表达式为布尔型，用于对 ARRAY 中的每个元素进行判断返回值。

举例

```
mysql> select array_last(x->x>2, [1,2,3,0]) ;
+-----+
| array_last(array_filter(ARRAY(1, 2, 3, 0), array_map([x] -> x(0) > 2, ARRAY(1, 2, 3, 0))), -1) |
+-----+
|                                                                                               3 |
+-----+

mysql> select array_last(x->x>4, [1,2,3,0]) ;
+-----+
| array_last(array_filter(ARRAY(1, 2, 3, 0), array_map([x] -> x(0) > 4, ARRAY(1, 2, 3, 0))), -1) |
+-----+
|                                                                                               NULL |
+-----+
```

keywords

ARRAY, LAST, ARRAY_LAST

ARRAYS_OVERLAP

arrays_overlap

arrays_overlap

描述

语法

BOOLEAN arrays_overlap(ARRAY<T> left, ARRAY<T> right)

判断left和right数组中是否包含公共元素。返回结果如下：

1

- left和right数组存在公共元素；

0

- left和right数组不存在公共元素；

NULL

- left或者right数组为NULL；或者left和right数组中，任意元素为NULL；

举例

mysql> select c_left,c_right,arrays_overlap(c_left,c_right) from array_test;

c_left	c_right	arrays_overlap(`c_left`, `c_right`)
[1, 2, 3]	[3, 4, 5]	1
[1, 2, 3]	[5, 6]	0
[1, 2, NULL]	[1]	NULL
NULL	[1, 2]	NULL
[1, 2, 3]	[1, 2]	1

keywords

ARRAY,ARRAYS,OVERLAP,ARRAYS_OVERLAP

ARRAY_COUNT

array_count

array_count

描述

```
array_count(lambda, array1, ...)
```

使用 lambda 表达式作为输入参数，对其他输入 ARRAY 参数的内部数据进行相应的表达式计算。返回使得 lambda(array1[i], ...) 返回值不为 0 的元素数量。如果找不到满足此条件的元素，则返回 0。

lambda 表达式中输入的参数为 1 个或多个，必须和后面输入的数组列数一致，且所有输入的 array 的元素个数必须相同。在 lambda 中可以执行合法的标量函数，不支持聚合函数等。

```
array_count(x->x, array1);
array_count(x->(x%2 = 0), array1);
array_count(x->(abs(x)-1), array1);
array_count((x,y)->(x = y), array1, array2);
```

举例

```
mysql> select array_count(x -> x, [0, 1, 2, 3]);
+-----+
| array_count(array_map([x] -> x(0), ARRAY(0, 1, 2, 3))) |
+-----+
| 3 |
+-----+
1 row in set (0.00 sec)

mysql> select array_count(x -> x > 2, [0, 1, 2, 3]);
+-----+
| array_count(array_map([x] -> x(0) > 2, ARRAY(0, 1, 2, 3))) |
+-----+
| 1 |
+-----+
1 row in set (0.01 sec)

mysql> select array_count(x -> x is null, [null, null, null, 1, 2]);
+-----+
| array_count(array_map([x] -> x(0) IS NULL, ARRAY(NULL, NULL, NULL, 1, 2))) |
+-----+
| 3 |
+-----+
1 row in set (0.01 sec)

mysql> select array_count(x -> power(x,2)>10, [1, 2, 3, 4, 5]);
+-----+
| array_count(array_map([x] -> power(x(0), 2.0) > 10.0, ARRAY(1, 2, 3, 4, 5))) |
+-----+
| 2 |
+-----+
```

```

+-----+
1 row in set (0.01 sec)

mysql> select *, array_count((x, y) -> x>y, c_array1, c_array2) from array_test;
+-----+
| id | c_array1 | c_array2 | array_count(array_map([x, y] -> x(0) > y(1), `c_array1`, `c_array2`)) |
+-----+
| 1 | [1, 2, 3, 4, 5] | [10, 20, -40, 80, -100] | 2 |
| 2 | [6, 7, 8] | [10, 12, 13] | 0 |
| 3 | [1] | [-100] | 1 |
| 4 | [1, NULL, 2] | [NULL, 3, 1] | 1 |
| 5 | [] | [] | 0 |
| 6 | NULL | NULL | 0 |
+-----+
6 rows in set (0.02 sec)

```

keywords

ARRAY, COUNT, ARRAY_COUNT

ARRAY_APPLY

array_apply

array_apply

描述

数组以特定的二元条件符过滤元素，并返回过滤后的结果

语法

```
array_apply(arr, op, val)
```

参数

arr — 输入的数组，如果是null，则返回null op — 过滤条件，条件包括 =, >=, <=, >, <, !=, 仅支持常量 val — 过滤的条件值，如果是null，则返回null，仅支持常量

返回值

过滤后的数组

类型: Array.

举例

```
mysql> select array_apply([1, 2, 3, 4, 5], ">=", 2);
+-----+
| array_apply(ARRAY(1, 2, 3, 4, 5), '>=', 2) |
+-----+
| [2, 3, 4, 5]                               |
+-----+
1 row in set (0.01 sec)

mysql> select array_apply([1000000, 1000001, 1000002], "=", "1000002");
+-----+
| array_apply(ARRAY(1000000, 1000001, 1000002), '=', 1000002) |
+-----+
| [1000002]                                                       |
+-----+
1 row in set (0.01 sec)
```

keywords

ARRAY,APPLY,ARRAY_APPLY



keywords

ARRAY,COUNTEQUAL

ELEMENT_AT

element_at

element_at

描述

语法

```
T element_at(ARRAY<T> arr, BIGINT position)
T arr[position]
```

返回数组中位置为 position 的元素。如果该位置上元素不存在，返回NULL。position 从1开始，并且支持负数。

举例

position 为正数使用范例:

```
mysql> SELECT id,c_array,element_at(c_array, 5) FROM `array_test`;
+-----+-----+-----+
| id | c_array | element_at(`c_array`, 5) |
+-----+-----+-----+
| 1 | [1, 2, 3, 4, 5] | 5 |
| 2 | [6, 7, 8] | NULL |
| 3 | [] | NULL |
| 4 | NULL | NULL |
+-----+-----+-----+
```

position 为负数使用范例:

```
mysql> SELECT id,c_array,c_array[-2] FROM `array_test`;
+-----+-----+-----+
| id | c_array | %element_extract%(`c_array`, -2) |
+-----+-----+-----+
| 1 | [1, 2, 3, 4, 5] | 4 |
| 2 | [6, 7, 8] | 7 |
| 3 | [] | NULL |
| 4 | NULL | NULL |
+-----+-----+-----+
```

keywords

ELEMENT_AT, SUBSCRIPT

CONVERT_TZ

convert_tz

描述

语法

DATETIME CONVERT_TZ(DATETIME dt, VARCHAR from_tz, VARCHAR to_tz)

转换datetime值，从 from_tz 给定时区转到 to_tz 给定时区，并返回结果值。如果参数无效该函数返回NULL。

举例

```
mysql> select convert_tz('2019-08-01 13:21:03', 'Asia/Shanghai', 'America/Los_Angeles');
+-----+
| convert_tz('2019-08-01 13:21:03', 'Asia/Shanghai', 'America/Los_Angeles') |
+-----+
| 2019-07-31 22:21:03 |
+-----+

mysql> select convert_tz('2019-08-01 13:21:03', '+08:00', 'America/Los_Angeles');
+-----+
| convert_tz('2019-08-01 13:21:03', '+08:00', 'America/Los_Angeles') |
+-----+
| 2019-07-31 22:21:03 |
+-----+
```

keywords

CONVERT_TZ

CURDATE,CURRENT_DATE

curdate,current_date

描述

语法

DATE CURDATE()

获取当前的日期，以DATE类型返回

举例s

```
mysql> SELECT CURDATE();
+-----+
| CURDATE() |
+-----+
| 2019-12-20 |
+-----+

mysql> SELECT CURDATE() + 0;
+-----+
| CURDATE() + 0 |
+-----+
|      20191220 |
+-----+
```

keywords

CURDATE,CURRENT_DATE

CURTIME,CURRENT_TIME

curtime,current_time

Syntax

TIME CURTIME()

描述

获得当前的时间，以TIME类型返回

举例s

```
mysql> select current_time();
+-----+
| current_time() |
+-----+
| 15:25:47       |
+-----+
```

keywords

CURTIME,CURRENT_TIME

CURRENT_TIMESTAMP

描述

函数用于获取当前系统时间，返回值为日期时间类型（DATETIME）。可以选择性地指定精度以调整返回值的小数秒部分的位数。

语法

```
CURRENT_TIMESTAMP([<precision>])
```

参数

参数	说明
<precision>	可选参数，表示返回值的小数秒部分的精度，取值范围为 0 到 6。默认为 0，即不返回小数秒部分。 受限于JDK实现，如果用户使用JDK8构建FE，则精度最多支持到毫秒（小数点后三位），更大的精度位将全部填充0。如果用户有更高精度需求，请使用JDK11。

返回值

- 返回当前系统时间，类型为 DATETIME
- 如果指定的 <precision> 超出范围（如为负数或大于 6），函数会返回错误。

举例

```
select CURRENT_TIMESTAMP(),CURRENT_TIMESTAMP(3),CURRENT_TIMESTAMP(6);
```

now()	now(3)	now(6)
2025-01-23 11:26:01	2025-01-23 11:26:01.771	2025-01-23 11:26:01.771000

LOCALTIME,LOCALTIMESTAMP

描述

函数用于获取当前系统时间，返回值为日期时间类型（DATETIME）。可以选择性地指定精度以调整返回值的小数秒部分的位数。

语法

```
LOCALTIME([<precision>])
LOCALTIMESTAMP([<precision>]))
```

参数

参数	说明
<precision>	可选参数，表示返回值的小数秒部分的精度，取值范围为 0 到 6。默认为 0，即不返回小数秒部分。 受限于JDK实现，如果用户使用JDK8构建FE，则精度最多支持到毫秒（小数点后三位），更大的精度位将全部填充0。如果用户有更高精度需求，请使用JDK11。

返回值

- 返回当前系统时间，类型为 DATETIME
- 如果指定的 <precision> 超出范围（如为负数或大于 6），函数会返回错误。

举例

```
select LOCALTIME(),LOCALTIME(3),LOCALTIME(6);
```

now()	now(3)	now(6)
2025-01-23 11:50:18	2025-01-23 11:50:18.883	2025-01-23 11:50:18.883000

NOW

描述

函数用于获取当前系统时间，返回值为日期时间类型（DATETIME）。可以选择性地指定精度以调整返回值的小数秒部分的位数。

语法

```
NOW([<precision>])
```

参数

参数	说明
<precision>	可选参数，表示返回值的小数秒部分的精度，取值范围为 0 到 6。默认为 0，即不返回小数秒部分。 受限于JDK实现，如果用户使用JDK8构建FE，则精度最多支持到毫秒（小数点后三位），更大的精度位将全部填充0。如果用户有更高精度需求，请使用JDK11。

返回值

- 返回当前系统时间，类型为 DATETIME
- 如果指定的 <precision> 超出范围（如为负数或大于 6），函数会返回错误。

举例

```
select NOW(),NOW(3),NOW(6);
```

now()	now(3)	now(6)
2025-01-23 11:08:35	2025-01-23 11:08:35.561	2025-01-23 11:08:35.562000

YEAR

year

描述

语法

INT YEAR(DATETIME date)

返回date类型的year部分，范围从1000-9999

参数为Date或者Datetime类型

举例

```
mysql> select year('1987-01-01');
+-----+
| year('1987-01-01 00:00:00') |
+-----+
| 1987 |
+-----+
```

keywords

YEAR

QUARTER

描述

函数用于返回指定 日期所属的季度（1 到 4）。每个季度包含三个月： - 第 1 季度：1 月至 3 月 - 第 2 季度：4 月至 6 月 - 第 3 季度：7 月至 9 月 - 第 4 季度：10 月至 12 月

语法

```
QUARTER(<datetime>)
```

参数

参数	说明
<datetime>	输入的日期或日期时间值，必须是有效的 DATE 或 DATETIME 类型。

返回值

- 返回一个整数，表示输入日期所属的季度，范围为 1 到 4。
- 如果输入值为 NULL，函数返回 NULL。
- 如果输入值为非法日期（如 0000-00-00），函数返回 NULL。

举例

```
SELECT QUARTER('2025-01-16'),QUARTER('2025-01-16 01:11:10');
```

quarter(cast('2025-01-16' as DATETIME))	quarter(cast('2025-01-16 01:11:10' as DATETIME))
1	1

MONTH

month

描述

语法

INT MONTH(DATETIME date)

返回时间类型中的月份信息，范围是1, 12

参数为Date或者Datetime类型

举例

```
mysql> select month('1987-01-01');
+-----+
| month('1987-01-01 00:00:00') |
+-----+
|                               1 |
+-----+
```

keywords

MONTH

DAY

day

描述

语法

INT DAY(DATETIME date)

获得日期中的天信息，返回值范围从1-31。

参数为Date或者Datetime类型

举例

```
mysql> select day('1987-01-31');
+-----+
| day('1987-01-31 00:00:00') |
+-----+
|                             31 |
+-----+
```

keywords

DAY

DAYOFYEAR

dayofyear

描述

语法

INT DAYOFYEAR(DATETIME date)

获得日期中对应当年中的哪一天。

参数为Date或者Datetime类型

举例

```
mysql> select dayofyear('2007-02-03 00:00:00');
+-----+
| dayofyear('2007-02-03 00:00:00') |
+-----+
|                                34 |
+-----+
```

keywords

DAYOFYEAR

DAYOFMONTH

dayofmonth

描述

语法

INT DAYOFMONTH(DATETIME date)

获得日期中的天信息，返回值范围从1-31。

参数为Date或者Datetime类型

举例

```
mysql> select dayofmonth('1987-01-31');
+-----+
| dayofmonth('1987-01-31 00:00:00') |
+-----+
|                                31 |
+-----+
```

keywords

DAYOFMONTH

DAYOFWEEK

dayofweek

描述

语法

INT DAYOFWEEK(DATETIME date)

DAYOFWEEK函数返回日期的工作日索引值，即星期日为1，星期一为2，星期六为7

参数为Date或者Datetime类型或者可以cast为Date或者Datetime类型的数字

举例

```
mysql> select dayofweek('2019-06-25');
+-----+
| dayofweek('2019-06-25 00:00:00') |
+-----+
|                                3 |
+-----+

mysql> select dayofweek(cast(20190625 as date));
+-----+
| dayofweek(CAST(20190625 AS DATE)) |
+-----+
|                                3 |
+-----+
```

keywords

DAYOFWEEK

WEEK

week

描述

语法

INT WEEK(DATE date[, INT mode])

返回指定日期的星期数。mode的值默认为0。参数mode的作用参见下面的表格：

Mode	星期的第一天	星期数的范围	第一个星期的定义
0	星期日	0-53	这一年中的第一个星期日所在的星期
1	星期一	0-53	这一年的日期所占的天数大于等于4天的第一个星期
2	星期日	1-53	这一年中的第一个星期日所在的星期
3	星期一	1-53	这一年的日期所占的天数大于等于4天的第一个星期
4	星期日	0-53	这一年的日期所占的天数大于等于4天的第一个星期
5	星期一	0-53	这一年中的第一个星期一所在的星期
6	星期日	1-53	这一年的日期所占的天数大于等于4天的第一个星期
7	星期一	1-53	这一年中的第一个星期一所在的星期

参数为Date或者Datetime类型

举例

```
mysql> select week('2020-1-1');
+-----+
| week('2020-1-1') |
+-----+
|                0 |
+-----+

mysql> select week('2020-7-1',1);
+-----+
| week('2020-7-1', 1) |
+-----+
|                27 |
+-----+
```

keywords

WEEK

WEEKDAY

weekday

描述

语法

INT WEEKDAY (DATETIME date)

WEEKDAY函数返回日期的工作日索引值，即星期一为0，星期二为1，星期日为6

参数为Date或者Datetime类型或者可以cast为Date或者Datetime类型的数字

注意WEEKDAY和DAYOFWEEK的区别：

	Sun	Mon	Tues	Wed	Thur	Fri	Sat	
weekday	6	0	1	2	3	4	5	
dayofweek	1	2	3	4	5	6	7	

举例

```
mysql> select weekday('2019-06-25');
+-----+
| weekday('2019-06-25 00:00:00') |
+-----+
| 1 |
+-----+

mysql> select weekday(cast(20190625 as date));
+-----+
| weekday(CAST(20190625 AS DATE)) |
+-----+
| 1 |
+-----+
```

keywords

WEEKDAY

WEEKOFYEAR

weekofyear

描述

语法

INT WEEKOFYEAR(DATETIME date)

获得一年中的第几周

参数为Date或者Datetime类型

举例

```
mysql> select weekofyear('2008-02-20 00:00:00');
+-----+
| weekofyear('2008-02-20 00:00:00') |
+-----+
|                                8 |
+-----+
```

keywords

```
WEEKOFYEAR
```


YEARWEEK

yearweek

描述

语法

INT YEARWEEK(DATE date[, INT mode])

返回指定日期的年份和星期数。mode的值默认为0。当日期所在的星期属于上一年时，返回的是上一年的年份和星期数；当日期所在的星期属于下一年时，返回的是下一年的年份，星期数为1。参数mode的作用参见下面的表格：

Mode	星期的第一天	星期数的范围	第一个星期的定义
0	星期日	1-53	这一年中的第一个星期日所在的星期
1	星期一	1-53	这一年的日期所占的天数大于等于4天的第一个星期
2	星期日	1-53	这一年中的第一个星期日所在的星期
3	星期一	1-53	这一年的日期所占的天数大于等于4天的第一个星期
4	星期日	1-53	这一年的日期所占的天数大于等于4天的第一个星期
5	星期一	1-53	这一年中的第一个星期一所在的星期
6	星期日	1-53	这一年的日期所占的天数大于等于4天的第一个星期
7	星期一	1-53	这一年中的第一个星期一所在的星期

参数为Date或者Datetime类型

举例

```
mysql> select yearweek('2021-1-1');
+-----+
| yearweek('2021-1-1') |
+-----+
|           202052 |
+-----+

mysql> select yearweek('2020-7-1');
+-----+
| yearweek('2020-7-1') |
+-----+
|           202026 |
+-----+

mysql> select yearweek('2024-12-30',1);
+-----+
```

	yearweek('2024-12-30 00:00:00', 1)	
+-----+		
	202501	
+-----+		

keywords

YEARWEEK

DAYNAME

dayname

描述

语法

VARCHAR DAYNAME (DATE)

返回日期对应的日期名字

参数为Date或者Datetime类型

举例

```
mysql> select dayname('2007-02-03 00:00:00');
+-----+
| dayname('2007-02-03 00:00:00') |
+-----+
| Saturday                        |
+-----+
```

keywords

DAYNAME

MONTHNAME

monthname

描述

语法

VARCHAR MONTHNAME (DATE)

返回日期对应的月份名字

参数为Date或者Datetime类型

举例

```
mysql> select monthname('2008-02-03 00:00:00');
+-----+
| monthname('2008-02-03 00:00:00') |
+-----+
| February                          |
+-----+
```

keywords

MONTHNAME

HOUR

hour

描述

语法

INT HOUR(DATETIME date)

获得日期中的小时的信息，返回值范围从0-23。

参数为Date或者Datetime类型

举例

```
mysql> select hour('2018-12-31 23:59:59');
+-----+
| hour('2018-12-31 23:59:59') |
+-----+
|                               23 |
+-----+
```

keywords

HOUR

MINUTE

minute

描述

语法

INT MINUTE(DATETIME date)

获得日期中的分钟的信息，返回值范围从0-59。

参数为Date或者Datetime类型

举例

```
mysql> select minute('2018-12-31 23:59:59');
+-----+
| minute('2018-12-31 23:59:59') |
+-----+
|                               59 |
+-----+
```

keywords

MINUTE

SECOND

描述

函数用于返回指定日期时间值中的秒数部分。秒数的范围是 0 到 59。

语法

```
SECOND(<datetime>)
```

参数

参数	说明
<datetime>	输入的日期或日期时间值，支持 DATE 或 DATETIME 类型。

返回值

- 返回一个整数，表示输入日期时间值中的秒数部分，范围为 0 到 59。
- 如果输入值为 NULL，函数返回 NULL。
- 如果输入值为非法日期（如 0000-00-00 00:00:00），函数返回 NULL。

举例

```
select second('2018-12-31 23:59:59');
```

second(cast('2018-12-31 23:59:59' as DATETIMEV2(0)))
59

FROM_DAYS

from_days

描述

语法

DATE FROM_DAYS(INT N)

给定一个天数，返回一个DATE。注意，为了和mysql保持一致的行为，不存在0000-02-29这个日期。

举例

```
mysql> select from_days(730669);
+-----+
| from_days(730669) |
+-----+
| 2000-07-03         |
+-----+

mysql> select from_days (5);
+-----+
| from_days(5) |
+-----+
| 0000-01-05   |
+-----+

mysql> select from_days (59);
+-----+
| from_days(59) |
+-----+
| 0000-02-28    |
+-----+

mysql> select from_days (60);
+-----+
| from_days(60) |
+-----+
| 0000-03-01    |
+-----+
```

keywords

FROM_DAYS, FROM, DAYS

LAST_DAY

last_day

描述

语法

DATE last_day(DATETIME date)

返回输入日期中月份的最后一天；所以返回的日期中，年和月不变，日可能是如下情况：‘28’(非闰年的二月份), ‘29’(闰年的二月份), ‘30’(四月，六月，九月，十一月), ‘31’(一月，三月，五月，七月，八月，十月，十二月)

举例

```
mysql > select last_day('2000-02-03');
+-----+
| last_day('2000-02-03 00:00:00') |
+-----+
| 2000-02-29                       |
+-----+
```

keywords

LAST_DAY,DAYS

TO_MONDAY

to_monday

描述

语法

DATE to_monday(DATETIME date)

将日期或带时间的日期向下舍入到最近的星期一。作为一种特殊情况，日期参数 1970-01-01、1970-01-02、1970-01-03 和 1970-01-04 返回日期 1970-01-01

举例

```
MySQL [(none)]> select to_monday('2022-09-10');
+-----+
| to_monday('2022-09-10 00:00:00') |
+-----+
| 2022-09-05                        |
+-----+
```

keywords

MONDAY

FROM_SECOND

描述

函数将输入的 Unix 时间戳（以秒为单位）转换为 DATETIME 类型的日期时间值。

语法

```
FROM_SECOND(<unix_timestamp>)
```

参数

参数	说明
<unix_timestamp>	必填，输入的 Unix 时间戳，表示从 1970-01-01 00:00:00 UTC 开始的秒数。

返回值

- 返回一个 DATETIME 类型的值，表示输入的 Unix 时间戳对应的日期时间。
- 如果 <unix_timestamp> 为 NULL，函数返回 NULL。
- 如果 <unix_timestamp> 超出有效范围，函数返回错误。

举例

```
SELECT FROM_SECOND(1700000000);
```

+-----+
from_second(1700000000)
+-----+
2023-11-15 06:13:20
+-----+

FROM_UNIXTIME

from_unixtime

描述

语法

DATETIME FROM_UNIXTIME(BIGINT unix_timestamp[, VARCHAR string_format])

将 unix 时间戳转化为对应的 time 格式，返回的格式由 string_format 指定

支持 date_format 中的 format 格式，默认为 %Y-%m-%d %H:%i:%s

传入的是整型，返回的是字符串类型

目前支持的 unix_timestamp 范围为 [0, 32536771199]，超出范围的 unix_timestamp 将会得到 NULL

举例

```
mysql> select from_unixtime(1196440219);
+-----+
| from_unixtime(1196440219) |
+-----+
| 2007-12-01 00:30:19      |
+-----+

mysql> select from_unixtime(1196440219, 'yyyy-MM-dd HH:mm:ss');
+-----+
| from_unixtime(1196440219, 'yyyy-MM-dd HH:mm:ss') |
+-----+
| 2007-12-01 00:30:19                                |
+-----+

mysql> select from_unixtime(1196440219, '%Y-%m-%d');
+-----+
| from_unixtime(1196440219, '%Y-%m-%d') |
+-----+
| 2007-12-01                             |
+-----+

mysql> select from_unixtime(1196440219, '%Y-%m-%d %H:%i:%s');
+-----+
| from_unixtime(1196440219, '%Y-%m-%d %H:%i:%s') |
+-----+
| 2007-12-01 00:30:19                                |
+-----+
```

对于超过范围的时间戳，可以采用from_second函数 DATETIME FROM_SECOND(BIGINT unix_timestamp)

```
mysql> select from_second(21474836470);
+-----+
| from_second(21474836470) |
+-----+
```

```
+-----+
| 2650-07-06 16:21:10 |
+-----+
```

keywords

FROM_UNIXTIME, FROM, UNIXTIME

UNIX_TIMESTAMP

unix_timestamp

描述

语法

```
INT UNIX_TIMESTAMP([DATETIME date[, STRING fmt]])
```

将 Date 或者 Datetime 类型转化为 unix 时间戳。

如果没有参数，则是将当前的时间转化为时间戳。

参数需要是 Date 或者 Datetime 类型。

对于在 1970-01-01 00:00:00 之前或 2038-01-19 03:14:07 之后的时间，该函数将返回 0。

Format 的格式请参阅 date_format 函数的格式说明。

该函数受时区影响。

举例

```
mysql> select unix_timestamp();
+-----+
| unix_timestamp() |
+-----+
|          1558589570 |
+-----+

mysql> select unix_timestamp('2007-11-30 10:30:19');
+-----+
| unix_timestamp('2007-11-30 10:30:19') |
+-----+
|                      1196389819 |
+-----+

mysql> select unix_timestamp('2007-11-30 10:30-19', '%Y-%m-%d %H:%i-%s');
+-----+
| unix_timestamp('2007-11-30 10:30-19') |
+-----+
|                      1196389819 |
+-----+

mysql> select unix_timestamp('2007-11-30 10:30%3A19', '%Y-%m-%d %H:%i%3A%s');
+-----+
| unix_timestamp('2007-11-30 10:30%3A19') |
+-----+
|                      1196389819 |
+-----+

mysql> select unix_timestamp('1969-01-01 00:00:00');
+-----+
```

	unix_timestamp('1969-01-01 00:00:00')	
+-----+		
	0	
+-----+		

keywords

UNIX_TIMESTAMP, UNIX, TIMESTAMP

UTC_TIMESTAMP

utc_timestamp

描述

语法

DATETIME UTC_TIMESTAMP()

返回当前UTC日期和时间在 “YYYY-MM-DD HH:MM:SS” 或

“YYYYMMDDHHMMSS”格式的一个值

根据该函数是否用在字符串或数字语境中

举例

```
mysql> select utc_timestamp(),utc_timestamp() + 1;
+-----+-----+
| utc_timestamp() | utc_timestamp() + 1 |
+-----+-----+
| 2019-07-10 12:31:18 | 20190710123119 |
+-----+-----+
```

keywords

UTC_TIMESTAMP,UTC,TIMESTAMP

TO_DATE

to_date

描述

语法

DATE TO_DATE(DATETIME)

返回 DATETIME 类型中的日期部分。

举例

```
mysql> select to_date("2020-02-02 00:00:00");
+-----+
| to_date('2020-02-02 00:00:00') |
+-----+
| 2020-02-02                      |
+-----+
```

keywords

TO_DATE

TO_DAYS

to_days

描述

语法

INT TO_DAYS(DATETIME date)

返回date距离0000-01-01的天数

参数为Date或者Datetime类型

举例

```
mysql> select to_days('2007-10-07');
+-----+
| to_days('2007-10-07') |
+-----+
|              733321   |
+-----+
```

keywords

TO_DAYS, TO, DAYS

TIME_TO_SEC

描述

函数将输入的 TIME 或 DATETIME 类型的值转换为以秒为单位的总时间。如果输入为 DATETIME 类型，函数会自动提取时间部分（HH:MM:SS）。

语法

```
TIME_TO_SEC(<time>)
```

参数

参数	说明
<time>	必填，支持 TIME 或 DATETIME 类型的值。如果输入为 DATETIME 类型，函数会提取时间部分进行计算。

返回值

- 返回一个整数，表示输入时间值转换为总秒数的结果。
- 如果输入的 <time> 为 NULL，函数返回 NULL。

举例

```
SELECT TIME_TO_SEC('16:32:18'),TIME_TO_SEC('2025-01-01 16:32:18');
```

time_to_sec(cast('16:32:18' as TIME))	time_to_sec(cast('2025-01-01 16:32:18' as TIME))
59538	59538

SEC_TO_TIME

描述

SEC_TO_TIME 函数将一个以秒为单位的值转换为 TIME 类型，返回格式为 HH:MM:SS。输入的秒数表示从一天的起点时间（00:00:00）开始计算的时间。### 语法

```
SEC_TO_TIME(<seconds>)
```

参数

参数	说明
<seconds>	必填，输入的秒数，表示从一天起点时间（00:00:00）开始计算的秒数，支持正整数或负整数类型。

返回值

- 返回一个 TIME 类型值，格式为 HH:MM:SS，表示从起点时间（00:00:00）开始计算的时间。
- 如果输入的 <seconds> 为 NULL，函数返回 NULL。

举例

```
SELECT SEC_TO_TIME(59738);
```

```
+-----+
| sec_to_time(59738) |
+-----+
| 16:35:38           |
+-----+
```

EXTRACT

extract

描述

语法

INT extract(unit FROM DATETIME)

提取DATETIME某个指定单位的值。单位可以为year, month, day, hour, minute, second 或者 microsecond

举例

```
mysql> select extract(year from '2022-09-22 17:01:30') as year,
-> extract(month from '2022-09-22 17:01:30') as month,
-> extract(day from '2022-09-22 17:01:30') as day,
-> extract(hour from '2022-09-22 17:01:30') as hour,
-> extract(minute from '2022-09-22 17:01:30') as minute,
-> extract(second from '2022-09-22 17:01:30') as second,
-> extract(microsecond from cast('2022-09-22 17:01:30.000123' as datetime(6))) as microsecond;
```

year	month	day	hour	minute	second	microsecond
2022	9	22	17	1	30	123

keywords

extract

MAKEDATE

makedate

描述

语法

DATE MAKEDATE(INT year, INT dayofyear)

返回指定年份和dayofyear构建的日期。dayofyear必须大于0，否则结果为空。

举例

```
mysql> select makedate(2021,1), makedate(2021,100), makedate(2021,400);
+-----+-----+-----+
| makedate(2021, 1) | makedate(2021, 100) | makedate(2021, 400) |
+-----+-----+-----+
| 2021-01-01        | 2021-04-10          | 2022-02-04          |
+-----+-----+-----+
```

keywords

MAKEDATE

STR_TO_DATE

描述

函数将输入的日期时间字符串根据指定的格式转换为 DATETIME 类型的值。

语法

```
STR_TO_DATE(<datetime_str>, <format>)
```

参数

参数	说明
<datetime_str>	必填，输入的日期时间字符串，表示要转换的日期或时间。
<format>	必填，指定的日期时间格式字符串，如 %Y-%m-%d %H:%i:%s 等，具体格式参数详见 DATE_FORMAT 文档

除此之外，<format> 额外支持以下若干代用格式，并按照正规 format 格式解读：

代用输入	解读为
yyyyMMdd	%Y%m%d
yyyy-MM-dd	%Y-%m-%d
yyyy-MM-dd HH:mm:ss	%Y-%m-%d %H:%i:%s

返回值

- 返回一个 DATETIME 类型值，表示转换后的日期时间。
- 如果输入的 <datetime_str> 或 <format> 无效，函数返回 NULL。

举例

将常见的日期时间字符串转换为 DATETIME 类型

```
SELECT STR_TO_DATE('2025-01-23 12:34:56', '%Y-%m-%d %H:%i:%s'),STR_TO_DATE('2025-01-23 12:34:56', 'yyyy-MM-dd HH:mm:ss');
```

```
+-----+-----+
| str_to_date('2025-01-23 12:34:56', '%Y-%m-%d %H:%i:%s') | str_to_date('2025-01-23 12:34:56', 'yyyy-MM-dd HH:mm:ss') |
+-----+-----+
| 2025-01-23 12:34:56.000000 | 2025-01-23 12:34:56.000000 |
|
```

+	+
-----+	

其他

```
select STR_TO_DATE('200442 Monday', '%X%V %W'),STR_TO_DATE('2023','%Y');
```

+	+	+
str_to_date('200442 Monday', '%X%V %W')	str_to_date('2023', '%Y')	
+	+	+
2004-10-18	2023-01-01	
+	+	+

TIME_ROUND

time_round

描述

语法

```
DATETIME TIME_ROUND(DATETIME expr)
DATETIME TIME_ROUND(DATETIME expr, INT period)
DATETIME TIME_ROUND(DATETIME expr, DATETIME origin)
DATETIME TIME_ROUND(DATETIME expr, INT period, DATETIME origin)
```

函数名 TIME_ROUND 由两部分组成，每部分由以下可选值组成 - TIME: SECOND, MINUTE, HOUR, DAY, WEEK, MONTH, YEAR - ROUND: FLOOR, CEIL

返回 expr 的上/下界。

- period 指定每个周期有多少个 TIME 单位组成，默认为 1。
- origin 指定周期的开始时间，默认为 1970-01-01T00:00:00，WEEK 的默认开始时间为 1970-01-04T00:00:00，即周日。可以比 expr 大。
- 请尽量选择常见 period，如 3 MONTH, 90 MINUTE 等，如设置了非常用 period，请同时指定 origin。

举例

```
MySQL> SELECT YEAR_FLOOR('20200202000000');
```

```
+-----+
| year_floor('20200202000000') |
+-----+
| 2020-01-01 00:00:00          |
+-----+
```

```
MySQL> SELECT MONTH_CEIL(CAST('2020-02-02 13:09:20' AS DATETIME), 3); --quarter
```

```
+-----+
| month_ceil(CAST('2020-02-02 13:09:20' AS DATETIME), 3) |
+-----+
| 2020-04-01 00:00:00                                     |
+-----+
```

```
MySQL> SELECT WEEK_CEIL('2020-02-02 13:09:20', '2020-01-06'); --monday
```

```
+-----+
| week_ceil('2020-02-02 13:09:20', '2020-01-06 00:00:00') |
+-----+
| 2020-02-03 00:00:00                                     |
+-----+
```

```
MySQL> SELECT MONTH_CEIL(CAST('2020-02-02 13:09:20' AS DATETIME), 3, CAST('1970-01-09 00:00:00' AS DATETIME)); --next rent day
```

```
+-----+
| month_ceil(CAST('2020-02-02 13:09:20' AS DATETIME), 3, CAST('1970-01-09 00:00:00' AS DATETIME)) |
+-----+
| 2020-04-09 00:00:00 |
+-----+
```

keywords

TIME_ROUND

TIMEDIFF

描述

TIMEDIFF 函数用于计算两个日期时间值之间的差值。该函数接受两个参数，并返回其差值，结果为 TIME 类型。

语法

```
TIMEDIFF(<end_datetime>, <start_datetime>)
```

参数

参数	说明
<end_datetime>	结束的时间或日期时间值
<start_datetime>	开始的时间或日期时间值

返回值

返回一个 TIME 类型的值，表示两个输入之间的时间差： - 当 <end_datetime> 晚于 <start_datetime> 时，返回正的时间差。 - 当 <end_datetime> 早于 <start_datetime> 时，返回负的时间差。 - 当 <end_datetime> 和 <start_datetime> 相等时，返回 00:00:00。 - 如果 <end_datetime> 或 <start_datetime> 为 NULL，函数返回 NULL。 - 如果 <end_datetime> 或 <start_datetime> 为非法时间或日期时间值（如 0000-00-00 00:00:00），函数返回 NULL。

举例

```
SELECT TIMEDIFF('2024-07-20 16:59:30','2024-07-11 16:35:21');
```

```
+-----+
| timediff(cast('2024-07-20 16:59:30' as DATETIMEV2(0)), cast('2024-07-11 16:35:21' as DATETIMEV2(0))) |
+-----+
| 216:24:09 |
+-----+
```

TIMESTAMPADD

timestampadd

描述

语法

DATETIME TIMESTAMPADD(unit, interval, DATETIME datetime_expr)

将整数表达式间隔添加到日期或日期时间表达式datetime_expr中。

interval的单位由unit参数给出，它应该是下列值之一：

SECOND, MINUTE, HOUR, DAY, WEEK, MONTH, or YEAR。

举例

```
mysql> SELECT TIMESTAMPADD(MINUTE,1,'2019-01-02');
+-----+
| timestampadd(MINUTE, 1, '2019-01-02 00:00:00') |
+-----+
| 2019-01-02 00:01:00                             |
+-----+

mysql> SELECT TIMESTAMPADD(WEEK,1,'2019-01-02');
+-----+
| timestampadd(WEEK, 1, '2019-01-02 00:00:00') |
+-----+
| 2019-01-09 00:00:00                             |
+-----+
```

keywords

TIMESTAMPADD

TIMESTAMPDIFF

timestampdiff

描述

语法

INT TIMESTAMPDIFF(unit, DATETIME datetime_expr1, DATETIME datetime_expr2)

返回datetime_expr2-datetime_expr1，其中datetime_expr1和datetime_expr2是日期或日期时间表达式。

结果(整数)的单位由unit参数给出。interval的单位由unit参数给出，它应该是下列值之一：

SECOND, MINUTE, HOUR, DAY, WEEK, MONTH, or YEAR。

举例

```
MySQL> SELECT TIMESTAMPDIFF(MONTH, '2003-02-01', '2003-05-01');
+-----+
| timestampdiff(MONTH, '2003-02-01 00:00:00', '2003-05-01 00:00:00') |
+-----+
| 3 |
+-----+

MySQL> SELECT TIMESTAMPDIFF(YEAR, '2002-05-01', '2001-01-01');
+-----+
| timestampdiff(YEAR, '2002-05-01 00:00:00', '2001-01-01 00:00:00') |
+-----+
| -1 |
+-----+

MySQL> SELECT TIMESTAMPDIFF(MINUTE, '2003-02-01', '2003-05-01 12:05:55');
+-----+
| timestampdiff(MINUTE, '2003-02-01 00:00:00', '2003-05-01 12:05:55') |
+-----+
| 128885 |
+-----+
```

keywords

TIMESTAMPDIFF

DATE_ADD

date_add

描述

语法

INT DATE_ADD(DATETIME date, INTERVAL expr type)

向日期添加指定的时间间隔。

date 参数是合法的日期表达式。

expr 参数是您希望添加的时间间隔。

type 参数可以是下列值：YEAR, MONTH, DAY, HOUR, MINUTE, SECOND

举例

```
mysql> select date_add('2010-11-30 23:59:59', INTERVAL 2 DAY);
+-----+
| date_add('2010-11-30 23:59:59', INTERVAL 2 DAY) |
+-----+
| 2010-12-02 23:59:59                               |
+-----+
```

keywords

DATE_ADD,DATE,ADD

DATE_SUB

date_sub

描述

语法

DATETIME DATE_SUB(DATETIME date, INTERVAL expr type)

从日期减去指定的时间间隔

date 参数是合法的日期表达式。

expr 参数是您希望添加的时间间隔。

type 参数可以是下列值：YEAR, MONTH, DAY, HOUR, MINUTE, SECOND

举例

```
mysql> select date_sub('2010-11-30 23:59:59', INTERVAL 2 DAY);
+-----+
| date_sub('2010-11-30 23:59:59', INTERVAL 2 DAY) |
+-----+
| 2010-11-28 23:59:59                               |
+-----+
```

keywords

DATE_SUB,DATE,SUB

DATE_TRUNC

date_trunc

date_trunc

描述

语法

DATETIME DATE_TRUNC(DATETIME datetime, VARCHAR unit)

将datetime按照指定的时间单位截断。

datetime 参数是合法的日期表达式。

unit 参数是您希望截断的时间间隔，可选的值如下：[second,minute,hour,day,week,month,quarter,year]。

举例

```
mysql> select date_trunc('2010-12-02 19:28:30', 'second');
```

date_trunc('2010-12-02 19:28:30', 'second')
2010-12-02 19:28:30

```
mysql> select date_trunc('2010-12-02 19:28:30', 'minute');
```

date_trunc('2010-12-02 19:28:30', 'minute')
2010-12-02 19:28:00

```
mysql> select date_trunc('2010-12-02 19:28:30', 'hour');
```

date_trunc('2010-12-02 19:28:30', 'hour')
2010-12-02 19:00:00

```
mysql> select date_trunc('2010-12-02 19:28:30', 'day');
```

date_trunc('2010-12-02 19:28:30', 'day')
2010-12-02 00:00:00

```
mysql> select date_trunc('2023-4-05 19:28:30', 'week');
```

date_trunc('2023-04-05 19:28:30', 'week')
2023-04-03 00:00:00


```
mysql> select date_trunc('2010-12-02 19:28:30', 'month');
+-----+
| date_trunc('2010-12-02 19:28:30', 'month') |
+-----+
| 2010-12-01 00:00:00                        |
+-----+

mysql> select date_trunc('2010-12-02 19:28:30', 'quarter');
+-----+
| date_trunc('2010-12-02 19:28:30', 'quarter') |
+-----+
| 2010-10-01 00:00:00                        |
+-----+

mysql> select date_trunc('2010-12-02 19:28:30', 'year');
+-----+
| date_trunc('2010-12-02 19:28:30', 'year') |
+-----+
| 2010-01-01 00:00:00                        |
+-----+
```

keywords

DATE_TRUNC,DATE,TRUNC

DATE_FORMAT

date_format

描述

语法

VARCHAR DATE_FORMAT(DATETIME date, VARCHAR format)

将日期类型按照format的类型转化为字符串， 当前支持最大128字节的字符串， 如果返回值长度超过128字节， 则返回NULL。

date 参数是合法的日期。format 规定日期/时间的输出格式。

可以使用的格式有：

格式符	描述
%a	三字母缩写星期名
%b	三字母缩写月名
%c	月，数值 (0-12)
%D	带有英文后缀的月中的天 (0th, 1st, 2nd, 3rd, ...)
%d	月的天，数值 (00-31)
%e	月的天，数值 (0-31)
%f	微秒 (000000-999999)
%H	小时 (00-23)
%h	小时 (01-12)
%I	小时 (01-12)
%i	分钟，数值 (00-59)
%j	年的天 (001-366)
%k	小时 (0-23)
%l	小时 (1-12)
%M	月名
%m	月，数值 (00-12)
%p	AM 或 PM
%r	时间，12-小时 (hh:mm:ss, 后跟 AM 或 PM)
%S	秒 (00-59)
%s	秒 (00-59)

格式符	描述
%T	时间, 24-小时 (hh:mm:ss)
%U	周 (00-53) 星期日是周的第一天
%u	周 (00-53) 星期一是周的第一天
%V	周 (01-53) 星期日是周的第一天, 与 %X 使用
%v	周 (01-53) 星期一是周的第一天, 与 %x 使用
%W	周中日的名称 (Sunday-Saturday)
%w	周的天 (0=星期日, 6=星期六)
%X	年, 其中的星期日是周的第一天, 4 位, 与 %V 使用
%x	年, 其中的星期一是周的第一天, 4 位, 与 %v 使用
%Y	年, 4 位
%y	年, 2 位
%%	用于表示 %
%x	对于任何未出现在上列的 x , 表示 x 本身

还可以使用三种特殊格式：

yyyyMMdd

yyyy-MM-dd

yyyy-MM-dd HH:mm:ss

举例

```
mysql> select date_format('2009-10-04 22:23:00', '%W %M %Y');
+-----+
| date_format('2009-10-04 22:23:00', '%W %M %Y') |
+-----+
| Sunday October 2009                             |
+-----+

mysql> select date_format('2007-10-04 22:23:00', '%H:%i:%s');
+-----+
| date_format('2007-10-04 22:23:00', '%H:%i:%s') |
+-----+
| 22:23:00                                         |
+-----+

mysql> select date_format('1900-10-04 22:23:00', '%D %y %a %d %m %b %j');
+-----+
| date_format('1900-10-04 22:23:00', '%D %y %a %d %m %b %j') |
+-----+
| 4th 00 Thu 04 10 Oct 277                             |
+-----+

mysql> select date_format('1997-10-04 22:23:00', '%H %k %I %r %T %S %w');
+-----+
| date_format('1997-10-04 22:23:00', '%H %k %I %r %T %S %w') |
+-----+
```

```

| 22 22 10 10:23:00 PM 22:23:00 00 6 |
+-----+

mysql> select date_format('1999-01-01 00:00:00', '%X %V');
+-----+
| date_format('1999-01-01 00:00:00', '%X %V') |
+-----+
| 1998 52 |
+-----+

mysql> select date_format('2006-06-01', '%d');
+-----+
| date_format('2006-06-01 00:00:00', '%d') |
+-----+
| 01 |
+-----+

mysql> select date_format('2006-06-01', '%%d');
+-----+
| date_format('2006-06-01 00:00:00', '%%d') |
+-----+
| %01 |
+-----+

```

keywords

DATE_FORMAT,DATE,FORMAT

DATEDIFF

datediff

描述

语法

INT DATEDIFF(DATETIME expr1, DATETIME expr2)

计算expr1 - expr2，结果精确到天。

expr1 和 expr2 参数是合法的日期或日期/时间表达式。

注释：只有值的日期部分参与计算。

举例

```
mysql> select datediff(CAST('2007-12-31 23:59:59' AS DATETIME), CAST('2007-12-30' AS DATETIME));
+-----+
| datediff(CAST('2007-12-31 23:59:59' AS DATETIME), CAST('2007-12-30' AS DATETIME)) |
+-----+
|                                                                                      1 |
+-----+

mysql> select datediff(CAST('2010-11-30 23:59:59' AS DATETIME), CAST('2010-12-31' AS DATETIME));
+-----+
| datediff(CAST('2010-11-30 23:59:59' AS DATETIME), CAST('2010-12-31' AS DATETIME)) |
+-----+
|                                                                                      -31 |
+-----+
```

keywords

DATEDIFF

SECOND_FLOOR

描述

函数用于将输入的日期时间值向下对齐到指定的秒周期边界，并返回对齐后的日期时间值。

语法

```
SECOND_FLOOR(<datetime>[, <period>][, <origin_datetime>])
```

参数

参数	说明
<datetime>	必填，输入的日期时间值，支持 DATETIME 类型。
<period>	可选，表示每个周期由多少秒组成，支持正整数类型（INT）。默认为 1 秒。
<origin_datetime>	可选，对齐的时间起点，支持 DATETIME 类型。如果未指定，默认为 0001-01-01T00:00:00。

返回值

- 返回一个日期时间值，表示输入日期时间向上对齐后的结果。
- 如果输入的 <datetime> 为 NULL，返回 NULL。
- 如果输入的 <datetime> 为非法日期（如 0000-00-00T00:00:00），返回 NULL。

举例

只指定参数<datetime>

```
SELECT SECOND_FLOOR('2025-01-23 12:34:56');
```

```
+-----+
| second_floor(cast('2025-01-23 12:34:56' as DATETIMEV2(0))) |
+-----+
| 2025-01-23 12:34:56                                         |
+-----+
```

指定参数 <datetime>, <origin_datetime>

```
SELECT SECOND_FLOOR('2025-01-23 12:34:56', '2025-01-01 00:00:00');
```

```
+-----+
| second_floor(cast('2025-01-23 12:34:56' as DATETIMEV2(0)), cast('2025-01-01 00:00:00' as DATETIMEV2(0))) |
+-----+
```

2025-01-23 12:34:56	
+	+

指定参数 <datetime>, <period>

```
SELECT SECOND_FLOOR('2025-01-23 12:34:56', 5);
```

+	+
second_floor(cast('2025-01-23 12:34:56' as DATETIMEV2(0)), 5)	
+	+
2025-01-23 12:34:55	
+	+

同时指定 <datetime>, <period>, <origin_datetime>

```
SELECT SECOND_FLOOR('2025-01-23 12:34:56', 10, '2025-01-23 12:00:00');
```

+	+
--+	
second_floor(cast('2025-01-23 12:34:56' as DATETIMEV2(0)), 10, cast('2025-01-23 12:00:00' as DATETIMEV2(0)))	
+	+
--+	
2025-01-23 12:34:50	
+	+
--+	

MINUTE_FLOOR

minute_floor

描述

语法

```
DATETIME MINUTE_FLOOR(DATETIME datetime)
DATETIME MINUTE_FLOOR(DATETIME datetime, DATETIME origin)
DATETIME MINUTE_FLOOR(DATETIME datetime, INT period)
DATETIME MINUTE_FLOOR(DATETIME datetime, INT period, DATETIME origin)
```

将日期转化为指定的时间间隔周期的最近下取整时刻。

- **datetime**：参数是合法的日期表达式。
- **period**：参数是指定每个周期有多少天组成。
- **origin**：开始的时间起点，如果不填，默认是 0001-01-01T00:00:00。

举例

```
mysql> select minute_floor("2023-07-13 22:28:18", 5);
+-----+
| minute_floor(cast('2023-07-13 22:28:18' as DATETIMEV2(0)), 5) |
+-----+
| 2023-07-13 22:25:00 |
+-----+
1 row in set (0.06 sec)
```

keywords

MINUTE_FLOOR, MINUTE, FLOOR

Best Practice

还可参阅 [date_floor](#)

HOUR_FLOOR

hour_floor

描述

语法

```
DATETIME HOUR_FLOOR(DATETIME datetime)
DATETIME HOUR_FLOOR(DATETIME datetime, DATETIME origin)
DATETIME HOUR_FLOOR(DATETIME datetime, INT period)
DATETIME HOUR_FLOOR(DATETIME datetime, INT period, DATETIME origin)
```

将日期转化为指定的时间间隔周期的最近下取整时刻。

- **datetime**：参数是合法的日期表达式。
- **period**：参数是指定每个周期有多少天组成。
- **origin**：开始的时间起点，如果不填，默认是 0001-01-01T00:00:00。

举例

```
mysql> select hour_floor("2023-07-13 22:28:18", 5);
+-----+
| hour_floor(cast('2023-07-13 22:28:18' as DATETIMEV2(0)), 5) |
+-----+
| 2023-07-13 21:00:00 |
+-----+
1 row in set (0.23 sec)
```

keywords

HOUR_FLOOR, HOUR, FLOOR

Best Practice

还可参阅 [date_floor](#)

DAY_FLOOR

day_floor

描述

语法

```
DATETIME DAY_FLOOR(DATETIME datetime)
DATETIME DAY_FLOOR(DATETIME datetime, DATETIME origin)
DATETIME DAY_FLOOR(DATETIME datetime, INT period)
DATETIME DAY_FLOOR(DATETIME datetime, INT period, DATETIME origin)
```

将日期转化为指定的时间间隔周期的最近下取整时刻。

- datetime：参数是合法的日期表达式。
- period：参数是指定每个周期有多少天组成。
- origin：开始的时间起点，如果不填，默认是 0001-01-01T00:00:00。

举例

```
mysql> select day_floor("2023-07-13 22:28:18", 5);
+-----+
| day_floor(cast('2023-07-13 22:28:18' as DATETIMEV2(0)), 5) |
+-----+
| 2023-07-12 00:00:00                                         |
+-----+
1 row in set (0.07 sec)
```

keywords

```
DAY_FLOOR, DAY, FLOOR
```

Best Practice

还可参阅 [date_floor](#)

MONTH_FLOOR

month_floor

描述

语法

```
DATETIME MONTH_FLOOR(DATETIME datetime)
DATETIME MONTH_FLOOR(DATETIME datetime, DATETIME origin)
DATETIME MONTH_FLOOR(DATETIME datetime, INT period)
DATETIME MONTH_FLOOR(DATETIME datetime, INT period, DATETIME origin)
```

将日期转化为指定的时间间隔周期的最近下取整时刻。

- **datetime**：参数是合法的日期表达式。
- **period**：参数是指定每个周期有多少天组成。
- **origin**：开始的时间起点，如果不填，默认是 0001-01-01T00:00:00。

举例

```
mysql> select month_floor("2023-07-13 22:28:18", 5);
+-----+
| month_floor(cast('2023-07-13 22:28:18' as DATETIMEV2(0)), 5) |
+-----+
| 2023-05-01 00:00:00 |
+-----+
1 row in set (0.12 sec)
```

keywords

MONTH_FLOOR, MONTH, FLOOR

Best Practice

还可参阅 [date_floor](#)

YEAR_FLOOR

year_floor

描述

语法

```
DATETIME YEAR_FLOOR(DATETIME datetime)
DATETIME YEAR_FLOOR(DATETIME datetime, DATETIME origin)
DATETIME YEAR_FLOOR(DATETIME datetime, INT period)
DATETIME YEAR_FLOOR(DATETIME datetime, INT period, DATETIME origin)
```

将日期转化为指定的时间间隔周期的最近下取整时刻。

- **datetime**：参数是合法的日期表达式。
- **period**：参数是指定每个周期有多少天组成。
- **origin**：开始的时间起点，如果不填，默认是 0001-01-01T00:00:00。

举例

```
mysql> select year_floor("2023-07-13 22:28:18", 5);
+-----+
| year_floor(cast('2023-07-13 22:28:18' as DATETIMEV2(0)), 5) |
+-----+
| 2020-01-01 00:00:00 |
+-----+
1 row in set (0.11 sec)
```

keywords

YEAR_FLOOR, YEAR, FLOOR

Best Practice

还可参阅 [date_floor](#)

DATE_CEIL

date_ceil

描述

语法

DATETIME DATE_CEIL(DATETIME datetime, INTERVAL period type)

将日期转化为指定的时间间隔周期的最近上取整时刻。

datetime 参数是合法的日期表达式。

period 参数是指定每个周期有多少个单位组成，开始的时间起点为0001-01-01T00:00:00.

type 参数可以是下列值：YEAR, MONTH, DAY, HOUR, MINUTE, SECOND.

举例

```
mysql [(none)]>select date_ceil("2023-07-13 22:28:18",interval 5 second);
+-----+
| second_ceil('2023-07-13 22:28:18', 5, '0001-01-01 00:00:00') |
+-----+
| 2023-07-13 22:28:20 |
+-----+
1 row in set (0.01 sec)

mysql [(none)]>select date_ceil("2023-07-13 22:28:18",interval 5 minute);
+-----+
| minute_ceil('2023-07-13 22:28:18', 5, '0001-01-01 00:00:00') |
+-----+
| 2023-07-13 22:30:00 |
+-----+
1 row in set (0.01 sec)

mysql [(none)]>select date_ceil("2023-07-13 22:28:18",interval 5 hour);
+-----+
| hour_ceil('2023-07-13 22:28:18', 5, '0001-01-01 00:00:00') |
+-----+
| 2023-07-13 23:00:00 |
+-----+
1 row in set (0.01 sec)

mysql [(none)]>select date_ceil("2023-07-13 22:28:18",interval 5 day);
+-----+
| day_ceil('2023-07-13 22:28:18', 5, '0001-01-01 00:00:00') |
+-----+
| 2023-07-15 00:00:00 |
+-----+
1 row in set (0.00 sec)

mysql [(none)]>select date_ceil("2023-07-13 22:28:18",interval 5 month);
+-----+
| month_ceil('2023-07-13 22:28:18', 5, '0001-01-01 00:00:00') |
```

```

+-----+
| 2023-12-01 00:00:00 |
+-----+
1 row in set (0.01 sec)

mysql [(none)]>select date_ceil("2023-07-13 22:28:18",interval 5 year);
+-----+
| year_ceil('2023-07-13 22:28:18', 5, '0001-01-01 00:00:00') |
+-----+
| 2026-01-01 00:00:00 |
+-----+
1 row in set (0.00 sec)

```

keywords

DATE_CEIL,DATE,CEIL

Best Practice

还可参阅： - [second_ceil](#) - [minute_ceil](#) - [hour_ceil](#) - [day_ceil](#) - [month_ceil](#) - [year_ceil](#)

SECOND_CEIL

描述

函数用于将输入的日期时间值向上对齐到指定的秒周期边界，并返回对齐后的日期时间值。

语法

```
SECOND_CEIL(<datetime>[, <period>][, <origin_datetime>])
```

参数

参数	说明
<datetime>	必填，输入的日期时间值，支持 DATETIME 类型。
<period>	可选，表示每个周期由多少秒组成，支持正整数类型（INT）。默认为 1 秒。
<origin_datetime>	可选，对齐的时间起点，支持 DATETIME 类型。如果未指定，默认为 0001-01-01T00:00:00。

返回值

- 返回一个日期时间值，表示输入日期时间向上对齐后的结果。
- 如果输入的 <datetime> 为 NULL，返回 NULL。
- 如果输入的 <datetime> 为非法日期（如 0000-00-00T00:00:00），返回 NULL。

举例

只指定参数<datetime>

```
SELECT SECOND_CEIL('2025-01-23 12:34:56');
```

```
+-----+
| second_ceil(cast('2025-01-23 12:34:56' as DATETIMEV2(0))) |
+-----+
| 2025-01-23 12:34:56                                         |
+-----+
```

指定参数 <datetime>, <origin_datetime>

```
SELECT SECOND_CEIL('2025-01-23 12:34:56', '2025-01-01 00:00:00');
```

```
+-----+
| second_ceil(cast('2025-01-23 12:34:56' as DATETIMEV2(0)), cast('2025-01-01 00:00:00' as DATETIMEV2(0))) |
+-----+
```

2025-01-23 12:34:56	
+-----+	

指定参数 <datetime>, <period>

```
SELECT SECOND_CEIL('2025-01-23 12:34:56', 5)
```

+-----+	
second_ceil(cast('2025-01-23 12:34:56' as DATETIMEV2(0)), 5)	
+-----+	
2025-01-23 12:35:00	
+-----+	

同时指定 <datetime>, <period>, <origin_datetime>

```
SELECT SECOND_CEIL('2025-01-23 12:34:56', 10, '2025-01-23 12:00:00');
```

+-----+	
--+	
second_ceil(cast('2025-01-23 12:34:56' as DATETIMEV2(0)), 10, cast('2025-01-23 12:00:00' as DATETIMEV2(0)))	
+-----+	
--+	
2025-01-23 12:35:00	
+-----+	
--+	

MINUTE_CEIL

minute_ceil

描述

语法

```
DATETIME MINUTE_CEIL(DATETIME datetime)
DATETIME MINUTE_CEIL(DATETIME datetime, DATETIME origin)
DATETIME MINUTE_CEIL(DATETIME datetime, INT period)
DATETIME MINUTE_CEIL(DATETIME datetime, INT period, DATETIME origin)
```

将日期转化为指定的时间间隔周期的最近上取整时刻。

- **datetime**：参数是合法的日期表达式。
- **period**：参数是指定每个周期有多少分钟组成。
- **origin**：开始的时间起点，如果不填，默认是 0001-01-01T00:00:00。

举例

```
mysql> select minute_ceil("2023-07-13 22:28:18", 5);
+-----+
| minute_ceil(cast('2023-07-13 22:28:18' as DATETIMEV2(0)), 5) |
+-----+
| 2023-07-13 22:30:00 |
+-----+
1 row in set (0.21 sec)
```

keywords

MINUTE_CEIL, MINUTE, CEIL

Best Practice

还可参阅 [date_ceil](#)

HOUR_CEIL

hour_ceil

描述

语法

```
DATETIME HOUR_CEIL(DATETIME datetime)
DATETIME HOUR_CEIL(DATETIME datetime, DATETIME origin)
DATETIME HOUR_CEIL(DATETIME datetime, INT period)
DATETIME HOUR_CEIL(DATETIME datetime, INT period, DATETIME origin)
```

将日期转化为指定的时间间隔周期的最近上取整时刻。

- **datetime**：参数是合法的日期表达式。
- **period**：参数是指定每个周期有多少小时组成。
- **origin**：开始的时间起点，如果不填，默认是 0001-01-01T00:00:00。

举例

```
mysql> select hour_ceil("2023-07-13 22:28:18", 5);
+-----+
| hour_ceil(cast('2023-07-13 22:28:18' as DATETIMEV2(0)), 5) |
+-----+
| 2023-07-14 02:00:00                                         |
+-----+
1 row in set (0.03 sec)
```

keywords

HOUR_CEIL, HOUR, CEIL

Best Practice

还可参阅 [date_ceil](#)

DAY_CEIL

day_ceil

描述

语法

```
DATETIME DAY_CEIL(DATETIME datetime)
DATETIME DAY_CEIL(DATETIME datetime, DATETIME origin)
DATETIME DAY_CEIL(DATETIME datetime, INT period)
DATETIME DAY_CEIL(DATETIME datetime, INT period, DATETIME origin)
```

将日期转化为指定的时间间隔周期的最近上取整时刻。

- **datetime**：参数是合法的日期表达式。
- **period**：参数是指定每个周期有多少天组成。
- **origin**：开始的时间起点，如果不填，默认是 0001-01-01T00:00:00。

举例

```
mysql> select day_ceil("2023-07-13 22:28:18", 5);
+-----+
| day_ceil(cast('2023-07-13 22:28:18' as DATETIMEV2(0)), 5) |
+-----+
| 2023-07-17 00:00:00                                         |
+-----+
1 row in set (0.01 sec)
```

keywords

DAY_CEIL, DAY, CEIL

Best Practice

还可参阅 [date_ceil](#)

MONTH_CEIL

month_ceil

描述

语法

```
DATETIME MONTH_CEIL(DATETIME datetime)
DATETIME MONTH_CEIL(DATETIME datetime, DATETIME origin)
DATETIME MONTH_CEIL(DATETIME datetime, INT period)
DATETIME MONTH_CEIL(DATETIME datetime, INT period, DATETIME origin)
```

将日期转化为指定的时间间隔周期的最近上取整时刻。

- **datetime**：参数是合法的日期表达式。
- **period**：参数是指定每个周期有几个月组成。
- **origin**：开始的时间起点，如果不填，默认是 0001-01-01T00:00:00。

举例

```
mysql> select month_ceil("2023-07-13 22:28:18", 5);
+-----+
| month_ceil(cast('2023-07-13 22:28:18' as DATETIMEV2(0)), 5) |
+-----+
| 2023-10-01 00:00:00                                         |
+-----+
1 row in set (0.02 sec)
```

keywords

MONTH_CEIL, MONTH, CEIL

Best Practice

还可参阅 [date_ceil](#)

YEAR_CEIL

year_ceil

描述

语法

```
DATETIME YEAR_CEIL(DATETIME datetime)
DATETIME YEAR_CEIL(DATETIME datetime, DATETIME origin)
DATETIME YEAR_CEIL(DATETIME datetime, INT period)
DATETIME YEAR_CEIL(DATETIME datetime, INT period, DATETIME origin)
```

将日期转化为指定的时间间隔周期的最近上取整时刻。

- datetime：参数是合法的日期表达式。
- period：参数是指定每个周期有几年组成。
- origin：开始的时间起点，如果不填，默认是 0001-01-01T00:00:00。

举例

```
mysql> select year_ceil("2023-07-13 22:28:18", 5);
+-----+
| year_ceil(cast('2023-07-13 22:28:18' as DATETIMEV2(0)), 5) |
+-----+
| 2025-01-01 00:00:00                                         |
+-----+
1 row in set (0.02 sec)
```

keywords

```
YEAR_CEIL, YEAR, CEIL
```

Best Practice

还可参阅 [date_ceil](#)

MICROSECOND

microsecond

描述

语法

INT MICROSECOND(DATETIMEV2 date)

获得日期中的微秒信息。

参数为 Datetime 类型

举例

```
mysql> select microsecond(cast('1999-01-02 10:11:12.000123' as datetimev2(6))) as microsecond;
+-----+
| microsecond |
+-----+
|          123 |
+-----+
```

keywords

MICROSECOND

MICROSECONDS_ADD

microseconds_add

描述

语法

DATETIMEV2 microseconds_add(DATETIMEV2 basetime, INT delta) - basetime: DATETIMEV2 类型起始时间 - delta: 从 basetime 起需要相加的微秒数 - 返回类型为 DATETIMEV2

举例

```
mysql> select now(3), microseconds_add(now(3), 100000);
+-----+-----+
| now(3) | microseconds_add(now(3), 100000) |
+-----+-----+
| 2023-02-21 11:35:56.556 | 2023-02-21 11:35:56.656 |
+-----+-----+
```

now(3) 返回精度位数 3 的 DATETIMEV2 类型当前时间，microseconds_add(now(3), 100000) 返回当前时间加上 100000 微秒后的 DATETIMEV2 类型时间

keywords

```
microseconds_add
```

MICROSECONDS_DIFF

microseconds_diff

描述

语法

INT microseconds_diff(DATETIME enddate, DATETIME startdate)

开始时间到结束时间相差几微秒

举例

```
mysql> select microseconds_diff('2020-12-25 21:00:00.623000','2020-12-25 21:00:00.123000');
+-----+
| microseconds_diff(cast('2020-12-25 21:00:00.623000' as DATETIMEV2(6)), cast('2020-12-25 21:00:00.123000' as DATETIMEV2(6))) |
+-----+
| 500000 |
+-----+
1 row in set (0.12 sec)
```

keywords

microseconds_diff

MICROSECONDS_SUB

microseconds_sub

描述

语法

DATETIMEV2 microseconds_sub(DATETIMEV2 basetime, INT delta) - basetime: DATETIMEV2 类型起始时间 - delta: 从 basetime 起需要扣减的微秒数 - 返回类型为 DATETIMEV2

举例

```
mysql> select now(3), microseconds_sub(now(3), 100000);
+-----+-----+
| now(3) | microseconds_sub(now(3), 100000) |
+-----+-----+
| 2023-02-25 02:03:05.174 | 2023-02-25 02:03:05.074 |
+-----+-----+
```

now(3) 返回精度位数 3 的 DATETIMEV2 类型当前时间, microseconds_add(now(3), 100000) 返回当前时间减去 100000 微秒后的 DATETIMEV2 类型时间

keywords

microseconds_sub

MILLISECONDS_ADD

milliseconds_add

描述

语法

DATETIMEV2 milliseconds_add(DATETIMEV2 basetime, INT delta) - basetime: DATETIMEV2 类型起始时间 - delta: 从 basetime 起需要相加的毫秒数 - 返回类型为 DATETIMEV2

举例

```
mysql> select milliseconds_add('2023-09-08 16:02:08.435123', 1);
+-----+
| milliseconds_add(cast('2023-09-08 16:02:08.435123' as DATETIMEV2(6)), 1) |
+-----+
| 2023-09-08 16:02:08.436123 |
+-----+
1 row in set (0.04 sec)
```

keywords

```
milliseconds_add
```

MILLISECONDS_DIFF

milliseconds_diff

描述

语法

INT milliseconds_diff(DATETIME enddate, DATETIME startdate)

开始时间到结束时间相差几毫秒

举例

```
mysql> select milliseconds_diff('2020-12-25 21:00:00.623000','2020-12-25 21:00:00.123000');
+-----+
| milliseconds_diff(cast('2020-12-25 21:00:00.623000' as DATETIMEV2(6)), cast('2020-12-25 21:00:00.123000' as DATETIMEV2(6))) |
+-----+
| 500 |
+-----+
1 row in set (0.03 sec)
```

keywords

milliseconds_diff

MILLISECONDS_SUB

milliseconds_sub

描述

语法

DATETIMEV2 milliseconds_sub(DATETIMEV2 basetime, INT delta) - basetime: DATETIMEV2 类型起始时间 - delta: 从 basetime 起需要扣减的毫秒数 - 返回类型为 DATETIMEV2

举例

```
mysql> select milliseconds_sub('2023-09-08 16:02:08.435123', 1);
+-----+
| milliseconds_sub(cast('2023-09-08 16:02:08.435123' as DATETIMEV2(6)), 1) |
+-----+
| 2023-09-08 16:02:08.434123 |
+-----+
1 row in set (0.11 sec)
```

keywords

```
milliseconds_sub
```

MINUTES_ADD

minutes_add

描述

语法

DATETIME MINUTES_ADD(DATETIME date, INT minutes)

从日期时间或日期加上指定分钟数

参数 date 可以是 DATETIME 或者 DATE 类型，返回类型为 DATETIME。

举例

```
mysql> select minutes_add("2020-02-02", 1);
+-----+
| minutes_add('2020-02-02 00:00:00', 1) |
+-----+
| 2020-02-02 00:01:00                    |
+-----+
```

keywords

MINUTES_ADD

MINUTES_DIFF

minutes_diff

描述

语法

INT minutes_diff(DATETIME enddate, DATETIME startdate)

开始时间到结束时间相差几分钟

举例

```
mysql> select minutes_diff('2020-12-25 22:00:00','2020-12-25 21:00:00');
+-----+
| minutes_diff('2020-12-25 22:00:00', '2020-12-25 21:00:00') |
+-----+
|                                                                60 |
+-----+
```

keywords

```
minutes_diff
```

MINUTES_SUB

minutes_sub

描述

语法

DATETIME MINUTES_SUB(DATETIME date, INT minutes)

从日期时间或日期减去指定分钟数

参数 date 可以是 DATETIME 或者 DATE 类型，返回类型为 DATETIME。

举例

```
mysql> select minutes_sub("2020-02-02 02:02:02", 1);
+-----+
| minutes_sub('2020-02-02 02:02:02', 1) |
+-----+
| 2020-02-02 02:01:02                    |
+-----+
```

keywords

MINUTES_SUB

SECONDS_ADD

描述

函数用于在指定的日期时间值上增加或减少指定的秒数，并返回计算后的日期时间值

语法

```
SECONDS_ADD(<datetime>, <seconds>)
```

参数

参数	说明
<datetime>	必填，输入的日期时间值，支持 DATETIME 或 DATE 类型
<seconds>	必填，要增加或减少的秒数，支持整数类型（INT）。正数表示增加秒数，负数表示减少秒数。

返回值

- 返回一个日期时间值，类型与输入的 <datetime> 类型一致。
- 如果 <datetime> 为 NULL，函数返回 NULL。
- 如果 <datetime> 为非法日期（如 0000-00-00T00:00:00），函数返回 NULL。

举例

```
SELECT SECONDS_ADD('2025-01-23 12:34:56', 30),SECONDS_ADD('2025-01-23 12:34:56', -30);
```

+-----+-----+ -----+ seconds_add(cast('2025-01-23 12:34:56' as DATETIMEV2(0)), 30) seconds_add(cast('2025-01-23 12:34:56' as DATETIMEV2(0)), -30) +-----+-----+	
-----+ 2025-01-23 12:35:26 2025-01-23 12:34:26 +-----+-----+	
-----+	

SECONDS_DIFF

描述

函数用于计算两个日期时间值之间的时间差，以秒为单位返回差值。

语法

```
SECONDS_DIFF(<end_datetime>, <start_datetime>)
```

参数

参数	说明
<end_datetime>	必填，结束的日期时间值，支持 DATETIME 或 DATE 类型。
<start_datetime>	必填，起始的日期时间值，支持 DATETIME 或 DATE 类型。

返回值

- 返回一个整数，表示两个日期时间值之间的秒差：
 - 如果 <end_datetime> 晚于 <start_datetime>，返回正数。
 - 如果 <end_datetime> 早于 <start_datetime>，返回负数。
 - 如果 <end_datetime> 和 <start_datetime> 相等，返回 0。
- 如果任一参数为 NULL，函数返回 NULL。
- 如果输入的日期时间值为非法日期（如 0000-00-00T00:00:00），函数返回 NULL。

举例

```
SELECT SECONDS_DIFF('2025-01-23 12:35:56', '2025-01-23 12:34:56');
```

```
+-----+
| seconds_diff(cast('2025-01-23 12:35:56' as DATETIMEV2(0)), cast('2025-01-23 12:34:56' as DATETIMEV2(0))) |
+-----+
|                                                                                                     60 |
+-----+
```

SECONDS_SUB

描述

函数用于在指定的日期时间值上减少或增加指定的秒数，并返回计算后的日期时间值

语法

```
SECONDS_SUB(<datetime>, <seconds>)
```

参数

参数	说明
<datetime>	必填，输入的日期时间值，支持 DATETIME 或 DATE 类型
<seconds>	必填，要减少或增加的秒数，支持整数类型（INT）。正数表示增加秒数，负数表示减少秒数。

返回值

- 返回一个日期时间值，类型与输入的 <datetime> 类型一致。
- 如果 <datetime> 为 NULL，函数返回 NULL。
- 如果 <datetime> 为非法日期（如 0000-00-00T00:00:00），函数返回 NULL。

举例

```
SELECT SECONDS_SUB('2025-01-23 12:34:56', 30),SECONDS_SUB('2025-01-23 12:34:56', -30);
```

+-----+-----+	
-----+	
seconds_sub(cast('2025-01-23 12:34:56' as DATETIMEV2(0)), 30) seconds_sub(cast('2025-01-23 12:34:56' as DATETIMEV2(0)), -30)	
+-----+-----+	
-----+	
2025-01-23 12:34:26	2025-01-23 12:35:26
+-----+-----+	
-----+	

HOURS_ADD

hours_add

描述

语法

DATETIME HOURS_ADD(DATETIME date, INT hours)

从日期时间或日期加上指定小时数

参数 date 可以是 DATETIME 或者 DATE 类型，返回类型为 DATETIME。

举例

```
mysql> select hours_add("2020-02-02 02:02:02", 1);
+-----+
| hours_add('2020-02-02 02:02:02', 1) |
+-----+
| 2020-02-02 03:02:02                  |
+-----+
```

keywords

HOURS_ADD

HOURS_DIFF

hours_diff

描述

语法

INT hours_diff(DATETIME enddate, DATETIME startdate)

开始时间到结束时间相差几小时

举例

```
mysql> select hours_diff('2020-12-25 22:00:00','2020-12-25 21:00:00');
+-----+
| hours_diff('2020-12-25 22:00:00', '2020-12-25 21:00:00') |
+-----+
|                                                    1 |
+-----+
```

keywords

hours_diff

HOURS_SUB

hours_sub

描述

语法

DATETIME HOURS_SUB(DATETIME date, INT hours)

从日期时间或日期减去指定小时数

参数 date 可以是 DATETIME 或者 DATE 类型，返回类型为 DATETIME。

举例

```
mysql> select hours_sub("2020-02-02 02:02:02", 1);
+-----+
| hours_sub('2020-02-02 02:02:02', 1) |
+-----+
| 2020-02-02 01:02:02                  |
+-----+
```

keywords

HOURS_SUB

DAYS_ADD

days_add

描述

语法

DATETIME DAYS_ADD(DATETIME date, INT days)

从日期时间或日期加上指定天数

参数 date 可以是 DATETIME 或者 DATE 类型，返回类型与参数 date 的类型一致。

举例

```
mysql> select days_add(to_date("2020-02-02 02:02:02"), 1);
+-----+
| days_add(to_date('2020-02-02 02:02:02'), 1) |
+-----+
| 2020-02-03                                |
+-----+
```

keywords

DAYS_ADD

DAYS_DIFF

days_diff

描述

语法

INT days_diff(DATETIME enddate, DATETIME startdate)

开始时间到结束时间相差几天，对日期的判断精确到秒，并向下取整数。区别于datediff，datediff函数对日期的判断精确到天。### 举例

```
mysql> select days_diff('2020-12-25 22:00:00','2020-12-24 22:00:00');
+-----+
| days_diff('2020-12-25 22:00:00', '2020-12-24 22:00:00') |
+-----+
| 1 |
+-----+

mysql> select days_diff('2020-12-25 22:00:00','2020-12-24 22:00:01');
+-----+
| days_diff('2020-12-24 22:00:01', '2020-12-25 22:00:00') |
+-----+
| 0 |
+-----+
```

keywords

days_diff

DAYS_SUB

days_sub

描述

语法

DATETIME DAYS_SUB(DATETIME date, INT days)

从日期时间或日期减去指定天数

参数 date 可以是 DATETIME 或者 DATE 类型，返回类型与参数 date 的类型一致。

举例

```
mysql> select days_sub("2020-02-02 02:02:02", 1);
+-----+
| days_sub('2020-02-02 02:02:02', 1) |
+-----+
| 2020-02-01 02:02:02                |
+-----+
```

keywords

DAYS_SUB

WEEKS_ADD

weeks_add

描述

语法

DATETIME WEEKS_ADD(DATETIME date, INT weeks)

从日期加上指定星期数

参数 date 可以是 DATETIME 或者 DATE 类型，返回类型与参数 date 的类型一致。

举例

```
mysql> select weeks_add("2020-02-02 02:02:02", 1);
+-----+
| weeks_add('2020-02-02 02:02:02', 1) |
+-----+
| 2020-02-09 02:02:02                  |
+-----+
```

keywords

WEEKS_ADD

WEEKS_DIFF

weeks_diff

描述

语法

INT weeks_diff(DATETIME enddate, DATETIME startdate)

开始时间到结束时间相差几星期

举例

```
mysql> select weeks_diff('2020-12-25','2020-10-25');
+-----+
| weeks_diff('2020-12-25 00:00:00', '2020-10-25 00:00:00') |
+-----+
|                                                    8 |
+-----+
```

keywords

```
weeks_diff
```

WEEKS_SUB

weeks_sub

描述

语法

DATETIME WEEKS_SUB(DATETIME date, INT weeks)

从日期时间或日期减去指定星期数

参数 date 可以是 DATETIME 或者 DATE 类型，返回类型与参数 date 的类型一致。

举例

```
mysql> select weeks_sub("2020-02-02 02:02:02", 1);
+-----+
| weeks_sub('2020-02-02 02:02:02', 1) |
+-----+
| 2020-01-26 02:02:02                  |
+-----+
```

keywords

WEEKS_SUB

MONTHS_ADD

描述

MONTHS_ADD 函数用于对指定日期添加或减去指定的月份数，并返回计算后的新日期

语法

```
MONTHS_ADD(<datetime/date>, <nums>)
```

参数

参数	说明
<datetime/date>	需要被计算加减月份的日期值
<nums>	需要加减的月份数

返回值

返回值与输入的类型一致 特殊情况： - 输入为 0000-00-00 或 0000-00-00 00:00:00 时，返回 NULL - 输入为 NULL 时，返回 NULL - 如果输入为 months_add("9999-12-31",1)，将返回 NULL

举例

```
select months_add("2020-01-31 02:02:02", 1),months_add("2020-01-31", 1),months_add("2020-01-31", -1);
```

```
+-----+-----+
+-----+
| months_add(cast('2020-01-31 02:02:02' as DATETIMEV2(0)), 1) | months_add(cast('2020-01-31' as DATEV2), 1) |
months_add(cast('2020-01-31' as DATEV2), -1) |
+-----+-----+
+-----+
| 2020-02-29 02:02:02 | 2020-02-29 |
2019-12-31 |
+-----+-----+
+-----+
```

MONTHS_DIFF

描述

MONTHS_DIFF 函数用于计算两个日期之间相差的月份数。该函数接受两个日期参数，返回第一个日期减去第二个日期后的相差月份数。

语法

```
MONTHS_DIFF(<enddate>, <startdate>)
```

参数

参数	说明
<enddate>	结束日期，表示计算差值时的较晚日期。支持日期类型（如 DATE）或日期时间类型（如 DATETIME）
<startdate>	开始日期，表示计算差值时的较早日期。支持日期类型（如 DATE）或日期时间类型（如 DATETIME）

返回值

返回 <enddate> 减去 <startdate> 所得月份数 - 当<enddate>与<startdate>任意为NULL，或者两者都为NULL时，返回NULL

举例

```
select months_diff('2020-12-25','2020-10-25'),months_diff('2020-10-25 10:00:00','2020-12-25 11:00:00');

+-----+-----+
| months_diff(cast('2020-12-25' as DATETIMEV2(0)), cast('2020-10-25' as DATETIMEV2(0))) | months_diff(cast('2020-10-25 10:00:00' as DATETIMEV2(0)), cast('2020-12-25 11:00:00' as DATETIMEV2(0))) |
+-----+-----+
|                                           2 |
-2 |
+-----+-----+
```

MONTHS_SUB

描述

MONTHS_SUB 函数用于对指定日期添加或减去指定的月份数，并返回计算后的新日期

语法

```
MONTHS_SUB(<datetime/date>, <nums>)
```

参数

参数	说明
<datetime/date>	需要被计算加减月份的日期值
<nums>	需要加减的月份数

返回值

返回值与输入的类型一致 特殊情况： - 输入为 0000-00-00 或 0000-00-00 00:00:00 时，返回 NULL - 输入为 NULL 时，返回 NULL - 如果输入为 months_sub("9999-12-31",-1)，将返回 NULL

举例

```
select months_sub("2020-01-31 02:02:02", 1),months_sub("2020-01-31", 1),months_sub("2020-01-31", -1);
```

```
+-----+-----+
+-----+
| months_sub(cast('2020-01-31 02:02:02' as DATETIMEV2(0)), 1) | months_sub(cast('2020-01-31' as DATEV2), 1) |
months_sub(cast('2020-01-31' as DATEV2), -1) |
+-----+-----+
+-----+
| 2019-12-31 02:02:02 | 2019-12-31 |
2020-02-29 |
+-----+-----+
+-----+
```

YEARS_ADD

描述

返回一个新的日期时间值，该值是在输入的日期时间上增加指定的年数。

语法

```
YEARS_ADD(<date>, <years>)
```

参数

参数	说明
<date>	输入的日期时间值，类型为 DATETIME 或 DATE
<years>	要增加的年数，类型为 INT

返回值

返回与输入 <date> 类型相同的值（DATETIME 或 DATE），表示在输入日期时间的基础上增加指定年数后的时间值。

举例

```
SELECT YEARS_ADD('2020-01-31 02:02:02', 1);
```

```
+-----+
| years_add('2020-01-31 02:02:02', 1) |
+-----+
| 2021-01-31 02:02:02                  |
+-----+
```

YEARS_DIFF

描述

计算两个日期时间值之间相差的年数。

语法

```
YEARS_DIFF(<enddate>, <startdate>)
```

参数

参数	说明
<enddate>	结束日期，类型为 DATETIME 或 DATE
<startdate>	开始日期，类型为 DATETIME 或 DATE

返回值

返回类型为 INT，表示两个日期之间相差的年数。

举例

```
SELECT YEARS_DIFF('2020-12-25', '2019-10-25');
```

years_diff('2020-12-25 00:00:00', '2019-10-25 00:00:00')
1

YEARS_SUB

描述

返回一个新的日期时间值，该值是从输入的日期时间中减去指定的年数。

语法

```
YEARS_SUB(<date>, <years>)
```

参数

参数	说明
<date>	输入的日期时间值，类型为 DATETIME 或 DATE
<years>	要减去的年数，类型为 INT

返回值

返回与输入 <date> 类型相同的值（DATETIME 或 DATE），表示从输入日期时间中减去指定年数后的时间值。

举例

```
SELECT YEARS_SUB('2020-02-02 02:02:02', 1);
```

```
+-----+
| years_sub('2020-02-02 02:02:02', 1) |
+-----+
| 2019-02-02 02:02:02                  |
+-----+
```

ST_X

描述

当 point 是一个合法的 POINT 类型时，返回对应的 X 坐标值

语法

```
ST_X( <point>)
```

参数

参数	说明
<point>	二维点的几何坐标

返回值

几何坐标中的 X 值

举例

```
SELECT ST_X(ST_Point(24.7, 56.7));
```

```
+-----+
| st_x(st_point(24.7, 56.7)) |
+-----+
|                24.7 |
+-----+
```

ST_Y

描述

当 point 是一个合法的 POINT 类型时，返回对应的 Y 坐标值

语法

```
ST_Y( <point>)
```

参数

参数	说明
<point>	二维点的几何坐标

返回值

几何坐标中的 Y 值

举例

```
SELECT ST_Y(ST_Point(24.7, 56.7));
```

```
+-----+
| ST_Y(ST_Point(24.7, 56.7)) |
+-----+
| 56.7                        |
+-----+
```

ST_CIRCLE

描述

将一个 WKT（Well Known Text）转化为地球球面上的一个圆。

语法

```
ST_CIRCLE( <center_lng>, <center_lat>, <radius>)
```

参数

参数	说明
<center_lng>	圆心的经度
<center_lat>	圆心的纬度
<radius>	圆的半径

- radius 单位是米，最大支持 9999999

返回值

根据圆的基本信息得到的球面上的一个圆

举例

```
SELECT ST_AsText(ST_Circle(111, 64, 10000));
```

```
+-----+
| st_astext(st_circle(111.0, 64.0, 10000.0)) |
+-----+
| CIRCLE ((111 64), 10000)                  |
+-----+
```

ST_DISTANCE_SPHERE

描述

计算地球两点之间的球面距离，单位为 米。传入的参数分别为 X 点的经度，X 点的纬度，Y 点的经度，Y 点的纬度。

语法

```
ST_DISTANCE_SPHERE( <x_lng>, <x_lat>, <y_lng>, <y_lat>)
```

参数

参数	说明
<x_lng>	经度数据，合理的取值范围是 [-180, 180]
<y_lng>	经度数据，合理的取值范围是 [-180, 180]
<x_lat>	纬度数据，合理的取值范围是 [-90, 90]
<y_lat>	纬度数据，合理的取值范围是 [-90, 90]

返回值

两点之间的球面距离

举例

```
select st_distance_sphere(116.35620117, 39.939093, 116.4274406433, 39.9020987219);

+-----+
| st_distance_sphere(116.35620117, 39.939093, 116.4274406433, 39.9020987219) |
+-----+
|                                     7336.9135549995917 |
+-----+
```

ST_ANGLE

描述

输入三个点，它们表示两条相交的线。返回这些线之间的夹角。

语法

```
ST_ANGLE( <point1>, <point2>, <point3>)
```

参数

参数	说明
<point1>	第一条直线的第一个端点
<point2>	第一条直线的第二个端点且是第二条直线的第一个端点
<point3>	第二条直线的第二个端点

返回值

这些线之间的夹角以弧度表示，范围为 [0, 2pi)。夹角按顺时针方向从第一条线开始测量，直至第二条线。

ST_ANGLE 存在以下边缘情况：

- 如果点 2 和点 3 相同，则返回 NULL。
- 如果点 2 和点 1 相同，则返回 NULL。
- 如果点 2 和点 3 是完全对映点，则返回 NULL。
- 如果点 2 和点 1 是完全对映点，则返回 NULL。
- 如果任何输入地理位置不是单点或为空地理位置，则会抛出错误。

举例

```
SELECT ST_Angle(ST_Point(1, 0),ST_Point(0, 0),ST_Point(0, 1));
```

```
+-----+
| st_angle(st_point(1.0, 0.0), st_point(0.0, 0.0), st_point(0.0, 1.0)) |
+-----+
|                               4.71238898038469 |
+-----+
```

```
SELECT ST_Angle(ST_Point(0, 0),ST_Point(1, 0),ST_Point(0, 1));
```

```
+-----+
| st_angle(st_point(0.0, 0.0), st_point(1.0, 0.0), st_point(0.0, 1.0)) |
+-----+
```

0.78547432161873854

```
SELECT ST_Angle(ST_Point(1, 0),ST_Point(0, 0),ST_Point(1, 0));
```

st_angle(st_point(1.0, 0.0), st_point(0.0, 0.0), st_point(1.0, 0.0))
0

```
SELECT ST_Angle(ST_Point(1, 0),ST_Point(0, 0),ST_Point(0, 0));
```

st_angle(st_point(1.0, 0.0), st_point(0.0, 0.0), st_point(0.0, 0.0))
NULL

```
SELECT ST_Angle(ST_Point(0, 0),ST_Point(-30, 0),ST_Point(150, 0));
```

st_angle(st_point(0.0, 0.0), st_point(-30.0, 0.0), st_point(150.0, 0.0))
NULL

ST_AZIMUTH

描述

输入两个点，并返回由点 1 和点 2 形成的线段的方位角。方位角是点 1 的真北方向线与点 1 和点 2 形成的线段之间的角的弧度。

语法

```
ST_AZIMUTH( <point1>, <point2>)
```

参数

参数	说明
<point1>	用于计算方位角的第一个点
<point2>	用于计算方位角的第二个点

返回值

正角在球面上按顺时针方向测量。例如，线段的方位角：

- 指北是 0
- 指东是 $\pi/2$
- 指南是 π
- 指西是 $3\pi/2$

ST_Azimuth 存在以下边缘情况：

- 如果两个输入点相同，则返回 NULL。
- 如果两个输入点是完全对映点，则返回 NULL。
- 如果任一输入地理位置不是单点或为空地理位置，则会抛出错误。

举例

```
SELECT st_azimuth(ST_Point(1, 0),ST_Point(0, 0));
```

```
+-----+
| st_azimuth(st_point(1.0, 0.0), st_point(0.0, 0.0)) |
+-----+
|                                     4.71238898038469 |
+-----+
```

```
SELECT st_azimuth(ST_Point(0, 0),ST_Point(1, 0));
```



```

+-----+
| st_azimuth(st_point(0.0, 0.0), st_point(1.0, 0.0)) |
+-----+
|                                1.5707963267948966 |
+-----+

```

```
SELECT st_azimuth(ST_Point(0, 0),ST_Point(0, 1));
```

```

+-----+
| st_azimuth(st_point(0.0, 0.0), st_point(0.0, 1.0)) |
+-----+
|                                0 |
+-----+

```

```
SELECT st_azimuth(ST_Point(-30, 0),ST_Point(150, 0));
```

```

+-----+
| st_azimuth(st_point(-30.0, 0.0), st_point(150.0, 0.0)) |
+-----+
|                                NULL |
+-----+

```

ST_ANGLE_SPHERE

描述

计算地球表面两点之间的圆心角，单位为 度。传入的参数分别为 X 点的经度，X 点的纬度，Y 点的经度，Y 点的纬度。

语法

```
ST_ANGLE_SPHERE( <x_lng>, <x_lat>, <y_lng>, <y_lat>)
```

参数

参数	说明
<x_lng>	经度数据，合理的取值范围是 [-180, 180]
<y_lng>	经度数据，合理的取值范围是 [-180, 180]
<x_lat>	纬度数据，合理的取值范围是 [-90, 90]
<y_lat>	纬度数据，合理的取值范围是 [-90, 90]

返回值

两点之间的圆心角角度

举例

```
select ST_Angle_Sphere(116.35620117, 39.939093, 116.4274406433, 39.9020987219);
```

```
+-----+
| st_angle_sphere(116.35620117, 39.939093, 116.4274406433, 39.9020987219) |
+-----+
|                                0.0659823452409903 |
+-----+
```

```
select ST_Angle_Sphere(0, 0, 45, 0);
```

```
+-----+
| st_angle_sphere(0.0, 0.0, 45.0, 0.0) |
+-----+
|                                45 |
+-----+
```

ST_AREA_SQUARE_METERS

描述

计算地球球面上区域的面积

语法

```
ST_AREA_SQUARE_METERS( <geo>)
```

参数

参数	说明
<geo>	地球球面位置

返回值

ST_Area_Square_Meters() 返回的单位是平方米

举例

```
SELECT ST_Area_Square_Meters(ST_Circle(0, 0, 1));
```

```
+-----+
| st_area_square_meters(st_circle(0.0, 0.0, 1.0)) |
+-----+
|                      3.1415926535897869 |
+-----+
```

```
SELECT ST_Area_Square_Meters(ST_Point(0, 1));
```

```
+-----+
| st_area_square_meters(st_point(0.0, 1.0)) |
+-----+
|                      0 |
+-----+
```

```
SELECT ST_Area_Square_Meters(ST_LineFromText("LINESTRING (1 1, 2 2)"));
```

```
+-----+
| st_area_square_meters(st_linefromtext('LINESTRING (1 1, 2 2)')) |
+-----+
|                      0 |
+-----+
```

ST_AREA_SQUARE_KM

描述

计算地球球面上区域的面积

语法

```
ST_AREA_SQUARE_KM( <geo>)
```

参数

参数	说明
<geo>	地球球面位置

返回值

ST_Area_Square_Km() 返回的单位是平方千米。

举例

```
SELECT ST_Area_Square_Km(ST_Polygon("POLYGON ((0 0, 1 0, 1 1, 0 1, 0 0))"));
```

```
+-----+
| st_area_square_km(st_polygon('POLYGON ((0 0, 1 0, 1 1, 0 1, 0 0))')) |
+-----+
|                                12364.036567076409 |
+-----+
```

ST_POINT

描述

通过给定的 X 坐标值，Y 坐标值返回对应的 Point。

当前这个值只是在球面集合上有意义，X/Y 对应的是经度/纬度 (longitude/latitude);

语法

```
ST_POINT( <x>, <y>)
```

参数

参数	说明
<x>	横坐标
<y>	纵坐标

返回值

给定横坐标以及纵坐标对应的位置信息

举例

```
SELECT ST_AsText(ST_Point(24.7, 56.7));
```

```
+-----+
| st_astext(st_point(24.7, 56.7)) |
+-----+
| POINT (24.7 56.7)               |
+-----+
```

ST_POLYGON

描述

将一个 WKT（Well Known Text）转化为对应的多边形内存形式

别名

- ST_POLYGONFROMTEXT
- ST_POLYFROMTEXT

语法

```
ST_POLYGON( <wkt>)
```

参数

参数	说明
<wkt>	由 POLYGON 函数生成的一个多边形

返回值

多边形的内存形式。

举例

```
SELECT ST_AsText(ST_Polygon("POLYGON ((0 0, 10 0, 10 10, 0 10, 0 0))"));
```

```
+-----+
| st_astext(st_polygon('POLYGON ((0 0, 10 0, 10 10, 0 10, 0 0))')) |
+-----+
| POLYGON ((0 0, 10 0, 10 10, 0 10, 0 0)) |
+-----+
```

ST_ASTEXT

描述

将一个几何图形转化为 WKT（Well Known Text） 的表示形式

别名

- ST_ASWKT

语法

```
ST_ASTEXT( <geo>)
```

参数

参数	说明
<geo>	待转换的几何图形

返回值

该几何图形的 WKT 表示形式

举例

```
SELECT ST_AsText(ST_Point(24.7, 56.7));
```

```
+-----+
| st_astext(st_point(24.7, 56.7)) |
+-----+
| POINT (24.7 56.7)               |
+-----+
```

ST_CONTAINS

描述

判断几何图形 shape1 是否完全能够包含几何图形 shape2

语法

```
ST_CONTAINS( <shape1>, <shape2>)
```

参数

参数	说明
<shape1>	传入的几何图形，用于判断是否包含 shape2
<shape2>	传入的几何图形，用于判断是被 shape1 包含

返回值

返回 1:shape1 图形可包含图形 shape2

返回 0:shape1 图形不可包含图形 shape2

举例

```
SELECT ST_Contains(ST_Polygon("POLYGON ((0 0, 10 0, 10 10, 0 10, 0 0))"), ST_Point(5, 5));
```

```
+-----+
| st_contains(st_polygon('POLYGON ((0 0, 10 0, 10 10, 0 10, 0 0))'), st_point(5.0, 5.0)) |
+-----+
|                                                                                          1 |
+-----+
```

```
SELECT ST_Contains(ST_Polygon("POLYGON ((0 0, 10 0, 10 10, 0 10, 0 0))"), ST_Point(50, 50));
```

```
+-----+
| st_contains(st_polygon('POLYGON ((0 0, 10 0, 10 10, 0 10, 0 0))'), st_point(50.0, 50.0)) |
+-----+
|                                                                                          0 |
+-----+
```


ST_GEOMETRYFROMTEXT

描述

将一个线型 WKT （Well Known Text） 转化为对应的内存的几何形式

别名

- ST_GEOMFROMTEXT

语法

```
ST_GEOMETRYFROMTEXT( <wkt>)
```

参数

参数	说明
<wkt>	图形的内存形式

返回值

WKB 的对应的几何存储形式

举例

```
SELECT ST_AsText(ST_GeometryFromText("LINESTRING (1 1, 2 2)"));
```

```
+-----+
| st_astext(st_geometryfromtext('LINESTRING (1 1, 2 2)')) |
+-----+
| LINESTRING (1 1, 2 2) |
+-----+
```

ST_LINEFROMTEXT

描述

将一个 WKT（Well Known Text）转化为一个 Line 形式的内存表现形式

别名

- ST_LINESTRINGFROMTEXT

语法

```
ST_LINEFROMTEXT( <wkt>)
```

参数

参数	说明
<wkt>	由两个坐标组成的线段

返回值

线段的内存形式。

举例

```
SELECT ST_AsText(ST_LineFromText("LINESTRING (1 1, 2 2)"));

+-----+
| st_astext(st_geometryfromtext('LINESTRING (1 1, 2 2)')) |
+-----+
| LINESTRING (1 1, 2 2) |
+-----+
```

ST_ASBINARY

描述

将一个几何图形转化为一个标准 WKB（Well-known binary）的表示形式。

目前支持对几何图形是：Point, LineString, Polygon。

语法

```
ST_ASBINARY( <geo>)
```

参数

参数	说明
<geo>	需要被转换的图形

返回值

该几何图形的 WKB 表示形式：

举例

```
select ST_AsBinary(st_point(24.7, 56.7));
```

```
+-----+
| st_asbinary(st_point(24.7, 56.7))          |
+-----+
| \x01010000003333333333b338409a99999999594c40 |
+-----+
```

```
select ST_AsBinary(ST_GeometryFromText("LINESTRING (1 1, 2 2)"));
```

```
+-----+
| st_asbinary(st_geometryfromtext('LINESTRING (1 1, 2 2)'))          |
+-----+
| \x01020000000200000000000000000000f03f000000000000f03f000000000000400000000000000040 |
+-----+
```

```
select ST_AsBinary(ST_Polygon("POLYGON ((114.104486 22.547119,114.093758 22.547753,114.096504
22.532057,114.104229 22.539826,114.106203 22.542680,114.104486 22.547119))"));
```

```
+-----+
+-----+
```

```
-----+
| st_asbinary(st_polygon('POLYGON (((114.104486 22.547119,114.093758 22.547753,114.096504 22.532057,114.104229
22.539826,114.106203 22.542680,114.104486 22.547119)))'))
|
+-----+
-----+
|
\x01030000000100000006000000f3380ce6af865c402d05a4fd0f8c364041ef8d2100865c403049658a398c3640b9fb1c1f2d865c409
d9b36e334883640de921cb0ab865c40cf876709328a36402cefaa07cc865c407b319413ed8a3640f3380ce6af865c402d05a4fd0f8c36
40 |
+-----+
-----+
```

ST_GEOMETRYFROMWKB

描述

将一个标准图形 WKB（Well-known binary）转化为对应的内存的几何形式

别名

- ST_GEOMFROMWKB

语法

```
ST_GEOMETRYFROMWKB( <wkb>)
```

参数

参数	说明
<wkb>	图形的内存形式

返回值

WKB 的对应的几何存储形式

举例

```
select ST_AsText(ST_GeometryFromWKB(ST_AsBinary(ST_Point(24.7, 56.7))));
```

```
+-----+
| st_astext(st_geometryfromwkb(st_asbinary(st_point(24.7, 56.7)))) |
+-----+
| POINT (24.7 56.7) |
+-----+
```

```
select ST_AsText(ST_GeomFromWKB(ST_AsBinary(ST_Point(24.7, 56.7))));
```

```
+-----+
| st_astext(st_geomfromwkb(st_asbinary(st_point(24.7, 56.7)))) |
+-----+
| POINT (24.7 56.7) |
+-----+
```

```
select ST_AsText(ST_GeometryFromWKB(ST_AsBinary(ST_GeometryFromText("LINESTRING (1 1, 2 2)"))));
```

```
+-----+
| st_astext(st_geometryfromwkb(st_asbinary(st_geometryfromtext('LINESTRING (1 1, 2 2)')))) |
+-----+
| LINESTRING (1 1, 2 2) |
+-----+
```

```
select ST_AsText(ST_GeometryFromWKB(ST_AsBinary(ST_Polygon("POLYGON ((114.104486 22.547119,114.093758
22.547753,114.096504 22.532057,114.104229 22.539826,114.106203 22.542680,114.104486 22.547119))"))));
```

```
+-----+
+-----+
| st_astext(st_geometryfromwkb(st_asbinary(st_polygon('POLYGON ((114.104486 22.547119,114.093758
22.547753,114.096504 22.532057,114.104229 22.539826,114.106203 22.542680,114.104486 22.547119))')))) |
+-----+
+-----+
| POLYGON ((114.104486 22.547119, 114.093758 22.547753, 114.096504 22.532057, 114.104229 22.539826,
114.106203 22.54268, 114.104486 22.547119)) |
+-----+
+-----+
```

```
select ST_AsText(ST_GeomFromWKB(ST_AsBinary(ST_Polygon("POLYGON ((114.104486 22.547119,114.093758
22.547753,114.096504 22.532057,114.104229 22.539826,114.106203 22.542680,114.104486 22.547119))"))));
```

```
+-----+
+-----+
| st_astext(st_geomfromwkb(st_asbinary(st_polygon('POLYGON ((114.104486 22.547119,114.093758
22.547753,114.096504 22.532057,114.104229 22.539826,114.106203 22.542680,114.104486 22.547119))')))) |
+-----+
+-----+
| POLYGON ((114.104486 22.547119, 114.093758 22.547753, 114.096504 22.532057, 114.104229 22.539826,
114.106203 22.54268, 114.104486 22.547119)) |
+-----+
+-----+
```

TO_BASE64

to_base64

描述

语法

VARCHAR to_base64(VARCHAR str)

返回对输入的字符串进行Base64编码后的结果

举例

```
mysql> select to_base64('1');
+-----+
| to_base64('1') |
+-----+
| MQ==           |
+-----+

mysql> select to_base64('234');
+-----+
| to_base64('234') |
+-----+
| MjM0             |
+-----+
```

keywords

to_base64

FROM_BASE64

from_base64

描述

语法

VARCHAR from_base64(VARCHAR str)

返回对输入的字符串进行Base64解码后的结果

举例

```
mysql> select from_base64('MQ==');
+-----+
| from_base64('MQ==') |
+-----+
| 1                    |
+-----+

mysql> select from_base64('MjM0');
+-----+
| from_base64('MjM0') |
+-----+
| 234                  |
+-----+
```

keywords

from_base64

ASCII

ascii

描述

语法

INT ascii(VARCHAR str)

返回字符串第一个字符对应的 ascii 码

举例

```
mysql> select ascii('1');
+-----+
| ascii('1') |
+-----+
|          49 |
+-----+

mysql> select ascii('234');
+-----+
| ascii('234') |
+-----+
|           50 |
+-----+
```

keywords

ASCII

LENGTH

length

描述

语法

INT length(VARCHAR str)

返回字符串的字节。

举例

```
mysql> select length("abc");
+-----+
| length('abc') |
+-----+
|              3 |
+-----+

mysql> select length("中国");
+-----+
| length('中国') |
+-----+
|              6 |
+-----+
```

keywords

LENGTH

BIT_LENGTH

bit_length

描述

语法

INT bit_length(VARCHAR str)

返回字符串的位长度。

举例

```
mysql> select bit_length("abc");
+-----+
| bit_length('abc') |
+-----+
|                24 |
+-----+

mysql> select bit_length("中国");
+-----+
| bit_length('中国') |
+-----+
|                48 |
+-----+
```

keywords

BIT_LENGTH

CHAR_LENGTH

char_length

描述

语法

INT char_length(VARCHAR str)

返回字符串的长度，对于多字节字符，返回字符数，目前仅支持utf8 编码。这个函数还有一个别名 character_length。

举例

```
mysql> select char_length("abc");
+-----+
| char_length('abc') |
+-----+
|                3 |
+-----+

mysql> select char_length("中国");
+-----+
| char_length('中国') |
+-----+
|                2 |
+-----+
```

keywords

CHAR_LENGTH, CHARACTER_LENGTH

LPAD

lpad

描述

语法

VARCHAR lpad(VARCHAR str, INT len, VARCHAR pad)

返回 str 中长度为 len（从首字母开始算起）的字符串。如果 len 大于 str 的长度，则在 str 的前面不断补充 pad 字符，直到该字符串的长度达到 len 为止。如果 len 小于 str 的长度，该函数相当于截断 str 字符串，只返回长度为 len 的字符串。len 指的是字符长度而不是字节长度。

除包含 NULL 值外，如果 pad 为空，则返回值为空串。

举例

```
mysql> SELECT lpad("hi", 5, "xy");
```

```
+-----+
| lpad('hi', 5, 'xy') |
+-----+
| xyxhi                |
+-----+
```

```
mysql> SELECT lpad("hi", 1, "xy");
```

```
+-----+
| lpad('hi', 1, 'xy') |
+-----+
| h                    |
+-----+
```

```
mysql> SELECT lpad("", 0, "");
```

```
+-----+
| lpad('', 0, '')      |
+-----+
|                      |
+-----+
```

keywords

LPAD

RPAD

rpad

描述

语法

VARCHAR rpad(VARCHAR str, INT len, VARCHAR pad)

返回 str 中长度为 len（从首字母开始算起）的字符串。如果 len 大于 str 的长度，则在 str 的后面不断补充 pad 字符，直到该字符串的长度达到 len 为止。如果 len 小于 str 的长度，该函数相当于截断 str 字符串，只返回长度为 len 的字符串。len 指的是字符长度而不是字节长度。

除包含 NULL 值外，如果 pad 为空，则返回值为空串。

举例

```
mysql> SELECT rpad("hi", 5, "xy");
```

```
+-----+
| rpad('hi', 5, 'xy') |
+-----+
| hixyx                |
+-----+
```

```
mysql> SELECT rpad("hi", 1, "xy");
```

```
+-----+
| rpad('hi', 1, 'xy') |
+-----+
| h                    |
+-----+
```

```
mysql> SELECT rpad("", 0, "");
```

```
+-----+
| rpad('', 0, '')      |
+-----+
|                      |
+-----+
```

keywords

RPAD

LOWER

lower

描述

语法

VARCHAR lower(VARCHAR str)

将参数中所有的字符串都转换成小写，该函数的另一个别名为[lcase](#)。

举例

```
mysql> SELECT lower("AbC123");
+-----+
| lower('AbC123') |
+-----+
| abc123          |
+-----+
```

keywords

LOWER

LCASE

lcase

描述

语法

INT lcase(VARCHAR str)

将参数中所有的字符串都转换成小写，该函数的另一个别名为[lower](#)。

keywords

LCASE

UPPER

upper

描述

语法

VARCHAR upper(VARCHAR str)

将参数中所有的字符串都转换成大写，此函数的另一个别名为[ucase](#)。

举例

```
mysql> SELECT upper("aBc123");
+-----+
| upper('aBc123') |
+-----+
| ABC123           |
+-----+
```

keywords

UPPER

UCASE

ucase

描述

语法

VARCHAR ucase(VARCHAR str)

将参数中所有的字符串都转换成大写，此函数的另一个别名为[upper](#)。

keywords

UCASE

INITCAP

initcap

描述

语法

VARCHAR initcap(VARCHAR str)

将参数中包含的单词首字母大写，其余字母转为小写。单词是由非字母数字字符分隔的字母数字字符序列。

举例

```
mysql> select initcap('hello hello.,HELL0123HELlo');
+-----+
| initcap('hello hello.,HELL0123HELlo') |
+-----+
| Hello Hello.,Hello123hello           |
+-----+
```

keywords

INITCAP

REPEAT

repeat

描述

语法

VARCHAR repeat(VARCHAR str, INT count)

将字符串 str 重复 count 次输出，count 小于1时返回空串，str, count 任一为NULL时，返回 NULL

举例

```
mysql> SELECT repeat("a", 3);
```

```
+-----+  
| repeat('a', 3) |  
+-----+  
| aaa           |  
+-----+
```

```
mysql> SELECT repeat("a", -1);
```

```
+-----+  
| repeat('a', -1) |  
+-----+  
|                 |  
+-----+
```

keywords

REPEAT

REVERSE

reverse

描述

语法

```
VARCHAR reverse(VARCHAR str)
ARRAY<T> reverse(ARRAY<T> arr)
```

将字符串或数组反转，返回的字符串或者数组的顺序和原来的顺序相反。

举例

```
mysql> SELECT REVERSE('hello');
+-----+
| REVERSE('hello') |
+-----+
| olleh            |
+-----+
1 row in set (0.00 sec)

mysql> SELECT REVERSE('你好');
+-----+
| REVERSE('你好')  |
+-----+
| 好你             |
+-----+
1 row in set (0.00 sec)

mysql> select k1, k2, reverse(k2) from array_test order by k1;
+-----+-----+-----+
| k1  | k2                                | reverse(`k2`) |
+-----+-----+-----+
| 1   | [1, 2, 3, 4, 5]                  | [5, 4, 3, 2, 1] |
| 2   | [6, 7, 8]                        | [8, 7, 6]      |
| 3   | []                                | []             |
| 4   | NULL                             | NULL           |
| 5   | [1, 2, 3, 4, 5, 4, 3, 2, 1]      | [1, 2, 3, 4, 5, 4, 3, 2, 1] |
| 6   | [1, 2, 3, NULL]                  | [NULL, 3, 2, 1] |
| 7   | [4, 5, 6, NULL, NULL]            | [NULL, NULL, 6, 5, 4] |
+-----+-----+-----+

mysql> select k1, k2, reverse(k2) from array_test01 order by k1;
+-----+-----+-----+
| k1  | k2                                | reverse(`k2`) |
+-----+-----+-----+
| 1   | ['a', 'b', 'c', 'd']             | ['d', 'c', 'b', 'a'] |
| 2   | ['e', 'f', 'g', 'h']             | ['h', 'g', 'f', 'e'] |
| 3   | [NULL, 'a', NULL, 'b', NULL, 'c'] | ['c', NULL, 'b', NULL, 'a', NULL] |
| 4   | ['d', 'e', NULL, ' ' ]            | [' ', NULL, 'e', 'd'] |
| 5   | [' ', NULL, 'f', 'g']             | ['g', 'f', NULL, ' ' ] |
+-----+-----+-----+
```

keywords

REVERSE, ARRAY

CHAR

function char

描述

语法

`VARCHAR char(INT,..., [USING charset_name])`

将每个参数解释为整数，并返回一个字符串，该字符串由这些整数的代码值给出的字符组成。忽略NULL值。

如果结果字符串对于给定字符集是非法的，相应的转换结果为NULL值。

大于 255 的参数将转换为多个结果字节。例如，`char(15049882)`等价于`char(229, 164, 154)`。

`charset_name`目前只支持utf8。

举例

```
mysql> select char(68, 111, 114, 105, 115);
+-----+
| char('utf8', 68, 111, 114, 105, 115) |
+-----+
| Doris                                |
+-----+

mysql> select char(15049882, 15179199, 14989469);
+-----+
| char('utf8', 15049882, 15179199, 14989469) |
+-----+
| 多睿丝                                    |
+-----+

mysql> select char(255);
+-----+
| char('utf8', 255) |
+-----+
| NULL              |
+-----+
```

keywords

CHAR

CONCAT

concat

描述

语法

VARCHAR concat(VARCHAR,...)

将多个字符串连接起来, 如果参数中任意一个值是 NULL, 那么返回的结果就是 NULL

举例

```
mysql> select concat("a", "b");
+-----+
| concat('a', 'b') |
+-----+
| ab               |
+-----+

mysql> select concat("a", "b", "c");
+-----+
| concat('a', 'b', 'c') |
+-----+
| abc                   |
+-----+

mysql> select concat("a", null, "c");
+-----+
| concat('a', NULL, 'c') |
+-----+
| NULL                   |
+-----+
```

keywords

CONCAT

CONCAT_WS

concat_ws

描述

语法

```
VARCHAR concat_ws(VARCHAR sep, VARCHAR str,...)
VARCHAR concat_ws(VARCHAR sep, ARRAY array)
```

使用第一个参数 `sep` 作为连接符，将第二个参数以及后续所有参数(或ARRAY中的所有字符串)拼接成一个字符串。如果分隔符是 `NULL`，返回 `NULL`。concat_ws函数不会跳过空字符串，会跳过 `NULL` 值。

举例

```
mysql> select concat_ws("or", "d", "is");
+-----+
| concat_ws('or', 'd', 'is') |
+-----+
| doris                        |
+-----+

mysql> select concat_ws(NULL, "d", "is");
+-----+
| concat_ws(NULL, 'd', 'is') |
+-----+
| NULL                        |
+-----+

mysql> select concat_ws("or", "d", NULL,"is");
+-----+
| concat_ws("or", "d", NULL,"is") |
+-----+
| doris                            |
+-----+

mysql> select concat_ws("or", ["d", "is"]);
+-----+
| concat_ws('or', ARRAY('d', 'is')) |
+-----+
| doris                             |
+-----+

mysql> select concat_ws(NULL, ["d", "is"]);
+-----+
| concat_ws(NULL, ARRAY('d', 'is')) |
+-----+
| NULL                             |
+-----+

mysql> select concat_ws("or", ["d", NULL,"is"]);
+-----+
| concat_ws('or', ARRAY('d', NULL, 'is')) |
+-----+
```

```
+-----+
| doris |
+-----+
```

keywords

```
CONCAT_WS, CONCAT, WS, ARRAY
```

SUBSTR

substr

描述

语法

VARCHAR substr(VARCHAR content, INT start, INT length)

求子字符串，返回第一个参数描述的字符串中从start开始长度为len的部分字符串。首字母的下标为1。

举例

```
mysql> select substr("Hello doris", 2, 1);
+-----+
| substr('Hello doris', 2, 1) |
+-----+
| e                             |
+-----+
mysql> select substr("Hello doris", 1, 2);
+-----+
| substr('Hello doris', 1, 2) |
+-----+
| He                           |
+-----+
```

keywords

SUBSTR

SUBSTRING

substring

描述

语法

VARCHAR substring(VARCHAR str, INT pos[, INT len])

没有 len 参数时返回从位置 pos 开始的字符串 str 的一个子字符串，在有 len 参数时返回从位置 pos 开始的字符串 str 的一个长度为 len 子字符串，pos 参数可以使用负值，在这种情况下，子字符串是以字符串 str 末尾开始计算 pos 个字符，而不是开头，pos 的值为 0 返回一个空字符串。

对于所有形式的 SUBSTRING(), 要从中提取子字符串的字符串中第一个字符的位置为1。

举例

```
mysql> select substring('abc1', 2);
```

+-----+	
substring('abc1', 2)	
+-----+	
bc1	
+-----+	

```
mysql> select substring('abc1', -2);
```

+-----+	
substring('abc1', -2)	
+-----+	
c1	
+-----+	

```
mysql> select substring('abc1', 0);
```

+-----+	
substring('abc1', 0)	
+-----+	
+-----+	

```
mysql> select substring('abc1', 5);
```

+-----+	
substring('abc1', 5)	
+-----+	
NULL	
+-----+	

```
mysql> select substring('abc1def', 2, 2);
```

+-----+	
substring('abc1def', 2, 2)	
+-----+	
bc	
+-----+	

keywords

SUBSTRING, STRING

SUB_REPLACE

sub_replace

描述

语法

VARCHAR sub_replace(VARCHAR str, VARCHAR new_str, INT start[, INT len])

返回用new_str字符串替换str中从start开始长度为len的新字符串。其中start,len为负整数，返回NULL，且len的默认值为new_str的长度。

举例

```
mysql> select sub_replace("this is origin str","NEW-STR",1);
```

```
+-----+
| sub_replace('this is origin str', 'NEW-STR', 1) |
+-----+
| tNEW-STRorigin str                               |
+-----+
```

```
mysql> select sub_replace("doris","***",1,2);
```

```
+-----+
| sub_replace('doris', '***', 1, 2) |
+-----+
| d***is                             |
+-----+
```

keywords

SUB_REPLACE

APPEND_TRAILING_CHAR_IF_ABSENT

append_trailing_char_if_absent

描述

语法

VARCHAR append_trailing_char_if_absent(VARCHAR str, VARCHAR trailing_char)

如果 str 字符串非空并且末尾不包含 trailing_char 字符，则将 trailing_char 字符附加到末尾。trailing_char 只能包含一个字符，如果包含多个字符，将返回NULL

举例

```
MySQL [test]> select append_trailing_char_if_absent('a','c');
+-----+
| append_trailing_char_if_absent('a', 'c') |
+-----+
| ac                                       |
+-----+
1 row in set (0.02 sec)

MySQL [test]> select append_trailing_char_if_absent('ac','c');
+-----+
| append_trailing_char_if_absent('ac', 'c') |
+-----+
| ac                                       |
+-----+
1 row in set (0.00 sec)
```

keywords

APPEND_TRAILING_CHAR_IF_ABSENT

ENDS_WITH

ends_with

描述

语法

BOOLEAN ENDS_WITH(VARCHAR str, VARCHAR suffix)

如果字符串以指定后缀结尾，返回true。否则，返回false。任意参数为NULL，返回NULL。

举例

```
mysql> select ends_with("Hello doris", "doris");
+-----+
| ends_with('Hello doris', 'doris') |
+-----+
| 1 |
+-----+

mysql> select ends_with("Hello doris", "Hello");
+-----+
| ends_with('Hello doris', 'Hello') |
+-----+
| 0 |
+-----+
```

keywords

ENDS_WITH

STARTS_WITH

starts_with

描述

语法

BOOLEAN STARTS_WITH(VARCHAR str, VARCHAR prefix)

如果字符串以指定前缀开头，返回true。否则，返回false。任意参数为NULL，返回NULL。

举例

```
MySQL [(none)]> select starts_with("hello world","hello");
+-----+
| starts_with('hello world', 'hello') |
+-----+
| 1 |
+-----+

MySQL [(none)]> select starts_with("hello world","world");
+-----+
| starts_with('hello world', 'world') |
+-----+
| 0 |
+-----+
```

keywords

STARTS_WITH

TRIM

trim

描述

语法

VARCHAR trim(VARCHAR str[, VARCHAR rhs])

当没有rhs参数时，将参数 str 中右侧和左侧开始部分连续出现的空格去掉，否则去掉rhs

举例

```
mysql> SELECT trim('  ab d  ') str;
+-----+
| str |
+-----+
| ab d |
+-----+

mysql> SELECT trim('ababccaab','ab') str;
+-----+
| str |
+-----+
| cca |
+-----+
```

keywords

TRIM

LTRIM

ltrim

描述

语法

VARCHAR ltrim(VARCHAR str[, VARCHAR rhs])

当没有rhs参数时，将参数 str 中从左侧部分开始部分连续出现的空格去掉，否则去掉rhs

举例

```
mysql> SELECT ltrim('  ab d') str;
+-----+
| str   |
+-----+
| ab d  |
+-----+

mysql> SELECT ltrim('ababccaab','ab') str;
+-----+
| str   |
+-----+
| ccaab |
+-----+
```

keywords

LTRIM

RTRIM

rtrim

描述

语法

VARCHAR rtrim(VARCHAR str[, VARCHAR rhs])

当没有rhs参数时，将参数 str 中从右侧部分开始部分连续出现的空格去掉，否则去掉rhs

举例

```
mysql> SELECT rtrim('ab d  ') str;
+-----+
| str   |
+-----+
| ab d  |
+-----+

mysql> SELECT rtrim('ababccaab','ab') str;
+-----+
| str      |
+-----+
| ababcca  |
+-----+
```

keywords

RTRIM

NULL_OR_EMPTY

描述

`null_or_empty` 函数用于判断给定的值是否为 NULL 或空。如果输入值为 NULL 或空字符串，则返回 `true`，否则返回 `false`。

语法

```
NULL_OR_EMPTY (<str>)
```

参数

参数	说明
<str>	字符串类型

返回值

如果字符串为空字符串或者 NULL，返回 `true`；否则返回 `false`。

示例

```
select null_or_empty(null);
```


```
+-----+
| null_or_empty(NULL) |
+-----+
| 1 |
+-----+
```

```
select null_or_empty("");
```

```
+-----+
| null_or_empty('') |
+-----+
| 1 |
+-----+
```

```
select null_or_empty("a");
```

```
+-----+
| null_or_empty('a') |
+-----+
```



NOT_NULL_OR_EMPTY

描述

not_null_or_empty 函数用于判断给定的值是否为非 NULL 且非空。如果输入值不为 NULL 且不为空，则返回 true；否则返回 false。

语法

```
NOT_NULL_OR_EMPTY (<str>)
```

参数

参数	说明
<str>	字符串类型

返回值

如果字符串为空字符串或者 NULL，返回 false；否则返回 true。

举例

```
select not_null_or_empty(null);
```


```
+-----+
| not_null_or_empty(NULL) |
+-----+
| 0 |
+-----+
```

```
select not_null_or_empty('');
```

```
+-----+
| not_null_or_empty('') |
+-----+
| 0 |
+-----+
```

```
select not_null_or_empty('a');
```

```
+-----+
| not_null_or_empty('a') |
+-----+
```



HEX

hex

描述

语法

VARCHAR hex(VARCHAR str)

VARCHAR hex(BIGINT num)

如果输入参数是数字，返回十六进制值的字符串表示形式；

如果输入参数是字符串，则将每个字符转化为两个十六进制的字符，将转化后的所有字符拼接为字符串输出

举例

输入字符串

```
mysql> select hex('1');
+-----+
| hex('1') |
+-----+
| 31       |
+-----+

mysql> select hex('@');
+-----+
| hex('@') |
+-----+
| 40       |
+-----+

mysql> select hex('12');
+-----+
| hex('12') |
+-----+
| 3132      |
+-----+
```

输入数字

```
mysql> select hex(12);
+-----+
| hex(12) |
+-----+
| C       |
+-----+

mysql> select hex(-1);
+-----+
| hex(-1) |
+-----+
```

| FFFFFFFFFFFFFFFF |
+-----+

keywords

HEX

UNHEX

unhex

描述

语法

VARCHAR unhex(VARCHAR str)

输入字符串，如果字符串长度为0或者为奇数，返回空串；如果字符串中包含[0-9]、[a-f]、[A-F]之外的字符，返回空串；其他情况每两个字符为一组转化为16进制后的字符，然后拼接成字符串输出

举例

```
mysql> select unhex('@');
+-----+
| unhex('@') |
+-----+
|             |
+-----+

mysql> select unhex('41');
+-----+
| unhex('41') |
+-----+
| A           |
+-----+

mysql> select unhex('4142');
+-----+
| unhex('4142') |
+-----+
| AB            |
+-----+
```

keywords

UNHEX

ELT

elt

描述

语法

VARCHAR elt(INT, VARCHAR,...)

在指定的索引处返回一个字符串。如果指定的索引处没有字符串，则返回NULL。

举例

```
mysql> select elt(1, 'aaa', 'bbb');
+-----+
| elt(1, 'aaa', 'bbb') |
+-----+
| aaa                  |
+-----+
mysql> select elt(2, 'aaa', 'bbb');
+-----+
| elt(2, 'aaa', 'bbb') |
+-----+
| bbb                  |
+-----+
mysql> select elt(0, 'aaa', 'bbb');
+-----+
| elt(0, 'aaa', 'bbb') |
+-----+
| NULL                 |
+-----+
mysql> select elt(2, 'aaa', 'bbb');
+-----+
| elt(3, 'aaa', 'bbb') |
+-----+
| NULL                 |
+-----+
```

keywords

ELT

INSTR

instr

描述

语法

INT instr(VARCHAR str, VARCHAR substr)

返回 substr 在 str 中第一次出现的位置（从1开始计数）。如果 substr 不在 str 中出现，则返回0。

举例

```
mysql> select instr("abc", "b");
+-----+
| instr('abc', 'b') |
+-----+
|                2 |
+-----+

mysql> select instr("abc", "d");
+-----+
| instr('abc', 'd') |
+-----+
|                0 |
+-----+
```

keywords

INSTR

LOCATE

locate

描述

语法

INT locate(VARCHAR substr, VARCHAR str[, INT pos])

返回 substr 在 str 中出现的位置（从1开始计数）。如果指定第3个参数 pos，则从 str 以 pos 下标开始的字符串处开始查找 substr 出现的位置。如果没有找到，返回0

举例

```
mysql> SELECT LOCATE('bar', 'foobarbar');
+-----+
| locate('bar', 'foobarbar') |
+-----+
| 4 |
+-----+

mysql> SELECT LOCATE('xbar', 'foobar');
+-----+
| locate('xbar', 'foobar') |
+-----+
| 0 |
+-----+

mysql> SELECT LOCATE('bar', 'foobarbar', 5);
+-----+
| locate('bar', 'foobarbar', 5) |
+-----+
| 7 |
+-----+
```

keywords

LOCATE

FIELD

描述

返回 <expr> 在参数列表中的位置（基于 1 的索引），常用于 ORDER BY 子句中实现自定义排序。如果 <expr> 不在参数列表中，或 <expr> 为 NULL，则返回 0。在自定义排序中，不在参数列表中的数据会被排到最前面，可通过 asc 或 desc 控制整体排序顺序；对于 NULL 值，可以使用 nulls first 或 nulls last 控制排序顺序。

语法

```
FIELD(<expr>, <param> [, ...])
```

参数

参数	说明
<expr>	要搜索的值。
<param>	用于比较的一系列值。

返回值

返回 <expr> 在 <param> 参数列表中的位置（基于 1 的索引）。如果 <expr> 不存在于参数列表中，或者 <expr> 为 NULL，则返回 0。

举例

```
SELECT k1, k7 FROM baseall WHERE k1 IN (1,2,3) ORDER BY FIELD(k1,2,1,3);
```

k1	k7
2	wangyu14
1	wangjing04
3	yuanyuan06

```
SELECT class_name FROM class_test ORDER BY FIELD(class_name, 'Suzi', 'Ben', 'Henry');
```

class_name
Suzi
Suzi
Ben
Ben
Henry

class_name
Henry

```
SELECT class_name FROM class_test ORDER BY FIELD(class_name, 'Suzi', 'Ben', 'Henry') DESC;
```

class_name
Henry
Henry
Ben
Ben
Suzi
Suzi

```
SELECT class_name FROM class_test ORDER BY FIELD(class_name, 'Suzi', 'Ben', 'Henry') NULLS FIRST;
```

class_name
NULL
Suzi
Suzi
Ben
Ben
Henry
Henry

FIND_IN_SET

find_in_set

描述

语法

INT find_in_set(VARCHAR str, VARCHAR strlist)

返回 strlist 中第一次出现 str 的位置（从1开始计数）。strlist 是用逗号分隔的字符串。如果没有找到，返回0。任意参数为 NULL，返回 NULL。

举例

```
mysql> select find_in_set("b", "a,b,c");
+-----+
| find_in_set('b', 'a,b,c') |
+-----+
|                2 |
+-----+
```

keywords

FIND_IN_SET,FIND,IN,SET

REPLACE

replace

描述

语法

VARCHAR REPLACE (VARCHAR str, VARCHAR old, VARCHAR new)

将str字符串中的old子串全部替换为new串

举例

```
mysql> select replace("http://www.baidu.com:9090", "9090", "");
+-----+
| replace('http://www.baidu.com:9090', '9090', '') |
+-----+
| http://www.baidu.com:                            |
+-----+
```

keywords

REPLACE

LEFT

left

描述

语法

VARCHAR left(VARCHAR str, INT len)

它返回具有指定长度的字符串的左边部分，长度的单位为utf8字符，此函数的另一个别名为[strleft](#)。

举例

```
mysql> select left("Hello doris",5);
+-----+
| left('Hello doris', 5) |
+-----+
| Hello                  |
+-----+
```

keywords

LEFT

RIGHT

right

描述

语法

VARCHAR right(VARCHAR str, INT len)

它返回具有指定长度的字符串的右边部分, 长度的单位为utf8字符。此函数的另一个别名为[strright](#)。

举例

```
mysql> select right("Hello doris",5);
+-----+
| right('Hello doris', 5) |
+-----+
| doris                    |
+-----+
```

keywords

RIGHT

STRLEFT

strleft

描述

语法

VARCHAR strleft(VARCHAR str, INT len)

它返回具有指定长度的字符串的左边部分，长度的单位为utf8字符，此函数的另一个别名为[left](#)。

举例

```
mysql> select strleft("Hello doris",5);
+-----+
| strleft('Hello doris', 5) |
+-----+
| Hello                      |
+-----+
```

keywords

STRLEFT

STRRIGHT

strright

描述

语法

VARCHAR strright(VARCHAR str, INT len)

它返回具有指定长度的字符串的右边部分, 长度的单位为utf8字符。此函数的另一个别名为[right](#)。

举例

```
mysql> select strright("Hello doris",5);
+-----+
| strright('Hello doris', 5) |
+-----+
| doris                        |
+-----+
```

keywords

STRRIGHT

SPLIT_PART

split_part

描述

语法

VARCHAR split_part(VARCHAR content, VARCHAR delimiter, INT field)

根据分割符拆分字符串, 返回指定的分割部分(从一或负一开始计数)。field字段支持负数, 代表从右往左倒着截取并取数。delimiter 和 field 参数需要是常量, 不支持变量。

举例

```
mysql> select split_part("hello world", " ", 1);
+-----+
| split_part('hello world', ' ', 1) |
+-----+
| hello                               |
+-----+

mysql> select split_part("hello world", " ", 2);
+-----+
| split_part('hello world', ' ', 2) |
+-----+
| world                               |
+-----+

mysql> select split_part("2019年7月8号", "月", 1);
+-----+
| split_part('2019年7月8号', '月', 1) |
+-----+
| 2019年7                             |
+-----+

mysql> select split_part("abca", "a", 1);
+-----+
| split_part('abca', 'a', 1) |
+-----+
|                             |
+-----+

mysql> select split_part("prefix_string", "_", -1);
+-----+
| split_part('prefix_string', '_', -1) |
+-----+
| string                               |
+-----+

mysql> select split_part("prefix_string", "_", -2);
+-----+
| split_part('prefix_string', '_', -2) |
+-----+
```

```

| prefix |
+-----+

mysql> select split_part("abc##123###234", "##", -1);
+-----+
| split_part('abc##123###234', '##', -1) |
+-----+
| 234 |
+-----+

mysql> select split_part("abc##123###234", "##", -2);
+-----+
| split_part('abc##123###234', '##', -2) |
+-----+
| 123# |
+-----+

```

keywords

SPLIT_PART,SPLIT,PART

SPLIT_BY_STRING

split_by_string

描述

语法

ARRAY<STRING> split_by_string(String s, String separator) 将字符串拆分为由字符串分隔的子字符串。它使用多个字符的常量字符串分隔符作为分隔符。如果字符串分隔符为空，它将字符串拆分为单个字符数组。

参数

separator — 分隔符是一个字符串，是用来分割的标志字符。类型: String

s — 需要分割的字符串。类型: String

返回值(s)

返回一个包含子字符串的数组。以下情况会返回空的子字符串:

需要分割的字符串的首尾是分隔符;

多个分隔符连续出现;

需要分割的字符串为空，而分隔符不为空。

Type: Array(String)

举例

```
select split_by_string('a1b1c1d','1');
+-----+
| split_by_string('a1b1c1d', '1') |
+-----+
| ['a', 'b', 'c', 'd']           |
+-----+

select split_by_string(',,a,b,c,',',');
+-----+
| split_by_string(',,a,b,c,', ',') |
+-----+
| ['', '', 'a', 'b', 'c', '']      |
+-----+

SELECT split_by_string(NULL,',');
+-----+
| split_by_string(NULL, ',') |
+-----+
| NULL                        |
+-----+
```

```

+-----+
select split_by_string('a,b,c,abcde','');
+-----+
| split_by_string('a,b,c,abcde','') |
+-----+
| ['a', 'b', 'c', 'abcde']          |
+-----+

select split_by_string('1,,2,3,,4,5,,abcde',',,');
+-----+
| split_by_string('1,,2,3,,4,5,,abcde',',,') |
+-----+
| ['1', '2,3', '4,5', 'abcde']              |
+-----+

select split_by_string(',,,',',,,');
+-----+
| split_by_string(',,,',',,,') |
+-----+
| ['', '', '']                 |
+-----+

select split_by_string(',,a,,b,,c,,',',,,');
+-----+
| split_by_string(',,a,,b,,c,',',,,') |
+-----+
| ['', 'a', 'b', 'c', '']              |
+-----+

```

keywords

SPLIT_BY_STRING,SPLIT

SUBSTRING_INDEX

substring_index

Name

提示

该功能自 Apache Doris 1.2 版本起支持

SUBSTRING_INDEX

描述

语法

VARCHAR substring_index(VARCHAR content, VARCHAR delimiter, INT field)

返回 content 的子字符串，在 delimiter 出现 field 次的位置按如下规则截取：

如果 field > 0，则从左边算起，返回截取位置前的子串；

如果 field < 0，则从右边算起，返回截取位置后的子串； 如果 field = 0，返回一个空串（content 不为 null），或者 Null（content = null）。

- delimiter 大小写敏感，且是多字节安全的。
- delimiter 和 field 参数需要是常量，不支持变量。

举例

```
mysql> select substring_index("hello world", " ", 1);
+-----+
| substring_index("hello world", " ", 1) |
+-----+
| hello                                   |
+-----+
mysql> select substring_index("hello world", " ", 2);
+-----+
| substring_index("hello world", " ", 2) |
+-----+
| hello world                             |
+-----+
mysql> select substring_index("hello world", " ", -1);
+-----+
| substring_index("hello world", " ", -1) |
+-----+
| world                                   |
+-----+
mysql> select substring_index("hello world", " ", -2);
+-----+
| substring_index("hello world", " ", -2) |
+-----+
```

```

+-----+
| hello world |
+-----+
mysql> select substring_index("hello world", " ", -3);
+-----+
| substring_index("hello world", " ", -3) |
+-----+
| hello world |
+-----+
mysql> select substring_index("hello world", " ", 0);
+-----+
| substring_index("hello world", " ", 0) |
+-----+
| |
+-----+

```

keywords

SUBSTRING_INDEX, SUBSTRING

MONEY_FORMAT

money_format

描述

语法

VARCHAR money_format(Number)

将数字按照货币格式输出，整数部分每隔3位用逗号分隔，小数部分保留2位

举例

```
mysql> select money_format(17014116);
+-----+
| money_format(17014116) |
+-----+
| 17,014,116.00          |
+-----+

mysql> select money_format(1123.456);
+-----+
| money_format(1123.456) |
+-----+
| 1,123.46               |
+-----+

mysql> select money_format(1123.4);
+-----+
| money_format(1123.4)   |
+-----+
| 1,123.40               |
+-----+
```

keywords

MONEY_FORMAT,MONEY,FORMAT

PARSE_URL

parse_url

描述

语法

VARCHAR parse_url(VARCHAR url, VARCHAR name)

在 url 解析出 name 对应的字段，name 可选项为：‘PROTOCOL’，‘HOST’，‘PATH’，‘REF’，‘AUTHORITY’，‘FILE’，‘USERINFO’，‘PORT’，‘QUERY’，将结果返回。

```
mysql> SELECT parse_url ('https://doris.apache.org/', 'HOST');
+-----+
| parse_url('https://doris.apache.org/', 'HOST') |
+-----+
| doris.apache.org                               |
+-----+
```

如果想获取 QUERY 中的特定参数，可使用[extract_url_parameter](#)。

keywords

PARSE URL

CONVERT_TO

描述

将指定的 VARCHAR 列的字符编码转换为目标字符集，常用于 ORDER BY 子句中对包含中文的列进行按拼音排序。当前仅支持将 <character> 转换为 'gbk' 编码。

语法

```
CONVERT_TO(<column>, <character>)
```

参数

参数	说明
<column>	需要转换字符编码的 VARCHAR 列。
<character>	目标字符集，目前仅支持 'gbk'。

返回值

返回转换编码后的 VARCHAR 值，可用于 ORDER BY 子句中按拼音顺序排序。

举例

```
SELECT * FROM class_test ORDER BY class_name;
```

class_id	class_name	student_ids
6	asd	[6]
7	qwe	[7]
8	z	[8]
2	哈	[2]
3	哦	[3]
1	啊	[1]
4	张	[4]
5	我	[5]

```
SELECT * FROM class_test ORDER BY CONVERT_TO(class_name, 'gbk');
```

class_id	class_name	student_ids
6	asd	[6]
7	qwe	[7]
8	z	[8]

	1		啊		[1]	
	2		哈		[2]	
	3		哦		[3]	
	5		我		[5]	
	4		张		[4]	
+-----+-----+-----+						

EXTRACT_URL_PARAMETER

extract_url_parameter

描述

语法

VARCHAR extract_url_parameter(VARCHAR url, VARCHAR name)

返回 URL 中“name”参数的值（如果存在）。否则为空字符串。如果有许多具有此名称的参数，则返回第一个出现的参数。此函数的工作假设参数名称在 URL 中的编码方式与在传递参数中的编码方式完全相同。

```
mysql> SELECT extract_url_parameter ("http://doris.apache.org?k1=aa&k2=bb&test=cc#999", "k2");
+-----+
| extract_url_parameter('http://doris.apache.org?k1=aa&k2=bb&test=cc#999', 'k2') |
+-----+
| bb                                         |
+-----+
```

如果想获取 URL 中的其他部分，可以使用[parse_url](#)。

keywords

EXTRACT URL PARAMETER

UUID

uuid

uuid

描述

语法

VARCHAR uuid()

返回一个随机的uuid字符串

举例

```
mysql> select uuid();
+-----+
| uuid() |
+-----+
| 29077778-fc5e-4603-8368-6b5f8fd55c24 |
+-----+
```

keywords

UUID

SPACE

space

描述

语法

VARCHAR space(Int num)

返回由num个空格组成的字符串。

举例

```
mysql> select length(space(10));
+-----+
| length(space(10)) |
+-----+
|          10      |
+-----+
1 row in set (0.01 sec)

mysql> select length(space(-10));
+-----+
| length(space(-10)) |
+-----+
|          0         |
+-----+
1 row in set (0.02 sec)
```

keywords

space

ESQUERY

描述

ESQUERY(<field>, <query_dsl>) 函数用于将无法用 SQL 表达的查询下推到 Elasticsearch 进行过滤。第一个参数 <field> 用于关联索引，第二个参数 <query_dsl> 为 Elasticsearch 的基本 Query DSL 的 JSON 表达式，JSON 需使用 {} 包裹，并且必须包含且仅包含一个根键，例如 match_phrase、geo_shape、bool 等。

语法

```
ESQUERY(<field>, <query_dsl>)
```

参数

参数	说明
<field>	需要查询的字段，用于关联 Elasticsearch 索引。
<query_dsl>	Elasticsearch Query DSL 的 JSON 表达式，需使用 {} 包裹，并且根键必须唯一（如 match_phrase、geo_shape、bool）。

返回值

返回一个布尔值，表示该文档是否匹配提供的 Elasticsearch 查询 DSL。

举例

```
-- match_phrase 查询:
SELECT * FROM es_table
WHERE ESQUERY(k4, '{
  "match_phrase": {
    "k4": "doris on es"
  }
}');
```

```
-- geo_shape 查询:
SELECT * FROM es_table
WHERE ESQUERY(k4, '{
  "geo_shape": {
    "location": {
      "shape": {
        "type": "envelope",
        "coordinates": [
          [13, 53],
          [14, 52]
        ]
      },
      "relation": "within"
    }
  }
}');
```

```
    }  
  }  
  }');  
}
```

MULTI_SEARCH_ALL_POSITIONS

multi_search_all_positions

描述

语法

ARRAY<INT> multi_search_all_positions(VARCHAR haystack, ARRAY<VARCHAR> needles)

返回一个 ARRAY，其中第 i 个元素为 needles 中第 i 个元素 needle，在字符串 haystack 中首次出现的位置。位置从1开始计数，0代表未找到该元素。**大小写敏感。**

举例

```
mysql> select multi_search_all_positions('Hello, World!', ['hello', '!', 'world']);
+-----+
| multi_search_all_positions('Hello, World!', ['hello', '!', 'world']) |
+-----+
| [0,13,0] |
+-----+

select multi_search_all_positions("Hello, World!", ['hello', '!', 'world', 'Hello', 'World']);
+-----+
| multi_search_all_positions('Hello, World!', ARRAY('hello', '!', 'world', 'Hello', 'World')) |
+-----+
| [0, 13, 0, 1, 8] |
+-----+
```

keywords

MULTI_SEARCH, SEARCH, POSITIONS

MULTI_MATCH_ANY

multi_match_any

描述

语法

TINYINT multi_match_any(VARCHAR haystack, ARRAY<VARCHAR> patterns)

检查字符串 haystack 是否与 re2 语法中的正则表达式 patterns 相匹配。如果都没有匹配的正则表达式返回 0，否则返回 1。

举例

```
mysql> select multi_match_any('Hello, World!', ['hello', '!', 'world']);
+-----+
| multi_match_any('Hello, World!', ['hello', '!', 'world']) |
+-----+
| 1 |
+-----+

mysql> select multi_match_any('abc', ['A', 'bcd']);
+-----+
| multi_match_any('abc', ['A', 'bcd']) |
+-----+
| 0 |
+-----+
```

keywords

MULTI_MATCH, MATCH, ANY

MASK

mask

描述

语法

VARCHAR mask(VARCHAR str[, VARCHAR upper[, VARCHAR lower[, VARCHAR number]])

返回 str 的掩码版本。默认情况下，大写字母转换为“X”，小写字母转换为“x”，数字转换为“n”。例如 mask(“abcd-EFGH-8765-4321”) 结果为 xxxx-XXXX-nnnn-nnnn。您可以通过提供附加参数来覆盖掩码中使用的字符：第二个参数控制大写字母的掩码字符，第三个参数控制小写字母，第四个参数控制数字。例如，mask(“abcd-EFGH-8765-4321”, “U”, “l”, “#”) 会得到 IIII-UUUU-####-####。

举例

```
// table test
+-----+
| name      |
+-----+
| abc123EFG |
| NULL      |
| 456AbCdEf |
+-----+

mysql> select mask(name) from test;
+-----+
| mask(`name`) |
+-----+
| xxxnnnXXX    |
| NULL         |
| nnnXxXxXx    |
+-----+

mysql> select mask(name, '*', '#', '$') from test;
+-----+
| mask(`name`, '*', '#', '$') |
+-----+
| ###$$*$$*   |
| NULL         |
| $$*$*##*#   |
+-----+
```

keywords

mask

MASK_FIRST_N

mask_first_n

描述

语法

VARCHAR mask_first_n(VARCHAR str[, INT n])

返回带有掩码的前 n 个值的 str 的掩码版本。大写字母转换为“X”，小写字母转换为“x”，数字转换为“n”。例如，mask_first_n(“1234-5678-8765-4321”, 4) 结果为 nnnn-5678-8765-4321。

举例

```
// table test
+-----+
| name   |
+-----+
| abc123EFG |
| NULL   |
| 456AbCdEf |
+-----+

mysql> select mask_first_n(name, 5) from test;
+-----+
| mask_first_n(`name`, 5) |
+-----+
| xxxnn3EFG               |
| NULL                    |
| nnnXxCdEf               |
+-----+
```

keywords

mask_first_n

MASK_LAST_N

mask_last_n

描述

语法

VARCHAR mask_last_n(VARCHAR str[, INT n])

返回 str 的掩码版本，其中最后 n 个字符被转换为掩码。大写字母转换为“X”，小写字母转换为“x”，数字转换为“n”。例如，mask_last_n(“1234-5678-8765-4321”, 4) 结果为 1234-5678-8765-nnnn。

举例

```
// table test
+-----+
| name      |
+-----+
| abc123EFG |
| NULL      |
| 456AbCdEf |
+-----+

mysql> select mask_last_n(name, 5) from test;
+-----+
| mask_last_n(`name`, 5) |
+-----+
| abc1nnXXX              |
| NULL                   |
| 456AxXxXx              |
+-----+
```

keywords

mask_last_n

LIKE

like

描述

语法

BOOLEAN like(VARCHAR str, VARCHAR pattern)

对字符串 **str** 进行模糊匹配，匹配上的则返回 **true**，没匹配上则返回 **false**。

like 匹配/模糊匹配，会与 **%** 和 **_** 结合使用。

百分号 **'%'** 代表零个、一个或多个字符。

下划线 **'_'** 代表单个字符。

```
'a'          // 精准匹配, 和 '=' 效果一致
'%a'         // 以a结尾的数据
'a%'         // 以a开头的数据
'%a%'        // 含有a的数据
'_a_'        // 三位且中间字符是 a的数据
'_a'         // 两位且结尾字符是 a的数据
'a_'         // 两位且开头字符是 a的数据
'a__b'       // 四位且以字符a开头、b结尾的数据
```

举例

```
// table test
+-----+
| k1    |
+-----+
| b     |
| bb    |
| bab   |
| a     |
+-----+

// 返回 k1 字符串中包含 a 的数据
mysql > select k1 from test where k1 like '%a%';
+-----+
| k1    |
+-----+
| a     |
| bab   |
+-----+

// 返回 k1 字符串中等于 a 的数据
mysql > select k1 from test where k1 like 'a';
+-----+
| k1    |
+-----+
```

| a |
+-----+

keywords

LIKE

NOT LIKE

not like

描述

语法

BOOLEAN not like(VARCHAR str, VARCHAR pattern)

对字符串 `str` 进行模糊匹配，匹配上的则返回 `false`，没匹配上则返回 `true`。

`like` 匹配/模糊匹配，会与 `%` 和 `_` 结合使用。

百分号 `'%'` 代表零个、一个或多个字符。

下划线 `'_'` 代表单个字符。

```
'a'          // 精准匹配，和 '=' 效果一致
'%a'         // 以a结尾的数据
'a%'         // 以a开头的数据
'%a%'        // 含有a的数据
'_a_'        // 三位且中间字母是 a 的数据
'_a'         // 两位且结尾字母是 a 的数据
'a_'         // 两位且开头字母是 a 的数据
'a__b'       // 四位且以字符a开头、b结尾的数据
```

举例

```
// table test
+-----+
| k1    |
+-----+
| b     |
| bb    |
| bab   |
| a     |
+-----+

// 返回 k1 字符串中不包含 a 的数据
mysql > select k1 from test where k1 not like '%a%';
+-----+
| k1    |
+-----+
| b     |
| bb    |
+-----+

// 返回 k1 字符串中不等于 a 的数据
mysql > select k1 from test where k1 not like 'a';
+-----+
| k1    |
+-----+
```

	b	
	bb	
	bab	
+	-----	+

keywords

LIKE, NOT, NOT LIKE

REGEXP

描述

对字符串 `str` 进行正则匹配，匹配上的则返回 `true`，没匹配上则返回 `false`。`pattern` 为正则表达式。

字符集匹配需要使用 Unicode 标准字符类型。例如，匹配中文请使用 `\p{Han}`。

语法

```
REGEXP(<str>, <pattern>)
```

参数

参数	描述
<str>	需要进行正则匹配的列。
<pattern>	目标模式。

返回值

一个 `BOOLEAN` 值，指示匹配是否成功

示例

让我们准备一些数据。

```
CREATE TABLE test ( k1 VARCHAR(255) ) properties("replication_num"="1")

INSERT INTO test (k1) VALUES ('billie eillish'), ('It\'s ok'), ('billie jean'), ('hello world');
```

现在进行 REGEXP

```
--- 查找 k1 字段中以 'billie' 为开头的所有数据
SELECT k1 FROM test WHERE k1 REGEXP '^billie'
-----

+-----+
| k1      |
+-----+
| billie eillish |
| billie jean   |
+-----+
2 rows in set (0.02 sec)

--- 查找 k1 字段中以 'ok' 为结尾的所有数据:
SELECT k1 FROM test WHERE k1 REGEXP 'ok$'
-----
```

```
+-----+
| k1      |
+-----+
| It's ok |
+-----+
1 row in set (0.03 sec)
```

中文字符示例

```
mysql> select regexp('这是一段中文This is a passage in English 1234567', '\\p{Han}');
+-----+
| ('这是一段中文This is a passage in English 1234567' regexp '\\p{Han}') |
+-----+
|                                                                                   1 |
+-----+
```

关键词

REGEXP

REGEXP_EXTRACT

regexp_extract

描述

语法

```
REGEXP_EXTRACT(<str>, <pattern>, <pos>)
```

对字符串 `str` 进行正则匹配，抽取符合 `pattern` 的第 `pos` 个匹配部分。需要 `pattern` 完全匹配 `str` 中的某部分，这样才能返回 `pattern` 部分中需匹配部分。如果没有匹配，返回空字符串。

字符集匹配需要使用 Unicode 标准字符类型。例如，匹配中文请使用 `\p{Han}`。

返回值

匹配 `<pattern>` 的部分。类型是 `Varchar`。

举例

```
mysql> SELECT regexp_extract('AbCdE', '([[:lower:]]+)C([[:lower:]]+)', 1);
+-----+
| regexp_extract('AbCdE', '([[:lower:]]+)C([[:lower:]]+)', 1) |
+-----+
| b                                     |
+-----+

mysql> SELECT regexp_extract('AbCdE', '([[:lower:]]+)C([[:lower:]]+)', 2);
+-----+
| regexp_extract('AbCdE', '([[:lower:]]+)C([[:lower:]]+)', 2) |
+-----+
| d                                     |
+-----+

mysql> select regexp_extract('这是一段中文This is a passage in English 1234567', '(\p{Han}+)(.+)', 2);
+-----+
| regexp_extract('这是一段中文This is a passage in English 1234567', '(\p{Han}+)(.+)', 2) |
+-----+
| This is a passage in English 1234567                                     |
+-----+
```

keywords

```
REGEXP_EXTRACT, REGEXP, EXTRACT
```

REGEXP_EXTRACT_ALL

描述

对字符串 `str` 进行正则匹配，抽取符合 `pattern` 的所有子模式匹配部分。需要 `pattern` 完全匹配 `str` 中的某部分，这样才能返回 `pattern` 部分中需匹配部分的字符串数组。如果没有匹配或者 `pattern` 没有子模式，返回空字符串。

字符集匹配需要使用 Unicode 标准字符类型。例如，匹配中文请使用 `\p{Han}`。

语法

`REGEXP_EXTRACT_ALL(<str>, <pattern>)`

返回值

String 类型。

举例

```
mysql> SELECT regexp_extract_all('AbCdE', '([[:lower:]]+)C([[:lower:]]+)');
+-----+
| regexp_extract_all('AbCdE', '([[:lower:]]+)C([[:lower:]]+)') |
+-----+
| ['b']                                                         |
+-----+

mysql> SELECT regexp_extract_all('AbCdEfCg', '([[:lower:]]+)C([[:lower:]]+)');
+-----+
| regexp_extract_all('AbCdEfCg', '([[:lower:]]+)C([[:lower:]]+)') |
+-----+
| ['b', 'f']                                                       |
+-----+

mysql> SELECT regexp_extract_all('abc=111, def=222, ghi=333', '("[^"]+"|\w+)("[^"]+"|\w+)');
+-----+
| regexp_extract_all('abc=111, def=222, ghi=333', '("[^"]+"|\w+)("[^"]+"|\w+)') |
+-----+
| ['abc', 'def', 'ghi']                                           |
+-----+

mysql> select regexp_extract_all('这是一段中文This is a passage in English 1234567', '(\p{Han}+)(.+)');
+-----+
| regexp_extract_all('这是一段中文This is a passage in English 1234567', '(\p{Han}+)(.+)') |
+-----+
| ['这是一段中文']                                               |
+-----+
```

REGEXP_REPLACE

描述

字符串 STR 进行正则匹配，将匹配 pattern 的部分替换为 repl。

- 字符集匹配需要使用 Unicode 标准字符类型。例如，匹配中文请使用 \p{Han}。

语法

```
REGEXP_REPLACE(<str>, <pattern>, <repl>)
```

参数

参数	描述
<str>	需要进行正则匹配的列。
<pattern>	目标模式。
<repl>	用于替换匹配模式的字符串。

返回值

替换之后的结果。类型是 Varchar。

举例

```
```sql mysql> SELECT regexp_replace('a b c', ' ','-'); +-----+ | regexp_replace('a b c', ' ','-')
| +-----+ | a-b-c | +-----+

mysql> SELECT regexp_replace('a b c', '(b)', '<\1>'); +-----+ | regexp_replace('a b c',
'(b)', '<\1>') | +-----+ | a c | +-----+

mysql> select regexp_replace('这是一段中文This is a passage in English 1234567', '\p{Han}+', '123'); +
-----+ | regexp_replace('这是一段中文This
is a passage in English 1234567', '+', '123') | +
-----+ | 123This is a passage in English
1234567 | +-----+
```

# REGEXP\_REPLACE\_ONE

## 描述

对字符串 STR 进行正则匹配, 将命中 pattern 的部分使用 repl 来进行替换, 仅替换第一个匹配项。

- 字符集匹配需要使用 Unicode 标准字符类型。例如，匹配中文请使用 \p{Han}。

## 语法

```
REGEXP_REPLACE_ONE(<str>, <pattern>, <repl>)
```

## 参数

参数	描述
<str>	需要进行正则匹配的列。
<pattern>	目标模式。
<repl>	用于替换匹配模式的字符串。

## 返回值

替换之后的结果，类型是 Varchar。

## 举例

```
mysql> SELECT regexp_replace_one('a b c', ' ', '-');
+-----+
| regexp_replace_one('a b c', ' ', '-') |
+-----+
| a-b c |
+-----+

mysql> SELECT regexp_replace_one('a b b', '(b)', '<\1>');
+-----+
| regexp_replace_one('a b b', '(b)', '<\1>') |
+-----+
| a b |
+-----+

mysql> select regexp_replace_one('这是一段中文This is a passage in English 1234567', '\p{Han}', '123');
+-----+
| regexp_replace_one('这是一段中文This is a passage in English 1234567', '\p{Han}', '123') |
+-----+
| 123是一段中文This is a passage in English 1234567 |
+-----+
```

# STRUCT

## struct()

### 提示

该功能自 Apache Doris 2.0 版本起支持

struct()

## 描述

## 语法

STRUCT<T1, T2, T3, ...> struct(T1, T2, T3, ...)

根据给定的值构造并返回 struct，参数可以是多列或常量

## 举例

```
mysql> select struct(1, 'a', "abc");
+-----+
| struct(1, 'a', 'abc') |
+-----+
| {1, 'a', 'abc'} |
+-----+
1 row in set (0.03 sec)

mysql> select struct(null, 1, null);
+-----+
| struct(NULL, 1, NULL) |
+-----+
| {NULL, 1, NULL} |
+-----+
1 row in set (0.02 sec)

mysql> select struct(cast('2023-03-16' as datetime));
+-----+
| struct(CAST('2023-03-16' AS DATETIME)) |
+-----+
| {2023-03-16 00:00:00} |
+-----+
1 row in set (0.01 sec)

mysql> select struct(k1, k2, null) from test_tb;
+-----+
| struct(`k1`, `k2`, NULL) |
+-----+
| {1, 'a', NULL} |
+-----+
1 row in set (0.04 sec)
```

## keywords

STRUCT, CONSTRUCTOR

# NAMED\_STRUCT

## named\_struct

named\_struct

## 描述

## 语法

STRUCT<T1, T2, T3, ...> named\_struct({VARCHAR, T1}, {VARCHAR, T2}, ...)

根据给定的字符串和值构造并返回struct

参数个数必须为非0偶数，奇数位是field的名字，必须为常量字符串，偶数位是field的值，可以是多列或常量

## 举例

```
mysql> select named_struct('f1', 1, 'f2', 'a', 'f3', "abc");
+-----+
| named_struct('f1', 1, 'f2', 'a', 'f3', 'abc') |
+-----+
| {1, 'a', 'abc'} |
+-----+
1 row in set (0.01 sec)

mysql> select named_struct('a', null, 'b', "v");
+-----+
| named_struct('a', NULL, 'b', 'v') |
+-----+
| {NULL, 'v'} |
+-----+
1 row in set (0.01 sec)

mysql> select named_struct('f1', k1, 'f2', k2, 'f3', null) from test_tb;
+-----+
| named_struct('f1', `k1`, 'f2', `k2`, 'f3', NULL) |
+-----+
| {1, 'a', NULL} |
+-----+
1 row in set (0.02 sec)
```

## keywords

NAMED, STRUCT, NAMED\_STRUCT

# STRUCT\_ELEMENT

## struct\_element

struct\_element

### 描述

返回 struct 数据列内的某一 field

### 语法

```
struct_element(struct, n/s)
```

### 参数

struct - 输入的struct列, 如果是null, 则返回null  
n - field的位置, 起始位置从1开始, 仅支持常量  
s - field的名字, 仅支持常量

### 返回值

返回指定的 field 列, 类型为任意类型

### 举例

```
mysql> select struct_element(named_struct('f1', 1, 'f2', 'a'), 'f2');
```

struct_element(named_struct('f1', 1, 'f2', 'a'), 'f2')
a

1 row in set (0.03 sec)

```
mysql> select struct_element(named_struct('f1', 1, 'f2', 'a'), 1);
```

struct_element(named_struct('f1', 1, 'f2', 'a'), 1)
1

1 row in set (0.02 sec)

```
mysql> select struct_col, struct_element(struct_col, 'f1') from test_struct;
```

struct_col	struct_element(`struct_col`, 'f1')
{1, 2, 3, 4, 5}	1
{1, 1000, 10000000, 100000000000, 100000000000}	1
{5, 4, 3, 2, 1}	5
NULL	NULL



{1, NULL, 3, NULL, 5}	1
+-----+	+-----+
9 rows in set (0.01 sec)	

## keywords

STRUCT, ELEMENT, STRUCT\_ELEMENT

# STATE

---

## 描述

返回聚合函数的中间结果，可以用于后续的聚合或者通过merge组合器获得实际计算结果，也可以直接写入agg\_state类型的表保存下来。结果的类型为agg\_state，agg\_state中的函数签名为AGGREGATE\_FUNCTION(arg... )。

## 语法

AGGREGATE\_FUNCTION\_STATE(arg...)

## 举例

```
mysql [test]>select avg_merge(t) from (select avg_union(avg_state(1)) as t from d_table group by k1)p;
+-----+
| avg_merge(`t`) |
+-----+
| 1 |
+-----+
```

## keywords

AGG\_STATE,STATE

# MERGE

---

## 描述

将聚合中间结果进行聚合并计算获得实际结果。 结果的类型与AGGREGATE\_FUNCTION一致。

## 语法

AGGREGATE\_FUNCTION\_MERGE(agg\_state)

## 举例

```
mysql [test]>select avg_merge(avg_state(1)) from d_table;
+-----+
| avg_merge(avg_state(1)) |
+-----+
| 1 |
+-----+
```

## Keywords

AGG\_STATE, MERGE

# UNION

---

## 描述

将多个聚合中间结果聚合为一个。结果的类型为agg\_state，函数签名与入参一致。

## 语法

AGGREGATE\_FUNCTION\_UNION(agg\_state)

## 举例

```
mysql [test]>select avg_merge(t) from (select avg_union(avg_state(1)) as t from d_table group by k1)p;
+-----+
| avg_merge(`t`) |
+-----+
| 1 |
+-----+
```

## keywords

AGG\_STATE, UNION

# COLLECT\_SET

## COLLECT\_SET

COLLECT\_SET

### 描述

### 语法

ARRAY<T> collect\_set(expr[,max\_size])

返回一个对expr去重后的数组。可选参数max\_size，通过设置该参数能够将结果数组的大小限制为 max\_size 个元素。得到的结果数组中不包含NULL元素，数组中的元素顺序不固定。该函数具有别名 group\_uniq\_array。### 举例

```
mysql> select k1,k2,k3 from collect_set_test order by k1;
+-----+-----+-----+
| k1 | k2 | k3 |
+-----+-----+-----+
| 1 | 2023-01-01 | hello |
| 2 | 2023-01-01 | NULL |
| 2 | 2023-01-02 | hello |
| 3 | NULL | world |
| 3 | 2023-01-02 | hello |
| 4 | 2023-01-02 | doris |
| 4 | 2023-01-03 | sql |
+-----+-----+-----+

mysql> select collect_set(k1),collect_set(k1,2) from collect_set_test;
+-----+-----+
| collect_set(`k1`) | collect_set(`k1`,2) |
+-----+-----+
| [4,3,2,1] | [1,2] |
+-----+-----+

mysql> select k1,collect_set(k2),collect_set(k3,1) from collect_set_test group by k1 order by k1;
+-----+-----+-----+
| k1 | collect_set(`k2`) | collect_set(`k3`,1) |
+-----+-----+-----+
| 1 | [2023-01-01] | [hello] |
| 2 | [2023-01-01,2023-01-02] | [hello] |
| 3 | [2023-01-02] | [world] |
| 4 | [2023-01-02,2023-01-03] | [sql] |
+-----+-----+-----+
```

### keywords

COLLECT\_SET, GROUP\_UNIQ\_ARRAY, COLLECT\_LIST, ARRAY

# MIN

---

## MIN

### 描述

### 语法

MIN(expr)

返回expr表达式的最小值

### 举例

```
MySQL > select min(scan_rows) from log_statistic group by datetime;
+-----+
| min(`scan_rows`) |
+-----+
| 0 |
+-----+
```

### keywords

MIN

# STDDEV\_SAMP

---

## STDDEV\_SAMP

### 描述

### 语法

STDDEV\_SAMP(expr)

返回expr表达式的样本标准差

### 举例

```
MySQL > select stddev_samp(scan_rows) from log_statistic group by datetime;
+-----+
| stddev_samp(`scan_rows`) |
+-----+
| 2.372044195280762 |
+-----+
```

### keywords

STDDEV\_SAMP,STDDEV,SAMP

# AVG

---

## AVG

### 描述

### 语法

AVG([DISTINCT] expr)

用于返回选中字段的平均值

可选字段DISTINCT参数可以用来返回去重平均值

### 举例

```
mysql> SELECT datetime, AVG(cost_time) FROM log_statistic group by datetime;
+-----+-----+
| datetime | avg(`cost_time`) |
+-----+-----+
| 2019-07-03 21:01:20 | 25.827794561933533 |
+-----+-----+

mysql> SELECT datetime, AVG(distinct cost_time) FROM log_statistic group by datetime;
+-----+-----+
| datetime | avg(DISTINCT `cost_time`) |
+-----+-----+
| 2019-07-04 02:23:24 | 20.666666666666668 |
+-----+-----+
```

### keywords

AVG



# AVG\_WEIGHTED

---

## AVG\_WEIGHTED

### 描述

### 语法

`double avg_weighted(x, weight)`

计算加权算术平均值, 即返回结果为: 所有对应数值和权重的乘积相累加, 除总的权重和。如果所有的权重和等于0, 将返回NaN。

### 举例

```
mysql> select avg_weighted(k2,k1) from baseall;
+-----+
| avg_weighted(`k2`, `k1`) |
+-----+
| 495.675 |
+-----+
1 row in set (0.02 sec)
```

### keywords

AVG\_WEIGHTED

# PERCENTILE

## 描述

## 语法

PERCENTILE(expr, DOUBLE p)

计算精确的百分位数，适用于小数据量。先对指定列降序排列，然后取精确的第 p 位百分数。p 的值介于 0 到 1 之间 如果 p 不指向精确的位置，则返回所指位置两侧相邻数值在 p 所指位置上产生的线性插值。注意这不是两数字的平均数。

参数说明 expr: 必填。值为整数（最大为 bigint）类型的列。 p: 常量，必填。需要精确的百分位数。取值为 [0.0,1.0]。

## 举例

```
MySQL > select `table`, percentile(cost_time,0.99) from log_statistic group by `table`;
```

table	percentile(`cost_time`, 0.99)
test	54.22

```
MySQL > select percentile(NULL,0.3) from table1;
```

percentile(NULL, 0.3)
NULL

## Keywords

PERCENTILE

# PERCENTILE\_ARRAY

---

## PERCENTILE\_ARRAY

### 描述

### 语法

ARRAY\_DOUBLE PERCENTILE\_ARRAY(BIGINT, ARRAY\_DOUBLE p)

计算精确的百分位数，适用于小数据量。先对指定列降序排列，然后取精确的第 p 位百分数。返回值为依次取数组p中指定的百分数组成的结果。参数说明: expr: 必填。值为整数（最大为bigint）类型的列。 p: 需要精确的百分位数, 由常量组成的数组, 取值为 [0.0,1.0]。

### 举例

```
mysql> select percentile_array(k1,[0.3,0.5,0.9]) from baseall;
+-----+
| percentile_array(`k1`, ARRAY(0.3, 0.5, 0.9)) |
+-----+
| [5.2, 8, 13.6] |
+-----+
1 row in set (0.02 sec)
```

### keywords

PERCENTILE\_ARRAY

# HLL\_UNION\_AGG

---

## HLL\_UNION\_AGG

### 描述

### 语法

HLL\_UNION\_AGG(hll)

HLL是基于HyperLogLog算法的工程实现，用于保存HyperLogLog计算过程的中间结果

它只能作为表的value列类型、通过聚合来不断的减少数据量，以此来实现加快查询的目的

基于它得到的是一个估算结果，误差大概在1%左右，hll列是通过其它列或者导入数据里面的数据生成的

导入的时候通过hll\_hash函数来指定数据中哪一列用于生成hll列，它常用于替代count distinct，通过结合rollup在业务上用于快速计算uv等

### 举例

```
MySQL > select HLL_UNION_AGG(uv_set) from test_uv;;
+-----+
| HLL_UNION_AGG(`uv_set`) |
+-----+
| 17721 |
+-----+
```

### keywords

HLL\_UNION\_AGG,HLL,UNION,AGG

# TOPN

## TOPN

### 描述

### 语法

`topn(expr, INT top_num[, INT space_expand_rate])`

该topn函数使用Space-Saving算法计算expr中的top\_num个频繁项，结果为频繁项及其出现次数，该结果为近似值

space\_expand\_rate参数是可选项，该值用来设置Space-Saving算法中使用的counter个数

```
counter numbers = top_num * space_expand_rate
```

space\_expand\_rate的值越大，结果越准确，默认值为50

### 举例

```
MySQL [test]> select topn(keyword,10) from keyword_table where date>= '2020-06-01' and date <= '2020-06-19' ;
+-----+
+
| topn(`keyword`, 10)
|
+-----+
+
| a:157, b:138, c:133, d:133, e:131, f:127, g:124, h:122, i:117, k:117
|
+-----+
+

MySQL [test]> select date,topn(keyword,10,100) from keyword_table where date>= '2020-06-17' and date <=
'2020-06-19' group by date;
+-----+-----+
+
| date | topn(`keyword`, 10, 100)
|
+-----+-----+
+
| 2020-06-19 | a:11, b:8, c:8, d:7, e:7, f:7, g:7, h:7, i:7, j:7
|
| 2020-06-18 | a:10, b:8, c:7, f:7, g:7, i:7, k:7, l:7, m:6, d:6
|
| 2020-06-17 | a:9, b:8, c:8, j:8, d:7, e:7, f:7, h:7, i:7, k:7
|
+-----+-----+
+
```

## keywords

TOPN

# TOPN\_ARRAY

---

## TOPN\_ARRAY

### 描述

### 语法

ARRAY<T> topn\_array(expr, INT top\_num[, INT space\_expand\_rate])

该topn\_array函数使用Space-Saving算法计算expr中的top\_num个频繁项，返回由前top\_num个组成的数组，该结果为近似值

space\_expand\_rate参数是可选项，该值用来设置Space-Saving算法中使用的counter个数

```
counter numbers = top_num * space_expand_rate
```

space\_expand\_rate的值越大，结果越准确，默认值为50

### 举例

```
mysql> select topn_array(k3,3) from baseall;
+-----+
| topn_array(`k3`, 3) |
+-----+
| [3021, 2147483647, 5014] |
+-----+
1 row in set (0.02 sec)

mysql> select topn_array(k3,3,100) from baseall;
+-----+
| topn_array(`k3`, 3, 100) |
+-----+
| [3021, 2147483647, 5014] |
+-----+
1 row in set (0.02 sec)
```

### keywords

TOPN, TOPN\_ARRAY

# TOPN\_WEIGHTED

---

## TOPN\_WEIGHTED

### 描述

### 语法

ARRAY<T> topn\_weighted(expr, BigInt weight, INT top\_num[, INT space\_expand\_rate])

该topn\_weighted函数使用Space-Saving算法计算，取expr中权重和为前top\_num个数组成的结果，该结果为近似值

space\_expand\_rate参数是可选项，该值用来设置Space-Saving算法中使用的counter个数

```
counter numbers = top_num * space_expand_rate
```

space\_expand\_rate的值越大，结果越准确，默认值为50

### 举例

```
mysql> select topn_weighted(k5,k1,3) from baseall;
+-----+
| topn_weighted(`k5`, `k1`, 3) |
+-----+
| [0, 243.325, 100.001] |
+-----+
1 row in set (0.02 sec)

mysql> select topn_weighted(k5,k1,3,100) from baseall;
+-----+
| topn_weighted(`k5`, `k1`, 3, 100) |
+-----+
| [0, 243.325, 100.001] |
+-----+
1 row in set (0.02 sec)
```

### keywords

TOPN, TOPN\_WEIGHTED



# COUNT

---

## COUNT

### 描述

### 语法

COUNT([DISTINCT] expr)

用于返回满足要求的行的数目

### 举例

```
MySQL > select count(*) from log_statistic group by datetime;
+-----+
| count(*) |
+-----+
| 28515903 |
+-----+

MySQL > select count(datetime) from log_statistic group by datetime;
+-----+
| count(`datetime`) |
+-----+
| 28521682 |
+-----+

MySQL > select count(distinct datetime) from log_statistic group by datetime;
+-----+
| count(DISTINCT `datetime`) |
+-----+
| 71045 |
+-----+
```

### keywords

COUNT

# SUM

---

## SUM

### 描述

### 语法

SUM(expr)

用于返回选中字段所有值的和

### 举例

```
MySQL > select sum(scan_rows) from log_statistic group by datetime;
+-----+
| sum(`scan_rows`) |
+-----+
| 8217360135 |
+-----+
```

### keywords

SUM

# MAX\_BY

## MAX\_BY

### 描述

### 语法

MAX\_BY(expr1, expr2)

返回与 expr2 的最大值关联的 expr1 的值。

### 举例

```
MySQL > select * from tbl;
+-----+-----+-----+-----+
| k1 | k2 | k3 | k4 |
+-----+-----+-----+-----+
| 0 | 3 | 2 | 100 |
| 1 | 2 | 3 | 4 |
| 4 | 3 | 2 | 1 |
| 3 | 4 | 2 | 1 |
+-----+-----+-----+-----+

MySQL > select max_by(k1, k4) from tbl;
+-----+
| max_by(`k1`, `k4`) |
+-----+
| 0 |
+-----+
```

### keywords

MAX\_BY

# BITMAP\_UNION

## BITMAP\_UNION

### 描述

### 举例

#### Create table

建表时需要使用聚合模型，数据类型是 bitmap，聚合函数是 bitmap\_union

```
CREATE TABLE `pv_bitmap` (
 `dt` int(11) NULL COMMENT "",
 `page` varchar(10) NULL COMMENT "",
 `user_id` bitmap BITMAP_UNION NULL COMMENT ""
) ENGINE=OLAP
AGGREGATE KEY(`dt`, `page`)
COMMENT "OLAP"
DISTRIBUTED BY HASH(`dt`) BUCKETS 2;
```

注：当数据量很大时，最好为高频率的 bitmap\_union 查询建立对应的 rollup 表

```
ALTER TABLE pv_bitmap ADD ROLLUP pv (page, user_id);
```

#### Data Load

T0\_BITMAP(expr) : 将 0 ~ 18446744073709551615 的 unsigned bigint 转为 bitmap

BITMAP\_EMPTY(): 生成空 bitmap 列，用于 insert 或导入的时填充默认值

BITMAP\_HASH(expr)或者BITMAP\_HASH64(expr): 将任意类型的列通过 Hash 的方式转为 bitmap

#### Stream Load

```
cat data | curl --location-trusted -u user:passwd -T - -H "columns: dt,page,user_id,
user_id=to_bitmap(user_id)" http://host:8410/api/test/testDb/_stream_load
```

```
cat data | curl --location-trusted -u user:passwd -T - -H "columns: dt,page,user_id,
user_id=bitmap_hash(user_id)" http://host:8410/api/test/testDb/_stream_load
```

```
cat data | curl --location-trusted -u user:passwd -T - -H "columns: dt,page,user_id, user_id=bitmap_empty()"
http://host:8410/api/test/testDb/_stream_load
```

## Insert Into

id2 的列类型是 bitmap

```
insert into bitmap_table1 select id, id2 from bitmap_table2;
```

id2 的列类型是 bitmap

```
INSERT INTO bitmap_table1 (id, id2) VALUES (1001, to_bitmap(1000)), (1001, to_bitmap(2000));
```

id2 的列类型是 bitmap

```
insert into bitmap_table1 select id, bitmap_union(id2) from bitmap_table2 group by id;
```

id2 的列类型是 int

```
insert into bitmap_table1 select id, to_bitmap(id2) from table;
```

id2 的列类型是 String

```
insert into bitmap_table1 select id, bitmap_hash(id_string) from table;
```

## Data Query

### 语法

**BITMAP\_UNION(expr)** : 计算输入 Bitmap 的并集，返回新的bitmap

**BITMAP\_UNION\_COUNT(expr)**: 计算输入 Bitmap 的并集，返回其基数，和 **BITMAP\_COUNT(BITMAP\_UNION(expr))** 等价。目前推荐优先使用 **BITMAP\_UNION\_COUNT**，其性能优于 **BITMAP\_COUNT(BITMAP\_UNION(expr))**

**BITMAP\_UNION\_INT(expr)** : 计算 TINYINT, SMALLINT 和 INT 类型的列中不同值的个数，返回值和 **COUNT(DISTINCT expr)** 相同

**INTERSECT\_COUNT(bitmap\_column\_to\_count, filter\_column, filter\_values ...)** : 计算满足 filter\_column 过滤条件的多个 bitmap 的交集的基数值。bitmap\_column\_to\_count 是 bitmap 类型的列，filter\_column 是变化的维度列，filter\_values 是维度取值列表

### 举例

下面的 SQL 以上面的 pv\_bitmap table 为例：

计算 user\_id 的去重值：

```
select bitmap_union_count(user_id) from pv_bitmap;
```

```
select bitmap_count(bitmap_union(user_id)) from pv_bitmap;
```

计算 id 的去重值:

```
select bitmap_union_int(id) from pv_bitmap;
```

计算 user\_id 的留存:

```
select intersect_count(user_id, page, 'meituan') as meituan_uv,
intersect_count(user_id, page, 'waimai') as waimai_uv,
intersect_count(user_id, page, 'meituan', 'waimai') as retention //在 'meituan' 和 'waimai' 两个页面都出现的用户数
from pv_bitmap
where page in ('meituan', 'waimai');
```

## keywords

BITMAP,BITMAP\_COUNT,BITMAP\_EMPTY,BITMAP\_UNION,BITMAP\_UNION\_INT,TO\_BITMAP,BITMAP\_UNION\_COUNT,INTERSECT\_COUNT

# GROUP\_BITMAP\_XOR

---

## group\_bitmap\_xor

### 描述

### 语法

BITMAP GROUP\_BITMAP\_XOR(expr)

对expr进行 xor 计算, 返回新的bitmap。

### 举例

```
mysql> select page, bitmap_to_string(user_id) from pv_bitmap;
+-----+-----+
| page | bitmap_to_string(`user_id`) |
+-----+-----+
| m | 4,7,8 |
| m | 1,3,6,15 |
| m | 4,7 |
+-----+-----+

mysql> select page, bitmap_to_string(group_bitmap_xor(user_id)) from pv_bitmap group by page;
+-----+-----+
| page | bitmap_to_string(group_bitmap_xor(`user_id`)) |
+-----+-----+
| m | 1,3,6,8,15 |
+-----+-----+
```

### keywords

GROUP\_BITMAP\_XOR,BITMAP

# GROUP\_BIT\_AND

---

## group\_bit\_and

### 描述

### 语法

expr GROUP\_BIT\_AND(expr)

对expr进行 and 计算, 返回新的expr 支持所有INT类型

### 举例

```
mysql> select * from group_bit;
+-----+
| value |
+-----+
| 3 |
| 1 |
| 2 |
| 4 |
+-----+
4 rows in set (0.02 sec)

mysql> select group_bit_and(value) from group_bit;
+-----+
| group_bit_and(`value`) |
+-----+
| 0 |
+-----+
```

### keywords

GROUP\_BIT\_AND,BIT



# GROUP\_BIT\_OR

---

## group\_bit\_or

### 描述

### 语法

expr GROUP\_BIT\_OR(expr)

对expr进行 or 计算, 返回新的expr 支持所有INT类型

### 举例

```
mysql> select * from group_bit;
+-----+
| value |
+-----+
| 3 |
| 1 |
| 2 |
| 4 |
+-----+
4 rows in set (0.02 sec)

mysql> select group_bit_or(value) from group_bit;
+-----+
| group_bit_or(`value`) |
+-----+
| 7 |
+-----+
```

### keywords

GROUP\_BIT\_OR,BIT

# GROUP\_BIT\_XOR

---

## group\_bit\_xor

### 描述

### 语法

expr GROUP\_BIT\_XOR(expr)

对expr进行 xor 计算, 返回新的expr 支持所有INT类型

### 举例

```
mysql> select * from group_bit;
+-----+
| value |
+-----+
| 3 |
| 1 |
| 2 |
| 4 |
+-----+
4 rows in set (0.02 sec)

mysql> select group_bit_xor(value) from group_bit;
+-----+
| group_bit_xor(`value`) |
+-----+
| 4 |
+-----+
```

### keywords

GROUP\_BIT\_XOR,BIT

# PERCENTILE\_APPROX

## PERCENTILE\_APPROX

### 描述

### 语法

PERCENTILE\_APPROX(expr, DOUBLE p[, DOUBLE compression])

返回第p个百分位点的近似值，p的值介于0到1之间

compression参数是可选项，可设置范围是[2048, 10000]，值越大，精度越高，内存消耗越大，计算耗时越长。  
compression参数未指定或设置的值在[2048, 10000]范围外，以10000的默认值运行

该函数使用固定大小的内存，因此对于低基数的列可以使用更少的内存，可用于计算tp99等统计值

### 举例

```
MySQL > select `table`, percentile_approx(cost_time,0.99) from log_statis group by `table`;
```

table	percentile_approx(`cost_time`, 0.99)
test	54.22

```
MySQL > select `table`, percentile_approx(cost_time,0.99, 4096) from log_statis group by `table`;
```

table	percentile_approx(`cost_time`, 0.99, 4096.0)
test	54.21

### keywords

PERCENTILE\_APPROX,PERCENTILE,APPROX

# STDDEV,STDDEV\_POP

---

## STDDEV,STDDEV\_POP

### 描述

### 语法

STDDEV(expr)

返回expr表达式的标准差

### 举例

```
MySQL > select stddev(scan_rows) from log_statistic group by datetime;
+-----+
| stddev(`scan_rows`) |
+-----+
| 2.3736656687790934 |
+-----+

MySQL > select stddev_pop(scan_rows) from log_statistic group by datetime;
+-----+
| stddev_pop(`scan_rows`) |
+-----+
| 2.3722760595994914 |
+-----+
```

### keywords

STDDEV,STDDEV\_POP,POP

# GROUP\_CONCAT

## group\_concat

### 描述

### 语法

```
VARCHAR GROUP_CONCAT([DISTINCT] VARCHAR str[, VARCHAR sep] [ORDER BY { col_name | expr}
[ASC | DESC]])
```

该函数是类似于 sum() 的聚合函数，group\_concat 将结果集中的多行结果连接成一个字符串。第二个参数 sep 为字符串之间的连接符号，该参数可以省略。该函数通常需要和 group by 语句一起使用。

支持Order By进行多行结果的排序，排序和聚合列可不同。

group\_concat暂不支持distinct和order by一起用。

### 举例

```
mysql> select value from test;
+-----+
| value |
+-----+
| a |
| b |
| c |
| c |
+-----+

mysql> select GROUP_CONCAT(value) from test;
+-----+
| GROUP_CONCAT(`value`) |
+-----+
| a, b, c, c |
+-----+

mysql> select GROUP_CONCAT(DISTINCT value) from test;
+-----+
| GROUP_CONCAT(`value`) |
+-----+
| a, b, c |
+-----+

mysql> select GROUP_CONCAT(value, " ") from test;
+-----+
| GROUP_CONCAT(`value`, ' ') |
+-----+
| a b c c |
+-----+

mysql> select GROUP_CONCAT(value, NULL) from test;
```

```
+-----+
| GROUP_CONCAT(`value`, NULL) |
+-----+
| NULL |
+-----+
```

## keywords

GROUP\_CONCAT, GROUP, CONCAT

# COLLECT\_LIST

## COLLECT\_LIST

### 描述

### 语法

```
ARRAY<T> collect_list(expr[,max_size])
```

返回一个包含 expr 中所有元素(不包括NULL)的数组，可选参数max\_size，通过设置该参数能够将结果数组的大小限制为 max\_size 个元素。得到的结果数组中不包含NULL元素，数组中的元素顺序不固定。该函数具有别名 group\_array。

### 举例

```
mysql> select k1,k2,k3 from collect_list_test order by k1;
+-----+-----+-----+
| k1 | k2 | k3 |
+-----+-----+-----+
| 1 | 2023-01-01 | hello |
| 2 | 2023-01-02 | NULL |
| 2 | 2023-01-02 | hello |
| 3 | NULL | world |
| 3 | 2023-01-02 | hello |
| 4 | 2023-01-02 | sql |
| 4 | 2023-01-03 | sql |
+-----+-----+-----+

mysql> select collect_list(k1),collect_list(k1,3) from collect_list_test;
+-----+-----+
| collect_list(`k1`) | collect_list(`k1`,3) |
+-----+-----+
| [1,2,2,3,3,4,4] | [1,2,2] |
+-----+-----+

mysql> select k1,collect_list(k2),collect_list(k3,1) from collect_list_test group by k1 order by k1;
+-----+-----+-----+
| k1 | collect_list(`k2`) | collect_list(`k3`,1) |
+-----+-----+-----+
| 1 | [2023-01-01] | [hello] |
| 2 | [2023-01-02,2023-01-02] | [hello] |
| 3 | [2023-01-02] | [world] |
| 4 | [2023-01-02,2023-01-03] | [sql] |
+-----+-----+-----+
```

### keywords

COLLECT\_LIST, GROUP\_ARRAY, COLLECT\_SET, ARRAY

# MIN\_BY

## MIN\_BY

### 描述

### 语法

MIN\_BY(expr1, expr2)

返回与 expr2 的最小值关联的 expr1 的值。

### 举例

```
MySQL > select * from tbl;
+-----+-----+-----+-----+
| k1 | k2 | k3 | k4 |
+-----+-----+-----+-----+
| 0 | 3 | 2 | 100 |
| 1 | 2 | 3 | 4 |
| 4 | 3 | 2 | 1 |
| 3 | 4 | 2 | 1 |
+-----+-----+-----+-----+

MySQL > select min_by(k1, k4) from tbl;
+-----+
| min_by(`k1`, `k4`) |
+-----+
| 4 |
+-----+
```

### keywords

MIN\_BY



# MAX

---

## MAX

### 描述

### 语法

MAX(expr)

返回expr表达式的最大值

### 举例

```
MySQL > select max(scan_rows) from log_statistic group by datetime;
+-----+
| max(`scan_rows`) |
+-----+
| 4671587 |
+-----+
```

### keywords

MAX

# ANY\_VALUE

---

## ANY\_VALUE

ANY\_VALUE

### 描述

### 语法

ANY\_VALUE(expr)

如果expr中存在非 NULL 值，返回任意非 NULL 值，否则返回 NULL。

别名函数： ANY(expr)

### 举例

```
mysql> select id, any_value(name) from cost2 group by id;
+-----+-----+
| id | any_value(`name`) |
+-----+-----+
| 3 | jack |
| 2 | jack |
+-----+-----+
```

### keywords

ANY\_VALUE, ANY

# VAR\_SAMP,VARIANCE\_SAMP

---

## VAR\_SAMP,VARIANCE\_SAMP

### 描述

### 语法

VAR\_SAMP(expr)

返回expr表达式的样本方差

### 举例

```
MySQL > select var_samp(scan_rows) from log_statistic group by datetime;
+-----+
| var_samp(`scan_rows`) |
+-----+
| 5.6227132145741789 |
+-----+
```

### keywords

VAR\_SAMP,VARIANCE\_SAMP,VAR,SAMP,VARIANCE

# APPROX\_COUNT\_DISTINCT

---

## 描述

## 语法

APPROX\_COUNT\_DISTINCT(expr)

返回类似于 COUNT(DISTINCT col) 结果的近似值聚合函数。

它基于 HyperLogLog 算法实现，使用固定大小的内存估算列基数。该算法基于尾部零分布假设进行计算，具体精确程度取决于数据分布。基于 Doris 使用的固定桶大小，该算法相对标准误差为 0.8125%

更详细具体的分析，详见[相关论文](#)

## 举例

```
MySQL > select approx_count_distinct(query_id) from log_statistic group by datetime;
+-----+
| approx_count_distinct(`query_id`) |
+-----+
| 17721 |
+-----+
```

## Keywords

APPROX\_COUNT\_DISTINCT

# VARIANCE,VAR\_POP,VARIANCE\_POP

---

## VARIANCE,VAR\_POP,VARIANCE\_POP

### 描述

### 语法

VARIANCE(expr)

返回expr表达式的方差

### 举例

```
MySQL > select variance(scan_rows) from log_statistic group by datetime;
+-----+
| variance(`scan_rows`) |
+-----+
| 5.6183332881176211 |
+-----+

MySQL > select var_pop(scan_rows) from log_statistic group by datetime;
+-----+
| var_pop(`scan_rows`) |
+-----+
| 5.6230744719006163 |
+-----+
```

### keywords

VARIANCE,VAR\_POP,VARIANCE\_POP,VAR,POP

# RETENTION

---

## RETENTION

RETENTION

### 描述

### 语法

```
retention(event1, event2, ... , eventN);
```

留存函数将一组条件作为参数，类型为1到32个UInt8类型的参数，用来表示事件是否满足特定条件。任何条件都可以指定为参数。

除了第一个以外，条件成对适用：如果第一个和第二个是真的，第二个结果将是真的，如果第一个和第三个是真的，第三个结果将是真的，等等。

简单来讲，返回值数组第1位表示event1的真假，第二位表示event1真假与event2真假相与，第三位表示event1真假与event3真假相与，等等。如果event1为假，则返回全是0的数组。

### 参数

event — 返回UInt8结果（1或0）的表达式。

### 返回值

由1和0组成的最大长度为32位的数组，最终输出数组的长度与输入参数长度相同。

1 — 条件满足。

0 — 条件不满足

### 举例

```
DROP TABLE IF EXISTS retention_test;

CREATE TABLE retention_test(
 `uid` int COMMENT 'user id',
 `date` datetime COMMENT 'date time'
)
DUPLICATE KEY(uid)
DISTRIBUTED BY HASH(uid) BUCKETS 3
PROPERTIES (
 "replication_num" = "1"
);

INSERT into retention_test (uid, date) values (0, '2022-10-12'),
 (0, '2022-10-13'),
 (0, '2022-10-14'),
```

```
(1, '2022-10-12'),
(1, '2022-10-13'),
(2, '2022-10-12');
```

```
SELECT * from retention_test;
```

uid	date
0	2022-10-14 00:00:00
0	2022-10-13 00:00:00
0	2022-10-12 00:00:00
1	2022-10-13 00:00:00
1	2022-10-12 00:00:00
2	2022-10-12 00:00:00

```
SELECT
 uid,
 retention(date = '2022-10-12')
 AS r
 FROM retention_test
 GROUP BY uid
 ORDER BY uid ASC;
```

uid	r
0	[1]
1	[1]
2	[1]

```
SELECT
 uid,
 retention(date = '2022-10-12', date = '2022-10-13')
 AS r
 FROM retention_test
 GROUP BY uid
 ORDER BY uid ASC;
```

uid	r
0	[1, 1]
1	[1, 1]
2	[1, 0]

```
SELECT
 uid,
 retention(date = '2022-10-12', date = '2022-10-13', date = '2022-10-14')
 AS r
 FROM retention_test
 GROUP BY uid
 ORDER BY uid ASC;
```

uid	r
0	[1, 1, 1]
1	[1, 1, 0]
2	[1, 0, 0]

## keywords

RETENTION



# SEQUENCE\_MATCH

---

## SEQUENCE-MATCH

### 描述

### 语法

```
sequence_match(pattern, timestamp, cond1, cond2, ...);
```

检查序列是否包含与模式匹配的事件链。

### 警告!

在同一秒钟发生的事件可能以未定义的顺序排列在序列中，会影响最终结果。

### 参数

pattern — 模式字符串。

### 模式语法

(?N) — 在位置N匹配条件参数。条件在编号 [1, 32] 范围。例如, (?1) 匹配传递给 cond1 参数。

. \* — 匹配任何事件的数字。不需要条件参数来匹配这个模式。

(?t operator value) — 分开两个事件的时间。单位为秒。

t表示为两个时间的差值，单位为秒。例如： (?1)(?t>1800)(?2) 匹配彼此发生超过1800秒的事件， (?1)(?t>10000)(?2)匹配彼此发生超过10000秒的事件。 这些事件之间可以存在任意数量的任何事件。 您可以使用 >=, >, <, <=, == 运算符。

timestamp — 包含时间的列。典型的时间类型是： Date 和 DateTime。也可以使用任何支持的 UInt 数据类型。

cond1, cond2 — 事件链的约束条件。数据类型是： UInt8。最多可以传递32个条件参数。该函数只考虑这些条件中描述的事件。如果序列包含未在条件中描述的数据，则函数将跳过这些数据。

### 返回值

1, 如果模式匹配。

0, 如果模式不匹配。

### 举例

#### 匹配例子

```

DROP TABLE IF EXISTS sequence_match_test1;

CREATE TABLE sequence_match_test1(
 `uid` int COMMENT 'user id',
 `date` datetime COMMENT 'date time',
 `number` int NULL COMMENT 'number'
)
DUPLICATE KEY(uid)
DISTRIBUTED BY HASH(uid) BUCKETS 3
PROPERTIES (
 "replication_num" = "1"
);

INSERT INTO sequence_match_test1(uid, date, number) values (1, '2022-11-02 10:41:00', 1),
(2, '2022-11-02 13:28:02', 2),
(3, '2022-11-02 16:15:01', 1),
(4, '2022-11-02 19:05:04', 2),
(5, '2022-11-02 20:08:44', 3);

SELECT * FROM sequence_match_test1 ORDER BY date;

```

uid	date	number
1	2022-11-02 10:41:00	1
2	2022-11-02 13:28:02	2
3	2022-11-02 16:15:01	1
4	2022-11-02 19:05:04	2
5	2022-11-02 20:08:44	3

```
SELECT sequence_match('(?1)(?2)', date, number = 1, number = 3) FROM sequence_match_test1;
```

sequence_match('( ?1 )( ?2 )', `date`, `number` = 1, `number` = 3)
1

```
SELECT sequence_match('(?1)(?2)', date, number = 1, number = 2) FROM sequence_match_test1;
```

sequence_match('( ?1 )( ?2 )', `date`, `number` = 1, `number` = 2)
1

```
SELECT sequence_match('(?1)(?t>=3600)(?2)', date, number = 1, number = 2) FROM sequence_match_test1;
```

sequence_match('( ?1 )( ?t>=3600 )( ?2 )', `date`, `number` = 1, `number` = 2)
1

## 不匹配例子

```

DROP TABLE IF EXISTS sequence_match_test2;

CREATE TABLE sequence_match_test2(
 `uid` int COMMENT 'user id',
 `date` datetime COMMENT 'date time',
 `number` int NULL COMMENT 'number'
)

```

```

)
 DUPLICATE KEY(uid)
 DISTRIBUTED BY HASH(uid) BUCKETS 3
 PROPERTIES (
 "replication_num" = "1"
);

INSERT INTO sequence_match_test2(uid, date, number) values (1, '2022-11-02 10:41:00', 1),
 (2, '2022-11-02 11:41:00', 7),
 (3, '2022-11-02 16:15:01', 3),
 (4, '2022-11-02 19:05:04', 4),
 (5, '2022-11-02 21:24:12', 5);

```

```
SELECT * FROM sequence_match_test2 ORDER BY date;
```

uid	date	number
1	2022-11-02 10:41:00	1
2	2022-11-02 11:41:00	7
3	2022-11-02 16:15:01	3
4	2022-11-02 19:05:04	4
5	2022-11-02 21:24:12	5

```
SELECT sequence_match('(?(1)(?2)', date, number = 1, number = 2) FROM sequence_match_test2;
```

sequence_match('(?(1)(?2)', `date`, `number` = 1, `number` = 2)
0

```
SELECT sequence_match('(?(1)(?2).*', date, number = 1, number = 2) FROM sequence_match_test2;
```

sequence_match('(?(1)(?2).*', `date`, `number` = 1, `number` = 2)
0

```
SELECT sequence_match('(?(1)(?t>3600)(?2)', date, number = 1, number = 7) FROM sequence_match_test2;
```

sequence_match('(?(1)(?t>3600)(?2)', `date`, `number` = 1, `number` = 7)
0

## 特殊例子

```
DROP TABLE IF EXISTS sequence_match_test3;
```

```

CREATE TABLE sequence_match_test3(
 `uid` int COMMENT 'user id',
 `date` datetime COMMENT 'date time',
 `number` int NULL COMMENT 'number'
)
DUPLICATE KEY(uid)
DISTRIBUTED BY HASH(uid) BUCKETS 3
PROPERTIES (
 "replication_num" = "1"
);

```

```
INSERT INTO sequence_match_test3(uid, date, number) values (1, '2022-11-02 10:41:00', 1),
(2, '2022-11-02 11:41:00', 7),
(3, '2022-11-02 16:15:01', 3),
(4, '2022-11-02 19:05:04', 4),
(5, '2022-11-02 21:24:12', 5);
```

```
SELECT * FROM sequence_match_test3 ORDER BY date;
```

uid	date	number
1	2022-11-02 10:41:00	1
2	2022-11-02 11:41:00	7
3	2022-11-02 16:15:01	3
4	2022-11-02 19:05:04	4
5	2022-11-02 21:24:12	5

Perform the query:

```
SELECT sequence_match('(?1)(?2)', date, number = 1, number = 5) FROM sequence_match_test3;
```

sequence_match('( ?1)( ?2)', `date`, `number` = 1, `number` = 5)
1

上面为一个非常简单的匹配例子，该函数找到了数字5跟随数字1的事件链。它跳过了它们之间的数字7，3，4，因为该数字没有被描述为事件。如果我们想在搜索示例中给出的事件链时考虑这个数字，我们应该为它创建一个条件。

现在，考虑如下执行语句：

```
SELECT sequence_match('(?1)(?2)', date, number = 1, number = 5, number = 4) FROM sequence_match_test3;
```

sequence_match('( ?1)( ?2)', `date`, `number` = 1, `number` = 5, `number` = 4)
0

您可能对这个结果有些许疑惑，在这种情况下，函数找不到与模式匹配的事件链，因为数字4的事件发生在1和5之间。如果在相同的情况下，我们检查了数字6的条件，则序列将与模式匹配。

```
SELECT sequence_match('(?1)(?2)', date, number = 1, number = 5, number = 6) FROM sequence_match_test3;
```

sequence_match('( ?1)( ?2)', `date`, `number` = 1, `number` = 5, `number` = 6)
1

## keywords

SEQUENCE\_MATCH

# SEQUENCE\_COUNT

## SEQUENCE-COUNT

### 描述

### 语法

```
sequence_count(pattern, timestamp, cond1, cond2, ...);
```

计算与模式匹配的事件链的数量。该函数搜索不重叠的事件链。当前链匹配后，它开始搜索下一个链。

### 警告!

在同一秒钟发生的事件可能以未定义的顺序排列在序列中，会影响最终结果。

### 参数

pattern — 模式字符串。

#### 模式语法

(?N) — 在位置N匹配条件参数。条件在编号 [1, 32] 范围。例如, (?1) 匹配传递给 cond1 参数。

. \* — 匹配任何事件的数字。不需要条件参数来匹配这个模式。

(?t operator value) — 分开两个事件的时间。单位为秒。

t表示为两个时间的差值，单位为秒。例如： (?1)(?t>1800)(?2) 匹配彼此发生超过1800秒的事件， (?1)(?t>10000)(?2) 匹配彼此发生超过10000秒的事件。 这些事件之间可以存在任意数量的任何事件。 您可以使用 >=, >, <, <=, == 运算符。

timestamp — 包含时间的列。典型的时间类型是： Date 和 DateTime。也可以使用任何支持的 UInt 数据类型。

cond1, cond2 — 事件链的约束条件。数据类型是： UInt8。最多可以传递32个条件参数。 该函数只考虑这些条件中描述的事件。 如果序列包含未在条件中描述的数据，则函数将跳过这些数据。

### 返回值

匹配的非重叠事件链数。

### 举例

#### 匹配例子

```
DROP TABLE IF EXISTS sequence_count_test1;
```

```
CREATE TABLE sequence_count_test1(
 `uid` int COMMENT 'user id',
 `date` datetime COMMENT 'date time',
 `number` int NULL COMMENT 'number'
)
DUPLICATE KEY(uid)
DISTRIBUTED BY HASH(uid) BUCKETS 3
PROPERTIES (
 "replication_num" = "1"
);

INSERT INTO sequence_count_test1(uid, date, number) values (1, '2022-11-02 10:41:00', 1),
(2, '2022-11-02 13:28:02', 2),
(3, '2022-11-02 16:15:01', 1),
(4, '2022-11-02 19:05:04', 2),
(5, '2022-11-02 20:08:44', 3);
```

```
SELECT * FROM sequence_count_test1 ORDER BY date;
```

uid	date	number
1	2022-11-02 10:41:00	1
2	2022-11-02 13:28:02	2
3	2022-11-02 16:15:01	1
4	2022-11-02 19:05:04	2
5	2022-11-02 20:08:44	3

```
SELECT sequence_count('(?)(?)', date, number = 1, number = 3) FROM sequence_count_test1;
```

sequence_count('(?)(?)', `date`, `number` = 1, `number` = 3)
1

```
SELECT sequence_count('(?)(?)', date, number = 1, number = 2) FROM sequence_count_test1;
```

sequence_count('(?)(?)', `date`, `number` = 1, `number` = 2)
2

```
SELECT sequence_count('(?) (?t>=3600) (?)', date, number = 1, number = 2) FROM sequence_count_test1;
```

sequence_count('(?) (?t>=3600) (?)', `date`, `number` = 1, `number` = 2)
2

## 不匹配例子

```
DROP TABLE IF EXISTS sequence_count_test2;
```

```
CREATE TABLE sequence_count_test2(
 `uid` int COMMENT 'user id',
 `date` datetime COMMENT 'date time',
 `number` int NULL COMMENT 'number'
)
DUPLICATE KEY(uid)
```

```
DISTRIBUTED BY HASH(uid) BUCKETS 3
PROPERTIES (
 "replication_num" = "1"
);

INSERT INTO sequence_count_test2(uid, date, number) values (1, '2022-11-02 10:41:00', 1),
 (2, '2022-11-02 11:41:00', 7),
 (3, '2022-11-02 16:15:01', 3),
 (4, '2022-11-02 19:05:04', 4),
 (5, '2022-11-02 21:24:12', 5);
```

```
SELECT * FROM sequence_count_test2 ORDER BY date;
```

uid	date	number
1	2022-11-02 10:41:00	1
2	2022-11-02 11:41:00	7
3	2022-11-02 16:15:01	3
4	2022-11-02 19:05:04	4
5	2022-11-02 21:24:12	5

```
SELECT sequence_count('(?(1)(?2)', date, number = 1, number = 2) FROM sequence_count_test2;
```

sequence_count('(?(1)(?2)', `date`, `number` = 1, `number` = 2)
0

```
SELECT sequence_count('(?(1)(?2).*', date, number = 1, number = 2) FROM sequence_count_test2;
```

sequence_count('(?(1)(?2).*', `date`, `number` = 1, `number` = 2)
0

```
SELECT sequence_count('(?(1)(?t>3600)(?2)', date, number = 1, number = 7) FROM sequence_count_test2;
```

sequence_count('(?(1)(?t>3600)(?2)', `date`, `number` = 1, `number` = 7)
0

## 特殊例子

```
DROP TABLE IF EXISTS sequence_count_test3;
```

```
CREATE TABLE sequence_count_test3(
 `uid` int COMMENT 'user id',
 `date` datetime COMMENT 'date time',
 `number` int NULL COMMENT 'number'
)
```

```
DUPLICATE KEY(uid)
```

```
DISTRIBUTED BY HASH(uid) BUCKETS 3
```

```
PROPERTIES (
 "replication_num" = "1"
);
```

```
INSERT INTO sequence_count_test3(uid, date, number) values (1, '2022-11-02 10:41:00', 1),
```



```
(2, '2022-11-02 11:41:00', 7),
(3, '2022-11-02 16:15:01', 3),
(4, '2022-11-02 19:05:04', 4),
(5, '2022-11-02 21:24:12', 5);
```

```
SELECT * FROM sequence_count_test3 ORDER BY date;
```

uid	date	number
1	2022-11-02 10:41:00	1
2	2022-11-02 11:41:00	7
3	2022-11-02 16:15:01	3
4	2022-11-02 19:05:04	4
5	2022-11-02 21:24:12	5

Perform the query:

```
SELECT sequence_count('(?)(?)', date, number = 1, number = 5) FROM sequence_count_test3;
```

sequence_count('(?)(?)', `date`, `number` = 1, `number` = 5)
1

上面为一个非常简单的匹配例子，该函数找到了数字5跟随数字1的事件链。它跳过了它们之间的数字7，3，4，因为该数字没有被描述为事件。如果我们想在搜索示例中给出的事件链时考虑这个数字，我们应该为它创建一个条件。

现在，考虑如下执行语句：

```
SELECT sequence_count('(?)(?)', date, number = 1, number = 5, number = 4) FROM sequence_count_test3;
```

sequence_count('(?)(?)', `date`, `number` = 1, `number` = 5, `number` = 4)
0

您可能对这个结果有些许疑惑，在这种情况下，函数找不到与模式匹配的事件链，因为数字4的事件发生在1和5之间。如果在相同的情况下，我们检查了数字6的条件，则序列将与模式匹配。

```
SELECT sequence_count('(?)(?)', date, number = 1, number = 5, number = 6) FROM sequence_count_test3;
```

sequence_count('(?)(?)', `date`, `number` = 1, `number` = 5, `number` = 6)
1

## keywords

### SEQUENCE\_COUNT

# GROUPING

## 描述

用于在包含 CUBE、ROLLUP 或 GROUPING SETS 的 SQL 语句中，判断某个在 GROUP BY 子句中的列或表达式是否为汇总结果。当结果集中的数据行是由 CUBE、ROLLUP 或 GROUPING SETS 操作产生的汇总行时，该函数返回 1；否则返回 0。GROUPING 函数可在 SELECT、HAVING 和 ORDER BY 子句中使用。

ROLLUP、CUBE 或 GROUPING SETS 操作产生的汇总结果会以 NULL 作为被分组列的值，因此 GROUPING 函数通常用于区分这些 NULL 值与表中实际存在的 NULL 值。

## 语法

```
GROUPING(<column_expression>)
```

## 参数

参数	说明
<column_expression>	在 GROUP BY 子句中包含的列或表达式。

## 返回值

返回 BIGINT 值。若该列或表达式对应的数据行为汇总行，则返回 1；否则返回 0。

## 举例

下面的例子使用 camp 列进行分组操作，并统计 occupation 的数量，同时利用 GROUPING 函数区分汇总行与表中实际存在的 NULL 值。

```
CREATE TABLE `roles` (
 role_id INT,
 occupation VARCHAR(32),
 camp VARCHAR(32),
 register_time DATE
)
UNIQUE KEY(role_id)
DISTRIBUTED BY HASH(role_id) BUCKETS 1
PROPERTIES (
 "replication_allocation" = "tag.location.default: 1"
);

INSERT INTO `roles` VALUES
(0, 'who am I', NULL, NULL),
(1, 'mage', 'alliance', '2018-12-03 16:11:28'),
(2, 'paladin', 'alliance', '2018-11-30 16:11:28'),
(3, 'rogue', 'horde', '2018-12-01 16:11:28'),
(4, 'priest', 'alliance', '2018-12-02 16:11:28'),
(5, 'shaman', 'horde', NULL),
(6, 'warrior', 'alliance', NULL),
```

```

(7, 'warlock', 'horde', '2018-12-04 16:11:28'),
(8, 'hunter', 'horde', NULL);

SELECT
 camp,
 COUNT(occupation) AS occ_cnt,
 GROUPING(camp) AS grouping
FROM
 `roles`
GROUP BY
 ROLLUP(camp);

```

在上述查询中，结果集中 camp 列出现了两个 NULL 值。其中，第一个 NULL（GROUPING 返回 1）表示该行为 ROLLUP 操作产生的汇总行，其 occ\_cnt 为所有 camp 的 occupation 计数；第二个 NULL（GROUPING 返回 0）表示表中实际存在的 NULL 值。

camp	occ_cnt	grouping
NULL	9	1
NULL	1	0
alliance	4	0
horde	4	0

# GROUPING\_ID

## 描述

GROUPING\_ID 是一个用于计算分组层级的函数。当 SQL 语句中使用了 GROUP BY 子句时，该函数可以在 SELECT、HAVING 或 ORDER BY 子句中使用，返回一个 BIGINT 值，该值表示各分组列聚合情况对应的二进制位图转换为十进制后的结果。

## 语法

```
GROUPING_ID (<column_expression>[,...n])
```

## 参数

参数	说明
<column_expression>	在 GROUP BY 子句中包含的列或表达式，可以指定多个参数。

## 返回值

返回一个 BIGINT 值，表示各分组列的聚合情况对应的二进制位图转换为十进制后的结果。

## 示例

### 示例 A: 识别分组层级

下面的例子按部门和职级统计雇员人数，并使用 GROUPING\_ID 函数计算每一行的聚合程度。

```
SELECT
 department,
 CASE
 WHEN GROUPING_ID(department, level) = 0 THEN level
 WHEN GROUPING_ID(department, level) = 1 THEN CONCAT('Total: ', department)
 WHEN GROUPING_ID(department, level) = 3 THEN 'Total: Company'
 ELSE 'Unknown'
 END AS 'Job Title',
 COUNT(uid) AS 'Employee Count'
FROM employee
GROUP BY ROLLUP(department, level)
ORDER BY GROUPING_ID(department, level) ASC;
```

department	Job Title	Employee Count
Board of Directors	Senior	2
Technology	Senior	3
Sales	Senior	1
Sales	Assistant	2
Sales	Trainee	1

Marketing	Senior		1	
Marketing	Trainee		2	
Marketing	Assistant		1	
Board of Directors	Total: Board of Directors		2	
Technology	Total: Technology		3	
Sales	Total: Sales		4	
Marketing	Total: Marketing		4	
NULL	Total: Company		13	
+-----+-----+-----+				

### 示例 B: 过滤结果集

下面的例子返回部门中级别为 “Senior” 的雇员统计数据。

```

SELECT
 department,
 CASE
 WHEN GROUPING_ID(department, level) = 0 THEN level
 WHEN GROUPING_ID(department, level) = 1 THEN CONCAT('Total: ', department)
 WHEN GROUPING_ID(department, level) = 3 THEN 'Total: Company'
 ELSE 'Unknown'
 END AS 'Job Title',
 COUNT(uid)
FROM employee
GROUP BY ROLLUP(department, level)
HAVING `Job Title` IN ('Senior');
```

+-----+-----+-----+			
department	Job Title		count(`uid`)
+-----+-----+-----+			
Board of Directors	Senior		2
Technology	Senior		3
Sales	Senior		1
Marketing	Senior		1
+-----+-----+-----+			

# COUNT\_BY\_ENUM

---

## COUNT\_BY\_ENUM

COUNT\_BY\_ENUM

### 描述

### 语法

```
count_by_enum(expr1, expr2, ... , exprN);
```

将列中数据看作枚举值，统计每个枚举值的个数。返回各个列枚举值的个数，以及非 null 值的个数与 null 值的个数。

### 参数

expr1 — 至少填写一个输入。值为字符串（STRING）类型的列。

### 返回值

返回一个 JSONArray 字符串。

例如：

```
[{
 "cbe": {
 "F": 100,
 "M": 99
 },
 "nonnull": 199,
 "null": 1,
 "all": 200
}, {
 "cbe": {
 "20": 10,
 "30": 5,
 "35": 1
 },
 "nonnull": 16,
 "null": 184,
 "all": 200
}, {
 "cbe": {
 "北京": 10,
 "上海": 9,
 "广州": 20,
 "深圳": 30
 },
 "nonnull": 69,
 "null": 131,
```

```
 "all": 200
 }
}
```

说明：返回值为一个 JSON array 字符串，内部对象的顺序是输入参数的顺序。  
 \* cbe：根据枚举值统计非 null 值的统计结果  
 \* notnull：非 null 的个数  
 \* null：null 值个数  
 \* all：总数，包括 null 值与非 null 值

## 举例

```
DROP TABLE IF EXISTS count_by_enum_test;

CREATE TABLE count_by_enum_test(
 `id` varchar(1024) NULL,
 `f1` text REPLACE_IF_NOT_NULL NULL,
 `f2` text REPLACE_IF_NOT_NULL NULL,
 `f3` text REPLACE_IF_NOT_NULL NULL
)
AGGREGATE KEY(`id`)
DISTRIBUTED BY HASH(id) BUCKETS 3
PROPERTIES (
 "replication_num" = "1"
);

INSERT into count_by_enum_test (id, f1, f2, f3) values
(1, "F", "10", "北京"),
(2, "F", "20", "北京"),
(3, "M", NULL, "上海"),
(4, "M", NULL, "上海"),
(5, "M", NULL, "广州");
```

```
SELECT * from count_by_enum_test;
```

id	f1	f2	f3
2	F	20	北京
3	M	NULL	上海
4	M	NULL	上海
5	M	NULL	广州
1	F	10	北京

```
select count_by_enum(f1) from count_by_enum_test;
```

count_by_enum(`f1`)
[{"cbe":{"M":3,"F":2},"notnull":5,"null":0,"all":5}]

```
select count_by_enum(f2) from count_by_enum_test;
```

count_by_enum(`f2`)
[{"cbe":{"10":1,"20":1},"notnull":2,"null":3,"all":5}]

```
select count_by_enum(f1,f2,f3) from count_by_enum_test;
```

count_by_enum(`f1`, `f2`, `f3`)
---------------------------------

+-----+
[{"cbe":{"M":3,"F":2},"nonnull":5,"null":0,"all":5},{"cbe":{"20":1,"10":1},"nonnull":2,"null":3,"all":5},
{"cbe":{"广州":1,"上海":2,"北京":2},"nonnull":5,"null":0,"all":5}]
+-----+

**keywords**

COUNT\_BY\_ENUM



# HISTOGRAM

## HISTOGRAM

### 描述

### 语法

`histogram(expr[, INT num_buckets])`

`histogram`（直方图）函数用于描述数据分布情况，它使用“等高”的分桶策略，并按照数据的值大小进行分桶，并用一些简单的数据来描述每个桶，比如落在桶里的值的个数。主要用于优化器进行区间查询的估算。

函数结果返回空或者 Json 字符串。

参数说明：- `num_buckets`：可选项。用于限制直方图桶（bucket）的数量，默认值 128。

别名函数：`hist(expr[, INT num_buckets])` ### 举例

```
MySQL [test]> SELECT histogram(c_float) FROM histogram_test;
+-----+
| histogram(`c_float`) |
+-----+
| {"num_buckets":3,"buckets":[{"lower":"0.1","upper":"0.1","count":1,"pre_sum":0,"ndv":1},...]} |
+-----+

MySQL [test]> SELECT histogram(c_string, 2) FROM histogram_test;
+-----+
| histogram(`c_string`) |
+-----+
| {"num_buckets":2,"buckets":[{"lower":"str1","upper":"str7","count":4,"pre_sum":0,"ndv":3},...]} |
+-----+
```

查询结果说明：

```
{
 "num_buckets": 3,
 "buckets": [
 {
 "lower": "0.1",
 "upper": "0.2",
 "count": 2,
 "pre_sum": 0,
 "ndv": 2
 },
 {
```

```
 "lower": "0.8",
 "upper": "0.9",
 "count": 2,
 "pre_sum": 2,
 "ndv": 2
 },
 {
 "lower": "1.0",
 "upper": "1.0",
 "count": 2,
 "pre_sum": 4,
 "ndv": 1
 }
]
}
```

字段说明： - num\_buckets: 桶的数量 - buckets: 直方图所包含的桶 - lower: 桶的上界 - upper: 桶的下界 - count: 桶内包含的元素数量 - pre\_sum: 前面桶的元素总量 - ndv: 桶内不同值的个数

直方图总的元素数量 = 最后一个桶的元素数量 (count) + 前面桶的元素总量 (pre\_sum)。

## keywords

HISTOGRAM, HIST

# MAP\_AGG

## MAP\_AGG

### 描述

### 语法

MAP\_AGG(expr1, expr2)

返回一个 map, 由 expr1 作为键, expr2 作为对应的值。

### 举例

```
MySQL > select `n_nationkey`, `n_name`, `n_regionkey` from `nation`;
```

n_nationkey	n_name	n_regionkey
0	ALGERIA	0
1	ARGENTINA	1
2	BRAZIL	1
3	CANADA	1
4	EGYPT	4
5	ETHIOPIA	0
6	FRANCE	3
7	GERMANY	3
8	INDIA	2
9	INDONESIA	2
10	IRAN	4
11	IRAQ	4
12	JAPAN	2
13	JORDAN	4
14	KENYA	0
15	MOROCCO	0
16	MOZAMBIQUE	0
17	PERU	1
18	CHINA	2
19	ROMANIA	3
20	SAUDI ARABIA	4
21	VIETNAM	2
22	RUSSIA	3
23	UNITED KINGDOM	3
24	UNITED STATES	1

```
MySQL > select `n_regionkey`, map_agg(`n_nationkey`, `n_name`) from `nation` group by `n_regionkey`;
```

n_regionkey	map_agg(`n_nationkey`, `n_name`)
1	{1:"ARGENTINA", 2:"BRAZIL", 3:"CANADA", 17:"PERU", 24:"UNITED STATES"}
0	{0:"ALGERIA", 5:"ETHIOPIA", 14:"KENYA", 15:"MOROCCO", 16:"MOZAMBIQUE"}
3	{6:"FRANCE", 7:"GERMANY", 19:"ROMANIA", 22:"RUSSIA", 23:"UNITED KINGDOM"}
4	{4:"EGYPT", 10:"IRAN", 11:"IRAQ", 13:"JORDAN", 20:"SAUDI ARABIA"}
2	{8:"INDIA", 9:"INDONESIA", 12:"JAPAN", 18:"CHINA", 21:"VIETNAM"}

```
MySQL > select n_regionkey, map_agg(`n_name`, `n_nationkey` % 5) from `nation` group by `n_regionkey`;
```

+-----+-----+-----+		
n_regionkey	map_agg(`n_name`, (`n_nationkey` % 5))	
+-----+-----+-----+		
2	{ "INDIA":3, "INDONESIA":4, "JAPAN":2, "CHINA":3, "VIETNAM":1 }	
0	{ "ALGERIA":0, "ETHIOPIA":0, "KENYA":4, "MOROCCO":0, "MOZAMBIQUE":1 }	
3	{ "FRANCE":1, "GERMANY":2, "ROMANIA":4, "RUSSIA":2, "UNITED KINGDOM":3 }	
1	{ "ARGENTINA":1, "BRAZIL":2, "CANADA":3, "PERU":2, "UNITED STATES":4 }	
4	{ "EGYPT":4, "IRAN":0, "IRAQ":1, "JORDAN":3, "SAUDI ARABIA":0 }	
+-----+-----+-----+		

## keywords

MAP\_AGG

# BITMAP\_AGG

## BITMAP\_AGG

### 描述

### 语法

BITMAP\_AGG(expr)

聚合 expr 的值（不包括任何空值）得到 bitmap。expr 的类型需要为 TINYINT,SMALLINT,INT 和 BIGINT 类型。

### 举例

```
MySQL > select `n_nationkey`, `n_name`, `n_regionkey` from `nation`;
```

n_nationkey	n_name	n_regionkey
0	ALGERIA	0
1	ARGENTINA	1
2	BRAZIL	1
3	CANADA	1
4	EGYPT	4
5	ETHIOPIA	0
6	FRANCE	3
7	GERMANY	3
8	INDIA	2
9	INDONESIA	2
10	IRAN	4
11	IRAQ	4
12	JAPAN	2
13	JORDAN	4
14	KENYA	0
15	MOROCCO	0
16	MOZAMBIQUE	0
17	PERU	1
18	CHINA	2
19	ROMANIA	3
20	SAUDI ARABIA	4
21	VIETNAM	2
22	RUSSIA	3
23	UNITED KINGDOM	3
24	UNITED STATES	1

```
MySQL > select n_regionkey, bitmap_to_string(bitmap_agg(n_nationkey)) from nation group by n_regionkey;
```

n_regionkey	bitmap_to_string(bitmap_agg(`n_nationkey`))
4	4,10,11,13,20
2	8,9,12,18,21
1	1,2,3,17,24
0	0,5,14,15,16
3	6,7,19,22,23

```

+-----+-----+
MySQL > select bitmap_count(bitmap_agg(n_nationkey)) from nation;
+-----+-----+
| bitmap_count(bitmap_agg(`n_nationkey`)) |
+-----+-----+
| 25 |
+-----+-----+

```

## keywords

BITMAP\_AGG

# TO\_BITMAP

---

## to\_bitmap

### 描述

### 语法

BITMAP TO\_BITMAP(expr)

输入为取值在 0 ~ 18446744073709551615 区间的 unsigned bigint，输出为包含该元素的bitmap。当输入值不在此范围时，会返回NULL。该函数主要用于stream load任务将整型字段导入Doris表的bitmap字段。例如

```
cat data | curl --location-trusted -u user:passwd -T - -H "columns: dt,page,user_id,
user_id=to_bitmap(user_id)" http://host:8410/api/test/testDb/_stream_load
```

### 举例

```
mysql> select bitmap_count(to_bitmap(10));
+-----+
| bitmap_count(to_bitmap(10)) |
+-----+
| 1 |
+-----+

MySQL> select bitmap_to_string(to_bitmap(-1));
+-----+
| bitmap_to_string(to_bitmap(-1)) |
+-----+
| |
+-----+
```

### keywords

TO\_BITMAP,BITMAP

# BITMAP\_HASH

## bitmap\_hash

### Name

BITMAP\_HASH

### 描述

对任意类型的输入，计算其 32 位的哈希值，并返回包含该哈希值的 bitmap。该函数使用的哈希算法为 MurMur3。MurMur3 算法是一种高性能的、低碰撞率的散列算法，其计算出来的值接近于随机分布，并且能通过卡方分布测试。需要注意的是，不同硬件平台、不同 Seed 值计算出来的散列值可能不同。关于此算法的性能可以参考 [Smhasher](#) 排行榜。

### 语法

BITMAP BITMAP\_HASH(<any\_value>)

### 参数

<any\_value> 任何值或字段表达式。

### Return Type

BITMAP

### Remarks


一般来说，MurMur 32 位算法对于完全随机的、较短的字符串的散列效果较好，碰撞率能达到几十亿分之一，但对于较长的字符串，比如你的操作系统路径，碰撞率会比较高。如果你扫描你系统里的路径，就会发现碰撞率仅仅只能达到百万分之一甚至是十万分之一。

下面两个字符串的 MurMur3 散列值是一样的：

```
SELECT
bitmap_to_string(bitmap_hash('/System/Volumes/Data/Library/Developer/CommandLineTools/SDKs/MacOSX12.3.sdk/System/Library/Frameworks/KernelManagement.framework/KernelManagement.tbd')) AS a ,

bitmap_to_string(bitmap_hash('/System/Library/PrivateFrameworks/Install.framework/Versions/Current/Resources/es_419.lproj/Architectures.strings')) AS b;
```

结果如下：





```
+-----+
| 282251871 | 282251871 |
+-----+
```

## 举例

如果你想计算某个值的 MurMur3，你可以：

```
select bitmap_to_array(bitmap_hash('hello'))[1];
```

结果如下：

```
+-----+
| %element_extract%(bitmap_to_array(bitmap_hash('hello')), 1) |
+-----+
| 1321743225 |
+-----+
```

如果你想统计某一列去重后的个数，可以使用位图的方式，某些场景下性能比 count distinct 好很多：

```
select bitmap_count(bitmap_union(bitmap_hash(`word`))) from `words`;
```

结果如下：

```
+-----+
| bitmap_count(bitmap_union(bitmap_hash(`word`))) |
+-----+
| 33263478 |
+-----+
```

## Keywords

```
BITMAP_HASH,BITMAP
```

## Best Practice

还可参见 - [BITMAP\\_HASH64](#)

# BITMAP\_FROM\_STRING

## bitmap\_from\_string

### 描述

### 语法

BITMAP BITMAP\_FROM\_STRING(VARCHAR input)

将一个字符串转化为一个BITMAP，字符串是由逗号分隔的一组unsigned bigint数字组成.(数字取值在:0 ~ 18446744073709551615) 比如"0, 1, 2"字符串会转化为一个Bitmap，其中的第0, 1, 2位被设置. 当输入字段不合法时，返回NULL

### 举例

```
mysql> select bitmap_to_string(bitmap_from_string("0, 1, 2"));
+-----+
| bitmap_to_string(bitmap_from_string('0, 1, 2')) |
+-----+
| 0,1,2 |
+-----+

mysql> select bitmap_from_string("-1, 0, 1, 2");
+-----+
| bitmap_from_string('-1, 0, 1, 2') |
+-----+
| NULL |
+-----+

mysql> select bitmap_to_string(bitmap_from_string("0, 1, 18446744073709551615"));
+-----+
| bitmap_to_string(bitmap_from_string('0, 1, 18446744073709551615')) |
+-----+
| 0,1,18446744073709551615 |
+-----+
```

### keywords

BITMAP\_FROM\_STRING,BITMAP

# BITMAP\_TO\_STRING

---

## bitmap\_to\_string

### 描述

### 语法

VARCHAR BITMAP\_TO\_STRING(BITMAP input)

将一个bitmap转化成一个逗号分隔的字符串，字符串中包含所有设置的BIT位。输入是null的话会返回null。

### 举例

```
mysql> select bitmap_to_string(null);
+-----+
| bitmap_to_string(NULL) |
+-----+
| NULL |
+-----+

mysql> select bitmap_to_string(bitmap_empty());
+-----+
| bitmap_to_string(bitmap_empty()) |
+-----+
| |
+-----+

mysql> select bitmap_to_string(to_bitmap(1));
+-----+
| bitmap_to_string(to_bitmap(1)) |
+-----+
| 1 |
+-----+

mysql> select bitmap_to_string(bitmap_or(to_bitmap(1), to_bitmap(2)));
+-----+
| bitmap_to_string(bitmap_or(to_bitmap(1), to_bitmap(2))) |
+-----+
| 1,2 |
+-----+
```

### keywords

BITMAP\_TO\_STRING,BITMAP

# BITMAP\_TO\_ARRAY

---

## bitmap\_to\_array

### 描述

### 语法

ARRAY\_BIGINT bitmap\_to\_array(BITMAP input)

将一个bitmap转化成一个array 数组。输入是null的话会返回null。

### 举例

```
mysql> select bitmap_to_array(null);
+-----+
| bitmap_to_array(NULL) |
+-----+
| NULL |
+-----+

mysql> select bitmap_to_array(bitmap_empty());
+-----+
| bitmap_to_array(bitmap_empty()) |
+-----+
| [] |
+-----+

mysql> select bitmap_to_array(to_bitmap(1));
+-----+
| bitmap_to_array(to_bitmap(1)) |
+-----+
| [1] |
+-----+

mysql> select bitmap_to_array(bitmap_from_string('1,2,3,4,5'));
+-----+
| bitmap_to_array(bitmap_from_string('1,2,3,4,5')) |
+-----+
| [1, 2, 3, 4, 5] |
+-----+
```

### keywords

BITMAP\_TO\_ARRAY,BITMAP

# BITMAP\_FROM\_ARRAY

## bitmap\_from\_array

### 描述

### 语法

BITMAP BITMAP\_FROM\_ARRAY(ARRAY input)

将一个TINYINT/SMALLINT/INT/BIGINT类型的数组转化为一个BITMAP 当输入字段不合法时，结果返回NULL

### 举例

```
mysql> select *, bitmap_to_string(bitmap_from_array(c_array)) from array_test;
```

id	c_array	bitmap_to_string(bitmap_from_array(`c_array`))
1	[NULL]	NULL
2	[1, 2, 3, NULL]	NULL
2	[1, 2, 3, -10]	NULL
3	[1, 2, 3, 4, 5, 6, 7]	1,2,3,4,5,6,7
4	[100, 200, 300, 300]	100,200,300

5 rows in set (0.02 sec)

### keywords

BITMAP\_FROM\_ARRAY,BITMAP

# BITMAP\_EMPTY

---

## bitmap\_empty

### 描述

### 语法

BITMAP BITMAP\_EMPTY()

返回一个空bitmap。主要用于 insert 或 stream load 时填充默认值。例如

```
cat data | curl --location-trusted -u user:passwd -T - -H "columns: dt,page,v1,v2=bitmap_empty()"
http://host:8410/api/test/testDb/_stream_load
```

### 举例

```
mysql> select bitmap_count(bitmap_empty());
+-----+
| bitmap_count(bitmap_empty()) |
+-----+
| 0 |
+-----+

mysql> select bitmap_to_string(bitmap_empty());
+-----+
| bitmap_to_string(bitmap_empty()) |
+-----+
| |
+-----+
```

### keywords

BITMAP\_EMPTY, BITMAP

# BITMAP\_OR

## bitmap\_or

### 描述

### 语法

BITMAP BITMAP\_OR(BITMAP lhs, BITMAP rhs, ...)

计算两个及以上的输入bitmap的并集，返回新的bitmap.

### 举例

```
mysql> select bitmap_count(bitmap_or(to_bitmap(1), to_bitmap(1))) cnt;
+-----+
| cnt |
+-----+
| 1 |
+-----+

mysql> select bitmap_to_string(bitmap_or(to_bitmap(1), to_bitmap(1))) ;
+-----+
| bitmap_to_string(bitmap_or(to_bitmap(1), to_bitmap(1))) |
+-----+
| 1 |
+-----+

mysql> select bitmap_count(bitmap_or(to_bitmap(1), to_bitmap(2))) cnt;
+-----+
| cnt |
+-----+
| 2 |
+-----+

mysql> select bitmap_to_string(bitmap_or(to_bitmap(1), to_bitmap(2)));
+-----+
| bitmap_to_string(bitmap_or(to_bitmap(1), to_bitmap(2))) |
+-----+
| 1,2 |
+-----+

mysql> select bitmap_to_string(bitmap_or(to_bitmap(1), to_bitmap(2), to_bitmap(10), to_bitmap(0), NULL));
+-----+
| bitmap_to_string(bitmap_or(to_bitmap(1), to_bitmap(2), to_bitmap(10), to_bitmap(0), NULL)) |
+-----+
| 0,1,2,10 |
+-----+

mysql> select bitmap_to_string(bitmap_or(to_bitmap(1), to_bitmap(2), to_bitmap(10), to_bitmap(0),
bitmap_empty()));
+-----+
| bitmap_to_string(bitmap_or(to_bitmap(1), to_bitmap(2), to_bitmap(10), to_bitmap(0), bitmap_empty())) |
+-----+
| 0,1,2,10 |
+-----+
```

```
mysql> select bitmap_to_string(bitmap_or(to_bitmap(10), bitmap_from_string('1,2'),
bitmap_from_string('1,2,3,4,5')));
+-----+
| bitmap_to_string(bitmap_or(to_bitmap(10), bitmap_from_string('1,2'), bitmap_from_string('1,2,3,4,5'))) |
+-----+
| 1,2,3,4,5,10 |
+-----+
```

## keywords

BITMAP\_OR,BITMAP



# BITMAP\_AND

## bitmap\_and

### 描述

### 语法

BITMAP BITMAP\_AND(BITMAP lhs, BITMAP rhs)

计算两个及以上输入bitmap的交集，返回新的bitmap.

### 举例

```
mysql> select bitmap_count(bitmap_and(to_bitmap(1), to_bitmap(2))) cnt;
+-----+
| cnt |
+-----+
| 0 |
+-----+

mysql> select bitmap_to_string(bitmap_and(to_bitmap(1), to_bitmap(2)));
+-----+
| bitmap_to_string(bitmap_and(to_bitmap(1), to_bitmap(2))) |
+-----+
| |
+-----+

mysql> select bitmap_count(bitmap_and(to_bitmap(1), to_bitmap(1))) cnt;
+-----+
| cnt |
+-----+
| 1 |
+-----+

MySQL> select bitmap_to_string(bitmap_and(to_bitmap(1), to_bitmap(1)));
+-----+
| bitmap_to_string(bitmap_and(to_bitmap(1), to_bitmap(1))) |
+-----+
| 1 |
+-----+

MySQL> select bitmap_to_string(bitmap_and(bitmap_from_string('1,2,3'), bitmap_from_string('1,2'),
bitmap_from_string('1,2,3,4,5')));
+-----+
| bitmap_to_string(bitmap_and(bitmap_from_string('1,2,3'), bitmap_from_string('1,2'),
bitmap_from_string('1,2,3,4,5'))) |
+-----+
| 1,2 |
| |
+-----+

MySQL> select bitmap_to_string(bitmap_and(bitmap_from_string('1,2,3'), bitmap_from_string('1,2'),
```

```

bitmap_from_string('1,2,3,4,5'),bitmap_empty()));
+-----+
| bitmap_to_string(bitmap_and(bitmap_from_string('1,2,3'), bitmap_from_string('1,2'),
bitmap_from_string('1,2,3,4,5'), bitmap_empty())) |
+-----+
|
|
+-----+
-----+

MySQL> select bitmap_to_string(bitmap_and(bitmap_from_string('1,2,3'), bitmap_from_string('1,2'),
bitmap_from_string('1,2,3,4,5'),NULL));
+-----+
| bitmap_to_string(bitmap_and(bitmap_from_string('1,2,3'), bitmap_from_string('1,2'),
bitmap_from_string('1,2,3,4,5'), NULL)) |
+-----+
| NULL
|
+-----+
-----+

```

## keywords

BITMAP\_AND,BITMAP

# BITMAP\_UNION

---

## bitmap\_union function

### 描述

聚合函数，用于计算分组后的 bitmap 并集。常见使用场景如：计算PV，UV。

### 语法

BITMAP BITMAP\_UNION(BITMAP value)

输入一组 bitmap 值，求这一组 bitmap 值的并集，并返回。

### 举例

```
mysql> select page_id, bitmap_union(user_id) from table group by page_id;
```

和 bitmap\_count 函数组合使用可以求得网页的 UV 数据

```
mysql> select page_id, bitmap_count(bitmap_union(user_id)) from table group by page_id;
```

当 user\_id 字段为 int 时，上面查询语义等同于

```
mysql> select page_id, count(distinct user_id) from table group by page_id;
```

### keywords

BITMAP\_UNION, BITMAP

# BITMAP\_XOR

## bitmap\_xor

### 描述

### 语法

BITMAP BITMAP\_XOR(BITMAP lhs, BITMAP rhs, ...)

计算两个及以上输入bitmap的差集，返回新的bitmap。

### 举例

```
mysql> select bitmap_count(bitmap_xor(bitmap_from_string('2,3'),bitmap_from_string('1,2,3,4'))) cnt;
+-----+
| cnt |
+-----+
| 2 |
+-----+

mysql> select bitmap_to_string(bitmap_xor(bitmap_from_string('2,3'),bitmap_from_string('1,2,3,4')));
+-----+
| bitmap_to_string(bitmap_xor(bitmap_from_string('2,3'), bitmap_from_string('1,2,3,4'))) |
+-----+
| 1,4 |
+-----+

MySQL> select
bitmap_to_string(bitmap_xor(bitmap_from_string('2,3'),bitmap_from_string('1,2,3,4'),bitmap_from_string('3,4,5
')));
+-----+
| bitmap_to_string(bitmap_xor(bitmap_from_string('2,3'), bitmap_from_string('1,2,3,4'),
bitmap_from_string('3,4,5'))) |
+-----+
| 1,3,5 |
| |
+-----+

MySQL> select
bitmap_to_string(bitmap_xor(bitmap_from_string('2,3'),bitmap_from_string('1,2,3,4'),bitmap_from_string('3,4,5
'),bitmap_empty()));
+-----+
| bitmap_to_string(bitmap_xor(bitmap_from_string('2,3'), bitmap_from_string('1,2,3,4'),
bitmap_from_string('3,4,5'), bitmap_empty())) |
+-----+
| 1,3,5 |
| |
+-----+
```

```

MySQL> select
bitmap_to_string(bitmap_xor(bitmap_from_string('2,3'),bitmap_from_string('1,2,3,4'),bitmap_from_string('3,4,5
'),NULL));
+-----+
-----+
| bitmap_to_string(bitmap_xor(bitmap_from_string('2,3'), bitmap_from_string('1,2,3,4'),
bitmap_from_string('3,4,5'), NULL)) |
+-----+
-----+
| NULL
|
+-----+
-----+

```

## keywords

BITMAP\_XOR,BITMAP

# BITMAP\_NOT

---

## bitmap\_not

### 描述

### 语法

BITMAP BITMAP\_NOT(BITMAP lhs, BITMAP rhs)

计算lhs减去rhs之后的集合，返回新的bitmap.

### 举例

```
mysql> select bitmap_to_string(bitmap_not(bitmap_from_string('2,3'),bitmap_from_string('1,2,3,4')));
+-----+
| bitmap_to_string(bitmap_not(bitmap_from_string('2,3'), bitmap_from_string('1,2,3,4'))) |
+-----+
| |
+-----+
1 row in set (0.01 sec)

mysql> select bitmap_to_string(bitmap_not(bitmap_from_string('2,3,5'),bitmap_from_string('1,2,3,4')));
+-----+
| bitmap_to_string(bitmap_not(bitmap_from_string('2,3,5'), bitmap_from_string('1,2,3,4'))) |
+-----+
| 5 |
+-----+
```

### keywords

BITMAP\_NOT, BITMAP

# BITMAP\_AND\_NOT,BITMAP\_ANDNOT

## bitmap\_and\_not,bitmap\_andnot

### 描述

### 语法

BITMAP BITMAP\_AND\_NOT(BITMAP lhs, BITMAP rhs)

将两个bitmap进行与非操作并返回计算结果。

### 举例

```
mysql> select bitmap_count(bitmap_and_not(bitmap_from_string('1,2,3'),bitmap_from_string('3,4,5'))) cnt;
+-----+
| cnt |
+-----+
| 2 |
+-----+

mysql> select bitmap_to_string(bitmap_and_not(bitmap_from_string('1,2,3'),bitmap_from_string('3,4,5')));
+-----+
| bitmap_to_string(bitmap_and_not(bitmap_from_string('1,2,3'), bitmap_from_string('3,4,5'))) |
+-----+
| 1,2 |
+-----+
1 row in set (0.01 sec)

mysql> select bitmap_to_string(bitmap_and_not(bitmap_from_string('1,2,3'),bitmap_empty())) ;
+-----+
| bitmap_to_string(bitmap_and_not(bitmap_from_string('1,2,3'), bitmap_empty())) |
+-----+
| 1,2,3 |
+-----+

mysql> select bitmap_to_string(bitmap_and_not(bitmap_from_string('1,2,3'),NULL));
+-----+
| bitmap_to_string(bitmap_and_not(bitmap_from_string('1,2,3'), NULL)) |
+-----+
| NULL |
+-----+
```

### keywords

BITMAP\_AND\_NOT,BITMAP\_ANDNOT,BITMAP

# BITMAP\_SUBSET\_LIMIT

---

## bitmap\_subset\_limit

### 描述

### 语法

BITMAP BITMAP\_SUBSET\_LIMIT(BITMAP src, BIGINT range\_start, BIGINT cardinality\_limit)

生成 src 的子 BITMAP，从不小于 range\_start 的位置开始，大小限制为 cardinality\_limit 。 range\_start: 范围起始点（含） cardinality\_limit: 子 BITMAP 基数上限

### 举例

```
mysql> select bitmap_to_string(bitmap_subset_limit(bitmap_from_string('1,2,3,4,5'), 0, 3)) value;
+-----+
| value |
+-----+
| 1,2,3 |
+-----+

mysql> select bitmap_to_string(bitmap_subset_limit(bitmap_from_string('1,2,3,4,5'), 4, 3)) value;
+-----+
| value |
+-----+
| 4, 5 |
+-----+
```

### keywords

BITMAP\_SUBSET\_LIMIT,BITMAP\_SUBSET,BITMAP



# BITMAP\_SUBSET\_IN\_RANGE

---

## bitmap\_subset\_in\_range

### 描述

### 语法

BITMAP BITMAP\_SUBSET\_IN\_RANGE(BITMAP src, BIGINT range\_start, BIGINT range\_end)

返回 BITMAP 指定范围内的子集(不包括范围结束)。

### 举例

```
mysql> select bitmap_to_string(bitmap_subset_in_range(bitmap_from_string('1,2,3,4,5'), 0, 9)) value;
+-----+
| value |
+-----+
| 1,2,3,4,5 |
+-----+

mysql> select bitmap_to_string(bitmap_subset_in_range(bitmap_from_string('1,2,3,4,5'), 2, 3)) value;
+-----+
| value |
+-----+
| 2 |
+-----+
```

### keywords

BITMAP\_SUBSET\_IN\_RANGE, BITMAP\_SUBSET, BITMAP

# SUB\_BITMAP

---

## sub\_bitmap

### 描述

### 语法

`BITMAP SUB_BITMAP(BITMAP src, BIGINT offset, BIGINT cardinality_limit)`

从 offset 指定位置开始，截取 cardinality\_limit 个 bitmap 元素，返回一个 bitmap 子集。

### 举例

```
mysql> select bitmap_to_string(sub_bitmap(bitmap_from_string('1,0,1,2,3,1,5'), 0, 3)) value;
+-----+
| value |
+-----+
| 0,1,2 |
+-----+

mysql> select bitmap_to_string(sub_bitmap(bitmap_from_string('1,0,1,2,3,1,5'), -3, 2)) value;
+-----+
| value |
+-----+
| 2,3 |
+-----+

mysql> select bitmap_to_string(sub_bitmap(bitmap_from_string('1,0,1,2,3,1,5'), 2, 100)) value;
+-----+
| value |
+-----+
| 2,3,5 |
+-----+
```

### keywords

SUB\_BITMAP, BITMAP\_SUBSET, BITMAP

# BITMAP\_COUNT

---

## bitmap\_count

### 描述

### 语法

BITMAP BITMAP\_COUNT(BITMAP lhs)

返回输入bitmap的个数。

### 举例

```
mysql> select bitmap_count(to_bitmap(1)) cnt;
+-----+
| cnt |
+-----+
| 1 |
+-----+

mysql> select bitmap_count(bitmap_and(to_bitmap(1), to_bitmap(1))) cnt;
+-----+
| cnt |
+-----+
| 1 |
+-----+
```

### keywords

BITMAP\_COUNT

# BITMAP\_AND\_COUNT

## bitmap\_and\_count

### 描述

### 语法

BigIntVal bitmap\_and\_count(BITMAP lhs, BITMAP rhs, ...)

计算两个及以上输入bitmap的交集，返回交集的个数。

### 举例

```
MySQL> select bitmap_and_count(bitmap_from_string('1,2,3'),bitmap_empty());
+-----+
| bitmap_and_count(bitmap_from_string('1,2,3'), bitmap_empty()) |
+-----+
| 0 |
+-----+

MySQL> select bitmap_and_count(bitmap_from_string('1,2,3'),bitmap_from_string('1,2,3'));
+-----+
| bitmap_and_count(bitmap_from_string('1,2,3'), bitmap_from_string('1,2,3')) |
+-----+
| 3 |
+-----+

MySQL> select bitmap_and_count(bitmap_from_string('1,2,3'),bitmap_from_string('3,4,5'));
+-----+
| bitmap_and_count(bitmap_from_string('1,2,3'), bitmap_from_string('3,4,5')) |
+-----+
| 1 |
+-----+

MySQL> select bitmap_and_count(bitmap_from_string('1,2,3'), bitmap_from_string('1,2'),
bitmap_from_string('1,2,3,4,5'));
+-----+
--+
| (bitmap_and_count(bitmap_from_string('1,2,3'), bitmap_from_string('1,2'), bitmap_from_string('1,2,3,4,5'))) |
+-----+
--+
| 2 |
+-----+
--+

MySQL> select bitmap_and_count(bitmap_from_string('1,2,3'), bitmap_from_string('1,2'),
bitmap_from_string('1,2,3,4,5'),bitmap_empty());
+-----+
-----+
| (bitmap_and_count(bitmap_from_string('1,2,3'), bitmap_from_string('1,2'), bitmap_from_string('1,2,3,4,5'),
bitmap_empty())) |
+-----+
```

```

-----+
|
0 |
+-----+

MySQL> select bitmap_and_count(bitmap_from_string('1,2,3'), bitmap_from_string('1,2'),
bitmap_from_string('1,2,3,4,5'), NULL);
+-----+
| (bitmap_and_count(bitmap_from_string('1,2,3'), bitmap_from_string('1,2'), bitmap_from_string('1,2,3,4,5'),
NULL)) |
+-----+
|
NULL |
+-----+
-----+

```

## keywords

```

BITMAP_AND_COUNT,BITMAP

```

# BITMAP\_AND\_NOT\_COUNT,BITMAP\_ANDNOT\_COUNT

---

bitmap\_and\_not\_count,bitmap\_andnot\_count

描述

语法

BITMAP BITMAP\_AND\_NOT\_COUNT(BITMAP lhs, BITMAP rhs)

将两个bitmap进行与非操作并返回计算返回的大小。

举例

```
mysql> select bitmap_and_not_count(bitmap_from_string('1,2,3'),bitmap_from_string('3,4,5')) cnt;
+-----+
| cnt |
+-----+
| 2 |
+-----+
```

keywords

BITMAP\_AND\_NOT\_COUNT,BITMAP\_ANDNOT\_COUNT,BITMAP

# BITMAP\_XOR\_COUNT

## bitmap\_xor\_count

### 描述

### 语法

BIGINT BITMAP\_XOR\_COUNT(BITMAP lhs, BITMAP rhs, ...)

将两个及以上bitmap集合进行异或操作并返回结果集的大小

### 举例

```
mysql> select bitmap_xor_count(bitmap_from_string('1,2,3'),bitmap_from_string('3,4,5'));
+-----+
| bitmap_xor_count(bitmap_from_string('1,2,3'), bitmap_from_string('3,4,5')) |
+-----+
| 4 |
+-----+

mysql> select bitmap_xor_count(bitmap_from_string('1,2,3'),bitmap_from_string('1,2,3'));
+-----+
| bitmap_xor_count(bitmap_from_string('1,2,3'), bitmap_from_string('1,2,3')) |
+-----+
| 0 |
+-----+

mysql> select bitmap_xor_count(bitmap_from_string('1,2,3'),bitmap_from_string('4,5,6'));
+-----+
| bitmap_xor_count(bitmap_from_string('1,2,3'), bitmap_from_string('4,5,6')) |
+-----+
| 6 |
+-----+

MySQL> select
(bitmap_xor_count(bitmap_from_string('2,3'),bitmap_from_string('1,2,3,4'),bitmap_from_string('3,4,5')));
+-----+
| (bitmap_xor_count(bitmap_from_string('2,3'), bitmap_from_string('1,2,3,4'), bitmap_from_string('3,4,5'))) |
+-----+
| 3 |
+-----+

MySQL> select
(bitmap_xor_count(bitmap_from_string('2,3'),bitmap_from_string('1,2,3,4'),bitmap_from_string('3,4,5'),bitmap_
empty()));
+-----+
| (bitmap_xor_count(bitmap_from_string('2,3'), bitmap_from_string('1,2,3,4'), bitmap_from_string('3,4,5'),
bitmap_empty())) |
+-----+
| 3 |
+-----+
```

```

MySQL> select
(bitmap_xor_count(bitmap_from_string('2,3'),bitmap_from_string('1,2,3,4'),bitmap_from_string('3,4,5'),NULL));
+-----+
-----+
| (bitmap_xor_count(bitmap_from_string('2,3'), bitmap_from_string('1,2,3,4'), bitmap_from_string('3,4,5'),
NULL)) |
+-----+
-----+
|
NULL |
+-----+
-----+

```

## keywords

```

BITMAP_XOR_COUNT,BITMAP

```



# BITMAP\_OR\_COUNT

## bitmap\_or\_count

### 描述

### 语法

BigIntVal bitmap\_or\_count(BITMAP lhs, BITMAP rhs, ...)

计算两个及以上输入bitmap的并集，返回并集的个数.

### 举例

```
MySQL> select bitmap_or_count(bitmap_from_string('1,2,3'),bitmap_empty());
+-----+
| bitmap_or_count(bitmap_from_string('1,2,3'), bitmap_empty()) |
+-----+
| 3 |
+-----+

MySQL> select bitmap_or_count(bitmap_from_string('1,2,3'),bitmap_from_string('1,2,3'));
+-----+
| bitmap_or_count(bitmap_from_string('1,2,3'), bitmap_from_string('1,2,3')) |
+-----+
| 3 |
+-----+

MySQL> select bitmap_or_count(bitmap_from_string('1,2,3'),bitmap_from_string('3,4,5'));
+-----+
| bitmap_or_count(bitmap_from_string('1,2,3'), bitmap_from_string('3,4,5')) |
+-----+
| 5 |
+-----+

MySQL> select bitmap_or_count(bitmap_from_string('1,2,3'), bitmap_from_string('3,4,5'), to_bitmap(100),
bitmap_empty());
+-----+
| bitmap_or_count(bitmap_from_string('1,2,3'), bitmap_from_string('3,4,5'), to_bitmap(100), bitmap_empty()) |
+-----+
| 6 |
+-----+

MySQL> select bitmap_or_count(bitmap_from_string('1,2,3'), bitmap_from_string('3,4,5'), to_bitmap(100),
NULL);
+-----+
| bitmap_or_count(bitmap_from_string('1,2,3'), bitmap_from_string('3,4,5'), to_bitmap(100), NULL) |
+-----+
| NULL |
+-----+
```

## keywords

BITMAP\_OR\_COUNT,BITMAP

# BITMAP\_CONTAINS

---

## bitmap\_contains

### 描述

### 语法

BOOLEAN BITMAP\_CONTAINS(BITMAP bitmap, BIGINT input)

计算输入值是否在Bitmap列中，返回值是Boolean值。

### 举例

```
mysql> select bitmap_contains(to_bitmap(1),2) cnt;
+-----+
| cnt |
+-----+
| 0 |
+-----+

mysql> select bitmap_contains(to_bitmap(1),1) cnt;
+-----+
| cnt |
+-----+
| 1 |
+-----+
```

### keywords

BITMAP\_CONTAINS,BITMAP

# BITMAP\_HAS\_ALL

---

## bitmap\_has\_all

### 描述

### 语法

BOOLEAN BITMAP\_HAS\_ALL(BITMAP lhs, BITMAP rhs)

如果第一个bitmap包含第二个bitmap的全部元素，则返回true。 如果第二个bitmap包含的元素为空，返回true。

### 举例

```
mysql> select bitmap_has_all(bitmap_from_string("0, 1, 2"), bitmap_from_string("1, 2"));
+-----+
| bitmap_has_all(bitmap_from_string('0, 1, 2'), bitmap_from_string('1, 2')) |
+-----+
| 1 |
+-----+

mysql> select bitmap_has_all(bitmap_empty(), bitmap_from_string("1, 2"));
+-----+
| bitmap_has_all(bitmap_empty(), bitmap_from_string('1, 2')) |
+-----+
| 0 |
+-----+
```

### keywords

BITMAP\_HAS\_ALL, BITMAP

# BITMAP\_HAS\_ANY

---

## bitmap\_has\_any

### 描述

### 语法

BOOLEAN BITMAP\_HAS\_ANY(BITMAP lhs, BITMAP rhs)

计算两个Bitmap列是否存在相交元素，返回值是Boolean值.

### 举例

```
mysql> select bitmap_has_any(to_bitmap(1),to_bitmap(2));
+-----+
| bitmap_has_any(to_bitmap(1), to_bitmap(2)) |
+-----+
| 0 |
+-----+

mysql> select bitmap_has_any(to_bitmap(1),to_bitmap(1));
+-----+
| bitmap_has_any(to_bitmap(1), to_bitmap(1)) |
+-----+
| 1 |
+-----+
```

### keywords

BITMAP\_HAS\_ANY, BITMAP

# BITMAP\_MAX

---

## bitmap\_max

### 描述

### 语法

BIGINT BITMAP\_MAX(BITMAP input)

计算并返回 bitmap 中的最大值.

### 举例

```
mysql> select bitmap_max(bitmap_from_string('')) value;
+-----+
| value |
+-----+
| NULL |
+-----+

mysql> select bitmap_max(bitmap_from_string('1,999999999')) value;
+-----+
| value |
+-----+
| 999999999 |
+-----+
```

### keywords

BITMAP\_MAX, BITMAP

# BITMAP\_MIN

---

## bitmap\_min

### 描述

### 语法

`BIGINT BITMAP_MIN(BITMAP input)`

计算并返回 bitmap 中的最小值.

### 举例

```
mysql> select bitmap_min(bitmap_from_string('')) value;
+-----+
| value |
+-----+
| NULL |
+-----+

mysql> select bitmap_min(bitmap_from_string('1,999999999')) value;
+-----+
| value |
+-----+
| 1 |
+-----+
```

### keywords

BITMAP\_MIN, BITMAP

# INTERSECT\_COUNT

## intersect\_count

### 描述

### 语法

BITMAP INTERSECT\_COUNT(bitmap\_column, column\_to\_filter, filter\_values) 聚合函数，求bitmap交集大小的函数，不要求数据分布正交 第一个参数是Bitmap列，第二个参数是用来过滤的维度列，第三个参数是变长参数，含义是过滤维度列的不同取值

### 举例

```
MySQL [test_query_qa]> select dt,bitmap_to_string(user_id) from pv_bitmap where dt in (3,4);
```

dt	bitmap_to_string(`user_id`)
4	1,2,3
3	1,2,3,4,5

2 rows in set (0.012 sec)

```
MySQL [test_query_qa]> select intersect_count(user_id,dt,3,4) from pv_bitmap;
```

intersect_count(`user_id`, `dt`, 3, 4)
3

1 row in set (0.014 sec)

### keywords

INTERSECT\_COUNT,BITMAP



# BITMAP\_INTERSECT

---

## bitmap\_intersect

### 描述

聚合函数，用于计算分组后的 bitmap 交集。常见使用场景如：计算用户留存率。

### 语法

BITMAP BITMAP\_INTERSECT(BITMAP value)

输入一组 bitmap 值，求这一组 bitmap 值的交集，并返回。

### 举例

表结构

```
KeyType: AGG_KEY
Columns: tag varchar, date datetime, user_id bitmap bitmap_union
```

求今天和昨天不同 tag 下的用户留存

```
mysql> select tag, bitmap_intersect(user_id) from (select tag, date, bitmap_union(user_id) user_id from table
where date in ('2020-05-18', '2020-05-19') group by tag, date) a group by tag;
```

和 bitmap\_to\_string 函数组合使用可以获取交集的具体数据

求今天和昨天不同 tag 下留存的用户都是哪些

```
mysql> select tag, bitmap_to_string(bitmap_intersect(user_id)) from (select tag, date, bitmap_union(user_id)
user_id from table where date in ('2020-05-18', '2020-05-19') group by tag, date) a group by tag;
```

### keywords

```
BITMAP_INTERSECT, BITMAP
```

# BITMAP\_HASH64

---

## bitmap\_hash64

### 描述

### 语法

BITMAP BITMAP\_HASH64(expr)

对任意类型的输入计算64位的哈希值，返回包含该哈希值的bitmap。主要用于stream load任务将非整型字段导入Doris表的bitmap字段。例如

```
cat data | curl --location-trusted -u user:passwd -T - -H "columns: dt,page,device_id,device_id=bitmap_hash64(device_id)" http://host:8410/api/test/testDb/_stream_load
```

### 举例

```
mysql> select bitmap_to_string(bitmap_hash64('hello'));
+-----+
| bitmap_to_string(bitmap_hash64('hello')) |
+-----+
| 15231136565543391023 |
+-----+
```

### keywords

BITMAP\_HASH, BITMAP

# BITMAP\_FROM\_BASE64

---

## bitmap\_from\_base64

### 描述

### 语法

BITMAP BITMAP\_FROM\_BASE64(VARCHAR input)

将一个base64字符串(bitmap\_to\_base64函数的结果)转化为一个BITMAP。当输入字符串不合法时，返回NULL。

### 举例

```
mysql> select bitmap_to_string(bitmap_from_base64("AA=="));
+-----+
| bitmap_to_string(bitmap_from_base64("AA==")) |
+-----+
| |
+-----+

mysql> select bitmap_to_string(bitmap_from_base64("AQEAAAA="));
+-----+
| bitmap_to_string(bitmap_from_base64("AQEAAAA=")) |
+-----+
| 1 |
+-----+

mysql> select bitmap_to_string(bitmap_from_base64("AjowAAACAAAAAAAAAJgAAAAAYAAAAGgAAAAEaf5Y="));
+-----+
| bitmap_to_string(bitmap_from_base64("AjowAAACAAAAAAAAAJgAAAAAYAAAAGgAAAAEaf5Y=")) |
+-----+
| 1,99999999 |
+-----+
```

### keywords

BITMAP\_FROM\_BASE64,BITMAP

# BITMAP\_TO\_BASE64

---

## bitmap\_to\_base64

### 描述

### 语法

VARCHAR BITMAP\_TO\_BASE64(BITMAP input)

将一个bitmap转化成一个base64字符串。输入是null的话返回null。BE配置项enable\_set\_in\_bitmap\_value会改变bitmap值在内存中的具体格式，因此会影响此函数的结果。

### 举例

```
mysql> select bitmap_to_base64(null);
+-----+
| bitmap_to_base64(NULL) |
+-----+
| NULL |
+-----+

mysql> select bitmap_to_base64(bitmap_empty());
+-----+
| bitmap_to_base64(bitmap_empty()) |
+-----+
| AA== |
+-----+

mysql> select bitmap_to_base64(to_bitmap(1));
+-----+
| bitmap_to_base64(to_bitmap(1)) |
+-----+
| AQEAAAA= |
+-----+

mysql> select bitmap_to_base64(bitmap_from_string("1,9999999"));
+-----+
| bitmap_to_base64(bitmap_from_string("1,9999999")) |
+-----+
| AjowAAACAAAAAAAAAJgAAAAAYAAAGgAAAAEAf5Y= |
+-----+
```

### keywords

BITMAP\_TO\_BASE64,BITMAP

# BITMAP\_REMOVE

---

## bitmap\_remove

### 描述

### 语法

BITMAP BITMAP\_REMOVE(BITMAP bitmap, BIGINT input)

从Bitmap列中删除指定的值。

### 举例

```
mysql [(none)]>select bitmap_to_string(bitmap_remove(bitmap_from_string('1, 2, 3'), 3)) res;
+-----+
| res |
+-----+
| 1,2 |
+-----+

mysql [(none)]>select bitmap_to_string(bitmap_remove(bitmap_from_string('1, 2, 3'), null)) res;
+-----+
| res |
+-----+
| NULL |
+-----+
```

### keywords

BITMAP\_REMOVE, BITMAP

# BITAND

---

## bitand

### 描述

### 语法

BITAND(Integer-type lhs, Integer-type rhs)

返回两个整数与运算的结果。

整数范围：TINYINT、SMALLINT、INT、BIGINT、LARGEINT

### 举例

```
mysql> select bitand(3,5) ans;
```

```
+-----+
| ans |
+-----+
| 1 |
+-----+
```

```
mysql> select bitand(4,7) ans;
```

```
+-----+
| ans |
+-----+
| 4 |
+-----+
```

### keywords

BITAND

# BITOR

---

## bitor

## 描述

## 语法

BITOR(Integer-type lhs, Integer-type rhs)

返回两个整数或运算的结果.

整数范围: TINYINT、SMALLINT、INT、BIGINT、LARGEINT

## 举例

```
mysql> select bitor(3,5) ans;
```

```
+-----+
| ans |
+-----+
| 7 |
+-----+
```

```
mysql> select bitor(4,7) ans;
```

```
+-----+
| ans |
+-----+
| 7 |
+-----+
```

## keywords

BITOR

# BITXOR

---

## bitxor

### 描述

### 语法

BITXOR(Integer-type lhs, Integer-type rhs)

返回两个整数异或运算的结果.

整数范围: TINYINT、SMALLINT、INT、BIGINT、LARGEINT

### 举例

```
mysql> select bitxor(3,5) ans;
```

```
+-----+
| ans |
+-----+
| 7 |
+-----+
```

```
mysql> select bitxor(1,7) ans;
```

```
+-----+
| ans |
+-----+
| 6 |
+-----+
```

### keywords

BITXOR



# BITNOT

---

## bitnot

## 描述

## 语法

BITNOT(Integer-type value)

返回一个整数取反运算的结果.

整数范围: TINYINT、SMALLINT、INT、BIGINT、LARGEINT

## 举例

```
mysql> select bitnot(7) ans;
+-----+
| ans |
+-----+
| -8 |
+-----+

mysql> select bitxor(-127) ans;
+-----+
| ans |
+-----+
| 126 |
+-----+
```

## keywords

BITNOT

# CASE

---

## case

### 描述

### 语法

```
CASE expression
 WHEN condition1 THEN result1
 [WHEN condition2 THEN result2]
 ...
 [WHEN conditionN THEN resultN]
 [ELSE result]
END
```

### OR

```
CASE WHEN condition1 THEN result1
 [WHEN condition2 THEN result2]
 ...
 [WHEN conditionN THEN resultN]
 [ELSE result]
END
```

将表达式和多个可能的值进行比较，当匹配时返回相应的结果

### 举例

```
mysql> select user_id, case user_id when 1 then 'user_id = 1' when 2 then 'user_id = 2' else 'user_id not exist' end test_case from test;
+-----+-----+
| user_id | test_case |
+-----+-----+
| 1 | user_id = 1 |
| 2 | user_id = 2 |
+-----+-----+

mysql> select user_id, case when user_id = 1 then 'user_id = 1' when user_id = 2 then 'user_id = 2' else 'user_id not exist' end test_case from test;
+-----+-----+
| user_id | test_case |
+-----+-----+
| 1 | user_id = 1 |
| 2 | user_id = 2 |
+-----+-----+
```

## keywords

CASE

# COALESCE

## 描述

返回参数列表中从左到右第一个非空表达式。如果所有参数都为 NULL，则返回 NULL。

## 语法

```
COALESCE(<expr> [, ...])
```

## 参数

参数	说明
<expr>	需要逐个检查的表达式序列，所有表达式必须具有兼容的数据类型。

## 返回值

参数列表中第一个非空表达式。如果所有参数都为 NULL，则返回 NULL。

## 示例

```
SELECT COALESCE(NULL, '1111', '0000');
```

```
+-----+
| coalesce(NULL, '1111', '0000') |
+-----+
| 1111 |
+-----+
```

# IF

## 描述

如果表达式 <condition> 成立，则返回 <value\_true>；否则返回 <value\_false\_or\_null>。  
返回类型：<value\_true> 表达式的结果类型。

## 语法

```
IF(<condition>, <value_true>, <value_false_or_null>)
```

## 参数

参数	说明
<condition>	用于判断的布尔表达式。
<value_true>	当 <condition> 为真时返回的值。
<value_false_or_null>	当 <condition> 为假时返回的值。

## 举例

```
SELECT user_id, IF(user_id = 1, "true", "false") AS test_if FROM test;
```

```
+-----+-----+
| user_id | test_if |
+-----+-----+
| 1 | true |
| 2 | false |
+-----+-----+
```

# IFNULL

## 描述

如果 <expr1> 的值不为 NULL，则返回 <expr1>；否则返回 <expr2>。

## 别名

- NVL

## 语法

```
IFNULL(<expr1>, <expr2>)
```

## 参数

参数	描述
<expr1>	需要判断是否为 NULL 的表达式。
<expr2>	<expr1> 为 NULL 时返回的值。

## 返回值

- 如果 <expr1> 不为 NULL，则返回 <expr1>。
- 否则，返回 <expr2>。

## 举例

```
SELECT IFNULL(1, 0);
```

1
---

```
SELECT IFNULL(NULL, 10);
```

10
----

# NVL

---

## nvl

nvl

## 描述

## 语法

`nvl(expr1, expr2)`

如果 `expr1` 的值不为 `NULL` 则返回 `expr1`，否则返回 `expr2`

## 举例

```
mysql> select nvl(1,0);
+-----+
| nvl(1, 0) |
+-----+
| 1 |
+-----+

mysql> select nvl(null,10);
+-----+
| nvl(NULL, 10) |
+-----+
| 10 |
+-----+
```

## keywords

NVL

# NULLIF

## 描述

如果两个输入值相等，则返回 NULL；否则返回第一个输入值。该函数等价于以下 CASE WHEN 表达式：

```
CASE
 WHEN <expr1> = <expr2> THEN NULL
 ELSE <expr1>
END
```

## 语法

```
NULLIF(<expr1>, <expr2>)
```

## 参数

参数	说明
<expr1>	需要进行比较的第一个输入值。
<expr2>	需要与第一个输入值进行比较的第二个值。

## 返回值

- 如果 <expr1> 等于 <expr2>，则返回 NULL。
- 否则，返回 <expr1> 的值。

## 举例

```
SELECT NULLIF(1, 1);
```

```
+-----+
| NULLIF(1, 1) |
+-----+
| NULL |
+-----+
```

```
SELECT NULLIF(1, 0);
```

```
+-----+
| NULLIF(1, 0) |
+-----+
| 1 |
+-----+
```

# JSON\_PARSE

## json\_parse

### 描述

### 语法

```
JSON json_parse(VARCHAR json_str)
JSON json_parse_error_to_null(VARCHAR json_str)
JSON json_parse_error_to_value(VARCHAR json_str, VARCHAR default_json_str)
```

将原始JSON字符串解析成JSON二进制格式。为了满足不同的异常数据处理需求，提供不同的json\_parse系列函数，具体行为如下： - json\_str为NULL时，都返回NULL - json\_str为非法JSON字符串时 - json\_parse报错 - json\_parse\_error\_to\_null返回NULL， - json\_parse\_error\_to\_value返回参数default\_json\_str指定的默认值

### 举例

#### 1. 正常JSON字符串解析

```
mysql> SELECT json_parse('{"k1":"v31","k2":300}');
+-----+
| json_parse('{"k1":"v31","k2":300}') |
+-----+
| {"k1":"v31","k2":300} |
+-----+
1 row in set (0.01 sec)
```

#### 2. 非法JSON字符串解析

```
mysql> SELECT json_parse('invalid json');
ERROR 1105 (HY000): errCode = 2, detailMessage = json parse error: Invalid document: document must be an object or an array for value: invalid json

mysql> SELECT json_parse_error_to_null('invalid json');
+-----+
| json_parse_error_to_null('invalid json') |
+-----+
| NULL |
+-----+
1 row in set (0.01 sec)

mysql> SELECT json_parse_error_to_value('invalid json', '{}');
+-----+
| json_parse_error_to_value('invalid json', '{}') |
+-----+
| {} |
+-----+
1 row in set (0.00 sec)
```



## **keywords**

JSONB, JSON, json\_parse, json\_parse\_error\_to\_null, json\_parse\_error\_to\_value

# JSON\_EXTRACT

## json\_extract

### 描述

### 语法

```
VARCHAR json_extract(VARCHAR json_str, VARCHAR path[, VARCHAR path] ...)
JSON jsonb_extract(JSON j, VARCHAR json_path)
BOOLEAN json_extract_isnull(JSON j, VARCHAR json_path)
BOOLEAN json_extract_bool(JSON j, VARCHAR json_path)
INT json_extract_int(JSON j, VARCHAR json_path)
BIGINT json_extract_bigint(JSON j, VARCHAR json_path)
LARGEINT json_extract_largeint(JSON j, VARCHAR json_path)
DOUBLE json_extract_double(JSON j, VARCHAR json_path)
STRING json_extract_string(JSON j, VARCHAR json_path)
```

json\_extract是一系列函数，从JSON类型的数据中提取json\_path指定的字段，根据要提取的字段类型不同提供不同的系列函数。 - json\_extract对VARCHAR类型的json string返回VARCHAR类型 - jsonb\_extract返回JSON类型 - json\_extract\_isnull返回是否为json null的BOOLEAN类型 - json\_extract\_bool返回BOOLEAN类型 - json\_extract\_int返回INT类型 - json\_extract\_bigint返回BIGINT类型 - json\_extract\_largeint返回LARGEINT类型 - json\_extract\_double返回DOUBLE类型 - json\_extract\_STRING返回STRING类型

json path的语法如下 - '\$' 代表json root - '.k1' 代表json object中key为'k1'的元素 - 如果 key 列值包含 ".", json\_path 中需要用双引号，例如 SELECT json\_extract('{\"k1.a\":\"abc\",\"k2\":300}', '\$.\"k1.a\"'); - '[i]' 代表json array 中下标为i的元素 - 获取 json\_array 的最后一个元素可以用'[last]'，倒数第二个元素可以用'[last-1]'，以此类推

特殊情况处理如下： - 如果 json\_path 指定的字段在JSON中不存在，返回NULL - 如果 json\_path 指定的字段在JSON中的实际类型和json\_extract\_t指定的类型不一致，如果能无损转换成指定类型返回指定类型t，如果不能则返回NULL

### 举例

参考 [json tutorial](#) 中的示例

```
mysql> SELECT json_extract('{\"id\": 123, \"name\": \"doris\"}', '$.id');
+-----+
| json_extract('{\"id\": 123, \"name\": \"doris\"}', '$.id') |
+-----+
| 123 |
+-----+
1 row in set (0.01 sec)

mysql> SELECT json_extract('[1, 2, 3]', '$.[1]');
+-----+
| json_extract('[1, 2, 3]', '$.[1]') |
+-----+
| 2 |
+-----+
1 row in set (0.01 sec)
```

```
mysql> SELECT json_extract('{ "k1": "v1", "k2": { "k21": 6.6, "k22": [1, 2] } }', '$.k1', '$.k2.k21',
'$.k2.k22', '$.k2.k22[1]');
+-----+
| json_extract('{ "k1": "v1", "k2": { "k21": 6.6, "k22": [1, 2] } }', '$.k1', '$.k2.k21', '$.k2.k22',
'$.k2.k22[1]') |
+-----+
| ["v1",6.6,[1,2],2] |
+-----+
1 row in set (0.01 sec)
```

```
mysql> SELECT json_extract('{ "id": 123, "name": "doris"}', '$.aaa', '$.name');
+-----+
| json_extract('{ "id": 123, "name": "doris"}', '$.aaa', '$.name') |
+-----+
| [null,"doris"] |
+-----+
1 row in set (0.01 sec)
```

## keywords

JSONB, JSON, json\_extract, json\_extract\_isnull, json\_extract\_bool, json\_extract\_int, json\_extract\_bigint, json\_extract\_largeint, json\_extract\_double, json\_extract\_string

# JSON\_EXISTS\_PATH

---

## json\_exists\_path

### 描述

用来判断json\_path指定的字段在JSON数据中是否存在，如果存在返回TRUE，不存在返回FALSE

### 语法

```
BOOLEAN json_exists_path(JSON j, VARCHAR json_path)
```

### 举例

参考 [json tutorial](#) 中的示例

### keywords

json\_exists\_path

# JSON\_TYPE

---

## jsonb\_type

### 描述

用来判断json\_path指定的字段在JSONB数据中的类型，如果字段不存在返回NULL，如果存在返回下面的类型之一

- object
- array
- null
- bool
- int
- bigint
- largeint
- double
- string

### 语法

```
STRING json_type(JSON j, VARCHAR json_path)
```

### 举例

参考 [json tutorial](#) 中的示例

### keywords

json\_type

# JSON\_ARRAY

---

## json\_array

### 描述

### 语法

VARCHAR json\_array(VARCHAR,...)

生成一个包含指定元素的json数组,未指定时返回空数组

### 举例

```
MySQL> select json_array();
+-----+
| json_array() |
+-----+
| [] |
+-----+

MySQL> select json_array(null);
+-----+
| json_array('NULL') |
+-----+
| [NULL] |
+-----+

MySQL> SELECT json_array(1, "abc", NULL, TRUE, CURTIME());
+-----+
| json_array(1, 'abc', 'NULL', TRUE, curtime()) |
+-----+
| [1, "abc", NULL, TRUE, "10:41:15"] |
+-----+

MySQL> select json_array("a", null, "c");
+-----+
| json_array('a', 'NULL', 'c') |
+-----+
| ["a", NULL, "c"] |
+-----+
```

### keywords

json,array,json\_array

# JSON\_OBJECT

---

## json\_object

### 描述

### 语法

VARCHAR json\_object(VARCHAR,...)

生成一个包含指定Key-Value对的json object, 当Key值为NULL或者传入参数为奇数个时, 返回异常错误

### 举例

```
MySQL> select json_object();
+-----+
| json_object() |
+-----+
| {} |
+-----+

MySQL> select json_object('time',curtime());
+-----+
| json_object('time', curtime()) |
+-----+
| {"time": "10:49:18"} |
+-----+

MySQL> SELECT json_object('id', 87, 'name', 'carrot');
+-----+
| json_object('id', 87, 'name', 'carrot') |
+-----+
| {"id": 87, "name": "carrot"} |
+-----+

MySQL> select json_object('username',null);
+-----+
| json_object('username', 'NULL') |
+-----+
| {"username": NULL} |
+-----+
```

### keywords

json,object,json\_object

# JSON\_QUOTE

---

## json\_quote

### 描述

### 语法

VARCHAR json\_quote(VARCHAR)

将json\_value用双引号（"）括起来，跳过其中包含的特殊转义字符

### 举例

```
MySQL> SELECT json_quote('null'), json_quote('"null"');
```

+-----+	
json_quote('null')	json_quote('"null"')
+-----+	
"null"	"\"null\""
+-----+	

```
MySQL> SELECT json_quote('[1, 2, 3]');
```

+-----+	
json_quote('[1, 2, 3]')	
+-----+	
"[1, 2, 3]"	
+-----+	

```
MySQL> SELECT json_quote(null);
```

+-----+	
json_quote(null)	
+-----+	
NULL	
+-----+	

```
MySQL> select json_quote("\n\b\r\t");
```

+-----+	
json_quote('\n\b\r\t')	
+-----+	
"\n\b\r\t"	
+-----+	

### keywords

json,quote,json\_quote



# JSON\_UNQUOTE

## json\_unquote

### 描述

### 语法

VARCHAR json\_unquote(VARCHAR)

这个函数将去掉 JSON 值中的引号，并将结果作为 utf8mb4 字符串返回。如果参数为 NULL，则返回 NULL。

在字符串中显示的如下转义序列将被识别，对于所有其他转义序列，反斜杠将被忽略。

转义序列	序列表示的字符
\"	双引号 "
\b	退格字符
\f	换页符
\n	换行符
\r	回车符
\t	制表符
\\	反斜杠 \
\uxxxx	Unicode 值 XXXX 的 UTF-8 字节

### 举例

```
mysql> SELECT json_unquote('\"doris\"');
+-----+
| json_unquote('\"doris\"') |
+-----+
| doris |
+-----+

mysql> SELECT json_unquote('[1, 2, 3]');
+-----+
| json_unquote('[1, 2, 3]') |
+-----+
| [1, 2, 3] |
+-----+

mysql> SELECT json_unquote(null);
+-----+
| json_unquote(NULL) |
+-----+
```

NULL	
+-----+	

```
mysql> SELECT json_unquote('"\ttest"');
+-----+
| json_unquote('"\ttest"') |
+-----+
| test |
+-----+
```

## keywords

json,unquote,json\_unquote

# JSON\_VALID

---

## json\_valid

### 描述

json\_valid 函数返回0或1以表明是否为有效的JSON, 如果参数是NULL则返回NULL。

### 语法

JSONB json\_valid(VARCHAR json\_str)

### 举例

#### 1. 正常JSON字符串

```
MySQL > SELECT json_valid('{"k1":"v31","k2":300}');
+-----+
| json_valid('{"k1":"v31","k2":300}') |
+-----+
| 1 |
+-----+
1 row in set (0.02 sec)
```

#### 2. 无效的JSON字符串

```
MySQL > SELECT json_valid('invalid json');
+-----+
| json_valid('invalid json') |
+-----+
| 0 |
+-----+
1 row in set (0.02 sec)
```

#### 3. NULL参数

```
MySQL > select json_valid(NULL);
+-----+
| json_valid(NULL) |
+-----+
| NULL |
+-----+
1 row in set (0.02 sec)
```

### keywords

JSON, VALID, JSON\_VALID

# JSON\_CONTAINS

## json\_contains

### 描述

### 语法

BOOLEAN json\_contains(JSON json\_str, JSON candidate)

BOOLEAN json\_contains(JSON json\_str, JSON candidate, VARCHAR json\_path)

BOOLEAN json\_contains(VARCHAR json\_str, VARCHAR candidate, VARCHAR json\_path)

通过返回 1 或 0 来指示给定的 candidate JSON 文档是否包含在 json\_str JSON json\_path 路径下的文档中

### 举例

```
mysql> SET @j = '{"a": 1, "b": 2, "c": {"d": 4}}';
mysql> SET @j2 = '1';
mysql> SELECT JSON_CONTAINS(@j, @j2, '$.a');
+-----+
| JSON_CONTAINS(@j, @j2, '$.a') |
+-----+
| 1 |
+-----+
mysql> SELECT JSON_CONTAINS(@j, @j2, '$.b');
+-----+
| JSON_CONTAINS(@j, @j2, '$.b') |
+-----+
| 0 |
+-----+

mysql> SET @j2 = '{"d": 4}';
mysql> SELECT JSON_CONTAINS(@j, @j2, '$.a');
+-----+
| JSON_CONTAINS(@j, @j2, '$.a') |
+-----+
| 0 |
+-----+
mysql> SELECT JSON_CONTAINS(@j, @j2, '$.c');
+-----+
| JSON_CONTAINS(@j, @j2, '$.c') |
+-----+
| 1 |
+-----+

mysql> SELECT json_contains('[1, 2, {"x": 3}]', '1');
+-----+
| json_contains('[1, 2, {"x": 3}]', '1') |
+-----+
| 1 |
+-----+
1 row in set (0.04 sec)
```

## keywords

json,json\_contains

# JSON\_LENGTH

## json\_length

### 描述

### 语法

INT json\_length(JSON json\_str)

INT json\_length(JSON json\_str, VARCHAR json\_path)

如果指定path，该JSON\_LENGTH()函数返回与 JSON 文档中的路径匹配的数据的长度，否则返回 JSON 文档的长度。该函数根据以下规则计算 JSON 文档的长度：

- 标量的长度为 1。例如：'1'，"x"，true，false，null 的长度均为 1。
- 数组的长度是数组元素的数量。例如：[1, 2] 的长度为2。
- 对象的长度是对象成员的数量。例如：{"x": 1} 的长度为1

### 举例

```
mysql> SELECT json_length('{\"k1\": \"v31\", \"k2\": 300}');
+-----+
| json_length('{\"k1\": \"v31\", \"k2\": 300}') |
+-----+
| 2 |
+-----+
1 row in set (0.26 sec)

mysql> SELECT json_length('\"abc\"');
+-----+
| json_length('\"abc\"') |
+-----+
| 1 |
+-----+
1 row in set (0.17 sec)

mysql> SELECT json_length('{\"x\": 1, \"y\": [1, 2]}', '$.y');
+-----+
| json_length('{\"x\": 1, \"y\": [1, 2]}', '$.y') |
+-----+
| 2 |
+-----+
1 row in set (0.07 sec)
```

### keywords

json,json\_length

# GET\_JSON\_DOUBLE

## get\_json\_double

### 描述

### 语法

DOUBLE get\_json\_double(VARCHAR json\_str, VARCHAR json\_path)

解析并获取 json 字符串内指定路径的浮点型内容。其中 json\_path 必须以 \$ 符号作为开头，使用 . 作为路径分割符。如果路径中包含 .，则可以使用双引号包围。使用 [] 表示数组下标，从 0 开始。path 的内容不能包含 “，[ 和 ]”。如果 json\_string 格式不对，或 json\_path 格式不对，或无法找到匹配项，则返回 NULL。

另外，推荐使用 jsonb 类型和 jsonb\_extract\_XXX 函数实现同样的功能。

特殊情况处理如下：- 如果 json\_path 指定的字段在 JSON 中不存在，返回 NULL - 如果 json\_path 指定的字段在 JSON 中的实际类型和 json\_extract\_t 指定的类型不一致，如果能无损转换成指定类型返回指定类型 t，如果不能则返回 NULL

### 举例

#### 1. 获取 key 为 “k1” 的 value

```
mysql> SELECT get_json_double('{"k1":1.3, "k2":"2"}', "$.k1");
+-----+
| get_json_double('{"k1":1.3, "k2":"2"}', '$.k1') |
+-----+
| 1.3 |
+-----+
```

#### 2. 获取 key 为 “my.key” 的数组中第二个元素

```
mysql> SELECT get_json_double('{"k1":"v1", "my.key":[1.1, 2.2, 3.3]}', '$."my.key"[1]');
+-----+
| get_json_double('{"k1":"v1", "my.key":[1.1, 2.2, 3.3]}', '$."my.key"[1]') |
+-----+
| 2.2 |
+-----+
```

#### 3. 获取二级路径为 k1.key -> k2 的数组中，第一个元素

```
mysql> SELECT get_json_double('{"k1.key":{"k2":[1.1, 2.2]}}', '$."k1.key".k2[0]');
+-----+
| get_json_double('{"k1.key":{"k2":[1.1, 2.2]}}', '$."k1.key".k2[0]') |
+-----+
| 1.1 |
+-----+
```

**keywords**

GET\_JSON\_DOUBLE,GET,JSON,DOUBLE



# GET\_JSON\_INT

## get\_json\_int

### 描述

### 语法

INT get\_json\_int(VARCHAR json\_str, VARCHAR json\_path)

解析并获取 json 字符串内指定路径的整型内容。其中 json\_path 必须以 \$ 符号作为开头，使用 . 作为路径分割符。如果路径中包含 .，则可以使用双引号包围。使用 [] 表示数组下标，从 0 开始。path 的内容不能包含 “, [ 和 ]”。如果 json\_string 格式不对，或 json\_path 格式不对，或无法找到匹配项，则返回 NULL。

另外，推荐使用 jsonb 类型和 jsonb\_extract\_XXX 函数实现同样的功能。

特殊情况处理如下： - 如果 json\_path 指定的字段在 JSON 中不存在，返回 NULL - 如果 json\_path 指定的字段在 JSON 中的实际类型和 json\_extract\_t 指定的类型不一致，如果能无损转换成指定类型返回指定类型 t，如果不能则返回 NULL

### 举例

#### 1. 获取 key 为 “k1” 的 value

```
mysql> SELECT get_json_int('{\"k1\":1, \"k2\":\"2\"}', '$.k1');
+-----+
| get_json_int('{\"k1\":1, \"k2\":\"2\"}', '$.k1') |
+-----+
| 1 |
+-----+
```

#### 2. 获取 key 为 “my.key” 的数组中第二个元素

```
mysql> SELECT get_json_int('{\"k1\":\"v1\", \"my.key\":[1, 2, 3]}', '$.\"my.key\"[1]');
+-----+
| get_json_int('{\"k1\":\"v1\", \"my.key\":[1, 2, 3]}', '$.\"my.key\"[1]') |
+-----+
| 2 |
+-----+
```

#### 3. 获取二级路径为 k1.key -> k2 的数组中，第一个元素

```
mysql> SELECT get_json_int('{\"k1.key\":{\"k2\":[1, 2]}}', '$.\"k1.key\".k2[0]');
+-----+
| get_json_int('{\"k1.key\":{\"k2\":[1, 2]}}', '$.\"k1.key\".k2[0]') |
+-----+
| 1 |
+-----+
```

## keywords

GET\_JSON\_INT,GET,JSON,INT

# GET\_JSON\_BIGINT

## get\_json\_bigint

### 描述

### 语法

```
INT get_json_bigint(VARCHAR json_str, VARCHAR json_path)
```

解析并获取 json 字符串内指定路径的整型(BIGINT)内容。其中 json\_path 必须以 \$ 符号作为开头，使用 . 作为路径分割符。如果路径中包含 .，则可以使用双引号包围。使用 [] 表示数组下标，从 0 开始。path 的内容不能包含 ,, [ 和 ]。如果 json\_string 格式不对，或 json\_path 格式不对，或无法找到匹配项，则返回 NULL。

另外，推荐使用jsonb类型和jsonb\_extract\_XXX函数实现同样的功能。

特殊情况处理如下： - 如果 json\_path 指定的字段在JSON中不存在，返回NULL - 如果 json\_path 指定的字段在JSON中的实际类型和json\_extract\_t指定的类型不一致，如果能无损转换成指定类型返回指定类型t，如果不能则返回NULL

### 举例

#### 1. 获取 key 为 “k1” 的 value

```
mysql> SELECT get_json_bigint('{"k1":1, "k2":"2"}', "$.k1");
+-----+
| get_json_bigint('{"k1":1, "k2":"2"}', '$.k1') |
+-----+
| 1 |
+-----+
```

#### 2. 获取 key 为 “my.key” 的数组中第二个元素

```
mysql> SELECT get_json_bigint('{"k1":"v1", "my.key":[1, 1678708107000, 3]}', '$."my.key"[1]');
+-----+
| get_json_bigint('{"k1":"v1", "my.key":[1, 1678708107000, 3]}', '$."my.key"[1]') |
+-----+
| 1678708107000 |
+-----+
```

#### 3. 获取二级路径为 k1.key -> k2 的数组中，第一个元素

```
mysql> SELECT get_json_bigint('{"k1.key":{"k2":[1678708107000, 2]}}', '$."k1.key".k2[0]');
+-----+
| get_json_bigint('{"k1.key":{"k2":[1678708107000, 2]}}', '$."k1.key".k2[0]') |
+-----+
| 1678708107000 |
+-----+
```

## keywords

GET\_JSON\_BIGINT,GET,JSON,BIGINT

# GET\_JSON\_STRING

## get\_json\_string

### 描述

### 语法

VARCHAR get\_json\_string(VARCHAR json\_str, VARCHAR json\_path)

解析并获取 json 字符串内指定路径的字符串内容。其中 json\_path 必须以 \$ 符号作为开头，使用 . 作为路径分割符。如果路径中包含 .，则可以使用双引号包围。使用 [] 表示数组下标，从 0 开始。path 的内容不能包含 “，[ 和 ]”。如果 json\_string 格式不对，或 json\_path 格式不对，或无法找到匹配项，则返回 NULL。

另外，推荐使用 jsonb 类型和 jsonb\_extract\_XXX 函数实现同样的功能。

特殊情况处理如下： - 如果 json\_path 指定的字段在 JSON 中不存在，返回 NULL - 如果 json\_path 指定的字段在 JSON 中的实际类型和 json\_extract\_t 指定的类型不一致，如果能无损转换成指定类型返回指定类型 t，如果不能则返回 NULL

### 举例

#### 1. 获取 key 为 “k1” 的 value

```
mysql> SELECT get_json_string('{"k1":"v1", "k2":"v2"}', "$.k1");
+-----+
| get_json_string('{"k1":"v1", "k2":"v2"}', '$.k1') |
+-----+
| v1 |
+-----+
```

#### 2. 获取 key 为 “my.key” 的数组中第二个元素

```
mysql> SELECT get_json_string('{"k1":"v1", "my.key":["e1", "e2", "e3"]}', '$."my.key"[1]');
+-----+
| get_json_string('{"k1":"v1", "my.key":["e1", "e2", "e3"]}', '$."my.key"[1]') |
+-----+
| e2 |
+-----+
```

#### 3. 获取二级路径为 k1.key -> k2 的数组中，第一个元素

```
mysql> SELECT get_json_string('{"k1.key":{"k2":["v1", "v2"]}}', '$."k1.key".k2[0]');
+-----+
| get_json_string('{"k1.key":{"k2":["v1", "v2"]}}', '$."k1.key".k2[0]') |
+-----+
| v1 |
+-----+
```

#### 4. 获取数组中，key 为 “k1” 的所有 value

```
mysql> SELECT get_json_string('[{"k1":"v1"}, {"k2":"v2"}, {"k1":"v3"}, {"k1":"v4"}]', '$.k1');
+-----+
| get_json_string('[{"k1":"v1"}, {"k2":"v2"}, {"k1":"v3"}, {"k1":"v4"}]', '$.k1') |
+-----+
| ["v1","v3","v4"] |
+-----+
```

#### keywords

GET\_JSON\_STRING,GET,JSON,STRING

# JSON\_INSERT

## json\_insert

### 描述

### 语法

VARCHAR json\_insert(VARCHAR json\_str, VARCHAR path, VARCHAR val[, VARCHAR path, VARCHAR val] ...)

json\_set 函数在 JSON 中插入数据并返回结果。如果 json\_str 或 path 为 NULL，则返回 NULL。否则，如果 json\_str 不是有效的 JSON 或任何 path 参数不是有效的路径表达式或包含了 \* 通配符，则会返回错误。

路径值对按从左到右的顺序进行评估。

如果 JSON 中不存在该路径，则路径值对会添加该值到 JSON 中，如果路径标识某个类型的值，则：

- 对于现有对象中不存在的成员，会将新成员添加到该对象中并与新值相关联。
- 对于现有数组结束后的位置，该数组将扩展为包含新值。如果现有值不是数组，则自动转换为数组，然后再扩展为包含新值的数组。

否则，对于 JSON 中不存在的某个路径的路径值对将被忽略且不会产生任何影响。

### 举例

```
MySQL> select json_insert(null, null, null);
+-----+
| json_insert(NULL, NULL, 'NULL') |
+-----+
| NULL |
+-----+

MySQL> select json_insert('{\"k\": 1}', \"$.k\", 2);
+-----+
| json_insert('{\"k\": 1}', '$.k', '2') |
+-----+
| {\"k\":1} |
+-----+

MySQL> select json_insert('{\"k\": 1}', \"$.j\", 2);
+-----+
| json_insert('{\"k\": 1}', '$.j', '2') |
+-----+
| {\"k\":1,\"j\":2} |
+-----+
```

### keywords

JSON, json\_insert

# JSON\_REPLACE

---

## json\_replace

### 描述

### 语法

VARCHAR json\_replace(VARCHAR json\_str, VARCHAR path, VARCHAR val[, VARCHAR path, VARCHAR val] ...)

json\_set 函数在 JSON 中更新数据并返回结果。如果 json\_str 或 path 为 NULL，则返回 NULL。否则，如果 json\_str 不是有效的 JSON 或任何 path 参数不是有效的路径表达式或包含了 \* 通配符，则会返回错误。

路径值对按从左到右的顺序进行评估。

如果 JSON 中已存在某个路径，则路径值对会将现有 JSON 值覆盖为新值。否则，对于 JSON 中不存在的某个路径的路径值对将被忽略且不会产生任何影响。

### 举例

```
MySQL> select json_replace(null, null, null);
+-----+
| json_replace(NULL, NULL, 'NULL') |
+-----+
| NULL |
+-----+

MySQL> select json_replace('{\"k\": 1}', \"$.k\", 2);
+-----+
| json_replace('{\"k\": 1}', '$.k', '2') |
+-----+
| {\"k\":2} |
+-----+

MySQL> select json_replace('{\"k\": 1}', \"$.j\", 2);
+-----+
| json_replace('{\"k\": 1}', '$.j', '2') |
+-----+
| {\"k\":1} |
+-----+
```

### keywords

JSON, json\_replace



# JSON\_SET

## json\_set

### 描述

### 语法

VARCHAR json\_set(VARCHAR json\_str, VARCHAR path, VARCHAR val[, VARCHAR path, VARCHAR val] ...)

json\_set 函数在 JSON 中插入或更新数据并返回结果。如果 json\_str 或 path 为 NULL，则返回 NULL。否则，如果 json\_str 不是有效的 JSON 或任何 path 参数不是有效的路径表达式或包含了 \* 通配符，则会返回错误。

路径值对按从左到右的顺序进行评估。

如果 JSON 中已存在某个路径，则路径值对会将现有 JSON 值覆盖为新值。如果 JSON 中不存在该路径，则路径值对会添加该值到 JSON 中，如果路径标识某个类型的值，则：

- 对于现有对象中不存在的成员，会将新成员添加到该对象中并与新值相关联。
- 对于现有数组结束后的位置，该数组将扩展为包含新值。如果现有值不是数组，则自动转换为数组，然后再扩展为包含新值的数组。

否则，对于 JSON 中不存在的某个路径的路径值对将被忽略且不会产生任何影响。

### 举例

```
MySQL> select json_set(null, null, null);
+-----+
| json_set(NULL, NULL, 'NULL') |
+-----+
| NULL |
+-----+

MySQL> select json_set('{\"k\": 1}', \"$.k\", 2);
+-----+
| json_set('{\"k\": 1}', '$.k', '2') |
+-----+
| {\"k\":2} |
+-----+

MySQL> select json_set('{\"k\": 1}', \"$.j\", 2);
+-----+
| json_set('{\"k\": 1}', '$.j', '2') |
+-----+
| {\"k\":1,\"j\":2} |
+-----+
```

## keywords

JSON, json\_set

# MAP

---

## 描述

## 语法

MAP<K, V> map(K key0, V value0, K key1, V value1, ..., K keyn, V valuen)

使用若干组键值对构造一个特定类型的 Map<K, V>

## 举例

```
mysql> select map(1, "100", 0.1, 2);
+-----+
| map(cast(1 as DECIMALV3(2, 1)), '100', cast(0.1 as DECIMALV3(2, 1)), cast(2 as TEXT)) |
+-----+
| {1.0:"100", 0.1:"2"} |
+-----+
1 row in set (0.16 sec)

mysql> select map(1, "100", 0.1, 2)[1];
+-----+
| element_at(map(cast(1 as DECIMALV3(2, 1)), '100', cast(0.1 as DECIMALV3(2, 1)), cast(2 as TEXT)), cast(1 as DECIMALV3(2, 1))) |
+-----+
| 100 |
+-----+
1 row in set (0.16 sec)
```

## Keywords

MAP

# MAP\_KEYS

---

## 描述

## 语法

ARRAY<K> map\_keys(Map<K, V> map)

将给定 map 的键提取成一个对应类型的 ARRAY

## 举例

```
mysql> select map_keys(map(1, "100", 0.1, 2));
+-----+
| map_keys(map(cast(1 as DECIMALV3(2, 1)), '100', cast(0.1 as DECIMALV3(2, 1)), cast(2 as TEXT))) |
+-----+
| [1.0, 0.1] |
+-----+
1 row in set (0.15 sec)

mysql> select map_keys(map());
+-----+
| map_keys(map()) |
+-----+
| [] |
+-----+
1 row in set (0.12 sec)
```

## Keywords

MAP, KEYS, MAP\_KEYS

# MAP\_VALUES

---

## 描述

## 语法

ARRAY<K> map\_values(Map<K, V> map)

将给定 map 的值提取成一个对应类型的 ARRAY

## 举例

```
mysql> select map_values(map(1, "100", 0.1, 2));
+-----+
| map_values(map(cast(1 as DECIMALV3(2, 1)), '100', cast(0.1 as DECIMALV3(2, 1)), cast(2 as TEXT))) |
+-----+
| ["100", "2"] |
+-----+
1 row in set (0.12 sec)

mysql> select map_values(map());
+-----+
| map_values(map()) |
+-----+
| [] |
+-----+
1 row in set (0.11 sec)
```

## Keywords

MAP, VALUES, MAP\_VALUES

# MAP\_CONTAINS\_KEY

## 描述

## 语法

BOOLEAN map\_contains\_key(Map<K, V> map, K key)

判断给定 map 中是否包含特定的键 key

## 举例

```
mysql> select map_contains_key(map(1, "100", 0.1, 2), "1");
+-----+
| map_contains_key(cast(map(cast(1 as DECIMALV3(2, 1)), '100', cast(0.1 as DECIMALV3(2, 1)), cast(2 as TEXT)) as MAP<DECIMALV3(38, 9),VARCHAR(3)>), cast('1' as DECIMALV3(38, 9))) |
+-----+
|
1 |
+-----+

1 row in set (0.17 sec)

mysql> select map_contains_key(map(1, "100", 0.1, 2), "abc");
+-----+
| map_contains_key(cast(map(cast(1 as DECIMALV3(2, 1)), '100', cast(0.1 as DECIMALV3(2, 1)), cast(2 as TEXT)) as MAP<DECIMALV3(38, 9),VARCHAR(3)>), cast('abc' as DECIMALV3(38, 9))) |
+-----+
|
0 |
+-----+

1 row in set (0.16 sec)

mysql> select map_contains_key(map(1, "100", 0.1, 2), 0.11);
+-----+
| map_contains_key(cast(map(cast(1 as DECIMALV3(2, 1)), '100', cast(0.1 as DECIMALV3(2, 1)), cast(2 as TEXT)) as MAP<DECIMALV3(3, 2),VARCHAR(3)>), cast(0.11 as DECIMALV3(3, 2))) |
+-----+
|
0 |
+-----+

1 row in set (0.15 sec)

mysql> select map_contains_key(map(null, 1, 2, null), null);
+-----+
| map_contains_key(map(NULL, 1, 2, NULL), NULL) |
+-----+
|
1 |
```

+-----+  
1 row in set (0.14 sec)

## Keywords

MAP, CONTAINS, KEY, MAP\_CONTAINS\_KEY

# MAP\_CONTAINS\_VALUE

## 描述

## 语法

BOOLEAN map\_contains\_value(Map<K, V> map, V value)

判断给定 map 中是否包含特定的值 value

## 举例

```
mysql> select map_contains_key(map(1, "100", 0.1, 2), "1");
+-----+
| map_contains_key(cast(map(cast(1 as DECIMALV3(2, 1)), '100', cast(0.1 as DECIMALV3(2, 1)), cast(2 as TEXT)) as MAP<DECIMALV3(38, 9),VARCHAR(3)>), cast('1' as DECIMALV3(38, 9))) |
+-----+
|
1 |
+-----+
1 row in set (0.17 sec)

mysql> select map_contains_key(map(1, "100", 0.1, 2), "abc");
+-----+
| map_contains_key(cast(map(cast(1 as DECIMALV3(2, 1)), '100', cast(0.1 as DECIMALV3(2, 1)), cast(2 as TEXT)) as MAP<DECIMALV3(38, 9),VARCHAR(3)>), cast('abc' as DECIMALV3(38, 9))) |
+-----+
|
0 |
+-----+
1 row in set (0.16 sec)

mysql> select map_contains_key(map(1, "100", 0.1, 2), 0.11);
+-----+
| map_contains_key(cast(map(cast(1 as DECIMALV3(2, 1)), '100', cast(0.1 as DECIMALV3(2, 1)), cast(2 as TEXT)) as MAP<DECIMALV3(3, 2),VARCHAR(3)>), cast(0.11 as DECIMALV3(3, 2))) |
+-----+
|
0 |
+-----+
1 row in set (0.15 sec)

mysql> select map_contains_value(map(1, "100", 0.1, 2), 100.0);
+-----+
| map_contains_value(map(cast(1 as DECIMALV3(2, 1)), '100', cast(0.1 as DECIMALV3(2, 1)), cast(2 as TEXT)), cast(100.0 as VARCHAR(3))) |
+-----+
```



```

-----+
|
1 |
-----+
1 row in set (0.16 sec)

mysql> select map_contains_value(map(1, "100", 0.1, 2), 101);
-----+
| map_contains_value(map(cast(1 as DECIMALV3(2, 1)), '100', cast(0.1 as DECIMALV3(2, 1)), cast(2 as TEXT)),
cast(101 as VARCHAR(3))) |
-----+
|
0 |
-----+
1 row in set (0.14 sec)

mysql> select map_contains_value(map(null, 1, 2, null), null);
-----+
| map_contains_value(map(NULL, 1, 2, NULL), NULL) |
-----+
| 1 |
-----+
1 row in set (0.15 sec)

```

## Keywords

MAP, CONTAINS, VALUE, MAP\_CONTAINS\_VALUE

# MURMUR\_HASH3\_32

---

## murmur\_hash3\_32

### 描述

### 语法

INT MURMUR\_HASH3\_32(VARCHAR input, ...)

返回输入字符串的32位murmur3 hash值

### 举例

```
mysql> select murmur_hash3_32(null);
+-----+
| murmur_hash3_32(NULL) |
+-----+
| NULL |
+-----+

mysql> select murmur_hash3_32("hello");
+-----+
| murmur_hash3_32('hello') |
+-----+
| 1321743225 |
+-----+

mysql> select murmur_hash3_32("hello", "world");
+-----+
| murmur_hash3_32('hello', 'world') |
+-----+
| 984713481 |
+-----+
```

### keywords

MURMUR\_HASH3\_32,HASH

# MURMUR\_HASH3\_64

---

## murmur\_hash3\_64

### 描述

### 语法

`BIGINT MURMUR_HASH3_64(VARCHAR input, ...)`

返回输入字符串的64位murmur3 hash值

### 举例

```
mysql> select murmur_hash3_64(null);
+-----+
| murmur_hash3_64(NULL) |
+-----+
| NULL |
+-----+

mysql> select murmur_hash3_64("hello");
+-----+
| murmur_hash3_64('hello') |
+-----+
| -3215607508166160593 |
+-----+

mysql> select murmur_hash3_64("hello", "world");
+-----+
| murmur_hash3_64('hello', 'world') |
+-----+
| 3583109472027628045 |
+-----+
```

### keywords

MURMUR\_HASH3\_64, HASH

# HLL\_CARDINALITY

## 描述

HLL\_CARDINALITY 用于计算 HLL（HyperLogLog）类型值的基数。HLL 是一种近似计数的算法，适用于大规模数据集的基数估算。

## 语法

```
HLL_CARDINALITY(<hll>)
```

## 参数

参数	说明
<hll>	HLL 类型的值，表示需要计算基数的数据集。

## 返回值

返回 HLL 类型值的基数，即数据集中不重复元素的估算数。

## 举例

```
select HLL_CARDINALITY(uv_set) from test_uv;
```

+-----+
hll_cardinality(`uv_set`)
+-----+
3
+-----+

# HLL\_EMPTY

---

## 描述

HLL\_EMPTY 用于返回一个 HLL（HyperLogLog）类型的空值，表示一个没有任何元素的数据集合。

## 语法

```
HLL_EMPTY()
```

## 返回值

返回一个 HLL 类型的空值，表示一个没有任何元素的数据集合。

## 举例

```
select hll_cardinality(hll_empty());
```

```
+-----+
| hll_cardinality(hll_empty()) |
+-----+
| 0 |
+-----+
```

# HLL\_HASH

## 描述

将一个值转换为 HLL（HyperLogLog）类型。该函数通常用于数据加载时，将普通类型的值转换为 HLL 类型，常用于处理大数据集的去重和计数操作。

特殊情况： - 如果输入值为 NULL，则返回 NULL。

## 语法

```
HLL_HASH(<value>)
```

## 参数

参数	说明
<value>	需要转换为 HLL 类型的值。可以是字符串、数字或任意数据类型。

## 返回值

返回一个 HLL 类型的值。返回结果类型为 HLL。

## 举例

```
select HLL_CARDINALITY(HLL_HASH('abc'));
```

hll_cardinality(HLL_HASH('abc'))
1

# CONV

## 描述

对输入的数字进行进制转换

## 语法

```
CONV(<input>, <from_base>, <to_base>)
```

## 参数

参数	说明
<input>	需要进行进制转换的参数，可为字符串或整数
<from_base>	数字，原始进制，范围应在 [2,36] 以内
<to_base>	数字，目标进制，范围应在 [2,36] 以内

## 返回值

转换后目标进制 <to\_base> 下的数字，以字符串形式返回。

## 举例

```
SELECT CONV(15,10,2);
```

```
+-----+
| conv(15, 10, 2) |
+-----+
| 1111 |
+-----+
```

```
SELECT CONV('ff',16,10);
```

```
+-----+
| conv('ff', 16, 10) |
+-----+
| 255 |
+-----+
```

```
SELECT CONV(230,10,16);
```

```
+-----+
| conv(230, 10, 16) |
```

-----+  
| E6 |  
-----+



# BIN

### 描述

将十进制数字转换为二进制文本。

## 语法

```
bin(<a>)
```

## 参数

参数	说明
<a>	需要转换的十进制值

## 返回值

参数 <a> 的二进制表示。当 <a> 为负数时，结果为其 64 位补码表示。

## 举例

```
select bin(0);
```

```

+-----+
| bin(0) |
+-----+
| 0 |
+-----+

```

```
select bin(-1);
```

[illegible]

```
select bin(123);
```

```
+-----+
| bin(123) |
+-----+
| 1111011 |
+-----+
```

# SIN

## 描述

计算参数的正弦值

## 语法

```
SIN(<a>)
```

## 参数

参数	说明
<a>	浮点数，要计算参数的弧度值

## 返回值

参数 <a> 的正弦值，弧度制表示。

## 举例

```
select sin(1);
```

```
+-----+
| sin(cast(1 as DOUBLE)) |
+-----+
| 0.8414709848078965 |
+-----+
```

```
select sin(0);
```

```
+-----+
| sin(cast(0 as DOUBLE)) |
+-----+
| 0.0 |
+-----+
```

```
select sin(Pi());
```

```
+-----+
| sin(pi()) |
+-----+
| 0.00000000000000012246467991473532 |
+-----+
```

# COS

## 描述

计算参数的余弦值

## 语法

```
COS(<a>)
```

## 参数

参数	说明
<a>	浮点数，要计算参数的弧度值

## 返回值

参数 <a> 的余弦值，弧度制表示。

## 举例

```
select cos(1);
```

```
+-----+
| cos(1.0) |
+-----+
| 0.54030230586813977 |
+-----+
```

```
select cos(0);
```

```
+-----+
| cos(cast(0 as DOUBLE)) |
+-----+
| 1.0 |
+-----+
```

```
select cos(Pi());
```

```
+-----+
| cos(pi()) |
+-----+
| -1 |
+-----+
```

# TAN

---

## tan

## 描述

## 语法

DOUBLE tan(DOUBLE x) 返回x的正切值，x为弧度值.

## 举例

```
mysql> select tan(0);
+-----+
| tan(0.0) |
+-----+
| 0 |
+-----+
mysql> select tan(1);
+-----+
| tan(1.0) |
+-----+
| 1.5574077246549023 |
+-----+
```

## keywords

TAN

# ASIN

---

## asin

## 描述

## 语法

DOUBLE asin(DOUBLE x) 返回x的反正弦值，若 x不在-1到 1的范围之内，则返回 nan.

## 举例

```
mysql> select asin(0.5);
+-----+
| asin(0.5) |
+-----+
| 0.52359877559829893 |
+-----+
mysql> select asin(2);
+-----+
| asin(2.0) |
+-----+
| nan |
+-----+
```

## keywords

ASIN

# ACOS

---

## acos

### 描述

### 语法

DOUBLE acos(DOUBLE x) 返回x的反余弦值，若 x不在-1到 1的范围之内，则返回 nan.

### 举例

```
mysql> select acos(1);
+-----+
| acos(1.0) |
+-----+
| 0 |
+-----+
mysql> select acos(0);
+-----+
| acos(0.0) |
+-----+
| 1.5707963267948966 |
+-----+
mysql> select acos(-2);
+-----+
| acos(-2.0) |
+-----+
| nan |
+-----+
```

### keywords

ACOS

# ATAN

---

## atan

## 描述

## 语法

DOUBLE atan(DOUBLE x) 返回x的反正切值，x为弧度值.

## 举例

```
mysql> select atan(0);
+-----+
| atan(0.0) |
+-----+
| 0 |
+-----+
mysql> select atan(2);
+-----+
| atan(2.0) |
+-----+
| 1.1071487177940904 |
+-----+
```

## keywords

ATAN

# E

---

## e

### 描述

### 语法

DOUBLE e() 返回常量e值.

### 举例

```
mysql> select e();
+-----+
| e() |
+-----+
| 2.7182818284590451 |
+-----+
```

### keywords

E



# PI

---

## Pi

### 描述

### 语法

DOUBLE Pi() 返回常量Pi值.

### 举例

```
mysql> select Pi();
+-----+
| pi() |
+-----+
| 3.1415926535897931 |
+-----+
```

### keywords

PI

# EXP

---

## exp

### 描述

### 语法

DOUBLE exp(DOUBLE x) 返回以e为底的x的幂。

该函数的另一个别名为 dexp。

### 举例

```
mysql> select exp(2);
+-----+
| exp(2.0) |
+-----+
| 7.38905609893065 |
+-----+
mysql> select exp(3.4);
+-----+
| exp(3.4) |
+-----+
| 29.964100047397011 |
+-----+
```

### keywords

EXP, DEXP

# LOG

---

## log

## 描述

## 语法

DOUBLE log(DOUBLE b, DOUBLE x) 返回基于底数b的x的对数.

## 举例

```
mysql> select log(5,1);
+-----+
| log(5.0, 1.0) |
+-----+
| 0 |
+-----+
mysql> select log(3,20);
+-----+
| log(3.0, 20.0) |
+-----+
| 2.7268330278608417 |
+-----+
mysql> select log(2,65536);
+-----+
| log(2.0, 65536.0) |
+-----+
| 16 |
+-----+
```

## keywords

LOG

# LOG2

---

## log2

### 描述

### 语法

DOUBLE log2(DOUBLE x) 返回以2为底的x的自然对数.

### 举例

```
mysql> select log2(1);
+-----+
| log2(1.0) |
+-----+
| 0 |
+-----+
mysql> select log2(2);
+-----+
| log2(2.0) |
+-----+
| 1 |
+-----+
mysql> select log2(10);
+-----+
| log2(10.0) |
+-----+
| 3.3219280948873622 |
+-----+
```

### keywords

LOG2

# LOG10

---

## log10

### 描述

### 语法

DOUBLE log10(DOUBLE x) 返回以10为底的x的自然对数.

该函数的另一个别名为 dlog10。

### 举例

```
mysql> select log10(1);
+-----+
| log10(1.0) |
+-----+
| 0 |
+-----+
mysql> select log10(10);
+-----+
| log10(10.0) |
+-----+
| 1 |
+-----+
mysql> select log10(16);
+-----+
| log10(16.0) |
+-----+
| 1.2041199826559248 |
+-----+
```

### keywords

LOG10, DLOG10

# LN

---

## ln

### 描述

### 语法

DOUBLE ln(DOUBLE x) 返回以e为底的x的自然对数。

该函数的另一个别名为 dlog1。

### 举例

```
mysql> select ln(1);
+-----+
| ln(1.0) |
+-----+
| 0 |
+-----+
mysql> select ln(e());
+-----+
| ln(e()) |
+-----+
| 1 |
+-----+
mysql> select ln(10);
+-----+
| ln(10.0) |
+-----+
| 2.3025850929940459 |
+-----+
```

### keywords

LN, DLOG1

# CEIL

## 描述

对浮点及定点小数按特定位数向上取整，返回取整过后的浮点或定点数。

## 语法

```
CEIL(<a>[, <d>])
```

## 参数

参数	说明
<a>	浮点(Double)或定点(Decimal)参数，表示要进行取整的参数
<d>	可选的，整数，表示舍入目标位数，正数为向小数点后舍入，负数为向小数点前舍入，0 表示舍入到整数。不填写时等同于 <d> = 0

## 返回值

按照下面规则返回最小的大于或者等于 <a> 的舍入数字:

舍入到  $1/(10^d)$  位，即，使结果可整除 $1/(10^d)$ 。如果  $1/(10^d)$  不精确，则舍入位数为相应数据类型的最接近的数字。

对于 Decimal 类型的入参 <a>，假设其类型为 Decimal(p, s)，则返回值类型为：

- Decimal(p, 0)，若 <d> <= 0
- Decimal(p, <d>), 若 0 < <d> <= s
- Decimal(p, s), 若 <d> > s

## 别名

- DCEIL
- CEILING

## 举例

```
select ceil(123.456);
```

```
+-----+
| ceil(123.456) |
+-----+
| 124 |
+-----+
```

```
select ceil(123.456, 2);
```

```
+-----+
| ceil(123.456, 2) |
+-----+
| 123.46 |
+-----+
```

```
select ceil(123.456, -2);
```

```
+-----+
| ceil(123.456, -2) |
+-----+
| 200 |
+-----+
```

```
select ceil(123.45, 1), ceil(123.45), ceil(123.45, 0), ceil(123.45, -1);
```

```
+-----+-----+-----+-----+
| ceil(123.45, 1) | ceil(123.45) | ceil(123.45, 0) | ceil(123.45, -1) |
+-----+-----+-----+-----+
| 123.5 | 124 | 124 | 130 |
+-----+-----+-----+-----+
```

```
select ceil(x, 2) from (select cast(123.456 as decimal(6,3)) as x from numbers("number"="5"))t;
```

```
+-----+
| ceil(x, 2) |
+-----+
| 123.46 |
| 123.46 |
| 123.46 |
| 123.46 |
| 123.46 |
+-----+
```



# FLOOR

## 描述

对浮点及定点小数按特定位数向下取整，返回取整过后的浮点或定点数。

## 语法

```
FLOOR(<a>[, <d>])
```

## 参数

参数	说明
<a>	浮点(Double)或定点(Decimal)参数，表示要进行取整的参数
<d>	可选的，整数，表示舍入目标位数，正数为向小数点后舍入，负数为向小数点前舍入，0 表示舍入到整数。不填写时等同于 <d> = 0

## 返回值

按照下面规则返回最大的小于或者等于 <a> 的舍入数字:

舍入到  $1/(10^d)$  位，即，使结果可整除 $1/(10^d)$ 。如果  $1/(10^d)$  不精确，则舍入位数为相应数据类型的最接近的数字。

对于 Decimal 类型的入参 <a>，假设其类型为 Decimal(p, s)，则返回值类型为：

- Decimal(p, 0)，若 <d> <= 0
- Decimal(p, <d>), 若 0 < <d> <= s
- Decimal(p, s), 若 <d> > s

## 别名

- DFLOOR

## 举例

```
select floor(123.456);
```

```
+-----+
| floor(123.456) |
+-----+
| 123 |
+-----+
```

```
select floor(123.456, 2);
```

```
+-----+
| floor(123.456, 2) |
+-----+
| 123.45 |
+-----+
```

```
select floor(123.456, -2);
```

```
+-----+
| floor(123.456, -2) |
+-----+
| 100 |
+-----+
```

```
select floor(123.45, 1), floor(123.45), floor(123.45, 0), floor(123.45, -1);
```

```
+-----+-----+-----+-----+
| floor(123.45, 1) | floor(123.45) | floor(123.45, 0) | floor(123.45, -1) |
+-----+-----+-----+-----+
| 123.4 | 123 | 123 | 120 |
+-----+-----+-----+-----+
```

```
select floor(x, 2) from (select cast(123.456 as decimal(6,3)) as x from numbers("number"="5"))t;
```

```
+-----+
| floor(x, 2) |
+-----+
| 123.45 |
| 123.45 |
| 123.45 |
| 123.45 |
| 123.45 |
+-----+
```

# PMOD

---

## pmod

## 描述

## 语法

```
BIGINT PMOD(BIGINT x, BIGINT y)
DOUBLE PMOD(DOUBLE x, DOUBLE y)
```

返回在模系下  $x \bmod y$  的最小正数解. 具体地说, 返回  $(x \% y + y) \% y$ .

## 举例

```
MySQL [test]> SELECT PMOD(13,5);
+-----+
| pmod(13, 5) |
+-----+
| 3 |
+-----+
MySQL [test]> SELECT PMOD(-13,5);
+-----+
| pmod(-13, 5) |
+-----+
| 2 |
+-----+
```

## keywords

PMOD

# ROUND

## round

### 描述

### 语法

T round(T x[, d]) 将x四舍五入后保留d位小数，d默认为0。如果d为负数，则小数点左边d位为0。如果x或d为null，返回null。2.5会舍入到3，如果想要舍入到2的算法，请使用round\_bankers函数。

该函数的另一个别名为 dround。

### 举例

```
mysql> select round(2.4);
+-----+
| round(2.4) |
+-----+
| 2 |
+-----+
mysql> select round(2.5);
+-----+
| round(2.5) |
+-----+
| 3 |
+-----+
mysql> select round(-3.4);
+-----+
| round(-3.4) |
+-----+
| -3 |
+-----+
mysql> select round(-3.5);
+-----+
| round(-3.5) |
+-----+
| -4 |
+-----+
mysql> select round(1667.2725, 2);
+-----+
| round(1667.2725, 2) |
+-----+
| 1667.27 |
+-----+
mysql> select round(1667.2725, -2);
+-----+
| round(1667.2725, -2) |
+-----+
| 1700 |
+-----+
```

**keywords**

ROUND, DROUND

# ROUND\_BANKERS

---

## round\_bankers

### 描述

### 语法

T round\_bankers(T x[, d]) 将x使用银行家舍入法后，保留d位小数，d默认为0。如果d为负数，则小数点左边d位为0。如果x或d为null，返回null。

- 如果舍入数介于两个数字之间，则该函数使用银行家的舍入
- 在其他情况下，该函数将数字四舍五入到最接近的整数。

### 举例

```
mysql> select round_bankers(0.4);
+-----+
| round_bankers(0.4) |
+-----+
| 0 |
+-----+
mysql> select round_bankers(-3.5);
+-----+
| round_bankers(-3.5) |
+-----+
| -4 |
+-----+
mysql> select round_bankers(-3.4);
+-----+
| round_bankers(-3.4) |
+-----+
| -3 |
+-----+
mysql> select round_bankers(10.755, 2);
+-----+
| round_bankers(10.755, 2) |
+-----+
| 10.76 |
+-----+
mysql> select round_bankers(1667.2725, 2);
+-----+
| round_bankers(1667.2725, 2) |
+-----+
| 1667.27 |
+-----+
mysql> select round_bankers(1667.2725, -2);
+-----+
| round_bankers(1667.2725, -2) |
+-----+
| 1700 |
+-----+
```

**keywords**

round\_bankers

# TRUNCATE

---

## truncate

### 描述

### 语法

`DOUBLE truncate(DOUBLE x, INT d)` 按照保留小数的位数d对x进行数值截取。

规则如下： 当  $d > 0$  时：保留x的d位小数 当  $d = 0$  时：将x的小数部分去除，只保留整数部分 当  $d < 0$  时：将x的小数部分去除，整数部分按照 d所指定的位数，采用数字0进行替换

### 举例

```
mysql> select truncate(124.3867, 2);
+-----+
| truncate(124.3867, 2) |
+-----+
| 124.38 |
+-----+
mysql> select truncate(124.3867, 0);
+-----+
| truncate(124.3867, 0) |
+-----+
| 124 |
+-----+
mysql> select truncate(-124.3867, -2);
+-----+
| truncate(-124.3867, -2) |
+-----+
| -100 |
+-----+
```

### keywords

TRUNCATE



# ABS

---

## abs

## 描述

## 语法

```
SMALLINT abs(TINYINT x)
INT abs(SMALLINT x)
BIGINT abs(INT x)
LARGEINT abs(BIGINT x)
LARGEINT abs(LARGEINT x)
DOUBLE abs(DOUBLE x)
FLOAT abs(FLOAT x)
DECIMAL abs(DECIMAL x)`
```

返回x的绝对值.

## 举例

```
mysql> select abs(-2);
+-----+
| abs(-2) |
+-----+
| 2 |
+-----+
mysql> select abs(3.254655654);
+-----+
| abs(3.254655654) |
+-----+
| 3.254655654 |
+-----+
mysql> select abs(-3254654236547654354654767);
+-----+
| abs(-3254654236547654354654767) |
+-----+
| 3254654236547654354654767 |
+-----+
```

## keywords

ABS

# SQRT

---

## sqrt

## 描述

## 语法

DOUBLE sqrt(DOUBLE x) 返回x的平方根，要求x大于或等于0.

该函数的另一个别名为 dsqrt。

## 举例

```
mysql> select sqrt(9);
+-----+
| sqrt(9.0) |
+-----+
| 3 |
+-----+
mysql> select sqrt(2);
+-----+
| sqrt(2.0) |
+-----+
| 1.4142135623730951 |
+-----+
mysql> select sqrt(100.0);
+-----+
| sqrt(100.0) |
+-----+
| 10 |
+-----+
```

## keywords

SQRT, DSQRT

# CBRT

## 描述

计算参数的立方根

## 语法

```
cbrt(<a>)
```

## 参数

参数	说明
<a>	浮点参数

## 返回值

参数 <a> 的立方根，浮点数。

## 举例

```
select cbrt(0);
```

```
+-----+
| cbrt(cast(0 as DOUBLE)) |
+-----+
| 0.0 |
+-----+
```

```
select cbrt(-111);
```

```
+-----+
| cbrt(cast(-111 as DOUBLE)) |
+-----+
| -4.805895533705333 |
+-----+
```

```
select cbrt(1234);
```

```
+-----+
| cbrt(cast(1234 as DOUBLE)) |
+-----+
| 10.726014668827325 |
+-----+
```

# POW

---

## pow

### 描述

返回第一个参数的值，该值是第二个参数的幂。

该函数的其他别名为 power、fpow、dpow

### 语法

DOUBLE pow(DOUBLE a, DOUBLE b) 返回a的b次方.

### 举例

```
mysql> select pow(2,0);
+-----+
| pow(2.0, 0.0) |
+-----+
| 1 |
+-----+
mysql> select pow(2,3);
+-----+
| pow(2.0, 3.0) |
+-----+
| 8 |
+-----+
mysql> select pow(3,2.4);
+-----+
| pow(3.0, 2.4) |
+-----+
| 13.966610165238235 |
+-----+
```

### keywords

POW, POWER, FPOW, DPOW

# DEGREES

## 描述

输入一个 double 类型的浮点数，由弧度转换为角度。

- 当参数为 NUL 时，返回 NULL

## 语法

```
DEGREES(<a>)
```

## 参数

参数	说明
<a>	需要由弧度转换为角度的值

## 返回值

参数 a 的角度

- 当参数为 NUL 时，返回 NULL

## 举例

```
select degrees(3.14),degrees(1),degrees(-1),degrees(NULL)
```

degrees(cast(3.14 as DOUBLE))	degrees(cast(1 as DOUBLE))	degrees(cast(-1 as DOUBLE))	degrees(NULL)
179.9087476710785	57.29577951308232	-57.29577951308232	NULL

# RADIANS

---

## radians

### 描述

### 语法

DOUBLE radians(DOUBLE x) 返回x的弧度值, 从度转换为弧度.

### 举例

```
mysql> select radians(0);
+-----+
| radians(0.0) |
+-----+
| 0 |
+-----+
mysql> select radians(30);
+-----+
| radians(30.0) |
+-----+
| 0.52359877559829882 |
+-----+
mysql> select radians(90);
+-----+
| radians(90.0) |
+-----+
| 1.5707963267948966 |
+-----+
```

### keywords

RADIANS

# SIGN

---

## sign

## 描述

## 语法

TINYINT sign(DOUBLE x) 返回x的符号.负数, 零或正数分别对应-1, 0或1.

## 举例

```
mysql> select sign(3);
+-----+
| sign(3.0) |
+-----+
| 1 |
+-----+
mysql> select sign(0);
+-----+
| sign(0.0) |
+-----+
| 0 |
+-----+
mysql> select sign(-10.0);
+-----+
| sign(-10.0) |
+-----+
| -1 |
+-----+
1 row in set (0.01 sec)
```

## keywords

SIGN

# POSITIVE

---

## positive

### 描述

### 语法

```
BIGINT positive(BIGINT x)
DOUBLE positive(DOUBLE x)
DECIMAL positive(DECIMAL x)
```

返回x.

### 举例

```
mysql> SELECT positive(-10);
+-----+
| positive(-10) |
+-----+
| -10 |
+-----+
mysql> SELECT positive(12);
+-----+
| positive(12) |
+-----+
| 12 |
+-----+
```

### keywords

POSITIVE



# NEGATIVE

---

## negative

### 描述

### 语法

```
BIGINT negative(BIGINT x)
DOUBLE negative(DOUBLE x)
DECIMAL negative(DECIMAL x)
```

返回-x.

### 举例

```
mysql> SELECT negative(-10);
+-----+
| negative(-10) |
+-----+
| 10 |
+-----+
mysql> SELECT negative(12);
+-----+
| negative(12) |
+-----+
| -12 |
+-----+
```

### keywords

```
NEGATIVE
```

# GREATEST

## 描述

比较多个表达式的大小，并返回其中的最大值。如果任意参数为 NULL，则返回 NULL。

## 语法

```
GREATEST(<expr> [, ...])
```

## 参数

参数	描述
<expr>	需要比较的多个表达式，支持 TINYINT、SMALLINT、INT、BIGINT、LARGEINT、FLOAT、DOUBLE、STRING、DATETIME 和 DECIMAL 类型。

## 返回值

- 返回给定表达式中的最大值。
- 如果任意参数为 NULL，则返回 NULL。

## 示例

```
SELECT GREATEST(-1, 0, 5, 8);
```

```
+-----+
| GREATEST(-1, 0, 5, 8) |
+-----+
| 8 |
+-----+
```

```
SELECT GREATEST(-1, 0, 5, NULL);
```

```
+-----+
| GREATEST(-1, 0, 5, NULL) |
+-----+
| NULL |
+-----+
```

```
SELECT GREATEST(6.3, 4.29, 7.6876);
```

```
+-----+
| GREATEST(6.3, 4.29, 7.6876) |
+-----+
```

	7.6876	
+-----+		

```
SELECT GREATEST('2022-02-26 20:02:11', '2020-01-23 20:02:11', '2020-06-22 20:02:11');
```

+-----+		
	GREATEST('2022-02-26 20:02:11', '2020-01-23 20:02:11', '2020-06-22 20:02:11')	
+-----+		
	2022-02-26 20:02:11	
+-----+		

# LEAST

## 描述

比较多个表达式的大小，返回其中的最小值。如果任意参数为 NULL，则返回 NULL。

## 语法

```
LEAST(<expr> [, ...])
```

## 参数

参数	描述
<expr>	需要进行比较的表达式。支持的类型包括 TINYINT、SMALLINT、INT、BIGINT、LARGEINT、FLOAT、DOUBLE、STRING、DATETIME 和 DECIMAL。

## 返回值

- 返回多个输入表达式中的最小值。
- 如果任意参数为 NULL，则返回 NULL。

## 示例

```
SELECT LEAST(-1, 0, 5, 8);
```

```
+-----+
| LEAST(-1, 0, 5, 8) |
+-----+
| -1 |
+-----+
```

```
SELECT LEAST(-1, 0, 5, NULL);
```

```
+-----+
| LEAST(-1, 0, 5, NULL) |
+-----+
| NULL |
+-----+
```

```
SELECT LEAST(6.3, 4.29, 7.6876);
```

```
+-----+
| LEAST(6.3, 4.29, 7.6876) |
+-----+
```

+-----+	
	4.29
+-----+	

```
SELECT LEAST('2022-02-26 20:02:11', '2020-01-23 20:02:11', '2020-06-22 20:02:11');
```

+-----+	
	LEAST('2022-02-26 20:02:11', '2020-01-23 20:02:11', '2020-06-22 20:02:11')
+-----+	
	2020-01-23 20:02:11
+-----+	

# RANDOM

---

## random

### 描述

### 语法

DOUBLE random() 返回0-1的随机数。

### 举例

```
mysql> select random();
+-----+
| random() |
+-----+
| 0.35446706030596947 |
+-----+
```

### keywords

RANDOM

# MOD

---

## mod

## 描述

## 语法

`mod(col_a, col_b)`

column支持以下类型：TINYINT SMALLINT INT BIGINT LARGEINT FLOAT DOUBLE DECIMAL

求a / b的余数。浮点类型请使用fmod函数。

## 举例

```
mysql> select mod(10, 3);
+-----+
| mod(10, 3) |
+-----+
| 1 |
+-----+

mysql> select fmod(10.1, 3.2);
+-----+
| fmod(10.1, 3.2) |
+-----+
| 0.50000024 |
+-----+
```

## keywords

MOD, FMOD

# RUNNING\_DIFFERENCE

## running\_difference

### 描述

### 语法

T running\_difference(T x) 计算数据块中连续行值的差值。该函数的结果取决于受影响的数据块和块中数据的顺序。

计算 running\_difference 期间使用的行顺序可能与返回给用户的行顺序不同。所以结果是不稳定的。**此函数会在后续版本中废弃**。推荐使用窗口函数完成预期功能。举例如下：

```
-- running difference(x)
SELECT running_difference(x) FROM t ORDER BY k;

-- 窗口函数
SELECT x - lag(x, 1, 0) OVER (ORDER BY k) FROM t;
```

### 参数

x - 一列数据:数据类型可以是

TINYINT,SMALLINT,INT,BIGINT,LARGEINT,FLOAT,DOUBLE,DATE,DATETIME,DECIMAL

### 返回值

第一行返回 0，随后的每一行返回与前一行的差值。

### 举例

```
DROP TABLE IF EXISTS running_difference_test;

CREATE TABLE running_difference_test (
 `id` int NOT NULL COMMENT 'id',
 `day` date COMMENT 'day',
 `time_val` datetime COMMENT 'time_val',
 `doublenum` double NULL COMMENT 'doublenum'
)
DUPLICATE KEY(id)
DISTRIBUTED BY HASH(id) BUCKETS 3
PROPERTIES (
 "replication_num" = "1"
);

INSERT into running_difference_test (id, day, time_val,doublenum) values ('1', '2022-10-28', '2022-03-12
10:41:00', null),
 ('2','2022-10-27', '2022-03-12 10:41:02', 2.6),
 ('3','2022-10-28', '2022-03-12 10:41:03', 2.5),
 ('4','2022-9-29', '2022-03-12 10:41:03', null),
```



```
('5', '2022-10-31', '2022-03-12 10:42:01', 3.3),
('6', '2022-11-08', '2022-03-12 11:05:04', 4.7);
```

```
SELECT * from running_difference_test ORDER BY id ASC;
```

id	day	time_val	doublenum
1	2022-10-28	2022-03-12 10:41:00	NULL
2	2022-10-27	2022-03-12 10:41:02	2.6
3	2022-10-28	2022-03-12 10:41:03	2.5
4	2022-09-29	2022-03-12 10:41:03	NULL
5	2022-10-31	2022-03-12 10:42:01	3.3
6	2022-11-08	2022-03-12 11:05:04	4.7

```
SELECT
 id,
 running_difference(id) AS delta
FROM
(
 SELECT
 id,
 day,
 time_val,
 doublenum
 FROM running_difference_test
)as runningDifference ORDER BY id ASC;
```

id	delta
1	0
2	1
3	1
4	1
5	1
6	1

```
SELECT
 day,
 running_difference(day) AS delta
FROM
(
 SELECT
 id,
 day,
 time_val,
 doublenum
 FROM running_difference_test
)as runningDifference ORDER BY id ASC;
```

day	delta
2022-10-28	0
2022-10-27	-1
2022-10-28	1
2022-09-29	-29
2022-10-31	32
2022-11-08	8

```
SELECT
```

```

 time_val,
 running_difference(time_val) AS delta
FROM
(
 SELECT
 id,
 day,
 time_val,
 doublenum
 FROM running_difference_test
)as runningDifference ORDER BY id ASC;

```

time_val	delta
2022-03-12 10:41:00	0
2022-03-12 10:41:02	2
2022-03-12 10:41:03	1
2022-03-12 10:41:03	0
2022-03-12 10:42:01	58
2022-03-12 11:05:04	1383

```

SELECT
 doublenum,
 running_difference(doublenum) AS delta
FROM
(
 SELECT
 id,
 day,
 time_val,
 doublenum
 FROM running_difference_test
)as runningDifference ORDER BY id ASC;

```

doublenum	delta
NULL	NULL
2.6	NULL
2.5	-0.10000000000000009
NULL	NULL
3.3	NULL
4.7	1.4000000000000004

## keywords

running\_difference

# UUID\_NUMERIC

---

## uuid\_numeric

### 描述

### 语法

LARGEINT uuid\_numeric()

返回一个 LARGEINT 类型的 uuid。注意 LARGEINT 是一个 Int128，所以 uuid\_numeric() 可能会得到负值。

### 举例

```
mysql> select uuid_numeric();
+-----+
| uuid_numeric() |
+-----+
| 82218484683747862468445277894131281464 |
+-----+
```

### keywords

UUID UUID-NUMERIC

# AES\_ENCRYPT

## 描述

AES 加密函数。该函数与 MySQL 中的 AES\_ENCRYPT 函数行为一致。默认采用 AES\_128\_ECB 算法，padding 模式为 PKCS7。

## 语法

```
VARCHAR AES_ENCRYPT(VARCHAR str, VARCHAR key_str[, VARCHAR init_vector][, VARCHAR encryption_mode])
```

## 参数

- str 为待加密文本；
- key\_str 为密钥。注意此密钥并非 16 进制编码，而是编码后的字符串表示。例如对于 128 位密钥加密，key\_str 长度应为 16。如果密钥长度不足，使用零填充补齐。如果长度超出，使用循环异或的方式求出最终密钥。例如算法使用的 128 位密钥为 key，则  $key[i] = key\_str[i] \oplus key\_str[i+128] \oplus key\_str[i+256] \oplus \dots$
- init\_vector 为算法中使用到的初始向量，仅在特定算法下生效，如不指定，则 Doris 使用内置向量；
- encryption\_mode 为加密算法，可选值见于变量。

两参数版本，会无视 **session variable** block\_encryption\_mode，始终使用 AES\_128\_ECB 算法进行加密。因此不推荐调用。

## 注意事项

AES\_ENCRYPT 函数对于传入的密钥，并不是直接使用，而是会进一步做处理，具体步骤如下：1. 根据使用的加密算法，确定密钥的字节数，比如使用 AES\_128\_ECB 算法，则密钥字节数为  $128 / 8 = 16$ （如果使用 AES\_256\_ECB 算法，则密钥字节数为  $256 / 8 = 32$ ）；2. 然后针对用户输入的密钥，第 i 位和第  $16*k+i$  位进行异或，如果用户输入的密钥不足 16 位，则后面补 0；3. 最后，再使用新生成的密钥进行加密；

## 示例

```
set block_encryption_mode='';
select to_base64(aes_encrypt('text','F3229A0B371ED2D9441B830D21A390C3'));
```

```
+-----+
| to_base64(aes_encrypt('text', '***', '', 'AES_128_ECB')) |
+-----+
| wr2JEDVXzL9+2XtRhGIloA== |
+-----+
```

```
set block_encryption_mode="AES_256_CBC";
select to_base64(aes_encrypt('text','F3229A0B371ED2D9441B830D21A390C3'));
```

```
+-----+
| to_base64(aes_encrypt('text', '***', '', 'AES_256_CBC')) |
+-----+
| 3dym0E7/+1zbrLIaBVNHSw== |
+-----+
```

```
select to_base64(aes_encrypt('text','F3229A0B371ED2D9441B830D21A390C3', '0123456789'));
```

```
+-----+
| to_base64(aes_encrypt('text', '***', '0123456789', 'AES_256_CBC')) |
+-----+
| tsmK1HzbpnEdR2//Wh0+MA== |
+-----+
```

# AES\_DECRYPT

## 描述

AES 解密函数。该函数与 MySQL 中的 AES\_DECRYPT 函数行为一致。默认采用 AES\_128\_ECB 算法，padding 模式为 PKCS7。

## 语法

```
VARCHAR AES_DECRYPT(VARCHAR str, VARCHAR key_str[, VARCHAR init_vector][, VARCHAR encryption_mode])
```

## 参数

- str 为待解密文本；
- key\_str 为密钥。注意此密钥并非 16 进制编码，而是编码后的字符串表示。例如对于 128 位密钥加密，key\_str 长度应为 16。如果密钥长度不足，使用零填充补齐。如果长度超出，使用循环异或的方式求出最终密钥。例如算法使用的 128 位密钥为 key，则  $key[i] = key\_str[i] \oplus key\_str[i+128] \oplus key\_str[i+256] \oplus \dots$
- init\_vector 为算法中使用到的初始向量，仅在特定算法下生效，如不指定，则 Doris 使用内置向量；
- encryption\_mode 为加密算法，可选值见于变量。

两参数版本，会无视 **session variable** block\_encryption\_mode，始终使用 AES\_128\_ECB 算法进行解密。因此不推荐调用。

## 示例

```
set block_encryption_mode='';
select aes_decrypt(from_base64('wr2JEDVXzL9+2XtRhGIloA=='), 'F3229A0B371ED2D9441B830D21A390C3');
```

```
+-----+
| aes_decrypt(from_base64('wr2JEDVXzL9+2XtRhGIloA=='), '***', '', 'AES_128_ECB') |
+-----+
| text |
+-----+
```

```
set block_encryption_mode="AES_256_CBC";
select aes_decrypt(from_base64('3dym0E7/+1zbrLIaBVNHSw=='), 'F3229A0B371ED2D9441B830D21A390C3');
```

```
+-----+
| aes_decrypt(from_base64('3dym0E7/+1zbrLIaBVNHSw=='), '***', '', 'AES_256_CBC') |
+-----+
| text |
+-----+
```

```
select AES_DECRYPT(FROM_BASE64('tsmK1HzbpnEdR2//Wh0+MA=='),'F3229A0B371ED2D9441B830D21A390C3', '0123456789');
```

```
+-----+
| aes_decrypt(from_base64('tsmK1HzbpnEdR2//Wh0+MA=='),'***', '0123456789', 'AES_256_CBC') |
+-----+
| text |
+-----+
```

# MD5

## 描述

计算 MD5 128-bit

## 语法

```
MD5(str)
```

## 示例

```
select md5("abc");
```

+-----+	
md5('abc')	
+-----+	
900150983cd24fb0d6963f7d28e17f72	
+-----+	



# MD5SUM

## 描述

计算 多个字符串 MD5 128-bit

## 语法

```
MD5SUM(str[,str])
```

## 示例

```
select md5("abcd");
```

+-----+	
md5('abcd')	
+-----+	
e2fc714c4727ee9395f324cd2e7f331f	
+-----+	

```
select md5sum("ab","cd");
```

+-----+	
md5sum('ab', 'cd')	
+-----+	
e2fc714c4727ee9395f324cd2e7f331f	
+-----+	

# SM4\_ENCRYPT

## 描述

SM4是一种国家标准的对称密钥加密算法，广泛应用于金融、通信、电子商务等领域。SM4\_ENCRYPT函数用于对数据进行SM4加密。默认采用 SM4\_128\_ECB 算法。

## 语法

```
VARCHAR SM4_ENCRYPT(VARCHAR str, VARCHAR key_str[, VARCHAR init_vector][, VARCHAR encryption_mode])
```

## 参数

- str 为待加密文本；
- key\_str 为密钥。注意此密钥并非 16 进制编码，而是编码后的字符串表示。例如对于 128 位密钥加密，key\_str 长度应为 16。如果密钥长度不足，使用零填充补齐。如果长度超出，使用循环异或的方式求出最终密钥。例如算法最终使用的 128 位密钥为 key，则  $key[i] = key\_str[i] \oplus key\_str[i+128] \oplus key\_str[i+256] \oplus \dots$
- init\_vector 为算法中使用到的初始向量，仅在特定算法下生效，如不指定，则 Doris 使用内置向量；
- encryption\_mode 为加密算法，可选值见于变量。

两参数版本，会无视 **session variable** block\_encryption\_mode，始终使用 SM4\_128\_ECB 算法进行加密。这与 1.2 版本行为不同，升降级时必须注意。

## 示例

```
set block_encryption_mode='';
select TO_BASE64(SM4_ENCRYPT('text','F3229A0B371ED2D9441B830D21A390C3'));
```

```
+-----+
| to_base64(sm4_encrypt('text', '***', '', 'SM4_128_ECB')) |
+-----+
| aDjwRf\BrDjhBZIOFNw3Tg== |
+-----+
```

```
select to_base64(SM4_ENCRYPT('text','F3229A0B371ED2D9441B830D21A390C3', '0123456789'));
```

```
to_base64(sm4_encrypt('text', 'F3229A0B371ED2D9441B830D21A390C3', '0123456789'))
G7yqOKfEyxdagboz6Qf01A==
```

...

# SM4\_DECRYPT

## 描述

SM4是一种国家标准的对称密钥加密算法，广泛应用于金融、通信、电子商务等领域。SM4\_DECRYPT函数用于对数据进行SM4解密。默认采用 SM4\_128\_ECB 算法。

## 语法

```
VARCHAR SM4_DECRYPT(VARCHAR str, VARCHAR key_str[, VARCHAR init_vector][, VARCHAR encryption_mode])
```

## 参数

- str 为待解密文本；
- key\_str 为密钥。注意此密钥并非 16 进制编码，而是编码后的字符串表示。例如对于 128 位密钥加密，key\_str 长度应为 16。如果密钥长度不足，使用零填充补齐。如果长度超出，使用循环异或的方式求出最终密钥。例如算法使用的 128 位密钥为 key，则  $key[i] = key\_str[i] \oplus key\_str[i+128] \oplus key\_str[i+256] \oplus \dots$
- init\_vector 为算法中使用到的初始向量，仅在特定算法下生效，如不指定，则 Doris 使用内置向量；
- encryption\_mode 为加密算法，可选值见于变量。

两参数版本，会无视 **session variable** block\_encryption\_mode，始终使用 SM4\_128\_ECB 算法进行解密。这与 1.2 版本行为不同，升降级时必须注意。

## 示例

```
set block_encryption_mode='';
select SM4_DECRYPT(FROM_BASE64('aDjwRfLBrDjhBZIOFNw3Tg=='),'F3229A0B371ED2D9441B830D21A390C3');
```

+-----+	
sm4_decrypt(from_base64('aDjwRfLBrDjhBZIOFNw3Tg=='), '***', '', 'SM4_128_ECB')	
+-----+	
text	
+-----+	

```
select SM4_DECRYPT(FROM_BASE64('G7yq0KfEyxdagboz6Qf01A=='),'F3229A0B371ED2D9441B830D21A390C3', '0123456789');
```

+-----+	
sm4_decrypt(from_base64('G7yq0KfEyxdagboz6Qf01A=='), 'F3229A0B371ED2D9441B830D21A390C3', '0123456789')	
+-----+	
text	
+-----+	

# SM3

## 描述

计算 SM3 256-bit

## 语法

```
SM3(str)
```

## 示例

```
select sm3("abcd");
```

+-----+	
sm3('abcd')	
+-----+	
82ec580fe6d36ae4f81cae3c73f4a5b3b5a09c943172dc9053c69fd8e18dca1e	
+-----+	

# SM3SUM

## 描述

计算 多个字符串 SM3 256-bit

## 语法

```
SM3SUM(str[,str])
```

## 示例

```
select sm3("abcd");
```

+-----+	
sm3('abcd')	
+-----+	
82ec580fe6d36ae4f81cae3c73f4a5b3b5a09c943172dc9053c69fd8e18dca1e	
+-----+	

```
select sm3sum("ab","cd");
```

+-----+	
sm3sum('ab', 'cd')	
+-----+	
82ec580fe6d36ae4f81cae3c73f4a5b3b5a09c943172dc9053c69fd8e18dca1e	
+-----+	

# SHA

## 描述

使用SHA1算法对信息进行摘要处理。

## 语法

```
{ SHA | SHA1 }(str)
```

## 示例

```
select sha("123");
```

+-----+	
sha1('123')	
+-----+	
40bd001563085fc35165329ea1ff5c5ecbdbbeef	
+-----+	

# SHA2

## 描述

使用SHA2对信息进行摘要处理。

## 语法

```
SHA2(str, digest_length)
```

## 参数

- str: 待加密的内容
- digest\_length: 摘要长度，支持 224, 256, 384, 512

## 示例

```
select sha2('abc', 224);
```

+-----+	
sha2('abc', 224)	
+-----+	
23097d223405d8228642a477bda255b32aadbce4bda0b3f7e36c9da7	
+-----+	

```
select sha2('abc', 384);
```

+-----+	
sha2('abc', 384)	
+-----+	
cb00753f45a35e8bb5a03d699ac65007272c32ab0eded1631a8b605a43ff5bed8086072ba1e7cc2358baeca134c825a7	
+-----+	

```
select sha2(NULL, 512);
```

+-----+	
sha2(NULL, 512)	
+-----+	
NULL	
+-----+	

# EXPLODE\_JSON\_ARRAY

## explode\_json\_array

### 描述

表函数，需配合 Lateral View 使用。

展开一个 json 数组。根据数组元素类型，有三种函数名称。分别对应整型、浮点和字符串数组。

### 语法

```
explode_json_array_int(json_str)
explode_json_array_double(json_str)
explode_json_array_string(json_str)
explode_json_array_json(json_str)
```

### 举例

原表数据：

```
mysql> select k1, e1 from example1 lateral view explode_json_array_int('[]') tmp1 as e1 order by k1, e1;
+-----+-----+
| k1 | e1 |
+-----+-----+
| 1 | NULL |
| 2 | NULL |
| 3 | NULL |
+-----+-----+

mysql> select k1, e1 from example1 lateral view explode_json_array_int('[1,2,3]') tmp1 as e1 order by k1, e1;
+-----+-----+
| k1 | e1 |
+-----+-----+
| 1 | 1 |
| 1 | 2 |
| 1 | 3 |
| 2 | 1 |
| 2 | 2 |
| 2 | 3 |
| 3 | 1 |
| 3 | 2 |
| 3 | 3 |
+-----+-----+

mysql> select k1, e1 from example1 lateral view explode_json_array_int('[1,"b",3]') tmp1 as e1 order by k1, e1;
+-----+-----+
| k1 | e1 |
+-----+-----+
| 1 | NULL |
| 1 | 1 |
| 1 | 3 |
| 2 | NULL |
+-----+-----+
```



	2		1	
	2		3	
	3		NULL	
	3		1	
	3		3	
+-----+-----+				

```
mysql> select k1, e1 from example1 lateral view explode_json_array_int('["a","b","c"]') tmp1 as e1 order by k1, e1;
```

+-----+-----+				
	k1		e1	
+-----+-----+				
	1		NULL	
	1		NULL	
	1		NULL	
	2		NULL	
	2		NULL	
	2		NULL	
	3		NULL	
	3		NULL	
	3		NULL	
+-----+-----+				

```
mysql> select k1, e1 from example1 lateral view explode_json_array_int('{ "a": 3 }') tmp1 as e1 order by k1, e1;
```

+-----+-----+				
	k1		e1	
+-----+-----+				
	1		NULL	
	2		NULL	
	3		NULL	
+-----+-----+				

```
mysql> select k1, e1 from example1 lateral view explode_json_array_double('[]') tmp1 as e1 order by k1, e1;
```

+-----+-----+				
	k1		e1	
+-----+-----+				
	1		NULL	
	2		NULL	
	3		NULL	
+-----+-----+				

```
mysql> select k1, e1 from example1 lateral view explode_json_array_double('[1,2,3]') tmp1 as e1 order by k1, e1;
```

+-----+-----+				
	k1		e1	
+-----+-----+				
	1		NULL	
	1		NULL	
	1		NULL	
	2		NULL	
	2		NULL	
	2		NULL	
	3		NULL	
	3		NULL	
	3		NULL	
+-----+-----+				

```
mysql> select k1, e1 from example1 lateral view explode_json_array_double('[1,"b",3]') tmp1 as e1 order by k1, e1;
```

+-----+-----+				
	k1		e1	
+-----+-----+				
	1		NULL	
	1		NULL	

	1		NULL	
	2		NULL	
	2		NULL	
	2		NULL	
	3		NULL	
	3		NULL	
	3		NULL	

```
mysql> select k1, e1 from example1 lateral view explode_json_array_double('[1.0,2.0,3.0]') tmp1 as e1 order by k1, e1;
```

	k1		e1	
	1		1	
	1		2	
	1		3	
	2		1	
	2		2	
	2		3	
	3		1	
	3		2	
	3		3	

```
mysql> select k1, e1 from example1 lateral view explode_json_array_double('[1,"b",3]') tmp1 as e1 order by k1, e1;
```

	k1		e1	
	1		NULL	
	1		NULL	
	1		NULL	
	2		NULL	
	2		NULL	
	2		NULL	
	3		NULL	
	3		NULL	
	3		NULL	

```
mysql> select k1, e1 from example1 lateral view explode_json_array_double('["a","b","c"]') tmp1 as e1 order by k1, e1;
```

	k1		e1	
	1		NULL	
	1		NULL	
	1		NULL	
	2		NULL	
	2		NULL	
	2		NULL	
	3		NULL	
	3		NULL	
	3		NULL	

```
mysql> select k1, e1 from example1 lateral view explode_json_array_double('{\"a\": 3}') tmp1 as e1 order by k1, e1;
```

	k1		e1	
	1		NULL	
	2		NULL	
	3		NULL	

```

+-----+-----+
mysql> select k1, e1 from example1 lateral view explode_json_array_string('[]') tmp1 as e1 order by k1, e1;
+-----+-----+
| k1 | e1 |
+-----+-----+
| 1 | NULL |
| 2 | NULL |
| 3 | NULL |
+-----+-----+

```

```

mysql> select k1, e1 from example1 lateral view explode_json_array_string('[1.0,2.0,3.0]') tmp1 as e1 order by k1, e1;
+-----+-----+
| k1 | e1 |
+-----+-----+
| 1 | 1.000000 |
| 1 | 2.000000 |
| 1 | 3.000000 |
| 2 | 1.000000 |
| 2 | 2.000000 |
| 2 | 3.000000 |
| 3 | 1.000000 |
| 3 | 2.000000 |
| 3 | 3.000000 |
+-----+-----+

```

```

mysql> select k1, e1 from example1 lateral view explode_json_array_string('[1,"b",3]') tmp1 as e1 order by k1, e1;
+-----+-----+
| k1 | e1 |
+-----+-----+
| 1 | 1 |
| 1 | 3 |
| 1 | b |
| 2 | 1 |
| 2 | 3 |
| 2 | b |
| 3 | 1 |
| 3 | 3 |
| 3 | b |
+-----+-----+

```

```

mysql> select k1, e1 from example1 lateral view explode_json_array_string('["a","b","c"]') tmp1 as e1 order by k1, e1;
+-----+-----+
| k1 | e1 |
+-----+-----+
| 1 | a |
| 1 | b |
| 1 | c |
| 2 | a |
| 2 | b |
| 2 | c |
| 3 | a |
| 3 | b |
| 3 | c |
+-----+-----+

```

```

mysql> select k1, e1 from example1 lateral view explode_json_array_string('{ "a": 3 }') tmp1 as e1 order by k1, e1;
+-----+-----+
| k1 | e1 |
+-----+-----+
| 1 | NULL |
+-----+-----+

```

	2	NULL	
	3	NULL	
+-----+-----+			

```
mysql> select k1, e1 from example1 lateral view explode_json_array_json('["id":1,"name":"John"},
{"id":2,"name":"Mary"},{"id":3,"name":"Bob"}]') tmp1 as e1 order by k1, e1;
```

+-----+-----+			
	k1	e1	
+-----+-----+			
	1	{"id":1,"name":"John"}	
	1	{"id":2,"name":"Mary"}	
	1	{"id":3,"name":"Bob"}	
	2	{"id":1,"name":"John"}	
	2	{"id":2,"name":"Mary"}	
	2	{"id":3,"name":"Bob"}	
	3	{"id":1,"name":"John"}	
	3	{"id":2,"name":"Mary"}	
	3	{"id":3,"name":"Bob"}	
+-----+-----+			

## keywords

explode,json,array,json\_array,explode\_json,explode\_json\_array

# EXPLODE

## explode

### 描述

表函数，需配合 Lateral View 使用。

将 array 列展开成多行。当 array 为NULL或者为空时，explode\_outer 返回NULL。explode 和 explode\_outer 都会返回 array 内部的NULL元素。

### 语法

```
explode(expr)
explode_outer(expr)
```

### 举例

```
mysql> select e1 from (select 1 k1) as t lateral view explode([1,2,3]) tmp1 as e1;
+-----+
| e1 |
+-----+
| 1 |
| 2 |
| 3 |
+-----+

mysql> select e1 from (select 1 k1) as t lateral view explode_outer(null) tmp1 as e1;
+-----+
| e1 |
+-----+
| NULL |
+-----+

mysql> select e1 from (select 1 k1) as t lateral view explode([]) tmp1 as e1;
Empty set (0.010 sec)

mysql> select e1 from (select 1 k1) as t lateral view explode([null,1,null]) tmp1 as e1;
+-----+
| e1 |
+-----+
| NULL |
| 1 |
| NULL |
+-----+

mysql> select e1 from (select 1 k1) as t lateral view explode_outer([null,1,null]) tmp1 as e1;
+-----+
| e1 |
+-----+
| NULL |
| 1 |
+-----+
```

| NULL |  
+-----+

## keywords

EXPLODE,EXPLODE\_OUTER,ARRAY

# EXPLODE\_SPLIT

## explode\_split

### 描述

表函数，需配合 Lateral View 使用。

将一个字符串按指定的分隔符分割成多个子串。

### 语法

`explode_split(str, delimiter)`

### 举例

原表数据：

```
mysql> select * from example1 order by k1;
+-----+-----+
| k1 | k2 |
+-----+-----+
| 1 | |
| 2 | NULL |
| 3 | , |
| 4 | 1 |
| 5 | 1,2,3 |
| 6 | a, b, c |
+-----+-----+
```

Lateral View:

```
mysql> select k1, e1 from example1 lateral view explode_split(k2, ',') tmp1 as e1 where k1 = 1 order by k1,
e1;
+-----+-----+
| k1 | e1 |
+-----+-----+
| 1 | |
+-----+-----+

mysql> select k1, e1 from example1 lateral view explode_split(k2, ',') tmp1 as e1 where k1 = 2 order by k1,
e1;
Empty set

mysql> select k1, e1 from example1 lateral view explode_split(k2, ',') tmp1 as e1 where k1 = 3 order by k1,
e1;
+-----+-----+
| k1 | e1 |
+-----+-----+
| 3 | |
+-----+-----+

mysql> select k1, e1 from example1 lateral view explode_split(k2, ',') tmp1 as e1 where k1 = 4 order by k1,
```

```

e1;
+-----+-----+
| k1 | e1 |
+-----+-----+
| 4 | 1 |
+-----+-----+

mysql> select k1, e1 from example1 lateral view explode_split(k2, ',') tmp1 as e1 where k1 = 5 order by k1,
e1;
+-----+-----+
| k1 | e1 |
+-----+-----+
| 5 | 2 |
| 5 | 3 |
| 5 | 1 |
+-----+-----+

mysql> select k1, e1 from example1 lateral view explode_split(k2, ',') tmp1 as e1 where k1 = 6 order by k1,
e1;
+-----+-----+
| k1 | e1 |
+-----+-----+
| 6 | b |
| 6 | c |
| 6 | a |
+-----+-----+

```

## keywords

explode,split,explode\_split



# EXPLODE\_BITMAP

## explode\_bitmap

### 描述

表函数，需配合 Lateral View 使用。

展开一个bitmap类型。

### 语法

```
explode_bitmap(bitmap)
```

### 举例

原表数据：

```
mysql> select k1 from example1 order by k1;
+-----+
| k1 |
+-----+
| 1 |
| 2 |
| 3 |
| 4 |
| 5 |
| 6 |
+-----+
```

Lateral View:

```
mysql> select k1, e1 from example1 lateral view explode_bitmap(bitmap_empty()) tmp1 as e1 order by k1, e1;
Empty set
```

```
mysql> select k1, e1 from example1 lateral view explode_bitmap(bitmap_from_string("1")) tmp1 as e1 order by k1, e1;
```

```
+-----+-----+
| k1 | e1 |
+-----+-----+
| 1 | 1 |
| 2 | 1 |
| 3 | 1 |
| 4 | 1 |
| 5 | 1 |
| 6 | 1 |
+-----+-----+
```

```
mysql> select k1, e1 from example1 lateral view explode_bitmap(bitmap_from_string("1,2")) tmp1 as e1 order by k1, e1;
```

```
+-----+-----+
| k1 | e1 |
+-----+-----+
```

	1		1	
	1		2	
	2		1	
	2		2	
	3		1	
	3		2	
	4		1	
	4		2	
	5		1	
	5		2	
	6		1	
	6		2	
+-----+-----+				

```
mysql> select k1, e1 from example1 lateral view explode_bitmap(bitmap_from_string("1,1000")) tmp1 as e1 order
by k1, e1;
```

+-----+-----+				
	k1		e1	
+-----+-----+				
	1		1	
	1		1000	
	2		1	
	2		1000	
	3		1	
	3		1000	
	4		1	
	4		1000	
	5		1	
	5		1000	
	6		1	
	6		1000	
+-----+-----+				

```
mysql> select k1, e1, e2 from example1
lateral view explode_bitmap(bitmap_from_string("1,1000")) tmp1 as e1
lateral view explode_split("a,b", ",") tmp2 as e2 order by k1, e1, e2;
```

+-----+-----+-----+						
	k1		e1		e2	
+-----+-----+-----+						
	1		1		a	
	1		1		b	
	1		1000		a	
	1		1000		b	
	2		1		a	
	2		1		b	
	2		1000		a	
	2		1000		b	
	3		1		a	
	3		1		b	
	3		1000		a	
	3		1000		b	
	4		1		a	
	4		1		b	
	4		1000		a	
	4		1000		b	
	5		1		a	
	5		1		b	
	5		1000		a	
	5		1000		b	
	6		1		a	
	6		1		b	
	6		1000		a	
	6		1000		b	
+-----+-----+-----+						

## keywords

explode,bitmap,explode\_bitmap

# NUMBERS

---

## numbers

### 描述

表函数，生成一张只含有一列的临时表，列名为number，如果指定了const\_value，则所有元素值均为const\_value，否则为[0,number)递增。

### 语法

```
numbers(
 "number" = "n"
 <, "const_value" = "x">
);
```

参数： - number: 行数。 - const\_value: 常量值。

### 举例

```
mysql> select * from numbers("number" = "5");
+-----+
| number |
+-----+
| 0 |
| 1 |
| 2 |
| 3 |
| 4 |
+-----+
5 rows in set (0.11 sec)

mysql> select * from numbers("number" = "5", "const_value" = "-123");
+-----+
| number |
+-----+
| -123 |
| -123 |
| -123 |
| -123 |
| -123 |
+-----+
5 rows in set (0.12 sec)
```

### keywords

```
numbers, const_value
```

# EXPLODE\_NUMBERS

---

## explode\_numbers

### 描述

表函数，需配合 Lateral View 使用。

获得一个[0,n)的序列。

### 语法

`explode_numbers(n)`

### 举例

```
mysql> select e1 from (select 1 k1) as t lateral view explode_numbers(5) tmp1 as e1;
+-----+
| e1 |
+-----+
| 0 |
| 1 |
| 2 |
| 3 |
| 4 |
+-----+
```

### keywords

explode,numbers,explode\_numbers

# OUTER 组合器

---

## outer组合器

### 描述

在table function的函数名后面添加\_outer后缀使得函数行为从non-outer变为outer,在表函数生成0行数据时添加一行Null数据。### 语法 explode\_numbers(INT x)

### 举例

```
mysql> select e1 from (select 1 k1) as t lateral view explode_numbers(0) tmp1 as e1;
Empty set

mysql> select e1 from (select 1 k1) as t lateral view explode_numbers_outer(0) tmp1 as e1;
+-----+
| e1 |
+-----+
| NULL |
+-----+
```

### keywords

outer

# S3

## S3

### Name

s3

### 描述

S3 表函数 (table-valued-function,tvf), 可以让用户像访问关系表格式数据一样, 读取并访问 S3 兼容的对象存储上的文件内容。目前支持csv/csv\_with\_names/csv\_with\_names\_and\_types/json/parquet/orc文件格式。

### 语法

```
s3(
 "uri" = "...",
 "s3.access_key" = "...",
 "s3.secret_key" = "...",
 "s3.region" = "...",
 "format" = "csv",
 "keyn" = "valuen",
 ...
);
```

### 参数说明

S3 TVF 中的每一个参数都是一个 "key"="value" 对。访问 S3 相关参数: - uri: (必填) 访问 S3 的 URI, S3 表函数会根据 use\_path\_style 参数来决定是否使用 Path Style 访问方式, 默认为 Virtual-hosted Style 方式 - s3.access\_key: (必填) - s3.secret\_key: (必填) - s3.region: (选填)。如果 Minio 服务设置了其他的 Region, 那么必填, 否则默认使用us-east-1。 - s3.session\_token: (选填) - use\_path\_style: (选填) 默认为false。S3 SDK 默认使用 Virtual-hosted Syle 方式。但某些对象存储系统可能没开启或没支持 Virtual-hosted Style 方式的访问, 此时我们可以添加 use\_path\_style 参数来强制使用 Path Style 方式。比如 minio 默认情况下只允许 path style 访问方式, 所以在访问 MinIO 时要加上 use\_path\_style=true。 - force\_parsing\_by\_standard\_uri: (选填) 默认 false。我们可以添加 force\_parsing\_by\_standard\_uri 参数来强制将非标准的 URI 解析为标准 URI。

对于 AWS S3, 标准 uri styles 有以下几种: 1. AWS Client Style(Hadoop S3 Style): s3://my-bucket/path/to/file?versionId=abc123&partNumber=77&partNumber=88。 2. Virtual Host Style:https://my-bucket.s3.us-west-1.amazonaws.com/resources/doc.txt?versionId=abc123&partNumber=77&partNumber=88。 3. Path Style:https://s3.us-west-1.amazonaws.com/my-bucket/resources/doc.txt?versionId=abc123&partNumber=77&partNumber=88。

除了支持以上三个标准常见的 URI Styles, 还支持其他一些 URI Styles (也许不常见, 但也有可能有): 1. Virtual Host AWS Client (Hadoop S3) Mixed Style: s3://my-bucket.s3.us-west-

1. `amazonaws.com/resources/doc.txt?versionId=abc123&partNumber=77&partNumber=88` 2. Path  
AWS Client (Hadoop S3) Mixed Style: `s3://s3.us-west-1.amazonaws.com/my-bucket/resources/doc.txt?versionId=abc123&partNumber=77&partNumber=88`

详细使用案例可以参考最下方 Best Practice。

文件格式参数：- format: (必填) 目前支持

csv/csv\_with\_names/csv\_with\_names\_and\_types/json/parquet/orc - column\_separator: (选填) 列分割符，默认为 \t。- line\_delimiter: (选填) 行分割符，默认为 \n。- compress\_type: (选填) 目前支持 UNKNOWN/PLAIN/GZ/LZO/BZ2/LZ4FRAME/DEFLATE/SNAPPYBLOCK。默认值为 UNKNOWN, 将会根据 uri 的后缀自动推断类型。

下面 6 个参数是用于 JSON 格式的导入，具体使用方法可以参照：[Json Load](#)

- read\_json\_by\_line: (选填) 默认为 "true"
- strip\_outer\_array: (选填) 默认为 "false"
- json\_root: (选填) 默认为空
- jsonpaths: (选填) 默认为空
- num\_as\_string: (选填) 默认为 false
- fuzzy\_parse: (选填) 默认为 false

下面 2 个参数是用于 CSV 格式的导入

- trim\_double\_quotes: 布尔类型，选填，默认值为 false，为 true 时表示裁剪掉 CSV 文件每个字段最外层的双引号
- skip\_lines: 整数类型，选填，默认值为 0，含义为跳过 CSV 文件的前几行。当设置 format 设置为 csv\_with\_names 或 csv\_with\_names\_and\_types 时，该参数会失效

其他参数：- path\_partition\_keys: (选填) 指定文件路径中携带的分区列名，例如

/path/to/city=beijing/date="2023-07-09", 则填写 path\_partition\_keys="city,date", 将会自动从路径中读取相应列名和列值进行导入。- resource: (选填) 指定 Resource 名，S3 TVF 可以利用已有的 S3 Resource 来直接访问 S3。创建 S3 Resource 的方法可以参照 [CREATE-RESOURCE](#)。该功能自 2.1.4 版本开始支持。

## 注意

直接查询 TVF 或基于该 TVF 创建 View，需要拥有该 Resource 的 USAGE 权限，查询基于 TVF 创建的 View，只需要该 View 的 SELECT 权限。

## 举例

读取并访问 S3 兼容的对象存储上的 CSV 格式文件

```
select * from s3("uri" = "http://127.0.0.1:9312/test2/student1.csv",
 "s3.access_key" = "minioadmin",
 "s3.secret_key" = "minioadmin",
 "format" = "csv",
 "use_path_style" = "true") order by c1;
```



可以配合 desc function 使用

```
MySQL [(none)]> Desc function s3("uri" = "http://127.0.0.1:9312/test2/student1.csv",
 "s3.access_key"= "minioadmin",
 "s3.secret_key" = "minioadmin",
 "format" = "csv",
 "use_path_style" = "true");
```

## Keywords

S3, table-valued-function, TVF

## Best Practice

不同 url schema 的写法 http:// 、 https:// 使用示例：

```
// 注意URI Bucket写法以及`use_path_style`参数设置, HTTP 同理。
// 由于设置了 `use_path_style`="true", 所以将采用 Path Style 的方式访问 S3。
select * from s3(
 "uri" = "https://endpoint/bucket/file/student.csv",
 "s3.access_key"= "ak",
 "s3.secret_key" = "sk",
 "format" = "csv",
 "use_path_style"="true");

// 注意 URI Bucket写法以及use_path_style参数设置, http同理。
// 由于设置了 `use_path_style`="false", 所以将采用 Virtual-hosted Style 方式访问 S3。
select * from s3(
 "uri" = "https://bucket.endpoint/bucket/file/student.csv",
 "s3.access_key"= "ak",
 "s3.secret_key" = "sk",
 "format" = "csv",
 "use_path_style"="false");

// 阿里云 OSS 和腾讯云 COS 采用 Virtual-hosted Style 方式访问 S3。
// OSS
select * from s3(
 "uri" = "http://example-bucket.oss-cn-beijing.aliyuncs.com/your-folder/file.parquet",
 "s3.access_key"= "ak",
 "s3.secret_key" = "sk",
 "s3.region" = "oss-cn-beijing",
 "format" = "parquet",
 "use_path_style" = "false");
// COS
select * from s3(
 "uri" = "https://example-bucket.cos.ap-hongkong.myqcloud.com/your-folder/file.parquet",
 "s3.access_key"= "ak",
 "s3.secret_key" = "sk",
 "s3.region" = "ap-hongkong",
 "format" = "parquet",
 "use_path_style" = "false");

// MinIO
select * from s3(
 "uri" = "s3://bucket/file.csv",
 "s3.endpoint" = "http://172.21.0.101:9000",
 "s3.access_key"= "ak",
 "s3.secret_key" = "sk",
 "s3.region" = "us-east-1",
```

```

 "format" = "csv"
);

// 百度云 B0S 采用兼容 S3 协议的 Virtual-hosted Style 方式访问 S3。
// B0S
select * from s3(
 "uri" = "https://example-bucket.s3.bj.bcebos.com/your-folder/file.parquet",
 "s3.access_key" = "ak",
 "s3.secret_key" = "sk",
 "s3.region" = "bj",
 "format" = "parquet",
 "use_path_style" = "false");

```

s3:// 使用示例：

```

// 注意 URI Bucket 写法，无需设置 `use_path_style` 参数。
// 将采用 Virtual-hosted Style 方式访问 S3。
select * from s3(
 "uri" = "s3://bucket/file/student.csv",
 "s3.endpoint" = "endpoint",
 "s3.region" = "region",
 "s3.access_key" = "ak",
 "s3.secret_key" = "sk",
 "format" = "csv");

```

其它支持的 URI 风格示例：

```

// Virtual Host AWS Client (Hadoop S3) Mixed Style。通过设置 `use_path_style = false` 以及
`force_parsing_by_standard_uri = true` 来使用。
select * from s3(
 "URI" = "s3://my-bucket.s3.us-west-1.amazonaws.com/resources/doc.txt?
versionId=abc123&partNumber=77&partNumber=88",
 "s3.access_key" = "ak",
 "s3.secret_key" = "sk",
 "format" = "csv",
 "use_path_style" = "false",
 "force_parsing_by_standard_uri" = "true");

// Path AWS Client (Hadoop S3) Mixed Style。通过设置 `use_path_style = true` 以及 `force_parsing_by_standard_uri
= true` 来使用。
select * from s3(
 "URI" = "s3://s3.us-west-1.amazonaws.com/my-bucket/resources/doc.txt?
versionId=abc123&partNumber=77&partNumber=88",
 "s3.access_key" = "ak",
 "s3.secret_key" = "sk",
 "format" = "csv",
 "use_path_style" = "true",
 "force_parsing_by_standard_uri" = "true");

```

**CSV format** 由于 S3 table-valued-function 事先并不知道 Table Schema，所以会先读一遍文件来解析出 Table Schema。

csv 格式：S3 table-valued-function 读取 S3 上的文件并当作 CSV 文件来处理，读取文件中的第一行用于解析 Table Schema。文件第一行的列个数 n 将作为 Table Schema 的列个数，Table Schema 的列名则自动取名为 c1, c2, ..., cn，列类型都设置为 String，举例：

student1.csv 文件内容为：

```
1,ftw,12
2,zs,18
3,ww,20
```

## 使用 S3 TVF

```
MySQL [(none)]> select * from s3("uri" = "http://127.0.0.1:9312/test2/student1.csv",
-> "s3.access_key"= "minioadmin",
-> "s3.secret_key" = "minioadmin",
-> "format" = "csv",
-> "use_path_style" = "true") order by c1;
+-----+-----+-----+
| c1 | c2 | c3 |
+-----+-----+-----+
| 1 | ftw | 12 |
| 2 | zs | 18 |
| 3 | ww | 20 |
+-----+-----+-----+
```

可以配合 desc function S3() 来查看 Table Schema

```
MySQL [(none)]> Desc function s3("uri" = "http://127.0.0.1:9312/test2/student1.csv",
-> "s3.access_key"= "minioadmin",
-> "s3.secret_key" = "minioadmin",
-> "format" = "csv",
-> "use_path_style" = "true");
+-----+-----+-----+-----+-----+-----+
| Field | Type | Null | Key | Default | Extra |
+-----+-----+-----+-----+-----+-----+
| c1 | TEXT | Yes | false | NULL | NONE |
| c2 | TEXT | Yes | false | NULL | NONE |
| c3 | TEXT | Yes | false | NULL | NONE |
+-----+-----+-----+-----+-----+-----+
```

**csv\_with\_names format** csv\_with\_names 格式：解析文件的第一行作为 Table Schema 的列个数和列名，列类型则都设置为 String，举例：

student\_with\_names.csv 文件内容为

```
id,name,age
1,ftw,12
2,zs,18
3,ww,20
```

## 使用 S3 tvf

```
MySQL [(none)]> select * from s3("uri" = "http://127.0.0.1:9312/test2/student_with_names.csv",
-> "s3.access_key"= "minioadmin",
-> "s3.secret_key" = "minioadmin",
-> "format" = "csv_with_names",
-> "use_path_style" = "true") order by id;
+-----+-----+-----+
| id | name | age |
+-----+-----+-----+
| 1 | ftw | 12 |
| 2 | zs | 18 |
+-----+-----+-----+
```

3	ww	20
---	----	----

同样配合 desc function S3() 可查看 Table Schema

```
MySQL [(none)]> Desc function s3("uri" = "http://127.0.0.1:9312/test2/student_with_names.csv",
-> "s3.access_key"= "minioadmin",
-> "s3.secret_key" = "minioadmin",
-> "format" = "csv_with_names",
-> "use_path_style" = "true");
```

Field	Type	Null	Key	Default	Extra
id	TEXT	Yes	false	NULL	NONE
name	TEXT	Yes	false	NULL	NONE
age	TEXT	Yes	false	NULL	NONE

### csv\_with\_names\_and\_types format

csv\_with\_names\_and\_types 格式：目前暂不支持从 CSV 文件中解析出 Column Type。使用该 Format 时，S3 TVF 会解析文件的第一行作为 Table Schema 的列个数和列名，列类型则都设置为 String，同时将忽略该文件的第二行。

student\_with\_names\_and\_types.csv 文件内容为

```
id,name,age
INT,STRING,INT
1,ftw,12
2,zs,18
3,ww,20
```

使用 S3 TVF

```
MySQL [(none)]> select * from s3("uri" = "http://127.0.0.1:9312/test2/student_with_names_and_types.csv",
-> "s3.access_key"= "minioadmin",
-> "s3.secret_key" = "minioadmin",
-> "format" = "csv_with_names_and_types",
-> "use_path_style" = "true") order by id;
```

id	name	age
1	ftw	12
2	zs	18
3	ww	20

同样配合 desc function S3() 可查看 Table Schema

```
MySQL [(none)]> Desc function s3("uri" = "http://127.0.0.1:9312/test2/student_with_names_and_types.csv",
-> "s3.access_key"= "minioadmin",
-> "s3.secret_key" = "minioadmin",
-> "format" = "csv_with_names_and_types",
-> "use_path_style" = "true");
```

Field	Type	Null	Key	Default	Extra
id	TEXT	Yes	false	NULL	NONE
name	TEXT	Yes	false	NULL	NONE
age	TEXT	Yes	false	NULL	NONE

id	TEXT	Yes	false	NULL	NONE
name	TEXT	Yes	false	NULL	NONE
age	TEXT	Yes	false	NULL	NONE

## JSON format

json 格式：JSON 格式涉及到较多的可选参数，各个参数的意义可以参考：[Json Load](#)。S3 TVF 查询 JSON 格式文件时根据 json\_root 和 jsonpaths 参数定位到一个 JSON 对象，将该对象的中的 key 作为 Table Schema 的列名，列类型都设置为 String。举例：

data.json 文件

```
[{"id":1, "name":"ftw", "age":18}]
[{"id":2, "name":"xxx", "age":17}]
[{"id":3, "name":"yyy", "age":19}]
```

使用 S3 TVF 查询

```
MySQL [(none)]> select * from s3(
 "uri" = "http://127.0.0.1:9312/test2/data.json",
 "s3.access_key"= "minioadmin",
 "s3.secret_key" = "minioadmin",
 "format" = "json",
 "strip_outer_array" = "true",
 "read_json_by_line" = "true",
 "use_path_style"="true");
```

id	name	age
1	ftw	18
2	xxx	17
3	yyy	19

```
MySQL [(none)]> select * from s3(
 "uri" = "http://127.0.0.1:9312/test2/data.json",
 "s3.access_key"= "minioadmin",
 "s3.secret_key" = "minioadmin",
 "format" = "json",
 "strip_outer_array" = "true",
 "jsonpaths" = "[\"$.id\", \"$.age\"]",
 "use_path_style"="true");
```

id	age
1	18
2	17
3	19

## Parquet format

parquet 格式：S3 TVF 支持从 Parquet 文件中解析出 Table Schema 的列名、列类型。举例：

```
MySQL [(none)]> select * from s3(
 "uri" = "http://127.0.0.1:9312/test2/test.snappy.parquet",
 "s3.access_key"= "minioadmin",
```

```
"s3.secret_key" = "minioadmin",
"format" = "parquet",
"use_path_style"="true") limit 5;
```

p_partkey	p_name	p_mfgr	p_brand	p_type
p_size	p_container	p_retailprice	p_comment	
1	goldenrod lavender spring chocolate lace	Manufacturer#1	Brand#13	PROMO BURNISHED COPPER
7	JUMBO PKG	901	ly. slyly ironi	
2	blush thistle blue yellow saddle	Manufacturer#1	Brand#13	LARGE BRUSHED BRASS
1	LG CASE	902	lar accounts amo	
3	spring green yellow purple cornsilk	Manufacturer#4	Brand#42	STANDARD POLISHED BRASS
21	WRAP CASE	903	egular deposits hag	
4	cornflower chocolate smoke green pink	Manufacturer#3	Brand#34	SMALL PLATED BRASS
14	MED DRUM	904	p furiously r	
5	forest brown coral puff cream	Manufacturer#3	Brand#32	STANDARD POLISHED TIN
15	SM PKG	905	wake carefully	

```
MySQL [(none)]> desc function s3(
 "uri" = "http://127.0.0.1:9312/test2/test.snappy.parquet",
 "s3.access_key"= "minioadmin",
 "s3.secret_key" = "minioadmin",
 "format" = "parquet",
 "use_path_style"="true");
```

Field	Type	Null	Key	Default	Extra
p_partkey	INT	Yes	false	NULL	NONE
p_name	TEXT	Yes	false	NULL	NONE
p_mfgr	TEXT	Yes	false	NULL	NONE
p_brand	TEXT	Yes	false	NULL	NONE
p_type	TEXT	Yes	false	NULL	NONE
p_size	INT	Yes	false	NULL	NONE
p_container	TEXT	Yes	false	NULL	NONE
p_retailprice	DECIMAL(9,0)	Yes	false	NULL	NONE
p_comment	TEXT	Yes	false	NULL	NONE

## orc format

orc 格式：和 parquet format 使用方法一致，将 format 参数设置为 orc。

```
MySQL [(none)]> select * from s3(
 "uri" = "http://127.0.0.1:9312/test2/test.snappy.orc",
 "s3.access_key"= "minioadmin",
 "s3.secret_key" = "minioadmin",
 "format" = "orc",
 "use_path_style"="true") limit 5;
```

p_partkey	p_name	p_mfgr	p_brand	p_type
p_size	p_container	p_retailprice	p_comment	
1	goldenrod lavender spring chocolate lace	Manufacturer#1	Brand#13	PROMO BURNISHED COPPER
7	JUMBO PKG	901	ly. slyly ironi	
2	blush thistle blue yellow saddle	Manufacturer#1	Brand#13	LARGE BRUSHED BRASS
1	LG CASE	902	lar accounts amo	

3	spring green yellow purple cornsilk	Manufacturer#4	Brand#42	STANDARD POLISHED BRASS
21	WRAP CASE	903	egular deposits hag	
4	cornflower chocolate smoke green pink	Manufacturer#3	Brand#34	SMALL PLATED BRASS
14	MED DRUM	904	p furiously r	
5	forest brown coral puff cream	Manufacturer#3	Brand#32	STANDARD POLISHED TIN
15	SM PKG	905	wake carefully	

## avro format

avro 格式：S3 TVF 支持从 avro 文件中解析出 Table Schema 的列名、列类型。举例：

```
select * from s3(
 "uri" = "http://127.0.0.1:9312/test2/person.avro",
 "ACCESS_KEY" = "ak",
 "SECRET_KEY" = "sk",
 "FORMAT" = "avro");
```

name	boolean_type	double_type	long_type
Alyssa	1	10.0012	100000000221133
Ben	0	5555.999	4009990000
lisi	0	5992225.999	9099933330

## URI 包含通配符

URI 可以使用通配符来读取多个文件。注意：如果使用通配符要保证各个文件的格式是一致的 (尤其是 csv/csv\_with\_names/csv\_with\_names\_and\_types 算做不同的格式)，S3 TVF 用第一个文件来解析出 Table Schema。如下两个 CSV 文件：

```
// file1.csv
1,aaa,18
2,qqq,20
3,qwe,19

// file2.csv
5,cyx,19
6,ftw,21
```

可以在 URI 上使用通配符来导入。

```
MySQL [(none)]> select * from s3(
 "uri" = "http://127.0.0.1:9312/test2/file*.csv",
 "s3.access_key"= "minioadmin",
 "s3.secret_key" = "minioadmin",
 "format" = "csv",
 "use_path_style"="true");
```

c1	c2	c3
1	aaa	18
2	qqq	20
3	qwe	19
5	cyx	19
6	ftw	21

## 配合 insert into 和 cast 使用 S3 TVF

```
// 创建 Doris 内部表
CREATE TABLE IF NOT EXISTS ${testTable}
(
 id int,
 name varchar(50),
 age int
)
COMMENT "my first table"
DISTRIBUTED BY HASH(id) BUCKETS 32
PROPERTIES("replication_num" = "1");

// 使用 S3 插入数据
insert into ${testTable} (id,name,age)
select cast (id as INT) as id, name, cast (age as INT) as age
from s3(
 "uri" = "${uri}",
 "s3.access_key"= "${ak}",
 "s3.secret_key" = "${sk}",
 "format" = "${format}",
 "strip_outer_array" = "true",
 "read_json_by_line" = "true",
 "use_path_style" = "true");
```



# HDFS

## HDFS

### 描述

HDFS 表函数 (table-valued-function,tvf), 可以让用户像访问关系表格式数据一样, 读取并访问 HDFS 上的文件内容。目前支持csv/csv\_with\_names/csv\_with\_names\_and\_types/json/parquet/orc文件格式。

### 语法

```
hdfs(
 "uri" = "...",
 "fs.defaultFS" = "...",
 "hadoop.username" = "...",
 "format" = "csv",
 "keyn" = "valuen"
 ...
);
```

### 参数说明

访问 HDFS 相关参数: - uri: (必填) 访问 HDFS 的 uri。如果 uri 路径不存在或文件都是空文件, HDFS TVF 将返回空集合。 - fs.defaultFS: (必填) - hadoop.username: (必填) 可以是任意字符串, 但不能为空 - hadoop.security.authentication: (选填) - hadoop.username: (选填) - hadoop.kerberos.principal: (选填) - hadoop.kerberos.keytab: (选填) - dfs.client.read.shortcircuit: (选填) - dfs.domain.socket.path: (选填)

访问 HA 模式 HDFS 相关参数: - dfs.nameservices: (选填) - dfs.ha.namenodes.your-nameservices: (选填) - dfs.namenode.rpc-address.your-nameservices.your-namenode: (选填) - dfs.client.failover.proxy.provider.your-nameservices: (选填)

文件格式相关参数: - format: (必填) 目前支持

csv/csv\_with\_names/csv\_with\_names\_and\_types/json/parquet/orc/avro - column\_separator: (选填) 列分割符, 默认为\t。 - line\_delimiter: (选填) 行分割符, 默认为\n。 - compress\_type: (选填) 目前支持 UNKNOWN/PLAIN/GZ/LZO/BZ2/LZ4FRAME/DEFLATE/SNAPPYBLOCK。默认值为 UNKNOWN, 将会根据 uri 的后缀自动推断类型。

下面 6 个参数是用于 JSON 格式的导入, 具体使用方法可以参照: [JSON Load](../../data-operate/import/file-format/json)

- read\_json\_by\_line: (选填) 默认为 "true"
- strip\_outer\_array: (选填) 默认为 "false"
- json\_root: (选填) 默认为空
- json\_paths: (选填) 默认为空

- num\_as\_string: (选填) 默认为 false
- fuzzy\_parse: (选填) 默认为 false

下面 2 个参数用于 CSV 格式的导入:

- trim\_double\_quotes: 布尔类型, 选填, 默认值为 false, 为 true 时表示裁剪掉 CSV 文件每个字段最外层的双引号
- skip\_lines: 整数类型, 选填, 默认值为 0, 含义为跳过 CSV 文件的前几行。当设置 Format 设置为 csv\_with\_names 或 csv\_with\_names\_and\_types 时, 该参数会失效

其他参数: - path\_partition\_keys: (选填) 指定文件路径中携带的分区列名, 例如/path/to/city=beijing/date="2023-07-09", 则填写path\_partition\_keys="city,date", 将会自动从路径中读取相应列名和列值进行导入。- resource: (选填) 指定 Resource 名, HDFS TVF 可以利用已有的 HDFS Resource 来直接访问 HDFS。创建 HDFS Resource 的方法可以参照 [CREATE-RESOURCE](#)。该功能自 2.1.4 版本开始支持。

### 注意

直接查询 TVF 或基于该 TVF 创建 View, 需要拥有该 Resource 的 USAGE 权限, 查询基于 TVF 创建的 View, 只需要该 View 的 SELECT 权限

## 举例s

读取并访问 HDFS 存储上的 CSV 格式文件

```
MySQL [(none)]> select * from hdfs(
 "uri" = "hdfs://127.0.0.1:842/user/doris/csv_format_test/student.csv",
 "fs.defaultFS" = "hdfs://127.0.0.1:8424",
 "hadoop.username" = "doris",
 "format" = "csv");
```

c1	c2	c3
1	alice	18
2	bob	20
3	jack	24
4	jackson	19
5	liming	18

读取并访问 HA 模式的 HDFS 存储上的 CSV 格式文件

```
MySQL [(none)]> select * from hdfs(
 "uri" = "hdfs://127.0.0.1:842/user/doris/csv_format_test/student.csv",
 "fs.defaultFS" = "hdfs://127.0.0.1:8424",
 "hadoop.username" = "doris",
 "format" = "csv",
 "dfs.nameservices" = "my_hdfs",
 "dfs.ha.namenodes.my_hdfs" = "nn1,nn2",
 "dfs.namenode.rpc-address.my_hdfs.nn1" = "nanmenode01:8020",
 "dfs.namenode.rpc-address.my_hdfs.nn2" = "nanmenode02:8020",
```

```
"dfs.client.failover.proxy.provider.my_hdfs" =
"org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider");
```

c1	c2	c3
1	alice	18
2	bob	20
3	jack	24
4	jackson	19
5	liming	18

可以配合 desc function 使用。

```
MySQL [(none)]> desc function hdfs(
 "uri" = "hdfs://127.0.0.1:8424/user/doris/csv_format_test/student_with_names.csv",
 "fs.defaultFS" = "hdfs://127.0.0.1:8424",
 "hadoop.username" = "doris",
 "format" = "csv_with_names");
```

## Keywords

HDFS, table-valued-function, TVF

## Best Practice

关于 HDFS TVF 的更详细使用方法可以参照 [S3](#) TVF, 唯一不同的是访问存储系统的方式不一样。

# LOCAL

---

## local

### Name

local

### 描述

Local表函数（table-valued-function,tvf），可以让用户像访问关系表格式数据一样，读取并访问 be 上的文件内容。目前支持csv/csv\_with\_names/csv\_with\_names\_and\_types/json/parquet/orc文件格式。

该函数需要 ADMIN 权限。

### 语法

```
local(
 "file_path" = "path/to/file.txt",
 "backend_id" = "be_id",
 "format" = "csv",
 "keyn" = "valuen"
 ...
);
```

### 参数说明

- 访问local文件的相关参数：
  - file\_path  
(必填) 待读取文件的路径，该路径是一个相对于 user\_files\_secure\_path 目录的相对路径, 其中 user\_files\_secure\_path 参数是 [be的一个配置项](#)。

路径中不能包含 ..，可以使用 glob 语法进行模糊匹配，如：logs/\*.log

- 执行方式相关：

在 2.1.1 之前的版本中，Doris 仅支持指定某一个 BE 节点，读取该节点上的本地数据文件。

- backend\_id:

文件所在的 be id。backend\_id 可以通过 show backends 命令得到。

从 2.1.2 版本开始，Doris 增加了新的参数 shared\_storage。

- shared\_storage

默认为 false。如果为 true，表示指定的文件存在于共享存储上（比如 NAS）。共享存储必须兼容 POSIX 文件接口，并且同时挂载在所有 BE 节点上。

当 `shared_storage` 为 `true` 时，可以不设置 `backend_id`，Doris 可能会利用到所有 BE 节点进行数据访问。如果设置了 `backend_id`，则仍然仅在指定 BE 节点上执行。

- 文件格式相关参数：

- `format`: (必填) 目前支持  
`csv/csv_with_names/csv_with_names_and_types/json/parquet/orc`
- `column_separator`: (选填) 列分割符, 默认为 `\t`。
- `line_delimiter`: (选填) 行分割符, 默认为 `\n`。
- `compress_type`: (选填) 目前支持  
`UNKNOWN/PLAIN/GZ/LZO/BZ2/LZ4FRAME/DEFLATE/SNAPPYBLOCK`。默认值为 `UNKNOWN`, 将会根据 `uri` 的后缀自动推断类型。

- 以下参数适用于json格式的导入，具体使用方法可以参照：[Json Load](#)

- `read_json_by_line`: (选填) 默认为 `"true"`
- `strip_outer_array`: (选填) 默认为 `"false"`
- `json_root`: (选填) 默认为空
- `json_paths`: (选填) 默认为空
- `num_as_string`: (选填) 默认为 `false`
- `fuzzy_parse`: (选填) 默认为 `false`

- 以下参数适用于csv格式的导入：

- `trim_double_quotes`: 布尔类型，选填，默认值为 `false`，为 `true` 时表示裁剪掉 csv 文件每个字段最外层的双引号
- `skip_lines`: 整数类型，选填，默认值为0，含义为跳过csv文件的前几行。当设置format设置为 `csv_with_names` 或 `csv_with_names_and_types` 时，该参数会失效

- 其他参数：

- `path_partition_keys`: (选填) 指定文件路径中携带的分区列名，例如  
`/path/to/city=beijing/date="2023-07-09"`, 则填写 `path_partition_keys="city,date"`, 将会自动从路径中读取相应列名和列值进行导入。

## 举例s

分析指定 BE 上的日志文件：

```
mysql> select * from local(
 "file_path" = "log/be.out",
 "backend_id" = "10006",
 "format" = "csv")
where c1 like "%start_time%" limit 10;
```

c1
start time: 2023年 08月 07日 星期一 23:20:32 CST
start time: 2023年 08月 07日 星期一 23:32:10 CST
start time: 2023年 08月 08日 星期二 00:20:50 CST
start time: 2023年 08月 08日 星期二 00:29:15 CST

读取和访问位于路径\${DORIS\_HOME}/student.csv的 csv格式文件：

```
mysql> select * from local(
 "file_path" = "student.csv",
 "backend_id" = "10003",
 "format" = "csv");
```

c1	c2	c3
1	alice	18
2	bob	20
3	jack	24
4	jackson	19
5	liming	d18

访问 NAS 上的共享数据：

```
mysql> select * from local(
 "file_path" = "/mnt/doris/prefix_*.txt",
 "format" = "csv",
 "column_separator" = ",",
 "shared_storage" = "true");
```

c1	c2	c3
1	2	3
1	2	3
1	2	3
1	2	3
1	2	3

可以配合desc function使用

```
mysql> desc function local(
 "file_path" = "student.csv",
 "backend_id" = "10003",
 "format" = "csv");
```

Field	Type	Null	Key	Default	Extra
c1	TEXT	Yes	false	NULL	NONE
c2	TEXT	Yes	false	NULL	NONE
c3	TEXT	Yes	false	NULL	NONE

## Keywords

local, table-valued-function, tvf

## Best Practice

- 关于 local tvf 的更详细使用方法可以参照 [S3 tvf](#), 唯一不同的是访问存储系统的方式不一样。
- 通过 local tvf 访问 NAS 上的数据

NAS 共享存储允许同时挂载到多个节点。每个节点都可以像访问本地文件一样访问共享存储中的文件。因此，可以将 NAS 视为本地文件系统，通过 local tvf 进行访问。

当设置 "shared\_storage" = "true" 时，Doris 会认为所指定的文件可以在任意 BE 节点访问。当使用通配符指定了一组文件时，Doris 会将访问文件的请求分发到多个 BE 节点上，这样可以利用多个节点的进行分布式文件扫描，提升查询性能。

# ICEBERG\_META

---

## iceberg\_meta

### Name

iceberg\_meta

### 描述

iceberg\_meta 表函数 (table-valued-function,tvf)，可以用于读取 iceberg 表的各类元数据信息，如操作历史、生成的快照、文件元数据等。

### 语法

```
iceberg_meta(
 "table" = "ctl.db.tbl",
 "query_type" = "snapshots"
 ...
);
```

### 参数说明

iceberg\_meta 表函数 tvf 中的每一个参数都是一个 "key"="value" 对。相关参数：- table: (必填) 完整的表名，需要按照目录名.库名.表名的格式，填写需要查看的 iceberg 表名。- query\_type: (必填) 想要查看的元数据类型，目前仅支持 snapshots。

### 举例

读取并访问 iceberg 表格式的 snapshots 元数据。

```
select * from iceberg_meta("table" = "ctl.db.tbl", "query_type" = "snapshots");
```

可以配合desc function使用

```
desc function iceberg_meta("table" = "ctl.db.tbl", "query_type" = "snapshots");
```

### Keywords

iceberg\_meta, table-valued-function, tvf

### Best Prac

查看 iceberg 表的 snapshots



```
select * from iceberg_meta("table" = "iceberg_ctl.test_db.test_tbl", "query_type" = "snapshots");
```

committed_at	snapshot_id	parent_id	operation	manifest_list	summary
2022-09-20 11:14:29	64123452344	-1	append	hdfs:/path/to/m1	{"flink.job-id":"xxm1", ...}
2022-09-21 10:36:35	98865735822	64123452344	overwrite	hdfs:/path/to/m2	{"flink.job-id":"xxm2", ...}
2022-09-21 21:44:11	51232845315	98865735822	overwrite	hdfs:/path/to/m3	{"flink.job-id":"xxm3", ...}

根据 snapshot\_id 字段筛选

```
select * from iceberg_meta("table" = "iceberg_ctl.test_db.test_tbl", "query_type" = "snapshots")
where snapshot_id = 98865735822;
```

committed_at	snapshot_id	parent_id	operation	manifest_list	summary
2022-09-21 10:36:35	98865735822	64123452344	overwrite	hdfs:/path/to/m2	{"flink.job-id":"xxm2", ...}

# BACKENDS

## backends

### Name

backends

### 描述

表函数，生成 backends 临时表，可以查看当前 doris 集群中的 BE 节点信息。

该函数用于 from 子句中。

### 语法

backends()

backends() 表结构：

```
mysql> desc function backends();
+-----+-----+-----+-----+-----+-----+
| Field | Type | Null | Key | Default | Extra |
+-----+-----+-----+-----+-----+-----+
| BackendId | BIGINT | No | false | NULL | NONE |
| Host | TEXT | No | false | NULL | NONE |
| HeartbeatPort | INT | No | false | NULL | NONE |
| BePort | INT | No | false | NULL | NONE |
| HttpPort | INT | No | false | NULL | NONE |
| BrpcPort | INT | No | false | NULL | NONE |
| LastStartTime | TEXT | No | false | NULL | NONE |
| LastHeartbeat | TEXT | No | false | NULL | NONE |
| Alive | BOOLEAN | No | false | NULL | NONE |
| SystemDecommissioned | BOOLEAN | No | false | NULL | NONE |
| TabletNum | BIGINT | No | false | NULL | NONE |
| DataUsedCapacity | BIGINT | No | false | NULL | NONE |
| AvailCapacity | BIGINT | No | false | NULL | NONE |
| TotalCapacity | BIGINT | No | false | NULL | NONE |
| UsedPct | DOUBLE | No | false | NULL | NONE |
| MaxDiskUsedPct | DOUBLE | No | false | NULL | NONE |
| RemoteUsedCapacity | BIGINT | No | false | NULL | NONE |
| Tag | TEXT | No | false | NULL | NONE |
| ErrMsg | TEXT | No | false | NULL | NONE |
| Version | TEXT | No | false | NULL | NONE |
| Status | TEXT | No | false | NULL | NONE |
| HeartbeatFailureCounter | INT | No | false | NULL | NONE |
| NodeRole | TEXT | No | false | NULL | NONE |
+-----+-----+-----+-----+-----+-----+
23 rows in set (0.002 sec)
```

backends() tfv 展示出来的信息基本与 show backends 语句展示出的信息一致，但是 backends() tfv 的各个字段类型更加明确，且可以利用 tfv 生成的表去做过滤、join 等操作。

对 `backends()` 信息展示进行了鉴权, 与 `show backends` 行为保持一致, 要求用户具有 ADMIN/OPERATOR 权限。

## 举例

```
mysql> select * from backends()\G
***** 1. row *****
 BackendId: 10002
 Host: 10.xx.xx.90
 HeartbeatPort: 9053
 BePort: 9063
 HttpPort: 8043
 BrpcPort: 8069
 LastStartTime: 2023-06-15 16:51:02
 LastHeartbeat: 2023-06-15 17:09:58
 Alive: 1
 SystemDecommissioned: 0
 TabletNum: 21
 DataUsedCapacity: 0
 AvailCapacity: 5187141550081
 TotalCapacity: 7750977622016
 UsedPct: 33.077583202570978
 MaxDiskUsedPct: 33.077583202583881
 RemoteUsedCapacity: 0
 Tag: {"location" : "default"}
 ErrMsg:
 Version: doris-0.0.0-trunk-4b18cde0c7
 Status: {"lastSuccessReportTabletsTime":"2023-06-15
17:09:02","lastStreamLoadTime":-1,"isQueryDisabled":false,"isLoadDisabled":false}
 HeartbeatFailureCounter: 0
 NodeRole: mix
1 row in set (0.038 sec)
```

## keywords

backends

# FRONTENDS

## frontends

### Name

frontends

### 描述

表函数，生成 `frontends` 临时表，可以查看当前 `doris` 集群中的 FE 节点信息。

该函数用于 `from` 子句中。

### 语法

`frontends()`

`frontends()` 表结构：

```
mysql> desc function frontends();
+-----+-----+-----+-----+-----+-----+
| Field | Type | Null | Key | Default | Extra |
+-----+-----+-----+-----+-----+-----+
| Name | TEXT | No | false | NULL | NONE |
| Host | TEXT | No | false | NULL | NONE |
| EditLogPort | TEXT | No | false | NULL | NONE |
| HttpPort | TEXT | No | false | NULL | NONE |
| QueryPort | TEXT | No | false | NULL | NONE |
| RpcPort | TEXT | No | false | NULL | NONE |
| ArrowFlightSqlPort | TEXT | No | false | NULL | NONE |
| Role | TEXT | No | false | NULL | NONE |
| IsMaster | TEXT | No | false | NULL | NONE |
| ClusterId | TEXT | No | false | NULL | NONE |
| Join | TEXT | No | false | NULL | NONE |
| Alive | TEXT | No | false | NULL | NONE |
| ReplayedJournalId | TEXT | No | false | NULL | NONE |
| LastHeartbeat | TEXT | No | false | NULL | NONE |
| IsHelper | TEXT | No | false | NULL | NONE |
| ErrMsg | TEXT | No | false | NULL | NONE |
| Version | TEXT | No | false | NULL | NONE |
| CurrentConnected | TEXT | No | false | NULL | NONE |
+-----+-----+-----+-----+-----+-----+
17 rows in set (0.022 sec)
```

`frontends()` tvf 展示出来的信息基本与 `show frontends` 语句展示出的信息一致，但是 `frontends()` tvf 的各个字段类型更加明确，且可以利用 tvf 生成的表去做过滤、join 等操作。

对 `frontends()` tvf 信息展示进行了鉴权，与 `show frontends` 行为保持一致，要求用户具有 `ADMIN/OPERATOR` 权限。

## 举例

```
mysql> select * from frontends()\G
***** 1. row *****
 Name: fe_5fa8bf19_fd6b_45cb_89c5_25a5ebc45582
 IP: 10.xx.xx.14
 EditLogPort: 9013
 HttpPort: 8034
 QueryPort: 9033
 RpcPort: 9023
ArrowFlightSqlPort: 9040
 Role: FOLLOWER
 IsMaster: true
 ClusterId: 1258341841
 Join: true
 Alive: true
ReplayedJournalId: 186
 LastHeartbeat: 2023-06-15 16:53:12
 IsHelper: true
 ErrMsg:
 Version: doris-0.0.0-trunk-4b18cde0c7
CurrentConnected: Yes
1 row in set (0.060 sec)
```

## keywords

frontends

# FRONTENDS\_DISKS

frontends\_disks

## Name

frontends\_disks

## 描述

表函数，生成 `frontends_disks` 临时表，可以查看当前 `doris` 集群中的 FE 节点的磁盘信息。

该函数用于 `from` 子句中。

## 语法

`frontends_disks()`

`frontends_disks()` 表结构：

```
mysql> desc function frontends_disks();
```

Field	Type	Null	Key	Default	Extra
Name	TEXT	No	false	NULL	NONE
Host	TEXT	No	false	NULL	NONE
DirType	TEXT	No	false	NULL	NONE
Dir	TEXT	No	false	NULL	NONE
Filesystem	TEXT	No	false	NULL	NONE
Capacity	TEXT	No	false	NULL	NONE
Used	TEXT	No	false	NULL	NONE
Available	TEXT	No	false	NULL	NONE
UseRate	TEXT	No	false	NULL	NONE
MountOn	TEXT	No	false	NULL	NONE

11 rows in set (0.14 sec)

`frontends_disks()` `tfv` 展示出来的信息基本与 `show frontends disks` 语句展示出的信息一致，但是 `frontends_disks()` `tfv` 的各个字段类型更加明确，且可以利用 `tfv` 生成的表去做过滤、`join` 等操作。

对 `frontends_disks()` `tfv` 信息展示进行了鉴权，与 `show frontends disks` 行为保持一致，要求用户具有 `ADMIN/OPERATOR` 权限。

## 举例

```
mysql> select * from frontends_disk()\G
```

***** 1. row *****
Name: fe_fe1d5bd9_d1e5_4ccc_9b03_ca79b95c9941
Host: 172.XX.XX.1
DirType: log
Dir: /data/doris/fe-github/log

```
Filesystem: /dev/sdc5
Capacity: 366G
Used: 119G
Available: 228G
UseRate: 35%
MountOn: /data
.....
12 row in set (0.03 sec)
```

## keywords

```
frontends_disks
```

# CATALOGS

## catalogs

### Name

catalogs

### 描述

表函数，生成 catalogs 临时表，可以查看当前doris中的创建的 catalogs 信息。

该函数用于 from 子句中。

### 语法

catalogs()

catalogs()表结构:

```
mysql> desc function catalogs();
+-----+-----+-----+-----+-----+-----+
| Field | Type | Null | Key | Default | Extra |
+-----+-----+-----+-----+-----+-----+
| CatalogId | BIGINT| No | false| NULL | NONE |
| CatalogName| TEXT | No | false| NULL | NONE |
| CatalogType| TEXT | No | false| NULL | NONE |
| Property | TEXT | No | false| NULL | NONE |
| Value | TEXT | No | false| NULL | NONE |
+-----+-----+-----+-----+-----+-----+
5 rows in set (0.04 sec)
```

catalogs() tvf展示的信息是综合了 show catalogs 与 show catalog xxx 语句的结果。

可以利用tvf生成的表去做过滤、join等操作。

### 举例

```
mysql> select * from catalogs();
+-----+-----+-----+-----+-----+-----+
| CatalogId | CatalogName | CatalogType | Property | Value |
+-----+-----+-----+-----+-----+-----+
| 16725 | hive | hms | dfs.client.failover.proxy.provider.HANN | org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider |
| 16725 | hive | hms | dfs.ha.namenodes.HANN | nn1,nn2 |
| 16725 | hive | hms | create_time | 2023-07-13 |
16:24:38.968 |
```



```

| 16725 | hive | hms | ipc.client.fallback-to-simple-auth-allowed | true
|
| 16725 | hive | hms | dfs.namenode.rpc-address.HANN.nn1 | nn1_host:rpc_port
|
| 16725 | hive | hms | hive.metastore.uris |
thrift://127.0.0.1:7004
| 16725 | hive | hms | dfs.namenode.rpc-address.HANN.nn2 | nn2_host:rpc_port
|
| 16725 | hive | hms | type | hms
|
| 16725 | hive | hms | dfs.nameservices | HANN
|
| 0 | internal | internal | NULL | NULL
|
| 16726 | es | es | create_time | 2023-07-13
16:24:44.922
| 16726 | es | es | type | es
|
| 16726 | es | es | hosts | http://127.0.0.1:9200
|
+-----+-----+-----+-----+
-----+
13 rows in set (0.01 sec)

```

## keywords

catalogs

# WORKLOAD\_GROUPS

workload\_groups

## Name

workload\_groups

已废弃。自 2.1.1 起，此表函数移到 `information_schema.workload_groups` 表。

## 描述

表函数，生成 `workload_groups` 临时表，可以查看当前用户具有权限的资源组信息。

该函数用于 `from` 子句中。

## 语法

`workload_groups()`

`workload_groups()`表结构：

```
mysql> desc function workload_groups();
```

Field	Type	Null	Key	Default	Extra
Id	BIGINT	No	false	NULL	NONE
Name	STRING	No	false	NULL	NONE
Item	STRING	No	false	NULL	NONE
Value	STRING	No	false	NULL	NONE

## 举例

```
mysql> select * from workload_groups()\G
```

Id	Name	Item	Value
11001	normal	memory_limit	100%
11001	normal	cpu_share	10

## keywords

workload\_groups

# 窗口函数概述

## 描述

[分析函数](#)（窗口函数）是一类特殊的内置函数。和聚合函数类似，分析函数也是对于多个输入行做计算得到一个数据值。不同的是，分析函数是在一个特定的窗口内对输入数据做处理，而不是按照 `group by` 来分组计算。每个窗口内的数据可以用 `over()` 从句进行排序和分组。分析函数会对结果集的每一行计算出一个单独的值，而不是每个 `group by` 分组计算一个值。这种灵活的方式允许用户在 `select` 从句中增加额外的列，给用户提供了更多的机会来对结果集进行重新组织和过滤。分析函数只能出现在 `select` 列表和最外层的 `order by` 从句中。在查询过程中，分析函数会在最后生效，就是说，在执行完 `join`，`where` 和 `group by` 等操作之后再执行。分析函数在金融和科学计算领域经常被使用到，用来分析趋势、计算离群值以及对大量数据进行分桶分析等。

分析函数的语法：

```
function(args) OVER(partition_by_clause order_by_clause [window_clause])
partition_by_clause ::= PARTITION BY expr [, expr ...]
order_by_clause ::= ORDER BY expr [ASC | DESC] [, expr [ASC | DESC] ...]
```

## Function

目前支持的 Function 包括 `AVG()`，`COUNT()`，`DENSE_RANK()`，`FIRST_VALUE()`，`LAG()`，`LAST_VALUE()`，`LEAD()`，`MAX()`，`MIN()`，`RANK()`，`ROW_NUMBER()` 和 `SUM()`。

## PARTITION BY 从句

Partition By 从句和 Group By 类似。它把输入行按照指定的一列或多列分组，相同值的行会被分到一组。

## ORDER BY 从句

Order By 从句和外层的 Order By 基本一致。它定义了输入行的排列顺序，如果指定了 Partition By，则 Order By 定义了每个 Partition 分组内的顺序。与外层 Order By 的唯一不同点是，OVER 从句中的 Order By `n`（`n`是正整数）相当于不做任何操作，而外层的 Order By `n`表示按照第`n`列排序。

举例：

这个例子展示了在`select`列表中增加一个`id`列，它的值是1，2，3等等，顺序按照`events`表中的`date_and_time`列排序。

```
SELECT
row_number() OVER (ORDER BY date_and_time) AS id,
c1, c2, c3, c4
FROM events;
```

## Window 从句

Window 从句用来为分析函数指定一个运算范围，以当前行为准，前后若干行作为分析函数运算的对象。

Window 从句支持的方法有：AVG(), COUNT(), FIRST\_VALUE(), LAST\_VALUE() 和 SUM()。对于 MAX() 和 MIN(), window 从句可以指定开始范围 UNBOUNDED PRECEDING

语法:

```
ROWS BETWEEN [{ m | UNBOUNDED } PRECEDING | CURRENT ROW] [AND [CURRENT ROW | { UNBOUNDED | n } FOLLOWING]]
```

## 举例

假设我们有如下的股票数据，股票代码是 JDR，closing price 是每天的收盘价。

```
create table stock_ticker (stock_symbol string, closing_price decimal(8,2), closing_date datetime);
...load some data...
select * from stock_ticker order by stock_symbol, closing_date
```

stock_symbol	closing_price	closing_date
JDR	12.86	2014-10-02 00:00:00
JDR	12.89	2014-10-03 00:00:00
JDR	12.94	2014-10-04 00:00:00
JDR	12.55	2014-10-05 00:00:00
JDR	14.03	2014-10-06 00:00:00
JDR	14.75	2014-10-07 00:00:00
JDR	13.98	2014-10-08 00:00:00

这个查询使用分析函数产生 moving\_average 这一列，它的值是3天的股票均价，即前一天、当前以及后一天三天的均价。第一天没有前一天的值，最后一天没有后一天的值，所以这两行只计算了两天的均值。这里 Partition By 没有起到作用，因为所有的数据都是 JDR 的数据，但如果还有其他股票信息，Partition By 会保证分析函数值作用在本 Partition 之内。

```
select stock_symbol, closing_date, closing_price,
avg(closing_price) over (partition by stock_symbol order by closing_date
rows between 1 preceding and 1 following) as moving_average
from stock_ticker;
```

stock_symbol	closing_date	closing_price	moving_average
JDR	2014-10-02 00:00:00	12.86	12.87
JDR	2014-10-03 00:00:00	12.89	12.89
JDR	2014-10-04 00:00:00	12.94	12.79
JDR	2014-10-05 00:00:00	12.55	13.17
JDR	2014-10-06 00:00:00	14.03	13.77
JDR	2014-10-07 00:00:00	14.75	14.25
JDR	2014-10-08 00:00:00	13.98	14.36

## 关键词

WINDOW, FUNCTION

# WINDOW\_FUNCTION\_SUM

## WINDOW FUNCTION SUM

### 描述

计算窗口内数据的和

```
SUM([ALL] expression) [OVER (analytic_clause)]
```

### 举例

按照 property 进行分组，在组内计算当前行以及前后各一行的x列的和。

```
select x, property,
sum(x) over
(
partition by property
order by x
rows between 1 preceding and 1 following
) as 'moving total'
from int_t where property in ('odd','even');
```

x	property	moving total
2	even	6
4	even	12
6	even	18
8	even	24
10	even	18
1	odd	4
3	odd	9
5	odd	15
7	odd	21
9	odd	16

### keywords

```
WINDOW, FUNCTION, SUM
```

# WINDOW\_FUNCTION\_MIN

## WINDOW FUNCTION MIN

### 描述

LEAD() 方法用来计算窗口内的最小值。

```
MAX([DISTINCT | ALL] expression) [OVER (analytic_clause)]
```

### 举例

计算从第一行到当前行之后一行的最小值

```
select x, property,
min(x) over
(
order by property, x desc
rows between unbounded preceding and 1 following
) as 'local minimum'
from int_t where property in ('prime','square');
| x | property | local minimum |
|---|-----|-----|
| 7 | prime | 5 |
| 5 | prime | 3 |
| 3 | prime | 2 |
| 2 | prime | 2 |
| 9 | square | 2 |
| 4 | square | 1 |
| 1 | square | 1 |
```

### keywords

```
WINDOW, FUNCTION, MIN
```

# WINDOW\_FUNCTION\_COUNT

## WINDOW FUNCTION COUNT

### 描述

计算窗口内数据出现次数

```
COUNT(expression) [OVER (analytic_clause)]
```

### 举例

计算从当前行到第一行x出现的次数。

```
select x, property,
count(x) over
(
partition by property
order by x
rows between unbounded preceding and current row
) as 'cumulative total'
from int_t where property in ('odd','even');
```

x	property	cumulative count
2	even	1
4	even	2
6	even	3
8	even	4
10	even	5
1	odd	1
3	odd	2
5	odd	3
7	odd	4
9	odd	5

### keywords

```
WINDOW, FUNCTION, COUNT
```

# WINDOW\_FUNCTION\_RANK

## WINDOW FUNCTION RANK

### 描述

RANK() 函数用来表示排名，与 DENSE\_RANK() 不同的是，RANK() 会出现空缺数字。比如，如果出现了两个并列的1， RANK() 的第三个数就是3，而不是2。

```
RANK() OVER(partition_by_clause order_by_clause)
```

### 举例

根据 x 进行排名

```
select x, y, rank() over(partition by x order by y) as rank from int_t;
```

x	y	rank
1	1	1
1	2	2
1	2	2
2	1	1
2	2	2
2	3	3
3	1	1
3	1	1
3	2	3

### keywords

```
WINDOW, FUNCTION, RANK
```



# WINDOW\_FUNCTION\_DENSE\_RANK

## WINDOW FUNCTION DENSE\_RANK

### 描述

DENSE\_RANK() 函数用来表示排名，与RANK()不同的是，DENSE\_RANK() 不会出现空缺数字。比如，如果出现了两个并列的1，DENSE\_RANK() 的第三个数仍然是2，而RANK()的第三个数是3。

```
DENSE_RANK() OVER(partition_by_clause order_by_clause)
```

### 举例

按照 property 列分组对x列排名：

```
select x, y, dense_rank() over(partition by x order by y) as rank from int_t;
```

x	y	rank
1	1	1
1	2	2
1	2	2
2	1	1
2	2	2
2	3	3
3	1	1
3	1	1
3	2	2

### keywords

```
WINDOW, FUNCTION, DENSE_RANK
```

# WINDOW\_FUNCTION\_FIRST\_VALUE

## WINDOW FUNCTION FIRST\_VALUE

### 描述

#### 备注

自 2.0.9 开始支持 ignore\_null 用法

FIRST\_VALUE() 返回窗口范围内的第一个值， ignore\_null 决定是否忽略 null 值，参数 ignore\_null 默认值为 false 。

```
FIRST_VALUE(expr[, ignore_null]) OVER(partition_by_clause order_by_clause [window_clause])
```

### 举例

我们有如下数据

```
select id, myday, time_col, state from t;
```

id	myday	time_col	state
3	21	04-21-13	3
7	22	04-22-10-24	NULL
8	22	04-22-10-25	9
10	23	04-23-12	10
4	22	04-22-10-21	NULL
9	23	04-23-11	NULL
1	21	04-21-11	NULL
5	22	04-22-10-22	NULL
12	24	02-24-10-21	NULL
2	21	04-21-12	2
6	22	04-22-10-23	5
11	23	04-23-13	NULL

使用 FIRST\_VALUE(), 根据 myday 分组，返回每个分组中第一个 state 的值：

```
select *,
first_value(`state`, 1) over(partition by `myday` order by `time_col` rows between 1 preceding and 1
following) as ignore_null,
first_value(`state`, 0) over(partition by `myday` order by `time_col` rows between 1 preceding and 1
following) as not_ignore_null,
first_value(`state`) over(partition by `myday` order by `time_col` rows between 1 preceding and 1 following)
as ignore_null_default
from t order by `id`, `myday`, `time_col`;
```

id	myday	time_col	state	ignore_null	not_ignore_null	ignore_null_default
1	21	04-21-11	NULL	2	NULL	NULL

	2		21		04-21-12		2		2		NULL		NULL	
	3		21		04-21-13		3		2		2		2	
	4		22		04-22-10-21		NULL		NULL		NULL		NULL	
	5		22		04-22-10-22		NULL		5		NULL		NULL	
	6		22		04-22-10-23		5		5		NULL		NULL	
	7		22		04-22-10-24		NULL		5		5		5	
	8		22		04-22-10-25		9		9		NULL		NULL	
	9		23		04-23-11		NULL		10		NULL		NULL	
	10		23		04-23-12		10		10		NULL		NULL	
	11		23		04-23-13		NULL		10		10		10	
	12		24		02-24-10-21		NULL		NULL		NULL		NULL	

keywords

WINDOW, FUNCTION, FIRST\_VALUE

# WINDOW\_FUNCTION\_LAST\_VALUE

## WINDOW FUNCTION LAST\_VALUE

### 描述

#### 备注

自 2.0.9 开始支持 ignore\_null 用法

LAST\_VALUE() 返回窗口范围内的最后一个值。与 FIRST\_VALUE() 相反。ignore\_null 决定是否忽略 null 值，参数 ignore\_null 默认值为 false 。

```
LAST_VALUE(expr[, ignore_null]) OVER(partition_by_clause order_by_clause [window_clause])
```

### 举例

使用FIRST\_VALUE()举例中的数据：

```
select * ,
last_value(`state`, 1) over(partition by `myday` order by `time_col` DESC rows between 1 preceding and 1
following) as ignore_null,
last_value(`state`, 0) over(partition by `myday` order by `time_col` DESC rows between 1 preceding and 1
following) as not_ignore_null,
last_value(`state`) over(partition by `myday` order by `time_col` DESC rows between 1 preceding and 1
following) as ignore_null_default
from t order by `id`, `myday`, `time_col`;
```

id	myday	time_col	state	ignore_null	not_ignore_null	ignore_null_default
1	21	04-21-11	NULL	2	NULL	NULL
2	21	04-21-12	2	2	NULL	NULL
3	21	04-21-13	3	2	2	2
4	22	04-22-10-21	NULL	NULL	NULL	NULL
5	22	04-22-10-22	NULL	5	NULL	NULL
6	22	04-22-10-23	5	5	NULL	NULL
7	22	04-22-10-24	NULL	5	5	5
8	22	04-22-10-25	9	9	NULL	NULL
9	23	04-23-11	NULL	10	NULL	NULL
10	23	04-23-12	10	10	NULL	NULL
11	23	04-23-13	NULL	10	10	10
12	24	02-24-10-21	NULL	NULL	NULL	NULL

### keywords

```
WINDOW, FUNCTION, LAST_VALUE
```

# WINDOW\_FUNCTION\_LEAD

## WINDOW FUNCTION LEAD

### 描述

LEAD() 方法用来计算当前行向后数若干行的值。

```
LEAD(expr, offset, default) OVER (partition_by_clause order_by_clause)
```

### 举例

计算第二天的收盘价对比当天收盘价的走势，即第二天收盘价比当天高还是低。

```
select stock_symbol, closing_date, closing_price,
case
(lead(closing_price,1, 0)
over (partition by stock_symbol order by closing_date)-closing_price) > 0
when true then "higher"
when false then "flat or lower"
end as "trending"
from stock_ticker
order by closing_date;
```

stock_symbol	closing_date	closing_price	trending
JDR	2014-09-13 00:00:00	12.86	higher
JDR	2014-09-14 00:00:00	12.89	higher
JDR	2014-09-15 00:00:00	12.94	flat or lower
JDR	2014-09-16 00:00:00	12.55	higher
JDR	2014-09-17 00:00:00	14.03	higher
JDR	2014-09-18 00:00:00	14.75	flat or lower
JDR	2014-09-19 00:00:00	13.98	flat or lower

### keywords

```
WINDOW, FUNCTION, LEAD
```

# WINDOW\_FUNCTION\_LAG

## WINDOW FUNCTION LAG

### 描述

LAG() 方法用来计算当前行向前数若干行的值。

```
LAG(expr, offset, default) OVER (partition_by_clause order_by_clause)
```

### 举例

计算前一天的收盘价

```
select stock_symbol, closing_date, closing_price,
lag(closing_price,1, 0) over (partition by stock_symbol order by closing_date) as "yesterday closing"
from stock_ticker
order by closing_date;
```

stock_symbol	closing_date	closing_price	yesterday closing
JDR	2014-09-13 00:00:00	12.86	0
JDR	2014-09-14 00:00:00	12.89	12.86
JDR	2014-09-15 00:00:00	12.94	12.89
JDR	2014-09-16 00:00:00	12.55	12.94
JDR	2014-09-17 00:00:00	14.03	12.55
JDR	2014-09-18 00:00:00	14.75	14.03
JDR	2014-09-19 00:00:00	13.98	14.75

### keywords

WINDOW, FUNCTION, LAG

# WINDOW\_FUNCTION\_ROW\_NUMBER

## WINDOW FUNCTION ROW\_NUMBER

### 描述

为每个 Partition 的每一行返回一个从1开始连续递增的整数。与 RANK() 和 DENSE\_RANK() 不同的是，ROW\_NUMBER() 返回的值不会重复也不会出现空缺，是连续递增的。

```
ROW_NUMBER() OVER(partition_by_clause order_by_clause)
```

### 举例

```
select x, y, row_number() over(partition by x order by y) as rank from int_t;
```

x	y	rank
1	1	1
1	2	2
1	2	3
2	1	1
2	2	2
2	3	3
3	1	1
3	1	2
3	2	3

### keywords

```
WINDOW, FUNCTION, ROW_NUMBER
```

# WINDOW\_FUNCTION\_WINDOW\_FUNNEL

## WINDOW FUNCTION WINDOW\_FUNNEL

### 描述

漏斗分析函数搜索滑动时间窗口内最大的发生的最大事件序列长度。

- window：滑动时间窗口大小，单位为秒。
- mode：模式，共有四种模式
  - “default”: 默认模式。
  - “deduplication”: 当某个事件重复发生时，这个重复发生的事件会阻止后续的处理过程。如，指定事件链为[event1='A', event2='B', event3='C', event4='D']，原始事件链为“A-B-C-B-D”。由于B事件重复，最终的结果事件链为A-B-C，最大长度为3。
  - “fixed”: 不允许事件的顺序发生交错，即事件发生的顺序必须和指定的事件链顺序一致。如，指定事件链为[event1='A', event2='B', event3='C', event4='D']，原始事件链为“A-B-D-C”，则结果事件链为A-B，最大长度为2
  - “increase”: 选中的事件的时间戳必须按照指定事件链严格递增。
- timestamp\_column：指定时间列，类型为DATETIME, 滑动窗口沿着此列工作。
- eventN：表示事件的布尔表达式。

漏斗分析函数按照如下算法工作：

- 搜索到满足条件的第一个事件，设置事件长度为1，此时开始滑动时间窗口计时。
- 如果事件在时间窗口内按照指定的顺序发生，时间长度累计增加。如果事件没有按照指定的顺序发生，时间长度不增加。
- 如果搜索到多个事件链，漏斗分析函数返回最大的长度。

```
window_funnel(window, mode, timestamp_column, event1, event2, ... , eventN)
```

### 举例

```
CREATE TABLE windowfunnel_test (
 `xwho` varchar(50) NULL COMMENT 'xwho',
 `xwhen` datetime COMMENT 'xwhen',
 `xwhat` int NULL COMMENT 'xwhat'
)
DUPLICATE KEY(xwho)
DISTRIBUTED BY HASH(xwho) BUCKETS 3
PROPERTIES (
 "replication_num" = "1"
);

INSERT into windowfunnel_test (xwho, xwhen, xwhat) values ('1', '2022-03-12 10:41:00', 1),
 ('1', '2022-03-12 13:28:02', 2),
 ('1', '2022-03-12 16:15:01', 3),
 ('1', '2022-03-12 19:05:04', 4);

select window_funnel(3600 * 3, 'default', t.xwhen, t.xwhat = 1, t.xwhat = 2) AS level from windowfunnel_test
```



```
t;

| level |
|---|
| 2 |
```

## keywords

```
WINDOW,FUNCTION,WINDOW_FUNNEL
```

# INET\_NTOA

## INET\_NTOA

INET\_NTOA

### 描述

### 语法

VARCHAR INET\_NTOA(BIGINT ipv4\_num)

接受一个类型为 Int16、Int32、Int64 且大端表示的 IPv4 的地址，返回相应 IPv4 的字符串表现形式，格式为 A.B.C.D（以点分割的十进制数字）。

### 注意事项

对于负数或超过4294967295（即 '255.255.255.255'）的入参都返回NULL，表示无效收入

### 举例

```
mysql> select inet_ntoa(3232235521);
+-----+
| inet_ntoa(3232235521) |
+-----+
| 192.168.0.1 |
+-----+
1 row in set (0.01 sec)

mysql> select num,inet_ntoa(num) from ipv4_bi;
+-----+-----+
| num | inet_ntoa(`num`) |
+-----+-----+
| -1 | NULL |
| 0 | 0.0.0.0 |
| 2130706433 | 127.0.0.1 |
| 4294967295 | 255.255.255.255 |
| 4294967296 | NULL |
+-----+-----+
7 rows in set (0.01 sec)
```

### keywords

INET\_NTOA, IP

# COSINE\_DISTANCE

---

## cosine\_distance

### 描述

### 语法

```
DOUBLE cosine_distance(ARRAY<T> array1, ARRAY<T> array2)
```

计算两个向量（向量值为坐标）之间的余弦距离 如果输入array为NULL，或者array中任何元素为NULL，则返回NULL

### 注意事项

- 输入数组的子类型支持：TINYINT、SMALLINT、INT、BIGINT、LARGEINT、FLOAT、DOUBLE
- 输入数组array1和array2，元素数量需保持一致

### 举例

```
sql> SELECT cosine_distance([1, 2], [2, 3]);
+-----+
| cosine_distance(ARRAY(1, 2), ARRAY(2, 3)) |
+-----+
| 0.0077221232863322609 |
+-----+
```

### keywords

```
COSINE_DISTANCE, DISTANCE, COSINE, ARRAY
```

# INNER\_PRODUCT

## inner\_product

### 描述

### 语法

```
DOUBLE inner_product(ARRAY<T> array1, ARRAY<T> array2)
```

计算两个大小相同的向量的标量积 如果输入array为NULL，或者array中任何元素为NULL，则返回NULL

### 注意事项

- 输入数组的子类型支持：TINYINT、SMALLINT、INT、BIGINT、LARGEINT、FLOAT、DOUBLE
- 输入数组array1和array2，元素数量需保持一致

### 举例

```
sql> SELECT inner_product([1, 2], [2, 3]);
+-----+
| inner_product(ARRAY(1, 2), ARRAY(2, 3)) |
+-----+
| 8 |
+-----+
```

### keywords

```
INNER_PRODUCT,DISTANCE,ARRAY
```

# L1\_DISTANCE

## l1\_distance

### 描述

### 语法

```
DOUBLE l1_distance(ARRAY<T> array1, ARRAY<T> array2)
```

计算L1空间中两点（向量值为坐标）之间的距离 如果输入array为NULL，或者array中任何元素为NULL，则返回NULL

### 注意事项

- 输入数组的子类型支持：TINYINT、SMALLINT、INT、BIGINT、LARGEINT、FLOAT、DOUBLE
- 输入数组array1和array2，元素数量需保持一致

### 举例

```
sql> SELECT l1_distance([1, 2], [2, 3]);
+-----+
| l1_distance(ARRAY(1, 2), ARRAY(2, 3)) |
+-----+
| 2 |
+-----+
```

### keywords

```
L1_DISTANCE, DISTANCE, L1, ARRAY
```

# L2\_DISTANCE

## l2\_distance

### 描述

### 语法

```
DOUBLE l2_distance(ARRAY<T> array1, ARRAY<T> array2)
```

计算欧几里得空间中两点（向量值为坐标）之间的距离 如果输入array为NULL，或者array中任何元素为NULL，则返回NULL

### 注意事项

- 输入数组的子类型支持：TINYINT、SMALLINT、INT、BIGINT、LARGEINT、FLOAT、DOUBLE
- 输入数组array1和array2，元素数量需保持一致

### 举例

```
sql> SELECT l2_distance([1, 2], [2, 3]);
+-----+
| l2_distance(ARRAY(1, 2), ARRAY(2, 3)) |
+-----+
| 1.4142135623730951 |
+-----+
```

### keywords

```
L2_DISTANCE, DISTANCE, L2, ARRAY
```

# CAST

## CAST

### 描述

### 语法

T cast (input as Type)

将 input 转成 指定的 Type类型

### 举例

#### 1. 转常量，或表中某列

```
mysql> select cast (1 as BIGINT);
+-----+
| CAST(1 AS BIGINT) |
+-----+
| 1 |
+-----+
```

#### 2. 转导入的原始数据

```
curl --location-trusted -u root: -T ~/user_data/bigint -H "columns: tmp_k1, k1=cast(tmp_k1 as BIGINT)"
http://host:port/api/test/bigint/_stream_load
```

注：在导入中，由于原始类型均为String，将值为浮点的原始数据做 cast的时候数据会被转换成 NULL，比如 12.0。Doris目前不会对原始数据做截断。

如果想强制将这种类型的原始数据 cast to int 的话。请看下面写法：

```
curl --location-trusted -u root: -T ~/user_data/bigint -H "columns: tmp_k1, k1=cast(cast(tmp_k1 as DOUBLE) as BIGINT)" http://host:port/api/test/bigint/_stream_load

mysql> select cast(cast ("11.2" as double) as bigint);
+-----+
| CAST(CAST('11.2' AS DOUBLE) AS BIGINT) |
+-----+
| 11 |
+-----+
1 row in set (0.00 sec)
```

对于DECIMALV3，DATETIME类型，cast会进行四舍五入

```
mysql> select cast (1.115 as DECIMALV3(16, 2));
+-----+
| cast(1.115 as DECIMALV3(16, 2)) |
+-----+
```

```

| 1.12 |
+-----+

mysql> select cast('2024-12-29-20:40:50.123500' as datetime(3));
+-----+
| cast('2024-12-29-20:40:50.123500' as DATETIMEV2(3)) |
+-----+
| 2024-12-29 20:40:50.124 |
+-----+

mysql> select cast('2024-12-29-20:40:50.123499' as datetime(3));
+-----+
| cast('2024-12-29-20:40:50.123499' as DATETIMEV2(3)) |
+-----+
| 2024-12-29 20:40:50.123 |
+-----+

```

## keywords

CAST



# DIGITAL\_MASKING

## 描述

别名函数，原始函数为 `concat(left(id,3),'****',right(id,4))`。

将输入的 `digital_number` 进行脱敏处理，返回遮盖脱敏后的结果。

## 语法

```
digital_masking(digital_number)
```

## 示例

将手机号码进行脱敏处理

```
select digital_masking(13812345678);
```

+-----+
digital_masking(13812345678)
+-----+
138****5678
+-----+

# WIDTH\_BUCKET

## width\_bucket

### 描述

构造等宽直方图，其中直方图范围被划分为相同大小的区间，并在计算后返回表达式的值所在的桶号。该函数返回一个整数值或空值（如果任何输入为空值则返回空值）。

### 语法

```
INT width_bucket(Expr expr, T min_value, T max_value, INT num_buckets)
```

### 参数

expr - 创建直方图的表达式。此表达式必须计算为数值或可隐式转换为数值的值。

此值的范围必须为  $-(2^{53} - 1)$  到  $2^{53} - 1$  (含)。

min\_value 和 max\_value - 表达式可接受范围的最低值点和最高值点。这两个参数必须为数值并且不相等。

最低值点和最高值点的范围必须为  $-(2^{53} - 1)$  to  $2^{53} - 1$  (含)。此外，最高值点与最低值点的差必须小于  $2^{53}$  (例如：  $\text{abs}(\text{max\_value} - \text{min\_value}) < 2^{53}$ )。

num\_buckets - 分桶的数量，必须是正整数值。将表达式中的一个值分配给每个存储桶，然后该函数返回相应的存储桶编号。

### 返回值

返回表达式值所在的桶号。

当表达式超出范围时，函数返回规则如下：

如果表达式的值小于min\_value返回0。

如果表达式的值大于或等于max\_value返回num\_buckets + 1。

如果任意参数为null返回null。

### 举例

```
DROP TABLE IF EXISTS width_bucket_test;

CREATE TABLE IF NOT EXISTS width_bucket_test (
 `k1` int NULL COMMENT '',
 `v1` date NULL COMMENT '',
 `v2` double NULL COMMENT '',
 `v3` bigint NULL COMMENT ''
) ENGINE=OLAP
```

```

DUPLICATE KEY(`k1`)
DISTRIBUTED BY HASH(`k1`) BUCKETS 1
PROPERTIES (
 "replication_allocation" = "tag.location.default: 1",
 "storage_format" = "V2"
);

```

```

INSERT INTO width_bucket_test VALUES (1, "2022-11-18", 290000.00, 290000),
 (2, "2023-11-18", 320000.00, 320000),
 (3, "2024-11-18", 399999.99, 399999),
 (4, "2025-11-18", 400000.00, 400000),
 (5, "2026-11-18", 470000.00, 470000),
 (6, "2027-11-18", 510000.00, 510000),
 (7, "2028-11-18", 610000.00, 610000),
 (8, null, null, null);

```

```
SELECT * FROM width_bucket_test ORDER BY k1;
```

k1	v1	v2	v3
1	2022-11-18	290000	290000
2	2023-11-18	320000	320000
3	2024-11-18	399999.99	399999
4	2025-11-18	400000	400000
5	2026-11-18	470000	470000
6	2027-11-18	510000	510000
7	2028-11-18	610000	610000
8	NULL	NULL	NULL

```
SELECT k1, v1, v2, v3, width_bucket(v1, date('2023-11-18'), date('2027-11-18'), 4) AS w FROM
width_bucket_test ORDER BY k1;
```

k1	v1	v2	v3	w
1	2022-11-18	290000	290000	0
2	2023-11-18	320000	320000	1
3	2024-11-18	399999.99	399999	2
4	2025-11-18	400000	400000	3
5	2026-11-18	470000	470000	4
6	2027-11-18	510000	510000	5
7	2028-11-18	610000	610000	5
8	NULL	NULL	NULL	NULL

```
SELECT k1, v1, v2, v3, width_bucket(v2, 200000, 600000, 4) AS w FROM width_bucket_test ORDER BY k1;
```

k1	v1	v2	v3	w
1	2022-11-18	290000	290000	1
2	2023-11-18	320000	320000	2
3	2024-11-18	399999.99	399999	2
4	2025-11-18	400000	400000	3
5	2026-11-18	470000	470000	3
6	2027-11-18	510000	510000	4
7	2028-11-18	610000	610000	5
8	NULL	NULL	NULL	NULL

```
SELECT k1, v1, v2, v3, width_bucket(v3, 200000, 600000, 4) AS w FROM width_bucket_test ORDER BY k1;
```

k1	v1	v2	v3	w
----	----	----	----	---

k1	v1	v2	v3	w
1	2022-11-18	290000	290000	1
2	2023-11-18	320000	320000	2
3	2024-11-18	399999.99	399999	2
4	2025-11-18	400000	400000	3
5	2026-11-18	470000	470000	3
6	2027-11-18	510000	510000	4
7	2028-11-18	610000	610000	5
8	NULL	NULL	NULL	NULL

keywords

WIDTH\_BUCKET

# ALTER-SYSTEM-ADD-FOLLOWER

---

## ALTER-SYSTEM-ADD-FOLLOWER

### Name

ALTER SYSTEM ADD FOLLOWER

### 描述

该语句是增加 FRONTEND 的 FOLLOWER 角色的节点, (仅管理员使用! )

语法:

```
ALTER SYSTEM ADD FOLLOWER "follower_host:edit_log_port"
```

说明:

1. host 可以是主机名或者ip地址
2. edit\_log\_port : edit\_log\_port 在其配置文件 fe.conf

### 举例

1. 添加一个 FOLLOWER节点

```
ALTER SYSTEM ADD FOLLOWER "host_ip:9010"
```

### Keywords

```
ALTER, SYSTEM, ADD, FOLLOWER, ALTER SYSTEM
```

### Best Practice

# ALTER-SYSTEM-ADD-OBSERVER

---

## ALTER-SYSTEM-ADD-OBSERVER

### Name

ALTER SYSTEM ADD OBSERVER

### 描述

该语句是增加 FRONTEND 的 OBSERVER 角色的节点, (仅管理员使用!)

语法:

```
ALTER SYSTEM ADD OBSERVER "follower_host:edit_log_port"
```

说明:

1. host 可以是主机名或者ip地址
2. edit\_log\_port : edit\_log\_port 在其配置文件 fe.conf

### 举例

1. 添加一个 OBSERVER 节点

```
ALTER SYSTEM ADD OBSERVER "host_ip:9010"
```

### Keywords

```
ALTER, SYSTEM, ADD, OBSERVER, ALTER SYSTEM
```

### Best Practice

# ALTER-SYSTEM-ADD-BACKEND

---

## ALTER-SYSTEM-ADD-BACKEND

### Name

ALTER SYSTEM ADD BACKEND

### 描述

该语句用于操作一个系统内的节点。(仅管理员使用!)

语法:

1) 增加节点

```
ALTER SYSTEM ADD BACKEND "host:heartbeat_port"[,"host:heartbeat_port"...];
```

说明:

1. host 可以是主机名或者ip地址
2. heartbeat\_port 为该节点的心跳端口
3. 增加和删除节点为同步操作。这两种操作不考虑节点上已有的数据, 节点直接从元数据中删除, 请谨慎使用。

### 举例

1. 增加一个节点

```
ALTER SYSTEM ADD BACKEND "host:port";
```

### Keywords

```
ALTER, SYSTEM, ADD, BACKEND, ALTER SYSTEM
```

### Best Practice

# ALTER-SYSTEM-ADD-BROKER

---

## ALTER-SYSTEM-ADD-BROKER

### Name

ALTER SYSTEM ADD BROKER

### 描述

该语句用于添加一个 BROKER 节点。(仅管理员使用!)

语法:

```
ALTER SYSTEM ADD BROKER broker_name "broker_host1:broker_ipc_port1","broker_host2:broker_ipc_port2",...;
```

### 举例

1. 增加两个 Broker

```
ALTER SYSTEM ADD BROKER "host1:port", "host2:port";
```

2. fe开启fqdn([fqdn](#))时添加一个Broker

```
ALTER SYSTEM ADD BROKER "broker_fqdn1:port";
```

### Keywords

```
ALTER, SYSTEM, ADD, FOLLOWER, ALTER SYSTEM
```

### Best Practice



# ALTER-SYSTEM-MODIFY-BACKEND

## ALTER-SYSTEM-MODIFY-BACKEND

### Name

ALTER SYSTEM MKDIFY BACKEND

### 描述

修改 BE 节点属性（仅管理员使用！）

语法：

- 通过 host 和 port 查找 backend

```
ALTER SYSTEM MODIFY BACKEND "host:heartbeat_port" SET ("key" = "value"[, ...]);
```

- 通过 backend\_id 查找 backend

```
ALTER SYSTEM MODIFY BACKEND "id1" SET ("key" = "value"[, ...]);
```

说明：

1. host 可以是主机名或者ip地址
2. heartbeat\_port 为该节点的心跳端口
3. 修改 BE 节点属性目前支持以下属性：

- tag.xxx：资源标签
- disable\_query: 查询禁用属性
- disable\_load: 导入禁用属性

注： 1. 可以给一个 Backend 设置多种资源标签。但必须包含“tag.location”。

### 举例

1. 修改 BE 的资源标签

```
ALTER SYSTEM MODIFY BACKEND "host1:heartbeat_port" SET ("tag.location" = "group_a");
ALTER SYSTEM MODIFY BACKEND "host1:heartbeat_port" SET ("tag.location" = "group_a", "tag.compute" = "c1");
```

```
ALTER SYSTEM MODIFY BACKEND "id1" SET ("tag.location" = "group_a");
ALTER SYSTEM MODIFY BACKEND "id1" SET ("tag.location" = "group_a", "tag.compute" = "c1");
```

2. 修改 BE 的查询禁用属性

```
ALTER SYSTEM MODIFY BACKEND "host1:heartbeat_port" SET ("disable_query" = "true");
```

```
ALTER SYSTEM MODIFY BACKEND "id1" SET ("disable_query" = "true");
```

### 3. 修改 BE 的导入禁用属性

```
ALTER SYSTEM MODIFY BACKEND "host1:heartbeat_port" SET ("disable_load" = "true");
```

```
ALTER SYSTEM MODIFY BACKEND "id1" SET ("disable_load" = "true");
```

## Keywords

ALTER, SYSTEM, ADD, BACKEND, ALTER SYSTEM

## Best Practice

# ALTER-SYSTEM-DECOMMISSION-BACKEND

## ALTER-SYSTEM-DECOMMISSION-BACKEND

### Name

ALTER SYSTEM DECOMMISSION BACKEND

### 描述

节点下线操作用于安全下线节点。该操作为异步操作。如果成功，节点最终会从元数据中删除。如果失败，则不会完成下线（仅管理员使用！）

语法：

- 通过 host 和 port 查找 backend

```
ALTER SYSTEM DECOMMISSION BACKEND "host:heartbeat_port"[,"host:heartbeat_port"...];
```

- 通过 backend\_id 查找 backend

```
ALTER SYSTEM DECOMMISSION BACKEND "id1","id2"...;
```

说明：

- host 可以是主机名或者ip地址
- heartbeat\_port 为该节点的心跳端口
- 节点下线操作用于安全下线节点。该操作为异步操作。如果成功，节点最终会从元数据中删除。如果失败，则不会完成下线。
- 可以手动取消节点下线操作。详见 CANCEL DECOMMISSION

### 举例

- 下线两个节点

```
ALTER SYSTEM DECOMMISSION BACKEND "host1:port", "host2:port";
```

```
ALTER SYSTEM DECOMMISSION BACKEND "id1", "id2";
```

### Keywords

ALTER, SYSTEM, DECOMMISSION, BACKEND, ALTER SYSTEM

### Best Practice

# ALTER-SYSTEM-DROP-FOLLOWER

---

## Name

ALTER SYSTEM DROP FOLLOWER

## Description

该语句是删除 FRONTEND 的 FOLLOWER 角色的节点，（仅管理员使用！）

语法：

```
ALTER SYSTEM DROP FOLLOWER "follower_host:edit_log_port"
```

说明：

1. host 可以是主机名或者 ip 地址
2. edit\_log\_port : edit\_log\_port 在其配置文件 fe.conf

## Example

1. 删除一个 FOLLOWER 节点

```
ALTER SYSTEM DROP FOLLOWER "host_ip:9010"
```

## Keywords

ALTER, SYSTEM, DROP, FOLLOWER, ALTER SYSTEM

# ALTER-SYSTEM-DROP-OBSERVER

---

## ALTER-SYSTEM-DROP-OBSERVER

### Name

ALTER SYSTEM DROP OBSERVER

### 描述

该语句是删除 FRONTEND 的 OBSERVER 角色的节点, (仅管理员使用!)

语法:

```
ALTER SYSTEM DROP OBSERVER "follower_host:edit_log_port"
```

说明:

1. host 可以是主机名或者ip地址
2. edit\_log\_port : edit\_log\_port 在其配置文件 fe.conf

### 举例

1. 添加一个 FOLLOWER节点

```
ALTER SYSTEM DROP OBSERVER "host_ip:9010"
```

### Keywords

```
ALTER, SYSTEM, DROP, OBSERVER, ALTER SYSTEM
```

### Best Practice

# ALTER-SYSTEM-DROP-BACKEND

---

## ALTER-SYSTEM-DROP-BACKEND

### Name

ALTER SYSTEM DROP BACKEND

### 描述

该语句用于删除 BACKEND 节点（仅管理员使用！）

语法：

- 通过 host 和 port 查找 backend

```
ALTER SYSTEM DROP BACKEND "host:heartbeat_port" [, "host:heartbeat_port" ...]
```

- 通过 backend\_id 查找 backend

```
ALTER SYSTEM DROP BACKEND "id1", "id2" ...;
```

说明：

1. host 可以是主机名或者ip地址
2. heartbeat\_port 为该节点的心跳端口
3. 增加和删除节点为同步操作。这两种操作不考虑节点上已有的数据，节点直接从元数据中删除，请谨慎使用。

### 举例

1. 删除两个节点

```
ALTER SYSTEM DROP BACKEND "host1:port", "host2:port";
```

```
ALTER SYSTEM DROP BACKEND "id1", "id2";
```

### Keywords

```
ALTER, SYSTEM, DROP, BACKEND, ALTER SYSTEM
```

### Best Practice

# ALTER-SYSTEM-DROP-BROKER

---

## ALTER-SYSTEM-DROP-BROKER

### Name

ALTER SYSTEM DROP BROKER

### 描述

该语句是删除 BROKER 节点，（仅限管理员使用）

语法：

```
删除所有 Broker
ALTER SYSTEM DROP ALL BROKER broker_name
删除某一个 Broker 节点
ALTER SYSTEM DROP BROKER broker_name "host:port"["host:port"...];
```

### 举例

#### 1. 删除所有 Broker

```
ALTER SYSTEM DROP ALL BROKER broker_name
```

#### 2. 删除某一个 Broker 节点

```
ALTER SYSTEM DROP BROKER broker_name "host:port"["host:port"...];
```

### Keywords

```
ALTER, SYSTEM, DROP, FOLLOWER, ALTER SYSTEM
```

### Best Practice

# CANCEL-ALTER-SYSTEM

---

## CANCEL-ALTER-SYSTEM

### Name

CANCEL DECOMMISSION

### 描述

该语句用于撤销一个节点下线操作。(仅管理员使用!)

语法:

- 通过 host 和 port 查找 backend

```
CANCEL DECOMMISSION BACKEND "host:heartbeat_port" [, "host:heartbeat_port"...];
```

- 通过 backend\_id 查找 backend

```
CANCEL DECOMMISSION BACKEND "id1", "id2", "id3...";
```

### 举例

1. 取消两个节点的下线操作:

```
CANCEL DECOMMISSION BACKEND "host1:port", "host2:port";
```

2. 取消 backend\_id 为 1 的节点的下线操作:

```
CANCEL DECOMMISSION BACKEND "1", "2";
```

### Keywords

```
CANCEL, DECOMMISSION, CANCEL ALTER
```

### Best Practice



# CREATE-ROLE

---

## CREATE ROLE

### Name

CREATE ROLE

### 描述

该语句用户创建一个角色

```
CREATE ROLE rol_name;
```

该语句创建一个无权限的角色，可以后续通过 GRANT 命令赋予该角色权限。

### 举例

1. 创建一个角色

```
CREATE ROLE role1;
```

### Keywords

```
CREATE, ROLE
```

### Best Practice

# CREATE-USER

## CREATE USER

### Name

CREATE USER

### 描述

CREATE USER 命令用于创建一个 Doris 用户。

```
CREATE USER [IF EXISTS] user_identity [IDENTIFIED BY 'password']
[DEFAULT ROLE 'role_name']
[password_policy]

user_identity:
 'user_name'@'host'

password_policy:

 1. PASSWORD_HISTORY [n|DEFAULT]
 2. PASSWORD_EXPIRE [DEFAULT|NEVER|INTERVAL n DAY/HOUR/SECOND]
 3. FAILED_LOGIN_ATTEMPTS n
 4. PASSWORD_LOCK_TIME [n DAY/HOUR/SECOND|UNBOUNDED]
```

在 Doris 中，一个 user\_identity 唯一标识一个用户。user\_identity 由两部分组成，user\_name 和 host，其中 username 为用户名。host 标识用户端连接所在的主机地址。host 部分可以使用 % 进行模糊匹配。如果不指定 host，默认为 '%'，即表示该用户可以从任意 host 连接到 Doris。

host 部分也可指定为 domain，语法为：'user\_name'@[domain]，即使用中括号包围，则 Doris 会认为这个是一个 domain，并尝试解析其 ip 地址。

如果指定了角色（ROLE），则会自动将该角色所拥有的权限赋予新创建的这个用户。如果不指定，则该用户默认没有任何权限。指定的 ROLE 必须已经存在。

password\_policy 是用于指定密码认证登录相关策略的子句，目前支持以下策略：

#### 1. PASSWORD\_HISTORY

是否允许当前用户重置密码时使用历史密码。如 PASSWORD\_HISTORY 10 表示禁止使用过去10次设置过的密码为新密码。如果设置为 PASSWORD\_HISTORY DEFAULT，则会使用全局变量 password\_history 中的值。0 表示不启用这个功能。默认为 0。

#### 2. PASSWORD\_EXPIRE

设置当前用户密码的过期时间。如 PASSWORD\_EXPIRE INTERVAL 10 DAY 表示密码会在 10 天后过期。PASSWORD\_EXPIRE NEVER 表示密码不过期。如果设置为 PASSWORD\_EXPIRE DEFAULT，则会使用全局变量 default\_password\_lifetime 中的值。默认为 NEVER（或0），表示不会过期。

### 3. FAILED\_LOGIN\_ATTEMPTS 和 PASSWORD\_LOCK\_TIME

设置当前用户登录时，如果使用错误的密码登录n次后，账户将被锁定，并设置锁定时间。如 FAILED\_LOGIN\_ATTEMPTS 3 PASSWORD\_LOCK\_TIME 1 DAY 表示如果3次错误登录，则账户会被锁定一天。

被锁定的账户可以通过 ALTER USER 语句主动解锁。

## 举例

1. 创建一个无密码用户（不指定 host，则等价于 jack@'%'）

```
CREATE USER 'jack';
```

2. 创建一个有密码用户，允许从 '172.10.1.10' 登陆

```
CREATE USER jack@'172.10.1.10' IDENTIFIED BY '123456';
```

3. 为了避免传递明文，用例2也可以使用下面的方式来创建

```
CREATE USER jack@'172.10.1.10' IDENTIFIED BY PASSWORD '*6BB4837EB74329105EE4568DDA7DC67ED2CA2AD9';
后面加密的内容可以通过PASSWORD()获得到,例如:
SELECT PASSWORD('123456');
```

4. 创建一个允许从 '192.168' 子网登陆的用户，同时指定其角色为 example\_role

```
CREATE USER 'jack'@'192.168.%' DEFAULT ROLE 'example_role';
```

5. 创建一个允许从域名 'example\_domain' 登陆的用户

```
CREATE USER 'jack'@['example_domain'] IDENTIFIED BY '12345';
```

6. 创建一个用户，并指定一个角色

```
CREATE USER 'jack'@'%' IDENTIFIED BY '12345' DEFAULT ROLE 'my_role';
```

7. 创建一个用户，设定密码10天后过期，并且设置如果3次错误登录则账户会被锁定一天。

```
CREATE USER 'jack' IDENTIFIED BY '12345' PASSWORD_EXPIRE INTERVAL 10 DAY FAILED_LOGIN_ATTEMPTS 3
PASSWORD_LOCK_TIME 1 DAY;
```

8. 创建一个用户，并限制不可重置密码为最近8次是用过的密码。

```
CREATE USER 'jack' IDENTIFIED BY '12345' PASSWORD_HISTORY 8;
```

**Keywords**

CREATE, USER

**Best Practice**

# ALTER-USER

## ALTER USER

### Name

ALTER USER

### 描述

ALTER USER 命令用于修改一个用户的账户属性，包括密码、和密码策略等

#### 注意：

从 2.0 版本开始，此命令不再支持修改用户角色，相关操作请使用[GRANT](#)和[REVOKE](#)

```
ALTER USER [IF EXISTS] user_identity [IDENTIFIED BY 'password']
[password_policy]

user_identity:
 'user_name'@'host'

password_policy:

 1. PASSWORD_HISTORY [n|DEFAULT]
 2. PASSWORD_EXPIRE [DEFAULT|NEVER|INTERVAL n DAY/HOUR/SECOND]
 3. FAILED_LOGIN_ATTEMPTS n
 4. PASSWORD_LOCK_TIME [n DAY/HOUR/SECOND|UNBOUNDED]
 5. ACCOUNT_UNLOCK
```

关于 user\_identity, 和 password\_policy 的说明，请参阅 CREATE USER 命令。

ACCOUNT\_UNLOCK 命令用于解锁一个被锁定的用户。

在一个 ALTER USER 命令中，只能同时对以下账户属性中的一项进行修改：

1. 修改密码
2. 修改 PASSWORD\_HISTORY
3. 修改 PASSWORD\_EXPIRE
4. 修改 FAILED\_LOGIN\_ATTEMPTS 和 PASSWORD\_LOCK\_TIME
5. 解锁用户

### 举例

1. 修改用户的密码

```
ALTER USER jack@'%' IDENTIFIED BY "12345";
```

## 2. 修改用户的密码策略

```
ALTER USER jack@'%' FAILED_LOGIN_ATTEMPTS 3 PASSWORD_LOCK_TIME 1 DAY;
```

## 3. 解锁一个用户

```
ALTER USER jack@'%' ACCOUNT_UNLOCK
```

## Keywords

ALTER, USER

## Best Practice

### 1. 修改密码策略

1. 修改 PASSWORD\_EXPIRE 会重置密码过期时间的计时。
2. 修改 FAILED\_LOGIN\_ATTEMPTS 或 PASSWORD\_LOCK\_TIME，会解锁用户。

# SET-PASSWORD

---

## SET-PASSWORD

### Name

SET PASSWORD

### 描述

SET PASSWORD 命令可以用于修改一个用户的登录密码。如果 [FOR user\_identity] 字段不存在，那么修改当前用户的密码

```
SET PASSWORD [FOR user_identity] =
[PASSWORD('plain password')][['hashed password']]
```

注意这里的 user\_identity 必须完全匹配在使用 CREATE USER 创建用户时指定的 user\_identity，否则会报错用户不存在。如果不指定 user\_identity，则当前用户为 'username'@'ip'，这个当前用户，可能无法匹配任何 user\_identity。可以通过 SHOW GRANTS 查看当前用户。

PASSWORD() 方式输入的是明文密码；而直接使用字符串，需要传递的是已加密的密码。如果修改其他用户的密码，需要具有管理员权限。

### 举例

#### 1. 修改当前用户的密码

```
SET PASSWORD = PASSWORD('123456')
SET PASSWORD = '*6BB4837EB74329105EE4568DDA7DC67ED2CA2AD9'
```

#### 2. 修改指定用户密码

```
SET PASSWORD FOR 'jack'@'192.%' = PASSWORD('123456')
SET PASSWORD FOR 'jack'@['domain'] = '*6BB4837EB74329105EE4568DDA7DC67ED2CA2AD9'
```

### Keywords

SET, PASSWORD

### Best Practice

# SET-PROPERTY

## SET PROPERTY

### Name

SET PROPERTY

### 描述

设置用户的属性，包括分配给用户的资源、导入cluster等

```
SET PROPERTY [FOR 'user'] 'key' = 'value' [, 'key' = 'value']
```

这里设置的用户属性，是针对 user 的，而不是 user\_identity。即假设通过 CREATE USER 语句创建了两个用户 'jack'@'%' 和 'jack'@'192.%'，则使用 SET PROPERTY 语句，只能针对 jack 这个用户，而不是 'jack'@'%' 或 'jack'@'192.%'

key:

超级用户权限:

max\_user\_connections: 最大连接数。

max\_query\_instances: 用户同一时间点执行查询可以使用的instance个数。

sql\_block\_rules: 设置 sql block rules。设置后，该用户发送的查询如果匹配规则，则会被拒绝。

cpu\_resource\_limit: 限制查询的cpu资源。详见会话变量 cpu\_resource\_limit 的介绍。-1 表示未设置。

exec\_mem\_limit: 限制查询的内存使用。详见会话变量 exec\_mem\_limit 的介绍。-1 表示未设置。

resource\_tags: 指定用户的资源标签权限。

query\_timeout: 指定用户的查询超时权限。

注: `cpu\_resource\_limit`, `exec\_mem\_limit` 两个属性如果未设置，则默认使用会话变量中值。

### 举例

1. 修改用户 jack 最大连接数为1000

```
SET PROPERTY FOR 'jack' 'max_user_connections' = '1000';
```

2. 修改用户jack的查询可用instance个数为3000



```
SET PROPERTY FOR 'jack' 'max_query_instances' = '3000';
```

### 3. 修改用户jack的sql block rule

```
SET PROPERTY FOR 'jack' 'sql_block_rules' = 'rule1, rule2';
```

### 4. 修改用户jack的 cpu 使用限制

```
SET PROPERTY FOR 'jack' 'cpu_resource_limit' = '2';
```

### 5. 修改用户的资源标签权限

```
SET PROPERTY FOR 'jack' 'resource_tags.location' = 'group_a, group_b';
```

### 6. 修改用户的查询内存使用限制，单位字节

```
SET PROPERTY FOR 'jack' 'exec_mem_limit' = '2147483648';
```

### 7. 修改用户的查询超时限制，单位秒

```
SET PROPERTY FOR 'jack' 'query_timeout' = '500';
```

## Keywords

SET, PROPERTY

## Best Practice

# LDAP

---

## LDAP

### Name

LDAP

### 描述

SET LDAP\_ADMIN\_PASSWORD

```
SET LDAP_ADMIN_PASSWORD = PASSWORD('plain password')
```

SET LDAP\_ADMIN\_PASSWORD 命令用于设置LDAP管理员密码。使用LDAP认证时，doris需使用管理员账户和密码来向LDAP服务查询登录用户的信息。

### 举例

1. 设置LDAP管理员密码

```
SET LDAP_ADMIN_PASSWORD = PASSWORD('123456')
```

### Keywords

LDAP, PASSWORD, LDAP\_ADMIN\_PASSWORD

### Best Practice

# GRANT

## GRANT

### Name

GRANT

### 描述

GRANT 命令有如下功能：

1. 将指定的权限授予某用户或角色。
2. 将指定角色授予某用户。

注意：

2.0 及之后版本支持“将指定角色授予用户”

```
GRANT privilege_list ON priv_level TO user_identity [ROLE role_name]

GRANT privilege_list ON RESOURCE resource_name TO user_identity [ROLE role_name]

GRANT role_list TO user_identity
```

GRANT privilege\_list ON WORKLOAD GROUP workload\_group\_name TO user\_identity [ROLE role\_name]  
privilege\_list 是需要赋予的权限列表，以逗号分隔。当前 Doris 支持如下权限：

NODE\_PRIV：集群节点操作权限，包括节点上下线等操作。同时拥有 Grant\_priv 和 Node\_priv 的用户，可以将该权限赋予其他用户。ADMIN\_PRIV：除 NODE\_PRIV 以外的所有权限。GRANT\_PRIV：操作权限的权限。包括创建删除用户、角色，授权和撤权，设置密码等。SELECT\_PRIV：对指定的库或表的读取权限  
LOAD\_PRIV：对指定的库或表的导入权限 ALTER\_PRIV：对指定的库或表的 schema 变更权限  
CREATE\_PRIV：对指定的库或表的创建权限 DROP\_PRIV：对指定的库或表的删除权限 USAGE\_PRIV：对指定资源的使用权限和 workload group 权限 SHOW\_VIEW\_PRIV：查看view创建语句的权限 (从 2.0.3 版本开始，SELECT\_PRIV和LOAD\_PRIV权限不能SHOW CREATE TABLE view\_name，拥有CREATE\_PRIV，ALTER\_PRIV，DROP\_PRIV，SHOW\_VIEW\_PRIV权限项中的任何一个，有权SHOW CREATE TABLE view\_name)

旧版权限中的 ALL 和 READ\_WRITE 会被转换成：

SELECT\_PRIV,LOAD\_PRIV,ALTER\_PRIV,CREATE\_PRIV,DROP\_PRIV； READ\_ONLY 会被转换为 SELECT\_PRIV。

权限分类：

1. 节点权限：NODE\_PRIV
2. 库表权限：SELECT\_PRIV,LOAD\_PRIV,ALTER\_PRIV,CREATE\_PRIV,DROP\_PRIV

3. 资源权限和 workload group 权限: USAGE\_PRIV

priv\_level 支持以下四种形式:

1. \*.\*.\* 权限可以应用于所有 catalog 及其中的所有库表
2. catalog\_name.\*.\* 权限可以应用于指定 catalog 中的所有库表
3. catalog\_name.db.\* 权限可以应用于指定库下的所有表
4. catalog\_name.db.tbl 权限可以应用于指定库下的指定表

这里指定的 catalog\_name 或库或表可以是不存在的库和表。

resource\_name 支持以下两种形式:

1. \* 权限应用于所有资源
2. resource 权限应用于指定资源

这里指定的资源可以是不存在的资源。另外, 这里的资源请跟外部表区分开, 有使用外部表的情况请都使用 catalog 作为替代。

workload\_group\_name 可指定 workload group 名, 支持 %和\_匹配符, %可匹配任意字符串, \_匹配任意单个字符。

user\_identity:

这里的 user\_identity 语法同 CREATE USER。且必须为使用 CREATE USER 创建过的 user\_identity。user\_identity 中的host可以是域名, 如果是域名的话, 权限的生效时间可能会有1分钟左右的延迟。

也可以将权限赋予指定的 ROLE, 如果指定的 ROLE 不存在, 则会自动创建。

role\_list 是需要赋予的角色列表, 以逗号分隔, 指定的角色必须存在。

## 举例

1. 授予所有 catalog 和库表的权限给用户

```
GRANT SELECT_PRIV ON *.*.* TO 'jack'@'%';
```

2. 授予指定库表的权限给用户

```
GRANT SELECT_PRIV,ALTER_PRIV,LOAD_PRIV ON ct11.db1.tbl1 TO 'jack'@'192.8.%';
```

3. 授予指定库表的权限给角色

```
GRANT LOAD_PRIV ON ct11.db1.* TO ROLE 'my_role';
```

4. 授予所有资源的使用权限给用户

```
GRANT USAGE_PRIV ON RESOURCE * TO 'jack'@'%';
```

5. 授予指定资源的使用权限给用户

```
GRANT USAGE_PRIV ON RESOURCE 'spark_resource' TO 'jack'@'%';
```

#### 6. 授予指定资源的使用权限给角色

```
GRANT USAGE_PRIV ON RESOURCE 'spark_resource' TO ROLE 'my_role';
```

### 提示

该功能自 Apache Doris 2.0 版本起支持

#### 7. 将指定角色授予某用户

```
GRANT 'role1','role2' TO 'jack'@'%';
```

#### 8. 将指定 workload group 'g1' 授予用户 jack

```
GRANT USAGE_PRIV ON WORKLOAD GROUP 'g1' TO 'jack'@'%';
```

#### 9. 匹配所有 workload group 授予用户 jack

```
GRANT USAGE_PRIV ON WORKLOAD GROUP '%' TO 'jack'@'%';
```

#### 10. 将指定 workload group 'g1' 授予角色 my\_role

```
GRANT USAGE_PRIV ON WORKLOAD GROUP 'g1' TO ROLE 'my_role';
```

#### 11. 允许 jack 查看 db1 下 view1 的创建语句

```
GRANT SHOW_VIEW_PRIV ON db1.view1 TO 'jack'@'%';
```

## Keywords

GRANT

## Best Practice

# REVOKE

## REVOKE

### Name

REVOKE

### 描述

REVOKE 命令有如下功能：

1. 撤销某用户或某角色的指定权限。
2. 撤销先前授予某用户的指定角色。

注意：

2.0及之后版本支持“撤销先前授予某用户的指定角色”

```
REVOKE privilege_list ON db_name[.tbl_name] FROM user_identity [ROLE role_name]

REVOKE privilege_list ON RESOURCE resource_name FROM user_identity [ROLE role_name]

REVOKE role_list FROM user_identity
```

user\_identity：

这里的 user\_identity 语法同 CREATE USER。且必须为使用 CREATE USER 创建过的 user\_identity。user\_identity 中的host可以是域名，如果是域名的话，权限的撤销时间可能会有1分钟左右的延迟。

也可以撤销指定的 ROLE 的权限，执行的 ROLE 必须存在。

role\_list 是需要撤销的角色列表，以逗号分隔，指定的角色必须存在。

### 举例

1. 撤销用户 jack 数据库 testDb 的权限

```
REVOKE SELECT_PRIV ON db1.* FROM 'jack'@'192.%';
```

2. 撤销用户 jack 资源 spark\_resource 的使用权限

```
REVOKE USAGE_PRIV ON RESOURCE 'spark_resource' FROM 'jack'@'192.%';
```

3. 撤销先前授予jack的角色role1和role2

```
REVOKE 'role1','role2' FROM 'jack'@'192.%';
```

## Keywords

REVOKE

## Best Practice

# DROP-ROLE

---

## DROP-ROLE

### Name

DROP ROLE

### 描述

语句用户删除角色

```
DROP ROLE [IF EXISTS] role1;
```

删除角色不会影响以前属于角色的用户的权限。它仅相当于解耦来自用户的角色。用户从角色获得的权限不会改变

### 举例

1. 删除一个角色

```
DROP ROLE role1;
```

### Keywords

DROP, ROLE

### Best Practice



# DROP-USER

---

## DROP-USER

### Name

DROP USER

### 描述

删除一个用户

```
DROP USER 'user_identity'

`user_identity`:

 user@'host'
 user@['domain']
```

删除指定的 user identity.

### 举例

1. 删除用户 jack@'192.%'

```
DROP USER 'jack'@'192.%'
```

### Keywords

DROP, USER

### Best Practice

# ADMIN-SHOW-CONFIG

## ADMIN-SHOW-CONFIG

### Name

ADMIN SHOW CONFIG

### 描述

该语句用于展示当前集群的配置（当前仅支持展示 FE 的配置项）

语法：

```
ADMIN SHOW FRONTEND CONFIG [LIKE "pattern"];
```

结果中的各列含义如下：

- 1. Key：配置项名称
- 2. Value：配置项值
- 3. Type：配置项类型
- 4. IsMutable：是否可以通过 ADMIN SET CONFIG 命令设置
- 5. MasterOnly：是否仅适用于 Master FE
- 6. Comment：配置项说明

### 举例

- 1. 查看当前FE节点的配置

```
ADMIN SHOW FRONTEND CONFIG;
```

- 2. 使用like谓词搜索当前Fe节点的配置

```
mysql> ADMIN SHOW FRONTEND CONFIG LIKE '%check_java_version%';
+-----+-----+-----+-----+-----+-----+
| Key | Value | Type | IsMutable | MasterOnly | Comment |
+-----+-----+-----+-----+-----+-----+
| check_java_version | true | boolean | false | false | |
+-----+-----+-----+-----+-----+-----+
1 row in set (0.01 sec)
```

### Keywords

ADMIN, SHOW, CONFIG, ADMIN SHOW

## Best Practice

# ADMIN-SET-CONFIG

## ADMIN-SET-CONFIG

### Name

ADMIN SET CONFIG

### 描述

该语句用于设置集群的配置项（当前仅支持设置FE的配置项）。可设置的配置项，可以通过 ADMIN SHOW FRONTEND CONFIG; 命令查看。

语法：

```
ADMIN SET FRONTEND CONFIG ("key" = "value") [ALL];
ADMIN SET ALL FRONTENDS CONFIG ("key" = "value");
```

说明：

1. 使用ALL关键字后配置参数将应用于所有FE(除 master\_only 参数外)

### 举例

1. 设置 'disable\_balance' 为 true

```
ADMIN SET FRONTEND CONFIG ("disable_balance" = "true");
```

### Keywords

ADMIN, SET, CONFIG

### Best Practice

# SET-VARIABLE

## SET-VARIABLE

### Name

SET VARIABLE

### 描述

该语句主要是用来修改 Doris 系统变量，这些系统变量可以分为全局以及会话级别层面来修改，有些也可以进行动态修改。你也可以通过 SHOW VARIABLE 来查看这些系统变量。

语法：

```
SET variable_assignment [, variable_assignment] ...
```

说明：

1. variable\_assignment: user\_var\_name = expr | [GLOBAL | SESSION] system\_var\_name = expr

注意：

1. 只有 ADMIN 用户可以设置变量的全局生效
2. 全局生效的变量影响当前会话和此后的新会话，不影响当前已经存在的其他会话。

### 举例

1. 设置时区为东八区

```
SET time_zone = "Asia/Shanghai";
```

2. 设置全局的执行内存大小

```
SET GLOBAL exec_mem_limit = 137438953472
```

### Keywords

SET, VARIABLE

# INSTALL-PLUGIN

---

## INSTALL-PLUGIN

### Name

INSTALL PLUGIN

### 描述

该语句用于安装一个插件。

语法：

```
INSTALL PLUGIN FROM [source] [PROPERTIES ("key"="value", ...)]
```

source 支持三种类型：

1. 指向一个 zip 文件的绝对路径。
2. 指向一个插件目录的绝对路径。
3. 指向一个 http 或 https 协议的 zip 文件下载路径

### 举例

1. 安装一个本地 zip 文件插件：

```
INSTALL PLUGIN FROM "/home/users/doris/auditdemo.zip";
```

2. 安装一个本地目录中的插件：

```
INSTALL PLUGIN FROM "/home/users/doris/auditdemo/";
```

3. 下载并安装一个插件：

```
INSTALL PLUGIN FROM "http://mywebsite.com/plugin.zip";
```

注意需要放置一个和 .zip 文件同名的 md5 文件, 如 <http://mywebsite.com/plugin.zip.md5> 。其中内容为 .zip 文件的 MD5 值。

4. 下载并安装一个插件,同时设置了zip文件的md5sum的值：

```
INSTALL PLUGIN FROM "http://mywebsite.com/plugin.zip" PROPERTIES("md5sum" =
"73877f6029216f4314d712086a146570");
```

**Keywords**

INSTALL, PLUGIN

**Best Practice**

# UNINSTALL-PLUGIN

---

## UNINSTALL-PLUGIN

### Name

UNINSTALL PLUGIN

### 描述

该语句用于卸载一个插件。

语法：

```
UNINSTALL PLUGIN plugin_name;
```

plugin\_name 可以通过 SHOW PLUGINS; 命令查看。

只能卸载非 builtin 的插件。

### 举例

1. 卸载一个插件：

```
UNINSTALL PLUGIN auditdemo;
```

### Keywords

```
UNINSTALL, PLUGIN
```

### Best Practice



# ADMIN SET REPLICA STATUS

## 描述

该语句用于设置指定副本的状态,目前仅用于手动将某些副本状态设置为 BAD、DROP 和 OK，从而使得系统能够自动修复这些副本。

## 语法

```
ADMIN SET REPLICA STATUS
PROPERTIES ("tablet_id"=<tablet_id>,"backend_id"=<backend_id>,"status"=<status>)
```

## 必选参数

1. <tablet\_id>

需要设置副本状态的 tablet ID。

2. <backend\_id>

指定副本所在的 BE 节点 ID

3. <status>

当前仅支持“drop”、“bad”、“ok” 如果指定的副本不存在，或状态已经是 bad，则会被忽略

注意：

- 设置为 Bad 状态的副本  
它将不能读写。另外，设置 Bad 有时是不生效的。如果该副本实际数据是正确的，当 BE 上报该副本状态是 ok 的，fe 将把副本自动恢复回 ok 状态。操作可能立刻删除该副本，请谨慎操作。
- 设置为 Drop 状态的副本  
它仍然可以读写。会在其他机器先增加一个健康副本，再删除该副本。相比设置 Bad，设置 Drop 的操作是安全的。

## 权限控制

执行此 SQL 命令的用户必须至少拥有以下权限：

权限	对象	说明
Admin_priv	Database	执行数据库管理操作所需的权限，包括管理表、分区以及系统级命令等操作。

## 示例

- 设置 tablet 10003 在 BE 10001 上的副本状态为 bad。

```
ADMIN SET REPLICA STATUS PROPERTIES("tablet_id" = "10003", "backend_id" = "10001", "status" = "bad");
```

- 设置 tablet 10003 在 BE 10001 上的副本状态为 drop。

```
ADMIN SET REPLICA STATUS PROPERTIES("tablet_id" = "10003", "backend_id" = "10001", "status" = "drop");
```

- 设置 tablet 10003 在 BE 10001 上的副本状态为 ok。

```
ADMIN SET REPLICA STATUS PROPERTIES("tablet_id" = "10003", "backend_id" = "10001", "status" = "ok");
```

# SHOW REPLICA DISTRIBUTION

## 描述

该语句用于展示一个表或分区副本分布状态

## 语法

```
SHOW REPLICA DISTRIBUTION FROM [<database_name>.<table_name> [<partition_list>]
[where_clause]
```

其中：

```
partition_list
: PARTITION (<partition_name>[, ...])
```

其中：

```
where_clause
: WHERE <output_column_name> = <value>
```

## 必选参数

### 1. <table\_name>

指定表的标识符（即名称），在其所在的数据库（Database）中必须唯一。

标识符必须以字母字符（如果开启 unicode 名字支持，则可以是任意语言文字的字符）开头，并且不能包含空格或特殊字符，除非整个标识符字符串用反引号括起来（例如My Object）。

标识符不能使用保留关键字。

有关更多详细信息，请参阅标识符要求和保留关键字。

## 可选参数

### 1. <db\_name>

指定数据库的标识符（即名称），在其所在的集群（Cluster）中必须唯一。

标识符必须以字母字符（如果开启 unicode 名字支持，则可以是任意语言文字的字符）开头，并且不能包含空格或特殊字符，除非整个标识符字符串用反引号括起来（例如My Object）。

标识符不能使用保留关键字。

有关更多详细信息，请参阅标识符要求和保留关键字。

## 2. <partition\_list>

指定分区的标识符（即名称）列表，以逗号分割，在其所在的表（Table）中必须唯一。

标识符必须以字母字符（如果开启 `unicode` 名字支持，则可以是任意语言文字的字符）开头，并且不能包含空格或特殊字符，除非整个标识符字符串用反引号括起来（例如 `My Object`）。

标识符不能使用保留关键字。

有关更多详细信息，请参阅标识符要求和保留关键字。

## 返回值

列名	类型	说明
BackendId	Int	BE（Backend）节点的 ID，表示该副本所在的节点。
ReplicaNum	Int	该 BE 节点上的副本数量。
ReplicaSize	Int	该 BE 节点上所有副本占用的存储大小（单位：bytes）。
NumGraph	String	以可视化方式（> 符号）表示副本数量的比例。
NumPercent	String	以百分比表示副本数量的占比，例如 100.00%。
SizeGraph	String	以可视化方式（> 符号）表示副本存储大小的比例。
SizePercent	String	以百分比表示副本存储大小的占比，例如 100.00%。

## 示例

- 查看表的副本分布

```
SHOW REPLICATION DISTRIBUTION FROM sell_user;
```

[illegible]

- 查看表的分区的副本分布

```
SHOW REPLICA DISTRIBUTION FROM db1.tbl1 PARTITION(p1, p2);
```

# SHOW REPLICA STATUS

## 描述

该语句用于展示一个表或分区的副本状态信息。

## 语法

```
SHOW REPLICA STATUS FROM [<database_name>.<table_name> [<partition_list>]
[where_clause]
```

其中：

```
partition_list
: PARTITION (<partition_name>[, ...])
```

其中：

```
where_clause
: WHERE <output_column_name> = <value>
```

## 必选参数

### 1. <table\_name>

指定表的标识符（即名称），在其所在的数据库（Database）中必须唯一。

标识符必须以字母字符（如果开启 unicode 名字支持，则可以是任意语言文字的字符）开头，并且不能包含空格或特殊字符，除非整个标识符字符串用反引号括起来（例如My Object）。

标识符不能使用保留关键字。

有关更多详细信息，请参阅标识符要求和保留关键字。

## 可选参数

### 1. <db\_name>

指定数据库的标识符（即名称），在其所在的集群（Cluster）中必须唯一。

标识符必须以字母字符（如果开启 unicode 名字支持，则可以是任意语言文字的字符）开头，并且不能包含空格或特殊字符，除非整个标识符字符串用反引号括起来（例如My Object）。

标识符不能使用保留关键字。

有关更多详细信息，请参阅标识符要求和保留关键字。

2. <partition\_list>

指定分区的标识符（即名称）列表，以逗号分割，在其所在的表（Table）中必须唯一。

标识符必须以字母字符（如果开启 unicode 名字支持，则可以是任意语言文字的字符）开头，并且不能包含空格或特殊字符，除非整个标识符字符串用反引号括起来（例如My Object）。

标识符不能使用保留关键字。

有关更多详细信息，请参阅标识符要求和保留关键字。

3. WHERE <output\_column\_name> = <value>

指定输出过滤条件，output\_column\_name 必须在输出的字段列表中。

当 output\_column\_name 为 STATUS 时

value 可选值如下 - OK: replica 处于健康状态 - DEAD: replica 所在 Backend 不可用 - VERSION\_ERROR: replica 数据版本有缺失 - SCHEMA\_ERROR: replica 的 schema hash 不正确 - MISSING: replica 不存在

返回值

列名	类型	说明
TabletId	Int	tablet 的唯一标识符。
ReplicaId	Int	副本的唯一标识符。
BackendId	Int	副本所在的 BE（Backend）节点的 ID。
Version	Int	副本的当前版本号。
LastFailedVersion	Int	副本最后失败的版本号，-1 表示没有失败。
LastSuccessVersion	Int	副本最后成功的版本号。
CommittedVersion	Int	副本的提交版本号。
SchemaHash	Int	副本的 schema 哈希值。
VersionNum	Int	副本的版本数量。
IsBad	Boolean	指示副本是否处于坏状态（true/false）。
IsUserDrop	Boolean	指示副本是否被标记为用户删除。
State	String	副本的当前状态（例如：NORMAL）。
Status	String	副本的健康状态（例如：OK）。

# 权限控制

执行此 SQL 命令的用户必须至少拥有以下权限：

权限	对象	说明
Admin_priv	Database	执行数据库管理操作所需的权限，包括管理表、分区以及系统级命令等操作。

## 示例

- 查看表全部的副本状态

```
SHOW REPLICA STATUS FROM db1.tbl1;
```

TabletId	ReplicaId	BackendId	Version	LastFailedVersion	LastSuccessVersion	CommittedVersion	SchemaHash	VersionNum	IsBad	IsUserDrop	State	Status
10145	10146	10009	14	-1								
182881783	1	false	false	NORMAL	OK							
10147	10148	10009	14	-1								
182881783	1	false	false	NORMAL	OK							
10149	10150	10009	14	-1								
182881783	1	false	false	NORMAL	OK							
10151	10152	10009	14	-1								
182881783	1	false	false	NORMAL	OK							

- 查看表某个分区状态为 VERSION\_ERROR 的副本

```
SHOW REPLICA STATUS FROM tbl1 PARTITION (p1, p2)
WHERE STATUS = "VERSION_ERROR";
```

- 查看表所有状态不健康的副本

```
SHOW REPLICA STATUS FROM tbl1
WHERE STATUS != "OK";
```

# ADMIN-REPAIR-TABLE

## ADMIN-REPAIR-TABLE

### Name

ADMIN REPAIR TABLE

### 描述

语句用于尝试优先修复指定的表或分区

语法：

```
ADMIN REPAIR TABLE table_name[PARTITION (p1,...)]
```

说明：

- 1. 该语句仅表示让系统尝试以高优先级修复指定表或分区的分片副本，并不保证能够修复成功。用户可以通过 ADMIN SHOW REPLICA STATUS 命令查看修复情况。
- 2. 默认的 timeout 是 14400 秒(4小时)。超时意味着系统将不再以高优先级修复指定表或分区的分片副本。需要重新使用该命令设置

### 举例

- 1. 尝试修复指定表

```
ADMIN REPAIR TABLE tbl1;
```

- 2. 尝试修复指定分区

```
ADMIN REPAIR TABLE tbl1 PARTITION (p1, p2);
```

### Keywords

```
ADMIN, REPAIR, TABLE
```

### Best Practice



# ADMIN-CANCEL-REPAIR

---

## ADMIN-CANCEL-REPAIR

### Name

ADMIN CANCEL REPAIR

### 描述

该语句用于取消以高优先级修复指定表或分区

语法：

```
ADMIN CANCEL REPAIR TABLE table_name[PARTITION (p1,...)];
```

说明：

1. 该语句仅表示系统不再以高优先级修复指定表或分区的分片副本。系统仍会以默认调度方式修复副本。

### 举例

1. 取消高优先级修复

```
ADMIN CANCEL REPAIR TABLE tbl PARTITION(p1);
```

### Keywords

```
ADMIN, CANCEL, REPAIR
```

### Best Practice

# ADMIN CHECK TABLET

## 描述

该语句用于对一组 tablet 执行指定的检查操作

## 语法

```
ADMIN CHECK TABLET (<tablet_id> [,...]) PROPERTIES("type" = "<type_value>")
```

## 必选参数

1. <tablet\_id>

需要进行执行指定的检查操作的 tablet ID。

## 可选参数

1. <type\_value> 目前只支持 consistency

- consistency:  
对 tablet 的副本数据一致性进行检查。该命令为异步命令，发送后，Doris 会开始执行对应 tablet 的一致性检查作业。

## 返回值

执行语句的最终的结果，将体现在SHOW PROC "/cluster\_health/tablet\_health"; 结果中的 InconsistentNum 列。

列名	类型	说明
InconsistentNum	Int	不一致的的 tablet 数量

## 权限控制

执行此 SQL 命令的用户必须至少拥有以下权限：

权限	对象	说明
Admin_priv	Database	执行数据库管理操作所需的权限，包括管理表、分区以及系统级命令等操作。

## 示例

- 对指定的一组 tablet 进行副本数据一致性检查

```
admin check tablet (10000, 10001) PROPERTIES("type" = "consistency");
```

# ADMIN DIAGNOSE TABLET

## ADMIN DIAGNOSE TABLET

### 描述

该语句用于诊断指定 tablet。结果中将显示这个 tablet 的信息和一些潜在的问题。

语法：

```
ADMIN DIAGNOSE TABLET tblet_id
```

说明：

结果中的各行信息如下：

1. TabletExist:	Tablet是否存在
2. TabletId:	Tablet ID
3. Database:	Tablet 所属 DB 和其 ID
4. Table:	Tablet 所属 Table 和其 ID
5. Partition:	Tablet 所属 Partition 和其 ID
6. MaterializedIndex:	Tablet 所属物化视图和其 ID
7. Replicas(ReplicaId -> BackendId):	Tablet 各副本和其所在 BE。
8. ReplicasNum:	副本数量是否正确。
9. ReplicaBackendStatus:	副本所在 BE 节点是否正常。
10. ReplicaVersionStatus:	副本的版本号是否正常。
11. ReplicaStatus:	副本状态是否正常。
12. ReplicaCompactionStatus:	副本 Compaction 状态是否正常。

### 举例

1. 查看 Tablet 10001 的诊断结果

```
ADMIN DIAGNOSE TABLET 10001;
```

### keywords

ADMIN,DIAGNOSE,TABLET

# ADMIN COPY TABLET

## 描述

该语句用于为指定的 tablet 制作快照，主要用于本地加载 tablet 来复现问题。

## 语法

```
ADMIN COPY TABLET <tablet_id> PROPERTIES ("<key>"="<value>" [,...]).
```

## 必选参数

1. <tablet\_id>

要复制的 tablet 的 ID。

## 可选参数

```
[PROPERTIES ("<key>"="<value>" [, ...])]
```

PROPERTIES 子句允许指定附加参数：

1. <backend\_id>

指定副本所在的 BE 节点 ID。如果未指定，则随机选择一个副本。

2. <version>

指定快照的版本。版本必须小于或等于副本的最大版本。如果未指定，则使用最大版本。

3. <expiration\_minutes>

快照的保留时间。默认为 1 小时，超时后会自动清理。单位为分钟。

## 返回值

列名	类型	说明
TabletId	string	为该 tablet 创建的快照的 ID。
BackendId	string	存储该快照的 BE 节点的 ID。
Ip	string	存储该快照的 BE 节点的 IP 地址。
Path	string	快照在 BE 节点上的存储路径。
ExpirationMinutes	string	快照将自动删除的时间（单位：分钟）。

列名	类型	说明
CreateTableStmt	string	对应 tablet 的表创建语句。此语句不是原始的建表语句，而是用于后续加载该 tablet 到本地的简化建表语句。

## 权限控制

执行此 SQL 命令的用户必须至少拥有以下权限：

权限	对象	说明
Admin_priv	Database	执行数据库管理操作所需的权限，包括管理表、分区以及系统级命令等操作。

## 示例

- 为指定 BE 节点上的副本创建快照

```
ADMIN COPY TABLET 10020 PROPERTIES("backend_id" = "10003");
```

```

 TabletId: 10020
 BackendId: 10003
 Ip: 192.168.10.1
 Path: /path/to/be/storage/snapshot/20220830101353.2.3600
ExpirationMinutes: 60
 CreateTableStmt: CREATE TABLE `tbl1` (
 `k1` int(11) NULL,
 `k2` int(11) NULL
) ENGINE=OLAP
 DUPLICATE KEY(`k1`, `k2`)
 DISTRIBUTED BY HASH(k1) BUCKETS 1
 PROPERTIES (
 "replication_num" = "1",
 "version_info" = "2"
);

```

- 为指定 BE 节点上指定版本的副本创建快照

```
ADMIN COPY TABLET 10010 PROPERTIES("backend_id" = "10003", "version" = "10");
```

```

 TabletId: 10010
 BackendId: 10003
 Ip: 192.168.10.1
 Path: /path/to/be/storage/snapshot/20220830101353.2.3600
ExpirationMinutes: 60
 CreateTableStmt: CREATE TABLE `tbl1` (
 `k1` int(11) NULL,
 `k2` int(11) NULL
) ENGINE=OLAP
 DUPLICATE KEY(`k1`, `k2`)
 DISTRIBUTED BY HASH(k1) BUCKETS 1
 PROPERTIES (
 "replication_num" = "1",
 "version_info" = "2"
);

```

# SHOW TABLET STORAGE FORMAT

## 描述

该语句用于显示 Backend 上的存储格式信息

## 语法

```
SHOW TABLET STORAGE FORMAT [VERBOSE]
```

## 可选参数

**\*\* 1. VERBOSE \*\***

展示更详细的信息

## 返回值

列名	类型	说明
BackendId	Int	BE (Backend) 节点的ID，表示该tablet的副本所在的节点。
V1Count	Int	V1 版本 tablet 数量。
V2Count	Int	V2 版本 tablet 数量。
TabletId	Int	tablet的唯一标识符，用于标识具体的tablet。
StorageFormat	String	tablet的版本 V1或V2

## 权限控制

执行此 SQL 命令的用户必须至少拥有以下权限：

权限	对象	说明
Admin_priv	Database	执行数据库管理操作所需的权限，包括管理表、分区以及系统级命令等操作。

## 示例

- 执行未添加 verbose 参数的语句

```
show tablet storage format;
```

```
+-----+-----+-----+
| BackendId | V1Count | V2Count |
+-----+-----+-----+
```

10002	0	2867	
+	+	+	+

- 执行添加 verbose 参数的语句

```
show tablet storage format verbose;
```

+	+	+	+
BackendId	TabletId	StorageFormat	
+	+	+	+
10002	39227	V2	
10002	39221	V2	
10002	39215	V2	
10002	39199	V2	
+	+	+	+



# ADMIN CLEAN TRASH

## 描述

该语句用于清理 backend 内的垃圾数据。

## 语法

```
ADMIN CLEAN TRASH [ON ("<be_host>:<be_heartbeat_port>" [, ...])];
```

## 可选参数

- 1. [ON ("<be\_host>:<be\_heartbeat\_port>" [, ...])]

指定需要清理的 backend。如果不加 ON，默认清理所有 backend。

## 权限控制

执行此 SQL 命令的用户必须至少具有以下权限：

权限 (Privilege)	对象 (Object)	说明 (Notes)
ADMIN_PRIV	用户 (User) 或 角色 (Role)	用户或者角色拥有 ADMIN_PRIV 权限才能进行CLEAN TRASH操作

## 示例

```
-- 清理所有be节点的垃圾数据。
ADMIN CLEAN TRASH;
```

```
-- 清理'192.168.0.1:9050'和'192.168.0.2:9050'的垃圾数据。
ADMIN CLEAN TRASH ON ("192.168.0.1:9050", "192.168.0.2:9050");
```

# RECOVER

---

## RECOVER

### Name

RECOVER

### 描述

该语句用于恢复之前删除的 database、table 或者 partition。支持通过name、id来恢复指定的元信息，并且支持将恢复的元信息重命名。

可以通过 SHOW CATALOG RECYCLE BIN 来查询当前可恢复的元信息。

语法：

1. 以name恢复 database

```
RECOVER DATABASE db_name;
```

2. 以name恢复 table

```
RECOVER TABLE [db_name.]table_name;
```

3. 以name恢复 partition

```
RECOVER PARTITION partition_name FROM [db_name.]table_name;
```

4. 以name和id恢复 database

```
RECOVER DATABASE db_name db_id;
```

5. 以name和id恢复 table

```
RECOVER TABLE [db_name.]table_name table_id;
```

6. 以name和id恢复 partition

```
RECOVER PARTITION partition_name partition_id FROM [db_name.]table_name;
```

7. 以name恢复 database 并设定新名字

```
RECOVER DATABASE db_name AS new_db_name;
```

## 8. 以name和id恢复 table 并设定新名字

```
RECOVER TABLE [db_name.]table_name table_id AS new_table_name;
```

## 9. 以name和id恢复 partition 并设定新名字

```
RECOVER PARTITION partition_name partition_id AS new_partition_name FROM [db_name.]table_name;
```

说明：

- 该操作仅能恢复之前一段时间内删除的元信息。默认为 1 天。（可通过fe.conf中 catalog\_trash\_expire\_second参数配置）
- 如果恢复元信息时没有指定id，则默认恢复最后一个删除的同名元数据。
- 可以通过 SHOW CATALOG RECYCLE BIN 来查询当前可恢复的元信息。

## 举例

### 1. 恢复名为 example\_db 的 database

```
RECOVER DATABASE example_db;
```

### 2. 恢复名为 example\_tbl 的 table

```
RECOVER TABLE example_db.example_tbl;
```

### 3. 恢复表 example\_tbl 中名为 p1 的 partition

```
RECOVER PARTITION p1 FROM example_tbl;
```

### 4. 恢复 example\_db\_id 且名为 example\_db 的 database

```
RECOVER DATABASE example_db example_db_id;
```

### 5. 恢复 example\_tbl\_id 且名为 example\_tbl 的 table

```
RECOVER TABLE example_db.example_tbl example_tbl_id;
```

### 6. 恢复表 example\_tbl 中 p1\_id 且名为 p1 的 partition

```
RECOVER PARTITION p1 p1_id FROM example_tbl;
```

### 7. 恢复 example\_db\_id 且名为 example\_db 的 database，并设定新名字 new\_example\_db

```
RECOVER DATABASE example_db example_db_id AS new_example_db;
```

### 8. 恢复名为 example\_tbl 的 table，并设定新名字 new\_example\_tbl

```
RECOVER TABLE example_db.example_tbl AS new_example_tbl;
```

9. 恢复表 example\_tbl 中 p1\_id 且名为 p1 的 partition，并设定新名字 new\_p1

```
RECOVER PARTITION p1 p1_id AS new_p1 FROM example_tbl;
```

## Keywords

RECOVER

## Best Practice

# KILL

---

## KILL

### Name

KILL

### 描述

每个 Doris 的连接都在一个单独的线程中运行。您可以使用 KILL processlist\_id 语句终止线程。

线程进程列表标识符可以从 INFORMATION\_SCHEMA PROCESSLIST 表的 ID 列、SHOW PROCESSLIST 输出的 Id 列和性能模式线程表的 PROCESSLIST\_ID 列确定。

语法：

```
KILL [CONNECTION] processlist_id
```

除此之外，您还可以使用 processlist\_id 或者 query\_id 终止正在执行的查询命令

语法：

```
KILL QUERY processlist_id | query_id
```

### 举例

### Keywords

```
KILL
```

### Best Practice

# ADMIN-REBALANCE-DISK

## ADMIN-REBALANCE-DISK

### Name

ADMIN REBALANCE DISK ### 描述

该语句用于尝试优先均衡指定的BE磁盘数据

语法：

```

 ...
ADMIN REBALANCE DISK [ON ("BackendHost1:BackendHeartBeatPort1", "BackendHost2:BackendHeartBeatPort2", ...)];
 ...

```

说明：

- 1. 该语句表示让系统尝试优先均衡指定BE的磁盘数据，不受限于集群是否均衡。
- 2. 默认的 timeout 是 24小时。超时意味着系统将不再优先均衡指定的BE磁盘数据。需要重新使用该命令设置。
- 3. 指定BE的磁盘数据均衡后，该BE的优先级将会失效。

### 举例

- 1. 尝试优先均衡集群内的所有BE

```
ADMIN REBALANCE DISK;
```

- 2. 尝试优先均衡指定BE

```
ADMIN REBALANCE DISK ON ("192.168.1.1:1234", "192.168.1.2:1234");
```

### Keywords

```
ADMIN, REBALANCE, DISK
```

### Best Practice

# ADMIN-CANCEL-REBALANCE-DISK

## ADMIN-CANCEL-REBALANCE-DISK

### Name

ADMIN CANCEL REBALANCE DISK ### 描述

该语句用于取消优先均衡BE的磁盘

语法:

```
ADMIN CANCEL REBALANCE DISK [ON ("BackendHost1:BackendHeartBeatPort1",
"BackendHost2:BackendHeartBeatPort2", ...)];
```

说明:

1. 该语句仅表示系统不再优先均衡指定BE的磁盘数据。系统仍会以默认调度方式均衡BE的磁盘数据。

### 举例

1. 取消集群所有BE的优先磁盘均衡

```
ADMIN CANCEL REBALANCE DISK;
```

2. 取消指定BE的优先磁盘均衡

```
ADMIN CANCEL REBALANCE DISK ON ("192.168.1.1:1234", "192.168.1.2:1234");
```

### Keywords

ADMIN,CANCEL,REBALANCE,DISK

### Best Practice

# ENABLE-FEATURE

---

## ENABLE-FEATURE

描述

举例

### Keywords

ENABLE, FEATURE

### Best Practice



# CREATE-CATALOG

---

## CREATE-CATALOG

### Name

CREATE CATALOG

### 描述

该语句用于创建外部数据目录（catalog）

语法：

```
CREATE CATALOG [IF NOT EXISTS] catalog_name [comment]
 PROPERTIES ("key"="value", ...);
```

- hms: Hive MetaStore
- es: Elasticsearch
- jdbc: 数据库访问的标准接口(JDBC), 当前支持 MySQL 和 PostgreSQL

### 举例

#### 1. 新建数据目录 hive

```
CREATE CATALOG hive comment 'hive catalog' PROPERTIES (
 'type'='hms',
 'hive.metastore.uris' = 'thrift://127.0.0.1:7004',
 'dfs.nameservices'='HANN',
 'dfs.ha.namenodes.HANN'='nn1,nn2',
 'dfs.namenode.rpc-address.HANN.nn1'='nn1_host:rpc_port',
 'dfs.namenode.rpc-address.HANN.nn2'='nn2_host:rpc_port',

 'dfs.client.failover.proxy.provider.HANN'='org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailove
rProxyProvider'
);
```

#### 2. 新建数据目录 es

```
CREATE CATALOG es PROPERTIES (
 "type"="es",
 "hosts"="http://127.0.0.1:9200"
);
```

#### 3. 新建数据目录 jdbc

**mysql**

```
CREATE CATALOG jdbc PROPERTIES (
 "type"="jdbc",
 "user"="root",
 "password"="123456",
 "jdbc_url" = "jdbc:mysql://127.0.0.1:3316/doris_test?useSSL=false",
 "driver_url" = "https://doris-community-test-1308700295.cos.ap-
hongkong.myqcloud.com/jdbc_driver/mysql-connector-java-8.0.25.jar",
 "driver_class" = "com.mysql.cj.jdbc.Driver"
);
```

## postgresql

```
CREATE CATALOG jdbc PROPERTIES (
 "type"="jdbc",
 "user"="postgres",
 "password"="123456",
 "jdbc_url" = "jdbc:postgresql://127.0.0.1:5432/demo",
 "driver_url" = "file:///path/to/postgresql-42.5.1.jar",
 "driver_class" = "org.postgresql.Driver"
);
```

## clickhouse

```
CREATE CATALOG jdbc PROPERTIES (
 "type"="jdbc",
 "user"="default",
 "password"="123456",
 "jdbc_url" = "jdbc:clickhouse://127.0.0.1:8123/demo",
 "driver_url" = "file:///path/to/clickhouse-jdbc-0.3.2-patch11-all.jar",
 "driver_class" = "com.clickhouse.jdbc.ClickHouseDriver"
)
```

**oracle** sql CREATE CATALOG jdbc PROPERTIES ( "type"="jdbc", "user"="doris",  
"password"="123456", "jdbc\_url" = "jdbc:oracle:thin:@127.0.0.1:1521:helowin",  
"driver\_url" = "file:///path/to/ojdbc8.jar", "driver\_class" =  
"oracle.jdbc.driver.OracleDriver" );

**SQLServer** sql CREATE CATALOG sqlserver\_catalog PROPERTIES ( "type"="jdbc",  
"user"="SA", "password"="Doris123456", "jdbc\_url" =  
"jdbc:sqlserver://localhost:1433;DataBaseName=doris\_test", "driver\_url" =  
"file:///path/to/mssql-jdbc-11.2.3.jre8.jar", "driver\_class" =  
"com.microsoft.sqlserver.jdbc.SQLServerDriver" );

**SAP HANA** sql CREATE CATALOG saphana\_catalog PROPERTIES ( "type"="jdbc",  
"user"="SYSTEM", "password"="SAPHANA", "jdbc\_url" =  
"jdbc:sap://localhost:31515/TEST", "driver\_url" = "file:///path/to/ngdbc.jar",  
"driver\_class" = "com.sap.db.jdbc.Driver" );

**Trino** sql CREATE CATALOG trino\_catalog PROPERTIES ( "type"="jdbc", "user"="hadoop",  
"password"="", "jdbc\_url" = "jdbc:trino://localhost:8080/hive", "driver\_url" =  
"file:///path/to/trino-jdbc-389.jar", "driver\_class" = "io.trino.jdbc.TrinoDriver" );

**OceanBase** sql CREATE CATALOG oceanbase\_catalog PROPERTIES ( "type"="jdbc",  
"user"="root", "password"="", "jdbc\_url" = "jdbc:oceanbase://localhost:2881/demo",

```
"driver_url" = "file:///path/to/oceanbase-client-2.4.2.jar", "driver_class" =
"com.oceanbase.jdbc.Driver");
```

## **Keywords**

CREATE, CATALOG

## **Best Practice**

# CREATE-DATABASE

## CREATE-DATABASE

### Name

CREATE DATABASE

### 描述

该语句用于新建数据库（database）

语法：

```
CREATE DATABASE [IF NOT EXISTS] db_name
[PROPERTIES ("key"="value", ...)];
```

PROPERTIES 该数据库的附加信息，可以缺省。

- 如果创建 Iceberg 数据库，则需要在 properties 中提供以下信息：

```
PROPERTIES (
 "iceberg.database" = "iceberg_db_name",
 "iceberg.hive.metastore.uris" = "thrift://127.0.0.1:9083",
 "iceberg.catalog.type" = "HIVE_CATALOG"
)
```

参数说明：

- iceberg.database：Iceberg 对应的库名；
  - iceberg.hive.metastore.uris：hive metastore 服务地址；
  - iceberg.catalog.type：默认为 HIVE\_CATALOG；当前仅支持 HIVE\_CATALOG，后续会支持更多 Iceberg catalog 类型。
- 如果要为db下的table指定默认的副本分布策略，需要指定replication\_allocation（table的replication\_allocation属性优先级会高于db）

```
PROPERTIES (
 "replication_allocation" = "tag.location.default:3"
)
```

### 举例

1. 新建数据库 db\_test

```
CREATE DATABASE db_test;
```

## 2. 新建 Iceberg 数据库 iceberg\_test

```
CREATE DATABASE `iceberg_test`
PROPERTIES (
 "iceberg.database" = "doris",
 "iceberg.hive.metastore.uris" = "thrift://127.0.0.1:9083",
 "iceberg.catalog.type" = "HIVE_CATALOG"
);
```

### Keywords

CREATE, DATABASE

### Best Practice

# CREATE-TABLE

## CREATE-TABLE

### 描述

该命令用于创建一张表。本文档主要介绍创建 Doris 自维护的表的语法。外部表语法请参阅 [CREATE-EXTERNAL-TABLE](#) 文档。

```
CREATE TABLE [IF NOT EXISTS] [database.]table
(
 column_definition_list
 [, index_definition_list]
)
[engine_type]
[keys_type]
[table_comment]
[partition_info]
distribution_desc
[rollup_list]
[properties]
[extra_properties]
```

### column\_definition\_list

列定义列表：

column\_definition[, column\_definition] \* column\_definition 列定义：

```
`column_name column_type [KEY] [aggr_type] [NULL] [default_value] [column_comment]`
* `column_type`
 列类型，支持以下类型：
    ```
    TINYINT (1 字节)
        范围：-2^7 + 1 ~ 2^7 - 1
    SMALLINT (2 字节)
        范围：-2^15 + 1 ~ 2^15 - 1
    INT (4 字节)
        范围：-2^31 + 1 ~ 2^31 - 1
    BIGINT (8 字节)
        范围：-2^63 + 1 ~ 2^63 - 1
    LARGEINT (16 字节)
        范围：-2^127 + 1 ~ 2^127 - 1
    FLOAT (4 字节)
        支持科学计数法
    DOUBLE (12 字节)
        支持科学计数法
    DECIMAL[(precision, scale)] (16 字节)
        保证精度的小数类型。默认是 DECIMAL(9, 0)
        precision: 1 ~ 27
        scale: 0 ~ 9
        其中整数部分为 1 ~ 18
        不支持科学计数法
    DATE (3 字节)
```

```

    范围: 0000-01-01 ~ 9999-12-31
DATETIME (8 字节)
    范围: 0000-01-01 00:00:00 ~ 9999-12-31 23:59:59
CHAR[(length)]
    定长字符串。长度范围: 1 ~ 255。默认为 1
VARCHAR[(length)]
    变长字符串。长度范围: 1 ~ 65533。默认为 65533
HLL (1~16385 个字节)
    HyperLogLog 列类型, 不需要指定长度和默认值。长度根据数据的聚合程度系统内控制。
    必须配合 HLL_UNION 聚合类型使用。
BITMAP
    bitmap 列类型, 不需要指定长度和默认值。表示整型的集合, 元素最大支持到  $2^{64} - 1$ 。
    必须配合 BITMAP_UNION 聚合类型使用。
```
* `aggr_type`
聚合类型, 支持以下聚合类型:
```
SUM: 求和。适用数值类型。
MIN: 求最小值。适合数值类型。
MAX: 求最大值。适合数值类型。
REPLACE: 替换。对于维度列相同的行, 指标列会按照导入的先后顺序, 后导入的替换先导入的。
REPLACE_IF_NOT_NULL: 非空值替换。和 REPLACE 的区别在于对于 null 值, 不做替换。这里要注意的是字段默认值要给 NULL, 而不能
是空字符串, 如果是空字符串, 会给你替换成空字符串。
HLL_UNION: HLL 类型的列的聚合方式, 通过 HyperLogLog 算法聚合。
BITMAP_UNION: BITMAP 类型的列的聚合方式, 进行位图的并集聚合。
```

```

- default\_value 列默认值, 当导入数据未指定该列的值时, 系统将赋予该列 default\_value。

```

语法为`default default_value`。

当前 default_value 支持两种形式:
1. 用户指定固定值, 如:
```SQL
    k1 INT DEFAULT '1',
    k2 CHAR(10) DEFAULT 'aaaa'
```

2. 系统提供的关键字, 目前支持以下关键字:

```SQL
    // 只用于 DATETIME 类型, 导入数据缺失该值时系统将赋予当前时间
    dt DATETIME DEFAULT CURRENT_TIMESTAMP
```

```

示例:

```

k1 TINYINT,
k2 DECIMAL(10,2) DEFAULT "10.5",
k4 BIGINT NULL DEFAULT "1000" COMMENT "This is column k4",
v1 VARCHAR(10) REPLACE NOT NULL,
v2 BITMAP BITMAP_UNION,
v3 HLL HLL_UNION,
v4 INT SUM NOT NULL DEFAULT "1" COMMENT "This is column v4"

```

## index\_definition\_list

索引列表定义:

index\_definition[, index\_definition]

- `index_definition`

索引定义：

```
INDEX index_name (col_name) [USING INVERTED] COMMENT 'xxxxxx'
```

示例：

```
INDEX idx1 (k1) USING INVERTED COMMENT "This is a inverted index1",
INDEX idx2 (k2) USING INVERTED COMMENT "This is a inverted index2",
...
```

## engine\_type

表引擎类型。本文档中类型皆为 OLAP。其他外部表引擎类型见 [CREATE EXTERNAL TABLE](#) 文档。示例：

```
`ENGINE=olap`
```

## keys\_type

数据模型。

`key_type(col1, col2, ...)`

`key_type` 支持以下模型：

- `DUPLICATE KEY`（默认）：其后指定的列为排序列。
- `AGGREGATE KEY`：其后指定的列为维度列。
- `UNIQUE KEY`：其后指定的列为主键列。

注：当表属性 `enable_duplicate_without_keys_by_default = true` 时，默认创建没有排序列的 `DUPLICATE` 表。

示例：

```
DUPLICATE KEY(col1, col2),
AGGREGATE KEY(k1, k2, k3),
UNIQUE KEY(k1, k2)
```

## table\_comment

表注释。示例：

```
```\nCOMMENT "This is my first DORIS table"\n```
```


partition_info

分区信息，支持三种写法：

1. LESS THAN：仅定义分区上界。下界由上一个分区的上界决定。

```
PARTITION BY RANGE(col1[, col2, ...])
(
    PARTITION partition_name1 VALUES LESS THAN MAXVALUE|("value1", "value2", ...),
    PARTITION partition_name2 VALUES LESS THAN MAXVALUE|("value1", "value2", ...)
)
```

2. FIXED RANGE：定义分区的左闭右开区间。

```
PARTITION BY RANGE(col1[, col2, ...])
(
    PARTITION partition_name1 VALUES [("k1-lower1", "k2-lower1", "k3-lower1",...), ("k1-upper1", "k2-upper1", "k3-upper1", ...)],
    PARTITION partition_name2 VALUES [("k1-lower1-2", "k2-lower1-2", ...), ("k1-upper1-2", MAXVALUE,
))
)
```

3. MULTI RANGE：批量创建 RANGE 分区，定义分区的左闭右开区间，设定时间单位和步长，时间单位支持年、月、日、周和小时。

```
PARTITION BY RANGE(col)
(
    FROM ("2000-11-14") TO ("2021-11-14") INTERVAL 1 YEAR,
    FROM ("2021-11-14") TO ("2022-11-14") INTERVAL 1 MONTH,
    FROM ("2022-11-14") TO ("2023-01-03") INTERVAL 1 WEEK,
    FROM ("2023-01-03") TO ("2023-01-14") INTERVAL 1 DAY
)
```

提示

该功能自 Apache Doris 1.2 版本起支持

4. MULTI RANGE：批量创建数字类型的 RANGE 分区，定义分区的左闭右开区间，设定步长。

```
PARTITION BY RANGE(int_col)
(
    FROM (1) TO (100) INTERVAL 10
)
```

distribution_desc

定义数据分桶方式。

1. Hash 分桶 语法：DISTRIBUTED BY HASH (k1[,k2 ...]) [BUCKETS num|auto] 说明：使用指定的 key 列进行哈希分桶。

2. Random 分桶 语法: DISTRIBUTED BY RANDOM [BUCKETS num|auto] 说明: 使用随机数进行分桶。

rollup_list

建表的同时可以创建多个物化视图 (ROLLUP)。

ROLLUP (rollup_definition[, rollup_definition, ...])

- rollup_definition

```
rollup_name (col1[, col2, ...]) [DUPLICATE KEY(col1[, col2, ...])] [PROPERTIES("key" = "value")]
```

示例:

```
ROLLUP (  
    r1 (k1, k3, v1, v2),  
    r2 (k1, v1)  
)
```

properties

设置表属性。目前支持以下属性:

- replication_num

副本数。默认副本数为 3。如果 BE 节点数量小于 3, 则需指定副本数小于等于 BE 节点数量。

在 0.15 版本后, 该属性将自动转换成 replication_allocation 属性, 如:

```
"replication_num" = "3" 会自动转换成 "replication_allocation" =  
"tag.location.default:3"
```

- replication_allocation

根据 Tag 设置副本分布情况。该属性可以完全覆盖 replication_num 属性的功能。

- is_being_synced

用于标识此表是否是被 CCR 复制而来并且正在被 syncer 同步, 默认为 false。

如果设置为 true:

colocate_with, storage_policy 属性将被擦除

dynamic partition, auto bucket 功能将会失效, 即在 show create table 中显示开启状态, 但不会实际生效。当 is_being_synced 被设置为 false 时, 这些功能将会恢复生效。

这个属性仅供 CCR 外围模块使用, 在 CCR 同步的过程中不要手动设置。

- storage_medium/storage_cooldown_time

数据存储介质。storage_medium 用于声明表数据的初始存储介质, 而 storage_cooldown_time 用于设定到期时间。示例:

```
"storage_medium" = "SSD",  
"storage_cooldown_time" = "2020-11-20 00:00:00"
```

这个示例表示数据存放在 SSD 中，并且在 2020-11-20 00:00:00 到期后，会自动迁移到 HDD 存储上。

- `colocate_with`

当需要使用 Colocation Join 功能时，使用这个参数设置 Colocation Group。

```
"colocate_with" = "group1"
```

- `bloom_filter_columns`

用户指定需要添加 Bloom Filter 索引的列名称列表。各个列的 Bloom Filter 索引是独立的，并不是组合索引。

```
"bloom_filter_columns" = "k1, k2, k3"
```

- `in_memory`

已弃用。只支持设置为 'false'。

- `compression`

Doris 表的默认压缩方式是 LZ4。1.1 版本后，支持将压缩方式指定为 ZSTD 以获得更高的压缩比。

```
"compression" = "zstd"
```

- `function_column.sequence_col`

当使用 UNIQUE KEY 模型时，可以指定一个 sequence 列，当 KEY 列相同时，将按照 sequence 列进行 REPLACE(较大值替换较小值，否则无法替换)

`function_column.sequence_col` 用来指定 sequence 列到表中某一列的映射，该列可以为整型和时间类型 (DATE、DATETIME)，创建后不能更改该列的类型。如果设置了 `function_column.sequence_col`，`function_column.sequence_type` 将被忽略。

```
"function_column.sequence_col" = 'column_name'
```

- `function_column.sequence_type`

当使用 UNIQUE KEY 模型时，可以指定一个 sequence 列，当 KEY 列相同时，将按照 sequence 列进行 REPLACE(较大值替换较小值，否则无法替换)

这里我们仅需指定顺序列的类型，支持时间类型或整型。Doris 会创建一个隐藏的顺序列。

```
"function_column.sequence_type" = 'Date'
```

- `light_schema_change`

是否使用 light schema change 优化。

如果设置成 true, 对于值列的加减操作，可以更快地，同步地完成。

```
"light_schema_change" = 'true'
```

该功能在 2.0.0 及之后版本默认开启。

- `disable_auto_compaction`

是否对这个表禁用自动 compaction。

如果这个属性设置成 true, 后台的自动 compaction 进程会跳过这个表的所有 tablet。

```
"disable_auto_compaction" = "false"
```

- `enable_single_replica_compaction`

是否对这个表开启单副本 compaction。

如果这个属性设置成 true, 这个表的 tablet 的所有副本只有一个 do compaction, 其他的从该副本拉取 rowset

```
"enable_single_replica_compaction" = "false"
```

- `enable_duplicate_without_keys_by_default`

当配置为true时, 如果创建表的时候没有指定 Unique、Aggregate 或 Duplicate 时, 会默认创建一个没有排序列和前缀索引的 Duplicate 模型的表。

```
"enable_duplicate_without_keys_by_default" = "false"
```

- `skip_write_index_on_load`

是否对这个表开启数据导入时不写索引。

如果这个属性设置成 true, 数据导入的时候不写索引 (目前仅对倒排索引生效), 而是在 compaction 的时候延迟写索引。这样可以避免首次写入和 compaction 重复写索引的 CPU 和 IO 资源消耗, 提升高吞吐导入的性能。

```
"skip_write_index_on_load" = "false"
```

- `compaction_policy`

配置这个表的 compaction 的合并策略, 仅支持配置为 time_series 或者 size_based

time_series: 当 rowset 的磁盘体积极攒到一定大小时进行版本合并。合并后的 rowset 直接晋升到 base compaction 阶段。在时序场景持续导入的情况下有效降低 compact 的写入放大率

此策略将使用 time_series_compaction 为前缀的参数调整 compaction 的执行

```
"compaction_policy" = ""
```

- `time_series_compaction_goal_size_mbytes`

compaction 的合并策略为 time_series 时, 将使用此参数来调整每次 compaction 输入的文件的大小, 输出的文件大小和输入相当

```
"time_series_compaction_goal_size_mbytes" = "1024"
```

- `time_series_compaction_file_count_threshold`

compaction 的合并策略为 time_series 时，将使用此参数来调整每次 compaction 输入的文件数量的最小值

一个 tablet 中，文件数超过该配置，就会触发 compaction

```
"time_series_compaction_file_count_threshold" = "2000"
```

- time_series_compaction_time_threshold_seconds

compaction 的合并策略为 time_series 时，将使用此参数来调整 compaction 的最长时间间隔，即长时间未执行过 compaction 时，就会触发一次 compaction，单位为秒

```
"time_series_compaction_time_threshold_seconds" = "3600"
```

- time_series_compaction_level_threshold

compaction 的合并策略为 time_series 时，此参数默认为 1，当设置为 2 时用来控住对于合并过一次的段再合并一层，保证段大小达到 time_series_compaction_goal_size_mbytes，

能达到段数量减少的效果。

```
"time_series_compaction_level_threshold" = "2"
```

- 动态分区相关

动态分区相关参数如下：

- dynamic_partition.enable: 用于指定表级别的动态分区功能是否开启。默认为 true。
- dynamic_partition.time_unit: 用于指定动态添加分区的时间单位，可选择为 DAY (天), WEEK(周), MONTH (月), YEAR (年), HOUR (时)。
- dynamic_partition.start: 用于指定向前删除多少个分区。值必须小于 0。默认为 Integer.MIN_VALUE。
- dynamic_partition.end: 用于指定提前创建的分区数量。值必须大于 0。
- dynamic_partition.prefix: 用于指定创建的分区名前缀，例如分区名前缀为 p，则自动创建分区名为 p20200108。
- dynamic_partition.buckets: 用于指定自动创建的分区桶数量。
- dynamic_partition.create_history_partition: 是否创建历史分区。
- dynamic_partition.history_partition_num: 指定创建历史分区的数量。
- dynamic_partition.reserved_history_periods: 用于指定保留的历史分区的时间段。

举例

1. 创建一个明细模型的表

```
CREATE TABLE example_db.table_hash
(
  k1 TINYINT,
  k2 DECIMAL(10, 2) DEFAULT "10.5",
  k3 CHAR(10) COMMENT "string column",
  k4 INT NOT NULL DEFAULT "1" COMMENT "int column"
)
COMMENT "my first table"
DISTRIBUTED BY HASH(k1) BUCKETS 32
```

2. 创建一个明细模型的表，分区，指定排序列，设置副本数为 1

```
CREATE TABLE example_db.table_hash
(
    k1 DATE,
    k2 DECIMAL(10, 2) DEFAULT "10.5",
    k3 CHAR(10) COMMENT "string column",
    k4 INT NOT NULL DEFAULT "1" COMMENT "int column"
)
DUPLICATE KEY(k1, k2)
COMMENT "my first table"
PARTITION BY RANGE(k1)
(
    PARTITION p1 VALUES LESS THAN ("2020-02-01"),
    PARTITION p2 VALUES LESS THAN ("2020-03-01"),
    PARTITION p3 VALUES LESS THAN ("2020-04-01")
)
DISTRIBUTED BY HASH(k1) BUCKETS 32
PROPERTIES (
    "replication_num" = "1"
);
```

3. 创建一个主键唯一模型的表，设置初始存储介质和冷却时间

```
CREATE TABLE example_db.table_hash
(
    k1 BIGINT,
    k2 LARGEINT,
    v1 VARCHAR(2048),
    v2 SMALLINT DEFAULT "10"
)
UNIQUE KEY(k1, k2)
DISTRIBUTED BY HASH (k1, k2) BUCKETS 32
PROPERTIES(
    "storage_medium" = "SSD",
    "storage_cooldown_time" = "2015-06-04 00:00:00"
);
```

4. 创建一个聚合模型表，使用固定范围分区描述

```
CREATE TABLE table_range
(
    k1 DATE,
    k2 INT,
    k3 SMALLINT,
    v1 VARCHAR(2048) REPLACE,
    v2 INT SUM DEFAULT "1"
)
AGGREGATE KEY(k1, k2, k3)
PARTITION BY RANGE (k1, k2, k3)
(
    PARTITION p1 VALUES [("2014-01-01", "10", "200"), ("2014-01-01", "20", "300")],
    PARTITION p2 VALUES [("2014-06-01", "100", "200"), ("2014-07-01", "100", "300")]
)
DISTRIBUTED BY HASH(k2) BUCKETS 32
```

5. 创建一个包含 HLL 和 BITMAP 列类型的聚合模型表

```
CREATE TABLE example_db.example_table
(
    k1 TINYINT,
    k2 DECIMAL(10, 2) DEFAULT "10.5",
    v1 HLL HLL_UNION,
    v2 BITMAP BITMAP_UNION
)
ENGINE=olap
AGGREGATE KEY(k1, k2)
DISTRIBUTED BY HASH(k1) BUCKETS 32
```

6. 创建两张同一个 Colocation Group 自维护的表。

```
CREATE TABLE t1 (
    id int(11) COMMENT "",
    value varchar(8) COMMENT ""
)
DUPLICATE KEY(id)
DISTRIBUTED BY HASH(id) BUCKETS 10
PROPERTIES (
    "colocate_with" = "group1"
);

CREATE TABLE t2 (
    id int(11) COMMENT "",
    value1 varchar(8) COMMENT "",
    value2 varchar(8) COMMENT ""
)
DUPLICATE KEY(`id`)
DISTRIBUTED BY HASH(`id`) BUCKETS 10
PROPERTIES (
    "colocate_with" = "group1"
);
```

7. 创建一个带有倒排索引以及 bloom filter 索引的表

```
CREATE TABLE example_db.table_hash
(
    k1 TINYINT,
    k2 DECIMAL(10, 2) DEFAULT "10.5",
    v1 CHAR(10) REPLACE,
    v2 INT SUM,
    INDEX k1_idx (k1) USING INVERTED COMMENT 'my first index'
)
AGGREGATE KEY(k1, k2)
DISTRIBUTED BY HASH(k1) BUCKETS 32
PROPERTIES (
    "bloom_filter_columns" = "k2"
);
```

8. 创建一个动态分区表。

该表每天提前创建 3 天的分区，并删除 3 天前的分区。例如今天为2020-01-08，则会创建分区名为p20200108, p20200109, p20200110, p20200111的分区。分区范围分别为：

```
[types: [DATE]; keys: [2020-01-08]; ..types: [DATE]; keys: [2020-01-09]; )
[types: [DATE]; keys: [2020-01-09]; ..types: [DATE]; keys: [2020-01-10]; )
```

```
[types: [DATE]; keys: [2020-01-10]; ..types: [DATE]; keys: [2020-01-11]; )
[types: [DATE]; keys: [2020-01-11]; ..types: [DATE]; keys: [2020-01-12]; )
```

```
CREATE TABLE example_db.dynamic_partition
(
    k1 DATE,
    k2 INT,
    k3 SMALLINT,
    v1 VARCHAR(2048),
    v2 DATETIME DEFAULT "2014-02-04 15:36:00"
)
DUPLICATE KEY(k1, k2, k3)
PARTITION BY RANGE (k1) ( )
DISTRIBUTED BY HASH(k2) BUCKETS 32
PROPERTIES(
    "dynamic_partition.time_unit" = "DAY",
    "dynamic_partition.start" = "-3",
    "dynamic_partition.end" = "3",
    "dynamic_partition.prefix" = "p",
    "dynamic_partition.buckets" = "32"
);
```

9. 创建一个带有物化视图（ROLLUP）的表。

```
CREATE TABLE example_db.rolup_index_table
(
    event_day DATE,
    siteid INT DEFAULT '10',
    citycode SMALLINT,
    username VARCHAR(32) DEFAULT '',
    pv BIGINT SUM DEFAULT '0'
)
AGGREGATE KEY(event_day, siteid, citycode, username)
DISTRIBUTED BY HASH(siteid) BUCKETS 10
ROLLUP (
    r1(event_day,siteid),
    r2(event_day,citycode),
    r3(event_day)
)
PROPERTIES("replication_num" = "3");
```

10. 通过 replication_allocation 属性设置表的副本。

```
CREATE TABLE example_db.table_hash
(
    k1 TINYINT,
    k2 DECIMAL(10, 2) DEFAULT "10.5"
)
DISTRIBUTED BY HASH(k1) BUCKETS 32
PROPERTIES (
    "replication_allocation"="tag.location.group_a:1, tag.location.group_b:2"
);
```

```
CREATE TABLE example_db.dynamic_partition
(
    k1 DATE,
    k2 INT,
    k3 SMALLINT,
    v1 VARCHAR(2048),
```



```

v2 DATETIME DEFAULT "2014-02-04 15:36:00"
)
PARTITION BY RANGE (k1) (
DISTRIBUTED BY HASH(k2) BUCKETS 32
PROPERTIES(
    "dynamic_partition.time_unit" = "DAY",
    "dynamic_partition.start" = "-3",
    "dynamic_partition.end" = "3",
    "dynamic_partition.prefix" = "p",
    "dynamic_partition.buckets" = "32",
    "dynamic_partition.replication_allocation" = "tag.location.group_a:3"
);

```

11. 通过storage_policy属性设置表的冷热分层数据迁移策略

```

CREATE TABLE IF NOT EXISTS create_table_use_created_policy
(
    k1 BIGINT,
    k2 LARGEINT,
    v1 VARCHAR(2048)
)
UNIQUE KEY(k1)
DISTRIBUTED BY HASH (k1) BUCKETS 3
PROPERTIES(
    "storage_policy" = "test_create_table_use_policy",
    "replication_num" = "1"
);

```

注：需要先创建 s3 resource 和 storage policy，表才能关联迁移策略成功

12. 为表的分区添加冷热分层数据迁移策略

```

CREATE TABLE create_table_partion_use_created_policy
(
    k1 DATE,
    k2 INT,
    V1 VARCHAR(2048) REPLACE
) PARTITION BY RANGE (k1) (
    PARTITION p1 VALUES LESS THAN ("2022-01-01") ("storage_policy" =
"test_create_table_partition_use_policy_1" ,"replication_num"="1"),
    PARTITION p2 VALUES LESS THAN ("2022-02-01") ("storage_policy" =
"test_create_table_partition_use_policy_2" ,"replication_num"="1")
) DISTRIBUTED BY HASH(k2) BUCKETS 1;

```

注：需要先创建 s3 resource 和 storage policy，表才能关联迁移策略成功

13. 批量创建分区

```

CREATE TABLE create_table_multi_partion_date
(
    k1 DATE,
    k2 INT,
    V1 VARCHAR(20)
) PARTITION BY RANGE (k1) (
    FROM ("2000-11-14") TO ("2021-11-14") INTERVAL 1 YEAR,
    FROM ("2021-11-14") TO ("2022-11-14") INTERVAL 1 MONTH,
    FROM ("2022-11-14") TO ("2023-01-03") INTERVAL 1 WEEK,
    FROM ("2023-01-03") TO ("2023-01-14") INTERVAL 1 DAY,
    PARTITION p_20230114 VALUES [('2023-01-14'), ('2023-01-15'))
);

```

```

) DISTRIBUTED BY HASH(k2) BUCKETS 1
PROPERTIES(
    "replication_num" = "1"
);

```

```

CREATE TABLE create_table_multi_partion_date_hour
(
    k1 DATETIME,
    k2 INT,
    V1 VARCHAR(20)
) PARTITION BY RANGE (k1) (
    FROM ("2023-01-03 12") TO ("2023-01-14 22") INTERVAL 1 HOUR
) DISTRIBUTED BY HASH(k2) BUCKETS 1
PROPERTIES(
    "replication_num" = "1"
);

```

```

CREATE TABLE create_table_multi_partion_integer
(
    k1 BIGINT,
    k2 INT,
    V1 VARCHAR(20)
) PARTITION BY RANGE (k1) (
    FROM (1) TO (100) INTERVAL 10
) DISTRIBUTED BY HASH(k2) BUCKETS 1
PROPERTIES(
    "replication_num" = "1"
);

```

注：批量创建分区可以和常规手动创建分区混用，使用时需要限制分区列只能有一个，批量创建分区实际创建默认最大数量为 4096，这个参数可以在 fe 配置项 max_multi_partition_num 调整

提示

该功能自 Apache Doris 1.2 版本起支持

1. 批量无排序列 Duplicate 表

```

CREATE TABLE example_db.table_hash
(
    k1 DATE,
    k2 DECIMAL(10, 2) DEFAULT "10.5",
    k3 CHAR(10) COMMENT "string column",
    k4 INT NOT NULL DEFAULT "1" COMMENT "int column"
)
COMMENT "duplicate without keys"
PARTITION BY RANGE(k1)
(
    PARTITION p1 VALUES LESS THAN ("2020-02-01"),
    PARTITION p2 VALUES LESS THAN ("2020-03-01"),
    PARTITION p3 VALUES LESS THAN ("2020-04-01")
)
DISTRIBUTED BY HASH(k1) BUCKETS 32
PROPERTIES (
    "replication_num" = "1",

```

```
"enable_duplicate_without_keys_by_default" = "true"
);
```

Keywords

CREATE, TABLE

Best Practice

分区和分桶

一个表必须指定分桶列，但可以不指定分区。关于分区和分桶的具体介绍，可参阅 [数据划分](#) 文档。

Doris 中的表可以分为分区表和无分区的表。这个属性在建表时确定，之后不可更改。即对于分区表，可以在之后的使用过程中对分区进行增删操作，而对于无分区的表，之后不能再进行增加分区等操作。

同时，分区列和分桶列在表创建之后不可更改，既不能更改分区和分桶列的类型，也不能对这些列进行任何增删操作。

所以建议在建表前，先确认使用方式来进行合理的建表。

动态分区

动态分区功能主要用于帮助用户自动的管理分区。通过设定一定的规则，Doris 系统定期增加新的分区或删除历史分区。可参阅 [动态分区](#) 文档查看更多帮助。

物化视图

用户可以在建表的同时创建多个物化视图（ROLLUP）。物化视图也可以在建表之后添加。写在建表语句中可以方便用户一次性创建所有物化视图。

如果在建表时创建好物化视图，则后续的所有数据导入操作都会同步生成物化视图的数据。物化视图的数量可能会影响数据导入的效率。

如果在之后的使用过程中添加物化视图，如果表中已有数据，则物化视图的创建时间取决于当前数据量大小。

关于物化视图的介绍，请参阅文档 [物化视图](#)。

索引

用户可以在建表的同时创建多个列的索引。索引也可以在建表之后再添加。

如果在之后的使用过程中添加索引，如果表中已有数据，则需要重写所有数据，因此索引的创建时间取决于当前数据量。

CREATE-TABLE-LIKE

CREATE-TABLE-LIKE

Name

CREATE TABLE LIKE

描述

该语句用于创建一个表结构和另一张表完全相同的空表，同时也能够可选复制一些rollup。

语法：

```
CREATE [EXTERNAL] TABLE [IF NOT EXISTS] [database.]table_name LIKE [database.]table_name [WITH ROLLUP (r1,r2,r3,...)]
```

说明：

- 复制的表结构包括Column Definition、Partitions、Table Properties等
- 用户需要对复制的原表有SELECT权限
- 支持复制MySQL等外表
- 支持复制OLAP Table的rollup

举例

1. 在test1库下创建一张表结构和table1相同的空表，表名为table2

```
CREATE TABLE test1.table2 LIKE test1.table1
```

2. 在test2库下创建一张表结构和test1.table1相同的空表，表名为table2

```
CREATE TABLE test2.table2 LIKE test1.table1
```

3. 在test1库下创建一张表结构和table1相同的空表，表名为table2，同时复制table1的r1，r2两个rollup

```
CREATE TABLE test1.table2 LIKE test1.table1 WITH ROLLUP (r1,r2)
```

4. 在test1库下创建一张表结构和table1相同的空表，表名为table2，同时复制table1的所有rollup

```
CREATE TABLE test1.table2 LIKE test1.table1 WITH ROLLUP
```

5. 在test2库下创建一张表结构和test1.table1相同的空表，表名为table2，同时复制table1的r1，r2两个rollup

```
CREATE TABLE test2.table2 LIKE test1.table1 WITH ROLLUP (r1,r2)
```

6. 在test2库下创建一张表结构和test1.table1相同的空表，表名为table2，同时复制table1的所有rollup

```
CREATE TABLE test2.table2 LIKE test1.table1 WITH ROLLUP
```

7. 在test1库下创建一张表结构和MySQL外表table1相同的空表，表名为table2

```
CREATE TABLE test1.table2 LIKE test1.table1
```

Keywords

CREATE, TABLE, LIKE

Best Practice

CREATE-TABLE-AS-SELECT

CREATE-TABLE-AS-SELECT

Name

CREATE TABLE AS SELECT

描述

该语句通过 Select 语句返回结果创建表结构，同时导入数据

语法：

```
CREATE TABLE table_name [( column_name_list )]  
    opt_engine:engineName  
    opt_keys:keys  
    opt_comment:tableComment  
    opt_partition:partition  
    opt_distribution:distribution  
    opt_rollup:index  
    opt_properties:tblProperties  
    opt_ext_properties:extProperties  
    KW_AS query_stmt:query_def
```

说明：

- 用户需要拥有来源表的SELECT权限和目标库的CREATE权限
- 创建表成功后，会进行数据导入，如果导入失败，将会删除表
- 可以自行指定 key type，默认为Duplicate Key

提示

该功能自 Apache Doris 1.2 版本起支持

- 所有字符串类型的列 (varchar/var/string) 都会被创建为 string 类型。
- 如果创建的来源为外部表，并且第一列为 String 类型，则会自动将第一列设置为 VARCHAR(65533)。因为 Doris 内部表，不允许 String 列作为第一列。

举例

1. 使用 select 语句中的字段名

```
create table `test`.`select_varchar`  
    PROPERTIES("replication_num" = "1")  
as select * from `test`.`varchar_table`
```

2. 自定义字段名 (需要与返回结果字段数量一致) sql `create table `test`.`select_name` (user, testname, userstatus) PROPERTIES("replication_num" = "1") as select vt.userId, vt.username, jt.status from `test`.`varchar_table` vt join `test`.`join_table` jt on vt.userId=jt.userId`
3. 指定表模型、分区、分桶 sql `CREATE TABLE t_user(dt, id, name) ENGINE=OLAP UNIQUE KEY(dt, id) COMMENT "OLAP" PARTITION BY RANGE(dt) ( FROM ("2020-01-01") TO ("2021-12-31") INTERVAL 1 YEAR ) DISTRIBUTED BY HASH(id) BUCKETS 1 PROPERTIES("replication_num"="1") AS SELECT cast('2020-05-20' as date) as dt, 1 as id, 'Tom' as name;`

Keywords

CREATE, TABLE, AS, SELECT

Best Practice

CREATE-EXTERNAL-TABLE

CREATE-EXTERNAL-TABLE

Name

CREATE EXTERNAL TABLE

描述

此语句用来创建外部表，具体语法参阅 [CREATE TABLE](#)。

主要通过 ENGINE 类型来标识是哪种类型的外部表，目前可选 MYSQL、BROKER、HIVE、ICEBERG、HUDI

1. 如果是 mysql，则需要在 properties 提供以下信息：

```
PROPERTIES (  
  "host" = "mysql_server_host",  
  "port" = "mysql_server_port",  
  "user" = "your_user_name",  
  "password" = "your_password",  
  "database" = "database_name",  
  "table" = "table_name"  
)
```

以及一个可选属性“charset”，可以用来设置 mysql 连接的字符集，默认值是“utf8”。如有需要，你可以设置为另外一个字符集“utf8mb4”。

注意：

- “table”条目中的“table_name”是 mysql 中的真实表名。而 CREATE TABLE 语句中的 table_name 是该 mysql 表在 Doris 中的名字，可以不同。
- 在 Doris 创建 mysql 表的目的是可以通过 Doris 访问 mysql 数据库。而 Doris 本身并不维护、存储任何 mysql 数据。

2. 如果是 broker，表示表的访问需要通过指定的 broker，需要在 properties 提供以下信息：

```
PROPERTIES (  
  "broker_name" = "broker_name",  
  "path" = "file_path1[,file_path2]",  
  "column_separator" = "value_separator"  
  "line_delimiter" = "value_delimiter"  
)
```

另外还需要提供 Broker 需要的 Property 信息，通过 BROKER PROPERTIES 来传递，例如 HDFS 需要传入

```
BROKER PROPERTIES(  
  "username" = "name",
```



```
"password" = "password"
)
```

这个根据不同的 Broker 类型，需要传入的内容也不相同

注意：

- “path” 中如果有多个文件，用逗号[,]分割。如果文件名中包含逗号，那么使用 %2c 来替代。如果文件名中包含 %，使用 %25 代替
- 现在文件内容格式支持 CSV，支持 GZ，BZ2，LZ4，LZO(LZOP) 压缩格式。

3. 如果是 hive，则需要在 properties 提供以下信息：

```
PROPERTIES (
  "database" = "hive_db_name",
  "table" = "hive_table_name",
  "hive.metastore.uris" = "thrift://127.0.0.1:9083"
)
```

其中 database 是 hive 表对应的库名字，table 是 hive 表的名字，hive.metastore.uris 是 hive metastore 服务地址。

4. 如果是 iceberg，则需要在 properties 中提供以下信息：

```
PROPERTIES (
  "iceberg.database" = "iceberg_db_name",
  "iceberg.table" = "iceberg_table_name",
  "iceberg.hive.metastore.uris" = "thrift://127.0.0.1:9083",
  "iceberg.catalog.type" = "HIVE_CATALOG"
)
```

其中 database 是 Iceberg 对应的库名； table 是 Iceberg 中对应的表名； hive.metastore.uris 是 hive metastore 服务地址； catalog.type 默认为 HIVE_CATALOG。当前仅支持 HIVE_CATALOG，后续会支持更多 Iceberg catalog 类型。

5. 如果是 hudi，则需要在 properties 中提供以下信息：

```
PROPERTIES (
  "hudi.database" = "hudi_db_in_hive_metastore",
  "hudi.table" = "hudi_table_in_hive_metastore",
  "hudi.hive.metastore.uris" = "thrift://127.0.0.1:9083"
)
```

其中 hudi.database 是 hive 表对应的库名字，hudi.table 是 hive 表的名字，hive.metastore.uris 是 hive metastore 服务地址。

举例

1. 创建 MYSQL 外部表

直接通过外表信息创建 mysql 表

```

CREATE EXTERNAL TABLE example_db.table_mysql
(
  k1 DATE,
  k2 INT,
  k3 SMALLINT,
  k4 VARCHAR(2048),
  k5 DATETIME
)
ENGINE=mysql
PROPERTIES
(
  "host" = "127.0.0.1",
  "port" = "8239",
  "user" = "mysql_user",
  "password" = "mysql_passwd",
  "database" = "mysql_db_test",
  "table" = "mysql_table_test",
  "charset" = "utf8mb4"
)

```

通过 External Catalog Resource 创建 mysql 表

```

# 先创建 Resource
CREATE EXTERNAL RESOURCE "mysql_resource"
PROPERTIES
(
  "type" = "odbc_catalog",
  "user" = "mysql_user",
  "password" = "mysql_passwd",
  "host" = "127.0.0.1",
  "port" = "8239"
);

# 再通过 Resource 创建 mysql 外部表
CREATE EXTERNAL TABLE example_db.table_mysql
(
  k1 DATE,
  k2 INT,
  k3 SMALLINT,
  k4 VARCHAR(2048),
  k5 DATETIME
)
ENGINE=mysql
PROPERTIES
(
  "odbc_catalog_resource" = "mysql_resource",
  "database" = "mysql_db_test",
  "table" = "mysql_table_test"
)

```

2. 创建一个数据文件存储在 HDFS 上的 broker 外部表，数据使用 “|” 分割，\n 换行

```

CREATE EXTERNAL TABLE example_db.table_broker (
  k1 DATE,
  k2 INT,
  k3 SMALLINT,
  k4 VARCHAR(2048),
  k5 DATETIME
)
ENGINE=broker
PROPERTIES (

```

```

    "broker_name" = "hdfs",
    "path" =
    "hdfs://hdfs_host:hdfs_port/data1,hdfs://hdfs_host:hdfs_port/data2,hdfs://hdfs_host:hdfs_port/data3%2c
    4",
    "column_separator" = "|",
    "line_delimiter" = "\n"
  )
  BROKER PROPERTIES (
    "username" = "hdfs_user",
    "password" = "hdfs_password"
  )

```

3. 创建一个 hive 外部表

```

CREATE TABLE example_db.table_hive
(
  k1 TINYINT,
  k2 VARCHAR(50),
  v INT
)
ENGINE=hive
PROPERTIES
(
  "database" = "hive_db_name",
  "table" = "hive_table_name",
  "hive.metastore.uris" = "thrift://127.0.0.1:9083"
);

```

4. 创建一个 Iceberg 外表

```

CREATE TABLE example_db.t_iceberg
ENGINE=ICEBERG
PROPERTIES (
  "iceberg.database" = "iceberg_db",
  "iceberg.table" = "iceberg_table",
  "iceberg.hive.metastore.uris" = "thrift://127.0.0.1:9083",
  "iceberg.catalog.type" = "HIVE_CATALOG"
);

```

5. 创建一个 Hudi 外表

创建时不指定 schema(推荐)

```

CREATE TABLE example_db.t_hudi
ENGINE=HUDI
PROPERTIES (
  "hudi.database" = "hudi_db_in_hive_metastore",
  "hudi.table" = "hudi_table_in_hive_metastore",
  "hudi.hive.metastore.uris" = "thrift://127.0.0.1:9083"
);

```

创建时指定 schema

```

CREATE TABLE example_db.t_hudi (
  `id` int NOT NULL COMMENT "id number",
  `name` varchar(10) NOT NULL COMMENT "user name"
)
ENGINE=HUDI

```

```
PROPERTIES (  
  "hudi.database" = "hudi_db_in_hive_metastore",  
  "hudi.table" = "hudi_table_in_hive_metastore",  
  "hudi.hive.metastore.uris" = "thrift://127.0.0.1:9083"  
);
```

Keywords

CREATE, EXTERNAL, TABLE

Best Practice

CREATE-INDEX

CREATE-INDEX

Name

CREATE INDEX

描述

该语句用于创建索引 语法：

```
CREATE INDEX [IF NOT EXISTS] index_name ON table_name (column [, ...],) [USING INVERTED] [COMMENT 'balabala'];
```

注意： - 倒排索引仅在单列上创建

举例

1. 在table1 上为siteid 创建倒排索引

```
CREATE INDEX [IF NOT EXISTS] index_name ON table1 (siteid) USING INVERTED COMMENT 'balabala';
```

Keywords

CREATE, INDEX

Best Practice

CREATE-VIEW

CREATE-VIEW

Name

CREATE VIEW

描述

该语句用于创建一个逻辑视图 语法：

```
CREATE VIEW [IF NOT EXISTS]
  [db_name.]view_name
  (column1[ COMMENT "col comment"][, column2, ...])
AS query_stmt
```

说明：

- 视图为逻辑视图，没有物理存储。所有在视图上的查询相当于在视图对应的子查询上进行。
- query_stmt 为任意支持的 SQL

举例

1. 在 example_db 上创建视图 example_view

```
CREATE VIEW example_db.example_view (k1, k2, k3, v1)
AS
SELECT c1 as k1, k2, k3, SUM(v1) FROM example_table
WHERE k1 = 20160112 GROUP BY k1,k2,k3;
```

2. 创建一个包含 comment 的 view

```
CREATE VIEW example_db.example_view
(
  k1 COMMENT "first key",
  k2 COMMENT "second key",
  k3 COMMENT "third key",
  v1 COMMENT "first value"
)
COMMENT "my first view"
AS
SELECT c1 as k1, k2, k3, SUM(v1) FROM example_table
WHERE k1 = 20160112 GROUP BY k1,k2,k3;
```

Keywords

CREATE, VIEW

Best Practice

CREATE-MATERIALIZED-VIEW

CREATE-MATERIALIZED-VIEW

Name

CREATE MATERIALIZED VIEW

描述

该语句用于创建物化视图。

该操作为异步操作，提交成功后，需通过 [SHOW ALTER TABLE MATERIALIZED VIEW](#) 查看作业进度。在显示 FINISHED 后既可通过 desc [table_name] all 命令来查看物化视图的 schema 了。

语法：

```
CREATE MATERIALIZED VIEW < MV name > as < query >
[PROPERTIES ("key" = "value")]
```

说明：

- MV name：物化视图的名称，必填项。相同表的物化视图名称不可重复。
- query：用于构建物化视图的查询语句，查询语句的结果既物化视图的数据。目前支持的 query 格式为：

```
SELECT select_expr[, select_expr ...]
FROM [Base view name]
GROUP BY column_name[, column_name ...]
ORDER BY column_name[, column_name ...]
```

语法和查询语句语法一致。

- select_expr：物化视图的 schema 中所有的列。
 - 至少包含一个单列。
 - base view name：物化视图的原始表名，必填项。
 - 必须是单表，且非子查询
 - group by：物化视图的分组列，选填项。
 - 不填则数据不进行分组。
 - order by：物化视图的排序列，选填项。
 - 排序列的声明顺序必须和 select_expr 中列声明顺序一致。
 - 如果不声明 order by，则根据规则自动补充排序列。如果物化视图是聚合类型，则所有的分组列自动补充为排序列。如果物化视图是非聚合类型，则前 36 个字节自动补充为排序列。
 - 如果自动补充的排序个数小于3个，则前三个作为排序列。如果 query 中包含分组列的话，则排序列必须和分组列一致。
- properties

声明物化视图的一些配置，选填项。

```
PROPERTIES ("key" = "value", "key" = "value" ...)
```

以下几个配置，均可声明在此处：

```
short_key: 排序列的个数。  
timeout: 物化视图构建的超时时间。
```

举例

Base 表结构为

```
mysql> desc duplicate_table;  
+-----+-----+-----+-----+-----+-----+  
| Field | Type  | Null | Key  | Default | Extra |  
+-----+-----+-----+-----+-----+-----+  
k1	INT	Yes	true	N/A	
k2	INT	Yes	true	N/A	
k3	BIGINT	Yes	true	N/A	
k4	BIGINT	Yes	true	N/A	
+-----+-----+-----+-----+-----+-----+
```

```
create table duplicate_table(  
    k1 int null,  
    k2 int null,  
    k3 bigint null,  
    k4 bigint null  
)  
duplicate key (k1,k2,k3,k4)  
distributed BY hash(k4) buckets 3  
properties("replication_num" = "1");
```

注意：如果物化视图包含了base表的分区列和分桶列,那么这些列必须作为物化视图中的key列

1. 创建一个仅包含原始表 （k1, k2） 列的物化视图

```
create materialized view k1_k2 as  
select k2, k1 from duplicate_table;
```

物化视图的 schema 如下图，物化视图仅包含两列 k1, k2 且不带任何聚合

```
+-----+-----+-----+-----+-----+-----+  
| IndexName | Field | Type | Null | Key | Default | Extra |  
+-----+-----+-----+-----+-----+-----+  
| k2_k1     | k2    | INT  | Yes  | true | N/A     |      |  
|           | k1    | INT  | Yes  | true | N/A     |      |  
+-----+-----+-----+-----+-----+-----+
```

2. 创建一个以 k2 为排序列的物化视图

```
create materialized view k2_order as
```

```
select k2, k1 from duplicate_table order by k2;
```

物化视图的 schema 如下图，物化视图仅包含两列 k2, k1，其中 k2 列为排序列，不带任何聚合。

| IndexName | Field | Type | Null | Key | Default | Extra |
|-----------|-------|------|------|-------|---------|-------|
| k2_order | k2 | INT | Yes | true | N/A | |
| | k1 | INT | Yes | false | N/A | NONE |

3. 创建一个以 k1, k2 分组，k3 列为 SUM 聚合的物化视图

```
create materialized view k1_k2_sumk3 as
select k1, k2, sum(k3) from duplicate_table group by k1, k2;
```

物化视图的 schema 如下图，物化视图包含两列 k1, k2, sum(k3) 其中 k1, k2 为分组列，sum(k3) 为根据 k1, k2 分组后的 k3 列的求和值。

由于物化视图没有声明排序列，且物化视图带聚合数据，系统默认补充分组列 k1, k2 为排序列。

| IndexName | Field | Type | Null | Key | Default | Extra |
|-------------|-------|--------|------|-------|---------|-------|
| k1_k2_sumk3 | k1 | INT | Yes | true | N/A | |
| | k2 | INT | Yes | true | N/A | |
| | k3 | BIGINT | Yes | false | N/A | SUM |

4. 创建一个去除重复行的物化视图

```
create materialized view deduplicate as
select k1, k2, k3, k4 from duplicate_table group by k1, k2, k3, k4;
```

物化视图 schema 如下图，物化视图包含 k1, k2, k3, k4列，且不存在重复行。

| IndexName | Field | Type | Null | Key | Default | Extra |
|-------------|-------|--------|------|------|---------|-------|
| deduplicate | k1 | INT | Yes | true | N/A | |
| | k2 | INT | Yes | true | N/A | |
| | k3 | BIGINT | Yes | true | N/A | |
| | k4 | BIGINT | Yes | true | N/A | |

5. 创建一个不声明排序列的非聚合型物化视图

all_type_table 的 schema 如下

| Field | Type | Null | Key | Default | Extra |
|-------|----------|------|------|---------|-------|
| k1 | TINYINT | Yes | true | N/A | |
| k2 | SMALLINT | Yes | true | N/A | |

| | | | | | | |
|---------------------------------------|--------------|-----|-------|-----|------|--|
| k3 | INT | Yes | true | N/A | | |
| k4 | BIGINT | Yes | true | N/A | | |
| k5 | DECIMAL(9,0) | Yes | true | N/A | | |
| k6 | DOUBLE | Yes | false | N/A | NONE | |
| k7 | VARCHAR(20) | Yes | false | N/A | NONE | |
| +-----+-----+-----+-----+-----+-----+ | | | | | | |

物化视图包含 k3, k4, k5, k6, k7 列，且不声明排序列，则创建语句如下：

```
create materialized view mv_1 as
select k3, k4, k5, k6, k7 from all_type_table;
```

系统默认补充的排序列为 k3, k4, k5 三列。这三列类型的字节数之和为 4(INT) + 8(BIGINT) + 16(DECIMAL) = 28 < 36。所以补充的是这三列作为排序列。物化视图的 schema 如下，可以看到其中 k3, k4, k5 列的 key 字段为 true，也就是排序列。k6, k7 列的 key 字段为 false，也就是非排序列。

| | | | | | | | | | | | | | | |
|---------------------------------------|-----------|--|-------|--|--------------|--|------|--|-------|--|---------|--|-------|--|
| | IndexName | | Field | | Type | | Null | | Key | | Default | | Extra | |
| | mv_1 | | k3 | | INT | | Yes | | true | | N/A | | | |
| | | | k4 | | BIGINT | | Yes | | true | | N/A | | | |
| | | | k5 | | DECIMAL(9,0) | | Yes | | true | | N/A | | | |
| | | | k6 | | DOUBLE | | Yes | | false | | N/A | | NONE | |
| | | | k7 | | VARCHAR(20) | | Yes | | false | | N/A | | NONE | |
| +-----+-----+-----+-----+-----+-----+ | | | | | | | | | | | | | | |

Keywords

```
CREATE, MATERIALIZED, VIEW
```

Best Practice

CREATE-FUNCTION

CREATE-FUNCTION

Name

CREATE FUNCTION

描述

此语句创建一个自定义函数。执行此命令需要用户拥有 ADMIN 权限。

如果 function_name 中包含了数据库名字，那么这个自定义函数会创建在对应的数据库中，否则这个函数将会创建在当前会话所在的数据库。新函数的名字与参数不能够与当前命名空间中已存在的函数相同，否则会创建失败。但是只有名字相同，参数不同是能够创建成功的。

语法：

```
CREATE [GLOBAL] [AGGREGATE] [ALIAS] FUNCTION function_name
    (arg_type [, ...])
    [RETURNS ret_type]
    [INTERMEDIATE inter_type]
    [WITH PARAMETER(param [,...]) AS origin_function]
    [PROPERTIES ("key" = "value" [, ...]) ]
```

参数说明：

- GLOBAL: 如果有此项，表示的是创建的函数是全局范围内生效。
- AGGREGATE: 如果有此项，表示的是创建的函数是一个聚合函数。
- ALIAS: 如果有此项，表示的是创建的函数是一个别名函数。

如果没有上述两项，表示创建的函数是一个标量函数

- function_name: 要创建函数的名字，可以包含数据库的名字。比如：db1.my_func。
- arg_type: 函数的参数类型，与建表时定义的类型一致。变长参数时可以使用，...来表示，如果是变长类型，那么变长部分参数的类型与最后一个非变长参数类型一致。

注意：ALIAS FUNCTION 不支持变长参数，且至少有一个参数。

- ret_type: 对创建新的函数来说，是必填项。如果是给已有函数取别名则可不用填写该参数。
- inter_type: 用于表示聚合函数中间阶段的数据类型。
- param: 用于表示别名函数的参数，至少包含一个。
- origin_function: 用于表示别名函数对应的原始函数。

- **properties:** 用于设定函数相关属性，能够设置的属性包括：
 - **file:** 表示的包含用户UDF的jar包，实现的 jar 包可以放在本地也可以存放在远程服务端通过 HTTP 下载，但必须让每个 FE 和 BE 节点都能获取到 jar 包。这个参数是必须设定的。
 - **symbol:** 表示的是包含UDF类的类名。这个参数是必须设定的
 - **type:** 表示的 UDF 调用类型，默认为 Native，使用 Java UDF时传 JAVA_UDF。
 - **always_nullable:** 表示的 UDF 返回结果中是否有可能出现NULL值，是可选参数，默认值为 true。

举例

1. 创建一个自定义UDF函数

```
CREATE FUNCTION java_udf_add_one(int) RETURNS int PROPERTIES (  
  "file"="file:///path/to/java-udf-demo-jar-with-dependencies.jar",  
  "symbol"="org.apache.doris.udf.AddOne",  
  "always_nullable"="true",  
  "type"="JAVA_UDF"  
);
```

2. 创建一个自定义UDAF函数

```
CREATE AGGREGATE FUNCTION simple_sum(INT) RETURNS INT PROPERTIES (  
  "file"="file:///pathTo/java-udaf.jar",  
  "symbol"="org.apache.doris.udf.demo.SimpleDemo",  
  "always_nullable"="true",  
  "type"="JAVA_UDF"  
);
```

3. 创建一个自定义别名函数

```
CREATE ALIAS FUNCTION id_masking(INT) WITH PARAMETER(id) AS CONCAT(LEFT(id, 3), '****', RIGHT(id, 4));
```

4. 创建一个全局自定义别名函数

```
CREATE GLOBAL ALIAS FUNCTION id_masking(INT) WITH PARAMETER(id) AS CONCAT(LEFT(id, 3), '****', RIGHT(id, 4));
```

Keywords

```
CREATE, FUNCTION
```

Best Practice

CREATE-FILE

CREATE-FILE

Name

CREATE FILE

描述

该语句用于创建并上传一个文件到 Doris 集群。该功能通常用于管理一些其他命令中需要使用到的文件，如证书、公钥私钥等等。

该命令只用 admin 权限用户可以执行。某个文件都归属与某一个的 database。对 database 拥有访问权限的用户都可以使用该文件。

单个文件大小限制为 1MB。一个 Doris 集群最多上传 100 个文件。

语法：

```
CREATE FILE "file_name" [IN database]
PROPERTIES("key"="value", ...)
```

说明：

- file_name: 自定义文件名。
- database: 文件归属于某一个 db，如果没有指定，则使用当前 session 的 db。
- properties 支持以下参数：
 - url: 必须。指定一个文件的下载路径。当前仅支持无认证的 http 下载路径。命令执行成功后，文件将被保存在 doris 中，该 url 将不再需要。
 - catalog: 必须。对文件的分类名，可以自定义。但在某些命令中，会查找指定 catalog 中的文件。比如例行导入中的，数据源为 kafka 时，会查找 catalog 名为 kafka 下的文件。
 - md5: 可选。文件的 md5。如果指定，会在下载文件后进行校验。

举例

1. 创建文件 ca.pem，分类为 kafka

```
CREATE FILE "ca.pem"
PROPERTIES
(
    "url" = "https://test.bj.bcebos.com/kafka-key/ca.pem",
    "catalog" = "kafka"
);
```

2. 创建文件 client.key，分类为 my_catalog

```
CREATE FILE "client.key"  
IN my_database  
PROPERTIES  
(  
    "url" = "https://test.bj.bcebos.com/kafka-key/client.key",  
    "catalog" = "my_catalog",  
    "md5" = "b5bb901bf10f99205b39a46ac3557dd9"  
);
```

Keywords

CREATE, FILE

Best Practice

1. 该命令只有 amdin 权限用户可以执行。某个文件都归属与某一个的 database。对 database 拥有访问权限的用户都可以使用该文件。
2. 文件大小和数量限制。

这个功能主要用于管理一些证书等小文件。因此单个文件大小限制为 1MB。一个 Doris 集群最多上传 100 个文件。

CREATE-POLICY

CREATE-POLICY

Name

提示

该功能自 Apache Doris 1.2 版本起支持

CREATE POLICY

描述

创建策略，包含以下几种：

1. 创建安全策略 (ROW POLICY)，explain 可以查看改写后的 SQL。
2. 创建数据迁移策略 (STORAGE POLICY)，用于冷热数据转换。

语法：

1. ROW POLICY

```
CREATE ROW POLICY test_row_policy_1 ON test.table1
AS {RESTRICTIVE|PERMISSIVE} TO test USING (id in (1, 2));
```

参数说明：

- filterType：RESTRICTIVE 将一组策略通过 AND 连接，PERMISSIVE 将一组策略通过 OR 连接
- 配置多个策略首先合并 RESTRICTIVE 的策略，再添加 PERMISSIVE 的策略
- RESTRICTIVE 和 PERMISSIVE 之间通过 AND 连接的
- 不允许对 root 和 admin 用户创建

2. STORAGE POLICY

```
CREATE STORAGE POLICY test_storage_policy_1
PROPERTIES ("key"="value", ...);
```

参数说明：- PROPERTIES 中需要指定资源的类型：1. storage_resource：指定策略使用的 storage resource 名称。2. cooldown_datetime：热数据转为冷数据时间，不能与 cooldown_ttl 同时存在。3. cooldown_ttl：热数据持续时间。从数据分片生成时开始计算，经过指定时间后转为冷数据。支持的格式：1d：1 天 1h：1 小时 50000：50000 秒

举例

1. 创建一组行安全策略

```
CREATE ROW POLICY test_row_policy_1 ON test.table1
AS RESTRICTIVE TO test USING (c1 = 'a');
```

```
CREATE ROW POLICY test_row_policy_2 ON test.table1
AS RESTRICTIVE TO test USING (c2 = 'b');
```

```
CREATE ROW POLICY test_row_policy_3 ON test.table1
AS PERMISSIVE TO test USING (c3 = 'c');
```

```
CREATE ROW POLICY test_row_policy_3 ON test.table1
AS PERMISSIVE TO test USING (c4 = 'd');
```

当我们执行对 `table1` 的查询时被改写后的 sql 为

```
select * from (select * from table1 where c1 = 'a' and c2 = 'b' or c3 = 'c' or c4 = 'd')
```

2. 创建数据迁移策略

1. 说明

- 冷热分层创建策略，必须先创建 `resource`，然后创建迁移策略时候关联创建的 `resource` 名
- 当前不支持删除 `drop` 数据迁移策略，防止数据被迁移后。策略被删除了，系统无法找回数据

2. 指定数据冷却时间创建数据迁移策略

```
CREATE STORAGE POLICY testPolicy
PROPERTIES(
  "storage_resource" = "s3",
  "cooldown_datetime" = "2022-06-08 00:00:00"
);
```

3. 指定热数据持续时间创建数据迁移策略 sql `CREATE STORAGE POLICY testPolicy PROPERTIES("storage_resource" = "s3", "cooldown_ttl" = "1d" );` 相关参数如下：

- `storage_resource`：创建的storage resource名称
- `cooldown_datetime`：迁移数据的时间点
- `cooldown_ttl`：迁移数据距离当前时间的倒计时，单位s。与`cooldown_datetime`二选一即可

Keywords

CREATE, POLICY

Best Practice

CREATE-ENCRYPT-KEY

CREATE-ENCRYPTKEY

Name

CREATE ENCRYPTKEY

描述

此语句创建一个自定义密钥。执行此命令需要用户拥有 ADMIN 权限。

语法：

```
CREATE ENCRYPTKEY key_name AS "key_string"
```

说明：

key_name: 要创建密钥的名字, 可以包含数据库的名字。比如: db1.my_key。

key_string: 要创建密钥的字符串。

如果 key_name 中包含了数据库名字, 那么这个自定义密钥会创建在对应的数据库中, 否则这个函数将会创建在当前会话所在的数据库。新密钥的名字不能够与对应数据库中已存在的密钥相同, 否则会创建失败。

举例

1. 创建一个自定义密钥

```
CREATE ENCRYPTKEY my_key AS "ABCD123456789";
```

2. 使用自定义密钥

使用自定义密钥需在密钥前添加关键字 KEY/key, 与 key_name 空格隔开。

```
mysql> SELECT HEX(AES_ENCRYPT("Doris is Great", KEY my_key));
+-----+
| hex(aes_encrypt('Doris is Great', key my_key)) |
+-----+
| D26DB38579D6A343350EDDC6F2AD47C6              |
+-----+
1 row in set (0.02 sec)

mysql> SELECT AES_DECRYPT(UNHEX('D26DB38579D6A343350EDDC6F2AD47C6'), KEY my_key);
+-----+
| aes_decrypt(unhex('D26DB38579D6A343350EDDC6F2AD47C6'), key my_key) |
+-----+
| Doris is Great                                                         |
+-----+
```

+-----+
1 row in set (0.01 sec)

Keywords

CREATE, ENCRYPTKEY

Best Practice

CREATE-RESOURCE

CREATE-RESOURCE

Name

CREATE RESOURCE

描述

该语句用于创建资源。仅 root 或 admin 用户可以创建资源。目前支持 Spark, ODBC, S3, JDBC, HDFS, HMS, ES 外部资源。将来其他外部资源可能会加入到 Doris 中使用, 如 Spark/GPU 用于查询, HDFS/S3 用于外部存储, MapReduce 用于 ETL 等。

语法:

```
CREATE [EXTERNAL] RESOURCE "resource_name"  
PROPERTIES ("key"="value", ...);
```

说明:

- PROPERTIES 中需要指定资源的类型 “type” = “[spark|odbc_catalog|s3|jdbc|hdfs|hms|es]”。
- 根据资源类型的不同 PROPERTIES 有所不同, 具体见示例。

举例

1. 创建 yarn cluster 模式, 名为 spark0 的 Spark 资源。

```
CREATE EXTERNAL RESOURCE "spark0"  
PROPERTIES  
(  
  "type" = "spark",  
  "spark.master" = "yarn",  
  "spark.submit.deployMode" = "cluster",  
  "spark.jars" = "xxx.jar,yyy.jar",  
  "spark.files" = "/tmp/aaa,/tmp/bbb",  
  "spark.executor.memory" = "1g",  
  "spark.yarn.queue" = "queue0",  
  "spark.hadoop.yarn.resourcemanager.address" = "127.0.0.1:9999",  
  "spark.hadoop.fs.defaultFS" = "hdfs://127.0.0.1:10000",  
  "working_dir" = "hdfs://127.0.0.1:10000/tmp/doris",  
  "broker" = "broker0",  
  "broker.username" = "user0",  
  "broker.password" = "password0"  
);
```

Spark 相关参数如下:

- spark.master: 必填, 目前支持 yarn, spark://host:port。
- spark.submit.deployMode: Spark 程序的部署模式, 必填, 支持 cluster, client 两种。

- spark.hadoop.yarn.resourcemanager.address: master 为 yarn 时必须填。
- spark.hadoop.fs.defaultFS: master 为 yarn 时必须填。
- 其他参数为可选, 参考[这里](#)

Spark 用于 ETL 时需要指定 working_dir 和 broker。说明如下:

- working_dir: ETL 使用的目录。spark 作为 ETL 资源使用时必填。例如: hdfs://host:port/tmp/doris。
- broker: broker 名字。spark 作为 ETL 资源使用时必填。需要使用 ALTER SYSTEM ADD BROKER 命令提前完成配置。
- broker.property_key: broker 读取 ETL 生成的中间文件时需要指定的认证信息等。

2. 创建 ODBC resource

```
CREATE EXTERNAL RESOURCE `oracle_odbc`
PROPERTIES (
  "type" = "odbc_catalog",
  "host" = "192.168.0.1",
  "port" = "8086",
  "user" = "test",
  "password" = "test",
  "database" = "test",
  "odbc_type" = "oracle",
  "driver" = "Oracle 19 ODBC driver"
);
```

ODBC 的相关参数如下:

- hosts: 外表数据库的 IP 地址
- driver: ODBC 外表的 Driver 名, 该名字需要和 be/conf/odbcinst.ini 中的 Driver 名一致。
- odbc_type: 外表数据库的类型, 当前支持 oracle, mysql, postgresql
- user: 外表数据库的用户名
- password: 对应用户的密码信息
- charset: 数据库链接的编码信息
- 另外还支持每个 ODBC Driver 实现自定义的参数, 参见对应 ODBC Driver 的说明

3. 创建 S3 resource

```
CREATE RESOURCE "remote_s3"
PROPERTIES
(
  "type" = "s3",
  "s3.endpoint" = "bj.s3.com",
  "s3.region" = "bj",
  "s3.access_key" = "bbb",
  "s3.secret_key" = "aaaa",
  -- the followings are optional
  "s3.connection.maximum" = "50",
  "s3.connection.request.timeout" = "3000",
  "s3.connection.timeout" = "1000"
);
```

如果 s3 resource 在[冷热分层](#)中使用, 需要添加额外的字段。

```
CREATE RESOURCE "remote_s3"
PROPERTIES
```

```
(
  "type" = "s3",
  "s3.endpoint" = "bj.s3.com",
  "s3.region" = "bj",
  "s3.access_key" = "bbb",
  "s3.secret_key" = "aaaa",
  -- required by cooldown
  "s3.root.path" = "/path/to/root",
  "s3.bucket" = "test-bucket"
);
```

S3 相关参数如下:

- 必需参数
 - s3.endpoint: s3 endpoint
 - s3.region: s3 region
 - s3.root.path: s3 根目录
 - s3.access_key: s3 access key
 - s3.secret_key: s3 secret key
 - s3.bucket: s3 的桶名
- 可选参数
 - s3.connection.maximum: s3 最大连接数量, 默认为 50
 - s3.connection.request.timeout: s3 请求超时时间, 单位毫秒, 默认为 3000
 - s3.connection.timeout: s3 连接超时时间, 单位毫秒, 默认为 1000

4. 创建 JDBC resource

```
CREATE RESOURCE mysql_resource PROPERTIES (
  "type"="jdbc",
  "user"="root",
  "password"="123456",
  "jdbc_url" = "jdbc:mysql://127.0.0.1:3316/doris_test?useSSL=false",
  "driver_url" = "https://doris-community-test-1308700295.cos.ap-
hongkong.myqcloud.com/jdbc_driver/mysql-connector-java-8.0.25.jar",
  "driver_class" = "com.mysql.cj.jdbc.Driver"
);
```

JDBC 的相关参数如下:

- user: 连接数据库使用的用户名
- password: 连接数据库使用的密码
- jdbc_url: 连接到指定数据库的标识符
- driver_url: jdbc 驱动包的 url
- driver_class: jdbc 驱动类

5. 创建 HDFS resource

```
CREATE RESOURCE hdfs_resource PROPERTIES (
  "type"="hdfs",
  "hadoop.username"="user",
  "dfs.nameservices" = "my_ha",
  "dfs.ha.namenodes.my_ha" = "my_namenode1, my_namenode2",
  "dfs.namenode.rpc-address.my_ha.my_namenode1" = "nn1_host:rpc_port",
  "dfs.namenode.rpc-address.my_ha.my_namenode2" = "nn2_host:rpc_port",
  "dfs.client.failover.proxy.provider.my_ha" =
```

```
"org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider"
);
```

HDFS 相关参数如下：

- fs.defaultFS: namenode 地址和端口
- hadoop.username: hdfs 用户名
- dfs.nameservices: name service 名称，与 hdfs-site.xml 保持一致
- dfs.ha.namenodes.[nameservice ID]: namenode 的 id 列表，与 hdfs-site.xml 保持一致
- dfs.namenode.rpc-address.[nameservice ID].[name node ID]: Name node 的 rpc 地址，数量与 namenode 数量相同，与 hdfs-site.xml 保持一致

6. 创建 HMS resource

HMS resource 用于 [hms catalog](#)

```
CREATE RESOURCE hms_resource PROPERTIES (
  'type'='hms',
  'hive.metastore.uris' = 'thrift://127.0.0.1:7004',
  'dfs.nameservices'='HANN',
  'dfs.ha.namenodes.HANN'='nn1,nn2',
  'dfs.namenode.rpc-address.HANN.nn1'='nn1_host:rpc_port',
  'dfs.namenode.rpc-address.HANN.nn2'='nn2_host:rpc_port',

  'dfs.client.failover.proxy.provider.HANN'='org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider'
);
```

HMS 的相关参数如下：

- hive.metastore.uris: hive metastore server 地址 可选参数：
- dfs.*: 如果 hive 数据存放在 hdfs，需要添加类似 HDFS resource 的参数，也可以将 hive-site.xml 拷贝到 fe/conf 目录下
- s3.*: 如果 hive 数据存放在 s3，需要添加类似 S3 resource 的参数。如果连接 [阿里云 Data Lake Formation](#)，可以将 hive-site.xml 拷贝到 fe/conf 目录下

7. 创建 ES resource

```
CREATE RESOURCE es_resource PROPERTIES (
  "type"="es",
  "hosts"="http://127.0.0.1:29200",
  "nodes_discovery"="false",
  "enable_keyword_sniff"="true"
);
```

ES 的相关参数如下：

- hosts: ES 地址，可以是一个或多个，也可以是 ES 的负载均衡地址
- user: ES 用户名
- password: 对应用户的密码信息
- enable_docvalue_scan: 是否开启通过 ES/Lucene 列式存储获取查询字段的值，默认为 true
- enable_keyword_sniff: 是否对 ES 中字符串分词类型 text.fields 进行探测，通过 keyword 进行查询 (默认为 true，设置为 false 会按照分词后的内容匹配)

- nodes_discovery: 是否开启 ES 节点发现，默认为 true，在网络隔离环境下设置为 false，只连接指定节点
- http_ssl_enabled: ES 是否开启 https 访问模式，目前在 fe/be 实现方式为信任所有

Keywords

CREATE, RESOURCE

Best Practice

CREATE-WORKLOAD-GROUP

CREATE-WORKLOAD-GROUP

Name

CREATE WORKLOAD GROUP

描述

该语句用于创建资源组。资源组可实现单个be上cpu资源和内存资源的隔离。

语法：

```
CREATE WORKLOAD GROUP [IF NOT EXISTS] "rg_name"
PROPERTIES (
    property_list
);
```

说明：

property_list 支持的属性：

- **cpu_share**: 必选，用于设置资源组获取cpu时间的多少，可以实现cpu资源软隔离。cpu_share 是相对值，表示正在运行的资源组可获取cpu资源的权重。例如，用户创建了3个资源组 rg-a、rg-b和rg-c，cpu_share 分别为 10、30、40，某一时刻rg-a和rg-b正在跑任务，而rg-c没有任务，此时rg-a可获得 $(10 / (10 + 30)) = 25\%$ 的cpu资源，而资源组rg-b可获得75%的cpu资源。如果系统只有一个资源组正在运行，则不管其cpu_share的值为多少，它都可以获取全部的cpu资源。
- **memory_limit**: 必选，用于设置资源组可以使用be内存的百分比。资源组内存限制的绝对值为：物理内存 * mem_limit * memory_limit，其中 mem_limit 为be配置项。系统所有资源组的 memory_limit总合不可超过100%。资源组在绝大多数情况下保证组内任务可使用memory_limit的内存，当资源组内存使用超出该限制后，组内内存占用较大的任务可能会被cancel以释放超出的内存，参考 enable_memory_overcommit。
- **enable_memory_overcommit**: 可选，用于开启资源组内存软隔离，默认为false。如果设置为false，则该资源组为内存硬隔离，系统检测到资源组内存使用超出限制后将立即cancel组内内存占用最大的若干个任务，以释放超出的内存；如果设置为true，则该资源组为内存软隔离，如果系统有空闲内存资源则该资源组在超出memory_limit的限制后可继续使用系统内存，在系统总内存紧张时会cancel组内内存占用最大的若干个任务，释放部分超出的内存以缓解系统内存压力。建议在有资源组开启该配置时，所有资源组的 memory_limit 总和低于100%，剩余部分用于资源组内存超发。

举例

1. 创建名为g1的资源组：

```
create workload group if not exists g1
properties (
    "cpu_share"="10",
    "memory_limit"="30%",
    "enable_memory_overcommit"="true"
);
```

Keywords

CREATE, WORKLOAD, GROUP

Best Practice

CREATE-SQL-BLOCK-RULE

CREATE-SQL-BLOCK-RULE

Name

CREATE SQL BLOCK RULE

描述

该语句创建 SQL 阻止规则，该功能可用于限制任何 sql 语句（包括 DDL 和 DML 语句）。

支持按用户配置 SQL 黑名单：

- 通过正则匹配的方式拒绝指定 SQL
- 通过设置 partition_num, tablet_num, cardinality, 检查一个查询是否达到其中一个限制
 - partition_num, tablet_num, cardinality 可以一起设置，一旦一个查询达到其中一个限制，查询将会被拦截

语法：

```
CREATE SQL_BLOCK_RULE rule_name
[PROPERTIES ("key"="value", ...)];
```

参数说明：

- sql：匹配规则（基于正则匹配，特殊字符需要转译，如select *使用select *），可选，默认值为“NULL”，最后不要带分号
- sqlHash: sql hash 值，用于完全匹配，我们会在fe.audit.log打印这个值，可选，这个参数和 sql 只能二选一，默认值为“NULL”
- partition_num: 一个扫描节点会扫描的最大 partition 数量，默认值为 0L
- tablet_num: 一个扫描节点会扫描的最大 tablet 数量，默认值为 0L
- cardinality: 一个扫描节点粗略的扫描行数，默认值为 0L
- global：是否全局（所有用户）生效，默认为 false
- enable：是否开启阻止规则，默认为 true

举例

1. 创建一个名称为 test_rule 的阻止规则

```
CREATE SQL_BLOCK_RULE test_rule
PROPERTIES(
  "sql"="select \\* from order_analysis",
  "global"="false",
  "enable"="true"
);
```

当我们去执行刚才我们定义在规则里的 sql 时就会返回异常错误，示例如下：

```
mysql> select * from order_analysis;
ERROR 1064 (HY000): errCode = 2, detailMessage = sql match regex sql block rule: order_analysis_rule
```

2. 创建 test_rule2，将最大扫描的分区数量限制在 30 个，最大扫描基数限制在 100 亿行，示例如下：

```
CREATE SQL_BLOCK_RULE test_rule2
PROPERTIES
(
  "partition_num" = "30",
  "cardinality" = "10000000000",
  "global" = "false",
  "enable" = "true"
);
Query OK, 0 rows affected (0.01 sec)
```

3. 创建包含特殊字符的 SQL BLOCK RULE，正则表达式中 (和) 符号是特殊符号，所以需要转义，示例如下：

```
CREATE SQL_BLOCK_RULE test_rule3
PROPERTIES
(
  "sql" = "select count\\(1\\) from db1.tbl1"
);
CREATE SQL_BLOCK_RULE test_rule4
PROPERTIES
(
  "sql" = "select \\* from db1.tbl1"
);
```

4. SQL_BLOCK_RULE 中，SQL 的匹配是基于正则的，如果想匹配更多模式的 SQL 需要写相应的正则，比如忽略 SQL 中空格，还有 order_ 开头的表都不能查询，示例如下：

```
CREATE SQL_BLOCK_RULE test_rule4
PROPERTIES(
  "sql"="\\s*select\\s*\\*\\s*from order_\\w*\\s*",
  "global"="false",
  "enable"="true"
);
```

附录

常用正则表达式如下：

- ：匹配任何单个字符，除了换行符 `\\n`。
- * ：匹配前面的元素零次或多次。例如，a* 匹配零个或多个 'a'。
- + ：匹配前面的元素一次或多次。例如，a+ 匹配一个或多个 'a'。
- ? ：匹配前面的元素零次或一次。例如，a? 匹配零个或一个 'a'。
- [] ：用于定义字符集合。例如，[aeiou] 匹配任何一个元音字母。

[^] : 在字符集合中使用 ^ 表示否定, 匹配不在集合内的字符。例如, [^0-9] 匹配任何非数字字符。

() : 用于分组表达式, 可以对其应用量词。例如, (ab)+ 匹配连续的 'ab'。

| : 用于表示或逻辑。例如, a|b 匹配 'a' 或 'b'。

^ : 匹配字符串的开头。例如, ^abc 匹配以 'abc' 开头的字符串。

\$: 匹配字符串的结尾。例如, xyz\$ 匹配以 'xyz' 结尾的字符串。

\ : 用于转义特殊字符, 使其变成普通字符。例如, \\. 匹配句点字符 '.'。

\s : 匹配任何空白字符, 包括空格、制表符、换行符等。

\d : 匹配任何数字字符, 相当于 [0-9]。

\w : 匹配任何单词字符, 包括字母、数字和下划线, 相当于 [a-zA-Z0-9_]。

Keywords

```
CREATE, SQL_BLOCK_RULE
```

Best Practice

ALTER-CATALOG

ALTER-CATALOG

Name

提示

该功能自 Apache Doris 1.2 版本起支持

ALTER CATALOG

描述

该语句用于设置指定数据目录的属性。（仅管理员使用）

1. 重命名数据目录

```
ALTER CATALOG catalog_name RENAME new_catalog_name;
```

注意： - internal 是内置数据目录，不允许重命名 - 对 catalog_name 拥有 Alter 权限才允许对其重命名 - 重命名数据目录后，如需要，请使用 REVOKE 和 GRANT 命令修改相应的用户权限。

2. 设置数据目录属性

```
ALTER CATALOG catalog_name SET PROPERTIES ('key1' = 'value1' [, 'key' = 'value2']);
```

更新指定属性的值为指定的 value。如果 SET PROPERTIES 从句中的 key 在指定 catalog 属性中不存在，则新增此 key。

注意： - 不可更改数据目录类型，即 type 属性 - 不可更改内置数据目录 internal 的属性

3. 修改数据目录注释

```
ALTER CATALOG catalog_name MODIFY COMMENT "new catalog comment";
```

注意： - internal 是内置数据目录，不允许修改注释

举例

1. 将数据目录 ctlg_hive 重命名为 hive

```
ALTER CATALOG ctlg_hive RENAME hive;
```

3. 更新名为 hive 数据目录的属性 hive.metastore.uris

```
ALTER CATALOG hive SET PROPERTIES ('hive.metastore.uris'='thrift://172.21.0.1:9083');
```

4. 更改名为 hive 数据目录的注释

```
ALTER CATALOG hive MODIFY COMMENT "new catalog comment";
```

Keywords

ALTER,CATALOG,RENAME,PROPERTY

Best Practice

ALTER-DATABASE

ALTER-DATABASE

Name

ALTER DATABASE

描述

该语句用于设置指定数据库的属性。(仅管理员使用)

1. 设置数据库数据量配额，单位为B/K/KB/M/MB/G/GB/T/TB/P/PB

```
ALTER DATABASE db_name SET DATA QUOTA quota;
```

2. 重命名数据库

```
ALTER DATABASE db_name RENAME new_db_name;
```

3. 设置数据库的副本数量配额

```
ALTER DATABASE db_name SET REPLICA QUOTA quota;
```

说明：重命名数据库后，如需要，请使用 REVOKE 和 GRANT 命令修改相应的用户权限。数据库的默认数据量配额为1PB，默认副本数量配额为1073741824。

4. 对已有 database 的 property 进行修改操作

```
ALTER DATABASE db_name SET PROPERTIES ("key"="value", ...);
```

举例

1. 设置指定数据库数据量配额

```
ALTER DATABASE example_db SET DATA QUOTA 10995116277760;
```

上述单位为字节,等价于

```
ALTER DATABASE example_db SET DATA QUOTA 10T;
```

```
ALTER DATABASE example_db SET DATA QUOTA 100G;
```

```
ALTER DATABASE example_db SET DATA QUOTA 200M;
```

2. 将数据库 example_db 重命名为 example_db2


```
ALTER DATABASE example_db RENAME example_db2;
```

3. 设定指定数据库副本数量配额

```
ALTER DATABASE example_db SET REPLICA QUOTA 102400;
```

4. 修改db下table的默认副本分布策略（该操作仅对新建的table生效，不会修改db下已存在的table）

```
ALTER DATABASE example_db SET PROPERTIES("replication_allocation" = "tag.location.default:2");
```

5. 取消db下table的默认副本分布策略（该操作仅对新建的table生效，不会修改db下已存在的table）

```
ALTER DATABASE example_db SET PROPERTIES("replication_allocation" = "");
```

Keywords

ALTER, DATABASE, RENAME

Best Practice

ALTER-TABLE-COLUMN

ALTER-TABLE-COLUMN

Name

ALTER TABLE COLUMN

描述

该语句用于对已有 table 进行 Schema change 操作。schema change 是异步的，任务提交成功则返回，之后可使用[SHOW ALTER TABLE COLUMN](#) 命令查看进度。

语法：

```
ALTER TABLE [database.]table alter_clause;
```

schema change 的 alter_clause 支持如下几种修改方式：

1. 向指定 index 的指定位置添加一列

语法：

```
ADD COLUMN column_name column_type [KEY | agg_type] [DEFAULT "default_value"]  
[AFTER column_name|FIRST]  
[TO rollup_index_name]  
[PROPERTIES ("key"="value", ...)]
```

注意：

- 聚合模型如果增加 value 列，需要指定 agg_type
- 非聚合模型（如 DUPLICATE KEY）如果增加key列，需要指定KEY关键字
- 不能在 rollup index 中增加 base index 中已经存在的列（如有需要，可以重新创建一个 rollup index）

2. 向指定 index 添加多列

语法：

```
ADD COLUMN (column_name1 column_type [KEY | agg_type] DEFAULT "default_value", ...)  
[TO rollup_index_name]  
[PROPERTIES ("key"="value", ...)]
```

注意：

- 聚合模型如果增加 value 列，需要指定agg_type
- 聚合模型如果增加key列，需要指定KEY关键字
- 不能在 rollup index 中增加 base index 中已经存在的列（如有需要，可以重新创建一个 rollup index）

3. 从指定 index 中删除一列

语法:

```
DROP COLUMN column_name  
[FROM rollup_index_name]
```

注意:

- 不能删除分区列
- 如果是从 base index 中删除列, 则如果 rollup index 中包含该列, 也会被删除

4. 修改指定 index 的列类型以及列位置

语法:

```
MODIFY COLUMN column_name column_type [KEY | agg_type] [NULL | NOT NULL] [DEFAULT "default_value"]  
[AFTER column_name|FIRST]  
[FROM rollup_index_name]  
[PROPERTIES ("key"="value", ...)]
```

注意:

- 聚合模型如果修改 value 列, 需要指定 agg_type
- 非聚合类型如果修改key列, 需要指定KEY关键字
- 只能修改列的类型, 列的其他属性维持原样 (即其他属性需在语句中按照原属性显式的写出, 参见 example 8)
- 分区列和分桶列不能做任何修改
- 目前支持以下类型的转换 (精度损失由用户保证)
 - TINYINT/SMALLINT/INT/BIGINT/LARGEINT/FLOAT/DOUBLE 类型向范围更大的数字类型转换
 - TINYINT/SMALLINT/INT/BIGINT/LARGEINT/FLOAT/DOUBLE/DECIMAL 转换成 VARCHAR
 - VARCHAR 支持修改最大长度
 - VARCHAR/CHAR 转换成 TINYINT/SMALLINT/INT/BIGINT/LARGEINT/FLOAT/DOUBLE
 - VARCHAR/CHAR 转换成 DATE (目前支持"%Y-%m-%d", "%y-%m-%d", "%Y%m%d", "%y%m%d", "%Y/%m/%d", "%y/%m/%d"六种格式化格式)
 - DATETIME 转换成 DATE(仅保留年-月-日信息, 例如: 2019-12-09 21:47:05 <--> 2019-12-09)
 - DATE 转换成 DATETIME(时分秒自动补零, 例如: 2019-12-09 <--> 2019-12-09 00:00:00)
 - FLOAT 转换成 DOUBLE
 - INT 转换成 DATE (如果INT类型数据不合法则转换失败, 原始数据不变)
 - 除DATE与DATETIME以外都可以转换成STRING, 但是STRING不能转换任何其他类型

5. 对指定 index 的列进行重新排序

语法:

```
ORDER BY (column_name1, column_name2, ...)  
[FROM rollup_index_name]  
[PROPERTIES ("key"="value", ...)]
```

注意:

- index 中的所有列都要写出来
- value 列在 key 列之后

举例

1. 向 example_rollup_index 的 col1 后添加一个key列 new_col(非聚合模型)

```
ALTER TABLE example_db.my_table
ADD COLUMN new_col INT KEY DEFAULT "0" AFTER col1
TO example_rollup_index;
```

2. 向example_rollup_index的col1后添加一个value列new_col(非聚合模型)

```
ALTER TABLE example_db.my_table
ADD COLUMN new_col INT DEFAULT "0" AFTER col1
TO example_rollup_index;
```

3. 向example_rollup_index的col1后添加一个key列new_col(聚合模型)

```
ALTER TABLE example_db.my_table
ADD COLUMN new_col INT DEFAULT "0" AFTER col1
TO example_rollup_index;
```

4. 向example_rollup_index的col1后添加一个value列new_col SUM聚合类型(聚合模型)

```
ALTER TABLE example_db.my_table
ADD COLUMN new_col INT SUM DEFAULT "0" AFTER col1
TO example_rollup_index;
```

5. 向 example_rollup_index 添加多列(聚合模型)

```
ALTER TABLE example_db.my_table
ADD COLUMN (col1 INT DEFAULT "1", col2 FLOAT SUM DEFAULT "2.3")
TO example_rollup_index;
```

6. 从 example_rollup_index 删除一列

```
ALTER TABLE example_db.my_table
DROP COLUMN col2
FROM example_rollup_index;
```

7. 修改 base index 的 key 列 col1 的类型为 BIGINT，并移动到 col2 列后面。

```
ALTER TABLE example_db.my_table
MODIFY COLUMN col1 BIGINT KEY DEFAULT "1" AFTER col2;
```

注意：无论是修改 key 列还是 value 列都需要声明完整的 column 信息

8. 修改 base index 的 val1 列最大长度。原 val1 为 (val1 VARCHAR(32) REPLACE DEFAULT "abc")

```
ALTER TABLE example_db.my_table  
MODIFY COLUMN val1 VARCHAR(64) REPLACE DEFAULT "abc";
```

注意：只能修改列的类型，列的其他属性维持原样

9. 重新排序 example_rollup_index 中的列（设原列顺序为：k1,k2,k3,v1,v2）

```
ALTER TABLE example_db.my_table  
ORDER BY (k3,k1,k2,v2,v1)  
FROM example_rollup_index;
```

10. 同时执行两种操作

```
ALTER TABLE example_db.my_table  
ADD COLUMN v2 INT MAX DEFAULT "0" AFTER k2 TO example_rollup_index,  
ORDER BY (k3,k1,k2,v2,v1) FROM example_rollup_index;
```

11. 修改Duplicate key 表 Key 列的某个字段的长度

```
alter table example_tbl modify column k3 varchar(50) key null comment 'to 50'
```

Keywords

ALTER, TABLE, COLUMN, ALTER TABLE

Best Practice

ALTER-TABLE-PARTITION

ALTER-TABLE-PARTITION

Name

ALTER TABLE PARTITION

描述

该语句用于对有 partition 的 table 进行修改操作。

这个操作是同步的，命令返回表示执行完毕。

语法：

```
ALTER TABLE [database.]table alter_clause;
```

partition 的 alter_clause 支持如下几种修改方式

1. 增加分区

语法：

```
ADD PARTITION [IF NOT EXISTS] partition_name  
partition_desc ["key"="value"]  
[DISTRIBUTED BY HASH (k1[,k2 ...]) [BUCKETS num]]
```

注意：

- partition_desc 支持以下两种写法
 - VALUES LESS THAN [MAXVALUE](“value1”, ...)]
 - VALUES [(“value1”, ...), (“value1”, ...)]
- 分区为左闭右开区间，如果用户仅指定右边界，系统会自动确定左边界
- 如果没有指定分桶方式，则自动使用建表使用的分桶方式和分桶数。
- 如指定分桶方式，只能修改分桶数，不可修改分桶方式或分桶列。如果指定了分桶方式，但是没有指定分桶数，则分桶数会使用默认值10，不会使用建表时指定的分桶数。如果要指定分桶数，则必须指定分桶方式。
- [“key”=“value”] 部分可以设置分区的一些属性，具体说明见 [CREATE TABLE](#)
- 如果建表时用户未显式创建Partition,则不支持通过ALTER的方式增加分区
- 如果用户使用的是List Partition则可以增加default partition， default partition将会存储所有不满足其他分区键要求的数据。
 - ALTER TABLE table_name ADD PARTITION partition_name

2. 删除分区

语法：

```
DROP PARTITION [IF EXISTS] partition_name [FORCE]
```

注意：

- 使用分区方式的表至少要保留一个分区。
- 执行 DROP PARTITION 一段时间内，可以通过 RECOVER 语句恢复被删除的分区。详见 SQL手册-数据库管理-RECOVER 语句
- 如果执行 DROP PARTITION FORCE，则系统不会检查该分区是否存在未完成的事务，分区将直接被删除并且不能被恢复，一般不建议执行此操作

3. 修改分区属性

语法：

```
MODIFY PARTITION p1|(p1[, p2, ...]) SET ("key" = "value", ...)
```

说明：

- 当前支持修改分区的下列属性：
 - storage_medium
 - storage_cooldown_time
 - replication_num
 - in_memory
- 对于单分区表，partition_name 同表名。

举例

1. 增加分区, 现有分区 [MIN, 2013-01-01), 增加分区 [2013-01-01, 2014-01-01), 使用默认分桶方式

```
ALTER TABLE example_db.my_table  
ADD PARTITION p1 VALUES LESS THAN ("2014-01-01");
```

2. 增加分区，使用新的分桶数

```
ALTER TABLE example_db.my_table  
ADD PARTITION p1 VALUES LESS THAN ("2015-01-01")  
DISTRIBUTED BY HASH(k1) BUCKETS 20;
```

3. 增加分区，使用新的副本数

```
ALTER TABLE example_db.my_table  
ADD PARTITION p1 VALUES LESS THAN ("2015-01-01")  
("replication_num"="1");
```

4. 修改分区副本数

```
ALTER TABLE example_db.my_table  
MODIFY PARTITION p1 SET("replication_num"="1");
```

5. 批量修改指定分区

```
ALTER TABLE example_db.my_table  
MODIFY PARTITION (p1, p2, p4) SET("replication_num"="1");
```

6. 批量修改所有分区

```
ALTER TABLE example_db.my_table  
MODIFY PARTITION (*) SET("storage_medium"="HDD");
```

7. 删除分区

```
ALTER TABLE example_db.my_table  
DROP PARTITION p1;
```

8. 增加一个指定上下界的分区

```
ALTER TABLE example_db.my_table  
ADD PARTITION p1 VALUES [("2014-01-01"), ("2014-02-01"));
```

Keywords

ALTER, TABLE, PARTITION, ALTER TABLE

Best Practice

ALTER-TABLE-ROLLUP

ALTER-TABLE-ROLLUP

Name

ALTER TABLE ROLLUP

描述

该语句用于对已有 table 进行 rollup 进行修改操作。rollup 是异步操作，任务提交成功则返回，之后可使用 [SHOW ALTER](#) 命令查看进度。

语法：

```
ALTER TABLE [database.]table alter_clause;
```

rollup 的 alter_clause 支持如下几种创建方式

1. 创建 rollup index

语法：

```
ADD ROLLUP rollup_name (column_name1, column_name2, ...)
[FROM from_index_name]
[PROPERTIES ("key"="value", ...)]
```

properties: 支持设置超时时间，默认超时时间为1天。

2. 批量创建 rollup index

语法：

```
ADD ROLLUP [rollup_name (column_name1, column_name2, ...)
            [FROM from_index_name]
            [PROPERTIES ("key"="value", ...)],...]
```

注意：

- 如果没有指定 from_index_name，则默认从 base index 创建
- rollup 表中的列必须是 from_index 中已有的列
- 在 properties 中，可以指定存储格式。具体请参阅 [CREATE TABLE](#)

3. 删除 rollup index

语法：

```
DROP ROLLUP rollup_name [PROPERTIES ("key"="value", ...)]
```

4. 批量删除 rollup index

语法:

```
DROP ROLLUP [rollup_name [PROPERTIES ("key"="value", ...)],...]
```

注意:

- 不能删除 base index

举例

1. 创建 index: example_rollup_index, 基于 base index (k1,k2,k3,v1,v2)。列式存储。

```
ALTER TABLE example_db.my_table  
ADD ROLLUP example_rollup_index(k1, k3, v1, v2);
```

2. 创建 index: example_rollup_index2, 基于 example_rollup_index (k1,k3,v1,v2)

```
ALTER TABLE example_db.my_table  
ADD ROLLUP example_rollup_index2 (k1, v1)  
FROM example_rollup_index;
```

3. 创建 index: example_rollup_index3, 基于 base index (k1,k2,k3,v1), 自定义 rollup 超时时间一小时。

```
ALTER TABLE example_db.my_table  
ADD ROLLUP example_rollup_index(k1, k3, v1)  
PROPERTIES("timeout" = "3600");
```

4. 删除 index: example_rollup_index2

```
ALTER TABLE example_db.my_table  
DROP ROLLUP example_rollup_index2;
```

5. 批量删除Rollup

```
ALTER TABLE example_db.my_table  
DROP ROLLUP example_rollup_index2,example_rollup_index3;
```

Keywords

```
ALTER, TABLE, ROLLUP, ALTER TABLE
```

Best Practice

ALTER-TABLE-RENAME

ALTER-TABLE-RENAME

Name

ALTER TABLE RENAME

描述

该语句用于对已有 table 属性的某些名称进行重命名操作。这个操作是同步的，命令返回表示执行完毕。

语法：

```
ALTER TABLE [database.]table alter_clause;
```

rename 的 alter_clause 支持对以下名称进行修改

1. 修改表名

语法：

```
RENAME new_table_name;
```

2. 修改 rollup index 名称

语法：

```
RENAME ROLLUP old_rollup_name new_rollup_name;
```

3. 修改 partition 名称

语法：

```
RENAME PARTITION old_partition_name new_partition_name;
```

4. 修改 column 名称

提示

该功能自 Apache Doris 1.2 版本起支持

修改 column 名称

语法：

```
RENAME COLUMN old_column_name new_column_name;
```

注意： - 建表时需要在 property 中设置 light_schema_change=true

举例

1. 将名为 table1 的表修改为 table2

```
ALTER TABLE table1 RENAME table2;
```

2. 将表 example_table 中名为 rollup1 的 rollup index 修改为 rollup2

```
ALTER TABLE example_table RENAME ROLLUP rollup1 rollup2;
```

3. 将表 example_table 中名为 p1 的 partition 修改为 p2

```
ALTER TABLE example_table RENAME PARTITION p1 p2;
```

4. 将表 example_table 中名为 c1 的 column 修改为 c2

```
ALTER TABLE example_table RENAME COLUMN c1 c2;
```

Keywords

```
ALTER, TABLE, RENAME, ALTER TABLE
```

Best Practice

ALTER-TABLE-REPLACE

ALTER-TABLE-REPLACE

Name

ALTER TABLE REPLACE

描述

对两个表进行原子的替换操作。该操作仅适用于 OLAP 表。

```
ALTER TABLE [db.]tbl1 REPLACE WITH TABLE tbl2
[PROPERTIES('swap' = 'true')];
```

将表 tbl1 替换为表 tbl2。

如果 swap 参数为 true，则替换后，名称为 tbl1 表中的数据为原 tbl2 表中的数据。而名称为 tbl2 表中的数据为原 tbl1 表中的数据。即两张表数据发生了互换。

如果 swap 参数为 false，则替换后，名称为 tbl1 表中的数据为原 tbl2 表中的数据。而名称为 tbl2 表被删除。

原理

替换表功能，实际上是将以下操作集合变成一个原子操作。

假设要将表 A 替换为表 B，且 swap 为 true，则操作如下：

1. 将表 B 重名为表 A。
2. 将表 A 重名为表 B。

如果 swap 为 false，则操作如下：

1. 删除表 A。
2. 将表 B 重名为表 A。

注意事项

1. swap 参数默认为 true。即替换表操作相当于将两张表数据进行交换。
2. 如果设置 swap 参数为 false，则被替换的表（表 A）将被删除，且无法恢复。
3. 替换操作仅能发生在两张 OLAP 表之间，且不会检查两张表的表结构是否一致。
4. 替换操作不会改变原有的权限设置。因为权限检查以表名称为准。

举例

1. 将 tbl1 与 tbl2 进行原子交换，不删除任何表（注：如果删除的话，实际上删除的是 tbl1，只是将 tbl2 重命名为 tbl1。）

```
ALTER TABLE tbl1 REPLACE WITH TABLE tbl2;
```

或

```
ALTER TABLE tbl1 REPLACE WITH TABLE tbl2 PROPERTIES('swap' = 'true') ;
```

2. 将 tbl1 与 tbl2 进行交换，删除 tbl2 表（保留名为tbl1,数据为tbl2的表）

```
ALTER TABLE tbl1 REPLACE WITH TABLE tbl2 PROPERTIES('swap' = 'false') ;
```

Keywords

```
ALTER, TABLE, REPLACE, ALTER TABLE
```

Best Practice

1. 原子的覆盖写操作

某些情况下，用户希望能够重写某张表的数据，但如果采用先删除再导入的方式进行，在中间会有一段时间无法查看数据。这时，用户可以先使用 CREATE TABLE LIKE 语句创建一个相同结构的新表，将新的数据导入到新表后，通过替换操作，原子的替换旧表，以达到目的。分区级别的原子覆盖写操作，请参阅 [临时分区文档](#)。

ALTER-TABLE-PROPERTY

ALTER-TABLE-PROPERTY

Name

ALTER TABLE PROPERTY

描述

该语句用于对已有 table 的 property 进行修改操作。这个操作是同步的，命令返回表示执行完毕。

语法：

```
ALTER TABLE [database.]table alter_clause;
```

property 的 alter_clause 支持如下几种修改方式

1. 修改表的 bloom filter 列

```
ALTER TABLE example_db.my_table SET ("bloom_filter_columns"="k1,k2,k3");
```

也可以合并到上面的 schema change 操作中（注意多子句的语法有少许区别）

```
ALTER TABLE example_db.my_table  
DROP COLUMN col2  
PROPERTIES ("bloom_filter_columns"="k1,k2,k3");
```

2. 修改表的Colocate 属性

```
ALTER TABLE example_db.my_table set ("colocate_with" = "t1");
```

3. 将表的分桶方式由 Hash Distribution 改为 Random Distribution

```
ALTER TABLE example_db.my_table set ("distribution_type" = "random");
```

4. 修改表的动态分区属性(支持未添加动态分区属性的表添加动态分区属性)

```
ALTER TABLE example_db.my_table set ("dynamic_partition.enable" = "false");
```

如果需要在未添加动态分区属性的表中添加动态分区属性，则需要指定所有的动态分区属性 (注:非分区表不支持添加动态分区属性)

```
ALTER TABLE example_db.my_table set (  
    "dynamic_partition.enable" = "true",
```

```
"dynamic_partition.time_unit" = "DAY",  
"dynamic_partition.end" = "3",  
"dynamic_partition.prefix" = "p",  
"dynamic_partition.buckets" = "32"  
);
```

5. 修改表的 in_memory 属性，只支持修改为'false'

```
ALTER TABLE example_db.my_table set ("in_memory" = "false");
```

6. 启用 批量删除功能

```
ALTER TABLE example_db.my_table ENABLE FEATURE "BATCH_DELETE";
```

注意：

- 只能用在unique 表
- 用于旧表支持批量删除功能，新表创建时已经支持

7. 启用按照sequence column的值来保证导入顺序的功能

```
ALTER TABLE example_db.my_table ENABLE FEATURE "SEQUENCE_LOAD" WITH PROPERTIES (  
"function_column.sequence_type" = "Date"  
);
```

注意：

- 只能用在unique 表
- sequence_type用来指定sequence列的类型，可以为整型和时间类型
- 只支持新导入数据的有序性，历史数据无法更改

8. 将表的默认分桶数改为50

```
ALTER TABLE example_db.my_table MODIFY DISTRIBUTION DISTRIBUTED BY HASH(k1) BUCKETS 50;
```

注意：

- 只能用在分区类型为RANGE，采用哈希分桶的非colocate表

9. 修改表注释

```
ALTER TABLE example_db.my_table MODIFY COMMENT "new comment";
```

10. 修改列注释

```
ALTER TABLE example_db.my_table MODIFY COLUMN k1 COMMENT "k1", MODIFY COLUMN k2 COMMENT "k2";
```

11. 修改引擎类型

仅支持将 MySQL 类型修改为 ODBC 类型。driver 的值为 odbc.init 配置中的 driver 名称。


```
ALTER TABLE example_db.mysql_table MODIFY ENGINE TO odbc PROPERTIES("driver" = "MySQL");
```

12. 修改副本数

```
ALTER TABLE example_db.mysql_table SET ("replication_num" = "2");
ALTER TABLE example_db.mysql_table SET ("default.replication_num" = "2");
ALTER TABLE example_db.mysql_table SET ("replication_allocation" = "tag.location.default: 1");
ALTER TABLE example_db.mysql_table SET ("default.replication_allocation" = "tag.location.default: 1");
```

注： 1. default 前缀的属性表示修改表的默认副本分布。这种修改不会修改表的当前实际副本分布，而只影响分区表上新建分区的副本分布。 2. 对于非分区表，修改不带 default 前缀的副本分布属性，会同时修改表的默认副本分布和实际副本分布。即修改后，通过 show create table 和 show partitions from tbl 语句可以看到副本分布数据都被修改了。 3. 对于分区表，表的实际副本分布是分区级别的，即每个分区有自己的副本分布，可以通过 show partitions from tbl 语句查看。如果想修改实际副本分布，请参阅 ALTER TABLE PARTITION。

13. [Experimental] 打开light_schema_change

对于建表时未开启light_schema_change的表，可以通过如下方式打开。

```
ALTER TABLE example_db.mysql_table SET ("light_schema_change" = "true");
```

举例

1. 修改表的 bloom filter 列

```
ALTER TABLE example_db.my_table SET (
    "bloom_filter_columns"="k1,k2,k3"
);
```

也可以合并到上面的 schema change 操作中（注意多子句的语法有少许区别）

```
ALTER TABLE example_db.my_table
DROP COLUMN col2
PROPERTIES (
    "bloom_filter_columns"="k1,k2,k3"
);
```

2. 修改表的Colocate 属性

```
ALTER TABLE example_db.my_table set ("colocate_with" = "t1");
```

3. 将表的分桶方式由 Hash Distribution 改为 Random Distribution

```
ALTER TABLE example_db.my_table set (
    "distribution_type" = "random"
);
```

4. 修改表的动态分区属性(支持未添加动态分区属性的表添加动态分区属性)

```
ALTER TABLE example_db.my_table set (  
    "dynamic_partition.enable" = "false"  
);
```

如果需要在未添加动态分区属性的表中添加动态分区属性，则需要指定所有的动态分区属性 (注:非分区表不支持添加动态分区属性)

```
ALTER TABLE example_db.my_table set (  
    "dynamic_partition.enable" = "true",  
    "dynamic_partition.time_unit" = "DAY",  
    "dynamic_partition.end" = "3",  
    "dynamic_partition.prefix" = "p",  
    "dynamic_partition.buckets" = "32"  
);
```

5. 修改表的 in_memory 属性，只支持修改为'false'

```
ALTER TABLE example_db.my_table set ("in_memory" = "false");
```

6. 启用 批量删除功能

```
ALTER TABLE example_db.my_table ENABLE FEATURE "BATCH_DELETE";
```

7. 启用按照sequence column的值来保证导入顺序的功能

```
ALTER TABLE example_db.my_table ENABLE FEATURE "SEQUENCE_LOAD" WITH PROPERTIES (  
    "function_column.sequence_type" = "Date"  
);
```

8. 将表的默认分桶数改为50

```
ALTER TABLE example_db.my_table MODIFY DISTRIBUTION DISTRIBUTED BY HASH(k1) BUCKETS 50;
```

9. 修改表注释

```
ALTER TABLE example_db.my_table MODIFY COMMENT "new comment";
```

10. 修改列注释

```
ALTER TABLE example_db.my_table MODIFY COLUMN k1 COMMENT "k1", MODIFY COLUMN k2 COMMENT "k2";
```

11. 修改引擎类型

```
ALTER TABLE example_db.mysql_table MODIFY ENGINE TO odbc PROPERTIES("driver" = "MySQL");
```

12. 给表添加冷热分层数据迁移策略

```
ALTER TABLE create_table_not_have_policy set ("storage_policy" = "created_create_table_alter_policy");
```

注：表没有关联过storage policy，才能被添加成功，一个表只能添加一个storage policy

13. 给表的partition添加冷热分层数据迁移策略

```
ALTER TABLE create_table_partition MODIFY PARTITION (*)  
SET("storage_policy"="created_create_table_partition_alter_policy");
```

注：表的partition没有关联过storage policy，才能被添加成功，一个表只能添加一个storage policy ####

Keywords

```
ALTER, TABLE, PROPERTY, ALTER TABLE
```

Best Practice

ALTER-TABLE-COMMENT

ALTER-TABLE-COMMENT

Name

ALTER TABLE COMMENT

描述

该语句用于对已有 table 的 comment 进行修改。这个操作是同步的，命令返回表示执行完毕。

语法：

```
ALTER TABLE [database.]table alter_clause;
```

1. 修改表注释

语法：

```
MODIFY COMMENT "new table comment";
```

2. 修改列注释

语法：

```
MODIFY COLUMN col1 COMMENT "new column comment";
```

举例

1. 将名为 table1 的 comment 修改为 table1_comment

```
ALTER TABLE table1 MODIFY COMMENT "table1_comment";
```

2. 将名为 table1 的 col1 列的 comment 修改为 table1_col1_comment

```
ALTER TABLE table1 MODIFY COLUMN col1 COMMENT "table1_col1_comment";
```

Keywords

ALTER, TABLE, COMMENT, ALTER TABLE

Best Practice

CANCEL-ALTER-TABLE

CANCEL-ALTER-TABLE

Name

CANCEL ALTER TABLE

描述

该语句用于撤销一个 ALTER 操作。

1. 撤销 ALTER TABLE COLUMN 操作

语法：

```
CANCEL ALTER TABLE COLUMN
FROM db_name.table_name
```

2. 撤销 ALTER TABLE ROLLUP 操作

语法：

```
CANCEL ALTER TABLE ROLLUP
FROM db_name.table_name
```

3. 根据job id批量撤销rollup操作

语法：

```
CANCEL ALTER TABLE ROLLUP
FROM db_name.table_name (jobid,...)
```

注意：

- 该命令为异步操作，具体是否执行成功需要使用show alter table rollup查看任务状态确认

4. 撤销 ALTER CLUSTER 操作

语法：

(待实现...)

举例

1. 撤销针对 my_table 的 ALTER COLUMN 操作。

[CANCEL ALTER TABLE COLUMN]

```
CANCEL ALTER TABLE COLUMN  
FROM example_db.my_table;
```

1. 撤销 my_table 下的 ADD ROLLUP 操作。

[CANCEL ALTER TABLE ROLLUP]

```
CANCEL ALTER TABLE ROLLUP  
FROM example_db.my_table;
```

1. 根据job id撤销 my_table 下的 ADD ROLLUP 操作。

[CANCEL ALTER TABLE ROLLUP]

```
CANCEL ALTER TABLE ROLLUP  
FROM example_db.my_table (12801,12802);
```

Keywords

CANCEL, ALTER, TABLE, CANCEL ALTER

Best Practice

ALTER-VIEW

ALTER-VIEW

Name

ALTER VIEW

描述

该语句用于修改一个view的定义

语法：

```
ALTER VIEW
[db_name.]view_name
(column1[ COMMENT "col comment"][, column2, ...])
AS query_stmt
```

说明：

- 视图都是逻辑上的，其中的数据不会存储在物理介质上，在查询时视图将作为语句中的子查询，因此，修改视图的定义等价于修改query_stmt。
- query_stmt 为任意支持的 SQL

举例

1、修改example_db上的视图example_view

```
ALTER VIEW example_db.example_view
(
    c1 COMMENT "column 1",
    c2 COMMENT "column 2",
    c3 COMMENT "column 3"
)
AS SELECT k1, k2, SUM(v1) FROM example_table
GROUP BY k1, k2
```

Keywords

ALTER, VIEW

Best Practice

ALTER-POLICY

ALTER-POLICY

Name

ALTER STORAGE POLICY

描述

该语句用于修改一个已有的冷热分层迁移策略。仅 root 或 admin 用户可以修改资源。语法：

```
ALTER STORAGE POLICY 'policy_name'  
PROPERTIES ("key"="value", ...);
```

举例

1. 修改名为 cooldown_datetime冷热分层数据迁移时间点：

```
ALTER STORAGE POLICY has_test_policy_to_alter PROPERTIES("cooldown_datetime" = "2023-06-08 00:00:00");
```

2. 修改名为 cooldown_ttl的冷热分层数据迁移倒计时

```
ALTER STORAGE POLICY has_test_policy_to_alter PROPERTIES ("cooldown_ttl" = "10000");  
ALTER STORAGE POLICY has_test_policy_to_alter PROPERTIES ("cooldown_ttl" = "1h");  
ALTER STORAGE POLICY has_test_policy_to_alter PROPERTIES ("cooldown_ttl" = "3d");
```

Keywords

ALTER, STORAGE, POLICY

Best Practice

ALTER-RESOURCE

ALTER-RESOURCE

Name

ALTER RESOURCE

描述

该语句用于修改一个已有的资源。仅 root 或 admin 用户可以修改资源。语法：

```
ALTER RESOURCE 'resource_name'  
PROPERTIES ("key"="value", ...);
```

注意：resource type 不支持修改。

举例

1. 修改名为 spark0 的 Spark 资源的工作目录：

```
ALTER RESOURCE 'spark0' PROPERTIES ("working_dir" = "hdfs://127.0.0.1:10000/tmp/doris_new");
```

2. 修改名为 remote_s3 的 S3 资源的最大连接数：

```
ALTER RESOURCE 'remote_s3' PROPERTIES ("s3.connection.maximum" = "100");
```

3. 修改冷热分层S3资源相关信息

- 支持修改项
 - s3.access_key s3的ak信息
 - s3.secret_key s3的sk信息
 - s3.session_token s3的session token信息
 - s3.connection.maximum s3最大连接数，默认50
 - s3.connection.timeout s3连接超时时间，默认1000ms
 - s3.connection.request.timeout s3请求超时时间，默认3000ms
- 禁止修改项
 - s3.region
 - s3.bucket
 - s3.root.path
 - s3.endpoint

```
ALTER RESOURCE "showPolicy_1_resource" PROPERTIES("s3.connection.maximum" = "1111");
```

Keywords

ALTER, RESOURCE

Best Practice

ALTER-COLOCATE-GROUP

ALTER-COLOCATE-GROUP

Name

ALTER COLOCATE GROUP

描述

该语句用于修改 Colocation Group 的属性。

语法：

```
ALTER COLOCATE GROUP [database.]group
SET (
    property_list
);
```

注意：

1. 如果colocate group是全局的，即它的名称是以 __global__ 开头的，那它不属于任何一个Database；
2. property_list 是colocation group属性，目前只支持修改replication_num 和 replication_allocation。修改colocation group的这两个属性修改之后，同时把该group的表的属性 default.replication_allocation、属性dynamic.replication_allocation、以及已有分区的 replication_allocation改成跟它一样。

举例

1. 修改一个全局group的副本数

```
# 建表时设置 "colocate_with" = "__global__foo"

ALTER COLOCATE GROUP __global__foo
SET (
    "replication_num"="1"
);
```

2. 修改一个非全局group的副本数

```
# 建表时设置 "colocate_with" = "bar", 且表属于Database example_db

ALTER COLOCATE GROUP example_db.bar
SET (
    "replication_num"="1"
);
...

#### Keywords
```

```
```sql
ALTER, COLOCATE , GROUP
```

## Best Practice

# ALTER-WORKLOAD-GROUP

---

## ALTER-WORKLOAD-GROUP

### Name

ALTER WORKLOAD GROUP

### 描述

该语句用于修改资源组。

语法：

```
ALTER WORKLOAD GROUP "rg_name"
PROPERTIES (
 property_list
);
```

注意：

- 修改 memory\_limit 属性时不可使所有 memory\_limit 值的总和超过100%；
- 支持修改部分属性，例如只修改cpu\_share的话，properties里只填cpu\_share即可。

### 举例

1. 修改名为 g1 的资源组：

```
alter workload group g1
properties (
 "cpu_share"="30",
 "memory_limit"="30%"
);
```

### Keywords

ALTER, WORKLOAD , GROUP

### Best Practice

# ALTER-SQL-BLOCK-RULE

## ALTER-SQL-BLOCK-RULE

### Name

ALTER SQL BLOCK RULE

### 描述

修改SQL阻止规则，允许对sql/sqlHash/partition\_num/tablet\_num/cardinality/global/enable等每一项进行修改。

语法：

```
ALTER SQL_BLOCK_RULE rule_name
[PROPERTIES ("key"="value", ...)];
```

说明：

- sql 和 sqlHash 不能同时被设置。这意味着，如果一个rule设置了sql或者sqlHash，则另一个属性将无法被修改；
- sql/sqlHash 和 partition\_num/tablet\_num/cardinality 不能同时被设置。举个例子，如果一个rule设置了partition\_num，那么sql或者sqlHash将无法被修改；

### 举例

1. 根据SQL属性进行修改

```
ALTER SQL_BLOCK_RULE test_rule PROPERTIES("sql"="select * from test_table","enable"="true")
```

2. 如果一个rule设置了partition\_num，那么sql或者sqlHash将无法被修改

```
ALTER SQL_BLOCK_RULE test_rule2 PROPERTIES("partition_num" = "10","tablet_num"="300","enable"="true")
```

### Keywords

ALTER, SQL\_BLOCK\_RULE

### Best Practice

# DROP-CATALOG

## DROP-CATALOG

### Name

**提示**

该功能自 Apache Doris 1.2 版本起支持

### CREATE CATALOG

### 描述

该语句用于删除外部数据目录（catalog）

语法：

```
DROP CATALOG [IF EXISTS] catalog_name;
```

### 举例

- 1. 删除数据目录 hive

```
DROP CATALOG hive;
```

### Keywords

DROP, CATALOG

### Best Practice

# DROP-DATABASE

---

## DROP-DATABASE

### Name

DOPR DATABASE

### 描述

该语句用于删除数据库（database）语法：

```
DROP DATABASE [IF EXISTS] db_name [FORCE];
```

说明：

- 执行 DROP DATABASE 一段时间内，可以通过 RECOVER 语句恢复被删除的数据库。详见 [RECOVER](#) 语句
- 如果执行 DROP DATABASE FORCE，则系统不会检查该数据库是否存在未完成的事务，数据库将直接被删除并且不能被恢复，一般不建议执行此操作

### 举例

1. 删除数据库 db\_test

```
DROP DATABASE db_test;
```

### Keywords

DROP, DATABASE

### Best Practice



# DROP-TABLE

---

## DROP-TABLE

### Name

DROP TABLE

### 描述

该语句用于删除 table 。语法：

```
DROP TABLE [IF EXISTS] [db_name.]table_name [FORCE];
```

说明：

- 执行 DROP TABLE 一段时间内，可以通过 RECOVER 语句恢复被删除的表。详见 [RECOVER](#) 语句
- 如果执行 DROP TABLE FORCE，则系统不会检查该表是否存在未完成的事务，表将直接被删除并且不能被恢复，一般不建议执行此操作

### 举例

1. 删除一个 table

```
DROP TABLE my_table;
```

2. 如果存在，删除指定 database 的 table

```
DROP TABLE IF EXISTS example_db.my_table;
```

### Keywords

DROP, TABLE

### Best Practice

# DROP-INDEX

---

## DROP-INDEX

### Name

DROP INDEX

### 描述

该语句用于从一个表中删除指定名称的索引，目前仅支持bitmap 索引 语法：

```
DROP INDEX [IF EXISTS] index_name ON [db_name.]table_name;
```

### 举例

#### 1. 删除索引

```
DROP INDEX [IF NOT EXISTS] index_name ON table1 ;
```

### Keywords

DROP, INDEX

### Best Practice

# DROP-MATERIALIZED-VIEW

## DROP-MATERIALIZED-VIEW

### Name

DROP MATERIALIZED VIEW

### 描述

该语句用于删除物化视图。同步语法

语法：

```
DROP MATERIALIZED VIEW [IF EXISTS] mv_name ON table_name;
```

- 1. IF EXISTS: 如果物化视图不存在，不要抛出错误。如果不声明此关键字，物化视图不存在则报错。
- 2. mv\_name: 待删除的物化视图的名称。必填项。
- 3. table\_name: 待删除的物化视图所属的表名。必填项。

### 举例

表结构为

mysql> desc all\_type\_table all;

IndexName	Field	Type	Null	Key	Default	Extra
all_type_table	k1	TINYINT	Yes	true	N/A	
	k2	SMALLINT	Yes	false	N/A	NONE
	k3	INT	Yes	false	N/A	NONE
	k4	BIGINT	Yes	false	N/A	NONE
	k5	LARGEINT	Yes	false	N/A	NONE
	k6	FLOAT	Yes	false	N/A	NONE
	k7	DOUBLE	Yes	false	N/A	NONE
k1_sumk2	k1	TINYINT	Yes	true	N/A	
	k2	SMALLINT	Yes	false	N/A	SUM

- 1. 删除表 all\_type\_table 的名为 k1\_sumk2 的物化视图

```
drop materialized view k1_sumk2 on all_type_table;
```

物化视图被删除后的表结构

IndexName	Field	Type	Null	Key	Default	Extra
all_type_table	k1	TINYINT	Yes	true	N/A	
	k2	SMALLINT	Yes	false	N/A	NONE
	k3	INT	Yes	false	N/A	NONE
	k4	BIGINT	Yes	false	N/A	NONE
	k5	LARGEINT	Yes	false	N/A	NONE
	k6	FLOAT	Yes	false	N/A	NONE
	k7	DOUBLE	Yes	false	N/A	NONE

## 2. 删除表 all\_type\_table 中一个不存在的物化视图

```
drop materialized view k1_k2 on all_type_table;
ERROR 1064 (HY000): errCode = 2, detailMessage = Materialized view [k1_k2] does not exist in table [all_type_table]
```

删除请求直接报错

## 3. 删除表 all\_type\_table 中的物化视图 k1\_k2，不存在不报错。

```
drop materialized view if exists k1_k2 on all_type_table;
Query OK, 0 rows affected (0.00 sec)
```

存在则删除，不存在则不报错。

## Keywords

DROP, MATERIALIZED, VIEW

## Best Practice

# DROP-FUNCTION

## 描述

删除一个自定义函数。

## 语法

```
DROP [GLOBAL] <function_name> (<arg_type>)
```

## 必选参数

### 1. <function\_name>

指定要删除的函数的名字。

该函数名称需要与建立函数时的函数名称完全一致

### 2. <arg\_type>

指定要删除函数的参数列表。

参数列表对应位置需要填写对应位置参数的数据类型

## 可选参数

### 1.GLOBAL

GLOBAL 为选填项

若填写 GLOBAL 则为全局搜索该函数并删除

若不填写 GLOABL 则只在当前数据库下搜索该函数并删除

## 权限控制

执行此 SQL 命令的用户必须至少具有以下权限：

权限（Privilege）	对象（Object）	说明（Notes）
ADMIN_PRIV	函数（自定义函数）	DROP 属于管理操作

## 注意事项

- 函数的名字、参数类型完全一致才能够被删除

## 示例

```
DROP FUNCTION my_add(INT, INT)
```

```
DROP GLOBAL FUNCTION my_add(INT, INT)
```

# DROP-FILE

---

## DROP-FILE

### Name

DROP FILE

### 描述

该语句用于删除一个已上传的文件。

语法：

```
DROP FILE "file_name" [FROM database]
[properties]
```

说明：

- file\_name: 文件名。
- database: 文件归属的某一个 db，如果没有指定，则使用当前 session 的 db。
- properties 支持以下参数：
  - catalog: 必须。文件所属分类。

### 举例

1. 删除文件 ca.pem

```
DROP FILE "ca.pem" properties("catalog" = "kafka");
```

### Keywords

DROP, FILE

### Best Practice

# DROP-POLICY

---

## DROP-POLICY

### Name

DROP POLICY

### 描述

删除安全策略

### 行安全策略

语法：

1. 删除行安全策略

```
DROP ROW POLICY test_row_policy_1 on table1 [FOR user| ROLE role];
```

2. 删除存储策略

```
DROP STORAGE POLICY policy_name1
```

### 举例

1. 删除 table1 的 test\_row\_policy\_1

```
DROP ROW POLICY test_row_policy_1 on table1
```

2. 删除 table1 作用于 test 的 test\_row\_policy\_1 行安全策略

```
DROP ROW POLICY test_row_policy_1 on table1 for test
```

3. 删除 table1 作用于 role1 的 test\_row\_policy\_1 行安全策略

```
DROP ROW POLICY test_row_policy_1 on table1 for role role1
```

4. 删除名字为policy\_name1的存储策略

```
DROP STORAGE POLICY policy_name1
```



**Keywords**

DROP, POLICY

**Best Practice**

# DROP-ENCRYPT-KEY

---

## DROP-ENCRYPTKEY

### Name

DROP ENCRYPTKEY

### 描述

语法：

```
DROP ENCRYPTKEY key_name
```

参数说明：

- key\_name: 要删除密钥的名字, 可以包含数据库的名字。比如：db1.my\_key。

删除一个自定义密钥。密钥的名字完全一致才能够被删除。

执行此命令需要用户拥有 ADMIN 权限。

### 举例

1. 删除掉一个密钥

```
DROP ENCRYPTKEY my_key;
```

### Keywords

```
DROP, ENCRYPT, KEY
```

### Best Practice

# DROP-RESOURCE

---

## DROP-RESOURCE

### Name

DROP RESOURCE

### 描述

该语句用于删除一个已有的资源。仅 root 或 admin 用户可以删除资源。语法：

```
DROP RESOURCE 'resource_name'
```

注意：正在使用的 ODBC/S3 资源无法删除。

### 举例

1. 删除名为 spark0 的 Spark 资源：

```
DROP RESOURCE 'spark0';
```

### Keywords

DROP, RESOURCE

### Best Practice

# DROP-WORKLOAD-GROUP

---

## DROP-WORKLOAD-GROUP

### Name

DROP WORKLOAD GROUP

### 描述

该语句用于删除资源组。

```
DROP WORKLOAD GROUP [IF EXISTS] 'rg_name'
```

### 举例

1. 删除名为 g1 的资源组：

```
drop workload group if exists g1;
```

### Keywords

```
DROP, WORKLOAD, GROUP
```

### Best Practice

# DROP-SQL-BLOCK-RULE

---

## DROP-SQL-BLOCK-RULE

### Name

DROP SQL BLOCK RULE

### 描述

删除SQL阻止规则，支持多规则，以,隔开

语法：

```
DROP SQL_BLOCK_RULE test_rule1,...
```

### 举例

1. 删除test\_rule1、test\_rule2阻止规则

```
mysql> DROP SQL_BLOCK_RULE test_rule1,test_rule2;
Query OK, 0 rows affected (0.00 sec)
```

### Keywords

DROP, SQL\_BLOCK\_RULE

### Best Practice

# TRUNCATE-TABLE

---

## TRUNCATE-TABLE

### Name

TRUNCATE TABLE

### 描述

该语句用于清空指定表和分区的数据 语法：

```
TRUNCATE TABLE [db.]tbl[PARTITION(p1, p2, ...)];
```

说明：

- 该语句清空数据，但保留表或分区。
- 不同于 DELETE，该语句只能整体清空指定的表或分区，不能添加过滤条件。
- 不同于 DELETE，使用该方式清空数据不会对查询性能造成影响。
- 该操作删除的数据不可恢复。
- 使用该命令时，表状态需为 NORMAL，即不允许正在进行 SCHEMA CHANGE 等操作。
- 该命令可能会导致正在进行的导入失败。

### 举例

1. 清空 example\_db 下的表 tbl

```
TRUNCATE TABLE example_db.tbl;
```

2. 清空表 tbl 的 p1 和 p2 分区

```
TRUNCATE TABLE tbl PARTITION(p1, p2);
```

### Keywords

TRUNCATE, TABLE

### Best Practice

# CREATE-REPOSITORY

---

## CREATE-REPOSITORY

### Name

CREATE REPOSITORY

### 描述

该语句用于创建仓库。仓库用于属于备份或恢复。仅 root 或 superuser 用户可以创建仓库。

语法：

```
CREATE [READ ONLY] REPOSITORY `repo_name`
WITH [S3|hdfs]
ON LOCATION `repo_location`
PROPERTIES ("key"="value", ...);
```

说明：

- 如果是只读仓库，则只能在仓库上进行恢复。如果不是，则可以进行备份和恢复操作。
- 根据 S3、HDFS 的不同类型，PROPERTIES 有所不同，具体见示例。
- ON LOCATION ,如果是 S3 ,这里后面跟的是 Bucket Name。

### 举例

1. 创建名为 s3\_repo 的仓库。

```
CREATE REPOSITORY `s3_repo`
WITH S3
ON LOCATION "s3://s3-repo"
PROPERTIES
(
 "s3.endpoint" = "http://s3-REGION.amazonaws.com",
 "s3.access_key" = "AWS_ACCESS_KEY",
 "s3.secret_key"="AWS_SECRET_KEY",
 "s3.region" = "REGION"
);
```

2. 创建名为 hdfs\_repo 的仓库。

```
CREATE REPOSITORY `hdfs_repo`
WITH hdfs
ON LOCATION "hdfs://hadoop-name-node:54310/path/to/repo/"
PROPERTIES
(
 "fs.defaultFS"="hdfs://hadoop-name-node:54310",
 "hadoop.username"="user"
);
```

### 3. 创建名为 minio\_repo 的仓库。

```
CREATE REPOSITORY `minio_repo`
WITH S3
ON LOCATION "s3://minio_repo"
PROPERTIES
(
 "s3.endpoint" = "http://minio.com",
 "s3.access_key" = "MINIO_USER",
 "s3.secret_key"="MINIO_PASSWORD",
 "s3.region" = "REGION",
 "use_path_style" = "true"
);
```

### 4. 使用临时密钥创建名为 minio\_repo 的仓库

```
CREATE REPOSITORY `minio_repo`
WITH S3
ON LOCATION "s3://minio_repo"
PROPERTIES
(
 "s3.endpoint" = "AWS_ENDPOINT",
 "s3.access_key" = "AWS_TEMP_ACCESS_KEY",
 "s3.secret_key" = "AWS_TEMP_SECRET_KEY",
 "s3.session_token" = "AWS_TEMP_TOKEN",
 "s3.region" = "AWS_REGION"
)
```

### 5. 使用腾讯云 COS 创建仓库

```
CREATE REPOSITORY `cos_repo`
WITH S3
ON LOCATION "s3://bucket1/"
PROPERTIES
(
 "s3.access_key" = "ak",
 "s3.secret_key" = "sk",
 "s3.endpoint" = "http://cos.ap-beijing.myqcloud.com",
 "s3.region" = "ap-beijing"
);
```

## Keywords

CREATE, REPOSITORY

## Best Practice

1. 一个集群可以创建过多个仓库。只有拥有 ADMIN 权限的用户才能创建仓库。
2. 任何用户都可以通过 [SHOW REPOSITORIES](#) 命令查看已经创建的仓库。
3. 在做数据迁移操作时，需要在源集群和目的集群创建完全相同的仓库，以便目的集群可以通过这个仓库，查看到源集群备份的数据快照。



# DROP-REPOSITORY

---

## DROP-REPOSITORY

### Name

DROP REPOSITORY

### 描述

该语句用于删除一个已创建的仓库。仅 root 或 superuser 用户可以删除仓库。

语法：

```
DROP REPOSITORY `repo_name`;
```

说明：

- 删除仓库，仅仅是删除该仓库在 Palo 中的映射，不会删除实际的仓库数据。删除后，可以再次通过指定相同的 LOCATION 映射到该仓库。

### 举例

- 删除名为 bos\_repo 的仓库：

```
DROP REPOSITORY `bos_repo`;
```

### Keywords

DROP, REPOSITORY

### Best Practice

# BACKUP

## BACKUP

### Name

BACKUP

### 描述

该语句用于备份指定数据库下的数据。该命令为异步操作。

仅 root 或 superuser 用户可以创建仓库。

提交成功后，需通过 SHOW BACKUP 命令查看进度。仅支持备份 OLAP 类型的表。

语法：

```
BACKUP SNAPSHOT [db_name].{snapshot_name}
TO `repository_name`
[ON|EXCLUDE] (
 `table_name` [PARTITION (`p1`, ...)],
 ...
)
PROPERTIES ("key"="value", ...);
```

说明：

- 同一数据库下只能有一个正在执行的 BACKUP 或 RESTORE 任务。
- ON 子句中标识需要备份的表和分区。如果不指定分区，则默认备份该表的所有分区
- EXCLUDE 子句中标识不需要备份的表和分区。备份除了指定的表或分区之外这个数据库中所有表的所有分区数据。
- PROPERTIES 目前支持以下属性：
  - “type” = “full”：表示这是一次全量更新（默认）
  - “timeout” = “3600”：任务超时时间，默认为一天。单位秒。

### 举例

1. 全量备份 example\_db 下的表 example\_tbl 到仓库 example\_repo 中：

```
BACKUP SNAPSHOT example_db.snapshot_label1
TO example_repo
ON (example_tbl)
PROPERTIES ("type" = "full");
```

2. 全量备份 example\_db 下，表 example\_tbl 的 p1, p2 分区，以及表 example\_tbl2 到仓库 example\_repo 中：

```
BACKUP SNAPSHOT example_db.snapshot_label2
TO example_repo
ON
(
 example_tbl PARTITION (p1,p2),
 example_tbl2
);
```

3. 全量备份 example\_db 下除了表 example\_tbl 的其他所有表到仓库 example\_repo 中：

```
BACKUP SNAPSHOT example_db.snapshot_label3
TO example_repo
EXCLUDE (example_tbl);
```

4. 全量备份 example\_db 下的表到仓库 example\_repo 中：

```
BACKUP SNAPSHOT example_db.snapshot_label3
TO example_repo;
```

## Keywords

BACKUP

## Best Practice

1. 同一个数据库下只能进行一个备份操作。
2. 备份操作会备份指定表或分区的基础表及同步物化视图[物化视图](#)，并且仅备份一副本，[异步物化视图](#) 当前未支持。
3. 备份操作的效率

备份操作的效率取决于数据量、Compute Node 节点数量以及文件数量。备份数据分片所在的每个 Compute Node 都会参与备份操作的上传阶段。节点数量越多，上传的效率越高。

文件数据量只涉及到的分片数，以及每个分片中文件的数量。如果分片非常多，或者分片内的小文件较多，都可能增加备份操作的时间。

# CANCEL-BACKUP

---

## CANCEL-BACKUP

### Name

CANCEL BACKUP

### 描述

该语句用于取消一个正在进行的 BACKUP 任务。

语法：

```
CANCEL BACKUP FROM db_name;
```

### 举例

1. 取消 example\_db 下的 BACKUP 任务。

```
CANCEL BACKUP FROM example_db;
```

### Keywords

```
CANCEL, BACKUP
```

### Best Practice

# RESTORE

## RESTORE

### Name

RESTORE

### 描述

该语句用于将之前通过 BACKUP 命令备份的数据，恢复到指定数据库下。该命令为异步操作。提交成功后，需通过 SHOW RESTORE 命令查看进度。仅支持恢复 OLAP 类型的表。

语法：

```
RESTORE SNAPSHOT [db_name].[snapshot_name]
FROM `repository_name`
[ON|EXCLUDE] (
 `table_name` [PARTITION (`p1`, ...)] [AS `tbl_alias`],
 ...
)
PROPERTIES ("key"="value", ...);
```

说明： - 同一数据库下只能有一个正在执行的 BACKUP 或 RESTORE 任务。 - ON 子句中标识需要恢复的表和分区。如果不指定分区，则默认恢复该表的所有分区。所指定的表和分区必须已存在于仓库备份中。 - EXCLUDE 子句中标识不需要恢复的表和分区。除了所指定的表或分区之外仓库中所有其他表的所有分区将被恢复。 - 可以通过 AS 语句将仓库中备份的表名恢复为新的表。但新表名不能已存在于数据库中。分区名称不能修改。 - 可以将仓库中备份的表恢复替换数据库中已有的同名表，但须保证两张表的表结构完全一致。表结构包括：表名、列、分区、Rollup 等等。 - 可以指定恢复表的部分分区，系统会检查分区 Range 或者 List 是否能够匹配。 - PROPERTIES 目前支持以下属性： - “backup\_timestamp” = “2018-05-04-16-45-08”：指定了恢复对应备份的哪个时间版本，必填。该信息可以通过 SHOW SNAPSHOT ON repo; 语句获得。 - “replication\_num” = “3”：指定恢复的表或分区的副本数。默认为 3。若恢复已存在的表或分区，则副本数必须和已存在表或分区的副本数相同。同时，必须有足够的 host 容纳多个副本。该功能自 Apache Doris 1.2 版本起支持。

- “reserve\_replica” = “true”：默认为 false。当该属性为 true 时，会忽略 replication\_num 属性，恢复的表或分区的副本数将与备份之前一样。支持多个表或表内多个分区有不同的副本数。该功能自 Apache Doris 1.2 版本起支持。
- “reserve\_dynamic\_partition\_enable” = “true”：默认为 false。当该属性为 true 时，恢复的表会保留该表备份之前的’dynamic\_partition\_enable’属性值。该值不为 true 时，则恢复出来的表的’dynamic\_partition\_enable’属性值会设置为 false。
- “timeout” = “3600”：任务超时时间，默认为一天。单位秒。
- “meta\_version” = 40：使用指定的 meta\_version 来读取之前备份的元数据。注意，该参数作为临时方案，仅用于恢复老版本 Doris 备份的数据。最新版本的备份数据中已经包含 meta version，无需再指定。该功能自 Apache Doris 2.0.15 版本起支持
- “clean\_tables”：表示是否清理不属于恢复目标的表。例如，如果恢复之前的目标数据库有备份中不存在的表，指定 clean\_tables 就可以在恢复期间删除这些额外的表并将其移入回收站。

- “clean\_partitions”：表示是否清理不属于恢复目标的分区。例如，如果恢复之前的目标表有备份中不存在的分区，指定 clean\_partitions 就可以在恢复期间删除这些额外的分区并将其移入回收站。

## 举例

1. 从 example\_repo 中恢复备份 snapshot\_1 中的表 backup\_tbl 到数据库 example\_db1，时间版本为“2018-05-04-16-45-08”。恢复为 1 个副本：

```
RESTORE SNAPSHOT example_db1.`snapshot_1`
FROM `example_repo`
ON (`backup_tbl`)
PROPERTIES
(
 "backup_timestamp"="2018-05-04-16-45-08",
 "replication_num" = "1"
);
```

2. 从 example\_repo 中恢复备份 snapshot\_2 中的表 backup\_tbl 的分区 p1,p2，以及表 backup\_tbl2 到数据库 example\_db1，并重命名为 new\_tbl，时间版本为“2018-05-04-17-11-01”。默认恢复为 3 个副本：

```
RESTORE SNAPSHOT example_db1.`snapshot_2`
FROM `example_repo`
ON
(
 `backup_tbl` PARTITION (`p1`, `p2`),
 `backup_tbl2` AS `new_tbl`
)
PROPERTIES
(
 "backup_timestamp"="2018-05-04-17-11-01"
);
```

3. 从 example\_repo 中恢复备份 snapshot\_3 中除了表 backup\_tbl 的其他所有表到数据库 example\_db1，时间版本为“2018-05-04-18-12-18”。

```
RESTORE SNAPSHOT example_db1.`snapshot_3`
FROM `example_repo`
EXCLUDE (`backup_tbl`)
PROPERTIES
(
 "backup_timestamp"="2018-05-04-18-12-18"
);
```

## Keywords

RESTORE

## Best Practice

1. 同一数据库下只能有一个正在执行的恢复操作。

2. 可以将仓库中备份的表恢复替换数据库中已有的同名表，但须保证两张表的表结构完全一致。表结构包括：表名、列、分区、物化视图等等。
3. 当指定恢复表的部分分区时，系统会检查分区范围是否能够匹配。
4. 恢复操作的效率：

在集群规模相同的情况下，恢复操作的耗时基本等同于备份操作的耗时。如果想加速恢复操作，可以先通过设置 `replication_num` 参数，仅恢复一个副本，之后在通过调整副本数 [ALTER TABLE PROPERTY](#)，将副本补齐。

# CANCEL-RESTORE

---

## CANCEL-RESTORE

### Name

CANCEL RESTORE

### 描述

该语句用于取消一个正在进行的 RESTORE 任务。

语法：

```
CANCEL RESTORE FROM db_name;
```

注意：

- 当取消处于 COMMIT 或之后阶段的恢复左右时，可能导致被恢复的表无法访问。此时只能通过再次执行恢复作业进行数据恢复。

### 举例

- 取消 example\_db 下的 RESTORE 任务。

```
CANCEL RESTORE FROM example_db;
```

### Keywords

```
CANCEL, RESTORE
```

### Best Practice



# STREAM-LOAD

---

## STREAM-LOAD

### Name

STREAM LOAD

### 描述

stream-load: load data to table in streaming

```
curl --location-trusted -u user:passwd [-H "..."] -T data.file -XPUT
http://fe_host:http_port/api/{db}/{table}/_stream_load
```

该语句用于向指定的 table 导入数据，与普通 Load 区别是，这种导入方式是同步导入。

这种导入方式仍然能够保证一批导入任务的原子性，要么全部数据导入成功，要么全部失败。

该操作会同时更新和此 base table 相关的 rollup table 的数据。

这是一个同步操作，整个数据导入工作完成后返回给用户导入结果。

当前支持 HTTP chunked 与非 chunked 上传两种方式，对于非 chunked 方式，必须要有 Content-Length 来标示上传内容长度，这样能够保证数据的完整性。

另外，用户最好设置 Expect Header 字段内容 100-continue，这样可以在某些出错场景下避免不必要的数据传输。

参数介绍：用户可以通过 HTTP 的 Header 部分来传入导入参数

1. label: 一次导入的标签，相同标签的数据无法多次导入。用户可以通过指定 Label 的方式来避免一份数据重复导入的问题。

当前 Doris 内部保留 30 分钟内最近成功的 label。

2. column\_separator: 用于指定导入文件中的列分隔符，默认为\t。如果是不可见字符，则需要加\x作为前缀，使用十六进制来表示分隔符。

如 hive 文件的分隔符\x01，需要指定为-H "column\_separator:\x01"。

可以使用多个字符的组合作为列分隔符。

3. line\_delimiter: 用于指定导入文件中的换行符，默认为\n。可以使用做多个字符的组合作为换行符。

4. columns: 用于指定导入文件中的列和 table 中的列的对应关系。如果源文件中的列正好对应表中的内容，那么是不需要指定这个字段的内容的。

如果源文件与表 schema 不对应，那么需要这个字段进行一些数据转换。这里有两种形式 column，一种是直接对应导入文件中的字段，直接使用字段名表示：

一种是衍生列，语法为 `column_name = expression`。举几个例子帮助理解。

例 1: 表中有 3 个列“c1, c2, c3”，源文件中的三个列一次对应的是“c3,c2,c1”；那么需要指定-H “columns: c3, c2, c1”

例2: 表中有3个列“c1, c2, c3”，源文件中前三列依次对应，但是有多余1列；那么需要指定-H “columns: c1, c2, c3, xxx”；

最后一个列随意指定个名称占位即可

例3: 表中有3个列“year, month, day”三个列，源文件中只有一个时间列，为“2018-06-01 01:02:03”格式；

那么可以指定-H “columns: col, year = year(col), month=month(col), day=day(col)”完成导入

5. where: 用于抽取部分数据。用户如果有需要将不需要的数据过滤掉，那么可以通过设定这个选项来达到。

例 1: 只导入大于 k1 列等于 20180601 的数据，那么可以在导入时候指定-H “where: k1 = 20180601”

6. max\_filter\_ratio: 最大容忍可过滤（数据不规范等原因）的数据比例。默认零容忍。数据不规范不包括通过 where 条件过滤掉的行。

7. partitions: 用于指定这次导入所设计的 partition。如果用户能够确定数据对应的 partition，推荐指定该项。不满足这些分区的数据将被过滤掉。

比如指定导入到 p1, p2 分区，-H “partitions: p1, p2”

8. timeout: 指定导入的超时时间。单位秒。默认是 600 秒。可设置范围为 1 秒 ~ 259200 秒。

9. strict\_mode: 用户指定此次导入是否开启严格模式，默认为关闭。开启方式为 -H “strict\_mode: true”。

10. timezone: 指定本次导入所使用的时区。默认为东八区。在本次导入事务中，该变量起到了替代 session variable time\_zone 的作用。详情请见[最佳实践](#)中“涉及时区的导入”一节。

11. exec\_mem\_limit: 导入内存限制。默认为 2GB。单位为字节。

12. format: 指定导入数据格式，支持 csv、json、csv\_with\_names(支持 csv 文件行首过滤)、csv\_with\_names\_and\_types(支持 csv 文件前两行过滤)、parquet、orc，默认是 csv。

## 提示

该功能自 Apache Doris 1.2 版本起支持

13. jsonpaths: 导入 json 方式分为：简单模式和匹配模式。

简单模式：没有设置 jsonpaths 参数即为简单模式，这种模式下要求 json 数据是对象类型，例如：

```
{"k1":1, "k2":2, "k3":"hello"}, 其中 k1, k2, k3 是列名字。
```

匹配模式：用于 json 数据相对复杂，需要通过 jsonpaths 参数匹配对应的 value。

14. `strip_outer_array`: 布尔类型, 为 `true` 表示 json 数据以数组对象开始且将数组对象中进行展平, 默认值是 `false`。例如: `[ {"k1" : 1, "v1" : 2}, {"k1" : 3, "v1" : 4} ]` 当 `strip_outer_array` 为 `true`, 最后导入到 doris 中会生成两行数据。
15. `json_root`: `json_root` 为合法的 jsonpath 字符串, 用于指定 json document 的根节点, 默认值为 `""`。
16. `merge_type`: 数据的合并类型, 一共支持三种类型 `APPEND`、`DELETE`、`MERGE` 其中, `APPEND` 是默认值, 表示这批数据全部需要追加到现有数据中, `DELETE` 表示删除与这批数据 `key` 相同的所有行, `MERGE` 语义 需要与 `DELETE` 条件联合使用, 表示满足 `DELETE` 条件的数据按照 `DELETE` 语义处理其余的按照 `APPEND` 语义处理, 示例: `-H "merge_type: MERGE" -H "delete: flag=1"`
17. `delete`: 仅在 `MERGE` 下有意义, 表示数据的删除条件
18. `function_column.sequence_col`: 只适用于 `UNIQUE_KEYS`, 相同 `key` 列下, 保证 `value` 列按照 `source_sequence` 列进行 `REPLACE`, `source_sequence` 可以是数据源中的列, 也可以是表结构中的一列。
19. `fuzzy_parse`: 布尔类型, 为 `true` 表示 json 将以第一行为 `schema` 进行解析, 开启这个选项可以提高 json 导入效率, 但是要求所有 json 对象的 `key` 的顺序和第一行一致, 默认为 `false`, 仅用于 json 格式
20. `num_as_string`: 布尔类型, 为 `true` 表示在解析 json 数据时会把数字类型转为字符串, 然后在确保不会出现精度丢失的情况下进行导入。
21. `read_json_by_line`: 布尔类型, 为 `true` 表示支持每行读取一个 json 对象, 默认值为 `false`。
22. `send_batch_parallelism`: 整型, 用于设置发送批处理数据的并行度, 如果并行度的值超过 BE 配置中的 `max_send_batch_parallelism_per_job`, 那么作为协调点的 BE 将使用 `max_send_batch_parallelism_per_job` 的值。
23. `hidden_columns`: 用于指定导入数据中包含的隐藏列, 在 Header 中不包含 `columns` 时生效, 多个 `hidden column` 用逗号分割。

```
```  
hidden_columns: __DORIS_DELETE_SIGN__, __DORIS_SEQUENCE_COL__  
系统会使用用户指定的数据导入数据。在上述用例中, 导入数据中最后一列数据为 __DORIS_SEQUENCE_COL__。  
```
```

## 提示

该功能自 Apache Doris 1.2 版本起支持

24. `load_to_single_tablet`: 布尔类型, 为 `true` 表示支持一个任务只导入数据到对应分区的一个 `tablet`, 默认值为 `false`, 该参数只允许在对带有 `random` 分桶的 `olap` 表导数的时候设置。
25. `compress_type`: 指定文件的压缩格式。目前只支持 `csv` 文件的压缩。支持 `gz`, `lzo`, `bz2`, `lz4`, `lzop`, `deflate` 压缩格式。
26. `trim_double_quotes`: 布尔类型, 默认值为 `false`, 为 `true` 时表示裁剪掉 `csv` 文件每个字段最外层的双引号。

27. skip\_lines: 整数类型，默认值为 0，含义为跳过 csv 文件的前几行。当设置 format 设置为 csv\_with\_names 或、csv\_with\_names\_and\_types 时，该参数会失效。

28. comment: 字符串类型，默认值为空。给任务增加额外的信息。

## 提示

该功能自 Apache Doris 1.2.3 版本起支持

29. enclose: 包围符。当 csv 数据字段中含有行分隔符或列分隔符时，为防止意外截断，可指定单字节字符作为包围符起到保护作用。例如列分隔符为“，”，包围符为“”“”，数据为“a,b,c”，则“b,c”会被解析为一个字段。注意：当 enclose 设置为“”时，trim\_double\_quotes 一定要设置为 true。

30. escape 转义符。用于转义在字段中出现的与包围符相同的字符。例如数据为“a,b,c”，包围符为“”“”，希望“b,c”被作为一个字段解析，则需要指定单字节转义符，例如 \，然后将数据修改为 a,b,\'c'。

## 举例

1. 将本地文件'testData'中的数据导入到数据库'testDb'中'testTbl'的表，使用 Label 用于去重。指定超时时间为 100 秒

```
curl --location-trusted -u root -H "label:123" -H "timeout:100" -T testData
http://host:port/api/testDb/testTbl/_stream_load
```

2. 将本地文件'testData'中的数据导入到数据库'testDb'中'testTbl'的表，使用 Label 用于去重，并且只导入 k1 等于 20180601 的数据

```
curl --location-trusted -u root -H "label:123" -H "where: k1=20180601" -T testData
http://host:port/api/testDb/testTbl/_stream_load
```

3. 将本地文件'testData'中的数据导入到数据库'testDb'中'testTbl'的表，允许 20% 的错误率（用户是 default\_cluster 中的）

```
curl --location-trusted -u root -H "label:123" -H "max_filter_ratio:0.2" -T testData
http://host:port/api/testDb/testTbl/_stream_load
```

4. 将本地文件'testData'中的数据导入到数据库'testDb'中'testTbl'的表，允许 20% 的错误率，并且指定文件的列名（用户是 default\_cluster 中的）

```
curl --location-trusted -u root -H "label:123" -H "max_filter_ratio:0.2" -H "columns: k2, k1, v1" -T
testData http://host:port/api/testDb/testTbl/_stream_load
```

5. 将本地文件'testData'中的数据导入到数据库'testDb'中'testTbl'的表中的 p1, p2 分区，允许 20% 的错误率。

```
curl --location-trusted -u root -H "label:123" -H "max_filter_ratio:0.2" -H "partitions: p1, p2" -T
testData http://host:port/api/testDb/testTbl/_stream_load
```

## 6. 使用 streaming 方式导入（用户是 defalut\_cluster 中的）

```
seq 1 10 | awk '{OFS="\t"}{print $1, $1 * 10}' | curl --location-trusted -u root -T -
http://host:port/api/testDb/testTbl/_stream_load
```

## 7. 导入含有 HLL 列的表，可以是表中的列或者数据中的列用于生成 HLL 列，也可使用 hll\_empty 补充数据中没有的列

```
curl --location-trusted -u root -H "columns: k1, k2, v1=hll_hash(k1), v2=hll_empty()" -T testData
http://host:port/api/testDb/testTbl/_stream_load
```

## 8. 导入数据进行严格模式过滤，并设置时区为 Africa/Abidjan

```
curl --location-trusted -u root -H "strict_mode: true" -H "timezone: Africa/Abidjan" -T testData
http://host:port/api/testDb/testTbl/_stream_load
```

## 9. 导入含有 BITMAP 列的表，可以是表中的列或者数据中的列用于生成 BITMAP 列，也可以使用 bitmap\_empty 填充空的 Bitmap

```
curl --location-trusted -u root -H "columns: k1, k2, v1=to_bitmap(k1), v2=bitmap_empty()" -T testData
http://host:port/api/testDb/testTbl/_stream_load
```

## 10. 简单模式，导入 JSON 数据

表结构：

```
`category` varchar(512) NULL COMMENT "",
`author` varchar(512) NULL COMMENT "",
`title` varchar(512) NULL COMMENT "",
`price` double NULL COMMENT ""
```

JSON 数据格式：

```
{"category":"C++","author":"avc","title":"C++ primer","price":895}
```

导入命令：

```
curl --location-trusted -u root -H "label:123" -H "format: json" -T testData
http://host:port/api/testDb/testTbl/_stream_load
```

为了提升吞吐量，支持一次性导入多条json数据，每行为一个json对象，默认使用\n作为换行符，需要将 read\_json\_by\_line 设置为 true，json 数据格式如下：

```
{"category":"C++","author":"avc","title":"C++ primer","price":89.5}
{"category":"Java","author":"avc","title":"Effective Java","price":95}
{"category":"Linux","author":"avc","title":"Linux kernel","price":195}
```

## 11. 匹配模式，导入 JSON 数据

JSON 数据格式:

```
[
 {"category":"xuxb111","author":"1avc","title":"SayingsoftheCentury","price":895},
 {"category":"xuxb222","author":"2avc","title":"SayingsoftheCentury","price":895},
 {"category":"xuxb333","author":"3avc","title":"SayingsoftheCentury","price":895}
]
```

通过指定jsonpath进行精准导入, 例如只导入category、author、price三个属性

```
curl --location-trusted -u root -H "columns: category, price, author" -H "label:123" -H "format: json" -H "jsonpaths: [\"$.category\", \"$.price\", \"$.author\"]" -H "strip_outer_array: true" -T testData http://host:port/api/testDb/testTbl/_stream_load
```

说明: 1) 如果json数据是以数组开始, 并且数组中每个对象是一条记录, 则需要将strip\_outer\_array设置成true, 表示展平数组。2) 如果json数据是以数组开始, 并且数组中每个对象是一条记录, 在设置jsonpath时, 我们的ROOT节点实际上是数组中对象。

## 12. 用户指定 JSON 根节点

JSON 数据格式:

```
{
 "RECORDS": [
 {"category":"11","title":"SayingsoftheCentury","price":895,"timestamp":1589191587},
 {"category":"22","author":"2avc","price":895,"timestamp":1589191487},
 {"category":"33","author":"3avc","title":"SayingsoftheCentury","timestamp":1589191387}
]
}
```

通过指定jsonpath进行精准导入, 例如只导入category、author、price三个属性

```
curl --location-trusted -u root -H "columns: category, price, author" -H "label:123" -H "format: json" -H "jsonpaths: [\"$.category\", \"$.price\", \"$.author\"]" -H "strip_outer_array: true" -H "json_root: $.RECORDS" -T testData http://host:port/api/testDb/testTbl/_stream_load
```

## 13. 删除与这批导入 key 相同的数据

```
curl --location-trusted -u root -H "merge_type: DELETE" -T testData http://host:port/api/testDb/testTbl/_stream_load
```

## 14. 将这批数据中与 flag 列为 ture 的数据相匹配的列删除, 其他行正常追加

```
curl --location-trusted -u root: -H "column_separator:," -H "columns: siteid, citycode, username, pv, flag" -H "merge_type: MERGE" -H "delete: flag=1" -T testData http://host:port/api/testDb/testTbl/_stream_load
```

## 15. 导入数据到含有 sequence 列的 UNIQUE\_KEYS 表中

```
curl --location-trusted -u root -H "columns: k1,k2,source_sequence,v1,v2" -H "function_column.sequence_col: source_sequence" -T testData http://host:port/api/testDb/testTbl/_stream_load
```

## 16. CSV 文件行首过滤导入

文件数据：

```
id,name,age
1,doris,20
2,flink,10
```

通过指定format=csv\_with\_names过滤首行导入

```
curl --location-trusted -u root -T test.csv -H "label:1" -H "format:csv_with_names" -H "column_separator:," http://host:port/api/testDb/testTbl/_stream_load
```

## 17. 导入数据到表字段含有 DEFAULT CURRENT\_TIMESTAMP 的表中

表结构：

```
`id` bigint(30) NOT NULL,
`order_code` varchar(30) DEFAULT NULL COMMENT '',
`create_time` datetime(3) DEFAULT CURRENT_TIMESTAMP
```

JSON 数据格式：

```
{"id":1,"order_Code":"avc"}
```

导入命令：

```
curl --location-trusted -u root -T test.json -H "label:1" -H "format:json" -H 'columns: id, order_code, create_time=CURRENT_TIMESTAMP()' http://host:port/api/testDb/testTbl/_stream_load
```

## Keywords

STREAM, LOAD

## Best Practice

### 1. 查看导入任务状态

Stream Load 是一个同步导入过程，语句执行成功即代表数据导入成功。导入的执行结果会通过 HTTP 返回值同步返回。并以 JSON 格式展示。示例如下：

```
{
 "TxnId": 17,
 "Label": "707717c0-271a-44c5-be0b-4e71bfeacaa5",
 "Status": "Success",
 "Message": "OK",
 "NumberTotalRows": 5,
 "NumberLoadedRows": 5,
 "NumberFilteredRows": 0,
 "NumberUnselectedRows": 0,
 "LoadBytes": 28,
 "LoadTimeMs": 27,
```

```
"BeginTxnTimeMs": 0,
"StreamLoadPutTimeMs": 2,
"ReadDataTimeMs": 0,
"WriteDataTimeMs": 3,
"CommitAndPublishTimeMs": 18
}
```

下面主要解释了 Stream load 导入结果参数：

- TxnId：导入的事务 ID。用户可不感知。
- Label：导入 Label。由用户指定或系统自动生成。
- Status：导入完成状态。

“Success”：表示导入成功。

“Publish Timeout”：该状态也表示导入已经完成，只是数据可能会延迟可见，无需重试。

“Label Already Exists”：Label 重复，需更换 Label。

“Fail”：导入失败。

- ExistingJobStatus：已存在的 Label 对应的导入作业的状态。

这个字段只有在当 Status 为 “Label Already Exists” 时才会显示。用户可以通过这个状态，知晓已存在 Label 对应的导入作业的状态。“RUNNING” 表示作业还在执行，“FINISHED” 表示作业成功。

- Message：导入错误信息。
- NumberTotalRows：导入总处理的行数。
- NumberLoadedRows：成功导入的行数。
- NumberFilteredRows：数据质量不合格的行数。
- NumberUnselectedRows：被 where 条件过滤的行数。
- LoadBytes：导入的字节数。
- LoadTimeMs：导入完成时间。单位毫秒。
- BeginTxnTimeMs：向 Fe 请求开始一个事务所花费的时间，单位毫秒。
- StreamLoadPutTimeMs：向 Fe 请求获取导入数据执行计划所花费的时间，单位毫秒。
- ReadDataTimeMs：读取数据所花费的时间，单位毫秒。
- WriteDataTimeMs：执行写入数据操作所花费的时间，单位毫秒。
- CommitAndPublishTimeMs：向 Fe 请求提交并且发布事务所花费的时间，单位毫秒。
- ErrorURL：如果有数据质量问题，通过访问这个 URL 查看具体错误行。



注意：由于 Stream load 是同步的导入方式，所以并不会在 Doris 系统中记录导入信息，用户无法异步的通过查看导入命令看到 Stream load。使用时需监听创建导入请求的返回值获取导入结果。

## 2. 如何正确提交 Stream Load 作业和处理返回结果。

Stream Load 是同步导入操作，因此用户需同步等待命令的返回结果，并根据返回结果决定下一步处理方式。

用户首要关注的是返回结果中的 Status 字段。

如果为 Success，则一切正常，可以进行之后的其他操作。

如果返回结果出现大量的 Publish Timeout，则可能说明目前集群某些资源（如 IO）紧张导致导入的数据无法最终生效。Publish Timeout 状态的导入任务已经成功，无需重试，但此时建议减缓或停止新导入任务的提交，并观察集群负载情况。

如果返回结果为 Fail，则说明导入失败，需根据具体原因查看问题。解决后，可以使用相同的 Label 重试。

在某些情况下，用户的 HTTP 连接可能会异常断开导致无法获取最终的返回结果。此时可以使用相同的 Label 重新提交导入任务，重新提交的任务可能有如下结果：

1. Status 状态为 Success, Fail 或者 Publish Timeout。此时按照正常的流程处理即可。
2. Status 状态为 Label Already Exists。则此时需继续查看 ExistingJobStatus 字段。如果该字段值为 FINISHED，则表示这个 Label 对应的导入任务已经成功，无需在重试。如果为 RUNNING，则表示这个 Label 对应的导入任务依然在运行，则此时需每隔一段时间（如 10 秒），使用相同的 Label 继续重复提交，直到 Status 不为 Label Already Exists，或者 ExistingJobStatus 字段值为 FINISHED 为止。

## 3. 取消导入任务

已提交切尚未结束的导入任务可以通过 CANCEL LOAD 命令取消。取消后，已写入的数据也会回滚，不会生效。

## 4. Label、导入事务、多表原子性

Doris 中所有导入任务都是原子生效的。并且在同一个导入任务中对多张表的导入也能够保证原子性。同时，Doris 还可以通过 Label 的机制来保证数据导入的不丢不重。具体说明可以参阅 [导入事务和原子性](#) 文档。

## 5. 列映射、衍生列和过滤

Doris 可以在导入语句中支持非常丰富的列转换和过滤操作。支持绝大多数内置函数和 UDF。关于如何正确的使用这个功能，可参阅 [列的映射，转换与过滤](#) 文档。

## 6. 错误数据过滤

Doris 的导入任务可以容忍一部分格式错误的数据。容忍率通过 max\_filter\_ratio 设置。默认为 0，即表示当有一条错误数据时，整个导入任务将会失败。如果用户希望忽略部分有问题的数据行，可以将参数设置为 0~1 之间的数值，Doris 会自动跳过哪些数据格式不正确的行。

关于容忍率的一些计算方式，可以参阅 [列的映射、转换与过滤](#) 文档。

## 7. 严格模式

`strict_mode` 属性用于设置导入任务是否运行在严格模式下。该属性会对列映射、转换和过滤的结果产生影响，它同时也将控制部分列更新的行为。关于严格模式的具体说明，可参阅 [严格模式](#) 文档。

## 8. 超时时间

Stream Load 的默认超时时间为 10 分钟。从任务提交开始算起。如果在超时时间内没有完成，则任务会失败。

## 9. 数据量和任务数限制

Stream Load 适合导入几个 GB 以内的数据，因为数据为单线程传输处理，因此导入过大的数据性能得不到保证。当有大量本地数据需要导入时，可以并行提交多个导入任务。

Doris 同时会限制集群内同时运行的导入任务数量，通常在 10-20 个不等。之后提交的导入作业会被拒绝。

## 10. 涉及时区的导入

由于 Doris 目前没有内置时区的时间类型，所有 DATETIME 相关类型均只表示绝对的时间点，而不包含时区信息，不因 Doris 系统时区变化而发生变化。因此，对于带时区数据的导入，我们统一的处理方式为将其转换为特定目标时区下的数据。在 Doris 系统中，即 session variable `time_zone` 所代表的时区。

而在导入中，我们的目标时区通过参数 `timezone` 指定，该变量在发生时区转换、运算时区敏感函数时将会替代 session variable `time_zone`。因此，如果没有特殊情况，在导入事务中应当设定 `timezone` 与当前 Doris 集群的 `time_zone` 一致。此时意味着所有带时区的时间数据，均会发生向该时区的转换。例如，Doris 系统时区为 “+08:00”，导入数据中的时间列包含两条数据，分别为 “2012-01-01 01:00:00Z” 和 “2015-12-12 12:12:12-08:00”，则我们在导入时通过 `-H "timezone: +08:00"` 指定导入事务的时区后，这两条数据都会向该时区发生转换，从而得到结果 “2012-01-01 09:00:00” 和 “2015-12-13 04:12:12”。

更详细的理解，请参阅[时区](#)文档。

## 11. 导入的执行引擎使用

Session Variable `enable_pipeline_load` 决定是否尝试开启 Pipeline 引擎执行 Streamload 任务。详见[导入](#)文档。

# MULTI-LOAD

## MULTI-LOAD

### Name

MULTI LOAD

### 描述

用户通过 HTTP 协议提交多个导入作业。Multi Load 可以保证多个导入作业的原子生效

Syntax:  
curl --location-trusted -u user:passwd -XPOST http://host:port/api/{db}/\_multi\_start?label=xxx  
curl --location-trusted -u user:passwd -T data.file http://host:port/api/{db}/{table1}/\_load?  
label=xxx&sub\_label=yyy  
curl --location-trusted -u user:passwd -T data.file http://host:port/api/{db}/{table2}/\_load?  
label=xxx&sub\_label=zzz  
curl --location-trusted -u user:passwd -XPOST http://host:port/api/{db}/\_multi\_commit?label=xxx  
curl --location-trusted -u user:passwd -XPOST http://host:port/api/{db}/\_multi\_desc?label=xxx

'MULTI LOAD'在'MINI LOAD'的基础上，可以支持用户同时向多个表进行导入，具体的命令如上面所示  
'/api/{db}/\_multi\_start'            开始一个多表导入任务  
'/api/{db}/{table}/\_load'        向一个导入任务添加一个要导入的表，与'MINI LOAD'的主要区别是，需要传入'sub\_label'参数  
'/api/{db}/\_multi\_commit'        提交整个多表导入任务，后台开始进行处理  
'/api/{db}/\_multi\_abort'        放弃一个多表导入任务  
'/api/{db}/\_multi\_desc'        可以展示某个多表导入任务已经提交的作业数

HTTP协议相关说明  
    权限认证                      当前 Doris 使用http的Basic方式权限认证。所以在导入的时候需要指定用户名密码  
                                    这种方式是明文传递密码的，鉴于我们当前都是内网环境。。。  
  
    Expect                        Doris 需要发送过来的http请求，需要有'Expect'头部信息，内容为'100-continue'  
                                    为什么呢？因为我们需要将请求进行redirect，那么必须在传输数据内容之前，  
                                    这样可以避免造成数据的多次传输，从而提高效率。  
  
    Content-Length                Doris 需要在发送请求是带有'Content-Length'这个头部信息。如果发送的内容比  
                                    'Content-Length'要少，那么Palo认为传输出现问题，则提交此次任务失败。  
    NOTE：如果，发送的数据比'Content-Length'要多，那么 Doris 只读取'Content-Length'  
                                    长度的内容，并进行导入

参数说明：  
    user:                        用户如果是在default\_cluster中的，user即为user\_name。否则为user\_name@cluster\_name。  
  
    label:                        用于指定这一批次导入的label号，用于后期进行作业状态查询等。  
                                    这个参数是必须传入的。  
  
    sub\_label:                    用于指定一个多表导入任务内部的子版本号。对于多表导入的load， 这个参数是必须传入的。  
  
    columns:                    用于描述导入文件中对应的列名字。  
                                    如果不传入，那么认为文件中的列顺序与建表的顺序一致，  
                                    指定的方式为逗号分隔，例如：columns=k1,k2,k3,k4  
  
    column\_separator:            用于指定列与列之间的分隔符，默认的为'\t'  
    NOTE：需要进行url编码，譬如需要指定'\t'为分隔符，  
                                    那么应该传入'column\_separator=%09'

**max\_filter\_ratio:** 用于指定允许过滤不规范数据的最大比例，默认是0，不允许过滤  
自定义指定应该如下: 'max\_filter\_ratio=0.2', 含义是允许20%的错误率  
在 '\_multi\_start' 时传入有效果

**NOTE:**

1. 此种导入方式当前是在一台机器上完成导入工作，因而不宜进行数据量较大的导入工作。  
建议导入数据量不要超过1GB
2. 当前无法使用`curl -T "{file1, file2}"`这样的方式提交多个文件，因为curl是将其拆成多个请求发送的，多个请求不能共用一个label号，所以无法使用
3. 支持类似streaming的方式使用curl来向 Doris 中导入数据，但是，只有等这个streaming结束后 Doris 才会发生真实的导入行为，这中方式数据量也不能过大。

## 举例

1. 将本地文件'testData1'中的数据导入到数据库'testDb'中'testTbl1'的表，并且把'testData2'的数据导入到'testDb'中的表'testTbl2' (用户是defalut\_cluster中的)  
curl --location-trusted -u root -XPOST http://host:port/api/testDb/\_multi\_start?label=123  
curl --location-trusted -u root -T testData1 http://host:port/api/testDb/testTbl1/\_load?label=123&sub\_label=1  
curl --location-trusted -u root -T testData2 http://host:port/api/testDb/testTbl2/\_load?label=123&sub\_label=2  
curl --location-trusted -u root -XPOST http://host:port/api/testDb/\_multi\_commit?label=123
2. 多表导入中途放弃(用户是defalut\_cluster中的)  
curl --location-trusted -u root -XPOST http://host:port/api/testDb/\_multi\_start?label=123  
curl --location-trusted -u root -T testData1 http://host:port/api/testDb/testTbl1/\_load?label=123&sub\_label=1  
curl --location-trusted -u root -XPOST http://host:port/api/testDb/\_multi\_abort?label=123
3. 多表导入查看已经提交多少内容(用户是defalut\_cluster中的)  
curl --location-trusted -u root -XPOST http://host:port/api/testDb/\_multi\_start?label=123  
curl --location-trusted -u root -T testData1 http://host:port/api/testDb/testTbl1/\_load?label=123&sub\_label=1  
curl --location-trusted -u root -XPOST http://host:port/api/testDb/\_multi\_desc?label=123

## Keywords

MULTI, MINI, LOAD

## Best Practice

# BROKER-LOAD

## BROKER-LOAD

### Name

BROKER LOAD

### 描述

该命令主要用于通过 Broker 服务进程读取远端存储（如 S3、HDFS）上的数据导入到 Doris 表里。

```
LOAD LABEL load_label
(
 data_desc1[, data_desc2, ...]
)
WITH BROKER broker_name
[broker_properties]
[load_properties]
[COMMENT "comments"];
```

- load\_label

每个导入需要指定一个唯一的 Label。后续可以通过这个 label 来查看作业进度。

[database.]label\_name

- data\_desc1

用于描述一组需要导入的文件。

```
[MERGE|APPEND|DELETE]
DATA INFILE
(
 "file_path1"[, file_path2, ...]
)
[NEGATIVE]
INTO TABLE `table_name`
[PARTITION (p1, p2, ...)]
[COLUMNS TERMINATED BY "column_separator"]
[LINES TERMINATED BY "line_delimiter"]
[FORMAT AS "file_type"]
[COMPRESS_TYPE AS "compress_type"]
[(column_list)]
[COLUMNS FROM PATH AS (c1, c2, ...)]
[SET (column_mapping)]
[PRECEDING FILTER predicate]
[WHERE predicate]
[DELETE ON expr]
[ORDER BY source_sequence]
[PROPERTIES ("key1"="value1", ...)]
```

- [MERGE|APPEND|DELETE]

数据合并类型。默认为 APPEND，表示本次导入是普通的追加写操作。MERGE 和 DELETE 类型仅适用于 Unique Key 模型表。其中 MERGE 类型需要配合 [DELETE ON] 语句使用，以标注 Delete Flag 列。而 DELETE 类型则表示本次导入的所有数据皆为删除数据。

- DATA INFILE

指定需要导入的文件路径。可以是多个。可以使用通配符。路径最终必须匹配到文件，如果只匹配到目录则导入会失败。

- NEGATIVE

该关键词用于表示本次导入为一批“负”导入。这种方式仅针对具有整型 SUM 聚合类型的聚合数据表。该方式会将导入数据中，SUM 聚合列对应的整型数值取反。主要用于冲抵之前导入错误的数

据。

- PARTITION(p1, p2, ...)

可以指定仅导入表的某些分区。不在分区范围内的数据将被忽略。

- COLUMNS TERMINATED BY

指定列分隔符。仅在 CSV 格式下有效。仅能指定单字节分隔符。

- LINES TERMINATED BY

指定行分隔符。仅在 CSV 格式下有效。仅能指定单字节分隔符。

- FORMAT AS

指定文件类型，支持 CSV、PARQUET 和 ORC 格式。默认为 CSV。

- COMPRESS\_TYPE AS 指定文件压缩类型，支持 GZ/BZ2/LZ4FRAME。

- column list

用于指定原始文件中的列顺序。关于这部分详细介绍，可以参阅 [列的映射、转换与过滤](#) 文档。

(k1, k2, tmpk1)

- COLUMNS FROM PATH AS

指定从导入文件路径中抽取的列。

- SET (column\_mapping)

指定列的转换函数。

- PRECEDING FILTER predicate

前置过滤条件。数据首先根据 column list 和 COLUMNS FROM PATH AS 按顺序拼接成原始数据行。然后按照前置过滤条件进行过滤。关于这部分详细介绍，可以参阅 [列的映射、转换与过滤](#) 文档。

- WHERE predicate

根据条件对导入的数据进行过滤。关于这部分详细介绍，可以参阅 [列的映射、转换与过滤](#) 文档。

- DELETE ON expr

需配合 MERERGE 导入模式一起使用，仅针对 Unique Key 模型的表。用于指定导入数据中表示 Delete Flag 的列和计算关系。

- ORDER BY

仅针对 Unique Key 模型的表。用于指定导入数据中表示 Sequence Col 的列。主要用于导入时保证数据顺序。

- PROPERTIES ("key1"="value1", ...)

指定导入的 format 的一些参数。如导入的文件是 json 格式，则可以在这里指定 json\_root、jsonpaths、fuzzy\_parse 等参数。

- `enclose`

包围符。当 csv 数据字段中含有行分隔符或列分隔符时，为防止意外截断，可指定单字节字符作为包围符起到保护作用。例如列分隔符为“;”，包围符为“””，数据为“a;b;c”，则“b,c”会被解析为一个字段。注意：当 `enclose` 设置为“””时，`trim_double_quotes` 一定要设置为 `true`。

- `escape`

转义符。用于转义在字段中出现的与包围符相同的字符。例如数据为“a;b;c”，包围符为“””，希望“b,c”被作为一个字段解析，则需要指定单字节转义符，例如“\”，然后将数据修改为“a;b\,c”。

- WITH BROKER broker\_name

指定需要使用的 Broker 服务名称。在公有云 Doris 中。Broker 服务名称为 bos

- broker\_properties

指定 broker 所需的信息。这些信息通常被用于 Broker 能够访问远端存储系统。如 BOS 或 HDFS。关于具体信息，可参阅 [Broker](#) 文档。

```
(
 "key1" = "val1",
 "key2" = "val2",
 ...
)
```

- load\_properties

指定导入的相关参数。目前支持以下参数：

- `timeout`

导入超时时间。默认为 4 小时。单位秒。

- `max_filter_ratio`

最大容忍可过滤（数据不规范等原因）的数据比例。默认零容忍。取值范围为 0 到 1。

- `exec_mem_limit`

导入内存限制。默认为 2GB。单位为字节。

- `strict_mode`

是否对数据进行严格限制。默认为 `false`。

- `partial_columns`

布尔类型，为 `true` 表示使用部分列更新，默认值为 `false`，该参数只允许在表模型为 `Unique` 且采用 `Merge on Write` 时设置。

- `timezone`

指定某些受时区影响的函数的时区，如 `strftime/alignment_timestamp/from_unixtime` 等等，具体请查阅 [时区](#) 文档。如果不指定，则使用 “Asia/Shanghai” 时区

- `load_parallelism`

导入并发度，默认为 1。调大导入并发度会启动多个执行计划同时执行导入任务，加快导入速度。

- `send_batch_parallelism`

用于设置发送批处理数据的并行度，如果并行度的值超过 BE 配置中的 `max_send_batch_parallelism_per_job`，那么作为协调点的 BE 将使用 `max_send_batch_parallelism_per_job` 的值。

- `load_to_single_tablet`

布尔类型，为 `true` 表示支持一个任务只导入数据到对应分区的一个 tablet，默认值为 `false`，作业的任务数取决于整体并发度。该参数只允许在对带有 `random` 分桶的 `olap` 表导数的时候设置。

- `priority`

设置导入任务的优先级，可选 `HIGH/NORMAL/LOW` 三种优先级，默认为 `NORMAL`，对于处在 `PENDING` 状态的导入任务，更高优先级的任务将优先被执行进入 `LOADING` 状态。

- `comment`

指定导入任务的备注信息。可选参数。

:::tip 提示 该功能自 Apache Doris 1.2.3 版本起支持 :::

## 举例

### 1. 从 HDFS 导入一批数据

```
LOAD LABEL example_db.label1
(
 DATA INFILE('hdfs://hdfs_host:hdfs_port/input/file.txt')
 INTO TABLE `my_table`
```



```

 COLUMNS TERMINATED BY ","
)
 WITH BROKER hdfs
 (
 "username"="hdfs_user",
 "password"="hdfs_password"
);

```

导入文件 file.txt，按逗号分隔，导入到表 my\_table。

## 2. 从 HDFS 导入数据，使用通配符匹配两批文件。分别导入到两个表中。

```

LOAD LABEL example_db.label2
(
 DATA INFILE("hdfs://hdfs_host:hdfs_port/input/file-10*")
 INTO TABLE `my_table1`
 PARTITION (p1)
 COLUMNS TERMINATED BY ","
 (k1, tmp_k2, tmp_k3)
 SET (
 k2 = tmp_k2 + 1,
 k3 = tmp_k3 + 1
)
 DATA INFILE("hdfs://hdfs_host:hdfs_port/input/file-20*")
 INTO TABLE `my_table2`
 COLUMNS TERMINATED BY ","
 (k1, k2, k3)
)
WITH BROKER hdfs
(
 "username"="hdfs_user",
 "password"="hdfs_password"
);

```

使用通配符匹配导入两批文件 file-10\* 和 file-20\*。分别导入到 my\_table1 和 my\_table2 两张表中。其中 my\_table1 指定导入到分区 p1 中，并且将导入源文件中第二列和第三列的值 +1 后导入。

## 3. 从 HDFS 导入一批数据。

```

LOAD LABEL example_db.label3
(
 DATA INFILE("hdfs://hdfs_host:hdfs_port/user/doris/data/*/*")
 INTO TABLE `my_table`
 COLUMNS TERMINATED BY "\\x01"
)
WITH BROKER my_hdfs_broker
(
 "username" = "",
 "password" = "",
 "fs.defaultFS" = "hdfs://my_ha",
 "dfs.nameservices" = "my_ha",
 "dfs.ha.namenodes.my_ha" = "my_namenode1, my_namenode2",
 "dfs.namenode.rpc-address.my_ha.my_namenode1" = "nn1_host:rpc_port",
 "dfs.namenode.rpc-address.my_ha.my_namenode2" = "nn2_host:rpc_port",
 "dfs.client.failover.proxy.provider.my_ha" =
 "org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider"
);

```

指定分隔符为 Hive 的默认分隔符 `\x01`，并使用通配符 `*` 指定 `data` 目录下所有目录的所有文件。使用简单认证，同时配置 `namenode HA`。

#### 4. 导入 Parquet 格式数据，指定 FORMAT 为 parquet。默认是通过文件后缀判断

```
LOAD LABEL example_db.label4
(
 DATA INFILE("hdfs://hdfs_host:hdfs_port/input/file")
 INTO TABLE `my_table`
 FORMAT AS "parquet"
 (k1, k2, k3)
)
WITH BROKER hdfs
(
 "username"="hdfs_user",
 "password"="hdfs_password"
);
```

#### 5. 导入数据，并提取文件路径中的分区字段

```
LOAD LABEL example_db.label10
(
 DATA INFILE("hdfs://hdfs_host:hdfs_port/input/city=beijing/*/*")
 INTO TABLE `my_table`
 FORMAT AS "csv"
 (k1, k2, k3)
 COLUMNS FROM PATH AS (city, utc_date)
)
WITH BROKER hdfs
(
 "username"="hdfs_user",
 "password"="hdfs_password"
);
```

`my_table` 表中的列为 `k1`, `k2`, `k3`, `city`, `utc_date`。

其中 `hdfs://hdfs_host:hdfs_port/user/doris/data/input/dir/city=beijing` 目录下包括如下文件：

```
hdfs://hdfs_host:hdfs_port/input/city=beijing/utc_date=2020-10-01/0000.csv
hdfs://hdfs_host:hdfs_port/input/city=beijing/utc_date=2020-10-02/0000.csv
hdfs://hdfs_host:hdfs_port/input/city=tianji/utc_date=2020-10-03/0000.csv
hdfs://hdfs_host:hdfs_port/input/city=tianji/utc_date=2020-10-04/0000.csv
```

文件中只包含 `k1`, `k2`, `k3` 三列数据，`city`, `utc_date` 这两列数据会从文件路径中提取。

#### 6. 对待导入数据进行过滤。

```
LOAD LABEL example_db.label6
(
 DATA INFILE("hdfs://host:port/input/file")
 INTO TABLE `my_table`
 (k1, k2, k3)
 SET (
 k2 = k2 + 1
)
 PRECEDING FILTER k1 = 1
```

```

WHERE k1 > k2
)
WITH BROKER hdfs
(
 "username"="user",
 "password"="pass"
);

```

只有原始数据中， $k1 = 1$ ，并且转换后， $k1 > k2$  的行才会被导入。

7. 导入数据，提取文件路径中的时间分区字段，并且时间包含 %3A (在 hdfs 路径中，不允许有 ':'，所有 ':' 会由 %3A 替换)

```

LOAD LABEL example_db.label7
(
 DATA INFILE("hdfs://host:port/user/data/*/test.txt")
 INTO TABLE `tbl12`
 COLUMNS TERMINATED BY ","
 (k2,k3)
 COLUMNS FROM PATH AS (data_time)
 SET (
 data_time=str_to_date(data_time, '%Y-%m-%d %H%%3Ai%%3As')
)
)
WITH BROKER hdfs
(
 "username"="user",
 "password"="pass"
);

```

路径下有如下文件：

```

/user/data/data_time=2020-02-17 00%3A00%3A00/test.txt
/user/data/data_time=2020-02-18 00%3A00%3A00/test.txt

```

表结构为：

```

data_time DATETIME,
k2 INT,
k3 INT

```

8. 从 HDFS 导入一批数据，指定超时时间和过滤比例。使用明文 my\_hdfs\_broker 的 broker。简单认证。并且将原有数据中与 导入数据中 v2 大于 100 的列相匹配的列删除，其他列正常导入

```

LOAD LABEL example_db.label8
(
 MERGE DATA INFILE("HDFS://test:802/input/file")
 INTO TABLE `my_table`
 (k1, k2, k3, v2, v1)
 DELETE ON v2 > 100
)
WITH HDFS
(
 "hadoop.username"="user",
 "password"="pass"
)
PROPERTIES

```

```
(
 "timeout" = "3600",
 "max_filter_ratio" = "0.1"
);
```

使用 MERGE 方式导入。my\_table 必须是一张 Unique Key 的表。当导入数据中的 v2 列的值大于 100 时，该行会被认为是一个删除行。

导入任务的超时时间是 3600 秒，并且允许错误率在 10% 以内。

9. 导入时指定 source\_sequence 列，保证 UNIQUE\_KEYS 表中的替换顺序：

```
LOAD LABEL example_db.label9
(
 DATA INFILE("HDFS://test:802/input/file")
 INTO TABLE `my_table`
 COLUMNS TERMINATED BY ","
 (k1,k2,source_sequence,v1,v2)
 ORDER BY source_sequence
)
WITH HDFS
(
 "hadoop.username"="user",
 "password"="pass"
)
```

my\_table 必须是 Unique Key 模型表，并且指定了 Sequence Col。数据会按照源数据中 source\_sequence 列的值来保证顺序性。

10. 从 HDFS 导入一批数据，指定文件格式为 json 并指定 json\_root、jsonpaths

```
LOAD LABEL example_db.label10
(
 DATA INFILE("HDFS://test:port/input/file.json")
 INTO TABLE `my_table`
 FORMAT AS "json"
 PROPERTIES(
 "json_root" = "$.item",
 "jsonpaths" = "[$.id, $.city, $.code]"
)
)
with HDFS (
 "hadoop.username" = "user"
 "password" = ""
)
PROPERTIES
(
 "timeout"="1200",
 "max_filter_ratio"="0.1"
);
```

jsonpaths 可与 column list 及 SET (column\_mapping)配合：

```
`sql LOAD LABEL example_db.label10 (DATA INFILE("HDFS://test:port/input/file.json")
INTO TABLEmy_table` FORMAT AS "json" (id, code, city) SET (id = id * 10) PROPERTIES("json_root" =
"$$.item", "jsonpaths" = "[$.id, $.code, $.city]")
```

```
) with HDFS ("hadoop.username" = "user" "password" = "") PROPERTIES ("timeout"="1200",
"max_filter_ratio"="0.1");
```

11. 从腾讯云 cos 中以 csv 格式导入数据。

```
LOAD LABEL example_db.label10
(
 DATA INFILE("cosn://my_bucket/input/file.csv")
 INTO TABLE `my_table`
 (k1, k2, k3)
)
WITH BROKER "broker_name"
(
 "fs.cosn.userinfo.secretId" = "xxx",
 "fs.cosn.userinfo.secretKey" = "xxxx",
 "fs.cosn.bucket.endpoint_suffix" = "cos.xxxxxxxx.myqcloud.com"
)
```

12. 导入 CSV 数据时去掉双引号，并跳过前 5 行。

```
LOAD LABEL example_db.label12
(
 DATA INFILE("cosn://my_bucket/input/file.csv")
 INTO TABLE `my_table`
 (k1, k2, k3)
 PROPERTIES("trim_double_quotes" = "true", "skip_lines" = "5")
)
WITH BROKER "broker_name"
(
 "fs.cosn.userinfo.secretId" = "xxx",
 "fs.cosn.userinfo.secretKey" = "xxxx",
 "fs.cosn.bucket.endpoint_suffix" = "cos.xxxxxxxx.myqcloud.com"
)
```

## Keywords

BROKER, LOAD

## Best Practice

### 1. 查看导入任务状态

Broker Load 是一个异步导入过程，语句执行成功仅代表导入任务提交成功，并不代表数据导入成功。导入状态需要通过 [SHOW LOAD](#) 命令查看。

### 2. 取消导入任务

已提交切尚未结束的导入任务可以通过 [CANCEL LOAD](#) 命令取消。取消后，已写入的数据也会回滚，不会生效。

### 3. Label、导入事务、多表原子性

Doris 中所有导入任务都是原子生效的。并且在同一个导入任务中对多张表的导入也能够保证原子性。同时，Doris 还可以通过 Label 的机制来保证数据导入的不丢不重。具体说明可以参阅 [导入事务和原子性](#) 文

档。

#### 4. 列映射、衍生列和过滤

Doris 可以在导入语句中支持非常丰富的列转换和过滤操作。支持绝大多数内置函数和 UDF。关于如何正确的使用这个功能，可参阅 [列的映射，转换与过滤](#) 文档。

#### 5. 错误数据过滤

Doris 的导入任务可以容忍一部分格式错误的数据。容忍了通过 `max_filter_ratio` 设置。默认为 0，即表示当有一条错误数据时，整个导入任务将会失败。如果用户希望忽略部分有问题的数据行，可以将该参数设置为 0~1 之间的数值，Doris 会自动跳过哪些数据格式不正确的行。

关于容忍率的一些计算方式，可以参阅 [列的映射，转换与过滤](#) 文档。

#### 6. 严格模式

`strict_mode` 属性用于设置导入任务是否运行在严格模式下。该格式会对列映射、转换和过滤的结果产生影响。关于严格模式的具体说明，可参阅 [严格模式](#) 文档。

#### 7. 超时时间

Broker Load 的默认超时时间为 4 小时。从任务提交开始算起。如果在超时时间内没有完成，则任务会失败。

#### 8. 数据量和任务数限制

Broker Load 适合在一个导入任务中导入 100GB 以内的数据。虽然理论上在一个导入任务中导入的数据量没有上限。但是提交过大的导入会导致运行时间较长，并且失败后重试的代价也会增加。

同时受限于集群规模，我们限制了导入的最大数据量为 `ComputeNode` 节点数 \* 3GB。以保证系统资源的合理利用。如果有大数据量需要导入，建议分成多个导入任务提交。

Doris 同时会限制集群内同时运行的导入任务数量，通常在 3-10 个不等。之后提交的导入作业会排队等待。队列最大长度为 100。之后的提交会直接拒绝。注意排队时间也被计算到了作业总时间中。如果超时，则作业会被取消。所以建议通过监控作业运行状态来合理控制作业提交频率。

# MYSQL-LOAD

## MYSQL-LOAD

### Name

MYSQL LOAD

### 描述

mysql-load: 使用 MySql 客户端导入本地数据

```
LOAD DATA
[LOCAL]
INFILE 'file_name'
INTO TABLE tbl_name
[PARTITION (partition_name [, partition_name] ...)]
[COLUMNS TERMINATED BY 'string']
[LINES TERMINATED BY 'string']
[IGNORE number {LINES | ROWS}]
[(col_name_or_user_var [, col_name_or_user_var] ...)]
[SET (col_name={expr | DEFAULT} [, col_name={expr | DEFAULT}] ...)]
[PROPERTIES (key1 = value1 [, key2=value2])]
```

该语句用于向指定的 table 导入数据，与普通 Load 区别是，这种导入方式是同步导入。

这种导入方式仍然能够保证一批导入任务的原子性，要么全部数据导入成功，要么全部失败。

1. MySQL Load 以语法LOAD DATA开头，无须指定 LABEL
2. 指定LOCAL表示读取客户端文件。不指定表示读取 FE 服务端本地文件。导入 FE 本地文件的功能默认是关闭的，需要在 FE 节点上设置mysql\_load\_server\_secure\_path来指定安全路径，才能打开该功能。
3. INFILE内填写本地文件路径，可以是相对路径，也可以是绝对路径。目前只支持单个文件，不支持多个文件
4. INTO TABLE的表名可以指定数据库名，如案例所示。也可以省略，则会使用当前用户所在的数据库。
5. PARTITION语法支持指定分区导入
6. COLUMNS TERMINATED BY指定列分隔符
7. LINES TERMINATED BY指定行分隔符
8. IGNORE num LINES用户跳过 CSV 的表头，可以跳过任意行数。该语法也可以用IGNORE num ROWS代替
9. 列映射语法，具体参数详见[导入的数据转换](#) 的列映射章节
10. PROPERTIES参数配置，详见下文

### PROPERTIES

1. max\_filter\_ratio: 最大容忍可过滤（数据不规范等原因）的数据比例。默认零容忍。
2. timeout: 指定导入的超时时间。单位秒。默认是 600 秒。可设置范围为 1 秒 ~ 259200 秒。
3. strict\_mode: 用户指定此次导入是否开启严格模式，默认为关闭。

4. `timezone`: 指定本次导入所使用的时区。默认为东八区。该参数会影响所有导入涉及的和时区有关的函数结果。
5. `exec_mem_limit`: 导入内存限制。默认为 2GB。单位为字节。
6. `trim_double_quotes`: 布尔类型，默认值为 `false`，为 `true` 时表示裁剪掉导入文件每个字段最外层的双引号。
7. `enclose`: 包围符。当 `csv` 数据字段中含有行分隔符或列分隔符时，为防止意外截断，可指定单字节字符作为包围符起到保护作用。例如列分隔符为“;”，包围符为“”，数据为“a;b;c”，则“b,c”会被解析为一个字段。注意：当 `enclose` 设置为“”时，`trim_double_quotes` 一定要设置为 `true`。
8. `escape`: 转义符。用于转义在 `csv` 字段中出现的与包围符相同的字符。例如数据为“a;b;c”，包围符为“”，希望“b,c”被作为一个字段解析，则需要指定单字节转义符，例如“”，然后将数据修改为“a;b,c”。

## 举例

1. 将客户端本地文件‘testData’中的数据导入到数据库‘testDb’中‘testTbl’的表。指定超时时间为 100 秒

```
LOAD DATA LOCAL
INFILE 'testData'
INTO TABLE testDb.testTbl
PROPERTIES ("timeout"="100")
```

2. 将服务端本地文件‘/root/testData’(需设置 FE 配置`mysql_load_server_secure_path`为/root) 中的数据导入到数据库‘testDb’中‘testTbl’的表。指定超时时间为 100 秒

```
LOAD DATA
INFILE '/root/testData'
INTO TABLE testDb.testTbl
PROPERTIES ("timeout"="100")
```

3. 将客户端本地文件‘testData’中的数据导入到数据库‘testDb’中‘testTbl’的表，允许 20% 的错误率

```
LOAD DATA LOCAL
INFILE 'testData'
INTO TABLE testDb.testTbl
PROPERTIES ("max_filter_ratio"="0.2")
```

4. 将客户端本地文件‘testData’中的数据导入到数据库‘testDb’中‘testTbl’的表，允许 20% 的错误率，并且指定文件的列名

```
LOAD DATA LOCAL
INFILE 'testData'
INTO TABLE testDb.testTbl
(k2, k1, v1)
PROPERTIES ("max_filter_ratio"="0.2")
```

5. 将本地文件‘testData’中的数据导入到数据库‘testDb’中‘testTbl’的表中的 p1, p2 分区，允许 20% 的错误率。



```
LOAD DATA LOCAL
INFILE 'testData'
INTO TABLE testDb.testTbl
PARTITION (p1, p2)
PROPERTIES ("max_filter_ratio"="0.2")
```

6. 将本地行分隔符为0102,列分隔符为0304的 CSV 文件'testData'中的数据导入到数据库'testDb'中'testTbl'的表中。

```
LOAD DATA LOCAL
INFILE 'testData'
INTO TABLE testDb.testTbl
COLUMNS TERMINATED BY '0304'
LINES TERMINATED BY '0102'
```

7. 将本地文件'testData'中的数据导入到数据库'testDb'中'testTbl'的表中的 p1, p2 分区, 并跳过前面 3 行。

```
LOAD DATA LOCAL
INFILE 'testData'
INTO TABLE testDb.testTbl
PARTITION (p1, p2)
IGNORE 1 LINES
```

8. 导入数据进行严格模式过滤, 并设置时区为 Africa/Abidjan

```
LOAD DATA LOCAL
INFILE 'testData'
INTO TABLE testDb.testTbl
PROPERTIES ("strict_mode"="true", "timezone"="Africa/Abidjan")
```

9. 导入数据进行限制导入内存为 10GB, 并在 10 分钟超时

```
LOAD DATA LOCAL
INFILE 'testData'
INTO TABLE testDb.testTbl
PROPERTIES ("exec_mem_limit"="10737418240", "timeout"="600")
```

## Keywords

MYSQL, LOAD

# CREATE-ROUTINE-LOAD

## CREATE-ROUTINE-LOAD

### Name

CREATE ROUTINE LOAD

### 描述

例行导入（Routine Load）功能，支持用户提交一个常驻的导入任务，通过不断的从指定的数据源读取数据，将数据导入到 Doris 中。

目前仅支持通过无认证或者 SSL 认证方式，从 Kafka 导入 CSV 或 Json 格式的数据。 [导入 Json 格式数据使用示例](#)

语法：

```
CREATE ROUTINE LOAD [db.]job_name [ON tbl_name]
[merge_type]
[load_properties]
[job_properties]
FROM data_source [data_source_properties]
[COMMENT "comment"]
```

- [db.]job\_name

导入作业的名称，在同一个 database 内，相同名称只能有一个 job 在运行。

- tbl\_name

指定需要导入的表的名称，可选参数，如果不指定，则采用动态表的方式，这个时候需要 Kafka 中的数据包含表名的信息。目前仅支持从 Kafka 的 Value 中获取表名，且需要符合这种格式：以 json 为例：

table\_name|{"col1": "val1", "col2": "val2"}，其中 tbl\_name 为表名，以 | 作为表名和表数据的分隔符。csv 格式的数据也是类似的，如：table\_name|val1,val2,val3。注意，这里的 table\_name 必须和 Doris 中的表名一致，否则会导致导入失败。

tips: 动态表不支持 columns\_mapping 参数。如果你的表结构和 Doris 中的表结构一致，且存在大量的表信息需要导入，那么这种方式将是不二选择。

- merge\_type

数据合并类型。默认为 APPEND，表示导入的数据都是普通的追加写操作。MERGE 和 DELETE 类型仅适用于 Unique Key 模型表。其中 MERGE 类型需要配合 [DELETE ON] 语句使用，以标注 Delete Flag 列。而 DELETE 类型则表示导入的所有数据皆为删除数据。tips: 当使用动态多表的时候，请注意此参数应该符合每张动态表的类型，否则会导致导入失败。

- load\_properties

用于描述导入数据。组成如下：

```
[column_separator],
[columns_mapping],
[preceding_filter],
[where_predicates],
[partitions],
[DELETE ON],
[ORDER BY]
```

- column\_separator

指定列分隔符，默认为 \t

COLUMNS TERMINATED BY ","

- columns\_mapping

用于指定文件列和表中列的映射关系，以及各种列转换等。关于这部分详细介绍，可以参阅 [列的映射，转换与过滤] 文档。

(k1, k2, tmpk1, k3 = tmpk1 + 1)

tips: 动态表不支持此参数。

- preceding\_filter

过滤原始数据。关于这部分详细介绍，可以参阅 [列的映射，转换与过滤] 文档。

tips: 动态表不支持此参数。

- where\_predicates

根据条件对导入的数据进行过滤。关于这部分详细介绍，可以参阅 [列的映射，转换与过滤] 文档。

WHERE k1 > 100 and k2 = 1000

tips: 当使用动态多表的时候，请注意此参数应该符合每张动态表的列，否则会导致导入失败。通常在使用动态多表的时候，我们仅建议通用公共列使用此参数。

- partitions

指定导入目的表的哪些 partition 中。如果不指定，则会自动导入到对应的 partition 中。

PARTITION(p1, p2, p3)

tips: 当使用动态多表的时候，请注意此参数应该符合每张动态表，否则会导致导入失败。

- DELETE ON

需配合 MEREGE 导入模式一起使用，仅针对 Unique Key 模型的表。用于指定导入数据中表示 Delete Flag 的列和计算关系。

DELETE ON v3 >100

tips: 当使用动态多表的时候，请注意此参数应该符合每张动态表，否则会导致导入失败。

- ORDER BY

仅针对 Unique Key 模型的表。用于指定导入数据中表示 Sequence Col 的列。主要用于导入时保证数据顺序。

tips: 当使用动态多表的时候, 请注意此参数应该符合每张动态表, 否则会导致导入失败。

- job\_properties

用于指定例行导入作业的通用参数。

```
PROPERTIES (
 "key1" = "val1",
 "key2" = "val2"
)
```

目前我们支持以下参数:

1. desired\_concurrent\_number

期望的并发度。一个例行导入作业会被分成多个子任务执行。这个参数指定一个作业最多有多少任务可以同时执行。必须大于 0。默认为 5。

这个并发度并不是实际的并发度, 实际的并发度, 会通过集群的节点数、负载情况, 以及数据源的情况综合考虑。

```
"desired_concurrent_number" = "3"
```

2. max\_batch\_interval/max\_batch\_rows/max\_batch\_size

这三个参数分别表示:

1. 每个子任务最大执行时间, 单位是秒。范围为 1 到 60。默认为 10。
2. 每个子任务最多读取的行数。必须大于等于 200000。默认是 200000(2.0.13 及更高版本为 20000000)。
3. 每个子任务最多读取的字节数。单位是字节, 范围是 100MB 到 1GB。默认是 100MB(2.0.13 及更高版本为 1G)。

这三个参数, 用于控制一个子任务的执行时间和处理量。当任意一个达到阈值, 则任务结束。

```
"max_batch_interval" = "20",
"max_batch_rows" = "300000",
"max_batch_size" = "209715200"
```

3. max\_error\_number

采样窗口内, 允许的最大错误行数。必须大于等于 0。默认是 0, 即不允许有错误行。

采样窗口为  $\text{max\_batch\_rows} * 10$ 。即如果在采样窗口内, 错误行数大于  $\text{max\_error\_number}$ , 则会导致例行作业被暂停, 需要人工介入检查数据质量问题。

被 where 条件过滤掉的行不算错误行。

4. strict\_mode

是否开启严格模式，默认为关闭。如果开启后，非空原始数据的列类型变换如果结果为 NULL，则会被过滤。指定方式为：

```
"strict_mode" = "true"
```

strict mode 模式的意思是：对于导入过程中的列类型转换进行严格过滤。严格过滤的策略如下：

- 1. 对于列类型转换来说，如果 strict mode 为 true，则错误的的数据将被 filter。这里的错误数据是指：原始数据并不为空值，在参与列类型转换后结果为空值的这一类数据。
- 2. 对于导入的某列由函数变换生成时，strict mode 对其不产生影响。
- 3. 对于导入的某列类型包含范围限制的，如果原始数据能正常通过类型转换，但无法通过范围限制的，strict mode 对其也不产生影响。例如：如果类型是 decimal(1,0), 原始数据为 10，则属于可以通过类型转换但不在列声明的范围内。这种数据 strict 对其不产生影响。

strict mode 与 source data 的导入关系

这里以列类型为 TinyInt 来举例

注：当表中的列允许导入空值时

source data	source data example	string to int	strict_mode	result
空值	\N	N/A	true or false	NULL
not null	aaa or 2000	NULL	true	invalid data(filtered)
not null	aaa	NULL	false	NULL
not null	1	1	true or false	correct data

这里以列类型为 Decimal(1,0) 举例

注：当表中的列允许导入空值时

source data	source data example	string to int	strict_mode	result
空值	\N	N/A	true or false	NULL
not null	aaa	NULL	true	invalid data(filtered)
not null	aaa	NULL	false	NULL
not null	1 or 10	1	true or false	correct data

注意：10 虽然是一个超过范围的值，但是因为其类型符合 decimal 的要求，所以 strict mode 对其不产生影响。10 最后会在其他 ETL 处理流程中被过滤。但不会被 strict mode 过滤。

5. timezone

指定导入作业所使用的时区。默认为使用 Session 的 `timezone` 参数。该参数会影响所有导入涉及的和时区有关的函数结果。

#### 6. `format`

指定导入数据格式，默认是 `csv`，支持 `json` 格式。

#### 7. `jsonpaths`

当导入数据格式为 `json` 时，可以通过 `jsonpaths` 指定抽取 Json 数据中的字段。

```
-H "jsonpaths: [\"$.k2\", \"$.k1\"]"
```

#### 8. `strip_outer_array`

当导入数据格式为 `json` 时，`strip_outer_array` 为 `true` 表示 Json 数据以数组的形式展现，数据中的每一个元素将被视为一行数据。默认值是 `false`。

```
-H "strip_outer_array: true"
```

#### 9. `json_root`

当导入数据格式为 `json` 时，可以通过 `json_root` 指定 Json 数据的根节点。Doris 将通过 `json_root` 抽取根节点的元素进行解析。默认为空。

```
-H "json_root: $.RECORDS"
```

#### 10. `send_batch_parallelism`

整型，用于设置发送批处理数据的并行度，如果并行度的值超过 BE 配置中的 `max_send_batch_parallelism_per_job`，那么作为协调点的 BE 将使用 `max_send_batch_parallelism_per_job` 的值。

#### 11. `load_to_single_tablet`

布尔类型，为 `true` 表示支持一个任务只导入数据到对应分区的一个 `tablet`，默认值为 `false`，该参数只允许在对带有 `random` 分桶的 `olap` 表导数的时候设置。

#### 12. `partial_columns` 布尔类型，为 `true` 表示使用部分列更新，默认值为 `false`，该参数只允许在表模型为 `Unique` 且采用 `Merge on Write` 时设置。一流多表不支持此参数。

#### 13. `max_filter_ratio`

采样窗口内，允许的最大过滤率。必须在大于等于0到小于等于1之间。默认值是 0。

采样窗口为 `max_batch_rows * 10`。即如果在采样窗口内，错误行数/总行数大于 `max_filter_ratio`，则会导致例行作业被暂停，需要人工介入检查数据质量问题。

被 `where` 条件过滤掉的行不算错误行。

#### 14. `enclose` 包围符。当 `csv` 数据字段中含有行分隔符或列分隔符时，为防止意外截断，可指定单字节字符作为包围符起到保护作用。例如列分隔符为“`,`”，包围符为“`“`”，数据为“`a,b,c`”，则“`b,c`”会被解析为一个字段。注意：当 `enclose` 设置为“`”`时，`trim_double_quotes` 一定要设置为 `true`。

15. escape 转义符。用于转义在csv字段中出现的与包围符相同的字符。例如数据为"a,b,c"，包围符为""，希望b,c被作为一个字段解析，则需要指定单字节转义符，例如 \，然后将数据修改为 a,'b,\c'。

- FROM data\_source [data\_source\_properties]

数据源的类型。当前支持：

```
FROM KAFKA
(
 "key1" = "val1",
 "key2" = "val2"
)
```

data\_source\_properties 支持如下数据源属性：

#### 1. kafka\_broker\_list

Kafka 的 broker 连接信息。格式为 ip:host。多个 broker 之间以逗号分隔。

"kafka\_broker\_list" = "broker1:9092,broker2:9092"

#### 2. kafka\_topic

指定要订阅的 Kafka 的 topic。

"kafka\_topic" = "my\_topic"

#### 3. kafka\_partitions/kafka\_offsets

指定需要订阅的 kafka partition，以及对应的每个 partition 的起始 offset。如果指定时间，则会从大于等于该时间的最近一个 offset 处开始消费。

offset 可以指定从大于等于 0 的具体 offset，或者：

- OFFSET\_BEGINNING: 从有数据的位置开始订阅。
- OFFSET\_END: 从末尾开始订阅。
- 时间格式，如：“2021-05-22 11:00:00”

如果没有指定，则默认从 OFFSET\_END 开始订阅 topic 下的所有 partition。

```
"kafka_partitions" = "0,1,2,3",
"kafka_offsets" = "101,0,OFFSET_BEGINNING,OFFSET_END"
```

```
"kafka_partitions" = "0,1,2,3",
"kafka_offsets" = "2021-05-22 11:00:00,2021-05-22 11:00:00,2021-05-22 11:00:00"
```

注意，时间格式不能和 OFFSET 格式混用。

#### 4. property

指定自定义 kafka 参数。功能等同于 kafka shell 中“-property”参数。

当参数的 value 为一个文件时，需要在 value 前加上关键词：“FILE:”。

关于如何创建文件，请参阅 [CREATE FILE](#) 命令文档。

更多支持的自定义参数，请参阅 librdkafka 的官方 CONFIGURATION 文档中，client 端的配置项。如：

```
"property.client.id" = "12345",
"property.ssl.ca.location" = "FILE:ca.pem"
```

#### 1. 使用 SSL 连接 Kafka 时，需要指定以下参数：

```
"property.security.protocol" = "ssl",
"property.ssl.ca.location" = "FILE:ca.pem",
"property.ssl.certificate.location" = "FILE:client.pem",
"property.ssl.key.location" = "FILE:client.key",
"property.ssl.key.password" = "abcdefg"
```

其中：

property.security.protocol 和 property.ssl.ca.location 为必须，用于指明连接方式为 SSL，以及 CA 证书的位置。

如果 Kafka server 端开启了 client 认证，则还需设置：

```
"property.ssl.certificate.location"
"property.ssl.key.location"
"property.ssl.key.password"
```

分别用于指定 client 的 public key，private key 以及 private key 的密码。

#### 2. 指定 kafka partition 的默认起始 offset

如果没有指定 kafka\_partitions/kafka\_offsets，默认消费所有分区。

此时可以指定 kafka\_default\_offsets 指定起始 offset。默认为 OFFSET\_END，即从末尾开始订阅。

示例：

```
"property.kafka_default_offsets" = "OFFSET_BEGINNING"
```

- comment

例行导入任务的注释信息。

:::tip 提示 该功能自 Apache Doris 1.2.3 版本起支持 :::

## 举例

1. 为 example\_db 的 example\_tbl 创建一个名为 test1 的 Kafka 例行导入任务。指定列分隔符和 group.id 和 client.id，并且自动默认消费所有分区，且从有数据的位置（OFFSET\_BEGINNING）开始订阅



```
CREATE ROUTINE LOAD example_db.test1 ON example_tbl
COLUMNS TERMINATED BY ",",
COLUMNS(k1, k2, k3, v1, v2, v3 = k1 * 100)
PROPERTIES
(
 "desired_concurrent_number"="3",
 "max_batch_interval" = "20",
 "max_batch_rows" = "300000",
 "max_batch_size" = "209715200",
 "strict_mode" = "false"
)
FROM KAFKA
(
 "kafka_broker_list" = "broker1:9092,broker2:9092,broker3:9092",
 "kafka_topic" = "my_topic",
 "property.group.id" = "xxx",
 "property.client.id" = "xxx",
 "property.kafka_default_offsets" = "OFFSET_BEGINNING"
);
```

2. 为 example\_db 创建一个名为 test1 的 Kafka 例行动态多表导入任务。指定列分隔符和 group.id 和 client.id, 并且自动默认消费所有分区, 且从有数据的位置 (OFFSET\_BEGINNING) 开始订阅

我们假设需要将 Kafka 中的数据导入到 example\_db 中的 test1 以及 test2 表中, 我们创建了一个名为 test1 的例行导入任务, 同时将 test1 和 test2 中的数据写到一个名为 my\_topic 的 Kafka 的 topic 中, 这样就可以通过一个例行导入任务将 Kafka 中的数据导入到两个表中。

```
CREATE ROUTINE LOAD example_db.test1
PROPERTIES
(
 "desired_concurrent_number"="3",
 "max_batch_interval" = "20",
 "max_batch_rows" = "300000",
 "max_batch_size" = "209715200",
 "strict_mode" = "false"
)
FROM KAFKA
(
 "kafka_broker_list" = "broker1:9092,broker2:9092,broker3:9092",
 "kafka_topic" = "my_topic",
 "property.group.id" = "xxx",
 "property.client.id" = "xxx",
 "property.kafka_default_offsets" = "OFFSET_BEGINNING"
);
```

3. 为 example\_db 的 example\_tbl 创建一个名为 test1 的 Kafka 例行导入任务。导入任务为严格模式。

```
CREATE ROUTINE LOAD example_db.test1 ON example_tbl
COLUMNS(k1, k2, k3, v1, v2, v3 = k1 * 100),
PRECEDING FILTER k1 = 1,
WHERE k1 > 100 and k2 like "%doris%"
PROPERTIES
(
 "desired_concurrent_number"="3",
 "max_batch_interval" = "20",
 "max_batch_rows" = "300000",
 "max_batch_size" = "209715200",
 "strict_mode" = "true"
)
```

```

FROM KAFKA
(
 "kafka_broker_list" = "broker1:9092,broker2:9092,broker3:9092",
 "kafka_topic" = "my_topic",
 "kafka_partitions" = "0,1,2,3",
 "kafka_offsets" = "101,0,0,200"
);

```

4. 通过 SSL 认证方式，从 Kafka 集群导入数据。同时设置 client.id 参数。导入任务为非严格模式，时区为 Africa/Abidjan

```

CREATE ROUTINE LOAD example_db.test1 ON example_tbl
COLUMNS(k1, k2, k3, v1, v2, v3 = k1 * 100),
WHERE k1 > 100 and k2 like "%doris%"
PROPERTIES
(
 "desired_concurrent_number"="3",
 "max_batch_interval" = "20",
 "max_batch_rows" = "300000",
 "max_batch_size" = "209715200",
 "strict_mode" = "false",
 "timezone" = "Africa/Abidjan"
)
FROM KAFKA
(
 "kafka_broker_list" = "broker1:9092,broker2:9092,broker3:9092",
 "kafka_topic" = "my_topic",
 "property.security.protocol" = "ssl",
 "property.ssl.ca.location" = "FILE:ca.pem",
 "property.ssl.certificate.location" = "FILE:client.pem",
 "property.ssl.key.location" = "FILE:client.key",
 "property.ssl.key.password" = "abcdefg",
 "property.client.id" = "my_client_id"
);

```

5. 导入 Json 格式数据。默认使用 Json 中的字段名作为列名映射。指定导入 0,1,2 三个分区，起始 offset 都为 0

```

CREATE ROUTINE LOAD example_db.test_json_label_1 ON table1
COLUMNS(category,price,author)
PROPERTIES
(
 "desired_concurrent_number"="3",
 "max_batch_interval" = "20",
 "max_batch_rows" = "300000",
 "max_batch_size" = "209715200",
 "strict_mode" = "false",
 "format" = "json"
)
FROM KAFKA
(
 "kafka_broker_list" = "broker1:9092,broker2:9092,broker3:9092",
 "kafka_topic" = "my_topic",
 "kafka_partitions" = "0,1,2",
 "kafka_offsets" = "0,0,0"
);

```

6. 导入 Json 数据，并通过 Jsonpaths 抽取字段，并指定 Json 文档根节点

```

CREATE ROUTINE LOAD example_db.test1 ON example_tbl
COLUMNS(category, author, price, timestamp, dt=from_unixtime(timestamp, '%Y%m%d'))
PROPERTIES
(
 "desired_concurrent_number"="3",
 "max_batch_interval" = "20",
 "max_batch_rows" = "300000",
 "max_batch_size" = "209715200",
 "strict_mode" = "false",
 "format" = "json",
 "jsonpaths" = "[\"$.category\", \"$.author\", \"$.price\", \"$.timestamp\"]",
 "json_root" = "$.RECORDS"
 "strip_outer_array" = "true"
)
FROM KAFKA
(
 "kafka_broker_list" = "broker1:9092,broker2:9092,broker3:9092",
 "kafka_topic" = "my_topic",
 "kafka_partitions" = "0,1,2",
 "kafka_offsets" = "0,0,0"
);

```

7. 为 example\_db 的 example\_tbl 创建一个名为 test1 的 Kafka 例行导入任务。并且使用条件过滤。

```

CREATE ROUTINE LOAD example_db.test1 ON example_tbl
WITH MERGE
COLUMNS(k1, k2, k3, v1, v2, v3),
WHERE k1 > 100 and k2 like "%doris%",
DELETE ON v3 >100
PROPERTIES
(
 "desired_concurrent_number"="3",
 "max_batch_interval" = "20",
 "max_batch_rows" = "300000",
 "max_batch_size" = "209715200",
 "strict_mode" = "false"
)
FROM KAFKA
(
 "kafka_broker_list" = "broker1:9092,broker2:9092,broker3:9092",
 "kafka_topic" = "my_topic",
 "kafka_partitions" = "0,1,2,3",
 "kafka_offsets" = "101,0,0,200"
);

```

8. 导入数据到含有 sequence 列的 Unique Key 模型表中

```

CREATE ROUTINE LOAD example_db.test_job ON example_tbl
COLUMNS TERMINATED BY ",",
COLUMNS(k1,k2,source_sequence,v1,v2),
ORDER BY source_sequence
PROPERTIES
(
 "desired_concurrent_number"="3",
 "max_batch_interval" = "30",
 "max_batch_rows" = "300000",
 "max_batch_size" = "209715200"
) FROM KAFKA
(
 "kafka_broker_list" = "broker1:9092,broker2:9092,broker3:9092",
 "kafka_topic" = "my_topic",

```

```
"kafka_partitions" = "0,1,2,3",
"kafka_offsets" = "101,0,0,200"
);
```

## 9. 从指定的时间点开始消费

```
CREATE ROUTINE LOAD example_db.test_job ON example_tbl
PROPERTIES
(
 "desired_concurrent_number"="3",
 "max_batch_interval" = "30",
 "max_batch_rows" = "300000",
 "max_batch_size" = "209715200"
) FROM KAFKA
(
 "kafka_broker_list" = "broker1:9092,broker2:9092",
 "kafka_topic" = "my_topic",
 "property.kafka_default_offsets" = "2021-05-21 10:00:00"
);
```

## Keywords

CREATE, ROUTINE, LOAD, CREATE LOAD

## Best Practice

关于指定消费的 Partition 和 Offset

Doris 支持指定 Partition 和 Offset 开始消费，还支持了指定时间点进行消费的功能。这里说明下对应参数的配置关系。

有三个相关参数：

- kafka\_partitions：指定待消费的 partition 列表，如：“0, 1, 2, 3”。
- kafka\_offsets：指定每个分区的起始 offset，必须和 kafka\_partitions 列表个数对应。如：“1000, 1000, 2000, 2000”
- `property.kafka\_default\_offsets`：指定分区默认的起始 offset。

在创建导入作业时，这三个参数可以有以下组合：

组合	kafka_partitions	kafka_offsets	property.kafka_default_offsets	行为
1	No	No	No	系统会自动查找 topic 对应的所有分区并从 OFFSET_END 开始消费
2	No	No	Yes	系统会自动查找 topic 对应的所有分区并从 default offset 指定的位置开始消费
3	Yes	No	No	系统会从指定分区的 OFFSET_END 开始消费
4	Yes	Yes	No	系统会从指定分区的指定 offset 处开始消费
5	Yes	No	Yes	系统会从指定分区，default offset 指定的位置开始消费

# ALTER-ROUTINE-LOAD

---

## ALTER-ROUTINE-LOAD

### Name

ALTER ROUTINE LOAD

### 描述

该语法用于修改已经创建的例行导入作业。

只能修改处于 PAUSED 状态的作业。

语法：

```
ALTER ROUTINE LOAD FOR [db.]job_name
[job_properties]
FROM data_source
[data_source_properties]
```

#### 1. [db.]job\_name

指定要修改的作业名称。

#### 2. tbl\_name

指定需要导入的表的名称。

#### 3. job\_properties

指定需要修改的作业参数。目前仅支持如下参数的修改：

1. desired\_concurrent\_number
2. max\_error\_number
3. max\_batch\_interval
4. max\_batch\_rows
5. max\_batch\_size
6. jsonpaths
7. json\_root
8. strip\_outer\_array
9. strict\_mode
10. timezone
11. num\_as\_string
12. fuzzy\_parse
13. partial\_columns
14. max\_filter\_ratio

#### 4. data\_source

数据源的类型。当前支持：

KAFKA

#### 5. data\_source\_properties

数据源的相关属性。目前仅支持：

1. kafka\_partitions
2. kafka\_offsets
3. kafka\_broker\_list
4. kafka\_topic
5. 自定义 property，如 property.group.id

注：

1. kafka\_partitions 和 kafka\_offsets 用于修改待消费的 kafka partition 的 offset，仅能修改当前已经消费的 partition。不能新增 partition。

## 举例

1. 将 desired\_concurrent\_number 修改为 1

```
ALTER ROUTINE LOAD FOR db1.label1
PROPERTIES
(
 "desired_concurrent_number" = "1"
);
```

2. 将 desired\_concurrent\_number 修改为 10，修改 partition 的 offset，修改 group id。

```
```sql ALTER ROUTINE LOAD FOR db1.label1 PROPERTIES ( "desired_concurrent_number" = "10" )
FROM kafka ( "kafka_partitions" = "0, 1, 2", "kafka_offsets" = "100, 200, 100", "property.group.id" =
"new_group" );
```

Keywords

ALTER, ROUTINE, LOAD

Best Practice

PAUSE-ROUTINE-LOAD

PAUSE-ROUTINE-LOAD

Name

PAUSE ROUTINE LOAD

描述

用于暂停一个 Routine Load 作业。被暂停的作业可以通过 RESUME 命令重新运行。

```
PAUSE [ALL] ROUTINE LOAD FOR job_name
```

举例

1. 暂停名称为 test1 的例行导入作业。

```
PAUSE ROUTINE LOAD FOR test1;
```

2. 暂停所有例行导入作业。

```
PAUSE ALL ROUTINE LOAD;
```

Keywords

```
PAUSE, ROUTINE, LOAD
```

Best Practice

RESUME-ROUTINE-LOAD

RESUME-ROUTINE-LOAD

Name

RESUME ROUTINE LOAD

描述

用于重启一个被暂停的 Routine Load 作业。重启的作业，将继续从之前已消费的 offset 继续消费。

```
RESUME [ALL] ROUTINE LOAD FOR job_name
```

举例

1. 重启名称为 test1 的例行导入作业。

```
RESUME ROUTINE LOAD FOR test1;
```

2. 重启所有例行导入作业。

```
RESUME ALL ROUTINE LOAD;
```

Keywords

```
RESUME, ROUTINE, LOAD
```

Best Practice

STOP-ROUTINE-LOAD

STOP-ROUTINE-LOAD

Name

STOP ROUTINE LOAD

描述

用户停止一个 Routine Load 作业。被停止的作业无法再重新运行。

```
STOP ROUTINE LOAD FOR job_name;
```

举例

1. 停止名称为 test1 的例行导入作业。

```
STOP ROUTINE LOAD FOR test1;
```

Keywords

```
STOP, ROUTINE, LOAD
```

Best Practice

CREATE-SYNC-JOB

CREATE-SYNC-JOB

Name

CREATE SYNC JOB

描述

数据同步(Sync Job)功能，支持用户提交一个常驻的数据同步作业，通过从指定的远端地址读取Binlog日志，增量同步用户在Mysql数据库的对数据更新操作的CDC(Change Data Capture)功能。

目前数据同步作业只支持对接Canal，从Canal Server上获取解析好的Binlog数据，导入到Doris内。

用户可通过 [SHOW SYNC JOB](#) 查看数据同步作业状态。

语法：

```
CREATE SYNC [db.]job_name
(
    channel_desc,
    channel_desc
    ...
)
binlog_desc
```

1. job_name

同步作业名称，是作业在当前数据库内的唯一标识，相同job_name的作业只能有一个在运行。

2. channel_desc

作业下的数据通道，用来描述mysql源表到doris目标表的映射关系。

语法：

```
FROM mysql_db.src_tbl INTO des_tbl
[column_mapping]
```

1. mysql_db.src_tbl

指定mysql端的数据库和源表。

2. des_tbl

指定doris端的目标表，只支持Unique表，且需开启表的batch delete功能(开启方法请看help alter table的'批量删除功能')。

3. column_mapping

指定mysql源表和doris目标表的列之间的映射关系。如果不指定，FE会默认源表和目标表的列按顺序一一对应。

不支持 `col_name = expr` 的形式表示列。

示例：

```
假设目标表列为(k1, k2, v1),  
  
改变列k1和k2的顺序  
(k2, k1, v1)  
  
忽略源数据的第四列  
(k2, k1, v1, dummy_column)
```

3. binlog_desc

用来描述远端数据源，目前仅支持canal一种。

语法：

```
FROM BINLOG  
(  
    "key1" = "value1",  
    "key2" = "value2"  
)
```

1. Canal 数据源对应的属性，以canal.为前缀

1. canal.server.ip: canal server的地址
2. canal.server.port: canal server的端口
3. canal.destination: instance的标识
4. canal.batchSize: 获取的batch大小的最大值，默认8192
5. canal.username: instance的用户名
6. canal.password: instance的密码
7. canal.debug: 可选，设置为true时，会将batch和每一行数据的详细信息都打印出来

举例

1. 简单为 test_db 的 test_tbl 创建一个名为 job1 的数据同步作业，连接本地的Canal服务器，对应Mysql源表 mysql_db1.tbl1。

```
CREATE SYNC `test_db`.`job1`  
(  
    FROM `mysql_db1`.`tbl1` INTO `test_tbl`  
)  
FROM BINLOG  
(  
    "type" = "canal",  
    "canal.server.ip" = "127.0.0.1",  
    "canal.server.port" = "11111",  
    "canal.destination" = "example",  
    "canal.username" = "",
```

```
"canal.password" = ""  
);
```

2. 为 test_db 的多张表创建一个名为 job1 的数据同步作业，一一对应多张Mysql源表，并显式的指定列映射。

```
CREATE SYNC `test_db`.`job1`  
(  
  FROM `mysql_db`.`t1` INTO `test1` (k1, k2, v1),  
  FROM `mysql_db`.`t2` INTO `test2` (k3, k4, v2)  
)  
FROM BINLOG  
(  
  "type" = "canal",  
  "canal.server.ip" = "xx.xxx.xxx.xx",  
  "canal.server.port" = "12111",  
  "canal.destination" = "example",  
  "canal.username" = "username",  
  "canal.password" = "password"  
);
```

Keywords

```
CREATE, SYNC, JOB
```

Best Practice

PAUSE SYNC JOB

描述

通过 `job_name` 暂停一个数据库内正在运行的常驻数据同步作业。被暂停的作业将停止同步数据，并保持消费的最新位置，直到用户恢复该作业。

语法

```
PAUSE SYNC JOB [<db>.<job_name>
```

必选参数

1. `<job_name>` > 要暂停的同步作业的名称。

可选参数

1. `<db>` > 如果使用`[.]`前缀指定了一个数据库，那么该作业将处于指定的数据库中；否则，将使用当前数据库。

权限控制

任意用户或角色都可以执行该操作

示例

1. 暂停名称为 `job_name` 的数据同步作业。

```
PAUSE SYNC JOB `job_name`;
```

RESUME-SYNC-JOB

RESUME-SYNC-JOB

Name

RESUME SYNC JOB

描述

通过 `job_name` 恢复一个当前数据库已被暂停的常驻数据同步作业，作业将从上一次被暂停前最新的位置继续同步数据。

语法:

```
RESUME SYNC JOB [db.]job_name
```

举例

1. 恢复名称为 `job_name` 的数据同步作业

```
RESUME SYNC JOB `job_name`;
```

Keywords

```
RESUME, SYNC, LOAD
```

Best Practice

STOP-SYNC-JOB

STOP-SYNC-JOB

Name

STOP SYNC JOB

描述

通过 job_name 停止一个数据库内非停止状态的常驻数据同步作业。

语法:

```
STOP SYNC JOB [db.]job_name
```

举例

1. 停止名称为 job_name 的数据同步作业

```
STOP SYNC JOB `job_name`;
```

Keywords

```
STOP, SYNC, JOB
```

Best Practice

CANCEL-LOAD

CANCEL-LOAD

Name

CANCEL LOAD

描述

该语句用于撤销指定 label 的导入作业。或者通过模糊匹配批量撤销导入作业

```
CANCEL LOAD
[FROM db_name]
WHERE [LABEL = "load_label" | LABEL like "label_pattern" | STATE = "PENDING/ETL/LOADING"]
```

注：1.2.0 版本之后支持根据 State 取消作业。

举例

1. 撤销数据库 example_db 上，label 为 example_db_test_load_label 的导入作业

```
CANCEL LOAD
FROM example_db
WHERE LABEL = "example_db_test_load_label";
```

2. 撤销数据库 exampledb 上，所有包含 example 的导入作业。

```
CANCEL LOAD
FROM example_db
WHERE LABEL like "example_";
```

3. 取消状态为 LOADING 的导入作业。

```
CANCEL LOAD
FROM example_db
WHERE STATE = "loading";
```

:::tip 提示 该功能自 Apache Doris 1.2 版本起支持 :::

Keywords

CANCEL, LOAD

Best Practice

1. 只能取消处于 PENDING、ETL、LOADING 状态的未完成的导入作业。
2. 当执行批量撤销时，Doris 不会保证所有对应的导入作业原子的撤销。即有可能仅有部分导入作业撤销成功。用户可以通过 SHOW LOAD 语句查看作业状态，并尝试重复执行 CANCEL LOAD 语句。

CLEAN-LABEL

CLEAN-LABEL

Name

提示

该功能自 Apache Doris 1.2 版本起支持

CLEAN LABEL

描述

用于手动清理历史导入作业的 Label。清理后，Label 可以重复使用。

语法：

```
CLEAN LABEL [label] FROM db;
```

举例

1. 清理 db1 中，Label 为 label1 的导入作业。

```
CLEAN LABEL label1 FROM db1;
```

2. 清理 db1 中所有历史 Label。

```
CLEAN LABEL FROM db1;
```

Keywords

```
CLEAN, LABEL
```

Best Practice

INSERT

INSERT

Name

INSERT

描述

该语句是完成数据插入操作。

```
INSERT INTO table_name
  [ PARTITION (p1, ...) ]
  [ WITH LABEL label]
  [ (column [, ...]) ]
  [ [ hint [, ...] ] ]
  { VALUES ( { expression | DEFAULT } [, ...] ) [, ...] | query }
```

Parameters

table_name: 导入数据的目的表。可以是 db_name.table_name 形式

partitions: 指定待导入的分区，必须是 table_name 中存在的分区，多个分区名称用逗号分隔

label: 为 Insert 任务指定一个 label

column_name: 指定的目的列，必须是 table_name 中存在的列

expression: 需要赋值给某个列的对应表达式

DEFAULT: 让对应列使用默认值

query: 一个普通查询，查询的结果会写入到目标中

hint: 用于指示 INSERT 执行行为的一些指示符。目前 hint 有三个可选值/*+ STREAMING */、/*+ SHUFFLE */或/*+ NOSHUFFLE */ 1. STREAMING：目前无实际作用，只是为了兼容之前的版本，因此保留。（之前的版本加上这个 hint 会返回 label，现在默认都会返回 label） 2. SHUFFLE：当目标表是分区表，开启这个 hint 会进行 repartition。 3. NOSHUFFLE：即使目标表是分区表，也不会进行 repartition，但会做一些其他操作以保证数据正确落到各个分区中。

对于开启了 merge-on-write 的 Unique 表，还可以使用 insert 语句进行部分列更新的操作。要使用 insert 语句进行部分列更新，需要将会话变量 enable_unique_key_partial_update 的值设置为 true(该变量默认值为 false，即默认无法通过 insert 语句进行部分列更新)。进行部分列更新时，插入的列必须至少包含所有的 Key 列，同时指定需要更新的列。如果插入行 Key 列的值在原表中存在，则将更新具有相同 key 列值那一行的数据。如果插入行 Key 列的值在原表中不存在，则将向表中插入一条新的数据，此时 insert 语句中没有指定的列必须有默认值或

可以为 null，这些缺失列会首先尝试用默认值填充，如果该列没有默认值，则尝试使用 null 值填充，如果该列不能为 null，则本次插入失败。

需要注意的是，控制 insert 语句是否开启严格模式的会话变量 `enable_insert_strict` 的默认值为 true，即 insert 语句默认开启严格模式，而在严格模式下进行部分列更新不允许更新不存在的 key。所以，在使用 insert 语句进行部分列更新的时候如果希望能插入不存在的 key，需要在 `enable_unique_key_partial_update` 设置为 true 的基础上同时将 `enable_insert_strict` 设置为 false。

注意：

当前执行 INSERT 语句时，对于有不符合目标表格式的数据，默认的行为是过滤，比如字符串超长等。但是对于有要求数据不能够被过滤的业务场景，可以通过设置会话变量 `enable_insert_strict` 为 true 来确保当有数据被过滤掉的时候，INSERT 不会被执行成功。

举例

test 表包含两个列 c1, c2。

1. 向test表中导入一行数据

```
INSERT INTO test VALUES (1, 2);
INSERT INTO test (c1, c2) VALUES (1, 2);
INSERT INTO test (c1, c2) VALUES (1, DEFAULT);
INSERT INTO test (c1) VALUES (1);
```

其中第一条、第二条语句是一样的效果。在不指定目标列时，使用表中的列顺序来作为默认的目标列。第三条、第四条语句表达的意思是一样的，使用 c2 列的默认值，来完成数据导入。

2. 向test表中一次性导入多行数据

```
INSERT INTO test VALUES (1, 2), (3, 2 + 2);
INSERT INTO test (c1, c2) VALUES (1, 2), (3, 2 * 2);
INSERT INTO test (c1) VALUES (1), (3);
INSERT INTO test (c1, c2) VALUES (1, DEFAULT), (3, DEFAULT);
```

其中第一条、第二条语句效果一样，向 test 表中一次性导入两条数据 第三条、第四条语句效果已知，使用 c2 列的默认值向 test 表中导入两条数据

3. 向 test 表中导入一个查询语句结果

```
INSERT INTO test SELECT * FROM test2;
INSERT INTO test (c1, c2) SELECT * from test2;
```

4. 向 test 表中导入一个查询语句结果，并指定 partition 和 label

```
INSERT INTO test PARTITION(p1, p2) WITH LABEL `label1` SELECT * FROM test2;
INSERT INTO test WITH LABEL `label1` (c1, c2) SELECT * from test2;
```

Keywords

INSERT

Best Practice

1. 查看返回结果

INSERT 操作是一个同步操作，返回结果即表示操作结束。用户需要根据返回结果的不同，进行对应的处理。

1. 执行成功，结果集为空

如果 insert 对应 select 语句的结果集为空，则返回如下：

```
mysql> insert into tbl1 select * from empty_tbl;  
Query OK, 0 rows affected (0.02 sec)
```

Query OK 表示执行成功。0 rows affected 表示没有数据被导入。

2. 执行成功，结果集不为空

在结果集不为空的情况下。返回结果分为如下几种情况：

1. Insert 执行成功并可见：

```
mysql> insert into tbl1 select * from tbl2;  
Query OK, 4 rows affected (0.38 sec)  
{'label':'insert_8510c568-9eda-4173-9e36-6adc7d35291c', 'status':'visible',  
'txnId':'4005'}
```

```
mysql> insert into tbl1 with label my_label1 select * from tbl2;  
Query OK, 4 rows affected (0.38 sec)  
{'label':'my_label1', 'status':'visible', 'txnId':'4005'}
```

```
mysql> insert into tbl1 select * from tbl2;  
Query OK, 2 rows affected, 2 warnings (0.31 sec)  
{'label':'insert_f0747f0e-7a35-46e2-affa-13a235f4020d', 'status':'visible',  
'txnId':'4005'}
```

```
mysql> insert into tbl1 select * from tbl2;  
Query OK, 2 rows affected, 2 warnings (0.31 sec)  
{'label':'insert_f0747f0e-7a35-46e2-affa-13a235f4020d', 'status':'committed',  
'txnId':'4005'}
```

Query OK 表示执行成功。4 rows affected 表示总共有 4 行数据被导入。2 warnings 表示被过滤的行数。

同时会返回一个 json 串：

```
{'label':'my_label1', 'status':'visible', 'txnId':'4005'}  
{'label':'insert_f0747f0e-7a35-46e2-affa-13a235f4020d', 'status':'committed',  
'txnId':'4005'}  
{'label':'my_label1', 'status':'visible', 'txnId':'4005', 'err':'some other error'}
```

label 为用户指定的 label 或自动生成的 label。Label 是该 Insert Into 导入作业的标识。每个导入作业，都有一个在单 database 内部唯一的 Label。

status 表示导入数据是否可见。如果可见，显示 visible，如果不可见，显示 committed。

txnId 为这个 insert 对应的导入事务的 id。

err 字段会显示一些其他非预期错误。

当需要查看被过滤的行时，用户可以通过如下语句

```
show load where label="xxx";
```

返回结果中的 URL 可以用于查询错误的数据，具体见后面 [查看错误行](#) 小结。

数据不可见是一个临时状态，这批数据最终是一定可见的

可以通过如下语句查看这批数据的可见状态：

```
show transaction where id=4005;
```

返回结果中的 TransactionStatus 列如果为 visible，则表述数据可见。

3. 执行失败

执行失败表示没有任何数据被成功导入，并返回如下：

```
mysql> insert into tbl1 select * from tbl2 where k1 = "a";
ERROR 1064 (HY000): all partitions have no load data. url:
http://10.74.167.16:8042/api/_load_error_log?
file=__shard_2/error_log_insert_stmt_ba8bb9e158e4879-
ae8de8507c0bf8a2_ba8bb9e158e4879_ae8de8507c0bf8a2
```

其中 ERROR 1064 (HY000): all partitions have no load data 显示失败原因。后面的 url 可以用于查询错误的数据：

```
show load warnings on "url";
```

可以查看到具体错误行。

2. 超时时间

INSERT 操作的超时时间由 [会话变量](#) insert_timeout 控制。默认为 4 小时。超时则作业会被取消。

3. Label 和原子性

INSERT 操作同样能够保证导入的原子性，可以参阅 [导入事务和原子性](#) 文档。

当需要使用 CTE(Common Table Expressions) 作为 insert 操作中的查询部分时，必须指定 WITH LABEL 和 column 部分。

4. 过滤阈值

与其他导入方式不同，INSERT 操作不能指定过滤阈值（max_filter_ratio）。默认的过滤阈值为 1，即素有错误行都可以被忽略。

对于有要求数据不能够被过滤的业务场景，可以通过设置 [会话变量](#) enable_insert_strict 为 true 来确保当有数据被过滤掉的时候，INSERT 不会被执行成功。

5. 性能问题

不建议使用 VALUES 方式进行单行的插入。如果必须这样使用，请将多行数据合并到一个 INSERT 语句中进行批量提交。

SELECT

SELECT

Name

SELECT

描述

主要介绍 Select 语法使用

语法：

```
SELECT
    [hint_statement, ...]
    [ALL | DISTINCT | DISTINCTROW | ALL EXCEPT ( col_name1 [, col_name2, col_name3, ...] )]
    select_expr [, select_expr ...]
    [FROM table_references
        [PARTITION partition_list]
        [TABLET tabletid_list]
        [TABLESAMPLE sample_value [ROWS | PERCENT]
            [REPEATABLE pos_seek]]
    [WHERE where_condition]
    [GROUP BY [GROUPING SETS | ROLLUP | CUBE] {col_name | expr | position}]
    [HAVING where_condition]
    [ORDER BY {col_name | expr | position}
        [ASC | DESC], ...]
    [LIMIT {[offset,] row_count | row_count OFFSET offset}]
    [INTO OUTFILE 'file_name']
```

语法说明：

1. select_expr, ... 检索并在结果中显示的列，使用别名时，as 为自选。
2. select_expr, ... 检索的目标表（一个或者多个表（包括子查询产生的临时表）
3. where_definition 检索条件（表达式），如果存在 WHERE 子句，其中的条件对行数据进行筛选。
where_condition 是一个表达式，对于要选择的每一行，其计算结果为 true。如果没有 WHERE 子句，该语句将选择所有行。在 WHERE 表达式中，您可以使用除聚合函数之外的任何 MySQL 支持的函数和运算符
4. ALL | DISTINCT：对结果集进行刷选，all 为全部，distinct/distinctrow 将刷选出重复列，默认为 all
5. ALL EXCEPT：对全部（all）结果集进行筛选，except 指定要从全部结果集中排除的一个或多个列的名称。输出中将忽略所有匹配的列名称。

提示

该功能自 Apache Doris 1.2 版本起支持

6. INTO OUTFILE 'file_name': 保存结果至新文件（之前不存在）中，区别在于保存的格式。

7. Group by having: 对结果集进行分组，having 出现则对 group by 的结果进行筛选。Grouping Sets、Rollup、Cube 为 group by 的扩展，详细可参考[GROUPING SETS 设计文档](#)。

8. Order by: 对最后的结果进行排序，Order by 通过比较一列或者多列的大小来对结果集进行排序。

Order by 是比较耗时耗资源的操作，因为所有数据都需要发送到 1 个节点后才能排序，排序操作相比不排序操作需要更多的内存。

如果需要返回前 N 个排序结果，需要使用 LIMIT 从句；为了限制内存的使用，如果用户没有指定 LIMIT 从句，则默认返回前 65535 个排序结果。

9. Limit n: 限制输出结果中的行数，limit m,n 表示从第 m 行开始输出 n 条记录，**使用 limit m,n 的时候要加上 order by 才有意义，否则每次执行的数据可能会不一致**

10. Having 从句不是过滤表中的行数据，而是过滤聚合函数产出的结果。

通常来说 having 要和聚合函数（例如 :COUNT(), SUM(), AVG(), MIN(), MAX()）以及 group by 从句一起使用。

11. SELECT 支持使用 PARTITION 显式分区选择，其中包含 table_reference 中表的名称后面的分区或子分区（或两者）列表。

12. [TABLET tids] TABLESAMPLE n [ROWS | PERCENT] [REPEATABLE seek]: 在 FROM 子句中限制表的读取行数，根据指定的行数或百分比从表中伪随机的选择数个 Tablet，REPEATABLE 指定种子数可使选择的样本再次返回，此外也可手动指定 TableID，注意这只能用于 OLAP 表。

13. hint_statement: 在 selectlist 前面使用 hint 表示可以通过 hint 去影响优化器的行为以期得到想要的执行计划，详情可参考[joinHint 使用文档](#)

语法约束：

1. SELECT 也可用于检索计算的行而不引用任何表。
2. 所有的子句必须严格地按照上面格式排序，一个 HAVING 子句必须位于 GROUP BY 子句之后，并位于 ORDER BY 子句之前。
3. 别名关键词 AS 自选。别名可用于 group by, order by 和 having
4. Where 子句：执行 WHERE 语句以确定哪些行应被包含在 GROUP BY 部分中，而 HAVING 用于确定应使用结果集中的哪些行。
5. HAVING 子句可以引用总计函数，而 WHERE 子句不能引用，如 count,sum,max,min,avg，同时，where 子句可以引用除总计函数外的其他函数。Where 子句中不能使用列别名来定义条件。
6. Group by 后跟 with rollup 可以对结果进行一次或者多次统计。

联接查询：

Doris 支持以下 JOIN 语法

```
JOIN
table_references:
    table_reference [, table_reference] ...
```

```

table_reference:
    table_factor
  | join_table
table_factor:
    tbl_name [[AS] alias]
      [{USE|IGNORE|FORCE} INDEX (key_list)]
  | ( table_references )
  | { OJ table_reference LEFT OUTER JOIN table_reference
      ON conditional_expr }
join_table:
    table_reference [INNER | CROSS] JOIN table_factor [join_condition]
  | table_reference STRAIGHT_JOIN table_factor
  | table_reference STRAIGHT_JOIN table_factor ON condition
  | table_reference LEFT [OUTER] JOIN table_reference join_condition
  | table_reference NATURAL [LEFT [OUTER]] JOIN table_factor
  | table_reference RIGHT [OUTER] JOIN table_reference join_condition
  | table_reference NATURAL [RIGHT [OUTER]] JOIN table_factor
join_condition:
    ON conditional_expr

```

UNION 语法:

```

SELECT ...
UNION [ALL| DISTINCT] SELECT .....
[UNION [ALL| DISTINCT] SELECT ...]

```

UNION 用于将多个 SELECT 语句 的结果组合 到单个结果集中。

第一个 SELECT 语句中的列名称用作返回结果的列名称。在每个 SELECT 语句的 相应位置列出的选定列 应具有相同的数据类型。（例如，第一个语句选择的第一列应该与其他语句选择的第一列具有相同的类型。）

默认行为 UNION 是从结果中删除重复的行。可选 DISTINCT 关键字除了默认值之外没有任何效果，因为它还指定了重复行删除。使用可选 ALL 关键字，不会发生重复行删除，结果包括所有 SELECT 语句中的 所有匹配行

WITH 语句:

要指定公用表表达式，请使用 WITH 具有一个或多个逗号分隔子句的子句。每个子条款都提供一个子查询，用于生成结果集，并将名称与子查询相关联。下面的示例定义名为的 CTE cte1 和 cte2 中 WITH 子句，并且是指它们在它们的顶层 SELECT 下面的 WITH 子句：

```

WITH
    cte1 AS (SELECT a, b FROM table1),
    cte2 AS (SELECT c, d FROM table2)
SELECT b, d FROM cte1 JOIN cte2
WHERE cte1.a = cte2.c;

```

在包含该 WITH 子句 的语句中，可以引用每个 CTE 名称以访问相应的 CTE 结果集。

CTE 名称可以在其他 CTE 中引用，从而可以基于其他 CTE 定义 CTE。

目前不支持递归的 CTE。

举例

1. 查询年龄分别是 18,20,25 的学生姓名

```
select Name from student where age in (18,20,25);
```

2. ALL EXCEPT 示例

```
-- 查询除了学生年龄的所有信息  
select * except(age) from student;
```

3. GROUP BY 示例

```
--查询 tb_book 表, 按照 type 分组, 求每类图书的平均价格,  
select type,avg(price) from tb_book group by type;
```

4. DISTINCT 使用

```
--查询 tb_book 表, 除去重复的 type 数据  
select distinct type from tb_book;
```

5. ORDER BY 示例

对查询结果进行升序（默认）或降序（DESC）排列。升序 NULL 在最前面，降序 NULL 在最后面

```
--查询 tb_book 表中的所有记录, 按照 id 降序排列, 显示三条记录  
select * from tb_book order by id desc limit 3;
```

6. LIKE 模糊查询

可实现模糊查询，它有两种通配符：%和_，%可以匹配一个或多个字符，_可以匹配一个字符

```
--查找所有第二个字符是 h 的图书  
select * from tb_book where name like('_h%');
```

7. LIMIT 限定结果行数

```
--1.降序显示 3 条记录  
select * from tb_book order by price desc limit 3;  
  
--2.从 id=1 显示 4 条记录  
select * from tb_book where id limit 1,4;
```

8. CONCAT 联合多列

```
--把 name 和 price 合并成一个新的字符串输出  
select id,concat(name,":",price) as info,type from tb_book;
```

9. 使用函数和表达式

```
--计算 tb_book 表中各类图书的总价格  
select sum(price) as total,type from tb_book group by type;
```

```
--price 打八折
select *,(price * 0.8) as "八折" from tb_book;
```

10. UNION 示例

```
SELECT a FROM t1 WHERE a = 10 AND B = 1 ORDER by a LIMIT 10
UNION
SELECT a FROM t2 WHERE a = 11 AND B = 2 ORDER by a LIMIT 10;
```

11. WITH 子句示例

```
WITH cte AS
(
    SELECT 1 AS col1, 2 AS col2
    UNION ALL
    SELECT 3, 4
)
SELECT col1, col2 FROM cte;
```

12. JOIN 示例

```
SELECT * FROM t1 LEFT JOIN (t2, t3, t4)
    ON (t2.a = t1.a AND t3.b = t1.b AND t4.c = t1.c)
```

等同于

```
SELECT * FROM t1 LEFT JOIN (t2 CROSS JOIN t3 CROSS JOIN t4)
    ON (t2.a = t1.a AND t3.b = t1.b AND t4.c = t1.c)
```

13. INNER JOIN

```
SELECT t1.name, t2.salary
    FROM employee AS t1 INNER JOIN info AS t2 ON t1.name = t2.name;

SELECT t1.name, t2.salary
    FROM employee t1 INNER JOIN info t2 ON t1.name = t2.name;
```

14. LEFT JOIN

```
SELECT left_tbl.*
    FROM left_tbl LEFT JOIN right_tbl ON left_tbl.id = right_tbl.id
    WHERE right_tbl.id IS NULL;
```

15. RIGHT JOIN

```
mysql> SELECT * FROM t1 RIGHT JOIN t2 ON (t1.a = t2.a);
```

a	b	a	c
2	y	2	z
NULL	NULL	3	w

16. TABLESAMPLE

--在t1中伪随机的抽样1000行。注意实际是根据表的统计信息选择若干Tablet，被选择的Tablet总行数可能大于1000，所以若想明确返回1000行需要加上Limit。

```
SELECT * FROM t1 TABLET(10001) TABLESAMPLE(1000 ROWS) REPEATABLE 2 limit 1000;
```

keywords

SELECT

Best Practice

1. 关于 SELECT 子句的一些附加知识

- 可以使用 AS alias_name 为 select_expr 指定别名。别名用作表达式的列名，可用于 GROUP BY, ORDER BY 或 HAVING 子句。AS 关键字是在指定列的别名时养成使用 AS 是一种好习惯。
- FROM 后的 table_references 指示参与查询的一个或者多个表。如果列出了多个表，就会执行 JOIN 操作。而对于每一个指定表，都可以为其定义别名
- SELECT 后被选择的列，可以在 ORDER IN 和 GROUP BY 中，通过列名、列别名或者代表列位置的整数（从 1 开始）来引用

```
SELECT college, region, seed FROM tournament
ORDER BY region, seed;

SELECT college, region AS r, seed AS s FROM tournament
ORDER BY r, s;

SELECT college, region, seed FROM tournament
ORDER BY 2, 3;
```

- 如果 ORDER BY 出现在子查询中，并且也应用于外部查询，则最外层的 ORDER BY 优先。
- 如果使用了 GROUP BY，被分组的列会自动按升序排列（就好像有一个 ORDER BY 语句后面跟了同样的列）。如果要避免 GROUP BY 因为自动排序生成的开销，添加 ORDER BY NULL 可以解决：

```
SELECT a, COUNT(b) FROM test_table GROUP BY a ORDER BY NULL;
```

- 当使用 ORDER BY 或 GROUP BY 对 SELECT 中的列进行排序时，服务器仅使用 max_sort_length 系统变量指示的初始字节数对值进行排序。
- Having 子句一般应用在最后，恰好在结果集被返回给 MySQL 客户端前，且没有进行优化。（而 LIMIT 应用在 HAVING 后）

SQL 标准要求：HAVING 必须引用在 GROUP BY 列表中或者聚合函数使用的列。然而，MySQL 对此进行了扩展，它允许 HAVING 引用 Select 子句列表中的列，还有外部子查询的列。

如果 HAVING 引用的列具有歧义，会有警告产生。下面的语句中，col2 具有歧义：

```
SELECT COUNT(col1) AS col2 FROM t GROUP BY col2 HAVING col2 = 2;
```

- 切记不要在该使用 WHERE 的地方使用 HAVING。HAVING 是和 GROUP BY 搭配的。
- HAVING 子句可以引用聚合函数，而 WHERE 不能。

```
SELECT user, MAX(salary) FROM users  
GROUP BY user HAVING MAX(salary) > 10;
```

- LIMIT 子句可用于约束 SELECT 语句返回的行数。LIMIT 可以有一个或者两个参数，都必须为非负整数。

```
/*取回结果集中的 6~15 行*/  
SELECT * FROM tbl LIMIT 5,10;  
/*那如果要取回一个设定某个偏移量之后的所有行，可以为第二参数设定一个非常大的常量。以下查询取回从第 96 行起的所有数据*/  
SELECT * FROM tbl LIMIT 95,18446744073709551615;  
/*若 LIMIT 只有一个参数，则参数指定应该取回的行数，偏移量默认为 0，即从第一行起*/
```

- SELECT...INTO 可以让查询结果写入到文件中

2. SELECT 关键字的修饰符

- 去重

ALL 和 DISTINCT 修饰符指定是否对结果集中的行（应该不是某个列）去重。

ALL 是默认修饰符，即满足要求的所有行都要被取回来。

DISTINCT 删除重复的行。

3. 子查询的主要优势

- 子查询允许结构化的查询，这样就可以把一个语句的每个部分隔离开。
- 有些操作需要复杂的联合和关联。子查询提供了其它的方法来执行这些操作

4. 加速查询

- 尽可能利用 Doris 的分区桶作为数据过滤条件，减少数据扫描范围
- 充分利用 Doris 的前缀索引字段作为数据过滤条件加速查询速度

5. UNION

- 只使用 union 关键词和使用 union disitnct 的效果是相同的。由于去重工作是比较耗费内存的，因此使用 union all 操作查询速度会快些，耗费内存会少些。如果用户想对返回结果集进行 order by 和 limit 操作，需要将 union 操作放在子查询中，然后 select from subquery，最后把 subquery 和 order by 放在子查询外面。

```
select * from (select age from student_01 union all select age from student_02) as t1  
order by age limit 4;
```

```
+-----+  
|   age   |  
+-----+
```

```
|      18      |  
|      19      |  
|      20      |  
|      21      |  
+-----+  
4 rows in set (0.01 sec)
```

6. JOIN

- 在 inner join 条件里除了支持等值 join，还支持不等值 join，为了性能考虑，推荐使用等值 join。
- 其它 join 只支持等值 join

DELETE

DELETE

Name

DELETE

描述

该语句用于按条件删除指定 table (base index) partition 中的数据。

该操作会同时删除和此 base index 相关的 rollup index 的数据。

语法

语法一：该语法只能指定过滤谓词

```
DELETE FROM table_name [table_alias] [PARTITION partition_name | PARTITIONS (partition_name [, partition_name])]  
WHERE  
column_name op { value | value_list } [ AND column_name op { value | value_list } ...];
```

语法二：该语法只能在 UNIQUE KEY 模型表上使用

```
DELETE FROM table_name [table_alias]  
[PARTITION partition_name | PARTITIONS (partition_name [, partition_name])]  
[USING additional_tables]  
WHERE condition
```

Required Parameters

- table_name: 指定需要删除数据的表
- column_name: 属于 table_name 的列
- op: 逻辑比较操作符，可选类型包括：=, >, <, >=, <=, !=, in, not in
- value | value_list: 做逻辑比较的值或值列表
- WHERE condition: 指定一个用于选择删除行的条件

Optional Parameters

- PARTITION partition_name | PARTITIONS (partition_name [, partition_name]): 指定执行删除数据的分区名，如果表不存在此分区，则报错

- `table_alias`: 表的别名
- `USING additional_tables`: 如果需要在 `WHERE` 语句中使用其他的表来帮助识别需要删除的行, 则可以在 `USING` 中指定这些表或者查询。

Note

1. 使用聚合类的表模型 (`AGGREGATE`、`UNIQUE`) 只能指定 `key` 列上的条件。
2. 当选定的 `key` 列不存在于某个 `rollup` 中时, 无法进行 `delete`。
3. 语法一中, 条件之间只能是“与”的关系。若希望达成“或”的关系, 需要将条件分写在两个 `DELETE` 语句中。
4. 语法一中, 如果为分区表, 需要指定分区, 如果不指定, `doris` 会从条件中推断出分区。两种情况下, `doris` 无法从条件中推断出分区: 1) 条件中不包含分区列; 2) 分区列的 `op` 为 `not in`。当分区表未指定分区, 或者无法从条件中推断分区的时候, 需要设置会话变量 `delete_without_partition` 为 `true`, 此时 `delete` 会应用到所有分区。

提示

该功能自 Apache Doris 1.2 版本起支持

5. 该语句可能会降低执行后一段时间内的查询效率。影响程度取决于语句中指定的删除条件的数量。指定的条件越多, 影响越大。

举例

1. 删除 `my_table` partition `p1` 中 `k1` 列值为 3 的数据行

```
DELETE FROM my_table PARTITION p1
WHERE k1 = 3;
```

2. 删除 `my_table` partition `p1` 中 `k1` 列值大于等于 3 且 `k2` 列值为 “abc” 的数据行

```
DELETE FROM my_table PARTITION p1
WHERE k1 >= 3 AND k2 = "abc";
```

3. 删除 `my_table` partition `p1`, `p2` 中 `k1` 列值大于等于 3 且 `k2` 列值为 “abc” 的数据行

```
DELETE FROM my_table PARTITIONS (p1, p2)
WHERE k1 >= 3 AND k2 = "abc";
```

4. 使用 `t2`和`t3`表连接的结果, 删除`t1`中的数据, 删除的表只支持 `unique` 模型

```
-- 创建 t1, t2, t3 三张表
CREATE TABLE t1
(id INT, c1 BIGINT, c2 STRING, c3 DOUBLE, c4 DATE)
UNIQUE KEY (id)
```

```

DISTRIBUTED BY HASH (id)
PROPERTIES('replication_num'='1', "function_column.sequence_col" = "c4");

CREATE TABLE t2
  (id INT, c1 BIGINT, c2 STRING, c3 DOUBLE, c4 DATE)
DISTRIBUTED BY HASH (id)
PROPERTIES('replication_num'='1');

CREATE TABLE t3
  (id INT)
DISTRIBUTED BY HASH (id)
PROPERTIES('replication_num'='1');

-- 插入数据
INSERT INTO t1 VALUES
  (1, 1, '1', 1.0, '2000-01-01'),
  (2, 2, '2', 2.0, '2000-01-02'),
  (3, 3, '3', 3.0, '2000-01-03');

INSERT INTO t2 VALUES
  (1, 10, '10', 10.0, '2000-01-10'),
  (2, 20, '20', 20.0, '2000-01-20'),
  (3, 30, '30', 30.0, '2000-01-30'),
  (4, 4, '4', 4.0, '2000-01-04'),
  (5, 5, '5', 5.0, '2000-01-05');

INSERT INTO t3 VALUES
  (1),
  (4),
  (5);

-- 删除 t1 中的数据
DELETE FROM t1
  USING t2 INNER JOIN t3 ON t2.id = t3.id
  WHERE t1.id = t2.id;

```

预期结果为，删除了t1表id为1的列

```

+---+---+---+---+---+
| id | c1 | c2 | c3 | c4 |
+---+---+---+---+---+
| 2  | 2  | 2  | 2.0 | 2000-01-02 |
| 3  | 3  | 3  | 3.0 | 2000-01-03 |
+---+---+---+---+---+

```

Keywords

DELETE

Best Practice

UPDATE

UPDATE

Name

UPDATE

描述

该语句是为进行对数据进行更新的操作，UPDATE 语句目前仅支持 UNIQUE KEY 模型。

UPDATE 操作目前只支持更新 Value 列，Key 列的更新可参考[使用 FlinkCDC 更新 Key 列](#)。

语法

```
UPDATE target_table [table_alias]
  SET assignment_list
  WHERE condition
```

```
assignment_list:
  assignment [, assignment] ...
```

```
assignment:
  col_name = value
```

```
value:
  {expr | DEFAULT}
```

```
UPDATE target_table [table_alias]
  SET assignment_list
  [ FROM additional_tables]
  WHERE condition
```

Required Parameters

- target_table: 待更新数据的目标表。可以是 'db_name.table_name' 形式
- assignment_list: 待更新的目标列，形如 'col_name = value, col_name = value' 格式
- WHERE condition: 期望更新的条件，一个返回 true 或者 false 的表达式即可

Optional Parameters

- table_alias: 表的别名
- FROM additional_tables: 指定一个或多个表，用于选中更新的行，或者获取更新的值。注意，如需要在此列表中再次使用目标表，需要为其显式指定别名。

Note

当前 UPDATE 语句仅支持在 UNIQUE KEY 模型上的行更新。

举例

test 表是一个 unique 模型的表，包含：k1, k2, v1, v2 四个列。其中 k1, k2 是 key，v1, v2 是 value，聚合方式是 Replace。

1. 将 'test' 表中满足条件 k1 =1 , k2 =2 的 v1 列更新为 1

```
UPDATE test SET v1 = 1 WHERE k1=1 and k2=2;
```

2. 将 'test' 表中 k1=1 的列的 v1 列自增 1

```
UPDATE test SET v1 = v1+1 WHERE k1=1;
```

3. 使用t2和t3表连接的结果，更新t1

```
-- 创建 t1, t2, t3 三张表
CREATE TABLE t1
  (id INT, c1 BIGINT, c2 STRING, c3 DOUBLE, c4 DATE)
UNIQUE KEY (id)
DISTRIBUTED BY HASH (id)
PROPERTIES('replication_num'='1', "function_column.sequence_col" = "c4");

CREATE TABLE t2
  (id INT, c1 BIGINT, c2 STRING, c3 DOUBLE, c4 DATE)
DISTRIBUTED BY HASH (id)
PROPERTIES('replication_num'='1');

CREATE TABLE t3
  (id INT)
DISTRIBUTED BY HASH (id)
PROPERTIES('replication_num'='1');

-- 插入数据
INSERT INTO t1 VALUES
  (1, 1, '1', 1.0, '2000-01-01'),
  (2, 2, '2', 2.0, '2000-01-02'),
  (3, 3, '3', 3.0, '2000-01-03');

INSERT INTO t2 VALUES
  (1, 10, '10', 10.0, '2000-01-10'),
  (2, 20, '20', 20.0, '2000-01-20'),
  (3, 30, '30', 30.0, '2000-01-30'),
  (4, 4, '4', 4.0, '2000-01-04'),
  (5, 5, '5', 5.0, '2000-01-05');

INSERT INTO t3 VALUES
  (1),
  (4),
  (5);

-- 更新 t1
UPDATE t1
  SET t1.c1 = t2.c1, t1.c3 = t2.c3 * 100
```

```
FROM t2 INNER JOIN t3 ON t2.id = t3.id
WHERE t1.id = t2.id;
```

预期结果为，更新了t1表id为1的列

id	c1	c2	c3	c4
1	10	1	1000.0	2000-01-01
2	2	2	2.0	2000-01-02
3	3	3	3.0	2000-01-03

Keywords

UPDATE

EXPORT

EXPORT

Name

EXPORT

描述

EXPORT 命令用于将指定表的数据导出为文件到指定位置。目前支持通过 Broker 进程，S3 协议或 HDFS 协议，导出到远端存储，如 HDFS，S3，BOS，COS（腾讯云）上。

EXPORT是一个异步操作，该命令会提交一个EXPORT JOB到 Doris，任务提交成功立即返回。执行后可使用 [SHOW EXPORT](#) 命令查看进度。

语法：

```
EXPORT TABLE table_name
[PARTITION (p1[,p2])]
[WHERE]
TO export_path
[opt_properties]
WITH BROKER/S3/HDFS
[broker_properties];
```

说明：

- table_name

当前要导出的表的表名。支持 Doris 本地表、视图 View、Catalog 外表数据的导出。

- partition

可以只导出指定表的某些指定分区，只对 Doris 本地表有效。

- export_path

导出的文件路径。可以是目录，也可以是文件目录加文件前缀，如hdfs://path/to/my_file_

- opt_properties

用于指定一些导出参数。

```
[PROPERTIES ("key"="value", ...)]
```

可以指定如下参数：

- label: 可选参数，指定此次 Export 任务的 label，当不指定时系统会随机生成一个 label。

- `column_separator`: 指定导出的列分隔符, 默认为 `\t`, 支持多字节。该参数只用于 csv 文件格式。
- `line_delimiter`: 指定导出的行分隔符, 默认为 `\n`, 支持多字节。该参数只用于 csv 文件格式。
- `columns`: 指定导出表的某些列。
- `format`: 指定导出作业的文件格式, 支持: `parquet`, `orc`, `csv`, `csv_with_names`、`csv_with_names_and_types`。默认为 csv 格式。
- `max_file_size`: 导出作业单个文件大小限制, 如果结果超过这个值, 将切割成多个文件。
`max_file_size`取值范围是[5MB, 2GB], 默认为 1GB。(当指定导出为 orc 文件格式时, 实际切分文件的大小将是 64MB 的倍数, 如: 指定 `max_file_size` = 5MB, 实际将以 64MB 为切分; 指定 `max_file_size` = 65MB, 实际将以 128MB 为切分)
- `parallelism`: 导出作业的并发度, 默认为1, 导出作业会开启`parallelism`个数的线程去执行 `select into outfile`语句。(如果 `parallelism` 个数大于表的 `tablets` 个数, 系统将自动把 `parallelism` 设置为 `tablets` 个数大小, 即每一个`select into outfile`语句负责一个 `tablets`)
- `delete_existing_files`: 默认为 `false`, 若指定为 `true`, 则会先删除`export_path`所指定目录下的所有文件, 然后导出数据到该目录下。例如: “`export_path`” = “`/user/tmp`”, 则会删除“`/user/`”下所有文件及目录; “`file_path`” = “`/user/tmp/`”, 则会删除“`/user/tmp/`”下所有文件及目录。
- `with_bom`: 默认为 `false`, 若指定为 `true`, 则导出的文件编码为带有 BOM 的 UTF8 编码 (只对 csv 相关的文件格式生效)。
- `timeout`: 导出作业的超时时间, 默认为 2 小时, 单位是秒。

注意: 要使用 `delete_existing_files` 参数, 还需要在 `fe.conf` 中添加配置
`enable_delete_existing_files` = `true`并重启 `fe`, 此时 `delete_existing_files` 才会生效。
`delete_existing_files` = `true` 是一个危险的操作, 建议只在测试环境中使用。

• WITH BROKER

可以通过 Broker 进程写数据到远端存储上。这里需要定义相关的连接信息供 Broker 使用。

语法:
`WITH BROKER "broker_name"`
`("key"="value"[,...])`

Broker 相关属性:

`username`: 用户名
`password`: 密码
`hadoop.security.authentication`: 指定认证方式为 `kerberos`
`kerberos_principal`: 指定 `kerberos` 的 `principal`
`kerberos_keytab`: 指定 `kerberos` 的 `keytab` 文件路径。该文件必须为 Broker 进程所在服务器上的文件的绝对路径。并且可以被 Broker 进程访问

• WITH HDFS

可以直接将数据写到远端 HDFS 上。

语法:

```
WITH HDFS ("key"="value"[,...])
```

HDFS 相关属性:

fs.defaultFS: namenode 地址和端口

hadoop.username: hdfs 用户名

dfs.nameservices: name service 名称, 与 hdfs-site.xml 保持一致

dfs.ha.namenodes.[nameservice ID]: namenode 的 id 列表, 与 hdfs-site.xml 保持一致

dfs.namenode.rpc-address.[nameservice ID].[name node ID]: Name node 的 rpc 地址, 数量与 namenode 数量相同, 与 hdfs-site.xml 保

对于开启kerberos认证的Hadoop 集群, 还需要额外设置如下 PROPERTIES 属性:

dfs.namenode.kerberos.principal: HDFS namenode 服务的 principal 名称

hadoop.security.authentication: 认证方式设置为 kerberos

hadoop.kerberos.principal: 设置 Doris 连接 HDFS 时使用的 Kerberos 主体

hadoop.kerberos.keytab: 设置 keytab 本地文件路径

- WITH S3

可以直接将数据写到远端 S3 对象存储上。

语法:

```
WITH S3 ("key"="value"[,...])
```

S3 相关属性:

AWS_ENDPOINT

AWS_ACCESS_KEY

AWS_SECRET_KEY

AWS_REGION

use_path_style: (选填) 默认为 false。S3 SDK 默认使用 virtual-hosted style 方式。但某些对象存储系统可能没开启或不支持 virtual-hosted style 方式的访问, 此时可以添加 use_path_style 参数来强制使用 path style 访问方式。

举例

export 数据到本地

export 数据到本地文件系统, 需要在 fe.conf 中添加enable_outfile_to_local=true并且重启 FE。

1. 将 test 表中的所有数据导出到本地存储, 默认导出 csv 格式文件

```
EXPORT TABLE test TO "file:///home/user/tmp/";
```

2. 将 test 表中的 k1,k2 列导出到本地存储, 默认导出 csv 文件格式, 并设置 label

```
EXPORT TABLE test TO "file:///home/user/tmp/"
PROPERTIES (
  "label" = "label1",
  "columns" = "k1,k2"
);
```

3. 将 test 表中的 k1 < 50 的行导出到本地存储, 默认导出 csv 格式文件, 并以,作为列分割符


```
EXPORT TABLE test WHERE k1 < 50 TO "file:///home/user/tmp/"
PROPERTIES (
  "columns" = "k1,k2",
  "column_separator"=", "
);
```

4. 将 test 表中的分区 p1,p2 导出到本地存储，默认导出 csv 格式文件

```
EXPORT TABLE test PARTITION (p1,p2) TO "file:///home/user/tmp/"
PROPERTIES ("columns" = "k1,k2");
```

5. 将 test 表中的所有数据导出到本地存储，导出其他格式的文件

```
// parquet格式
EXPORT TABLE test TO "file:///home/user/tmp/"
PROPERTIES (
  "columns" = "k1,k2",
  "format" = "parquet"
);

// orc格式
EXPORT TABLE test TO "file:///home/user/tmp/"
PROPERTIES (
  "columns" = "k1,k2",
  "format" = "orc"
);

// csv_with_names格式，以'AA'为列分割符，'zz'为行分割符
EXPORT TABLE test TO "file:///home/user/tmp/"
PROPERTIES (
  "format" = "csv_with_names",
  "column_separator"="AA",
  "line_delimiter" = "zz"
);

// csv_with_names_and_types格式
EXPORT TABLE test TO "file:///home/user/tmp/"
PROPERTIES (
  "format" = "csv_with_names_and_types"
);
```

6. 设置 max_file_sizes 属性

```
EXPORT TABLE test TO "file:///home/user/tmp/"
PROPERTIES (
  "format" = "parquet",
  "max_file_size" = "5MB"
);
```

当导出文件大于 5MB 时，将切割数据为多个文件，每个文件最大为 5MB。

7. 设置 parallelism 属性

```
EXPORT TABLE test TO "file:///home/user/tmp/"
PROPERTIES (
  "format" = "parquet",
  "max_file_size" = "5MB",
```

```
"parallelism" = "5"
);
```

8. 设置 delete_existing_files 属性

```
EXPORT TABLE test TO "file:///home/user/tmp"
PROPERTIES (
  "format" = "parquet",
  "max_file_size" = "5MB",
  "delete_existing_files" = "true"
);
```

Export 导出数据时会先将 /home/user/ 目录下所有文件及目录删除，然后导出数据到该目录下。

export with S3

1. 将 s3_test 表中的所有数据导出到 s3 上，以不可见字符 \x07 作为列或者行分隔符。如果需要将数据导出到 minio，还需要指定 use_path_style=true。

```
EXPORT TABLE s3_test TO "s3://bucket/a/b/c"
PROPERTIES (
  "column_separator"="\x07",
  "line_delimiter" = "\x07"
) WITH s3 (
  "s3.endpoint" = "xxxxx",
  "s3.region" = "xxxxx",
  "s3.secret_key"="xxxxx",
  "s3.access_key" = "xxxxx"
)
```

export with HDFS

1. 将 test 表中的所有数据导出到 HDFS 上，导出文件格式为 parquet，导出作业单个文件大小限制为 512MB，保留所指定目录下的所有文件。

```
EXPORT TABLE test TO "hdfs://hdfs_host:port/a/b/c/"
PROPERTIES(
  "format" = "parquet",
  "max_file_size" = "512MB",
  "delete_existing_files" = "false"
)
with HDFS (
  "fs.defaultFS"="hdfs://hdfs_host:port",
  "hadoop.username" = "hadoop"
);
```

export with Broker

需要先启动 broker 进程，并在 FE 中添加该 broker。1. 将 test 表中的所有数据导出到 hdfs 上

```
EXPORT TABLE test TO "hdfs://hdfs_host:port/a/b/c"
WITH BROKER "broker_name"
(
```

```
"username"="xxx",
"password"="yyy"
);
```

2. 将 testTbl 表中的分区 p1,p2 导出到 hdfs 上，以“,”作为列分隔符，并指定 label

```
EXPORT TABLE testTbl PARTITION (p1,p2) TO "hdfs://hdfs_host:port/a/b/c"
PROPERTIES (
  "label" = "mylabel",
  "column_separator"=",",
)
WITH BROKER "broker_name"
(
  "username"="xxx",
  "password"="yyy"
);
```

3. 将 testTbl 表中的所有数据导出到 hdfs 上，以不可见字符 \x07 作为列或者行分隔符。

```
EXPORT TABLE testTbl TO "hdfs://hdfs_host:port/a/b/c"
PROPERTIES (
  "column_separator"="\x07",
  "line_delimiter" = "\x07"
)
WITH BROKER "broker_name"
(
  "username"="xxx",
  "password"="yyy"
)
```

Keywords

```
EXPORT
```

Best Practice

并发执行

一个 Export 作业可以设置parallelism参数来并发导出数据。parallelism参数实际就是指定执行 EXPORT 作业的线程数量。每一个线程会负责导出表的部分 Tablets。

一个 Export 作业的底层执行逻辑实际上是SELECT INTO OUTFILE语句，parallelism参数设置的每一个线程都会去执行独立的SELECT INTO OUTFILE语句。

Export 作业拆分成多个SELECT INTO OUTFILE的具体逻辑是：将该表的所有 tablets 平均的分给所有 parallel 线程，如： - num(tablets) = 40, parallelism = 3，则这 3 个线程各自负责的 tablets 数量分别为 14, 13, 13 个。 - num(tablets) = 2, parallelism = 3，则 Doris 会自动将 parallelism 设置为 2，每一个线程负责一个 tablets。

当一个线程负责的 tablest 超过 maximum_tablets_of_outfile_in_export 数值（默认为 10，可在 fe.conf 中添加maximum_tablets_of_outfile_in_export参数来修改该值）时，该线程就会拆分为多个SELECT INTO OUTFILE语句，如： - 一个线程负责的 tablets 数量分别为 14, maximum_tablets_of_outfile_in_export =

10, 则该线程负责两个SELECT INTO OUTFILE语句, 第一个SELECT INTO OUTFILE语句导出 10 个 tablets, 第二个SELECT INTO OUTFILE语句导出 4 个 tablets, 两个SELECT INTO OUTFILE语句由该线程串行执行。

当所要导出的数据量很大时, 可以考虑适当调大parallelism参数来增加并发导出。若机器核数紧张, 无法再增加parallelism 而导出表的 Tablets 又较多时, 可以考虑调大maximum_tablets_of_outfile_in_export来增加一个SELECT INTO OUTFILE语句负责的 tablets 数量, 也可以加快导出速度。

内存限制

通常一个 Export 作业的查询计划只有 扫描-导出 两部分, 不涉及需要太多内存的计算逻辑。所以通常 2GB 的默认内存限制可以满足需求。

但在某些场景下, 比如一个查询计划, 在同一个 BE 上需要扫描的 Tablet 过多, 或者 Tablet 的数据版本过多时, 可能会导致内存不足。可以调整 session 变量exec_mem_limit来调大内存使用限制。

注意事项

- 不建议一次性导出大量数据。一个 Export 作业建议的导出数据量最大在几十 GB。过大的导出会导致更多的垃圾文件和更高的重试成本。如果表数据量过大, 建议按照分区导出。
- 如果 Export 作业运行失败, 已经生成的文件不会被删除, 需要用户手动删除。
- Export 作业会扫描数据, 占用 IO 资源, 可能会影响系统的查询延迟。
- 目前在 export 时只是简单检查 tablets 版本是否一致, 建议在执行 export 过程中不要对该表进行导入数据操作。
- 一个 Export Job 允许导出的分区数量最大为 2000, 可以在 fe.conf 中添加参数 maximum_number_of_export_partitions并重启 FE 来修改该设置。

CANCEL-EXPORT

CANCEL-EXPORT

Name

CANCEL EXPORT

描述

该语句用于撤销指定 label 的 EXPORT 作业，或者通过模糊匹配批量撤销 EXPORT 作业

```
CANCEL EXPORT
[FROM db_name]
WHERE [LABEL = "export_label" | LABEL like "label_pattern" | STATE = "PENDING/IN_QUEUE/EXPORTING"]
```

举例

1. 撤销数据库 example_db 上，label 为 example_db_test_export_label 的 EXPORT 作业

```
CANCEL EXPORT
FROM example_db
WHERE LABEL = "example_db_test_export_label" and STATE = "EXPORTING";
```

2. 撤销数据库 example_db 上，所有包含 example 的 EXPORT 作业。

```
CANCEL EXPORT
FROM example_db
WHERE LABEL like "%example%";
```

3. 取消状态为 PENDING 的导出作业。

```
CANCEL EXPORT
FROM example_db
WHERE STATE = "PENDING";
```

Keywords

CANCEL, EXPORT

Best Practice

1. 只能取消处于 PENDING、IN_QUEUE、EXPORTING 状态的未完成的导出作业。
2. 当执行批量撤销时，Doris 不会保证所有对应的 EXPORT 作业原子的撤销。即有可能仅有部分 EXPORT 作业撤销成功。用户可以通过 SHOW EXPORT 语句查看作业状态，并尝试重复执行 CANCEL EXPORT

语句。

3. 当撤销EXPORTING状态的作业时，有可能作业已经导出部分数据到存储系统上，用户需要自行处理 (删除) 该部分导出数据。

INSERT-OVERWRITE

INSERT OVERWRITE

Name

INSERT OVERWRITE

描述

该语句的功能是重写表或表的某些分区

```
INSERT OVERWRITE table table_name
  [ PARTITION (p1, ...) ]
  [ WITH LABEL label]
  [ (column [, ...]) ]
  [ [ hint [, ...] ] ]
  { VALUES ( { expression | DEFAULT } [, ...] ) [, ...] | query }
```

Parameters

table_name: 需要重写的目的表。这个表必须存在。可以是 `db_name.table_name` 形式

partitions: 需要重写的表分区，必须是 `table_name` 中存在的分区，多个分区名称用逗号分隔

label: 为 Insert 任务指定一个 label

column_name: 指定的目的列，必须是 `table_name` 中存在的列

expression: 需要赋值给某个列的对应表达式

DEFAULT: 让对应列使用默认值

query: 一个普通查询，查询的结果会重写到目标中

hint: 用于指示 INSERT 执行行为的一些指示符。目前 hint 有三个可选值 `/*+ STREAMING */`、`/*+ SHUFFLE */`或`/*+ NOSHUFFLE */`

1. **STREAMING:** 目前无实际作用，只是为了兼容之前的版本，因此保留。（之前的版本加上这个 hint 会返回 label，现在默认都会返回 label）
2. **SHUFFLE:** 当目标表是分区表，开启这个 hint 会进行 repartition。
3. **NOSHUFFLE:** 即使目标表是分区表，也不会进行 repartition，但会做一些其他操作以保证数据正确落到各个分区中。

注意：

在当前版本中，会话变量 `enable_insert_strict` 默认为 `true`，如果执行 `INSERT OVERWRITE` 语句时，对于有不符合目标表格式的数据被过滤掉的话会重写目标表失败（比如重写分区时，不满足所有分区条件的数据会被过滤）。

`INSERT OVERWRITE` 语句会首先创建一个新表，将需要重写的的数据插入到新表中，最后原子性的用新表替换旧表并修改名称。因此，在重写表的过程中，旧表中的数据在重写完毕之前仍然可以正常访问。

举例

假设有 `test` 表。该表包含两个列 `c1`, `c2`，两个分区 `p1`, `p2`。建表语句如下所示

```
CREATE TABLE IF NOT EXISTS test (
  `c1` int NOT NULL DEFAULT "1",
  `c2` int NOT NULL DEFAULT "4"
) ENGINE=OLAP
UNIQUE KEY(`c1`)
PARTITION BY LIST (`c1`)
(
  PARTITION p1 VALUES IN ("1","2","3"),
  PARTITION p2 VALUES IN ("4","5","6")
)
DISTRIBUTED BY HASH(`c1`) BUCKETS 3
PROPERTIES (
  "replication_allocation" = "tag.location.default: 1",
  "in_memory" = "false",
  "storage_format" = "V2"
);
```

Overwrite Table

1. VALUES的形式重写test表

```
# 单行重写
INSERT OVERWRITE table test VALUES (1, 2);
INSERT OVERWRITE table test (c1, c2) VALUES (1, 2);
INSERT OVERWRITE table test (c1, c2) VALUES (1, DEFAULT);
INSERT OVERWRITE table test (c1) VALUES (1);
# 多行重写
INSERT OVERWRITE table test VALUES (1, 2), (3, 2 + 2);
INSERT OVERWRITE table test (c1, c2) VALUES (1, 2), (3, 2 * 2);
INSERT OVERWRITE table test (c1, c2) VALUES (1, DEFAULT), (3, DEFAULT);
INSERT OVERWRITE table test (c1) VALUES (1), (3);
```

- 第一条语句和第二条语句的效果一致，重写时如果不指定目标列，会使用表中的列顺序来作为默认的目标列。重写成功后表 `test` 中只有一行数据。
- 第三条语句和第四条语句的效果一致，没有指定的列 `c2` 会使用默认值 `4` 来完成数据重写。重写成功后表 `test` 中只有一行数据。
- 第五条语句和第六条语句的效果一致，在语句中可以使用表达式（如 `2+2`, `2*2`），执行语句的时候会计算出表达式的结果再重写表 `test`。重写成功后表 `test` 中有两行数据。
- 第七条语句和第八条语句的效果一致，没有指定的列 `c2` 会使用默认值 `4` 来完成数据重写。重写成功后表 `test` 中有两行数据。

2. 查询语句的形式重写test表，表test2和表test的数据格式需要保持一致，如果不一致会触发数据类型的隐式转换

```
INSERT OVERWRITE table test SELECT * FROM test2;
INSERT OVERWRITE table test (c1, c2) SELECT * from test2;
```

- 第一条语句和第二条语句的效果一致，该语句的作用是将数据从表test2中取出，使用取出的数据重写表test。重写成功后表test中的数据和表test2中的数据保持一致。

3. 重写 test 表并指定label

```
INSERT OVERWRITE table test WITH LABEL `label1` SELECT * FROM test2;
INSERT OVERWRITE table test WITH LABEL `label2` (c1, c2) SELECT * from test2;
```

- 用户可以通过SHOW LOAD;命令查看此label导入作业的状态。需要注意的是label具有唯一性。

Overwrite Table Partition

使用 INSERT OVERWRITE 重写分区时，实际我们是将如下三步操作封装为一个事务并执行，如果中途失败，已进行的操作将会回滚： 1. 假设指定重写分区 p1，首先创建一个与重写的目标分区结构相同的空临时分区 pTMP 2. 向 pTMP 中写入数据 3. 使用 pTMP 原子替换 p1 分区

举例如下：

1. VALUES的形式重写test表分区P1和p2

```
# 单行重写
INSERT OVERWRITE table test PARTITION(p1,p2) VALUES (1, 2);
INSERT OVERWRITE table test PARTITION(p1,p2) (c1, c2) VALUES (1, 2);
INSERT OVERWRITE table test PARTITION(p1,p2) (c1, c2) VALUES (1, DEFAULT);
INSERT OVERWRITE table test PARTITION(p1,p2) (c1) VALUES (1);
# 多行重写
INSERT OVERWRITE table test PARTITION(p1,p2) VALUES (1, 2), (4, 2 + 2);
INSERT OVERWRITE table test PARTITION(p1,p2) (c1, c2) VALUES (1, 2), (4, 2 * 2);
INSERT OVERWRITE table test PARTITION(p1,p2) (c1, c2) VALUES (1, DEFAULT), (4, DEFAULT);
INSERT OVERWRITE table test PARTITION(p1,p2) (c1) VALUES (1), (4);
```

以上语句与重写表不同的是，它们都是重写表中的分区。分区可以一次重写一个分区也可以一次重写多个分区。需要注意的是，只有满足对应分区过滤条件的数据才能够重写成功。如果重写的数据中有数据不满足其中任意一个分区，那么本次重写会失败。一个失败的例子如下所示

```
INSERT OVERWRITE table test PARTITION(p1,p2) VALUES (7, 2);
```

以上语句重写的数据c1=7分区p1和p2的条件都不满足，因此会重写失败。

2. 查询语句的形式重写test表分区P1和p2，表test2和表test的数据格式需要保持一致，如果不一致会触发数据类型的隐式转换

```
INSERT OVERWRITE table test PARTITION(p1,p2) SELECT * FROM test2;
INSERT OVERWRITE table test PARTITION(p1,p2) (c1, c2) SELECT * from test2;
```

3. 重写 test 表分区P1和p2并指定label

```
INSERT OVERWRITE table test PARTITION(p1,p2) WITH LABEL `label3` SELECT * FROM test2;  
INSERT OVERWRITE table test PARTITION(p1,p2) WITH LABEL `label4` (c1, c2) SELECT * from test2;
```

Keywords

INSERT OVERWRITE

ANALYZE

ANALYZE

Name

ANALYZE

描述

该语句用于收集各列的统计信息。

```
ANALYZE < TABLE | DATABASE table_name | db_name >  
  [ (column_name [, ...]) ]  
  [ [ WITH SYNC ] [ WITH SAMPLE PERCENT | ROWS ] ];
```

- **table_name**: 指定的目标表。可以是 `db_name.table_name` 形式。
- **column_name**: 指定的目标列。必须是 `table_name` 中存在的列，多个列名称用逗号分隔。
- **sync**: 同步收集统计信息。收集完后返回。若不指定则异步执行并返回 JOB ID。
- **sample percent | rows**: 抽样收集统计信息。可以指定抽样比例或者抽样行数。

举例

对一张表按照 10% 的比例采样收集统计数据：

```
ANALYZE TABLE lineitem WITH SAMPLE PERCENT 10;
```

对一张表按采样 10 万行收集统计数据

```
ANALYZE TABLE lineitem WITH SAMPLE ROWS 100000;
```

Keywords

ANALYZE

OUTFILE

OUTFILE

Name

OUTFILE

描述

SELECT INTO OUTFILE 命令用于将查询结果导出为文件。目前支持通过 Broker 进程, S3 协议或HDFS 协议, 导出到远端存储, 如 HDFS, S3, BOS, COS (腾讯云) 上。

语法:

```
query_stmt  
INTO OUTFILE "file_path"  
[format_as]  
[properties]
```

说明:

1. file_path

文件存储的路径及文件前缀。

file_path 指向文件存储的路径以及文件前缀。如 `hdfs://path/to/my\_file\_`。

最终的文件名将由 `my\_file\_`、文件序号以及文件格式后缀组成。其中文件序号由0开始, 数量为文件被分割的数量。如:

```
my_file_abcdefg_0.csv  
my_file_abcdefg_1.csv  
my_file_abcdefg_2.csv
```

也可以省略文件前缀, 只指定文件目录, 如hdfs://path/to/

2. format_as

```
FORMAT AS CSV
```

指定导出格式. 支持 CSV、PARQUET、CSV_WITH_NAMES、CSV_WITH_NAMES_AND_TYPES、ORC. 默认为 CSV。

注: PARQUET、CSV_WITH_NAMES、CSV_WITH_NAMES_AND_TYPES、ORC 在 1.2 版本开始支持。

3. properties

指定相关属性。目前支持通过 Broker 进程，或通过 S3/HDFS协议进行导出。

语法：

```
[PROPERTIES ("key"="value", ...)]
```

支持如下属性：

文件相关的属性：

column_separator: 列分隔符，只用于csv相关格式。在 1.2 版本开始支持多字节分隔符，如："\x01", "abc"。

line_delimiter: 行分隔符，只用于csv相关格式。在 1.2 版本开始支持多字节分隔符，如："\x01", "abc"。

max_file_size: 单个文件大小限制，如果结果超过这个值，将切割成多个文件，max_file_size取值范围是[5MB, 2GB]，默认为1GB。（当指定导出为orc文件格式时，实际切分文件的大小将是64MB的倍数，如：指定max_file_size = 5MB，实际将以64MB为切分；指定max_file_size = 65MB，实际将以128MB为切分）

delete_existing_files: 默认为false，若指定为true，则会先删除file_path指定的目录下的所有文件，然后导出数据到该目录下。例如："file_path" = "/user/tmp"，则会删除"/user/"下所有文件及目录；"file_path" = "/user/tmp/"，则会删除"/user/tmp/"下所有文件及目录。

file_suffix: 指定导出文件的后缀，若不指定该参数，将使用文件格式的默认后缀。

Broker 相关属性需加前缀 `broker.`：

broker.name: broker名称

broker.hadoop.security.authentication: 指定认证方式为 kerberos

broker.kerberos_principal: 指定 kerberos 的 principal

broker.kerberos_keytab: 指定 kerberos 的 keytab 文件路径。该文件必须为 Broker 进程所在服务器上的文件的绝对路径。并且可以被 Broker 进程访问

HDFS 相关属性：

fs.defaultFS: namenode 地址和端口

hadoop.username: hdfs 用户名

dfs.nameservices: name service名称，与hdfs-site.xml保持一致

dfs.ha.namenodes.[nameservice ID]: namenode的id列表,与hdfs-site.xml保持一致

dfs.namenode.rpc-address.[nameservice ID].[name node ID]: Name node的rpc地址，数量与namenode数量相同，与hdfs-site.xml保持一致

dfs.client.failover.proxy.provider.[nameservice ID]: HDFS客户端连接活跃namenode的java类，通常是"org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider"

对于开启kerberos认证的Hadoop 集群，还需要额外设置如下 PROPERTIES 属性：

dfs.namenode.kerberos.principal: HDFS namenode 服务的 principal 名称

hadoop.security.authentication: 认证方式设置为 kerberos

hadoop.kerberos.principal: 设置 Doris 连接 HDFS 时使用的 Kerberos 主体

hadoop.kerberos.keytab: 设置 keytab 本地文件路径

S3 协议则直接执行 S3 协议配置即可：

s3.endpoint

s3.access_key

s3.secret_key

s3.region

use_path_style: (选填) 默认为false。S3 SDK 默认使用 virtual-hosted style 方式。但某些对象存储系统可能没开启或不支持virtual-hosted style 方式的访问，此时可以添加 use_path_style 参数来强制使用 path style 访问方式。

注意：若要使用delete_existing_files参数，还需要在fe.conf中添加配置

enable_delete_existing_files = true并重启fe，此时delete_existing_files才会生效。

delete_existing_files = true 是一个危险的操作，建议只在测试环境中使用。

4. 导出的数据类型

所有文件类型都支持导出基本数据类型，而对于复杂数据类型（ARRAY/MAP/STRUCT），当前只有 csv/orc/csv_with_names/csv_with_names_and_types支持导出复杂类型,且不支持嵌套复杂类型。

5. 并发导出

设置session变量`set enable_parallel_outfile = true;`可开启outfile并发导出，详细使用方法见[导出查询结果集](#)

6. 导出到本地

导出到本地文件时需要先在`fe.conf`中配置`enable_outfile_to_local=true`

```
select * from tbl1 limit 10
INTO OUTFILE "file:///home/work/path/result_";
```

数据类型映射

parquet、orc文件格式拥有自己的数据类型，Doris的导出功能能够自动将Doris的数据类型导出到parquet/orc文件格式的对应数据类型，以下是Doris数据类型和parquet/orc文件格式的数据类型映射关系表：

1. Doris导出到Orc文件格式的数据类型映射表：

Doris Type	Orc Type
boolean	boolean
tinyint	tinyint
smallint	smallint
int	int
bigint	bigint
largeint	string
date	string
datev2	string
datetime	string
datetimev2	timestamp
float	float
double	double
char / varchar	string
decimal	decimal
struct	struct
map	map
array	array
2. Doris导出到Parquet文件格式时，会先将Doris内存数据转换为arrow内存数据格式，然后由arrow写出到parquet文件格式。Doris数据类型到arrow数据类的映射关系为：

Doris Type	Arrow Type
boolean	boolean
tinyint	int8
smallint	int16
int	int32
bigint	int64
largeint	utf8
date	utf8
datev2	utf8
datetime	utf8
datetimev2	utf8
float	float32
double	float64
char / varchar	string
decimal	decimal128
struct	struct
map	map
array	list

举例

1. 使用 broker 方式导出，将简单查询结果导出到文件 `hdfs://path/to/result.txt`。指定导出格式为 CSV。使用 `my_broker` 并设置 `kerberos` 认证信息。指定列分隔符为 `,`，行分隔符为 `\n`。

```
SELECT * FROM tbl
INTO OUTFILE "hdfs://path/to/result_"
FORMAT AS CSV
PROPERTIES
(
  "broker.name" = "my_broker",
  "broker.hadoop.security.authentication" = "kerberos",
  "broker.kerberos_principal" = "doris@YOUR.COM",
  "broker.kerberos_keytab" = "/home/doris/my.keytab",
  "column_separator" = ",",
  "line_delimiter" = "\n",
  "max_file_size" = "100MB"
);
```

最终生成文件如如果不大于 100MB，则为：`result_0.csv`。如果大于 100MB，则可能为 `result_0.csv`, `result_1.csv`, ...。

2. 将简单查询结果导出到文件 `hdfs://path/to/result.parquet`。指定导出格式为 `PARQUET`。使用 `my_broker` 并设置 `kerberos` 认证信息。

```

SELECT c1, c2, c3 FROM tbl
INTO OUTFILE "hdfs://path/to/result_"
FORMAT AS PARQUET
PROPERTIES
(
    "broker.name" = "my_broker",
    "broker.hadoop.security.authentication" = "kerberos",
    "broker.kerberos_principal" = "doris@YOUR.COM",
    "broker.kerberos_keytab" = "/home/doris/my.keytab"
);

```

3. 将 CTE 语句的查询结果导出到文件 `hdfs://path/to/result.txt`。默认导出格式为 CSV。使用 `my_broker` 并设置 `hdfs` 高可用信息。使用默认的行列分隔符。

```

WITH
x1 AS
(SELECT k1, k2 FROM tbl1),
x2 AS
(SELECT k3 FROM tbl2)
SELEC k1 FROM x1 UNION SELECT k3 FROM x2
INTO OUTFILE "hdfs://path/to/result_"
PROPERTIES
(
    "broker.name" = "my_broker",
    "broker.username"="user",
    "broker.password"="passwd",
    "broker.dfs.nameservices" = "my_ha",
    "broker.dfs.ha.namenodes.my_ha" = "my_namenode1, my_namenode2",
    "broker.dfs.namenode.rpc-address.my_ha.my_namenode1" = "nn1_host:rpc_port",
    "broker.dfs.namenode.rpc-address.my_ha.my_namenode2" = "nn2_host:rpc_port",
    "broker.dfs.client.failover.proxy.provider.my_ha" =
    "org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider"
);

```

最终生成文件如如果不大于 1GB，则为：`result_0.csv`。如果大于 1GB，则可能为 `result_0.csv`，`result_1.csv`，...

4. 将 UNION 语句的查询结果导出到文件 `bos://bucket/result.txt`。指定导出格式为 PARQUET。使用 `my_broker` 并设置 `hdfs` 高可用信息。PARQUET 格式无需指定列分割符。导出完成后，生成一个标识文件。

```

SELECT k1 FROM tbl1 UNION SELECT k2 FROM tbl1
INTO OUTFILE "bos://bucket/result_"
FORMAT AS PARQUET
PROPERTIES
(
    "broker.name" = "my_broker",
    "broker.bos_endpoint" = "http://bj.bcebos.com",
    "broker.bos_accesskey" = "xxxxxxxxxxxxxxxxxxxxxxxx",
    "broker.bos_secret_accesskey" = "yyyyyyyyyyyyyyyyyyyy"
);

```

5. 将 select 语句的查询结果导出到文件 `s3a://${bucket_name}/path/result.txt`。指定导出格式为 csv。导出完成后，生成一个标识文件。

```

select k1,k2,v1 from tbl1 limit 100000
into outfile "s3a://my_bucket/export/my_file_"

```

```

FORMAT AS CSV
PROPERTIES
(
    "broker.name" = "hdfs_broker",
    "broker.fs.s3a.access.key" = "xxx",
    "broker.fs.s3a.secret.key" = "xxxx",
    "broker.fs.s3a.endpoint" = "https://cos.xxxxxx.myqcloud.com/",
    "column_separator" = ",",
    "line_delimiter" = "\n",
    "max_file_size" = "1024MB",
    "success_file_name" = "SUCCESS"
)

```

最终生成文件如如果不大于 1GB，则为：my_file_0.csv。如果大于 1GB，则可能为 my_file_0.csv, result_1.csv, ...。在cos上验证

1. 不存在的path会自动创建
2. access.key/secret.key/endpoint需要和cos的同学确认。尤其是endpoint的值，不需要填写bucket_name。

6. 使用 s3 协议导出到 bos，并且并发导出开启。

```

set enable_parallel_outfile = true;
select k1 from tb1 limit 1000
into outfile "s3://my_bucket/export/my_file_"
format as csv
properties
(
    "s3.endpoint" = "http://s3.bd.bcebos.com",
    "s3.access_key" = "xxxx",
    "s3.secret_key" = "xxx",
    "s3.region" = "bd"
)

```

最终生成的文件前缀为 my_file_{fragment_instance_id}_。

7. 使用 s3 协议导出到 bos，并且并发导出 session 变量开启。注意：但由于查询语句带了一个顶层的排序节点，所以这个查询即使开启并发导出的 session 变量，也是无法并发导出的。

```

set enable_parallel_outfile = true;
select k1 from tb1 order by k1 limit 1000
into outfile "s3://my_bucket/export/my_file_"
format as csv
properties
(
    "s3.endpoint" = "http://s3.bd.bcebos.com",
    "s3.access_key" = "xxxx",
    "s3.secret_key" = "xxx",
    "s3.region" = "bd"
)

```

8. 使用 hdfs 方式导出，将简单查询结果导出到文件

hdfs://\${host}:\${fileSystem_port}/path/to/result.txt。指定导出格式为 CSV，用户名为 work。指定列分隔符为 ,，行分隔符为 \n。

```

-- fileSystem_port默认值为9000
SELECT * FROM tb1

```



```

INTO OUTFILE "hdfs://${host}:${fileSystem_port}/path/to/result_"
FORMAT AS CSV
PROPERTIES
(
    "fs.defaultFS" = "hdfs://ip:port",
    "hadoop.username" = "work"
);

```

如果Hadoop 集群开启高可用并且启用 Kerberos 认证，可以参考如下SQL语句：

```

SELECT * FROM tbl
INTO OUTFILE "hdfs://path/to/result_"
FORMAT AS CSV
PROPERTIES
(
    'fs.defaultFS'='hdfs://hacluster/',
    'dfs.nameservices'='hacluster',
    'dfs.ha.namenodes.hacluster'='n1,n2',
    'dfs.namenode.rpc-address.hacluster.n1'='192.168.0.1:8020',
    'dfs.namenode.rpc-address.hacluster.n2'='192.168.0.2:8020',
    'dfs.client.failover.proxy.provider.hacluster'='org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider',
    'dfs.namenode.kerberos.principal'='hadoop/_HOST@REALM.COM'
    'hadoop.security.authentication'='kerberos',
    'hadoop.kerberos.principal'='doris_test@REALM.COM',
    'hadoop.kerberos.keytab'='/path/to/doris_test.keytab'
);

```

最终生成文件如如果不大于 100MB，则为：result_0.csv。如果大于 100MB，则可能为 result_0.csv, result_1.csv, ...。

9. 将 select 语句的查询结果导出到腾讯云cos的文件 cosn://\${bucket_name}/path/result.txt。指定导出格式为 csv。导出完成后，生成一个标识文件。

```

select k1,k2,v1 from tbl1 limit 100000
into outfile "cosn://my_bucket/export/my_file_"
FORMAT AS CSV
PROPERTIES
(
    "broker.name" = "broker_name",
    "broker.fs.cosn.userinfo.secretId" = "xxx",
    "broker.fs.cosn.userinfo.secretKey" = "xxxx",
    "broker.fs.cosn.bucket.endpoint_suffix" = "cos.xxxxxx.myqcloud.com",
    "column_separator" = ",",
    "line_delimiter" = "\n",
    "max_file_size" = "1024MB",
    "success_file_name" = "SUCCESS"
)

```

keywords

```
SELECT, INTO, OUTFILE
```

Best Practice

1. 导出数据量和导出效率

该功能本质上是执行一个 SQL 查询命令。最终的结果是单线程输出的。所以整个导出的耗时包括查询本身的耗时，和最终结果集写出的耗时。如果查询较大，需要设置会话变量 `query_timeout` 适当的延长查询超时时间。

2. 导出文件的管理

Doris 不会管理导出的文件。包括导出成功的，或者导出失败后残留的文件，都需要用户自行处理。

3. 导出到本地文件

导出到本地文件的功能不适用于公有云用户，仅适用于私有化部署的用户。并且默认用户对集群节点有完全的控制权限。Doris 对于用户填写的导出路径不会做合法性检查。如果 Doris 的进程用户对该路径无写权限，或路径不存在，则会报错。同时处于安全性考虑，如果该路径已存在同名的文件，则也会导出失败。

Doris 不会管理导出到本地的文件，也不会检查磁盘空间等。这些文件需要用户自行管理，如清理等。

4. 结果完整性保证

该命令是一个同步命令，因此有可能在执行过程中任务连接断开了，从而无法获悉导出的数据是否正常结束，或是否完整。此时可以使用 `success_file_name` 参数要求任务成功后，在目录下生成一个成功文件标识。用户可以通过这个文件，来判断导出是否正常结束。

5. 其他注意事项

见[导出查询结果集](#)

SHOW ALTER TABLE MATERIALIZED VIEW

描述

该命令用于查看通过 [CREATE-MATERIALIZED-VIEW](#) 语句提交的创建物化视图作业的执行情况。

该语句等同于 SHOW ALTER TABLE ROLLUP;

语法

```
SHOW ALTER TABLE MATERIALIZED VIEW
[FROM <database>]
[<where_clause>]
[ORDER BY <order_by_key> [, ...]]
[LIMIT <limit_rows> [ OFFSET <offset_rows>]]
```

可选参数

1. FROM <database>

查看指定数据库下的作业。如不指定，使用当前数据库。

2. <where_clause>

可以对结果列进行筛选，目前仅支持对以下列进行筛选： - TableName：仅支持等值筛选。 - State：仅支持等值筛选。 - Createtime/FinishTime：支持 =, >=, <=, >, <, !=

3. ORDER BY

可以对结果集按任意列进行排序。

4. LIMIT <limit_rows> [OFFSET <offset_rows>]

翻页查询。

返回值

列名	说明
JobId	作业唯一 ID
TableName	基表名称
CreateTime	作业创建时间
FinishTime	作业结束时间
BaseIndexName	基表名称
RollupIndexName	物化视图名称
RollupId	物化视图的唯一 ID
TransactionId	见 State 字段说明
State	作业状态。
Msg	错误信息
Progress	作业进度。这里的进度表示 已完成的tablet数量/总 tablet数量。创建物化视图是按 tablet 粒度进行的
Timeout	作业超时时间，单位秒

State 说明： - PENDING：作业准备中。

- WAITING_TXN： 在正式开始产生物化视图数据前，会等待当前这个表上的正在运行的导入事务完成。而 TransactionId 字段就是当前正在等待的事务 ID。当这个 ID 之前的导入都完成后，就会实际开始作业。
- RUNNING： 作业运行中。
- FINISHED： 作业运行成功。
- CANCELLED： 作业运行失败。

权限控制

执行此 SQL 命令的用户必须至少具有以下权限：

权限	对象	说明
ALTER_PRIV	table	

示例

1. 查看数据库 example_db 下的物化视图作业

```
SHOW ALTER TABLE MATERIALIZED VIEW FROM example_db;
```

SHOW-ALTER

SHOW-ALTER

Name

SHOW ALTER

描述

该语句用于展示当前正在进行的各类修改任务的执行情况

```
SHOW ALTER [CLUSTER | TABLE [COLUMN | ROLLUP] [FROM db_name]];
```

说明：

1. TABLE COLUMN：展示修改列的 ALTER 任务
2. 支持语法[WHERE TableName|CreateTime|FinishTime|State] [ORDER BY] [LIMIT]
3. TABLE ROLLUP：展示创建或删除 ROLLUP index 的任务
4. 如果不指定 db_name，使用当前默认 db
5. CLUSTER: 展示集群操作相关任务情况（仅管理员使用！待实现...）

举例

1. 展示默认 db 的所有修改列的任务执行情况

```
SHOW ALTER TABLE COLUMN;
```

2. 展示某个表最近一次修改列的任务执行情况

```
SHOW ALTER TABLE COLUMN WHERE TableName = "table1" ORDER BY CreateTime DESC LIMIT 1;
```

3. 展示指定 db 的创建或删除 ROLLUP index 的任务执行情况

```
SHOW ALTER TABLE ROLLUP FROM example_db;
```

4. 展示集群操作相关任务（仅管理员使用！待实现...）

```
SHOW ALTER CLUSTER;
```

Keywords

SHOW, ALTER

Best Practice

SHOW-ANALYZE

SHOW-ANALYZE

Name

SHOW ANALYZE

描述

通过 SHOW ANALYZE 来查看统计信息收集作业的信息。

语法如下：

```
SHOW [AUTO] ANALYZE < table_name | job_id >
  [ WHERE [ STATE = [ "PENDING" | "RUNNING" | "FINISHED" | "FAILED" ] ] ];
```

- AUTO：仅仅展示自动收集历史作业信息。需要注意的是默认只保存过去 20000 个执行完毕的自动收集作业的状态。
- table_name：表名，指定后可查看该表对应的统计作业信息。可以是 db_name.table_name 形式。不指定时返回所有统计作业信息。
- job_id：统计信息作业 ID，执行 ANALYZE 异步收集时得到。不指定 id 时此命令返回所有统计作业信息。

输出：

列名	说明
job_id	统计作业 ID
catalog_name	catalog 名称
db_name	数据库名称
tbl_name	表名称
col_name	列名称列表
job_type	作业类型
analysis_type	统计类型
message	作业信息
last_exec_time_in_ms	上次执行时间
state	作业状态
schedule_type	调度方式

下面是一个例子：

```
mysql> show analyze 245073\G;
***** 1. row *****
```

```

        job_id: 245073
        catalog_name: internal
        db_name: default_cluster:tpch
        tbl_name: lineitem
        col_name:
[l_returnflag,l_receiptdate,l_tax,l_shipmode,l_suppkey,l_shipdate,l_commitdate,l_partkey,l_orderkey,l_quantit
y,l_linestatus,l_comment,l_extendedprice,l_linenummer,l_discount,l_shipinstruct]
        job_type: MANUAL
        analysis_type: FUNDAMENTALS
        message:
last_exec_time_in_ms: 2023-11-07 11:00:52
        state: FINISHED
        progress: 16 Finished | 0 Failed | 0 In Progress | 16 Total
        schedule_type: ONCE

```

每个收集作业中可以包含一到多个任务，每个任务对应一系列的收集。用户可通过如下命令查看具体每列的统计信息收集完成情况。

语法：

```
SHOW ANALYZE TASK STATUS [job_id]
```

下面是一个例子：

```

mysql> show analyze task status 20038 ;
+-----+-----+-----+-----+-----+
| task_id | col_name | message | last_exec_time_in_ms | state |
+-----+-----+-----+-----+-----+
| 20039 | col4 | | 2023-06-01 17:22:15 | FINISHED |
| 20040 | col2 | | 2023-06-01 17:22:15 | FINISHED |
| 20041 | col3 | | 2023-06-01 17:22:15 | FINISHED |
| 20042 | col1 | | 2023-06-01 17:22:15 | FINISHED |
+-----+-----+-----+-----+-----+

```

Keywords

SHOW, ANALYZE

SHOW-BACKUP

SHOW-BACKUP

Name

SHOW BACKUP

描述

该语句用于查看 BACKUP 任务

语法：

```
SHOW BACKUP [FROM db_name]
```

说明：

1. Doris 中仅保存最近一次 BACKUP 任务。
2. 各列含义如下：

JobId:	唯一作业id
SnapshotName:	备份的名称
DbName:	所属数据库
State:	当前阶段
PENDING:	提交作业后的初始状态
SNAPSHOTING:	执行快照中
UPLOAD_SNAPSHOT:	快照完成，准备上传
UPLOADING:	快照上传中
SAVE_META:	将作业元信息保存为本地文件
UPLOAD_INFO:	上传作业元信息
FINISHED:	作业成功
CANCELLED:	作业失败
BackupObjs:	备份的表和分区
CreateTime:	任务提交时间
SnapshotFinishedTime:	快照完成时间
UploadFinishedTime:	快照上传完成时间
FinishedTime:	作业结束时间
UnfinishedTasks:	在 SNAPSHOTING 和 UPLOADING 阶段会显示还未完成的子任务id
Status:	如果作业失败，显示失败信息
Timeout:	作业超时时间，单位秒

举例

1. 查看 example_db 下最后一次 BACKUP 任务。

```
SHOW BACKUP FROM example_db;
```

Keywords

SHOW, BACKUP

Best Practice

SHOW-BACKENDS

SHOW-BACKENDS

Name

SHOW BACKENDS

描述

该语句用于查看 cluster 内的 BE 节点

```
SHOW BACKENDS;
```

说明：

1. LastStartTime 表示最近一次 BE 启动时间。
2. LastHeartbeat 表示最近一次心跳。
3. Alive 表示节点是否存活。
4. SystemDecommissioned 为 true 表示节点正在安全下线中。
5. ClusterDecommissioned 为 true 表示节点正在冲当前cluster中下线。
6. TabletNum 表示该节点上分片数量。
7. DataUsedCapacity 表示实际用户数据所占用的空间。
8. AvailCapacity 表示磁盘的可使用空间。
9. TotalCapacity 表示总磁盘空间。TotalCapacity = AvailCapacity + DataUsedCapacity + 其他非用户数据文件占用空间。
10. UsedPct 表示磁盘已使用量百分比。
11. ErrMsg 用于显示心跳失败时的错误信息。
12. Status 用于以 JSON 格式显示BE的一些状态信息，目前包括最后一次BE汇报其tablet的时间信息。
13. HeartbeatFailureCounter: 现在当前连续失败的心跳次数，如果次数超过`max\_backend\_heartbeat\_failure\_tolerance\_count`配置，则 isAlive 字段会置为 false。
14. NodeRole用于展示节点角色，现在有两种类型：Mix代表原来的节点类型，computation代表只做计算的节点类型。

举例

Keywords

SHOW, BACKENDS

Best Practice

SHOW-BROKER

SHOW-BROKER

Name

SHOW BROKER

描述

该语句用于查看当前存在的 broker

语法：

```
SHOW BROKER;
```

说明：

- 1. LastStartTime 表示最近一次 BE 启动时间。
- 2. LastHeartbeat 表示最近一次心跳。
- 3. Alive 表示节点是否存活。
- 4. ErrMsg 用于显示心跳失败时的错误信息。

举例

Keywords

```
SHOW, BROKER
```

Best Practice

SHOW-CATALOGS

SHOW-CATALOGS

Name

提示

该功能自 Apache Doris 1.2 版本起支持

SHOW CATALOGS

描述

该语句用于显示已存在是数据目录（catalog）

语法：

```
SHOW CATALOGS [LIKE]
```

说明：

LIKE：可按照 CATALOG 名进行模糊查询

返回结果说明：

- CatalogId：数据目录唯一 ID
- CatalogName：数据目录名称。其中 internal 是默认内置的 catalog，不可修改。
- Type：数据目录类型。
- IsCurrent: 是否为当前正在使用的数据目录。

举例

1. 查看当前已创建的数据目录

```
sql SHOW CATALOGS; +-----+-----+-----+-----+ | CatalogId |
CatalogName | Type | IsCurrent | +-----+-----+-----+-----+ |
130100 | hive | hms | | 0 | internal | internal | yes | +-----+-----+
+-----+-----+
```

2. 按照目录名进行模糊搜索

```
sql SHOW CATALOGS LIKE 'hi%'; +-----+-----+-----+-----+ |
CatalogId | CatalogName | Type | IsCurrent | +-----+-----+-----+-----+
```

-----+ | 130100 | hive | hms | | +-----+-----+-----+-----+
-+

Keywords

SHOW, CATALOG, CATALOGS

Best Practice

SHOW-CREATE-TABLE

SHOW-CREATE-TABLE

Name

SHOW CREATE TABLE

描述

该语句用于展示数据表的创建语句。

语法：

```
SHOW [BRIEF] CREATE TABLE [DBNAME.]TABLE_NAME
```

说明：

1. BRIEF：返回结果中不展示分区信息
2. DBNAME：数据库名称
3. TABLE_NAME：表名

举例

1. 查看某个表的建表语句

```
SHOW CREATE TABLE demo.tb1
```

Keywords

```
SHOW, CREATE, TABLE
```

Best Practice

SHOW-CHARSET

SHOW-CHARSET

描述

举例

Keywords

SHOW, CHARSET

Best Practice

SHOW-CREATE-CATALOG

SHOW-CREATE-CATALOG

Name

提示

该功能自 Apache Doris 1.2 版本起支持

SHOW CREATE CATALOG

描述

该语句查看 doris 数据目录的创建语句。

语法：

```
SHOW CREATE CATALOG catalog_name;
```

说明：

- catalog_name: 为 doris 中存在的数据目录的名称。

举例

1. 查看 doris 中 hive 数据目录的创建语句

```
SHOW CREATE CATALOG hive;
```

Keywords

SHOW, CREATE, CATALOG

Best Practice

SHOW-CREATE-DATABASE

SHOW-CREATE-DATABASE

Name

SHOW CREATE DATABASE

描述

该语句查看doris数据库的创建情况。

语法：

```
SHOW CREATE DATABASE db_name;
```

说明：

- db_name: 为doris存在的数据库名称。

举例

1. 查看doris中test数据库的创建情况

```
mysql> SHOW CREATE DATABASE test;
+-----+-----+
| Database | Create Database |
+-----+-----+
| test    | CREATE DATABASE `test` |
+-----+-----+
1 row in set (0.00 sec)
```

Keywords

SHOW, CREATE, DATABASE

Best Practice

SHOW-CREATE-MATERIALIZED-VIEW

SHOW-CREATE-MATERIALIZED-VIEW

Name

SHOW CREATE MATERIALIZED VIEW

描述

该语句用于查询创建物化视图的语句。

语法：

```
SHOW CREATE MATERIALIZED VIEW mv_name ON table_name
```

- 1. mv_name: 物化视图的名称。必填项。
- 2. table_name: 物化视图所属的表名。必填项。

举例

创建物化视图的语句为

```
create materialized view id_col1 as select id,col1 from table3;
```

查询后返回

```
mysql> show create materialized view id_col1 on table3;
+-----+-----+-----+
| TableName | ViewName | CreateStmt |
+-----+-----+-----+
| table3    | id_col1  | create materialized view id_col1 as select id,col1 from table3 |
+-----+-----+-----+
1 row in set (0.00 sec)
```

Keywords

```
SHOW, MATERIALIZED, VIEW
```

Best Practice

SHOW-CREATE-LOAD

SHOW-CREATE-LOAD

Name

SHOW CREATE LOAD

描述

该语句用于展示导入作业的创建语句。

语法：

```
SHOW CREATE LOAD for load_name;
```

说明： 1. load_name: 例行导入作业名称

举例

1. 展示默认db下指定导入作业的创建语句

```
SHOW CREATE LOAD for test_load
```

Keywords

```
SHOW, CREATE, LOAD
```

Best Practice

SHOW-CREATE-REPOSITORY

SHOW-CREATE-REPOSITORY

Name

SHOW CREATE REPOSITORY

描述

该语句用于展示仓库的创建语句。

语法：

```
SHOW CREATE REPOSITORY for repository_name;
```

说明： - repository_name: 仓库名称

举例

1. 展示指定仓库的创建语句

```
SHOW CREATE REPOSITORY for test_repository
```

Keywords

```
SHOW, CREATE, REPOSITORY
```

Best Practice

SHOW-CREATE-ROUTINE-LOAD

SHOW-CREATE-ROUTINE-LOAD

Name

SHOW CREATE ROUTINE LOAD

描述

该语句用于展示例行导入作业的创建语句。

结果中的 kafka partition 和 offset 展示的当前消费的 partition，以及对应的待消费的 offset。

语法：

```
SHOW [ALL] CREATE ROUTINE LOAD for load_name;
```

说明： 1. ALL: 可选参数，代表获取所有作业，包括历史作业 2. load_name: 例行导入作业名称

举例

1. 展示默认db下指定例行导入作业的创建语句

```
SHOW CREATE ROUTINE LOAD for test_load
```

Keywords

SHOW, CREATE, ROUTINE, LOAD

Best Practice

SHOW-CREATE-FUNCTION

描述

该语句用于展示用户自定义函数的创建语句

语法

```
SHOW CREATE [ GLOBAL ] FUNCTION <function_name>( <arg_type> ) [ FROM <db_name> ];
```

必选参数

1. <function_name>

需要查询创建语句的自定义函数的名称。

2. <arg_type>

需要查询创建语句的自定义函数的参数列表。

参数列表对应位置需要填写对应位置参数的数据类型

可选参数

1.GLOBAL

GLOBAL 为选填项

若填写 GLOBAL 则为全局搜索该函数

若不填写 GLOABL 则只在当前数据库下搜索该函数

2.<db_name>

FROM db_name 表示从指定的数据库中查询该自定义函数

返回值

列名	说明
SYMBOL	函数包名
FILE	jar 包路径
ALWAYS_NULLABLE	结果是否可以为 NULL
TYPE	函数类型

权限控制

执行此 SQL 命令的用户必须至少具有以下权限：

权限 (Privilege)	对象 (Object)	说明 (Notes)
SHOW_PRIV	函数	需要对该函数有 show 权限

示例

```
SHOW CREATE FUNCTION add_one(INT)

| Function Signature | Create Function
+-----+-----+
| add_one(INT)      | CREATE FUNCTION add_one(INT) RETURNS INT PROPERTIES (
|   "SYMBOL"="org.apache.doris.udf.AddOne",
|   "FILE"="file:///xxx.jar",
|   "ALWAYS_NULLABLE"="true",
|   "TYPE"="JAVA_UDF"
| ); |
+-----+-----+
```


SHOW-COLUMNS

SHOW-COLUMNS

Name

SHOW FULL COLUMNS

描述

该语句用于指定表的列信息

语法：

```
SHOW [FULL] COLUMNS FROM tbl;
```

举例

1. 查看指定表的列信息

```
SHOW FULL COLUMNS FROM tbl;
```

Keywords

```
SHOW, FULL, COLUMNS
```

Best Practice

SHOW-COLUMN-STATS

SHOW-COLUMN-STATS

Name

SHOW COLUMN STATS

描述

通过 SHOW COLUMN STATS 来查看列的各项统计数据。

语法如下：

```
SHOW COLUMN [cached] STATS table_name [ (column_name [, ...]) ];
```

其中：

- **cached**: 展示当前 FE 内存缓存中的统计信息。
- **table_name**: 收集统计信息的目标表。可以是 `db_name.table_name` 形式。
- **column_name**: 指定的目标列，必须是 `table_name` 中存在的列，多个列名称用逗号分隔。

下面是一个例子：

```
mysql> show column stats lineitem(l_tax)\G;
***** 1. row *****
column_name: l_tax
  count: 6001215.0
    ndv: 9.0
 num_null: 0.0
data_size: 4.800972E7
avg_size_byte: 8.0
    min: 0.00
    max: 0.08
  method: FULL
    type: FUNDAMENTALS
  trigger: MANUAL
query_times: 0
updated_time: 2023-11-07 11:00:46
```

Keywords

SHOW, COLUMN, STATS

SHOW-COLLATION

描述

在 Doris 中，SHOW COLLATION 命令用于显示数据库中可用的字符集校对。校对是一组决定数据如何排序和比较的规则。这些规则会影响字符数据的存储和检索。此命令所返回的内容仅用于兼容 MySQL 的行为。不代表 Doris 真是支持的字符集校对列表。Doris 目前主要支持 utf8mb4_0900_bin 这一种校对方式。

语法

```
SHOW COLLATION
```

返回结果

SHOW COLLATION 命令返回以下字段：

- Collation：校对名称
- Charset：字符集
- Id：校对的ID
- Default：是否是该字符集的默认校对
- Compiled：是否已编译
- Sortlen：排序长度

示例

```
show collation;
```

Collation	Charset	Id	Default	Compiled	Sortlen
utf8_general_ci	utf8	33	Yes	Yes	1

注意事项

在 Doris 中，虽然兼容 MySQL 的设置 collation 的命令。但是实际并不会生效。执行时，永远会使用 utf8mb4_0900_bin 作为比较规则。

SHOW-DATABASES

SHOW-DATABASES

Name

SHOW DATABASES

描述

该语句用于展示当前可见的 db

语法：

```
SHOW DATABASES [FROM catalog] [filter expr];
```

说明: 1. SHOW DATABASES 会展示当前所有的数据库名称. 2. SHOW DATABASES FROM catalog 会展示catalog中所有的数据库名称. 3. SHOW DATABASES filter_expr 会展示当前所有经过过滤后的数据库名称. 4. SHOW DATABASES FROM catalog filter_expr 这种语法不支持.

举例

1. 展示当前所有的数据库名称.

```
SHOW DATABASES;
```

```
+-----+
| Database |
+-----+
| test     |
| information_schema |
+-----+
```

2. 会展示hms_catalog中所有的数据库名称.

```
SHOW DATABASES from hms_catalog;
```

```
+-----+
| Database |
+-----+
| default  |
| tpch     |
+-----+
```

3. 展示当前所有经过表示式like 'infor%'过滤后的数据库名称.

```
SHOW DATABASES like 'infor%';
```

```
+-----+  
| Database |  
+-----+  
| information_schema |  
+-----+
```

Keywords

SHOW, DATABASES

Best Practice

SHOW-DATA-SKEW

SHOW-DATA-SKEW

Name

SHOW DATA SKEW

描述

该语句用于查看表或某个分区的数据倾斜情况。

语法：

```
SHOW DATA SKEW FROM [db_name.]tbl_name PARTITION (partition_name);
```

说明：

1. 必须指定且仅指定一个分区。对于非分区表，分区名称同表名。
2. 结果将展示指定分区下，各个分桶的数据行数，数据量，以及每个分桶数据量在总数据量中的占比。

举例

1. 查看表的数据倾斜情况

```
SHOW DATA SKEW FROM db1.test PARTITION(p1);
```

Keywords

SHOW, DATA, SKEW

Best Practice

SHOW-DATABASE-ID

SHOW-DATABASE-ID

Name

SHOW DATABASE ID

描述

该语句用于根据 database id 查找对应的 database name（仅管理员使用）

语法：

```
SHOW DATABASE [database_id]
```

举例

1. 根据 database id 查找对应的 database name

```
SHOW DATABASE 1001;
```

Keywords

```
SHOW, DATABASE, ID
```

Best Practice

SHOW-DYNAMIC-PARTITION

SHOW-DYNAMIC-PARTITION

Name

SHOW DYNAMIC

描述

该语句用于展示当前db下所有的动态分区表状态

语法：

```
SHOW DYNAMIC PARTITION TABLES [FROM db_name];
```

举例

1. 展示数据库 database 的所有动态分区表状态

```
SHOW DYNAMIC PARTITION TABLES FROM database;
```

Keywords

```
SHOW, DYNAMIC, PARTITION
```

Best Practice

SHOW-DELETE

SHOW-DELETE

Name

SHOW DELETE

描述

该语句用于展示已执行成功的历史 delete 任务

语法：

```
SHOW DELETE [FROM db_name]
```

举例

1. 展示数据库 database 的所有历史 delete 任务

```
SHOW DELETE FROM database;
```

Keywords

```
SHOW, DELETE
```

Best Practice

SHOW-DATA

SHOW-DATA

Name

SHOW DATA

描述

该语句用于展示数据量、副本数量以及统计行数。

语法：

```
SHOW DATA [FROM [db_name.]table_name] [ORDER BY ...];
```

说明：

- 1. 如果不指定 FROM 子句，则展示当前 db 下细分到各个 table 的数据量和副本数量。其中数据量为所有副本的总数据量。而副本数量为表的所有分区以及所有物化视图的副本数量。
- 2. 如果指定 FROM 子句，则展示 table 下细分到各个物化视图的数据量、副本数量和统计行数。其中数据量为所有副本的总数据量。副本数量为对应物化视图的所有分区的副本数量。统计行数为对应物化视图的所有分区统计行数。
- 3. 统计行数时，以多个副本中，行数最大的那个副本为准。
- 4. 结果集中的 Total 行表示汇总行。Quota 行表示当前数据库设置的配额。Left 行表示剩余配额。
- 5. 如果想查看各个 Partition 的大小，请参阅 help show partitions。
- 6. 可以使用 ORDER BY 对任意列组合进行排序。

举例

- 1. 展示默认 db 的各个 table 的数据量，副本数量，汇总数据量和汇总副本数量。

SHOW DATA;

TableName	Size	ReplicaCount
tbl1	900.000 B	6
tbl2	500.000 B	3
Total	1.400 KB	9
Quota	1024.000 GB	1073741824
Left	1021.921 GB	1073741815

2. 展示指定 db 的下指定表的细分数据量、副本数量和统计行数

```
SHOW DATA FROM example_db.test;
```

TableName	IndexName	Size	ReplicaCount	RowCount
test	r1	10.000MB	30	10000
	r2	20.000MB	30	20000
	test2	50.000MB	30	50000
	Total	80.000	90	

3. 可以按照数据量、副本数量、统计行数等进行组合排序

```
SHOW DATA ORDER BY ReplicaCount desc,Size asc;
```

TableName	Size	ReplicaCount
table_c	3.102 KB	40
table_d	.000	20
table_b	324.000 B	20
table_a	1.266 KB	10
Total	4.684 KB	90
Quota	1024.000 GB	1073741824
Left	1024.000 GB	1073741734

Keywords

SHOW, DATA

Best Practice

SHOW-ENGINES

SHOW-ENGINES

Name

SHOW ENGINES

描述

举例

Keywords

SHOW, ENGINES

Best Practice

SHOW-EVENTS

SHOW-EVENTS

Name

SHOW EVENTS

描述

举例

Keywords

SHOW, EVENTS

Best Practice

SHOW-EXPORT

SHOW-EXPORT

Name

SHOW EXPORT

描述

该语句用于展示指定的导出任务的执行情况

语法：

```
SHOW EXPORT
[FROM db_name]
[
  WHERE
    [ID = your_job_id]
    [STATE = ["PENDING"|"EXPORTING"|"FINISHED"|"CANCELLED"]]
    [LABEL = your_label]
]
[ORDER BY ...]
[LIMIT limit];
```

说明： 1. 如果不指定 db_name，使用当前默认db 2. 如果指定了 STATE，则匹配 EXPORT 状态 3. 可以使用 ORDER BY 对任意列组合进行排序 4. 如果指定了 LIMIT，则显示 limit 条匹配记录。否则全部显示

举例

1. 展示默认 db 的所有导出任务

```
SHOW EXPORT;
```

2. 展示指定 db 的导出任务，按 StartTime 降序排序

```
SHOW EXPORT FROM example_db ORDER BY StartTime DESC;
```

3. 展示指定 db 的导出任务，state 为 “exporting”，并按 StartTime 降序排序

```
SHOW EXPORT FROM example_db WHERE STATE = "exporting" ORDER BY StartTime DESC;
```

4. 展示指定db，指定job_id的导出任务

```
SHOW EXPORT FROM example_db WHERE ID = job_id;
```

5. 展示指定db，指定label的导出任务

```
SHOW EXPORT FROM example_db WHERE LABEL = "mylabel";
```

Keywords

SHOW, EXPORT

Best Practice

SHOW-ENCRYPT-KEY

SHOW-ENCRYPT-KEY

Name

SHOW ENCRYPTKEYS

描述

查看数据库下所有的自定义的密钥。如果用户指定了数据库，那么查看对应数据库的，否则直接查询当前会话所在数据库。

需要对这个数据库拥有 ADMIN 权限

语法：

```
SHOW ENCRYPTKEYS [IN|FROM db] [LIKE 'key_pattern']
```

参数

db: 要查询的数据库名字 key_pattern: 用来过滤密钥名称的参数

举例

```
mysql> SHOW ENCRYPTKEYS;
+-----+-----+
| EncryptKey Name | EncryptKey String |
+-----+-----+
| example_db.my_key | ABCD123456789 |
+-----+-----+
1 row in set (0.00 sec)

mysql> SHOW ENCRYPTKEYS FROM example_db LIKE "%my%";
+-----+-----+
| EncryptKey Name | EncryptKey String |
+-----+-----+
| example_db.my_key | ABCD123456789 |
+-----+-----+
1 row in set (0.00 sec)
```

Keywords

SHOW, ENCRYPT, KEY

Best Practice

SHOW-FUNCTIONS

描述

查看数据库下所有的自定义与系统提供的函数。

语法

```
SHOW [ FULL ] [ BUILTIN ] FUNCTIONS [ { IN | FROM } <db> ] [ LIKE '<function_pattern>' ]
```

变种语法

```
SHOW GLOBAL [ FULL ] FUNCTIONS [ LIKE '<function_pattern>' ]
```

必选参数

1. <function_pattern>

用来过滤函数名称的匹配模式规则

可选参数

1. FULL

FULL 为选填项

若填写表示显示函数的详细信息。

2. BUILTIN

BUILTIN 为选填项

若填写表示需要显示系统提供的函数

3. <db>

db 为选填项

若填写表示在指定的数据库下查询

返回值

列名	说明
Signature	函数名与参数类型
Return Type	函数返回值的数据类型
Function Type	函数的类型
Intermediate Type	中间结果类型
Properties	函数的详细属性

权限控制

执行此 SQL 命令的用户必须至少具有以下权限：

权限 (Privilege)	对象 (Object)	说明 (Notes)
SHOW_PRIV	函数	需要对该函数有 show 权限

示例

```
show full functions in testDb

***** 1. row *****
Signature: my_add(INT,INT)
Return Type: INT
Function Type: Scalar
Intermediate Type: NULL
Properties:
{"symbol": "_ZN9doris_udf6AddUdfEPNS_15FunctionContextERKNS_6IntValES4_", "object_file": "http://host:port/libudfsample.so", "md5": "cfe7a362d10f3aaf6c49974ee0f1f878"}
***** 2. row *****
Signature: my_count(BIGINT)
Return Type: BIGINT
Function Type: Aggregate
Intermediate Type: NULL
Properties:
{"object_file": "http://host:port/libudasample.so", "finalize_fn": "_ZN9doris_udf13CountFinalizeEPNS_15FunctionContextERKNS_9BigIntValE", "init_fn": "_ZN9doris_udf9CountInitEPNS_15FunctionContextEPNS_9BigIntValE", "merge_fn": "_ZN9doris_udf10CountMergeEPNS_15FunctionContextERKNS_9BigIntValEPS2_", "md5": "37d185f80f95569e2676da3d5b5b9d2f", "update_fn": "_ZN9doris_udf11CountUpdateEPNS_15FunctionContextERKNS_6IntValEPNS_9BigIntValE"}
***** 3. row *****
Signature: id_masking(BIGINT)
Return Type: VARCHAR
Function Type: Alias
Intermediate Type: NULL
Properties: {"parameter": "id", "origin_function": "concat(left(`id`, 3), `****`, right(`id`, 4))"}

show builtin functions in testDb like 'year%';
```

```

+-----+
| Function Name |
+-----+
| year          |
| years_add     |
| years_diff    |
| years_sub     |
+-----+

```

```
show global full functions
```

```

***** 1. row *****
Signature: decimal(ALL, INT, INT)
Return Type: VARCHAR
Function Type: Alias
Intermediate Type: NULL
Properties: {"parameter":"col, precision, scale","origin_function":"CAST(`col` AS decimal(`precision`,
`scale`))"}
***** 2. row *****
Signature: id_masking(BIGINT)
Return Type: VARCHAR
Function Type: Alias
Intermediate Type: NULL
Properties: {"parameter":"id","origin_function":"concat(left(`id`, 3), `****`, right(`id`, 4))"}

```

```
show global functions
```

```

+-----+
| Function Name |
+-----+
| decimal       |
| id_masking    |
+-----+

```

SHOW-TYPECAST

SHOW-TYPECAST

Name

SHOW TYPECAST

描述

查看数据库下所有的类型转换。如果用户指定了数据库，那么查看对应数据库的，否则直接查询当前会话所在数据库

需要对这个数据库拥有 SHOW 权限

语法

```
SHOW TYPE_CAST [IN|FROM db]
```

Parameters

db: database name to query

举例

```
mysql> show type_cast in testDb\G
***** 1. row *****
Origin Type: TIMEV2
Cast Type: TIMEV2
***** 2. row *****
Origin Type: TIMEV2
Cast Type: TIMEV2
***** 3. row *****
Origin Type: TIMEV2
Cast Type: TIMEV2

3 rows in set (0.00 sec)
```

Keywords

SHOW, TYPECAST

Best Practice

SHOW-FILE

SHOW-FILE

Name

SHOW FILE

描述

该语句用于展示一个 database 内创建的文件

语法：

```
SHOW FILE [FROM database];
```

说明：

FileId:	文件ID, 全局唯一
DbName:	所属数据库名称
Catalog:	自定义分类
FileName:	文件名
FileSize:	文件大小, 单位字节
MD5:	文件的 MD5

举例

1. 查看数据库 my_database 中已上传的文件

```
SHOW FILE FROM my_database;
```

Keywords

```
SHOW, FILE
```

Best Practice

SHOW-GRANTS

SHOW-GRANTS

Name

SHOW GRANTS

描述

该语句用于查看用户权限。

语法：

```
SHOW [ALL] GRANTS [FOR user_identity];
```

说明：

1. SHOW ALL GRANTS 可以查看所有用户的权限。
2. 如果指定 user_identity，则查看该指定用户的权限。且该 user_identity 必须为通过 CREATE USER 命令创建的。
3. 如果不指定 user_identity，则查看当前用户的权限。

举例

1. 查看所有用户权限信息

```
SHOW ALL GRANTS;
```

2. 查看指定 user 的权限

```
SHOW GRANTS FOR jack@'%';
```

3. 查看当前用户的权限

```
SHOW GRANTS;
```

Keywords

```
SHOW, GRANTS
```

Best Practice

SHOW-LAST-INSERT

SHOW-LAST-INSERT

Name

SHOW LAST INSERT

描述

该语法用于查看在当前session连接中，最近一次 insert 操作的结果

语法：

```
SHOW LAST INSERT
```

返回结果示例：

```
TransactionId: 64067
  Label: insert_ba8f33aea9544866-8ed77e2844d0cc9b
  Database: default_cluster:db1
  Table: t1
TransactionStatus: VISIBLE
  LoadedRows: 2
  FilteredRows: 0
```

说明：

- TransactionId：事务id
- Label：insert任务对应的 label
- Database：insert对应的数据库
- Table：insert对应的表
- TransactionStatus：事务状态
 - PREPARE：准备阶段
 - PRECOMMITTED：预提交阶段
 - COMMITTED：事务成功，但数据不可见
 - VISIBLE：事务成功且数据可见
 - ABORTED：事务失败
- LoadedRows：导入的行数
- FilteredRows：被过滤的行数

举例

Keywords

```
SHOW, LAST, INSERT
```

Best Practice

SHOW-LOAD-PROFILE

SHOW-LOAD-PROFILE

Name

SHOW LOAD PROFILE

描述

该语句是用来查看导入操作的 Profile 信息，该功能需要用户打开 Profile 设置，0.15 之前版本执行下面的设置：

```
SET is_report_success=true;
```

0.15 及之后的版本执行下面的设置：

```
SET [GLOBAL] enable_profile=true;
```

语法：

```
show load profile "/";

show load profile "/[queryId]"

show load profile "/[queryId]/[TaskId]"

show load profile "/[queryId]/[TaskId]/[FragmentId]/"

show load profile "/[queryId]/[TaskId]/[FragmentId]/[InstanceId]"
```

这个命令会列出当前保存的所有导入 Profile。每行对应一个导入。其中 QueryId 列为导入作业的 ID。这个 ID 也可以通过 SHOW LOAD 语句查看拿到。我们可以选择我们想看的 Profile 对应的 QueryId，查看具体情况

举例

1. 列出所有的 Load Profile

```
mysql> show load profile "/"G
***** 1. row *****
      JobId: 20010
      QueryId: 980014623046410a-af5d36f23381017f
      User: root
      DefaultDb: default_cluster:test
      SQL: LOAD LABEL xxx
      QueryType: Load
      StartTime: 2023-03-07 19:48:24
      EndTime: 2023-03-07 19:50:45
      TotalTime: 2m21s
      QueryState: N/A
      TraceId:
```

```

AnalysisTime: NULL
PlanTime: NULL
ScheduleTime: NULL
FetchResultTime: NULL
WriteResultTime: NULL
WaitAndFetchResultTime: NULL
***** 2. row *****
JobId: N/A
QueryId: 7cc2d0282a7a4391-8dd75030185134d8
User: root
DefaultDb: default_cluster:test
SQL: insert into xxx
QueryType: Load
StartTime: 2023-03-07 19:49:15
EndTime: 2023-03-07 19:49:15
TotalTime: 102ms
QueryState: OK
TraceId:
AnalysisTime: 825.277us
PlanTime: 4.126ms
ScheduleTime: N/A
FetchResultTime: 0ns
WriteResultTime: 0ns
WaitAndFetchResultTime: N/A

```


2. 查看有导入作业的子任务概况：


```
mysql> show load profile "/980014623046410a-af5d36f23381017f";
```

TaskId	ActiveTime
980014623046410a-af5d36f23381017f	3m14s

3. 查看子任务的执行树：

```
show load profile "/980014623046410a-af5d36f23381017f/980014623046410a-af5d36f23381017f";
```





这一层会显示子任务的查询树，其中标注了 Fragment id。

4. 查看指定 Fragment 的 Instance 概况

```
mysql> show load profile "/980014623046410a-af5d36f23381017f/980014623046410a-af5d36f23381017f/1";
```

Instances	Host	ActiveTime
980014623046410a-88e260f0c43031f2	10.81.85.89:9067	3m7s
980014623046410a-88e260f0c43031f3	10.81.85.89:9067	3m6s
980014623046410a-88e260f0c43031f4	10.81.85.89:9067	3m10s
980014623046410a-88e260f0c43031f5	10.81.85.89:9067	3m14s

5. 继续查看某一个具体的 Instance 上各个算子的详细 Profile

```
mysql> show load profile "/980014623046410a-af5d36f23381017f/980014623046410a-af5d36f23381017f/1/980014623046410a-88e260f0c43031f5"\G
```

***** 1. row *****

Instance:

```

[-1: OlapTableSink]
(Active: 2m17s, non-child: 70.91)
- Counters:
  - CloseWaitTime: 1m53s
  - ConvertBatchTime: 0ns
  - MaxAddBatchExecTime: 1m46s
  - NonBlockingSendTime: 3m11s
  - NumberBatchAdded: 782
  - NumberNodeChannels: 1
  - OpenTime: 743.822us
  - RowsFiltered: 0
  - RowsRead: 1.599729M (1599729)
  - RowsReturned: 1.599729M (1599729)
  - SendDataTime: 11s761ms
  - TotalAddBatchExecTime: 1m46s
  - ValidateDataTime: 9s802ms
  
```

```

[0: BROKER_SCAN_NODE]
(Active: 56s537ms, non-child: 29.06)
- Counters:
  - BytesDecompressed: 0.00
  - BytesRead: 5.77 GB
  
```

```
- DecompressTime: 0ns
- FileReadTime: 34s263ms
- MaterializeTupleTime(*): 45s54ms
- NumDiskAccess: 0
- PeakMemoryUsage: 33.03 MB
- RowsRead: 1.599729M (1599729)
- RowsReturned: 1.599729M (1599729)
- RowsReturnedRate: 28.295K sec
- TotalRawReadTime(*): 1m20s
- TotalReadThroughput: 30.39858627319336 MB/sec
- WaitScannerTime: 56s528ms
```

Keywords

SHOW, LOAD, PROFILE

Best Practice

SHOW-LOAD-WARNINGS

SHOW-LOAD-WARNINGS

Name

SHOW LOAD WARNINGS

描述

如果导入任务失败且错误信息为 ETL_QUALITY_UNSATISFIED，则说明存在导入质量问题, 如果想看到这些有质量问题的导入任务，该语句就是完成这个操作的。

语法：

```
SHOW LOAD WARNINGS
[FROM db_name]
[
  WHERE
    [LABEL [ = "your_label" ]]
    [LOAD_JOB_ID = ["job id"]]
]
```

1. 如果不指定 db_name，使用当前默认db
2. 如果使用 LABEL = ，则精确匹配指定的 label
3. 如果指定了 LOAD_JOB_ID，则精确匹配指定的 JOB ID

举例

1. 展示指定 db 的导入任务中存在质量问题的数据，指定 label 为 “load_demo_20210112”

```
SHOW LOAD WARNINGS FROM demo WHERE LABEL = "load_demo_20210112"
```

Keywords

SHOW, LOAD, WARNINGS

Best Practice

SHOW-INDEX

SHOW-INDEX

Name

SHOW INDEX

描述

该语句用于展示一个表中索引的相关信息，目前只支持bitmap 索引

语法：

```
SHOW INDEX[ES] FROM [db_name.]table_name [FROM database];  
或者  
SHOW KEY[S] FROM [db_name.]table_name [FROM database];
```

举例

1. 展示指定 table_name 的下索引

```
SHOW INDEX FROM example_db.table_name;
```

Keywords

SHOW, INDEX

Best Practice

SHOW PARTITION ID

描述

该语句用于根据 partition id 查找对应的 database name, table name, partition name

语法

```
SHOW PARTITION <partition_id>
```

必选参数

- 1. <partition_id>

分区 id

权限控制

执行此 SQL 命令的用户必须至少具有以下权限：

权限	对象	说明
ADMIN_PRIV		

示例

- 1. 根据 partition id 查找对应的 database name, table name, partition name

```
SHOW PARTITION 10002;
```

SHOW-SNAPSHOT

SHOW-SNAPSHOT

Name

SHOW SNAPSHOT

描述

该语句用于查看仓库中已存在的备份。

语法：

```
SHOW SNAPSHOT ON `repo_name`  
[WHERE SNAPSHOT = "snapshot" [AND TIMESTAMP = "backup_timestamp"]];
```

说明： 1. 各列含义如下： Snapshot： 备份的名称 Timestamp： 对应备份的时间版本 Status： 如果备份正常，则显示 OK，否则显示错误信息 2. 如果指定了 TIMESTAMP，则会额外显示如下信息： Database： 备份数据原属的数据库名称 Details： 以 Json 的形式，展示整个备份的数据目录及文件结构

举例

1. 查看仓库 example_repo 中已有的备份

```
SHOW SNAPSHOT ON example_repo;
```

2. 仅查看仓库 example_repo 中名称为 backup1 的备份：

```
SHOW SNAPSHOT ON example_repo WHERE SNAPSHOT = "backup1";
```

3. 查看仓库 example_repo 中名称为 backup1 的备份，时间版本为“2018-05-05-15-34-26”的详细信息：

```
SHOW SNAPSHOT ON example_repo  
WHERE SNAPSHOT = "backup1" AND TIMESTAMP = "2018-05-05-15-34-26";
```

Keywords

SHOW, SNAPSHOT

Best Practice

SHOW-SQL-BLOCK-RULE

SHOW-SQL-BLOCK-RULE

Name

SHOW SQL BLOCK RULE

描述

查看已配置的SQL阻止规则，不指定规则名则为查看所有规则。

语法：

```
SHOW SQL_BLOCK_RULE [FOR RULE_NAME];
```

举例

- 1. 查看所有规则。

```
mysql> SHOW SQL_BLOCK_RULE;
+-----+-----+-----+-----+-----+-----+-----+-----+
| Name      | Sql                                | SqlHash | PartitionNum | TabletNum | Cardinality | Global | Enable |
+-----+-----+-----+-----+-----+-----+-----+-----+
| test_rule | select * from order_analysis      | NULL    | 0             | 0          | 0           | true  | true   |
| test_rule2 | NULL                             | NULL    | 30            | 0          | 10000000000 | false | true   |
+-----+-----+-----+-----+-----+-----+-----+-----+
2 rows in set (0.01 sec)
```

- 2. 指定规则名查询

```
mysql> SHOW SQL_BLOCK_RULE FOR test_rule2;
+-----+-----+-----+-----+-----+-----+-----+-----+
| Name      | Sql | SqlHash | PartitionNum | TabletNum | Cardinality | Global | Enable |
+-----+-----+-----+-----+-----+-----+-----+-----+
| test_rule2 | NULL | NULL    | 30           | 0          | 10000000000 | false | true   |
+-----+-----+-----+-----+-----+-----+-----+-----+
1 row in set (0.00 sec)
```

Keywords

```
SHOW, SQL_BLOCK_RULE
```

Best Practice

SHOW-ROUTINE-LOAD

SHOW-ROUTINE-LOAD

Name

SHOW ROUTINE LOAD

描述

该语句用于展示 Routine Load 作业运行状态

语法：

```
SHOW [ALL] ROUTINE LOAD [FOR jobName];
```

结果说明：

Id: 作业ID

Name: 作业名称

CreateTime: 作业创建时间

PauseTime: 最近一次作业暂停时间

EndTime: 作业结束时间

DbName: 对应数据库名称

TableName: 对应表名称（多表的情况下由于是动态表，因此不显示具体表名，我们统一显示 multi-table）

IsMultiTbl: 是否为多表

State: 作业运行状态

DataSourceType: 数据源类型：KAFKA

CurrentTaskNum: 当前子任务数量

JobProperties: 作业配置详情

DataSourceProperties: 数据源配置详情

CustomProperties: 自定义配置

Statistic: 作业运行状态统计信息

Progress: 作业运行进度

Lag: 作业延迟状态

ReasonOfStateChanged: 作业状态变更的原因

ErrorLogUrls: 被过滤的质量不合格的数据的查看地址

OtherMsg: 其他错误信息

- State

有以下5种State：

* NEED_SCHEDULE：作业等待被调度

* RUNNING：作业运行中

* PAUSED：作业被暂停

* STOPPED：作业已结束

* CANCELLED：作业已取消

- Progress

对于Kafka数据源，显示每个分区当前已消费的offset。如 `{"0": "2"}` 表示Kafka分区0的消费进度为2。

- Lag

对于Kafka数据源，显示每个分区的消费延迟。如`{"0": 10}` 表示Kafka分区0的消费延迟为10。

举例

1. 展示名称为 test1 的所有例行导入作业（包括已停止或取消的作业）。结果为一行或多行。

```
SHOW ALL ROUTINE LOAD FOR test1;
```

2. 展示名称为 test1 的当前正在运行的例行导入作业

```
SHOW ROUTINE LOAD FOR test1;
```

3. 显示 example_db 下，所有的例行导入作业（包括已停止或取消的作业）。结果为一行或多行。

```
use example_db;  
SHOW ALL ROUTINE LOAD;
```

4. 显示 example_db 下，所有正在运行的例行导入作业

```
use example_db;  
SHOW ROUTINE LOAD;
```

5. 显示 example_db 下，名称为 test1 的当前正在运行的例行导入作业

```
SHOW ROUTINE LOAD FOR example_db.test1;
```

6. 显示 example_db 下，名称为 test1 的所有例行导入作业（包括已停止或取消的作业）。结果为一行或多行。

```
SHOW ALL ROUTINE LOAD FOR example_db.test1;
```

Keywords

SHOW, ROUTINE, LOAD

Best Practice

SHOW-SYNC-JOB

SHOW-SYNC-JOB

Name

SHOW SYNC JOB

描述

此命令用于当前显示所有数据库内的常驻数据同步作业状态。

语法：

```
SHOW SYNC JOB [FROM db_name]
```

举例

1. 展示当前数据库的所有数据同步作业状态。

```
SHOW SYNC JOB;
```

2. 展示数据库 test_db 下的所有数据同步作业状态。

```
SHOW SYNC JOB FROM `test_db`;
```

Keywords

```
SHOW, SYNC, JOB
```

Best Practice

SHOW-WHITE-LIST

SHOW-WHITE-LIST

描述

举例

Keywords

SHOW, WHITE, LIST

Best Practice

SHOW-WARNING

SHOW-WARNING

描述

举例

Keywords

SHOW, WARNING

Best Practice

SHOW TABLET

描述

该语句用于显示指定tablet id 信息（仅管理员使用）。

语法

```
SHOW TABLET <tablet_id>;
```

必选参数

1. <tablet_id>

要显示信息的特定 tablet 的 ID。

返回值

使用 SHOW TABLET <tablet_id> 时，将返回以下列：

列名	数据类型	说明
DbName	String	包含该 tablet 的数据库名称。
TableName	String	包含该 tablet 的表名称。
PartitionName	String	包含该 tablet 的分区名称。
IndexName	String	包含该 tablet 的索引名称。
DbId	Int	数据库的 ID。
TableId	Int	表的 ID。
PartitionId	Int	分区的 ID。
IndexId	Int	索引的 ID。
IsSync	Boolean	该 tablet 是否与其副本同步。
Order	Int	tablet 的顺序。
QueryHits	Int	该 tablet 上的查询命中次数。
DetailCmd	String	获取有关该 tablet 更详细信息的命令。

权限控制

执行此 SQL 命令的用户必须至少具有以下权限：

权限	对象	说明
Admin_priv	Database	需要执行数据库的管理操作，包括管理表、分区和系统级命令。

示例

显示特定 tablet 的详细信息：

```
SHOW TABLET 10145;
```

```
+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+
+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+
| DbName | TableName | PartitionName | IndexName | DbId | TableId | PartitionId | IndexId | IsSync | Order |
QueryHits | DetailCmd |
+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+
+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+
| test | sell_user | sell_user | sell_user | 10103 | 10143 | 10142 | 10144 | true | 0 |
0 | SHOW PROC '/dbs/10103/10143/partitions/10142/10144/10145'; |
+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+
+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+
```

SHOW TABLETS BELONG

描述

该语句用于显示指定 tablet 及其所属表的信息。

语法

```
SHOW TABLETS BELONG <tablet_id> [, <tablet_id>]...;
```

必选参数

1. <tablet_id>

一个或多个 tablet ID，用逗号分隔。结果中会对重复的 ID 进行去重。

返回值

使用 SHOW TABLETS BELONG <tablet_id> [, <tablet_id>]... 时，将返回以下列：

列名	数据类型	说明
DbName	String	包含该 tablet 的数据库名称。
TableName	String	包含该 tablet 的表名称。
TableSize	String	表的大小（例如：“8.649 KB”）。
PartitionNum	Int	表中的分区数量。
BucketNum	Int	表中的分桶数量。
ReplicaCount	Int	表中的副本数量。
TabletIds	Array	属于该表的 tablet ID 列表。

权限控制

执行此 SQL 命令的用户必须至少具有以下权限：

权限	对象	说明
Admin_priv	Database	需要执行数据库的管理操作，包括管理表、分区和系统级命令。

示例

显示特定 tablet 的信息：

SHOW TABLETS BELONG 10145;

DbName	TableName	TableSize	PartitionNum	BucketNum	ReplicaCount	TabletIds
test	sell_user	8.649 KB	1	4	4	[10145]

显示多个 tablet 的信息：

SHOW TABLETS BELONG 27028,78880,78382,27028;

DbName	TableName	TableSize	PartitionNum	BucketNum	ReplicaCount	TabletIds
default_cluster:db1	kec	613.000 B	379	604	604	[78880, 78382]
default_cluster:db1	test	1.874 KB	1	1	1	[27028]

SHOW-VARIABLES

SHOW-VARIABLES

Name

SHOW VARIABLES

描述

该语句是用来显示Doris系统变量，可以通过条件查询

语法：

```
SHOW [GLOBAL | SESSION] VARIABLES  
[LIKE 'pattern' | WHERE expr]
```

说明：

- show variables主要是用来查看系统变量的值.
- 执行SHOW VARIABLES命令不需要任何权限,只要求能够连接到服务器就可以.
- 使用like语句表示用variable_name进行匹配.
- %百分号通配符可以用在匹配模式中的任何位置

举例

1. 这里默认的就是对Variable_name进行匹配,这里是准确匹配

```
show variables like 'max_connections';
```

2. 通过百分号(%)这个通配符进行匹配,可以匹配多项

```
show variables like '%connec%';
```

3. 使用 Where 子句进行匹配查询

```
show variables where variable_name = 'version';
```

Keywords

SHOW, VARIABLES

Best Practice

SHOW-PLUGINS

SHOW-PLUGINS

Name

SHOW PLUGINS

描述

该语句用于展示已安装的插件

语法：

```
SHOW PLUGINS
```

该命令会展示所有用户安装的和系统内置的插件

举例

1. 展示已安装的插件：

```
SHOW PLUGINS;
```

Keywords

```
SHOW, PLUGINS
```

Best Practice

SHOW-ROLES

SHOW-ROLES

Name

SHOW ROLES

描述

该语句用于展示所有已创建的角色信息，包括角色名称，包含的用户以及权限。

语法：

```
SHOW ROLES
```

举例

- 1. 查看已创建的角色

```
SHOW ROLES
```

Keywords

```
SHOW, ROLES
```

Best Practice

SHOW-PROCEDURE

SHOW-PROCEDURE

描述

举例

Keywords

SHOW, PROCEDURE

Best Practice

SHOW-ROUTINE-LOAD-TASK

SHOW-ROUTINE-LOAD-TASK

Name

SHOW ROUTINE LOAD TASK

描述

查看一个指定的 Routine Load 作业的当前正在运行的子任务情况。

```
SHOW ROUTINE LOAD TASK
WHERE JobName = "job_name";
```

返回结果如下：

```
TaskId: d67ce537f1be4b86-abf47530b79ab8e6
TxnId: 4
TxnStatus: UNKNOWN
JobId: 10280
CreateTime: 2020-12-12 20:29:48
ExecuteStartTime: 2020-12-12 20:29:48
Timeout: 20
BeId: 10002
DataSourceProperties: {"0":19}
```

- TaskId：子任务的唯一 ID。
- TxnId：子任务对应的导入事务 ID。
- TxnStatus：子任务对应的导入事务状态。为 null 时表示子任务还未开始调度。
- JobId：子任务对应的作业 ID。
- CreateTime：子任务的创建时间。
- ExecuteStartTime：子任务被调度执行的时间，通常晚于创建时间。
- Timeout：子任务超时时间，通常是作业设置的 max_batch_interval 的两倍。
- BeId：执行这个子任务的 BE 节点 ID。
- DataSourceProperties：子任务准备消费的 Kafka Partition 的起始 offset。是一个 Json 格式字符串。Key 为 Partition Id。Value 为消费的起始 offset。

举例

1. 展示名为 test1 的例行导入任务的子任务信息。

```
SHOW ROUTINE LOAD TASK WHERE JobName = "test1";
```


Keywords

SHOW, ROUTINE, LOAD, TASK

Best Practice

通过这个命令，可以查看一个 Routine Load 作业当前有多少子任务在运行，具体运行在哪个 BE 节点上。

SHOW-PROC

SHOW-PROC

Name

SHOW PROC

描述

Proc 系统是 Doris 的一个比较有特色的功能。使用过 Linux 的同学可能比较了解这个概念。在 Linux 系统中，proc 是一个虚拟的文件系统，通常挂载在 /proc 目录下。用户可以通过这个文件系统来查看系统内部的数据结构。比如可以通过 /proc/pid 查看指定 pid 进程的详细情况。

和 Linux 中的 proc 系统类似，Doris 中的 proc 系统也被组织成一个类似目录的结构，根据用户指定的“目录路径（proc 路径）”，来查看不同的系统信息。

proc 系统被设计为主要面向系统管理人员，方便其查看系统内部的一些运行状态。如表的 tablet 状态、集群均衡状态、各种作业的状态等等。是一个非常实用的功能

Doris 中有两种方式可以查看 proc 系统。

1. 通过 Doris 提供的 WEB UI 界面查看，访问地址：http://FE_IP:FE_HTTP_PORT
2. 另外一种方式是通过命令

通过 SHOW PROC "/"; 可看到 Doris PROC 支持的所有命令

通过 MySQL 客户端连接 Doris 后，可以执行 SHOW PROC 语句查看指定 proc 目录的信息。proc 目录是以 "/" 开头的绝对路径。

show proc 语句的结果以二维表的形式展现。而通常结果表的第一列的值为 proc 的下一级子目录。

```
mysql> show proc "/";
+-----+
| name |
+-----+
| auth |
| backends |
| bdbje |
| brokers |
| catalogs |
| cluster_balance |
| cluster_health |
| colocation_group |
| current_backend_instances |
| current_queries |
| current_query_stmts |
| dbs |
| frontends |
| jobs |
| load_error_hub |
| monitor |
```

```

| resources          |
| routine_loads     |
| statistic          |
| stream_loads       |
| tasks              |
| transactions       |
| trash              |
+-----+
23 rows in set (0.00 sec)

```

说明：

1. auth：用户名称及对应的权限信息
2. backends：显示集群中 BE 的节点列表，等同于 [SHOW BACKENDS](#)
3. bdbje：查看 bdbje 数据库列表，需要修改 fe.conf 文件增加 enable_bdbje_debug_mode=true，然后通过 sh start_fe.sh --daemon 启动 FE 即可进入 debug 模式。进入 debug 模式之后，仅会启动 http server 和 MySQLServer 并打开 BDBJE 实例，但不会进入任何元数据的加载及后续其他启动流程，
4. brokers：查看集群 Broker 节点信息，等同于 [SHOW BROKER](#)
5. catalogs：查看当前已创建的数据目录，等同于 [SHOW CATALOGS](#)
6. cluster_balance：查看集群均衡情况，具体参照 [数据副本管理](#)
7. cluster_health：通过 SHOW PROC '/cluster_health/tablet_health'；命令可以查看整个集群的副本状态。
8. colocation_group：该命令可以查看集群内已存在的 Group 信息，具体可以查看 [Colocation Join](#) 章节
9. current_backend_instances：显示当前正在执行作业的 be 节点列表
10. current_queries：查看正在执行的查询列表，当前正在运行的 SQL 语句。
11. current_query_stmts：返回当前正在执行的 query。
12. dbs：主要用于查看 Doris 集群中各个数据库以及其中的表的元数据信息。这些信息包括表结构、分区、物化视图、数据分片和副本等等。通过这个目录和其子目录，可以清楚的展示集群中的表元数据情况，以及定位一些如数据倾斜、副本故障等问题
13. frontends：显示集群中所有的 FE 节点信息，包括 IP 地址、角色、状态、是否是 mater 等，等同于 [SHOW FRONTENDS](#)
14. jobs：各类任务的统计信息，可查看指定数据库的 Job 的统计信息，如果 dbId = -1, 则返回所有库的汇总信息
15. load_error_hub：Doris 支持将 load 作业产生的错误信息集中存储到一个 error hub 中。然后直接通过 SHOW LOAD WARNINGS；语句查看错误信息。这里展示的就是 error hub 的配置信息。
16. monitor：显示的是 FE JVM 的资源使用情况
17. resources：查看系统资源，普通账户只能看到自己有 USAGE_PRIV 使用权限的资源。只有 root 和 admin 账户可以看到所有的资源。等同于 [SHOW RESOURCES](#)
18. routine_loads：显示所有的 routine load 作业信息，包括作业名称、状态等
19. statistics：主要用于汇总查看 Doris 集群中数据库、表、分区、分片、副本的数量。以及不健康副本的数量。这个信息有助于我们总体把控集群元信息的规模。帮助我们从整体视角查看集群分片情况，能够快速查看集群分片的健康情况。从而进一步定位有问题的数据分片。
20. stream_loads：返回当前正在执行的 stream load 任务。
21. tasks：显示现在各种作业的任务总量，及失败的数量。
22. transactions：用于查看指定 transaction id 的事务详情，等同于 [SHOW TRANSACTION](#)
23. trash：该语句用于查看 backend 内的垃圾数据占用空间。等同于 [SHOW TRASH](#)

举例

1. 如 “/dbs” 展示所有数据库，而 “/dbs/10002” 展示 id 为 10002 的数据库下的所有表

```
mysql> show proc "/dbs/10002";
```

TableId	TableName	IndexNum	PartitionColumnName	PartitionNum	State	Type
LastConsistencyCheckTime	ReplicaCount					
10065	dwd_product_live	1	dt	9	NORMAL	OLAP
NULL	18					
10109	ODS_MR_BILL_COSTS_DO	1	NULL	1	NORMAL	OLAP
NULL	1					
10119	test	1	NULL	1	NORMAL	OLAP
NULL	1					
10124	test_parquet_import	1	NULL	1	NORMAL	OLAP
NULL	1					

4 rows in set (0.00 sec)

2. 展示集群中所有库表个数相关的信息。

```
mysql> show proc '/statistic';
```

DbId	DbName	TableNum	PartitionNum	IndexNum	TabletNum	ReplicaNum
10002	default_cluster:test	4	12	12	21	21
Total	1	4	12	12	21	21

2 rows in set (0.00 sec)

3. 以下命令可以查看集群内已存在的 Group 信息。

```
SHOW PROC '/colocation_group';
```

GroupId	GroupName	TableIds	BucketsNum	ReplicationNum	DistCols	IsStable
10005.10008	10005_group1	10007, 10040	10	3	int(11)	true

- GroupId: 一个 Group 的全集群唯一标识, 前半部分为 db id, 后半部分为 group id。
- GroupName: Group 的全名。
- TabletIds: 该 Group 包含的 Table 的 id 列表。
- BucketsNum: 分桶数。
- ReplicationNum: 副本数。
- DistCols: Distribution columns, 即分桶列类型。
- IsStable: 该 Group 是否稳定 (稳定的定义, 见 Colocation 副本均衡和修复 一节)。

4. 通过以下命令可以进一步查看一个 Group 的数据分布情况:

```
SHOW PROC '/colocation_group/10005.10008';
```

BucketIndex	BackendIds
0	10004, 10002, 10001
1	10003, 10002, 10004

2	10002, 10004, 10001
3	10003, 10002, 10004
4	10002, 10004, 10003
5	10003, 10002, 10001
6	10003, 10004, 10001
7	10003, 10004, 10002
+-----+	

- BucketIndex: 分桶序列的下标。
- BackendIds: 分桶中数据分片所在的 BE 节点 id 列表。

5. 显示现在各种作业的任务总量，及失败的数量。

```
mysql> show proc '/tasks';
```

TaskType	FailedNum	TotalNum
CREATE	0	0
DROP	0	0
PUSH	0	0
CLONE	0	0
STORAGE_MEDIUM_MIGRATE	0	0
ROLLUP	0	0
SCHEMA_CHANGE	0	0
CANCEL_DELETE	0	0
MAKE_SNAPSHOT	0	0
RELEASE_SNAPSHOT	0	0
CHECK_CONSISTENCY	0	0
UPLOAD	0	0
DOWNLOAD	0	0
CLEAR_REMOTE_FILE	0	0
MOVE	0	0
REALTIME_PUSH	0	0
PUBLISH_VERSION	0	0
CLEAR_ALTER_TASK	0	0
CLEAR_TRANSACTION_TASK	0	0
RECOVER_TABLET	0	0
STREAM_LOAD	0	0
UPDATE_TABLET_META_INFO	0	0
ALTER	0	0
INSTALL_PLUGIN	0	0
UNINSTALL_PLUGIN	0	0
Total	0	0

26 rows in set (0.01 sec)

6. 显示整个集群的副本状态。

```
mysql> show proc '/cluster_health/tablet_health';
```

DbId	DbName	TabletNum	HealthyNum	ReplicaMissingNum	VersionIncompleteNum	ReplicaRelocatingNum	RedundantNum	ReplicaMissingInClusterNum	ReplicaMissingForTagNum	ForceRedundantNum	ColocateMismatchNum	ColocateRedundantNum	NeedFurtherRepairNum	UnrecoverableNum	ReplicaCompactionTooSlowNum	InconsistentNum	OversizeNum	CloningNum
------	--------	-----------	------------	-------------------	----------------------	----------------------	--------------	----------------------------	-------------------------	-------------------	---------------------	----------------------	----------------------	------------------	-----------------------------	-----------------	-------------	------------

```

+-----+-----+-----+-----+
| 25852112 | default_cluster:bowen | 1920 | 1920 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 25342914 | default_cluster:bw | 128 | 128 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 2575532 | default_cluster:cps | 1440 | 1440 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 0 | 16 | 0 | 0 | 0 | 0 | 0 |
| 26150325 | default_cluster:db | 38374 | 38374 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 0 | 453 | 0 | 0 | 0 | 0 | 0 |
+-----+-----+-----+-----+
+-----+-----+-----+-----+
+-----+-----+-----+-----+
+-----+-----+-----+-----+
4 rows in set (0.01 sec)

```

查看某个数据库下面的副本状态，如 DbId 为 25852112 的数据库。

```
mysql> show proc '/cluster_health/tablet_health/25852112';
```

Keywords

SHOW, PROC

Best Practice

SHOW-TABLE-STATS

SHOW-TABLE-STATS

Name

SHOW TABLE STATS

描述

通过 SHOW TABLE STATS 查看表的统计信息收集概况。

语法如下：

```
SHOW TABLE STATS table_name;
```

其中：

- table_name: 目标表表名。可以是 db_name.table_name 形式。

输出：

列名	说明
updated_rows	自上次 ANALYZE 以来该表的更新行数
query_times	保留列，后续版本用以记录该表查询次数
row_count	行数（不反映命令执行时的准确行数）
updated_time	上次更新时间
columns	收集过统计信息的列
trigger	触发方式

下面是一个例子：

```
mysql> show table stats lineitem \G;
***** 1. row *****
updated_rows: 0
query_times: 0
row_count: 6001215
updated_time: 2023-11-07
columns: [_returnflag, _receiptdate, _tax, _shipmode, _suppkey, _shipdate, _commitdate,
_partkey, _orderkey, _quantity, _linestatus, _comment, _extendedprice, _linenumber, _discount,
_shipinstruct]
trigger: MANUAL
```

Keywords

SHOW, TABLE, STATS

SHOW-TABLE-STATUS

SHOW-TABLE-STATUS

Name

SHOW TABLE STATUS

描述

该语句用于查看 Table 的一些信息。

语法：

```
SHOW TABLE STATUS  
[FROM db] [LIKE "pattern"]
```

说明：

1. 该语句主要用于兼容 MySQL 语法，目前仅显示 Comment 等少量信息

举例

1. 查看当前数据库下所有表的信息

```
SHOW TABLE STATUS;
```

2. 查看指定数据库下，名称包含 example 的表的信息

```
SHOW TABLE STATUS FROM db LIKE "%example%";
```

Keywords

```
SHOW, TABLE, STATUS
```

Best Practice

SHOW-REPOSITORIES

SHOW-REPOSITORIES

Name

SHOW REPOSITORIES

描述

该语句用于查看当前已创建的仓库

语法：

```
SHOW REPOSITORIES;
```

说明：

- 1. 各列含义如下： Repold： 唯一的仓库ID RepoName： 仓库名称 CreateTime： 第一次创建该仓库的时间
IsReadOnly： 是否为只读仓库 Location： 仓库中用于备份数据的根目录 Broker： 依赖的 Broker
ErrMsg： Doris 会定期检查仓库的连通性，如果出现问题，这里会显示错误信息

举例

- 1. 查看已创建的仓库：

```
SHOW REPOSITORIES;
```

Keywords

```
SHOW, REPOSITORIES
```

Best Practice

SHOW-QUERY-PROFILE

SHOW-QUERY-PROFILE

Name

SHOW QUERY PROFILE

描述

该语句是用来查看QUERY操作的树状Profile信息，该功能需要用户打开 Profile 设置，0.15 之前版本执行下面的设置：

```
SET is_report_success=true;
```

0.15 及之后的版本执行下面的设置：

```
SET [GLOBAL] enable_profile=true;
```

语法：

```
show query profile "/";
```

这个命令会列出当前保存的所有query操作的 Profile 。

```
show query profile "/queryId"\G;  
show query profile "/queryId/fragment_id/instance_id";
```

获取指定query id树状profile信息,返回profile 简易树形图。指定fragment_id和instance_id则返回对应的详细profile树形图。

举例

1. 列出所有的 query Profile

```
mysql> show query profile "/";  
+-----+-----+-----+-----+-----+-----+  
+-----+-----+-----+-----+-----+-----+  
| QueryId          | User | DefaultDb          | SQL          | QueryType  
| StartTime        | EndTime        | TotalTime | QueryState |  
+-----+-----+-----+-----+-----+-----+  
+-----+-----+-----+-----+-----+-----+  
| 327167e0db4749a9-adce3b3d770b2bb1 | root | default_cluster:test_db | select * from test | Query  
| 2022-08-09 10:50:09 | 2022-08-09 10:50:09 | 19ms      | EOF        |  
+-----+-----+-----+-----+-----+-----+  
1 row in set (0.00 sec)
```

2. 列出指定QueryId的 query Profile

```
mysql> show query profile "/327167e0db4749a9-adce3b3d770b2bb1"\G
***** 1. row *****
Fragments: [
  [-1: VDataBufferSender]
  |
  | Fragment: 0
  | MaxActiveTime: 783.263us
  |
  |
  | [1: VEXCHANGE_NODE]
  |
  | Fragment: 0
  |
  |
  | [1: VDataStreamSender]
  |
  | Fragment: 1
  | MaxActiveTime: 847.612us
  |
  |
  | [0: VOLAP_SCAN_NODE]
  |
  | Fragment: 1
  |
  |
  | [0lapScanner]
  |
  | Fragment: 1
  |
  |
  | [SegmentIterator]
  |
  | Fragment: 1
  |
]
1 row in set (0.00 sec)
```

3. 列出指定 Fragment 的 Instance 概况

```
mysql> show query profile "/327167e0db4749a9-adce3b3d770b2bb1/1"\G
***** 1. row *****
Instances: 327167e0db4749a9-adce3b3d770b2bb2
Host: 172.26.0.1:9111
ActiveTime: 847.612us
1 row in set (0.01 sec)
```

4. 继续查看某一个具体的 Instance 上各个算子的详细 Profile

```
mysql> show query profile "/327167e0db4749a9-adce3b3d770b2bb1/1/327167e0db4749a9-adce3b3d770b2bb2"\G
***** 1. row *****
Instance: [
  [1: VDataStreamSender]
  |
  | (Active: 36.944us, non-child: 0.20)
  |
  | - Counters:
  |   - BytesSent: 0.00
  |   - IgnoreRows: 0
  |
]
```

```
- LocalBytesSent: 20.00 B
- OverallThroughput: 0.0 /sec
- PeakMemoryUsage: 0.00
- SerializeBatchTime: 0ns
- UncompressedRowBatchSize: 0.00
```

```
[0: VOLAP_SCAN_NODE]
(Active: 563.241us, non-child: 3.00)
- Counters:
  - BatchQueueWaitTime: 444.714us
  - BytesRead: 37.00 B
  - NumDiskAccess: 1
  - NumScanners: 2
  - PeakMemoryUsage: 320.00 KB
  - RowsRead: 4
  - RowsReturned: 4
  - RowsReturnedRate: 7.101K /sec
  - ScannerBatchWaitTime: 206.40us
  - ScannerSchedCount : 2
  - ScannerWorkerWaitTime: 34.640us
  - TabletCount : 2
  - TotalReadThroughput: 0.0 /sec
```

```
[OlapScanner]
(Active: 0ns, non-child: 0.00)
- Counters:
  - BlockConvertTime: 0ns
  - BlockFetchTime: 183.741us
  - ReaderInitTime: 180.741us
  - RowsDelFiltered: 0
  - RowsPushedCondFiltered: 0
  - ScanCpuTime: 388.576us
  - ScanTime: 0ns
  - ShowHintsTime_V1: 0ns
```

```
[SegmentIterator]
(Active: 0ns, non-child: 0.00)
- Counters:
  - BitmapIndexFilterTimer: 124ns
  - BlockLoadTime: 179.202us
  - BlockSeekCount: 5
  - BlockSeekTime: 18.792us
  - BlocksLoad: 4
  - CachedPagesNum: 2
  - CompressedBytesRead: 0.00
  - DecompressorTimer: 0ns
  - IOTimer: 0ns
  - IndexLoadTime_V1: 0ns
  - NumSegmentFiltered: 0
  - NumSegmentTotal: 2
  - RawRowsRead: 4
  - RowsBitmapIndexFiltered: 0
  - RowsBloomFilterFiltered: 0
  - RowsConditionsFiltered: 0
  - RowsKeyRangeFiltered: 0
  - RowsStatsFiltered: 0
```

```
- RowsVectorPredFiltered: 0
- TotalPagesNum: 2
- UncompressedBytesRead: 0.00
- VectorPredEvalTime: 0ns
```

1 row in set (0.01 sec)

Keywords

SHOW, QUERY, PROFILE

Best Practice

SHOW-OPEN-TABLES

SHOW-OPEN-TABLES

Name

SHOW TABLES

描述

该语句用于展示当前 db 下所有的 table

语法：

```
SHOW TABLES
```

举例

Keywords

```
SHOW, OPEN, TABLES
```

Best Practice

SHOW-TABLETS

SHOW-TABLETS

Name

SHOW TABLETS

描述

该语句用于列出指定table的所有tablets（仅管理员使用）

语法：

```
SHOW TABLETS FROM [database.]table [PARTITIONS(p1,p2)]  
[WHERE where_condition]  
[ORDER BY col_name]  
[LIMIT [offset,] row_count]
```

1. Syntax Description:

where_condition 可以为下列条件之一：

```
Version = version  
state = "NORMAL|ROLLUP|CLONE|DECOMMISSION"  
BackendId = backend_id  
IndexName = rollup_name
```

或者通过AND组合的复合条件.

举例

1. 列出指定table所有的tablets

```
SHOW TABLETS FROM example_db.table_name;
```

2. 列出指定partitions的所有tablets

```
SHOW TABLETS FROM example_db.table_name PARTITIONS(p1, p2);
```

3. 列出某个backend上状态为DECOMMISSION的tablets

```
SHOW TABLETS FROM example_db.table_name WHERE state="DECOMMISSION" AND BackendId=11003;
```


Keywords

SHOW, TABLETS

Best Practice

SHOW-LOAD

SHOW-LOAD

Name

SHOW LOAD

描述

该语句用于展示指定的导入任务的执行情况

语法：

```
SHOW LOAD
[FROM db_name]
[
  WHERE
    [LABEL [ = "your_label" | LIKE "label_matcher"]]
    [STATE = ["PENDING"|"ETL"|"LOADING"|"FINISHED"|"CANCELLED"]]
]
[ORDER BY ...]
[LIMIT limit][OFFSET offset];
```

说明：

1. 如果不指定 db_name，使用当前默认db
2. 如果使用 LABEL LIKE，则会匹配导入任务的 label 包含 label_matcher 的导入任务
3. 如果使用 LABEL = ，则精确匹配指定的 label
4. 如果指定了 STATE，则匹配 LOAD 状态
5. 可以使用 ORDER BY 对任意列组合进行排序
6. 如果指定了 LIMIT，则显示 limit 条匹配记录。否则全部显示
7. 如果指定了 OFFSET，则从偏移量offset开始显示查询结果。默认情况下偏移量为0。
8. 如果是使用 broker/mini load，则 URL 列中的连接可以使用以下命令查看：

```
SHOW LOAD WARNINGS ON 'url'
```

举例

1. 展示默认 db 的所有导入任务

```
SHOW LOAD;
```

2. 展示指定 db 的导入任务，label 中包含字符串“2014_01_02”，展示最老的10个

```
SHOW LOAD FROM example_db WHERE LABEL LIKE "2014_01_02" LIMIT 10;
```

3. 展示指定 db 的导入任务，指定 label 为“load_example_db_20140102”并按 LoadStartTime 降序排序

```
SHOW LOAD FROM example_db WHERE LABEL = "load_example_db_20140102" ORDER BY LoadStartTime DESC;
```

4. 展示指定 db 的导入任务，指定 label 为“load_example_db_20140102”，state 为“loading”，并按 LoadStartTime 降序排序

```
SHOW LOAD FROM example_db WHERE LABEL = "load_example_db_20140102" AND STATE = "loading" ORDER BY LoadStartTime DESC;
```

5. 展示指定 db 的导入任务 并按 LoadStartTime 降序排序,并从偏移量5开始显示10条查询结果

```
SHOW LOAD FROM example_db ORDER BY LoadStartTime DESC limit 5,10;  
SHOW LOAD FROM example_db ORDER BY LoadStartTime DESC limit 10 offset 5;
```

6. 小批量导入是查看导入状态的命令

```
curl --location-trusted -u {user}:{passwd} http://{hostname}:{port}/api/{database}/_load_info?label={labelname}
```

Keywords

SHOW, LOAD

Best Practice

SHOW-TABLES

SHOW-TABLES

Name

SHOW TABLES

描述

该语句用于展示当前 db 下所有的 table

语法：

```
SHOW [FULL] TABLES [LIKE]
```

说明：

1. LIKE：可按照表名进行模糊查询

举例

1. 查看DB下所有表

```
mysql> show tables;
+-----+
| Tables_in_demo |
+-----+
| ads_client_biz_aggr_di_20220419 |
| cmy1 |
| cmy2 |
| intern_theme |
| left_table |
+-----+
5 rows in set (0.00 sec)
```

2. 按照表名进行模糊查询

```
mysql> show tables like '%cm%';
+-----+
| Tables_in_demo |
+-----+
| cmy1 |
| cmy2 |
+-----+
2 rows in set (0.00 sec)
```

Keywords

SHOW, TABLES

Best Practice

SHOW-RESOURCES

SHOW-RESOURCES

Name

SHOW RESOURCES

描述

该语句用于展示用户有使用权限的资源。普通用户仅能展示有使用权限的资源，root 或 admin 用户会展示所有的资源。

语法：

```
SHOW RESOURCES
[
  WHERE
    [NAME [= "your_resource_name" | LIKE "name_matcher"]]
    [RESOURCETYPE = ["SPARK"]]
]
[ORDER BY ...]
[LIMIT limit][OFFSET offset];
```

说明：

1. 如果使用 NAME LIKE，则会匹配 RESOURCES 的 Name 包含 name_matcher 的Resource
2. 如果使用 NAME =，则精确匹配指定的 Name
3. 如果指定了 RESOURCETYPE，则匹配对应的 Resource 类型
4. 可以使用 ORDER BY 对任意列组合进行排序
5. 如果指定了 LIMIT，则显示 limit 条匹配记录。否则全部显示
6. 如果指定了 OFFSET，则从偏移量 offset 开始显示查询结果。默认情况下偏移量为0。

举例

1. 展示当前用户拥有权限的所有 Resource

```
SHOW RESOURCES;
```

2. 展示指定 Resource，NAME 中包含字符串“20140102”，展示10个属性

```
SHOW RESOURCES WHERE NAME LIKE "2014_01_02" LIMIT 10;
```

3. 展示指定 Resource，指定 NAME 为“20140102”并按 KEY 降序排序

```
SHOW RESOURCES WHERE NAME = "20140102" ORDER BY `KEY` DESC;
```

Keywords

SHOW, RESOURCES

Best Practice

SHOW-WORKLOAD-GROUPS

SHOW-WORKLOAD-GROUPS

Name

SHOW WORKLOAD GROUPS

描述

该语句用于展示当前用户具有usage_priv权限的资源组。

语法：

```
SHOW WORKLOAD GROUPS;
```

说明：

该语句仅做资源组简单展示，更复杂的展示可参考 tvf workload_groups().

举例

- 1. 展示所有资源组：

```
mysql> show workload groups;
+-----+-----+-----+-----+
| Id      | Name  | Item                      | Value  |
+-----+-----+-----+-----+
| 10343386 | normal | cpu_share                 | 10     |
| 10343386 | normal | memory_limit              | 30%    |
| 10343386 | normal | enable_memory_overcommit | true   |
| 10352416 | g1     | memory_limit              | 20%    |
| 10352416 | g1     | cpu_share                 | 10     |
+-----+-----+-----+-----+
```

Keywords

```
SHOW, WORKLOAD, GROUPS, GROUP
```

Best Practice

SHOW-PARTITIONS

SHOW-PARTITIONS

Name

SHOW PARTITIONS

描述

该语句用于展示分区信息。支持 Internal catalog 和 Hive Catalog

语法：

```
SHOW [TEMPORARY] PARTITIONS FROM [db_name.]table_name [WHERE] [ORDER BY] [LIMIT];
```

说明：

对于 Internal catalog： 1. 支持

PartitionId,PartitionName,State,Buckets,ReplicationNum,LastConsistencyCheckTime 等列的过滤 2.

TEMPORARY 指定列出临时分区

需要注意的是： 1. 目前 where子句等操作符。对字符型的 PartitionName, State 只支持=、!=、like 操作符。对其余的只支持 =、!=、>、<、>=、<= 操作符。 2. where子句使用上面的操作符时，列名需要在左侧。 3. where子句可以包含AND。

对于 Hive Catalog： 支持返回所有分区，包括多级分区

举例

1. 展示指定 db 下指定表的所有非临时分区信息

```
SHOW PARTITIONS FROM example_db.table_name;
```

2. 展示指定 db 下指定表的所有临时分区信

```
SHOW TEMPORARY PARTITIONS FROM example_db.table_name;
```

3. 展示指定 db 下指定表的指定非临时分区的信息

```
SHOW PARTITIONS FROM example_db.table_name WHERE PartitionName = "p1";
```

4. 展示指定 db 下指定表的最新非临时分区的信息

```
SHOW PARTITIONS FROM example_db.table_name ORDER BY PartitionId DESC LIMIT 1;
```

Keywords

SHOW, PARTITIONS

Best Practice

SHOW-FRONTENDS

SHOW-FRONTENDS

Name

SHOW FRONTENDS

描述

该语句用于查看 FE 节点

语法：

```
SHOW FRONTENDS;
```

说明： 1. name 表示该 FE 节点在 bdbje 中的名称。 2. Join 为 true 表示该节点曾经加入过集群。但不代表当前还在集群内（可能已失联） 3. Alive 表示节点是否存活。 4. ReplayedJournalId 表示该节点当前已经回放的最大元数据日志id。
5. LastHeartbeat 是最近一次心跳。 6. IsHelper 表示该节点是否是 bdbje 中的 helper 节点。 7. ErrMsg 用于显示心跳失败时的错误信息。 8. CurrentConnected 表示是否是当前连接的FE节点

举例

Keywords

```
SHOW, FRONTENDS
```

Best Practice

SHOW FRONTENDS DISKS

描述

该语句用于查看 FE 节点的重要目录如：元数据、日志、审计日志、临时目录对应的磁盘信息

语法

```
SHOW FRONTENDS DISKS;
```

返回值

列名	说明
Name	该 FE 节点在 bdbje 中的名称
Host	该 FE 节点的 IP
DirType	要展示的目录类型，分别有四种类型：meta、log、audit-log、temp、deploy
Dir	要展示的目录类型的目录
FileSystem	要展示的目录类型所在的 linux 系统的文件系统
Capacity	文件系统的容量
Used	文件系统已用大小
Available	文件系统剩余容量
UseRate	文件系统使用容量占比
MountOn	文件系统挂载目录

权限控制

执行此 SQL 命令的用户必须至少具有以下权限：

权限	对象	说明
ADMIN_PRIV 或 NODE_PRIV		

注意事项

如果需要对查询结果进行进一步的过滤，可以使用表值函数[frontends_disks\(\)](#)。SHOW FRONTENDS DISKS 与下面语句等价：

```
SELECT * FROM FRONTENDS_DISKS();
```

示例

SHOW FRONTENDS DISKS;

Name							Host	DirType	Dir
Filesystem	Capacity	Used	Available	UseRate	MountOn				
fe_a1daac68_5ec0_477c_b5e8_f90a33cdc1bb	7T	2T	4T	36%	/home/disk		10.xx.xx.90	meta	/home/disk/output/fe/doris-meta
/dev/sdf1									
fe_a1daac68_5ec0_477c_b5e8_f90a33cdc1bb	7T	2T	4T	36%	/home/disk		10.xx.xx.90	log	/home/disk/output/fe/log
/dev/sdf1									
fe_a1daac68_5ec0_477c_b5e8_f90a33cdc1bb	7T	2T	4T	36%	/home/disk		10.xx.xx.90	audit-log	/home/disk/output/fe/log
/dev/sdf1									
fe_a1daac68_5ec0_477c_b5e8_f90a33cdc1bb	7T	2T	4T	36%	/home/disk		10.xx.xx.90	temp	/home/disk/output/fe/temp_dir
/dev/sdf1									
fe_a1daac68_5ec0_477c_b5e8_f90a33cdc1bb	7T	2T	4T	36%	/home/disk		10.xx.xx.90	deploy	/home/disk/output/fe
/dev/sdf1									

SHOW-RESTORE

SHOW-RESTORE

Name

SHOW RESTORE

描述

该语句用于查看 RESTORE 任务

语法：

```
SHOW [BRIEF] RESTORE [FROM DB_NAME]
```

说明： 1. Doris 中仅保存最近一次 RESTORE 任务。 2. 各列含义如下： JobId：唯一作业 id Label：要恢复的备份的名称 Timestamp：要恢复的备份的时间版本 DbName：所属数据库 State：当前阶段 PENDING：提交作业后的初始状态 SNAPSHOTING：执行快照中 DOWNLOAD：快照完成，准备下载仓库中的快照 DOWNLOADING：快照下载中 COMMIT：快照下载完成，准备生效 COMMITTING：生效中 FINISHED：作业成功 CANCELLED：作业失败 AllowLoad：恢复时是否允许导入（当前不支持） ReplicationNum：指定恢复的副本数 RestoreJobs：要恢复的表和分区 CreateTime：任务提交时间 MetaPreparedTime：元数据准备完成时间 SnapshotFinishedTime：快照完成时间 DownloadFinishedTime：快照下载完成时间 FinishedTime：作业结束时间 UnfinishedTasks：在 SNAPSHOTING、DOWNLOADING 和 COMMITTING 阶段会显示还未完成的子任务 id Status：如果作业失败，显示失败信息 Timeout：作业超时时间，单位秒

2. brief：仅返回精简格式的 RESTORE 任务信息，不包含 RestoreObjs, Progress, TaskErrMsg 三列

举例

1. 查看 example_db 下最近一次 RESTORE 任务。

```
SHOW RESTORE FROM example_db;
```

Keywords

SHOW, RESTORE

Best Practice

SHOW-PROPERTY

SHOW-PROPERTY

Name

SHOW PROPERTY

描述

该语句用于查看用户的属性

语法：

```
SHOW PROPERTY [FOR user] [LIKE key]
SHOW ALL PROPERTIES [LIKE key]
```

- user
查看指定用户的属性。如果未指定，请检查当前用户的。
- LIKE
模糊匹配可以通过属性名来完成。
- ALL
查看所有用户的属性(从2.0.3版本开始支持)

返回结果说明：

```
mysql> show property like '%connection%';
+-----+-----+
| Key           | Value |
+-----+-----+
| max_user_connections | 100   |
+-----+-----+
1 row in set (0.01 sec)
```

- Key
属性名.
- Value
属性值.

```
mysql> show all properties like "%connection%";
+-----+-----+
| User           | Properties |
+-----+-----+
```

+-----+-----+		
root	{"max_user_connections": "100"}	
admin	{"max_user_connections": "100"}	
default_cluster:a	{"max_user_connections": "1000"}	
+-----+-----+		

- User

用户名.

- Properties

对应用户各个property的key:value.

举例

1. 查看 jack 用户的属性

```
SHOW PROPERTY FOR 'jack'
```

2. 查看 jack 用户导入cluster相关属性

```
SHOW PROPERTY FOR 'jack' LIKE '%load_cluster%'
```

3. 查看所有用户导入cluster相关属性

```
SHOW ALL PROPERTIES LIKE '%load_cluster%'
```

Keywords

```
SHOW, PROPERTY, ALL
```

Best Practice

SHOW-TRIGGERS

SHOW-TRIGGERS

描述

举例

Keywords

SHOW, TRIGGERS

Best Practice

SHOW-PROCESSLIST

SHOW-PROCESSLIST

Name

SHOW PROCESSLIST

描述

显示用户正在运行的线程，需要注意的是，除了 root 用户能看到所有正在运行的线程外，其他用户都只能看到自己正在运行的线程，看不到其它用户正在运行的线程

语法：

```
SHOW [FULL] PROCESSLIST
```

说明：

- CurrentConnected: 是否为当前连接。
- Id: 就是这个线程的唯一标识，当我们发现这个线程有问题的时候，可以通过 kill 命令，加上这个Id值将这个线程杀掉。前面我们说了show processlist 显示的信息时来自information_schema.processlist 表，所以这个Id就是这个表的主键。
- User: 就是指启动这个线程的用户。
- Host: 记录了发送请求的客户端的 IP 和 端口号。通过这些信息在排查问题的时候，我们可以定位到是哪个客户端的哪个进程发送的请求。
- LoginTime: 建立连接的时间。
- Catalog: 当前执行的命令是在哪一个数据目录上。
- Db: 当前执行的命令是在哪一个数据库上。如果没有指定数据库，则该值为 NULL 。
- Command: 是指此刻该线程正在执行的命令。
- Time: 上一条命令提交到当前状态的时间，单位为秒。
- State: 线程的状态，和 Command 对应。
- QueryId: 当前查询语句的ID。
- Info: 一般记录的是线程执行的语句。默认只显示前100个字符，也就是你看到的语句可能是截断了的，要看全部信息，需要使用 show full processlist。

常见的 Command 类型如下：

- Query: 该线程正在执行一个语句
- Sleep: 正在等待客户端向它发送执行语句
- Quit: 该线程正在退出
- Kill : 正在执行 kill 语句，杀死指定线程

其他类型可以参考 [MySQL 官网解释](#)

举例

- 1. 查看当前用户正在运行的线程

```
SHOW PROCESSLIST
```

返回结果

```
MySQL [test]> show full processlist;
+-----+-----+-----+-----+-----+-----+-----+-----+
+-----+-----+-----+-----+-----+-----+-----+-----+
| CurrentConnected | Id   | User | Host           | LoginTime           | Catalog | Db   | Command |
Time | State | QueryId           | Info           |
+-----+-----+-----+-----+-----+-----+-----+-----+
+-----+-----+-----+-----+-----+-----+-----+-----+
| Yes              | 0   | root | 127.0.0.1:34650 | 2023-09-06 12:01:02 | internal | test | Query   |
0 | OK    | c84e397193a54fe7-bbe9bc219318b75e | select 1          |
|                  | 1   | root | 127.0.0.1:34776 | 2023-09-06 12:01:07 | internal |      | Sleep   |
29 | EOF   | 886ffe2894314f50-8dd73a6ca06699e4 | show full processlist |
+-----+-----+-----+-----+-----+-----+-----+-----+
+-----+-----+-----+-----+-----+-----+-----+-----+
```

Keywords

```
SHOW, PROCESSLIST
```

Best Practice

SHOW TRASH

描述

该语句用于查看 backend 内的垃圾数据占用空间。

语法：

```
SHOW TRASH [ON ("<be_host>:<be_heartbeat_port>" [, ...])];
```

可选参数

- 1. [ON ("<be_host>:<be_heartbeat_port>" [, ...])]

指定需要查看的 backend。如果不加 ON，默认查看所有 backend。

权限控制

执行此 SQL 命令的用户必须至少具有以下权限：

权限 (Privilege)	对象 (Object)	说明 (Notes)
ADMIN_PRIV 或 NODE_PRIV	用户 (User) 或 角色 (Role)	用户或者角色拥有 ADMIN_PRIV 或 NODE_PRIV 权限才能进行SHOW TRASH操作

示例

- 1. 查看所有 be 节点的垃圾数据占用空间。

```
SHOW TRASH;
```

- 2. 查看'192.168.0.1:9050'的垃圾数据占用空间 (会显示具体磁盘信息)。

```
SHOW TRASH ON "192.168.0.1:9050";
```

SHOW-VIEW

SHOW-VIEW

Name

SHOW VIEW

描述

该语句用于展示基于给定表建立的所有视图

语法：

```
SHOW VIEW { FROM | IN } table [ FROM db ]
```

举例

1. 展示基于表 testTbl 建立的所有视图 view

```
SHOW VIEW FROM testTbl;
```

Keywords

```
SHOW, VIEW
```

Best Practice

SHOW-TRANSACTION

SHOW-TRANSACTION

Name

SHOW TRANSACTION

描述

该语法用于查看指定 transaction id 或 label 的事务详情。

语法：

```
SHOW TRANSACTION
[FROM db_name]
WHERE
[id = transaction_id]
[label = label_name];
```

返回结果示例：

```
TransactionId: 4005
      Label: insert_8d807d5d-bcdd-46eb-be6d-3fa87aa4952d
Coordinator: FE: 10.74.167.16
TransactionStatus: VISIBLE
LoadJobSourceType: INSERT_STREAMING
      PrepareTime: 2020-01-09 14:59:07
      CommitTime: 2020-01-09 14:59:09
      FinishTime: 2020-01-09 14:59:09
      Reason:
ErrorReplicasCount: 0
      ListenerId: -1
      TimeoutMs: 300000
```

- TransactionId: 事务id
- Label: 导入任务对应的 label
- Coordinator: 负责事务协调的节点
- TransactionStatus: 事务状态
 - PREPARE: 准备阶段
 - COMMITTED: 事务成功，但数据不可见
 - VISIBLE: 事务成功且数据可见
 - ABORTED: 事务失败
- LoadJobSourceType: 导入任务的类型。
- PrepareTime: 事务开始时间
- CommitTime: 事务提交成功的时间
- FinishTime: 数据可见的时间
- Reason: 错误信息
- ErrorReplicasCount: 有错误的副本数

- ListenerId: 相关的导入作业的id
- TimeoutMs: 事务超时时间, 单位毫秒

举例

1. 查看 id 为 4005 的事务:

```
SHOW TRANSACTION WHERE ID=4005;
```

2. 指定 db 中, 查看 id 为 4005 的事务:

```
SHOW TRANSACTION FROM db WHERE ID=4005;
```

3. 查看 label 为 label_name的事务:

```
SHOW TRANSACTION WHERE LABEL = 'label_name';
```

Keywords

```
SHOW, TRANSACTION
```

Best Practice

SHOW-STREAM-LOAD

SHOW-STREAM-LOAD

Name

SHOW STREAM LOAD

描述

该语句用于展示指定的Stream Load任务的执行情况

语法：

```
SHOW STREAM LOAD
[FROM db_name]
[
  WHERE
    [LABEL [= "your_label" | LIKE "label_matcher"]]
    [STATUS = ["SUCCESS"|"FAIL"]]
]
[ORDER BY ...]
[LIMIT limit][OFFSET offset];
```

说明：

1. 默认 BE 是不记录 Stream Load 的记录，如果你要查看需要在 BE 上启用记录，配置参数是：
enable_stream_load_record=true，具体怎么配置请参照 [BE 配置项](#)
2. 如果不指定 db_name，使用当前默认db
3. 如果使用 LABEL LIKE，则会匹配Stream Load任务的 label 包含 label_matcher 的任务
4. 如果使用 LABEL =，则精确匹配指定的 label
5. 如果指定了 STATUS，则匹配 STREAM LOAD 状态
6. 可以使用 ORDER BY 对任意列组合进行排序
7. 如果指定了 LIMIT，则显示 limit 条匹配记录。否则全部显示
8. 如果指定了 OFFSET，则从偏移量offset开始显示查询结果。默认情况下偏移量为0。

举例

1. 展示默认 db 的所有Stream Load任务

```
SHOW STREAM LOAD;
```

2. 展示指定 db 的Stream Load任务，label 中包含字符串“2014_01_02”，展示最老的10个


```
SHOW STREAM LOAD FROM example_db WHERE LABEL LIKE "2014_01_02" LIMIT 10;
```

3. 展示指定 db 的Stream Load任务, 指定 label 为 “load_example_db_20140102”

```
SHOW STREAM LOAD FROM example_db WHERE LABEL = "load_example_db_20140102";
```

4. 展示指定 db 的Stream Load任务, 指定 status 为 “success”, 并按 StartTime 降序排序

```
SHOW STREAM LOAD FROM example_db WHERE STATUS = "success" ORDER BY StartTime DESC;
```

5. 展示指定 db 的导入任务 并按 StartTime 降序排序,并从偏移量5开始显示10条查询结果

```
SHOW STREAM LOAD FROM example_db ORDER BY StartTime DESC limit 5,10;  
SHOW STREAM LOAD FROM example_db ORDER BY StartTime DESC limit 10 offset 5;
```

Keywords

SHOW, STREAM, LOAD

Best Practice

SHOW-STATUS

SHOW-STATUS

Name

SHOW STATUS

描述

该命令用于查看通过[创建物化视图](#)语句提交的创建物化视图作业的执行情况。

该语句相当于SHOW ALTER TABLE ROLLUP;

```
SHOW ALTER TABLE MATERIALIZED VIEW
[FROM database]
[WHERE]
[ORDER BY]
[LIMIT OFFSET]
```

- database：查看指定数据库下的作业。如果未指定，则使用当前数据库。
- WHERE：您可以过滤结果列，目前仅支持以下列：
 - TableName：仅支持等值过滤。
 - State：仅支持等效过滤。
 - Createtime/FinishTime：支持 =、>=、<=、>、<、!=
- ORDER BY：结果集可以按任何列排序。
- LIMIT：使用 ORDER BY 进行翻页查询。

Return result description:

```
mysql> show alter table materialized view\G
***** 1. row *****
      JobId: 11001
      TableName: tbl1
      CreateTime: 2020-12-23 10:41:00
      FinishTime: NULL
      BaseIndexName: tbl1
      RollupIndexName: r1
      RollupId: 11002
      TransactionId: 5070
      State: WAITING_TXN
      Msg:
      Progress: NULL
      Timeout: 86400
1 row in set (0.00 sec)
```

- JobId：作业唯一 ID。

- **TableName**: 基表名称
- **CreateTime/FinishTime**: 作业创建时间和结束时间。
- **BaseIndexName/RollupIndexName**: 基表名称和物化视图名称。
- **RollupId**: 物化视图的唯一 ID。
- **TransactionId**: 参见**State**字段的描述。
- **State**: 工作状态。
 - **PENDING**: 工作正在准备中。
 - **WAITING_TXN**:
在正式开始生成物化视图数据之前，它会等待当前正在运行的该表上的导入事务完成。而 **TransactionId** 字段是当前等待的交易 ID。当此 ID 的所有先前导入完成后，作业将真正开始。
 - **RUNNING**: 作业正在运行。
 - **FINISHED**: 作业成功运行。
 - **CANCELLED**: 作业运行失败。
- **Msg**: 错误信息
- **Progress**: 作业进度。这里的进度是指 `completed tablets/total tablets`。物化视图以 **tablet** 粒度创建。
- **Timeout**: 作业超时，以秒为单位。

举例

Keywords

SHOW, STATUS

Best Practice

SHOW-TABLE-ID

SHOW-TABLE-ID

Name

SHOW TABLE ID

描述

该语句用于根据 table id 查找对应的 database name, table name（仅管理员使用）

语法：

```
SHOW TABLE [table_id]
```

举例

1. 根据 table id 查找对应的 database name, table name

```
SHOW TABLE 10001;
```

Keywords

```
SHOW, TABLE, ID
```

Best Practice

SHOW-SMALL-FILES

SHOW-SMALL-FILES

Name

SHOW FILE

描述

该语句用于展示一个数据库内，由 CREATE FILE 命令创建的文件。

```
SHOW FILE [FROM database];
```

返回结果说明：

- FileId: 文件ID，全局唯一
- DbName: 所属数据库名称
- Catalog: 自定义分类
- FileName: 文件名
- FileSize: 文件大小，单位字节
- MD5: 文件的 MD5

举例

1. 查看数据库 my_database 中已上传的文件

```
SHOW FILE FROM my_database;
```

Keywords

```
SHOW, SMALL, FILES
```

Best Practice

SHOW-POLICY

SHOW-POLICY

Name

SHOW ROW POLICY

描述

查看当前 DB 下的行安全策略

语法：

```
SHOW ROW POLICY [FOR user| ROLE role]
```

举例

- 1. 查看所有安全策略。

```
mysql> SHOW ROW POLICY;
+-----+-----+-----+-----+-----+-----+-----+
| PolicyName | DbName | TableName | Type | FilterType | WherePredicate | User |
+-----+-----+-----+-----+-----+-----+-----+
| test_row_policy_1 | default_cluster:test | table1 | ROW | RESTRICTIVE | `id` IN (1, 2) | root |
/* ApplicationName=DataGrip 2021.3.4 */ CREATE ROW POLICY test_row_policy_1 ON test.table1 AS
RESTRICTIVE TO root USING (id in (1, 2));
| test_row_policy_2 | default_cluster:test | table1 | ROW | RESTRICTIVE | `col1` = 'col1_1' | root |
/* ApplicationName=DataGrip 2021.3.4 */ CREATE ROW POLICY test_row_policy_2 ON test.table1 AS
RESTRICTIVE TO root USING (col1='col1_1');
+-----+-----+-----+-----+-----+-----+-----+
2 rows in set (0.00 sec)
```

- 2. 指定用户名查询

```
mysql> SHOW ROW POLICY FOR test;
+-----+-----+-----+-----+-----+-----+-----+
| PolicyName | DbName | TableName | Type | FilterType | WherePredicate | User |
+-----+-----+-----+-----+-----+-----+-----+
| test_row_policy_1 | default_cluster:test | table1 | ROW | RESTRICTIVE | `id` IN (1, 2) | root |
/* ApplicationName=DataGrip 2021.3.4 */ CREATE ROW POLICY test_row_policy_1 ON test.table1 AS
RESTRICTIVE TO root USING (id in (1, 2));
| test_row_policy_2 | default_cluster:test | table1 | ROW | RESTRICTIVE | `col1` = 'col1_1' | root |
/* ApplicationName=DataGrip 2021.3.4 */ CREATE ROW POLICY test_row_policy_2 ON test.table1 AS
RESTRICTIVE TO root USING (col1='col1_1');
+-----+-----+-----+-----+-----+-----+-----+
2 rows in set (0.00 sec)
```

```

| test_row_policy_3 | default_cluster:test | table1 | ROW | PERMISSIVE | `col1` = 'col1_2' |
default_cluster:test | /* ApplicationName=DataGrip 2021.3.4 */ CREATE ROW POLICY test_row_policy_3 ON
test.table1 AS PERMISSIVE TO test USING (col1='col1_2');

```

Best Practice

SHOW-STORAGE-POLICY-USING

SHOW-STORAGE-POLICY-USING

Name

SHOW STORAGE POLICY USING

描述

查看所有/指定存储策略关联的表和分区

语法：

```
SHOW STORAGE POLICY USING [FOR some_policy]
```

举例

- 1. 查看所有启用了存储策略的对象

```
mysql> show storage policy using;
+-----+-----+-----+
| PolicyName      | Database              | Table                                     |
| Partitions      |                        |                                           |
+-----+-----+-----+
| test_storage_policy | regression_test_cold_heat_separation_p2 | table_with_storage_policy_1 |
| ALL              |                                           |                               |
| test_storage_policy | regression_test_cold_heat_separation_p2 | partition_with_multiple_storage_policy |
| p201701          |                                           |                               |
| test_storage_policy_2 | regression_test_cold_heat_separation_p2 | partition_with_multiple_storage_policy |
| p201702          |                                           |                               |
| test_storage_policy_2 | regression_test_cold_heat_separation_p2 | table_with_storage_policy_2 |
| ALL              |                                           |                               |
| test_policy        | db2                    | db2_test_1                             |
| ALL              |                                           |                               |
+-----+-----+-----+
```

- 2. 查看使用存储策略test_storage_policy的对象

```
mysql> show storage policy using for test_storage_policy;
+-----+-----+-----+-----+
| PolicyName      | Database | Table                                     | Partitions |
+-----+-----+-----+-----+
| test_storage_policy | db_1     | partition_with_storage_policy_1 | p201701    |
| test_storage_policy | db_1     | table_with_storage_policy_1     | ALL        |
+-----+-----+-----+-----+
```

Keywords

SHOW, STORAGE, POLICY, USING

Best Practice

SHOW-CATALOG-RECYCLE-BIN

SHOW-CATALOG-RECYCLE-BIN

Name

提示

该功能自 Apache Doris 1.2 版本起支持

SHOW CATALOG RECYCLE BIN

描述

该语句用于展示回收站中可回收的库，表或分区元数据信息

语法：

```
SHOW CATALOG RECYCLE BIN [ WHERE NAME [ = "name" | LIKE "name_matcher" ] ]
```

说明：

各列含义如下：	
Type:	元数据类型:Database、Table、Partition
Name:	元数据名称
DbId:	database对应的id
TableId:	table对应的id
PartitionId:	partition对应的id
DropTime:	元数据放入回收站的时间

举例

- 1. 展示所有回收站元数据

```
SHOW CATALOG RECYCLE BIN;
```

- 2. 展示回收站中名称'test'的元数据

```
SHOW CATALOG RECYCLE BIN WHERE NAME = 'test';
```

Keywords

```
SHOW, CATALOG RECYCLE BIN
```

Best Practice

SHOW-QUERY-STATS

SHOW-QUERY-STATS

Name

SHOW QUERY STATS

描述

该语句用于展示数据库中历史查询命中的库表列的情况

```
SHOW QUERY STATS [[FOR db_name]][FROM table_name]] [ALL] [VERBOSE];
```

说明：

- 1. 支持查询数据库和表的历史查询命中情况，重启 fe 后数据会重置，每个 fe 单独统计
- 2. 通过 FOR DATABASE 和 FROM TABLE 可以指定查询数据库或者表的命中情况，后面分别接数据库名或者表名
- 3. ALL 可以指定是否展示所有 index 的查询命中情况，VERBOSE 可以展示更详细的命中情况，这两个参数可以单独使用，也可以一起使用，但是必须放在最后 而且只能用在表的查询上
- 4. 如果没有 use 任何数据库那么直接执行SHOW QUERY STATS 将展示所有数据库的命中情况
- 5. 命中结果中可能有两列： QueryCount: 该列被查询次数 FilterCount: 该列作为 where 条件被查询的次数
举例
- 6. 展示表baseall 的查询命中情况

```
MySQL [test_query_db]> show query stats from baseall;
+-----+-----+-----+
| Field | QueryCount | FilterCount |
+-----+-----+-----+
| k0    | 0          | 0          |
| k1    | 0          | 0          |
| k2    | 0          | 0          |
| k3    | 0          | 0          |
| k4    | 0          | 0          |
| k5    | 0          | 0          |
| k6    | 0          | 0          |
| k10   | 0          | 0          |
| k11   | 0          | 0          |
| k7    | 0          | 0          |
| k8    | 0          | 0          |
| k9    | 0          | 0          |
| k12   | 0          | 0          |
| k13   | 0          | 0          |
+-----+-----+-----+
14 rows in set (0.002 sec)
```

```
MySQL [test_query_db]> select k0, k1,k2, sum(k3) from baseall where k9 > 1 group by k0,k1,k2;
```

k0	k1	k2	sum(`k3`)
0	6	32767	3021
1	12	32767	-2147483647
0	3	1989	1002
0	7	-32767	1002
1	8	255	2147483647
1	9	1991	-2147483647
1	11	1989	25699
1	13	-32767	2147483647
1	14	255	103
0	1	1989	1001
0	2	1986	1001
1	15	1992	3021

12 rows in set (0.050 sec)

```
MySQL [test_query_db]> show query stats from baseall;
```

Field	QueryCount	FilterCount
k0	1	0
k1	1	0
k2	1	0
k3	1	0
k4	0	0
k5	0	0
k6	0	0
k10	0	0
k11	0	0
k7	0	0
k8	0	0
k9	1	1
k12	0	0
k13	0	0

14 rows in set (0.001 sec)

7. 展示表的物化视图的命中的汇总情况

```
MySQL [test_query_db]> show query stats from baseall all;
```

IndexName	QueryCount
baseall	1

1 row in set (0.005 sec)

8. 展示表的物化视图的命中的详细情况

```
MySQL [test_query_db]> show query stats from baseall all verbose;
```

IndexName	Field	QueryCount	FilterCount
baseall	k0	1	0
	k1	1	0
	k2	1	0
	k3	1	0
	k4	0	0
	k5	0	0

	k6	0	0
	k10	0	0
	k11	0	0
	k7	0	0
	k8	0	0
	k9	1	1
	k12	0	0
	k13	0	0

14 rows in set (0.017 sec)

9. 展示数据库的命中情况

```
MySQL [test_query_db]> show query stats for test_query_db;
```

TableName	QueryCount
compaction_tbl	0
bigtable	0
empty	0
tempbaseall	0
test	0
test_data_type	0
test_string_function_field	0
baseall	1
nullable	0

9 rows in set (0.005 sec)

10. 展示所有数据库的命中情况，这时不能 use 任何数据库

```
MySQL [(none)]> show query stats;
```

Database	QueryCount
test_query_db	1

1 rows in set (0.005 sec)

SHOW QUERY STATS; ``

Keywords

SHOW, QUERY, STATS;

Best Practice

IN

IN

IN

描述

语法

```
expr IN (value, ...)
```

```
expr IN (subquery)
```

如果 `expr` 等于 IN 列表中的任何值则返回`true`，否则返回`false`。

`subquery` 只能返回一列，并且子查询返回的列类型必须 `expr` 类型兼容。

如果 `subquery` 返回`bitmap`数据类型列，`expr`必须是整型。

举例

```
mysql> select id from cost where id in (1, 2);
```

```
+-----+
| id  |
+-----+
|  2  |
|  1  |
+-----+
```

```
mysql> select id from tbl1 where id in (select id from tbl2);
```

```
+-----+
| id  |
+-----+
|  1  |
|  4  |
|  5  |
+-----+
```

```
mysql> select id from tbl1 where id in (select bitmap_col from tbl3);
```

```
+-----+
| id  |
+-----+
|  1  |
|  3  |
+-----+
```


keywords

IN

HELP

HELP

Name

HELP

描述

通过改命令可以查询到帮助的目录

语法：

```
HELP <item>
```

可以通过 help 列出所有的 Doris 命令

```
List of all MySQL commands:
Note that all text commands must be first on line and end with ';'
?          (\?) Synonym for `help'.
clear      (\c) Clear the current input statement.
connect    (\r) Reconnect to the server. Optional arguments are db and host.
delimiter  (\d) Set statement delimiter.
edit       (\e) Edit command with $EDITOR.
ego        (\G) Send command to mysql server, display result vertically.
exit       (\q) Exit mysql. Same as quit.
go         (\g) Send command to mysql server.
help       (\h) Display this help.
nopager    (\n) Disable pager, print to stdout.
notee      (\t) Don't write into outfile.
pager      (\P) Set PAGER [to_pager]. Print the query results via PAGER.
print      (\p) Print current command.
prompt     (\R) Change your mysql prompt.
quit       (\q) Quit mysql.
rehash     (\#) Rebuild completion hash.
source     (.) Execute an SQL script file. Takes a file name as an argument.
status     (\s) Get status information from the server.
system     (\!) Execute a system shell command.
tee        (\T) Set outfile [to_outfile]. Append everything into given outfile.
use        (\u) Use another database. Takes database name as argument.
charset    (\C) Switch to another charset. Might be needed for processing binlog with multi-byte charsets.
warnings   (\W) Show warnings after every statement.
nowarning  (\w) Don't show warnings after every statement.
resetconnection(\x) Clean session context.
```

For server side help, type 'help contents'

通过 help contents 获取 Doris SQL 帮助目录

```
Many help items for your request exist.
To make a more specific request, please type 'help <item>',
where <item> is one of the following
```

```
categories:
  sql-functions
  sql-statements
```

举例

1. 列出 Doris 所有的 SQL 帮助目录

```
help contents
```

2. 列出 Doris 集群所有函数目录的命令

```
help sql-functions
```

3. 列出日期函数下的所有函数列表

```
help date-time-functions
```

Keywords

```
HELP
```

Best Practice

USE

USE

Name

USE

描述

USE 命令可以让我们来使用数据库

语法：

```
USE <[CATALOG_NAME].DATABASE_NAME>
```

说明: 1. 使用USE CATALOG_NAME.DATABASE_NAME, 会先将当前的Catalog切换为CATALOG_NAME, 然后再讲当前的Database切换为DATABASE_NAME

举例

1. 如果 demo 数据库存在，尝试使用它：

```
mysql> use demo;  
Database changed
```

2. 如果 demo 数据库在hms_catalog的Catalog下存在，尝试切换到hms_catalog, 并使用它：

```
mysql> use hms_catalog.demo;  
Database changed
```

Keywords

USE

Best Practice

DESCRIBE

DESCRIBE

Name

DESCRIBE

描述

该语句用于展示指定 table 的 schema 信息

语法：

```
DESC[RIBE] [db_name.]table_name [ALL];
```

说明：

1. 如果指定 ALL，则显示该 table 的所有 index(rollup) 的 schema

举例

1. 显示Base表Schema

```
DESC table_name;
```

2. 显示表所有 index 的 schema

```
DESC db1.table_name ALL;
```

Keywords

```
DESCRIBE, DESC
```

Best Practice

SWITCH

SWITCH

Name

SWITCH

描述

该语句用于切换数据目录（catalog）

语法：

```
SWITCH catalog_name
```

举例

1. 切换到数据目录 hive

```
SWITCH hive;
```

Keywords

SWITCH, CATALOG

Best Practice

REFRESH

REFRESH

Name

REFRESH

描述

该语句用于刷新指定 Catalog/Database/Table 的元数据。

语法：

```
REFRESH CATALOG catalog_name;  
REFRESH DATABASE [catalog_name.]database_name;  
REFRESH TABLE [catalog_name.][database_name.]table_name;
```

刷新Catalog的同时，会强制使对象相关的 Cache 失效。

包括Partition Cache、Schema Cache、File Cache等。

举例

1. 刷新 hive catalog

```
REFRESH CATALOG hive;
```

2. 刷新 database1

```
REFRESH DATABASE ctl.database1;  
REFRESH DATABASE database1;
```

3. 刷新 table1

```
REFRESH TABLE ctl.db.table1;  
REFRESH TABLE db.table1;  
REFRESH TABLE table1;
```

Keywords

REFRESH, CATALOG, DATABASE, TABLE

Best Practice

SYNC

描述

该语句用于同步非 Master Frontend (FE) 节点的元数据。在 Apache Doris 中，只有 Master FE 节点可以写入元数据，其他 FE 节点的元数据写入操作都会转发至 Master 节点。在 Master 节点完成元数据写入操作后，非 Master 节点会存在短暂的元数据同步延迟。可以使用该语句强制同步元数据。

语法

```
SYNC;
```

权限控制

任意用户或角色都可以执行该操作

示例

同步元数据：

```
```sql
SYNC;
```
```


CLEAN-QUERY-STATS

CLEAN-QUERY-STATS

Name

CLEAN QUERY STATS

描述

该语句用清空查询统计信息

语法：

```
CLEAN [ALL| DATABASE | TABLE] QUERY STATS [[FOR db_name]|[FROM|IN] table_name]];
```

说明：

- 1. 如果指定 ALL，则清空所有查询统计信息，包括数据库和表的统计信息，需要 admin 权限
- 2. 如果指定 DATABASE，则清空指定数据库的查询统计信息，需要对应 database 的 alter 权限
- 3. 如果指定 TABLE，则清空指定表的查询统计信息，需要对应表的 alter 权限

举例

- 1. 清空所有统计信息

```
clean all query stats;
```

- 2. 清空指定数据库的统计信息

```
clean database query stats for test_query_db;
```

- 3. 清空指定表的统计信息

```
clean table query stats from test_query_db.baseall;
```

Keywords

```
CLEAN, QUERY, STATS
```

Best Practice

FE 配置项

Doris FE 配置参数

该文档主要介绍 FE 的相关配置项。

FE 的配置文件 `fe.conf` 通常存放在 FE 部署路径的 `conf/` 目录下。而在 0.14 版本中会引入另一个配置文件 `fe_custom.conf`。该配置文件用于记录用户在运行时动态配置并持久化的配置项。

FE 进程启动后，会先读取 `fe.conf` 中的配置项，之后再读取 `fe_custom.conf` 中的配置项。`fe_custom.conf` 中的配置项会覆盖 `fe.conf` 中相同的配置项。

`fe_custom.conf` 文件的位置可以在 `fe.conf` 通过 `custom_config_dir` 配置项配置。

注意事项

1. 出于简化架构的目的，目前通过mysql协议修改Config的方式修改配置只会修改本地 FE 内存中的数据，而不会把变更同步到所有 FE。对于只会在 Master FE 生效的 Config 项，修改请求会自动转发到 Master 节点
2. 需要注意`forward_to_master`选项会影响`admin show frontend config`的展示结果，如果`forward_to_master=true`，那么只会展示 Master 的配置（即使您此时连接的是 Follower FE 节点），这可能导致您无法看到对本地 FE 配置的修改；如果期望 `show config` 返回本地 FE 的配置项，那么执行命令`set forward_to_master=false`

查看配置项

FE 的配置项有两种方式进行查看：

1. FE 前端页面查看

在浏览器中打开 FE 前端页面 `http://fe_host:fe_http_port/Configure`。在 Configure Info 中可以看到当前生效的 FE 配置项。

2. 通过命令查看

FE 启动后，可以在 MySQL 客户端中，通过以下命令查看 FE 的配置项：

```
ADMIN SHOW FRONTEND CONFIG;
```

结果中各列含义如下：

- Key：配置项名称。
- Value：当前配置项的值。
- Type：配置项值类型，如整型、字符串。
- IsMutable：是否可以动态配置。如果为 `true`，表示该配置项可以在运行时进行动态配置。如果 `false`，则表示该配置项只能在 `fe.conf` 中配置并且重启 FE 后生效。
- MasterOnly：是否为 Master FE 节点独有的配置项。如果为 `true`，则表示该配置项仅在 Master FE 节点有意义，对其他类型的 FE 节点无意义。如果为 `false`，则表示该配置项在所有 FE 节点中均有

意义。

- Comment: 配置项的描述。

设置配置项

FE 的配置项有两种方式进行配置：

1. 静态配置

在 `conf/fe.conf` 文件中添加和设置配置项。`fe.conf` 中的配置项会在 FE 进程启动时被读取。没有在 `fe.conf` 中的配置项将使用默认值。

2. 通过 MySQL 协议动态配置

FE 启动后，可以通过以下命令动态设置配置项。该命令需要管理员权限。

```
ADMIN SET FRONTEND CONFIG ("fe_config_name" = "fe_config_value");
```

不是所有配置项都支持动态配置。可以通过 `ADMIN SHOW FRONTEND CONFIG;` 命令结果中的 `IsMutable` 列查看是否支持动态配置。

如果是修改 `MasterOnly` 的配置项，则该命令会直接转发给 Master FE 并且仅修改 Master FE 中对应的配置项。

通过该方式修改的配置项将在 FE 进程重启后失效。

更多该命令的帮助，可以通过 `HELP ADMIN SET CONFIG;` 命令查看。

3. 通过 HTTP 协议动态配置

具体请参阅 [Set Config Action](#)

该方式也可以持久化修改后的配置项。配置项将持久化在 `fe_custom.conf` 文件中，在 FE 重启后仍会生效。

应用举例

1. 修改 `async_pending_load_task_pool_size`

通过 `ADMIN SHOW FRONTEND CONFIG;` 可以查看到该配置项不能动态配置 (`IsMutable` 为 `false`)。则需要 在 `fe.conf` 中添加：

```
async_pending_load_task_pool_size=20
```

之后重启 FE 进程以生效该配置。

2. 修改 `dynamic_partition_enable`

通过 `ADMIN SHOW FRONTEND CONFIG;` 可以查看到该配置项可以动态配置 (`IsMutable` 为 `true`)。并且是 Master FE 独有配置。则首先我们可以连接到任意 FE，执行如下命令修改配置：

```
ADMIN SET FRONTEND CONFIG ("dynamic_partition_enable" = "true");`
```

之后可以通过如下命令查看修改后的值：

```
set forward_to_master=true;  
ADMIN SHOW FRONTEND CONFIG;
```

通过以上方式修改后，如果 Master FE 重启或进行了 Master 切换，则配置将失效。可以通过在 `fe.conf` 中直接添加配置项，并重启 FE 后，永久生效该配置项。

3. 修改 `max_distribution_pruner_recursion_depth`

通过 `ADMIN SHOW FRONTEND CONFIG;` 可以查看到该配置项可以动态配置 (`IsMutable` 为 `true`)。并且不是 Master FE 独有配置。

同样，我们可以通过动态修改配置的命令修改该配置。因为该配置不是 Master FE 独有配置，所以需要单独连接到不同的 FE，进行动态修改配置的操作，这样才能保证所有 FE 都使用了修改后的配置值

配置项列表

注：

以下内容由 `docs/generate-config-and-variable-doc.sh` 自动生成。

如需修改，请修改 `fe/fe-common/src/main/java/org/apache/doris/common/Config.java` 中的描述信息。

<--DOC_PLACEHOLDER-->

数据库 CDC 导入

生态概览

日志存储与分析

日志是系统运行的详细记录，包含各种事件发生的主体、时间、位置、内容等关键信息。出于运维可观测、网络安全监控及业务分析等多重需求，企业通常需要将分散的日志采集起来，进行集中存储、查询和分析，以进一步从日志数据里挖掘出有价值的内容。


针对此场景，Apache Doris 提供了相应解决方案，针对日志场景的特点，增加了倒排索引和极速全文检索能力，极致优化写入性能和存储空间，使得用户可以基于 Apache Doris 构建开放、高性能、低成本、统一的日志存储与分析平台。

本文将围绕这一解决方案，介绍以下内容：

- **整体架构：**说明基于 Apache Doris 构建的日志存储与分析平台的核心组成部分和基础架构。
- **特点与优势：**说明基于 Apache Doris 构建的日志存储与分析平台的特点和优势。
- **操作指南：**说明如何基于 Apache Doris 构建日志存储分析平台。

整体架构

基于 Apache Doris 构建的日志存储与分析平台的架构如下图：



Overall architecture

此架构主要由 3 大部分组成：

- **日志采集和预处理：**多种日志采集工具可以通过 HTTP APIs 将日志数据写入 Apache Doris。
- **日志存储和分析引擎：**Apache Doris 提供高性能、低成本的统一日志存储，通过 SQL 接口提供丰富的检索分析能力。
- **日志分析和告警界面：**多种日志检索分析通工具通过标准 SQL 接口查询 Apache Doris，为用户提供简单易用的界面。

特点与优势

基于 Apache Doris 构建的日志存储与分析平台的特点和优势如下：

- **高吞吐、低延迟日志写入：**支持每天百 TB 级、GB/s 级日志数据持续稳定写入，同时保持延迟 1s 以内。

- **海量日志数据低成本存储**：支持 PB 级海量存储，相对于 Elasticsearch 存储成本节省 60% 到 80%，支持冷数据存储到 S3/HDFS，存储成本再降 50%。
- **高性能日志全文检索分析**：支持倒排索引和全文检索，日志场景常见查询（关键词检索明细、趋势分析等）秒级响应。
- **开放、易用的上下游生态**：上游通过 Stream Load 通用 HTTP APIs 对接常见的日志采集系统和数据源 Logstash、Filebeat、Fluentbit、Kafka 等，下游通过标准 MySQL 协议和语法对接各种可视化分析 UI，比如可观测性 Grafana、BI 分析 Superset、类 Kibana 的日志检索 Doris WebUI。

高性能、低成本

经过 Benchmark 测试及生产验证，基于 Apache Doris 构建的日志存储与分析平台，性价比相对于 Elasticsearch 具有 5~10 倍的提升。Apache Doris 的性能优势，主要得益于全球领先的高性能存储和查询引擎，以及下面一些针对日志场景的专门优化：

- **写入吞吐提升**：Elasticsearch 写入的性能瓶颈在于解析数据和构建倒排索引的 CPU 消耗。相比之下，Apache Doris 进行了两方面的写入优化：一方面利用 SIMD 等 CPU 向量化指令提升了 JSON 数据解析速度和索引构建性能；另一方面针对日志场景简化了倒排索引结构，去掉日志场景不需要的正排等数据结构，有效降低了索引构建的复杂度。同样的资源，Apache Doris 的写入性能是 Elasticsearch 的 3~5 倍。
- **存储成本降低**：Elasticsearch 存储瓶颈在于正排、倒排、Docvalue 列存多份存储和通用压缩算法压缩率较低。相比之下，Apache Doris 在存储上进行了以下优化：去掉正排，缩减了 30% 的索引数据量；采用列式存储和 Zstandard 压缩算法，压缩比可达到 5~10 倍，远高于 Elasticsearch 的 1.5 倍；日志数据中冷数据访问频率很低，Apache Doris 冷热分层功能可以将超过定义时间段的日志自动存储到更低的目标存储中，冷数据的存储成本可降低 70% 以上。同样的原始数据，Doris 的存储成本只需要 Elasticsearch 的 20% 左右。
- **查询性能提升**：Apache Doris 将全文检索的流程简化，跳过了相关性打分等日志场景不需要的算法，加速基础的检索性能。同时针对日志场景常见的查询，比如查询包含某个关键字的最新 100 条日志，在查询规划和执行上做专门的 TopN 动态剪枝等优化。

分析能力强

Apache Doris 支持标准 SQL、兼容 MySQL 协议和语法，因此基于 Apache Doris 构建的日志系统能够使用 SQL 进行日志分析，这使得日志系统具备以下优势：

- **简单易用**：工程师和数据分析师对于 SQL 非常熟悉，经验可以复用，不需要学习新的技术栈即可快速上手。
- **生态丰富**：MySQL 生态是数据库领域使用最广泛的语言，因此可以与 MySQL 生态的集成和应用无缝衔接。Doris 可以利用 MySQL 命令行与各种 GUI 工具、BI 工具等大数据生态结合，实现更复杂及多样化的数据处理分析需求。
- **分析能力强**：SQL 语言已经成为数据库和大数据分析的事实标准，它具有强大的表达能力和功能，支持检索、聚合、多表 JOIN、子查询、UDF、逻辑视图、物化视图等多种数据分析能力。

Flexible Schema

下面是一个典型的 JSON 格式半结构化日志样例。顶层字段是一些比较固定的字段，比如日志时间戳 (timestamp)，日志来源 (source)，日志所在机器 (node)，打日志的模块 (component)，日志级别 (level)，客户端请求标识 (clientRequestId)，日志内容 (message)，日志扩展属性 (properties)，基本

上每条日志都会有。而扩展属性 `properties` 的内部嵌套字段 `properties.size`、`properties.format` 等是比较动态的，每条日志的字段可能不一样。

```
{
  "timestamp": "2014-03-08T00:50:03.8432810Z",
  "source": "ADOPTIONCUSTOMERS81",
  "node": "Engine000000000405",
  "level": "Information",
  "component": "DOWNLOADER",
  "clientRequestId": "671db15d-abad-94f6-dd93-b3a2e6000672",
  "message": "Downloading file path: benchmark/2014/ADOPTIONCUSTOMERS81_94_0.parquet.gz",
  "properties": {
    "size": 1495636750,
    "format": "parquet",
    "rowCount": 855138,
    "downloadDuration": "00:01:58.3520561"
  }
}
```

Apache Doris 对 Flexible Schema 的日志数据提供了几个方面的支持：

- 对于顶层字段的少量变化，可以通过 Light Schema Change 发起 ADD / DROP COLUMN 增加 / 删除列，ADD / DROP INDEX 增加 / 删除索引，能够在秒级完成 Schema 变更。用户在日志平台规划时只需考虑当前需要哪些字段创建索引。
- 对于类似 `properties` 的扩展字段，提供了原生半结构化数据类型 `VARIANT`，可以写入任何 JSON 数据，自动识别 JSON 中的字段名和类型，并自动拆分频繁出现的字段采用列式存储，以便于后续的分析，还可以对 `VARIANT` 创建倒排索引，加快内部字段的查询和检索。

相对于 Elasticsearch 的 Dynamic Mapping，Apache Doris 的 Flexible Schema 有以下优势：

- 允许一个字段有多种类型，`VARIANT` 自动对字段类型做冲突处理和类型提升，更好地适应日志数据的迭代变化。
- `VARIANT` 自动将不频繁出现的字段合并成一个列存储，可避免字段、元数据、列过多导致性能问题。
- 不仅可以动态加列，还可以动态删列、动态增加索引、动态删索引，无需像 Elasticsearch 在一开始对所有字段建索引，减少不必要的成本。

操作指南

第 1 步：评估资源

在部署集群之前，首先应评估所需服务器硬件资源，包括以下几个关键步骤：

1. 评估写入资源：计算公式如下：

- 平均写入吞吐 = 日增数据量 / 86400 s
- 峰值写入吞吐 = 平均写入吞吐 * 写入吞吐峰值 / 均值比
- 峰值写入所需 CPU 核数 = 峰值写入吞吐 / 单核写入吞吐

2. 评估存储资源：计算公式为 所需存储空间 = 日增数据量 / 压缩率 * 副本数 * 数据存储周期

3. 评估查询资源：查询的资源消耗随查询量和复杂度而异，建议初始预留 50% 的 CPU 资源用于查询，再根据实际测试情况进行调整。

4. 汇总整合资源：由第 1 步和第 3 步估算出所需 CPU 核数后，除以单机 CPU 核数，估算出 BE 服务器数量，再根据 BE 服务器数量和第 2 步的结果，估算出每台 BE 服务器所需存储空间，然后分摊到 4~12 块数据盘，计算出单盘存储容量。

以每天新增 100 TB 数据量（压缩前）、5 倍压缩率、1 副本、热数据存储 3 天、冷数据存储 30 天、写入吞吐峰值 / 均值比 200%、单核写入吞吐 10 MB/s、查询预留 50% CPU 资源为例，可估算出：

- FE：3 台服务器，每台配置 16 核 CPU、64 GB 内存、1 块 100 GB SSD 盘
- BE：15 台服务器，每台配置 32 核 CPU、256 GB 内存、10 块 600 GB SSD 盘
- S3 对象存储空间：即为预估冷数据存储空间，600 TB

该例子中，各关键指标的值及具体计算方法可见下表：

| 关键指标（单位） | 值 | 说明 |
|---------------------|-------|---|
| 日增数据量（TB） | 100 | 根据实际需求填写 |
| 压缩率 | 5 | 一般为 3~10 倍（含索引），根据实际需求填写 |
| 副本数 | 1 | 根据实际需求填写，默认 1 副本，可选值：1，2，3 |
| 热数据存储周期（天） | 3 | 根据实际需求填写 |
| 冷数据存储周期（天） | 30 | 根据实际需求填写 |
| 总存储周期（天） | 33 | 算法：热数据存储周期 + 冷数据存储周期 |
| 预估热数据存储空间（TB） | 60 | 算法：日增数据量 / 压缩率 * 副本数 * 热数据存储周期 |
| 预估冷数据存储空间（TB） | 600 | 算法：日增数据量 / 压缩率 * 副本数 * 冷数据存储周期 |
| 写入吞吐峰值 / 均值比 | 200 % | 根据实际需求填写，默认 200% |
| 单机 CPU 核数 | 32 | 根据实际需求填写，默认 32 核 |
| 平均写入吞吐（MB/s） | 1214 | 算法：日增数据量 / 86400 s |
| 峰值写入吞吐（MB/s） | 2427 | 算法：平均写入吞吐 * 写入吞吐峰值 / 均值比 |
| 峰值写入所需 CPU 核数 | 2427 | 算法：峰值写入吞吐 / 单核写入吞吐 |
| 查询预留 CPU 百分比 | 50% | 根据实际需求填写，默认 50% |
| 预估 BE 服务器数 | 15.2 | 算法：峰值写入所需 CPU 核数 / 单机 CPU 核数 / (1 - 查询预留 CPU 百分比) |
| 预估 BE 服务器数取整 | 15 | 算法：MAX（副本数，预估 BE 服务器数取整） |
| 预估每台 BE 服务器存储空间（TB） | 5.7 | 算法：预估热数据存储空间 / 预估 BE 服务器数 / (1 - 30%)，其中，30% 是存储空间预留值。建议每台 BE 服务器挂载 4~12 块数据盘，以提高 I/O 能力。 |

第 2 步：部署集群

完成资源评估后，可以开始部署 Apache Doris 集群，推荐在物理机及虚拟机环境中进行部署。手动部署集群，可参考 [手动部署](#)。

第 3 步：优化 FE 和 BE 配置

完成集群部署后，需分别优化 FE 和 BE 配置参数，以更加契合日志存储与分析的场景。

优化 FE 配置

在 `fe/conf/fe.conf` 目录下找到 FE 的相关配置项，并按照以下表格，调整 FE 配置。

| 需调整参数 | 说明 |
|--|---|
| <code>max_running_txn_num_per_db = 10000</code> | 高并发导入运行事务数较多，需调高参数。 |
| <code>streaming_label_keep_max_second = 3600</code>
<code>label_keep_max_second = 7200</code> | 高频导入事务标签内存占用多，保留时间调短。 |
| <code>enable_round_robin_create_tablet = true</code> | 创建 Tablet 时，采用 Round Robin 策略，尽量均匀。 |
| <code>tablet_rebalancer_type = partition</code> | 均衡 Tablet 时，采用每个分区内尽量均匀的策略。 |
| <code>autobucket_min_buckets = 10</code> | 将自动分桶的最小分桶数从 1 调大到 10，避免日志量增加时分桶不够。 |
| <code>max_backend_heartbeat_failure_tolerance_count = 10</code> | 日志场景下 BE 服务器压力较大，可能短时间心跳超时，因此将容忍次数从 1 调大到 10。 |

更多关于 FE 配置项的信息，可参考 [FE 配置项](#)。

优化 BE 配置

在 `be/conf/be.conf` 目录下找到 BE 的相关配置项，并按照以下表格，调整 BE 配置。

| 模块 | 需调整参数 | 说明 |
|------------|---|--|
| 存储 | <code>storage_root_path = /path/to/dir1;/path/to/dir2;...;/path/to/dir12</code> | 配置热数据在磁盘目录上的存储路径。 |
| - | <code>enable_file_cache = true</code> | 开启文件缓存。 |
| - | <code>file_cache_path = [{"path": "/mnt/datadisk0/file_cache", "total_size":53687091200, "query_limit": "10737418240"}], [{"path": "/mnt/datadisk1/file_cache", "total_size":53687091200, "query_limit": "10737418240"}]</code> | 配置冷数据的缓存路径和相关设置，具体配置说明如下：
path：缓存路径
total_size：该缓存路径的总大小，单位为字节，53687091200 字节等于 50 GB
query_limit：单次查询可以从缓存路径中查询的最大数据量，单位为字节，10737418240 字节等于 10 GB |
| 写入 | <code>write_buffer_size = 1073741824</code> | 增加写入缓冲区（buffer）的文件大小，减少小文件和随机 I/O 操作，提升性能。 |
| - | <code>max_tablet_version_num = 20000</code> | 配合建表的 <code>time_series compaction</code> 策略，允许更多版本暂时未合并。 |
| Compaction | <code>max_cumu_compaction_threads = 8</code> | 设置为 CPU 核数 / 4，意味着 CPU 资源的 1/4 用于写入，1/4 用于后台 Compaction，2/1 留给查询和其他操作。 |
| - | <code>inverted_index_compaction_enable = true</code> | 开启索引合并（index compaction），减少 Compaction 时的 CPU 消耗。 |
| - | <code>enable_segcompaction = false</code>
<code>enable_ordered_data_compaction = false</code> | 关闭日志场景不需要的两个 Compaction 功能。 |

| 模块 | 需调整参数 | 说明 |
|----|--|---|
| - | enable_compaction_priority_scheduling = false | 低优先级 compaction 在一块盘上限制 2 个任务，会影响 compaction 速度。 |
| - | total_permits_for_compaction_score = 200000 | 该参数用来控制内存，time series 策略下本身可以控制内存。 |
| 缓存 | disable_storage_page_cache = true
inverted_index_searcher_cache_limit = 30% | 因为日志数据量较大，缓存（cache）作用有限，因此关闭数据缓存，调换为索引缓存（index cache）的方式。 |
| - | inverted_index_cache_stale_sweep_time_sec = 3600
index_cache_entry_stay_time_after_lookup_s = 3600 | 让索引缓存在内存中尽量保留 1 小时。 |
| - | enable_inverted_index_cache_on_cooldown = true
enable_write_index_searcher_cache = false | 开启索引上传冷数据存储时自动缓存的功能。 |
| - | tablet_schema_cache_recycle_interval = 3600
segment_cache_capacity = 20000 | 减少其他缓存对内存的占用。 |
| - | inverted_index_ram_dir_enable = true | 减少写入时索引临时文件带来的 IO 开销。 |
| 线程 | pipeline_executor_size = 24
doris_scanner_thread_pool_thread_num = 48 | 32 核 CPU 的计算线程和 I/O 线程配置，根据核数等比扩缩。 |
| - | scan_thread_nice_value = 5 | 降低查询 I/O 线程的优先级，保证写入性能和时效性。 |
| 其他 | string_type_length_soft_limit_bytes = 10485760 | 将 String 类型数据的长度限制调高至 10 MB。 |
| - | trash_file_expire_time_sec = 300
path_gc_check_interval_second = 900
path_scan_interval_second = 900 | 调快垃圾文件的回收时间。 |

更多关于 BE 配置项的信息，可参考 [BE 配置项](#)。

第 4 步：建表

由于日志数据的写入和查询都具备明显的特征，因此，在建表时按照本节说明进行针对性配置，以提升性能表现。

配置分区分桶参数

分区时，按照以下说明配置：- [使用时间字段上的](#) (PARTITION BY RANGE(ts))，并开启 [动态分区](#) ("dynamic_partition.enable" = "true")，按天自动管理分区。- 使用 Datetime 类型的时间字段作为 Key (DUPLICATE KEY(ts))，在查询最新 N 条日志时有数倍加速。

分桶时，按照以下说明配置：- 分桶数量大致为集群磁盘总数的 3 倍，每个桶的数据量压缩后 5GB 左右。- 使用 Random 策略 (DISTRIBUTED BY RANDOM BUCKETS 60)，配合写入时的 Single Tablet 导入，可以提升批量 (Batch) 写入的效率。

更多关于分区分桶的信息，可参考 [数据划分](#)。

配置压缩参数 - 使用 zstd 压缩算法 ("compression" = "zstd"), 提高数据压缩率。

配置 Compaction 参数

按照以下说明配置 Compaction 参数：

- 使用 `time_series` 策略 (`"compaction_policy" = "time_series"`), 以减轻写放大效应, 对于高吞吐日志写入的资源写入很重要。

建立和配置索引参数

按照以下说明操作:

- 对经常查询的字段建立索引 (`USING INVERTED`)。
- 对需要全文检索的字段, 将分词器 (`parser`) 参数赋值为 `unicode`, 一般能满足大部分需求。如有支持短语查询的需求, 将 `support_phrase` 参数赋值为 `true`; 如不需要, 则设置为 `false`, 以降低存储空间。

配置存储策略

按照以下说明操作:

- 对于热存储数据, 如果使用云盘, 可配置 1 副本; 如果使用物理盘, 则至少配置 2 副本 (`"replication_num" = "2"`)。
- 配置 `log_s3` 的存储位置 (`CREATE RESOURCE "log_s3"`), 并设置 `log_policy_3day` 冷热数据分层策略 (`CREATE STORAGE POLICY log_policy_3day`), 即在超过 3 天后将数据冷却至 `log_s3` 指定的存储位置。可参考以下代码:

```
CREATE DATABASE log_db;
USE log_db;

CREATE RESOURCE "log_s3"
PROPERTIES
(
    "type" = "s3",
    "s3.endpoint" = "your_endpoint_url",
    "s3.region" = "your_region",
    "s3.bucket" = "your_bucket",
    "s3.root.path" = "your_path",
    "s3.access_key" = "your_ak",
    "s3.secret_key" = "your_sk"
);

CREATE STORAGE POLICY log_policy_3day
PROPERTIES(
    "storage_resource" = "log_s3",
    "cooldown_ttl" = "259200"
);

CREATE TABLE log_table
(
    `ts` DATETIME,
    `host` TEXT,
    `path` TEXT,
    `message` TEXT,
    INDEX idx_host (`host`) USING INVERTED,
    INDEX idx_path (`path`) USING INVERTED,
    INDEX idx_message (`message`) USING INVERTED PROPERTIES("parser" = "unicode", "support_phrase" = "true")
)
ENGINE = OLAP
DUPLICATE KEY(`ts`)
PARTITION BY RANGE(`ts`) ()
DISTRIBUTED BY RANDOM BUCKETS 60
PROPERTIES (
    "compression" = "zstd",
    "compaction_policy" = "time_series",
    "dynamic_partition.enable" = "true",
```

```
"dynamic_partition.create_history_partition" = "true",
"dynamic_partition.time_unit" = "DAY",
"dynamic_partition.start" = "-30",
"dynamic_partition.end" = "1",
"dynamic_partition.prefix" = "p",
"dynamic_partition.buckets" = "60",
"dynamic_partition.replication_num" = "2", -- 存算分离不需要
"replication_num" = "2", -- 存算分离不需要
"storage_policy" = "log_policy_3day" -- 存算分离不需要
);
```

第 5 步：采集日志

完成建表后，可进行日志采集。

Apache Doris 提供开放、通用的 Stream HTTP APIs，通过这些 APIs，你可与常用的日志采集器打通，包括 Logstash、Filebeat、Kafka 等，从而开展日志采集工作。本节介绍了如何使用 Stream HTTP APIs 对接日志采集器。

对接 Logstash

按照以下步骤操作：

1. 下载并安装 Logstash Doris Output 插件。你可选择以下两种方式之一：

- 直接下载：[点此下载](#)。
- 从源码编译，并运行下方命令安装：

```
./bin/logstash-plugin install logstash-output-doris-1.2.0.gem
```

2. 配置 Logstash。需配置以下参数：

- logstash.yml：配置 Logstash 批处理日志的条数和时间，用于提升数据写入性能。

```
pipeline.batch.size: 1000000
pipeline.batch.delay: 10000
```

- logstash_demo.conf：配置所采集日志的具体输入路径和输出到 Apache Doris 的设置。

```
input {
  file {
    path => "/path/to/your/log"
  }
}

output {
  doris {
    http_hosts => [ "<http://fehost1:http_port>", "<http://fehost2:http_port>", "<http://fehost3:http_port>" ]
    user => "your_username"
    password => "your_password"
    db => "your_db"
    table => "your_table"

    # doris stream load http headers
    headers => {
```

```

"format" => "json"
"read_json_by_line" => "true"
"load_to_single_tablet" => "true"
}

# field mapping: doris field name => logstash field name
# %{ } to get a logstash field, [ ] for nested field such as [host][name] for host.name
mapping => {
  "ts" => "%{@timestamp}"
  "host" => "%{[host][name]}"
  "path" => "%{[log][file][path]}"
  "message" => "%{message}"
}
log_request => true
log_speed_interval => 10
}
}

```

3. 按照下方命令运行 Logstash，采集日志并输出至 Apache Doris。

```
./bin/logstash -f logstash_demo.conf
```

更多关于 Logstash 配置和使用的说明，可参考 [Logstash Doris Output Plugin](#)。

对接 Filebeat

按照以下步骤操作：

1. 获取支持输出至 Apache Doris 的 Filebeat 二进制文件。可 [点此下载](#) 或者从 Apache Doris 源码编译。
2. 配置 Filebeat。需配置以下参数：
 - filebeat_demo.yml：配置所采集日志的具体输入路径和输出到 Apache Doris 的设置。

```

# input
filebeat.inputs:
- type: log
  enabled: true
  paths:
    - /path/to/your/log
# multiline 可以将跨行的日志（比如 Java stacktrace）拼接起来
multiline:
  type: pattern
  # 效果：以 yyyy-mm-dd HH:MM:SS 开头的行认为是一条新的日志，其他都拼接上一条日志
  pattern: '^[0-9]{4}-[0-9]{2}-[0-9]{2} [0-9]{2}:[0-9]{2}:[0-9]{2}'
  negate: true
  match: after
  skip_newline: true

processors:
# 用 js script 插件将日志中的 \t 替换成空格，避免 JSON 解析报错
- script:
    lang: javascript
    source: >
      function process(event) {
        var msg = event.Get("message");
        msg = msg.replace(/\t/g, " ");
        event.Put("message", msg);
      }
# 用 dissect 插件做简单的日志解析
- dissect:

```

```
# 2024-06-08 18:26:25,481 INFO (report-thread|199) [ReportHandler.cpuReport():617] begin to handle
tokenizer: "%{day} %{time} %{log_level} (%{thread}) [%{position}] %{content}"
target_prefix: ""
ignore_failure: true
overwrite_keys: true

# queue and batch
queue.mem:
  events: 1000000
  flush.min_events: 100000
  flush.timeout: 10s

# output
output.doris:
  fenodes: [ "http://fehost1:http_port", "http://fehost2:http_port", "http://fehost3:http_port" ]
  user: "your_username"
  password: "your_password"
  database: "your_db"
  table: "your_table"
# output string format
## %{[agent][hostname]} %{[log][file][path]} 是filebeat自带的metadata
## 常用的 filebeat metadata 还是有采集时间戳 %{[timestamp]}
## %{[day]} %{[time]} 是上面 dissect 解析得到字段
codec_format_string: '{"ts": "%{[day]} %{[time]}", "host": "%{[agent][hostname]}", "path": "%{[log][file][path]}", "message": "%{[message]}"}'
headers:
  format: "json"
  read_json_by_line: "true"
  load_to_single_tablet: "true"
```

3. 按照下方命令运行 Filebeat，采集日志并输出至 Apache Doris。

```
chmod +x filebeat-doris-2.1.1
./filebeat-doris-2.1.1 -c filebeat_demo.yml
```

更多关于 Filebeat 配置和使用的说明，可参考 [Beats Doris Output Plugin](#)。

对接 Kafka

将 JSON 格式的日志写入 Kafka 的消息队列，创建 Kafka Routine Load，即可让 Apache Doris 从 Kafka 主动拉取数据。

可参考如下示例。其中，property.* 是 Librdkafka 客户端相关配置，根据实际 Kafka 集群情况配置。

```
-- 准备好 kafka 集群和 topic log__topic_
-- 创建 routine load, 从 kafka log__topic_将数据导入 log_table 表
CREATE ROUTINE LOAD load_log_kafka ON log_db.log_table
COLUMNS(ts, clientip, request, status, size)
PROPERTIES (
  "max_batch_interval" = "60",
  "max_batch_rows" = "20000000",
  "max_batch_size" = "1073741824",
  "load_to_single_tablet" = "true",
  "format" = "json"
)
FROM KAFKA (
  "kafka_broker_list" = "host:port",
  "kafka_topic" = "log__topic_",
  "property.group.id" = "your_group_id",
  "property.security.protocol"="SASL_PLAINTEXT",
```



```
"property.sasl.mechanism"="GSSAPI",
"property.sasl.kerberos.service.name"="kafka",
"property.sasl.kerberos.keytab"="/path/to/xxx.keytab",
"property.sasl.kerberos.principal"="<xxx@yyy.com>"
);
-- 查看 routine 的状态
SHOW ROUTINE LOAD;
```

更多关于 Kafka 配置和使用的说明，可参考 [Routine Load](#)。

使用自定义程序采集日志

除了对接常用的日志采集器以外，你也可以自定义程序，通过 HTTP API Stream Load 将日志数据导入 Apache Doris。参考以下代码：

```
curl
--location-trusted
-u username:password
-H "format:json"
-H "read_json_by_line:true"
-H "load_to_single_tablet:true"
-H "timeout:600"
-T logfile.json
http://fe_host:fe_http_port/api/log_db/log_table/_stream_load
```

在使用自定义程序时，需注意以下关键点：

- 使用 Basic Auth 进行 HTTP 鉴权，用命令 `echo -n 'username:password' | base64` 进行计算。
- 设置 HTTP header “format:json”，指定数据格式为 JSON。
- 设置 HTTP header “read_json_by_line:true”，指定每行一个 JSON。
- 设置 HTTP header “load_to_single_tablet:true”，指定一次导入写入一个分桶减少导入的小文件。
- 建议写入客户端一个 Batch 的大小为 100MB ~ 1GB。如果你使用的是 Apache Doris 2.1 及更高版本，需通过服务端 Group Commit 功能，降低客户端 Batch 大小。

第 6 步：查询和分析日志

日志查询

Apache Doris 支持标准 SQL，因此，你可以通过 MySQL 客户端或者 JDBC 等方式连接到集群，执行 SQL 进行日志查询。参考以下命令：

```
mysql -h fe_host -P fe_mysql_port -u your_username -Dyour_db_name
```

下方列出常见的 5 条 SQL 查询命令，以供参考：

- 查看最新的 10 条数据

```
SELECT * FROM your_table_name ORDER BY ts DESC LIMIT 10;
```

- 查询 host 为 8.8.8.8 的最新 10 条数据

```
SELECT * FROM your_table_name WHERE host = '8.8.8.8' ORDER BY ts DESC LIMIT 10;
```

- 检索请求字段中有 error 或者 404 的最新 10 条数据。其中，MATCH_ANY 是 Apache Doris 全文检索的 SQL 语法，用于匹配参数中任一关键字。

```
SELECT * FROM your_table_name WHERE message MATCH_ANY 'error 404'
ORDER BY ts DESC LIMIT 10;
```

- 检索请求字段中有 image 和 faq 的最新 10 条数据。其中，MATCH_ALL 是 Apache Doris 全文检索的 SQL 语法，用于匹配参数中所有关键字。


```
SELECT * FROM your_table_name WHERE message MATCH_ALL 'image faq'
ORDER BY ts DESC LIMIT 10;
```

- 检索请求字段中有 image 和 faq 的最新 10 条数据。其中，MATCH_PHRASE 是 Apache Doris 全文检索的 SQL 语法，用于匹配参数中所有关键字，并且要求顺序一致。在下方例子中，a image faq b 能匹配，但是 a faq image b 不能匹配，因为 image 和 faq 的顺序与查询不一致。

```
SELECT * FROM your_table_name WHERE message MATCH_PHRASE 'image faq'
ORDER BY ts DESC LIMIT 10;
```

可视化日志分析

一些第三方厂商提供了基于 Apache Doris 的可视化日志分析开发平台，包含类 Kibana Discover 的日志检索分析界面，提供直观、易用的探索式日志分析交互。



WebUI

- 支持全文检索和 SQL 两种模式
- 支持时间框和直方图上选择查询日志的时间段
- 支持信息丰富的日志明细展示，还可以展开成 JSON 或表格
- 在日志数据上下文交互式点击增加和删除筛选条件
- 搜索结果的字段 Top 值展示，便于发现异常值和进一步下钻分析

您可以联系 dev@doris.apache.org 获得更多帮助。

获取 Profile

背景

我们时常遇到对应 SQL 执行时间不及预期的情况，为了优化 SQL 达到预期查询时延，通过 Profile 我们能够看出可以做哪些优化。现在说明在不同环境下应该如何拿到对应 Query 的 Profile。

请求

HTTP://FE_IP:HTTP_PORT GET /API/Profile

Doris 集群能够正常访问外网

1. 开启 Profile 上报参数 enable_profile

该参数开启的是 session 变量，此变量不建议全局开启。

```
--开启变量
mysql> set enable_profile=true;
Query OK, 0 rows affected (0.00 sec)

--确认变量是否正常开启
mysql> show variables like '%profile%';
+-----+-----+-----+-----+
| Variable_name | Value | Default_Value | Changed |
+-----+-----+-----+-----+
| enable_profile | true  | false         | 1       |
+-----+-----+-----+-----+
1 row in set (0.00 sec)
```

2. 执行对应 Query

集群在多个 FE 的情况下，需要到开启 Profile 上报参数的 FE 上执行对应 Query, 参数并没有全局生效。


```
--开启变量
mysql> set enable_profile=true;
Query OK, 0 rows affected (0.00 sec)
--确认变量是否正常开启
mysql> show variables like '%profile%';
+-----+-----+-----+-----+
| Variable_name | Value | Default_Value | Changed |
+-----+-----+-----+-----+
| enable_profile | true  | false         | 1       |
+-----+-----+-----+-----+
1 row in set (0.00 sec)

--执行对应 Query
mysql> select id,name from test.test where name like "%Ru0%";
+-----+-----+
| id      | name  |
+-----+-----+
|         |       |
+-----+-----+
```


```
-----+
| 1ZWXYGbb8nr5Pi29J4cEMyEMb |
ZN1nqzBRS1lrTrr99rnX1apLxhRu0UTLw6so7rzjLRQ317gTPxh0dHljmrARDJh7FjRkJW9c7YuUBmWikq7eNgmFKJPreWirDrGrF
zUYH4eP6kDtSA3UTnNIIj |
-----+
1 row in set (0.01 sec)
```

3. 获取 Profile

集群在多个 FE 的情况下，需要访问执行对应 Query 的 FE HTTP 界面 (HTTP://FE_IP:HTTP_PORT) 的 QueryProfile 页面，点击对应 Profile ID 查看对应 Profile，还可以在 Profile 界面下载对应 Profile。



profile1.png



profile2.png

Doris 集群访问外网受到限制

集群不能正常访问外网时，需要通过 API 的方式拿到对应 Profile (HTTP://FE_IP:HTTP_PORT/API/Profile?Query_ID=),IP 和端口是指执行对应 Query 的 FE 对应 IP 和端口。此时获取对应 Query 的 Profile 步骤前两步和正常访问外网时是一样的，第三步获取 Profile 时会有差别。

获取 Porfile

- 找到对应 Query ID

```
--根据对应 Query 找到 Profile ID
mysql> show query profile "/";
+-----+-----+-----+-----+-----+-----+
| Profile ID | Task Type | Start Time | End Time | Total | Task State |
```

| User | Default Db | Sql Statement | | | | | |
|-----------------------------------|------------|---|-------|---------------------|---------------------|------|-----|
| 1b0bb22689734d30-bbe56e17c2ff21dc | root | select id,name from test.test where name like "%Ru0%" | QUERY | 2024-02-28 11:00:17 | 2024-02-28 11:00:17 | 7ms | EOF |
| 202fb174510c4772-965289e8f7f0cf10 | root | select id,name from test.test where name like "%KJ%" | QUERY | 2024-02-25 19:39:20 | 2024-02-25 19:39:20 | 19ms | EOF |

2 rows in set (0.00 sec)

- 查询 Profile 并将 Profile 重定向到一个文本中

模板: `CURL -X GET -u user:password http://fe_ip:http_port/api/profile?query_id=1b0bb22689734d30-bbe56e17c2ff21dc > test.profile`

```
[user@VM-10-6-centos profile]$ curl -X GET -u root:root http://127.0.0.1:8030/api/profile?query_id=1b0bb22689734d30-bbe56e17c2ff21dc > test.profile
```

| % Total | % Received | % Xferd | Average Speed | Time | Time | Time | Current |
|---------|------------|---------|---------------|-------|-------|------|---------|
| | | | Dload Upload | Total | Spent | Left | Speed |
| 100 | 1211 | 0 | 1211 | 0 | 0 | 168k | 0 |

- 返回的 Profile 换行符为 \ \n 分析起来很不方便, 可以在文本编辑工具中将 \ \n 替换为 \n

```
[user@VM-10-6-centos profile]$ cat test.profile
{"msg":"success","code":0,"data":{"profile":"Query:\n Summary:\n
- Profile ID: 1b0bb22689734d30-bbe56e17c2ff21dc\n - Task Type: QUERY\n
- Start Time: 2024-02-28 11:00:17\n - End Time: 2024-02-28 11:00:17\n
- Total: 7ms\n - Task State: EOF\n - User: root\n - Default Db: \n
- Sql Statement: select id,name from test.test where name like \"%Ru0%\"\n Execution Summary:\n
- Workload Group: \n - Analysis Time: 1ms\n
- Plan Time: 2ms\n - JoinReorder Time: N/A\n
- CreateSingleNode Time: N/A\n - QueryDistributed Time: N/A\n
- Init Scan Node Time: N/A\n - Finalize Scan Node Time: N/A\n
- Get Splits Time: N/A\n - Get PARTITIONS Time: N/A\n
- Get PARTITION FILES Time: N/A\n - Create Scan Range Time: N/A\n
- Schedule Time: N/A\n - Fetch Result Time: 0ms\n - Write Result Time: 0ms\n
- Wait and Fetch Result Time: N/A\n - Doris Version: doris-2.0.4-rc06-003a815b63\n
- Is Nereids: Yes\n - Is Pipeline: Yes\n - Is Cached: Yes\n
- Total Instances Num: 0\n - Instances Num Per BE: \n
- Parallel Fragment Exec Instance Num: 48\n - Trace ID: \"\", \"count\":0}
```

- 替换后的效果如下

```
{"msg":"success","code":0,"data":{"profile":"Query:
Summary:
- Profile ID: 1b0bb22689734d30-bbe56e17c2ff21dc
- Task Type: QUERY
- Start Time: 2024-02-28 11:00:17
- End Time: 2024-02-28 11:00:17
- Total: 7ms
- Task State: EOF
- User: root
- Default Db:
- Sql Statement: select id,name from test.test where name like \"%Ru0%\"
Execution Summary:
- Workload Group:
- Analysis Time: 1ms
- Plan Time: 2ms
- JoinReorder Time: N/A
```

```
- CreateSingleNode Time: N/A
- QueryDistributed Time: N/A
- Init Scan Node Time: N/A
- Finalize Scan Node Time: N/A
  - Get Splits Time: N/A
    - Get PARTITIONS Time: N/A
    - Get PARTITION FILES Time: N/A
  - Create Scan Range Time: N/A
- Schedule Time: N/A
- Fetch Result Time: 0ms
- Write Result Time: 0ms
- Wait and Fetch Result Time: N/A
- Doris Version: doris-2.0.4-rc06-003a815b63
- Is Nereids: Yes
- Is Pipeline: Yes
- Is Cached: Yes
- Total Instances Num: 0
- Instances Num Per BE:
- Parallel Fragment Exec Instance Num: 48
- Trace ID:
"}, "count": 0}
```

SECOND_TIMESTAMP

描述

函数将输入的 DATETIME 值转换为从 1970-01-01 00:00:00 UTC 开始的 Unix 时间戳（以秒为单位）。

语法

```
SECOND_TIMESTAMP(<datetime>)
```

参数

| 参数 | 说明 |
|------------|---|
| <datetime> | 必填，输入的 DATETIME 值，表示要转换为 Unix 时间戳的日期时间。 |

返回值

- 返回一个整数，表示输入日期时间对应的 Unix 时间戳（以秒为单位）。
- 如果 <datetime> 为 NULL，函数返回 NULL。
- 如果 <datetime> 超出有效范围，函数可能返回错误或异常值。

举例

```
SELECT SECOND_TIMESTAMP('2025-01-23 12:34:56');
```

```
+-----+
| second_timestamp(cast('2025-01-23 12:34:56' as DATETIMEV2(0))) |
+-----+
|                               1737606896 |
+-----+
```


IPV4_NUM_TO_STRING

IPV4_NUM_TO_STRING

描述

IPV4_NUM_TO_STRING

语法

VARCHAR IPV4_NUM_TO_STRING(BIGINT ipv4_num)

接受一个类型为 Int16、Int32、Int64 且大端表示的 IPv4 的地址，返回相应 IPv4 的字符串表现形式，格式为 A.B.C.D（以点分割的十进制数字）。

注意事项

对于负数或超过4294967295（即 '255.255.255.255'）的入参都返回NULL，表示无效收入

举例

```
mysql> select ipv4_num_to_string(3232235521);
+-----+
| ipv4_num_to_string(3232235521) |
+-----+
| 192.168.0.1                    |
+-----+
1 row in set (0.01 sec)

mysql> select num,ipv4_num_to_string(num) from ipv4_bi;
+-----+-----+
| num      | ipv4_num_to_string(`num`) |
+-----+-----+
-1	NULL
0	0.0.0.0
2130706433	127.0.0.1
4294967295	255.255.255.255
4294967296	NULL
+-----+-----+
7 rows in set (0.01 sec)
```

keywords

IPV4_NUM_TO_STRING, IP

WINDOW_FUNCTION_AVG

WINDOW FUNCTION AVG

描述

计算窗口内数据的平均值

```
AVG([ALL] *expression*) [OVER (*analytic_clause*)]
```

举例

计算当前行和它前后各一行数据的x平均值

```
select x, property,
avg(x) over
(
partition by property
order by x
rows between 1 preceding and 1 following
) as 'moving average'
from int_t where property in ('odd','even');
```

| x | property | moving average |
|----|----------|----------------|
| 2 | even | 3 |
| 4 | even | 4 |
| 6 | even | 6 |
| 8 | even | 8 |
| 10 | even | 9 |
| 1 | odd | 2 |
| 3 | odd | 3 |
| 5 | odd | 5 |
| 7 | odd | 7 |
| 9 | odd | 8 |

keywords

WINDOW,FUNCTION,AVG

WINDOW_FUNCTION_MAX

WINDOW FUNCTION MAX

描述

LEAD() 方法用来计算窗口内的最大值。

```
MAX([DISTINCT | ALL] expression) [OVER (analytic_clause)]
```

举例

计算从第一行到当前行之后一行的最大值

```
select x, property,
max(x) over
(
order by property, x
rows between unbounded preceding and 1 following
) as 'local maximum'
from int_t where property in ('prime','square');
```

| x | property | local maximum |
|---|----------|---------------|
| 2 | prime | 3 |
| 3 | prime | 5 |
| 5 | prime | 7 |
| 7 | prime | 7 |
| 1 | square | 7 |
| 4 | square | 9 |
| 9 | square | 9 |

keywords

WINDOW,FUNCTION,MAX

WINDOW_FUNCTION_NTILE

WINDOW FUNCTION NTILE

描述

对于NTILE(n), 该函数会将排序分区中的所有行按顺序分配到n个桶中(编号较小的桶满了之后才能分配编号较大的桶)。对于每一行, NTILE()函数会返回该行数据所在的桶的编号(从1到n)。对于不能平均分配的情况, 优先分配到编号较小的桶中。所有桶中的行数相差不能超过1。目前n只能是正整数。

```
NTILE(n) OVER(partition_by_clause order_by_clause)
```

举例

```
select x, y, ntile(2) over(partition by x order by y) as rank from int_t;
```

| x | y | rank |
|---|---|------|
| 1 | 1 | 1 |
| 1 | 2 | 1 |
| 1 | 2 | 2 |
| 2 | 1 | 1 |
| 2 | 2 | 1 |
| 2 | 3 | 2 |
| 3 | 1 | 1 |
| 3 | 1 | 1 |
| 3 | 2 | 2 |

keywords

WINDOW,FUNCTION,NTILE

PAUSE-JOB

PAUSE-JOB

Name

PAUSE JOB

描述

用户暂停一个 JOB 作业。被停止的作业可以通过 RESUME JOB 恢复。

```
PAUSE JOB FOR job_name;
```

举例

1. 暂停名称为 test1 的作业。

```
PAUSE JOB FOR test1;
```

Keywords

```
PAUSE, JOB
```

Best Practice

RESUME-JOB

RESUME-JOB

Name

RESUME JOB

描述

用于重启一个 PAUSE 状态的 JOB 作业。重启的作业，将继续按照周期执行。STOP 状态的 JOB 无法被恢复。

```
RESUME JOB FOR job_name;
```

举例

1. 重启名称为 test1 的 JOB。

```
RESUME JOB FOR test1;
```

Keywords

RESUME, JOB

Best Practice

STOP-JOB

STOP-JOB

Name

STOP JOB

描述

用户停止一个 JOB 作业。被停止的作业无法再重新运行。

```
STOP JOB FOR job_name;
```

举例

1. 停止名称为 test1 的作业。

```
STOP JOB FOR test1;
```

Keywords

```
STOP, JOB
```

Best Practice

CLEAN-PROFILE

CLEAN-PROFILE

Name

提示

该功能自 Apache Doris 1.2 版本起支持

CLEAN PROFILE

描述

用于手动清理所有历史 query 或 load 的 profile 信息。

语法：

```
CLEAN ALL PROFILE;
```

举例

- 1. 清理所有 profile 信息。

```
CLEAN ALL PROFILE;
```

Keywords

```
CLEAN, PROFILE
```

Best Practice

SHOW-CONVERT-LIGHT-SCHEMA-CHANGE-PROCESS

SHOW-CONVERT-LIGHT-SCHEMA-CHANGE-PROCESS

Name

SHOW CONVERT LIGHT SCHEMA CHANGE PROCESS

描述

用来查看将非light schema change的olpa表转换为light schema change表的情况， 需要开启配置 enable_convert_light_weight_schema_change

语法:

```
SHOW CONVERT_LIGHT_SCHEMA_CHANGE_PROCESS [FROM db]
```

举例

1. 查看在database test上的转换情况

```
SHOW CONVERT_LIGHT_SCHEMA_CHANGE_PROCESS FROM test;
```

2. 查看全局的转换情况

```
SHOW CONVERT_LIGHT_SCHEMA_CHANGE_PROCESS;
```

Keywords

```
SHOW, CONVERT_LIGHT_SCHEMA_CHANGE_PROCESS
```

Best Practice

SHOW-DATA-TYPES

SHOW-DATA-TYPES

Name

SHOW DATA TYPES

描述

该语句用于查看DORIS支持的所有数据类型。

语法:

```
```sql
SHOW DATA TYPES;
```
```

举例

1. 查看Doris支持的所有数据类型

```
SHOW DATA TYPES;
```

Keywords

SHOW, DATA, TYPES

Best Practice

SHOW-JOB-TASK

SHOW-JOB-TASK

Name

SHOW JOB TASK

描述

该语句用于展示 JOB 子任务的执行结果列表, 默认会保留最新的 20 条记录。

语法:

```
SHOW JOB TASKS FOR job_name;
```

结果说明:

| |
|-------------------|
| JobId: JobId |
| TaskId: TaskId |
| StartTime: 开始执行时间 |
| EndTime: 结束时间 |
| Status: 状态 |
| Result: 执行结果 |
| ErrMsg: 错误信息 |

- State

```
有以下 2 种 State:  
* SUCCESS  
* FAIL
```

举例

1. 展示名称为 test1 的 JOB 的任务执行列表

```
SHOW JOB TASKS FOR test1;
```

Keywords

```
SHOW, JOB, TASK
```

Best Practice

SHOW-MIGRATIONS

SHOW-MIGRATIONS

Name

SHOW MIGRATIONS

描述

该语句用于查看数据库迁移的进度

语法：

```
SHOW MIGRATIONS
```

举例

Keywords

```
SHOW, MIGRATIONS
```

Best Practice

REFRESH-LDAP

REFRESH-LDAP

Name

REFRESH-LDAP

描述

该语句用于刷新 Doris 中 LDAP 的缓存信息。修改 LDAP 服务中用户信息或者修改 Doris 中 LDAP 用户组对应的 role 权限，可能因为缓存的原因不会立即生效，可通过该语句刷新缓存。Doris 中 LDAP 信息缓存默认时间为 12 小时，可以通过 `ADMIN SHOW FRONTEND CONFIG LIKE 'ldap_user_cache_timeout_s'` 查看。

语法：

```
REFRESH LDAP ALL;  
REFRESH LDAP [for user_name];
```

举例

1. 刷新所有 LDAP 用户缓存信息

```
REFRESH LDAP ALL;
```

2. 刷新当前 LDAP 用户的缓存信息

```
REFRESH LDAP;
```

3. 刷新指定 LDAP 用户 user1 的缓存信息

```
REFRESH LDAP for user1;
```

Keywords

REFRESH, LDAP

Best Practice

位图索引

位图索引（Bitmap Index）就是用位图表示的索引，对列的每个键值建立一个位图，相对于其它索引，占用的存储空间非常小，创建和使用非常快，缺点是修改操作锁粒度大，不适合频繁更新。

如下图，bitmap 索引将每个被索引的列的值作为 KEY，使用每个 BIT 表示一行，当这行中包含这个值时，设置为 1，否则设置为 0。

| Record No. | Name | Gender | Address | Income_Level |
|------------|-------|--------|------------|--------------|
| 0 | John | M | Perryridge | L1 |
| 1 | Diana | F | Brooklyn | L2 |
| 2 | Mary | F | Jonestown | L1 |
| 3 | Peter | M | Brooklyn | L4 |
| 4 | Kathy | F | Perryridge | L3 |

| Bitmaps for Gender | |
|--------------------|-------|
| M | 10010 |
| F | 01101 |

| Bitmaps for Income_Level | |
|--------------------------|-------|
| L1 | 10100 |
| L2 | 01000 |
| L3 | 00001 |
| L4 | 00010 |
| L5 | 00000 |

Bitmap Index

适用场景

- 建在值重复度高的列上，建议在 100 到 100,000 之间，如：职业、地市等。重复度过高则对比其他类型索引没有明显优势；重复度过低，则空间效率和性能会大大降低。
- 特定类型的查询例如 count、or、and 等逻辑操作只需要进行位运算。如：通过多个条件组合查询，`select count(*) from table where city = '南京市' and job = '医生' and phonetype = 'iphone' and gender = '男'`。类似这种场景，如果在每个查询条件列上都建立了 Bitmap 索引，则数据库可以进行高效的 bit 运算，精确定位到需要的数据，减少磁盘 IO，并且筛选出的结果集越小，Bitmap 索引的优势越明显。
- 适用于即席查询、多维分析等分析场景。如果有一张表有 100 列，用户会使用其中的 20 个列作为查询条件（任意使用这 20 个列上的 N 的列），在这些列上创建 20 个 Bitmap 索引，那么所有的查询都可以应用到索引。

不适用场景

- 值重复度低的列，如：身份证号、手机号码等。
- 重复度过高的列，如：性别，可以建立 Bitmap 索引，但不建议单独作为查询条件使用，建议与其他条件共同过滤。
- 经常需要更新修改的列。

创建位图索引

在表名为 table_name 上为 siteid 创建 Bitmap 索引

```
CREATE INDEX [IF NOT EXISTS] index_name ON table1 (siteid) USING BITMAP;
```

查看位图索引

展示指定 table_name 的下索引

```
SHOW INDEX FROM table_name;
```

删除索引

删除指定 table_name 的下索引

```
DROP INDEX [IF EXISTS] index_name ON table_name;
```

注意事项

- Bitmap 索引仅在单列上创建。
- Bitmap 索引能够应用在 Duplicate、Uniq 数据模型的所有列和 Aggregate模型的 Key 列上。
- Bitmap 索引支持的数据类型如下：
 - TINYINT
 - SMALLINT
 - INT
 - BIGINT
 - CHAR
 - VARCHAR
 - DATE
 - DATETIME
 - LARGEINT
 - DECIMAL
 - BOOL