



Apache Paimon



StarRocks

StarRocks X Paimon 创建 Streaming Lakehouse

焦明烨/阿里云计算平台事业部OLAP引擎开发工程师

Streaming Lakehouse Meetup

CONTENT

目录 >>

01 /

StarRocks数据湖能力介绍

02 /

使用阿里云EMR StarRocks构建
基于Paimon的极速实时湖仓

03 /

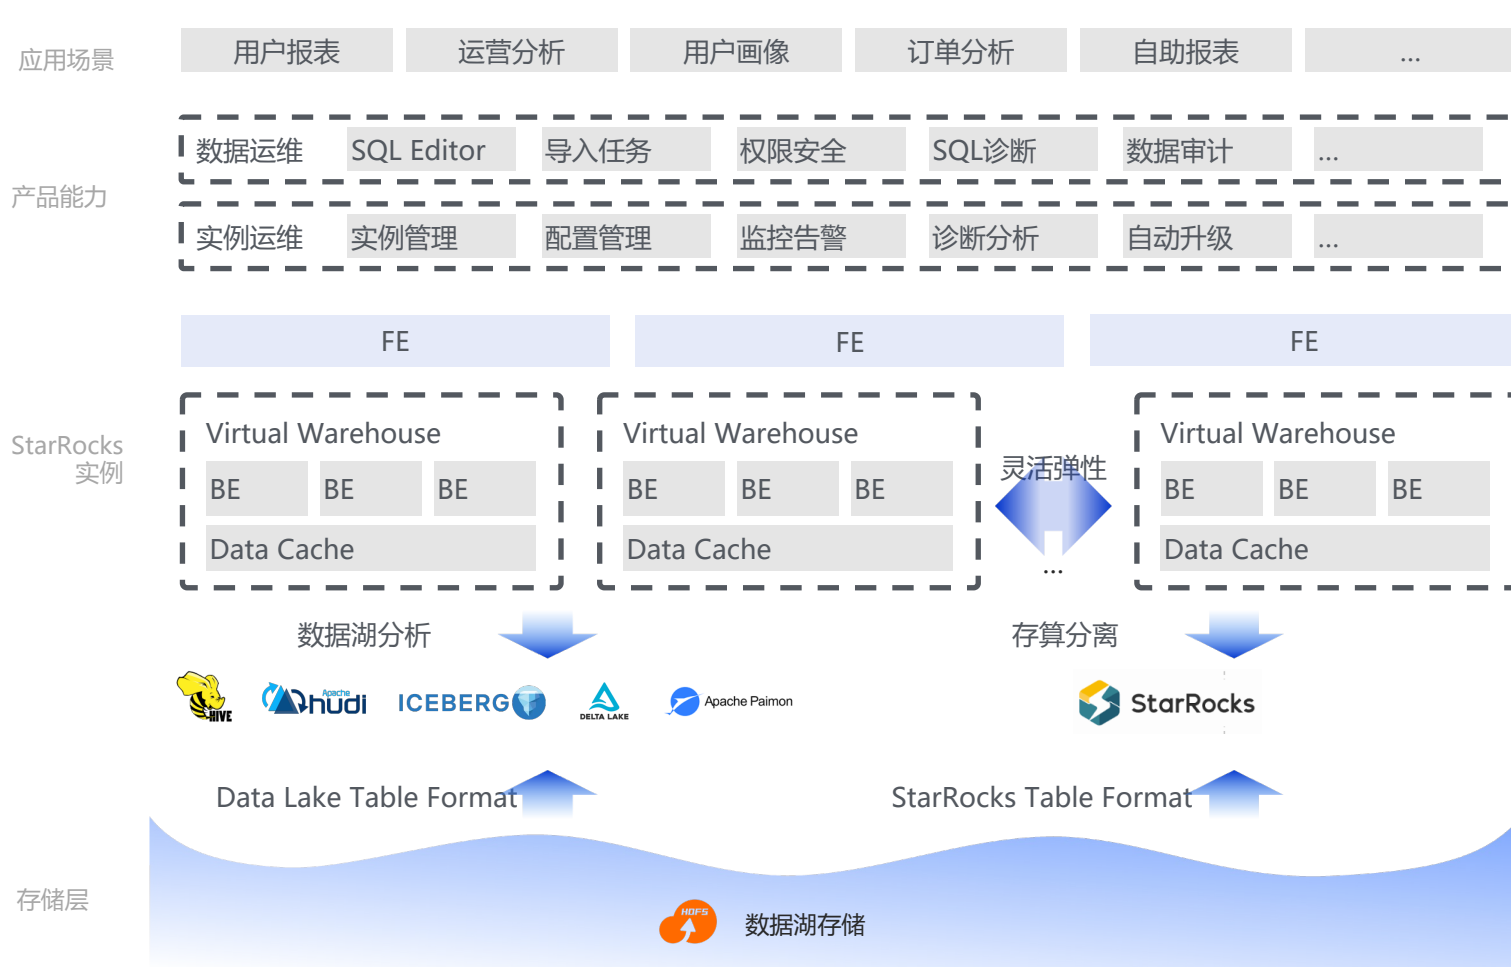
StarRocks + Paimon的最新进展

04 /

StarRocks + Paimon未来规划

01 StarRocks数据湖能力介绍

StarRocks数据湖整体架构




极速统一

- 全面向量化执行引擎，现代化CBO完全兼容多种数据湖格式，IO合并优化对象存储读取，相对Trino有3倍以上提升
- 支持物化视图与ELT场景，一站式完成数据分层加工

简单易用

- 建立连接方便快捷，开箱即用
- 兼容Trino SQL的关键字，语法和函数转义等，迁移便利，兼容度达90%
- 支持Audit Profile等多种方式，全面分析业务


极速统一



StarRocks内表存储

外部数据源

- 通过统一 Catalog 机制，单个引擎管理与分析内外部数据源，充分利用 StarRocks 极速分析能力
- 支持 Internal、Data lake、JDBC、ES 等catalog 及跨数据源的联邦分析
- 内外表数据访问通过 RBAC 机制统一管理



简单易用

```
MySQL [(none)]> create external catalog dlf properties ("type" = "paimon", "paimon.catalog.type" = "dlf-paimon", "dlf.catalog.id" = "taobao_demo_0726");
```

Query OK, 0 rows affected (0.014 sec)

```
MySQL [(none)]> show databases from dlf;
```

Database
default
information_schema
sr
sr_etl_db
taobao_db

5 rows in set (0.356 sec)

```
MySQL [(none)]> select count(1) from dlf.sr.more;select last_query_id();
```

count(1)
10000

1 row in set (4.079 sec)

last_query_id()
8d20c44a-5082-11ef-a534-00163e366656

1 row in set (0.020 sec)

上：动态配置Catalog，方便灵活，即插即用

右：Profile文本示意

get_query_profile('8d20c44a-5082-11ef-a534-00163e366656'): Query:

Summary:

- Query ID: 8d20c44a-5082-11ef-a534-00163e366656
- Start Time: 2024-08-02 11:51:51
- End Time: 2024-08-02 11:51:55
- Total: 4s107ms
- Query Type: Query
- Query State: Finished
- StarRocks Version: dlf2-4a719d3
- User: root
- Default Db
- Sql Statement: select count(1) from dlf.sr.more
- Variables: parallel_fragment_exec_instance_num=1,max_parallel_scan_instance_num=-

1,pipeline_dop=0,enable_adaptive_sink_dop=true,enable_runtime_adaptive_dop=false,runtime_profile_report_interval=10,enable_pipeline_engine=true

- NonDefaultSessionVariables:

{"enable_adaptive_sink_dop":{"defaultValue":false,"actualValue":true},"enable_profile":{"defaultValue":false,"actualValue":true}}

- Collect Profile Time: 2ms

- IsProfileAsync: true

Planner:

- -- Total[1] 3s425ms
- -- Analyzer[1] 2s648ms
- -- AnalyzeDatabase[1] 115ms
- -- AnalyzeTable[1] 2s531ms
- -- Transformer[1] 0
- -- Optimizer[1] 770ms
- -- MVPPreprocess[1] 0
- -- MVChooseCandidates[1] 0
- -- MVGenerateMvPlan[1] 0
- -- MVValidateMv[1] 0
- -- MVProcessWithView[1] 0
- -- RuleBaseOptimize[1] 764ms
- -- CostBaseOptimize[1] 3ms
- -- PhysicalRewrite[1] 0
- -- PlanValidate[1] 0
- -- InputDependenciesChecker[1] 0
- -- TypeChecker[1] 0
- -- CTEUniqueChecker[1] 0
- -- ColumnReuseChecker[1] 0
- -- ExecPlanBuild[1] 6ms
- -- Pending[1] 0
- -- Prepare[1] 0
- -- Deploy[1] 10ms
- -- DeployLockInternalTime[1] 10ms
- -- DeploySerializeConcurrencyTime[2] 2ms
- -- DeployStageByStageTime[6] 0

...

数据湖分析常见场景

01

数据湖分析加速

02

湖仓分层建模


03

冷热融合

04

全链路ELT


场景一：数据湖分析加速



- 支持Trino SQL的关键字，语法和函数转义等
- Trino SQL转换为StarRocks AST, 再生成逻辑计划，复用StarRocks优化器
- **set sql_dialect = "Trino"** 开启
- 兼容Hive view
- 在多家用户实际业务测试，兼容度达90%以上

场景一：数据湖分析加速


1X



Paimon

3X

- CBO
- 向量化引擎
- IO合并
- 延迟物化




Paimon

6X

- 数据缓存
- 内存+磁盘二级缓存



Local cache




Paimon

10X+

- 透明加速
- 查询改写
- 数据建模
- 冷热分离
- 统计信息
- 高性能索引




物化视图



Paimon

场景二：湖仓分层建模



- 简化数据加工，无需维护外部组件
- 自动管理数据间依赖，分区粒度刷新

场景三：冷热融合

业务场景

数据具有冷热特性，想要加速近期查询
创建物化视图指定热数据周期：partition_ttl=3 day



dt=2024/01/02

dt=2024/01/03

...

dt=2024/01/04

dt=2024/01/05

dt=2024/01/06

冷数据



物化视图

dt=2024/01/04


dt=2024/01/05

dt=2024/01/06


热数据

冷热分区合并

热数据物化加速：MV 物化热数据存在StarRocks里
冷数据低成本存储：冷数据使用Paimon 格式放在对象存储
自动查询改写：无需修改查询，优化器自动改写并Union冷数据和热数据



场景四：全链路ELT



高稳定性

- 大幅优化算子 Spill 特性, 提供企业级 MPP ETL 模式
- 通过 VVP CTAS/CDAS, 打造全链路实时数仓

全湖ELT

- 完善的 Data Sink Connector, 支持多种湖格式
- 基于 DataLake 的 ELT 全链路, 一站式读写和加工湖数据


02 使用阿里云EMR StarRocks构建 基于Paimon的极速实时湖仓

EMR Serverless StarRocks



极速

- 海量数据极速分析
- 全新Pipeline执行引擎
- 全面向量化技术
- 全新CBO技术
- 高效实时数据写入与更新
- 针对主键表查询进行大量优化
- 行列混存，大幅提升点查效率



OLAP统一

- 多维报表分析
- 多种数据模型，适应不同场景
- 万级高并发查询
- 实时数据分析
- 业界最高性能数据湖分析，支持多种湖格式
- 物化视图、查询改写、ETL 能力增强



易用

- 针对不同场景创建集群
- 免运维，SLA 保障
- 兼容多种BI报表工具
- 集成 DataWorks & MC 等云上生态
- 便捷的导入任务管理
- 可视化元数据管理
- 集群健康报表
- 慢 SQL 归因分析



云原生

- 即开即用，分钟级交付
- 高效扩缩容/升降配
- 与DLF深度集成
- 存算分离，多级缓存
- 弹性伸缩，负载分析
- MultiWareHouse 资源硬隔离
- CacheManager 缓存可观测易管理

EMR Serverless StarRocks版本

存算一体

极致性能，适用于高并发查询、实时数据分析场景

- 适用于对查询效率要求极高的 OLAP 多维分析、高并发查询、实时数据分析的场景。
- 存算一体版数据存储在云盘或本地盘中。
- 无需远端读取，数据读写性能高。

存算分离

成本降低，Cache 管理，资源隔离，弹性

- 采用存储计算分离架构
- 版本数据存储在 OSS 对象中，存储成本优势大。
- 适用于对查询效率要求略低的 OLAP 多维分析、实时数据分析、以及数据仓库场
- Cache管理能力，预热。以及查询IO本地及远端占比分析

数据湖分析

湖仓新范式架构，Trino平替

- 兼容Trino / Presto 语法。
- 资源完全用于缓存与计算
- 适用于数据湖或数据仓库查询分析的场景，如已有外部数据存储在 HDFS 或者 OSS，需要对该湖上数据进行查询分析。

*购买Serverless StarRocks集群可按三个版本划分

即开即用的SQL Editor, 方便快捷

查询列表

数据库

Catalog: dlf

default

+

dwd_users_samples

+

raw_sample

+

user_profile

sr_etl_db

dwd

id

VARCHAR(1048576)

gender

VARCHAR(1048576)

age_level

VARCHAR(1048576)

shopping_level

VARCHAR(1048576)

+

information_schema

Catalog与库表信息管理

场景二: VVP数据MV加速

场景三: 轻量ETL

场景一: VVP数据ad hoc分析

Catalog创建

运行

保存


格式化

```
6 CREATE EXTERNAL CATALOG `dlf`
7 PROPERTIES (
8   "type" = "paimon",
9   "paimon.catalog.type" = "dlf-paimon",
10  "dlf.catalog.id" = "flink_test"
11 );
12
13 -- Paimon数据查询
14 SELECT count(1) FROM dlf.`default`.user_profile WHERE shopping_level > "2";
15
16 -- 创建存储物化视图的数据库
17 CREATE DATABASE IF NOT EXISTS mv;
18 -- 创建Paimon物化视图
19 -- 设置物化视图异步刷新, 每小时刷新一次
20 CREATE MATERIALIZED VIEW mv.paimon_mv
21 DISTRIBUTED BY RANDOM
22 REFRESH ASYNC EVERY(INTERVAL 1 HOUR)
23 AS SELECT
24   p.pvalue_level AS consumption_level,
25   p.shopping_level AS shopping_depth,
26   r.pid AS resource_position,
27   COUNT(DISTINCT CASE WHEN r.clk = '1' THEN r.user_id END) AS clicks,
28   COUNT(DISTINCT r.user_id) AS total_users,
29   (COUNT(DISTINCT CASE WHEN r.clk = '1' THEN r.user_id END) * 100.0 / COUNT(DISTINCT r.user_id)) AS click_rate
30 FROM
31   dlf.`default`.user_profile p
32 JOIN
33   dlf.`default`.raw_sample r ON p.user_id = r.user_id
34 GROUP BY
35   p.pvalue_level, p.shopping_level, r.pid
36 ORDER BY
37   consumption_level, shopping_depth, click_rate DESC;
38 -- (可选) 刷新物化视图, 确保获取到最新的数据
39 REFRESH MATERIALIZED VIEW mv.paimon_mv;
40 -- 等待物化视图刷新完成后, 查询物化视图, 即可快速得到数据
41 SELECT consumption_level, count(1) FROM mv.paimon_mv GROUP BY consumption_level;
```

数据湖分析场景

数据建模与透明加速场景

智能诊断与分析，清晰直观




诊断与分析

海量SQL可视化查询，筛选慢SQL，并提供针对SQL执行信息的统计以及可视化Profile。

使用场景

- 慢SQL分析与诊断，进行针对性SQL优化或表模型优化。
- SQL按照用户粒度审计。
- 按照用户粒度进行资源使用分析。

可视化监控告警，简洁明了



03 StarRocks + Paimon的最新进展

StarRocks + Paimon的最新进展



读Deletion Vector

相比传统 MOR 表, 读性能更好




物化视图改写

支持在 StarRocks 里创建 Paimon 物化视图, 并将查询自动改写 to 物化视图内表上



接入Unified Catalog

接入外表统一 Catalog



初步支持Paimon Sink

支持写 Paimon 表, 服务轻量ETL场景

读取Deletion Vector

assume: map size = 3, files' bitmap size are 100, 200, 50


file_name	bitmap
data_file_0	bin {3}
data_file_1	bin {2,10}
data_file_10	bin {5}



index file meta:


_INDEX_TYPE: DELETION_VECTORS
_FILENAME: xxx
_FILE_SIZE: 375
_ROW_COUNT: 3
_DELETION_VECTORS _RANGES: binary map { data_file_0 -> (1, 100), data_file_1 -> (109, 200), data_file_10 -> (317, 50) }

index file:



Index文件内容

类似Iceberg Position Delete，用Bitmap标记删除的行



Deletion Vector文件结构

读取Deletion Vector

Deletion Vector与MOR表读性能对比

数据：
-- 数据行数：number-of-rows=
500,000,000，单个副本存储大小约97.3GB
-- 主键范围：0 ~ 1,000,000,000
-- 独立主键数390,000,000+

集群规模：1FE 1BE 8CU

SF=100 on HDFS 原始数据条数： 500,000,000	MOR PK表 数据量：393461137	DV表 数据量：393465715
SQL	查询速度（单位：秒）	查询速度（单位：秒）
select count(1) from paimon_hdfs.paimon_db.dv_orders;	51.408	9.022
select avg(order_product_id) from paimon_hdfs.paimon_db.dv_orders where order_product_id > 100;	51.063	8.905
select avg(order_product_id),avg(order_shop_id) from paimon_hdfs.paimon_db.dv_orders where order_product_id > 100;	59.356	9.340
select avg(order_product_id),avg(order_shop_id),avg(order_user_id) from paimon_hdfs.paimon_db.dv_orders where order_product_id > 100;	64.908	9.714


物化视图改写

```
CREATE MATERIALIZED VIEW mv1 AS
SELECT *
FROM lineorder t1
LEFT JOIN customer t2
ON t1.lo_custkey = t2.c_custkey
GROUP BY c_city
```



自动改写

```
SELECT lo_orderdate, c_city, count(*)
FROM lineorder t1
LEFT JOIN customer t2
ON t1.lo_custkey = t2.c_custkey
LEFT JOIN supplier t3
ON t1.lo_suppkey = t3.s_suppkey
```



自动利用物化视图查询改写透明加速

- 支持 Aggregate、Join、Union 等查询
- 支持改写类型：
 - Complete match
 - partial match
 - query delta join

Unified Catalog

概念

单一Catalog, 查询各种湖格式,
包括
Paimon/Hive/Iceberg/Hudi/Kudu/Delta Lake...

作用范围

支持Hive MetaStore和DLF
不支持FileSystem

```
CREATE EXTERNAL CATALOG unified_catalog
PROPERTIES
(
    "type"="unified",
    "unified.metastore.type"="dlf",
    "paimon.catalog.warehouse"="oss://<YourBucketName>/<YourPath>/"
);
```

Paimon Sink

实现方式

- 接入Connector Sink框架
- 构造JNI Writer, 调用Paimon SDK, 执行批写
- 提交元数据, 完成写入

使用限制

- 当前仅支持整数、浮点数、字符串、时间类型
- 有显著内存消耗, 速度欠佳

```
MySQL [(none)]> select count(1) from dlf2.taobao_db.commerce_taobao_adv_ad_feature;
+-----+
| count(1) |
+-----+
| 846811 |
+-----+
1 row in set (3.550 sec)

MySQL [(none)]> create table dlf2.sr.test as select * from dlf2.taobao_db.commerce_taobao_adv_ad_feature limit 1;
Query OK, 1 row affected (14.669 sec)

MySQL [(none)]> select * from dlf2.sr.test;
+-----+-----+-----+-----+-----+-----+
| adgroup_id | cate_id | campaign_id | customer_id | brand | price |
+-----+-----+-----+-----+-----+-----+
| 63133      | 6406    | 83237      | 1           | 95471 | 170.0 |
+-----+-----+-----+-----+-----+-----+
1 row in set (4.978 sec)
```

04 StarRocks + Paimon未来规划

StarRocks + Paimon未来规划



元数据缓存

Catalog 级别Paimon元数据缓存, 有效加快查询速度, 解决MV改写慢的痛点




分布式Plan

使用BE生成执行计划, 防止查询时单点FE单点成为读性能瓶颈



索引支持

支持Bitmap和Bloom Filter索引| 加快读取速度



DLF 2.0

接入DLF 2.0, 构建云上统一湖仓



Apache Paimon



StarRocks

Thanks

Streaming Lakehouse Meetup