

AI 驱动 软件研发 全面进入数字化时代

中国·深圳 11.24-25

AI+
software
Development
Digital
summit



OpenMLDB: 以实时特征驱动实时智能决策

陈迪豪 第四范式

科技生态圈峰会 + 深度研习



—1000+ 技术团队的选择



K+全球软件研发行业创新峰会

会议时间: 2024.05.24-25



K+全球软件研发行业创新峰会

会议时间: 2024.09.20-21



AI+ 软件研发数字峰会

会议时间: 2023.11.24-25



AI+ 软件研发数字峰会

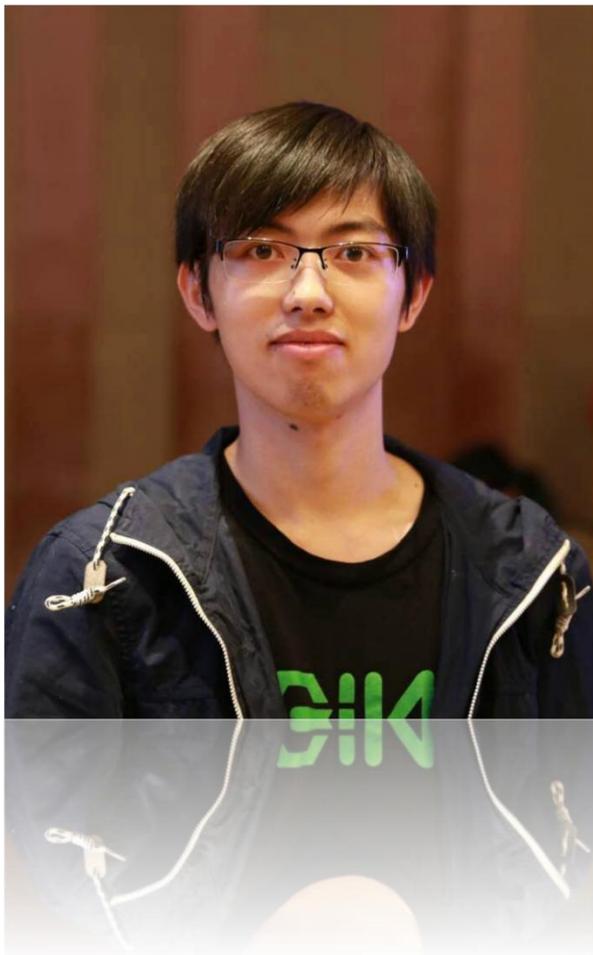
会议时间: 2024.07.19-20



AI+ 软件研发数字峰会

会议时间: 2024.11.15-16

▶ 演讲嘉宾



陈迪豪

第四范式平台架构师, OpenMLDB PMC Member

目前担任 OpenMLDB PMC 以及第四范式平台架构师, 曾担任小米云深度学习平台架构师以及优思德云计算公司存储和容器团队负责人。活跃于分布式系统、机器学习相关的开源社区, 也是HBase、OpenStack、TensorFlow、TVM等开源项目贡献者。

目录

CONTENTS

1. 实时智能决策的工程化挑战
2. OpenMLDB 提供线上线下一致的实时特征计算
3. 社区生态和案例分享

PART 01

实时智能决策的工程化挑战

▶ 实时智能决策的工程化挑战

基于机器学习的实时智能决策，需要毫秒级的实时计算能力

两大 AI 应用：感知类、决策类

硬实时计算真正满足实时决策需求 – 实时数据、实时计算

流式计算为 Big Data 和 BI 设计



python Spark Streaming Flink AI无人车 AI事中反欺诈

SAS APACHE STORM kafka 量化交易 航空航天

TensorFlow 现在市面上所谓的AI实时计算 大都是流式计算

硬实时场景蕴藏巨大商业价值，鲜有通用商业化产品

银行要求毫秒级业务响应

以某银行反欺诈场景为例

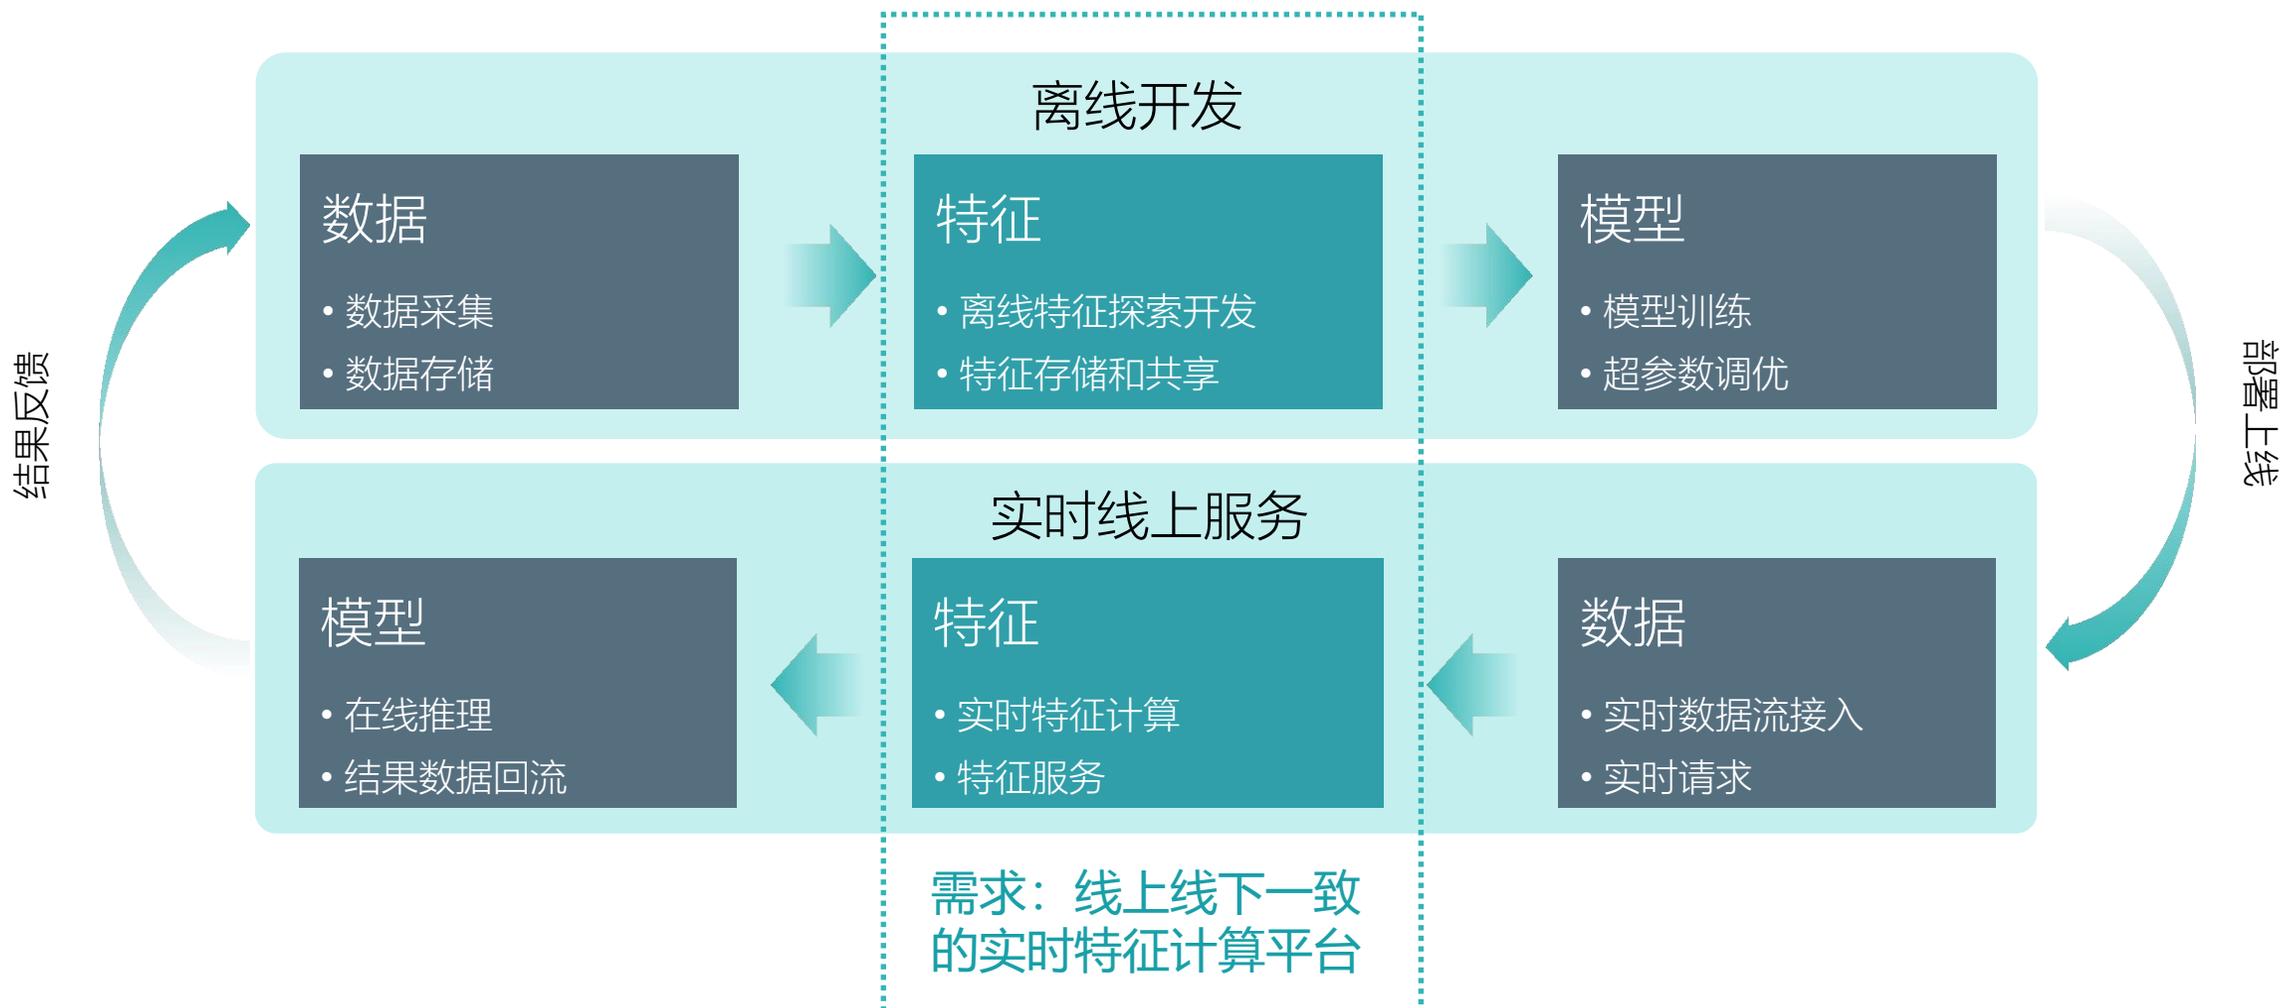
客户需求：

特征计算响应时间 20ms 内，高准召率的事中反欺诈系统

解决方案	响应时间	准召率
传统规则系统	~200ms	较差
客户自研系统	~50ms	中等
第四范式先知	<20ms	优等

▶ 实时智能决策的工程化挑战

基于机器学习的智能决策从离线开发到上线全流程



实时智能决策的工程化挑战

事中反欺诈交易的实时特征计算

刷卡记录



卡号	刷卡金额	刷卡时间
012159	1000	2022/01/12 08:00:00

虚拟插入

历史交易表

卡号	刷卡金额	刷卡时间 (已排序)
012112	223	2022/01/12 02:00:00
012159	15	2022/01/12 06:00:00
012159	1000	2022/01/12 07:59:55
012159	2000	2022/01/12 07:59:57
012159	1000	2022/01/12 08:00:00

基于窗口聚合

10s

3h

特征计算

生成的特征

卡号	刷卡金额	过去10秒内: 刷卡次数 刷卡最大金额 最小金额 平均金额	过去三小时内: 刷卡次数 刷卡最大金额 最小金额 平均金额
012159	1000	3 2000 1000 1333	4 2000 14 1003

工程化需求

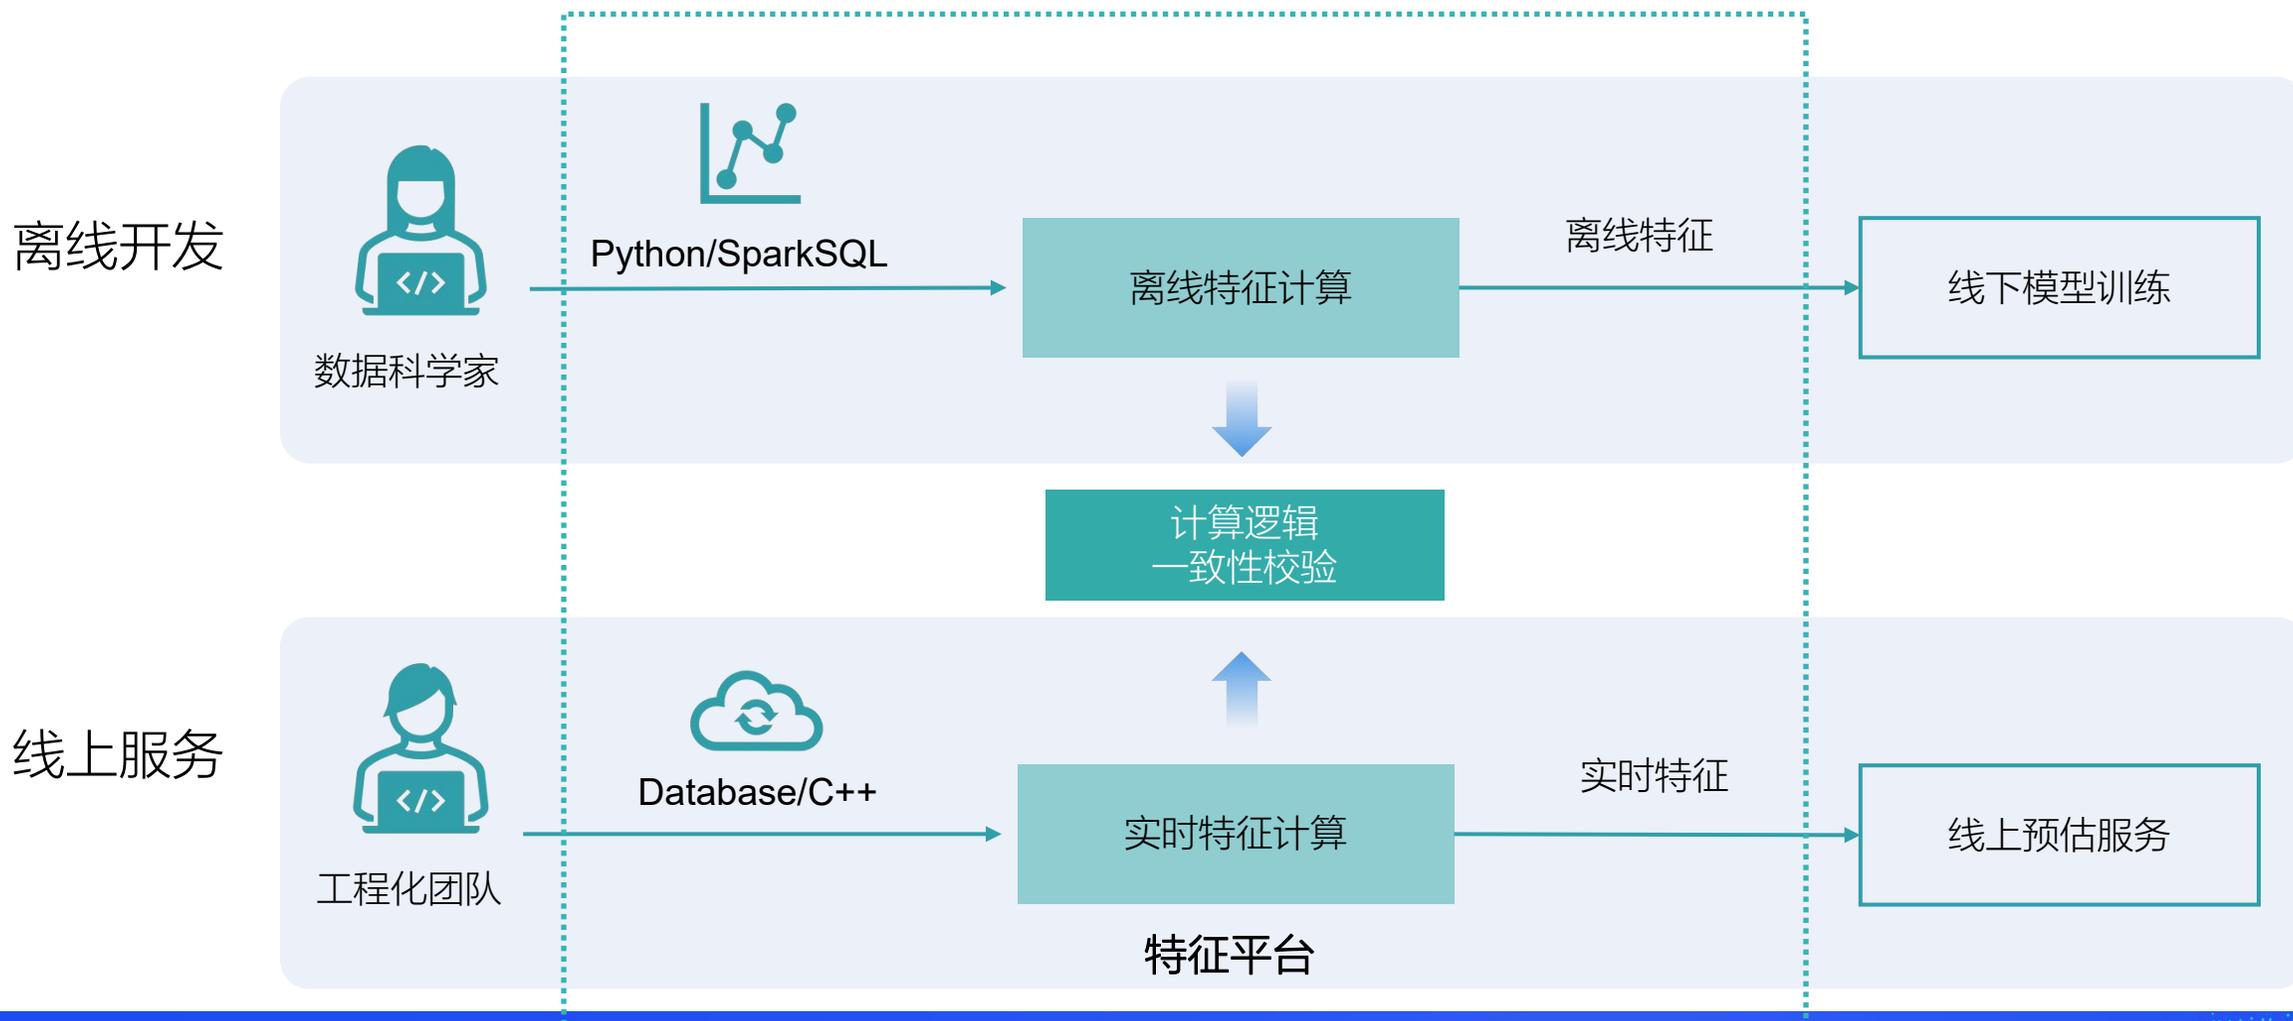
1. 线上线下一致性
2. 低延迟、高并发、高可用

模型推理

欺诈交易?

▶ 实时智能决策的工程化挑战

传统特征开发：离线开发和线上服务分离，高成本投入



▶ 实时智能决策的工程化挑战

线上线下一致性可能的原因

工具能力的不一致性

离线开发



Python

```
import pandas as pd
t1 = pd.read_csv("data.csv")
account_feat = t1['account'].std()
```

$$\sqrt{\sum_{i=0}^N \frac{(x_i - \mu)^2}{N - 1}}$$

标准差

(Bessel's Correction)

线上应用



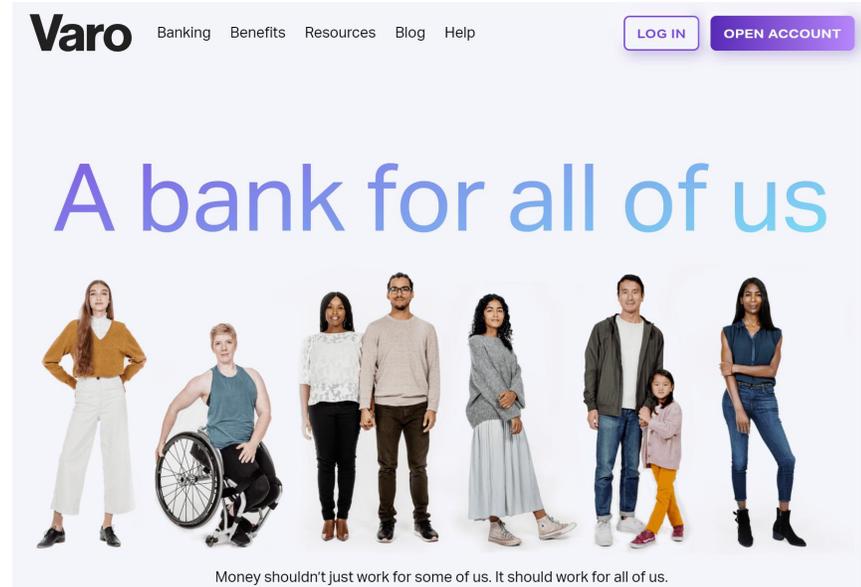
MySQL

```
select std(account) as account_feat from t1;
```

$$\sqrt{\sum_{i=0}^N \frac{(x_i - \mu)^2}{N}}$$

标准差

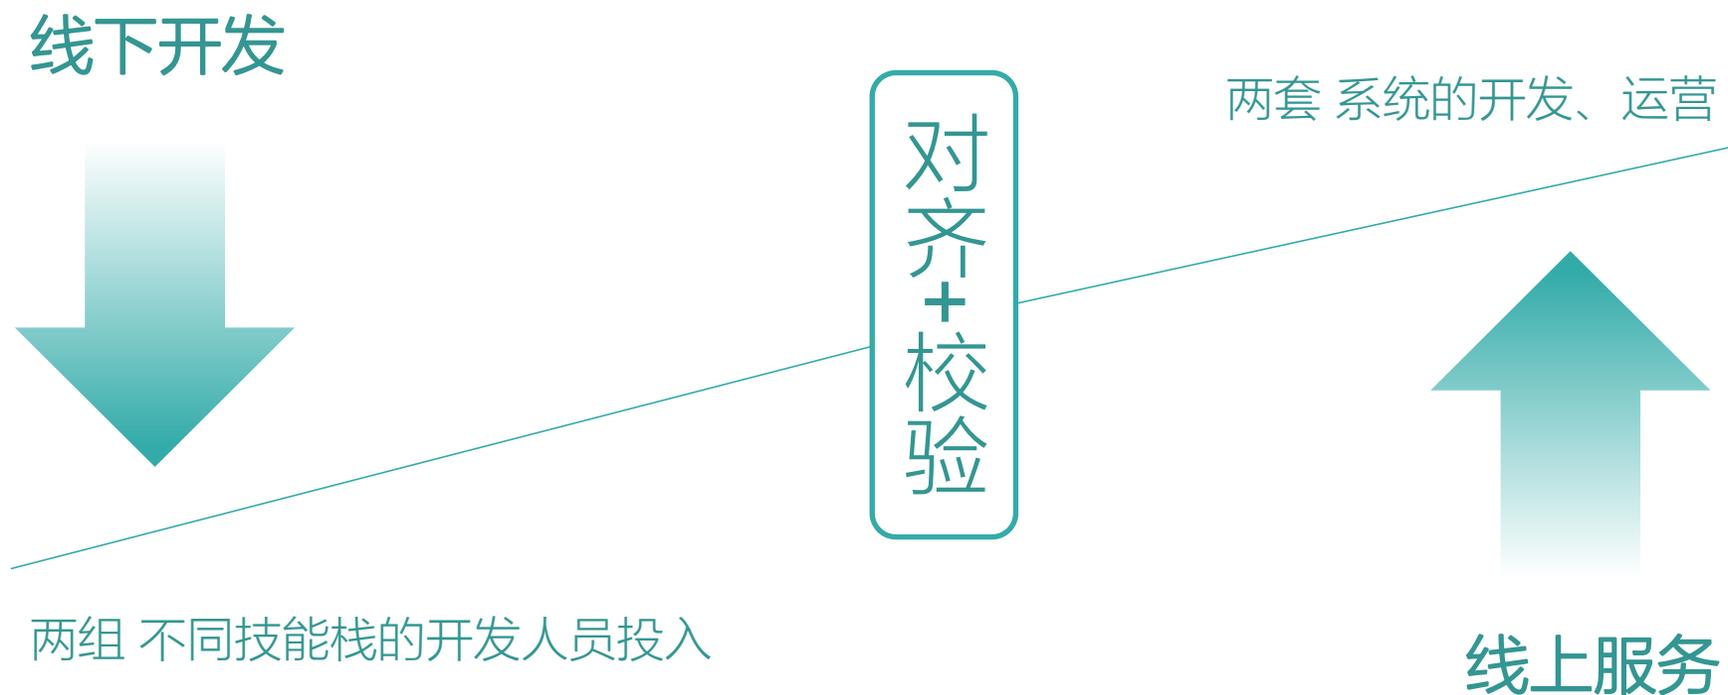
需求沟通的认知差



	Account Balance
线上应用	current "account balance"
离线开发	"account balance" as of yesterday

▶▶ 实时智能决策的工程化挑战

线上线下一致性校验带来的高昂工程化落地成本



PART 02

OpenMLDB 提供线上线下一致的 实时特征计算

▶ OpenMLDB 提供线上线下一致的实时特征计算

OpenMLDB 发展历程：从闭源走向开源



开源前，跟随第四范式 先知 平台，在 100+场景 落地，覆盖超过 300个节点。

开源后，以开放姿态积极拥抱社区开发者、整合开源生态，提供商业化定制和支持。



主要使用场景

信用卡现金分期精准营销	贷前风险评分	营销获客	个性化推荐	反洗钱可疑交易智能识别
信用卡账户风险预警	合规额度决策	风险管理	投顾客户挖掘	信用卡申请反欺诈
欺诈养卡防控	理财个性化推荐	零售贷款反欺诈	历史客户激活	客户流失预警
网点流量预测	交易欺诈评分	现金分期个性化推荐	信用卡交易反欺诈	金融产品推荐

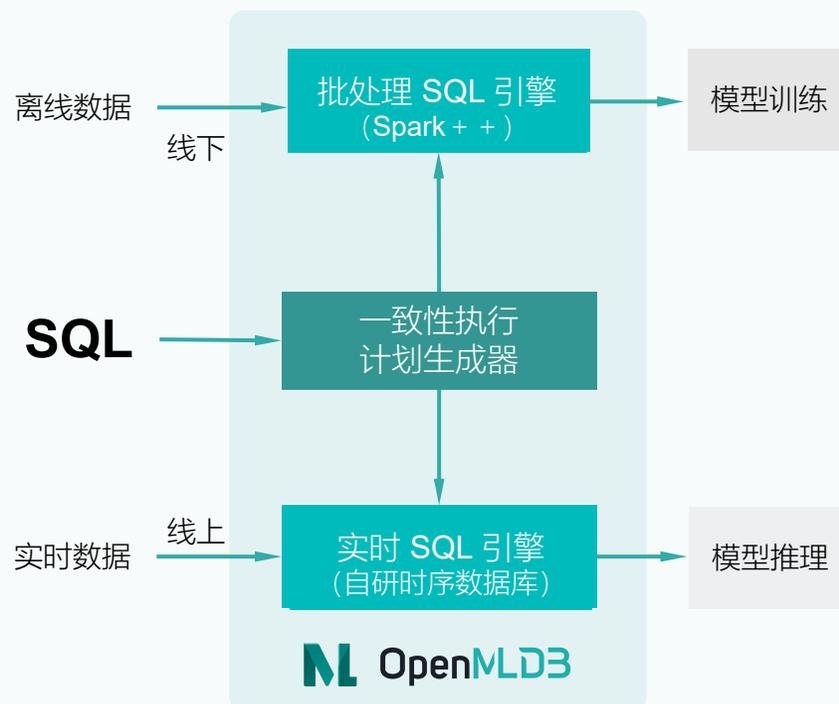
▶ OpenMLDB 提供线上线下一致的实时特征计算

OpenMLDB: 开源机器学习数据库, 线上线下一致的特征平台

原有流程



OpenMLDB 抽象架构

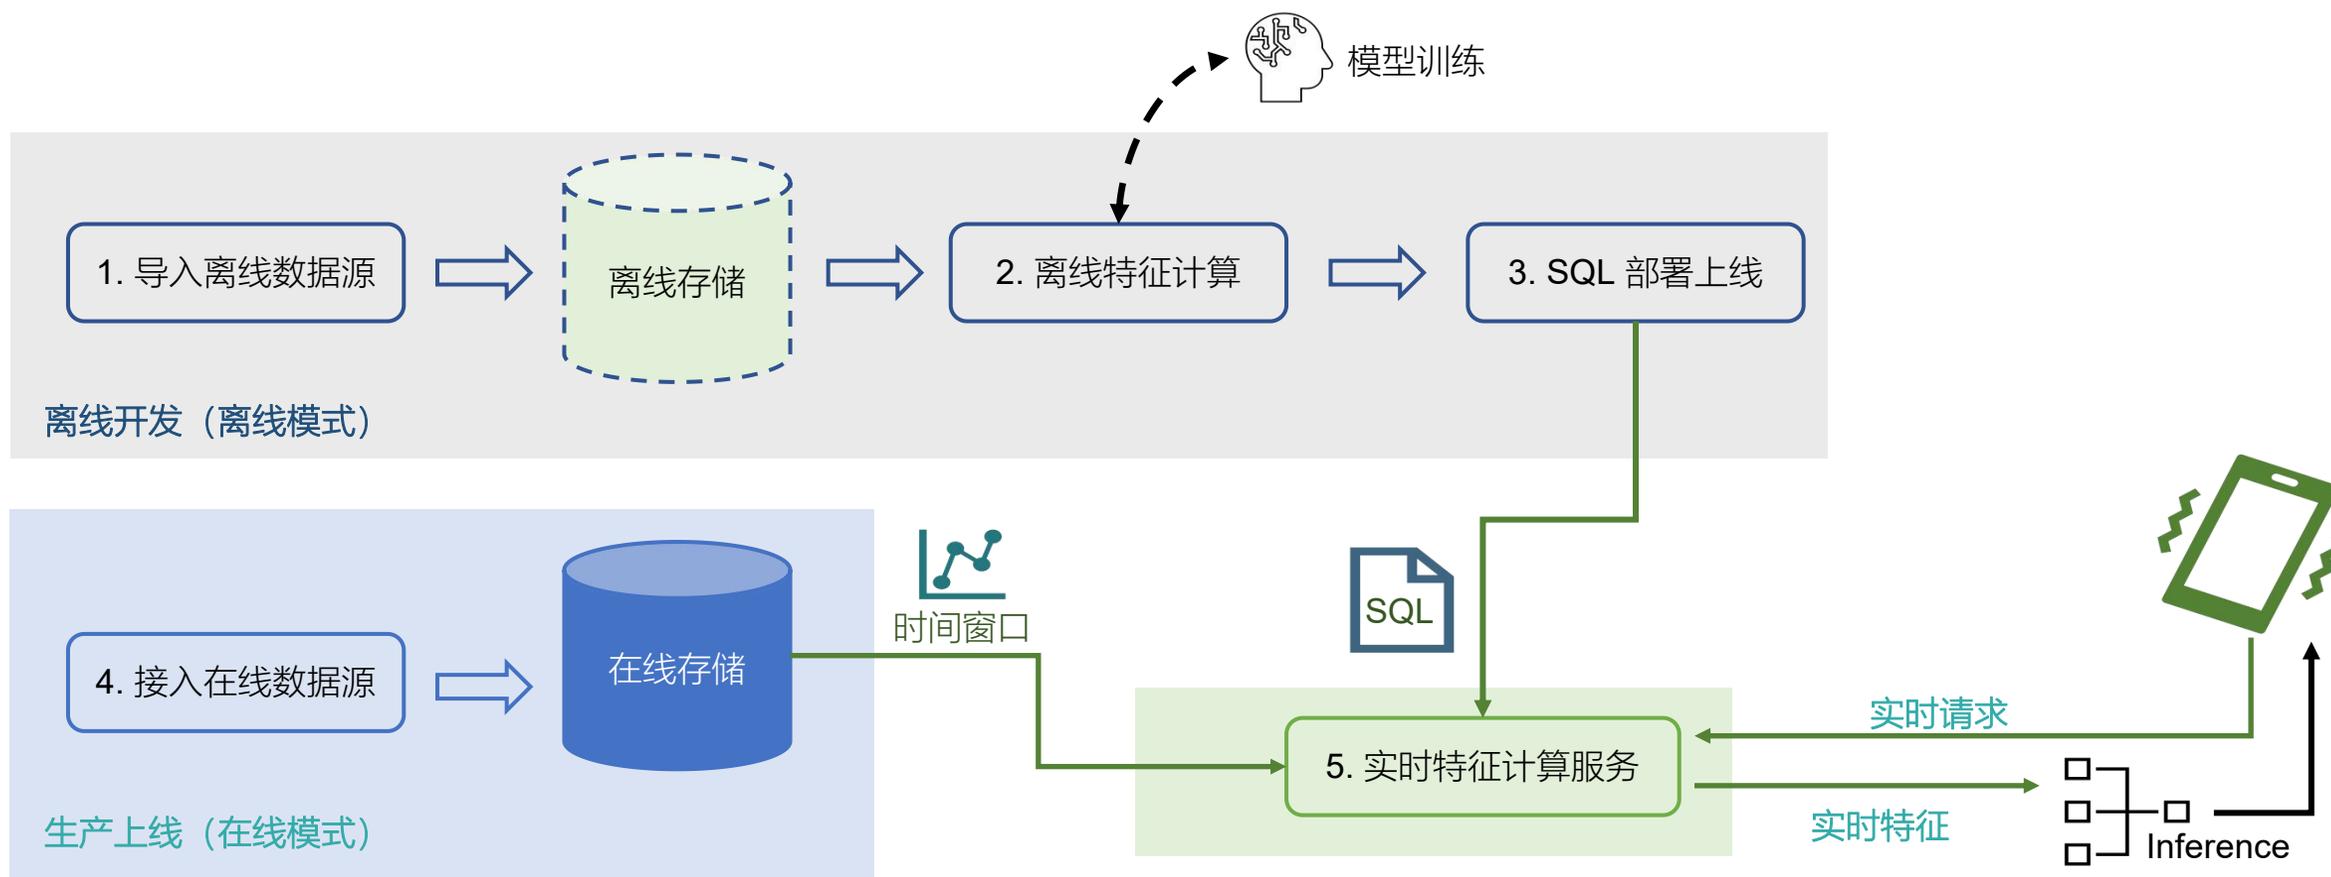


基于 OpenMLDB 的流程



▶ OpenMLDB 提供线上线下一致的实时特征计算

从离线开发到线上服务完整流程



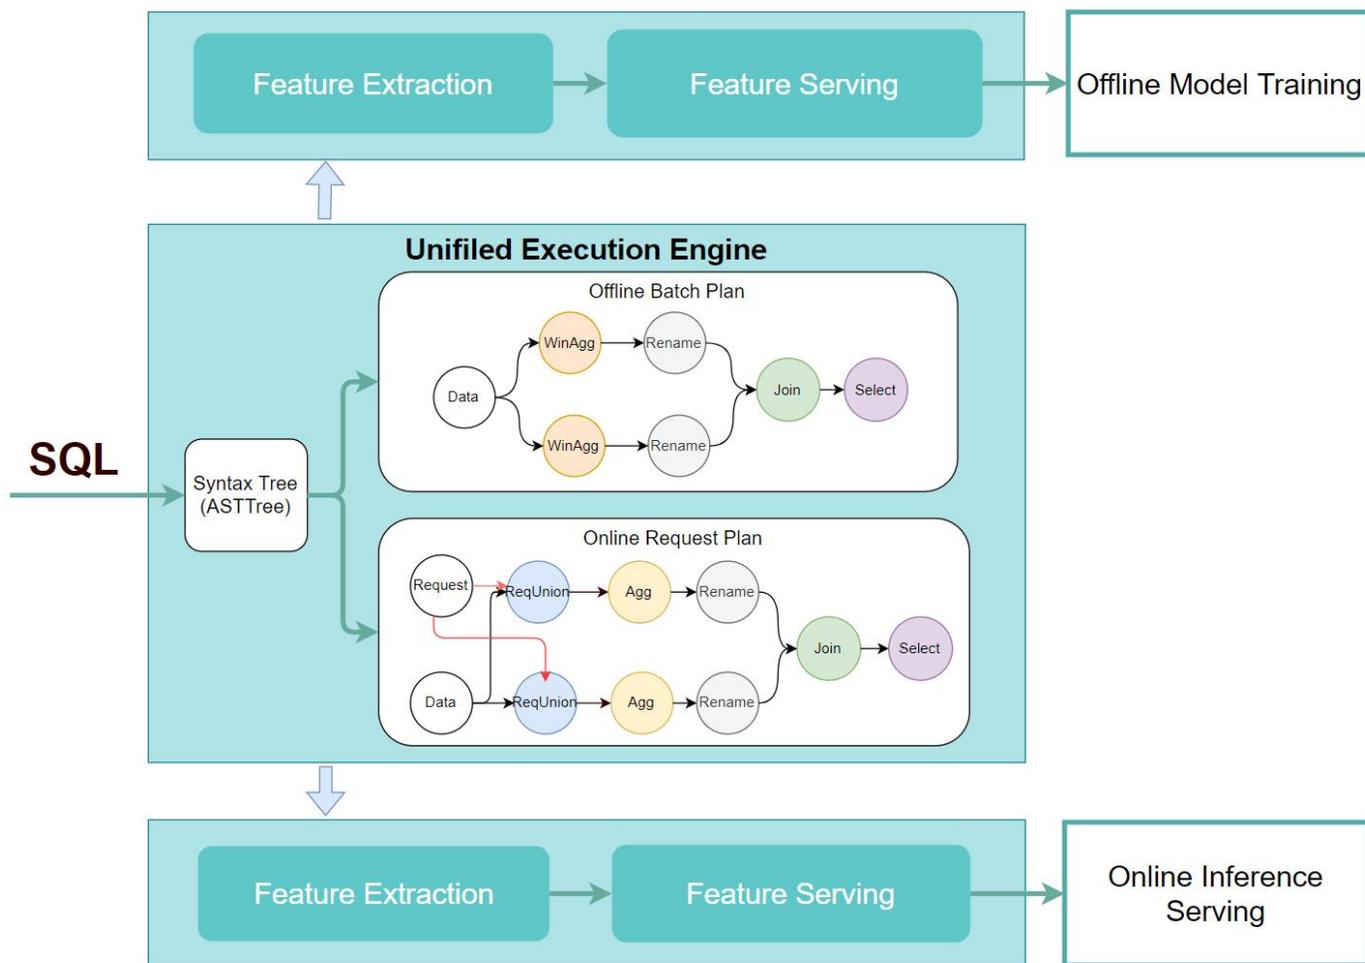
▶ OpenMLDB 提供线上线下一致的实时特征计算

OpenMLDB 提供了一个 **线上线下一致** 的 **毫秒级** 实时特征计算平台

- 基于实时数据按需计算 (on-demand)
- 基于 SQL 定义特征
- 生产级平台, 分布式、可扩展、高可用

► OpenMLDB 提供线上线下一致的实时特征计算

核心组件一：线上线下一致性执行引擎



- 统一的底层计算函数
- 逻辑计划到物理计划的线上线下一致性执行模式自适应调整



线上线下一致性得到 天然保障

► OpenMLDB 提供线上线下一致的实时特征计算

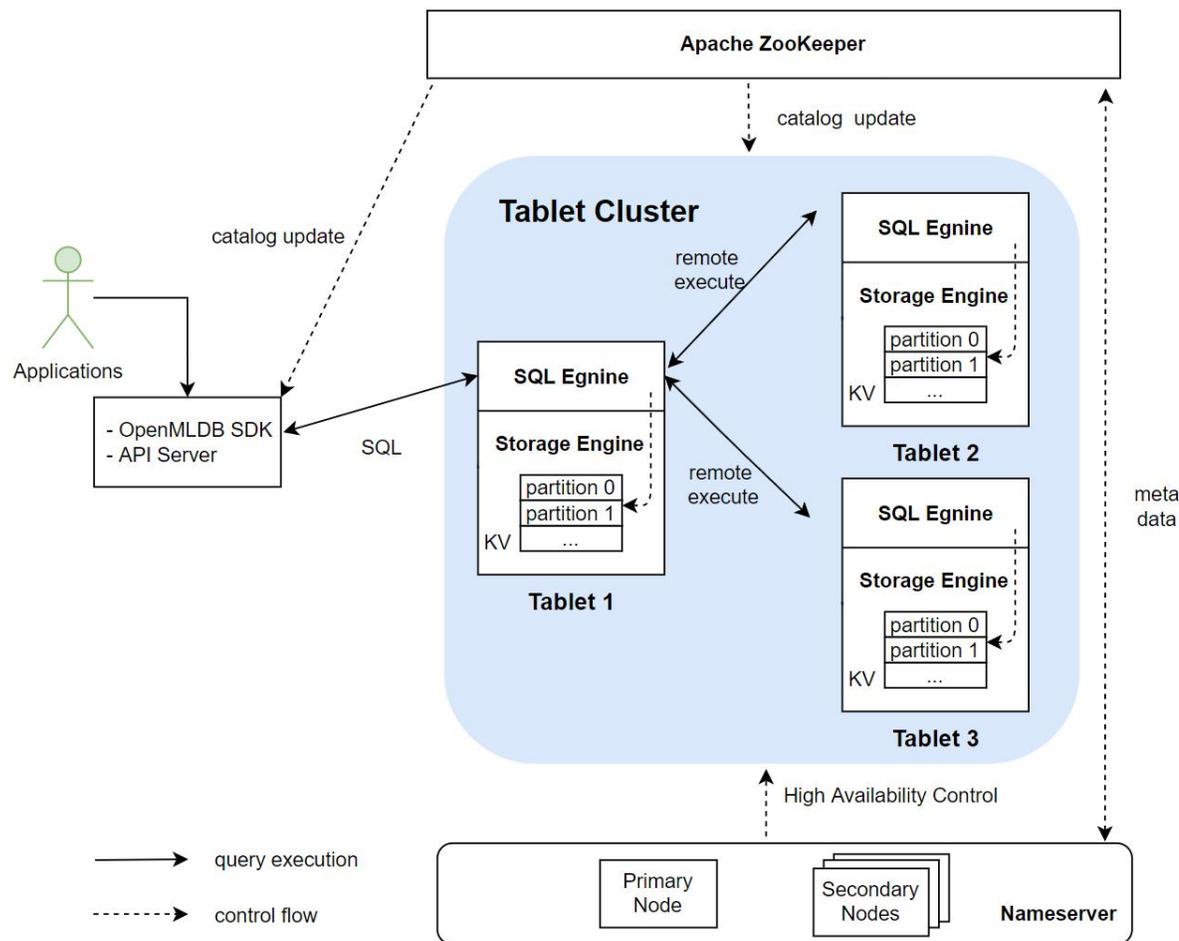
核心组件二：高性能实时 SQL 引擎

分布式实时 SQL 引擎主要模块

- **ZooKeeper** – 元数据存储和管理
- **Nameserver** – tablet 管理和故障转移
- **Tablets**
 - 分布式 SQL 执行引擎
 - 分布式存储引擎：
内存、磁盘双存储引擎
- 高性能、可扩展、高可用

详细线上引擎架构描述参见：

<https://openmlDB.feishu.cn/wiki/wikcnvULzxKH5Aka3ox0871R2f>

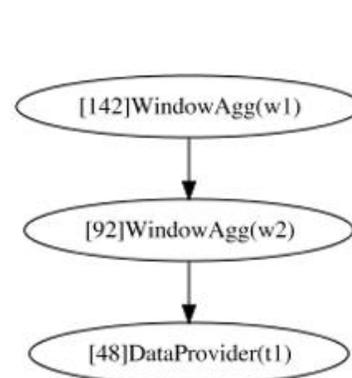
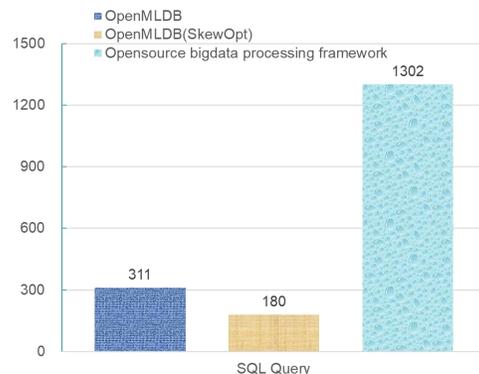
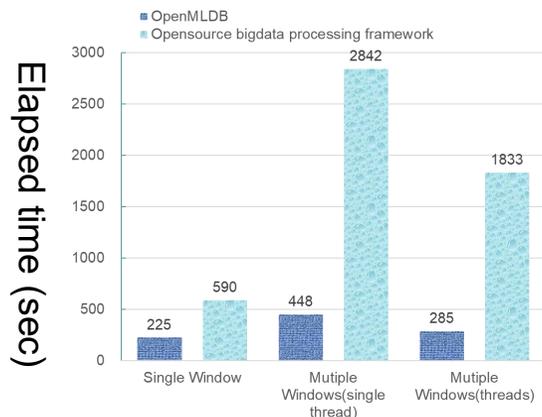


▶ OpenMLDB 提供线上线下一致的实时特征计算

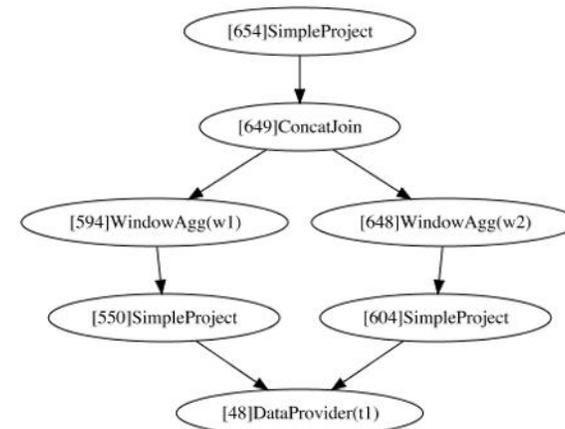
核心组件三：面向特征计算的优化的离线计算引擎

- 多窗口并行计算优化
- 数据倾斜计算优化
- SQL 语法扩展
- 针对特征计算优化的 OpenMLDB Spark 发行版

```
SELECT
  min(age) OVER w1 as w1_min_age,
  min(age) OVER w2 as w2_min_age
FROM t1
WINDOW
  w1 as (PARTITION BY name ORDER by age ROWS BETWEEN 10 PRECEDING AND CURRENT ROW),
  w2 as (PARTITION BY age ORDER by age ROWS BETWEEN 10 PRECEDING AND CURRENT ROW)"
```



Spark 3.0.0



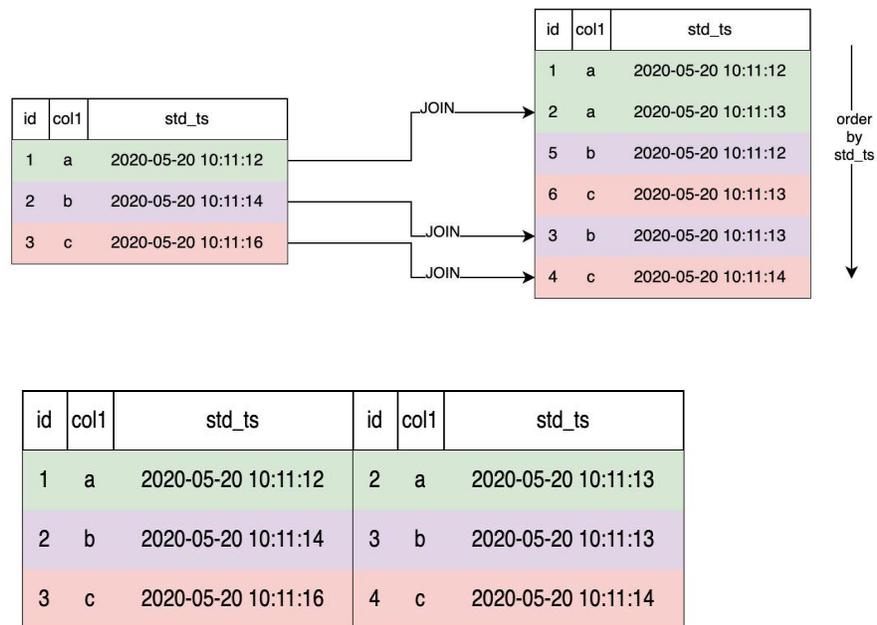
OpenMLDB

► OpenMLDB 提供线上线下一致的实时特征计算

核心组件四：针对特征工程的 SQL 扩展

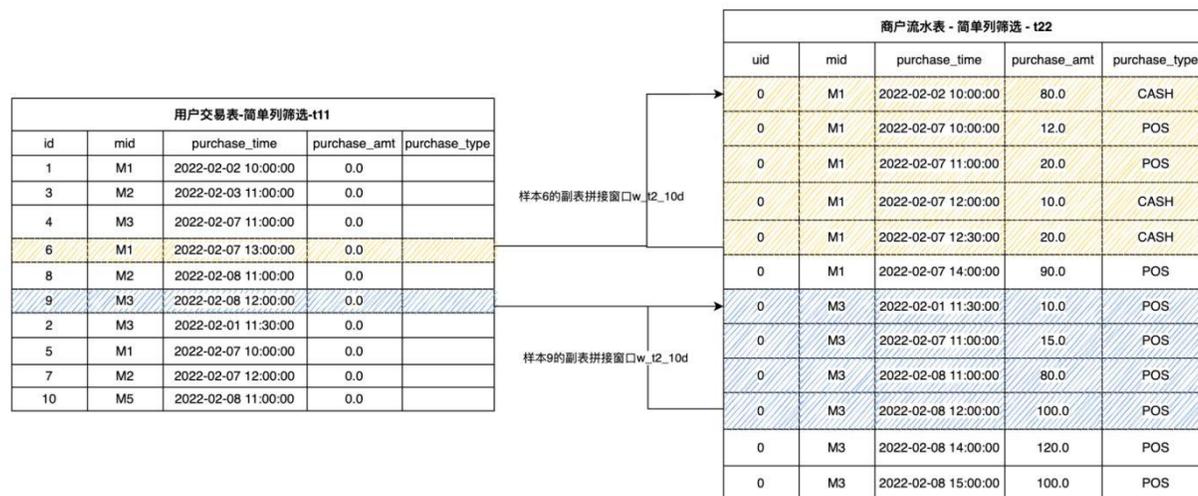
LAST JOIN

多行匹配时，仅匹配最新记录



WINDOW UNION

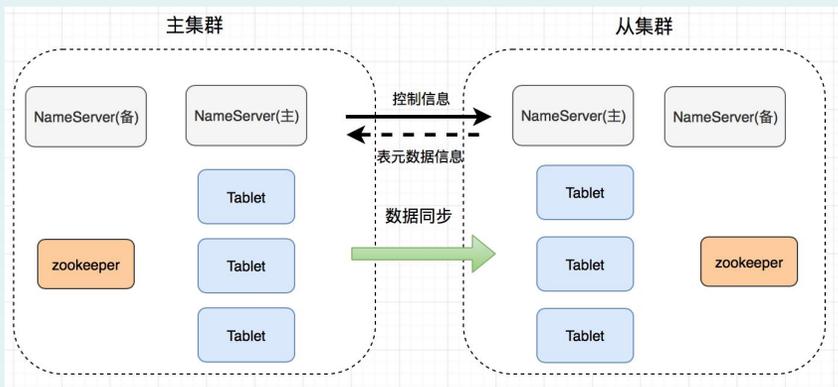
跨表的 join 和窗口聚合操作 (point-in-time), 避免特征穿越



▶ OpenMLDB 提供线上线下一致的实时特征计算 高级生产级特性，保证系统稳定性和可扩展性

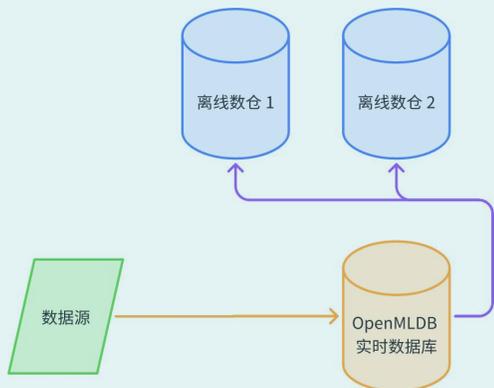
跨机房容灾

构建主从集群，进一步提升可靠性



自动化在离线数据同步

简化运维操作，保证数据一致性

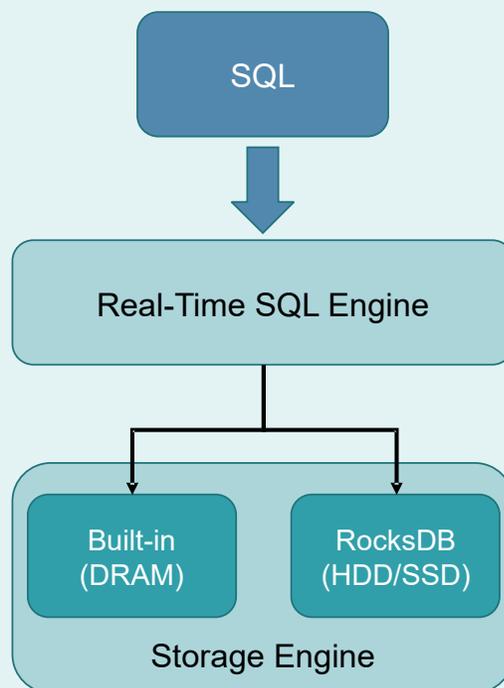


自动化同步

通过 OpenMLDB 同步工具，自动地实时或者定时同步到一个或者多个离线数仓。实时数据库依然只保存窗口内数据，离线存储保存全量数据。(0.8.0 以后版本可用)

线上内存/磁盘双引擎存储架构

平衡性能和成本



智能化运维和诊断

智能诊断 分片自动平衡 一键数据恢复



支持不同部署模式



OpenMLDB 原生形态部署

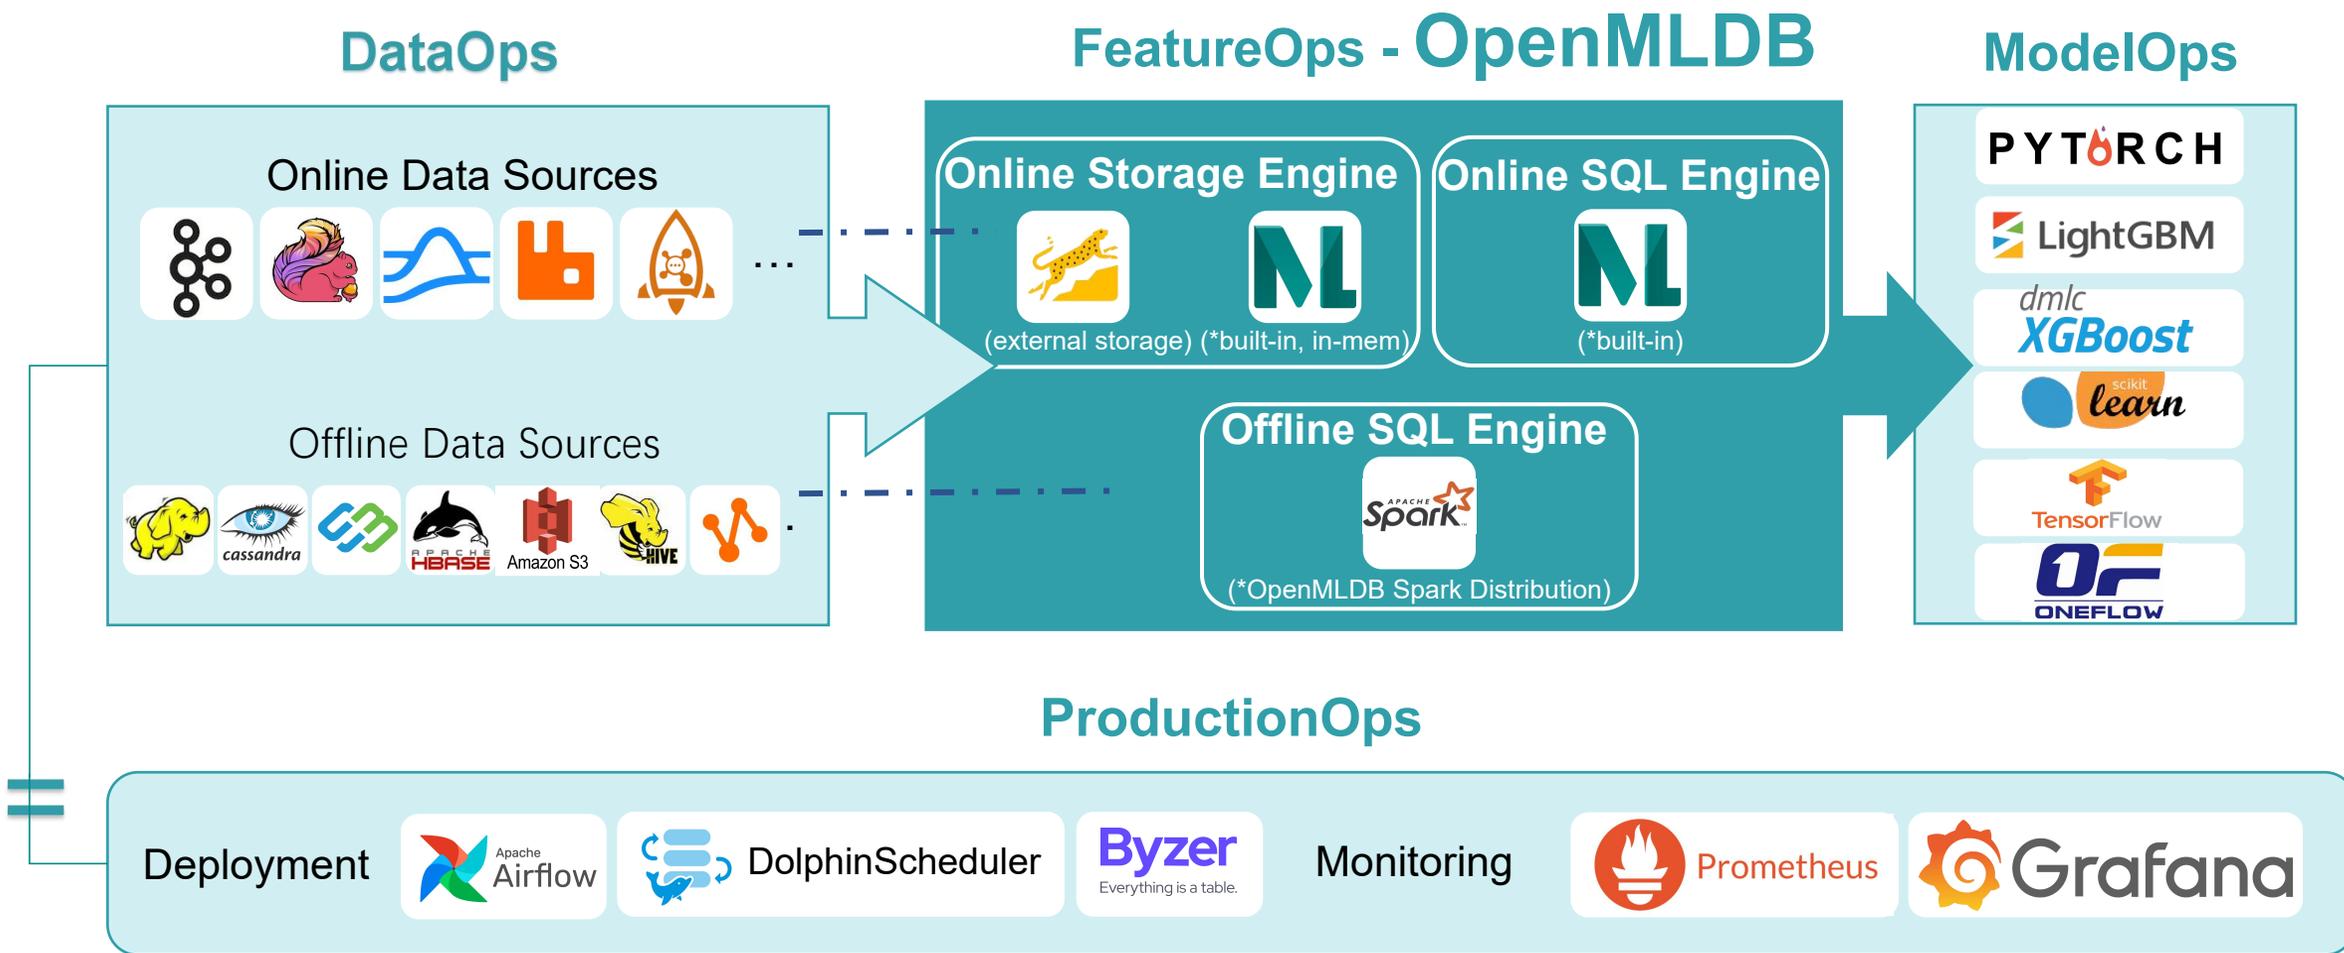
PART 03

社区生态和案例分享



▶ 社区生态和案例分享

OpenMLDB 上下游开源生态



▶ 社区生态和案例分享

基于 OpenMLDB 的特征平台

- 可视化特征开发和管理界面
- 基于 DAG 的大型复杂特征开发辅助
- 特征灵活复用
- 特征血缘管理和版本管理
- 同时支持毫秒级实时特征、离线特征

特征服务: s1 版本: v1 验证服务

名称	s1
版本	v1
特征名	v1:age,v1:name
数据库	db1
SQL	DEPLOY FEATURE_PLATFORM_s1_v1 OPTIONS (SKIP_INDEX_CHECK="TRUE") SELECT age,name FROM (select name, age from user)
Deployment	FEATURE_PLATFORM_s1_v1
描述	

特征

特征视图	特征名	类型	描述
v1	age	INTEGER	年龄
v1	name	VARCHAR	姓名

依赖表

数据库	表
db1	user

离线样本: 1

任务编号	1
特征名	v1:name,v1:age
路径	file:///tmp/d10
选项	
数据库	db1
SQL	select name, age from user INTO OUTFILE 'file:///tmp/d10' OPTIONS ()

离线任务: 1

任务编号	1
任务类型	ExportOfflineData
状态	FINISHED
开始时间	2023-10-21T11:14:02.880+00:00
结束时间	2023-10-21T11:14:14.243+00:00
参数	{var/folders/jz/df2p7wt50fd40w2y9kkm05h40000gn/T/sql-494314059763595228
集群	local[*]

▶ 社区生态和案例分享

OpenMLDB 案例 – Akulaku 智能计算架构中的特征平台



场景驱动: OpenMLDB

▶ 社区生态和案例分享

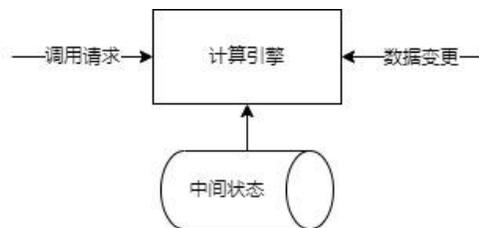
Akulaku 智能风控场景，对 10 亿条订单进行窗口特征计算，达到 4 毫秒延迟性能

特征计算环节难点

- 线上部署：低延迟，高时效性，尽可能反映数据变更
- 线下分析：高吞吐量
- 逻辑一致：线下分析和线上部署的逻辑需要完全一致

OpenMLDB 解决方案

- 场景驱动：业务调用环节驱动，实时计算结果，现用现算
- 具体方案：1) 使用SQL作为离线和在线的桥梁；2) 在线基于时序数据库做时间滑窗



```
(product_id:1, price:2, .update_time:100L )  
(product_id:1, price:3, .update_time:200L )  
  
(product_id:2, price:3, .update_time:1000L )  
(product_id:2, price:4, .update_time:1201L )  
(product_id:2, price:3.5, .update_time:1100L )
```

```
SELECT COUNT(*)  
FROM w100ms  
  
WINDOW w100ms AS  
(PARTITION BY product_id ORDER BY update_time  
ROWS_RANGE BETWEEN 100ms PRECEDING  
AND  
CURRENT ROW)
```

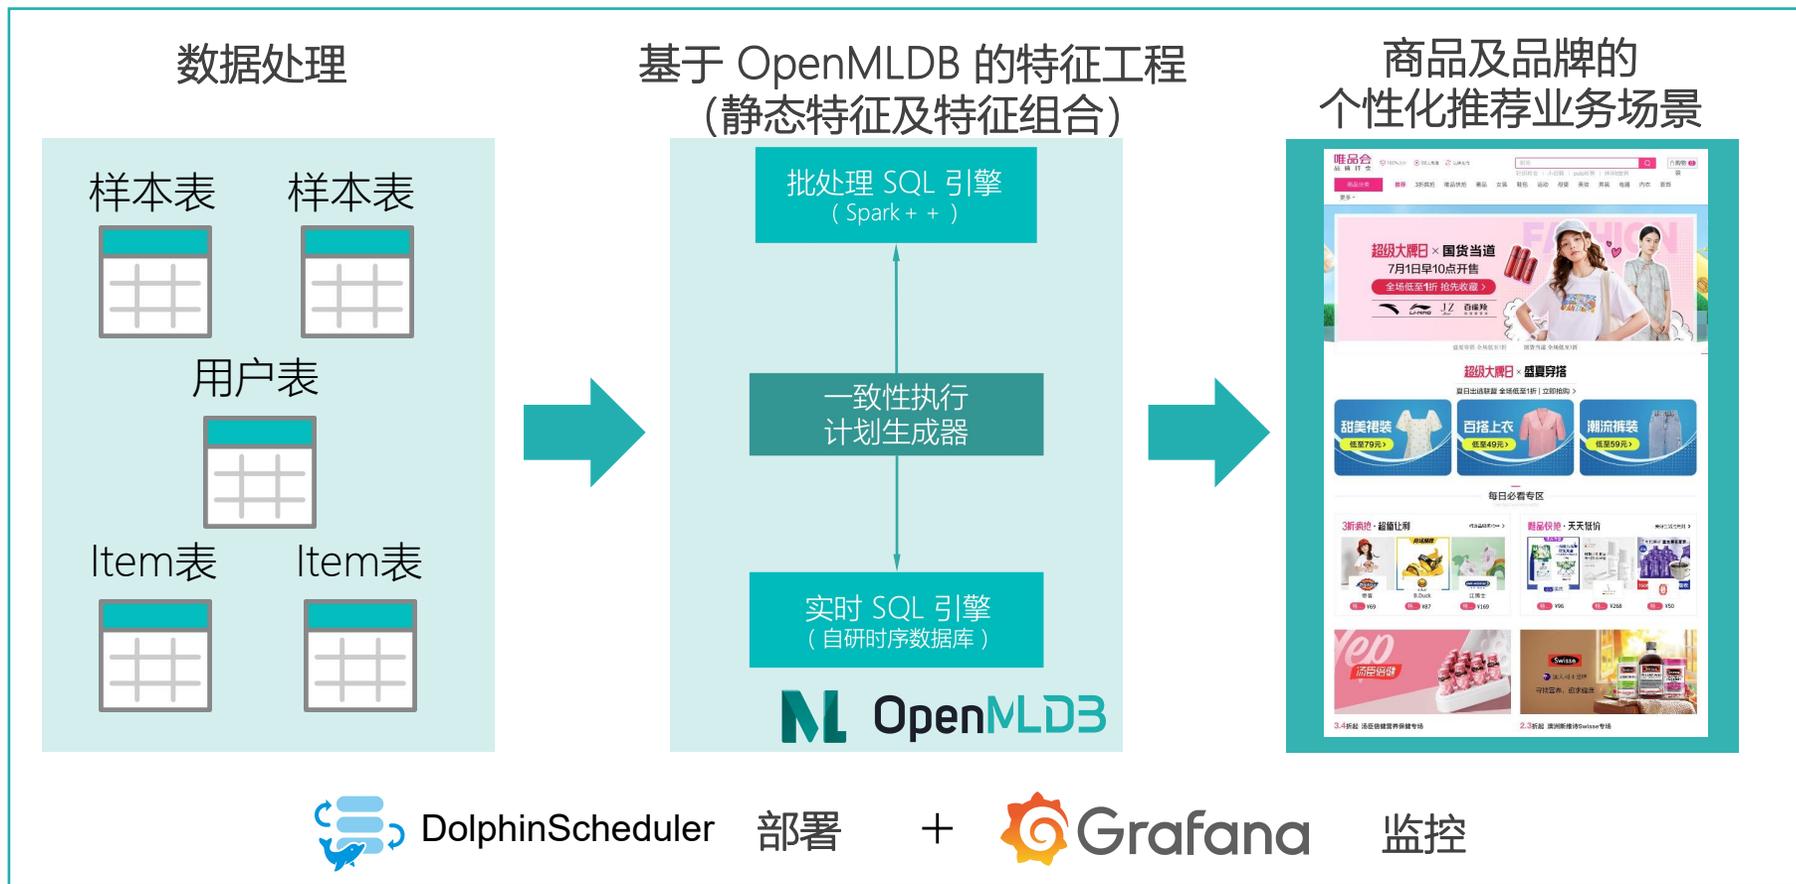
基于 OpenMLDB 的业务实现

- 场景：近1天订单个数实时计算
- 数据量：10亿条订单数据/天
- 需求：实时更新，时间窗口实时滑动，存在复杂关联需求
- 测试结果：4毫秒延迟



社区生态和案例分享

唯品会将 OpenMLDB 应用于商品及品牌个性化推荐场景，带来特征开发迭代速度60%的提升



特征开发迭代速度

5人天 → 2人天

注：
样本表：不同场景下的用户行为表，包括曝光点击收藏
用户表：用户侧所有用户画像信息
Item表：不同物料的全量信息表

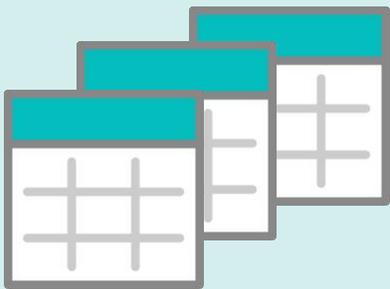
社区生态和案例分享

某头部ICT公司将 OpenMLDB 用于实时商品个性化推荐场景

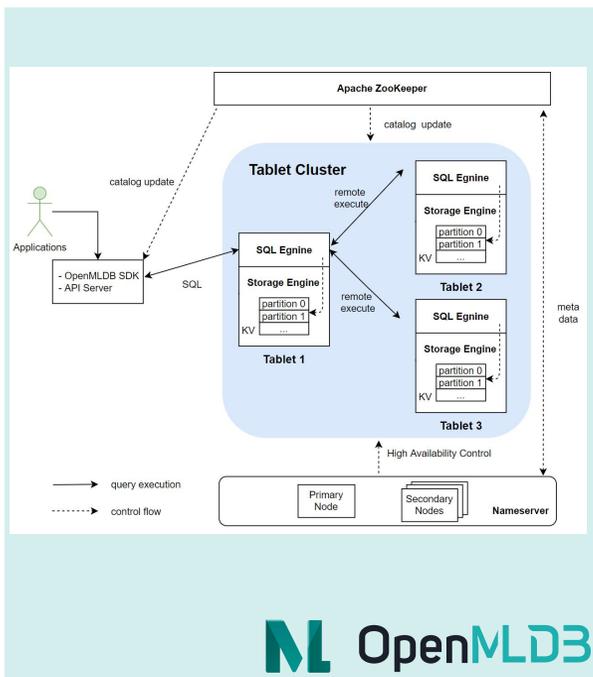
线上实时数据

- 数据分钟级更新
- 7.2亿条订单数据/天

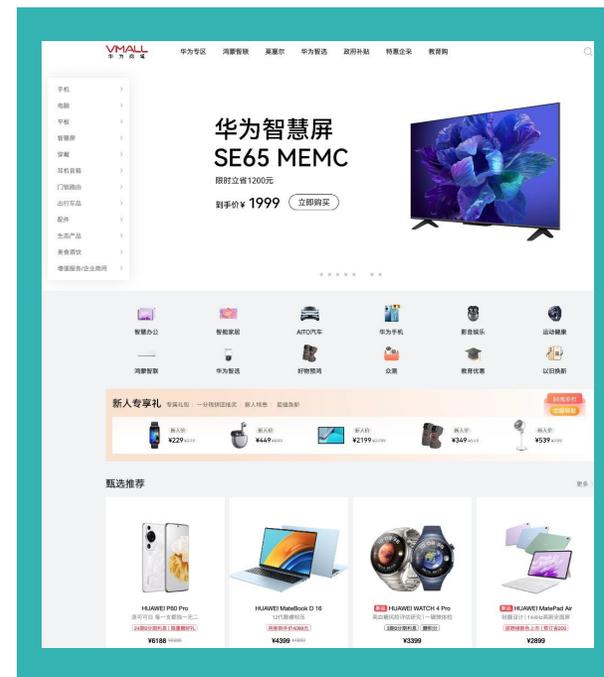
客户数据表



基于OpenMLDB的实时特征抽取



小时级特征上线



THANKS

