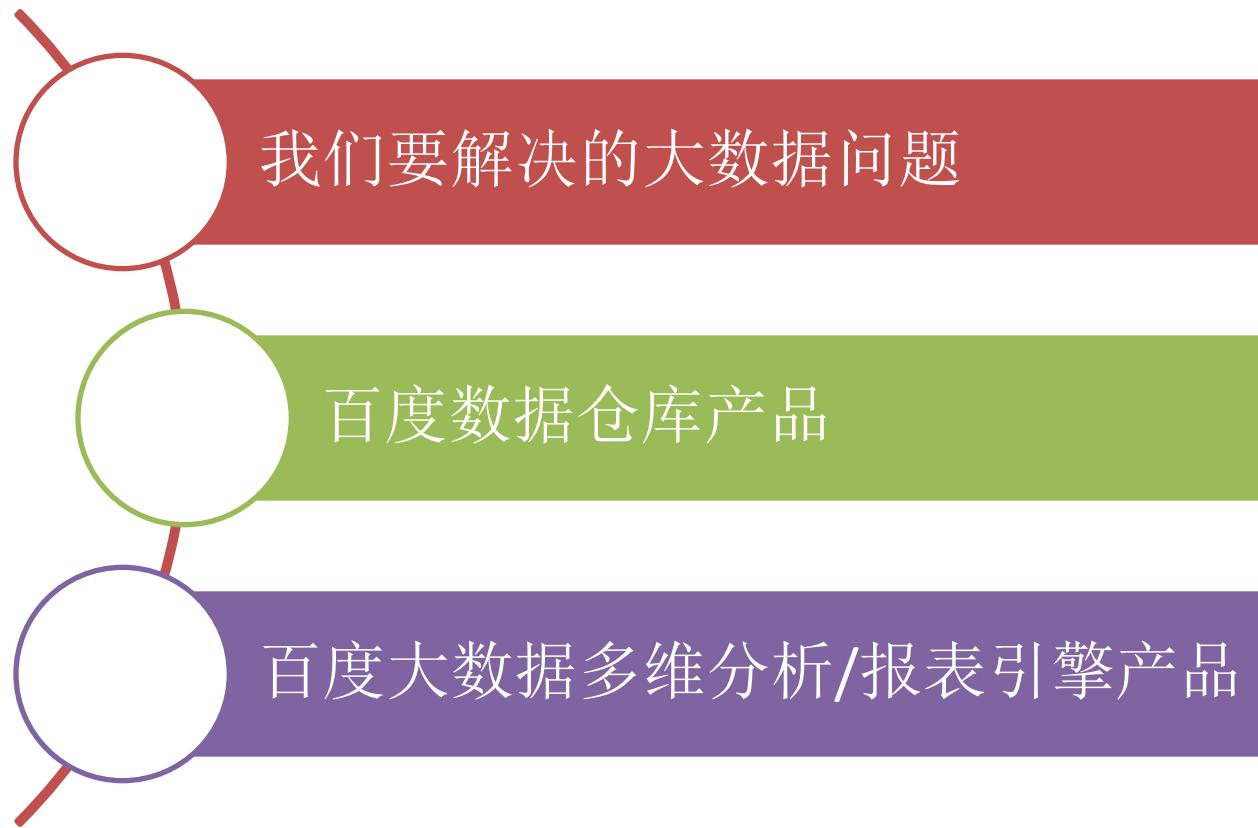


百度数据仓库体系介绍

刘立萍
liuliping@baidu.com
2012年11月27日

提纲



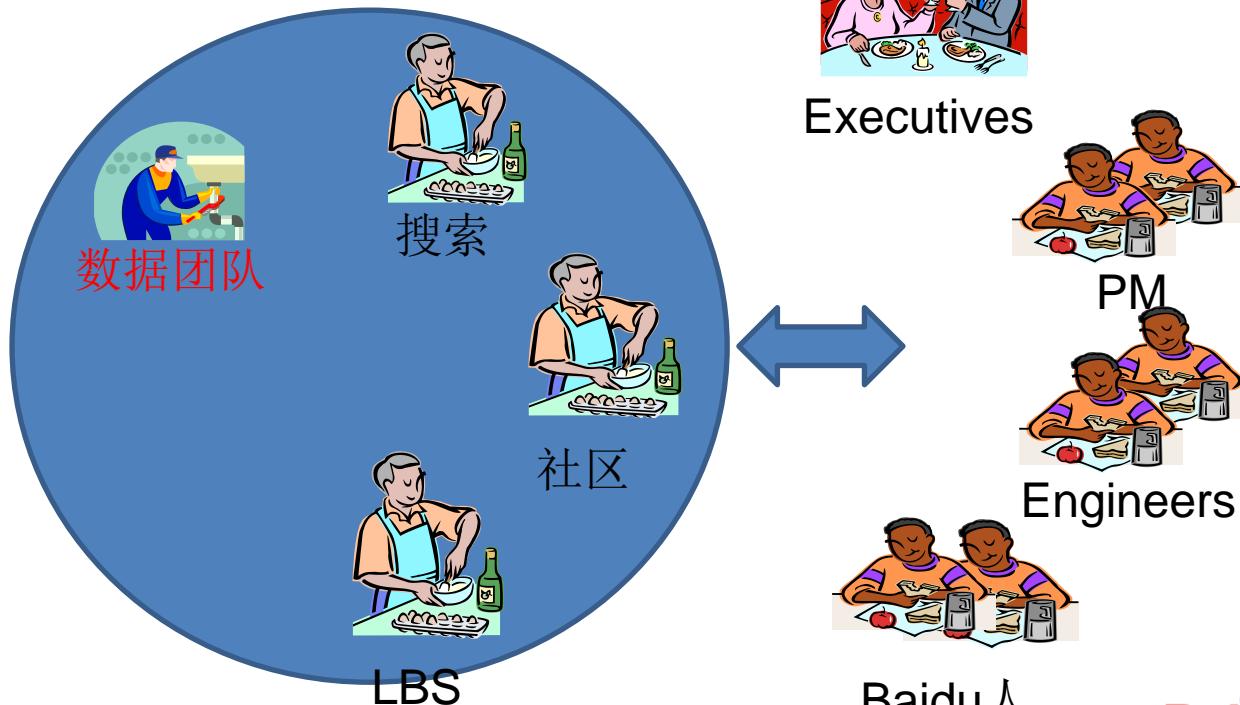
百度大数据应用

- 网页和超链 10PB-50PB
- 日志 100PB
- 数据仓库 80PB
- 广告 1TB

百度基础架构部数据团队

- 我们的职责：
 - 整合Baidu基础数据，构建数据平台，提供技术服务，推动数据处理，挖掘和应用

- 我们的用户：



基础架构部大数据平台

- 分布式存储
 - KV : Mola、
 - Table : CCDB
- 计算
 - 批量计算 : Abaci、Peta
 - 小批量计算: Mini-Batch Process
 - 流式计算 : Stream Process
- 调度
 - 底层资源管理 : Matrix
 - 上层通用调度 : Long-Scheduler
- 数据仓库体系
 - 格式化 : Logging/PB
 - 传输 : BigPipe、LogSaver
 - 数据仓库 : DW
 - 报表&多维分析引擎 : Doris
 - Ad Hoc 查询引擎 : Query Engine
 - BI : Baidu Insight



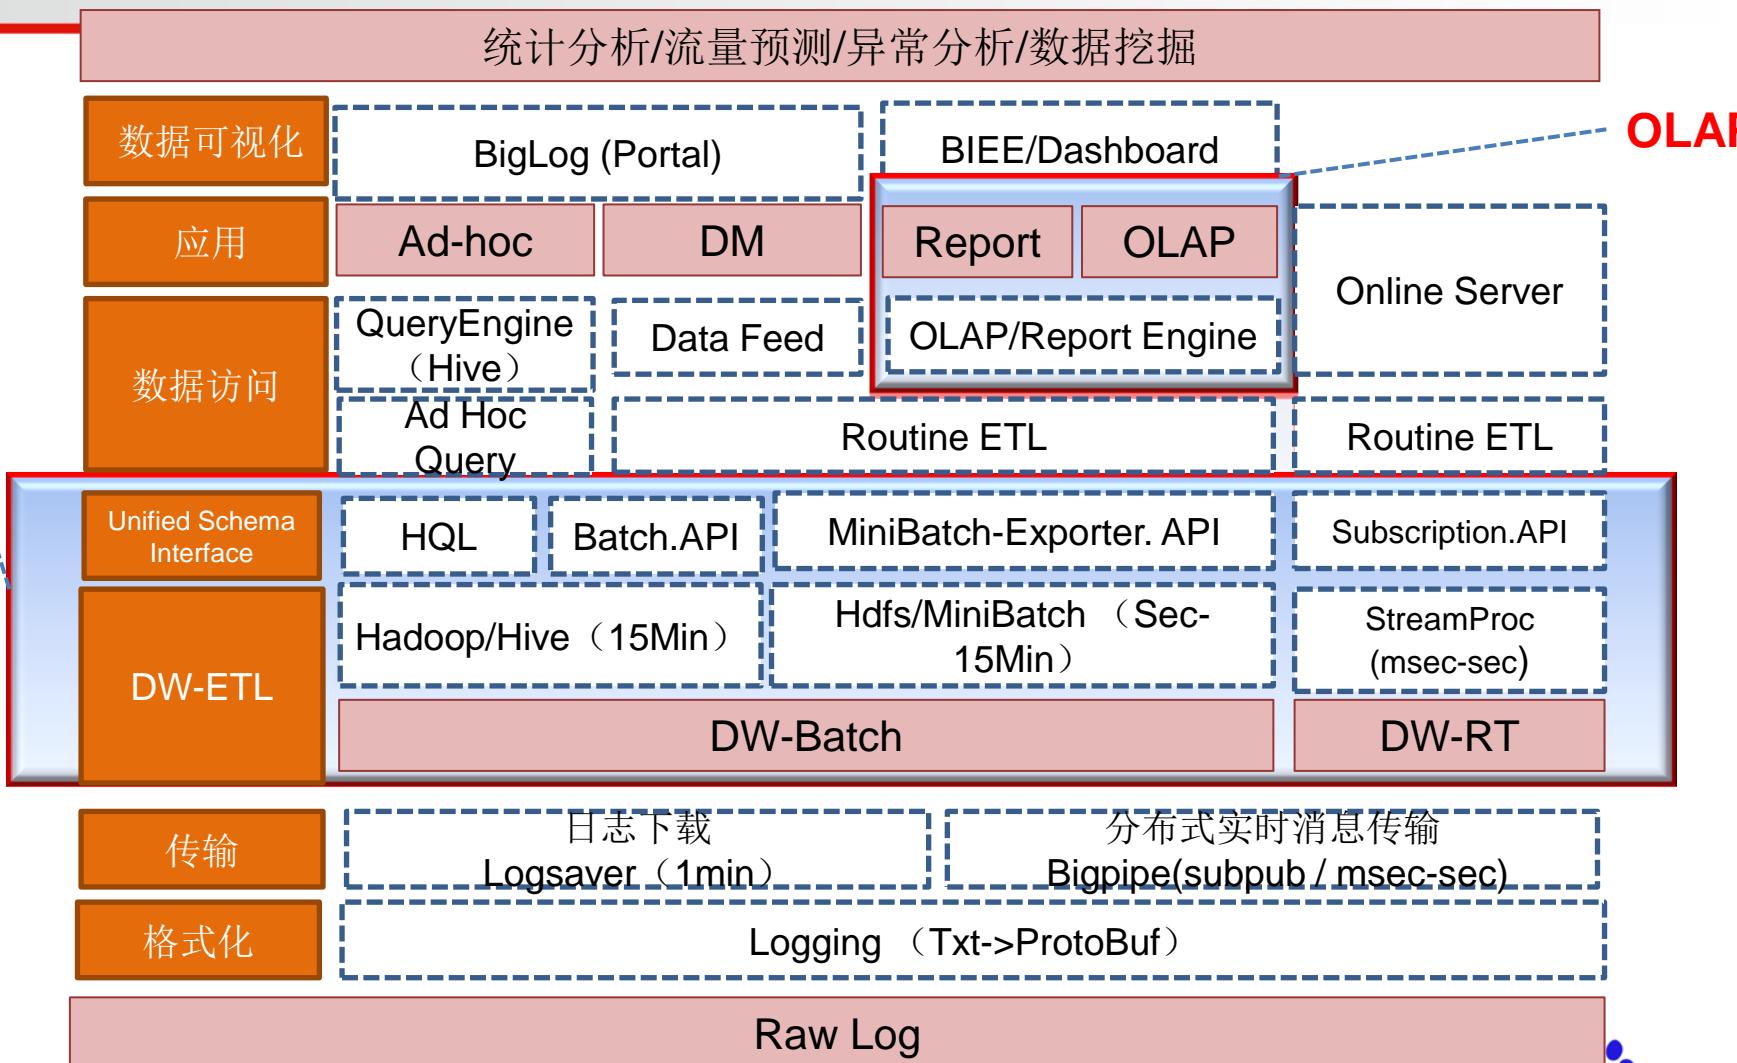
DW

DW设计目标

- 目标：
 - 应用场景：策略分析，统计分析，挖掘程序，DataFeeds
 - 用户：可以通过类SQL工具进行即席(Ad-hoc)查询，提高访问效率
- 思路：
 - 数据全，准确，一致
 - 易于理解：数据建模
 - 一致的数据结构
 - Fast IN：数据写入，由ETL效率决定
 - Fast OUT：数据访问，由吞吐率决定
- 价值：非结构化高价值数据治理，数据分层
 - 基础数据提供者
 - 数据集市（Data-Mart）：增加特定领域（Domain Specific）数据，逻辑，与DW搭配成为数据管理基本结构;特定领域数据主题分片，提速，固化领域逻辑
 - 可以隐藏99%的对原始日志访问需求

DW集成环境

DW



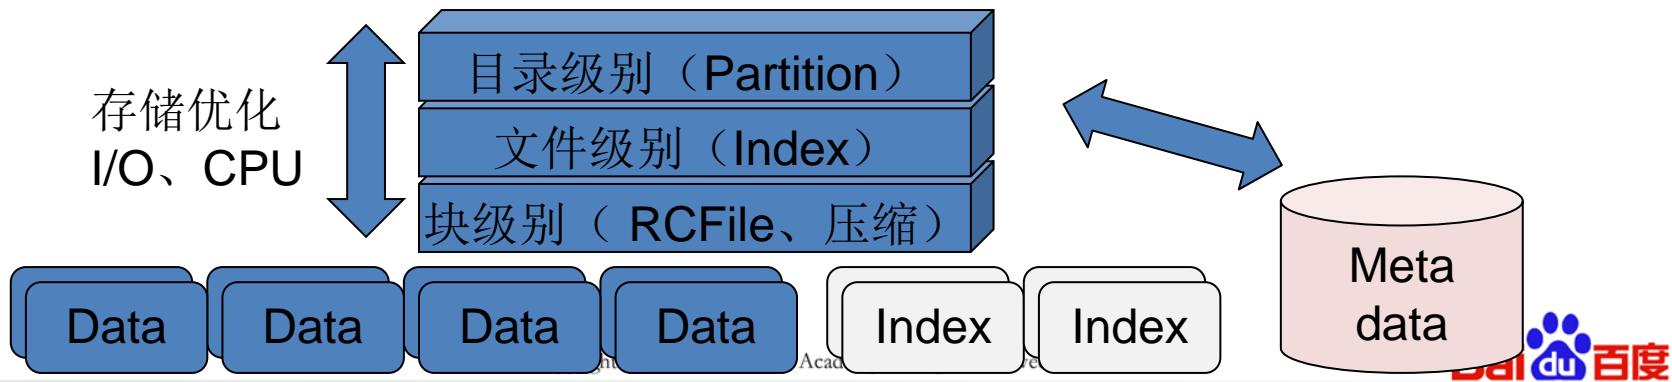
- 逻辑模型
 - 概念层、逻辑层、物理层
- ETL时效性
 - 引入实时流式计算模型：DW-RT（DAG）
 - 引入增量计算模型 Mini-Batch Computing : [Plan]
- 存储、访问优化 [Doing]
 - Index
 - 列式存储
 - PAPI性能优化

逻辑层次

主题:概念表



物理层次



ETL时效性：DW-RT

- 内核基于百度流式计算系统

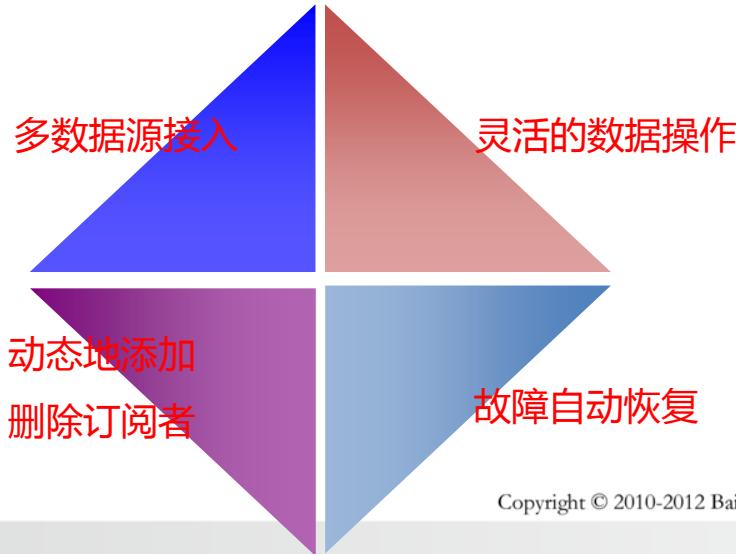
- 高性能DAG流式处理系统
- Process Node \leftrightarrow Task tracker
- Process Element (PE) \leftrightarrow Mapper/Reducer
- Processor \rightarrow N * PE (多并发)
- 故障的PE会被自动重启或迁移，在恢复过程中丢失数据

- 灵活数据操作：

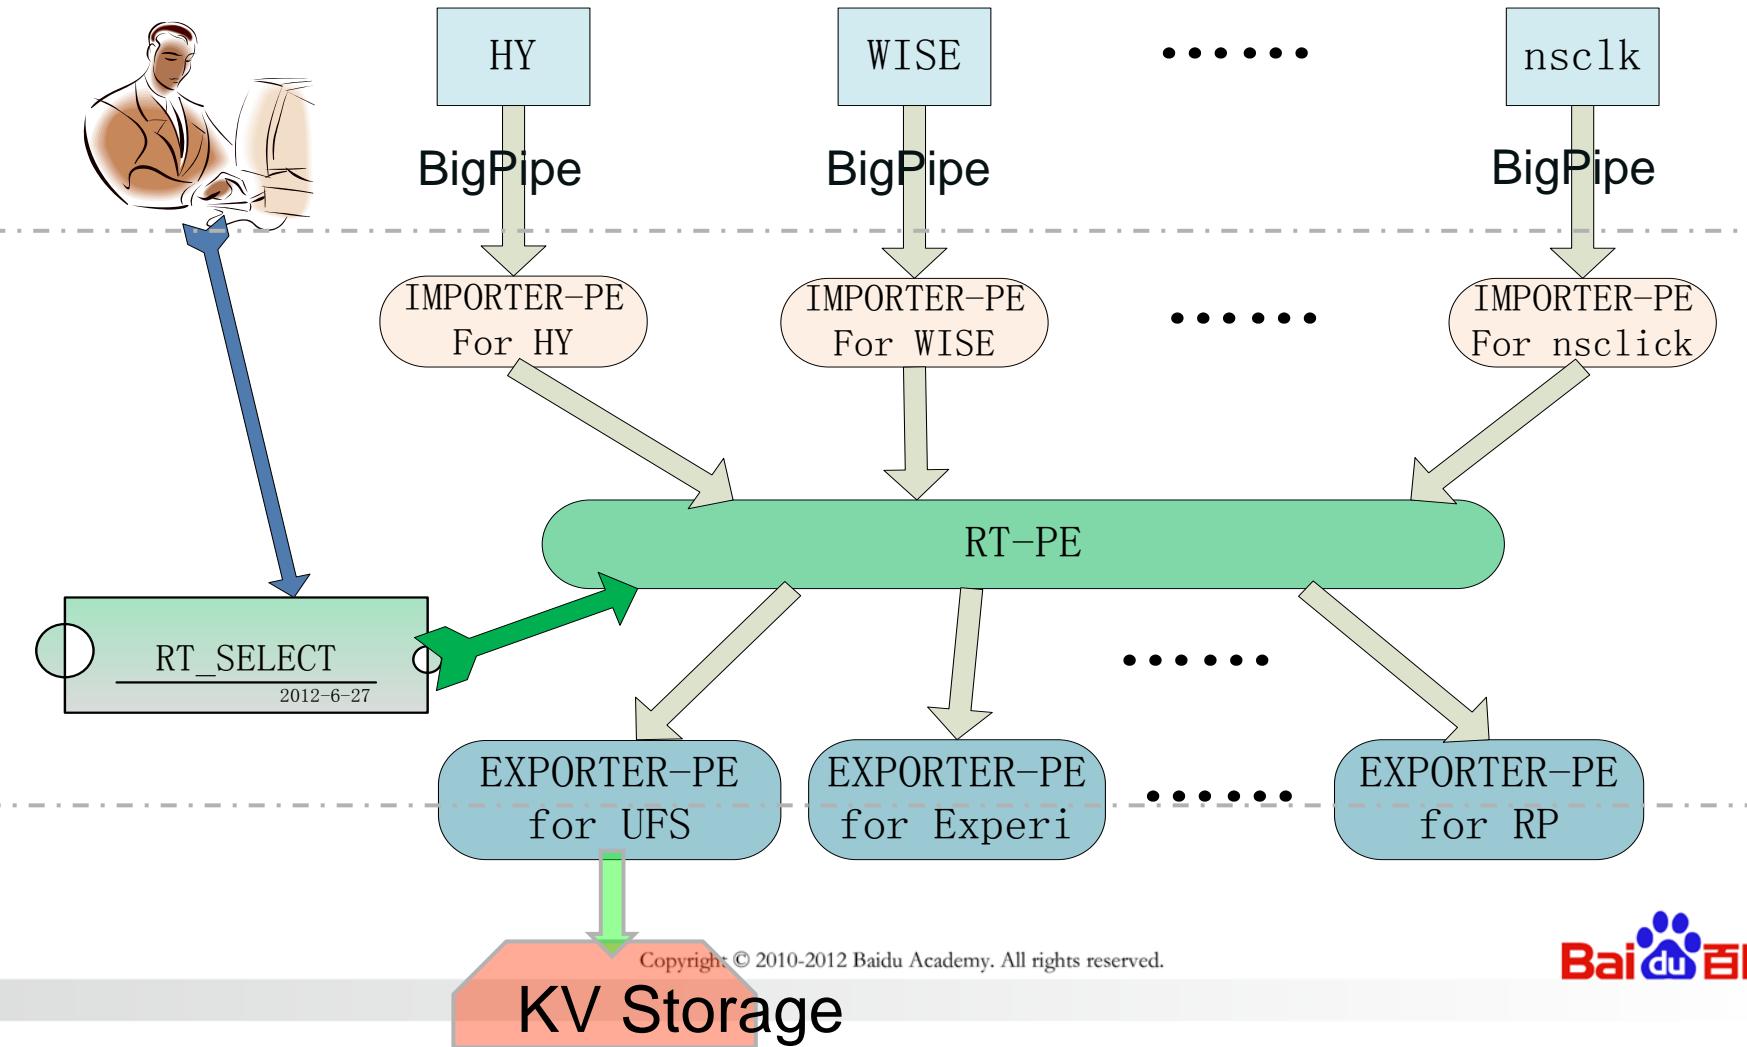
- 物理源 \rightarrow 逻辑源 \rightarrow 新的逻辑源
- SQL-LIKE、三种数据操作
 - filter ...
 - project ...
 - union

- 动态修改订阅者：调研任务支持

- 逻辑/物理源都可被订阅
- 通过客户端订阅数据源，即时获得数据
- 订阅者隔离
- 动态扩容



DW-RT工作流图



- 提高基础数据覆盖率：
- 数据模型完善：
- 提供更好/更高效的ETL 框架: DW ETL , DM ETL , 统计ETL , Data Feed ETL , DataMart ETL
- 新的存储技术的考虑，如Column IO etc.
- 增量小批量处理技术在ETL中的应用
- 跨机房/集群的数据存储和访问，数据同步
- 异构数据的ETL和访问

OLAP

OLAP设计目标

- 问题：
 - 提供用户数据报表后台引擎：商业产品/用户产品分析报表
 - 定制报表 + OLAP 报表
- 要求：
 - 95%查询响应时间 < 10 sec
 - 可以对最细粒度数据进行统计和访问
 - 7*24h，服务可用性>99.999%
 - 容量100T+

- 星型多维数据模型：
 - Fact Table：维度id与事实（指标）
 - Dimension Table：维度id与分层维度描述
- 计算模型
 - Rollup/Drilldown
 - 计算相对简单
 - 事实表：select / group by / aggregate / filter / sort
 - 维度表：select / filter
 - 事实表结果与维度表结果大小表Join
- 思路
 - 并行查询 + 行列式存储

- 优化方法

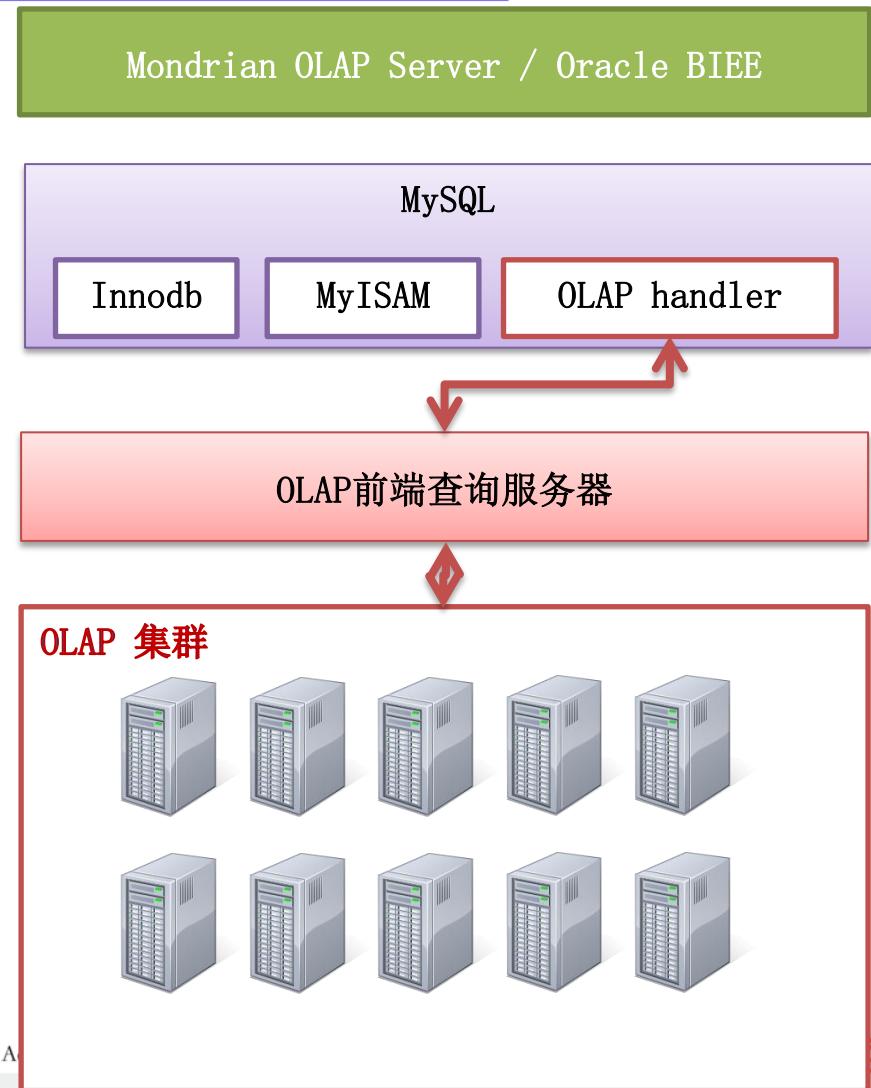
- 单机扫描能力做到极致
- 多机并行汇聚查询
- 减少扫描量
 - 物化视图：对某些维度的组合聚合结果的预计算
 - 索引
 - 压缩：根据数据特点的高压缩比算法
 - 按列存储
- 提高写入速度
 - 上游接小批量实时计算系统
 - 增量数据更新

OLAP Engine Intro

- **核心技术**
 - 可扩展性：
 - 数据分布式存储
 - 行列组织：
 - Row-group : Sorted Keys Range +数据量切分 (1GB)
 - Column: 压缩比>15:1
 - 并行查询
 - 自动选择最优化视图
 - 支持SQL92、和Mysql结合
 - **设计原则**
 - 简单有效
 - 业务需求驱动
 - **功能**
 - 多视图、多索引
 - Schema change
 - 多版本视图间Transaction更新

OLAP Engine Intro (cont.)

- 系统性能指标 (100 节点)
 - 规模 : 总量 500T ; 更新 1T/Day;
 - 日查询量 : 2亿 ;
 - 最大导入速度 : 300MB/s
 - 单节点最大扫描速度 : 1.5GB/s
 - 平均响应时间 : msec ; 大查询 <10sec
 - Max QPS : 5000;
 - 查询成功率: 99.999%
- TODOs
 - 计算层 : 分布式排序、Join
 - 存储层 : 按列存储
 - 运维 : 数据恢复流程优化



谢谢