DTCC

2016中国数据库技术大会

DATABASE TECHNOLOGY CONFERENCE CHINA 2016

数 据 定 义 未 来

SequeMedia 盛拓传媒 IT168.com ChinaUnix ITPUB

常冰琳
小米工程师 Apache Kudu(Incubator) PPMC & Committer

使用KUDU搭建OLAP服务

目录

- 现状
- Kudu目标和设计
- OLAP服务架构
- 性能测试

现状

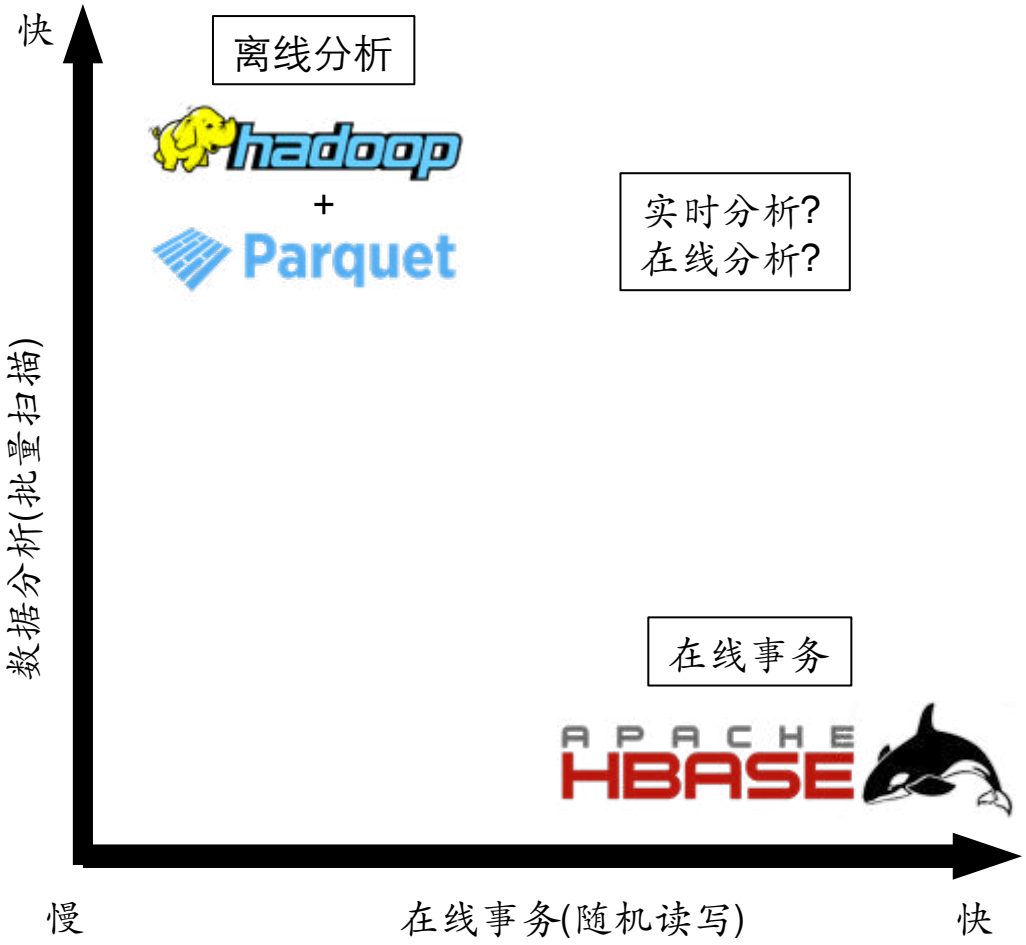

HDFS

- 批量写入
- 顺序扫描
- 批量离线分析

HBase

- 随机读写
- 高可用性
- 在线事务处理

如何能够实时分析在线事务系统实时产生的数据?
如何能够提供在线分析服务?

设计目标

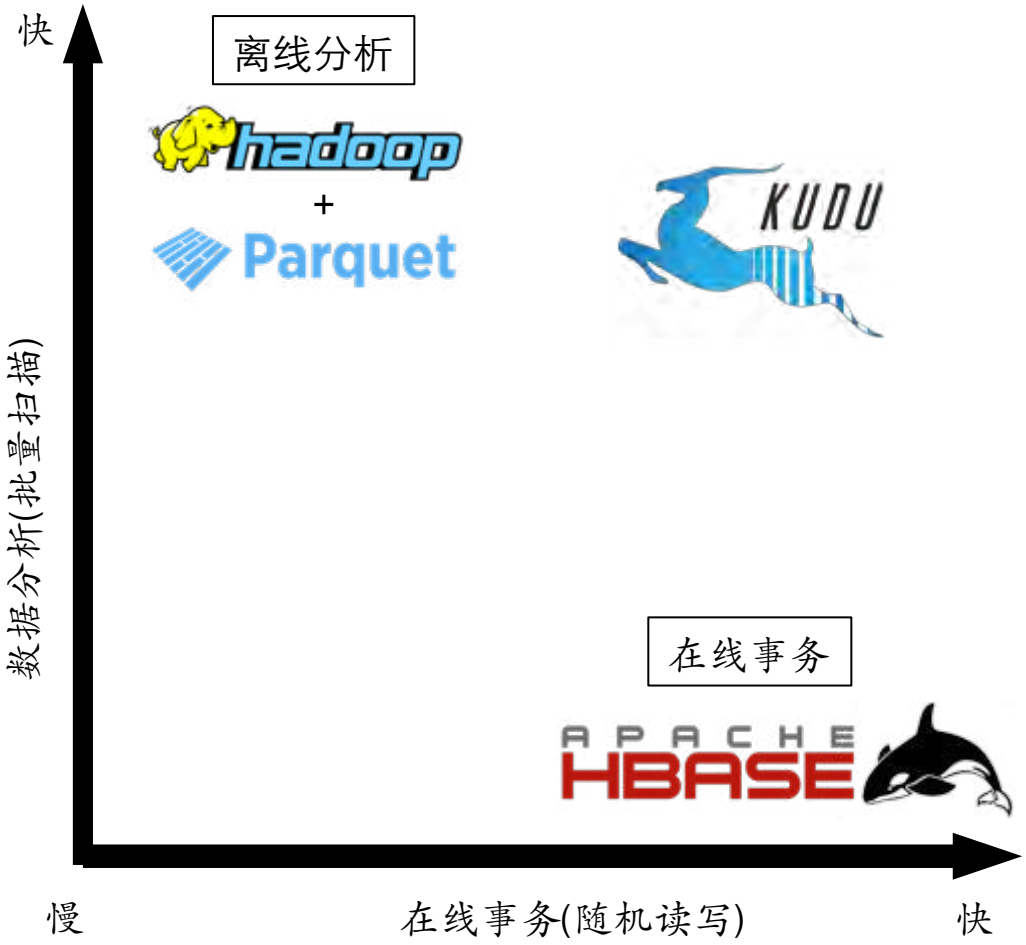

支持随机读写
- 接近HBase的吞吐性能
- 更低的延迟：1ms (SSD)

高性能的顺序读
- 接近HDFS的读性能
- 列存储，接近Parquet性能

高可用
- Raft一致性协议

类关系数据库数据模型
- 支持事务(单行)
- 计算引擎支持 Impala/Spark/Drill/...

设计目标-新硬件趋势

- 存储越来越快
  - NAND Flash
    - 450K read/250K write IOPS
  - 3D Xpoint
    - 性能接近内存，但是可持久化
    - 性能比NAND还要快1000倍
- 内存越来越大
- CPU成为新瓶颈，存储系统需要优化CPU
- 列存储应用在线事务系统也是可行的

应用场景-HDFS

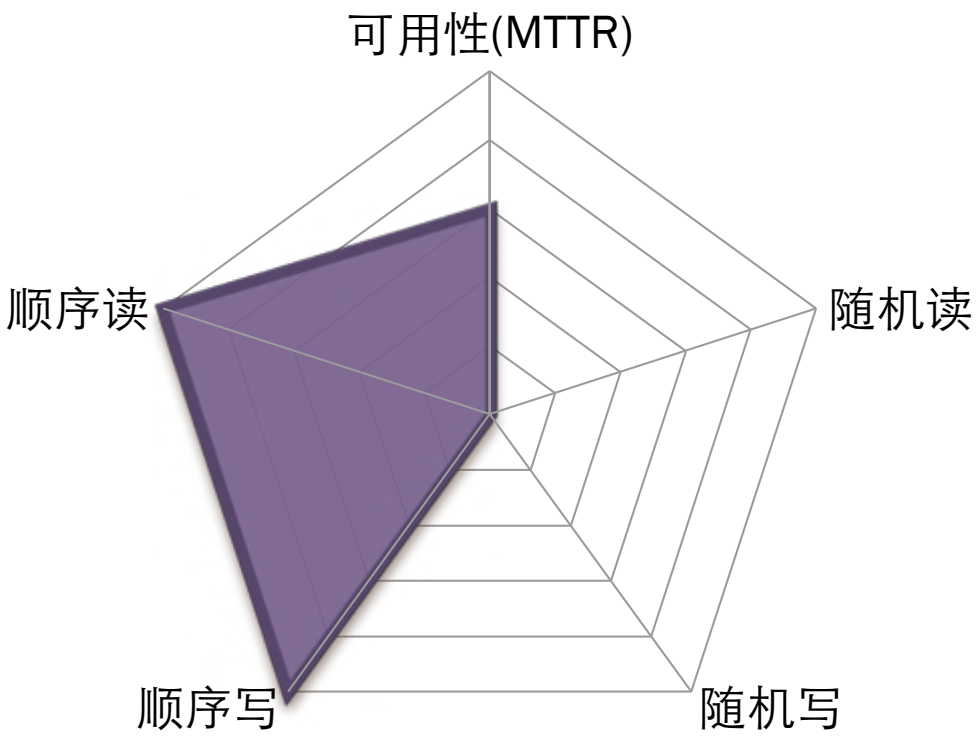

HDFS

- 离线数据存储
- ETL等预处理
- 复杂分析

应用场景

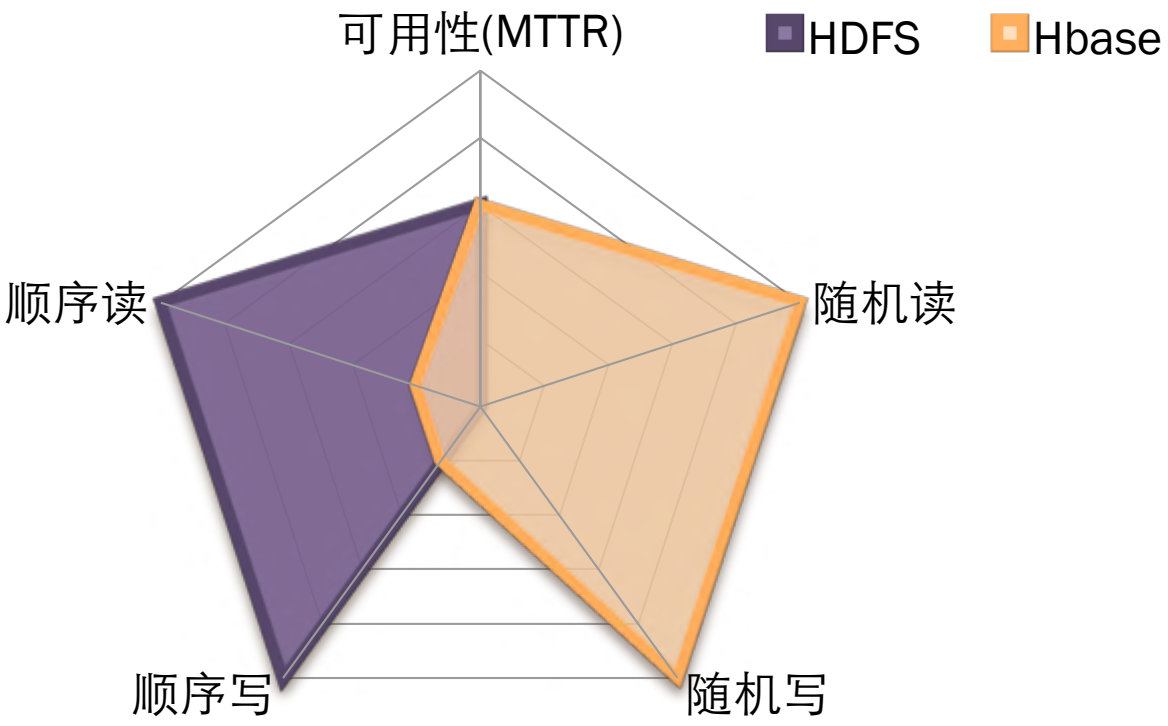

HBase

- 在线事务处理
- 计算中的随机查询
- 流计算状态存储

应用场景

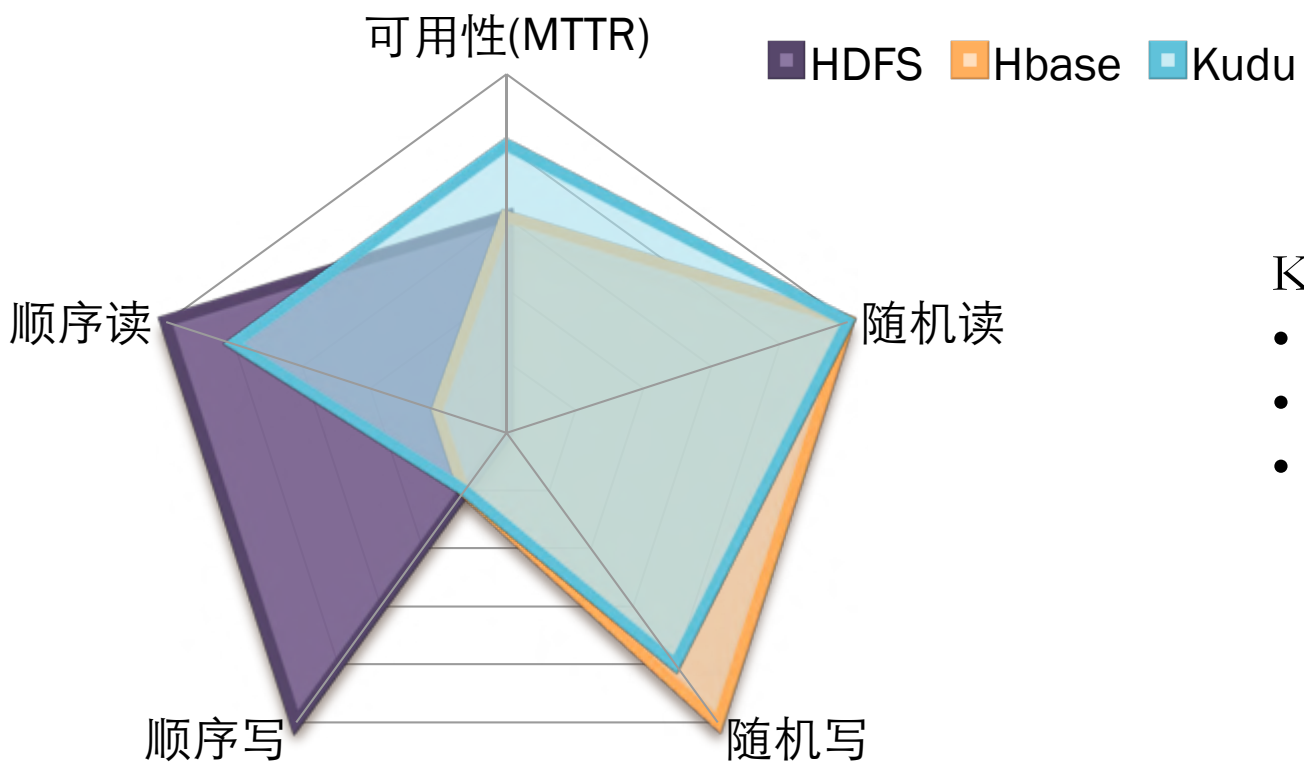

Kudu

- 在线分析
- 实时数据分析
- 事务数据分析

历史

- 2012.10 Cloudera发起
- 2014.9 小米加入
- 2015.10 对外公布，发布Beta版本
- 2015.11 Apache Incubator
- 2015.12 小米生产环境上线
- 2016Q3 计划1.0 Release

介绍–数据模型和使用

- 数据模型：类似关系数据库表
  - 有限固定列，支持alter table
  - 强类型(bool，int8/16/32/64, float/double, string etc.)
  - 主键索引（支持多列)
- NoSQL API
  - Insert/Update/Delete/Scan/Get*
  - C++/Java/Python
- Hadoop生态集成
  - Impala/Spark/Drill/MapReduce/Ibis(Python)

介绍-分区

Range Parition

Hash Partition

Range + Hash

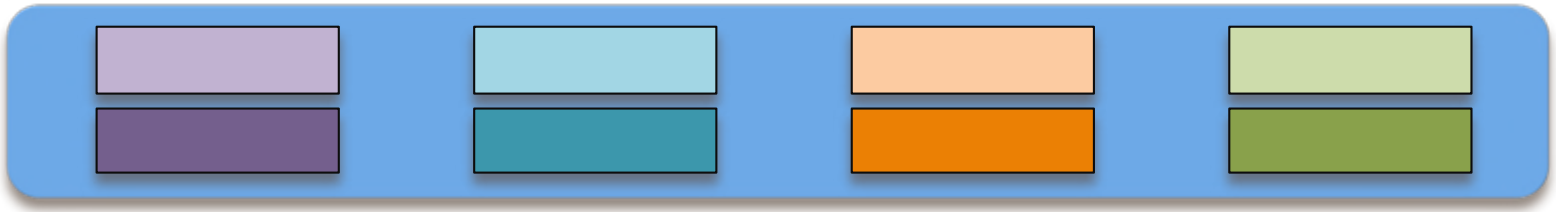

社区新进展：Range分区支持非全覆盖，动态修改

适合日志和时间序列，维护一个动态时间窗口

例如：每天动态生成新分区，删除几天前的老分区

介绍-副本

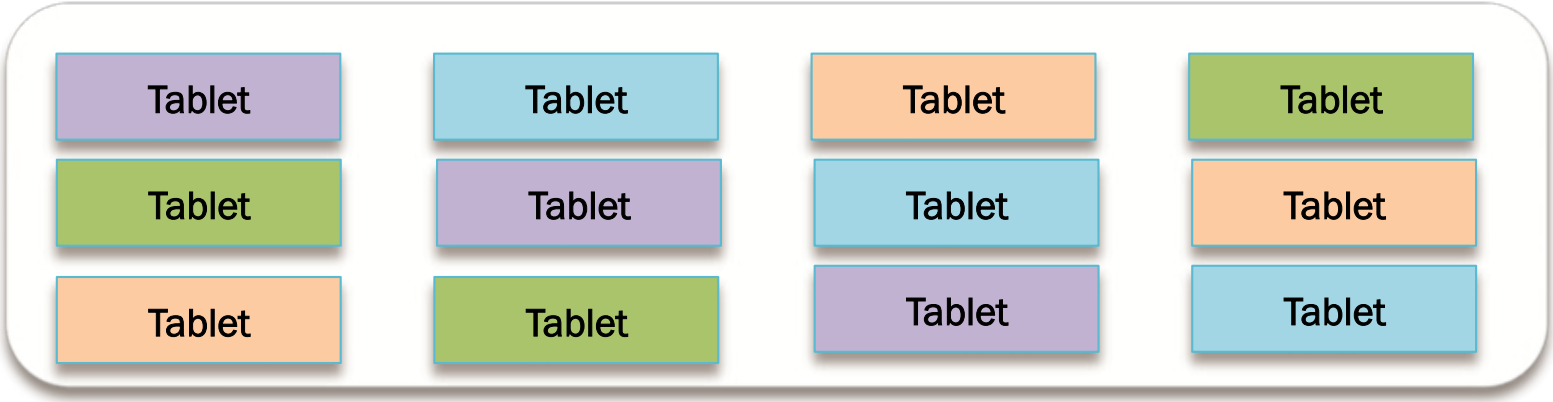

每个Tablet维护多个(3或5)副本，使用Raft一致性协议

- 强一致
- 低延迟: 多数写成功即可返回(没有gc和大compaction)
- 高可用: 低MTTR, Leader失败检测+重选主时间短
- 允许从Follower进行Snapshot Read
- HybridTime支持外部一致性(类似Google Spanner)

介绍-容错

- Follower临时失败
  - Leader仍可取得多数，不影响读写
  - 5分钟内恢复，仍然可以重新加入
- Leader临时失败
  - 心跳停止，follow心跳超时后重新选主
  - 5分钟内恢复，变为follower
- 永久失败
  - 踢掉该follower，master重选一个replica
  - 从leader拷贝数据后，加入成为新的follower

介绍–集群

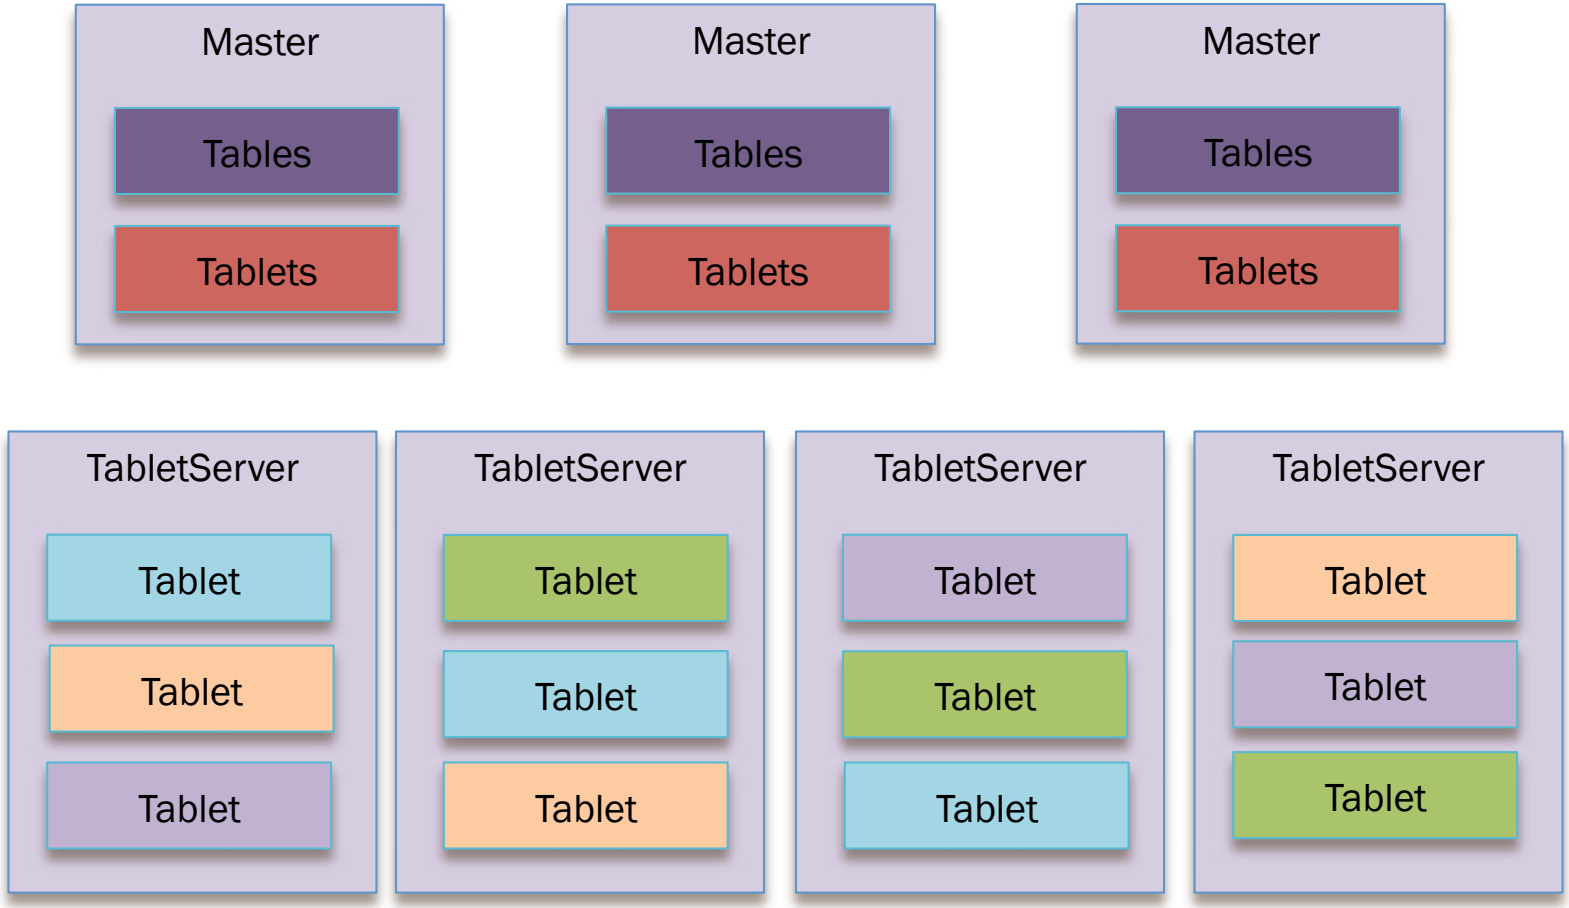
Master
Tables
Tablets
Master
Tables
Tablets
Master
Tables
Tablets
TabletServer
Tablet
Tablet
Tablet
TabletServer
Tablet
Tablet
Tablet
TabletServer
Tablet
Tablet
Tablet
TabletServer
Tablet
Tablet
Tablet

介绍-MASTER

- 类似TabletServer，Raft保证多副本一致性
- 管理两个元表(Tables, Tablets)
- Tables
  - 表的schema，parititon等元数据
- Tablets
  - 所有tablet的元信息,状态信息(tablet到tablet server映射)
- 所有元数据缓存在内存
  - 查询非常快(99.99th<1ms)
- 客户端缓存
  - 减少与maser通信，避免master压力过大

介绍-TABLET存储设计

- 类似LSM(Hbase/BigTable)，但不完全相同
- 每个Tablet包含：
  - 一个MemoryRowSet(MRS)
  - 多个DiskRowSet(DRS)，列存储，类似parquet
- Insert写入MRS，MRS满或者定时Flush为DRS

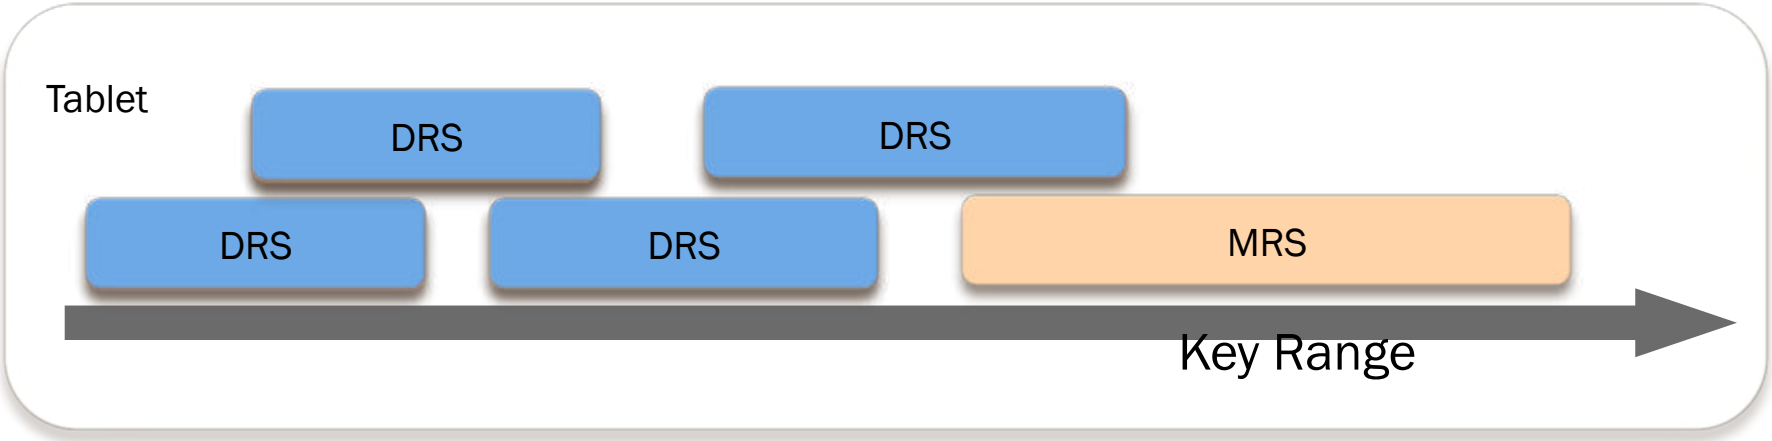

DELTA COMPACTION

Before

读最新数据需要合并base和redo

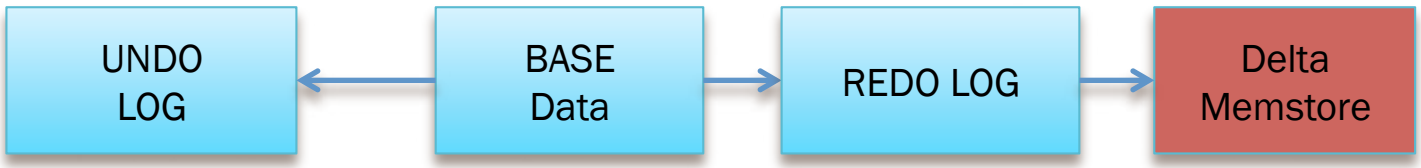

After

读最新数据仅需要读取base

ROWSET COMPACTION

- DRS区间覆盖过多影响读写效率
- Compaction减少区间覆盖
- 频繁地做小规模Compaction，不做大Compaction
- 每次Compaction 严格限制IO量(128MB)
- 对随机读写延迟影响很小
- 顺序写不会导致Compaction

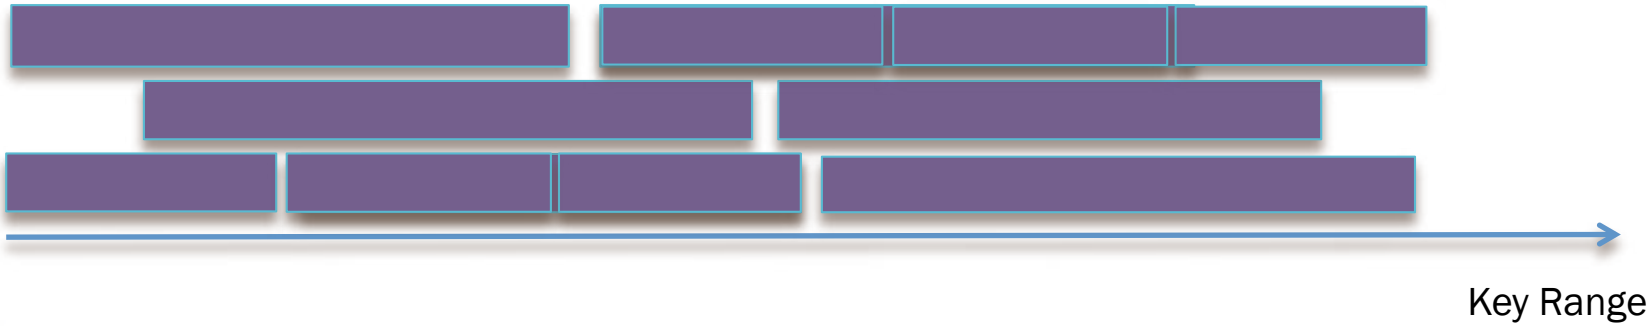

传统数据流

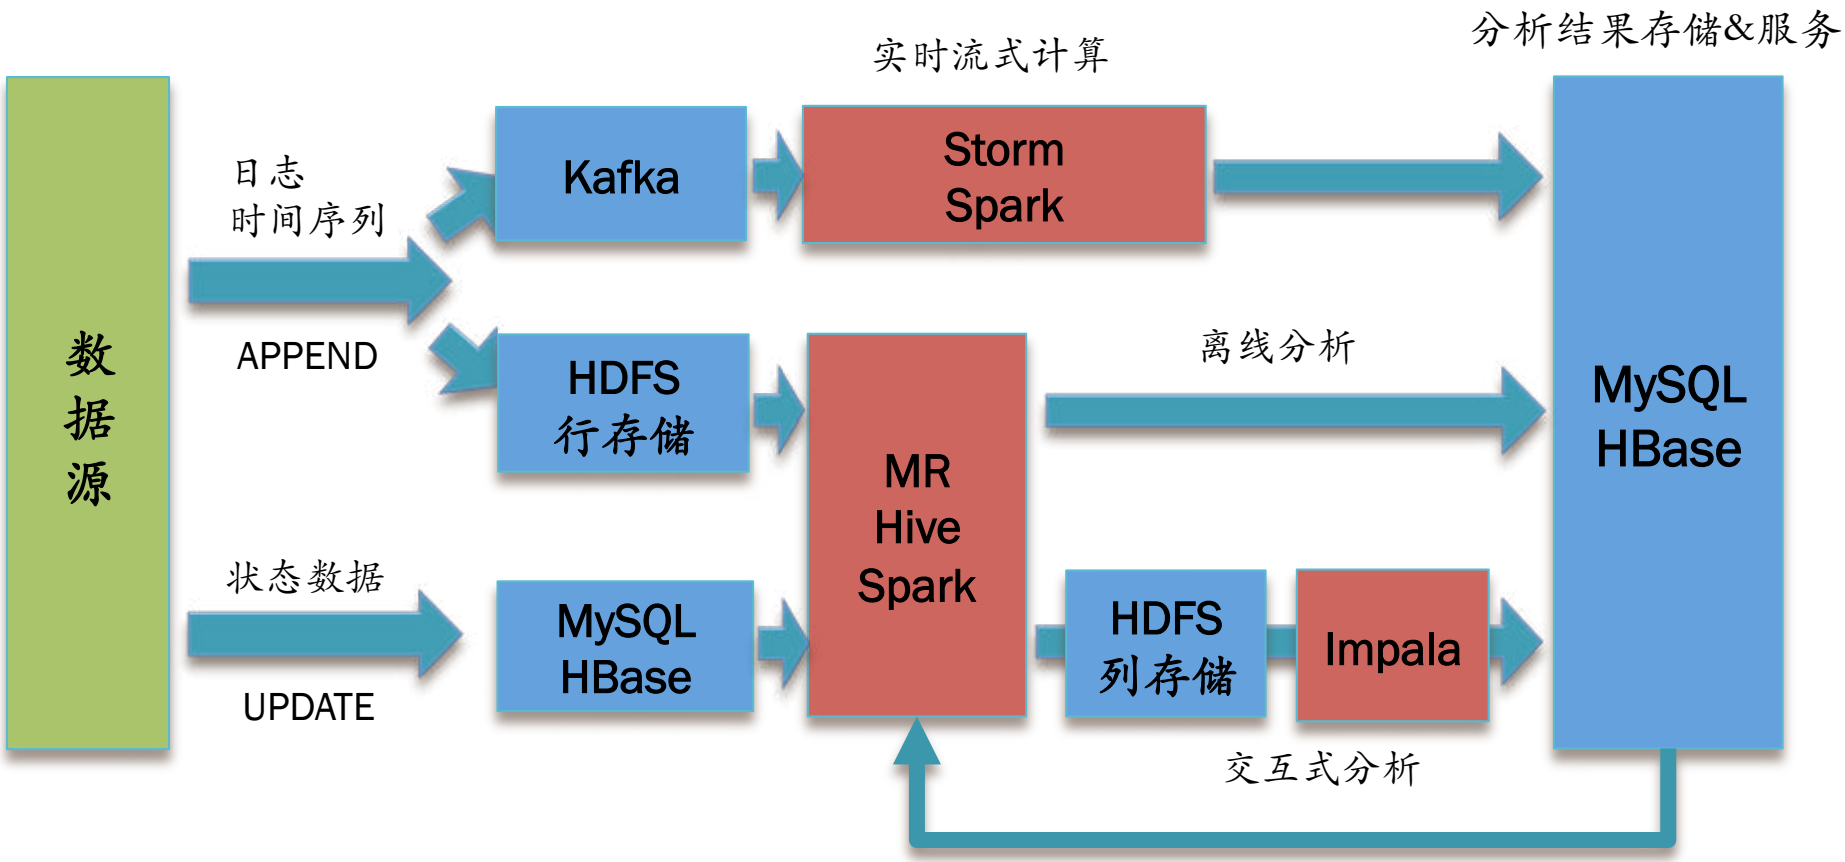
分析结果存储&服务
实时流式计算
数据源
日志
时间序列
APPEND
Kafka
Storm
Spark
HDFS
行存储
MR
Hive
Spark
离线分析
MySQL
HBase
状态数据
UPDATE
MySQL
HBase
HDFS
列存储
Impala
交互式分析

KUDU数据流

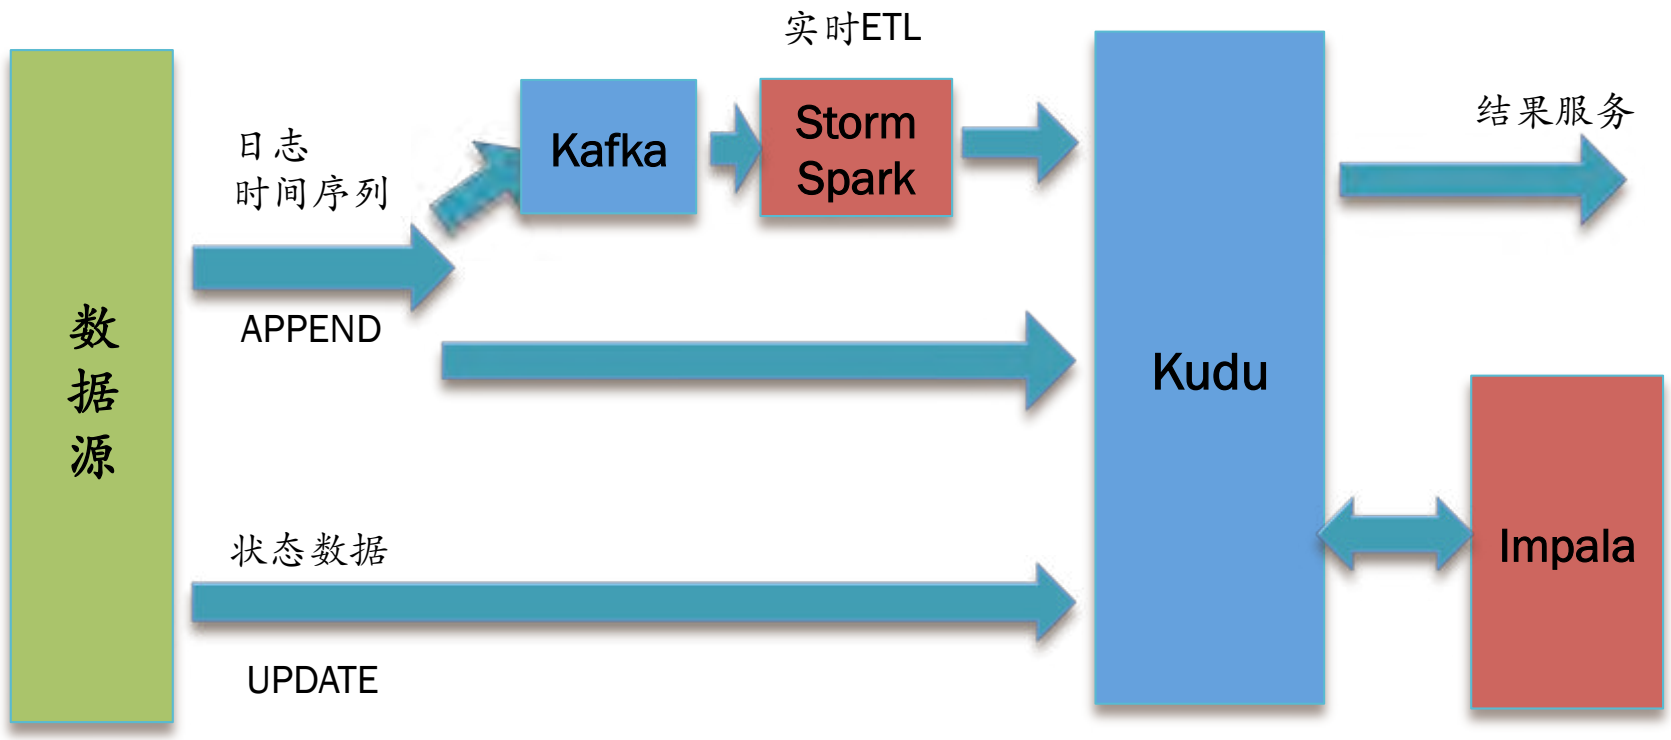
实时ETL
数据源
日志
时间序列
Kafka
Storm
Spark
结果服务
APPEND
Kudu
Impala
状态数据
UPDATE

KUDU优势–统一数据存储

- 简化数据流，降低延迟
  - 不需要定时从行存储转化为列存储
  - 支持需要update的分析型应用
- 统一元数据和存储格式
  - 避免数据格式转化和不一致问题
- 分析结果存储和服务
  - 分析结果重复使用
  - 统一SQL管理

KUDU优势–事务和主键索引

- 事务型存储，主键索引
  - 存储层支持去重，Exactly Once语义
  - 简化计算层容错处理
- 数据到达时间有延迟
  - 可按时间排序，简化或加速分析处理
  - 问题：Hive/MR/Spark需读取多余日志
  - 问题：流式计算窗口问题

例子-WORDCOUNT

```
// 创建表(持久化数据流)
create table words (ts int key, seqid int key, word string);

// 实时数据插入
insert into words values (xxx, xxx, xxx);

// 实时查询最近两分钟top10 Word
select ts/60, word, count(*) as cnt from words
  where ts >= 1462856700 and ts < 1462856820
  group by ts/60
  order by cnt desc
  limit 10;

// 分析结果保存为Kudu表，直接提供随机查询服务，如在线报表
create table wordcout (ts int key, rank int key, word string, cnt int)
insert overwrite wordcount select ...
```

OLAP云服务

- 为生态链企业提供数据分析服务
- 像数据库一样简单易用（REST + SQL)
  - OLAP数据库包含部分OLTP功能
  - 导入/查询/管理/权限/Quota统一集中管理
- 良好的可扩展性
- 一定程度的隔离

OLAP服务

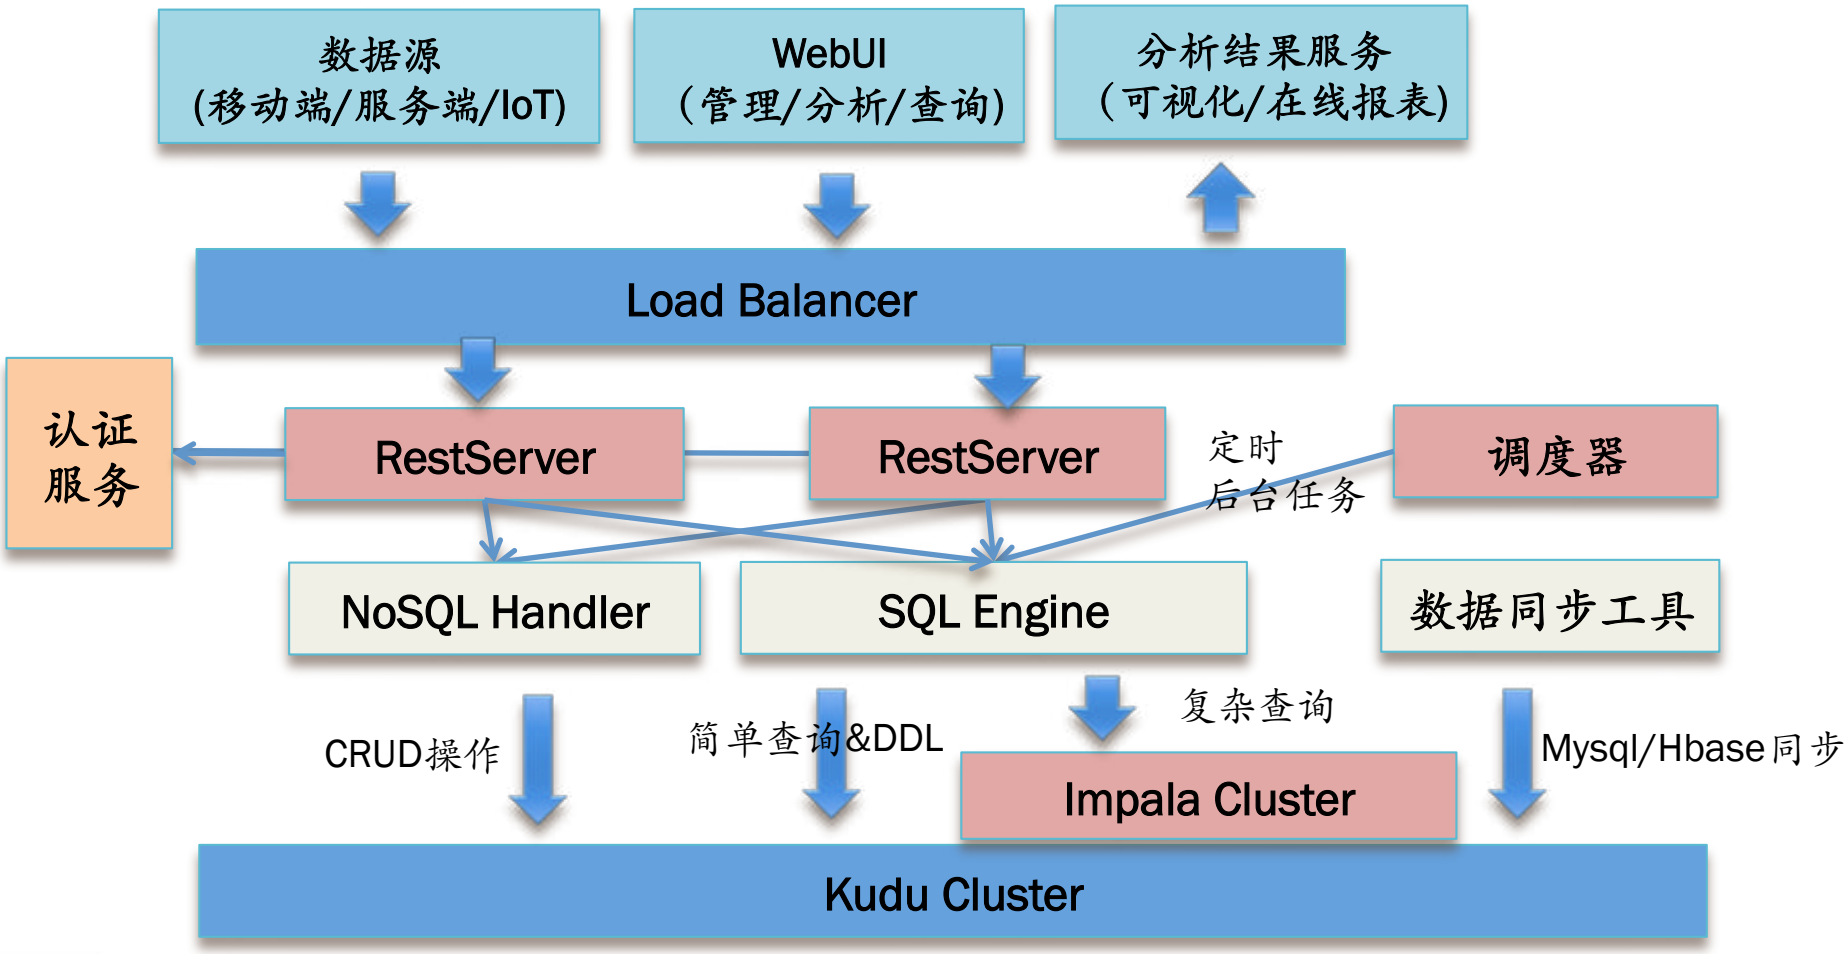
数据源
(移动端/服务端/IoT)
WebUI
(管理/分析/查询)
分析结果服务
(可视化/在线报表)
Load Balancer
认证
服务
RestServer
RestServer
定时
后台任务
调度器
NoSQL Handler
SQL Engine
数据同步工具
CRUD操作
简单查询&DDL
复杂查询
Mysql/Hbase同步
Impala Cluster
Kudu Cluster

OLAP服务-NOSQL

- 主要用于数据导入和结果服务
- Kudu API封装为REST服务
  - 通用性和易用性
  - 认证和权限验证
- 水平可扩展，高性能
- CRUD (Insert/Update/Delete/Get)
  - 同步写：低延迟
  - 批量写：高吞吐

OLAP服务-SQL

- 主要用于分析查询，数据和任务管理
- SQL封装为REST服务
- 对SQL请求做语法解析，分析查询类型
- 元数据管理、DDL、简单查询
  - 直接操作Kudu
- 复杂查询
  - 转发Impala
- 任务管理，扩展库，数据导入导出等功能
  - 添加SQL扩展语法

OLAP服务-容量规划和隔离

- NoSQL服务隔离
  - 写请求压力预期相对稳定
  - 每个分区写请求有固定Quota
  - 根据应用需求规划Partition数(类似AWS Kinesis)
- 实现
  - Kudu添加Partition级别Write Throttling
  - Token Bucket算法，细粒度时间(0.1s)

OLAP服务-容量规划和隔离

- SQL查询服务隔离
  - 查询不稳定，突发
  - 预期执行时间短，但占用资源多
- 实现
  - 每个查询收集聚合Impala和Kudu资源占用
  - Token Bucket，粗粒度时间(1min)
  - 限制大查询，添加后台查询模式(类似BigQuery)

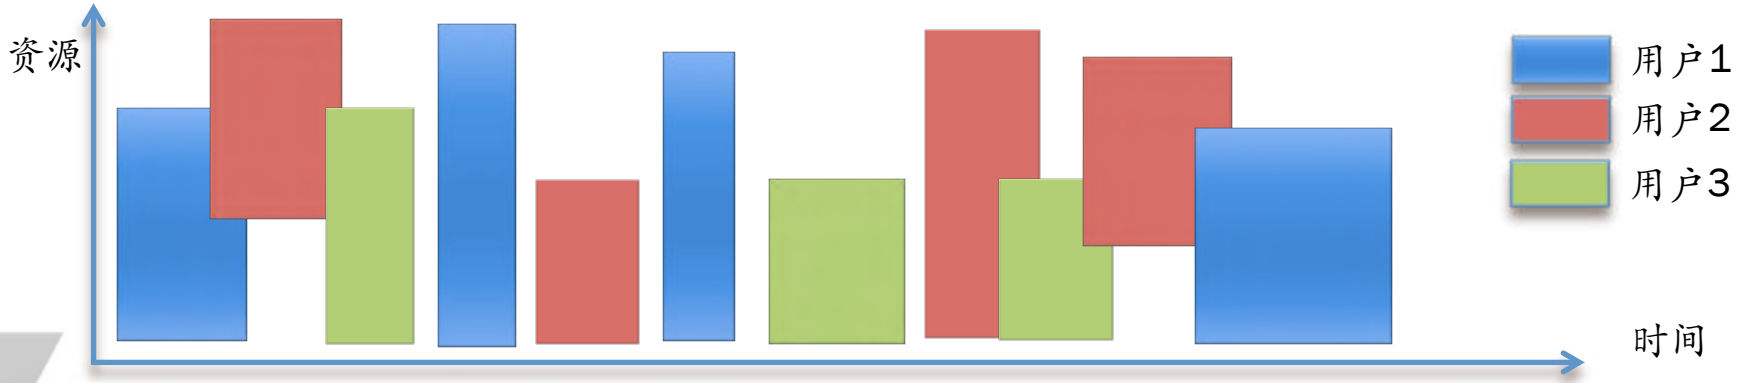

性能-随机读写

总结：

设计上牺牲写换取读

实际测试结果：

- 随机写差距不明显(20K-30K)
- 99th延迟控制很好(~5ms)
- 频繁更新性能比较差
- 随机读性能很好 (>50%)
- Scan性能>40倍
  - HBase ~ 150K cell/s
  - Kudu ~ 6M cell/s

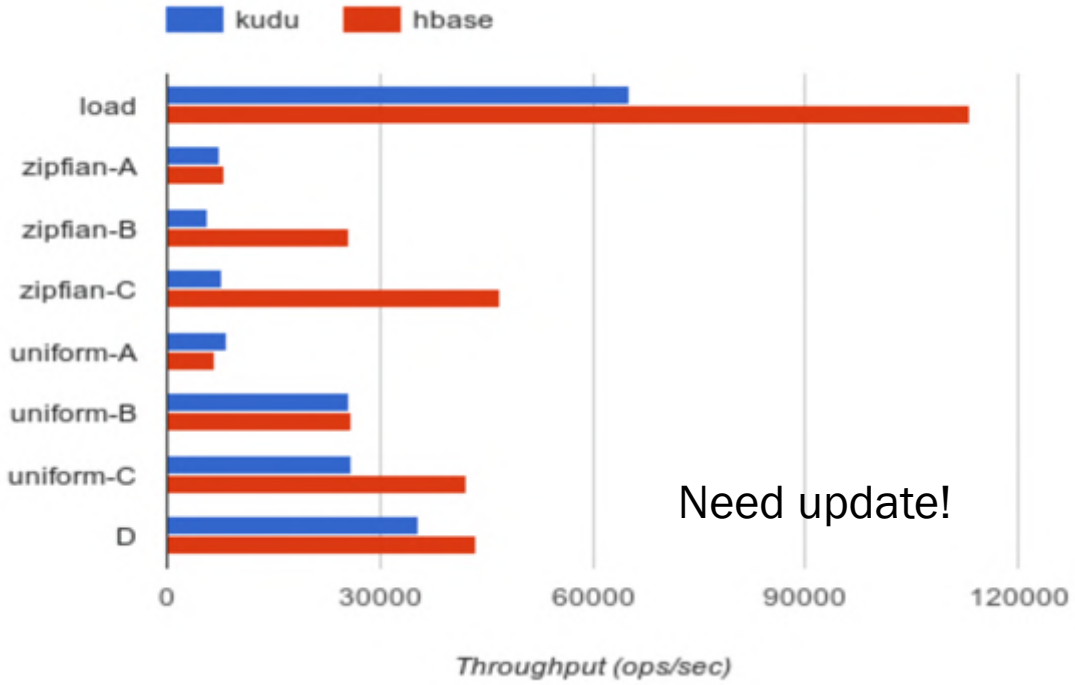

社区新进展：

RPC性能优化：性能>5倍提升

Get API (单节点800K QPS)

支持高性能随机读的应用，例如：计算结果服务

MultiGet，支持Index Join

性能–分析型查询

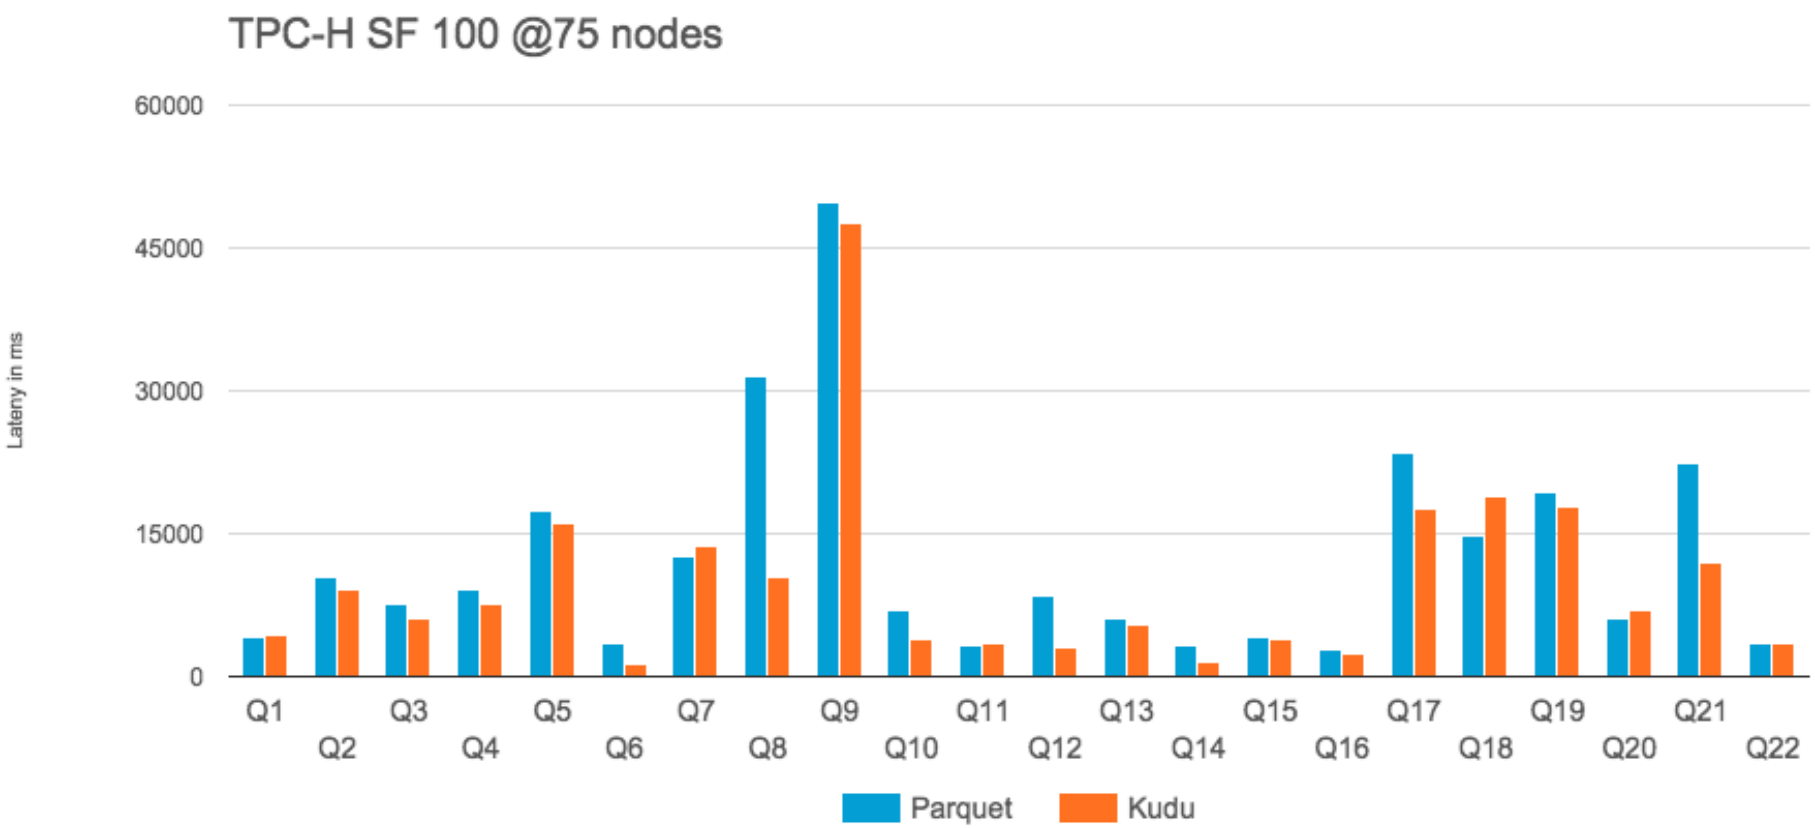
TPC-H SF 100 @75 nodes
Lateny in ms
60000
45000
30000
15000
0
Q1
Q2
Q3
Q4
Q5
Q6
Q7
Q8
Q9
Q10
Q11
Q12
Q13
Q14
Q15
Q16
Q17
Q18
Q19
Q20
Q21
Q22
Parquet
Kudu

性能-分析型查询

小米应用，71节点，260亿记录

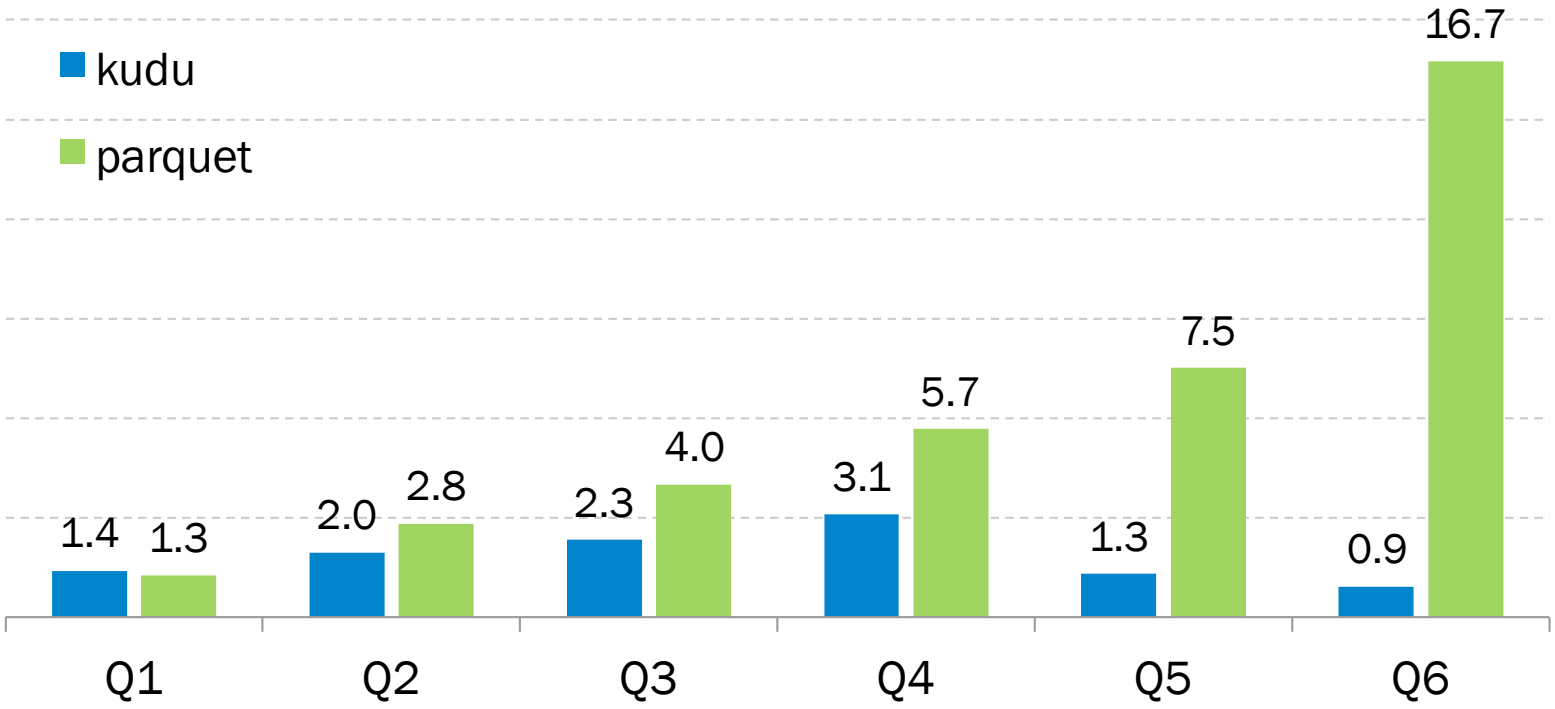

THANKS

SequeMedia 盛拓传媒 IT168.com ChinaUnix ITPUB