腾讯社交广告
Tencent Social Ads

The Power to
Connect Businesses and People
赋能商业 | 始终于人

# 对2000多亿条数据做一次Group By需要多久

易杰@腾讯

InfoQueue 促进软件开发领域知识与创新的传播

关注InfoQ官方信息
及时获取QCon软件开发者
大会演讲视频信息

扫码，获取限时优惠

ArchSummit 全球架构师峰会 2017 [深圳站]
2017年7月7－8日 深圳·华侨城洲际酒店
咨询热线：010-89880682

QCon 全球软件开发大会 [上海站]
2017年10月19-21日
咨询热线：010-64738142

# 关于我

06年加入腾讯
现负责社交广告引擎研发
关注高性能架构

# Contents


- 章节1 业务背景
- 章节2 系统架构
- 章节3 核心实现
- 章节4 性能数据
- 章节5 总结

# 腾讯社交广告

- 覆盖8亿优质用户

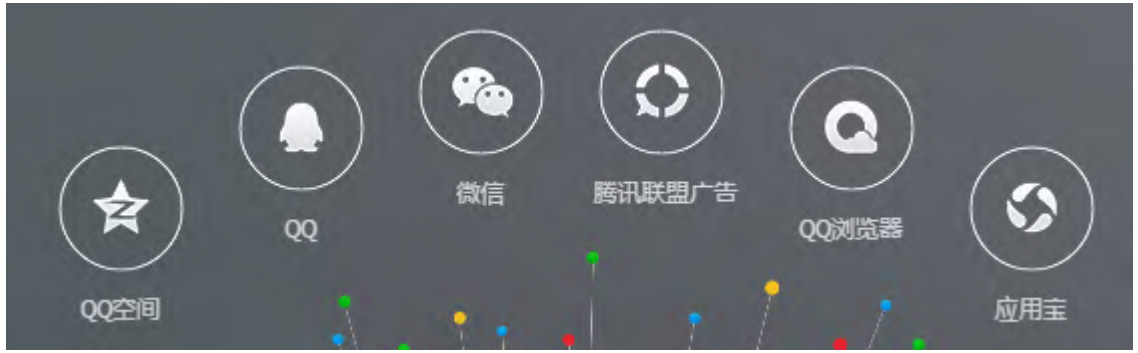

- 精准的定向能力

# 多维数据分析场景

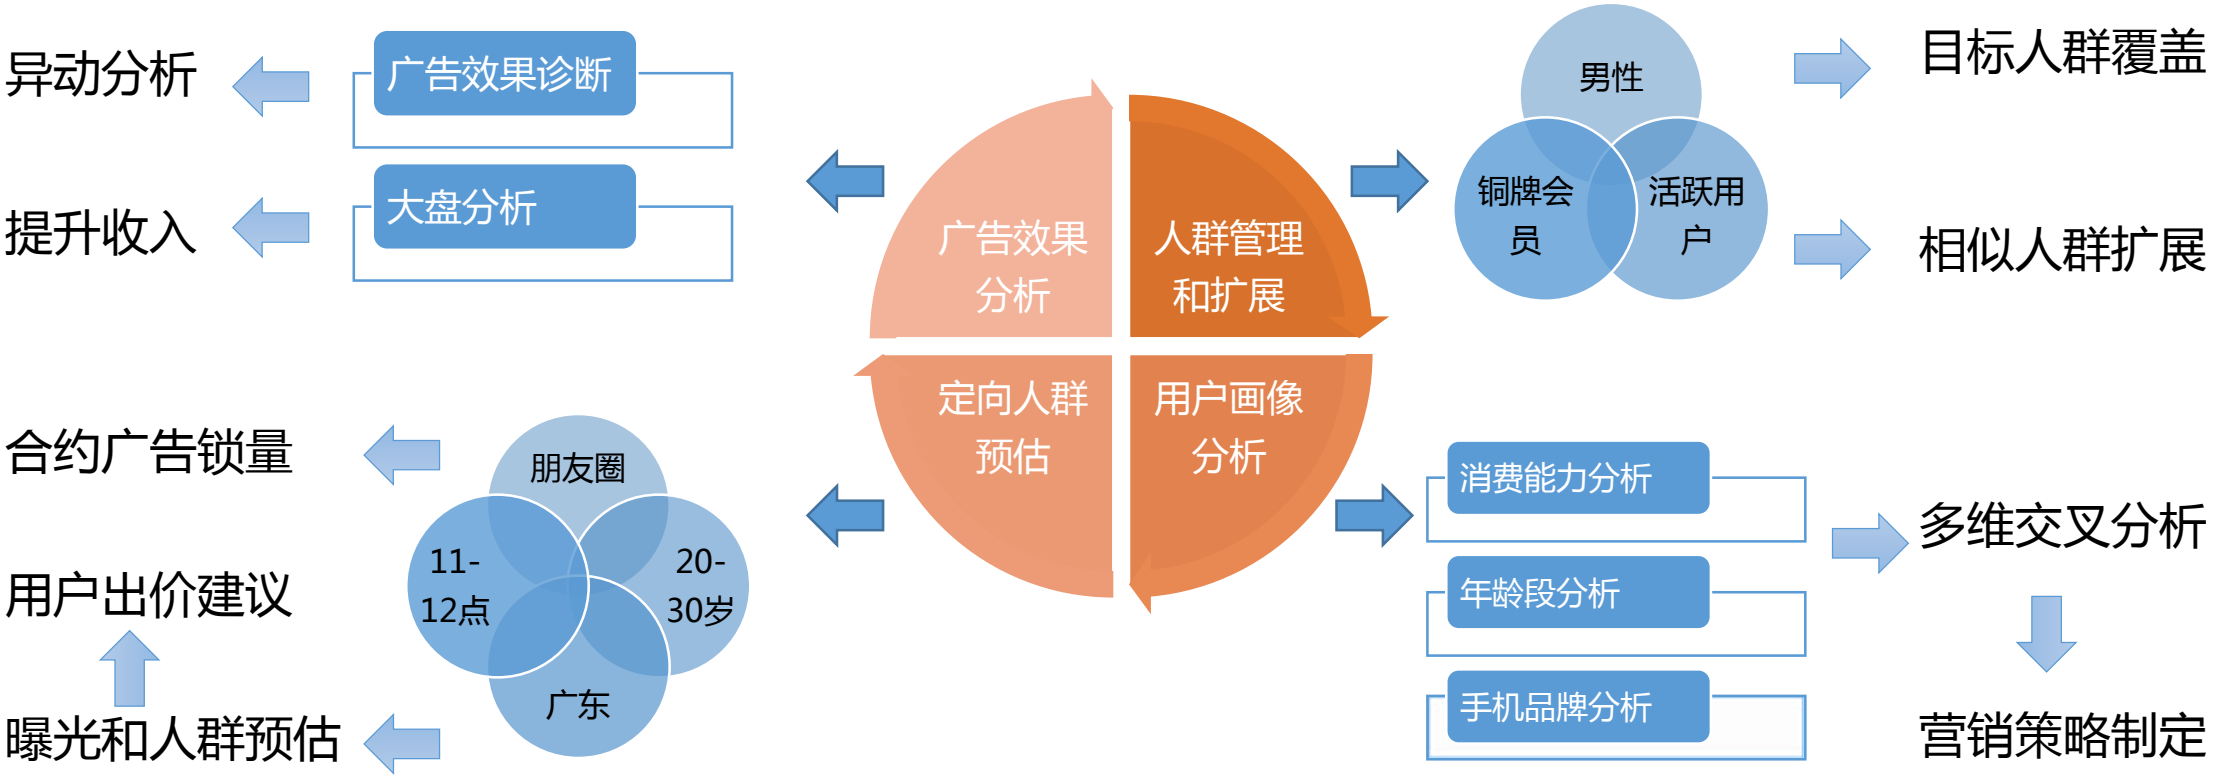
异动分析
广告效果诊断
提升收入
大盘分析
合约广告锁量
用户出价建议
曝光和人群预估
朋友圈
11-12点
20-30岁
广东
广告效果分析
人群管理和扩展
定向人群预估
用户画像分析
男性
铜牌会员
活跃用户
目标人群覆盖
相似人群扩展
消费能力分析
年龄段分析
手机品牌分析
多维交叉分析
营销策略制定

# 多维数据分析场景

- 多维度人群下钻分析
- 相似人群扩展
- 时延<100ms

# SQL举例

- 广告主查询用户年龄的分布

```
select age, count(*) from log where advertiser_id=123 group by age;
```

- 运营查询不同曝光次数的用户的占比、点击率、收入等

```
SELECT exposure_num, COUNT(*) as user_num,
    SUM(sum_click) / SUM(exposure_num) as click_rate, SUM(sum_cost) AS total_cost
FROM
    (SELECT qq, COUNT(*) AS exposure_num,
        SUM(click_count) AS sum_click, SUM(cost) AS sum_cost
    FROM log
    GROUP BY qq) temp_table
GROUP BY exposure_num;
```

# 系统目标

流程描述：

## 高性能

- 千亿规模原始数据集
- （毫）秒级端到端响应

## 低成本

- 索引规模相对原始数据集膨胀可控
- 利用SSD磁盘，降低内存使用

## 可扩展

- 增量数据修改
- 接口易用，支持SQL/RPC

业界实现：SQL-on-Hadoop(Hive/Dremel/Kylin/Drill)、Druid

自研：Pivot

# Contents


- 章节1 业务背景
- 章节2 系统架构
- 章节3 核心实现
- 章节4 性能数据
- 章节5 总结

# 系统架构

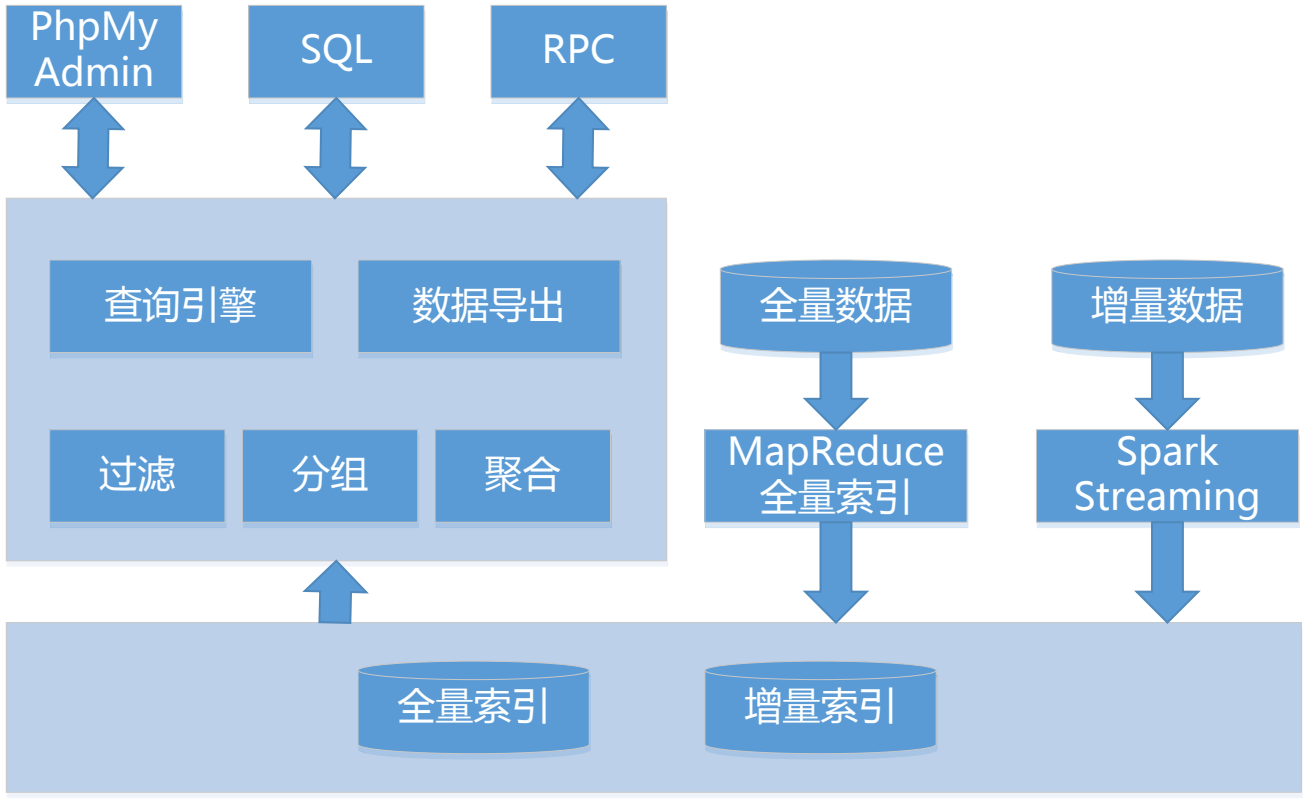


- 全量+增量，满足多种需求
- 索引分片，多级聚合
- 标准SQL接口，降低使用门槛
- 唯快不破

# Lambda架构

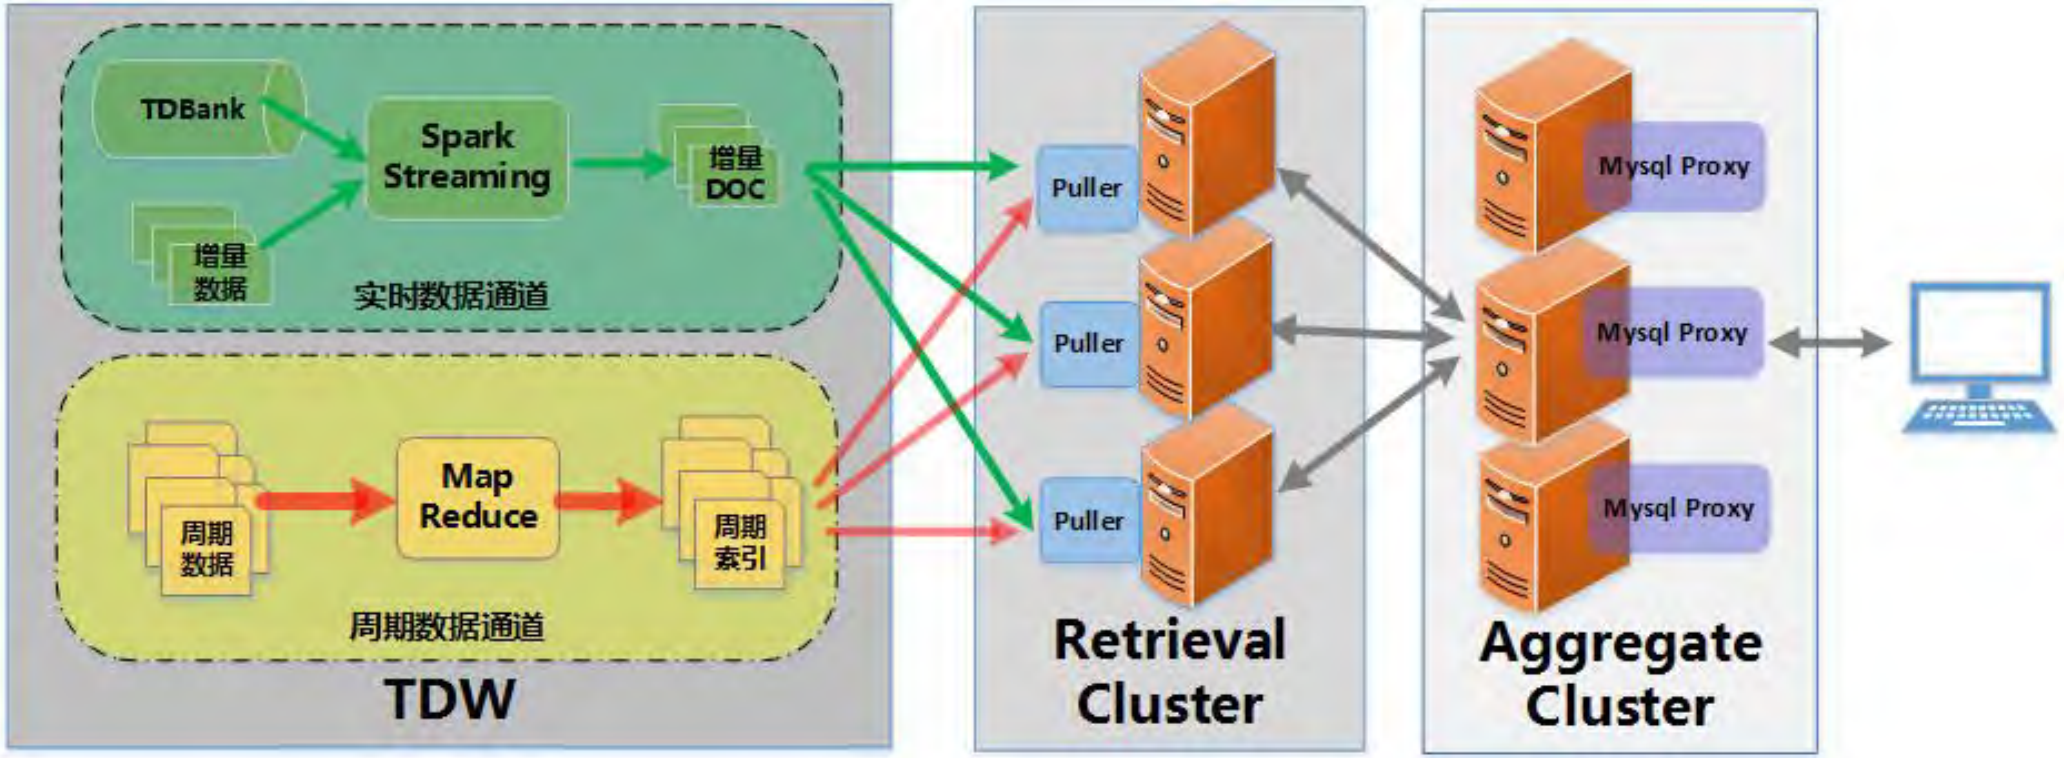
TDBank
Spark Streaming
增量 DOC
增量 数据
实时数据通道
周期 数据
Map Reduce
周期 索引
周期数据通道
TDW
Puller
Puller
Puller
Retrieval Cluster
Mysql Proxy
Mysql Proxy
Mysql Proxy
Aggregate Cluster

# Contents


- 章节1 业务背景
- 章节2 系统架构
- 章节3 核心实现
- 章节4 性能数据
- 章节5 总结

# 索引文件设计

索引数据结构：

| 全局信息 | 列值字典 | 倒排数据 | 正排数据 |
| --- | --- | --- | --- |
| | 每一列(Column)的值编码为列值(Term ) ID | 列值ID对应的文档ID列表 | 列式存储的压缩数据 |

检索查询流程：

- 查询条件：• Where age>=20 and age<30
- 命中列值：• 找到age满足条件的列值ID
- 倒排拉链：• 拉出列值对应的倒排拉链
- 集合运算：• 根据逻辑对结果进行集合运算

| | Column 0 | Column 1 | Column 2 | ... |
| --- | --- | --- | --- | --- |
| Doc 0 | term list | term list | term list | term list |
| Doc 1 | term list | term list | term list | term list |
| ... | term list | term list | term list | term list |

# 列值字典String压缩

- 前缀压缩节省空间
  - 例如词表：{“aa”，“abc”，“abcd”，“abd”，“abe”}
- 实现采用更高效的Vector前缀压缩
  - 词ID快速定位

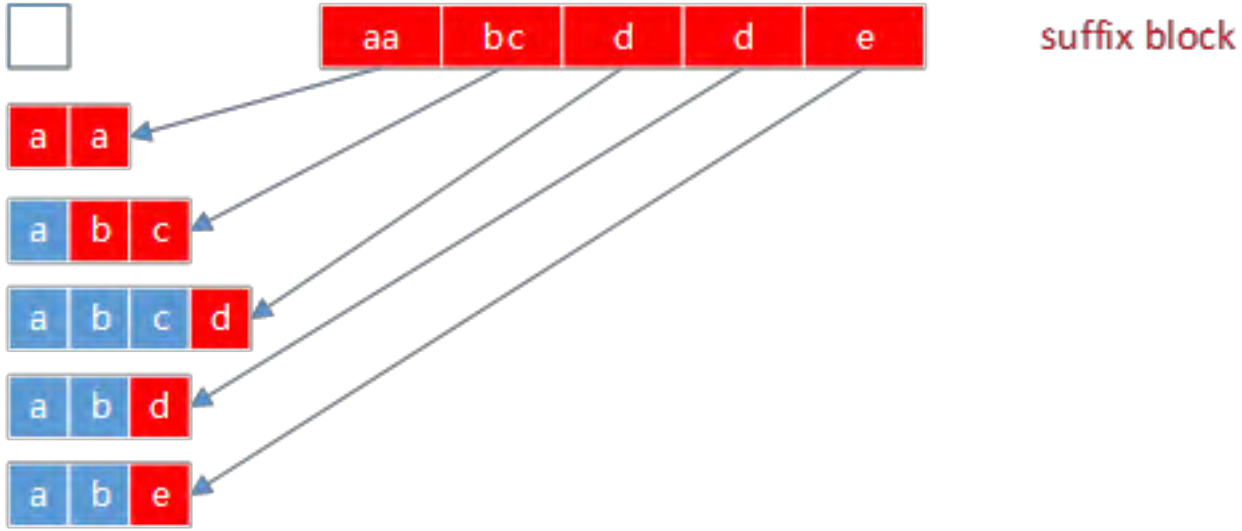


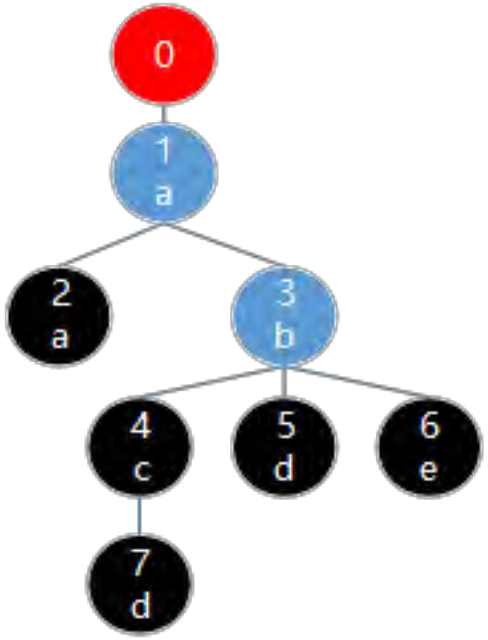

# 倒排数据存储

- 倒排 – 列值对应的文档ID列表
- 位图（Bitmap）压缩存放倒排拉链列表
  - RoaringBitmap支持AND、OR等运算，线性性能
  - 根据元素个数动态选择有序数组或bitmap存储
  - 基于RoaringBitmap源码做了存储和性能的优化

Roaring与其他位图算法的性能比较：

(a) Size expansion if Roaring is replaced with other schemes.

| | CENSUS1881 | CENSUSINCOME | WIKILEAKS | WEATHER |
|---|---|---|---|---|
| Concise | 2.2 | 1.4 | 0.79 | 1.4 |
| WAH | 2.4 | 1.6 | 0.79 | 1.5 |
| BitSet | 42 | 2.9 | 55 | 3.5 |

(b) Time increase, for AND, if Roaring is replaced with other schemes.

| | CENSUS1881 | CENSUSINCOME | WIKILEAKS | WEATHER |
|---|---|---|---|---|
| Concise | 920 | 6.6 | 8.3 | 6.3 |
| WAH | 840 | 5.9 | 8.2 | 5.4 |
| BitSet | 730 | 0.42 | 28 | 0.64 |

(c) Time increases, for OR, if Roaring is replaced with other schemes.

| | CENSUS1881 | CENSUSINCOME | WIKILEAKS | WEATHER |
|---|---|---|---|---|
| Concise | 34 | 5.4 | 2.1 | 3.9 |
| WAH | 31 | 4.9 | 2.1 | 3.4 |
| BitSet | 29 | 0.43 | 6.7 | 0.48 |

-

- Roaring is 20 to 100 times faster than Concise on unions
- Roaring is 40 to 200 times faster than Concise on intersections
- Roaring can scan the set bits up to 3 times faster than Concise
- Roaring can offer better compression (up to 1.6x better than Concise)
- Roaring never uses more than 300 bytes per bitmap

Roaring性能最优

# 正排数据存储

- 60%的索引空间是正排数据
- 减少磁盘IO访问-列存储
- 最大程度节省磁盘空间-编码压缩

数据编码步骤：

| | |
|---|---|
| 筛选11种编码算法 | 定长类型编码：定长数组编码、列值个数索引编码、定长列表编码、变长列表编码 |
| | String类型编码：单string长度索引编码、多string长度索引编码、单string列表编码、多string列表编码 |
| | 简单字典编码：适用列值重复较多的string类型 |
| | Huffman字典编码：列值分布不均匀情况下对简单字典编码的优化 |
| | 二进制String编码：较特殊的二进制数据类型 |

# 正排数据压缩编码

- 定长数组编码
  - 适用列值取值平均个数约等于最大值，譬如年龄
  - 数值压缩存放

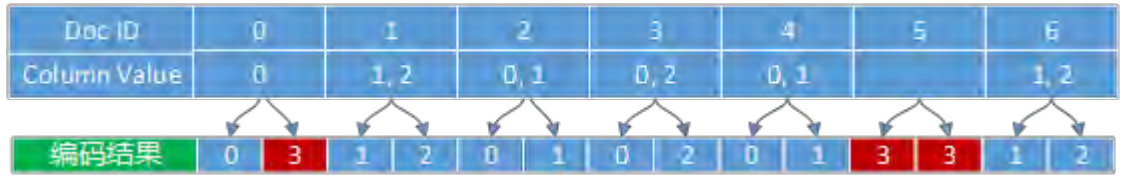


- 定长列表编码
  - 适用列值稀疏情形
  - 文档ID差值压缩存放

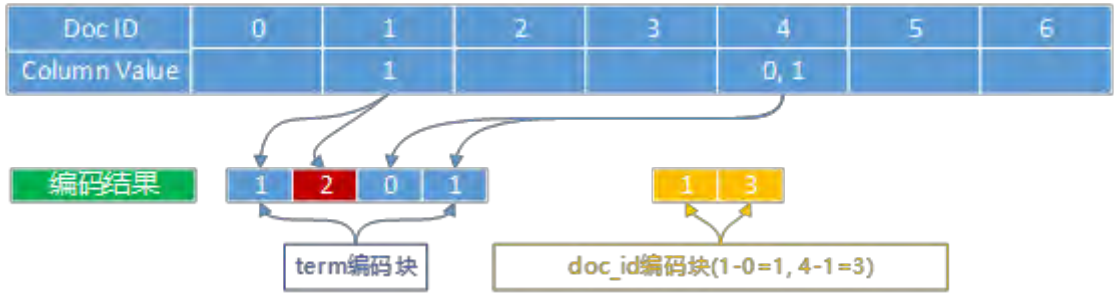

# 分组（Group By）实现

- 基于排序
  - 代价高， O(n*log(n))
  - 数据库Group by未命中索引时
- 基于索引
  - 同一组的数据在此索引(有序) 连续排列
  - 数据库Group by有序命中索引时

# 遍历正排数据实现分组

- 按照列的顺序逐列分组
  - 当列值作为key，map规模可控
- 按照树形结构进行分组
- 一个文档可能被分到多个组

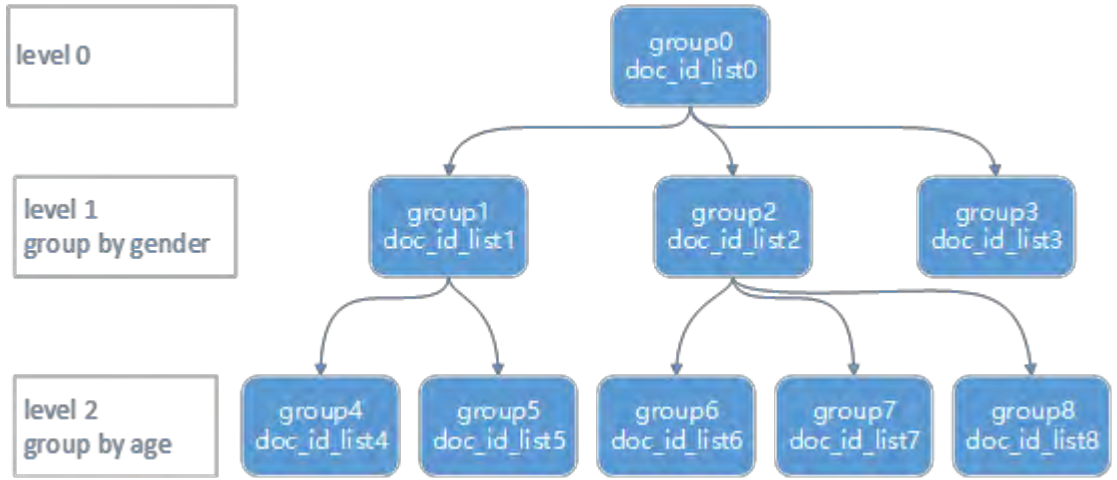


分层Group By

Doc Id到group Id映射

# 基于倒排数据实现分组

- 集合求交更快
- 适用分组数较少时

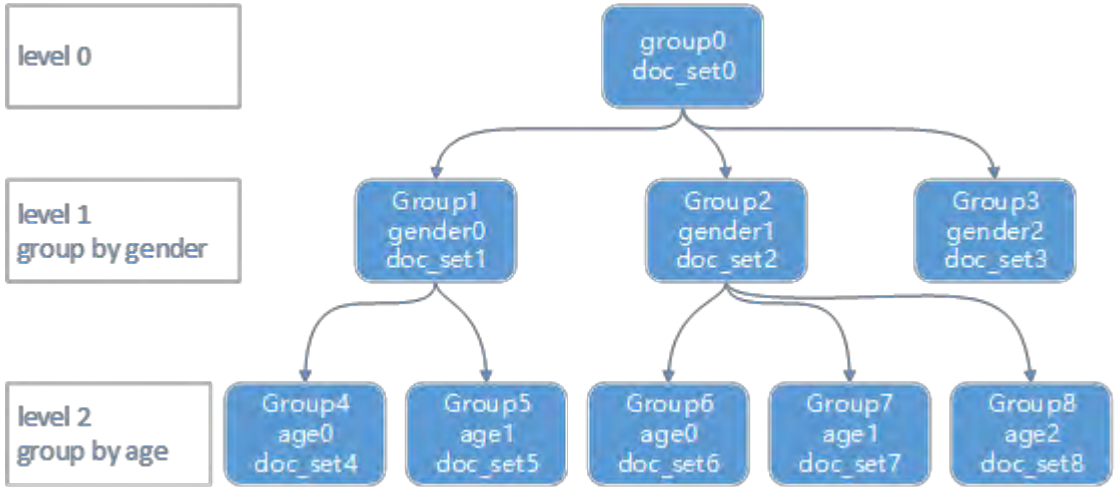


倒排分层Group By

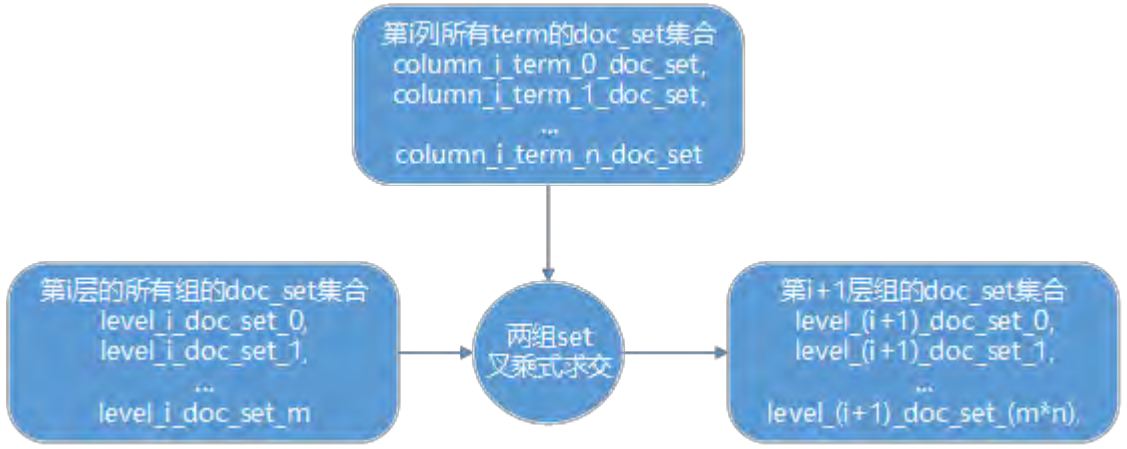


集合求交

# 分组性能对比

- 6000万条数据，按照性别、年龄两列分组查询

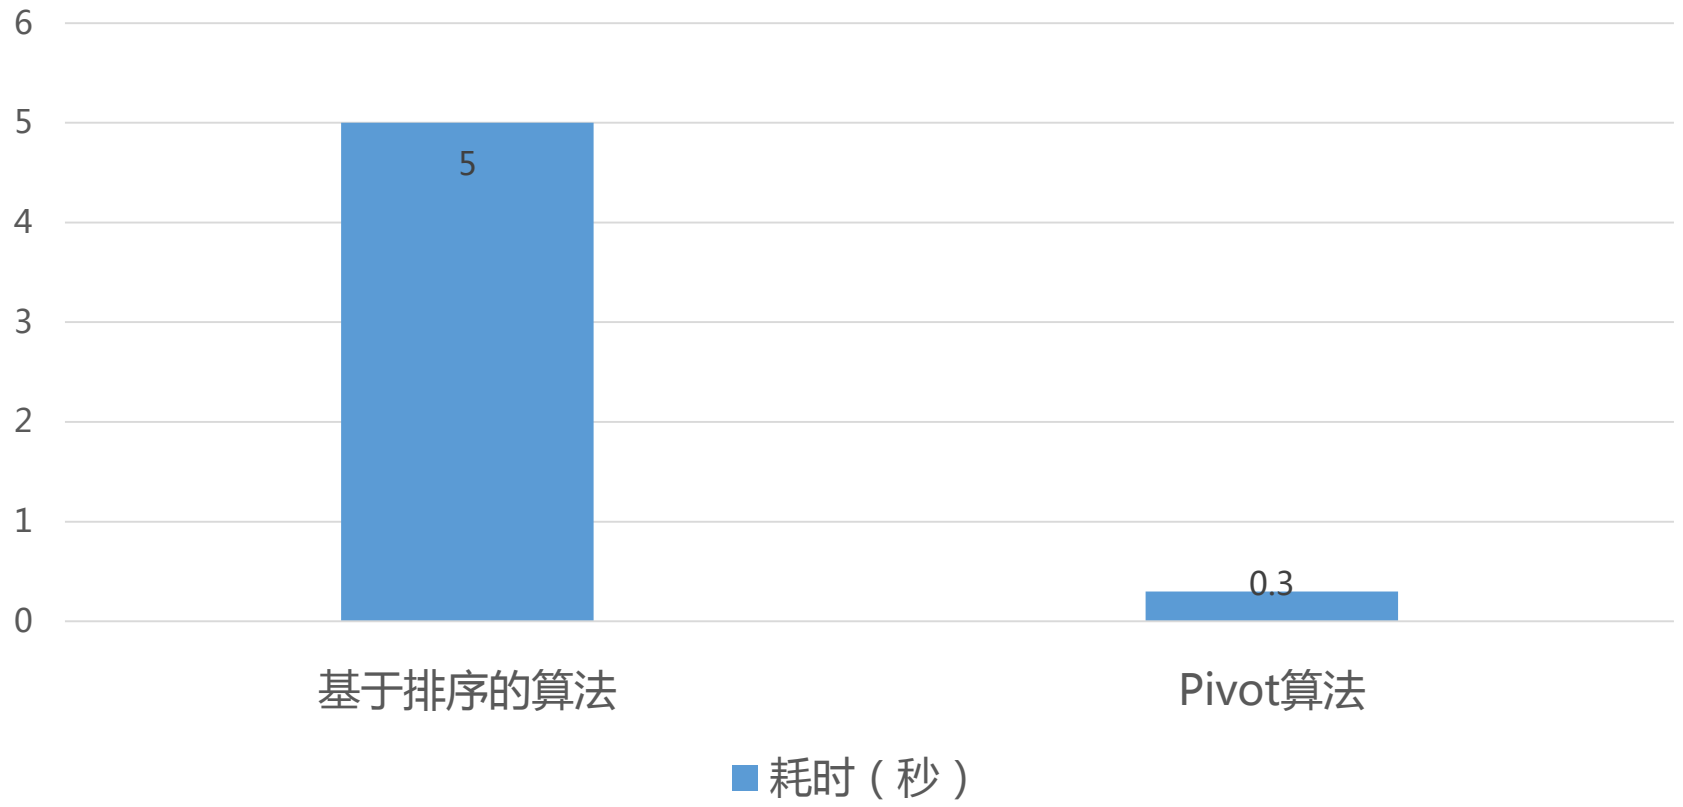

# 求和实现算法（SUM）

- Group By后对各个组的某列进行SUM求和
- 借鉴Group by算法，实现了两种SUM算法

| 基于倒排集合求交 | 基于列值字典遍历正排 |
| --- | --- |
| ➓累加变乘法，操作结果集数量级优化<br>➓适用结果集合总数较少时 | ➓方法和Group By类似<br>➓适用结果集合总数很大时 |

# 分区管理

- 数据存储与管理
  - 方便对“过期”数据清理
- 提升查询性能
  - 大部分请求并不需要检索全量数据
  - 缩小数据扫描范围
- 关键字Partition
  - select count(*) from log partition('20170201','20170202');

# 优先级调度

- 不抢占
  - 先到先处理
- 任务级优先调度
  - 先处理优先级高的任务
- 分片级优先调度
  - 更细粒度的调度

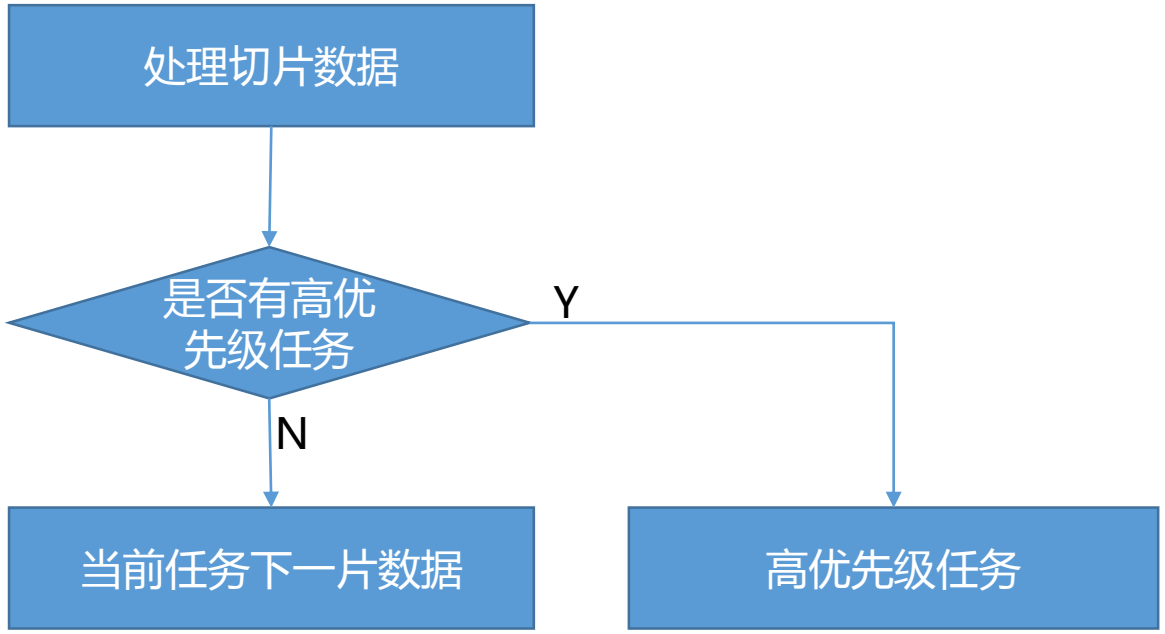

# 插件设计

- 开放Functor

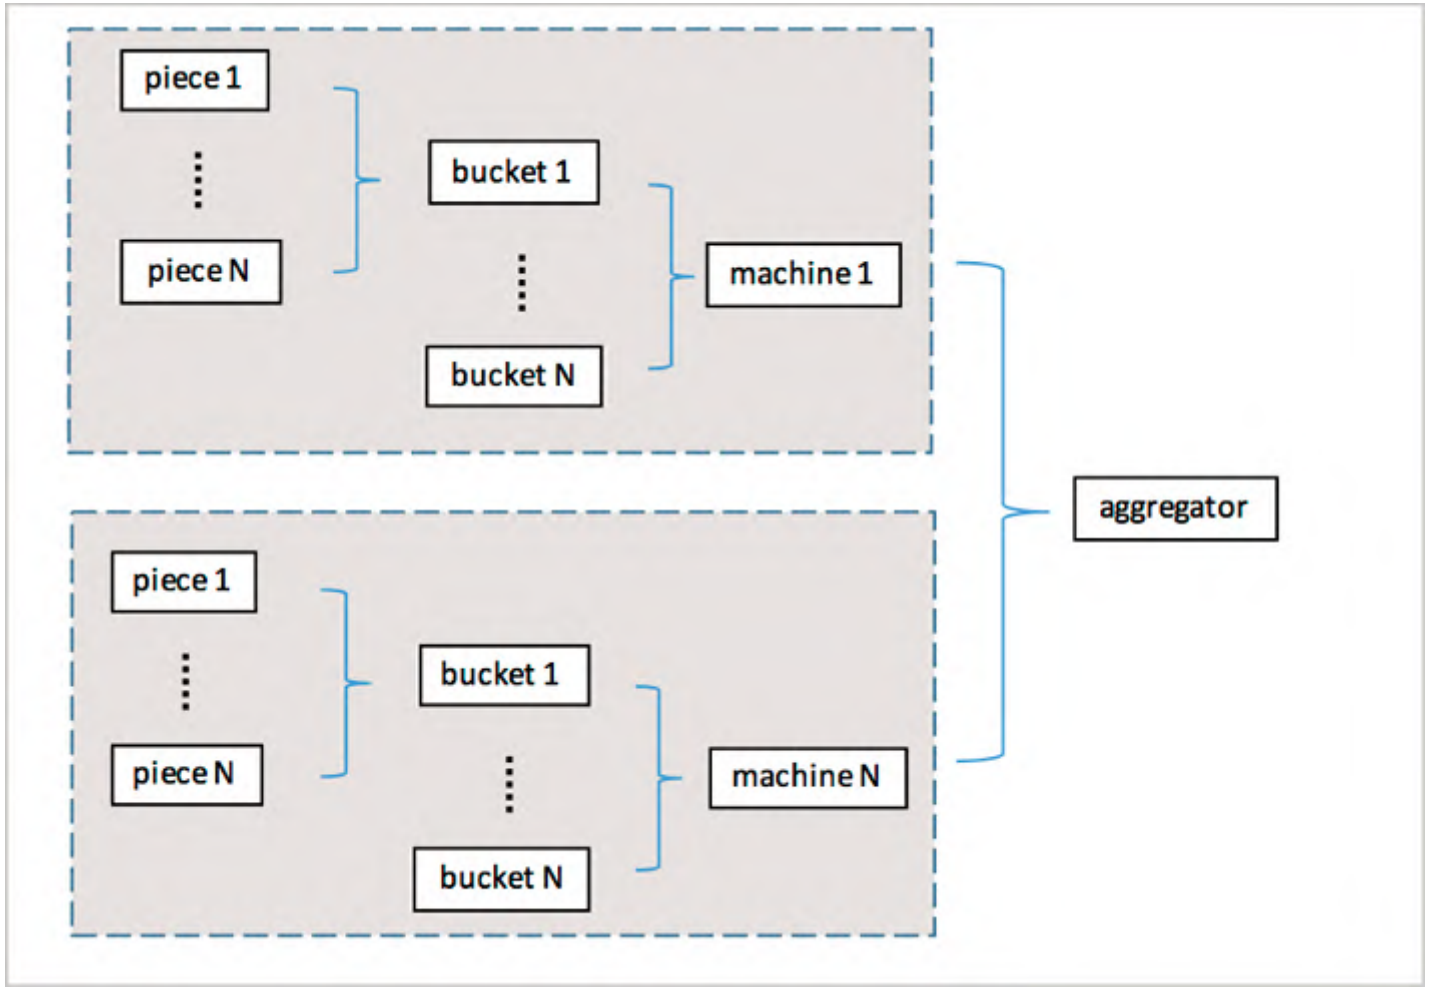

# 索引更新设计

- 公司TDW集群管理索引，可靠性高
- 支持增量更新
  - 譬如用户的行为（标签）会随时变更
- 打补丁更新方式，记录新增和删除的增量索引
- 增量索引和检索独立部署 – 避免IO干扰

增量索引设计：

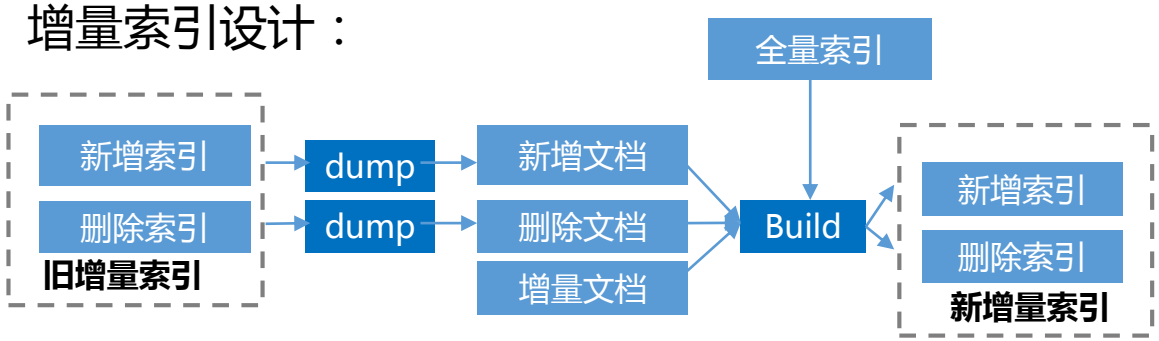


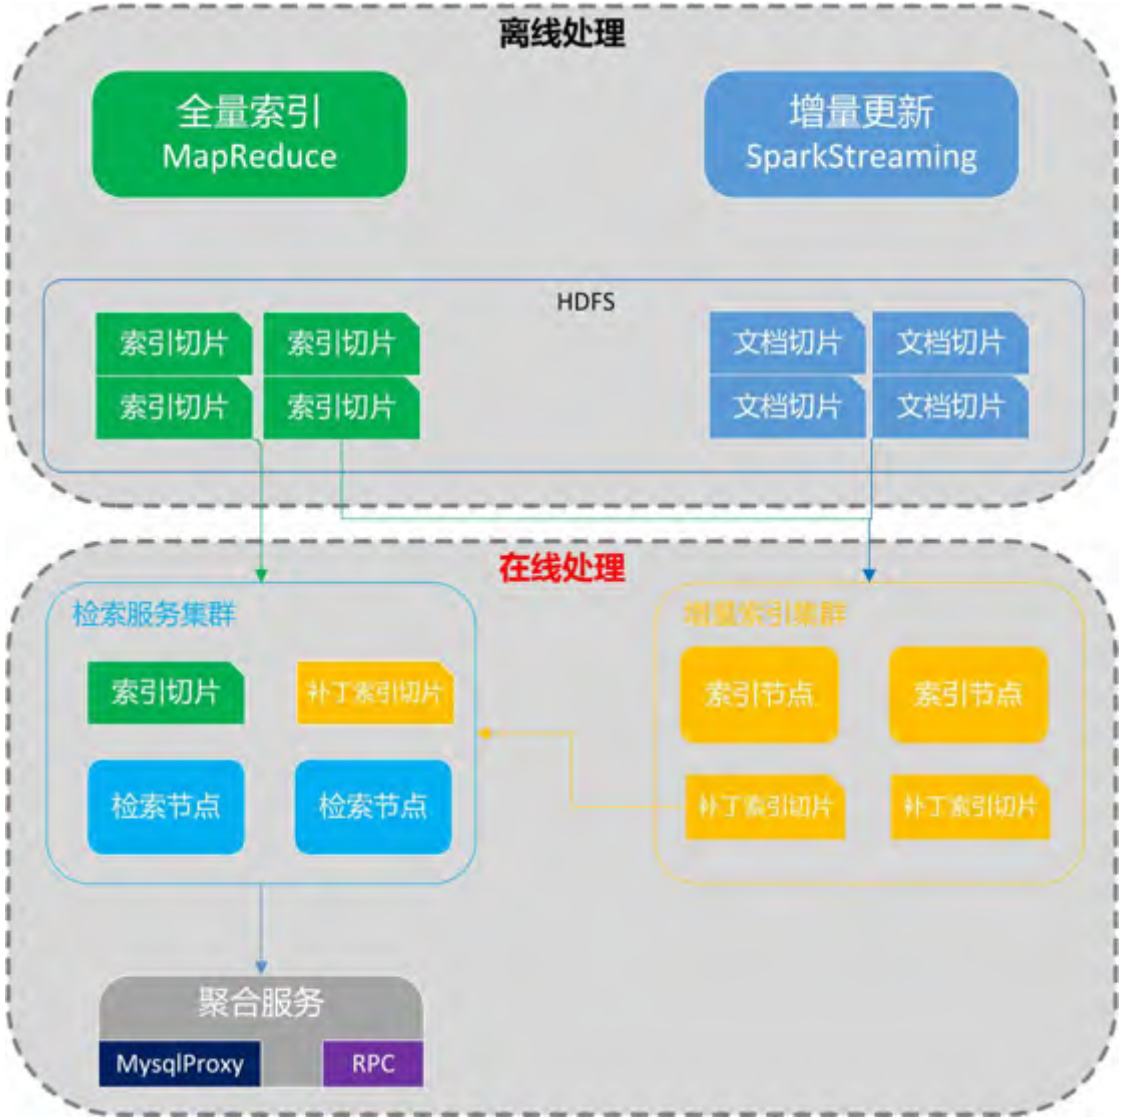

# 并行计算设计

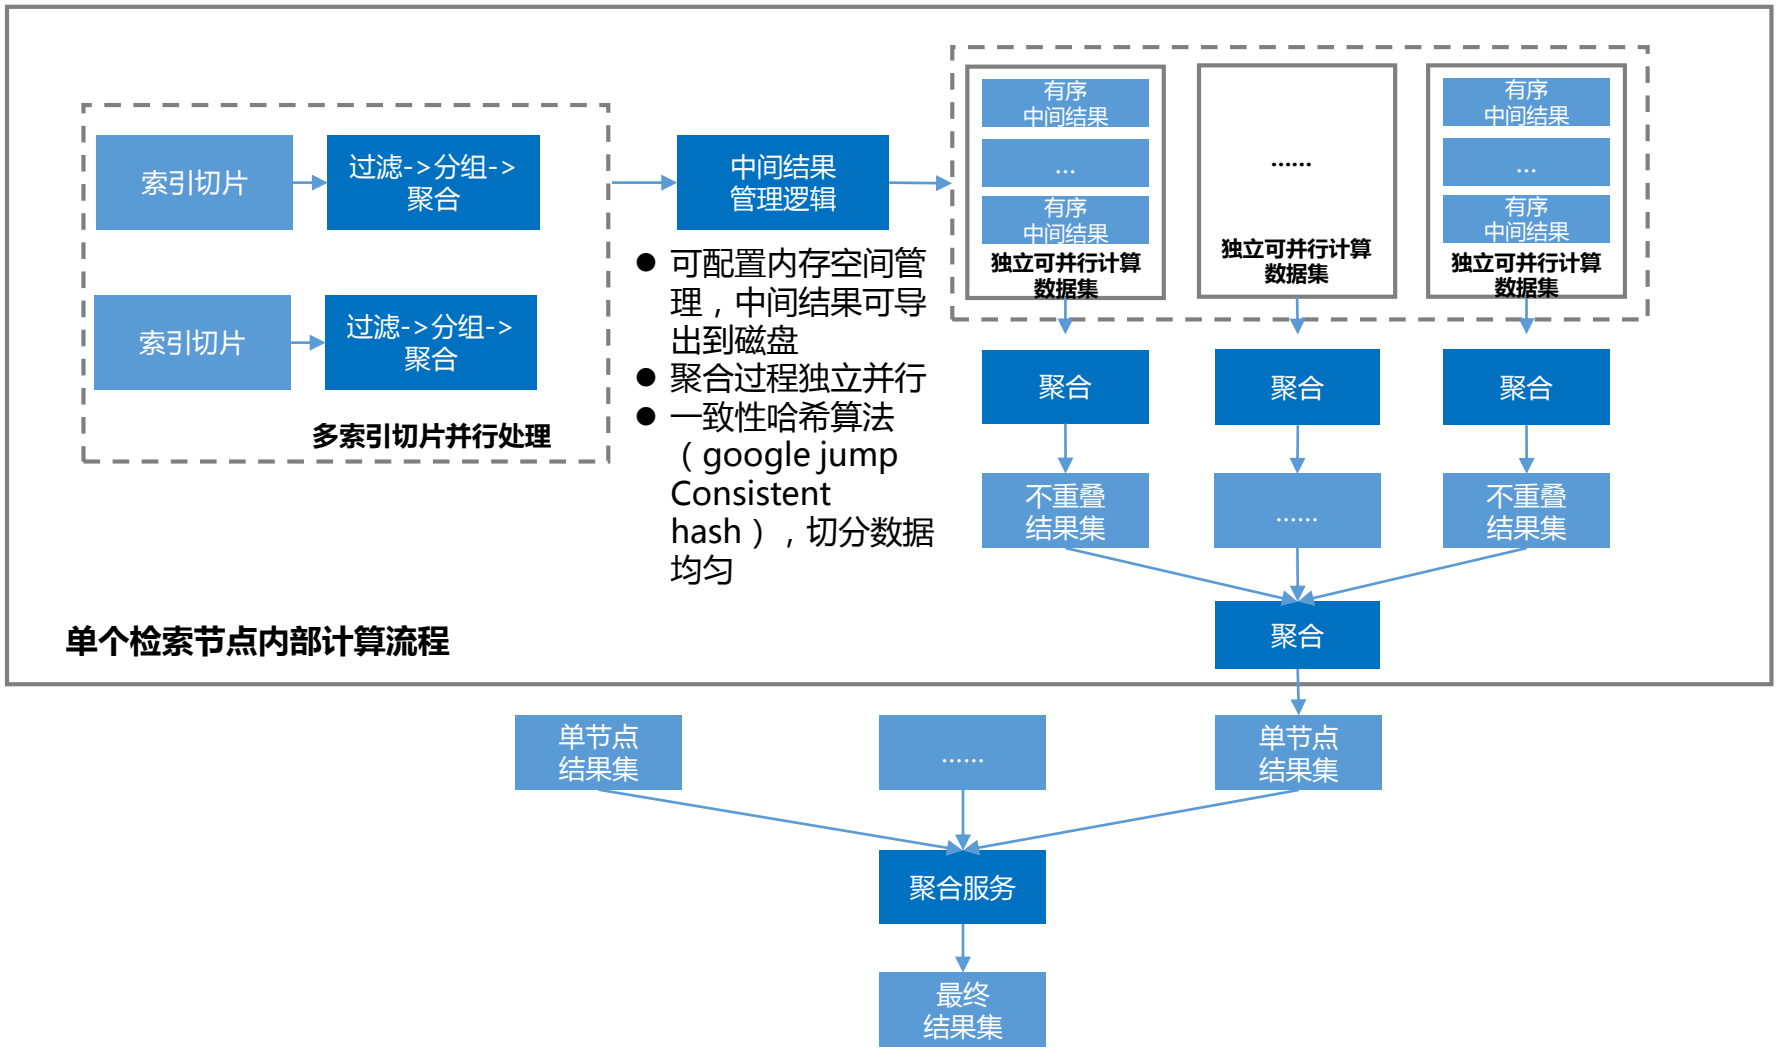
索引切片
过滤->分组->聚合
索引切片
过滤->分组->聚合
多索引切片并行处理
中间结果管理逻辑
可配置内存空间管理，中间结果可导出到磁盘
聚合过程独立并行
一致性哈希算法（google jump Consistent hash），切分数据均匀
有序中间结果
...
有序中间结果
独立可并行计算数据集
.....
独立可并行计算数据集
有序中间结果
...
有序中间结果
独立可并行计算数据集
聚合
聚合
聚合
不重叠结果集
.....
不重叠结果集
聚合
单节点结果集
.....
单节点结果集
聚合服务
最终结果集
单个检索节点内部计算流程

# Contents


- 章节1 业务背景
- 章节2 系统架构
- 章节3 核心实现
- 章节4 性能数据
- 章节5 总结

# 性能数据

- Pivot VS Druid：Druid索引小，Pivot查询快数量级

| 测试项（机型TS8：CPU 24核，内存32G，硬盘290*11） | druid | pivot |
|---|---|---|
| 数据源记录数（Druid单机上试图导入更多数据时，构建失败） | 6000万 | 6000万 |
| 索引大小 | 7.2G | 12G |
| select count(*) from log | 10ms | 2ms |
| select producttype, count(*) from log group by producttype | 4.7s | 57ms |
| select gender, count(*) from log group by gender | 4.7s | 27ms |
| select age, count(*) from log group by age; | 4.9s | 102ms |
| select gender, age, count(*) from log group by gender, age | 7.3s | 325ms |
| select gender, sum(impression_count) from log group by gender | 4.7s | 51ms |
| select producttype, sum(impression_count) from log group by producttype | 5.0s | 91ms |
| select count(distinct(qq)) from log | 12.5s | 1.85s |

# 性能数据

```
mysql> select count(*) from log;
+--------------+
| COUNT(*)     |
+--------------+
| 249243862771 |
+--------------+
1 row in set (0.03 sec)

mysql> select new_gender, count(*) from log group by new_gender;
+------------+--------------+
| new_gender | COUNT(*)     |
+------------+--------------+
|          0 |  23752244705 |
|          1 | 125602742040 |
|          2 |  99888876026 |
+------------+--------------+
3 rows in set (2.27 sec)
```

# 性能数据

```
mysql> select count(*) from log where advertiser_id=3665472;
+----------+
| COUNT(*) |
+----------+
| 79174926 |
+----------+
1 row in set (0.07 sec)

mysql> select new_gender, count(*) from log where advertiser_id=3665472 group by new_gender;
+------------+----------+
| new_gender | COUNT(*) |
+------------+----------+
|          0 |   980955 |
|          1 | 40963790 |
|          2 | 37230181 |
+------------+----------+
3 rows in set (1.82 sec)
```

# 性能数据

```
mysql> select new_gender, count(*) from log group by new_gender partition('20170411');
+-------------+-------------+
| new_gender  | COUNT(*)    |
+-------------+-------------+
|           0 |   419041045 |
|           1 |  2391438901 |
|           2 |  1907457933 |
+-------------+-------------+
3 rows in set (0.37 sec)
```

# Contents


- 章节1 业务背景
- 章节2 系统架构
- 章节3 核心实现
- 章节4 性能数据
- 章节5 总结

# 总结

- 进一步完善SQL
- 资源管理

腾讯社交广告
Tencent Social Ads

The Power to
Connect Businesses and People
赋能商业 | 始终于人