千亿大数据
即席踪迹分析

核心技术原理与实现详解

个人介绍

母延年 十年行业经验 曾任职 新浪、酷六、阿里与腾讯

11年：支付宝黄金策的海狗

12年：阿里开源项目
MDRLL（多维分析）与 JStorm（流计算）

14年：腾讯的Hermes(每天千亿总量万亿)

15年：技术创业 ，潜心研究技术。

目录

什么是千亿数据即席踪迹分析？

千亿

数据量在每天千亿条，总量在万亿规模的实时数据。

即席

首先含有当场，即兴的意思。没有事先准备，想查哪里就查哪里。
其次要求很快的响应，不能等待太久，即查即所得。

踪迹

了解数据里的风吹草动，行踪查询，轨迹分析.
一般指的是 时间、位置、操作等有关。

即席踪迹分析是做什么的

通过在大数据中快速的查询比对。发现目标的行踪轨迹。
常用于破获案件、截获情报、舆论定位、排查故障、资金流向追溯、通话记录分析等。

公安	• 技侦：通话记录分析，同行同住，尾随人识别，连环案件等 • 网监：海量信息搜索，关键词统计，相似度匹配等
交通	• 机动车缉查布控：车牌模糊查询，同行车辆，昼伏夜出，陌生车辆等 • 交通运输：车辆行驶轨迹，特种车辆监控，道路养护，流量监控等
电信	• 通话数据统计与分析：通话质量，套餐推荐，用户习惯分析等 • 通信设备保养与维护：故障定位，故障预警，负载评估等
金融	• 流水日志分析：日志快速定位，明细查询，问题追溯，投诉处理等 • 行情监测分析：指标监控，多维分析，监管合规等
电商	• 用户画像，趋势分析，精准营销，推荐系统等 • 日志定位监测，用户行为分析，探索性数据分析等
物流	• 订单轨迹，订单状态，物流车辆状态，服务质量评估等

由于公安场景比较敏感，暂不对外公布
本PPT仅保留技术实现……

这些场景带来的挑战！

IOT-物联网，传感器，摄像头

视频识别
行车：位置，速度，车牌，颜色，车内人数
行人：性别，衣服颜色、人群密度，行走速度

UGC:用户产生内容

上网发帖，发博客
语音通话，照片分享

Transactions：事物日志

刷卡消费，买火车票
酒店入住，网吧上网
手机信令位置定位

转换为文本

超大规模：
数据总量达到数十亿到数万亿条
日均产生数千万到千亿条数据

超多维度：
字段数达到数百个，数千个，
甚至数十几万个

无法预计算：
每种组合都算好的话可能达数年。

即席查询：
即查即所见、任意多维组合分析

目前业界现有主流方案存在的问题

Hive，Spark SQL，SQL on Hadoop：纯粹的暴力扫描

HBase，KV型NoSQL数据库：只能局部计算，不灵活

Kylin：本质上是预计算，只能看特定的维度、粒度。

“千亿即席踪迹分析”的性能比对

“千亿即席踪迹分析”的必备特性

实时导入

- 数据产生后约1~2分钟，系统内可查
- 每天千亿增量，总量可达万亿

多维分析

- 任意维度组合统计分析，任意维度过滤筛选
- 像百度那样快速的搜索与响应。

即席查询

- 想查什么立即就查，不需要预计算。
- 保存原始数据，任意维度组合均可见。

超快排序

- 百亿数据，2台24core机器，秒级时间排序。

新方案的排序性能对比

amtint 列筛选	筛选后条数	排序方式	YDB BlockSort	Spark
无筛选	100 亿	降序	3.3	1118
		升序	3.6	1085
100 TO 900	80 亿	降序	1.5	1093
		升序	1.3	1070
100 TO 600	50 亿	降序	1.53	1104
		升序	1.38	867
100 TO 200	10 亿	降序	7.00	1115
		升序	1.11	1131
100 TO 110	1 亿	降序	2.1	1160
		升序	3.44	1114
100 TO 101	0.1 亿	降序	10.67	1089
		升序	7.0	1110

检索过滤性能相对于原生spark提升倍数

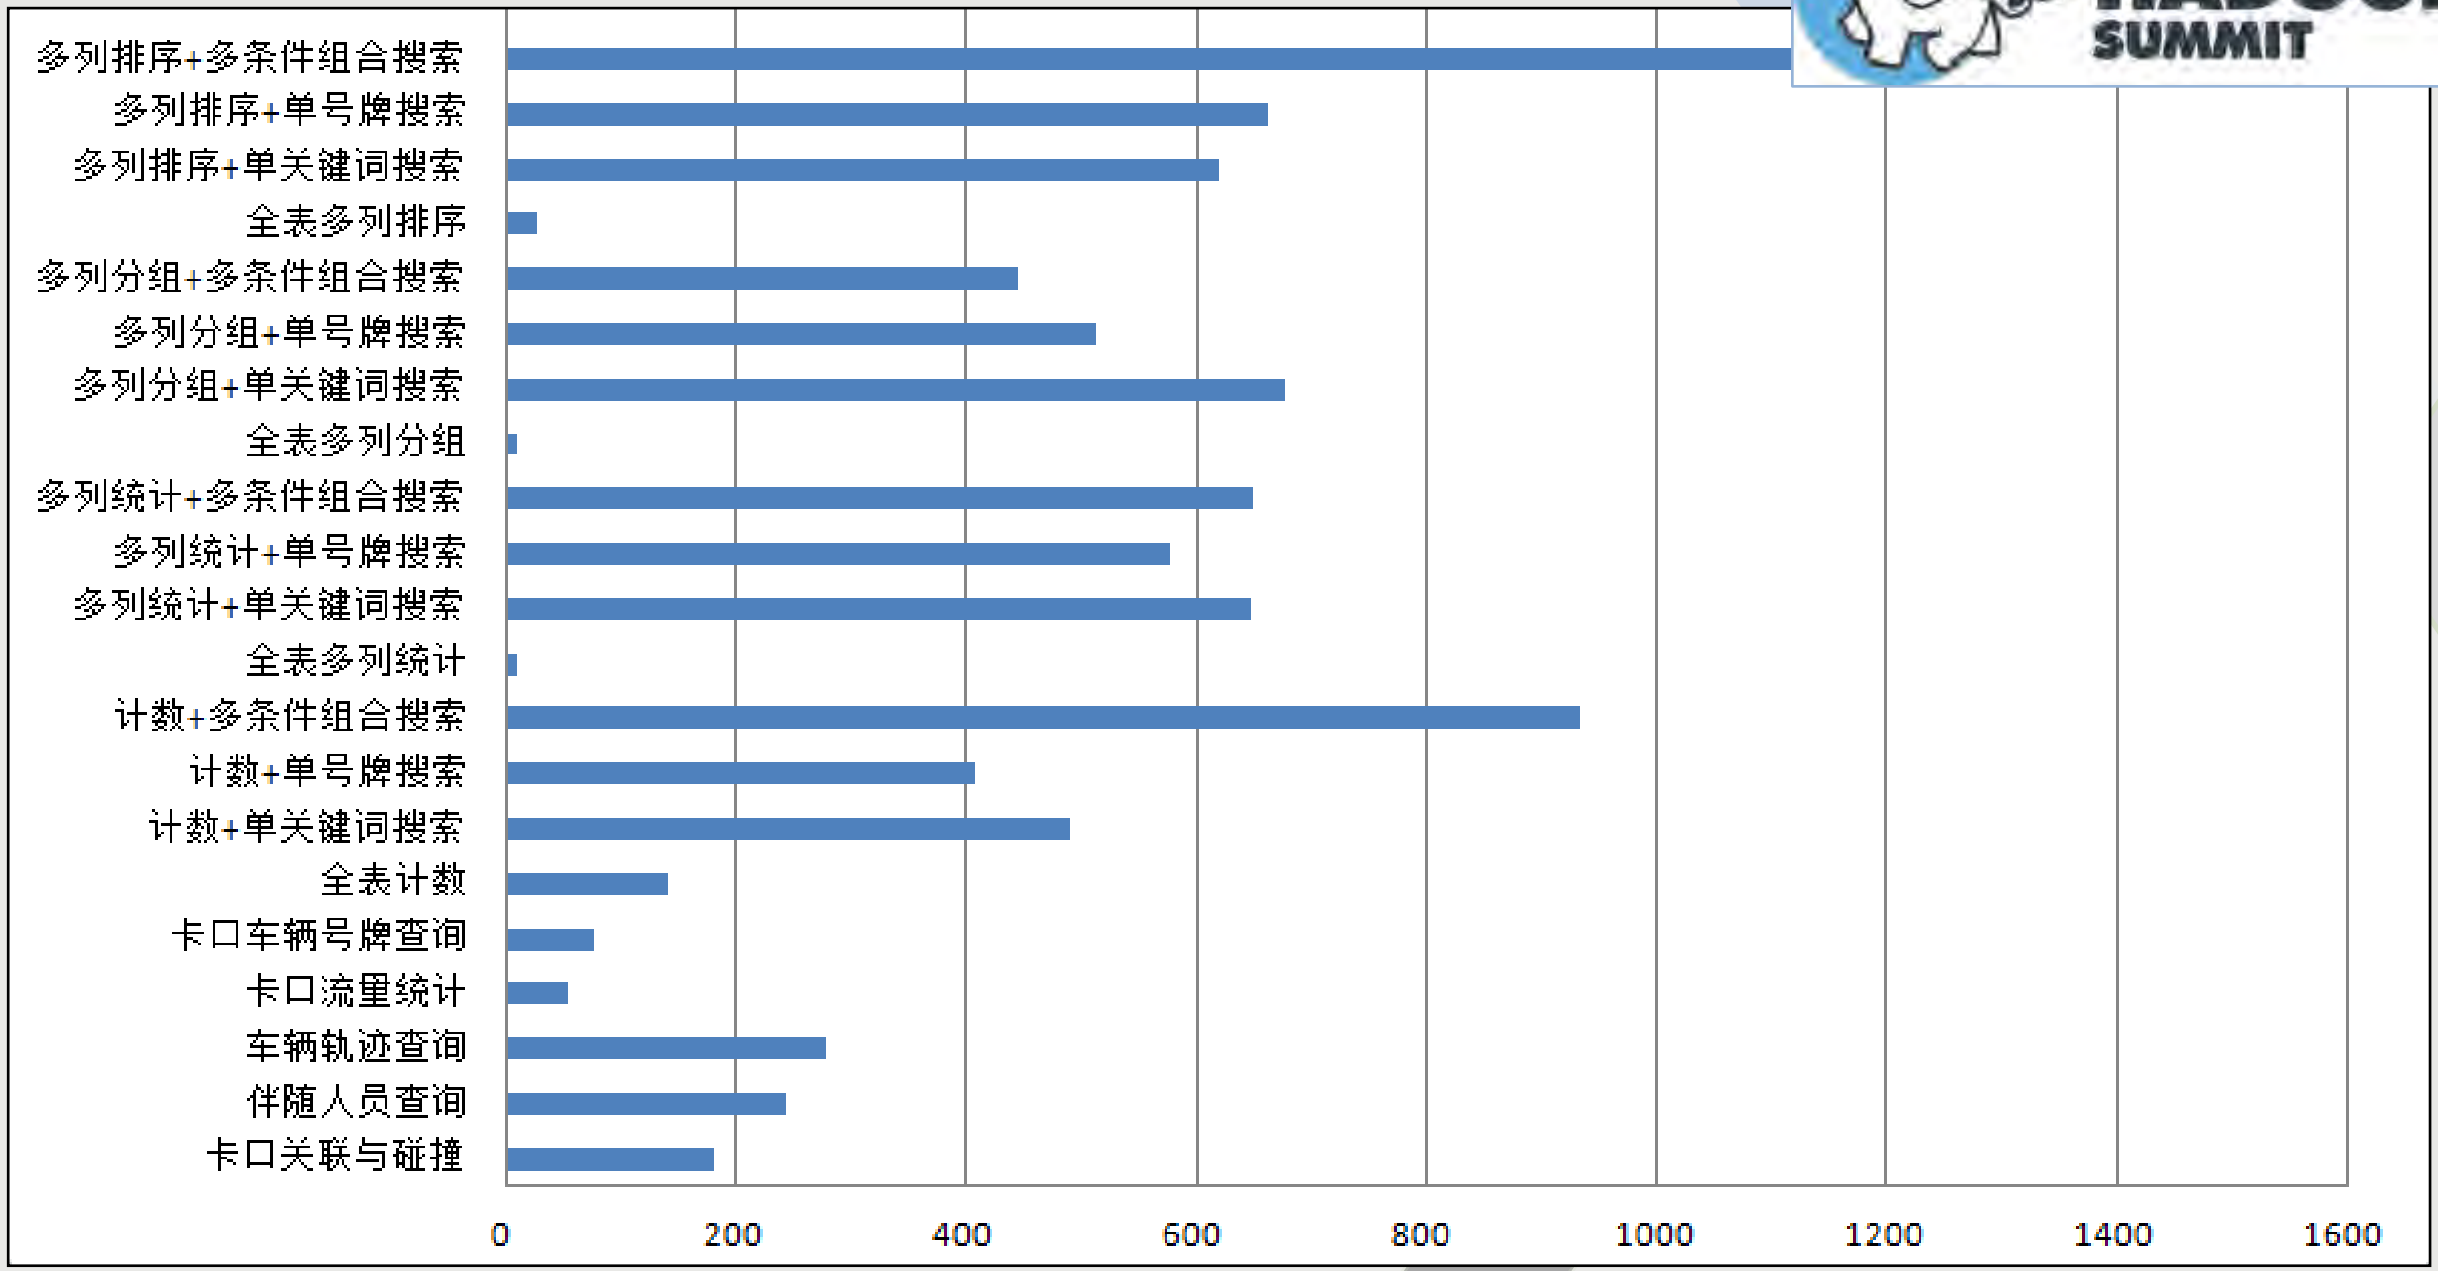

机动车稽查

测试环境	
数据条数	200亿条
数据大小	1000G
CPU	2*6核
内存	64GB
机器台数	2台

场景测试	
行车轨迹查询/重点车辆分析	0.43秒
同行车辆分析	1.56秒
区域碰撞分析	1.23秒
昼伏夜出、落脚点分析	1.5秒
陌生车辆分析	7.9秒
嫌疑车牌模糊搜索与定位	1.6秒

完备的功能-复杂的SQL查询咱必须要支持

功能	概述
检索过滤	等值匹配,支持 in操作,>,<,>=,<= and与or的嵌套组合
统计分析排序	单/多列group by,max,min,sum,avg,count,distinct,order by
复杂SQL	自定义udf,udaf,udft,SQL多层嵌套,union,多表关联join
模糊查询	全文检索,临近搜索,相似文本(文章)搜索, like。
数据类型	string,int,long,float,double,一列多值,地理位置,行存储,列存储
中文分词	内嵌二元分词，IK词库分词,也可自定义或拓展第三方分词。 YDB自带的ngram多元分词也更适合数字，邮箱，车牌，符号的匹配。

“千亿即席踪迹分析”的技术实现

架构描述

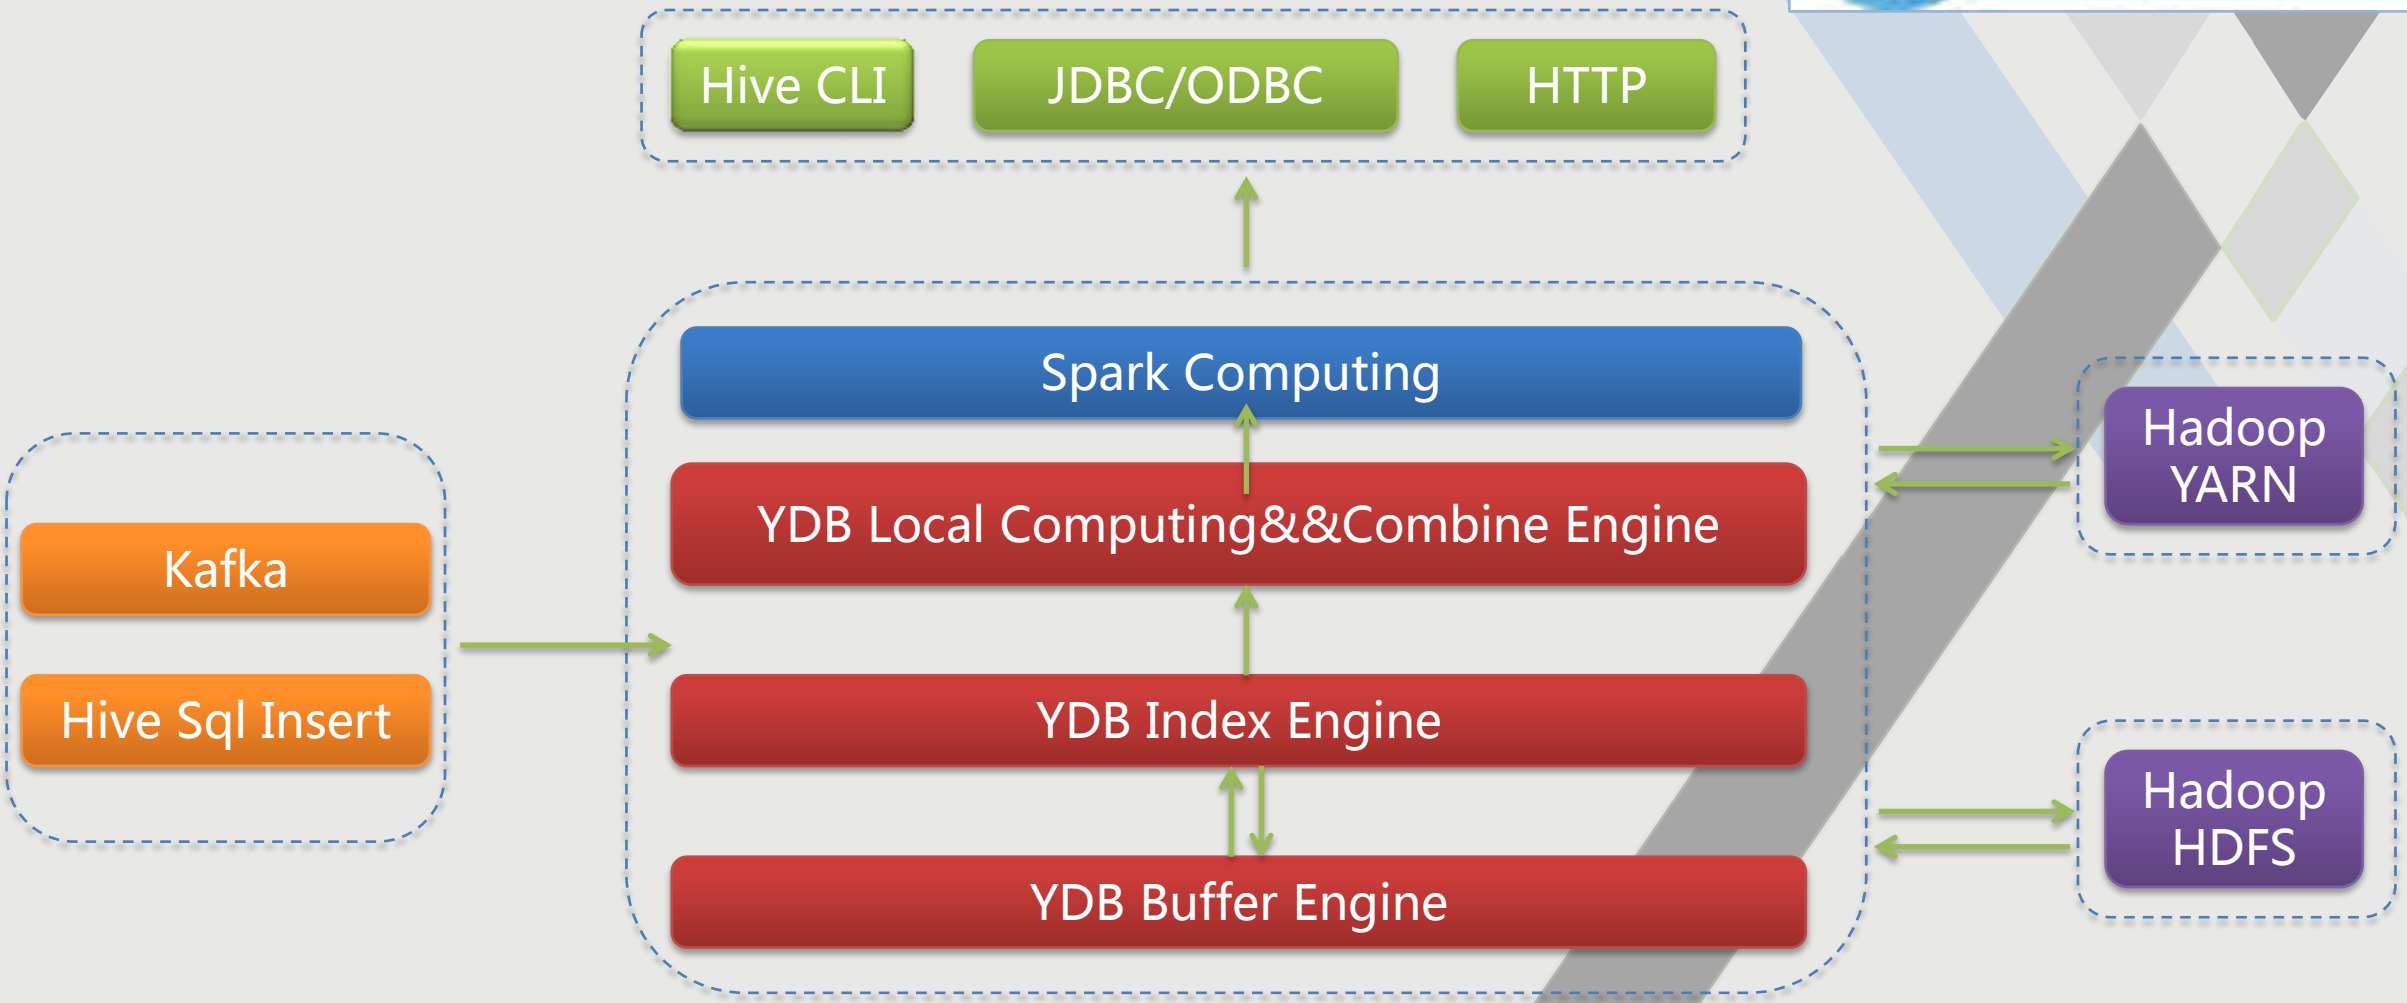
Hive CLI
JDBC/ODBC
HTTP
Spark Computing
YDB Local Computing&&Combine Engine
YDB Index Engine
YDB Buffer Engine
Kafka
Hive Sql Insert
Hadoop YARN
Hadoop HDFS

我们在hdfs之上的分布式实时索引

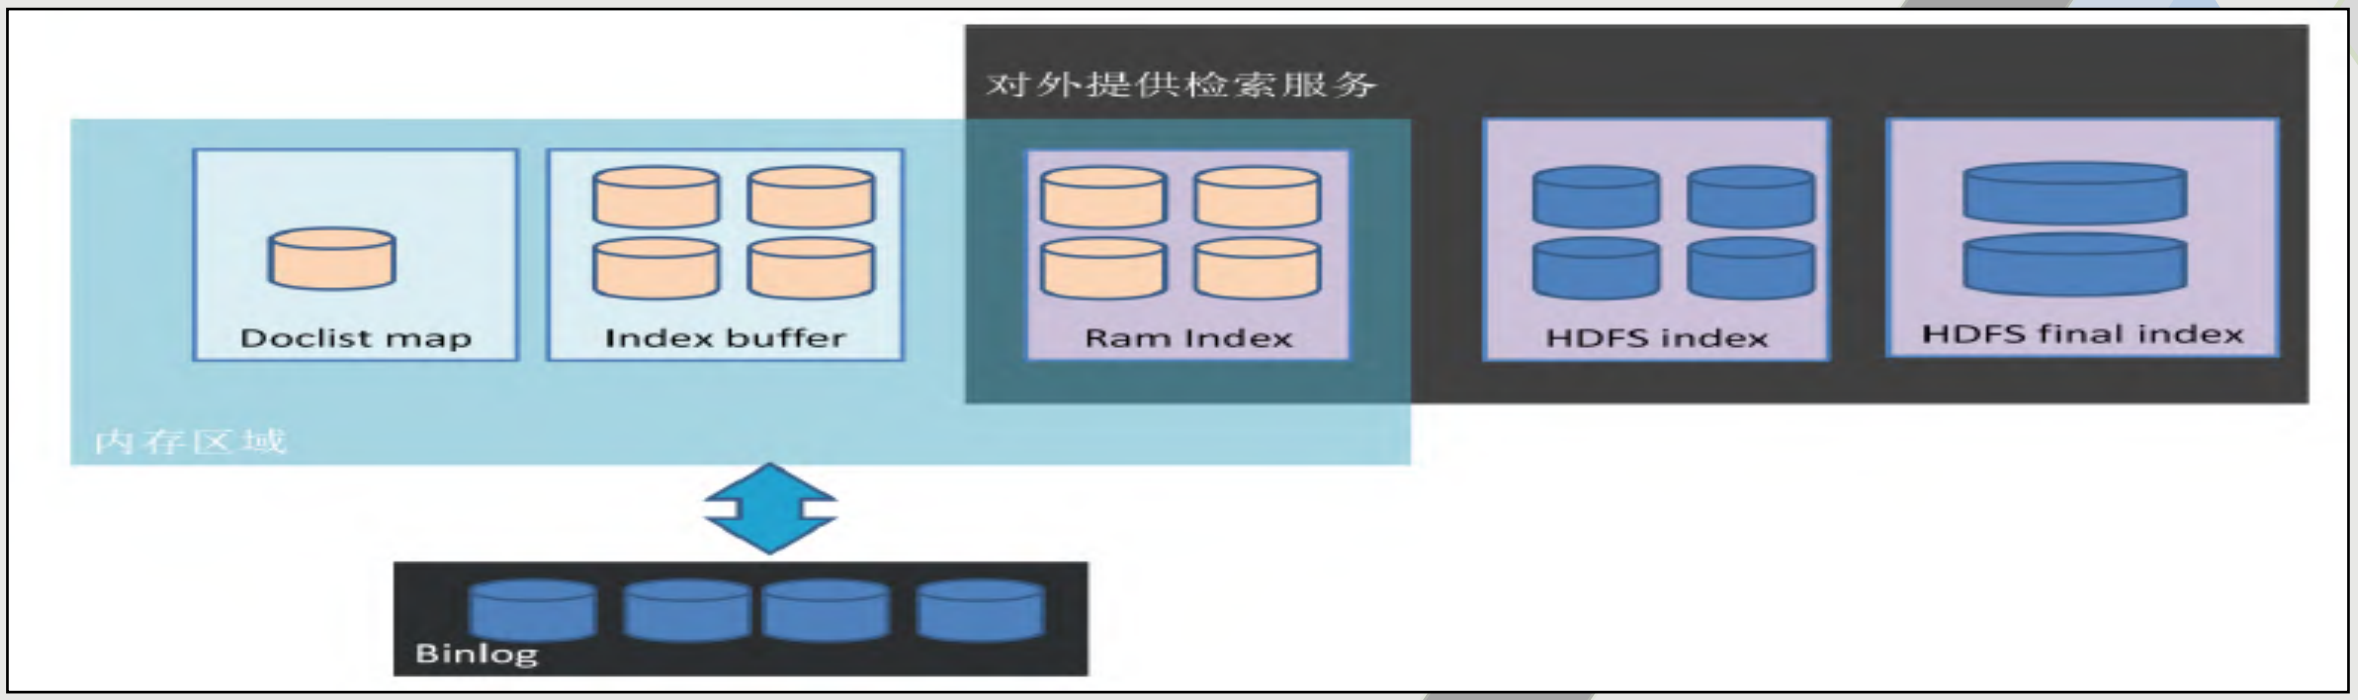

利用大索引技术跳过不需要的行

大数据就好比是一本新华字典

大多时候不需要一页一页的翻

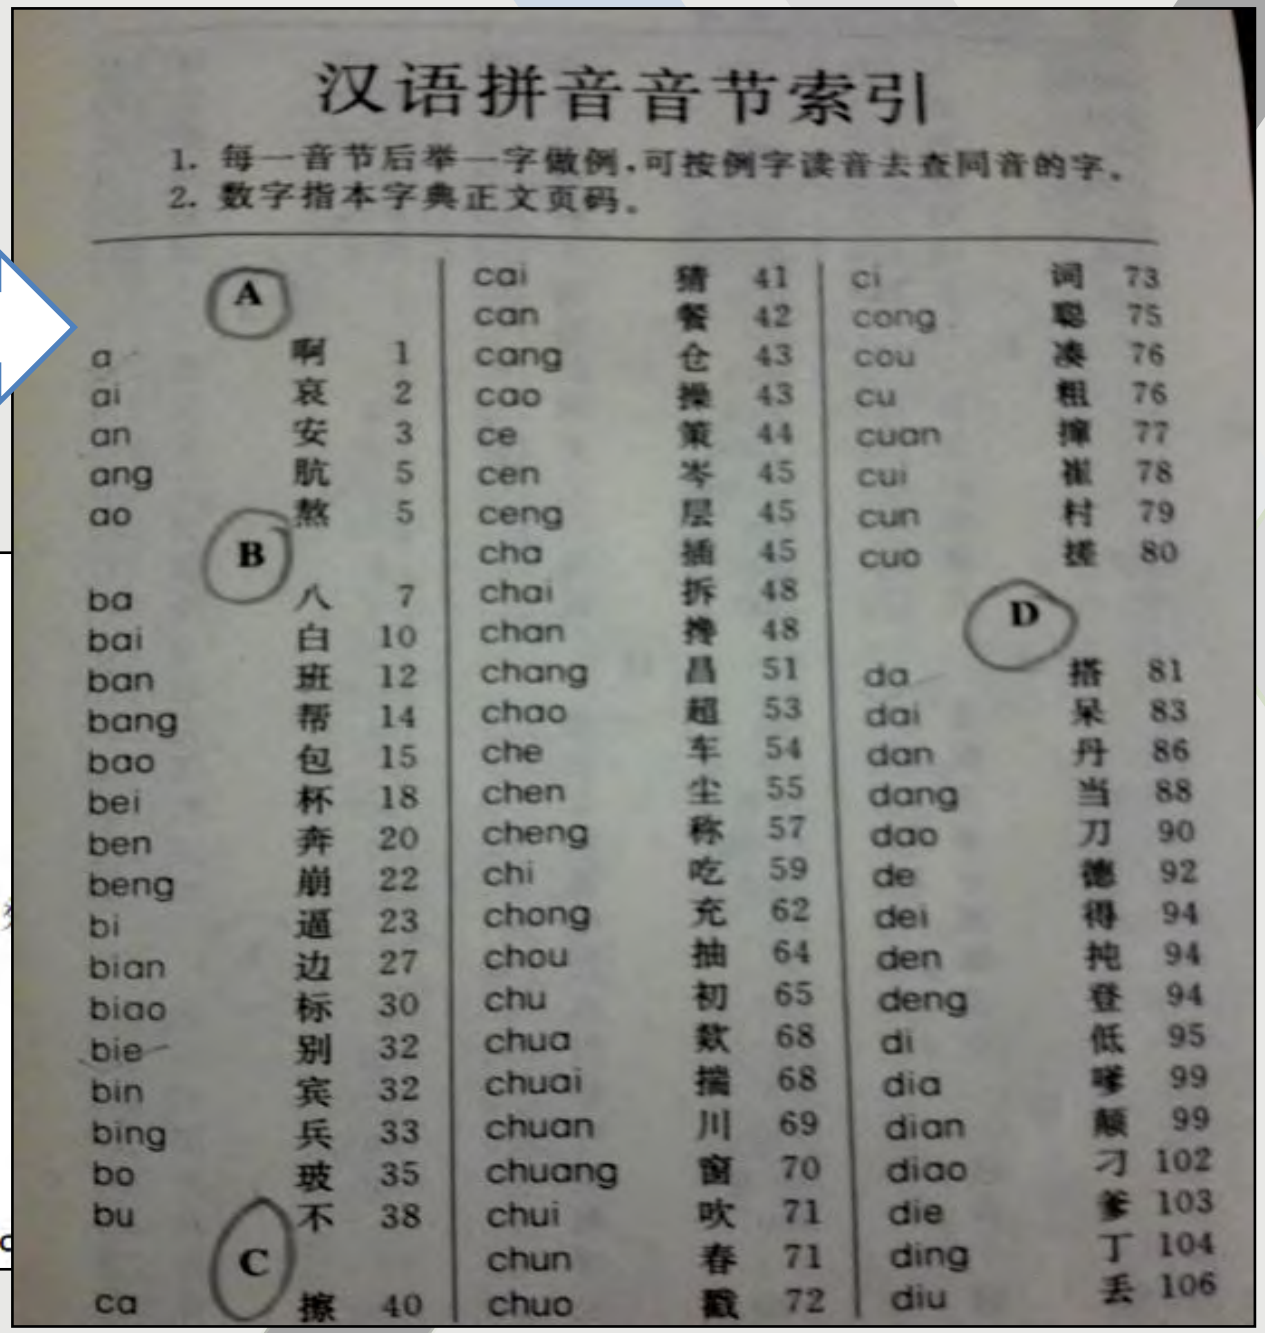

汉语拼音音节索引

1. 每一音节后举一字做例，可按例字读音去查同音的字。
2. 数字指本字典正文页码。

- 等值匹配：

如 qq="165162897"

- 支持 in 操作，

如：indexnum in (1,2,3)

- >,<,>=,<=,区间查询的写法

clickcount >="10" and clickcount <="11"

- 对于带有范围的过滤筛选，使用下面的方式能提升查询

indexnum like "({0 TO 11}) "　　不包含边界值

indexnum like "([10 TO 11]) "　　包含边界值

- 不等于的写法

label<>"l_14" and label<>"l_15"

- 过滤条件可以进行 and 与 or 的组合

indexnum="1" or indexnum="2" or (clickcount >="5" and clicko

采用blockSort实现2台机器百亿数据秒级排序

采用冒泡排序、快速排序、插入排序还是希尔排序？

别闹了！就两台机器，就算您的CPU能算的那么快，您的磁盘也转不了那么快！

将数据按照大小预先划分好，如划分成 大、中、小三个块(block)。

如果想找最大的数据，那么只需要在最大的那个块里去找就可以了

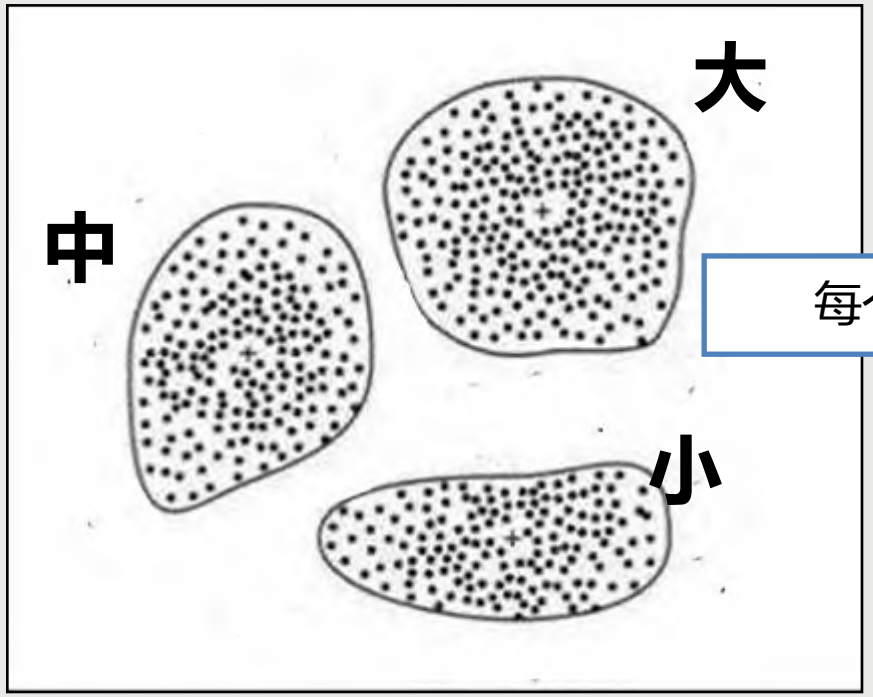

每个block内还有子block

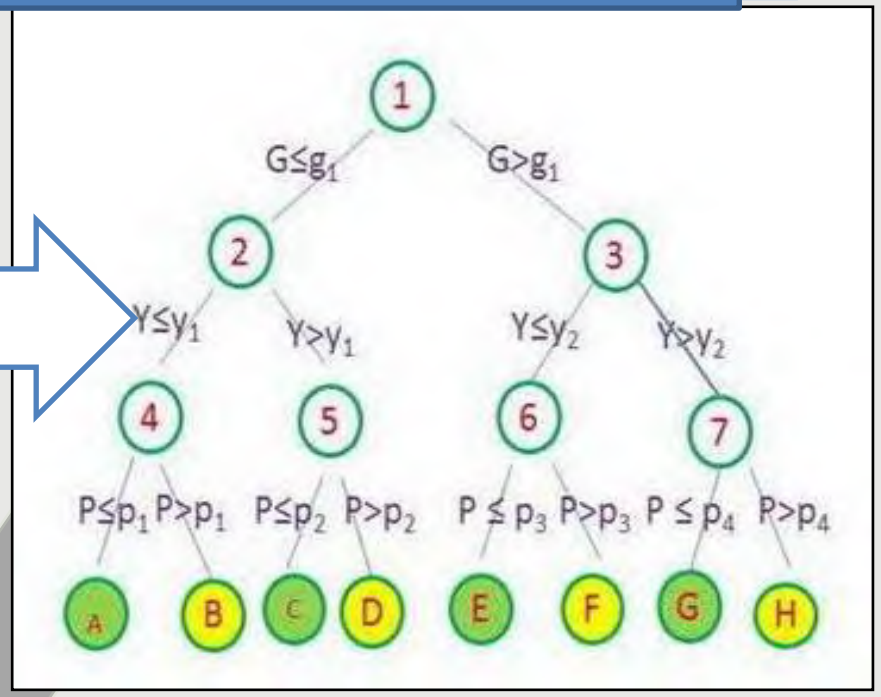

采用标签技术的按单元格存储-提升统计分析性能

原始值
张三
王五
李四
张三
李四
张三
王五
李四
赵六
张三
王五
张三

给原始值排重后由小到大加标签

标签值	字典值
0	张三
1	李四
2	王五
3	赵六

优点

1. 重复值仅存储一份，可以减少存储空间占用。
2. 标签值采用定长存储，可随机读取。
3. Group by分组计算的时候，使用标签代替原始值，数值型计算速度比字符串的计算速度快很多。
4. 标签值的大小原始值的大小是对应的，故排序的时候也仅读取标签进行排序。
5. 标签比原始值占的内存少。

缺点

1. 如果数据重复值很低，存储空间相反比原始数据大。
2. 如果重复值很低，且查询逻辑需要大量的根据标签值获取原始值的操作的时候，性能比原始值慢。

因为标签的存在-我们的数据按列定长存储

既按行 又按照列

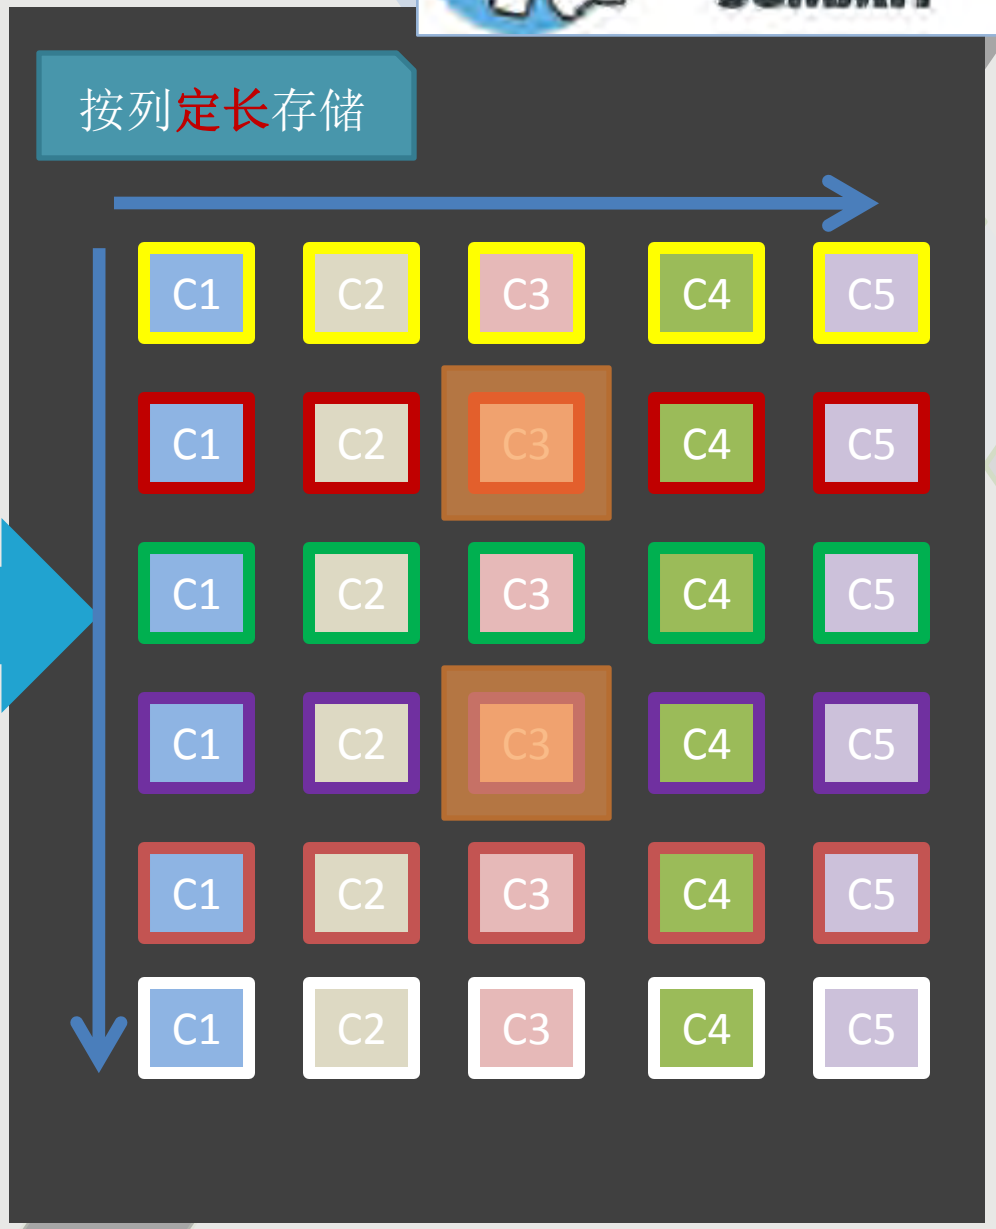

采用两段式查询与延迟读取技术 减少不必要的IO消耗

SQL场景：按照日志时间排序

```
select
    phone,name, lon,lat,logtime,speed,mac,content
from spark_txt
    order by logtime desc
limit 10;
```

第一次查询，**只读需要排序的列，以及行ID,第一次查询不会获取数据的真实值,仅仅读取数据标签**

第二次查询，才将剩余过滤后的10行的其他列的值返查回来

延迟读取可以节省磁盘IO与跳跃次数。

持久化的进程+process local+LRU Cache

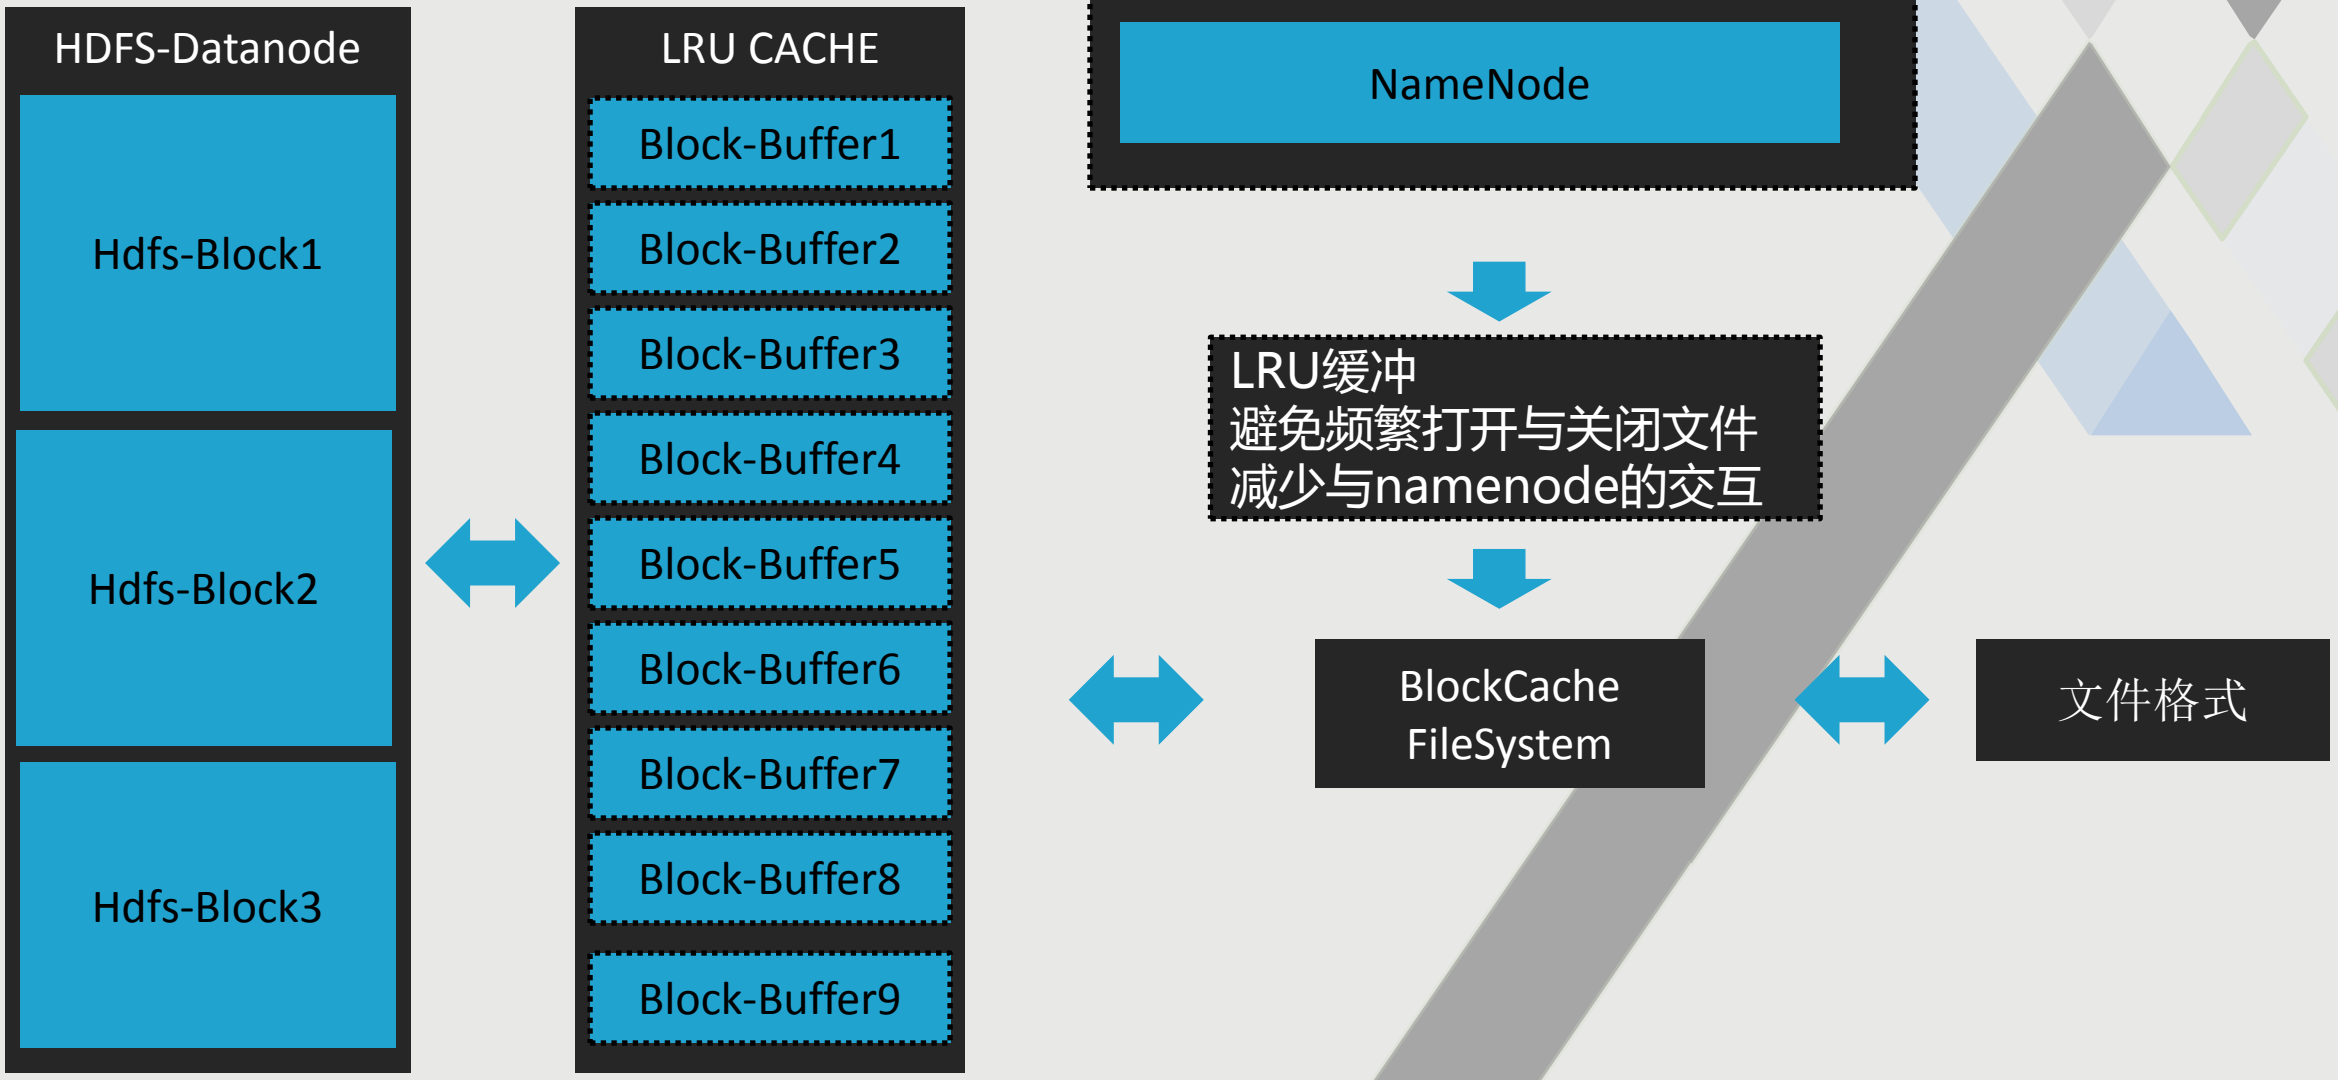

基于spark，细粒度的原子调度，一个比job更细粒度的调度

现有spark任务调度的缺点

1.只有fifo与fair 没有容量调度，一个任务可以占满全部的资源。

2.调度粒度为job级别，资源腾出时间为分钟级别，是等待还是kill掉。

原子调度：

1让用户能够精细化的管控资源，任务切分粒度更细。

2.优先级较高的任务可以毫秒的时间抢占优先级低的任务资源

原子任务切分

将一个job切分成更细的小的原子粒度，**如每个64m的task任务按照8k切分成一万个原子单元**

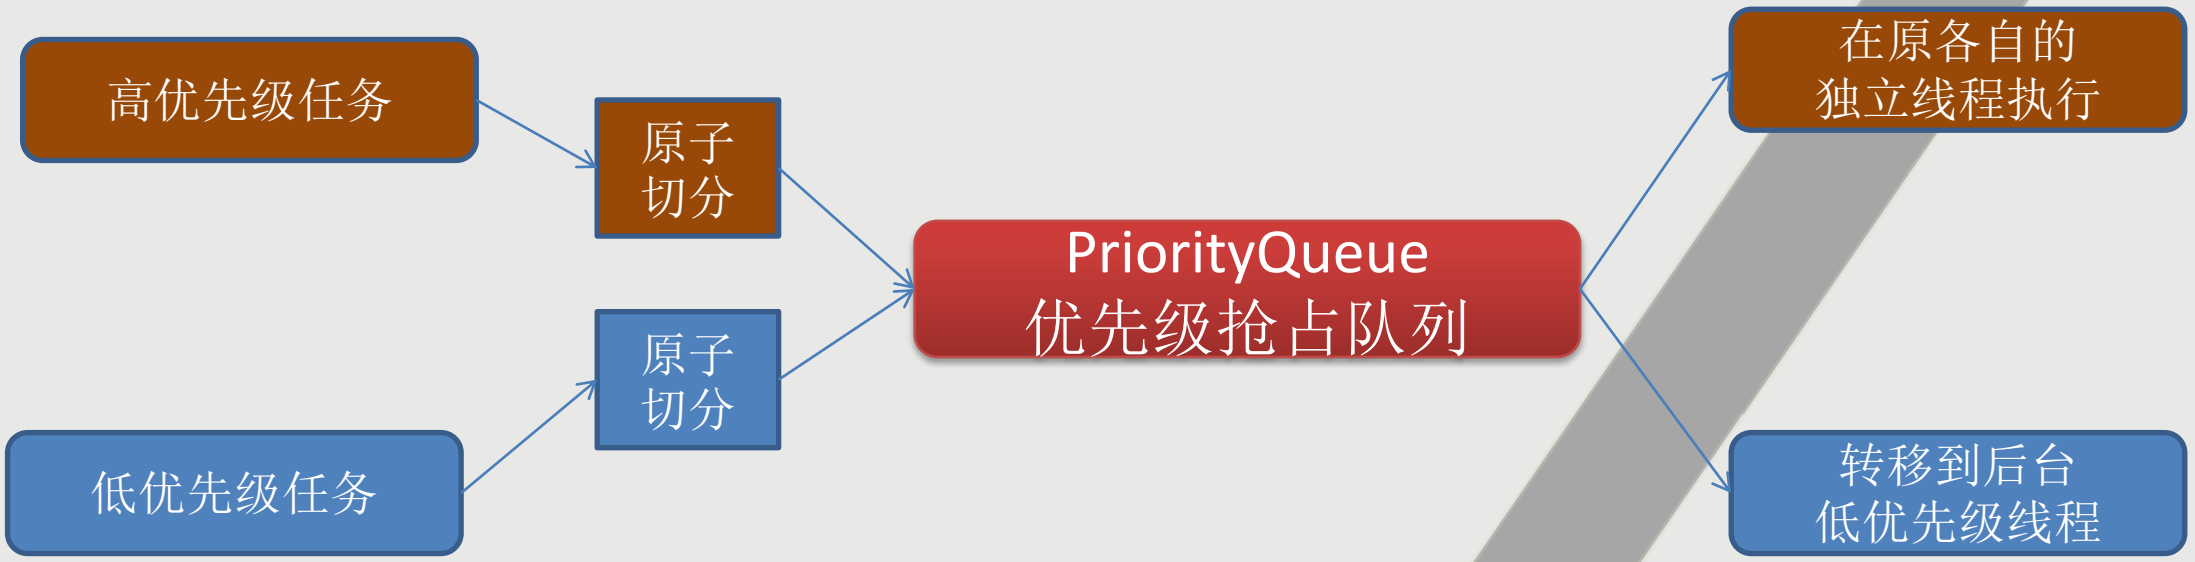

巧用Spark的brocast广播 提升join性能


```
select * from A where
  userid in (select userid from B where action= 'TO DO STH')
```

问题：

1. A 表需要全表扫描么？是不是利用上索引更好？
2. 索引的in操作，如何获取到B表的筛选结果？

思路：

1.借助Broadcast的p2p特性，将小表数据广播到每个节点。
2.利用索引让小表关联更高效。

基于spark，但我们修改了spark的一些影响稳定的BUG

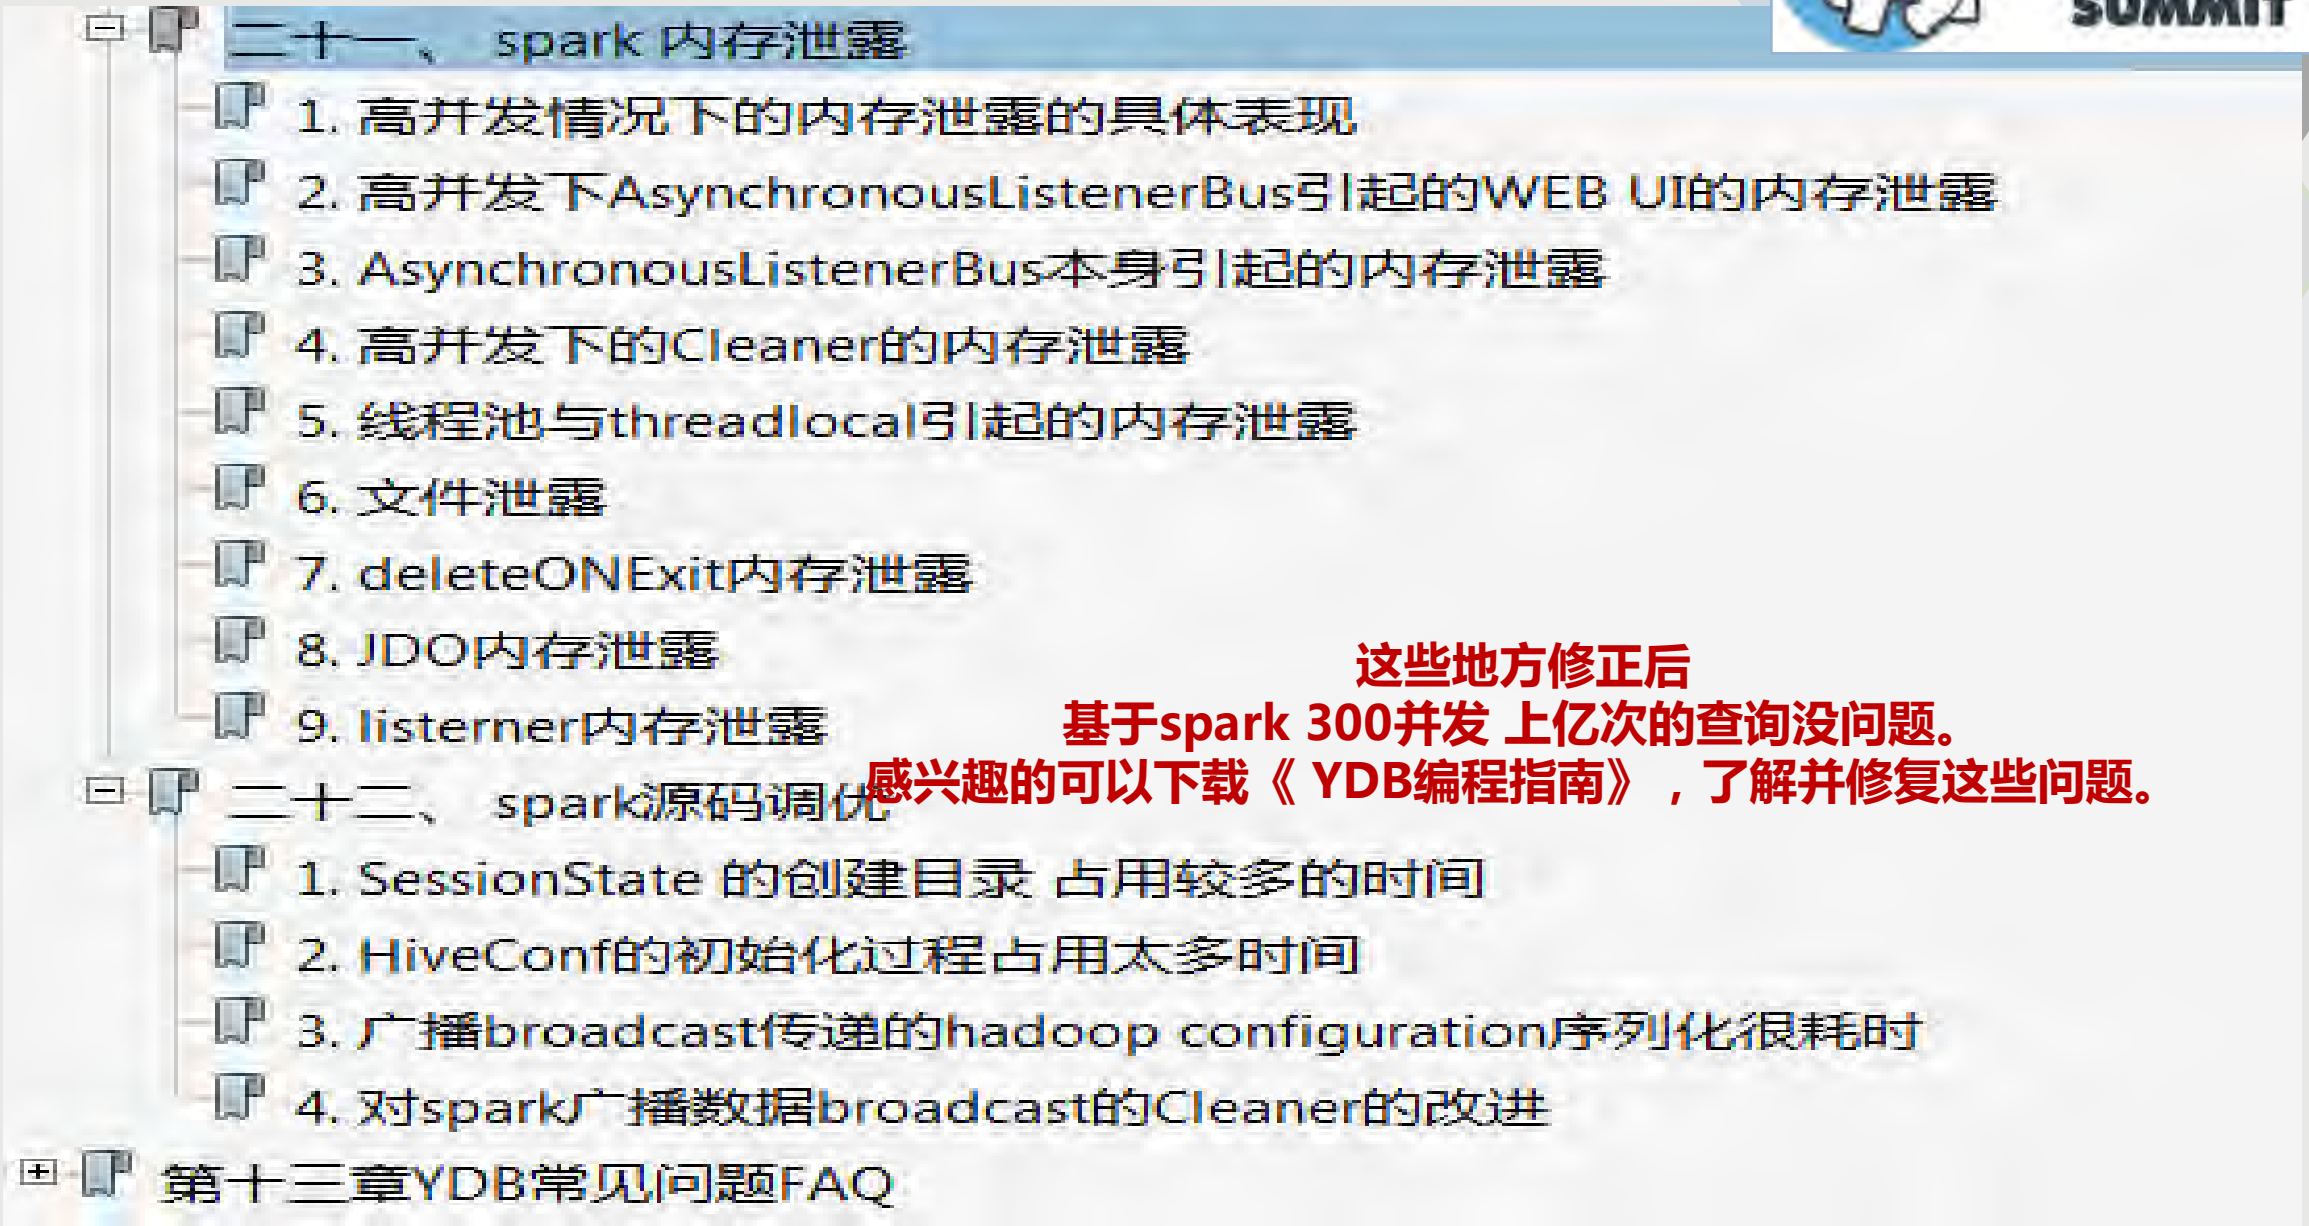

这些地方修正后
基于spark 300并发 上亿次的查询没问题。
感兴趣的可以下载《 YDB编程指南》，了解并修复这些问题。

谢谢大家!