DTCC

2017第八届中国数据库技术大会

DATABASE TECHNOLOGY CONFERENCE CHINA 2017

基于SparkSQL的海量数据仓库设计与实践

360大数据基础架构团队　李振炜

2017.5.13

大纲

- Spark在360的实践与改进
- SparkSQL多数据源整合
- SparkSQL海量数据即席查询的实现

Spark在360的实践与改进

- 团队
  - 奇虎360大数据基础架构团队
  - 离线计算
  - 早期spark推广应用到生产环境的团队；
- 集群规模
  - 总物理机结点数超过8k，
  - 单集群最大节点超过3k；
- Spark任务
  - 10w
  - SQL， MLLib, Streaming

Spark在360的实践与改进

- 改进
  - SQL
    - 扩展语法，优化执行，提高效率
  - MLLib
    - 实现多个社群发现算法
    - 改进PageRank算法，比自带算法速度提升5倍
    - 改进LR算法，支持千万+高维特征
    - 为LDA算法扩展gibbs sampling
    - 改进word2vec，精度接近单机版
    - 引入了FM，xgboost等
  - 深度学习
    - TensorFlow，MXnet，Caffe

Spark在360的实践与改进

- SparkSQL替换Hive
  - 封装为spark-hive
  - 现在已经完成了hive作业向Spark的迁移
  - 稳定运行的SQL作业超过5W

Spark在360的实践与改进

- SparkSQL改进 (50+)
  - Insert overwrite local directory的支持
  - 修复SortMergeJoin 数据倾斜出现OOM
  - 修复Shuffle使用堆外内存，造成executor的内存超限
  - 修复动态资源调整的时候，Driver端出现死锁

SparkSQL多数据源整合

- 动机
  - 数据存储多样
    - 不同的数据在不同的存储
    - 同一份数据在不同的存储
  - 熟悉不同的平台
  - 数据频繁导入导出
  - 业务逻辑复杂

SparkSQL多数据源整合

多数据源整合架构

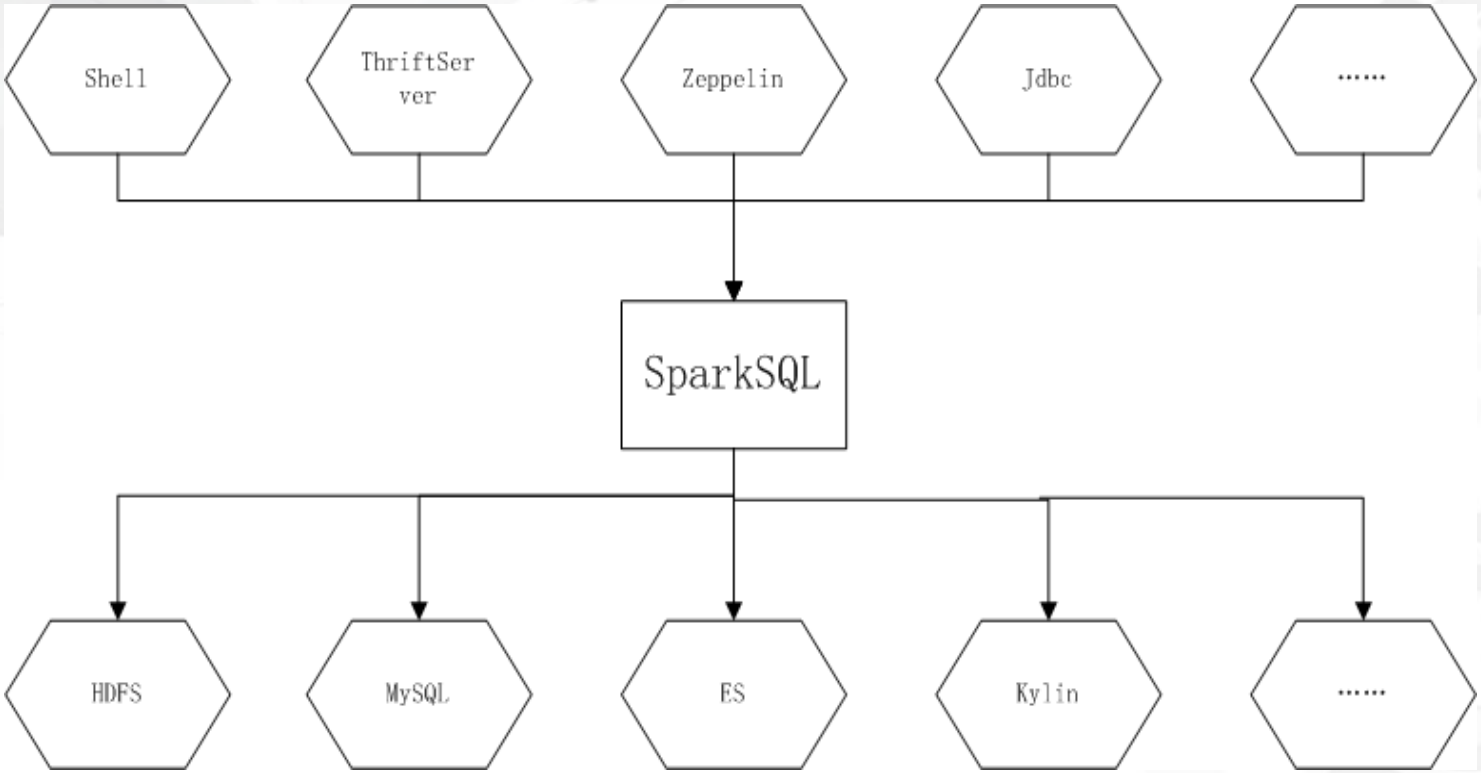

SparkSQL多数据源整合

- 基于ES全文检索
  - 增加TEXT类型，标记分词
  - 扩展建表，删表语法
  - 支持Lucene检索语法
  - SQL查询转换为ES查询

SparkSQL多数据源整合

- 基于Kylin的OLAP

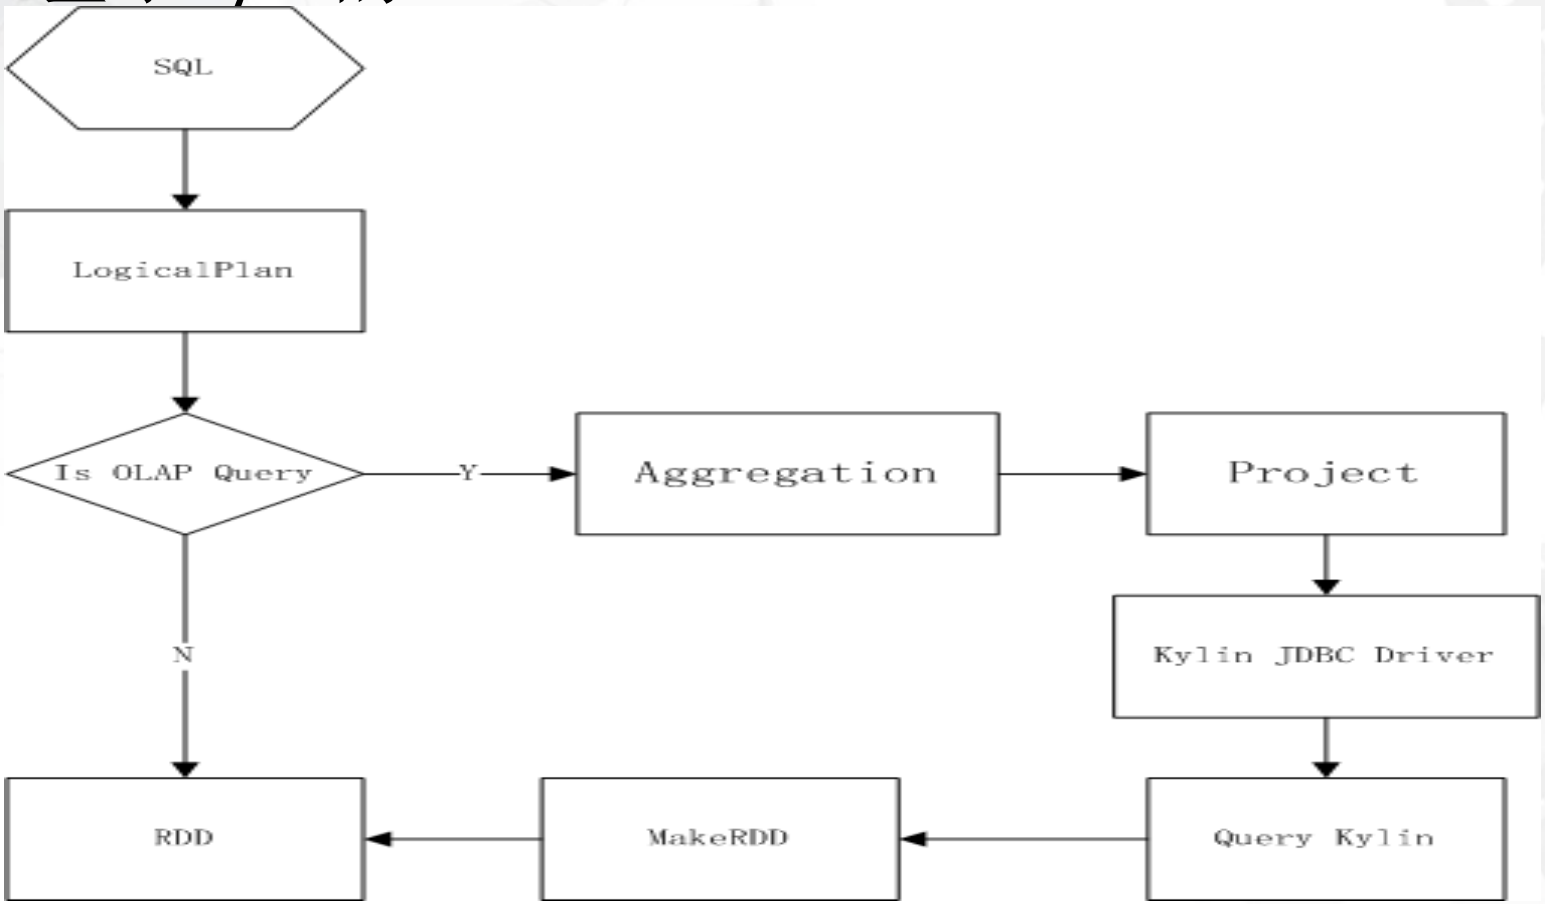

SparkSQL多数据源整合

- 优势
  - 同时分析不同的数据源中的数据
  - 根据不同的SQL自动选择合适的数据源
  - 分析结果写入合适的数据源

SparkSQL海量数据即席查询的实现

- 面临的痛点
  - 数据量与查询效率的矛盾
  - 顺序读与随机读的矛盾
- 现有方案
  - 不同的需求对应不同的存储
- 影响
  - 数据多份存储，增加存储成本
  - 引入多个平台，运维成本高
  - 有些平台的分布式横向扩展遇到瓶颈

SparkSQL海量数据即席查询的实现

- 前提
  - 在Spark+hadoop的框架内解决
  - 最好不引入新的存储格式
  - 兼容现有的业务逻辑

SparkSQL海量数据即席查询的实现

- 方案
  - 为数据建立一套外部索引
- 设计
  - 存储： Parquet + Hdfs
  - 索引： Lucene + Hdfs + IndexServer
  - 计算： Spark

SparkSQL海量数据即席查询的实现

即席查询架构

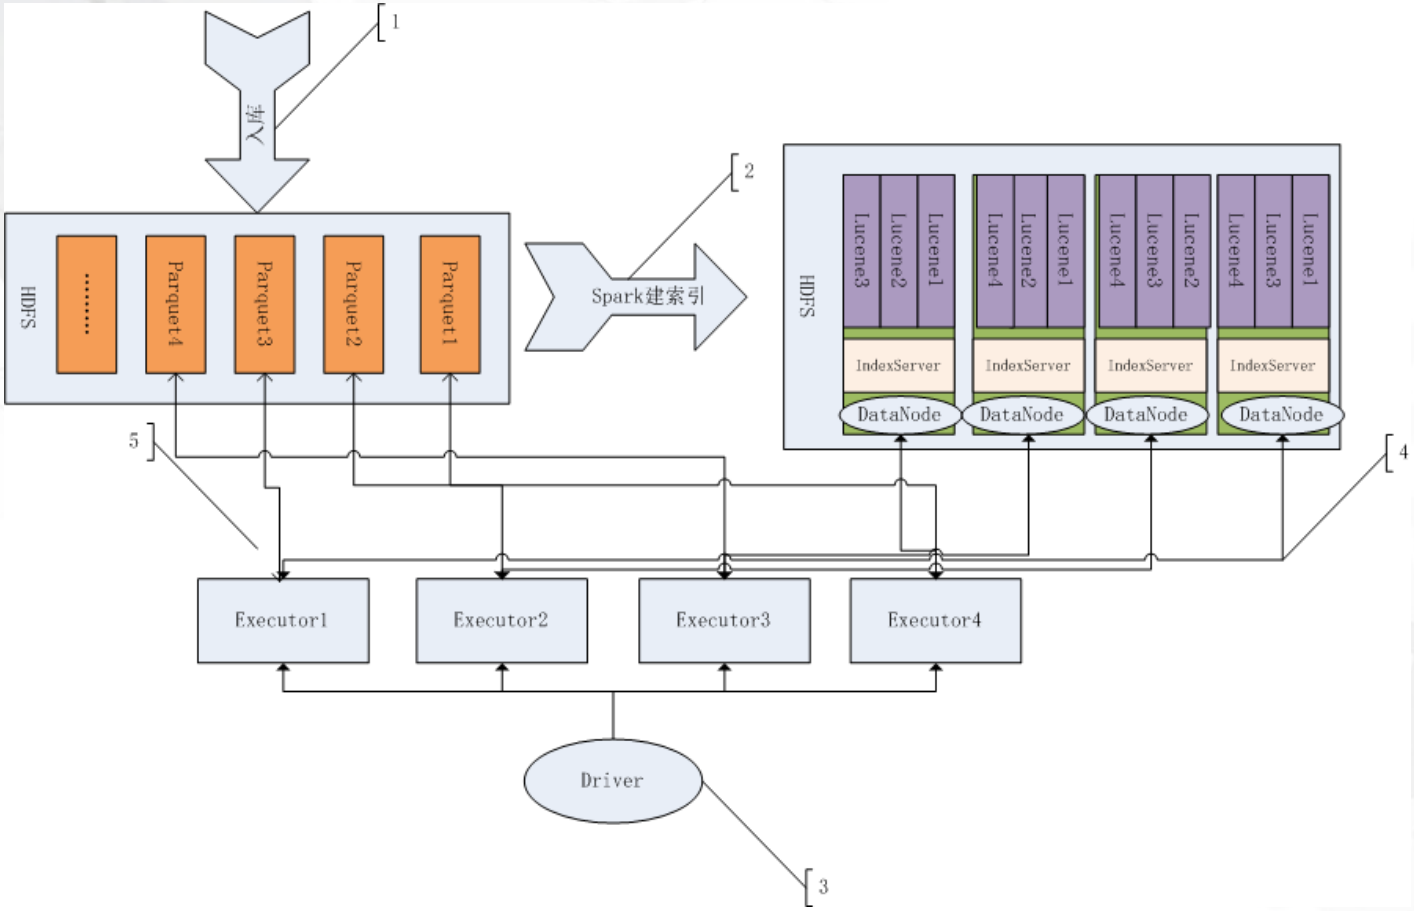

1.清洗后的数据以Parquet格式写入HDFS；

2.用Spark对每个Parquet 文件批量建Lucene索引。

3.SQL查询转化为Spark任务；

4.每个Executor由所处理Parquet 文件，得到对应索引文件所在DataNode的地址，向其IndexServer发起查询请求并得到命中的索引；

5.根据索引读取对应的Page，返回查询结果。

SparkSQL海量数据即席查询的实现

入库优化

- 按行数划分Page。
- 每个RowGroup中都记录每列值最大值和最小值，可以作为一个粗粒度的索引。在此基础上，我们对数值列做了进一步改进：计算出均值和标准差，对应列数值做如下处理

$$x' = \frac{x-\mu}{\sigma} \qquad x_{new} = \begin{cases} 3 & x' \geq 3 \\ x' & other \\ -3 & x' \leq -3 \end{cases} \qquad y_n = if\left(n == Round\left(\frac{x_{new}+3}{6}N\right)\right)\ 1 else\ \ 0$$

把均值和标准差以及由 $y_0 y_1 \ldots y_{N-1} y_N$ 组成的Byte数组写入到RowGroup元信息中。

- 为整个Parquet文件也建立改进后的索引。

SparkSQL海量数据即席查询的实现

建立索引

- 读取元信息
- 写Lucene文件
  - 每行作为一个Doc
  - 索引列作为Field
  - 为每个Parquet文件单独建索引
- 优化
  - 只索引而不存储
  - 增大数值类型切分精度
  - 删减Lucene功能

SparkSQL海量数据即席查询的实现

SparkSQL转化

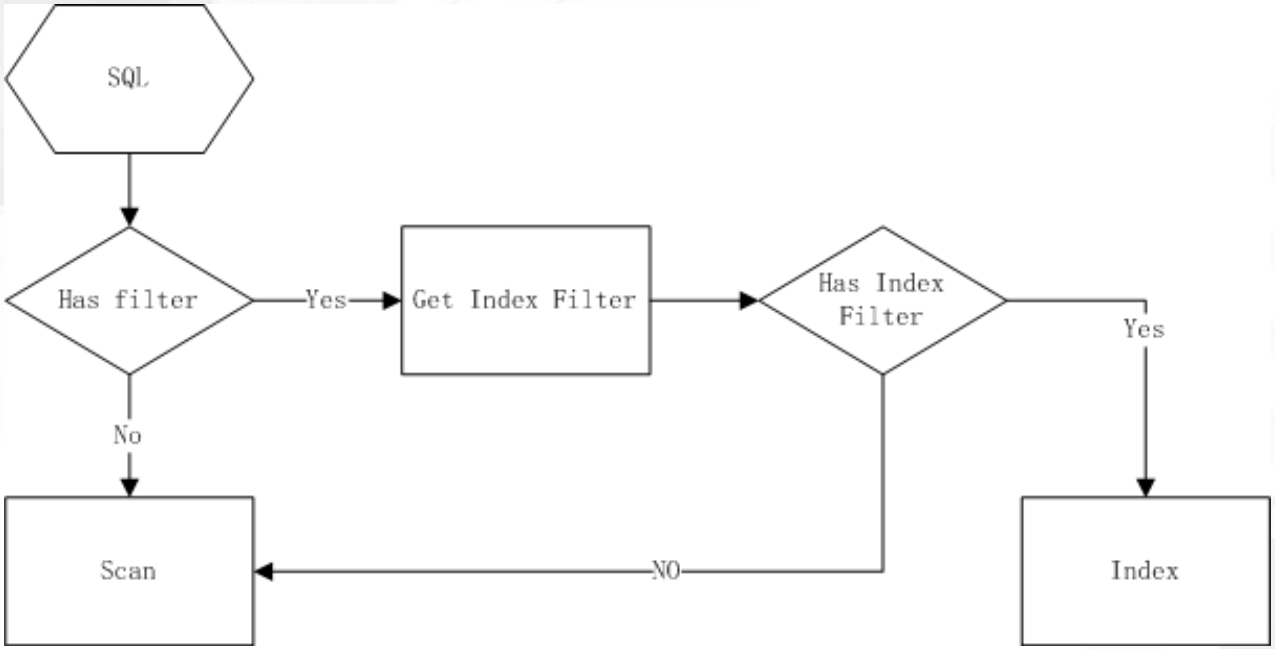

SparkSQL海量数据即席查询的实现

SparkSQL转化

- 优化
  - 每个Parquet为一个Task
  - 缓存元信息
  - 合并Spark Task
  - 复杂Filter下推
  - 字符串查找匹配

SparkSQL海量数据即席查询的实现

SparkSQL执行查询

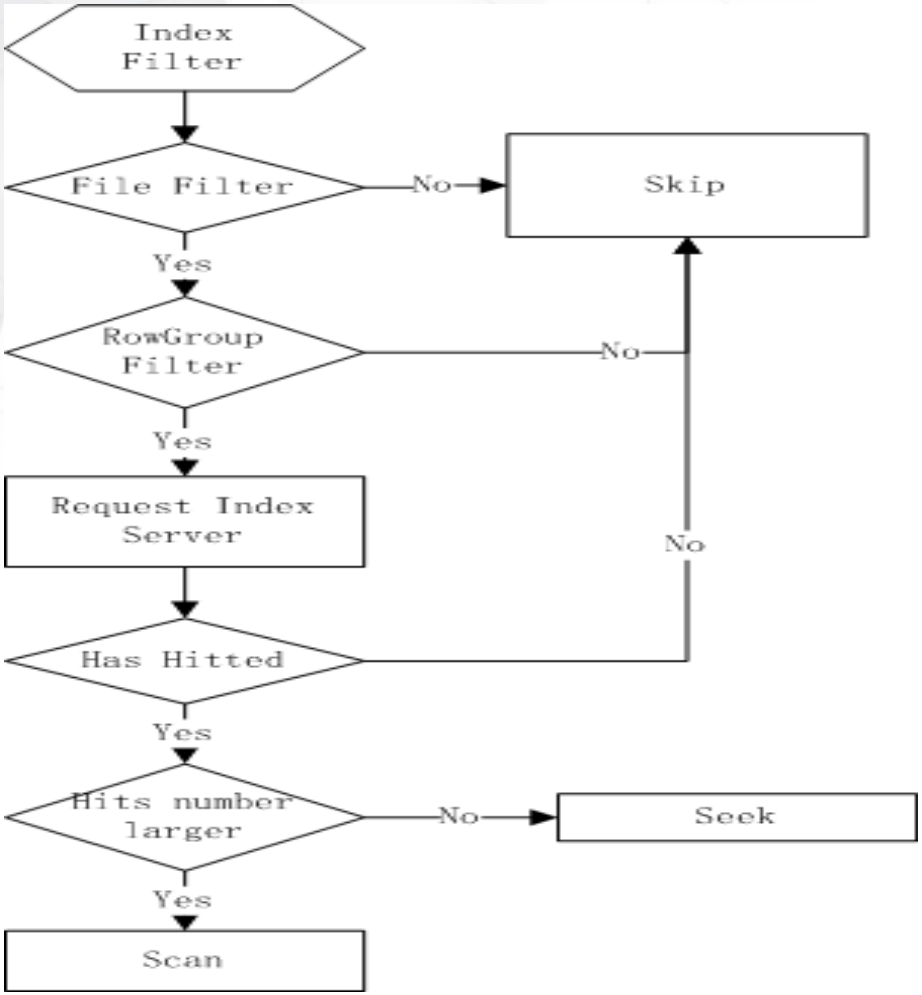

每个Task根据索引查询结果自动选择是执行Scan还是Seek.

SparkSQL海量数据即席查询的实现

SparkSQL执行查询

- 索引查询策略：固定数据，移动查询。
- 索引文件多副本，发起多个查询，最先返回的作为结果，避免查询长尾的出现，保证查询的稳定性。
- 索引文件的管理全部依赖于Hdfs，具有极强扩展能力，同时减少运维压力。
- IndexServer 是无中心，无状态独立服务，依托于多副本，自动实现容错。

SparkSQL海量数据即席查询的实现

SparkSQL读取数据

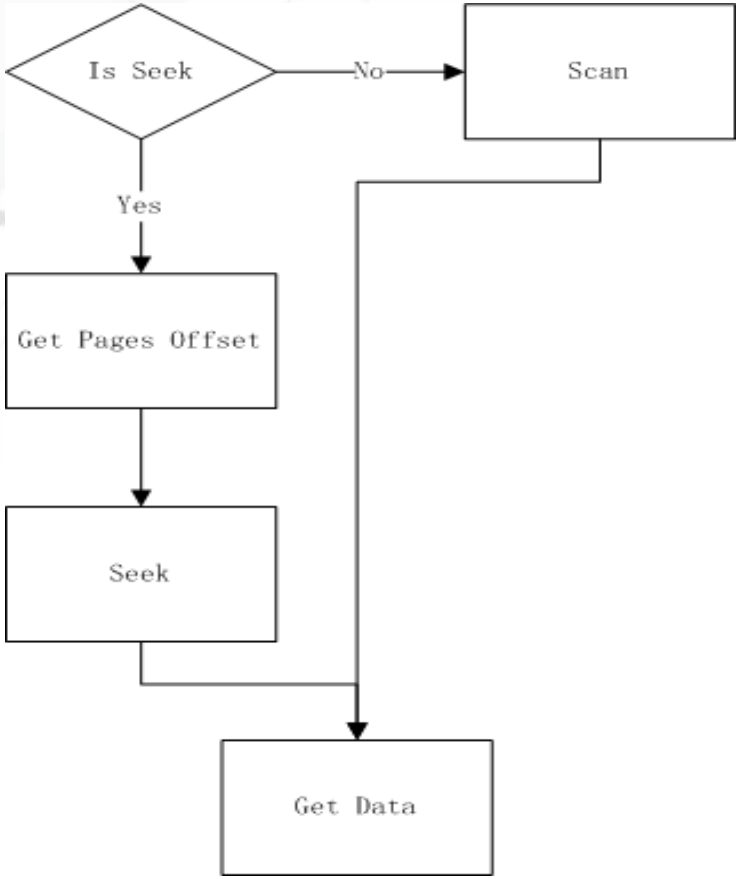

SparkSQL海量数据即席查询的实现

性能分析

- 分析背景
  - 数据
    - 选取万亿规模的真实业务数据
    - 包括20W个Parquet
    - Parquet文件总大小约70T
    - 每个Parquet包含500W条记录
  - Spark集群
    - 125个Executors,
    - 每个Executor: 4cores and 5G
  - 测试SQL
    - Select count(*) from table where a="748e8837b09e6b253de7389de6c7e2c4“ and b="748e8837b09e6b253de7389de6c7e2c4“ and c like "3110002037%“
    - 命中结果为27710，大约分布在5%的文件中

SparkSQL海量数据即席查询的实现

性能分析

- 过程分析
  - 对于全表遍历的数据的情况：
    - 读取单个Parquet文件，逐行遍历，并返回命中的结果，需要的时间5s
    - 实测时间为2376s
  - 利用索引，随机读数据：
    - 查索引且未命中的代价平均为50ms
    - 查索引命中且从Hdfs读取对应的Page，遍历Page，返回命中结果，需要时间平均200ms
    - 实测时间为27s

SparkSQL海量数据即席查询的实现

总结

- 数据和索引分离，完全兼容现有的业务；
- 数据和索引存储于Hdfs，可以支持海量的数据；
- IndexServer无中心，无状态，容错及负载均衡天然与Hdfs绑定，运维成本低；
- 查询找数据，避免了数据的网络传输；
- 顺序读和随机读可以根据具体的执行逻辑，自动切换，并且代价很低；
- 对于不再使用的索引，可以单独删除，节约空间。

THANKS

SequeMedia 盛拓传媒 ITPUB ChinaUnix