



一种支持实时复杂查询和分 析的NoSQL系统

中科院计算所

INSTITUTE OF COMPUTING TECHNOLOGY

王树鹏

中国科学院计算技术研究所



题 纲

- 系统需求与现有方案
- 技术方案
- 应用案例



系统需求概述

■ 数据及系统特点

- 结构化：每条记录包含10个字段左右，每条记录的大小大约是几百字节
- 数据量巨大：达到千亿级以上，达到PB级
- 加载速度快：达到百万条/s的规模
- 系统规模：可以扩展到上千个节点



系统需求概述


■ 对数据的访问需求

- 提供SQL访问接口
- 支持大规模结果集：达到千万条规模
- 支持按多列的实时查询（秒级）
 - 支持多列之间的逻辑比较关系，例如AND、OR、NOT等
 - 支持多列之间的的算术比较关系，例如=、>、<等
- 支持统计、聚合、分组、排序等操作（秒级）
 - ORDER BY ASC (DESC), GROUP BY, TOP, LIMIT
 - SUM, COUNT, AVG, MAX, MIN
- 数据不更新，但需要对数据批量删除




现有方案(1)—关系数据库

- 关系型数据库都主要关注了CA，即一致性和可用性
- 性能、可扩展性上都比较差
- 无法满足可扩展性和性能的要求



单机数据库结构




Oracle RAC



现有方案(2)—关系数据库集群

- 数据分片(sharding)或者功能分区
- 将数据按照不同的策略进行划分：功能、字段值范围、HASH等
- 优点：能够有效的解决可扩展性的问题
- 缺点：shard的扩容比较复杂；联合多个shard的表数据查询复杂。





现有方案(3)-NoSQL方案

■ NoSQL（非关系型）

- NoSQL $\neq$ No SQL，而是No Relationship，Not Only SQL

■ 系统特点

- 可以处理超大规模的数据，可支持到千亿规模
- Sharing-Noting架构，可扩展性强
- 数据加载速度快，并可随节点个数线性增长



现有方案(3)-NoSQL方案

- 根据特定应用场景的需要设计开发了很多NoSQL系统
 - 分布式KV型：例如：Dynamo, PNUTS、Flare
 - CF型： 例如：Bigtable, Cassandra和Hbase。
 - 文档型： 例如：MongoDB, couchDB




现有方案(3)-NoSQL方案

- 现有No-SQL数据管理系统检索能力差
 - K/V型：仅支持基于Key的查询，无法做多关键字查询以及根据Value的复杂查询
 - Column-Based型：扩展了KV数据模型的表述能力，但是仅支持关键字查询，时间区间查询，不支持针对属性的复杂查询以及统计、分析等操作



现有方案(4)—Hadoop+MR+HIVE



- 面向非实时的分析型应用
- 速度慢，无法满足实时性的要求



现有方案分析

PDBMS、No-SQL数据库、Hadoop局限性分析！

RDBMS

当节点规模扩大时，由于关系模式的约束，子表维护、数据错误等原因导致关系数据库的性能急剧下降！

Hadoop+MR+Hive

MapReduce无索引的检索方式与“pull”模式的中间数据处理流程导致检索效率低下！

No-SQL

仅支持基于Row_Key的查询，不支持多列查询，统计分析等复杂查询；针对大返回结果集的查询效率低！




现有方案分析

系统分类		典型系统	特点概述
关系型数据库		DBMS-X, Verita, GreenPlum, AsterData	具备检索复杂性, 但是不具有扩展性
Hadoop		HIVE, PIG, HadoopDB etc	具备扩展性, 但是检索效率低
No-SQL	Local Host-Key Value	TC(KC), BDB	不具备扩展性
	Hash-based Key Value	Dynamo, Pnuts, voldemort, falre	具备扩展性, 但是不支持区间查询
	Column-family	Hbase, Hypertable, Cassandra, Memcachedb, levelDB etc	具备扩展性, 但是不支持多列查询
	Document based DB	MongoDB, couchDB	加载、检索效率低



系统设计目标

- 改善传统数据库的可扩展性差，并发性差的问题
- 解决NoSQL数据的检索能力差的问题，增加多列查询、统计排序等功能






题 纲

- 系统需求与现有方案
- 技术方案
- 应用案例



系统物理架构





索引结构

■ 分布式Hash表

- 随机读，不支持范围查询
- 实例：Tair, Memcache, Dynamo, Cassandra


■ 分布式B+ Tree

- 随机读和顺序扫描，支持范围查询；
- 顺序划分不均匀，需要叶子节点分裂合并
- 实例：Bigtable & HBase, Google Megastore



索引结构

- 系统采用全局索引+局部索引机制
 - 全局索引：分布式B+树结构，支持对目标数据的快速定位
 - 局部索引：保存在每个node内部，支持复杂的查询和统计





存储及I/O方式

■ 列存储

- 每个Shard由一个或者多个Store File组成，每个store File保存一个列


■ I/O并行

- 将数据分配到Data Node的多块磁盘上；
- 数据I/O时并行从多块磁盘访问；
- 实现多块磁盘IOPS和带宽的聚合。



分布式查询流程

■ 分级、并行检索机制






分布式查询流程

- Datanode独立接收查询规划树
- 根据语法树叶节点的属性值检索局部索引
- 根据语法树内节点合并、过滤规则，生成局部结果集

SELECT * FROM TABLE WHERE
(DOMAIN= 'www.baidu.com' AND NOT VALUE
= '8.8.8.8')OR(DOMAIN = ['www.google.ak' TO
'www.google.coml'])AND NOT DOMAIN='www.google.cn*';

语法
解析



ValueList (VL)				
VLVersion	IndexCount	MAXLen	ValueIndex	ValueIndex
VLVersion	ValueCount	...	ValueInfo1	ValueInfo10
Value_Delta	ValueFreq	ValueRIDDelta	ValueRID_SkipDelta	...

RecordIDList (RIDL)			
RIDVersion	ValueToRIDList	ValueToRIDList	...
RecordID_Delta	RecordFreq_Delta	SkipList	
RecordID_Delta	RecordFreq_Delta		
RecordID_Delta	RecordFreq_Delta		

RecordIndex (RI)				
MetaInfo	RecordIOffset	...	RecordIOffset	
RecordData (RD)				
FieldCount	FieldNum	FieldData	FieldNum	FieldData

结果集





分布式查询规划—查询规划

- 投影与选择: π , θ ——shard
 - π : select DOMAIN, VALUE...
 - θ : where DOMAIN= 'www.baidu.com' and TYPE=A...
 - 在Datanode上, 针对每个shard并发处执行
- 分组与排序: Order By, Group BY——datanode+client
 - 在Datanode上, 第二级汇总处执行
 - 在Client一级级处汇总多Datanode结果, 做最后的排序、分组
- 聚合函数——client
 - 在Client第一级汇总处完成, 汇总每个Datanode返回的结果集后, 进行分组与排序, 执行具体的聚合函数, 再运行排序与topk处理



系统扩展性分析

■ 存储规模分析

- 系统采用share-nothing结构，增加存储节点，可以增加集群的计算能力并线性扩展存储空间
- 读写完全并行化





系统扩展性分析

■ 加载能力分析

- 在所有Datanode上加载数据，系统加载效率可以线性提升

■ 检索效率分析

- 在二级并发处会线性提高检索效率
 - 数据规模一定，在仅有选择，投影检索条件时，检索效率会随着存储节点的增加而线性增加



系统可靠性分析

- 元数据管理集群化，防止单点失效问题
 - 元数据信息存储在zookeeper集群和DataNode集群上，具备数据容错功能，在线数据恢复，提供集群高可用性服务
 - Master点不存储元数据信息，可实现快速失效切换
- 引入commit-log，提供记录级别的原子操作
 - 防止内存数据的掉电丢失
 - 以记录为单位，提供前滚或回滚操作，保证记录写操作的原子性
- 引入副本容错机制
 - 支持多副本
 - 采用增量压缩技术，提高存储效率
- 无单点失效问题



系统功能概述—查询方法


■ 对外提供在线检索和离线检索两类查询方法

■ 在线检索

- 通过SQL-LIKE语言描述检索规则，利用SHELL或API接口返回结果
- 可实时查询内存数据或历史数据


■ 离线检索

- 用户定义查询任务，定时启动任务，结果导入离线数据分析库
- 在离线数据分析库中查询获得相对复杂、耗时的数据查询





系统功能概述—功能汇总



(1) 支持SQL语言的核心功能

- 支持多列查询、分组、排序、聚合等查询功能
- 提供必要的函数和数据类型定义
- 提供**SHELL**交互界面**WebService**接口

(2) 支持分布式并发查询功能

- 支持二级并发机制：节点之间和**shard**之间
- 采用分布式查询规划

(3) 支持在线查询与定时复杂任务查询

(4) 全局索引+局部索引的分布索引式机制

- 全局索引采用分布式**B+Tree**
- 局部建立了面向多个属性的索引
- 数据以**shard**为单位进行列存储

(5) 支持副本容错功能，无单点失效影响

(6) 支持并发加载功能

- 采用带外传输机制写入数据到**Datanode**
- **Datanode**并发加载方式



题 纲

- 系统需求与现有方案
- 技术方案
- 应用案例

谢 谢