cloudera

HBase最佳实践及优化

陈飚

cb@cloudera.com

Cloudera



关于我...

陈飚

Cloudera售前技术经理、资深方案架构师 http://biaobean.pro



原Intel Hadoop发行版核心开发人员, 成功实施并运维多个上百节点Hadoop大数据集群。

- 曾在Intel编译器部门从事服务器中间件软件开发,擅长服务器软件调试与优化,与团队一起开发出世界上性能领先的XSLT语言处理器
- 2010 年后开始Hadoop 产品开发及方案顾问,先后负责Hadoop 产品化、HBase 性能调优,以及行业解决方案顾问



HBase的历史

HBase是Google BigTable的开源实现

- BigTable利用GFS作为其文件存储系统
- HBase使用HDFS作为其文件存储系统

2007年10月建立 了第一个可用的 HBase版本

2008年成为 Apache Hadoop 的一个子项目

2007年2月建立 了HBase的原型 版本

2006年 Google发表 了 BigTable 论文

PowerSet 的 Chad Walters和 Jim Kellerman 发起了HBase 项目, 依据 BigTable的论文 重构关系数据

2006年底由



HBase的模型特性

Hadoop database and NoSQL database

- 基本的数据库操作CRUD
- 强一致性
- 无SQL语言支持
- 稀疏的多维映射表
 - 列存储
 - 只用row key来定位行
 - 每行可以有不同的列
 - 数据有多个版本(在不同的时间点的快照信息)
- 分布式的多层次映射表结构(key-value形式, value有多个)
 - 固定一个数据模型(固定数据模型能得到高性能,同时满足应用需求)
 - 无数据类型



HBase的实现特性

- 非常高的数据读写速度,为写特别优化
 - 高效的随机读取
 - 对于数据的某一个子集能够进行有效地扫描
- 具有容错特性, 能够将数据持久化的非易失性 存储中
 - 使用HDFS做底层存储,可利用Hadoop的压缩 Codec等减少空间占用
- 自动水平扩展
 - 只需要加入新的结点即可提高存储容量和吞吐量
 - 服务器能够被动态加入或者删除(用以维护和升级)
 - 服务器自动调整负载平衡





HBase的原子性保证

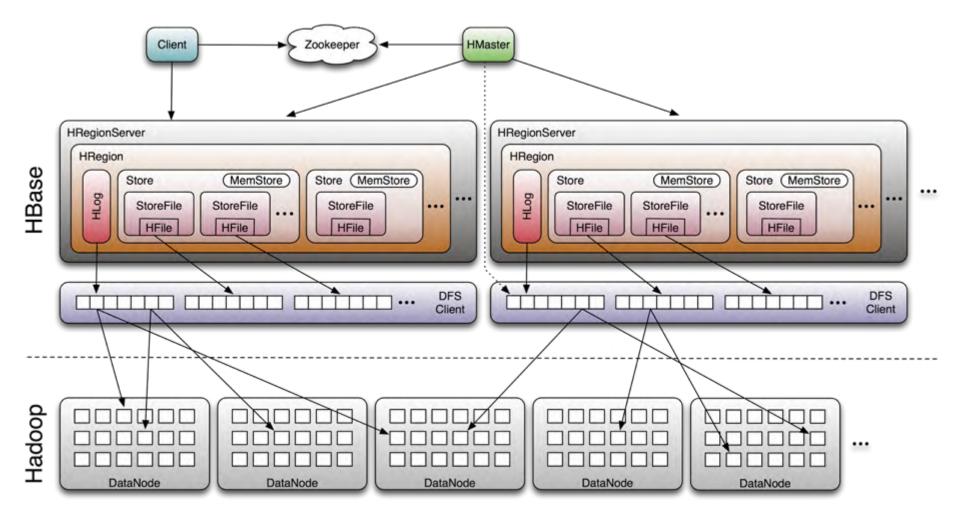
HBase仅保证对行操作的原子性

- 任何行级的操作是原子的
 - 一条记录的Put操作要么完全成功,要么完全失败。
 - · 操作返回成功(success)表示操作完成
 - 操作返回失败(failure)表示操作全部失败
 - 超时操作可能是成功也可能失败, 但不可能部分成功
 - 即使跨column family的行操作也是原子的
- 支持一次性修改多行的API并不保证跨行的原 子性操作
 - 一般情况下,API会在结果中分别返回执行成功、 失败以及超时的行操作列表





HBase体系结构



场景及应用

HBase Sweet Spot

- 1. 使用主流廉价服务器搭建的单一大规模集群 (服务器数目大于100甚至1000台)
- 2. 小规模的Scan操作(<1百万行)和Get操作
- 3. 运维难度大,大规模部署后单位运维成本低
- 4. 强一致性、开源、兼容私有部署/公有云部署
- 5. 通用的低延迟的基础存储引擎
- 尚未有系统同时很好地处理分析和OLTP任务
- 在HBase擅长的场景至今尚未有可替代品





典型用户案例: Data Storage

• 场景

- 用于收集并存储非结构化以及半结构化数据
- 数据存储要求可靠
- 保证数据强一致性
- 数据可被排序以便提供低延时的随机查询
- 案例
 - 原始日志查询系统
 - 在线指标查询系统
- 主要组件
 - HBase, Flume, Sqoop



HBase适用场景

- 高并发高性能读写访问场景
 - 数据有随机更新、删除
 - 数据写入性能高于读取性能, 加载有实时性要求的场景 适合写多读少或数据
- 需按主键排序的半结构化数据存储
- 支持基于固定有限条件的高并发高性能**查询**
- 高速计数器aggregation类型的任务
 - HBase强一致性(Strongly consistent)读写保证
- 其他适用Hadoop的NoSQL场景
 - HBase基于HDFS存储,和 MapReduce/Hive/Spark等紧密结合

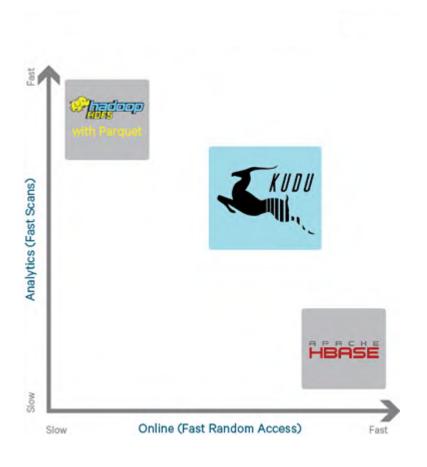


HBase现存缺点

- SQL(传统BI)不友好,不支持很多传统DBMS 功能,如外键,约束...
- 数据无类型
- 非RowKey查询性能差
- Column Family限制(数目, Partition对齐)
- Region资源消耗大,实例数目不能太多
- 无法保证服务质量*
 - Split/Compaction等操作对集群性能影响极大
- 多租户隔离能力差
- 大内存(>100GB)管理差



Kudu的设计目标



- 扫描大数据量时吞吐率高(列式存储和多副本机制)
 - 目标: 相对Parquet的扫描性能差距 在2x之内
- 访问少量数据时延时低(主键索引和多数占优复制机制)
 - 目标: SSD上读写延时不超过1毫秒
- 类似的数据库语义(初期支持单行记录的ACID)
- 关系数据模型
 - SQL查询
 - "NoSQL"风格的扫描/插入/更新 (Java客户端)

28日下午 15:40 - 16:20

Hadoop最新结构化存储利器Kudu介绍 分会场2



案例:运营商清帐单系统关键需求

- 必须能够高效处理海量数据
 - 单月清单数据量约1000亿条×1k/条=100TB,6个月总量高达 ~600TB
 - 从600TB清单数据中检索某用户某个月的清单记录,响应时间应小 于1秒
 - 支持高峰期每秒2000个并发访问查询
 - 满足现在清帐单业务的查询统计需求(23类)
 - 实时入库,清单文件无积压(清单文件最大2万条,最小1条记录。 实时生产,平均每秒2个20MB的清单文件,高峰期到每秒10个 20MB文件)
 - 对联机分析必须提供标准编程接口,支持SQL/JDBC/ODBC等
- 高可扩展和高可用
 - 用户程序查询数据不需要知道底层细节,比如数据分布细节
 - 可以水平扩展
 - 允许多台机器故障的场景下,业务不中断





原有方案: 小型机+存储+Oracle

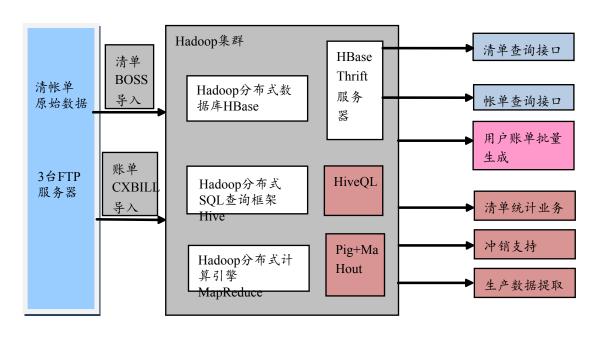
- 成本高、扩展性差
 - 价格昂贵
 - 服务器采用P595的两个分区(48CPU), 部署不同的地市, 互为主备
 - 存储使用2台DS8300, RAID5方式, 有效容量54TB
 - 数据量大,增长迅速,但数据库的扩容工程施工风险 高
- 数据风险高
 - 灾难恢复依赖磁带,业务中断时间长
- 效率低
 - 关系数据库处理困难,查询慢(超过15秒)
 - 关系数据库入库慢,常有清单文件积压,不能实时入库,从而不能实时查询





基于Hadoop的清帐单系统架构

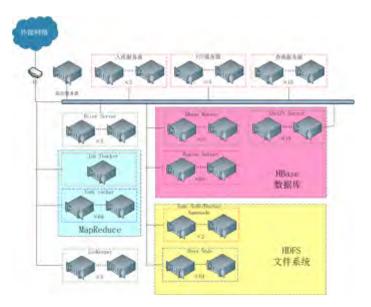
新版清帐单系统采用了基于 Hadoop的大数据平台,使用 分布式文件系统HDFS,数据存 储则采用了分布式数据库 HBase,同时结合云计算的其 他组件构成





部署方案

- 底层通过78台X3650 PC服务器组构建Hadoop集群,有效容量 138TB
- 数据的分发、复制、任务调度、容错都是由系统软件来控制, 同时具备线性的横向扩展能力
- 3份冗余的数据保证对硬件的容错和读处理的支持



设备	硬件设备	数量
Hadoop 集群管理节点	IBM 3650 PC,双路六核,Intel X5650处理器, 2.66GHz主频,48GB内存,6*1TB SATA硬盘	1台
Hadoop集群 NameNode/JobTracker	IBM 3650 PC, 双路六核, Intel X5650处理器, 2.66GHz主频, 48GB内存, 6*1TB SATA硬盘	1台
NameNode/JobTracker HA备份 节点	IBM 3650 PC,双路六核,Intel X5650处理器, 2.66GHz主频,48GB内存,6*1TB SATA硬盘	1台
Secondary NameNode	IBM 3650 PC,双路六核,Intel X5650处理器, 2.66GHz主频,48GB内存,6*1TB SATA硬盘	1台
HBase 集群Master和Zookeeper 节点	IBM 3650 PC,双路六核,Intel X5650处理器, 2.66GHz主频,48GB内存,6*1TB SATA硬盘	5台
DataNode/TaskTracker/Region Server	IBM 3650 PC,双路六核,Intel X5650处理器, 2.66GHz主频,48GB内存,6*1TB SATA硬盘	69台
HBase Thrift服务器节点/查询服务器	IBM 3650 PC,双路六核,Intel X5650处理器, 2.66GHz主频,48GB内存,6*1TB SATA硬盘	15台(使用 集群节点)
入库服务器	IBM 3650 PC,双路六核,Intel X5650处理器, 2.66GHz主频,48GB内存,6*1TB SATA硬盘	3台(不属 于集群节点)
FTP服务器	IBM 3650 PC,双路六核,Intel X5650处理器, 2.66GHz主频,48GB内存,6*1TB SATA硬盘	3台(不属 于集群节点)





案例2: 上网记录集中查询与分析

- 采用**全国集中的一级架构**方案进行建 设
- 主要包含数据采集子系统、数据入库子系统、数据存储子系统、数据查询与分析子系统
- 采用Hadoop/HBase作为上网记录存储 方案
- 采用MapReduce/Hive作用统计分析和 数据挖掘工具

【关键性能指标】

- 每日入库>5TB数据
- 上网记录入库时间:一般小于30分钟, 实际约10分钟
- 存储全国移动用户不小于6个月的原始 上网记录,统计分析中间报表数据保存 不小于5年
- 上网记录查询速度:不高于1秒(不含用户访问查询页面的时间)
- 支持并发查询数目: 1000请求/秒

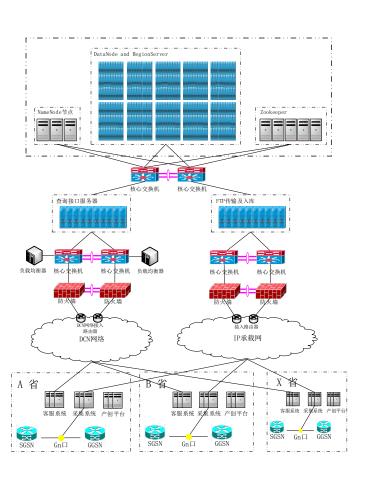


			N-155)#	文學系统					1	MADE MX
透信有限公司移动上向迈录详单										
ENGL.						MACRE 44				
						Earlie makes	ne - e e e ge	-		
	1841	40, cm (m ta-								
-	DEL BUR	-	_						16 SE 2115 MAY	M
-	THE TOTAL	(M)	-	1810	N. SERVICE	1000	Property.	- Control	FREE R	-
7	20	Special Contract of the last o	183	-	0.000.73	2012-09-19 19:29:49	87	Miles and the first contraction	ment.	25
	-	Agreet	100	-	LEIEN	2012-00-0100-0131	147	THE CHARLEST LABOR TOWN	HER THE REAL	27
20	20	type	181	181118	1,000,00	propose or de-exact	131	THE CHIEF OF SATISFACE	HOTELS AND	-
2	201	Sport	1000	-	4.000.00	Dispose in territory	149	PRINCIPAL OF LABOR CO.	with the last	225
-	20	Spring	100		8,000(3)	property of the second	171	THE COMMAND AND ADDRESS.	HOTELS SHO	25
6	30	Spreed	100	DESCRIPTION.	2.078.00	\$112.40 IS 18.36.36	149	THE COMMAND AND ADDRESS OF	will be to be a second or the	25
-	201	Agreem			1,674.73	2012-06-03 DE24/30	192	PROCESSOR AND ADDRESSOR	HOPENIA TH	82
	30.	Agreet	100	SECTION.	TARRETT.	STATE OF THE STATE OF	300	Telly college and dealing com-	HOPING HO	27
	34	Spring.	100	-	3,494:30	2012/06/08 20 20 20 20 20 20 20 20 20 20 20 20 20	80	PROPERTY AND LOSS AND LOSS.	MONTHS AND	100
-	-	Agreet	160	PRINCIPLE (1991)	7796 616	\$150 em in 16 57 es	411	Telligrational services	PERMIT	27
	196	Spreid	100	SECURITY.	TERM	grant do no participa	. 1	PROCESSORS SQUESTION	HOSPIGGERS.	E2
10	361	Agreet	rier	PRODUCE COST	202.24	2712 de 18 18 12 44	41	Tellar crimp is serial con	PREST	87
12	96	Agreem	ries	manufilm room	265.17	2000-08-19-19-90-90		New York also below our	HOTOGRAM	85
	100	Agrees	100	SERVICE SERVIC	275.00	DESCRIPTION OF THE PROPERTY.		Miller of City and control	men's	85
100	316	Agrees	1989	HARLEST HARLES	249.46	distribution on the resident		PROGRAMME AND ADDRESS OF	HORFIGNATURE	67
	30	Agreet	rier	MARLETTER LINES	276.07	STATE OF THE SECTION S	4	Miles of the party of the party	HOW THE REAL PROPERTY.	105
67	244	April	1989	www.pfresh colors	215.00	desirable on the service		NOTICE WHEN AND THE PARTY AND	MOTORA TO	425





系统部署



- NameNode节点: 3台
- DataNode(数据存储节点): 178台
- Zookeeper节点: 7台
- 集群监控节点: 1台
- 入库服务节点: 24台
- Web查询应用服务节点: 20台
- 机架间通过万兆交换机连接
- 网络冗余



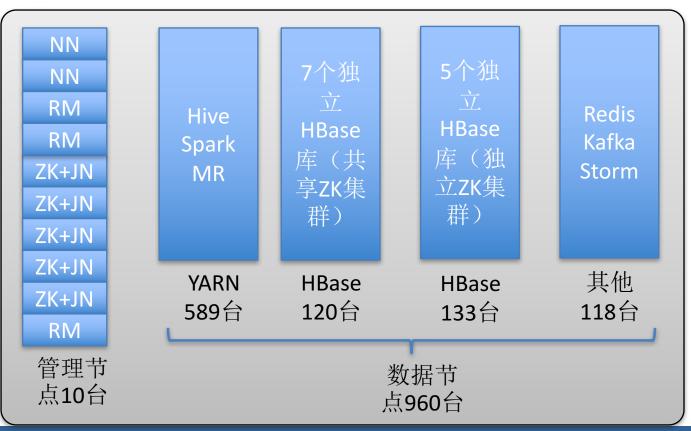


某大规模HBase多用户服务平台

• Hadoop平台集群1135个节点,其中集群970,客户端165,总存储16PB,每日采集数据压缩后40TB,集群数据块4700万个

客户端 Gateway Web FTP-o-H

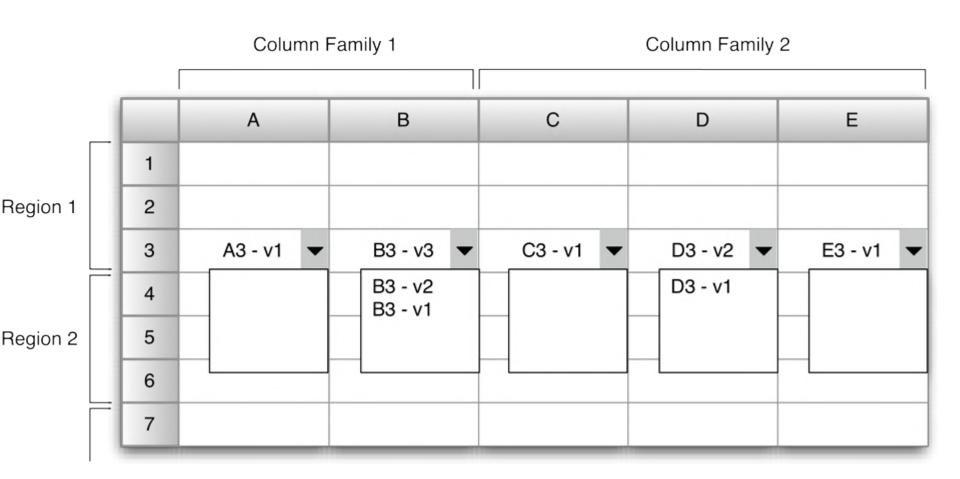
> 接口 **165**台





开发指南

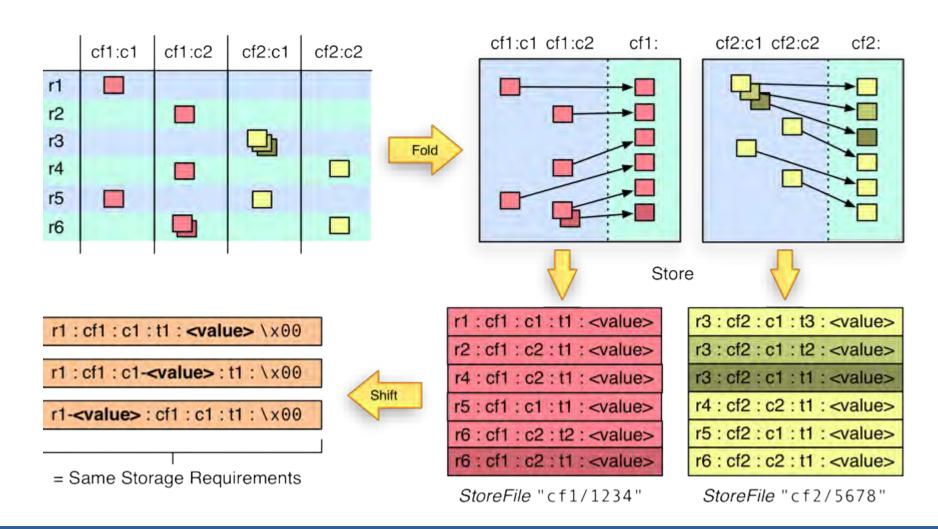
HBase表结构逻辑图



HBase基础

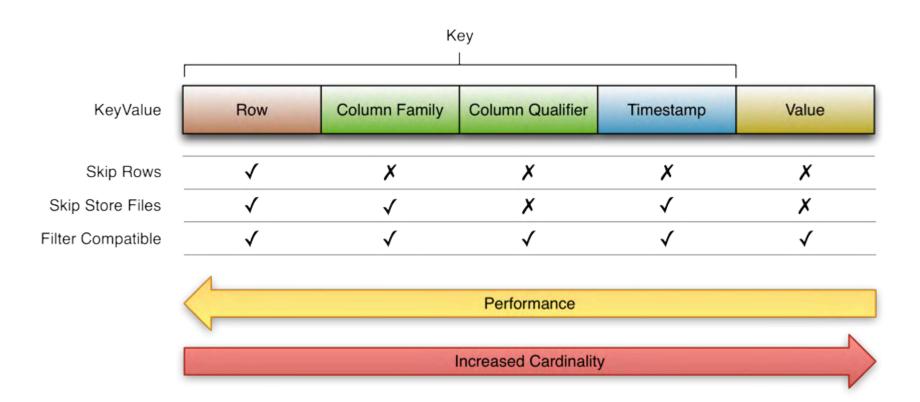
- 表记录按RowKey字典序存储
- 表Schema只定义到Column Family级别属性
 - 每个Column Family可以有任意多个Column
 - 每个Column有可以有任意多个版本(version)的数据
 - Column只有在有赋值时才被真正存储,NULL值无存储消耗
 - 一个Column Family内的Column统一存储并排序
 - 除表名外所有数据皆为无类型数据(byte数组)

HBase数据模型





Key粒度及性能

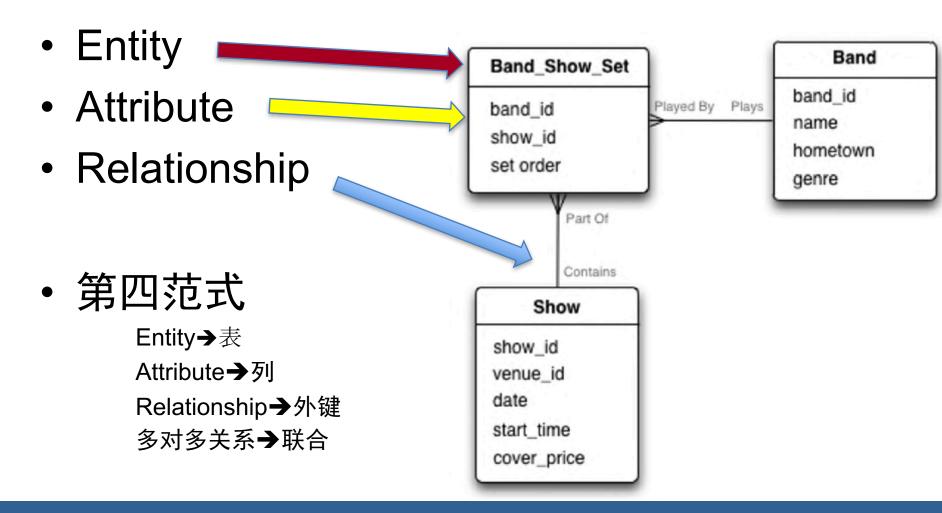


Key对数据查询的影响

- 使用RowKey进行查询的性能最好
- 指定Timestamp能减少store file级别的读操作
 - Bloom Filter也能达到同样目的
- 选择指定的Column Family可以减少查询需要读取的数据量
- · 简单的纯基于filter的值查找是一个全表扫描 操作
 - 但使用filter可以减少网络传输数据量



关系型数据库中的数据模型

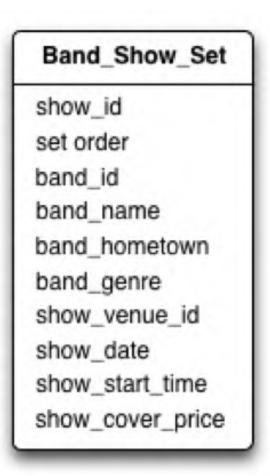






NoSQL数据库的典型数据模型 (muddle)

- 将所有数据关系放在一行宽 记录中存储
 - 避免数据查找及跨网络访问
 - 随机数据读取变为顺序读取
 - 易于分表
 - 空间换时间
 - 原子性更新?
- 第三范式





行记录设计

- 采用多行存储还是单行多列存储?
 - 将数据另存储为一行还是"覆盖"存储为列(Column)的不同版 本
 - 将数据另存储为一行还是增加一个列

建议

- 通常情况下的回答: 分行存储
 - 能获得更好的Get以及scan的性能
 - 太长的行记录不利于做Region的split
- 行设计必须符合数据原子性操作要求
 - HBase只保证行级别数据的原子性操作





RowKey设计

- RowKey的组成元素
 - 尽量将所有常用查询所使用的域放入RK
 - 优先使用RK filter, 其次使用value filter
 - 保持RK值得唯一性(添加序列号)
 - RK长度越短越好(通用数据定义规则,适用于其他)
 - » 考虑KeyValue的物理存储规则
 - 一般建议RK长度 < 50B
- RK的设计首要考虑便于能将最常用的查询转 化为HBase的get或者基于RK范围的scan操作
 - 最重要的域放在首位, 依次...





单调递增序列数据/时间序列数据

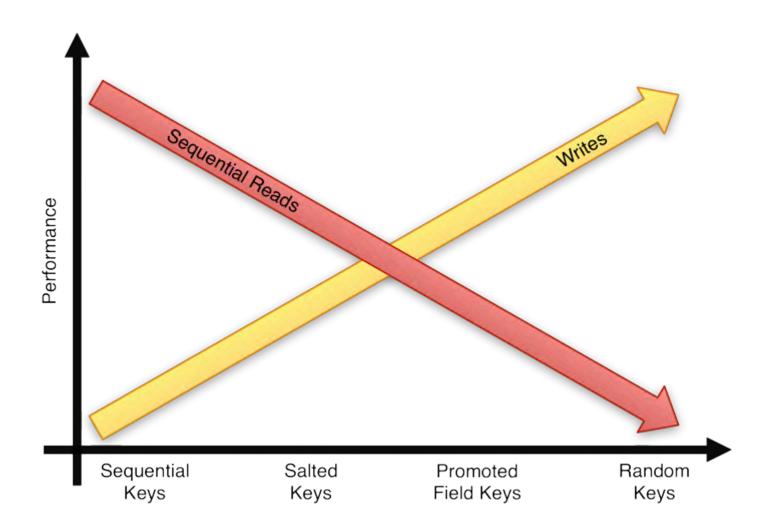
- RK = <time> <other-keys>
- 不好!
 - 单Region成热点Region
- 解决方案:
- 为单调值添加Hash函数使其分布平均,具体 Hash方法包括
 - 基于节点信息等静态配置信息 (静态Hash)
 - 基于其他数据信息,如其他key值(动态Hash)
 - 直接使用RowKey Hash值 (Random)
 - 值交织 (Interwave)





性能优化

读写性能取舍*







性能优化目标

- 读 vs. 写?
 - 读需要合并HFile, 因此文件越少越好
 - 写需要减少Compaction操作,因此文件越多越好
 - 优化读或者写**之一**,而不是全部
- 顺序 vs. 随机?
- 参考值——每个RegionServer吞吐率>20MB/s
 - 读吞吐率>3000ops/s, 写吞吐率>10000ops/s
- 尽量在HBase表结构设计时就考虑解决性能问题, 而不是通过设置参数来调整HBase性能!





HBase的性能优化

- 预分配region
- · 启用压缩以减少HDFS数据量,可提高读性能
- Region Server进程配置大内存(>16G),但不要太大(<100G)
- 每个Region Server拥有的region数量<200
- · 优化表结构设计,防止少数几个region成为瓶颈
 - 一个简单的经验公式:每台region server纯写入时 高负载应能达到>1万条记录/秒(每记录200字节)

Region数目

- 通常每台服务器能服务的Region数目为20 到150个,集群粗略估计可按100个Region 为上限,具体视服务器能力(CPU内核) 及访问压力(每个Region的服务量)而定
- · 过多Region的症状:
 - CPU线程切换频繁
 - 内存使用过大,造成GC频繁,服务Timeout
 - 每个Region的Memstore太小,磁盘flush频繁, HFile文件过多小文件





Major Compaction

- HBase根据时间来计划执行Major Compaction
 - hbase.hregion.majorcompaction = 604800000 (缺省 值为一周)
 - hbase.hregion.majorcompaction.jitter = 0.5 (缺省值 为半周)
- 执行过程非常长,且非常耗资源
 - 无法控制只在合适的时间执行
- 建议在生产环境禁用计划Major Compaction, 通过命令行手工触发或自己进行物理数据删除





Compaction

- 检测:通过HBase管理页面查看CompactionQueue长度以及 Region中StoreFile的个数,如果CompactionQueue队列长度过 长(如>10)或增长过快,则需要考虑调整Compaction参数
 - 注意查看Region以及StoreFile的大小,确认是否因为太多过小文件的原因导致文件数目多。如是,需要检查内存使用及设置

• 主要参数

- hbase.hstore.compactionThreshold, 建议值10
- hbase.hstore.blockingStoreFiles, 建议值30
- 更大的hbase.hregion.memstore.flush.size能减少Compaction的次数
 - 现在缺省128MB, 一般不用修改





HBase的GC特点

- 由单个RPC带来的操作类垃圾对象是短期的
- Memstore是相对长期驻留的,按2MB为单位分配
- Blockcache是长期驻留的、按64KB为单位分配
- 如何有效的回收RPC操作带来的临时对象是HBase 的GC重点
- 不建议HBase的堆大小操作操过64GB,否则GC压力大、执行时间太长

https://blogs.apache.org/hbase/entry/tuning_g1gc_for_your_hbase http://blog.cloudera.com/blog/2014/12/tuning-java-garbage-collection-for-hbase/





G1GC

-XX:+UseG1GC -XX:+UnlockExperimentalVMOptions -Xmx32g -Xms32g 32 GB heap, initial and max should be the same -XX:ParallelGCThreads = 8+(logical processors-8)(5/8) Minimum size for Eden each epoch, differs by -XX:G1NewSizePercent= 3-9 cluster This value is intentionally very low and doesn't actually represent a pause time upper bound. We -XX:MaxGCPauseMillis=50 recommend keeping it low to pin Eden to the low end of its range (see Tuning #2). Optimistic target, most clusters take 100+ ms Better stack traces in some circumstances, traded -XX:-OmitStackTraceInFastThrow for a bit more CPU usage Helps keep a lid on reference processing -XX:+ParallelRefProcEnabled time issues were were seeing -XX:+PerfDisableSharedMem Alleged to protect against a bizarre Linux issue Alleged to save some CPU cycles in between GC ·XX:-ResizePLAB

epochs

RegionServer硬件建议

- 服务器硬盘空间不大于6TB*RegionServer
- 足够的内存堆大小(约等于硬盘空间/200)
- HBase对于CPU要求高,越多core越好
- 磁盘与网络的速度匹配
 - 比如如果是24块硬盘,吞吐率约2.4GB/s,则 网络需要至少万兆网络。而千兆网一般配4到6 块硬盘。
- 更多的硬盘数量能增加并发,提高HBase 的读性能





写性能

- HBase理论平均写延时<10ms, 时间复杂度O(1)
- 没有可用的handler响应
 - 考虑增加handler数目或硬件资源
- 更常见的情况是95%-99%的写入都很快,但有些写入非常慢,甚至慢上万倍,一般问题在服务器端:
 - 写入Memstore慢
 - HLog写入超时——考虑HDFS及硬盘异常
 - GC——考虑优化内存使用(GC参数及算法调优有限)
 - Flush慢
 - HFile写入超时——考虑HDFS及硬盘异常
 - Compaction被触发且运行时间长——优化高峰期Compaction 策略





读性能优化

- 使用Redis、Memcache等缓存
- 使用Read Replica
- 使用Bloom Filter
- Filter等过滤结果数据
- Block cache大小
 - 查看cache命中率
- StoreFile过多,影响查找效率,手工Compact
 - 相比单个文件, 10个StoreFile文件性能下降约50%-100%
- · 本地化读写太差,网络IO消耗严重



HBase客户端性能优化

- 使用批量数据处理接口
- 保持2MB的Chunk Size
- 使用内存pool缓存HTable及其他可重用对象
- 使用多线程并发技术
 - Parallel Scanner
- 使用异步调用接口
 - AsyncClient
- 使用数据预取以及预缓存





Thanks!



@Cloudera中国



@陈飚