

日期	2020年3月5日	周次	第一周	时数	4课时
教学单元	开发环境配置				
教学目标	<p>知识目标：</p> <ol style="list-style-type: none"> 1. 了解 HBase 背景； 2. 了解 NoSQL 与传统 RDBMS 的区别； 3. 了解 HBase 应用场景； 4. HBase 特点。 				
	<p>技能目标：</p> <ol style="list-style-type: none"> 1. 能够区分 NoSQL 与传统 RDBMS； 2. 能够掌握 HBase 特点。 				
	<p>素质目标：</p> <ol style="list-style-type: none"> 1. 提高学生逻辑思维，创新能力； 2. 树立团队协作意识； 3. 树立正确的道德素质（诚实守信、情趣健康、生活朴实）。 				
教学重点	<ol style="list-style-type: none"> 1. HBase 特点； 2. NoSQL 与传统 RDBMS 的区别。 				
教学难点	NoSQL 与传统 RDBMS 的区别。				

教学方法	讲授演示法；任务驱动法
教学手段	云班课信息化教学；多媒体教学；钉钉直播教学
教学过程及内容	
<p>1. 新课引入</p> <p>随着计算机科技技术的发展，电子设备越来越普及，价格也变得越来越便宜，各种电子设备（如手机、智能家居、网络摄像头等）产生的数量正在急剧增长，到 2020 年，全球数据总量预计将超过 50ZB。</p> <p>2. 知识讲解</p> <p>HBase 的原型是 Google 的 BigTable 论文，受到了该论文思想的启发，目前作为 Hadoop 的子项目来开发维护，用于支持结构化的数据存储。</p> <p>官方网站：http://hbase.apache.org</p> <ul style="list-style-type: none"> -- 2006 年 Google 发表 BigTable 白皮书 -- 2006 年开始开发 HBase -- 2008 年北京成功开奥运会，程序员默默地将 HBase 弄成了 Hadoop 的子项目 -- 2010 年 HBase 成为 Apache 顶级项目 -- 现在很多公司二次开发出了很多发行版本，你也开始使用了。 	

HBase 是一个高可靠性、高性能、面向列、可伸缩的分布式存储系统，利用 HBASE 技术可在廉价 PC Server 上搭建起大规模结构化存储集群。

HBase 的目标是存储并处理大型的数据，更具体来说是仅需使用普通的硬件配置，就能够处理由成千上万的行和列所组成的大型数据。

HBase 是 Google Bigtable 的开源实现，但是也有很多不同之处。比如：Google Bigtable 利用 GFS 作为其文件存储系统，HBase 利用 Hadoop HDFS 作为其文件存储系统；Google 运行 MAPREDUCE 来处理 Bigtable 中的海量数据，HBase 同样利用 Hadoop MapReduce 来处理 HBase 中的海量数据；Google Bigtable 利用 Chubby 作为协同服务，HBase 利用 Zookeeper 作为对应。

1.2 HBase 特点

1) 海量存储

Hbase 适合存储 PB 级别的海量数据，在 PB 级别的数据以及采用廉价 PC 存储的情况下，能在几十到百毫秒内返回数据。这与 Hbase 的极易扩展性息息相关。正式因为 Hbase 良好的扩展性，才为海量数据的存储提供了便利。

2) 列式存储

这里的列式存储其实说的是列族存储，Hbase 是根据列族来存储数据的。列族下面可以有非常多的列，列族在创建表的时候就必须指定。

3) 极易扩展

Hbase 的扩展性主要体现在两个方面，一个是基于上层处理能力（RegionServer）的扩展，一个是基于存储的扩展（HDFS）。

通过横向添加 RegionServer 的机器，进行水平扩展，提升 Hbase 上层的处理能力，提升 Hbase 服务更多 Region 的能力。

备注：RegionServer 的作用是管理 region、承接业务的访问，这个后面会详细的介绍通过横向添加 Datanode 的机器，进行存储层扩容，提升 Hbase 的数据存储能力和提升后端存储的读写能力。

4) 高并发

由于目前大部分使用 Hbase 的架构，都是采用的廉价 PC，因此单个 IO 的延迟其实并不小，一般在几十到上百 ms 之间。这里说的高并发，主要是在并发的情况下，Hbase 的单个 IO 延迟下降并不多。能获得高并发、低延迟的服务。

5) 稀疏

稀疏主要是针对 Hbase 列的灵活性，在列族中，你可以指定任意多的列，在列数据为空的情况下，是不会占用存储空间的。

3. 课堂总结

HBase 的特点：

海量存储

列式存储

极易扩展

高并发

稀疏	
参考资料 及应用	《HBase 入门与实践》 主编：彭旭 出版社：人民邮电出版社
作业	完成第一章 HBase 简介练习题
教学反思	部分学生没有自主学习能力，应提供层次清楚、条理分明的板书

日期	2020年3月18日	周次	第三周	时数	4课时
教学单元	HBase 安装				
教学目标	知识目标： 1. Zookeeper 正常部署 2. Hadoop 正常部署 3. HBase 安装与配置 4. HBase 服务启动				
	技能目标：				
	素质目标： 4. 提高学生逻辑思维，创新能力； 5. 树立团队协作意识； 6. 树立正确的道德素质（诚实守信、情趣健康、生活朴实）。				
教学重点	1. HBase 安装与配置 2. HBase 服务启动				
教学难点	HBase 安装				

教学方法	讲授演示法；任务驱动法
教学手段	云班课信息化教学；多媒体教学；钉钉直播教学
教学过程及内容	
<p>新课引入 HBase 安装</p> <p>1.1 Zookeeper 正常部署</p> <p>首先保证 Zookeeper 集群的正常部署，并启动之：</p> <pre>[sun@hadoop102 zookeeper-3.4.10]\$ bin/zkServer.sh start</pre> <pre>[sun@hadoop103 zookeeper-3.4.10]\$ bin/zkServer.sh start</pre> <pre>[sun@hadoop104 zookeeper-3.4.10]\$ bin/zkServer.sh start</pre> <p>1.2 Hadoop 正常部署</p> <p>Hadoop 集群的正常部署并启动：</p> <pre>[sun@hadoop102 hadoop-2.7.2]\$ sbin/start-dfs.sh</pre> <pre>[sun@hadoop103 hadoop-2.7.2]\$ sbin/start-yarn.sh</pre> <p>1.3 HBase 的解压</p> <p>解压 HBase 到指定目录：</p> <pre>[sun@hadoop102 software]\$ tar -zxvf hbase-1.3.1-bin.tar.gz -C /opt/module</pre> <p>1.4 HBase 的配置文件</p>	

修改 HBase 对应的配置文件（conf 文件夹下）。

1) hbase-env.sh 修改内容：

```
export JAVA_HOME=/opt/module/jdk1.8.0_144
```

```
export HBASE_MANAGES_ZK=false
```

2) hbase-site.xml 修改内容：

3) regionservers:

4) 软连接 hadoop 配置文件到 hbase:

```
[sun@hadoop102 module]$ ln -s  
/opt/module/hadoop-2.7.2/etc/hadoop/core-site.xml
```

```
/opt/module/hbase/conf/core-site.xml
```

```
[sun@hadoop102 module]$ ln -s  
/opt/module/hadoop-2.7.2/etc/hadoop/hdfs-site.xml
```

```
/opt/module/hbase/conf/hdfs-site.xml
```

1.5 HBase 远程发送到其他集群

```
[sun@hadoop102 module]$ xsync hbase/
```

1.6 HBase 服务的启动

1. 启动方式 1

```
[sun@hadoop102 hbase]$ bin/hbase-daemon.sh start master
```

```
[sun@hadoop102 hbase]$ bin/hbase-daemon.sh start regionserver
```

提示：如果集群之间的节点时间不同步，会导致 regionserver 无法启动，抛出 ClockOutOfSyncException 异常。

修复提示：

a、同步时间服务

b、属性：`hbase.master.maxclockskew` 设置更大的值

2. 启动方式 2

```
[sun@hadoop102 hbase]$ bin/start-hbase.sh
```

对应的停止服务：

```
[sun@hadoop102 hbase]$ bin/stop-hbase.sh
```

1.7 查看 HBase 页面

启动成功后，可以通过“host:port”的方式来访问 HBase 管理页面，

例如：

<http://hadoop102:16010>

参考资料 及应用	《HBase 入门与实践》 主编：彭旭 出版社：人民邮电出版社
作业	在自己电脑上安装 HBase
教学反思	无

日期	2020年3月20日	周次	第四周	时数	4课时
教学单元	HBase Shell 操作 01				
教学目标	知识目标： 1. 掌握进入/退出 HBase 客户端； 2. 掌握查看表； 3. 掌握查看帮助命令。				
	技能目标： 1. 能够熟练操作 HBase 客户端； 2. 能够掌握查看帮助命令。				
	素质目标： 7. 提高学生逻辑思维，创新能力； 8. 树立团队协作意识； 9. 树立良好的道德素质（诚实守信、情趣健康、生活朴实）。				
教学重点	1. 创建表 2. 插入数据到表 3. 扫描查看表数据 4. 查看表结构				
教学难点	创建表、插入数据				

教学方法	讲授演示法；任务驱动法
教学手段	云班课信息化教学；多媒体教学；钉钉直播教学
教学过程及内容	
<p>4. 新课引入</p> <p>HBase Shell 操作</p> <p>5. 知识讲解</p> <p>1.1 基本操作</p> <p>1. 进入 HBase 客户端命令行</p> <pre>[atguigu@hadoop102 hbase]\$ bin/hbase shell</pre> <p>2. 查看帮助命令</p> <pre>hbase(main):001:0> help</pre> <p>3. 查看当前数据库中有哪些表</p> <pre>hbase(main):002:0> list</pre> <p>1.2 表的操作</p> <p>1. 创建表</p> <pre>hbase(main):002:0> create 'student', 'info'</pre> <p>2. 插入数据到表</p> <pre>hbase(main):003:0> put 'student', '1001', 'info:sex', 'male'</pre>	

```
hbase(main):004:0> put 'student', '1001', 'info:age', '18'  
hbase(main):005:0> put 'student', '1002', 'info:name', 'Janna'  
hbase(main):006:0> put 'student', '1002', 'info:sex', 'female'  
hbase(main):007:0> put 'student', '1002', 'info:age', '20'
```

3. 扫描查看表数据

```
hbase(main):008:0> scan 'student'  
hbase(main):009:0> scan 'student', {STARTROW => '1001',  
STOPROW => '1001'}  
hbase(main):010:0> scan 'student', {STARTROW => '1001'}
```

4. 查看表结构

```
hbase(main):011:0> describe 'student'
```

6. 课堂总结

创建表

插入数据到表

扫描查看表数据

查看表结构

	《HBase 入门与实践》
参考资料	主编：彭旭
及应用	出版社：人民邮电出版社

作业	完成 HBase Shell 语法练习
教学反思	适当增加任务驱动法使用，提高学生兴趣

日期	2020年4月2日	周次	第五周	时数	4课时
教学单元	HBase Shell 操作 02				
教学目标	知识目标： 1. 了解 HBase 客户端操作； 2. 掌握更新指定字段的数据； 3. 掌握查看“指定行”或“指定列族:列”的数据； 4. 掌握统计表数据行数。				
	技能目标： 能够掌握更新指定字段的数据				
	素质目标： 10. 提高学生逻辑思维，创新能力； 11. 树立团队协作意识； 12. 树立良好的道德素质（诚实守信、情趣健康、生活朴实）。				
教学重点	1. 掌握更新指定字段的数据； 2. 掌握查看“指定行”或“指定列族:列”的数据； 3. 掌握统计表数据行数。				
教学难点	掌握查看“指定行”或“指定列族:列”的数据				

教学方法	讲授演示法；任务驱动法
教学手段	云班课信息化教学；多媒体教学；钉钉直播教学
教学过程及内容	
<p>7. 新课引入</p> <p>8. 知识讲解</p> <p>1. 更新指定字段的数据</p> <pre>hbase(main):012:0> put 'student','1001','info:name','Nick'</pre> <pre>hbase(main):013:0> put 'student','1001','info:age','100'</pre> <p>2. 查看“指定行”或“指定列族:列”的数据</p> <pre>hbase(main):014:0> get 'student','1001'</pre> <pre>hbase(main):015:0> get 'student','1001','info:name'</pre> <p>3. 统计表数据行数</p> <pre>hbase(main):021:0> count 'student'</pre> <p>4. 删除数据</p> <p>删除某 rowkey 的全部数据:</p> <pre>hbase(main):016:0> deleteall 'student','1001'</pre> <p>删除某 rowkey 的某一列数据:</p> <pre>hbase(main):017:0> delete 'student','1002','info:sex'</pre>	

5. 清空表数据

```
hbase(main):018:0> truncate 'student'
```

提示：清空表的操作顺序为先 disable，然后再 truncate。

6. 删除表

首先需要先让该表为 disable 状态：

```
hbase(main):019:0> disable 'student'
```

然后才能 drop 这个表：

```
hbase(main):020:0> drop 'student'
```

提示：如果直接 drop 表，会报错：ERROR: Table student is enabled.
Disable it first.

7. 变更表信息

将 info 列族中的数据存放 3 个版本：

```
hbase(main):022:0> alter  
'student', {NAME=>'info', VERSIONS=>3}
```

```
hbase(main):022:0> get  
'student', '1001', {COLUMN=>'info:name', VERSIONS=>3}
```

9. 课堂总结

更新指定字段的数据

查看“指定行”或“指定列族:列”的数据

统计表数据行数

删除表

变更表信息

参考资料 及应用	《HBase 入门与实践》 主编：彭旭 出版社：人民邮电出版社
作业	完成 HBase Shell 语法练习
教学反思	提高教学方法上的改革与创新

日期	2020 年 4 月 5 日	周次	第六周	时数	4 课时
教学单元	HBase 数据结构				
教学目标	<p>知识目标：</p> <ol style="list-style-type: none"> 1. 掌握 RowKey 设计； 2. 掌握 Column Family； 3. 掌握时间戳 (Time Stamp)； 4. 了解命名空间。 				
	<p>技能目标：</p> <p>能够掌握 RowKey 设计</p>				
	<p>素质目标：</p> <ol style="list-style-type: none"> 13. 提高学生逻辑思维，创新能力； 14. 树立团队协作意识； 15. 树立良好的道德素质（诚实守信、情趣健康、生活朴实）。 				
教学重点	<ol style="list-style-type: none"> 1. 掌握 RowKey 设计； 2. 掌握 Column Family； 3. 掌握时间戳 (Time Stamp)； 				
教学难点	掌握 RowKey 设计				

教学方法	讲授演示法；任务驱动法
教学手段	云班课信息化教学；多媒体教学；钉钉直播教学
教学过程及内容	
<p>10. 新课引入</p> <p>11. 知识讲解</p> <p>HBase 数据结构</p> <p>1.1 RowKey</p> <p>与 nosql 数据库们一样, RowKey 是用来检索记录的主键。访问 HBASE table 中的行, 只有三种方式:</p> <ol style="list-style-type: none"> 1. 通过单个 RowKey 访问 2. 通过 RowKey 的 range (正则) 3. 全表扫描 <p>RowKey 行键 (RowKey) 可以是任意字符串(最大长度是 64KB, 实际应用中长度一般为 10-100bytes), 在 HBASE 内部, RowKey 保存为字节数组。存储时, 数据按照 RowKey 的字典序(byte order)排序存储。</p> <p>设计 RowKey 时, 要充分排序存储这个特性, 将经常一起读取的行存储放到一起。(位置相关性)</p> <p>1.2 Column Family</p>	

列族: HBASE 表中的每个列, 都归属于某个列族。列族是表的 schema 的一部分(而列不是), 必须在使用表之前定义。列名都以列族作为前缀。例如 `courses:history`, `courses:math` 都属于 `courses` 这个列族。

1.3 Cell

由 {rowkey, column Family:column, version} 唯一确定的单元。
cell 中的数据是没有类型的, 全部是字节码形式存贮。

关键字: 无类型、字节码

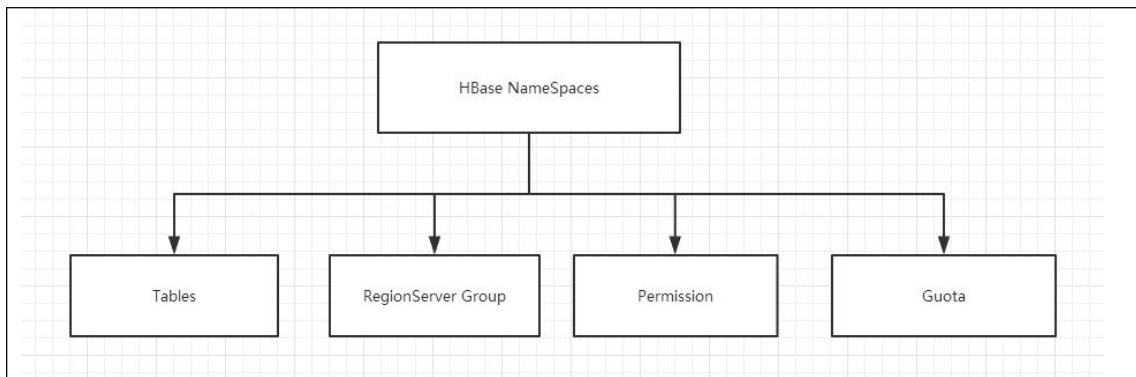
1.4 Time Stamp

HBASE 中通过 rowkey 和 columns 确定的为一个存贮单元称为 cell。每个 cell 都保存着同一份数据的多个版本。版本通过时间戳来索引。时间戳的类型是 64 位整型。时间戳可以由 HBASE(在数据写入时自动)赋值, 此时时间戳是精确到毫秒的当前系统时间。时间戳也可以由客户显式赋值。如果应用程序要避免数据版本冲突, 就必须自己生成具有唯一性的时间戳。每个 cell 中, 不同版本的数据按照时间倒序排序, 即最新的数据排在最前面。

为了避免数据存在过多版本造成的管理(包括存贮和索引)负担, HBASE 提供了两种数据版本回收方式。一是保存数据的最后 n 个版本, 二是保存最近一段时间内的版本(比如最近七天)。用户可以针对每个列族进行设置。

1.5 命名空间

命名空间的结构:



- 1) Table: 表，所有的表都是命名空间的成员，即表必属于某个命名空间，如果没有指定，则在 default 默认的命名空间中。
- 2) RegionServer group: 一个命名空间包含了默认的 RegionServer Group。
- 3) Permission: 权限，命名空间能够让我们来定义访问控制列表 ACL (Access Control List)。例如，创建表，读取表，删除，更新等等操作。
- 4) Quota: 限额，可以强制一个命名空间可包含的 region 的数量。

12. 课堂总结

RowKey 设计

全表扫描

Column Family

命名空间

	《HBase 入门与实践》
参考资料	主编：彭旭
及应用	出版社：人民邮电出版社

作业	完成课堂练习
教学反思	无

日期	2020年4月11日	周次	第七周	时数	4课时
教学单元	HBase 读写流程				
教学目标	知识目标： 1. 掌握 HBase 读流程； 2. 掌握 HBase 写流程； 3. 了解数据 Flush 过程。				
	技能目标： 1. 掌握 HBase 读流程； 2. 掌握 HBase 写流程。				
	素质目标： 16. 提高学生逻辑思维，创新能力； 17. 树立团队协作意识； 18. 树立良好的道德素质（诚实守信、情趣健康、生活朴实）。				
教学重点	1. 掌握 HBase 读流程； 2. 掌握 HBase 写流程。				
教学难点	掌握 HBase 读写流程图				

教学方法	讲授演示法；任务驱动法
教学手段	云班课信息化教学；多媒体教学；钉钉直播教学

教学过程及内容

13. 新课引入

14. 知识讲解

HBase 读数据流程如图 3 所示

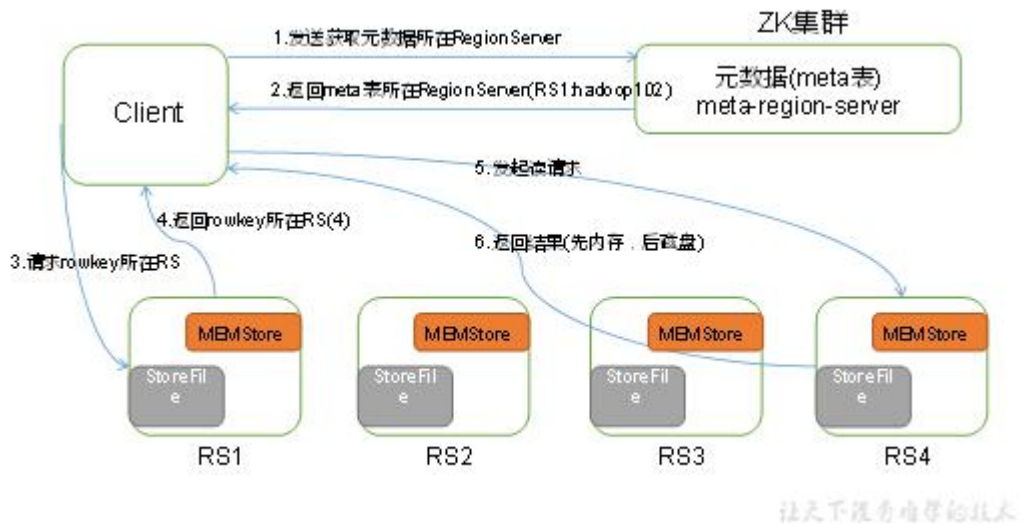


图 3 所示 HBase 读数据流程

- 1) Client 先访问 zookeeper，从 meta 表读取 region 的位置，然后读取 meta 表中的数据。meta 中又存储了用户表的 region 信息；
- 2) 根据 namespace、表名和 rowkey 在 meta 表中找到对应的 region 信息；

- 3) 找到这个 region 对应的 regionserver;
- 4) 查找对应的 region;
- 5) 先从 MemStore 找数据, 如果没有, 再到 BlockCache 里面读;
- 6) BlockCache 还没有, 再到 StoreFile 上读(为了读取的效率);
- 7) 如果是从 StoreFile 里面读取的数据, 不是直接返回给客户端, 而是先写入 BlockCache, 再返回给客户端。

5.2 写流程

Hbase 写流程如图 2 所示

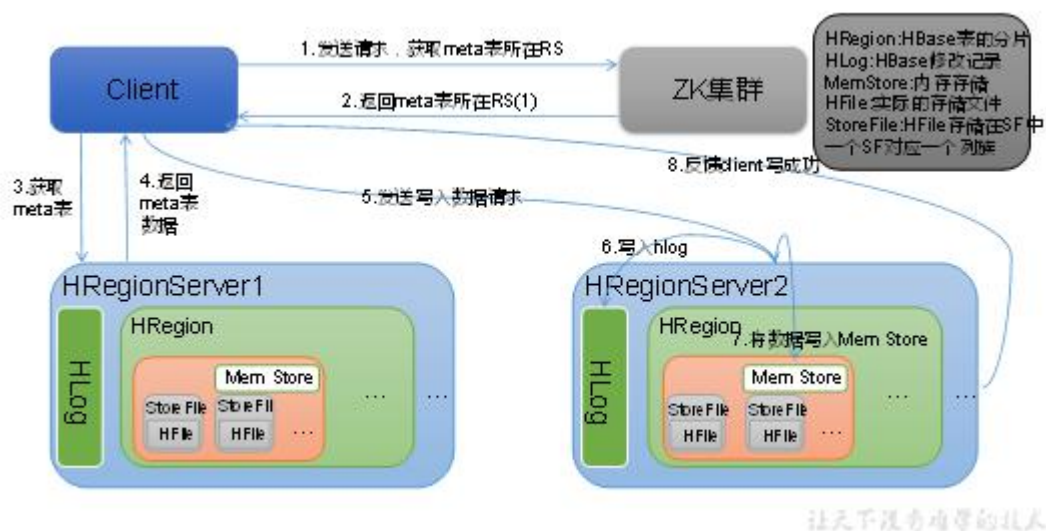


图 2 HBase 写数据流程

- 1) Client 向 HregionServer 发送写请求;
- 2) HregionServer 将数据写到 HLog (write ahead log)。为了数据的持久化和恢复;
- 3) HregionServer 将数据写到内存 (MemStore);
- 4) 反馈 Client 写成功。

15. 课堂总结

HBase 读流程

HBase 写流程

参考资料 及应用	《HBase 入门与实践》 主编：彭旭 出版社：人民邮电出版社
作业	画出 HBase 读写流程图
教学反思	设计教学环节需更加细化、合理

日期	2020年4月22日	周次	第一周	时数	4课时
教学单元	HBase 数据合并				
教学目标	知识目标： 1. 掌握 Hbase 读写数据； 2. 掌握数据 Flush 过程； 3. 掌握数据合并过程。				
	技能目标： 能够掌握数据合并过程				
	素质目标： 19. 提高学生逻辑思维，创新能力； 20. 树立团队协作意识； 21. 树立正确的道德素质（诚实守信、情趣健康、生活朴实）。				
教学重点	1. 掌握 Hbase 读写数据； 2. 掌握数据 Flush 过程； 3. 掌握数据合并过程。				
教学难点	数据 Flush 过程				

教学方法	讲授演示法；任务驱动法
教学手段	云班课信息化教学；多媒体教学；钉钉直播教学
教学过程及内容	
<p>16. 新课引入</p> <p>17. 知识讲解</p> <p>1) Client 向 HregionServer 发送写请求；</p> <p>2) HregionServer 将数据写到 HLog (write ahead log)。为了数据的持久化和恢复；</p> <p>3) HregionServer 将数据写到内存 (MemStore)；</p> <p>4) 反馈 Client 写成功。</p> <p>5.3 数据 Flush 过程</p> <p>1) 当 MemStore 数据达到阈值 (默认是 128M, 老版本是 64M), 将数据刷到硬盘, 将内存中的数据删除, 同时删除 HLog 中的历史数据；</p> <p>2) 并将数据存储到 HDFS 中；</p> <p>3) 在 HLog 中做标记点。</p> <p>5.4 数据合并过程</p> <p>1) 当数据块达到 4 块, Hmaster 触发合并操作, Region 将数据块加载到本地, 进行合并；</p>	

- 2) 当合并的数据超过 256M，进行拆分，将拆分后的 Region 分配给不同的 HregionServer 管理；
- 3) 当 HregionServer 宕机后，将 HregionServer 上的 hlog 拆分，然后分配给不同的 HregionServer 加载，修改.META.；
- 4) 注意：HLog 会同步到 HDFS。

18. 课堂总结

回顾数据 Flush 过程；

数据合并过程。

<p>参考资料 及应用</p>	<p>《HBase 入门与实践》 主编：彭旭 出版社：人民邮电出版社</p>
<p>作业</p>	<p>对两个不同文件完成数据合并。</p>
<p>教学反思</p>	<p>无</p>

日期	2020年4月26日	周次	第九周	时数	4课时
教学单元	HBase API 操作				
教学目标	知识目标： 1. 了解 API 操作环境准备； 2. 掌握判断表是否存在； 3. 掌握创建表； 4. 掌握删除表。				
	技能目标： 能够使用 API 操作 HBase				
	素质目标： 22. 提高学生逻辑思维，创新能力； 23. 树立团队协作意识； 24. 树立良好的道德素质（诚实守信、情趣健康、生活朴实）。				
教学重点	1. 掌握判断表是否存在； 2. 掌握创建表； 3. 掌握删除表。				
教学难点	创建表、删除表				

教学方法	讲授演示法；任务驱动法
教学手段	云班课信息化教学；多媒体教学；钉钉直播教学
教学过程及内容	
<p>19. 新课引入</p> <p>20. 知识讲解</p> <pre> public static void createTable(String tableName, String... columnFamily) throws MasterNotRunningException, ZooKeeperConnectionException, IOException{ HBaseAdmin admin = new HBaseAdmin(conf); //判断表是否存在 if(isTableExist(tableName)){ System.out.println("表" + tableName + "已存在"); //System.exit(0); }else{ //创建表属性对象, 表名需要转字节 HTableDescriptor descriptor = new HTableDescriptor(tableName); </pre>	

```

//创建多个列族
for(String cf : columnFamily) {
    descriptor.addFamily(new HColumnDescriptor(cf));
}

//根据对表的配置，创建表
admin.createTable(descriptor);

System.out.println("表" + tableName + "创建成功!");
}
}

```

21. 课堂总结

掌握判断表是否存在；

掌握创建表；

掌握删除表。

<p>参考资料 及应用</p>	<p>《HBase 入门与实践》 主编：彭旭 出版社：人民邮电出版社</p>
<p>作业</p>	<p>完成课堂代码</p>

教学反思	实操速度较快，部分学生跟不上，适当放慢速度
------	-----------------------

日期	2020年4月28日	周次	第十周	时数	4课时
教学单元	HBase API 高级				
教学目标	知识目标： 1. 掌握向表中插入数据； 2. 掌握删除多行数据； 3. 掌握获取多行数据； 4. 掌握获取所有、某一行数据。				
	技能目标： 能够熟练使用 API				
	素质目标： 25. 提高学生逻辑思维，创新能力； 26. 树立团队协作意识； 27. 树立良好的道德素质（诚实守信、情趣健康、生活朴实）。				
教学重点	1. 掌握向表中插入数据； 2. 掌握删除多行数据； 3. 掌握获取多行数据；				
教学难点	1. 掌握获取多行数据； 2. 掌握获取所有、某一行数据。				

教学方法	讲授演示法；任务驱动法
教学手段	云班课信息化教学；多媒体教学；钉钉直播教学
教学过程及内容	
<p>22. 新课引入</p> <p>23. 知识讲解</p> <p>1 HBaseAPI</p> <p>1.1 获取 Configuration 对象</p> <pre> public static Configuration conf; static{ //使用 HBaseConfiguration 的单例方法实例化 conf = HBaseConfiguration.create(); conf.set("hbase.zookeeper.quorum", "192.168.9.102"); conf.set("hbase.zookeeper.property.clientPort", "2181"); } </pre> <p>1.2 判断表是否存在</p> <pre> public static boolean isTableExist(String tableName) throws MasterNotRunningException, ZooKeeperConnectionException, IOException{ </pre>	

```
    //在 HBase 中管理、访问表需要先创建 HBaseAdmin 对象
    //Connection                connection                =
    ConnectionFactory.createConnection(conf);
    //HBaseAdmin admin = (HBaseAdmin) connection.getAdmin();
    HBaseAdmin admin = new HBaseAdmin(conf);
    return admin.tableExists(tableName);
}
```

1.3 创建表

1.2 向表中插入数据

1.4 删除表

```
public static void dropTable(String tableName) throws
MasterNotRunningException,
ZooKeeperConnectionException, IOException{
    HBaseAdmin admin = new HBaseAdmin(conf);
    if(isTableExist(tableName)){
        admin.disableTable(tableName);
        admin.deleteTable(tableName);
        System.out.println("表" + tableName + "删除成功!");
    }else{
        System.out.println("表" + tableName + "不存在!");
    }
}
```

}

24. 课堂总结

向表中插入数据；

删除多行数据；

获取多行数据；

获取所有、某一行数据。

参考资料 及应用	《HBase 入门与实践》 主编：彭旭 出版社：人民邮电出版社
作业	完成 HBase API 练习
教学反思	无

日期	2020年5月5日	周次	第十一周	时数	4课时
教学单元	MapReduce				
教学目标	知识目标： 1. 了解官方 HBase-MapReduce； 2. 掌握自定义 HBase-MapReduce1； 3. 掌握自定义 HBase-MapReduce2。				
	技能目标： 能够掌握自定义 HBase-MapReduce				
	素质目标： 28. 提高学生逻辑思维，创新能力； 29. 树立团队协作意识； 30. 树立正确的道德素质（诚实守信、情趣健康、生活朴实）。				
教学重点	1. 掌握自定义 HBase-MapReduce1； 2. 掌握 HBase 与 Hive 集成使用。				
教学难点	掌握自定义 HBase-MapReduce				

教学方法	讲授演示法；任务驱动法
教学手段	云班课信息化教学；多媒体教学；钉钉直播教学
教学过程及内容	
<p>25. 新课引入</p> <p>26. 知识讲解</p> <p>MapReduce</p> <p>通过 HBase 的相关 JavaAPI，我们可以实现伴随 HBase 操作的 MapReduce 过程，比如使用 MapReduce 将数据从本地文件系统导入到 HBase 的表中，比如我们从 HBase 中读取一些原始数据后使用 MapReduce 做数据分析。</p> <p>1.1 官方 HBase-MapReduce</p> <p>1. 查看 HBase 的 MapReduce 任务的执行</p> <pre>\$ bin/hbase mapredcp</pre> <p>2. 环境变量的导入</p> <p>(1) 执行环境变量的导入（临时生效，在命令行执行下述操作）</p> <p>(2) 永久生效：在/etc/profile 配置</p> <pre>export HBASE_HOME=/opt/module/hbase-1.3.1</pre> <pre>export HADOOP_HOME=/opt/module/hadoop-2.7.2</pre>	

并在 `hadoop-env.sh` 中配置：（注意：在 `for` 循环之后配）

```
export
```

```
HADOOP_CLASSPATH=$HADOOP_CLASSPATH:/opt/module/hbase/lib/*
```

3. 运行官方的 MapReduce 任务

-- 案例一：统计 Student 表中有多少行数据

```
$ /opt/module/hadoop-2.7.2/bin/yarn jar
lib/hbase-server-1.3.1.jar rowcounter student
```

-- 案例二：使用 MapReduce 将本地数据导入到 HBase

1) 在本地创建一个 `tsv` 格式的文件：`fruit.tsv`

```
1001 Apple Red
1002 Pear Yellow
1003 Pineapple Yellow
```

2) 创建 HBase 表

```
hbase(main):001:0> create 'fruit','info'
```

3) 在 HDFS 中创建 `input_fruit` 文件夹并上传 `fruit.tsv` 文件

```
$ /opt/module/hadoop-2.7.2/bin/hdfs dfs -mkdir /input_fruit/
$ /opt/module/hadoop-2.7.2/bin/hdfs dfs -put fruit.tsv
/input_fruit/
```

执行 MapReduce 到 HBase 的 `fruit` 表中

```
$ /opt/module/hadoop-2.7.2/bin/yarn jar
lib/hbase-server-1.3.1.jar importtsv \
```



```
-Dimporttsv.columns=HBASE_ROW_KEY, info:name, info:color
```

```
fruit \
```

```
hdfs://hadoop102:9000/input_fruit
```

使用 scan 命令查看导入后的结果

```
hbase(main):001:0> scan 'fruit'
```

27. 课堂总结

官方 HBase-MapReduce;

自定义 HBase-MapReduce1;

自定义 HBase-MapReduce2。

参考资料 及应用	《HBase 入门与实践》 主编：彭旭 出版社：人民邮电出版社
作业	完成查看 HBase 的 MapReduce 任务的执行
教学反思	任务驱动教学学生学习效率大大提高

日期	2020年5月14日	周次	第十二周	时数	4课时
教学单元	HBase 与 Hive 的集成				
教学目标	知识目标： 1. 了解 HBase 与 Hive 的对比； 2. 掌握 HBase 与 Hive 集成使用。				
	技能目标： 能够掌握 HBase 与 Hive 集成使用				
	素质目标： 31. 提高学生逻辑思维，创新能力； 32. 树立团队协作意识； 33. 树立正确的道德素质（诚实守信、情趣健康、生活朴实）。				
教学重点	掌握 HBase 与 Hive 集成使用				
教学难点	掌握 HBase 与 Hive 集成使用				
教学方法	讲授演示法；任务驱动法				

教学手段	云班课信息化教学；多媒体教学；钉钉直播教学
------	-----------------------

教学过程及内容

28. 新课引入

29. 知识讲解

与 Hive 的集成

1.1 HBase 与 Hive 的对比

1. Hive

(1) 数据仓库

Hive 的本质其实就相当于将 HDFS 中已经存储的文件在 Mysql 中做了一个双射关系，以方便使用 HQL 去管理查询。

(2) 用于数据分析、清洗

Hive 适用于离线的数据分析和清洗，延迟较高。

(3) 基于 HDFS、MapReduce

Hive 存储的数据依旧在 DataNode 上，编写的 HQL 语句终将是转换为 MapReduce 代码执行。

2. HBase

(1) 数据库

是一种面向列存储的非关系型数据库。

(2) 用于存储结构化和非结构化的数据

适用于单表非关系型数据的存储，不适合做关联查询，类似 JOIN 等

操作。

(3) 基于 HDFS

数据持久化存储的体现形式是 Hfile，存放于 DataNode 中，被 ResionServer 以 region 的形式进行管理。

(4) 延迟较低，接入在线业务使用

面对大量的企业数据，HBase 可以直线单表大量数据的存储，同时提供了高效的数据访问速度。

1.2 HBase 与 Hive 集成使用

尖叫提示：HBase 与 Hive 的集成在最新的两个版本中无法兼容。所以，我们只能含着泪勇敢的重新编译：
hive-hbase-handler-1.2.2.jar!! 好气!!

环境准备

因为我们后续可能会在操作 Hive 的同时对 HBase 也会产生影响，所以 Hive 需要持有操作 HBase 的 Jar，那么接下来拷贝 Hive 所依赖的 Jar 包（或者使用软连接的形式）。

同时在 hive-site.xml 中修改 zookeeper 的属性，如下：

1. 案例一

目标：建立 Hive 表，关联 HBase 表，插入数据到 Hive 表的同时能够影响 HBase 表。

分步实现：

(1) 在 Hive 中创建表同时关联 HBase

提示：完成之后，可以分别进入 Hive 和 HBase 查看，都生成了对应

的表

(2) 在 Hive 中创建临时中间表，用于 load 文件中的数据

提示：不能将数据直接 load 进 Hive 所关联 HBase 的那张表中

(3) 向 Hive 中间表中 load 数据

```
hive> load data local inpath
' /home/admin/software/data/emp.txt' into table emp;
```

(4) 通过 insert 命令将中间表中的数据导入到 Hive 关联 HBase 的那张表中

```
hive> insert into table hive_hbase_emp_table select * from
emp;
```

(5) 查看 Hive 以及关联的 HBase 表中是否已经成功的同步插入了数据

Hive:

```
hive> select * from hive_hbase_emp_table;
```

HBase:

```
hbase> scan 'hbase_emp_table'
```

2. 案例二

目标: 在 HBase 中已经存储了某一张表 hbase_emp_table, 然后在 Hive 中创建一个外部表来关联 HBase 中的 hbase_emp_table 这张表, 使之可以借助 Hive 来分析 HBase 这张表中的数据。

注: 该案例 2 紧跟案例 1 的脚步, 所以完成此案例前, 请先完成案例 1。

分步实现：

(1) 在 Hive 中创建外部表

(2) 关联后就可以使用 Hive 函数进行一些分析操作了

```
hive (default)> select * from relevance_hbase_emp;
```

30. 课堂总结

HBase 与 Hive 的对比；

HBase 与 Hive 集成使用。

参考资料 及应用	《HBase 入门与实践》 主编：彭旭 出版社：人民邮电出版社
作业	完成 HBase 与 Hive 习题
教学反思	部分学生指令记忆不清晰，后续组织默写

日期	2020年5月16日	周次	第十三周	时数	4课时
教学单元	HBase 高可用性				
教学目标	知识目标： 1. 了解高可用； 2. 了解预分区； 3. 掌握 RowKey 设计。				
	技能目标： 能够进行 RowKey 设计				
	素质目标： 34. 提高学生逻辑思维，创新能力； 35. 树立团队协作意识； 36. 树立正确的道德素质（诚实守信、情趣健康、生活朴实）。				
教学重点	掌握 RowKey 设计				
教学难点	掌握 RowKey 设计				

教学方法	讲授演示法；任务驱动法
教学手段	云班课信息化教学；多媒体教学；钉钉直播教学
教学过程及内容	
<p>31. 新课引入</p> <p>32. 知识讲解</p> <p>1.1 高可用</p> <p>在 HBase 中 Hmaster 负责监控 RegionServer 的生命周期，均衡 RegionServer 的负载，如果 Hmaster 挂掉了，那么整个 HBase 集群将陷入不健康的状态，并且此时的工作状态并不会维持太久。所以 HBase 支持对 Hmaster 的高可用配置。</p> <p>1. 关闭 HBase 集群（如果没有开启则跳过此步）</p> <pre>[atguigu@hadoop102 hbase]\$ bin/stop-hbase.sh</pre> <p>2. 在 conf 目录下创建 backup-masters 文件</p> <pre>[atguigu@hadoop102 hbase]\$ touch conf/backup-masters</pre> <p>3. 在 backup-masters 文件中配置高可用 HMaster 节点</p> <pre>[atguigu@hadoop102 hbase]\$ echo hadoop103 > conf/backup-masters</pre> <p>4. 将整个 conf 目录 scp 到其他节点</p>	


```
[atguigu@hadoop102 hbase]$ scp -r conf/
hadoop103:/opt/module/hbase/
```

```
[atguigu@hadoop102 hbase]$ scp -r conf/
hadoop104:/opt/module/hbase/
```

5. 打开页面测试查看

<http://hadoo102:16010>

1.2 预分区

每一个 region 维护着 startRow 与 endRowKey, 如果加入的数据符合某个 region 维护的 rowKey 范围, 则该数据交给这个 region 维护。那么依照这个原则, 我们可以将数据所要投放的分区提前大致的规划好, 以提高 HBase 性能。

1. 手动设定预分区

```
hbase> create 'staff1','info','partition1',SPLITS =>
['1000','2000','3000','4000']
```

2. 生成 16 进制序列预分区

```
create 'staff2','info','partition2',{NUMREGIONS => 15,
SPLITALGO => 'HexStringSplit'}
```

3. 按照文件中设置的规则预分区

创建 splits.txt 文件内容如下:

aaaa

bbbb

cccc

dddd

然后执行：

```
create 'staff3', 'partition3', SPLITS_FILE => 'splits.txt'
```

4. 使用 JavaAPI 创建预分区

//自定义算法，产生一系列 Hash 散列值存储在二维数组中

```
byte[][] splitKeys = 某个散列值函数
```

//创建 HBaseAdmin 实例

```
HBaseAdmin hAdmin = new  
HBaseAdmin(HBaseConfiguration.create());
```

//创建 HTableDescriptor 实例

```
HTableDescriptor tableDesc = new  
HTableDescriptor(tableName);
```

//通过 HTableDescriptor 实例和散列值二维数组创建带有预分区的
的 HBase 表

```
hAdmin.createTable(tableDesc, splitKeys);
```

1.3 RowKey 设计

一条数据的唯一标识就是 rowkey，那么这条数据存储于哪个分区，取决于 rowkey 处于哪个一个预分区的区间内，设计 rowkey 的主要目的，就是让数据均匀的分布于所有的 region 中，在一定程度上防止数据倾斜。接下来我们就谈一谈 rowkey 常用的设计方案。

1. 生成随机数、hash、散列值

比如：

原本 rowKey 为 1001 的，SHA1 后变成：

dd01903921ea24941c26a48f2cec24e0bb0e8cc7

原本 rowKey 为 3001 的，SHA1 后变成：

49042c54de64a1e9bf0b33e00245660ef92dc7bd

原本 rowKey 为 5001 的，SHA1 后变成：

7b61dec07e02c188790670af43e717f0f46e8913

在做此操作之前，一般我们会选择从数据集中抽取样本，来决定什么样的 rowKey 来 Hash 后作为每个分区的临界值。

2. 字符串反转

20170524000001 转成 10000042507102

20170524000002 转成 20000042507102

这样也可以在一定程度上散列逐步 put 进来的数据。

3. 字符串拼接

20170524000001_a12e

20170524000001_93i7

33. 课堂总结

什么是高可用；

什么是预分区；

如何进行 RowKey 设计。

参考资料 及应用	《HBase 入门与实践》 主编：彭旭 出版社：人民邮电出版社
作业	完成课后练习（RowKey 设计）
教学反思	无

日期	2020年5月20日	周次	第十四周	时数	4课时
教学单元	HBase 优化				
教学目标	知识目标： 1. 了解什么是优化； 2. 掌握 HBase 内存优化； 3. 掌握 HBase 基础优化。				
	技能目标： 1. 能够进行 HBase 内存优化； 2. 能够进行 Hbase 基础优化。				
	素质目标： 37. 提高学生逻辑思维，创新能力； 38. 树立团队协作意识； 39. 树立良好的道德素质（诚实守信、情趣健康、生活朴实）。				
教学重点	1. 掌握 HBase 内存优化； 2. 掌握 HBase 基础优化。				
教学难点	1. HBase 内存优化； 2. HBase 基础优化。				

教学方法	讲授演示法；任务驱动法
教学手段	云班课信息化教学；多媒体教学；钉钉直播教学
教学过程及内容	
<p>34. 新课引入</p> <p>35. 知识讲解</p> <p>1.1 内存优化</p> <p>HBase 操作过程中需要大量的内存开销，毕竟 Table 是可以缓存在内存中的，一般会分配整个可用内存的 70%给 HBase 的 Java 堆。但是不建议分配非常大的堆内存，因为 GC 过程持续太久会导致 RegionServer 处于长期不可用状态，一般 16~48G 内存就可以了，如果因为框架占用内存过高导致系统内存不足，框架一样会被系统服务拖死。</p> <p>1.2 基础优化</p> <p>1. 允许在 HDFS 的文件中追加内容</p> <p>hdfs-site.xml、hbase-site.xml</p> <p>属性：dfs.support.append</p> <p>解释：开启 HDFS 追加同步，可以优秀的配合 HBase 的数据同步和持久化。默认值为 true。</p>	

2. 优化 DataNode 允许的最大文件打开数

hdfs-site.xml

属性: `dfs.datanode.max.transfer.threads`

解释: HBase 一般都会同一时间操作大量的文件, 根据集群的数量和规模以及数据动作, 设置为 4096 或者更高。默认值: 4096

3. 优化延迟高的数据操作的等待时间

hdfs-site.xml

属性: `dfs.image.transfer.timeout`

解释: 如果对于某一次数据操作来讲, 延迟非常高, socket 需要等待更长的时间, 建议把该值设置为更大的值 (默认 60000 毫秒), 以确保 socket 不会被 timeout 掉。

4. 优化数据的写入效率

mapred-site.xml

属性:

`mapreduce.map.output.compress`

`mapreduce.map.output.compress.codec`

解释: 开启这两个数据可以大大提高文件的写入效率, 减少写入时间。第一个属性值修改为 `true`, 第二个属性值修改为: `org.apache.hadoop.io.compress.GzipCodec` 或者其他压缩方式。

5. 设置 RPC 监听数量

hbase-site.xml

属性: `hbase.regionserver.handler.count`

解释：默认值为 30，用于指定 RPC 监听的数量，可以根据客户端的请求数进行调整，读写请求较多时，增加此值。

6. 优化 HStore 文件大小

hbase-site.xml

属性：hbase.hregion.max.filesize

解释：默认值 10737418240（10GB），如果需要运行 HBase 的 MR 任务，可以减小此值，因为一个 region 对应一个 map 任务，如果单个 region 过大，会导致 map 任务执行时间过长。该值的意思就是，如果 HFile 的大小达到这个数值，则这个 region 会被切分为两个 Hfile。

7. 优化 hbase 客户端缓存

hbase-site.xml

属性：hbase.client.write.buffer

解释：用于指定 HBase 客户端缓存，增大该值可以减少 RPC 调用次数，但是会消耗更多内存，反之则反之。一般我们需要设定一定的缓存大小，以达到减少 RPC 次数的目的。

8. 指定 scan.next 扫描 HBase 所获取的行数

hbase-site.xml

属性：hbase.client.scanner.caching

解释：用于指定 scan.next 方法获取的默认行数，值越大，消耗内存越大。

9. flush、compact、split 机制

当 MemStore 达到阈值，将 Memstore 中的数据 Flush 进 Storefile；compact 机制则是把 flush 出来的小文件合并成大的 Storefile 文件。split 则是当 Region 达到阈值，会把过大的 Region 一分为二。

涉及属性：

即：128M 就是 Memstore 的默认阈值

```
hbase.hregion.memstore.flush.size: 134217728
```

即：这个参数的作用是当单个 HRegion 内所有的 Memstore 大小总和超过指定值时，flush 该 HRegion 的所有 memstore。RegionServer 的 flush 是通过将请求添加一个队列，模拟生产消费模型来异步处理的。那这里就有一个问题，当队列来不及消费，产生大量积压请求时，可能会导致内存陡增，最坏的情况是触发 OOM。

```
hbase.regionserver.global.memstore.upperLimit: 0.4
```

```
hbase.regionserver.global.memstore.lowerLimit: 0.38
```

即：当 MemStore 使用内存总量达到 hbase.regionserver.global.memstore.upperLimit 指定值时，将会有多个 MemStores flush 到文件中，MemStore flush 顺序是按照大小降序执行的，直到刷新到 MemStore 使用内存略小于 lowerLimit

36. 课堂总结

什么是优化：

HBase 内存优化：

HBase 基础优化。

参考资料 及应用	《HBase 入门与实践》 主编：彭旭 出版社：人民邮电出版社
作业	尝试对原先设计的 HBase 表进行内存优化，基础优化。
教学反思	任务驱动教学学生学习效率大大提高

日期	2020年6月1日	周次	第一周	时数	4课时
教学单元	HBaseJJ 微博设计 01				
教学目标	<p>知识目标：</p> <ol style="list-style-type: none"> 1. 掌握编写 JJ 微博需求分析； 2. 掌握代码设计； 3. 掌握 JJ 微博数据库设计。 				
	<p>技能目标：</p> <p>能够进行 JJ 微博数据库设计</p>				
	<p>素质目标：</p> <ol style="list-style-type: none"> 40. 提高学生逻辑思维，创新能力； 41. 树立团队协作意识； 42. 树立正确的道德素质（诚实守信、情趣健康、生活朴实）。 				
教学重点	<ol style="list-style-type: none"> 1. 掌握编写 JJ 微博需求分析； 2. 掌握代码设计； 3. 掌握 JJ 微博数据库设计。 				
教学难点	掌握 JJ 微博数据库设计				

教学方法	讲授演示法；任务驱动法
教学手段	云班课信息化教学；多媒体教学；钉钉直播教学
教学过程及内容	
<p>37. 新课引入</p> <p>38. 知识讲解</p> <p>HBase 实战之谷粒微博</p> <p>1.1 需求分析</p> <ol style="list-style-type: none"> 1) 微博内容的浏览，数据库表设计 2) 用户社交体现：关注用户，取关用户 3) 拉取关注的人的微博内容 <p>1.2 代码实现</p> <p>1.2.1 代码设计总览：</p> <ol style="list-style-type: none"> 1) 创建命名空间以及表名的定义 2) 创建微博内容表 3) 创建用户关系表 4) 创建用户微博内容接收邮件表 5) 发布微博内容 6) 添加关注用户 	

- 7) 移除（取关）用户
- 8) 获取关注的人的微博内容
- 9) 测试

1.2.2 创建命名空间以及表名的定义

```
//获取配置 conf

private Configuration conf = HBaseConfiguration.create();

//微博内容表的表名

private static final byte[] TABLE_CONTENT =
Bytes.toBytes("weibo:content");

//用户关系表的表名

private static final byte[] TABLE_RELATIONS =
Bytes.toBytes("weibo:relations");

//微博收件箱表的表名

private static final byte[] TABLE_RECEIVE_CONTENT_EMAIL =
Bytes.toBytes("weibo:receive_content_email");

public void initNamespace() {

    HBaseAdmin admin = null;

    try {

        admin = new HBaseAdmin(conf);

        //命名空间类似于关系型数据库中的 schema，可以想象成文件夹

        NamespaceDescriptor weibo = NamespaceDescriptor
```

```
        .create("weibo")
        .addConfiguration("creator", "Jinji")
        .addConfiguration("create_time",
System.currentTimeMillis() + "")
        .build();
    admin.createNamespace(weibo);
} catch (MasterNotRunningException e) {
    e.printStackTrace();
} catch (ZooKeeperConnectionException e) {
    e.printStackTrace();
} catch (IOException e) {
    e.printStackTrace();
}finally{
    if(null != admin){
        try {
            admin.close();
        } catch (IOException e) {
            e.printStackTrace();
        }
    }
}
}
```

39. 课堂总结

编写 JJ 微博需求分析；

代码设计；

JJ 微博数据库设计。

参考资料 及应用	《HBase 入门与实践》 主编：彭旭 出版社：人民邮电出版社
作业	完成 JJ 微博数据库设计
教学反思	无

日期	2020年6月5日	周次	第十六周	时数	4课时
教学单元	HBase 商业应用				
教学目标	<p>知识目标：</p> <ol style="list-style-type: none"> 1. 了解 HBase 在商业项目中的能力； 2. 掌握布隆过滤器； 3. 掌握 HBase2.0 新特性。 				
	<p>技能目标：</p> <p>能够 HBase2.0 新特性</p>				
	<p>素质目标：</p> <ol style="list-style-type: none"> 43. 提高学生逻辑思维，创新能力； 44. 树立团队协作意识； 45. 树立正确的道德素质（诚实守信、情趣健康、生活朴实）。 				
教学重点	<ol style="list-style-type: none"> 1. 掌握布隆过滤器； 2. 掌握 HBase2.0 新特性 				
教学难点	掌握布隆过滤器				

教学方法	讲授演示法；任务驱动法
教学手段	云班课信息化教学；多媒体教学；钉钉直播教学
教学过程及内容	
<p>40. 新课引入</p> <p>41. 知识讲解</p> <p>1.1 HBase 在商业项目中的能力</p> <p>每天：</p> <ol style="list-style-type: none"> 1) 消息量：发送和接收的消息数超过 60 亿 2) 将近 1000 亿条数据的读写 3) 高峰期每秒 150 万左右操作 4) 整体读取数据占有约 55%，写入占有 45% 5) 超过 2PB 的数据，涉及冗余共 6PB 数据 6) 数据每月大概增长 300 千兆字节。 <p>1.2 布隆过滤器</p> <p>在日常生活中，包括在设计计算机软件时，我们经常要判断一个元素是否在一个集合中。比如在字处理软件中，需要检查一个英语单词是否拼写正确（也就是要判断它是否在已知的字典中）；在 FBI，一个嫌疑人的名字是否已经在嫌疑名单上；在网络爬虫里，一个网址是否</p>	

被访问过等等。最直接的方法就是将集合中全部的元素存在计算机中，遇到一个新元素时，将它和集合中的元素直接比较即可。一般来讲，计算机中的集合是用哈希表（hash table）来存储的。它的好处是快速准确，缺点是费存储空间。当集合比较小时，这个问题不显著，但是当集合巨大时，哈希表存储效率低的问题就显现出来了。比如说，一个像 Yahoo, Hotmail 和 Gmai 那样的公众电子邮件（email）提供商，总是需要过滤来自发送垃圾邮件的人（spamer）的垃圾邮件。一个办法就是记录下那些发垃圾邮件的 email 地址。由于那些发送者不停地在注册新的地址，全世界少说也有几十亿个发垃圾邮件的地址，将他们都存起来则需要大量的网络服务器。如果用哈希表，每存储一亿个 email 地址，就需要 1.6GB 的内存（用哈希表实现的具体办法是将每一个 email 地址对应成一个八字节的信息指纹 googlechinablog.com/2006/08/blog-post.html，然后将这些信息指纹存入哈希表，由于哈希表的存储效率一般只有 50%，因此一个 email 地址需要占用十六个字节。一亿个地址大约要 1.6GB，即十六亿字节的内存）。因此存贮几十亿个邮件地址可能需要上百 GB 的内存。除非是超级计算机，一般服务器是无法存储的。

布隆过滤器只需要哈希表 $1/8$ 到 $1/4$ 的大小就能解决同样的问题。

Bloom Filter 是一种空间效率很高的随机数据结构，它利用位数组很简洁地表示一个集合，并能判断一个元素是否属于这个集合。Bloom Filter 的这种高效是有一定代价的：在判断一个元素是否属于某个

集合时，有可能会把不属于这个集合的元素误认为属于这个集合（false positive）。因此，Bloom Filter 不适合那些“零错误”的应用场合。而在能容忍低错误率的应用场合下，Bloom Filter 通过极少的错误换取了存储空间的极大节省。

下面我们具体来看 Bloom Filter 是如何用位数组表示集合的。初始状态时，Bloom Filter 是一个包含 m 位的位数组，每一位都置为 0，如图 9-5 所示。




图 9-5

为了表达 $S = \{x_1, x_2, \dots, x_n\}$ 这样一个 n 个元素的集合，Bloom Filter 使用 k 个相互独立的哈希函数（Hash Function），它们分别将集合中的每个元素映射到 $\{1, \dots, m\}$ 的范围中。对任意一个元素 x ，第 i 个哈希函数映射的位置 $h_i(x)$ 就会被置为 1 ($1 \leq i \leq k$)。注意，如果一个位置多次被置为 1，那么只有第一次会起作用，后面几次将没有任何效果。如图 9-6 所示， $k=3$ ，且有两个哈希函数选中同一个位置（从左边数第五位）。



图 9-6

在判断 y 是否属于这个集合时，我们对 y 应用 k 次哈希函数，如果所有 $h_i(y)$ 的位置都是 1 ($1 \leq i \leq k$)，那么我们就认为 y 是集合中的元素，否则就认为 y 不是集合中的元素。如图 9-7 所示 y_1 就不是集合

中的元素。y2 或者属于这个集合，或者刚好是一个 false positive。



图 9-7

- 为了 add 一个元素，用 k 个 hash function 将它 hash 得到 bloom filter 中 k 个 bit 位，将这 k 个 bit 位置 1。
- 为了 query 一个元素，即判断它是否在集合中，用 k 个 hash function 将它 hash 得到 k 个 bit 位。若这 k bits 全为 1，则此元素在集合中；若其中任一位不为 1，则此元素不在集合中（因为如果在，则在 add 时已经把对应的 k 个 bits 位置为 1）。
- 不允许 remove 元素，因为那样的话会把相应的 k 个 bits 位置为 0，而其中很有可能有其他元素对应的位。因此 remove 会引入 false negative，这是绝对不被允许的。

布隆过滤器决不会漏掉任何一个在黑名单中的可疑地址。但是，它有一条不足之处，也就是它有极小的可能将一个不在黑名单中的电子邮件地址判定为在黑名单中，因为有可能某个好的邮件地址正巧对应一个八个都被设置成一的二进制位。好在这种可能性很小，我们把它称为误识概率。

布隆过滤器的好处在于快速，省空间，但是有一定的误识别率，常见的补救办法是在建立一个小的白名单，存储那些可能个别误判的邮件地址。

布隆过滤器具体算法高级内容，如错误率估计，最优哈希函数个数计

算，位数组大小计算，请参见
<http://blog.csdn.net/jiaomeng/article/details/1495500>。

42. 课堂总结

HBase 在商业项目中的能力；

布隆过滤器；

HBase2.0 新特性。

参考资料 及应用	《HBase 入门与实践》 主编：彭旭 出版社：人民邮电出版社
作业	学习 HBase2.0 新特性
教学反思	无