

第3章Spark编程实训

第3章Spark编程实训

CH03实训1：使用spark-shell进行词频统计

训练要点

需求说明

实现思路及步骤

作业要求

实现参考

环境准备参考

数据准备

在spark-shell上执行

spark-shell预期输出：

在hdfs上观察

学习视频

CH03实训2：通过spark编程统计某月份的客户总消费金额

训练要点

需求说明

实现思路及步骤

作业要求

实现参考

数据准备

spark-shell脚本

预期输出

CH03实训3：通过Spark编程计算各城市的平均气温

训练要点

需求说明

实现思路及步骤

作业要求

实现参考

数据准备

在spark-shell上执行

spark-shell预期输出：

CH03实训1：使用spark-shell进行词频统计

训练要点

1. 掌握RDD创建方法，读取数据文件和存储文件的方法。
2. 掌握flatMap操作、map操作、reduceByKey操作、filter操作方法。

需求说明

数据文件words.txt如下文所示，文件中包含了多行句子，现在要求对文档中的单词计数，并把单词计数超过3的结果存储到HDFS上

words.txt

WHat is going on there?

I talked to John on email. We talked about some computer stuff that's it.

I went bike riding in the rain, it was not that cold.

We went to the museum in SF yesterday it was \$3 to get in and they had free food. At the same time was a SF Giants game, when we got done we had to take the train with all the Giants fans, they are 1/2 drunk.

可以在linux下使用wget获取该文件:

wget <http://bigdata.hddly.cn/b46488/file/chap3/words.txt>

实现思路及步骤

1. 通过textFile的方法读取数据。
2. 通过flatMap将字符串切分成单词。
3. 通过map将单词转化为(单词, 1)的形式。
4. 通过reduceByKey将同一——个单词的所有值相加。
5. 通过filter将单词计数大于3的结果过滤出来。
6. 通过saveAsTextFile将结果写入到HDFS

作业要求

1. 将测试文件words.txt上传到hdfs上的/user/myname/目录下,并截图(myname要改为自己名字全拼)
2. 通过crt进入spark-shell命令窗口, 执行词频分析脚本, 其中输出结果文件存于 /user/myname/output_wordcount, 并截图运行过程;
3. 提交hdfs上生成的结果文件: /user/myname/output_wordcount 的内容截图, 图中需显示完整的文件路径。

实现参考

环境准备参考

```
1 //启动hadoop集群
2 start-all.sh
3 //启动spark集群
4 cd /usr/local/spark/sbin
5 ./start-all.sh
```

使用jps检查master主机进程

```
1 [root@master sbin]# jps
2 2421 SecondaryNameNode
3 2134 NameNode
4 2710 ResourceManager
5 3150 Master
6 3902 Jps
7 [root@master sbin]
```

数据准备

在slave1下执行

```
1 cd /root/spark
2 wget https://biglab.site//b59510spark/file/spark_t_data.tar.gz
3 tar -xzvf ./spark_t_data.tar.gz
4 hdfs dfs -rm /user/myname/words.txt
5 hdfs dfs -rm -r /user/myname/output_wordcount
6 hdfs dfs -put ./spark_t_data/words.txt /user/myname/
```

在spark-shell上执行

```
1 spark-shell
```

```
1 val worddata=sc.textFile("/user/myname/words.txt").flatMap(x=>x.split(" ")).map(x=>(x,1)).reduceByKey((x,y)=>x+y)
2
3 val worddata_3=worddata.filter(x=>x._2>=2).map(x=>x._1)
4
5 worddata_3.repartition(1).saveAsTextFile("/user/myname/output_wordcount")
```

spark-shell预期输出：

```
1  scala> val  
2    worddata=sc.textFile("/user/myname/words.txt").flatMap(x=>x.split(""  
3    ")).map(x=>(x,1)).reduceByKey((x,y)=>x+y)  
4    worddata: org.apache.spark.rdd.RDD[(String, Int)] = shuffledRDD[16] at  
5    reduceByKey at <console>:24  
6  
7  scala>  
8  
9  scala> val worddata_3=worddata.filter(x=>x._2>3).map(x=>x._1)  
10  worddata_3: org.apache.spark.rdd.RDD[String] = MapPartitionsRDD[18] at map at  
11  <console>:25  
12  
13  scala>
```

在hdfs上观察

```
1 | /user/myname/output_wordcount
```

学习视频

[学习视频](#)

CH03实训2：通过spark编程统计某月份的客户总消费金额

训练要点

1. 掌握数据读取和存储的方法。
2. 掌握RDD基本操作

需求说明

大数据和人工智能技术的应用，使得我国广大科技工作者能够把握大势、抢占先机、直面问题、迎难而上，瞄准世界科技前沿，引领科技发展方向。

本任务中，某互联网企业，创建了线上购物平台，开拓了新的商品销售渠道。现有一份某电商2020年12月份的订单数据文件online_retail.csv，记录了每位顾客每笔订单的购物情况，包含3个数据字段，字段说明如表3. 7所示。因为该电商准备给重要的客户发放购物津贴作为福利回馈，提高顾客满意度，所以需要统计每位客户的总消费金额，并筛选出消费金额排在前50名的客户。

某电商的订单数据字段说明：

字段名称	说明
Invoice	订单编号
Price	订单价格 (单位: 元)
Customer ID	客户编号

实现思路及步骤

1. 读取数据并创建RDD.
2. 通过map()方法分割数据，选择客户编号和订单价格字段组成键值对数据.
3. 使用reduceByKey()方法计算每位客户的总消费金额.
4. 使用sortBy()方法对每位客户的总消费金额进行降序排序，取出前50条数据.

作业要求

提交源码和脚本运行过程截图

实现参考

数据准备

在slave1上运行：

```

1 cd /root/spark
2 wget https://biglab.site//b59510spark/file/spark_t_data.tar.gz
3 tar -xzvf ./spark_t_data.tar.gz
4 hdfs dfs -put ./spark_t_data/online_retail.txt /user/myname/

```

spark-shell脚本

```

1 //在Spark-shell中 读取上传到HDFS上的数据
2 val input = sc.textFile("/user/myname/online_retail.txt")
3
4 //去除csv数据文件的第一行
5 val cutinput = input.mapPartitionsWithIndex((ix, it) => {
6   if (ix == 0) it.drop(1)
7   it
8 })
9 cutinput.collect
10
11 val re = cutinput.map(line => {val data = line.split(","); (data(0),
12   data(1).toDouble)}).reduceByKey(_+_)
13
14 val re_sort = re.filter(x=> !(x._1=="")).sortBy(x=>x._2, false)
15
16 re_sort.take(50)

```

预期输出

```
1 scala> //在Spark-shell中 读取上传到HDFS上的数据
2
3 scala> val input = sc.textFile("/user/myname/online_retail.txt")
4 input: org.apache.spark.rdd.RDD[String] = /user/myname/online_retail.txt
MapPartitionsRDD[1] at textFile at <console>:24
5
6 scala>
7
8 scala> //去除csv数据文件的第一行
9
10 scala> val cutinput = input.mapPartitionsWithIndex((ix, it) => {
11 |   if (ix == 0) it.drop(1)
12 |   it
13 | })
14 cutinput: org.apache.spark.rdd.RDD[String] = MapPartitionsRDD[2] at
mapPartitionsWithIndex at <console>:25
15
16 scala> cutinput.collect
17 res0: Array[String] = Array(17850,2.55,536365, 17850,3.39,536365,
17850,2.75,536365, 17850,3.39,536365, 17850,3.39,536365, 17850,7.65,536365,
17850,4.25,536365, 17850,1.85,536366, 17850,1.85,536366, 13047,4.25,536368,
13047,4.95,536368, 13047,4.95,536368, 13047,4.95,536368, 13047,1.69,536367,
13047,2.1,536367, 13047,2.1,536367, 13047,3.75,536367, 13047,1.65,536367,
13047,4.25,536367, 13047,4.95,536367, 13047,9.95,536367, 13047,5.95,536367,
13047,5.95,536367, 13047,7.95,536367, 13047,7.95,536367, 13047,5.95,536369,
12583,3.75,536370, 12583,3.75,536370, 12583,3.75,536370, 12583,0.85,536370,
12583,0.65,536370, 12583,0.85,536370, 12583,1.25,536370, 12583,2.95,536370,
12583,2.95,536370, 12583,1.95,536370, 12583,1.95,536370, 12583,1.95,536370,
12583,0.85,536370, 1258...
18
19 scala>
20
21 scala> val re = cutinput.map(line => {val data = line.split(",");(data(0),
data(1).toDouble)}).reduceByKey(_+_)
22 re: org.apache.spark.rdd.RDD[(String, Double)] = shuffledRDD[4] at
reduceByKey at <console>:25
23
24 scala>
25
26 scala> val re_sort = re.filter(x=> !(x._1=="")).sortBy(x=>x._2,false)
27 re_sort: org.apache.spark.rdd.RDD[(String, Double)] = MapPartitionsRDD[10] at
sortBy at <console>:25
28
29 scala>
30
31 scala> re_sort.take(50)
```

```
32 res1: Array[(String, Double)] = Array((12748,1618.1500000000015),  
33 (14911,1573.1600000000014), (17850,1176.229999999982),  
34 (17841,1073.129999999997), (14606,828.519999999996),  
35 (16607,726.319999999999), (14527,666.139999999996),  
36 (17340,613.509999999999), (15311,582.789999999997),  
37 (15044,545.459999999998), (13174,519.7500000000001),  
38 (14667,506.549999999998), (15727,456.449999999993),  
39 (17961,414.82000000000005), (14030,413.75), (18116,410.979999999973),  
40 (15039,404.669999999998), (16873,401.429999999999),  
41 (18118,389.709999999998), (15574,386.249999999999),  
42 (14180,382.249999999994), (16713,377.519999999987),  
43 (18055,377.379999999999), (14505,373.299999999956),  
44 (15498,369.669999999996), (15808,366.299999999998),  
45 (15570,363.509999999993), (12...  
33  
34 scala>
```

CH03实训3：通过Spark编程计算各城市的平均气温

训练要点

1. 掌握RDD创建方法
2. 掌握map()、groupBy()、mapvalues()、reduce()方法的使用

需求说明

天气预报每天都会显示各城市的温度，方便出行人士根据当天的温度穿上合适的衣物。现有一份各城市的温度数据文件avgTemperature.txt，数据如表所示，记录了某段时间范围内各城市每天的温度，文件中每一行数据分别表示城市名和温度，现要求使用spark 编程计算出各城市的平均气温。

各城市温度部分数据

```
1 being 28.1  
2 shanghai 28.7  
3 guangzhou 32.0  
4 shenzhen 33.1  
5 being 27.3  
6 shanghai 30.1  
7 guangzhou 33.3  
8 shenzhen 28.6  
9 beijing 28.2  
10 shanghai 29.1  
11 guangzhou 32.0  
12 shenzhen 32.1
```

实现思路及步骤

1. 通过textFile()方法读取数据创建RDD
2. 使用map()方法将输入数据按制表符(TAB)进行分割，并转化成（城市，温度）的形式。
3. 使用groupByKey()方法按城市分组，得到每个城市对应的所有温度。
4. 使用mapvalues()和reduce()方法计算各城市平均气温

作业要求

提交源码和脚本运行过程截图

实现参考

数据准备

```
1 cd /root/spark
2 wget https://biglab.site//b59510spark/file/spark_t_data.tar.gz
3 tar -xzvf ./spark_t_data.tar.gz
4 hdfs dfs -put ./spark_t_data/avgTemperature.txt /user/myname/
```

在spark-shell上执行

```
1 val input = sc.textFile("/user/myname/avgTemperature.txt")
2 // 利用map算子转换数据类型
3 val mapRDD = input.map(
4     data => {
5         val datas = data.split("\t")
6         (datas(0), datas(1).toDouble)
7     }
8 )
9 //按城市分组
10 val groupRDD = mapRDD.groupBy(_._1)
11 // 计算各城市平均气温
12 val avgTmp = groupRDD.mapValues(data => {
13     val a = data.reduce((x, y) => ("", x._2 + y._2))
14     a._2 / data.size
15 })
16 avgTmp.collect
```

spark-shell预期输出：

```
1 scala> val
2 worddata=sc.textFile("/user/myname/words.txt").flatMap(x=>x.split(" "))
3 ")).map(x=>(x,1)).reduceByKey((x,y)=>x+y)
4 worddata: org.apache.spark.rdd.RDD[(String, Int)] = shuffledRDD[16] at
5 reduceByKey at <console>:24
6
7 scala>
8
9 scala> val worddata_3=worddata.filter(x=>x._2>3).map(x=>x._1)
```

```
7 worddata_3: org.apache.spark.rdd.RDD[String] = MapPartitionsRDD[18] at map at
<console>:25
8
9 scala>
10
11 scala>
12 worddata_3.repartition(1).saveAsTextFile("/user/myname/output_wordcount")
13
14 scala> val input = sc.textFile("/user/myname/avgTemperature.txt")
15 input: org.apache.spark.rdd.RDD[String] = /user/myname/avgTemperature.txt
MapPartitionsRDD[25] at textFile at <console>:24
16
17 scala> // 利用map算子转换数据类型
18
19 scala> val mapRDD = input.map(
20 |     data => {
21 |         val datas = data.split("\t")
22 |         (datas(0), datas(1).toDouble)
23 |     }
24 | )
25 mapRDD: org.apache.spark.rdd.RDD[(String, Double)] = MapPartitionsRDD[26] at
map at <console>:25
26
27 scala> //按城市分组
28
29 scala> val groupRDD = mapRDD.groupBy(_._1)
30 groupRDD: org.apache.spark.rdd.RDD[(String, Iterable[(String, Double)])] =
ShuffledRDD[28] at groupBy at <console>:25
31
32 scala> // 计算各城市平均气温
33
34 scala> val avgTmp = groupRDD.mapValues(data => {
35 |     val a = data.reduce((x, y) => ("", x._2 + y._2))
36 |     a._2 / data.size
37 | }
38 avgTmp: org.apache.spark.rdd.RDD[(String, Double)] = MapPartitionsRDD[29] at
mapvalues at <console>:25
39
40 scala> avgTmp.collect
41 res3: Array[(String, Double)] = Array((guangzhou,32.43333333333333),
(beijing,27.86666666666667), (shenzhen,32.6), (shanghai,29.3))
42
43 scala>
```