

АНАЛИЗ ЭФФЕКТИВНОСТИ АЛГОРИТМА MAPREDUCE ПРИ РЕШЕНИИ ЗАДАЧИ ВЫЧИСЛЕНИЯ СУММАРНОЙ ВЫРУЧКИ ПРЕДПРИЯТИЙ РЕГИОНА С ПОМОЩЬЮ APACHE HADOOP

Диденко А.А., магистрант гр. ПИм-171, I курс

Научный руководитель: Пимонов А.Г., д.т.н., профессор

Кузбасский государственный технический университет имени Т.Ф. Горбачева
г. Кемерово

Введение. В современном обществе все чаще возникают проблемы анализа большого объема данных, таких как логи покупок, посещений интернет-сайтов, геоданных и много другого. Для решения данной проблемы компания Google разработала и выложила в открытый доступ алгоритм распределенных вычислений MapReduce [1], который послужил основой для свободно распространяемого проекта Apache Software Foundation, состоящего из набора утилит, библиотек и фреймворка для разработки и выполнения распределенных программ, работающих на кластерах из сотен и тысяч узлов [2]. В данной статье представлены анализ и демонстрация работы данного алгоритма на примере решения задачи по вычислению суммарной выручки предприятий в регионе с помощью Apache Hadoop на кластере, поднятом в виртуальной машине.

Постановка задачи. Есть лог из 4 млн. транзакций, представленный в формате: Date \t Time \t Region \t Product \t Amount \t Method \n. Пример записей из лога представлен на рис. 1. Необходимо вычислить суммарную выручку предприятий в регионе.

purchases.txt						
2012-12-31	17:58	Daytona	Toys	66.01	MasterCard	
2012-12-31	17:58	Newark	DVDs	199.78	MasterCard	
2012-12-31	17:58	Fort Worth	Pet Supplies	438.98	Amex	
2012-12-31	17:58	Washington	CDs	52.83	Discover	
2012-12-31	17:59	Baltimore	DVDs	467.3	Visa	
2012-12-31	17:59	Santa Ana	Video Games	144.73	Visa	
2012-12-31	17:59	Gilbert	Consumer Electronics	354.66	Discover	
2012-12-31	17:59	Memphis	Sporting Goods	124.79	Amex	
2012-12-31	17:59	Chicago	Men's Clothing	386.54	MasterCard	
2012-12-31	17:59	Birmingham	CDs	118.04	Cash	
2012-12-31	17:59	Las Vegas	Health and Beauty	420.46	Amex	
2012-12-31	17:59	Wichita	Toys	383.9	Cash	
2012-12-31	17:59	Tucson	Pet Supplies	268.39	MasterCard	
2012-12-31	17:59	Glendale	Women's Clothing	68.05	Amex	
2012-12-31	17:59	Albuquerque	Toys	345.7	MasterCard	
2012-12-31	17:59	Rochester	DVDs	399.57	Amex	
2012-12-31	17:59	Greensboro	Baby	277.27	Discover	
2012-12-31	17:59	Arlington	Women's Clothing	134.95	MasterCard	
2012-12-31	17:59	Corpus Christi	DVDs	441.61	Discover	

Рис. 1. Лог транзакций

Решение данной задачи стандартными методами программирования, например, с помощью программы на Java, которая парсит этот лог построчно и суммирует суммы покупок по регионам, занимает довольно большой

промежуток времени, а конкретно около 40 минут для моей системы. Это неприемлемый результат для такого относительно небольшого набора данных. Теперь решим эту же задачу, но уже с помощью алгоритма MapReduce. Данный алгоритм состоит из нескольких шагов [3]. Первый шаг – это применение функции Map к каждому элементу исходного лога. Функция возвращает либо ноль, либо создает объект, состоящий из пары значений Key/Value, в нашем случае Key – Region/Value – Amount. Примеры таких объектов: [Washington/52.83], [Baltimore/467.3], [Washington/37.23] и так далее. Следующим шагом алгоритм отсортирует все объекты методом shuffle and sort, а также создает новые экземпляры объектов, где все значения (Value) будут сгруппированы по ключу. Примеры таких объектов: [Washington: 52.83, 37.23, ...], [Baltimore: 467.3, ...] и так далее. Последним шагом будет выполнение функции Reduce для каждого сгенерированного объекта. С помощью этой функции будут просуммированы все элементы Value объекта, а результаты ее работы возвращены в коллекцию в формате Key: Result. Все три шага изображены на рис. 2. Примеры результирующих объектов: [Washington: 90.06], [Baltimore: 467.3] и так далее.

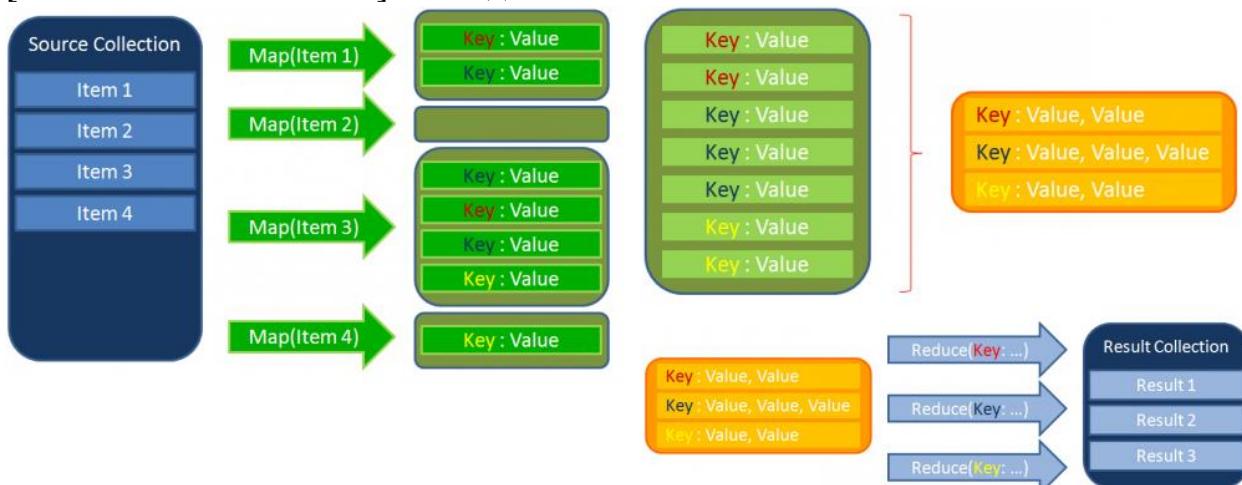
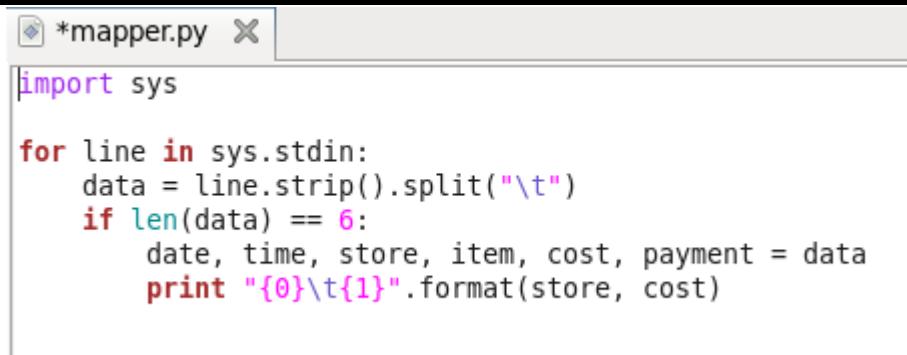


Рис. 2. Алгоритм MapReduce

Для реализации данного алгоритма был выбран язык программирования Python, а также был создан виртуальный кластер в программе Oracle VM VirtualBox. Код Map и Reduce для данной задачи представлен на рис. 3, 4.

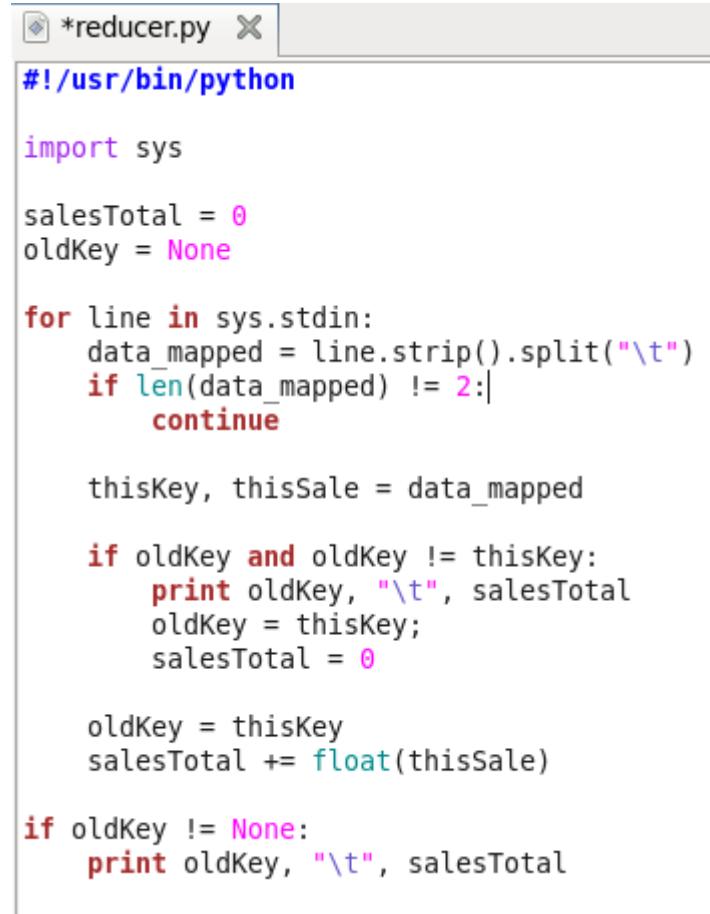
Процесс и результаты решения задачи представлены на рис. 5. Кроме того во время решения данной задачи на виртуальном кластере собиралась статистика, представленная на рис. 6., из которой видно, что для решения было создано четыре параллельные задачи map и одна – reduce. Распределение времени, потраченного на копирование, сортировку и сборку в процентах представлено на последнем графике (рис. 6).



```
import sys

for line in sys.stdin:
    data = line.strip().split("\t")
    if len(data) == 6:
        date, time, store, item, cost, payment = data
        print "{0}\t{1}".format(store, cost)
```

Рис. 3. Mapper.py



```
#!/usr/bin/python

import sys

salesTotal = 0
oldKey = None

for line in sys.stdin:
    data_mapped = line.strip().split("\t")
    if len(data_mapped) != 2:
        continue

    thisKey, thisSale = data_mapped

    if oldKey and oldKey != thisKey:
        print oldKey, "\t", salesTotal
        oldKey = thisKey
        salesTotal = 0

    oldKey = thisKey
    salesTotal += float(thisSale)

if oldKey != None:
    print oldKey, "\t", salesTotal
```

Рис. 4. Reducer.py

Заключение. В данной статье был рассмотрен алгоритм MapReduce на примере решения задачи по вычислению суммарной выручки предприятий в регионе с помощью Apache Hadoop на виртуальном кластере. В результате было наглядно продемонстрировано, что для данного лога и конкретного компьютера алгоритм MapReduce в 30-35 раз эффективнее по времени, чем линейное решение, написанное на Java.

File	Edit	View	Search	Terminal	Help	File	Edit	View	Search	Terminal	Help
[training@localhost code]\$	hs	mapper.py	reducer.py	myinput	output2	Albuquerque	10052311.42				
packageJobJar:	[mapper.py, reducer.py, /tmp/hadoop-training/hadoop-unjar62176556	484266683/]	[] /tmp/streamjob7816135680932716611.jar	tmpDir=null		Anaheim	10076416.36				
18/03/13 15:16:30	WARN	mapred.JobClient:	Use GenericOptionsParser for parsing the arguments.	Applications should implement Tool for the same.		Anchorage	9933500.4				
18/03/13 15:16:30	WARN	snappy.LoadSnappy:	Snappy native library is available			Arlington	10072207.97				
18/03/13 15:16:30	INFO	snappy.LoadSnappy:	Snappy native library loaded			Atlanta	9997146.7				
18/03/13 15:16:30	INFO	mapred.FileInputFormat:	Total input paths to process : 1			Aurora	9992970.92				
18/03/13 15:16:31	INFO	streaming.StreamJob:	getLocalDirs(): [/var/lib/hadoop-hdfs/cache/training/mapred/local]			Austin	10057158.9				
18/03/13 15:16:31	INFO	streaming.StreamJob:	Running job: job_201803131444_0004			Bakersfield	10031208.92				
18/03/13 15:16:31	INFO	streaming.StreamJob:	To kill this job, run:			Baltimore	10096521.45				
18/03/13 15:16:31	INFO	streaming.StreamJob:	UNDEF/bin/hadoop job -Dmapred.job.tracker=0.0.0.0:8021 -kill job_201803131444_0004			Baton Rouge	10131273.23				
18/03/13 15:16:31	INFO	streaming.StreamJob:	Tracking URL: http://0.0.0.0:50030/jobdetails.jsp?jobid=job_201803131444_0004			Birmingham	10076606.52				
18/03/13 15:16:32	INFO	streaming.StreamJob:	map 0% reduce 0%			Boise	10039166.74				
18/03/13 15:16:45	INFO	streaming.StreamJob:	map 6% reduce 0%			Buffalo	1001941.19				
18/03/13 15:16:46	INFO	streaming.StreamJob:	map 13% reduce 0%			Chandler	9919559.86				
18/03/13 15:16:48	INFO	streaming.StreamJob:	map 18% reduce 0%			Charlotte	10112531.34				
18/03/13 15:16:49	INFO	streaming.StreamJob:	map 23% reduce 0%			Chesapeake	10038504.92				
18/03/13 15:16:51	INFO	streaming.StreamJob:	map 28% reduce 0%			Chicago	10062522.07				
18/03/13 15:16:52	INFO	streaming.StreamJob:	map 33% reduce 0%			Chula Vista	9974951.34				
18/03/13 15:16:54	INFO	streaming.StreamJob:	map 39% reduce 0%			Cincinnati	10139505.74				
18/03/13 15:16:55	INFO	streaming.StreamJob:	map 45% reduce 0%			Cleveland	10067835.84				
18/03/13 15:16:57	INFO	streaming.StreamJob:	map 50% reduce 0%			Colorado Springs	10061105.87				
18/03/13 15:17:04	INFO	streaming.StreamJob:	map 75% reduce 0%			Columbus	10035241.03				
18/03/13 15:17:07	INFO	streaming.StreamJob:	map 90% reduce 25%			Corpus Christi	9976522.77				
18/03/13 15:17:10	INFO	streaming.StreamJob:	map 100% reduce 25%			Dallas	10066548.45				
18/03/13 15:17:16	INFO	streaming.StreamJob:	map 100% reduce 77%			Denver	10031534.87				
18/03/13 15:17:19	INFO	streaming.StreamJob:	map 100% reduce 89%			Detroit	9979260.76				
18/03/13 15:17:23	INFO	streaming.StreamJob:	map 100% reduce 100%			Durham	10153890.21				
18/03/13 15:17:24	INFO	streaming.StreamJob:	Job complete: job_201803131444_0004			El Paso	10016409.97				
18/03/13 15:17:24	INFO	streaming.StreamJob:	Output: output2			Fort Wayne	10132594.02				
[training@localhost code]\$	hadoop	fs	-ls	output2		Fort Worth	10120830.65				
Found 3 items						Fremont	10053242.36				
-rw-r--r--	1	training	supergroup		0 2018-03-13 15:17 output2/_SUCCESS	Fresno	9976260.26				
drwxr-xr-x	-	training	supergroup		0 2018-03-13 15:16 output2/_logs	Garland	10071043.92				
-rw-r--r--	1	training	supergroup		2296 2018-03-13 15:17 output2/part-0000	Gilbert	10062115.19				
						Glendale	10044493.97				
						Greensboro	10033781.39				
						Henderson	10053416.05				
						:					

Рис. 5. Процесс и результаты решения задачи алгоритмом MapReduce

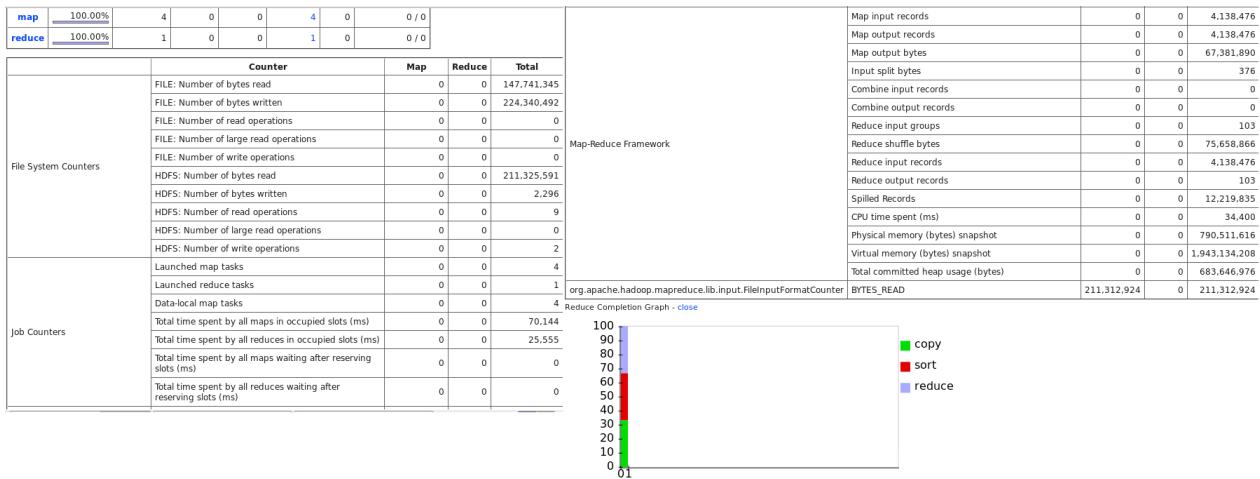


Рис. 6. Статистика решения задачи на виртуальном кластере

Список литературы:

1. Википедия MapReduce [Электронный ресурс]. – Режим доступа: <https://ru.wikipedia.org/wiki/MapReduce>, свободный (дата обращения 22.03.2018).
2. Википедия Hadoop [Электронный ресурс]. – Режим доступа: <https://ru.wikipedia.org/wiki/Hadoop>, свободный (дата обращения: 22.03.2018).

3. Что такое MapReduce?] // Статья блога о разработке, программировании на C#/.NET, и не только [Электронный ресурс]. – Режим доступа: [http://regfordev.blogspot.ru/2015/09/
mapreduce.html#.WrQJDOjFKUm](http://regfordev.blogspot.ru/2015/09/mapreduce.html#.WrQJDOjFKUm), свободный (дата обращения 22.03.2018).