
TP 1 : Gestion et analyse des Big Data

I/ Suivre les étapes suivantes pour exécuter le programme Wordcount en langage Java

1/ Démarrer l'hadoop en suivant les commandes

sudo rm -r hdfs/datanode/current

sudo rm -r hdfs/namenode/current

hdfs namenode -format

start-dfs.sh

start-yarn.sh

Soyez sûr que les six services sont démarrés

Remarque :

Le fichier /usr/local/hadoop/etc/hadoop/mapred-site.xml doit contenir la propriété :

<property>

<name>mapreduce.application.classpath</name>

<value>\$HADOOP_MAPRED_HOME/share/hadoop/mapreduce/*:\$HADOOP_MAPRED_HOME/share/hadoop/mapreduce/lib/*</value>

</property>

Et le fichier /usr/local/hadoop/etc/hadoop/yarn-site.xml doit aussi contenir la propriété

<property>

<name>yarn.nodemanager.env-whitelist</name>

<value>JAVA_HOME,HADOOP_COMMON_HOME,HADOOP_HDFS_HOME,HADOOP_CONF_DIR,CLASSPATH_PREPEND_DISTCACHE,HADOOP_YARN_HOME,HADOOP_HOME,PATH,LANG,TZ,HADOOP_MAPRED_HOME</value>

</property>

2/ préparer un fichier texte avec une bonne taille ; mettre le dans /home/Desktop/exemple.txt

3/ Mettre ce fichier dans le hdfs

hadoop fs -put /home/Desktop/exemple.txt /imput_dir

Verifier dans le navigateur la présence du dossier imput_dir

4/ exécuter la classe wordcount pour compter le nombre d'occurrence de mots

hadoop jar /usr/local/hadoop/share/hadoop/mapreduce/hadoop-mapreduce-examples-3.3.1.jar wordcount /input_dir /output_dir

verifier votre hdfs

5/ afficher le contenu du fichier part-r-00000

hdfs dfs -cat /output_dir/part-r-00000

II/ Suivre les étapes suivantes pour exécuter wordcount écrit en Python

1/ créer les fichiers mapper.py

cd Documents

touch mapper.py

nano mapper.py

saisir ce code python qui la fonction map

#!/usr/bin/python3

import sys because we need to read and write data to STDIN and STDOUT

import sys

reading entire line from STDIN (standard input)

for line in sys.stdin:

to remove leading and trailing whitespace

line = line.strip()

split the line into words

words = line.split()

we are looping over the words array and printing the word

with the count of 1 to the STDOUT

for word in words:

write the results to STDOUT (standard output);

```
# what we output here will be the input for the  
  
# Reduce step, i.e. the input for reducer.py  
  
print ('%s\t%s' % (word, 1))
```

1/ créer les fichiers reducer.py

cd Documents

touch reducer.py

nano reducer.py

saisir ce code python qui la fonction reduce

```
#!/usr/bin/python3
```

```
from operator import itemgetter
```

```
import sys
```

```
current_word = None
```

```
current_count = 0
```

```
word = None
```

```
# read the entire line from STDIN
```

```
for line in sys.stdin:
```

```
    # remove leading and trailing whitespace
```

```
    line = line.strip()
```

```
    # splitting the data on the basis of tab we have provided in mapper.py
```

```
    word, count = line.split('\t', 1)
```

```
    # convert count (currently a string) to int
```

```
    try:
```

```
        count = int(count)
```

```
    except ValueError:
```

```
# count was not a number, so silently

# ignore/discard this line

continue

# this IF-switch only works because Hadoop sorts map output
# by key (here: word) before it is passed to the reducer

if current_word == word:

    current_count += count

else:

    if current_word:

        # write result to STDOUT

        print ('%s\t%s' % (current_word, current_count))

    current_count = count

    current_word = word

# do not forget to output the last word if needed!

if current_word == word:

    print ('%s\t%s' % (current_word, current_count))

3/ vérifier si vous avez Python 3 ; sinon install le

sudo apt update

sudo apt install python3

sudo add-apt-repository ppa:deadsnakes/ppa

4/ Préparer un fichier texte et mettre le dans Documents/word_count_data.txt

5/ donner les droits d'accès aux deux programmes

chmod 777 /home/Documents/mapper.py

chmod 777 /Documents/reducer.py

6/ vérifier le fonctionnement des deux programmes
```

cat word_count_data.txt |python3 mapper.py

cat word_count_data.txt |python3 mapper.py | sort -k1,1 | python3 reducer.py

7/ sortir du répertoire Documents

8/ Démarrer Hadoop

hdfs dfs -mkdir /word_count_in_python

**hdfs dfs -copyFromLocal /home/votre-user/Documents/word_count_data.txt
word_count_in_python**

votre-user c'est le nom de votre compte

maintenant mettre le jar hadoop-streaming-3.3.1.jar dans le dossier Documents

**hadoop jar /home/votre-user/Documents/hadoop-streaming-3.3.1.jar -input
word_count_in_python/word_count_data.txt -output word_count_in_python/output -
mapper /home/votre-user/Documents/mapper.py -reducer /home/votre-
user/Documents/reducer.py**

9/ vérifier le résultat et afficher le contenu du fichier part-00000

Travail à rendre dans la séance

Ecrire en pseudo-code python les fonctions Map et Reduce qui comptent le nombre de voyelles et celui des consonnes dans un texte en entrée.

Note : le travail sera calculé dans la note TP