

pig_cloudera

July 1, 2023

1 Map/Reduce avec PIG sur cloudera - énoncé

Manipulation de fichiers sur un cluster Hadoop Cloudera, premier job map/reduce avec [PIG](#). Lire aussi [From Pig to Spark: An Easy Journey to Spark for Apache Pig Developers](#).

```
[1]: from jyquickhelper import add_notebook_menu  
add_notebook_menu()
```

```
[1]: <IPython.core.display.HTML object>
```

1.1 Données

On considère le jeu de données suivant : [Localization Data for Person Activity Data Set](#) qu'on récupère comme suit :

```
[2]: import pyensae.datasource  
import urllib.error  
try:  
    # ce soir ça ne marche pas...  
    pyensae.datasource.download_data("ConfLongDemo_JSI.txt",  
                                    website="https://archive.ics.uci.edu/ml/  
machine-learning-databases/00196/")  
except urllib.error.URLError:  
    # donc je récupère une vieille copie  
    pyensae.datasource.download_data("ConfLongDemo_JSI.zip")
```

On l'insère dans une base de données SQL.

```
[3]: columns = "sequence tag timestamp dateformat x y z activity".split()  
import pandas, sqlite3, os  
df = pandas.read_csv("ConfLongDemo_JSI.txt", sep=",", names=columns)  
if os.path.exists("ConfLongDemo_JSI.db3"):  
    os.remove("ConfLongDemo_JSI.db3")  
  
con = sqlite3.connect("ConfLongDemo_JSI.db3")  
df.to_sql("person", con)  
con.close()  
df.head()
```

```
[3]:   sequence          tag      timestamp      dateformat  \\\n0       A01  010-000-024-033  633790226051280329  27.05.2009 14:03:25:127  
1       A01  020-000-033-111  633790226051820913  27.05.2009 14:03:25:183  
2       A01  020-000-032-221  633790226052091205  27.05.2009 14:03:25:210
```

```
3      A01 010-000-024-033 633790226052361498 27.05.2009 14:03:25:237
4      A01 010-000-030-096 633790226052631792 27.05.2009 14:03:25:263
```

```
          x      y      z activity
0  4.062931  1.892434  0.507425 walking
1  4.291954  1.781140  1.344495 walking
2  4.359101  1.826456  0.968821 walking
3  4.087835  1.879999  0.466983 walking
4  4.324462  2.072460  0.488065 walking
```

On crée un petit exemple pour plus tard qu'on enregistre également dans la base de données.

```
[4]: columns = "sequence tag timestamp dateformat x y z activity".split()
import pandas
df = pandas.read_csv("ConfLongDemo_JSI.txt", sep=",", names=columns)
dfs = df[:1000]
dfs.to_csv("ConfLongDemo_JSI.small.txt", header=False)

import sqlite3
con = sqlite3.connect("ConfLongDemo_JSI.db3")
dfs.to_sql("person_small", con)
con.close()
```

```
[5]: [ _ for _ in os.listdir(".") if "db3" in _ ]
```

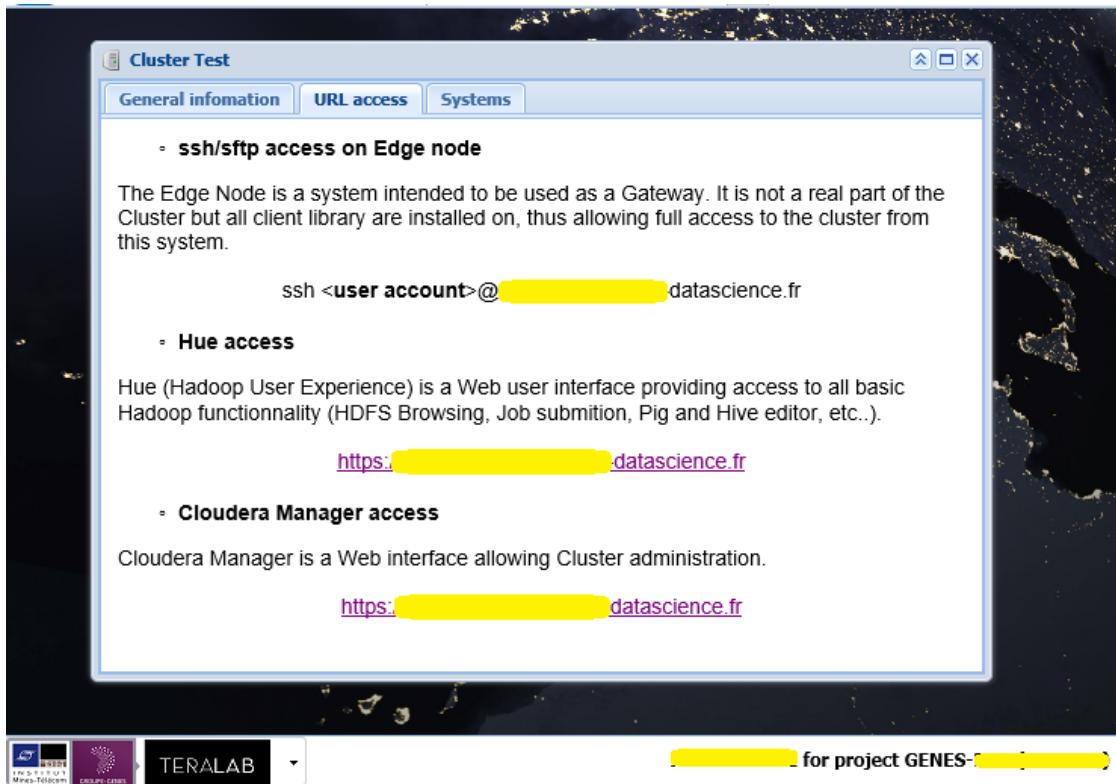
```
[5]: ['ConfLongDemo_JSI.db3']
```

1.2 Partie 0 : aperçu du cluster Teralab

Il faut se connecter au cluster avec l'url : <https://....datascience.fr/....&login=<login>>.

```
[6]: from pyquickhelper.helpgen import NbImage
NbImage("cluster1.png", width=500)
```

```
[6]:
```



Il faut cliquer ensuite sur **Hue Access** une fenêtre s'ouvre. Il faut ensuite trouver l'onglet qui permette d'obtenir l'image suivante et le bouton **Upload** :

[7] : NbImage("hdfs1.png", width=900)

[7] :

Name	Size	User	Group	Permissions	Date
.		xavierdupre	xavierdupre	drwxr-xr-x	August 28, 2014 03:49 PM
..		xavierdupre	xavierdupre	drwxr-xr-x	August 28, 2014 03:18 PM
stations_count_2013-05-24.paris.short.pig.txt	3.3 MB	xavierdupre	xavierdupre	drwxr-xr-x	August 28, 2014 03:49 PM
velib_20r.txt		xavierdupre	xavierdupre	-rwxr-xr-x	August 28, 2014 03:13 PM

Les notebooks n'utiliseront que rarement cette interface qui est lente [Hue extremely slow in running Hive Queries, hue is very slow](#).

1.3 Partie 1 : manipulation de fichiers

Avant de commencer à déplacer des fichiers, il faut comprendre qu'il y a trois emplacements :

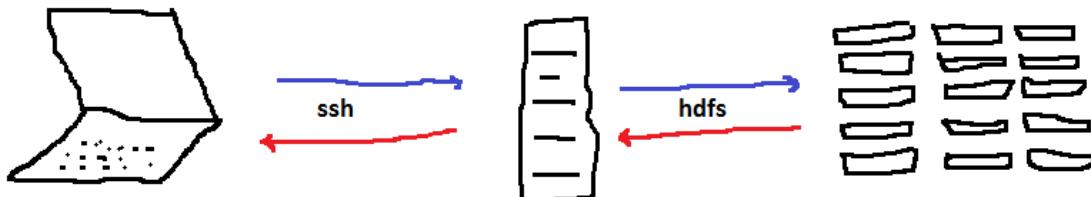
- l'ordinateur local (celui dont vous vous servez)
- la machine distante ou [passerelle](#)
- le cluster

Les fichiers vont transiter sans cesse par cette passerelle. La passerelle est connectée à l'ordinateur local via SSH.

[8] :

```
from pyquickhelper.helpgen import NbImage
NbImage("hdfspath.png")
```

[8] :

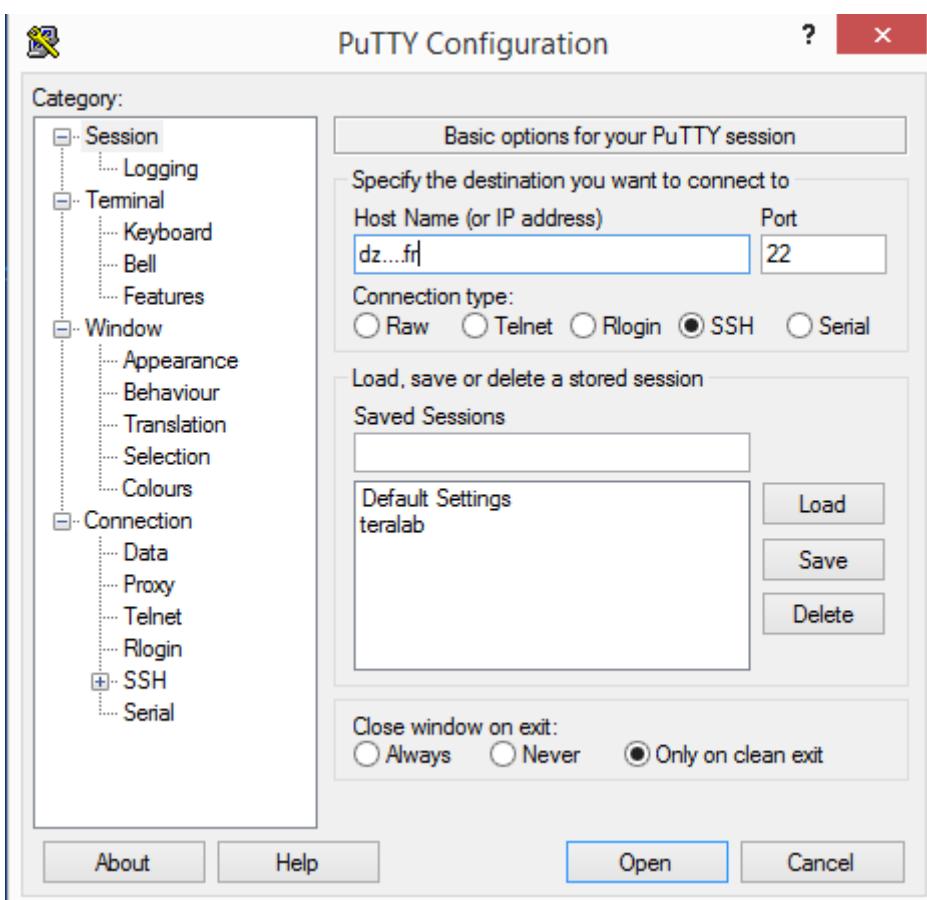


On **upload** pour le chemin bleu, on **download** pour le chemin rouge. La passerelle est sous linux et c'est par son intermédiaire qu'on va communiquer avec le cluster. Toutes les commandes qui suivent vont être exécutées depuis cette machine. L'outil le plus connu pour s'y connecter est [Putty](#). La commande magique `%remote_cmd` imite le comportement d'une fenêtre putty.

[9] :

```
from pyquickhelper.helpgen import NbImage
NbImage("putty1.png", width=400)
```

[9] :



```
[10]: NbImage("putty2.png", width=600)
```

[10]:



A screenshot of a terminal window titled "xavierdupre@en1:~". The window shows the command "Using username \"xavierdupre\"." followed by a password prompt: "xavierdupr... 's password: [REDACTED]". The terminal has a dark background and light-colored text.

Le cluster [Hadoop](#) inclut un système de fichiers [HDFS](#). Celui fonctionne à peu près comme un système de fichiers linux avec les mêmes commandes à ceci près qu'un fichier n'est plus nécessaire localisé sur une seule machine mais peut-être réparti sur plusieurs. Pour éviter la perte de données due à des machines défaillantes, les données sont [répliquées trois fois](#). Les opérations standard sont disponibles (copy, rename, delete) auxquelles on ajoute deux opérations : upload, download. Les commandes sont presque identiques à celles de linux mais précédées de [hdfs](#).

Pour manipuler les données sur un cluster, il faut d'abord les [uploader](#) sur ce cluster. Pour les récupérer, il faut les [downloader](#). Pour faciliter les choses, on va utiliser des [commandes magiques](#) implémentées dans le module [pyensae](#) (≥ 0.8). La première tâche est d'enregistrer dans l'espace de travail le nom du server, votre alias et votre mot de passe dans le workspace du notebook.

Le code est avant tout destiné à **ne pas laisser votre mot de passe en clair dans le notebook**. S'il est en clair, tôt ou tard, vous oublierez de l'effacer avant de partager votre notebook. Dans ce cas, il faut changer de mot de passe sans tarder.

Le code suivant vérifie d'abord qu'il n'existe pas de variable d'environnement CRTERALAB afin de ne pas avoir à rentrer les mot de passe à chaque fois (voir [Mettre ses mots de passe dans les variables d'environnement](#)). Si cette variable existe, le notebook s'attend à trouver l'information `server**password**username`.

```
[11]: import os
if "CRTERALAB" in os.environ:
    spl = os.environ["CRTERALAB"].split("**")
    params=dict(server=spl[0], password=spl[1], username=spl[2])
    r = dict
else:
    from pyquickhelper.ipythonhelper import open_html_form
    params={"server": "", "username": "", "password": ""}
    r = open_html_form(params=params,title="server + credentials", key_save="params")
r
```

```
[11]: dict
```

On stocke le mot de passe dans trois variables de l'espace de travail afin que les commandes magiques trouvent ces informations.

```
[12]: password = params["password"]
server = params["server"]
username = params["username"]
```

On ouvre la connection SSH qui restera ouverte jusqu'à ce qu'on la ferme.

```
[13]: %load_ext pyensae  
%load_ext pyenbc  
%remote_open
```

```
[13]: <pyensae.remote.ssh_remote_connection.ASSHClient at 0xbb31f28>
```

On regarde le contenu du répertoire qui vous est associé sur la machine distante :

```
[14]: %remote_cmd ls -l
```

```
[14]: <IPython.core.display.HTML object>
```

On efface tout :

```
[15]: %remote_cmd rm -r *
```

```
[15]: <IPython.core.display.HTML object>
```

```
[16]: %remote_cmd ls -l
```

```
[16]: <IPython.core.display.HTML object>
```

C'est une commande linux. Les commandes les plus fréquentes sont accessibles décrites à [Les commandes de base en console](#). L'instruction suivante consiste à uploader un fichier depuis l'ordinateur local vers la passerelle.

```
[17]: %remote_up ConfLongDemo_JSI.small.txt ConfLongDemo_JSI.small.example.txt
```

```
[17]: 'ConfLongDemo_JSI.small.example.txt'
```

On vérifie que celui-ci a bien été transféré :

```
[18]: %remote_cmd ls -l
```

```
[18]: <IPython.core.display.HTML object>
```

Ensuite, on regarde le contenu du répertoire qui vous est associé sur le cluster :

```
[19]: %remote_cmd hdfs dfs -ls
```

```
[19]: <IPython.core.display.HTML object>
```

On supprime les précédentes exécutions :

```
[20]: %remote_cmd hdfs dfs -rm -f -R ConfLong*
```

```
[20]: <IPython.core.display.HTML object>
```

```
[21]: %remote_cmd hdfs dfs -ls
```

```
[21]: <IPython.core.display.HTML object>
```

Les commandes HDFS décrite à [Apache Hadoop 2.3.0](#). Elles sont très proches des commandes linux. Ensuite, on upload le fichier sur le système de fichier distribué du cluster (HDFS) :

```
[22]: %remote_cmd hdfs dfs -put ConfLongDemo_JSI.small.example.txt ./ConfLongDemo_JSI.small.  
→example.txt
```

```
[22]: <IPython.core.display.HTML object>
```

Puis on vérifie que le fichier a bien été uploadé sur le cluster :

```
[23]: %remote_cmd hdfs dfs -ls
```

```
[23]: <IPython.core.display.HTML object>
```

On regarde la fin du fichier sur le cluster :

```
[24]: %remote_cmd hdfs dfs -tail ConfLongDemo_JSI.small.example.txt
```

```
[24]: <IPython.core.display.HTML object>
```

Le fichier va suivre maintenant le chemin inverse. On le rapatrie depuis le cluster jusqu'à l'ordinateur local. Première étape : du cluster à la passerelle :

```
[25]: %remote_cmd hdfs dfs -get ConfLongDemo_JSI.small.example.txt ConfLongDemo_JSI.small.  
↳example.is_back.txt
```

```
[25]: <IPython.core.display.HTML object>
```

On vérifie que le fichier est sur la passerelle :

```
[26]: %remote_cmd ls -l
```

```
[26]: <IPython.core.display.HTML object>
```

On supprime le fichier de la précédente exécution :

```
[27]: import os  
if os.path.exists("ConfLongDemo_JSI.small.example.is_back_local.txt") :  
    os.remove("ConfLongDemo_JSI.small.example.is_back_local.txt")
```

```
[28]: [ _ for _ in os.listdir(".") if "txt" in _ ]
```

```
[28]: ['ConfLongDemo_JSI.small.txt', 'ConfLongDemo_JSI.txt']
```

Second transfert depuis la passerelle jusqu'à l'ordinateur local :

```
[29]: %remote_down ConfLongDemo_JSI.small.example.is_back.txt ConfLongDemo_JSI.small.example.  
↳is_back_local.txt
```

```
[29]: 'ConfLongDemo_JSI.small.example.is_back_local.txt'
```

```
[30]: [ _ for _ in os.listdir(".") if "txt" in _ ]
```

```
[30]: ['ConfLongDemo_JSI.small.example.is_back_local.txt',  
      'ConfLongDemo_JSI.small.txt',  
      'ConfLongDemo_JSI.txt']
```

```
[31]: %remote_close
```

```
[31]: True
```

1.4 Partie 2 : premier job map/reduce avec PIG

Pour cette partie, l'idée d'exécuter des jobs Map/Reduce sur le fichier ConfLongDemo_JSI.small.example.txt puis de vérifier qu'on obtient bien les même résultats sur le même fichier en utilisant une requête SQL. Le code pour créer la connexion à la passerelle est recopié ci-dessous mais il n'est pas nécessaire de l'exécuter si la connexion n'a pas été interrompue.

```
[32]: import pyensae
from pyquickhelper.ipythonhelper import open_html_form
open_html_form(params=params,title="server + credentials", key_save="params")
```

```
[32]: <IPython.core.display.HTML at 0x7bcf230>
```

```
[33]: password = params["password"]
server = params["server"]
username = params["username"]
```

```
[34]: ssh = %remote_open
ssh
```

```
[34]: <pyensae.remote.ssh_remote_connection.ASSHClient at 0xa499908>
```

JOB

Un job définit l'ensemble des traitements que vous souhaitez effectuer sur un ou plusieurs fichiers. Le langage **PIG** permet de décrire ces traitements. Le programme est ensuite interprété puis soumis à Hadoop qui s'occupe de répartir de traitements sur l'ensemble des ressources dont il dispose. La commande suivante permet d'obtenir l'ensemble des tâches associés aux jobs :

```
[35]: %remote_cmd mapred --help
```

```
[35]: <IPython.core.display.HTML object>
```

Et plus spécifiquement pour la commande `mapred job` :

```
Usage: CLI <command> <args>
      [-submit <job-file>]
      [-status <job-id>]
      [-counter <job-id> <group-name> <counter-name>]
      [-kill <job-id>]
      [-set-priority <job-id> <priority>]. Valid values for priorities are: VERY_HIGH HIGH NORMAL LOW VERY_LOW
      [-events <job-id> <from-event-> #<#-of-events>]
      [-history <jobHistoryFile>]
      [-list [all]]
      [-list-active-trackers]
      [-list-blacklisted-trackers]
      [-list-attempt-ids <job-id> <task-type> <task-state>]. Valid values for <task-type> are REDUCE MAP.
      [-kill-task <task-attempt-id>]
      [-fail-task <task-attempt-id>]
      [-logs <job-id> <task-attempt-id>]
```

D'autres commandes sont disponibles avec la commande `pig` :

```
[36]: %remote_cmd pig --help
```

```
[36]: <IPython.core.display.HTML object>
```

Le job suit le processus suivant :

- Le job est soumis à Hadoop.
- Il est ensuite placé dans une file d'attente avec une priorité qui détermine son ordre d'exécution (**queue**).
- Il est exécuté.

SELECT ... WHERE

```
[37]: import sqlite3
con = sqlite3.connect("ConfLongDemo_JSI.db3")

import pandas.io.sql as psql
sql = 'SELECT * FROM person_small WHERE activity == "walking"'
df = psql.read_sql(sql, con)
con.close()
df.tail()
```

```
[37]:      index sequence          tag      timestamp \
165     698      A01 010-000-030-096 633790226277429870
166     699      A01 020-000-032-221 633790226277970452
167     700      A01 010-000-024-033 633790226278240749
168     701      A01 020-000-033-111 633790226278781331
169     702      A01 020-000-032-221 633790226279051629

      dateformat      x      y      z activity
165 27.05.2009 14:03:47:743 2.965434 1.782434 0.228563 walking
166 27.05.2009 14:03:47:797 4.322405 1.571452 1.400499 walking
167 27.05.2009 14:03:47:823 3.133065 1.769329 -0.022590 walking
168 27.05.2009 14:03:47:877 3.121254 1.549842 1.048139 walking
169 27.05.2009 14:03:47:907 3.281498 1.498734 0.620412 walking
```

Avec [PIG \(syntaxe\)](#), le programme inclut trois étapes :

- la déclaration de l'entrée (le fichier ConfLongDemo_JSI.small.example.txt) (voir [LOAD](#))
- la tâche à proprement parler (voir [FILTER](#))
- la création de la sortie (le fichier ConfLongDemo_JSI.small.example.walking.txt) (voir [STORE](#))

La commande magique permet d'écrire un fichier select1.pig avec l'encoding utf-8 (les caractères accentués sont possibles).

```
[38]: %%PIG select1.pig

myinput = LOAD 'ConfLongDemo_JSI.small.example.txt' USING PigStorage(',') AS
(index:long, sequence, tag, timestamp:long, dateformat, x:double,y:double, z:
double, activity) ;
filt = FILTER myinput BY activity == "walking" ;

STORE filt INTO 'ConfLongDemo_JSI.small.example.walking_test.txt' USING PigStorage() ;
```

La commande suivante uploadé le script et vérifie sa syntaxe (commande `pig -check <jobname>`) :

```
[39]: %job_syntax select1.pig
```

```
[39]: <IPython.core.display.HTML object>
```

Les guillemets ne font pas partie de la syntaxe du langage :

```
[40]: %%PIG select2.pig

myinput = LOAD 'ConfLongDemo_JSI.small.example.txt'
using PigStorage(',')
AS (index:long, sequence, tag, timestamp:long, dateformat, x:double,y:
double, z:double, activity) ;
```

```

filt = FILTER myinput BY activity == 'walking' ;

STORE filt INTO 'ConfLongDemo_JSI.small.example2.walking_test20.txt' USING
→PigStorage() ;

```

La commande suivante fait deux choses : elle upload le job sur la passerelle et le soumet via la commande pig -execute -f <filename>. S'il n'y a pas d'erreur, il rejoint la file d'attente.

[41]: %pig_submit select2.pig -r None

[41]: <IPython.core.display.HTML object>

Derrrière cette command magique, il y a la fonction pig_submit.

[42]: help(ssh.pig_submit)

Help on method pig_submit in module pyensae.remote.ssh_remote_connection:

```

pig_submit(pig_file, dependencies=None, params=None,
redirection='redirection.pig', local=False, stop_on_failure=False, check=False,
no_exception=True, fLOG=<function noLOG at 0x000000000573E620>) method of
pyensae.remote.ssh_remote_connection.ASSHClient instance
    submits a PIG script, it first upload the script
    to the default folder and submit it

    @param      pig_file      pig script (local)
    @param      dependencies   others files to upload (still in the default
folder)
    @param      params        parameters to send to the job
    @param      redirection   string empty or not
    @param      local         local run or not (option `‐x local
<https://cwiki.apache.org/confluence/display/PIG/PigTutorial>`_) (in that case,
redirection will be empty)
    @param      stop_on_failure if True, add option `‐stop_on_failure` on the
command line
    @param      check         if True, add option `‐check` (in that case,
redirection will be empty)
    @param      no_exception  sent to @see me execute_command
    @param      fLOG          logging function
    @return

If *redirection* is not empty, the job is submitted but
the function returns after the standard output and error were
redirected to `‐redirection.out` and `‐redirection.err`.
```

The first file will contain the results of commands
`DESCRIBE <<http://pig.apache.org/docs/r0.14.0/test.html#describe>>`_
`DUMP <<http://pig.apache.org/docs/r0.14.0/test.html#dump>>`_,
`EXPLAIN <<http://pig.apache.org/docs/r0.14.0/test.html#explain>>`_.
The standard error receives logs and exceptions.

The function executes the command line::

```
pig -execute -f <filename>
```

With redirection::

```
    pig -execute -f <filename> 2> redirection.pig.err 1> redirection.pig.out
&
.. versionadded:: 1.1
```

On retrouve bien les mêmes résultats. Cependant, on n'a pas envie d'attendre la fin d'un job pour reprendre la main sur le notebook. Pour ce faire, on crée un second job.

[43]: %%PIG select3.pig

```
myinput = LOAD 'ConfLongDemo_JSI.small.example.txt'
    using PigStorage(',')
        AS (index:long, sequence, tag, timestamp:long, dateformat, x:double,y:
            double, z:double, activity) ;

filt = FILTER myinput BY activity == 'walking' ;

STORE filt INTO 'ConfLongDemo_JSI.small.example2.walking_test30_nowait.txt' USING
    PigStorage() ;
```

[44]: %pig_submit select3.pig

[44]: <IPython.core.display.HTML object>

[45]: %remote_cmd tail redirection.pig.err -n 15

[45]: <IPython.core.display.HTML object>

On vérifie le contenu du cluster :

[46]: %remote_cmd hdfs dfs -ls

[46]: <IPython.core.display.HTML object>

La sortie n'est pas un fichier mais un répertoire. Chaque partie provient d'une machine différente. Dans notre cas, les données étant de petite taille le calcul n'a pas été distribué.

[47]: %remote_cmd hdfs dfs -tail ConfLongDemo_JSI.small.example2.walking.txt/part-m-00000

[47]: <IPython.core.display.HTML object>

On retrouve bien les mêmes résultats. Cependant, on n'a pas envie d'attendre la fin d'un job pour reprendre la main sur le notebook. Pour ce faire, on crée un second job.

On regarde la liste des jobs en cours avec `hadoop queue` :

[48]: %remote_cmd hadoop queue -info root.xavierdupre -showJobs

[48]: <IPython.core.display.HTML object>

[49]: %remote_cmd hdfs dfs -ls ConfLongDemo_JSI.small.example2.walking_test30_nowait.txt

[49]: <IPython.core.display.HTML object>

C'est plus pratique mais la correction des erreurs quand elles se produisent n'est plus aussi pratique. On termine par une instruction qui permet de récupérer tous les fichiers d'un même répertoire en une seule fois :

```
[50]: %remote_cmd hdfs dfs -getmerge ConfLongDemo_JSI.small.example2.walking_test30_nowait.  
→txt toutenun.txt
```

```
[50]: <IPython.core.display.HTML object>
```

Le fichier est maintenant sur la passerelle.

```
[51]: %remote_cmd ls -l tout*
```

```
[51]: <IPython.core.display.HTML object>
```

Lorsqu'on lance des jobs conséquent, il est important de savoir comment les arrêter avec `hadoop job -kill jobid`:

```
[52]: %remote_cmd hadoop job -list all
```

```
[52]: <IPython.core.display.HTML object>
```

On peut tuer un job lorsqu'il est dans la file d'attente ou en train de s'exécuter.

```
[53]: #%remote_cmd hadoop job -kill job_1414491244634_0002
```

1.5 Partie 3 : syntaxe PIG et exercices

Dans cette partie, l'objectif est de transcrire un GROUP BY en PIG, un JOIN et de combiner toutes ces opérations en un seul job au cours du second exercice. Ces exemples utilisent de petits fichiers. Utiliser un job Map/Reduce n'a pas beaucoup d'intérêt à moins que la taille de ces fichiers n'atteigne un giga-octets. Les instructions sont à chercher dans cette page : [Pig Latin Basics](#).

1.5.1 Exercice 1 : GROUP BY

```
[54]: import pandas, sqlite3  
con = sqlite3.connect("ConfLongDemo_JSI.db3")  
df = pandas.read_sql("""SELECT activity, count(*) as nb FROM person GROUP BY  
→activity""", con)  
con.close()  
df.head()
```

```
[54]:      activity      nb  
0      falling    2973  
1      lying    54480  
2  lying down    6168  
3  on all fours    5210  
4      sitting   27244
```

Il faut maintenant le faire avec PIG.

```
[55]:
```

1.5.2 Exercice 2 : JOIN

```
[56]: con = sqlite3.connect("ConfLongDemo_JSI.db3")  
df = pandas.read_sql("""SELECT person.*, A.nb FROM person INNER JOIN (  
SELECT activity, count(*) as nb FROM person GROUP BY  
→activity) AS A  
ON person.activity == A.activity""", con)
```

```
con.close()  
df.head()
```

```
[56]:   index sequence          tag      timestamp  \\  
0       0      A01  010-000-024-033  633790226051280329  
1       1      A01  020-000-033-111  633790226051820913  
2       2      A01  020-000-032-221  633790226052091205  
3       3      A01  010-000-024-033  633790226052361498  
4       4      A01  010-000-030-096  633790226052631792  
  
        dateformat      x        y        z activity    nb  
0  27.05.2009 14:03:25:127  4.062931  1.892434  0.507425 walking  32710  
1  27.05.2009 14:03:25:183  4.291954  1.781140  1.344495 walking  32710  
2  27.05.2009 14:03:25:210  4.359101  1.826456  0.968821 walking  32710  
3  27.05.2009 14:03:25:237  4.087835  1.879999  0.466983 walking  32710  
4  27.05.2009 14:03:25:263  4.324462  2.072460  0.488065 walking  32710
```

Idem, maintenant il faut le faire avec PIG.

```
[57]:
```