
TP N° 1 : Introduction: Python, Numpy, Pandas, *et al.*

Pour ce TP de test de la plate-forme “Classgrade” vous devez déposer un **unique** fichier **anonymisé** (votre nom ne doit apparaître nulle part y compris dans son nom lui-même) sous format `ipynb` sur le site <http://peergrade.enst.fr/>. La partie rendu ne concerne que la partie 2 “ Introduction à Pandas, Matplotlib, etc.” Vous devez charger votre fichier, avant le mercredi 04/09/2017 23h59. Entre le jeudi 05/09/2017 et le dimanche 08/09/2017 octobre, 23h59, vous devrez noter trois copies qui vous seront assignées anonymement, en tenant compte du barème suivant pour chaque question :

- 0 (manquant/ non compris/ non fait/ insuffisant)
- 1 (passable/partiellement satisfaisant)
- 2 (bien)

Ensuite, il faudra également remplir de la même manière les points de notation suivants :

- aspect global de présentation : qualité de rédaction, d’orthographe, d’aspect de présentation, graphes, titres, etc. (Question 10).
- aspect global du code : indentation, Style PEP8, lisibilité du code, commentaires adaptés (Question 11)
- Point particulier : absence de bug sur votre machine (Question 12)

Des commentaires adaptés pourront être ajoutés question par question si vous en sentez le besoin ou l’utilité pour aider la personne notée à s’améliorer. Enfin, veillez à rester polis et courtois dans vos retours.

Rappel : aucun travail par mail accepté !

Quelques remarques avant de démarrer

On va utiliser `Jupyter notebook` durant cette séance. Pour cela choisissez la version Anaconda sur les machines de l’école. Quelques points importants à retenir :

- CHARGEMENTS DIVERS -

```
import math                # importe un package
import numpy as np         # importe un package sous un nom particulier
from sklearn import linear_model # importe tout un module
from os import mkdir       # importe une fonction
```

- UTILISATION DE L'AIDE -

```
help(mkdir)                # pour obtenir de l'aide sur mkdir
linear_model.LinearRegression? # pour obtenir de l'aide sur LinearRegression
```

- VERSIONS DE PACKAGE, LOCALISATION DES FONCTIONS -

```
print(np.__version__)      # obtenir la version d'un package
from inspect import getsourcelines # obtenir le code source de fonctions
getsourcelines(linear_model.LinearRegression)
```

Rem: Pour tous les traitements numériques on utilisera `numpy` (pour la gestion des matrices notamment) et `scipy`.

1 Introduction à Python, Numpy et Scipy

Il est bon de parcourir les documents suivants pour obtenir plus d'aide sur Python, pour ceux qui ne sont pas encore très familier avec ce langage :

http://perso.telecom-paristech.fr/~gramfort/liesse_python/1-Intro-Python.html

http://perso.telecom-paristech.fr/~gramfort/liesse_python/2-Numpy.html

http://perso.telecom-paristech.fr/~gramfort/liesse_python/3-Scipy.html

On pourra faire les questions associées :

- 1) Écrire une fonction `nextpower` qui calcule la première puissance de 2 supérieure ou égale à un nombre n (on veillera à ce que le type de sortie soit un `int`, tester cela avec `type` par exemple).
- 2) En partant du mot contenant toutes les lettres de l'alphabet, générer par une opération de *slicing* la chaîne de caractère `cfilorux` et, de deux façons différentes, la chaîne de caractère `vxz`.
- 3) Afficher le nombre π avec 9 décimales après la virgule.
- 4) Compter le nombre d'occurrences de chaque caractère dans la chaîne de caractères `s="HeLLo WorLd!!"`. On renverra un dictionnaire qui à chaque lettre associe son nombre d'occurrences.
- 5) Écrire une fonction de codage par inversion de lettres¹ : chaque lettre d'un mot est remplacée par une (et une seule) autre. On se servira de la fonction `shuffle` sur la chaîne de caractère contenant tout l'alphabet.
- 6) Calculer $2 \prod_{k=1}^{\infty} \frac{4k^2}{4k^2 - 1}$ efficacement. On pourra utiliser `time` (ou `%timeit`) pour déterminer la rapidité de votre méthode. Proposer une version avec et une version sans boucle (utilisant Numpy).
- 7) Créer une fonction `quicksort` qui trie une liste, en remplissant les éléments manquants dans le code suivant. On testera que la fonction est correcte sur l'exemple `quicksort([-2, 3, 5, 1, 3])` :

```
def quicksort(l1):
    """ a sorting algorithm with a pivot value"""
    if len(l1) <= 1:
        return l1
    else:
        TODO # pivot = last element of the list l1.
        less = []
        greater = []
        for x in l1:
            if x <= pivot:
                TODO # append 'x' to 'less'
            else:
                TODO # append 'x' to 'greater'
        return TODO # concatenate quicksort(less), pivot and quicksort(greater)
```

Indices : la longueur d'une liste est donnée par `len(l)` deux listes peuvent être concaténées avec `l1 + l2` et `l.pop()` retire le dernier élément d'une liste.

- 8) Sans utiliser de boucles `for` / `while` : créer une matrice $M \in \mathbb{R}^{5 \times 6}$ aléatoire à coefficients uniformes dans $[-1, 1]$, puis remplacer une colonne sur deux par sa valeur moins le double de la colonne suivante. Remplacer enfin les valeurs négatives par 0 en utilisant un masque binaire.
- 9) Créer une matrice $M \in \mathbb{R}^{5 \times 20}$ aléatoire à coefficients uniformes dans $[-1, 1]$. Tester que $G = M^T M$ est symétrique et que ses valeurs propres sont positives (on parle de alors de matrice définie positive). Quel est le rang de G ?

Aide : on utilisera par exemple `np.allclose`, `np.logical_not`, `np.all` pour les tests numériques.

1. aussi connu sous le nom de code de César.

2 Introduction à Pandas, Matplotlib, etc.

On pourra commencer par consulter le tutoriel (en anglais) :
<http://pandas.pydata.org/pandas-docs/stable/tutorials.html>

- CHARGER DES DONNÉES -

On utilise la base de données² **Individual household electric power consumption Data Set**.

1) Pour cela utiliser les commandes ci-dessous :

```
from os import path
import pandas as pd
import urllib
import zipfile
import sys

url = 'https://archive.ics.uci.edu/ml/machine-learning-databases/00235/'
filename = 'household_power_consumption'
zipfilename = filename + '.zip'
Location = url + zipfilename
# testing existence of file:
if sys.version_info >= (3, 0):
    if not(path.isfile('zipfilename')):
        urllib.request.urlretrieve(Location, zipfilename)
    else:
        if not(path.isfile('zipfilename')):
            urllib.urlretrieve(Location, zipfilename)
# unzip part
zip = zipfile.ZipFile(zipfilename)
zip.extractall()
na_values = ['?', '']
fields = ['Date', 'Time', 'Global_active_power']
df = pd.read_csv(filename + '.txt', sep=';', nrows=200000,
na_values=na_values, usecols=fields)
```

On ne s'intéresse dans un premier temps qu'à la grandeur `Global_active_power`.

- 1) Détecter et dénombrer le nombre de lignes ayant des valeurs manquantes.
- 2) Supprimer toutes les lignes avec des valeurs manquantes.
- 3) Utiliser `to_datetime` et `set_index` pour créer une **Time Series** (on prendra garde au format des dates internationales qui diffère du format français).
- 4) Afficher le graphique des moyennes journalières entre le 1er janvier et le 30 avril 2007. Proposer une cause expliquant la consommation fin février et début avril. On pourra utiliser en plus de `matplotlib` le package `seaborn` pour améliorer le rendu visuel.

On va maintenant ajouter des informations de température pour cette étude. Les données utilisées sont disponibles sur EOLE dans "TG_STAID011249.txt"³. Ici les températures relevées sont celles d'Orly (noter cependant qu'on ne connaît pas le lieux de relevé de la précédente base de données).

- 5) Charger les données avec `pandas`, et ne garder que les colonnes `DATE` et `TG`. Diviser par 10 la colonne `TG` pour obtenir des températures en degrés Celsius. Traiter les éléments de température aberrants comme des `NaN`.
- 6) Créer une **Time Series pandas** des températures journalières entre le 1er janvier et le 30 avril 2007. Afficher sur un même graphique ces températures et la **Time Series Global_active_power**.

2. <https://archive.ics.uci.edu/ml/datasets/Individual+household+electric+power+consumption>

3. on peut aussi trouver d'autres informations sur le site <http://eca.knmi.nl/dailydata/predefinedseries.php>

On considère maintenant le jeu de données `airparif_abae1bd78def4fe8a409ab8c95fc4608.zip` sur EOLE.

- 7) Proposer une visualisation de la pollution moyenne par année (pour l'ozone).
- 8) Proposer une visualisation de la pollution la plus critique par année.
- 9) Donner une représentation par mois de la pollution. Quel est le mois le plus pollué?

Pour aller plus loin

- <http://blog.yhat.com/posts/aggregating-and-plotting-time-series-in-python.html>
- <http://www.math.univ-toulouse.fr/~besse/Wikistat/pdf/st-tutor2-python-pandas.pdf>