Bases élémentaires de Python pour sciences humaines et sociales

Éric Guichard

2023–2024

Ce document est un « pense-bête » adapté à divers cours tenus à l'université de Lyon et destinés aux étudiants de culture dite « littéraire ». Il ne constitue pas à proprement parler une documentation pour `python`. Pour cela, vous pourrez consulter les sites `https://www.python.org` et `https://fr.scribd.com/document/356740978/courspython3-pdf`. Vous pouvez aussi profiter des exemples du manuel d'Emilien Schultz : `https://github.com/pyshs/exemples-manuel/tree/master`. Pour les graphiques, je conseille le site `https://courspython.com` de David Cassagne.

Attention Dans les *scripts* de ce document, il m'arrive souvent d'écrire ’ au lieu de '. Exemple : `a=’jour’`. Si vous les copiez, n'oubliez pas de remplacer l'apostrophe typographique par l'apostrophe simple : `a='jour'`. Sinon, votre programme ne fonctionnera pas.

1 Variables, listes, dictionnaires

Le « langage » `python` propose diverses catégories d'objets, résumées pour la pédagogie à 3 : les variables, les listes, les dictionnaires. Mieux vaut leur donner des noms explicites :

`mot="soleil"` est mieux que `x="soleil"`.

On peut dire, par métaphore, qu'une liste est une succession de variables et qu'un dictionnaire est un tableau indexé : une sorte de couple de listes, la première composée de *clés*, associées à des *valeurs* qui constituent la seconde liste.

Lien avec `perl`, langage pour lequel une variable commence par un `$`, une liste par une `@` et un *hash* (tableau indexé) par un `%`.

1.1 Variables

Une variable peut être du texte (une chaîne de caractères), un nombre (entier ou à virgule : « flottant »), une chose de type vrai/faux (« booléen », souvent apparenté à 1 / 0).

Un roman entier peut être inséré dans une variable, que l'on peut transformer en liste : par exemple de mots, délimités par la ponctuation. Exemples :

```
phrase="Il fait beau ce matin."
abbreviation-mois="03"
nombre=3
```

Une variable textuelle peut être prédéfinie en étant mise à vide : `phrase=""`. De même pour une variable numérique, mise à zéro : `nombre=0`.

1.2 Listes

Une liste mise à vide (initialisée) s'écrit `liste=[]`.

On peut définir une liste de façon exhaustive :

```
liste=[2,3,"le soir",18, "hier"].
```

Les éléments d'une liste sont numérotés à partir de zéro ; et ça « boucle » :
`print (liste[2])` donne `le soir`.
`print (liste[-1])` donne `hier`.

Toute liste a une longueur (ici 5) : `len(liste)`. Il s'ensuit que le dernier élément de la liste est `liste[len(liste)-1]`.

1.2.1 Auto-indexation de listes : `enumerate`

Un exemple valant mieux que de longs discours...

```
for index, element in enumerate(liste):
        print ("l'index auto de l'élément <",element,"> vaut",index)
```

Résultat :

```
l'index auto de l'élément < 2 > vaut 0
l'index auto de l'élément < 3 > vaut 1
l'index auto de l'élément < le soir > vaut 2
l'index auto de l'élément < 18 > vaut 3
l'index auto de l'élément < hier > vaut 4
```

La variable `index` est donc créée automatiquement et donne la valeur courante du rang de l'élément sur lequel on travaille.

Une autre façon de voir l'usage de cette fonction consiste à demander le résultat de `print (list(enumerate(liste)))`.

La machine répond : `[(0, 2), (1, 3), (2, 'le soir'), (3, 18), (4, 'hier')]`.

1.2.2 Listes inattendues

Les variables textuelles sont d'étranges listes (de caractères) à leur façon :
`phrase="Il fait beau ce matin."`
`print (phrase[3])` renvoie `f` (le 4e caractère).

Et donc `print (liste[-1][2])` renvoie `e`.

Étrangement, `print (phrase[3:5])` renvoie `fa` (2 éléments seulement : le 5e caractère est *exclu* : cf. point 2.1).

Ceci **ne fonctionne pas pour les (variables) nombres**, qui ne sont pas découpables en listes :
`a="123"`
`print (a[0])` renvoie `1`. Mais
`b=123`
`print (b[0])` renvoie `TypeError: 'int' object is not subscriptable`.

1.2.3 Compléter une liste

Ajouter un élément à une liste : avec la fonction `append`. Ex. :
`liste.append(18)`. Un `print (liste)` donne alors
`[2, 3, 'le soir', 18, 'hier', 18]`.

Attention : cet exemple prouve qu'une liste peut contenir plusieurs éléments identiques.

On pourra aisément produire des itérations à partir des éléments d'une liste et transformer une liste en variable.

1.2.4 Réduire une liste : `pop`

Enlever le 4e élément de notre liste (complétée) :

```
liste.pop(3)
print (liste)
```

On obtient : `[2, 3, 'le soir', 'hier',18]`

On peut aussi garder en mémoire l'élément enlevé :

```
a=liste.pop(0)
print ("liste: ",liste,"et la variable a vaut:",a)
```

Réponse :

```
liste:  [3, 'le soir', 'hier', 18] et la variable a vaut: 2
```

`pop(0)` est souvent utilisé pour enlever (et mémoriser) la première ligne d'un fichier de données (celle qui contient les noms des variables).

1.2.5 Fabriquer une liste à partir d'une variable : `split`

`split(sep)` coupe la variable en rondelles selon le séparateur `sep` (qui disparaît). Exemple banal : `a="le chat dort le soir au coin du feu"`

```
loste=a.split(" ")
print (loste)
```

donne

```
['le', 'chat', 'dort', 'le', 'soir', 'au', 'coin', 'du', 'feu']
```

Autre exemple, plus farfelu mais instructif

```
laste=a.split("o")
print (laste)
```

donnera

```
['le chat d', 'rt le s', 'ir au c', 'in du feu']
```

Cette commande est très utilisée, notamment avec les expressions régulières. Vous en trouverez divers usages dans cette documentation. Par exemple dans le programme de comptage de mots (point 8).

1.3 Dictionnaires ou tableaux

Un dictionnaire initialisé s'écrit `dict={}`.

Évidemment, toutes les clés d'un dictionnaire sont uniques.

Diverses manières de remplir un dictionnaire

```
dict={"abc":2, "bcd":3}
dict["abc"]=2
```

etc.

Expliciter le contenu d'un dictionnaire

```
for cle in dict.keys():
    print("à la clé", cle, " est associée la valeur ", dict[cle]))
```

Autre **façon** :

```
for cle, valeur in dict.items():
    print("à la clé", cle, " est associée la valeur ", valeur)
```

Récursivité La valeur d'une clé peut être une variable (cas précédents), une liste ou même un dictionnaire. Un dictionnaire est confortable quand on le produit soi-même. S'il est « donné » sans que sa structure soit explicitée (ce qui peut être le cas de certains fichiers `json` importés en tant que dictionnaires), la reconstitution de son squelette peut s'avérer complexe.

2 Boucles et conditions

Cas des `for`, `if`, `while`, etc.

Syntaxe générale :

```
ligne de la condition:
-- > (TAB)   actions si condition réalisée
```

En d'autres termes, la ligne du type `for`, `if`, `else`, `elif`, `while` se termine par deux points « : ». Les lignes des commandes correspondantes commencent par une **tabulation**.

2.1 Cas des listes ordonnées

`range(0,10)` contient dix nombres, de **0 à 9**. Le dernier (10) est donc **exclu**. Preuve-exemple :

```
liste=range(0,10)
for i in liste:
        print (i)
print ("Attention "+str(len(liste))+" n'est pas affiché")
```

Seront affichés `0, 1`, etc. jusqu'à `9` et la ligne `Attention 10 n'est pas affiché`.

2.2 Sorties de boucles ou conditions

On usera de 3 types d'instructions : `pass` (peu utile), `continue` (sortie temporaire) et `break` (sortie définitive).

Exemples

```
for i in liste:
        if i==3:
                break
        print (i)
```

Seront affichés : 0,1,2.

*

```
        if i==3:
                continue
        print (i)
```

Seront affichés : 0,1,2, puis 4, 5… 9.

*

```
for i in liste:
        if i %2==0: #si i divisé par 2 donne un reste nul
                print (str(i)+ " est pair")
        else:
                pass
```

Dans ce dernier cas, les lignes contenant `else` et `pass` sont en fait inutiles. Mais elles peuvent être confortables

— quand on n'est pas sûr de soi (pas de `if` sans `else`),
— si on veut remettre à plus tard les instructions du `else`.

2.3 Exemple : compter des objets

En `python`, on ne peut créer de tableaux (dictionnaires) à la volée comme en `perl` (même si la fonction `enumerate` a ses charmes, cf. point 1.2.1). Il faut donc initialiser leurs clés. Un cas fréquent consiste à compter tous les mots d'une liste et leurs fréquences.

Exemple : On suppose qu'on demande à des personnes leurs lieux de naissance, et on obtient la liste suivante.
`liste=[Paris,Lyon,Paris,Rouen,Bron,Lyon]`

Combien sont nées à Paris, etc. ? Voici une solution, qui sollicite les boucles et conditions.

```
liste=["Paris","Lyon","Paris","Rouen","Bron","Lyon"]
sommelieux={}
for v in liste:
        if v in sommelieux.keys(): # si on a déjà vu v
                sommelieux[v]+=1 #on ajoute 1 à sa valeur associée
        else:
                sommelieux[v]=1 # on crée la clé v et on lui associe 1
print (sommelieux)
```

Ce qui donne : `{'Paris': 2, 'Lyon': 2, 'Rouen': 1, 'Bron': 1}`

On peut remplacer la dernière ligne par celles-ci :

```
for i in sorted(sommelieux.keys()):
        print (sommelieux[i],"personne(s) sont nées à", i)
```

Résultat :

```
1 personne(s) sont nées à Bron
2 personne(s) sont nées à Lyon
2 personne(s) sont nées à Paris
1 personne(s) sont nées à Rouen
```

3 Lire un fichier, écrire dans un fichier

3.1 Écrire simplement

`monfic=open("carres.html", "w")` crée le fichier `carres.html` sur le disque dur (`"w"` pour *write*). Pour le programme, son nom sera `monfic`.

Pour y inscrire la variable `a`, il suffira d'écrire `monfic.write(a)`.

Pour écrire dans un fichier existant sans le supprimer, c'est-à-dire pour *compléter* ce fichier : choisir l'option `"a"` pour *append*.
Ex. : `monfic=open("carres.html", "a")`.

3.2 Lire simplement

Pour les fichiers courts et en mode *texte*, la méthode `read` peut fonctionner. Mais elle n'est pas optimale :
`monfic=open("unfichierbref", "r")`

```
leslignes = monfic.read()
print(leslignes)
```

Sinon, la solution la plus simple est d'utiliser une *library* (`csv.reader`, via un `import csv`), comme indiqué plus bas.

Note Il est aussi possible de lire des fichiers *formatés* par des logiciels externes (ex. : XL ou LibreOffice) avec d'autres bibliothèques (ex. : `openpyxl` ou `pandas`).

3.3 Exemple de lecture avec `csv.reader`

On gagne la suppression des sauts de ligne et une lecture « automatisée ».

Soit un fichier `cercles` qui a l'allure suivante :

X	Y	R
10	90	5
30	60	10
60	80	15

On veut récupérer les coordonnées X, Y des centres (on oublie les rayons). La 5e ligne présente un usage de `pop(0)` (cf. point 1.2.4).

```
import csv
nomInterneDuFichier = csv.reader(
open("cercles", 'r', encoding='UTF-8'), delimiter='\t')
totaldeslignes = list(nomInterneDuFichier)
totaldeslignes.pop(0) # si vous ne voulez pas de la 1re ligne

for lignecourante in totaldeslignes:
        print (lignecourante)
        coord1,coord2,rien=lignecourante #grâce au délimiteur \t
        #la variable inutile (rien) est indispensable...
        #autre solution: coord1=lignecourante[0], etc.
        print (coord2) #à compléter...
```

3.4 Exemple de lecture sans `csv.reader`

C'est à vous de « découper » explicitement la ligne courante en variables avec la commande `split` (Cf. point 1.2.5). Reprise du même exemple.

```
nomInterneDuFichier = open("cercles", 'r', encoding='UTF-8')
sommelignes = list(nomInterneDuFichier)
for lignecourante in sommelignes:
        print (lignecourante)
        coord1,coord2,rien=lignecourante.split('\t')
        print (coord2,rien)
```

Piège `python` a besoin du nombre exact de variables créées par le séparateur pour lire correctement une ligne. D'où la sollicitation de la variable `rien`, au nom explicite. Une solution consiste à mettre tout ce qui ne nous intéresse pas dans une liste, qui absorbera en vrac tous les objets restants :

```
listerien=[] #on définit cette liste
for... :
        x,y,listerien=lignecourante.split('\t')
```

Sagesse : fermer un fichier Quand le fichier nommé (par exemple) `monfic` dans le programme n'est plus utilisé, un `monfic.close()` est fortement conseillé.

3.5 Lire une série de fichiers

Faire usage de la *library* `os` : *operating system*. Exemple

```
import os
os.chdir("1erTourbis") # on va dans ce dossier
print(os.listdir()) #affiche de son contenu
for fichier in os.listdir(): #pour chaque fichier
        if fichier.endswith("TRUC"):
                ...
                with open(fichier, "r",encoding='utf8') as circons:
                        lignes=list(circons)
                        for chaqueligne in lignes:
                                ...
```

4 Commentaires, variables et caractères bizarres, etc.

4.1 Apostrophes et guillemets

En anglais : *single and double quotes* : ' et ".

Absence de différences Une variable texte peut indifféremment être détaillée entre guillemets ou entre apostrophes :

`a="bonjour"` ou `a='bonjour'`

Remarque J'aurais dû écrire `a='bonjour'` mais cela me prend beaucoup plus de temps. D'où la mention « Attention » évoquée au début du document.

Dans la pratique, on essaie d'utiliser le délimiteur qui est le moins utilisé.

Si j'écris `a='aujourd'hui'`, j'induis une erreur : il y a 3 apostrophes. Je préfèrerai alors écrire `a="aujourd'hui"`.

Une autre solution consiste à *protéger* l'apostrophe du mot :

`a='aujourd\'hui'`

Par exemple, si j'ai besoin d'insérer dans une variable l'expression
`<svg xmlns="http://www.w3.org/2000/svg" xmlns:xlink="http://www.w3.org/1999/xlink"`
j'écrirai `a='<svg xmlns="http...xlink"` 'car il n'y a pas d'apostrophes dans cette expression pleine de guillemets.

4.2 Cas des variables avec plusieurs lignes

Deux solutions :
— avec des sauts de ligne encodés : `a='première ligne\nseconde ligne'` ou `a="première ligne\nseconde l`

— en utilisant 3 guillemets : `a="""un paragraphe séparé`
`par de banals`
`retours chariots"""`
produit le résultat escompté. Cette solution fonctionne aussi avec 3 apostrophes.

Note Perl n'aurait pas eu le même comportement : ce dernier langage interprète ce qui est entre guillemets, mais pas ce qui est entre apostrophes : dans le premier cas `\n` produit un saut de ligne, dans le second, il produit un `\` suivi d'un `n`.

Longs commentaires Comme python ne tient pas compte des formes textuelles non assignées à une variable, tout paragraphe entre 3 apostrophes ou guillemets sera pris comme un commentaire (détournement fréquent) :

```
''' Ici
un long
commentaire'''
```

4.3 Additions et surprenantes concaténations

Selon les contextes, le signe `+` symbolise l'addition entre deux nombres ou la concaténation de deux chaînes de caractères. Exemple.

```
mot="bonjour"
nombre=23
print (mot+mot, nombre+nombre)

Réponse: bonjourbonjour 46
```

Si j'écris `a="bonjour"` et `b=" à tous"` un `print (a+b)` donnera donc `bonjour à tous`.

Mais si j'écris `c=2`, un `print (a+b+" "+c)` me renverra un message d'erreur, alors que si j'avais écrit `c="2"`, j'aurais obtenu comme imaginé `bonjour à tous 2`.

Il faut convertir `c` en chaîne de caractères pour l'intégrer en une autre (`string`) : `print (a+b+" "+str(c))`

4.4 D'une chaîne à un nombre

L'inverse peut se produire quand on lit une série dans un fichier : ce qu'on croit être un nombre `n` pourra être pris pour un caractère et on ne pourra alors pas l'utiliser pour des calculs.

En ce cas, la fonction (pour une conversion en entier) est `int()`. Ex. : `int(n)`. Pour une conversion en nombre banal (décimal) : `float(n)`. Pour s'y retrouver, la fonction `type` précise le type de la chose manipulée :

`print (type(a))` donne `<class 'str'>`

`print (type(c))` donne `<class 'int'>`

`print (type(2.5))` donne `<class 'float'>`

`liiiste=[2,5]` suivi d'un `print (type(liiiste))` donne `<class 'list'>`.

4.5 Extrapolation

Soit la série d'instructions suivantes, séparées par des lignes.

`e="2" f=5 g="." h=e+g+str(f) print (h) i=float(h)`

Un `print (type(i/2))` donnera `<class 'float'>`. Ouf !

5 Formatage de nombres et commande `format`

Cf. `https://courspython.com/print-format.html?highlight=format` et `https://python.sdv.univ-paris-diderot.fr/03_affichage`.

5.1 Usage des chaînes formatées : *fstring*

Il s'agit en général d'obtenir des expressions simplifiées ou homogènes de valeurs numériques. Exemple, déclinable de façons très variées :

```
a=2
b=3.1278
print(f"a vaut {a:.2f} et b vaut {b:.2f} ")
```

Résultat : `a vaut 2.00 et b vaut 3.13`

Ce formatage est indépendant de la fonction `print` :
`c=f"{b:.2f}"` # ne pas oublier les guillemets !
`print (c)` donnera `3.13`.

5.2 la fonction `format`

5.2.1 Exemple simplissime

```
print ("x vaut {}, y vaut {} et z vaut {}".format('2','3','4'));
```

Donne comme résultat
`x vaut 2, y vaut 3 et z vaut 4`.

Très utile pour le svg...

5.2.2 Second exemple

```
stock = ['papier', 'carton', 'chemise', 'encre']
print("Nous avons de l'{} et du {} en stock\n".format(stock[3],stock[0]))
#autre solution, moins lisible:
print("Nous avons de l'{0[3]} et du {0[0]} en stock\n".format(stock))
```

6 Nettoyages textuels, expressions régulières

6.1 Premiers nettoyages

6.1.1 `replace`

La fonction `replace` est fort confortable. Exemple, sachant qu'`\n` est un saut de ligne :

```
phrase="Il fait beau\nce matin"
phrase=phrase.replace('\n'," ")
print (phrase)
```

Résultat : `Il fait beau ce matin`.

6.1.2 `strip`

`strip` est utile quand il s'agit de travailler sur des objets comme des noms de fichiers qu'on veut débarrasser des espaces (␣) qui parfois les enveloppent. Ex. :
`a="␣fichier␣␣"`
`a=a.strip()`
`print ("T"+a+"T")` renvoie `TfichierT`.

Paramètres complémentaires :

`strip('liste de caractères bordants à enlever')` Ces caractères peuvent être dans le désordre mais tous doivent être présents (y compris l'espace au besoin).

Attention `strip` enlève les *whitespaces*, souvent traduits par « espaces » en français. En fait, un *whitespace* est un caractère blanc, donc : une ou plusieurs espaces ␣, une tabulation ou un saut de ligne.

En bref, pour un `a="Essai␣␣ \n"` (des espaces, des tabulations et un saut de ligne à droite), `a.strip()` renverra un `Essai` tout court.

Seconde remarque La gestion des espaces (et des sauts de ligne) par `python` peut s'avérer désarçonnante. Par exemple, `print ("XXX","YYY")` affiche un `XXX YYY` (introduction d'une espace).

6.1.3 Commence ou finit par...

Les commandes `endswith` et `startswith` sont simples et utiles.

```
a="coucou"
if a.endswith("u"):
    print (a)
```

6.2 Vers les expressions régulières

6.2.1 Citation

Source : `https://docs.python.org/3/howto/regex.html#match-versus-search`, fin de page.

> Le livre le plus complet sur les expressions régulières est certainement *Mastering Regular Expressions* de Jeffrey Friedl, publié par O'Reilly. Malheureusement, il se concentre exclusivement sur les expressions régulières de Perl et de Java, et ne contient aucune information sur Python, de sorte qu'il ne sera pas utile en tant que référence pour la programmation en Python. (La première édition couvrait le module regex de Python, aujourd'hui supprimé, ce qui ne vous aidera pas beaucoup). Pensez à le consulter dans votre bibliothèque.

Ne soyez donc pas trop optimistes...

6.2.2 Substitution

Vous aurez besoin de la bibliothèque `re` (*regular expression*, expression rationnelle). Exemple simple :

```
import re
a="bonjour"
```

```
b=re.sub("jou","soi",a)
print (b)
```

Renverra `bonsoir`

6.2.3 Expression rationnelle

Exemple plus efficace, avec une première expression rationnelle, qui élimine la ponctuation dans une phrase ou un texte (par exemple pour compter des mots). En fait, les caractères cités (éventuellement protégés) sont remplacés par des espaces.

```
import re
lignecourante="Le terme « poésie » et ses dérivés « poète »,
« poème » viennent du grec ancien (poiesis)"
lignesimple=re.sub('[ \.,«»()\']+', ' ', lignecourante)
print (lignesimple)
```

Réponse : `Le terme poésie et ses dérivés poète poème viennent du grec ancien poiesis`.

7 Rudiments graphiques

Les exemples suivants donnent une idée des possibilités de `matplotlib`.

7.1 Listes de nombres

C'est le cas le plus simple. On veut représenter une série de points de coordonnées (x, y). On fabrique alors la liste des x, notée ici `abscisses`, et celle des y, notée ici `ordonnees`. Le graphique 1 page 16 est ainsi construit. Syntaxe, suivie d'un exemple simple.

```
import matplotlib.pyplot as plt
plt.plot(abscisses, ordonnees)
plt.show() # ne pas oublier!
```

```
import matplotlib.pyplot as plt
abscisses=range(0,5)
freq = [25, 12, 49, 14, 32]
plt.plot(abscisses, freq)
plt.show()
```

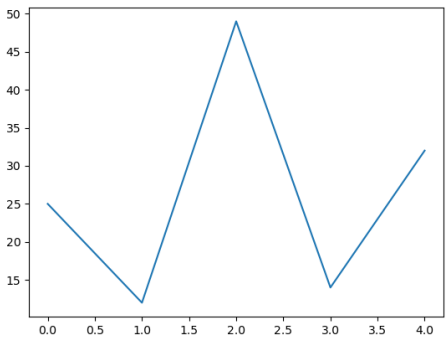

Pour mieux voir les hauteurs exactes des points, on peut demander (avec la même logique : `plt.plot`) à visualiser les axes :

```
import matplotlib.pyplot as plt
abscisses=range(0,5)
freq = [25, 12, 49, 14,32]
plt.plot(abscisses, freq)
plt.plot((0, 0), (-2, 50), 'r--') #vertical
plt.plot((0, 4), (0, 0), 'r--')
plt.show()
```

On obtient alors le graphique

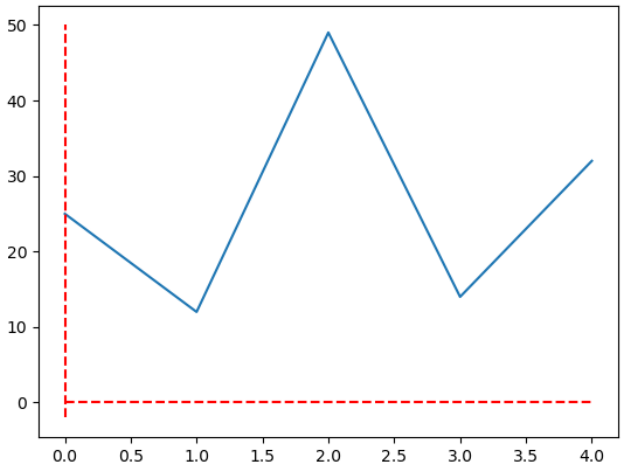

7.2 Histogrammes

Il suffit de remplacer `plot` par `bar`.

```
...
plt.bar(abscisses, freq)
plt.show()
```

Ce qui donne :

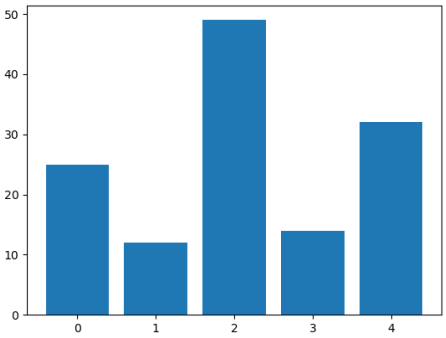

Cette méthode fonctionne aussi quand il s'agit de décrire des catégories non numériques (histogrammes généraux). On peut évidemment jouer à l'infini sur la présentation (titres, couleur, etc.).

```
import matplotlib.pyplot as plt
mots= ['abbé', 'ailleurs', 'après', 'argent','assez']
freq = [25, 12, 49, 14,32]
plt.bar(mots, freq,color='darkblue') #ou plot
plt.plot(mots, freq,"o-", label='Fréquence',color='red')
plt.title("Fréquence de quelques mots dans Candide")
plt.show()
```

Voici le résultat (deux représentations différentes pour les mêmes données) :

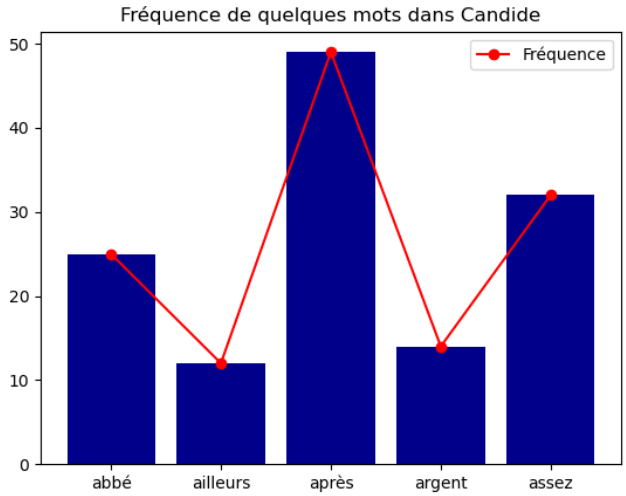

Le point 9 permettra d'approfondir la question des graphiques multiples.

7.3 Graphes de fonctions

C'est assez simple. Exemple.

```
import matplotlib.pyplot as plt
import numpy as np

x = np.linspace(0.1, 2, 30)
#fabrique une liste de 30 éléments entre 0.1 et 2
y1 = np.sqrt(x) #racine de x
y2 = np.log(x)  #log de x

plt.plot(x, y1, label="racine carrée de x")
plt.plot(x, y2, label="logarithme de x")

plt.plot((0, 0), (-2, 2), 'r--') #repérage axes
plt.plot((-1, 2), (0, 0), 'r--')
plt.legend()
plt.show()
```

Ce qui donne :

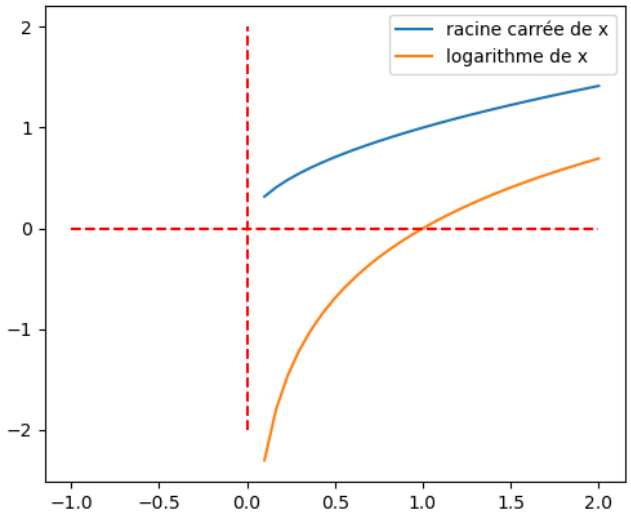

8 Un programme de comptage de mots : `Zipf.py`

Un programme à lancer et à commenter. Attention les indentations sont peut-être imparfaites.

8.1 Comptage des mots d'un texte

```
import re
fichier=open("PoesieWP", "r")
leslignes = list(fichier)
totalmots={}
for lignecourante in leslignes:
    print (lignecourante)
    lignesimple=re.sub('[ \.,«»()\']+', ' ', lignecourante)
    mots=lignesimple.split(" ")
    for m in mots:
        if m in totalmots:
            print ("déjà vu")
            totalmots[m]=1+totalmots[m]
        else:
            print ("nouveau")
            totalmots[m]=1
        print (m)

for i in totalmots:
    if totalmots[i]>2:
        print (i, " apparaît ",totalmots[i]," fois")

print (sorted(totalmots.keys(),key=str.lower))
print (sorted(totalmots.values(),reverse=True))
print (totalmots.items())
```

8.2 Final : visualisation de la loi de Zipf

Le fichier `CandideFr.txt` est le « Candide » de Voltaire, dans sa version `https://www.gutenberg.org`. Vous pouvez le remplacer par un autre fichier.

```
import re
import math
import matplotlib.pyplot as plt
import numpy as np

fichier= open('CandideFr.txt', "r",encoding='utf8')
fresu= open('DicoCandideFr', "w",encoding='utf8')

leslignes = list(fichier)
totalmots={}
totalhapax=0
leslogs=[]
abscisses=[]
lesinfos=""

for lignecourante in leslignes:
    print (lignecourante)
    lignesimple=re.sub('[ \.,«»()\'!-\?;\n\t]+', ' ', lignecourante)
    mots=lignesimple.split(" ")
    for m in mots:
        m=m.lower()
        if len(m)==0:
            continue
        if m in totalmots:
            totalmots[m]=1+totalmots[m]
        else:
            print ("nouveau")
            totalmots[m]=1
            print (m)
#Fin calculs

for i in totalmots:
    if totalmots[i]>1:
        leslogs.append(math.log(totalmots[i]))
    else:
        totalhapax+=1

lesinfos+="nb d'hapax: "+str(totalhapax)+"\n"
lesinfos+="nb mots différents: "+str(len(totalmots))+"\n"

print (sorted(totalmots.keys()))
print (sorted(totalmots.values(),reverse=True))

for m in sorted(totalmots.keys()):
    ligne=m+"\t"+str(totalmots[m])+"\n"
    fresu.write(ligne)

fresu.write("\n\nLes infos\n")
fresu.write(lesinfos)
fresu.close

leslogs=sorted(leslogs,reverse=True)

for i in range (1,len(leslogs)+1):
    j=math.log(i)
    abscisses.append(j)

plt.plot(abscisses, leslogs)
#La suite est étrangement indispensable:
plt.show()
#Attention, le graphique peut masquer la fin de l'écriture de fresu
```

```
exit()
```

8.3 Graphique de la loi de puissance : fig. 1

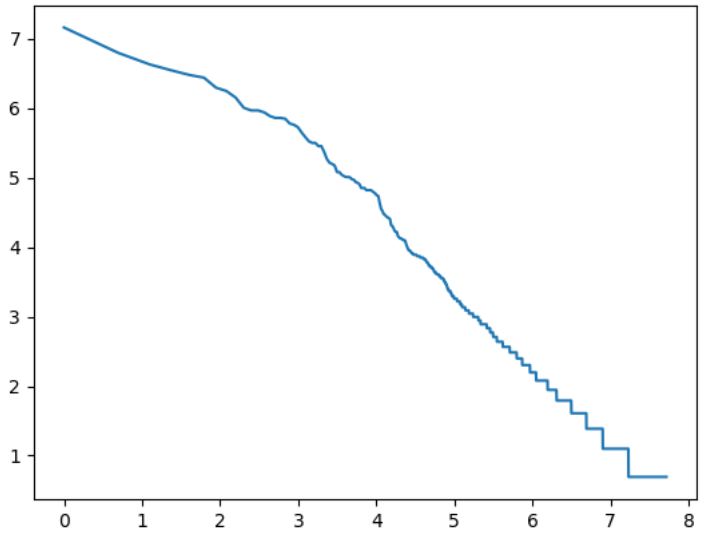

Figure 1 – Loi de Zipf. On remarque l'allure linéaire de pente environ -1 du graphique *log-log* du couple *rang-fréquence* des mots.

9 Statistiques élémentaires

On se place ici dans le registre des enquêtes avec variables qualitatives, et donc des fichiers (texte) ayant cette allure :

```
Nom         Variable1         Variable2
Dupont         H                 bleu
Durand         F                 vert
Dubois         H                 orange...
```

Il s'agit alors de décrire sommairement les variables (pourcentages, histogrammes, etc.), de les croiser, de vérifier si elles sont indépendantes : test du χ^2 (*chi-square*), comparaison (graphique) de profils, etc. : le b-a-ba du traitement d'enquête pour historiens ou sociologues.

9.1 Tris à plat « à la main »

La plupart des opérations peuvent se réaliser avec les méthodes précédentes. Par exemple, pour produire l'histogramme d'une variable, il suffit

— d'ouvrir le fichier (avec `csv.reader` s'il est tabulé, cf. pt 3.3),
— de transformer la colonne de la variable en liste (cf. pt 1.2.3),
— de compter les éléments de cette liste (*via* un dictionnaire, cf. pt 2.3),
— puis de réaliser l'histogramme de ses clés et valeurs (point 7.2).

9.2 Tris à plat avec pandas

Reconnaissons que les bibliothèques de python permettent d'aller vite, et notamment `pandas`. Pour cette documentation élémentaire, nous considérons que `pandas` fabrique et manipule essentiellement des tableaux de données (*dataframes*) et des séries, même si cette *library* fait bien plus que cela.

```
import pandas as pd
data = pd.read_csv('Votrefichier.csv')
modalites=data["Variable1"].value_counts()
modalitesENpc=data["Variable1"].value_counts(normalize=True)
print (modalites, modalitesENpc)
```

Donnera comme réponse (exemple tiré d'un fichier pédagogique) : les femmes sont 2685 et représentant 54% des individus de notre fichier.

```
Variable1
F    2685
H    2243
Name: count, dtype: int64 Variable1
F    0.544846
H    0.455154
Name: proportion, dtype: float64
```

Dans le script, `data` est un *dataframe* et `modalitesENpc` une série. Une série est une (sorte de) liste caractérisées par son *index* et son *array*, ce qui la rend proche d'un dictionnaire. En l'occurrence, `print (modalitesENpc.index)` donnera un
`Index(['F', 'H'], dtype='object', name='Variable1')` et un
`print (modalitesENpc.array)` produira un
`<PandasArray> [0.5448457792207793, 0.4551542207792208]...`.

Il s'ensuit qu'un `plt.bar(modalitesENpc.index,modalitesENpc.array)` produira l'histogramme de notre variable (cf. point 7.2). `array` peut être remplacé par `values` mais non par `values()` (différence entre attributs et méthodes) : `plt.bar(modalitesENpc.index,modalitesENpc.values)` fonctionne aussi bien. Récapitulatif :

```
import pandas as pd
import matplotlib.pyplot as plt
data = pd.read_csv('Votrefichier.csv')
modalitesENpc=data["Variable1"].value_counts(normalize=True)
plt.bar(modalitesENpc.index,modalitesENpc.array)
plt.show()
```

Ce script produit en 6 lignes le calcul et le graphique de l'histogramme :

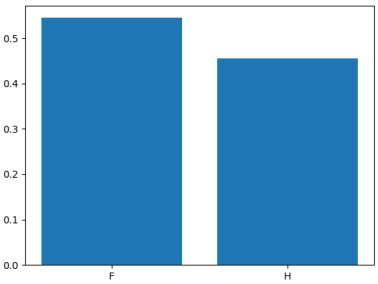

Note sur les csv `csv` signifie souvent que la virgule sert de séparateur de colonne. Si votre séparateur est autre, par exemple une tabulation (notée `\t`), il vous faudra le préciser dans le script :
`data = pd.read_csv('Votrefichier.csv',delimiter="\t")`

9.3 Tableaux croisés

Il est aussi aisé de les produire. L'option `normalize` ramène ces tableaux à l'état de pourcentages en colonnes (le total de chaque colonne vaut 100% : `normalize='columns'`) ou en ligne (le total de chaque ligne vaut 100% : `normalize='index'`). On parle alors (respectivement) de profils colonnes et de profils lignes.

```
import pandas as pd
data = pd.read_csv('Votrefichier.csv')
tableau_croise = pd.crosstab(data['Variable2'], data['Variable1'])
tableau_pcc = pd.crosstab(data['Variable2'], data['Variable1'],normalize='columns')
tableau_pcl = pd.crosstab(data['Variable2'], data['Variable1'],normalize='index')
```

Résultat (après un `print(...)`), toujours tiré d'un fichier à fonction pédagogique, où la variable `Variable2` a 3 modalités : `1Xj`, `qqX` et `ssobj`.

Tableau des effectifs ↓

```
Variable1            F     H
Variable2
1Xj            631   676
qqX            507   432
ssobj         1547  1135
```

Profils colonnes↓

```
Variable1                F         H
Variable2
1Xj           0.235009  0.301382
qqX           0.188827  0.192599
ssobj         0.576164  0.506019
```

Profils lignes ↓

```
Variable1                F         H
Variable2
1Xj           0.482785  0.517215
qqX           0.539936  0.460064
ssobj         0.576808  0.423192
```

9.3.1 Graphiques des profils

Diverses solutions existent, parmi lesquelles la suivante :

Les lignes de nos tableaux s'obtiennent par leur identifiant, qui les *localisent*. Par exemple, `tableau_pcl.loc['1Xj']` donne

```
Variable1
F    0.482785
H    0.517215
```

Ce qui correspond bien au profil ligne de la modalité `1Xj`, même si on est surpris qu'il apparaisse comme une colonne. On obtient de même le profil des deux autres modalités. On peut alors les comparer graphiquement, comme on l'a déjà fait.

Il ne nous manque plus que la légende (H, F). En fait, ce sont les indicateurs des colonnes. Nous pouvons alors tenter un

`print(tableau_pcl.columns)`, qui nous donnera un `Index(['F', 'H'],...`.

Il nous suffit de reprendre la logique de la section 7.1, qui nous proposait d'oser un `plt.plot(abscisses, ordonnees)`. Or nous avons désormais ces deux listes d'abscisses et d'ordonnées :

```
plt.plot(tableau_pcl.columns, tableau_pcl.loc['1Xj'])
```

Il est alors aisé de comparer graphiquement les 3 profils lignes :

```
import pandas as pd
import matplotlib.pyplot as plt
data = pd.read_csv('Votrefichier.csv')

tableau_pcl = pd.crosstab(data['Variable2'], data['Variable1'],
normalize='index')

plt.plot(tableau_pcl.columns, tableau_pcl.loc["1Xj"],label="1Xj")
plt.plot(tableau_pcl.columns, tableau_pcl.loc["qqX"],label="qqX")
plt.plot(tableau_pcl.columns, tableau_pcl.loc["ssobj"],label="ssobj")

plt.legend()
plt.show()
```

On comprendra à l'usage pourquoi ce type d'histogramme est plus lisible qu'un banal histogramme en bâtons :

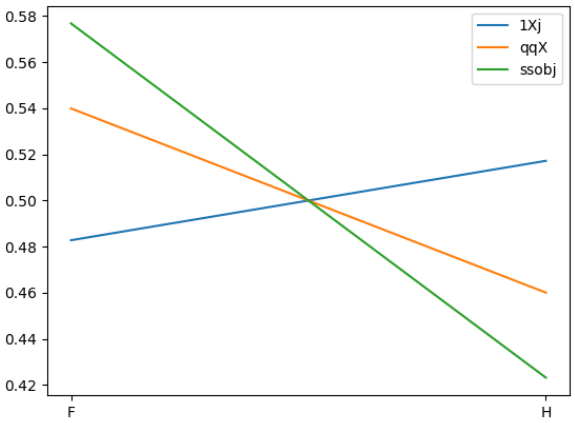

En première conclusion, nous voyons que nos variables ne sont pas indépendantes : sinon les droites (les profils) auraient la même allure (et mêmes pentes). Nous confirmerons cela au point 9.3.2 avec le test du χ^2 (Khi-2).

En seconde conclusion, nous pouvons vérifier notre intuition en considérant les profils des colonnes, afin de vérifier si les pratiques des femmes et des hommes diffèrent ou non. C'est plus simple que les pratiques des personnes `1Xj` !

Nous avons la légende : non pas `tableau_pcl.index`, mais `tableau_pcc.index` (pour les colonnes) ! Reste les colonnes des variables. Une façon rapide est de transposer le tableau et de faire le travail sur les lignes qu'on vient de faire (`tableau_pcl.T`). Une autres est d'inverser les deux variables. et la troisième est la suivante : attraper les colonnnes par leur index (leur nom) : `tableau_pcc[["F"]]`.

Il s'ensuit qu'un `plt.plot(tableau_pcc.index, tableau_pcc[["F"]]` fera l'affaire. Et le complément suivant

```
plt.plot(tableau_pcc.index, tableau_pcc[["F"]],label="Femmes")
plt.plot(tableau_pcc.index, tableau_pcc[["H"]],label="Hommes")
```

produira ce graphique. Les différences de profil ne sont pas excessives.

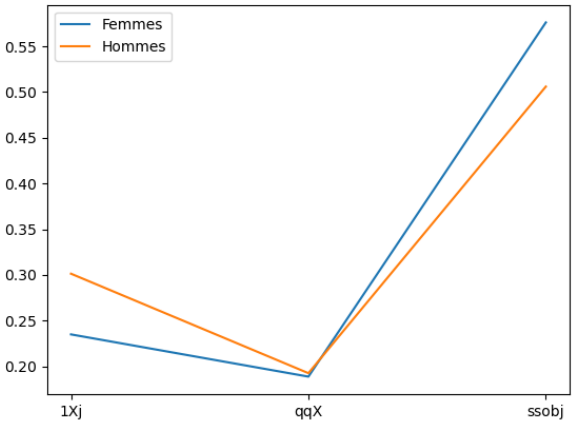

9.3.2 Test d'indépendance

Pour rester dans un cadre très général (le test du χ^2 ne s'explique pas en 30 secondes), nous dirons que l'appel `chi2_contingency(tableau_croise)` produit un ensemble de résultats dont les premiers sont

— la valeur du χ^2 total du tableau,
— la probabilité (souvent faible) qu'il ait cette valeur sous hypothèse d'indépendance,
— le nombre de degrés de liberté
— et d'autres choses, qui commencent par `array` : le tableau des valeurs théoriques.

Si la probabilité est inférieure à $0,05$, on rejette « l'hypothèse d'indépendance » : il y a dépendance entre les deux variables. Exemple.

```
import pandas as pd
from scipy.stats import chi2_contingency
data = pd.read_csv('Votrefichier.csv')
tableau_croise = pd.crosstab(data['Variable2'], data['Variable1'])

print(chi2_contingency(tableau_croise))

print ("Khi-2 total:",chi2_contingency(tableau_croise)[0])
print ("Degrés de liberté:",chi2_contingency(tableau_croise)[2])
print ("On rejette l'hyp d'ind si ce nombre est inférieur à 0,05:",
chi2_contingency(tableau_croise)[1])
```

Et on lit, successivement, la valeur de `chi2_contingency(tableau_croise)` :

```
(31.439092345248675, 1.4896623422462532e-07, 2,
array([[ 712.11343344,  594.88656656],
       [ 511.61018669,  427.38981331],
       [1461.27637987, 1220.72362013]]))
```

Et les 3 réponses à nos questions (`print ("Khi-2 total, ...`) :

```
Khi-2 total: 31.439092345248675
On rejette l'hyp d'ind si ce nombre est inférieur à 0,05:
 1.4896623422462532e-07
Degrés de liberté: 2
```

Comme $1.489 * 10^{-7}$ est bien plus petit que 0.05, on rejette sans souci l'hypothèse d'indépendance.

Attention Il faut faire le calcul sur le **tableau des effectifs** et non sur l'un des tableaux de profils lignes ou colonnes.

10 Installations, usages

10.1 Installations et précautions

Cette section aurait peut-être dû apparaître au début. Mais comme elle est peu appétissante, elle a été rétrogradée ici. Elle sera prochainement complétée et elle évoquera pip, VSC, les *notebooks* comme `jupyter`, les comportements variables de python selon les OS et les environnements, etc. Idées :

Il faut tout d'abord installer `pip` (le gestionnaire de paquets pour Python) : `https://www.odoo.com/fr_FR/forum/aide-1/how-to-install-pip-in-python-3-on-ubuntu-18-04-167715`.

Cela peut se faire dans un terminal avec les commandes `sudo apt update`, puis `sudo apt install python3-pip` (`sudo` pour effectuer ces commandes en tant que super-utilisateur : *root*).

Ensuite on sollicite `pip` pour installer la bibliothèque de son choix. Exemple, pour *Beautiful Soup* : `pip install beautifulsoup4`.

10.2 Usages

`Python` est un langage orienté objet. Sous ses allures de simplicité, il sollicite des concepts assez délicats et reste destiné aux personnes qui possèdent une culture théorique en informatique et aussi en mathématiques, comme on l'a vu avec le test du χ^2 : *grosso modo* des ingénieurs. Il est à la mode, mais `perl` reste un « langage de programmation » très accessible et très efficace pour les personnes de culture littéraire.

Table des matières