



TD15

COMMANDES PANDAS ET COUPLES DE VARIABLES DISCRÈTES.

EXERCICE 1

Supposons que vous soyez le chef de direction d'une camions ambulants (*Food Trucks*). Vous envisagez différentes villes pour ouvrir un nouveau point de vente. La chaîne a déjà des camions dans différentes villes et vous avez des données pour les bénéfices et les populations des villes. Vous souhaitez utiliser ces données pour vous aider à choisir votre nouvelle implantation.

On dispose d'un fichier `data.csv` et on utilise la bibliothèque `pandas`.

1. On exécute les instructions suivantes qui donnent l'affichage ci-après. Que contient le fichier `data.csv` importé ?

```
1 import pandas as pd
2 import numpy as np
3 import numpy.random as rd
4 import matplotlib.pyplot as plt
5
6 donnees = pd.csv_read('data.csv', sep=';')
7
8 donnees.head()
```

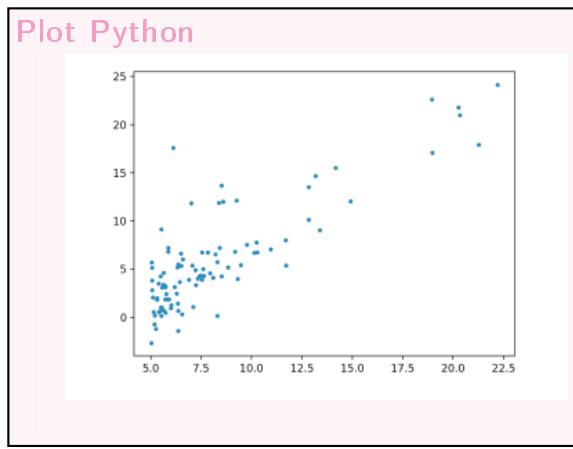
Affichage Python

```
1 >>> donnees.head()
2
3      Populations (en 10k)      Profit (en 10k EUR)
4 0      6.1101      17.4920
5 1      5.5277      9.1302
6 2      8.5186      13.6620
7 3      7.0032      11.8540
8 4      5.8598      6.8233
```

2. On ajoute les commandes suivantes

```
1 table = donnees.rename(columns={'Population (en 10k)' : 'pop', 'Profit (en 10k EUR)' :
2 : 'Profit'})
3
4 X = table['pop']
5 Y = table['profit']
6 plt.grid()
7 plt.plot(X,Y,'.')
```

qui renvoie le plot suivant



- Que représente cette figure ?
 - Expliquer pourquoi la figure ci-dessus permet de conjecturer qu'il existe deux réels a et b tels que $ax + b$ où x est le nombre d'habitants (en dizaines de milliers d'habitants) de la ville est une approximation raisonnable du profit (en dizaines de milliers d'euros) d'un *Food Trucks* installé dans cette ville.
 - Quelle quantité pourrait-on calculer pour conforter cette approximation ? Donner une suite d'instructions Python permettant de la calculer.
 - On suppose qu'on a été en mesure de répondre à la question précédente correctement. L'exécution de ces commandes affiche alors
- ```
1 0.83788623092365654
```
- Est-ce cohérent ?
- Il y a 182354 habitants à *Légumeville* et pas encore de *Food Truck*. Quelle commande Python permettraient d'estimer raisonnablement le profit d'un camion dans cette localité.
  - Votre société a beau être établie en zone euro, son siège social est dans le Delaware aux États-Unis, et on décide d'exprimer le profit en dollars. Au moment où j'écris ce texte, un euro vaut environ 1.02 dollars. Que devient alors la covariance des séries statistiques habitants / profits ? Même question avec le coefficient de corrélation linéaire.

## EXERCICE 2 d'après ECRICOME 2023.

Soit  $n$  un entier naturel non nul.

Une urne contient  $n$  boules indiscernables au toucher et numérotées de 1 à  $n$ . On tire une boule au hasard dans cette urne. Si cette boule porte le numéro  $k$ , alors on place dans une seconde urne une boule numérotée 1, deux boules numérotées 2, et plus généralement, pour tout  $j \in \llbracket 1, k \rrbracket$ ,  $j$  boules numérotées  $j$ , jusqu'à  $k$  boules numérotées  $k$ . Les boules de cette 2ème urne sont aussi indiscernables au toucher. On effectue alors un tirage au hasard d'une boule dans cette seconde urne.

Et on note  $X$  la variable aléatoire égale au numéro de la première boule tirée et  $Y$  la variable aléatoire égale au numéro de la 2ème boule tirée.

- Reconnaître la loi de  $X$  et donner son espérance et sa variance.
- Déterminer  $Y(\Omega)$ .
- Soit  $k \in \llbracket 1, n \rrbracket$ .
  - On suppose que l'événement  $[X = k]$  est réalisé. Déterminer en fonction de  $k$ , le nombre totale de boules présentes dans la seconde urne.
  - Pour tout entier  $j$  de  $\llbracket 1, n \rrbracket$ , exprimer  $\mathbb{P}_{[X=k]}(Y = j)$  en fonction de  $k$  et  $j$ .  
 $On distinguer les cas j \leq k$  et  $j \geq k + 1$ .

4. a. Déterminer deux réels  $a$  et  $b$  tels que, pour tout entier naturel  $k$  non nul,

$$\frac{1}{k(k+1)} = \frac{a}{k} + \frac{b}{k+1}.$$

- b. En déduire que, pour tout élément  $j$  de  $Y(\Omega)$ ,

$$\mathbb{P}([Y = j]) = \frac{2(n+1-j)}{n(n+1)}.$$

5. Justifier que  $Y$  admet une espérance et montrer que  $\mathbb{E}(Y) = \frac{n+2}{3}$ .

6. Les variables  $X$  et  $Y$  sont-elles indépendantes ?

7. a. Montrer que  $\mathbb{E}(XY) = \frac{(n+1)(4n+5)}{18}$ .

- b. En déduire que  $\text{Cov}(X, Y) = \frac{n^2-1}{18}$ .

8. a. Écrire une fonction en langage Python, nommée `seconde_urne`, prenant en entrée un entier naturel  $k$  non nul, et renvoyant une liste contenant 1 élément valant 1, 2 élément valant 2,...,  $j$  éléments valant  $j$ ,... jusqu'à  $k$  éléments valant  $k$ .

Par exemple, l'appel de `seconde_urne(4)` renverra `[1,2,2,3,3,3,4,4,4,4]`.

- b. Recopier et compléter la fonction en langage Python suivante pour qu'elle prenne en entrée un entier naturel non nul  $n$  et qu'elle renvoie une réalisation du couple de variables aléatoires  $(X, Y)$ .

```

1 import numpy.random as rd
2
3 def simul_XY(n) :
4 X =
5 urne2 = seconde_urne(.....)
6 nb = len(urne2)
7 i = rd.randint(0, nb)
8 Y =
9 return X, Y

```

- c. On considère la fonction en langage Python suivante, prenant en entier un entier naturel  $n$  non nul.

```

1 def fonction(n) :
2 liste = [0]*n
3 for i in range(10000) :
4 j = simul_XY[1]
5 liste[j-1] = liste[j-1] + 1/10000
6 return liste

```

Quelles valeurs les éléments de la liste renvoyée permettent-ils d'estimer ?

9. Dans toute cette question, on suppose que  $n = 20$ . On réalise 50 simulations du couple de variables  $(X, Y)$  à l'aide de la fonction `simul_XY(20)`. On représente alors les valeurs obtenues sous la forme d'un nuage de points, où les valeurs des réalisations de  $X$  sont représentées en abscisse et les valeurs de réalisations de  $Y$  en ordonnées. On trace également sur la même figure, la droite de régression linéaire associée à ce nuage de points.

- a. Déterminer par un calcul la valeur approchée des coordonnées du point moyen du nuage de points. Quel théorème de probabilités permet de justifier cette approximation ?

- b. Parmi les figures représentées ci-dessous, en justifiant soigneusement votre réponse, indiquer celle qui correspond au nuage de points et à la droite de régression étudiés.

