

INTERROGATION DE PYTHON N°8

EXERCICE

10 points

On considère x la série statistique obtenue par simulations de n variables de loi binomiale de paramètres $n = 100$ et $p = 0.5$ indépendantes. On suppose avoir importé la bibliothèque `random` de la façon suivante :

```
import random as rd
```

Et on rappelle que la commande `rd.binomial(n,p)` renvoie la simulation d'une variable de loi binomiale de paramètres n, p .

1. (a) Compléter la commande permettant de stocker dans la variable x une telle série statistique :

`x=[rd. (.... ,) for]`

- (b) Compléter la fonction `mod(x)` qui prend en argument un série statistique et renvoie la liste des modalités de cette série :

```
1 def mod(x):
2     L= .....
3     for k in ..... :
4         if k not in ..... :
5             L.append( .... )
6     return L
```

- (c) La commande `55 in mod(x)` renvoie `True`.

On tape ensuite `np.sum(x==55)` et on trouve 4 760. En déduire la fréquence de la modalité associée.

.....

.....

- (d) Rappeler l'expression de \bar{x} .

.....

Soit $(m_i)_{i \in \llbracket 1; p \rrbracket}$ les modalités de x et $(f_i)_{i \in \llbracket 1; p \rrbracket}$ les fréquences associées. Montrer que $\bar{x} = \sum_{i=1}^p m_i f_i$.

.....

.....

.....


.....

- (e) On tape la commande `np.mean(x)` et on obtient le résultat 49.98638. Ce résultat vous paraît-il cohérent avec la définition de la série statistique ? Justifier votre réponse.

.....

.....

2. On tape la commande suivante : `plt.hist(x,bins='auto',density=True)`
et on obtient le graphique suivante :



(a) Rappeler les définitions suivantes :

Médiane :

1er quartile :

3ème quartile :

On donne :

`np.mean(x<=50)=0.5398,` `np.mean(x<=46)=0.24433,` `np.mean(x<=53)=0.75817.`

Que pouvez vous en déduire ?
.....
.....
.....

(b) On tape la commande `np.std(x)` et on obtient le résultat ≈ 5.03192 . Commentez.

.....
.....

INTERROGATION PYTHON N°8 : CORRECTION

EXERCICE

10 points

On considère x la série statistique obtenue par simulations de 100 000 variables de loi binomiale de paramètres $n = 100$ et $p = 0.5$ indépendantes. On suppose avoir importé la bibliothèque random de la façon suivante :

```
import random as rd
```

Et on rappelle que la commande `rd.binomial(n,p)` renvoie la simulation d'une variable de loi binomiale de paramètres n, p .

1. (a) La commande suivante permet de stocker dans la variable x une telle série statistique :

```
x=[rd.binomial ( 100, 0.5) for_ in range(100000)]
```

- (b) La fonction `mod(x)` prend en argument une série statistique et renvoie la liste des modalités de cette série :

```
1 def mod(x):
2     L= []
3     for k in x :
4         if k not in L:
5             L.append( k )
6     return L
```

- (c) La commande `55 in mod(x)` renvoie True.

On tape ensuite `np.sum(x==55)` et on trouve 4 760.

Le fait que `55 in mod(x)` renvoie True signifie que $m_i = 55$ est une modalité de x .

La commande `np.sum(x==55)` donne l'effectif associé qui donc de $n_i = 4 760$. La fréquence associée est donc de

$$f_i = \frac{n_i}{n} \text{ soit } f_i = \frac{4\,760}{100\,000} = 0,0476.$$

- (d) On note $x = [x_1, \dots, x_n]$. $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$.

Soit $(m_i)_{i \in \{1; p\}}$ les modalités de x et $(f_i)_{i \in \{1; p\}}$ les fréquences associées.

On a $f_i = \frac{n_i}{n}$ où n_i désigne l'effectif de la modalité m_i . Ainsi $m_i f_i = \frac{m_i n_i}{n}$ et $m_i n_i$ revient donc à sommer la modalité m_i autant de fois qu'elle apparaît dans la série.

Il vient donc que $\sum_{i=1}^p m_i n_i = \sum_{i=1}^p x_i \iff \sum_{i=1}^p m_i n_i = n \bar{x}$ et donc que :


$$\frac{1}{n} \sum_{i=1}^p m_i n_i = \bar{x} \iff \bar{x} = \sum_{i=1}^p \frac{m_i n_i}{n} \iff \bar{x} = \sum_{i=1}^p m_i f_i.$$

- (e) On tape la commande `np.mean(x)` et on obtient le résultat 49.98638.

Oui le résultat est cohérent puisque la série statistique représente 100 000 simulations d'une variable $X \hookrightarrow \mathcal{B}(100, 0.5)$ qui a pour espérance $n \times p = 100 \times \frac{1}{2} = 50$.

2. On tape la commande suivante : `plt.hist(x, bins='auto', density=True)`

et on obtient le graphique suivante :



(a) Médiane : la médiane d'une série statistique est un réel m qui sépare la série en deux séries de mêmes effectifs.

1er quartile : le 1er quartile d'une série est le plus grand réel q_1 tel que la série correspondante aux valeurs de x inférieures à q_1 représente 25% de la série x .

3ème quartile : le 3ème quartile d'une série est le plus grand réel q_3 tel que la série correspondante aux valeurs de x inférieures à q_3 représente 75% de la série x .

$$\text{np.mean}(x \leq 50) = 0.5398, \quad \text{np.mean}(x \leq 46) = 0.24433, \quad \text{np.mean}(x \leq 53) = 0.75817.$$

$$m \approx 50$$

$$q_1 \approx 46$$

$$q_3 \approx 53.$$

(b) On tape les commandes `np.max(x)-np.min(x)` et `np.std(x)` et on obtient les résultats 44 et 5.03192.

La commande `np.max(x)-np.min(x)` renvoie l'étendue de la série.

La commande `np.std(x)` renvoie l'écart-type de la série.

Avec une étendue de 44 et un écart-type de ≈ 5 on peut dire que la série n'est pas très dispersée autour de sa moyenne empirique qui vaut ≈ 50 pour une médiane de ≈ 50 .

Ce que confirme largement l'histogramme.