

### Sujet d'entraînement n°3

Ecricome 2023, exercice 1 (sur 3)

Corrigé

**Exercice 1** - extrait Ecricome (un exemple d'exercice avec une petite partie de statistiques)

Soit  $n$  un entier naturel non nul.

Une urne contient  $n$  boules indiscernables au toucher numérotées de 1 à  $n$ . On tire une boule au hasard dans l'urne. Si cette boule tirée porte le numéro  $k$ , on place alors dans une seconde urne toutes les boules suivantes : 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 deuxième urne sont indiscernables au toucher. On effectue alors un tirage au hasard dans cette seconde urne.

On note  $X$  la variable aléatoire égale au numéro de la première boule tirée et  $Y$  la variable aléatoire égale au numéro de la deuxième boule tirée.

1. Le premier tirage se fait dans une urne qui contient  $n$  boules indiscernables au toucher et chaque numéro est alors équiprobable ; on a reconnu la loi uniforme

$$X \hookrightarrow \mathcal{U}(\llbracket 1, n \rrbracket).$$

En particulier, les formules du cours donnent directement  $E(X) = \frac{n+1}{2}$ ,  $V(X) = \frac{n^2-1}{12}$ .

2. Dans le *pire* des cas, on pioche lors du premier tirage la boule numérotée 1 et il n'y a dans la deuxième urne qu'une boule numérotée 1. Si on pioche au premier coup la boule numérotée  $n$ , il y a ensuite des boules numérotées de 1 à  $n$  dans la deuxième urne. Ainsi, la valeur de la deuxième boule piochée est toujours une valeur entre 1 et  $n$  et toutes les valeurs sont possibles. On a donc  $Y(\Omega) = \llbracket 1, n \rrbracket$ .

3. Soit  $k \in \llbracket 1, n \rrbracket$ .

- a. On suppose que l'évènement  $[X = k]$  est réalisé.

D'après la description de l'expérience, on a disposé dans la deuxième urne un nombre de boules égal à

$$1 + 2 + \dots + k = \sum_{j=1}^k j = \frac{k(k+1)}{2}.$$

- b. Si  $j \in \llbracket 1, k \rrbracket$ , il y a dans l'urne des boules numérotées  $j$  (et il y en a exactement  $j$ ). Sinon, les boules  $j$  ne font pas partie de l'urne (et la probabilité de les piocher alors nulle). On a donc par équiprobabilité et avec la formule ci-dessus pour le total de boules :

$$P_{[X=k]}(Y = j) = \begin{cases} \frac{2j}{k(k+1)}, & \text{si } 1 \leq j \leq k \\ 0, & \text{si } k < j \end{cases}$$

4. a. Commençons par mettre au même dénominateur.

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

Ainsi, par principe d'identification des polynômes

$$\left( \forall k \in \mathbb{N}^*, \quad \frac{a}{k} + \frac{b}{k+1} = \frac{1}{k(k+1)} \right) \iff \begin{cases} a+b = 0 \\ a = 1 \end{cases} \iff \begin{cases} b = -1 \\ a = 1 \end{cases}$$

On peut alors écrire, pour tout  $k \in \mathbb{N}^*$ ,

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

b. Soit  $j \in \llbracket 1, n \rrbracket$ . D'après la formule des probabilités totales appliquée au s.c.e  $\{[X = k] : k \in \llbracket 1, n \rrbracket\}$ , on a

$$\begin{aligned} P(Y = j) &= \sum_{k=1}^n P_{[X=k]}(Y = j)P(X = k) \\ &= \sum_{k=j}^n P_{[X=k]}(Y = j)P(X = k) \\ &= \sum_{k=j}^n \frac{2j}{k(k+1)} \times \frac{1}{n} = \frac{2j}{n} \sum_{k=j}^n \frac{1}{k(k+1)} \\ &= \frac{2j}{n} \sum_{k=j}^n \left( \frac{1}{k} - \frac{1}{k+1} \right) \\ &= \frac{2j}{n} \left( \frac{1}{j} - \frac{1}{n+1} \right) \\ &= \frac{2(n+1-j)}{n(n+1)}, \end{aligned}$$

ce qui est bien le résultat demandé.

5.  $Y$  a un univers image fini, elle admet donc une espérance. De plus,

$$\begin{aligned} E(Y) &= \sum_{j=1}^n jP(Y = j) = \sum_{j=1}^n j \frac{2(n+1-j)}{n(n+1)} \\ &= \frac{2}{n(n+1)} \sum_{j=1}^n j(n+1-j) = \frac{2}{n(n+1)} \left( (n+1) \sum_{j=1}^n j - \sum_{j=1}^n j^2 \right) \\ &= \frac{2}{n(n+1)} \left( (n+1) \frac{n(n+1)}{2} - \frac{n(n+1)(2n+1)}{6} \right) \\ &= (n+1) - \frac{2n+1}{3} \\ &= \frac{n+2}{3}, \end{aligned}$$

ce qui est bien le résultat attendu.

6. Soit  $n \geq 2$ . Si  $X$  et  $Y$  étaient indépendantes alors, pour tout couple  $(k, j) \in \llbracket 1, n \rrbracket^2$ , on aurait

$$P_{[X=k]}(Y = j) = P(Y = j) \neq 0.$$

Or, la probabilité de gauche est nulle dès que  $j > k$ . Les variables  $X$  et  $Y$  ne sont donc pas indépendantes.

Pour  $n = 1$ , les deux variables aléatoires  $X$  et  $Y$  sont certaines et égales à 1... elles sont donc indépendantes.

7. a. Par le théorème de transfert, on a

$$\begin{aligned}
E(XY) &= \sum_{k=1}^n \sum_{j=1}^n kjP([X = k] \cap [Y = j]) = \sum_{k=1}^n \sum_{j=1}^n kjP([X = k])P_{[X=k]}([Y = j]) \\
&= \sum_{k=1}^n \sum_{j=1}^k kj \times \frac{1}{n} \times \frac{2j}{k(k+1)} \\
&= \frac{1}{n} \sum_{k=1}^n \frac{2}{k+1} \sum_{j=1}^k j^2 = \frac{1}{n} \sum_{k=1}^n \frac{2}{k+1} \times \frac{k(k+1)(2k+1)}{6} \\
&= \frac{1}{3n} \sum_{k=1}^n k(2k+1) = \frac{1}{3n} \left( 2 \sum_{k=1}^n k^2 + \sum_{k=1}^n k \right) \\
&= \frac{1}{3n} \left( \frac{n(n+1)(2n+1)}{3} + \frac{n(n+1)}{2} \right) \\
&= \frac{n+1}{18} (2(2n+1) + 3) \\
&= \frac{(n+1)(4n+5)}{18},
\end{aligned}$$

ce qui fait plaisir car c'est ce qu'on demande !

b. Par la formule de König-Huyguens,

$$\begin{aligned}
\text{Cov}(X, Y) &= E(XY) - E(X)E(Y) = \frac{(n+1)(4n+5)}{18} - \frac{n+1}{2} \times \frac{n+2}{3} \\
&= \frac{n+1}{18} (4n+5 - 3(n+2)) \\
&= \frac{(n+1)(n-1)}{18} = \frac{n^2-1}{18}
\end{aligned}$$

et c'est tout bon.

(On remarque que, pour  $n = 1$ , la covariance est nulle, ce qui est cohérent avec ce qu'on a mentionné ci-avant quant à l'indépendance de  $X$  et  $Y$ .)

8. a. Il suffit d'utiliser l'instruction `append` pour compléter la liste avec deux boucles `for`.

```

def seconde_urne(k):
    L = []
    for j in range(1, k+1) :
        for i in range(j):
            L.append(j)
    return L

```

b. La variable  $X$  se simule grâce à la commande `rd.randint(1, n+1)`. On crée l'urne 2 à l'aide de la valeur de  $X$ . On prend ensuite le terme de la liste `urne2` à la position  $i$  (où  $i$  est choisi aléatoirement uniformément parmi le nombre de boules disponibles) pour  $Y$ . Ceci donne

```

import numpy.random as rd

def simul_XY(n) :
    X = rd.randint(1, n+1)
    urne2=seconde_urne(X)
    nb=len(urne2) # nombre de boules dans l'urne 2
    i=rd.randint(0, nb)
    Y=urne2[i]
    return X,Y

```

c. Le programme proposé est le suivant

```

def fonction(n):
    liste=[0]*n

```

```

for i in range(10000):
    j = simul_XY[1]
    liste[j-1]=liste[j-1]+1/10000
return liste

```

La variable `liste` contient la liste des fréquences de chaque valeur prise par  $Y$  lors de 10000 simulations de celle-ci. C'est à dire qu'on *estime* la loi de  $Y$  (les fréquences observées donnent des valeurs approchées des valeurs théoriques  $P(Y = j)$ ).

On commence, avec la commande `liste=[0]*n` par créer une liste de  $n$  zéros qui va être actualisé. Le  $j$ –ième terme de la liste (indexé en Python par  $j - 1$ ) contient la fréquence de passage par la valeur  $j$ .

En effet, la commande `j = simul_XY[1]` simule  $Y$  (c'est la deuxième composante du couple  $(X, Y)$  car on indexe en commençant par 0...) et les composantes de `liste` sont les fréquences qui augmentent de 1 divisé par l'effectif total dès lors que  $Y$  a pris la valeur de la composante en question.

**9.** Dans toute cette question, on suppose  $n = 20$ .

- a.** Le point moyen a pour coordonnées  $(\bar{x}, \bar{y})$  où  $\bar{x}$  et  $\bar{y}$  désignent respectivement les moyennes des 20 valeurs obtenues par les simulations de  $X$  et de  $Y$ . Lorsque  $n$  devient grand, la *loi faible des grands nombres* permet d'affirmer (enfin il faudrait dire que  $X$  et  $Y$  admettent une variance mais c'est le cas car les univers images sont finis) que la moyenne empirique d'un  $n$ –échantillon fournit une bonne<sup>1</sup> estimation de l'espérance. Donc le point moyen devrait avoir des coordonnées

$$\bar{x} \simeq E(X) = \frac{21}{2} = 10,5, \quad \text{et} \quad \bar{y} \simeq E(Y) = \frac{22}{3} \simeq 7,33.$$

- b.** Les valeurs prises par  $X$  et  $Y$  sont entre 1 et 20 : on peut éliminer la figure 1 (le nuage de points ne correspond pas). La covariance de  $X$  et  $Y$  est positive, la droite de régression est donc croissante. On peut éliminer la 4. La droite de régression passe par le point moyen, donc elle doit passer par  $(10,5; 7,33)$ . On peut donc éliminer les figures 2 et 4 où c'est la droite de régression qui ne correspond pas.

C'est donc la figure 3 qui correspond au nuage de points étudié.

---

1. c'est un estimateur convergent et non biaisé mais ces notions ne sont plus vraiment au programme