

## Problème de Mathématiques

Référence pp1714 — Version du 31 décembre 2025

Une urne contient  $n$  boules numérotées de 1 à  $n$ . On effectue alors deux tirages avec le protocole suivant :

- On tire une première boule au hasard ;
- Si la première boule tirée porte le numéro  $1 \leq k \leq n$ , on la remet dans l'urne avec  $k$  nouvelles boules numérotées  $k$  et on tire une deuxième boule au hasard dans l'urne.

Par exemple, si on a tiré la boule numéro 3, on remet quatre boules portant le numéro 3 dans l'urne avant de procéder au second tirage : la boule numéro 3 qui a été extraite lors du premier tirage et trois autres boules de numéro 3. On procède alors au second tirage dans une urne qui contient  $(n+3)$  boules.

On note  $X$  (resp.  $Y$ ), le numéro de la boule choisie lors du premier tirage (resp. du second tirage).

Pour modéliser l'expérience aléatoire, on considère que  $X$  et  $Y$  sont deux variables aléatoires discrètes définies sur un même espace probabilisé  $(\Omega, \mathcal{A}, \mathbf{P})$ , à valeurs dans  $E_n = \{1, \dots, n\}$ .

On rappelle que toute l'information disponible sur le couple de variables aléatoires  $(X, Y)$  est contenue dans sa loi conjointe, qui est (par définition) une mesure de probabilité discrète sur l'ensemble fini  $E_n \times E_n$ .

1. Comment la loi conjointe d'un couple de variables aléatoires à valeurs dans  $E_n$  est-elle caractérisée habituellement ?
2. a. Pourquoi est-il légitime de supposer que la variable aléatoire  $X$  suit la loi uniforme sur  $E_n$  ?
2. b. Calculer l'espérance de  $X$ .
3. Soit  $1 \leq k \leq n$ .
3. a. Expliquer pourquoi il est légitime de poser

$$\forall \ell \in E_n \setminus \{k\}, \quad \mathbf{P}(Y = \ell \mid X = k) = \frac{1}{n+k}.$$

3. b. Comment peut-on en déduire  $\mathbf{P}(Y = k \mid X = k)$  ?
4. En déduire une caractérisation de la loi de  $Y$ .
5. Démontrer que  $Y$  est une variable aléatoire d'espérance finie et déduire de ce qui précède que

$$\mathbf{E}(Y) = \frac{n+1}{2} \sum_{k=1}^n \frac{1}{n+k} + \frac{1}{n} \sum_{k=1}^n \frac{k^2}{n+k}.$$

En déduire un équivalent de  $\mathbf{E}(Y)$  lorsque  $n$  tend vers  $+\infty$ .

6. Expliquer le sens du code Python suivant et démontrer que l'instruction `simulation(10)` permet d'estimer l'espérance de  $Y$  dans le cas  $n = 10$ .

```
from random import randint as unif

def tirages(n):
    X = unif(1, n)
    L = list(range(1,n+1))+[X]*X
    i = unif(1, len(L))
    Y = L[i-1]
    return [X, Y]

def simulation(n, N=10**5):
    ech_XY = [tirages(n) for k in range(N)]
    ech_Y = [t[1] for t in ech_XY]
    s = 0
    for Y in ech_Y:
        s += Y
    return s/N
```

## Solution   ✱   Un modèle d'urne

1. La loi conjointe de  $(X, Y)$  est caractérisée par la famille

$$(\mathbf{P}(X = i, Y = j))_{1 \leq i, j \leq n}.$$

2. a. La loi de  $X$  est une mesure de probabilité sur  $E_n$  qui indique avec quelles fréquences la variable  $X$  prend ses valeurs. Comme rien, dans l'énoncé, n'indique qu'une des boules a plus de chance qu'une autre d'être tirée, il est légitime de considérer que  $X$  suit la loi uniforme sur  $E_n$ .

2. b. Comme  $X$  est une variable aléatoire bornée, elle est d'espérance finie et comme, pour tout  $1 \leq k \leq n$ ,

$$\mathbf{P}(X = k) = \frac{1}{n}$$

alors

$$\mathbf{E}(X) = \sum_{k=1}^n \frac{k}{n} = \frac{n+1}{2}.$$

3. a. Comme  $\mathbf{P}(X = k) = 1/n > 0$ , les probabilités conditionnelles  $\mathbf{P}(Y = \ell \mid X = k)$  sont bien définies.

Conditionner par  $[X = k]$  revient à supposer que la variable  $X$  a pris la valeur  $k$ , c'est-à-dire qu'on a tiré la boule numérotée  $k$  lors du premier tirage. Par conséquent, on va tirer la seconde boule dans une urne qui contient  $(n + k)$  boules :

- une boule numérotée  $i$  pour tout indice  $1 \leq i \leq n$  différent de  $k$ ;
- et  $(k + 1)$  boules numérotées  $k$ .

Une fois encore, rien n'indique qu'une boule a plus de chance qu'une autre d'être tirée, donc chaque boule numérotée  $i \in E_n \setminus \{k\}$  a une chance sur  $(n + k)$  d'être choisie.

Autrement dit,

$$\forall \ell \in E_n \setminus \{k\}, \quad \mathbf{P}(Y = \ell \mid X = k) = \frac{1}{n + k}.$$

3. b. La famille  $([Y = \ell])_{\ell \in E_n}$  est un système complet d'événements (puisque  $Y$  est une variable aléatoire à valeurs dans  $E_n$ ) et  $\mathbf{P}_{[X=k]}$  est une mesure de probabilité sur  $\mathcal{A}$ , donc

$$\sum_{\ell=1}^n \mathbf{P}_{X=k}(Y = \ell) = 1.$$

D'après la question précédente,

$$\mathbf{P}_{X=k}(Y = k) + \sum_{\ell \in E_n \setminus \{k\}} \frac{1}{n + k} = 1$$

et donc

$$\mathbf{P}(Y = k \mid X = k) = 1 - \frac{n-1}{n+k} = \frac{k+1}{n+k}.$$

4. D'après la formule des probabilités totales et les questions précédentes,

$$\begin{aligned} \forall \ell \in E_n, \quad \mathbf{P}(Y = \ell) &= \sum_{k=1}^n \mathbf{P}(Y = \ell \mid X = k) \mathbf{P}(X = k) = \frac{1}{n} \sum_{k \in E_n \setminus \{\ell\}} \frac{1}{n+k} + \frac{1}{n} \frac{\ell+1}{n+\ell} \\ &= \frac{\ell}{n(n+\ell)} + \frac{1}{n} \sum_{k=1}^n \frac{1}{n+k} \end{aligned}$$

et comme  $Y$  est une variable aléatoire à valeurs dans  $E_n$ , on sait que la famille de probabilités

$$(\mathbf{P}(Y = \ell))_{\ell \in E_n}$$

caractérise la loi de  $Y$ .

5. Comme la variable aléatoire  $Y$  est bornée, elle est d'espérance finie et d'après ce qui précède,

$$\begin{aligned} \mathbf{E}(Y) &= \sum_{\ell=1}^n \ell \mathbf{P}(Y = \ell) = \sum_{\ell=1}^n \sum_{k=1}^n \frac{\ell}{n(n+k)} + \sum_{\ell=1}^n \frac{\ell^2}{n(n+\ell)} \\ &= \frac{n+1}{2} \sum_{k=1}^n \frac{1}{n+k} + \frac{1}{n} \sum_{\ell=1}^n \frac{\ell^2}{n+\ell}. \end{aligned}$$

On peut expliciter deux sommes de Riemann.

$$\mathbf{E}(Y) = \frac{n+1}{2} \cdot \frac{1}{n} \sum_{k=1}^n \frac{1}{1+k/n} + n \cdot \frac{1}{n} \sum_{k=1}^n \frac{k^2/n^2}{1+k/n}.$$

Les fonctions  $[t \mapsto \frac{1}{1+t}]$  et  $[t \mapsto \frac{t^2}{1+t}]$  sont continues sur le segment  $[0, 1]$ , donc

$$\frac{1}{n} \sum_{k=1}^n \frac{1}{1+k/n} \rightarrow \int_0^1 \frac{dt}{1+t} = \ln 2$$

et

$$\frac{1}{n} \sum_{k=1}^n \frac{k^2/n^2}{1+k/n} \rightarrow \int_0^1 \frac{t^2 dt}{1+t} = \int_0^1 t - 1 + \frac{1}{1+t} dt = \ln 2 - \frac{1}{2}.$$

Par conséquent,

$$\mathbf{E}(Y) \sim \left( \frac{3}{2} \ln 2 - \frac{1}{2} \right) \cdot n$$

lorsque  $n$  tend vers  $+\infty$ .

#### 6. Étude de la fonction tirages

On donne à  $X$  une valeur comprise entre 1 et  $n$  au sens large (choisie au hasard suivant la loi uniforme).

En notant  $k$ , la valeur attribuée à  $X$ , on construit ensuite la liste  $L$  égale à

$$(1, 2, \dots, k, \dots, n, \underbrace{k, \dots, k}_{k \text{ exemplaires}}).$$

La longueur de cette liste est donc égale à  $n + k$ .

On choisit ensuite un indice  $i$  compris entre 1 et  $n + k$  au sens large (choisi au hasard suivant la loi uniforme) et on attribue à  $Y$  la valeur de  $L[i-1]$ .

La valeur de  $Y$  est donc égale à  $\ell \neq k$  lorsque  $i$  prend la valeur  $\ell + 1$  et égal à  $k$  lorsque  $i$  prend la valeur  $k + 1$  ou une valeur comprise entre  $n + 1$  et  $n + k$ .

Donc  $Y$  prend une valeur  $\ell \neq k$  avec probabilité  $\frac{1}{n+k}$  et prend la valeur  $k$  (la valeur de  $X$ ) avec probabilité  $\frac{k+1}{n+k}$ .

La liste  $[X, Y]$  retournée par tirages est une simulation de  $(X, Y)$  qui est conforme à la loi conjointe du couple  $(X, Y)$  définie plus haut.

#### • Étude de la fonction simulation

La fonction `simulation` effectue  $N$  appels successifs à la fonction `tirages` avec  $N = 10^5$  par défaut.

La liste `ech_XY` contient donc une réalisation de l'échantillon

$$((X_n, Y_n))_{0 \leq n < N}$$

et la liste `ech_Y` une réalisation de l'échantillon

$$(Y_n)_{0 \leq n < N}$$

où les variables  $Y_n$  sont indépendantes et suivent toutes la loi de  $Y$ .

La variable `s` sert à calculer la somme des éléments de la liste `ech_Y` et la fonction `simulation` retourne le quotient de cette somme par le nombre  $N$  de termes, c'est-à-dire la *moyenne* de l'échantillon `ech_Y`.

Comme la variable  $Y$  est bornée, elle est de carré intégrable et la Loi des grands nombres peut s'appliquer : pour tout  $\varepsilon > 0$ ,

$$\mathbf{P}\left(\left|\frac{Y_0 + \dots + Y_{N-1}}{N} - \mathbf{E}(Y)\right| \geq \varepsilon\right) \xrightarrow{N \rightarrow +\infty} 0.$$

En admettant que  $N = 10^5$  soit assez grand, on en déduit que la moyenne de l'échantillon retournée par la fonction `simulation` est proche de  $\mathbf{E}(Y)$  avec une probabilité assez forte.

|| On peut rendre la discussion précédente plus précise grâce à l'inégalité de Bienaymé-Tchebychev.

|| Pour  $n = 10$ , on a  $\mathbf{E}(Y) \approx 5,866$  et en exécutant dix fois l'instruction `simulation(10)`, on obtient les résultats suivants.

5,865	5,863	5,872	5,879	5,859
5,883	5,870	5,873	5,855	5,855

|| C'est probant !