



PROBABILITÉS DISCRETES

ÉNONCÉ DE L'EXERCICE

ÉNONCÉ-32

Une urne contient des boules numérotées de 1 à N , où N est un entier supérieur ou égal à 2. Elles sont indiscernables au toucher et l'on effectue n tirages successifs d'une boule avec remise. Pour tout $j \in \llbracket 1, N \rrbracket$, on note Z_j le numéro obtenu au $j^{\text{ème}}$ tirage. On suppose N inconnu et on cherche à l'estimer.

1) On considère la moyenne empirique :

$$M_n = \frac{1}{n}(Z_1 + Z_2 + \dots + Z_n)$$

Calculer l'espérance $E(M_n)$ de M_n et en déduire un estimateur sans biais de N .

2) On considère maintenant $X_n = \sup(Z_1, \dots, Z_n)$ et on cherche à montrer que X_n est un estimateur asymptotiquement sans biais de N , c'est-à-dire que :

$$\lim_{n \rightarrow +\infty} E(X_n) = N$$

a) Donner la fonction de répartition de X_n .

b) Montrer que, pour toute variable aléatoire Y à valeurs dans $\llbracket 1, N \rrbracket$, on a :

$$\sum_{k=1}^N P(Y \geq k) = E(Y)$$

c) En déduire que $E(X_n) \geq N - \frac{N}{n+1}$ et conclure.

CORRIGE DE L'EXERCICE NUMERO 32

1) _____

Par linéarité de l'espérance, $E(M_n) = E\left(\frac{1}{n} \sum_{j=1}^n Z_j\right) = \frac{1}{n} \sum_{j=1}^n E(Z_j)$.

Or les variables Z_j suivent la loi uniforme sur $\llbracket 1, N \rrbracket$ puisqu'à chaque tirage, la situation est la même qu'initialement. Donc $E(Z_j) = \frac{N+1}{2}$.

Il s'ensuit que

$$E(M_n) = \frac{1}{n} n \frac{N+1}{2} = \frac{N+1}{2}.$$

On en déduit qu'un estimateur sans biais de N est $T_n = 2M_n - 1$ puisque

$$E(T_n) = 2E(M_n) - 1 = N + 1 - 1 = N.$$

2-a) _____

La variable X_n est discrète puisque, par indépendance des variables Z_j , on a : $X_n(\Omega) = \llbracket 1, N \rrbracket$. En effet, pour toute valeur $k \in \llbracket 1, N \rrbracket$, l'événement $(X_n = k)$ est réalisé lorsque toutes les variables Z_j prennent la valeur k , ce qui n'est pas impossible.

Donc, puisque X_n est discrète, sa fonction de répartition est entièrement déterminée par les valeurs $F_{X_n}(k)$ pour $k \in \llbracket 1, N \rrbracket$.

Soit $k \in \llbracket 1, N \rrbracket$. On a :

$F_{X_n}(k) = P(X_n \leq k) = P(Z_1 \leq k) \cap Z_2 \leq k \cap \dots \cap Z_n \leq k)$, car dire que le plus grand des n nombres Z_1, \dots, Z_n est inférieur ou égal à k veut dire que chacun d'entre eux est inférieur ou égal à k .

Par indépendance (implicite) des variables Z_j , on peut écrire

$$F_{X_n}(k) = P(Z_1 \leq k)P(Z_2 \leq k) \dots P(Z_n \leq k) = \left(\frac{k}{N}\right)^n$$

2-b) _____

Il n'y a pas de problème d'existence de l'espérance puisque $Y(\Omega)$ est un ensemble fini.

$\sum_{k=1}^N P(Y \geq k) = \sum_{k=1}^N \sum_{j=k}^N P(Y = j)$; en effet l'événement $(Y \leq k) = \bigcup_{j=k}^N (Y = j)$ et les événements $(Y = j)$ sont deux à deux incompatibles.

A partir de là, intervertissons l'ordre des sommations en remarquant que l'on a : $1 \leq k \leq j \leq N$. Donc j prend toutes les valeurs de $\llbracket 1, N \rrbracket$ et lorsque j est fixé, k varie entre 1 et j ; d'où la formule

$$\sum_{k=1}^N \sum_{j=k}^N P(Y = j) = \sum_{j=1}^N \sum_{k=1}^j P(Y = j) = \sum_{j=1}^N j P(Y = j) = E(Y).$$

$$E(Y) = \sum_{k=1}^N P(Y \geq k)$$

2-c)

On a ici :

$$\begin{aligned} E(X_n) &= \sum_{k=1}^N P(X_n \geq k) \\ &= \sum_{k=1}^N (1 - P(X_n < k)) \\ &= \sum_{k=1}^N (1 - F_{X_n}(k-1)) \\ &= \sum_{k=1}^N (1 - (\frac{k-1}{N})^n) \end{aligned}$$

formule valable pour $k=1$ car $F_{X_n}(0) = 0$

On obtient donc $E(X_n) = N - \sum_{k=1}^N (\frac{k-1}{N})^n = N - \sum_{j=0}^{N-1} (\frac{j}{N})^n$ après avoir effectué dans la somme le changement d'indice $j = k - 1$.

Or :

$\forall t \in [\frac{j}{N}, \frac{j+1}{N}]$, $0 \leq \frac{j}{N} \leq t$; on peut donc élever cette inégalité à la puissance n et puisque cette fonction puissance est croissante sur \mathbb{R}_+ , on obtient $(\frac{j}{N})^n \leq t^n$.

Intégrons cette inégalité entre $\frac{j}{N}$ et $\frac{j+1}{N}$; les bornes sont dans l'ordre croissant, cela donne :

$$\int_{\frac{j}{N}}^{\frac{j+1}{N}} (\frac{j}{N})^n dt \leq \int_{\frac{j}{N}}^{\frac{j+1}{N}} t^n dt \text{ ou encore } \frac{1}{N} (\frac{j}{N})^n \leq \int_{\frac{j}{N}}^{\frac{j+1}{N}} t^n dt$$

Sommons ces dernières inégalités pour j variant de 0 à $N-1$ et pour l'intégrale utilisons la relation de Chasles, il vient :

$$\begin{aligned} \sum_{j=0}^{N-1} \frac{1}{N} (\frac{j}{N})^n &\leq \sum_{j=0}^{N-1} \int_{\frac{j}{N}}^{\frac{j+1}{N}} t^n dt \\ \sum_{j=0}^{N-1} \frac{1}{N} (\frac{j}{N})^n &\leq \int_0^1 t^n dt \\ \sum_{j=0}^{N-1} \frac{1}{N} (\frac{j}{N})^n &\leq \frac{1}{n+1} \end{aligned}$$

$$\text{Donc finalement, } \sum_{j=0}^{N-1} (\frac{j}{N})^n \leq \frac{N}{n+1}.$$

Or on sait que $E(X_n) = N - \sum_{j=0}^{N-1} (\frac{j}{N})^n$; l'inégalité précédente permet d'écrire

$$E(X_n) \geq N - \frac{N}{n+1}.$$

Il est évident que $E(X_n) \leq N$ puisque N est la plus grande des valeurs possibles de X_n . On a donc l'encadrement

$$N - \frac{N}{n+1} \leq E(X_n) \leq N.$$

Par encadrement : $\lim_{n \rightarrow +\infty} E(X_n) = N$