

Soit $(X_n)_{n \geq 1}$, une suite de variables aléatoires définies sur un même espace probabilisé $(\Omega, \mathcal{A}, \mathbf{P})$, indépendantes, de même loi, à valeurs dans \mathbb{N} . Pour tout entier $n \geq 1$, on pose

$$C_n = \#\{X_1, \dots, X_n\}.$$

1 Pour tout entier $n \geq 1$, l'application $C_n : \Omega \rightarrow \mathbb{N}$ est une variable aléatoire d'espérance finie.

2 Démontrer que, pour tout $n \in \mathbb{N}^*$ et tout $k \in \mathbb{N}$,

$$\mathbf{E}(C_n) \leq k + n^2 \mathbf{P}(X_1 \geq k).$$

3 On suppose dorénavant que les variables aléatoires X_k sont d'espérance finie.

Démontrer que

$$\mathbf{P}(X_1 \geq k) \underset{k \rightarrow +\infty}{=} o(1/k).$$

En déduire que

$$\mathbf{E}(C_n) \underset{n \rightarrow +\infty}{=} o(n).$$

1 Il est clair que les valeurs de C_n sont comprises entre 1 (cas où toutes les variables aléatoires X_k prennent la même valeur) et n (cas où toutes les variables aléatoires X_k prennent des valeurs distinctes).

L'ensemble \mathbb{N}^n est dénombrable (produit cartésien d'un nombre fini d'ensembles dénombrables) et

$$\mathbb{N}^n = \bigsqcup_{1 \leq k \leq n} E_k$$

où E_k est l'ensemble des n -uplets formés au moyen de k entiers naturels distincts.

Les ensembles E_k sont donc des ensembles dénombrables (ils sont contenus dans un ensemble dénombrable et manifestement ils sont infinis) et, pour tout entier $1 \leq k \leq n$,

$$C_n(\omega) = k \iff \exists (i_1, \dots, i_n) \in E_k, \quad (X_1(\omega), \dots, X_n(\omega)) = (i_1, \dots, i_n).$$

Autrement dit,

$$[C_n = k] = \bigsqcup_{(i_1, \dots, i_n) \in E_k} [X_1 = i_1] \cap \dots \cap [X_n = i_n]$$

ce qui prouve que

$$\forall 1 \leq k \leq n, \quad [C_n = k] \in \mathcal{A}$$

et donc que C_n est bien une variable aléatoire discrète sur (Ω, \mathcal{A}) .

• Comme C_n est une variable aléatoire bornée, elle est d'espérance finie.

• Plus précisément, $1 \leq \mathbf{E}(C_n) \leq n$, ce qui donne de l'intérêt aux estimations qui vont suivre.

2 Soit $k \in \mathbb{N}$. De deux choses l'une :

- ou bien toutes les variables aléatoires X_1, \dots, X_n sont strictement inférieures à k et dans ce cas, elles ne peuvent pas prendre plus de k valeurs distinctes ;
- ou bien l'une d'elles au moins est supérieure à k .

Autrement dit :

$$\Omega = [X_1 < k, \dots, X_n < k] \sqcup ([X_1 \geq k] \cup \dots \cup [X_n \geq k])$$

et

$$[X_1 < k, \dots, X_n < k] \subset [C_n \leq k].$$

Comme $C_n(\omega) \leq n$ pour tout $\omega \in \Omega$, on en déduit que

$$C_n \leq k \mathbb{1}_{[X_1 < k, \dots, X_n < k]} + n \mathbb{1}_{[X_1 \geq k] \cup \dots \cup [X_n \geq k]}.$$

Comme l'espérance conserve les inégalités, on en déduit que

$$\mathbf{E}(C_n) \leq k \mathbf{P}([X_1 < k, \dots, X_n < k]) + n \mathbf{P}([X_1 \geq k] \cup \dots \cup [X_n \geq k]).$$

Les variables aléatoires X_k sont de même loi, donc

$$\mathbf{P}([X_1 \geq k] \cup \dots \cup [X_n \geq k]) \leq \sum_{i=1}^n \mathbf{P}(X_i \geq k) = n \mathbf{P}(X_1 \geq k)$$

et finalement

$$\mathbf{E}(C_n) \leq k \times 1 + n \times n \mathbf{P}(X_1 \geq k) = k + n^2 \mathbf{P}(X_1 \geq k).$$

🔗 Il n'y a plus de calcul de probabilité dans ce qui suit, c'est un résultat d'analyse. Nous considérerons donc deux suites positives $(u_n)_{n \in \mathbb{N}}$ et $(\varepsilon_n)_{n \in \mathbb{N}}$ telles que

$$\forall 0 \leq k \leq n, \quad 0 \leq u_n \leq k + n^2 \frac{\varepsilon_k}{k} \quad \text{avec} \quad \lim_{k \rightarrow +\infty} \varepsilon_k = 0.$$

et nous cherchons à en déduire que

$$\lim_{n \rightarrow +\infty} \frac{u_n}{n} = 0.$$

3. Fixons $0 < \eta < 1$ et posons $\varepsilon = \sqrt{\eta} \in]0, 1[$.
D'après les hypothèses,

$$\forall n \in \mathbb{N}, \forall 0 \leq k \leq n, \quad 0 \leq \frac{u_n}{n} \leq \frac{k}{n} + n \frac{\varepsilon_k}{k}$$

et, comme $\eta > 0$, il existe un entier $K_0 \in \mathbb{N}$ tel que

$$\forall k \geq K_0, \quad 0 \leq \varepsilon_k \leq \varepsilon.$$

Par conséquent,

$$\forall n > K_0, \forall K_0 \leq k \leq n, \quad 0 \leq \frac{u_n}{n} \leq \frac{k}{n} + n \frac{\varepsilon}{k}. \quad (*)$$

🔗 Le principe du raisonnement qui va suivre est classique : c'est un passage à la borne inférieure. Si

$$\forall x \in [a, b], \quad g(n) \leq f(x)$$

alors

$$g(n) \leq \inf_{x \in [a, b]} f(x).$$

La mise en œuvre de ce raisonnement est (un peu) compliquée par le fait que, ici, le majorant est une fonction de la variable entière k et non pas une fonction de la variable réelle x .

• Une étude rapide montre que la fonction f définie par

$$\forall x > 0, \quad f(x) = \frac{x}{n} + \frac{n\varepsilon}{x}$$

atteint son minimum en $x_0 = n\sqrt{\varepsilon}$. Comme $0 < \varepsilon < 1$, on a $n\sqrt{\varepsilon} < n$ pour tout n et la suite de terme général $y_n = n\sqrt{\varepsilon}$ tend vers $+\infty$, donc il existe donc un rang $N_1 \in \mathbb{N}$ tel que

$$\forall n \geq N_1, \quad K_0 \leq k_0 \stackrel{\text{d\u00e9f.}}{=} \lfloor n\sqrt{\varepsilon} \rfloor \leq n.$$

🔗 À défaut de pouvoir majorer par le minimum de la fonction f , on va majorer par une valeur particulière de f qui est assez proche du minimum de f .

On déduit donc de (*) que

$$\begin{aligned}\forall n > \max\{K_0, N_1\}, \quad 0 \leq \frac{u_n}{n} &\leq f(k_0) = \frac{\lfloor n\sqrt{\varepsilon} \rfloor}{n} + n \frac{\varepsilon}{\lfloor n\sqrt{\varepsilon} \rfloor} \\ &\leq \frac{n\sqrt{\varepsilon} + 1}{n} + n \frac{\varepsilon}{n\sqrt{\varepsilon}} \leq \frac{1}{n} + 2\sqrt{\varepsilon}.\end{aligned}$$

Comme la suite de terme général $1/n$ tend vers 0, il existe un rang $N_1 \in \mathbb{N}$ tel que

$$\forall n \geq N_2, \quad \frac{1}{n} \leq \eta.$$

Finalement, en posant $N_0 = \min\{K_0, N_1, N_2\} \in \mathbb{N}$,

$$\forall n > N_0, \quad 0 \leq \frac{u_n}{n} \leq 3\eta$$

et nous avons bien démontré que

$$\lim_{n \rightarrow +\infty} \frac{u_n}{n} = 0.$$