

# PROBABILITÉS ET STATISTIQUES

## COMMENTAIRES

Bien que les trois parties du problème puissent, pour l'essentiel, être traitées séparément, il est conseillé de les traiter dans l'ordre de l'énoncé.

## NOTATIONS

Dans tout le problème,  $P(\Theta)$  désigne la probabilité d'un événement  $\Theta$ . Si  $(\Omega, E, P)$  est un espace de probabilité, on dira que l'espace de probabilité  $(\Omega', E', P')$  est un espace de probabilité *agrandi* à partir de  $(\Omega, E, P)$ , si  $\Omega \subset \Omega'$ ,  $E \subset E'$ , et si la restriction  $P'|_E$  de la probabilité  $P'$  à  $E$  coïncide avec  $P$ . On notera alors  $P' = P$  par abus de langage.

On désignera respectivement par  $E(X)$  et  $V(X)$  l'espérance et la variance d'une variable aléatoire  $X$ . La loi de probabilité (ou la distribution) de  $X$  sera désignée par  $L(X)$ .

Le logarithme népérien de  $x$  est noté  $\ln x$ . On pose de même  $\ln \ln x = \ln(\ln x)$ .

## PREMIÈRE PARTIE

Soient  $U$  et  $V$  deux variables aléatoires à valeurs dans  $\mathbb{N} = \{0, 1, 2, \dots\}$ . On définit la *distance en variation* entre les lois  $L(U)$  de  $U$  et  $L(V)$  de  $V$  par :

$$d(L(U), L(V)) = \sup_{D \subset \mathbb{N}} |P(U \in D) - P(V \in D)|$$

On note  $A, B, C$  la partition de  $\mathbb{N}$  définie par :

$$A = \{k : k \in \mathbb{N}, P(U = k) < P(V = k)\}$$

$$B = \{k : k \in \mathbb{N}, P(U = k) = P(V = k)\}$$

$$C = \{k : k \in \mathbb{N}, P(U = k) > P(V = k)\}$$

1° Établir les identités :

$$d(L(U), L(V)) = \frac{1}{2} \sum_{k=0}^{+\infty} |P(U = k) - P(V = k)| = 1 - \sum_{k=0}^{+\infty} \min\{P(U = k), P(V = k)\}$$

2° On suppose que  $U$  et  $V$  sont définies simultanément sur le même espace de probabilités. Montrer que :

$$d(L(U), L(V)) \leq P(U \neq V)$$

3° On pose :

$$p_{kk} = \min\{P(U = k), P(V = k)\}, \quad k \in \mathbb{N},$$

$$p_{kl} = 0 \quad \text{si } k \neq l, \quad \text{avec } (k, l) \in (A \times \mathbb{N}) \cup (B \times \mathbb{N}) \cup (\mathbb{N} \times B) \cup (\mathbb{N} \times C)$$

a. Soient deux mesures de probabilités  $P'$  sur  $\Omega' = \{1, \dots, I\}$ , et  $P''$  sur  $\Omega'' = \{1, \dots, J\}$ . On pose :

$$P_i = P'(i), \quad Q_j = P''(j), \quad \text{et} \quad R_{ij} = P_i Q_j, \\ 1 \leq i \leq I, \quad 1 \leq j \leq J.$$

Vérifier que  $R(i, j) = R_{ij}$  définit une mesure de probabilité sur l'ensemble produit  $\Omega' \times \Omega''$ , de marges  $P'$  et  $P''$ .

b. Montrer qu'il est possible de définir  $p_{kl}$  pour  $k \neq l$  avec  $(k, l) \in (\mathbb{C} \times \mathbb{A})$ , de manière que :

$$\text{— pour tout } k \in \mathbb{N}, \quad \sum_{j=0}^{+\infty} p_{kj} = P(U = k),$$

$$\text{— pour tout } l \in \mathbb{N}, \quad \sum_{i=0}^{+\infty} p_{il} = P(V = l),$$

$$\text{— pour tout } k \in \mathbb{N} \text{ et pour tout } l \in \mathbb{N}, \quad p_{kl} \geq 0.$$

c. En déduire qu'il existe toujours un espace de probabilité sur lequel  $U$  et  $V$ , de lois  $L(U)$  et  $L(V)$  données sont définies simultanément, de manière que :

$$d(L(U), L(V)) = P(U \neq V)$$

On dira d'une loi jointe de  $U$  et  $V$  satisfaisant l'égalité ci-dessus qu'elle définit un *couplage maximal* de  $U$  et  $V$ .

4° On considère dans cette question le cas particulier où :

— la loi  $L(U)$  de  $U$  est une loi de Bernoulli :

$$P(U = 1) = 1 - P(U = 0) = p \in (0, 1)$$

où en général on désigne par  $(\alpha, \beta)$  l'intervalle ouvert d'extrémités  $\alpha$  et  $\beta$ .

— la loi  $L(V)$  de  $V$  est une loi de Poisson d'espérance  $E(V) = p \in (0, 1)$  :

$$P(V = r) = \frac{p^r}{r!} e^{-p}, \quad r = 0, 1, 2, \dots$$

a. Évaluer  $d(L(U), L(V))$  en fonction de  $p$ . On exprimera le résultat par une expression ne faisant intervenir ni sommation infinie, ni valeur absolue, et exprimée en fonction de  $p$  et  $e^{-p}$ .

b. Montrer qu'il est possible de définir simultanément  $U$  et  $V$  sur le même espace de probabilités, conjointement à une variable aléatoire  $W$ , de manière que  $U$  et  $W$  soient indépendants et que  $V = WU$ . Déterminer la loi de  $W$  et prouver qu'une telle construction établit un couplage maximal de  $U$  et  $V$ .

5° On considère maintenant une suite  $X_1, X_2, \dots, X_n$  de variables aléatoires indépendantes de Bernoulli, telles que, pour  $i = 1, 2, \dots, n$ ,

$$P(X_i = 1) = 1 - P(X_i = 0) = p_i \in (0, 1)$$

On pose  $S_n = X_1 + \dots + X_n$ .

Parallèlement, on considère une suite  $Y_1, Y_2, \dots, Y_n$  de variables aléatoires indépendantes de Poisson, telles que, pour  $i = 1, 2, \dots, n$ ,

$$P(Y_i = r) = \frac{p_i^r}{r!} e^{-p_i}, \quad r = 0, 1, 2, \dots$$

On pose  $T_n = Y_1 + \dots + Y_n$ .

a. Quelle est la distribution de  $T_n$  ?

b. Établir les inégalités (indication : on pourra utiliser la construction du 4<sup>o</sup>, b) :

$$d(L(S_n), L(T_n)) \leq 1 - \prod_{i=1}^n (1 - d(L(X_i), L(Y_i))) \leq \sum_{i=1}^n p_i^2.$$

## DEUXIÈME PARTIE

Dans toute cette partie, on considère une suite infinie de variables aléatoires de Bernoulli indépendantes  $X_1, X_2, \dots$ , telles que :

$$P(X_i = 1) = 1 - P(X_i = 0) = \frac{1}{i}, \quad i = 1, 2, \dots$$

On notera  $\iota = \sqrt{-1}$  le nombre complexe de module 1 et d'argument  $\frac{\pi}{2}$ .

On pose  $S_0 = 0$ ,  $S_n = X_1 + \dots + X_n$ ,  $n = 1, 2, \dots$ ,

$$N(m, n) = S_n - S_m, \quad 0 \leq m \leq n < \infty$$

On admettra que la limite :

$$\lim_{n \rightarrow \infty} \left( 1 + \frac{1}{2} + \frac{1}{3} + \dots + \frac{1}{n} - \ln n \right) = \gamma$$

existe et est finie, ainsi que la formule :

$$\sum_{n=1}^{+\infty} \frac{1}{n^2} = \frac{\pi^2}{6}$$

1<sup>o</sup> Montrer que :

$$\lim_{N \rightarrow \infty} \left\{ \sup_{N \leq m \leq n} \left| E(N(m, n)) - \ln \frac{n}{m} \right| \right\} = \lim_{N \rightarrow \infty} \left\{ \sup_{N \leq m \leq n} \left| V(N(m, n)) - \ln \frac{n}{m} \right| \right\} = 0$$

2<sup>o</sup> On désigne par  $[u]$  la partie entière de  $u$  ( $[u] \leq u < [u] + 1$ ).

On pose :

$$M_T(s, t) = N([T e^s], [T e^t]), \quad 0 \leq s \leq t, \quad T > 0$$

a. Évaluer la fonction caractéristique  $E(\exp(\iota u N(m, n)))$  de  $N(m, n)$ . En déduire :

$$\lim_{T \rightarrow \infty} E(\exp(\iota u M_T(s, t)))$$

b. Montrer que, pour tout  $k$ -uplet  $0 \leq s_1 < s_2 < \dots < s_k$  fixé, la loi limite jointe de  $M_T(s_1, s_2), M_T(s_2, s_3), \dots, M_T(s_{k-1}, s_k)$  lorsque  $T$  tend vers l'infini est un produit de lois de Poisson indépendantes, dont on précisera les paramètres.

c. Montrer que (indication : on pourra utiliser les fonctions caractéristiques) :

$$\lim_{n \rightarrow \infty} P\left(\frac{S_n - \ln n}{\sqrt{\ln n}} < t\right) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^t e^{-v^2/2} dv$$

d. Évaluer :

$$\lim_{n \rightarrow \infty} \{ E(S_n) - \ln n \}, \text{ et } \lim_{n \rightarrow \infty} \{ V(S_n) - \ln n \}$$

3° a. Montrer, en se servant des résultats obtenus dans la première partie, qu'il existe une suite de variables aléatoires  $Y_1, Y_2, \dots$  construites sur le même espace de probabilité que  $X_1, X_2, \dots$ , éventuellement agrandi, et telles que :

— pour tout  $i = 1, 2, \dots$ ,  $Y_i$  suit une loi de Poisson d'espérance  $1/i$ ;

— pour tout  $i = 1, 2, \dots$ , on a :

$$d(L(X_i), L(Y_i)) = P(X_i \neq Y_i) \leq \frac{1}{i^2}$$

b. On pose  $T_n = Y_1 + \dots + Y_n$ . Quelle est la loi de  $T_n$  ?

Montrer que la limite :

$$\lim_{n \rightarrow \infty} \{ S_n - T_n \}$$

existe et est finie presque sûrement.

4° a. On considère trois variables aléatoires  $\xi, \eta$  et  $\zeta$ , telles que :

— pour  $r = 0, 1, 2, \dots$ ,  $P(\zeta = r) = \frac{\alpha^r}{r!} e^{-\alpha}$ , où  $\alpha > 0$  est un nombre fixé;

— on a  $\xi \geq 0, \eta \geq 0, \xi + \eta = \zeta$ , la loi conditionnelle de  $\xi$  et  $\eta$  sachant  $\zeta$  étant donnée par :

$$P(\xi = m, \eta = r - m | \zeta = r) = \binom{r}{m} \theta^m (1 - \theta)^{r-m}, \quad m = 0, 1, \dots, r$$

où  $\theta \in (0, 1)$  est un paramètre fixé.

Déterminer la loi jointe de  $\xi$  et  $\eta$ .

b. En déduire qu'il est possible de construire sur le même espace de probabilité les suites  $X_1, X_2, \dots$ , et  $Y_1, Y_2, \dots$ , ainsi qu'une suite de variables aléatoires indépendantes  $Z_1, Z_2, \dots$ , de même loi de Poisson d'espérance 1, de telle manière que :

— pour tout  $n = 1, 2, \dots$ , si  $l(n) = \left[ 1 + \frac{1}{2} + \dots + \frac{1}{n} \right]$ , alors :

$$\sum_{i=1}^{l(n)} Z_i \leq T_n \leq \sum_{i=1}^{l(n)+1} Z_i$$

— pour tout  $n = 1, 2, \dots$ ,  $T_n - \sum_{i=1}^{l(n)} Z_i$  suit une loi de Poisson d'espérance  $1 + \frac{1}{2} + \dots + \frac{1}{n} - l(n)$ ,

et est une variable aléatoire indépendante de  $Y_{n+1}, Y_{n+2}, \dots$

c. Montrer que :

$$\lim_{n \rightarrow \infty} \frac{S_n}{\ln n} = 1 \text{ presque sûrement.}$$

### TROISIÈME PARTIE

Dans cette partie, on considère une suite  $\omega_1, \omega_2, \dots, \omega_n$  de variables aléatoires indépendantes et uniformément distribuées sur l'intervalle  $(0, 1)$ .

1° Montrer qu'avec probabilité un, pour tout  $n = 2, 3, \dots$ ,  $\omega_1, \dots, \omega_n$  sont distincts. En déduire que la statistique ordonnée :

$$\omega_{1,n} < \omega_{2,n} < \dots < \omega_{n,n}$$

obtenue en rangeant  $\omega_1, \dots, \omega_n$  par ordre croissant, est définie de manière unique presque sûrement.

2° Soit  $t \in (0, 1)$  fixé, et soit  $D_n(t)$  le nombre de variables parmi  $\omega_1, \dots, \omega_n$ , inférieures ou égales à  $t$ .

a. Pour  $i = 0, 1, \dots, n$ , déterminer  $P(D_n(t) = i)$ .

b. En déduire, pour  $i = 1, \dots, n$ ,  $P(\omega_{i,n} \leq t)$ .

c. Montrer que cette probabilité peut s'écrire sous la forme :

$$P(\omega_{i,n} \leq t) = \frac{1}{\beta(u, v)} \int_0^t x^{u-1} (1-x)^{v-1} dx \quad t \in (0, 1)$$

où :

$$\beta(u, v) = \int_0^1 x^{u-1} (1-x)^{v-1} dx$$

et où  $u$  et  $v$  sont des paramètres dont on précisera les valeurs, en fonction de  $i$  et  $n$ . On admettra que, pour  $j, k$  entiers,

$$\beta(j, k) = (k-1)!(j-1)! / (k+j-1)!$$

3° a. Montrer que, pour tout  $n = 1, 2, \dots$ , l'identité :

$$\omega_i = \omega_{r_{i,n}, n} \quad , \quad i = 1, \dots, n$$

définit presque sûrement une permutation  $r = \{r_{1,n}, \dots, r_{n,n}\}$  de  $\{1, \dots, n\}$ .

b. Vérifier que, pour  $r = \{r_{1,n}, \dots, r_{n,n}\}$  donné, la correspondance entre  $\{\omega_1, \dots, \omega_n\}$  et  $\{\omega_{1,n}, \dots, \omega_{n,n}\}$  est biunivoque et de jacobien unité si  $\omega_{1,n} < \dots < \omega_{n,n}$ .

En déduire que la densité jointe de  $\{\omega_{1,n}, \dots, \omega_{n,n}\}$  est  $n!$  sur l'ensemble  $\{(x_1, \dots, x_n) : 0 < x_1 < \dots < x_n < 1\}$ .

c. En déduire que  $r = \{r_{1,n}, \dots, r_{n,n}\}$  est indépendant de  $\{\omega_{1,n}, \dots, \omega_{n,n}\}$  et équidistribué sur l'ensemble de toutes les permutations de  $\{1, \dots, n\}$ .

4° On pose désormais  $R(n) = r_{n,n}$ , c'est-à-dire  $R(1) = 1$  et, pour  $n \geq 2$  :

$$R(n) = \begin{cases} 1 & \text{si } \omega_n < \omega_{1, n-1}, \\ i & \text{si } \omega_{i-1, n-1} < \omega_n < \omega_{i, n-1}, \quad i = 2, 3, \dots, n-1, \\ n & \text{si } \omega_n > \omega_{n-1, n-1}. \end{cases}$$

a. Montrer que la suite  $\{R(n), n \geq 1\}$  est définie presque sûrement.

b. Déterminer la probabilité conditionnelle  $P(R(n) \leq i \mid \omega_{i, n-1} = t)$ .

En déduire  $P(R(n) \leq i)$ , puis  $P(R(n) = i)$ ,  $i = 1, \dots, n$ . Montrer que :

$$P(R(n) = n) = \frac{1}{n}, \quad n = 1, 2, \dots$$

c. Montrer que la suite  $\{R(n), n \geq 1\}$  est une suite de variables aléatoires indépendantes.

5° Pour  $n = 2, 3, \dots$ , on pose  $X_n = 1$  si  $\omega_n \geq \max\{\omega_1, \dots, \omega_{n-1}\}$  et  $X_n = 0$  autrement. On pose  $X_1 = 1$ . Lorsque  $X_n = 1$ , on dit que  $\omega_n$  est un *record* (sous-entendu de la suite  $\omega_1, \omega_2, \dots$ ), et que l'indice  $n$  correspondant est un *temps de record*.

a. Soit  $N(n, kn) = \sum_{i=n+1}^{kn} X_i$  le nombre de records observés dans l'intervalle  $i \in \{n+1, \dots, kn\}$ . En se servant des résultats de la première et de la deuxième partie, évaluer la loi limite de  $N(n, kn)$  lorsque  $n$  tend vers l'infini. En particulier, déterminer :

$$\lim_{n \rightarrow \infty} P(N(n, kn) = r), \quad r = 0, 1, 2, \dots$$

NOTA BENE :  $k$  est ici un nombre entier fixé.

b. Établir les inégalités, pour  $0 < \theta < N$ ,

$$\frac{\theta^N}{N!} e^{-\theta} \leq \sum_{r=N}^{+\infty} \frac{\theta^r}{r!} e^{-\theta} \leq \frac{\theta^N}{N!} e^{-\theta} \left\{ \frac{1}{1 - \frac{\theta}{N}} \right\}$$

c. En déduire que, pour tout  $\varepsilon > 0$ , il existe presque sûrement un indice  $n_\varepsilon$  tel que  $n \geq n_\varepsilon$  implique (pour  $k \geq 2$ , fixé à l'avance) :

$$N(n, kn) \leq \frac{(1 + \varepsilon) \ln n}{\ln \ln n}.$$

Indications : On rappelle la formule de Stirling :

$$n! = \left(\frac{n}{e}\right)^n \sqrt{2\pi n} (1 + o(1)), \quad n \rightarrow \infty$$

On pourra faire usage des résultats du 3° de la deuxième partie.

6° On utilise dans cette question la suite  $\{Z_n, n \geq 1\}$  construite au 4°, b de la deuxième partie, ainsi que les notations introduites dans cette question. On supposera par la suite que  $k \geq 3$  est fixé.

a. On donne les évaluations numériques suivantes :

$$0,577 < \gamma < 0,578, \quad 1,098 < \ln 3 < 1,099, \\ 0,693 < \ln 2 < 0,694$$

Montrer que, pour tout  $k \geq 3$ ,

$$1 \leq \liminf_{n \rightarrow \infty} \{l(kn) - l(n)\} \leq \limsup_{n \rightarrow \infty} \{l(kn) - l(n)\} \leq [\ln k] + 1$$

b. On pose, pour  $K \geq 1$ ,  $\tau_n = \sum_{i=n+1}^{n+K} Z_i$ ,  $n = 0, 1, 2, \dots$

Montrer que, indépendamment de  $K \geq 1$  fixé,

$$\limsup_{n \rightarrow \infty} \left\{ \frac{\ln \ln n}{\ln n} \right\} \tau_n = 1 \text{ presque sûrement.}$$

c. En déduire que, pour tout  $k \geq 3$  fixé,

$$\limsup_{n \rightarrow \infty} \left\{ \frac{\ln \ln n}{\ln n} \right\} N(n, kn) = 1 \text{ presque sûrement.}$$

d. Comment pourrait-on montrer que le résultat ci-dessus reste valable pour  $k = 2$  ?