

Exercice 1 : deux questions indépendantes

1. On considère les événements A : «l'étudiant **connaît** la réponse à la question posée» et J : «l'étudiant donne la **bonne réponse** à la question posée».

L'énoncé demande de calculer la probabilité conditionnelle : $P_J(A)$.

On dispose de $P(A) = q$ d'où $P(\bar{A}) = 1 - P(A) = 1 - q$.

Il est clair que $P_A(J) = 1$ car si l'étudiant connaît la réponse, il donnera la bonne réponse. Mais quand l'étudiant ne connaît pas la réponse, il choisit au hasard l'une des n réponses proposées et $P_{\bar{A}}(J) = \frac{1}{n}$.

Par définition, $P_J(A) = \frac{P(A \cap J)}{P(J)}$

Or d'après la formule des probabilités composées, $P(A \cap J) = P(A) P_A(J)$ et d'après la formule des probabilités totales,

$$P(J) = P(A \cap J) + P(\bar{A} \cap J) = P(A) P_A(J) + P(\bar{A}) P_{\bar{A}}(J)$$

$$\text{Donc } P_J(A) = \frac{P(A) P_A(J)}{P(A) P_A(J) + P(\bar{A}) P_{\bar{A}}(J)} = \frac{q \times 1}{q \times 1 + (1 - q) \frac{1}{n}}$$

$$\text{Finalement } \boxed{P_J(A) = \frac{nq}{1 + (n-1)q}}$$

2. Un QCM d'examen comporte 10 questions indépendantes. 1600 étudiants passent cet examen. Chaque étudiant a 1 chance sur 3 de répondre correctement à chacune des 10 questions posées et répond à toutes les questions.

Soit X la variable aléatoire égale au nombre de bonnes réponses obtenues pour un étudiant à ce QCM.

(a) X suit la loi binomiale de paramètres $n_1 = 10$ et $p = 1/3$.

(b) Posons $n = 1600$. La moyenne des notes obtenues par l'ensemble des 1600 étudiants est

$$\bar{X} = \frac{1}{n} \sum_{k=1}^n X_k \text{ où } X_k \text{ est la variable aléatoire qui représente le nombre de}$$

bonnes réponses obtenues par le k -ème étudiant.

Les variables aléatoires suivent la même loi de probabilité, on considère qu'elles sont mutuellement indépendantes. Elles admettent pour espérance $\mu = E(X_1) = 10/3$ et pour variance $\sigma^2 = n_1 p(1-p) = 20/9$.

Donc, d'après le théorème central limite, \bar{X} suit approximativement la loi normale $\mathcal{N}\left(\mu, \frac{\sigma}{\sqrt{n}}\right)$.

Soit U une variable aléatoire de loi normale centrée réduite $\mathcal{N}(0, 1)$.

$$5\% = P(\bar{X} \leq a) = P\left(\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq \frac{a - \mu}{\sigma/\sqrt{n}}\right) \approx P\left(U \leq \frac{a - \mu}{\sigma/\sqrt{n}}\right) = \Phi\left(\frac{a - \mu}{\sigma/\sqrt{n}}\right)$$

On est donc amené à résoudre l'équation d'inconnue a :

$$\Phi\left(\frac{a - \mu}{\sigma/\sqrt{n}}\right) = 0,05 \iff \frac{a - \mu}{\sigma/\sqrt{n}} = \Phi^{-1}(0,05)$$

$$\iff a = \mu + \frac{\sigma}{\sqrt{n}} \Phi^{-1}(0,05) \iff a = \frac{10}{3} + \frac{\sqrt{5}}{60} \Phi^{-1}(0,05)$$

Or $\Phi^{-1}(0,05) \approx -1,6449$. Par conséquent $a \approx 3,272$

Exercice 2 : indépendance de variables aléatoires

1. Chaque variable aléatoire X_k suit la loi uniforme sur l'intervalle $[0, 1]$. Sa fonction de répartition F est définie par :

$$F(x) = \begin{cases} 0 & \text{si } x < 0 \\ x & \text{si } 0 \leq x \leq 1 \\ 1 & \text{si } x > 1 \end{cases}$$

2. (a) Soit x un nombre réel.

$$Y_n \leq x \iff \max\{X_1, X_2, \dots, X_n\} \leq x \iff \forall k \in \llbracket 1, n \rrbracket, X_k \leq x.$$

$$\text{Donc } [Y_n \leq x] = \bigcap_{k=1}^n [X_k \leq x]$$

- (b) Soit x un nombre réel.

$$G_n(x) = P([Y_n \leq x]) = P\left(\bigcap_{k=1}^n [X_k \leq x]\right) = \prod_{k=1}^n P([X_k \leq x]) \text{ car les variables aléatoires } X_k \text{ sont mutuellement indépendantes.}$$

$$\text{D'où } G_n(x) = \prod_{k=1}^n F(x) = F(x)^n = \begin{cases} 0 & \text{si } x < 0 \\ x^n & \text{si } 0 \leq x \leq 1 \\ 1 & \text{si } x > 1 \end{cases}$$

3. La fonction de répartition G_n de Y_n est continue sur \mathbb{R} , de classe \mathcal{C}^1 sur une partie de \mathbb{R} contenant $\mathbb{R} \setminus \{0, 1\}$ (en fait G_n est de classe \mathcal{C}^1 sur $\mathbb{R} \setminus \{1\}$ dès que $n \geq 2$). Donc Y_n est une variable aléatoire à densité, dont une densité g_n vérifie :

$$\forall t \in \mathbb{R} \setminus \{0, 1\}, g_n(t) = G'_n(t) = \begin{cases} 0 & \text{si } t < 0 \\ nt^{n-1} & \text{si } 0 < t < 1 \\ 0 & \text{si } t > 1 \end{cases}$$

On choisit de prendre $g_n(0) = 0$ et $g_n(1) = n$.

4. Comme la densité g_n est nulle en dehors du segment $[0, 1]$, Y_n admet une espérance mathématique égale à :

$$E(Y_n) = \int_0^1 t g_n(t) dt = n \int_0^1 t^n dt = n \left[\frac{t^{n+1}}{n+1} \right]_0^1 = n \frac{1^{n+1}}{n+1}$$

Donc $E(Y_n) = \frac{n}{n+1}$

5. Comme la densité g_n est nulle en dehors du segment $[0, 1]$, Y_n admet un moment d'ordre 2 et une variance. D'après la formule de König-Huyghens,

$$\begin{aligned} V(Y_n) &= E(Y_n^2) - E(Y_n)^2 = \int_0^1 t^2 g_n(t) dt - E(Y_n)^2 \\ &= n \int_0^1 t^{n+1} dt - E(Y_n)^2 = n \left[\frac{t^{n+2}}{n+2} \right]_0^1 - E(Y_n)^2 \\ &= \frac{n}{n+2} - \frac{n^2}{(n+1)^2} = \frac{n(n+1)^2 - n^2(n+2)}{(n+2)(n+1)^2} = \frac{n[(n+1)^2 - n(n+2)]}{(n+2)(n+1)^2} \end{aligned}$$

$$\text{Ainsi } V(Y_n) = \frac{n[n^2 + 2n + 1 - n^2 - 2n]}{(n+2)(n+1)^2} = \frac{n}{(n+1)^2(n+2)}.$$

Exercice 3 : estimation par intervalle de confiance

$(X_n)_{n \in \mathbb{N}^*}$ est une suite de variables aléatoires mutuellement indépendantes qui suivent toutes la loi exponentielle de paramètre $\lambda > 0$.

On pose pour tout entier $n \geq 3$, $S_n = \sum_{k=1}^n X_k$; $J_n = \lambda S_n$ et $T_n = \frac{n}{S_n}$.

1. On a $E(S_n) = \sum_{k=1}^n E(X_k) = n/\lambda$, et $V(S_n) = \sum_{k=1}^n V(X_k) = n/\lambda^2$ par indépendance.

$$E(J_n) = \lambda E(S_n) = n \text{ et } V(J_n) = \lambda^2 V(S_n) = n$$

2. (a) T_n est une fonction du n -échantillon. Donc c'est un estimateur de λ .

$$T_n = \lambda \frac{n}{\lambda S_n} = \lambda n \frac{1}{J_n} \text{ donc } E(T_n) = \lambda n E\left(\frac{1}{J_n}\right) = \lambda n \frac{1}{n-1} \neq \lambda$$

Conclusion : T_n est biaisé.

$$\text{Mais } E(T_n) = \frac{n}{n-1} \lambda = \frac{1}{1-1/n} \lambda \xrightarrow{(n \rightarrow +\infty)} \lambda$$

Donc T_n est asymptotiquement sans biais.

- (b) Le risque quadratique associé à T_n est

$$r(T_n) = V(T_n) + b(T_n)^2 = V(T_n) + (E(T_n) - \lambda)^2$$

$$\text{Or } V(T_n) = V\left(\lambda n \frac{1}{J_n}\right) = \lambda^2 n^2 V\left(\frac{1}{J_n}\right)$$

avec

$$\begin{aligned} V\left(\frac{1}{J_n}\right) &= E\left(\frac{1}{J_n^2}\right) - E\left(\frac{1}{J_n}\right)^2 = \frac{1}{(n-1)(n-2)} - \frac{1}{(n-1)^2} \\ &= \frac{1}{(n-1)^2(n-2)} \end{aligned}$$

$$V(T_n) = \frac{\lambda^2 n^2}{(n-1)^2(n-2)}$$

Donc le risque quadratique est

$$\begin{aligned} r(T_n) &= V(T_n) + \left(\frac{n}{n-1} \lambda - \lambda\right)^2 \\ &= \frac{\lambda^2 n^2}{(n-1)^2(n-2)} + \left(\frac{\lambda}{n-1}\right)^2 \\ &= \frac{\lambda^2 (n^2 + n - 2)}{(n-1)^2(n-2)} = \frac{\lambda^2 (n-1)(n+2)}{(n-1)^2(n-2)} \\ &= \frac{\lambda^2 (n+2)}{(n-1)(n-2)} \end{aligned}$$

- (c) $r(T_n) = \frac{n+2}{n^2-3n+2} \lambda^2 \underset{(n \rightarrow +\infty)}{\sim} \frac{n}{n^2} \lambda^2 = \frac{\lambda^2}{n}$ avec $\lim_{n \rightarrow +\infty} \frac{\lambda^2}{n} = 0$.

Par conséquent $\lim_{n \rightarrow +\infty} r(T_n) = 0$ le risque quadratique de T_n tend vers 0 quand n tend vers $+\infty$.

3. (a) Selon le théorème de la limite centrée, étant donnée une suite de variables aléatoires (X_n) mutuellement indépendantes, de même loi et de variance non nulle, la somme centrée réduite des n premiers termes converge en loi vers une variable aléatoire U de loi normale $\mathcal{N}(0, 1)$.

C'est-à-dire que la fonction de répartition de la somme centrée réduite tend vers Φ .

On a vu que $S_n = \sum_{k=1}^n X_k$ avait pour espérance $\frac{n}{\lambda}$ et pour variance $\frac{n}{\lambda^2}$

Les $(X_k)_{k \in N^*}$ sont indépendantes et ont une variance non nulle. Donc la centrée réduite $\frac{S_n - \frac{n}{\lambda}}{\frac{\sqrt{n}}{\lambda}} = \frac{\lambda S_n - n}{\sqrt{n}} = \frac{\lambda S_n}{\sqrt{n}} - \sqrt{n} = S_n^*$ converge en loi vers

U de loi normale centrée réduite.

(b) Donc, pour n assez grand (en général $n > 50$),

$$\begin{aligned} P(-t_\alpha \leq S_n^* \leq t_\alpha) &\simeq P(-t_\alpha \leq U \leq t_\alpha) \\ &= \Phi(t_\alpha) - \Phi(-t_\alpha) \\ &= \Phi(t_\alpha) - [1 - \Phi(t_\alpha)] \\ &= 2\Phi(t_\alpha) - 1 \\ &= 2\left(1 - \frac{\alpha}{2}\right) - 1 = 1 - \alpha \end{aligned}$$

(c) On résout : $\lambda \in \left[\left(1 - \frac{t_\alpha}{\sqrt{n}}\right) T_n, \left(1 + \frac{t_\alpha}{\sqrt{n}}\right) T_n \right]$

$$\Leftrightarrow \left(1 - \frac{t_\alpha}{\sqrt{n}}\right) \frac{n}{S_n} \leq \lambda \leq \left(1 + \frac{t_\alpha}{\sqrt{n}}\right) \frac{n}{S_n}$$

$$\Leftrightarrow n \left(1 - \frac{t_\alpha}{\sqrt{n}}\right) \leq \lambda S_n \leq n \left(1 + \frac{t_\alpha}{\sqrt{n}}\right)$$

$$\Leftrightarrow \sqrt{n} \left(1 - \frac{t_\alpha}{\sqrt{n}}\right) \leq \frac{\lambda S_n}{\sqrt{n}} \leq \sqrt{n} \left(1 + \frac{t_\alpha}{\sqrt{n}}\right)$$

$$\Leftrightarrow \sqrt{n} - t_\alpha \leq \frac{\lambda S_n}{\sqrt{n}} \leq \sqrt{n} + t_\alpha$$

$$\Leftrightarrow -t_\alpha \leq \frac{\lambda S_n}{\sqrt{n}} - \sqrt{n} \leq t_\alpha$$

$$\Leftrightarrow -t_\alpha \leq S_n^* \leq t_\alpha$$

$$\text{Donc } P\left(\lambda \in \left[\left(1 - \frac{t_\alpha}{\sqrt{n}}\right) T_n, \left(1 + \frac{t_\alpha}{\sqrt{n}}\right) T_n\right]\right) = P(-t_\alpha \leq S_n^* \leq t_\alpha) \simeq 1 - \alpha$$

Ainsi $\left[\left(1 - \frac{t_\alpha}{\sqrt{n}}\right) T_n, \left(1 + \frac{t_\alpha}{\sqrt{n}}\right) T_n\right]$ est un intervalle de confiance **aléatoire** pour λ au niveau de risque α quand n est grand.

4. La commande `sum(grand(1,100, "exp", 1/lambda))` renvoie 14.646

$$(a) t_\alpha = \Phi^{-1}\left(1 - \frac{\alpha}{2}\right) = \Phi^{-1}(0.975).$$

Avec la calculatrice ou la commande `cdfnor("X",0,1,1-0.05/2,0.05/2)` sur SCILAB, on obtient : $t_\alpha \approx 1.959964 \approx 1.96$

(b) Avec l'échantillon observé où $n = 100$, une réalisation de T_n est :

$$T_n(\omega) = \frac{n}{\sum_{k=1}^n x_k} = \frac{100}{14.646}$$

Donc un intervalle de confiance **observé** pour λ au niveau de confiance 95% est :

$$I_{95\%,obs} = \left[\left(1 - \frac{t_\alpha}{10}\right) \frac{100}{14.646}, \left(1 + \frac{t_\alpha}{10}\right) \frac{100}{14.646} \right] = [5.489, 8.166]$$