

CONTRÔLE

La calculatrice et les documents sont autorisés. Toutes vos réponses doivent être soigneusement rédigées. Le barème est donné à titre indicatif

Exercice 1 (3 points)

Un joueur lance un dé. S'il obtient un 6 il gagne 8 euros. Sinon, il perd 2 euros.

- Calculer l'espérance de gain du joueur.

$$E = 8 \times \frac{1}{6} + (-2) \times \frac{5}{6} = -\frac{1}{3}.$$

On propose au joueur d'acheter pour n euros un deuxième dé avant de jouer. Il peut dans ce cas lancer les deux dés. Les gains sont les mêmes : 8 euros s'il obtient au moins un 6, et -2 euros sinon.

- Pour quelles valeurs de n cet achat rend-il le jeu plus avantageux ?

Calculons l'espérance de gain de ce second jeu : il a 11 chances sur 36 d'obtenir au moins un 6.

$$E' = 8 \times \frac{11}{36} + (-2) \times \frac{25}{36} = \frac{38}{36}.$$

Mais pour comparer avec le premier jeu, il faut tenir compte de l'achat du dé. Ce jeu est plus favorable si $\frac{38}{36} - n \geq -\frac{1}{3}$. Le jeu est donc plus avantageux pour $n < \frac{50}{36} \approx 1,39$ euros.

Exercice 2 : loi de Pareto (10 points)

Soit $k > 1$. La loi de Pareto de paramètre k , notée $\mathcal{P}ar(k)$, est donnée par la densité de probabilité f nulle sur $] -\infty, 1[$ et définie sur $[1, +\infty[$ par

$$f(x) = \frac{k}{x^{k+1}}.$$

Soit $X \sim \mathcal{P}ar(k)$.

- (a) Vérifier que f est bien une densité de probabilité.

$$f \text{ est une fonction positive et } \int_{-\infty}^{+\infty} f(x)dx = \int_1^{+\infty} \frac{k}{x^{k+1}}dx = \left[-\frac{1}{x^k}\right]_1^{+\infty} = 1.$$

- (b) Calculer l'espérance de X .

$$E[X] = \int_{-\infty}^{+\infty} xf(x)dx = \int_1^{+\infty} \frac{k}{x^k}dx = \left[-\frac{k}{(k-1)x^{k-1}}\right]_1^{+\infty} = \frac{k}{k-1}.$$

(On rappelle que $k > 1$.)

(c) Soit $a > 1$. Calculer $\mathbf{P}(X > a)$.

$$\mathbf{P}(X > a) = \int_a^{+\infty} \frac{k}{x^{k+1}} dx = \left[-\frac{1}{x^k}\right]_a^{+\infty} = \frac{1}{a^k}.$$

(d) Déterminer la médiane de X , c'est-à-dire la valeur m telle que $\mathbf{P}(X < m) = \mathbf{P}(X > m)$.

On cherche donc m tel que $\mathbf{P}(X > a) = \frac{1}{2}$. Donc $\frac{1}{m^k} = \frac{1}{2}$ et $m = 2^{\frac{1}{k}}$.

(e) Soit $b > 1$. Calculer $\mathbf{P}(X > a + b | X > a)$. Montrer que cette probabilité croît avec a .

$$\mathbf{P}(X > a+b | X > a) = \frac{\mathbf{P}(X > a+b \cap X > a)}{\mathbf{P}(X > a)} = \frac{\mathbf{P}(X > a+b)}{\mathbf{P}(X > a)} = \frac{a^k}{(a+b)^k} = \left(\frac{a}{a+b}\right)^k.$$

La fonction $a \mapsto \frac{a}{a+b}$ est croissante puisque sa dérivée $\frac{b}{(a+b)^2}$ est positive. Donc comme $k > 1$, $\left(\frac{a}{a+b}\right)^k$ est croissante avec a .

(f) Si X représente une durée de vie, comment peut-on interpréter ce résultat ?

On a calculé la probabilité qu'ayant vécu un temps a , on vive un temps b supplémentaire. la croissance de cette probabilité avec a signifie donc que plus on a vécu longtemps, plus la probabilité de vivre un temps b supplémentaire est élevée. Autrement dit, le temps passé ne fait qu'augmenter le temps qu'on peut espérer vivre encore. On peut dire que le système rajeunit.

2. (a) Posons $Y = \ln(X)$. Montrer que Y suit la loi exponentielle de paramètre k .

Cherchons la fonction de répartition de Y . Soit $x > 0$.

$$F_Y(x) = \mathbf{P}(Y \leq x) = \mathbf{P}(\ln(X) \leq x) = \mathbf{P}(X \leq e^x) = 1 - \frac{1}{(e^x)^k} = 1 - e^{-kx}.$$

Sa densité est donc donnée par la dérivée de cette fonction :

$$f_Y(x) = F'_Y(x) = ke^{-kx}.$$

On reconnaît la densité de la loi exponentielle de paramètre k .

(b) Soit $n \geq 30$. Écrire le théorème central limite pour n tirages Y_j indépendants de la variable Y . L'espérance de Y est $1/k$ et sa variance $1/k^2$. On peut donc écrire le théorème central limite :

$$\frac{\sum_{j=1}^n Y_j - n/k}{\sqrt{n}/k} = \frac{1}{\sqrt{n}}(k \sum_{j=1}^n Y_j - n) \sim \mathcal{N}(0, 1).$$

(c) On dispose d'un échantillon de 50 valeurs de la variable X tirées indépendamment. On souhaite estimer la valeur du paramètre k . On sait simplement que le produit des 50 valeurs vaut approximativement 500000.

Donner une estimation de k à l'aide de la variable Y .

Notons x_1, \dots, x_{50} les résultats des tirages. On sait que la moyenne de Y est $1/k$. Or $\ln(x_1), \dots, \ln(x_{50})$ constituent des tirages indépendants de la variable Y . Leur moyenne empirique fournit donc une estimation de $1/k$:

$$\frac{\ln(x_1) + \dots + \ln(x_{50})}{50} = \frac{\ln(x_1 x_2 \dots x_{50})}{50} \approx \frac{1}{k}.$$

On peut ainsi estimer k par

$$k \approx \frac{50}{\ln(500000)} \approx 3,81.$$

(d) Donner un intervalle de confiance à 95% pour k .

On utilise pour cela le théorème central limite. On sait que

$$\mathbf{P}(-1,96 < \frac{1}{\sqrt{50}}(k \sum_{j=1}^{50} Y_j - 50) < 1,96) \approx 0,95.$$

On dispose ici de $\sum_{j=1}^{50} Y_j = \ln(500000) \approx 13,12$. Donc k est situé dans l'intervalle de confiance à 95%

$$[(50 - \sqrt{501}, 96)/13,12; (50 + \sqrt{501}, 96)/13,12] = [2,75; 4,87].$$

Exercice 3 : Valeur moyenne d'un signal bruité (7 points)

On reçoit un signal f entre les instants $t = 0$ et $t = 1$ et on souhaite calculer sa valeur moyenne donnée par $\int_0^1 f(t)dt$. Le résultat ne sera pas exact pour deux raisons. Le signal a été échantillonné, l'intégrale sera donc approchée par la moyenne des valeurs observées et de plus le signal émis a été perturbé par la présence d'un bruit. Le but de cet exercice est de mesurer l'impact qu'a ce bruit sur l'exactitude du résultat obtenu.

On note f le signal émis et ε le bruit. Ces fonctions sont définies sur $[0,1]$. Le signal reçu est ainsi donné par $g = f + \varepsilon$. Le signal a été échantillonné avec un pas de $\frac{1}{n}$ avec $n \in \mathbf{N}^*$. On on a donc reçu les valeurs $g(\frac{k}{n})$ pour $k = 1 \dots n$. La valeur moyenne de f sera donc estimée par $\frac{1}{n} \sum_{k=1}^n g(\frac{k}{n})$. En l'absence de bruit, on sait que l'erreur commise pour la fonction f considérée aurait été donnée par $|\int_0^1 f(t)dt - \frac{1}{n} \sum_{k=1}^n f(\frac{k}{n})| < \frac{10}{n}$.

Le bruit ε est modélisé à l'aide de la loi normale. On suppose que les variables $X_k = \varepsilon(\frac{k}{n})$ pour $k = 1 \dots n$ sont des variables indépendantes de même loi $\mathcal{N}(0,1)$.

On prendra $n = 100$ comme fréquence d'échantillonnage (hormis dans les questions 3 et 4).

1. Appliquer le théorème central limite aux variables X_k .

Les X_k ont pour loi $\mathcal{N}(0,1)$. Elles sont donc d'espérance nulle et de variance 1. Comme elles sont de plus indépendantes et que $n = 100 > 30$, on peut appliquer le théorème central limite :

$$\frac{\sum_{k=1}^n X_k - 0}{1 \times \sqrt{n}} \text{ suit à peu près la loi } \mathcal{N}(0,1).$$

2. Déterminer la probabilité p que $|\frac{1}{n} \sum_{k=1}^n g(\frac{k}{n}) - \frac{1}{n} \sum_{k=1}^n f(\frac{k}{n})| < 0,1$.

$$|\frac{1}{n} \sum_{k=1}^n g(\frac{k}{n}) - \frac{1}{n} \sum_{k=1}^n f(\frac{k}{n})| = |\frac{1}{n} \sum_{k=1}^n \varepsilon(\frac{k}{n})| = |\frac{\sum_{k=1}^n X_k}{n}|. \text{ Ainsi}$$

$$p = \mathbf{P}(|\frac{\sum_{k=1}^n X_k}{n}| < 0,1) = \mathbf{P}(-0,1\sqrt{n} < \frac{\sum_{k=1}^n X_k}{\sqrt{n}} < 0,1\sqrt{n}) = \mathbf{P}(-1 < \frac{\sum_{k=1}^n X_k}{\sqrt{n}} < 1)$$

car $n = 100$. En utilisant le théorème central limite, on obtient

$$p \approx F_{\mathcal{N}}(1) - F_{\mathcal{N}}(-1) = 2F_{\mathcal{N}}(1) - 1 \approx 0,68.$$

3. Déterminer une valeur de n , c'est-à-dire une fréquence d'échantillonnage, telle que cette probabilité p soit de l'ordre de 0,99.

On prend n quelconque supérieur à 30. On a encore

$$p = \mathbf{P}(-0,1\sqrt{n} < \frac{\sum_{k=1}^n X_k}{\sqrt{n}} < 0,1\sqrt{n}) = 2F_{\mathcal{N}}(0,1\sqrt{n}) - 1.$$

On souhaite avoir $p = 0,99$. Il faut donc avoir $F_{\mathcal{N}}(0,1\sqrt{n}) = 0,995$. Ainsi, d'après les tables, $0,1\sqrt{n} = 2,58$. Donc $n = 665,64$. Il faut donc prendre au moins $n = 666$ pour que la probabilité que l'erreur soit supérieure à 10% soit inférieure à 1%.

4. Que peut-on alors dire de la précision de la valeur moyenne de f obtenue ?

Il y a deux erreurs commises dans le calcul de la valeur moyenne de f . On peut majorer l'erreur totale ainsi :

$$\left| \int_0^1 f - \frac{1}{n} \sum_{k=0}^n g\left(\frac{k}{n}\right) \right| \leq \left| \int_0^1 f - \frac{1}{n} \sum_{k=0}^n f\left(\frac{k}{n}\right) \right| + \left| \frac{1}{n} \sum_{k=0}^n f\left(\frac{k}{n}\right) - \frac{1}{n} \sum_{k=0}^n g\left(\frac{k}{n}\right) \right|$$

Pour $n = 666$, le premier terme est majoré par $10/666 \approx 0,015$ et le second par 0,1 avec un risque de 1%. L'erreur totale est donc majorée par 0,115. On constate que c'est le bruit qui est la principale cause d'erreur dans le calcul.

5. Si on ne peut pas augmenter la fréquence d'échantillonnage $n = 100$, on peut essayer de diminuer le bruit. Déterminer une valeur de l'écart-type σ telle que si le bruit est décrit par une loi normale $\mathcal{N}(0, \sigma^2)$, alors la probabilité p sera de l'ordre de 0,99.

On réécrit le théorème central limite pour $n = 100$:

$$\frac{\sum_{k=1}^{100} X_k}{10\sigma} \text{ suit à peu près la loi } \mathcal{N}(0, 1).$$

Ainsi $p = \mathbf{P}(-0,1 < \frac{\sum_{k=1}^{100} X_k}{10\sigma} < 0,1) = \mathbf{P}(-\frac{1}{\sigma} < \frac{\sum_{k=1}^{100} X_k}{10\sigma} < \frac{1}{\sigma})$. Pour avoir $p = 0,99$, il faut donc avoir $2F_{\mathcal{N}}(\frac{1}{\sigma}) - 1 = 0,99$. Donc $F_{\mathcal{N}}(\frac{1}{\sigma}) = 0,995$ et $\frac{1}{\sigma} \approx 2,58$. Il faut donc avoir un écart-type au plus égal à $\sigma = 0,39$.