

CONTRÔLE

*Les documents sont interdits, la calculatrice est autorisée.
Le barème est donné à titre indicatif.*

Exercice 1 : Combinaison de lois normales (6 points)

Une étude s'est intéressée à la quantité maximale de fumées toxiques (d'une certaine substance) que peuvent supporter les individus. Chez les femmes, ce seuil est modélisé par une variable X_f suivant la loi normale $\mathcal{N}(38, 9)$, et chez les hommes par X_h suivant la loi normale $\mathcal{N}(48, 9)$.

On prend un individu au hasard dans la population et on note X le seuil d'enfumage toxique qu'il peut supporter.

- Justifier que pour tout x ,

$$\mathbf{P}(X \leq x) = \frac{1}{2}\mathbf{P}(X_f \leq x) + \frac{1}{2}\mathbf{P}(X_h \leq x)$$

On fait l'hypothèse qu'il y a autant d'hommes que de femmes dans la population. Un individu pris au hasard a donc une probabilité $\frac{1}{2}$ d'être une femme et une probabilité $\frac{1}{2}$ d'être un homme. La situation se modélise simplement par un arbre à deux branches. La probabilité demandée se lit directement sur cet arbre :

$$\begin{aligned} \mathbf{P}(X \leq x) &= \mathbf{P}(\text{Femme}) \times \mathbf{P}(X \leq x \mid \text{Femme}) + \mathbf{P}(\text{Homme}) \times \mathbf{P}(X \leq x \mid \text{Homme}) \\ &= \frac{1}{2}\mathbf{P}(X_f \leq x) + \frac{1}{2}\mathbf{P}(X_h \leq x) \end{aligned}$$

- En déduire l'expression de la densité f_X de X .


Par définition, $\mathbf{P}(X_f \leq x) = F_f(x)$ où F_f désigne la fonction de répartition de la loi $\mathcal{N}(38, 9)$, et $\mathbf{P}(X_h \leq x) = F_h(x)$ où F_h désigne la fonction de répartition de la loi $\mathcal{N}(48, 9)$. L'égalité précédente se réécrit ainsi :

$$F_X(x) = \frac{1}{2}F_f(x) + \frac{1}{2}F_h(x)$$

Dérivons pour obtenir la densité de X :

$$f_X(x) = \frac{1}{2}f_f(x) + \frac{1}{2}f_h(x) = \frac{1}{6\sqrt{2\pi}}e^{-\frac{(x-38)^2}{18}} + \frac{1}{6\sqrt{2\pi}}e^{-\frac{(x-48)^2}{18}}.$$

Nous la représentons ci-dessous.



3. Estimer graphiquement l'espérance et l'écart-type de X .

Par symétrie de la densité, l'espérance de X est clairement égale à 43. L'écart-type est l'écart quadratique moyen à la moyenne. Il est de l'ordre de 5. (Sa valeur exacte est $\sqrt{34} \approx 5,8$.)

4. On observe une quantité d'enfumage de 36,7. On souhaite déterminer la part d'individus en danger.

Calculer à 10^{-2} près les probabilités $\mathbf{P}(X_f \leq 36,7)$, $\mathbf{P}(X_h \leq 36,7)$ et $\mathbf{P}(X \leq 36,7)$.

On se ramène à la loi normale centrée réduite : Comme $X_f \sim \mathcal{N}(38, 9)$, $\frac{X_f - 38}{3} \sim \mathcal{N}(0, 1)$ et de même, $\frac{X_h - 48}{3} \sim \mathcal{N}(0, 1)$. Alors

$$\mathbf{P}(X_f \leq 36,7) = \mathbf{P}\left(\frac{X_f - 38}{3} \leq \frac{36,7 - 38}{3}\right) = F_{\mathcal{N}}(-0,433) \approx 1 - 0,66 = 0,34.$$

$$\mathbf{P}(X_h \leq 36,7) = \mathbf{P}\left(\frac{X_h - 48}{3} \leq \frac{36,7 - 48}{3}\right) = F_{\mathcal{N}}(-3,77) \approx 0.$$

Finalement,

$$\mathbf{P}(X \leq 36,7) = \frac{1}{2} \times 0,34 + \frac{1}{2} \times 0 = 0,17.$$

5. En déduire simplement la quantité d'enfumage insupportable pour 83% de la population.

Nous cherchons a tel que $\mathbf{P}(X \leq a) = 0,83$, autrement dit $\mathbf{P}(X \geq a) = 0,17$.

En utilisant la symétrie de la densité de X , on peut se ramener au calcul précédent. L'espérance étant de 43, on a pour tout b , $\mathbf{P}(X \leq 43 - b) = \mathbf{P}(X \geq 43 + b)$. Ainsi, $\mathbf{P}(X \leq 36,7) = \mathbf{P}(X \geq 49,3) = 0,17$.

La quantité d'enfumage insupportable pour 83% de la population est donc de 49,3.

Exercice 2 : Produit de Pareto

On considère la loi de Pareto de densité définie sur $[1, +\infty[$ par

$$f(x) = \frac{1}{x^2}.$$

1. Étude de la loi (5 points)

Soit X une variable aléatoire suivant la loi de Pareto.

(a) Calculer l'espérance de X .

L'espérance de X est donnée par

$$\int_1^{+\infty} \frac{x}{x^2} dx = [\ln(x)]_1^{+\infty} = +\infty.$$

L'intégrale ci-dessus est divergente ; la variable X n'a pas d'espérance finie. C'est pour cette raison que l'on va plutôt s'intéresser ici à la médiane de X qui est elle finie.

(b) Déterminer la fonction de répartition de X .

Il s'agit de la primitive de f qui s'annule en 1. On trouve $F_X(x) = \int_1^x \frac{1}{t^2} dt = 1 - \frac{1}{x}$.

(c) Trouver la médiane de X , c'est-à-dire la valeur de m telle que $\mathbf{P}(X \leq m) = \frac{1}{2}$.

On cherche m tel que $F_X(m) = \frac{1}{2}$. On trouve $m = 2$.

(d) Soit $Z = \ln(X)$. Montrer que Z suit la loi exponentielle $\mathcal{E}(1)$.

Cherchons la fonction de répartition de Z qui est une variable à valeurs dans \mathbf{R}_+ . Soit $t \geq 0$.

$$F_Z(t) = \mathbf{P}(Z \leq t) = \mathbf{P}(X \leq e^t) = F_X(e^t) = 1 - e^{-t}.$$

La densité de Z est alors donnée par

$$f_Z(t) = F'_Z(t) = e^{-t}.$$

On reconnaît la densité d'une loi exponentielle. Ainsi $Z \sim \mathcal{E}(1)$.


2. Couple de variables (5 points)

Soient X et Y deux variables indépendantes suivant toutes les deux la loi de Pareto.

(a) Soit $P = XY$. Montrer que la fonction de répartition de P est définie par

$$\forall t \geq 1, \quad F_P(t) = 1 - \frac{1}{t} - \frac{\ln(t)}{t}.$$

Il s'agit d'un problème de couple de variables indépendantes. La variable P est à valeurs dans $[1, +\infty[$. Soit $t \geq 1$. On représente dans $[1, +\infty[\times [1, +\infty[$ l'ensemble $A = \{xy \leq t\}$ et on le paramètre.




$$A = \left\{ (x, y) \in \mathbf{R}^2 ; 1 \leq x \leq t \text{ et } 1 \leq y \leq \frac{t}{x} \right\}$$

Alors


$$\begin{aligned}
 F_P(t) &= \mathbf{P}(XY \leq t) = \mathbf{P}(Y \leq \frac{t}{X}) \\
 &= \int_{x=1}^t \int_{y=1}^{\frac{t}{x}} \frac{1}{x^2} \times \frac{1}{y^2} dy dx \\
 &= \int_{x=1}^t \frac{1}{x^2} \left[-\frac{1}{y} \right]_1^{\frac{t}{x}} dx \\
 &= \int_{x=1}^t \frac{1}{x^2} - \frac{1}{tx} dx \\
 &= \left[-\frac{1}{x} - \frac{\ln(x)}{t} \right]_1^t \\
 &= 1 - \frac{1}{t} - \frac{\ln(t)}{t}
 \end{aligned}$$

- (b) Nous donnons ci-contre le graphe de $t \mapsto \ln(t)$ pour $t \in [1, 7]$.
 Estimer la médiane de P , en utilisant ce graphe ou une calculatrice.



On cherche à résoudre l'équation $F_P(t) = \frac{1}{2}$. Cela revient à résoudre $\frac{\ln(t)}{t} = \frac{1}{2} - \frac{1}{t}$, ou encore $\ln(t) = \frac{t}{2} - 1$. Graphiquement, on peut tracer la droite d'équation $y = \frac{x}{2} - 1$ et déterminer le point où elle intersecte le graphe de \ln . On obtient que la médiane de P vaut approximativement 5,4.

Remarque : le graphe de \ln se prolonge entre 0 et 1. Il existe ainsi une seconde intersection entre la droite et son graphe autour de la valeur 0,46. C'est aussi une valeur qu'on peut obtenir avec la calculatrice. Elle n'a aucun sens pour notre problème puisqu'elle est inférieure à 1.



3. Théorème central limite (4 points)

Soit maintenant $n \geq 30$ et X_1, \dots, X_n des variables indépendantes suivant la loi de Pareto. On pose $P_n = \prod_{i=1}^n X_i$.

- (a) Peut-on appliquer le théorème central limite aux variables X_i ?

La loi de Pareto n'ayant pas d'espérance finie, on ne peut pas lui appliquer le théorème central limite.

- (b) Écrire le théorème central limite pour une somme de n variables indépendantes Z_i de même loi $\mathcal{E}(1)$.

La loi $\mathcal{E}(1)$ est d'espérance 1 et de variance 1. Le théorème central limite stipule que les variables $\frac{\sum_{i=1}^n Z_i - n \times 1}{\sqrt{1 \times n}} = \frac{\sum_{i=1}^n Z_i - n}{\sqrt{n}}$ convergent en loi vers la loi $\mathcal{N}(0, 1)$ lorsque n tend vers l'infini.

- (c) Déterminer ainsi la valeur de a pour laquelle $\mathbf{P}\left(\sum_{i=1}^n Z_i \leq a\right) \approx \frac{1}{2}$.

On considère que pour $n \geq 30$, $\frac{\sum_{i=1}^n Z_i - n}{\sqrt{n}} \sim \mathcal{N}(0, 1)$ à peu près. Pour cette loi normale, $F_{\mathcal{N}}(0) = \frac{1}{2}$. Ainsi, $\mathbf{P}\left(\frac{\sum_{i=1}^n Z_i - n}{\sqrt{n}} \leq 0\right) \approx \frac{1}{2}$. On en déduit que $\mathbf{P}\left(\sum_{i=1}^n Z_i \leq n\right) \approx \frac{1}{2}$, donc $a = n$.

- (d) En déduire, à l'aide de la question 1-d, une estimation de la médiane de P_n .

On cherche b tel que $\mathbf{P}(P_n \leq b) \approx \frac{1}{2}$. Passons au logarithme dans cette inégalité :

$$\prod_{i=1}^n X_i \leq b \Leftrightarrow \ln\left(\prod_{i=1}^n X_i\right) \leq \ln(b) \Leftrightarrow \sum_{i=1}^n \ln(X_i) \leq \ln(b).$$

Or, d'après la question 1-d, les variables $\ln(X_i)$ suivent la loi $\mathcal{E}(1)$. Comme les X_i sont indépendantes, les variables $\ln(X_i)$ le sont aussi. Ainsi, d'après la question précédente, $\mathbf{P}\left(\sum_{i=1}^n \ln(X_i) \leq n\right) \approx \frac{1}{2}$. Donc $\ln(b) = n$ et $b = e^n$.

Conclusion : lorsque n est très grand, la médiane de P_n est de l'ordre de e^n .

Formulaire de probabilités

Probabilités élémentaires

- Axiomes : (Ω, \mathbf{P}) espace probabilisé si $\mathbf{P}(\Omega) = 1$ et pour tous ensembles disjoints A_n ,

$$\mathbf{P}(\cup_{n=1}^{+\infty} A_n) = \sum_{n=1}^{+\infty} \mathbf{P}(A_n)$$

- Union : $\mathbf{P}(A \cup B) = \mathbf{P}(A) + \mathbf{P}(B) - \mathbf{P}(A \cap B)$
- Indépendance : $\mathbf{P}(A \cap B) = \mathbf{P}(A) \times \mathbf{P}(B)$
- Proba conditionnelles :

$$\mathbf{P}_B(A) = \mathbf{P}(A|B) = \frac{\mathbf{P}(A \cap B)}{\mathbf{P}(B)}$$

- Formules de Bayes : $\mathbf{P}(B|A) = \frac{\mathbf{P}(B)\mathbf{P}(A|B)}{\mathbf{P}(A)}$

$$\text{et } \mathbf{P}(A) = \mathbf{P}(A|B)\mathbf{P}(B) + \mathbf{P}(A|\bar{B})\mathbf{P}(\bar{B})$$

Densité, fonction de répartition

- Variable aléatoire : $X : \Omega \rightarrow \mathbf{R}$

- Cas des variables continues

$$\text{Densité } f_x \text{ de } X : \mathbf{P}(X \in [a, b]) = \int_a^b f_x$$

$$\text{Fonction de répartition : } F_X(x) = \mathbf{P}(X \leq x)$$

$$\text{Déduire la densité de la } f^\circ \text{ de répart. : } f_x = F'_x$$

Espérance, Variance

- Espérance : $\mathbf{E}(X) = \sum_i x_i \mathbf{P}_X(x_i)$ (discret)
 $\mathbf{E}(X) = \int_{-\infty}^{+\infty} x f_x(x) dx$ (continu)

- Variance : $\mathbf{V}(X) = \sum_i (x_i - \mathbf{E}(X))^2 \mathbf{P}_X(x_i)$
 $\mathbf{V}(X) = \int_{-\infty}^{+\infty} (x - \mathbf{E}(X))^2 f_x(x) dx$

- Écart-type : $\sigma(X) = \sqrt{\mathbf{V}(X)}$

- Propriétés : $\mathbf{E}(X + \alpha Y) = \mathbf{E}(X) + \alpha \mathbf{E}(Y)$
 $\mathbf{V}(X) = \mathbf{E}(X^2) - \mathbf{E}(X)^2$
 $\mathbf{V}(\alpha X + \beta) = \alpha^2 \mathbf{V}(X)$

- X, Y indépendantes $\implies \mathbf{E}(XY) = \mathbf{E}(X)\mathbf{E}(Y)$
 et $\mathbf{V}(X + Y) = \mathbf{V}(X) + \mathbf{V}(Y)$

Couple de variables

X, Y variables indépendantes de densités f_x, f_y
 $\mathcal{A} \subset \mathbf{R}^2$.

Alors $\mathbf{P}((X, Y) \in \mathcal{A}) = \iint_{\mathcal{A}} f_x(x) f_y(y) dy dx$.
 Représenter \mathcal{A} et le paramétrer pour Fubini.

Lois usuelles

- Bernoulli : $X \sim \mathcal{B}(p)$

$$\mathbf{P}(X=1) = p, \quad \mathbf{P}(X=0) = 1 - p$$

$$\mathbf{E}(X) = p \quad \mathbf{V}(X) = p(1 - p)$$

- Binomiale : $X \sim \mathcal{B}(n, p)$

$$\mathbf{P}(X=k) = \binom{n}{k} p^k (1-p)^{n-k}, \quad k \in \llbracket 0, n \rrbracket$$

$$\mathbf{E}(X) = np \quad \mathbf{V}(X) = np(1-p)$$

- Géométrique : $X \sim \mathcal{G}(p)$

$$\mathbf{P}(X=k) = p(1-p)^{k-1}, \quad k \in \mathbf{N}^*$$

$$\mathbf{E}(X) = \frac{1}{p} \quad \mathbf{V}(X) = \frac{1-p}{p^2}$$

- Uniforme : $X \sim \mathcal{U}([a, b])$

$$f_x(x) = \frac{1}{b-a}, \quad x \in [a, b].$$

$$\mathbf{E}(X) = \frac{a+b}{2} \quad \mathbf{V}(X) = \frac{(b-a)^2}{12}$$

- Exponentielle : $X \sim \mathcal{E}(\lambda)$

$$f_x(x) = \lambda e^{-\lambda x}, \quad x \in \mathbf{R}_+$$

$$\mathbf{E}(X) = \frac{1}{\lambda} \quad \mathbf{V}(X) = \frac{1}{\lambda^2}$$

- Loi normale : $X \sim \mathcal{N}(m, \sigma^2)$

$$f_x(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-m)^2}{2\sigma^2}}, \quad x \in \mathbf{R}$$

$$\mathbf{E}(X) = m \quad \mathbf{V}(X) = \sigma^2.$$

$$X \sim \mathcal{N}(m, \sigma^2) \implies \frac{X-m}{\sigma} \sim \mathcal{N}(0, 1)$$

$$X_1 \sim \mathcal{N}(m_1, \sigma_1^2), X_2 \sim \mathcal{N}(m_2, \sigma_2^2) \text{ indep.}$$

$$\implies X_1 + X_2 \sim \mathcal{N}(m_1 + m_2, \sigma_1^2 + \sigma_2^2)$$

Théorèmes limites

- Loi forte : (X_k) iid d'espérance m

$$\text{alors } \frac{1}{n} \sum_{k=1}^n X_k \rightarrow m \text{ presque sûrement}$$

- TCL : (X_k) iid d'espérance m , variance σ^2

$$\text{alors } \frac{\sum_{k=1}^n X_k - nm}{\sigma\sqrt{n}} \rightarrow_{n \rightarrow \infty} \text{ en loi } \mathcal{N}(0, 1)$$

- En pratique : pour $n \geq 30$, on a à peu près

$$\frac{\sum_1^n X_k - nm}{\sigma\sqrt{n}} \sim \mathcal{N}(0, 1) \quad \sum_{k=1}^n X_k \sim \mathcal{N}(nm, n\sigma^2)$$

$$\frac{\frac{1}{n} \sum_1^n X_k - m}{\frac{\sigma}{\sqrt{n}}} \sim \mathcal{N}(0, 1)$$

Quelques valeurs de la fonction de répartition de la loi normale $\mathcal{N}(0, 1)$:

x	0	0,25	0,43	0,61	0,84	1,08	1,30	1,65	1,96	2,33	2,58	3,0
$F_{\mathcal{N}}(x)$	0,5	0,60	0,66	0,73	0,80	0,86	0,90	0,95	0,975	0,99	0,995	0,999

$$F_{\mathcal{N}}(-a) = 1 - F_{\mathcal{N}}(a)$$

$$\mathbf{P}_{\mathcal{N}}([-a, a]) = 2F_{\mathcal{N}}(a) - 1$$