

Estimation

Exercice 1 (ECRICOME)

Soient a et b deux réels tels que $a \geq 0$ et $b > 0$. On considère la fonction $f_{a,b}$ définie sur \mathbb{R} par :

$$f_{a,b}(x) = \begin{cases} \frac{1}{b} \exp\left(-\frac{x-a}{b}\right) & \text{si } x \geq a, \\ 0 & \text{sinon.} \end{cases}$$

1. Vérifier que $f_{a,b}$ est bien une densité de variable aléatoire. On note $\mathcal{E}(a, b)$ la loi associée.
2. On considère désormais une variable aléatoire X de loi $\mathcal{E}(a, b)$.
Déterminer la fonction de répartition de X .
3. On pose $Y = X - a$. Déterminer la loi de Y et la reconnaître. En déduire $E(X)$ et $V(X)$.

On considère désormais une suite de variables aléatoires $(X_i)_{i \geq 1}$ indépendantes, identiquement distribuées de loi $\mathcal{E}(a, b)$, c'est-à-dire qui suivent toutes la loi $\mathcal{E}(a, b)$.

Pour tout entier n supérieur ou égal à 2, on considère les variables aléatoires S_n et Y_n définies par $S_n = X_1 + \dots + X_n$ et $Y_n = \min(X_1, \dots, X_n)$.

Le but des questions suivantes est de déterminer des estimateurs de a et b .

4. Déterminer l'espérance et la variance de S_n .
5. (a) Déterminer la fonction de répartition de Y_n .
(b) En déduire que Y_n suit une loi $\mathcal{E}(a_n, b_n)$ (on précisera a_n et b_n).
(c) Donner les valeurs de $E(Y_n)$ et $V(Y_n)$.

6. On pose $Z_n = \frac{S_n}{n} - Y_n$.

(a) Montrer que $\lim_{n \rightarrow +\infty} E(Z_n) = b$.

(b) On note $r_b(Z_n) = E((Z_n - b)^2)$ le risque quadratique de Z_n . Montrer que :

$$r_b(Z_n) = \frac{b^2}{n^2} + V(Z_n).$$

(c) En déduire que :

$$r_b(Z_n) = \frac{2b^2}{n^2} + \frac{b^2}{n} - \frac{2}{n} \text{Cov}(S_n, Y_n).$$

(d) Justifier que $(\text{Cov}(S_n, Y_n))^2 \leq V(S_n)V(Y_n)$, puis montrer que $\lim_{n \rightarrow +\infty} r_b(Z_n) = 0$.

Exercice 2 (EML)

Dans cet exercice, toutes les variables aléatoires sont supposées définies sur un même espace probabilisé noté (Ω, \mathcal{A}, P) .

Partie A : Loi de Pareto

Soient a et b deux réels strictement positifs. On définit la fonction f sur \mathbb{R} par :

$$f : x \mapsto \begin{cases} 0 & \text{si } x < b, \\ b^a & \text{si } x = b, \\ a \frac{b^a}{x^{a+1}} & \text{si } x > b. \end{cases}$$

1. Montrer que f est une densité de probabilité.

On dit qu'une variable aléatoire suit la loi de Pareto de paramètres a et b lorsqu'elle admet pour densité la fonction f .

Dans toute la suite de l'exercice, on considère une variable aléatoire X suivant la loi de Pareto de paramètres a et b .

2. Déterminer la fonction de répartition de X .

3. (a) Soit U une variable aléatoire suivant la loi uniforme sur $]0, 1]$.

Montrer que la variable aléatoire $bU^{-\frac{1}{a}}$ suit la loi de Pareto de paramètres a et b .

(b) En déduire une fonction Python d'en-tête `def pareto(a,b)` qui prend en arguments deux réels a et b strictement positifs et qui renvoie une simulation de la variable aléatoire X .

(c) On considère la fonction Python ci-dessous.

Que contient la liste L renvoyée par la fonction `mystere` ?

```

1 | def mystere(a, b)
2 |     L = []
3 |     for p in range(2, 7):
4 |         S = 0
5 |         for k in range(10**p):
6 |             S = S + pareto(a,b)
7 |         L.append(S/10**p)
8 |     return(L)

```

(d) On exécute la fonction précédente avec différentes valeurs de a et de b .

Comment interpréter les résultats obtenus ?

```

>>>mystere(2,1)
[1.9306917  1.9411352  1.9840089  1.9977684  2.0012415]
>>>mystere(3,2)
[3.1050951  3.0142956  2.9849407  2.9931656  2.9991517]
>>>mystere(1,4)
[21.053151  249.58609  51.230522  137.64549  40.243918]

```

4. (a) Montrer que X admet une espérance si et seulement si $a > 1$ et que, dans ce cas :

$$E(X) = \frac{ab}{a - 1}$$

(b) Montrer que X admet une variance si et seulement si $a > 2$ et que, dans ce cas :

$$V(X) = \frac{ab^2}{(a - 1)^2 (a - 2)}$$

Partie B : Estimation du paramètre b

On suppose **dans cette partie uniquement** que $a = 3$ et on cherche à déterminer un estimateur performant de b . Ainsi, la variable aléatoire X admet pour densité la fonction f définie par :

$$f : x \mapsto \begin{cases} 0 & \text{si } x < b, \\ \frac{3b^3}{x^4} & \text{si } x \geq b. \end{cases}$$

Soient $n \in \mathbb{N}^*$ et X_1, \dots, X_n des variables aléatoires indépendantes, toutes de même loi que X .

On définit :

$$Y_n = \min(X_1, \dots, X_n) \quad \text{et} \quad Z_n = \frac{X_1 + \dots + X_n}{n}$$

On admet que Y_n et Z_n sont encore des variables aléatoires définies sur (Ω, \mathcal{A}, P) .

5. (a) Calculer, pour tout x de $[b, +\infty[$, $P(Y_n > x)$.
 (b) En déduire que Y_n suit une loi de Pareto dont on précisera les paramètres.
 (c) Montrer que $Y'_n = \frac{3n-1}{3n} Y_n$ admet une espérance égale à b .
 Calculer la variance de Y'_n .
6. (a) Déterminer l'espérance et la variance de Z_n .
 (b) En déduire un estimateur noté Z'_n d'espérance égale à b de la forme αZ_n où α est un réel à préciser.
 Calculer la variance de Z'_n .
7. Entre Y'_n et Z'_n , quel estimateur choisir ? Justifier.

Partie C : Estimation du paramètre a

On suppose **dans cette partie uniquement** que $b = 1$ et on cherche à construire un intervalle de confiance pour a . Ainsi, la variable aléatoire X admet pour densité la fonction f définie par :

$$f : x \mapsto \begin{cases} 0 & \text{si } x < 1, \\ \frac{a}{x^{a+1}} & \text{si } x \geq 1. \end{cases}$$

Soit $(X_n)_{n \in \mathbb{N}^*}$ une suite de variables aléatoires indépendantes, toutes de même loi que X .

8. Soit $n \in \mathbb{N}^*$. On pose : $W_n = \ln(X_n)$.
 Montrer que la variable aléatoire W_n suit une loi exponentielle dont on précisera le paramètre.
 En déduire l'espérance et la variance de W_n .
9. On définit, pour tout n de \mathbb{N}^* :

$$M_n = \frac{\ln(X_1) + \dots + \ln(X_n)}{n} \quad \text{et} \quad T_n = \sqrt{n}(a M_n - 1)$$

- (a) Justifier que la suite de variables aléatoires $(T_n)_{n \in \mathbb{N}^*}$ converge en loi vers une variable aléatoire suivant la loi normale centrée réduite.
- (b) En déduire que l'intervalle $\left[\frac{\sqrt{n}-2}{\sqrt{n}M_n} ; \frac{\sqrt{n}+2}{\sqrt{n}M_n} \right]$ est un intervalle de confiance asymptotique pour a au niveau de confiance 95%.
On admettra que $\Phi(2) \geq 0,975$, où Φ désigne la fonction de répartition d'une variable aléatoire suivant la loi normale centrée réduite.

Exercice 3 (ESSEC)

Notations

- Tout au long du sujet (Ω, \mathcal{F}, P) désignera un espace probabilisé et les variables aléatoires utilisées seront toutes définies sur cet espace probabilisé. Sous réserve d'existence, l'espérance mathématique d'une variable aléatoire réelle X sera notée $E(X)$ et sa variance sera notée $V(X)$.
- Pour un événement A , on notera $P_B(A)$ la probabilité conditionnelle de A sachant B où B est un événement non négligeable.

Le sujet est composé de quatre parties. Les parties I, II, III et IV.A sont **indépendantes**. Il s'agit de variations autour de la notion de risque quadratique en théorie de l'estimation.

I. Premier problème d'estimation

Dans ce premier problème d'estimation, on dispose d'une seule observation notée X . On suppose que X admet pour densité f_θ définie sur \mathbb{R} par

$$f_\theta(x) = \begin{cases} \frac{k+1}{\theta^{k+1}} x^k & \text{pour tout } x \in [0, \theta] \\ 0 & \text{sinon} \end{cases}$$

où k est un entier naturel non nul et θ un paramètre réel inconnu strictement positif que l'on souhaite estimer.

1. Montrer que f_θ est bien une densité de probabilité.
2. Calculer $E(X)$.

On définit le biais de T estimateur de θ par :

$$b(T, \theta) = E(T - \theta)$$

On dira que T est sans biais si $b(T, \theta) = 0$ et qu'il est biaisé sinon.

3. Déterminer λ_0 réel dépendant uniquement de k tel que $\lambda_0 X$ estime θ sans biais.
4. Calculer $V(X)$.

On définit le risque quadratique de T estimateur de θ par :

$$R(T, \theta) = E\left((T - \theta)^2\right)$$

5. Démontrer que pour tout T estimateur de θ , on a :

$$R(T, \theta) = (b(T, \theta))^2 + V(T)$$

6. Donner la valeur de $R(\lambda_0 X, \theta)$.

Le but de la fin de cette partie I est de déterminer un estimateur de θ ayant un plus petit risque quadratique que celui de $\lambda_0 X$.

7. En utilisant I.5 montrer que pour tout λ réel

$$R(\lambda X, \theta) = \theta^2 Q(\lambda)$$

où Q est un polynôme de degré 2 dont les coefficients ne dépendent que de k .

8. Montrer que la fonction $\lambda \mapsto Q(\lambda)$ atteint son minimum en un unique réel noté λ^* que l'on exprimera en fonction de k .
9. Conclure sur le but recherché.

II. Second problème d'estimation

Dans ce second problème d'estimation, on dispose de n observations indépendantes ($n \geq 2$) notées X_1, \dots, X_n de même loi de Poisson de paramètre θ inconnu ($\theta \in]0, +\infty[$). On souhaite estimer le paramètre $\exp(-\theta)$.

On définit pour tout i élément de $\{1, \dots, n\}$ la variable aléatoire Y_i par

$$Y_i = 1 \text{ si } X_i = 0 \quad \text{et} \quad Y_i = 0 \text{ sinon.}$$

Puis on note

$$\bar{Y}_n = \frac{1}{n} \sum_{i=1}^n Y_i.$$

10. Pour tout i élément de $\{1, \dots, n\}$, donner la loi de Y_i .

11. Donner la loi de $\sum_{i=1}^n Y_i$, puis montrer que $E(\overline{Y}_n) = \exp(-\theta)$.

On dira dans ce cas que \overline{Y}_n est un estimateur sans biais de $\exp(-\theta)$.

12. Calculer $V(\overline{Y}_n)$.

Pour tout k élément de $\{1, \dots, n\}$ on définit $S_k = \sum_{i=1}^k X_i$.

13. Rappeler sans démonstration la loi de S_k pour tout k élément de $\{1, \dots, n\}$.

On définit jusqu'à la fin de cette partie II pour tout j entier naturel

$$\varphi(j) = P_{\{S_n=j\}}(X_1 = 0)$$

14. Montrer que pour tout j entier naturel

$$\varphi(j) = \left(1 - \frac{1}{n}\right)^j$$

On a donc $\varphi(j)$ indépendant du paramètre θ inconnu.

D'après la question 14, on peut définir l'estimateur

$$\varphi(S_n) = \left(1 - \frac{1}{n}\right)^{S_n}$$

15. Montrer que $\varphi(S_n)$ admet une espérance et que $E(\varphi(S_n)) = \exp(-\theta)$.

On dira dans ce cas que $\varphi(S_n)$ est un estimateur sans biais de $\exp(-\theta)$.

16. Montrer que $\varphi(S_n)$ admet une variance vérifiant

$$V(\varphi(S_n)) = \exp(-2\theta) \left(\exp\left(\frac{\theta}{n}\right) - 1 \right)$$

17. On souhaite comparer les performances de \overline{Y}_n et $\varphi(S_n)$ en tant qu'estimateurs de $\exp(-\theta)$.

(a) En utilisant le théorème des accroissements finis, démontrer que

$$1 \leq \frac{\exp(\theta) - 1}{\theta} \leq \exp(\theta)$$

(b) Soit la fonction $h : [0, 1] \rightarrow \mathbb{R}$ définie par

$$h(t) = t \exp(\theta) + (1-t) - \exp(t\theta)$$

pour tout $t \in [0, 1]$. Étudier les variations de h .

(c) En déduire que

$$\exp\left(\frac{\theta}{n}\right) \leq \frac{\exp(\theta)}{n} + \frac{n-1}{n}$$

puis l'inégalité

$$V(\varphi(S_n)) \leq V(\overline{Y}_n)$$

(d) On définit le risque quadratique de T_n estimateur de $\exp(-\theta)$ par

$$R(T_n, \exp(-\theta)) = E\left((T_n - \exp(-\theta))^2\right)$$

Comparer les risques quadratiques de \bar{Y}_n et $\varphi(S_n)$.

On reprendra à la fin de la partie IV l'étude de $\varphi(S_n)$.

III. Information de Fisher

A. Cas discret

Dans cette section III.A, on considère I un intervalle de \mathbb{R} , θ un paramètre inconnu de I et X une variable aléatoire à valeurs dans \mathbb{N} ($X(\Omega) \subseteq \mathbb{N}$). On suppose qu'il existe une fonction p définie sur $I \times X(\Omega)$ telle que pour tout k élément de $X(\Omega)$

$$P(X = k) = p(\theta, k)$$

et vérifiant pour tout k de $X(\Omega)$, $\theta \mapsto p(\theta, k)$ dérivable sur I .

On définit sous réserve d'existence l'**information de Fisher** de X par

$$I_X(\theta) = \sum_{k \in X(\Omega)} \left(\frac{\partial}{\partial \theta} \ln p(\theta, k) \right)^2 p(\theta, k)$$

18. Dans cette question, on considère X variable aléatoire de loi de Bernoulli de paramètre θ ($\theta \in]0, 1[$).

On a alors $X(\Omega) = \{0, 1\}$, $P(X = 1) = p(\theta, 1) = \theta$, $P(X = 0) = p(\theta, 0) = 1 - \theta$ et

$$I_X(\theta) = \left(\frac{\partial}{\partial \theta} \ln p(\theta, 1) \right)^2 p(\theta, 1) + \left(\frac{\partial}{\partial \theta} \ln p(\theta, 0) \right)^2 p(\theta, 0)$$

Montrer que

$$I_X(\theta) = \frac{1}{\theta(1-\theta)}$$

19. Dans cette question, on considère X variable aléatoire de loi binomiale de paramètres N et θ ($N \in \mathbb{N}^*$, $\theta \in]0, 1[$).

(a) Montrer que

$$I_X(\theta) = \frac{1}{(\theta(1-\theta))^2} \sum_{k=0}^N (k - N\theta)^2 \binom{N}{k} \theta^k (1-\theta)^{N-k}$$

(b) En déduire que

$$I_X(\theta) = \frac{V(X)}{(\theta(1-\theta))^2}$$

puis donner la valeur de $I_X(\theta)$.

20. Dans cette question, on considère X une variable aléatoire de Poisson de paramètre θ ($\theta \in]0, +\infty[$). Puisque $X(\Omega) = \mathbb{N}$, on a sous réserve de convergence

$$I_X(\theta) = \sum_{k=0}^{+\infty} \left(\frac{\partial}{\partial \theta} \ln p(\theta, k) \right)^2 p(\theta, k)$$

(a) Montrer que la série de terme général $\left(\frac{\partial}{\partial \theta} \ln p(\theta, k) \right)^2 p(\theta, k)$ converge et calculer sa somme $I_X(\theta)$.

(b) Justifier que

$$I_X(\theta) = E \left(\left(\frac{\partial}{\partial \theta} \ln p(\theta, X) \right)^2 \right).$$

B. Cas d'une variable gaussienne

Soit X une variable aléatoire qui suit la loi normale de moyenne θ ($\theta \in \mathbb{R}$) et de variance 1 dont la densité est notée $x \mapsto f(\theta, x)$. On définit sous réserve de convergence l'information de Fisher de X par

$$I_X(\theta) = \int_{-\infty}^{+\infty} \left(\frac{\partial}{\partial \theta} \ln(f(\theta, x)) \right)^2 f(\theta, x) dx$$

21. Montrer que sous réserve de convergence

$$I_X(\theta) = \int_{-\infty}^{+\infty} (x - \theta)^2 f(\theta, x) dx$$

22. En déduire l'existence et la valeur de $I_X(\theta)$.

23. Justifier que

$$I_X(\theta) = E \left(\left(\frac{\partial}{\partial \theta} \ln(f(\theta, X)) \right)^2 \right)$$

IV. Minoration du risque quadratique

A. Inégalité de Cramer-Rao

Dans cette section IV.A, on considère I un intervalle de \mathbb{R} , θ un paramètre inconnu de I et X une variable aléatoire telle que $X(\Omega) = \{0, \dots, N\}$ ($N \in \mathbb{N}$). On suppose qu'il existe une fonction p définie sur $I \times X(\Omega)$ telle que pour tout $k \in \{0, \dots, N\}$

$$P(X = k) = p(\theta, k)$$

et vérifiant :

- pour tout $k \in \{0, \dots, N\}$, $\theta \mapsto p(\theta, k)$ dérivable sur I ,
- l'information de Fisher de X notée $I_X(\theta)$ définie dans la partie III est non nulle pour tout $\theta \in I$.

Le but de la section IV.A est de démontrer l'inégalité suivante due à Cramer et Rao.

Théorème de Cramer-Rao

Soit $f(X)$ un estimateur sans biais de $g(\theta)$ à savoir tel que $E(f(X)) = g(\theta)$ où g est dérivable sur I . On a alors

$$V(f(X)) \geq \frac{(g'(\theta))^2}{I_X(\theta)}$$

24. Montrer que pour tout θ élément de I ,

$$\sum_{k=0}^N \frac{\partial}{\partial \theta} (p(\theta, k)) = 0$$

25. En déduire que pour tout θ élément de I

$$E \left(\frac{\partial}{\partial \theta} \ln(p(\theta, X)) \right) = 0 \tag{E}$$

26. En dérivant partiellement par rapport à θ les deux membres de l'égalité (E), montrer que pour tout θ élément de I ,

$$E \left(\frac{\partial^2}{\partial \theta^2} \ln(p(\theta, X)) \right) = -E \left(\left(\frac{\partial}{\partial \theta} \ln(p(\theta, X)) \right)^2 \right).$$

27. Montrer que pour tout θ élément de I ,

$$g'(\theta) = \sum_{k=0}^N f(k) \left(\frac{\partial}{\partial \theta} \ln(p(\theta, k)) \right) p(\theta, k)$$

puis que

$$g'(\theta) = E \left((f(X) - g(\theta)) \frac{\partial}{\partial \theta} \ln(p(\theta, X)) \right)$$

28. On pose pour tout t réel

$$L(t) = E \left(\left((f(X) - g(\theta)) + t \frac{\partial}{\partial \theta} \ln(p(\theta, X)) \right)^2 \right)$$

- (a) Développer le polynôme L suivant les puissances décroissantes de t .
- (b) Calculer le discriminant Δ de L et justifier que $\Delta \leq 0$.
- (c) En déduire l'inégalité de Cramer-Rao.

B. Extension du théorème de Cramer-Rao

On reprend dans cette section IV.B les notations et hypothèses de la partie II. On admet que, dans ce contexte, le théorème de Cramer-Rao peut se généraliser comme suit :

Théorème de Cramer-Rao

Soit $T_n = f(X_1, \dots, X_n)$ un estimateur sans biais de $g(\theta)$ à savoir tel que $E(f(X_1, \dots, X_n)) = g(\theta)$ où g est dérivable sur $]0, +\infty[$. On a alors

$$V(T_n) \geq \frac{(g'(\theta))^2}{nI_{X_1}(\theta)}$$

où $I_{X_1}(\theta)$ est l'information de Fisher d'une variable aléatoire de loi de Poisson de paramètre θ définie et calculée à la partie III.

Il s'agit dans cette section d'exploiter cette nouvelle inégalité de Cramer-Rao. On note

$$\overline{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$$

29. Calculer $E(\overline{X}_n)$ et $V(\overline{X}_n)$.

30. Déduire de la généralisation de Cramer-Rao, que \overline{X}_n a le plus petit risque quadratique parmi les estimateurs sans biais de θ .

31. Montrer que pour $g(\theta) = \exp(-\theta)$ où $\theta \in]0, +\infty[$

$$V(\varphi(S_n)) \underset{n \rightarrow +\infty}{\sim} \frac{(g'(\theta))^2}{nI_{X_1}(\theta)}$$

32. Que prouve ce résultat en terme d'optimalité de $\varphi(S_n)$ dans l'estimation de $\exp(-\theta)$?

33. A la lumière de la partie I, peut-on conclure que lorsque n est grand $\varphi(S_n)$ est le meilleur estimateur de $\exp(-\theta)$ en terme de risque quadratique ?