

Exercices supplémentaires TD5 Statistique 2

Exercice 1:

Soit X_1, \dots, X_n un échantillon de v.a.i.i.d. de loi absolument continue de densité:

$$f_\theta(x) = \begin{cases} \frac{2(1-x)}{(1-\theta)^2}, & \text{si } \theta \leq x \leq 1, \\ 0, & \text{sinon,} \end{cases} \quad \text{où } \theta \in [0, 1[\text{ est un paramètre inconnu.}$$

1. Vérifier que f_θ est une densité
2. Déterminer le modèle statistique et la fonction de vraisemblance.
3. Démontrer que ce modèle admet un unique estimateur du maximum de vraisemblance $\hat{\theta}$ de θ .
4. Démontrer que $n(\hat{\theta} - \theta)$ tend en loi vers une distribution à préciser. En déduire un intervalle de confiance asymptotique de niveau 95% sur θ .
5. Déterminer l'espérance de X_1 . En déduire un autre estimateur possible pour θ .

Proof. 1. On a f_θ qui est une fonction mesurable (car continue) et positive. De plus, on vérifie que :

$$\int_{\theta}^1 \frac{2(1-x)}{(1-\theta)^2} dx = \frac{2}{(1-\theta)^2} \int_{\theta}^1 (1-x) dx = \frac{2}{(1-\theta)^2} \frac{(1-\theta)^2}{2} = 1.$$

Donc, f_θ est bien une densité de probabilité.

2. Le modèle statistique est $\left([0, 1]^n, \mathcal{B}([0, 1]^n), \left(\int f_\theta d\lambda_{[0,1]}\right)^{\otimes n}, \theta \in [0, 1[\right)$.

Pour $(x_1, \dots, x_n) \in [0, 1]^n$, du fait de l'indépendance et de l'i.d., on a pour vraisemblance:

$$L_\theta(x_1, \dots, x_n) = \prod_{i=1}^n \frac{2(1-x_i)}{(1-\theta)^2} \mathbb{I}_{\theta \leq x_i} = 2^n (1-\theta)^{-2n} \left(\prod_{i=1}^n (1-x_i) \right) \mathbb{I}_{\theta \leq \min(x_i)}.$$

3. On voit que $L_\theta(X_1, \dots, X_n) = 0$ si $\theta > \min_i(X_i)$. On considérera donc des valeurs de θ dans $[0, \min_i(X_i)]$ et on veut maximiser la fonction $\theta \in [0, \min_i(X_i)] \rightarrow L_\theta(X_1, \dots, X_n)$. La log-vraisemblance $\ell(\theta)$ sur $[0, \min_i(X_i)]$ est définie par:

$$\ell(\theta) = \log(L_\theta(X_1, \dots, X_n)) = n \log(2) - 2n \log(1-\theta) + \sum_{i=1}^n \log(1-x_i).$$

On a $\ell'(\theta) = \frac{2n}{1-\theta}$: fonction strictement croissante qui atteint son maximum en $\min_i(X_i)$. D'où

$$\hat{\theta} = \min(X_1, \dots, X_n).$$

4. Soit F_θ la fonction de répartition de X . Pour $x \in]-\infty, \theta]$, $F_\theta(x) = 0$. Pour $x \in [\theta, 1]$,

$$F_\theta(x) = \int_{\theta}^x \frac{2(1-t)}{(1-\theta)^2} dt = \frac{(1-\theta)^2 - (1-x)^2}{(1-\theta)^2} = \frac{(x-\theta)(2-\theta-x)}{(1-\theta)^2}$$

Alors $\mathbb{P}(\hat{\theta} > t) = (1 - F_\theta(t))^n$. Donc $\mathbb{P}(\hat{\theta} \leq t) = 1 - (1 - F_\theta(t))^n$ et ainsi pour $z \geq 0$:

$$\mathbb{P}(n(\hat{\theta} - \theta) \leq z) = 1 - (1 - F_\theta(\theta + z/n))^n = 1 - \left(1 - \frac{\frac{z}{n}(2 - 2\theta - z/n)}{(1 - \theta)^2}\right)^n.$$

Pour trouver la limite quand $n \rightarrow \infty$, on passe à l'exponentielle et donc:

$$\mathbb{P}(n(\hat{\theta} - \theta) \leq z) = 1 - \exp\left(n \log\left(1 - \frac{\frac{z}{n}(2 - 2\theta - z/n)}{(1 - \theta)^2}\right)\right) \xrightarrow{n \rightarrow \infty} 1 - \exp\left(-2 \frac{z}{(1 - \theta)}\right),$$

en utilisant le DL de $\log(1 - u)$ en 0. On reconnaît ici la fonction de répartition d'une loi exponentielle de paramètre $2/(1 - \theta)$.

5. On peut calculer l'espérance de X_1 :

$$\begin{aligned} \mathbb{E}[X_1] &= \int_\theta^1 x f_\theta(x) dx = \frac{2}{(1 - \theta)^2} \int_\theta^1 x(1 - x) dx = \frac{2}{(1 - \theta)^2} \left[\frac{1}{2} x^2 - \frac{1}{3} x^3 \right]_\theta^1 = \frac{1}{3(1 - \theta)^2} (1 - 3\theta^2 + 2\theta^3) \\ &= \frac{1 + \theta - 2\theta^2}{3(1 - \theta)} = \frac{1}{3} (1 + 2\theta). \end{aligned}$$

On en déduit que $\theta = \frac{1}{2}(3\mathbb{E}[X_1] - 1)$. Donc comme \bar{X}_n est un estimateur convergent de $\mathbb{E}[X_1]$, on en déduit que $\tilde{\theta}_n = \frac{1}{2}(3\bar{X}_n - 1)$ est un autre estimateur convergent de θ (mais qui converge à vitesse \sqrt{n} et non à vitesse n comme $\hat{\theta}_n$, qui est donc bien plus intéressant).

□

Exercice 2:

On considère (X_1, \dots, X_{2n}) un vecteur gaussien centré tel que $\mathbb{E}[X_i X_j] = 0$ si $i \neq j$, $\mathbb{E}[X_i^2] = \sigma^2$ si $1 \leq i \leq n$, $\mathbb{E}[X_i^2] = \alpha \sigma^2$ si $n + 1 \leq i \leq 2n$, avec $\sigma^2 > 0$ et $\alpha > 0$ deux paramètres à estimer.

1. (X_1, \dots, X_{2n}) est-elle une famille de v.a.i.i.d.?
2. Déterminer le modèle statistique et préciser la vraisemblance du vecteur $\theta = (\sigma^2, \alpha)$.
3. Montrer que l'estimateur du maximum de vraisemblance $\hat{\theta}$ de θ est unique et s'écrit

$$\hat{\theta} = (\hat{\sigma}^2, \hat{\alpha}) = \left(\frac{1}{n} \sum_{k=1}^n X_k^2, \frac{\sum_{k=n+1}^{2n} X_k^2}{\sum_{k=1}^n X_k^2} \right).$$

4. Démontrer que $\hat{\theta} \xrightarrow[n \rightarrow +\infty]{\mathcal{P}} \theta$.
5. Démontrer un TLC pour $\frac{1}{n\sigma^2} \sum_{k=n+1}^{2n} X_k^2$ et en déduire en justifiant un TLC pour $\hat{\alpha}$. Donner un intervalle de confiance asymptotique de niveau 95% pour α .
6. Déterminer l'information de Fisher du modèle. L'estimateur $\hat{\theta}$ est-il efficace?

Proof. 1. Bien que les variables soient indépendantes et gaussiennes centrées, leurs variances diffèrent selon que $i \leq n$ ou $i > n$. Elles ne sont donc pas identiquement distribuées.

2. Le modèle statistique est: $(\mathbf{R}^{2n}, \mathcal{B}(\mathbf{R}^{2n}), \mathcal{N}(0, \sigma^2)^{\otimes n} \otimes \mathcal{N}(0, \alpha \sigma^2)^{\otimes n}, \theta = (\sigma^2, \alpha) \in \mathbf{R}_+^* \times \mathbf{R}_+^*)$.

Pour $(x_1, \dots, x_{2n}) \in \mathbf{R}^{2n}$, du fait de l'indépendance on peut écrire que la densité jointe du vecteur est:

$$L_\theta(x_1, \dots, x_{2n}) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{x_i^2}{2\sigma^2}\right) \cdot \prod_{j=n+1}^{2n} \frac{1}{\sqrt{2\pi\alpha\sigma^2}} \exp\left(-\frac{x_j^2}{2\alpha\sigma^2}\right).$$

Ce qui se simplifie par:

$$L_\theta(x_1, \dots, x_{2n}) = \frac{1}{(2\pi)^n} \frac{1}{(\sigma^2)^n} \frac{1}{\alpha^{n/2}} \exp\left(-\frac{1}{2\sigma^2} \left(\sum_{i=1}^n x_i^2 + \frac{1}{\alpha} \sum_{i=n+1}^{2n} x_i^2\right)\right).$$

3. La log-vraisemblance en (X_1, \dots, X_{2n}) est donc:

$$\ell(\theta) = -n \log(2\pi\sigma^2) - \frac{n}{2} \log(\alpha) - \frac{1}{2\sigma^2} \sum_{i=1}^n x_i^2 - \frac{1}{2\alpha\sigma^2} \sum_{j=n+1}^{2n} x_j^2.$$

On maximise $\theta \rightarrow \ell(\theta)$ en dérivant partiellement:

$$\begin{cases} \frac{\partial \ell(\theta)}{\partial \sigma^2} = -\frac{n}{\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n x_i^2 + \frac{1}{2\alpha\sigma^4} \sum_{j=n+1}^{2n} x_j^2 \\ \frac{\partial \ell(\theta)}{\partial \alpha} = -\frac{n}{2\alpha} + \frac{1}{2\alpha^2\sigma^2} \sum_{j=n+1}^{2n} x_j^2. \end{cases}$$

En résolvant le système d'équations $\frac{\partial \ell(\theta)}{\partial \theta} = 0$, on obtient $\hat{\theta} = (\hat{\sigma}^2, \hat{\alpha})$:

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n x_i^2, \quad \hat{\alpha} = \frac{\sum_{j=n+1}^{2n} x_j^2}{\sum_{i=1}^n x_i^2}.$$

On vérifie que la matrice hessienne $\frac{\partial^2 \ell(\theta)}{\partial \theta^2}$ en $\theta = \hat{\theta}$ est négative:

$$\frac{\partial^2 \ell(\theta)}{\partial \theta^2} = \begin{pmatrix} \frac{n}{\sigma^4} - \frac{1}{\sigma^6} \sum_{i=1}^n x_i^2 - \frac{1}{\alpha\sigma^6} \sum_{j=n+1}^{2n} x_j^2 & -\frac{1}{2\alpha^2\sigma^4} \sum_{j=n+1}^{2n} x_j^2 \\ -\frac{1}{2\alpha^2\sigma^4} \sum_{j=n+1}^{2n} x_j^2 & \frac{n}{2\alpha^2} - \frac{1}{\alpha^3\sigma^2} \sum_{j=n+1}^{2n} x_j^2 \end{pmatrix}.$$

D'où $\frac{\partial^2 \ell(\hat{\theta})}{\partial \theta^2} = \begin{pmatrix} -\frac{n}{\hat{\sigma}^4} & -\frac{n}{2\hat{\alpha}\hat{\sigma}^2} \\ -\frac{n}{2\hat{\alpha}\hat{\sigma}^2} & -\frac{n}{2\hat{\alpha}^2} \end{pmatrix}$ qui est clairement une matrice négative. C'est donc bien un maximum local, qui est aussi un maximum global.

4. Par la loi faible des grands nombres appliquée aux (X_i^2) qui sont des v.a.i.i.d. d'espérance finie, on a:

$$\frac{1}{n} \sum_{i=1}^n X_i^2 \xrightarrow[n \rightarrow +\infty]{\mathcal{P}} \mathbb{E}[X_1^2] = \sigma^2, \quad \frac{1}{n} \sum_{j=n+1}^{2n} X_j^2 \xrightarrow[n \rightarrow +\infty]{\mathcal{P}} \alpha \sigma^2.$$

Donc :

$$\hat{\sigma}^2 \xrightarrow[n \rightarrow +\infty]{\mathcal{P}} \sigma^2, \quad \hat{\alpha} = \frac{\frac{1}{n} \sum_{j=n+1}^{2n} X_j^2}{\frac{1}{n} \sum_{i=1}^n X_i^2} \xrightarrow[n \rightarrow +\infty]{\mathcal{P}} \frac{\alpha \sigma^2}{\sigma^2} = \alpha.$$

5. Les variables $(X_j^2)_{n+1 \leq j}$ sont des v.a.i.i.d., d'espérance $\alpha \sigma^2$ et de variance finie $2\alpha^2 \sigma^4$. Donc on peut appliquer le TLC et on obtient:

$$\sqrt{n} \left(\frac{1}{n} \sum_{j=n+1}^{2n} X_j^2 - \alpha \sigma^2 \right) \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, 2\alpha^2 \sigma^4) \implies \sqrt{n} \left(\frac{1}{n\sigma^2} \sum_{j=n+1}^{2n} X_j^2 - \alpha \right) \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, 2\alpha^2). \quad (1)$$

Mais par le TLC, on a également:

$$\sqrt{n} \left(\alpha \frac{\hat{\sigma}^2}{\sigma^2} - \alpha \right) \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, 2\alpha^2). \quad (2)$$

Des TLC (1) et (2), et du fait que les deux sommes sont indépendantes (donc la variance limite est la somme des 2 variances limites), on obtient finalement:

$$\sqrt{n} \left(\frac{1}{n\sigma^2} \sum_{j=n+1}^{2n} X_j^2 - \alpha \right) - \sqrt{n} \left(\alpha \frac{\hat{\sigma}^2}{\sigma^2} - \alpha \right) = \sqrt{n} \left(\frac{1}{n\sigma^2} \sum_{j=n+1}^{2n} X_j^2 - \alpha \frac{\hat{\sigma}^2}{\sigma^2} \right) \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, 4\alpha^2).$$

Comme $\hat{\sigma}^2 \xrightarrow[n \rightarrow +\infty]{\mathcal{P}} \sigma^2$, en multipliant le TLC précédent par $\sigma^2/\hat{\sigma}^2$, et en utilisant le Lemme de Slutsky, on obtient:

$$\sqrt{n} \frac{\sigma^2}{\hat{\sigma}^2} \left(\frac{1}{n\sigma^2} \sum_{j=n+1}^{2n} X_j^2 - \alpha \frac{\hat{\sigma}^2}{\sigma^2} \right) = \sqrt{n} (\hat{\alpha} - \alpha) \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, 4\alpha^2).$$

Pour obtenir un intervalle de confiance à 95% sur α , on réécrit le TLC précédent et on obtient:

$$\sqrt{n}\left(\frac{\hat{\alpha}}{2\alpha} - \frac{1}{2}\right) \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, 1).$$

On obtient ainsi avec le quantile $q_{0.975} \simeq 1.96$ à 97.5% d'une loi $\mathcal{N}(0, 1)$ que

$$\mathbb{P}\left(-q_{0.975} \leq \sqrt{n}\left(\frac{\hat{\alpha}}{2\alpha} - \frac{1}{2}\right) \leq q_{0.975}\right) \simeq 0.95 \quad \Rightarrow \quad \mathbb{P}\left(\left(\frac{1}{1 + \frac{2q_{0.975}}{\sqrt{n}}}\right)\hat{\alpha} \leq \alpha \leq \left(\frac{1}{1 - \frac{2q_{0.975}}{\sqrt{n}}}\right)\hat{\alpha}\right) \simeq 0.95.$$

6. On calcule l'information de Fisher grâce au calcul de la matrice Hessienne précédente et en prenant $-\mathbb{E}$ de cette matrice:

$$I(\theta) = -\mathbb{E} \begin{pmatrix} \frac{n}{\sigma^4} - \frac{1}{\sigma^6} \sum_{i=1}^n x_i^2 - \frac{1}{\alpha \sigma^6} \sum_{j=n+1}^{2n} x_j^2 & -\frac{1}{2\alpha^2 \sigma^4} \sum_{j=n+1}^{2n} x_j^2 \\ -\frac{1}{2\alpha^2 \sigma^4} \sum_{j=n+1}^{2n} x_j^2 & \frac{n}{2\alpha^2} - \frac{1}{\alpha^3 \sigma^2} \sum_{j=n+1}^{2n} x_j^2 \end{pmatrix} = \begin{pmatrix} \frac{n}{\sigma^4} & \frac{n}{2\alpha \sigma^2} \\ \frac{n}{2\alpha \sigma^2} & \frac{n}{2\alpha^2} \end{pmatrix}.$$

Le modèle est régulier donc l'estimateur de maximum de vraisemblance est asymptotiquement efficace.

□