

Première Année Master M.A.E.F. 2017 – 2018

Statistiques I

Contrôle continu n°2, décembre 2017

Examen de 1h30. Tout document ou calculatrice est interdit.

1. (**Sur 12 points**) Soit la variable X qui suit une loi dont la densité f_X par rapport à la mesure de Lebesgue sur $]0, 1]$ est, avec β et $K \in \mathbb{R}$:

$$f_X(x) = K x^\beta \quad \text{pour tout } x \in]0, 1],$$

- (a) Déterminer K en fonction de β (**0.5pts**), en précisant quelle condition doit vérifier β (**0.5pts**). En déduire $\mathbb{E}(X)$ (**0.5pts**) et $\text{var}(X)$ (**1pt**), en précisant également les conditions portant sur β .
- (b) On suppose que la suite $(X_i)_{i \in \mathbb{N}}$ est constituée de variables aléatoires indépendantes et identiquement distribuées suivant la même loi que X . Soit un échantillon observé (X_1, \dots, X_n) . On désire estimer β à partir de cet échantillon. Quel est le modèle statistique (**0.5pts**)? Montrer que ce modèle appartient à la famille exponentielle (**0.5pts**).
- (c) En déduire qu'il n'existe pas d'estimateur sans biais efficace de β (**1.5pts**).
- (d) Montrer que $-\log(X)$ suit une loi connue dont on précisera le paramètre (**1.5pts**). En déduire que $\tilde{\beta}_n = -1 - (n-1) \left(\sum_{i=1}^n \log(X_i) \right)^{-1}$ est un estimateur sans biais de β (utiliser la loi gamma...) pour $n \geq 2$ (**1.5pts**), puis qu'il est de variance uniformément minimale parmi les estimateurs sans biais (**1pt**).
- (e) Montrer que l'estimateur $\hat{\beta}_n$ de β par maximum de vraisemblance diffère de $\tilde{\beta}_n$ (**1pt**). Montrer que $\hat{\beta}_n$ est biaisé mais asymptotiquement non biaisé (**1pt**). Montrer sans calcul que $\text{var}(\hat{\beta}_n) < \text{var}(\tilde{\beta}_n)$ (**1pts**).

Proof. (a) On a pour $\beta \in]-1, \infty[$, $\int_0^1 K x^\beta dx = \frac{K}{\beta+1}$, donc $K = \beta + 1$.

On en déduit que $\mathbb{E}(X) = (\beta + 1) \int_0^1 x^{\beta+1} dx = \frac{1+\beta}{2+\beta}$, toujours pour $\beta > -1$.

De même $\text{var}(X) = (\beta + 1) \int_0^1 x^{\beta+2} dx - \left(\frac{1+\beta}{2+\beta} \right)^2 = \frac{1+\beta}{3+\beta} - \left(\frac{1+\beta}{2+\beta} \right)^2 = \frac{1+\beta}{(2+\beta)^2(3+\beta)}$, toujours pour $\beta > -1$.

(b) Le modèle statistique est $(]0, 1]^n, \mathcal{B}(]0, 1]^n), (\int f(x) dx)^{\otimes n}$, dominé par $\lambda_{]0, 1]^n}$.

On peut écrire que la vraisemblance est $L_\beta(x_1, \dots, x_n) = \exp(n \log(1+\beta) + \beta \sum_{i=1}^n \log(x_i))$: le modèle est bien exponentiel.

(c) Le modèle est régulier et exponentiel, avec $\beta(\beta) = n \log(1+\beta)$, $\alpha_1(\beta) = \beta$ et $a_1(x_1, \dots, x_n) = \sum_{i=1}^n \log(x_i)$. On en déduit que la fonction (à une transformation affine près) de β que l'on peut estimer sans biais et efficacement est: $g(\beta) = \frac{n}{1+\beta}$.

(d) Comme X prend ses valeurs dans $]0, 1]$, alors $-\log(X)$ prend ses valeurs dans $[0, \infty[$. Pour $x \geq 0$, on a $\mathbb{P}(-\log(X) \leq x) = \mathbb{P}(X \geq e^{-x}) = 1 - (1+\beta) \int_0^{e^{-x}} t^\beta dt = 1 - e^{-(1+\beta)x}$. Donc la densité de $\log(X)$ est $(1+\beta)e^{-(1+\beta)x} \mathbb{1}_{x \geq 0}$: $-\log(X)$ suit une loi $\mathcal{E}(1+\beta)$.

La loi de $-\sum_{i=1}^n \log(X_i)$ est donc une loi $\Gamma(n, (1+\beta))$. Donc $\mathbb{E}(-1/\sum_{i=1}^n \log(X_i)) = \frac{(1+\beta)^n}{\Gamma(n)} \int_0^\infty x^{-1} x^{n-1} e^{-(1+\beta)x} dx = \frac{(1+\beta)}{\Gamma(n)} \int_0^\infty y^{n-2} e^{-y} dy = \frac{(1+\beta)}{\Gamma(n)} \Gamma(n-1) = \frac{(1+\beta)}{(n-1)}$. En conséquence, $\mathbb{E}(\tilde{\beta}_n) = -1 + (1+\beta) = \beta$: l'estimateur est sans biais.

On a un modèle exponentiel et l'intérieur de $\alpha(\Theta)$ est $] -1, \infty[$ donc non vide. On en déduit que la statistique $\sum_{i=1}^n \log(X_i)$ est exhaustive complète pour le modèle. D'après le Théorème de Lehmann-Scheffé, on sait qu'il existe une unique fonction de cette statistique sans biais de variance uniformément minimale: c'est donc $\tilde{\beta}_n$.

(e) On montre en dérivant la log-vraisemblance par β que $\hat{\beta}_n = -1 - n \left(\sum_{i=1}^n \log(X_i) \right)^{-1}$, sa dérivée seconde étant $-n(1+\beta)^{-2}$ donc négative.

A partir du calcul du biais de $\tilde{\beta}_n$, on a $\mathbb{E}(\hat{\beta}_n) = -1 + \frac{n}{n-1}(1+\beta) = \beta + \frac{1+\beta}{n-1}$, d'où $\hat{\beta}_n$ estimateur biaisé mais asymptotiquement non biaisé.

On a $\tilde{\beta}_n = \frac{1}{n} + \frac{n-1}{n} \hat{\beta}_n$, d'où le résultat. □

2. (**Sur 20 points**) Soit une suite $(X_i)_{n \geq 1}$ de variables aléatoires indépendantes et identiquement distribuées suivant une loi uniforme sur $\{-m, 1-m, \dots, m-1, m\}$ où $m \in \mathbf{N}$ est inconnu. On observe (X_1, \dots, X_n) où $n \in \mathbf{N}^*$.

- Rappeler la loi de X_1 ainsi que son espérance (**1pt**).
- Déterminer le modèle statistique induit par (X_1, \dots, X_n) (**0.5pts**). Est-ce un modèle dominé (**0.5pts**)? Exponentiel (**0.5pts**)?
- Montrer que $\widehat{T} = (\min_{1 \leq i \leq n} X_i, \max_{1 \leq i \leq n} X_i)$ est une statistique exhaustive pour le modèle (**1pt**).
- Montrer que $\widehat{T}' = \max_{1 \leq i \leq n} |X_i|$ est aussi une statistique exhaustive (**1pt**). Montrer qu'elle est minimale (**1.5pts**) alors que T ne l'est pas (**1pt**).
- Déterminer la loi de $|X_1|$ (**0.5pts**), et en déduire que $\mathbb{P}(\widehat{T}' = j) = \frac{(2j+1)^n - (2j-1)^n}{(2m+1)^n}$ pour $j \in \{1, 2, \dots, m\}$ (**2.5pts**).
- Soit $h : \mathbf{N} \rightarrow \mathbf{R}$, quelconque. Déterminer explicitement $\mathbb{E}[h(\widehat{T}')]$ (**0.5pts**). En déduire que si $\mathbb{E}[h(\widehat{T}')] = 0$ pour tout $m \in \mathbf{N}$, alors $h \equiv 0$ (on pourra commencer par le cas $m = 0, \dots$) (**2pts**). Conséquence (**0.5pts**)?
- Déterminer \widehat{m}_n l'estimateur du maximum de vraisemblance de m (**1pt**), puis montrer que $\mathbb{E}(\widehat{m}_n) = m - b_n(m)$ avec $b_n(m) = \frac{1}{(2m+1)^n} \sum_{i=1}^{m-1} (2i+1)^n$ (**2pts**).
- A l'aide d'une comparaison avec une intégrale, montrer que $b_n(m) \leq (2m+1)/(n+1)$ (**2pts**). En déduire que $\mathbb{E}[|\widehat{m}_n - m|] \xrightarrow{n \rightarrow +\infty} 0$ (**1pt**), puis que \widehat{m}_n est un estimateur convergent de m (**0.5pts**). A quelle vitesse converge-t-il (**0.5pts**)?

Proof. (a) On a une loi discrète à valeurs dans $\{-m, 1-m, \dots, m-1, m\}$ et pour tout $j \in \{-m, 1-m, \dots, m-1, m\}$, on a $\mathbb{P}(X_1 = j) = \frac{1}{(2m+1)}$.

On a facilement $\mathbb{E}(X_1) = 0$

- (b) Le modèle statistique est $(\mathbf{Z}^n, \mathcal{P}(\mathbf{Z}^n), \mathbb{P}_m^{\otimes n})_{m \in \mathbf{N}}$.

Le modèle est dominé par la mesure $(\sum_{i \in \mathbf{Z}} \delta_i)^{\otimes n}$, mesure de comptage sur \mathbf{Z}^n .

La vraisemblance du modèle est $L_m(x_1, \dots, x_n) = \frac{1}{(2m+1)^n} \mathbb{I}_{\min_i(X_i) \geq -m \cap \max_i(X_i) \leq m}$. Ce n'est pas un modèle exponentiel car cette vraisemblance peut s'annuler.

- (c) D'après la forme de la vraisemblance, on a $L_m(x_1, \dots, x_n) = g_m(\widehat{T})$, donc d'après la factorisation de Neyman, on en déduit que \widehat{T} est une statistique exhaustive.

- (d) On peut écrire que

$\{\min_i(X_i) \geq -m \cap \max_i(X_i) \leq m\} \iff \{\max(-\min_i(X_i), \max_i(X_i)) \leq m\} \iff \{\max(\max_i(-X_i), \max_i(X_i)) \leq m\} \iff \{\max_i(|X_i|) \leq m\}$. Donc $L_m(x_1, \dots, x_n) = \frac{1}{(2m+1)^n} \mathbb{I}_{\max_i(|X_i|) \leq m}$: la statistique \widehat{T}' est donc aussi exhaustive pour le modèle.

On a $\frac{L_m(x_1, \dots, x_n)}{L_m(y_1, \dots, y_n)} = \frac{\mathbb{I}_{\max_i(|x_i|) \leq m}}{\mathbb{I}_{\max_i(|y_i|) \leq m}}$ et pour que ce rapport ne dépende pas de m , il est nécessaire que $\max_i(|x_i|) = \max_i(|y_i|)$, donc \widehat{T}' est bien minimale.

Si \widehat{T} était minimale, alors on aurait \widehat{T} qui pourrait s'écrire comme une fonction de \widehat{T}' . Mais $\min_i(X_i)$ et $\max_i(X_i)$ ne peuvent se déduire de $\max_i(|X_i|)$ dès que $n \geq 2$. Par exemple, si $(X_1, X_2) = (3, -1)$ alors $\widehat{T}' = 3$ alors que $\widehat{T} = (-1, 3)$.

- (e) La loi de $|X_1|$ est discrète à valeurs dans $\{0, 1, \dots, m\}$, et $\mathbb{P}(|X_1| = j) = \frac{2}{2m+1}$ pour $j \in \{1, 2, \dots, m\}$ et $\mathbb{P}(|X_1| = 0) = \frac{1}{2m+1}$. On a pour $j \in \{0, 1, \dots, m\}$, $\mathbb{P}(\max_i(|X_i|) \leq j) = \mathbb{P}(|X_1| \leq j)^n$ puisque on considère des va iid. Mais $\mathbb{P}(|X_1| \leq j) = \frac{2j+1}{2m+1}$. Donc $\mathbb{P}(\max_i(|X_i|) \leq j) = \left(\frac{2j+1}{2m+1}\right)^n$. Enfin $\mathbb{P}(|X_1| = j) = \mathbb{P}(|X_1| \leq j) - \mathbb{P}(|X_1| \leq j-1)$, d'où le résultat.

- (f) On a $\mathbb{E}(h(\widehat{T}')) = \sum_{j=0}^m h(j) \mathbb{P}(|X_1| = j)$. Si on a $\mathbb{E}(h(\widehat{T}')) = 0$ pour tout $m \in \mathbf{N}$, cela est vrai pour $m = 0$, pour lequel $\mathbb{E}(h(\widehat{T}')) = h(0) \mathbb{P}(|X_1| = 0)$ et donc $h(0) = 0$. De même pour $m = 1$, donc $h(1) = 0$ puisque $h(0) = 0$. Par itération, on en déduit que $h(j) = 0$ pour tout $j \in \mathbf{N}$, donc $h = 0$: la statistique est complète.

En conséquence, on sait qu'un estimateur sans biais uniformément de variance minimale pourra être obtenu comme une fonction unique de \widehat{T}' (Théorème de Lehmann-Scheffé).

- (g) Comme $L_m(x_1, \dots, x_n) = \frac{1}{(2m+1)^n} \mathbb{I}_{\widehat{T}' \leq m}$, on en déduit que la vraisemblance sera maximale si elle est non nulle et si m est le plus petit possible. Cela est obtenu pour $m = \widehat{T}'$, donc $\widehat{m}_n = \max_i(|X_i|)$.

On a $\mathbb{E}(\widehat{m}_n) = \sum_{j=0}^m j \mathbb{P}(|X_1| = j) = (1+2m)^{-m} \sum_{j=1}^m j((2j+1)^n - (2j-1)^n)$. La série se simplifie par télescopage et on a $\mathbb{E}(\widehat{m}_n) = (1+2m)^{-m} \left(\sum_{j=1}^m j(2j+1)^n - \sum_{j=0}^{m-1} (j+1)(2j+1)^n \right) = (1+2m)^{-m} \left(m(2m+1)^n - \sum_{j=0}^{m-1} (2j+1)^n \right) = m - \sum_{j=0}^{m-1} \left(\frac{2j+1}{2m+1} \right)^n$.

- (h) Comme la fonction $x \mapsto x^n$ est croissante, on en déduit que pour tout $x \in [2j+1, 2j+3]$, alors $\left(\frac{2j+1}{2m+1}\right)^n \leq \left(\frac{x}{2m+1}\right)^n$. Donc $b_n \leq (2m+1)^{-n} \sum_{j=1}^{m-1} \int_j^{j+1} (2x+1)^n dx \leq (2m+1)^{-n} \int_0^m (2x+1)^n dx \leq \frac{2m+1}{n+1}$.

Par construction, comme $\widehat{m}_n \leq m$, on en déduit que $|\widehat{m}_n - m| = m - \widehat{m}_n$ donc $\mathbb{E}[|\widehat{m}_n - m|] = b_n \xrightarrow{n \rightarrow +\infty} 0$.

D'après l'inégalité de Markov, on a tout de suite la convergence en probabilité de \widehat{m}_n vers m .
La vitesse de convergence est inférieure à $\frac{2m+1}{n+1}$, ce qui est mieux qu'avec un modèle régulier...

□