

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

Statistiques I

Contrôle continu n°1, novembre 2017

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

1. **(Sur 12 points)** Soit (X_1, \dots, X_n) une suite de variables aléatoires indépendantes et identiquement distribuées suivant une loi de Weibull, c'est-à-dire une loi dont la fonction de répartition est:

$$F(x) = 1 - \exp\left(-\left(\frac{x}{\lambda}\right)^\beta\right) \quad \text{pour } x \geq 0,$$

avec $\theta = (\lambda, \beta) \in]0, \infty[^2$ inconnu.

- Déterminer $F(x)$ pour $x < 0$ **(0.5pts)**.
- Déterminer le modèle statistique paramétrique induit par (X_1, \dots, X_n) **(0.5pts)** et montrer qu'il est dominé **(1pt)**.
- Préciser la vraisemblance de ce modèle **(1pt)**.
- Le modèle fait-il partie de la famille exponentielle? (justifier...) **(3pts)**
- Montrer que la statistique $\hat{T} = (X_1, X_2, \dots, X_n)$ est exhaustive minimale pour ce modèle **(4pts)**.
- On suppose que β est connu. Préciser alors le modèle statistique et déterminer une statistique exhaustive complète pour ce modèle **(2pts)**.

Proof. (a) $F(x) = 0$ pour $x < 0$ car $F(0) = 0$ et F croissante.

(b) Le modèle paramétrique induit est $([0, \infty[^n, \mathcal{B}([0, \infty[^n), \mathbb{P}_\theta^{\otimes n})$ où $\theta = (\lambda, \beta) \in]0, \infty[^2$ car les variables sont iid, chacune de loi \mathbb{P}_θ . Comme F est absolument continue, $F(x) = \int_0^x f_\theta(t)dt$ où $f_\theta(x) = \frac{\beta}{\lambda} \left(\frac{x}{\lambda}\right)^{\beta-1} \exp\left(-\left(\frac{x}{\lambda}\right)^\beta\right)$ pour $x \geq 0$. La mesure qui domine est la mesure de Lebesgue sur $[0, \infty[^n$.

(c) Pour $(x_1, \dots, x_n) \in [0, \infty[^n$, $L_\theta(x_1, \dots, x_n) = \left(\frac{\beta}{\lambda}\right)^n \exp\left(-\sum_{i=1}^n \left(\frac{x_i}{\lambda}\right)^\beta\right) \prod_{i=1}^n \left(\frac{x_i}{\lambda}\right)^{\beta-1}$ car valid.

(d) On peut encore écrire que $L_\theta(x_1, \dots, x_n) = \exp\left(n \log(\beta/\lambda) + n(1-\beta) \log \lambda + (\beta-1) \sum_{i=1}^n \log x_i - \sum_{i=1}^n \left(\frac{x_i}{\lambda}\right)^\beta\right)$. On peut donc noter $\beta(\theta) = n \log(\beta/\lambda) + n(1-\beta) \log \lambda$, $b(x_1, \dots, x_n) = 0$, $a_1(x_1, \dots, x_n) = \sum_{i=1}^n \log x_i$ et $\alpha_1(\theta) = \beta - 1$ qui correspondent à un modèle de la famille exponentielle, mais $\sum_{i=1}^n \left(\frac{x_i}{\lambda}\right)^\beta$ ne peut pas s'écrire sous la forme $a_2(x_1, \dots, x_n)\alpha_2(\theta)$. Cela peut se montrer pour $n = 1$: si $x^\beta = f(\beta)g(x)$ pour tout $\beta > 0$ et tout $x \geq 0$, on aurait $g(x) = f(2)x^2 = f(1)x$ ce qui n'est clairement pas possible pour tout $x \geq 0$.

(e) La statistique \hat{T} est exhaustive (voir le cours). Pour montrer qu'elle est minimale, on écrit:

$$\frac{L_\theta(x_1, \dots, x_n)}{L_\theta(y_1, \dots, y_n)} = \exp\left((\beta-1) \sum_{i=1}^n \log(x_i/y_i) + \sum_{i=1}^n \left(\frac{y_i}{\lambda}\right)^\beta - \left(\frac{x_i}{\lambda}\right)^\beta\right).$$

Pour que ce rapport ne dépende pas de θ , cela revient à ce que pour $\lambda = 1$, $(\beta-1) \sum_{i=1}^n \log(x_i/y_i) + \sum_{i=1}^n y_i^\beta - x_i^\beta$ ne dépende pas de β . On peut dériver deux fois par rapport à β , et on devra avoir $\sum_{i=1}^n \log^2(y_i)y_i^\beta - \log^2(x_i)x_i^\beta = 0$ pour tout $\beta > 0$. Comme ceci doit être vrai quelque soient les n -uplets (x_1, \dots, x_n) et (y_1, \dots, y_n) on en déduit (en prenant par exemple tous les x_i et y_i égaux à 1 sauf pour $i = j$), que $x_j = y_j$ nécessairement, et ceci pour tout j . Donc $\hat{T}(x_1, \dots, x_j) = \hat{T}(y_1, \dots, y_j)$: la statistique est bien minimale.

- (f) Si β est connu, alors le modèle est le même que précédemment mais $\theta = \lambda \in]0, \infty[$.
Ce modèle appartient à la famille exponentielle avec la décomposition précédente. Comme β n'est plus inconnu, alors $b(x_1, \dots, x_n) = (\beta - 1) \sum_{i=1}^n \log x_i$ et $-\sum_{i=1}^n \left(\frac{x_i}{\lambda}\right)^\beta = a_1(x_1, \dots, x_n) \alpha_1(\theta)$, avec $\alpha_1(\lambda) = -\lambda^{-\beta}$ et $a_1(x_1, \dots, x_n) = \sum_{i=1}^n x_i^\beta$. On peut alors noter $\hat{T} = \sum_{i=1}^n x_i^\beta$. Ce sera une statistique exhaustive complète si l'ensemble des $\alpha(\lambda) = -\lambda^{-\beta}$ pour $\lambda > 0$ est d'intérieur non nul, ce qui est vrai car c'est $] -\infty, 0[$.

□

2. **(Sur 16 points)** Soit une suite $(\varepsilon_i)_{n \geq 1}$ de variables aléatoires indépendantes et identiquement distribuées suivant une loi de Bernoulli de paramètre $p \in]0, 1[$ inconnu. On définit également la suite $(X_n)_{n \geq 1}$ par

$$X_{n+1} = \varepsilon_{n+1} X_n \quad \text{pour } n \in \mathbf{N}^*, \text{ et } X_1 = \varepsilon_1.$$

On observe (X_1, \dots, X_n) où $n \in \mathbf{N}^*$.

- (a) Pour $k \in \mathbf{N}^*$ fixé, écrire X_k en fonction des ε_i **(0.5pts)**. Quelles sont les valeurs possibles pour X_k **(0.5pts)**? Quelle est sa loi **(0.5pts)**? Les variables (X_k) sont-elles indépendantes **(1.5pts)**? Identiquement distribuées **(0.5pts)**?
- (b) Montrer que le vecteur (X_1, \dots, X_n) ne peut prendre que $(n+1)$ valeurs que l'on précisera **(1pt)**. En déduire le modèle statistique induit par ce vecteur (on n'explicitera pas sa mesure de probabilité) **(0.5pts)**.
- (c) Démontrer que pour (x_1, \dots, x_n) appartenant au modèle statistique **(1pt)**:

$$\mathbb{P}\left((X_1, \dots, X_n) = (x_1, \dots, x_n)\right) = \mathbb{P}(X_1 = x_1) \prod_{k=2}^n \mathbb{P}\left(X_k = x_k \mid (X_1, \dots, X_{k-1}) = (x_1, \dots, x_{k-1})\right).$$

- (d) Montrer que $\mathbb{P}\left(X_k = x_k \mid (X_1, \dots, X_{k-1}) = (x_1, \dots, x_{k-1})\right) = \mathbb{P}\left(X_k = x_k \mid X_{k-1} = x_{k-1}\right)$ **(1pt)**, puis que $\mathbb{P}\left(X_k = x_k \mid X_{k-1} = x_{k-1}\right) = p^{x_k} (1-p)^{x_{k-1}-x_k}$ pour $k \geq 2$ **(2pts)**.
- (e) En déduire l'expression de la vraisemblance du modèle **(1pt)**.
- (f) Le modèle appartient-il à la famille exponentielle **(1pt)**?
- (g) Peut-on en déduire que $\hat{T} = (\sum_{i=1}^n X_i, X_n)$ est une statistique exhaustive complète pour le modèle **(3pts)**?
- (h) Déterminer l'estimateur par maximum de vraisemblance de p (c'est-à-dire la valeur de $p \in]0, 1[$ qui maximise la vraisemblance du modèle prise en (X_1, \dots, X_n)) et vérifier que c'est une fonction de \hat{T} **(2pts)**.

Proof. (a) On a facilement $X_k = \varepsilon_1 \times \dots \times \varepsilon_k$ pour tout $k \geq 1$.

Il est clair que X_k ne peut prendre pour valeurs que 0 ou 1. Elle suit donc une loi de Bernoulli. Par ailleurs, $\mathbb{P}(X_k = 1) = p^k$, donc X_k suit une loi de Bernoulli de paramètre p^k .

On a $\mathbb{P}(X_1 = 0 \cap X_2 = 1) = 0 \neq \mathbb{P}(X_1 = 0) \cap \mathbb{P}(X_2 = 1) = (1-p)p$, donc X_1 et X_2 sont indépendantes.

Comme $\mathbb{P}(X_k = 1) = p^k$, dépend de k , la loi de X_k dépend de k : les variables ne sont pas identiquement distribuées.

- (b) Il est clair que si $X_k = 0$ alors $X_{k+i} = 0$ pour tout $i \geq 0$. Donc (X_1, \dots, X_n) ne peut prendre que pour valeurs que les n -uplets $(0, \dots, 0)$, $(1, \dots, 1)$ ou tous ceux de type $(1, \dots, 1, 0, \dots, 0)$. Cela en fait bien $(n+1)$.
Le modèle statistique induit est donc $(\Omega_n, \mathcal{P}(\Omega_n), P_\theta^{(n)})$ où $\theta = p$, Ω_n l'ensemble des $n+1$ n -uplet défini au-dessus, $\mathcal{P}(\Omega_n)$ l'ensemble des parties de cet ensemble et $P_\theta^{(n)}$ la loi de probabilité de (X_1, \dots, X_n) .
- (c) On a $\mathbb{P}(A \cap B) = \mathbb{P}(B) \mathbb{P}(A \mid B)$ pour tous événements A et B . Donc $\mathbb{P}(X_n = x_n \cap \{X_{n-1} = x_{n-1}, \dots, X_1 = x_1\}) = \mathbb{P}(X_{n-1} = x_{n-1}, \dots, X_1 = x_1) \mathbb{P}(X_n = x_n \mid \{X_{n-1} = x_{n-1}, \dots, X_1 = x_1\})$ et on itère l'écriture.
- (d) On a $\mathbb{P}\left(X_k = x_k \mid (X_1, \dots, X_{k-1}) = (x_1, \dots, x_{k-1})\right) = \mathbb{P}\left(\varepsilon_k X_{k-1} = x_k \mid X_{k-1} = x_{k-1}\right)$. Or ε_k est indépendant de (X_1, \dots, X_{k-1}) donc $\varepsilon_k X_{k-1}$ ne dépend que de X_{k-1} , d'où le résultat.
On a $\mathbb{P}\left(X_k = x_k \mid X_{k-1} = x_{k-1}\right) = 1$ pour $x_{k-1} = 0$ et tout $x_k \in \{0, 1\}$, $\mathbb{P}\left(X_k = x_k \mid X_{k-1} = x_{k-1}\right) = p$

pour $x_{k-1} = 1$ et $x_k = 1$, et $\mathbb{P}(X_k = x_k | X_{k-1} = x_{k-1}) = 1 - p$ pour $x_{k-1} = 1$ et $x_k = 0$. La formule $\mathbb{P}(X_k = x_k | X_{k-1} = x_{k-1}) = p^{x_k} (1 - p)^{x_{k-1} - x_k}$ permet de retrouver ces 3 cas.

(e) En utilisant la formule établie plus haut, on en déduit que la vraisemblance du modèle est

$$L_\theta(x_1, \dots, x_n) = p^{x_1} (1 - p)^{1 - x_1} \prod_{k=2}^n p^{x_k} (1 - p)^{x_{k-1} - x_k} = p^{\sum_{k=1}^n x_k} (1 - p)^{1 - x_n}.$$

(f) On peut également écrire que

$$L_\theta(x_1, \dots, x_n) = \exp \left(\log(1 - p) + \log p \sum_{k=1}^n x_k - x_n \log(1 - p) \right).$$

Donc le modèle appartient à la famille exponentielle.

(g) D'après cette écriture on sait que $\widehat{T} = (\sum_{i=1}^n X_i, X_n)$ sera une statistique exhaustive complète si $\alpha(p) = (\log p, -\log(1 - p))$ décrit un ensemble d'intérieur non nul quand p varie dans $]0, 1[$, ce qui n'est pas le cas! (c'est une courbe dans un espace de dimension 2 donc on ne peut pas trouver une boule ouverte contenu dans cette courbe). On ne peut donc pas en déduire que la statistique est complète.

(h) On peut dériver $p \in]0, 1[\rightarrow \log(1 - p) + \log p \sum_{k=1}^n x_k - x_n \log(1 - p)$ et on obtient

$$\frac{X_n - 1}{1 - \widehat{p}} + \frac{1}{\widehat{p}} \sum_{k=1}^n X_k = 0 \iff \widehat{p} = \frac{\sum_{k=1}^n X_k}{1 - X_n + \sum_{k=1}^n X_k},$$

qui est bien une fonction de \widehat{T} . C'est bien un maximum car la dérivée seconde est $\frac{X_n - 1}{(1 - \widehat{p})^2} - \frac{1}{\widehat{p}^2} \sum_{k=1}^n X_k$ qui est négative strictement.

□