
EXAMEN STATISTIQUE - 1TR

Mardi 8 Décembre 2015

Partiel sans document (Une feuille A4 recto-verso autorisée)

Exercice 1 : Estimation (11 points)

On considère n variables aléatoires X_1, \dots, X_n indépendantes suivant la même loi continue de densité

$$p(x_i; r, \alpha) = \begin{cases} \frac{r\alpha^r}{(\alpha+x_i)^{r+1}} & \text{si } x_i > 0 \\ 0 & \text{sinon} \end{cases}$$

avec $\alpha > 0$ et $r > 2$. On admettra qu'une telle loi est de moyenne $E[X_i] = \frac{\alpha}{r-1}$ et de variance $\text{Var}[X_i] = \frac{2\alpha^2}{(r-1)(r-2)}$. On suppose que le paramètre α est connu et on cherche à étudier des estimateurs du paramètre r .

1. Montrer que la vraisemblance associée à l'échantillon (X_1, \dots, X_n) admet un unique maximum global pour une valeur de r que l'on déterminera. En déduire l'estimateur du maximum de vraisemblance de r noté \hat{r}_{MV} en fonction de n, α et de l'échantillon (X_1, \dots, X_n) .

2. En utilisant l'expression de $E[X_i]$, déterminer un estimateur des moments du paramètre r noté \hat{r}_{Mo} .

3. Montrer que si X_i possède la densité $p(x_i; r, \alpha)$ définie ci-dessus, alors $V_i = \ln\left(\frac{\alpha+X_i}{\alpha}\right)$ suit une loi exponentielle de densité

$$g(v_i; r) = \begin{cases} re^{-rv_i} & \text{si } v_i > 0 \\ 0 & \text{sinon} \end{cases}$$

En utilisant les tables de lois, déterminer la fonction caractéristique de V_i et montrer que $V = \sum_{i=1}^n V_i$ suit une loi gamma $\Gamma(r, n)$. En déduire que \hat{r}_{MV} suit une loi inverse gamma $IG(\theta, \nu)$ de paramètres $\theta = nr$ et $\nu = n$.

4. En utilisant le fait que \hat{r}_{MV} suit une loi inverse gamma $IG(\theta, \nu)$ de paramètres $\theta = nr$ et $\nu = n$, montrer que \hat{r}_{MV} est un estimateur biaisé du paramètre r et en déduire un estimateur non biaisé de r noté \hat{r}^* . Déterminer la variance de \hat{r}^* et en déduire que cet estimateur est convergent.

5. Déterminer la borne de Cramer-Rao d'un estimateur non biaisé de r . L'estimateur \hat{r}^* est-il l'estimateur efficace du paramètre r ?

6. On suppose qu'on dispose d'une information a priori sur le paramètre r résumée dans une loi gamma $\Gamma(a, b)$. Montrer que la loi a posteriori de $r|x_1, \dots, x_n$ est également une loi gamma dont on précisera les paramètres. Quel est l'estimateur du maximum a posteriori du paramètre r noté \hat{r}_{MAP} ?

Exercice 2: Tests Statistiques (9 points)

Comme dans l'exercice précédent, on considère n variables aléatoires X_1, \dots, X_n indépendantes suivant la même loi continue de densité

$$p(x_i; r, \alpha) = \begin{cases} \frac{r\alpha^r}{(\alpha+x_i)^{r+1}} & \text{si } x_i > 0 \\ 0 & \text{sinon} \end{cases}$$

avec $\alpha > 0$ et $r > 2$. Dans un premier temps, on cherche à effectuer le test d'hypothèses simples

$$H_0 : r = r_0$$

$$H_1 : r = r_1$$

avec $r_1 > r_0 > 2$.

1. Montrer que le test de Neyman Pearson conduit à la statistique de test

$$T_n = \sum_{i=1}^n \ln \left(\frac{\alpha + X_i}{\alpha} \right)$$

et indiquer la région critique de ce test.

2. On admet que T_n suit une loi gamma $\Gamma(r_j, n)$ sous l'hypothèse H_j avec $j \in \{0, 1\}$, et on suppose qu'on sait calculer la fonction Q_n définie par

$$Q_n(x) = \frac{1}{\Gamma(n)} \int_0^x u^{n-1} e^{-u} du$$

ainsi que son inverse $Q_n^{-1}(x)$ pour toutes les valeurs de n et de x . Déterminer la valeur du seuil K_α du test de Neyman Pearson en fonction de r_0, α et de Q_n^{-1} .

3. Déterminer la puissance du test en fonction de K_α, r_1 et Q_n . En déduire les courbes COR du test étudié dans cet exercice et tracer la forme de ces courbes pour différentes valeurs du couple (r_0, r_1) .
4. Lorsqu'on ne peut pas calculer les fonctions Q_n et Q_n^{-1} , on peut approcher la loi de T_n par une loi normale d'après le théorème de la limite centrale. Calculer le seuil K_α et la puissance du test lorsqu'on utilise cette loi approchée en fonction de n, r_0, r_1 et de la fonction de répartition de la loi normale $\mathcal{N}(0, 1)$. En déduire l'expression des courbes COR résultant de ces approximations.

Partie I

(1)

1) Vraisemblance de l'échantillon (2pts)

$$L(x_1, \dots, x_n; \alpha) = \prod_{i=1}^n \frac{\alpha^\alpha}{(\alpha + x_i)^{\alpha+1}} = \frac{(\alpha^\alpha)^\alpha}{\prod_{i=1}^n (\alpha + x_i)^{\alpha+1}}$$


donc $\ln L(x_1, \dots, x_n; \alpha) = n \ln \alpha + n \alpha \ln \alpha - \sum_{i=1}^n (\alpha + 1) \ln(\alpha + x_i)$

$$\frac{\partial \ln L}{\partial \alpha} \geq 0 \Leftrightarrow \frac{n}{\alpha} + n \ln \alpha - \sum_{i=1}^n \ln(\alpha + x_i) \geq 0$$

$$\Leftrightarrow \alpha \leq \frac{n}{\sum_{i=1}^n \ln\left(\frac{\alpha + x_i}{\alpha}\right)}$$

Rg = puisque $x_i > 0$, on a $\frac{\alpha + x_i}{\alpha} > 1$ et donc $\ln\left(\frac{\alpha + x_i}{\alpha}\right) > 0$

D'où le tableau de variations



On en déduit que $\frac{n}{\sum_{i=1}^n \ln\left(\frac{\alpha + x_i}{\alpha}\right)}$ est un maximum global unique de L
d'où

$$\hat{\alpha}_{MV} = \frac{n}{\sum_{i=1}^n \ln\left(\frac{\alpha + x_i}{\alpha}\right)}$$

1pt

2) Méthode des moments (1pt)

$$E[x_i] = \frac{\alpha}{\alpha - 1} \Leftrightarrow \alpha = 1 + \frac{\alpha}{E[x_i]}$$

d'où

$$\hat{\alpha}_{Mo} = 1 + \frac{\alpha}{\frac{1}{n} \sum_{i=1}^n x_i}$$

1pt

$$3) \quad v_i = \ln\left(\frac{\alpha + x_i}{\alpha}\right) \Leftrightarrow x_i = \alpha(e^{v_i} - 1) \quad (3 \text{ points}) \quad (2)$$

Le changement de variables est donc bijectif de \mathbb{R}^+ dans D , où D est défini par

$$x_i > 0 \Leftrightarrow \alpha(e^{v_i} - 1) > 0 \Leftrightarrow v_i > 0$$

c'est-à-dire $D = \mathbb{R}^+$. De plus, on a $\frac{dx_i}{dv_i} = \alpha e^{v_i}$, d'où la densité de v_i en appliquant le théorème du changement de variables

$$\pi(v_i) = \frac{\Gamma \alpha^\Gamma}{(\alpha e^{v_i})^{\Gamma+1}} \left| \alpha e^{v_i} \right| \mathbb{1}_D(v_i)$$

$$\boxed{\pi(v_i) = \Gamma e^{-\Gamma v_i} \mathbb{1}_{\mathbb{R}^+}(v_i)}$$

[1pt]

On reconnaît la densité d'une loi exponentielle, c'est-à-dire d'une loi gamma $\Gamma(\Gamma, 1)$. La fonction caractéristique de v_i est donnée dans les tables de lois

$$\phi_{v_i}(t) = E[e^{i v_i t}] = \frac{1}{1 - \frac{it}{\Gamma}}$$

Puisque les v_i sont indépendants, les v_i le sont aussi, d'où

$$\phi_v(t) = E[e^{itv}] = E\left[e^{it \sum_{k=1}^n v_k}\right] = E\left[\prod_{k=1}^n e^{itv_k}\right]$$

$$\stackrel{\substack{\uparrow \\ \text{ind des } v_k}}{\prod_{k=1}^n} E[e^{itv_k}] = \frac{1}{\left(1 - \frac{it}{\Gamma}\right)^n}$$

On reconnaît la fonction caractéristique d'une loi gamma $\Gamma(\Gamma, n)$

Donc $\boxed{v \sim \Gamma(\Gamma, n)}$ [1pt]

Pour avoir la loi de $\hat{\mu}_{MV}$, il suffit de remarquer que

$$\hat{\mu}_{MV} = \frac{n}{\sum_{k=1}^n \ln\left(\frac{\alpha + x_k}{\alpha}\right)} = \frac{n}{\sum_{k=1}^n v_k} = \frac{n}{v}$$

Pour avoir la loi de $\hat{\lambda}_{MV}$, il suffit de faire le changement de variables $w = \frac{n}{v}$ qui est bijectif de \mathbb{R}^+ dans \mathbb{R}^+ . De plus

(3)

$$w = \frac{n}{v} \Leftrightarrow v = \frac{n}{w} \Rightarrow \frac{dv}{dw} = -\frac{n}{w^2} \Rightarrow \left| \frac{dv}{dw} \right| = \frac{n}{w^2}$$

On en déduit la densité de w

$$h(w) = \frac{n^n}{\Gamma(n)} e^{-\frac{n}{w}} \left(\frac{n}{w}\right)^{n-1} \frac{n}{w^2} \mathbb{1}_{\mathbb{R}^+}(w)$$

Soit

$$h(w) = \frac{(n\Gamma)^n}{\Gamma(n)} \frac{1}{w^{n+1}} e^{-\frac{n}{w}} \mathbb{1}_{\mathbb{R}^+}(w)$$

On reconnaît la densité d'une loi inverse gamma de paramètres $n\Gamma$ et n , c'est à dire

$$\hat{\lambda}_{MV} = \frac{n}{v} \sim IG(n\Gamma, n) \quad [1 \text{ pt}]$$

4) En utilisant les tables de lois, on obtient les résultats suivants (2.5 points)

$$E[\hat{\lambda}_{MV}] = \frac{n\Gamma}{n-1}$$

$$\text{Var}[\hat{\lambda}_{MV}] = \frac{n^2\Gamma^2}{(n-1)^2(n-2)}$$

L'estimateur $\hat{\lambda}_{MV}$ est donc biaisé, mais on peut construire l'estimateur

$$\hat{\lambda}^* = \frac{n-1}{n} \hat{\lambda}_{MV} = \frac{n-1}{\sum_{i=1}^n \ln\left(\frac{\alpha + x_i}{\alpha}\right)} \quad [1 \text{ pt}]$$

qui vérifie $E[\hat{\lambda}^*] = \frac{n-1}{n} E[\hat{\lambda}_{MV}] = \Gamma$ et donc est non-biaisé. De manière immédiate, on obtient

$$\text{Var}(\hat{\lambda}^*) = \left(\frac{n-1}{n}\right)^2 \text{Var}(\hat{\lambda}_{MV}) = \frac{\Gamma^2}{n-2} \quad [1 \text{ pt}]$$

$$\text{Var}(\hat{\lambda}^*) \xrightarrow[n \rightarrow \infty]{} 0$$

$\hat{\lambda}^*$ non biaisé

$\Rightarrow \hat{\lambda}^*$ convergent
(estimateur convergent des)

[0.5 pt]

5) Borne de Cramér-Rao d'un estimateur non-biaisé de λ (1.5pr) (4)

On a $\frac{\partial \ln L}{\partial \lambda} = \frac{n}{\lambda} + n \ln \lambda - \sum_{i=1}^n \ln(\lambda + x_i)$ (voir question 1)

Donc $\frac{\partial^2 \ln L}{\partial \lambda^2} = -\frac{n}{\lambda^2} \Rightarrow E\left[-\frac{\partial^2 \ln L}{\partial \lambda^2}\right] = \frac{n}{\lambda^2}$

d'où la borne de Cramér-Rao

$$\boxed{B_{CR} = \frac{\lambda^2}{n}}$$

1pr

$Var(\hat{\lambda}^*) = \frac{\lambda^2}{n-2} > \frac{\lambda^2}{n} = B_{CR}$ donc $\hat{\lambda}^*$ n'est pas l'estimateur efficace de λ (0.5pr)

6) La loi a posteriori de $\lambda | x_1, \dots, x_n$ vérifie (2 points)

$P(\lambda | x_1, \dots, x_n) \propto$ $\begin{matrix} P(x_1, \dots, x_n; \lambda) & P(\lambda) \\ \uparrow & \uparrow \\ \text{proportionnel à} & \text{véraisemblance} & \text{loi a priori de } \lambda \end{matrix}$

soit

$P(\lambda | x_1, \dots, x_n) \propto \frac{\Gamma^n \lambda^{n\Gamma}}{\left[\prod_{i=1}^n (\lambda + x_i)\right]^{n+1}} e^{-a\lambda} \lambda^{b-1}$ \uparrow $\Gamma(\lambda)$

$\propto \Gamma^{n+b-1} \exp\left[-\lambda \left(a - \ln \lambda + \sum_{i=1}^n \ln(\lambda + x_i)\right)\right]$

On reconnaît une loi gamma de paramètres $a + \sum_{i=1}^n \ln\left(\frac{\lambda + x_i}{\lambda}\right)$ et $n+b$

soit

$$\boxed{\lambda | x_1, \dots, x_n \sim \Gamma\left(a + \sum_{i=1}^n \ln\left(\frac{\lambda + x_i}{\lambda}\right), n+b\right)}$$

1pr

L'estimateur du maximum a posteriori de λ s'obtient en maximisant $\ln p(\lambda | x_1, \dots, x_n)$ par rapport à λ . On obtient

$$\boxed{\hat{\lambda}_{MAP} = \frac{1 + \frac{b-1}{n}}{\frac{1}{n} \sum_{i=1}^n \ln\left(\frac{\lambda + x_i}{\lambda}\right) + \frac{a}{n}}}$$

1pr

On remarquera que $\frac{\hat{\Gamma}_{MAP}}{\hat{\Gamma}_{MV}} \xrightarrow[n \rightarrow +\infty]{} 1$

L'estimateur MAP se comporte comme l'estimateur du maximum de vraisemblance lorsque $n \rightarrow +\infty$, ce qui est un résultat très classique

Partie II = Test Statistique

1) Test de Neyman Pearson (1 point)

Il est défini par Rejet de H_0 si $\frac{P(x_1, \dots, x_n | H_1)}{P(x_1, \dots, x_n | H_0)} > \text{seuil}$

Soit

$$\text{Rejet de } H_0 \text{ si } \frac{\prod_{i=1}^n \left(\frac{\alpha+x_i}{\alpha}\right)^{\Gamma_0}}{\prod_{i=1}^n \left(\frac{\alpha+x_i}{\alpha}\right)^{\Gamma_1}} > s_\alpha$$

i.e., si $\sum_{i=1}^n (\Gamma_0 - \Gamma_1) \ln\left(\frac{\alpha+x_i}{\alpha}\right) > \ln s_\alpha$

Puisque $\Gamma_0 - \Gamma_1 < 0$, on déduit

Rejet de H_0 si $\sum_{i=1}^n \ln\left(\frac{\alpha+x_i}{\alpha}\right) < k_\alpha$ 1ph

2) Détermination du seuil k_α (1 point)

$$\alpha = P[\text{Rejet } H_0 | H_0 \text{ vraie}] = P[T_n < k_\alpha | H_0 \text{ vraie}]$$

Soit

$$\alpha = P[T_n < k_\alpha | T_n \sim \Gamma(\Gamma_0, n)] = \int_{-\infty}^{k_\alpha} \frac{\Gamma_0^n}{\Gamma(\Gamma_0)} e^{-\Gamma_0 x} x^{\Gamma_0-1} dx$$

On fait le changement de variables $u = \Gamma_0 x$ et on obtient

$$\alpha = \int_{-\infty}^{\Gamma_0 k_\alpha} \frac{\Gamma_0^n}{\Gamma(\Gamma_0)} e^{-u} \left(\frac{u}{\Gamma_0}\right)^{\Gamma_0-1} \frac{du}{\Gamma_0} = Q_n(\Gamma_0 k_\alpha)$$

d'où $\alpha = Q_n(\Gamma_0 k_\alpha)$ et donc $k_\alpha = \frac{1}{\Gamma_0} Q_n^{-1}(\alpha)$ 1ph

3) Puissance du test et courbes COR (2 points)

La puissance du test est $\pi = P[\text{Rejeter } H_0 | H_1 \text{ vraie}] = 1 - \beta$


donc $\pi = P(T_n < k_\alpha | T_n \sim \Gamma(\lambda_1, n))$

$\pi = Q_n(\lambda_1, k_\alpha)$

En remplaçant k_α par son expression, on obtient

$\pi = Q_n\left[\frac{\lambda_1}{\lambda_0} Q_n^{-1}(\alpha)\right]$ (1pr)

On remarque que π est une fonction croissante de $\frac{\lambda_1}{\lambda_0}$. On a donc des courbes COR de la forme



(1pr)

4) Théorème de la limite centrale (4 points)

Puisque T_n est la somme de n variables aléatoires indépendantes $V_i = \ln\left(\frac{\alpha + X_i}{\alpha}\right)$ et de même loi, on peut appliquer le théorème de la limite centrale

$T_n \underset{n \text{ grand}}{\sim} W\left(nE[V_i], n\text{Var}[V_i]\right)$

Puisque T_n suit une loi gamma $\Gamma(\lambda_1, n)$ sous l'hypothèse H_1 , on a

$E[T_n] = \frac{n}{\lambda_1}$ et $\text{Var}[T_n] = \frac{n}{\lambda_1^2}$

soit

$T_n \underset{n \text{ grand}}{\sim} W\left(\frac{n}{\lambda_1}, \frac{n}{\lambda_1^2}\right)$ sous l'hypothèse H_1 (1pr)

On en déduit

$$\alpha = P[T_n < k_\alpha | \Gamma = \Gamma_0] \sim P\left[\frac{T_n - n/\Gamma_0}{\sqrt{n/\Gamma_0^2}} < \frac{k_\alpha - n/\Gamma_0}{\sqrt{n/\Gamma_0^2}} \mid U_n \sim N(0,1)\right] \quad (7)$$

Est

$$\alpha = F_{N(0,1)}\left[\frac{k_\alpha - n/\Gamma_0}{\sqrt{n/\Gamma_0^2}}\right] = \boxed{F_{N(0,1)}\left[\frac{\Gamma_0 k_\alpha - n}{\sqrt{n}}\right]} \quad [1pt]$$

On en déduit

$$\frac{\Gamma_0 k_\alpha}{\sqrt{n}} - \sqrt{n} = F_{N(0,1)}^{-1}(\alpha)$$

$$\text{ou } \boxed{k_\alpha = \frac{\sqrt{n}}{\Gamma_0} \left[\sqrt{n} + F_{N(0,1)}^{-1}(\alpha) \right]} \quad (*)$$

De la même manière

$$\boxed{\pi = F_{N(0,1)}\left[\frac{\Gamma_1 k_\alpha - n}{\sqrt{n}}\right]} \quad [1pt]$$

d'où, en remplaçant k_α par son expression (*)

$$\boxed{\pi = F_{N(0,1)}\left[\frac{\Gamma_1}{\Gamma_0} \sqrt{n} - \sqrt{n} + \frac{\Gamma_1}{\Gamma_0} F_{N(0,1)}^{-1}(\alpha)\right]} \quad [1pt]$$

On remarquera qu'à nouveau π ne dépend de Γ_0 et de Γ_1 que via le rapport $\frac{\Gamma_1}{\Gamma_0}$.

BARÈME

Partie I (13 points)

1) $\hat{\alpha}_{MV} = \frac{n}{\sum_{i=1}^n \ln(\frac{\alpha + X_i}{\alpha})}$ [1pt]

max de vraisemblance

$L \rightarrow \frac{n}{\sum \ln(\frac{\alpha + X_i}{\alpha})}$ [1pt]

2) $\hat{\Gamma}_{MO} = 1 + \frac{\alpha}{x}$ [1pt]

3) $\pi(v_i) = \alpha e^{-\alpha v_i} \mathbb{1}_{\mathbb{R}^+(v_i)}$ [1pt]

$V = \sum_{i=1}^n v_i \sim \Gamma^2(\alpha, n)$ [1pt]

$\hat{\alpha}_{MV} = \frac{n}{V} \sim \mathcal{IG}(n, n\alpha)$ [1pt]

4) $\hat{\alpha}^* = \frac{n-1}{n} \hat{\alpha}_{MV}$ [0.5]

$E(\hat{\alpha}_{MV}) = \frac{n\alpha}{n-1}$ [0.5]

$Var(\hat{\alpha}^*) = \frac{\alpha^2}{n-2}$ [1pt]

$\hat{\alpha}^*$ convergent [0.5]

5) $BCR = \frac{\alpha^2}{n}$ [1]

$\hat{\alpha}^*$ non efficace [0.5]

$\Gamma | x_1, \dots, x_n \sim \Gamma^2\left(\alpha + \sum_{i=1}^n \ln(\frac{\alpha + X_i}{\alpha}), b+n\right)$ [1pt]

$\hat{\alpha}_{MAP} = \frac{1 + \frac{b-1}{n}}{\frac{1}{n} \sum_{k=1}^n \ln(\frac{\alpha + X_k}{\alpha}) + \frac{\alpha}{n}}$ [1pt]

$\frac{\hat{\alpha}_{MAP}}{\hat{\alpha}_{MV}} \rightarrow 1$
 $n \rightarrow \infty$

(2)

(1)

(3)

(2.5)

(1.5)

(1pt)


Partie II (8 points)

(8)

1) Rejet de H_0 si $T_n < k_\alpha$
 $T_n = \sum_{k=1}^n \ln(\frac{\alpha + X_i}{\alpha})$ [1]

2) $\alpha = Q_n(\tau_0, k_\alpha)$ [1]

3) $\pi = Q_n\left[\frac{\tau_1}{\tau_0}, Q_n^{-1}(\alpha)\right]$



(2)

4) $T_j \sim N\left(\frac{n}{j}, \frac{n}{j^2}\right)$ [1pt]

$\alpha = F_{N(0,1)}\left[\frac{k_\alpha - \frac{n}{\tau_0}}{\sqrt{\frac{n}{\tau_0^2}}}\right]$ [1pt]

$\pi = F\left[\frac{k_\alpha - \frac{n}{\tau_1}}{\sqrt{\frac{n}{\tau_1^2}}}\right]$ [1pt]

$\pi = F\left[\frac{\frac{\tau_1}{\tau_0} F^{-1}(\alpha) + \frac{\tau_1}{\tau_0} \sqrt{n} - \sqrt{n}}{\sqrt{\frac{n}{\tau_0^2}}}\right]$ [1pt]

(4)

(3)