

## Correction Feuille de Travaux Dirigés 3

### Tests Asymptotiques

#### Exercice 1

1 Nous calculons tout d'abord la densité de  $Y_i = (Y_i^1, Y_i^2, Y_i^3)$  pour  $i = 1, \dots, n$ . Soit  $y_i = (y_i^1, y_i^2, y_i^3)$  une observation de  $Y_i$ , et  $\theta = (\gamma, \lambda, p)$ .

Pour tout  $i$  :

$$\begin{aligned} f(y_i, \theta) &= f(y_i^1) \times f(y_i^2 | y_i^1) \times f(y_i^3 | y_i^1, y_i^2) \\ &= \gamma e^{-\gamma y_i^1} \times e^{-\lambda y_i^1} \frac{(\lambda y_i^1)^{y_i^2}}{y_i^2!} \times C_{y_i^2}^{y_i^3} p^{y_i^3} (1-p)^{y_i^2 - y_i^3} \\ &= \gamma e^{-(\gamma + \lambda) y_i^1} (\lambda y_i^1)^{y_i^2} \frac{p^{y_i^3} (1-p)^{y_i^2 - y_i^3}}{y_i^3! (y_i^2 - y_i^3)!}. \end{aligned}$$

Notant  $y = (y_1, \dots, y_n)$ , la log-vraisemblance est alors :

$$\begin{aligned} L_n(y, \theta) &= \sum_{i=1}^n \log f(y_i, \theta) \\ &= n \log \gamma - (\gamma + \lambda) \sum_{i=1}^n y_i^1 + \sum_{i=1}^n y_i^2 \log(\lambda y_i^1) + \sum_{i=1}^n y_i^3 \log p \\ &\quad + \sum_{i=1}^n (y_i^2 - y_i^3) \log(1-p) - \sum_{i=1}^n \log(y_i^3! (y_i^2 - y_i^3)!). \end{aligned}$$

Nous calculons ensuite les dérivées partielles de  $L_n$  par rapport à  $\lambda, \gamma, p$ , soit

$$\frac{\partial L_n(y, \theta)}{\partial \gamma} = \frac{n}{\gamma} - \sum_{i=1}^n y_i^1$$

$$\begin{aligned}\frac{\partial L_n(y, \theta)}{\partial \lambda} &= -\sum_{i=1}^n y_i^1 + \frac{\sum_{i=1}^n y_i^2}{\lambda} \\ \frac{\partial L_n(y, \theta)}{\partial p} &= \frac{\sum_{i=1}^n y_i^3}{p} - \frac{\sum_{i=1}^n (y_i^2 - y_i^3)}{1-p}.\end{aligned}$$

D'où, en remarquant  $\mathbb{E}(Y_i^2) = \mathbb{E}(\mathbb{E}(Y_i^2|Y_i^1)) = \mathbb{E}(\lambda Y_i^1) = \frac{\lambda}{\gamma}$  et  $\mathbb{E}(Y_i^3) = p\lambda/\gamma$  (même calcul).

$$\begin{aligned}\mathbb{E}\left(\frac{\partial L_n(Y, \theta)}{\partial \gamma}\right) &= \frac{n}{\gamma} - \sum_{i=1}^n \mathbb{E}(Y_i^1) = \frac{n}{\gamma} - \frac{n}{\gamma} = 0 \\ \mathbb{E}\left(\frac{\partial L_n(Y, \theta)}{\partial \lambda}\right) &= -\frac{n}{\gamma} + \frac{1}{\lambda} \sum_{i=1}^n \mathbb{E}(Y_i^2) = 0 \\ \mathbb{E}\left(\frac{\partial L_n(Y, \theta)}{\partial p}\right) &= \frac{\sum_{i=1}^n \mathbb{E}(Y_i^3)}{p} - \frac{\sum_{i=1}^n \mathbb{E}(Y_i^2 - Y_i^3)}{1-p} = 0,\end{aligned}$$

Ceci donne le résultat.

**2** Pour obtenir les estimateurs de maximum de vraisemblance, nous annulons les dérivées partielles ce qui donne : notant  $\overline{Y^j} = \frac{1}{n} \sum_{i=1}^n Y_i^j$ , la moyenne empirique,

$$\begin{aligned}\frac{\partial L_n(Y, \theta)}{\partial \gamma} = 0 &\iff \hat{\gamma} = \frac{n}{\sum_{i=1}^n Y_i^1} \implies \hat{\gamma} = \frac{1}{\overline{Y^1}} \\ \frac{\partial L_n(Y, \theta)}{\partial \lambda} = 0 &\iff \hat{\lambda} = \frac{\sum_{i=1}^n Y_i^2}{\sum_{i=1}^n Y_i^1} \implies \hat{\lambda} = \frac{\overline{Y^2}}{\overline{Y^1}}\end{aligned}$$

$$\frac{\partial L_n(Y, \theta)}{\partial p} = 0 \iff \hat{p} = \frac{\sum_{i=1}^n Y_i^3}{\sum_{i=1}^n Y_i^2} \implies \hat{\lambda} = \frac{\overline{Y^3}}{\overline{Y^2}}.$$

Nous calculons maintenant la matrice des dérivées secondes, soit

$$\frac{\partial^2 L_n(y, \theta)}{\partial \theta^2} = \begin{pmatrix} -\frac{n}{\gamma^2} & 0 & 0 \\ 0 & -\frac{\sum_{i=1}^n y_i^2}{\lambda^2} & 0 \\ 0 & 0 & -\frac{\sum_{i=1}^n y_i^3}{p^2} - \frac{\sum_{i=1}^n (y_i^2 - y_i^3)}{(1-p)^2} \end{pmatrix}$$

et donc

$$\Gamma_n(\theta) = -\mathbb{E} \left( \frac{\partial^2 L_n(Y, \theta)}{\partial \theta^2} \right) = \begin{pmatrix} \frac{n}{\gamma^2} & 0 & 0 \\ 0 & \frac{n}{\lambda\gamma} & 0 \\ 0 & 0 & \frac{n\lambda}{\gamma p} + \frac{n\lambda}{\gamma(1-p)} \end{pmatrix}$$

et

$$\Gamma(\theta) = \frac{1}{n} \Gamma_n(\theta) = \begin{pmatrix} \frac{1}{\gamma^2} & 0 & 0 \\ 0 & \frac{1}{\lambda\gamma} & 0 \\ 0 & 0 & \frac{1\lambda}{\gamma p} + \frac{1\lambda}{\gamma(1-p)} \end{pmatrix}.$$

Nous savons de plus que

$$\sqrt{n}(\hat{\theta} - \theta) \rightarrow \mathcal{N}_3(0, \Gamma^{-1}(\theta))$$

avec

$$\Gamma^{-1}(\theta) = \begin{pmatrix} \gamma^2 & 0 & 0 \\ 0 & \lambda\gamma & 0 \\ 0 & 0 & \frac{\gamma p(1-p)}{\lambda} \end{pmatrix}.$$

Ce qui signifie notamment que pour  $n$  grand, nous avons  $\sqrt{n}(\gamma - \hat{\gamma})/\hat{\gamma} \sim \mathcal{N}(0, 1)$ .

Si  $u_\alpha$  est le quantile d'ordre  $1 - \alpha/2$  d'une loi normale centrée réduite, alors

$$\mathbb{P}(-u_\alpha \leq \mathcal{N}(0, 1) \leq u_\alpha) = 1 - \alpha.$$

Nous trouvons ainsi pour les intervalles de confiance :

$$\gamma \quad : \quad IC = \left[ \hat{\gamma} \pm u_\alpha \frac{\hat{\gamma}}{\sqrt{n}} \right]$$

$$\lambda \quad : \quad IC = \left[ \hat{\lambda} \pm u_\alpha \sqrt{\frac{\hat{\lambda}\hat{\gamma}}{n}} \right]$$

$$p \quad : \quad IC = \left[ \hat{p} \pm u_\alpha \sqrt{\frac{\hat{\gamma}\hat{p}(1-\hat{p})}{\hat{\lambda}n}} \right]$$

### 3 Test de Wald

Il s'agit ici de  $h(\theta) = \gamma - \lambda$  et  $H_0 : \{\theta : h(\theta) = 0\}$ .

Nous avons  $h'(\theta) = (1, -1, 0)$ , d'où

$$\sqrt{n}((\hat{\gamma} - \hat{\lambda}) - (\gamma - \lambda)) \rightarrow \mathcal{N}(0, h'(\theta)\Gamma^{-1}(\theta)^t h'(\theta)) \sim \mathcal{N}(0, \gamma^2 + \lambda\gamma)$$

ce qui donne la statistique de Wald :

$$W = \frac{n(\hat{\gamma} - \hat{\lambda})^2}{\hat{\gamma}^2 + \hat{\lambda}\hat{\gamma}}.$$

Sous l'hypothèse  $H_0$ , nous avons  $W \rightarrow \chi^2(1)$ . Pour un risque de première espèce asymptotiquement égal à  $\alpha$ , nous rejetons  $H_0$  si  $w > F_{\chi^2(1)}^{-1}(1 - \alpha)$  où  $w$  est la réalisation de la variable aléatoire  $W$ .

### Test du rapport de vraisemblance

Soit  $L_n^0$  la vraisemblance de  $y$  sous l'hypothèse  $H_0$ . Soit  $\hat{\gamma}^0$  et  $\hat{p}^0$  les estimateurs du maximum de vraisemblance de  $\gamma$  et  $p$  sous l'hypothèse  $H_0$ .

$$\text{Nous avons } \frac{\partial L_n^0(y, \gamma, p)}{\partial \gamma} = \frac{n}{\gamma} - 2 \sum_{i=1}^n y_i^1 + \frac{\sum_{i=1}^n y_i^2}{\gamma}$$

$$\text{et } \frac{\partial L_n^0(y, \gamma, p)}{\partial p} = \frac{\sum_{i=1}^n y_i^3}{p} - \frac{\sum_{i=1}^n (y_i^2 - y_i^3)}{1-p}.$$

Ainsi,  $\hat{\gamma}_0 = \frac{1+\bar{Y}^2}{2\bar{y}^1} = \frac{\hat{\gamma}+\hat{\lambda}}{2}$  et  $\hat{p}_0 = \hat{p}$ .

La statistique du rapport de vraisemblance est alors :

$$R = 2 \left( L_n(Y, \hat{\theta}) - L_n^0(Y, \hat{\gamma}^0, \hat{p}^0) \right)$$

$$\begin{aligned}
&= 2 \left( n \log \left( \frac{2\hat{\gamma}}{\hat{\gamma} + \hat{\lambda}} \right) + \log \left( \frac{2\hat{\lambda}}{\hat{\gamma} + \hat{\lambda}} \right) \sum_{i=1}^n Y_i^2 \right) \\
&= 2n \left( \log \left( \frac{2\hat{\gamma}}{\hat{\gamma} + \hat{\lambda}} \right) + \frac{\hat{\lambda}}{\hat{\gamma}} \log \left( \frac{2\hat{\lambda}}{\hat{\gamma} + \hat{\lambda}} \right) \right)
\end{aligned}$$

Sous l'hypothèse  $H_0$ , nous avons  $R \rightarrow \chi^2(1)$ . Pour un risque de première espèce asymptotiquement égal à  $\alpha$ , nous rejetons  $H_0$  si  $r > F_{\chi^2(1)}^{-1}(1 - \alpha)$  où  $r$  est la réalisation de la variable aléatoire  $R$ .

## Exercice 2

**1** Soit  $I_{X_1, \dots, X_n}(\mu, \sigma^2)$  la matrice d'information de Fisher apporté par l'échantillon  $X_1, \dots, X_n$  sur les paramètres  $\mu$  et  $\sigma^2$ .

Nous avons

$$I_{X_1, \dots, X_n}(\mu, \sigma^2) = n \begin{bmatrix} 1/\sigma^2 & 0 \\ 0 & 1/(2\sigma^4) \end{bmatrix}.$$

**2** Nous avons

$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}, \quad \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \hat{\mu})^2.$$

Sous l'hypothèse  $H_0$ ,  $\sigma^2 = \mu^2$ .

Après calculs nous obtenons,

$$\tilde{\mu} = \frac{\sqrt{(\sum_{i=1}^n X_i)^2 + 4n \sum_{i=1}^n X_i^2}}{2n} - \frac{\bar{X}}{2}.$$

En outre, sous l'hypothèse  $H_0$ , nous avons

$$\mathbb{E} \left[ \left( a \sum_{i=1}^n X_i - \mu \right)^2 \right] = na^2 \mu^2 + \mu^2 (an - 1)^2.$$

Par conséquent sous l'hypothèse  $H_0$ , le meilleur estimateur de  $\mu$  au sens de l'erreur quadratique moyenne de la forme  $a \sum_{i=1}^n X_i$  est  $\frac{1}{n+1} \sum_{i=1}^n X_i$ .

**3**  $H_0 : \{\sigma^2 = \mu^2\} : \{h(\mu, \sigma^2) = \mu^2 - \sigma^2 = 0$   
 Sous l'hypothèse  $H_0$ ,  $\sqrt{n}(\hat{\mu}^2 - \hat{\sigma}^2) \rightarrow N(0, 4\mu^2\sigma^2 + 2\sigma^4)$ .  
 Ainsi

$$W = \frac{n((\hat{\mu})^2 - \hat{\sigma}^2)^2}{4\hat{\mu}^2\hat{\sigma}^2 + 2\hat{\sigma}^4} \rightarrow \chi^2(1).$$

Pour un risque de première espèce asymptotiquement égal à  $\alpha$ , le test de Wald consiste à rejeter  $H_0$  si  $w > F_{\chi^2(1)}^{-1}(1 - \alpha)$  où  $w$  est la réalisation de la variable aléatoire  $W$ .

### Exercice 3

Soit  $f$  la densité de  $y = (y_1, \dots, y_n)$ .

$$\text{Nous avons } f(y; \lambda) = \prod_{i=1}^n e^{-\lambda} \frac{\lambda^{y_i}}{y_i!} = e^{-n\lambda} \frac{\lambda^{\sum_{i=1}^n y_i}}{\prod_{i=1}^n y_i!}.$$

Soit  $L_n$  la log-vraisemblance.

$$\text{Nous avons } L_n(y; \lambda) = - \sum_{i=1}^n \log(y_i!) - n\lambda + \sum_{i=1}^n y_i \log(\lambda)$$

et  $\frac{\partial L_n(y; \lambda)}{\partial \lambda} = -n + \left(\frac{1}{\lambda}\right) \sum_{i=1}^n y_i.$

Soit  $\hat{\lambda}$  l'estimateur du maximum de vraisemblance de  $\lambda$ .  $\hat{\lambda}$  est tel que :

$$\text{CN1 : } -n + \left(\frac{1}{\hat{\lambda}}\right) \sum_{i=1}^n Y_i = 0 \iff \hat{\lambda} = \left(\frac{1}{n}\right) \sum_{i=1}^n Y_i = \bar{Y}.$$

CN2 : Vérifiée.

Soit  $I_n(\lambda)$  l'information de Fisher.

$$\text{Nous avons } I_n(\lambda) = \mathbb{V} \left( \frac{\partial L_n(Y; \lambda)}{\partial \lambda} \right) = \frac{n}{\lambda}.$$

**Test de Wald**  $H_0 : \lambda = \lambda_0$

Nous avons  $\sqrt{n}(\hat{\lambda} - \lambda) \rightarrow N\left(0, \frac{n}{I_n(\lambda)}\right)$ . Ainsi,  $\sqrt{n}(\hat{\lambda} - \lambda) \rightarrow N(0, \lambda)$ .

Par conséquent, sous  $H_0$ ,  $\frac{n(\hat{\lambda} - \lambda_0)^2}{\lambda_0} \rightarrow \chi^2(1)$ .

Pour un risque de première espèce asymptotiquement égal à  $\alpha$ , nous rejetons  $H_0$  si  $\frac{n(\bar{y} - \lambda_0)^2}{\lambda_0} > F_{\chi^2(1)}^{-1}(1 - \alpha)$ .

**Test du rapport de vraisemblance  $H_0 : \lambda = \lambda_0$**

Sous  $H_0$ , nous avons  $2 \left( L_n(Y; \hat{\lambda}) - L_n(Y; \lambda_0) \right) \rightarrow \chi^2(1)$ .

Ainsi,  $2 \left( n\bar{Y} [\log(\bar{Y}) - \log(\lambda_0)] + n[\lambda_0 - \bar{Y}] \right) \rightarrow \chi^2(1)$ .

Pour un risque de première espèce asymptotiquement égal à  $\alpha$ , nous rejetons  $H_0$  si  $2 \left( n\bar{y} [\log(\bar{y}) - \log(\lambda_0)] + n[\lambda_0 - \bar{y}] \right) > F_{\chi^2(1)}^{-1}(1 - \alpha)$ .

**Test du score  $H_0 : \lambda = \lambda_0$**

Nous maximisons  $L_n$  par rapport à  $\lambda$  sous la contrainte  $\lambda = \lambda_0$ . Soit  $\alpha$  le multiplicateur de Lagrange associé à la contrainte  $\lambda = \lambda_0$ .

Le lagrangien  $K$  est

$$K(\lambda, \alpha) = - \sum_{i=1}^n \log(y_i!) - n\lambda + \sum_{i=1}^n y_i \log(\lambda) + \alpha(\lambda - \lambda_0).$$

$$\text{CKT} : -n + \left( \frac{1}{\hat{\lambda}} \right) \sum_{i=1}^n Y_i + \hat{\alpha} = 0 \text{ et } \hat{\lambda} = \lambda_0.$$

$$\text{D'où, } \hat{\lambda} = \lambda_0 \text{ et } \hat{\alpha} = n - \left( \frac{1}{\lambda_0} \right) \sum_{i=1}^n Y_i.$$

CN2 : Vérifiée.

Sous  $H_0$ , nous avons  $\frac{n}{nI_n(\lambda_0)} \left( n - \frac{n\bar{Y}}{\lambda_0} \right)^2 \rightarrow \chi^2(1)$ .

D'où, sous  $H_0$ ,  $\frac{n(\bar{Y} - \lambda_0)^2}{\lambda_0} \rightarrow \chi^2(1)$ .

Pour un risque de première espèce asymptotiquement égal à  $\alpha$ , nous rejetons  $H_0$  si  $\frac{n(\bar{y} - \lambda_0)^2}{\lambda_0} > F_{\chi^2(1)}^{-1}(1 - \alpha)$ .

Le test du score est, dans ce cas, équivalent au test de Wald.

#### Exercice 4

Posons  $x = (x_1, \dots, x_n)$  et  $y = (y_1, \dots, y_n)$ .

Soit  $f$  la densité de  $(x, y)$ .

$$\text{Nous avons } f(x, y; \lambda, \mu) = e^{-n(\lambda+\mu)} \frac{\lambda^{\sum_{i=1}^n x_i} \mu^{\sum_{i=1}^n y_i}}{\prod_{i=1}^n x_i! y_i!}.$$

Soit  $L_n$  la log-vraisemblance.

Nous avons :

$$L_n(x, y; \lambda, \mu) = -n(\lambda + \mu) + \log(\lambda) \sum_{i=1}^n x_i + \log(\mu) \sum_{i=1}^n y_i - \sum_{i=1}^n \log(x_i! y_i!)$$

Soit  $(\hat{\lambda}, \hat{\mu})$  l'estimateur du maximum de vraisemblance de  $(\lambda, \mu)$ .

$(\hat{\lambda}, \hat{\mu})$  est tel que :

$$\text{CN1 : } -n + \frac{\sum_{i=1}^n X_i}{\hat{\lambda}} = 0 \text{ et } -n + \frac{\sum_{i=1}^n Y_i}{\hat{\mu}} = 0.$$

D'où,  $\hat{\lambda} = \bar{X}$  et  $\hat{\mu} = \bar{Y}$ .

CN2 : Vérifiée.

Soit  $I_n(\lambda, \mu)$  la matrice d'information de Fisher.

$$\text{Nous avons } I_n(\lambda, \mu) = \begin{bmatrix} \frac{n}{\lambda} & 0 \\ 0 & \frac{n}{\mu} \end{bmatrix}.$$

**Test de Wald**  $H_0 : \{\lambda = \mu\} : \{h(\lambda, \mu) = \lambda - \mu = 0\}$

Nous avons  $\sqrt{n} \left[ (\hat{\lambda} - \hat{\mu}) - (\lambda - \mu) \right] \rightarrow N(0, \lambda + \mu)$ .

D'où, sous  $H_0$ ,  $\frac{n(\bar{X} - \bar{Y})^2}{\bar{X} + \bar{Y}} \rightarrow \chi^2(1)$ .

Pour un risque de première espèce asymptotiquement égal à  $\alpha$ , nous rejetons

$$H_0 \text{ si } \frac{n(\bar{x} - \bar{y})^2}{\bar{x} + \bar{y}} > F_{\chi^2(1)}^{-1}(1 - \alpha).$$



## Exercice 5

### 1 Calcul de l'espérance

$$\mathbb{E}_\beta(X_i) = \int_0^\beta x \frac{(\alpha+1)x^\alpha}{\beta^{\alpha+1}} dx = \frac{\alpha+1}{\alpha+2} \beta.$$

d'où  $\mathbb{E}\left(\frac{\alpha+2}{\alpha+1} \sum_{i=1}^n \frac{X_i}{n}\right) = \beta$ , et on en déduit ainsi l'estimateur empirique sans biais de  $\beta$

$$\hat{\beta} = \frac{\alpha+2}{\alpha+1} \sum_{i=1}^n \frac{X_i}{n}.$$

**2** On utilise le théorème de factorisation de Neyman-Fisher : une CNS pour que la statistique  $S$  soit exhaustive est que la densité s'écrive  $f_\beta(x) = g_\beta(S(x)) h(x)$  avec  $g_\beta$  et  $h$  deux fonctions mesurables.

Dans notre cas, notant  $x = (x_1, \dots, x_n)$

$$\begin{aligned} f_\beta(x) &= \prod_1^n \frac{(\alpha+1)x_i^\alpha}{\beta^{\alpha+1}} 1_{]0, \beta[}(x_i) \\ &= \frac{(\alpha+1)^n}{\beta^{n(\alpha+1)}} \prod_1^n x_i^\alpha 1_{]0, \beta[}(x_i) \\ &= \frac{(\alpha+1)^n}{\beta^{n(\alpha+1)}} \prod_1^n x_i^\alpha 1_{0 < \min_i(x_i)} 1_{\max_i(x_i) < \beta} \\ &= \underbrace{(\alpha+1)^n \prod_1^n x_i^\alpha 1_{0 < \min_i(x_i)}}_{h(x)} \underbrace{\frac{1_{\max_i(x_i) < \beta}}{\beta^{n(\alpha+1)}}}_{g_\beta(S(x))}. \end{aligned}$$

d'où  $Y = \max(X_1, \dots, X_n)$  est une statistique exhaustive pour  $\beta$ .

### 3 Calculons tout d'abord la loi de $Y$ ,

$$\begin{aligned} \mathbb{P}(Y \leq y) &= \mathbb{P}(\max(X_1, \dots, X_n) \leq y) \\ &= \mathbb{P}(X_1 \leq y, \dots, X_n \leq y) \\ &= \begin{cases} \mathbb{P}(X_1 \leq y)^n & \text{si } y \in ]0, \beta[ \\ 0 & \text{si } y \leq 0 \\ 1 & \text{si } y \geq \beta \end{cases} \end{aligned}$$

or pour  $y \in ]0, \beta[$

$$\mathbb{P}(X_1 \leq y) = \int_0^y (\alpha + 1) \frac{x^\alpha}{\beta^{\alpha+1}} dx = \frac{y^{\alpha+1}}{\beta^{\alpha+1}}$$

d'où

$$\mathbb{P}(Y \leq y) = \begin{cases} \frac{y^{n\alpha+n}}{\beta^{n\alpha+n}} & \text{si } y \in ]0, \beta[ \\ 0 & \text{si } y \leq 0 \\ 1 & \text{si } y \geq \beta \end{cases}$$

ce qui permet de calculer la densité de  $Y$

$$f_Y(y) = \frac{n\alpha + n}{\beta^{n\alpha+n}} y^{n\alpha+n-1} 1_{]0, \beta[}(y).$$

On peut ainsi calculer l'espérance de  $Y$

$$\mathbb{E}_\beta(Y) = \frac{n\alpha + n}{n\alpha + n + 1} \beta$$

et on déduit donc l'estimateur sans biais de  $\beta$  basé sur la statistique exhaustive  $Y$

$$\tilde{\beta} = \frac{n\alpha + n + 1}{n\alpha + n} \max(X_1, \dots, X_n).$$

4 Comparons les variances de ces deux estimateurs.

$$\begin{aligned} \mathbb{V}(\hat{\beta}) &= V\left(\frac{\alpha + 2}{\alpha + 1} \sum_1^n \frac{X_i}{n}\right) \\ &= \left(\frac{\alpha + 2}{\alpha + 1}\right)^2 \frac{V(X_1)}{n} \\ &= \left(\frac{\alpha + 2}{\alpha + 1}\right)^2 \frac{\beta^2}{n} \left(\frac{\alpha + 1}{\alpha + 3} - \left(\frac{\alpha + 1}{\alpha + 2}\right)^2\right) \\ &= \frac{1}{(\alpha + 1)(\alpha + 3)} \frac{\beta^2}{n} \end{aligned}$$

$$\begin{aligned} \mathbb{V}(\tilde{\beta}) &= \left(\frac{n\alpha + n + 1}{n\alpha + n}\right)^2 V(Y) \\ &= \left(\frac{n\alpha + n + 1}{n\alpha + n}\right)^2 \left(\frac{n\alpha + n}{n\alpha + n + 2} - \left(\frac{n\alpha + n}{n\alpha + n + 1}\right)^2\right) \beta^2 \\ &= \frac{1}{(n\alpha + n)(n\alpha + n + 2)} \beta^2 \end{aligned}$$

ce qui permet ainsi de vérifier que

$$V(\hat{\beta}) \geq V(\tilde{\beta}).$$

**5** On dit que  $S$  est complète si et seulement si  $\mathbb{E}_\beta(f(S)) = 0 \quad \forall \beta \in \Theta \Rightarrow f = 0 \quad \mathbb{P}_\beta - p.s. \quad \forall \beta \in \Theta$ .

$$\mathbb{E}_\beta(f(Y)) = 0 \iff \int_0^\beta f(y)y^{n\alpha+n-1}dy = 0$$

ce qui implique en dérivant des deux côtés que  $\forall \beta > 0$

$$\beta^{n\alpha+n-1}f(\beta) = 0 \iff f(\beta) = 0$$

et donc  $Y$  est une statistique complète. Par le théorème de Lehmann-Scheffé, on a alors que  $\tilde{\beta}$  est optimal sans biais.