

Statistique/Modèle linéaire

Corrigé commenté du partiel du 12 novembre 2002

EXERCICE 1

1. Non, il n'est pas vrai que $f(x|\theta) > f(x|d)$ pour tout x ! Par contre, comme la fonction \log est concave, par l'inégalité de Jensen,

$$\mathbb{E}_\theta [-\log h(X)] \geq -\log \mathbb{E}_\theta [h(X)],$$

et

$$\begin{aligned} \mathbb{E}_\theta \left[\log \frac{f(X|\theta)}{f(X|d)} \right] &= \mathbb{E}_\theta \left[-\log \frac{f(X|d)}{f(X|\theta)} \right] \geq -\log \mathbb{E}_\theta \left[\frac{f(X|d)}{f(X|\theta)} \right] \\ &= -\log \int \frac{f(x|d)}{f(x|\theta)} f(x|\theta) dx = 0 \end{aligned}$$

L'égalité n'a lieu que si la variable aléatoire $f(X|d)/f(X|\theta)$ est presque sûrement constante, car \log est strictement concave. Donc seulement si $f(\cdot|\theta) > f(\cdot|d)$.

2. Pour la loi $\mathcal{N}(\theta, 1)$, $f(x|\theta) \propto \exp -(x - \theta)^2/2$ et

$$L^\epsilon(\theta, d) = \mathbb{E}_\theta [(X - d)^2 - (X - \theta)^2] / 2 = (\theta - d)^2 / 2.$$

Pour la loi $\mathcal{N}(0, e^{2\theta})$, $f(x|\theta) \propto e^{-\theta} \exp -x^2/2e^{2\theta}$, donc $\log f(x|\theta) = -\theta - e^{-2\theta} x^2/2 + c$ et

$$\begin{aligned} L^\epsilon(\theta, d) &= \mathbb{E}_\theta [d - \theta - (X^2/2) \{e^{-2\theta} - e^{-2d}\}] \\ &= d - \theta - e^{2\theta} \{e^{-2\theta} - e^{-2d}\} / 2 \\ &= d - \theta + \{e^{2(\theta-d)} - 1\} / 2 \end{aligned}$$

Pour la loi $\mathcal{P}(e^\theta)$, $f(x|\theta) = e^{-e^\theta} e^{x\theta} / x!$, donc

$$L^\epsilon(\theta, d) = \mathbb{E}_\theta [e^{-d} - e^\theta + X(\theta - d)] = e^d - e^\theta + e^\theta(\theta - d)$$

3. Pour la distribution $\mathcal{N}(0, e^{2\theta})$, le coût à minimiser (en d) est

$$\mathbb{E}^\pi [d - \theta + \{e^{2(\theta-d)} - 1\} / 2 | x],$$

donc en dérivant par rapport à d ,

$$1 - \mathbb{E}^\pi [e^{2(\theta-d)} | x] = 0$$

soit encore

$$d^* = \log \{ \mathbb{E}^\pi [e^{2\theta} | x] \} / 2$$

4. Si $\mu = \exp(-2\theta) \sim \beta^\alpha \frac{\mu^{\alpha-1}}{\Gamma(\alpha)} \exp(-\beta\mu)$, la formule du Jacobien donne

$$\begin{aligned} \theta &\sim \beta^\alpha \frac{\exp\{-2(\alpha-1)\theta\}}{\Gamma(\alpha)} \exp\{-\beta \exp(-2\theta)\} 2 \exp\{-2\theta\} \\ &= 2\beta^\alpha \frac{\exp\{-2\alpha\theta\}}{\Gamma(\alpha)} \exp\{-\beta \exp(-2\theta)\} \end{aligned}$$

Cette loi est conjuguée si $X \sim \mathcal{N}(0, e^{2\theta})$ puisque

$$\pi(\theta|x) \propto \exp\{-2\alpha\theta\} \exp\{-\beta \exp(-2\theta)\} \times \exp\{-\theta\} \exp\{-(x^2/2) \exp(-2\theta)\};$$

α est donc changé en $\alpha + (1/2)$ et β en $\beta + (x^2/2)$. On retrouve simplement le résultat connu que, si $1/\mu \sim \mathcal{G}(\alpha, \beta)$,

$$1/\mu | x \sim \mathcal{G}(\alpha + 1/2, \beta + (x^2/2)).$$

Alors

$$\delta^\pi(x) = \frac{1}{2} \log \mathbb{E}^\pi [e^{2\theta} | x] = \frac{1}{2} \log \mathbb{E}^\pi \left[\frac{1}{\mu} \middle| x \right] = \frac{1}{2} \log \frac{\alpha + 1/2}{\beta + (x^2/2)} = \frac{1}{2} \log \frac{2\alpha + 1}{2\beta + x}$$

5. Si $\alpha = \beta = 0$, δ^π est bien défini pour $x > 0$, à la fois dans la formule ci-dessus et comme estimateur associé à la loi a posteriori $\mathcal{G}(1/2, x^2/2)$.

EXERCICE 2

1. La loi exponentielle est une loi sur \mathbb{R}_+ , pas sur \mathbb{N} . Et la loi de Y a comme support $\{0, 1\} \dots$ Il vient $Y_i \sim B(p)$, où

$$p = P(X_i \geq 2) = \int_2^\infty \theta e^{-\theta x} dx = -e^{-\theta x} \Big|_2^\infty = e^{-2\theta},$$

2. $\hat{\theta} = -\frac{\log \bar{Y}}{2}$ converge p.s. vers $-\frac{\log \mathbb{E}(Y_i)}{2}$. Donc, comme la transformation est régulière,

$$\hat{\theta} \xrightarrow{n \rightarrow \infty} -\frac{\log p}{2} = -\frac{\log e^{-2\theta}}{2} = \theta. \quad (p.s.)$$

3. Par le TCL,

$$\sqrt{n} (\bar{Y} - p) \xrightarrow{n \rightarrow \infty} \mathcal{N}(0, p(1-p)).$$

Posons $g(x) = -\log(x)/2$. Alors, par le théorème de Slutsky,

$$\begin{aligned} \sqrt{n} (g(\bar{Y}) - g(p)) &\xrightarrow{n \rightarrow \infty} \mathcal{N}(0, p(1-p)g'(p)^2) \\ \Leftrightarrow \sqrt{n} (\hat{\theta} - \theta) &\xrightarrow{n \rightarrow \infty} \mathcal{N}\left(0, \frac{p(1-p)}{4p^2}\right) \\ \Leftrightarrow \sqrt{n} (\hat{\theta} - \theta) &\xrightarrow{n \rightarrow \infty} \mathcal{N}\left(0, \frac{e^{2\theta} - 1}{4}\right) \quad [p = e^{-2\theta}] \end{aligned}$$

4. Dans le cas où l'alternative est $\theta = \theta_1$, le test de Neyman-Pearson est fondé sur le rapport des vraisemblances en θ_0 et en θ_1 , qui ne dépend que de

$$\exp\{(\theta_1 - \theta_0)n\bar{x}\}.$$

Donc, si $\theta_1 > \theta_0$, ce test rejette H_0 pour $\bar{x} > k$, tandis que, pour $\theta_1 < \theta_0$, ce test rejette H_0 pour $\bar{x} < k'$. Il n'y a donc pas de test de Neyman-Pearson pour l'ensemble des alternatives possibles. On prendra à la place un test de la forme

$$\varphi(\bar{x}) = \begin{cases} 1 & \text{si } \bar{x} \in [k', k] \\ 0 & \text{sinon} \end{cases}$$

Le problème étant la détermination des bornes, on simplifie en prenant (k, k') tel que

$$k^{n-1} e^{-\theta_0 k} = k'^{n-1} e^{-\theta_0 k'},$$

avec $\Pr_{\theta_0}(\bar{X} \in [k', k]) = \alpha$.

5. Comme $\tilde{\theta} = 1/\bar{X}$ est l'emv dans ce cas, que l'information de Fisher est $1/\theta^2$ pour la loi exponentielle, on a l'approximation

$$\sqrt{n} \frac{\tilde{\theta} - \theta}{\theta} \approx \mathcal{N}(0, 1)$$

et la statistique de Wald vaut

$$\xi_n^W = n \frac{(\hat{\theta} - \theta_0)^2}{\hat{\theta}^2} = n\bar{X}^2 \{(1/\bar{X}) - \theta_0\}^2 \sim \chi_1^2 \quad \text{sous } H_0.$$

6. Suivant le résultat de la question 3,

$$\sqrt{n} \sqrt{\frac{4}{e^{2\theta} - 1}} (\hat{\theta} - \theta) \xrightarrow{n \rightarrow \infty} \mathcal{N}(0, 1),$$

et la statistique de Wald vaut

$$\xi_n^W = \frac{4n}{e^{2\theta} - 1} (\hat{\theta} - \theta)^2 = \frac{4n}{(1/\bar{Y}) - 1} \left\{ -\frac{\log \bar{Y}}{2} - \theta_0 \right\}^2$$

7. On accepte H_0 si

$$n\bar{x}^2((1/\bar{x}) - \theta_0)^2 = 143.143 (\theta_0 - 0.473)^2 < 3.84$$

pour les X_i , et si

$$\frac{4n}{(1/\bar{y}) - 1} (\hat{\theta} - \theta_0)^2 = 112.601 (\theta_0 - 0.380)^2 < 3.84,$$

pour les Y_i . Les réponses au test pourront donc différer suivant les valeurs de θ_0 , comme le montre le graphe ci-dessous (où la courbe marron correspond aux Y_i et celle en noir aux X_i).

