

Ex1 La vraisemblance de $x = (x_1, \dots, x_n)$ et $y = (y_1, \dots, y_m)$ s'écrit

1

$$L(x, y; \mu) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma_1^2}} \exp\left(-\frac{(x_i - \mu)^2}{2\sigma_1^2}\right) \times \prod_{j=1}^m \frac{1}{\sqrt{2\pi\sigma_2^2}} \exp\left[-\frac{(y_j - \mu)^2}{2\sigma_2^2}\right]$$

(pr)
$$= \frac{1}{(2\pi)^{n+m/2}} \frac{1}{(\sigma_1^2)^{n/2} (\sigma_2^2)^{m/2}} \exp\left[-\frac{1}{2\sigma_1^2} \sum_{i=1}^n (x_i - \mu)^2 - \frac{1}{2\sigma_2^2} \sum_{j=1}^m (y_j - \mu)^2\right]$$

(1 pr)

La log-vraisemblance s'écrit (à une constante additive près)

$$\ln L(x, y; \mu) = K - \frac{1}{2\sigma_1^2} \sum_{i=1}^n (x_i - \mu)^2 - \frac{1}{2\sigma_2^2} \sum_{j=1}^m (y_j - \mu)^2$$

sa dérivée est


$$\begin{aligned} \frac{\partial \ln L}{\partial \mu} &= \frac{1}{\sigma_1^2} \left(\sum_{i=1}^n x_i - n\mu \right) + \frac{1}{\sigma_2^2} \left(\sum_{j=1}^m y_j - m\mu \right) \\ &= \frac{n}{\sigma_1^2} (\bar{x} - \mu) + \frac{m}{\sigma_2^2} (\bar{y} - \mu) \end{aligned}$$

Donc

$$\frac{\partial \ln L}{\partial \mu} \geq 0 \Leftrightarrow \frac{n\bar{x}}{\sigma_1^2} + \frac{m\bar{y}}{\sigma_2^2} \geq \frac{n\mu}{\sigma_1^2} + \frac{m\mu}{\sigma_2^2} = \mu \left(\frac{n}{\sigma_1^2} + \frac{m}{\sigma_2^2} \right)$$

$$\Leftrightarrow \mu \leq \frac{\frac{n}{\sigma_1^2} \bar{x} + \frac{m}{\sigma_2^2} \bar{y}}{\frac{n}{\sigma_1^2} + \frac{m}{\sigma_2^2}} = \frac{1}{1 + \frac{\sigma_1^2 n}{\sigma_2^2 m}} \bar{x} + \frac{\frac{m}{\sigma_2^2}}{\frac{m}{\sigma_2^2} + \frac{n}{\sigma_1^2}} \bar{y}$$

on pose $\alpha = \frac{1}{1 + \frac{\sigma_1^2 n}{\sigma_2^2 m}}$ et on remarque $\frac{m/\sigma_2^2}{m/\sigma_2^2 + n/\sigma_1^2} = 1 - \alpha$ d'où le tableau de variation



qui montre que la vraisemblance admet un maximum global unique pour $\mu = \alpha \bar{x} + (1-\alpha) \bar{y}$

On en conclut

2pts

$$\hat{\mu}_{MV} = \alpha \bar{X} + (1-\alpha) \bar{Y}$$

$$E[\hat{\mu}_{MV}] = \alpha \mu + (1-\alpha) \mu = \mu$$

donc $\hat{\mu}_{MV}$ est un estimateur non biaisé de μ

1pt

En utilisant l'indépendance entre \bar{X} et \bar{Y} , on obtient

$$\text{Var} \hat{\mu}_{MV} = \alpha^2 \text{Var} \bar{X} + (1-\alpha)^2 \text{Var} \bar{Y}$$

1pt

$$\text{Var} \hat{\mu}_{MV} = \left[\alpha^2 \frac{\sigma_1^2}{n} + (1-\alpha)^2 \frac{\sigma_2^2}{m} \right]$$

Lorsque $n=m$; on a $\alpha = \frac{\sigma_2^2}{\sigma_1^2 + \sigma_2^2}$ et $1-\alpha = \frac{\sigma_1^2}{\sigma_1^2 + \sigma_2^2}$ qui

sont tous deux indépendants de n . Donc

$$\text{Var} \hat{\mu}_{MV} \xrightarrow{n=m \rightarrow \infty} 0$$

Rg: Comme $\hat{\mu}_{MV}$ est non biaisé et que $\text{Var}[\hat{\mu}_{MV}] \rightarrow 0$ on en déduit que $\hat{\mu}_{MV}$ est un estimateur convergent de μ

3) La borne de Cramer-Rao pour un estimateur non

$$\text{BCR}(\mu) = \frac{-1}{E\left[\frac{\partial^2 \text{Ln} L(x,y|\mu)}{\partial \mu^2}\right]}$$

1pt

$$\frac{\partial^2 \text{Ln} L}{\partial \mu^2} = -\frac{n}{\sigma_1^2} - \frac{m}{\sigma_2^2} \quad \text{d'où} \quad \text{BCR}(\mu) = \frac{\sigma_1^2 \sigma_2^2}{n \sigma_2^2 + m \sigma_1^2}$$

Pour déterminer si $\hat{\mu}_{MV}$ est l'estimateur efficace du paramètre μ , il suffit de vérifier si $\text{Var}(\hat{\mu}_{MV}) = \text{BCR}(\mu)$

$$\begin{aligned} \text{Mais } \text{Var}[\hat{\mu}_{MV}] &= \alpha^2 \frac{\sigma_1^2}{n} + (1-\alpha)^2 \frac{\sigma_2^2}{m} \\ &= \frac{\left(\frac{n}{\sigma_1^2}\right)^2 \frac{\sigma_1^2}{n}}{\left(\frac{n}{\sigma_1^2} + \frac{m}{\sigma_2^2}\right)^2} + \frac{\left(\frac{m}{\sigma_2^2}\right)^2 \frac{\sigma_2^2}{m}}{\left(\frac{n}{\sigma_1^2} + \frac{m}{\sigma_2^2}\right)^2} = \frac{1}{\frac{n}{\sigma_1^2} + \frac{m}{\sigma_2^2}} \end{aligned}$$

c'est-à-dire

$$\text{Var}[\hat{\mu}_{MV}] = \frac{\sigma_1^2 \sigma_2^2}{n\sigma_2^2 + m\sigma_1^2} = \text{BCR}(\mu)$$

3

On en déduit que $\hat{\mu}_{MV}$ est l'estimateur efficace du paramètre μ

1 pr

4) On a vu que $\text{BCR}(\mu) = \frac{\sigma_1^2 \sigma_2^2}{n\sigma_2^2 + m\sigma_1^2} = \frac{1}{n}$

Donc pour $\sigma_1^2 = \sigma_2^2 = \sigma^2$ on a $\text{BCR}_1(\mu) = \frac{\sigma^2}{n+m}$

1 pr Tandis que pour $\sigma_1^2 = 2\sigma_2^2 = \sigma^2$ on a $\text{BCR}_2(\mu) = \frac{\sigma^2}{n+2m}$

Comme $\frac{\sigma^2}{n+2m} < \frac{\sigma^2}{n+m}$, le second cas donne une performance optimale d'estimation (donnée par la borne de Cramér-Rao) meilleure que le premier cas. Ceci s'explique car dans le second cas, le capteur #2 a une variance $\sigma_2^2 = \frac{\sigma^2}{2}$ plus faible que dans le premier cas où $\sigma_2^2 = \sigma^2$.

Ex2

1) Le test de Neyman-Pearson est défini par

$$\text{Rejet de } H_0 \text{ si } \frac{\prod_{i=1}^n f(x_i; \theta_1)}{\prod_{i=1}^n f(x_i; \theta_0)} > K_{\alpha}$$

c'est-à-dire (après quelques calculs élémentaires)

$$\text{Rejet de } H_0 \text{ si } \underbrace{\left(\frac{1}{\theta_0} - \frac{1}{\theta_1}\right)}_{> 0 \text{ car } \theta_1 > \theta_0} \sum_{i=1}^n x_i^3 > K_{\alpha}$$

On en déduit

1 pr

$$\text{Rejet de } H_0 \text{ si } T_n = \sum_{i=1}^n x_i^3 > S_{\alpha}$$

2) Il suffit d'effectuer un changement de variable

$$y_i = \frac{2}{\theta} x_i^3 \text{ est un changement de variables bijectif de } \mathbb{R}^+ \text{ dans } \mathbb{R}^+$$

$$y_i = \frac{2}{\theta} x_i^3 \Leftrightarrow x_i = \left(\frac{\theta}{2} y_i\right)^{1/3}$$

Le Jacobien de cette transformation s'est

14

$$J = \left(\frac{dx_i}{dy_i} \right) = \left(\frac{\theta}{2} \right)^{n/3} \frac{1}{3} y_i^{-2/3}$$

On en déduit la densité de y_i

$$\pi(y_i) = \frac{2}{\theta} \underbrace{\left(\frac{\theta}{2} \right)^{n/3}}_{\cancel{\theta^2}} y_i^{2/3} \exp\left(-\frac{y_i}{2}\right) \underbrace{\left(\frac{\theta}{2} \right)^{n/3}}_{\cancel{\theta^2}} \frac{1}{3} y_i^{-2/3} \mathbb{1}_{\mathbb{R}^+}(y_i)$$

c'est

1 pr

$$\pi(y_i) = \frac{1}{2} \exp\left(-\frac{y_i}{2}\right) \mathbb{1}_{\mathbb{R}^+}(y_i)$$

qui est bien la densité d'une loi du χ^2_2 .

Si $Z \sim \chi^2_{n_2}$ et $T \sim \chi^2_{n_T}$, on a en vertu de l'indépendance entre Z et T

$$\phi_{Z+T}(t) = E[e^{izt} e^{iTt}] = \phi_Z(t) \phi_T(t)$$

Fonction caractéristique de $Z+T$

En utilisant les tables, on obtient $\phi_{Z+T}(t) = \frac{1}{(1-2it)^{\frac{n_2+n_T}{2}}}$

qui est la fonction caractéristique d'une loi du $\chi^2_{n_2+n_T}$.

On en déduit

$$T+Z \sim \chi^2_{n_2+n_T}$$

1 pr

3) On sait que $\alpha = P[\text{Rejeter } H_0 \mid H_0 \text{ vraie}] = P\left[T_n = \sum_{i=1}^n X_i^3 > S_\alpha \mid \theta = \theta_0\right]$

Donc

$$\alpha = P\left[\frac{2}{\theta_0} T_n = \sum_{i=1}^n \frac{2}{\theta_0} X_i^3 > \frac{2}{\theta_0} S_\alpha \mid \frac{2}{\theta_0} T_n \sim \chi^2_{2n}\right]$$

Soit

$$\alpha = 1 - F_{2n}\left(\frac{2}{\theta_0} S_\alpha\right), \text{ i.e.,}$$

$$S_\alpha = \frac{\theta_0}{2} F_{2n}^{-1}(1-\alpha)$$

1 pr

4) De la même façon, la puissance du test est

$$\pi = P[\text{Rejeter } H_0 \mid H_1 \text{ vraie}] = P\left[\frac{2}{\theta_1} T_n > \frac{2}{\theta_1} S_\alpha \mid \frac{2}{\theta_1} T_n \sim \chi^2_{2n}\right]$$

donc

$$\pi = 1 - F_{2n}\left[\frac{2}{\theta_1} S_\alpha\right] = 1 - F_{2n}\left[\frac{\theta_0}{\theta_1} F_{2n}^{-1}(1-\alpha)\right] = \pi$$

1 pr

1 pr

On observe que la puissance ne dépend que de $\frac{\theta_0}{\theta_1}$.

Plus θ_2 augmente, plus $\frac{\theta_0}{\theta_1}$ diminue - Mais F_{Z_n} est une fonction croissante (comme toute fonction de répartition) -

Donc plus θ_2 augmente, plus $F_{Z_n} \left[\frac{\theta_0}{\theta_1}, F_{Z_n}^{-1}(1-\alpha) \right]$ diminue donc plus π augmente. Ceci est normal car $\frac{\theta_0}{\theta_1}$ représente l'écart entre θ_0 et θ_1 - Plus celui-ci augmente, meilleur est le test

1 pr

Ex3

1) Le test de Kolmogorov est défini par

$$\text{Rejet de } H_0 \text{ si } T_n = \sup_{y \in \mathbb{R}} |F_n(y) - F(y)| > K_\alpha$$

(1 pr) où $F_n(y)$ est la fonction de répartition empirique de (y_1, \dots, y_n) et $F(y)$ est la fonction de répartition théorique de la loi testée (ici inclue χ^2_2)

2) Nous avons vu en cours que

$$\sup_{y \in \mathbb{R}} |F_n(y) - F(y)| = \sup_{i=1, \dots, n} \left\{ \max \left\{ \left| F(y_i) - \frac{i-1}{n} \right|, \left| F(y_i) - \frac{i}{n} \right| \right\} \right\} = E_i$$

on obtient en observant $\frac{1}{n} = \frac{1}{5} = 0.2$

$$E_1 = \max \left\{ \left| F(y_1) - 0 \right|, \left| F(y_1) - 0.2 \right| \right\} = \max \{ 0.42, 0.22 \} = 0.42$$

$$E_2 = \max \left\{ \left| F(y_2) - \frac{1}{5} \right|, \left| F(y_2) - \frac{2}{5} \right| \right\} = \max \{ 0.48, 0.28 \} = 0.48$$

(1 pr) $E_3 = \max \{ 0.53, 0.33 \} = 0.53$

$$E_4 = \max \{ 0.38, 0.18 \} = 0.18$$

$$E_5 = \max \{ 0.19, 0.01 \} = 0.19$$

(1 pr) $T_n = \sup_{i=1, \dots, 5} E_i = 0.53$

3)

3) on a $\alpha = P(\text{Rejeter } H_0 \mid H_0 \text{ vraie}) = P(T_n > S_\alpha \mid H_0 \text{ vraie})$ (6)

donc plus α est grand plus le on rejette H_0 et plus le seuil S_α est faible d'où $S_{0.05} (=0.294) < S_{0.01} (=0.352)$

(1pt)

4) On ne peut calculer la puissance du test de Kolmogorov car la loi de T_n sous H_1 est inconnue.

(1pt)