

A

Ex1

$$1) L(x_1, \dots, x_n; \theta) = \prod_{i=1}^n \frac{1}{\theta^p \Gamma(p)} \frac{1}{x_i^{p+1}} \exp\left(-\frac{1}{\theta} \sum_{i=1}^n \frac{1}{x_i}\right)$$

$$= \frac{1}{\theta^{np} \Gamma_p^n} \prod_{i=1}^n x_i^{p+1} \exp\left(-\frac{1}{\theta} \sum_{i=1}^n \frac{1}{x_i}\right)$$

$$\text{Donc } \ln L(x_1, \dots, x_n; \theta) = -np \ln \theta + \frac{1}{\theta} \sum_{i=1}^n \frac{1}{x_i} + \text{quantité indépendante}$$

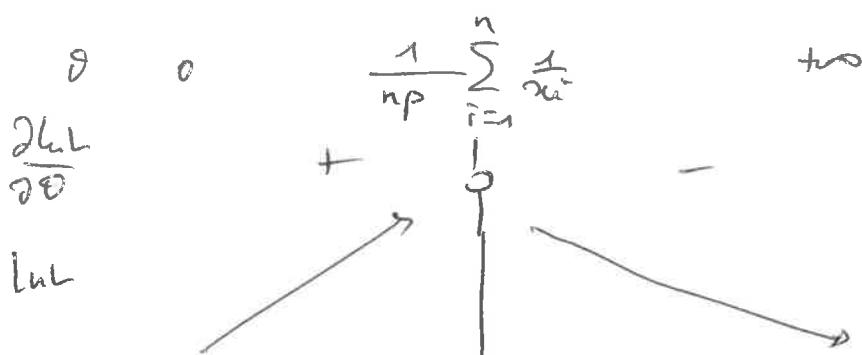
On en déduit

$$\frac{\partial \ln L}{\partial \theta} = -\frac{np}{\theta} + \frac{1}{\theta^2} \sum_{i=1}^n \frac{1}{x_i}$$

On peut étudier les variations de la fonction  $\ln L$  puisque

$$\frac{\partial \ln L}{\partial \theta} \geq 0 \Leftrightarrow -\frac{np}{\theta} + \frac{1}{\theta^2} \sum_{i=1}^n \frac{1}{x_i} \geq 0 \Leftrightarrow \theta \leq \frac{1}{np} \sum_{i=1}^n \frac{1}{x_i}$$

On a



ce qui montre que  $\theta = \frac{1}{np} \sum_{i=1}^n \frac{1}{x_i}$  est un maximum global unique de  $L(x_1, \dots, x_n; \theta)$ . On en déduit

1pt

$$\hat{\theta}_{\text{MV}} = \frac{1}{np} \sum_{i=1}^n \frac{1}{x_i}$$

2) On effectue un changement de variables pour trouver la loi de  $Y_i = \frac{1}{x_i}$   
La densité de  $Y_i$  est

$$\pi(y_i) = \frac{1}{\theta^{np} \Gamma(p)} y_i^{p+1} \exp\left(-\frac{y_i}{\theta}\right) \left| \frac{dx_i}{dy_i} \right|$$

Le Jacobien est  $\left| \frac{dx_i}{dy_i} \right| = \left| \frac{1}{y_i^2} \right| = \frac{1}{y_i^2}$  et le changement de variables est bijectif de  $\mathbb{R}^+$  dans  $\mathbb{R}^+$ . On en déduit

1pt

$$\pi(y_i) = \frac{y_i^{p-1}}{\theta^{np} \Gamma(p)} \exp\left(-\frac{y_i}{\theta}\right) D_{R^+}(y_i)$$

qui est bien la densité de la loi  $\Gamma(\theta, v)$  avec  $\theta = \frac{1}{\hat{\theta}}$  et  $v = p$

B

On en déduit à l'aide des tables

$$E[Y_i] = \frac{v}{\theta} = p\hat{\theta}$$

$$\text{Var}[Y_i] = \frac{v}{(\theta^2)} = \frac{p}{p\hat{\theta}^2}$$

3)  $E[\hat{\theta}_{\text{MV}}] = \frac{1}{np} \sum_{i=1}^n E[Y_i] = \hat{\theta}$  donc  $\hat{\theta}_{\text{MV}}$  est un estimateur

0,5 non biaisé du paramètre  $\theta$

①  $\text{Var} \hat{\theta}_{\text{MV}} = \frac{1}{n^2 p^2} \sum_{i=1}^n \text{Var} Y_i = \frac{np\hat{\theta}^2}{n^2 p^2} = \boxed{\frac{\hat{\theta}^2}{np}}$

$Y_1, \dots, Y_n$  va ind

Puisque  $\hat{\theta}_{\text{MV}}$  est non biaisé et que  $\text{Var} \hat{\theta}_{\text{MV}} \xrightarrow[n \rightarrow \infty]{\text{as}} \hat{\theta}_{\text{MV}}$  est un estimateur convergent de  $\theta$

0,5

4) La borne de Cramér-Rao d'un estimateur non biaisé de  $\theta$  est définie par

$$\text{BCR}(\theta) = \frac{-1}{E\left[\frac{\partial^2 \ln L(X_1, \dots, X_n; \theta)}{\partial \theta^2}\right]}$$

On a vu  $\frac{\partial \ln L}{\partial \theta} = -\frac{np}{\theta} + \frac{1}{\theta^2} \sum_{i=1}^n \frac{1}{x_i}$

donc  $\frac{\partial^2 \ln L}{\partial \theta^2} = \frac{np}{\theta^2} - \frac{2}{\theta^3} \sum_{i=1}^n \frac{1}{x_i}$

et finalement  $E\left[\frac{\partial^2 \ln L}{\partial \theta^2}\right] = \frac{np}{\theta^2} - \frac{2}{\theta^3} \sum_{i=1}^n \frac{E[Y_i]}{p\hat{\theta}} = \frac{-np}{\theta^2}$

Sont

$$\boxed{\text{BCR}(\theta) = \frac{\theta^2}{np}}$$

$\text{Var} \hat{\theta}_{\text{MV}} = \text{BCR} \theta$

$\hat{\theta}_{\text{MV}}$  non biaisé

$\Rightarrow \hat{\theta}_{\text{MV}}$  est l'estimateur efficace de  $\theta$

0,5

5) La vraisemblance  $L(x_1, \dots, x_n; p, \theta)$  est définie par (voir question) [C]

$$L(x_1, \dots, x_n; p, \theta) = \frac{1}{\theta^n p^{\sum x_i}} \exp\left(-\frac{1}{\theta} \sum_{i=1}^n \frac{1}{x_i}\right)$$

L'estimateur du maximum de vraisemblance du couple  $(p, \theta)$  se détermine en cherchant la ou les solutions du système

$$\begin{cases} \frac{\partial L}{\partial p} = 0 \\ \frac{\partial L}{\partial \theta} = 0 \end{cases} \quad \text{ou} \quad \begin{cases} \frac{\partial \ln L}{\partial p} = 0 \\ \frac{\partial \ln L}{\partial \theta} = 0 \end{cases}$$

Comme En raison de la fonction  $\Gamma^n(p)$ , la première équation

$\frac{\partial L}{\partial p} = 0$  (ou  $\frac{\partial \ln L}{\partial p} = 0$ ) n'admet pas de solution simple

0,5

On a vu  $E[Y_i] = M_1 = \boxed{p\theta}$

et  $E[Y_i^2] = M_2 = \text{Var}[Y_i] + E[Y_i]^2 = \boxed{p\theta^2 + p^2\theta^2}$

On peut donc exprimer  $p$  et  $\theta$  en fonction de  $M_1$  et  $M_2$ . Des calculs élémentaires conduisent à

$$\begin{aligned} \theta &= \frac{M_2 - M_1^2}{M_1} \\ p &= \frac{M_1}{\theta} = \frac{M_1^2}{M_2 - M_1^2} \end{aligned}$$

On en déduit

$$\hat{\theta}_{MO} = \frac{\frac{1}{n} \sum_{i=1}^n x_i^2 - \left(\frac{1}{n} \sum_{i=1}^n x_i\right)^2}{\frac{1}{n} \sum_{i=1}^n x_i}$$

$$\hat{p}_{MO} = \frac{\left(\frac{1}{n} \sum_{i=1}^n x_i\right)^2}{\frac{1}{n} \sum_{i=1}^n x_i^2 - \left(\frac{1}{n} \sum_{i=1}^n x_i\right)^2}$$

( $\hat{\theta}_{MO}, \hat{p}_{MO}$ ) estimateur convergent de  $(\theta, p)$  mais étude du biais difficile

1)

Ex 2

1) En utilisant l'indépendance mutuelle des variables  $x_1, \dots, x_n, y_1, \dots, y_m$ , on obtient

$$(1pt) \quad L(x, y; \boldsymbol{\nu}) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma_1} \exp\left[-\frac{(x_i - \nu_1)^2}{2\sigma_1^2}\right] \times \prod_{j=1}^m \frac{1}{\sqrt{2\pi}\sigma_2} \exp\left[-\frac{(y_j - \nu_2)^2}{2\sigma_2^2}\right]$$

2) Le Théorème de Neyman-Pearson est défini par

$$\text{Rejet de } H_0 \text{ si } \frac{L(x, y; \boldsymbol{\nu}_1)}{L(x, y; \boldsymbol{\nu}_0)} > \lambda_\alpha$$

ce qui conduit à rejeter  $H_0$  si

$$-\frac{1}{2\sigma_1^2} \sum_{i=1}^n (x_i - \nu_1)^2 - \frac{1}{2\sigma_2^2} \sum_{j=1}^m (y_j - \nu_2)^2 + \frac{1}{2\sigma_1^2} \sum_{i=1}^n x_i^2 + \frac{1}{2\sigma_2^2} \sum_{j=1}^m y_j^2 > k_\alpha$$

Sont

$$-\frac{1}{2\sigma_1^2} \left( -2\nu_1 \sum_{i=1}^n x_i + n\nu_1^2 \right) - \frac{1}{2\sigma_2^2} \left( -2\nu_2 \sum_{j=1}^m y_j + m\nu_2^2 \right) > k_\alpha$$

c'est à dire

$$\nu_1 \left[ \frac{1}{\sigma_1^2} \sum_{i=1}^n x_i + \frac{1}{\sigma_2^2} \sum_{j=1}^m y_j \right] > k'_\alpha$$

Comme  $\nu_1 < 0$ , on en déduit

$$\boxed{\text{Rejet de } H_0 \text{ si } T_n = \frac{1}{\sigma_1^2} \sum_{i=1}^n x_i + \frac{1}{\sigma_2^2} \sum_{j=1}^m y_j < A_\alpha}$$

~~2pt~~

(2pt)

3) En utilisant les résultats classiques sur les vecteurs gaussiens, on ait

$$\text{que } \sum_{i=1}^n x_i \sim N(n\nu_1, n\sigma_1^2) \text{ et } \sum_{j=1}^m y_j \sim N(m\nu_2, m\sigma_2^2)$$

En utilisant l'indépendance de  $\sum_{i=1}^n x_i$  et  $\sum_{j=1}^m y_j$ , on a

$$\boxed{T_n \sim N\left(\left(\frac{n}{\sigma_1^2} + \frac{m}{\sigma_2^2}\right)\nu, \frac{n}{\sigma_1^2} + \frac{m}{\sigma_2^2}\right)}$$

$$\text{Donc sous } H_0 \quad T \sim N(0, \theta^2) \quad \text{avec} \quad \theta^2 = \frac{n}{\sigma_1^2} + \frac{m}{\sigma_2^2} = \frac{n\sigma_2^2 + m\sigma_1^2}{\sigma_1^2\sigma_2^2}$$

(2pt)

$$\text{sous } H_1 \quad T \sim N(\theta^2\nu, \theta^2)$$

$$4) \alpha = P[\text{Rejeter } H_0 \mid H_0 \text{ vraie}] = P[T_n < A_\alpha \mid T_n \sim N(0, \sigma^2)]$$

d'où

$$\alpha = P\left[\frac{T_n}{\sigma} < \frac{A_\alpha}{\sigma} \mid \frac{T_n}{\sigma} \sim N(0, 1)\right]$$

2)

c'est à dire

$$\alpha = F\left[\frac{A_\alpha}{\sigma}\right] = \boxed{F\left[\frac{A_\alpha \sigma_1 \sigma_2}{\sqrt{n\sigma_2^2 + m\sigma_1^2}}\right]}$$

De la même façon

$$\beta = P[\text{Rejeter } H_1 \mid H_1 \text{ vraie}] = P[T_n > A_\alpha \mid T_n \sim N(\mu_1, \sigma^2)]$$

Soit

$$\beta = P\left[\frac{T_n - \mu_1 \sigma^2}{\sigma} > \frac{A_\alpha - \mu_1 \sigma^2}{\sigma} \mid \frac{T_n - \mu_1 \sigma^2}{\sigma} \sim N(0, 1)\right]$$

$$\beta = 1 - F\left[\frac{A_\alpha - \mu_1 \sigma^2}{\sigma}\right]$$

Finalement

$$\boxed{\beta = 1 - F\left[\frac{\sigma_1 \sigma_2}{\sqrt{n\sigma_2^2 + m\sigma_1^2}} \left(A_\alpha - \mu_1 \frac{n\sigma_2^2 + m\sigma_1^2}{\sigma_1^2 \sigma_2^2}\right)\right]}$$

5) Les courbes COR sont définies par  $\Pi = 1 - \beta$  en fonction de  $\alpha$

D'après la question précédente

$$A_\alpha = F^{-1}(\alpha) \frac{\sqrt{n\sigma_2^2 + m\sigma_1^2}}{\sigma_1 \sigma_2}$$

et

$$\Pi = 1 - \beta = F\left[\frac{\sigma_1 \sigma_2}{\sqrt{n\sigma_2^2 + m\sigma_1^2}} \left(A_\alpha - \mu_1 \frac{n\sigma_2^2 + m\sigma_1^2}{\sigma_1^2 \sigma_2^2}\right)\right]$$

En remplaçant  $A_\alpha$  dans l'expression de  $\Pi$ , on obtient

$$\boxed{\Pi = F\left[F^{-1}(\alpha) - \mu_1 \frac{\sqrt{n\sigma_2^2 + m\sigma_1^2}}{\sigma_1 \sigma_2}\right]}$$

Performance du test en fonction de  $\mu_1$

Comme  $F(\alpha)$ , plus  $\mu_1$  diminue, plus  $-A_\alpha$  augmente et plus la puissance du test augmente, ce qui est naturel

## Analyse du tnr en fonction de n, m, $\sigma_1^2$ et $\sigma_2^2$

Comme le montre l'expression de la puissance du tnr, les performances sont liées à la valeur de  $SNR = \frac{n\sigma_2^2 + m\sigma_1^2}{\sigma_1\sigma_2}$  qu'on appelle parfois rapport signal sur bruit du tnr.

Plus SNR augmente, plus ( $\underbrace{-\mu_n}_{\geq 0}$ ) SNR augmente et donc plus le tnr est puissant.

2pts