

Corrigé de l'interrogation n°2

Exercice [8points]

On dispose d'un échantillon (X_1, X_2, \dots, X_N) de taille N d'une variable suivant une loi Normale de paramètres m et σ^2 avec $\sigma > 0$, de densité :

$$f(x ; m, \sigma^2) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{1}{2\sigma^2}(x-m)^2\right)$$

1- La fonction de vraisemblance associée à la loi Normale de paramètre m et σ^2 est donc :

$$\begin{aligned} L(x_1, x_2, \dots, x_N; m, \sigma^2) &= \prod_{i=1}^N f(x_i ; m, \sigma^2) = \prod_{i=1}^N \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{1}{2\sigma^2}(x_i - m)^2\right) \\ &= (2\pi\sigma^2)^{-\frac{N}{2}} \prod_{i=1}^N \exp\left(-\frac{(x_i - m)^2}{2\sigma^2}\right) = (2\pi\sigma^2)^{-\frac{N}{2}} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^N (x_i - m)^2\right) \end{aligned}$$

La log-vraisemblance d'un échantillon (x_1, x_2, \dots, x_n) est donc égale à :

$$\begin{aligned} \ln L(x_1, x_2, \dots, x_N; m, \sigma^2) &= \ln\left[(2\pi\sigma^2)^{-\frac{N}{2}}\right] + \ln\left[\exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^N (x_i - m)^2\right)\right] \\ &= -\frac{N}{2} \ln[2\pi\sigma^2] - \frac{1}{2\sigma^2} \sum_{i=1}^N (x_i - m)^2 \\ &= -\frac{N}{2} \ln[2\pi] - \frac{N}{2} \ln[\sigma^2] - \frac{1}{2\sigma^2} \sum_{i=1}^N (x_i - m)^2 \end{aligned}$$

2- En utilisant la condition du premier ordre portant sur m , déterminer l'estimateur du maximum de vraisemblance \hat{m} du paramètre m .

1.b. Afin de déterminer l'estimateur du maximum de vraisemblance \hat{m} du paramètre m , il faut maximiser la log-vraisemblance par rapport à la variable m à (x_1, x_2, \dots, x_N) donnés. La première étape consiste à résoudre l'équation correspondant à la condition du premier ordre :

$$\frac{\partial \ln L}{\partial m}(x_1, x_2, \dots, x_N; m, \sigma^2) = 0$$

$$\text{or } \frac{\partial \ln L}{\partial m}(x_1, x_2, \dots, x_N; m, \sigma^2) = -\frac{1}{2\sigma^2} \sum_{i=1}^N (-2)(x_i - m) = \frac{1}{\sigma^2} \sum_{i=1}^N (x_i - m) \text{ donc :}$$

$$\frac{\partial \ln L}{\partial m}(x_1, x_2, \dots, x_N; m, \sigma^2) = 0 \iff \frac{1}{\sigma^2} \sum_{i=1}^N (x_i - \hat{m}) = 0 \iff \sum_{i=1}^N (x_i - \hat{m}) = 0 \text{ d'où}$$

$$\frac{\partial \ln L}{\partial m}(x_1, x_2, \dots, x_N; m, \sigma^2) = 0 \iff \sum_{i=1}^N x_i - \sum_{i=1}^N \hat{m} = 0 \iff \sum_{i=1}^N x_i = N \hat{m} \iff$$

$$\hat{m} = \frac{1}{N} \sum_{i=1}^N x_i = \bar{x}$$

La fonction $m \rightarrow \ln L(x_1, x_2, \dots, x_N; m, \sigma^2)$ atteint donc un extrémum (c'est-à-dire un maximum ou un minimum) au point $\hat{m} = \frac{1}{N} \sum_{i=1}^N x_i$. Il s'agit bien d'un maximum car la fonction $m \rightarrow \ln L(x_1, x_2, \dots, x_N; m, \sigma^2)$ est concave. En effet, pour tout $(x_1, x_2, \dots, x_N; m, \sigma^2)$, on a :

$$\frac{\partial^2 \ln L}{\partial m^2}(x_1, x_2, \dots, x_N; m, \sigma^2) = -\frac{N}{\sigma^2} < 0$$

En particulier, la condition du second ordre $\frac{\partial^2 \ln L}{\partial m^2}(x_1, x_2, \dots, x_N; m, \sigma^2) < 0$ est satisfaite.

Conclusion: L'estimateur du maximum de vraisemblance du paramètre m est $\hat{m} = \frac{1}{n} \sum_{i=1}^n X_i$.

3- On pose $s = \sigma^2$.

$$\begin{aligned} \ln L(x_1, x_2, \dots, x_N; m, \sigma^2) &= -\frac{N}{2} \ln [2\pi] - \frac{N}{2} \ln [\sigma^2] - \frac{1}{2\sigma^2} \sum_{i=1}^N (x_i - m)^2 \\ &= -\frac{N}{2} \ln [2\pi] - \frac{N}{2} \ln [s] - \frac{1}{2s} \sum_{i=1}^N (x_i - m)^2 \end{aligned}$$

La condition du premier ordre sur s : $\frac{\partial \ln L}{\partial s}(x_1, x_2, \dots, x_N; m, \sigma^2) = 0$ or

$$\frac{\partial \ln L}{\partial s}(x_1, x_2, \dots, x_N; m, \sigma^2) = -\frac{N}{2} \frac{1}{s} + \frac{1}{s^2} \frac{1}{2} \sum_{i=1}^N (x_i - m)^2 = \frac{1}{2s} \left[-N + \frac{1}{s} \sum_{i=1}^N (x_i - m)^2 \right]$$

donc : $\frac{\partial \ln L}{\partial s}(x_1, x_2, \dots, x_N; m, \sigma^2) = 0$ et pour $m = \hat{m} = \bar{x} \iff -N + \frac{1}{s} \sum_{i=1}^N (x_i - \bar{x})^2 = 0 \iff \frac{1}{s} \sum_{i=1}^N (x_i - \bar{x})^2 = N$ d'où $\frac{\partial \ln L}{\partial m}(x_1, x_2, \dots, x_N; m, \sigma^2) = 0$

$$\iff \sum_{i=1}^N (x_i - \bar{x})^2 = N \hat{s} \iff \hat{s} = \frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N}$$

La fonction $s \rightarrow \ln L(x_1, x_2, \dots, x_N; m, \sigma^2)$ atteint donc un extrémum (c'est-à-dire un maximum ou un minimum) au point $\hat{s} = \frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N}$. Il s'agit bien d'un maximum car, pour tout $(x_1, x_2, \dots, x_N; m, \sigma^2)$, on a :

$$\frac{\partial^2 \ln L}{\partial s^2}(x_1, x_2, \dots, x_N; m, \sigma^2) = \frac{N}{2} \frac{1}{s^2} - \frac{2}{s^4} \frac{1}{2} \sum_{i=1}^N (x_i - m)^2 = \frac{N}{2} \frac{1}{s^2} - \frac{1}{s^3} \sum_{i=1}^N (x_i - \bar{x})^2$$

Pour $s = \hat{s} = \frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N}$, $\frac{\partial^2 \ln L}{\partial s^2}(x_1, x_2, \dots, x_N; m, \sigma^2) = \frac{N}{2} \frac{1}{\hat{s}^2} - \frac{1}{\hat{s}^3} N \hat{s} = -\frac{N}{2} \frac{1}{\hat{s}^2} < 0$

D'où, la condition du second ordre $\frac{\partial^2 \ln L}{\partial s^2}(x_1, x_2, \dots, x_N; m, \sigma^2) < 0$ est satisfaite.

Conclusion: L'estimateur du maximum de vraisemblance du paramètre s

$$\text{est } \hat{s} = \frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N}$$

$$4- E(\hat{m}) = \frac{1}{N} \sum_{i=1}^N E(X_i) = \frac{N m}{N} = m \text{ (l'estimateur } \hat{m} \text{ est sans biais).}$$

$V(\hat{m}) = V\left(\frac{1}{N} \sum_{i=1}^N X_i\right) = \frac{1}{N^2} V\left(\sum_{i=1}^N X_i\right)$ or $V\left(\sum_{i=1}^N X_i\right) = \sum_{i=1}^N V(X_i)$ car les X_i sont supposés indépendants, donc

$$V(\hat{m}) = \frac{1}{N^2} \sum_{i=1}^N V(X_i) = \frac{1}{N^2} N \sigma^2 = \frac{\sigma^2}{N}$$

L'expression de la quantité d'information de Fisher est :

$$I_n(m) = E\left(\left[\frac{\partial \ln L(X_1, \dots, X_N; m, \sigma^2)}{\partial m}\right]^2\right) = -E\left(\frac{\partial^2 \ln L(X_1, \dots, X_N; m, \sigma^2)}{\partial m^2}\right)$$

D'après ce qui précède, on a : $\frac{\partial^2 \ln L}{\partial m^2}(x_1, x_2, \dots, x_N; m, \sigma^2) = -\frac{N}{\sigma^2}$ donc $E\left(\frac{\partial^2 \ln L(X_1, \dots, X_N; m, \sigma^2)}{\partial m^2}\right) = -\frac{N}{\sigma^2}$ et $I_n(m) = \frac{N}{\sigma^2}$

L'estimateur \hat{m} est un estimateur sans biais et sa variance vérifie $V(\hat{m}) = \frac{1}{I_n(m)}$. Il s'agit donc d'un estimateur efficace.

5* (Bonus 2 points)** Etudier le biais de \hat{s} . Comment peut-on le modifier pour qu'il devienne sans biais ?

$$E(\hat{s}) = E\left[\frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N}\right] = \frac{1}{N} E\left[\sum_{i=1}^N (x_i - \bar{x})^2\right] = \frac{1}{N} \sum_{i=1}^N E[(x_i - \bar{x})^2] \text{ Or}$$

$$E[(x_i - \bar{x})^2] = V[(x_i - \bar{x})] + [E(x_i - \bar{x})]^2$$

$$E(x_i - \bar{x}) = E(x_i) - E(\bar{x}) = m - m = 0$$

$$V[(x_i - \bar{x})] = V(x_i) - 2Cov(x_i, \bar{x}) + V(\bar{x})$$

$$Cov(x_i, \bar{x}) = Cov\left(x_i, \frac{1}{N} \sum_{j=1}^N x_j\right) = \frac{1}{N} Cov(x_i, x_i) + \frac{1}{N} Cov\left(x_i, \sum_{j \neq i}^N x_j\right) =$$

$$\frac{1}{N} Cov(x_i, x_i) + 0 = \frac{1}{N} V(x_i) = \frac{\sigma^2}{N}$$

D'où, $V[(x_i - \bar{x})] = V(x_i) - 2Cov(x_i, \bar{x}) + V(\bar{x}) = \sigma^2 - 2\frac{\sigma^2}{N} + \frac{\sigma^2}{N} = \sigma^2 - \frac{\sigma^2}{N} = \frac{N-1}{N} \sigma^2$ et donc $E[(x_i - \bar{x})^2] = V[(x_i - \bar{x})] + [E(x_i - \bar{x})]^2 = V[(x_i - \bar{x})]$

$$E(\hat{s}) = \frac{1}{N} \sum_{i=1}^N E[(x_i - \bar{x})^2] \quad E(\hat{s}) = \frac{1}{N} \sum_{i=1}^N \frac{N-1}{N} \sigma^2 = \frac{N-1}{N} \sigma^2 \neq \sigma^2 \text{ donc}$$

l'estimateur des MVS \hat{s} est biaisé. L'estimateur sans biais de σ^2 (s) est

$$\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2 \text{ soit } \frac{N}{N-1} \hat{s}.$$

Problème [15points] :

1. Le modèle : $y_i = \beta_1 + \beta_2 x_i + \varepsilon_i \quad i = 1, \dots, N$ peut s'écrire sous la forme :

$$y = X\beta + \varepsilon \text{ avec } y = \begin{bmatrix} y_1 \\ \vdots \\ y_i \\ \vdots \\ y_N \end{bmatrix}, X = \begin{bmatrix} 1 & x_1 \\ \vdots & \vdots \\ 1 & x_i \\ \vdots & \vdots \\ 1 & x_N \end{bmatrix}, \text{ et } \beta = \begin{bmatrix} \beta_1 \\ \beta_2 \end{bmatrix} \varepsilon = \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_i \\ \vdots \\ \varepsilon_N \end{bmatrix}$$

2. L'estimation par la méthode des moindres carrés ordinaires se fait à partir de la minimisation de la somme des carrés des résidus $\sum_{i=1}^N \varepsilon_i^2 = \sum_{i=1}^N (y_i - \beta_1 - \beta_2 x_i)^2$. Les équations normales s'obtiennent à partir des conditions du premier ordre :

$$\frac{\partial \left(\sum_{i=1}^N (y_i - \beta_1 - \beta_2 x_i)^2 \right)}{\partial \beta_2} = 0$$

$$\frac{\partial \left(\sum_{i=1}^N (y_i - \beta_1 - \beta_2 x_i)^2 \right)}{\partial \beta_1} = 0$$

ces deux conditions étant vérifiées pour $\beta_2 = \widehat{\beta}_2$ et $\beta_1 = \widehat{\beta}_1$.

Or $\frac{\partial \left(\sum_{i=1}^N (y_i - \beta_1 - \beta_2 x_i)^2 \right)}{\partial \beta_2} = -2 \sum_{i=1}^N x_i (y_i - \beta_1 - \beta_2 x_i) = -2 \sum_{i=1}^N (x_i y_i - \beta_1 x_i - \beta_2 x_i^2) = -2 \left[\sum_{i=1}^N x_i y_i - \beta_2 \sum_{i=1}^N x_i^2 - \beta_1 \sum_{i=1}^N x_i \right]$ et $\frac{\partial \left(\sum_{i=1}^N (y_i - \beta_1 - \beta_2 x_i)^2 \right)}{\partial \beta_1} = -2 \sum_{i=1}^N (y_i - \beta_1 - \beta_2 x_i) = -2 \left[\sum_{i=1}^N y_i - \beta_1 N - \beta_2 \sum_{i=1}^N x_i \right]$ donc les estimateurs $\widehat{\beta}_1$ et $\widehat{\beta}_2$ vérifient les deux équations suivantes (dites équations normales) :

$$\sum_{i=1}^N x_i y_i - \widehat{\beta}_2 \sum_{i=1}^N x_i^2 - \widehat{\beta}_1 \sum_{i=1}^N x_i = 0 \quad (1)$$

$$\sum_{i=1}^N y_i - \widehat{\beta}_2 \sum_{i=1}^N x_i - \widehat{\beta}_1 N = 0 \quad (2)$$

3. En divisant par N les deux membres de l'équation (2) on obtient l'expression de $\widehat{\beta}_1$ en fonction de $\widehat{\beta}_2$:

$$\widehat{\beta}_1 = \bar{y} - \widehat{\beta}_2 \bar{x}$$

et en remplaçant $\widehat{\beta}_1$ dans l'équation (1) par son expression, on obtient :

$$\sum_{i=1}^N x_i y_i - \widehat{\beta}_2 \sum_{i=1}^N x_i^2 - (\bar{y} - \widehat{\beta}_2 \bar{x}) \sum_{i=1}^N x_i = 0$$

or $\sum_{i=1}^N x_i = N \bar{x}$ donc

$$\sum_{i=1}^N x_i y_i - \widehat{\beta}_2 \sum_{i=1}^N x_i^2 - N \bar{x} \bar{y} + \widehat{\beta}_2 N \bar{x}^2 = 0$$

d'où

$$\widehat{\beta}_2 \sum_{i=1}^N x_i^2 - \widehat{\beta}_2 N \bar{x}^2 = \sum_{i=1}^N x_i y_i - N \bar{x} \bar{y}$$

et par conséquent :

$$\widehat{\beta}_2 = \frac{\sum_{i=1}^N x_i y_i - N \bar{x} \bar{y}}{\sum_{i=1}^N x_i^2 - N \bar{x}^2} = \frac{S_{xy}}{S_{xx}}$$

$$4. \widehat{\beta} = (X'X)^{-1} X'y = (X'X)^{-1} [X'X\beta + \varepsilon] = (X'X)^{-1} X'X\beta + (X'X)^{-1} X'\varepsilon = \beta + (X'X)^{-1} X'\varepsilon$$

$$\widehat{\beta}_2 = \frac{\sum_{i=1}^N x_i y_i - N \bar{x} \bar{y}}{\sum_{i=1}^N x_i^2 - N \bar{x}^2} = \beta_2 + \frac{\sum_{i=1}^N x_i \varepsilon_i - N \bar{x} \bar{\varepsilon}}{S_{xx}}$$

$$\widehat{\beta}_1 = \bar{y} - \widehat{\beta}_2 \bar{x} = \bar{y} = \beta_1 + \beta_2 \bar{x} + \bar{\varepsilon} - \left[\beta_2 + \frac{1}{S_{xx}} \sum_{i=1}^N x_i \varepsilon_i - N \bar{x} \bar{\varepsilon} \right] \bar{x} = \beta_1 + \frac{\bar{\varepsilon} \sum_{i=1}^N x_i^2 - \bar{x} \sum_{i=1}^N x_i \varepsilon_i}{S_{xx}}$$

5. Les estimateurs des MCO $\widehat{\beta}_1$ et $\widehat{\beta}_2$ sont sans biais, linéaires par rapport aux variables dépendantes y_i et de variance minimale dans la classe des estimateurs linéaires sans biais. Cette dernière propriété porte sur l'efficacité *relative* des estimateurs des MCO par rapport aux autres estimateurs linéaires sans biais (Théorème de Gauss-Markov). En aucun cas, ceci n'implique que les estimateurs $\widehat{\beta}_1$ et $\widehat{\beta}_2$ sont efficaces au sens où leur variance atteint la borne FDRC.

$$E(\widehat{\beta}) = E\left(\beta + (X'X)^{-1} \varepsilon\right) = E(\beta) + E\left((X'X)^{-1} X'\varepsilon\right) = \beta + (X'X)^{-1} X'E(\varepsilon)$$

or $E(\varepsilon) = 0$

$$E\left(\widehat{\beta}\right) = \begin{bmatrix} E\left(\widehat{\beta}_1\right) \\ E\left(\widehat{\beta}_2\right) \end{bmatrix} = \beta = \begin{bmatrix} \beta_1 \\ \beta_2 \end{bmatrix}$$

6.1 L'estimateur $\widehat{\beta}_2$ est une combinaison linéaire d'une variable aléatoire normale donc $\widehat{\beta}_2$ suit une loi Normale.

$$E\left(\widehat{\beta}_2\right) = \beta_2 \text{ et } V\left(\widehat{\beta}_2\right) = \frac{\sigma^2}{S_{xx}} = \sigma_2^2 \text{ D'où } \widehat{\beta}_2 \sim N\left(\beta_2, \sigma_2^2\right) \text{ . de même pour}$$

l'estimateur $\widehat{\beta}_1 \sim N\left(\beta_1, \sigma_1^2\right)$ avec $\sigma_1^2 = \frac{\sigma^2}{N} \frac{\sum_{i=1}^N x_i^2}{S_{xx}}$

6.2 On a montré plus haut que $\widehat{\beta}_2 \sim N\left(\beta_2, \sigma_2^2\right)$, et donc $\frac{\widehat{\beta}_2 - \beta_2}{\sigma_2} \sim N(0, 1)$

Posons $U = \frac{\widehat{\beta}_2 - \beta_2}{\sigma_2}$, $P(-u \leq U \leq u) = 0.98 = 2F(u) - 1$ où F est la fonction de répartition de la loi $N(0, 1)$, d'où $F(u) = 0.99$. Sur la table statistique de $N(0, 1)$, $u = 2.33$

$$P(-2.33 \leq U \leq 2.33) = P\left(-2.33 \leq \frac{\widehat{\beta}_2 - \beta_2}{\sigma_2} \leq 2.33\right) = 0.98$$

donc :

$$P\left(\widehat{\beta}_2 - 2.33 \sigma_2 \leq \beta_2 \leq \widehat{\beta}_2 + 2.33 \sigma_2\right) = 0.98$$

On obtient alors l'intervalle de confiance pour β_2 au seuil de 98% suivant :
 $\widehat{\beta}_2 - 2.33 \sigma_2 \leq \beta_2 \leq \widehat{\beta}_2 + 2.33 \sigma_2$

De la même manière l'intervalle de confiance pour β_1 au seuil de 98% suivant :
 $\widehat{\beta}_1 - 2.33 \sigma_1 \leq \beta_1 \leq \widehat{\beta}_1 + 2.33 \sigma_1$

6.3 Sachant, $N = 5$, $\sum_{i=1}^5 y_i = 75$, $\sum_{i=1}^5 x_i = 55$, $\sum_{i=1}^5 x_i y_i = 880$, $\sum_{i=1}^5 x_i^2 = 633$ et $\sigma^2 = 0,25$

$$\bar{y} = \frac{1}{N} \sum_{i=1}^N y_i = 15$$

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i = 11$$

$$S_{xy} = \sum_{i=1}^N x_i y_i - N \bar{x} \bar{y} = 55$$

$$S_{xx} = \sum_{i=1}^N x_i^2 - N (\bar{x})^2 = 28$$

$$\text{D'où } \widehat{\beta}_2 = \frac{S_{xy}}{S_{xx}} = \frac{55}{28} = 1.96 \simeq 2 \text{ et } \widehat{\beta}_1 = \bar{y} - \widehat{\beta}_2 \bar{x} = 15 - 2 \times 11 = -7$$

$$\sigma_1^2 = \frac{\sigma^2}{N} \frac{\sum_{i=1}^N x_i^2}{S_{xx}} = (1.6)^2 \text{ et } \sigma_2^2 = \frac{\sigma^2}{S_{xx}} = (0.09)^2$$

Pour ces valeurs, on obtient l'intervalle de confiance pour β_2 au seuil de 98% suivant : [1.79 , 2.21].

Ainsi que l'intervalle de confiance pour β_1 au seuil de 98% suivant : [-9.47 , -4.53]

$$7.1 \ z_i = y_i - x_i = \beta_1 + \beta_2 x_i + \varepsilon_i - x_i = \beta_1 + (\beta_2 - 1)x_i + \varepsilon_i = a + b x_i + v_i$$

$$\text{d'où } a = \beta_1, \ b = \beta_2 - 1 \text{ et } v_i = \varepsilon_i.$$

7-2 On considère le modèle : $z_i = a + b x_i + v_i$

$$\begin{aligned} \widehat{a} &= \bar{z} - \widehat{b} \bar{x} \\ \widehat{\beta}_2 &= \frac{S_{xz}}{S_{xx}} \end{aligned}$$

$$7-3 \ S_{xz} = \sum_{i=1}^N x_i z_i - N \bar{x} \bar{z} = \sum_{i=1}^N x_i (y_i - x_i) - N \bar{x} (\bar{y} - \bar{x}) = \sum_{i=1}^N (x_i y_i - x_i^2) -$$

$$N \bar{x} \bar{y} - N \bar{x}^2$$

$$S_{xz} = \sum_{i=1}^N x_i y_i - N \bar{x} \bar{y} - \left(\sum_{i=1}^N x_i^2 - N \bar{x}^2 \right) = S_{xy} - S_{xx}$$

7-4

$$\begin{aligned} \widehat{a} &= \bar{z} - \widehat{b} \bar{x} = (\bar{y} - \bar{x}) - (\widehat{\beta}_2 - 1) \bar{x} = \bar{y} - \widehat{\beta}_2 \bar{x} = \widehat{\beta}_1 \\ \widehat{b} &= \frac{S_{xz}}{S_{xx}} = \frac{S_{xy} - S_{xx}}{S_{xx}} = \frac{S_{xy}}{S_{xx}} - 1 = \widehat{\beta}_2 - 1 \end{aligned}$$