

Eléments de réponses – Examen de la session d'automne 2010/2011

Les résultats doivent tous être démontrés, les réponses doivent toutes être rédigées.

Exercice 1.

Soit X la variable aléatoire représentant le poids après remplissage d'un contenant pris au hasard. On suppose que X suit une loi normale $\mathcal{N}(m, \sigma^2)$. Soit (X_1, \dots, X_n) un échantillon i.i.d. de variable parente X .

1. Dans le cas de la loi normale, l'estimateur de $\theta = (m, \sigma^2)$ de la méthode des moments coïncide avec l'estimateur de la méthode du maximum de vraisemblance et vaut $\hat{\theta} = (\hat{m}, \hat{\sigma}^2)$

$$\text{avec } \hat{m} = \frac{1}{n} \sum_{i=1}^n X_i \text{ et } \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2.$$

\hat{m} est sans biais pour m , $\hat{\sigma}^2$ est biaisé pour σ^2 mais asymptotiquement non biaisé (ce que l'on obtient en calculant l'espérance de l'estimateur).

De plus, $\hat{\theta}$ est fortement consistant pour θ (appliquer la loi forte des grands nombres et le théorème de la transformation continue).

Enfin, $\hat{\theta}$ est l'EMV de θ calculé à partir d'observations i.i.d. dans un modèle régulier (puisque la loi normale appartient à la famille exponentielle en dimension 2) et est fortement consistant donc le TCL pour l'EMV s'applique, ce qui permet d'affirmer que $\hat{\theta}$ est asymptotiquement efficace.

Ici, les observations fournissent les estimations $\hat{m} = 360g$ et $\hat{\sigma}^2 = 100g^2$.

2. On veut estimer

$$p_1 = \mathbb{P}[340 < X < 360] = \mathbb{P}\left[\frac{340 - m}{\sqrt{\sigma^2}} < \frac{X - m}{\sqrt{\sigma^2}} < \frac{360 - m}{\sqrt{\sigma^2}}\right] = \phi\left(\frac{360 - m}{\sqrt{\sigma^2}}\right) - \phi\left(\frac{340 - m}{\sqrt{\sigma^2}}\right)$$

car ϕ est continue. On propose l'estimateur

$$\hat{p}_1 = \phi\left(\frac{360 - \hat{m}}{\sqrt{\hat{\sigma}^2}}\right) - \phi\left(\frac{340 - \hat{m}}{\sqrt{\hat{\sigma}^2}}\right)$$

ce qui donne l'estimation $\hat{p}_1 = \phi(0) - \phi(-2) = \phi(2) - 0.5$

3. On veut estimer

$$N = 1000\mathbb{P}[X < 330] = 1000\mathbb{P}\left[\frac{X - m}{\sqrt{\sigma^2}} < \frac{330 - m}{\sqrt{\sigma^2}}\right] = 1000\phi\left(\frac{330 - m}{\sqrt{\sigma^2}}\right).$$

On propose l'estimateur

$$\hat{N} = 1000\phi\left(\frac{330 - \hat{m}}{\sqrt{\hat{\sigma}^2}}\right)$$

ce qui donne l'estimation $\hat{N} = 1000(1 - \phi(3))$.

4. On veut estimer

$$\begin{aligned} p_2 &= \mathbb{P}[\max(X_1, \dots, X_n) < 360] = \mathbb{P}[X_1 < 360, \dots, X_n < 360] = \mathbb{P}[X < 360]^{100} \text{ par indépendance} \\ &= \mathbb{P}\left[\frac{X - m}{\sqrt{\sigma^2}} < \frac{360 - m}{\sqrt{\sigma^2}}\right]^{100} = \phi\left(\frac{360 - m}{\sqrt{\sigma^2}}\right)^{100}. \end{aligned}$$

On propose l'estimateur

$$\hat{p}_2 = \phi\left(\frac{360 - \hat{m}}{\sqrt{\hat{\sigma}^2}}\right)^{100}$$

ce qui donne l'estimation $\hat{p}_2 = \phi(0)^{100} = 0.5^{100}$.

5. On veut estimer

$$\begin{aligned} p_3 &= \mathbb{P}[\min(X_1, \dots, X_n) > 330] = \mathbb{P}[X_1 > 330, \dots, X_n > 330] = \mathbb{P}[X > 330]^{100} \text{ par indépendance} \\ &= \mathbb{P}\left[\frac{X - m}{\sqrt{\sigma^2}} > \frac{330 - m}{\sqrt{\sigma^2}}\right]^{100} = \left(1 - \phi\left(\frac{330 - m}{\sqrt{\sigma^2}}\right)\right)^{100}. \end{aligned}$$

On propose l'estimateur

$$\hat{p}_3 = \left(1 - \phi\left(\frac{330 - \hat{m}}{\sqrt{\hat{\sigma}^2}}\right)\right)^{100}$$

ce qui donne l'estimation $\hat{p}_3 = \phi(3)^{100}$.

Exercice 2.

1. f_μ est une densité de probabilité ssi $f_\mu(x) \geq 0$ pour tout $x \in \mathbb{R}$ et $\int f_\mu(x)dx = 1$ puisque le modèle est dominé par la mesure de Lebesgue.
2. $\mathbb{E}_\mu[X] = \mu$, $\text{Var}_\mu(X) = 2$ et $q_{1/2}(X) = \mu$.
3. Utilisons la première définition de l'information de Fisher valable sous les hypothèses (H_1) et (H_2) à rappeler et à vérifier. On obtient $I(\mu) = 1$.
4. Le modèle n'appartient pas à la famille exponentielle car on ne peut pas l'écrire sous la forme

$$f_\mu(x) = \exp(Q(\mu)\psi(x) - \tilde{B}(\mu))h(x)$$

5. L'estimateur de la méthode des moments de μ est $\tilde{\mu}_n = \bar{X}_n$. Montrer que $\tilde{\mu}_n$ est sans biais pour μ , fortement consistant et que $\sqrt{n}(\tilde{\mu}_n - \mu) \xrightarrow{\mathcal{D}} \mathcal{N}(0, 2)$.
6. L'estimateur de la méthode du maximum de vraisemblance de μ est $\hat{\mu}_n = \text{med}(X_1, \dots, X_n)$ = médiane empirique.

Exercice 3.

Soit X la variable aléatoire représentant la durée de vie des non-fumeurs ($X(\Omega) = \mathbb{R}^{*+}$) et Y la variable aléatoire représentant la durée de vie des fumeurs ($Y(\Omega) = \mathbb{R}^{*+}$).

Soit (X_1, \dots, X_{n_1}) un échantillon i.i.d. distribué comme X et soit (Y_1, \dots, Y_{n_2}) un échantillon i.i.d. distribué comme Y , indépendant de (X_1, \dots, X_{n_1}) .

1. On propose d'estimer $\theta := \frac{\mathbb{E}[X]}{\mathbb{E}[Y]}$ par $\hat{\theta} = \frac{\bar{X}_{n_1}}{\bar{Y}_{n_2}}$ avec $\bar{X}_{n_1} = \frac{1}{n_1} \sum_{i=1}^{n_1} X_i$ et $\bar{Y}_{n_2} = \frac{1}{n_2} \sum_{i=1}^{n_2} Y_i$.

En effet, la LFGN permet d'affirmer que \bar{X}_{n_1} et \bar{Y}_{n_2} sont fortement consistants respectivement pour $\mathbb{E}[X]$ et $\mathbb{E}[Y]$. Comme la fonction $g : (x, y) \rightarrow \frac{x}{y}$ est continue sur $\mathbb{R}^{*+} \times \mathbb{R}^{*+}$,

on en déduit que $\hat{\theta}$ est fortement consistant pour θ .

2. Le TCL pour v.a.i.i.d. admettant des moments d'ordre 1 et 2 permet d'affirmer d'une part que :

$$\sqrt{n}(\bar{X}_n - \mathbb{E}[X]) \xrightarrow{\mathcal{D}} U \sim \mathcal{N}(0, \text{Var}(X))$$

et d'autre part que

$$\sqrt{n}(\bar{Y}_n - \mathbb{E}[Y]) \xrightarrow{\mathcal{D}} V \sim \mathcal{N}(0, \text{Var}(Y))$$

Comme les X_i sont indépendants des Y_i , on en déduit que les deux convergences précédentes ont lieu de façon jointe de sorte que l'on peut écrire :

$$\sqrt{n} \begin{pmatrix} \bar{X}_n - \mathbb{E}[X] \\ \bar{Y}_n - \mathbb{E}[Y] \end{pmatrix} \xrightarrow{\mathcal{D}} \begin{pmatrix} U \\ V \end{pmatrix} \sim \mathcal{N}_2 \left(\begin{pmatrix} 0 \\ 0 \end{pmatrix}, \begin{pmatrix} \text{Var}(X) & 0 \\ 0 & \text{Var}(Y) \end{pmatrix} \right)$$

Appliquons la delta-méthode bivariée avec $\psi : (u, v) \rightarrow \frac{u}{v}$ qui est de classe c^1 sur $\mathbb{R}^{*+} \times \mathbb{R}^{*+}$. Déterminons la matrice de l'application linéaire tangente à $\psi : D\psi(u, v) = \left(\frac{1}{v}, -\frac{u}{v^2} \right)$.

On obtient alors

$$\sqrt{n}(\psi(\bar{X}_n, \bar{Y}_n) - \psi(\mathbb{E}[X], \mathbb{E}[Y])) \xrightarrow{\mathcal{D}} D\psi(\mathbb{E}[X], \mathbb{E}[Y]) \cdot \begin{pmatrix} U \\ V \end{pmatrix} = \frac{U}{\mathbb{E}[Y]} - \frac{\mathbb{E}[X]V}{\mathbb{E}[Y]^2}$$

Déterminons la loi de W : c'est l'image par une application linéaire d'un vecteur gaussien donc W suit la loi normale en dimension 1. Il reste à déterminer la moyenne et la variance de la loi de W . On conclut

$$\sqrt{n}(\hat{\theta} - \theta) \xrightarrow{\mathcal{D}} \mathcal{N}(0, \sigma_W^2)$$

avec $\sigma_W^2 = \frac{\text{Var}(X)}{\mathbb{E}[Y]^2} + \frac{\mathbb{E}[X]^2}{\mathbb{E}[Y]^4} \text{Var}(Y)$ par indépendance des deux composantes U et V du vecteur gaussien limite.

3. Estimons σ_W^2 par

$$\widehat{\sigma}_W^2 = \frac{\widehat{\sigma}_{n,X}^2}{(\bar{Y}_n)^2} + \frac{(\bar{X}_n)^2}{(\bar{Y}_n)^4} \widehat{\sigma}_{n,X}^2$$

avec

$$\widehat{\sigma}_{n,X}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2, \quad \widehat{\sigma}_{n,Y}^2 = \frac{1}{n} \sum_{i=1}^n (Y_i - \bar{Y}_n)^2.$$

D'après la LFGN, $\widehat{\sigma}_{n,X}^2 \rightarrow \sigma_{n,X}^2$ presque-sûrement. On déduit de ce qui précède et du théorème de Slutsky que

$$\sqrt{n} \frac{(\hat{\theta} - \theta)}{\sqrt{\widehat{\sigma}_{n,X}^2}} \xrightarrow{\mathcal{D}} \mathcal{N}(0, 1)$$

On peut alors construire l'intervalle de confiance suivant pour θ au niveau de confiance $1 - \alpha$ (donner le détail de la construction) en notant ϕ la fonction de répartition de la loi

normale centrée réduite :

$$\mathbb{P} \left[\hat{\theta} - \phi(1 - \alpha/2)^{-1} \sqrt{\frac{\widehat{\sigma_W^2}}{n}} \leq \theta \leq \hat{\theta} + \phi(1 - \alpha/2)^{-1} \sqrt{\frac{\widehat{\sigma_W^2}}{n}} \right] = 1 - \alpha.$$

Exercice 4.

1. $\mathbb{E}[Y|X] = a \log(X) + b$, $\text{Var}(Y|X) = \sigma^2$, la covariable X influe sur la moyenne de Y de façon logarithmique avec une erreur aléatoire centrée.
2. La détermination de (\hat{a}, \hat{b}) estimateur des moindres carrés de (a, b) peut se faire ou bien

en annulant le vecteur gradient de $Q(a, b) = \sum_{i=1}^n (Y_i - a \log(X_i) - b)^2$ et en vérifiant que la matrice hessienne en la solution obtenue est définie positive ou bien en appliquant le théorème de projection orthogonale sur un sous-espace vectoriel de \mathbb{R}^n .

Rappel du théorème de projection sur un sous espace vectoriel fermé d'un espace de Hilbert :

Soit F un sous espace vectoriel fermé d'un espace de Hilbert muni d'un produit scalaire $\langle \cdot, \cdot \rangle$ et d'une norme $\|\cdot\|$. Alors, pour tout \mathbb{Y} de H , il existe un unique point noté $p_F(\mathbb{Y})$ tel que $\|\mathbb{Y} - p_F(\mathbb{Y})\| = \inf_{\mathbb{U} \in F} \|\mathbb{Y} - \mathbb{U}\|$ et qui se caractérise par deux conditions à savoir

$$\begin{cases} p_F(\mathbb{Y}) \in F, \\ \mathbb{Y} - p_F(\mathbb{Y}) \in F^\perp. \end{cases}$$

Appliquons ce théorème avec $H = \mathbb{R}^n$ muni de $\langle x, y \rangle = \sum_{i=1}^n x_i y_i$ et de $\|x\|^2 = \sum_{i=1}^n x_i^2$ et

avec $F = \text{Vect} \left(\begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix}, \begin{pmatrix} \log(X_1) \\ \vdots \\ \log(X_n) \end{pmatrix} \right)$ de sorte que déterminer $\text{argmin}_{a,b} Q(a, b)$ revient à

déterminer $\text{argmin}_{\mathbb{U} \in F} \|\mathbb{Y} - \mathbb{U}\|$ avec $\mathbb{Y} = \begin{pmatrix} Y_1 \\ \vdots \\ Y_n \end{pmatrix}$ et $\mathbb{U} = a \begin{pmatrix} \log(X_1) \\ \vdots \\ \log(X_n) \end{pmatrix} + b \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix}$. Ainsi

(\hat{a}, \hat{b}) est tel que $p_F(\mathbb{Y}) = \hat{a} \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix} + \hat{b} \begin{pmatrix} \log(X_1) \\ \vdots \\ \log(X_n) \end{pmatrix}$. Il reste donc à déterminer $p_F(\mathbb{Y})$.

Au bout des calculs, on obtient

$$\hat{a} = \frac{\overline{(Y \log(X))}_n - \overline{Y}_n \overline{\log(X)}_n}{\overline{(\log(X)^2)}_n - (\overline{\log(X)}_n)^2}, \quad \hat{b} = \frac{\overline{Y}_n \overline{(\log(X)^2)}_n - \overline{\log(X)}_n \overline{(Y \log(X))}_n}{\overline{(\log(X)^2)}_n - (\overline{\log(X)}_n)^2}$$

en notant

$$\overline{Y}_n = \frac{1}{n} \sum_{i=1}^n Y_i, \quad \overline{\log(X)}_n = \frac{1}{n} \sum_{i=1}^n \log(X_i)$$

$$\overline{(Y \log(X))}_n = \frac{1}{n} \sum_{i=1}^n Y_i \log(X_i), \quad \overline{(\log(X)^2)}_n = \frac{1}{n} \sum_{i=1}^n \log(X_i)^2.$$

Exercice 5.

1. $\begin{pmatrix} 6 & -3 & -2 \\ -3 & 3 & 2 \\ -2 & -2 & 3 \end{pmatrix}$ n'est pas une matrice de variance car elle n'est pas symétrique.
- $\begin{pmatrix} 4 & 1 & 2 \\ 1 & 9 & -1 \\ 2 & -1 & -3 \end{pmatrix}$ n'est pas une matrice de variance car l'un des coefficients diagonaux est négatifs.

$M = \begin{pmatrix} 6 & -3 & 0 \\ -3 & 3 & 2 \\ 0 & 2 & 3 \end{pmatrix}$ est une matrice symétrique, tous ces coefficients diagonaux sont strictement positifs, il reste à montrer qu'elle est définie positive ie que son spectre est inclus dans \mathbb{R}^{*+} . Or $\det(M - xI_3) = -x^3 + 8x^2 - 4x - 9$. En étudiant les variations de cette fonction et en utilisant le fait que $\det(M) = 15$, on obtient le résultat.

2. $\mathbb{E}[X - Z|Y - X] = \frac{11}{15}(X - Y) + \frac{19}{15}$ donc $\mathcal{L}(\mathbb{E}[X - Z|Y - X]) = \mathcal{N}(2, 121/15)$.