

Exercices

Econométrie 2

Exercice 1.

(*) Soit y_1, \dots, y_n des réels. Déterminer le réel \hat{m} qui minimise $SCR(m) = \sum_{i=1}^n |y_i - m|^2$. Que représente \hat{m} par rapport à y_1, \dots, y_n ?

Proof. On a $SCR'(m) = 2 \sum_{i=1}^n (m - y_i)$ et $SCR''(m) = 2 \cdot n$. Donc $SCR'(\hat{m}) = 0 \iff \hat{m} = \frac{1}{n} \sum_{i=1}^n y_i$ et $SCR''(m) > 0$ pour tout $m \in \mathbb{R}$: \hat{m} est un minimum local d'une fonction convexe, c'est donc aussi un minimum global. De plus \hat{m} est la moyenne empirique des (y_i) . \square

Exercice 2.

(**) Soit y_1, \dots, y_n des réels. Déterminer le réel \tilde{m} qui minimise la somme des valeurs absolues $SVA(m) = \sum_{i=1}^n |y_i - m|$ (on pourra traiter d'abord le cas où $n = 2p + 1$ et classer les réels (y_i) sous la forme $y_{(1)} \leq y_{(2)} \leq \dots \leq y_{(n-1)} \leq y_{(n)}$, puis passer au cas où $n = 2p$). Que représente \tilde{m} par rapport à y_1, \dots, y_n ?

Proof. 1. pour $n = 2p + 1$, on montre que $\tilde{m} = y_{(p+1)}$. En effet, dans un tel cas

$$SVA(y_{(p+1)}) = \sum_{i=1}^p (y_{(p+1)} - y_{(i)}) + \sum_{i=p+2}^{2p+1} (y_{(i)} - y_{(p+1)}) = \sum_{i=p+2}^{2p+1} y_{(i)} - \sum_{i=1}^p y_{(i)}.$$

Pour $m \in]y_{(j)}, y_{(j+1)}[$ et $j = p + 1, \dots, 2p + 1$ (avec, par convention, $y_{(2p+2)} = +\infty$ et les sommes vides nulles),

$$\begin{aligned} SVA(m) &= \sum_{i=1}^j (m - y_{(i)}) + \sum_{i=j+1}^{2p+1} (y_{(i)} - m) \\ &= \sum_{i=1}^p (m - y_{(i)}) + \sum_{i=p+2}^{2p+1} (y_{(i)} - m) + \sum_{i=p+1}^j (y_{(i)} - m) - \sum_{i=p+2}^j (y_{(i)} - m) \\ &= \sum_{i=p+2}^{2p+1} y_{(i)} - \sum_{i=1}^p y_{(i)} + 2 \sum_{i=p+2}^j (m - y_{(i)}) + (m - y_{(p+1)}) \\ &> SVA(y_{(p+1)}). \end{aligned}$$

Par symétrie, il en est de même si $m \in [y_{(j)}, y_{(j+1)}[$ et $j = 0, \dots, p$. On en déduit que le minimum de $SVA(\cdot)$ est atteint en $\tilde{m} = y_{(p+1)}$, qui est la médiane des (y_j) .

2. Si $n = 2p$, on déduit de ce qui précède que le minimum de SVA doit se trouver entre $y_{(p)}$ et $y_{(p+1)}$. En effet, pour $m \in]y_{(p)}, y_{(p+1)}[$,

$$\begin{aligned} SVA(m) &= \sum_{i=1}^p (m - y_{(i)}) + \sum_{i=p+1}^{2p} (y_{(i)} - m) \\ &= \sum_{i=p+1}^{2p} y_{(i)} - \sum_{i=1}^p y_{(i)}, \end{aligned}$$

qui est indépendant de m . Maintenant, pour $m \in [y_{(j)}, y_{(j+1)}[$ et $j = p + 1, \dots, 2p + 1$, on a :

$$\begin{aligned} SVA(m) &= \sum_{i=1}^j (m - y_{(i)}) + \sum_{i=j+1}^{2p+1} (y_{(i)} - m) \\ &= \sum_{i=1}^p (m - y_{(i)}) + \sum_{i=p+1}^{2p} (y_{(i)} - m) + 2 \sum_{i=p+1}^j (m - y_{(i)}) \\ &> \sum_{i=p+1}^{2p} y_{(i)} - \sum_{i=1}^p y_{(i)}. \end{aligned}$$

On retrouve bien que le minimum est atteint entre $y_{(p)}$ et $y_{(p+1)}$, donc en la médiane des (y_i) . □

Exercice 3.

(*) Soit $(x_1, y_1), \dots, (x_n, y_n)$ des couples de réels. Déterminer le réel \hat{a} qui minimise la somme des carrés résiduelle $SCR(a) = \sum_{i=1}^n |y_i - a x_i|^2$. Que représente \hat{a} par rapport à y_1, \dots, y_n ? Comparer avec la valeur $\hat{\beta}$ obtenue dans le cadre de la régression linéaire simple classique.

Proof. On a $SCR'(a) = 2 \sum_{i=1}^n x_i(a \cdot x_i - y_i)$ et $SCR''(a) = 2 \sum_{i=1}^n x_i^2$. Donc $SCR'(\hat{a}) = 0 \iff \hat{a} = \frac{\sum_{i=1}^n x_i y_i}{\sum_{i=1}^n x_i^2}$ et $SCR''(a) > 0$ pour tout $a \in \mathbb{R}$: \hat{a} est un minimum local d'une fonction convexe, c'est donc aussi un minimum global. On remarque que si la série a été recentrée (à savoir que l'on a retranché la moyenne des x_i à chacun des x_i , et la moyenne des y_i à chacun des y_i), alors $\hat{a} = \hat{\beta}$, pente de la régression simple. □

Exercice 4.

(*) Soit $Y = (Y_i)_{1 \leq i \leq n}$ qui suit un modèle linéaire $Y = Z \theta^* + \varepsilon$, avec les ε_i des v.a. centrées de variance constante. Soit $T \in \mathbb{R}^n$ un vecteur déterministe. Montrer que

$$\mathbb{E} [\|T - Y\|^2] = n \sigma^2 + \|T - Z \theta^*\|^2.$$

Proof. On a :

$$\begin{aligned} \mathbb{E} [\|Y - T\|^2] &= \mathbb{E} [\|(Y - Z \theta) + (Z \theta^* - T)\|^2] \\ &= \mathbb{E} [\|Y - Z \theta^*\|^2 + \|T - Z \theta^*\|^2 + 2^t (Z \theta^* - T)(Y - Z \theta^*)] \\ &= \mathbb{E} [\|\varepsilon\|^2] + \|T - Z \theta^*\|^2 + 2^t (Z \theta^* - T) \mathbb{E} [\varepsilon] \\ &= \sum_{i=1}^n \mathbb{E} [\varepsilon_i^2] + \|T - Z \theta^*\|^2 \\ &= n \sigma^2 + \|T - Z \theta^*\|^2 \end{aligned}$$

□

Exercice 5.

(*) Soit $Y = (Y_i)_{1 \leq i \leq n}$ qui suit un modèle linéaire de régression multiple avec les ε_i des v.a. et la condition **(A0)**. On note $(\hat{\varepsilon}_i)_{1 \leq i \leq n}$ les résidus. Montrer que $\frac{1}{n} \sum_{i=1}^n \hat{\varepsilon}_i = 0$.

Proof. Sous l'hypothèse **(A0)** on a $\hat{\varepsilon} = P_{[Z]^\perp} \varepsilon$. On note $\mathbb{1} = {}^t(1, \dots, 1)$. On sait que $\mathbb{1} \in [Z]$ donc $\mathbb{1} \perp [Z]^\perp$. Or $\frac{1}{n} \sum_{i=1}^n \hat{\varepsilon}_i = \frac{1}{n} \langle \mathbb{1}, \hat{\varepsilon} \rangle$. Mais comme $\mathbb{1} \perp [Z]^\perp$ alors $\langle \mathbb{1}, P_{[Z]^\perp} \varepsilon \rangle = 0$ donc $\frac{1}{n} \sum_{i=1}^n \hat{\varepsilon}_i = 0$. \square

Exercice 6.

()** [Maximum de vraisemblance] On se place dans le cadre général du modèle linéaire vectoriel de taille $n \geq p + 1$,

$$Y = X \theta + \varepsilon, \quad \varepsilon \sim \mathcal{N}_n(0, \sigma^2 I_n), \tag{1}$$

où X est une matrice $(n, p + 1)$ de rang plein et $\theta \in \mathbb{R}^{p+1}$.

- i. Déterminer les estimateurs de θ et σ^2 par maximum de vraisemblance.
- ii. Déterminer la statistique du test du rapport de vraisemblance pour le problème de test $H_0: {}^t C \theta = 0$ contre $H_1: {}^t C \theta \neq 0$, où C est un vecteur de \mathbb{R}^n . Retrouve-t-on la statistique de Student?

Proof. i. En notant $f_{\theta, \sigma^2}(Y)$ la densité de $Y = (Y_1, \dots, Y_n)'$, comme $\mathbb{E}(Y) = X \theta$ et $\text{Var}(Y) = \sigma^2 I_n$ et comme le bruit est supposé gaussien, alors $f_{\theta, \sigma^2}(Y) = \frac{1}{(2\pi \sigma^2)^{n/2}} \exp \left\{ -\frac{1}{2\sigma^2} (Y - X \theta)' (Y - X \theta) \right\}$. Par suite, avec pour $Y \in \mathbb{R}^n$, $L(\theta, \sigma^2) = -2 \times \log(f_{\theta, \sigma^2}(Y))$, on a :

$$L(\theta, \sigma^2) = n \log(2\pi) + n \log(\sigma^2) + \frac{1}{\sigma^2} (Y - X \theta)' (Y - X \theta).$$

Pour déterminer un estimateur du maximum de vraisemblance des $p + 2$ paramètres, on peut chercher un minimum local de $L(\theta, \sigma^2)$, c'est-à-dire un point critique de cette fonction. On obtient ainsi, en différentiant par rapport à θ et à σ^2 :

$$\begin{cases} \frac{\partial L}{\partial \theta}(\theta, \sigma^2) = -\frac{1}{\sigma^2} (X' (Y - X \theta) + (Y - X \theta)' X) = -\frac{2}{\sigma^2} X' (Y - X \theta) \\ \frac{\partial L}{\partial \sigma^2}(\theta, \sigma^2) = \frac{n}{\sigma^2} - \frac{1}{\sigma^4} (Y - X \theta)' (Y - X \theta) \end{cases}$$

(noter que la différentiation par rapport à θ se fait matriciellement) et ainsi, en résolvant $\frac{\partial L}{\partial \theta}(\theta, \sigma^2) = 0$ et $\frac{\partial L}{\partial \sigma^2}(\theta, \sigma^2) = 0$, on obtient :

$$\begin{pmatrix} \hat{\theta} \\ \hat{\sigma}^2 \end{pmatrix} = \begin{pmatrix} \hat{\theta} \\ \frac{1}{n} \|Y - X \hat{\theta}\|^2 \end{pmatrix}$$

(on vérifie également que la matrice hessienne de l'application $L(\theta, \sigma^2)$ est définie positive et donc que l'on a bien un minimum). Seul l'estimateur de la variance est différent de celui obtenu par la méthode des moindres carrés.

- ii. Soit le problème de test $\begin{cases} H_0 : {}^t C \theta = 0 \\ H_1 : {}^t C \theta \neq 0 \end{cases}$. Notons Θ_0 le s.e.v. de \mathbb{R}^{p+1} tel que $\Theta_0 = \{\theta \in \mathbb{R}^{p+1}, {}^t C \theta\} = \{C\}^\perp$ et $\Theta_1 = \mathbb{R}^{p+1} \setminus \Theta_0$. Pour simplifier le problème, on supposera que C est un vecteur tel que ${}^t C C = \|C\|^2 = 1$.

La statistique du rapport de vraisemblance pour ce problème de test s'écrit: $\widehat{LR} = \frac{\sup_{\theta \in \Theta_0, \sigma^2 > 0} L(\theta, \sigma^2)}{\sup_{\theta \in \Theta_1, \sigma^2 > 0} L(\theta, \sigma^2)}$.

Notons $\{C\}^\perp = [(C_1, \dots, C_p)]$, sev engendré par les p vecteurs C_i , que l'on peut choisir comme une base orthonormale. On peut écrire que $\theta = ({}^t C \theta) C + \sum_{k=1}^p {}^t C_k ({}^t C_k \theta)$. Donc sous H_0 , comme $({}^t C \theta) = 0$, $X \theta = X (\sum_{k=1}^p C_k {}^t C_k \theta)$. Notons $X^{(0)}$ la matrice de taille (n, p) et de rang p engendrée par $X (\sum_{k=1}^p C_k {}^t C_k)$. On en déduit que sous H_0 le modèle s'écrit:

$$Y = X^{(0)} \theta^{(0)} + \varepsilon, \quad \text{où } [X^{(0)}] \text{ est un sev de } [X] \text{ de dimension } p \text{ et } \theta^{(0)} \in \mathbb{R}^p.$$

En conséquence, pour $\sup_{\theta \in \Theta_0, \sigma^2 > 0} L(\theta, \sigma^2) = L(\hat{\theta}^{(0)}, \hat{\sigma}^{(0)2})$, avec $\hat{\theta}^{(0)} = ({}^t X^{(0)} X^{(0)})^{-1} {}^t X^{(0)} Y$ et $\hat{\sigma}^{(0)2} = \frac{1}{n} \|X^{(0)} \hat{\theta}^{(0)}\|^2$. Ceci entraîne que

$$\sup_{\theta \in \Theta_0, \sigma^2 > 0} L(\theta, \sigma^2) = \frac{1}{(2\pi)^{n/2}} \frac{1}{(\hat{\sigma}^{(0)2})^{n/2}} e^{-n/2}.$$

On a également $\sup_{\theta \in \Theta_0, \sigma^2 > 0} L(\theta, \sigma^2) = \frac{1}{(2\pi)^{n/2}} \frac{1}{(\hat{\sigma}^2)^{n/2}} e^{-n/2}$, car prendre le sup sur $(\Theta_1, \sigma^2 > 0)$ c'est prendre le sup sur $\mathbb{R}^{p+1} \times]0, \infty[$ du fait que Θ_0 est de mesure nulle dans \mathbb{R}^{p+1} . Par conséquent :

$$\widehat{LR} = \left(\frac{\hat{\sigma}^{(0)2}}{\hat{\sigma}^2} \right)^{-n/2}.$$

Telle quelle, on ne retrouve pas du tout la statistique de Student. Mais sous H_0 ,

$$\frac{\hat{\sigma}^{(0)2}}{\hat{\sigma}^2} - 1 = \frac{\hat{\sigma}^{(0)2} - \hat{\sigma}^2}{\hat{\sigma}^2} = \frac{1}{n} \frac{\|P_{[X^{(0)]^\perp} \varepsilon]\|^2 - \|P_{[X]^\perp} \varepsilon\|^2}{\hat{\sigma}^2} = \frac{1}{n} \frac{\|P_{[X^{(0)]^\perp \cap [X]} \varepsilon]\|^2}{\hat{\sigma}^2}$$

en utilisant Pythagore. Or $[X^{(0)}]^\perp \cap [X]$ est un sev de dimension 1 dans \mathbb{R}^n . On peut montrer que $\frac{({}^t C \varepsilon)^2}{(C {}^t X X {}^t C)^{-1}} = \|P_{[X^{(0)]^\perp \cap [X]} \varepsilon\|^2$: on retrouve le carré de la statistique de Student (on rappelle que si E est un sev de \mathbb{R}^n ayant une base orthonormale (e_1, \dots, e_k) , la projection de u sur E est égale à $\sum_{i=1}^k \langle e_i, u \rangle e_i = \sum_{i=1}^k ({}^t e_i u) e_i$). \square

Exercice 7.

(**) [Théorème de Gauss-Markov] On se propose de montrer dans cet exercice que, pour Y qui suit le modèle linéaire $Y = Z \theta^* + \varepsilon$, sous **(A0)**-**(A3)**, l'estimateur des moindres carrés $\hat{\theta}$ est optimal parmi les estimateurs linéaires sans biais.

L'optimalité veut dire que si $\tilde{\theta}$ est un autre estimateur linéaire sans biais :

$$\text{cov}(\tilde{\theta}) - \text{cov}(\hat{\theta}) \text{ est une matrice semi-définie positive,}$$

ou encore, ce qui est équivalent, que pour toute combinaison linéaire ${}^t C \theta$ des paramètres,

$$\text{Var}({}^t C \tilde{\theta}) \geq \text{Var}({}^t C \hat{\theta}).$$

i. Posons $\tilde{\theta} = M Y$ où M est une matrice de taille $(p+1, n)$. Montrer que $M Z = I_{p+1}$.

ii. Ecrire $\hat{\theta} = T P_{[Z]} Y$, et montrer que $M P_{[Z]} = T P_{[Z]}$.

iii. Montrer que $\tilde{\theta} = \hat{\theta} + M P_{[Z]^\perp} Y$, la somme étant non-corrélée. Conclure.

Proof. (i) $\tilde{\theta}$ est sans biais donc $\forall \theta^* \in \mathbb{R}^{p+1}, \mathbb{E}[\tilde{\theta}] = \theta^*$. C'est-à-dire: $M Z \theta^* = \theta^*$ car $\mathbb{E}[M Y] = \mathbb{E}[M(Z \theta^* + \varepsilon)] = \mathbb{E}[M Z \theta^*] + \mathbb{E}[M \varepsilon] = M Z \theta^*$ car $\mathbb{E}[\varepsilon] = 0$ d'après **(A1)**. 1 est donc valeur propre de la matrice $M Z$ et le sous-espace propre est \mathbb{R}^{p+1} tout entier, d'où $M Z$ est diagonalisable et sa matrice diagonale est I_{p+1} , donc $M Z = P I_{p+1} P^{-1}$ où P est la matrice de passage, et ainsi $M Z = I_{p+1}$.

(ii) $\hat{\theta} = ({}^t Z Z)^{-1} {}^t Z Z ({}^t Z Z)^{-1} {}^t Z Y$ donc $T = ({}^t Z Z)^{-1} {}^t Z$.

$$M P_{[Z]} = M Z ({}^t Z Z)^{-1} {}^t Z = ({}^t Z Z)^{-1} {}^t Z$$

$$T P_{[Z]} = ({}^t Z Z)^{-1} {}^t Z Z ({}^t Z Z)^{-1} {}^t Z = ({}^t Z Z)^{-1} {}^t Z.$$

(iii) $\tilde{\theta} = M(P_{[Z]} Y + P_{[Z]^\perp} Y) = \hat{\theta} + M P_{[Z]^\perp} Y$, la somme étant non-corrélée car $P_{[Z]} Y$ et $P_{[Z]^\perp} Y$ le sont. En effet $\text{cov}(P_{[Z]} Y, P_{[Z]^\perp} Y) = \text{cov}(P_{[Z]} \varepsilon, P_{[Z]^\perp} \varepsilon) = \mathbb{E}(P_{[Z]} \varepsilon {}^t (P_{[Z]^\perp} \varepsilon)) = P_{[Z]} \mathbb{E}(\varepsilon {}^t \varepsilon) P_{[Z]^\perp} = \sigma^2 P_{[Z]} P_{[Z]^\perp} = 0$. On en déduit

$$\text{cov}(\tilde{\theta}) = \text{cov}(\hat{\theta}) + \text{cov}(M P_{[Z]^\perp} Y).$$

ce qui donne le résultat. \square