

Première Année Master M.A.E.F. 2018 – 2019
Econométrie II

Contrôle continu n°1, mars 2019

Examen de 1h30. Tout document ou calculatrice est interdit.

Soit $(Y_i)_{1 \leq i \leq n}$ une famille de variables aléatoires telle que:

$$Y_i = \mu_i^* + \varepsilon_i \quad \text{pour tout } i \in \{1, \dots, n\}, \quad (1)$$

où $(\varepsilon_i)_{i \in \mathbf{N}}$ est une suite de variables aléatoires identiquement distribuées indépendantes centrées et gaussiennes telles que $\text{var}(\varepsilon_1) = \sigma^2 < \infty$ et $\mu^* = (\mu_i^*)_{1 \leq i \leq n} \in \mathbf{R}^n$, vecteur fixé, appartenant à F un sous-espace vectoriel de \mathbf{R}^n . Dans toute la suite on notera $\|\cdot\|$ la norme sur \mathbf{R}^n telle que pour tout $Z \in \mathbf{R}^n$, $\|Z\|^2 = {}^t Z Z$ (${}^t A$ désignant la transposée de la matrice A). On définit les estimateurs respectifs de μ^* et σ^2 par

$$\hat{\mu} = \text{Argmin}_{\mu \in F} \|Y - \mu\| \quad \text{et} \quad \hat{\sigma}_n^2 = \frac{1}{n} \|Y - \hat{\mu}\|^2.$$

- On note $Y = (Y_i)_{1 \leq i \leq n}$. Ecrire le modèle (1) sous une forme vectorielle. Calculer $\mathbb{E}(Y)$ et $\text{cov}(Y)$ (matrice de variance-covariance de Y).
- Soit $X_0 \in \mathbf{R}^n$ tel que ${}^t X_0 = (1, 1, \dots, 1)$. On suppose dans cette question que $F = \text{Vect}(X_0) = [X_0]$, sous-espace engendré par X_0 . Montrer alors que $\hat{\mu} = \bar{Y}_n X_0$, où $\bar{Y}_n = \frac{1}{n} \sum_{i=1}^n Y_i$. Calculer le risque quadratique de $\hat{\mu}$, c'est-à-dire $\mathbb{E}(\|\hat{\mu} - \mu^*\|^2)$. Calculer $\mathbb{E}(\hat{\sigma}_n^2)$ et montrer que $\hat{\sigma}_n^2 \xrightarrow[n \rightarrow +\infty]{p.s.} \sigma^2$. Montrer que $(\hat{\mu}, \hat{\sigma}_n^2)$ est l'estimateur par maximum de vraisemblance de (μ^*, σ^2) . Est-ce un estimateur efficace?
- Soit $X_1 \in \mathbf{R}^n$, avec (X_0, X_1) non colinéaires. On suppose maintenant que $F = \text{Vect}(X_0, X_1) = [X_0, X_1]$. Rappeler quelle est la loi de $\|\hat{\mu} - \mu^*\|^2$, en déduire le risque quadratique de $\hat{\mu}$. Montrer que $\hat{\sigma}_n^2 \xrightarrow[n \rightarrow +\infty]{P} \sigma^2$.
- On suppose que la variable X_1 n'est en réalité pas explicative, c'est-à-dire que $F = [X_0]$ mais que $\hat{\mu}$ a la même expression que dans la question précédente (donc construit avec X_0 et X_1) car on a cru que X_1 était explicative. Déterminer alors la loi de $\|Y - \hat{\mu}\|^2$ puis le risque quadratique de $\hat{\mu}$. Comparer ce risque avec celui obtenu dans le cas où l'on sait à l'avance que seule X_0 est explicative.
- On veut tester $H_0 : F = \text{Vect}(X_0)$ contre $H_1 : F = \text{Vect}(X_0, X_1)$. Pour cela on considère la statistique

$$\hat{S} = \frac{\|Y - P_{[X_0]} Y\|^2 - \|Y - P_{[X_0, X_1]} Y\|^2}{\frac{1}{n-2} \|Y - P_{[X_0, X_1]} Y\|^2},$$

où P_E désigne la matrice de projection orthogonale sur le sev E . Montrer que \hat{S} est une variable positive, puis que \hat{S} suit une loi de Fisher $F(1, n-2)$ sous H_0 .

- On se place maintenant sous l'hypothèse H_1 avec précisément $\mu^* = a_0^* X_0 + a_1^* X_1$, où $a_1^* \neq 0$. Montrer alors que $\mathbb{E}(\|Y - P_{[X_0]} Y\|^2 - \|Y - P_{[X_0, X_1]} Y\|^2) = n(a_1^*)^2 \sigma_{1,n}^2 + \sigma^2$ avec $\sigma_{1,n}^2 = \frac{1}{n} {}^t X_1 X_1 - (\frac{1}{n} {}^t X_0 X_1)^2$. On suppose que $\sigma_{1,n}^2 \xrightarrow[n \rightarrow \infty]{} \sigma_1^2$ avec $\sigma_1^2 > 0$. En déduire alors que sous H_1 , $\hat{S} \xrightarrow[n \rightarrow +\infty]{P} +\infty$. Montrer que ce sera notamment le cas si X_1 est la réalisation de n variés de variance σ_1^2 , indépendantes de ε . Et que se passe-t-il si $X_1 = {}^t(1, 2, 3, \dots, n)$?

Proof. 1. On a bien-sûr $Y = \mu^* + \varepsilon$, $\mathbb{E}Y = \mu^*$ et $\text{cov}(Y) = \sigma^2 I_n$, où I_n est la matrice identité (**1.5 pts**).

2. On a $\widehat{\mu} = X_0({}^t X_0 X_0)^{-1} {}^t X_0 Y = \bar{Y}_n X_0 = \mu^* + \bar{\varepsilon}_n X_0$ (car ${}^t X_0 X_0 = n$ et $\mu^* \in \text{Vect}(X_0)$) (**1 pt**).

De plus, $\mathbb{E}(\|\widehat{\mu} - \mu^*\|^2) = \mathbb{E}(\|P_{[X_0]}\varepsilon\|^2) = \sigma^2$ car d'après le Théorème de Cochran, $\|P_{[X_0]}\varepsilon\|^2$ suit un $\sigma^2 \chi^2$ avec pour nombre de degrés de liberté $\dim([X_0]) = 1$ (**1 pt**).

On a $\mathbb{E}(\widehat{\sigma}_n^2) = \frac{1}{n} \mathbb{E}(\|P_{[X_0]^\perp}\varepsilon\|^2) = \frac{n-1}{n} \sigma^2$ car d'après le Théorème de Cochran, $\|P_{[X_0]^\perp}\varepsilon\|^2$ suit un $\sigma^2 \chi^2$ avec pour nombre de degrés de liberté $n - \dim([X_0]) = n - 1$ (**1 pt**).

On a encore $\widehat{\sigma}_n^2 = \frac{1}{n} \sum_{i=1}^n (\varepsilon_i - \bar{\varepsilon}_n)^2 = \frac{1}{n} \sum_{i=1}^n \varepsilon_i^2 - (\bar{\varepsilon}_n)^2$. Mais les ε_i^2 sont des v.a. d'espérance finie ($= \sigma^2$), on peut donc appliquer la loi forte des grands nombres et $\frac{1}{n} \sum_{i=1}^n \varepsilon_i^2 \xrightarrow[n \rightarrow +\infty]{p.s.} \sigma^2$. Ensuite $\bar{\varepsilon}_n \xrightarrow[n \rightarrow +\infty]{p.s.} 0$ (loi forte des grands nombres appliquée à (ε_i)). Enfin la somme de 2 suites de v.a. convergeant ps converge ps vers la somme des limites, donc $\widehat{\sigma}_n^2 \xrightarrow[n \rightarrow +\infty]{p.s.} \sigma^2$ (**2 pts**).

La log-vraisemblance de (Y_1, \dots, Y_n) est $L_{\mu, \sigma^2}(Y_1, \dots, Y_n) = -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log(\sigma^2) - \frac{1}{2\sigma^2} \|Y - \mu\|^2$ que l'on maximise pour trouver $(\widehat{\mu}, \widehat{\sigma}^2)$ (**2 pts**).

Le modèle statistique proposé est un modèle régulier de la famille exponentielle donc l'estimateur du MV est efficace (**2 pts**).

3. Par le même raisonnement que précédemment, $\mathbb{E}(\|\widehat{\mu} - \mu^*\|^2) = \mathbb{E}(\|P_{[X_0, X_1]}\varepsilon\|^2) = 2\sigma^2$ (**1 pt**).

De plus, $\|P_{F^\perp} Y\|^2$ a pour loi $\sigma^2 \chi^2(n-2)$. Mais comme un $\chi^2(n-2)$ peut s'écrire comme une somme de $n-2$ carrés de v.a. gaussiennes centrées réduites, d'après la loi des grands nombres, $\frac{1}{n-2} \chi^2(n-2) \xrightarrow[n \rightarrow \infty]{\mathcal{L}} 1$, donc $\widehat{\sigma}_n^2 \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \sigma^2$, ou encore $\widehat{\sigma}_n^2 \xrightarrow[n \rightarrow +\infty]{\mathcal{P}} \sigma^2$ (**1.5 pts**).

4. $\|Y - \widehat{\mu}\|^2 = \|P_{[X_0, X_1]^\perp} \varepsilon\|^2$ a pour loi un $\sigma^2 \chi^2(n-2)$.

Le risque quadratique est encore $2\sigma^2$, donc 2 fois plus grand que le risque obtenu dans le cas où l'on sait à l'avance que seule X_0 intervient (**1 pt**).

5. On a $\|Y - P_{[X_0]} Y\|^2 - \|Y - P_{[X_0, X_1]} Y\|^2 = \|P_{[X_0]^\perp} Y\|^2 - \|P_{[X_0, X_1]^\perp} Y\|^2$. Comme $[X_0, X_1]^\perp \subset [X_0]^\perp$, on peut toujours écrire que $\|Y - P_{[X_0]} Y\|^2 - \|Y - P_{[X_0, X_1]} Y\|^2 = \|P_{[X_0, X_1] \cap [X_0]^\perp} Y\|^2$ d'après Pythagore, donc la variable \widehat{S} est positive (**1.5 pts**).

On a sous H_0 , $\|Y - P_{[X_0]} Y\|^2 - \|Y - P_{[X_0, X_1]} Y\|^2 = \|P_{[X_0, X_1] \cap [X_0]^\perp} \varepsilon\|^2$ et $\|Y - P_{[X_0, X_1]} Y\|^2 = \|P_{[X_0, X_1]^\perp} \varepsilon\|^2$. Or d'après Cochran, $\|P_{[X_0, X_1] \cap [X_0]^\perp} \varepsilon\|^2 \stackrel{\mathcal{L}}{\sim} \sigma^2 \chi^2(1)$ et $\|P_{[X_0, X_1]^\perp} \varepsilon\|^2 \stackrel{\mathcal{L}}{\sim} \sigma^2 \chi^2(n-2)$, les deux χ^2 étant indépendants car les sous-espaces de projection sont orthogonaux. On en déduit bien que $\widehat{S} \stackrel{\mathcal{L}}{\sim} F(1, n-2)$ (**2.5 pts**).

6. On a sous l'hypothèse H_1 , $\|Y - P_{[X_0]} Y\|^2 = \|P_{[X_0]^\perp} Y\|^2 = \|P_{[X_0]^\perp} (a_0^* X_0 + a_1^* X_1 + \varepsilon)\|^2 = \|a_1^* P_{[X_0]^\perp} * X_1 + P_{[X_0]^\perp} \varepsilon\|^2$. En conséquence, $\mathbb{E}(\|Y - P_{[X_0]} Y\|^2) = \mathbb{E}(\|P_{[X_0]^\perp} Y\|^2) = \|a_1^* P_{[X_0]^\perp} * X_1\|^2 + \mathbb{E}(\|P_{[X_0]^\perp} \varepsilon\|^2) = (a_1^*)^2 ({}^t X_1 X_1 - \frac{1}{n} ({}^t X_0 X_1)^2) + (n-1)\sigma^2$. Comme $\mathbb{E}(\|Y - P_{[X_0, X_1]} Y\|^2) = (n-2)\sigma^2$, on en déduit le résultat (**3 pts**).

En reprenant le calcul précédent, on a donc $\|Y - P_{[X_0]} Y\|^2 = (a_1^*)^2 ({}^t X_1 X_1 - \frac{1}{n} ({}^t X_0 X_1)^2) + \|P_{[X_0]^\perp} \varepsilon\|^2 + 2a_1^{*t} X_1 P_{[X_0]^\perp} \varepsilon$.

Mais $\mathbb{E}({}^t X_1 P_{[X_0]^\perp} \varepsilon) = 0$ et $\text{var}({}^t X_1 P_{[X_0]^\perp} \varepsilon) = \sigma^2 n \sigma_{1,n}^2$, donc ${}^t X_1 P_{[X_0]^\perp} \varepsilon / (n \sigma_{1,n}^2) \xrightarrow[n \rightarrow +\infty]{\mathcal{P}} 0$. On en déduit donc d'après Slutski que $\|Y - P_{[X_0]} Y\|^2 - \|Y - P_{[X_0, X_1]} Y\|^2 \xrightarrow[n \rightarrow +\infty]{\mathcal{P}}$.

Or on sait que le dénominateur de \widehat{S} converge vers σ^2 , ce qui montre d'après Slutski que $\widehat{S} \xrightarrow[n \rightarrow +\infty]{\mathcal{P}} \infty$ (**3 pts**).

D'après la question précédente 2., $\sigma_{1,n}^2 \xrightarrow[n \rightarrow +\infty]{p.s.} \sigma_1^2$ (**1 pt**).

Le résultat, $\widehat{S} \xrightarrow[n \rightarrow +\infty]{\mathcal{P}} \infty$, est le même dans le cas où $X_1 = {}^t(1, 2, 3, \dots, n)$ (**1 pt**).

□