

Première Année Master M.A.E.F. 2020 – 2021

Econométrie II

Contrôle continu n°1, mars 2021

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

On suppose que pour n et p deux entiers tels que $n \geq p + 2$, on observe $Y = {}^t(Y_i)_{1 \leq i \leq n}$ défini par :

$$Y_i = \theta_0 + \theta_1 X_i^{(1)} + \dots + \theta_p X_i^{(p)} + \varepsilon_i \quad \text{pour tout } i = 1, \dots, n, \quad (1)$$

avec une famille connue de réels $(X_i^{(j)})_{1 \leq i \leq n, 1 \leq j \leq p}$, et telle que $X = \begin{pmatrix} 1 & X_1^{(1)} & \dots & X_1^{(p)} \\ \vdots & \vdots & & \vdots \\ 1 & X_n^{(1)} & \dots & X_n^{(p)} \end{pmatrix}$ soit une

matrice de rang $p + 1$, $\theta = {}^t(\theta_j)_{0 \leq j \leq p}$ un vecteur de nombres réels inconnus et $\varepsilon = {}^t(\varepsilon_i)_{1 \leq i \leq n}$ un vecteur d'erreur de loi $\mathcal{N}(0, \sigma^2 I_n)$ non observé, où $\sigma^2 > 0$ est inconnu et I_n est la matrice identité de taille n .

Pour M une matrice de taille $(n, p + 1)$, on note $[M] = \{M\alpha, \alpha \in \mathbf{R}^{p+1}\}$ et P_A la matrice de projection orthogonale sur un sous-espace A de \mathbf{R}^n .

1. Pour A et B deux sous-espaces vectoriels de \mathbf{R}^n , montrer que $P_A P_B = P_B P_A = P_{A \cap B}$ (**1.5pts**).
2. Ecrire le modèle sous une forme matricielle, et rappeler l'expression du vecteur $\hat{Y} = (\hat{Y}_i)_{1 \leq i \leq n} = X \hat{\theta}$ obtenu par moindres carrés. Démontrer que la loi de \hat{Y} est $\mathcal{N}_n(X\theta, \sigma^2 X({}^t X X)^{-1} X)$ (**2.5pts**).
3. Démontrer que $\frac{1}{n} \sum_{i=1}^n \hat{Y}_i = \frac{1}{n} \sum_{i=1}^n Y_i$ (**1.5pts**).
4. Rappeler en la justifiant la loi de $\hat{\sigma}^2$ estimateur non biaisé de σ^2 (**1pt**).
5. On veut tester si l'observation Y_n n'est pas une donnée aberrante, alors que les autres Y_i ne le sont pas. On considère ainsi le problème de test $H_0: \varepsilon_n$ suit la loi $\mathcal{N}(0, \sigma^2)$, contre $H_1: \varepsilon_n$ ne suit pas la loi $\mathcal{N}(0, \sigma^2)$. Soit $X_{(n)}$ la matrice X où l'on remplace la dernière ligne par des 0 et $E_n = \text{Vect}({}^t(0, \dots, 0, 1))$.
 - (a) Montrer que $E_n \subset [X_{(n)}]^\perp$ (**1pt**).
 - (b) Montrer que $\hat{\sigma}_{(n)}^2$ l'estimateur non biaisé de σ^2 à partir de l'échantillon privé de l'individu n s'écrit $\frac{1}{n-p-2} \|P_{E_n^\perp} P_{[X_{(n)}]^\perp} \varepsilon\|^2$ (**3pts**).
 - (c) Montrer que $\hat{\varepsilon}_n = Y_n - \hat{Y}_n = (0, \dots, 0, 1) P_{E_n} P_{[X]^\perp} \varepsilon$ (**2pts**).
 - (d) En déduire que $\varepsilon'_n = \frac{Y_n - \hat{Y}_n}{(\hat{\sigma}_{(n)}^2 (1 - p_{nn}))^{1/2}}$ suit une loi de student à $n - p - 2$ degrés de liberté, où $P_{[X]} = (p_{ij})_{1 \leq i, j \leq n}$. Comment utiliser ε'_n pour accepter ou non H_0 ? (**2pts**).

6. On suppose que l'on observe $X_{n+1} = (1, X_{n+1}^{(1)}, \dots, X_{n+1}^{(p)})$, vecteur de réels connus, et l'on veut prédire Y_{n+1} .
- Montrer qu'une prédiction de Y_{n+1} est $\tilde{Y}_{n+1} = X_{n+1}({}^t X X)^{-1} {}^t X Y$ et montrer que $\mathbb{E}(\tilde{Y}_{n+1}) = \mathbb{E}(Y_{n+1})$ (**2pts**).
 - Déterminer la loi de \tilde{Y}_{n+1} , puis montrer que $\frac{\tilde{Y}_{n+1} - \mathbb{E}(Y_{n+1})}{(\hat{\sigma}^2 X_{n+1}({}^t X X)^{-1} X_{n+1})^{1/2}}$ suit une loi que l'on précisera (**2pts**).
 - En déduire un intervalle de prédiction à 95% pour Y_{n+1} . Sans l'hypothèse gaussienne sur ε , quel intervalle aurait-on pu obtenir et sous quelles hypothèses? (**2pts**)
7. On se place dans le simple cadre où $p = 1$, et sans l'hypothèse de gaussianité de ε .
- Ecrire $\hat{\theta}$ en fonction des $x_i = X_i^{(1)}$ et des Y_i (on utilisera les notations $\bar{x}_n = \frac{1}{n}(x_1 + \dots + x_n)$ et $\bar{Y}_n = \frac{1}{n}(Y_1 + \dots + Y_n)$) (**1pt**).
 - Donner une hypothèse suffisante pour que $\hat{\theta}$ satisfasse un théorème de la limite centrale que l'on précisera (**1.5pts**).
 - Donner alors explicitement la statistique du test de Fisher global du modèle ainsi que sa limite (**1pt**).
 - Donner ensuite l'intervalle asymptotique de prédiction à 95% pour Y_{n+1} en fonction de x_{n+1} . Que se passe-t-il quand $x_{n+1} \rightarrow \infty$? (**1.5pts**).

Proof. 1. Pour $U \in A \cap B$, on a $P_A U = U$ puisque $U \in A \cap B$ donc $U \in A$, $P_B U = U$ et également $P_{A \cap B} U = P_A P_B U = P_B P_A U$. Pour $V \in (A \cap B)^\perp$, on a $P_{A \cap B} V = 0$ par définition. Mais $(A \cap B)^\perp = A^\perp + B^\perp$, donc $V = P_{A^\perp} V + P_{B^\perp} V$. Mais $P_A(P_{A^\perp} V + P_{B^\perp} V) = P_A P_{B^\perp} V$. D'où $P_B P_A V = P_B = P_A P_{B^\perp} V = 0$. Et la même chose pour $P_A P_B V = 0$. D'où $P_{A \cap B} = P_A P_B = P_B P_A$.

2. On a $Y = X\theta + \varepsilon$ et $\hat{Y} = P_{[X]} Y = X({}^t X X)^{-1} {}^t X Y$.
On a $Y = X\theta + \varepsilon$, d'où $\hat{Y} = P_{[X]} X\theta + P_{[X]} \varepsilon = X\theta + P_{[X]} \varepsilon$ car $X\theta \in [X]$. On sait que ε est un vecteur gaussien, comme $P_{[X]}$ est une matrice de réels, alors $P_{[X]} \varepsilon$ est aussi un vecteur gaussien. Et comme $X\theta$ est un vecteur de réels, alors \hat{Y} est bien un vecteur gaussien. Il est défini par son espérance et sa matrice de variance-covariance. $\mathbb{E}[\hat{Y}] = X\theta + \mathbb{E}[P_{[X]} \varepsilon] = X\theta$ car $\mathbb{E}[\varepsilon] = 0$. Et $\text{cov}(\hat{Y}) = \text{cov}(P_{[X]} \varepsilon) = P_{[X]} \text{cov}(\varepsilon) {}^t P_{[X]}$. On sait que $\text{cov}(\varepsilon) = \sigma^2 I_n$, donc $\text{cov}(\hat{Y}) = \sigma^2 P_{[X]} {}^t P_{[X]} = \sigma^2 P_{[X]}$ car ${}^t P_{[X]} = P_{[X]}$ pour une projection orthogonale et $P_{[X]} P_{[X]} = P_{[X]}$ car projection. D'où le résultat.
3. Soit le vecteur $\mathbb{I} = {}^t(1, \dots, 1)$. Alors $\frac{1}{n} \sum_{i=1}^n \hat{Y}_i = \frac{1}{n} {}^t \mathbb{I} \hat{Y} = \frac{1}{n} {}^t \mathbb{I} P_{[X]} Y = \frac{1}{n} {}^t (P_{[X]} \mathbb{I}) Y = \frac{1}{n} {}^t \mathbb{I} Y = \bar{Y}$ car $\mathbb{I} \in [X]$ donc $P_{[X]} \mathbb{I} = \mathbb{I}$.
4. On a $\hat{\sigma}^2 = \frac{1}{n-(p+1)} \|Y - \hat{Y}\|^2 = \frac{1}{n-(p+1)} \|P_{[X]^\perp} Y\|^2$. D'après Cochran, $\|P_{[X]^\perp} Y\|^2 \stackrel{\mathcal{L}}{\sim} \sigma^2 \chi^2(n - (p+1))$, d'où $\hat{\sigma}^2 \stackrel{\mathcal{L}}{\sim} \frac{\sigma^2}{n-(p+1)} \chi^2(n - (p+1))$.
5. (a) $[X_{(n)}]$ est généré par $p+1$ vecteurs de \mathbf{R}^n ayant tous 0 pour dernière coordonnée. Donc le produit scalaire euclidien classique de ces vecteurs et de E_n est nul: E_n est orthogonal à chacun de ces vecteurs, donc $E_n \subset [X_{(n)}]^\perp$.
- (b) Si l'on effectue une régression par moindres carrés par rapport au $(n-1)$ premières données, on obtient un vecteur de prédiction $\hat{Y}^{(n)} = P_{[X_{(n)}]} Y$ et un vecteur de résidus $\hat{\varepsilon}^{(n)} = Y - P_{[X_{(n)}]} Y = P_{[X_{(n)}]^\perp} \varepsilon$ mais il faut enlever la n -ième composante qui vaut Y_n . Aussi peut-on appliquer une projection sur E_n^\perp puisque $P_{[E_n]^\perp} \hat{\varepsilon}^{(n)} = \hat{\varepsilon}^{(n)} - P_{[E_n]} \hat{\varepsilon}^{(n)}$ et $P_{[E_n]} \hat{\varepsilon}^{(n)} = {}^t(0, \dots, 0, Y_n)$. Donc d'appliquer $P_{[E_n]^\perp}$ à $\hat{\varepsilon}^{(n)}$ transforme sa n -ième composante en 0, et les $n-1$ autres composantes sont inchangées. Or l'estimateur $\hat{\sigma}_{(n)}^2$ vaut $\hat{\sigma}_{(n)}^2 = \frac{1}{n-1-(p+1)} \sum_{i=1}^{n-1} (\hat{\varepsilon}_i^{(n)})^2$. Et cette somme est exactement égale à $\frac{1}{n-p-2} \|P_{E_n^\perp} P_{[X_{(n)}]^\perp} \varepsilon\|^2$.

(c) Il est clair que $\widehat{\varepsilon} = P_{[X]^\perp} \varepsilon$. Donc $P_{E_n} \widehat{\varepsilon} = P_{[X]^\perp} \varepsilon = {}^t(0, \dots, 0, \widehat{\varepsilon}_n)$, puisque projeter sur E_n c'est annuler les $(n-1)$ premières composantes d'un vecteur de \mathbf{R}^n . Donc $(0, \dots, 0, 1)P_{E_n} P_{[X]^\perp} \varepsilon$ représente le produit scalaire entre ${}^t(0, \dots, 0, \widehat{\varepsilon}_n)$ et ${}^t(0, \dots, 0, 1)$, soit $\widehat{\varepsilon}_n$.

(d) On a $\widehat{\varepsilon}_n \stackrel{\mathcal{L}}{\sim} \mathcal{N}(0, \sigma^2(1 - p_{nn}))$ car $\widehat{\varepsilon} \stackrel{\mathcal{L}}{\sim} \mathcal{N}_n(0, \sigma^2(I_n - P_{[X]}))$. Donc $\frac{\widehat{\varepsilon}_n}{(\sigma^2(1 - p_{nn}))^{1/2}} \stackrel{\mathcal{L}}{\sim} \mathcal{N}(0, 1)$. Or

$\varepsilon'_n = \frac{\widehat{\varepsilon}_n}{(\sigma^2(1 - p_{nn}))^{1/2}} \left(\frac{\widehat{\sigma}_{(n)}^2}{\sigma^2} \right)^{-1/2}$. De plus, grâce au résultat vu précédemment mais appliqué au $(n-1)$ premières données, $\widehat{\sigma}_{(n)}^2 \stackrel{\mathcal{L}}{\sim} \frac{\sigma^2}{n-p-2} \chi^2(n-p-2)$. Ainsi, il ne nous reste qu'à montrer que $\widehat{\varepsilon}_n$ est

indépendant de $\widehat{\sigma}_{(n)}^2$ pour obtenir le fait que $\varepsilon'_n \stackrel{\mathcal{L}}{\sim} t(n-p-2)$. Mais $\widehat{\varepsilon}_n = (0, \dots, 0, 1)P_{E_n} P_{[X]^\perp} \varepsilon$ et $\widehat{\sigma}_{(n)}^2 = \frac{1}{n-p-2} \|P_{E_n^\perp} P_{[X_{(n)}]^\perp} \varepsilon\|^2$. Or les sous-espaces vectoriels de \mathbf{R}^n , $E_n \cap [X]^\perp$ (numérateur) et $E_n^\perp \cap [X_{(n)}]^\perp$ (dénominateur) sont orthogonaux, donc d'après Cochran, les vecteurs aléatoires dans \mathbf{R}^n constitués par les projections orthogonales sur ses sev sont indépendantes. D'où le résultat.

Pour accepter H_0 avec un risque α , il suffira de vérifier que ε'_n est dans un intervalle $[q_{\alpha/2}, q_{1-\alpha/2}]$ où q_β désigne le quantile β de la loi $t(n-p-2)$.

6. (a) On a $\widehat{\theta} = ({}^t X X)^{-1} {}^t X Y$. On prédira donc Y_{n+1} à l'aide de $\widehat{\theta}$ et X_{n+1} par la formule $X_{n+1} \widehat{\theta}$ soit \widetilde{Y}_{n+1} . $\mathbb{E}[\widetilde{Y}_{n+1}] = \mathbb{E}[X_{n+1} \widehat{\theta}] = \mathbb{E}[X_{n+1} \theta] + \mathbb{E}[X_{n+1} ({}^t X X)^{-1} {}^t X \varepsilon] = X_{n+1} \theta + 0$ car $\mathbb{E}[\varepsilon] = 0$. Et $\mathbb{E}[Y_{n+1}] = \mathbb{E}[X_{n+1} \theta + \varepsilon] = X_{n+1} \theta + 0$. D'où le résultat.

(b) \widetilde{Y}_{n+1} est gaussien car Y est un vecteur gaussien et $\widetilde{Y}_{n+1} = X_{n+1} ({}^t X X)^{-1} {}^t X Y$. D'où

$$\widetilde{Y}_{n+1} \stackrel{\mathcal{L}}{\sim} \mathcal{N}\left(X_{n+1} \theta, X_{n+1} ({}^t X X)^{-1} X \text{cov}(\varepsilon) {}^t (X_{n+1} ({}^t X X)^{-1} X)\right) = \mathcal{N}\left(X_{n+1} \theta, \sigma^2 X_{n+1} ({}^t X X)^{-1} X_{n+1}\right).$$

On en déduit que $\frac{\widetilde{Y}_{n+1} - \mathbb{E}(Y_{n+1})}{(\sigma^2 X_{n+1} ({}^t X X)^{-1} X_{n+1})^{1/2}} \stackrel{\mathcal{L}}{\sim} \mathcal{N}(0, 1)$. On a vu que $\widehat{\sigma}^2 \stackrel{\mathcal{L}}{\sim} \frac{\sigma^2}{n-(p+1)} \chi^2(n-(p+1))$. Il reste à montrer que $\widehat{\sigma}^2$ et \widetilde{Y}_{n+1} sont indépendants, ce qui est le cas car on sait d'après le cours que $\widehat{\sigma}^2$ et $\widehat{\theta}$ sont indépendantes (Cochran). Ainsi

$$\frac{\widetilde{Y}_{n+1} - \mathbb{E}(Y_{n+1})}{(\widehat{\sigma}^2 X_{n+1} ({}^t X X)^{-1} X_{n+1})^{1/2}} \stackrel{\mathcal{L}}{\sim} t(n-(p+1)).$$

(c) On en déduit qu'un intervalle de prédiction à 95% pour Y_{n+1} est

$$\left[\widetilde{Y}_{n+1} - q_{0.975} (\widehat{\sigma}^2 X_{n+1} ({}^t X X)^{-1} X_{n+1})^{1/2}, \widetilde{Y}_{n+1} + q_{0.975} (\widehat{\sigma}^2 X_{n+1} ({}^t X X)^{-1} X_{n+1})^{1/2} \right],$$

avec $q_{0.975}$ le quantile à 97.5% de la loi $t(n-p-1)$.

Si on rajoute l'hypothèse $\max_{1 \leq i \leq n} \{ |p_{ii}| \} \xrightarrow{n \rightarrow \infty} 0$, alors $\widehat{\sigma}^2 \xrightarrow[n \rightarrow +\infty]{\mathcal{P}} \sigma^2$ et $\widehat{\theta}$ donc \widetilde{Y}_{n+1} est asymptotiquement gaussien. Et on aura

$$\frac{\widetilde{Y}_{n+1} - \mathbb{E}(Y_{n+1})}{(\widehat{\sigma}^2 X_{n+1} ({}^t X X)^{-1} X_{n+1})^{1/2}} \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, 1).$$

7. (a) On a $\widehat{\theta} = {}^t \left(\bar{y} - \frac{\bar{\sigma}_{xy}}{\bar{\sigma}_x^2} \bar{x}, \frac{\bar{\sigma}_{xy}}{\bar{\sigma}_x^2} \right)$.

(b) On calcule $P_{[X]}$ dans ce cas, qui vaut $X ({}^t X X)^{-1} {}^t X$. Or ici $({}^t X X)^{-1} = \frac{1}{n \bar{\sigma}_x^2} \begin{pmatrix} \bar{x}^2 & -\bar{x} \\ -\bar{x} & 1 \end{pmatrix}$ et après calculs on obtient pour terme général $\left(\frac{1}{n \bar{\sigma}_x^2} (\bar{x}^2 - (x_i + x_j) \bar{x} + x_i x_j) \right)_{1 \leq i, j \leq n}$. La condition pour obtenir la normalité est donc

$$\max_{1 \leq i \leq n} \left\{ \frac{1}{n \bar{\sigma}_x^2} |\bar{x}^2 - 2x_i \bar{x} + x_i^2| \right\} = \frac{1}{n} + \max_{1 \leq i \leq n} \left\{ \frac{(\bar{x} - x_i)^2}{n \bar{\sigma}_x^2} \right\} \xrightarrow{n \rightarrow \infty} 0.$$

(c) La statistique de Fisher est obtenue pour $C = {}^t(0, 1)$ et ainsi $\widehat{F} = \frac{1}{\widehat{\sigma}^2} {}^t \widehat{\theta}_1 (C ({}^t X X)^{-1} C)^{-1} \widehat{\theta}_1$. Après simplifications, on obtient:

$$\widehat{F} = \frac{n \bar{\sigma}_x^2}{\widehat{\sigma}^2} \left(\frac{\bar{\sigma}_{xy}}{\bar{\sigma}_x^2} \right)^2 = n \frac{(\bar{\sigma}_{xy})^2}{\widehat{\sigma}^2 \bar{\sigma}_x^2} \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \chi^2(1).$$

□