

Introduction à l'Econométrie - Licence 3

Correction Interro écrite no.1

Rémi Yin

12 mars 2014

Questions de cours (4 points)

1. **On considère le modèle $y_n = a + bx_n + \varepsilon_n$ pour lequel on dispose de N observations. Qu'appelle-t-on coefficient de détermination (R^2) du modèle ? Expliquez pourquoi il est compris entre 0 et 1. (2 points)**

Le coefficient de détermination est défini par

$$R^2 = \frac{SCE}{SCT} = \frac{\sum_{n=1}^N (\hat{y}_n - \bar{y}_N)^2}{\sum_{n=1}^N (y_n - \bar{y}_N)^2} = 1 - \frac{SCR}{SCT}$$

Le coefficient de détermination est donc compris entre 0 et 1 car il s'agit d'un rapport entre la variance expliquée par le modèle et la variance totale du phénomène observé. Le pouvoir explicatif des variables utilisées est ainsi d'autant plus fort que le R^2 est proche de 1. Bien que cette quantité soit systématiquement utilisée pour évaluer la qualité globale du modèle estimé, son interprétation nécessite beaucoup de précautions. Pour les lecteurs avertis : [Le prochain qui me parle du \$R^2\$...](#)

2. **On considère le modèle $y_n = a + bx_n + \varepsilon_n$ pour lequel on dispose de N observations. Définir les résidus estimés $\hat{\varepsilon}_n$. Quelles sont leurs propriétés ? (2 points)**

Les résidus estimés sont la différence entre la valeur y observée et la valeur y estimée. Formellement :

$$\forall n \quad \hat{\varepsilon}_n = y_n - \hat{y}_n$$

Pour ce qui est des propriétés des résidus, on sait d'après les équations normales (Conditions du premier ordre) du programme de minimisation des erreurs que :

$$\begin{aligned} -2 \sum_{n=1}^N (y_n - \hat{a} - \hat{b}x_n) &= 0 \Leftrightarrow \sum_{n=0}^N \hat{\varepsilon}_n = 0 \\ -2 \sum_{n=1}^N x_n \cdot (y_n - \hat{a} - \hat{b}x_n) &= 0 \Leftrightarrow \sum_{n=0}^N \hat{\varepsilon}_n x_n = 0 \end{aligned}$$

On peut en déduire que la moyenne empirique des résidus estimés est égale à 0 :

$$\overline{\hat{\varepsilon}_N} = 0$$



FIGURE 1 – CR7 du Real Madrid

Exercice 1 (12 points)

On s'intéresse au lien qu'il peut y avoir entre le poids et la taille des buteurs dans les différents championnats Européens de Football en 2014 . On considère le modèle linéaire simple :

$$y_n = a + bx_n + \varepsilon_n \quad \forall n = 1, \dots, N \quad (1)$$

où y_n désigne la poids et x_n la taille des buteurs. On suppose que les résidus sont indépendants et suivent une loi $\mathcal{N}(0; \sigma^2)$

On estime ce modèle par moindres carrés ordinaires et le site de la Fifa nous donne des informations sur $N = 55$ footballeurs. Les observations (en centimètres et en kilogrammes) conduisent aux valeurs suivantes :

$$\bar{x}_N = 183,6 \quad \bar{y}_N = 79$$

$$Cov_{emp}(x_n; y_n) = 39,2$$

$$s_x = 6,7 \quad s_y = 7,3$$

où s_x et s_y sont respectivement les **écarts-types** empiriques de la taille et du poids. Les données récoltées pour ce dossier sont disponibles sur le site du jeu Fifa 14 : sofifa.com/fr

1. Calculez \hat{a} et \hat{b} (2 points)

$$\hat{b} = \frac{Cov_{emp}(x_n; y_n)}{V_{emp}(x_n)} = \frac{39,2}{6,7^2} = 0,87$$

$$\hat{a} = \bar{y}_N - \hat{b}\bar{x}_N = 79 - 0,87 \times 183,6 = -80,7$$

2. Calculez $\hat{\sigma}^2$ (2 points)

On souhaite calculer $\hat{\sigma}^2 = \frac{SCR}{N-2}$ Or, on sait que :

$$SCR = \sum_{n=1}^N \hat{\varepsilon}_n^2$$

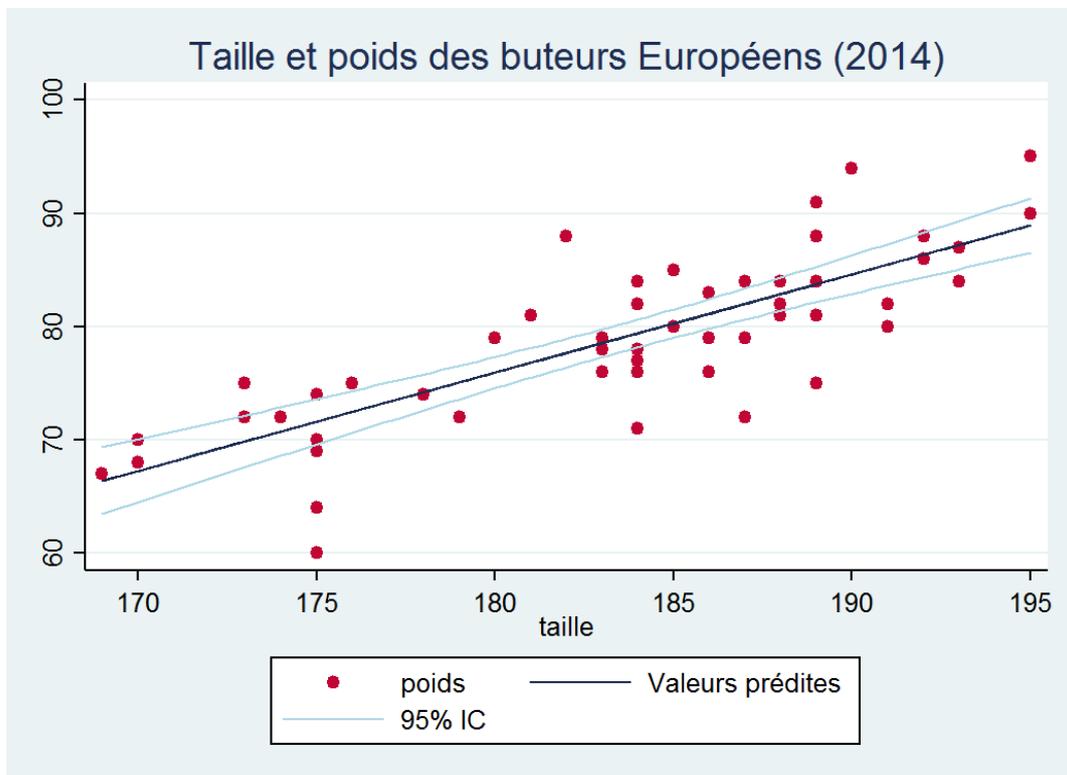


FIGURE 2 – Régression par la méthode des m.c.o

$$\begin{aligned}
 \sum_{n=1}^N \hat{\varepsilon}_n^2 &= \sum_{n=1}^N (y_n - \hat{y}_N)^2 \\
 &= \sum_{n=1}^N (y_n - \hat{a} - \hat{b}x_n)^2 \\
 &= \sum_{n=1}^N (y_n - \bar{y}_N + \hat{b}\bar{x}_N - \hat{b}x_n)^2 \\
 &= \sum_{n=1}^N (y_n - \bar{y}_N)^2 + \hat{b}^2(x_n - \bar{x}_N)^2 - 2\hat{b}(x_n - \bar{x}_N)(y_n - \bar{y}_N) \\
 &= N.V_{emp}(y_n) + \hat{b}^2.N.V_{emp}(x_n) - 2\hat{b}.N.Cov_{emp}(x_n; y_n) \\
 &= 55 \times 7.3^2 + 0.87^2 \times 55 \times 6.7^2 - 0.87 \times 2 \times 55 \times 39.2 \\
 &= 1048.26
 \end{aligned}$$

On en déduit $\hat{\sigma}^2 = \frac{1048.26}{53} = 19.78$

3. Menez, au seuil de 10%, les tests des significativités du modèle. (2 points)

On s'intéresse au test $H_0 : b = 0$ contre $H_1 : b \neq 0$ au niveau $\alpha = 10\%$

On sait que :

$$\begin{aligned} \frac{\hat{b} - b}{\sqrt{\frac{\hat{\sigma}^2}{N.V_{emp}(x_n)}}} &\rightarrow \mathcal{T}_{N-2} \\ \Rightarrow \frac{\hat{b}}{\sqrt{\frac{\hat{\sigma}^2}{N.V_{emp}(x_n)}}} &\xrightarrow{H_0} \mathcal{T}_{N-2} \end{aligned}$$

On rejette donc H_0 si

$$\left| \frac{\hat{b}}{\sqrt{\frac{\hat{\sigma}^2}{N.V_{emp}(x_n)}}} \right| > t_{0.95;53}^* = 1.676$$

Or,

$$\left| \frac{\hat{b}}{\sqrt{\frac{\hat{\sigma}^2}{N.V_{emp}(x_n)}}} \right| = 9.7$$

On conclut donc au rejet de H_0 au niveau 10%. b est significatif au seuil de 10 %.

On s'intéresse au test $H_0 : a = 0$ contre $H_1 : a \neq 0$ au niveau $\alpha = 10\%$ On sait que :

$$\begin{aligned} \frac{\hat{a} - a}{\sqrt{\frac{\hat{\sigma}^2}{N.V_{emp}(x_n)}(s_x^2 + \bar{x}_N^2)}} &\rightarrow \mathcal{T}_{N-2} \\ \Rightarrow \frac{\hat{a}}{\sqrt{\frac{\hat{\sigma}^2}{N.V_{emp}(x_n)}(s_x^2 + \bar{x}_N^2)}} &\xrightarrow{H_0} \mathcal{T}_{N-2} \end{aligned}$$

On rejette H_0 si $\left| \frac{\hat{a}}{\sqrt{\frac{\hat{\sigma}^2}{N.V_{emp}(x_n)}(s_x^2 + \bar{x}_N^2)}} \right| > t_{0.95;53}^* = 1.676$

Or,

$$\left| \frac{\hat{a}}{\sqrt{\frac{\hat{\sigma}^2}{N.V_{emp}(x_n)}(s_x^2 + \bar{x}_N^2)}} \right| = 4.90$$

On conclut donc au rejet de H_0 au niveau 10%. a est significatif au seuil de 10%.

4. **Menez, au seuil de 10% le test d'hypothèse $H_0 : b = 0,8$ contre l'hypothèse $H_1 : b \neq 0,8$ (1,5 point)**

On s'intéresse au test $H_0 : b = 0.8$ contre $H_1 : b \neq 0.8$ au niveau $\alpha = 10\%$.

$$\frac{\hat{b} - 0.8}{\sqrt{\frac{\hat{\sigma}^2}{N.V_{emp}(x_n)}}} \xrightarrow{H_0} \mathcal{T}_{N-2}$$

Il s'agit d'un test **bilatéral** :

$$\text{On rejette donc } H_0 \text{ si } \left| \frac{\hat{b}-0.8}{\sqrt{\frac{\hat{\sigma}^2}{N.V_{emp}(x_n)}}} \right| > t_{0.95;53}^* = 1.676$$

Or,

$$\left| \frac{\hat{b}-0.8}{\sqrt{\frac{\hat{\sigma}^2}{N.V_{emp}(x_n)}}} \right| = 0.78$$

On ne rejette pas H_0 au seuil 10%. b est significativement égal à 0.8 au seuil de 10%

5. **Menez, au seuil de 10% le test d'hypothèse $H_0 : b \leq 0,8$ contre l'hypothèse $H_1 : b > 0,8$ (1,5 point)**

On s'intéresse au test $H_0 : b = 0.8$ contre $H_1 : b > 0.8$ au niveau $\alpha = 10\%$.

$$\frac{\hat{b}-0.8}{\sqrt{\frac{\hat{\sigma}^2}{N.V_{emp}(x_n)}}} \xrightarrow{H_0} \mathcal{T}_{N-2}$$

Il s'agit d'un test **unilatéral** :

$$\text{On rejette donc } H_0 \text{ si } \frac{\hat{b}-0.8}{\sqrt{\frac{\hat{\sigma}^2}{N.V_{emp}(x_n)}}} > t_{0.90;53}^* = 1.299$$

Or,

$$\frac{\hat{b}-0.8}{\sqrt{\frac{\hat{\sigma}^2}{N.V_{emp}(x_n)}}} = 0.78$$

On ne rejette pas H_0 au seuil 5%. b est significativement inférieur à 0.8.

6. **Construisez un intervalle de confiance à 5 % pour le paramètre b (1 point)** cf. Cours magistraux et TD de statistiques du premier semestre pour la procédure de l'intervalle de confiance. On veut :

$$P\left(-t_{(0.975,53)} < \frac{\hat{b}-0.8}{\sqrt{\frac{\hat{\sigma}^2}{N.V_{emp}(x_n)}}} < t_{(0.975,53)}\right) = 95\%$$

Les calculs permettent d'écrire l'intervalle de confiance sous la forme suivante :

$$\begin{aligned} IC(b) &= \left[\hat{b} \pm 2.009 \sqrt{\frac{19.78}{55 \times 6.7^2}} \right] \\ &= [0.69; 1.049] \end{aligned}$$

7. **Construisez un intervalle de prévision au niveau de confiance 95% lorsque $x_{N+1} = 195$ (2 point)**

On réalise l'estimation ponctuelle : $y_{N+1}^* = -80.7 + 0.87 \times 195 = 88.95$

On sait que :

$$\frac{Y_{N+1}^* - Y_{N+1}}{\sqrt{\hat{\sigma}^2 \lambda_{N+1}}} \rightsquigarrow \mathcal{T}_{N-2}$$

Avec

$$\lambda_{N+1} = 1 + \frac{1}{N} + \frac{(x_{N+1} - \bar{x}_N)^2}{N.V_{emp}(x_n)}$$

On veut :

$$P\left(-t_{(0.975,53)} < \frac{Y_{N+1}^* - Y_{N+1}}{\sqrt{\hat{\sigma}^2 \lambda_{N+1}}} < t_{(0.975,53)}\right) = 95\%$$

Les calculs permettent d'écrire l'intervalle de prévision sous la forme suivante :

$$\begin{aligned} IC(b) &= \left[Y_{N+1} \pm 2.009 \sqrt{1 + \frac{1}{55} + \frac{(195 - 1836.6)^2}{55 \times 7.3^2}} \right] \\ &= \left[79.73; 98.16 \right] \end{aligned}$$

Ainsi, pour un buteur mesurant 1,95m, on peut affirmer avec une certitude de 95% qu'il pèse entre 79,73 et 98,16 kilos.

Exercice 2 (3 points)

On considère le modèle linéaire simple :

$$y_n = a + bx_n + \varepsilon_n \quad \forall n = 1, \dots, N \quad (2)$$

pour lequel on dispose de N observations.

On note R^2 le coefficient de détermination obtenu lorsqu'on estime ce modèle par m.c.o et ρ_{xy}^2 le coefficient de corrélation empirique entre x et y .

1. **Montrez que $R^2 = \rho_{xy}^2$ (3 points)**

Cf, exercice de TD pour la correction.

TABLE 1 – Extrait du tableau Taille-Poids des buteurs en 2014 (Données <http://sofifa.com/fr>)

Nom	Taille	Poids
Ibrahimovic	195	95
falcao	176	75
Van Persie	187	72
Suarez	181	81
Cavani	184	71
Lewandowski	184	78
Tevez	173	75
Benzema	187	79
Gomez	189	88
Neymar	175	64
Balotelli	189	88
Higuain	184	82
Huntelaar	186	83
Negredo	186	79
Drogba	189	91
Jovetic	183	79
Mandzukic	187	84
Dzeko	193	84
Diego Costa	188	81
Soldado	179	72
David Villa	175	69
Eto'o	180	79
Martinez	185	85
Hernandez	175	60
Sturridge	183	76
Rossi	173	72
Llorente	195	90
Palacio	175	70
Fernando Torres	183	78
Berbatov	189	75
Klose	184	84
Cardosa	188	84
Bony	182	88
Benteke	192	86
Cardozo	193	87
Ba	189	84
Milito	183	78
Kiessling	191	80
Di Natale	170	68
Defoe	170	70
Barrogios	189	81
Lukaku	190	94
Doumbia	178	74
Remy	184	76
Giroud	192	88
...