

Fiche sur les régressions

Correction de l'exercice 6

9 janvier 2007

1. La variable expliquée est la valeur ajoutée de l'entreprise Y . Les variables explicatives sont la valeur du capital utilisé X et le nombre de salariés employés Z . En prenant de log du modèle M , nous obtenons :

$$\log(Y) = a \log(X) + (1 - a) \log(Z) + \log(k). \quad (1)$$

a et $1 - a$ s'interprètent comme les élasticités relatives de la valeur ajoutée de Y par rapport à X et Z :

$$a = \frac{d \log(Y)}{d \log(X)} = \frac{dY/Y}{dX/X}, \quad (1 - a) = \frac{d \log(Y)}{d \log(Z)} = \frac{dY/Y}{dZ/Z}.$$

Si on multiplie X et Z par la même constante $c > 0$, alors la valeur ajoutée de l'entreprise correspondante, prévue par le modèle M est :

$$k(cX)^a (cZ)^{1-a} = kc^a X^a c^{1-a} Z^{1-a} = c (kX^a Z^{1-a}),$$

et on constate qu'elle est elle également multipliée par c : f telle que $Y = f(X, Z)$ est homogène de degré 1.

2. Dans le modèle M , Y n'est pas linéaire en X ni en Z . En prenant le log comme en (1), et en utilisant les notations de l'énoncé :

$$y = ax + (1 - a)z + c, \quad \Leftrightarrow \quad (y - z) = a(x - z) + c \quad [M'].$$

Le modèle $[M']$ est un modèle de régression linéaire où la variable expliquée est $y - z$ et la variable explicative $x - z$, et on peut estimer les coefficients a et c par la méthode des moindres carrés.

3. Nous pouvons obtenir en prenant le log de nos données (X_j, Y_j, Z_j) , pour $j \in \llbracket 1, n \rrbracket$, des données $(x_j = \log(X_j), y_j = \log(Y_j), z_j = \log(Z_j))$, pour $j \in \llbracket 1, n \rrbracket$. Nous avons :

$$\begin{aligned} \text{cov}(x - z, y - z) &= \frac{1}{n} \sum_{j=1}^n (x_j - z_j - \bar{x} + \bar{z})(y_j - z_j - \bar{y} + \bar{z}) = \frac{1}{n} \sum_{j=1}^n [(x_j - \bar{x}) - (z_j - \bar{z})][(y_j - \bar{y}) - (z_j - \bar{z})] \\ &= \frac{1}{n} \sum_{j=1}^n \left[(x_j - \bar{x})(y_j - \bar{y}) - (x_j - \bar{x})(z_j - \bar{z}) - (z_j - \bar{z})(y_j - \bar{y}) + (z_j - \bar{z})^2 \right] \\ &= \text{cov}(x, y) - \text{cov}(x, z) - \text{cov}(y, z) + \text{Var}(z). \end{aligned} \quad (2)$$

Comme :

$$\text{Var}(x - z) = \text{cov}(x - z, x - z),$$

en utilisant le calcul fait en (2) et en y remplaçant y par x , on obtient :

$$\text{Var}(x - z) = \text{Var}(x) - 2\text{cov}(x, z) + \text{Var}(z). \quad (3)$$

De même, en remplaçant dans (3) x par y , $\text{Var}(y - z) = \text{Var}(y) - 2\text{cov}(y, z) + \text{Var}(z)$.

4. En utilisant les formules du cours et les résultats des questions 2 et 3 :

$$\begin{aligned} \hat{a} &= \frac{\text{cov}(x - z, y - z)}{\text{Var}(x - z)} = \frac{\text{cov}(x, y) - \text{cov}(x, z) - \text{cov}(y, z) + \text{Var}(z)}{\text{Var}(x) - 2\text{cov}(x, z) + \text{Var}(z)} \\ &= \frac{0,1836 - 0,1791 - 0,1760 + 0,1720}{0,1887 - 2 \times 0,1791 + 0,1720} = 0,20 \\ \hat{c} &= \overline{y - z} - \hat{a} \overline{x - z} = \bar{y} - \bar{z} - \hat{a}(\bar{x} - \bar{z}) \\ &= 9,97 - 4,71 - 0,20 \times (4,76 - 4,71) = 5,25. \end{aligned}$$

Pour une entreprise de valeur ajoutée Y , de capital X et ayant Z salarié, la nouvelle valeur ajoutée Y' obtenue avec le même capital X et un nombre de salarié Z' sera $Y' = kX^a Z'^{1-a} = Y(Z'/Z)^{1-a}$. On en déduit $Y'/Y = (Z'/Z)^{1-a}$. Si $Z'/Z = 0,01$, l'augmentation prévue en remplaçant a par \hat{a} est : $Y'/Y = 2,5\%$.

On définit :

$$\hat{y} = z + \hat{a}(x - z) + \hat{c} = \bar{y} + (z - \bar{z}) + \hat{a}((x - z) - \overline{x - z}) \quad (4)$$

en remplaçant \hat{c} par $\overline{y - z} - \hat{a}\overline{x - z}$. On pose $\hat{\varepsilon} = (y - z) - (\hat{y} - z) = y - \hat{y}$. En utilisant la définition de la variance et (4), on a :

$$\begin{aligned} \text{Var}(\hat{y} - z) &= \frac{1}{n} \sum_{j=1}^n (\hat{y}_j - z_j - \bar{y} + \bar{z})^2 = \frac{\hat{a}^2}{n} \sum_{j=1}^n ((x_j - z_j) - \overline{x - z})^2 \\ &= \hat{a}^2 \text{Var}(x - z) = \hat{a}^2 (\text{Var}(x) - 2\text{cov}(x, z) + \text{Var}(z)), \end{aligned}$$

par (3). L'équation d'analyse de la variance s'écrit alors :

$$\begin{aligned} \text{Var}(\hat{\varepsilon}) &= \text{Var}(y - z) - \text{Var}(\hat{y} - z) \quad (5) \\ &= (\text{Var}(y) - 2\text{cov}(y, z) + \text{Var}(z)) - \hat{a}^2 (\text{Var}(x) - 2\text{cov}(x, z) + \text{Var}(z)) \\ &= (0,1804 - 2 \times 0,1836 + 0,1720) - 0,20^2 \times (0,1887 - 2 \times 0,1791 + 0,1720) = 3,6 \cdot 10^{-4}. \end{aligned}$$

On en déduit :

$$\begin{aligned} R^2 &= \frac{\text{Var}(\hat{y} - z)}{\text{Var}(y - z)} = 1 - \frac{\text{Var}(\hat{\varepsilon})}{\text{Var}(y - z)} \quad \text{Ceci est une conséquence de (5) à retenir!} \\ &= 1 - \frac{3,6 \cdot 10^{-4}}{0,1804 - 2 \times 0,1760 + 0,1720} = 0,10. \end{aligned}$$

La part de variance expliquée, selon le modèle M' est très mauvaise.

$$\sqrt{\frac{1}{n} \sum_{j=1}^n \hat{\varepsilon}_j^2} = \sqrt{\text{Var}(\hat{\varepsilon})} = 1,90\%,$$

ce qui est très mauvais.