

Exercice n°4

1) moyenne empirique

$$\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$$

ici $\bar{x}_{10} = \frac{1}{10} \sum_{i=1}^{10} x_i = 80,3$

$$\bar{y}_n = \frac{1}{n} \sum_{i=1}^n y_i$$

ici $\bar{y}_{10} = \frac{1}{10} \sum_{i=1}^{10} y_i = 113,2$

variance empirique:

$$s_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2$$

ici $s_x^2 = \frac{1}{9} \sum_{i=1}^{10} (x_i - \bar{x}_n)^2 = \frac{9}{46,1}$

$$s_y^2 = \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y}_n)^2$$

ici $s_y^2 = \frac{1}{9} \sum_{i=1}^{10} (y_i - \bar{y}_n)^2 = \frac{9}{347,6}$

covariance empirique:

$$cov(x, y) = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)(y_i - \bar{y}_n)$$

ici $cov(x, y) = \frac{1}{9} \sum_{i=1}^{10} (x_i - \bar{x}_n)(y_i - \bar{y}_n) = \frac{9}{146,4}$

2)

La droite de régression expliquant y par x est : $\hat{y} = \hat{a}_n + \hat{b}_n x$ avec $\hat{a}_n = \bar{y}_n - \hat{b}_n \bar{x}_n$

et $\hat{b}_n = \frac{\sum (x_i - \bar{x}_n)(y_i - \bar{y}_n)}{\sum (x_i - \bar{x}_n)^2}$

ici $\hat{b}_n = \frac{9}{146,4}$

ici $\hat{a}_n = 113,2 - \frac{9}{146,4} \cdot 80,3$

3)

(a) le coefficient de détermination $R^2 = \frac{\sum (y_i - \hat{y}_n)^2}{\sum (y_i - \bar{y}_n)^2}$

erreur quadratique : $\frac{1}{n-1} \sum_{i=1}^n (y_i - \hat{y}_i)^2 = EQ$

$$\begin{aligned}
 \text{a} \quad \sum_{i=1}^n (y_i - \bar{y}_n)^2 &= \sum_{i=1}^n (y_i - \bar{y}_i)^2 + \sum_{i=1}^n (\bar{y}_i - \bar{y}_n)^2 \\
 \text{donc } R^2 &= \frac{\sum_{i=1}^n (y_i - \bar{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2 + \sum_{i=1}^n (\bar{y}_i - \bar{y}_n)^2} \\
 \text{soit } R^2 &= 1 - \frac{\sum_{i=1}^n (\bar{y}_i - \bar{y}_n)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2}
 \end{aligned}$$

(b)

Dans le cas de la régression linéaire simple, on a $R^2 = (x)^2$ avec x le coefficient de corrélation

$$\text{donc } (x)^2 = 1 - \frac{\sum_{i=1}^n \bar{y}_i^2}{\sum_{i=1}^n y_i^2}$$

(c)

si $|r|$ est proche de 1, cela signifie que l'erreur quadratique est proche de 0. Et donc que les y_i ont d'autant plus tendance à être proches les uns des autres.

Erreur:

- il faut être cohérent entre la définition des variables et covariances empiriques
- il faut connaître la définition des coefficients de détermination et de corrélation.