

Statistique

TD n°9

Ex 1

$$\min \left(\sum_{i=1}^n (y_i - (b + a x_i))^2 \right) = \sum \xi_i^2$$

Regression:

$$Y = a_1 x_1 + \dots + a_m x_m + b + \xi$$

$$m = 1$$

$$Y_i = b + a x_i + \xi_i$$

On observe $x_1 \dots x_m$

Estimer les paramètres $a, b \rightarrow \hat{a}, \hat{b}$
 $\xi \rightarrow \hat{\xi}$

$$\hat{Y} = \hat{b} + \hat{a}x$$

Validité du modèle

$$Y_i = b + a_1 X_{1i} + a_2 X_{2i} + \xi_i$$

$$H_0 : a_i = 0 \forall i$$

H_1 : il existe au moins un $a_i \neq 0$.

1) Test sur R^2 :

$$\text{Si } F_{\text{calculé}} = \frac{n-m-1}{m} \times \frac{R^2}{1-R^2} > F_{\alpha, m, n-m-1}$$

On rejette H_0 : il existe au moins un $a_i \neq 0$ et on valide le modèle proposé.

2) Test des coef a_i ($H_0 : a_i = 0$, contre $a_i \neq 0$)

$$\frac{|\hat{a}_i|}{\sqrt{(\hat{a}_i)}} \leq t_{\alpha, n-m-1}$$

écart-type \rightarrow

alors \hat{a}_i est proche de 0.

Pour l'exercice 1:

Y_t : prix moyen d'un kg de banane

X_t : prix du ticket de métro

$t = 1, \dots, 9$

1975, ..., 1983


Modèle 1

$$X_t = at + b + \varepsilon_t \quad (m=1, n=9)$$

1) Nuage de points

(t, X_t)

$$\hat{X}_t = \hat{a}t + \hat{b}$$



\Rightarrow on peut approximer
par une droite; le
modèle semble bon

2) Test de validité du modèle (1)

$$\frac{\hat{a}}{\sqrt{V(\hat{a})}} = \frac{0,505}{0,032} = 15,78125$$

à comparer avec $t_{0,05,7} = 1,833$

\Rightarrow on rejette l'hypothèse $H_0: a=0$: le modèle
proposé est significatif (il semble bon).

3) L'erreur commise pour l'année 79 $\rightarrow t=5$

$$\varepsilon_t = X_t - (at + b)$$

On calcule une estimation de l'erreur

$$\hat{\varepsilon}_t = X_t - (\hat{a}t + \hat{b})$$

$$\begin{aligned}\hat{\epsilon}_t &= X_t - (S\hat{a} + \hat{b}) \\ &= 3,6 - (5 \times 0,505 + 1,364) \\ &= 0,289\end{aligned}$$

4) Pour l'année 1985 $\rightarrow t = 11$

$$\hat{X}_{11} = 11\hat{a} + \hat{b} = 11 \times 0,505 + 1,364 = 6,919 \approx 6,75$$

(5) Du point de vue mathématique c'est un modèle significatif.