

RÉGRESSION LINÉAIRE SIMPLE

1 Capitole.

Un particulier cherche à acquérir un appartement aux alentours immédiats de la place du Capitole. Il a sélectionné les 24 offres de vente suivantes où X représente la surface en mètres carrés et Y correspond au prix en milliers d'Euros

| | | | | | | | | | | | | |
|---|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|
| X | 28 | 50 | 196 | 55 | 190 | 110 | 60 | 48 | 90 | 35 | 86 | 65 |
| Y | 130 | 280 | 800 | 268 | 790 | 500 | 320 | 250 | 378 | 250 | 350 | 300 |

| | | | | | | | | | | | | |
|---|-----|-----|-----|-----|----|----|-----|-----|-----|-----|----|-----|
| X | 32 | 52 | 40 | 70 | 28 | 30 | 105 | 52 | 80 | 60 | 20 | 100 |
| Y | 155 | 245 | 200 | 325 | 85 | 78 | 375 | 200 | 270 | 295 | 85 | 495 |

- 1) Déterminer l'équation de la droite de régression linéaire de Y en X .
- 2) Proposer un intervalle de confiance à 95% pour la variance résiduelle σ^2 .
- 3) Tester la significativité de X .
- 4) Pour une nouvelle valeur $x^* = 100$, calculer la prédiction naturelle \hat{Y}^* de Y^* et trouver un intervalle de prévision à 95% pour Y^* .

2 Combinaison Linéaire.

On considère la régression linéaire simple identifiable

$$Y_i = a + bx_i + \varepsilon_i, \quad i = 1, 2, \dots, n$$

où (ε_i) est une suite de variables aléatoires indépendantes de loi $\mathcal{N}(0, \sigma^2)$.

- 1) Pour $a = 0$, donner l'estimateur des moindres carrés \hat{b} de b et déterminer sa loi.
- 2) Construire un test de l'hypothèse $a = 0$ contre $a \neq 0$ puis de $b = 0$ contre $b \neq 0$.
- 3) Soient $\alpha, \beta \in \mathbb{R}$ et $c \in \mathbb{R}$ donnés. Construire un test de l'hypothèse $\alpha a + \beta b = c$ contre $\alpha a + \beta b \neq c$.

3 Réduction de variance.

On considère la régression linéaire simple identifiable

$$Y_i = a + bx_i + \varepsilon_i, \quad i = 1, 2, \dots, n.$$

On va vérifier qu'ajouter une observation (Y_{n+1}, x_{n+1}) à la régression permet d'améliorer l'estimation des paramètres a et b . On pose

$$\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i \quad \text{et} \quad \overline{x_n^2} = \frac{1}{n} \sum_{i=1}^n x_i^2.$$

- 1) Si $v_n = \overline{x_n^2} - (\bar{x}_n)^2$, montrer la relation récursive

$$v_{n+1} = \frac{n}{(n+1)} v_n + \frac{n}{(n+1)^2} (x_{n+1} - \bar{x}_n)^2.$$

- 2) En déduire que $Var(\hat{a}_{n+1}) \leq Var(\hat{a}_n)$ et $Var(\hat{b}_{n+1}) \leq Var(\hat{b}_n)$ puis conclure à l'amélioration de l'estimation des paramètres a et b .

4 Moindres Carrés Pondérés.

On considère la régression linéaire simple identifiable

$$Y_i = a + bx_i + \varepsilon_i, \quad i = 1, 2, \dots, n$$

où (ε_i) est une suite de variables aléatoires centrées et non-corrélées avec $Var(\varepsilon_i) = \sigma^2 z_i^2$ où (z_i) est strictement positive connue.

- 1) Déterminer les estimateurs des moindres carrés pondérés \hat{a} et \hat{b} de a et b .
- 2) Montrer qu'ils sont des estimateurs sans biais et de variance minimale.
- 3) Proposer un estimateur sans biais $\hat{\sigma}^2$ de σ^2
- 4) Trouver les lois de \hat{a} , \hat{b} et $\hat{\sigma}^2$ dans le cadre gaussien.

5 Durbin-Watson.

On considère la régression linéaire gaussienne identifiable définie, pour $i = 1, 2, \dots, n$, par

$$\begin{cases} Y_i = a + bx_i + \varepsilon_i \\ \varepsilon_i = \rho \varepsilon_{i-1} + e_i \end{cases}$$

où $|\rho| < 1$ et (e_i) est une suite de variables aléatoires indépendantes de loi $\mathcal{N}(0, \sigma^2)$. Proposer une statistique permettant de tester la non-corrélation des résidus.