

# Régression linéaire multiple

## Exercice 1

On considère une modélisation linéaire simple  $Y_i = z_i \mathbf{a} + \mathbf{b} + \varepsilon_i$  où  $\varepsilon_i \sim \mathcal{N}(0, \sigma)$  pour  $n > 2$  observations des caractères  $z$  et  $y$ .

On choisit d'utiliser les outils de modélisation linéaire multiple et de modéliser le problème à l'aide du langage matricielle  $Y = \mathbf{x}\mathbf{m} + \varepsilon$ .

1. Donner les dimensions des matrices  $Y$ ,  $\mathbf{x}$ ,  $\mathbf{m}$  et  $\varepsilon$ .
2. Montrer que :

$$(a) \quad {}^t\mathbf{x}\mathbf{x} = \begin{pmatrix} n\bar{z}^2 & n\bar{z} \\ n\bar{z} & n \end{pmatrix}$$

$$(b) \quad {}^t\mathbf{x}\mathbf{y} = \begin{pmatrix} n\bar{z}\bar{y} \\ n\bar{y} \end{pmatrix}$$

3. On peut montrer que l'inverse de la matrice  $\mathbf{A} = \begin{pmatrix} \alpha & \beta \\ \gamma & \delta \end{pmatrix}$  est la matrice  $\frac{1}{\det(\mathbf{A})} \begin{pmatrix} \delta & -\beta \\ -\gamma & \alpha \end{pmatrix}$ .

(a) Montrer que  $\det({}^t\mathbf{x}\mathbf{x}) = n^2 \sigma_z^2$ .

(b) Montrer que  $({}^t\mathbf{x}\mathbf{x})^{-1} = \frac{1}{n\sigma_z^2} \begin{pmatrix} 1 & -\bar{z} \\ -\bar{z} & \bar{z}^2 \end{pmatrix}$ .

(c) En déduire la valeur de  $\hat{\mathbf{m}}$ .

(d) Comparez ces résultats avec les estimations de la modélisation linéaire simple.

4. (a) Donnez une estimation de la matrice de variance-covariance de l'estimateur de  $\mathbf{m}$ .

(b) En déduire les valeurs de  $\hat{\sigma}_a^2$  et  $\hat{\sigma}_b^2$ . Comparez vos résultats avec les variances de la modélisation linéaire simple.

(c) Donnez une estimation de  $\text{Cov}(\mathbf{A}_n, \mathbf{B}_n)$  où  $\mathbf{A}_n$  est l'estimateur de  $\mathbf{a}$  et  $\mathbf{B}_n$  l'estimateur de  $\mathbf{b}$ .

## Exercice 2

Le prof, ce petit malin, a demandé à python deux nombres de manière équiprobable, appelé  $x$  et  $y$ , parmi  $-1, 0$  et  $1$  puis a appliqué une petite formule  $z = \mathbf{a} + \mathbf{b}x + \mathbf{c}y + \varepsilon$  où  $\mathbf{a}, \mathbf{b}$  et  $\mathbf{c}$  sont des constantes et  $\varepsilon$  est la partie entière d'un tirage aléatoire d'une loi normale centrée de variance  $\sigma$ . Dans ce modèle il y a donc 4 inconnues :  $\mathbf{a}, \mathbf{b}, \mathbf{c}$  et  $\sigma$ . Le prof, ce petit malin, a réalisé cette expérience aléatoire cinq fois. Voici ce qu'il a obtenu.

x	y	z
0	0	2
0	-1	1
0	0	0
0	0	4
1	1	1

Le but du problème est d'estimer les 4 inconnues. On utilise le langage matricielle et on modélise le problème sous la forme  $Z = \mathbf{A}\mathbf{m} + \varepsilon$ .

1. Donner la matrice  $\mathbf{A}$  ainsi que  ${}^t\mathbf{A}\mathbf{A}$ .

2. La matrice  $\mathbf{B} = \begin{pmatrix} 1 & -2 & 1 \\ -2 & 10 & -5 \\ 1 & -5 & 4 \end{pmatrix}$  n'est pas la matrice inverse de  ${}^t\mathbf{A}\mathbf{A}$ . Cependant on peut démontrer qu'il existe un réel  $\lambda$  tel que  $({}^t\mathbf{A}\mathbf{A})^{-1} = \lambda\mathbf{B}$ .

(a) Déterminer la valeur de  $\lambda$ .

(b) En déduire  $\hat{\mathbf{m}}$  l'estimation ponctuelle de  $\mathbf{m}$ .

3. Quelle opération matricielle permet d'obtenir les valeurs de  $\hat{z}_i$ ? Réalisez cette opération.
4. Donner une estimation de  $\sigma$ .

5. On note  $\vec{X}$  le vecteur aléatoire en dimension 3 de coordonnées  $A_n$ ,  $B_n$  et  $C_n$  les estimateurs des paramètres  $\mathbf{a}$ ,  $\mathbf{b}$  et  $\mathbf{c}$ .
- (a) Donnez  $\mathbb{V}(\vec{X})$  la matrice de variance-covariance de  $\vec{X}$ .
  - (b) En déduire  $\mathbb{V}(B_n)$  et  $\text{Cov}(A_n, C_n)$ .
6. Question de mémoire :
- (a) Déterminer le  $R^2$  de ce modèle.
  - (b) Donnez l'intervalle de confiance symétrique de niveau 95% de  $B_n$  ainsi que l'estimation de cet intervalle.