

Feuille d'exercices sur le modèle linéaire

1 Cuatro Cuaranta

Soit n_1 et n_2 deux entiers strictement positifs fixés et $n = 2p > 2 \max(n_1, n_2)$. On considère pour $j = 1 \dots n$, le modèle de régression périodique :

$$Y_j = a_0 + a_1 \cos(2\pi n_1 \frac{j}{n}) + a_2 \cos(2\pi n_2 \frac{j}{n}) + b_1 \sin(2\pi n_1 \frac{j}{n}) + b_2 \sin(2\pi n_2 \frac{j}{n}) + \varepsilon_j.$$

a) Montrer ou admettre pour $i, i' = 1, 2$, les relations suivantes :

$$\begin{aligned} \sum_{j=1}^n \cos(2\pi n_i \frac{j}{n}) \cos(2\pi n_{i'} \frac{j}{n}) &= 0 \quad \text{si } i \neq i' \\ &= p \quad \text{si } i = i' \end{aligned}$$

$$\begin{aligned} \sum_{j=1}^n \sin(2\pi n_i \frac{j}{n}) \sin(2\pi n_{i'} \frac{j}{n}) &= 0 \quad \text{si } i \neq i' \\ &= p \quad \text{si } i = i' \end{aligned}$$

$$\sum_{j=1}^n \cos(2\pi n_i \frac{j}{n}) = \sum_{j=1}^n \sin(2\pi n_i \frac{j}{n}) = \sum_{j=1}^n \cos(2\pi n_i \frac{j}{n}) \sin(2\pi n_{i'} \frac{j}{n}) = 0.$$

b) Montrer que les estimateurs (du maximum de vraisemblance) des paramètres sont :

$$\hat{a}_0 = \frac{1}{n} \sum_{j=1}^n Y_j$$

$$\hat{a}_i = \frac{1}{p} \sum_{j=1}^n Y_j \cos(2\pi n_i \frac{j}{n}), \quad i = 1, 2$$

$$\hat{b}_i = \frac{1}{p} \sum_{j=1}^n Y_j \sin(2\pi n_i \frac{j}{n}), \quad i = 1, 2$$

$$S^2 = \frac{1}{2p-5} \sum_{j=1}^n \left[Y_j - \left(\hat{a}_0 + \hat{a}_1 \cos(2\pi n_1 \frac{j}{n}) + \hat{a}_2 \cos(2\pi n_2 \frac{j}{n}) + \hat{b}_1 \sin(2\pi n_1 \frac{j}{n}) + \hat{b}_2 \sin(2\pi n_2 \frac{j}{n}) \right) \right]^2$$

c) Construire le test d'hypothèse de $a_1 = a_2 = b_1 = b_2 = 0$, puis celui de $a_1 = b_1 = 0$.

d) Application numérique pour le second test de la question précédente. Cas de la note LA , $n_2 = 440$, $n = 1000$. Tester si la note est un LA pur (c'est-à-dire $a_1 = b_1 = 0$) avec $S_{\text{obs}}^2 = 1,5$, $\hat{a}_1^{\text{obs}} = 0,52$, $\hat{b}_1^{\text{obs}} = 0,98$

On considère le modèle de régression multiple :

$$Y_j = a + bx_j + cz_j + \epsilon_j, \quad j = 1 \dots 4n.$$

Où :

- a, b, c sont des paramètres inconnus.

- $\epsilon = \begin{pmatrix} \epsilon_1 \\ \vdots \\ \epsilon_{4n} \end{pmatrix} \sim \mathcal{N}_{4n}(0, \sigma^2 I_{4n})$, la variance σ^2 est inconnue.

- $x_{4j-3} = -1, x_{4j-2} = 1, x_{4j-1} = -1, x_{4j} = 1, z_{4j-3} = 1, z_{4j-2} = 1, z_{4j-1} = -1, z_{4j} = -1,$
 $(j = 1, \dots, n).$

a) Estimer les paramètres a, b, c, σ^2 . Dans la suite on note S^2 l'estimateur de σ^2 .

b) Tester l'hypothèse $a = 0$. Application numérique : $n = 50, S_{\text{obs}}^2 = 2.0, \bar{Y}_{\text{obs}} = 0.17$.

c) Tester l'hypothèse $b = c$.

d) Quelle est la loi de

$$\frac{1}{4n\sigma^2} \left[\left(\sum_{j=1}^{4n} x_j \epsilon_j \right)^2 + \left(\sum_{j=1}^{4n} z_j \epsilon_j \right)^2 \right] ?$$

3 Régression (Bis)

On considère les modèles de régression :

$$Y_i = \alpha x_i + \varepsilon_i, \quad i = 1, \dots, n$$

$$Z_i = \beta w_i + \varepsilon'_i, \quad i = 1, \dots, n.$$

$\varepsilon_1, \dots, \varepsilon_n, \varepsilon'_1, \dots, \varepsilon'_n$ sont des suites i.i.d. indépendantes de loi $\mathcal{N}(0, \sigma^2)$, $\sigma > 0$.

a) Sous quelle condition sur $(x_i)_{i=1 \dots n}$ et $(w_i)_{i=1 \dots n}$ les paramètres α et β sont-ils estimables ?

On supposera dans la suite que cette condition est vérifiée.

b) Estimer les paramètres α, β et σ^2 .

c) Tester $\alpha = \beta$.

d) On suppose que α a pour loi a priori, la loi $\mathcal{N}(0, \tau^2)$, $\tau > 0$. Calculer, l'estimateur bayésien de α .

e) On suppose que β a pour loi a priori, la loi de Bernoulli de paramètre 0.5. Que signifie cette hypothèse ? Calculer, l'estimateur bayésien de α .

4 Régression périodique

On considère, pour $N \geq 1$, le modèle de régression :

$$Y_j = ax_j + b \cos x_j + \epsilon_j, \quad j = -N \dots N.$$

Où :

- a, b sont des paramètres inconnus.

- $\epsilon = \begin{pmatrix} \epsilon_{-N} \\ \vdots \\ \epsilon_N \end{pmatrix} \sim \mathcal{N}_{2N+1}(0, \sigma^2 I_{2N+1})$, la variance σ^2 est inconnue.

- $x_j = \frac{j\pi}{N}$, $(j = -N, \dots, N)$.

$$\sum_{j=1}^N j^2 = \frac{N(N+1)(2N+1)}{6}$$

$$\sum_{j=-N}^{N-1} \cos^2(x_j) = N$$

- b) Estimer les paramètres a, b, σ^2 . Dans la suite on note S^2 l'estimateur de σ^2 .
 c) Tester l'hypothèse $a = 0$.
 d) Tester l'hypothèse $b = 0$.

5 Régression polynômiale

Soient p et n deux entiers tels que $0 \leq p < n$. Pour tout $1 \leq j \leq n$ on pose $x_j = j - \frac{n+1}{2}$. On considère $\psi_0, \psi_1, \dots, \psi_p$ polynômes fixés tels que :

- $\text{degré}(\psi_i) = i, \forall 0 \leq i \leq p$
- $\sum_{j=1}^n \psi_i(x_j)\psi_k(x_j) = 0, \forall 0 \leq i \neq k \leq p$

On a en vue d'étudier le modèle de régression

$$Y_j = \sum_{i=0}^p \lambda_i \psi_i(x_j) + \varepsilon_j, \quad 1 \leq j \leq n$$

où $\varepsilon_1, \dots, \varepsilon_n$ sont indépendantes et de même loi $\mathcal{N}(0, \sigma^2)$ et $\lambda_0, \dots, \lambda_p, \sigma^2$ sont des paramètres inconnus.

- a) Estimer les paramètres de ce modèle.
 b) Ecrire un test de niveau α de " $\lambda_p = 0$ " contre " $\lambda_p \neq 0$ ".

Le revenu net par action de la compagnie Gillette pour les années 57 à 64 est le suivant :

Année (z_j)	:	1957	1958	1959	1960	1961	1962	1963	1964
Revenu en \$ ($Y_j(\omega)$)	:	0,93	0,99	1,11	1,33	1,52	1,60	1,47	1,33

On pose $x_j = z_j - 1960,5$ puis $\psi_0(x) = 1, \psi_1(x) = 2x$ et $\psi_2(x) = x^2 - 21/4$.

c) Vérifier brièvement que le choix ci-dessus de $x_j, \psi_0, \psi_1, \psi_2$ rentre dans le cadre décrit plus haut.

d) En supposant que $Y_j = \sum_{i=0}^2 \lambda_i \psi_i(x_j) + \varepsilon_j, \quad 1 \leq j \leq 8$ avec $\varepsilon_1, \dots, \varepsilon_8$ indépendantes et de même loi $\mathcal{N}(0, \sigma^2)$, estimer $\lambda_0, \lambda_1, \lambda_2$ et σ^2 . Tester si $\lambda_2 = 0$.

e) Faire une prévision pour le revenu net par action en 1965.

N.B. Pour faciliter les calculs, on indique les valeurs numériques suivantes :

$$\sum_j \psi_1^2(x_j) = \sum_j \psi_2^2(x_j) = 168 \quad \sum_j Y_j^2(\omega) = 13,65 \quad \sum_j \psi_0(x_j)Y_j(\omega) = 10,28$$

$$\sum_j \psi_1(x_j)Y_j(\omega) = 6,86 \quad \sum_j \psi_2(x_j)Y_j(\omega) = -4,1.$$

6 Degré 3

Pour les données ci-dessous, ajuster le modèle :

$$Y = \beta_0 + \beta_1 X + \beta_2 X^2 + \beta_3 X^3 + \epsilon.$$

Tester l'hypothèse $\beta_2 = \beta_3$.

X	-5	-3	-1	1	3	5
Y	13	4	3	4	10	22

Soit p un entier naturel strictement positif, on considère le modèle linéaire

$$Y_{ij} = a_i x_{ij} + b_i + \varepsilon_{ij}, \quad i = 1, 2, \quad j = 1 \dots 2p,$$

où

- ε_{ij} , $i = 1, 2$, $j = 1 \dots 2p$, sont des variables i.i.d., gaussiennes de variance σ^2 .
 - $x_{ij} = (-1)^{i+j}$, $i = 1, 2$, $j = 1 \dots 2p$.
 - Les paramètres a_i , b_i $i = 1, 2$ et σ^2 sont inconnus.
- a) Calculer les estimateurs du maximum de vraisemblance des paramètres.
 - b) Déterminer une région de confiance pour le couple de coefficients directeurs (a_1, a_2) . Pour $p = 50$, on suppose que l'on a observé $S^{2\text{obs}} = 0.9$ (S^2 est l'estimateur du maximum de vraisemblance de σ^2), et $(\sum_{j=1}^{2p} x_{1j} Y_{1j})^{\text{obs}} = 2.5$ $(\sum_{j=1}^{2p} x_{2j} Y_{2j})^{\text{obs}} = 1.4$. Tracer, pour ces observations, la région de confiance obtenue dans le plan (a_1, a_2) .
 - c) Tester l'égalité des coefficients directeurs $a_1 = a_2$.
Application numérique : reprendre les valeurs numériques données à la question précédente.
 - d) Tester l'égalité des ordonnées à l'origine $b_1 = b_2$.
Application numérique : on reprend les valeurs de p et de S^2 de la question b) et l'on suppose que $Y_1^{\text{obs}} = (1/(2p) \sum_{j=1}^{2p} Y_{1j})^{\text{obs}} = 5.3$ $Y_2^{\text{obs}} = (1/(2p) \sum_{j=1}^{2p} Y_{2j})^{\text{obs}} = 4.95$.
 - e) On suppose que $a_1 = a_2 = a$ et $b_1 = b_2 = 0$. Calculer l'estimateur de Bayes de a , si la loi a priori est la loi $\mathcal{N}(m, \xi^2)$ ($m \in \mathbb{R}, \xi > 0$).

8 Modèle linéaire et test d'hypothèses non linéaires

Soit ε_{ij} , $i = 1, \dots, k$ $j = 1 \dots n$, des variables i.i.d., de loi normale centrée réduite. Soit $m_1, \dots, m_k \in \mathbb{R}$, on pose $Y_{ij} = m_i + \varepsilon_{ij}$ $i = 1, \dots, k$ $j = 1 \dots n$.

- a) Quels sont les estimateurs du maximum de vraisemblance \hat{m}_i de m_i ($i = 1, \dots, k$) ?
- b) On se propose maintenant de construire une statistique de test pour les hypothèses non linéaires :

$$H_0 \quad \sum_{i=1}^k m_i^2 = 1 \quad H_1 \quad \sum_{i=1}^k m_i^2 \neq 1.$$

Pour cela, on se propose d'utiliser la statistique de test

$$T_n = \sqrt{n} \left(\sum_{i=1}^k \hat{m}_i^2 - 1 \right).$$

Montrer que T_n peut s'écrire sous la forme suivante

$$T_n = \frac{1}{\sqrt{n}} \sum_{i=1}^k (\xi_i^n)^2 + 2 \sum_{i=1}^k (\xi_i^n) m_i + \sqrt{n} \left(\sum_{i=1}^k m_i^2 - 1 \right),$$

- o $(\xi_i^n)_{i=1 \dots k}$ sont i.i.d. de loi $\mathcal{N}(0, 1)$.
- c) On suppose que H_0 est vérifiée. Montrer que $\frac{1}{\sqrt{n}} \sum_{i=1}^k (\xi_i^n)^2$ converge en probabilité vers 0. En déduire que T_n converge en loi. Préciser la loi limite.
 - d) On suppose que H_1 est vérifiée. En utilisant la question précédente, montrer que presque sûrement $\lim_{n \rightarrow \infty} |T_n| = +\infty$.
 - e) Déduire des questions précédentes une procédure de test pour décider entre H_0 et H_1 .