

## TD DE MODÈLES LINÉAIRES I - SÉRIE 7

**Exercice 1.** Nous estimons le paramètre vectoriel  $\theta_1 \in \mathbb{R}^{p_1}$  du modèle de régression linéaire approché :

$$Y = W\theta_1 + U$$

où  $\mathbb{E}_\theta(U) = 0_n$  et  $Var_\theta(U) = \sigma^2 I_n$ , alors que le vrai modèle est

$$Y = W\theta_1 + Z\theta_2 + V$$

où  $\mathbb{E}_\theta(V) = 0_n$ ,  $Var_\theta(V) = \sigma^2 I_n$ ,  $\theta_2 \in \mathbb{R}^{p_2}$ , et  $X = (W, Z) \in \mathcal{M}(n, p)$  avec  $p = p_1 + p_2$ . Nous supposons que la matrice  $X$  est de rang  $p$ .

1) Calculer  $\mathbb{E}_\theta(\tilde{\theta}_1)$  où  $\tilde{\theta}_1$  est l'estimateur MCO du paramètre  $\theta_1$  du modèle approché.

Nous pouvons considérer que l'estimation dans le modèle approché revient à estimer le vrai modèle sous contraintes.

2) Ecrire le modèle sous contraintes.

3) Nous étudions ici le cas d'un modèle  $Y = X\theta + \xi$  sous la contrainte  $G\theta = b$  avec  $\mathbb{E}_\theta(\xi) = 0_n$  et  $Var_\theta(\xi) = \sigma^2 I_n$ ,  $G \in \mathcal{M}(r, p)$  et  $G$  de rang  $r$ .

a) Notons  $\hat{\theta}$  l'estimateur MCO de  $\theta$  sans considérer la contrainte et  $\hat{\theta}^0$  l'estimateur MCO de  $\theta$  en considérant la contrainte. Montrer que :

$$\hat{\theta}^0 = \hat{\theta} + (X'X)^{-1}G'[G(X'X)^{-1}G']^{-1}(b - G\hat{\theta}).$$

b) Calculer  $\mathbb{E}_\theta(\hat{\theta}^0)$ .

c) Montrer que

$$Var_\theta(\hat{\theta}^0) = \sigma^2 [(X'X)^{-1} - (X'X)^{-1}G'[G(X'X)^{-1}G']^{-1}G(X'X)^{-1}].$$

d) Comparer  $Var_\theta(\hat{\theta}^0)$  et  $Var_\theta(\hat{\theta})$ .

4) Interpréter le résultat précédent dans le cas d'omission de variables..

**Exercice 2** Considérons le modèle

$$X_{ij} = \mu + \alpha_i + \varepsilon_{ij}, 1 \leq i \leq I, 1 \leq j \leq n_i,$$

où les  $\varepsilon_{ij}$  sont indépendantes de loi  $\mathcal{N}(0, \sigma^2)$  et  $\sum_{i=1}^I n_i \alpha_i = 0$ .

1) Montrer que  $X = A\theta + \varepsilon$ , où  $A = [1A_1 \dots A_I]$  avec  $1, A_1, \dots, A_I$ , éléments de  $\mathbb{R}^{IJ}$  que l'on précisera.

2) Soit  $F_0 = \{\mu 1, \mu \in \mathbb{R}\}$ ,  $F_1 = \left\{ \sum_{i=1}^I \alpha_i A_i, \alpha_i \in \mathbb{R}, \sum_{i=1}^I n_i \alpha_i = 0 \right\}$ .

Montrer que  $F_0$  et  $F_1$  sont des sous-espaces vectoriels deux-à-deux orthogonaux. En déduire qu'il existe un espace  $G$  tel que

$$\mathbb{R}^{IJ} = F_0 \oplus F_1 \oplus G.$$

3) Calculer  $P_0, P_0 + P_1$  ( $P_0$  étant la projection orthogonale sur  $F_0$ ). En déduire  $P_1$ . Calculer  $P_G$ .

4) Construire la table d'analyse de la variance.

5) Tester l'hypothèse  $H_0$ : "tous les  $\alpha_i$  sont nuls" contre  $H_1$ : "tous les  $\alpha_i$  ne sont pas nuls".

**Application.** Les mesures de teneur en octane sur des échantillons de carburant prélevés dans quatre régions du nord-est des États Unis durant l'été 1953, sont reproduites dans le tableau ci-après.

Notant  $X_{ij}$  la jème mesure effectuée dans la région  $i$ , on donne les quantités suivantes :

| Région                          | A      | B      | C     | D      |
|---------------------------------|--------|--------|-------|--------|
| $n_i$                           | 16     | 13     | 18    | 22     |
| $\bar{X}_i$                     | 83.875 | 82.846 | 83.22 | 83.009 |
| $\sum_j (X_{ij} - \bar{X}_i)^2$ | 17.81  | 2.67   | 28.97 | 33.04  |

Peut-on conclure que la teneur en octane est différente suivant les régions?

| Région A | Région B | Région C | Région D |
|----------|----------|----------|----------|
| 84.0     | 82.4     | 83.2     | 80.2     |
| 83.5     | 82.4     | 82.8     | 82.9     |
| 84.0     | 83.4     | 83.4     | 84.6     |
| 85.0     | 83.3     | 80.2     | 84.2     |
| 83.1     | 83.1     | 82.7     | 82.8     |
| 83.5     | 83.3     | 83.0     | 83.0     |
| 81.7     | 82.4     | 85.0     | 82.9     |
| 85.4     | 83.3     | 83.0     | 83.4     |
| 84.1     | 82.6     | 85.0     | 83.1     |
| 83.0     | 82.0     | 83.7     | 83.5     |
| 85.8     | 83.2     | 83.6     | 83.6     |
| 84.0     | 83.1     | 83.3     | 86.7     |
| 84.2     | 82.5     | 83.8     | 82.6     |
| 82.2     |          | 85.1     | 82.4     |
| 83.6     |          | 83.1     | 83.4     |
| 84.9     |          | 84.2     | 82.7     |
|          |          | 80.6     | 82.9     |
|          |          | 82.3     | 83.7     |
|          |          |          | 81.5     |
|          |          |          | 81.9     |
|          |          |          | 81.7     |
|          |          |          | 82.5     |

Data from O.C. Blade "National motor-gasoline survey" Bureau of Mines Report of Investigation 5041.

**Exercice 3.** On considère une expérience dont le résultat est un tableau  $\{X_{ij}, 1 \leq i, j \leq 2\}$  composé de 4 variables indépendantes de même variance. On adopte le modèle  $X_{ij} \sim \mathcal{N}(\mu + \alpha_i - \alpha_j, \sigma^2), 1 \leq i, j \leq 2$ , où  $\alpha_1 + \alpha_2 = 0$ .

- 1) Déterminer les ESBVM de  $\mu, \alpha_1$  et  $\alpha_2$ .
- 2) Tester l'hypothèse  $\mu = 0$  au seuil  $\alpha$ .
- 3) A.N.  $\alpha = 0.05, X_{11} = 4, X_{12} = 1, X_{21} = -3, X_{22} = 2$ .