

# Modèle de régression linéaire - Feuille 4

## Projections

**EXERCICE 1** Soit  $X$  de loi  $\mathcal{N}(0, I_n)$  et  $\delta$  un vecteur fixé de  $\mathbb{R}^n$ . On définit la variable aléatoire réelle  $Y$  par

$$Y = \|X + \delta\|^2 = \sum_{i=1}^n (X_i + \delta_i)^2.$$

On dit que  $Y$  suit un  $\chi^2(n, \|\delta\|^2)$ . Supposons  $\delta \neq 0$ . Calculer l'espérance et la variance de  $Y$ .

**EXERCICE 2** Soit  $X$  de loi  $\mathcal{N}(0, I_n)$ . Soit  $P$  une projection orthogonale de rang  $r$ . Montrer que  $X'PX$  suit un  $\chi^2_r$ .

**EXERCICE 3** Soit  $Z$  une matrice de taille  $n \times q$  de rang  $q$  et soit  $X$  une matrice  $n \times p$  de rang  $p$  composée des  $q$  vecteurs colonne de  $Z$  et de  $p - q$  autres vecteurs linéairement indépendants. Nous considérons les deux modèles suivants

$$\begin{aligned} Y &= Z\beta + \varepsilon \\ Y &= X\beta^* + \eta \end{aligned}$$

Supposons pour simplifier que la constante ne fait partie d'aucun modèle. Notons respectivement  $P_X$  et  $P_Z$  les projections orthogonales sur les sous-espaces  $\mathcal{M}(X)$  et  $\mathcal{M}(Z)$  engendrés par les  $p$  colonnes de  $X$  et les  $q$  colonnes de  $Z$ . Notons enfin  $P_{X \cap Z^\perp}$  la projection orthogonale sur  $\mathcal{M}(X) \cap \mathcal{M}(Z)^\perp$ , orthogonal de  $\mathcal{M}(Z)$  dans  $\mathcal{M}(X)$ , soit

$$\mathbb{R}^n = \mathcal{M}(X) \overset{\perp}{\oplus} \mathcal{M}(X)^\perp = \left( \mathcal{M}(Z) \overset{\perp}{\oplus} (\mathcal{M}(X) \cap \mathcal{M}(Z)^\perp) \right) \overset{\perp}{\oplus} \mathcal{M}(X)^\perp.$$

1. Exprimer  $\|P_X Y\|^2$  en fonction de  $\|P_Z Y\|^2$  et  $\|P_{X \cap Z^\perp} Y\|^2$ .
2. Comparer alors les coefficients de détermination des deux modèles, soit  $R_Z^2$  et  $R_X^2$ .
3. De façon générale, qu'en déduire quant à l'utilisation du  $R^2$  pour le choix de variables ?

**EXERCICE 4** Deux variables explicatives

On examine l'évolution d'une variable réponse  $y_i$  en fonction de deux variables explicatives  $x_i$  et  $z_i$ . Soit  $X = (\mathbf{1} \ x \ z)$  la matrice  $n \times 3$  du plan d'expérience.

1. Nous avons obtenu :

$$X'X = \begin{bmatrix} 25 & 0 & 0 \\ ? & 9.3 & 5.4 \\ ? & ? & 12.7 \end{bmatrix}, \quad (X'X)^{-1} = \begin{bmatrix} 0.04 & 0 & 0 \\ 0 & 0.1428 & -0.0607 \\ 0 & -0.0607 & 0.1046 \end{bmatrix}$$

- (a) Donner les valeurs manquantes.
- (b) Que vaut  $n$  ?
- (c) Calculer le coefficient de corrélation empirique entre  $x$  et  $z$ .
2. La régression linéaire de  $Y$  sur  $(\mathbf{1}, x, z)$  donne :

$$Y = -1.61\mathbf{1} + 0.61x + 0.46z + \hat{\varepsilon}, \quad SCR = \|\hat{\varepsilon}\|^2 = 0.3$$

Déterminer la moyenne empirique  $\bar{y}$ . Calculer la somme des carrés expliquée et totalement, ainsi que  $R^2$ ,  $R_a^2$ .

**EXERCICE 5** (Régression sur variables centrées) Nous considérons le modèle de régression linéaire

$$Y = X\beta + \varepsilon, \quad (1)$$

où  $Y \in \mathbb{N}^n$ ,  $X$  est une matrice de taille  $n \times p$  de rang  $p$ ,  $\beta \in \mathbb{N}^p$  et  $\varepsilon \in \mathbb{N}^n$ . La première colonne de  $X$  est le vecteur constant  $\mathbf{1}$ .  $X$  peut donc s'écrire  $X = [\mathbf{1}, Z]$  où  $Z = [X_2, \dots, X_p]$  est la matrice  $n \times (p-1)$  des  $(p-1)$  derniers vecteurs colonnes de  $X$ . Le modèle peut donc s'écrire sous la forme :

$$Y = \beta_1 \mathbf{1} + Z\beta_{(1)} + \varepsilon,$$

où  $\beta_1$  est la première coordonnée du vecteur  $\beta$  et  $\beta_{(1)}$  représente  $\beta$  privé de sa première coordonnée.

1. Donner  $P_{\mathbf{1}}$ , matrice de projection orthogonale sur le sous-espace engendré par le vecteur  $\mathbf{1}$ .
2. En déduire la matrice de projection orthogonale  $P_{\mathbf{1}^\perp}$  sur le sous-espace  $\mathbf{1}^\perp$  orthogonal au vecteur  $\mathbf{1}$ .
3. Calculer  $P_{\mathbf{1}^\perp} Z$ .
4. En déduire que l'estimateur de  $\beta$  des Moindres Carrés Ordinaires du modèle (1) peut être obtenu en minimisant par les MCO le modèle suivant :

$$\tilde{Y} = \tilde{Z}\beta_{(1)} + \eta, \quad (2)$$

où  $\tilde{Y} = P_{\mathbf{1}^\perp} Y$  et  $\tilde{Z} = P_{\mathbf{1}^\perp} Z$ .

5. Ecrire la *SCR* estimée dans le modèle (2) en fonction des variables du modèle (2). Vérifier que la *SCR* du modèle (2) est identique à celle qui serait obtenue par l'estimation du modèle (1).

**EXERCICE 6** Soit  $(Y_i)_{1 \leq i \leq n}$  une famille de variables aléatoires définie par :

$$Y_i = \theta_0 + \sum_{k=1}^p \theta_k Z_i^{(k)} + \varepsilon_i \quad \text{pour tout } i \in \{1, \dots, n\}, \quad \text{où :} \quad (3)$$

- $\theta = {}^t(\theta_0, \theta_1, \dots, \theta_p)$  est un vecteur composé de  $p+1$  réels inconnus.
- pour  $1 \leq j \leq p$ , les  $(Z_i^{(j)})_{1 \leq i \leq n}$  sont  $p$  familles de réels connues.

On note  $X = \begin{pmatrix} 1 & Z_1^{(1)} & \dots & Z_1^{(p)} \\ \vdots & \vdots & & \vdots \\ 1 & Z_n^{(1)} & \dots & Z_n^{(p)} \end{pmatrix}$  et on suppose que son rang est  $p+1$  avec  $p+1 \leq n+1$ .

- la suite  $(\varepsilon_i)_i$  est une suite de v.a.i.i.d. de loi **gaussienne** centrée de variance  $\sigma^2 > 0$ .
- 1. On note  $Y = (Y_i)_{1 \leq i \leq n}$  et  $\varepsilon = (\varepsilon_i)_{1 \leq i \leq n}$ . Ecrire le modèle (3) sous une forme matricielle, en précisant la loi du vecteur d'erreur  $\varepsilon$ .
- 2. Rappeler l'expression de l'estimateur  $\hat{\theta}$  de  $\theta$  par moindres carrés en fonction de  $X$  et  $Y$ . On note  $\hat{Y} = X \hat{\theta}$ . On mesure la qualité de la prédiction par cet estimateur avec le risque quadratique  $R(\hat{Y}) = \mathbb{E}(\|\hat{Y} - X \theta\|^2)$ , où  $\|\cdot\|$  désigne la norme euclidienne classique. Déterminer  $R(\hat{Y})$  (en justifiant).
- 3. A partir du modèle (3), on veut tester l'hypothèse  $H_0 : \theta_i = 0$  pour tout  $i = p-p_0, \dots, p$ , où  $p_0 \in \mathbb{N}^*$ , contre l'hypothèse  $H_1$ , son complément. On note  $\hat{\sigma}^2 = \frac{1}{n-(p+1)} \|Y - \hat{Y}\|^2$ . Déterminer sous  $H_0$  la loi de  $\hat{\sigma}^2$ .
- 4. On note  $X^0$  la matrice extraite de  $X$  contenant uniquement ses  $p-p_0+1$  premières colonnes et  $\hat{Y}^0 = X^0 \hat{\theta}^0$ , où  $\hat{\theta}^0$  est obtenu par régression par moindres carrés sur les  $p-p_0$  premières variables. On définit :

$$\hat{F} = \frac{\frac{1}{p_0} \|\hat{Y} - \hat{Y}^0\|^2}{\hat{\sigma}^2}.$$

Montrer que sous  $H_0$ ,  $\|\widehat{Y} - \widehat{Y}^0\|^2 = \|P_A \varepsilon\|^2$  où  $A$  est un sous-espace vectoriel de  $\mathbb{N}^n$  de dimension  $p_0$  que l'on précisera et  $P_A$  est la matrice de la projection orthogonale sur  $A$ . En déduire la loi du numérateur de  $\widehat{F}$ .

Montrer que  $\widehat{F}$  suit une loi de Fisher à  $(p_0, n - p - 1)$  degrés de liberté. Quelle règle de décision s'en déduit pour décider de  $H_0$  avec un risque de première espèce  $\alpha \in ]0, 1[$  ?

5. On suppose jusqu'à la fin du problème que  $\theta_i = 0$  pour tout  $i = p - p_0, \dots, p$ . Déterminer alors  $R(\widehat{Y})$  et  $R(\widehat{Y}^0)$ . Quel estimateur vaut-il mieux choisir entre  $\widehat{\theta}$  et  $\widehat{\theta}^0$  ?
6. Pour estimer  $\sigma^2$ , on utilise les estimateurs par moindres carrés non biaisés  $\widehat{\sigma}^2$  et  $\widehat{\sigma}_0^2$  construits respectivement à partir de  $\widehat{\theta}$  et  $\widehat{\theta}^0$ .

Déterminer en justifiant la loi de  $\widehat{\sigma}_0^2$ .

Montrer que pour  $Z$  une variable de loi  $\mathcal{N}(0, 1)$ ,  $\text{Var}(Z) = 2$ .

Déterminer alors les risques quadratiques de  $\widehat{\sigma}^2$  et  $\widehat{\sigma}_0^2$ , soit  $\mathbb{E}[(\widehat{\sigma}^2 - \sigma^2)^2]$  et  $\mathbb{E}[(\widehat{\sigma}_0^2 - \sigma^2)^2]$ .

Quel estimateur de  $\sigma^2$  vaut-il mieux choisir entre les deux ?

7. Pour  $A$  et  $B$  deux sous-espaces vectoriels de  $\mathbb{N}^n$  tels que  $A \subset B$ , montrer que pour tout  $x \in \mathbb{N}^n$ ,  $\|P_A x\|^2 \leq \|P_B x\|^2$ . On note  $\widehat{R}^2$  et  $\widehat{R}_0^2$  les coefficients de détermination  $R^2$  respectifs pour les modèles avec  $\widehat{\theta}$  et avec  $\widehat{\theta}^0$ . Montrer que  $\widehat{R}^2 \geq \widehat{R}_0^2$  presque sûrement. Par rapport à ce critère, quel estimateur choisiriez-vous ?