

Exercice 1

$y = \log(\text{temps})$

$x_1 = \text{âge}, \dots, x_7 = \text{SCALC}$

1) Régression linéaire multiple :

$$(M1) \quad y_i = b_0 + b_1 x_{1i} + \dots + b_7 x_{7i} + \varepsilon_i, \quad \varepsilon_i \sim N(0, \sigma^2) \quad i.i.d. \quad i=1, \dots, n \quad n=65$$

2) Coefficients :  $b_0, b_1, \dots, b_7$  estimés par moindres carrés par maximum de vraisemblance.

3)  $H_0$ : (M1) non significatif  $\Leftrightarrow$  aucune var  $x_1, \dots, x_7$  n'influe sur  $y$

$$\Leftrightarrow b_1 = \dots = b_7 = 0$$

Modèle réduit :  $y_i = b_0 + \varepsilon_i$

$H_1$ : (M1) significatif  $\Leftrightarrow \exists j \in \{1, \dots, 7\}$  t. q.  $x_j$  influe sur  $y$

$$\Leftrightarrow \exists j \text{ t. q. } b_j \neq 0$$

Modèle complet : (M1)

Statistique de test :  $Z = \frac{SM/7}{SR/57} \underset{H_0}{\sim} F(7, 57)$

Valeur statistique de test :  $z = 3,939 \Rightarrow p\text{value} = 0,0014 < 0,05$

$\Rightarrow H_0$  rejetée avec un risque  $\alpha = 0,05$ .

4) On teste  $x_1$ : l'âge.

$H_0$ :  $x_1$  n'influe pas sur  $y | x_2, \dots, x_7$  dans le modèle

$$\Leftrightarrow b_1 = 0 | x_2, \dots, x_7 \text{ dans le modèle}$$

$$\Leftrightarrow \text{Modèle réduit : } y_i = b_0 + b_2 x_{2i} + \dots + b_7 x_{7i} + \varepsilon_i$$

$H_1$ :  $x_1$  influe sur  $y | x_2, \dots, x_7$  dans le modèle

$$\Leftrightarrow b_1 \neq 0 | \text{-----}$$

$\Leftrightarrow$  Modèle complet : (M1)

Statistique de test  $Z = \frac{\beta_1}{\sqrt{\text{Var}(\beta_1)}} \underset{H_0}{\sim} t(n-p-1) = t(57)$

$$p=7$$

Valeur de la stat de test :  $z = 0,321 \Rightarrow p\text{value} = 0,75 > 0,05$

$\Rightarrow$  l'âge n'influe pas sur  $y$  si  $x_2, \dots, x_7$  dans le modèle.

Les variables significatives :  $x_2$

(2)

les variables:  $x_1, x_4, x_5, x_6, x_7$  non signif.  $\Rightarrow$  à enlever.

La var  $x_3$  a une pvalue = 0,09, on va la garder quand même dans le modèle, pour une étude plus poussée.

5)  $\hat{b}_0 = 6,80 \Rightarrow$  c'est la valeur prévue pour  $y$  si  $x_1 = x_2 = \dots = x_7 = 0$

$\hat{b}_1 = 0,004 \Rightarrow$  avec chaque année de plus la valeur de  $y$  augmente de 0,004

$\hat{b}_2 = -1,487 \Rightarrow$  si  $x_2$  diminue alors  $y$  augmente alors  $y$

:

$\hat{b}_7 = -0,09$

$\hat{\sigma} = 0,93$

6)  $R^2_{\text{adj}} = 0,24 \Rightarrow$  (M1) de qualité médiocre.

7)  $\hat{y}_i = \hat{b}_0 + \hat{b}_1 x_{1i} + \dots + \hat{b}_7 x_{7i}$  la prévision de  $y_i$

Le résidus correspondant:  $e_i = y_i - \hat{y}_i$

Pour tester la normalité on utilise le test de Shapiro.

$H_0: e_i \sim N$        $H_1: e_i \not\sim N$

Valeur stat de test:  $w = 0,978$ ,  $p\text{value} = 0,31 > 0,05$   
 $\Rightarrow H_0$  acceptée, donc  $e_i \sim N$   $i=1, \dots, n$ .

Donc, on a eu raison de considérer comme méthode d'estimation celle des moindres carrés.

8) (M2)  $y_i = b_0 + b_2 x_{2i} + b_3 x_{3i} + \varepsilon_i \quad i=1, \dots, n$   
 $\varepsilon_i \sim N(0, \sigma^2)$  i.i.d.

9) Modèle (M2) significatif avec seulement la var  $x_2$  significative. La var  $x_3$  a une pvalue associée 0,13 donc elle n'influe pas sur  $y$  si  $x_2$  dans le modèle.

$\hat{\sigma} = 0,939$  à peu près pareil que pour (M1).

$R^2_{\text{adj}} = 0,23$  pareil que pour (M1).

10) Les modèles (M3) et (M4) sont identiques :

$$(M3), (M4) \quad y_i = b_1 x_{1i} + \dots + b_7 x_{7i} + \varepsilon_i, \quad \varepsilon_i \sim N(0, \sigma^2) \text{ i.i.d.} \quad i=1, \dots, n$$

Les coef de (M3) sont estimés par moindres carrés.

11) Les coef de (M3) sont estimés par la méthode LASSO adaptative :

$$(\hat{b}_{1n}, \dots, \hat{b}_{7n})_{\text{LASSO}} = \arg \min_{(b_1, \dots, b_7) \in \mathbb{R}^7} \left( \sum_{i=1}^n (y_i - b_1 x_{1i} - \dots - b_7 x_{7i})^2 + \lambda \sum_{j=1}^7 |\beta_j| \right)$$

$$\text{avec } \lambda_n \rightarrow 0, \quad \lambda_n = n^{-\frac{3}{5} + 1}$$

$$\hat{\omega}_j = \frac{1}{|\hat{b}_{jn}|^\gamma}, \quad \gamma = \frac{2}{5}, \quad \hat{b}_j^{\text{LS}} \text{ estim par moindres carrés.}$$

$$(\hat{b}_{1n}^{\text{LS}}, \dots, \hat{b}_{7n}^{\text{LS}}) = \arg \min_{b_1, \dots, b_7 \in \mathbb{R}^7} \sum_{i=1}^n (y_i - b_1 x_{1i} - \dots - b_7 x_{7i})^2.$$

12) Les valeurs de  $\hat{b}_{1n}^{\text{LS}}, \dots, \hat{b}_{7n}^{\text{LS}}$  ne sont égales à 0.

$$\begin{cases} \hat{b}_{jn}^{\text{LASSO}} = 0 & \forall j \in \{1, 2, 3, 5, 6, 7\} \\ \hat{b}_{4n}^{\text{LASSO}} \neq 0 \end{cases}$$

13)  $A1 = \{4\}$  contient l'indice  $j$  de la var  $x_j$  qui a des estimations non nulles pour son coefficient par la méthode LASSO adaptative.

14) (M5)  $y_i = b_4 x_{4i} + \varepsilon_i, \quad \varepsilon_i \sim N(0, \sigma^2) \text{ i.i.d.}, \quad i=1, \dots, n.$

pvalue =  $10^{-16} \Rightarrow (M5)$  significatif

15)  $R^2_{\text{adj}}$  par (M2) = 0,23  
(M5) = 0,848

Le  $R^2_{\text{adj}}$  de (M2) est plus faible que celui de (M5). Une explication possible : l'élimination des vars  $x_1, x_4, x_5, x_6, x_7$  de (M1) n'est pas conseillée.

$$16) (M6) \quad Y_i = b_1 X_{1i} + \dots + b_7 X_{7i} + \varepsilon_i^{\text{④}}, \quad \varepsilon_i \text{ i.i.d } i=1, \dots, n.$$

Les coef sont estimés par la méthode médiane des moindres déviations.

$$(\hat{b}_{1n}^{\text{LAD}}, \dots, \hat{b}_{7n}^{\text{LAD}}) = \underset{b_1, \dots, b_7 \in \mathbb{R}^7}{\operatorname{arg\,min}} \sum_{i=1}^n |Y_i - b_1 X_{1i} - \dots - b_7 X_{7i}|$$

$$17) H_0: X_1 \text{ n'influe pas } Y \mid X_2, \dots, X_7 \text{ sont dans le modèle}$$

$$\left\{ \begin{array}{l} \Leftrightarrow b_1 = 0 \\ \Leftrightarrow \text{Modèle réduit: } Y_i = b_2 X_{2i} + \dots + b_7 X_{7i} + \varepsilon_i \end{array} \right.$$

$$H_1: X_1 \text{ influe } Y \mid X_2, \dots, X_7 \text{ dans le modèle}$$

$$\left\{ \begin{array}{l} \Leftrightarrow b_1 \neq 0 \\ \Leftrightarrow \text{Modèle (M6)} \end{array} \right.$$

$$\text{Statistique de test: } z = \frac{\hat{b}_{1n}^{\text{LAD}}}{\sqrt{\text{Var}(\hat{b}_{1n}^{\text{LAD}})}} \xrightarrow[n \rightarrow \infty]{H_0} N(0, 1)$$

Valeur stat de test  $z = 2,29$  p-value  $= 0,02 < 0,05$   
 $\Rightarrow H_0$  rejettée  $\Rightarrow X_1$  influe.

Variables influentes:  $X_1, X_2$

non influentes:  $X_3, X_4, X_5, X_6, X_7$ . A enlever.

18) (M7) a été obtenu de (M6) en gardant les var-significatives  
 Pour  $X_1$ : p-value  $= 4 \cdot 10^{-5} \Rightarrow X_1$  influe sur  $X_2$  dans le modèle  
 $X_2$ : p-value  $= 0,33 \Rightarrow X_2$  n'influe pas sur  $X_1$  dans le modèle.

19) Par la méthode LASSO adaptative quantile ( $z = \frac{1}{2}$ ):

$$(\hat{b}_{1n}^{\text{AQ}}, \dots, \hat{b}_{7n}^{\text{AQ}}) = \underset{(b_1, \dots, b_7) \in \mathbb{R}^7}{\operatorname{arg\,min}} \left( \sum_{i=1}^n |Y_i - b_1 X_{1i} - \dots - b_7 X_{7i}| + \lambda_n \sum_{j=1}^7 \hat{\omega}_j |\beta_j| \right)$$

$$\text{avec } \lambda_n = n^{2/5}, \quad \hat{\omega}_j = \frac{1}{|\hat{b}_{1n}^{\text{LAD}}|^{\gamma}}, \quad \gamma = 1,225$$

(5)

- 20)  $A_2 = \{44\} \Rightarrow (\text{MG}) \quad Y_i = b_4 X_{4i} + \xi_i, \quad \xi_i \text{ i.i.d.}, \quad i=1..n$   
 Méthode des moindres déviations.  $\text{mediane}(\xi_i) = 0$

### Exercice 2

$Y_v = \text{VSTATUS}$  qui prend 2 valeurs  $\begin{cases} 0 \\ 1 \end{cases}$

- 1) On modélise  $\pi(x) = P[Y=1|x]$ , avec  $x = (x_1, \dots, x_7)$   
 Par une régression logistique.

$$(\text{ML}) : \pi(x) = \frac{\exp(\beta^T x)}{1 + \exp(\beta^T x)}$$

avec  $\beta = (b_0, b_1, \dots, b_7)$

- 2)  $H_0 : \begin{cases} x_1 \text{ n'influe pas } \pi(x) \mid x_2, x_3, \dots, x_7 \text{ dans le modèle} \\ b_1 = 0 \end{cases} \quad \text{---} \quad H_1 : \begin{cases} x_1 \text{ influe } \pi(x) \mid x_2, \dots, x_7 \text{ dans le modèle} \\ b_1 \neq 0 \end{cases} \quad \text{---} \quad$

$$\text{Modèle : } \pi(x) = \frac{\exp(b_0 + b_1 x_1 + \dots + b_7 x_7)}{1 + \exp(b_0 + b_1 x_1 + \dots + b_7 x_7)}$$

$$H_1 : \begin{cases} x_1 \text{ influe } \pi(x) \mid x_2, \dots, x_7 \text{ dans le modèle} \\ b_1 \neq 0 \end{cases} \quad \text{---} \quad$$

Modèle (M10)

$$\text{statistique de test : } z = \frac{\hat{b}_1}{\sqrt{\text{Var}(\hat{b}_1)}} \xrightarrow[\substack{u \rightarrow \infty \\ H_0}]{L} N(0, 1)$$

Valeur de la stat de test:  $\hat{z} = -0.85$ , pvalue = 0.39 > 0.05  
 $\Rightarrow x_1$  n'influe pas  $\pi(x)$ .

Toutes les  $x_1, \dots, x_7$  sont non significatives.

- 3) Sur 17 valeurs de  $Y_v = 0$  on prévoit bien seulement 2 observations.  $\Rightarrow$  taux erreur  $15/17$   
 Sur les 48 obs  $Y_v = 1$  on prévoit correctement 45 obs.

Taux d'erreur  $\frac{3}{48}$

La mauvaise prévision de  $y_{12}$  par (M10) est due au fait qu'aucune var  $(x_j)_{1 \leq j \leq n}$  n'influe  $\bar{y}(x)$ . (6)

### Exercice 3

1) On a un modèle d'analyse de variance à 2 facteurs  $F_1$  et  $F_2$  avec interaction.

$$F_1: PLATELET <^0_1$$

chaque facteur a 2 valeurs.

$$F_2: FRAC <^0_1$$

$$(M11) \quad y_{ijk} = \mu + F_{1,i} + F_{2,j} + (F_1 * F_2)_{ij} + \varepsilon_{ijk}$$

$i=1,2 \quad j=1,2 \quad k=1, \dots, n_{ij}$   
 $\varepsilon_{ijk} \sim N(0, \sigma^2)$  i.i.d.

Contraintes

$$\left. \begin{array}{l} F_{1,1} + F_{1,2} = 0 \\ F_{2,1} + F_{2,2} = 0 \\ \forall j \in \{1, 2\}, \sum_{i=1}^2 (F_1 * F_2)_{ij} = 0 \\ \forall i \in \{1, 2\}, \sum_{j=1}^2 (F_1 * F_2)_{ij} = 0 \end{array} \right\}$$

$F_{1,1}$  l'effet d'une plaquette anormale sur  $y$   
 $F_{1,2}$  ——— il ————— normale ———

$F_{2,1}$  l'effet qu'il n'y a pas de fracture sur  $y$   
 $F_{2,2}$  ——— il y a de fracture sur  $y$

$(F_1 * F_2)_{12}$  l'effet de l'interaction entre une plaquette anormale et la présence d'une fracture, sur  $y$ .

2)  $H_0$ : (M11) non significatif

$\Leftrightarrow F_1, F_2, F_1 * F_2$  n'influe pas  $y$

$\Leftrightarrow F_{1,i} = F_{2,j} = (F_1 * F_2)_{ij}, \forall i, j \in \{1, 2\}$

$$\text{Modèle: } Y_{ijk} = \mu + \varepsilon_{ijk} \quad (7)$$

$H_1: \begin{cases} (\text{MII}) \text{ significatif} \Leftrightarrow F_1 \text{ ou } F_2 \text{ ou } F_1 * F_2 \text{ influe} \\ \Leftrightarrow \exists i \text{ ou } j \text{ t. q. } F_{1i} \neq 0 \text{ ou } F_{2j} \neq 0 \text{ ou } (F_1 * F_2)_{ij} \neq 0 \end{cases}$

Modèle (MII).

Statistique de test:

$$z = \frac{SM/3}{SR/61} \underset{H_0}{\sim} F(3, 61)$$

Valeur stat de test  $z = 0,56$ ,  $p\text{valeur} = 0,64 \Rightarrow H_0$  acceptée  
 $\Rightarrow$  Modèle (MII) non significatif.

3) La prévision de  $y_i$ :

$$\text{- par (M2)} \quad \hat{y}_i = \hat{b}_0^{LS} + \hat{b}_1^{LS} X_{2i} + \hat{b}_3^{LS} X_{3i} \quad i = 1, \dots, n$$

avec  $\hat{b}_j^{LS}$  estimateurs par moindres carrés.

$$\text{- Par (MII): } \hat{Y}_{ijk} = \hat{\mu} + \hat{F}_{1i} + \hat{F}_{2j} + \hat{(F_1 * F_2)}_{ij} \quad \begin{matrix} i = 1, 2 \\ j = 1, 2 \end{matrix}$$

$$R^2 \text{ adj par (M2)} = 0,23$$

$$R^2 \text{ adj par (MII)} = -0,02$$

$\} \Rightarrow (\text{M2})$  donne des meilleurs résultats d'ajustement.  
 car son  $R^2 \text{ adj}$  est plus grand.