

Corrigé examen RGD, 19/02/2025

Exercice 1

$Y = \log(\text{pH})$, $X_1 = N$, $X_2 = \text{Dens}$, $X_3 = P$, $X_4 = Ca$, $X_5 = Mg$, $X_6 = K$,
 $X_7 = Na$, $X_8 = \text{Conduc}$, toutes numériques.

1) Régression linéaire multiple:

$$(M1) \quad Y_i = b_0 + b_1 X_{1i} + \dots + b_8 X_{8i} + \varepsilon_i \quad i=1, \dots, n$$

$\varepsilon_i \text{ i.i.d. } \sim N(0, \sigma^2)$

2) Coefficients: $b_0, b_1, \dots, b_8$ estimés par moindres carrés σ^2 par maximum de vraisemblance.

3) $H_0: (M1) \text{ non significatif} \Leftrightarrow \text{aucune var } X_1, \dots, X_8 \text{ n'influe } Y$
 $\Leftrightarrow b_1 = \dots = b_8 = 0 \Leftrightarrow \text{Modèle réduit: } Y_i = b_0 + \varepsilon_i$

$H_1: (M1) \text{ significatif} \Leftrightarrow \exists j \in \{1, \dots, 8\} \text{ t.q. } X_j \text{ influe } Y \Leftrightarrow \exists j \text{ t.q. } b_j \neq 0$
 $\Leftrightarrow \text{Modèle complet } (M1)$

Statistique de test $Z = \frac{SM/8}{SR/39} \underset{H_0}{\sim} F(8, 39)$

Valeur de la statistique de test $z = 16,47 \Rightarrow p\text{-value} = 10^{-10} < 0.05$
 $\Rightarrow H_0$ rejetée avec un risque 0.05

4) On teste $X_1 = N$

$H_0: \begin{cases} X_1 \text{ n'influe pas } Y \text{ si } X_2, \dots, X_8 \text{ sont dans le modèle} \\ \Leftrightarrow b_1 = 0 \text{ si } \text{---} \\ \Leftrightarrow \text{Modèle réduit: } Y_i = b_0 + b_2 X_{2i} + \dots + b_8 X_{8i} + \varepsilon_i \end{cases}$

$H_1: \begin{cases} X_1 \text{ influe } Y \text{ si } X_2, \dots, X_8 \text{ sont dans le modèle} \\ \Leftrightarrow b_1 \neq 0 \text{ si } \text{---} \\ \Leftrightarrow \text{Modèle complet: } (M1) \end{cases}$

Statistique de test: $Z = \frac{B_1}{\sqrt{\text{Var}(B_1)}} \underset{H_0}{\sim} t(n-p-1) = t(39)$

Valeur de la statistique de test: $z = -0,898 \Rightarrow p\text{-value} = 0,37$
 $\Rightarrow$ l'azote n'influe pas le log du pH du sol, si $X_2, \dots, X_8$ sont dans le modèle.

Les variables significatives: $X_4 = Ca$, $X_7 = Na$, $X_8 = \text{Conduc}$.
Il faut enlever: X_1, X_2, X_3, X_5, X_6 .

5) $\hat{b}_0 = 1,311$, $\hat{b}_1 = -0,42$, $\dots$, $\hat{b}_8 = -0,04$.

Si X_8 augmente alors Y diminue
Si X_7 --- augmente

$$\hat{\sigma} = 0,07$$

⑥ $R^2_{adj} = 0,72 \Rightarrow (M1)$ de bonne qualité

7) $\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_{1i} + \dots + \hat{\beta}_8 x_{8i}$ la prévision de y .

Le résidu : $e_i = y_i - \hat{y}_i \quad i = 1, \dots, n$

On utilise le test de Shapiro pour tester la normalité de e .

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

Valeur de la stat de test 0.96, pvalue = 0.14 $\Rightarrow H_0$ acceptée pour $\alpha = 0,05$

8) Les deux modèles ont la même forme:

(M2), (M3): $y_i = \beta_1 x_{1i} + \dots + \beta_8 x_{8i} + \varepsilon_i$

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

$$(\hat{\beta}_{1n}^{LASSO}, \dots, \hat{\beta}_{8n}^{LASSO}) = \arg \min_{(\beta_1, \dots, \beta_8) \in \mathbb{R}^8} \left(\sum_{i=1}^n (y_i - \beta_1 x_{1i} - \dots - \beta_8 x_{8i})^2 + \lambda_n \sum_{j=1}^8 \hat{\omega}_j |\beta_j| \right)$$

avec $\lambda_n \rightarrow \infty, \lambda_n = 1 - 3/5, \gamma = 2/5$

$\hat{\omega}_j = \frac{1}{|\hat{\beta}_{jn}^{LS}|^\gamma}$, avec $\hat{\beta}_{jn}^{LS}$ l'estimateur par moindres carrés de $\beta_j, j = 1, \dots, 8$

10) Les estimation par moindres carrés sont toutes différentes de 0, deux étant proches de 0.

Les valeurs de $\hat{\beta}_{1n}^{LASSO}$ et $\hat{\beta}_{2n}^{LASSO}$ sont les seules différentes de 0.

11) (M4) $y_i = \beta_1 x_{1i} + \beta_2 x_{2i} + \varepsilon_i, \quad \varepsilon_i \sim N(0, \sigma^2) \text{ i.i.d.}$

pvalue = 0,80 $\Rightarrow$ les résidus de (M4) sont de loi Normale.

Exercice 2

1) F1: groupe, facteur qui prend 12 valeurs: 1, 2, ..., 12

F2: Block, facteur à 4 niveaux: 1, 2, 3, 4.

$Y = \log(PH)$

(M5) $y_{ijk} = \mu + F1_i + F2_j + \varepsilon_{ijk}, \quad \varepsilon_{ijk} \sim N(0, \sigma^2) \text{ i.i.d.}$

$i = 1, \dots, 12 \quad j = 1, 2, 3, 4$

$k = 1, \dots, n_{ij}$

Contraintes:

$$\begin{cases} \sum_{i=1}^{12} F1_i = 0 \\ \sum_{j=1}^4 F2_j = 0 \end{cases}$$

$F1$, est l'effet du groupe 1 sur le log du pH.

$F2_3$ —||— block 3 —||—

C'est un modèle d'analyse de variance à 2 facteurs, sans interaction.

2) H_0 : (M5) non signif $\Leftrightarrow F1$ et $F2$ n'influencent pas Y

$$\left\{ \begin{array}{l} \Leftrightarrow F1_i = F2_j = 0 \quad \forall i, j \\ \text{Modèle réduit } Y_{ijk} = \mu + \varepsilon_{ijk} \end{array} \right.$$

H_1 : (M5) significatif $\Leftrightarrow F1$ ou $F2$ influence Y

$$\left\{ \begin{array}{l} \Leftrightarrow \exists i \in \{1, \dots, 12\} \text{ t.q. } F1_i \neq 0 \text{ ou } \exists j \in \{1, 2, 3, 4\} \text{ t.q. } F2_j \neq 0 \\ \Leftrightarrow \text{Modèle (M5)} \end{array} \right.$$

Statistique de test: $Z = \frac{SM/14}{SR/33} \underset{H_0}{\sim} F(14, 33)$

Valeur stat de test: $z = 10.86$, $p\text{-value} = 10^{-8} \Rightarrow H_0$ rejetée

$\Rightarrow$ (M5) significatif.

$$3) \hat{\mu} = 1.53 \quad \hat{F1}_1 = 0.14 \quad \hat{F1}_{11} = -0.06, \quad \hat{F1}_{12} = -\sum_{i=1}^{11} \hat{F1}_i$$

$$\hat{F2}_1 = -0.04 \quad \dots \quad \hat{F2}_4 = -\sum_{j=1}^3 \hat{F2}_j$$

$$\hat{\sigma} = 0.07$$

Le groupe 1 a un effet de +0.14 sur log(pH) par rapport à la moyenne.

Le block 1 diminue de 0.04 le log(pH) par rapport à la moyenne.

4) H_0 : $F1$ n'influence pas Y si $F2$ est dans le modèle.

$$\left\{ \begin{array}{l} F1_i = 0 \quad \forall i. \quad \text{—||—} \\ \text{Modèle: } Y_{ijk} = \mu + F_j + \varepsilon_{ijk} \end{array} \right.$$

H_1 : $F1$ influence Y si $F2$ est dans le modèle

$$\left\{ \begin{array}{l} \exists i \in \{1, \dots, 12\} \text{ t.q. } F1_i \neq 0 \quad \text{—||—} \\ \text{Modèle: (M5)} \end{array} \right.$$

Stat de test: $Z = \frac{SF1/11}{SR/33} \underset{H_0}{\sim} F(11, 33)$

Valeur stat de test: $z = 12.93$. $p\text{-value} = 10^{-9} \Rightarrow F1$ significatif

Le facteur $F2 = \text{Block}$ est également significatif.

Exercice 3

(4)

$$1) \quad Y = \begin{cases} 0 & \text{si } \log(\text{pH}) \leq 1.5 \\ 1 & \text{si } \log(\text{pH}) > 1.5 \end{cases}$$

(M6) $X_4 = \text{Ca}$, $X_7 = \text{Na}$, $X_8 = \text{Conduc}$, $F2 = \text{Block}$.

$$\pi(\text{pH})[Y=1] = \frac{\exp(\mu + b_4 X_4 + b_7 X_7 + b_8 X_8 + F2_j)}{1 + \exp(\mu + b_4 X_4 + b_7 X_7 + b_8 X_8 + F2_j)} \quad j=1,2,3,4$$

Il s'agit d'une régression logistique.

$$2) \quad H_0: \begin{cases} X_4 \text{ n'influe pas } \pi(x) \text{ si } X_7, X_8 \text{ et } F2 \text{ dans le modèle} \\ b_4 = 0 \end{cases}$$

$$\text{Modèle: } \pi(x) = \frac{\exp(\mu + b_7 X_7 + b_8 X_8 + F2_j)}{1 + \exp(\mu + b_7 X_7 + b_8 X_8 + F2_j)}$$

$$H_1: \begin{cases} X_4 \text{ influe } \pi(x) \text{ si } X_7, X_8, F2 \text{ dans le modèle} \\ b_4 \neq 0 \end{cases}$$

$$\text{Modèle: (M6)}$$

$$\text{Stat de test: } z = \frac{\hat{B}_4}{\sqrt{\text{Var}(\hat{B}_4)}} \xrightarrow[H_0]{n \rightarrow \infty} N(0,1)$$

Valeur stat de test: $z = 1.09$ $p\text{-value} = 0.27 \Rightarrow H_0 \text{ accept}$

Variables numériques significatives: X_8 .

Le facteur $F2$ est non significatif car toutes les $p\text{-values}$ sont > 0.05 .

3) Sur les 23 valeurs de $Y=0$ on prévoit correctement 21
25 $Y=1$ 22

$$\text{Taux d'erreur } \frac{1}{2} \left(\frac{2}{23} + \frac{3}{25} \right).$$

Exercice 4

$$1) \quad Y = \text{pH} \quad X = (X_1, \dots, X_8)$$

Modèle de régression linéaire multiple, estimé par la méthode des moindres déviations.

$$(M7) = (M1) \text{ sauf que } \varepsilon_i \text{ i.i.d, médiane}(\varepsilon_i) = 0$$

$$(\hat{\beta}_{\text{LAD}}^0, \dots, \hat{\beta}_{\text{LAD}}^8) = \arg \min_{b_0, b_1, \dots, b_8} \sum_{i=1}^n |Y_i - b_0 - b_1 X_{1i} - \dots - b_8 X_{8i}|$$

$$2) \quad H_0: \begin{cases} X_1 \text{ n'influe pas } Y \text{ si } X_2, \dots, X_8 \text{ dans le modèle} \\ b_1 = 0 \end{cases}$$

$$\text{Modèle: } Y_i = b_0 + b_2 X_{2i} + \dots + b_8 X_{8i} + \varepsilon_i$$

(5)

$H_0 : \begin{cases} X_1 \text{ influe } Y \text{ si } \dots \\ b_1 \neq 0 \text{ si } \dots \end{cases} \Leftrightarrow \text{Modèle (M7)}$

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

Valeur stat test. $z = -2,53$ $p\text{-value} = 0,01$

Variables à enlever de (M7): X_2, X_6, X_7

Exercice 5

1) Y : visits X_1 : age X_2 : chronic $\leftarrow$ les 3 var sont numériques

La variable expliquée est Y et elle est de loi Poisson

2) Les coefficients estimés sont:

pour l'âge: $-0,039$

AIC = 37533

chronic: $0,199$

3) Test de l'âge: $p\text{-value} = 10^{-5}$
 X_2 $p\text{-value} = 10^{-16}$ $\} \Rightarrow X_1 \text{ et } X_2 \text{ influent } Y$

Exercice 1

$Y = \log(\text{temps})$
 $X_1 = \text{age}, \dots, X_7 = \text{SCALE}$

1) Régression linéaire multiple :

$$(M1) \quad Y_i = b_0 + b_1 X_{1i} + \dots + b_7 X_{7i} + \varepsilon_i, \quad \varepsilon_i \sim N(0, \sigma^2) \text{ i.i.d.}$$

$i = 1, \dots, n \quad n = 65$

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

3) H_0 : (M1) non significatif $\Leftrightarrow$ aucune var $X_1, \dots, X_7$ n'influe 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 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 Y | $X_2, \dots, X_7$ dans le modèle

$$\Leftrightarrow b_1 = 0 \mid X_2, \dots, X_7 \text{ dans le modèle}$$

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

H_1 : X_1 influe Y | $X_2, \dots, X_7$ dans le modèle

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

$\Leftrightarrow$ Modèle complet: (M1)

Statistique de test $Z = \frac{B_1}{\sqrt{\widehat{\text{var}}(B_1)}} \underset{H_0}{\sim} t(n-p-1) = t(57)$

$p = 7$.

Valeur de la stat de test: $z = 0,321 \Rightarrow p\text{-value} = 0,75 > 0,05$
 $\Rightarrow$ l'âge n'influe pas 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 p-value = 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 ^{augmente alors} ~~diminue~~

$\vdots$

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

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

6) $R^2_{adj} = 0,24 \Rightarrow (M1)$ 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-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) $y_i = b_0 + b_2 X_{2i} + b_3 X_{3i} + \varepsilon_i$ $i = 1, \dots, n$
 $\varepsilon_i \sim N(0, \sigma^2)$ i.i.d.

9) Modèle (M2) significatif avec seulement la var X_2 significative. La var X_3 a une p-value associée 0,13 donc elle n'influe pas Y si X_2 dans le modèle.

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

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

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

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

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

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

$$(\hat{b}_{1n}^{\text{aLASSO}}, \dots, \hat{b}_{7n}^{\text{aLASSO}}) = \arg \min_{(b_1, \dots, b_7) \in \mathbb{R}^7} \left(\sum_{i=1}^n (Y_i - b_1 X_{1i} - \dots - b_7 X_{7i})^2 + \lambda_n \sum_{j=1}^7 \hat{\omega}_j |\beta_j| \right)$$

$$\text{avec } \lambda_n \rightarrow \infty, \quad \lambda_n = n^{-\frac{2}{5} + 1}$$

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

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

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

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

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) $Y_i = b_4 X_{4i} + \varepsilon_i, \quad \varepsilon_i \sim \mathcal{N}(0, \sigma^2) \text{ i.i.d.}, \quad i = 1, \dots, n.$
 $p\text{-value} = 10^{-16} \Rightarrow (M5) \text{ significatif}$

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

Le R^2_{adj} de (M2) est plus faible que celui de (M5). Une explication possible : l'élimination des var X_1, X_4, X_5, X_6, X_7 de (M1) n'est pas conseillée.

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

Les coef sont estimés par la méthode médiane ou moindres déviations. $\text{médiane}(\varepsilon_i) = 0$.

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

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

$$\begin{cases} \Leftrightarrow b_1 = 0 & | - || - \\ \Leftrightarrow \text{Modèle réduit: } Y_i = b_2 X_{2i} + \dots + b_7 X_{7i} + \varepsilon_i \end{cases}$$

$H_1: X_1$ influe $Y | X_2, \dots, X_7$ dans le modèle

$$\begin{cases} \Leftrightarrow b_1 \neq 0 & | - || - \\ \Leftrightarrow \text{Modèle (M6)} \end{cases}$$

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

Valeur stat de test $z = 2,29$ $p\text{-value} = 0,02 < 0,05$
 $\Rightarrow H_0$ rejetée $\Rightarrow X_1$ 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 : $p\text{-value} = 4 \cdot 10^{-5} \Rightarrow X_1$ influe Y si X_2 dans le modèle
 X_2 : $p\text{-value} = 0.33 \Rightarrow X_2$ n'influe pas Y si X_1 dans le modèle.

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

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

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

(5)

20) $A2 = \{44\} \Rightarrow (M9) \quad y_i = b_4 x_{4i} + \varepsilon_i, \quad \varepsilon_i \text{ i.i.d.}, \quad i=1, \dots, n$
 Méthode des moindres déviations. médiante(ε_i) = 0

Exercice 2

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

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

$$(M10): \pi(x) = \frac{\exp(\beta^T x)}{1 + \exp(\beta^T x)}$$

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

2) $H_0: \begin{cases} X_1 \text{ n'influence pas } \pi(x) \\ b_1 = 0 \end{cases} \mid x_2, x_3, \dots, x_7 \text{ dans le modèle}$
 Modèle: $\pi(x) = \frac{\exp(b_0 + b_2 x_2 + \dots + b_7 x_7)}{1 + \exp(b_0 + b_2 x_2 + \dots + b_7 x_7)}$

$H_1: \begin{cases} X_1 \text{ influe } \pi(x) \\ b_1 \neq 0 \end{cases} \mid x_2, \dots, x_7 \text{ dans le modèle}$
 Modèle (M10)

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

Valeur de la stat de test: $z = -0.85$, $p\text{-value} = 0.39 > 0.05$
 $\Rightarrow X_1$ n'influence 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 erreurs $15/17$
 Sur les 48 obs $Y_v = 1$ on prévoit correctement 45 obs.
 Taux d'erreur $\frac{3}{48}$

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

Exercice 3

1) On a un modèle d'analyse de variance à 2 facteurs $F1$ et $F2$ avec interaction.

$F1: PLATELET < \begin{smallmatrix} 0 \\ 1 \end{smallmatrix}$

chaque facteur a 2 valeurs.

$F2: FRAC < \begin{smallmatrix} 0 \\ 1 \end{smallmatrix}$

$$(M11) \quad Y_{ijk} = \mu + F1_i + F2_j + (F1 * F2)_{ij} + \varepsilon_{ijk}$$

$$i=1,2 \quad j=1,2 \quad k=1, \dots, n_{ij}$$

$$\varepsilon_{ijk} \sim N(0, \sigma^2) \text{ i.i.d.}$$

Contraintes

$$\left\{ \begin{array}{l} F1_1 + F1_2 = 0 \\ F2_1 + F2_2 = 0 \\ \forall j \in \{1,2\}, \sum_{i=1}^2 (F1 * F2)_{ij} = 0 \\ \forall i \in \{1,2\}, \sum_{j=1}^2 (F1 * F2)_{ij} = 0 \end{array} \right.$$

$F1_1$ l'effet d'une plaquette anormale sur y
 $F1_2$ ———— normale ————

$F2_1$ l'effet qu'il n'y a pas de fracture sur y
 $F2_2$ ———— il y a de fracture sur y

$(F1 * F2)_{12}$ l'effet de l'interaction entre une plaquette anormale et la présence d'une fracture, sur y .

2) $H_0: (M11)$ non significatif

$\Leftrightarrow F1, F2, F1 * F2$ n'influe pas y

$\Leftrightarrow F1_i = F2_j = (F1 * F2)_{ij}, \forall i, j \in \{1,2\}$

⑦

Modèle: $y_{ijk} = \mu + \varepsilon_{ijk}$.

H_1 : (M11) significatif $\Leftrightarrow F1$ ou $F2$ ou $F1 \times F2$ influe y
 $\Leftrightarrow \exists i$ ou j t. g. $F1_i \neq 0$ ou $F2_j \neq 0$ ou $(F1 \times F2)_{ij} \neq 0$
 { Modèle (M11).

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 (M11) non significatif.

3) La prévision de y_i :

- par (M2) $\hat{y}_i = \hat{b}_0^{ls} + \hat{b}_2^{ls} X_{2i} + \hat{b}_3^{ls} X_{3i} \quad i = 1, \dots, n$

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

- par (M11): $\hat{y}_{ijk} = \hat{\mu} + \hat{F1}_i + \hat{F2}_j + (\hat{F1 \times F2})_{ij} \quad \begin{matrix} i = 1, 2 \\ j = 1, 2 \\ k = 1, \dots, n_{ij}' \end{matrix}$

R^2_{adj} par (M2) = 0,23

R^2_{adj} par (M11) = -0,02

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