

Corrigé examen 27 janvier 2021

Exercice 1

y : BP change et deux facteurs: F_1 et F_2 , avec
 F_1 : "Dose" à 6 niveaux
 F_2 : "Treatment" à 2 niveaux.

1) On a un modèle d'analyse de variance à 2 facteurs avec une interaction

$$(M1) \quad Y_{ijk} = \mu + (F1)_i + (F2)_j + (F1 * F2)_{ij} + \varepsilon_{ijk}$$

$i = 1, \dots, 6 \quad j = 1, 2 \quad k = 1, \dots, n_{ij}$

$F1_i$: c'est l'effet du niveau i de F_1 sur y

$F2_j$ —||— $F2$ —||—

$(F1 * F2)_{ij}$... ^{de l'interaction} des niveaux i de F_1 et k de F_2 sur y

Contraintes: $\sum_{i=1}^6 F1_i = 0$, $\sum_{j=1}^2 F2_j = 0$, $\forall i=1, 6-6$, $\sum_{i=1}^6 (F1 * F2)_{ij} = 0$
 $\forall j=1, 2$, $\sum_{i=1}^6 (F1 * F2)_{ij} = 0$

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

2) H_0 : (M1) non significatif \Leftrightarrow aucun des 2 facteurs et de l'interaction n'influent y .

$$\Leftrightarrow \begin{cases} F1_i = 0 \quad \forall i=1, \dots, 6 \\ (F1 * F2)_{ij} = 0 \quad \forall i=1, \dots, 6, \forall j=1, 2 \end{cases}$$

$$\Leftrightarrow \text{Modèle réduit: } Y_{ijk} = \mu + \varepsilon_{ijk}$$

H_1 : (M1) significatif $\Leftrightarrow y$ influencée par F_1 ou F_2 ou $F_1 * F_2 \Leftrightarrow \exists F1_i \neq 0$ ou $\exists F2_j \neq 0$ ou $\exists (F1 * F2)_{ij} \neq 0$

Modèle complet: (M1)

Statistique de test:

$$Z = \frac{SM/11}{SR/48} \underset{H_0}{\sim} F(11, 48)$$

Stat de test: $z = 29,45$ ⁽²⁾, pvalue $< 10^{-16} \Rightarrow H_0$ rejetée \Rightarrow
 \Rightarrow (M1) significative

3) On teste F^2 :

H_0 : $\left\{ \begin{array}{l} F_2 \text{ n'influe pas } y \text{ si } F_1 \text{ et } F_1 \times F_2 \text{ sont dans} \\ \text{le modèle} \Leftrightarrow F_{2j} = 0 \quad \forall j=1,2 \\ \text{Modèle: } y_{ijk} = \mu + (F_1)_i + (F_1 \times F_2)_{ij} + \varepsilon_{ijk} \end{array} \right.$

H_1 : $\left\{ \begin{array}{l} F_2 \text{ influe } y \text{ si } F_1 \text{ et } F_1 \times F_2 \text{ sont dans le modèle} \\ \Leftrightarrow \exists F_{2j} \neq 0 \\ \text{Modèle: (M1)} \end{array} \right.$

Stat de test: $z_{F_2} = \frac{S_{F_2}/1}{SR/48} \underset{H_0}{\sim} F(1, 48)$

pvalue = 0,0002

$z = 15,72$

\Downarrow
 H_0 rejetée $\Rightarrow F_2$ influe y si F_1 et $F_1 \times F_2$ dans le modèle.

Pour les autres variables: F_1 et $F_1 \times F_2$ influent également y .

Il ne faut pas enlever des variables.

4) $\hat{\mu} = 11,2$ $\hat{F}_{11} = -9,8$ $\hat{F}_{12} = -9,2, \dots$ $\hat{F}_{16} = -(\hat{F}_{11} + \dots + \hat{F}_{15})$

par rapport à la moyenne la dose 1 diminue la pression artérielle de 9,8

$(F_1 \times F_2)_{11} = -2,68$ $(F_1 \times F_2)_{12} = 2,68$, $\hat{\sigma} = 4,572$

par rapport à la moyenne la dose 1 et le traitement 1 diminuent la pression de 2,68

5) $R^2_{adj} = 0,84 \Rightarrow$ (M1) de bonne qualité d'ajustement

Exercice 2. $Y = \text{remiss}$, var. qualitative qui prend 2 valeurs.

Trois variables explicatives numériques:

$X_1 = \text{cell}$, $X_2 = \text{li}$, $X_3 = \text{blast}$.

1) $Y=0$ pour 18 obs et $=1$ pour 9 obs $\Rightarrow 27$ obs.

2) On a un modèle logistique de la forme:

$$(M2) P[Y_i=1 | X_{1i}, X_{2i}, X_{3i}] = \frac{\exp(b_0 + b_1 X_{1i} + b_2 X_{2i} + b_3 X_{3i})}{1 + \exp(b_0 + b_1 X_{1i} + b_2 X_{2i} + b_3 X_{3i})}$$

$i=1, \dots, 27$.

3) H_0 : X_1 n'influe pas $P[Y=1]$ si X_2 et X_3 sont dans le modèle.

$$\Leftrightarrow b_1 = 0 \Leftrightarrow P[Y_i=1 | X_{2i}, X_{3i}] = \frac{\exp(b_0 + b_2 X_{2i} + b_3 X_{3i})}{1 + \exp(b_0 + b_2 X_{2i} + b_3 X_{3i})}$$

H_1 : X_1 influe $P[Y=1]$ si X_2 et X_3 sont dans le modèle

$$\Leftrightarrow b_1 \neq 0 \Leftrightarrow (M2)$$

Stat de test $Z_1 = \frac{\hat{b}_1}{\hat{\sigma}_{\hat{b}_1}} \xrightarrow{H_0} N(0,1)$

valeur: $Z_1 = 1,058$ pvalue = 0,29 $\Rightarrow H_0$ acceptée

Pareil: X_2 influe, X_3 n'influe pas $P[Y=1]$

4) $\hat{b}_0 = -10,6$, $\hat{b}_1 = 7,46 > 0$, $\hat{b}_2 = 3,26 > 0$, $\hat{b}_3 = -0,57 < 0$

quand X_1 et X_2 ~~se~~ augmentent $P[Y=1]$ augmente
 $P[Y=1]$ diminue si X_3 augmente.

5) $\hat{P}[Y=0]$: Prévission des $Y=0$ (non rémission) sur les 18 obs, 16 sont bien prévues.

Taux de mauvaise prévision: $\frac{2}{18}$

(4)

$Y=1$ (rémission) : seulement 4 obs sur 9 sont bien prévues par (M2). Taux d'erreur: $\frac{5}{9}$.

$$6) P[Y_i=1 | X_{2i}] = \frac{\exp(b_0 + b_1 X_{2i})}{1 + \exp(b_0 + b_1 X_{2i})} \quad i=1, \dots, 9.$$

modèle de régression logistique avec une seule variable explicative.

7) Les prévisions pour Y sont les mêmes par (M2) et (M3). Ce n'est pas surprenant. car (M3) est obtenu à partir de (M2) en enlevant les 2 var. explicatives non significatives.