

Corrigé examen 14 décembre 2016

M2 "Modèles de régression"

Exercice 1

1) On modélise une variable qualitative fonction de variables numériques. On a donc un modèle logistique : $y = \text{1 and 0}$, 2 valeurs : R : absence ; N : présence
 $\pi(x) = P[y = "R" | X = x]$ avec $x = [km91, km118, \dots, km338, (x_1, x_2, \dots, x_7)]$

Alors, le modèle logistique est :

$$(1) \quad P[y = "R" | X = x] = \frac{\exp(b_0 + \sum_{j=1}^7 b_j x_j)}{1 + \exp(b_0 + \sum_{j=1}^7 b_j x_j)}$$

proba d'absence de nids

2) Le nombre de sites est 60. Le nombres de sites où il y a des nids de chouettes = 30.

3) Pour étudier la présence de nids de chouettes on regarde les sorties SAS :

H_0 : les 7 variables n'ont aucune influence sur l'absence des nids de chouettes
 $b_1 = b_2 = \dots = b_7 = 0$

Modèle :

$$(2) \quad \pi(x) = P[y = "R" | X = x] = \frac{\exp(b_0)}{1 + \exp(b_0)}$$

en fait, $\pi(x)$ est constante, ne dépend pas de x .

H_1 : $\exists j \in \{1, \dots, 7\}$ t. q. $b_j \neq 0 \Leftrightarrow \pi(x)$ influence par au moins une des sept variables.

Modèle : r_1

(2)

Par les trois statistiques de test : rapport de vrais score, Wald, l'hypothèse H_0 est rejetée ($p\text{-val} < 0.05$) et donc le modèle (1) significatif.

Indicateurs quantitatifs :

Pour (1) $AIC = 68.134 \quad BIC = 84.888$

(2) $AIC = 85.178 \quad BIC = 87.272$

les deux critères diminuent pour le modèle (1).

Q) On étudie les sorties R. Les sorties SAS donnent les mêmes résultats.

H_0 : x_1 n'influe pas $P[y = "R"]$ si x_2, \dots, x_7 sont dans le modèle.

H_0 : $b_1 = 0$ | x_2, \dots, x_7 dans le modèle

Modèle :

$$(3) P[y = "R" | x = z] = \frac{\exp(b_0 + \sum_{j=2}^7 b_j z_j)}{1 + \exp(b_0 + \sum_{j=2}^7 b_j z_j)}$$

H_1 : $b_1 \neq 0$ | x_2, \dots, x_7 dans le modèle.

Modèle : (1).

Stat de test: $z_1 = \frac{B_1}{\sqrt{B_1}} \xrightarrow{D} N(0, 1)$

La réalisation: $z_1 = -1,535 \Rightarrow p\text{-value} = 0.12$

$\Rightarrow H_0$ acceptée.

Conclusion: les var. qui influent $P[y = "R"]$ sont :

$\begin{cases} \text{km118} \\ \text{km140} \end{cases}$

Rq : $b_0 \neq 0$. On garde aussi km91 et km241 .

5) Le Modèle (M2) est : (3)

$$(4) P[y = "R" | x = z] = \frac{\exp(f_0 + f_1 z_1 + f_2 z_2 + f_3 z_3 + f_6 z_6)}{1 + \exp(f_0 + f_1 z_1 + f_2 z_2 + f_3 z_3 + f_6 z_6)}$$

Les estimations des paramètres :

$$\begin{aligned}\hat{f}_0 &= 10,2758 & \hat{f}_1 &= 0,1199 & \hat{f}_6 &= -0,08 \\ \hat{f}_2 &= -0,0643 & \hat{f}_3 &= -0,12\end{aligned}$$

La var $z_2 = \text{km}118$ a une influence positive sur la probabilité d'absence de nids pendant que km91, km140 et km261 ont une influence négative.

Prévisions pour (M2) :

- parmi les 30 sites avec nids, 24 sont bien prévus
- — " sans — — "

Taux d'erreur : $\frac{1}{2} \left(\frac{6}{30} + \frac{6}{30} \right) = \frac{1}{5} = 20\%$

Exercice 2

- 1) Les variables explicatives "site" et "faam" sont de type qualitatives, pendant que la variable expliquée "biomass" est numérique. Donc, on a un modèle d'analyse de variance à 2 facteurs
- 2) Le nb d'obs totales : 612
Nb d'obs utilisées : 450

Le modèle (M3) est :

$$y_{ijk} = \mu + (\text{site})_i + (\text{faam})_j + (\text{site} \times \text{faam})_{ij} + \varepsilon_{ijk}$$

$$\text{avec : } \varepsilon_{ijk} \sim N(0, \sigma^2) \quad i = 1, \dots, 6 \quad j = 1, 2, 3, 4 \quad k = 1, \dots, n_{ij}$$

$$\varepsilon_{ijk} \perp \varepsilon_{i'j'k'}$$

$(\text{site})_i$: l'effet du site i sur la biomasse

y : biomasse

$(faam)_j$: l'effet de la famille j sur la biomasse
 $(site * faam)_{ij}$: l'effet de l'interaction entre le site i et la famille j sur y .

Contraintes : $\sum_{i=1}^6 (site)_i = 0$, $\sum_{j=1}^4 (faam)_j = 0$
 $\forall i = 1, \dots, 6$, $\sum_{j=1}^4 (site * faam)_{ij} = 0$
 $\forall j = 1, 2, 3, 4$, $\sum_{i=1}^6 (site * faam)_{ij} = 0$

Les valeurs des variables :

"site": 1, 2, ..., 6

"faam": 1, 2, 3, 4

3) H_0 : le modèle (M3) n'est pas significatif
 \Leftrightarrow le site et la famille des pins n'ont aucune influence sur la biomasse
 $\Leftrightarrow \forall site_i = 0$, $\forall faam_j = 0$, $\forall (site * faam)_{ij} = 0$
 \Leftrightarrow Modèle : $y_{ijk} = \mu + \varepsilon_{ijk}$

H_1 : (M3) significatif

$\Leftrightarrow y$ influencé par le site, ou par la famille, ou par leur interaction.

$\Leftrightarrow \exists i$, $site_{i \neq 0}$ ou $\exists faam_j \neq 0$ ou $\exists i, j$, $(site * faam)_{ij} \neq 0$

\Leftrightarrow Modèle (M3)

Statistique de test :

$$z = \frac{SM/17}{SR/432} \underset{H_0}{\sim} F(17, 432)$$

Valeur stat de test : $z = 16,78$ et $p\text{-value} \leq 10^{-4}$
 $\Rightarrow H_0$ rejetée \Rightarrow (M3) significatif.

(5)

Tests des 2 facteurs et de leur interaction :

H_0 : le site n'influe pas la biomasse | la famille et l'interaction site*famille sont dans le modèle

$\Leftrightarrow \forall i = 1, \dots, 6 \quad \text{site}_i = 0 \quad \dots$

Modèle: $y_{ijk} = \mu + (\text{faam})_j + (\text{site} * \text{faam})_{ij} + \varepsilon_{ijk}$

H_1 : le site influe | faam et site*faam dans le modèle

$\Leftrightarrow \exists i, \quad \text{site}_i \neq 0$

Modèle : (M3)

Stat de test: $z = \frac{s_{\text{site}} / s}{s_{R/432}} \sim_{H_0} F(5, 432)$

Valeur stat de test $z = 54,97$, pvalue $< 10^{-4}$
 \Rightarrow le site signif.

Parce que, on obtient que "faam" et "site*faam" n'influent pas y , si on garde les autres var dans le modèle.

- 4) (M4): $y_{ij} = \mu + \text{site}_i + \varepsilon_{ij} \quad i=1, \dots, 6$
 $\sum_{i=1}^6 \text{site}_i = 0 \quad \varepsilon_{ij} \sim N(0, \sigma^2) \quad j=1, \dots, n_i$
 $\varepsilon_{ij} \perp \!\!\! \perp \varepsilon_{i,j'}$
- 5) H_0 : pour (M4) le site n'influe pas y
 $\Leftrightarrow \text{site}_i = 0 \quad \forall i = 1, \dots, 6$
 \Leftrightarrow Modèle : $y_{ij} = \mu + \varepsilon_{ij}$
- H_1 : le site influe y dans (M4)
 \Leftrightarrow Modèle (M4)

$$\text{Stat de test: } z = \frac{SM/5}{SR/444} \underset{H_0}{\sim} F(5, 444)$$

La valeur de la stat de test $z = 55.79$
 $p\text{ value} < 10^{-4} \Rightarrow$ le site influe sur $\gamma \Rightarrow (M_4) \text{ signif}$

6) $\hat{\sigma}^2 = 129807,23$ } sorties R.
 $\hat{\mu}_1 = 773,83$
 $\hat{\mu}_{site_1} = 301,5$

$$\hat{\mu}_{site_5} = 301,57$$

$$\hat{\mu}_{site_6} = - \sum_{j=1}^5 \hat{\mu}_{site_j}$$

Par rapport à la moyenne, un pin du site = 1
 a une biomasse plus grande avec 301,5,
 le site = 2 a une biomasse inférieure de
 $479,7$

7) On utilise les sorties SAS: on a que
 l'hypothèse $site_4 = 0$ est acceptée. Mais la
 contrainte est $site_6 = 0$. Donc les sites 4 et 6
 ont la même biomasse.

8) Pour (M_3) $R^2_{adj} = 0,374$ donc on a les
 (M_4) : $R^2_{adj} = 0,379$ mêmes R^2 ajustés

parce que (M_4) a été obtenu à partir de (M_3)
 en supprimant les variables non significatives.
 Donc (M_4) et (M_3) obtiennent la même
 qualité de prévision assez bonne.

