

## Examen de contrôle continu

**Durée 1h15 - Sans document - 8 octobre 2019**

### Exercice 1 (5 pts)

On considère le modèle de régression suivant :

$$y_i = \beta_0 + \beta_1 x_{i,1} + \beta_2 x_{i,2} + \beta_3 x_{i,3} + \epsilon_i$$

pour  $1 \leq i \leq n$ , les vecteurs des  $x_i$  sont déterministes et le vecteur des  $\epsilon_i$  est un vecteur gaussien centré de matrice de variance covariance  $\sigma^2 I_n$ . On pose  $y = (y_1, \dots, y_n)$  et

$$X = \begin{bmatrix} 1 & x_{1,1} & \dots & x_{1,3} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & x_{n,1} & \dots & x_{n,3} \end{bmatrix}$$

Nous avons

$$X^T X = \begin{bmatrix} 50 & 0 & 0 & 0 \\ 0 & 20 & 15 & 4 \\ 0 & 15 & 30 & 10 \\ 0 & 4 & 10 & 40 \end{bmatrix}, \quad X^T y = (100, 50, 40, 80), \quad y^T y = 640.$$

On admet que

$$\begin{bmatrix} 20 & 15 & 4 \\ 15 & 30 & 10 \\ 4 & 10 & 40 \end{bmatrix}^{-1} = \frac{1}{13720} \begin{bmatrix} 1100 & -560 & 30 \\ -560 & 784 & -140 \\ 30 & -140 & 375 \end{bmatrix}.$$

**1 (1 pt)** Donner la valeur de  $n$ .

**2 (1 pt)** Interpréter les 0 de la matrice  $X^T X$ .

**3 (1 pt)** Donner l'estimateur des moindres carrés de  $(\beta_0, \beta_1, \beta_2, \beta_3)$ , peut-on calculer l'estimation associée avec les données fournies ?

**4 (1 pt)** Donner un intervalle de confiance de niveau de confiance à 95% pour  $\beta_3$ .

**5 (1 pt)** Construire un test de niveau 5% de l'hypothèse  $H_0 : \beta_3 = 0$  contre  $H_1 : \beta_3 \neq 0$ .

### Exercice 2 (3 pts)

On considère  $n$  variables aléatoires indépendantes  $y_1, \dots, y_n$  telles que  $y_i$  est distribuée suivant une loi de Poisson de paramètre  $\lambda_i$ .

**1 (0.5 pt)** Montrer que la loi de Poisson appartient à la famille exponentielle.

**2 (0.5 pt)** Calculer  $\mathbb{E}(y_i)$  et  $\mathbb{V}(y_i)$ .

Pour tout  $i = 1, \dots, n$ , on suppose que  $\log(\sqrt{\lambda_i}) = \beta_1 + \beta_2 x_i$ .

**3 (1 pt)** Montrer qu'il s'agit d'un modèle linéaire généralisé. La fonction de lien canonique a-t-elle été utilisée ?

### Exercice 3 (6 pts)

Expliquer en détails les résultats produits par le code Python ci-dessous

```
import numpy as np
import matplotlib.pyplot as plt

from sklearn import datasets
from sklearn.linear_model import Lasso
from sklearn.model_selection import GridSearchCV

diabetes = datasets.load_diabetes()
X = diabetes.data
y = diabetes.target

print(diabetes.data.shape)
# (442, 10)

print(diabetes.target.shape)
# (442, )

lasso = Lasso()
alphas = np.logspace(-4, -0.5, 30)
alphas[0]
# 0.0001
alphas[29]
# 0.31622776601683794
10**(-0.5)
# 0.31622776601683794

tuned_parameters = [{'alpha': alphas}]
n_folds = 5

clf = GridSearchCV(lasso, tuned_parameters, cv=n_folds)
clf.fit(X, y)
scores = clf.cv_results_['mean_test_score']
scores_std = clf.cv_results_['std_test_score']
```

```

print(scores)
#[0.48229145 0.48229179 0.48229211 0.48229232 0.48229222 0.48229143
# 0.48228924 0.48228437 0.48227446 0.48233369 0.48242998 0.48244909
# 0.48247616 0.48249863 0.48242247 0.48197794 0.48127519 0.48112164
# 0.48136664 0.48170547 0.48183326 0.48204223 0.48199684 0.4818627
# 0.48099981 0.47905578 0.47625075 0.47224129 0.46542727 0.45651226]

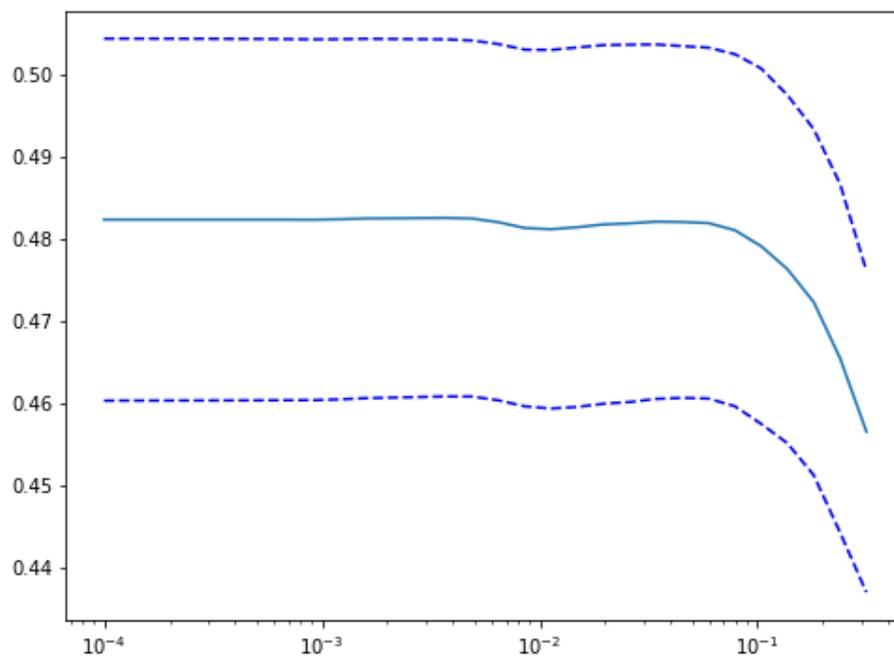
print(scores_std)
# [0.04923312 0.04922588 0.04921635 0.04920385 0.04918746 0.04916604
# 0.04913812 0.0491019 0.04905525 0.04897275 0.04887265 0.04876697
# 0.04865917 0.0485564 0.04842364 0.04844148 0.04849849 0.04875972
# 0.04888454 0.048766 0.04859029 0.04819974 0.0478335 0.04771292
# 0.04788694 0.04833115 0.04734514 0.04707518 0.04738262 0.04372668]

plt.figure().set_size_inches(8, 6)
plt.semilogx(alphas, scores)

std_error = scores_std / np.sqrt(n_folds)

plt.semilogx(alphas, scores + std_error, 'b--')
plt.semilogx(alphas, scores - std_error, 'b--')

```



#### Exercice 4 (6 pts)

Expliquer en détails les résultats produits par le code R ci-dessous

```
n <- 100
x1 <- rnorm(n)
x2 <- rnorm(n)
x3 <- rnorm(n)
u <- rnorm(n)
y <- 1+1.5*x1+2*x2-0.7*x3+u

d <- 80
z <- matrix(runif(n*d),n)

app <- data.frame(y=y,x1=x1,x2=x2,x3=x3,z=z)
names(app)[- (1:4)] <- paste("z",1:80,sep="")

model1 <- lm(y~1,data=app)
model2 <- lm(y~.,data=app)
model3 <- lm(y~x1+x2+x3,data=app)

library(glmnet)
library(caret)
x <- as.matrix(app[,-1])
model4 <- glmnet(x,y,family="gaussian",nlambda=50,alpha=1)
model5 <- train(x,y,method="glmnet",metric="RMSE",
               trControl=trainControl(method="repeatedcv",
                                       number=5,repeats=100),
               tuneGrid=data.frame(alpha=1,lambda=model4$lambda))

ntest <- 1000
x1test <- rnorm(n)
x2test <- rnorm(n)
x3test <- rnorm(n)
utest <- rnorm(n)
ytest <- 1+1.5*x1test+2*x2test-0.7*x3test+utest
ztest <- matrix(runif(n*d),n)

test <- data.frame(y=ytest,x1=x1test,x2=x2test,x3=x3test,z=ztest)
names(test)[- (1:4)] <- paste("z",1:80,sep="")

mean((predict(model3,test)-ytest)^2)
# 1.000278
mean((predict(model1,test)-ytest)^2)
# 10.37723
mean((predict(model2,test)-ytest)^2)
# 6.840056
mean((predict(model5,test)-ytest)^2)
# 1.217017
```

①

Correction examen  
de contrôle continu  
8 octobre 2019  
HPPA 304

Exercice 1

1)  $n = 50$

2) les variables explicatives  
 $x_1, x_2$  et  $x_3$  sont centrées.

3)  $\hat{\beta} = (X^T X)^{-1} X^T y$

$\hat{\beta} = (\hat{\beta}_0, \hat{\beta}_1, \hat{\beta}_2, \hat{\beta}_3)$

Nous pouvons calculer l'estimation  
espérée avec les données du problème en

$$(X^T X)^{-1} = \begin{bmatrix} \frac{1}{50} & 0 & 0 & 0 \\ 0 & \begin{bmatrix} 20 & 15 & 4 \\ 15 & 30 & 10 \\ 4 & 10 & 40 \end{bmatrix}^{-1} \\ 0 & & & \\ 0 & & & \end{bmatrix}$$

2) Nous savons que

(2)

$$\hat{\beta}_3 - \beta_3 \sim N_{\mathbb{R}}(0, \sigma^2 (X^T X)^{-1}_{(4,4)})$$

Donc évidemment, on peut estimer

$$\sigma^2 \text{ par } \hat{\sigma}^2 = \frac{(y - \hat{y})^T (y - \hat{y})}{n-4}$$

$(y - \hat{y})^T (y - \hat{y})$  est la somme des carrés résiduelle

$$\hat{y} = X \hat{\beta} = X (X^T X)^{-1} X^T y$$

$$(y - \hat{y}) = [I_n - X (X^T X)^{-1} X^T] y$$

$$(y - \hat{y})^T (y - \hat{y}) = y^T [I_n - X (X^T X)^{-1} X^T] y$$

$$(y - \hat{y})^T (y - \hat{y}) = y^T y - y^T X (X^T X)^{-1} X^T y$$

Avec les données du problème, on peut calculer  $(y - \hat{y})^T (y - \hat{y})$ .

(3)

Answer,

$$\frac{(\hat{\beta}_3 - \beta_3) / \sqrt{\hat{\sigma}^2 (X'X)^{-1}_{(4,4)}}}{\sqrt{\frac{(y - \hat{y})^T (y - \hat{y})}{\sigma^2 (n-4)}}} \sim T / (n-4)$$

$$\frac{(\hat{\beta}_3 - \beta_3)}{\sqrt{\hat{\sigma}^2 (X'X)^{-1}_{(4,4)}}} \sim T (n-4)$$

Answer,  $n \cdot q = F_{1, (n-4)}^{-1} (0, 975)$

$$P\left(-q \leq \frac{(\hat{\beta}_3 - \beta_3)}{\sqrt{\hat{\sigma}^2 (X'X)^{-1}_{(4,4)}}} \leq q\right) = 0.95$$

$$IC_{95\%}(\beta_3) = \left[ \hat{\beta}_3 \pm q \sqrt{\hat{\sigma}^2 (X'X)^{-1}_{(4,4)}} \right]$$

5] Om reject  $H_0: \beta_3 = 0$  (4)

ni  $0 \notin I_{95\%}(\beta_3)$ .

## Exercice 2

1]  $P_N(y) = \frac{e^{-\lambda} \lambda^y}{y!} \prod_{i=1}^N \pi(y) \tau(\lambda y)$   
où  $\tau(\cdot)$  est la mesure de comptage.

$P_N(y) = \exp\{-\lambda + y \log(\lambda)\} \tau(\lambda y)$

où  $\tau(\lambda y) = \frac{1}{y!} \prod_{i=1}^N \pi(y)$

La loi de Poisson appartient à une famille exponentielle canonique.

$$\theta = -\log(\lambda) \Rightarrow \lambda = e^{-\theta}$$

$$h(\theta) = e^{-\theta}$$

$$2] E(y) = h'(\theta) = e^{-\theta} = \lambda$$

$$V(y) = h''(\theta) = e^{-\theta} = \lambda$$

(5)

3] mem mem

$$\text{log}(\sqrt{x}) = \beta_1 + \beta_2 x$$

$$\Rightarrow x = \exp(2\beta_1 + 2\beta_2 x)$$

$$\Rightarrow E(y) = f(\beta_1 + \beta_2 x)$$

IC s'agit bien d'un modèle linéaire généralisé.

En effet,  $Q \neq \beta_1 + \beta_2 x$

donc ce n'est pas le lien canonique qui a été utilisé.

Cependant,  $Q = \varepsilon\beta_1 + \varepsilon\beta_2 x$  et donc à une reparamétrisation près, il s'agit bien du lien canonique.

6

### Exercice 3

Le jeu de données ci-dessus est analysé. Il contient une variable quantitative à prévoir et 10 variables quantitatives prédictives. Les observations - concernant 442 individus.

Une régression lasso est mise en œuvre, le paramètre de régularisation  $\alpha$  est calibré par validation croisée à 5 ensembles. 30 valeurs sont testées de  $10^{-4}$  à  $10^{-7/2}$ . Plus  $\alpha$  est fort, plus on régularise. Le valeur de  $\alpha$  choisie pour le critère de  $R^2$  est très petite, il n'y a pas de  $\neq$  significative pour les petites valeurs. La régularisation semble ici inutile.

# Exercice 4

(7)

On simule 100 données  $Y$  suivant le modèle

$$Y = 1 + 1,5 \pi_1 + 2 \pi_2 - 0,7 \pi_3 + \mu$$

avec  $\mu \sim N(0, 1)$ , les  $\pi_i$  sont également des gaussiennes centrées réduites.

On teste 4 modèles :

- modèle 1 : - contient uniquement la constante
- modèle 2 : - contient 83 variables  $\pi_1, \pi_2$  et  $\pi_3$  et 80 variables de bruit
- modèle 3 : modèle exact, - contient les 3 variables  $\pi_1, \pi_2$  et  $\pi_3$
- modèle 5 : régression lasso sur les 83 variables avec paramètre de régularisation choisi par validation croisée  $\alpha$  5 ensembles répété 100 fois

Sur un jeu de données de test <sup>(8)</sup>  
de taille 1000, on observe  
que le modèle passe mieux  
à d'excellents résultats. Son  
erreur quadratique moyenne est  
très proche de celle du  
modèle vu.