

Examen final

Durée 2h - Sans document - 5 novembre 2018

Exercice 1 (10 pts)

1 (4 pts) On rappelle que la loi Beta de paramètre $\alpha > 0$ et $\beta > 0$ admet pour densité de probabilité

$$f(x) = \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha)\Gamma(\beta)} x^{\alpha-1} (1-x)^{\beta-1} \mathbf{1}_{]0,1[}(x).$$

Décrire les procédures mises en oeuvre par l'intermédiaire du code R suivant.

```
f <- fonction(x)
{
  sqrt((1-x)*x)/(exp(x)+log(1+x))
}

x <- runif(10000)
mean(f(x))
sqrt(var(f(x)))

x <- rbeta(10000,3/2,3/2)
h <- fonction(x)
{
  1/(exp(x)+log(1+x))
}
gamma(3/2)^2/gamma(3)*mean(h(x))
gamma(3/2)^2/gamma(3)*sqrt(var(h(x)))
```

2 (2 pts) Donner le code R permettant de générer une réalisation suivant une variable aléatoire X telle que $\mathbb{P}(X = 1) = 0.6$, $\mathbb{P}(X = 2) = 0.3$ et $\mathbb{P}(X = 3) = 0.1$.

2 (4 pts) Pour quel type de données et répondre à quelle question les modèles log-linéaires graphiques sont-ils utilisés? Donner un exemple. Quelle procédure peut-on mettre en oeuvre pour sélectionner le modèle log-linéaire graphique le plus adapté à un ensemble de données?

Exercice 2 (4 pts)

On considère n variables aléatoires indépendantes y_1, \dots, y_n telles que y_i est distribué suivant une loi binomiale négative de paramètres (h, π_i) . Nous supposons que h est fixé. De manière générique, la loi négative binomiale modélise, dans le contexte d'une suite d'épreuves de Bernoulli indépendantes, le nombre d'échecs nécessaires pour obtenir h succès, π représentant la probabilité de succès :

$$f(y; \pi) = C_{h+y-1}^y \pi^h (1 - \pi)^y \mathbf{1}_{\mathbb{N}}(y).$$

1 (1 pt) Montrer que la loi binomiale négative appartient à la famille exponentielle.

2 (1 pt) Calculer $\mathbb{E}(y)$ et $\mathbb{V}(y)$.

Pour tout $i = 1, \dots, n$, on suppose que $\log(1 - \pi_i) = \beta_1 + \beta_2 x_i$.

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

4 (1 pt) Donner la log-vraisemblance et les équations de vraisemblance.

Exercice 3 (6 pts)

Expliquer en détails les procédures mises en oeuvre par l'intermédiaire du code R suivant.

```
library(glmnet)
library(nnet)
library(caret)

set.seed(8750)
n <- 1000
p <- 200
x <- matrix(rnorm(n*p), nrow=n, ncol=p)
colnames(x) <- paste("v", 1:p, sep="")

y <- rep(0,n)
for (i in 1:n)
{
  p <- exp(sum(x[i,]))/(1+exp(sum(x[i,])))
  y[i] <- sample(c(0,1),1,prob=c(1-p,p))
}

train_rows <- sample(1:n,0.66*n)
x.train <- x[train_rows, ]
x.test <- x[-train_rows, ]
```

```

y.train <- y[train_rows]
y.test <- y[-train_rows]

train <- data.frame(y=y.train,x.train)
test <- data.frame(y=y.test,x.test)

modell <- multinom(y~.,family="binomial",data=train)
# weights: 202 (201 variable)
# initial value 457.477139
# iter 10 value 3.602629
# iter 20 value 1.458515
# iter 30 value 0.921504
# iter 40 value 0.191383
# iter 50 value 0.009916
# iter 60 value 0.001003
# iter 70 value 0.000214
# final value 0.000086
# converged

mean(predict(modell,test)!=as.factor(y.test))
# [1] 0.1647059

model <- glmnet(x.train, as.factor(y.train), family="binomial", alpha=1)
model2 <- train(x.train, as.factor(y.train), method="glmnet", family="binomial",
               metric="Accuracy", trControl=
               trainControl(method="repeatedcv", number=5, repeats=10),
               tuneGrid=data.frame(alpha=1, lambda=model$lambda))
mean(predict(model2,x.test)!=as.factor(y.test))
# [1] 0.1735294

y.star <- rep(0,340)
for (i in 1:340)
{
  p <- exp(sum(x.test[i,]))/(1+exp(sum(x.test[i,])))
  if (p>=1/2) y.star[i] <- 1
}
mean(y.star!=y.test)
# [1] 0.02647059

```

(1)

Examen final
 HMPA 304
 Correction
 5/11/2018

Exercice 1

Nous souhaitons approximer

$$\int_0^1 \left[\frac{\sqrt{x(1-x)}}{e^x + \log(1+x)} \right] dx = I$$

Dans un premier temps, une méthode de Monte Carlo standard est mise en œuvre. En effet,

$$I = \mathbb{E}_{U \sim [0,1]} \left[\frac{\sqrt{X(1-X)}}{e^X + \log(1+X)} \right]$$

On génère 10000 réalisations U_i i.i.d. suivant la loi uniforme U_1, \dots, U_{10000} .

On estime I par

(2)

$$\hat{I}^1 = \frac{1}{10000} \sum_{i=1}^{10000} \left\{ \frac{\sqrt{U_i(1-U_i)}}{e^{U_i} + \log(1+U_i)} \right\}$$

L'écart-type de \hat{I}^1 est également estimé.

Dans un second temps, on remarque que

$$\hat{I} = \mathbb{E}_{\text{Beta}\left(\frac{3}{2}, \frac{3}{2}\right)} \left[\frac{(\Gamma(\frac{3}{2}))^2}{\Gamma(3)} \frac{1}{e^x + \log(1+x)} \right]$$

Puis, on simule 10000 réalisations $\{x_i\}$ suivant une loi $\text{Beta}\left(\frac{3}{2}, \frac{3}{2}\right)$ et on estime I

par

$$\hat{I}^2 = \left[\frac{1}{10000} \sum_{i=1}^{10000} \frac{1}{e^{x_i} + \log(1+x_i)} \right] \frac{\Gamma(\frac{3}{2})^2}{\Gamma(3)}$$

L'écart-type de \hat{I}^2 est également estimé.

2]

sample($C(1,2,3)$, 1, prob = $C(0.6, 0.3, 0.1)$)

3] Voir cours.

Exercice 2

1]

$$f(y; \pi) = \exp \left\{ h \log(\pi) + y \log(1-\pi) \right\} \cdot \frac{\pi^y (1-\pi)^{n-y}}{n!}$$

$$\theta = \log(1-\pi)$$

$$\Rightarrow \pi = 1 - e^\theta$$

$$h(\theta) = -h \log(1 - e^\theta)$$

$$E[y] = h'(\theta) = h \frac{e^\theta}{1 - e^\theta} = h \left(\frac{1-\pi}{\pi} \right)$$

$$V[y] = h''(\theta) = h \frac{e^\theta}{(1 - e^\theta)^2} = h \left(\frac{1-\pi}{\pi^2} \right)$$

3] log(1-π) = β1 + β2 κ

=> 1-π = e^(β1+β2 κ)

=> π = 1 - e^(β1+β2 κ)

=> E[y] = h * [e^(β1+β2 κ) / (1 - e^(β1+β2 κ))]

= J(β1+β2 κ)

J(u) = h * [e^u / (1 - e^u)] = J'(u)

C'est un match linéaire généralisé qui se utilise ainsi que le lim-convexité.

4] L(V(β1, β2))

= h * sum_{i=1}^n log(1 - e^(β1+β2 κi)) + sum_{i=1}^M yi (β1 + β2 κi) + cst

(5)

$$\frac{dL V}{d\beta_2}(\beta_1, \beta_2) = 0$$

$$\Leftrightarrow \sum_{i=1}^m y_i - h \sum_{i=1}^m \left[\frac{e^{\beta_1 + \beta_2 \pi_i}}{1 - e^{\beta_1 + \beta_2 \pi_i}} \right] = 0$$

$$\frac{dL V}{d\beta_2}(\beta_1, \beta_2) = 0$$

$$\Leftrightarrow \sum_{i=1}^m y_i \pi_i - h \sum_{i=1}^m \left[\frac{\pi_i e^{\beta_1 + \beta_2 \pi_i}}{1 - e^{\beta_1 + \beta_2 \pi_i}} \right] = 0$$

Pas de solution analytique.

Exercice 3

On génère un jeu de données contenant 1000 individus, 200 variables prédictives et une variable binaire à expliquer suivant un modèle de régression logistique dont tous les coefficients de variables sont égaux à 1.

On isole 33% des données (6)
comme données de test.

On compare les performances
des classifieurs avec, par
régression logistique classique
et régression logistique avec
régularisation L_1 dont le
paramètre de régularisation est
calibré par validation croisée
à 5 ensembles répétés 10 fois.