

Examen de contrôle continu sans document - 11 octobre 2017

Exercice 1 (3 pts)

Expliquer en quoi consiste une regression ridge ?

Exercice 2 (4 pts)

On considère le modèle de régression suivant, pour tout $i = 1, \dots, n$

$$y_i = ax_i + u_i$$

avec $\mathbb{E}(u_i) = 0$, $\mathbb{V}(u_i) = \sigma_i^2$, $\mathbb{C}(u_i, u_j) = 0$ si $i \neq j$, x_i et a des réels.

Donner les expressions des estimateur des moindres carrés ordinaires et généralisés de a .

Exercice 3 (6 pts)

On considère n variables aléatoires indépendantes y_1, \dots, y_n telles que y_i est distribuée suivant une loi inverse gaussienne de paramètres (μ_i, σ^2) où $\mu_i > 0$ et $\sigma^2 > 0$.

Le terme inverse ne doit pas être mal interprété, la loi est inverse dans le sens suivant : la valeur du mouvement brownien à un temps fixé est de loi normale, à l'inverse, le temps en lequel le mouvement brownien avec une dérive positive atteint une valeur fixée est de loi inverse gaussienne. Nous avons

$$f(y_i; \mu_i, \sigma^2) = \frac{1}{\sqrt{2\pi y_i^3 \sigma}} \exp\left(-\frac{(y_i - \mu_i)^2}{2(\mu_i \sigma)^2 y_i}\right) \mathbf{1}_{y_i > 0}.$$

1 (2 pts) Montrer que la loi inverse gaussienne appartient à la famille exponentielle avec un paramètre de nuisance.

2 (2 pts) Calculer $\mathbb{E}(y_i)$ et $\mathbb{V}(y_i)$.

Pour tout $i = 1, \dots, n$, on suppose que $\log(\mu_i) = a + bx_i$ où $x_i \in \mathbb{R}$ est supposé connu, a et b sont des paramètres inconnus.

3 (2 pts) Montrer qu'il s'agit d'un modèle linéaire généralisé. La fonction de lien canonique a-t-elle été utilisée ?

Exercice 4 (7 pts)

1 (4 pts) Expliquer en détails les procédures mises en oeuvre par l'intermédiaire du code R suivant.

```
n <- 50
x1 <- rnorm(n)
x2 <- rnorm(n)
x3 <- rnorm(n)
u <- rnorm(n,0,sqrt(2))
d <- 30
z <- matrix(runif(n*d),n)
y <- 1+0.5*x1+2*x2-0.2*x3+u
app <- data.frame(y=y,x1=x1,x2=x2,x3=x3,z=z)
names(app)[- (1:4)] <- paste("z",1:30,sep="")

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

library(glmnet)
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))
```

2 (3 pts) Donner le code R permettant de comparer les taux d'erreurs associés aux modèles considérés dans la question précédente. A quel résultat peut-on s'attendre ?

Correction contrôle continu

НППА 304

11/10/2017

①

Exercice 1

Méthode de régularisation en régression
utilisée lorsque $n \approx p$ et éventuellement

$$p > n$$

$\hat{\beta}^\lambda$ est la solution de

$$\min_{\beta \in \mathbb{R}^p} \sum_{i=1}^n (y_i - x_i \beta)^2 \text{ sous contrainte } \sum \beta_j^2 \leq \lambda$$

Diminuer la variance des
estimateurs en introduisant
un peu de biais.

Exercício 2

(2)

$$\hat{\alpha}^{OLS} \in \text{arg} \min_{\alpha \in \mathbb{R}} \sum_{i=1}^m (y_i - \alpha \mu_i)^2$$

$$\hat{\alpha}^{OLS} = \frac{\sum_{i=1}^m \mu_i y_i}{\sum_{i=1}^m \mu_i^2}$$

$$\hat{\alpha}^{GLS} \in \text{arg} \min_{\alpha \in \mathbb{R}} \sum_{i=1}^m \left[\frac{(y_i - \alpha \mu_i)^2}{\sigma_i^2} \right]$$

$$\hat{\alpha}^{GLS} = \frac{\sum_{i=1}^m \frac{\mu_i y_i}{\sigma_i^2}}{\sum_{i=1}^m \frac{\mu_i^2}{\sigma_i^2}}$$

Exercício 3

$$\underline{1)} f(y, \mu, \sigma^2) = \frac{1}{\sqrt{2\pi y^3}} \exp \left\{ -\frac{y^2 - 2y\mu + \mu^2}{2\mu^2 \sigma^2 y} - \frac{1}{2} \log(\sigma^2) \right\} \mathbb{1}_{\{y > 0\}}$$

$$f(y; \mu, \sigma^2) = \exp \left\{ -\frac{y}{2\mu^2\sigma^2} + \frac{1}{\mu\sigma^2} - \frac{1}{2\sigma^2 y} - \frac{1}{2} \log(\sigma^2) \right\} \frac{1}{\sqrt{2\pi y^3}} \mathbb{1}_{\{y > 0\}} \quad (3)$$

$$\theta = -\frac{1}{2\mu^2}, \quad \phi = \sigma^2$$

$$\Rightarrow \mu^2 = \frac{-1}{2\theta} \Rightarrow \mu = \frac{1}{\sqrt{-2\theta}}$$

$$h(\theta) = -\sqrt{-2\theta}$$

$$c(y, \phi) = -\frac{1}{2\phi y} - \frac{1}{2} \log(\phi)$$

↳ Ici inverse gaussienne appartient
 bien à la famille exponentielle.

$$\begin{aligned} \underline{2)} \quad E(y) &= h'(\theta) = \left(-\frac{1}{2}\right) \frac{(-2)}{\sqrt{-2\theta}} \\ &= \frac{1}{\sqrt{-2\theta}} = \mu \end{aligned}$$

$$\begin{aligned}
 V(y) &= \phi b''(\theta) \\
 &= \sigma^2 \frac{-(-2)}{2(-2\theta)\sqrt{-2\theta}} \\
 &= \sigma^2 \mu^3
 \end{aligned}$$

3] $\log(\mu) = a + b\kappa$
 $\Rightarrow E(y) = \mu = e^{a+b\kappa}$

$\Rightarrow E(y) = f(a+b\kappa)$

Il s'agit bien d'un modèle linéaire généralisé

$f(\mu) = e^\mu \neq b'(\mu)$

Ce n'est pas le lien canonique qui a été utilisé -