

Examen de contrôle continu

Durée 1h - Sans document
Vendredi 6 octobre 2023

Exercice 1 (10 pts)

Décrire et commenter les résultats obtenus à l'aide du code R ci-dessous.

```
> library(glmnet)
Loading required package: Matrix
Loaded glmnet 4.1-6
> library(plotmo)
Loading required package: Formula
Loading required package: plotrix
Loading required package: TeachingDemos
> library(caret)
Loading required package: ggplot2
Loading required package: lattice

> set.seed(1974)

> n <- 100
> d <- 50
> X <- matrix(rnorm(n*d),n,d)
> colnames(X) <- paste("x",1:d,sep="")
> y <- as.vector(2+X%*%rep(1,d)+rnorm(n,sd=2))
> training.set <- data.frame(y=y,X)

> Xtest <- matrix(rnorm(n*d),n,d)
> colnames(Xtest) <- paste("x",1:d,sep="")
> ytest <- 2+Xtest%*%rep(1,d)+rnorm(n,sd=2)
> test.set <- data.frame(Xtest)

> yhat <- 2+Xtest%*%rep(1,d)
> sqrt(mean((yhat-ytest)^2))
[1] 2.362255

> model <- lm(y~.,data=training.set)
> yhat <- predict(model,test.set)
> sqrt(mean((yhat-ytest)^2))
[1] 3.513195
```

```

> model <- train(X,y,method="glmnet",metric="RMSE",
+               trControl=trainControl(method="repeatedcv",
+                                       number=n,repeats=10),
+               tuneGrid=data.frame(alpha=0,lambda = seq(0,1,length=50)))
> model
glmnet

100 samples
50 predictor

No pre-processing
Resampling: Cross-Validated (100 fold, repeated 10 times)
Summary of sample sizes: 99, 99, 99, 99, 99, 99, ...

Tuning parameter 'alpha' was held constant at a value of 0
RMSE was used to select the optimal model using the smallest value.
The final values used for the model were alpha = 0 and lambda = 0.

> yhat <- predict(model,test.set)
> sqrt(mean((yhat-ytest)^2))
[1] 3.513195

> y <- as.vector(2+X%%rep(1,d)+rnorm(n,sd=5))
> training.set$y <- y
> ytest <- 2+Xtest%%rep(1,d)+rnorm(n,sd=5)

> yhat <- 2+Xtest%%rep(1,d)
> sqrt(mean((yhat-ytest)^2))
[1] 4.760175

> model <- lm(y~.,data=training.set)
> yhat <- predict(model,test.set)
> sqrt(mean((yhat-ytest)^2))
[1] 6.816788

> model <- train(X,y,method="glmnet",metric="RMSE",
+               trControl=trainControl(method="repeatedcv",
+                                       number=n,repeats=10),
+               tuneGrid=data.frame(alpha=0,lambda = seq(0,20,length=50)))
> model
glmnet

100 samples
50 predictor

No pre-processing
Resampling: Cross-Validated (100 fold, repeated 10 times)
Summary of sample sizes: 99, 99, 99, 99, 99, 99, ...

```

Tuning parameter 'alpha' was held constant at a value of 0
RMSE was used to select the optimal model using the smallest value.
The final values used for the model were alpha = 0 and lambda = 1.632653.

```
> yhat <- predict(model, test.set)
> sqrt(mean((yhat-ytest)^2))
[1] 6.555984
```

Exercice 2 (2 pts)

Expliquer en quoi consiste une regression LASSO.

Exercice 3 (2 pts)

Expliquer la construction de l'estimateur des moindres carrés généralisés.

Exercice 4 (6 pts)

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

$$y_i = \beta_1 + \beta_2 x_i + u_i$$

avec $\mathbb{E}(u_i) = 0$, $\mathbb{V}(u_i) = 1$ si i est pair et $\mathbb{V}(u_i) = 2$ si i est impair, $\mathbb{C}(u_i, u_j) = 0$ si $i \neq j$.
Donner l'expression de l'estimateur des moindres carrés généralisés de β_1 , commenter.

Correction examen partiel
6 octobre 2023
HAX 912X

(1)

Exercice 1

5 points doivent être mentionnés

1) Nous simulons deux jeux de données
un échantillon d'apprentissage
contenant 100 individus et un
échantillon de test contenant
également 100 individus suivant
le modèle de régression ci-dessous

$$y = \beta + \sum_{j=1}^d \alpha_j x_j + \epsilon$$

(2 pts)

$$\epsilon \sim \mathcal{N}(0, 4)$$

$$\alpha_j \sim \mathcal{N}(0, 1) \quad \forall j = 1, \dots, 50$$

Tous les coefficients du modèle de régression hormis la constante sont égaux à 1 - (2)

2) Nous comparons le modèle de régression quantitative moyen de classe multiple = celle du modèle OLS de

où les valeurs des coefficients et la constante sont supposées égales, (2 pts) erreurs qui nous ne pouvons éviter; celle d'un modèle de régression linéaire multiple non régularisé. Lors l'ajout, nous obtenons # 24 et pour le modèle de régression # 3,5 -

3) Un modèle de régression régularisé par contraintes L2 (ridge) est mis en œuvre et utilise une stratégie de validation croisée à 100 ensembles répétées 10 fois - (2 pts)

Il est finalement estimé que la régularisation n'est pas nécessaire $\lambda = 0$. Le risque de l'erreur quadratique moyen est identique à celui de la méthode de régression multiple. (3)

4] Deux nouveaux jeux de données sont simulés suivant le modèle ci-dessous

$$y = \beta_0 + \sum_{j=1}^k \beta_j x_j + \mu$$

$$\text{avec } \mu \sim N(0, 25)$$

$$x_j \sim N(0, 1) \quad \forall j = 1, \dots, 50$$

(2pts)

Le risque de l'erreur quadratique moyen est simulé simultanément avec la régression multiple.

5] Le modèle de régularisation ridge a été comme précédemment simulé légèrement les résultats. (2)

Exercice 2

(4)

Regularisation avec contraintes l_2
On minimise les moindres carrés
sous contrainte $\sum |\beta_j|$ peut être fait.
On introduit ainsi un biais forçant
les coefficients à se rapprocher de 0
et à peine avec restrictions
la variance des estimateurs des
coefficients de régression. Cela
peut engendrer des gains importants
sur l'erreur quadratique moyenne et
donc permettre d'obtenir de meilleures
prédictions.

Exercice 3

Estimateur OLS tient compte de l'hétéroscé-
dasticité des erreurs d'observation.
On minimise en β $(y - X\beta)^T \Sigma^{-1} (y - X\beta)$ -

$$\frac{dh}{d\beta_2}(\beta_1, \beta_2) = -2 \sum_{k=1}^{M/2} \kappa_{2k} (y_{2k} - \beta_1 - \beta_2 \kappa_{2k}) \quad (6)$$

$$- \sum_{k=1}^{M/2} \kappa_{2k-1} (y_{2k-1} - \beta_1 - \beta_2 \kappa_{2k-1})$$

\Leftrightarrow

$$\left\{ \begin{array}{l} \frac{dh}{d\beta_1}(\beta_1, \beta_2) = 0 \\ \frac{dh}{d\beta_2}(\beta_1, \beta_2) = 0 \end{array} \right.$$

$$\left\{ \begin{array}{l} \frac{dh}{d\beta_1}(\beta_1, \beta_2) = 0 \\ \frac{dh}{d\beta_2}(\beta_1, \beta_2) = 0 \end{array} \right.$$

$$\Leftrightarrow \left\{ \begin{array}{l} - \sum_{i=1}^M y_i - \sum_{k=1}^{M/2} y_{2k} + \frac{3M}{2} \beta_1 + \beta_2 \left(\sum_{i=1}^M \kappa_i + \sum_{k=1}^{M/2} \kappa_{2k} \right) = 0 \\ - \sum_{i=1}^M \kappa_i y_i - \sum_{k=1}^{M/2} \kappa_{2k} y_{2k} + \beta_2 \left(\sum_{i=1}^M \kappa_i^2 + \sum_{k=1}^{M/2} \kappa_{2k}^2 \right) + \beta_1 \left(\sum_{i=1}^M \kappa_i + \sum_{k=1}^{M/2} \kappa_{2k} \right) = 0 \end{array} \right.$$

(7)

$$C_y = \sum_{i=1}^m y_i + \sum_{k=1}^{m/2} y_{2k}$$

$$C_{\kappa} = \sum_{i=1}^m \kappa_i + \sum_{k=1}^{m/2} \kappa_{2k}$$

$$C_{\kappa y} = \sum_{i=1}^m \kappa_i y_i + \sum_{k=1}^{m/2} \kappa_{2k} y_{2k}$$

$$C_{\kappa^2} = \sum_{i=1}^m \kappa_i^2 + \sum_{k=1}^{m/2} \kappa_{2k}^2$$

$$\begin{cases} -C_y + \frac{3m}{2} \beta_1 + C_{\kappa} \beta_2 = 0 \\ -C_{\kappa y} + C_{\kappa} \beta_1 + C_{\kappa^2} \beta_2 = 0 \end{cases}$$

$$\Leftrightarrow \begin{cases} \beta_1 = \frac{2(C_y - C_{\kappa} \beta_2)}{3m} \\ -C_{\kappa y} + C_{\kappa} \left[\frac{2(C_y - C_{\kappa} \beta_2)}{3m} \right] + C_{\kappa^2} \beta_2 = 0 \end{cases}$$

$$\Leftrightarrow \begin{cases} \beta_1 = \frac{2(C_y - C_{\kappa} \beta_2)}{3m} \\ \beta_2 = \frac{\frac{3m C_{\kappa} C_y - 2 C_{\kappa} C_y}{3m}}{3m C_{\kappa^2} - 2(C_{\kappa})^2} \cdot 3m \end{cases}$$

$$\Rightarrow \left\{ \begin{array}{l} \beta_2^* = \frac{3m C_{11} \bar{y} - 2 C_{12} C_{11}}{3m C_{12} - 2(C_{11})^2} \\ \beta_1^* = \left[\frac{2(C_{11} \bar{y} - C_{12} \beta_2^*)}{3m} \right] \end{array} \right.$$

(8)

$$\hat{\beta}_1^{PCO} = \frac{2(C_{11} \bar{y} - C_{12} \hat{\beta}_2^{PCO})}{3m}$$

$$\hat{\beta}_1^{PKK} = \frac{2 C_{11} \bar{y}}{3m} - \frac{2 C_{12}}{3m} \hat{\beta}_2^{PCO}$$

$$\hat{\beta}_1^{PCO} = \bar{y} - \pi \hat{\beta}_2^{PCO}$$