

Exercices pour le cours d'Apprentissage et Grande Dimension  
en statistique

February 27, 2017

# 1 Pénalisation, parcimonie et classification linéaire

## 1.1 Méthode LASSO

On se place dans le modèle de régression

$$\mathbf{y} = X\boldsymbol{\beta} + \sigma\xi, \quad \boldsymbol{\beta} \in \mathbb{R}^M$$

où  $\mathbf{y} \in \mathbb{R}^n$  et  $\xi$  est un vecteur gaussien centré de matrice de variance-covariance l'identité (avec les notations du cours).

$$\hat{\boldsymbol{\beta}}_L = \operatorname{argmin}_{\boldsymbol{\beta} \in \mathbb{R}^M} \left( \frac{\|\mathbf{y} - X\boldsymbol{\beta}\|_n^2}{2} + \lambda \|\boldsymbol{\beta}\|_1 \right)$$

1. On suppose l'hypothèse ORT sur la matrice de design, c'est-à-dire  $n^{-1}X^T X = \operatorname{Id}_M$ . Montrer que  $\hat{\boldsymbol{\beta}}_L$  est aussi défini par

$$\hat{\boldsymbol{\beta}}_L = \operatorname{argmin}_{\boldsymbol{\beta} \in \mathbb{R}^M} \left( \frac{\sum_{j=1}^M (z_j - \beta_j)^2}{2} + \lambda \|\boldsymbol{\beta}\|_1 \right)$$

pour un vecteur  $\mathbf{z}$  dépendant de  $\mathbf{y}$  et  $X$  que l'on déterminera

2. En déduire, dans le cas de la question 1 que pour tout  $j \leq M$

$$\hat{\beta}_j^L = \operatorname{sgn}(\hat{\beta}_j)(|\hat{\beta}_j| - \lambda)_+, \quad \text{où } (x)_+ = \max(x, 0)$$

3. Si le design est quelconque. Soit  $X_j$  la  $j$  ième colonne de  $X$  et supposons que  $X_j^t X_j = n$  pour tout  $j \leq M$ . Soit  $F_n(\boldsymbol{\beta}) = \|\mathbf{y} - X\boldsymbol{\beta}\|_n^2 + 2\lambda \|\boldsymbol{\beta}\|_1$ . Montrer que

$$\frac{\partial F_n(\boldsymbol{\beta})}{\partial \beta_j} = -\frac{X_j^t(\mathbf{y} - X\boldsymbol{\beta})}{n} + 2\lambda \frac{\beta_j}{|\beta_j|}$$

4. soit  $\boldsymbol{\beta} \in \mathbb{R}^M$  et  $\boldsymbol{\beta}^{(j)}$  défini par  $\beta_k^{(j)} = \beta_k$  si  $k \neq j$  et

$$\beta_j^{(j)} = R_j \left( 1 - \frac{\tau}{|R_j|} \right)_+, \quad R_j = \frac{1}{n} X_j^t (\mathbf{y} - \sum_{k \neq j} \beta_k X_k)$$

Montrer que  $F_n(\boldsymbol{\beta}^{(j)}) \leq F_n(\boldsymbol{\beta})$  et que si  $\boldsymbol{\beta}^{(j)} \neq \boldsymbol{\beta}$  alors  $F_n(\boldsymbol{\beta}^{(j)}) < F_n(\boldsymbol{\beta})$ . En déduire une possibilité d'algorithme pour minimiser  $F_n$ .

## 1.2 Pénalisation BIC et AIC

On se place dans le modèle de régression

$$\mathbf{y} = \boldsymbol{\theta} + \sigma\xi, \quad \xi = (\xi_1, \dots, \xi_n)^t, \quad \xi_i \stackrel{iid}{\sim} \mathcal{N}(0, \sigma^2)$$

$$\boldsymbol{\theta} = (\theta_1, \dots, \theta_n)^t.$$

1. Calculer l'estimateur de maximum de vraisemblance en  $\boldsymbol{\theta}$  en supposant  $\sigma$  connu. Quel est l'estimateur de  $\sigma$  si  $\sigma$  est supposé inconnu? Pourquoi cela pose-t-il problème?

2. Considérons le modèle indexé par  $\gamma \in \{0, 1\}^n$  tel que  $\theta_i = 0$  si  $\gamma_i = 0$ . Pour tout  $\gamma \in \{0, 1\}^n$  calculer le maximum de vraisemblance dans ce modèle.

3. En supposant  $\sigma$  connu, pour tout  $r \in \{0, \dots, n\}$  et tout  $\gamma \in \{0, 1\}^n$  tel que  $\sum_{i=1}^n \gamma_i = r$ , soit

$$BIC(\gamma) = \ell_n(\hat{\theta}_\gamma, \gamma) - \frac{r}{2} \log n, \quad \text{où}$$

$\ell_n(\theta, \gamma)$  est la vraisemblance dans le modèle  $\gamma$  et  $\hat{\theta}_\gamma$  le maximum de vraisemblance associé. Montrer que

$$BIC(\gamma) \leq -\frac{\sum_{i=1}^{n-r} y_{(i)}^2}{2\sigma^2} - \frac{r}{2} \log n := C(r), \quad y_{(1)}^2 \leq y_{(2)}^2 \leq \dots \leq y_{(n)}^2$$

4. Supposons que le vrai paramètre de la loi de  $\mathbf{y}$  soit  $\boldsymbol{\theta} = (0, \dots, 0)$ . Montrer qu'avec une probabilité tendant vers 1,

$$C(0) \geq C(1)$$

5. Montrer que le résultat est faux si le BIC est remplacé par

$$AIC(\gamma) = \ell_n(\hat{\theta}_\gamma, \gamma) - 2r$$

### 1.3 Classification linéaire

Considérons un problème de classification à 2 classes  $\{1, 2\}$  basé sur des données  $\{(y_i, x_i)_{i=1}^n$ . On notera  $n_1$  la taille de la population dans la classe 1 et  $n_2$  celle de la classe 2. on considèrera une approche par analyses discriminantes linéaires pour lesquelles  $\hat{\pi}_1 = n_1/n$  et  $\hat{\pi}_2 = n_2/n$ .

1. Ecrire la résolution par l'analyse discriminante linéaire construite à partir des estimateurs des moments
2. Ecrire la résolution par l'analyse discriminante linéaire construite à partir du maximum de vraisemblance
3. Soit  $\hat{\sigma}^2 = [\sum_{i:y_i=1} (x_i - \bar{x}_1)^2 + \sum_{i:y_i=2} (x_i - \bar{x}_2)^2]/(n-2)$  et  $\hat{\sigma}_b^2 = n_1 n_2 (\bar{x}_1 - \bar{x}_2)^2$ . Montrer que l'estimateur  $\hat{\beta}$  des moindres carrés associé à  $\sum_i (y_i - \beta_0 - x_i \beta)^2$  vérifie

$$[(n-2)\hat{\sigma}^2 + n\hat{\sigma}_b^2]\hat{b} = n(\bar{x}_2 - \bar{x}_1)$$

et qu'il existe une constante  $c$  telle que

$$\hat{\beta} = c\hat{\sigma}^{-2}(\bar{x}_2 - \bar{x}_1)$$

### 1.4 Contrôle du risque

On suppose que la loi  $P$  du couple  $(X, Y)$  est donnée de la manière suivante:  $Y \sim \mathcal{B}(p)$  pour un paramètre  $p \in ]0, 1[$  puis  $X \in \mathbb{R}^d$  est donné par sa loi conditionnelle sachant  $Y$ :

$$X|Y \sim \mathcal{N}(\mu_Y, \Sigma)$$

où  $\Sigma$  est une matrice définie positive et  $\mu_0, \mu_1$  sont deux vecteurs distincts de  $\mathbb{R}^d$ .

1. Déterminer la fonction de régression

$$\eta(x) = E(Y|X = x).$$

2. En déduire la forme du classifieur de Bayes,  $g^*$ , et montrer que son risque de classification s'écrit

$$R^* = pP\left[Z > \delta/2 + \delta^{-1} \log\left(\frac{p}{1-p}\right)\right] + (1-p)P\left[Z < -\delta/2 + \delta^{-1} \log\left(\frac{p}{1-p}\right)\right]$$

où  $\delta = \|\Sigma^{-1/2}(\mu_1 - \mu_0)\|$  et  $Z \sim \mathcal{N}(0, 1)$ .

3. En pratique, on dispose d'un  $n$ -échantillon  $(X_i, Y_i)$ ,  $1 \leq i \leq n$ , de la loi  $P$ . On suppose que l'on est dans un cas où l'on connaît  $p$  et  $\Sigma$  et on se propose d'estimer  $\mu_0$  et  $\mu_1$  par maximum de vraisemblance. Donner la forme des estimateurs  $\hat{\mu}_0$  et  $\hat{\mu}_1$  ainsi obtenus.
4. En déduire un estimateur de la fonction de régression,  $\hat{\eta}$  et une règle de classification,  $\hat{g}$ .
5. Montrer que  $R(\hat{g}) \rightarrow R^*$  en probabilité, quand  $n \rightarrow \infty$ .
6. Montrer que  $\hat{g}$  n'est pas universellement consistante. Il suffira de fabriquer une autre loi  $P'$  telle que si  $(X_i, Y_i)$  et  $(X, Y)$  sont iid de loi  $P'$ , alors  $R(\hat{g})$  ne converge pas vers  $R^*$ .

## 2 Minimisation du risque empirique

### 2.1 Dictionnaire fini et inégalité de Hoeffding

Soit  $\mathcal{G} = \{f_1, \dots, f_p\}$  une famille finie de classifieurs. Soit, avec la notation habituelle,  $\mathcal{D}_n = ((X_1, Y_1), \dots, (X_n, Y_n))$  un famille de couples aléatoires i.i.d. de loi  $P$ . Soit  $\widehat{R}_n$  le risque empirique. Soit  $\hat{g}$  la règle de minimisation du risque empirique.

1. Ecrire le risque théorique  $R(f_j)$  pour chaque  $f_j$  ainsi que le risque empirique  $\widehat{R}_n(f_j)$ .
2. En utilisant l'inégalité de Markov, montrer que pour tout  $t > 0$ , pour tout  $j \in \{1, \dots, p\}$ ,

$$P \left[ R(f_j) - \widehat{R}_n(f_j) > t \right] \leq \frac{R(f_j)(1 - R(f_j))}{nt^2}.$$

3. En déduire que

$$P \left[ R(\hat{g}) - \inf_{1 \leq i \leq p} R(f_i) \leq \sqrt{\frac{p}{n\varepsilon}} \right] \geq 1 - \varepsilon$$

et

$$E \left[ R(\hat{g}) - \inf_{1 \leq i \leq p} R(f_i) \right] \leq 2\sqrt{p/n}.$$

4. Comparer avec le résultat obtenu en cours où l'on utilisait l'inégalité de Hoeffding.
5. Montrer que s'il existe un  $j$  tel que  $R(f_j) = 0$ , on a

$$P \left[ R(\hat{g}) - \inf_{1 \leq i \leq p} R(f_i) \leq \frac{1}{n} \log(p/\varepsilon) \right] \geq 1 - \varepsilon.$$

Donner la majoration qui en découle pour  $E[R(\hat{g}) - \inf_{1 \leq i \leq p} R(f_i)]$ .

### 2.2 Dictionnaire dénombrable et inégalité de Hoeffding

Soit  $\mathcal{G} = \{f_j : j \in \mathbb{N}\}$  une famille dénombrable de classifieurs. Soit  $\mathcal{D}_n = ((X_1, Y_1), \dots, (X_n, Y_n))$  un famille de couples aléatoires i.i.d. de loi  $P$ . Soit  $\widehat{R}_n$  le risque empirique. Enfin, soient  $p_j > 0$  des réels tels que

$$\sum_{j=0}^{\infty} p_j = 1.$$

1. En utilisant l'inégalité de Hoeffding, montrer que:

$$P \left[ \forall j, R(f_j) - \widehat{R}_n(f_j) \leq \sqrt{\frac{\log\left(\frac{2}{p_j\varepsilon}\right)}{2n}} \right] \geq 1 - \frac{\varepsilon}{2}.$$

2. On suppose qu'il existe  $\tilde{j} \in \mathbb{N}^*$  tel que

$$\inf_{j \geq 0} R(f_j) = R(f_{\tilde{j}}).$$

Montrer que la règle de classification

$$\hat{g} = f_{\hat{j}}(\cdot) \text{ où } \hat{j} \in \arg \min_{j \in \mathbb{N}} \left( \hat{R}_n(f_j) + \sqrt{\frac{\log\left(\frac{2}{p_j \epsilon}\right)}{2n}} \right)$$

satisfait pour tout  $\epsilon > 0$  :

$$P \left[ R(\hat{g}) - R(f_{\tilde{j}}) \leq \sqrt{\frac{\log\left(\frac{2}{p_{\tilde{j}} \epsilon}\right)}{2n}} + \sqrt{\frac{\log\left(\frac{2}{\epsilon}\right)}{2n}} \right] \geq 1 - \epsilon.$$