

## TD 12

*Les questions marquées d'un astérisque (\*) sont facultatives.*

**Exercice 1. (Lasso slow rates)** Soient  $n$  et  $d$  deux entiers naturels strictement positifs. Considérons le modèle linéaire  $Y = X\beta^* + \varepsilon$  où  $Y \in \mathbb{R}^n$  et  $\beta^* \in \mathbb{R}^d$ , ainsi que l'estimateur Lasso  $\hat{\beta} \in \arg \min_{\beta \in \mathbb{R}^d} (\|Y - X\beta\|_2^2 + \lambda_n \|\beta\|_1)$ , où  $\lambda_n$  est un réel strictement positif.

1. Montrer que  $\|X(\hat{\beta} - \beta^*)\|_2^2 \leq 2|\varepsilon^\top X(\hat{\beta} - \beta^*)| + \lambda_n(\|\beta^*\|_1 - \|\hat{\beta}\|_1)$ .

*Indication : utiliser que  $\hat{\beta}$  minimise le critère du Lasso. En particulier, il est meilleur que tous les autres  $\beta$  possibles.*

2. Montrer que  $|\varepsilon^\top X(\hat{\beta} - \beta^*)| \leq \|X^\top \varepsilon\|_\infty \|\hat{\beta} - \beta^*\|_1 \leq \|X^\top \varepsilon\|_\infty (\|\hat{\beta}\|_1 + \|\beta^*\|_1)$ .

3. En déduire que si  $\lambda_n \geq 2\|X^\top \varepsilon\|_\infty$ , alors  $\|X(\hat{\beta} - \beta^*)\|_2^2 \leq 2\lambda_n \|\beta^*\|_1$ .

*Application.* On suppose à présent que les  $n$  coordonnées de  $\varepsilon$  sont des variables i.i.d. de loi  $\mathcal{N}(0, \sigma^2)$ . On suppose qu'il existe une constante  $c$  telle que, en notant  $X_{.j}$  la  $j$ -ième colonne de la matrice  $X$ , on ait  $\max_{1 \leq j \leq d} \|X_{.j}\|_2 \leq c\sqrt{n}$ .

4. Montrer que si  $\|X\|_\infty \leq c$ , alors la condition  $\max_{1 \leq j \leq d} \|X_{.j}\|_2 \leq c\sqrt{n}$  est satisfaite.

5. Quelle est la loi de  $X_{.j}^\top \varepsilon$  ?

6. Soit  $a > 0$ . Trouver  $t$  tel que  $\mathbb{P}(|X_{.j}^\top \varepsilon| \geq t) \leq \frac{2}{dn^a}$ .

*Indication : admettez l'inégalité de concentration suivante : si  $Z \sim \mathcal{N}(0, \sigma^2)$ , alors pour tout  $x > 0$ ,  $\mathbb{P}(|Z| \geq x) \leq 2 \exp\left(\frac{-x^2}{2\sigma^2}\right)$ .*

7. Toujours avec le même  $a$ , en déduire un  $t$  tel que  $\mathbb{P}(\|X^\top \varepsilon\|_\infty \geq t) \leq \frac{2}{n^a}$ .

8. En déduire qu'avec probabilité au moins  $1 - 2/n^a$ ,

$$\frac{1}{n} \|X(\hat{\beta} - \beta^*)\|_2^2 \leq 4\sqrt{2}\sigma c \|\beta^*\|_1 \sqrt{\frac{\log d + a \log n}{n}}.$$

**Exercice 2.** Soient  $\mu \in \mathbb{R}$ ,  $\sigma > 0$  et  $\theta \sim \mathcal{N}(\mu, \sigma^2)$ . On observe  $X_1, \dots, X_n$  i.i.d. de loi  $\mathcal{N}(\theta, 1)$  (on suppose donc la variance des  $X_i$  sachant  $\theta$  connue).

1. Quelle est la loi a posteriori de  $\theta$  ?
2. Calculer un estimateur du maximum a posteriori de  $\theta$ .
3. Donner un intervalle de crédibilité de niveau  $1 - \alpha$  de  $\theta$ .

**Exercice 3. (Régression linéaire et Ridge, cadre bayésien)**

1. Etant donné un paramètre (aléatoire)  $\theta$  suivant une loi de densité  $p$  et des observations  $X = (X_1, \dots, X_n)$  telles que conditionnellement à  $\theta$ ,  $X$  a pour densité  $x \mapsto q(x|\theta)$ , montrer que l'estimateur du maximum a posteriori de  $\theta$  maximise

$$\theta \mapsto \log q(X|\theta) + \log p(\theta).$$

Considérons le modèle suivant. Soient  $a, \sigma > 0$ . Comme loi *a priori*, on suppose  $\beta \sim \mathcal{N}(0, a^2 I_d)$ . On observe la matrice  $X$  de taille  $n \times d$  et le vecteur  $Y = X\beta + \varepsilon \in \mathbb{R}^n$  avec  $\varepsilon \sim \mathcal{N}(0, \sigma^2 I_n)$  indépendant de  $\beta$ .

2. Montrer que l'estimateur du maximum a posteriori minimise la fonction

$$\beta \mapsto \frac{1}{\sigma^2} \|Y - X\beta\|_2^2 + \frac{1}{a^2} \|\beta\|_2^2.$$

3. En déduire que l'estimateur du maximum a posteriori correspond à l'estimateur Ridge pour un paramètre de régularisation à préciser.
4. Que se passe-t-il quand  $a \rightarrow 0$  ? Quand  $a \rightarrow \infty$  ? Commenter.
5. (\*) Quelle est la loi a posteriori de  $\beta$  ?