

Contrôle : Statistique pour les big data

Patrick Tardivel,
Université de Bourgogne

Quelques rappels

Soit $X \in \mathbb{R}^{n \times p}$, $y \in \mathbb{R}^n$ et $\lambda > 0$, l'ensemble $S_{X,\lambda,\|\cdot\|_1}(y)$ des solutions LASSO est défini par

$$S_{X,\lambda,\|\cdot\|_1}(y) := \underset{b \in \mathbb{R}^p}{\operatorname{Argmin}} \frac{1}{2} \|y - Xb\|_2^2 + \lambda \|b\|_1.$$

On rappelle que $\hat{\beta} \in S_{X,\lambda,\|\cdot\|_1}(y)$ si et seulement si l'une des caractérisations suivantes est satisfaite

$$\|X^T(y - X\hat{\beta})\|_\infty \leq \lambda \text{ et } \forall i \in \operatorname{supp}(\hat{\beta}), X_i^T(y - X\hat{\beta}) = \lambda \operatorname{sign}(\hat{\beta}_i) \Leftrightarrow \|X^T(y - X\hat{\beta})\|_\infty \leq \lambda \text{ et } \hat{\beta}^T X^T(y - X\hat{\beta}) = \lambda \|\hat{\beta}\|_1.$$

Exercice 1 (questions de cours)

1. Soit $z \in \mathbb{R}$, on considère la fonction

$$f : t \in \mathbb{R} \mapsto \frac{1}{2}(z - t)^2 + \lambda |t|$$

En quel point la fonction f atteint son minimum ? Pour la preuve, on pourra sans perte de généralité supposer que $z > 0$.

Soit $y \in \mathbb{R}^p$ et $X \in \mathbb{R}^{n \times p}$. Lorsque $X = I_p$, rappeler (sans justifier), l'expression explicite de la solution du problème LASSO :

$$S_{I_p,\lambda,\|\cdot\|_1}(y) := \underset{b \in \mathbb{R}^n}{\operatorname{argmin}} \frac{1}{2} \|y - b\|_2^2 + \lambda \|b\|_1$$

Lorsque X est une matrice telle que $X^T X = I_p$, rappeler (sans justifier), l'expression explicite de la solution du problème LASSO $S_{X,\lambda,\|\cdot\|_1}(y)$.

2. Soit $X \in \mathbb{R}^{n \times p}$, $y \in \mathbb{R}^n$, $\lambda > 0$ et $\hat{\beta}$ un élément arbitraire de $S_{X,\lambda,\|\cdot\|_1}(y)$. On pose $\hat{r} = y - X\hat{\beta}$. Montrer que \hat{r} est la solution du problème suivant

$$\hat{r} = \underset{r \in \mathbb{R}^n}{\operatorname{argmin}} \|y - r\|_2 \text{ sous la contrainte } \|X^T r\|_\infty \leq \lambda.$$

3. Soit $Z \in \mathbb{R}^{n \times p}$ une matrice dont les coefficients sont iid $\mathcal{N}(0,1)$ et $x^* \in \mathbb{R}^p$ tel que $\|x^*\|_0 = k$. Pour chacun des cas suivant justifier si la probabilité que x^* soit identifiable relativement à Z et la norme ℓ_1 est proche de 0 ou proche 1.

a) Lorsque $k = 100$, $n = 500$ et $p = 2000$.

b) Lorsque $k = 600$, $n = 1000$ et $p = 2000$.

Pour cette question on pourra utiliser la courbe de transition de Donoho-Tanner donnée ci-dessous :

Exercice 2 Soit $A \in \mathbb{R}^{2 \times 3}$ la matrice

$$A := \begin{pmatrix} 1 & 0 & 2/3 \\ 0 & 1 & 2/3 \end{pmatrix}.$$





FIGURE 1 – Courbe de transition de Donoho-Tanner

1. Tracer sur la boule unité de la norme N_A définie par

$$\forall b \in \mathbb{R}^2, N_A(b) := \min\{\|x\|_1 : Ax = b\}.$$



2. On considère un vecteur $x = (x_1, x_2, x_3)$ tel que $x_1 > 0, x_2 > 0$ et $x_3 = 0$. Est-ce que x est identifiable relativement à A et à la norme ℓ_1 ?

3. On considère un vecteur $x = (x_1, x_2, x_3)$ tel que $x_1 > 0, x_2 < 0$ et $x_3 = 0$. Est-ce que x est identifiable relativement à A et à la norme ℓ_1 ?

Le but du problème suivant est de démontrer la Proposition 1 issue de l'article [1]. Cette proposition propose une méthode simple pour identifier certaines composantes nulles du LASSO.

Proposition 1 (Méthode de dépistage des zéros) Soit $X = (X_1 | \dots | X_p) \in \mathbb{R}^{n \times p}$, $y \in \mathbb{R}^n$ tel que $\|X^T y\|_\infty \neq 0$, $\lambda > 0$ tel que $\lambda < \|X^T y\|_\infty$ et $\hat{\beta}$ une solution LASSO de $S_{X, \lambda, \|\cdot\|_1}(y)$. Si l'inégalité suivante est satisfaite :

$$|X_j^T y| < \lambda \left(1 + \frac{\|X_j\|_2 \|y\|_2}{\|X^T y\|_\infty} \right) - \|X_j\|_2 \|y\|_2$$

alors $\hat{\beta}_j = 0$.

Problème : méthode de dépistage des zéros

Soit $X = (X_1 | \dots | X_p) \in \mathbb{R}^{n \times p}$, $y \in \mathbb{R}^n$ tel que $\|X^T y\|_\infty \neq 0$, $\lambda > 0$ tel que $\lambda < \|X^T y\|_\infty$ et $\hat{\beta} \in S_{X, \lambda, \|\cdot\|_1}(y)$. On pose $\hat{r} = y - X\hat{\beta}$ et on rappelle que

$$\hat{r} := \underset{r \in \mathbb{R}^n}{\operatorname{argmin}} \|y - r\|_2 \text{ sous la contrainte } \|X^T y\|_\infty \leq \lambda. \quad (1)$$

1. En utilisant le vecteur $r_0 = \lambda y / \|X^T y\|_\infty$ et l'expression (1) montrer l'inégalité suivante :

$$\|y - \hat{r}\|_2 \leq \left(1 - \frac{\lambda}{\|X^T y\|_\infty} \right) \|y\|_2.$$

2. Soit $a \in \mathbb{R}^n, b \in \mathbb{R}^n$ et $\gamma \geq 0$. Montrer que l'on a l'égalité suivante

$$\sup\{|a^T v| : \|b - v\|_2 \leq \gamma\} = |a^T b| + \|a\|_2 \gamma$$

3. En prenant $\gamma = \left(1 - \frac{\lambda}{\|X^T y\|_\infty} \right) \|y\|_2$ dans la question 2) et en utilisant la question 1), montrer que

$$|X_j^T \hat{r}| \leq |X_j^T y| + \|X_j\|_2 \|y\|_2 \left(1 - \frac{\lambda}{\|X^T y\|_\infty} \right).$$

4. En utilisant la question 3), montrer que si

$$|X_j^T y| < \lambda \left(1 + \frac{\|X_j\|_2 \|y\|_2}{\|X^T y\|_\infty} \right) - \|X_j\|_2 \|y\|_2$$

alors $\hat{\beta}_j = 0$.

Références

[1] Laurent El Ghaoui, Vivian Viallon, and Tarek Rabbani. Safe feature elimination for the lasso and sparse supervised learning problems. *arXiv preprint arXiv :1009.4219*, 2010.