

Chapitre 3 : Problème d'optimisation de LASSO

Le problème LASSO (Least Absolute Shrinkage & Selection Operator) a été introduit par Chen & Dunnett (1994) et par Tibshirani (1996).

Définition: (LASSO) → méthode de MoC pénalisée

Soit $X \in \mathbb{R}^{n \times p}$ et $y \in \mathbb{R}^n$ et $\lambda > 0$. L'ensemble des solutions du problème d'optimisation LASSO est,

$$S_{\lambda, \lambda}(x) = \operatorname{Argmin}_{b \in \mathbb{R}^p} \left\{ \frac{1}{2} \|y - Xb\|_2^2 + \lambda \|b\|_1 \right\}.$$

↳ souvent utile en stats. ↳ variable réponse

Proposition: Soit $X \in \mathbb{R}^{n \times p}$, $y \in \mathbb{R}^n$ et $\lambda > 0$, alors,

i) l'ensemble $S_{\lambda, \lambda}(x)$ est non-vide.

ii) Il existe $\hat{\beta} \in S_{\lambda, \lambda}(x)$ tel que $\|\hat{\beta}\|_0 \leq \operatorname{rg}(X)$

↳ Lorsque $p \gg n$
 $\hat{\beta}$ a au moins $p-n$ 0

Proposition: (Valeurs ajustées LASSO)

Soit $X \in \mathbb{R}^{n \times p}$, $y \in \mathbb{R}^n$, $\lambda > 0$ et $S_{\lambda, \lambda}(y)$ l'ens. des solutions du problème LASSO.

Si $\hat{\beta} \in S_{\lambda, \lambda}(y)$ et $\tilde{\beta} \in S_{\lambda, \lambda}(y)$ alors $X\hat{\beta} = X\tilde{\beta}$
et $\|\hat{\beta}\|_1 = \|\tilde{\beta}\|_1$.

↳ Preuve: Montrons que $X\hat{\beta} = X\tilde{\beta}$

Supposons que $X\hat{\beta} \neq X\tilde{\beta}$. Comme la fonction $y \in \mathbb{R}^n \mapsto \|u\|^2$ est strictement convexe alors en posant $\beta^0 = \frac{\hat{\beta} + \tilde{\beta}}{2}$ en a, $\|y - X\beta^0\|_2^2 = \left\| \frac{1}{2}(y - X\hat{\beta}) + \frac{1}{2}(y - X\tilde{\beta}) \right\|_2^2$

Par conséquent, puisque $\|\beta^0\|_1 \leq \frac{1}{2}\|\hat{\beta}\|_1 + \frac{1}{2}\|\tilde{\beta}\|_1$

On en déduit,

ineq triang. $\frac{1}{2}\|y - X\beta^0\|_2^2 + \lambda\|\beta^0\|_1$

$< \frac{1}{2} \left(\underbrace{\frac{1}{2}\|y - X\hat{\beta}\|_2^2 + \lambda\|\hat{\beta}\|_1}_{(1)} + \frac{1}{2}\|y - X\tilde{\beta}\|_2^2 + \lambda\|\tilde{\beta}\|_1}_{(2)} \right)$

Ce qui implique que β^0 est soit strictement inférieur au premier terme (1) soit au deuxième (2), ce qui signifierait $\hat{\beta} \notin S_{\lambda, \lambda}(y)$ ou $\tilde{\beta} \notin S_{\lambda, \lambda}(y)$.

et ainsi par contradiction en a, $X\hat{\beta} = X\tilde{\beta}$. Par conséquent, comme $\frac{1}{2}\|y - X\hat{\beta}\|_2^2 + \lambda\|\hat{\beta}\|_1 = \frac{1}{2}\|y - X\tilde{\beta}\|_2^2 + \lambda\|\tilde{\beta}\|_1$.

On en déduit $\|\hat{\beta}\|_1 = \|\tilde{\beta}\|_1$. \square

colonnes 2 à 2 \perp

I / Expression explicite du LASSO où X orthogonal

Lemme: (opérateur proximal)

Soit $y \in \mathbb{R}^p$. la fonction $f: b \in \mathbb{R} \mapsto \frac{1}{2}\|y - b\|_2^2 + \lambda\|b\|_1$ atteint son minimum en un unique point.

$$\hat{\beta} = \begin{pmatrix} \text{sign}(y_1)(|y_1| - \lambda)_+ \\ \vdots \\ \text{sign}(y_p)(|y_p| - \lambda)_+ \end{pmatrix}$$

↳ Preuve:

On a,
$$\frac{1}{2} \|y - b\|_2^2 + \lambda \|b\|_1 = \sum_{i=1}^p \left(\frac{1}{2} (y_i - b_i)^2 + \lambda |b_i| \right)$$

On peut se restreindre à $p=1$, pour $b \neq 0$ on a,

$$f'(b) = \begin{cases} b - y + \lambda & b > 0 \\ b - y - \lambda & b < 0 \end{cases}$$

• Distinction de cas: $f'(b) = 0 \Leftrightarrow \begin{cases} b = y - \lambda \\ b = y + \lambda \end{cases}$

* Si $y < -\lambda$: (1^{er} cas)

b	$-\infty$	$y + \lambda$	0	$+\infty$
$f'(b)$	$-$	0	$+$	$+$
$f(b)$	↘ ↗			

Donc $\hat{\beta} = y + \lambda = -(|y| - \lambda) = \text{sign}(y)(|y| - \lambda)_+$

* Si $-\lambda \leq y \leq \lambda$: (2^e cas)

b	$-\infty$	0	$+\infty$
$f'(b)$	$-$	0	$+$
$f(b)$	↘ ↗		

Alors, $\hat{\beta} = 0 = \text{sign}(y)(|y| - \lambda)_+$

* Si $y > \lambda$: (3^e cas)

b	$-\infty$	0	$y - \lambda$	$+\infty$
$f'(b)$	$-$	0	$-$	$+$
$f(b)$	↘ ↗			

ainsi on obtient, $\hat{\beta} = y - \lambda = \text{sign}(y) (|y| - \lambda)_+$. \square

Corollaire: Soit $X = (X_1 | \dots | X_p) \in \mathbb{R}^{n \times p}$ telle que ${}^t X X = I_d_p$, $y \in \mathbb{R}^n$ et $\lambda > 0$.

L'unique élément de $S_{\lambda, 2}(y)$ est,

$$\hat{\beta} = \begin{pmatrix} \text{sign}({}^t X_1 y) (|{}^t X_1 y| - \lambda)_+ \\ \vdots \\ \text{sign}({}^t X_p y) (|{}^t X_p y| - \lambda)_+ \end{pmatrix}$$

↳ Preuve: On pose $\sigma = {}^t X y = ({}^t X_1 y | \dots | {}^t X_p y)$.

$$\begin{aligned} \text{On a, } \|y - Xb\|_2^2 &= \|y - X\sigma + X\sigma - Xb\|_2^2 \\ &= \|y - X\sigma\|_2^2 + \|X\sigma - Xb\|_2^2 \\ &\quad + 2({}^t (y - X\sigma)(X\sigma - Xb)) \end{aligned}$$

$$\begin{aligned} \text{Comme, } {}^t (y - X\sigma)(X\sigma - Xb) &= \underbrace{{}^t X y}_{=\sigma} - \underbrace{{}^t X X \sigma}_{=I \cdot \sigma} (\sigma - b) \\ &= 0. \end{aligned}$$

On en déduit que,

$$\|y - Xb\|_2^2 = \|y - X\sigma\|_2^2 + \underbrace{\|X\sigma - Xb\|_2^2}_{=\|\sigma - b\|_2^2}$$

Finalement, la fonction $b \in \mathbb{R}^p \mapsto \frac{1}{2} \|y - Xb\|_2^2 + \lambda \|b\|_1$ atteint son minimum au même point que la fonction précédente $b \in \mathbb{R}^p \mapsto \frac{1}{2} \|\sigma - b\|_2^2 + \lambda \|b\|_1$ d'où, d'après le lemme précédent.

$$\hat{\beta} = (\text{sign}(\sigma_1)(|\sigma_1 - \lambda|)_+, \dots, \text{sign}(\sigma_p)(|\sigma_p - \lambda|)_+) \quad \square$$

II / Caractérisation des solutions du LASSO

Proposition: Soit $X = (X_1 | \dots | X_p) \in \mathbb{R}^{n \times p}$, $y \in \mathbb{R}^n$
et $\lambda > 0$.

Les assertions suivantes sont équivalentes :

- i) $\hat{\beta} \in \delta_{X, \lambda}(y)$
- ii) $\begin{cases} \|{}^t X(y - X\hat{\beta})\|_{\infty} \leq \lambda \\ {}^t X_i(y - X\hat{\beta}) = \lambda \text{sign}(\hat{\beta}_i) \quad \forall i \in \text{supp}(\hat{\beta}) \end{cases}$
- iii) $\begin{cases} \|{}^t X(y - X\hat{\beta})\|_{\infty} \leq \lambda \\ {}^t \hat{\beta} {}^t X(y - X\hat{\beta}) = \lambda \|\hat{\beta}\|_1. \end{cases}$

Caractère: Soit $X \in \mathbb{R}^{n \times p}$ et $\lambda > 0$,

alors $\delta_{X, \lambda}(y) = \{0\}$ si et seulement si $\|{}^t X y\|_{\infty} \leq \lambda$

↳ Preuve:

• Existence:

⇒) Supposons que $\hat{\beta} = 0 \in \delta_{X, \lambda}(y)$, alors,

$$\|{}^t X(y - \underbrace{X\hat{\beta}}_0)\|_{\infty} \leq \lambda \Leftrightarrow \|{}^t X y\|_{\infty} \leq \lambda$$

⇐) Inversement, si $\|{}^t X y\| \leq \lambda$ alors $\begin{cases} \|{}^t X(y - X0)\|_{\infty} \leq \lambda \\ {}^t 0 {}^t X(y - X0) = \lambda \|0\|_1 \end{cases}$

Donc $0 \in \mathcal{D}_{X,\lambda}(y)$

• Unicité: Si $\hat{\beta} \in \mathcal{D}_{X,\lambda}(y)$ alors $\|\hat{\beta}\|_1 = 0$
donc $\hat{\beta} = 0$ et ainsi $\mathcal{D}_{X,\lambda}(y) = \{0\}$ \square

Exercice: $X = \begin{pmatrix} 1 & 0 & 2/3 \\ 0 & 1 & 2/3 \end{pmatrix}$, $y = \begin{pmatrix} 2 \\ 2 \end{pmatrix}$ et $\lambda = 1$

Montrons que $\hat{\beta} = {}^t(0, 0, \frac{15}{8}) \in \mathcal{D}_{X,\lambda}(y)$.

On rappelle que $\hat{\beta}$ doit vérifier,

$$\begin{cases} \|{}^t X(y - X\hat{\beta})\|_{\infty} \leq 1 \\ {}^t X_i (y - X\hat{\beta}) = \lambda \operatorname{sign}(\hat{\beta}_i) \quad \forall i \in \operatorname{supp}(\hat{\beta}) \end{cases}$$

On a,
$$\begin{pmatrix} 0 & 1 \\ 1 & 0 \\ \frac{2}{3} & \frac{2}{3} \end{pmatrix} \begin{pmatrix} 2 \\ 2 \end{pmatrix} - \begin{pmatrix} 1 & 0 & 2/3 \\ 0 & 1 & 2/3 \end{pmatrix} \begin{pmatrix} 0 \\ 0 \\ \frac{15}{8} \end{pmatrix} = \frac{1}{4} \begin{pmatrix} 3 \\ 3 \\ 4 \end{pmatrix}$$

$\underbrace{\begin{pmatrix} 5/4 \\ 5/4 \end{pmatrix}}_{\begin{pmatrix} 3/4 \\ 3/4 \end{pmatrix}}$

Donc, $\| \frac{1}{4} \begin{pmatrix} 3 \\ 3 \\ 4 \end{pmatrix} \|_{\infty} = 1 \leq 1$

et ${}^t \hat{\beta} \begin{pmatrix} 1 \\ 4 \end{pmatrix} \begin{pmatrix} 3 \\ 3 \\ 4 \end{pmatrix} = \frac{15}{8} = \underbrace{1}_{\lambda} \times \underbrace{\| \begin{pmatrix} 0 \\ 0 \\ \frac{15}{8} \end{pmatrix} \|_1}_{\|\hat{\beta}\|_1}$

Donc $\hat{\beta} \in \mathcal{D}_{X,\lambda}(y)$.

III / Condition nécessaire et suffisante pour l'unicité de LASSO.

Proposition: (condition suffisante pour l'unicité)

Soit $X \in \mathbb{R}^{n \times p}$ telle que $\text{Ker}(X) = \{0\}$ alors pour tout $y \in \mathbb{R}^n$ et tout $\lambda > 0$, $S_{X,\lambda}(y) = \{0\}$.

Preuve: La fonction $b \in \mathbb{R}^p \mapsto \frac{1}{2} \|y - Xb\|_2^2$ est strictement convexe.

En effet, $\text{Hess} f(b) = {}^t X X$ est définie positive.

ainsi la fonction $\phi : b \in \mathbb{R}^{n \times p} \mapsto \frac{1}{2} \|y - Xb\|_2^2 + \lambda \|b\|_1$ est strictement convexe donc $S_{X,\lambda}(y)$ est un singleton.

□.

Proposition: (condition nécessaire et suffisante pour l'unicité)

Soit $X \in \mathbb{R}^{n \times p}$, il existe $y \in \mathbb{R}^n$, il existe $\lambda > 0$ tel que $S_{X,\lambda}(y)$ n'est pas un singleton si et seulement si $\text{Im}({}^t X)$ coupe une face de $[-1; 1]^p$ dont la dimension est strictement inférieure à $\dim(\text{Ker}(X))$.

Remarque: Lorsque $\text{Ker}(X) = \{0\}$ alors $\text{Im}({}^t X)$ ne coupe pas une face de $[-1; 1]^p$ dont la dimension est strictement inférieure à $\dim(\text{Ker}(X)) = 0$.

Donc pour tout $y \in \mathbb{R}^n$, $\forall \lambda > 0$, $S_{X,\lambda}(y)$ est un singleton.

IV - Chemin des solutions de LASSO.

Proposition: (Chemin des solutions de LASSO)

Soit $X \in \mathbb{R}^{n \times p}$ et $y \in \mathbb{R}^n$,

- i) Le chemin des valeurs ajustées du LASSO, $\lambda \mapsto X \hat{\beta}(\lambda)$, où $\hat{\beta} \in S_{X,\lambda}(y)$ est une fonction affine et continue par morceaux.
- ii) Pour tout $\lambda > 0$, on suppose que $S_{X,\lambda}(y)$ a un unique élément $\hat{\beta}(\lambda)$ alors le chemin des solutions du LASSO $\lambda \mapsto \hat{\beta}(\lambda)$ est continue et affine par morceaux.

V / Relation entre LASSO et poursuite de base

Proposition: (relation entre LASSO et poursuite de base)

Soit $X \in \mathbb{R}^{n \times p}$,

- i) Soit $y \in \mathbb{R}^n$, $\lambda > 0$ un élément $\hat{\beta} \in S_{X,\lambda}(y)$ est identifiable relativement à X et à la norme ℓ_1 .
- ii) Soit $y \in \text{Im}(X)$. Pour tout $\lambda > 0$ et pour tout $\hat{\beta} \in S_{X,\lambda}(y)$, $\|\hat{\beta}\|_1 \leq N_X(y)$.
- iii) Supposons que $\text{Im}(X)$ ne coupe pas une face de $[-1; 1]^p$ (dont la dim est $< \dim(\text{Ker}(X))$)

Si $y \in \text{Im}(X)$ alors la fonction $\lambda > 0 \mapsto \hat{\beta}(\lambda)$, où $\hat{\beta}$ est l'unique élément de $S_{X,\lambda}(y)$, converge lorsque $\lambda \rightarrow 0$ vers l'unique solution du pb $P\beta$ $X\beta = y$.

VI / Problème d'optimisation lié au LASSO.

Proposition : (Tibshirani et al 2002)

Soit $X \in \mathbb{R}^{n \times p}$, $\lambda > 0$ et $\hat{\beta} \in S_{X,\lambda}(y)$.


On pose $\hat{r} = y - X\hat{\beta}$ (appelés résidus de LASSO), alors

$$\hat{r} = \operatorname{argmin} \|y - r\|_2 \text{ s.c. } \|{}^t X r\|_\infty \leq \lambda$$

Preuve: Comme $\hat{\beta} \in S_{X,\lambda}(y)$ alors

$$\lambda \geq \|{}^t X (y - X\hat{\beta})\|_\infty = \|{}^t X \hat{r}\|_\infty \quad (\text{contrainte satisf.})$$

Montrons que la projection de y sur l'ensemble convexe fermé $\{r \in \mathbb{R}^n : \|{}^t X r\|_\infty \leq \lambda\}$ vaut \hat{r} .



Soit $z \in \mathbb{R}^n : \|{}^t X z\| \leq \lambda$ alors,


$$\begin{aligned} {}^t (y - \hat{r})(z - \hat{r}) &= {}^t \hat{\beta} {}^t X (z - \hat{r}) \\ &= {}^t \hat{\beta} {}^t X z - {}^t \hat{\beta} {}^t X \hat{r} \\ &= {}^t \hat{\beta} {}^t X z - \underbrace{{}^t \hat{\beta} {}^t X (y - X\hat{\beta})}_{\lambda \|\hat{\beta}\|_1} \\ &\leq \underbrace{\|\hat{\beta}\|_1}_{\leq \lambda} \underbrace{\|{}^t X z\|_\infty}_{\leq \lambda} - \lambda \|\hat{\beta}\|_1 \\ &\leq \lambda \|\hat{\beta}\|_1 - \lambda \|\hat{\beta}\|_1 = 0 \end{aligned}$$

□

Exemple: $X = \begin{pmatrix} 1 & 0 & 2/3 \\ 0 & 1 & 2/3 \end{pmatrix}$, $y = \begin{pmatrix} 2 \\ 2 \end{pmatrix}$ et $\lambda = 1$

On rappelle que $\hat{\beta} = (0, 0, 15/8) \in \mathcal{S}_{\lambda, \lambda}(y)$.
 La projection de y sur $\{x \in \mathbb{R}^2 : \|{}^t X x\|_{\infty} \leq \lambda\}$
 vaut $\hat{x} = y - X\hat{\beta} = \begin{pmatrix} 3/4 \\ 3/4 \end{pmatrix}$

$$\|{}^t X x\|_{\infty} \leq \lambda \Leftrightarrow \begin{cases} |x_1| \leq \lambda \\ |x_2| \leq \lambda \\ |\frac{2}{3}x_1 + \frac{2}{3}x_2| \leq \lambda \end{cases} \Leftrightarrow \begin{cases} -\lambda \leq x_1 \leq \lambda \\ -\lambda \leq x_2 \leq \lambda \\ -\lambda \leq (*) \leq \lambda \end{cases}$$



Exercice: $X = (X_1 | X_2 | X_3) = \begin{pmatrix} 1 & 1 & 2 \\ 1 & -1 & 0 \end{pmatrix}$
 $y = \begin{pmatrix} 0.6 \\ 1.2 \end{pmatrix}$ et $\lambda = 1$

On commence par chercher $\|{}^t X r\|_{\infty} \leq \lambda$,

$$\begin{cases} |x_1 + x_2| \leq \lambda \\ |-x_1 + x_2| \leq \lambda \\ |2x_1| \leq \lambda \end{cases} \Leftrightarrow \begin{cases} -1 \leq x_1 + x_2 \leq 1 \\ -1 \leq -x_1 + x_2 \leq 1 \\ -\frac{1}{2} \leq x_1 \leq \frac{1}{2} \end{cases}$$




Figure : Polyèdre nul du LASSO

Graphiquement on observe que ,

$$* \hat{x}_1 + \hat{x}_2 = {}^t X \hat{u} = \lambda \quad \text{donc } \hat{\beta}_1 \geq 0$$

↳ \hat{u} sur le bord $x_1 + x_2 = \lambda$

$$* |\hat{x}_1 - \hat{x}_2| = |{}^t X_2 \hat{u}| = |{}^t X_2 (y - X \hat{\beta})| < \lambda$$

↳ \hat{u} n'est pas sur le bord :
 $x_1 - x_2 = \pm \lambda$

donc $\hat{\beta}_2 = 0$.

$$* |2x_1| = |{}^t X_3 \hat{u}| = |{}^t X_3 (y - X \hat{\beta})| < \lambda$$

donc $\hat{\beta}_3 = 0$.

Déterminons $\hat{\beta}_1$:

$$\begin{aligned} 1 = \lambda &= {}^t X_1 (y - X \hat{\beta}) = {}^t X_1 (y - \hat{\beta}_1 X_1) \\ &= {}^t X_1 y - \hat{\beta}_1 {}^t X_1 X_1 = 1,8 - 2\hat{\beta}_1 \end{aligned}$$

d'où $\hat{\beta}_1 = 0,4$


ainsi, $\hat{\beta} = \begin{pmatrix} 0,4 \\ 0 \\ 0 \end{pmatrix}$.

Exercice : $X = \begin{pmatrix} 2 & 1 \end{pmatrix}$ $y = 1$ et $\lambda = 1$

Déterminer $S_{X,\lambda}(y)$:

On cherche α tq $\|{}^t X \alpha\|_{\infty} \leq \lambda = 1$,

$$\begin{cases} -1 \leq 2\alpha \leq 1 \\ -1 \leq \alpha \leq 1 \end{cases}$$



On observe que $|2\hat{\alpha}| = |{}^t X_1 \hat{\alpha}| = |{}^t X_1 (y - X \hat{\beta}_1)| = \lambda$
donc $\hat{\beta}_1 \geq 0$

et $|\hat{\alpha}| = |{}^t X_2 \hat{\alpha}| = |{}^t X_2 (y - X \hat{\beta}_2)| < \lambda$

donc $\hat{\beta}_2 = 0$.

On détermine $\hat{\beta}_1$:

$$\begin{aligned} 1 = \lambda &= {}^t X_1 (y - X \hat{\beta}) = {}^t X_1 y - \hat{\beta}_1 {}^t X_1 X_1 \\ \Leftrightarrow 1 &= 2 - \hat{\beta}_1 4 \Leftrightarrow \hat{\beta}_1 = \frac{1}{4} \end{aligned}$$

On obtient $\tilde{\beta} = \begin{pmatrix} 1/4 \\ 0 \end{pmatrix}$.