

Le Lasso

Le gradient proximal

S.Canu
APPS ITI /INSA de Rouen Normandie

23 octobre 2023

Le Lasso

- Données
 - ▶ $X \in \mathbb{R}^{n \times p}$ les p variables observées n fois
 - ▶ $y \in \mathbb{R}^n$ la variable réponse
- Inconnues
 - ▶ $\beta \in \mathbb{R}^p$
- hypothèses : pas de biais (pas de terme constant)
 - ▶ $\text{mean}(X) = 0$
 - ▶ $\|X_j\|^2 = 1$
 - ▶ $\text{mean}(y) = 0$

le cout pénalisé

$$J_\lambda(\beta) = \frac{1}{2} \|X\beta - y\|^2 + \lambda \|\beta\|_1 ,$$

Les conditions d'optimalité

$$0 \in \partial J_\lambda(\beta) = X^\top (X\beta - y) + \lambda \partial(\|\beta\|_1) ,$$

idée 1 : Le proximal L1

$$\text{prox}_{l_1}(w, \lambda) = \underset{u}{\text{argmin}} \quad \lambda \|u\|_1 + \frac{1}{2} \|u - w\|^2$$

$$\text{prox}_{l_1}(w, \lambda) = \text{sign}(w) \max(|w| - \lambda, 0)$$

idée 2 : la linéarisation

$$\begin{aligned} J : \mathbb{R}^p &\longrightarrow \mathbb{R} \\ \mathbf{x} &\longmapsto J(\mathbf{x}) \end{aligned}$$

Développement de Taylor au premier ordre

$$J(\beta) = J(\beta^0) + (\beta - \beta^0)^t \nabla_{\beta} J(\beta^0) + o(\|\beta - \beta^0\|)$$

$$\begin{aligned} J(\beta) &= J(\beta^0) + (\beta - \beta^0)^t \nabla_{\beta} J(\beta^0) + o(\|\beta - \beta^0\|) \\ \frac{1}{2} \|\mathbf{X}\beta - \mathbf{y}\|^2 &= \frac{1}{2} \|\mathbf{X}\beta^0 - \mathbf{y}\|^2 + (\beta - \beta^0)^t \mathbf{X}^t (\mathbf{X}\beta^0 - \mathbf{y}) + o(\|\beta - \beta^0\|) \end{aligned}$$

Développement de Taylor au second ordre

$$J(\beta) = J(\beta^0) + (\beta - \beta^0)^t \nabla_{\beta} J(\beta^0) + \frac{1}{2} (\beta - \beta^0)^t H(\beta^0) (\beta - \beta^0) + o(\|\beta - \beta^0\|^2)$$

idée 3 : la méthode de la région de confiance

Pour un β^0 donné

$$\begin{aligned} \min_{\beta} \quad & \frac{1}{2} \|X\beta - y\|^2 + \lambda \|\beta\|_1, \\ \text{avec} \quad & \|\beta - \beta^0\|^2 \leq \varepsilon \end{aligned}$$

$$\min_{\beta} \frac{1}{2} \|X\beta - y\|^2 + \lambda \|\beta\|_1 + \frac{1}{2t} (\|\beta - \beta^0\|^2 - \varepsilon)$$

idée 3 : la méthode de la région de confiance

Pour un β^0 donné

$$\begin{aligned} \min_{\beta} \quad & \frac{1}{2} \|X\beta - y\|^2 + \lambda \|\beta\|_1, \\ \text{avec} \quad & \|\beta - \beta^0\|^2 \leq \varepsilon \end{aligned}$$

$$\min_{\beta} \frac{1}{2} \|X\beta - y\|^2 + \lambda \|\beta\|_1 + \frac{1}{2t} (\|\beta - \beta^0\|^2 - \varepsilon)$$

idée 2+idée 3

Pour un β^0 donné

$$\min_{\beta} \frac{1}{2} \|X\beta - y\|^2 + \lambda \|\beta\|_1 + \frac{1}{2t} (\|\beta - \beta^0\|^2 - \varepsilon)$$

$$\begin{aligned} J(\beta) = \frac{1}{2} \|X\beta - y\|^2 &= J(\beta^0) + (\beta - \beta^0)^t \nabla_{\beta} J(\beta^0) \\ &= \frac{1}{2} \|X\beta^0 - y\|^2 + (\beta - \beta^0)^t X^t (X\beta^0 - y) \end{aligned}$$

$$\min_{\beta} (\beta - \beta^0)^t X^t (X\beta^0 - y) + \lambda \|\beta\|_1 + \frac{1}{2t} \|\beta - \beta^0\|^2$$

$$\min_{\beta} \lambda \|\beta\|_1 + \frac{1}{2t} \|\beta - \beta^0 + tX^t(X\beta^0 - y)\|^2$$

idée 2+idée 3+idée 1

Pour un β^0 donné

$$\min_{\beta} t\lambda\|\beta\|_1 + \frac{1}{2}\|\beta - \beta^0 + tX^t(X\beta^0 - y)\|^2$$

$$\begin{aligned} \min_{\beta} \quad & t\lambda\|\beta\|_1 + \frac{1}{2}\|\beta - v\|^2 \\ \text{avec} \quad & v = \beta^0 - tX^t(X\beta^0 - y) \end{aligned}$$

L'algorithme du gradient proximal

Pour un β^0 donné

$$t = \frac{1}{\|X^t X\|}$$

Tant qu'on n' pas convergé....

$$\begin{aligned} v &= \beta^k - tX^t(X\beta^k - y) \\ \beta^{k+1} &= \arg \min_{\beta} t\lambda\|\beta\|_1 + \frac{1}{2}\|\beta - v\|^2 \end{aligned}$$

Comment choisir t ?

J est gradient Lipschitz s'il existe une constante $0 < L$ telle que, $\forall \beta, \beta^0$

$$\|\nabla_{\beta} J(\beta) - \nabla_{\beta} J(\beta^0)\| \leq L \|\beta - \beta^0\|$$

Choix de t : argument de convergence


Si

$$t \leq \frac{1}{L}$$

L'algorithme du gradient proximal converge

```
stepsize = 1/np.linalg.norm(X.T@X)
```

Quadratic upper bound from Lipschitz property



- affine lower bound from convexity

$$g(y) \geq g(x) + \nabla g(x)^T (y - x) \quad \forall x, y$$

- quadratic upper bound from Lipschitz property

$$g(y) \leq g(x) + \nabla g(x)^T (y - x) + \frac{L}{2} \|y - x\|_2^2 \quad \forall x, y$$