

Exercice 1

$$\hat{\beta}_1(\lambda) \in \underset{\beta \in \mathbb{R}^d}{\operatorname{argmin}} \left\{ \|Y - X\beta\|_2^2 + \lambda h(\beta) \right\} \quad (1)$$

$$\hat{\beta}_2(t) \in \underset{\beta \in \mathbb{R}^d : h(\beta) \leq t}{\operatorname{argmin}} \|Y - X\beta\|_2^2 \quad (2)$$

Soit $\lambda \geq 0$, posons $t = h(\hat{\beta}_1(\lambda))$.

h peut être soit $\beta \mapsto \|\beta\|_2^2$
soit $\beta \mapsto \|\beta\|_1$
soit $\beta \mapsto \|\beta\|_0$.

1) Par définition, $h(\hat{\beta}_2(t)) \leq t = h(\hat{\beta}_1(\lambda))$

Et comme $h(\hat{\beta}_1(\lambda)) \leq t$,

$$\|Y - X\hat{\beta}_2(t)\|_2^2 \leq \|Y - X\hat{\beta}_1(\lambda)\|_2^2.$$

2) Par conséquent, $\|Y - X\hat{\beta}_2(t)\|_2^2 + \lambda h(\hat{\beta}_2(t)) \leq \|Y - X\hat{\beta}_1(\lambda)\|_2^2 + \lambda h(\hat{\beta}_1(\lambda))$

or $\hat{\beta}_1(\lambda)$ est un minimiseur de $\beta \mapsto \|Y - X\beta\|_2^2 + \lambda h(\beta)$

$$\text{donc } \|Y - X\hat{\beta}_2(t)\|_2^2 + \lambda h(\hat{\beta}_2(t)) = \|Y - X\hat{\beta}_1(\lambda)\|_2^2 + \lambda h(\hat{\beta}_1(\lambda))$$

donc $\hat{\beta}_2(t)$ est aussi un minimiseur de $\beta \mapsto \|Y - X\beta\|_2^2 + \lambda h(\beta)$, donc est solution de (1).

3) D'après 2), $\|Y - X\hat{\beta}_2(t)\|_2^2 + \lambda h(\hat{\beta}_2(t)) = \|Y - X\hat{\beta}_1(\lambda)\|_2^2 + \lambda h(\hat{\beta}_1(\lambda))$

$$\begin{aligned} h(\hat{\beta}_2(t)) &\leq h(\hat{\beta}_1(\lambda)) \\ \|\hat{\beta}_2(t)\|_2^2 &\leq \|\hat{\beta}_1(\lambda)\|_2^2 \end{aligned}$$


donc

$$\|Y - X\hat{\beta}_2(t)\|_2^2 = \|\hat{\beta}_1(\lambda)\|_2^2 \text{ et } h(\hat{\beta}_2(t)) = h(\hat{\beta}_1(\lambda))$$

donc

$\hat{\beta}_1(\lambda)$ est une solution de (2).

illustration
de (2)



(R)

$$\begin{aligned} \|Y - X\beta\|_2^2 &= \|Y - X\hat{\beta}_1(\lambda)\|_2^2 \\ &\quad + \|\hat{\beta}_1(\lambda) - \beta\|_2^2 \end{aligned}$$

Bilan: Les solutions de (1) sont solution de (2) et vice-versa, pourvu que t soit bien choisi.

Exercice 2

1) a) $\hat{\beta}^{LS}$ minimise $\beta \mapsto \|Y - X\beta\|_2^2 = (Y - X\beta)^T(Y - X\beta) = Y^T Y - Y^T(X\beta) - (X\beta)^T Y + (X\beta)^T(X\beta)$
 $= \|Y\|_2^2 - 2Y^T X + \beta^T X^T X$

Le gradient de cette fonction en β est $-2Y^T X + 2\beta^T X^T X = -2(Y - X\beta)^T X$


Comme $\hat{\beta}^{LS}$ minimise cette fonction et que cette fonction est C^1 sur \mathbb{R}^d , le gradient s'annule en $\hat{\beta}^{LS}$, c.-à-d.:


$$(Y - X\hat{\beta}^{LS})^T X = 0.$$

b) $\|Y - X\beta\|_2^2 = \|Y - X\hat{\beta}^{LS} + X\hat{\beta}^{LS} - X\beta\|_2^2 = \|Y - X\hat{\beta}^{LS}\|_2^2 + \|X\hat{\beta}^{LS} - X\beta\|_2^2 + 2 \langle Y - X\hat{\beta}^{LS}, X\hat{\beta}^{LS} - X\beta \rangle$

or $\langle Y - X\hat{\beta}^{LS}, X\hat{\beta}^{LS} - X\beta \rangle = (Y - X\hat{\beta}^{LS})^T X (\hat{\beta}^{LS} - \beta) = 0$.
= 0 (1a)

On vient de remettre une version du théorème de Pythagore: $X\hat{\beta}^{LS}$ est le projeté orthogonal de Y sur $\{X\beta, \beta \in \mathbb{R}^d\}$





c) * si $f: R^n \rightarrow R$ est convexe, $Y \in R^n$ et $X \in R^{n \times d}$, alors $\beta \mapsto f(Y - X\beta)$ est aussi convexe

$$(f(Y - X(t\beta_1 + (1-t)\beta_2)) = f(t(Y - X\beta_1) + (1-t)(Y - X\beta_2))$$

* Si $f: R^d \rightarrow R_+$ est convexe alors $\beta \mapsto f(\beta)^2$ est aussi convexe.

$$f(t\beta_1 + (1-t)\beta_2)^2 \leq (tf(\beta_1) + (1-t)f(\beta_2))^2 \stackrel{\text{convexité de } x \mapsto x^2}{\leq} t f(\beta_1)^2 + (1-t) f(\beta_2)^2$$

\uparrow *f convexe $x \mapsto x^2$ croissante sur R_+*

$$* \beta \mapsto \|X\beta\|_2^2 \text{ est convexe : } \|t\beta_1 + (1-t)\beta_2\|_2^2 \leq \|t\beta_1\|_2^2 + \|(1-t)\beta_2\|_2^2 = t\|\beta_1\|_2^2 + (1-t)\|\beta_2\|_2^2. \quad \text{I.T. même}$$

Donc $\beta \mapsto \|X\beta\|_2^2$ est convexe
puis $\beta \mapsto \|Y - X\beta\|_2^2$ est convexe.

Indications: - Si f, g convexes, alors $f+g$ convexe
Si g strictement convexe et f convexe alors $f \circ g$ strictement convexe) écrire la définition

- Si f continue, strictement convexe, et $f(x) \xrightarrow[\|x\| \rightarrow +\infty]{} +\infty$ $f: R^n \rightarrow R$

$$\left\{ x \in R^n : f(x) \leq \inf_{x' \in R^n} f(x') + 1 \right\} \text{ est borné} \quad (\text{car } f(x) \xrightarrow[\|x\| \rightarrow +\infty]{} +\infty)$$

on 0 si $\inf_{x' \in R^n} f(x') = -\infty$

c'est aussi un fermé (car f continue) donc c'est un compact.

Comme f continue, f atteint son minimum sur cet ensemble, et par définition de cet ensemble c'est un minimum global (sur R^n).

Si ce minimum est atteint en x et x' avec $x \neq x'$ alors pour tout $t \in (0,1)$,

$$f(tx + (1-t)x') \stackrel{\text{strict}}{\leq} tf(x) + (1-t)f(x') = \inf_{x'' \in R^n} f(x'') \leq f(tx + (1-t)x') \quad \text{impossible.}$$

Donc le minimum est unique.

- Si $A \in R^{d \times d}$ est inversible et $f: R^d \rightarrow R$ strictement convexe alors $\beta \mapsto f(A\beta)$ est strictement convexe.

$\beta \mapsto \|X\beta\|_2^2$ est strictement convexe.

Montrer que $\beta \mapsto \|Y - X\beta\|_2^2$ est strictement convexe revient à montrer que $\beta \mapsto \|X(\beta - \tilde{\beta})\|_2^2$ est strictement convexe (par 1.b)

donc à montrer que $\beta \mapsto \|X\beta\|_2^2$ est strictement convexe
 $= \beta^T X^T X \beta$

Décomposition en valeurs singulières de X : $X = U^T \sum_{i=1}^n \sigma_i V_i$ donc $X^T X = V^T \begin{pmatrix} \sigma_1^2 & 0 \\ 0 & \ddots \\ 0 & 0 \end{pmatrix} V$

$$\|V^T V\|^2 = V^T V = I \Rightarrow \|V^T V\| = \sqrt{\sigma_1^2 + \dots + \sigma_n^2} = \sqrt{\|X\|^2}$$

(σ_i i-ème valeur singulière de X)

$$\|X\beta\|_2^2 = \beta^T X^T X \beta = \beta^T V^T \begin{pmatrix} \sigma_i^2 & 0 \\ 0 & \sigma_j^2 \end{pmatrix} V \beta = \left\| \begin{pmatrix} \sigma_i^2 & 0 \\ 0 & \sigma_j^2 \end{pmatrix} V \beta \right\|_2^2$$

(si $\sigma_i \neq 0$ pour tout i , c.à.d. $X^T X$ définie positive / inversible)

Donc $\beta \mapsto \|Y - X\beta\|_2^2$ strictement convexe dès que $X^T X$ définie positive.

2) Comme $\beta \mapsto \|\beta\|_2^2$ est strictement convexe, $\beta \mapsto d \|\beta\|_2^2$ est strictement convexe dès que $d > 0$
et $\beta \mapsto \|Y - X\beta\|_2^2$ est convexe, donc $\beta \mapsto \|Y - X\beta\|_2^2 + d \|\beta\|_2^2$ est strictement convexe (et continue),
donc son minimum est atteint en un unique point: l'estimation Ridge.

3) Lorsque $X^T X$ est définie positive, $\beta \mapsto \|Y - X\beta\|_2^2$ est strictement convexe.
 $\beta \mapsto d \|\beta\|_2^2$ est convexe
donc $\beta \mapsto \|Y - X\beta\|_2^2 + d \|\beta\|_2^2$ est strictement convexe (et continue) donc son minimum
est atteint en un unique point: l'estimation Lasso.

