

TD N° 2 : Optimisation sous contraintes

EXERCICE 1. Résoudre le problème suivant :

$$\begin{aligned} \min_{(x_1, x_2, x_3) \in \mathbb{R}^3} & \frac{1}{2} [(x_1 - 2)^2 + (x_2 - 2)^2 + (x_3 - 2)^2] \\ \text{s.c.} & \quad x_1 + x_2 + x_3 = 1 \end{aligned} \quad (1)$$

EXERCICE 2.

On prend $y \in \mathbb{R}^n$, $X \in \mathbb{R}^{n \times p}$ avec $\text{rg}(X) = p$, $R \in \mathbb{R}^{q \times p}$ avec $\text{rg}(R) = q$ et enfin $r \in \mathbb{R}^q$. On définit les moindres carrés sous contraintes de la manière suivante :

$$\begin{aligned} \hat{\beta}^c \in \arg \min_{\beta \in \mathbb{R}^p} & \frac{1}{2} \|y - X\beta\|^2 \\ \text{s.c.} & \quad R\beta = r \end{aligned}$$

1) Montrer qu'avec $\hat{\beta}^{\text{LS}}$ solution des moindres carrés (non contraints), on obtient :

$$\hat{\beta}^c = \hat{\beta}^{\text{LS}} + (X^\top X)^{-1} R^\top \left[R (X^\top X)^{-1} R^\top \right]^{-1} (r - R\hat{\beta}^{\text{LS}})$$

2) Montrer de plus que sous l'hypothèse gaussienne de modèle de régression linéaire classique :

$$\frac{1}{q\sigma^2} (R(\hat{\beta}^{\text{LS}} - \beta^*))^\top \left[R (X^\top X)^{-1} R^\top \right]^{-1} R(\hat{\beta}^{\text{LS}} - \beta^*) \sim \mathcal{F}_{n-p}^q$$

où \mathcal{F}_{n-p}^q est une loi de Fisher.

3) Montrer que $(R\hat{\beta}^{\text{LS}} - r)^\top \left[R (X^\top X)^{-1} R^\top \right]^{-1} (R\hat{\beta}^{\text{LS}} - r) = \|\hat{y}^{\text{LS}} - \hat{y}^c\|^2$, et que $\|\hat{y}^{\text{LS}} - \hat{y}^c\|^2 = \|y - \hat{y}^c\|^2 - \|\hat{y}^{\text{LS}} - y\|^2$ où $\hat{y}^{\text{LS}} = X\hat{\beta}^{\text{LS}}$ et $\hat{y}^c = X\hat{\beta}^c$.

4) Prendre $X = [\mathbf{1}_{C_1}, \dots, \mathbf{1}_{C_K}]$, et en déduire un test de l'hypothèse " $\mu_1 = \dots = \mu_K$ " dans l'ANOVA à un facteur.

EXERCICE 3. Soit $X = \left[\frac{\mathbf{1}_{C_1}}{\sqrt{n_1}}, \dots, \frac{\mathbf{1}_{C_K}}{\sqrt{n_K}} \right]$ (avec $\mathbf{x}_k = \frac{\mathbf{1}_{C_k}}{\sqrt{n_k}}$), avec $\hat{\mu}_k = \frac{1}{n_k} \sum_{i \in C_k} y_i$ et $n_k = \#\{i \in C_k, i \in \llbracket 1, n \rrbracket\}$ avec $n_1 + \dots + n_K = n$, et on suppose que les C_k forment une partition de $\llbracket 1, n \rrbracket$.

On propose l'estimateur suivant :

$$(\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_K)^\top = \arg \min_{\beta_0, \dots, \beta_K} \frac{1}{2} \left\| \mathbf{y} - \beta_0 \mathbf{1}_n - \sum_{j=1}^K \beta_j \mathbf{x}_j \right\|^2 + \frac{\lambda}{2} \sum_{j=1}^K \beta_j^2$$

- 1) Donner la valeur de $X^\top X$ et de $X^\top y$.
- 2) Donner une formule explicite pour l'estimateur Ridge, en fonction de $y, \hat{\mu}_1, \dots, \hat{\mu}_K$, et des n_1, \dots, n_K .
- 3) Comparer avec l'estimateur Ridge classique obtenu en forçant la contrainte $\beta_0 = 0$.

EXERCICE 4. On observe K classes C_1, \dots, C_K et n observations d'un phénomène (*e.g.*, le rendement de la variété) sont consignées. On fait l'hypothèse que les classes C_k sont disjointes et forment une partition

des observations : $\cup_{k=1}^K C_k = \llbracket 1, n \rrbracket$ et $\forall (k, k') \in \llbracket 1, K \rrbracket, C_k \cap C_{k'} = \emptyset$. Enfin on suppose que la cardinalité de chaque classe C_k est n_k , et donc que $n = \sum_{k=1}^K n_k$.

Le modèle linéaire associé peut s'écrire de la façon suivante : on définit les α_k , coefficients qui correspondent au niveau d'influence de la k^e classe

$$y = \underbrace{\begin{bmatrix} \mathbb{1}_n & \mathbb{1}_{C_1} & \dots & \mathbb{1}_{C_K} \end{bmatrix}}_X \underbrace{\begin{bmatrix} \mu \\ \alpha_1 \\ \vdots \\ \alpha_K \end{bmatrix}}_{\beta} + \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_K \end{bmatrix} .$$

Donner alors l'estimateur des moindres carrés sous contraintes associé :

$$\min_{\beta \in \mathbb{R}^{K+1}} \frac{1}{2} \|y - X\beta\|^2 ,$$

$$\text{t.q. } \beta = (\mu, \alpha_1, \dots, \alpha_K)^\top \text{ et } \sum_{k=1}^K c_k \alpha_k = 0 ,$$

où le vecteur $c = (c_1, \dots, c_K)^\top \in \mathbb{R}^K$ est un vecteur encodant les contraintes choisies tel que $\sum_{k=1}^K c_k \neq 0$.

EXERCICE 5. Soit $X = \left[\frac{\mathbb{1}_{C_1}}{\sqrt{n_1}}, \dots, \frac{\mathbb{1}_{C_K}}{\sqrt{n_K}} \right]$ (avec $\mathbf{x}_k = \frac{\mathbb{1}_{C_k}}{\sqrt{n_k}}$), avec $\hat{\mu}_k = \frac{1}{n_k} \sum_{i \in C_k} y_i$ et $n_k = \#\{i \in C_k, i \in \llbracket 1, n \rrbracket\}$ avec $n_1 + \dots + n_K = n$.

L'estimateur Lasso (sans pénalité sur la constante) est solution de

$$(\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_K)^\top = \arg \min_{\beta_0, \dots, \beta_K} \frac{1}{2} \left\| \mathbf{y} - \beta_0 \mathbb{1}_n - \sum_{j=1}^K \beta_j \mathbf{x}_j \right\|_2^2 + \lambda \sum_{j=1}^K |\beta_j|$$

- 1) Donner la valeur de $X^\top X$ et de $X^\top y$
- 2) Donner une formule explicite pour l'estimateur Lasso, en fonction de $y, \hat{\mu}_1, \dots, \hat{\mu}_K$, et des n_1, \dots, n_K .