

# TD 1 : Introduction à l'optimisation

Optimisation pour l'apprentissage automatique, M2 Big Data

23 novembre 2021



## Exercice 1 : Moindres carrés linéaires

On considère un jeu de données de la forme  $\{(\mathbf{x}_i, y_i)\}_{i=1}^n$ , où chaque  $\mathbf{x}_i$  est un vecteur de  $\mathbb{R}^d$  et chaque  $y_i$  appartient à  $\mathbb{R}$ . On cherche un modèle linéaire qui explique les données, que l'on obtient en considérant le problème :

$$\underset{\mathbf{w} \in \mathbb{R}^d}{\text{minimiser}} f(\mathbf{w}) := \frac{1}{2} \|\mathbf{X}\mathbf{w} - \mathbf{y}\|^2 = \frac{1}{2} \sum_{i=1}^n (\mathbf{x}_i^T \mathbf{w} - y_i)^2, \quad (1)$$

où  $\mathbf{X} \in \mathbb{R}^{n \times d}$  et  $\mathbf{y} \in \mathbb{R}^n$  concatènent les données, c'est-à-dire que

$$\mathbf{X} = \begin{bmatrix} \mathbf{x}_1^T \\ \vdots \\ \mathbf{x}_n^T \end{bmatrix}, \quad \mathbf{y} = \begin{bmatrix} y_1 \\ \vdots \\ y_n \end{bmatrix}.$$

Ce problème est un des plus classiques en analyse de données; sa fonction objectif est de classe  $\mathcal{C}^2$ , et on peut montrer qu'il possède toujours au moins une solution.

- Supposons que  $\mathbf{w}^*$  vérifie  $\mathbf{X}\mathbf{w}^* = \mathbf{y}$  (c'est donc une solution du système linéaire  $\mathbf{X}\mathbf{w} = \mathbf{y}$ ). Justifier que  $\mathbf{w}^*$  est alors un minimum global du problème.
- Le gradient de  $f$  en  $\mathbf{w} \in \mathbb{R}^d$  est donné par  $\nabla f(\mathbf{w}) = \mathbf{X}^T(\mathbf{X}\mathbf{w} - \mathbf{y})$ . Si  $\mathbf{w}^*$  est un minimum local de  $f$ , que vaut  $\nabla f(\mathbf{w}^*)$  ?
- La matrice hessienne de  $f$  en  $\mathbf{w} \in \mathbb{R}^d$  est donnée par  $\nabla^2 f(\mathbf{w}) = \mathbf{X}^T \mathbf{X}$ . Elle est donc constante et définie par les données du problème.
  - On a toujours  $\mathbf{X}^T \mathbf{X} \succeq \mathbf{0}$ . Quelle propriété sur  $f$  cela implique-t-il ?
  - On suppose que  $\mathbf{X}^T \mathbf{X} \succeq \mu \mathbf{I}_d$  avec  $\mu > 0$ . Dans ce cas, que peut-on dire de  $\nabla^2 f(\mathbf{w})$  pour tout  $\mathbf{w}$  ? Qu'en déduit-on sur l'ensemble des solutions du problème (1) ?

## Exercice 2 : Fonction convexe

Soit la fonction  $q : \mathbb{R}^d \rightarrow \mathbb{R}$  définie par  $q(\mathbf{w}) = \frac{1}{4}\|\mathbf{w}\|^4$ . Cette fonction est de classe  $\mathcal{C}^2$ , et pour tout  $\mathbf{w} \in \mathbb{R}^d$ , on a :

$$\nabla q(\mathbf{w}) = \|\mathbf{w}\|^2 \mathbf{w}, \quad \nabla^2 q(\mathbf{w}) = 2\mathbf{w}\mathbf{w}^T + \|\mathbf{w}\|^2 \mathbf{I}_d.$$

- En utilisant sa matrice hessienne, montrer que la fonction  $q$  est convexe. Quelle conséquence cela a-t-il sur ses minima ?
- Montrer que le vecteur nul  $\mathbf{0}_{\mathbb{R}^d}$  est un minimum local. Satisfait-il la condition suffisante à l'ordre 2 ?
- En fonction de la réponse à la question précédente, la fonction peut-elle alors être fortement convexe ?

## Exercice 3 : Fonctions quasi-convexes

Une fonction  $f : \mathbb{R}^d \rightarrow \mathbb{R}$  est dite **quasi-convexe** si

$$\forall \mathbf{w}, \mathbf{v} \in \mathbb{R}^d, \forall t \in [0, 1], \quad f(t\mathbf{w} + (1-t)\mathbf{v}) \leq \max\{f(\mathbf{w}), f(\mathbf{v})\}. \quad (2)$$

Toute fonction convexe est quasi-convexe, mais la réciproque est fausse.

On s'intéresse ici aux solutions du problème

$$\underset{\mathbf{w} \in \mathbb{R}^d}{\text{minimiser}} f(\mathbf{w}), \quad (3)$$

où l'on suppose que  $f$  est quasi-convexe et de classe  $\mathcal{C}^2$ .

- Donner les conditions d'optimalité nécessaires à l'ordre 1 et à l'ordre 2 pour le problème (3).
- Comme  $f$  est quasi-convexe, on a la propriété suivante :

$$\forall \mathbf{w} \in \mathbb{R}^d, \forall \mathbf{v} \in \mathbb{R}^d, \quad \mathbf{v}^T \nabla f(\mathbf{w}) = 0 \Rightarrow \mathbf{v}^T \nabla^2 f(\mathbf{w}) \mathbf{v} \geq 0. \quad (4)$$

Soit  $\mathbf{w}^*$  un point stationnaire d'ordre 1. Justifier que  $\mathbf{w}^*$  est aussi un point stationnaire d'ordre 2.

## Solutions des exercices

### Solutions de l'exercice 1

a) Si  $\mathbf{X}\mathbf{w}^* = \mathbf{y}$ , alors on a

$$f(\mathbf{w}^*) = \frac{1}{2}\|\mathbf{X}\mathbf{w}^* - \mathbf{y}\|^2 = \frac{1}{2}\|\mathbf{0}\|^2 = 0.$$

Or la fonction  $f$  est toujours positive ou nulle; on a ainsi

$$\forall \mathbf{w} \in \mathbb{R}^d, f(\mathbf{w}) \geq 0 = f(\mathbf{w}^*).$$

Cette propriété correspond à la définition d'un minimum global, d'où l'on conclut que  $\mathbf{w}^*$  est bien un minimum global du problème.

b) Si  $\mathbf{w}^*$  est un minimum local du problème (1) et donc de  $f$ , alors on a  $\nabla f(\mathbf{w}^*) = \mathbf{0}$ . C'est la condition d'optimalité nécessaire à l'ordre 1.

i) Si  $\mathbf{X}^T\mathbf{X} \succeq \mathbf{0}$ , alors on a  $\nabla^2 f(\mathbf{w}) \succeq \mathbf{0}$  pour tout  $\mathbf{w}$ : c'est une caractérisation de la convexité pour une fonction de classe  $\mathcal{C}^2$ , et l'on en conclut donc que  $f$  est convexe.

ii) Comme dans la question précédente, le fait que  $\mathbf{X}^T\mathbf{X} \succeq \mu\mathbf{I}_d$  signifie que  $\nabla^2 f(\mathbf{w}) \succeq \mu\mathbf{I}_d$  pour tout  $\mathbf{w} \in \mathbb{R}^d$ . C'est une caractérisation de la convexité forte, d'où l'on conclut que  $f$  est  $\mu$ -fortement convexe. Par conséquent, la solution du problème (on sait qu'il en existe au moins une d'après l'énoncé) est unique.

### Solutions de l'exercice 2

a) Pour tous  $\mathbf{w} \in \mathbb{R}^d$  et  $\mathbf{v} \in \mathbb{R}^d$ , on a en utilisant la linéarité des produits scalaires et produits matrice-vecteur :

$$\begin{aligned} \mathbf{v}^T \nabla^2 q(\mathbf{w}) \mathbf{v} &= \mathbf{v}^T (2\mathbf{w}\mathbf{w}^T + \|\mathbf{w}\|^2 \mathbf{I}_d) \mathbf{v} \\ &= \mathbf{v}^T (2\mathbf{w}\mathbf{w}^T \mathbf{v} + \|\mathbf{w}\|^2 \mathbf{v}) \\ &= 2\mathbf{v}^T \mathbf{w}\mathbf{w}^T \mathbf{v} + \|\mathbf{w}\|^2 \mathbf{v}^T \mathbf{v} \\ &= 2(\mathbf{w}^T \mathbf{v})^2 + \|\mathbf{w}\|^2 \mathbf{v}^T \mathbf{v} \\ &= 2(\mathbf{w}^T \mathbf{v})^2 + \|\mathbf{w}\|^2 \|\mathbf{v}\|^2 \\ &\geq 0. \end{aligned}$$

Par conséquent, pour tout  $\mathbf{w} \in \mathbb{R}^d$ , la matrice hessienne  $\nabla^2 q(\mathbf{w})$  est semi-définie positive : on a  $\nabla^2 q(\mathbf{w}) \succeq \mathbf{0}$ . On en déduit que la fonction  $q$  est convexe, et donc que tous ses minima locaux sont globaux (elle ne possède ainsi que des minima globaux).

b) Puisque  $q$  est convexe, il y a équivalence entre minimum local et minimum global. Or, on a

$$q(\mathbf{w}) = \frac{1}{4}\|\mathbf{w}\|^4 \geq 0 = q(\mathbf{0}_{\mathbb{R}^d}).$$

Le vecteur nul  $\mathbf{0}_{\mathbb{R}^d}$  est donc un minimum global de  $q$ . Pour satisfaire la condition suffisante d'optimalité à l'ordre 2, il faudrait avoir  $\nabla^2 q(\mathbf{w}) \succ \mathbf{0}$ ; or, on trouve en remplaçant dans l'expression donnée dans l'énoncé que

$$\nabla^2 q(\mathbf{0}_{\mathbb{R}^d}) = \mathbf{0},$$

qui n'est pas définie positive mais uniquement semi-définie positive : par conséquent, le vecteur nul ne vérifie pas la condition suffisante d'optimalité. *Remarque : cela ne contredit pas le fait que  $\mathbf{0}$  est un minimum global.*

- c) Si la fonction était fortement convexe, on aurait  $\nabla^2 q(\mathbf{w}) \succeq \mu \mathbf{I}_d \succ \mathbf{0}$  pour tout  $\mathbf{w}$ , et donc en particulier pour le vecteur nul. Ce n'est pas le cas, et on en conclut donc que cette fonction n'est pas fortement convexe.

### Solutions de l'exercice 3

- a) *Il s'agit d'une question de cours.* La condition nécessaire d'optimalité à l'ordre 1 s'énonce comme suit : si  $\mathbf{w}^* \in \mathbb{R}^d$  est un minimum local de  $f$ , alors  $\nabla f(\mathbf{w}^*) = \mathbf{0}$ . La condition nécessaire d'optimalité à l'ordre 2 est plus précise encore : si  $\mathbf{w}^* \in \mathbb{R}^d$  est un minimum local de  $f$ , alors

$$\nabla f(\mathbf{w}^*) = \mathbf{0} \quad \text{et} \quad \nabla^2 f(\mathbf{w}^*) \succeq \mathbf{0}.$$

- b) Puisque  $\mathbf{w}^*$  est un point stationnaire d'ordre 1, il vérifie la condition d'optimalité nécessaire à l'ordre 1 : on a donc  $\nabla f(\mathbf{w}^*) = \mathbf{0}$ . Par conséquent, on a

$$\forall \mathbf{v} \in \mathbb{R}^d, \quad \mathbf{v}^T \nabla f(\mathbf{w}^*) = \mathbf{v}^T \mathbf{0} = 0.$$

La première partie de l'implication (4) est donc vraie pour  $\mathbf{w}^*$  et pour tout vecteur  $\mathbf{v}$ . On en déduit donc que la seconde partie de l'implication l'est aussi, c'est-à-dire que l'on a :

$$\mathbf{v}^T \nabla^2 f(\mathbf{w}^*) \mathbf{v} \geq 0 \quad \forall \mathbf{v} \in \mathbb{R}^d,$$

qui correspond à  $\nabla^2 f(\mathbf{w}^*) \succeq \mathbf{0}$ . Par conséquent,  $\mathbf{w}^*$  vérifie la condition nécessaire d'optimalité à l'ordre 2 : c'est donc bien un point stationnaire d'ordre 2.