

9. Projections et moindres carrés

Sections 4.2 et 4.3

MTH1007

J. Guérin, N. Lahrichi, S. Le Digabel
Polytechnique Montréal

H2023

(v2)

Plan

1. Projections

2. Approximations par moindres carrés

1. Projections

2. Approximations par moindres carrés

Projection sur une droite (1/2)

Soit L le sous-espace vectoriel de \mathbb{R}^m correspondant à la droite engendrée par le vecteur non nul $\mathbf{a} \in \mathbb{R}^m$

- ▶ La *projection orthogonale* du vecteur $\mathbf{b} \in \mathbb{R}^m$ sur L est le vecteur $\mathbf{p} \in L$ le plus proche de \mathbf{b}
- ▶ La projection de \mathbf{b} sur L est $\mathbf{p} = \hat{x}\mathbf{a} = \mathbf{a}\hat{x}$ où $\hat{x} = \frac{\mathbf{a}^\top \mathbf{b}}{\mathbf{a}^\top \mathbf{a}}$
- ▶ On peut le voir aussi comme $\mathbf{p} = (\mathbf{u}^\top \mathbf{b})\mathbf{u}$ avec
 - ▶ $\mathbf{u} = \frac{\mathbf{a}}{\|\mathbf{a}\|}$ la *normalisation* de \mathbf{a}
 - ▶ $\mathbf{a} = \|\mathbf{a}\|\mathbf{u}$ et $\|\mathbf{u}\| = \mathbf{u}^\top \mathbf{u} = 1$ (\mathbf{u} est *unitaire*)
- ▶ La droite allant de \mathbf{p} à \mathbf{b} est orthogonale à \mathbf{a} : $\mathbf{a} \perp \mathbf{e}$ avec $\mathbf{e} = \mathbf{b} - \mathbf{p}$ (\mathbf{e} est appelé l'*erreur*)
- ▶ **Exemple** : Avec $\mathbf{a} = (3, 2)$ et $\mathbf{b} = (5, 5)$, on a $\mathbf{p} = \frac{1}{13}(75, 50)$

Projection sur une droite (2/2)

- ▶ Matriciellement, le résultat précédent se reformule comme suit :

La projection de $\mathbf{b} \in \mathbb{R}^m$ sur L est $\mathbf{p} = P\mathbf{b}$, où $P \in \mathbb{R}^{m \times m}$ est la *matrice de projection* symétrique suivante :

$$P = \frac{\mathbf{a}\mathbf{a}^\top}{\mathbf{a}^\top\mathbf{a}} = \mathbf{u}\mathbf{u}^\top \text{ avec } \mathbf{u} = \frac{\mathbf{a}}{\|\mathbf{a}\|}$$

$$\text{car } \mathbf{p} = \frac{\mathbf{a}^\top\mathbf{b}}{\mathbf{a}^\top\mathbf{a}}\mathbf{a} = \mathbf{a}\frac{\mathbf{a}^\top\mathbf{b}}{\mathbf{a}^\top\mathbf{a}} = \frac{\mathbf{a}\mathbf{a}^\top}{\mathbf{a}^\top\mathbf{a}}\mathbf{b} = P\mathbf{b}$$

- ▶ **Exemple :**

Avec $\mathbf{a} = (3, 2)$ et $\mathbf{b} = (5, 5)$, on a $P = \frac{1}{13} \begin{bmatrix} 9 & 6 \\ 6 & 4 \end{bmatrix}$

Remarques

- ▶ P symétrique, $r(P) = 1$, $C(P) = C([\mathbf{a}]) = L$
- ▶ Si \mathbf{b} est orthogonal à \mathbf{a} , alors $\mathbf{a}^\top \mathbf{b} = 0$. La projection est $\mathbf{p} = \mathbf{0}$
- ▶ Si $\mathbf{b} = \mathbf{a}$, alors $\hat{x} = 1$. La projection de \mathbf{a} sur lui-même donne \mathbf{a} : $P\mathbf{a} = \mathbf{a}$ (mais $P \neq I$)
- ▶ Si $\mathbf{b} \in L$, alors $\mathbf{p} = \mathbf{b}$ et $\mathbf{e} = \mathbf{0}$
- ▶ Projeter une deuxième fois ne change rien :

$$P^2 = PP = (\mathbf{u}\mathbf{u}^\top)(\mathbf{u}\mathbf{u}^\top) = \mathbf{u}(\mathbf{u}^\top \mathbf{u})\mathbf{u}^\top = \mathbf{u}\mathbf{u}^\top = P$$

- ▶ Lorsque P projette sur un sous-espace ($C(P)$), $I - P$ projette sur le sous-espace orthogonal ($N(P)$)
- ▶ **Exemple :**

Illustrer avec $\mathbf{a} = (3, 2)$, $\mathbf{b} = (5, 5)$, et $P = \frac{1}{13} \begin{bmatrix} 9 & 6 \\ 6 & 4 \end{bmatrix}$

Projection dans un sous-espace

Soit $\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_n \in \mathbb{R}^m$ n vecteurs linéairement indépendants avec $n < m$ et W le sous-espace de \mathbb{R}^m de dimension n engendré par ces vecteurs

- ▶ La *projection orthogonale* du vecteur $\mathbf{b} \in \mathbb{R}^m$ sur W est le vecteur $\mathbf{p} \in W$ le plus proche de \mathbf{b}
- ▶ La projection de \mathbf{b} sur W est $\mathbf{p} = A\hat{\mathbf{x}} \in \mathbb{R}^m$ où

$$A = \begin{bmatrix} \mathbf{a}_1 & \mathbf{a}_2 & \cdots & \mathbf{a}_n \end{bmatrix} \in \mathbb{R}^{m \times n}$$

et

$$\hat{\mathbf{x}} = \left(A^T A \right)^{-1} A^T \mathbf{b} \in \mathbb{R}^n$$

- ▶ $\mathbf{p} = P\mathbf{b}$ où P est la *matrice de projection*

$$P = A \left(A^T A \right)^{-1} A^T \in \mathbb{R}^{m \times m}$$

Remarques (1/2)

- ▶ Le SÉL $Ax = \mathbf{b}$ n'a pas toujours de solution ($m > n$)
- ▶ $C(A^\top) = \mathbb{R}^n$ et $N(A) = \{\mathbf{0}\}$
- ▶ La matrice $A^\top A$ est symétrique et de taille $n \times n$. Elle est inversible car $r(A) = r(A^\top A)$ (preuve en exercice) et $r(A) = n$
- ▶ Intuition pour la formule de $\hat{\mathbf{x}}$: la droite allant de \mathbf{p} à \mathbf{b} est orthogonale au sous-espace $W = C(A)$:

$$\begin{aligned} A^\top(\mathbf{b} - \mathbf{p}) &= A^\top \mathbf{e} = \mathbf{0} = A^\top(\mathbf{b} - A\hat{\mathbf{x}}) \Rightarrow A^\top A\hat{\mathbf{x}} = A^\top \mathbf{b} \\ &\Rightarrow \hat{\mathbf{x}} = (A^\top A)^{-1} A^\top \mathbf{b} \end{aligned}$$

- ▶ Pour trouver la projection \mathbf{p} , il faut résoudre le système $A^\top A\hat{\mathbf{x}} = A^\top \mathbf{b}$, qui possède une solution unique

Remarques (2/2)

- ▶ Les matrices de projection $P \in \mathbb{R}^{m \times m}$ vérifient :
 $P^2 = P$, $P^\top = P$, $r(P) = n < m$ (P est singulière)
- ▶ $W = C(A) = C(P) = C(P^\top)$: La projection sur W peut être vue comme la multiplication des vecteurs de \mathbb{R}^n par A ($A\mathbf{x} \in W$ pour tout $\mathbf{x} \in \mathbb{R}^n$) ou bien comme la multiplication des vecteurs de \mathbb{R}^m par P ($P\mathbf{b} \in W$ pour tout $\mathbf{b} \in \mathbb{R}^m$)
- ▶ $N(P) = N(P^\top) = N(A^\top)$
- ▶ $\mathbf{e} = \mathbf{b} - \mathbf{p}$ est orthogonal aux vecteurs de $W = C(A)$. Il est donc dans les noyaux à gauche de A et P : $A^\top \mathbf{e} = \mathbf{0}$ et $P^\top \mathbf{e} = \mathbf{0}$
- ▶ Décomposition de \mathbb{R}^m : $\mathbf{b} = \underbrace{\mathbf{p}}_{\in C(A)} + \underbrace{\mathbf{e}}_{\in C(A)^\perp = N(A^\top)} \in \mathbb{R}^m$

La projection sur une droite est un cas particulier

Si $n = 1$, on retrouve les formules de la projection sur une droite dans \mathbb{R}^m :

$$A \in \mathbb{R}^{m \times n} \quad \rightarrow \quad \mathbf{a} \in \mathbb{R}^m$$

$$\mathbf{p} = P\mathbf{b} = A\hat{\mathbf{x}} \in \mathbb{R}^m \quad \rightarrow \quad \mathbf{p} = P\mathbf{b} = \hat{\mathbf{x}}\mathbf{a} \in \mathbb{R}^m$$

$$\hat{\mathbf{x}} = (A^T A)^{-1} A^T \mathbf{b} \in \mathbb{R}^n \quad \rightarrow \quad \hat{\mathbf{x}} = \frac{\mathbf{a}^T \mathbf{b}}{\mathbf{a}^T \mathbf{a}} \in \mathbb{R}$$

$$P = A (A^T A)^{-1} A^T \in \mathbb{R}^{m \times m} \quad \rightarrow \quad P = \frac{\mathbf{a}\mathbf{a}^T}{\mathbf{a}^T \mathbf{a}} \in \mathbb{R}^{m \times m}$$

1. Projections

2. Approximations par moindres carrés

Introduction

- ▶ $A \in \mathbb{R}^{m \times n}$ avec $m > n$ et $r(A) = n$
- ▶ Le SÉL $Ax = b$ est de plein rang colonne et ne possède pas toujours de solution
- ▶ Au lieu on résout le système $A^T A \hat{x} = A^T b$ qui possède toujours une solution (ce sont les *équations normales*)
- ▶ $p = A\hat{x}$ est la projection de b dans $C(A)$: C'est donc le point de $C(A)$ le plus proche de b
- ▶ \hat{x} minimise l'erreur

$$\|e\|^2 = \|b - p\|^2 = \|b - Pb\|^2 = \|b - A\hat{x}\|^2$$

- ▶ On peut donc voir \hat{x} comme la *meilleure "solution" possible* à $Ax = b$
- ▶ \hat{x} est appelée la solution de $Ax = b$ au sens des *moindres carrés*

Application : Droite d'ajustement (1/3)

- ▶ Étant donnés $m > 2$ *points de données* $(t_1, b_1), (t_2, b_2), \dots, (t_m, b_m)$ de \mathbb{R}^2 , on essaie de trouver l'équation d'une droite qui passe par les m points
- ▶ Cette équation est $b(t) = c + dt$ avec $c, d \in \mathbb{R}$
- ▶ c et d devraient être les solutions du système $A\mathbf{x} = \mathbf{b}$ avec

$$A = \begin{bmatrix} 1 & t_1 \\ 1 & t_2 \\ \vdots & \vdots \\ 1 & t_m \end{bmatrix}, \quad \mathbf{x} = \begin{bmatrix} c \\ d \end{bmatrix}, \quad \mathbf{b} = \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_m \end{bmatrix}$$

Droite d'ajustement (2/3)

- ▶ Or le système $A\mathbf{x} = \mathbf{b}$ n'a a priori pas de solution car il est peu probable que les m points soient alignés
- ▶ Au lieu, on résout

$$A^T A \hat{\mathbf{x}} = A^T \mathbf{b}$$

- ▶ La solution $\hat{\mathbf{x}} = (c, d)$ donnera la *droite d'ajustement* ou de *régression* qui minimise la somme des erreurs verticales avec les points de données : $\hat{\mathbf{x}}$ est tel que $E(\mathbf{x}) = \|A\mathbf{x} - \mathbf{b}\|^2$ est le plus petit possible :

$$\|\mathbf{e}\|^2 = E(\hat{\mathbf{x}}) = \min_{\mathbf{x} \in \mathbb{R}^2} E(\mathbf{x})$$

Droite d'ajustement (3/3)

Explicitement, le système d'équations 2×2 qui définit la droite d'ajustement est

$$\underbrace{\begin{bmatrix} m & \sum_{i=1}^m t_i \\ \sum_{i=1}^m t_i & \sum_{i=1}^m t_i^2 \end{bmatrix}}_{A^T A} \begin{bmatrix} c \\ d \end{bmatrix} = \underbrace{\begin{bmatrix} \sum_{i=1}^m b_i \\ \sum_{i=1}^m t_i b_i \end{bmatrix}}_{A^T b}$$

Point de vue géométrique

- ▶ On cherche le vecteur de $C(A)$ qui est le plus proche de \mathbf{b}
- ▶ Il s'agit du vecteur \mathbf{p} qui minimise (le carré de) la distance

$$\|\mathbf{e}\|^2 = \|\mathbf{p} - \mathbf{b}\|^2$$

- ▶ Cette distance représente la somme des carrés des erreurs verticales entre les points et la droite

Point de vue algébrique

- ▶ Chaque vecteur $\mathbf{b} \in \mathbb{R}^m$ se décompose en $\mathbf{b} = \mathbf{p} + \mathbf{e}$ où $\mathbf{p} \in C(A)$ et $\mathbf{e} \in C(A)^\perp = N(A^\top)$
- ▶ Le système $A\mathbf{x} = \mathbf{p} + \mathbf{e}$ n'a pas de solution mais $A\hat{\mathbf{x}} = \mathbf{p}$ possède une solution
- ▶ $A\mathbf{x} \in \mathbb{R}^m$ et $\mathbf{p} \in \mathbb{R}^m$ sont dans $C(A)$, donc $A\mathbf{x} - \mathbf{p} \in C(A)$. Ainsi $(A\mathbf{x} - \mathbf{p}) \perp \mathbf{e}$
- ▶ Cette solution minimise l'erreur

$$E(\mathbf{x}) = \|A\mathbf{x} - \mathbf{b}\|^2 = \|A\mathbf{x} - \mathbf{p}\|^2 + \|\mathbf{e}\|^2$$

et

$$E(\hat{\mathbf{x}}) = \|A\hat{\mathbf{x}} - \mathbf{b}\|^2 = \|\mathbf{e}\|^2$$

Point de vue de l'optimisation

- ▶ On minimise la fonction d'erreur

$$E(\mathbf{x}) = \|A\mathbf{x} - \mathbf{b}\|^2$$

- ▶ Pour cela, on résout $\nabla E(\mathbf{x}) = \mathbf{0}$ (donne $\hat{\mathbf{x}}$) et on montre que $\nabla^2 E(\hat{\mathbf{x}})$ est *définie-positif*
- ▶ Ce qui revient à

$$A^\top A \hat{\mathbf{x}} = A^\top \mathbf{b}$$

Solution analytique

- ▶ Il n'est pas nécessaire de résoudre explicitement $A^T A \hat{\mathbf{x}} = A^T \mathbf{b}$, car on peut trouver une solution analytique
- ▶ Par exemple, par l'optimisation, on obtient

$$\begin{cases} d &= \frac{\sum_{i=1}^m t_i b_i - m \hat{t} \hat{b}}{\sum_{i=1}^m t_i^2 - m \hat{t}^2} = \frac{\sum_{i=1}^m (t_i - \hat{t})(b_i - \hat{b})}{\sum_{i=1}^m (t_i - \hat{t})^2} \\ c &= \hat{b} - d \hat{t} \end{cases}$$

avec $\hat{b} = \frac{1}{m} \sum_{i=1}^m b_i$ et $\hat{t} = \frac{1}{m} \sum_{i=1}^m t_i$ (moyennes des b_i et des t_i)

Généralisation

Le même principe s'applique à l'ajustement d'une courbe de forme connue à un ensemble de points donnés

Par exemple : Ajuster une parabole sur les points $(0, 6)$, $(1, 0)$, $(2, 0)$ et $(1/2, 1)$:

