

FONDÉMENTS DU PL

15/10/2024

Programme

Ch Modèle linéaire (2/2) .

TD Fin ACP + Début modèle linéaire

PREMIERS PAS AVEC LE MODÈLE LINÉAIRE (suite)

Rappel: $X \in \mathbb{R}^{m \times n}$, $y \in \mathbb{R}^m$

$$x = \begin{bmatrix} x_1^T \\ \vdots \\ x_m^T \end{bmatrix} \quad y = \begin{bmatrix} y_1 \\ \vdots \\ y_m \end{bmatrix}$$


On cherche $\beta \in \mathbb{R}^n$ tel que

$$x_i^T \beta = y_i \quad \forall i=1..m$$

On a vu que la pseudo-inverse de X donnait une solution de ce système quand il en existe une.

⇒ Que dire lorsque le système n'admet pas de solution ?

⇒ Est-ce que la solution donnée par la pseudo-inverse est la meilleure solution lorsque y en a une infinité ?



Approche (par moindres carrés)

Trouver le meilleur modèle linéaire possible relativement aux données (x_i, y_i)

Mathématiquement, cette approche se modélise en utilisant un problème d'optimisation

⇒ On va chercher à minimiser l'écart entre $x_i^T \beta$ (valeur donnée par le modèle linéaire) et y_i (vrai label que l'on cherche à prédire)


Si on peut interpoler les données, c'est-à-dire s'il existe β^* tel que $x_i^T \beta^* = y_i \quad \forall i=1..m$, alors ce β^* minimise les écarts.

\Rightarrow On mesure ici l'écart via une verté aux molindes canés

$$\frac{1}{2} (x_i^T \beta - y_i)^2$$

$(\frac{1}{2}$: convention de normalisation)

Graphiquer



\hookrightarrow On mesure l'écart du modèle $x \mapsto x^T \beta$ sur le jeu de données $\{(x_i, y_i)\}_{i=1..m}$ par

$$\begin{bmatrix} x_1^T \beta \\ x_m^T \beta \end{bmatrix}$$

$$\frac{1}{2} \sum_{i=1}^m (x_i^T \beta - y_i)^2 = \frac{1}{2} \|X\beta - y\|^2$$

\rightarrow On va chercher le vecteur β qui minimise la valeur $\frac{1}{2} \|X\beta - y\|^2$, ce que l'on écrit comme un problème d'optimisation

"minimiser"


$$\min_{\beta \in \mathbb{R}^m}$$

"par rapport à β "

$$\frac{1}{2} \|X\beta - y\|^2$$

"fonction objectif du problème"

$$\beta \mapsto \frac{1}{2} \|X\beta - y\|^2$$



Remarque

. $\forall a > 0, \forall b \in \mathbb{R}$,

$\min_{\beta \in \mathbb{R}^m} \frac{1}{2} \|X\beta - y\|^2$ et $\min_{\beta \in \mathbb{R}^m} \left(\frac{a}{2} \|X\beta - y\|^2 + b \right)$ ont le même ensemble

de solutions (mais la valeur de la fonction objectif en la solution sera différente)

On notera $\underset{\beta \in \mathbb{R}^m}{\text{argmin}} \frac{1}{2} \|X\beta - y\|^2$ l'ensemble des solutions du problème

$$\underset{\beta \in \mathbb{R}^m}{\text{min}} \frac{1}{2} \|X\beta - y\|^2$$

(argmin = argument minimal)

Définition: Étant donné (X, y) et $\hat{\beta} \in \mathbb{R}^m$, on dit que:

• $\hat{\beta}$ est une solution au sens des moindres carrés si:

$$\hat{\beta} \in \underset{\beta \in \mathbb{R}^m}{\text{argmin}} \frac{1}{2} \|X\beta - y\|^2$$

(solution du problème d'optimisation)

• $\hat{\beta}$ est une solution au sens classique si:

$$X\hat{\beta} = y$$

(solution du système linéaire)

Rémarque: → Toute solution au sens classique est une solution au sens des moindres carrés

Si $\hat{\beta}$ est une solution au sens classique, alors $X\hat{\beta} - y = 0_{\mathbb{R}^m}$

$$\frac{1}{2} \|X\hat{\beta} - y\|^2 = \frac{1}{2} \|0_{\mathbb{R}^m}\|^2 = 0$$

on a $\forall \beta \in \mathbb{R}^m$, $\frac{1}{2} \|X\beta - y\|^2 \geq 0$

$\forall \beta \in \mathbb{R}^m$, $\frac{1}{2} \|X\beta - y\|^2 \geq \frac{1}{2} \|X\hat{\beta} - y\|^2$

$\Leftrightarrow \hat{\beta} \in \underset{\beta \in \mathbb{R}^m}{\text{argmin}} \frac{1}{2} \|X\beta - y\|^2$

→ Si il existe une solution au sens classique, alors l'ensemble des solutions au sens classique coïncide avec l'ensemble des solutions au sens des moindres carrés

→ En revanche, il peut y avoir des solutions au sens des moindres carrés et pas de solution au sens classique

$$m=2$$

$$x_1^T = [1]$$

$$x_2^T = [1]$$

$$y_1 = 0$$

$$y_2 = 1$$

$$\text{Ex) } X = \begin{bmatrix} 1 \\ 1 \end{bmatrix} \in \mathbb{R}^{2 \times 1} \quad y = \begin{bmatrix} 0 \\ 1 \end{bmatrix} \in \mathbb{R}^2$$

$$X\beta = y \Leftrightarrow \begin{cases} \beta = 0 \\ \beta = 1 \end{cases} \quad \begin{array}{l} x_1^T \beta = y_1 \\ \text{pas de solution au sens classique} \end{array}$$

$$\min_{\beta \in \mathbb{R}} \frac{1}{2} \|X\beta - y\|^2 = \frac{1}{2} \left[(\beta - 0)^2 + (\beta - 1)^2 \right] = \frac{1}{2} \left[\beta^2 + (\beta - 1)^2 \right]$$

$$\text{a pour solution } \hat{\beta} = \frac{1}{2}$$

$$\frac{1}{2} \left[\hat{\beta}^2 + (\hat{\beta} - 1)^2 \right] = \frac{1}{2} \left(\frac{1}{4} + \frac{1}{4} \right) = \frac{1}{4}$$

Théorème (Propriétés du problème d'optimisation "aux moindres carrés linéaires")
linear least squares

Soient $X \in \mathbb{R}^{m \times n}$ et $y \in \mathbb{R}^m$.

1) Le problème aux moindres carrés $\min_{\beta \in \mathbb{R}^m} \frac{1}{2} \|X\beta - y\|^2$ possède toujours au moins une solution.

2) Le vecteur $\hat{\beta} = X^T y$ est toujours une solution du problème.

3) Parmi toutes les solutions possibles, $\hat{\beta} = X^T y$ est la solution de norme minimale, c'est-à-dire

$$\forall \gamma \in \arg \min_{\beta \in \mathbb{R}^m} \frac{1}{2} \|X\beta - y\|^2, \quad \|\gamma\| \geq \|X^T y\|$$

Démo: Cf. Seconde 2

Interprétation :

1) \Rightarrow Problème "bien posé" (convenablement à l'écriture en système linéaire)

$X\beta = y$: problème d'interpolation

$\min_{\beta \in \mathbb{R}^m} \frac{1}{2} \|X\beta - y\|^2$: problème de régression

2) On sait calculer une solution

3) La solution $X^T y$ a de bonnes propriétés

Norme minimale \Rightarrow Simplicité du modèle

(+ variance réduite par rapport aux données)

Résolution du problème aux moindres carrés linéaires

$$\min_{\beta \in \mathbb{R}^m} \frac{1}{2} \|X\beta - y\|^2 \quad \text{On note } \hat{\beta} = X^T y$$

9 cas à considérer

1) $m = m$

1-a) $\text{rang}(X) = m = m$

$\rightarrow \hat{\beta}$ est l'unique solution au sens des moindres carrés et l'unique solution au sens classique

$$\rightarrow \hat{\beta} = X^{-1} y$$

1-b) $\text{rang}(X) < m$ et $y \in \text{Im}(X)$

$\rightarrow \hat{\beta}$ est solution au sens classique

$\rightarrow \hat{\beta}$ est solution au sens des moindres carrés de norme minimale

\rightarrow Il existe une infinité de solutions au sens classique au sens des moindres carrés

En effet, $\forall v \in \ker(X)$, $X(\hat{\beta} + v) = \underbrace{X\hat{\beta}}_{=y} + \underbrace{Xv}_{=0} = y$
 donc $\hat{\beta} + v \in \arg\min_{\beta \in \mathbb{R}^n} \frac{1}{2} \|X\beta - y\|^2$

1-c) $\text{rang}(X) < m$, $y \notin \text{Im}(X)$

→ Pas de solution au sens classique

→ Une infinité de solutions au sens des moindres carrés
 et $\hat{\beta}$ est une solution de norme minimale
au sens des moindres carrés

2) $m < n$ (cas sous-déterminé)

2-a) $\text{rang}(X) = m$

→ $\hat{\beta}$ s'écrit $X^T(XX^T)^{-1}y$. C'est une solution au sens classique, et c'est la solution de norme minimale au sens des moindres carrés.

→ Il y a une infinité de solutions ($\ker(X) \neq \{0\}$)

2-b) $\text{rang}(X) < m$, $y \in \text{Im}(X)$

→ $\hat{\beta}$ solution au sens classique et solution au sens des moindres carrés de norme minimale

→ Infinité de solutions (dans les deux sens)

2-c) $\text{rang}(X) < m$, $y \notin \text{Im}(X)$

→ Pas de solution au sens classique

→ Infinité de solutions au sens des moindres carrés. Parmi celles-ci, $\hat{\beta}$ est la solution de norme minimale

3) $m > n$ (cas sur-déterminé)

3-a) $\text{rang}(X) = n$

→ $\hat{\beta} = (X^T X)^{-1} X^T y$ est l'unique solution au sens des moindres carrés

→ $\hat{\beta}$ est une solution au sens classique si $y \in \text{Im}(X)$, dans
ce cas c'est l'unique solution, sinon il n'y a pas de solution au sens classique

3-b) $\text{rang}(X) < n \wedge y \in \text{Im}(X)$

→ $\hat{\beta}$ solution au sens classique et solution au sens des moindres carrés de norme minimale

→ Infinité de solutions

3-c) $\text{rang}(X) < n, y \notin \text{Im}(X)$

→ Pas de solution au sens classique

→ Infinité de solutions au sens des moindres carrés, dont
 $\hat{\beta}$ qui est la solution de norme minimale

BILAN

Face à un problème de modèle linéaire :

- Pas toujours possible d'interpoler (dépend de si $y \in \text{Im}(X)$)
- La formulation par moindres carrés permet toujours de calculer le meilleur modèle linéaire possible (il y en a une infinité lorsque $\text{rang}(X) < \min(m, n)$)
- Ce(s) meilleur(s) modèle(s) permettent d'interpoler lorsque cela est possible.

. le modèle donné par le pseudo-inverse (X^+y , dont l'expression se simplifie lorsque $\text{rang}(X) = \min(m, n)$) est toujours solution aux moindres carrés et est une solution remarquable (simplicité induite par la norme minimale)

