

FONDEMENTS DU MACHINE LEARNING

8 octobre 2024

Cette semaine:

CM Intro modèle linéaire 1/2
TD ACP

La suivante

CM Intro modèle linéaire 2/2
TD Intro modèle linéaire

PREMIERS PAS AVEC LE MODÈLE LINÉAIRE

① Introduction

Cours 1 à 5: Extraire de l'information de $X \in \mathbb{R}^{m \times n}$ (SVD, ACP)

A partir de maintenant: Etablir une relation linéaire entre des entrées et des sorties, représentées par une matrice d'entrées

X : "attributs"
 y : "labels"

$X = \begin{bmatrix} x_1^T \\ \vdots \\ x_m^T \end{bmatrix} \in \mathbb{R}^{m \times n}$ et un vecteur de sorties $y \in \mathbb{R}^m$

Cadre de travail: On cherche une fonction linéaire $h: \mathbb{R}^n \rightarrow \mathbb{R}$ telle que $h(x_i) = x_i^T \beta$ soit égal à y_i $\forall i=1..m$

avec $\beta \in \mathbb{R}^n$
paramètres du modèle linéaire

$\Rightarrow$ Réécriture sous forme matricielle

$$x_i^T \beta = y_i \quad \forall i=1..m \Leftrightarrow \boxed{X \beta = y} \quad \text{Système linéaire d'équations}$$

⚠ Rien ne garantit qu'il existe un vecteur β vérifiant ce système d'équations, ou qu'un tel vecteur (s'il existe) est unique

Notre plan de bataille: Comprendre les systèmes linéaires tel que celui ci-dessus pour pouvoir proposer les meilleurs modèles linéaires possibles.

NB.

$$X \beta = y$$

$$\Leftrightarrow \begin{cases} x_1^T \beta = y_1 \\ \vdots \\ x_m^T \beta = y_m \end{cases}$$

$$\Leftrightarrow \begin{cases} x_{11} \beta_1 + x_{12} \beta_2 + \dots + x_{1n} \beta_n = y_1 \\ \vdots \\ x_{m1} \beta_1 + x_{m2} \beta_2 + \dots + x_{mn} \beta_n = y_m \end{cases}$$

② Systèmes linéaires : principes de base

a) Cas d'un système cané

$$X\beta = y \quad X \in \mathbb{R}^{n \times n}, y \in \mathbb{R}^n \text{ données}$$

$\Rightarrow$ Objectif: Trouver β s'il existe.

3 cas possibles (illustration avec $n=2$)

$$1) \quad \begin{cases} \beta_1 + \beta_2 = 0 \\ 3\beta_1 + 2\beta_2 = 1 \end{cases} \quad X = \begin{bmatrix} 1 & 1 \\ 3 & 2 \end{bmatrix} \quad y = \begin{bmatrix} 0 \\ 1 \end{bmatrix} \quad \Rightarrow \text{1 unique solution} \\ \beta_1 = 1 \quad \beta_2 = -1$$

$$2) \quad \begin{cases} \beta_1 = 0 \\ \beta_1 = -1 \end{cases} \quad X = \begin{bmatrix} 1 & 0 \\ 1 & 0 \end{bmatrix} \quad y = \begin{bmatrix} 0 \\ -1 \end{bmatrix} \quad \Rightarrow \text{Pas de solution}$$

$$3) \quad \begin{cases} \beta_1 + 2\beta_2 = 2 \\ 2\beta_1 + 4\beta_2 = 4 \end{cases} \quad X = \begin{bmatrix} 1 & 2 \\ 2 & 4 \end{bmatrix} \quad y = \begin{bmatrix} 2 \\ 4 \end{bmatrix} \quad \Rightarrow \text{Une infinité de solutions} \\ \left\{ \begin{bmatrix} \alpha \\ 1 - \alpha/2 \end{bmatrix} \mid \alpha \in \mathbb{R} \right\}$$

Théorème: Soit $X \in \mathbb{R}^{n \times n}$ une matrice inversible

Soit $y \in \mathbb{R}^n$.

Alors le système $X\beta = y$ possède une unique solution
donnée par $\beta^* = X^{-1}y$

$\hookrightarrow$ Lorsque X n'est pas inversible, alors

- soit $y \in \text{Im}(X) = \{z \in \mathbb{R}^n \mid \exists x \in \mathbb{R}^n, Xx = z\}$ et le système a alors une infinité de solutions

- soit $y \notin \text{Im}(X)$ et le système n'a pas de solution

b) Systèmes rectangulaires

Si $X \in \mathbb{R}^{m \times n}$ est une matrice rectangulaire, on peut avoir les mêmes cas que précédemment (1 unique solution, pas de solution, une infinité)

$\Rightarrow$ Mais si $m \neq n$, on ne peut pas parler d'inverse de X

Définition: $X \in \mathbb{R}^{m \times n}$ est dite de rang plein (full rank) si $\text{rang}(X) = \min(m, n)$, c'est-à-dire que X n'a pas de valeurs singulières nulles.

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

a) Si $\text{rang}(X) = m$, alors $\underbrace{X X^T}_{m \times m} \in \mathbb{R}^{m \times m}$ est inversible et

$\bar{\beta} = X^T (X X^T)^{-1} y$ est une solution de $X \beta = y$.

b) Si $\text{rang}(X) = n$, alors $X^T X \in \mathbb{R}^{n \times n}$ est inversible et

$\hat{\beta} = (X^T X)^{-1} X^T y$ est l'unique solution de $X \beta = y$ si $y \in \text{Im}(X)$

Démonstration: a) $\text{rang}(X) = \text{rang}(X X^T) = m$ donc $X X^T$ est bien inversible

Posons $\bar{\beta} = X^T (X X^T)^{-1} y$. Alors,

$$X \bar{\beta} = X \left(X^T (X X^T)^{-1} y \right) = \underbrace{X X^T}_{I_m} \underbrace{(X X^T)^{-1}}^{-1} y = I_m y = y$$

$$\underbrace{\bar{\beta} = \underbrace{X^T}_{n \times m} \underbrace{(X X^T)^{-1}}_{m \times m} \underbrace{y}_{m \times 1}}_{m \times 1}$$

b) $\text{rang}(X) = \text{rang}(X^T X) = n$ donc $X^T X$ est inversible

Soit une solution de $X\beta = y$, notée $\hat{\beta}$.

$$X\hat{\beta} = y \Rightarrow X^T X \hat{\beta} = X^T y \quad (\text{multiplication à gauche par } X^T)$$

$X^T X$ inversible $\Rightarrow \hat{\beta} = (X^T X)^{-1} X^T y$

Donc toute solution de $X\beta = y$ est nécessairement égale à $\hat{\beta}$.

Réciproquement, $\hat{\beta}$ n'est solution de $X\beta = y$ que lorsque ce système possède une solution, c'est-à-dire quand $y \in \text{Im}(X)$

↳ Les résultats ci-dessus ne couvrent qu'un sous-ensemble des cas possibles. On cherche une approche plus systématique, que l'on va construire via deux ingrédients : la pseudo-inverse et les moindres carrés linéaires.

③ Pseudo-inverse (aka le retour de la SVD)

Pour une matrice carrée $X \in \mathbb{R}^{n \times n}$, l'inverse est définie comme $X^{-1} \in \mathbb{R}^{n \times n}$ telle que $X^{-1}X = XX^{-1} = I_n$, et n'existe pas toujours.

Définition Pour toute matrice $X \in \mathbb{R}^{m \times n}$, il existe une unique matrice

$M \in \mathbb{R}^{n \times m}$ telle que

Équations de
Penrose-Penrose

$$\left\{ \begin{array}{l} XMX = X \\ MXM = M \\ (XM)^T = XM \\ (MX)^T = MX \end{array} \right.$$

On l'appelle la pseudo-inverse de X , et on la note X^+ .

Remarque: La pseudo-inverse est aussi appelée inverse généralisée ou inverse de Moore-Penrose

Q) Comment calculer la pseudo-inverse?

Proposition: Soit une matrice $\Sigma \in \mathbb{R}^{m \times n}$ de la forme

$$\Sigma = \left[\begin{array}{cc|c} \sigma_1 & & 0 \\ & \ddots & \\ 0 & & \sigma_r \\ \hline & & 0 \\ 0 & & 0 \end{array} \right] \begin{matrix} \updownarrow r \\ \updownarrow m-r \end{matrix}$$

$\xleftarrow{n} \quad \xleftarrow{n-r}$

avec $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > 0$
et $r \leq \min(m, n)$

Alors la pseudo-inverse de Σ est donnée par

$$\Sigma^+ = \begin{matrix} \xleftarrow{r} & \xleftarrow{m-r} \\ \updownarrow r & \updownarrow m-r \\ \updownarrow m-r & \end{matrix} \left[\begin{array}{cc|c} 1/\sigma_1 & & 0 \\ & \ddots & \\ 0 & & 1/\sigma_r \\ \hline & & 0 \\ 0 & & 0 \end{array} \right] \in \mathbb{R}^{m \times n}$$

Démo: Vérifier les équations de Moore-Penrose avec $X = \Sigma$ et $M = \Sigma^+$

Par exemple, $XM = \underbrace{\Sigma}_{m \times n} \underbrace{\Sigma^+}_{n \times m} = \left[\begin{array}{cc|c} \sigma_1 & & 0 \\ & \ddots & \\ 0 & & \sigma_r \\ \hline & & 0 \\ 0 & & 0 \end{array} \right] \left[\begin{array}{cc|c} 1/\sigma_1 & & 0 \\ & \ddots & \\ 0 & & 1/\sigma_r \\ \hline & & 0 \\ 0 & & 0 \end{array} \right] \begin{matrix} \xleftarrow{r} \quad \xleftarrow{m-r} \\ \updownarrow r \\ \updownarrow m-r \end{matrix}$

$$= \begin{matrix} \xleftarrow{r} & \xleftarrow{m-r} \\ \updownarrow r & \updownarrow m-r \\ \updownarrow m-r & \end{matrix} \left[\begin{array}{cc|c} 1 & & 0 \\ & \ddots & \\ 0 & & 1 \\ \hline & & 0 \\ 0 & & 0 \end{array} \right] \in \mathbb{R}^{m \times n}$$

$\Rightarrow$ Matrice diagonale carrée donc symétrique $(XM)^T = XM$

Théorème: Soit $X \in \mathbb{R}^{m \times n}$ et $X = U \Sigma V^T$ une SVD de X .

avec $\Sigma = \left[\begin{array}{cc|c} \sigma_1 & & 0 \\ & \ddots & \\ 0 & & \sigma_r \\ \hline & & 0 \\ 0 & & 0 \end{array} \right] \quad \sigma_1 \geq \dots \geq \sigma_r > 0 = \sigma_{r+1} = \dots = \sigma_{\min(m,n)}$

$r = \text{rang}(X)$

Alors, la pseudo-inverse de X est donnée par

$$X^{\dagger} = \underbrace{V}_{n \times n} \underbrace{\Sigma^{\dagger}}_{n \times m} \underbrace{U^T}_{m \times m} \in \mathbb{R}^{m \times n}$$

Remarques

- Le calcul de $X^{\dagger}$ à partir de la SVD se fait très facilement
- $X = \sum_{i=1}^r \sigma_i u_i v_i^T$ et $X^{\dagger} = \sum_{i=1}^r \frac{1}{\sigma_i} v_i u_i^T$
- La méthode via la SVD est la méthode de calcul numérique de pseudo-inverse la plus usuelle (et la plus stable numériquement, c'est la plus robuste aux erreurs numériques)

Corollaire: Pour toute $X \in \mathbb{R}^{m \times n}$, on a:

- $X^{\dagger} = X^T (X X^T)^{-1}$ si $\text{rang}(X) = m$
- $X^{\dagger} = (X^T X)^{-1} X^T$ si $\text{rang}(X) = n$
- $X^{\dagger} = X^{-1}$ si $\text{rang}(X) = m = n$ (X carrée inversible)

(et dans ce dernier cas $X^{\dagger} = X^{-1} = (X^T X)^{-1} X^T = X^T (X X^T)^{-1}$)

Théorème: Soit $X \in \mathbb{R}^{m \times n}$ et $y \in \text{Im}(X)$.

Alors $\hat{\beta} = X^{\dagger} y$ est une solution de $X \beta = y$.

→ Généralisation des cas X inversible et X de rang plein (avec $y \in \text{Im}(X)$)

Démo

Identifie au cas $\text{rang}(X) = m$, $\text{rang}(X) = n$ et X inversible

Dans le cas où $\text{rang}(X) < \min(m, n)$, on utilise la décomposition en valeurs singulières de X

Si $y \in \text{Im}(X)$, $y = X\delta$ pour $\delta \in \mathbb{R}^n$

$$= U \Sigma V^T \delta \quad \text{ou} \quad X = U \Sigma V^T \text{ est une SVD}$$

$$\Sigma = \begin{bmatrix} \sigma_1 & & \\ & \sigma_n & \\ & & 0 \end{bmatrix} \text{ avec } n < \min(m, n)$$

$$\left(y = \sum_{i=1}^n \sigma_i u_i v_i^T \delta \right)$$

$$\begin{aligned} \text{Par ailleurs, } X^T y &= V \Sigma^T U^T y \quad \left[\begin{array}{c} 1 \\ \vdots \\ \sigma_n \\ 0 \end{array} \right] \\ &= V \Sigma^T U^T U \Sigma V^T \delta = V \Sigma^T \Sigma V^T \delta \\ &\quad \left(= \sum_{i=1}^n v_i v_i^T \delta \right) \end{aligned}$$

$$\begin{aligned} \text{et donc } X(X^T y) &= U \Sigma V^T (V \Sigma^T \Sigma V^T \delta) \\ &= U \Sigma \underbrace{V^T V}_{I_m} \Sigma^T \Sigma V^T \delta \\ &= U \underbrace{\Sigma \Sigma^T \Sigma}_{\Sigma} V^T \delta \quad \left(= \sum_{i=1}^n \sigma_i \frac{1}{\sigma_i} \sigma_i u_i v_i^T \delta \right) \\ &= \Sigma \text{ par propriété de } \Sigma^T \\ &= U \Sigma V^T \delta = y \end{aligned}$$