

FONDEMENTS DU MACHINE LEARNING

10 septembre 2024

Au programme

- Cours 2: SVD

- TD 1: Mise en pratique

Décomposition en valeurs singulières / Singular value decomposition (SVD)

Motivation : Jeu de données $X \in \mathbb{R}^{m \times n}$

But : Comprendre la structure de X pour potentiellement représenter X avec moins de $m \times n$ coefficients

Approche : Analyser X en tant qu'application linéaire

① Sous-espaces fondamentaux

Définition : Pour toute matrice $X \in \mathbb{R}^{m \times n}$, on définit :

- le noyau de X : $\ker(X) := \{ v \in \mathbb{R}^n \mid Xv = \textcircled{0} \}$
- l'image de X : $\text{Im}(X) := \{ u \in \mathbb{R}^m \mid \exists v \in \mathbb{R}^n, u = Xv \}$

$\mathbb{R}^m$

↳ Les sous-espaces fondamentaux liés à X : $\ker(X), \text{Im}(X)$
 $\ker(X^T), \text{Im}(X^T)$

Définition : Le rang de X est la dimension de $\text{Im}(X)$

Théorème du rang : $\forall X \in \mathbb{R}^{m \times n}, \dim(\ker(X)) + \text{rang}(X) = n$

② Cas des matrices symétriques

Dans cette partie, on suppose que $m = n$ et $X^T = X$

Alors, il existe une décomposition spectrale de X de la forme

$$X = P \Lambda P^T$$

$P \in \mathbb{R}^{n \times n}$ orthogonale
($P^T = P^{-1}$)

$$\Lambda = \begin{bmatrix} \lambda_1 & & 0 \\ & \ddots & \\ 0 & & \lambda_n \end{bmatrix} \text{ matrice diagonale}$$

$\lambda_1 \geq \dots \geq \lambda_n$ réels
valeurs propres

- P permet de transformer X en une matrice diagonale
- Les valeurs propres nous disent comment X transforme les colonnes de P

$\Rightarrow$ Le rang de X est le nombre de valeurs propres non nulles

$\Rightarrow$ Le noyau de X est engendré par les colonnes de P correspondant aux valeurs propres nulles

$\Rightarrow$ Pour $\lambda_i \neq 0$, si $|\lambda_i| > 1$, alors X a un effet d'augmentation dans la direction de la i -ème colonne de P
si $|\lambda_i| < 1$, alors X a un effet de réduction dans la direction de la i -ème colonne de P

$$P = [p_1 \dots p_n]$$

$$p_i \in \mathbb{R}^n \forall i$$

$$X p_i = \lambda_i p_i$$


Ex)

$$\underbrace{\begin{bmatrix} 1 & 1 \\ 1 & 1 \end{bmatrix}}_X = \underbrace{\begin{bmatrix} 1/\sqrt{2} & 1/\sqrt{2} \\ 1/\sqrt{2} & -1/\sqrt{2} \end{bmatrix}}_P \underbrace{\begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix}}_{\Lambda} \underbrace{\begin{bmatrix} 1/\sqrt{2} & 1/\sqrt{2} \\ 1/\sqrt{2} & -1/\sqrt{2} \end{bmatrix}}_{P^T = P^{-1}}$$

• 1 valeur propre nulle $\Rightarrow \text{rang}(X) = 1$

On dit que la matrice n'est pas de rang plein, ce qui signifie qu'elle contient moins d'information que sa capacité

• 1 valeur propre égale à 1 $\Rightarrow$ préservation des vecteurs colinéaires à $p_1 = \begin{bmatrix} 1/\sqrt{2} \\ 1/\sqrt{2} \end{bmatrix}$



Avec la bonne base P , X s'écrit $P \begin{pmatrix} 2 & 0 \\ 0 & 1 \end{pmatrix} P^T$

③ Cas général

$\hookrightarrow$ On revient au cas $X \in \mathbb{R}^{m \times n}$ avec m, n quelconques (≥ 1)



$\hookrightarrow$ Q: Existe-il un analogue de la décomposition spectrale dans ce cas général?

Idée: X n'est pas nécessairement symétrique (ni carrée), mais $\underbrace{X^T X}_{m \times m}$ et $\underbrace{X X^T}_{m \times m}$ le sont!

NB:

$$X = \begin{array}{|c|} \hline \text{rectangle} \\ \hline \end{array} \begin{array}{l} \xleftarrow{m} \\ \xrightarrow{m} \\ \uparrow m \\ \downarrow m \end{array}$$

$$\underbrace{XX^T}_{\in \mathbb{R}^{m \times m}} = \begin{array}{|c|} \hline \text{square} \\ \hline \end{array} \begin{array}{l} m \\ m \end{array}$$

$$X^T X = \begin{array}{|c|} \hline \text{square} \\ \hline \end{array} \begin{array}{l} \xleftarrow{m} \\ \xrightarrow{m} \\ \uparrow m \\ \downarrow m \end{array}$$

Propriétés des matrices XX^T et $X^T X$

- $\ker(X^T X) = \ker(X)$ et $\ker(XX^T) = \ker(X^T)$
- $\text{Im}(X^T X) = \text{Im}(X^T)$ et $\text{Im}(XX^T) = \text{Im}(X)$
- $\text{rang}(X^T X) = \text{rang}(X)$ et $\text{rang}(XX^T) = \text{rang}(X^T)$

$\Rightarrow$ L'étude de X via ses 4 sous-espaces fondamentaux se ramène à l'étude des matrices symétriques XX^T et $X^T X$, qui ont chacune 2 sous-espaces fondamentaux.

Cela revient à dire que l'on peut étudier X via les décompositions spectrales de XX^T et $X^T X$.

- Les valeurs propres de XX^T et $X^T X$ sont positives ou nulles ($XX^T \geq 0$ et $X^T X \geq 0$)

Théorème (SVD)

Soit $X \in \mathbb{R}^{m \times m}$. Cette matrice

admet une décomposition en valeurs singulières de la forme:

$$U \in \mathbb{R}^{m \times m}, U^T = U^{-1} \text{ (orthogonale)}$$

$$X = U \Sigma V^T \text{ avec } V \in \mathbb{R}^{n \times n}, V^T = V^{-1}$$

• Colonnes de U : vecteurs singuliers à gauche

• Colonnes de V : vecteurs singuliers à droite

• Coefficients "diagonaux" de Σ

$$\sigma_1, \dots, \sigma_{\min(m,n)}$$

valeurs singulières (en général on les ordonne: $\sigma_1 \geq \dots \geq \sigma_{\min(m,n)} \geq 0$)

(x) $X \in \mathbb{R}^{3 \times 2}$

$$X = \underbrace{\begin{bmatrix} u_1 & u_2 & u_3 \\ \uparrow & \uparrow & \uparrow \\ \mathbb{R}^3 & \mathbb{R}^3 & \mathbb{R}^3 \end{bmatrix}}_U \underbrace{\begin{bmatrix} \sigma_1 & 0 \\ 0 & \sigma_2 \\ 0 & 0 \end{bmatrix}}_{\Sigma} \underbrace{\begin{bmatrix} v_1^T \\ v_2^T \end{bmatrix}}_{V^T}$$

$\sigma_1 \geq \sigma_2 \geq 0$ $v_1 \in \mathbb{R}^2$
 $v_2 \in \mathbb{R}^2$

$$X \in \mathbb{R}^{1 \times 2}$$

$$X = [x \ y]$$

$$X = \underbrace{\begin{bmatrix} \pm 1 \end{bmatrix}}_U \underbrace{\begin{bmatrix} \sigma_1 & 0 \end{bmatrix}}_{\Sigma} \underbrace{\begin{bmatrix} \hat{v}_1 \\ \hat{v}_2 \end{bmatrix}}_{V^T}$$

Propriétés de la SVD

i) Le rang de X est le nombre de valeurs singulières non nulles ($\text{rang}(X) \leq \min(m,n)$)

ii) Les carrés des valeurs singulières de X
 $\sigma_1^2 \geq \dots \geq \sigma_{\min(m,n)}^2$

sont : valeurs propres de $X^T X$ et $X X^T$

iii) Si $X = U \Sigma V^T$ est une SVD de X , alors

$U^T \Sigma^T V$ est une SVD de X^T

ID: Preuve constructive de la SVD

Calcul pratique de la SVD:
* Efficace grâce à l'algorithme de Golub & Kahan
* Stable numériquement

(4) SVD et réduction de dimension

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

avec $\Sigma = \begin{bmatrix} \sigma_1 & & 0 \\ & \ddots & \\ 0 & & \sigma_{\min(m,n)} \\ & & & 0 \end{bmatrix}$ $\sigma_1 \geq \dots \geq \sigma_{\min(m,n)}$

$$U = [u_1 \dots u_m] \text{ avec } u_i \in \mathbb{R}^m \nmid i$$

$$V = [v_1 \dots v_n] \text{ avec } v_j \in \mathbb{R}^n \nmid j$$

SVD réduite de X

$$X = \underbrace{[u_1 \dots u_r]}_{m \times r} \underbrace{\begin{bmatrix} \sigma_1 & & 0 \\ & \ddots & \\ 0 & & \sigma_r \end{bmatrix}}_{r \times r} \underbrace{\begin{bmatrix} v_1^T \\ \vdots \\ v_r^T \end{bmatrix}}_{r \times n}$$

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

SVD tronquée de X
/ k -SVD

$$X_k = [u_1 \dots u_k] \begin{bmatrix} \sigma_1 & & 0 \\ & \ddots & \\ 0 & & \sigma_k \end{bmatrix} \begin{bmatrix} v_1^T \\ \vdots \\ v_k^T \end{bmatrix}$$

$k \leq \text{rang}(X)$

↳ Si $r \ll \min(m, n)$, alors la SVD réduite permet de représenter X avec moins de $m \times n$ coefficients

↳ Si $k \ll \min(m, n)$, alors la k -SVD permet d'approcher X avec moins de $m \times n$ coefficients