

FONDEMENTS DU MACHINE LEARNING

17 septembre 2024

Aujourd'hui

SVD et applications

SVD et applications

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

Une SVD de X est de la forme

$$U \Sigma V^T = [u_1 \dots u_m] \left[\begin{array}{c|c} \sigma_1 & \\ \vdots & \\ \sigma_r & \\ \hline & 0 \end{array} \right] \begin{bmatrix} v_1 \\ \vdots \\ v_m \end{bmatrix}^T$$

$$U \in \mathbb{R}^{m \times m}, \quad U^T U = I_m = U U^T$$

$$V \in \mathbb{R}^{n \times n}, \quad V^T V = I_n = V V^T$$

$$\Sigma = \left[\begin{array}{c|c} \begin{matrix} \sigma_1 & & \\ & \ddots & \\ & & \sigma_{\min(m,n)} \end{matrix} & \begin{matrix} \text{---} \\ \text{---} \\ \text{---} \end{matrix} \\ \hline \begin{matrix} 0 \\ \vdots \\ 0 \end{matrix} & \begin{matrix} 0 \\ \vdots \\ 0 \end{matrix} \end{array} \right] \begin{matrix} \leftarrow m - \min(m,n) \\ \updownarrow m - \min(m,n) \end{matrix}$$

$$m > n \quad \Sigma = \left[\begin{array}{c|c} \begin{matrix} \sigma_1 & & \\ & \ddots & \\ & & \sigma_n \end{matrix} & \begin{matrix} \text{---} \\ \text{---} \\ \text{---} \end{matrix} \\ \hline \begin{matrix} 0 \\ \vdots \\ 0 \end{matrix} & \begin{matrix} 0 \\ \vdots \\ 0 \end{matrix} \end{array} \right] \begin{matrix} \updownarrow n \\ \updownarrow m-n \end{matrix} \quad m \geq n \quad \Sigma = \left[\begin{array}{c|c} \begin{matrix} \sigma_1 & & \\ & \ddots & \\ & & \sigma_m \end{matrix} & \begin{matrix} \text{---} \\ \text{---} \\ \text{---} \end{matrix} \\ \hline \begin{matrix} 0 \\ \vdots \\ 0 \end{matrix} & \begin{matrix} 0 \\ \vdots \\ 0 \end{matrix} \end{array} \right]$$

$$\sigma_1 \geq \dots \geq \sigma_{\min(m,n)} \geq 0$$

Remarque: La SVD permet naturellement (par construction) d'ordonner les valeurs singulières

$$\text{rang}(X) = r \iff \sigma_1 \geq \dots \geq \sigma_r > 0 = \sigma_{r+1} = \dots = \sigma_{\min(m,n)}$$

Corollaire: Pour représenter X (de taille $m \times n$), on peut utiliser $(m+n+1)r$ coefficients

$$mr: u_1, \dots, u_r$$

$$mr: v_1, \dots, v_r$$

$$r: \sigma_1, \dots, \sigma_r$$

Si $r \ll \min(m, n)$, $(m+n+1)r \ll mn$

↑
Matrice de rang faible (notion relative)

Remarque: L'écriture $\sum_{i=1}^r \sigma_i u_i v_i^T$ a beaucoup d'avantages pratiques (en plus du coût de stockage)

- plus facile de calculer la somme de manière incrémentale
- plus facile de l'appliquer à un vecteur

$$\forall w \in \mathbb{R}^n, \quad Xw \Rightarrow \sum_{i=1}^r \sigma_i \underbrace{u_i v_i^T w}_{\text{produit scalaire}} = \sum_{i=1}^r \sigma_i (v_i^T w) u_i$$

SVD tronquée: $\forall k \in [1, r]$ avec r rang de X

$$k\text{-SVD / SVD tronquée de rang } k: \quad X_k = \sum_{i=1}^k \sigma_i u_i v_i^T$$

• $X_r = X$ mais $X_k \neq X$ pour $k < r$

• Coût de stockage de la k -SVD: $(m+n+1)k$

• $\text{rang}(X_k) = k$ (SVD réduite $X_k = \sum_{i=1}^k \sigma_i u_i v_i^T$)

Q] Est-ce que la k -SVD est une bonne approximation de la matrice d'origine ?

Théorème : (Eckhart-Young)

Soit $X \in \mathbb{R}^{m \times n}$ de rang r et soit X_k une k -SVD de X .
Alors, pour toute matrice $A \in \mathbb{R}^{m \times n}$ de rang k , on a :

$$\|X - A\| \geq \|X - X_k\|$$

$$\left(\forall M \in \mathbb{R}^{m \times n}, \|M\| = \max_{x \neq 0} \frac{\|Mx\|}{\|x\|} \right)$$

La k -SVD fournit la meilleure approximation possible de X par une matrice de rang k .

Q] En pratique, est-il intéressant d'approcher une matrice de rang r par sa k -SVD de rang $k < r$?

→ Oui ! En pratique, on rencontre des matrices dont les valeurs singulières décroissent rapidement, pour lesquelles l'approximation par une k -SVD est une très bonne approximation, car

que $k \ll r$ et $\frac{\|X - X_k\|}{\|X\|} \ll 1$


erreur relative d'approximation

↓
Gain
mémoire

Approximation précise

→ En fonction de X, m, n, π et de la nature des données, on cherche à déterminer une bonne valeur de k pour que la k -SVD soit une bonne approximation

- Peut se faire manuellement ($k=1$, si par sufficient $k=?$, etc)
- Peut se faire en fonction des valeurs singulières
→ Tronquer les valeurs singulières inférieures à une certaine précision / tolérance $\varepsilon > 0$



→ Le choix de ε ou de k est très dépendant du problème

Exemple:

$$X \in \mathbb{R}^{m \times n}$$

$$X = \underbrace{X_{\text{true}}}_{\text{ vraie matrice}} + \underbrace{X_{\text{noise}}}_{\text{ bruit aléatoire}}$$

But: Récupérer X_{true} à partir de X sans connaître X_{noise} de manière exacte
(ou approcher X_{true})

(qu'on cherche à mesurer)

(bruit qui entache les observations)

Hypothèse: X_{true} est de rang faible, X est de rang plein à cause du bruit

X_{noise} bruit iid gaussien

$$\forall (i, j) \in \{1, \dots, n\}^2, [X_{\text{noise}}]_{ij} \sim \mathcal{N}(0, 1)$$

Théorème (Gavish & Donoho, 2014)

Une k -SVD de X avec $\sigma_k \geq \frac{4}{\sqrt{3}} \sqrt{m}$ élimine le bruit.

Référence: S. Brunker et J.N. Kutz, Data-driven science and engineering, 2021 (avec codes Python)

En bref:

→ Si une matrice est de rang faible, sa SVD réduite peut déjà être une façon moins coûteuse de stocker la matrice

→ On peut toujours construire une approximation de rang faible avec une k -SVD où k est suffisamment petit

→ En pratique, si on regarde l'ensemble des valeurs singulières d'une matrice, les premières valeurs singulières sont souvent bien plus grandes que les autres \Rightarrow incite à faire une approximation!

→ Déterminer un bon compromis entre approximation de qualité et approximation peu coûteuse est un processus qui dépend fortement des données

À suivre:

$X = \begin{bmatrix} x_1^T \\ \vdots \\ x_m^T \end{bmatrix}$ matrice d'individus x_1, \dots, x_m $\frac{XX^T}{n-1}$: matrice de covariance empirique

SVD de $X \Rightarrow$ ACP de XX^T