

# 13. Décomposition en valeurs singulières (SVD)

MTH1008

Sébastien Le Digabel  
Polytechnique Montréal

H2024

2024-04-17

v3

# Plan

1. Décomposition en valeurs singulières (SVD)
2. Applications et exemples

## Liens avec le livre et exercices suggérés

7.4 Décomposition en valeurs singulières 1, 3, 5, 7, 9, 11, 13, 15, 17,  
19, 21, 23, 24, 25

# 1. Décomposition en valeurs singulières (SVD)

## 2. Applications et exemples

## Rappels

1. Si  $\mathbf{A}$  est carrée  $n \times n$  avec  $n$  vecteurs propres indépendants alors  $\mathbf{A}$  est diagonalisable :  $\mathbf{S}^{-1}\mathbf{A}\mathbf{S} = \mathbf{\Lambda}$  et  $\mathbf{A} = \mathbf{S}\mathbf{\Lambda}\mathbf{S}^{-1}$
2. Si  $\mathbf{A}$  est symétrique :
  - ▶ Elle est diagonalisable (théorème spectral)
  - ▶ Ses vecteurs propres peuvent être choisis orthonormaux
  - ▶  $\mathbf{Q}^T \mathbf{A} \mathbf{Q} = \mathbf{\Lambda}$  et  $\mathbf{A} = \mathbf{Q} \mathbf{\Lambda} \mathbf{Q}^T$
3. Si  $\mathbf{A}$  est symétrique et semi-définie positive alors  $\mathbf{Q}^T \mathbf{A} \mathbf{Q} = \mathbf{\Lambda}$  où  $\lambda_i \geq 0$  pour tout  $i \in \{1, 2, \dots, n\}$

**SVD** : Diagonalisation d'une matrice quelconque  $m \times n$ , avec des vecteurs *singuliers* orthogonaux

## Théorème : Décomposition SVD

Une matrice  $\mathbf{A}$  de taille  $m \times n$  et de rang  $r$  peut décomposer  $A$  comme suit :

$$\mathbf{A} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^{\top} = \sigma_1\mathbf{u}_1\mathbf{v}_1^{\top} + \sigma_2\mathbf{u}_2\mathbf{v}_2^{\top} + \cdots + \sigma_r\mathbf{u}_r\mathbf{v}_r^{\top}$$

avec  $\mathbf{U} \in \mathbb{R}^{m \times m}$  et  $\mathbf{V} \in \mathbb{R}^{n \times n}$  deux matrices **orthogonales**, et  $\mathbf{\Sigma} \in \mathbb{R}^{m \times n}$  une matrice “diagonale” formée par les  $r$  *valeurs singulières*  $\sigma_1, \sigma_2, \dots, \sigma_r$

## Valeurs singulières

Soit  $\mathbf{A} \in \mathbb{R}^{m \times n}$  de rang  $r$ . La matrice  $\mathbf{A}^\top \mathbf{A} \in \mathbb{R}^{n \times n}$  est symétrique et **semi-définie positive**. Soient :

- ▶  $\sigma_1^2, \sigma_2^2, \dots, \sigma_n^2$  les valeurs propres de  $\mathbf{A}^\top \mathbf{A}$ . Les  $r$  premières sont strictement positives. Les  $n - r$  suivantes sont nulles
- ▶ Les  $\sigma_i$  sont les *valeurs singulières* de  $\mathbf{A}$  (pour  $i = 1, 2, \dots, r$ )
- ▶  $\sigma_i = \sqrt{\sigma_i^2} \geq 0$  : Les valeurs singulières sont toujours positives ou nulles

## Vecteurs singuliers (deux ensembles : $\mathbf{u}$ et $\mathbf{v}$ )

Soient de plus :

- ▶  $\mathbf{v}_1, \mathbf{v}_2 \dots, \mathbf{v}_r \in \mathbb{R}^n$  les vecteurs propres correspondant aux valeurs propres strictement positives de  $\mathbf{A}^\top \mathbf{A}$   
Ils peuvent être pris comme orthonormaux, forment une base de  $\text{Im}(\mathbf{A}^\top)$ , et sont appelés les *vecteurs singuliers* de  $\mathbf{A}$
- ▶  $\mathbf{v}_{r+1}, \mathbf{v}_{r+2} \dots, \mathbf{v}_n \in \mathbb{R}^n$  une base orthonormale de  $\text{Ker}(\mathbf{A})$
- ▶  $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_r \in \mathbb{R}^m$  les vecteurs *unitaires* de  $\text{Im}(\mathbf{A})$  définis par

$$\mathbf{u}_i = \frac{1}{\sigma_i} \mathbf{A} \mathbf{v}_i \quad \text{pour } i = 1, 2, \dots, r$$

Ils sont *orthonormaux*, forment une base de  $\text{Im}(\mathbf{A})$ , et des vecteurs propres de  $\mathbf{A} \mathbf{A}^\top$ . Ils sont aussi appelés *singuliers*

- ▶  $\mathbf{u}_{r+1}, \mathbf{u}_{r+2} \dots, \mathbf{u}_m \in \mathbb{R}^m$  une base orthonormale de  $\text{Ker}(\mathbf{A}^\top)$

## Diagonalisation $\mathbf{AV}_r = \mathbf{U}_r \mathbf{\Sigma}_r$

- ▶  $\mathbf{A}$  est diagonalisée avec

$$\mathbf{A}\mathbf{v}_1 = \sigma_1 \mathbf{u}_1, \mathbf{A}\mathbf{v}_2 = \sigma_2 \mathbf{u}_2, \dots, \mathbf{A}\mathbf{v}_r = \sigma_r \mathbf{u}_r$$

- ▶ Sous forme matricielle :  $\mathbf{AV}_r = \mathbf{U}_r \mathbf{\Sigma}_r$  :

$$\mathbf{A} \begin{bmatrix} \mathbf{v}_1 & \cdots & \mathbf{v}_r \end{bmatrix} = \begin{bmatrix} \mathbf{u}_1 & \cdots & \mathbf{u}_r \end{bmatrix} \begin{bmatrix} \sigma_1 & & \\ & \ddots & \\ & & \sigma_r \end{bmatrix}$$

$$(m \times n)(n \times r) = (m \times r)(r \times r)$$

## Complétion de $\mathbf{U}$ , $\mathbf{V}$ , et $\Sigma$

- ▶ On complète  $\mathbf{U}_r$  et  $\mathbf{V}_r$  avec  $\mathbf{u}_{r+1}, \mathbf{u}_{r+2}, \dots, \mathbf{u}_m$  et  $\mathbf{v}_{r+1}, \mathbf{v}_{r+2}, \dots, \mathbf{v}_n$  pour obtenir les matrices  $\mathbf{U}$  et  $\mathbf{V}$  carrées et orthogonales

- ▶ Les matrices  $\mathbf{U}$  et  $\mathbf{V}$  contiennent alors des bases orthonormales pour les quatre sous-espaces :

$$\begin{array}{ll} r & \text{premières colonnes de } \mathbf{V} : \text{Im}(\mathbf{A}^\top) \\ n - r & \text{dernières colonnes de } \mathbf{V} : \text{Ker}(\mathbf{A}) \\ r & \text{premières colonnes de } \mathbf{U} : \text{Im}(\mathbf{A}) \\ m - r & \text{dernières colonnes de } \mathbf{U} : \text{Ker}(\mathbf{A}^\top) \end{array}$$

- ▶ On passe aussi de  $\Sigma_r \in \mathbb{R}^{r \times r}$  à  $\Sigma \in \mathbb{R}^{m \times n}$  en ajoutant  $m - r$  lignes de zéros et  $n - r$  colonnes de zéros

## Décomposition $A = U\Sigma V^T$ (SVD)

On a

$$AV = U\Sigma, A = U\Sigma V^T, \text{ et } \Sigma = U^T AV$$

avec les matrices

$$V = [ \mathbf{v}_1 \quad \mathbf{v}_2 \quad \cdots \quad \mathbf{v}_n ] \in \mathbb{R}^{n \times n}$$

$$U = [ \mathbf{u}_1 \quad \mathbf{u}_2 \quad \cdots \quad \mathbf{u}_m ] \in \mathbb{R}^{m \times m}$$

$$\Sigma = \left[ \begin{array}{ccc|ccc} \sigma_1 & & & & & \\ & \sigma_2 & & & & \\ & & \ddots & & & \\ & & & \sigma_r & & \\ \hline & & & & & \\ & & & & & \end{array} \right] \in \mathbb{R}^{m \times n}$$

1. Décomposition en valeurs singulières (SVD)

2. Applications et exemples

## Exemples

Donner la décomposition SVD des matrices

$$\begin{bmatrix} 2 & 2 \\ -1 & 1 \end{bmatrix}$$

et

$$\begin{bmatrix} 2 & 2 \\ 1 & 1 \end{bmatrix}$$

## Conditionnement d'une matrice

- ▶ Le *conditionnement* de la matrice  $\mathbf{A}$ , noté  $\kappa(\mathbf{A})$ , mesure à quel point la solution de  $\mathbf{Ax} = \mathbf{b}$  change lorsque  $\mathbf{b}$  change
- ▶ C'est la *sensibilité* de  $\mathbf{Ax} = \mathbf{b}$  relativement à  $\mathbf{b}$
- ▶ Il est préférable d'avoir  $\kappa(\mathbf{A})$  le plus petit possible afin de minimiser l'erreur numérique sur  $\mathbf{x}$  lors de la résolution de  $\mathbf{Ax} = \mathbf{b}$
- ▶ Avec une norme matricielle  $\|\cdot\|$ , on a  $\kappa(\mathbf{A}) = \|\mathbf{A}^{-1}\| \times \|\mathbf{A}\|$
- ▶ Avec les valeurs singulières, on a  $\kappa(\mathbf{A}) = \frac{\sigma_{\max}(\mathbf{A})}{\sigma_{\min}(\mathbf{A})}$  où  $\sigma_{\min}(\mathbf{A})$  et  $\sigma_{\max}(\mathbf{A})$  sont les plus petite et plus grande valeurs singulières, respectivement

## Application : Approximation d'une matrice pour la compression (avec pertes)

$$\mathbf{A} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^\top = \sigma_1 \mathbf{u}_1 \mathbf{v}_1^\top + \sigma_2 \mathbf{u}_2 \mathbf{v}_2^\top + \cdots + \sigma_r \mathbf{u}_r \mathbf{v}_r^\top$$

peut s'écrire

$$\mathbf{A} = \sigma_{(1)} \mathbf{u}_{(1)} \mathbf{v}_{(1)}^\top + \sigma_{(2)} \mathbf{u}_{(2)} \mathbf{v}_{(2)}^\top + \cdots + \sigma_{(r)} \mathbf{u}_{(r)} \mathbf{v}_{(r)}^\top$$

avec (1) l'indice de la plus grande valeur singulière, (2) l'indice de la deuxième plus grande valeur singulière, etc.

- ▶ Chaque matrice  $\sigma_i \mathbf{u}_i \mathbf{v}_i^\top$  est de rang 1
- ▶ Toute troncature à droite de cette somme donnera une approximation de  $\mathbf{A}$

Exemple pour la compression d'images :

<https://timbaumann.info/svd-image-compression-demo/>