

# TD 01 : Décomposition en valeurs singulières

Fondements du Machine Learning, L3 IM2D

Septembre 2024



## Exercice 1.1: Valeurs propres et valeurs singulières

Soit  $U\Sigma V^T$  une SVD de  $A \in \mathbb{R}^{m \times n}$  avec  $U = [u_1 \dots u_m]$ ,  $V = [v_1 \dots v_n]$ , et  $\sigma_i = [\Sigma]_{ii}$  pour tout  $1 \leq i \leq \min(m, n)$ .

- Montrer que  $Av_i = \sigma_i u_i$  et  $A^T u_i = \sigma_i v_i$  pour tout  $1 \leq i \leq \min(m, n)$ .
- En déduire un lien entre les valeurs propres de  $A^T A$  et les valeurs singulières de  $A$ .
- Si  $\text{rang}(A) = r$ , que peut-on dire des valeurs singulières ?

## Exercice 1.2: Carrés de matrices

Soit  $A \in \mathbb{R}^{n \times n}$  une matrice définie positive (donc symétrique). Soit  $P\Lambda P^T$  une décomposition en valeurs propres de  $A$ , avec  $P$  orthogonale et  $\Lambda$  diagonale à coefficients diagonaux ordonnés par ordre croissant  $\Lambda_{11} \geq \Lambda_{22} \geq \dots \geq \Lambda_{nn}$ .

- Donner une décomposition en valeurs singulières de  $A$  basée sur la décomposition en valeurs propres ci-dessus.
- Soit  $B \in \mathbb{R}^{n \times n}$  telle que  $B^2 = A$  et  $B \succ 0$ . Donner une décomposition en valeurs propres et une décomposition en valeurs singulières de  $B$  en fonction de celles de  $A$ .
- Que vaut  $B^T B$  ? Retrouver alors le lien entre les valeurs propres de  $B^T B$  et les valeurs singulières de  $B$ .

## Exercice 1.3: SVD et factorisation QR

On appelle *factorisation QR* d'une matrice  $X \in \mathbb{R}^{m \times n}$  toute décomposition de la forme  $X = QR$ , où  $Q \in \mathbb{R}^{m \times m}$  est orthogonale et  $R$  est triangulaire supérieure, c'est-à-dire que  $[R]_{ij} = 0$  si  $i > j$ .

- Pour toute matrice orthogonale  $C \in \mathbb{R}^{m \times m}$ , donner une décomposition en valeurs singulières de  $CX$  en fonction de la SVD de  $X$ .
- En déduire une décomposition en valeurs singulières de  $R$  en fonction de la SVD de  $X$  de la question a).

### Exercice 1.4: Normes et valeurs singulières

On définit sur  $\mathbb{R}^{m \times n}$  la norme matricielle induite et la norme de Frobenius :

$$\forall \mathbf{A} \in \mathbb{R}^{m \times n}, \left\{ \begin{array}{l} \|\mathbf{A}\| := \max_{\substack{\mathbf{x} \in \mathbb{R}^n \\ \mathbf{x} \neq \mathbf{0}}} \frac{\|\mathbf{A}\mathbf{x}\|}{\|\mathbf{x}\|} \\ \|\mathbf{A}\|_F := \sqrt{\sum_{\substack{1 \leq i \leq m \\ 1 \leq j \leq n}} [\mathbf{A}]_{ij}^2}. \end{array} \right.$$

a) En utilisant une décomposition en valeurs singulières de  $\mathbf{A}$ , montrer que  $\|\mathbf{A}\| = \sigma_1$ , où  $\sigma_1$  désigne la plus grande valeur singulière de la matrice  $\mathbf{A}$ .

*Indication: Utiliser le fait que si  $\mathbf{Q} \in \mathbb{R}^{\ell \times \ell}$  est une matrice orthogonale, on a  $\|\mathbf{Q}\mathbf{x}\| = \|\mathbf{x}\|$  pour tout  $\mathbf{x} \in \mathbb{R}^\ell$ .*

b) Si  $\mathbf{A}$  est carrée et symétrique, que vaut  $\|\mathbf{A}\|$  ?

c) Avec les notations de la question a), montrer également que

$$\|\mathbf{A}\|_F = \sqrt{\sum_{i=1}^{\min(n,m)} \sigma_i^2}$$

où  $\sigma_1 \geq \dots \geq \sigma_{\min(n,m)}$  sont les valeurs singulières de  $\mathbf{A}$ .

### Exercice 1.5: Preuve constructive de la SVD

Soit une matrice  $\mathbf{X} \in \mathbb{R}^{m \times n}$  non nulle.

a) En utilisant la définition de  $\|\mathbf{X}\|$ , trouver  $\mathbf{v}_1 \in \mathbb{R}^n$  et  $\mathbf{u}_1 \in \mathbb{R}^m$  tels que  $\|\mathbf{u}_1\| = 1, \|\mathbf{v}_1\| = 1$  et  $\mathbf{X}\mathbf{v}_1 = \sigma_1 \mathbf{u}_1$ , où  $\sigma_1 = \|\mathbf{X}\|$ .

b) Prouver alors qu'il existe  $\mathbf{U}_1$  et  $\mathbf{V}_1$  telles que

$$\mathbf{X} = \mathbf{U}_1 \mathbf{X}_1 \mathbf{V}_1^T, \quad \mathbf{X}_1 = \left[ \begin{array}{c|c} \sigma_1 & \mathbf{w}^T \\ \hline 0 & \mathbf{Y}_1 \end{array} \right].$$

en précisant les dimensions de  $\mathbf{U}_1, \mathbf{V}_1, \mathbf{w}, \mathbf{Y}_1$ .

c) Montrer que  $\left\| \mathbf{X}_1 \begin{bmatrix} \sigma_1 \\ \mathbf{w} \end{bmatrix} \right\| \geq (\sigma_1^2 + \mathbf{w}^T \mathbf{w})$ . En utilisant la valeur de  $\|\mathbf{X}_1\|$ , en déduire que  $\mathbf{w} = \mathbf{0}$ .

d) Conclure.

### Exercice 1.6: SVD tronquée

Soit  $\mathbf{X} \in \mathbb{R}^{m \times n}$  de rang  $r$ ,  $\mathbf{U}\Sigma\mathbf{V}^T$  une SVD réduite de  $\mathbf{X}$  avec  $\sigma_1 > \dots > \sigma_r > 0$ .

a) On considère la SVD tronquée  $\mathbf{X}_k = \mathbf{U}_k \Sigma_{k,k} \mathbf{V}_k^T$ . Evaluer  $\|\mathbf{X} - \mathbf{X}_k\|_F^2$ .

b) Application : Supposons que  $\sigma_i^2 = \frac{1}{2^i} \forall i = 1, \dots, m$ . Pour tout  $\epsilon > 0$ , déterminer le plus petit  $k$  tel que  $\|\mathbf{X} - \mathbf{X}_k\|_F^2 \leq \epsilon^2$ .

## Solutions

### Solution de l'exercice 1.1: Valeurs propres et valeurs singulières

a) Comme  $A = U\Sigma V^T$  et  $V$  est orthogonale, on a  $AV = U\Sigma$ . Par conséquent, pour tout  $i$  entre 1 et  $\min(m, n)$ ,  $Av_i$  est la  $i$ -ème colonne de  $AV$ , et donc de  $U\Sigma$ . Cette  $i$ -ème colonne est obtenue par le produit

$$[\mathbf{u}_1 \cdots \mathbf{u}_i \cdots \mathbf{u}_m] \begin{bmatrix} 0 \\ \vdots \\ 0 \\ \sigma_i \\ 0 \\ \vdots \\ 0 \end{bmatrix} = \begin{bmatrix} \sigma_i [\mathbf{u}_i]_1 \\ \vdots \\ \vdots \\ \sigma_i [\mathbf{u}_i]_m \end{bmatrix} = \sigma_i \mathbf{u}_i,$$

d'où le résultat. La seconde propriété  $A^T \mathbf{u}_i = \sigma_i \mathbf{v}_i$  s'obtient de manière identique en utilisant  $A^T = V\Sigma^T U^T$ .

b) Pour tout  $i \leq \min(m, n)$ , on a

$$A^T A \mathbf{v}_i = \sigma_i A^T \mathbf{u}_i = \sigma_i^2 \mathbf{v}_i,$$

d'où l'on obtient que  $\sigma_i^2$  est une valeur propre de  $A^T A$  (et  $\mathbf{v}_i$  un vecteur propre associé). Comme les  $\mathbf{v}_i$  forment une base de l'espace  $\mathbb{R}^n$  ( $V$  est orthogonale), on peut conclure que l'ensemble des  $\{\sigma_i^2\}_i$  est *exactement* l'ensemble des valeurs propres de  $A^T A$ .

c) D'après les résultats précédents, si  $\text{rang}(A) = \text{rang}(A^T A) = r$ , alors il y a exactement  $r$  valeurs singulières de  $A$  non nulles.

### Solution de l'exercice 1.2: Carrés de matrices

a) On a  $A = P\Lambda P^T$ . Une décomposition en valeurs singulières de  $A$  est de la forme  $U\Sigma V^T$ , où  $U$  et  $V$  doivent être des matrices orthogonales de taille  $n \times n$ , et  $\Sigma$  doit être de taille  $n \times n$  diagonale (car carrée ici). Pour obtenir une décomposition qui convienne à cette définition, il suffit de poser :

$$U = P, \quad \Sigma = \Lambda, \quad V = P.$$

b) La matrice  $B$  est définie positive, donc symétrique. Elle admet donc une décomposition en valeurs propres, qui s'écrit  $QDQ^T$ , où  $Q$  est orthogonale et  $D$  diagonale. Comme  $B^2 = A$ , on a alors :

$$B^2 = QDQ^T QDQ^T = QD^2Q^T = P\Lambda P^T = A.$$

En posant  $Q = P$  et  $D = \Lambda^{1/2}$  (matrice diagonale dont les coefficients diagonaux sont  $\sqrt{\Lambda_{11}}, \sqrt{\Lambda_{22}}, \dots, \sqrt{\Lambda_{nn}}$  dans cet ordre), on obtient bien le résultat.

Par le même raisonnement qu'à la question a), on en déduit que la décomposition  $P\Lambda^{1/2}P^T$  est également une décomposition en valeurs singulières de  $B$ .

c) En utilisant la décomposition de  $B$  trouvée dans la question précédente, on a :

$$\begin{aligned}
 B^T B &= (QDQ^T)^T QDQ^T \\
 &= QD^T Q^T QDQ^T \\
 &= QDQ^T QDQ^T \\
 &= QD^2 Q^T \\
 &= P\Lambda P^T.
 \end{aligned}$$

On a donc  $B^T B = A$ : les valeurs propres de  $B^T B$  sont donc celles de  $A$ . Celles-ci sont les carrés des valeurs propres de  $B$ , qui sont aussi les valeurs singulières de  $B$ . On retrouve donc sur cet exemple la propriété que les valeurs propres de  $B^T B$  sont les carrés des valeurs singulières de  $B$ , qui est vraie pour toute matrice réelle.

### Solution de l'exercice 1.3: SVD et factorisation QR

a) Une décomposition valide en valeurs singulières de  $CX$  est  $U_C \Sigma V^T$  avec  $U_C = CU \in \mathbb{R}^{m \times m}$ , qui est bien une matrice orthogonale.

b) On utilise la relation  $X = QR \Leftrightarrow R = Q^T X$  (qui est valide car  $Q$  est orthogonale par hypothèse). En appliquant le résultat de la question a) avec  $C = Q^T$ , on obtient  $R = (Q^T U) \Sigma V^T$ , où les matrices  $Q^T U$ ,  $\Sigma$  et  $V$  forment les facteurs de la décomposition en valeurs singulières.

### Solution de l'exercice 1.4: Normes et valeurs singulières

a) Soit  $U \Sigma V^T$  une décomposition en valeurs singulières de  $A$ , avec  $\Sigma$  à coefficients diagonaux  $\sigma_1 \geq \dots \geq \sigma_{\min(m,n)}$ .

Le raisonnement se base sur les propriétés des matrices  $U$  et  $V^T$ . La matrice  $U$  est orthogonale par définition de la SVD : on a donc  $\|Uy\| = \|y\|$  pour tout  $y \in \mathbb{R}^m$ . La matrice  $V$  est également orthogonale, ce qui signifie que  $V^T = V^{-1}$  l'est aussi. On a donc  $\|x\| = \|V^T x\|$  pour tout  $x \in \mathbb{R}^n$ ; de plus, l'inversibilité de  $V^T$  garantit que

$$\{ z \in \mathbb{R}^n \mid z = V^T x, x \in \mathbb{R}^n \} = \mathbb{R}^n.$$

En conséquence,

$$\begin{aligned}
 \max_{\substack{x \in \mathbb{R}^n \\ x \neq 0}} \frac{\|Ax\|}{\|x\|} &= \max_{\substack{x \in \mathbb{R}^n \\ x \neq 0}} \frac{\|U \Sigma V^T x\|}{\|x\|} \\
 &= \max_{\substack{x \in \mathbb{R}^n \\ x \neq 0}} \frac{\|\Sigma V^T x\|}{\|x\|} \\
 &= \max_{\substack{x \in \mathbb{R}^n \\ x \neq 0}} \frac{\|\Sigma V^T x\|}{\|V^T x\|} \\
 &= \max_{\substack{z \in \mathbb{R}^n \\ z \neq 0}} \frac{\|\Sigma z\|}{\|z\|}.
 \end{aligned}$$

On en déduit donc que  $\|\mathbf{A}\| = \|\mathbf{\Sigma}\|$ . Le calcul explicite de cette seconde norme est possible, car on a :

$$\begin{aligned}
 \max_{\substack{\mathbf{z} \in \mathbb{R}^n \\ \mathbf{z} \neq \mathbf{0}}} \frac{\|\mathbf{\Sigma}\mathbf{z}\|}{\|\mathbf{z}\|} &= \max_{\substack{\mathbf{z} \in \mathbb{R}^n \\ \|\mathbf{z}\|=1}} \|\mathbf{\Sigma}\mathbf{z}\| \\
 &= \max_{\substack{\mathbf{z} \in \mathbb{R}^n \\ \|\mathbf{z}\|=1}} \left\| \begin{array}{c} \sigma_1 z_1 \\ \vdots \\ \sigma_{\min(m,n)} z_{\min(m,n)} \\ 0 \\ \vdots \\ 0 \end{array} \right\| \\
 &= \max_{\substack{\mathbf{z} \in \mathbb{R}^n \\ \|\mathbf{z}\|=1}} \sqrt{\sum_{i=1}^{\min(m,n)} \sigma_i^2 z_i^2} \\
 &\leq \max_{\substack{\mathbf{z} \in \mathbb{R}^n \\ \|\mathbf{z}\|=1}} \sqrt{\sum_{i=1}^{\min(m,n)} \sigma_1^2 z_i^2} \\
 &= \max_{\substack{\mathbf{z} \in \mathbb{R}^n \\ \|\mathbf{z}\|=1}} \sigma_1 \sqrt{\sum_{i=1}^{\min(m,n)} z_i^2} \\
 &\leq \max_{\substack{\mathbf{z} \in \mathbb{R}^n \\ \|\mathbf{z}\|=1}} \sigma_1 \|\mathbf{z}\| = \sigma_1.
 \end{aligned}$$

Il suffit ensuite de noter que le choix  $\mathbf{z} = \begin{bmatrix} 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$  vérifie  $\|\mathbf{\Sigma}\mathbf{z}\| = \sigma_1$  pour justifier que cette inégalité

est en fait une égalité.

On a donc prouvé que  $\|\mathbf{A}\| = \|\mathbf{\Sigma}\| = \sigma_1$ .

**b)** Si  $\mathbf{A}$  est carrée diagonalisable, on a  $\mathbf{A} = \mathbf{P}\mathbf{\Lambda}\mathbf{P}^T$  avec  $\mathbf{P}$  orthogonale et  $\mathbf{\Lambda}$  est diagonale. On a alors  $\mathbf{A}^T\mathbf{A} = \mathbf{P}\mathbf{\Lambda}^2\mathbf{P}^T$ , et on peut donc définir  $\lambda_1^2 \geq \dots \geq \lambda_n^2$  comme les valeurs propres de cette matrice. On sait que les valeurs singulières de  $\mathbf{A}$  sont les racines carrées des valeurs propres de  $\mathbf{A}^T\mathbf{A}$ , et on a donc  $\sigma_1 = |\lambda_1|$ . On retrouve ainsi le fait que la norme matricielle  $\|\cdot\|$  est égale à la plus grande valeur propre (en valeur absolue), ce qu'on appelle également le rayon spectral.

**c)** En utilisant la même décomposition qu'en question a), et les propriétés d'orthogonalité de  $\mathbf{U}$  et  $\mathbf{V}$ , on a  $\|\mathbf{U}\mathbf{x}\| = \|\mathbf{x}\|$  pour tout  $\mathbf{x} \in \mathbb{R}^m$ , et  $\|\mathbf{z}\mathbf{V}^T\| = \|\mathbf{z}\|$  pour tout  $\mathbf{z} \in \mathbb{R}^n$ . Or, pour toute matrice  $\mathbf{M} \in \mathbb{R}^{m \times n}$ , la définition de  $\|\mathbf{M}\|_F$  donne

$$\|\mathbf{M}\|_F = \sqrt{\|\mathbf{m}_{1\bullet}\|^2 + \dots + \|\mathbf{m}_{m\bullet}\|^2} = \sqrt{\|\mathbf{m}_{\bullet 1}\|^2 + \dots + \|\mathbf{m}_{\bullet n}\|^2}$$

où  $M = \begin{bmatrix} m_{1\bullet}^T \\ \vdots \\ m_{m\bullet}^T \end{bmatrix} = [m_{\bullet 1} \cdots m_{\bullet n}]$  (la norme de Frobenius d'une matrice au carré est égale à la somme des carrés des normes de ses colonnes ou de ses lignes). Par conséquent, on a aussi  $\|UM\|_F = \|MV^T\|_F = \|M\|_F$  si  $U$  et  $V$  sont orthogonales.

On obtient donc :

$$\|A\|_F = \|U\Sigma V^T\|_F = \|\Sigma\|_F = \sqrt{\sum_{i=1}^{\min(m,n)} \sigma_i^2}.$$

## Solution de l'exercice 1.5: Preuve constructive de la SVD

a) Par définition de  $\|X\| = \max_{\substack{z \in \mathbb{R}^n \\ \|z\|=1}} \|Xz\|$ , il existe un vecteur  $v_1 \in \mathbb{R}^n$  de norme 1 tel que  $\|Xv_1\| = \|X\|$ . En posant  $u_1 = \frac{Xv_1}{\sigma_1}$  avec  $\sigma_1 = \|X\|$ , on obtient bien les vecteurs souhaités.

b) Soient  $U_1$  et  $V_1$  des matrices orthogonales, respectivement dans  $\mathbb{R}^{m \times m}$  et  $\mathbb{R}^{n \times n}$ , telles que  $u_1$  et  $v_1$  soient les premières colonnes des matrices  $U_1$  et  $V_1$ , respectivement. Soient  $u_1^{(1)}, \dots, u_{m-1}^{(1)}$  et  $v_1^{(1)}, \dots, v_{n-1}^{(1)}$  les colonnes restantes de  $U_1$  et  $V_1$ . On peut alors considérer la matrice  $U_1^T X V_1$ , dont les coefficients sont donnés par :

$$\left[ \begin{array}{c|c} u_1^T X v_1 & [u_1^T X v_j^{(1)}]_{j=1, \dots, n-1} \\ \hline [(u_i^{(1)})^T X v_1]_{i=1, \dots, m-1} & [(u_i^{(1)})^T X v_j^{(1)}]_{\substack{i=1, \dots, m-1 \\ j=1, \dots, n-1}} \end{array} \right].$$

Notre but est de montrer que cette matrice est de la forme :

$$U_1^T X V_1 = \begin{bmatrix} \sigma_1 & w^T \\ 0 & Y_1 \end{bmatrix},$$

où  $w \in \mathbb{R}^{n-1}$  et  $Y_1 \in \mathbb{R}^{(m-1) \times (n-1)}$ .

On a  $u_1^T X v_1 = \sigma_1 u_1^T u_1 = \sigma_1 \|u_1\|^2 = \sigma_1$  d'après la première question.

Par ailleurs, pour tout  $j = 1, \dots, n-1$ , on a :

$$u_1^T X v_j^{(1)} = u_1^T u_j^{(1)} = 0$$

car  $V_1$  est une matrice orthogonale.

En posant  $w = [u_1^T X v_j^{(1)}]_{j=1, \dots, n-1}$  et  $Y_1 = [(u_i^{(1)})^T X v_j^{(1)}]_{\substack{i=1, \dots, m-1 \\ j=1, \dots, n-1}}$ , on obtient alors la décomposition recherchée.

c) On a :

$$X_1 \begin{bmatrix} \sigma_1 \\ w \end{bmatrix} = \begin{bmatrix} \sigma_1 & w^T \\ 0 & Y_1 \end{bmatrix} \begin{bmatrix} \sigma_1 \\ w \end{bmatrix} = \begin{bmatrix} \sigma_1^2 + w^T w \\ Y_1 w \end{bmatrix}.$$

Par conséquent,

$$\left\| X_1 \begin{bmatrix} \sigma_1 \\ w \end{bmatrix} \right\| = \left\| \begin{bmatrix} \sigma_1^2 + w^T w \\ Y_1 w \end{bmatrix} \right\| \geq \left\| \begin{bmatrix} \sigma_1^2 + w^T w \\ 0 \end{bmatrix} \right\| \geq \sigma_1^2 + w^T w$$

où l'on a utilisé la définition de la norme d'un vecteur pour obtenir l'avant-dernière égalité. On remarque que  $\sigma_1^2 + \mathbf{w}^T \mathbf{w} = \left\| \begin{bmatrix} \sigma_1 \\ \mathbf{w} \end{bmatrix} \right\|^2$ .

Il s'agit maintenant d'établir que  $\mathbf{w} = \mathbf{0}$ . Pour cela, on utilise le fait que  $\|\mathbf{X}_1\| = \|\mathbf{X}\| = \sigma_1$ , car la norme ne change pas par multiplication avec une matrice orthogonale<sup>1</sup>. Cela signifie que

$$\begin{aligned} \sigma_1 &= \max_{\substack{\mathbf{x} \in \mathbb{R}^n \\ \mathbf{x} \neq \mathbf{0}}} \frac{\|\mathbf{X}_1 \mathbf{x}\|}{\|\mathbf{x}\|} \\ &\geq \frac{\left\| \mathbf{X}_1 \begin{bmatrix} \sigma_1 \\ \mathbf{w} \end{bmatrix} \right\|}{\left\| \begin{bmatrix} \sigma_1 \\ \mathbf{w} \end{bmatrix} \right\|} \\ &\geq \frac{\sigma_1^2 + \mathbf{w}^T \mathbf{w}}{\sqrt{\sigma_1^2 + \mathbf{w}^T \mathbf{w}}} \\ &= \sqrt{\sigma_1^2 + \mathbf{w}^T \mathbf{w}}. \end{aligned}$$

Si  $\mathbf{w}^T \mathbf{w} > 0$ , alors on obtient  $\sigma_1 > \sqrt{\sigma_1^2} = \sigma_1$ , ce qui est absurde. On en déduit donc que  $\mathbf{w}^T \mathbf{w} = \|\mathbf{w}\|^2 = 0$ , donc que  $\mathbf{w}$  est un vecteur nul.

**d)** Dans les questions précédentes, on a prouvé que l'on pouvait définir des matrices  $\mathbf{U}_1$  et  $\mathbf{V}_1$  telles que

$$\mathbf{U}_1^T \mathbf{X} \mathbf{V}_1 = \left[ \begin{array}{c|c} \sigma_1 & 0 \\ \hline 0 & \mathbf{Y} \end{array} \right].$$

avec  $\sigma_1 = \|\mathbf{X}\|$ . On peut maintenant appliquer cette technique à  $\mathbf{Y}$ , et obtenir des matrices orthogonales  $\mathbf{U}_2 \in \mathbb{R}^{(m-1) \times (m-1)}$  et  $\mathbf{V}_2 \in \mathbb{R}^{(n-1) \times (n-1)}$  telles que

$$\mathbf{U}_2^T \mathbf{Y} \mathbf{V}_2 = \left[ \begin{array}{c|c} \sigma_2 & 0 \\ \hline 0 & \mathbf{Z} \end{array} \right].$$

où  $\sigma_2 = \|\mathbf{Y}\|$  et  $\mathbf{Z} \in \mathbb{R}^{(m-2) \times (n-2)}$ . Soient  $\mathbf{U}_{12} = [\mathbf{u}_1 \ \mathbf{U}_2] \mathbf{U}_1$  et  $\mathbf{V}_{12} = [\mathbf{v}_1 \ \mathbf{V}_2] \mathbf{V}_1$ : on peut vérifier que ces matrices sont bien orthogonales comme produits de matrices elles-mêmes orthogonales, et on a alors :

$$\mathbf{U}_{12}^T \mathbf{X} \mathbf{V}_{12} = \left[ \begin{array}{c|c|c} \sigma_1 & 0 & 0 \\ \hline 0 & \sigma_2 & 0 \\ \hline 0 & 0 & \mathbf{Z} \end{array} \right].$$

En répétant cette opération autant de fois que nécessaire, on obtiendra donc une décomposition qui s'identifie à la décomposition en valeurs singulières.

## Solution de l'exercice 1.6: SVD tronquée

**a)** On a :

$$\|\mathbf{X} - \mathbf{X}_k\|_F^2 = \left\| \mathbf{U} \mathbf{\Sigma} \mathbf{V}^T - \mathbf{U} \left[ \begin{array}{c|c} \mathbf{\Sigma}_{k,k} & 0 \\ \hline 0 & 0 \end{array} \right] \mathbf{V}^T \right\|_F^2.$$

<sup>1</sup>Note : contrairement à l'exercice 4, on a défini ici  $\sigma_1 \stackrel{d}{=} \|\mathbf{X}\|$ .

La norme de Frobenius est invariante par multiplication avec une matrice orthogonale; on a donc

$$\|\mathbf{X} - \mathbf{X}_k\|_F^2 = \left\| \Sigma - \left[ \begin{array}{c|c} \Sigma_{k,k} & 0 \\ \hline 0 & 0 \end{array} \right] \right\|_F^2 = \sum_{i=k+1}^r \sigma_i^2.$$

**b)** D'après ce qui précède,

$$\begin{aligned} \|\mathbf{X} - \mathbf{X}_k\|_F^2 &= \sum_{i=k+1}^r \sigma_i^2 \\ &= \sum_{i=k+1}^r \frac{1}{2^i} \\ &= \frac{1}{2^{k+1}} \frac{1 - (1/2)^{r-k}}{1 - 1/2} = \frac{2^{r-k} - 1}{2^r}. \end{aligned}$$

On a donc  $\|\mathbf{X} - \mathbf{X}_k\|_F^2 > \epsilon^2$  si

$$\frac{2^{r-k} - 1}{2^r} > \epsilon^2 \Leftrightarrow k < r - \log_2(1 + 2^r \epsilon^2).$$

La valeur cherchée est donc  $\lceil r - \log_2(1 + 2^r \epsilon^2) \rceil$ .