

TD 3

On admet le résultat suivant, l'une des conséquences les plus importantes de la SVD :

Théorème d'Eckart-Young

Soit $\mathbf{A} \in \mathbb{R}^{n \times d}$. La norme de Frobenius de \mathbf{A} est définie par $\|\mathbf{A}\|_F^2 = \sum_{i,j} A_{ij}^2$. Soit E_r l'ensemble des matrices $\mathbf{B} \in \mathbb{R}^{n \times d}$ telles que $\text{rang}(\mathbf{B}) \leq r \leq \min(d, n)$. On écrit la décomposition SVD de $\mathbf{A} = \sum_{i=1}^{\min(n,d)} \sigma_i \mathbf{u}_i \mathbf{v}_i^\top$, où $\sigma_1 \geq \sigma_2 \geq \dots$. Alors la meilleure approximation de rang maximal r de \mathbf{A} définie par

$$\min_{\mathbf{B} \in E_r} \|\mathbf{A} - \mathbf{B}\|_F^2$$

est donnée par :

$$\mathbf{B}^* = \sum_{i=1}^r \sigma_i \mathbf{u}_i \mathbf{v}_i^\top$$

Exercice 1 (Lemme : Décomposition matricielle)

Soit $\mathbf{A} \in \mathbb{S}_d$ une matrice symétrique semi-définie positive de taille d . On suppose que son rang est égal à r . Montrez qu'il existe $\mathbf{Z} \in \mathbb{R}^{d \times r}$ telle que :

$$\mathbf{A} = \mathbf{Z}\mathbf{Z}^\top$$

Exercice 2 (Classical MDS)

Soit $\mathbf{X} \in \mathbb{R}^{n \times d}$ une matrice des données en dimension d d'un vecteur aléatoire centré. Classical MDS cherche la meilleure représentation en dimension $q < d$ ($\mathbf{Z} \in \mathbb{R}^{n \times q}$) qui préservent les produits scalaires $\langle \mathbf{x}_i, \mathbf{x}_j \rangle$. Ainsi on cherche à résoudre :

$$\min_{\mathbf{z}_1, \dots, \mathbf{z}_n \in \mathbb{R}^q} \sum_{i,j}^n (\mathbf{x}_i^\top \mathbf{x}_j - \mathbf{z}_i^\top \mathbf{z}_j)^2$$

1. Comment peut-on écrire le problème d'optimisation ci-dessus en fonction des matrices \mathbf{X} et \mathbf{Z} et de la norme de Frobenius ?
2. Montrez que le problème Classical MDS est équivalent à une approximation de faible rang et en déduire que la solution est donnée par les q premiers vecteurs propres de la matrice $\mathbf{X}\mathbf{X}^\top$ multipliés par des scalaires à déterminer.
3. En effectuant une SVD de \mathbf{X} , déterminez les valeurs propres et les vecteurs propres de $\mathbf{X}\mathbf{X}^\top$ et $\mathbf{X}^\top\mathbf{X}$ en fonction des éléments de la SVD de \mathbf{X} .
4. En déduire que les projets \mathbf{z}_i sont les mêmes que les projets $\text{PCA}_q(\mathbf{x}_i)$.


Exercice 3 (Classical MDS : double centering)

Soit $\mathbf{X} \in \mathbb{R}^{n \times d}$ une matrice des données en dimension d d'un vecteur aléatoire centré, on suppose donc que la moyenne empirique est nulle. On suppose que l'on a pas accès à la matrice \mathbf{X} ni aux produits scalaires $\langle \mathbf{x}_i, \mathbf{x}_j \rangle$. Mais on a la matrice des distances Euclidiennes $D_{ij} = \|\mathbf{x}_i - \mathbf{x}_j\|^2$. On définit $A \stackrel{\text{def}}{=} \mathbf{X}\mathbf{X}^\top$.

- Écrivez d_{ij} en fonction de A_{ij} , A_{ii} et A_{jj} .
- Calculez $\sum_{i=1}^n d_{ij}$ et $\sum_{j=1}^n d_{ij}$ et $\sum_{i,j} d_{ij}$ en fonction de A_{jj} , A_{ii} et $\text{trace}(A)$.
- En déduire A_{ij} en fonction des termes de D .
- Montrez que $A = -\frac{1}{2}H D H$ où $H = I_n - \frac{1}{n}1_n 1_n^\top$.
- On appelle H une matrice de centrage. Pourquoi ?
- En déduire un algorithme Classical MDS à appliquer sur une matrice des distances $D \in \mathbb{R}^{n \times n}$.

Exercice 4 (Analyse de données)


On observe 200 observations en deux dimensions. On applique la PCA et Isomap avec 10 voisins en deux dimensions dans le but d'essayer d'isoler les deux clusters à part et de pouvoir les séparer avec une droite.



- La PCA semble avoir échangé les deux variables. Expliquez pourquoi.
- La PCA n'a pas réussi à séparer les deux clusters. Qu'en est-il de Classical MDS ?
- Et si on utilisait MDS avec les distances Euclidiennes ?
- Expliquez la capacité d'Isomap à rassembler les deux classes.

Exercice 5 (Prédiction simple)

On observe n observations en deux dimensions données par la matrice $X \in \mathbb{R}^{n \times 2}$ pour lesquels on a des labels binaires y_1, \dots, y_n . On observe également 3 échantillons " X_{test} " pour lesquels on n'a pas accès aux labels. Voici la visualisation entière de ces données.



- Si on transforme ces données avec une PCA avec deux composantes, la représentation des données serait-elle différente des données d'origine ? Justifiez votre réponse.
- On souhaite utiliser les données labélisées pour prédire les labels des 3 observations de test. En se basant sur la figure ci-dessus, déterminez les labels des trois échantillons de gauche à droite en utilisant le modèle k-Nearest-Neighbors avec $k = 1$ et $k = 2$ et $k = n$.
- À quoi correspond la fonction de prédiction k-NN $\varphi : \mathbf{x} \in \mathbb{R}^2 \mapsto \mathbf{y} \in \{0, 1\}$ si $k = n$?