

Fondements du Machine Learning

Clément Royer

Licence 3 Informatique et Mathématiques pour la Décision et les Données

7 septembre 2020



- Nous sommes en distanciel au moins jusqu'en octobre...
- Réunion de rentrée tout à l'heure;
- Pas de présentiel avant un moment.

- Nous sommes en distanciel au moins jusqu'en octobre...
- Réunion de rentrée tout à l'heure;
- Pas de présentiel avant un moment.

Présentez-vous !

Dans le chat :

- Nom+Prénom;
- Université/Établissement en 2019-2020;
- Ville de naissance (ou votre ville préférée).

Enseignant : Clément Royer



- Né à Pau (Pyrénées-Atlantiques);
- Maître de conférences à Dauphine (MIDO) depuis 2019;
- Chercheur au LAMSADE en optimisation pour les sciences des données;
- Email :
`clement.royer@dauphine.psl.eu`
- [Lien vers ma page personnelle](#)

Liens utiles

- Page du cours :
<https://www.lamsade.dauphine.fr/~croyer/coursFML.html>
- Polycopié (mis à jour au fil de l'eau).
- Espace My Course dédié :
A3IIMD_20/21_Fondements du machine learning_Clément ROYER
- Équipe dédiée sur Microsoft Teams;

Utilisation des ressources

- Teams pour les séances;
- Documents accessibles via ma page personnelle.

Telle qu'annoncée

- Cours :
 - Lundi 10h15-11h45;
 - Dernier cours le 23/11, pas de cours les 26/10 et 09/11;
- TD :
 - Mardi 13h45-15h15;
 - Premier TD le 15/09, dernier le 24/11;

Évaluation

- $\text{Note} = 0.3 \cdot \text{CC} + 0.7 \cdot \text{E}$;
- Contrôle continu : En présentiel si possible, devoir maison sinon.
- Examen : En janvier.

En temps normal

- Ponctualité;
- Discussions;
- **Retours.**

Ces temps-ci

- **Coupez votre micro** quand vous n'intervenez pas ou que vous arrivez en retard;
- Échangez via le chat/les canaux dédiés.

En temps normal

- Cours le lundi;
- TD le mardi.

En temps normal

- Cours le lundi;
- TD le mardi.

Ces temps-ci

- **Polycopié disponible en avance de phase;**
- Chaque semaine, un sujet, avec cours + exercices;
 - Idéalement, cours/preuves lundi, TD le mardi;
 - Mais le fonctionnement est flexible!

- Présenter des modèles simples d'**analyse de données**...
- ...très fréquents en **apprentissage machine** (*machine learning*).
- **Outils** : algèbre linéaire, probabilités/statistiques.

- Introduction et motivation;
- Algèbre linéaire et modèles linéaires :
 - Décomposition en valeurs propres/valeurs singulières;
 - Moindres carrés linéaires.
- Outils statistiques :
 - Statistique unidimensionnelle;
 - Compromis biais-variance.
- **Régression linéaire:**
 - Simple, multiple;
 - Régularisation.
- Réduction de dimension:
 - **Analyse en composantes principales;**
 - Applications.

Différents domaines

- Analyse de données (*data analysis*);
- Fouille de données (*data mining*);
- Apprentissage [machine/automatique/artificiel] (*machine learning*);
- Intelligence artificielle (*AI*);
- Masses de données (*Big Data*);
- etc.

Différents domaines

- Analyse de données (*data analysis*);
- Fouille de données (*data mining*);
- Apprentissage [machine/automatique/artificiel] (*machine learning*);
- Intelligence artificielle (*AI*);
- Masses de données (*Big Data*);
- etc.

Sciences des données (*data science*)

Ensemble de **techniques** qui visent à extraire de l'information d'un jeu de **données**.

Ensemble de **techniques** qui visent à extraire de l'information d'un jeu de **données**.

Principe 1: Grande quantité de données

- Pour avoir de l'information à extraire;
- Pour être représentatif.

Ensemble de **techniques** qui visent à extraire de l'information d'un jeu de **données**.

Principe 1: Grande quantité de données

- Pour avoir de l'information à extraire;
- Pour être représentatif.

Principe 2: Utilisation d'algorithmes

- Traitement systématique et efficace;
- Théorie mathématique+implémentation.

Pourquoi s'intéresser aux données ?

Essentiel pour les entreprises

- Modèle économique des GAF(A)M);
- Service gratuit mais valeur dans l'exploitation des données.

Pourquoi s'intéresser aux données ?

Essentiel pour les entreprises

- Modèle économique des GAF(A)(M);
- Service gratuit mais valeur dans l'exploitation des données.

Important pour la recherche

- Quantité massive de données générées en biologie, médecine,...
- Difficultés mathématiques et informatiques.

Pourquoi s'intéresser aux données ?

Essentiel pour les entreprises

- Modèle économique des GAF(A)M);
- Service gratuit mais valeur dans l'exploitation des données.

Important pour la recherche

- Quantité massive de données générées en biologie, médecine,...
- Difficultés mathématiques et informatiques.

Approches guidées par les données

Ou data-driven, drivées par les données, etc.

- Pallie le manque de modèles formels;
- Pourrait remplacer la modélisation à terme.

But : Suggérer du contenu en se basant sur les préférences.

- Séries/Films/Vidéos (Netflix, Youtube);
- Produits commerciaux (Ebay, Amazon);
- Hôtels/Restaurants/Voyages (Google, Facebook).

But : Suggérer du contenu en se basant sur les préférences.

- Séries/Films/Vidéos (Netflix, Youtube);
- Produits commerciaux (Ebay, Amazon);
- Hôtels/Restaurants/Voyages (Google, Facebook).

Outil : Une matrice des avis (Clients/Produits).

But : Suggérer du contenu en se basant sur les préférences.

- Séries/Films/Vidéos (Netflix, Youtube);
- Produits commerciaux (Ebay, Amazon);
- Hôtels/Restaurants/Voyages (Google, Facebook).

Outil : Une matrice des avis (Clients/Produits).

Les grandes questions

Comment suggérer du contenu pertinent, et donc...

- 1 Quels sont les éléments principaux de nos préférences ?
- 2 Comment gérer un grand nombre d'avis ?
- 3 Les avis reflètent-ils vraiment la réalité ?

Fondamentaux de l'apprentissage (*machine learning*)

- Des modèles **linéaires** de l'information dans les données;
- Les données sont vues comme des réalisations de variables aléatoires (typiquement **gaussiennes**).

Fondamentaux de l'apprentissage (*machine learning*)

- Des modèles **linéaires** de l'information dans les données;
- Les données sont vues comme des réalisations de variables aléatoires (typiquement **gaussiennes**).

Solide sur les fondamentaux

- Souvent efficace en pratique;
- Très souvent le premier cas considéré en recherche;
- Utilise des savoirs fondamentaux en algèbre linéaire, statistiques (et optimisation).

Modèle fonctionnel

- Distribution (de probabilité) des données connue;
- Développement de modèles ad hoc;
- Apprentissage supervisé.

⇒ **Régression linéaire.**

Modèle fonctionnel

- Distribution (de probabilité) des données connue;
- Développement de modèles ad hoc;
- Apprentissage supervisé.

⇒ **Régression linéaire.**

Modèle prédictif

- Pas de distribution connue;
- Extraction d'information des données;
- Fréquent en apprentissage non supervisé.

⇒ **Analyse en composante principales.**

Machine learning/Apprentissage

- Décrire le comportement de données;
- Prédire les propriétés de données futures.

Notre approche

- Le cas linéaire : souvent efficace et populaire en pratique.
- Le modèle linéaire : permet de présenter les enjeux et les outils fondamentaux.

- 1 Préambule
- 2 Introduction et motivation
- 3 Rappels et compléments en algèbre linéaire matricielle

1 Préambule

2 Introduction et motivation

3 **Rappels et compléments en algèbre linéaire matricielle**

- **Notations et résultats de base**
- Valeurs propres et décomposition spectrale
- Décomposition en valeurs singulières

Objectif 1 : Fixer les notations

- Différentes écoles : dauphinoise, toulousaine, anglo-saxonne,...
- Un seul cours !

Objectif 2 : Parler le même langage

- Lever toute ambiguïté dès le départ...
- ...pour se rapprocher de notations usuelles (recherche+industrie).

Notations en algèbre linéaire

- Coefficients/Scalars : α, β, γ ;
- Vecteurs/Variables : x, y, z ;
- Matrices : A, B, C .

Notations en algèbre linéaire

- Coefficients/Scalars : α, β, γ ;
- Vecteurs/Variables : x, y, z ;
- Matrices : A, B, C .

Notations en statistiques

- Coefficients/Scalars : $a, b, c, \dots, \alpha, \beta, \gamma$;
- Vecteurs/Variables : α, β, μ ;
- Matrices : X, Y, Z, \dots

Conventions

- Scalaires : $a, b, c, \dots, \alpha, \beta, \gamma$;
- Vecteurs : $\mathbf{a}, \mathbf{b}, \mathbf{c}, \dots, \alpha, \beta, \gamma$;
- Matrices : $\mathbf{A}, \mathbf{B}, \mathbf{C}$.

Distinction

- Partie algèbre linéaire : \mathbf{x}, \mathbf{y} génériques;
- Partie statistiques et seq : $\mathbf{x}, \mathbf{y}, \mathbf{X}, \mathbf{Y}$ représenteront les **données**.

Notations vectorielles

- \mathbb{R}^n : ensemble des vecteurs à $n \geq 1$ composantes réelles;
- Par convention, $\mathbf{x} \in \mathbb{R}^n$ est un vecteur colonne, et on note \mathbf{x}^T le vecteur ligne correspondant.
- Pour tout $\mathbf{x} \in \mathbb{R}^n$ et tout $i \in \{1, \dots, n\}$, on notera $x_i \in \mathbb{R}$ sa i -ème coordonnée (dans la base canonique de \mathbb{R}^n) $\Rightarrow \mathbf{x} = [x_i]_{1 \leq i \leq n}$.

Notations vectorielles

- \mathbb{R}^n : ensemble des vecteurs à $n \geq 1$ composantes réelles;
- Par convention, $\mathbf{x} \in \mathbb{R}^n$ est un vecteur colonne, et on note \mathbf{x}^T le vecteur ligne correspondant.
- Pour tout $\mathbf{x} \in \mathbb{R}^n$ et tout $i \in \{1, \dots, n\}$, on notera $x_i \in \mathbb{R}$ sa i -ème coordonnée (dans la base canonique de \mathbb{R}^n) $\Rightarrow \mathbf{x} = [x_i]_{1 \leq i \leq n}$.

Structure d'espace vectoriel normé

- *Addition dans \mathbb{R}^n* : $\mathbf{x} + \mathbf{y} := [x_i + y_i]_{1 \leq i \leq n}$;
- *Multiplication par un réel* :

$$\lambda \mathbf{x} \stackrel{n}{=} \lambda \cdot \mathbf{x} := [\lambda x_i]_{1 \leq i \leq n} ;$$

- *Norme euclidienne* :

$$\|\mathbf{x}\| := \sqrt{\sum_{i=1}^n x_i^2}.$$

Produit scalaire sur \mathbb{R}^n

Le produit scalaire induit par la norme euclidienne est défini pour tous vecteurs $\mathbf{x}, \mathbf{y} \in \mathbb{R}^n$ par

$$\mathbf{x}^T \mathbf{y} := \sum_{i=1}^n x_i y_i.$$

C'est une forme bilinéaire symétrique définie positive (NB : $\mathbf{y}^T \mathbf{x} = \mathbf{x}^T \mathbf{y}$).

Produit scalaire sur \mathbb{R}^n

Le produit scalaire induit par la norme euclidienne est défini pour tous vecteurs $\mathbf{x}, \mathbf{y} \in \mathbb{R}^n$ par

$$\mathbf{x}^T \mathbf{y} := \sum_{i=1}^n x_i y_i.$$

C'est une forme bilinéaire symétrique définie positive (NB : $\mathbf{y}^T \mathbf{x} = \mathbf{x}^T \mathbf{y}$).

Sous-espace engendré

Soient $\mathbf{x}_1, \dots, \mathbf{x}_p$ p vecteurs de \mathbb{R}^n . Le *sous-espace engendré par les vecteurs $\mathbf{x}_1, \dots, \mathbf{x}_p$* est le sous-espace vectoriel

$$\text{vect}(\mathbf{x}_1, \dots, \mathbf{x}_p) := \left\{ \mathbf{x} = \sum_{i=1}^p \alpha_i \mathbf{x}_i \mid \alpha_i \in \mathbb{R}^n \forall i \right\}.$$

Ce sous-espace est de dimension au plus $\min\{n, p\}$.

Notations matricielles

- $\mathbb{R}^{m \times n}$: ensemble des matrices à m lignes, n colonnes à coefficients réels (on supposera toujours $m \geq 1$ et $n \geq 1$).
- NB : $\mathbb{R}^{m \times 1} \simeq \mathbb{R}^m$.

Coefficients, lignes et colonnes

Pour $\mathbf{A} \in \mathbb{R}^{m \times n}$, on utilisera

- $[\mathbf{A}]_{ij}$ pour le coefficient (i, j) de \mathbf{A} ;
- \mathbf{a}_i^T pour la i -ème ligne de \mathbf{A} ;
- OU \mathbf{a}_j pour la j -ème colonne de \mathbf{A} .

Les notations suivantes seront équivalentes à \mathbf{A} :

$$[\mathbf{A}_{ij}]_{\substack{1 \leq i \leq m, \\ 1 \leq j \leq n}} \quad \begin{bmatrix} \mathbf{a}_1^T \\ \cdots \\ \mathbf{a}_m^T \end{bmatrix} \quad \text{OU} \quad [\mathbf{a}_1 \cdots \mathbf{a}_n].$$

Définitions

Soit $\mathbf{A} = [\mathbf{A}_{ij}] \in \mathbb{R}^{m \times n}$ une matrice à m lignes et n colonnes.

- La *transposée de \mathbf{A}* , notée \mathbf{A}^T , est la matrice à n lignes et m colonnes telle que

$$\forall i = 1, \dots, m, \forall j = 1, \dots, n, \quad \left[\mathbf{A}^T \right]_{ij} = \mathbf{A}_{ji}.$$

Définitions

Soit $\mathbf{A} = [\mathbf{A}_{ij}] \in \mathbb{R}^{m \times n}$ une matrice à m lignes et n colonnes.

- La *transposée* de \mathbf{A} , notée \mathbf{A}^T , est la matrice à n lignes et m colonnes telle que

$$\forall i = 1, \dots, m, \forall j = 1, \dots, n, \quad \left[\mathbf{A}^T \right]_{ij} = \mathbf{A}_{ji}.$$

Cas des matrices carrées

- $\mathbf{A}^T \in \mathbb{R}^{n \times n}$;
- \mathbf{A} est dite *symétrique* si $\mathbf{A} = \mathbf{A}^T$.

Ex) Matrices diagonales, de covariance, d'adjacence, etc.

Soit $\mathbf{A} \in \mathbb{R}^{m \times n}$.

- Le **noyau** (*kernel/null space*) de \mathbf{A} est le sous-espace vectoriel

$$\ker(\mathbf{A}) := \{\mathbf{x} \in \mathbb{R}^n \mid \mathbf{Ax} = \mathbf{0}_{\mathbb{R}^m}\}.$$

- L'**image** (*range space*) de \mathbf{A} est le sous-espace vectoriel

$$\text{Im}(\mathbf{A}) := \{\mathbf{y} \in \mathbb{R}^m \mid \exists \mathbf{x} \in \mathbb{R}^n, \mathbf{y} = \mathbf{Ax}\}.$$

- Le **rang** (*rank*) de \mathbf{A} , noté $\text{rang}(\mathbf{A})$, est la dimension du sous-espace vectoriel $\text{Im}(\mathbf{A})$. On a $\text{rang}(\mathbf{A}) \leq \min\{m, n\}$.

Soit $\mathbf{A} \in \mathbb{R}^{m \times n}$.

- Le **noyau** (*kernel/null space*) de \mathbf{A} est le sous-espace vectoriel

$$\ker(\mathbf{A}) := \{\mathbf{x} \in \mathbb{R}^n \mid \mathbf{Ax} = \mathbf{0}_{\mathbb{R}^m}\}.$$

- L'**image** (*range space*) de \mathbf{A} est le sous-espace vectoriel

$$\text{Im}(\mathbf{A}) := \{\mathbf{y} \in \mathbb{R}^m \mid \exists \mathbf{x} \in \mathbb{R}^n, \mathbf{y} = \mathbf{Ax}\}.$$

- Le **rang** (*rank*) de \mathbf{A} , noté $\text{rang}(\mathbf{A})$, est la dimension du sous-espace vectoriel $\text{Im}(\mathbf{A})$. On a $\text{rang}(\mathbf{A}) \leq \min\{m, n\}$.

Théorème du rang

Pour toute matrice $\mathbf{A} \in \mathbb{R}^{m \times n}$, on a

$$\dim(\ker(\mathbf{A})) + \text{rang}(\mathbf{A}) = n.$$

Une matrice $\mathbf{A} \in \mathbb{R}^{n \times n}$ est dite *inversible* s'il existe $\mathbf{B} \in \mathbb{R}^{n \times n}$ telle que $\mathbf{BA} = \mathbf{AB} = \mathbf{I}_n$, où \mathbf{I}_n est la matrice identité de $\mathbb{R}^{n \times n}$.

La matrice \mathbf{B} est alors unique : elle est appelée *l'inverse de \mathbf{A}* et se note \mathbf{A}^{-1} .

Une matrice $\mathbf{A} \in \mathbb{R}^{n \times n}$ est dite *semi-définie positive* si

$$\forall \mathbf{x} \in \mathbb{R}^n, \quad \mathbf{x}^T \mathbf{A} \mathbf{x} \geq 0.$$

Elle est dite *définie positive* lorsque $\mathbf{x}^T \mathbf{A} \mathbf{x} > 0$ pour tout vecteur \mathbf{x} non nul.

1 Préambule

2 Introduction et motivation

3 **Rappels et compléments en algèbre linéaire matricielle**

- Notations et résultats de base
- **Valeurs propres et décomposition spectrale**
- Décomposition en valeurs singulières

Definition

Soit $\mathbf{A} \in \mathbb{R}^{n \times n}$. On dit que $\lambda \in \mathbb{R}$ est une *valeur propre* de \mathbf{A} si

$$\exists \mathbf{v} \in \mathbb{R}^n, \mathbf{v} \neq \vec{0}, \quad \mathbf{A}\mathbf{v} = \lambda\mathbf{v}.$$

Le vecteur \mathbf{v} est alors un *vecteur propre* associé à la *valeur propre* λ .
L'ensemble des valeurs propres de \mathbf{A} s'appelle le *spectre*.

Definition

Soit $\mathbf{A} \in \mathbb{R}^{n \times n}$. On dit que $\lambda \in \mathbb{R}$ est une *valeur propre* de \mathbf{A} si

$$\exists \mathbf{v} \in \mathbb{R}^n, \mathbf{v} \neq \vec{0}, \quad \mathbf{A}\mathbf{v} = \lambda\mathbf{v}.$$

Le vecteur \mathbf{v} est alors un *vecteur propre associé* à la *valeur propre* λ .
L'ensemble des valeurs propres de \mathbf{A} s'appelle le *spectre*.

- Toute matrice de $\mathbb{R}^{n \times n}$ possède n valeurs propres complexes, mais pas nécessairement n valeurs propres réelles.
- Les valeurs propres réelles d'une matrice semi-définie positive (resp. définie positive) sont positives (resp. strictement positives).
- Le noyau de \mathbf{A} est engendré par les vecteurs propres associés à la valeur propre 0.

Théorème

Toute matrice $\mathbf{A} \in \mathbb{R}^{n \times n}$ symétrique admet une décomposition dite **spectrale** de la forme :

$$\mathbf{A} = \mathbf{P}\mathbf{\Lambda}\mathbf{P}^{-1},$$

avec

- $\mathbf{P} \in \mathbb{R}^{n \times n}$ matrice **orthogonale** ($\mathbf{P}^T = \mathbf{P}^{-1}$), dont les colonnes $\mathbf{p}_1, \dots, \mathbf{p}_n$ forment une *base orthonormée* de vecteurs propres.
- $\mathbf{\Lambda}$ matrice diagonale, qui contient les n valeurs propres de \mathbf{A} $\lambda_1, \dots, \lambda_n$ sur la diagonale.

Théorème

Toute matrice $\mathbf{A} \in \mathbb{R}^{n \times n}$ symétrique admet une décomposition dite **spectrale** de la forme :

$$\mathbf{A} = \mathbf{P}\mathbf{\Lambda}\mathbf{P}^{-1},$$

avec

- $\mathbf{P} \in \mathbb{R}^{n \times n}$ matrice **orthogonale** ($\mathbf{P}^T = \mathbf{P}^{-1}$), dont les colonnes $\mathbf{p}_1, \dots, \mathbf{p}_n$ forment une *base orthonormée* de vecteurs propres.
- $\mathbf{\Lambda}$ matrice diagonale, qui contient les n valeurs propres de \mathbf{A} $\lambda_1, \dots, \lambda_n$ sur la diagonale.

- Il n'y a pas unicité de la décomposition spectrale;
- Aux permutations près, l'ensemble des valeurs propres est unique.

Importance de la décomposition

Chaque valeur propre λ_i caractérise l'effet de \mathbf{A} sur le vecteur \mathbf{p}_i :

- $|\lambda_i| \gg 1 \Rightarrow \|\mathbf{A}\mathbf{p}_i\| \gg \|\mathbf{p}_i\|$;
- $|\lambda_i| \ll 1 \Rightarrow \|\mathbf{A}\mathbf{p}_i\| \ll \|\mathbf{p}_i\|$.

Interprétation géométrique

L'action de la matrice \mathbf{A} sur un vecteur \mathbf{x}

- Allonge les composantes de \mathbf{x} dans la base des vecteurs propres associées aux plus grandes valeurs propres en valeur absolue;
- Réduit les composantes de \mathbf{x} associées aux valeurs propres les plus faibles en valeur absolue;
- **Cas extrême** : si $\ker(\mathbf{A}) \neq \{\mathbf{0}\}$, toute composante de \mathbf{x} selon un vecteur du noyau est réduite à zéro par \mathbf{A} .

1 Préambule

2 Introduction et motivation

3 **Rappels et compléments en algèbre linéaire matricielle**

- Notations et résultats de base
- Valeurs propres et décomposition spectrale
- **Décomposition en valeurs singulières**

Notion de valeur propre

Soit $\mathbf{A} \in \mathbb{R}^{m \times n}$. On peut parler :

- des valeurs propres de $\mathbf{A}^T \mathbf{A} \in \mathbb{R}^{n \times n}$;
- des valeurs propres de $\mathbf{A} \mathbf{A}^T \in \mathbb{R}^{m \times m}$.

Peut-on s'en servir pour obtenir une décomposition de \mathbf{A} ?

Le cas des matrices rectangulaires

Notion de valeur propre

Soit $\mathbf{A} \in \mathbb{R}^{m \times n}$. On peut parler :

- des valeurs propres de $\mathbf{A}^T \mathbf{A} \in \mathbb{R}^{n \times n}$;
- des valeurs propres de $\mathbf{A} \mathbf{A}^T \in \mathbb{R}^{m \times m}$.

Peut-on s'en servir pour obtenir une décomposition de \mathbf{A} ?

Observations concernant $\mathbf{A}^T \mathbf{A}$

- $\mathbf{A}^T \mathbf{A}$ est semi-définie positive;
- $\mathbf{A}^T \mathbf{A}$ est symétrique.
- $\ker(\mathbf{A}^T \mathbf{A}) = \ker(\mathbf{A})$;
- $\text{Im}(\mathbf{A}^T \mathbf{A}) = \text{Im}(\mathbf{A}^T)$;
- $\text{rang}(\mathbf{A}^T \mathbf{A}) = \text{rang}(\mathbf{A})$.

(On a des résultats similaires pour $\mathbf{A} \mathbf{A}^T$.)

Théorème

Toute matrice $\mathbf{A} \in \mathbb{R}^{m \times n}$ admet une **décomposition en valeurs singulières** (SVD) de la forme

$$\mathbf{A} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^T.$$

- $\mathbf{U} \in \mathbb{R}^{m \times m}$ est orthogonale;
- $\mathbf{V} \in \mathbb{R}^{n \times n}$ est orthogonale;
- $\mathbf{\Sigma} \in \mathbb{R}^{m \times n}$ est diagonale par blocs, avec des coefficients nuls sauf ceux de la diagonale $\{[\mathbf{\Sigma}]_{ii}\}_i$ qui sont positifs (ou nuls). Ces éléments, notés $\{\sigma_i\}$, s'appellent les **valeurs singulières de \mathbf{A}** .

Théorème

Toute matrice $\mathbf{A} \in \mathbb{R}^{m \times n}$ admet une **décomposition en valeurs singulières** (SVD) de la forme

$$\mathbf{A} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^T.$$

- $\mathbf{U} \in \mathbb{R}^{m \times m}$ est orthogonale;
- $\mathbf{V} \in \mathbb{R}^{n \times n}$ est orthogonale;
- $\mathbf{\Sigma} \in \mathbb{R}^{m \times n}$ est diagonale par blocs, avec des coefficients nuls sauf ceux de la diagonale $\{[\mathbf{\Sigma}]_{ii}\}_i$ qui sont positifs (ou nuls). Ces éléments, notés $\{\sigma_i\}$, s'appellent les **valeurs singulières de \mathbf{A}** .

- $\mathbf{A} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^T \Leftrightarrow \mathbf{U}^T\mathbf{A}\mathbf{V}^T = \mathbf{\Sigma}$;
- Une SVD n'est pas définie de façon unique mais ses valeurs singulières le sont.

Cours

- La décomposition en valeurs singulières (SVD) : outil fondamental;
- Applications.

TD

- Quelques exercices d'algèbre linéaire;
- Preuve constructive de la SVD.

Exercice (I-1 polycopié)

Soit $\mathbf{A} \in \mathbb{R}^{m \times n}$. Démontrer les propriétés suivantes sans utiliser la décomposition en valeurs singulières :

- a) $\ker(\mathbf{A}^T \mathbf{A}) = \ker(\mathbf{A})$;
- b) $\text{rang}(\mathbf{A}^T) = \text{rang}(\mathbf{A})$;
- c) $\text{rang}(\mathbf{A}^T \mathbf{A}) = \text{rang}(\mathbf{A})$, et en déduire que $\text{Im}(\mathbf{A}^T \mathbf{A}) = \text{Im}(\mathbf{A}^T)$.

Comment les démontrer en utilisant maintenant la SVD ?