

Fondements du Machine Learning

Florentin Goyens

Licence 3 Informatique et Mathématiques pour la Décision et les Données

6 septembre 2022



Liens utiles

- Mon adresse email: florentin.goyens@dauphine.psl.eu
- Page du cours :
<https://flgoyens.github.io/teach/FML2022>
- Notes de cours.
- Equipe sur Microsoft Teams

Programme

- Cours : 10 séances de 1h30. Attention, changement de programme !
 - Mardi 13h45-15h15;
 - pas de cours les mardi 20 septembre, 27 septembre et 1er novembre; dernier cours le mardi 29 novembre.
- TD : avec Lucas GNECCO HEREDIA
 - Mardi 15h30-17h00;
- Flexible

Évaluation

- $\text{Note} = 0.3 * \text{Contrôle Continu} + 0.7 * \text{Examen}$;
- Contrôle continu : en présentiel ou devoir à la maison.
- Examen : En janvier.

Notes de cours (polycopié)

- Disponibles sur la page du cours;
- mises à jour de semaine en semaine;

Ne pas hésiter à poser des questions pendant le cours

- C'est bon pour vous;
- et pour moi aussi.

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

Différents domaines

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

Différents domaines

- Analyse de données (*data analysis*);
- 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 et prendre des décisions de manière automatique.**

Principe 1: Grande quantité de données

- Pour avoir de l'information à extraire;
- Pour être statistiquement 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 GAFA(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 de certains systèmes physiques 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).

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**).


Modèles linéaires

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

Premier modèle d'apprentissage

- Distribution (de probabilité) des données connue;
- Apprentissage supervisé.


⇒ **Régression linéaire.**



Second modèle d'apprentissage

- 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.

- Introduction et motivation (Chapitre 1);
- Algèbre linéaire et modèles linéaires :
 - Décomposition en valeurs propres/valeurs singulières (Chap. 2);
 - Moindres carrés linéaires (Chap. 3).
- Outils statistiques (Chapitre 4) :
 - Statistique multidimensionnelle;
 - Compromis biais-variance.
- **Régression linéaire** (Chapitre 5):
 - Simple, multiple;
 - Régularisation.
- Réduction de dimension (Chapitre 6):
 - **Analyse en composantes principales;**
 - Applications.

- 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

Conventions

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

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) $\Rightarrow \mathbf{x} = [x_i]_{1 \leq i \leq n}$.

- \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 :*

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

Produit scalaire sur \mathbb{R}^n

Le produit scalaire 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 : $\mathbf{y}^T \mathbf{x} = \mathbf{x}^T \mathbf{y}$).

Norme Euclidienne d'un vecteur :

Pour tout $\mathbf{x} \in \mathbb{R}^n$

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

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

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

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

Definition d'une base de \mathbb{R}^n

Une base de \mathbb{R}^n est une suite de vecteurs linéairement indépendants et générateurs de \mathbb{R}^n

Soit $\mathbf{A} \in \mathbb{R}^{m \times n}$ ensemble des matrices à m lignes, n colonnes et $\mathbf{x} \in \mathbb{R}^n$,
 $\mathbf{A}: \mathbb{R}^n \rightarrow \mathbb{R}^m$.

Représentation de \mathbf{A} en colonnes

$$A = [\mathbf{a}_1 \quad \mathbf{a}_2 \quad \cdots \quad \mathbf{a}_n]$$

ou en lignes

$$A = \begin{bmatrix} \mathbf{a}_1^T \\ \vdots \\ \mathbf{a}_m^T \end{bmatrix}.$$

Un produit matrice vecteur \mathbf{Ax} est une combinaison linéaire des colonnes de \mathbf{A}

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

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

Norme opérateur

$$\|\mathbf{A}\| = \max_{\mathbf{x} \neq 0} \frac{\|\mathbf{Ax}\|}{\|\mathbf{x}\|} = \max_{\|\mathbf{x}\|=1} \|\mathbf{Ax}\|$$

Norme de Frobenius

$$\|\mathbf{A}\|_F = \sqrt{\sum_{i=1}^m \sum_{j=1}^n A_{ij}^2} = \text{trace}(\mathbf{A}^\top \mathbf{A})$$

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

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

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

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

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.

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.

Matrices orthogonales

Une matrice carée $\mathbf{Q} \in \mathbb{R}^{n \times n}$ tel que $\mathbf{Q}^\top \mathbf{Q} = \mathbf{Q} \mathbf{Q}^\top = \mathbf{I}_n$ est dite orthogonale.

Une matrice $\mathbf{Q} \in \mathbb{R}^{m \times n}$ avec $m \geq n$, est dite orthogonale si ces colonnes sont des vecteurs orthonormés, $\mathbf{Q}^\top \mathbf{Q} = \mathbf{I}_n$

Une transformation orthogonale conserve la norme

Soit $\mathbf{A} \in \mathbb{R}^{m \times n}$ et deux matrices orthogonales $\mathbf{U} \in \mathbb{R}^{m \times m}$ et $\mathbf{V} \in \mathbb{R}^{n \times n}$.

Alors

$$\|\mathbf{A}\| = \|\mathbf{U}\mathbf{A}\| = \|\mathbf{A}\mathbf{V}\|$$

et

$$\|\mathbf{A}\|_F = \|\mathbf{U}\mathbf{A}\|_F = \|\mathbf{A}\mathbf{V}\|_F$$

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.

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

- $|\lambda_j| \gg 1 \Rightarrow \|\mathbf{A}\mathbf{p}_j\| \gg \|\mathbf{p}_j\|$;
- $|\lambda_j| \ll 1 \Rightarrow \|\mathbf{A}\mathbf{p}_j\| \ll \|\mathbf{p}_j\|$.

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} .

Interpretation comme un changement de base

La decomposition $\mathbf{A} = \mathbf{P}\mathbf{\Lambda}\mathbf{P}^{-1}$ exprime l'application \mathbf{A} dans la base $\rho = (\mathbf{p}_1, \dots, \mathbf{p}_n)$, où \mathbf{A} est diagonale.

En effet, $\mathbf{P}\mathbf{x} = \mathbf{b}$ signifie que $(\mathbf{b})_e = (\mathbf{x})_\rho$. De même on a $\mathbf{x} = \mathbf{P}^{-1}\mathbf{b}$ qui signifie que $\mathbf{P}^{-1}\mathbf{b}$ represente les coefficients du vecteur \mathbf{b} dans la base ρ .

$$P = {}_e(I)_\rho$$

et

$$P^{-1} = {}_\rho(I)_e$$

Donc

$$\mathbf{A} = \mathbf{P}\mathbf{\Lambda}\mathbf{P}^{-1} = {}_e(I)_\rho {}_\rho(\mathbf{A})_\rho {}_\rho(I)_e$$

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} ?

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

(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) : Preuve constructive;
- outil fondamental;
- .

TD

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

Exercice (I-1 photocopié)

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 ?