

# Troisième cours

- DM1 en ligne ce soir ([thomas.schatz.cogserver.net/teaching](http://thomas.schatz.cogserver.net/teaching)), à rendre pour le 6 Octobre (en main propre ou par email: [thomas.schatz@univ-amu.fr](mailto:thomas.schatz@univ-amu.fr))
- Scribe ? (rendu = fichier .tex)
- Aujourd'hui
  - Fin de l'algèbre linéaire
    - Théorème de Cayley-Hamilton
    - Algèbre linéaire numérique
  - Début de l'Optimisation

# Plan du cours

1. Introduction générale
2. Preuves (revue)
3. Algèbre linéaire (revue)
4. Optimisation (revue)
5. Optimisation sous contraintes
6. Probabilités (revue)
7. Statistique
- 8. Théorie de l'apprentissage**
- 9. Optimisation pour l'apprentissage**

# Propriétés du produit matriciel

$$A \times (B \times C) = (A \times B) \times C$$

$$A \times (B + C) = A \times B + A \times C$$

$$(A + B) \times C = A \times C + B \times C$$

$$c(A \times B) = (cA) \times B = A \times (cB)$$

# Espaces de fonctions linéaires

Espace de matrice, muni de l'addition et la multiplication matricielle et de la multiplication par un scalaire:

$$\mathcal{M}_{m,n}(\mathbf{R})$$

Espace de fonctions linéaires muni de l'addition et de la composition de fonctions linéaires et de la multiplication par un scalaire:

$$\mathcal{L}(E, F)$$

# Déterminant et trace

A matrice carrée  $n \times n$

$$\det(A) = \sum_{\sigma \in \mathcal{S}_n} \left( \operatorname{sgn}(\sigma) \prod_{i=1}^n a_{i, \sigma_i} \right),$$

$\operatorname{sgn}(\sigma)$  est la parité du nombre d'éléments dans une décomposition de  $\sigma$  en une séquence de transpositions (échange de deux éléments).

$$\det(AB) = \det(A) \det(B)$$

$$\operatorname{Tr}(A) = \sum_{i=1}^n a_{i,i} \quad \operatorname{Tr}(AB) = \operatorname{Tr}(BA)$$

$$\operatorname{Tr}(A_1 A_2 \dots A_k) = \operatorname{Tr}(A_2 A_3 \dots A_k A_1) = \dots = \operatorname{Tr}(A_k A_1 A_2 \dots A_{k-1})$$

# Théorème de Cayley-Hamilton

**Cayley-Hamilton theorem:** for any  $A \in \mathbf{R}^{n \times n}$  we have  $\mathcal{X}(A) = 0$ , where  $\mathcal{X}(s) = \det(sI - A)$

Corollaire : pour tout entier naturel  $p$ ,  $A^p \in \text{Vect}(I, A, A^2, \dots, A^{n-1})$

# Algèbre linéaire numérique

**Exemple : produit matrice-matrice**  $A: m \times n, B: n \times p.$

Produit matriciel  $C = AB :$

$$C = 0$$

Boucle  $i = 1..m, j = 1..p, k = 1..n :$

$$c_{ij} = c_{ij} + a_{ik}b_{kj}$$

**Ordre des trois boucles ?**

$$\text{i en premier } C = \begin{bmatrix} \tilde{c}_1^T \\ \vdots \\ \tilde{c}_m^T \end{bmatrix} = AB = \begin{bmatrix} \tilde{a}_1^T B \\ \vdots \\ \tilde{a}_m^T B \end{bmatrix}$$

$$\text{j en premier } C = [ c_1 \cdots c_p ] = AB = [ Ab_1 \cdots Ab_p ]$$

$$\text{k en premier } C = AB = \sum_{k=1}^n a_k \tilde{b}_k^T$$

# Algèbre linéaire numérique

Stabilité numérique

# Normes de vecteurs

A function  $\|\cdot\| : \mathbb{R}^n \rightarrow \mathbb{R}$  is called a *vector norm* if it has the following properties:

1.  $\|\mathbf{x}\| \geq 0$  for any vector  $\mathbf{x} \in \mathbb{R}^n$ , and  $\|\mathbf{x}\| = 0$  if and only if  $\mathbf{x} = \mathbf{0}$
2.  $\|\alpha\mathbf{x}\| = |\alpha|\|\mathbf{x}\|$  for any vector  $\mathbf{x} \in \mathbb{R}^n$  and any scalar  $\alpha \in \mathbb{R}$
3.  $\|\mathbf{x} + \mathbf{y}\| \leq \|\mathbf{x}\| + \|\mathbf{y}\|$  for any vectors  $\mathbf{x}, \mathbf{y} \in \mathbb{R}^n$ .

$$\|\mathbf{x}\|_p = \left( \sum_{i=1}^n |x_i|^p \right)^{1/p}.$$

$$|\mathbf{x}^T \mathbf{y}| \leq \|\mathbf{x}\|_2 \|\mathbf{y}\|_2$$

$$\|\mathbf{x}\|_1 = |x_1| + |x_2| + \cdots + |x_n|$$

$$\|\mathbf{x}\|_2 = \sqrt{x_1^2 + x_2^2 + \cdots + x_n^2} = \sqrt{\mathbf{x}^T \mathbf{x}}$$

$$\|\mathbf{x}\|_\infty = \max_{1 \leq i \leq n} |x_i|$$

Si  $Q$  est une matrice orthogonale,  
 $\|Qx\|_2 = \|x\|_2$

# Application de la notion de norme: lien valeurs propres, valeurs singulières

$$\sigma_r \leq |\lambda| \leq \sigma_1$$

# Application de la notion de norme: lien valeurs propres, valeurs singulières

$$\sigma_r \leq |\lambda| \leq \sigma_1$$

Éléments propres de  $A^T A$  et  $AA^T$  ?

# Normes de matrices

A matrix norm is a function  $\| \cdot \| : \mathbb{R}^{m \times n} \rightarrow \mathbb{R}$  that has the following properties:

- $\|A\| \geq 0$  for any  $A \in \mathbb{R}^{m \times n}$ , and  $\|A\| = 0$  if and only if  $A = 0$
- $\|\alpha A\| = |\alpha| \|A\|$  for any  $m \times n$  matrix  $A$  and scalar  $\alpha$
- $\|A + B\| \leq \|A\| + \|B\|$  for any  $m \times n$  matrices  $A$  and  $B$

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

$$\|A\|_2 = \sigma_1$$

$$\|A\|_F = \left( \sum_{i=1}^m \sum_{j=1}^n a_{ij}^2 \right)^{1/2}.$$

$$\|A\|_F = \sqrt{\sigma_1^2 + \cdots + \sigma_r^2}$$

# Algèbre linéaire numérique

## Stabilité numérique

Supposons qu'un processus nous donne la solution estimée  $\hat{x}$  d'un système linéaire  $Ax = b$  en effectuant toutes les opérations matricielles de manière exacte mais qu'il y a des erreurs d'arrondi dans le stockage en nombre flottants de  $A$  et de  $b$  dans la mémoire (en pratique les opérations matricielles effectuées pour trouver  $x$  introduisent davantage d'erreurs d'arrondis, ce modèle donne donc une borne supérieure sur la qualité possible d'un algorithme numérique pour résoudre des systèmes linéaires).

Alors,

$$\text{si } \mathbf{u}\kappa_{\infty}(A) \leq .5 \quad \frac{\|x - \hat{x}\|_{\infty}}{\|x\|_{\infty}} \leq 4\mathbf{u}\kappa_{\infty}(A)$$

$\mathbf{u}$  est le unité d'arrondi, égale à la moitié de l'écart entre 1 et le plus petit nombre flottant strictement supérieur à 1. Pour les nombres flottants IEEE single précision,  $\mathbf{u}$  est d'environ  $10^{-7}$ . Il est d'environ  $10^{-16}$  pour les nombres flottants IEEE double précision.

$\kappa_{\infty}(A) := \|A\|_{\infty}\|A^{-1}\|_{\infty}$  est le conditionnement de  $A$  pour la norme  $\infty$

# Plan du cours

1. Introduction générale
2. Preuves (revue)
3. Algèbre linéaire (revue)
4. Optimisation (revue)
5. Optimisation sous contraintes
6. Probabilités (revue)
7. Statistique
- 8. Théorie de l'apprentissage**
- 9. Optimisation pour l'apprentissage**

# Partie 4 – Optimisation (revue)

# Optimisation sans contraintes

$$f : \mathbf{R}^n \mapsto \mathbf{R}$$

$$\min_x f(x) ?$$

$x^*$  est un minimum global de  $f$  ssi pour tout  $x \in \mathbf{R}^n$ ,  $f(x^*) \leq f(x)$

$x^*$  est un minimum local de  $f$  ssi il existe un ensemble ouvert  $U \subset \mathbf{R}^n$  contenant  $x^*$  tel que pour tout  $x \in U$ ,  $f(x^*) \leq f(x)$

# Analyse

**Concept central**  $\lim_{x \rightarrow a} f(x) = l ?$

## **Notions de base de topologie**

Dans  $\mathbf{R}^n$ , La boule fermée  $B_f(x, \epsilon)$ , centrée sur  $x$  et de rayon  $\epsilon$  associée à la norme Euclidienne est l'ensemble des points  $y$  de  $\mathbf{R}^n$  tels que  $\|x - y\|_2 \leq \epsilon$

Dans  $\mathbf{R}^n$ , La boule ouverte  $B_o(x, \epsilon)$ , centrée sur  $x$  et de rayon  $\epsilon$  associée à la norme Euclidienne est l'ensemble des points  $y$  de  $\mathbf{R}^n$  tels que  $\|x - y\|_2 < \epsilon$

$U$  est un ouvert de  $\mathbf{R}^n$  ssi  $U \subset \mathbf{R}^n$  et pour tout  $x$  dans  $U$ , il existe  $\epsilon > 0$ , tel que  $B_f(x, \epsilon) \subset U$ .

$U$  est un fermé de  $\mathbf{R}^n$  ssi son complément dans  $\mathbf{R}^n$  est un ouvert de  $\mathbf{R}^n$

# Jacobienne, gradient

$$f : U \subset \mathbf{R}^n \rightarrow \mathbf{R}^m, \text{ de classe } C^1$$

**Dérivée partielle**  $f : x \mapsto (f_1(x), f_2(x), \dots, f_m(x))$

$$\frac{\partial f_i}{\partial x_j} : (a_1, \dots, a_n) \mapsto \lim_{h \rightarrow 0} \frac{f_i(a_1, \dots, a_{j-1}, a_j + h, a_{j+1}, \dots, a_n) - f_i(a_1, \dots, a_j, \dots, a_n)}{h}$$

**Matrice Jacobienne (transposée du gradient si  $m=1$ )**

$$\mathbf{J} = \begin{bmatrix} \frac{\partial \mathbf{f}}{\partial x_1} & \dots & \frac{\partial \mathbf{f}}{\partial x_n} \end{bmatrix} = \begin{bmatrix} \nabla^T f_1 \\ \vdots \\ \nabla^T f_m \end{bmatrix} = \begin{bmatrix} \frac{\partial f_1}{\partial x_1} & \dots & \frac{\partial f_1}{\partial x_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial f_m}{\partial x_1} & \dots & \frac{\partial f_m}{\partial x_n} \end{bmatrix}$$

“Chain rule”

$$J_{f \circ g}(\mathbf{a}) = J_f(g(\mathbf{a}))J_g(\mathbf{a}),$$

# Crédits

Certaines figures de

- Wikipedia