



ANALYSE NUMÉRIQUE

Thomas Harbreteau

13 avril 2020

Notes du cours de Benjamin Boutin.
Université de Rennes 1, année 2019/2020.

Sommaire

1	Résolution de systèmes linéaires	2
1	Rappels et notations	2
2	Réduction en dimension finie	2
3	Propriétés spectrales des matrices hermitiennes	4
4	Normes subordonnées et rayon spectral	5
5	Conditionnement	7
6	Exemple important : matrice du laplacien 1d	9
2	Méthodes directes	14
1	Remarques préliminaires	14
2	Factorisation LU	14
3	Décomposition de Cholesky	16
3	Méthodes itératives	18
1	Généralités	18
2	Méthodes usuelles	19
3	Critères explicites de convergence	20
4	Résolution de systèmes linéaires au sens des moindres carrés	21
5	Méthodes variationnelles	24
4	Approximation spectrale	27
1	Motivation	27
2	Méthodes numériques	27

Chapitre 1

Résolution de systèmes linéaires

1 Rappels et notations

1.1 Rappels

Soit $A \in \mathcal{M}_n(\mathbf{K})$ et $\lambda \in \sigma(A)$.

- Polynôme caractéristique : $\chi_A = \det(A - XI_n)$.
- Multiplicité algébrique de λ : multiplicité en tant que racine du polynôme caractéristique.
- Multiplicité géométrique de λ : dimension du sous-espace propre associé à λ .
- Valeur propre défective : multiplicité géométriques et algébriques différentes.

1.2 Notations

- $T_n^u(\mathbf{K})$ l'ensemble des matrices triangulaires supérieures.
- $U_n(\mathbf{K})$ l'ensemble des matrices unitaires, i. e. dont les colonnes forment une base orthonormée pour le produit scalaire hermitien (analogue aux matrices orthogonales réelles). Caractérisation matricielle : $U^*U = UU^* = I_n$.

2 Réduction en dimension finie

Théorème 1.2.1 (Réduction de Jordan) Soit $A \in \mathcal{M}_n(\mathbf{K})$, supposée trigonalisable sur \mathbf{K} ,

$$\exists P \in \mathcal{GL}_n(\mathbf{K}), \quad P^{-1}AP = \begin{pmatrix} J_{k_1}(\lambda_1) & 0 & \dots & 0 \\ 0 & J_{k_2}(\lambda_2) & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \dots & 0 & J_{k_m}(\lambda_m) \end{pmatrix},$$

où

- les $(\lambda_i)_{1 \leq i \leq m}$ non-nécessairement distincts deux à deux,
- pour tout $i \in \{1, \dots, m\}$, $J_{k_i}(\lambda_i)$ désigne un bloc de Jordan de taille $k_i \geq 1$:

$$J_k(\lambda) = \begin{pmatrix} \lambda & 1 & 0 & \dots & 0 \\ 0 & \lambda & \ddots & \ddots & \vdots \\ \vdots & \ddots & \ddots & \ddots & 0 \\ \vdots & & \ddots & \ddots & 1 \\ 0 & \dots & \dots & 0 & \lambda \end{pmatrix}.$$

2.1 Réduction en base orthonormée

Proposition 1.2.2 (Produit scalaire hermitien) $\forall x, y, z \in \mathbf{C}^*, \forall \lambda, \mu \in \mathbf{C}, \forall A \in \mathcal{M}_n(\mathbf{C})$,

- $\langle x, y + z \rangle = \langle x, y \rangle + \langle x, z \rangle$,
- $\langle x, y \rangle = \overline{\langle y, x \rangle}$,
- $\langle \lambda x, \mu y \rangle = \bar{\lambda}\mu \langle x, y \rangle$,
- $\langle Ax, y \rangle = \langle x, A^*x \rangle$, où $A^* = \bar{A}^T$ (définition de l'adjoint),
- $|\langle x, y \rangle| \leq \|x\|_2 \|y\|_2$.

Proposition 1.2.3 (Projection orthogonale) On considère F un sous-espace de \mathbf{K}^n et (e_1, \dots, e_n) une base orthonormée de F . Alors la projection orthogonale sur F parallèlement à F^\perp , notée p_F , est obtenue comme :

$$\forall x \in \mathbf{K}^n, \quad p_F(x) = \sum_{i=1}^m \langle e_i, x \rangle e_i = \left(\sum_{i=1}^m e_i e_i^* \right) x.$$

PREUVE.

$$\sum_{i=1}^m \langle e_i, x \rangle e_i = \sum_{i=1}^m (e_i^* x) e_i = \sum_{i=1}^m e_i (e_i^* x) = \left[\sum_{i=1}^m (e_i e_i^*) \right] x.$$

□

Proposition 1.2.4 (Orthonormalisation de Gram-Schmidt) Soit $(v_i)_{1 \leq i \leq n}$ une base de \mathbf{K}^n . On construit une base orthonormée $(e_i)_{1 \leq i \leq n}$ de \mathbf{K}^n par projections successives sur les directions précédemment construites :

$$u_1 := v_1, \quad e_1 := u_1 / \|u_1\|,$$

et pour tout $k \in \{2, \dots, n\}$,

$$u_k := v_k - p_{\text{Vect}(e_1, \dots, e_{k-1})}(v_k) = v_k - \sum_{i=1}^{k-1} \frac{\langle u_i, v_k \rangle}{\langle u_i, u_i \rangle} u_i, \quad e_k := \frac{u_k}{\|u_k\|}.$$

Proposition 1.2.5 (Factorisation QR) Soit $A \in \mathcal{GL}_n(\mathbf{C})$, alors il existe $Q \in U_n(\mathbf{C})$ et $R \in T_n^u(\mathbf{C})$ telles que $A = QR$. Cette décomposition est de plus unique si on suppose les termes diagonaux de R réels positifs.

PREUVE.

$$\forall k \in \{1, \dots, n\}, \quad v_k = u_k + \sum_{i=1}^{k-1} \frac{\langle u_i, v_k \rangle}{\langle u_i, u_i \rangle} u_i = \|u_k\| e_k + \sum_{i=1}^{k-1} \langle e_i, v_k \rangle e_i.$$

Ainsi,

$$A = \begin{pmatrix} \vdots & & \vdots \\ v_1 & \dots & v_n \\ \vdots & & \vdots \end{pmatrix} = \begin{pmatrix} \vdots & & \vdots \\ e_1 & \dots & e_n \\ \vdots & & \vdots \end{pmatrix} \begin{pmatrix} \|u_1\| & & (\langle e_i, v_j \rangle) \\ & \ddots & \\ (0) & & \|u_n\| \end{pmatrix}.$$

□

Théorème 1.2.6 (Schur) Soit $A \in \mathcal{M}_n(\mathbf{C})$, alors il existe $U \in U_n(\mathbf{C})$ et $T \in T_n^u(\mathbf{C})$ telles que $U^* A U = T$.

PREUVE. P admet une factorisation QR , notée $P = QR$, où $Q \in U_n(\mathbf{C})$ et $R \in T_n^u(\mathbf{C})$. Alors

$$A = QRT(QR)^{-1} = QRTR^{-1}Q^{-1} = Q \underbrace{(RTR^{-1})}_{\in T_n^u(\mathbf{C})} Q^*.$$

□

2.2 Réduction des matrices normales

Définition 1.2.7 (Matrice normale) Une matrice $A \in \mathcal{M}_n(\mathbf{C})$ est dite normale si $AA^* = A^*A$.

Exemple 1.2.8 $S_n(\mathbf{R})$; $H_n(\mathbf{C})$ hermitiennes complexes ($A^* = A$); $O_n(\mathbf{R})$; $U_n(\mathbf{C})$.

Lemme 1.2.9 Toute matrice triangulaire (supérieure ou inférieure) et normale est diagonale.

PREUVE. Soit $A \in T_n^u(\mathbf{C})$.

$$\forall i \in \{1, \dots, n\}, \quad \begin{cases} (A^*A)_{i,i} &= \sum_{j=1}^i \bar{A}_{j,i} A_{j,i} &= \sum_{j=1}^i |a_{i,j}^2| \\ (AA^*)_{i,i} &= |a_{i,i}|^2. \end{cases}$$

□

Théorème 1.2.10 Une matrice $A \in \mathcal{M}_n(\mathbf{C})$ est normale si et seulement si elle est diagonalisable en base orthonormée.

PREUVE. (\Leftarrow) : Supposons A diagonalisable en base orthonormée. On note $A = UDU^*$, où $U \in U_n(\mathbf{C})$ et D diagonale. Alors

$$\begin{cases} A^*A &= (UDU^*)^*(UDU^*) = UD^*(U^*U)DU^* = UD^*DU^* \\ AA^* &= UDD^*U^*. \end{cases}$$

Ainsi,

$$AA^* = A^*A \iff DD^* = D^*D \iff \forall i \in \{1, \dots, n\}, \quad D_{i,i}\bar{D}_{i,i} = \bar{D}_{i,i}D_{i,i}.$$

(\Rightarrow) : Soit $A \in \mathcal{M}_n(\mathbf{C})$ normale, $AA^* = A^*A$. Par théorème de Schur, il existe $U \in U_n(\mathbf{C})$ et $T \in T_n^u(\mathbf{C})$ telles que $A = UTU^*$. Du fait de l'égalité $AA^* = A^*A$, on trouve $TT^* = T^*T$ après calculs. Ainsi, T est normale et triangulaire supérieure, donc est diagonale par le lemme précédent. \square

Proposition 1.2.11 Les valeurs propres d'une matrice normale sont

- réelles si $A \in S_n(\mathbf{R})$, ou plus généralement si $A \in H_n(\mathbf{C})$,
- réelles positives si $A \in S_n^+(\mathbf{R})$ ou si $A \in H_n^+(\mathbf{R})$,
- réelles strictement positives si $A \in S_n^{++}(\mathbf{R})$ ou si $A \in H_n^{++}(\mathbf{R})$,
- imaginaires pures si A est anti-symétrique réelle ou anti-hermitienne,
- complexes de module 1 si $A \in O_n(\mathbf{R})$ ou plus généralement si $A \in U_n(\mathbf{C})$.

PREUVE.

- Valeurs propres de $A \in U_n(\mathbf{C})$? Soit A normale, alors $A = UDU^*$ avec U unitaire et D vérifie $D^*D = DD^* = I_n$ (car $A^*A = AA^* = I_n$). On déduit de cette dernière égalité que

$$\forall i \in \{1, \dots, n\}, \quad |D_{i,i}|^2 = 1,$$

donc $\sigma(A) = \sigma(D) = \{z \in \mathbf{C} \mid |z| = 1\}$. \square

3 Propriétés spectrales des matrices hermitiennes

Définition 1.3.1 (Quotient de Rayleigh) Soit $A \in H_n(\mathbf{C})$, on définit l'application

$$R_A : \begin{array}{ccc} (\mathbf{C}^n)^* & \longrightarrow & \mathbf{R} \\ x & \longmapsto & \frac{\langle Ax, x \rangle}{\langle x, x \rangle} \end{array} .$$

PREUVE. Si $A \in H_n(\mathbf{C})$,

$$\forall x \in \mathbf{C}^n, \quad \langle Ax, x \rangle = (Ax)^*x = x^*(A^*x) = \langle x, A^*x \rangle = \langle x, Ax \rangle,$$

car $A = A^*$. Par caractère hermitien du produit scalaire, $\langle Ax, x \rangle = \overline{\langle x, Ax \rangle}$, donc ici, $\langle x, Ax \rangle = \overline{\langle x, Ax \rangle} \in \mathbf{R}$. Ainsi, $R_A(x) \in \mathbf{R}$. \square

Théorème 1.3.2 Soit $A \in H_n(\mathbf{C})$ de valeurs propres (non nécessairement positives) $\lambda_{\min} = \lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_n = \lambda_{\max}$, alors

$$\max_{x \neq 0} R_A(x) = \lambda_{\max}, \quad \text{et} \quad \min_{x \neq 0} R_A(x) = \lambda_{\min}.$$

PREUVE. Soient $x \in \mathbf{C}^n \setminus \{0\}$ et $z \in \mathbf{C} \setminus \{0\}$,

$$R_A(zx) = \frac{\langle Azx, zx \rangle}{\langle zx, zx \rangle} = \frac{\bar{z}z \langle Ax, x \rangle}{\bar{z}z \langle x, x \rangle} = R_A(x).$$

Étudier les extremums de R_A sur $\mathbf{C}^n \setminus \{0\}$ se ramène à les étudier sur $\mathcal{S} := \{x \in \mathbf{C}^n \mid \|x\|_2 = 1\}$.

\mathcal{S} étant compacte et R_A continue sur \mathcal{S} , R_A est bornée et atteint ses bornes.

A étant hermitienne, elle est diagonalisable en base orthonormée. Notons $A = UDU^*$, avec $U \in U_n(\mathbf{C})$ et D diagonale réelle (car A est hermitienne), $D = \text{diag}(\lambda_1, \dots, \lambda_n)$ avec $\lambda_1 \leq \dots \leq \lambda_n$. Alors

$$R_A(x) = \frac{\langle UDU^*x, x \rangle}{\langle U^*x, U^*x \rangle} = \frac{\langle DU^*x, U^*x \rangle}{\langle U^*x, U^*x \rangle} = R_D(U^*x).$$

L'application

$$\sigma : \begin{array}{ccc} \mathcal{S} & \longrightarrow & \mathcal{S} \\ x & \longmapsto & U^*x \end{array}$$

définit une bijection sur \mathcal{S} . Les extremums de R_A sur \mathcal{S} sont ceux de R_D . Soit $y \in \mathcal{S}$,

$$R_D(y) = \frac{\langle Dy, y \rangle}{\langle y, y \rangle} = \langle Dy, y \rangle = y^* D^* y = y^* D y = \sum_{i=1}^n \bar{y}_i \lambda_i y_i = \sum_{i=1}^n \lambda_i |y_i|^2.$$

Comme y est de norme 1,

$$\lambda_{\min} \underbrace{\sum_{i=1}^n |y_i|^2}_{=1} \leq R_D(y) \leq \lambda_{\max} \underbrace{\sum_{i=1}^n |y_i|^2}_{=1}.$$

Les égalités sont atteintes à gauche pour $y = (1, 0, \dots, 0)^T$ et à droite pour $y = (0, \dots, 0, 1)^T$. □

Remarque 1.3.3 On peut bien permuter les vecteurs colonnes de D . Soit P une matrice de permutation, $\tilde{D} = PDP^{-1} = PDP^*$, alors

$$A = UDU^* = UP^* \tilde{D} PU^* = (\underbrace{UP^*}_{\text{unitaire}}) \tilde{D} (UP^*)^*.$$

4 Normes subordonnées et rayon spectral

4.1 Définitions

Définition 1.4.1 (Normes usuelles) On considère $x \in \mathbf{C}^n$ et $A \in \mathcal{M}_n(\mathbf{C})$.

$$\|x\|_1 = \sum_{j=1}^n |x_j|, \quad \|A\|_1 = \max_{1 \leq j \leq n} \sum_{i=1}^n |A_{i,j}|.$$

$$\|x\|_\infty = \max_{1 \leq j \leq n} |x_j|, \quad \|A\|_\infty = \max_{1 \leq i \leq n} \sum_{j=1}^n |A_{i,j}|.$$

4.2 Rayon spectral

Définition 1.4.2 (Rayon spectral) Soit $A \in \mathcal{M}_n(\mathbf{K})$. On appelle rayon spectral de A la quantité

$$\rho(A) = \max\{|\lambda| \mid \lambda \in \sigma(A)\}.$$

Lemme 1.4.3 Si A est normale, alors $\|A\|_2 = \rho(A)$. Plus généralement, pour toute matrice $A \in \mathcal{M}_n(\mathbf{C})$, on a $\|A\|_2 = \sqrt{\rho(A^*A)}$.

Théorème 1.4.4 Soit $A \in \mathcal{M}_n(\mathbf{K})$.

1. Pour toute norme subordonnée $\|\cdot\|$, on a $\rho(A) \leq \|A\|$.
 2. Réciproquement, pour tout $\varepsilon > 0$, il existe une norme subordonnée $\|\cdot\|_\varepsilon$ telle que $\|A\|_\varepsilon \leq \rho(A) + \varepsilon$.
- Ainsi,

$$\rho(A) = \inf_{\|\cdot\| \text{ subordonnée}} \|A\|.$$

PREUVE.

1. Soit $\lambda \in \sigma(A)$ telle que $\rho(A) = |\lambda|$, et $x \in \mathbf{C}^n \setminus \{0\}$, $Ax = \lambda x$.

$$\|Ax\| = \|\lambda x\| = |\lambda| \|x\| = \rho(A) \|x\|,$$

et

$$\frac{\|Ax\|}{\|x\|} = \rho(A) = \max_{y \in \mathbf{C}^n \setminus \{0\}} \frac{\|Ay\|}{\|y\|} = \|A\|_{\mathcal{M}_n(\mathbf{C})}.$$

2. Soit $A \in \mathcal{M}_n(\mathbf{C})$. Par théorème de Schur, il existe $U \in U_n(\mathbf{C})$ et $T \in T_n^u(\mathbf{C})$ telles que $A = UTU^*$. Alors $\rho(A) = \rho(T)$, mais a-t-on une relation entre $\|A\|$ et $\|T\|$, pour une norme quelconque? On calcule

$$\|T_1\| = \max_{1 \leq j \leq n} \left(|\lambda_j| + \underbrace{\sum_{i=1}^{j-1} |T_{i,j}|}_{\text{à « éliminer »}} \right).$$

Soit $\eta > 0$, on note

$$D(\eta) := \begin{pmatrix} \eta & & (0) \\ & \eta^2 & \\ & & \ddots \\ (0) & & & \eta^n \end{pmatrix},$$

et on définit

$$T(\eta) := \begin{pmatrix} \lambda_1 & & (\eta^{-i+j}T_{i,j}) \\ & \ddots & \\ (0) & & \lambda_n \end{pmatrix}.$$

On remarque que $T(\eta) \xrightarrow{(\eta \rightarrow 0)} \text{diag}(\lambda_1, \dots, \lambda_n)$, donc

$$\|T(\eta)\|_1 = \max_j \left(|\lambda_j| + \eta \sum_{i=1}^{j-1} \eta^{j-1-i} |T_{i,j}| \right) \xrightarrow{\eta \rightarrow 0} \max_j |\lambda_j| = \rho(A).$$

Soient $\varepsilon > 0$ et η suffisamment petit de sorte que $\|T(\eta)\|_1 \leq \rho(A) + \varepsilon$. De plus, on a

$$A = (UD(\eta))T(\eta)(D(\eta)^{-1}U^*).$$

On considère sur \mathbf{C}^n la norme

$$\forall x \in \mathbf{C}^n, \quad \|x\|_\varepsilon = \|D(\eta)^{-1}U^*x\|_1.$$

Ainsi,

$$\begin{aligned} \|Ax\|_\varepsilon &= \|D(\eta)^{-1}U^*Ax\|_1 \\ &= \underbrace{\|(D(\eta)^{-1}U^*)(UD(\eta))\|}_{=I_n} \|T(\eta)(D(\eta)^{-1}U^*)x\|_1 \\ &= \|T(\eta)D(\eta)^{-1}U^*x\|_1 \\ &\leq \|T(\eta)\|_1 \|D(\eta)U^*x\|_1 \\ &\leq (\rho(A) + \varepsilon) \|x\|_1. \end{aligned}$$

Par conséquent,

$$\rho(A) = \inf_{\|\cdot\| \text{ subordonnée}} \|A\|.$$

□

4.3 Utilisation du rayon spectral

Théorème 1.4.5 Soit $A \in \mathcal{M}_n(\mathbf{K})$, il y a équivalence entre les propositions suivantes.

1. $\lim_{(k \rightarrow +\infty)} A^k = 0$.
2. Il existe une norme subordonnée $\|\cdot\|$ telle que $\|A\| < 1$.
3. $\rho(A) < 1$.

PREUVE. 2) \implies 1) : $A^k \rightarrow 0 \iff \|A^k\| \rightarrow 0$, mais $\|A^k\| \leq \|A\|^k \rightarrow 0$.

2) \iff 3) : Conséquence du théorème précédent.

1) \implies 3) : Par contraposée, supposons que $\rho(A) \geq 1$. Alors il existe $\lambda \in \mathbf{C}$ et $x \in \mathbf{C}^n$ tels que $|\lambda| \geq 1$, $x \neq 0$ et $Ax = \lambda x$. Par récurrence, pour tout $k \in \mathbf{N}$, $A^k x = \lambda^k x$, donc

$$\|A^k x\| = |\lambda^k| \|x\| \geq \|x\| \neq 0.$$

Ainsi,

$$\|A^k\| = \sup_{y \neq 0} \frac{\|A^k y\|}{\|y\|} \geq 1,$$

donc $(A^k)_k$ ne peut tendre vers 0. □

Corollaire 1.4.6 Soit $A \in \mathcal{M}_n(\mathbf{K})$, pour toute norme subordonnée $\|\cdot\|$, on a

$$\lim_{k \rightarrow +\infty} \|A^k\|^{1/k} = \rho(A).$$

PREUVE. Soient $\lambda \in \mathbf{C}$ et $x \in \mathbf{C}^n$ tels que $x \neq 0$, $Ax = \lambda x$ et $|\lambda| = \rho(A)$. Alors

$$\|A^k x\| = |\lambda|^k \|x\| = \rho(A)^k \|x\|,$$

donc $\|A^k\| \geq \rho(A)^k$, d'où $\|A^k\|^{1/k} \geq \rho(A)$, et ce pour tout $k \in \mathbf{N}$.

Soit $\varepsilon > 0$, On souhaiterait obtenir pour k assez grand $\|A^k\|^{1/k} \leq \rho(A) + \varepsilon$. Posons

$$A_\varepsilon = \frac{A}{\rho(A) + \varepsilon}.$$

On a alors $\rho(A_\varepsilon) = \rho(A)/(\rho(A) + \varepsilon) < 1$, donc $A_\varepsilon^k \rightarrow_{(k \rightarrow +\infty)} 0$. À partir d'un certain rang k_0 , $\|A_\varepsilon^k\| \leq 1$, or

$$\|A_\varepsilon^k\| = \left(\frac{1}{\rho(A) + \varepsilon} \right)^k \|A\|^k.$$

Par conséquent, pour $k \geq k_0$, $\|A^k\| \leq (\rho(A) + \varepsilon)^k$, d'où $\|A^k\|^{1/k} \leq \rho(A) + \varepsilon$. □

Théorème 1.4.7 Soit $A \in \mathcal{M}_n(\mathbf{K})$, il y a équivalence entre les propositions suivantes.

1. La suite $(A^k)_{k \geq 0}$ est bornée.

2. $\rho(A) \leq 1$ et les valeurs propres de A de module 1 sont toutes semi-simples.

PREUVE. Idée essentielle : T la réduite de Jordan de A , de blocs de Jordan les $J_{k_j}(\lambda_j)$, alors

$$(A^k)_k \text{ bornée} \iff \forall j \in \{1, \dots, n\}, \quad (J_{k_j}(\lambda_j)^k)_k \text{ est bornée.}$$

or

$$J_{k_j}(\lambda_j)^k = \begin{pmatrix} \lambda_j^k & k\lambda_j^{k-1} & \dots & \binom{k}{i} \lambda_j^{k-i} \\ & \ddots & \ddots & \vdots \\ & & \ddots & k\lambda_j^{k-1} \\ & & & \lambda_j^k \end{pmatrix}.$$

Ainsi,

- si $|\lambda_j| < 1$, $J_{k_j}(\lambda_j)^k \rightarrow 0$,
- si $|\lambda_j| > 1$, $|\lambda_j^k| \rightarrow +\infty$, donc $(J_{k_j}(\lambda_j)^k)_k$ n'est pas bornée. □

Exemple 1.4.8

- Soit

$$A := \begin{pmatrix} 2 & 1 & 3 \\ 0 & 1 & 5 \\ 0 & 0 & 1/2 \end{pmatrix},$$

alors $\rho(A) = 1 > 1$, donc $(A^k)_k$ n'est pas bornée.

- Soit

$$B := \begin{pmatrix} i & 1 & 0 \\ 0 & 1 & 1 \\ 0 & 0 & 1 \end{pmatrix},$$

alors $\rho(B) = 1$ et $\sigma(B) = \{1, i\}$. La valeur propre 1 est défective (associée à un bloc de Jordan de taille $2 > 1$), donc $(B^k)_k$ n'est pas bornée.

- Soit

$$C := \begin{pmatrix} e^{i\pi} & 0 & 0 \\ 0 & e^{i\pi/6} & 0 \\ 0 & 0 & e^{i\pi/6} \end{pmatrix}.$$

Alors $\rho(C) = 1$ et $(C^k)_k$ est bornée.

5 Conditionnement

On se place dans \mathbf{K}^n muni d'une norme vectorielle $\|\cdot\|$ et $\mathcal{M}_n(\mathbf{K})$ muni de la norme induite $\|\cdot\|$.

Définition 1.5.1 (Conditionnement) Étant donnée $A \in \mathcal{GL}_n(\mathbf{K})$, on appelle conditionnement de A dans la norme $\|\cdot\|$ la quantité

$$\text{cond}(A) = \|A\| \|A^{-1}\|.$$

Proposition 1.5.2

1. $\text{cond}(A) \geq 1$.
2. $\forall \alpha \in \mathbf{K}^*, \text{cond}(\alpha A) = \text{cond}(A)$.
3. $\forall A, B \in \mathcal{GL}_n(\mathbf{K}), \text{cond}(AB) \leq \text{cond}(A) \text{cond}(B)$.

Proposition 1.5.3 (Conditionnement en norme 2)

1. Soit $A \in \mathcal{GL}_n(\mathbf{K})$,

$$\text{cond}_2(A) = \sqrt{\frac{\max\{|\lambda| \mid \lambda \in \sigma(A^*A)\}}{\min\{|\lambda| \mid \lambda \in \sigma(A^*A)\}}}$$

2. Si de plus A est normale, alors

$$\text{cond}_2(A) = \frac{\max\{|\lambda| \mid \lambda \in \sigma(A)\}}{\min\{|\lambda| \mid \lambda \in \sigma(A)\}}$$

3. En particulier, si $A \in U_n(\mathbf{C})$, ou si $A \in O_n(\mathbf{R})$, alors $\text{cond}_2(A) = 1$.

PREUVE. Si A est normale, on sait que $\rho(A) = \|A\|_2 = \max\{|\lambda| \mid \lambda \in \sigma(A)\}$. De plus, si $A \in \mathcal{GL}_n(\mathbf{C})$,

$$\rho(A^{-1}) = \max\{|\lambda^{-1}| \mid \lambda \in \sigma(A)\} = \min\{|\lambda| \mid \lambda \in \sigma(A)\}^{-1}.$$

Mais A^{-1} est normale ($(AA^*)^{-1} = (A^*A)^{-1}$), donc $\rho(A^{-1}) = \|A^{-1}\|_2$. Ainsi,

$$\text{cond}_2(A) = \frac{\max |\lambda|}{\min |\lambda|}.$$

□

Théorème 1.5.4 Soient $A \in \mathcal{GL}_n(\mathbf{K})$, $b \in \mathbf{K}^n$ et $x \in \mathbf{K}^n$ tels que $Ax = b$.

1. Soient $\delta x \in \mathbf{K}^n$ et $\delta b \in \mathbf{K}^n$ tels que $A(x + \delta x) = b + \delta b$, alors

$$\frac{\|\delta x\|}{\|x\|} \leq \text{cond}(A) \frac{\|\delta b\|}{\|b\|}.$$

2. Soient $\delta x \in \mathbf{K}^n$ et $\delta A \in \mathcal{M}_n(\mathbf{K})$ tels que $A + \delta A \in \mathcal{GL}_n(\mathbf{K})$ et $(A + \delta A)(x + \delta x) = b$, alors

$$\frac{\|\delta x\|}{\|x + \delta x\|} \leq \text{cond}(A) \frac{\|\delta A\|}{\|A\|}.$$

PREUVE. Soient $A \in \mathcal{GL}_n(\mathbf{C})$, $b \in \mathbf{C}^n$ et $x \in \mathbf{C}^n$ tels que $Ax = b$. Soit $\delta b \in \mathbf{C}^n$ une perturbation. Notons $y := x + \delta x$ l'unique solution de $Ay = b + \delta b$. Donc si $Ax + A\delta x = b + \delta b$, alors $\delta x = A^{-1}\delta b$. Par conséquent,

$$\|\delta x\| = \|A^{-1}\delta b\| \leq \|A^{-1}\| \|\delta b\|,$$

donc

$$\|b\| = \|Ax\| \leq \|A\| \|x\|,$$

d'où

$$\frac{\|\delta x\|}{\|x\|} \leq \|A\| \|A^{-1}\| \frac{\|\delta b\|}{\|b\|}.$$

□

Exemple 1.5.5 Problèmes mal conditionnés :

- Interpolation polynomiale : Soient $(x_i)_{1 \leq i \leq n}$ et $(y_i)_{1 \leq i \leq n}$ des complexes. On suppose les $(x_i)_i$ deux à deux distincts. On cherche le polynôme $P \in \mathbf{C}[X]$ de degré minimal vérifiant pour tout $i \in \{1, \dots, n\}$, $P(x_i) = y_i$. Il existe un unique $P \in \mathbf{C}_{n-1}[X]$ solution. On peut le chercher dans la base canonique de $\mathbf{C}_{n-1}[X]$,

$$P = \sum_{j=0}^{n-1} a_{j+1} X^j.$$

Le vecteur $A = (a_1, \dots, a_n)^T \in \mathbf{C}^n$ est alors solution de

$$VA = \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix}, \quad \text{avec } V = (x_i^{j-1})_{1 \leq i, j \leq n} \text{ la matrice de Vandermonde (inversible).}$$

$\text{cond}(V)$ est très grand pour n assez grand. Conséquence (en présence d'une arithmétique approchée) : la solution obtenue numériquement est loin d'être bonne. Sur le test, $\text{cond}(V) \simeq 10^{24}$, avec une erreur machine de 10^{-16} . On peut donc s'attendre à $\|\delta x\|/\|x\| \simeq 10^8$.

Pour contourner cette difficulté, on reformule le problème au niveau algébrique. Cela revient à changer de base dans la formulation d'origine. Par exemple :

— Base de Lagrange associée aux points $(x_i)_{1 \leq i \leq n}$,

$$L_i = \prod_{\substack{j=1 \\ j \neq i}}^n \frac{X - x_j}{x_i - x_j}, \quad P = \sum_{i=1}^n y_i L_i.$$

Dans ce cas, la formulation « algèbre linéaire » revient à inverser la matrice identité, de conditionnement 1.

— Base de Newton :

$$P = b_0 + b_1(X - x_1) + b_2(X - x_1)(X - x_2) + \dots + b_{n-1}(X - x_1) \dots (X - x_{n-1}).$$

L'algorithme des différences divisées (mémo Scilab) permet de trouver les $(b_i)_{1 \leq i \leq n-1}$ (de type « taux d'accroissement »).

6 Exemple important : matrice du laplacien 1d

De nombreux problèmes sur des applications des mathématiques font intervenir l'opérateur laplacien

$$\Delta u = \frac{\partial^2 u}{\partial x^2} + \frac{\partial^2 u}{\partial y^2} + \frac{\partial^2 u}{\partial z^2} \quad \text{en dimension 3,}$$

comme

- l'équation de la chaleur : $\frac{\partial u}{\partial t} = K \Delta u$,
- l'équation des ondes : $\frac{\partial^2 u}{\partial t^2} - c^2 \Delta u = 0$.

Exemple 1.6.1 $f \in \mathcal{C}^0([0, 1])$ est donnée, on considère le système

$$(\mathcal{S}) : \begin{cases} -u''(x) = f(x) & , \quad x \in]0, 1[\\ u(0) = u(1) = 0 \end{cases}.$$

Si $f = 0$, l'unique $u \in \mathcal{C}^2([0, 1])$ est $u = 0$. Sinon, on peut trouver une formule par intégrations successives (en dimension plus grande, cette méthode échoue).

6.1 Discrétisation aux différences finies

Soit $n \in \mathbf{N}$, $n \geq 1$, on pose $h := 1/(n + 1)$ ainsi que $x_i := ih$ pour $0 \leq i \leq n + 1$,

$$0 = x_0 \leq x_1 \leq \dots \leq x_{n+1} = 1.$$

Supposons qu'il existe une unique solution $u \in \mathcal{C}^4([0, 1])$ au problème précédent. Par formules de Taylor,

$$\forall i \in \{1, \dots, n\}, \quad u''(x_i) = -f(x_i) = \frac{u(x_{i+1}) - u(x_i)}{h} - \frac{u(x_i) - u(x_{i-1}))}{h} + \frac{h^2}{12} u^{(4)}(x_i + \theta_i h), \quad \theta_i \in [-1, 1].$$

On simplifie le problème (en réalité on l'approche) en dimension finie, sous forme linéaire en le problème suivant.

Trouver $U \in \mathbf{R}^n$ tel que, ayant posé $U_0 = U_{n+1} = 0$ (conditions aux limites), on ait

$$\forall i \in \{1, \dots, n\}, \quad \frac{U_{i+1} - 2U_i + U_{i-1}}{h^2} = -f(x_i),$$

i. e. $AU = F$, où $F = (f(x_i))_i$ et

$$A = \frac{1}{h^2} \begin{pmatrix} 2 & -1 & & (0) \\ -1 & \ddots & \ddots & \\ & \ddots & \ddots & -1 \\ (0) & & -1 & 2 \end{pmatrix}.$$

Définition 1.6.2 (Laplacien) La matrice

$$A_n = \frac{1}{h^2} \begin{pmatrix} 2 & -1 & & (0) \\ -1 & \ddots & \ddots & \\ & \ddots & \ddots & -1 \\ (0) & & -1 & 2 \end{pmatrix}.$$

est égale à l'opposé de la matrice du laplacien.

Le problème à résoudre est $(n + 1)^2 A_n U = F$, avec $U \in \mathbf{R}^n$ et $F \in \mathbf{R}^n$ donnée, pour approcher (\mathcal{S}) .

6.2 Propriétés hermitiennes de A_n

Proposition 1.6.3 *La matrice A_n est symétrique définie positive.*

PREUVE. Soit $U \in \mathbf{R}^n$, on impose $U_0 = U_{n+1} = 0$. Par sommation d'Abel,

$$\langle A_n U, U \rangle = \sum_{i=1}^n U_i \underbrace{(-U_{i-1} + 2U_i - U_{i+1})}_{=-(U_{i-1}+U_i)+(U_i-U_{i-1})} = \sum_{i=2}^n (U_i - U_{i-1})U_{i-1} + \sum_{i=1}^n (U_i - U_{i-1})U_i + U_n^2 = \sum_{i=2}^n (U_i - U_{i-1})^2 + U_1^2 + U_n^2.$$

Si $\langle A_n U, U \rangle = 0$, alors $U_1 = U_n = 0$ et pour tout $n \in \{2, \dots, n\}$, $U_i - U_{i-1} = 0$, donc $U = 0$. Par conséquent, $\sigma(A_n) \subset \mathbf{R}_+^*$. En utilisant le rayon spectral, $\rho(A_n) \leq \|A_n\|_\infty \leq 4$ (égalité si $n \geq 3$). Ainsi, $\sigma(A_n) \subset]0, 4]$. \square

Remarque 1.6.4 On peut montrer que $A_n - 4I_n$ est symétrique défini négative, et donc $\sigma(A_n) \subset]0, 4]$.

Proposition 1.6.5 (Spectre de A_n)

$$\sigma(A_n) = \left\{ 4 \sin^2 \left(\frac{k\pi}{2(n+1)} \right) \mid 1 \leq k \leq n \right\}.$$

PREUVE. 1^{ère} méthode : Voir TD, par coïncidence algébrique (avec le problème continu).

2^{ème} méthode : Cherchons $U \in \mathbf{R}^n$ et $\lambda \in]0, 4]$ tels que $U \neq 0$ et $A_n U = \lambda U$. On résout

$$\forall i \in \{1, \dots, n\}, \quad -U_{i-1} + 2U_i - U_{i+1} - U_{i+1} = \lambda U_i,$$

avec $U_0 = U_{n+1} = 0$. $(U_i)_{1 \leq i \leq n}$ est solution d'une récurrence linéaire d'ordre 2. Le polynôme caractéristique de cette récurrence est $X^2 - (2 - \lambda)X + 1 = 0$, de racines

$$r := \frac{1}{2}[(2 - \lambda) + i\sqrt{\lambda(4 - \lambda)}], \quad \text{et } \bar{r}.$$

Ainsi, pour tout j , $U_j = \alpha r^j + \beta \bar{r}^j$, avec $\alpha, \beta \in \mathbf{C}$. Comme $|r|^2 = r\bar{r} = 1$, on a $r = e^{i\theta}$, avec $\theta \in \mathbf{R}$. Les conditions $U_0 = U_{n+1} = 0$ permettent d'obtenir α et β . En l'occurrence, en (α, β) ,

$$\begin{cases} U_0 & = & \alpha + \beta & = & 0 \\ U_{n+1} & = & \alpha r^{n+1} + \beta \bar{r}^{n+1} & = & \alpha [e^{i(n+1)\theta} - e^{-i(n+1)\theta}]. \end{cases}$$

Si la différence d'exponentielles est non nulle, alors $\alpha = \beta = 0$, et $U = 0$, et $\lambda \notin \sigma(A_n)$. Si elle est nulle, on obtient une droite vectorielle de solutions de la forme $U_j = \alpha(r^j - \bar{r}^j)$. Il suffit de trouver $\lambda \in]0, 4[$ tel que $r = e^{i\theta}$ vérifie

$$e^{i(n+1)\theta} = e^{-i(n+1)\theta},$$

ce qui est équivalent à $\theta = k\pi/(n+1)$, où $k \in \mathbf{Z}$. Pour résoudre $\lambda \in]0, 4[$ tel que $r(\lambda) = e^{ik\pi/(n+1)}$, où $k \in \mathbf{Z}$, on observe que

$$\Re(r(\lambda)) = \cos \left(\frac{k\pi}{n+1} \right) = \frac{1}{2}(2 - \lambda),$$

d'où

$$\lambda = 2 - 2 \cos \left(\frac{k\pi}{n+1} \right) = 4 \sin^2 \left(\frac{k\pi}{2(n+1)} \right).$$

Parmi ces valeurs pour $k \in \mathbf{Z}$, il y a exactement n valeur deux à deux distinctes. Ainsi,

$$\sigma(A_n) \subset \left\{ 4 \sin^2 \left(\frac{k\pi}{2(n+1)} \right) \mid k \in \mathbf{Z} \right\} = \left\{ 4 \sin^2 \left(\frac{k\pi}{2(n+1)} \right) \mid 1 \leq k \leq n \right\}.$$

L'inclusion réciproque est dans la synthèse de la preuve. \square

On peut ainsi identifier explicitement

$$\|A_n\|_2 = \rho(A_n) = 4 \sin^2 \left(\frac{n\pi}{2(n+1)} \right),$$

et également

$$\|A_n^{-1}\|_2 = \rho(A_n^{-1}) = \left[4 \sin^2 \left(\frac{n\pi}{2(n+1)} \right) \right]^{-1}.$$

De plus, $\text{cond}_2(A_n) = \|A_n\|_2 \|A_n^{-1}\|_2$.

6.3 Monotonie de la matrice A_n

Définition 1.6.6 (Positivité et monotonie)

- Un vecteur $v \in \mathbf{R}^n$ est dit positif si ses composantes le sont. On note alors $v \geq 0$.
- Une matrice $A \in \mathcal{M}_n(\mathbf{R})$ est dite positive, noté $A \geq 0$, si ses coefficients le sont.
- Une matrice $A \in \mathcal{M}_n(\mathbf{R})$ est dite monotone si $A \in \mathcal{GL}_n(\mathbf{R})$ et $A^{-1} \geq 0$.

Remarque 1.6.7 Il n'y a aucun lien entre la positivité des matrices symétriques et cette positivité ci. Par exemple, la matrice

$$\begin{pmatrix} 1 & 2 \\ 2 & 1 \end{pmatrix}$$

est positive mais de spectre $\{-1, 3\}$.

Proposition 1.6.8 Soit $A \in \mathcal{M}_n(\mathbf{R})$. Il y a équivalence entre

- A est monotone,
- $\forall v \in \mathbf{R}^n, Av \geq 0 \implies v \geq 0$.

PREUVE. (\implies) : On suppose $A \in \mathcal{GL}_n(\mathbf{R})$ et $A^{-1} \geq 0$. Soit $v \in \mathbf{R}^n$ tel que $Av \geq 0$, alors $v = A^{-1}(Av)$, d'où

$$\forall j \in \{1, \dots, n\}, v_j = \sum_{i=1}^n \underbrace{(A^{-1})_{j,i}}_{\geq 0} \underbrace{(Av)_i}_{\geq 0} \geq 0,$$

donc $v \geq 0$.

(\impliedby) : Soit $v \in \mathbf{R}^n$ tel que $Av = 0$, alors $Av \geq 0$, donc $v \geq 0$, et $A(-v) \geq 0$, donc $v \leq 0$. Donc $v = 0$, et $\text{Ker}(A) = \{0\}$ et $A \in \mathcal{GL}_n(\mathbf{R})$. De plus, on pose e_i le $i^{\text{ème}}$ vecteur de la base canonique de \mathbf{R}^n . $e_i \geq 0$ donc $A^{-1}e_i \geq 0$ par la propriété. Ce vecteur étant la $i^{\text{ème}}$ colonne de A^{-1} , on a bien $A^{-1} \geq 0$. \square

Si A est monotone et $x, y \in \mathbf{R}^n$ sont tels que $A(y - x) \geq 0$, alors $y - x \geq 0$. On obtient un principe de comparaison des solutions de $Ax = f$.

Proposition 1.6.9 Pour tout $n \in \mathbf{N}^*$, A_n est monotone.

PREUVE. Soit $v \in \mathbf{R}^n$ tel que $A_n v \geq 0$. Montrons que $v \geq 0$. Les coefficients de v vérifient

$$\forall i \in \{1, \dots, n\}, -v_{i-1} + 2v_i - v_{i+1} \geq 0,$$

après avoir posé $v_0 = v_{n+1} = 0$. La première équation est $2v_1 - v_2 \geq 0$. Posons $k \in \{1, \dots, n\}$ tel que $v_k = \min_{1 \leq i \leq n} v_i$. Il suffit de montrer que $v_k \geq 0$.

Si $k = 1$, alors

$$2v_1 - v_2 \geq 0 \implies v_1 = v_k \underbrace{\geq}_{\text{équation}} v_2 - v_1 \underbrace{\geq}_{\text{définition de } k} 0.$$

Si $k = n$, alors

$$2v_n - v_{n-1} \geq 0 \implies v_n = v_k \geq v_{n-1} - v_n \geq 0.$$

Si $k \in \{2, \dots, n-1\}$, alors la $k^{\text{ème}}$ équation $(Av_k)_k = -v_{k+1} + 2v_k - v_{k-1} \geq 0$, de sorte que

$$\underbrace{(-v_{k+1} + v_k)}_{\leq 0} + \underbrace{(v_k - v_{k-1})}_{\leq 0} \geq 0.$$

Ainsi, $v_k = v_{k-1} = v_{k+1}$. On peut, par récurrence sur l'indice, montrer que les v_i sont tous égaux \square

Conséquence : Pour $n \geq 3$, on peut montrer que $\|A_n\|_\infty$ vaut $(n+1)^2/8$ si n est impair et $n(n+2)/8$ sinon.

PREUVE. Observons que la fonction

$$\varphi : \begin{array}{ll} [0, 1] & \longrightarrow \mathbf{R} \\ x & \longmapsto \frac{1}{2}x(1-x) \end{array}$$

est solution de $-\varphi'' = 1$ sur $]0, 1[$, et que $\varphi(0) = \varphi(1) = 0$. Posons pour $n \geq 3$, $\phi \in \mathbf{R}^n$ tel que

$$\phi_i = \varphi\left(\frac{i}{n+1}\right) = \frac{1}{2(n+1)^2}i(n+1-i).$$

On peut calculer

$$(n+1)^2 A_n \phi = \frac{1}{2} [2i(n+1-i) - (i-1)(n+1-i+1) - (i+1)(n+1-i-1)]_{1 \leq i \leq n} = (\mathbf{1})_{1 \leq i \leq n}.$$

Soit $F \in \mathbf{R}^n$ tel que

$$\forall i \in \{1, \dots, n\}, \quad \|F\|_\infty \leq F_i \leq \|F\|_\infty,$$

alors

$$0 \leq v_1 := \|F\|_\infty \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix} - F, \quad \text{et} \quad v_2 := F + \|F\|_\infty \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix} \geq 0.$$

Or $(n+1)^2 A_n$ est monotone, donc

$$(n+1)^2 A_n v \geq 0 \implies v \geq 0 \quad \text{ou} \quad v \geq 0 \implies ((n+1)^2 A_n)^{-1} v \geq 0.$$

On en déduit que

$$\begin{cases} 0 \leq ((n+1)^2 A_n)^{-1} v_1 \\ 0 \leq ((n+1)^2 A_n)^{-1} v_2 \end{cases},$$

mais

$$((n+1)^2 A_n)^{-1} \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix} = \phi,$$

d'où, en comparant composante par composante,

$$-\|F\|_\infty \phi \leq \underbrace{((n+1)^2 A_n)^{-1} F}_{=U} \leq \|F\|_\infty \phi.$$

Ainsi,

$$\|U\|_\infty \leq \|F\|_\infty \|\phi\|_\infty.$$

On peut interpréter cela comme

$$\|A_n^{-1}\| = \sup_{F \neq 0} \frac{A_n^{-1} F \|F\|_\infty}{\|F\|_\infty} = \sup_{F \neq 0} \frac{(n+1)^2 \|((n+1)^2 A_n)^{-1} F\|_\infty}{\|F\|_\infty} \leq (n+1)^2 \|\phi\|_\infty.$$

Il y a égalité pour $F = (1, \dots, 1)^T$. Reste à calculer $\|\phi\|_\infty$. □

6.4 Convergence de la méthode (en norme uniforme)

Soit $f \in \mathcal{C}^2([0, 1])$ et u l'unique solution du système

$$(\mathcal{S}) : \begin{cases} -u'' & = & f \\ u(0) & = & u(1) = 0 \end{cases}$$

En fait, $u \in \mathcal{C}^4([0, 1])$. Pour $n \in \mathbf{N}^*$, on considère les objets suivants.

- $U^{ex} \in \mathbf{R}^n$ le vecteur de composantes $U_i^{ex} = u(i/(n+1))$, pour $1 \leq i \leq n$. En particulier, il vérifie $(n+1)^2 A_n U^{ex} = F + \varepsilon$, avec $F = (f(i/(n+1)))_{1 \leq i \leq n}$, et $\varepsilon \in \mathbf{R}^n$, appelé *erreur de coïncidence*. Par développement de Taylor,

$$\forall i \in \{1, \dots, N\}, \exists \theta_i \in [-1, 1], \quad \varepsilon_i = \frac{1}{(n+1)^2} \frac{1}{12} u^{(4)} \left(\frac{i}{n+1} + \frac{\theta_i}{n+1} \right).$$

Donc

$$\|\varepsilon\|_\infty \leq \frac{1}{12(n+1)^2} \max_{x \in [0, 1]} |f^{(4)}(x)|.$$

- $U^{(n)} \in \mathbf{R}^n$ la solution du problème approché $(n+1)^2 A_n U^{(n)} = F$.

Question : $\|U^{ex} - U^{(n)}\|_\infty \xrightarrow{(n \rightarrow +\infty)} 0$? On a

$$(n+1)^2 A_n (U^{ex} - U^{(n)}) = F + \varepsilon - F = \varepsilon,$$

donc

$$\|U^{ex} - U^{(n)}\|_\infty \leq (n+1)^{-2} \underbrace{\|A_n^{-1}\|_\infty}_{\sim n^2/8} \underbrace{\|\varepsilon\|_\infty}_{\sim n^{-2} \|f^{(4)}\|_\infty / 12}.$$

Ainsi,

$$\|U^{ex} - U^{(n)}\|_\infty \leq C n^{-2} \|f^{(4)}\|_\infty \xrightarrow{n \rightarrow \infty} 0,$$

pour $C \in \mathbf{R}^n$ une constante indépendante de n et de f .

Remarque 1.6.10

$$\|U^{ex} - U^{(n)}\|_2^2 = \sum_{i=1}^n |U_i^{ex} - U_i^{(n)}|^2 \leq n \|u^{ex} - u^{(n)}\|_\infty^2,$$

donc

$$\|U^{ex} - U^{(n)}\|_2 \leq \sqrt{n} C n^{-2} \|f^{(2)}\|_\infty \leq C n^{-3/2} \|f^{(2)}\|_\infty \xrightarrow{n \rightarrow +\infty} 0.$$

Chapitre 2

Méthodes directes

1 Remarques préliminaires

Soient $A \in \mathcal{GL}_n(\mathbf{K})$ et $b \in \mathbf{K}^n$. Pour résoudre $Ax = b$ par formule de Cramer, et calculs de déterminants de taille n , la complexité de calcul est en $O(nn!)$. Sur un supercalculateur à 200 petaflops (= $200 \cdot 10^{15}$ opérations flottants par seconde), pour $n = 50$, il faut 2.10^{61} années. Pour $n = 12$, il faut environ une année. En réalité, on peut trouver des algorithmes en $O(n^3)$ opérations. Pour $n = 10000$, votre machine peut résoudre en quelques secondes. Le cas particulier des matrices triangulaires mène à deux algorithmes :

- l'algorithme de descente, pour $A \in T_n^l(\mathbf{K})$, en $O(n^2)$ opérations,
- l'algorithme de remontée, pour $A \in T_n^u(\mathbf{K})$, de même complexité.

2 Factorisation LU

Rappel : Opérations du pivot de Gauss.

- Opérer sur les lignes équivaut à multiplier à gauche par A .
- Opérer sur les colonnes équivaut à multiplier à droite par A .
- La matrice $D(\lambda, i) = I_n + (\lambda - 1)E_{i,i}$, où $\lambda \notin \{0, 1\}$, est la matrice de dilatation de la $i^{\text{ème}}$ ligne par λ , $L_i \leftarrow \lambda L_i$.
- La matrice $P(i, j) = I_n - E_{i,i} - E_{j,j} + E_{i,j} + E_{j,i}$ est la matrice de permutation, qui permute les $i^{\text{ème}}$ et $j^{\text{ème}}$ lignes, $(L_i, L_j) \leftarrow (L_j, L_i)$.
- La matrice $T(\lambda, i, j) = I_n + \lambda E_{i,j}$, où $i \neq j$ et $\lambda \neq 0$, est la matrice de transvection, $L_i \leftarrow L_i + \lambda L_j$.

Remarque 2.2.1 Le calcul du rang, déterminant, noyau, image peuvent se faire à partir de ces opérations en examinant les invariants de ces opérations. Par exemple,

$$\text{Ker } A = \text{Ker}(T(\lambda, i, j)A), \quad \text{Im } A = \text{Im}(AT(\lambda, i, j)).$$

Pour résoudre $Ax = b$, les opérations du pivot de Gauss peuvent être « stockées » dans une factorisation LU de A . De même, inverser A revient à résoudre n systèmes linéaires $Ax = e_i$, où e_i est le $i^{\text{ème}}$ vecteur de la base canonique.

Définition 2.2.2 (Mineurs principaux dominants) Soit $A \in \mathcal{M}_n(\mathbf{K})$, les mineurs principaux dominants de A sont les $\det((A_{i,j})_{1 \leq i,j \leq k})$, pour $1 \leq k \leq n$.

Remarque 2.2.3

- Toute matrice dont les mineurs principaux dominants sont non nuls est inversible.
- La réciproque est fautive. Par exemple,

$$\begin{pmatrix} 0 & 1 \\ 1 & 1 \end{pmatrix}$$

est inversible, mais le mineurs principaux dominants de taille 1 est nul.

- Toute matrice symétrique définie positive réelle a ses mineurs principaux dominants tous non nuls. C'est une conséquence de la réduction des formes bilinéaires. En réalité, si A est symétrique, il y a équivalence entre A symétrique définie positive et ses mineurs principaux dominants sont strictement positifs.

Lemme 2.2.4 Soit $A \in \mathcal{M}_n(\mathbf{K})$ dont tous les mineurs principaux dominants sont non nuls. Alors pour tous $\lambda \in \mathbf{K}$, pour tous $i < j$, $T(\lambda, i, j)A$ a aussi ses mineurs principaux dominants non nuls.

Pourquoi ?

$$T_k = \prod_{i=k+1}^n (I_n - x_{i,n}^{(k)} E_{i,k}),$$

$$T_{k-1} = \prod_{i=k+1}^n (I_k + x_{i,n}^{(k)} E_{i,k}) = I_n + \sum_{i=k+1}^n x_{i,k}^{(k)} E_{i,k}.$$

Par exemple, $T_k^{-1} T_{k+1}^{-1}$ fait intervenir des produits $E_{i,k} E_{j,k+1}$ avec $i \geq k+1$ et $j \geq k+2$,

$$T_k^{-1} T_{k+1}^{-1} = \left(I + \sum_{i \geq k+1} x_{i,k}^{(k)} E_{i,k} \right) \left(I + \sum_{j \geq k+2} x_{j,k+1}^{(k+1)} E_{j,k+1} \right)$$

$$= I + \sum_{i \geq k+1} x_{i,k}^{(k)} E_{i,k} + \sum_{j \geq k+1} x_{j,k+1}^{(k+1)} E_{j,k+1} + 0.$$

et ce produit est nul. On obtient ainsi

$$L = T_1^{-1} \dots T_{n-1}^{-1} = I_n + \sum_{j=1}^{n-1} \sum_{i=j+1}^n x_{i,j}^{(j)} E_{i,j}.$$

□

Conséquence : Pour résoudre un ou plusieurs systèmes $Ax = b$ (pour différents b , par exemple pour A^{-1}), on peut

- précalculer $A = LU$, en $O(2n^3/2)$ opérations,
- résoudre $Ly = b$ et $Ux = y$, chacun en $O(n^2)$ opérations.

On a « stocké » les opérations du pivot du second membre b dans la matrice L .

Concernant le choix des pivots, si l'un des mineurs principaux dominants est nul, supposons le $k^{\text{ème}}$ le plus petit non nul, alors l'algorithme s'arrête à la $k^{\text{ème}}$ étape car $a_{k,k}^{(k)} = 0$. Mais si A est inversible, il existe $a_{i,k}^{(k)} \neq 0$ pour $i \geq k+1$ (sans que $\text{rg } A \leq n-1$). On pourrait permuter les lignes k et la i pour utiliser $a_{i,k}^{(k)}$ comme pivot. Cela donne une factorisation de $A = PLU$, où P est une matrice de permutation.

Si un pivot est très petit, une difficulté numérique se pose sur l'arithmétique approchée. L'erreur de calcul sur $a_{i,k}^{(k)}$ par $|a_{k,k}^{(k)}| \gg 1$. On peut alors établir une stratégie de pivot en permutant pour limiter cet effet.

- Pivot partiel : Soit avec la ligne i de sorte que $\max_{i \geq k} |a_{i,k}^{(k)}|$ est réalisé sur la diagonale.
- Pivot total : On suppose $|a_{i,j}^{(k)}|$ maximal pour $i, j \geq k$. On permute lignes et colonnes pour utiliser cette valeur comme pivot, $A = PLUQ$.

On peut citer l'exemple des matrices bandes / creuses, dans lesquelles seule un groupe de sous-diagonales est non nul. On appelle *demi-largeur de bande* l'entier p tel que p sous-diagonales soient non nulles de chaque côté de la diagonale. La complexité de la factorisation LU est alors en $O(np^2)$ opérations, et les matrices L et U ont le même profil (seulement p sous-diagonales non nulles).

3 Décomposition de Cholesky

Théorème 2.3.1 (Décomposition de Cholesky) Soit $A \in S_n^{++}(\mathbf{R})$, il existe une unique $B \in T_n^1(\mathbf{R})$ telle que

$$\begin{cases} \forall i \in \{1, \dots, n\}, & B_{i,i} > 0, \\ A = BB^T. \end{cases}$$

PREUVE. Existence : A admet une unique factorisation $LU = A$, avec $L_{i,i} = 1$ pour tous $1 \leq i \leq n$.

$$U = \begin{pmatrix} * & & * \\ & \ddots & \\ 0 & & * \end{pmatrix} = D\tilde{U},$$

avec $D = \text{diag}((u_{i,i})_{1 \leq i \leq n})$, $\tilde{U} \in T_n^u(\mathbf{R})$, $\tilde{U}_{i,i} = 1$ pour tous $1 \leq i \leq n$. Comme $A = LU = A^T$, et que A^T admet une factorisation LU, qui est $U^T L^T$. On en déduit que $\tilde{U}^T D^T L^T = LD\tilde{U}$. Par unicité, $L = \tilde{U}^T$, $\tilde{U} = L^T$ et $D = D^T$, et donc $A = LDL^T$. Pour $x \neq 0$, comme A est symétrique définie positive, on a

$$0 < \langle Ax, x \rangle = \langle LDL^T x, x \rangle = \langle DL^T x, L^T x \rangle,$$

donc

$$\forall y \neq 0, \quad \langle Dy, y \rangle > 0,$$

ce qui montre que $D \in D_n^{++}(\mathbf{R})$. On peut donc écrire $A = LD\tilde{U} = L\sqrt{D}\sqrt{D}\tilde{U}$. On pose $B := L \operatorname{diag}((\sqrt{D_{i,i}})_{1 \leq i \leq n}) \in T_n^l(\mathbf{R})$, avec $B_{i,i} = L_{i,i}\sqrt{D_{i,i}} > 0$. Ainsi, $A = BB^T$.

Unicité : laissé en exercice. □

Algorithme : $A = BB^T$, équations d'inconnues $(B_{i,j})$.

$$\forall j \in \{1, \dots, n\}, \quad b_{j,j}^2 + \sum_{k=1}^{j-1} b_{j,k}^2 = a_{j,j}.$$

On pose

$$b_{j,j} := \sqrt{a_{j,j} + \sum_{k=1}^n b_{j,k}^2},$$

et donc

$$\forall i \geq j+1, \quad b_{i,j} = \frac{a_{i,j} - \sum_{k=1}^{j+1} b_{j,k}b_{i,k}}{b_{j,j}}.$$

Cette méthode est en $O(n^3/3)$ opérations.

Chapitre 3

Méthodes itératives

1 Généralités

Soit $A \in \mathcal{GL}_n(\mathbf{K})$, on cherche à résoudre $Ax = b$. On choisit deux matrices $M, N \in \mathcal{M}_n(\mathbf{K})$ telles que

$$\begin{cases} A = M - N \\ M \text{ est facile à inverser (algorithmiquement peu coûteuse à inverser)}. \end{cases}$$

On définit alors pour un $x_0 \in \mathbf{K}^n$ donné la suite récurrente

$$\forall k \geq 1, \quad Mx_{k+1} = Nx_k + b.$$

Définition 3.1.1 (Méthode itérative convergente) On dit qu'une méthode itérative est convergente si pour tout $x_0 \in \mathbf{K}^n$, la suite $(x_k)_k$ converge.

Remarque 3.1.2 A étant inversible, la seule limite possible est la solution $x = A^{-1}b$.

Définition 3.1.3 (Vocabulaire)

- Résidu à l'étape k : $r_k := b - Ax_k$.
- Erreur à l'étape k : $e_k := x - x_k$.

On a

$$x_k \xrightarrow[k \rightarrow +\infty]{} x \iff e_k \xrightarrow[k \rightarrow +\infty]{} 0 \iff r_k \xrightarrow[k \rightarrow +\infty]{} 0.$$

Remarque 3.1.4 $e_k = x - x_k = A(b - Ax_k) = A^{-1}r_k$, donc $\|e_k\| \leq \|A^{-1}\| \|r_k\|$. Cela peut servir à définir un critère d'arrêt à partir de $\|r_k\|$ et de $\|A^{-1}\|$.

Théorème 3.1.5 La méthode itérative pour $A = M - N$ est convergente si et seulement si $\rho(M^{-1}N) < 1$.

PREUVE. On a

$$\begin{cases} \forall k \geq 0, & x_{k+1} = M^{-1}Nx_k + M^{-1}b \\ x = M^{-1}Nx + M^{-1}b \end{cases},$$

donc pour tout $k \in \mathbf{N}$, $e_{k+1} = M^{-1}Ne_k$, soit $e_k = (M^{-1}N)^k e_0$. On souhaite que pour tout $e_0 \in \mathbf{K}^n$, $e_k \xrightarrow[k \rightarrow +\infty]{} 0$, donc que $(M^{-1}N)^k \xrightarrow[k \rightarrow +\infty]{} 0$. C'est équivalent au fait que $\rho(M^{-1}N) < 1$. \square

Remarque 3.1.6 La vitesse de convergence est au plus géométrique, et est liée à la quantité $\rho(M^{-1}N)$:

$$\forall \varepsilon > 0, \exists \|\cdot\| \text{ norme sur } \mathbf{K}^n, \quad \|M^{-1}N\| \leq \rho(M^{-1}N) + \varepsilon.$$

Ainsi,

$$\forall k \in \mathbf{N}, \quad \|(M^{-1}N)^k\| \|e_0\| \leq (\rho(M^{-1}N) + \varepsilon)^k \|e_0\|,$$

avec pour ε petit, $\rho(M^{-1}N) + \varepsilon < 1$. Pour une norme donnée, par exemple $\|\cdot\|_2$ sur \mathbf{K}^n , par équivalence des normes en dimension finie, il existe $C_\varepsilon > 0$ tel que

$$\forall k \in \mathbf{N}, \quad \|e_k\|_2 \leq C(\rho(M^{-1}N) + \varepsilon)^k \|e_0\|_2.$$

On appelle *taux de convergence* la quantité $-\log(\rho(M^{-1}N))$. La convergence est d'autant plus rapide (pour le x_0 le pire) que le taux est grand.

2 Méthodes usuelles

2.1 Méthode de Richardson

Soit $\alpha \in \mathbf{R}^*$, on pose $M := \alpha^{-1}I_n$ et $N := \alpha^{-1}I_n - A$. La suite récurrence est

$$x_{k+1} = M^{-1}Nx_k + M^{-1}b = x_k + \alpha(b - Ax_k),$$

et $M^{-1}N = I_n - \alpha A$. Par conséquent,

$$\sigma(M^{-1}N) = \{1 - \alpha\lambda, \lambda \in \sigma(A)\}.$$

Supposons que $A \in S_n^{++}(\mathbf{R})$, alors $\sigma(A) \subset \mathbf{R}_+^*$. On note $0 < \lambda_1 \leq \dots \leq \lambda_n$ les valeurs propres de A . On a

$$\rho(M^{-1}N) = \begin{cases} |1 - \alpha\lambda_n| & \text{si } \alpha \notin]0, +\alpha_*[\\ |1 - \alpha\lambda_1| & \text{si } \alpha \in]0, +\alpha_*], \end{cases},$$

avec $\alpha_* := 2/(\lambda_1 + \lambda_n)$. En particulier,

$$\rho(M^{-1}N) < 1 \iff \alpha \in \left]0, \frac{2}{\lambda_n} \left[= \right]0, \frac{2}{\rho(A)} \left[.$$

Mieux, le rayon spectral est minimal lorsque $\alpha = \alpha_*$. On a alors

$$\rho(M^{-1}N) = \frac{\lambda_n - \lambda_1}{\lambda_n + \lambda_1} = \frac{\text{cond}_2(A) - 1}{\text{cond}_2(A) + 1}.$$

Si $\text{cond}_2(A) \gg 1$, cette quantité approche 1 par valeurs inférieures. Si $\text{cond}_2(A) \simeq 1$, elle approche 0.

2.2 Méthode de Jacobi

On choisit $M := D := \text{diag}(A)$. Il est nécessaire de supposer $D \in \mathcal{GL}_n(\mathbf{R})$. La matrice d'itération est $M^{-1}N = D^{-1}(D - A) = I_n - D^{-1}A$. En pratique, l'algorithme « en place » prend la forme :

Soit $x^{(0)} \in \mathbf{R}^n$,

$$\forall k \geq 0, \forall i \in \{1, \dots, n\}, \quad x_i^{(k+1)} = \frac{1}{a_{i,i}} \left(b_i - \sum_{j \neq i} a_{i,j} x_j^{(k)} \right).$$

Idée : x vérifie

$$\forall i \in \{1, \dots, n\}, \quad a_{i,i} \underbrace{x_i}_{\text{inconnu}} + \sum_{\substack{j=1 \\ j \neq i}}^n a_{i,j} \underbrace{x_j}_{\text{supposé connu}} = b_i.$$

2.3 Méthode de Gauss-Seidel

Soit $A \in \mathcal{M}_n(\mathbf{R})$, on note $D \in \mathcal{M}_n(\mathbf{R})$ sa diagonale, $-E \in T_n^l(\mathbf{R})$ sa sous-diagonale et $-F \in T_n^u(\mathbf{R})$ sa sur-diagonale, de sorte que $A = D - E - F$. On pose

$$\begin{cases} M & := & D - E \\ N & := & F. \end{cases}$$

M est inversible si et seulement si $D \in \mathcal{GL}_n(\mathbf{R})$.

Algorithme : On pose pour tous $k \geq 0, i \in \{1, \dots, n\}$,

$$x_i^{(k+1)} = \frac{1}{a_{i,i}} \left(b_i - \sum_{j=1}^{i-1} a_{i,j} x_j^{(k+1)} - \sum_{j=i+1}^n a_{i,j} x_j^{(k)} \right).$$

2.4 Méthode de relaxation (SOR)

Soit $\omega \in \mathbf{R}_+^*$, avec les notations précédentes, on pose

$$\begin{cases} M & := & \frac{1}{\omega}D - E \\ N & := & \frac{1-\omega}{\omega}D + F. \end{cases}$$

M est inversible si et seulement si $D \in \mathcal{GL}_n(\mathbf{R})$.

3 Critères explicites de convergence

3.1 Matrices à diagonale dominante

Définition 3.3.1 (Matrice à diagonale strictement dominante) Soit $A \in \mathcal{M}_n(\mathbf{C})$, on dit qu'elle est à diagonale strictement dominante si

$$\forall i \in \{1, \dots, n\}, \quad |a_{i,i}| > \sum_{\substack{j=1 \\ j \neq i}}^n |a_{i,j}|.$$

Remarque 3.3.2 Toute telle matrice a une diagonale inversible. Les méthodes précédentes peuvent donc s'appliquer, i. e. on peut bien définir la suite récurrente $(x_k)_k$.

Proposition 3.3.3 Si $A \in \mathcal{M}_n(\mathbf{C})$ est à diagonale strictement dominante, alors $A \in \mathcal{GL}_n(\mathbf{C})$.

PREUVE. Soit $x \in \text{Ker } A$, alors

$$\forall i \in \{1, \dots, n\}, \quad \sum_{j=1}^n a_{i,j}x_j = 0,$$

donc

$$\forall i \in \{1, \dots, n\}, \quad a_{i,i}x_i = - \sum_{j \neq i} a_{i,j}x_j.$$

Soit $i \in \{1, \dots, n\}$, par inégalité triangulaire,

$$|a_{i,i}||x_i| \leq \sum_{j \neq i} |a_{i,j}||x_j| \leq \left(\sum_{j \neq i} |a_{i,j}| \right) \|x\|_\infty.$$

Or il existe $i \in \{1, \dots, n\}$ tel que $|x_i| = \|x\|_\infty$, et donc

$$\underbrace{\left(\sum_{j \neq i} |a_{i,j}| - |a_{i,i}| \right)}_{< 0} \|x\|_\infty \geq 0,$$

d'où $x = 0$. □

A-t-on convergence des précédentes méthodes pour de telles matrices ?

Théorème 3.3.4 Soit $A \in \mathcal{M}_n(\mathbf{C})$ à diagonale strictement dominante. Le méthodes de Jacobi, Gauss-Seidel et relaxation convergent pour $\omega \in]0, 1]$.

PREUVE. On se contentera de donner la preuve pour Jacobi. On a avec les notations précédentes, $M^{-1}N = I_n - D^{-1}A$. Soit $\lambda \in \sigma(M^{-1}N)$ tel que $|\lambda| = \rho(M^{-1}N)$ et $x \in \mathbf{C}^n$ un vecteur propre associé. Alors $M^{-1}Nx = \lambda x$, donc $Nx = \lambda Mx$, soit $(D - A)x = \lambda Dx$. On considère l'indice $i \in \{1, \dots, n\}$ tel que $|x_i| = \|x\|_\infty \neq 0$. On a

$$- \sum_{j \neq i} a_{i,j}x_j = \lambda a_{i,i}x_i, \quad \text{donc} \quad \lambda = - \frac{\sum_{j \neq i} a_{i,j}x_j}{a_{i,i}x_i}.$$

Ainsi,

$$|\lambda| \leq \frac{\sum_{j \neq i} |a_{i,j}||x_j|}{|a_{i,i}||x_i|} \leq \frac{\sum_{j \neq i} |a_{i,j}|}{\underbrace{|a_{i,i}|}_{< 1 \text{ par hypothèse}} \underbrace{\frac{\|x\|_\infty}{|x_i|}}_{= \|x\|_\infty}}.$$

Donc $\rho(M^{-1}N) < 1$ et la méthode converge. □

3.2 Matrices $H_n^{++}(\mathbf{C})$

Théorème 3.3.5 Soit $A \in H_n^{++}(\mathbf{C})$, on écrit $A = M - N$ avec $M \in \mathcal{GL}_n(\mathbf{C})$. Alors $M^* + N$ est hermitienne.

Si de plus $M^* + N \in H_n^{++}(\mathbf{C})$, alors $\rho(M^{-1}N) < 1$ (et la méthode itérative converge).

PREUVE. $(M^* + N)^* = M + N^* = (A + N) + N^* = (A^* + N^*) + N = M^* + N$, donc cette matrice est hermitienne.

Supposons que $M^* + N \in H_n^{++}(\mathbf{C})$. Il suffit de trouver une norme subordonnée sur $\mathcal{M}_n(\mathbf{C})$ telle que $\|M^{-1}N\| < 1$. On va utiliser la norme induite par A , induite par le produit scalaire

$$\forall x, y \in \mathbf{C}^n, \quad \langle x, y \rangle_A = \langle Ax, y \rangle.$$

Considérons $x \in \mathbf{C}^n$ tel que $\|x\|_A = 1$ et $\|M^{-1}Nx\|_1 = \|M^{-1}N\|_A$. On a

$$\begin{aligned} \|M^{-1}Nx\|_1^2 &= \langle AM^{-1}Nx, M^{-1}Nx \rangle \\ &= \langle AM^{-1}(M - A)x, M^{-1}(M - A)x \rangle \\ &= \langle Ax - Ax, x - y \rangle \quad (y := M^{-1}Ax) \\ &= \underbrace{\langle Ax, x \rangle}_{=\|x\|_A=1} - \underbrace{\langle Ay, x \rangle}_{=\langle y, Ax \rangle} - \underbrace{\langle Ax, y \rangle + \langle Ay, y \rangle}_{=My} \\ &= 1 - \underbrace{\langle (M^* + N)y, y \rangle}_{=\langle y, My \rangle = \langle M^*y, y \rangle} \quad (y \neq 0 \text{ car } M^{-1}A \in \mathcal{GL}_n(\mathbf{C}), x \neq 0) \\ &< 1. \end{aligned}$$

□

Exemple 3.3.6 On considère la matrice A_n de l'opposé du Laplacien. On sait que $A_n \in S_n^{++}(\mathbf{R})$. On lui applique la méthode de Jacobi. Posons $M := 2I_n$, alors $M^* + N = -A_n + 4I_n$, mais $\sigma(A_n) \subset]0, 4[$, d'où $\sigma(M^* + N) \subset]0, 4[\subset \mathbf{R}_+^*$. Par conséquent, $M^* + N \in S_n^{++}(\mathbf{R})$ et la méthode de Jacobi converge.

Exemple 3.3.7 Pour la méthode de Gauss-Seidel, $M^* + N = 2I_n$ et la méthode converge aussi.

4 Résolution de systèmes linéaires au sens des moindres carrés

Soient $n, p \in \mathbf{N}^*$, $A \in \mathcal{M}_{n,p}(\mathbf{K})$ et $b \in \mathbf{K}^n$. On cherche un vecteur $x \in \mathbf{K}^p$ tel que $Ax = b$. On dit que le système linéaire $Ax = b$ est

1. *carré* si $n = p$,
2. *surdéterminé* si $n > p$,
3. *sous-déterminé* si $n < p$,
4. de *rang maximal* si $\text{rg } A = \min(n, p)$,
5. *incompatible* si $b \notin \text{Im } A$,
6. *compatible* si $b \in \text{Im } A$.

Si le système est compatible, alors il existe des solutions. Si $\text{rg } A = p$, il existe une unique solution et si $\text{rg } A < p$, il existe une infinité de solutions. En particulier, s'il est surdéterminé, de rang maximal et compatible, alors il existe une unique solution. S'il est sous-déterminé de rang maximal, alors il est compatible et il existe une infinité de solutions.

Mais que se passe-t-il si le système est incompatible ?

Définition 3.4.1 (Résolution au sens des moindres carrés) *Résoudre le système $Ax = b$ au sens des moindres carrés, c'est trouver un vecteur $x \in \mathbf{K}^p$ minimisant la quantité $\|Ax - b\|_2^2$.*

4.1 Existence et unicité

Théorème 3.4.2 *L'ensemble des solutions du système $Ax = b$ au sens des moindres carrés est*

$$\{x \in \mathbf{K}^p \mid Ax = p(b)\},$$

où l'application p est la projection orthogonale sur $\text{Im } A$.

PREUVE. Comme $p(b) \in \text{Im } A$, la caractérisation du projeté donne

$$\forall w \in \text{Im } A, \quad \langle p(b) - b, w \rangle = 0.$$

Soit $v \in \text{Im } A$, d'après le théorème de Pythagore,

$$\|v - b\|^2 = \|v - p(b)\|^2 + \|p(b) - b\|^2 \geq \|p(b) - b\|^2,$$

avec égalité si et seulement si $v = p(b)$. De plus, il existe $x_0 \in \mathbf{K}^p$ tel que $Ax_0 = p(b)$. L'unicité est garantie si et seulement si $\text{Ker } A = \{0\}$. □

4.2 Équation normale

Lemme 3.4.3 *Les solutions du système $Ax = b$ au sens des moindres carrés sont exactement les solutions de l'équation $A^*Ax = A^*b$.*

PREUVE. D'après le lemme précédent, il faut montrer que $\Gamma_1 := \{x \in \mathbf{K}^p \mid Ax = p(b)\}$ est égal à $\Gamma_2 := \{x \in \mathbf{K}^p \mid A^*Ax = A^*b\}$.

Soit $x \in \Gamma_1$, alors $A^*Ax = A^*p(b)$. Montrons que $A^*p(b) = A^*b$, i. e. que $p(b) - b \in \text{Ker } A^*$. On sait que $\text{Ker } A^* = (\text{Im } A)^\perp$, or $p(b) - b \in (\text{Im } A)^\perp$, d'où $A^*p(b) = A^*b$, et $x \in \Gamma_2$.

Soit $x \in \Gamma_2$. Comme $p(b) - b \in \text{Ker } A^*$, on a

$$A^*Ax = A^*(b - p(b) + p(b)) = A^*p(b),$$

d'où $Ax - p(b) \in \text{Ker } A^*$. Mais $\text{Ker } A^* = (\text{Im } A)^\perp$, et $Ax - p(b) \in \text{Im } A$. Par conséquent, $Ax - p(b) = 0$, donc $x \in \Gamma_1$.
Ainsi, $\Gamma_1 = \Gamma_2$. □

Remarque 3.4.4 L'équation normale $A^*Ax = A^*b$ fait intervenir une matrice A^*A qui est hermitienne et positive. De plus, son noyau est égal à celui de A . Ainsi, le système carré $AA^*x = b$ est inversible et il existe une unique solution pour les moindres carrés.

4.3 Exemple de la régression linéaire

Soit $(x_i, y_i)_{1 \leq i \leq n}$ une famille de points de \mathbf{R}^2 . On cherche un couple $(a, b) \in \mathbf{R}^2$ tel que

$$\forall i \in \{1, \dots, n\}, \quad ax_i + b = y_i.$$

Matriciellement, le problème s'écrit sous la forme $A(a, b) = b$, avec

$$A := \begin{pmatrix} x_1 & 1 \\ \vdots & \vdots \\ x_n & 1 \end{pmatrix}, \quad \text{et} \quad b := \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix}.$$

L'équation normale fait intervenir la matrice et le vecteur

$$A^*A = \begin{pmatrix} \sum_{i=1}^n x_i^2 & \sum_{i=1}^n x_i \\ \sum_{i=1}^n x_i & \sum_{i=1}^n 1 \end{pmatrix}, \quad \text{et} \quad A^*b = \begin{pmatrix} \sum_{i=1}^n x_i y_i \\ \sum_{i=1}^n y_i \end{pmatrix}.$$

De plus, on a $\text{Ker } A = \text{Ker } A^*A = \{0\}$ dès que $n \geq 2$, et qu'au moins deux des réels x_i sont distincts. Après résolution de l'équation normale, on obtient que

$$\begin{cases} a = \frac{n \sum_{i=1}^n x_i y_i - \left(\sum_{i=1}^n x_i\right) \left(\sum_{i=1}^n y_i\right)}{n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i\right)^2} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2}, \\ b = \bar{y} - a\bar{x} \end{cases},$$

avec

$$\bar{x} := \frac{1}{n} \sum_{i=1}^n x_i, \quad \text{et} \quad \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i.$$

4.4 Factorisation QR par les matrices de Householder

On veut utiliser de symétries orthogonales pour produire une factorisation QR.

Remarque 3.4.5 Si $Q \in H_n(\mathbf{C}) \cap U_n(\mathbf{C})$, alors $Q^{-1} = Q^* = Q$.

Définition 3.4.6 (Matrice de Householder) *On appelle matrice de Householder associée à un vecteur $v \in \mathbf{R}^n$ la matrice*

$$H(v) := \begin{cases} I_n & \text{si } v = 0 \\ I_n - 2 \frac{vv^T}{v^T v} & \text{sinon} \end{cases}.$$

Proposition 3.4.7 Soit $v \in \mathbf{R}^n$, alors

1. la matrice $H(v)$ est symétrique et orthogonale,
2. si $v \neq 0$, alors $H(v)$ est la matrice de la symétrie orthogonale sur v^\perp parallèlement à $\text{Vect}(v)$,
3. pour tout $e \in \mathbf{R}^n$ tel que $e^*e = 1$, on a

$$H(v + \|v\|e)v = -\|v\|e, \quad \text{et} \quad H(v - \|v\|e)v = \|v\|e.$$

On obtient ainsi un nouvel algorithme d'élimination. Soit $A \in \mathcal{M}_{n,p}(\mathbf{R})$. On note $a^{(1)} \in \mathbf{R}^n$ la première colonne de A et $e_1 \in \mathbf{R}^n$ le premier vecteur de la base canonique de \mathbf{R}^n . On pose $H^{(1)} := H(a^{(1)} - \|a^{(1)}\|e_1)$. Alors

$$H^{(1)}e^{(1)} = \|a^{(1)}\|e_1, \quad \text{et} \quad H^{(1)}A = \begin{pmatrix} \|a^{(1)}\| & \\ \vdots & * \\ 0 & \end{pmatrix},$$

où cette dernière matrice est du même rang que A . Supposons qu'à l'étape $k \in \{1, \dots, n\}$, on a

$$H^{(k-1)} \dots H^{(1)}A = \begin{pmatrix} T & & * \\ (0) & a^{(k)} & * \\ & | & \\ & | & \end{pmatrix},$$

où T est triangulaire supérieure et $a^{(k)} \in \mathbf{R}^{n-k+1}$ est non nul si $\text{rg } A > k$. On pose alors

$$H^{(k)} = \begin{pmatrix} I_{k-1} & & 0 \\ 0 & H(a^{(k)} - \|a^{(k)}\|(1, 0, \dots, 0)) & \end{pmatrix},$$

de sorte que

$$\begin{pmatrix} T & & * \\ & \|a^{(k+1)}\| & \\ (0) & \vdots & * \\ & 0 & \end{pmatrix}.$$

Remarque 3.4.8

- Si $n = p$ et A est inversible, on obtient $A = QR$ avec $R \in T_n^u(\mathbf{R})$ et $Q := H^{(1)} \dots H^{(n)} \in O_n(\mathbf{R})$. On a également $R \in \mathcal{GL}_n(\mathbf{R})$.
- Si $n > p$ et $\text{rg } A = p$, on obtient $A = QR$, avec $Q \in O_n(\mathbf{R})$ et $R \in \mathcal{M}_{n,p}(\mathbf{R})$. La matrice R peut être mise sous la forme

$$R = \begin{pmatrix} R_1 \\ 0_{n-p} \end{pmatrix},$$

avec $R_1 \in T_p^u(\mathbf{R}) \cap \mathcal{GL}_p(\mathbf{R})$, et la matrice Q peut se décomposer sous la forme $Q = (Q_1 \quad Q_2)$. De cette manière, on a $A = Q_1R_1$. De plus, pour tout $x \in \mathbf{R}^p$, on a

$$\|Ax - b\|^2 = \|QRx - b\|^2 = \|Rx - Q^*b\|^2 = \|R_1x - Q_1^*b\|^2 + \|Q_2^*b\|^2.$$

On trouve donc la solution au sens des moindres carrés qui est $x = R_1^{-1}Q_1^*b$, et le résidu est $\|Ax - b\| = \|Q_2^*b\|$.

- Si $n > p$ et $r := \text{rg } A < p$, on obtient $Q = QR$, où la matrice R se met sous la forme

$$R = \begin{pmatrix} R_1 & R_2 \\ 0 & 0 \end{pmatrix},$$

avec $R_1 \in T_r^u(\mathbf{R})$ et $R_2 \in \mathcal{M}_{n,p-r}(\mathbf{R})$. De plus, la matrice Q se met sous la forme $Q = (Q_1 \quad Q_2)$, avec $Q_1 \in \mathcal{M}_{n,r}(\mathbf{R})$. Alors pour tout $x = (x_1, x_2) \in \mathbf{R}^r \times \mathbf{R}^{p-r}$, on a

$$\|Rx - Q^*b\|^2 = \|R_1x_1 + R_2x_2 - Q_1^*b\|^2 = \|Q_2^*b\|^2.$$

Cette quantité est minimale pour $x_1 = R_1^{-1}Q_1^*b - R_1^{-1}R_2x_2$, i. e. pour

$$x = \begin{pmatrix} R_1^{-1}Q_1^*b \\ 0 \end{pmatrix} + \underbrace{\begin{pmatrix} -R_1^{-1}R_2x_2 \\ x_2 \end{pmatrix}}_{\in \text{Ker } A}, \quad \text{avec } x_2 \in \mathbf{R}^{p-r}.$$

Un défaut d'unicité apparaît par la présence du vecteur $x_2 \in \mathbf{R}^{p-r}$ en paramètre, qui est traité en choisant la solution de norme minimale.

4.5 Décomposition en valeurs singulières

Définition 3.4.9 (Valeurs singulières) Soit $A \in \mathcal{M}_{n,p}(\mathbf{C})$. Les valeurs singulières de A sont les réels positifs $\sigma_i := \sqrt{\lambda_i}$, où les λ_i sont les valeurs propres réelles non nulles de A^*A .

Remarque 3.4.10 Comme les matrices A et A^*A ont même noyau, elles ont le même rang, donc la matrice A^*A admet exactement $r := \text{rg } A$ valeurs singulières, comptées avec leurs multiplicités.

Théorème 3.4.11 Soit $A \in \mathcal{M}_{n,p}(\mathbf{C})$ de rang $r \leq \min(n,p)$. Alors A admet exactement r valeurs singulières comptées avec leurs multiplicités, et il existe $U \in U_n(\mathbf{C})$ et $V \in U_p(\mathbf{C})$ telles que $A = U\Sigma V^*$, avec

$$\Sigma := \text{diag}(\sigma_1, \dots, \sigma_r, 0) \in \mathcal{M}_{n,p}(\mathbf{R}),$$

où les réels σ_i sont les valeurs singulières de A .

Définition 3.4.12 (Pseudo-inverse) On appelle pseudo-inverse d'une matrice $A \in \mathcal{M}_{n,p}(\mathbf{C})$ la matrice

$$A^+ := V\Sigma^+U^*, \quad \text{avec } \Sigma^+ := \text{diag}(\sigma_1^{-1}, \dots, \sigma_r^{-1}, 0) \in \mathcal{M}_{p,n}(\mathbf{R}),$$

en reprenant les notations du théorème précédent.

Remarque 3.4.13 La pseudo-inverse ne dépend pas du choix de la décomposition en valeurs singulières.

Appliquons ceci à la méthode des moindres carrés. On écrit $A = U\Sigma V^*$ la décomposition en valeurs singulières de A . Soit $x \in \mathbf{C}^p$. Alors

$$\|Ax - b\| = \|U^*Ax - U^*b\| = \|\Sigma V^*x - U^*b\|.$$

On pose $c := U^*b \in \mathbf{C}^n$, et $y := V^*x \in \mathbf{C}^p$. Alors

$$\|\Sigma y - c\|^2 = \sum_{i=1}^r |\sigma_i y_i - c_i|^2 + \sum_{i=r+1}^n |c_i|^2,$$

et ce terme est minimal si $y_i = \sigma_i^{-1}c_i$ pour tout $i \in \{1, \dots, r\}$, i. e. $y = \Sigma^+c + y_0$, avec $y_0 := (0, \dots, 0, y_{r+1}, \dots, y_p) \in \mathbf{C}^p$. D'où $x = A^+b + Vy_0$. Parmi ces solutions, le vecteur x est de norme minimale si et seulement si le vecteur y l'est, avec

$$\|y\|^2 \leq \sum_{i=1}^r |\sigma_i^{-1}c_i|^2 + \sum_{i=1}^n |c_i|^2,$$

i. e. si et seulement si $x = A^+b$.

5 Méthodes variationnelles

5.1 Principe

5.2 Algorithme du gradient à pas fixe

5.3 Algorithme du gradient à pas optimal

On considère une suite $(x_j)_j$ de \mathbf{R}^n définie par

$$\forall j \in \mathbf{N}, \quad x_{j+1} = x_j - \alpha_j \nabla f(x_j), \quad \text{avec } \alpha_j := \underset{\alpha \in \mathbf{R}}{\text{argmin}} f(x_j - \alpha \nabla f(x_j)).$$

Petit calcul : Soit $A \in S_n^{++}(\mathbf{R})$. On va poser $A^{1/2} \in S_n^{++}(\mathbf{R})$ vérifiant $(A^{1/2})^2 = A$. Ainsi,

$$\forall y \in \mathbf{R}^n, \quad \|y\|_A^2 = \langle Ay, y \rangle = \langle A^{1/2}y, A^{1/2}y \rangle = \|A^{1/2}y\|_2^2,$$

donc

$$\forall y \in \mathbf{R}^n, \quad f(y) = \frac{1}{2}(\langle Ay, y \rangle - 2\langle Ax, y \rangle) = \frac{1}{2}(\langle A(y-x), y-x \rangle - \langle Ax, x \rangle) = \frac{1}{2}(\|y-x\|_A^2 - \|x\|_A^2),$$

où $Ax = b$.

Proposition 3.5.1 Pour tout espace affine \mathcal{E} de \mathbf{R}^n ,

$$\operatorname{argmin}_{\mathcal{E}} f = \operatorname{argmin}_{y \in \mathcal{E}} \|y - x\|_A^2$$

est le projeté A -orthogonal de x sur \mathcal{E} .

PREUVE. On a

$$\forall j \in \mathbf{N}, \quad \|x_{j+1} - x\|_A \leq \frac{k-1}{k+1} \|x_j - x\|_A,$$

avec $K := \operatorname{cond}_2 A$. Notons pour $j \in \mathbf{N}$, $e_j := x_h - x$. Alors

$$\|e_{j+1}\|_A = \min_{\alpha \in \mathbf{R}} \|x_j - \underbrace{\alpha(Ax_j - b)}_{:= e_{j+1}^{(R)}} - x\|_A \leq \|x_j - \alpha_R(Ax_j - b) - x\|_A,$$

où α_R est la constante optimale dans la méthode itérative de Richardson, $\alpha_R := 2/(\lambda_{\min} + \lambda_{\max})$. Et

$$\|e_{j+1}^{(R)}\|_A = \|A^{1/2}e_{j+1}^{(R)}\| = A^{1/2}RA^{-1/2}A^{1/2}e_j\|_2 \leq \underbrace{\|A^{1/2}RA^{-1/2}\|_2}_{\in \mathfrak{S}_n(\mathbf{R})} \|A^{1/2}e_j\|_2 = \underbrace{\rho(A^{1/2}RA^{-1/2})}_{=\rho(R)=\frac{K-1}{K+1}} \|e_j\|_A,$$

où $R := (I - \alpha_R A)$. □

5.4 Espaces de Krylov

Définition 3.5.2 (Espace de Krylov) Soient $r \in \mathbf{R}^n$, $j \in \mathbf{N}$ et $A \in \mathcal{M}_n(\mathbf{R})$. On appelle espace de Krylov de A associé à r et d'ordre j l'ensemble

$$K_j := \operatorname{Vect}(r, Ar, \dots, A^{j-1}r),$$

noté parfois $K_j(A, r)$. On pose par convention $K_0 := \{0\}$.

Proposition 3.5.3 Soient $r \in \mathbf{R}^n$, $A \in \mathcal{M}_n(\mathbf{R})$ et la suite $(K_j)_j$ vérifiant

$$K_0 \subset K_1 \subset \dots \subset K_l = K_{l+1} = \dots,$$

pour un certain $l \leq n$. On a donc

$$\dim K_j = \begin{cases} j & \text{pour } j \leq l \\ l & \text{pour } j > l. \end{cases}$$

Exercice 3.5.4 Considérer l'ensemble $\{j \in \mathbf{N} \mid (r, Ar, \dots, A^{j-1}r)\}$ est une famille libre}, et l son maximum.

Remarque 3.5.5

- $\forall j \in \mathbf{N}, \quad K_j(A, r) = \{P(A)r \mid P \in \mathbf{R}_{j-1}[X]\}$.
- Les méthodes GPF et GPO vérifient la propriété : en posant pour $j \in \mathbf{N}$, $r_j := b - Ax_j$, on a

$$\begin{cases} r_j \in K_{j+1}(A, r_0) \\ x_j \in x_0 + K_j(A, r_0) \end{cases}$$

Ceci se démontre par récurrence, le cas $j = 0$ étant vérifié. Pour l'hérédité, on utilise le fait que pour $j \in \mathbf{N}$,

$$x_{j+1} = \underbrace{x_j}_{\in x_0 + K_j} + \alpha_j \underbrace{r_j}_{\in K_{j+1}},$$

donc

$$r_{j+1} = \underbrace{r_j}_{\in K_{j+1}} - \alpha_j \underbrace{Ar_j}_{\in K_{j+2}} \in K_{j+2}(A, r_0).$$

Pourrait-on modifier les algorithmes précédents de sorte que $x_j = x + A^{-1}b$ pour j assez grand (typiquement, n), avec toujours $x_j \in x_0 + K_j(A, r_0)$, i. e. construire $P \in \mathbf{R}[X]$ tel que $x - x_0 \in P(A)r_0$?

Proposition 3.5.6 Soient $A \in \mathcal{GL}_n(\mathbf{R})$, $x_0 \in \mathbf{R}^n$ et $K_l(A, r_0)$ l'espace de Krylov maximal associé à $r_0 := b - Ax_0$. Alors $x = A^{-1}b \in x_0 + K_l(A, r_0)$, un sous-espace vectoriel affine de dimension $l \leq n$.

PREUVE. La famille liée $(r_0, Ar_0, \dots, A^l r_0)$ par définition de l'entier l . Alors il existe $\alpha_0, \dots, \alpha_{l-1} \in \mathbf{R}$ tels que

$$A^l r_0 = \alpha_0 r_0 + \dots + \alpha_{l-1} A^{l-1} r_0.$$

Pour montrer que $\alpha_0 \neq 0$, on procède par l'absurde. Si $\alpha_0 = 0$, alors

$$A(A^{l-1} r_0) = A(\alpha_1 r_0 + \dots + \alpha_{l-1} A^{l-2} r_0),$$

ce qui est impossible car $(r_0, \dots, A^{l-1} r_0)$ est libre. Ainsi,

$$x = \frac{1}{\alpha_0} (A^{l-1} r_0 - \alpha_1 r_0 - \dots - A^{l-2} r_0) + x_0 \in x_0 + K_l(A, r_0).$$

□

5.5 Algorithme du gradient conjugué

Soit $A \in S_n^{++}(\mathbf{R})$. On veut construire récursivement les projetés A -orthogonaux de $x = A^{-1}b$ sur les sous-espaces affines croissants $x_0 + K_j(A, r_0)$, pour $j \in \mathbf{N}$ à partir d'un choix $x_0 \in \mathbf{R}^n$, et ce sans connaître x . Par la proposition précédente, le $n^{\text{ème}}$ itéré (au plus tard) coïncide avec x . l'algorithme converge exactement en l étapes. Mais comment construire un telle suite $(x_j)_j$, de sorte que

$$x_j = \underset{x_0 + K_j(A, r_0)}{\operatorname{argmin}} f.$$

Pour obtenir x_{j+1} à partir de x_j , on va utiliser les directions A -orthogonales des espaces de Krylov.

Soient $x_0 \in \mathbf{R}^n$, $r_0 := b - Ax_0$, $p_0 := r_0$, la direction de descente. La famille (p_0) est une base A -orthogonale de $K_1(A, r_0)$. L'objectif est de construire (p_0, \dots, p_{l-1}) une base A -orthogonale de $K_l(A, r_0)$ en drapeau. Connaissant x_j , on cherche $x_{j+1} = x_j + \alpha_j p_j$, pour un α_j bien choisi. On sait que $x_j = p_{\mathcal{E}_j}(x)$, avec $\mathcal{E}_j := x + K_j(A, r_0)$. Alors

$$\forall i \leq j-1, \quad \langle x_{j+1} - x, p_i \rangle_A = \underbrace{\langle x_{j+1} - x_j, p_i \rangle_A}_{=0 \text{ car } \langle p_j, p_i \rangle_A = 0} + \underbrace{\langle x_j - x, p_i \rangle_A}_{=0 \text{ car } x_j = p_{\mathcal{E}_j}(x)} = 0.$$

Pour $i = j$,

$$\langle x_{j+1} - x, p_j \rangle_A = \alpha_j \|p_j\|_A^2 + \langle x_j - x, p_j \rangle_A = \alpha_j \|p_j\|_A^2 + \langle Ax_j - b, p_j \rangle_2.$$

Ainsi, on pose

$$\alpha_j := \frac{\langle r_j, p_j \rangle}{\|p_j\|_A^2},$$

avec $r_j := b - Ax_j$.

Comment trouver $(p_j)_j$? On utilise l'algorithme de Gram-Schmidt pour déduire p_j de (p_0, \dots, p_{j-1}) base de K_j et de r_j qui complète cette base en une base de K_{j+1} . Cette orthogonalisation est « courte » :

$$p_j = r_j - \sum_{i=0}^{j-1} \beta_i p_i, \quad \text{avec} \quad \beta_i = \frac{\langle r_j, p_i \rangle}{\|p_i\|_A^2}.$$

Pour $i \leq j-2$, $\langle r_j, p_i \rangle_A = \langle r_j, Ap_i \rangle_2$, avec $Ap_i \in K_{j-1}$. or $r_j = b - Ax_j \in K_j^{\perp A}$, donc $\langle r_j, p_i \rangle_A = 0$. Donc $p_j = r_j - \beta_{j-1} p_{j-1}$, avec

$$\beta_{j-1} = \frac{\langle r_j, p_{j-1} \rangle_A}{\|p_{j-1}\|_A^2} = -\frac{\|r_j\|^2}{\|r_{j-1}\|^2}.$$

Chapitre 4

Approximation spectrale

1 Motivation

Soit $A \in \mathcal{M}_n(\mathbf{K})$, $\mathbf{K} = \mathbf{R}$ ou \mathbf{C} . Comment trouver les éléments propres de A ? Ce problème pose plusieurs difficultés.

- Pour n grand, on n'a pas d'espoir de résoudre algébriquement.
- L'équation est non linéaire.
- Si on ne connaît A qu'approximativement, le résultat est-il suffisant?

2 Méthodes numériques

2.1 Méthode de la puissance

Soit $A \in \mathcal{M}_n(\mathbf{R})$, pour trouver la valeur propre $\lambda \in \mathbf{C}$ tel que $|\lambda| = \rho(A)$, on s'appuie sur l'observation vague $A^k x \simeq \lambda^k x$ pour k grand (c'est faux). Plus précisément, A^k est obtenue à partir des sous-espaces propres ou caractéristiques de A et des λ_i^k , $\lambda_i \in \sigma(A)$.

On considère l'algorithme suivant. Soit $x_0 \in \mathbf{C}^n$, on pose pour tout $k \in \mathbf{N}$,

$$x_{k+1} := \frac{Ax_k}{\|Ax_k\|_2}, \quad v_k := \langle x_k, Ax_k \rangle.$$

Théorème 4.2.1 Soit $A \in \mathcal{M}_n(\mathbf{C})$, de valeurs propres $\lambda_1, \dots, \lambda_d$, avec

$$|\lambda_1| > |\lambda_2| \geq |\lambda_3| \geq \dots \geq |\lambda_d|.$$

On dit que λ_1 est dominante. Soit $x_0 \notin \bigoplus_{i=2}^d \text{Ker}((A - \lambda_i I_n)^{m_i})$. On peut interpréter ceci en disant que x_0 possède une composante normale dans $\text{Ker}((A - \lambda_1 I_n)^{m_1})$ dans $\mathbf{C}^n = \bigoplus_{i=1}^d \text{Ker}((A - \lambda_i I_n)^{m_i})$.

Alors les suites $(x_k)_k$ et $(v_k)_k$ sont bien définies et on a

$$\lim_{k \rightarrow +\infty} v_k = \lambda_1,$$

et

$$\lim_{k \rightarrow +\infty} q_k = e \in \text{Ker}(A - \lambda_1 I_n),$$

où

$$q_k := \left(\frac{\bar{\lambda}_1}{|\lambda_1|} \right)^k x_k.$$

De plus, $(x_k)_k$ « converge » vers $\text{Ker}(A - \lambda_1 I_n)$.