

CADRE: $\mathbb{K} = \mathbb{R}$ ou \mathbb{C} .

I. Normes matricielles, rayon spectral, conditionnement

Def 1: Soit $\|\cdot\|$ une norme vectorielle sur \mathbb{K}^n et $A \in M_n(\mathbb{K})$, on définit la norme subordonnée de A comme $\|A\| = \sup_{x \in \mathbb{K}^n \setminus \{0\}} \frac{\|Ax\|}{\|x\|}$.

Prop 2: Pour $\|\cdot\|$ une norme subordonnée, on a :

- $\|I\| = 1$
- $\forall A, B \in M_n(\mathbb{K}) \quad \|AB\| \leq \|A\| \|B\|$
- $\forall A \in M_n(\mathbb{K}) \quad \|A\| = \sup_{\|x\|=1} \|Ax\| = \max_{\|x\|=1} \|Ax\|$

Ex 3: $\|A\|_1 = \sup_{1 \leq j \leq n} \left(\sum_{i=1}^n |a_{ij}| \right) \quad ; \quad \|A\|_\infty = \sup_{1 \leq i \leq n} \left(\sum_{j=1}^n |a_{ij}| \right)$.

C-ex 4: $\|A\|_{F^*} = \left(\sum_{1 \leq i, j \leq n} |a_{ij}|^2 \right)^{\frac{1}{2}}$ n'est pas une norme subordonnée.

Def 5: Soit $A \in M_n(\mathbb{C})$, le rayon spectral de A est le module de sa plus grande valeur propre, et est noté $\rho(A)$.

Ex 6: $\begin{pmatrix} 2 & -1 \\ 1 & 0 \end{pmatrix}$ a pour rayon spectral 1.

Def 7: Soit $\|\cdot\|$ un norme matricielle subordonnée, et $A \in GL_n(\mathbb{K})$.

Le conditionnement de A est défini par : $\text{cond}(A) = \|A\| \cdot \|A^{-1}\|$.

Ex 8: $\text{cond}_\infty \begin{pmatrix} 2 & -1 \\ 1 & 0 \end{pmatrix} = 9$, où cond_∞ est le conditionnement associé à $\|\cdot\|_\infty$.

Prop 9: Soit $A \in GL_n(\mathbb{K})$, $b, \delta b \in \mathbb{K}^n$. Soit x vérifiant $Ax = b$ et $x + \delta x$ vérifiant $A(x + \delta x) = b + \delta b$. Alors $\frac{\|\delta x\|}{\|x\|} \leq \text{cond}(A) \frac{\|\delta b\|}{\|b\|}$.

Prop 10: Soit $A \in M_n(\mathbb{K})$, on a :

- si $\lambda \neq 0$ $\text{cond}(\lambda A) = \text{cond}(A) = \text{cond}(A^{-1})$.
- $\text{cond}_2(A) = \sqrt{\frac{\mu_1}{\mu_n}}$ avec $\text{Sp}(A^* A) = \{\mu_1, \dots, \mu_n\}$ et $\mu_1 \geq \dots \geq \mu_n > 0$
- si $A^* A = AA^*$, $\text{cond}_2(A) = \frac{1/\lambda_1}{1/\lambda_n} = \rho(A) \rho(A^{-1})$ avec $\text{Sp}(A) = \{\lambda_1, \dots, \lambda_n\}$ et $|\lambda_1| \geq \dots \geq |\lambda_n|$.

• si $U \in M_n(\mathbb{K})$ vérifie $U^* U = I_n$, alors $\text{cond}_2(U) = 1$.

• pour tout $U \in M_n(\mathbb{K})$ tel que $U^* U = I_n$,

$\text{cond}_2(UA) = \text{cond}_2(UA) = \text{cond}_2(A)$.

(cond_2 désigne le conditionnement associé à la norme $\|\cdot\|_2$).

II. Résolution approchée de systèmes linéaires

On cherche à résoudre des systèmes d'équations linéaires du type $Ax = b$ où $A \in GL_n(\mathbb{K})$ et $b \in \mathbb{K}^n$.

1. Méthodes de splitting

Def 11: Soit $A \in GL_n(\mathbb{K})$. Une décomposition régulière, ou splitting, de A est un couple de matrices (M, N) avec $M \in GL_n(\mathbb{K})$ tel que $A = M - N$. Une méthode itérative basée sur cette décomposition est définie par : $\begin{cases} x_0 \in \mathbb{K}^n \\ \forall k \in \mathbb{N}^* \quad Mx_{k+1} = Nx_k + b \end{cases}$

Lemme 12: Soit $A \in M_n(\mathbb{K})$, $\rho(A) = \inf_{\substack{\text{II-II norme} \\ \text{subordonnée}}} \|A\|$.

Thm 13: La méthode itérative associée à la décomposition $A = M - N$ converge si et seulement si $\rho(M^{-1}N) < 1$.

Prop 14: Si A est hermitienne définie positive et $A = M - N$ une décomposition régulière de A . Alors $(M^* + N)$ est hermitienne. De plus, si $(M^* + N)$ est définie positive, alors $\rho(M^{-1}N) < 1$.

Def 15 (Jacobi): Soit $A \in GL_n(\mathbb{K})$. On note D la diagonale de A . La méthode de Jacobi est la méthode associée à la décomposition $M = D$, $N = D - A$. On note $J = M^{-1}N = I - D^{-1}A$.

Ex 16: Pour $A = \begin{pmatrix} 1 & 1 \\ -1 & 2 \end{pmatrix}$, on a $M = \begin{pmatrix} 1 & 0 \\ 0 & 2 \end{pmatrix}$ et $N = \begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix}$.

Prop 17: Si A est hermitienne, la méthode de Jacobi converge si A et $2D - A$ sont définies positives.

Def 18 (Gauss-Seidel): Soit $A \in GL_n(\mathbb{K})$. On décompose A sous la forme $A = D - E - F$ où D est la partie diagonale, $-E$ la partie inférieure et $-F$ la partie supérieure de A .

$$A = \begin{pmatrix} D & -F \\ -E & \end{pmatrix}$$

La méthode de Gauss-Seidel est la méthode associée à la décomposition $M = D - E$, $N = F$. On note $G_1 = M^{-1}N = (D - E)^{-1}F$.

Ex 19: Pour $A = \begin{pmatrix} 1 & 1 \\ -1 & 2 \end{pmatrix}$, on a $M = \begin{pmatrix} 1 & 0 \\ -1 & 2 \end{pmatrix}$ et $N = \begin{pmatrix} 0 & 1 \\ 0 & 0 \end{pmatrix}$.

Prop 20: Si A est hermitienne définie positive, alors $M^* + N = D$ est aussi hermitienne définie positive, et donc la méthode de Gauss-Seidel converge.

DEV

Def 21 (Relaxation): Soit $w \in \mathbb{R}^+$. La méthode de relaxation pour le paramètre w est la méthode associée à la décomposition

$$M = \frac{1}{w} D - E, \quad N = \frac{1-w}{w} D + F.$$

$$\text{On note } G_w = M^{-1}N = \left(\frac{1}{w}D - E\right)^{-1}\left(\frac{1-w}{w}D + F\right).$$

$$\text{Ex 22: Pour } A = \begin{pmatrix} 1 & 1 \\ 1 & 2 \end{pmatrix}, \text{ on a } M = \begin{pmatrix} \frac{1}{w} & 0 \\ -1 & \frac{2}{w} \end{pmatrix} \text{ et } N = \begin{pmatrix} \frac{1-w}{w} & -1 \\ 0 & 2\frac{1-w}{w} \end{pmatrix}$$

Rq. 23: Si $w=1$, on retrouve la méthode de Gauss-Seidel.

Prop 24: Si A est hermitienne définie positive, alors pour tout $w \in]0, 2[$, la méthode de relaxation converge.

Prop 25: Pour toute matrice $A \in M_n(\mathbb{K})$, on a $\forall w \neq 0 \quad \rho(G_w) \geq 1 - |w|$.

Ainsi, la méthode de relaxation ne converge que si $0 < w < 2$.

Rq 26: Pour que les méthodes de Jacobi, Gauss-Seidel et de relaxation soient bien définies, il faut que la matrice D soit inversible, i.e. que les coefficients diagonaux de A soient non nuls.

2. Comparaison des méthodes pour des matrices tridiagonales

Thm 27: Soit A une matrice tridiagonale. On a $\rho(G_1) = \rho(J)^2$.

- Les méthodes de Jacobi et Gauss-Seidel convergent ou divergent simultanément.
- En cas de convergence, la méthode de Gauss-Seidel converge plus vite que celle de Jacobi.

Thm 28: Si A est tridiagonale, hermitienne, définie positive, alors les trois méthodes convergent, et de plus, il existe un unique paramètre optimal $w_{opt} \in]0, 2[$ pour la méthode de relaxation :

$$w_{opt} = \frac{2}{1 + \sqrt{1 - \rho(J)^2}}.$$

Appli 29 (problème du Laplacien): On considère l'équation $\begin{cases} -u''(x) = f(x), \\ u(0) = u(1) = 0 \end{cases}$.

En divisant l'intervalle $[0, 1]$ en n intervalles de taille $\frac{1}{n}$, on se ramène à la résolution du système linéaire $A_n x = b$ avec $A_n = n^2 \begin{pmatrix} 2 & -1 & 0 & \cdots & 0 \\ -1 & 2 & -1 & \cdots & 0 \\ 0 & -1 & 2 & \cdots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \cdots & 2 \end{pmatrix}$ et $b = \begin{pmatrix} f(t_0) \\ f(t_1) \\ \vdots \\ f(t_{n-1}) \end{pmatrix}$

où $\{t_0, \dots, t_n\}$ est la subdivision de $[0, 1]$ en intervalles de taille $\frac{1}{n}$.

Prop 30: Pour le problème du Laplacien, en fixant un seuil d'erreur $\epsilon > 0$, le nombre d'itération pour descendre en-dessous de ce seuil est en $O(n^2)$ pour les méthodes de Jacobi et de Gauss-Seidel, et en $O(n)$ pour la méthode de relaxation avec le paramètre optimal.

3. Approche géométrique

Résoudre $Ax=b$ équivaut à chercher l'intersection de n hyperplans $(H_i)_{i \in \mathbb{N}}$ d'équation $(Au-b)_i = \sum_{j=1}^n a_{ij}u_j - b_i = 0$, pour $i \in \{1, \dots, n\}$.

Prop 31 (méthode de Karmarkar): Si $A \in GL_n(\mathbb{K})$, alors, partant d'un vecteur $x_0 \in \mathbb{R}^n$ et en le projetant successivement sur les hyperplans $H_i, i \in \{1, \dots, n\}$, la méthode converge vers la solution de $Ax=b$.

DEV 2

III. Optimisation

Soit $A \in M_n(\mathbb{R})$ une matrice symétrique et $b \in \mathbb{R}^n$. On considère le problème de minimisation de la fonction quadratique $J: \mathbb{R}^n \rightarrow \mathbb{R}$ définie par :

$$J(x) = \frac{1}{2} \langle Ax, x \rangle - \langle b, x \rangle = \frac{1}{2} \sum_{i,j=1}^n a_{ij}x_i x_j - \sum_{i=1}^n b_i x_i.$$

Prop 32: Le gradient de J en $x \in \mathbb{R}^n$ est $\nabla J(x) = Ax - b$.

Prop 33: Si, de plus, A est définie positive, alors J admet un unique minimum en x_0 qui est la solution de $Ax=b$. Et on a :

$x_0 \in \mathbb{R}^n$ est le minimum de J si et seulement si $\nabla J(x_0) = 0$.

Prop 34: Soit $x \in \mathbb{R}^n$ tel que $\nabla J(x) \neq 0$, alors $\forall \alpha \in]0, \frac{2}{\rho(A)}[$,

$$J(x - \alpha \nabla J(x)) < J(x).$$

Cor 35 (méthode du gradient): Pour minimiser J et résoudre $\nabla J(x) = Ax - b = 0$, on construit une suite de points $(x_k)_{k \in \mathbb{N}}$ tels que la suite $(f(x_k))_{k \in \mathbb{N}}$ soit décroissante en posant : $x_{k+1} = x_k - \alpha \nabla f(x_k) = x_k + \alpha (b - Ax_k)$ où $\alpha \in]0, \frac{2}{\rho(A)}[$.

IV. Recherche de valeurs propres et vecteurs propres

1. Calcul de la plus grande valeur propre

Soit $A \in M_n(\mathbb{R})$. $\text{Sp}(A) = \{\lambda_1, \dots, \lambda_n\}$ avec $|\lambda_1| \geq \dots \geq |\lambda_n|$.

Def 36 (méthode la puissance): Soit $\epsilon > 0$.

Initialisation: Choisir $x_0 \in \mathbb{R}^n$ tel que $\|x_0\|=1$.

Iterations: Pour $k \geq 1$ et $\|x_k - x_{k-1}\| \leq \epsilon$:

$$y_k = Ax_{k-1}$$

$$x_k = y_k / \|y_k\|$$

FinPour

Prop 37: En sortant de la boucle, x_k est un vecteur propre approché de A associé à la valeur propre approchée $\|y_k\| \approx |\lambda_1|$.

Rq 38: En pratique, cette méthode est limitée au calcul de la plus grande valeur propre de A , si cette valeur propre est simple et réelle.

Thm 39: Si la plus grande valeur propre de A (en module) est un réel positif et si elle est simple, alors l'algorithme termine.

Cex 40: Si $A = \begin{pmatrix} -1 & 0 \\ 0 & 0 \end{pmatrix}$ et $x_0 = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$, l'algorithme ne s'arrête pas.

2. Calcul des autres valeurs propres

Def 41 (méthode de la puissance inverse): Pour trouver la plus petite valeur propre (en module) et un vecteur propre correspondant, on adapte l'algorithme de la méthode de la puissance : Soit $\varepsilon > 0$.

Initialisation: Choisir $x_0 \in \mathbb{R}^n$ tel que $\|x_0\|=1$.

Iterations: Pour $k \geq 1$ et $\|x_k - x_{k-1}\| \leq \varepsilon$:

$$\text{résoudre } Ax_k = x_{k-1}$$

$$x_k = y_k / \|y_k\|$$

Fin Pour

Prop 42: En sortant de la boucle, x_k est un vecteur propre approché de A associé à la valeur propre approchée $\sqrt{\|y_k\|} \approx |\lambda_n|$.

Thm 43: Si A est inversible et diagonalisable, et si sa plus petite valeur propre (en valeur absolue) est simple et strictement positive, alors l'algorithme termine.

Rq 44: Connaisant λ_1 la plus grande valeur propre de A (en module), on peut trouver la suivante en appliquant la méthode de la puissance à $\tilde{A} = A - \lambda_1 I_n$.

3. Vitesse de convergence

Prop 45: Pour la méthode de la puissance, la vitesse de convergence est proportionnelle à $\frac{|\lambda_2|}{|\lambda_1|}$: si $x = \lim_{k \rightarrow \infty} x_k$,

$$\|x_k - x\| = O\left(\left(\frac{|\lambda_2|}{|\lambda_1|}\right)^k\right) \quad \text{et} \quad \|(y_k - \lambda_1)\| = O\left(\left(\frac{|\lambda_2|}{|\lambda_1|}\right)^k\right)$$

Pour la méthode de la puissance inverse, on a, de même :

$$\|x_k - x\| = O\left(\left(\frac{|\lambda_n|}{|\lambda_{n-1}|}\right)^k\right) \quad \text{et} \quad \|(y_k^{-1} - \lambda_n)\| = O\left(\left(\frac{|\lambda_n|}{|\lambda_{n-1}|}\right)^k\right)$$

Il existe des variantes de la méthode de la puissance afin d'obtenir des algorithmes qui convergent plus rapidement.

Prop 46 (méthode des traces): Soit $A \in \mathbb{C}^{n \times n}$ dont la plus grande valeur propre en module est simple. Alors $(\text{tr}(A^m))^{\frac{1}{m}} = \lambda_1 + O\left(\frac{1}{m}\left(\frac{|\lambda_2|}{|\lambda_1|}\right)^m\right)$.

$$\text{D'où } \lim_{m \rightarrow \infty} (\text{tr}(A^m))^{\frac{1}{m}} = \lambda_1.$$

Rq 47: Cette méthode ne permet pas de trouver un vecteur propre associé à la valeur propre λ_1 .

4. Une application : le web

Lorsque l'on recherche un document sur le web, on peut se retrouver confronté à un très grand nombre de pages.

Le moteur de recherche Google utilise un algorithme visant à classer ces pages par ordre de pertinence afin de faciliter les recherches.

Cet algorithme consiste à trouver un point fixe de l'application

$\mathbb{R}^n \xrightarrow{\quad P \quad} \mathbb{R}^n$, où P est une matrice stochastique construite en comptant le nombre de liens d'une page i vers une page j .

Cela revient à trouver un vecteur propre de P associé à la valeur propre 1. On peut le calculer avec la méthode de la puissance qui termine grâce au théorème de Perron-Frobenius qui assure que l'on se trouve dans le cadre du Théorème 3.9.

Thm 47 (Perron-Frobenius): Soit $A \in \mathbb{M}_n(\mathbb{R})$ à coefficients positifs.

Si A est irréductible, alors :

- A a une valeur propre égale à $\rho(A)$;
- $\rho(A)$ est une valeur propre simple;
- il existe un vecteur propre correspondant à $\rho(A)$ dont toutes les composantes sont strictement positives.

(Admis)

- Références:
- Algèbre linéaire numérique, G. Allaire, S.M. Kaber
 - Méthodes numériques itératives, C. Brezinski, M. Redivo-Zaglia