

1/4

m
n

Analyse numérique matricielle: résolution approchée de systèmes linéaires, recherche de vecteurs propres, exemples.

Dans toute la lesson, $\kappa = 10^6$ cm/s.

on étudie deux classes de problèmes

- Résolution de $Ax = b$, $b \in \mathbb{K}^m$, $A \in \mathbb{K}^{m \times n}$
- recherche d'éléments propres de A .

I - Rayon spectral, conditionnement

1. Normes matricielles

Def 1 Soit $\|\cdot\|$ une norme sur \mathbb{K}^m , on définit dans une même manière, notée de la même façon, sur $M_{n \times n}(\mathbb{K})$, par $\|A\| = \sup \frac{\|Ax\|}{\|x\|}$

Def 2 Transposition de A est sup $\|A^T\|$ ($\|A^T\| = \|A\|$)

$$\|Ab\| \leq \|A\| \|b\| \quad (1)$$

$$\text{Ex 3} \quad \|Af\|_2 = \sqrt{\rho(A^TA)}$$

$$\|Af\|_2 = \sup \sum_i |f_i| a_{ii}$$

Def 3 On déconditionnement pour $\|A\|_{\text{cond}}(A) = \|A\| \|A^{-1}\|$

Ex 4 Si A est normale, alors $\text{cond}_2(A) = \max_i |\lambda_i|$ où $\text{sp}(A) = \{\lambda_i\}_{i=1}^n$

Résp 3 $\text{cond}(A) \geq \kappa(\text{valeur}_n/A)$

Où $\kappa = \frac{\text{valeur}_1}{\text{valeur}_n} = \frac{\text{cond}_2(A)}{\text{cond}_1(A)}$

$$\text{Prop 3} \quad \text{Si } A = b \text{ et } A(x + \delta x) = b + \delta b \text{ alors } \frac{\|\delta x\|}{\|\delta b\|} \leq \text{cond}(A) \frac{\|b\|}{\|\delta b\|}$$

$$\begin{aligned} \text{Prop 4} \quad & \text{Si } Ax = b \text{ et } (A + \Delta A)x = b \\ & \text{alors } \frac{\|b - Ax\|}{\|\Delta A\|} \leq \text{cond}(A) \frac{\|b - Ax\|}{\|A + \Delta A\|} \end{aligned}$$

Prop 5 Si $\|A\| = 1$, $\|Ax\| = 1$ alors $\frac{\|x\|}{\|A\|} \leq \text{cond}(A) \frac{\|x\|}{\|A\|}$

Exemple 1 : Si on a un système $Ax = b$ et si A est normale, alors $\|x\| \leq \text{cond}(A) \|b\|$

2. Localisation des valeurs propres

Motivation

Exemple 2 : on a un opérateur T sur $L^2(\mathbb{C}, \mathbb{T})$ ($H^2(\mathbb{C}, \mathbb{T}) \cap H^1(\mathbb{C}, \mathbb{T})$) dans $L^2(\mathbb{C}, \mathbb{T})$ qui possède une base orthonormée $\{e_k\}_{k=1}^\infty$ par ses vecteurs propres. T est inversible et on a une chose. Des valeurs et vecteurs propres et ceci est possible en étudiant le problème discrétisé.

Prop 4 Si $A = b$ et $A(x + \delta x) = b + \delta b$ alors $\frac{\|\delta x\|}{\|\delta b\|} \leq \text{cond}(A) \frac{\|b\|}{\|\delta b\|}$

Prop 4 3 Soit A une matrice diagonale et telle que $PAP^{-1} = \text{diag}(\lambda_k)$

et $\| \cdot \|$ une norme subordonnée relée

que $\| \text{diag}(\mathbf{d}_i) \| = \max_i |d_i|^{1/\alpha_i}$

$$\text{Sp}(A - \delta A) \subset \bigcap_{i=1}^n \overline{D(\lambda_i, \text{cond}(S))}$$

Def 14 $A \in M_n(\mathbb{K})$ est dite à diagonale

strictement dominante si $\forall i, |\lambda_{ii}| > \sum_{j \neq i} |\lambda_{ij}|$

Théorème 15 (Gauss-Suin) Si A est à diagonale

strictement dominante, $\text{Sp}(A) \subset \bigcap_{i=1}^n \overline{D(\lambda_i, \sum_{j \neq i} |\lambda_{ij}|)}$

III - Méthodes itératives pour Aoc = L

1. Inconvénients de méthode directe

Il existe des méthodes directes de résolution, elles sont cependant, quelle que soit (Picard, Gauß, Factorisations LU ou Choleski), des inconvénients : → des divergences : $D(m, n)$ opérateur → peu stables : risques de division par de petits nombres

2. Étude théorique On écrit $A = M - N$ avec

M inversible, alors $A = b \Leftrightarrow x = M^{-1}(Nx + b)$, problème de point fixe que l'on résoud par itération grâce au théorème de Picard.

Théorème 16 (Hausdorff)

$$P(A) = \inf_{\| \mathbf{f} \|} \| \mathbf{f} \|$$

si \mathbf{f} norme subordonnée

Théorème 17 La méthode itérative associée

à $A = M - N$ converge si : $\rho(M^{-1}N) < 1$

Rémi 20 Dans l'algorithme on a $\| x^{(m+1)} - x^{(m)} \|$

Rémi 21 Le taux de convergence d'une méthode itérative est $\gamma = -\log(\rho(M^{-1}N))$.

La première converge deux fois plus vite.

Notation 20 On écrit $\mathbf{M} = \begin{pmatrix} D & -F \\ -E & M \end{pmatrix} = D - E + F$

de plus on suppose D inversible

3 - Méthode de Jacobi $M = P \quad N = E + F$

$$\text{alors } x_{i, (m+1)} = (a_{ii})^{-1} (b_{ii} - \sum_{j \neq i} a_{ij} x_j^{(m)})$$

Théorème 21 Si A est à diagonale forte-

-ment dominante - alors $\rho(\mathbf{J}) = M^{-1}N < 1$

4 - Méthode de relaxation on fixe w

$$\text{ex } M = \frac{\omega}{\omega - 1} D - E, N = \left(\frac{1-\omega}{\omega} \right) D + F, \text{ on a alors}$$

$$x_{i, (m+1)} = \frac{\omega}{\omega - 1} \left[b_{ii} - \sum_{j \neq i} a_{ij} x_j^{(m+1)} - \sum_{j \neq i} a_{ij} x_j^{(m)} + \left(\frac{1-\omega}{\omega} \right) a_{ii} x_i^{(m)} \right]$$

Rémi 22 on ne calcule pas M^{-1}

Théorème 23 - Si A est à diagonale partiellement dominante alors $\rho(\mathbf{J}) = M^{-1}N < 1$ pour tout w

- si $A \in \text{HDF}_{\mathbb{R}}$, $D(\lambda_i)$ est nul si $\lambda_i = 1$

Rémi 24 Pour $w = 1$ on parle de méthode de Gauss-Seidel.

5. Etude du cas tridiagonal

Rémi 25 En EDP, les matrices sont souvent tridiagonales

Théorème 26 Soit $C = C_0 + C_- + C_+$ une matrice tridiagonale, alors $\det C = \det(C_0 + \frac{1}{\lambda} C_- + \mu C_+)$

preuve : on conjugue par $\begin{pmatrix} 1 & 0 & \dots \\ 0 & \lambda & \dots \\ \vdots & \vdots & \ddots \end{pmatrix}$

2.7 Etape tridiagonale avec

$$\text{f}(x_2) = (f(u))^n \chi_{\tilde{\delta}} \left(\frac{u^2 + w - 1}{w} \right)$$

en 2.8 $\rho(\tilde{\delta}) = \rho(\tilde{\delta}, \tilde{\tau})^2$ dans la méthode de jacobi converge sur celle de Gauss Seidel et 2 fois plus rapide que celle de Gauss Seidel et 2 fois plus rapide alors (pour u réel) : $\rho(f_w) < 1$ si $w > 1/2$

De plus le taux de convergence est maximal pour $w = \frac{1}{1 + (\sqrt{1 - \rho(\tilde{\delta}, \tilde{\tau})^2})^2}$ et alors $\rho(f_w) = w^2 - 1 = \frac{1 - \sqrt{1 - \rho(\tilde{\delta}, \tilde{\tau})^2}}{1 + \sqrt{1 + \rho(\tilde{\delta}, \tilde{\tau})^2}}$

Ex 3.0 Pour $n = 10$, $\lambda = \begin{pmatrix} 2 & -1 \\ -1 & 2 \end{pmatrix}$, $\rho(\tilde{\delta}, \tilde{\tau}) \approx 0,95$

donc $w = 4,5625$

6. Lien avec l'optimisation : gradient consigne

Prop 3.1 Si $A \in \mathbb{R}^{m,n}$, $\|A\|_F = \sqrt{\lambda_1 + \dots + \lambda_n}$ sur \mathbb{R}^m

Algorithm 3.2 On fixe $x_0 \in \mathbb{R}^m$

$$r_0 = b - Ax_0, \quad p_0 = r_0$$

• par récurrence tant que $r_k \neq 0$

$$d_k = \|r_k\|^2, \quad x_{k+1} = x_k + \alpha_k p_k,$$

$\alpha_k = \frac{r_k^T p_k}{p_k^T p_k}$

$$r_{k+1} = r_k - d_k A p_k, \quad p_{k+1} = \frac{1}{\|M\|_F} p_k$$

$$p_{k+1} = r_{k+1} + \beta_k p_k$$

Théorème 3.2 La méthode du gradient converge en une itération

remarque : on utilise comme méthode itérative

IV - Recherche d'éléments propres

1. Méthode QR

Prop 3.3 Soit $M \in \mathbb{C}^{n,n}$, unitaire, tri-diagonale avec diagonale strictement positive telle que $M = Q R$ (algorithme en annexe) et la factorisation se fait en 3 opérations

Théorème 3.4 On pose $A = P$, on décompose $P M = Q M P$ et on pose P par récurrence $P_m = P_{m-1} Q_m$ avec $P_0 = I$.

Si A est invariante et ses valeurs propres sont de modules différents ie $\rho(A) = 1$ avec $|A|_1 > \dots > |A|_n > 0$ alors $\rho(A) = \sqrt{\lambda_1}$ avec $\lambda_1 = \lambda_{\max}(A)$

Théorème 3.5 Si A est de Hessenberg, le théorème du théorème 3.4 reste valable carée et unitairement semblable à une matrice de Hessenberg.

Théorème 3.6 Si A est de Hessenberg, les hypothèses du théorème 3.5 sont vérifiées.

2. Méthode de la puissance

Algorithme 4.1 On fixe $x_0 \in \mathbb{C}^m$ et par récurrence on construit $x^{(m)} = M x^{(m-1)} / \|M x^{(m-1)}\|$

Théorème 4.2 Si A a une seule valeur propre λ le module $\rho(A)$ est si x_0 n'appartient pas à l'ensemble de de Ker($A - \lambda$) alors $\|M x^{(k)}\| \rightarrow \rho(A)$ et converge vers λ lorsque $k \rightarrow \infty$

• On en déduit à

Théorème 4.3 Si A est diagonalisable et si $\rho(A)$ est la valeur propre de A plus grande alors la convergence vers l'unique de $(\rho(A), \lambda)$ alors. La convergence est de $O(1/k)$

Applique la méthode de la puissance initialement de chaîne de Markov.

Decomposition QR

- Méthode de Householder

des dons A_n
 $R = A_n$ est triangulaire supérieure

$$Q = (H_{n-1} \cdots H_2)^{-1} = H_2 \cdots H_{n-1}$$

est orthogonale

$$A = \begin{pmatrix} \alpha_1 & & & \\ & R_2 & & \\ \alpha_2 & & \alpha_3 & \\ & & & \ddots \\ & & & \alpha_n \end{pmatrix} *$$

$$\begin{pmatrix} \alpha_1 & & & \\ & R_2 & & \\ \alpha_2 & & \alpha_3 & \\ & & & \ddots \\ & & & \alpha_n \end{pmatrix} = \begin{pmatrix} \alpha_1 & & & \\ & \alpha_2 & & \\ & & \alpha_3 & \\ & & & \ddots \\ & & & \alpha_n \end{pmatrix} \begin{pmatrix} 1 & & & \\ & 0 & & \\ & & 1 & \\ & & & \ddots \\ & & & 0 \end{pmatrix}$$

$$\text{on pose } H_1 = I_m - 2 \frac{VV^*}{V^*V}$$

$$\alpha_1 = \alpha_1 + \lambda \operatorname{sign}(\alpha_1) \| \alpha_1 \|_2 e_1$$

$$\text{et on pose } \begin{cases} H_2 = A \\ H_2 = H_1 A \end{cases}$$

et même faire de procéder en parallèle

$$\text{on pose } H_n = \begin{pmatrix} I_{m-2} & 0 \\ 0 & I_{m-2} - 2 \frac{VV^*}{V^*V} \end{pmatrix}$$

$$\text{avec } V = \alpha_2 + \lambda \operatorname{sign}(\alpha_2) \| \alpha_2 \|_2 e_2$$

$$\text{Alors finalement } A_n = H_{n-1} \cdots H_2 A$$

Soit de plus trouver un équation pour le

$\inf_{\Sigma \in \mathcal{S}(G, T)} \sum d(x, \Sigma)$ lorsque Σ tend vers

$$P'$$

$$T_0 \Sigma$$

$$P' \Sigma = P$$