

Analyse numérique: résolution approchée de systèmes linéaires. Recherche de vecteurs propres. Applications

I Outils matriciels

Def 1: Soit $\| \cdot \|$ une norme sur $\mathcal{M}_n(\mathbb{K})$. On dit que c'est une norme matricielle si elle vérifie
 $\forall A, B \in \mathcal{M}_n(\mathbb{K}) \quad \|AB\| \leq \|A\| \|B\|$

Ex 2: la norme de Frobenius $\|A\|_F = \sqrt{\sum_{i,j} (a_{ij})^2}$
 est une norme matricielle.

Contre exemple 3: $\|A\| = \max_{1 \leq i, j \leq n} |a_{ij}|$ n'est pas matricielle.

Def 4: Soit $\| \cdot \|$ une norme sur \mathbb{K}^n . On lui associe une norme subordonnée définie par

$$\|A\| = \sup_{x \neq 0, x \in \mathbb{K}^n} \frac{\|Ax\|}{\|x\|}$$

Prop 5: Une norme subordonnée est une norme matricielle

Prop 6: Il existe des normes matricielles non subordonnées comme $\| \cdot \|_F$.

Def 7: Soit A une matrice dans $\mathcal{M}_n(\mathbb{C})$. On appelle rayon spectral de A (noté $\rho(A)$), le maximum des modules des valeurs propres de A .

Prop 8: On a $\rho(A) = \lim_{k \rightarrow +\infty} (\|A^k\|)^{1/k}$ pour $\| \cdot \|$ une norme matricielle.

Def 9: Pour une norme matricielle subordonnée $\| \cdot \|$, on appelle conditionnement de $A \in \mathcal{M}_n(\mathbb{C})$, la valeur

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

Prop 10: Soit $A \in \mathcal{M}_n(\mathbb{C})$
 (i) $\text{cond}(A) = \text{cond}(A^{-1}) = \text{cond}(\alpha A) \quad \forall \alpha \neq 0$
 (ii) $\text{cond}_2(A) = \rho(A) \rho(A^{-1}) = \frac{\lambda_{\max}(A)}{\lambda_{\min}(A)}$

II Systèmes linéaires

On veut résoudre $Ax = b$ $A \in \mathcal{M}_n(\mathbb{K})$
 $b \in \mathbb{K}^n$

1) Méthode directe

* Pivot de Gauss

Thm 11: Pour A matrice carrée, il existe au moins une matrice inversible T telle que $T = MA$ soit triangulaire supérieure.

Prop 12: On peut trouver T en appliquant des dilatations et des transvections aux lignes de A .

Pour résoudre $Ax = b$ il suffit ensuite de résoudre les égalités car $Tx = Mb$ $(\nabla)(x) = (|)$

* Méthode LU

Thm 13: Soit $A \in \mathcal{M}_n(\mathbb{K})$ dont toutes les sous matrices diagonales d'ordre k soient inversibles. Il existe un unique couple de matrices (L, U) avec U triangulaire supérieure et L triangulaire inférieure tel que $A = LU$

Prop 14: on doit résoudre $LUx = b$ on trouve déjà y tel que $Ly = b$ puis on résout $Ux = y$ pour avoir x

* Méthode QR

Thm 15: Soit A réelle inversible. Il existe un unique couple (Q, R) où Q est une matrice orthogonale et R une matrice triangulaire supérieure dont tous les éléments diagonaux sont positifs tel que $A = QR$

Prop 16: on doit résoudre $QRx = b$ or $Q^{-1} = Q^T$ d'où $Rx = Q^T b$ et R triangulaire donc comme pour le pivot on résout les égalités.

TR

2) Problème des moindres carrés

On veut trouver une solution x la plus fidèle possible à un problème $Ax = b$ qui n'a pas de solution.

Problème de minimisation: (voir Annexe 1)

$$(*) \quad \|b - Ax\|_n = \min_{y \in \mathbb{R}^p} \|b - Ay\|_n \text{ pour } A \in \mathcal{D}_{n,p}(\mathbb{R})$$

Prop 17: Il existe une solution $x \in \mathbb{R}^p$ du problème (*)

$$\text{ssi } x \text{ satisfait } A^*Ax = A^*b$$

Thm 18: Pour tout $A \in \mathcal{D}_{n,p}(\mathbb{R})$, il existe toujours au moins une solution à $A^*Ax = A^*b$

De plus, elle est unique ssi $\text{Ker } A = \{0\}$ et $x = (A^*A)^{-1}A^*b$.

3) Méthodes itératives

Def 20: Soit A inversible, on appelle décomposition régulière de A un couple de matrices (M, N) avec M inversible tel que $A = M - N$

L'idée générale est de construire la suite
$$Mx^{(k+1)} = Nx^{(k)} + b \quad \forall k \text{ avec } x_0 \in \mathbb{R}^n \quad (**)$$

donc il faut (dans la pratique) que M soit beaucoup plus facile à inverser que A .

Par passage à la limite on a $(M - N)x = b$.

Def 21: On dit qu'une méthode itérative converge si $\forall x_0 \in \mathbb{R}^n$, la suite (x_n) converge vers la solution exacte x .

Thm 22: La méthode (**) converge ssi $\rho(M^{-1}N) < 1$.

* Méthode de Jacobi

On associe $M = D$ diagonale de A
et $N = D - A$

Avantage: M^{-1} est facile à calculer

Inconvénient: pour calculer $x^{(k+1)}$, il faut toutes les composantes de $x^{(k)}$

* Méthode de Gauss-Seidel

On associe $M = D - E$ ou $-E$ est la partie inférieure de A triangulaire
et $N = F$ la partie triangulaire supérieure de A

Avantage: $x^{(k+1)}$ se calcule sans utiliser toutes les composantes de $x^{(k)}$ à chaque pas

Inconvénient: T^{-1} moins facile à calculer (mais quand même triangulaire)

* Méthode de relaxation

Soit $\omega \in \mathbb{R}^+$ on associe $M = \frac{D}{\omega} - E$
$$N = \frac{1-\omega}{\omega}D + F$$

Remarque 23: pour $\omega = 1$ on retrouve Gauss-Seidel

Thm 24: Soit A une matrice hermitienne définie positive
Alors $\forall \omega \in]0; 2[$, la méthode de relaxation converge

Thm 25: Pour tout A , la méthode de relaxation ne converge que si $\omega \in]0; 2[$.

III Recherche de valeurs propres

Méthode la puissance

Thm 26: Soit A diagonalisable de valeurs propres réelles
 $(\lambda_1 - \lambda_n) / |\lambda_1| \leq |\lambda_2| \leq \dots \leq |\lambda_{n-1}| < \lambda_n$

Alors pour tout $x_0 \in \mathbb{R}^n / \|x_0\| = 1$, l'algorithme suivant

$$\left\{ \begin{array}{l} \text{Pour } k > 1 \text{ et } \|x_k - x_{k-1}\| \leq \varepsilon \\ y_k = Ax_{k-1} \\ x_k = y_k / \|y_k\| \\ a = \|y_k\| \end{array} \right.$$

Entrée: A
Sortie: $a \approx \lambda_n$
 $x_k \approx e_n$

converge, et ainsi $\lim_{k \rightarrow +\infty} \|y_k\| = \lambda_n$ et $\lim x_k = x_{\infty}$

ou $x_{\infty} = \pm e_n$ vecteur propre associé à λ_n .

Rem 27: On peut adapter l'algorithme pour trouver la valeur propre de plus petit module en considérant A^{-1}
On appelle cela la méthode de la puissance inverse.

IV) Analyse fonctionnelle

1) Optimisation d'une fonctionnelle

* Méthode du gradient à pas optimal
On veut trouver un minimum d'une fonctionnelle J sur \mathbb{R}^n
on veut donc résoudre

$$\left\{ \begin{array}{l} J(u_k) - \rho(u_k) \nabla J(u_k) = \inf_{\rho \in \mathbb{R}} J(u_k - \rho \nabla J(u_k)) \\ u_{k+1} = u_k - \rho(u_k) \nabla J(u_k) \end{array} \right.$$

Thm 28.5: J est elliptique, i.e. $\exists \alpha > 0 \langle \nabla J(u) - \nabla J(v), u - v \rangle \geq \alpha \|u - v\|^2 \forall u, v \in \mathbb{R}^n$
Alors la méthode du gradient à pas optimal converge

Rem 29: Toutes les méthodes de type gradient
i.e. $u_{k+1} = u_k - \rho_k \nabla J(u_k)$

veulent résoudre: trouver $u \in \mathbb{R}^n$ tel que $J(u) = \inf_{v \in \mathbb{R}^n} J(v)$

2) Résolution approchée d'équations différentielles.

On veut approcher la solution de l'équation différentielle

$$\begin{cases} y' = f(t, y) \text{ sur } I \text{ borné} \\ y(t_0) = y_0 \end{cases} \quad (**)$$

* Schema d'Euler explicite

Soit $t_0 < t_1 < \dots < t_m$ une subdivision de I

$$\text{on pose la suite } \begin{cases} \tilde{y}_0 = y_0 \\ \tilde{y}_{n+1} = \tilde{y}_n + (t_{n+1} - t_n) f(t_n, \tilde{y}_n) \end{cases}$$

Thm 30: Soit y la solution de (***) telle que $y \in C^2(I)$

Supposons qu'il existe $\varepsilon > 0, L \in \mathbb{R}$ tels que

$$\forall t \in I, \forall \tilde{y} \in \mathbb{R}^m \text{ avec } |\tilde{y} - y(t)| \leq \varepsilon, |f(t, \tilde{y}) - f(t, y(t))| \leq L |\tilde{y} - y(t)|$$


Alors il existe $h^* > 0$ tel que $\forall 0 < h \leq h^*$ et $\forall n \in \{0, \dots, m\}$
on ait $|y(t_n) - \tilde{y}_n| \leq h \int_{t_0}^{t_n} e^{L(t_n-s)} |y''(s)| ds$.

* Schema d'Euler implicite


La suite que l'on pose est:

$$\begin{cases} \tilde{y}_0 = y_0 \\ \tilde{y}_{n+1} = \tilde{y}_n + (t_{n+1} - t_n) f(t_{n+1}, \tilde{y}_{n+1}) \end{cases}$$

Rem 31: plus difficile à calculer en pratique
mais une meilleure majoration de l'erreur.



Annexe 1 : moindres carrés



Annexe 2 : Euler explicite