

Séance 11 : méthodes itératives de résolution de systèmes linéaires

On revient au problème de la résolution du système linéaire cramérien

$$Ax = b \quad (A \in GL_n(\mathbb{R}), b \in \mathbb{R}^n)$$

mais avec une autre approche consistant à construire une suite d'approximations $(x_k) \in (\mathbb{R}^n)^{\mathbb{N}}$. Cette construction est itérative :

$$\begin{cases} x_0 \in \mathbb{R}^n \text{ quelconque} \\ x_{k+1} = f(x_k) \quad 0 \leq k \end{cases}$$

et telle que $\lim_{k \rightarrow +\infty} x_k = x^*$ solution de $Ax = b$.

1) Principe général de construction

On décompose A de la manière suivante :

$$A = M - N$$

avec $M, N \in \mathcal{M}_n(\mathbb{R})$ telles que

- ci) M inversible
- cii) M facile à inverser : diagonale, triangulaire, orthogonale, ...

On prend alors la suite

$$x_{k+1} = M^{-1}(Nx_k + b)$$

Dans ce cas, si $x_k \rightarrow \tilde{x}$, alors
 $\tilde{x} = M^{-1}(N\tilde{x} + b)$ soit
 $A\tilde{x} = b$ et $\tilde{x} = x^*$.

On a le résultat général suivant :

Théorème : la méthode itérative
définie par la relation

$$\begin{cases} x_0 \in \mathbb{R}^n \\ x_{k+1} = M^{-1}(Nx_k + b) \end{cases}$$

converge (c'est à dire (x_k) tend vers
 x^* pour tout $x_0 \in \mathbb{R}^n$) si et seulement
si $\rho(M^{-1}N) < 1$

preuve : on suppose que $\rho(M^{-1}N) < 1$. Avec le résultat de
la séance précédente, il existe $\| \cdot \|$
telle que $\| M^{-1}N \| < 1$. Pour cette
norme, en utilisant la norme $\| \cdot \|$
associée sur $\mathbb{R}^n$, on a

$$x_{k+1} - x^* = M^{-1}(N(x_k - x^*))$$

$$\Rightarrow \|x_{k+1} - x^*\| \leq \|M^{-1}N\|^{-1} \|x_k - x^*\|$$

et $\|x_k - x^*\| \rightarrow 0$ car $\|M^{-1}N\| < 1$

* on suppose que $\rho(M^{-1}N) \geq 1$
dans ce cas, il existe $u_0 \in \mathbb{C}^n$ tel

que $M^T N u_0 = \mathcal{C}(M^T N) u_0$

En particulier

$$\| (M^T N)^k u_0 \| \not\rightarrow 0$$

En prenant

$$x_0 = x^* + \text{Re}(u_0) \text{ ou}$$

$$x_0 = x^* + \text{Im}(u_0)$$

L'une des deux conditions initiales sera telle que

$$\| (M^T N)^k (x_k - x^*) \| \not\rightarrow 0$$

Si la matrice A est symétrique définie positive, on a une

condition suffisante plus simple : 3

Théorème : soit $A \gg 0$.

Par la méthode itérative associée à la décomposition (M, N) , on a

${}^t M + N \in \mathcal{S}_n(\mathbb{R})$ et de plus, la méthode est convergente si ${}^t M + N$ est définie positive.

preuve : ${}^t A = A \Rightarrow$

$${}^t(M - N) = M - N \text{ soit}$$

$${}^t M + N = M + {}^t N = {}^t({}^t M + N).$$

et si de plus ${}^t M + N \gg 0$, on montre que la méthode est convergente

construisant la norme subordonnée associée à la norme euclidienne:

$$\|x\|_A = \sqrt{x, Ax}.$$

On montre que $\|M^{-1}N\|_A < 1$,
et donc que la méthode est convergente.

(voir détails dans poly de cours ou références usuelles).

2) Méthodes de Jacobi et Gauss Seidel

2.1) Méthode de Jacobi

On choisit ici

$$M = D \text{ où } D = \begin{pmatrix} a_{11} & & & \\ & \ddots & & \\ & & \ddots & \\ 0 & & & a_{nn} \end{pmatrix}$$

$$\text{et } N = M - A$$

Cette méthode n'est définie que si
 $\forall i \in \{1, \dots, n\}, a_{ii} \neq 0$.

Dans ce cas, une itération s'écrit:

$$x_{k+1} = M^{-1}(Nx_k + b)$$

soit

$$x_{k+1}^i = \frac{1}{a_{ii}} \left(-a_{i,1} x_k^1 - \dots - a_{i,i-1} x_k^{i-1} - a_{i,i+1} x_k^{i+1} - \dots - a_{i,n} x_k^n + b_i \right) \quad (1 \leq i \leq n)$$

On note :

$$J = D^{-1}(D - A)$$

* Cette méthode converge ssi $\rho(J) < 1$

* Lorsque $A \gg 0$, la méthode est bien définie

$$M + N = 2D - A$$

Si $2D - A \gg 0$, cette méthode converge.

(voir Exercice, TD 7).

2.2. Méthode de Gauss Seidel

On écrit

partie
supérieure
strictement

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

On choisit ici :

$$M = \begin{pmatrix} a_{11} & & 0 \\ & \ddots & \\ 0 & & a_{nn} \end{pmatrix} = D - E$$

$$\text{et } N = M - A = F$$

$$(A = M - N = D - E - F)$$

Cette méthode n'est définie que si

$$\forall i \in \{1, \dots, n\}, a_{ii} \neq 0.$$

Dans ce cas, une itération s'écrit :

$$x_{k+1} = M^{-1}(Nx_k + b) \text{ soit :}$$

$$x_{k+1}^i = \frac{1}{a_{ii}} \left(-a_{i,1} x_{k+1}^1 - \dots - a_{i,i-1} x_{k+1}^{i-1} - a_{i,i+1} x_k^{i+1} - \dots - a_{i,n} x_k^n + b_i \right) \quad (1 \leq i \leq n)$$

On note $L_1 = (D - E)^{-1} F$

La méthode de Gauss Seidel converge
ssi $\rho(L_1) < 1$.

* Lorsque $A \gg 0$, la méthode est
bien définie et

$$M + N = (D - E) + F = D - E + F$$

or, $E = F$ et ainsi $M + N = D$

la méthode est toujours convergente $\gg 0$

2.3) Comparaison des 2 méthodes

Dans le cas général, il n'existe pas
de comparaison (voir TD 7).

Il existe des comparaisons dans
certains cas particuliers :

Proposition : soit A tridiagonale
telle que $a_{ii} \neq 0 \forall i \in \{1, \dots, n\}$.

Alors $\rho(L_1) = \rho(J)^2$

En particulier, les 2 méthodes
convergent simultanément. La méthode
de Gauss Seidel converge toujours
rapidement (car $\rho(L_1) < \rho(J) < 1$)

preuve : voir poly. On montre en

particulier que $\chi_{L_1}(\lambda^2) = (\lambda^n) \chi_J(\lambda)$

Quelques exemples (issus du TDT)

Ex 2) $A = \begin{pmatrix} 1 & 3/4 & 3/4 \\ 3/4 & 1 & 3/4 \\ 3/4 & 3/4 & 1 \end{pmatrix}$

A est symétrique. Est-elle définie positive ? On vérifie le critère de Sylvester :

$$\rightarrow 1 > 0$$

$$\rightarrow 1 - (3/4)^2 > 0$$

$$\rightarrow (1 - (3/4)^2) - 3/4(0) + 3/4((3/4)^2 - 3/4) \\ = 1 + (3/4)^3 - 2 \cdot (3/4)^2 > 0$$

$$\text{et } A \gg 0.$$

* Méthode de Gauss-Seidel :

rayons convergente

* Méthode de Jacobi : on calcule

$$2D - A = \begin{pmatrix} 1 & -3/4 & -3/4 \\ -3/4 & 1 & -3/4 \\ -3/4 & -3/4 & 1 \end{pmatrix}$$

Est-elle définie positive ? On

note : $\downarrow$ Sarrus

$$\det(2D - A) \stackrel{\downarrow \text{Sarrus}}{=} 1 - (3/4)^3 - (3/4)^3 \\ + 3(3/4)^2 > 0$$

la méthode de Jacobi converge

7

Ex 3

$$A = \begin{pmatrix} 1 & 2 & -2 \\ 1 & 1 & 1 \\ 2 & 2 & 1 \end{pmatrix}$$

→ Les 2 méthodes sont bien définies.

$$J = M^{-1}N = D^{-1}(D - A)$$

$$= \begin{pmatrix} 0 & -2 & 2 \\ -1 & 0 & -1 \\ -2 & -2 & 0 \end{pmatrix}$$

(rayon spectral à calculer)

Idem pour Gauss Seidel avec

$$L_1 = M^{-1}N = \begin{pmatrix} 1 & 0 & 0 \\ 2 & 1 & 0 \\ 2 & 2 & 1 \end{pmatrix}^{-1} (M - A)$$

(on trouve après calculs que
Jacobi converge et pas Gauss-Seidel)

3) Autres méthodes

Successive
Over
Relaxation
↓

3.1) Méthode de relaxation (ou SOR)

Le principe consiste à relaxer la
méthode Gauss Seidel en reportissant
la diagonale de A entre M et N :
En notant $A = D - E - F$, on prend

$$\begin{cases} M = \frac{1}{\omega} D - E \end{cases}$$

$$\begin{cases} N = M - A = \left(\frac{1}{\omega} - 1\right) D + F \end{cases}$$

où $\omega \in \mathbb{R}_+^*$ est appelé paramètre de relaxation ($\omega = 1 \equiv$ Gauss Seidel)

On note

$$L_\omega = M^{-1}N = \left(\frac{1}{\omega}D - E\right)^{-1} \left(\left(\frac{1}{\omega} - 1\right)D + F\right)$$

On a nécessairement $\omega \in]0, 2[$, car

$$\det(L_\omega) = \frac{\left(\frac{1}{\omega} - 1\right)^n}{\left(\frac{1}{\omega}\right)^n} = (1 - \omega)^n$$

Ainsi, $|\det(L_\omega)| \geq 1$ si $\omega \notin]0, 2[$.

$$= \left| \prod_{i=1}^n \lambda_i \right|$$

et en particulier $\rho(L_\omega) \geq 1$

* Si $A \gg 0$,

$$M + N = \frac{1}{\omega}D - E + \left(\frac{1}{\omega} - 1\right)D + F$$
$$= \underbrace{\left(\frac{2}{\omega} - 1\right)}_{> 0 \text{ si } \omega \in]0, 2[} D$$

Ainsi, la méthode converge pour tout $\omega \in]0, 2[$.

En particulier, il est possible d'ajuster le paramètre ω pour améliorer la convergence de la méthode de Gauss-Seidel.

On peut par exemple démontrer le théorème suivant :

Théorème : soit A une matrice
 tri-diagonale, définie positive
 (par exemple, $A = \begin{pmatrix} 2 & -1 & 0 \\ -1 & 2 & -1 \\ 0 & -1 & 2 \end{pmatrix}$)

Les 3 méthodes, Jacobi, Gauss-
 Seidel et relaxation convergent.

De plus, il existe un paramètre
 de relaxation optimal $\omega_{opt} \in]1, 2[$,

tel que
 $\rho(L_{\omega_{opt}}) = \inf_{\omega \in]0, 2[} \rho(L_{\omega})$


De plus,

$$\omega_{opt} = \frac{2}{1 + \sqrt{1 - \rho(W)^2}}$$

et
 $\rho(L_{\omega_{opt}}) = \omega_{opt} - 1 < \rho(L_1) = \rho(W)$

preuve : voir poly de cours, ou bibliographie
 (Ciarlet)

Illustration graphique :



Implementation SOR :

$$x_{k+1}^i = \frac{1}{(\frac{1}{\omega} a_{ii})} \left(-a_{i,i-1} x_{k+1}^{i-1} - a_{i,i+1} x_k^{i+1} - a_{i,i+1} x_k^i - \dots - a_{i,n} x_k^n + b_i \right)$$

3.2) Méthode de gradient

Dans cette méthode, on choisit la décomposition suivante :

$$\begin{cases} M = \frac{1}{\alpha} \text{Id} \\ N = M - A = \frac{1}{\alpha} \text{Id} - A \end{cases} \quad (\alpha \in \mathbb{R}_+^*)$$

Cette méthode est toujours correctement définie et s'écrit :

$$\begin{aligned} \underline{x_{k+1}} &= \alpha \text{Id} \left(\frac{1}{\alpha} \text{Id} - A \right) x_k + b \\ &= \alpha \left(\frac{1}{\alpha} x_k - A x_k + b \right) \\ &= \underline{x_k - \alpha (A x_k - b)} \end{aligned}$$

* si $A \gg 0$, on a

$$\begin{aligned} M + N &= \frac{1}{\alpha} \text{Id} + \frac{1}{\alpha} \text{Id} - A \\ &= \frac{2}{\alpha} \text{Id} - A \gg 0 \text{ ssi} \\ &\alpha \in]0, \frac{2}{\rho(A)}[\end{aligned}$$

Proposition : soit $A \in \mathcal{S}_n(\mathbb{R})$.

* si A n'est pas définie négative ou définie positive, la méthode ne converge pas.

* si $A \gg 0$ de valeurs propres $0 < \lambda_1 \leq \dots \leq \lambda_n$, la méthode converge ssi $\alpha \in]0, \frac{2}{\lambda_n}[$. De

plus, la convergence est optimale si

$$\alpha = \frac{2}{\lambda_1 + \lambda_n} \quad \text{par lequel:}$$

$$\rho(M^{-1}N) = \frac{\lambda_n - \lambda_1}{\lambda_n + \lambda_1}$$

preuve (à faire avec le TDF)

Ex 4

1) $G_n \alpha$

$$x^{(k+1)} = x^{(k)} - \alpha (Ax^{(k)} - b)$$

soit:

$$x^{(k+1)} = B_\alpha x^{(k)} + c \quad (*)$$

$$B_\alpha = Id - \alpha A$$

$$c = \alpha b$$

2) La méthode (*) converge si

$$\rho(B_\alpha) < 1.$$

$$\text{soit: } \max_{1 \leq i \leq n} |1 - \alpha \lambda_i| < 1$$

3) on suppose

$$\lambda_1 < 0 < \lambda_2 \leq \dots \leq \lambda_n$$

(par exemple)

$$\text{Si } \alpha < 0, |1 - \alpha \lambda_n| = 1 - \alpha \lambda_n > 1$$


$$\text{Si } \alpha > 0, |1 - \alpha \lambda_1| = 1 - \alpha \lambda_1 > 1$$

La méthode ne converge pour aucun α .

4) On suppose $0 < \lambda_1 \leq \dots \leq \lambda_n$.

a) Alors

$$\max_{1 \leq i \leq n} |1 - \alpha \lambda_i| = \max(|1 - \alpha \lambda_1|, |1 - \alpha \lambda_n|)$$



On a donc


$$\max(|1 - \alpha \lambda_1|, |1 - \alpha \lambda_n|) < 1$$

si et seulement si $0 < \alpha < \frac{2}{\lambda_n} = \frac{2}{\rho(A)}$

b, c) On cherche $\alpha_{opt} \in]0, \frac{2}{\rho(A)}[$ 13
pour lequel

$\max_{1 \leq i \leq n} |1 - \alpha \lambda_i|$ soit minimal.

$$\rho(B_\alpha)$$



En ce point, on a

$$|1 - \alpha \lambda_1| = |1 - \alpha \lambda_n|$$

$$\text{soit } 1 - \alpha \lambda_1 = \alpha \lambda_n = 1$$

On trouve $\alpha_{\text{opt}} = \frac{2}{\lambda_1 + \lambda_n}$

En cette valeur

$$\begin{aligned} \rho(B_\alpha) &= 1 - \alpha_{\text{opt}} \lambda_1 \\ &= 1 - \frac{2\lambda_1}{\lambda_1 + \lambda_n} \\ &= \frac{\lambda_n - \lambda_1}{\lambda_n + \lambda_1} \end{aligned}$$

d) On admet (provisoirement) que $\text{cond}_2(A) = \frac{\lambda_n}{\lambda_1}$ si $A \gg 0$.
On a donc

$$\rho(B_\alpha) = \frac{\frac{\lambda_n}{\lambda_1} - 1}{\frac{\lambda_n}{\lambda_1} + 1} = \frac{\kappa_2(A) - 1}{\kappa_2(A) + 1}$$

Si la matrice est mal conditionnée) 14
C'est à dire $\kappa_2(A)$ grand, alors

$\rho(B_\alpha) \approx 1$ (et la méthode itérative converge très lentement)

Remarque: on parle de la méthode du gradient, car on minimise aussi la fonction quadratique suivante:

$$J(x) = \frac{1}{2} \langle Ax, x \rangle - \langle b, x \rangle$$

par laquelle

$\nabla J(x) = Ax - b$ gradient de J
par la méthode d'optimisation du gradient
à pas α : $x_{k+1} = x_k - \alpha (Ax_k - b)$

A faire: implémentation Python
des méthodes itératives usuelles sur

différents exemples:

* $A = \begin{pmatrix} 2 & -1 & & 0 \\ -1 & \ddots & \ddots & \\ 0 & \ddots & -1 & 2 \end{pmatrix}$ (4 méthodes possibles)

* les exemples de TD 7

Jacobi: x_0 donné et 15

$$x_{k+1}^i = \frac{1}{a_{ii}} \left(-a_{i,1} x_k^1 - \dots - a_{i,i-1} x_k^{i-1} - a_{i,i+1} x_k^{i+1} - \dots - a_{i,n} x_k^n + b_i \right)$$

($1 \leq i \leq n$)
($0 \leq k$)

Gauss-Seidel: x_0 donné et

$$x_{k+1}^i = \frac{1}{a_{ii}} \left(-a_{i,1} x_{k+1}^1 - \dots - a_{i,i-1} x_{k+1}^{i-1} - a_{i,i+1} x_k^{i+1} - \dots - a_{i,n} x_k^n + b_i \right)$$

($1 \leq i \leq n$)

SOR

$$x_{k+1}^i = \frac{1}{\left(\frac{1}{\omega} a_{ii}\right)} \left(-a_{i,1} x_{k+1}^1 - \dots - a_{i,i-1} x_{k+1}^{i-1} - a_{i,i+1} x_k^{i+1} - \dots - a_{i,n} x_k^n + b_i + \left(\frac{1}{\omega} - 1\right) a_{ii} x_k^i \right)$$

($1 \leq i \leq n$)