

# ASI 3

## Méthodes numériques pour l'ingénieur

Résolution de systèmes linéaires  
par des méthodes itératives :  
Jacobi, Gauss Seidel, relaxation

### Résoudre un système linéaire

$$Ax = b \Leftrightarrow \begin{cases} 2x_1 + 4x_2 - 2x_3 & = -6 \\ x_1 + 3x_2 & + x_4 = 0 \\ 3x_1 - x_2 + x_3 + 2x_4 & = 8 \\ -x_2 + 2x_3 + x_4 & = 6 \end{cases}$$

soit  $(\tilde{x}_1, \tilde{x}_2, \tilde{x}_3, \tilde{x}_4)$  une "presque" solution

imaginons que  $\tilde{A}\tilde{x} = \tilde{b}$  avec par exemple  $dist(A, \tilde{A}) < \varepsilon$

si on essayait :

$$\begin{cases} x_1 = \frac{-6 - 4\tilde{x}_2 + 2\tilde{x}_3}{2} \\ x_2 = \frac{0 - \tilde{x}_1 - \tilde{x}_4}{3} \\ x_3 = \frac{8 - 3\tilde{x}_1 + \tilde{x}_2 - 2\tilde{x}_4}{1} \\ x_4 = \frac{6 + \tilde{x}_2 - 2\tilde{x}_3}{1} \end{cases} \quad \text{soit } x_i = \frac{b_i - \sum_{j=1, j \neq i}^n a_{ij}\tilde{x}_j}{a_{ii}}$$

## Résoudre un système linéaire en itérant

$$\begin{cases} x_1 = \frac{-6 - 4\tilde{x}_2 + 2\tilde{x}_3}{2} \\ x_2 = \frac{0 - \tilde{x}_1 - \tilde{x}_4}{3} \\ x_3 = \frac{8 - 3\tilde{x}_1 + \tilde{x}_2 - 2\tilde{x}_4}{1} \\ x_4 = \frac{6 + \tilde{x}_2 - 2\tilde{x}_3}{1} \end{cases} \quad \text{soit} \quad x_i = \frac{b_i - \sum_{j=1, j \neq i}^n a_{ij} \tilde{x}_j}{a_{ii}}$$

Si  $Ax$  n'est pas encore égale à  $b$ , on recommence !

tant que  $dist(Ax_{new}, b) > \varepsilon$  (i.e.  $10^{-12}$ )

$$x_i^{new} = \frac{b_i - \sum_{j=1, j \neq i}^n a_{ij} x_j^{old}}{a_{ii}}$$

fin

## Osons itérer ! méthode de Jacobi

tant que  $dist(Ax_{new}, b) > \varepsilon$  (i.e.  $10^{-12}$ )

$$x_i^{new} = \frac{b_i - \sum_{j=1, j \neq i}^n a_{ij} x_j^{old}}{a_{ii}}$$

fin

Soit  $D$  la diagonale de la matrice  $A$ , et  $G$  le reste :

$$A = D + G$$

$$D = \begin{pmatrix} a_{11} & 0 & 0 & 0 & 0 \\ 0 & \ddots & 0 & 0 & 0 \\ 0 & 0 & a_{ii} & 0 & 0 \\ 0 & 0 & 0 & \ddots & 0 \\ 0 & 0 & 0 & 0 & a_{nn} \end{pmatrix} \quad G = \begin{pmatrix} 0 & a_{12} & a_{1i} & \cdots & a_{1n} \\ a_{21} & 0 & a_{2i} & \ddots & \vdots \\ a_{i1} & a_{i,i-1} & 0 & a_{i-1,i} & a_{i,n} \\ \vdots & \ddots & a_{i,i+1} & 0 & a_{n-1,n} \\ a_{n1} & \cdots & a_{ni} & a_{n,n-1} & 0 \end{pmatrix}$$

- new    -    - old            new    -1    -    old

## Gauss Seidel

$$Ax = b \Leftrightarrow \begin{cases} 2x_1 + 4x_2 - 2x_3 & = -6 \\ x_1 + 3x_2 & + x_4 = 0 \\ 3x_1 - x_2 + x_3 + 2x_4 & = 8 \\ -x_2 + 2x_3 + x_4 & = 6 \end{cases}$$

$$\begin{cases} x_1 = \frac{-6 - 4\tilde{x}_2 + 2\tilde{x}_3}{2} \\ x_2 = \frac{0 - x_1 - \tilde{x}_4}{3} \\ x_3 = \frac{8 - 3x_1 + x_2 - 2\tilde{x}_4}{1} \\ x_4 = \frac{6 + x_2 - 2x_3}{1} \end{cases}$$

$$\text{soit } x_i = \frac{b_i - \sum_{j=1}^{i-1} a_{ij}x_j - \sum_{j=i+1}^n a_{ij}\tilde{x}_j}{a_{ii}}$$

## méthode de Gauss-Seidel

tant que  $\text{dist}(Ax_{\text{new}}, b) > \varepsilon$  (i.e.  $10^{-12}$ )

$$x_i^{\text{new}} = \frac{b_i - \sum_{j=1}^{i-1} a_{ij}x_j^{\text{new}} - \sum_{j=i+1}^n a_{ij}x_j^{\text{old}}}{a_{ii}}$$

fin

Soit  $E$  la triangulaire inférieure et  $F$  la supérieure de la matrice  $A$  :

$$A = D + E + F$$

$$E = \begin{pmatrix} 0 & 0 & 0 & \cdots & 0 \\ a_{21} & 0 & 0 & \ddots & \vdots \\ a_{31} & a_{32} & 0 & 0 & 0 \\ \vdots & \ddots & a_{i,i+1} & 0 & 0 \\ a_{n1} & \cdots & a_{ni} & a_{n,n-1} & 0 \end{pmatrix} \quad F = \begin{pmatrix} 0 & a_{12} & a_{1i} & \cdots & a_{1n} \\ 0 & 0 & a_{2,i} & \ddots & \vdots \\ 0 & 0 & 0 & a_{-1,i} & a_{i,n} \\ \vdots & \ddots & 0 & 0 & a_{n-1,n} \\ 0 & \cdots & 0 & 0 & 0 \end{pmatrix}$$

— — new — — old    new — —<sup>-1</sup> — — old

## La relaxation

$$x^{new} = \varphi(x^{old})$$

$$x_r^{new} = \omega x^{new} + (1 - \omega)x^{old}$$

$\omega > 0$  : paramètre de relaxation

$$\begin{cases} \omega \in ]0,1[ : \text{interpolation} \\ \omega = 1 : \text{status quo} \\ \omega \in ]1,2[ : \text{extrapolation} \end{cases}$$

Jacobi:

$$x^{new} = (D)^{-1}(b - (E + F)x^{old})$$

$$x_r^{new} = \omega(D)^{-1}(b - Gx^{old}) + (1 - \omega)x^{old}$$

en multipliant par  $D$

$$Dx_r^{new} = \omega b + ((1 - \omega)D - \omega G)x^{old}$$

Gauss-Seidel:

$$x^{new} = (D + E)^{-1}(b - Fx^{old})$$

$$x_r^{new} = \omega(D + E)^{-1}(b - Fx^{old}) + (1 - \omega)x^{old}$$

$$(D + \omega E)x_r^{new} = \omega b + ((1 - \omega)D - \omega F)x^{old}$$

## Résumé « algorithmique »

$$Mx^{new} = Nx^{old} + b$$

Jacobi:

$$Dx^{new} = (b - (E + F)x^{old}) : \begin{cases} M = D \\ N = -E - F \end{cases}$$

Gauss-Seidel:

$$(D + E)x^{new} = (b - Fx^{old}) : \begin{cases} M = D + E \\ N = -F \end{cases}$$

Relaxation:

$$\left(\frac{\omega}{1-\omega}D + E\right)x^{new} = b + \left(\frac{1-\omega}{1-\omega}D - F\right)x^{old} : \begin{cases} M = \frac{\omega}{1-\omega}D + E \\ N = \frac{1-\omega}{1-\omega}D - F \end{cases}$$

# Convergence

$$\begin{cases} x^0 & \text{donné,} \\ x^{k+1} & = Cx^k + d \end{cases} \quad \text{Principes généraux}$$

**Théorème** : S'il existe une norme matricielle subordonnée telle que  $\|C\| < 1$

Alors l'algorithme ci-dessus converge pour tout  $x^0$  vers  $x^*$  la solution de :

$$(I - C)x^* = d$$

## Éléments de démonstration

-  $x^*$  est un point fixe de l'algorithme

$$- e^k = x^k - x^*$$

$$= Cx^{k-1} + d - Cx^* - d \quad \Leftrightarrow \quad e^k = Ce^{k-1} = C^k e^0$$

$$= C(x^{k-1} - x^*)$$

$$\|e^k\| \leq \|C^k\| \|e^0\| \leq \|C\|^k \|e^0\| \quad \text{si } \|C\| < 1, \quad \|C\|^k \xrightarrow{k \rightarrow \infty} 0$$

# Normes matricielles

$$\text{norme : } \begin{cases} n : E \rightarrow \mathbb{R}^+ \\ x \mapsto n(x) \end{cases} \quad \text{vérifiant} \quad \begin{cases} n(x) \geq 0 & \text{positivité} \\ n(x) = 0 \Leftrightarrow x = 0 \\ n(\lambda x) = |\lambda| n(x) \\ n(x+y) \leq n(x) + n(y) \end{cases}$$

exemples  $E = \mathbb{R}^n$  ;

$$\|x\|_2^2 = \sum_{i=1}^n x_i^2 \quad ; \quad \|x\|_p^p = \sum_{i=1}^n |x_i|^p \quad (p \geq 1); \quad \|x\|_1 = \sum_{i=1}^n |x_i| \quad ; \quad \|x\|_\infty = \sup_{i=1, \dots, n} |x_i|$$

## Définition

Soit  $A$  une matrice  $n \times m$ , étant donnée une norme vectorielle, on appelle norme matricielle subordonnée, la norme matricielle définie par :

$$\|A\| = \max_{\|x\|=1} \|Ax\|$$

Conséquence :  $\|A\|_1 \sim \sum_{j=1}^m \|A_{\cdot j}\|$  ;  $\|A\|_\infty \sim \max_{i=1, \dots, n} \|A_{i \cdot}\|$

## Exemples


norme de Frobenius :  $\|A\|_F^2 = \sum_{j=1}^m \sum_{i=1}^n a_{ij}^2 = \text{tr}(A'A)$ ;

$\|A\|_1 = \max_{1 \leq j \leq m} \sum_{i=1}^n |a_{ij}|$  ;  $\|A\|_\infty = \max_{1 \leq i \leq n} \sum_{j=1}^m |a_{ij}|$  ;

$\|A\|_1 = \|A\|_\infty$

*à utiliser pour le calcul !*

### Illustration 2d



$$\|A\| = \max_{x \in \mathbb{R}^n, \|x\|=1} \|Ax\|$$

## Calculez les valeurs propres de

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

$$\dots \sqrt{\dots} \dots \sqrt{\dots} \dots$$

Et ses vecteurs propres ?

$$v_1 = \begin{pmatrix} 1 \\ 1 \\ 0 \end{pmatrix}, \quad v_2 = \begin{pmatrix} -\frac{\sqrt{3}}{2i-3} \\ \frac{\sqrt{3}}{i-3} \\ 3 \\ 1 \end{pmatrix}, \quad v_3 = \begin{pmatrix} \frac{\sqrt{3}}{2i-3} \\ \frac{\sqrt{3}}{i-3} \\ 3 \\ 1 \end{pmatrix}$$

## Rayon spectrale d'une matrice

**Définition** : on appelle rayon spectrale d'une matrice carrée  $A$ , le nombre réel  $\rho(A)$  tel que :

$$\rho(A) = \max_{i=1,n} |\lambda_i(A)|$$

**Théorème** : soit  $A$  une matrice  $n \times m$ , alors :

$$\|A\|_F^2 = \rho(A' A)$$

**Corollaire** : si  $A$  est une matrice carrée symétrique  $n \times n$ , alors :

$$\|A\|_F = \rho(A)$$

**Remarque** : en général, le rayon spectrale n'est pas une norme :

$$A = \begin{pmatrix} 0 & 1 \\ 0 & 0 \end{pmatrix}, \quad \|A\|_F = 1 \neq 0, \quad \rho(A) = 0$$

## Convergence : le retour

*Principes généraux*

$$\begin{cases} x^0 & \text{donné,} \\ x^{k+1} & = Cx^k + d \end{cases}$$

**Théorème** : S'il existe une norme matricielle subordonnée telle que  $\|C\| < 1$

Alors l'algorithme ci-dessus converge pour tout  $x^0$  vers  $x^*$  la solution de :

$$(I - C)x^* = d$$

**Théorème** : les points suivants sont équivalents :

- $C$  est une matrice convergente, (i.e.  $C^k$  tend vers 0)
- $\rho(C) < 1$
- $\|C\| < 1$

## Résumé « algorithmique »

$$Mx^{\text{new}} = Nx^{\text{old}} + b$$

Jacobi:

$$Dx^{\text{new}} = (b - (E + F)x^{\text{old}}): \begin{cases} M = D \\ N = -E - F \end{cases}$$

Gauss-Seidel:

$$(D + E)x^{\text{new}} = (b - Fx^{\text{old}}): \begin{cases} M = D + E \\ N = -F \end{cases}$$

Relaxation:

$$\left(\frac{1}{\omega}D + E\right)x^{\text{new}} = b + \left(\frac{1-\omega}{\omega}D - F\right)x^{\text{old}}: \begin{cases} M = \frac{1}{\omega}D + E \\ N = \frac{1-\omega}{\omega}D - F \end{cases}$$

## Convergence

**Théorème** : Si  $A$  est une matrice à diagonale strictement dominante, alors la méthode de Jacobi converge.

**Démonstration**

Jacobi:

$$x^{k+1} = (D)^{-1} (b - (E + F)x^k)$$

$$x^{k+1} = Cx^k + d \quad \text{avec} \quad C = D^{-1}(E + F), \quad d = D^{-1}b$$

$$\|C\|_{\infty} = \|D^{-1}(E + F)\|_{\infty} = \max_j \left( \sum_i |a_{ij}| \right) < 1$$

**Remarque** : il en est de même pour la méthode de Gauss-Seidel

## Convergence

**Théorème** : soit une méthode itérative :  $Mx^{k+1} = Nx^k + b$   
 Si  $A$  est une matrice symétrique définie positive  
 telle que si  $A = M - N$  alors  $M + N'$  est définie positive  
 Alors la méthode itérative est convergente

**Démonstration**  $A$  symétrique définie positive  $\Leftrightarrow \|x\|_A^2 = \sqrt{x'Ax}$   
 $\|M^{-1}Nx\|_A^2 = \|M^{-1}(M - A)x\|_A^2 = \|x - M^{-1}Ax\|_A^2$


posons  $y = M^{-1}Ax \Leftrightarrow My = Ax$

$$\begin{aligned} \|x - M^{-1}Ax\|_A^2 &= \|x - y\|_A^2 = (x - y)' A (x - y) = \|x\|_A^2 - x' Ay - y' Ax + y' Ay \\ &= \|x\|_A^2 - y' M' y - y' My + y' Ay = \|x\|_A^2 - y' (M + N) y \end{aligned}$$

on a donc :  $\|x - M^{-1}Ax\|_A^2 < \|x\|_A^2 \Rightarrow \|M^{-1}N\|_A = \max_{\|x\|_A=1} \|M^{-1}Nx\|_A < 1$

**Théorème** : Si  $A$  est une matrice symétrique définie positive,  
 la méthode de la relaxation converge pour :  $0 < \omega < 2$

## Influence de $\omega$



## Remarques

*pratique :*

- pas de preuve de convergence généralisée,
- on préfère la relaxation avec différents tests pour  $\omega$ ,
- on préfère les méthodes directes,
- voir les méthodes semi directes pour les problèmes de grande taille (cf les méthodes « multigrilles »),

## Conditionnement d'un système linéaire


$$Ax = b \Leftrightarrow \begin{pmatrix} 1 & 2 \\ 1.0001 & 2 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} 3 \\ 3 \end{pmatrix}$$

examinons deux solutions

$$x = \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} 1 \\ 1 \end{pmatrix} \quad y = \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} = \begin{pmatrix} 3 \\ 0 \end{pmatrix} \quad \begin{cases} r_x = Ax - b = [0 \quad 0]^T \\ r_y = Ay - b = [0 \quad 0.0002]^T \end{cases}$$

$$\|r_x - r_y\| = 0.0002 \quad \text{et} \quad \|x - y\| = 2$$

Deux vecteurs très différents donnent des solutions très proches



## Conditionnement : influence du second membre

$$A = \begin{pmatrix} 8 & 10 & 10 & 10 \\ 1 & 5 & 6 & 1 \\ 7 & 10 & 4 & 7 \\ 7 & 8 & 1 & 7 \end{pmatrix}, b = \begin{pmatrix} 38 \\ 13 \\ 28 \\ 23 \end{pmatrix}, \text{ admet comme solution } x = \begin{pmatrix} 1 \\ 1 \\ 1 \\ 1 \end{pmatrix}$$

$$b + \delta b = \begin{pmatrix} 38.1 \\ 12.9 \\ 28.1 \\ 22.9 \end{pmatrix}, x + \delta x = \begin{pmatrix} -34.5 \\ 11.0 \\ -5.6 \\ 26.0 \end{pmatrix} : \frac{\|\delta b\|}{\|b\|} = 3.7 \cdot 10^{-3} \frac{\|\delta x\|}{\|x\|} = 22.6$$

$$\lambda_1 = 24.1, \lambda_4 = -0.007 : \text{cond}(A) = 7363$$

$$\begin{aligned} r &= (b - (b + \delta b)) \\ &= Ax - A\tilde{x} && \text{avec } \tilde{x} = (x + \delta x) \\ &= A(x - \tilde{x}) \Leftrightarrow (x - \tilde{x}) = A^{-1}r \quad A \text{ non singulière} \\ \Rightarrow \|x - \tilde{x}\| &\leq \|A^{-1}\| \|r\| \end{aligned}$$

## Conditionnement

**Définition** : on appelle conditionnement d'une matrice carrée  $A$ , relatif à une norme subordonnée, le nombre réel  $\chi(A)$  :

$$\chi(A) = \|A\| \|A^{-1}\|$$

**Remarque** :  $\|I\| = \|I^{-1}\| = 1 < \|A\| \|A^{-1}\| = \chi(A) > 1$

**Théorème** : Si  $A$  est une matrice carrée, non singulière (régulière)

$$Ax = b, \quad A(x + \delta x) = b + \delta b$$

$$\frac{\|\delta x\|}{\|x\|} \leq \chi(A) \frac{\|\delta b\|}{\|b\|}$$

Perturbation du second membre

$$Ax = b, \quad (A + \delta A)(x + \delta x) = b$$

$$\frac{\|\delta x\|}{\|x\|} \leq \chi(A) \frac{\|\delta A\|}{\|A\|}$$

Perturbation de la matrice

Un problème est dit « **bien conditionné** » si  $\chi(A)$  est proche de 1, il est dit « **mal conditionné** » si  $\chi(A)$  est grand (et mal posé si  $\chi(A)$  est infini)

## Conditionnement

$$1) \quad Ax = b \Rightarrow \|b\| \leq \|A\| \|x\| \Rightarrow \frac{1}{\|x\|} \leq \|A\| \frac{1}{\|b\|}$$

$$2) \quad A(x + \delta x) = b + \delta b \Rightarrow \delta b \leq A \delta x \Rightarrow \|\delta x\| \leq \|A^{-1}\| \|\delta b\|$$

$$1) + 2) \Rightarrow \frac{\|\delta x\|}{\|x\|} \leq \|A\| \|A^{-1}\| \frac{\|\delta b\|}{\|b\|}$$

$$\chi(A) = \|A\| \|A^{-1}\|$$

**Remarque** : si  $A$  est symétrique, si on note ses valeurs propres  $\lambda_i$

$$|\lambda_1|, |\lambda_2|, \dots, |\lambda_i|, \dots, |\lambda_n|, \quad \frac{1}{|\lambda_1|} = \|A^{-1}\|_2 \quad |\lambda_n| = \|A\|_2$$

$$\text{et donc } \chi_2(A) = \frac{|\lambda_n|}{|\lambda_1|}$$

Dans l'exemple,  $\chi_2(A) = 7363$ ,  $\|\delta b\| = 0.0037$

la borne de l'erreur est de l'ordre de  $\chi_2(A) \|\delta b\| = 27.2$  (on a trouvé 22.5)

## Comment améliorer le conditionnement ?

Ajouter un « chouia » sur la diagonale

$$\chi_2(A + \mu I) = \frac{|\lambda_n + \mu|}{|\lambda_1 + \mu|}$$

## Itérations !

$$Ax = b$$

$$\tilde{x} = \text{gauss}(A,b)$$

$$\text{err} = A\tilde{x} - b$$

$$A(\tilde{x} + \delta x) = b$$

$$A\delta x = \tilde{b} = b - A\tilde{x}$$

```
A = randn(n);
b = ones(n,1);
x = A\b;
err = A*x-b;
norm(err)
```

```
ans = 2.8246e-013
```

```
dx = A\err;
```

```
err2 = A*(x-dx)-b;
norm(err2)
```

```
ans = 6.4789e-014
```

## TP - la relaxation

Le but du TP est d'écrire un programme matlab résolvant un système linéaire par la méthode de la relaxation

$$x = \text{relax}(A,b,w,nite,err)$$

Pour ce faire, il faut étudier l'évolution du rayon spectral

- mettez vous par binôme
- rédigez une page :
  - recto : ce que vous avez fait
  - verso ce que vous en pensez
- a rendre pour le 8 décembre à 17h30 (publication du corrigé)

Indices : créer un problème test,  
les fonction `cpucting` et `flaps`  
`tril` et `triu` pourraient vous simpl  
et `diag(diag())` et `eig` aussi

## Propriétés

**Définition** : on appelle quotient de Rayleigh la fonction  $q_A(x)$

$$q_A(x) = \frac{x'Ax}{x'x}$$

Soit  $A$  une matrice carrée, on appelle polynôme caractéristique de  $A$  le polynôme défini par :

$$p(\lambda) = \det(A - \lambda I)$$

Les  $n$  racines  $\lambda_i$  de ce polynôme sont les valeurs propres de  $A$ ,  $v_i$  est un vecteur propre de  $A$ . Il existe  $n$  vecteurs  $v_i$  tels que :

$$Av_i = \lambda_i v_i \quad \begin{array}{l} \lambda_i \text{ est une valeur propre de } A, \\ v_i \text{ est un vecteur propre de } A. \end{array}$$

**Théorème** : si  $A$  est symétrique,

$$\max_i \lambda_i = \max_x q_A(x)$$