

# Chapitre II

## Algèbre linéaire

- I - Méthodes de résolution de systèmes linéaires
- II - Algèbre linéaire et perturbations
- III - Méthodes itératives
- IV - Méthodes de descente
- V - Préconditionnement.

①

\* On cherche à résoudre le pb suivant :

$Ax = b$ . La première idée est d'inverser la matrice. Mais ceci est un pb difficile.

\* Cas où  $A$  est diagonale. La solut<sup>o</sup> est immédiate :  $A^{-1} = D \left( \frac{1}{a_{11}}, \frac{1}{a_{22}}, \dots, \frac{1}{a_{mm}} \right)$   
La solution est donc :

$$x_i = \frac{1}{a_{ii}} * b_i$$

\* Cas où  $A$  est triangulaire supérieure.

$$x_m \leftarrow \frac{b_m}{a_{mm}}$$

Pour  $i \leftarrow m-1$  à  $1$  pas  $-1$  faire

$$x_i \leftarrow \left( b_i - \sum_{j=i+1}^m a_{ij} x_j \right) / a_{ii}$$

Fin Pour

## \* Méthodes directes.

L'idée est de remplacer le système  $Ax=b$  de lequel la matrice  $A$  est pleine, par plusieurs systèmes faciles à résoudre car creux.

L'idéal serait de remplacer  $A$  par  $PDP^{-1}$  avec  $D$  diagonal mais trop coûteux.

L'alternative est de remplacer  $A$  par  $LU$  avec  $L$  triangulaire inf et  $U$  triangulaire sup.

On résoud alors  $Ly=b$  puis  $Ux=y$ .

La factorisation  $LU$ , qd elle existe, n'est pas unique. Pour la rendre unique, on ajoute la contrainte que la diagonale de  $L$  est à 1. C'est la factorisation de Gauss.

Pour les matrices définies positives et symétriques, on utilise la factorisation de Cholesky  $A=MM^T$  où  $M$  est triangulaire inférieure.

## \* Factorisation de Gauss.

→ On applique la méthode des pivot de Gauss  
( $\Rightarrow$  pas de 0 sur la diagonale)

$$A^{(1)} = \begin{pmatrix} a_{11} & & a_{1n} \\ & & \\ a_{m1} & & a_{mn} \end{pmatrix}; \Rightarrow M^{(1)} = \begin{bmatrix} 1 & 0 & \dots & 0 \\ -\frac{a_{21}}{a_{11}} & 1 & 0 & \dots & 0 \\ \vdots & 0 & \ddots & & \\ -\frac{a_{m1}}{a_{11}} & 0 & & & \ddots \end{bmatrix}$$

$$\Rightarrow L^{(1)} = M^{(1)} - I = \begin{bmatrix} 1 & 0 & \dots & 0 \\ a_{21} & 1 & 0 & \dots & 0 \\ a_{31} & & \ddots & & \\ \vdots & & & \ddots & \\ a_{m1} & & & & 1 \\ a_{n1} & 0 & \dots & & 1 \end{bmatrix}$$

$$\Rightarrow L^{(1)} = -M^{(1)} + 2I$$

$$\text{et } A^{(2)} = M^{(1)} A^{(1)} \quad (\text{ça revient à faire Gauss})$$

On répète l'opération  $(m-1)$  fois.

$$\text{A la fin on a } L = L^{(1)} L^{(2)} L^{(3)} \dots L^{(m-1)} \\ \text{et } U = A^{(m)}$$

$$\text{et } A = LU$$

$$\text{Rq : } L = L^{(1)} + L^{(2)} \dots + L^{(m-1)} - I^{(m-2)}$$

Coût :  $\frac{m^3}{3}$  additions/multiplications et  $\frac{m(m-1)}{2}$  divisions.

$$\rightarrow \det A = \det LU = \det L \cdot \det U = \prod p_{ii} \cdot \prod u_{ii} \\ = \prod u_{ii}$$

Algo :

Pour  $j \leftarrow 1$  à  $m-1$

Pour  $i \leftarrow j+1$  à  $m$

$$A(i, j) = A(i, j) / A_{jj}$$

Pour  $k \leftarrow j+1$  à  $m$

$$A(i, k) = A(i, k) - A(i, j) * A(j, k)$$

Fin Pour

Fin Pour

Fin Pour

\* Une matrice  $A$  admet une factorisation LU si Tous les blocs  $A_p$ ,  $1 \leq p \leq n$  sont inversibles.

### \* Factorisation de Cholesky

Algo :  $L(1,1) \leftarrow \sqrt{A(1,1)}$   
 Pour  $i \leftarrow 2$  à  $n$   
 Pour  $j \leftarrow 1$  à  $i-1$   
 $L(i,j) \leftarrow \frac{1}{L(j,j)} \left( A(i,j) - \sum_{k=1}^{j-1} L(i,k) \cdot L(j,k) \right)$   
 Fin Pour  
 $L(i,i) \leftarrow \left[ A(i,i) - \sum_{k=1}^{i-1} L^2(i,k) \right]^{1/2}$

Coût :  $\frac{n^3}{6}$  addit° / multiplications.  
 $\frac{n(n-1)}{2}$  divisions.  
 $n$  évaluations.

\* la méthode de Gauss peut-être bloquée si on tombe sur un pivot nul. la méthode de Gauss avec pivotage partiel résout ce pb. en échangeant les lignes de la pb lorsque le pivot est nul. On utilise les matrices de permutations.

Ainsi, si on note  $P$  la matrice des permutations, toute matrice inversible  $A$  peut s'écrire sous la forme

$$PA = LU \quad \text{avec } P \text{ matrice de permutations.}$$

Rq : pivotage partiel  $\Rightarrow$  meilleure stabilité.

A chaque étape, on prend comme pivot (permutat°) l'élément de la diag qui est le  $\oplus$  grand en valeur absolue.

II

## \* Normes vectorielles

- Propriétés d'une norme  $\|\cdot\|$ :

$$\|x\| \geq 0$$

$$\|\alpha x\| = |\alpha| \cdot \|x\|$$

$$\|x+y\| \leq \|x\| + \|y\|$$

- Normes les plus utilisées:

$$1) \|x\|_1 = \sum_{i=1}^n |x_i|$$

$$2) \|x\|_2 = \sqrt{x^T x}$$

$$3) \|x\|_\infty = \max |x_i|$$

- Norme générale:

$$\|x\|_p = \left( \sum |x_i|^p \right)^{1/p}$$

- Inégalité de Hölder

$$\sum_{i=1}^n |x_i y_i| \leq \|x\|_p \cdot \|y\|_q \quad \text{et} \quad \frac{1}{p} + \frac{1}{q} = 1$$

- Inégalité de Cauchy

$$\sum_{i=1}^n |x_i y_i| \leq \sqrt{\sum |x_j|^2} \cdot \sqrt{\sum |y_j|^2}$$

- Toutes les normes de  $\mathbb{R}^n$  sont équivalentes

## \* Norme matricielle.

• Propriétés d'une norme matricielle.

1)  $\|A\| \geq 0$  et  $\|A\| = 0$  ssi  $A = 0$

2)  $\|\alpha A\| = |\alpha| \cdot \|A\|$

3)  $\|A+B\| \leq \|A\| + \|B\|$

Si de plus on a  $\|AB\| \leq \|A\| \cdot \|B\|$ , la norme est ss-multiplicative.

• A toute norme vectorielle on peut faire correspondre une norme matricielle :

$$\|A\| = \sup_{\|x\|=1} \|Ax\| = \sup_{\|x\| \neq 0} \frac{\|Ax\|}{\|x\|}$$

Une telle norme est dite subordonnée et notée  $\text{sub}(A)$ .

• Normes les plus utilisées.

1°) somme des colonnes :  $\|A\|_1 = \sup_{\|x\|_1=1} \|Ax\|_1 = \max_{j=1..m} \sum_i |a_{ij}|$

2°)  $\|A\|_2 = \sup_{\|x\|_2=1} \|Ax\|_2 = \sqrt{\rho(A^T A)}$

3°)  $\|A\|_\infty = \sup_{\|x\|_\infty=1} \|Ax\|_\infty = \max_{i=1..m} \sum_{j=1}^m |a_{ij}|$  somme des lignes

Une norme est consistante ssi  $\|Ax\| \leq \|A\| \cdot \|x\|$ . La norme 2 (ou de Schur) est consistante avec la norme euclidienne consistante + subordonnée  $\Rightarrow$  ss-multiplicative

Le rayon spectral d'une matrice est inférieur (ou égal) à la norme de celle-ci :

$$\rho(A) \leq \|A\|$$

## \* Conditionnement d'une matrice.

Un pb est bien conditionné si une petite variation des entrées entraîne une petite variation des sorties.

Dans la même idée, on détermine le conditionnement d'une matrice

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

Il faut  $\kappa(A)$  le plus petit possible.

Théorème: Si  $A$  est régulière et si

$$\frac{\|\Delta A\|}{\|A\|} < \frac{1}{\kappa(A)} \text{ alors } A + \Delta A \text{ est régulière.}$$

$\rightarrow \frac{1}{\kappa(A)}$  mesure la distance qui sépare d'une matrice singulière.

### Justification:

- Perturbation de  $b$ :  $A(x + \Delta x) = b + \Delta b$

$$\hookrightarrow A \Delta x = \Delta b$$

$$\hookrightarrow \|\Delta x\| = \|A^{-1}\| \cdot \|\Delta b\|$$

$$\underline{\text{or}} \quad Ax = b \text{ et } \|Ax\| = \|b\| \leq \|A\| \cdot \|x\|$$

$$\Rightarrow \|\Delta x\| \cdot \|b\| \leq \|A\| \cdot \|x\| \cdot \|A^{-1}\| \cdot \|\Delta b\|$$

$$\rightarrow \frac{\|\Delta x\|}{\|x\|} \leq \kappa(A) \cdot \frac{\|\Delta b\|}{\|b\|}$$

- Perturbation de  $A$ :  $(A + \Delta A)(x + \Delta x) = b$

$$\hookrightarrow A \Delta x = -\Delta A(x + \Delta x)$$

$$\hookrightarrow \|\Delta x\| = \|A^{-1}\| \cdot \|\Delta A\| \cdot \|x + \Delta x\|$$

$$\Rightarrow \|\Delta x\| \leq \|A^{-1}\| \cdot \|\Delta A\| \cdot (\|x\| + \|\Delta x\|)$$

$$\Rightarrow \|\Delta x\| (1 - \|\Delta A\| \cdot \|A^{-1}\|) \leq \|A^{-1}\| \cdot \|\Delta A\| \cdot \|x\|$$

$$\text{Si } \|A^{-1}\| \cdot \|\Delta A\| \ll 1$$

$$\Rightarrow \frac{\|\Delta x\|}{\|x\|} \leq \kappa(A) \cdot \frac{\|\Delta A\|}{\|A\|}$$

• Perturbation de A et b:  $(A + \Delta A)(x + \Delta x) = b + \Delta b$ .

$$\hookrightarrow A \Delta x + \Delta A x + \underbrace{\Delta A \Delta x}_{\text{négliger}} = \Delta b.$$

$$\hookrightarrow \Delta x = -A^{-1} \Delta A x + A^{-1} \Delta b.$$

$$\rightarrow \frac{\|\Delta x\|}{\|x\|} \leq \|A^{-1}\| \cdot \|\Delta A\| + \|A^{-1}\| \cdot \frac{\|\Delta b\|}{\|x\|}$$

$$\Rightarrow \frac{\|\Delta x\|}{\|x\|} \leq \kappa(A) \cdot \frac{\|\Delta A\|}{\|A\|} + \kappa(A) \cdot \frac{\|\Delta b\|}{\|A\| \cdot \|x\|}$$

$$\text{car: } Ax = b \Rightarrow \|A\| \cdot \|x\| \geq \|b\|$$

$$\Rightarrow \frac{\|\Delta x\|}{\|x\|} \leq \kappa(A) \left( \frac{\|\Delta A\|}{\|A\|} + \frac{\|\Delta b\|}{\|b\|} \right)$$

\* Analyse de l'erreur active

$$\bullet m(x) = x + \eta x \text{ ou } m(x) = \frac{x}{1 + \eta} \text{ avec } |\eta| \leq \text{eps}$$

$$\bullet \text{On pose } S_R = x_1 + \dots + x_R$$

$$\hookrightarrow s_R = s_{R-1} + x_R$$

$$\bullet m(s_R) = s_R + e_R = \frac{s_R}{1 + \epsilon_R}; \quad m(x_R) = x_R (1 + \eta_R)$$

$$\rightarrow s_R + e_R + \epsilon_R m(s_R) = s_{R-1} + e_{R-1} + x_R + \eta_R x_R$$

$$\Rightarrow |e_R| \leq |e_{R-1}| + \text{eps} |x_R| + \text{eps} |m(s_R)|$$

$$\text{On pose } \delta_R = s_{R-1} + |x_R| + |m(s_R)|$$

$$\Rightarrow |e_R| \leq \text{eps} \delta_R$$

Analyse active de l'erreur:  $|x \oplus y - m(x \oplus y)| \leq \text{eps} |m(x \oplus y)|$

\* Erreur d'un produit vectoriel.

↳ soit  $A = xy^T = (a_{ij})$  et  $m(a_{ij}) = \alpha_i y_j (1 + \beta_{ij})$   
 $m(A) = xy^T + \Delta$  avec  $\|\Delta\| \leq \epsilon \alpha \|xy^T\|$ .

\* Erreur d'un produit matriciel.

↳ soit  $C = A \cdot B$ ,  $A \in \mathbb{R}^{m \times n}$ ,  $B \in \mathbb{R}^{n \times p}$

Exprimons

$$A = \begin{bmatrix} a_1 \\ \vdots \\ a_m \end{bmatrix} \text{ avec } a_i \text{ vecteur ligne.}$$

$$B = [b_1 \dots b_p] \text{ avec } b_j \text{ vecteur colonne}$$

$$\Rightarrow c_{ij} = a_i b_j \text{ donc } m(c_{ij}) = (a_i + \Delta a_i) b_j$$

avec  $\|\Delta a_i\| \leq \gamma_m \|a_i\|$

erreur en retard  $\Rightarrow m(c_j) = (A + \Delta A) b_j$   
avec  $\begin{cases} \|\Delta A\| \leq \gamma_m \|A\| \\ c_j \text{ vecteur colonne.} \end{cases}$

erreur en avance  $\Rightarrow \|e - m(e)\| \leq \gamma_m \|A\| \|B\|$ .

\* Préconditionnement d'une matrice

↳ soit  $A_0 x = b$  avec  $A_0$  mal conditionnée  
c-à-d  $\|A_0 B_0 - I\|$  est supérieur à un  
seuil donné. On construit le système  
préconditionné  $B_0 A_0 x = B_0 b$ .

On pose  $A_1 = B_0 A_0$

On calcule  $B_1$  l'inverse de  $A_1$ .

Si on est toujours au dessus du seuil,  
on calcule  $B_2$  l'inverse de  $A_2 = B_1 B_0 A_0$

On itère jusqu'à passer en-dessous  
du seuil.

(III)

## Méthode itérative

↳ Construire une suite qui converge vers la solution.

Exemple

Une méthode itérative de la forme :

$$\begin{cases} x^{(0)} \text{ donné} \\ x^{(k+1)} = Bx^{(k)} + f \end{cases}$$

Celle-ci est dite consistante si la solution  $x$  vérifie  $x = Bx + f \Leftrightarrow f = (I - B)A^{-1}b$ .

On note  $e^{(k)} = x^{(k)} - x$  l'erreur de la  $k^{\text{ème}}$  itération.

Théorème : Une méthode consistante converge vers la solution pour toute valeur initiale ssi  $\rho(B) < 1$

Théorème : les erreurs  $e^{(k)} = x^{(k)} - x$  satisfont :

$$\sup_{e^{(0)} \neq 0} \lim_{k \rightarrow +\infty} \sqrt[k]{\frac{\|e^{(k)}\|}{\|e^{(0)}\|}} = \rho(B)$$

## \* Méthode itérative linéaire

↳ décomposit° de  $A$  (splitting) :  $A = P - N$  avec  $P$  inversible

$$\text{On pose } Px^{(k+1)} = Nx^{(k)} + b$$

$$\Rightarrow x^{(k+1)} = Bx^{(k)} + f \text{ avec } \begin{cases} B = P^{-1}N \\ f = P^{-1}b \end{cases}$$

On peut aussi écrire :

$$x^{(k+1)} = Bx^{(k)} + P^{-1}\pi^{(k)}$$

$$\text{avec } \pi^{(k)} = b - Ax^{(k)}$$

\* Décomposition d'une matrice: Jacobi vs Gauss Siedel

$$A = \begin{bmatrix} & & & & \\ & & & & \\ & L & D & & U \\ & & & & \\ & & & & \end{bmatrix}$$

| Méthode      | Décomposition   | $M^{-1}N$          | Itération                        |
|--------------|-----------------|--------------------|----------------------------------|
| Jacobi       | $A = D - (L+U)$ | $J = -D^{-1}(L+U)$ | $Dx^{(k+1)} = -(L+U)x^{(k)} + b$ |
| Gauss Siedel | $A = (D+L) - U$ | $G = (D+L)^{-1}U$  | $(D+L)x^{(k+1)} = Ux^{(k)} + b$  |

\* Amélioration: méthodes relaxées.

↳ On remplace l'itéré calculé par une méthode précédente ( $\hat{x}^{(k+1)}$ ) par  $x^{(k+1)}$  en faisant intervenir  $x^{(k)}$ ; prise en compte des plusieurs états antérieurs avec pondération:

$$x^{(k+1)} = \omega \hat{x}^{(k+1)} + (1-\omega)x^{(k)}$$

- Jacobi relaxé

$$x^{(k+1)} = (1-\omega)x^{(k)} - \omega D^{-1}(L+U)x^{(k)} + \omega D^{-1}b$$

- Gauss-Siedel relaxé

$$x^{(k+1)} = (1-\omega)(I + \omega D^{-1}L)^{-1}x^{(k)} - \omega(I + \omega D^{-1}L)^{-1}D^{-1}Ux^{(k)} + \omega(D + \omega L)^{-1}D^{-1}b$$

\* Conditions de convergence a priori

- $A$  à diagonale strictement dominante  $\Rightarrow$  convergence
- $A$  et  $2D-A$  sym. définies positives, alors convergence par Jacobi et  $\rho(J) = \|J\|$
- $A$  sym. def. positives  $\Rightarrow$  convergence par Jacobi relaxée si  $0 < \omega < \frac{2}{\rho(D^{-1}A)}$
- $A$  def. pos. sym  $\Rightarrow$  Gauss-Seidel converge
- Si convergence par Jacobi alors convergence par Jacobi relaxé pour  $0 < \omega < 1$ .

\* Nbre d'itérations:  $k_{\min} \approx -\frac{\log(\epsilon)}{R(B)}$   $\begin{cases} \epsilon: \text{erreur admise} \\ R(B) = -\log \rho(B) \end{cases}$

\* Test d'arrêt

1)  $C^{(k+1)} = B C^{(k)} \Rightarrow \|e^{(k+1)}\| \leq \frac{\|B\|^{k+1}}{1 - \|B\|} \cdot \|x^{(1)} - x^{(0)}\|$

2)  $\frac{\|P_x^{-1}(A)\|}{\|P_x^{-1}(b)\|} \leq \epsilon$

## IV

La résolution d'un système linéaire peut être vu comme la minimisation d'une fonctionnelle.

$$Ax = b, \quad A \in \mathbb{R}^{m \times m}, \quad x \in \mathbb{R}^m$$

la fonctionnelle est définie comme suit:

$$J(x) = \frac{1}{2} (x^T A x) - x^T b.$$

Gradient  $\rightarrow \nabla J(x) = \frac{1}{2} (A^T + A)x - x^T A = Ax - b.$

Résoudre le système revient à résoudre  $\nabla J(x) = 0.$

$\rightarrow$  on a donc un pb. d'optimisation.

On cherche  $x^*$  tq  $J(x^*)$  soit  $\begin{cases} \text{minimum.} \\ \text{maximum.} \end{cases}$

### Rappels.

gradient  $\cdot \nabla J = \left[ \frac{\partial J}{\partial x_1}, \frac{\partial J}{\partial x_2}, \dots, \frac{\partial J}{\partial x_m} \right]$

hessienne  $\cdot HJ = \nabla^T J \cdot \nabla J.$

$$= \begin{bmatrix} \frac{\partial^2 J}{\partial x_1^2} & \dots & \frac{\partial^2 J}{\partial x_1 \partial x_m} \\ \vdots & & \vdots \\ \frac{\partial^2 J}{\partial x_m \partial x_1} & \dots & \frac{\partial^2 J}{\partial x_m^2} \end{bmatrix}$$

norme de l'énergie  $\cdot \|x\|_A^2 = x^T A x$

$\cdot A \leq B \quad \text{ssi} \quad \|x\|_A \leq \|x\|_B$

fonction convexe •  $\mathcal{J}(\lambda x + (1-\lambda)y) \leq \lambda \mathcal{J}(x) + (1-\lambda)\mathcal{J}(y)$

fortement convexe •  $\mathcal{J}(v) \geq \mathcal{J}(u) + \nabla \mathcal{J}(u)^T (v-u) + \frac{\alpha}{2} \|v-u\|^2$

extremum •  $x^*$  extremum  $\Rightarrow \nabla \mathcal{J}(x^*) = 0$   
 $\mathcal{J}$  convexe et  $\nabla \mathcal{J}(x^*) = 0 \Rightarrow x^*$  extremum

minimum local •  $\exists B(x^*, r)$  tq  $\forall x \in B, \mathcal{J}(x^*) \leq \mathcal{J}(x)$

minimum global •  $\forall x, \mathcal{J}(x^*) \leq \mathcal{J}(x)$

On appelle direction admissible en  $x$ , tout vecteur  $d$  tq  $\exists h > 0 : [x; x+hd] \subset U$ . On note  $D(x)$  l'ensemble des directions admissibles.

Un vecteur  $d$  est une direction de descente pour une fonctionnelle  $\mathcal{J}$  au pt  $x$  si  $\forall \gamma, \exists h \in ]0; \gamma[$  tel que  $\mathcal{J}(x + hd) \leq \mathcal{J}(x)$ .

L'idée de l'algo. est de partir d'un pt  $x^{(0)}$  tq  $\nabla \mathcal{J}(x^{(0)}) \neq 0$  et de construire  $x^{(1)}$  en utilisant une direction de descente depuis  $x^{(0)}$ .

1°) DIRECTION

→ Cauchy :  $d = -\nabla \mathcal{J}(x)$

→ Newton :  $d = -H^{-1}(\mathcal{J}(x)) \nabla \mathcal{J}(x)$ , avec  $H$  définie positive

2°) PAS

→ Pas fixe : pas fixé, tjs le même

→ Pas Optimal : pas choisi à chaque itérat° tq :  $\mathcal{J}(x^{(0)} + \gamma d)$  soit optimal.

### \* Algo du gradient à pas fixe

Etape 1  $\rightarrow x^{(0)}$ , on calcule  $d_0 = -\nabla J(x^{(0)})^T$

$$\hookrightarrow x^{(1)} = x^{(0)} + h \times d_0$$

Etape k  $\rightarrow x^{(k)}$ , on calcule  $d_k = -\nabla J(x^{(k)})^T$

$$\hookrightarrow x^{(k+1)} = x^{(k)} + h \times d_k$$

Arrêt  $\rightarrow \|\nabla J(x^{(k)})\| \leq \epsilon_{\text{seuil}}$

### \* Algo du gradient à pas optimal

Etape 1  $\rightarrow x^{(0)}$ , on calcule  $d_0 = -\nabla J(x^{(0)})^T$

on calcule  $h_0 = \arg \left[ \min_{h \geq 0} J(x^{(0)} - h \times \nabla J(x^{(0)}))^T \right]$

rappel:  $z = |z| \mathcal{C}$   $\mathcal{C} = \arg(z)$

$$\hookrightarrow x^{(1)} = x^{(0)} + h_0 * d_0$$

Etape k  $\rightarrow x^{(k)}$ , on calcule  $d_k = -\nabla J(x^{(k)})^T$

on calcule  $h_k = \arg \left[ \min_{h \geq 0} J(x^{(k)} - h * \nabla J(x^{(k)}))^T \right]$

Arrêt  $\rightarrow \|\nabla J(x^{(k+1)})\| \leq \epsilon_{\text{seuil}}$

En général,  $\epsilon = 10^{-6} * \|\nabla J(x^{(0)})\|$

⚠ Vérifier que la solution n'est pas un pt selle.

Théorème : Si  $J(x) = \frac{1}{2} x^T A x - b^T x$  avec  $A$  sym. def. positive, la méthode du gradient à pas optimal converge vers l'optimum unique  $x^* = A^{-1}b$ .  
 De plus  $\|x^{(k+1)} - x^*\| \leq \|x^{(k)} - x^*\|^2 \frac{(\kappa(A)-1)^2}{\kappa(A)+1}$   
 où  $\kappa(A)$  est le conditionnement de  $A$  relativement à la norme 2.

\* Algo de Newton

Soit  $x^{(0)} \in U$ . Par Taylor, on a au voisinage de  $x^{(0)}$ .

$$J(x) \approx J(x^{(0)}) + \nabla J(x^{(0)}) [x - x^{(0)}] + \frac{1}{2} (x - x^{(0)})^T J''(x^{(0)}) (x - x^{(0)})$$

On minimise la fct<sup>o</sup> quadratique  $J^o$  et on obtient  $x^{(1)}$ :

$$x^{(1)} = x^{(0)} - [H(J(x^{(0)}))]^{-1} \nabla J(x^{(0)})^T$$

A l'étape  $k$ , on construit  $J^{(k)}$  que l'on minimise pour obtenir

$$x^{(k+1)} = x^{(k)} - [H(J(x^{(k)}))]^{-1} \nabla J(x^{(k)})^T$$

\* Algo du gradient conjugué

Etape 1 :  $x^{(0)}$ , on calcule  $d_0 = \nabla J(x^{(0)})^T$

A l'itération  $k$ , on calcule la valeur du pas

$$\rightarrow h_k = \frac{d_{k-1}^T \cdot \nabla J(x^{(k-1)})}{d_{k-1}^T \cdot H(J(x^{(k-1)})) d_{k-1}}$$

on calcule le nouveau point

$$\rightarrow x^{(k)} = x^{(k-1)} - h_k d_{k-1}$$

on calcule la nouvelle direction

$$\rightarrow d_k = \nabla J(x^{(k)}) - \frac{H(J(x^{(k)})) d_k}{H(J(x^{(k-1)}))}$$

Arrêt  $\| \nabla J(x^{(k)}) \| \leq \epsilon$  seuil.

\* Algo du gradient conjugué appliqué à la résolution d'un système linéaire.

1) On choisit un vecteur initial  $x^{(0)} \in \mathbb{R}^m$ .

On calcule le résidu

$$r_0 = Ax^{(0)} - b.$$

et la direction

$$d_0 = r_0.$$

2) \* A l'itération  $k \geq 1$ , on calcule la valeur de  $\alpha_k$

$$\alpha_k = \frac{d_{k-1}^T \cdot r_{k-1}}{d_{k-1}^T A d_{k-1}}$$

\* On calcule le nouveau point

$$x^{(k)} = x^{(k-1)} + \alpha_k d_{k-1}$$

\* On calcule le nouveau résidu

$$r_k = r_{k-1} - \alpha_k A d_{k-1}$$

\* On calcule la nouvelle direction

$$d_k = r_k - \frac{(A d_{k-1})^T r_k}{(A d_{k-1})^T d_{k-1}} d_{k-1}$$

3) A met lorsque

$$\|r_k\| < \epsilon_{\text{seuil}}$$

IV

Deux problèmes récurrents peuvent se poser lorsque on essaie de résoudre un système de grande taille :

- 1) la matrice n'est pas symétrique, ni définie positive
- 2) la matrice a un mauvais conditionnement

\* Matrice non symétrique.  $Ax = b$

↳ on résoud le système suivant :

$A^T A x = A^T b$  ( $\Leftrightarrow$  moindres carrés)

↳ autre solution : on pose  $x = A^T u$   
 $\Rightarrow A A^T u = b$

⚠ Dans les deux cas, si  $\kappa(A)$  est grand (mauvais conditionnement) alors  $AA^T$  et  $A^T A$  sont pires !!!

$\kappa_2(A^T A) = \kappa_2(A)^2$

\* Préconditionnement : On cherche  $C$  tq  $\left\{ \begin{array}{l} CA \text{ est bien conditionnée} \\ \text{produit } CA \text{ peut coûter} \end{array} \right.$

• Décomposition :  $C = (D + \omega L) D^{-1} (D + \omega U)$  avec  $\omega \sim 1$

et  $A = \begin{bmatrix} & & U \\ & D & \\ L & & \end{bmatrix}$

• Factorisation incomplète

$A = LU + R$   
 $\rightarrow C = U^{-1} L^{-1}$

• Inverse approchée : On cherche  $C$  qui minimise  $\|I - CA\|$   
 $\propto \|I - AC\|$

## \* Gradient Conjugué Préconditionné

Préconditionnement :  $Ax = b \Leftrightarrow \tilde{A}\tilde{x} = \tilde{b}$

où  $C$  est sym. def. positive :

$$\tilde{A} = C^{-1}AC^{-1}$$

$$\tilde{x} = Cx$$

$$\tilde{b} = C^{-1}b$$

### Algorithme amélioré

On prend  $M = C^2$  comme préconditionneur

et on note  $z^{(k)}$  solution de  $Mz^{(k)} = r^{(k)}$

$$x^{(0)} \text{ donné } \in \mathbb{R}^m$$

$$k = 0.$$

$$\text{Calculer } r^{(0)} = b - Ax^{(0)}$$

Tant que  $r^{(k)} \neq 0$  Faire.

$$\text{Résoudre } Mz^{(k)} = r^{(k)}$$

$$k = k + 1$$

Si  $k \neq 1$  alors

$$\beta_k = - \frac{(r^{(k-1)})^T z^{(k-1)}}{(r^{(k-2)})^T z^{(k-2)}}$$

$$p^{(k)} = z^{(k-1)} + \beta_k p^{(k-1)}$$

Si non

$$p^{(k)} = z^{(k)}$$

FinSi

$$\alpha_k = \frac{(r^{(k-1)})^T z^{(k-1)}}{(p^{(k)})^T A p^{(k)}}$$

$$x^{(k)} = x^{(k-1)} + \alpha_k p^{(k)}$$

$$r^{(k)} = r^{(k-1)} - \alpha_k A p^{(k)}$$

FinTantQue

$$x = x^{(k)}$$

## \* Raffinement itératif

↳ post-traitement des résultats pour corriger une partie des erreurs.

On suppose qu'au lieu de factoriser

$$A = LU, \text{ on a factorisé } \bar{A}$$

$$(A+E) = L_c U_c$$

et on a résolu exactement

$$(A+E) x_c = b.$$

$$\Rightarrow r_c = b - A x_c \neq 0.$$

On pose  $x^{(0)} = x_c$  et  $r^{(0)} = r_c$ . On introduit alors le processus suivant:

$$(A+E) e^{(k+1)} = r^{(k)}$$

$$x^{(k+1)} = (x^{(k)} + e^{(k+1)})$$

$$r^{(k+1)} = (b - A x^{(k+1)})$$

$$\Rightarrow x - x^{(k+1)} = (I - (A+E)^{-1}A) (x - x^{(k)})$$

Deux itérations de ce processus suffisent à nettement améliorer le résultat.

## \* Préconditionnement et erreurs de calcul.

$$\bullet \quad \frac{1}{K(A)} \cdot \frac{\|r^{(k)}\|}{\|r^{(0)}\|} \leq \frac{\|e^{(k)}\|}{\|e^{(0)}\|} \leq K(A) \frac{\|r^{(k)}\|}{\|r^{(0)}\|} \leq K^2(A) \frac{\|e^{(k)}\|}{\|e^{(0)}\|}$$

• Critère système d'arrêt : soit  $x + \Delta x$  solut° des système perturbé  $A + \Delta A$ .

On a la relation

$$\frac{\|r\|}{\|A\| \cdot \|x + \Delta x\|} \leq \frac{\|A + \Delta A\|}{\|A\|}$$

↳ petit  $\Rightarrow$  résultat acceptable.

On calcule alors le résidu selon la formule suivante:

$$r = b - A(x + \Delta x)$$