

car

(18)

$$\begin{aligned}
 J(x_k) - J(x_{k+1}) &= \frac{1}{2} (x_k - x_{k+1}) \cdot A (x_k - x_{k+1}) + r_{k+1} \cdot \underbrace{(x_{k+1} - x_k)}_{\alpha_k r_k} \\
 &= \frac{1}{2} (x_k - x_{k+1}) \cdot A (x_k - x_{k+1}) \\
 &\geq \frac{\rho}{2} \|x_k - x_{k+1}\|_2^2
 \end{aligned}$$

$(r_k, \alpha_k r_k) - \frac{\alpha_k^2}{2} (A r_k, r_k)$   
 $= \frac{\alpha_k}{2} \|r_k\|_2^2$

• Pour démontrer la conv. de cette méthode nous écrivons:

$$\begin{aligned}
 \alpha \|x_{k+1} - x\|_2^2 &\leq (x_k - x) \cdot A (x_k - x) \\
 &= (x_k - x) \cdot r_k \\
 &\leq \|x_k - x\| \cdot \|r_k\|_2
 \end{aligned}$$

$$\|x_{k+1} - x\|_2 \leq \frac{\|r_k\|_2}{\alpha} \quad (2^*)$$

Mais  $\|r_k\|_2^2 = r_k \cdot (r_k - r_{k+1}) \leq \|r_k\|_2 \|r_k - r_{k+1}\|_2$

Donc  $\|r_k\|_2 \leq \|r_k - r_{k+1}\|_2$

$$\begin{aligned}
 \Rightarrow \|x_{k+1} - x\|_2 &\leq \frac{\|r_k - r_{k+1}\|_2}{\alpha} \\
 &\leq \frac{c}{\alpha} \|x_k - x_{k+1}\|_2
 \end{aligned}$$

voir suite (18') - (18'')

$$\begin{aligned}
 r_k &= A x_k - b \\
 r_{k+1} &= A x_{k+1} - b \\
 \Rightarrow r_k - r_{k+1} &= A (x_k - x_{k+1}) \\
 \|r_k - r_{k+1}\|_2 &\leq \|A\| \|x_k - x_{k+1}\|_2
 \end{aligned}$$

• La méthode du Gradient conjugué: L'idée de base est de choisir un ensemble  $(f_1, \dots, f_n)$  composé de  $n$  vecteurs linéairement indépendants pour former une base de  $\mathbb{R}^n$  et puis on écrit la sol<sup>n</sup> de  $Ax = b$  (notée  $x^*$ ) en fct de cette base; i.e:

$$x^* = \sum_{j=1}^n \alpha_j^* f_j$$

• Pour calculer facilement les  $\alpha_j^*$  les vecteurs  $(f_1, \dots, f_n)$  sont choisis (19)  
 $A$  - conjugués i.e

$$f_i \cdot A f_l = 0 \quad i \neq l$$

Pour obtenir que

$$\boxed{\alpha_j^* = \frac{f_j \cdot b}{f_j \cdot A f_j}}$$

En effet :

$$f_j \cdot b = f_j \cdot A x^*$$

$$= f_j \cdot A \left( \sum_{i=1}^n \alpha_i^* f_i \right)$$

$$= \sum_{i=1}^n \alpha_i^* f_j \cdot A f_i = \alpha_j^* f_j \cdot A f_j$$

$$\Rightarrow \boxed{\alpha_j^* = \frac{f_j \cdot b}{f_j \cdot A f_j}}$$

L'itération est définie par :

$$\boxed{\begin{aligned} x_{(0)} &= 0 \\ x_k &= \sum_{j=1}^k \alpha_j^* f_j \quad k \geq 1 \end{aligned}}$$

i.e le passage de  $x_{k-1}$  à  $x_k$  et à partir du vecteur de direction  $f_k$ . Donc :

$$\boxed{x_k = x_{k-1} + \alpha_k^* f_k}$$

Géométriquement cela signifie :  
 1/ Choisir une direction de descente  $f_k$ .  
 2/ Minimiser  $J$  dans cette direction.

$$J(x_{k-1} + \alpha f_k) = \min_{\alpha \in \mathbb{R}} J(x_{k-1} + \alpha f_k)$$

or d'après (2\*):

$$J(x_{k-1} + \alpha f_k) = J(x_{k-1}) + \underbrace{\alpha (A x_{k-1} - b) \cdot f_k}_{-r_{k-1} \cdot f_k} + \frac{1}{2} \alpha^2 f_k^T A f_k$$

La direction la plus descendue est "Steepest descent":

$$-\nabla J(x_{k-1}) = b - A x_{k-1} = r_{k-1}$$

On peut essayer de choisir  $f_k = r_{k-1}$ , mais les  $f_j$  ne sont pas  $A$ -conjugués.

On écrit donc :

$$f_k = r_{k-1} - \sum_{j=1}^{k-1} \beta_j f_j$$

Le vecteur le plus proche de  $r_{k-1}$  ds  $\|\cdot\|_2$ .

$$\beta_j = \frac{f_j \cdot A r_{k-1}}{f_j \cdot A f_j}$$

Est ce qu'on a cv si  $f_k = 0$ ? oui parce que

$$f_k = 0 \Rightarrow r_{k-1} = \sum_{j=1}^{k-1} \beta_j f_j$$

$$r_{k-1} \cdot r_{k-1} = \left( \sum_{j=1}^{k-1} \beta_j f_j \right) \cdot r_{k-1} = 0 \Rightarrow r_{k-1} = 0$$

$$\Rightarrow A x_{k-1} = b \Rightarrow x_{k-1} = x^* \text{ donc la conv.}$$

Les résidus  $r_j$  sont orthogonaux ie :

$$r_j \cdot r_k = 0 \quad j < k$$

Donc l'algorithme est :

$$x_0 = 0$$

Pour  $k=1, \dots, n$  faire

$$r_{k-1} = b - A x_{k-1}$$

Si  $r_{k-1} = 0$  Alors écrire  $x_{k-1} = x^*$  et sortir.

$$\text{Si } k=1 \text{ Alors } f_1 = r_0$$

$$\text{Sinon } f_k = r_{k-1} - \sum_{j=1}^{k-1} \frac{f_j \cdot A r_{k-1}}{f_j \cdot A f_j} f_j$$

$$\alpha_k^* = \frac{b \cdot f_k}{f_k \cdot A f_k}$$

$$x_k = x_{k-1} + \alpha_k^* f_k$$

Remarque : Dans chaque itération on a un certain nombre de multiplication Matrice-Vecteur et les  $(f_i)_{i=1, n}$  doivent être tous sauvegardés

$\Rightarrow$  L'algorithme est moins efficace (manque d'efficacité)

• On peut de changement <sup>sont</sup> et nécessaire pour rendre cet algorithme efficace.

(1) On peut augmenter l'efficacité on observerons que :

$$f_j \cdot A r_{k-1} = 0 \quad j < k-1 \quad (*)$$

et l'expression des  $f_k$  ds l'algorithme devraient uniquement :

$$f_k = r_{k-1} - \frac{f_{k-1} \cdot A r_{k-1}}{f_{k-1} \cdot A f_{k-1}} f_{k-1}$$

(\*) vient de :

$$f_j \cdot A r_{k-1} = \alpha_j^* A f_j \cdot r_{k-1} / \alpha_j^*$$

$$= (A x_j - A x_{j-1}) \cdot r_{k-1} / \alpha_j^*$$

$$= (A x_j - b + b - A x_{j-1}) \cdot r_{k-1} / \alpha_j^*$$

$$= (-r_j + r_{j-1}) \cdot r_{k-1} / \alpha_j^* = 0$$

argument  
(2\*)

← (2) On peut aussi augmenter l'efficacité de l'algo. si on écrit :

$$(a) \quad \alpha_k^* = \frac{b \cdot f_k}{f_k \cdot A f_k} = \frac{(A x_{k-1} + r_{k-1}) \cdot f_k}{f_k \cdot A f_k} = \boxed{\frac{r_{k-1} \cdot f_k}{f_k \cdot A f_k}}$$

$$\text{car } \frac{A x_{k-1} \cdot f_k}{f_k \cdot A f_k} = \frac{x_{k-1} \cdot A f_k}{f_k \cdot A f_k} = \frac{\left( \sum_{j=1}^{k-1} \alpha_j^* f_j \right) \cdot A f_k}{f_k \cdot A f_k} = 0$$

Donc 
$$\alpha_k^* = \frac{r_{k-1} \cdot f_k}{f_k \cdot A f_k} = \frac{r_{k-1} \cdot (r_{k-1} - \sum_{j=1}^{k-2} \beta_j f_j)}{f_k \cdot A f_k}$$

$$= \frac{r_{k-1} \cdot r_{k-1}}{f_k \cdot A f_k}$$

2<sup>e</sup> expression de  $f_k$ :

(b) 
$$\frac{f_{k-1} \cdot A r_{k-1}}{f_{k-1} \cdot A f_{k-1}} = \frac{f_{k-1} \cdot A r_{k-1}}{f_{k-1} \cdot A r_{k-2}} \text{ puisque } f_{k-1} = r_{k-2} - \sum_{j=1}^{k-2} \beta_j f_j$$

$$= \frac{(r_{k-2} - r_{k-1}) \cdot r_{k-1}}{(r_{k-2} - r_{k-1}) \cdot r_{k-2}} \quad (\text{comme ds (2*)})$$

$$= - \frac{r_{k-1} \cdot r_{k-1}}{r_{k-2} \cdot r_{k-2}} \quad (\text{par l'orthogonalité des résidus}).$$

(c) 
$$r_k = r_{k-1} - \alpha_k^* \cdot A f_k \quad \left[ \begin{array}{l} \text{Ça vient de } x_k = x_{k-1} + \alpha_k^* f_k \\ b - A x_k = b - A x_{k-1} - \alpha_k^* A f_k \end{array} \right]$$

$r_k \qquad r_{k-1}$

La forme finale de l'algorithme du G.C.:

Maintenant notre algorithme peut être écrit sous une forme plus efficace comme suit : (forme finale):

$x_0 = 0$   
 $r_0 = b$   
 Pour  $k = 1, \dots, n$  faire  
     Si  $r_{k-1} = 0$  Alors Imprimer  $x_{k-1}^*$  et sortir  
     Si  $k = 1$  Alors  $f_1 = r_0$   
     Sinon  $f_k = r_{k-1} - \frac{r_{k-1} \cdot r_{k-1}}{r_{k-2} \cdot r_{k-2}} f_{k-1}$   
      $\alpha_k^* = \frac{r_{k-1} \cdot r_{k-1}}{f_k \cdot A f_k}$

$$x_k = x_{k-1} + \alpha_k^* f_k$$
$$r_k = r_{k-1} - \alpha_k^* A f_k$$

Fini k

Sortir  $x_k$

• Remarque : La seule matrice vecteur multiplication à faire c'est  $A f_k$  (dans chaque itération) et on sauvegarde les vecteurs  $x_k, r_k, f_k, A f_k$  et les scalaires  $r_k \cdot r_k, r_{k-1} \cdot r_{k-1}$ .

Convergence de la méthode G.C. : On remarque au départ que la recherche du minimum de  $J(\cdot)$   $\Leftrightarrow$  la recherche du minimum de  $E(\cdot)$  avec :

$$E(x) = \frac{1}{2} (x - x^*) \cdot A (x - x^*)$$
$$= \frac{1}{2} x \cdot Ax + \frac{1}{2} x^* \cdot Ax^* - x \cdot Ax^*$$
$$= J(x) + \underbrace{\frac{1}{2} x^* \cdot Ax^*}_{>0}$$

$E(\cdot)$  et  $J(\cdot)$  atteignent leur minimum au même point. Puisque  $Ax - Ax^* = Ax - b = -r(x)$  on peut écrire que :

$$E(x) = r(x) \cdot A^{-1} r(x) \quad \left\{ \begin{array}{l} x - x^* = -A^{-1} r(x) \\ = -r(x) \end{array} \right.$$

Donc

$$x_k = \sum_{j=1}^k \alpha_j^* f_j$$

$$(x^* - x_k) \cdot A (x^* - x_k) = \min_{x \in P_k} \{ (b - Ax) \cdot A^{-1} (b - Ax) \}$$
$$P_k = \left\{ \sum_{j=1}^k \alpha_j A^{j-1} b, (\alpha_j)_{j=1}^k \text{ q.l.q.} \right\} \quad \left( \begin{array}{l} \text{espace} \\ \text{Krylov} \end{array} \right. \text{ engendré par } b$$

Puisque

$$f_1 = b = (r_0)$$
$$f_2 = r_1 + (\text{termes en } f_1) = -Ab + [b \text{ term}]$$
$$f_3 = r_2 + (\text{termes en } f_1, f_2) = A^2 b + (b, Ab, \dots)$$

$\Rightarrow (\varphi_1, \dots, \varphi_k)$  et  $(b, Ab, A^2b, \dots, A^{k-1}b)$  engendre le même sous espace  $\mathcal{P}_k$ . (espace de Krylov engendré <sup>direct =  $K_k$  sous espace vect. de  $\mathbb{R}^n$</sup>  <sub>par  $b$</sub> )  $(x \in X_0 + K_k)$ .

$$\begin{aligned} (x^* - x_k) \cdot A(x^* - x_k) &= \min_{x \in \mathcal{P}_k} \{ (b - Ax) \cdot A^{-1}(b - Ax) \} \\ &= \min_{\gamma_1, \dots, \gamma_k} \left\{ \left( b - \sum_{j=1}^k \gamma_j A^j b \right) \cdot A^{-1} \left( b - \sum_{j=1}^k \gamma_j A^j b \right) \right\} \\ &= \min_{\gamma_1, \dots, \gamma_k} [P_k(A)b] \cdot A^{-1}[P_k(A)b] \end{aligned}$$

avec  $P_k(t) = 1 + \sum_{j=1}^k \gamma_j t^j$ ,  $P_k(0) = 1$ .

Si  $\lambda_j$  sont les valeurs propres de  $A$ ,  $u_j$  les vecteurs propres correspondants (orthogonaux) et  $b = \sum_{j=1}^n \eta_j u_j$

Alors

$$P_k(A)b = \sum_{j=1}^n P_k(\lambda_j) \eta_j u_j$$

$$A^{-1}[P_k(A)b] = \sum_{j=1}^n \frac{P_k(\lambda_j) \eta_j u_j}{\lambda_j}$$

et  $\{P_k(A)b\} \cdot A^{-1}\{P_k(A)b\} = \sum_{j=1}^n \frac{P_k(\lambda_j)^2}{\lambda_j} \eta_j^2$

Donc on a :

$$(x^* - x_k) \cdot A(x^* - x_k) = \min_{\gamma_i} \left\{ \sum_{j=1}^n \frac{P_k(\lambda_j)^2}{\lambda_j} \eta_j^2 \right\}$$

Le minimum est trouvé sur tous les polynômes  $P_k(t) \in \mathcal{P}_k$  qui satisfait  $P_k(0) = 1$ . Un certain nbre de remarque peuvent être faite à cette étape, concernant la conv. de la 1<sup>de</sup> du G.C

a) Si  $A$  a seulement  $\Delta$  valeurs propres distinctes  $\lambda_1, \dots, \lambda_\Delta$  ( $\Delta \leq n$ )

25

On peut trouver un polynôme de degré  $s$  qui a les  $(\lambda_i)_{i=1}^s$  comme racines et  $= 1$  en zéro i.e

$$P_s(t) = \frac{(\lambda_1 - t) \cdots (\lambda_s - t)}{\lambda_1 \lambda_2 \cdots \lambda_s}$$

tel que  $(x^* - x_s) \cdot A(x^* - x_s) = 0$  et la sol<sup>n</sup> est trouvée après  $s$  itérations.

b) Si les valeurs propres de  $A$  sont  $0 < \lambda_1 < \lambda_2 < \cdots < \lambda_n$ . On sait que le polynôme  $\{P_k(t)$  de degré  $k$  tq  $P_k(0) = 1\}$  qui a le plus petit maximum sur  $[\lambda_1, \lambda_n]$  est:

$$P_k^*(t) = T_k(\mu) = \frac{T_k\left(\frac{+2t + (\lambda_n + \lambda_1)}{\lambda_n - \lambda_1}\right)}{T_k\left(\frac{+ \lambda_n + \lambda_1}{\lambda_n - \lambda_1}\right)}, \quad T_k(0) = 1$$

$\mu \in [-1, 1]$   
 $\mu = \frac{-(\lambda_n + \lambda_1) + 2t}{\lambda_n - \lambda_1}$

et le max  $P_k^*(t)$  sur  $[\lambda_1, \lambda_n]$  est,  $|T_k(\mu)| = |\cos(k \arccos(\mu))| \leq 1$

$$\leq \frac{1}{T_k\left(\frac{+ \lambda_n + \lambda_1}{\lambda_n - \lambda_1}\right)}$$

Donc

$$\begin{aligned} (x^* - x_k) \cdot A(x^* - x_k) &\leq \frac{1}{\left\{T_k\left(\frac{\lambda_n + \lambda_1}{\lambda_n - \lambda_1}\right)\right\}^2} \sum_{j=1}^n \frac{\lambda_j^2}{\lambda_j} \\ &= \frac{1}{\left\{T_k\left(\frac{\lambda_n + \lambda_1}{\lambda_n - \lambda_1}\right)\right\}^2} b \cdot A^{-1} b \\ &\stackrel{(*)}{=} \frac{1}{\left\{T_k\left(\frac{\lambda_n + \lambda_1}{\lambda_n - \lambda_1}\right)\right\}^2} x^* A x^* \end{aligned}$$

Mais on a que  $\lambda_1 x \cdot x \leq x \cdot A x \leq \lambda_n x \cdot x \quad \forall x \in \mathbb{R}^n$

L'erreur relative décrit:

(26)

$$\frac{\|x^* - x_k\|_2}{\|x^*\|_2} \leq \frac{\lambda_n}{\lambda_1} \cdot \frac{1}{T_k\left(\frac{\lambda_n + \lambda_1}{\lambda_n - \lambda_1}\right)}$$

$$\rho = \frac{\lambda_n + \lambda_1}{\lambda_n - \lambda_1}$$

• On peut démontrer que  $T_k(\rho) \geq \frac{(\rho + \sqrt{\rho^2 - 1})^k}{2} \rightarrow$  exercice

Et parce que  $\frac{\lambda_n + \lambda_1}{\lambda_n - \lambda_1} + \sqrt{\left(\frac{\lambda_n + \lambda_1}{\lambda_n - \lambda_1}\right)^2 - 1} = \frac{\sqrt{\lambda_n} + \sqrt{\lambda_1}}{\sqrt{\lambda_n} - \sqrt{\lambda_1}} \geq 1$  (exercice)

$$\Rightarrow \frac{\|x^* - x_k\|_2}{\|x^*\|_2} \leq 2 \frac{\sqrt{\lambda_n}}{\sqrt{\lambda_1}} \left( \frac{\sqrt{\lambda_n} - \sqrt{\lambda_1}}{\sqrt{\lambda_n} + \sqrt{\lambda_1}} \right)^k \rightarrow \frac{1}{2} (\rho + \sqrt{\rho^2 - 1})^k$$

$$= 2\sqrt{K(A)} \left( \frac{\sqrt{K(A)} - 1}{\sqrt{K(A)} + 1} \right)^k \quad \left( K(A) = \frac{\lambda_n(A)}{\lambda_1(A)} \right)$$

↑  
erreur relative

- Remarques
- ① Il n'est pas nécessaire de connaître les valeurs propres de  $A$  pour appliquer la méthode du Gradient (pas de paramètre à estimer).
  - ② Il n'est pas nécessaire de commencer l'itération par  $x_0 = (0, \dots, 0)$ . Si une bonne approximation est connue on peut l'utiliser comme valeur initiale.

La méthode du Gradient conjugué préconditionnée:

Arithmétique inexacte  $\Rightarrow$  Perte de la propriété des  $f_j$ . ↗ d'A-conjugaison

- Conséquence:
- ① Convergence en  $n$  itérations ne pourra être réalisée quand  $n$  est assez grande.
  - ② Pour  $n$  assez grande, on espère que la méthode converge après  $k$  itérations  $k < n$ . Donc pour remédier l'effet des erreurs

$$M^{-1}Ax = \tilde{M}b \quad (*)$$

au lieu de  $Ax=b$  avec  $M$  est SDP facilement inversible choisie de telle manière que la méthode du Gradient conjugué converge plus rapide avec arithmétique inexacte.  $M$  s'appelle "matrice de préconditionnement".

On considère la connaissance de factorisation de Cholesky de  $M$ ;

$$M = U^T U \quad (Mz=d \text{ est simple à résoudre})$$

- Pour appliquer GC à (\*),  $M^{-1}A$  doit être symétrique. Donc au lieu d'appliquer la méthode du GC à (\*), on l'applique à :

$$U^{-T} A U^{-1} y = c \quad ; \quad c = U^{-T} b$$

(a)  $U^{-T} A U^{-1}$  est symétrique.

(b)  $U^{-T} A U^{-1}$  a les mêmes valeurs propres que  $M^{-1}A$ .

(parce que  $U^{-1} (U^{-T} A U^{-1}) U = M^{-1}A$ ).

- Si la sol<sup>n</sup> de ce système est  $y^* \Rightarrow \boxed{x^* = U^{-1} y^*}$  sol<sup>n</sup> de  $Ax=b$ .

Donc on applique l'algorithme du G-C au système :

$$\boxed{\hat{A} y = c}$$

$$\hat{A} = U^T A U^{-1}, \quad c = U^{-T} b$$

- choix de  $M$  : Parmi les choix très populaire de  $M$  c'est : SSOR d'Evans

$$M_{SSOR} = \frac{1}{\omega(2-\omega)} (D - \omega L) D^{-1} (D - \omega L^T)$$

↗ car rekr  
Sym. fin  
0 < ω < 2

- On constate que  $M$  est obtenue directement en fonction de  $A$  : Aucun calcul ni aucun stockage n'est nécessaire.

$$M_{SSOR} = U^T U, \quad L \cdot L^T$$

$$\boxed{U^T = \frac{(D - \omega L) D^{-1/2}}{\sqrt{\omega(2-\omega)}}$$

Lemme : Les valeurs propres de  $M_{SSOR}^{-1}A$  sont réelles et dans l'intervalle  $]0,1]$ .

(28)

Preuve : Posons  $U^T = \left(\frac{D}{\omega} - L\right) \left(\frac{\omega}{2-\omega}\right)^{\frac{1}{2}} D^{-\frac{1}{2}}$ . Alors  $M = UU^T$ .

Posons  $\tilde{D} = \frac{2-\omega}{\omega} D$  et  $\tilde{L} = \frac{1-\omega}{\omega} D + L$ .

Alors nous avons la relation :  $A = \tilde{D} - \tilde{L} - \tilde{L}^T$

$$\begin{aligned} \text{et } M &= \frac{1}{\omega(2-\omega)} (D - \omega L) D^2 (D - \omega L^T) \\ &\stackrel{+ \left(\frac{A\omega}{\omega}\right) D}{=} \left(\frac{1}{\omega} D - L\right) \left(\frac{\omega}{2-\omega}\right) D^{-1} \left(\frac{1}{\omega} D - L^T\right) \\ &= (\tilde{D} - \tilde{L})(\tilde{D}^{-1})(\tilde{D} - \tilde{L}^T) \\ &= \tilde{D} - \tilde{L} - \tilde{L}^T + \tilde{L} \tilde{D}^{-1} \tilde{L}^T = A + \tilde{L} \tilde{D}^{-1} \tilde{L}^T \geq A > 0 \quad (*) \end{aligned}$$

Soit  $(\lambda, u)$  un couple de valeur propre - vecteur propre de  $M^{-1}A$ ,  
alors  $M^{-1}Au = \lambda u$  donc

$$\begin{aligned} Au &= \lambda Mu \\ \Rightarrow (u, Au) &= \lambda (u, Mu) \Rightarrow 0 < \lambda = \frac{(u, Au)}{(u, Mu)} \leq 1 \\ &\text{d'après } (*). \end{aligned}$$

---