

ANALYSE NUMÉRIQUE SV

SYSTÈMES LINÉAIRES

Simone Deparis

EPFL Lausanne – MATH

Printemps 2021




CONVERGENCE : CONDITIONS SUFFISANTES



LA MÉTHODE DE RICHARDSON PRÉCONDITIONNÉE

RICHARDSON : CHOIX DE α_k



LA MÉTHODE DE RICHARDSON NON-PRÉCONDITIONNÉE

Si $P = I$ et A est symétrique définie positive, on trouve les méthodes :

- de **Richardson stationnaire** si on choisit :

$$\alpha_k = \alpha_{opt} = \frac{2}{\lambda_{min}(A) + \lambda_{max}(A)}. \quad (3)$$

- du **gradient** si :

$$\alpha_k = \frac{(r^{(k)})^T r^{(k)}}{(r^{(k)})^T A r^{(k)}}, \quad k \geq 0. \quad (4)$$

ALGORITHME DU GRADIENT PRÉCONDITIONNÉ

On peut réécrire plus efficacement la méthode du gradient préconditionné de la manière suivante : soit $x^{(0)}$, poser $r^{(0)} = b - Ax^{(0)}$, puis pour $k \geq 0$,

$$\begin{aligned} Pz^{(k)} &= r^{(k)} \\ \alpha_k &= \frac{(z^{(k)})^T r^{(k)}}{(z^{(k)})^T A z^{(k)}} \\ x^{(k+1)} &= x^{(k)} + \alpha_k z^{(k)} \\ r^{(k+1)} &= r^{(k)} - \alpha_k A z^{(k)}. \end{aligned}$$



CONVERGENCE DE LA MÉTH. DE RICHARDSON

Considérons tout d'abord les méthodes de Richardson stationnaires ; on a le résultat de convergence suivant :

THÉORÈME (CAS STATIONNAIRE)

On suppose la matrice P inversible et les valeurs propres de $P^{-1}A$ strictement positives et telles que $\lambda_{\max} = \lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n = \lambda_{\min} > 0$. Alors la méthode de Richardson stationnaire est convergente si et seulement si $0 < \alpha < 2/\lambda_1$. De plus, le rayon spectral de la matrice d'itération R_α est minimal si $\alpha = \alpha_{\text{opt}}$

$$\alpha_{\text{opt}} = \frac{2}{\lambda_{\min} + \lambda_{\max}},$$

avec

$$\rho_{\text{opt}} = \frac{\lambda_{\max} - \lambda_{\min}}{\lambda_{\min} + \lambda_{\max}}$$

Dans le cas dynamique, on a un résultat qui permet de choisir de façon optimale le paramètre d'accélération à chaque étape, si la matrice A est symétrique définie positive :

THÉORÈME (CAS DYNAMIQUE)

Si A est symétrique définie positive, le choix optimal de α_k est donné par

$$\alpha_k = \frac{(r^{(k)}, z^{(k)})}{(Az^{(k)}, z^{(k)})}, \quad k \geq 0 \quad (5)$$

où

$$z^{(k)} = P^{-1}r^{(k)}. \quad (6)$$

Pour le cas stationnaire et pour le cas dynamique on peut démontrer que, si A et P sont symétriques définies positives, la suite $\{x^{(k)}\}$ donnée par la méthode de Richardson (stationnaire et dynamique) converge vers x lorsque $k \rightarrow \infty$, et

$$\|x^{(k)} - x\|_A \leq \left(\frac{K(P^{-1}A) - 1}{K(P^{-1}A) + 1} \right)^k \|x^{(0)} - x\|_A, \quad k \geq 0, \quad (7)$$

où $\|v\|_A = \sqrt{v^T A v}$ et $K(P^{-1}A)$ est le conditionnement de la matrice $P^{-1}A$:

$$K(C) = \sqrt{\frac{\lambda_{\max}(C^T C)}{\lambda_{\min}(C^T C)}}$$

Remarque. Dans le cas de la méthode du gradient ou de Richardson stationnaire l'estimation de l'erreur devient

$$\|x^{(k)} - x\|_A \leq \left(\frac{K(A) - 1}{K(A) + 1} \right)^k \|x^{(0)} - x\|_A, \quad k \geq 0. \quad (8)$$

Remarque. Si A et P sont symétriques définies positives, on a

$$K(P^{-1}A) = \frac{\lambda_{\max}(P^{-1}A)}{\lambda_{\min}(P^{-1}A)}.$$



LA MÉTHODE DU GRADIENT CONJUGUÉ

Une méthode encore plus rapide dans le cas où P et A sont **symétriques définies positives** est celle du **gradient conjugué préconditionné** qui s'exprime ainsi :
soit $x^{(0)}$ une donnée initiale ; on calcule $r^{(0)} = b - Ax^{(0)}$, $z^{(0)} = P^{-1}r^{(0)}$,
 $p^{(0)} = z^{(0)}$, puis pour $k \geq 0$,

$$\begin{aligned}\alpha_k &= \frac{p^{(k)T} r^{(k)}}{p^{(k)T} A p^{(k)}} \\ x^{(k+1)} &= x^{(k)} + \alpha_k p^{(k)} \\ r^{(k+1)} &= r^{(k)} - \alpha_k A p^{(k)} \\ P z^{(k+1)} &= r^{(k+1)} \\ \beta_k &= \frac{(A p^{(k)})^T z^{(k+1)}}{(A p^{(k)})^T p^{(k)}} \\ p^{(k+1)} &= z^{(k+1)} - \beta_k p^{(k)}.\end{aligned}$$

Dans ce cas, l'estimation de l'erreur est donnée par

$$\|x^{(k)} - x\|_A \leq \frac{2c^k}{1 + c^{2k}} \|x^{(0)} - x\|_A, \quad k \geq 0 \quad \text{où} \quad c = \frac{\sqrt{K_2(P^{-1}A)} - 1}{\sqrt{K_2(P^{-1}A)} + 1}. \quad (9)$$

