
Méthodes numériques et conditionnement pour les systèmes d'équations linéaires

4.1 Système d'équations linéaires

Définition 4.1.1 Soit n et m deux entiers naturels non nuls. Un système linéaire de n équations à m inconnues x_1, \dots, x_m est un système (S) de la forme:

$$\left\{ \begin{array}{l} a_{11} x_1 + a_{12} x_2 + \dots + a_{1j} x_j + \dots + a_{1m} x_m = b_1 \\ \cdot \\ \cdot \\ \cdot \\ \cdot \\ a_{i1} x_1 + a_{i2} x_2 + \dots + a_{ij} x_j + \dots + a_{im} x_m = b_i \\ \cdot \\ \cdot \\ \cdot \\ \cdot \\ a_{n1} x_1 + a_{n2} x_2 + \dots + a_{nj} x_j + \dots + a_{nm} x_m = b_n \end{array} \right. \quad (S)$$

où les a_{ij} ($1 \leq i \leq n$, $1 \leq j \leq m$) et les b_k ($1 \leq k \leq n$) sont des éléments de \mathbb{k} fixés.

Notation 4.1.1 On note $A = [a_{ij}]_{\substack{1 \leq i \leq n \\ 1 \leq j \leq m}}$ la matrice du système (S) .

Forme matricielle: Si on note $x = \begin{pmatrix} x_1 \\ \cdot \\ \cdot \\ x_n \end{pmatrix}$ et $b = \begin{pmatrix} b_1 \\ \cdot \\ \cdot \\ b_n \end{pmatrix}$ le système (S) s'écrit :

$$Ax = b.$$

Exemple 4.1.1 On considère le système (S) de deux équations à trois inconnues :

$$\begin{cases} x_1 - 2x_2 = 1 \\ x_2 - 3x_3 = 2 \end{cases} \quad (\text{S})$$

La matrice A de ce système est :

$$A = \begin{pmatrix} 1 & -2 & 0 \\ 0 & 1 & -3 \end{pmatrix}$$

et la forme matricielle est donc :

$$\begin{pmatrix} 1 & -2 & 0 \\ 0 & 1 & -3 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = \begin{pmatrix} 1 \\ 2 \end{pmatrix}$$

4.1.1 Conditionnement d'un système d'équations linéaires

Définition 4.1.2 Soit $A \in \mathbf{M}_n(\mathbb{k})$ une matrice inversible. Le nombre noté $\text{cond}(A) = \|A\| \cdot \|A^{-1}\|$ est appelé le conditionnement de la matrice A , relativement à la norme matricielle considérée.

Théorème 4.1.1 Soient $A \in \mathbf{M}_n(\mathbb{k})$ une matrice inversible, b un vecteur non nul.

1- Soient $x, x + \delta x$ les solutions des systèmes $Ax = b$ et $A(x + \delta x) = b + \delta b$.

On suppose que $b \neq 0$, alors on a :

$$\frac{\|\delta x\|}{\|x\|} \leq \text{cond}(A) \frac{\|\delta b\|}{\|b\|} \quad (4.1.1)$$

et c'est la meilleure possible (c'est-à-dire : $\exists b \neq 0$ et $\delta b \neq 0$ tels que (3.1) devienne égalité).

2- Soient $x, x + \delta x$ les solutions des systèmes $Ax = b$ et $(A + \delta A)(x + \delta x) = b$.

On suppose que $b \neq 0$, alors on a :

$$\frac{\|\delta x\|}{\|x + \delta x\|} \leq \text{cond}(A) \frac{\|\delta A\|}{\|A\|} \quad (4.1.2)$$

et c'est la meilleure possible (c'est-à-dire : $\exists b \neq 0$ et $\delta b \neq 0$ tels que (3.2) devienne égalité).

Preuve 1- Soient $Ax = b$ et $A(x + \delta x) = b + \delta b$, d'où $A^{-1}b = x$, $A\delta x = \delta b$ et $A^{-1}\delta b = \delta x$.

On a : $\|b\| = \|Ax\| \leq \|A\| \|x\|$, ce qui implique

$$\|x\| \geq \frac{\|b\|}{\|A\|} \quad (*)$$

et

$$\frac{\|\delta x\|}{\|x\|} = \frac{\|A^{-1}\delta b\|}{\|x\|} \leq \frac{\|A^{-1}\| \|\delta b\|}{\|x\|}$$

D'après (*), il vient

$$\frac{\|\delta x\|}{\|x\|} \leq \frac{\|A^{-1}\| \|\delta b\|}{\|x\|} \leq \|A^{-1}\| \cdot \|\delta b\| \cdot \frac{\|A\|}{\|b\|}$$

ce qui implique

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

Pour vérifier que c'est la meilleure, prendre $b \neq 0$ et $\delta b \neq 0$ tels que

$$\|A^{-1}\delta b\| = \|A^{-1}\| \|\delta b\|$$

on a l'égalité dans (3.1).

2- On a : $(A + \delta A)(x + \delta x) = b$ implique $\delta x = -A^{-1}\delta A(x + \delta x)$ ce qui implique

$$\|\delta x\| \leq \|A^{-1}\| \cdot \|\delta A\| \|x + \delta x\|$$

d'où

$$\frac{\|\delta x\|}{\|x + \delta x\|} = \frac{\|A^{-1}\delta A(x + \delta x)\|}{\|x + \delta x\|} \leq \|A^{-1}\| \cdot \|\delta A\| = \text{cond}(A) \frac{\|\delta A\|}{\|A\|}$$

Pour vérifier que c'est la meilleure, prendre un vecteur $y \neq 0$ tel que :

$$\|A^{-1}y\| = \|A^{-1}\| \cdot \|y\| \quad (**)$$

et un scalaire $\beta \neq 0$. et on prend alors : $b = (A + \beta I_n)y$, $\delta A = \beta I_n$ et $\delta x = -\beta A^{-1}y$, ce qui implique $x + \delta x = y$, $Ax = b$ et $(A + \delta A)(x + \delta x) = (A + \beta I_n)y = b$.

D'où d'après (**):

$$\|\delta x\| \leq |\beta| \cdot \|A^{-1}y\| = \|A^{-1}\| \cdot \|y\| = \|A^{-1}\| \cdot \|\delta A\| \|x + \delta x\|.$$

De plus si β n'est pas une valeur propre de A , alors $b \neq 0$.

Exercice 4.1.1 1- Pour toute matrice A inversible. Montrer que

- $\text{cond}(A) \geq 1$
- $\text{cond}(A) = \text{cond}(A^{-1})$
- $\text{cond}(\alpha A) = \text{cond}(A)$ pour tout $\alpha \geq 0$.

2- On désigne par $\text{cond}_2(A)$ le conditionnement de la matrice A , relatif à la norme euclidienne. Montrer que

Si A est une matrice normale (c'est-à-dire $A \times A^T = A^T \times A$),

$$\text{cond}_2(A) = \frac{\max_i |\lambda_i(A)|}{\min_i |\lambda_i(A)|},$$

où les $\lambda_i(A)$ sont les valeurs propres de la matrice A .

- Si A est une matrice unitaire (c'est-à-dire $A \times A^* = A^* \times A = I_n$) ou orthogonale (c'est-à-dire $A \times A^T = A^T \times A = I_n$), alors :

$$\text{cond}_2(A) = 1.$$

4.2 Méthodes itératives

On va voir un type de méthodes itératives de résolution du système $Ax = b$.

Soit la forme matricielle $Ax = b$ avec $A \in \mathbf{M}_n(\mathbb{k})$, $\det(A) \neq 0$ et $b \in \mathbb{k}^n$. Une méthode itérative se présente sous la forme

$$\left\{ \begin{array}{l} x^{(0)} \text{ vecteur arbitraire,} \\ x^{(k+1)} = Bx^{(k)} + c, \quad k \geq 0 \end{array} \right. \quad (4.2.1)$$

avec $B \in \mathbf{M}_n(\mathbb{k})$ en fonction de A et b , c un vecteur de \mathbb{k}^n construit à partir de b .

4.2.1 Convergence des méthodes itératives

Définition 4.2.1 La méthode itérative (3.2) est dite convergente si pour tout $x^{(0)}$

$$\lim_{k \rightarrow +\infty} x^{(k)} = x^*$$

où x^* est la solution de $Ax = b$.

Remarque 4.2.1 1- On a alors $x^* = Bx^* + c$.

2- Si on pose $e^{(k)} = x^{(k)} - x^*$, pour $k \geq 0$

Comme

$$\begin{cases} x^* = Bx^* + c \\ \text{et} \\ x^{(k+1)} = Bx^{(k)} + c \end{cases},$$

on a

$$e^{(k)} = Bx^{(k-1)} - Bx^* = Be^{(k-1)} = \dots = B^k e^{(0)}$$

de plus $\lim_{k \rightarrow +\infty} x^{(k)} = x^*$ équivaut à $\lim_{k \rightarrow +\infty} e^{(k)} = 0$ équivaut à $\lim_{k \rightarrow +\infty} B^k e^{(0)} = 0$.

Donc la méthode itérative (3.2) est convergente si

$$\lim_{k \rightarrow +\infty} B^k v = 0, \forall v$$

ce qui est équivaut à

$$\lim_{k \rightarrow +\infty} \|B^k v\| = 0, \forall v$$

pour toute norme vectorielle $\|\cdot\|$.

Critère de convergence des méthodes itératives

Théorème 4.2.1 Les propositions suivantes sont équivalentes :

(i) La méthode (3.2) est convergente vers x^* tel que $x^* = Bx^* + c$;

(ii) $\rho(B) < 1$;

(iii) $\|B\| < 1$ pour au moins une norme matricielle $\|\cdot\|$.

Preuve (i) \implies (ii)

Supposon que $\rho(B) \geq 1$, $\rho(B) = |\lambda|$, donc il existe un vecteur q tels que :

$$q \neq 0, Bq = \lambda q \text{ et } |\lambda| \geq 1$$

ce qui implique

$$\forall k \geq 0, \|B^k q\| = \|\lambda^k q\| = |\lambda^k| \|q\| = |\lambda|^k \|q\| \geq \|q\|$$

ce qui contredit

$$\lim_{k \rightarrow +\infty} \|B^k q\| = 0.$$

(ii) \implies (iii)

D'après le théorème (2.3) : $\forall \epsilon > 0$, il existe au moins une norme matricielle subordonnée telle que :

$$\|B\| \leq \rho(B) + \epsilon$$

(iii) \implies (i) Soit $\|\cdot\|$ une norme matricielle subordonnée, d'après la Proposition 2.6,

$$\forall k \geq 0, \forall v \in \mathbb{k}^n, 0 \leq \|B^k v\| \leq \|B^k\| \|v\| \leq \|B\|^k \|v\|.$$

Puisque $\|B\| < 1$, alors

$$\lim_{k \rightarrow +\infty} \|B\|^k = 0$$

ce qui implique

$$\lim_{k \rightarrow +\infty} \|B^k v\| = 0.$$

4.2.2 Quelques méthodes itératives particulières

On décompose A sous la forme $A = M - N$ avec M facile à inverser. Alors :

$$Ax = b \text{ si et seulement si } x = M^{-1}.N.x + M^{-1}.b$$

ce qui équivaut à

$$x = B.x + c$$

avec

$$\begin{cases} B = M^{-1}.N \\ \text{et} \\ c = M^{-1}.b \end{cases},$$

et on s'intéresse à la méthode itérative (3.2).

Pratiquement, on résout les systèmes linéaires successifs :

$$\text{pour } k \geq 0, M.x^{(k+1)} = N.x^{(k)} + b.$$

a). Méthode de Jacobi

On suppose que $a_{ii} \neq 0$, $i = 1, \dots, n$.

On décompose A sous la forme $A = D - (E + F)$ avec

$$\begin{cases} M = D = \text{diag}(a_{ii}) \text{ (c'est-à-dire diagonale de } A) \\ \text{et} \\ N = E + F \end{cases}$$

où

$$E = \begin{cases} -a_{ij}, & \text{si } i > j \\ 0, & \text{ailleurs} \end{cases}$$

et

$$F = \begin{cases} -a_{ij}, & \text{si } i < j \\ 0, & \text{ailleurs} \end{cases}$$

En partant de $Bx^{(k)} + c$ avec

$$\begin{cases} B = M^{-1}.N = D^{-1}.(E + F) \\ \text{et} \\ c = D^{-1}.b \end{cases},$$

on obtient l'algorithme suivant :

Algorithme 4.2.1

$$\begin{cases} x^{(0)} \text{ donnée initiale} \\ \vdots \\ x^{(k+1)} = J.x^{(k)} + c, \quad k \geq 0 \end{cases}$$

où $J = D^{-1}.(E + F) = I_n - D^{-1}.A$ est appelée *matrice de Jacobi*.

En posant $x^{(k)} = (x_1^{(k)}, x_2^{(k)}, \dots, x_n^{(k)})$, on est conduit à résoudre $D.x^{(k+1)} = (D - A).x^{(k)} + b$ c'est-à-dire le système suivant :

$$\begin{cases} a_{11} x_1^{(k+1)} = -a_{12} x_2^{(k)} - a_{13} x_3^{(k)} - \dots - a_{1n} x_n^{(k)} + b_1 \\ \vdots \\ a_{22} x_2^{(k+1)} = -a_{21} x_1^{(k)} - a_{23} x_3^{(k)} - \dots - a_{2n} x_n^{(k)} + b_2 \\ \vdots \\ \vdots \\ a_{nn} x_n^{(k+1)} = -a_{n1} x_1^{(k)} - a_{n2} x_2^{(k)} - \dots - a_{nn-1} x_{n-1}^{(k)} + b_n \end{cases}$$

b). Méthode de Gauss-Seidel

Posons $M = D - E$, $N = F$, et $G = M^{-1}.N = (D - E)^{-1}.F$.

On pourrait améliorer la méthode précédente en utilisant les quantités déjà calculées

:

$$\left\{ \begin{array}{l} a_{11} x_1^{(k+1)} = -a_{12} x_2^{(k)} - a_{13} x_3^{(k)} - \dots - a_{1n} x_n^{(k)} + b_1 \\ \cdot \\ a_{22} x_2^{(k+1)} = -a_{21} x_1^{(k)} - a_{23} x_3^{(k)} - \dots - a_{2n} x_n^{(k)} + b_2 \\ \cdot \\ \cdot \\ \cdot \\ a_{nn} x_n^{(k+1)} = -a_{n1} x_1^{(k)} - a_{n2} x_2^{(k)} - \dots - a_{nn-1} x_{n-1}^{(k)} + b_n \end{array} \right.$$

ce qui revient à écrire l'algorithme suivant :

Algorithme 4.2.2

$$\left\{ \begin{array}{l} x^{(0)} \text{ donnée initiale} \\ D.x^{(k+1)} = E.x^{(k+1)} + F.x^{(k)} + b \end{array} \right.$$

ou encore

$$\left\{ \begin{array}{l} x^{(0)} \text{ donnée initiale} \\ x^{(k+1)} = G.x^{(k)} + (D - E)^{-1} b \end{array} \right.$$

où $G = (D - E)^{-1} \cdot F$ est appelée matrice de Gauss-Seidel. Elle est inversible si $a_{ii} \neq 0$, $i = 1, \dots, n$.

c). Méthode de relaxation

Pour $\omega \neq 0$, en posant $M = \frac{1}{\omega} D - E$, $N = \left(\frac{1-\omega}{\omega}\right) D + F$, et $R_\omega = M^{-1}N = \left(\frac{1}{\omega} D - E\right)^{-1} \left(\frac{1-\omega}{\omega} D + F\right)$, on a

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

et

$$\left\{ \begin{array}{l} a_{11} x_1^{(k+1)} = a_{11} x_1^{(k)} - \omega \left\{ a_{11} x_1^{(k)} + a_{12} x_2^{(k)} + \dots + a_{1n} x_n^{(k)} \right\} + \omega b_1 \\ \cdot \\ a_{22} x_2^{(k+1)} = a_{22} x_2^{(k)} - \omega \left\{ a_{21} x_1^{(k)} + a_{22} x_2^{(k)} + \dots + a_{2n} x_n^{(k)} \right\} + \omega b_2 \\ \cdot \\ \cdot \\ \cdot \\ a_{nn} x_n^{(k+1)} = a_{nn} x_n^{(k)} - \omega \left\{ a_{n1} x_1^{(k)} + a_{n2} x_2^{(k)} + \dots + a_{nn} x_n^{(k)} \right\} + \omega b_n \end{array} \right.$$

ce qui revient à écrire l'algorithme suivant :

Algorithme 4.2.3

$$\left\{ \begin{array}{l} x^{(0)} \text{ donnée initiale} \\ \left(\frac{1}{\omega} D - E \right) .x^{(k+1)} = \left(\frac{1-\omega}{\omega} .D + F \right) .x^{(k)} + b \end{array} \right.$$

ou encore

$$\left\{ \begin{array}{l} x^{(0)} \text{ donnée initiale} \\ x^{(k+1)} = R_\omega .x^{(k)} + \left(\frac{1}{\omega} D - E \right)^{-1} b \end{array} \right.$$

où $R_\omega = \left(\frac{1}{\omega} D - E \right)^{-1} \left(\frac{1-\omega}{\omega} .D + F \right)$ est appelée matrice de relaxation.

Remarque 4.2.2 1- Pour $\omega = 1$, $R_\omega = G$.

2- Comme $a_{ii} \neq 0$ pour tout i , $\left(\frac{1}{\omega} D - E \right)$ est inversible.

3- Lorsque $\omega > 1$, on parle de sur-relaxation.

4- Lorsque $\omega < 1$, on parle de sous-relaxation.

4.2.3 Convergence des méthodes de Jacobi, de Gauss-Seidel, et relaxation

Théorème 4.2.2 Soit A une matrice symétrique définie positive, décomposée sous la forme $A = M - N$ avec M inversible.

Si la matrice symétrique $M^T + N$ est définie positive, alors :

$$\rho(M^{-1}.N) < 1.$$

Preuve 1- $M^T + N$ est symétrique car : $A = M - N$ implique $M = A + N$ ce qui implique $M^T = A^T + N^T$,

Puisque A symétrique, donc

$$M^T + N = A^T + N^T + N = A + N^T + N = M + N^T.$$

2- Comme A est symétrique définie positive, l'application

$$v \in \mathbb{R}^n \longrightarrow \|v\| = (v^T A v)^{\frac{1}{2}}$$

définit une norme sur \mathbb{R}^n .

On considère alors la norme matricielle $\|\cdot\|$ induite par cette norme vectorielle.

$$\|M^{-1}.N\| = \|I_n - M^{-1}.A\| = \sup_{\|v\|=1} \|v - M^{-1}.Av\|$$

Soit v un vecteur tel que $\|v\| = 1$. On pose $w = M^{-1}.Av$, on a

$$\begin{aligned} \|v - w\|^2 &= (v - w)^T A (v - w) = 1 - v^T .Aw - w^T .Av + w^T .Aw \\ &= 1 - w^T .M^T w - w^T .Mw + w^T .Aw \\ &= 1 - w^T (M^T + N) w. \end{aligned}$$

Si $v \neq 0$, alors $w = M^{-1}.Av \neq 0$. D'où

$$w^T (M^T + N) w > 0.$$

Donc si la matrice symétrique $M^T + N$ est définie positive, on a

$$\|v - w\|^2 = 1 - w^T (M^T + N) w < 1.$$

Exemple 4.2.1 Soit

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

1- Pour tout $v \in \mathbb{R}^n$,

$$v^T A v = v_1^2 + v_n^2 + \sum_{i=2}^n (v_i + v_{i-1})^2 > 0, \quad v \neq 0,$$

donc la matrice symétrique A est définie positive.

2- Pour la méthode de Jacobi : on prend

$$\begin{cases} M = D \\ N = E + F \end{cases}$$

$A = M - N$ est symétrique définie positive, car

$$v^T (M^T + N) v = v_1^2 + v_n^2 + \sum_{i=2}^n (v_i + v_{i-1})^2 > 0, \quad v \neq 0.$$

$M^T + N$ est définie positive ce qui implique

$$\rho(M^{-1}.N) < 1.$$

Théorème 4.2.3 (Ostrowski-Reich) (**Conditions suffisante de convergence de la méthode de relaxation**)

Si A est symétrique définie positive, la méthode de relaxation converge pour $\omega \in]0, 2[$.

Preuve On applique le théorème précédent.

On a $A = M - N$ avec

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

Comme $E^T = F$, alors

$$\begin{aligned} M^T + N &= \frac{1}{\omega} D - E^T + \left(\frac{1-\omega}{\omega} \right) D + F \\ &= \frac{1}{\omega} D + \left(\frac{1-\omega}{\omega} \right) D \\ &= \left(\frac{2-\omega}{\omega} \right) D \end{aligned}$$

Puisque $\omega \in]0, 2[$, alors

$$\left(\frac{2-\omega}{\omega}\right) > 0.$$

Donc $M^T + N = \left(\frac{2-\omega}{\omega}\right) D$ est définie positive.

Théorème 4.2.4 (*Conditions nécessaire de convergence de la méthode de relaxation*)

1- Le rayon spectral de la matrice de relaxation est tel que $\rho(R_\omega) \geq |\omega - 1|$.

2- Ainsi, si $\omega \notin]0, 2[$, la méthode de relaxation ne converge pas.

Preuve On a $R_\omega = \left(\frac{1}{\omega}D - E\right)^{-1} \left(\left(\frac{1-\omega}{\omega}\right)D + F\right) = M^{-1}N$. Alors

$$\begin{aligned} \prod_{i=1}^n \lambda_i(R_\omega) &= \det(R_\omega) = \det(M^{-1}N) = \frac{\det(N)}{\det(M)} \\ &= \frac{\det\left(\left(\frac{1-\omega}{\omega}\right)D + F\right)}{\det\left(\frac{1}{\omega}D - E\right)} \\ &= \frac{\left(\frac{1-\omega}{\omega}\right)^n \det D}{\frac{1}{\omega^n} \det D} = (1-\omega)^n. \end{aligned}$$

On en déduit que

$$(\rho(R_\omega))^n \geq \prod_{i=1}^n |\lambda_i(R_\omega)| = |1-\omega|^n,$$

donc $\rho(R_\omega) \geq |1-\omega|$ et la méthode de relaxation ne peut converger que pour $\omega \in]0, 2[$.

Exercice 4.2.1 Soit A une matrice hermitienne définie positive. Montrer que pour tout $\omega \in]0, 2[$, la méthode de relaxation converge.

4.2.4 Autres méthodes itératives :

Méthode du gradient à pas fixe

L'algorithme du gradient à pas fixe généralement est donné comme suit :

Algorithme 4.2.4

$$\begin{cases} x^{(0)} \text{ donnée initiale} \\ x^{(k+1)} = x^{(k)} - \alpha \cdot (A \cdot x^{(k)} - b), \quad k \geq 0, \end{cases}$$

où α est une constante fixée.

Si on pose $r^{(k)} = A.x^{(k)} - b$, on a

$$x^{(k+1)} = x^{(k)} - \alpha.r^{(k)}$$

ce qui implique

$$r^{(k+1)} = r^{(k)} - \alpha.A.r^{(k)} = (I_n - \alpha.A).r^{(k)}.$$

Condition nécessaire et suffisante de convergence : La méthode du gradient à pas fixe est convergente si

$$\rho(I_n - \alpha.A) < 1.$$

Proposition 4.2.1 *Si la matrice A est symétrique définie positive alors la méthode du gradient à pas fixe converge si et seulement si*

$$0 < \alpha < \frac{2}{\lambda_n}$$

avec λ_n la plus grande valeur propre de A .

De plus $\alpha = \frac{2}{\lambda_1 + \lambda_n}$ est une valeur optimale (c'est-à-dire que $I_n - \alpha.A$ a le plus petit rayon spectral).

Méthode du gradient à pas optimal

On considère le système suivant :

$$\begin{cases} x^{(0)} \text{ donnée initiale} \\ x^{(k+1)} = x^{(k)} - \alpha_k.(A.x^{(k)} - b), \quad k \geq 0, \end{cases}$$

où α_k est choisi tel que :

$$r^{(k+1)} \perp r^{(k)}$$

avec $r^{(k)} = A.x^{(k)} - b$. Donc $r^{(k+1)} = r^{(k)} - \alpha_k.A.r^{(k)}$.

$r^{(k+1)} \perp r^{(k)}$ équivaut dire que $\langle r^{(k)} - \alpha_k.A.r^{(k)}, r^{(k)} \rangle = 0$ équivaut à

$$\alpha_k = \frac{\|r^{(k)}\|_2^2}{\langle r^{(k)} A, r^{(k)} \rangle}$$

Algorithme 4.2.5 *L'algorithme de la méthode du gradient à pas optimal est donné par :*

(0) $k = 0$

$x^{(0)}$ donnée initiale

(1) calcul de $r^{(k)} = A.x^{(k)} - b$

(2) Si $r^{(k)} = 0$, c'est terminé.

(3) Si $r^{(k)} \neq 0$, on calcul :

$$\alpha_k = \frac{\|r^{(k)}\|_2^2}{\langle A.r^{(k)}, r^{(k)} \rangle}$$

et

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

(4) $k := k + 1$ et aller à (1).

Exemple 4.2.2

$$A = \begin{pmatrix} 2 & 1 \\ 1 & 3 \end{pmatrix}, \quad b = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$$

La solution du système $Ax = b$ est $x = \begin{pmatrix} \frac{3}{5} \\ -\frac{1}{5} \end{pmatrix}$.

Les valeurs propres de la matrice A sont:

$$\begin{cases} \lambda_1 = \frac{5}{2} - \frac{1}{2}\sqrt{5} > 0 \\ \text{et} \\ \lambda_2 = \frac{5}{2} + \frac{1}{2}\sqrt{5} > 0 \end{cases}.$$

Remarquons que A est symétrique car

$$A = A^T = \begin{pmatrix} 2 & 1 \\ 1 & 3 \end{pmatrix},$$

de plus, elle est définie positive (Proposition 2.5). Donc A est symétrique définie positive.

On choisit une donnée initiale

$$x^{(0)} = \begin{pmatrix} 1 \\ \frac{1}{2} \end{pmatrix},$$

et on calcul le premier itéré pour :

a). Méthode de Jacobi:

$$x^{(1)} = \begin{pmatrix} \frac{1}{4} \\ -\frac{1}{3} \end{pmatrix},$$

b). Méthode de Gauss-Seidel:

$$x^{(1)} = \begin{pmatrix} \frac{1}{4} \\ -\frac{1}{12} \end{pmatrix},$$

c). Méthode du gradient à pas fixe:

On a $r^{(0)} = A.x^{(0)} - b = \begin{pmatrix} \frac{3}{2} \\ \frac{5}{2} \end{pmatrix}$.

Convergence de la méthode:

Comme A est symétrique définie positive, si on choisit α (Proposition 3.2) tel que:

$$0 < \alpha < \frac{2}{\lambda_2} = \frac{2}{\frac{5}{2} + \frac{1}{2}\sqrt{5}} = 0,55279,$$

$$\alpha = \frac{2}{\lambda_1 + \lambda_2} = \frac{2}{5}.$$

La méthode converge.

Calcul de $x^{(1)}$: Si on prend $\alpha = \frac{1}{2} < 0,55279$, on obtient

$$\begin{aligned} x^{(1)} &= x^{(0)} - \alpha.r^{(0)} = \begin{pmatrix} 1 \\ \frac{1}{2} \end{pmatrix} - \frac{1}{2} \begin{pmatrix} \frac{3}{2} \\ \frac{5}{2} \end{pmatrix} \\ &= \begin{pmatrix} \frac{1}{4} \\ -\frac{3}{4} \end{pmatrix} \end{aligned}$$

Si on prend $\alpha = \frac{2}{5} < 0,55279$, on obtient

$$\begin{aligned} x^{(1)} &= x^{(0)} - \alpha.r^{(0)} = \begin{pmatrix} 1 \\ \frac{1}{2} \end{pmatrix} - \frac{2}{5} \begin{pmatrix} \frac{3}{2} \\ \frac{5}{2} \end{pmatrix} \\ &= \begin{pmatrix} \frac{2}{5} \\ -\frac{1}{2} \end{pmatrix} \end{aligned}$$

d). Méthode du gradient à pas optimal: $r^{(0)} = \begin{pmatrix} \frac{3}{2} \\ \frac{5}{2} \end{pmatrix}$.

Calcul de $\alpha_{(0)}$: On a

$$\|r^{(0)}\|_2^2 = \begin{pmatrix} \frac{3}{2} & \frac{5}{2} \end{pmatrix} \begin{pmatrix} \frac{3}{2} \\ \frac{5}{2} \end{pmatrix} = \frac{17}{2}$$

et

$$\begin{aligned} \langle A.r^{(0)}, r^{(0)} \rangle &= \begin{pmatrix} \frac{3}{2} & \frac{5}{2} \end{pmatrix} \begin{pmatrix} 2 & 1 \\ 1 & 3 \end{pmatrix} \begin{pmatrix} \frac{3}{2} \\ \frac{5}{2} \end{pmatrix} \\ &= \frac{123}{4}. \end{aligned}$$

Donc

$$\begin{aligned}\alpha_0 &= \frac{\|r^{(0)}\|_2^2}{\langle A.r^{(0)}, r^{(0)} \rangle} = \frac{17}{2} \times \frac{4}{123} \\ &= \frac{34}{123}\end{aligned}$$

Calcul de $x^{(1)}$:

$$x^{(1)} = \begin{pmatrix} 1 \\ \frac{1}{2} \end{pmatrix} - \frac{34}{123} \begin{pmatrix} \frac{3}{2} \\ \frac{5}{2} \end{pmatrix}.$$