

RÉSOLUTION DE SYSTÈMES LINÉAIRES PAR DÉCOMPOSITION DE MATRICE

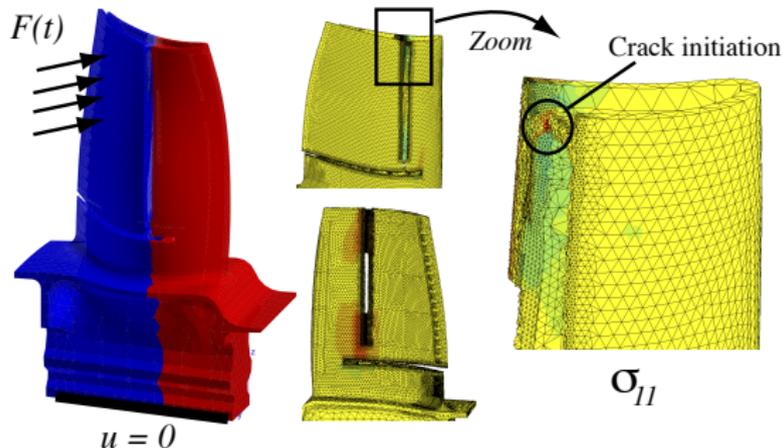
David Ryckelynck

Centre des Matériaux, Mines ParisTech

24 septembre 2015

- 1 Motivations
- 2 Remarques préliminaires
- 3 Méthode d'élimination de Gauss-Jordan
- 4 Décomposition LU
- 5 Décomposition de Cholesky
- 6 Complexité numérique des méthodes du type Gauss
- 7 Erreurs et conditionnement
- 8 Exercice

- La résolution d'équations aux dérivées partielles, linéaire ou non linéaire, conduit à la résolution de systèmes linéaires de grande taille.
- La matrice d'un système linéaire incorpore tous les couplages issus du modèle physique. C'est le cas par exemple pour les couplages induits par des conditions d'équilibre.
- Pour les problèmes à variables dépendantes du temps et de l'espace, la résolution de systèmes linéaires intervient dans l'intégration implicite des équations d'évolution.
- Nous abordons dans ce cours les **méthodes directes**, en opposition aux méthodes itératives qui construisent une suite convergente d'approximations.
- Les méthodes directes sont adaptées à de grandes classes de problèmes linéaires.



Calcul d'une aube entaillée soumise à un chargement cyclique [thèse Mélanie Leroy 2013].

Il s'agit de la simulation d'un essai de flexion pour modéliser la durée de vie d'un joint de grain [thèse Mélanie Leroy 2013]. Le but de simulation est d'estimer l'état de contrainte dans le voisinage du joint de grain.

La simulation non linéaire de 5 cycles de chargement dure 67 heures, pour 131 pas de temps et 1,7 millions variables de déplacements à déterminer à chaque pas de temps.

La résolution de systèmes linéaires représente 75% de la durée totale de la simulation. Réduire de 20% ce temps de calcul permet de gagner environ 13h !

A l'aide de l'algorithme de Newton Raphson, la recherche d'une solution approchée d'un problème non linéaire s'obtient par une suite de corrections linéaires.

Soit $\mathbf{R}(\mathbf{q}) = 0$ le système de N équations non linéaires dont la solution est $\mathbf{q} \in \mathbb{R}^N$. On suppose qu'il existe une matrice jacobienne \mathbf{J} :

$$\mathbf{R}(\mathbf{q} + d\mathbf{q}) = \mathbf{R}(\mathbf{q}) + \mathbf{J}(\mathbf{q}) d\mathbf{q}, \text{ au premier ordre quand } d\mathbf{q} \rightarrow 0$$

Connaissant une estimation de \mathbf{q} notée \mathbf{q}_n on cherche une correction $\delta\mathbf{q}$ tel que :

$$0 = \mathbf{R}(\mathbf{q}_n) + \mathbf{J}(\mathbf{q}_n) \delta\mathbf{q}, \quad \mathbf{q}_{n+1} = \mathbf{q}_n + \delta\mathbf{q}$$

Ce qui nécessite de résoudre le système linéaire suivant :

$$\mathbf{J}(\mathbf{q}_n) \delta\mathbf{q} = -\mathbf{R}(\mathbf{q}_n)$$

Dans la suite du cours, on s'intéressera au système linéaire suivant :

$$\mathbf{A}\mathbf{x} = \mathbf{b}, \quad \mathbf{A} \in \mathbb{R}^{N \times N}, \quad \mathbf{b} \in \mathbb{R}^N, \quad \mathbf{x} \in \mathbb{R}^N$$

Dans le cas d'une résolution multiple, pour différents seconds membres, on adopte la notation suivante :

$$\mathbf{A}\mathbf{X} = \mathbf{B}, \quad \mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_m], \quad \mathbf{B} = [\mathbf{b}_1, \dots, \mathbf{b}_m]$$

On aura une attention particulière au cas des matrices creuses ou bandes. Ce type de matrice est fréquent quand on résout des EDP en thermomécanique des structures.

Notation par bloc :

$$[\bar{\mathbf{B}}, \tilde{\mathbf{B}}] = [\bar{\mathbf{b}}_1, \dots, \bar{\mathbf{b}}_{\bar{m}}, \tilde{\mathbf{b}}_1, \dots, \tilde{\mathbf{b}}_{\tilde{m}}], \quad \bar{\mathbf{B}} \in \mathbb{R}^{N \times \bar{m}}, \quad \tilde{\mathbf{B}} \in \mathbb{R}^{N \times \tilde{m}}$$

$$\bar{\mathbf{b}}_1 = \begin{bmatrix} \vdots \\ \bar{B}_{i1} \\ \vdots \end{bmatrix}$$

Etude d'un cas de découplage d'équations.

Cas d'un bloc d'équations découplé de la première variable x_1 :

$$\mathbf{A} = \begin{bmatrix} 1 & \mathbf{W} \\ 0 & \tilde{\mathbf{A}} \end{bmatrix}, \quad \mathbf{x}^T = [x_1, \tilde{\mathbf{x}}^T], \quad \mathbf{b}^T = [b_1, \tilde{\mathbf{b}}^T]$$

On peut alors déterminer $\tilde{\mathbf{x}}$ puis déterminer x_1 de façon explicite :

$$\tilde{\mathbf{A}} \cdot \tilde{\mathbf{x}} = \tilde{\mathbf{b}}$$

$$x_1 = b_1 - \mathbf{W} \cdot \tilde{\mathbf{x}}$$

La **complexité numérique** de l'équation donnant x_1 est inférieure à N produits et N additions (moins de $2N$ Flops, opérations à virgule flottante).

$$\mathbf{A} = \begin{bmatrix} A_{11} & A_{12} & A_{13} & A_{14} \\ 0 & A_{22} & A_{23} & A_{24} \\ 0 & 0 & A_{33} & A_{34} \\ 0 & 0 & 0 & A_{44} \end{bmatrix}$$

On calcul $x_4 = \frac{b_4}{A_{44}}$ (x_N dans le cas général), puis $x_3 \dots$ jusqu'à x_1 .

Il y a une division, puis une multiplication, une addition et une division, ...

Il faut N divisions, et $(N - 1)^2 - \frac{N-1}{2}$ multiplications et additions. Soit une complexité numérique proportionnelle à N^2 quand N est grand. Pour une matrice creuse ayant ω termes non nuls en moyenne par ligne, on a une complexité proportionnelle à $N\omega$. En général ω est fonction de N .

Méthode d'élimination de Gauss-Jordan

Cette méthode permet de comprendre la problématique de la résolution numérique de systèmes linéaires. Ce n'est pas la plus performante.

Considérons le cas suivant :

$$\mathbf{A} \cdot \mathbf{X} = \mathbf{B}$$

On peut permuter deux lignes de \mathbf{A} sans changer la solution \mathbf{x} , en effectuant la même permutation de ligne sur \mathbf{B} .

On peut modifier une ligne de \mathbf{A} avec une combinaison linéaire d'autres lignes de \mathbf{A} sans changer la solution \mathbf{x} , en effectuant la même combinaison de lignes sur \mathbf{B} .

On peut permuter deux colonnes de \mathbf{A} si l'on permute les lignes correspondantes de \mathbf{X} . Il faudra dans ce cas reconstruire les solutions avec la numérotation d'origine.

On cherche à transformer \mathbf{A} en \mathbf{I} par des permutations et des combinaisons linéaires.

Gauss (1777 - 1855)

Elimination de Gauss-Jordan sans pivot de Gauss

On ne réalise que des combinaisons linéaires de lignes de **A**, de **B** et **I**.

$$\mathbf{A}^{(1)} = \mathbf{A} = \begin{bmatrix} A_{11} & A_{12} & A_{13} & A_{14} \\ A_{21} & A_{22} & A_{23} & A_{24} \\ A_{31} & A_{32} & A_{33} & A_{34} \\ A_{41} & A_{42} & A_{43} & A_{44} \end{bmatrix}$$

On suppose $A_{11} \neq 0$. On divise la première ligne par A_{11} et on soustrait cette ligne à chaque ligne i divisée par A_{i1} si $A_{i1} \neq 0$.

$$\widehat{\mathbf{A}}^{(1)} = \begin{bmatrix} 1 & \frac{A_{12}}{A_{11}} & \frac{A_{13}}{A_{11}} & \frac{A_{14}}{A_{11}} \\ A_{21} - c_2^{(1)} A_{11} = 0 & A_{22} - c_2^{(1)} A_{12} & A_{23} - c_2^{(1)} A_{13} & A_{24} - c_2^{(1)} A_{14} \\ A_{31} - c_3^{(1)} A_{11} = 0 & A_{32} - c_3^{(1)} A_{12} & A_{33} - c_3^{(1)} A_{13} & A_{34} - c_3^{(1)} A_{14} \\ A_{41} - c_4^{(1)} A_{11} = 0 & A_{42} - c_4^{(1)} A_{12} & A_{43} - c_4^{(1)} A_{13} & A_{44} - c_4^{(1)} A_{14} \end{bmatrix}$$

$$\text{avec } c_2^{(1)} = \frac{A_{21}}{A_{11}}, \dots, c_j^{(1)} = \frac{A_{j1}}{A_{11}}$$

On obtient alors un certain découplage :

$$\widehat{\mathbf{A}}^{(1)} = \begin{bmatrix} 1 & \mathbf{W} \\ 0 & \mathbf{A}^{(2)} \end{bmatrix}, \quad \mathbf{b}^T = \left[\frac{b_1}{A_{11}}, (b_j - c_j^{(1)} b_1)_{j=2}^N \right]$$

$$\mathbf{W} = \left[\frac{A_{12}}{A_{11}}, \frac{A_{13}}{A_{11}}, \frac{A_{14}}{A_{11}} \right]$$

$$\mathbf{A}^{(2)} = \begin{bmatrix} A_{22} - c_2^{(1)} A_{12} & A_{23} - c_2^{(1)} A_{13} & A_{24} - c_2^{(1)} A_{14} \\ A_{32} - c_3^{(1)} A_{12} & A_{33} - c_3^{(1)} A_{13} & A_{34} - c_3^{(1)} A_{14} \\ A_{42} - c_4^{(1)} A_{12} & A_{43} - c_4^{(1)} A_{13} & A_{44} - c_4^{(1)} A_{14} \end{bmatrix}$$

Il reste à traiter $\mathbf{A}^{(2)}$ de la même façon, afin d'obtenir $\widehat{\mathbf{A}}^{(2)}$:

$$\widehat{\mathbf{A}}^{(2)} = \begin{bmatrix} 1 & \mathbf{L} \\ 0 & \mathbf{A}^{(3)} \end{bmatrix}$$

puis on continue jusqu'à obtenir une matrice triangulaire.

Dans la méthode de Gauss-Jordan, on élimine également sur la colonne traitée, les termes des lignes précédentes. On construit ainsi une matrice identité.

Elimination de Gauss-Jordan sans pivot de Gauss

Les opérations précédentes sont linéaires. Il existe une matrice $\mathbf{P}^{(1)}$ telle que :

$$\widehat{\mathbf{A}}^{(1)} = \mathbf{P}^{(1)} \cdot \mathbf{A}^{(1)}$$

avec un produit à gauche pour modifier des lignes, avec un traitement identique de toutes les colonnes.

Par identification, on en déduit que :

$$\mathbf{P}^{(1)} = \begin{bmatrix} \frac{1}{A_{11}^{(1)}} & 0 & 0 & 0 \\ -C_2^{(1)} & 1 & 0 & 0 \\ -C_3^{(1)} & 0 & 1 & 0 \\ -C_4^{(1)} & 0 & 0 & 1 \end{bmatrix}, \quad \mathbf{P}^{(2)} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & \frac{1}{A_{11}^{(2)}} & 0 & 0 \\ 0 & -C_2^{(2)} & 1 & 0 \\ 0 & -C_3^{(2)} & 0 & 1 \end{bmatrix}$$

Par récurrence on a :

$$\widehat{\mathbf{A}}^{(2)} = \mathbf{P}^{(2)} \cdot \mathbf{P}^{(1)} \cdot \mathbf{A}$$

A la fin, on obtient la matrice triangulaire supérieur \mathbf{U} (Upper) :

$$\mathbf{U} = \mathbf{P} \cdot \mathbf{A}, \quad \mathbf{P} = \mathbf{P}^{(4)} \cdot \mathbf{P}^{(3)} \cdot \mathbf{P}^{(2)} \cdot \mathbf{P}^{(1)}$$

où \mathbf{P} est la matrice de permutation, avec \mathbf{U} et \mathbf{P} inversibles.

On note \mathbf{L} l'inverse de \mathbf{P} . On obtient alors la décomposition LU de \mathbf{A} :

$$\mathbf{L.U} = \mathbf{A}$$

Propriété : \mathbf{P} étant triangulaire inférieure, \mathbf{L} est une matrice triangulaire inférieure (Lower).

Ici l'analyse est purement formelle. En pratique on conserve l'algorithme d'élimination. On a :

$$\mathbf{U} = \mathbf{P.A} \quad \Rightarrow \quad \mathbf{U.X} = \mathbf{P.B}$$

Or $\widehat{\mathbf{X}} = \mathbf{P.B}$ est la solution de $\mathbf{L.X} = \mathbf{B}$. Après permutation par la matrice \mathbf{P} , il reste à résoudre un système triangulaire supérieur pour trouver \mathbf{X} :

$$\mathbf{U.X} = \widehat{\mathbf{X}}$$

Dans ce cas, on commence par rechercher $\hat{\mathbf{x}}$, puis on en déduit la solution recherchée $\tilde{\mathbf{x}}$ tel que :

$$\mathbf{L}.\hat{\mathbf{x}} = \tilde{\mathbf{b}}$$

$$\mathbf{U}.\tilde{\mathbf{x}} = \hat{\mathbf{x}}$$

$$\Rightarrow \tilde{\mathbf{b}} - \mathbf{A}.\tilde{\mathbf{x}} = 0$$

Il faut donc stocker en mémoire \mathbf{L} et \mathbf{U} .

Si A_{11} est nul, il faut permuter la ligne 1 avec une autre. Dans le cas du **pivotage partiel**, on ne fait que des permutations de lignes. On cherche la ligne qui maximise $|A_{i1}|$ pour la permuter avec la première ligne.

La matrice de permutation de la ligne 3 avec la ligne 1 s'écrit :

$$\mathbf{P}^{(1-3)} = \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

Dans le cas du **pivotage total**, on réalise aussi une recherche sur les colonnes, pour trouver un terme A_{ij} maximum (ou significatif), qui remplace A_{11} .

Définition : Une méthode numérique de résolution de système linéaire est dite mathématiquement stable lorsque "quelque soit la matrice \mathbf{A} régulière, l'algorithme réussit".

Théorème : La méthode de GAUSS avec une stratégie de pivotage est mathématiquement stable pour toute matrice régulière.

Corollaire : Si au cours d'une factorisation de GAUSS avec pivotage, un pivot nul est détecté alors la matrice est singulière et ce système n'a pas de solution unique.

Théorème : La méthode de GAUSS (sans pivotage) est stable pour des matrices réelles définies positives.

Proposition : La décomposition LU n'est pas unique. Pour la rendre unique, il faut spécifier la diagonale de \mathbf{L} ou de \mathbf{U} .

Décomposition de Crout

Pour les matrices \mathbf{A} ne nécessitant pas de pivotage, on peut utiliser la décomposition de Crout.

On procède par identification du produit $\mathbf{L}\mathbf{U}$, avec $L_{ii} = 1$:

$$A_{ij} = \sum_{k=1}^N L_{ik} U_{kj}, \quad \text{avec } L_{ik} = 0 \text{ pour } k > i, \quad U_{kj} = 0 \text{ pour } k > j$$

Donc

$$\text{pour } i \leq j \quad A_{ij} = U_{ij} + \sum_{k=1}^{i-1} L_{ik} U_{kj}$$

$$\text{pour } i > j \quad A_{ij} = \sum_{k=1}^j L_{ik} U_{kj}$$

On commence par la première ligne de \mathbf{A} pour en déduire U_{1j} , de façon progressive de $j = 1$ à $j = N$. Puis on traite la première colonne de la deuxième ligne :

$$L_{21} = \frac{A_{21}}{U_{11}}$$

Puis on traite le reste de la deuxième ligne...

La décomposition de Crout appliquée aux matrices symétriques régulières (inversibles) conduit à la proposition suivante : Il existe **L** triangulaire inférieure à diagonale unitaire et **D** matrice diagonale régulière tel que :

$$\mathbf{A} = \mathbf{L} \cdot \mathbf{D} \cdot \mathbf{L}^T$$

Décomposition de Cholesky des matrices symétriques définies positives

Si la matrice \mathbf{A} est symétrique positive, $\mathbf{x}^T \cdot \mathbf{A} \cdot \mathbf{x} > 0 \quad \forall \mathbf{x} \neq 0$ alors les termes de la diagonale de \mathbf{D} sont strictement positifs. On a alors : $\mathbf{D} = \mathbf{D}^{1/2} \cdot (\mathbf{D}^{1/2})^T$.

On obtient donc la décomposition de Cholesky :

$$\mathbf{A} = \tilde{\mathbf{L}} \cdot \tilde{\mathbf{L}}^T$$

avec $\tilde{\mathbf{L}}$ matrice triangulaire inférieure et $\tilde{\mathbf{L}} = \mathbf{L} \cdot \mathbf{D}^{1/2}$.

Pour construire la décomposition de Cholesky on procède également par identification du produit :

$$\text{pour } i \leq j \quad A_{ij} = \sum_{k=1}^i \tilde{L}_{ik} \tilde{L}_{jk}$$

On parcourt la matrice comme pour Crout.

Pour les matrices de largeur de bande ω la complexité numérique des méthodes de type Gauss est proportionnelle à $N \omega^2$. Soit pour les matrices pleines N^3 ...

Mais, lorsque l'on change uniquement de second membre la complexité numérique est proportionnelle à N^2 pour le traitement des systèmes triangulaires.

Une renumérotation des inconnues permettant de réduire la largeur de bande permettra une décomposition plus rapide.

Par définition :

$$\text{Cond}(\mathbf{A}) = \|\mathbf{A}\| \|\mathbf{A}^{-1}\|, \quad \|\mathbf{A}\| = \sup_{\mathbf{v}} \frac{\|\mathbf{A} \cdot \mathbf{v}\|}{\|\mathbf{v}\|}$$

Considérons l'erreur $\delta\mathbf{A}$ sur la matrice :

$$(\mathbf{A} + \delta\mathbf{A}) \cdot (\mathbf{x} + \delta\mathbf{x}) = \mathbf{b}, \quad \mathbf{A} \cdot \mathbf{x} = \mathbf{b}$$

avec $\delta\mathbf{A} \cdot \delta\mathbf{x}$ négligeable. Ainsi :

$$\delta\mathbf{x} = -\mathbf{A}^{-1} \cdot \delta\mathbf{A} \cdot \mathbf{x}$$

Donc :

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

En conclusion :

$$\frac{\|\delta\mathbf{x}\|}{\|\mathbf{x}\|} \leq \text{Cond}(\mathbf{A}) \frac{\|\delta\mathbf{A}\|}{\|\mathbf{A}\|}$$

Un mauvais conditionnement amplifie les erreurs d'arrondi générées lors de la décomposition de \mathbf{A} .

Rappel sur les normes matricielles : $\|\mathbf{A} \cdot \mathbf{B}\| \leq \|\mathbf{A}\| \|\mathbf{B}\|$

Pour réduire le conditionnement il est possible de réaliser une mise à l'échelle avec deux matrices diagonales \mathbf{W}^1 , \mathbf{W}^2 tel que :

$$\text{Cond}(\mathbf{W}^1 \cdot \mathbf{A} \cdot \mathbf{W}^2) < \text{Cond}(\mathbf{A})$$

On peut utiliser par exemple :

$$\mathbf{W}^1 = \mathbf{W}^2$$
$$(\mathbf{W}^1)_{ii} = \frac{1}{A_{ii}} \text{ si } A_{ii} \neq 0, \text{ sinon } (\mathbf{W}^1)_{ii} = 1$$

On considère une matrice de rigidité associée à un système de ressorts. L'énergie potentielle $E(\mathbf{x})$ est la somme des énergies de chaque ressort reliant x_i à x_j , moins le travail des efforts extérieurs (ici $x_1 F$) :

$$E(\mathbf{x}) = \sum_{k=1}^m \frac{1}{2} \lambda (x_{L(k,1)} - x_{L(k,2)})^2 + \frac{1}{2} \lambda x_1^2 - x_1 F$$

$L(k, :)$ est une table de connectivité où une ligne indique les variables reliées par un ressort. Par définition la matrice de rigidité \mathbf{A} est symétrique positive et elle vérifie la propriété suivante :

$$E(\mathbf{x}) = \frac{1}{2} \mathbf{x}^T \cdot \mathbf{A} \cdot \mathbf{x} - \mathbf{x}^T \cdot \mathbf{b}$$

avec $\mathbf{b}^T = F [1, 0, \dots, 0]$. La minimisation de l'énergie potentielle conduit à l'équation d'équilibre suivante :

$$\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$$

- Construire \mathbf{A} pour 10 ressorts reliant 11 points tel que $L(k, 1) = k$, $L(k, 2) = k + 1$.
- Quelle est la largeur de bande de la matrice \mathbf{A} ?
- Etudier les temps de calcul de la décomposition pour $N=10, 100, 1000, 10000$.
- Traiter un cas ayant une matrice mal conditionnée.
- Augmenter la largeur de bande de la matrice en rajoutant des ressorts entre les inconnues k et $k + 2$, dans le cas $N = 1000$.
- Quel est la durée de la décomposition de cette matrice.
- comment tenir compte du fait que la matrice est creuse ?

[Press94] Numerical Recipes in C, The Art of Scientific Computing, second edition, William H. Press, Saul A. Teukolsky, William T. Vetterling, Brian P. Flannery, Cambridge University Press, 1994.

Fascicule r6.02 : Méthodes directes, D. SELIGMANN, J. PELLET, Code Aster, EDF R & D, 2009,
http://www.code-aster.org/V2/doc/v11/fr/man_r/r6/r6.02.01.pdf