Résolution de systèmes linéaires

Skander Zannad et Judicaël Courant

2014-02-21

1 Motivations

Résolution d'une EDO : inconnue dans $E^{\mathbb{R}}$ (où E espace vectoriel).

Méthode d'Euler : recherche d'un nombre fini de valeurs ($y(t_0 + k\delta)$ où t_0 instant initial, δ pas), vérifiant certaines relations.

Principe : *discrétisation* du temps.

En physique : beaucoup d'équations aux dérivées partielles (EDP).

Résolution : discrétisation du temps et/ou de l'espace.

Applications :

- Diffusion de la chaleur dans un matériau ;
- Calcul du champ magnétique induit par une source électromagnétique ;
- Simulation de déformation d'une voiture en cas de choc.
- ...

Solution d'une équation magnétostatique. À droite, le maillage utilisé.

2 Méthode de Gauss-Jordan

Appelée aussi méthode du pivot de Gauss.

Cadre : équation $Ax = b$, où $A \in \mathcal{M}_n(\mathbb{K})$, $b \in \mathcal{M}_{n1}(\mathbb{K})$, inconnue $x \in \mathcal{M}_{n1}(\mathbb{K})$.

2.1 Cas où A est triangulaire

Si A est triangulaire (par ex. supérieure) et inversible ($\forall k \quad a_{kk} \neq 0$), la résolution est facile. Les solutions du système :

$$\begin{array}{cccccccc}
 a_{11}x_1 & + & a_{12}x_2 & + & \cdots & + & \cdots & + & a_{1n}x_n & = & b_1 \\
 & & a_{22}x_2 & + & \cdots & + & \cdots & + & a_{2n}x_n & = & b_2 \\
 & & & & \ddots & & & & \vdots & & \vdots \\
 & & & & & & a_{kk}x_k & + & \cdots & + & a_{kn}x_n & = & b_k \\
 & & & & & & \ddots & & \vdots & & \vdots \\
 & & & & & & & & a_{nn}x_n & = & b_n
 \end{array}$$

se calculent de proche en proche :

$$\begin{aligned}
 x_n &= \frac{1}{a_{nn}} (b_n) \\
 x_{n-1} &= \frac{1}{a_{n-1,n-1}} (b_{n-1} - a_{n-1,n}x_n) \\
 &\vdots \\
 x_k &= \frac{1}{a_{k,k}} (b_k - a_{k,k+1}x_{k+1} - \cdots - a_{k,n}x_n)
 \end{aligned}$$

2.2 Cas général

On se ramène au cas triangulaire : pour cela on va effectuer des opérations sur les lignes du système $Ax = b$.

En numérotant les lignes de 0 à $n - 1$ et les colonnes de 0 à $n - 1$, et en notant L_i la ligne i pour $i \in \llbracket 0, n \rrbracket$, l'algorithme du pivot partiel est le suivant :

- (i) Pour $i = 0, 1, \dots, n - 1$:
 - (i) Trouver j dans $\llbracket i, n \rrbracket$ tel que $|a_{ji}|$ soit maximal
 - (ii) Échanger les lignes i et j dans A et dans b .
 - (iii) Poser $p = a_{ii}$.
 - (iv) Pour j de $i + 1$ à $n - 1$:
 - (i) Remplacer b_j par $b_j - \frac{a_{ij}}{p} b_i$.
 - (ii) Remplacer la ligne L_j de A par $L_j - \frac{a_{ji}}{p} L_i$.
- (ii) A est maintenant triangulaire, calculer la solution avec la méthode précédente.

3 Implantation

A et b matrices, donnés sous forme d'un tableau bidimensionnel (type array de numpy). Intérêt d'array :

- (i) opérations d'ajout de lignes et de multiplication d'une ligne par un scalaire déjà disponibles (sinon, il faut les programmer) ;
- (ii) extractions de lignes faciles (tableau unidimensionnel).

NB : Il existe aussi un type matrix. Adapté pour des manipulations de matrices mais pas très pratique pour l'extraction de lignes.

```
from numpy import array, zeros
```

```
def matrice(m):  
    """ Construit une matrice à partir  
    d'une liste de listes donnée en argument. """  
    return array(m)
```

```
def mat_nulle(p, q):  
    """ Retourne, la matrice nulle de dimension  $p * q$   
    sous forme de tableau (array). """  
    return zeros(shape=(p, q))
```

```
def echange_lignes(A, i, j):  
    """ Échange les lignes  $i$  et  $j$  de la matrice,  
    représentée comme liste de lignes de type array """  
    # on COPIE les éléments de la ligne  $j$  :
```

```

t = A[j,:].copy()
# avant de l'écraser:
A[j,:] = A[i,:]
A[i,:] = t

def resout_triang_inf(A, b):
    """Résout le système  $Ax = b$ .
    Préconditions: A triangulaire inférieure
    et b a autant de lignes que A. """
    n = len(A)
    p = len(b)
    assert n == p # même nombre de lignes dans A et b
    x = mat_nulle(len(A[0]), len(b[0]))
    for k in range(n-1, -1, -1):
        x[k,:] = 1./A[k,k] * (
            b[k,:] - sum(A[k,j]*x[j,:] for j in range(k+1, n)))
    return x

def cherche_pivot(A, i):
    """Cherche et retourne un j tel que
    abs(A[j][i]) est maximal, avec j>=i """
    n = len(A)
    best = i
    for j in range(i+1, n):
        # invariant: pour tout k <= j
        # abs(A[best][i]) >= abs(A[k][i])
        if abs(A[j,i]) > abs(A[best,i]):
            best = j
    return best

def resout(A, b):
    """Applique la méthode du pivot pour résoudre  $Ax = b$ .
    Retourne la solution x trouvée.
    Précondition : A et b sont de type array,
    A est inversible, b a même nombre de lignes que A.
    Attention: cette fonction modifie A et b. """
    n = len(A)
    q = len(b)
    assert n == q # même nombre de lignes dans A et b
    A = A.copy()
    b = b.copy()

    for i in range(n):
        j = cherche_pivot(A, i)
        # on met en place la ligne du pivot :
        echange_lignes(A, i, j)
        echange_lignes(b, i, j)

```

```

p = A[i, i] # le pivot
for j in range(i+1, n):
    b[j,:] -= A[j,i] / p * b[i,:]
    A[j,:] -= A[j,i] / p * A[i,:]
return resout_triangu_inf(A, b)

```

4 Temps de calcul

Quel est le coût de l'algorithme du pivot ?

- (i) Cas d'une matrice triangulaire : le calcul de la dernière composante de la solution requiert une division, la précédente une division, une multiplication, une soustraction, ..., la première composante une division, $n - 1$ multiplications et $n - 1$ soustractions. Au total : n divisions, $n(n - 1)/2$ multiplications et $n(n - 1)/2$ soustractions. Temps de calcul : $\Theta(n^2)$.
- (ii) Cas général : à l'étape i , on cherche le pivot ($n - i - 1$ comparaisons), un échange de lignes (n flottants à échanger), puis pour chacune des $n - i - 1$ dernières lignes, on effectue une multiplication de la ligne i avant de soustraire le résultat. Il est clair que le nombre d'opérations avant d'arriver à une matrice triangulaire est un $O(n^3)$ et que c'est un $\Omega(n^3)$ (les $n/2$ premières étapes ont un coût supérieur à $n^3/8$).

L'algorithme du pivot est donc relativement coûteux.

Il est ici du même ordre que le produit (naïf) de deux matrices ($\Theta(n^3)$).

Voir plus loin les améliorations possibles.

5 Stabilité numérique : Problèmes possibles

Les calculs n'étant pas faits de façon exacte mais approchée, des problèmes peuvent survenir.

5.1 Incapacité à inverser une matrice

La matrice suivante est inversible :

$$\begin{pmatrix} 10^{20} & 10^{20} & 10 \\ 10^{19} & 1 & 0 \\ 10^{19} & 0 & 0 \end{pmatrix}$$

Après une étape de pivot, on arrive à :

$$\begin{pmatrix} 10^{20} & 10^{20} & 1 \\ 0 & 1 - 10^{19} & -1 \\ 0 & -10^{19} & -1 \end{pmatrix}$$

Mais en machine, $1 - 10^{19}$ va être arrondi (à la même valeur que -10^{19}) :

$$\begin{pmatrix} 10^{20} & 10^{20} & 1 \\ 0 & -10^{19} & -1 \\ 0 & -10^{19} & -1 \end{pmatrix}$$

Résultat : les deux dernières lignes sont égales et la matrice n'est plus inversible.

5.2 Capacité à inverser des matrices non inversibles

Considérons une matrice de la forme

$$\begin{pmatrix} a & b \\ a & b \end{pmatrix}$$

avec $a \neq 0$.

Après une étape de pivot, on obtient :

$$\begin{pmatrix} a & b \\ 0 & b - (b/a) \times a \end{pmatrix}$$

Si, en raison d'un arrondi, $b - (b/a) \times a$ ne donne pas 0, on obtient une matrice triangulaire sans zéro sur sa diagonale, donc inversible.

(en flottant ce problème se produit par exemple avec $b = 0,9999$ et $a = 1,9999$).

5.3 Conditionnement

Considérons la matrice $M = ((i + j - 1)^{-1})_{1 \leq i, j \leq 5}$ (matrice de Hilbert) et cherchons à résoudre $MX = B_1$ et $MX = B_2$ pour deux valeurs proches de B_1 et B_2 :

```
n = 5
M = matrice([[ 1/(i+j+1.) for j in range(n)]
             for i in range(n)])
u0 = matrice([[ -0.76785474],
              [ -0.44579106],
              [ -0.32157829],
              [ -0.25343894],
              [ -0.20982264]])
s0 = resout(M, u0)
u1 = matrice([[ -0.76784856],
              [ -0.44590775],
              [ -0.32107213],
              [ -0.25420613],
              [ -0.20944639]])
s1 = resout(M, u1)
```

Résultat :

```
>>> s0
array([[ -0.4900022],
       [ -0.2844282],
       [ -0.2054472],
       [ -0.1613528],
       [ -0.1340892]])

>>> u1 / u0
array([[ 0.99999195],
       [ 1.00026176],
       [ 0.99842601],
       [ 1.00302712],
       [ 0.99820682]])

>>> s1
array([[ 1.3877308],
       [ -35.7756354],
       [ 153.7403826],
       [ -233.496746 ],
       [ 114.2981532]])

>>> s1 / s0
array([[ -2.83209096],
       [ 125.78090147],
       [ -748.32065172],
       [ 1447.1192691 ],
       [ -852.40387145]])
```

Le problème n'est pas dû au calcul numérique : il est inhérent à la matrice M .

Étant donné un vecteur x , on peut définir sa norme de plusieurs façons. Pour fixer les idées, pour $x = (x_1, \dots, x_n) \in \mathbb{R}^N$, posons

$$\|x\| = \sqrt{x_1^2 + \dots + x_n^2}$$

(appelée *norme 2*)

Étant donnés deux vecteurs $x \neq 0$ et x' , on dit que l'erreur relative commise en prenant x' au lieu de x est $\frac{\|x-x'\|}{\|x\|}$.

On dit que M^{-1} est mal conditionnée car une petite erreur relative sur x peut se traduire par une grande erreur relative sur $M^{-1}x$.

Plus précisément, en posant

$$E_M = \left\{ \frac{\|Mx\|}{\|x\|} \mid x \neq 0 \right\} = \{ \|Mx\| \mid \|x\| = 1 \}$$

Le *conditionnement* c_M de la matrice M est la valeur

$$c_M = \frac{\sup E_M}{\inf E_M} = \frac{\max E_M}{\min E_M}$$

NB : on a aussi

$$c_M = \max E_M \times \max E_{M^{-1}} = c_{M^{-1}}$$

(et $\max E_M$ est souvent noté $\|M\|$). Alors, pour tout $x \neq 0$ et tout x' :

$$\frac{\|Mx - Mx'\|}{\|Mx\|} \leq c_M \times \frac{\|x - x'\|}{\|x\|}$$

et cette borne est serrée :

$$\exists x \neq 0 \exists x' \frac{\|Mx - Mx'\|}{\|Mx\|} = c_M \times \frac{\|x - x'\|}{\|x\|}$$

Donc si le conditionnement de M (donc de M^{-1}) est grand, une petite erreur relative sur x peut donner une grande erreur relative sur $M^{-1}x$.

6 Remarques sur l'algorithme

6.1 Résolution simultanée de plusieurs systèmes

- (i) On peut résoudre plusieurs systèmes $Ax = b_1, Ax = b_2, \dots, Ax = b_p$ en utilisant l'algorithme avec un b matriciel dont les colonnes sont $b_1, \dots, b_p$.
- (ii) Si on prend pour membre droit I_n , alors le x trouvé sera A^{-1} .

6.2 Décomposition dite «LU»

Les différentes opérations effectuées sur le système consistent à le transformer en un système $UX = b'$ où U est triangulaire supérieure.

Ces opérations peuvent être exprimées comme des multiplications successives de la matrice A et de la matrice b à gauche par des matrices.

Ces matrices sont de deux types :

- (i) Des matrices de permutation.
- (ii) Des matrices de *transvection*.

6.2.1 Matrices de permutation

Déf $P_\sigma = (p_{ij})_{(i,j) \in \llbracket 1, n \rrbracket^2}$ matrice de permutation associée à une permutation $\sigma : \llbracket 1, n \rrbracket \rightarrow \llbracket 1, n \rrbracket$ si $\forall (i, j) \in \llbracket 1, n \rrbracket \quad m_{ij} = \delta_{i, \sigma(j)}$.

Prop P matrice de permutation si et seulement si P est carrée, ne contient que des 0 et des 1 avec exactement un 1 par ligne et par colonne.

Prop P de taille n matrice de permutation si et seulement si pour toute matrice M de taille $n \times p$, PM est la matrice M à permutation près des lignes (cette permutation étant celle associée à P : la ligne i de M est envoyée en $\sigma(i)$).

Rem $P_\sigma \circ P_{\sigma'} = P_{\sigma \circ \sigma'}$.

Rem P_σ inversible et $(P_\sigma)^{-1} = P_{\sigma^{-1}}$.

6.2.2 Matrices de transvection

Exemple :

$$T_\lambda = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ \lambda & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

Soit B matrice ayant 4 lignes L_1, L_2, L_3, L_4 .

$T_\lambda B$ a les mêmes lignes que B sauf la 3^e ligne qui est $L_3 + \lambda L_1$.

Définition : matrice s'écrivant I_n plus une matrice avec un seul coefficient non-nul, situé sous la diagonale.

Rem :

- (i) On a $T_\lambda T_\mu = T_{\lambda+\mu}$.
- (ii) Donc T_λ inversible et $T_\lambda^{-1} = T_{-\lambda}$.

6.2.3 Décomposition PLU

La méthode du pivot consiste à obtenir une matrice U triangulaire supérieure en appliquant, en multipliant A à gauche par

- une matrice de permutation S_1 ;
- puis un produit de matrices de transvection G_1 ;
- ...
- une matrice de permutation S_n ;
- un produit de matrices de transvection G_n .

$$G_n S_n \cdots G_1 S_1 A = U$$

D'où :

$$A = S_1^{-1} G_1^{-1} \cdots S_n^{-1} G_n^{-1} U$$

On peut montrer qu'on peut simplifier ça en

$$A = PLU$$

où L est une triangulaire inférieure, P matrice de permutation.¹

(On écrit parfois $P^{-1}A = LU$)

6.2.4 Algorithme

En pratique, on peut construire explicitement la matrice L et la permutation associée à P ou lors de l'exécution de l'algorithme du pivot et les retourner.

6.2.5 Avertissement

On parle de décomposition LU mais certaines matrices (bien qu'inversibles) n'admettent pas de décomposition LU . Par exemple

$$\begin{pmatrix} 0 & 2 \\ 7 & 8 \end{pmatrix}$$

n'en admet pas. Exercice : pourquoi ? (indication : s'intéresser au coefficient 0)

6.2.6 Applications

Résolution de $Ax = b$ On résout $PLUx = b$, en résolvant

$Py = b$ par application de la permutation réciproque aux lignes de b ;

$Lz = y$ qui est triangulaire ;

$Ux = z$ qui est triangulaire.

Calcul de l'inverse On prend $b = I_n$ et on résout $Ax = b$.

Calcul du déterminant On a $\det A = \det P \times \det L \times \det U$ et

- $\det P$ est la signature de la permutation associée à P

- $\det L$ et $\det U$ sont le produit des éléments diagonaux.

NB : En pratique, on peut souvent se passer de calculer explicitement L , U et P .

1. U pour «Upper», L pour «Lower».

7 Méthode des moindres carrés

7.1 Cadre

En physique ou en économie, il est fréquent qu'on soit dans la situation suivante :

- (i) On sait/conjecture qu'une valeur b dépend linéairement de paramètres $(\alpha_1, \dots, \alpha_q)$: il existe des constantes $C_1, \dots, C_q$ telles que pour toute valeur des paramètres et toute valeur de b associée

$$b = \sum_{k=1}^q C_k \alpha_k = (\alpha_1 \ \cdots \ \alpha_q) \times \begin{pmatrix} C_1 \\ \vdots \\ C_q \end{pmatrix}$$

- (ii) On a mesuré des valeurs $b_1, \dots, b_p$ et $(a_{11}, \dots, a_{1q}), \dots, (a_{p1}, \dots, a_{pq})$ les valeurs associées des paramètres.
(iii) On aimerait connaître $C_1, \dots, C_q$.

On a :

- nombre de mesures : p ;
- nombre de paramètres : q .

On prend $p \geq q$ (sinon on n'arrivera pas à connaître tous les paramètres) et même $p > q$ pour voir si ce modèle linéaire est réaliste, pour essayer de réduire l'effet des erreurs (aléatoires) de mesure.

Il s'agit de résoudre :

$$\begin{pmatrix} a_{11} & \cdots & a_{1q} \\ \vdots & & \vdots \\ a_{p1} & \cdots & a_{pq} \end{pmatrix} \times \begin{pmatrix} C_1 \\ \vdots \\ C_q \end{pmatrix} = \begin{pmatrix} b_1 \\ \vdots \\ b_p \end{pmatrix}$$

d'inconnues $C_1, \dots, C_q$.

Problèmes :

- (i) Erreurs de mesure : pas de solution.
(ii) La modélisation linéaire n'est en général qu'une approximation.

Pour s'en sortir :

Ne pas chercher à *résoudre*

$$Ax - b$$

mais plutôt à *minimiser*

$$\|Ax - b\|$$

On prendra la norme 2 (c'est le plus facile).

Donc on minimise le carré des écarts de Ax à b .

D'où le nom : «Méthode(s) des moindres carrés».

7.2 Matrices orthogonales

On dira qu'une matrice $M \in \mathcal{M}_{nm}(\mathbb{R})$ est *orthogonale* si l'application

$$\begin{aligned} \mathbb{R}^m &\rightarrow \mathbb{R}^n \\ x &\mapsto Mx \end{aligned}$$

préserve la norme 2, i.e. $\forall x \in \mathbb{R}^m \quad \|Mx\| = \|x\|$

Toute matrice orthogonale :

(i) préserve les produits scalaires car $M(\vec{u} + \vec{v}) = M\vec{u} + M\vec{v}$ et

$$\vec{u} \cdot \vec{v} = \frac{1}{2} (\|\vec{u} + \vec{v}\|^2 - \|\vec{u}\|^2 - \|\vec{v}\|^2)$$

(ii) préserve les angles car

$$\cos(\vec{u}, \vec{v}) = \frac{\vec{u} \cdot \vec{v}}{\|\vec{u}\| \times \|\vec{v}\|}$$

7.3 Pseudo-inverse

Étant donné une matrice $A \in \mathcal{M}_{pq}(\mathbb{R})$, on peut définir son *pseudo-inverse de Moore-Penrose* A^+ (même si A non inversible et même si A non carrée).

C'est l'unique matrice vérifiant :

- (i) $A^+ \in \mathcal{M}_{pq}(\mathbb{R})$
- (ii) $AA^+A = A$
- (iii) $A^+AA^+ = A^+$
- (iv) AA^+ est une matrice orthogonale
- (v) A^+A est une matrice orthogonale

7.4 Moindres carrés

L'ensemble des vecteurs x minimisant $\|Ax - b\|$ est le sous-espace affine $A^+b + \text{Ker } A$.
Et parmi eux, A^+b est le vecteur de norme minimale.

7.5 Calcul du pseudo-inverse

Il existe plusieurs méthodes de calculs. Les plus utilisées passent par une décomposition implicite ou explicite de la matrice A :

Décomposition QR A est mis sous la forme QR où R triangulaire supérieure et Q orthogonale.

Décomposition en valeurs singulières² A est mis sous la forme $U\Sigma V$ où U et V orthogonales et Σ diagonale à coefficients positifs ou nuls.

8 Regard critique

8.1 Résumons

On travaille sur une matrice carrée A de taille n .

- (i) On veut parfois des valeurs de n élevées : plusieurs milliers.
- (ii) La complexité de ces méthodes est en général de l'ordre de la méthode du pivot : $\Theta(n^3)$.
- (iii) C'est l'ordre de grandeur du coût de la multiplication naïve.

Peut-on faire mieux ?

- oui, il y a des algorithmes un peu plus efficaces pour obtenir les mêmes décompositions (mais c'est délicat).
- mais bien souvent en informatique, il vaut mieux se poser la question de la pertinence de ce qu'on fait.

8.2 Cadre physique

- (i) interactions seulement entre des points proches
- (ii) donc la matrice A est creuse (une majorité de zéros).

On peut améliorer la représentation des matrices et les algorithmes d'addition et de multiplication pour en tirer parti.

Problème : les méthodes de décomposition ont tendance à remplir les matrices.

8.3 Méthodes plus adaptées aux matrices creuses

Pour résoudre $Ax = b$ pour une matrice creuse,

Utilisation de méthodes itératives pour les matrices creuses :

- (i) on part d'une solution approchée ;
- (ii) on l'améliore ;
- (iii) revenir au point précédent tant que nécessaire.

Intérêt de ces méthodes :

- (i) Pas besoin de calculer de nouvelles matrices (on reste sur des matrices creuses) ;
- (ii) On améliore peu à peu une solution : impact des erreurs de calcul a priori plus faible.