

Sisteme de ecuații algebrice liniare - metode iterative

Prof.dr.ing. Gabriela Ciuprina

Universitatea "Politehnica" Bucureşti, Facultatea de Inginerie Electrică,
Departamentul de Electrotehnica

Suport didactic pentru disciplina *Algoritmi Numerici*, 2017-2018

- 1 Formularea problemei
 - 2 Metode staționare
 - Ideea
 - Metoda Jacobi
 - Metoda Gauss-Seidel
 - SOR
 - 3 Metoda gradientilor conjugăți
 - Ideea metodei gradientilor conjugăți
 - Metoda gradientului
 - Metoda direcțiilor conjugate
 - Metoda gradientilor conjugăți
 - 4 Precondiționare
 - Referințe
 - Biblioteci existente

Notes

Notes

Formularea problemei

Sistem de n ecuații algebrice liniare cu n necunoscute:

$$\begin{cases} a_{11}x_1 + a_{12}x_2 + \cdots + a_{1n}x_n = b_1, \\ a_{21}x_1 + a_{22}x_2 + \cdots + a_{2n}x_n = b_2, \\ \dots \\ a_{n1}x_1 + a_{n2}x_2 + \cdots + a_{nn}x_n = b_n. \end{cases} \quad (1)$$

Notes

Formularea problemei

Se dă matricea coeficienților

$$\mathbf{A} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \dots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{bmatrix} \in \mathbb{R}^{n \times n} \quad (2)$$

și vectorul termenilor liberi

$$\mathbf{b} = [b_1 \ b_2 \ \cdots \ b_n]^T \in \mathbb{R}^n, \quad (3)$$

se cere să se rezolve sistemul

$$\mathbf{Ax} = \mathbf{b}, \quad (4)$$

unde \mathbf{x} este soluția

$$\mathbf{x} = [x_1 \ x_2 \ \cdots \ x_n]^T \in \mathbb{R}^n. \quad (5)$$

Notes

Buna formulare matematică

Problema este bine formulată din punct de vedere matematic
(soluția există și este unică)

\Leftrightarrow
matricea A este nesingulară (are determinantul nenul).
Se scrie formal:

" $\mathbf{x} = \mathbf{A}^{-1}\mathbf{b}$ "

trebuie citită ca:

" x este solutia sistemului algebraic liniar $Ax = b$ "

și NU "se calculează inversa matricei \mathbf{A} care se înmulțește cu vectorul \mathbf{b} ".

Conditionarea problemei

$$\kappa(\mathbf{A}) = \|\mathbf{A}\| \|\mathbf{A}^{-1}\| \quad (6)$$

număr de condiționare la inversare al matricei A.

$$\varepsilon_X \leq \kappa(\mathbf{A})\varepsilon_B, \quad (7)$$

- $\kappa(\mathbf{A}) \geq 1$:
Cazul cel mai favorabil: $n_A = 1$ și $\varepsilon_x = \varepsilon_b$. (matrice ortogonală)
 - Numărul de condiționare este o proprietate a matricei și nu are legătură nici cu metoda de rezolvare propriu-zisă, nici cu erorile de rotunjire care apar în mediul de calcul

În practică:

Dacă $\kappa(\mathbf{A}) > 1/\text{eps}$ problema se consideră slab conditionată.

Clasificarea metodelor

- 1 **Metode directe** - găsesc soluția teoretică a problemei într-un **număr finit de pași**. (Gauss, factorizare LU)
- 2 **Metode iterative** - generează un **șir de aproximări** ale soluției care se dorește a fi convergent către soluția exactă.
 - **staționare:** Jacobi, Gauss-Seidel, SOR, SSOR
 - **nestaționare (semiiterative):** gradienti conjugăți (GC), reziduu minim (MINRES), reziduu minim generalizat (GMRES), gradienti biconjugăți (BiGC), etc.

Notes

Idea

Metoda Jacobi
Metoda Gauss-Seidel
SOR

Ideea metodelor staționare

$$\mathbf{A}\mathbf{x} = \mathbf{b} \quad (8)$$

se construiește un **șir de aproximări**
 $\mathbf{x}^{(0)}, \mathbf{x}^{(1)}, \dots, \mathbf{x}^{(k)}, \dots$

$$\lim_{k \rightarrow \infty} \mathbf{x}^{(k)} = \mathbf{x}^*, \quad \text{unde} \quad \mathbf{A}\mathbf{x}^* = \mathbf{b}. \quad (9)$$

$$\mathbf{x}^{(k)} = \begin{bmatrix} x_1^{(k)} \\ x_2^{(k)} \\ \vdots \\ x_n^{(k)} \end{bmatrix} \in \mathbb{R}^{n \times 1}.$$

Notes

Ideea metodelor staționare

Algoritmul are nevoie de

- ➊ o inițializare $\mathbf{x}^{(0)}$;
- ➋ un mod de generare a sirului de iterații;
- ➌ un criteriu de oprire.

1. Inițializarea

- în principiu, arbitrară;
- dacă este posibil, cât mai aproape de soluție.

Ideea metodelor staționare

2. Sirul de iterații se generează recursiv:

$$\mathbf{x}^{(k)} = F(\mathbf{x}^{(k-1)}), \quad (10)$$

$$\mathbf{x}^* = F(\mathbf{x}^*), \quad (11)$$

\mathbf{x}^* este punct fix pentru aplicația F .

În concluzie, soluția exactă a sistemului de ecuații este și punct fix pentru F . Rezolvarea sistemului de ecuații algebrice liniare se face prin căutarea unui punct fix pentru F .

Notes

Notes

Ideea metodelor staționare

$$\mathbf{A} = \mathbf{B} - \mathbf{C}. \quad (12)$$

$$\mathbf{Bx} = \mathbf{Cx} + \mathbf{b} \quad (13)$$

$$\mathbf{x} = \mathbf{Mx} + \mathbf{u}, \quad (14)$$

$$\begin{aligned} \mathbf{M} &= \mathbf{B}^{-1}\mathbf{C}, \\ \mathbf{u} &= \mathbf{B}^{-1}\mathbf{b}. \end{aligned} \quad (15)$$

$\mathbf{M} \in \mathbb{R}^{n \times n}$ se numește *matrice de iteratie*.

$$F(\mathbf{x}) = \mathbf{Mx} + \mathbf{u}, \quad (16)$$

Ideea metodelor staționare

$$\mathbf{x}^{(k)} = F(\mathbf{x}^{(k-1)}), \quad (17)$$

$$\mathbf{x}^{(k)} = \mathbf{Mx}^{(k-1)} + \mathbf{u}, \quad (18)$$

$$\mathbf{x}^{(k)} = \mathbf{B}^{-1}\mathbf{Cx}^{(k-1)} + \mathbf{B}^{-1}\mathbf{b}. \quad (19)$$

$$\mathbf{Bx}^{(k)} = \mathbf{Cx}^{(k-1)} + \mathbf{b}, \quad (20)$$

\mathbf{B} are o structură particulară.

Notes

Ideea metodelor staționare

3. Criteriul de oprire

Condiție de oprire bazată de criteriu Cauchy de convergență:

$$\|\mathbf{x}^{(k)} - \mathbf{x}^{(k-1)}\| \leq \varepsilon, \quad (21)$$

Se poate întâmpla însă ca sirul iterațiilor să nu fie convergent.

Procedurile iterative vor avea ca parametri de intrare, pe lângă mărimele ce definesc sistemul:

- o eroare ce reprezintă criteriul dorit de oprire a iterării;
- un număr maxim de iterări, util pentru a asigura oprirea naturală a procedurii în caz de neconvergență.

Nu are sens ca $\varepsilon < \text{eps } \|\mathbf{x}^{(k)}\|$.

Util: vectori și valori proprii

Definiție: vectorii proprii \mathbf{v} ai unei matrice pătrate reale \mathbf{M} , de dimensiune n sunt acei vectori nenuli, pentru care există un scalar λ astfel încât

$$\mathbf{M}\mathbf{v} = \lambda\mathbf{v}. \quad (22)$$

Obs:

- Reprezentarea geometrică: prin aplicarea \mathbf{M} asupra lui, vectorul nu se rotește;
- Vectorii proprii ai unei matrice nu sunt unici. Dacă \mathbf{v} este un vector propriu, atunci și vectorul scalat $\alpha\mathbf{v}$ este de asemenea vector propriu;
- λ se numește valoare proprie a matricei \mathbf{M} asociată vectorului propriu \mathbf{v} .

Notes




Notes

Util: vettori si valori proprii

$$\mathbf{M}^k \mathbf{v} = \lambda^k \mathbf{v}. \quad (23)$$

Dacă $|\lambda| < 1$ atunci $\lim_{k \rightarrow \infty} \|\mathbf{M}^k \mathbf{v}\| = 0$.

Dacă $|\lambda| > 1$ atunci $\lim_{k \rightarrow \infty} \|\mathbf{M}^k \mathbf{v}\| = \infty$.



Înmulțirea repetată dintre o matrice și vectorii ei proprii

Util: vectori si valori proprii

Dacă M este simetrică, atunci ea are n vectori proprii liniar independenti:

independents:

Această mulțime nu este unică, dar fiecare vector propriu are asociată o valoare proprie unică

Dacă cei n vectori proprii ai lui \mathbf{M} formează o bază, atunci orice vector $\mathbf{u} = \sum_{i=1}^n \alpha_i \mathbf{v}^{(i)}$.

$$\mathbf{M}^k \mathbf{u} = \alpha_1 \lambda_1^k \mathbf{v}^{(1)} + \cdots + \alpha_n \lambda_n^k \mathbf{v}^{(n)}. \quad (24)$$

Dacă toate valorile proprii sunt subunitare în modul, atunci norma vectorului resultant va fi de către zero. E suficient ca o singură valoare proprie să fie în modul mai mare ca 1, ca norma vectorului rezultant să fie de către infinit.

Notes

Util: vectori și valori proprii

Raza spectrală a unei matrice: propriii

$$\rho(M) = \max_i |\lambda_i|. \quad (25)$$

Valorile proprii sunt rădăcinile polinomului characteristic.

Deoarece

$$(\lambda I - M)v = 0 \quad (26)$$

rezultă în mod necesar anularea *polinomului characteristic al matricei*:

$$\det(\lambda I - M) = 0. \quad (27)$$

Ecuație de gradul n în λ care, cf. teoremei fundamentale a algebrei, are exact n soluții (reale sau în perechi complex conjugate), care sunt valorile proprii ale matricei.

Convergență

Teorema 1: Condiția necesară și suficientă

ca procesul iterativ să fie convergent este ca raza spectrală a matricei de iterație să fie strict subunitară:

$$\rho(M) < 1.$$

$$\mathbf{e}^{(k)} = \mathbf{x}^{(k)} - \mathbf{x}^* = F(\mathbf{x}^{(k-1)}) - F(\mathbf{x}^*) = M\mathbf{x}^{(k-1)} + \mathbf{u} - M\mathbf{x}^* - \mathbf{u} = M\mathbf{e}^{(k-1)}, \quad (28)$$

$$\mathbf{e}^{(k)} = M\mathbf{e}^{(k-1)} = M^2\mathbf{e}^{(k-2)} = \dots = M^k\mathbf{e}^{(0)}. \quad (29)$$

Notes

Convergență

Teorema 2: O condiție suficientă

ca procesul iterativ să fie convergent este ca norma matricei de iterație să fie strict subunitară:

$$\|\mathbf{M}\| < 1.$$

$$\rho(\mathbf{M}) \leq \|\mathbf{M}\|. \quad (30)$$

$$\|\mathbf{e}^{(k)}\| \leq \|\mathbf{M}\|^k \|\mathbf{e}^{(0)}\|. \quad (31)$$

Convergență

Mai mult

$$\begin{aligned} \|\mathbf{x}^{(k)} - \mathbf{x}^{(k-1)}\| &= \|\mathbf{Mx}^{(k-1)} + \mathbf{u} - \mathbf{Mx}^{(k-2)} - \mathbf{u}\| = \\ &= \|\mathbf{M}(\mathbf{x}^{(k-1)} - \mathbf{x}^{(k-2)})\| \leq \\ &\leq \|\mathbf{M}\| \|\mathbf{x}^{(k-1)} - \mathbf{x}^{(k-2)}\|, \end{aligned} \quad (32)$$

⇒ Utilizarea unui criteriu de oprire Cauchy este pe deplin justificată.

Notes

Notes

Convergență

Fie o margine a erorii absolute notată cu a_k , unde $\|\mathbf{e}^{(k)}\| \leq a_k$.

$$a_k = \|\mathbf{M}\|^k a_0, \quad (33)$$

$$\log(a_k) = k \log \|\mathbf{M}\| + \log a_0. \quad (34)$$

$R(\mathbf{M}) = -\log \|\mathbf{M}\|$ se numește rata de convergență.

$$\log(a_k) = -kR(\mathbf{M}) + \log a_0. \quad (35)$$

$$R(\mathbf{M}) = \log(a_{k-1}) - \log(a_k), \quad (36)$$

Notes

Convergență

$$R(\mathbf{M}) = \log(a_{k-1}) - \log(a_k), \quad (37)$$

Rata de convergență = numărul de cifre semnificative corecte ce se câștigă la fiecare iterație.

Exemplu:

- $\|\mathbf{M}\| = 10^{-3}$, rata de convergență este 3, deci la fiecare iterație numărul de cifre semnificative corecte crește cu 3.
- $\|\mathbf{M}\| = 10^{-1}$, la fiecare iterație se câștigă o cifră semnificativă.

OBS:

- Alegerea valorii inițiale nu are nici o influență asupra convergenței sau neconvergenței procesului iterativ;
- În cazul unui proces iterativ convergent, valoarea inițială afectează doar numărul de iterării necesar pentru atingerea unei erori impuse.

Notes

Algoritm general

```
procedură metodă_iterativă(n, B, C, b, x0, er, maxit, x)
...
xv = x0 ; inițializează sirul iterărilor
k = 0 ; inițializare contor iterări
repetă
    t = C * xv + b
    metodă_directă (n, B, t, x)
    d = ||xv - x|| ; actualizează soluția veche
    xv = x
    k = k + 1
cât timp d > er și k ≤ maxit
return
```

Algoritm general

Efortul de calcul

- poate fi făcut doar pentru o singură iterație;
- depinde de structura matricelor în care a fost descompusă matricea coeficientilor;
- e consumat mai ales în calculul lui **t** și în procedura de rezolvare directă, care în general are o complexitate liniară deoarece **B** are o structură rară, particulară.
- este de așteptat ca procedeul iterativ să fie cu atât mai rapid convergent cu cât **B** conține mai multă informație din **A**.

Notes

Algoritm general

Efortul de calcul

- poate fi făcut doar pentru o singură iterare;
- depinde de structura matricelor în care a fost descompusă matricea coeficientilor;
- e consumat mai ales în calculul lui **t** și în procedura de rezolvare directă, care în general are o complexitate liniară deoarece **B** are o structură rară, particulară.
- este de așteptat ca procedeul iterativ să fie cu atât mai rapid convergent cu cât **B** conține mai multă informație din **A**.

Notes

Metoda Jacobi: un exemplu simplu

A se descompune astfel încât **B** este diagonală.

$$\left\{ \begin{array}{ccccccc} x & + & 2y & - & z & = & -1 \\ -2x & + & 3y & + & z & = & 0 \\ 4x & - & y & - & 3z & = & -2 \end{array} \right. \Leftrightarrow \left\{ \begin{array}{ccccccc} x & = & -2y + z - 1 \\ 3y & = & 2x - z \\ -3z & = & -4x + y - 2 \end{array} \right. \quad (38)$$

$$\begin{aligned} x^{(n)} &= -2y^{(v)} + z^{(v)} - 1 \\ y^{(n)} &= 2x^{(v)} - z^{(v)} \\ z^{(n)} &= -4x^{(v)} + y^{(v)} - 2 \end{aligned} \quad (39)$$

$[0, 0, 0]^T$, $[-1, 0, -2]^T$, $[-3, 0, 2]^T$, etc.

Algoritmul metodei Jacobi

Partitionarea matricei în metodele iterative:

$$\begin{aligned}
 \mathbf{A} &= \begin{bmatrix} a_{11} & a_{12} & a_{13} & a_{14} \\ a_{21} & a_{22} & a_{23} & a_{24} \\ a_{31} & a_{32} & a_{33} & a_{34} \\ a_{41} & a_{42} & a_{43} & a_{44} \end{bmatrix} = \\
 &= \begin{bmatrix} 0 & 0 & 0 & 0 \\ a_{21} & 0 & 0 & 0 \\ a_{31} & a_{32} & 0 & 0 \\ a_{41} & a_{42} & a_{43} & 0 \end{bmatrix} + \begin{bmatrix} a_{11} & 0 & 0 & 0 \\ 0 & a_{22} & 0 & 0 \\ 0 & 0 & a_{33} & 0 \\ 0 & 0 & 0 & a_{44} \end{bmatrix} + \begin{bmatrix} 0 & a_{12} & a_{13} & a_{14} \\ 0 & 0 & a_{23} & a_{24} \\ 0 & 0 & 0 & a_{34} \\ 0 & 0 & 0 & 0 \end{bmatrix} \\
 &= \mathbf{L} + \mathbf{D} + \mathbf{U}
 \end{aligned}$$

$$\mathbf{A} = \mathbf{L} + \mathbf{D} + \mathbf{U}$$

A = B - C unde, în metoda Jacobi

$$\mathbf{B} = \mathbf{D}, \quad \mathbf{C} = -(\mathbf{L} + \mathbf{U}), \quad (40)$$

Algoritmul metodei Jacobi

Calculul recursiv al noii iterării

$$\mathbf{D}\mathbf{x}^{(k)} = -(\mathbf{L} + \mathbf{U})\mathbf{x}^{(k-1)} + \mathbf{b}. \quad (41)$$

Ecuăția i :

$$a_{ii}x_i^{(k)} = - \sum_{\substack{j=1 \\ j \neq i}}^n a_{ij}x_j^{(k-1)} + b_i. \quad (42)$$

$$\mathbf{x}_i^{(n)} = (b_i - \sum_{\substack{j=1 \\ j \neq i}}^n x_j^{(n)}) / a_{ii} \quad i = 1, \dots, n. \quad (43)$$

Obs: Fiecare componentă nouă poate fi calculată independent de celelalte componente noi, motiv pentru care metoda Jacobi se mai numește și **metoda deplasărilor simultane**.

Algoritmul metodei Jacobi

Notes

Notes

Algoritmul metodei Jacobi

procedură Jacobi($n, a, b, x_0, er, maxit, x$)


pentru $i = 1, n$
 $xv_i = x_0$
 • $k = 0$; inițializare contor iterări
repetă
 $d = 0$
pentru $i = 1, n$
 $s = 0$
pentru $j = 1, n$
dacă $j \neq i$
 $s = s + a_{ij} * xv_j$
 •
 $x_i = (b_i - s) / a_{ii}$
 $d = d + (x_i - xv_i)^2$
 •
 $d = \sqrt{d}$
pentru $i = 1, n$
 $xv_i = x_i$; actualizează soluția veche
 •
 $k = k + 1$
cât timp $d > er$ și $k \leq maxit$
return

A set of small, light-blue navigation icons typically found in presentation software like Beamer. They include symbols for back, forward, search, and other document-related functions.

Convergența metodei Jacobi

Matricea de iteratie

$$\mathbf{M} = -\mathbf{D}^{-1}(\mathbf{L} + \mathbf{U}). \quad (44)$$



Schimbarea ordinii ecuațiilor din sistem înseamnă schimbarea matricei de iterație, deci a proprietăților de convergență ale metodei Jacobi.

Rezultat util: Dacă matricea coeficientelor este diagonal dominantă, atunci condiția suficientă de convergență este satisfăcută și algoritmul Jacobi este convergent.


A set of small, semi-transparent navigation icons typically found in presentation software like Beamer. The icons include symbols for back, forward, search, and other document-related functions.

Notes

Convergența metodei Jacobi

Matricea de iteratie

$$\mathbf{M} = -\mathbf{D}^{-1}(\mathbf{L} + \mathbf{U}). \quad (44)$$



Schimbarea ordinii ecuațiilor din sistem înseamnă schimbarea matricei de iterație, deci a proprietăților de convergență ale metodei Jacobi.

Rezultat util: Dacă matricea coeficientelor este diagonal dominantă, atunci condiția suficientă de convergență este satisfăcută și algoritmul Jacobi este convergent.

A set of small, semi-transparent navigation icons typically found in presentation software like Beamer. The icons include symbols for back, forward, search, and other document-related functions.

Notes

Metoda Gauss-Seidel: un exemplu simplu

A se descompune astfel încât **B** este triunghiular inferioară.

$$\left\{ \begin{array}{ccccccc} x & + & 2y & - & z & = & -1 \\ -2x & + & 3y & + & z & = & 0 \\ 4x & - & y & - & 3z & = & -2 \end{array} \right. \Leftrightarrow \left\{ \begin{array}{ccccccc} x & & & & & & = -2y + z - 1 \\ -2x & + & 3y & & & & = -z \\ 4x & - & y & - & 3z & = & -2 \end{array} \right. \quad (45)$$

$$\begin{array}{rcl}
 x^{(n)} & = & -2y^{(v)} + z^{(v)} - 1 \\
 -2x^{(n)} + 3y^{(n)} & = & -z^{(v)} \\
 4x^{(n)} - y^{(n)} - 3z^{(n)} & = & -2
 \end{array} \tag{46}$$

$[0, 0, 0]^T$, $[-1, -2, 4]^T$, $[7, 10, -40]^T$, etc.

Algoritmul metodei Gauss-Seidel

Partitionarea matricei în metodele iterative:

$$\begin{aligned}
 \mathbf{A} &= \begin{bmatrix} a_{11} & a_{12} & a_{13} & a_{14} \\ a_{21} & a_{22} & a_{23} & a_{24} \\ a_{31} & a_{32} & a_{33} & a_{34} \\ a_{41} & a_{42} & a_{43} & a_{44} \end{bmatrix} = \\
 &= \begin{bmatrix} 0 & 0 & 0 & 0 \\ a_{21} & 0 & 0 & 0 \\ a_{31} & a_{32} & 0 & 0 \\ a_{41} & a_{42} & a_{43} & 0 \end{bmatrix} + \begin{bmatrix} a_{11} & 0 & 0 & 0 \\ 0 & a_{22} & 0 & 0 \\ 0 & 0 & a_{33} & 0 \\ 0 & 0 & 0 & a_{44} \end{bmatrix} + \begin{bmatrix} 0 & a_{12} & a_{13} & a_{14} \\ 0 & 0 & a_{23} & a_{24} \\ 0 & 0 & 0 & a_{34} \\ 0 & 0 & 0 & 0 \end{bmatrix} \\
 &= \mathbf{L} + \mathbf{D} + \mathbf{U}
 \end{aligned}$$

$$\mathbf{A} \equiv \mathbf{L} + \mathbf{D} + \mathbf{U}$$

A = B - C, unde în metoda Gauss-Seidel

$$\mathbf{B} \equiv \mathbf{L} \pm \mathbf{D}, \quad \mathbf{C} \equiv -\mathbf{U}. \quad (47)$$

Notes

Notes

Algoritmul metodei Gauss-Seidel

Calculul recursiv al noii iterări

$$(\mathbf{L} + \mathbf{D})\mathbf{x}^{(k)} = -\mathbf{U}\mathbf{x}^{(k-1)} + \mathbf{b}. \quad (48)$$

Ecuația i :

$$\sum_{j=1}^{i-1} a_{ij}x_j^{(k)} + a_{ii}x_i^{(k)} = -\sum_{j=i+1}^n a_{ij}x_j^{(k-1)} + b_i. \quad (49)$$

$$\sum_{j=1}^{i-1} a_{ij}x_j^{(n)} + a_{ii}x_i^{(n)} = -\sum_{j=i+1}^n a_{ij}x_j^{(v)} + b_i, \quad (50)$$

Rezolvarea sistemului: prin substituție progresivă, conform formulei:

$$\mathbf{x}_i^{(n)} = (b_i - \sum_{j=1}^{i-1} a_{ij}x_j^{(n)} - \sum_{j=i+1}^n a_{ij}x_j^{(v)})/a_{ii}. \quad (51)$$

Notes

Algoritmul metodei Gauss-Seidel

Observații:

- Este respectat **principiul lui Seidel**, conform căruia o valoare nouă a unei necunoscute trebuie folosită imediat în calcule.
- O componentă nouă nu poate fi calculată independent de celelalte componente noi, motiv pentru care metoda Gauss-Seidel se mai numește și **metoda deplasărilor successive**

Notes

Algoritmul metodei Gauss-Seidel

```

procedură Gauss-Seidel(n, a, b, x0, er, maxit, x)
; rezolvă sistemul algebric liniar  $ax = b$ , de dimensiune  $n$  prin metoda Gauss-Seidel
; declarații ca la procedura Jacobi
...
pentru  $i = 1, n$ 
     $xv_i = x0_i$ 
•
 $k = 0$                                 ; inițializare contor iterării
repetă
     $d = 0$ 
    pentru  $i = 1, n$ 
         $s = b_i$ 
        pentru  $j = 1, n$ 
            dacă  $j \neq i$ 
                 $s = s + a_{ij} * xv_j$ 
        •
         $s = s / a_{ii}$ 
         $p = |x_j - s|$ 
        dacă  $p > d$ 
             $d = p$ 
    •
     $x_i = s$ 
    •
     $k = k + 1$ 
cât timp  $d > er$  și  $k \leq maxit$ 
return

```


Gabriela Ciuprina Sisteme de ecuatii algebrice liniare - metode iterative

nu este necesara memorarea soluției anterioare (ca la JACOU). Udată calculată noua valoare, vechea valoare este folosită doar la calculul ero-

Convergența metodei Gauss-Seidel

Matricea de iteratie

$$\mathbf{M} = -(\mathbf{L} + \mathbf{D})^{-1}\mathbf{U}. \quad (52)$$



Schimbarea ordinii ecuațiilor din sistem înseamnă schimbarea matricei de iterare, deci a proprietăților de convergență ale metodei Gauss-Seidel.

Rezultate utile:

- Dacă matricea coeficienților este diagonal dominantă, atunci algoritmul Gauss-Seidel este convergent.

Notes

Notes

Evaluarea algoritmilor Jacobi și Gauss-Seidel

Efortul total de calcul depinde de numărul de operații m (care depinde de matricea de iterare).

- Efortul de calcul pe iterare este $O(2n^2)$.
 - Efortul total de calcul al algoritmilor Jacobi și Gauss-Seidel *implementați cu matrice pline*: $T = O(2mn^2)$.
 - Metoda Jacobi sau Gauss-Seidel este mai eficientă decât metoda Gauss dacă $2mn^2 < 2n^3/3$, deci dacă $m < n/3$.

Necesarul de memorie (matrice pline):

$$M_{GS} = O(n^2 + 2n) \approx O(n^2)$$

$$M_J = O(n^2 + 3n) \approx O(n^2)$$

diferența este nesemnificativă

Evaluarea algoritmilor Jacobi și Gauss-Seidel

Observații:

- ① Dacă matricea coeficienților este rară (memorată MM, CRS sau CCS), atunci efortul de calcul pe iterație se poate diminua.
 - ② Important: *Nu putem vorbi de umpleri ale matricei coeficienților* aşa cum se întâmplă în cazul algoritmului Gauss aplicat pentru matrice rare.

Metodele iterative sunt mai potrivite decât metodele directe pentru rezolvarea sistemelor cu matrice rare, într-un context hardware în care memoria disponibilă nu este suficientă rezolvării prin metode directe.

Notes

Metoda Suprarelaxării succesive (SOR)

Procedeu de accelerare a convergenței:

$$x_i^{(n)} = x_i^{(\nu)} + \omega(x_i^{(n_{-GS})} - x_i^{(\nu)}). \quad (53)$$

unde ω se numește factor de suprarelaxare

$\omega = 1$ corespunde metodei Gauss-Seidel.

Modificarea în pseudocodul algoritmului Gauss-Seidel:

instructiunea $x_i = s$ se înlocuiește cu $x_i = x_i + \omega(s - x_i)$.

$$\begin{aligned} x_i^{(n)} &= \omega x_i^{(n-GS)} + (1-\omega)x_i^{(v)} = \\ &= \omega(b_i - \sum_{j=1}^{i-1} a_{ij}x_j^{(n)} - \sum_{j=i+1}^n a_{ij}x_j^{(v)})/a_{ii} + (1-\omega)x_i^{(v)} \end{aligned} \quad (54)$$

$$(\mathbf{D} + \omega \mathbf{L})\mathbf{x}^{(n)} = [(1 - \omega)\mathbf{D} - \omega \mathbf{U}]\mathbf{x}^{(v)} + \omega b. \quad (55)$$

Metoda Suprarelaxării succesive (SOR)

Matricea de iteratie a metodei SOR:

$$\mathbf{M} = (\mathbf{D} + \omega \mathbf{L})^{-1} [(1 - \omega) \mathbf{D} - \omega \mathbf{U}], \quad (56)$$

- Metoda nu converge dacă $\omega \notin (0, 2)$.
 - Cazul $\omega \in (0, 1)$ corespunde unei subrelaxări și se folosește atunci când metoda Gauss-Seidel nu converge.
 - Dacă matricea este simetrică și pozitiv definită, SOR este garantat convergentă (\forall) $\omega \in (0, 2)$.
 - Alegerea valorii lui ω poate afecta în mod semnificativ rata de convergență.
 - În general, este dificil să se calculeze apriori valoarea optimală a factorului de suprarelaxare.

Metoda Suprarelaxării succesive (SOR)

- Pentru matricile obținute prin discretizarea unor ecuații cu derivate parțiale prin parcurgerea sistematică a nodurilor rețelei de discretizare se poate demonstra că

$$\omega_{opt} = \frac{2}{1 + \sqrt{1 - \rho^2}}, \quad (57)$$

unde ρ este raza spectrală a matricei de iterație Jacobi. În practică se folosesc tehnici euristice, ce iau în considerare dimensiunea gridului de discretizare al problemei ["Templates"].

- În cazul matricelor simetrice, o variantă a metodei SOR, numită SSOR, este folosită ca metodă de preconditionare pentru metode nestaționare.

Algoritmul general al metodelor stationare

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

$$A \equiv B - C$$

$$\mathbf{Bx}^{(k+1)} = \mathbf{Cx}^{(k)} + \mathbf{b}. \quad (58)$$

$$\mathbf{B}(\mathbf{x}^{(k+1)} - \mathbf{x}^{(k)}) = \mathbf{b} - \mathbf{Ax}^{(k)}. \quad (59)$$

Reziduul la iteratia k

$$\mathbf{r}^{(k)} \equiv \mathbf{b} - \mathbf{A}\mathbf{x}^{(k)}. \quad (60)$$

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \mathbf{B}^{-1} \mathbf{r}^{(k)} \quad (61)$$

Algoritmul general al metodelor stationare

$$\mathbf{r}^{(k)} = \mathbf{b} - \mathbf{Ax}^{(k)}, \quad (62)$$

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \mathbf{B}^{-1} \mathbf{r}^{(k)}, \quad (63)$$

Staționaritatea se referă la faptul că reziduu este întotdeauna înmulțit cu matricea \mathbf{B}^{-1} , aceeași pe parcursul tuturor iteratiilor:

- Jacobi: $\mathbf{B} = \mathbf{D}$
 - Gauss-Seidel: $\mathbf{B} = \mathbf{D} + \mathbf{L}$
 - SOR: $\mathbf{B} = \omega^{-1}(\mathbf{D} + \omega\mathbf{L})$.

Nu se face inversarea propriu zisă, ci se rezolvă un sistem algebric liniar.

Algoritmul general al metodelor stationare

procedură metodă_iterativă_v2($n, B, A, b, x_0, er, maxit, x$)
 ...
xv = x0 ; inițializează sirul iterărilor
 $k = 0$; inițializare contor iterării
repetă
 r = b - A · xv ; calculează reziduu
 metodă_directă (n, B, r, z)
 $d = \|z\|$
 x = xv + z
 xv = x ; actualizează soluția veche
 $k = k + 1$
cât timp $d > er$ și $k \leq maxit$
 retur

Algoritmul general al metodelor staționare

- Metodele iterative sunt eficiente însă pentru matrici rare.
- În cazul matricilor pline, timpul de rezolvare cu metode iterative poate fi comparabil cu timpul de factorizare. Într-o astfel de situație, factorizarea este mai utilă deoarece, o dată ce factorii L și U sunt calculați, rezolvarea sistemului poate fi făcută oricând pentru alt termen liber.
- De aceea, un pseudocod simplificat, în care sunt scrise operații cu matrice este mai general, putând fi adaptat unor matrice rare.

Notes

Clasa de probleme

Este o metodă iterativă nestaționară, pentru rezolvarea unor sisteme de ecuații algebrice de forma

$$\mathbf{A}\mathbf{x} = \mathbf{b}, \quad (64)$$

unde **A** este **simetrică și pozitiv definită**.

- Algoritmul metodei gradientilor conjugăți (GC) este eficient pentru **matrice rare**.

⇒ Pseudocodurile vor fi descrise simplificat, evidențiind operații de algebră liniară, presupuse a fi implementate ținând cont de raritatea structurilor de date.

Notes

Forma pătratică

Metoda GC este simplu de înțeles dacă ea este formulată ca o problemă de minimizare.

Fie o formă pătratică

$$f : \mathbb{R}^n \rightarrow \mathbb{R}$$
$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^T \mathbf{A} \mathbf{x} - \mathbf{b}^T \mathbf{x} + c, \quad (65)$$

unde $\mathbf{A} \in \mathbb{R}^{n \times n}$, $\mathbf{x}, \mathbf{b} \in \mathbb{R}^{n \times 1}$, $c \in \mathbb{R}$.

Teoremă

Dacă \mathbf{A} este simetrică și pozitiv definită, atunci funcția $f(\mathbf{x})$ dată de (65) este minimizată de soluția ecuației $\mathbf{Ax} = \mathbf{b}$.

Forma pătratică

Justificarea teoremei:

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^T \mathbf{A} \mathbf{x} - \mathbf{b}^T \mathbf{x} + c \quad (66)$$

$$\nabla f(\mathbf{x}) = \frac{1}{2} \mathbf{A}^T \mathbf{x} + \frac{1}{2} \mathbf{A} \mathbf{x} - \mathbf{b}. \quad (67)$$

În punctul de minim gradientul este zero

$$\nabla f(\mathbf{x}) = 0 \Rightarrow \frac{1}{2} (\mathbf{A}^T + \mathbf{A}) \mathbf{x} = \mathbf{b}. \quad (68)$$


Dacă $\mathbf{A}^T = \mathbf{A}$ (matrice simetrică) atunci (68) $\Leftrightarrow \mathbf{Ax} = \mathbf{b}$.

\Rightarrow soluția ecuației $\mathbf{Ax} = \mathbf{b}$ este punct critic pentru f .


Dacă în plus, \mathbf{A} pozitiv definită, atunci pct.critic este un minim.

Notes

Matrice pozitiv definită - intuitiv




Funcția pătratică asociată unei matrice pozitiv definite. Minimul funcției coincide cu soluția sistemului. GC funcționează.




Funcția pătratică asociată unei matrice negativ definite. Maximul funcției coincide cu soluția sistemului. Algoritmul GC poate fi modificat cu siguranță pentru a putea funcționa.

Matrice pozitiv semidefinită/indefinită - intuitiv



Funcția pătratică asociată unei matrice singulare, pozitiv semidefinite. Minimul este atins într-o infinitate de valori. Sistemul are o infinitate de soluții (problema prost formulată matematic).



Funcția pătratică asociată unei matrice indefinite. Soluția sistemului este punct și pentru f. GC nu funcționează.

Notes

Metoda celei mai rapide coborâri (a gradientului)

$$\mathbf{A}\mathbf{x} = \mathbf{b}, \quad (69)$$

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^T \mathbf{A} \mathbf{x} - \mathbf{b}^T \mathbf{x} + \mathbf{c} \quad (70)$$

$$\nabla f(\mathbf{x}) = \frac{1}{2}\mathbf{A}^T\mathbf{x} + \frac{1}{2}\mathbf{Ax} - \mathbf{b} = \mathbf{Ax} - \mathbf{b}. \quad (71)$$

Idea: căutarea pe direcții care corespund ratei celei mai mari de schimbare a funcției.

Pentru aproximarea $\mathbf{x}^{(k)}$, direcția celei mai rapide coborâri:

$$-\nabla f(\mathbf{x}^{(k)}) = \mathbf{b} - \mathbf{A}\mathbf{x}^{(k)}. \quad (72)$$

Se definen:

$$\mathbf{e}^{(k)} = \mathbf{x}^{(k)} - \mathbf{x}, \quad (73)$$

$$\mathbf{r}^{(k)} \equiv \mathbf{b} - \mathbf{Ax}^{(k)}. \quad (74)$$

$\mathbf{r}^{(k)}$ - reziduul la iteratia k .

Metoda celei mai rapide coborâri (a gradientului)

$$\mathbf{e}^{(k)} \equiv \mathbf{x}^{(k)} - \mathbf{x}_* \quad (75)$$

$$\mathbf{r}^{(k)} \equiv \mathbf{b} - \mathbf{A}\mathbf{x}^{(k)}. \quad (76)$$

$$\mathbf{r}^{(k)} \equiv \mathbf{b} - \mathbf{A}(\mathbf{e}^{(k)} + \mathbf{x}) \equiv \mathbf{b} - \mathbf{A}\mathbf{e}^{(k)} - \mathbf{Ax}.$$

Legătura între eroare și reziduu:

$$\mathbf{r}^{(k)} = -\mathbf{A}\mathbf{e}^{(k)} \quad (77)$$

$$\begin{aligned}\nabla f(\mathbf{x}) &= \mathbf{A}\mathbf{x} - \mathbf{b}, \\ -\nabla f(\mathbf{x}^{(k)}) &\equiv \mathbf{b} - \mathbf{A}\mathbf{x}^{(k)}\end{aligned}\quad (78)$$

Beziduiul este directia celei mai rapide coborâri:

$$\mathbf{r}^{(k)} = -\nabla f(\mathbf{x}^{(k)}) \quad (79)$$

Notes

Metoda celei mai rapide coborâri (a gradientului)

Corecția primei iterații: după direcția reziduului inițializării:

$$\mathbf{x}^{(1)} = \mathbf{x}^{(0)} + \alpha \mathbf{r}^{(0)}. \quad (80)$$

α se va alege a.î. pe direcția respectivă funcția să fie minimă.

$$g(\alpha) = f(\mathbf{x}^{(1)}) \text{ minimă, } \Rightarrow \frac{dg}{d\alpha}(\mathbf{x}^{(1)}) = 0 \quad \Rightarrow (\nabla f(\mathbf{x}^{(1)}))^T \cdot \frac{d\mathbf{x}^{(1)}}{d\alpha} = 0. \quad (81)$$

$$\text{Din (79)} \Rightarrow \nabla f(\mathbf{x}^{(1)}) = -\mathbf{r}^{(1)}.$$

$$\text{Din}(80) \Rightarrow \frac{dx^{(1)}}{d\alpha} = r^{(0)}$$

(81) ⇒

$$\begin{aligned}
 (\mathbf{r}^{(1)})^T \cdot \mathbf{r}^{(0)} &= 0, \\
 (\mathbf{b} - \mathbf{Ax}^{(1)})^T \cdot \mathbf{r}^{(0)} &= 0, \quad \text{A simetrică} \Rightarrow \\
 [\mathbf{b} - \mathbf{A}(\mathbf{x}^{(0)} + \alpha \mathbf{r}^{(0)})]^T \mathbf{r}^{(0)} &= 0, \\
 (\mathbf{b} - \mathbf{Ax}^{(0)} - \alpha \mathbf{Ar}^{(0)})^T \cdot \mathbf{r}^{(0)} &= 0, \\
 (\mathbf{b} - \mathbf{Ax}^{(0)})^T \cdot \mathbf{r}^{(0)} - \alpha (\mathbf{Ar}^{(0)})^T \mathbf{r}^{(0)} &= 0, \\
 (\mathbf{r}^{(0)})^T \mathbf{r}^{(0)} &= \alpha (\mathbf{r}^{(0)})^T \mathbf{Ar}^{(0)}. \tag{82}
 \end{aligned}$$

Metoda celei mai rapide coborâri (a gradientului)

Corecția iterăției $k + 1$:

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \alpha_k \mathbf{r}^{(k)}. \quad (83)$$

α_k se va alege a.î.:

$g(\alpha_k) = f(\mathbf{x}^{(k+1)})$ minimă, \Rightarrow

$$\frac{dg}{d\alpha}(\mathbf{x}^{(k+1)}) = 0 \quad \Rightarrow (\nabla f(\mathbf{x}^{(k+1)}))^T \cdot \frac{d\mathbf{x}^{(k+1)}}{d\alpha_k} = 0. \quad (84)$$

$$\text{Din (79)} \Rightarrow \nabla f(\mathbf{x}^{(k+1)}) = -\mathbf{r}^{(k+1)};$$

$$\text{Din} \quad (83) \Rightarrow \frac{d\mathbf{x}^{(k+1)}}{d\alpha_k} = \mathbf{r}^{(k)}.$$

(84) \Rightarrow ortogonalitatea reziduurilor:

$$\begin{aligned}
 (\mathbf{r}^{(k+1)})^T \cdot \mathbf{r}^{(k)} &= 0, \\
 (\mathbf{b} - \mathbf{A}\mathbf{x}^{(k+1)})^T \cdot \mathbf{r}^{(k)} &= 0, \quad \text{A simetrică} \Rightarrow \\
 [\mathbf{b} - \mathbf{A}(\mathbf{x}^{(k)} + \alpha\mathbf{r}^{(k)})]^T \mathbf{r}^{(k)} &= 0, \\
 (\mathbf{b} - \mathbf{A}\mathbf{x}^{(k)} - \alpha\mathbf{A}\mathbf{r}^{(k)})^T \cdot \mathbf{r}^{(k)} &= 0, \\
 (\mathbf{b} - \mathbf{A}\mathbf{x}^{(k)})^T \cdot \mathbf{r}^{(k)} - \alpha(\mathbf{A}\mathbf{r}^{(k)})^T \mathbf{r}^{(k)} &= 0, \\
 (\mathbf{r}^{(k)})^T \mathbf{r}^{(k)} &= \alpha(\mathbf{r}^{(k)})^T \mathbf{A}^T \mathbf{r}^{(k)}
 \end{aligned} \tag{85}$$

Notes

Metoda celei mai rapide coborâri (a gradientului)

Algoritm - varianta 0

```
procedură metoda_gradientului_v0(n, A, b, x0, er, maxit, x)
...
xv = x0
k = 0
r = b - A · xv
    ; initializează sirul iterărilor
    ; initializare contor iterării
    ; calculează reziduu
cât timp  $\|r\| > er$  și k  $\leq maxit$ 
     $\alpha = r^T r / (r^T A r)$ 
    x = xv + αr
    r = b - A · xv
    xv = x
        ; actualizează soluția veche
    k = k + 1
•
return
```

Efortul cel mai mare: produsul matrice - vector. (2/iter.).

Metoda celei mai rapide coborâri (a gradientului)

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \alpha_k \mathbf{r}^{(k)}, \quad (86)$$

Înmulțim la stânga cu $-\mathbf{A}$ și adunăm $\mathbf{b} \Rightarrow$

$$\mathbf{r}^{(k+1)} = \mathbf{r}^{(k)} - \alpha_k \mathbf{A} \mathbf{r}^{(k)}, \quad (87)$$

Notes

Metoda celei mai rapide coborâri (a gradientului)

```
procedură metoda_gradientului(n, A, b, x0, er, maxit, x)
...
xv = x0 ; inițializează sirul iterațiilor
k = 0 ; inițializare contor iterații
r = b - A · xv ; calculează reziduu
e =  $\|r\|$ 
cât timp e > er și k ≤ maxit
    m = A · r
     $\alpha = r^T r / (r^T m)$ 
    e =  $\|r\|$ 
    x = xv + αr
    xv = x ; actualizează soluția veche
    k = k + 1
    r = r - αm
•
return
```

Metoda celei mai rapide coborâri (a gradientului)

Observații:

- 1 singur produs matrice vector pe iterație;
- Reziduul se calculează recursiv. Se pot acumula erori de rotunjire. Este bine ca periodic $r^{(k)} = b - Ax^{(k)}$.

Notes

Metoda celei mai rapide coborâri (a gradientului)

Analiza convergenței acestei metode se face pe baza
numărului de condiționare spectrală

$$\kappa = \frac{\max \lambda_i}{\min \lambda_i} \geq 1. \quad (88)$$

- Metoda poate converge rapid, într-un singur pas, dacă punctul de start este ales pe axele elipsoidului sau dacă forma pătratică este sferică (ceea ce corespunde cazului în care toate valorile proprii sunt egale).

Metoda celei mai rapide coborâri (a gradientului)


- În rest, convergența depinde de numărul de condiționare κ și de inițializare.
- Se poate demonstra că eroarea la fiecare iterație i este mărginită de

$$\|\mathbf{e}^{(i)}\| \leq \left(\frac{\kappa - 1}{\kappa + 1}\right)^i \|\mathbf{e}^{(0)}\| \quad (89)$$


Notes

Notes


Metoda celei mai rapide coborâri (a gradientului)



$\kappa = 10$



$\kappa = 10$



$\kappa = 1$

Convergența metodei gradientului depinde de inițializare și de numărul de condiționare spectrală. O problemă care are numărul de condiționare spectrală $\kappa = 1$ (toate valorile proprii sunt egale, iar forma pătratică este sferică) converge într-un singur pas.

Metoda direcțiilor conjugate

Metoda gradientului converge atât de încet deoarece direcțiile de căutare sunt ortogonale și se întâmplă ca pe parcursul iteratiilor direcțiile de căutare să se repete.

Ar fi de dorit să existe exact n direcții de căutare, $\mathbf{d}^{(0)}, \mathbf{d}^{(1)}, \dots, \mathbf{d}^{(n-1)}$ astfel încât soluția să fie găsită după exact n pași.

Notes

Metoda direcțiilor conjugate

La fiecare pas nou

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \alpha_k \mathbf{d}^{(k)}, \quad (90)$$

iar α_k se va alege astfel încât eroarea $\mathbf{e}^{(k+1)}$ să fie ortogonală pe $\mathbf{d}^{(k)}$ și, în consecință, nici o altă corecție să nu se mai facă în direcția lui $\mathbf{d}^{(k)}$:

$$(\mathbf{d}^{(k)})^T \mathbf{e}^{(k+1)} = 0. \quad (91)$$

OBS: În cazul particular în care direcțiile $\mathbf{d}^{(k)}$ sunt reziduurile, se obține exact metoda celei mai rapide coborâri.

Notes

Metoda direcțiilor conjugate

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \alpha_k \mathbf{d}^{(k)}, \quad (92)$$

Scădem soluția exactă din ambii termeni \Rightarrow

$$\mathbf{e}^{(k+1)} = \mathbf{e}^{(k)} + \alpha_k \mathbf{d}^{(k)}, \quad (93)$$

Din

$$(\mathbf{d}^{(k)})^T \mathbf{e}^{(k+1)} = 0. \quad (94)$$

$$(\mathbf{d}^{(k)})^T (\mathbf{e}^{(k)} + \alpha_k \mathbf{d}^{(k)}) = 0. \quad (95)$$

$$\alpha_k = -\frac{(\mathbf{d}^{(k)})^T \mathbf{e}^{(k)}}{(\mathbf{d}^{(k)})^T \mathbf{d}^{(k)}}. \quad (96)$$

Nu este utilă deoarece eroarea nu este cunoscută.

Notes

Metoda direcțiilor conjugate

Soluția constă în a face **direcțiile de căutare A-ortogonale** și nu ortogonale:

$$(\mathbf{d}^{(k)})^T \mathbf{A} \mathbf{d}^{(j)} = 0. \quad j < k. \quad (97)$$

Noua cerință: $\mathbf{e}^{(k+1)}$ să fie A-ortogonal pe $\mathbf{d}^{(k)}$

(echivalent cu găsirea unui punct de minim de-a lungul direcției $\mathbf{d}^{(k)}$, ca la metoda gradientului).

$$\begin{aligned} \frac{d}{d\alpha} f(\mathbf{x}^{(k+1)}) &= 0, \\ (\nabla f(\mathbf{x}^{(k+1)}))^T \frac{d}{d\alpha} (\mathbf{x}^{(k+1)}) &= 0, \\ -(\mathbf{r}^{(k+1)})^T \mathbf{d}^{(k)} &= 0, \\ (\mathbf{d}^{(k)})^T \mathbf{A} \mathbf{e}^{(k+1)} &= 0. \end{aligned} \quad (98)$$

Metoda direcțiilor conjugate

Rezultă

$$(\mathbf{d}^{(k)})^T \mathbf{A} (\mathbf{e}^{(k)} + \alpha_k \mathbf{d}^{(k)}) = 0$$

de unde

$$\alpha_k = -\frac{(\mathbf{d}^{(k)})^T \mathbf{A} \mathbf{e}^{(k)}}{(\mathbf{d}^{(k)})^T \mathbf{A} \mathbf{d}^{(k)}} = \frac{(\mathbf{d}^{(k)})^T \mathbf{r}^{(k)}}{(\mathbf{d}^{(k)})^T \mathbf{A} \mathbf{d}^{(k)}}, \quad (99)$$

expresie ce se poate calcula.

Notes

Metoda direcțiilor conjugate

Teorema

Metoda direcțiilor conjugate calculează soluția în exact n pași.

Pentru demonstrație consultați [Shewchuk94].

Găsirea unui set de direcții A-ortogonale $\mathbf{d}^{(k)}$ se realizează ușor cu ajutorul procedurii Gram-Schmidt conjugate.

- Se pornește de la o mulțime de n vectori liniar independenti $\mathbf{u}^{(0)}, \mathbf{u}^{(1)}, \dots, \mathbf{u}^{(n-1)}$

$$\mathbf{d}^{(0)} = \mathbf{u}^{(0)}. \quad (100)$$

- A doua direcție pornește de la al doilea vector la care se adaugă un vector orientat pe direcția anteroiară, scalat a.î. rezultatul să fie A-ortogonal pe direcția anteroiară.

Metoda direcțiilor conjugate

$$\mathbf{d}^{(1)} = \mathbf{u}^{(1)} + \beta_{10} \mathbf{d}^{(0)}, \quad (101)$$

unde β_{10} se alege astfel încât

$$(\mathbf{d}^{(1)})^T \mathbf{A} \mathbf{d}^{(0)} \equiv 0. \quad (102)$$

Această relație este echivalentă cu

$$(\mathbf{u}^{(1)} + \beta_{10}\mathbf{q}^{(0)})^T \mathbf{A}\mathbf{q}^{(0)} \equiv 0. \quad (103)$$

de unde

$$\beta_{10} = -\frac{(\mathbf{u}^{(1)})^T \mathbf{A} \mathbf{d}^{(0)}}{(\mathbf{d}^{(0)})^T \mathbf{A} \mathbf{d}^{(0)}}. \quad (104)$$

Notes

Metoda direcțiilor conjugate

- Similar, următoarea direcție este

$$\mathbf{d}^{(2)} = \mathbf{u}^{(2)} + \beta_{20}\mathbf{d}^{(0)} + \beta_{21}\mathbf{d}^{(1)}, \quad (105)$$

unde β_{20} și β_{21} se aleg astfel încât

$$(\mathbf{d}^{(2)})^T \mathbf{A} \mathbf{d}^{(0)} = 0 \quad \text{și} \quad (\mathbf{d}^{(2)})^T \mathbf{A} \mathbf{d}^{(1)} = 0, \quad (106)$$

de unde rezultă

$$\beta_{20} = -\frac{(\mathbf{u}^{(2)})^T \mathbf{A} \mathbf{d}^{(0)}}{(\mathbf{d}^{(0)})^T \mathbf{A} \mathbf{d}^{(0)}}, \quad \beta_{21} = -\frac{(\mathbf{u}^{(2)})^T \mathbf{A} \mathbf{d}^{(1)}}{(\mathbf{d}^{(1)})^T \mathbf{A} \mathbf{d}^{(1)}}. \quad (107)$$

Metoda direcțiilor conjugate

- În general

$$\mathbf{d}^{(k)} = \mathbf{u}^{(k)} + \sum_{j=0}^{k-1} \beta_{kj} \mathbf{d}^{(j)}, \quad (108)$$

unde β_{kj} , definiți pentru $k > j$, sunt deduși din condițiile de A-ortogonalitate impuse direcțiilor, rezultând

$$\beta_{kj} = -\frac{(\mathbf{u}^{(k)})^T \mathbf{A} \mathbf{d}^{(j)}}{(\mathbf{d}^{(j)})^T \mathbf{A} \mathbf{d}^{(j)}}. \quad (109)$$

Dificultate: toate direcțiile de căutare trebuie memorate pentru a construi o direcție de căutare nouă.

Notes

Metoda gradientilor conjugăți

Metoda gradientilor conjugăți este metoda direcțiilor conjugate în care direcțiile de căutare sunt construite prin conjugarea reziduurilor:

$$\mathbf{u}^{(k)} = \mathbf{r}^{(k)}. \quad (110)$$

Notes

Metoda gradientilor conjugăți

Justificarea acestei alegeri:

- 1 Intuitiv, inspirat de metoda celei mai rapide coborâri, în care direcțiile de căutare erau direcțiile reziduurilor.
- 2 Proprietatea reziduuului de a fi ortogonal pe direcțiile de căutare anterioare și pe reziduurile anterioare.

$$(\mathbf{d}^k)^T \mathbf{r}^{(i)} = 0, \quad k < i, \quad (111)$$

$$(\mathbf{r}^k)^T \mathbf{r}^{(i)} = 0, \quad k < i. \quad (112)$$

Notes

Metoda gradientilor conjugăți

De asemenea, reziduul \mathbf{r}^k este o combinație liniară dintre reziduul anterior și produsul $\mathbf{A}\mathbf{d}^{(k-1)}$:

$$\mathbf{r}^{(k)} = -\mathbf{A}\mathbf{e}^{(k)} = -\mathbf{A}(\mathbf{e}^{(k)} + \alpha_k \mathbf{d}^{(k)}) = \mathbf{r}^{(k-1)} - \alpha_{k-1} \mathbf{A}\mathbf{d}^{(k-1)}. \quad (113)$$

Notes

Metoda gradientilor conjugăți

Coeficienții β

$$\beta_{kj} = -\frac{(\mathbf{r}^{(k)})^T \mathbf{A}\mathbf{d}^{(j)}}{(\mathbf{d}^{(j)})^T \mathbf{A}\mathbf{d}^{(j)}}. \quad (114)$$

Pentru a explicita termenul de la numărător, vom înmulți relația (113) la stânga cu $(\mathbf{r}^{(i)})^T$:

$$(\mathbf{r}^{(i)})^T \mathbf{r}^{(k+1)} = (\mathbf{r}^{(i)})^T \mathbf{r}^{(k)} - \alpha_k (\mathbf{r}^{(i)})^T \mathbf{A}\mathbf{d}^{(k)}, \quad (115)$$

de unde

$$\alpha_k (\mathbf{r}^{(i)})^T \mathbf{A}\mathbf{d}^{(k)} = (\mathbf{r}^{(i)})^T \mathbf{r}^{(k)} - (\mathbf{r}^{(i)})^T \mathbf{r}^{(k+1)}. \quad (116)$$

Notes

Metoda gradientilor conjugăți

Pentru $i \neq k$, membrul drept al acestei relații este nenul doar pentru cazul $i = k + 1$, când valoarea lui este $-(\mathbf{r}^{(i)})^T \mathbf{r}^{(i)} / \alpha_{i-1}$.
Rezultă că valorile β sunt nenele doar dacă $i = k + 1$:

$$\beta_{kj} = \begin{cases} \frac{(\mathbf{r}^{(k)})^T \mathbf{r}^{(k)}}{\alpha_{k-1} (\mathbf{d}^{(k-1)})^T \mathbf{A} \mathbf{d}^{(k-1)}} & k = i - 1, \\ 0 & k < i - 1 \end{cases} \quad (117)$$

Notes

Metoda gradientilor conjugăți

Nu mai este necesar ca valorile β să fie notate cu doi indici.
Vom renota

$$\begin{aligned} \beta_k &= \beta_{k,k-1} = \\ &= \frac{(\mathbf{r}^{(k)})^T \mathbf{r}^{(k)}}{\alpha_{k-1} (\mathbf{d}^{(k-1)})^T \mathbf{A} \mathbf{d}^{(k-1)}} = \\ &= \frac{(\mathbf{r}^{(k)})^T \mathbf{r}^{(k)}}{(\mathbf{d}^{(k-1)})^T \mathbf{r}^{(k-1)}} = \\ &= \frac{(\mathbf{r}^{(k)})^T \mathbf{r}^{(k)}}{(\mathbf{r}^{(k-1)})^T \mathbf{r}^{(k-1)}}. \end{aligned} \quad (118)$$

Notes


Metoda gradientelor conjugăți

În concluzie, metoda gradientelor conjugăți se bazează pe următoarele șase relații:

$$\begin{aligned}\mathbf{d}^{(0)} &= \mathbf{r}^{(0)} = \mathbf{b} - \mathbf{Ax}^{(0)} \\ \alpha_k &= \frac{(\mathbf{r}^{(k)})^T \mathbf{r}^{(k)}}{(\mathbf{d}^{(k)})^T \mathbf{Ad}^{(k)}} \\ \mathbf{x}^{(k+1)} &= \mathbf{x}^{(k)} + \alpha_k \mathbf{d}^{(k)} \\ \mathbf{r}^{(k+1)} &= \mathbf{r}^{(k)} - \alpha_k \mathbf{Ad}^{(k)} \\ \beta_{k+1} &= \frac{(\mathbf{r}^{(k+1)})^T \mathbf{r}^{(k+1)}}{(\mathbf{r}^{(k)})^T \mathbf{r}^{(k)}} \\ \mathbf{d}^{(k+1)} &= \mathbf{r}^{(k+1)} + \beta_{k+1} \mathbf{d}^{(k)}\end{aligned}$$

Metoda gradientelor conjugăți

Algoritmul este complet după n iterații.



Convergența metodei gradientului depinde de inițializare și de numărul de condiționare spectrală (stânga). Metoda gradientelor conjugăți converge în exact n pași, indiferent de inițializare și de numărul de condiționare spectrală (dreapta).

Notes

Metoda gradientilor conjugăți

```
procedură metoda_gradientilor_conjugati(n, A, b, x0, er, maxit, x)
...
xv = x0 ; inițializează sirul iterărilor
k = 0 ; inițializare contor iterării
r = b - A · xv ; calculează reziduu
cât timp ||r|| > er și k ≤ maxit
    dacă k = 0
        d = r
    altfel
        β = rTr / (rT · rv)
        d = r + βdv
    •
        α = rTr / (dTAd)
        x = xv + αd
        rv = r
        r = rv - αAd
        xv = x
        dv = d
        k = k + 1
    •
return
```

Algoritmul se poate îmbunătăți, calculând la o iterare o singură dată produsul matrice - vector Ad și produsul scalar

$r^T r$.

Metoda gradientilor conjugăți

- Algoritmul este complet după n iterări. Din acest motiv, se mai spune că **metoda este semi-iterativă**, sirul iterărilor nu tinde către soluția exactă atunci când numărul iterărilor tinde la infinit, ci, într-o aritmetică exactă, soluția exactă se obține după exact n iterări.
- În practică însă metoda este folosită pentru probleme atât de mari încât nu ar fi fezabil să se execute toate cele n iterări. De aceea, iterările în algoritm sunt executate într-un ciclu cu test și nu într-un ciclu cu contor.

Notes

Preconditionare

Precondiționare = transformarea problemei inițiale într-o echivalentă care are proprietăți îmbunătățite considerabil.

Preconditionare la stânga

$$\mathbf{A}\mathbf{x} = \mathbf{b} \quad (119)$$

$$\mathbf{M}^{-1}\mathbf{A}\mathbf{x} = \mathbf{M}^{-1}\mathbf{b}, \quad (120)$$

Matrice nesingulară, numită *matrice de preconditionare* sau *preconditionator*.

- Convergența depinde de proprietățile matricei $\mathbf{M}^{-1}\mathbf{A}$.
 - $\mathbf{M}^{-1}\mathbf{A}$ nu se calculează explicit, ci se rezolvă $\mathbf{My} = \mathbf{A}$
 - Cazurile extreme: $\mathbf{M} = \mathbf{I}$ și $\mathbf{M} = \mathbf{A}$ - nu există nici un câștig.
 - O condiție puternică pentru un bun precondiționator este ca valorile proprii ale matricei $\mathbf{M}^{-1}\mathbf{A}$ să fie apropiate de 1 și ca norma $\|\mathbf{M}^{-1}\mathbf{A} - \mathbf{I}\|_2$ să fie mică [Trefethen97].

Precondizionare

Preconditionare la dreapta

$$\mathbf{A}\mathbf{M}^{-1}\mathbf{y} = \mathbf{b}, \quad (121)$$

unde $\mathbf{x} = \mathbf{M}^{-1}\mathbf{y}$.

Se pot folosi ambele tipuri de preconditionare simultan.

Preconditionare matricelor simetrice și pozitiv definite

Preconditionarea se face astfel încât să se păstreze această proprietate.

Fie $\mathbf{M} = \mathbf{C}\mathbf{C}^T$ - simetrică și pozitiv definită.

$$\left[\mathbf{C}^{-1} \mathbf{A} \mathbf{C}^{-T} \right] \mathbf{C}^T \mathbf{x} = \mathbf{C}^{-1} \mathbf{b}, \quad (122)$$

unde $\mathbf{C}^{-T} = (\mathbf{C}^{-1})^T = (\mathbf{C}^T)^{-1}$, iar matricea din paranteza dreaptă este simetrică și pozitiv definită.

Precondizionare

Metode de preconditionare celebre

- ① *Precondiționarea Jacobi (sau scalarea diagonală):*
 $M = \text{diag}(A)$, nesingulară. Generalizare: $M = \text{diag}(c)$, unde c ales convenabil.
 - ② *Factorizarea incompletă Cholesky sau LU* în care se aplică procedura de factorizare, dar factorii nu sunt calculați complet, valorile care ar umple matricea nu sunt luate în considerare. Matricea de preconditionare se obține ca produsul acestor factori incompleți.

Precondi>onare

- Aceste două exemple de preconditionatori nu fac nicio referire la problema inițială care a generat sistemul (119).
 - Cel mai bun sfat general: de a încerca să se construiască preconditionatorul pe baza unei versiuni mai simple a problemei. Pe această idee se bazează *metodele multigrid* care se bazează și pe preconditionatori obținuți din Jacobi și SSOR.

Notes

Notes

Referințe

- [Ciuprina13a] Gabriela Ciuprina - Algoritmi numerici pentru calcule științifice în ingineria electrică , Editura MatrixROM, 2013, pag. 88-120.
disponibilă la http://www.lmn.pub.ro/~gabriela/books/AlgNr_MatrixRom2013.pdf
 - [Saad03] Yousef Saad, *Iterative Methods for Sparse Linear Systems*, SIAM, 2003.
 - [Barrett94] Richard Barrett, Michael Berry, Tony F. Chan, James Demmel, June M. Donato, Jack Dongarra, Victor Eijkhout, Roldan Pozo, Charles Romine, and Henk Van der Vorst, *Templates for the Solution of Linear Systems: Building Blocks for Iterative Methods*, SIAM 1994.
disponibilă la <http://www.netlib.org/templates/templates.pdf>
 - [Shewchuk94] J.R. Shewchuk, *An Introduction to the Conjugate Gradient Method Without the Agonizing Pain*
disponibilă online [aici](#)
 - [Trefethen97] Lloyd N. Trefethen, David Bau III *Numerical Linear Algebra*, SIAM 1997.

Bibliotecas existentes

Biblioteci existente:

- [Dongarra2016] Freely Available Software for Linear Algebra (September 2016),
<http://www.netlib.org/utk/people/JackDongarra/la-sw.html>
 - [Eijkhout97] Overview of Iterative Linear System Solver Packages <http://www.netlib.org/utk/papers/iterative-survey/>

BDDCML, BILUM, BlockSolve95, CERFACS, DUNE/ISTL, GMM++, HIPSPACK, HYPRE, IML++, ITL, ITPACK, ITSOL, Lis, PARALUTION, pARMS, PETSc, PIM, QMRPACK, SLAP, SOL, SPARSKIT, SPLIB, Templates, Trilinos

Notes

Notes

Formularea problemei
Metode staționare
Metoda gradientilor conjugati
Precondiționare

Precondiționare
Referințe
Biblioteci existente

Referințe

www.netlib.org/utk/people/JackDongarra/la-sw.html

SPARSE ITERATIVE SOLVERS	License	Support	Type	Language			Mode		Dense	Sparse Direct	Sparse Iterative	Sparse Eigenvalue	Last release date
				Fortran	C	C++	Shared	Accel.					
BDDCML	LGPL	yes	X	X	X	X		M			X X		2014-03-12
BILUM	Own	?	X	X	X	X					X X		1998-03-18
BlockSolve94	Own	?	X	X	X	X		M			X X		1997-07-08
CERFACS	?	yes	X X	X							X X		2007-07-01
DUNE / INSL	GPL	yes	X X		X X			M			X X		2014-12-18
GMM++	LGPL	yes	X X		X X					X	X X		2014-08-21
HIPS	C/C++-C	yes	X X	X X	X X	X X		M			X X		2010-10-13
HYPRE	LGPL	yes	X	X X	X X	X		M			P P P		2015-01-22
IML++	PD	?	X				X X				X X		1998-01-05
ITL	Own	yes	X				X X				X X		2001-10-26
ITPACK	PD	?	X	X	X	X					X X		1989-05-01
ITSOL	GPL	yes	X		X						X		2012-10-25
Lis	BSD	yes	X X	X X	X X	X		M			P P P P		2015-05-14
PARALUTION	GPL	yes	X				X X	C O			X X		2015-02-27
pARMS	LGPL	yes	X	X X	X X	X		M			X X		2011-01-14
PETSc	Own	yes	X X	X X	X X	X	C O	M			P P		2015-01-31
PIM	Own	yes	X X	X X	X X	X		M			X X		2003-06-20
QMRPACK (tar.gz)	Own	?	X X	X X	X X	X					X X X X		1996-04-15
SLAP	PD	?	X	X	X						X X		1998-07-21
SOL	CPL or BSD	yes	X	X X	X X	X					X X		2015-05-14
SPARSKIT	LGPL	yes	X	X	X	X					X		2009-11-18
SPLIT (tar.gz)	Own	?	X	X	X	X					X X		1999-04-01
Templates	BSD	yes	X	X X	X X	X					X X		1998-07-21
Trilinos AztecOO	BSD	yes	X	X X	X X	X		M			X X		2015-08-07
Trilinos Belos	BSD	yes	X X	X X	X X	X X		M			X X		2015-05-07

87/92


Gabriela Ciuprina Sisteme de ecuații algebrice liniare - metode iterative

Formularea problemei
Metode staționare
Metoda gradientilor conjugati
Precondiționare

Precondiționare
Referințe
Biblioteci existente

Pe scurt

Fiți atenți la astfel de informații (capturi din LTSPICE).
Consultați documentația pentru detalii!



88/92

Gabriela Ciuprina Sisteme de ecuații algebrice liniare - metode iterative

Notes


Notes

Formularea problemei
Metode staționare
Metoda gradientilor conjugati
Precondiționare

Precondiționare
Referințe
Biblioteci existente

Pe scurt

Fii atenți la astfel de informații (capturi din LTSPICE).
Consultați documentația pentru detaliu!




Formularea problemei
Metode staționare
Metoda gradientilor conjugati
Precondiționare

Precondiționare
Referințe
Biblioteci existente

Pe scurt

Fii atenți la astfel de informații (capturi din COMSOL)




Gabriela Ciuprina Sisteme de ecuații algebrice liniare - metode iterative

Notes

Notes


Pe scurt

Fii atenți la astfel de informații (capturi din COMSOL)



Notes

Pe scurt



Notes
