

1. Sisteme de ecuații liniare

Reamintim că un sistem de n ecuații algebrice liniare cu n necunoscute este de forma:

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

Dacă notăm cu A matricea coeficienților, cu x vectorul coloană format cu necunoscutele sistemului și cu b coloana termenilor liberi, sistemul (1) se scrie sub formă matriceală :

$$Ax=b, \quad (2)$$

unde:

$$A = \begin{pmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \vdots & \vdots & & \vdots \\ a_{n1} & a_{n2} & \dots & a_{nn} \end{pmatrix}, \quad x = \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix}, \quad b = \begin{pmatrix} b_1 \\ b_2 \\ \vdots \\ b_n \end{pmatrix}$$

Metodele numerice de rezolvare a sistemelor algebrice de ecuații liniare sunt de două tipuri: *metode directe* și *metode indirecte* (sau *iterative*).

Metodele directe constau în transformarea sistemului (1) într-un sistem triunghiular echivalent, care se rezolvă ușor. Cele mai cunoscute metode directe sunt: *metoda Gauss*, *metoda Cholesky* (utilizată pentru sistemele în care matricea A este simetrică și pozitiv definită) și *metoda Householder*.

Metodele directe permit determinarea soluției exacte a sistemului în cazul ideal, când nu avem erori de rotunjire. Numărul operațiilor aritmetice efectuate este de ordinul n^3 . Pentru sisteme cu un număr de ecuații mai mare de 100, metodele directe devin inutilizabile datorită acumulării erorilor de rotunjire care alterează soluția.

Metodele indirecte (sau *iterative*) constau în construcția unui șir $\{x^{(k)}\}$ de vectori n -dimensionali, care converge la soluția exactă a sistemului. Se alege ca

soluție aproximativă a sistemului un termen $x^{(s)}$ al șirului, al cărui ordin depinde de precizia impusă.

O iterație presupune efectuarea unui număr de operații aritmetice de ordinul n^2 . Metodele iterative sunt utilizate la rezolvarea sistemelor mari de ecuații. Cele mai cunoscute metode iterative sunt: *Jacobi*, *Gauss–Seidel*, *metodele de relaxare*.

§1.1. Metoda Gauss. Factorizarea LU

Fie

$$m_r = \begin{pmatrix} 0 \\ \vdots \\ 0 \\ m_{r+1,r} \\ \vdots \\ m_{n,r} \end{pmatrix} \quad \text{și} \quad e_r = \begin{pmatrix} 0 \\ \vdots \\ 1 \\ 0 \\ \vdots \\ 0 \end{pmatrix}$$

(elementul 1 din e_r se află pe linia r).

O matrice de forma $M_r = I_n - m_r \cdot e_r^T$, unde $e_r^T = (0, \dots, 1, \dots, 0)$, se numește *matrice Frobenius*. O astfel de matrice are următoarea structură:

$$M_r = \begin{pmatrix} 1 & & 0 & 0 & \dots & 0 \\ & \ddots & & & & \\ 0 & & 1 & 0 & \dots & \\ 0 & \dots & -m_{r+1,r} & 1 & \dots & 0 \\ & & \vdots & & & \\ 0 & \dots & -m_{nr} & 0 & \dots & 1 \end{pmatrix}$$

De exemplu, dacă $n=4$ și $r=2$, avem:

$$\begin{aligned} M_2 &= \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix} - \begin{pmatrix} 0 \\ 0 \\ m_{32} \\ m_{42} \end{pmatrix} \begin{pmatrix} 0 & 1 & 0 & 0 \end{pmatrix} = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix} - \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & m_{32} & 0 & 0 \\ 0 & m_{42} & 0 & 0 \end{pmatrix} = \\ &= \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & -m_{32} & 1 & 0 \\ 0 & -m_{42} & 0 & 1 \end{pmatrix} \end{aligned}$$

Propoziția 1. Orice matrice Frobenius M_r este inversabilă și inversa sa este:

$$M_r^{-1} = I_n + m_r \cdot e_r^T.$$

Demonstrație.

$$(I_n - m_r \cdot e_r^T)(I_n + m_r \cdot e_r^T) = I_n - m_r \cdot e_r^T + m_r \cdot e_r^T - m_r(e_r^T m_r) e_r^T.$$

Deoarece $e_r^T \cdot m_r = 0$, rezultă:

$$M_r(I_n + m_r \cdot e_r^T) = I_n, \text{ și deci } M_r^{-1} = I_n + m_r \cdot e_r^T. \quad \square$$

Teorema 1. Fie A o matrice pătrată de ordinul n care satisface condiția:

$$(*) \quad \det \begin{pmatrix} a_{11} & \dots & a_{1r} \\ \vdots & & \vdots \\ a_{r1} & \dots & a_{rr} \end{pmatrix} \neq 0 \text{ pentru orice } r = \overline{1, n-1}.$$

Atunci există o matrice inferior triunghiulară $M \in M_n(\mathbb{R})$ astfel încât matricea $U = MA$ este superior triunghiulară.

Demonstrație. Deoarece $a_{11} \neq 0$, putem considera matricea Frobenius

$$M_1 = \begin{pmatrix} 1 & 0 & \dots & 0 \\ -\frac{a_{21}}{a_{11}} & 1 & 0 & \dots & 0 \\ a_{11} & & & & \\ \vdots & & & & \vdots \\ -\frac{a_{n1}}{a_{11}} & 0 & \dots & & 1 \\ a_{11} & & & & \end{pmatrix}.$$

Dacă notăm $A_1 = A$ și $A_2 = M_1 A_1$, atunci avem

$$A_2 = \begin{pmatrix} a_{11}^{(2)} & a_{12}^{(2)} & \dots & a_{1n}^{(2)} \\ 0 & a_{22}^{(2)} & \dots & a_{2n}^{(2)} \\ \vdots & \vdots & & \vdots \\ 0 & a_{n2}^{(2)} & \dots & a_{nn}^{(2)} \end{pmatrix},$$

unde, notând cu $a_{ij}^{(1)} = a_{ij}$, pentru $i, j = \overline{1, n}$, avem: $a_{1j}^{(2)} = a_{1j}^{(1)}$ pentru

$$j = \overline{1, n}; \quad a_{ij}^{(2)} = a_{ij}^{(1)} - \frac{a_{i1}^{(1)} a_{1j}^{(1)}}{a_{11}^{(1)}}, \text{ pentru orice } i, j = \overline{2, n}.$$

Observăm că

$$a_{22}^{(2)} = a_{22} - \frac{a_{21} a_{12}}{a_{11}} = \frac{1}{a_{11}} \begin{vmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{vmatrix} \neq 0.$$

Dacă notăm

$$M_2 = \begin{pmatrix} 1 & 0 & 0 & \dots & 0 \\ 0 & 1 & 0 & \dots & 0 \\ 0 & -\frac{a_{32}^{(2)}}{a_{22}^{(2)}} & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & -\frac{a_{n2}^{(2)}}{a_{22}^{(2)}} & 0 & \dots & 1 \end{pmatrix},$$

atunci

$$A_3 = M_2 A_2 = \begin{pmatrix} a_{11}^{(3)} & a_{12}^{(3)} & a_{13}^{(3)} & \dots & a_{1n}^{(3)} \\ 0 & a_{22}^{(3)} & a_{23}^{(3)} & \dots & a_{2n}^{(3)} \\ 0 & 0 & a_{33}^{(3)} & \dots & a_{3n}^{(3)} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & a_{nn}^{(3)} \end{pmatrix},$$

unde $a_{ij}^{(3)} = a_{ij}^{(2)}$ pentru $i=1, 2, j=\overline{1, n}$ și $a_{ij}^{(3)} = a_{ij}^{(2)} - \frac{a_{i2}^{(2)} a_{2j}^{(2)}}{a_{22}^{(2)}}$, $i, j = \overline{3, n}$.

Un calcul simplu ne arată că

$$a_{33}^{(3)} = \frac{1}{a_{11}^{(1)} a_{22}^{(2)}} \begin{vmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{vmatrix} \neq 0.$$

În general, $a_{rr}^{(r)} \neq 0$ și se poate considera matricea Frobenius:

$$M_r = \begin{pmatrix} 1 & & 0 & 0 & \dots & 0 \\ & \ddots & & & & \\ 0 & & 1 & 0 & \dots & \\ 0 & \dots & -\frac{a_{r+1,r}^{(r)}}{a_{rr}^{(r)}} & 1 & \dots & 0 \\ & & \vdots & & \ddots & \\ 0 & \dots & -\frac{a_{nr}^{(r)}}{a_{rr}^{(r)}} & 0 & \dots & 1 \end{pmatrix}.$$

Dacă notăm cu $A_{r+1} = M_r A_r$, atunci

$$A_{r+1} = \begin{pmatrix} a_{11}^{(r+1)} & a_{12}^{(r+1)} & \dots & a_{1r}^{(r+1)} & \dots & a_{1n}^{(r+1)} \\ 0 & a_{22}^{(r+1)} & \dots & a_{2r}^{(r+1)} & \dots & a_{2n}^{(r+1)} \\ \vdots & \vdots & & \vdots & & \vdots \\ 0 & 0 & \dots & a_{rr}^{(r+1)} & \dots & a_{rn}^{(r+1)} \\ 0 & 0 & \dots & 0 & a_{r+1,r+1}^{(r+1)} & \dots & a_{r+1,n}^{(r+1)} \\ \vdots & \vdots & & \vdots & \vdots & & \vdots \\ 0 & 0 & \dots & 0 & a_{n,r+1}^{(r+1)} & \dots & a_{nn}^{(r+1)} \end{pmatrix},$$

unde $a_{ij}^{(r+1)} = a_{ij}^{(r)}$, pentru $i = \overline{1, r}$, $j = \overline{1, n}$, $a_{ij}^{(r+1)} = a_{ij}^{(r)} - \frac{a_{ir}^{(r)} a_{rj}^{(r)}}{a_{rr}^{(r)}}$,

$i, j = \overline{r+1, n}$.

În final se obține matricea superior triunghiulară

$$U = A_n = M_{n-1} \dots M_2 M_1 A = \begin{pmatrix} a_{11}^{(n)} & a_{12}^{(n)} & \dots & a_{1n}^{(n)} \\ 0 & a_{22}^{(n)} & \dots & a_{2n}^{(n)} \\ \vdots & \vdots & & \vdots \\ 0 & 0 & \dots & a_{nn}^{(n)} \end{pmatrix}.$$

Notăm cu $M = M_{n-1} M_{n-2} \dots M_2 M_1$ și demonstrația teoremei este completă. \square

Exemplu.

$$A_1 = A = \begin{pmatrix} 5 & 2 & 1 \\ 5 & -6 & 2 \\ -4 & 2 & 1 \end{pmatrix}, \quad M_1 = \begin{pmatrix} 1 & 0 & 0 \\ -1 & 1 & 0 \\ \frac{4}{5} & 0 & 1 \end{pmatrix}, \quad A_2 = \begin{pmatrix} 5 & 2 & 1 \\ 0 & -8 & 1 \\ 0 & \frac{18}{5} & \frac{9}{5} \end{pmatrix},$$

$$M_2 = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & \frac{9}{20} & 1 \end{pmatrix}, \quad U = A_3 = \begin{pmatrix} 5 & 2 & 1 \\ 0 & -8 & 1 \\ 0 & 0 & \frac{9}{4} \end{pmatrix}, \quad M = M_2 M_1 = \begin{pmatrix} 1 & 0 & 0 \\ -1 & 1 & 0 \\ \frac{7}{20} & \frac{9}{20} & 1 \end{pmatrix}.$$

Considerăm sistemul

$$\begin{cases} 5x_1 + 2x_2 + x_3 = 12 \\ 5x_1 - 6x_2 + 2x_3 = -1 \\ -4x_1 + 2x_2 + x_3 = 3 \end{cases},$$

a cărui soluție este $x_1=1, x_2=2, x_3=3$. Sub formă matriceală sistemul se scrie:

$Ax=b$, unde $b = \begin{pmatrix} 12 \\ -1 \\ 3 \end{pmatrix}$. Acest sistem este echivalent cu următorul sistem:

$(M_2M_1A)x=(M_2M_1)b$. Efectuând calculele obținem

$$\begin{cases} 5x_1 + 2x_2 + x_3 = 12 \\ -8x_2 + x_3 = -13 \\ \frac{9}{4}x_3 = \frac{27}{4} \end{cases} .$$

Numărul operațiilor pentru determinarea matricei U și a vectorului Mb

Pentru o linie fixată i se calculează $-\frac{a_{ir}^{(r)}}{a_{rr}^{(r)}}$, apoi se fac înmulțirile cu

$a_{rj}^{(r)}, r+1 \leq j \leq n$, și se adună $a_{ij}^{(r)}, r+1 \leq j \leq n$. La fel și cu $b_i^{(r+1)}$. Sunt

$2(n-r)+3$ operații elementare pentru fiecare linie $i, r+1 \leq i \leq n$, și pentru fiecare etapă r vor fi $(n-r)[2(n-r)+3]$ operații. În total vor fi

$\sum_{r=1}^n [2(n-r)^2 + 3(n-r)] = \frac{2}{3}n^3 + \frac{1}{2}n^2 - \frac{7}{6}n$ operații elementare. Dacă adăugăm și

cele n^2 operații pentru rezolvarea sistemului triunghiular, rezultă că numărul de

operații pentru rezolvarea sistemului $Ax=b$ este $\frac{2}{3}n^3 + \frac{3}{2}n^2 - \frac{7}{6}n$.

În continuare notăm cu $L_r = M_r^{-1}$. Din Propoziția 1 rezultă că L_r este de forma:

$$L_r = \begin{pmatrix} 1 & \dots & 0 & \dots & 0 \\ \vdots & \ddots & \vdots & & \vdots \\ 0 & & 1 & \dots & 0 \\ 0 & & \frac{a_{r+1,r}^{(r)}}{a_{rr}^{(r)}} & \dots & 0 \\ \vdots & & \vdots & & \vdots \\ 0 & \dots & \frac{a_{nr}^{(r)}}{a_{rr}^{(r)}} & 0 & \dots & 1 \end{pmatrix} .$$

Dacă notăm cu $L=L_1L_2\dots L_{n-1}$, atunci L este o matrice inferior triunghiulară de tipul următor

$$L = \begin{pmatrix} 1 & 0 & 0 & \dots & 0 \\ \ell_{21} & 1 & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & & \vdots \\ \ell_{n1} & \ell_{n2} & \ell_{n3} & \dots & 1 \end{pmatrix}.$$

Deoarece $A = M_1^{-1}M_2^{-1}\dots M_{n-1}^{-1}U$, rezultă că:

$$A = LU \quad (3)$$

Așadar, orice matrice pătratică ce îndeplinește condiția (*) din Teorema 1 admite o descompunere unică de forma (3), unde L este inferior triunghiulară având elementele de pe diagonala principală egale cu 1 și U este superior triunghiulară. Descompunerea (3) este cunoscută sub numele de *factorizarea LU*.

Algoritmul pentru factorizarea LU

{ Determinarea matricelor U și L cu păstrarea matricei A }

Pentru $i:=1, n$ execută

 Pentru $j:=1, n$ execută

$u_{ij} := a_{ij}$;

 dacă $i=j$ atunci $l_{ii}:=1$ altfel $l_{ij}:=0$;

 sfârșit pentru j ;

sfârșit pentru i ;

Pentru $r:=1, n-1$ execută

 Pentru $i:=r+1, n$ execută

 Pentru $j:=r+1, n$ execută

$$u_{ij} := u_{ij} - \frac{u_{ir}u_{rj}}{u_{rr}};$$

 sfârșit pentru j ;

$$l_{ir} := \frac{u_{ir}}{u_{rr}};$$

 sfârșit pentru i ;

sfârșit pentru r ;

Pentru $i:=2, n$ execută

 Pentru $j:=1, i-1$ execută

$u_{ij}:=0$;

 sfârșit pentru j ;

sfârșit pentru i .

Algoritmul se află programat în MATLAB și poate fi apelat cu secvența:

$[L, U] = lu(A)$ { se afișează cele două matrice }

În exemplul precedent avem:

$$L_1 = \begin{pmatrix} 1 & 0 & 0 \\ 1 & 1 & 0 \\ -\frac{4}{5} & 0 & 1 \end{pmatrix}, \quad L_2 = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & -\frac{9}{20} & 1 \end{pmatrix},$$

$$A=LU = \begin{pmatrix} 1 & 0 & 0 \\ 1 & 1 & 0 \\ -\frac{4}{5} & -\frac{9}{20} & 1 \end{pmatrix} \begin{pmatrix} 5 & 2 & 1 \\ 0 & -8 & 1 \\ 0 & 0 & \frac{9}{4} \end{pmatrix} = \begin{pmatrix} 5 & 2 & 1 \\ 5 & -6 & 2 \\ -4 & 2 & 1 \end{pmatrix}$$

Observația 1. Dacă pivotul este “foarte mic”, adică $|a_{rr}^{(r)}| \ll 1$, atunci împărțirile la acest pivot produc erori de rotunjire foarte mari, care alterează soluția. În acest caz se recomandă schimbarea pivotului. Se poate alege un nou pivot

$$\pi_r = |a_{ir}^{(r)}| = \max \left\{ |a_{ij}^{(r)}| ; r \leq j \leq n \right\}$$

$$\text{sau } \pi_r = |a_{jr}^{(r)}| = \max \left\{ |a_{k\ell}^{(r)}| ; r \leq k, \ell \leq n \right\}$$

Aceasta presupune schimbarea între ele a două linii și eventual și a două coloane.

Algoritmul Gauss pentru rezolvarea sistemelor de ecuații liniare

Pentru $r:=1, n-1$ execută

Pentru $i:=r+1, n$ execută

Pentru $j:=r+1, n$ execută

găsește pivotul conform cu (B);

schimbă linia i cu linia pivotului și coloana j cu coloana pivotului dacă este cazul;

sfârșit pentru j

sfârșit pentru i

Pentru $i:=r+1, n$ execută

$$b_i = b_i - \frac{a_{ir} b_r}{a_{rr}}$$

Pentru $j:=r+1, n$ execută

$$a_{ij} = a_{ij} - \frac{a_{ir} a_{rj}}{a_{rr}} ;$$

sfârșit pentru j ;

sfârșit pentru i ;

sfârșit pentru r ;

$$x_n := \frac{b_n}{a_{nn}} ;$$

Pentru $i:=n-1,1,-1$ execută
 $s:=0$;
 Pentru $j:=i+1,n$ execută
 $s:=s+a_{ij}x_j$;
 sfârșit pentru j ;
 $x_i := \frac{(b_i - s)}{a_{ii}}$;
 sfârșit pentru i .

§1.2. Matrice simetrice pozitiv definite

Reamintim că o matrice simetrică se numește pozitiv definită, dacă forma pătratică asociată este pozitiv definită. Mai precis, dacă A este o matrice simetrică, atunci A se numește *pozitiv definită* dacă

$$\varphi(x)=x^T Ax > 0 ,$$

pentru orice $x \neq 0$, unde $x = (x_1, x_2, \dots, x_n)^T$.

Din Algebra Liniară, se știe că o matrice simetrică A , este pozitiv definită dacă și numai dacă $\Delta_r > 0$ pentru orice $r = \overline{1, n}$, unde

$$\Delta_r = \det \begin{pmatrix} a_{11} & \dots & a_{1r} \\ \vdots & & \vdots \\ a_{r1} & \dots & a_{rr} \end{pmatrix} .$$

În practică aceste condiții sunt greu de verificat pentru matrice de dimensiuni mari. De aceea, în continuare vom prezenta unele condiții necesare, respectiv și suficiente, pentru ca o matrice simetrică să fie pozitiv definită.

Propoziția 1. Dacă A este o matrice simetrică pozitiv definită, atunci:

- (a) $a_{ii} > 0$ pentru orice $i = \overline{1, n}$,
- (b) $a_{ii}a_{jj} > a_{ij}^2$ pentru orice $i, j = \overline{1, n}$.

Demonstrație.

$$\begin{aligned} \varphi(x) = x^T Ax &= (x_1, \dots, x_n) \cdot \begin{pmatrix} a_{11}x_1 + \dots + a_{1n}x_n \\ \vdots \\ a_{n1}x_1 + \dots + a_{nn}x_n \end{pmatrix} = (a_{11}x_1 + a_{12}x_2 + \dots + a_{1n}x_n)x_1 + \\ &+ (a_{21}x_1 + a_{22}x_2 + \dots + a_{2n}x_n)x_2 + \dots + (a_{n1}x_1 + a_{n2}x_2 + \dots + a_{nn}x_n)x_n \end{aligned}$$

Ținând seama că $a_{ij} = a_{ji}$, în continuare avem

$$\begin{aligned} \varphi(x) = \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j = & a_{11} x_1^2 + 2a_{12} x_1 x_2 + \dots + 2a_{1n} x_1 x_n + \\ & + a_{22} x_2^2 + \dots + 2a_{2n} x_2 x_n + \\ & \vdots \\ & + a_{nn} x_n^2 \end{aligned}$$

În particular, pentru $x = e_i = \begin{pmatrix} 0 \\ \vdots \\ 1 \\ \vdots \\ 0 \end{pmatrix}$ avem $\varphi(e_i) = a_{ii}$. Cum φ este pozitiv definită și

$e_i \neq 0$, rezultă că $a_{ii} = \varphi(e_i) > 0$, adică (a).

Pentru un număr real oarecare λ avem

$$\varphi(\lambda e_i + e_j) = a_{ii} \lambda^2 + 2a_{ij} \lambda + a_{jj} > 0. \quad (1)$$

Pentru ca inegalitatea (1) să fie adevărată pentru orice $\lambda \in \mathbb{R}$, trebuie ca

$$\Delta = 4(a_{ij}^2 - a_{ii} a_{jj}) < 0.$$

Așadar am demonstrat că $a_{ij}^2 < a_{ii} a_{jj}$ pentru orice $i, j = \overline{1, n}$, adică (b). \square

Observația 2. Condițiile care apar în Propoziția 1 sunt doar necesare nu și suficiente.

Exemplu.

Matricea $A = \begin{pmatrix} 3 & 2 & -2 \\ 2 & 3 & 2 \\ -2 & 2 & 3 \end{pmatrix}$ satisface condițiile din Propoziția 1, dar nu este

pozitiv definită.

Într-adevăr,

$$\varphi(x) = 3(x_1^2 + x_2^2 + x_3^2) + 4(x_1 x_2 - x_1 x_3 + x_2 x_3).$$

Dacă $x = \begin{pmatrix} 1 \\ -1 \\ 1 \end{pmatrix}$, atunci $\varphi(x) = 9 - 12 = -3 < 0$, deci φ nu este pozitiv definită.

Definiția 1. Spunem că matricea A este tare diagonal dominantă dacă elementele sale satisfac inegalitățile:

$$|a_{ii}| > \sum_{\substack{j=1 \\ j \neq i}}^n |a_{ij}|, \quad i = \overline{1, n}. \quad (d)$$

Dacă inegalitățile (d) devin egalități pentru anumiți indici, dar nu pentru toți, matricea se numește slab diagonal dominantă.

Teorema 1. Fie A o matrice simetrică cu următoarele proprietăți:

- (i) A este tare diagonal dominantă,
- (ii) $a_{ii} > 0$ pentru $i = \overline{1, n}$.

Atunci A este pozitiv definită.

Demonstrație.

Din condiția (i) rezultă că dacă $x \neq 0$, atunci:

$$\begin{aligned} \varphi(x) &= \sum_{i=1}^n a_{ii} x_i^2 + \sum_{i=1}^n \sum_{\substack{j=1 \\ j \neq i}}^n a_{ij} x_i x_j > \sum_{i=1}^n \sum_{\substack{j=1 \\ j \neq i}}^n |a_{ij}| x_i^2 - \sum_{i=1}^n \sum_{\substack{j=1 \\ j \neq i}}^n |a_{ij}| \cdot |x_i| \cdot |x_j| = \\ &= \sum_{i=1}^n \sum_{\substack{j=1 \\ j \neq i}}^n |a_{ij}| \cdot |x_i| \cdot (|x_i| - |x_j|) \end{aligned}$$

Deoarece $a_{ij} = a_{ji}$ avem și inegalitatea:

$$\varphi(x) > \sum_{i=1}^n \sum_{\substack{j=1 \\ j \neq i}}^n |a_{ij}| \cdot |x_j| (|x_j| - |x_i|).$$

Adunând cele două inegalități rezultă

$$2\varphi(x) > \sum_{i=1}^n \sum_{\substack{j=1 \\ j \neq i}}^n |a_{ij}| \cdot (|x_i| - |x_j|)^2 \geq 0.$$

Așadar, $\varphi(x) > 0$ pentru orice $x \neq 0$, deci φ este pozitiv definită. \square

Definiția 2. Fie $M = \{1, 2, \dots, n\}$. O matrice A se numește reductibilă dacă există două submulțimi $S, T \subset M$ cu proprietățile:

- (i) $S \neq \emptyset, T \neq \emptyset$
- (ii) $S \cap T = \emptyset$
- (iii) $S \cup T = M$
- (iv) $a_{ij} = 0$ pentru orice $i \in S$ și $j \in T$.

Matricea A se numește ireductibilă dacă oricare ar fi submulțimile S și T ale lui M cu proprietățile (i)–(iii), există $i_0 \in S$ și $j_0 \in T$ astfel încât $a_{i_0 j_0} \neq 0$.

Cel mai simplu exemplu de matrice reductibilă este matricea diagonală.

Teorema 2. Fie A o matrice simetrică având următoarele proprietăți:

- (i) A este slab diagonal dominantă,
- (ii) A este ireductibilă,
- (iii) $a_{ii} > 0$ pentru orice $i = \overline{1, n}$.

Atunci A este pozitiv definită.

Demonstrație. Procedând ca în demonstrația Teoremei 1, rezultă:

$$\varphi(x) \geq \frac{1}{2} \sum_{i=1}^n \sum_{\substack{j=1 \\ j \neq i}}^n |a_{ij}| \cdot (|x_i| - |x_j|)^2 \geq 0.$$

Vom arăta că situația $\varphi(x)=0$ pentru $x \neq 0$ nu poate avea loc. Într-adevăr, $\varphi(x)$ se anulează în următoarele cazuri:

1) $a_{ij} = 0$ pentru orice $i \neq j$. Atunci matricea A are forma diagonală și este reductibilă.

2) $|x_i| = |x_j| = \alpha \neq 0$ pentru orice i și j .

$$\varphi(x) = \sum_{i=1}^n a_{ii} \alpha^2 + \sum_{\substack{i=1 \\ j \neq i}}^n \sum_{j=1}^n a_{ij} x_i x_j \geq \sum_{i=1}^n (a_{ii} - \sum_{\substack{j=1 \\ j \neq i}}^n |a_{ij}|) \cdot \alpha^2 \geq 0.$$

Cum există cel puțin un indice i_0 astfel încât $\sum_{\substack{j=1 \\ j \neq i_0}}^n |a_{i_0 j}| < a_{i_0 i_0}$, rezultă

$\varphi(x) > 0$ pentru $x \neq 0$.

3) $a_{ij} = 0$ pentru orice pereche de indici (i, j) pentru care $|x_i| \neq |x_j|$ și $a_{ij} \neq 0$ dacă $|x_i| = |x_j| \neq 0$.

Fie $M = \{1, 2, \dots, n\}$ și $S = \{i, j \in M; |x_i| = |x_j| \neq 0\}$.

Dacă $S = M$, atunci suntem în cazul 2).

Dacă $S = \emptyset$, atunci $|x_i| \neq |x_j|$ pentru orice i și j și evident $\varphi(x) > 0$ pentru $x \neq 0$.

Așadar, putem presupune că $\emptyset \neq S \subset M$ (incluziune strictă). Dacă notăm cu $T = M \setminus S$ atunci S și T satisfac condițiile (i)–(iv) din Definiția 2, deci A este reductibilă. \square

Exemplu.

Fie

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

Matricea A este simetrică, slab diagonal dominantă, ireductibilă și are elementele de pe diagonală principală strict pozitive. Din Teorema 2 rezultă că A este pozitiv definită.

Oservația 2. Teorema 2 este utilă la stabilirea faptului că anumite matrice care apar în rezolvarea numerică a ecuațiilor cu derivate parțiale de tip eliptic sunt pozitiv definite.

§1.3. Metoda Cholesky

Fie A o matrice simetrică, pozitiv definită și

$$\varphi(x) = x^T Ax = \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j$$

forma pătratică asociată. Deoarece $a_{11} > 0$ avem:

$$\begin{aligned} \varphi(x) = a_{11}x_1^2 + 2a_{12}x_1x_2 + \dots + 2a_{1n}x_1x_n + \sum_{i=2}^n \sum_{j=2}^n a_{ij}x_ix_j = & \left(\sqrt{a_{11}}x_1 + \sum_{j=2}^n \frac{a_{1j}}{\sqrt{a_{11}}}x_j \right)^2 + \\ & + \sum_{i=2}^n \sum_{j=2}^n a_{ij}^{(1)}x_ix_j, \text{ unde } a_{ij}^{(1)} = a_{ij} - \frac{a_{1i}a_{1j}}{a_{11}}, \quad i, j = \overline{2, n} \end{aligned}$$

Dacă notăm cu

$$\varphi_1(x) = \sum_{i=2}^n \sum_{j=2}^n a_{ij}^{(1)}x_ix_j,$$

atunci φ_1 este la rândul său o formă pătratică pozitiv definită.

Într-adevăr, să presupunem prin absurd că există $z = \begin{pmatrix} z_2 \\ \vdots \\ z_n \end{pmatrix} \neq 0$ astfel încât

$$\varphi_1(z) \leq 0.$$

$$\text{Fie } z_1 = -\sum_{j=2}^n \frac{a_{1j}}{a_{11}}z_j \text{ și } \bar{z} = \begin{pmatrix} z_1 \\ z_2 \\ \vdots \\ z_n \end{pmatrix}.$$

În continuare avem

$$\varphi(\bar{z}) = \left(\sqrt{a_{11}}z_1 + \sum_{j=2}^n \frac{a_{1j}}{\sqrt{a_{11}}}z_j \right)^2 + \varphi_1(z) = 0 + \varphi_1(z) \leq 0,$$

ceea ce contrazice faptul că φ este pozitiv definită.

Așadar, am demonstrat că φ_1 este pozitiv definită. În particular, rezultă că $a_{22}^{(1)} > 0$. Mai departe procedăm cu φ_1 așa cum am procedat cu φ și obținem

$$\varphi_1(x) = \left(\sqrt{a_{22}^{(1)}} x_2 + \sum_{j=3}^n \frac{a_{2j}^{(1)}}{\sqrt{a_{22}^{(1)}}} x_j \right)^2 + \varphi_2(x) \quad ,$$

unde

$$\varphi_2(x) = \sum_{i=3}^n \sum_{j=3}^n a_{ij}^{(2)} x_i x_j$$

este pozitiv definită. În final $\varphi(x)$ se reprezintă ca o sumă de pătrate. Mai precis $\varphi(x)$ admite următoarea scriere:

$$\varphi(x) = \sum_{i=1}^n \left(\sqrt{a_{ii}^{(i-1)}} x_i + \sum_{j=i+1}^n \frac{a_{ij}^{(i-1)}}{\sqrt{a_{ii}^{(i-1)}}} x_j \right)^2 ,$$

unde

$$a_{ij}^{(0)} = a_{ij} \quad \text{și} \quad a_{ij}^{(p)} = a_{ij}^{(p-1)} - \frac{a_{pi}^{(p-1)} a_{pj}^{(p-1)}}{a_{pp}^{(p-1)}} , \quad p = \overline{1, n-1} .$$

Introducem notațiile:

$$\begin{aligned} r_{ii} &= \sqrt{a_{ii}^{(i-1)}} , \quad i = \overline{1, n} \\ r_{ij} &= \frac{a_{ij}^{(i-1)}}{r_{ii}} , \quad i < j \\ r_{ij} &= 0 , \quad j < i \\ a_{ij}^{(p)} &= a_{ij}^{(p-1)} - r_{pi} r_{pj} , \quad p = \overline{1, n-1} , \quad i, j = \overline{p+1, n} . \end{aligned} \quad (1)$$

Cu aceste notații avem

$$\begin{aligned} \varphi(x) &= \sum_{i=1}^n \left(\sum_{j=i}^n r_{ij} x_j \right)^2 = (r_{11} x_1 + r_{12} x_2 + \dots + r_{1n} x_n)^2 + (r_{22} x_2 + \dots + r_{2n} x_n)^2 + \\ &\quad + \dots + (r_{nn} x_n)^2 \end{aligned}$$

Dacă notăm cu R următoarea matrice superior triunghiulară

$$R = \begin{pmatrix} r_{11} & r_{12} & \dots & r_{1n} \\ 0 & r_{22} & \dots & r_{2n} \\ \vdots & \vdots & & \vdots \\ 0 & 0 & \dots & r_{nn} \end{pmatrix} ,$$

atunci $\varphi(x) = (x^T R^T)(R x) = x^T (R^T R) x$. Pe de altă parte, $\varphi(x) = x^T A x$. Se obține astfel următoarea descompunere a matricei A

$$A = R^T R \quad (2)$$

unde R este o matrice superior triunghiulară.

Descompunerea (2) poartă numele de *factorizarea Cholesky* a matricei A și are loc pentru matrice simetrice pozitiv definite.

Numărul de operații pentru determinarea matricei R

Pentru a calcula elementele liniei a i -a a matricei R sunt necesare $(n-i)(2i-1)+2i-2$ operații elementare și o extragere de rădăcină pătrată. Pentru toate liniile sunt necesare

$$\sum_{i=1}^n [(n-i)(2i-1)+2i-2] = \frac{n^3}{3} + \frac{n^2}{2} - \frac{5n}{6}$$

operații elementare plus n extrageri de rădăcină pătrată.

Exemplu. Să se determine descompunerea Cholesky a matricei

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

$$r_{11} = \sqrt{3}, \quad r_{12} = \frac{2}{\sqrt{3}}, \quad r_{13} = \frac{2}{\sqrt{3}}, \quad a_{22}^{(1)} = a_{22} - r_{12}^2 = \frac{5}{3}, \quad r_{22} = \sqrt{\frac{5}{3}},$$

$$a_{23}^{(1)} = a_{23} - r_{12}r_{13} = \frac{2}{3}, \quad r_{23} = \frac{a_{23}^{(1)}}{r_{22}} = \frac{2}{\sqrt{15}}, \quad a_{33}^{(1)} = a_{33} - r_{13}^2 = \frac{5}{3},$$

$$a_{33}^{(2)} = a_{33}^{(1)} - r_{23}^2 = \frac{7}{5}, \quad r_{33} = \sqrt{\frac{7}{5}}$$

$$R = \begin{pmatrix} \sqrt{3} & \frac{2}{\sqrt{3}} & \frac{2}{\sqrt{3}} \\ 0 & \sqrt{\frac{5}{3}} & \frac{2}{\sqrt{15}} \\ 0 & 0 & \sqrt{\frac{7}{5}} \end{pmatrix}.$$

Se verifică imediat că $A = R^T R$.

Rezolvarea sistemului $Ax=b$ cu metoda Cholesky, în cazul când matricea A este simetrică și pozitiv definită, revine la rezolvarea a două sisteme triunghiulare și anume

$$\begin{cases} R^T y = b \\ Rx = y \end{cases}$$

Algoritmul Cholesky pentru rezolvarea sistemelor de ecuații liniare

Pentru $p:=1, n-1$ execută

$r_{pp} := \sqrt{a_{pp}}$;
 Pentru $k:=p+1, n-1$ execută

$$r_{pk} := \frac{a_{pk}}{r_{pp}} ;$$
 sfârșit pentru k ;
 Pentru $i:=p+1, n$ execută
 Pentru $j:=i, n$ execută
 $a_{ij} := a_{ij} - r_{pi} r_{pj}$;
 sfârșit pentru j ;
 sfârșit pentru i ;
 sfârșit pentru p ;
 { Rezolvarea sistemului $R^T y = b$ }

$$y_1 = \frac{b_1}{r_{11}} ;$$
 Pentru $i:=2, n$ execută
 $s := 0$;
 Pentru $j:=1, i$ execută
 $s := s + r_{ij} y_j$;
 sfârșit pentru j ;

$$y_i := \frac{b_i - s}{r_{ii}} ;$$
 sfârșit pentru i ;
 { Rezolvarea sistemului $Rx = y$ }

$$x_n = \frac{y_n}{r_{nn}} ;$$
 Pentru $i:=n-1, 1$ execută
 $s := 0$;
 Pentru $j:=i+1, n$ execută
 $s := s + r_{ij} x_j$;
 sfârșit pentru j ;

$$x_i := \frac{y_i - s}{r_{ii}} ;$$
 sfârșit pentru i .

Algoritmul se află programat și în MATLAB și se apelează cu secvența:

$R = \text{chol}(A)$;

$x = R \setminus R \setminus b$ { pentru afișarea soluției }

§1.4. Metoda Householder. Factorizarea QR

O matrice Householder este o matrice de forma $H = I_n - 2hh^T$, unde $h^T = (0, \dots, 0, h_i, \dots, h_n)$ și $\|h\|_2 = \sqrt{h_i^2 + \dots + h_n^2} = 1$. Se observă imediat că o matrice Householder este simetrică și are următoarea structură:

$$H = \begin{pmatrix} 1 & & & & & 0 \\ & \ddots & & & & \\ & & 1 & & & \\ 0 & & & 1-2h_i^2 & -2h_i h_{i+1} & \dots & -2h_i h_n \\ & & & \vdots & \vdots & & \vdots \\ & & & -2h_n h_i & -2h_n h_{i+1} & \dots & 1-2h_n^2 \end{pmatrix}$$

Mai mult, constatăm că H este ortogonală. Într-adevăr,

$$H^2 = (I_n - 2hh^T)(I_n - 2hh^T) = I_n - 2hh^T - 2hh^T + 4h(h^T h)h^T.$$

Cum $h^T h = 1$, rezultă $H^2 = I_n$. Așadar, avem $H^{-1} = H = H^T$.

Un calcul simplu ne arată că $(hh^T)x = (h^T x)h$, pentru orice $x = (x_1, x_2, \dots, x_n)^T$.

În continuare ne punem următoarea problemă: *dat fiind un vector coloană $x \neq 0$, se poate determina o matrice Householder H , astfel încât Hx să fie colinear cu e_1 ? (unde $e_1^T = (1, 0, \dots, 0)$).*

Cu alte cuvinte, se poate determina un vector coloană h , cu $\|h\|_2 = 1$ și un număr real σ astfel încât $Hx = x - 2hh^T x = \sigma e_1$?

Ținând seama de observația de mai sus, aceasta revine la $x - 2(h^T x)h = \sigma e_1$, de unde rezultă $x - \sigma e_1 = 2(h^T x)h$. Așadar, h trebuie să fie colinear cu $x - \sigma e_1$. Cum $\|h\|_2 = 1$ rezultă

$$h = \frac{x - \sigma \cdot e_1}{\|x - \sigma \cdot e_1\|_2}. \quad (1)$$

Pe de altă parte, H fiind ortogonală avem

$$\|x\|_2 = \|Hx\|_2 = |\sigma| \cdot \|e_1\|_2 = |\sigma|.$$

Alegem $\sigma = -\operatorname{sgn}(x_1) \|x\|_2$ și facem convenția $\operatorname{sgn}(x_1) = 1$ dacă $x_1 = 0$.

În continuare avem

$$x - \sigma \cdot e_1 = \begin{pmatrix} x_1 + \operatorname{sgn}(x_1) \cdot \|x\|_2 \\ x_2 \\ \vdots \\ x_n \end{pmatrix} = \begin{pmatrix} (|x_1| + \|x\|_2) \cdot \operatorname{sgn}(x_1) \\ x_2 \\ \vdots \\ x_n \end{pmatrix} \text{ și}$$

$$\|x - \sigma e_1\|_2^2 = 2\|x\|_2^2 + 2|x_1| \cdot \|x\|_2 = 2\|x\|_2 (\|x\|_2 + |x_1|) .$$

Înlocuind în (1) obținem

$$h = \frac{1}{\sqrt{2\|x\|_2 (\|x\|_2 + |x_1|)}} \begin{pmatrix} (|x_1| + \|x\|_2) \operatorname{sgn} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix} . \quad (2)$$

Se obține astfel următorul algoritm pentru determinarea lui h și deci a matricei H :

$$\begin{aligned} H &= I_n - \beta u u^T \\ \beta &= \left(\|x\|_2 (\|x\|_2 + |x_1|) \right)^{-1} \\ u &= \left((|x_1| + \|x\|_2) \operatorname{sgn}(x_1), x_2, \dots, x_n \right)^T \\ \operatorname{sgn}(x_1) &= 1 \text{ dacă } x_1 = 0. \end{aligned} \quad (3)$$

Teorema 1. Pentru orice matrice $A \in M_n(\mathbb{R})$ nesingulară există o matrice ortogonală H astfel încât matricea $R = HA$ este superior triunghiulară.

Demonstrație.

Fie $a_1 = \begin{pmatrix} a_{11} \\ a_{21} \\ \vdots \\ a_{n1} \end{pmatrix}$, prima coloană a matricei A . Din cele arătate mai înainte rezultă

că există o matrice Householder H_1 astfel încât $H_1 a_1 = \sigma e_1$. Matricea H_1 se determină astfel:

$$s = \left(\sum_{j=1}^n a_{j1}^2 \right)^{1/2}, \quad \beta = (s(s + |a_{11}|))^{-1}, \quad u = \left((|a_{11}| + s) \operatorname{sgn}(a_{11}), a_{21}, \dots, a_{n1} \right)^T,$$

$$\operatorname{sgn}(a_{11}) = 1 \text{ dacă } a_{11} = 0, \quad H_1 = I_n - \beta u u^T. \quad (4)$$

Dacă notăm cu $A_1 = H_1 A$, atunci A_1 are următoarea formă:

$$A_1 = \begin{pmatrix} -\operatorname{sgn}(a_{11})s & a_{12}^{(1)} & \dots & a_{1n}^{(1)} \\ 0 & a_{22}^{(1)} & \dots & a_{2n}^{(1)} \\ \vdots & \vdots & \dots & \vdots \\ 0 & a_{n2}^{(1)} & \dots & a_{nn}^{(1)} \end{pmatrix}$$

În continuare considerăm vectorul $a_2^{(1)} = \begin{pmatrix} a_{22}^{(1)} \\ \vdots \\ a_{n2}^{(1)} \end{pmatrix}$ și determinăm o matrice

ortogonală $\tilde{H}_2 \in M_{n-1}(\mathbb{R})$ astfel încât

$$\tilde{H}_2 a_2^{(1)} = \sigma \cdot \tilde{e}_1,$$

unde $\tilde{e}_1^T = (1, 0, \dots, 0) \in \mathbb{R}^{n-1}$.

Notăm cu $H_2 = \begin{pmatrix} 1 & 0 \\ 0 & \tilde{H}_2 \end{pmatrix} \in M_n(\mathbb{R})$ și cu $A_2 = H_2 A_1$. Matricea A_2 va arăta astfel

$$A_2 = \begin{pmatrix} a_{11}^{(2)} & a_{12}^{(2)} & a_{13}^{(2)} & \dots & a_{1n}^{(2)} \\ 0 & a_{22}^{(2)} & a_{23}^{(2)} & \dots & a_{2n}^{(2)} \\ 0 & 0 & a_{33}^{(2)} & \dots & a_{3n}^{(2)} \\ \vdots & \vdots & \vdots & & \vdots \\ 0 & 0 & a_{n3}^{(2)} & \dots & a_{nn}^{(2)} \end{pmatrix}, \text{ unde } a_{1j}^{(2)} = a_{1j}^{(1)}, j = \overline{1, n}.$$

În continuare se determină o matrice Householder $\tilde{H}_3 \in M_{n-2}(\mathbb{R})$ cu proprietatea că $\tilde{H}_3 a_3^{(2)} = \sigma \tilde{e}_1$, unde $\tilde{e}_1^T = (1, 0, \dots, 0) \in M_{n-2}(\mathbb{R})$. Vom nota cu

$H_3 = \begin{pmatrix} I_2 & 0 \\ 0 & \tilde{H}_3 \end{pmatrix} \in M_n(\mathbb{R})$ și cu $A_3 = H_3 A_2$. Matricea A_3 va avea toate elementele de

sub diagonala principală, din primele trei coloane, zero. Procedul continuă într-un mod evident. În final, obținem o matrice superior triunghiulară $A_{n-1} = H_{n-1} A_{n-2} = \dots = H_{n-1} \dots H_2 H_1 A$. Dacă notăm $H = H_{n-1} \dots H_2 H_1$ și cu $R = HA$, atunci H este ortogonală și R superior triunghiulară. \square

Corolar. Pentru orice matrice nesingulară $A \in M_n(\mathbb{R})$ există o matrice ortogonală Q și o matrice superior triunghiulară R astfel încât $A = QR$.

Algoritmul Householder pentru rezolvarea sistemelor de ecuații liniare

Fie sistemul $Ax = b$ cu $A \in M_n(\mathbb{R})$. Notăm cu $C = (A|b) = (c_{ij}) \in M_{n, n+1}(\mathbb{R})$ matricea extinsă.

Pentru $i = 1, n-1$ execută

$$s := \sqrt{\sum_{j=i}^n c_{ji}^2};$$

dacă $s = 0$ atunci A este singulară. Stop!

altfel $\beta := (s(|c_{ii}| + s))^{-1}$; dacă $c_{ii} = 0$ atunci $\text{sgn}(c_{ii}) := 1$;

$$u := (0, \dots, 0, (c_{ii} + s) \cdot \text{sgn}(c_{ii}), c_{i+1,i}, \dots, c_{ni})^T;$$

$$H_i = I_n - \beta uu^T; \quad C := H_i C;$$

sfârșit pentru i ;

Exemplu. Fie sistemul

$$\begin{cases} 5x_1 + 2x_2 + x_3 = 12 \\ 5x_1 - 6x_2 + 2x_3 = -1 \\ -4x_1 + 2x_2 + x_3 = 3 \end{cases}$$

Soluția exactă este $x_1 = 1, x_2 = 2, x_3 = 3$.

Aplicăm metoda Householder.

$$A = \begin{pmatrix} 5 & 2 & 1 \\ 5 & -6 & 2 \\ -4 & 2 & 1 \end{pmatrix}; \quad b = \begin{pmatrix} 12 \\ -1 \\ 3 \end{pmatrix}, \quad C = \begin{pmatrix} 5 & 2 & 1 & 12 \\ 5 & -6 & 2 & -1 \\ -4 & 2 & 1 & 3 \end{pmatrix};$$

Iterația I

$$a_1 = \begin{pmatrix} 5 \\ 5 \\ -4 \end{pmatrix}; \quad c_{11} = 5; \quad s = \sqrt{66} = 8.124038405;$$

$$\beta = \frac{1}{8.124038405 \cdot 13.124038405} = 9.379086466 \cdot 10^{-3}; \quad u = \begin{pmatrix} 13.124038405 \\ 5 \\ -4 \end{pmatrix};$$

$$H_1 = \begin{pmatrix} -0.615457455 & -0.615457455 & 0.492365964 \\ -0.615457455 & 0.765522838 & 0.187581729 \\ 0.492365964 & 0.187581729 & 0.849934617 \end{pmatrix}$$

$$A_1 = H_1 A = \begin{pmatrix} -8.12403840 & 3.44656174 & -1.35400640 \\ 0 & -5.44888848 & 1.10316995 \\ 0 & 1.55911078 & 1.71746403 \end{pmatrix};$$

$$b_1 = H_1 b = \begin{pmatrix} -5.292934112 \\ -7.588267109 \\ 8.270613687 \end{pmatrix}; \quad C = H_1 \cdot C = [A_1 | b_1]$$

Iterația a II-a

$$a_2^{(1)} = \begin{pmatrix} -5.448888481 \\ 1.559110785 \end{pmatrix}; \quad s = \sqrt{c_{22}^2 + c_{32}^2} = 5.667557862;$$

$$c_{22} = -5.448888481; \quad \beta = 0.015872234; \quad u = \begin{pmatrix} 0 \\ -11.116446343 \\ 1.559110785 \end{pmatrix};$$

$$H_2 = \begin{pmatrix} 1 & 0 & 0 \\ 0 & -0.961417354 & 0.275093933 \\ 0 & 0.275093933 & 0.961417354 \end{pmatrix};$$

$$A_2 = H_2 A_1 = \begin{pmatrix} -8.124038405 & 3.446561747 & -1.354006401 \\ 0 & 5.667557862 & -0.588142797 \\ 0 & 0 & 1.954675092 \end{pmatrix};$$

$$b_2 = H_2 b_1 = \begin{pmatrix} -5.292934112 \\ 9.570687333 \\ 5.864025277 \end{pmatrix}; \quad C = H_2 \cdot C = [A_2 | b_2];$$

$$H = H_2 \cdot H_1 = \begin{pmatrix} -0.615457455 & -0.615457455 & 0.492365964 \\ 0.727158367 & -0.684384346 & 0.053467527 \\ 0.30406057 & 0.390935018 & 0.868744486 \end{pmatrix};$$

$$R = H \cdot A = \begin{pmatrix} -8.124038405 & 3.446561747 & -1.354006401 \\ 0 & 5.667557862 & -0.588142797 \\ 0 & 0 & 1.954675092 \end{pmatrix};$$

Soluția sistemului inițial este $x = R^{-1} H b$, unde:

$$R^{-1} = \begin{pmatrix} -0.123091491 & 0.074854538 & -0.062742657 \\ 0 & 0.176442839 & 0.053089941 \\ 0 & 0 & 0.511593975 \end{pmatrix}.$$

Se obține soluția $x_1=1$; $x_2=2$; $x_3=3.000000001$.

§1.5. Norme de matrice

Cele mai utilizate norme vectoriale pe \mathbb{R}^n sunt:

$$1) \quad \|x\|_\infty = \max \{ |x_1|, |x_2|, \dots, |x_n| \}$$

$$2) \quad \|x\|_p = \left(\sum_{i=1}^n |x_i|^p \right)^{1/p}, \quad 1 \leq p < \infty$$

unde $x^T = (x_1, x_2, \dots, x_n) \in \mathbb{R}^n$.

Definiția 1. Se numește normă de matrice orice aplicație

$$A \rightarrow \|A\|_M : M_n(\mathbb{R}) \rightarrow \mathbb{R}_+$$

cu proprietățile:

- (i) $\|A\|_M = 0$ dacă și numai dacă $A = 0$,
- (ii) $\|\lambda A\|_M = |\lambda| \|A\|_M$, ; $\lambda \in \mathbb{R}$, $A \in M_n(\mathbb{R})$,
- (iii) $\|A + B\|_M \leq \|A\|_M + \|B\|_M$,
- (iv) $\|AB\|_M \leq \|A\|_M \cdot \|B\|_M$, $A, B \in M_n(\mathbb{R})$.

Un exemplu de normă de matrice este *norma euclidiană* de matrice, care se definește astfel

$$\|A\|_E = \left(\sum_{i=1}^n \sum_{j=1}^n a_{ij}^2 \right)^{1/2}. \quad (1)$$

Proprietățile (i) și (ii) sunt evidente. Pentru a demonstra proprietățile (iii) și (iv) se folosește inegalitatea Cauchy–Buniakovski–Schwarz pe \mathbb{R}^n . Pentru exemplificare demonstrăm (iv). Fie $C = AB$. Atunci

$$c_{ij}^2 = \left(\sum_{k=1}^n a_{ik} b_{kj} \right)^2 \leq \left(\sum_{k=1}^n a_{ik}^2 \right) \left(\sum_{k=1}^n b_{kj}^2 \right)$$

În continuare avem

$$\|AB\|_E^2 = \sum_{i=1}^n \sum_{j=1}^n c_{ij}^2 \leq \sum_{i=1}^n \left(\sum_{k=1}^n a_{ik}^2 \right) \cdot \sum_{j=1}^n \left(\sum_{k=1}^n b_{kj}^2 \right) = \|A\|_E^2 \cdot \|B\|_E^2,$$

de unde rezultă $\|AB\|_E \leq \|A\|_E \cdot \|B\|_E$.

Definiția 2. O normă de matrice $\|\cdot\|_M$ se numește *compatibilă cu norma vectorială* $\|\cdot\|_p$ dacă $\|Ax\|_p \leq \|A\|_M \|x\|_p$ pentru orice x .

Observația 1. $\|Ax\|_2 \leq \|A\|_E \|x\|_2$, $(\forall) x$.

Într-adevăr, $\|Ax\|_2^2 = \sum_{i=1}^n (a_{i1}x_1 + \dots + a_{in}x_n)^2 \leq \sum_{i=1}^n \left(\sum_{j=1}^n a_{ij}^2 \right) \left(\sum_{j=1}^n x_j^2 \right) = \|A\|_E^2 \cdot \|x\|_2^2$.

Observația 2. Dacă λ este o valoare proprie a matricei A , atunci $|\lambda| \leq \|A\|_M$ pentru orice normă de matrice compatibilă cu o normă vectorială.

Într-adevăr, fie v un vector propriu al matricei A care corespunde valorii proprii λ . Atunci avem

$$|\lambda| \cdot \|v\| = \|\lambda v\| = \|Av\| \leq \|A\|_M \|v\|,$$

deci $|\lambda| \leq \|A\|_M$.

După cum se știe, între mulțimea $M_n(\mathbb{R})$ a matricelor pătratice cu elemente din \mathbb{R} și mulțimea $L(\mathbb{R}^n)$ a aplicațiilor liniare și continue, $U: \mathbb{R}^n \rightarrow \mathbb{R}^n$, există o corespondență bijectivă. Mai precis, dacă A este matricea asociată transformării liniare U , atunci $U(e_i^T) = (a_{1i}, a_{2i}, \dots, a_{ni})$, unde $e_i^T = (0, \dots, 1, \dots, 0) \in \mathbb{R}^n$ și $U(x^T) = (Ax)^T$. Pe de altă parte, spațiul $L(\mathbb{R}^n)$ este un spațiu normat în raport cu norma operatorială:

$$\|U\|_O = \sup \left\{ \|U(x^T)\|; \|x^T\| = 1 \right\} \quad (2)$$

unde cu $\|\cdot\|$ am notat o normă oarecare pe \mathbb{R}^n .

Se știe de asemenea că:

$$\|U\|_O = \inf \left\{ c > 0; \|U(x^T)\| \leq c \|x^T\|, (\forall) x^T \in \mathbb{R}^n \right\} \quad (3)$$

Definiția 3. Se numește norma matricei A subordonată normei vectoriale $\|\cdot\|$ următorul număr:

$$\|A\| = \sup \left\{ \|Ax\|; \|x\| = 1 \right\} = \sup_{x \neq 0} \frac{\|Ax\|}{\|x\|} \quad (4)$$

Ca și în cazul normei operatoriale, avem

$$\|A\| = \inf \left\{ c > 0; \|Ax\| \leq c \|x\|, (\forall) x \right\}. \quad (5)$$

Din relația (5) rezultă în particular că $\|Ax\| \leq \|A\| \cdot \|x\|$, $\forall x \in \mathbb{R}^n$, deci norma matriceală definită de (4) este compatibilă cu norma vectorială căreia îi este subordonată.

Este evident că aplicația $A \rightarrow \|A\|$ definită de (4) satisface proprietățile (i)–(iii) din definiția 1. De asemenea avem

$$\|ABx\| \leq \|A\| \cdot \|Bx\| \leq \|A\| \cdot \|B\| \cdot \|x\|,$$

de unde rezultă $\|A \cdot B\| \leq \|A\| \cdot \|B\|$.

Așadar, formula (4) definește într-adevăr o normă de matrice.

Definiția 4. Dacă $\lambda_1, \dots, \lambda_n$ sunt valorile proprii ale matricei A , atunci se notează cu $\rho(A) = \max_{1 \leq i \leq n} |\lambda_i|$ și $\rho(A)$ se numește raza spectrală a matricei A (în această definiție λ_i pot fi reale sau complexe)

Teorema 1. Pentru $A \in M_n(\mathbb{R})$ avem:

$$(1) \quad \|A\|_\infty = \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}|,$$

$$(2) \quad \|A\|_1 = \max_{1 \leq j \leq n} \sum_{i=1}^n |a_{ij}| ,$$

$$(3) \quad \|A\|_2 = \left(\rho(A^T \cdot A) \right)^{\frac{1}{2}} ,$$

unde cu $\|A\|_p$ am notat norma matricei A subordonată normei vectoriale $\|x\|_p$.

Demonstrație.

$$\|Ax\|_\infty = \max_{1 \leq i \leq n} \left| \sum_{j=1}^n a_{ij} x_j \right| \leq \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}| \cdot |x_j| \leq \|x\|_\infty \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}|$$

Rezultă $\|A\|_\infty \leq \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}|$. Rămâne să arătăm că există \tilde{x} cu $\|\tilde{x}\|_\infty = 1$

astfel încât $\|A\tilde{x}\|_\infty = \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}|$. Pentru aceasta, fie k astfel încât să avem

$$\sum_{j=1}^n |a_{kj}| = \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}| \quad (6)$$

$$\text{și fie } \tilde{x}_j = \begin{cases} 0 & \text{dacă } a_{kj} = 0 \\ \frac{a_{kj}}{|a_{kj}|} & \text{dacă } a_{kj} \neq 0 \end{cases} .$$

Evident că $\|\tilde{x}\|_\infty = 1$ și $\|A\tilde{x}\|_\infty = \sum_{j=1}^n |a_{kj}| = \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}|$. Așadar, am demonstrat

(1). În continuare avem

$$\begin{aligned} \|Ax\|_1 &= \sum_{i=1}^n |a_{i1}x_1 + \dots + a_{in}x_n| \leq \sum_{i=1}^n (|a_{i1}|x_1 + \dots + |a_{in}|x_n) \leq \\ &\leq \left(\max_{1 \leq j \leq n} \sum_{i=1}^n |a_{ij}| \right) \cdot (|x_1| + \dots + |x_n|) = \max_{1 \leq j \leq n} \left(\sum_{i=1}^n |a_{ij}| \right) \cdot \|x\|_1 \end{aligned}$$

de unde rezultă $\|A\|_1 \leq \max_{1 \leq j \leq n} \sum_{i=1}^n |a_{ij}|$.

Pe de altă parte dacă $e_j^T = (0, \dots, 1, \dots, 0)$, atunci $\|e_j\|_1 = 1$ și $\|Ae_j\|_1 = \sum_{i=1}^n |a_{ij}|$, de

unde rezultă $\|A\|_1 \geq \sum_{i=1}^n |a_{ij}|$, pentru orice $j = \overline{1, n}$. Așadar, $\|A\|_1 \geq \max_{1 \leq j \leq n} \sum_{i=1}^n |a_{ij}|$

și cu aceasta afirmația (2) este dovedită.

Fie $B = A^T A$ și fie

$$\mu_1 = \sup \left\{ x^T B x ; \|x\|_2 = 1 \right\} \quad (7)$$

Evident $\mu_1 = \sup \left\{ (Ax)^T Ax ; \|x\|_2 = 1 \right\} = \|A\|_2^2$, deci $\|A\|_2 = \sqrt{\mu_1}$.

Deoarece mulțimea $S = \{x ; \|x\|_2 = 1\}$ este compactă, rezultă că există v cu proprietățile: $\mu_1 = v^T B v$ și $\|v\|_2 = 1$.

Vom arăta în continuare că $Bv = \mu_1 v$, deci că v este un vector propriu pentru B și corespunde valorii proprii μ_1 .

Într-adevăr, pentru orice $z \neq 0$ avem: $\left(\frac{z}{\|z\|_2} \right)^T B \left(\frac{z}{\|z\|_2} \right) \leq \mu_1$ și deci

$$z^T B z \leq \mu_1 \|z\|_2^2 = \mu_1 z^T z \quad (8)$$

Pe de altă parte este evident că relația (8) este verificată și pentru $z=0$. Deci relația (8) are loc pentru orice z . De asemenea avem:

$$v^T B v = \mu_1 v^T v \quad (9)$$

Dacă notăm cu $C = B - \mu_1 I_n$, atunci avem:

$$z^T C z \leq 0, \quad (\forall) z \text{ și} \quad (8')$$

$$v^T C v = 0 \quad (9')$$

Fie $z = v + ty$, unde $t \in \mathbb{R}$ este oarecare și y este un vector oarecare. Din (8') și din faptul că C este simetrică rezultă

$$v^T C v + 2ty^T(Cv) + t^2 y^T C y \leq 0.$$

Ținând seama de (9') avem

$$t^2 y^T C y + 2ty^T(Cv) \leq 0. \quad (10)$$

Pentru ca (10) să fie adevărată pentru orice $t \in \mathbb{R}$ trebuie ca $y^T C v = 0$. Cum y a fost arbitrar rezultă $0 = C v = (B - \mu_1 I_n) v = B v - \mu_1 v$.

Așadar, avem $Bv = \mu_1 v$, deci μ_1 este valoare proprie pentru B și în plus $\mu_1 = \|A\|_2^2$.

Pe de altă parte, fie μ o altă valoare proprie a matricei B și fie $u \neq 0$, $\|u\|_2 = 1$, astfel încât $Bu = \mu u$. În continuare avem

$$\mu_1 = \|A\|_2^2 \geq \|Au\|_2^2 = u^T B u = u^T \mu u = \mu.$$

Așadar, μ_1 este cea mai mare valoare proprie a matricei B , deci am demonstrat și afirmația (3). \square

În particular dacă presupunem că matricea A este simetrică, rezultă că $B=A^2$. Fie $\lambda_1, \lambda_2, \dots, \lambda_n$ valorile proprii ale matricei A , care în acest caz sunt reale. Se știe că $\lambda_1^2, \lambda_2^2, \dots, \lambda_n^2$ sunt valorile proprii ale matricei A^2 . Să presupunem că $\lambda_1^2 = \max_{1 \leq j \leq n} \lambda_j^2$.

Din Teorema 1 rezultă că $\|A\|_2 = |\lambda_1|$. Dacă, în plus, A este pozitiv definită, atunci $\lambda_i > 0$ pentru orice i . Să presupunem că: $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$. Din cele de mai sus rezultă $\|A\|_2 = \lambda_1$, unde λ_1 este cea mai mare valoare proprie a matricei simetrice și pozitiv definite A .

§1.6. Perturbarea sistemelor liniare. Numărul de condiționare al unei matrice

Considerăm următorul sistem de ecuații liniare

$$\begin{cases} 10x_1 + 7x_2 + 8x_3 + 7x_4 = 32 \\ 7x_1 + 5x_2 + 6x_3 + 5x_4 = 23 \\ 8x_1 + 6x_2 + 10x_3 + 9x_4 = 33 \\ 7x_1 + 5x_2 + 9x_3 + 10x_4 = 31 \end{cases} \quad (1)$$

a cărui soluție exactă este $x_1=x_2=x_3=x_4=1$.

Să considerăm acum sistemul (1') în care am modificat "puțin" termenii liberi

$$\begin{cases} 10x_1 + 7x_2 + 8x_3 + 7x_4 = 32.1 \\ 7x_1 + 5x_2 + 6x_3 + 5x_4 = 22.9 \\ 8x_1 + 6x_2 + 10x_3 + 9x_4 = 33.1 \\ 7x_1 + 5x_2 + 9x_3 + 10x_4 = 30.9 \end{cases} \quad (1')$$

Soluția sistemului (1') este $x_1 = 9.2$; $x_2 = -12.6$; $x_3 = 4.5$; $x_4 = -1.1$. Așadar, o eroare mică, de ordinul 0.1, a termenilor liberi, produce o eroare mare, de ordinul 10, a soluției sistemului.

Fie acum sistemul (1'') în care modificăm puțin coeficienții sistemului

$$\begin{cases} 10x_1 + 7x_2 + 8.1x_3 + 7.2x_4 = 32 \\ 7.08x_1 + 5.04x_2 + 6x_3 + 5x_4 = 23 \\ 8x_1 + 5.98x_2 + 9.89x_3 + 9x_4 = 33 \\ 6.99x_1 + 4.99x_2 + 9x_3 + 9.98x_4 = 31 \end{cases} \quad (1'')$$

Soluția sistemului (1'') este: $x_1 = -81$; $x_2 = 137$; $x_3 = -34$; $x_4 = 22$.

Să analizăm acum efectul perturbării membrului drept asupra soluției unui sistem liniar $Ax=b$, în care matricea A este nesingulară.

Notăm cu δb perturbarea membrului drept și cu δx perturbarea care rezultă pentru soluție. Avem: $A(x + \delta x) = b + \delta b$, de unde rezultă $A \delta x = \delta b$ și deci $\delta x = A^{-1} \delta b$. Pentru orice normă de matrice compatibilă avem:

$$\|\delta x\| \leq \|A^{-1}\| \cdot \|\delta b\| \quad (2)$$

Pe de altă parte $\|b\| = \|Ax\| \leq \|A\| \cdot \|x\|$, de unde rezultă:

$$\frac{1}{\|x\|} \leq \frac{\|A\|}{\|b\|} \quad (3)$$

Din relațiile (2) și (3) obținem $\frac{\|\delta x\|}{\|x\|} \leq \|A\| \cdot \|A^{-1}\| \cdot \frac{\|\delta b\|}{\|b\|}$.

Numărul de condiționare al unei matrice se definește astfel

$$\text{cond}(A) = \|A\| \cdot \|A^{-1}\|. \quad (4)$$

Așadar, între eroarea relativă a membrului drept și eroarea relativă a soluției sistemului avem următoarea inegalitate

$$\frac{\|\delta x\|}{\|x\|} \leq \text{cond}(A) \cdot \frac{\|\delta b\|}{\|b\|}. \quad (5)$$

Observăm că dacă numărul de condiționare al matricei coeficienților sistemului este mare, atunci la erori relativ mici ale termenilor liberi, pot apare erori relativ mari pentru soluția sistemului. În cazul exemplului (1) avem

$$A = \begin{pmatrix} 10 & 7 & 8 & 8 \\ 7 & 5 & 6 & 5 \\ 8 & 6 & 10 & 9 \\ 7 & 5 & 9 & 10 \end{pmatrix}, \quad A^{-1} = \begin{pmatrix} 25 & -41 & 10 & -6 \\ -41 & 68 & -17 & 10 \\ 10 & -17 & 5 & -3 \\ -6 & 10 & -3 & 2 \end{pmatrix}$$

și $\text{cond}_2(A) \cong 2984$. (S-a folosit norma de matrice $\|\cdot\|_2$). După cum se vede, numărul de condiționare este destul de mare, ceea ce explică instabilitatea soluției sistemului.

Numărul de condiționare are următoarele proprietăți:

- (i) $\text{cond}(I_n) \geq 1$
- (ii) $\text{cond}(A) = \text{cond}(A^{-1})$
- (iii) $\text{cond}(\alpha A) = \text{cond}(A)$ pentru orice $\alpha \neq 0$
- (iv) $\text{cond}_2(A) = \frac{\sqrt{\mu_1}}{\sqrt{\mu_n}}$, unde $\mu_1 \geq \mu_2 \geq \dots \geq \mu_n > 0$ sunt valorile proprii ale matricei

$$B = A^T A$$

- (v) Dacă A este simetrică, atunci $\text{cond}_2(A) = \frac{\max|\lambda_i|}{\min|\lambda_i|}$, unde $\lambda_1, \dots, \lambda_n$ sunt valorile proprii ale matricei A
- (vi) Dacă A este ortogonală, atunci $\text{cond}(A)=1$.
- Pentru a evalua eroarea soluției sistemului la o perturbare a coeficienților sistemului, avem nevoie de următoarele două leme.

Lema 1. Dacă $A \in M_n(\mathbb{R})$ și $\|A\| < 1$, atunci:

(i) $A+I_n$ și $A-I_n$ sunt nesingulare, și

$$(ii) \quad \frac{1}{\|A\|+1} \leq \|(A \pm I_n)^{-1}\| \leq \frac{1}{1-\|A\|}.$$

Demonstrație.

Prezentăm demonstrația pentru $A+I_n$.

Presupunem prin absurd că $A+I_n$ este singulară. Atunci există $x \neq 0$,

$\|x\|=1$ astfel încât $(A+I_n) \cdot x = 0$. În continuare avem $x = -Ax$, deci $\|x\| \leq \|A\| \cdot \|x\|$.

Rezultă $\|A\| \geq 1$ ceea ce contrazice ipoteza $\|A\| < 1$.

Pentru a demonstra (ii) observăm că

$$1 = \|I_n\| = \|(I_n + A)(I_n + A)^{-1}\| \leq \|I_n + A\| \cdot \|(I_n + A)^{-1}\| \leq (1 + \|A\|) \cdot \|(I_n + A)^{-1}\|$$

de unde rezultă

$$\frac{1}{\|A\|+1} \leq \|(A + I_n)^{-1}\|.$$

Pe de altă parte avem

$$I_n = (I_n + A)^{-1} + A(I_n + A)^{-1},$$

de unde rezultă

$$\|(I_n + A)^{-1}\| = \|I_n - A(I_n + A)^{-1}\| \leq 1 + \|A\| \cdot \|(I_n + A)^{-1}\|,$$

și mai departe

$$\|(I_n + A)^{-1}\| \leq \frac{1}{1-\|A\|}. \quad \square$$

Lema 2 (a perturbării). Fie $A, B \in M_n(\mathbb{R})$ cu proprietățile:

$$(i) \quad \|A^{-1}\| \leq \alpha$$

$$(ii) \quad \|A^{-1}(B - A)\| \leq k < 1.$$

Atunci B este nesingulară și $\|B^{-1}\| \leq \frac{\alpha}{1-k}$.

Demonstrație.

Din Lema 1 rezultă că $I_n + A^{-1}(B - A) = A^{-1}B$ este nesingulară.

Cum $\det(A^{-1}B) = \det(A^{-1}) \cdot \det B$, va rezulta $\det B \neq 0$, deci B este nesingulară. Tot din Lema 1 rezultă

$$\|B^{-1}A\| = \left\| [I_n + A^{-1}(B-A)]^{-1} \right\| \leq \frac{1}{1 - \|A^{-1}(B-A)\|} \leq \frac{1}{1-k}.$$

Mai departe avem

$$\|B^{-1}\| = \|(B^{-1}A)A^{-1}\| \leq \|B^{-1}A\| \cdot \|A^{-1}\| \leq \frac{\alpha}{1-k}. \quad \square$$

Teorema 1. Dacă perturbăm matricea coeficienților sistemului $Ax = b$ cu δA și $\|A^{-1}\delta A\| < 1$, atunci între eroarea relativă a soluției și eroarea relativă a matricei coeficienților are loc inegalitatea

$$\frac{\|\delta x\|}{\|x\|} \leq \frac{\text{cond}(A)}{1 - \text{cond}(A)} \frac{\|\delta A\|}{\|A\|}.$$

Demonstrație.

Din egalitățile $Ax=b$ și $(A+\delta A)(x+\delta x)=b$ rezultă $A\delta x + \delta Ax + \delta A\delta x=0$. În continuare avem $\delta x = -(A+\delta A)^{-1}\delta Ax$ și mai departe

$$\frac{\|\delta x\|}{\|x\|} \leq \|(A+\delta A)^{-1}\| \cdot \|\delta A\| \quad (6)$$

Dacă alegem în Lema 2 $\alpha = \|A^{-1}\|$ și $B=A+\delta A$, atunci

$$\|A^{-1}(B-A)\| = \|A^{-1}\delta A\| < 1$$

și va rezulta

$$\|B^{-1}\| = \|(A+\delta A)^{-1}\| \leq \frac{\|A^{-1}\|}{1 - \|A^{-1}\delta A\|} \leq \frac{\|A^{-1}\|}{1 - \|A^{-1}\| \cdot \|\delta A\|}. \quad (7)$$

Din (6) și (7) obținem

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

Ținând seama de definiția numărului de condiționare, ultima inegalitate devine

$$\frac{\|\delta x\|}{\|x\|} \leq \frac{\text{cond}(A)}{1 - \text{cond}(A)} \frac{\|\delta A\|}{\|A\|}. \quad \square$$

Observația 1. Dacă presupunem în plus că perturbăm și membrul drept al sistemului cu δb atunci rezultă

$$\frac{\|\delta x\|}{\|x\|} \leq \frac{\text{cond}(A)}{1 - \text{cond}(A) \frac{\|\delta A\|}{\|A\|}} \left(\frac{\|\delta A\|}{\|A\|} + \frac{\|\delta b\|}{\|b\|} \right).$$

Observația 2. Rezolvarea sistemului $Ax=b$, cu metoda Gauss revine la rezolvarea a două sisteme triunghiulare $Uy=b$ și $Lx=y$. Rezolvarea fiecărui sistem necesită n^2 operații. Dacă unul din aceste sisteme este rău condiționat (ceea ce se poate întâmpla chiar dacă sistemul inițial $Ax=b$ este bine condiționat) metoda Gauss conduce la erori mari.

Cu totul altfel stau lucrurile în cazul metodei Householder. Deoarece $\text{cond}(Q) = 1$ și $\text{cond}(QR) = \text{cond}(R)$, rezultă că sistemul $Qy = b$ este bine condiționat și deci că sistemul $Ax = b$ are aceeași condiționare ca sistemul $Rx = y$. Așadar, algoritmul Householder are proprietăți de stabilitate mai bune decât algoritmul Gauss.

Observația 3. Pentru evaluarea numărului de condiționare $\text{cond}(A)$, este suficient să cunoaștem un majorant pentru $\|A^{-1}\|$.

Calculul lui $\|(LU)^{-1}\|$ este mai ușor decât calculul lui $\|A^{-1}\|$, deoarece inversarea matricelor triunghiulare este ușoară. Să presupunem că

$$\|(LU)^{-1}\| = \alpha \quad \text{și} \quad \|A - LU\| < \frac{k}{\alpha}$$

unde $0 < k < 1$. Atunci din Lema 2 rezultă $\|A^{-1}\| \leq \frac{\alpha}{1-k}$.

Într-adevăr, să alegem în Lema 2 matricea LU în loc de A și matricea A în loc de B . Avem

$$\|A^{-1}(A - LU)\| \leq \|A^{-1}\| \cdot \|A - LU\| \leq \alpha \cdot \frac{k}{\alpha} = k < 1.$$

Atunci rezultă $\|A^{-1}\| \leq \frac{\alpha}{1-k}$ și deci $\text{cond}(A) \leq \frac{\alpha\|A\|}{1-k}$. □

§1.7. Metode iterative de rezolvare a sistemelor de ecuații liniare

Metodele directe de rezolvare numerică a sistemelor de ecuații liniare se utilizează pentru sisteme care au matricea coeficienților densă (aproape toți coeficienții sunt nenuli) și cu un număr de ecuații moderat (până la 100 de ecuații). Pentru sisteme mari de ecuații de ordinul $10^3 \rightarrow 10^5$ și care au matricea coeficienților rară (cu multe elemente nule), se utilizează metode iterative de rezolvare numerică.

Să presupunem că sistemul

$$Ax = b \quad (1)$$

se poate pune sub forma echivalentă

$$x = Bx + c \quad (2)$$

Forma echivalentă (2) ne sugerează următorul proces iterativ:

$$x^{(m+1)} = Bx^{(m)} + c, \quad m \geq 0, \quad (3)$$

unde $x^{(0)}$ este un vector arbitrar.

Dacă notăm cu x^* soluția exactă a sistemului, atunci avem

$$x^* = Bx^* + c \quad (4)$$

Fie $e^{(m)} = x^* - x^{(m)}$ vectorul eroare.

Din (3) și (4) rezultă $e^{(m+1)} = Be^{(m)}$, $m \in \mathbb{N}^*$ și mai departe

$$e^{(m)} = B^m e^{(0)} \quad (5)$$

Teorema 1. Dacă $\|B\| < 1$, atunci șirul $(x^{(m)})$ este convergent și $\lim_{m \rightarrow \infty} x^{(m)} = x^*$.

Demonstrație.

Este suficient să arătăm că $\lim_{m \rightarrow \infty} e^{(m)} = 0$.

Din (5) avem

$$\|e^{(m)}\| \leq \|B^m\| \|e^{(0)}\| \leq \|B\|^m \cdot \|e^{(0)}\|.$$

Deoarece $\lim_{m \rightarrow \infty} \|B\|^m = 0$, rezultă $\lim_{m \rightarrow \infty} e^{(m)} = 0$. \square

Teorema 2. Condiția necesară și suficientă ca șirul $(x^{(m)})$ definit de (3) să fie convergent este ca $\rho(B) < 1$, unde cu $\rho(B)$ s-a notat raza spectrală a matricei B .

Demonstrație.

Este suficient să arătăm că $\lim_{m \rightarrow \infty} B^m = 0$ dacă și numai dacă $\rho(B) < 1$. Din

Algebra liniară se știe că matricea B se poate aduce la *forma canonică Jordan*, deci că există o matrice nesingulară C astfel încât

$$C^{-1} \cdot B \cdot C = J = \begin{pmatrix} J_{p_1}(\lambda_1) & \dots & 0 \\ \vdots & J_{p_2}(\lambda_2) & \vdots \\ 0 & & J_{p_r}(\lambda_r) \end{pmatrix},$$

unde

$$J_p(\lambda) = \begin{pmatrix} \lambda & 1 & 0 & \dots & 0 \\ & \lambda & 1 & & \vdots \\ \vdots & & & \ddots & 1 \\ 0 & & & & \lambda \end{pmatrix}$$

este o *celulă Jordan*, $\lambda_1, \dots, \lambda_r$ sunt valorile proprii ale matricei B și p_1, \dots, p_r sunt ordinele de multiplicitate ale acestor valori proprii. Deoarece $C^{-1} B^m C = J^m$, rezultă că $\lim_{m \rightarrow \infty} B^m = 0$ dacă și numai dacă $\lim_{m \rightarrow \infty} J^m = 0$. Pe

de altă parte, $J = D + N$, unde

$$D = \begin{pmatrix} \lambda_1 & & & & 0 \\ & \ddots & & & \\ 0 & & \lambda_1 & & \\ & & & \ddots & \\ & & & & \lambda_r & & 0 \\ & & & & & \ddots & \\ 0 & & & & 0 & & \lambda_r \end{pmatrix}$$

este o matrice diagonală de ordinul n , iar N este o *matrice nilpotentă de ordinul n* , adică $N^n = 0$.

În continuare avem $J^m = \sum_{k=0}^m C_m^k D^{m-k} N^k$. Deoarece $N^k = 0$ pentru $k \geq n$, vom

avea

$$J^m = \sum_{k=0}^n C_m^k D^{m-k} N^k. \quad (6)$$

Observăm că $\|D\|_\infty = \max_{1 \leq i \leq r} |\lambda_i| = \rho(B) < 1$. Din (6) rezultă:

$$\|J^m\|_\infty \leq \sum_{k=0}^n \frac{m(m-1)\dots(m-k+1)}{k!} \|D\|_\infty^{m-k} \|N\|_\infty^k < \sum_{k=0}^n \frac{m^k}{k!} \|N\|_\infty^k \cdot (\rho(B))^{m-k}$$

Cum $\lim_{m \rightarrow \infty} m^k (\rho(B))^{m-k} = 0$, rezultă că $\lim_{m \rightarrow \infty} \|J^m\|_{\infty} = 0$, deci că $\lim_{m \rightarrow \infty} J^m = 0$.

Reciproc, să presupunem că $\lim_{m \rightarrow \infty} B^m = 0$ și că $\rho(B) \geq 1$. Atunci există un vector propriu $x \neq 0$ și o valoare proprie λ , cu $|\lambda| \geq 1$, astfel încât $Bx = \lambda x$ și deci $B^m x = \lambda^m x$.

Cum $(\lambda^m x)$ nu converge la 0, rezultă că B^m nu converge la 0, ceea ce contrazice ipoteza făcută. \square

Una din cele mai cunoscute metode iterative este *metoda Jacobi*.

Să presupunem că matricea sistemului $Ax = b$ are proprietatea $a_{ii} \neq 0, i = \overline{1, n}$. Dacă notăm cu $D = \text{diag}(a_{11}, \dots, a_{nn})$ și cu $E = D - A$, atunci obținem sistemul echivalent $(D - E)x = b$ și mai departe

$$x = D^{-1}Ex + D^{-1}b \quad (7)$$

Cum $D^{-1} = \text{diag}\left(\frac{1}{a_{11}}, \dots, \frac{1}{a_{nn}}\right)$, rezultă că $\|D^{-1}E\|_{\infty} = \max_{1 \leq i \leq n} \sum_{\substack{j=1 \\ j \neq i}}^n \frac{|a_{ij}|}{|a_{ii}|}$.

Observăm că dacă matricea A este tare diagonal dominantă, atunci $\|D^{-1}E\|_{\infty} < 1$ și

în virtutea Teoremei 1, șirul

$$x^{(m+1)} = (D^{-1}E)x^{(m)} + D^{-1}b, \quad m \geq 0 \quad (8)$$

este convergent pentru orice aproximație inițială $x^{(0)}$. Așadar, metoda Jacobi constă în următoarele:

Sistemul $Ax = b$ se pune sub forma echivalentă (7).

Scris pe componente, sistemul (7) arată astfel

$$x_i = \frac{1}{a_{ii}} \left(b_i - \sum_{\substack{j=1 \\ j \neq i}}^n a_{ij} x_j \right), \quad i = \overline{1, n} \quad (7')$$

Se obține șirul recurent $\{x^{(m)}\}$ unde

$$x_i^{(m+1)} = \frac{1}{a_{ii}} \left(b_i - \sum_{\substack{j=1 \\ j \neq i}}^n a_{ij} x_j^{(m)} \right), \quad i = \overline{1, n} \quad (8')$$

Dacă matricea A este tare diagonal dominantă, șirul $(x^{(m)})$ converge la soluția exactă a sistemului.

Exemplu. Fie sistemul

$$\begin{pmatrix} 5 & -1 & -1 & -1 \\ -1 & 10 & -1 & -1 \\ -1 & -1 & 5 & -1 \\ -1 & -1 & -1 & 10 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \end{pmatrix} = \begin{pmatrix} -4 \\ 12 \\ 8 \\ 34 \end{pmatrix}$$

Soluția exactă este $x_1 = 1$, $x_2 = 2$, $x_3 = 3$, $x_4 = 4$.

$$D = \begin{pmatrix} 5 & 0 & 0 & 0 \\ 0 & 10 & 0 & 0 \\ 0 & 0 & 5 & 0 \\ 0 & 0 & 0 & 10 \end{pmatrix}, \quad E = \begin{pmatrix} 0 & 1 & 1 & 1 \\ 1 & 0 & 1 & 1 \\ 1 & 1 & 0 & 1 \\ 1 & 1 & 1 & 0 \end{pmatrix}, \quad D^{-1}E = \begin{pmatrix} 0 & 0,2 & 0,2 & 0,2 \\ 0,1 & 0 & 0,1 & 0,1 \\ 0,2 & 0,2 & 0 & 0,2 \\ 0,1 & 0,1 & 0,1 & 0 \end{pmatrix},$$

$$D^{-1}b = \begin{pmatrix} -0,8 \\ 1,2 \\ 1,6 \\ 3,4 \end{pmatrix}, \quad \|D^{-1}E\|_{\infty} = 0,6 < 1.$$

Obținem următorul proces iterativ:

$$\begin{cases} x_1^{(m+1)} = 0,2x_2^{(m)} + 0,2x_3^{(m)} + 0,2x_4^{(m)} - 0,8 \\ x_2^{(m+1)} = 0,1x_1^{(m)} + 0,1x_3^{(m)} + 0,1x_4^{(m)} - 1,2 \\ x_3^{(m+1)} = 0,2x_1^{(m)} + 0,2x_2^{(m)} + 0,2x_4^{(m)} + 1,6 \\ x_4^{(m+1)} = 0,1x_1^{(m)} + 0,1x_2^{(m)} + 0,1x_3^{(m)} + 3,4 \end{cases}$$

Dacă alegem aproximația inițială $x_1^0 = x_2^0 = x_3^0 = x_4^0 = 0$ atunci după 5 iterații obținem

$$x_1^{(5)} = 0,948; \quad x_2^{(5)} = 1,969; \quad x_3^{(5)} = 2,948; \quad x_4^{(5)} = 3,969$$

O altă metodă iterativă cunoscută este *metoda Gauss-Seidel* și care corespunde următoarei *spargerii* a matricei coeficienților:

$$A = (D+L)+U \text{ unde } D = \text{diag}(a_{11}, \dots, a_{nn}),$$

$$L = \begin{pmatrix} 0 & 0 & \dots & 0 \\ a_{21} & 0 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ a_{n1} & a_{n2} & \dots & 0 \end{pmatrix}, \text{ iar } U = \begin{pmatrix} 0 & a_{12} & \dots & a_{1n} \\ 0 & 0 & \dots & a_{2n} \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & 0 \end{pmatrix}.$$

Sistemul (1) devine $(D+L)x = -Ux + b$ și mai departe obținem următorul proces iterativ:

$$(D+L)x^{(m+1)} = -Ux^{(m)} + b \quad (9)$$

Pe componente obținem

$$x_i^{(m+1)} = \frac{1}{a_{ii}} \left(b_i - \sum_{j=1}^{i-1} a_{ij} x_j^{(m+1)} - \sum_{j=i+1}^n a_{ij} x_j^{(m)} \right), \quad i = \overline{1, n} \quad (10)$$

Din algoritmul (10) se observă că fiecare nouă componentă, $x_j^{(m+1)}$, este imediat utilizată la calculul următoarei componente.

Se poate arăta că procesul iterativ Gauss-Seidel este convergent dacă matricea A este tare diagonal dominantă.

În cazul exemplului precedent obținem

$$\begin{pmatrix} 5 & 0 & 0 & 0 \\ -1 & 10 & 0 & 0 \\ -1 & -1 & 5 & 0 \\ -1 & -1 & -1 & 10 \end{pmatrix} \begin{pmatrix} x_1^{(m+1)} \\ x_2^{(m+1)} \\ x_3^{(m+1)} \\ x_4^{(m+1)} \end{pmatrix} = \begin{pmatrix} 0 & 1 & 1 & 1 \\ 0 & 0 & 1 & 1 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 \end{pmatrix} \begin{pmatrix} x_1^{(m)} \\ x_2^{(m)} \\ x_3^{(m)} \\ x_4^{(m)} \end{pmatrix} + \begin{pmatrix} -4 \\ 12 \\ 8 \\ 34 \end{pmatrix}$$

sau

$$\begin{cases} x_1^{(m+1)} = \frac{1}{5} (x_2^{(m)} + x_3^{(m)} + x_4^{(m)} - 4) \\ x_2^{(m+1)} = \frac{1}{10} (x_1^{(m+1)} + x_3^{(m)} + x_4^{(m)} + 12) \\ x_3^{(m+1)} = \frac{1}{5} (x_1^{(m+1)} + x_2^{(m+1)} + x_4^{(m)} + 8) \\ x_4^{(m+1)} = \frac{1}{10} (x_1^{(m+1)} + x_2^{(m+1)} + x_3^{(m+1)} + 34) \end{cases}$$

Pentru $x_1^{(0)} = x_2^{(0)} = x_3^{(0)} = x_4^{(0)} = 0$, după 5 iterații obținem

$$x_1^{(5)} = 0.995 ; \quad x_2^{(5)} = 1.998 ; \quad x_3^{(5)} = 2.998 ; \quad x_4^{(5)} = 3.999 .$$

§1.8. Metode de relaxare. Principiile de bază

Metodele de relaxare sunt metode iterative și sunt utilizate pentru rezolvarea numerică a sistemelor liniare care au matricea coeficienților simetrică și pozitiv definită.

Fie sistemul liniar

$$Ax - b = 0 \quad (1)$$

unde matricea A este simetrică și pozitiv definită. Dacă $v = \begin{pmatrix} v_1 \\ v_2 \\ \vdots \\ v_n \end{pmatrix}$ este un vector de

probă oarecare, atunci notăm cu

$$r = Av - b. \quad (2)$$

Vectorul r se numește *vectorul rezidual*.

Scopul oricărei metode de relaxare este ca prin schimbarea sistematică a vectorului v , vectorul rezidual corespunzător r să se micșoreze, eventual să se anuleze.

În cele ce urmează, pentru orice doi vectori

$$u = \begin{pmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{pmatrix} \quad \text{și} \quad v = \begin{pmatrix} v_1 \\ v_2 \\ \vdots \\ v_n \end{pmatrix}$$

vom nota produsul lor scalar cu

$$\langle u, v \rangle = v^T u = u_1 v_1 + u_2 v_2 + \dots + u_n v_n \quad (3)$$

Asociem sistemului (1) funcția pătratică

$$F(v) = \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n a_{ij} v_i v_j - \sum_{i=1}^n b_i v_i = \frac{1}{2} \langle Av, v \rangle - \langle b, v \rangle \quad (4)$$

Deoarece A este pozitiv definită, rezultă $Q(v) > 0$ pentru orice $v \neq 0$, unde $Q(v) = \langle Av, v \rangle$. Observăm de asemenea că pentru orice $i = \overline{1, n}$ avem

$$\frac{\partial F}{\partial v_i} = \sum_{j=1}^n a_{ij} v_j - b_i,$$

deci vectorul rezidual

$$r = \text{grad} F. \quad (5)$$

Teorema 1. Problema determinării soluției sistemului (1) este echivalentă cu problema determinării punctului de minim al funcției pătratice (4).

Demonstrație.

Fie v_0 soluția sistemului (1). Atunci $r_0 = Av_0 - b = 0$. Cum

$r_0 = \text{grad} F(v_0)$, rezultă $\frac{\partial F}{\partial v_i}(v_0) = 0$. Așadar, $v = v_0$ este punct critic pentru F . Pe

de altă parte,

$$d^2 F(v_0) = \sum_{i=1}^n \sum_{j=1}^n a_{ij} dv_i dv_j > 0.$$

Rezultă că $v = v_0$ este un punct de minim global pentru F .

Reciproc, dacă $v=v_0$ este punct de minim pentru F atunci

$$\frac{\partial F}{\partial v_i}(v_0) = 0, \quad i = \overline{1, n}.$$

Rezultă $\sum_{j=1}^n a_{ij}v_j^0 - b_i = 0, \quad i = \overline{1, n}$, deci $v=v_0$ este soluție pentru (1). \square

În continuare prezentăm principiul de bază al metodei relaxării. Fie v un vector de probă oarecare, p o direcție dată și $D = \{v' = v + tp; t \in \mathbb{R}\}$, dreapta care trece prin v și este paralelă cu p . Ne propunem să determinăm $v'_0 \in D$ astfel încât $F(v'_0) = \min\{F(v'); v' \in D\}$. Ținând seama de (4), rezultă

$$\begin{aligned} F(v') &= \frac{1}{2} \langle A(v + tp), v + tp \rangle - \langle b, v + tp \rangle = \\ &= \frac{1}{2} \langle Av, v \rangle - \langle b, v \rangle + \frac{t}{2} \langle Av, p \rangle + \frac{t^2}{2} \langle Ap, p \rangle + \frac{t}{2} \langle Ap, v \rangle - t \langle b, p \rangle = \\ &= F(v) + \frac{t^2}{2} \langle Ap, p \rangle + t \langle Av, p \rangle - t \langle b, p \rangle = F(v) + \frac{t^2}{2} \langle Ap, p \rangle + t \langle Av - b, p \rangle = \\ &= F(v) + \frac{t^2}{2} \langle Ap, p \rangle + t \langle r, p \rangle. \end{aligned}$$

Folosim notația

$$f(t) = F(v') = F(v + tp) = F(v) + \frac{t^2}{2} \langle Ap, p \rangle + t \langle r, p \rangle \quad (6)$$

Determinăm pe t astfel încât $f(t) = F(v')$ să fie minimă. Pentru aceasta trebuie să avem $f'(t) = 0$, de unde rezultă $t \langle Ap, p \rangle + \langle r, p \rangle = 0$. Așadar, obținem:

$$t_{\min} = -\frac{\langle r, p \rangle}{\langle Ap, p \rangle} \quad (7)$$

Cum $f''(t) = \langle Ap, p \rangle > 0$, rezultă că vectorul $v'_0 = v + t_{\min} p$ este un punct de minim pentru $F(v')$.

În continuare avem

$$f(t_{\min}) = F(v'_0) = F(v) - \frac{1}{2} \frac{\langle r, p \rangle^2}{\langle Ap, p \rangle}$$

de unde rezultă

$$\Delta F = F(v'_0) - F(v) = -\frac{1}{2} \frac{\langle r, p \rangle^2}{\langle Ap, p \rangle} \leq 0.$$

Pentru ca $\Delta F < 0$, trebuie ca $\langle r, p \rangle \neq 0$. Rezultă că direcția p se alege astfel încât p să nu fie perpendiculară pe r .

Observația 1. Dacă $r'_0 = Av'_0 - b$ este vectorul rezidual corespunzător vectorului $v'_0 = v + t_{\min} p$, atunci $\langle r'_0, p \rangle = 0$.

Într-adevăr,

$$\langle r'_0, p \rangle = \langle Av - b, p \rangle + t_{\min} \langle Ap, p \rangle = \langle r, p \rangle - \frac{\langle r, p \rangle}{\langle Ap, p \rangle} \langle Ap, p \rangle = 0 .$$

Pentru interpretarea geometrică a principiului relaxării să considerăm cazul particular $n = 2$.

Ecuțiile $F(v) = \text{constant}$, reprezintă ecuațiile unor elipse concentrice, al căror centru comun, coincide cu punctul de minim al funcției F . Într-adevăr, ecuația $F(v) = c$ revine la

$$a_{11}v_1^2 + 2a_{12}v_1v_2 + a_{22}v_2^2 - 2b_1v_1 - 2b_2v_2 = 2c . \quad (8)$$

Deoarece A este pozitiv definită, rezultă că

$$\delta = \begin{pmatrix} a_{11} & a_{12} \\ a_{12} & a_{22} \end{pmatrix} > 0 ,$$


deci (8) reprezintă o elipsă.

Fie v_0 un vector de probă oarecare și $c_0 = F(v_0)$. Ecuația $F(v) = c_0$ reprezintă o elipsă și $v = v_0$ aparține acestei elipse. Deoarece $r_0 = \text{grad}F(v_0)$, rezultă că r_0 este perpendicular pe tangenta în $v = v_0$ la elipsă. Direcția p_1 o alegem astfel încât să nu fie perpendiculară pe r_0 . Fie $v_1 = v_0 + t_{\min} p_1$ și fie $c_1 = F(v_1)$.

Punctul $v = v_1$ aparține elipsei $F(v) = c_1$ și de asemenea aparține dreptei ce trece prin v_0 și are direcția p_1 .

Fie $r_1 = Av_1 - b$. Din Observația 1, rezultă că r_1 este perpendicular pe direcția p_1 . Pe de altă parte $r_1 = \text{grad}F(v_1)$ este perpendicular pe tangenta în $v = v_1$ la elipsa $F(v) = c_1$. Rezultă că $v = v_1$, este punctul de tangență la elipsa

$F(v) = c_1$ al dreptei care trece prin v_0 și are direcția p_1 .



§1.9. Metoda relaxării simple

Este o metodă specifică calculului de mână, având mai ales o semnificație istorică.

Fie v un vector de probă oarecare și fie $r = Av - b$ vectorul rezidual corespunzător.

Dacă $\max_{1 \leq i \leq n} |r_i| = |r_j|$, atunci alegem $p = e_j$ unde $e_j^T = (0, \dots, 1, \dots, 0)$. Rezultă

$$t_{\min} = -\frac{\langle r, p \rangle}{\langle Ap, p \rangle} = -\frac{r_j}{a_{jj}} \quad \text{și}$$

$$v' = v + t_{\min} p = v - \frac{r_j}{a_{jj}} e_j \quad (1)$$

Pe componente avem:

$$v'_i = \begin{cases} v_i & \text{daca } i \neq j \\ v_j - \frac{r_j}{a_{jj}} & \text{daca } i = j \end{cases} \quad (2)$$

De asemenea vom avea $r' = Av' - b = r - \frac{r_j}{a_{jj}} Ae_j$ și mai departe

$$\begin{cases} r'_1 = r_1 - \frac{r_j}{a_{jj}} a_{1j} \\ \dots\dots\dots \\ r'_j = 0 \\ \dots\dots\dots \\ r'_n = r_n - \frac{r_j}{a_{jj}} a_{nj} \end{cases} \quad (3)$$

$$\Delta F = F(v) - F(v') = -\frac{1}{2} \frac{r_j^2}{a_{jj}} < 0,$$

ceea ce asigură convergența metodei. Deși convergența este asigurată, experiențele numerice arată că aceasta este foarte lentă. Convergența este îmbunătățită dacă matricea A este tare diagonal dominantă.

Exemplu.

$$\begin{cases} -x_1 + 0.2x_2 + 0.2x_3 + 0.6 = 0 \\ 0.2x_1 - x_2 + 0.2x_3 + 0.5 = 0 \\ 0.2x_1 + 0.2x_2 - x_3 + 0.4 = 0 \end{cases}$$

Dacă alegem $v^{(1)} = \begin{pmatrix} 0 \\ 0 \\ 0 \end{pmatrix}$, atunci

$$r^{(1)} = \begin{pmatrix} 0.6 \\ 0.5 \\ 0.4 \end{pmatrix} \text{ și } \max(r_1^{(1)}, r_2^{(1)}, r_3^{(1)}) = r_1^{(1)} = 0.6 .$$

Așadar

$$p_1 = e_1 = \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix}, \quad v^{(2)} = v^{(1)} - \frac{r_1^{(1)}}{a_{11}} e_1 \quad \text{și} \quad r^{(2)} = r^{(1)} - \frac{r_1^{(1)}}{a_{11}} A e_1 .$$

Pe componente avem

$$\begin{cases} v_1^{(2)} = 0.6 \\ v_2^{(2)} = 0 \\ v_3^{(2)} = 0 \end{cases}, \quad \begin{cases} r_1^{(2)} = 0 \\ r_2^{(2)} = 0.62 \\ r_3^{(2)} = 0.52 \end{cases},$$

$$r_2^{(2)} = \max(r_1^{(2)}, r_2^{(2)}, r_3^{(2)}) = 0.62 .$$

Rezultă

$$p_2 = e_2 = \begin{pmatrix} 0 \\ 1 \\ 0 \end{pmatrix}, \quad v^{(3)} = v^{(2)} - \frac{r_2^{(2)}}{a_{22}} e_2 \quad \text{și} \quad r^{(3)} = r^{(2)} - \frac{r_2^{(2)}}{a_{22}} A e_2 ;$$

$$\begin{cases} v_1^{(3)} = 0.6 \\ v_2^{(3)} = 0.62 \\ v_3^{(3)} = 0 \end{cases}, \quad \begin{cases} r_1^{(3)} = 0.124 \\ r_2^{(3)} = 0 \\ r_3^{(3)} = 0.644 \end{cases}$$

$$r_3^{(3)} = \max(r_1^{(3)}, r_2^{(3)}, r_3^{(3)}) = 0.644 .$$

În continuare

$$p_3 = e_3 = \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix}, \quad v^{(4)} = v^{(3)} - \frac{r_3^{(3)}}{a_{33}} e_3 \quad \text{și} \quad r^{(4)} = r^{(3)} - \frac{r_3^{(3)}}{a_{33}} A e_3 .$$

$$\begin{cases} v_1^{(4)} = 0.6 \\ v_2^{(4)} = 0.62 \\ v_3^{(4)} = 0.644 \end{cases}, \quad \begin{cases} r_1^{(4)} = 0.2528 \\ r_2^{(4)} = 0.1288 \\ r_3^{(4)} = 0 \end{cases}, \text{ etc.}$$

§1.10. Metoda deplasărilor succesive (Gauss - Seidel)

În metoda deplasărilor succesive, direcția de relaxare urmează ciclic direcțiile e_1, e_2, \dots, e_n , indiferent de reziduurile respective, după care ciclul se reia. Pentru simplificare să presupunem că avem sistemul

$$\begin{cases} a_{11}x_1 + a_{12}x_2 + a_{13}x_3 - b_1 = 0 \\ a_{21}x_1 + a_{22}x_2 + a_{23}x_3 - b_2 = 0 \\ a_{31}x_1 + a_{32}x_2 + a_{33}x_3 - b_3 = 0 \end{cases}$$

Fie $v^{(0)}$ vectorul de probă inițial și fie $p' = e_1 = \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix}$. Conform formulei (1) din §9

rezultă $v' = v^{(0)} - \frac{r_1^{(0)}}{a_{11}} e_1$, iar pe componente

$$\begin{cases} v'_1 = v_1^{(0)} - \frac{1}{a_{11}}(a_{11}v_1^{(0)} + a_{12}v_2^{(0)} + a_{13}v_3^{(0)} - b_1) \\ v'_2 = v_2^{(0)} \\ v'_3 = v_3^{(0)} \end{cases}$$

În continuare alegem direcția de relaxare

$$p'' = e_2 = \begin{pmatrix} 0 \\ 1 \\ 0 \end{pmatrix}$$

și obținem vectorul v'' de componente

$$\begin{cases} v''_1 = v'_1 \\ v''_2 = v_2^{(0)} - \frac{1}{a_{22}}(a_{21}v'_1 + a_{22}v_2^{(0)} + a_{23}v_3^{(0)} - b_2) \\ v''_3 = v_3^{(0)} \end{cases}$$

În sfârșit, pentru direcția de relaxare

$$p''' = e_3 = \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix},$$

obținem vectorul v''' de componente

$$\begin{cases} v_1''' = v_1'' \\ v_2''' = v_2'' \\ v_3''' = v_3^{(0)} - \frac{1}{a_{33}}(a_{31}v_1'' + a_{32}v_2'' + a_{33}v_3'' - b_3) \end{cases}$$

După încheierea acestui ciclu, vectorul găsit va fi notat cu $v^{(1)}$ și va avea componentele:

$$\begin{cases} v_1^{(1)} = v_1''' = -\frac{a_{12}}{a_{11}}v_2^{(0)} - \frac{a_{13}}{a_{11}}v_3^{(0)} + \frac{b_1}{a_{11}} \\ v_2^{(1)} = v_2''' = -\frac{a_{21}}{a_{22}}v_1^{(1)} - \frac{a_{23}}{a_{22}}v_3^{(0)} + \frac{b_2}{a_{22}} \\ v_3^{(1)} = v_3''' = -\frac{a_{31}}{a_{33}}v_1^{(1)} - \frac{a_{32}}{a_{33}}v_2^{(1)} + \frac{b_3}{a_{33}} \end{cases} \quad (1)$$

Efectuând calculele obținem:

$$\begin{cases} a_{11}v_1^{(1)} + a_{12}v_2^{(0)} + a_{13}v_3^{(0)} = b_1 \\ a_{21}v_1^{(1)} + a_{22}v_2^{(1)} + a_{23}v_3^{(0)} = b_2 \\ a_{31}v_1^{(1)} + a_{32}v_2^{(1)} + a_{33}v_3^{(1)} = b_3 \end{cases}$$

În general, pentru un sistem de n ecuații, după $(m+1)$ cicluri se obține vectorul $v^{(m+1)}$ care verifică ecuațiile:

$$\begin{cases} a_{11}v_1^{(m+1)} + a_{12}v_2^{(m)} + a_{13}v_3^{(m)} + \dots + a_{1n}v_n^{(m)} = b_1 \\ a_{21}v_1^{(m+1)} + a_{22}v_2^{(m+1)} + a_{23}v_3^{(m)} + \dots + a_{2n}v_n^{(m)} = b_2 \\ \dots \\ a_{n1}v_1^{(m+1)} + a_{n2}v_2^{(m+1)} + a_{n3}v_3^{(m+1)} + \dots + a_{nn}v_n^{(m+1)} = b_n \end{cases} \quad (2)$$

Observația 1. Formulele (1) coincid cu formulele (10) din §7.

Dacă notăm cu

$$E = \begin{pmatrix} 0 & 0 & 0 \dots & 0 \\ a_{21} & 0 & 0 \dots & 0 \\ a_{31} & a_{32} & 0 \dots & 0 \\ \dots & \dots & \dots & \dots \\ a_{n1} & a_{n2} & \dots & 0 \end{pmatrix}, \quad F = E^T \quad \text{și} \quad D = \begin{pmatrix} a_{11} & 0 & \dots & 0 \\ 0 & a_{22} & \dots & 0 \\ \vdots & \vdots & \dots & \vdots \\ 0 & 0 & \dots & a_{nn} \end{pmatrix},$$

atunci matricea A admite descompunerea $A=E+D+F$ și șirul de vectori $v^{(m)}$ verifică relația matricială

$$(D+E)v^{(m+1)} + Fv^{(m)} = b, \quad (3)$$

de unde rezultă

$$v^{(m+1)} = -(D+E)^{-1}Fv^{(m)} + (D+E)^{-1}b. \quad (4)$$

În sfârșit, notând

$$M = -(D+E)^{-1}F \quad \text{și} \quad C = (D+E)^{-1}b \quad (5)$$

obținem procesul iterativ

$$v^{(m+1)} = Mv^{(m)} + C. \quad (6)$$

Exemplu. Să se găsească soluția aproximativă obținută după 5 iterații cu metoda deplasărilor succesive, luând vectorul inițial $(0, 0, 0)$, pentru sistemul $Ax = b$, unde:

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

Rezolvare

$$(D+E)^{-1} = \frac{1}{36} \begin{pmatrix} 18 & 0 & 0 & 0 \\ 6 & 12 & 0 & 0 \\ 2 & 4 & 12 & 0 \\ 1 & 2 & 6 & 18 \end{pmatrix} \quad F = \begin{pmatrix} 0 & -1 & 0 & 0 \\ 0 & 0 & -1 & 0 \\ 0 & 0 & 0 & -1 \\ 0 & 0 & 0 & 0 \end{pmatrix}$$

$$M = -(D+E)^{-1}F = \frac{1}{36} \begin{pmatrix} 0 & 18 & 0 & 0 \\ 0 & 6 & 12 & 0 \\ 0 & 2 & 4 & 12 \\ 0 & 1 & 2 & 6 \end{pmatrix}$$

$$\det(M - \lambda I) = \lambda^2 \left(\lambda^2 - \frac{4}{9}\lambda + \frac{1}{36} \right).$$

Valorile proprii ale matricei M sunt $\lambda_1 = 0.369$; $\lambda_2 = 0.077$; $\lambda_3 = 0$; $\lambda_4 = 0$.
 $\rho(M) = 0.369 < 1$, deci procesul este convergent.

Pe componente algoritmul conduce la:

Iterația I

$$\begin{cases} x_1^{(1)} = \frac{1}{a_{11}}(b - a_{12}x_2^{(0)} - a_{13}x_3^{(0)} - a_{14}x_4^{(0)}) \\ x_2^{(1)} = \frac{1}{a_{22}}(b - a_{21}x_1^{(1)} - a_{23}x_3^{(0)} - a_{24}x_4^{(0)}) \\ x_3^{(1)} = \frac{1}{a_{33}}(b - a_{31}x_1^{(1)} - a_{32}x_2^{(1)} - a_{34}x_4^{(0)}) \\ x_4^{(1)} = \frac{1}{a_{44}}(b - a_{41}x_1^{(1)} - a_{42}x_2^{(1)} - a_{43}x_3^{(1)}) \end{cases} \text{ rezultă } x^{(1)} = \begin{pmatrix} 0.5 \\ 0.5 \\ 0.5 \\ 0.75 \end{pmatrix}$$

Iterația a II – a

$$\begin{cases} x_1^{(2)} = \frac{1}{a_{11}}(b - a_{12}x_2^{(1)} - a_{13}x_3^{(1)} - a_{14}x_4^{(1)}) \\ x_2^{(2)} = \frac{1}{a_{22}}(b - a_{21}x_1^{(2)} - a_{23}x_3^{(1)} - a_{24}x_4^{(1)}) \\ x_3^{(2)} = \frac{1}{a_{33}}(b - a_{31}x_1^{(2)} - a_{32}x_2^{(2)} - a_{34}x_4^{(1)}) \\ x_4^{(2)} = \frac{1}{a_{44}}(b - a_{41}x_1^{(2)} - a_{42}x_2^{(2)} - a_{43}x_3^{(2)}) \end{cases} \text{ rezultă } x^{(2)} = \begin{pmatrix} 0.75 \\ 0.75 \\ 0.83333 \\ 0.91667 \end{pmatrix}$$

Iterația a III – a

$$\begin{cases} x_1^{(3)} = \frac{1}{a_{11}}(b - a_{12}x_2^{(2)} - a_{13}x_3^{(2)} - a_{14}x_4^{(2)}) \\ x_2^{(3)} = \frac{1}{a_{22}}(b - a_{21}x_1^{(3)} - a_{23}x_3^{(2)} - a_{24}x_4^{(2)}) \\ x_3^{(3)} = \frac{1}{a_{33}}(b - a_{31}x_1^{(3)} - a_{32}x_2^{(3)} - a_{34}x_4^{(2)}) \\ x_4^{(3)} = \frac{1}{a_{44}}(b - a_{41}x_1^{(3)} - a_{42}x_2^{(3)} - a_{43}x_3^{(3)}) \end{cases} \text{ rezultă } x^{(3)} = \begin{pmatrix} 0.875 \\ 0.90278 \\ 0.93981 \\ 0.96991 \end{pmatrix}$$

Iterația a IV – a

$$\begin{cases} x_1^{(4)} = \frac{1}{a_{11}}(b - a_{12}x_2^{(3)} - a_{13}x_3^{(3)} - a_{14}x_4^{(3)}) \\ x_2^{(4)} = \frac{1}{a_{22}}(b - a_{21}x_1^{(4)} - a_{23}x_3^{(3)} - a_{24}x_4^{(3)}) \\ x_3^{(4)} = \frac{1}{a_{33}}(b - a_{31}x_1^{(4)} - a_{32}x_2^{(4)} - a_{34}x_4^{(3)}) \\ x_4^{(4)} = \frac{1}{a_{44}}(b - a_{41}x_1^{(4)} - a_{42}x_2^{(4)} - a_{43}x_3^{(4)}) \end{cases} \text{ rezultă } x^{(4)} = \begin{pmatrix} 0.95139 \\ 0.96373 \\ 0.97788 \\ 0.98894 \end{pmatrix}$$

Iterația a V – a

$$\begin{cases} x_1^{(5)} = \frac{1}{a_{11}}(b - a_{12}x_2^{(4)} - a_{13}x_3^{(4)} - a_{14}x_4^{(4)}) \\ x_2^{(5)} = \frac{1}{a_{22}}(b - a_{21}x_1^{(5)} - a_{23}x_3^{(4)} - a_{24}x_4^{(4)}) \\ x_3^{(5)} = \frac{1}{a_{33}}(b - a_{31}x_1^{(5)} - a_{32}x_2^{(5)} - a_{34}x_4^{(4)}) \\ x_4^{(5)} = \frac{1}{a_{44}}(b - a_{41}x_1^{(5)} - a_{42}x_2^{(5)} - a_{43}x_3^{(5)}) \end{cases} \text{ rezultă } x^{(5)} = \begin{pmatrix} 0.98187 \\ 0.98658 \\ 0.99184 \\ 0.99592 \end{pmatrix}.$$

Teorema 1. Dacă matricea A este simetrică și pozitiv definită, procesul iterativ Gauss–Seidel este convergent.

Demonstrația rezultă din analiza descreșterii funcției pătratice F prin trecerea de la o iterație la alta. O altă demonstrație se bazează pe faptul că se poate arăta că dacă A este simetrică și pozitiv definită, atunci $\rho(M) < 1$ și conform Teoremei 2 din §7, procesul iterativ este convergent.

§1.11. Metoda suprarelaxării

Pentru sisteme mari de ecuații, procesul iterativ Gauss–Seidel converge lent, deoarece raza spectrală $\rho(M)$ este în vecinătatea lui 1.

Metoda suprarelaxării este o generalizare a metodei Gauss–Seidel, care constă în introducerea unui parametru ω în vederea accelerării convergenței. Ca și în metoda Gauss–Seidel, direcția de relaxare urmează ciclic direcțiile e_1, e_2, \dots, e_n dar se înlocuiește t_{\min} cu $t = \omega t_{\min}$. Exemplificăm metoda pe cazul particular al unui sistem de trei ecuații. Fie $v^{(0)}$ vectorul de probă inițial. După un ciclu în care direcția de relaxare urmează succesiv direcțiile e_1, e_2, e_3 obținem vectorul $v^{(1)}$ de componente:

$$\begin{cases} v_1^{(1)} = v_1^{(0)} - \frac{\omega}{a_{11}}(a_{11}v_1^{(0)} + a_{12}v_2^{(0)} + a_{13}v_3^{(0)} - b_1) \\ v_2^{(1)} = v_2^{(0)} - \frac{\omega}{a_{22}}(a_{21}v_1^{(1)} + a_{22}v_2^{(0)} + a_{23}v_3^{(0)} - b_2) \\ v_3^{(1)} = v_3^{(0)} - \frac{\omega}{a_{33}}(a_{31}v_1^{(1)} + a_{32}v_2^{(1)} + a_{33}v_3^{(0)} - b_3) \end{cases} \quad (1)$$

Dacă $\omega = 1$, obținem din nou formulele (1) din §10. După efectuarea calculelor rezultă:

$$\begin{cases} \omega^{-1}a_{11}v_1^{(1)} + (1-\omega^{-1})a_{11}v_1^{(0)} + a_{12}v_2^{(0)} + a_{13}v_3^{(0)} = b_1 \\ a_{21}v_1^{(1)} + a_{22}\omega^{-1}v_2^{(1)} + (1-\omega^{-1})a_{22}v_2^{(0)} + a_{23}v_3^{(0)} = b_2 \\ a_{31}v_1^{(1)} + a_{32}v_2^{(1)} + a_{33}\omega^{-1}v_3^{(1)} + (1-\omega^{-1})a_{33}v_3^{(0)} = b_3 \end{cases} \quad (2)$$

Dacă introducem notațiile

$$E = \begin{pmatrix} 0 & 0 & 0 \\ a_{21} & 0 & 0 \\ a_{31} & a_{32} & 0 \end{pmatrix}, \quad D = \begin{pmatrix} a_{11} & 0 & 0 \\ 0 & a_{22} & 0 \\ 0 & 0 & a_{33} \end{pmatrix} \quad \text{și } F = E^T,$$

relațiile (2) capătă forma matricială

$$(E + \omega^{-1}D)v^{(1)} + [F + (1 - \omega^{-1})D]v^{(0)} = b. \quad (3)$$

În general, pentru un sistem de n ecuații, șirul de vectori $v^{(m)}$ satisface relația:

$$(E + \omega^{-1}D)v^{(m+1)} + [F + (1 - \omega^{-1})D]v^{(m)} = b. \quad (4)$$

În continuare avem

$$v^{(m+1)} = -(E + \omega^{-1}D)^{-1} [F + (1 - \omega^{-1})D] v^{(m)} + (E + \omega^{-1}D)^{-1} b.$$

Notăm cu

$$\begin{cases} M(\omega) = -(E + \omega^{-1}D)^{-1} [F + (1 - \omega^{-1})D] \\ C(\omega) = [E + \omega^{-1}D]^{-1} b \end{cases}. \quad (5)$$

Obținem astfel procesul iterativ

$$v^{(m+1)} = M(\omega)v^{(m)} + C(\omega). \quad (6)$$

Pentru $\omega = 1$ obținem algoritmul Gauss –Seidel (vezi (4), (5), (6) din §10).

Parametrul optim, ω_{opt} , va fi acela pentru care raza spectrală a matricei $M(\omega)$ va fi minimă. Evident, pentru acest parametru se obține cea mai rapidă convergență.

Se poate demonstra următoarea teoremă.

Teorema 1. Dacă matricea A este simetrică și pozitiv definită, metoda suprarelaxării este convergentă pentru orice $0 < \omega < 2$.

În particular, rezultă că metoda Gauss –Seidel este convergentă dacă A este simetrică și pozitiv definită, deoarece corespunde cazului particular $\omega = 1$.

Determinarea parametrului optim, ω_{opt} , este posibilă în cazul matricelor bloc tridiagonale.

Definiția 1. O matrice A se numește bloc tridiagonală, dacă are următoarea structură:

$$A = \begin{pmatrix} D_1 & F_1 & 0 & 0 & \cdots & & 0 \\ E_1 & D_2 & F_2 & 0 & \cdots & & 0 \\ 0 & E_2 & D_3 & F_3 & \cdots & & 0 \\ \vdots & & & & \ddots & & \vdots \\ 0 & & & & \cdots & E_{m-2} & D_{m-1} & F_{m-1} \\ 0 & & & & \cdots & 0 & E_{m-1} & D_m \end{pmatrix},$$

unde D_i sunt matrice pătratice de diferite ordine, E_k și F_k sunt, în general, matrice dreptunghiulare. F_k are același număr de linii ca matricea D_k și același număr de coloane ca matricea D_{k+1} . E_k are același număr de linii cu D_{k+1} și același număr de coloane cu D_k . În afara matricelor care intră în bandă, toate elementele sunt nule. Dacă, în plus, matricele D_i sunt diagonale, A se numește diagonal bloc tridiagonală.

Prezentăm de asemenea fără demonstrație următoarea teoremă.

Teorema 2. Fie A o matrice simetrică, pozitiv definită și diagonal bloc tridiagonală.

Atunci parametrul optim de relaxare este dat de relația $\omega_{\text{opt}} = \frac{2}{1 + \sqrt{1 - \lambda_1^2}}$, unde

λ_1 este cea mai mare valoare proprie a matricei $-D^{-1}(E+F)$.

Exemplu. Fie sistemul $Ax = b$ din exemplul din paragraful precedent, care are matricea diagonal bloc tridiagonală

$$A = \begin{pmatrix} 2 & -1 & 0 & 0 \\ -1 & 3 & -1 & 0 \\ 0 & -1 & 3 & -1 \\ 0 & 0 & -1 & 2 \end{pmatrix}, \quad E + F = \begin{pmatrix} 0 & -1 & 0 & 0 \\ -1 & 0 & -1 & 0 \\ 0 & -1 & 0 & -1 \\ 0 & 0 & -1 & 0 \end{pmatrix},$$

$$D = \begin{pmatrix} 2 & 0 & 0 & 0 \\ 0 & 3 & 0 & 0 \\ 0 & 0 & 3 & 0 \\ 0 & 0 & 0 & 2 \end{pmatrix}, \quad -D^{-1}(E+F) = \begin{pmatrix} 0 & \frac{1}{2} & 0 & 0 \\ \frac{1}{3} & 0 & \frac{1}{3} & 0 \\ 0 & \frac{1}{3} & 0 & \frac{1}{3} \\ 0 & 0 & \frac{1}{2} & 0 \end{pmatrix}.$$

Ecuația caracteristică este

$$\begin{vmatrix} -\lambda & \frac{1}{2} & 0 & 0 \\ \frac{1}{3} & -\lambda & \frac{1}{3} & 0 \\ 0 & \frac{1}{3} & -\lambda & \frac{1}{3} \\ 0 & 0 & \frac{1}{2} & -\lambda \end{vmatrix} = 0,$$

care este echivalentă cu

$$\begin{vmatrix} 2\lambda & -1 & 0 & 0 \\ -1 & 3\lambda & -1 & 0 \\ 0 & -1 & 3\lambda & -1 \\ 0 & 0 & -1 & 2\lambda \end{vmatrix} = 36\lambda^4 + 16\lambda^2 + 1 = 0.$$

Rezultă $\lambda_i = \pm \sqrt{\frac{4 \pm \sqrt{7}}{18}}$ și $\lambda_1 = 0.60763$.

Parametrul optim de relaxare $\omega_{opt} = \frac{2}{1 + \sqrt{1 - \lambda_1^2}} = 1.11469$.

Procedeul iterativ $x^{(m+1)} = M(\omega)x^{(m)} + C(\omega)$, unde

$$M(\omega) = \begin{pmatrix} -0.11469 & 0.55734 & 0 & 0 \\ -0.04261 & 0.0924 & 0.37156 & 0 \\ -0.01583 & 0.03433 & 0.02337 & 0.37156 \\ -0.00882482 & 0.01913 & 0.01303 & 0.0924 \end{pmatrix}, \quad C(\omega) = \begin{pmatrix} 0.55734 \\ 0.57865 \\ 0.58657 \\ 0.88426 \end{pmatrix},$$

conduce la următoarele valori ale vectorului soluțiilor pentru primele cinci iterații:

$$x^{(1)} = \begin{pmatrix} 0.55734 \\ 0.57865 \\ 0.58657 \\ 0.88426 \end{pmatrix}, \quad x^{(2)} = \begin{pmatrix} 0.81593 \\ 0.82631 \\ 0.93988 \\ 0.97976 \end{pmatrix}, \quad x^{(3)} = \begin{pmatrix} 0.92431 \\ 0.96946 \\ 0.98803 \\ 0.99565 \end{pmatrix}, \quad x^{(4)} = \begin{pmatrix} 0.99166 \\ 0.99595 \\ 0.99825 \\ 0.99953 \end{pmatrix},$$

$$x^{(5)} = \begin{pmatrix} 0.9987 \\ 0.99933 \\ 0.99978 \\ 0.99993 \end{pmatrix}.$$

§1.12. Metoda gradientilor conjugați

Fie sistemul $Ax=b$, unde A este simetrică și pozitiv definită.

Definiția 1. Spunem că direcțiile p și q sunt direcții conjugate în raport cu matricea A dacă $\langle Ap, q \rangle = \langle p, Aq \rangle = 0$.

Fie $v^{(0)}$ un vector de probă și $r^{(0)} = Av^{(0)} - b$ vectorul rezidual corespunzător. În metoda gradientilor conjugați pentru rezolvarea sistemului $Ax=b$, prima direcție de relaxare se alege $p^{(1)} = -r^{(0)}$. În continuare avem:

$$t_{\min} = -\frac{\langle r^{(0)}, p^{(1)} \rangle}{\langle Ap^{(1)}, p^{(1)} \rangle} = \frac{\langle r^{(0)}, r^{(0)} \rangle}{\langle Ap^{(1)}, p^{(1)} \rangle}, \quad (1)$$

$$v^{(1)} = v^{(0)} + q_1 p^{(1)}, \quad (2)$$

unde

$$q_1 = t_{\min} = -\frac{\langle r^{(0)}, p^{(1)} \rangle}{\langle Ap^{(1)}, p^{(1)} \rangle} \quad (3)$$

Valoarea minimă a funcției $F=F(v)$, când v parcurge dreapta ce trece prin $v^{(0)}$ și are direcția $p^{(1)} = -r^{(0)}$ este $v^{(1)}$.

Fie

$$r^{(1)} = \text{grad}F(v^{(1)}) = Av^{(1)} - b.$$

Din Observația 1 din §8 rezultă că

$$\langle r^{(1)}, p^{(1)} \rangle = -\langle r^{(1)}, r^{(0)} \rangle = 0. \quad (4)$$

Următoarea direcție de relaxare $p^{(2)}$ se alege de forma $p^{(2)} = -r^{(1)} + c_1 p^{(1)}$ și în plus să fie conjugată direcției $p^{(1)}$ în raport cu A .

Așadar, avem:

$$0 = \langle Ap^{(2)}, p^{(1)} \rangle = \langle p^{(2)}, Ap^{(1)} \rangle = -\langle r^{(1)}, Ap^{(1)} \rangle + c_1 \langle Ap^{(1)}, p^{(1)} \rangle$$

de unde rezultă

$$c_1 = \frac{\langle r^{(1)}, Ap^{(1)} \rangle}{\langle Ap^{(1)}, p^{(1)} \rangle}. \quad (5)$$

Avem de asemenea

$$v^{(2)} = v^{(1)} + t_{\min} p^{(2)} = v^{(1)} - \frac{\langle r^{(1)}, p^{(2)} \rangle}{\langle Ap^{(2)}, p^{(2)} \rangle} p^{(2)} . \quad (6)$$

În general, pentru orice $k \geq 2$ obținem

$$c_{k-1} = \frac{\langle r^{(k-1)}, Ap^{(k-1)} \rangle}{\langle Ap^{(k-1)}, p^{(k-1)} \rangle} , \quad (7)$$

$$p^{(k)} = -r^{(k-1)} + c_{k-1} p^{(k-1)} , \quad (8)$$

$$q_k = -\frac{\langle r^{(k-1)}, p^{(k)} \rangle}{\langle Ap^{(k)}, p^{(k)} \rangle} , \quad (9)$$

$$v_k = v^{(k-1)} + q_k p^{(k)} . \quad (10)$$

Metoda gradientilor conjugați este definită de formulele (7) – (10).

În continuare prezentăm unele simplificări și proprietăți suplimentare.

Deoarece $r^{(k-1)}$ este ortogonal pe direcția $p^{(k-1)}$ rezultă

$$\langle r^{(k-1)}, p^{(k)} \rangle = \langle r^{(k-1)}, -r^{(k-1)} + c_{k-1} p^{(k-1)} \rangle = -\langle r^{(k-1)}, r^{(k-1)} \rangle$$

și deci

$$q_k = \frac{\langle r^{(k-1)}, r^{(k-1)} \rangle}{\langle Ap^{(k)}, p^{(k)} \rangle} > 0 . \quad (9')$$

Pe de altă parte, din (10) avem

$$r^{(k)} = Av^{(k)} - b = Av^{(k-1)} + q_k Ap^{(k)} - b = r^{(k-1)} + q_k Ap^{(k)} .$$

Obținem deci următoarea relația de recurență

$$r^{(k)} = r^{(k-1)} + q_k Ap^{(k)} . \quad (11)$$

Observăm că

$$\langle r^{(k)}, r^{(k-1)} \rangle = 0 . \quad (12)$$

Într-adevăr, din (11) rezultă

$$\langle r^{(k)}, r^{(k-1)} \rangle = \langle r^{(k-1)}, r^{(k-1)} \rangle + q_k \langle r^{(k-1)}, Ap^{(k)} \rangle . \quad (13)$$

Pe de altă parte, ținând seama de (8), de (9') și de faptul că $p^{(k)}$ și $p^{(k-1)}$ sunt A -conjugate, rezultă

$$q_k \langle r^{(k-1)}, Ap^{(k)} \rangle = \langle r^{(k-1)}, r^{(k-1)} \rangle \frac{\langle r^{(k-1)}, Ap^{(k)} \rangle}{\langle Ap^{(k)}, -r^{(k-1)} + c_{k-1} p^{(k-1)} \rangle} = -\langle r^{(k-1)}, r^{(k-1)} \rangle$$

Din (13) și (14) rezultă acum (12) .

Deoarece $Ap^{(k)}$ oricum trebuie calculat, rezultă că vectorul rezidual $r^{(k)}$ se va calcula din relația de recurență (11) și nu prin înlocuirea directă a lui $v^{(k)}$ în expresia $Av=b$.

În continuare vom stabili o altă formulă pentru coeficientul c_{k-1} .

Din (11) și (12) rezultă

$$\langle r^{(k-1)}, Ap^{(k-1)} \rangle = \left\langle r^{(k-1)}, \frac{1}{q_{k-1}} (r^{(k-1)} - r^{(k-2)}) \right\rangle = \frac{1}{q_{k-1}} \langle r^{(k-1)}, r^{(k-1)} \rangle.$$

Ținând seama de (7) și de (9') obținem

$$c_{k-1} = \frac{\langle r^{(k-1)}, Ap^{(k-1)} \rangle}{\langle Ap^{(k-1)}, p^{(k-1)} \rangle} = \frac{\langle r^{(k-1)}, r^{(k-1)} \rangle}{\langle r^{(k-2)}, r^{(k-2)} \rangle}.$$

Algoritm pentru rezolvarea sistemelor de ecuații liniare cu metoda gradientilor conjugați

Calculează

$$r^{(0)} = Av^{(0)} - b; \quad p^{(1)} = -r^{(0)};$$

$$q_1 = \frac{\langle r^{(0)}, r^{(0)} \rangle}{\langle Ap^{(1)}, p^{(1)} \rangle}; \quad v^{(1)} = v^{(0)} + q_1 p^{(1)}; \quad r^{(1)} = r^{(0)} + q_1 Ap^{(1)};$$

Pentru $k:=2, n$ calculează

$$c_{k-1} = \frac{\langle r^{(k-1)}, r^{(k-1)} \rangle}{\langle r^{(k-2)}, r^{(k-2)} \rangle}; \quad p^{(k)} = -r^{(k-1)} + c_{k-1} p^{(k-1)};$$

$$q_k = \frac{\langle r^{(k-1)}, r^{(k-1)} \rangle}{\langle Ap^{(k)}, p^{(k)} \rangle}; \quad v^{(k)} = v^{(k-1)} + q_k p^{(k)}; \quad r^{(k)} = r^{(k-1)} + q_k Ap^{(k)};$$

sfârșit pentru k .

În Mathcad algoritmul de mai sus este aplicat unui exemplu.

Metoda gradientilor conjugati

Folosind metoda gradientilor conjugati sa se gaseasca solutia sistemului de ecuatii liniare $Ax=b$

$$A := \begin{bmatrix} 5 & 1 & -1 & 1 \\ 1 & 6 & 2 & -2 \\ -1 & 2 & 7 & 1 \\ 1 & -2 & 1 & 8 \end{bmatrix} \quad b := \begin{bmatrix} 6 \\ 7 \\ 9 \\ 8 \end{bmatrix} \quad \text{Vectorul de proba} \quad x := \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \end{bmatrix} \quad n := 4$$

Algoritmul metodei gradientilor conjugati

$$\text{GrCon}(A, b, x, n) := \left. \begin{array}{l} r^{<0>} \leftarrow A \cdot x - b \\ p \leftarrow -r^{<0>} \\ q \leftarrow \frac{r^{<0>} \cdot r^{<0>}}{A \cdot p \cdot p} \\ x \leftarrow x + q \cdot p \\ r^{<1>} \leftarrow r^{<0>} + q \cdot A \cdot p \\ \text{for } k \in 2..n \\ \quad \left. \begin{array}{l} c \leftarrow \frac{r^{<k-1>} \cdot r^{<k-1>}}{r^{<k-2>} \cdot r^{<k-2>}} \\ p \leftarrow -r^{<k-1>} + c \cdot p \\ q \leftarrow \frac{r^{<k-1>} \cdot r^{<k-1>}}{A \cdot p \cdot p} \\ x \leftarrow x + q \cdot p \\ r^{<k>} \leftarrow r^{<k-1>} + q \cdot A \cdot p \end{array} \right\} \\ x \end{array} \right|$$

Apelarea programului si afisarea rezultatelor

$$\text{GrCon}(A, b, x, n) = \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \end{bmatrix}$$

Teorema 1. În metoda gradientilor conjugați direcțiile de relaxare $p^{(k)}$, ($k=1,2,\dots$) sunt conjugate două câte două în raport cu matricea A , iar vectorii reziduali $r^{(k)}$, ($k=0,1,\dots$) sunt ortogonali doi câte doi.

Demonstrație.

Demonstrația se face prin inducție relativ la k . Pentru $k=1$ avem $\langle r^{(1)}, r^{(0)} \rangle = 0$

din (4), iar pentru prima afirmație nu avem ce arăta. Ipoteza de inducție este:

$$\langle r^{(i)}, r^{(j)} \rangle = 0 \quad \text{pentru } i \neq j, \quad 0 \leq i, j \leq k, \quad (15)$$

$$\langle p^{(i)}, Ap^{(j)} \rangle = 0 \quad \text{pentru } i \neq j, \quad 1 \leq i \leq j \leq k. \quad (16)$$

Va trebui să arătăm că

$$\langle r^{(k+1)}, r^{(j)} \rangle = 0, \quad \text{pentru } j = \overline{0, k} \quad (17)$$

$$\langle p^{(k+1)}, Ap^{(j)} \rangle = 0, \quad \text{pentru } j = \overline{1, k}. \quad (18)$$

Fie $j=k$, atunci

$$\langle p^{(k+1)}, Ap^{(k)} \rangle = \langle Ap^{(k+1)}, p^{(k)} \rangle = 0$$

deoarece $p^{(k)}$ și $p^{(k+1)}$ sunt A -conjugate.

Fie $1 \leq j < k$, atunci

$$\langle p^{(k+1)}, Ap^{(j)} \rangle = \langle -r^{(k)} + c_k p^{(k)}, Ap^{(j)} \rangle = -\langle r^{(k)}, Ap^{(j)} \rangle,$$

deoarece $\langle p^{(k)}, Ap^{(j)} \rangle = 0$ conform ipotezei (16).

Pe de altă parte,

$$Ap^{(j)} = \frac{1}{q_j} (r^{(j)} - r^{(j-1)})$$

și din (15) rezultă $\langle r^{(k)}, Ap^{(j)} \rangle = 0$.

Așadar am demonstrat (18).

Pentru $j=k$, (17) este adevărată din (12).

Fie $0 \leq j < k$. Din (11) și (15) rezultă:

$$\begin{aligned} \langle r^{(k+1)}, r^{(j)} \rangle &= \langle r^{(k)} + q_{k+1} Ap^{(k+1)}, r^{(j)} \rangle = q_{k+1} \langle Ap^{(k+1)}, r^{(j)} \rangle = \\ &= q_{k+1} \langle Ap^{(k+1)}, -p^{(j)} + c_{j-1} p^{(j-1)} \rangle \end{aligned}$$

Ținând seama de (18) și de faptul că A este simetrică, rezultă $\langle r^{(k+1)}, r^{(j)} \rangle = 0$ și cu aceasta teorema este demonstrată. \square

Din Teorema 1 rezultă că vectorii reziduali $r^{(k)}$ sunt ortogonali doi câte doi și deci sunt liniar independenți (dacă sunt nenuli). Așadar, nu pot exista $(n+1)$ vectori reziduali nenuli. Rezultă că în metoda gradientilor conjugați soluția exactă

se găsește în cel mult n pași. Teoretic ar trebui ca vectorul rezidual $r^{(n)}$ să fie zero și deci $v=v^{(n)}$ să fie soluția exactă a sistemului.

În practică acest lucru nu se întâmplă, deoarece în determinarea vectorilor $r^{(k)}$ intervin erori de calcul, care fac ca aceștia să nu formeze un sistem ortogonal. Deoarece în general $r^{(n)} \neq 0$, continuăm să calculăm $r^{(k)}$, $k > n$ până obținem un vector rezidual nul sau foarte mic ($\|r^{(k)}\| \ll 1$). Această atitudine se justifică prin faptul că metoda gradientilor conjugați este o metodă de relaxare prin care valoarea funcției pătratică $F=F(v)$ se micșorează la fiecare pas.

Metoda gradientilor conjugați se dovedește foarte utilă pentru sistemele în care matricea A are multe zerouri și fiecare ecuație are o anumită regularitate internă.

Astfel de sisteme apar în procesul de discretizare a problemei la limită a ecuațiilor cu derivate parțiale de tip eliptic.

§1.13. Metoda celor mai mici pătrate

În procesul de prelucrare și ajustare a datelor, apar sisteme de ecuații liniare supradimensionate sau subdimensionate. Abordăm pentru început problema sistemelor supradimensionate. Fie sistemul

$$\begin{cases} a_{11}x_1 + \dots + a_{1n}x_n = b_1 \\ \dots \\ a_{m1}x_1 + \dots + a_{mn}x_n = b_m \end{cases}, \quad m > n. \quad (1)$$

Evident, un asemenea sistem poate să nu aibă soluție. Fie

$$r = Ax - b = (r_1, r_2, \dots, r_m)^T \quad (2)$$

vectorul rezidual, unde

$$r_i = a_{i1}x_1 + \dots + a_{in}x_n - b_i, \quad i = \overline{1, m}.$$

Considerăm funcția pătratică

$$f(x) = f(x_1, \dots, x_n) = \langle r, r \rangle = r_1^2 + r_2^2 + \dots + r_m^2 \quad (3)$$

Definiția 1. Se numește soluție în sensul celor mai mici pătrate a sistemului (1), acel vector x^* , pentru care funcția (2) are valoarea minimă.

Dacă: $\min_{x \in \mathbb{R}^n} f(x) = f(x^*) = 0$, atunci $r_i(x^*) = 0$, pentru orice $i = \overline{1, m}$. Rezultă că sistemul (1) este compatibil și $x=x^*$ este soluția exactă a sa.

În general, sistemul (1) nu este compatibil și $\min_{x \in \mathbb{R}^n} f(x) = f(x^*) > 0$, iar $x = x^*$ este un substitut pentru soluția sistemului și anume soluția în sensul celor mai mici pătrate.

Funcția f se poate pune sub forma

$$f(x) = \langle r, r \rangle = \langle Ax - b, Ax - b \rangle = \langle Ax, Ax \rangle - 2\langle Ax, b \rangle + \langle b, b \rangle$$

și mai departe

$$f(x) = \langle A^T Ax, x \rangle - 2\langle A^T b, x \rangle + \langle b, b \rangle \quad (4)$$

Teorema 1. Dacă $\text{rang} A = n$, atunci sistemul (1) admite o singură soluție în sensul celor mai mici pătrate și aceasta este soluția (unică) a sistemului.

$$A^T Ax = A^T b \quad (5)$$

(Sistemul (5) se numește sistemul normal al lui Gauss).

Demonstrație.

Punctele de extrem ale funcției pătratice f dată de (4), se caută printre punctele sale critice, iar acestea, se află rezolvând sistemul:

$$\text{grad } f = 0$$

Cum $\text{grad } f = A^T Ax - A^T b$, obținem sistemul $A^T Ax = A^T b$. Pe de altă parte se știe că:

$$\text{rang } A = \text{rang } A^T = \text{rang} \begin{pmatrix} A^T & A \end{pmatrix} = \text{rang} \begin{pmatrix} A & A^T \end{pmatrix}.$$

Matricea $B = A^T A$ este o matrice pătratică de ordinul n și $\text{rang } B = n$, conform celor de mai sus. Rezultă că sistemul (5) admite o soluție unică, $x = x^*$, care este punct critic pentru f .

Matricea B este evident simetrică și semipozitiv definită. Mai mult, în ipoteza noastră, matricea B este pozitiv definită. Într-adevăr, dacă presupunem că $\langle Bx, x \rangle = 0$, atunci rezultă $\langle Ax, Ax \rangle = 0$ și deci $Ax = 0$. Cum $\text{rang } A = n < m$ rezultă $x = 0$.

Pe de altă parte avem

$$d^2 f(x) = \sum_{i=1}^n \sum_{j=1}^n b_{ij} dx_i dx_j > 0,$$

de unde rezultă că $x = x^*$ este punct de minim pentru f și cu aceasta teorema este demonstrată. \square

Așadar, în ipoteza $\text{rang } A = n$, soluția sistemului (1), în sensul celor mai mici pătrate, este unică și se află rezolvând sistemul (5). Acest sistem este simetric pozitiv definit. Rezolvarea sa se poate face prin metoda Cholesky sau una din metodele de relaxare.

Observația 1. Teoretic, soluția sistemului (5) este $x^* = (A^T A)^{-1} A^T b$. Matricea $P = (A^T A)^{-1} A^T$ se numește pseudoinversa matricei (dreptunghiulară) A .

Se observă că dacă A este pătratică, atunci $P=A^{-1}(A^T)^{-1}A^T=A^{-1}$, deci noțiunea de matrice pseudoinversă generalizează noțiunea de matrice inversă (pentru matrice dreptunghiulare).

Rezolvarea practică a sistemului (5) ridică probleme din cauza faptului că numărul de condiționare al matricei $B=A^T A$ este mare. Fie $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n > 0$ valorile proprii ale matricei B . Atunci:

$$\text{cond}(B) = \frac{\lambda_1}{\lambda_n} . \quad (6)$$

Cum

$$\lambda_1 = \sup_{x \neq 0} \frac{\langle Bx, x \rangle}{\langle x, x \rangle} \geq \max_i \langle B e_i, e_i \rangle = \max_i b_{ii} \quad \text{și} \quad \lambda_n = \inf_{x \neq 0} \frac{\langle Bx, x \rangle}{\langle x, x \rangle} \leq \min_i \langle B e_i, e_i \rangle = \min_i b_{ii} ,$$

rezultă

$$\text{cond}(B) \geq \frac{\max b_{ii}}{\min b_{ii}} . \quad (7)$$

Exemplul 1. (Dreapta de regresie)

Să presupunem că vrem să găsim o dreaptă $y=mx+n$ care să treacă prin punctele:

$$M_1(0,0) ; M_2(2,1) ; M_3(5,3) ; M_4(8,5) ; M_6(10,6)$$

Se obține astfel sistemul

$$\begin{cases} 0 \cdot m + n = 0 \\ 2 \cdot m + n = 1 \\ 5 \cdot m + n = 3 \\ 8 \cdot m + n = 5 \\ 10 \cdot m + n = 6 \end{cases} . \quad (8)$$

Evident, sistemul (8) este supradimensionat și incompatibil. Avem:

$$A = \begin{pmatrix} 0 & 1 \\ 2 & 1 \\ 5 & 1 \\ 8 & 1 \\ 10 & 1 \end{pmatrix} ; b = \begin{pmatrix} 0 \\ 1 \\ 3 \\ 5 \\ 6 \end{pmatrix} ; B = A^T A = \begin{pmatrix} 193 & 25 \\ 25 & 5 \end{pmatrix} ; A^T b = \begin{pmatrix} 117 \\ 15 \end{pmatrix} .$$

Ecuțiile normale ale lui Gauss sunt

$$\begin{cases} 193m + 25n = 117 \\ 25m + 5n = 15 \end{cases} .$$

Soluția exactă este $m = \frac{21}{34}, n = -\frac{3}{34}$, iar valorile proprii sunt $\lambda_1 = 196.268$ și

$\lambda_2 = 1.732$. Rezultă $\text{cond}(B) \cong 113$. Dacă folosim estimarea (7) obținem

Revenind la cazul general, se pune problema să determinăm n necunoscute x_1, x_2, \dots, x_n care satisfac legăturile (9) și care minimizează funcția:

$$f(x_1, \dots, x_n) = (x_1 - l_1)^2 + \dots + (x_n - l_n)^2 .$$

Considerăm funcția auxiliară

$$\begin{aligned} \Phi(x_1, \dots, x_n, \lambda_1, \dots, \lambda_m) &= (x_1 - l_1)^2 + \dots + (x_n - l_n)^2 - \\ &- 2\lambda_1(a_{11}x_1 + \dots + a_{1n}x_n - b_1) \dots - 2\lambda_m(a_{m1}x_1 + \dots + a_{mn}x_n - b_m) \end{aligned}$$

Punctele critice ale funcției ϕ sunt date de sistemul

$$\begin{cases} x_1 - l_1 - (a_{11}\lambda_1 + \dots + a_{m1}\lambda_m) = 0 \\ \dots \\ x_n - l_n - (a_{1n}\lambda_1 + \dots + a_{mn}\lambda_m) = 0 \\ a_{11}x_1 + \dots + a_{1n}x_n - b_1 = 0 \\ \dots \\ a_{m1}x_1 + \dots + a_{mn}x_n - b_m = 0 \end{cases} \quad (10)$$

Dacă notăm cu $l = (l_1, \dots, l_n)^T$ și cu $\lambda = (\lambda_1, \dots, \lambda_m)^T$, atunci sistemul (10) se scrie sub forma matricială

$$x = A^T \lambda + l \quad (10')$$

$$Ax = b \quad (10'')$$

Înlocuind (10') în (10'') obținem sistemul

$$AA^T \lambda = b - Al \quad (11)$$

Dacă $\text{rang } A = m$, atunci $\text{rang}(AA^T) = m$ și sistemul (11) are soluție unică. Mai mult, matricea AA^T este pătratică, simetrică și pozitiv definită, deci rezolvarea sistemului (11) se poate face cu metoda Cholesky sau una din metodele de relaxare. Rezolvând sistemul (11) găsim multiplicatorii lui Lagrange $\lambda_1, \dots, \lambda_m$, iar din relația $x = A^T \lambda + l$ determinăm punctul de minim condiționat al funcției f . (Cum $d^2 \phi = 2(dx_1^2 + \dots + dx_n^2) > 0$ rezultă că avem într-adevăr un punct de minim).

Exerciții

Folosind metoda Gauss să se rezolve următoarele sisteme de ecuații liniare:

$$1. \begin{cases} 6x_1 + x_2 - x_3 + x_4 = 2 \\ x_1 + 7x_2 + 2x_3 - x_4 = -1 \\ -x_1 + 2x_2 + 8x_3 + x_4 = 12 \\ x_1 - x_2 + x_3 + 9x_4 = -5 \end{cases}$$

$$R. \text{ Matricea triunghiulară } \tilde{A} = \begin{pmatrix} 1.0 & 0.1667 & -0.1667 & 0.1667 \\ 0 & 1.0 & 0.3171 & -0.1707 \\ 0 & 0 & 1.0 & 0.2150 \\ 0 & 0 & 0 & 1.0 \end{pmatrix},$$

$$\text{vectorul termenilor liberi transformat } \tilde{b} = \begin{pmatrix} 0.333 \\ -0.1951 \\ 1.7850 \\ -1.0 \end{pmatrix}.$$

$$\text{Soluția sistemului } x = \begin{pmatrix} 1 \\ -1 \\ 2 \\ -1 \end{pmatrix}.$$

$$2. \begin{cases} 4x_1 + x_2 - x_3 + x_4 = 1 \\ x_1 + 8x_2 + x_3 + x_4 = 7 \\ x_1 + x_2 + 6x_3 + x_4 = -10 \\ x_1 + x_2 + x_3 + 7x_4 = 12 \end{cases}$$

$$R. \text{ Matricea triunghiulară } \tilde{A} = \begin{pmatrix} 1.0 & 0.2500 & -0.2500 & 0.2500 \\ 0 & 1.0 & 0.1613 & 0.0968 \\ 0 & 0 & 1.0 & 0.1105 \\ 0 & 0 & 0 & 1.0 \end{pmatrix},$$

$$\text{vectorul termenilor liberi transformat } \tilde{b} = \begin{pmatrix} 0.2500 \\ 0.8710 \\ -1.7789 \\ 2.0 \end{pmatrix}.$$

$$\text{Soluția sistemului } x = (-1 \ 1 \ -2 \ 2)'$$

$$3. \quad \begin{cases} 5x_1 + x_2 + x_3 + x_4 = 14 \\ x_1 + 8x_2 + 2x_3 + x_4 = 127 \\ -x_1 + x_2 + 6x_3 - x_4 = 15 \\ x_1 + x_2 + x_3 + x_4 = 10 \end{cases}$$

$$R. \text{ Matricea triunghiulară } \tilde{A} = \begin{pmatrix} 1.0 & 0.2000 & -0.2000 & 0.2000 \\ 0 & 1.0 & 0.2308 & 0.1026 \\ 0 & 0 & 1.0 & -0.1558 \\ 0 & 0 & 0 & 1.0 \end{pmatrix},$$

$$\text{vectorul termenilor liberi transformat } \tilde{b} = \begin{pmatrix} 2.8000 \\ 3.1026 \\ 2.3766 \\ 4.0 \end{pmatrix}.$$

Soluția sistemului $x = (1 \ 2 \ 3 \ 4)'$.

Să se rezolve următoarele sisteme de ecuații liniare folosind metoda Cholesky:

$$4. \quad \begin{cases} 10x_1 + x_2 - x_3 - x_4 = 9 \\ x_1 + 9x_2 + x_3 - x_4 = -6 \\ -x_1 + x_2 + 11x_3 + x_4 = 8 \\ -x_1 - x_2 + x_3 + 8x_4 = -7 \end{cases}$$

$$R. \quad R^T = \begin{pmatrix} 3.1623 & 0 & 0 & 0 \\ 0.3162 & 2.9833 & 0 & 0 \\ -0.3162 & 0.3687 & 0.32809 & 0 \\ -0.3162 & -0.3017 & 0.3082 & 2.7774 \end{pmatrix}. \quad \text{Soluția sistemului}$$

$$R^T y = b \quad \text{este} \quad y = \begin{pmatrix} 2.846 \\ -2.3129 \\ 2.9726 \\ -2.7774 \end{pmatrix}, \quad \text{iar cea a sistemului } Rx=y, \quad \text{și deci soluția}$$

$$\text{sistemului inițial este } x = \begin{pmatrix} 1 \\ -1 \\ 1 \\ -1 \end{pmatrix}.$$

$$5. \quad \begin{cases} 8x_1 - x_2 - x_3 + x_4 & = 7 \\ -x_1 + 6x_2 + x_3 - 2x_4 & = 6 \\ -x_1 + x_2 + 7x_3 + x_4 & = -8 \\ x_1 - 2x_2 + x_3 + 9x_4 & = -11 \end{cases}$$

$$R. \quad R^T = \begin{pmatrix} 2.82843 & 0 & 0 & 0 \\ -0.35355 & 2.42384 & 0 & 0 \\ -0.35355 & 0.361 & 2.59705 & 0 \\ 0.35355 & -0.77357 & 0.54071 & 2.82564 \end{pmatrix}.$$

Soluția sistemului $R^T y = b$ este $y = \begin{pmatrix} 2.47487 \\ 2.83641 \\ -3.13776 \\ -2.82564 \end{pmatrix}$ iar cea a sistemului $Rx = y$, și

deci soluția sistemului inițial este $x = \begin{pmatrix} 1 \\ 1 \\ -1 \\ -1 \end{pmatrix}$.

$$6. \quad \begin{cases} 6x_1 + x_2 - 2x_3 - x_4 & = 19 \\ x_1 + 5x_2 + x_3 - x_4 & = 15 \\ -2x_1 + x_2 + 11x_3 - x_4 & = 8 \\ -x_1 - x_2 - x_3 + 4x_4 & = -10 \end{cases}$$

$$R. \quad R^T = \begin{pmatrix} 2.44949 & 0 & 0 & 0 \\ 0.40825 & 2.19848 & 0 & 0 \\ -0.8165 & 0.60648 & 3.15682 & 0 \\ -0.40825 & -0.37905 & -0.34954 & 1.88878 \end{pmatrix}.$$

Soluția sistemului $R^T y = b$ este $y = \begin{pmatrix} 7.75672 \\ 5.3825 \\ 3.50636 \\ -1.88878 \end{pmatrix}$, iar cea a sistemului $Rx = y$, și

deci soluția sistemului inițial este $x = (3 \ 2 \ 1 \ -1)'$.

Folosind metoda Householder, să se rezolve sistemele:

$$7. \begin{cases} 4x_1 + 3x_2 - 2x_3 + x_4 = 2 \\ 5x_1 + 6x_2 + 7x_3 - 8x_4 = -14 \\ 9x_1 - 8x_2 + 7x_3 - 6x_4 = -30 \\ x_1 + x_2 - x_3 - x_4 = 0 \end{cases}$$

R. $\det(A) = -1112$; descompunerea $A = QR$ este dată de

$$Q = \begin{pmatrix} 0.3607 & -0.3882 & 0.7877 & -0.3143 \\ 0.4508 & -0.7068 & -0.5445 & 0.0257 \\ 0.8115 & 0.5787 & -0.0784 & 0.02 \\ 0.0902 & -0.1217 & 0.2774 & 0.9487 \end{pmatrix},$$

$$R = \begin{pmatrix} 110905 & -26148 & 80249 & -80249 \\ 0 & -101569 & 0.0016 & 1.9155 \\ 0 & 0 & -6.2130 & 5.83368 \\ 0 & 0 & 0 & -1.58889 \end{pmatrix}.$$

Soluția sistemului $Qy = b$ este $y = \begin{pmatrix} 299354 \\ -8.2430 \\ 11.5498 \\ -1.5888 \end{pmatrix},$

iar cea sistemului $Rx = y$ este $x = (-1 \ 1 \ -1 \ 1)'$.

$$8. \begin{cases} x_1 + 2x_2 - 3x_3 - 4x_4 = 16 \\ 5x_1 - 6x_2 + 7x_3 - 8x_4 = 2 \\ 9x_1 + 8x_2 + 7x_3 + 6x_4 = 6 \\ 4x_1 - 3x_2 + 2x_3 - x_4 = -2 \end{cases}$$

R. $\det(A) = -2808$; descompunerea $A = QR$ este dată

$$Q = \begin{pmatrix} 0.09017 & 0.17005 & 0.78843 & -0.58424 \\ 0.45083 & -0.71359 & -0.2494 & -0.47469 \\ 0.8115 & 0.55307 & -0.18504 & 0.03651 \\ 0.36067 & -0.39494 & 0.53098 & 0.65727 \end{pmatrix},$$

$$R = \begin{pmatrix} 1109054 & 2.88534 & 9.2872 & 0.541 \\ 0 & 10.23107 & -2.42367 & 8.7419 \\ 0 & 0 & -4.3444 & -2.79972 \\ 0 & 0 & 0 & 5.69631 \end{pmatrix}.$$

Soluția sistemului $Qy=b$ este $y = \begin{pmatrix} 6.49202 \\ 5.40201 \\ 9.94384 \\ -11.39263 \end{pmatrix}$,

iar cea sistemului $Rx=y$ este $x = \begin{pmatrix} 1 \\ 2 \\ -1 \\ -2 \end{pmatrix}$.

9.
$$\begin{cases} 4x_1 + 3x_2 + 2x_3 + x_4 = 2 \\ x_1 + 2x_2 + 3x_3 + 4x_4 = -2 \\ 9x_1 - 8x_2 + 6x_3 - 7x_4 = 30 \\ x_1 - x_2 + x_3 - x_4 = 4 \end{cases}$$

R. $\det(A) = -80$; descompunerea $A=QR$ este dată de

$$Q = \begin{pmatrix} 0.40202 & -0.82257 & 0.3961 & 0.0697 \\ 0.1005 & -0.39663 & -0.90448 & -0.12039 \\ 0.90453 & 0.4028 & -0.05925 & -0.12673 \\ 0.1005 & 0.06173 & -0.14663 & 0.98213 \end{pmatrix},$$

$$R = \begin{pmatrix} 9.94987 & -5.92972 & 6.63325 & -5.62821 \\ 0 & -6.5451 & -0.3565 & -5.29041 \\ 0 & 0 & -2.42341 & -2.66043 \\ 0 & 0 & 0 & -0.50691 \end{pmatrix}.$$

Soluția sistemului $Qy=b$ este $y = \begin{pmatrix} 28.14106 \\ 11.47901 \\ 0.23702 \\ 0.50691 \end{pmatrix}$,

iar cea sistemului $Rx=y$ este $x = \begin{pmatrix} 1 \\ -1 \\ 1 \\ -1 \end{pmatrix}$.

10. Pentru matricea $A = \begin{pmatrix} 1 & 2 & 1 & -1 \\ 2 & 1 & -1 & 3 \\ 2 & 1 & -1 & 1 \\ 1 & -1 & -1 & 1 \end{pmatrix}$, să se calculeze:

- a) $\det(A)$, A^{-1} , $\det(A^{-1})$;
 b) $\|A\|_1$, $\|A\|_2$, $\|A\|_\infty$; $\|A^{-1}\|_1$, $\|A^{-1}\|_2$, $\|A^{-1}\|_\infty$;
 c) $\text{cond}_1(A)$, $\text{cond}_2(A)$, $\text{cond}_\infty(A)$.

R. a) $\det(A)=6$, $A^{-1} = \begin{pmatrix} 0.6667 & 0 & -0.3333 & 1 \\ -0.3333 & 0 & 0.6667 & -1 \\ 1 & 0.5 & -1.5 & 1 \\ 0 & 0.5 & -0.5 & 0 \end{pmatrix}$,

$\det(A^{-1})=-0.1667$;

- b) $\begin{cases} \|A\|_1 = 6, \|A\|_2 = 5.7446, \|A\|_\infty = 7; \\ \|A^{-1}\|_1 = 3, \|A^{-1}\|_2 = 2.848, \|A^{-1}\|_\infty = 4. \end{cases}$
 c) $\text{cond}_1(A)=18$, $\text{cond}_2(A)=12.7511$, $\text{cond}_\infty(A)=28$.

11. Să se calculeze:

- a) $\det(A)$, A^{-1} , $\det(A^{-1})$;
 b) $\|A\|_1$, $\|A\|_2$, $\|A\|_\infty$; $\|A^{-1}\|_1$, $\|A^{-1}\|_2$, $\|A^{-1}\|_\infty$;
 c) $\text{cond}_1(A)$, $\text{cond}_2(A)$, $\text{cond}_\infty(A)$

pentru matricea $A = \begin{pmatrix} 4 & -1 & 5 \\ 3 & 2 & -2 \\ 6 & 1 & 3 \end{pmatrix}$.

R. a) $\det(A)=8$, $A^{-1} = \begin{pmatrix} 1 & 1 & -1 \\ -2.625 & -2.25 & 2.875 \\ -1.125 & -1.25 & 1.375 \end{pmatrix}$, $\det(A^{-1})=0.125$;

- b) $\begin{cases} \|A\|_1 = 6, \|A\|_2 = 5.7446, \|A\|_\infty = 7; \\ \|A^{-1}\|_1 = 3, \|A^{-1}\|_2 = 2.848, \|A^{-1}\|_\infty = 4. \end{cases}$

- c) $\text{cond}_1(A)=68.25$, $\text{cond}_2(A)=48.28525$, $\text{cond}_\infty(A)=77.5$.

Folosind metoda Iacobi să se găsească soluția aproximativă pentru următoarele sisteme de ecuații liniare :

$$12. \begin{cases} 5x_1 - x_2 - x_3 = 5 \\ x_1 + 6x_2 + x_3 = -4 \\ x_1 - x_2 + 7x_3 = 9 \end{cases}$$

R. Sistemul se poate pune sub forma $x = Bx + c$, unde $B = D^{-1} \cdot (D - A)$, iar $D =$

$$\begin{pmatrix} 5 & 0 & 0 \\ 0 & 6 & 0 \\ 0 & 0 & 7 \end{pmatrix}, \quad E = D - A = \begin{pmatrix} 0 & 1 & 1 \\ -1 & 0 & -1 \\ -1 & 1 & 0 \end{pmatrix},$$

$$B = \begin{pmatrix} 0 & 0.2 & 0.2 \\ -0.16667 & 0 & -0.16667 \\ -0.14286 & 0.14286 & 0 \end{pmatrix}, \quad c = D^{-1} \cdot b = \begin{pmatrix} 1 \\ -0.66667 \\ 1.28571 \end{pmatrix}, \quad \|B\|_2 = 0.41997,$$

$\rho(B) = 0.29277$. Soluția la fiecare iterație, pornind cu $x^{(0)} = \begin{pmatrix} 0 \\ 0 \\ 0 \end{pmatrix}$, este:

$$x^{(1)} = \begin{pmatrix} 1 \\ -0.66667 \\ 1.28571 \end{pmatrix}, \quad x^{(2)} = \begin{pmatrix} 1.12381 \\ -1.04762 \\ 1.04762 \end{pmatrix},$$

$$x^{(3)} = \begin{pmatrix} 1 \\ -1.02857 \\ 0.97551 \end{pmatrix}, \quad x^{(4)} = \begin{pmatrix} 0.98939 \\ -0.99592 \\ 0.99592 \end{pmatrix}.$$

Soluția exactă fiind $x^* = \begin{pmatrix} 1 \\ -1 \\ 1 \end{pmatrix}$, eroarea care se face dacă se reține ca soluție

aproximativă $x^{(4)}$, este $\|x^* - x^{(4)}\| = 0.01208$.

$$13. \begin{cases} 6x_1 + x_2 - x_3 + x_4 = 2 \\ x_1 + 7x_2 + x_3 - x_4 = -4 \\ x_1 + 2x_2 + 8x_3 + x_4 = 6 \\ x_1 + x_2 + x_3 + 9x_4 = -8 \end{cases} \quad (\text{să se scrie soluția obținută după patru}$$

iterații).

R. Se poate pune sistemul sub forma $x = Bx + c$, unde $B = D^{-1} \cdot E$, iar

$$D = \begin{pmatrix} 6 & 0 & 0 & 0 \\ 0 & 7 & 0 & 0 \\ 0 & 0 & 8 & 0 \\ 0 & 0 & 0 & 9 \end{pmatrix}, \quad E = D - A = \begin{pmatrix} 0 & -1 & 1 & 2 \\ -1 & 0 & -1 & 1 \\ -1 & -2 & 0 & -1 \\ 1 & 1 & 1 & 0 \end{pmatrix},$$

$$B = \begin{pmatrix} 0 & -0.16667 & 0.16667 & -0.33333 \\ -0.14286 & 0 & -0.14286 & 0.14286 \\ -0.125 & -0.25 & 0 & -0.125 \\ -0.11111 & -0.11111 & -0.11111 & 0 \end{pmatrix},$$

$$c = D^{-1} \cdot b = \begin{pmatrix} 0.33333 \\ -0.57143 \\ 0.75 \\ -0.88889 \end{pmatrix}, \quad \|B\|_2 = 0.5989, \quad \rho(B) = 0.27926. \quad \text{Soluția pentru primele}$$

$$4 \text{ iterații, pornind cu } x^{(0)} = \begin{pmatrix} 0 \\ 0 \\ 0 \\ 0 \end{pmatrix}, \text{ este: } x^{(1)} = \begin{pmatrix} 0.33333 \\ -0.57143 \\ 0.75 \\ -0.88889 \end{pmatrix},$$

$$x^{(2)} = \begin{pmatrix} 0.84987 \\ -0.85317 \\ 0.9623 \\ -0.94577 \end{pmatrix}, \quad x^{(3)} = \begin{pmatrix} 0.95117 \\ -0.96542 \\ 0.97528 \\ -0.99544 \end{pmatrix}, \quad x^{(4)} = \begin{pmatrix} 0.9886 \\ -0.98884 \\ 0.99689 \\ -0.99567 \end{pmatrix}.$$

$$\text{Soluția exactă fiind } x^* = \begin{pmatrix} 1 \\ -1 \\ 1 \\ -1 \end{pmatrix}, \text{ eroarea care se face dacă se reține ca soluție}$$

$$\text{aproximativă } x^{(4)}, \text{ este } \|x^* - x^{(4)}\| = 0.01682.$$

$$14. \quad \begin{cases} 4x_1 - x_2 - x_3 + x_4 = 3 \\ x_1 + 7x_2 + x_3 - x_4 = 14 \\ x_1 - x_2 + 6x_3 + x_4 = 21 \\ x_1 - x_2 - x_3 + 9x_4 = 38 \end{cases}$$

R. Se poate pune sistemul sub forma $x = Bx + c$, unde $B = D^{-1} \cdot E$, iar

$$D = \begin{pmatrix} 4 & 0 & 0 & 0 \\ 0 & 7 & 0 & 0 \\ 0 & 0 & 6 & 0 \\ 0 & 0 & 0 & 9 \end{pmatrix}, \quad E = D - A = \begin{pmatrix} 0 & 1 & 1 & -1 \\ -1 & 0 & -1 & 1 \\ -1 & 1 & 0 & -1 \\ -1 & 1 & -1 & 0 \end{pmatrix},$$

$$B = \begin{pmatrix} 0 & 0.25 & 0.25 & -0.25 \\ -0.14286 & 0 & -0.14286 & 0.14286 \\ -0.16667 & 0.16667 & 0 & -0.16667 \\ -0.11111 & 0.11111 & -0.11111 & 0 \end{pmatrix},$$

$$c = D^{-1} \cdot b = \begin{pmatrix} 0.75 \\ 2 \\ 3.5 \\ 4.22222 \end{pmatrix}, \quad \|B\|_2 = 0.60753, \quad \rho(B) = 0.22758. \text{ Pentru primele 4 iterații,}$$

pornind cu $x^{(0)} = \begin{pmatrix} 0 \\ 0 \\ 0 \\ 0 \end{pmatrix}$, soluția este: $x^{(1)} = \begin{pmatrix} 0.75 \\ 2 \\ 3.5 \\ 4.22222 \end{pmatrix}$,

$$x^{(2)} = \begin{pmatrix} 1.06944 \\ 1.99603 \\ 3.00463 \\ 3.97222 \end{pmatrix}, \quad x^{(3)} = \begin{pmatrix} 1.00711 \\ 1.98545 \\ 2.99239 \\ 3.99133 \end{pmatrix}, \quad x^{(4)} = \begin{pmatrix} 0.99663 \\ 1.99883 \\ 2.99784 \\ 3.99844 \end{pmatrix}.$$

Soluția exactă fiind $x^* = \begin{pmatrix} 1 \\ 2 \\ 3 \\ 4 \end{pmatrix}$, eroarea care se face dacă se reține ca soluție

aproximativă $x^{(4)}$, este $\|x^* - x^{(4)}\| = 0.00417$.

Să se rezolve cu metoda Gauss–Seidel următoarele sisteme:

$$15. \quad \begin{cases} 5x_1 - 2x_2 - 2x_3 = -3 \\ -x_1 + 6x_2 - x_3 = 2 \\ -x_1 - 3x_2 + 4x_3 = 8 \end{cases}$$

R. Se observă că matricea coeficienților sistemului $A = \begin{pmatrix} 5 & -2 & -2 \\ -1 & 6 & -1 \\ -1 & -3 & 4 \end{pmatrix}$ este tare

diagonal dominantă și atunci algoritmul Gauss–Seidel este convergent.

Sistemul se poate pune sub forma $x^{(m+1)} = (D+L)^{-1}(-Ux^{(m)}+b)$, $m \geq 0$, unde:

$$L = \begin{pmatrix} 0 & 0 & 0 \\ -1 & 0 & 0 \\ -1 & -3 & 0 \end{pmatrix}, \quad U = \begin{pmatrix} 0 & -2 & -2 \\ 0 & 0 & -1 \\ 0 & 0 & 0 \end{pmatrix}, \quad D = \begin{pmatrix} 5 & 0 & 0 \\ 0 & 6 & 0 \\ 0 & 0 & 4 \end{pmatrix}.$$

Atunci

$$(D+L)^{-1} = \begin{pmatrix} 0.2 & 0 & 0 \\ 0.03333 & 0.16667 & 0 \\ 0.075 & 0.125 & 0.25 \end{pmatrix},$$

$$-(D+L)^{-1}U = \begin{pmatrix} 0 & 0.4 & 0.4 \\ 0 & 0.06667 & 0.23333 \\ 0 & 0.15 & 0.275 \end{pmatrix},$$

$$(D+L)^{-1}b = \begin{pmatrix} -0.6 \\ 0.23333 \\ 2.025 \end{pmatrix}. \text{ Se obțin pornind cu } x^{(0)} = \begin{pmatrix} 0 \\ 0 \\ 0 \end{pmatrix}, \text{ vectorii:}$$

$$x^{(1)} = \begin{pmatrix} -0.6 \\ 0.23333 \\ 2.025 \end{pmatrix}, x^{(2)} = \begin{pmatrix} 0.30333 \\ 0.72139 \\ 2.61687 \end{pmatrix}, x^{(3)} = \begin{pmatrix} 0.73531 \\ 0.89203 \\ 2.85285 \end{pmatrix},$$

$$x^{(4)} = \begin{pmatrix} 0.89795 \\ 0.95847 \\ 2.94334 \end{pmatrix}.$$

$$16. \begin{cases} 6x_1 - x_2 - 2x_3 + x_4 & = 2 \\ 2x_1 + 6x_2 - x_3 - x_4 & = 8 \\ -x_1 - 3x_2 + 8x_3 + 2x_4 & = 2 \\ x_1 + x_2 + x_3 + 4x_4 & = -1 \end{cases}$$

R. Se observă că matricea coeficienților sistemului

$$A = \begin{pmatrix} 6 & -1 & -2 & 1 \\ 2 & 6 & -1 & -1 \\ -1 & -3 & 8 & 2 \\ 1 & 1 & 1 & 4 \end{pmatrix}$$

este tare diagonal dominantă și algoritmul Gauss–Seidel este convergent.

Sistemul se poate pune sub forma $x^{(m+1)} = (D+L)^{-1}(-Ux^{(m)}+b)$, $m \geq 0$, unde:

$$L = \begin{pmatrix} 0 & 0 & 0 & 0 \\ 2 & 0 & 0 & 0 \\ -1 & -3 & 0 & 0 \\ 1 & 1 & 1 & 0 \end{pmatrix}, U = \begin{pmatrix} 0 & -1 & -2 & 1 \\ 0 & 0 & -1 & -1 \\ 0 & 0 & 0 & 2 \\ 0 & 0 & 0 & 0 \end{pmatrix},$$

$$D = \begin{pmatrix} 6 & 0 & 0 & 0 \\ 0 & 6 & 0 & 0 \\ 0 & 0 & 8 & 0 \\ 0 & 0 & 0 & 4 \end{pmatrix} .$$

$$\text{Atunci } (D+L)^{-1} = \begin{pmatrix} 0.16667 & 0 & 0 & 0 \\ -0.05556 & 0.16667 & 0 & 0 \\ 0 & 0.0625 & 0.125 & 0 \\ -0.02778 & -0.05729 & -0.03125 & 0.25 \end{pmatrix} ,$$

$$-(D+L)^{-1}U = \begin{pmatrix} 0 & 0.16667 & 0.33333 & -0.16667 \\ 0 & -0.05556 & 0.05556 & 0.22222 \\ 0 & 0 & 0.0625 & -0.1875 \\ 0 & -0.02778 & -0.11285 & 0.03299 \end{pmatrix} ,$$

$$(D+L)^{-1}b = \begin{pmatrix} 0.33333 \\ 1.22222 \\ 0.75 \\ -0.82639 \end{pmatrix} .$$

$$\text{Alegând } x^{(0)} = \begin{pmatrix} 0 \\ 0 \\ 0 \\ 0 \end{pmatrix} , \text{ obținem: } x^{(1)} = \begin{pmatrix} 0.5 \\ 1 \\ 0.9375 \\ -0.85938 \end{pmatrix} , x^{(2)} = \begin{pmatrix} 0.95573 \\ 1.02778 \\ 0.96973 \\ -0.98831 \end{pmatrix} ,$$

$$x^{(3)} = \begin{pmatrix} 0.99259 \\ 0.99937 \\ 0.99592 \\ -0.99697 \end{pmatrix} , x^{(4)} = \begin{pmatrix} 0.99803 \\ 1.00048 \\ 0.99918 \\ -0.99942 \end{pmatrix} , x^{(5)} = \begin{pmatrix} 0.99971 \\ 1.00006 \\ 0.99984 \\ -0.9999 \end{pmatrix} .$$

$$17. \begin{cases} 10x_1 - x_2 - x_3 + x_4 & = 7 \\ x_1 + 11x_2 - x_3 - x_4 & = -10 \\ -x_1 - x_2 + 12x_3 + x_4 & = 22 \\ x_1 + x_2 + x_3 + 13x_4 & = -24 \end{cases}$$

R. Se observă că matricea coeficienților sistemului

$$A = \begin{pmatrix} 10 & -1 & -1 & 1 \\ 1 & 11 & -1 & -1 \\ -1 & -1 & 12 & 1 \\ 1 & 1 & 1 & 13 \end{pmatrix}$$

este tare diagonal dominantă și algoritmul Gauss–Seidel este convergent.

Sistemul se poate pune sub forma $x^{(m+1)} = (D+L)^{-1}(-Ux^{(m)} + b)$, $m \geq 0$, unde:

$$L = \begin{pmatrix} 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ -1 & -1 & 0 & 0 \\ 1 & 1 & 1 & 0 \end{pmatrix}, \quad U = \begin{pmatrix} 0 & -1 & -1 & 1 \\ 0 & 0 & -1 & -1 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 \end{pmatrix},$$

$$D = \begin{pmatrix} 10 & 0 & 0 & 0 \\ 0 & 11 & 0 & 0 \\ 0 & 0 & 12 & 0 \\ 0 & 0 & 0 & 13 \end{pmatrix}$$

Atunci

$$(D+L)^{-1} = \begin{pmatrix} 0.1 & 0 & 0 & 0 \\ -0.00909 & 0.09091 & 0 & 0 \\ 0.00758 & 0.00758 & 0.08333 & 0 \\ -0.00758 & -0.00758 & -0.00641 & 0.07692 \end{pmatrix},$$

$$-(D+L)^{-1}U = \begin{pmatrix} 0 & 0.1 & 0.1 & -0.1 \\ 0 & -0.00909 & 0.08182 & 0.1 \\ 0 & 0.00758 & 0.01515 & -0.08333 \\ 0 & -0.00758 & -0.01515 & 0.00641 \end{pmatrix},$$

$$(D+L)^{-1}b = \begin{pmatrix} 0.7 \\ -0.97273 \\ 1.81061 \\ -1.96445 \end{pmatrix}.$$

Alegând $x^{(0)} = \begin{pmatrix} 0 \\ 0 \\ 0 \\ 0 \end{pmatrix}$, obținem: $x^{(1)} = \begin{pmatrix} 0.7 \\ -0.97273 \\ 1.81061 \\ -1.96445 \end{pmatrix},$

$$x^{(2)} = \begin{pmatrix} 0.98023 \\ -1.01219 \\ 1.99437 \\ -1.99711 \end{pmatrix}, \quad x^{(3)} = \begin{pmatrix} 0.99793 \\ -1.00001 \\ 1.99958 \\ -1.99999 \end{pmatrix}, \quad x^{(4)} = \begin{pmatrix} 0.99993 \\ -1.00001 \\ 1.99998 \\ -1.99999 \end{pmatrix},$$

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

Folosind metoda relaxării simple să se scrie soluția aproximativă pentru următoarele sisteme:

$$18. \begin{cases} 8x_1 - x_2 + x_3 = 3 \\ -x_1 + 6x_2 - x_3 = 14 \\ x_1 - x_2 + 9x_3 = -28 \end{cases}$$

R. Matricea sistemului este $A = \begin{pmatrix} 8 & -1 & 1 \\ -1 & 6 & -1 \\ 1 & -1 & 9 \end{pmatrix}$.

Luând vectorul de probă $x^{(1)} = \begin{pmatrix} 0 \\ 0 \\ 0 \end{pmatrix}$ se obține $r^{(1)} = \begin{pmatrix} -3 \\ -14 \\ 28 \end{pmatrix}$, deci prima direcție

de relaxare este $p^{(1)} = e_3 = \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix}$. Rezultă $x^{(2)} = \begin{pmatrix} 0 \\ 0 \\ -3.111111 \end{pmatrix}$.

Analog :

$$r^{(2)} = \begin{pmatrix} -6.111111 \\ -10.888889 \\ 0 \end{pmatrix}, p^{(2)} = e_2 = \begin{pmatrix} 0 \\ 1 \\ 0 \end{pmatrix}, x^{(3)} = \begin{pmatrix} 0 \\ 1.81481 \\ -3.111111 \end{pmatrix};$$

$$r^{(3)} = \begin{pmatrix} -7.92593 \\ 0 \\ -1.81481 \end{pmatrix}, p^{(3)} = e_1 = \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix}, x^{(3)} = \begin{pmatrix} 0.99074 \\ 1.81481 \\ -3.111111 \end{pmatrix};$$

$$r^{(4)} = \begin{pmatrix} 0 \\ -0.99074 \\ -0.824070 \end{pmatrix}, p^{(4)} = e_2 = \begin{pmatrix} 0 \\ 1 \\ 0 \end{pmatrix}, x^{(4)} = \begin{pmatrix} 0.99074 \\ 1.91994 \\ -3.111111 \end{pmatrix}.$$

ș. a. m. d.

$$19. \begin{cases} 10x_1 + x_2 - x_3 - x_4 = 9 \\ x_1 + 9x_2 - x_3 + x_4 = -24 \\ -x_1 - x_2 + 11x_3 + x_4 = 30 \\ -x_1 + x_2 + x_3 + 8x_4 = -32 \end{cases}$$

R. Matricea sistemului este $A = \begin{pmatrix} 10 & 1 & -1 & -1 \\ 1 & 9 & -1 & 1 \\ -1 & -1 & 11 & 1 \\ -1 & 1 & 1 & 8 \end{pmatrix}$.

Alegând $x^{(1)} = \begin{pmatrix} 0 \\ 0 \\ 0 \\ 0 \end{pmatrix}$ se obține $r^{(1)} = \begin{pmatrix} -9 \\ 24 \\ -30 \\ 32 \end{pmatrix}$.

Deci $p^{(1)} = e_4 = \begin{pmatrix} 0 \\ 0 \\ 0 \\ 1 \end{pmatrix}$, $x^{(2)} = \begin{pmatrix} 0 \\ 0 \\ 0 \\ -4 \end{pmatrix}$, $r^{(2)} = \begin{pmatrix} -5 \\ 20 \\ -34 \\ 0 \end{pmatrix}$.

Mai departe obținem :

$$p^{(2)} = e_3 = \begin{pmatrix} 0 \\ 0 \\ 1 \\ 0 \end{pmatrix}, x^{(3)} = \begin{pmatrix} 0 \\ 0 \\ 3.090901 \\ -4 \end{pmatrix}; r^{(3)} = \begin{pmatrix} -8.09091 \\ 16.90909 \\ 0 \\ 3.09091 \end{pmatrix}, p^{(3)} = e_2 = \begin{pmatrix} 0 \\ 1 \\ 0 \\ 0 \end{pmatrix},$$

$$x^{(4)} = \begin{pmatrix} 0 \\ -1.87879 \\ 3.09091 \\ -4 \end{pmatrix}; p^{(4)} = e_1 = \begin{pmatrix} 1 \\ 0 \\ 0 \\ 0 \end{pmatrix}, x^{(5)} = \begin{pmatrix} 0.99697 \\ -1.87879 \\ 3.09091 \\ -4 \end{pmatrix}; r^{(5)} = \begin{pmatrix} 0 \\ 0.99697 \\ 0.88182 \\ 0.21515 \end{pmatrix}$$

$$, p^{(5)} = e_1 = \begin{pmatrix} 0 \\ 1 \\ 0 \\ 0 \end{pmatrix}, x^{(6)} = \begin{pmatrix} 0.99697 \\ -1.98956 \\ 3.09091 \\ -4 \end{pmatrix}.$$

$$20. \begin{cases} 4x_1 - 2x_2 + x_3 = 9 \\ -2x_1 + 6x_2 - x_3 = 5 \\ x_1 - x_2 + 5x_3 = 6 \end{cases}$$

R. Matricea $A = \begin{pmatrix} 4 & -2 & 1 \\ -2 & 6 & -1 \\ 1 & -1 & 5 \end{pmatrix}$ este simetrică, tare diagonal dominantă:

$|4| > |-2| + |1|$, $|6| > |-2| + |-1|$, $|5| > |1| + |-1|$, $\Delta_1=4$, $\Delta_2=20$, $\Delta_3=94$, deci pozitiv definită și se poate aplica metoda. Luând vectorul de probă

$$\begin{aligned}
 x^{(1)} &= \begin{pmatrix} 0 \\ 0 \\ 0 \end{pmatrix} \text{ se obțin: } r^{(1)} = \begin{pmatrix} -9 \\ -5 \\ -6 \end{pmatrix}, p^{(1)} = e_1 = \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix}, x^{(2)} = \begin{pmatrix} 2.25 \\ 0 \\ 0 \end{pmatrix}; \\
 r^{(2)} &= \begin{pmatrix} 0 \\ -9.5 \\ -3.75 \end{pmatrix}, \text{ este } p^{(2)} = e_2 = \begin{pmatrix} 0 \\ 1 \\ 0 \end{pmatrix}, x^{(3)} = \begin{pmatrix} 2.25 \\ 1.58333 \\ 0 \end{pmatrix}; r^{(3)} = \begin{pmatrix} -3.16667 \\ 0 \\ -5.33333 \end{pmatrix} \\
 , p^{(3)} &= e_3 = \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix}, x^{(3)} = \begin{pmatrix} 2.25 \\ 1.5833 \\ 1.06667 \end{pmatrix}; r^{(4)} = \begin{pmatrix} -2.1 \\ -1.06667 \\ 0 \end{pmatrix}, p^{(4)} = e_1 = \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix}, \\
 x^{(4)} &= \begin{pmatrix} 2.775 \\ 1.58333 \\ 1.06667 \end{pmatrix}.
 \end{aligned}$$

Să se scrie soluția aproximativă pentru următoarele sisteme de ecuații liniare obținută cu metoda suprarelaxării:

$$21. \begin{cases} 2x_1 - x_2 &= 3 \\ -x_1 + 3x_2 - x_3 &= -5 \\ -x_2 + 4x_3 &= 5 \end{cases}$$

R. Matricea coeficienților sistemului este bloc tridiagonală, simetrică și pozitiv definită, deci metoda suprarelaxării este convergentă. Sistemul se poate pune sub forma:

$$x^{(m+1)} = Mx^{(m)} + C, \quad m \geq 0, \text{ unde: } M = -\left(E + \frac{1}{\omega}D\right)^{-1} \cdot \left[F + \left(1 - \frac{1}{\omega}\right)D\right], \\
 C = \left(E + \frac{1}{\omega}\right)^{-1} \cdot b, \quad E = \begin{pmatrix} 0 & 0 & 0 \\ -1 & 0 & 0 \\ 0 & -1 & 0 \end{pmatrix}, \quad D = \begin{pmatrix} 2 & 0 & 0 \\ 0 & 3 & 0 \\ 0 & 0 & 4 \end{pmatrix}, \quad F = E^T,$$

$$\omega = \frac{2}{1 + \sqrt{1 - \lambda_1^2}}, \quad \lambda_1 \text{ fiind cea mai mare valoare proprie a matricei } -D^{-1}(E+F),$$

$\lambda_1 = 0.5$, $\omega = 1.0718$ și considerând vectorul inițial $x^{(0)} = b$, rezultă

$$x^{(1)} = \begin{pmatrix} -1.28719 \\ -0.10088 \\ 0.95373 \end{pmatrix}, \quad x^{(2)} = \begin{pmatrix} 1.64605 \\ -0.85027 \\ 1.04344 \end{pmatrix}, \quad x^{(3)} = \begin{pmatrix} 1.03385 \\ -0.98314 \\ 1.0014 \end{pmatrix},$$

$$x^{(4)} = \begin{pmatrix} 1.00661 \\ -0.99835 \\ 1.00034 \end{pmatrix}.$$

$$22. \quad \begin{cases} 14x_1 + x_2 & = 13 \\ x_1 + 5x_2 - x_3 & = -3 \\ -x_2 + 14x_3 - 2x_4 & = -15 \\ -2x_3 + 5x_4 & = 7 \end{cases}$$

R. Matricea coeficienților sistemului este bloc tridiagonală, simetrică și pozitiv definită, deci metoda suprarelaxării este convergentă. Sistemul se poate pune sub forma

$$x^{(m+1)} = Mx^{(m)} + C, \quad m \geq 0, \quad \text{unde} \quad M = -\left(E + \frac{1}{\omega}D\right)^{-1} \cdot \left[F + \left(1 - \frac{1}{\omega}\right)D\right],$$

$$C = \left(E + \frac{1}{\omega}\right)^{-1} \cdot b, \quad E = \begin{pmatrix} 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 0 & -1 & 0 & 0 \\ 0 & 0 & -2 & 0 \end{pmatrix}, \quad D = \begin{pmatrix} 14 & 0 & 0 & 0 \\ 0 & 5 & 0 & 0 \\ 0 & 0 & 14 & 0 \\ 0 & 0 & 0 & 5 \end{pmatrix}, \quad F = E^T,$$

$$\omega = \frac{2}{1 + \sqrt{1 - \lambda_1^2}}, \quad \lambda_1 \text{ fiind cea mai mare valoare proprie a matricei } -D^{-1}(E+F),$$

$\lambda_1 = 0.2735$, $\omega = 1.01943$ și considerând vectorul inițial $x^{(0)} = b$, rezultă:

$$x^{(1)} = \begin{pmatrix} 0.91242 \\ -3.79769 \\ -0.05784 \\ 1.26758 \end{pmatrix}, \quad x^{(2)} = \begin{pmatrix} 1.20542 \\ -0.79542 \\ -0.96444 \\ 1.0093 \end{pmatrix}, \quad x^{(3)} = \begin{pmatrix} 0.98111 \\ -0.99288 \\ -0.99882 \\ 1.0003 \end{pmatrix},$$

$$x^{(4)} = \begin{pmatrix} 0.99985 \\ -0.99987 \\ -0.99997 \\ 1.00001 \end{pmatrix}, \quad x^{(5)} = \begin{pmatrix} 0.99999 \\ -0.99999 \\ -1 \\ 1 \end{pmatrix}.$$

Să se găsească soluția aproximativă obținută cu metoda Gauss-Seidel pentru sistemele de ecuații liniare următoare:

$$23. \begin{cases} 14x_1 + x_2 & = 13 \\ x_1 + 5x_2 - x_3 & = -3 \\ -x_2 + 14x_3 - 2x_4 & = -15 \\ -2x_3 + 5x_4 & = 7 \end{cases}$$

Să se precizeze numărul de iterații necesare pentru ca eroarea să se micșoreze de 10 ori.

R. Matricea A fiind simetrică și pozitiv definită procedeul iterativ Gauss-Seidel este convergent. Sistemul se poate pune sub forma

$$x^{(m+1)} = Mx^{(m)} + C, \quad m \geq 0,$$

unde

$$M = -(D+E)^{-1}F, \quad C = (D+E)^{-1}b, \quad E = \begin{pmatrix} 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 0 & -1 & 0 & 0 \\ 0 & 0 & -2 & 0 \end{pmatrix}, \quad F = E^T,$$

$$D = \begin{pmatrix} 14 & 0 & 0 & 0 \\ 0 & 5 & 0 & 0 \\ 0 & 0 & 14 & 0 \\ 0 & 0 & 0 & 5 \end{pmatrix}.$$

$$\text{Deci } M = \begin{pmatrix} 0 & -0.07143 & 0 & 0 \\ 0 & 0.01429 & 0.2 & 0 \\ 0 & 0.00102 & 0.01429 & 0.14286 \\ 0 & 0.0004 & 0.000571 & 0.05714 \end{pmatrix}, \quad C = \begin{pmatrix} 0.92857 \\ -0.78571 \\ -1.12755 \\ 0.94898 \end{pmatrix}.$$

Dacă se pornește cu $v^{(0)} = b$ obțin vectorii:

$$v^{(1)} = \begin{pmatrix} 1.14286 \\ -3.82857 \\ -0.3449 \\ 1.26204 \end{pmatrix}, \quad v^{(2)} = \begin{pmatrix} 1.20204 \\ -0.90939 \\ -0.95609 \\ 1.01756 \end{pmatrix}, \quad v^{(3)} = \begin{pmatrix} 0.99353 \\ -0.98992 \\ -0.99677 \\ 1.00129 \end{pmatrix},$$

$$v^{(4)} = \begin{pmatrix} 0.99928 \\ -0.99921 \\ -0.99976 \\ 1.0001 \end{pmatrix}, \quad v^{(5)} = \begin{pmatrix} 0.99994 \\ -0.99994 \\ -0.99998 \\ 1.00001 \end{pmatrix}.$$

Raza spectrală este $\rho(M) = 0.0748$, rata de convergență este $R(M) = -\lg(\rho(M)) = 1.12609$ și numărul de iterații după care eroarea scade de 10 ori

este $K \approx \frac{1}{R(M)} = 0.88803$, adică la fiecare iterație eroarea scade de 10 ori.

$$24. \quad \begin{cases} 5x_1 + x_2 - x_3 & = 5 \\ x_1 + 8x_2 + x_3 & = 10 \\ -x_1 + x_2 + 15x_3 & = 15 \end{cases}$$

Să se precizeze numărul de iterații necesare pentru ca eroarea să se micșoreze de 10 ori.

R. Matricea A fiind simetrică și pozitiv definită procedeul iterativ

Gauss–Seidel este convergent. Sistemul se poate pune sub forma

$$x^{(m+1)} = Mx^{(m)} + C, \quad m \geq 0,$$

unde

$$M = -(D+E)^{-1}F, \quad C = (D+E)^{-1}b, \quad E = \begin{pmatrix} 0 & 0 & 0 \\ 1 & 0 & 0 \\ -1 & 1 & 0 \end{pmatrix}, \quad F = E^T, \quad D = \begin{pmatrix} 5 & 0 & 0 \\ 0 & 8 & 0 \\ 0 & 0 & 15 \end{pmatrix}$$

$$\text{Deci} \quad M = \begin{pmatrix} 0 & -0.2 & 0.2 \\ 0 & 0.02 & -0.12 \\ 0 & -0.01467 & 0.02133 \end{pmatrix}, \quad C = \begin{pmatrix} 1 \\ 0.9 \\ 1.0067 \end{pmatrix}.$$

Dacă se pornește cu $v^{(0)} = b$ obțin vectorii:

$$v^{(1)} = \begin{pmatrix} 2 \\ -0.7 \\ 1.18 \end{pmatrix}, \quad v^{(2)} = \begin{pmatrix} 1.376 \\ 0.7444 \\ 1.04211 \end{pmatrix}, \quad v^{(3)} = \begin{pmatrix} 1.05954 \\ 0.78984 \\ 1.01798 \end{pmatrix}, \quad v^{(4)} = \begin{pmatrix} 1.04563 \\ 0.79364 \\ 1.0168 \end{pmatrix},$$

$$v^{(5)} = \begin{pmatrix} 1.04463 \\ 0.79386 \\ 1.01672 \end{pmatrix}.$$

Raza spectrală este $\rho(M) = 0.06262$, rata de convergență este $R(M) = -\lg(\rho(M)) = 1.20326$ și numărul de iterații după care eroarea scade de 10 ori

este $K \approx \frac{1}{R(M)} = 0.83108$, adică la fiecare iterație eroarea scade de 10 ori.

Să se scrie soluția aproximativă obținută cu metoda gradientilor conjugați aplicată sistemelor de ecuații liniare:

$$25. \quad \begin{cases} 6x_1 + x_2 - x_3 & = 6 \\ x_1 + 8x_2 + x_3 & = -8 \\ -x_1 + x_2 + 10x_3 & = -12 \end{cases}.$$

R. Matricea coeficienților sistemului este simetrică și pozitiv definită și deci se

poate aplica metoda. Luând $x^{(0)} = \begin{pmatrix} 0 \\ 0 \\ 0 \end{pmatrix}$ ca vector de probă, se obțin rezultatele.

Iterația I.

$$r^{(0)} = Ax_0 - b = \begin{pmatrix} -6 \\ 8 \\ 12 \end{pmatrix}, \text{ prima direcție de relaxare, } p^{(1)} = -r^{(0)},$$

$$q_1 = -\frac{\langle r^{(0)}, p^{(1)} \rangle}{\langle Ap^{(1)}, p^{(1)} \rangle} = 0.10133, \quad x^{(1)} = x^{(0)} + q_1 p^{(1)} = \begin{pmatrix} 0.60797 \\ -0.81063 \\ -1.21595 \end{pmatrix}.$$

Iterația a II-a .

$$r^{(1)} = r^{(0)} + q_1 Ap^{(1)} = \begin{pmatrix} -1.94684 \\ 0.90698 \\ -1.57807 \end{pmatrix}, \quad c_1 = \frac{\langle r^{(1)}, r^{(1)} \rangle}{\langle r^{(0)}, r^{(0)} \rangle} = 0.02911$$

$$p^{(2)} = -r^{(1)} + c_1 p^{(1)} = \begin{pmatrix} 2.12151 \\ -1.13987 \\ 1.22874 \end{pmatrix}, \quad q_2 = -\frac{\langle r^{(1)}, p^{(2)} \rangle}{\langle Ap^{(2)}, p^{(2)} \rangle} = 0.17916,$$

$$x^{(2)} = x^{(1)} + q_2 p^{(2)} = \begin{pmatrix} 0.98807 \\ -1.01485 \\ -0.9958 \end{pmatrix}.$$

Iterația a III-a.

$$r^{(2)} = r^{(1)} + q_2 Ap^{(2)} = \begin{pmatrix} -0.09062 \\ -0.12656 \\ 0.03906 \end{pmatrix}, \quad c_2 = \frac{\langle r^{(2)}, r^{(2)} \rangle}{\langle r^{(1)}, r^{(1)} \rangle} = 3.62608 \cdot 10^{-3}$$

$$p^{(3)} = -r^{(2)} + c_2 p^{(2)} = \begin{pmatrix} 0.09832 \\ 0.12243 \\ -0.03461 \end{pmatrix}, \quad q_3 = -\frac{\langle r^{(2)}, p^{(3)} \rangle}{\langle Ap^{(3)}, p^{(3)} \rangle} = 0.12133,$$

$$x^{(3)} = x^{(2)} + q_3 p^{(3)} = \begin{pmatrix} 1 \\ -1 \\ -1 \end{pmatrix}.$$

26. Să se determine traseul optim pentru o conductă de gaze naturale care să treacă prin "apropierea" localităților L_i , $i=1, \dots, 10$, care raportate la un sistem cartezian de referință au coordonatele următoare:

$$L_1(1,2), L_2(2,2), L_3(5,3), L_4(7,4), L_5(10,2), L_6(11,3), L_7(15,4), L_8(16,5), L_9(18,1), \\ L_{10}(20,4).$$

R. Luând traseul după o dreaptă, se obține sistemul:

$$\begin{cases} a + b = 2 \\ 2a + b = 2 \\ 5a + b = 3 \\ 7a + b = 4 \\ 10a + b = 2 \\ 11a + b = 3 \\ 15a + b = 4 \\ 16a + b = 5 \\ 18a + b = 1 \\ 20a + b = 4 \end{cases}$$

care este supradimensionat. Se formează sistemul normal al lui Gauss $Bu=c$, unde

$$B=A^T A, \quad c=A^T b, \quad \text{adică: } B = \begin{pmatrix} 1505 & 105 \\ 105 & 10 \end{pmatrix}, \quad c = \begin{pmatrix} 340 \\ 30 \end{pmatrix}, \quad \text{a cărui soluție este}$$

$u_1=0.06211$, $u_2=2.34783$. Raportat la acel sistem de coordonate traseul conductei trebuie să urmeze dreapta $y = 0.06211x + 2.34783$.