

## LABORATOR 5 - METODE ITERATIVE DE REZOLVARE A SISTEMELOR DE ECUAȚII LINIARE. METODE DE RELAXARE

### 1. METODE DE RELAXARE. PRINCIPII DE BAZĂ

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

Fie sistemul liniar

$$(1.1) \quad Ax - b = 0,$$

unde matricea  $A$  a sistemului este simetrică și pozitiv definită. Dacă  $v = \begin{bmatrix} v_1 \\ v_2 \\ \vdots \\ v_n \end{bmatrix}$

este un vector de probă oarecare, atunci notăm cu

$$(1.2) \quad r = Av - b.$$

Vectorul  $r$  se numește *vector rezidual*.

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

În cele ce urmează, pentru orice doi vectori  $u = \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix}$  și  $v = \begin{bmatrix} v_1 \\ v_2 \\ \vdots \\ v_n \end{bmatrix}$  vom nota produsul lor scalar cu

$$(1.3) \quad \langle u, v \rangle = u^T v = u_1 v_1 + u_2 v_2 + \dots + u_n v_n.$$

Asociem sistemului 1.1 funcția pătratică

$$(1.4) \quad F(v) = \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n a_{ij} v_i v_j - \sum_{i=1}^n b_i v_i = \frac{1}{2} \langle Av, v \rangle - \langle b, v \rangle.$$

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  $i = 1, \dots, n$  avem

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

deci vectorul rezidual satisfacă relația

$$(1.5) \quad r = \text{grad } F.$$

**Teorema 1.** Problema determinării soluției sistemului (1.1) este echivalentă cu problema determinării punctului de minim al funcției pătratice (1.4).

*Demonstrație.* Fie  $v_0$  soluția sistemului 1.1. 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,

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

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

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

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

Rezultă  $\sum_{j=1}^n a_{ij} v_j^0 - b_i = 0, i = 1, \dots, n$ , deci  $v = v_0$  este soluție pentru 1.1.  $\square$

În continuare prezentăm principiul de bază al metodei relaxării. Fie  $v$  un vector de probă oarecare,  $p$  o direcție dată și  $D = \{v' = v + tp \mid t \in \mathbb{R}\}$ , dreapta care trece prin  $v$  și este paralelă cu  $p$ . Ne propunem să determinăm  $v'_0 \in D$  astfel încât  $F(v'_0) = \min\{F(v') \mid v' \in D\}$ . Înținând seama de 1.4, 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

$$(1.6) \quad f(t) = F(v') = F(v + tp) = F(v) + \frac{t^2}{2} \langle Ap, p \rangle + t \langle r, p \rangle.$$

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

$$(1.7) \quad t_{\min} = -\frac{\langle r, p \rangle}{\langle Ap, p \rangle}.$$

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 considerăm cazul particular  $n = 2$ .

Ecuațiile  $F(v) = \text{const.}$  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

$$(1.8) \quad a_{11}v_1^2 + 2a_{12}v_1v_2 + a_{22}v_2^2 - 2b_1v_1 - 2b_2v_2 = 2c.$$

Deoarece  $A$  este pozitiv definită, rezultă că

$$\delta = \begin{vmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{vmatrix} > 0,$$

deci 1.8 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 care trece prin  $v_0$  și are direcția  $p_1$ . Fie  $r_1 = Av_1 - b$ . Din **Observația 1** avem 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  $p_1$ .

## 2. METODA RELAXĂRII SIMPLE

Este o metodă specifică mai ales calculelor de mâna, având o semnificație istorică.

Fie  $v$  un vector de probă oarecare și fie  $r = Av - b$  vectorul rezidual corespunzător. Dacă  $|r_j| = \max_{1 \leq i \leq n} |r_i|$ , atunci alegem  $p = e_j$ , unde  $e_j = (0, \dots, 0, 1, 0, \dots, 0)^T$ . Rezultă

$$(2.1) \quad \begin{aligned} t_{\min} &= -\frac{\langle r, p \rangle}{\langle Ap, p \rangle} = -\frac{r_j}{a_{jj}} \text{ și} \\ v' &= v + t_{\min}p = v - \frac{r_j}{a_{jj}} e_j. \end{aligned}$$

Pe componente avem:

$$(2.2) \quad v'_i = \begin{cases} v_i, & \text{dacă } i \neq j \\ v_j - \frac{r_j}{a_{jj}}, & \text{dacă } i = j. \end{cases}$$

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

$$(2.3) \quad \begin{cases} r'_1 = r_1 - \frac{r_j}{a_{jj}} a_{1j} \\ \dots \\ r'_j = 0 \\ \dots \\ r'_n = r_n - \frac{r_j}{a_{jj}} a_{nj} \end{cases}.$$

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

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 dominată.

**Exemplul 1.**  $\begin{cases} -x_1 + 0.2x_2 + 0.2x_3 + 0.6 = 0 \\ 0.2x_1 - x_2 + 0.2x_3 + 0.5 = 0 \\ 0.2x_1 + 0.2x_2 - x_3 + 0.4 = 0 \end{cases}$

Dacă alegem  $v^{(1)} = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}$ , atunci  $r^{(1)} = \begin{bmatrix} 0.6 \\ 0.5 \\ 0.4 \end{bmatrix}$  și  $\max\{r_1^{(1)}, r_2^{(1)}, r_3^{(1)}\} = r_1^{(1)} = 0.6$ .

Așadar  $p_1 = e_1 = \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix}$ ,  $v^{(2)} = v^{(1)} - \frac{r_1^{(1)}}{a_{11}}e_1$  și  $r^{(2)} = r^{(1)} - \frac{r_1^{(1)}}{a_{11}}Ae_1$ .

Pe componente avem:

...

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

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

Rezultă

$$p_3 = e_3 = \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix}, v^{(4)} = v^{(3)} - \frac{r_3^{(3)}}{a_{33}}e_3 \text{ și } r^{(4)} = r^{(3)} - \frac{r_3^{(3)}}{a_{33}}Ae_3$$

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

Algoritmul MATLAB pentru metoda relaxării simple

```

clc
% Introducere A, matricea coeficienților
% Introducere b, vectorul termenilor liberi
n=size(A);
x=zeros(n,1);
r=A*x-b;
eps=input('Dati ordinul erorii, eps=')
i=0;
while(norm(r,<inf)>eps)
    i=i+1
    p=zeros(n,1);
    for j=1:n
        s(j)=norm(r(j));
    end

```

```

[C,I] = max(s)
p(I)=1
t=-r(I)/A(I,I)
x=x+t*p
r=A*x-b
end
disp('Solutia sistemului prin metoda relaxarii simple')
x
fprintf('neste obtinuta la pasul %g.\n',i)
disp('Verificare')
A*x

```

### 3. METODA DEPLASĂRILOR SUCCESIVE (GAUSS-SIEDEL)

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 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  $p' = e_1 = \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix}$ . Conform formulei 2.1

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  $p'' = e_2 = \begin{bmatrix} 0 \\ 1 \\ 0 \end{bmatrix}$  și obținem vectorul  $v''$  de componente

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

În sfârșit, pentru direcția de relaxare  $p''' = e_3 = \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix}$ , 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:

$$(3.1) \quad \begin{cases} v_1^{(1)} = v_1''' = -\frac{a_{12}}{a_{11}}v_2^{(0)} - \frac{a_{13}}{a_{11}}v_3^{(0)} + \frac{b_1}{a_{11}} \\ v_2^{(1)} = v_2''' = -\frac{a_{21}}{a_{22}}v_1^{(1)} - \frac{a_{23}}{a_{22}}v_3^{(0)} + \frac{b_2}{a_{22}} \\ v_3^{(1)} = v_3''' = -\frac{a_{31}}{a_{33}}v_1^{(1)} - \frac{a_{32}}{a_{33}}v_2^{(1)} + \frac{b_3}{a_{33}} \end{cases}.$$

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:

$$(3.2) \quad \begin{cases} a_{11}v_1^{(m+1)} + a_{12}v_2^{(m)} + a_{13}v_3^{(m)} + \dots + a_{1n}v_n^{(m+1)} = b_1 \\ a_{21}v_1^{(m+1)} + a_{22}v_2^{(m+1)} + a_{23}v_3^{(m)} + \dots + a_{2n}v_n^{(m)} = b_2 \\ \dots \\ a_{n1}v_1^{(m+1)} + a_{n2}v_2^{(m+1)} + a_{n3}v_3^{(m+1)} + \dots + a_{nn}v_n^{(m+1)} = b_n \end{cases}.$$

**Observația 2.** Formulele (3.2) se regăsesc și în cursul anterior, la metoda Gauss-Siedel.

Dacă notăm cu

$$E = \begin{bmatrix} 0 & 0 & 0 & \dots & 0 \\ a_{21} & 0 & 0 & \dots & 0 \\ a_{31} & a_{32} & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & a_{n3} & \dots & 0 \end{bmatrix}, F = E^T \text{ și } D = \begin{bmatrix} a_{11} & 0 & \dots & 0 \\ 0 & a_{22} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & a_{nn} \end{bmatrix},$$

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

$$(3.3) \quad (D + E)v^{(m+1)} + Fv^{(m)} = b,$$

de unde rezultă

$$(3.4) \quad v^{(m+1)} = -(D + E)^{-1}Fv^{(m)} + (D + E)^{-1}b.$$

În sfârșit, notând

$$(3.5) \quad M = -(D + E)^{-1}F \text{ și } c = (D + E)^{-1}b,$$

obținem procesul iterativ

$$(3.6) \quad v^{(m+1)} = Mv^{(m)} + c.$$

**Exemplul 2.**

$$\begin{aligned}
 A &= \begin{bmatrix} 2 & -1 & 0 & 0 \\ -1 & 3 & -1 & 0 \\ 0 & -1 & 3 & -1 \\ 0 & 0 & -1 & 2 \end{bmatrix}, \quad D + E = \begin{bmatrix} 2 & 0 & 0 & 0 \\ -1 & 3 & 0 & 0 \\ 0 & -1 & 3 & 0 \\ 0 & 0 & -1 & 2 \end{bmatrix}, \\
 (D + E)^{-1} &= \frac{1}{36} \begin{bmatrix} 18 & 0 & 0 & 0 \\ 6 & 12 & 0 & 0 \\ 2 & 4 & 12 & 0 \\ 1 & 2 & 3 & 18 \end{bmatrix}, \quad F = \begin{bmatrix} 0 & -1 & 0 & 0 \\ 0 & 0 & -1 & 0 \\ 0 & 0 & 0 & -1 \\ 0 & 0 & 0 & 0 \end{bmatrix}, \\
 M &= -(D + E)^{-1}F = \frac{1}{36} \begin{bmatrix} 0 & 18 & 0 & 0 \\ 0 & 6 & 12 & 0 \\ 0 & 2 & 4 & 12 \\ 0 & 1 & 2 & 6 \end{bmatrix} \\
 \det(M - \lambda I) &= \lambda^2 \left( \lambda^2 - \frac{4}{9}\lambda + \frac{1}{36} \right).
 \end{aligned}$$

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

**Teorema 2.** Dacă matricea  $A$  este simetrică și pozitiv definită, procesul iterativ Gauss-Siedel este convergent.

Demonstrația se bazează pe faptul că dacă matricea  $A$  este simetrică și pozitiv definită, atunci  $\rho(M) < 1$ , deci procesul iterativ este convergent.

#### 4. METODA SUPRARELAXĂRII

Pentru sisteme mari de ecuații, procesul iterativ Gauss-Siedel converge lent, deoarece raza spectrală  $\rho(M)$  este în vecinătatea lui 1. Metoda suprarelaxării este o generalizare a metodei Gauss-Siedel, care constă în introducerea unui parametru  $\omega$  în vederea accelerării convergenței. Ca și la metoda Gauss-Siedel, 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 initial. După un ciclu în care direcția de relaxare urmează succesiv direcțiile  $e_1, e_2, e_3$  obținem vectorul  $v^{(1)}$  de componente:

$$(4.1) \quad \begin{cases} v_1^{(1)} = v_1^{(0)} - \frac{\omega}{a_{11}} (a_{11}v_1^{(0)} + a_{12}v_2^{(0)} + a_{13}v_3^{(0)} - b_1) \\ v_2^{(1)} = v_2^{(0)} - \frac{\omega}{a_{22}} (a_{21}v_1^{(1)} + a_{22}v_2^{(0)} + a_{23}v_3^{(0)} - b_2) \\ v_3^{(1)} = v_3^{(0)} - \frac{\omega}{a_{33}} (a_{31}v_1^{(1)} + a_{32}v_2^{(1)} + a_{33}v_3^{(0)} - b_3) \end{cases}.$$

Dacă  $\omega = 1$ , obținem din nou formulele (3.1). După efectuarea calculelor rezultă:

$$(4.2) \quad \begin{cases} \omega^{-1}a_{11}v_1^{(1)} + (1 - \omega^{-1})a_{11}v_1^{(0)} + a_{12}v_2^{(0)} + a_{13}v_3^{(0)} = b_1 \\ a_{21}v_1^{(1)} + \omega^{-1}a_{22}v_2^{(1)} + (1 - \omega^{-1})a_{22}v_2^{(0)} + a_{23}v_3^{(0)} = b_2 \\ a_{31}v_1^{(1)} + a_{32}v_2^{(1)} + \omega^{-1}a_{33}v_3^{(1)} + (1 - \omega^{-1})a_{33}v_3^{(0)} = b_3 \end{cases}$$

Dacă introducem notațiile

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

relațiile (4.2) iau forma matriceală

$$(4.3) \quad (E + \omega^{-1}D)v^{(1)} + [F + (1 - \omega^{-1})D]v^{(0)} = b.$$

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

$$(4.4) \quad (E + \omega^{-1}D)v^{(m+1)} + [F + (1 - \omega^{-1})D]v^{(m)} = b.$$

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

$$(4.5) \quad \begin{cases} M(\omega) = -(E + \omega^{-1}D)^{-1}[F + (1 - \omega^{-1})D] \\ c(\omega) = (E + \omega^{-1}D)^{-1}b. \end{cases}$$

Obținem astfel procesul iterativ

$$(4.6) \quad v^{(m+1)} = M(\omega)v^{(m)} + c(\omega).$$

Pentru  $\omega = 1$  obținem algoritmul Gauss-Siedel. Parametrul optim,  $\omega_{opt}$ , va fi acela pentru care raza spectrală a matricii  $M(\omega)$  va fi minimă. Evident, pentru acest parametru se obține cea mai rapidă convergență.

Se poate demonstra următoarea teoremă.

**Teorema 3.** *Dacă matricea  $A$  este simetrică și pozitiv definită, metoda suprarelaxării este convergentă pentru orice  $0 < \omega < 2$ .*

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

Determinarea parametrului optim,  $\omega_{opt}$ , este posibilă în cazul *matricilor bloc tridiagonale*.

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

$$A = \begin{bmatrix} D_1 & F_1 & 0 & 0 & \cdots & & 0 \\ E_1 & D_2 & F_2 & 0 & \cdots & & 0 \\ 0 & E_2 & D_3 & F_3 & \cdots & & 0 \\ 0 & 0 & E_3 & D_4 & \cdots & & \\ \vdots & \vdots & & & \ddots & & \vdots \\ 0 & 0 & \cdots & & D_{m-2} & F_{m-2} & 0 \\ 0 & 0 & \cdots & & E_{m-2} & D_{m-1} & F_{m-1} \\ 0 & 0 & \cdots & & 0 & E_{m-1} & D_m \end{bmatrix},$$

unde  $D_i$  sunt matrici pătratice de diferite ordine,  $E_k$  și  $F_k$  sunt, în general, matrici 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 afară de matricile care intră în bandă, restul elementelor sunt nule. Dacă, în plus, matricile  $D_i$  sunt diagonale, matricea  $A$  se numește **diagonal bloc tridiagonală**.

Prezentăm de asemenea fără demonstrație următoarea teoremă.

**Teorema 4.** *Fie  $A$  o matrice simetrică, pozitiv definită și diagonal tridiagonală.*

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

*$\lambda_1$  este cea mai mare valoare proprie a matricii  $-D^{-1}(E + F)$ .*

**Exemplul 3.** Fie matricea diagonal bloc tridiagonală

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

Ecuația caracteristică este

$$\left| \begin{array}{cccc} -\lambda & \frac{1}{2} & 0 & 0 \\ \frac{1}{3} & -\lambda & \frac{1}{3} & 0 \\ 0 & \frac{1}{3} & -\lambda & \frac{1}{3} \\ 0 & 0 & \frac{1}{2} & -\lambda \end{array} \right| = 0,$$

adică  $36\lambda^4 + 16\lambda^2 + 1 = 0$ . Rezultă  $\lambda_i = \pm\sqrt{\frac{4 \pm \sqrt{7}}{18}}$  și  $\lambda_1 \approx 0.6076$ . Parametrul optim de relaxare  $\omega_{opt} = \frac{2}{1 + \sqrt{1 - \lambda_1^2}} \approx 1.115$ .

Algoritmul MATLAB pentru metoda suprarelaxării

```

clc
% Introducere A, matricea coeficientilor
% Introducere b, vectorul termenilor liberi
n=size(A);
D=diag(diag(A))
E=tril(A)-D
F=E';
T=-inv(D)*(E+F)
v=eig(T)
ro=max(v)
omega=2/(1+sqrt(1-ro^2))
M=-inv(E+1/omega*D)*(F+(1-1/omega)*D)
c=inv(E+1/omega*D)*b
x=zeros(n,1);
r=A*x-b
eps=input('Dati ordinul erorii, eps=')

```

```
i=0;  
while(norm(r,inf)>eps)  
    i  
    x=M*x+c  
    r=A*x-b  
end  
disp('Solutia sistemului prin metoda suprarelaxarii')  
x  
fprintf('\neste obtinuta la pasul %g.\n',i)  
disp('Verificare')  
A*x
```