

Prelegerea nr. 6

VI. METODE ITERATIVE DE REZOLVARE A SISTEMELOR DE ECUAȚII LINIARE

Sumar

- Schema generală de construire a metodelor iterative
- Metoda iterativă Jacobi
- Metoda Gauss-Seidel
- Metoda suprarelaxărilor succesive

6.1 Schema generală de construire a metodelor iterative

Să considerăm sistemul de ecuații liniare:

$$Ax = b \quad (6.1)$$

unde $b \in R^n$ iar A este o matrice nesingulară ($\det(A) \neq 0$) de dimensiune $n \times n$. Metoda eliminării a lui Gauss de rezolvare a sistemului liniar (6.1) necesită cel puțin $n^3/3$ operații aritmetice și atât timp cât acest număr de operații este acceptabil putem utiliza această metodă. Pe de altă parte, când $n^3/3$ este mare, cu ajutorul metodelor iterative se poate obține cu aproximație satisfăcătoare a soluției după efectuarea unui număr mult mai mic de operații aritmetice.

Metodele iterative se construiesc utilizând desfacerea matricei A definită prin:

$$A = S - T.$$

Atunci sistemul (6.1) este echivalent cu sistemul :

$$Sx = Tx + b, \quad (6.2)$$

sau

$$x = Qx + d, \quad (6.3)$$

unde: $Q = S^{-1}T$, $d = S^{-1}b$. Prin urmare putem construi șirul $\{x^{(k)}\}$ utilizând relația recurentă:

$$Sx^{(k+1)} = Tx^{(k)} + b, \quad k = 0, 1, 2, \dots, \quad (6.4)$$

sau

$$x^{(k+1)} = Qx^{(k)} + d, \quad k = 0, 1, 2, \dots, \quad (6.5)$$

unde $x^{(0)} \in R^n$ este o aproximație inițială a soluției x^* .

Pentru a reduce sistemul (6.1) la forma (6.2) sau (6.4), potrivită pentru iterație, desfacerea matricei A trebuie să satisfacă condițiile:

- Sistemul (6.4) are o soluție unică $x^{(k+1)}$ și se rezolvă ușor. De aceea matricea S se alege de o formă simplă și este inversabilă. Ea poate fi diagonală sau triunghiulară.
- Șirul $\{x^{(k)}\}_{k=0}^{\infty}$ converge către soluția exactă x^* oricare ar fi $x^{(0)} \in R^n$.

Deoarece $x^* = Qx^* + d$ avem:

$$x^{(k+1)} - x^* = Q(x^{(k)} - x^*), \quad k = 0, 1, 2, \dots,$$

de unde rezultă că:

$$x^{(k+1)} - x^* = Q^k(x^{(0)} - x^*)$$

Evident că $\lim_{k \rightarrow \infty} x^{(k)} = x^*$ dacă și numai dacă

$$\lim_{k \rightarrow \infty} Q^k = O.$$

În cursul algebrei se demonstrează că $Q^k \xrightarrow[k \rightarrow \infty]{} O$, dacă și numai dacă raza spectrală a lui Q este mai mică ca unitatea: $\rho(Q) = \max_{\lambda \in \sigma(Q)} |\lambda| < 1$. Viteza de convergență a șirului matriceal $Q, Q^2, Q^3, \dots, Q^k, \dots$ către matricea nulă O , și deci a șirului $\{x^{(k)}\}_{k=0}^{\infty}$ către x^* , este cu atât mai mare cu cât raza spectrală $\rho(Q)$ este mai mică. Rezultă că este adevărată următoarea teoremă.

Teorema 1. (Condiția necesară și suficientă de convergență). Șirul $\{x^{(k)}\}$ definit prin (6.5) converge către soluția unică x^* a sistemului (6.3 pentru orice aproximație inițială $x^{(0)} \in R^n$ dacă și numai dacă

$$\rho(Q) = \max_{\lambda \in \sigma(Q)} |\lambda| < 1. \quad (6.6)$$

În practică nu cunoaștem valorile proprii ale lui Q , de aceea teorema 1 este dificil de folosit. În locul teoremei 1 se utilizează următoarea teoremă.

Teorema 2. (Condiția suficientă de convergență). Dacă există o normă matriceală subordonată unei norme vectoriale astfel încât $\|Q\| \leq q < 1$, atunci sistemul (6.3) are o soluție unică x^* , șirul $\{x^{(k)}\}$ definit prin (6.5) converge către x^* oricare ar fi aproximația inițială $x^{(0)} \in R^n$ și eroarea se evaluează prin:

$$\|x^{(k)} - x^*\| \leq \frac{q}{1-q} \|x^{(k)} - x^{(k-1)}\| \leq \frac{q^k}{1-q} \|x^{(1)} - x^{(0)}\|.$$

Demonstrație. Condiția $\|Q\| < 1$ implică condiția (6.6) (vezi paragraful 3.2). Pentru a obține o estimare a erorii folosim relația:

$$x^* - x^{(k-1)} = x^{(k)} - x^{(k-1)} + Q(x^* - x^{(k-1)}).$$

Deci

$$\|x^* - x^{(k-1)}\| \leq \|x^{(k)} - x^{(k-1)}\| + \|Q\| \|x^* - x^{(k-1)}\|,$$

sau

$$(1 - \|Q\|) \|x^* - x^{(k-1)}\| \leq \|x^{(k)} - x^{(k-1)}\|.$$

Deoarece prin ipoteză $1 - \|Q\| \geq 1 - q > 0$ avem:

$$\|x^* - x^{(k-1)}\| \leq \frac{1}{1-q} \|x^{(k)} - x^{(k-1)}\|.$$

Pe de altă parte

$$\|x^* - x^{(k)}\| = \|Q(x^* - x^{(k-1)})\| \leq \|Q\| \|x^* - x^{(k-1)}\|.$$

Prin urmare

$$\|x^* - x^{(k)}\| \leq \frac{q}{1-q} \|x^{(k)} - x^{(k-1)}\|.$$

Teorema este demonstrată.

6.2 Metoda iterativă Jacobi

Presupunem că elementele diagonale $a_{ii} \neq 0$, $i = 1, 2, \dots, n$. Atunci în calitate de matrice S se poate lua matricea diagonală atașată matricei A :

$$S = \text{Diag}(a_{11}, a_{22}, \dots, a_{nn}).$$

Avem

$$S^{-1} = \text{Diag}\left(\frac{1}{a_{11}}, \frac{1}{a_{22}}, \dots, \frac{1}{a_{nn}}\right)$$

În acest caz sistemul (6.3) devine:

$$x_i = \frac{1}{a_{ii}} \left(b_i - \sum_{\substack{j=1 \\ j \neq i}}^n a_{ij} x_j \right), \quad i = 1, 2, \dots, n.$$

Procesul iterativ (6.5) este definit prin:

$$x_i^{(k+1)} = \frac{1}{a_{ii}} \left(b_i - \sum_{\substack{j=1 \\ j \neq i}}^n a_{ij} x_j^{(k)} \right), \quad i = 1, 2, \dots, n. \quad (6.7)$$

Astfel obținem o metodă de rezolvare a sistemului liniar (3.13) numită **metoda lui Jacobi**.

Exemplu. Fie dat sistemul de ecuații liniare:

$$\left. \begin{aligned} 2x_1 - x_2 &= 1, \\ -x_1 + 2x_2 &= 1 \end{aligned} \right\} \quad (6.8)$$

Vom avea:

$$A = \begin{pmatrix} 2 & -1 \\ -1 & 2 \end{pmatrix}, \quad S = \begin{pmatrix} 2 & 0 \\ 0 & 2 \end{pmatrix}, \quad T = \begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix},$$

$$Q = S^{-1}T = \begin{pmatrix} 0 & \frac{1}{2} \\ \frac{1}{2} & 0 \end{pmatrix}, \quad d = \begin{pmatrix} \frac{1}{2} \\ \frac{1}{2} \end{pmatrix}.$$

Valorile proprii ale matricei Q sunt: $\lambda_1 = -\frac{1}{2}$, $\lambda_2 = \frac{1}{2}$. Deci metoda lui Jacobi:

$$\left. \begin{aligned} x_1^{(k+1)} &= \frac{1}{2}x_2^{(k)} + \frac{1}{2}, \\ x_2^{(k+1)} &= \frac{1}{2}x_1^{(k)} + \frac{1}{2} \end{aligned} \right\}$$

converge către soluția exactă $x^* = (1, 1)^T$ oricare ar fi $x^{(0)} \in \mathbb{R}^2$. În particular, pentru $x^{(0)} = (0, 0)^T$ obținem șirul:

$$x^{(1)} = \left(\frac{1}{2}, \frac{1}{2}\right)^T, x^{(2)} = \left(\frac{3}{4}, \frac{3}{4}\right)^T, x^{(3)} = \left(\frac{7}{8}, \frac{7}{8}\right)^T, x^{(4)} = \left(\frac{15}{16}, \frac{15}{16}\right)^T, \dots$$

Observăm că pentru metoda lui Jacobi matricea Q are elementele

$$q_{ij} = \begin{cases} 0, & \text{dacă } i = j, \\ -\frac{a_{ij}}{a_{ii}}, & \text{dacă } i \neq j \end{cases}$$

Utilizând teorema 2 cu norma $\|\bullet\|_\infty$ obținem:

$$\|Q\|_\infty = \max_{1 \leq i \leq n} \sum_{j=1}^n |q_{ij}| = \max_{1 \leq i \leq n} \sum_{\substack{j=1 \\ j \neq i}}^n \frac{|a_{ij}|}{|a_{ii}|} < 1.$$

Rezultă că dacă

$$a_{ii} |a_{ij}| > \sum_{\substack{j=1 \\ j \neq i}}^n |a_{ij}|, \quad i = 1, 2, \dots, n,$$

adică dacă matricea A este **diagonal dominantă**, atunci metoda lui Jacobi este convergentă.

6.3 Metoda Gauss-Seidel

În metoda lui Jacobi este necesar a păstra în memoria calculatorului toate componentele vectorului $x^{(k)}$ atâta timp cât se calculează vectorul $x^{(k+1)}$. Putem modifica metoda lui Jacobi astfel încât la pasul $(k+1)$ să folosim în calculul componentei $x_i^{(k+1)}$, valorile deja calculate la același pas: $x_1^{(k+1)}, x_2^{(k+1)}, \dots, x_{i-1}^{(k+1)}$. Această modificare a metodei lui Jacobi se numește **metoda lui Gauss-Seidel**, iar șirul iterativ (6.7) devine:

$$x_i^{(k+1)} = \frac{1}{a_{ii}} \left(b_i - \sum_{j=1}^{i-1} a_{ij} x_j^{(k+1)} - \sum_{j=i}^n a_{ij} x_j^{(k)} \right), \quad i = 1, 2, \dots, n.$$

j=i+1

Se observă ușor că metodei lui Gauss-Seidel corespunde desfacerea $A=S-T$ unde S este matricea subdiagonală atașată lui A , iar T este matricea strict supradiagonală cu elementele $-a_{ij}$ atașată la aceeași matrice A :

$$S = \begin{pmatrix} a_{11} & 0 & 0 & \dots & 0 \\ a_{21} & a_{22} & 0 & \dots & 0 \\ a_{31} & a_{32} & a_{33} & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots \\ a_{n1} & a_{n2} & a_{n3} & \dots & a_{nn} \end{pmatrix}, \quad T = \begin{pmatrix} 0 & -a_{12} & -a_{13} & \dots & -a_{1n} \\ 0 & 0 & -a_{23} & \dots & -a_{2n} \\ 0 & 0 & 0 & \dots & -a_{3n} \\ \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & \dots & 0 \end{pmatrix}.$$

Să reluăm exemplul de mai sus cu sistemul de ecuații (6.8). Pentru metoda Gauss-Seidel avem:

$$A = \begin{pmatrix} 2 & -1 \\ -1 & 2 \end{pmatrix}, \quad S = \begin{pmatrix} 2 & 0 \\ -1 & 2 \end{pmatrix}, \quad T = \begin{pmatrix} 0 & 1 \\ 0 & 0 \end{pmatrix},$$

$$Q = S^{-1}T = \begin{pmatrix} 0 & \frac{1}{2} \\ 0 & \frac{1}{4} \end{pmatrix}, \quad d = \begin{pmatrix} \frac{1}{2} \\ \frac{1}{2} \end{pmatrix}.$$

Șirul Gauss-Seidel arată astfel:

$$\left. \begin{aligned} x_1^{(k+1)} &= \frac{1}{2}x_2^{(k)} + \frac{1}{2}, \\ x_2^{(k+1)} &= \frac{1}{2}x_1^{(k+1)} + \frac{1}{2} \end{aligned} \right\}$$

ori:

$$\begin{pmatrix} 2 & 0 \\ -1 & 2 \end{pmatrix} \begin{pmatrix} x_1^{(k+1)} \\ x_2^{(k+1)} \end{pmatrix} = \begin{pmatrix} 0 & 1 \\ 0 & 0 \end{pmatrix} \begin{pmatrix} x_1^{(k)} \\ x_2^{(k)} \end{pmatrix} + \begin{pmatrix} 1 \\ 1 \end{pmatrix}.$$

Pentru aproximația inițială $x^{(0)} = (0, 0)^T$ obținem:

$$x^{(1)} = \left(\frac{1}{2}, \frac{1}{2}\right)^T, \quad x^{(2)} = \left(\frac{3}{4}, \frac{7}{8}\right)^T, \quad x^{(3)} = \left(\frac{15}{16}, \frac{31}{32}\right)^T, \dots$$

Se observă că o iterație Gauss – Seidel aici este echivalentă cu două iterații Jacobi, deoarece valorile proprii ale matricei Q sunt 0 și $\frac{1}{4}$, deci raza spectrală este $\rho(S^{-1}T) = \frac{1}{4}$. Aceasta înseamnă că eroarea la fiecare iterație se împarte la 4; în metoda lui Jacobi $\rho(S^{-1}T) = \frac{1}{2}$ și eroarea se împarte la 2.

Subliniem că metoda lui Gauss – Seidel, necesitând același număr de operații aritmetice, este în caz general mai bună ca metoda lui Jacobi. Se poate arăta că, dacă A este o matrice pozitiv definită atunci metoda Gauss – Seidel converge de două ori mai repede către soluție decât metoda lui Jacobi.

Se demonstrează și aici (vezi, de exemplu, [15], pag.181) că dacă matricea A este diagonal dominantă atunci metoda Gauss – Seidel converge. Se cunosc modele în care metoda lui Gauss – Seidel converge, iar metoda lui Jacobi nu converge și invers. Pentru ilustrare anunțăm următoarea teoremă.

Teorema (Reich). Dacă matricea A este simetrică și are elementele diagonale $a_{ii} > 0$ pentru orice i atunci metoda Gauss – Seidel converge dacă și numai dacă A este o matrice pozitiv definită.

Este cunoscut că metoda lui Jacobi nu întotdeauna converge pentru matricea A pozitiv definită. De exemplu, dacă A este o matrice pozitiv definită și nu este diagonal dominantă, atunci este posibil ca raza spectrală $\rho(S^{-1}T) > 1$ pentru metoda lui Jacobi.

După cum sa văzut mai sus, dacă matricea A este diagonal dominantă, atunci metoda lui Jacobi și metoda lui Gauss – Seidel vor genera un șir de aproximații succesive care converge către soluția exactă oricare ar fi aproximația inițială $x^{(0)}$. Subliniem că această condiție este numai suficientă și nu necesară. De exemplu pentru matricea

$$A = \begin{pmatrix} 8 & 2 & 1 \\ 10 & 4 & 1 \\ 50 & 25 & 2 \end{pmatrix}$$

care nu este diagonal dominantă metoda lui Gauss – Seidel converge foarte rapid.

6.4 Metoda suprarelaxărilor succesive

Metoda lui Gauss – Seidel poate fi modificată pentru îmbunătățirea vitezei de convergență a șirului aproximațiilor succesive. Fie $\tilde{x}^{(k)}$ vectorul obținut la pasul $k + 1$ prin metoda Gauss – Seidel. Metoda iterativă definită prin:

$$x^{(k+1)} = x^{(k)} + \omega(\tilde{x}^{(k)} - x^{(k)})$$

este cunoscută cu numele de **metoda suprarelaxărilor succesive**. Parametrul de relaxare ω se alege astfel încât să crească viteza de convergență. Pentru $\omega = 1$ metoda se reduce la metoda lui Gauss – Seidel.

S-a găsit că pentru o alegere potrivită a parametrului ω convergența metodei suprarelaxării succesive este net superioară metodelor Jacobi și Gauss – Seidel. De exemplu, în cazul sistemului de ecuații liniare (6.8) o iterație prin metoda suprarelaxării succesive este echivalentă (vezi [2,35]) cu 30 de iterații prin metoda lui Jacobi.

Se poate arăta că $\omega \in (0, 2)$, de regulă, în practică:

$$\omega \approx 1.8 \div 1.9.$$

Se demonstrează că metoda suprarelaxărilor succesive converge pentru toate matricele A simetrice pozitiv definite.