

## CURS 3

# METODE NUMERICE PENTRU SISTEME DE ECUAȚII LINIARE

---

## Partea II

- 4 Matrici bandă
- 5 Metode iterative: Jacobi; Gauss-Seidel; SOR
- 6 Stabilitatea soluției și condiționarea sistemului

### 4 Matrici bandă – simetrice și pozitiv definite

#### 4.1 Matrice bandă simetrică

Presupunem că matricea sistemului este simetrică și, în plus, are structura de *matrice bandă*, adică în fiecare linie elementele matricii sunt constituite din:

- Elementul diagonal, un număr de  $LIM-1$  elemente la stânga acestuia, și  $LIM-1$  elemente la dreapta.
- Celelalte elemente din linie sunt zero.

Numărul  $LIM$  va fi numit *semi-lățimea* de bandă.  $LIM$  reprezintă numărul elementelor din semi-bandă, inclusiv elementul diagonal.

#### *Observație*

Între elementele din bandă, pot fi și elemente nule, dar caracterul de bandă este dat de faptul că toate elementele situate în afara benzii sunt nule. În acest sens  $LIM$  poate fi considerat semi-lățimea de bandă *maximă* ■

Exemplu: Matrice  $6 \times 6$ ,  $a_{ij} = a_{ji}$ , și  $LIM = 3$ :



Stocarea se mai poate face pe linii de  $LIM$  elemente, într-un tablou  $B(n, LIM)$ . Liniile care conțin mai puțin de  $LIM$  elemente se completează cu elemente nule (exemplu: liniile 5 și 6).

### 4.3 Metoda Cholesky

Proprietatea esențială este următoarea:

Dacă matricea bandă este *simetrică și pozitiv definită*, atunci descompunerea  $LL^T$  sau  $S^T S$  poate fi făcută lucrând *exclusiv* în bandă ■

În ceea ce urmează vom considera descompunerea  $A = S^T S$ , lucrând cu semi-banda superioară.


Pașii sunt cei de la Cholesky, lucrul cu [matricea S](#).

Elementele active la un pas al descompunerii, sunt conținute într-un triunghi cu laturile  $LIM$  – numit “triunghiul activ”. În cursul procesului, triunghiul activ coboară cu câte o linie în bandă.

Metoda implementată în ANA\Cholesky\_Band utilizează un vector de lucru  $Y$ , de dimensiune  $NY$ , unde:

$$NY0 = LIM * (LIM + 1) / 2; \quad NY = NY0 + n * LIM .$$

Acest vector este constituit din două părți:



Tablourile Y1 și YA

- Sub-vectorul  $Y1(1: NY0)$ , de dimensiune  $LIM * (LIM + 1) / 2$ : servește ca front de lucru, pentru descompunerea Cholesky; în acestea se generează elementele triunghiului activ la un pas (triunghi cu laturile  $LIM$ ).

- Sub-vectorul YA( NY0+1 : NY ), de dimensiune  $n * LIM$  : inițial, stochează matricea **A**, pe linii. În cursul descompunerii Cholesky, stochează liniile procesate ale matricii A.

## 5. METODE ITERATIVE

### 5.1 Metoda JACOBI

*Exemplu numeric*

Fie sistemul:

$$8x_1 + x_2 - x_3 = 8$$

$$2x_1 + x_2 + 9x_3 = 12$$

$$x_1 - 7x_2 + 2x_3 = -4$$

Rezolvăm fiecare ecuație  $i = 1, 2, 3$ , în raport cu necunoscuta  $x_i$ , căutând ca aceasta să fie necunoscuta cu coeficientul cel mai mare din ecuație, eventual rearanjând ecuațiile.

Intervertind ecuațiile 2 și 3, avem:

$$x_1 = 1 - (1/8)x_2 + (1/8)x_3$$

$$x_2 = 4/7 + (1/7)x_1 + (2/7)x_3$$

$$x_3 = 12/9 - (2/9)x_1 - (1/9)x_2$$

Sau matriceal:

$$\begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} 1 \\ 4/7 \\ 12/9 \end{bmatrix} + \begin{bmatrix} 0 & -1/8 & 1/8 \\ 1/7 & 0 & 2/7 \\ -2/9 & -1/9 & 0 \end{bmatrix} \cdot \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} \quad (1')$$

care este de forma

$$\mathbf{x}^{(m+1)} = \mathbf{g} + \mathbf{M}\mathbf{x}^{(m)}$$

Se iterează, cu aproximația inițială  $\mathbf{x}^{(0)} = [1 \ 4/7 \ 12/9]^T$ ; testul de oprire a iterației este  $\|\mathbf{x}^{(m+1)} - \mathbf{x}^{(m)}\|_{\infty} \leq 1E - 6$ . La iterația 12 rezultă soluția (1.0, 1.0, 1.0). Coordonata de modul maxim în  $\mathbf{Ax} - \mathbf{b}$  (rezidualul maxim) este 1.43E-06 (ecuația 3).

■

### Metoda

Fie sistemul dat  $\mathbf{Ax} = \mathbf{b}$ . Se rezolvă fiecare ecuație  $i$  în raport cu necunoscuta  $x_i$ . Explicitând  $x_i$  se obține:

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

S-a presupus  $a_{ii} \neq 0$ . Iterația Jacobi va fi:

$$\begin{cases} \mathbf{x}^{(0)} = \text{arbitrar} \\ x_i^{(m+1)} = (b_i - \sum_{j=1, j \neq i}^n a_{ij} x_j^{(m)}) / a_{ii}, \quad i = 1, 2, \dots, n; \quad m \geq 0 \end{cases}$$

Testul de oprire a iterației este  $\|\mathbf{x}^{(m+1)} - \mathbf{x}^{(m)}\|_{\infty} \leq \text{eps}$ .

Metoda Jacobi se mai zice metoda “iterațiilor simultane”, pentru că, coordonatele  $x_i$  ale soluției  $\mathbf{x}$  se calculează independent unele de altele. (Pentru alt mod de calcul – v. metoda Metoda Gauss\_Seidel, mai jos.)

*Condiție suficientă de convergență:*

Matricea  $\mathbf{A}$  este *diagonal dominantă*, adică avem:

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

■

## 5.2 Metoda Gauss\_Seidel

Se modifică metoda Jacobi, astfel că, la calculul coordonatei  $x_i^{(m)}$  se utilizează valorile  $x_1^{(m)}$ , ...,  $x_{i-1}^{(m)}$  deja calculate, care în general, sunt aproximații mai bune ale soluției.

Pentru [exemplul anterior](#):

$$x_1^{(1)} = 1 - (1/8)x_2^{(0)} + (1/8)x_3^{(0)}$$

$$x_2^{(1)} = 4/7 + (1/7)x_1^{(1)} + (2/7)x_3^{(0)}$$

$$x_3^{(1)} = 12/9 - (2/9)x_1^{(1)} - (1/9)x_2^{(1)}$$

Cu  $\mathbf{x}^{(0)} = [0 \ 0 \ 0]^T$  și aceeași toleranță  $1E-6$ , la iterația 9, se obține soluția (1.0, 1.0, 1.0).

Rezidualul maxim este 0.0.

■

Formulele generale ale metodei Gauss-Seidel sunt:

$$\begin{cases} \mathbf{x}^{(0)} = \text{arbitrar} \\ x_i^{(m+1)} = (b_i - \sum_{j=1}^{i-1} a_{ij}x_j^{(m+1)} - \sum_{j=i+1}^n a_{ij}x_j^{(m)}) / a_{ii}, \quad i = 1, 2, \dots, n; \quad m \geq 0 \end{cases}$$

Testul de oprire a iterației este  $\|\mathbf{x}^{(m+1)} - \mathbf{x}^{(m)}\|_{\infty} \leq \text{eps}$ .

Metoda Gauss-Seidel se mai zice metoda “iterațiilor succesive”, pentru că la un pas  $m+1$ ,  $m \geq 0$ , de îndată ce o coordonată  $x_j^{(m+1)}$  a soluției este calculată, ea se utilizează în ecuațiile pentru coordonatele următoare  $x_i^{(m+1)}$ ,  $i > j$ .

*Condiții suficiente de convergență:*

- Matricea **A** este *diagonal dominantă*.
- Matricea **A** este *simetrică și pozitiv definită*.

Când ambele metode Jacobi și Gauss-Seidel converg, metoda Gauss-Seidel converge mai rapid. Pentru alte considerații privind convergența, v. Cap. 4-IV.

### 5.3 SOR - Metoda relaxării (Successive Over-Relaxation).

Reluăm formula metodei [Gauss-Seidel](#):

$$x_i^{(m+1)} = (b_i - \sum_{j=1}^{i-1} a_{ij} x_j^{(m+1)} - \sum_{j=i+1}^n a_{ij} x_j^{(m)}) / a_{ii}, \quad i = 1, 2, \dots, n; \quad m \geq 0$$

Formula se pune sub forma următoare, adunând și scăzând  $x_i^{(m)}$  în membrul doi (observați că acum, în a doua sumă, indicele  $j$  ia valori de la  $i$  și nu de la  $i+1$ ):

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

Termenul care se adună la  $x_i^{(m)}$  este diferența  $(x_i^{m+1} - x_i^m)$ . Metoda SOR constă în înmulțirea acestei diferențe cu un factor de accelerare (sau relaxare)  $\omega > 1$ . Întrucât  $\omega > 1$ , metoda se zice *supra-relaxare*. Alegerea lui  $\omega$  se discută mai jos. Formula metodei SOR este deci

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

Explicitând  $x_i^{(m)}$  din a doua sumă, rezultă:

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

Se notează expresia din prima paranteză cu  $z_i^{(m+1)}$  (aceasta este coordonata  $i$  a iteratei  $(m+1)$  din metoda Gauss-Seidel.)

Formula de iterare este echivalentă cu următoarele ecuații considerate pentru  $i = \overline{1, n}$ :

$$z_i^{(m+1)} = (b_i - \sum_{j=1}^{i-1} a_{ij} x_j^{(m+1)} - \sum_{j=i+1}^n a_{ij} x_j^{(m)}) / a_{ii},$$

$$x_i^{(m+1)} = \omega z_i^{(m+1)} + (1 - \omega) x_i^{(m)}$$

În cele mai multe cazuri, valoarea optimă a lui  $\omega$  satisface relația

$$1 < \omega < 2.$$

În practică, se poate alege  $\omega$  astfel: se utilizează valori  $\omega$  de test, pe un număr limitat de iterații; se alege ca valoare optimă acel  $\omega$ , pentru care convergența este cea mai rapidă.

## 6. STABILITATEA SOLUȚIEI ȘI CONDIȚIONAREA SISTEMULUI

Se consideră sistemul de  $n$  ecuații liniare

$$\mathbf{Ax} = \mathbf{b} \quad (1)$$

cu  $\mathbf{A}$  = nesingulară. Se va analiza stabilitatea soluției sistemului, în raport cu o mică variație (perturbare), în:

- Termenii liberi  $\mathbf{b}$
- Matricea  $\mathbf{A}$  a sistemului

Prima problemă conduce la numărul de condiție al matricii  $\mathbf{A}$ . A doua problemă va conduce la o evaluare a variației soluției, în care intervine numărul de condiție.

### 6.1 Perturbare în $\mathbf{b}$ . Număr de condiție

Fie sistemul (1), în care termenii liberi  $\mathbf{b}$  suferă o perturbare  $\mathbf{r}$ , devenind  $\tilde{\mathbf{b}}$ , unde

$\mathbf{r} = \tilde{\mathbf{b}} - \mathbf{b}$ , și  $\|\mathbf{r}\| \ll \|\mathbf{b}\|$ . Sistemul perturbat va fi:

$$\mathbf{A}\tilde{\mathbf{x}} = \tilde{\mathbf{b}} \quad (2)$$

Notând perturbarea soluției prin  $\mathbf{e} = \tilde{\mathbf{x}} - \mathbf{x}$ , și scăzând (1) din (2) rezultă:

$$\mathbf{A}\mathbf{e} = \mathbf{r}, \quad (3)$$

din care avem și:

$$\mathbf{e} = \mathbf{A}^{-1}\mathbf{r} \quad (3').$$

Pentru a examina stabilitatea soluției  $\mathbf{x}$ , căutăm o evaluare a raportului

$$\frac{\|\mathbf{e}\| / \|\mathbf{x}\|}{\|\mathbf{r}\| / \|\mathbf{b}\|} = \frac{\text{perturbarea relativă în } \mathbf{x}}{\text{perturbarea relativă în } \mathbf{b}}.$$



Acest raport exprimă efectul perturbării în  $\mathbf{b}$  asupra soluției  $\mathbf{x}$ , și anume: După cum raportul este  $\approx 1$ , respectiv  $\gg 1$ , perturbarea relativă a soluției este de același ordin, respectiv de ordin mult mai mare, în raport cu perturbarea relativă în  $\mathbf{b}$ .

Luând norma în (3), (3') avem:

$$\|\mathbf{r}\| \leq \|\mathbf{A}\| \cdot \|\mathbf{e}\|, \quad \|\mathbf{e}\| \leq \|\mathbf{A}^{-1}\| \cdot \|\mathbf{r}\|,$$

din care, rezultă:

$$\frac{1}{\|\mathbf{A}\|} \leq \frac{\|\mathbf{e}\|}{\|\mathbf{r}\|} \leq \|\mathbf{A}^{-1}\| \quad (4)$$

Înmulțind (4) cu  $\|\mathbf{b}\| / \|\mathbf{x}\|$ , rezultă:

$$\frac{1}{\|\mathbf{A}\|} \cdot \frac{\|\mathbf{b}\|}{\|\mathbf{x}\|} \leq \frac{\|\mathbf{e}\| / \|\mathbf{x}\|}{\|\mathbf{r}\| / \|\mathbf{b}\|} \leq \|\mathbf{A}^{-1}\| \cdot \frac{\|\mathbf{b}\|}{\|\mathbf{x}\|} \quad (5)$$

Analog, luând norma în (1) și în  $\mathbf{x} = \mathbf{A}^{-1} \cdot \mathbf{b}$ , rezultă:

$$\frac{1}{\|\mathbf{A}^{-1}\|} \leq \frac{\|\mathbf{b}\|}{\|\mathbf{x}\|} \leq \|\mathbf{A}\| \quad (6)$$

Din (5) și (6) rezultă:

$$\frac{1}{\|\mathbf{A}\| \cdot \|\mathbf{A}^{-1}\|} \leq \frac{\|\mathbf{e}\| / \|\mathbf{x}\|}{\|\mathbf{r}\| / \|\mathbf{b}\|} \leq \|\mathbf{A}\| \cdot \|\mathbf{A}^{-1}\| \quad (7)$$

Introducem următoarea

### **Definiție**

*Numărul de condiție* al matricii  $\mathbf{A}$ , este:

$$\text{Cond}(\mathbf{A}) = \|\mathbf{A}\| \cdot \|\mathbf{A}^{-1}\| \quad \blacksquare \quad (8)$$

Numărul de condiție depinde de normă, dar este *mărginit inferior* de 1:

$$\text{Cond}(\mathbf{A}) \geq 1 \quad (9)$$

Într-adevăr, din  $\mathbf{I} = \mathbf{A}\mathbf{A}^{-1}$  rezultă:  $1 \leq \|\mathbf{A}\| \cdot \|\mathbf{A}^{-1}\| = \text{Cond}(\mathbf{A}) \quad \blacksquare$

Cu definiția (8), din (7) rezultă:

$$\frac{1}{\text{Cond}(\mathbf{A})} \leq \frac{\|\mathbf{e}\| / \|\mathbf{x}\|}{\|\mathbf{r}\| / \|\mathbf{b}\|} \leq \text{Cond}(\mathbf{A}) \quad (10)$$

Sau:

$$\frac{1}{\text{Cond}(\mathbf{A})} \cdot \frac{\|\mathbf{r}\|}{\|\mathbf{b}\|} \leq \frac{\|\mathbf{e}\|}{\|\mathbf{x}\|} \leq \text{Cond}(\mathbf{A}) \cdot \frac{\|\mathbf{r}\|}{\|\mathbf{b}\|} \quad (10')$$

Din această relație rezultă că, pentru  $\|\mathbf{r}\| / \|\mathbf{b}\| = \text{'mic'}$ , avem:

- Dacă  $\text{Cond}(\mathbf{A}) \sim 1$ :  $\|\mathbf{e}\| / \|\mathbf{x}\|$  este 'mic', și  $\mathbf{A}$  este *bine-condiționată*.
- Dacă  $\text{Cond}(\mathbf{A}) \gg 1$ :  $\|\mathbf{e}\| / \|\mathbf{x}\|$  poate fi 'mare';  $\mathbf{A}$  este *rău-condiționată*.

Întrucât în Definiția (8)  $\text{Cond}(\mathbf{A})$  depinde de normă, se utilizează și un alt număr de condiție care este independent de normă. Avem  $\|\mathbf{A}\| \geq \rho(\mathbf{A})$ , unde  $\rho(\mathbf{A})$  este raza spectrală a matricii  $\mathbf{A}$ ; urmează:

$$\text{Cond}(\mathbf{A}) \geq \rho(\mathbf{A}) \cdot \rho(\mathbf{A}^{-1})$$

Sau, definind

$$\text{Cond}(\mathbf{A})_* = \rho(\mathbf{A}) \cdot \rho(\mathbf{A}^{-1}) \quad (11)$$

avem

$$\text{Cond}(\mathbf{A}) \geq \text{Cond}(\mathbf{A})_*$$

Cum valorile proprii ale matricii  $\mathbf{A}^{-1}$  sunt inversele valorilor proprii ale lui  $\mathbf{A}$ , notând cu  $\sigma(\mathbf{A})$  spectrul matricii  $\mathbf{A}$ , rezultă formula de calcul:

$$\text{Cond}(\mathbf{A})_* = \frac{\max_{\lambda \in \sigma(\mathbf{A})} |\lambda|}{\min_{\lambda \in \sigma(\mathbf{A})} |\lambda|} \quad (11')$$

*Observații asupra calculului lui  $\text{Cond}(\mathbf{A})_2$*

După definiție, avem

$$\text{Cond}(\mathbf{A})_2 = \|\mathbf{A}\|_2 \cdot \|\mathbf{A}^{-1}\|_2$$

Cu  $\mathbf{B} = \mathbf{A}^T \mathbf{A}$ , valorile proprii ale lui  $\mathbf{B}$  sunt reale și pozitive, și avem  $\|\mathbf{A}\|_2 = (\lambda_{B, \max})^{1/2}$  (v. 4-I, 3.3 – Observații și Cap. 5).

Analog, cu  $\mathbf{D} = \mathbf{A}^{-T} \mathbf{A}^{-1}$ , avem  $\|\mathbf{A}^{-1}\|_2 = (\lambda_{D, \max})^{1/2}$ , și rezultă

$$\text{Cond}(\mathbf{A})_2 = (\lambda_{B, \max})^{1/2} (\lambda_{D, \max})^{1/2}.$$

**Putem evita inversarea matricii  $\mathbf{A}$** , conform următoarelor proprietăți:

- Valorile proprii ale lui  $\mathbf{D}$  sunt inversele valorilor proprii ale lui  $\mathbf{D}^{-1} = \mathbf{A} \mathbf{A}^T$ .

Punem  $\mathbf{C} = \mathbf{A} \mathbf{A}^T$ , și astfel,  $\lambda_{D, \max} = 1 / \lambda_{C, \min}$ . Expresia anterioară devine:

$$\text{Cond}(\mathbf{A})_2 = \frac{(\lambda_{B, \max})^{1/2}}{(\lambda_{C, \min})^{1/2}}$$

- Apoi, se arată ușor că  $\mathbf{B} = \mathbf{A}^T \mathbf{A}$  și  $\mathbf{C} = \mathbf{A} \mathbf{A}^T$  au *același valori proprii* (Exercițiu).

Urmează că, în final avem:

$$\text{Cond}(\mathbf{A})_2 = \left( \frac{\lambda_{B, \max}}{\lambda_{B, \min}} \right)^{1/2}$$

Aceasta se mai scrie:  $\text{Cond}(\mathbf{A})_2 = (\text{Cond}(\mathbf{B})_*)^{1/2}$  ■

### Exemplu – 1

Fie sistemul liniar:

$$8x_1 + 9x_2 = b_1$$

$$7x_1 + 8x_2 = b_2$$

Avem:

$$\mathbf{A} = \begin{bmatrix} 8 & 9 \\ 7 & 8 \end{bmatrix}, \quad \mathbf{A}^{-1} = \begin{bmatrix} 8 & -9 \\ -7 & 8 \end{bmatrix}$$

Numerele de condiție, după diferite norme, sunt:

$$\text{Cond}(\mathbf{A})_\infty = \text{Cond}(\mathbf{A})_1 = 289,$$

$$\text{Cond}(\mathbf{A})_2 \approx 258,$$

$$\text{Cond}(\mathbf{A})_* \approx 254$$

a) Detalii pentru calculul lui  $\text{Cond}(\mathbf{A})_*$ :

Polinomul caracteristic al lui  $\mathbf{A}$ , este  $p(\lambda) = \lambda^2 - 16\lambda + 1$ , de unde  $\lambda_{1,2} = 8 \pm \sqrt{63}$ . Urmează

$$\text{Cond}(\mathbf{A})_* = \lambda_1 / \lambda_2 \approx 254.$$

b) Detalii pentru calculul lui  $\text{Cond}(\mathbf{A})_2$ :

$$\mathbf{B} = \mathbf{A}^T \mathbf{A} = \begin{bmatrix} 8 & 7 \\ 9 & 8 \end{bmatrix} \begin{bmatrix} 8 & 9 \\ 7 & 8 \end{bmatrix} = \begin{bmatrix} 113 & 128 \\ 128 & 145 \end{bmatrix}. \text{ Polinomul caracteristic al lui } \mathbf{B}, \text{ este}$$

$$p(\lambda) = \lambda^2 - 258\lambda + 1. \text{ Avem } \lambda_{1,2} = 129 \pm \sqrt{129^2 - 1}, \lambda_1 / \lambda_2 = (\lambda_1)^2. \text{ Rezultă}$$

$$\text{Cond}(\mathbf{A})_2 = \lambda_1 \approx 258.$$

Se verifică, în particular, observația anterioară:  $\mathbf{C} = \mathbf{A}\mathbf{A}^T = \begin{bmatrix} 145 & 128 \\ 128 & 113 \end{bmatrix}$ , are același polinom caracteristic ca și  $\mathbf{B}$ .

Exercițiu: Calculați  $\text{Cond}(\mathbf{A})_2$ , direct după definiția (8).

■

Întrucât numărul de condiție este mare, aceasta arată că sistemul este sensibil la mici schimbări în  $\mathbf{b}$ . Într-adevăr, fie de exemplu, termenii liberi dați și perturbați, și soluțiile respective, cum urmează:

$$\mathbf{b} = \begin{bmatrix} 17 \\ 15 \end{bmatrix}; \quad \tilde{\mathbf{b}} = \begin{bmatrix} 16.9 \\ 15.1 \end{bmatrix}; \quad \mathbf{r} = \tilde{\mathbf{b}} - \mathbf{b} = \begin{bmatrix} -0.1 \\ 0.1 \end{bmatrix}.$$

$$\mathbf{x} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}; \quad \tilde{\mathbf{x}} = \begin{bmatrix} -0.7 \\ 2.5 \end{bmatrix}; \quad \mathbf{e} = \tilde{\mathbf{x}} - \mathbf{x} = \begin{bmatrix} -1.7 \\ 1.5 \end{bmatrix}.$$

Cu acestea, rezultă:

$$\frac{\|\mathbf{r}\|_\infty}{\|\mathbf{b}\|_\infty} = \frac{0.1}{17}, \quad \frac{\|\mathbf{e}\|_\infty}{\|\mathbf{x}\|_\infty} = \frac{1.7}{1} = 1.7, \quad \frac{\|\mathbf{e}\|_\infty / \|\mathbf{x}\|_\infty}{\|\mathbf{r}\|_\infty / \|\mathbf{b}\|_\infty} = \frac{1.7}{0.1/17} = 289.$$

Se observă că schimbări “mici” în  $\mathbf{b}$  produc schimbări ”mari” în  $\mathbf{x}$ : perturbarea relativă în  $\mathbf{x}$  este de 289 ori mai mare decât perturbarea relativă în  $\mathbf{b}$ .

În particular, în acest exemplu, marginea superioară din (10) este atinsă – conform  $Cond(\mathbf{A})_{\infty} = 289$ .

Un asemenea sistem se zice **rău-condiționat**. Se observă că numerele  $Cond(\mathbf{A})$  și  $Cond(\mathbf{A})_*$  sunt o măsură bună pentru condiționarea sistemului.

### Exemplu – 2

Există sisteme care nu sunt rău-condiționate, deși  $Cond(\mathbf{A})$  este mare. De exemplu, să considerăm următoarea matrice, în care  $m$  este un întreg  $\geq 1$ :

$$\mathbf{A} = \begin{bmatrix} 1 & 0 \\ 0 & 10^{-m} \end{bmatrix}; \quad \mathbf{A}^{-1} = \begin{bmatrix} 1 & 0 \\ 0 & 10^m \end{bmatrix}.$$

Avem  $Cond(\mathbf{A})_{1,\infty} = Cond(\mathbf{A})_* = 10^m$ . Totuși sistemul este bine-condiționat. Valoarea mare a numărului de condiție se elimină prin scalarea matricii  $\mathbf{A}$ .

### Exemplu – 3: Interpretare geometrică a condiționării sistemului

Considerăm sistemul următor:


$$x + y = 2$$

$$1.1x + y = 2.1$$

care are soluția  $x = y = 1.0$ . Numerele de condiție sunt:

$$Cond(\mathbf{A})_1 = Cond(\mathbf{A})_{\infty} = 44.10, \quad Cond(\mathbf{A})_2 \approx 42.08, \quad Cond(\mathbf{A})_* \approx 41.98,$$

astfel că sistemul este rău-condiționat. Rezolvarea sistemului revine la găsirea intersecției dreptelor reprezentate de cele două ecuații.



Sistem rău condiționat: Interpretare geometrică

Pantele celor două drepte sunt respectiv  $-1.0$  și  $-1.1$ , adică apropiate. Dacă considerăm o incertitudine în coeficienții sistemului, banda de incertitudine a rădăcinii va fi ‘largă’ – și cu atât mai largă cu cât pantele sunt mai apropiate. Vezi Figura de mai sus: incertitudinea în valorile  $y(x)$  este reprezentată de linia ‘groasă’ a graficului. În schimb, dacă pantele sunt diferite, intersecția dreptelor este netă și banda de incertitudine este ‘îngustă’.

#### Exemplu – 4: Matricea Hilbert

Un exemplu de matrice rău-condiționată este următoarea matrice numită matricea Hilbert:

$$\mathbf{H}_n = \begin{bmatrix} 1 & \frac{1}{2} & \frac{1}{3} & \dots & \frac{1}{n} \\ \frac{1}{2} & \frac{1}{3} & \frac{1}{4} & \dots & \frac{1}{n+1} \\ \vdots & & & & \vdots \\ \frac{1}{n} & \frac{1}{n+1} & \frac{1}{n+2} & \dots & \frac{1}{2n-1} \end{bmatrix}$$

Inversa matricii  $\mathbf{H}_n$  este cunoscută analitic, și anume: punând  $\mathbf{H}_n^{-1} = [\alpha_{ij}^{(n)}]$ , avem – v.

Atkinson (1978), Ralston & Rabinowitz (1978):

$$\alpha_{ij}^{(n)} = (-1)^{i+j} \frac{(n+i-1)!(n+j-1)!}{(i+j-1)[(i-1)!(j-1)!]^2 (n-i)!(n-j)!}, \quad \overline{i, j} = \overline{1, n}$$

Numărul de condiție al matricii  $\mathbf{H}_n$  crește cu  $n$ , matricea fiind cu atât mai rău condiționată cu cât  $n$  este mai mare. Exemple:

$n$	$\text{Cond}(\mathbf{H}_n)_1$
3	7.48 E+02
4	2.84 E+04
5	9.44 E+05
6	2.91 E+07
7	9.85 E+08

Ca exemplu, calculând inversa matricii pentru  $n = 4$ , prin eliminare Gauss, cu elementele lui  $\mathbf{H}_4$  reprezentate în simplă precizie, se obține:

$$\hat{\mathbf{H}}_4^{-1} = \begin{bmatrix} 15.99979 & -119.9980 & 239.9954 & -139.9971 \\ -119.9979 & 1199.981 & -2699.957 & 1679.974 \\ 239.9954 & -2699.958 & 6479.907 & -4199.943 \\ -139.9972 & 1679.974 & -4199.943 & 2799.965 \end{bmatrix}$$

Inversa calculată analitic  $\mathbf{H}_4^{-1}$ , are elemente întregi:  $\alpha_{11} = 16, \dots, \alpha_{44} = 2800$ . Calculând numărul de condiție al matricii  $\mathbf{H}_4$ , cu 1-norma, se obține:

$$\text{Cond}(\mathbf{H}_4)_1 = \|\mathbf{H}_4\|_1 \cdot \|\mathbf{H}_4^{-1}\|_1 = (25/12) \cdot 13260 = 28375$$

## 6.2 Perturbare în $\mathbf{A}$ și $\mathbf{b}$

Să presupunem că atât matricea  $\mathbf{A}$  a sistemului, cât și termenul liber  $\mathbf{b}$ , suferă mici schimbări  $\delta\mathbf{A}$ , respectiv,  $\delta\mathbf{b}$ , iar soluția devine  $\mathbf{x} + \delta\mathbf{x}$ :

$$(\mathbf{A} + \delta\mathbf{A})(\mathbf{x} + \delta\mathbf{x}) = \mathbf{b} + \delta\mathbf{b}$$

Avem următoarea

### ***Teoremă***

Presupunem  $\mathbf{A}$  nesingulară și fie perturbarea  $\delta\mathbf{A}$  satisfăcând condiția

$$\|\delta\mathbf{A}\| < 1 / \|\mathbf{A}^{-1}\|.$$

Atunci:

$$\frac{\|\delta\mathbf{x}\|}{\|\mathbf{x}\|} \leq \frac{\text{Cond}(\mathbf{A})}{1 - \text{Cond}(\mathbf{A}) \cdot \|\delta\mathbf{A}\| / \|\mathbf{A}\|} \left( \frac{\|\delta\mathbf{A}\|}{\|\mathbf{A}\|} + \frac{\|\delta\mathbf{b}\|}{\|\mathbf{b}\|} \right) \quad (12)$$

■

Pentru demonstrație – v. Atkinson (1978), Ralston & Rabinowitz (1978).

În particular, dacă  $\delta\mathbf{b} = 0$ , atunci efectul unei perturbări în  $\mathbf{A}$  este dat de:

$$\frac{\|\delta\mathbf{x}\|}{\|\mathbf{x}\|} \leq \frac{\text{Cond}(\mathbf{A})}{1 - \text{Cond}(\mathbf{A}) \cdot \|\delta\mathbf{A}\| / \|\mathbf{A}\|} \cdot \frac{\|\delta\mathbf{A}\|}{\|\mathbf{A}\|} \quad (13)$$

■

În ceea ce urmează vom da rezultate privind efectul erorilor de rotunjire asupra soluției calculate prin eliminarea Gauss.

Rezultatul (13) va fi utilizat în estimarea *a priori* a erorii în eliminarea Gauss.