

## CURS 4

### METODE NUMERICE PENTRU PROBLEMA DE VALORI PROPRII

---

#### Partea I

1. Definiții, proprietăți.
2. Metoda puterii și variante ale acesteia. Metoda iterațiilor simultane.
3. Metoda Jacobi.

## 1 Valori și vectori proprii

### 1.1 Valori și vectori proprii. Polinom caracteristic. Subspațiu propriu.

Fie dată matricea  $\mathbf{A}$   $n \times n$ , reală sau complexă.

*Definiție*

Dacă vectorul  $\mathbf{x} \neq \mathbf{0}$  și scalarul  $\lambda$  satisfac relația

$$\mathbf{Ax} = \lambda \mathbf{x}, \quad (1)$$

atunci:  $\lambda$  se numește *valoare proprie*, iar  $\mathbf{x}$  *vectorul propriu* asociat lui  $\lambda$  ■

Dacă  $\mathbf{x}$  și  $\mathbf{y}$  sunt asociați cu  $\lambda$ , atunci și  $\alpha\mathbf{x} + \beta\mathbf{y}$ ,  $\alpha, \beta$  scalari, este asociat lui  $\lambda$ .

Dacă  $\mathbf{P}$  este o matrice  $n \times n$  nesingulară, matricea

$$\mathbf{A}' = \mathbf{P}^{-1} \mathbf{AP}$$

se zice *similară* cu  $\mathbf{A}$ .  $\mathbf{P}$  se zice matrice de transformare.

*Propoziție*

- Matricile similare au aceleași valori proprii.
- Dacă  $\mathbf{x}'$  sunt vectorii proprii ai lui  $\mathbf{A}'$ , vectorii proprii  $\mathbf{x}$  ai lui  $\mathbf{A}$  se găsesc din relația  $\mathbf{x} = \mathbf{Px}'$  ■

(Într-adevăr: dacă  $\mathbf{Ax} = \lambda \mathbf{x}$ , rezultă  $\mathbf{P}^{-1} \mathbf{Ax} = \lambda \mathbf{P}^{-1} \mathbf{x}$ , sau  $\mathbf{P}^{-1} \mathbf{AP}(\mathbf{P}^{-1} \mathbf{x}) = \lambda(\mathbf{P}^{-1} \mathbf{x})$ ; cu

$$\mathbf{x}' = \mathbf{P}^{-1} \mathbf{x}, \text{ rezultă } \mathbf{A}' \mathbf{x}' = \lambda \mathbf{x}' .)$$

Mai multe metode numerice transformă matricea  $\mathbf{A}$  într-o matrice similară  $\mathbf{A}'$ , de o formă mai simplă, determinând valorile proprii și vectorii proprii ai matricii  $\mathbf{A}'$ ; apoi, se determină vectorii proprii ai lui  $\mathbf{A}$ , cu relația de mai sus.

### Polinomul caracteristic

Relația (1) este ecuația din care se găsesc  $\lambda$  și  $\mathbf{x}$ . Aceasta se mai scrie

$$(\mathbf{A} - \lambda \mathbf{I})\mathbf{x} = \mathbf{0} \quad (2)$$

unde  $\mathbf{I}$  este matricea unitate. Explicit,

$$\begin{bmatrix} a_{11} - \lambda & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} - \lambda & \dots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \dots & a_{nn} - \lambda \end{bmatrix} \cdot \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad (2')$$

Condiția ca (2) să aibă soluții netriviale  $\mathbf{x}$ , este  $\det(\mathbf{A} - \lambda \mathbf{I}) = 0$ . Explicit,

$$p(\lambda) = \begin{vmatrix} a_{11} - \lambda & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} - \lambda & \dots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \dots & a_{nn} - \lambda \end{vmatrix} = 0 \quad (3)$$

$p(\lambda)$  se zice *polinomul caracteristic* al matricii  $\mathbf{A}$ , și  $p(\lambda) = 0$  – ecuația caracteristică.

Fie determinantul desvoltat:

$$p(\lambda) = (-1)^n \lambda^n + c_1 \lambda^{n-1} + \dots + c_{n-1} \lambda + c_n \quad (3')$$

Din (3, 3') și relațiile între coeficienți și rădăcini, rezultă următoarele proprietăți ale coeficienților și valorilor proprii:

1) Avem  $p(0) = c_n$ , și din determinant  $p(0) = \det(\mathbf{A})$ ; urmează

$$c_n = \det(\mathbf{A})$$

Pe de altă parte,  $\lambda_1 \lambda_2 \dots \lambda_n = c_n$ , și astfel  $\lambda_1 \lambda_2 \dots \lambda_n = \det(\mathbf{A})$ .

2) Coeficientul lui  $\lambda^{n-1}$  se găsește din termenul

$$(a_{11} - \lambda) \dots (a_{nn} - \lambda) = (-\lambda)^n + (\sum_{i=1}^n a_{ii})(-\lambda)^{n-1} + \dots \text{ Astfel, rezultă:}$$

$$c_1 = (-1)^{n-1} \sum_1^n a_{ii} ;$$

Pe de altă parte, din relațiile între coeficienți și rădăcini avem

$$\lambda_1 + \lambda_2 + \dots + \lambda_n = -\frac{c_1}{(-1)^n}. \text{ În consecință, rezultă}$$

$$\lambda_1 + \lambda_2 + \dots + \lambda_n = \sum_1^n a_{ii} .$$

$$(Tr(\mathbf{A}) = \sum_1^n a_{ii} \text{ se zice urma matricii } \mathbf{A}.)$$

3) În general:

$$c_i = (-1)^{n-i} \times \text{Suma minorilor principali de ordinul } i \text{ ai matricii } \mathbf{A}.$$

### *Observații*

1) Ordonarea valorilor proprii:

Valorile proprii se ordonează în sirul  $\lambda_1, \lambda_2, \dots, \lambda_n$ . În acest sir, o rădăcină multiplă de ordinul  $r$ , se repetă de  $r$  ori. Uzual, valorile proprii se indexează în ordinea descrescătoare a modulului, adică  $|\lambda_1| \geq |\lambda_2| \geq \dots \geq |\lambda_n|$ . Valoarea proprie  $\lambda_1$  se zice *dominantă*. Multimea valorilor proprii  $\{\lambda_i, i = \overline{1, n}\}$  se zice *spectrul* matricii  $\mathbf{A}$ .

2) Vectorii proprii asociați unei valori proprii:

După determinarea valorilor proprii, vectorii proprii asociați cu  $\lambda_i$  se găsesc punând  $\lambda = \lambda_i$  în (2'), și rezolvând sistemul liniar și omogen (2').

- Dacă  $\mathbf{A}$  este reală: În general,  $\lambda_i$  poate fi complex, și atunci vectorul propriu  $\mathbf{x}_i$  asociat cu  $\lambda_i$  este complex. Dacă  $\mathbf{A}$  și  $\lambda_i$  sunt reali, atunci vectorul propriu  $\mathbf{x}_i$  este real.
- Dacă  $\mathbf{A}$  este complexă: În general, valorile proprii și vectorii proprii sunt mărimi complexe. În particular, unele dintre acestea pot fi și reale.



### **Subspațiu propriu și dimensiunea acestuia**

Sistemul (2') este omogen, astfel că dacă  $\mathbf{x}, \mathbf{y}$  sunt soluții, atunci  $\alpha\mathbf{x} + \beta\mathbf{y}$  sunt soluții.

Adică, lui  $\lambda_i$  îi este asociat un subspațiu liniar  $S_i$  de soluții  $\mathbf{x}$ . Se arată că:

Dimensiunea subspațiului  $S_i$  este *mai mică decât sau egală cu* ordinul de multiplicitate a rădăcinii  $\lambda_i$  ■

Dacă  $r_i$  este ordinul de multiplicitate a rădăcinii  $\lambda_i$  și  $p_i$  dimensiunea lui  $S_i$ , avem  $\underline{p_i \leq r_i}$ . Adică, în  $S_i$  există cel mult  $r_i$  vectori liniar independenți.

Dacă  $p_i < r_i$ , valoarea  $\lambda_i$  se zice *defectivă*; în acest caz, și matricea  $\mathbf{A}$  se zice *defectivă*.

( $r_i$  se mai zice *multiplicitate algebrică*, iar  $p_i$  *multiplicitate geometrică*.)

3) Determinarea efectivă a sistemului propriu:

Pentru calculația practică ( $n > 3$ ), nu se recomandă:

- *Calculul direct al valorilor proprii*, prin rezolvarea ecuației caracteristice (3'). Aceasta, datorită faptului că problema calculului rădăcinilor unui polinom este foarte sensibilă la mici perturbații în coeficienți (aceste perturbații apar din erorile de rotunjire).
- *Calculul direct al vectorilor proprii*, din sistemul (2').

Metode numerice pentru găsirea valorilor proprii  $\lambda_i$ , și a vectorilor proprii asociați  $\mathbf{x}^{(i)}$ , sunt prezentate în continuare.

■

#### **Exemplu-1**

Fie matricea:

$$\mathbf{A} = \begin{bmatrix} 1 & 2 & 3 \\ 2 & 3 & 4 \\ 3 & 4 & 5 \end{bmatrix}$$

Polinomul caracteristic este:

$$\begin{bmatrix} 1 - \lambda & 2 & 3 \\ 2 & 3 - \lambda & 4 \\ 3 & 4 & 5 - \lambda \end{bmatrix} = 0$$

Sau cf. (3')

$$p(\lambda) = -\lambda^3 + c_1\lambda^2 + c_2\lambda + c_3 = 0,$$

unde:

$$c_3 = \det(\mathbf{A}) = 1 \cdot (-1) - 2 \cdot (-2) + 3 \cdot (-1) = 0$$

$$c_1 = (-1)^2(1 + 3 + 5) = 9$$

$$c_2 = (-1)^1 \left( \begin{vmatrix} 1 & 2 \\ 2 & 3 \end{vmatrix} + \begin{vmatrix} 1 & 3 \\ 3 & 5 \end{vmatrix} + \begin{vmatrix} 3 & 4 \\ 4 & 5 \end{vmatrix} \right) = -(-1 - 4 - 1) = 6$$

$$p(\lambda) = -\lambda^3 + 9\lambda^2 + 6\lambda = 0$$

De unde:

$$\lambda = 0$$

$$\lambda^2 - 9\lambda - 6 = 0; \lambda = \frac{9 \pm \sqrt{105}}{2} = -0.623475383; 9.62347538$$

Ordonând (descrescător, după module):

$$\lambda_1 = 9.62347538$$

$$\lambda_2 = -0.623475383$$

$$\lambda_3 = 0$$

Vectorii proprii  $\mathbf{x}^{(i)} = \begin{bmatrix} x_1^{(i)} \\ x_2^{(i)} \\ x_3^{(i)} \end{bmatrix}, i = 1, 2, 3$  se determină din sistemul omogen

$$\begin{bmatrix} 1 - \lambda & 2 & 3 \\ 2 & 3 - \lambda & 4 \\ 3 & 4 & 5 - \lambda \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix},$$

în care se înlocuiește  $\lambda = \lambda_i$ .

De exemplu, vectorul propriu nr. 1 se găsește din sistemul:

$$\begin{bmatrix} -8.62347538 & 2 & 3 \\ 2 & -6.62347538 & 4 \\ 3 & 4 & -4.62347538 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}$$

Una dintre coordonate rămâne arbitrară: să alegem de ex.,  $x_1 = 1$ , rezultă

$$2x_2 + 3x_3 = 8.62347538$$

$$4x_2 - 4.62347538x_3 = -3$$

Rezultă (rezolvând în simplă precizie):

$$\mathbf{x}^{(1)} = \begin{bmatrix} 1.0 \\ 1.452934 \\ 1.905869 \end{bmatrix}$$

Orice vector  $\alpha \mathbf{x}^{(1)}$  unde  $\alpha = \text{real}$ , face funcție de vector propriu nr. 1.

Analog, se determină vectorii proprii nr. 2 și 3.

■

## 1.2 Matrici hermitiene și unitare

Operația \* aplicată unui vector sau unei matrici notează *transpus-conjugata*. Astfel:

- Dacă  $\mathbf{x}$  este un vector,  $\mathbf{x}^* = \bar{\mathbf{x}}^T$ .
- Dacă  $\mathbf{A}$ , este o matrice,  $\mathbf{A}^* = \bar{\mathbf{A}}^T$ .

Explicit:  $\mathbf{A} = [a_{ij}]$ ,  $\mathbf{A}^* = [a_{ij}^*]$ , avem:  $a_{ij}^* = \bar{a}_{ji}$ .

În expresiile anterioare, bara notează conjugata:  $\bar{\mathbf{x}} = [\bar{x}_i]$ ;  $\bar{\mathbf{A}} = [\bar{a}_{ij}]$ .

Pentru un vector real, sau o matrice reală, operația \* revine la transpunere:

$$\mathbf{x}^* = \mathbf{x}^T; \quad \mathbf{A}^* = \mathbf{A}^T.$$

În particular, pentru un scalar, operația revine la conjugare:  $s^* = \bar{s}$ .

*Matrici hermitiene*:

Matricea  $\mathbf{A}$  se zice *hermitiană*, dacă  $\mathbf{A}^* = \mathbf{A}$  ■

Exemplu de matrice hermitiană:

$$\mathbf{A} = \begin{bmatrix} 1 & 1-7i & -i \\ 1+7i & 5 & 10-3i \\ i & 10+3i & -2 \end{bmatrix}$$

Remarcați că elementele diagonale sunt reale, iar elementele simetrice sunt conjugate ■

O matrice reală este hermitiană, dacă este simetrică ( $\mathbf{A}^T = \mathbf{A}$ ).

O matrice hermitiană se zice *pozitiv definită*, dacă  $\forall \mathbf{x} \neq \mathbf{0} \quad \mathbf{x}^* \mathbf{A} \mathbf{x} > 0$  ( $\mathbf{x}^* \mathbf{A} \mathbf{x}$  este real) ■

În particular, o matrice reală și simetrică este pozitiv definită, dacă:  $\forall \mathbf{x} \neq 0 \quad \mathbf{x}^T \mathbf{A} \mathbf{x} > 0$ .

*Matrici unitare:*

Matricea  $\mathbf{U}$  se zice *unitară*, dacă  $\mathbf{U}^* \mathbf{U} = \mathbf{I}$ , unde  $\mathbf{I}$  este matricea unitate;  
echivalent,  $\mathbf{U}^{-1} = \mathbf{U}^*$  ■

O matrice *reală* este unitară dacă  $\mathbf{U}^T \mathbf{U} = \mathbf{I}$ , sau  $\mathbf{U}^{-1} = \mathbf{U}^T$ .

Valorile proprii ale unei matrici unitare au modulul egal cu 1.

Exemplu de matrice unitară (reală):

Matricea de rotație a axelor în plan este unitară:

$$\mathbf{A} = \begin{bmatrix} \cos\alpha & \sin\alpha \\ -\sin\alpha & \cos\alpha \end{bmatrix}$$

Într-adevăr, avem  $\mathbf{A}^T = \begin{bmatrix} \cos\alpha & -\sin\alpha \\ \sin\alpha & \cos\alpha \end{bmatrix}$ , și se verifică imediat că  $\mathbf{A}^T \mathbf{A} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$ . ■

*Proprietăți ale matricilor hermitiene (în particular, reale și simetrice):*

**P1.** Dacă  $\mathbf{A}$  este hermitiană, și are valorile proprii  $\{\lambda_i\}$  distințe sau nu, atunci:

(a) Există o matrice unitară  $\mathbf{U}$ , astfel că  $\mathbf{U}^* \mathbf{A} \mathbf{U}$  este diagonală:

$$\mathbf{U}^* \mathbf{A} \mathbf{U} = \text{diag}(\lambda_1, \dots, \lambda_n).$$

(se zice că  $\mathbf{U}$  diagonalizează pe  $\mathbf{A}$ .)

- (b) Există  $n$  vectorii proprii liniar independenți care formează o bază ortonormată în  $\mathbf{C}^n$  (aceștia sunt coloanele lui  $\mathbf{U}$ );
- (c) Valorile proprii sunt *reale* ■

În particular, pentru  $\mathbf{A}$  reală și simetrică:

- (a-1) Există  $\mathbf{U}$  unitară și reală, astfel că  $\mathbf{U}^T \mathbf{A} \mathbf{U} = \text{diag}(\lambda_1, \dots, \lambda_n)$ .
- (b-1) Există  $n$  vectorii proprii liniar independenți; aceștia formează o bază ortonormată în  $\mathbf{R}^n$  (coloanele lui  $\mathbf{U}$ );
- (c-1) Valorile proprii sunt *reale*, și vectorii proprii sunt reali ■

Avem și proprietatea:

**P1'.** Dacă  $\mathbf{A}$  este hermitiană (reală și simetrică) și pozitiv definită, atunci valorile proprii ale lui  $\mathbf{A}$  sunt *reale* și *pozitive* ■

### 1.3 Produs scalar și proprietăți de ortogonalitate

#### 1.3.1 Spațiu vectorial real $V_n$

Fie  $x$  un vector din  $V_n$ , și  $\mathbf{x}$  matricea coloană a coordonatelor sale într-o bază a lui  $V_n$  ( $x_i \in \mathbf{R}, i = \overline{1, n}$ ).

Dacă matricea  $\mathbf{A}$  reală, este *simetrică și pozitiv definită*, se definește produsul scalar în raport cu matricea  $\mathbf{A}$ , prin:

$$\langle x, y \rangle_A = \mathbf{x}^T \mathbf{A} \mathbf{y} = \mathbf{y}^T \mathbf{A} \mathbf{x}$$

În particular, pentru  $\mathbf{A} = \mathbf{I}$ , acesta devine produsul scalar standard:

$$\langle x, y \rangle = \mathbf{x}^T \mathbf{y} = \mathbf{y}^T \mathbf{x}$$

Avem:  $\langle y, x \rangle_A = \langle x, y \rangle_A$ ;  $\langle y, x \rangle = \langle x, y \rangle$ .

Vectorii  $x$  și  $y$  se zic *ortogonali* (relativ la produsul scalar), dacă  $\langle x, y \rangle_A = 0$ , sau  $\langle x, y \rangle = 0$  ■

Astfel:

- Vectorii  $x$  și  $y$  sunt *ortogonali relativ la matricea  $\mathbf{A}$* , dacă  
 $\mathbf{x}^T \mathbf{A} \mathbf{y} = 0$ , sau  $\mathbf{y}^T \mathbf{A} \mathbf{x} = 0$ .
- Vectorii sunt *ortogonali*, dacă  $\mathbf{x}^T \mathbf{y} = 0$ , sau  $\mathbf{y}^T \mathbf{x} = 0$ .

■

### 1.3.2 Spațiu vectorial complex $V_n$

Fie  $x$  un vector din  $V_n$ , și  $\mathbf{x}$  matricea coloană a coordonatelor într-o bază a lui  $V_n$  ( $x_i \in \mathbf{C}, i = \overline{1, n}$ ).

Dacă  $\mathbf{A}$  este o matrice *hermitiană și pozitiv definită*, se definește produsul scalar în raport cu matricea  $\mathbf{A}$ , prin:

$$\langle x, y \rangle_A = \mathbf{x}^T \mathbf{A} \bar{\mathbf{y}} = \mathbf{y}^* \mathbf{A}^T \mathbf{x}.$$

(Ultima egalitate rezultă din aceea că scalarul  $s = \langle x, y \rangle_A$  este egal cu transpusul său).

Produsul scalar definit de  $\mathbf{A} = \mathbf{I}$  este:

$$\langle x, y \rangle = \mathbf{x}^T \bar{\mathbf{y}} = \mathbf{y}^* \mathbf{x}$$

Avem:  $\langle y, x \rangle_A = \overline{\langle x, y \rangle_A}$ , și  $\langle y, x \rangle = \overline{\langle x, y \rangle}$ .

Ortogonalitatea a doi vectori se definește ca înainte, prin condiția  $\langle x, y \rangle_A = 0$ , sau  $\langle x, y \rangle = 0$  ■

*Observație:* Dacă avem  $\langle x, y \rangle_A = 0$ , avem și  $\langle y, x \rangle_A = 0$  ■

Astfel:

- Vectorii  $\mathbf{x}, \mathbf{y}$  sunt *ortogonali în raport cu  $\mathbf{A}$* , dacă:

$$\mathbf{x}^T \mathbf{A} \bar{\mathbf{y}} = 0, \text{ sau } \mathbf{y}^* \mathbf{A}^T \mathbf{x} = 0.$$

- Vectorii  $\mathbf{x}, \mathbf{y}$  sunt *ortogonali*, dacă:

$$\mathbf{x}^T \bar{\mathbf{y}} = 0, \text{ sau } \mathbf{y}^* \mathbf{x} = 0.$$

**P2.** Dacă  $\mathbf{A}$  este hermitiană, atunci:

- Vectorii proprii asociati la două valori proprii distincte sunt *ortogonali*: dacă  $\lambda_1 \neq \lambda_2$ , atunci  $\mathbf{x}_2^* \mathbf{x}_1 = 0$  și  $\mathbf{x}_1^* \mathbf{x}_2 = 0$ .
- Avem și:  $\mathbf{x}_2^* \mathbf{A} \mathbf{x}_1 = 0, \mathbf{x}_1^* \mathbf{A} \mathbf{x}_2 = 0$ .

(Dacă  $\mathbf{A}$  hermitiană este și pozitiv definită, vectorii  $\mathbf{x}_1, \mathbf{x}_2$  sunt *ortogonali relativ la matricea  $\mathbf{A}^T$* .)

■

Dacă  $\mathbf{A}$  este reală și simetrică:

- Vectorii proprii asociati la două valori proprii *distincte* sunt *ortogonali*:  $\mathbf{x}_2^T \mathbf{x}_1 = 0, \mathbf{x}_1^T \mathbf{x}_2 = 0$ .
- Avem și:  $\mathbf{x}_2^T \mathbf{A} \mathbf{x}_1 = 0, \mathbf{x}_1^T \mathbf{A} \mathbf{x}_2 = 0$ .

(Dacă  $\mathbf{A}$  reală și simetrică, este și pozitiv definită, vectorii  $\mathbf{x}_1, \mathbf{x}_2$  sunt *ortogonali relativ la matricea  $\mathbf{A}$* )

■

#### 1.4 Câțul Rayleigh

Fie  $\mathbf{A}$  o matrice  $n \times n$  complexă (sau reală). Fie  $\mathbf{v} \in \mathbf{C}^n$  un vector arbitrar, și definim

$$\rho(\mathbf{v}) = \frac{\mathbf{v}^* \mathbf{A} \mathbf{v}}{\mathbf{v}^* \mathbf{v}}$$

$\rho(\mathbf{v})$  se numește *câțul Rayleigh*.

*Proprietate-1:*

Dacă  $\mathbf{x}$  este vector propriu asociat cu  $\lambda$ , atunci  $\rho(\mathbf{x}) = \lambda$  ■

Astfel, câtul Rayleigh poate fi utilizat pentru a găsi o aproximare a valorii proprii  $\lambda$ , dacă se cunoaște o aproximare  $\mathbf{v}$  a vectorului propriu  $\mathbf{x}$ :  $\mathbf{v} \approx \mathbf{x} \Rightarrow \lambda \approx \rho(\mathbf{v})$ .

*Proprietate-2:*

Dacă matricea este hermitiană, câtul Rayleigh este mărginit de valorile proprii extreme ■

Valorile proprii sunt reale; fie acestea  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$ , atunci, avem:

$$\lambda_n \leq \rho(\mathbf{v}) \leq \lambda_1, \text{ pentru orice } \mathbf{v} \in \mathbf{C}^n.$$

## 2 Metoda puterii

### 2.1 Metoda puterii

Metoda puterii determină valoarea proprie dominantă și vectorul propriu asociat, ale unei matrici  $\mathbf{A}$ , reale sau complexe.

Aplicată la inversa  $\mathbf{A}^{-1}$  metoda determină valoarea proprie cea mai mică (în modul), și vectorul propriu asociat cu aceasta. Aceasta, conform proprietății:

Matricea  $\mathbf{A}^{-1}$  are ca valori proprii inversele valorilor proprii ale lui  $\mathbf{A}$  și aceiași vectori proprii.

Într-adevăr: din  $\mathbf{Ax} = \lambda\mathbf{x}$ , înmulțind la stânga cu  $\mathbf{A}^{-1}$ , rezultă  $\mathbf{x} = \lambda\mathbf{A}^{-1}\mathbf{x}$ , sau

$$\mathbf{A}^{-1}\mathbf{x} = \frac{1}{\lambda}\mathbf{x}. \text{ Explicit: } \mathbf{A} : \{\lambda_1, \dots, \lambda_n\}; \mathbf{A}^{-1} : \{\mu_1, \dots, \mu_n\}. \text{ Avem:}$$

$$\lambda_n = \frac{1}{\mu_1}, \dots, \lambda_1 = \frac{1}{\mu_n}.$$

■

*Ipotezele* metodei puterii:

- Există un set de  $n$  vectori proprii *liniar independenți*.
- Există o singură valoare proprie dominantă  $\lambda_1$ :

$$|\lambda_1| > |\lambda_2| \geq \dots \geq |\lambda_n|.$$

(Remarcați că prima inegalitate este strictă!)

*Metoda:*

Fie  $\mathbf{w}^{(0)}$  un vector inițial, ales arbitrar – cu singura condiție ca să aibă o componentă în direcția lui  $\mathbf{x}^{(1)}$ . Pentru a împlini această cerință, unele coduri generează un vector aleator. (În fapt,  $\mathbf{w}^{(0)}$  este o aproximare a vectorului propriu  $\mathbf{x}^{(1)}$ ; dacă o astfel de aproximare este cunoscută, atunci aceasta accelerează iterația de mai jos).

Desvoltăm  $\mathbf{w}^{(0)}$  în baza vectorilor proprii:

$$\mathbf{w}^{(0)} = a_1 \mathbf{x}^{(1)} + a_2 \mathbf{x}^{(2)} + \dots + a_n \mathbf{x}^{(n)} \quad (\text{a})$$

Presupunem că  $a_1 \neq 0$  ([condiția](#) de mai sus), și formăm sirul de vectori

$$\mathbf{w}^{(k+1)} = \mathbf{A}\mathbf{w}^{(k)} = \mathbf{A}^{k+1}\mathbf{w}^{(0)}, \quad k \geq 0$$

Avem:

$$\begin{aligned} \mathbf{w}^{(1)} &= \mathbf{A}\mathbf{w}^{(0)} = \lambda_1 a_1 \mathbf{x}^{(1)} + \lambda_2 a_2 \mathbf{x}^{(2)} + \dots + \lambda_n a_n \mathbf{x}^{(n)} \\ &= \lambda_1 \left[ a_1 \mathbf{x}^{(1)} + \left( \frac{\lambda_2}{\lambda_1} \right) a_2 \mathbf{x}^{(2)} + \dots + \left( \frac{\lambda_n}{\lambda_1} \right) a_n \mathbf{x}^{(n)} \right] \end{aligned}$$

În general,

$$\mathbf{w}^{(k)} = \mathbf{A}^k \mathbf{w}^{(0)} = (\lambda_1)^k \left[ a_1 \mathbf{x}^{(1)} + \left( \frac{\lambda_2}{\lambda_1} \right)^k a_2 \mathbf{x}^{(2)} + \dots + \left( \frac{\lambda_n}{\lambda_1} \right)^k a_n \mathbf{x}^{(n)} \right] \quad (\text{b})$$

Cum  $|\lambda_1| > |\lambda_i|$  pentru  $i \geq 2$ , urmează că rapoartele  $(\lambda_i / \lambda_1)^k$  tind la 0 pentru  $k \rightarrow \infty$ . Astfel, pentru  $k$  crescător, vectorii  $\mathbf{w}^{(k)}$  se aliniază din ce în ce mai mult la direcția vectorului propriu  $\mathbf{x}^{(1)}$ . În consecință, pentru un  $k$  suficient de mare, avem  $\mathbf{w}^{(k)} \approx (\lambda_1)^k a_1 \mathbf{x}^{(1)}$ .

Să considerăm de asemenea relația  $\mathbf{w}^{(k+1)} \approx (\lambda_1)^{k+1} a_1 \mathbf{x}^{(1)}$ . Luând orice coordonată non-zero a lui  $\mathbf{w}^{(k+1)}$ ,  $\mathbf{w}^{(k)}$ , să zicem cea de-a  $m$ -a coordonată, obținem

$$\lambda_1 \approx \frac{w_m^{(k+1)}}{w_m^{(k)}}$$

Dezavantajul formulei precedente este că, coordonatele nenule ale lui  $\mathbf{w}^{(k)}$  devin fie foarte mici ( $|\lambda_1| < 1$ ), fie foarte mari ( $|\lambda_1| > 1$ ), odată cu creșterea lui  $k$ . Aceasta se evită prin normalizarea (sau scalarea) lui  $\mathbf{w}^{(k)}$ , la fiecare pas  $k$ . Normele utilizate sunt norma- $\infty$  și norma-2.

Astfel, algoritmul metodei este:

$\mathbf{w}^{(0)}$  = Vector inițial

$$\mathbf{z}^{(k)} = \frac{\mathbf{w}^{(k)}}{\|\mathbf{w}^{(k)}\|}, \text{ pentru } k \geq 0 \dots \text{ Normalizare}$$

$$\mathbf{w}^{(k+1)} = \mathbf{A}\mathbf{z}^{(k)}, \text{ pentru } k \geq 0 \dots \text{ Iterație}$$

### Teste de oprire a iterăției

1. *Test de coliniaritate a doi vectori succesivi.*

Vectorii  $\mathbf{z}^{(k)}$  și  $\mathbf{z}^{(k+1)}$  sunt coliniari, dacă rapoartele  $\rho_i = z_i^{(k+1)} / z_i^{(k)}$ ,  $z_i^{(k)} \neq 0$  sunt egale (coordonatele nenule sunt proporționale), sau  $z_i^{(k+1)} = z_i^{(k)} = 0$ . În calculația practică, punem condiția  $|\rho(i) - \rho(i_0)| \leq TOL$ , dacă  $|z_i^{(k)}| > TOL$ ; sau, să avem simultan,  $|z_i^{(k)}| \leq TOL$  și  $|z_i^{(k+1)}| \leq TOL$ .  $TOL$  este o toleranță specificată;  $i_0$  este indicele unei coordonate fixate: este convenabil să luăm  $i_0 = imax =$  indicele coordonatei de modul maxim din  $\mathbf{z}^{(k+1)}$ .

Se introduc atunci, factorii de coliniaritate prin vectorul **colin**(1 :  $n$ ), definit astfel:

$$\begin{aligned} \text{colin}(i) = & \begin{cases} z^{(k+1)}(imax) / z^{(k)}(imax) & \dots \text{dacă } |z^{(k+1)}(i)| \leq TOL \text{ și } |z^{(k)}(i)| \leq TOL \\ z^{(k+1)}(i) / z^{(k)}(i) & \dots \text{altfel} \end{cases} \\ i = & \overline{1, n} \end{aligned}$$

Testul este:

$$\|\mathbf{colin} - \mathbf{colin}(imax)\| \leq TOL$$

Aceasta înseamnă să avem  $\frac{z_i^{(k+1)}}{z_i^{(k)}} - \frac{z_{imax}^{(k+1)}}{z_{imax}^{(k)}} \approx 0$  (pentru  $z_k^{(k)} \neq 0$ ).

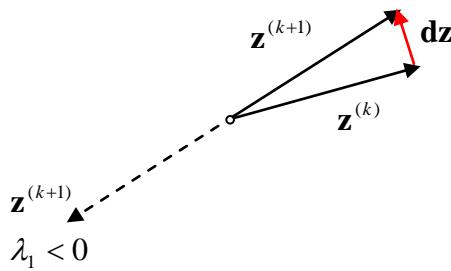
### Observație

*Test pentru norma-2 (euclidiană):*

Dacă, pentru normalizarea lui  $\mathbf{w}^{(k)}$ , se utilizează norma-2, vectorii  $\mathbf{z}^{(k)}$  au norma-2 egală cu 1, și testul de coliniaritate poate lua forma

$$\|\mathbf{z}^{(k+1)} - \mathbf{z}^{(k)}\|_2 \leq TOL.$$

O problemă specială apare pentru  $\mathbf{A}$  reală, dacă valoarea proprie dominantă este reală și negativă,  $\lambda_1 < 0$ , și anume: din  $\mathbf{w}^{(k)} = \mathbf{A}^{(k)} \mathbf{z}^{(0)} = (\lambda_1)^k [a_1 \mathbf{x}^{(1)} + \mathbf{r}^{(k)}]$  și  $\mathbf{z}^{(k)} = \mathbf{w}^{(k)} / \| \mathbf{w}^{(k)} \|$ , rezultă că vectorul  $\mathbf{z}^{(k)}$  schimbă de semn de la pasul  $k$  la pasul  $k+1$ . (Valoarea proprie, dată de  $\lambda_1^{(k+1)} = w_m^{(k+1)} / z_m^{(k)}$ , nu este afectată.).



Testul de coliniaritate trebuie să țină cont de aceasta. Astfel, definim,

$$is = sign(1., \lambda_1^{(k+1)}), \quad \mathbf{dz} = \mathbf{z}^{(k+1)} - is * \mathbf{z}^{(k)}$$

Testul corect este

$$\| \mathbf{dz} \|_2 \leq TOL.$$

■

## 2. Test asupra lui $\lambda$ :

Iterația se oprește prin condiția

$$| \lambda_1^{(k+1)} - \lambda_1^{(k)} | \leq TOL$$

unde  $TOL$  este o toleranță.

## 3. Test de satisfacere a relației de definiție:

$$\| \mathbf{Az} - \lambda \mathbf{z} \| \leq TOL$$

Practic,  $\mathbf{z} = \mathbf{z}^{(k)}$ ,  $\mathbf{Az}^{(k)} = \mathbf{w}^{(k+1)}$ , și  $\lambda = \lambda^{(k+1)}$ . Definind

$$\mathbf{dif} = \mathbf{w}^{(k+1)} - \lambda^{(k+1)} \mathbf{z}^{(k)},$$

se pune testul

$$\|\mathbf{dif}\| \leq TOL$$

*Observații:*

- În cod, dacă valorile anterioare ( $k$ ) sunt stocate în  $z_0$  și  $\lambda_{\text{lambda}0}$ , iar valorile curente ( $k+1$ ) în  $z$  și  $\lambda_{\text{lambda}}$ , definiția lui  $\mathbf{dif}$  devine

$$\mathbf{dif} = z - \lambda_{\text{lambda}} * z_0,$$

luând  $z$  *înainte* de normalizare.

- Vectorul  $\mathbf{r} = \mathbf{Az} - \lambda \mathbf{z}$  se zice *vectorul rezidual*. Astfel, testul se mai scrie

$$\|\mathbf{r}\| \leq TOL.$$

*Note*

- Testul propriu pentru metodă este Testul 1, însă, în esență, metoda determină vectorul propriu nr. 1, și apoi determină  $\lambda_1$  din acesta. Cu Testul 1, se obțin vectori proprii mai preciși decât cu Testul 2 (la aceeași toleranță).
- Testul 3 nu este specific metodei puterii, ci poate fi aplicat oricărei metode iterative pentru valori și vectori proprii. Codurile din Lapack (Bai et al.(2000)), utilizează Testul 3, cu  $TOL = \varepsilon_M |\lambda|$ , unde  $\varepsilon_M$  este  $\varepsilon$ -mașină.

(În metodele din ANA: Testul 3 va fi utilizat numai la verificarea sistemului propriu. Face excepție metoda puterii, unde pentru studiu, se poate alege unul din Testele 1-3; alegerea se face printr-un cod.)

■

**Convergență:**

Convergența  $\lambda_1^{(k)} \rightarrow \lambda_1$  este liniară, iar rata convergenței este aproximativ  $|\lambda_2 / \lambda_1|$ .

(Acest rezultat are loc în ipoteza metodei  $|\lambda_1| > |\lambda_2|$ , cu ipoteza suplimentară: pentru  $k \geq k_1$ , cantitățile  $(\lambda_i / \lambda_2)^k$ ,  $i \geq 3$ , sunt neglijabile în raport cu  $(\lambda_2 / \lambda_1)^k$ .)

## 2.2 Metoda puterii inverse cu translație (shift)

Fie matricea  $\mathbf{A}$ , cu valorile proprii  $\lambda_j$ ,  $j = 1, n$ . Metoda găsește valoarea proprie  $\lambda_i$  a lui  $\mathbf{A}$ , cea mai apropiată de un număr dat  $s$ ; adică,  $|\lambda_i - s| = \text{minim}$ .

Se consideră matricea

$$\mathbf{B} = \mathbf{A} - s\mathbf{I}$$

și presupunem că  $\mathbf{B}$  este nesingulară. Se verifică imediat că valorile proprii ale lui  $\mathbf{B}$  sunt  $\mu_j = \lambda_j - s$ . Cantitatea  $s$  zice *deplasare* sau *translație* (shift).

Fie  $\mu_i = \lambda_i - s$ , valoarea proprie de modul minim a lui  $\mathbf{B}$ , adică:

$$0 < |\mu_i| < \varepsilon < |\mu_j|, \text{ pentru } j \neq i.$$

Atunci, metoda puterii aplicată lui  $\mathbf{B}^{-1}$  produce valoarea proprie de modul maxim, fie aceasta  $\nu_i = 1/\mu_i$  ( $\nu_i$  este valoarea dominantă pentru  $\mathbf{B}^{-1}$ ). Avem  $\mu_i = 1/\nu_i$ , și

$$\lambda_i = \frac{1}{\nu_i} + s.$$

Principala aplicație a metodei este de a găsi vectorul propriu, dacă este cunoscută o aproximare bună a valorii proprii, să zicem  $\hat{\lambda}_i$ . (Aceasta poate fi furnizată de o metodă în care se determină numai valorile proprii – nu și vectorii proprii.)

Se aplică metoda puterii inverse, cu deplasarea  $s = \hat{\lambda}_i$ . Chiar dacă  $\hat{\lambda}_i$  este apropiată de  $\lambda_i$ , matricea  $\mathbf{B} = \mathbf{A} - \hat{\lambda}_i \mathbf{I}$  este încă nesingulară, și se obține o bună aproximare a vectorului propriu  $\mathbf{x}^{(i)}$ .

Metoda iterației inverse cu deplasare, este una dintre cele mai precise metode pentru calculul vectorilor proprii.

Algoritmul practic, este următorul:

Iterația din metoda puterii, aplicată la matricea  $\mathbf{B}^{-1}$ , este

$$\mathbf{w}^{(k+1)} = \mathbf{B}^{-1} \mathbf{z}^{(k)}.$$

În loc de a inversa  $\mathbf{B}$ , calculăm  $\mathbf{w}^{(k+1)}$  din sistemul liniar

$$\mathbf{B}\mathbf{w}^{(k+1)} = \mathbf{z}^{(k)},$$

prin descompunere **LU**. Factorizarea se face o singură dată, și sistemul se rezolvă succesiv cu membrii drepti  $\mathbf{z}^{(k)}$ ,  $k \geq 0$ .

■

### 2.3 Metoda iterațiilor simultane – matrice hermitiană.

Aceasta este o extindere a metodei puterii pentru o matrice **A hermitiană** (în particular, reală și simetrică). O astfel de matrice, are valori proprii reale.

Presupunem, mai mult, că valorile proprii sunt **de module distințe**:

$$|\lambda_1| > |\lambda_2| > \dots > |\lambda_n|.$$

În loc de un vector de start  $\mathbf{w}^{(0)}$ , se utilizează o matrice de start, ale cărei coloane sunt vectorii de start:  $\mathbf{W}^{(0)} = [\mathbf{w}^{(0,1)} \mid \mathbf{w}^{(0,2)} \mid \dots \mid \mathbf{w}^{(0,m)}]$ .

Dacă matricea **A** este  $n \times n$ ,  $\mathbf{W}^{(0)}$  este  $n \times m$ , unde  $m \leq n$ . Vectorii de start  $\mathbf{w}^{(0,j)}$  trebuie să fie liniar independenți. Metoda de bază rămâne înmulțirea la stânga a lui  $\mathbf{W}^{(0)}$  cu matricea **A**, adică,  $\mathbf{W}^{(k+1)} = \mathbf{A}\mathbf{W}^{(k)}$ ,  $k \geq 0$ . Înainte de fiecare etapă a iterației, matricea curentă **W** este ortogonalizată prin procedeul Gram-Schmidt, astfel încât coloanele ei  $\mathbf{w}^{(j)}$  devin vectori ortonormați (ortogonali, și având normă euclidiană unitară). Astfel, vectorii  $\mathbf{w}^{(j)}$  formează o bază ortonormată a sub-spațiului  $m$ -dimensional al lui  $\mathbf{R}^n$ , sub-întins de vectorii inițiali  $\mathbf{w}^{(0,j)}$ . În cursul iterației, această bază se aliniază din ce în ce mai mult la baza vectorilor proprii ai lui **A**, *direcția*  $\mathbf{w}^{(j)} \rightarrow$  *direcția*  $\mathbf{x}^{(j)}$ ,  $j \geq 1$ . Valorile proprii se evaluatează prin câtul Rayleigh.

Iterația se încheie când se atinge o toleranță convenabilă, privitor la direcțiile a două baze succeseive  $\{\mathbf{w}^{(j)}\}$ . Dacă matricea de start  $\mathbf{W}^{(0)}$  are  $m < n$  coloane, se obțin primii  $m$  vectori proprii. Pentru  $m = n$ , adică  $\mathbf{W}^{(0)}$  este  $n \times n$ , se găsesc toți vectorii proprii.

Algoritmul:

Se cere un număr  $ne \leq n$  de vectori proprii.  $\mathbf{W}^{(0)}$  și  $\mathbf{W}$  sunt matrici  $n \times ne$ .

1. Se definește matricea  $\mathbf{W}^{(0)}$ : dacă o aproximare inițială a vectorilor proprii nu este cunoscută, se ia  $\mathbf{W}^{(0)} = [\mathbf{e}^{(1)} \mid \mathbf{e}^{(2)} \mid \dots \mid \mathbf{e}^{(ne)}]$ , adică,  $\mathbf{W}^{(0)}$  este formată din primele  $ne$  coloane ale matricii unitate  $\mathbf{I}$ . Pentru  $ne = n$ ,  $\mathbf{W}^{(0)} = \mathbf{I}$ .
2. Se aplică ortogonalizarea Gram-Schmidt la  $\mathbf{W}^{(0)}$  (cu excepția cazului în care aceasta este deja ortonormată). Se atribuie  $\mathbf{W} = \mathbf{W}^{(0)}$ .
3. Inițializare contor: iter = 0
4. Iterații: iter = iter + 1;

Atribuire:  $\mathbf{W}^{(0)} = \mathbf{W}$  ( $\mathbf{W}$  = matricea curentă;  $\mathbf{W}^{(0)}$  = matricea anterioară.)

5. Se calculează  $\mathbf{W} = \mathbf{A}\mathbf{W}^{(0)}$ .
6. Se calculează  $\lambda_j$ ,  $j = \overline{1, ne}$ , prin câtul Rayleigh:

Fie  $\mathbf{w}^{(j)}$  și  $\mathbf{w}^{(0,j)}$  a  $j$ -a coloană a lui  $\mathbf{W}$  și  $\mathbf{W}^{(0)}$ , respectiv; avem

$$\lambda_j = \langle \mathbf{w}^{(0,j)}, \mathbf{w}^{(j)} \rangle$$

( $\mathbf{w}^{(j)} = \mathbf{A}\mathbf{w}^{(0,j)}$  – Pasul 5; și  $\langle \mathbf{w}^{(0,j)}, \mathbf{w}^{(0,j)} \rangle = 1$  – Pașii 2 și 4.)

7. Se aplică Gram-Schmidt la  $\mathbf{W}$ , astfel că  $\mathbf{W}$  devine ortonormată.
8. Se verifică atingerea toleranței  $TOL$ :

Prin testul de coliniaritate – 1.3, 1: se definește **colin**( $n$ ) pentru fiecare vector

$$\mathbf{z} = \mathbf{W}(:, j)$$
, și  $test\_val = \max_{je=1, ne} \|\mathbf{colin} - \mathbf{colin}(imax)\|$ .

(Întrucât  $\mathbf{z}$  sunt normalizați, testul se poate pune și sub forma din 1, [Observație](#).)

- Dacă  $\|test\_val\| \leq TOL$ , ieșire din iterăție.
- Altfel, GOTO 4.

### *Observații*

- Se poate prescrie un număr limită de iterății *lInit*: atunci, se adaugă la Pasul 8 un test  $iter \leq lInit$ .

- Pasul 6 se poate realiza numai o singură dată, după ce s-a ieșit din iterație.
- 

### *Observații*

#### 1. *Valori proprii de același modul*

Întrucât metoda iterării simultane este în esență metoda puterii, nu se obține convergență pentru vectorii proprii, dacă există valori proprii de modul egal.

#### 2. *Matrici non-hermitiene*

Dacă aplicăm algoritmul de mai sus unei matrici non-hermitiene, nu vom obține convergență pentru vectorii proprii, cu excepția vectorului propriu corespunzând valorii dominante  $\lambda_1$  (pentru care, metoda revine la metoda puterii). Aceasta se întâmplă deoarece ipoteza esențială a metodei este că vectorii proprii formează o bază ortogonală – și procedeul Gram-Schmidt forțează ca, la fiecare pas  $k$ , vectorii  $\mathbf{w}^{(k,j)}$  să fie ortogonali.

Totuși, dacă valorile proprii sunt de module distincte, atunci vectorii proprii sunt liniar independenți, și se obțin aproximări foarte bune pentru valorile proprii.

Explicația este că, procedeul Gram-Schmidt furnizează un set de vectori  $\{\mathbf{w}^{(j)}\}$  liniar independenți (ortonormați), iar valorile proprii sunt calculate cu câtul Rayleigh – care dă aproximări bune ale valorilor proprii chiar cu aproximări grose pentru vectorii proprii.

Valorile proprii găsite pot fi utilizate ulterior, în metoda puterii inverse cu translație, pentru a obține vectorii proprii pentru valorile  $\lambda_i$ ,  $i \geq 2$ .

■

### 3 Metoda Jacobi – matrice reală simetrică

*Metoda:*

Metoda Jacobi este o metodă convenabilă pentru a găsi toate valorile proprii și vectorii proprii ai unei matrici reale și simetrice, de ordin moderat. Determinarea vectorilor proprii este opțională.

Fie  $\mathbf{A}$  o matrice reală și simetrică. Dacă  $\mathbf{N}$  este o matrice nesingulară, atunci matricea  $\bar{\mathbf{A}} = \mathbf{N}^{-1}\mathbf{A}\mathbf{N}$  este similară cu  $\mathbf{A}$ , și are aceleași valori proprii (bara nu notează acum conjugata). Vectorii proprii  $\mathbf{x}$  ai lui  $\mathbf{A}$ , sunt legați de vectorii proprii  $\bar{\mathbf{x}}$  ai lui  $\bar{\mathbf{A}}$ , prin:  $\mathbf{x} = \mathbf{N}\bar{\mathbf{x}}$ . ([Propoziția din 1.1](#)).

Să presupunem acum, că  $\mathbf{N}$  este *unitară*, adică  $\mathbf{N}^{-1} = \mathbf{N}^T$ . Matricea  $\bar{\mathbf{A}}$  devine

$$\bar{\mathbf{A}} = \mathbf{N}^T \mathbf{A} \mathbf{N}$$

Notați că  $\bar{\mathbf{A}}$  este de asemenea simetrică.

*Diagonalizarea lui  $\mathbf{A}$ :*

Să presupunem că  $\mathbf{N}$  este aleasă astfel încât  $\bar{\mathbf{A}}$  să devină *diagonală*:

$$\bar{\mathbf{A}} = \mathbf{N}^T \mathbf{A} \mathbf{N} = \text{diag}(\bar{a}_{ii})$$

Pentru matricea  $\bar{\mathbf{A}}$ , avem proprietățile:

- Valorile proprii ale lui  $\bar{\mathbf{A}}$  sunt elementele diagonale:  $\lambda_i = \bar{a}_{ii}$
- Vectorii proprii ai lui  $\bar{\mathbf{A}}$  sunt coloanele matricii unitate  $\mathbf{I}$ :

$$\bar{\mathbf{x}}^{(i)} = \mathbf{e}^{(i)} \quad (\text{unde } e_j^{(i)} = \delta_{ij}).$$

În consecință, rezultă pentru  $\mathbf{A}$ :

- Valorile proprii ale lui  $\mathbf{A}$  se găsesc pe diagonala matricii  $\bar{\mathbf{A}}$ .
- Vectorii proprii ai lui  $\mathbf{A}$  sunt coloanele matricii  $\mathbf{N}$ .

Exemplu:

$$\mathbf{x}^{(1)} = \mathbf{N}\mathbf{e}^{(1)} = \begin{bmatrix} n_{11} & \dots \\ n_{21} & \dots \\ \vdots & \\ n_{n1} & \dots \end{bmatrix} \begin{bmatrix} 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix} = \begin{bmatrix} n_{11} \\ n_{21} \\ \vdots \\ n_{n1} \end{bmatrix}$$

*Diagonalizarea Jacobi:*

Metoda Jacobi constă în transformări unitare (sau, ortogonale) aplicate succesiv lui  $\mathbf{A}$ , până la obținerea unei forme aproape diagonale. Anume, dacă  $\mathbf{N}_i$  sunt matrici unitare, matricea  $\mathbf{A}$  se transformă cum urmează:

$$\overline{\mathbf{A}}_1 = \mathbf{N}_1^T \mathbf{A} \mathbf{N}_1$$

$$\overline{\mathbf{A}}_2 = \mathbf{N}_2^T \overline{\mathbf{A}}_1 \mathbf{N}_2 = (\mathbf{N}_2^T \mathbf{N}_1^T) \mathbf{A} (\mathbf{N}_1 \mathbf{N}_2)$$

...

$$\overline{\mathbf{A}}_k = \mathbf{N}_k^T \overline{\mathbf{A}}_{k-1} \mathbf{N}_k = (\mathbf{N}_k^T \mathbf{N}_{k-1}^T \dots \mathbf{N}_1^T) \mathbf{A} (\mathbf{N}_1 \mathbf{N}_2 \dots \mathbf{N}_k)$$

Dacă matricea  $\overline{\mathbf{A}}_k$  este *aproape* diagonală, adică, elementele non-diagonale sunt aproximativ zero, luăm

$$\overline{\mathbf{A}} \approx \overline{\mathbf{A}}_k = \mathbf{N}^T \mathbf{A} \mathbf{N}$$

unde

$$\mathbf{N} = \mathbf{N}_1 \mathbf{N}_2 \dots \mathbf{N}_k$$

Fiecare transformare  $\mathbf{N}_i$  se alege astfel ca să eliminate o pereche de elemente non-diagonale (să zicem  $a_{pq}$  și  $a_{qp}$  – la pasul  $i$ ). O astfel de matrice are structura:

$$\mathbf{N}_i = \begin{bmatrix} 1 & & & & & \\ & \ddots & & & & \\ & & 1 & & & \\ & & & \ddots & & \\ & & & & \cos \alpha & -\sin \alpha \\ & & & & & \ddots \\ & & & & & & 1 \\ & & & & & & & \ddots \\ & & & & \sin \alpha & \cos \alpha & & \\ & & & & & & & & \ddots \\ & & & & & & & & & 1 \end{bmatrix} \dots (p) \dots (q)$$

(p) (q)

Elementele nescrise sunt zero (cu excepția diagonalei principale unde acestea sunt unu).

Transformările  $\mathbf{N}_i$  se aplică succesiv, fiecare dintre ele eliminând elementul non-diagonal  $a_{pq}$ , de modul maxim. Principala proprietate a unei astfel de transformări este că produsul  $\mathbf{N}_i^T \mathbf{A} \mathbf{N}_i$  modifică *numai* elementele lui  $\mathbf{A}$  din liniile și coloanele  $p$  și  $q$ .

Unghiul  $\alpha$  se alege astfel încât

$$\bar{a}_{pq} = 0$$

Noile elemente diagonale, sunt date de formulele:

$$r = \sqrt{4a_{pq}^2 + (a_{pp} - a_{qq})^2}; \quad \sin \alpha = +\sqrt{\frac{1}{2} - \frac{a_{pp} - a_{qq}}{2r}}; \quad \cos \alpha = \frac{a_{pq}}{r \sin \alpha};$$

$$\bar{a}_{pp} = \frac{1}{2}(a_{pp} + a_{qq} + r)$$

$$\bar{a}_{qq} = \frac{1}{2}(a_{pp} + a_{qq} - r)$$

### *Observații*

- Transformările  $\mathbf{N}_i$  se aplică succesiv, fiecare dintre ele eliminând elementul non-diagonal de mărime maximă.
- Elementele reduse la zero într-o transformare nu rămân zero la transformarea următoare. Dar, se poate arăta că fiecare transformare reduce suma de pătrate a elementelor non-diagonale cu  $2a_{pq}^2$ , adică,  $\sum_{i \neq j} \bar{a}_{ij}^2 = \sum_{i \neq j} a_{ij}^2 - 2a_{pq}^2$ . Atfel, după un anumit număr de transformări, această sumă poate fi făcută mai mică decât o toleranță  $\varepsilon$  aleasă dinainte.

Pentru alte detalii, v. Cap. 5-II, 2



### *Considerații de programare*

#### *Stocajul matricii:*

Se lucrează cu triunghiul superior al lui  $\mathbf{A}$ , astfel încât, după diagonalizarea lui  $\mathbf{A}$ , elementul (1,1) conține  $\lambda_1$ , etc. Triunghiul superior este stocat în vectorul  $\mathbf{a} (n * (n+1) / 2)$ , în ordinea coloanelor, adică:

$$\mathbf{a} = [a_{11} \mid a_{12} \quad a_{22} \mid a_{13} \quad a_{23} \quad a_{33} \mid \dots \mid a_{1n} \quad a_{2n} \quad \dots \quad a_{nn}]$$

Adresa elementului  $(i, j)$  este dată de următoarea funcție:

$$Loca(i, j) = (j - 1) * j / 2 + i$$

În particular, elementul diagonal  $(i, i)$  are adresa  $Loca(i, i) = (i + 1) * i / 2$ . După ce s-a efectuat o transformare, matricea curentă  $\bar{\mathbf{A}}$  este stocată în același vector  $\mathbf{a}$ .

■

### Strategia de eliminare

Aceasta este *căutarea completă*, adică: se caută în toată matricea  $\mathbf{A}$  (concret, în vectorul  $\mathbf{a}$ ), elementul non-diagonal de modul maxim. (Pentru alte strategii, v. „Numerical Analysis”, Cap. 5-II, 2.)

Elementele non-diagonale se consideră zero, dacă sunt mai mici (în modul) decât o toleranță  $TOL$ .

---