

# Algebră Liniară și Optimizare

## Curs 9

Conf. dr. Anca Ignat

Conf. dr. Corina Forăscu

April 25, 2026

# Valori și vectori proprii (Eigenvalues, eigenvectors)

# Valori și vectori proprii

## Definiție

Fie  $A \in \mathbb{R}^{n \times n}$ . Numărul complex  $\lambda \in \mathbb{C}$  se numește **valoare proprie** a matricei  $A$  dacă există un vector  $\mathbf{u} \in \mathbb{C}^n$ ,  $\mathbf{u} \neq \mathbf{0}$ , astfel încât:

$$A\mathbf{u} = \lambda\mathbf{u}$$

Vectorul  $\mathbf{u}$  se numește *vector propriu* asociat valorii proprii  $\lambda$ .

Pentru existența unui vector propriu  $\mathbf{u} \neq \mathbf{0}$  este necesar și suficient ca matricea  $\lambda I_n - A$  să fie singulară, adică:  
 $\det(\lambda I_n - A) = 0$ .

# Valori și vectori proprii

Polinomul de grad  $n$ :

$$p_A(\lambda) = \det(\lambda I_n - A)$$

se numește **polinomul caracteristic** al matricei  $A$ .

## Propoziția 1

Fie rădăcinile polinomului caracteristic  $\lambda_1, \lambda_2, \dots, \lambda_n$  distincte, adică  $\lambda_i \neq \lambda_j$  pentru  $1 \leq i < j \leq n$ , și fie  $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_n$  vectorii proprii corespunzători. Atunci vectorii  $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_n$  sunt liniar independenți.

*(Demonstrația Propoziției se face prin inducție.)*

# Diagonalizarea matricelor

## Propoziția 2

Fie valorile proprii  $\lambda_i$  ale matricei  $A \in \mathbb{R}^{n \times n}$  distincte. Atunci există o matrice nesingulară  $T$  astfel ca:

$$T^{-1}AT = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_n)$$

*Demonstrație:* Fie  $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_n$  vectorii proprii ai matricei  $A$ . Construim matricea  $T$  ale cărei coloane sunt vectorii proprii  $\mathbf{u}_i$ ,  $T = [\mathbf{u}_1 \ \mathbf{u}_2 \ \dots \ \mathbf{u}_n]$ .

Deoarece vectorii proprii sunt liniar independenți (conform Propoziției 1), rezultă că matricea  $T$  este nesingulară.

# Diagonalizarea matricelor

*Demonstrație: (continuare)*

Avem:

$$\begin{aligned}AT &= [A\mathbf{u}_1 \ A\mathbf{u}_2 \ \dots \ A\mathbf{u}_n] = [\lambda_1\mathbf{u}_1 \ \lambda_2\mathbf{u}_2 \ \dots \ \lambda_n\mathbf{u}_n] \\ &= T * \text{diag}[\lambda_1 \ \lambda_2 \ \dots \ \lambda_n]\end{aligned}$$

Înmulțind la stânga cu  $T^{-1}$ , obținem:

$$T^{-1}AT = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_n).$$

# Matrici asemenea

## Definiție

Matricele  $A$  și  $B$  sunt **asemenea** (notație  $A \sim B$ ) dacă și numai dacă există o matrice nesingulară  $T$  ( $\det T \neq 0$ ) astfel ca:

$$A = TBT^{-1}.$$

## Propoziția 3

$$A \sim B \Rightarrow p_A(\lambda) = p_B(\lambda).$$

*Demonstrație:*

$$\begin{aligned} p_A(\lambda) &= \det(\lambda I_n - A) = \det(\lambda I_n - TBT^{-1}) = \det(\lambda TT^{-1} - TBT^{-1}) \\ &= \det(T(\lambda I_n - B)T^{-1}) = \det(T) \det(\lambda I_n - B) \det(T^{-1}) = p_B(\lambda) \end{aligned}$$

Propoziția 3 ne spune că matricele asemenea au același polinom caracteristic și aceleași valori proprii.

# Teorema lui Gershgorin

## Teorema lui Gershgorin

Fie  $A \in \mathbb{R}^{n \times n}$  și  $\lambda \in \mathbb{C}$  o valoare proprie oarecare a matricei  $A$ .  
Atunci:

$$\exists i_0 \in \{1, 2, \dots, n\} \text{ astfel încât } |\lambda - a_{i_0 i_0}| \leq r_{i_0}, r_{i_0} = \sum_{\substack{j=1 \\ j \neq i_0}}^n |a_{i_0 j}|.$$

(Valoarea proprie  $\lambda$  se află în cercul din planul complex de centru  $a_{i_0 i_0}$  și rază  $r_{i_0}$ .)

# Teorema lui Gershgorin

*Demonstrație:* Fie  $\lambda \in \mathbb{C}$  o valoare proprie a matricei  $A$  și  $\mathbf{u} \neq \mathbf{0}$  un vector propriu asociat valorii proprii  $\lambda$ ,  $A\mathbf{u} = \lambda\mathbf{u}$ .  
Avem

$$\lambda \mathbf{u}_i = \sum_{j=1}^n a_{ij} \mathbf{u}_j \iff (\lambda - a_{ii}) \mathbf{u}_i = \sum_{\substack{j=1 \\ j \neq i}}^n a_{ij} \mathbf{u}_j, \quad i = 1, \dots, n.$$

Fie  $i_0$  astfel ca:

$$|\mathbf{u}_{i_0}| = \|\mathbf{u}\|_\infty = \max\{|\mathbf{u}_k|; k = 1, \dots, n\} > 0, (\mathbf{u} \neq \mathbf{0})$$

Vom avea:

$$|\lambda - a_{i_0 i_0}| = \left| \sum_{\substack{j=1 \\ j \neq i_0}}^n a_{i_0 j} \frac{u_j}{u_{i_0}} \right| \leq \sum_{j=1}^n |a_{i_0 j}| \frac{|u_j|}{|u_{i_0}|} \leq r_{i_0} \text{ deoarece } \frac{|u_j|}{|u_{i_0}|} \leq 1.$$



**Observație:** Presupunem că matricea  $A$  are  $n$  vectori proprii linear independenți  $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_n$  asociați valorilor proprii  $\lambda_1, \lambda_2, \dots, \lambda_n$ .

Fie:  $U = [\mathbf{u}_1 \ \mathbf{u}_2 \ \dots \ \mathbf{u}_n]$  Datorită independenței vectorilor  $\mathbf{u}_k$ , rezultă că matricea  $U$  este nesingulară și avem:

$$\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_n) \qquad U^{-1}AU = \Lambda.$$

Considerăm matricea perturbată:

$$A(\varepsilon) = A + \varepsilon B$$

$$U^{-1}A(\varepsilon)U = \Lambda + \varepsilon U^{-1}BU =: \Lambda + \varepsilon C$$

Rezultă că  $A(\varepsilon) \sim U^{-1}A(\varepsilon)U \Rightarrow$  au aceleași valori proprii  $\lambda_i(\varepsilon)$ .

$$|\lambda_i(\varepsilon) - \lambda_i - \varepsilon c_{ii}| \leq \varepsilon \sum_{\substack{j=1 \\ j \neq i}}^n |c_{ij}| \Rightarrow |\lambda(\varepsilon) - \lambda_i| = \mathcal{O}(\varepsilon).$$

# Metoda puterii pentru matrice simetrice

# Metoda puterii pentru matrice simetrice

## Propoziție

Fie  $A \in \mathbb{R}^{n \times n}$ ,  $A^T = A$ . Atunci toate valorile proprii ale matricei  $A$  sunt numere reale.

*Demonstrație:* Fie  $\lambda \in \mathbb{C}$  și  $\mathbf{u} \in \mathbb{C}^n$ ,  $\mathbf{u} \neq 0$ , astfel încât  $A\mathbf{u} = \lambda\mathbf{u}$ .

Considerăm produsul scalar:

$$(A\mathbf{u}, \mathbf{u})_{\mathbb{C}^n} = \lambda(\mathbf{u}, \mathbf{u})_{\mathbb{C}^n} = \lambda\|\mathbf{u}\|_2^2.$$

Dar deoarece  $A^T = A$ , avem:

$$(A\mathbf{u}, \mathbf{u})_{\mathbb{C}^n} = (\mathbf{u}, A^T\mathbf{u})_{\mathbb{C}^n} = (\mathbf{u}, A\mathbf{u})_{\mathbb{C}^n} = \overline{(A\mathbf{u}, \mathbf{u})_{\mathbb{C}^n}} \Rightarrow (A\mathbf{u}, \mathbf{u})_{\mathbb{C}^n} \in \mathbb{R}.$$

Rezultă:

$$\lambda = \frac{(A\mathbf{u}, \mathbf{u})_{\mathbb{C}^n}}{\|\mathbf{u}\|_2^2} \in \mathbb{R}.$$

# Metoda puterii pentru matrice simetrice

## Propoziție

Fie  $A \in \mathbb{R}^{n \times n}$ ,  $A = A^T$ . Atunci există o bază ortonormată de vectori proprii ai matricei  $A$ ,  $\{\mathbf{u}^1, \mathbf{u}^2, \dots, \mathbf{u}^n\}$  astfel încât

$$(\mathbf{u}^i, \mathbf{u}^j) = \delta_{ij} = \begin{cases} 1, & \text{dacă } i = j \\ 0, & \text{dacă } i \neq j \end{cases}$$

Echivalent, putem scrie că există vectori proprii  $\{\mathbf{u}^1, \mathbf{u}^2, \dots, \mathbf{u}^n\}$  asociați valorilor proprii reale  $\{\lambda_1, \lambda_2, \dots, \lambda_n\}$  astfel ca:

$$AU = U\Lambda \quad \Leftrightarrow \quad U^T AU = \Lambda$$

cu  $\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_n)$ , și  $U = [\mathbf{u}_1 \ \mathbf{u}_2 \ \dots \ \mathbf{u}_n]$  matrice ortogonală.

# Metoda puterii pentru matrice simetrice

## Definiție

Se numește *coeficient Rayleigh* al vectorului  $\mathbf{u} \in \mathbb{R}^n$  pentru matricea  $A$  următoarea mărime scalară:

$$r(\mathbf{u}) = \frac{\mathbf{u}^T A \mathbf{u}}{\mathbf{u}^T \mathbf{u}} = \frac{(A \mathbf{u}, \mathbf{u})_{\mathbb{R}^n}}{(\mathbf{u}, \mathbf{u})_{\mathbb{R}^n}} = \frac{(A \mathbf{u}, \mathbf{u})_{\mathbb{R}^n}}{\|\mathbf{u}\|_2^2}.$$

Se verifică ușor că dacă  $\mathbf{u} \in \mathbb{R}^n$  este vector propriu al matricei  $A$  asociat valorii proprii  $\lambda$ , atunci  $r(\mathbf{u}) = \lambda$ .

Fie  $A \in \mathbb{R}^{n \times n}$ ,  $A = A^T$ . Matricea are valori proprii reale  $\lambda_1, \lambda_2, \dots, \lambda_n$ . Presupunem în plus că:

$$|\lambda_1| \geq |\lambda_2| \geq \dots \geq |\lambda_n| \geq 0.$$

Vectorii proprii se notează  $\mathbf{u}^1, \mathbf{u}^2, \dots, \mathbf{u}^n$ .

# Metoda puterii pentru matrice simetrice

Metoda puterii este un algoritm care aproximează valoarea proprie de modul maxim  $\lambda_1$  și un vector propriu asociat.

Se pornește de la un vector nenul de normă euclidiană 1,  $\mathbf{u}^{(0)} \in \mathbb{R}^n$ ,  $\|\mathbf{u}^{(0)}\|_2 = 1$ , și se construiește următorul șir de vectori de normă euclidiană 1:

$$\mathbf{u}^{(0)}, \quad \mathbf{u}^{(1)} = \frac{1}{\|A\mathbf{u}^{(0)}\|_2} A\mathbf{u}^{(0)}, \quad \mathbf{u}^{(2)} = \frac{1}{\|A\mathbf{u}^{(1)}\|_2} A\mathbf{u}^{(1)} \quad \dots$$

$$\mathbf{u}^{(k)} = \frac{1}{\|A\mathbf{u}^{(k-1)}\|_2} A\mathbf{u}^{(k-1)},$$

În anumite condiții, acest șir converge la un vector propriu asociat valorii proprii  $\lambda_1$ , iar coeficienții Rayleigh corespunzători converg către  $\lambda_1$ .

# Metoda puterii pentru matrice simetrice

## Teoremă

Fie  $A \in \mathbb{R}^{n \times n}$  o matrice simetrică pentru care valorile proprii îndeplinesc condiția:

$$|\lambda_1| > |\lambda_2| \geq \dots \geq |\lambda_n| \geq 0.$$

Dacă  $\mathbf{u}^{(0)} \in \mathbb{R}^n$ ,  $\|\mathbf{u}^{(0)}\|_2 = 1$  și  $(\mathbf{u}^{(0)}, \mathbf{u}^1) \neq 0$ , unde  $\mathbf{u}^1$  este vector propriu asociat lui  $\lambda_1$ , atunci:

$$\mathbf{u}^{(k)} = \frac{1}{\|A^k \mathbf{u}^{(0)}\|_2} A^k \mathbf{u}^{(0)} \rightarrow \mathbf{u}^1, \text{ (vector propriu asociat lui } \lambda_1)$$

iar coeficienții Rayleigh satisfac:

$$r(\mathbf{u}^{(k)}) \rightarrow \lambda_1.$$

# Metoda puterii pentru matrice simetrice

*Demonstrație.* Fie  $\{\mathbf{u}^1, \mathbf{u}^2, \dots, \mathbf{u}^n\}$  vectori proprii asociați valorilor proprii  $\{\lambda_1, \lambda_2, \dots, \lambda_n\}$ , care formează o bază ortonormată în  $\mathbb{R}^n$ .

Atunci avem

$$\mathbf{u}^{(0)} = a_1 \mathbf{u}^1 + a_2 \mathbf{u}^2 + \dots + a_n \mathbf{u}^n, \quad a_i \in \mathbb{R}.$$

Deoarece  $(\mathbf{u}^{(0)}, \mathbf{u}^1)_{\mathbb{R}^n} \neq 0$ , rezultă că  $a_1 \neq 0$ .

Din construcția șirului  $\mathbf{u}^{(k)}$ , deducem că există o constantă  $c_k$  astfel încât:

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

# Metoda puterii pentru matrice simetrice

*Demonstrație.(continuare)*

Din această ultimă relație, din faptul că  $\lambda_1$  este valoare proprie dominantă și  $a_1 \neq 0$  deducem că pentru  $k$  suficient de mare vectorul  $\mathbf{u}^{(k)}$  se aliniază după vectorul propriu  $\mathbf{u}^1$ :

$$\mathbf{u}^{(k)} \approx c_k \lambda_1^k a_1 \mathbf{u}^1.$$

# Metoda puterii

$$\mathbf{u}^{(0)} \in \mathbb{R}^n, \|\mathbf{u}^{(0)}\|_2 = 1;$$

$$k=0;$$

do

- $k++$ ;
- $\mathbf{w} = A\mathbf{u}^{k-1}$ ;
- $\mathbf{u}^{(k)} = \frac{1}{\|\mathbf{w}\|_2} \mathbf{w}$ ;
- $\lambda_k = r(\mathbf{u}^{(k)}) = (A\mathbf{u}^k, \mathbf{u}^k)_{\mathbb{R}^n}$ ;

while ( $\|A\mathbf{u}^k - \lambda_k \mathbf{u}^k\| > \varepsilon$  și  $k \leq k_{max}$ );

# Metoda iterației inverse

# Metoda iterației inverse

Considerăm o matrice simetrică  $A \in \mathbb{R}^{n \times n}$ , cu  $A = A^T$ , și fie  $\mu \in \mathbb{R}$  un număr real care nu este valoare proprie a lui  $A$ .

Vom folosi metoda puterii pentru a aproxima valoarea proprie a matricei  $A$  cea mai apropiată de  $\mu$  și un vector propriu asociat.

$$\mu \neq \text{valoare proprie} \rightarrow \det(A - \mu I_n) \neq 0 \Rightarrow \exists (A - \mu I_n)^{-1}.$$

# Metoda iterației inverse

Fie  $\{\lambda_1, \lambda_2, \dots, \lambda_n\}$  valorile proprii reale ale matricei  $A$ .  
Valorile proprii ale matricei  $(A - \mu I_n)^{-1}$  sunt:

$$\left\{ \frac{1}{\lambda_1 - \mu'}, \frac{1}{\lambda_2 - \mu'}, \dots, \frac{1}{\lambda_n - \mu} \right\}$$

Matricele  $A$  și  $(A - \mu I_n)^{-1}$  au aceiași vectori proprii.

# Metoda iterației inverse

Presupunem că  $\lambda_I$  este valoarea proprie cea mai apropiată de  $\mu$  (și singura). Atunci avem

$$\frac{1}{|\lambda_I - \mu|} > \frac{1}{|\lambda_j - \mu|}, \quad \forall j \neq I. \quad (*)$$

Relația (\*) sugerează aplicarea metodei puterii pentru matricea  $(A - \mu I_n)^{-1}$ , pentru a aproxima valoarea proprie  $(\lambda_I - \mu)^{-1}$  și un vector propriu asociat.

Algoritmul conduce la aproximarea valorii proprii cea mai apropiată de  $\mu$ ,  $\lambda_I$ , și a unui vector propriu asociat acesteia,  $u^I$ .

# Metoda iterației inverse

$$\mathbf{u}^{(0)} \in \mathbb{R}^n, \|\mathbf{u}^{(0)}\|_2 = 1;$$

$$k=0;$$

do

- $k++$ ;
- Se rezolvă sistemul  $(A - \mu I_n)\mathbf{w} = \mathbf{u}^{(k-1)}$ ;
- $\mathbf{u}^{(k)} = \frac{1}{\|\mathbf{w}\|_2} \mathbf{w}$ ;
- $\lambda_k = r(\mathbf{u}^{(k)}) = (A\mathbf{u}^k, \mathbf{u}^k)_{\mathbb{R}^n}$ ;

while ( $\|A\mathbf{u}^k - \lambda_k \mathbf{u}^k\| > \varepsilon$  și  $k \leq k_{max}$ );

# Forma superioară Hessenberg

# Forma superioară Hessenberg

Spunem că o matrice  $H \in \mathbb{R}^{n \times n}$  este în formă Hessenberg superioară dacă:

$$h_{ij} = 0, \quad \text{pentru } i = 1, \dots, n, j = 1, \dots, i - 2,$$

O matrice în formă Hessenberg superioară are forma:

$$H = \begin{pmatrix} h_{11} & h_{12} & h_{13} & \cdots & h_{1 \ n-1} & h_{1n} \\ h_{21} & h_{22} & h_{23} & \cdots & h_{2 \ n-1} & h_{2n} \\ 0 & h_{32} & h_{33} & \cdots & h_{3 \ n-1} & h_{3n} \\ 0 & 0 & h_{43} & \cdots & h_{4 \ n-1} & h_{4n} \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & 0 & \cdots & h_{n \ n-1} & h_{nn} \end{pmatrix}$$

# Forma superioară Hessenberg

Ne interesează un algoritm care să transforme o matrice pătratică oarecare  $A$  într-o matrice Hessenberg superioară  $H$ , care să aibă aceleași valori proprii.

Dorim o transformare de forma:

$$A \rightarrow H \text{ a.î. } H \sim A, H = \tilde{P}A\tilde{P}^{-1},$$

cu  $\tilde{P}$  o matrice nesingulară.

Algoritmul este o adaptare a metodei lui Householder și se desfășoară în  $n - 2$  pași, folosind matrici de reflexie pentru a transforma matricea.

# Reducerea la forma Hessenberg superioară

Algoritmul de reducere la forma Hessenberg superioară constă în:

**Pas 1:** Se calculează

$$A^{(1)} = P_1 A P_1$$

Matricea  $P_1$  se alege astfel încât coloana 1 să fie adusă în formă Hessenberg superioară.

**Pas 2:**

$$A^{(2)} = P_2 A^{(1)} P_2 = P_2 (P_1 A^{init} P_1) P_2$$

Matricea  $P_2$  transformă coloana 2 în formă Hessenberg superioară fără să modifice coloana 1.

# Reducerea la forma Hessenberg superioară

Algoritmul de reducere la forma Hessenberg superioară constă în:

**Pasul  $r$ :**

$$A^{(r)} = P_r A^{(r-1)} P_r = P_r (P_{r-1} \cdots (P_1 A^{init} P_1) \cdots P_{r-1}) P_r$$

Se transformă coloana  $r$  în formă Hessenberg superioară fără a modifica primele  $r - 1$  coloane.

# Reducerea la forma Hessenberg superioară

**Pasul general  $r$ , unde  $r = 1, 2, \dots, n - 2$ :**

La intrarea în pasul  $r$ , matricea  $A$  are primele  $r - 1$  coloane în formă Hessenberg superioară. La ieșire, va avea primele  $r$  coloane în această formă:

$$A_{ies} = P_r A_{intr} P_r, \quad A_{ies} \sim A_{intr}.$$

$$P_r = I - 2\mathbf{v}^r(\mathbf{v}^r)^T, \quad \mathbf{v}^r \in \mathbb{R}^n, \quad \|\mathbf{v}^r\|_2 = 1$$

Vectorul  $\mathbf{v}^r$  se alege astfel încât matricea  $A_{ies}$  să aibă coloana  $r$  în formă Hessenberg superioară, și să nu schimbe primele  $r - 1$  coloane ale matricii  $A_{intr}$ .

## Calculul matricii $P_r$ :

$$P_r = I - \frac{1}{\beta} \mathbf{u} \mathbf{u}^T$$

$$\beta = \sigma - k \cdot a_{r+1 r},$$

$$k^2 = \sigma = a_{r+1 r}^2 + \cdots + a_{i r}^2 + \cdots + a_{n r}^2 = \sum_{i=r+1}^n a_{i r}^2 \Rightarrow k = \pm \sqrt{\sigma}$$

$$\text{semn } k = - \text{semn } a_{r+1 r}$$

$$\mathbf{u} := \begin{pmatrix} 0 \\ \vdots \\ a_{r+1 r} - k \\ \vdots \\ a_{i r} \\ \vdots \\ a_{n r} \end{pmatrix}, \quad \beta = 0 \rightarrow r = r + 1 (P_r = I_n).$$

## Aplicarea transformării $P_r A$

Algoritmul de trecere de la matricea  $A$  la matricea  $P_r A$  este următorul:

$$(P_r A)\mathbf{e}_j = \begin{cases} A\mathbf{e}_j, & \text{pentru } j = 1, \dots, r-1 \\ (a_{1r}, a_{2r}, \dots, a_{rr}, k, 0, \dots, 0)^T & \text{pentru } j = r \\ A\mathbf{e}_j - \frac{\gamma_j}{\beta} \mathbf{u}, & \text{pentru } j = r+1, \dots, n \end{cases}$$

unde

$$\gamma_j = (A\mathbf{e}_j, \mathbf{u})_{\mathbb{R}^n} = \sum_{i=r+1}^n a_{ij} u_i$$

și vectorul  $\mathbf{u}$  are componentele:

$$u_i = 0, \quad i = 1, \dots, r, \quad u_{r+1} = a_{r+1, r} - k, \quad u_i = a_{ir}, \quad i = r+2, \dots, n.$$

## Aplicarea transformării $P_r A$

Vom descrie în continuare cum se efectuează operația

$$A := AP_r$$

fără a face înmulțire matricială, unde  $A$  este matricea obținută anterior, având primele  $r$  coloane în formă Hessenberg superioară.

Vom arăta că această operație nu schimbă forma Hessenberg superioară deja obținută. Vom pune în evidență transformările liniilor matricii  $A$ .

Pentru  $i = 1, \dots, n$ , avem:

$$\begin{aligned} \mathbf{e}_i^T(AP) &= \text{noua linia } i \text{ a matricii } AP = (\mathbf{e}_i^T A) \left( I_n - \frac{1}{\beta} \mathbf{u}\mathbf{u}^T \right) \\ &= \mathbf{e}_i^T A - \frac{1}{\beta} (\mathbf{e}_i^T A) \mathbf{u}\mathbf{u}^T = \mathbf{e}_i^T A - \frac{\gamma_i}{\beta} \mathbf{u}^T. \end{aligned}$$

## Aplicarea transformării $P_r A$

unde  $\gamma_i = (\mathbf{e}_i^T A)\mathbf{u} = a_{i\ r+1}\mathbf{u}_{r+1} + \dots + a_{in}\mathbf{u}_n$ .

Elementele liniei  $i$  se schimbă astfel:

$$a_{ij} = a_{ij} - \frac{\gamma_i}{\beta}\mathbf{u}_j, \quad j = r + 1, \dots, n, \quad i = 1, \dots, n.$$

Operația  $A := AP_r$  nu modifică primele  $r$  coloane ale matricii  $A$ , ele rămânând în formă superior Hessenberg.

# Algoritmul de obținere a formei superior Hessenberg (1/2)

for  $r = 1, \dots, n - 2$

// construcția matricii  $P_r$  - constanta  $\beta$  și vectorul  $\mathbf{u}$

- $\sigma = \sum_{i=r+1}^n a_{ir}^2$ ;
- if ( $\sigma \leq \varepsilon$ ) break; //  $r = r + 1 \Leftrightarrow P_r = I_n$
- $k = \sqrt{\sigma}$ ;
- if ( $a_{r+1 r} > 0$ )  $k = -k$ ;
- $\beta = \sigma - k \cdot a_{r+1 r}$ ;
- $\mathbf{u}_{r+1} = a_{r+1 r} - k$ ;  $\mathbf{u}_r = a_{ir}$ ,  $i = r + 2, \dots, n$ ;

# Algoritmul de obținere a formei superior Hessenberg (2/3)

//  $A = P_r * A$

// transformarea coloanelor  $j = r + 1, \dots, n$

- for  $j = r + 1, \dots, n$

$$\left\{ \begin{array}{l} \gamma = (\gamma_j / \beta) = (A\mathbf{e}_j, \mathbf{u}) / \beta = \left( \sum_{i=r+1}^n \mathbf{u}_i a_{ij} \right) / \beta; \\ \text{for } i = r + 1, \dots, n \\ \quad a_{ij} = a_{ij} - \gamma * \mathbf{u}_i; \end{array} \right.$$

// transformarea coloanei  $r$  a matricii  $A$

- $a_{r+1 r} = k; a_{ir} = 0, i = r + 2, \dots, n;$

# Algoritmul de obținere a formei superior Hessenberg (3/3)

$$// A = A * P_r$$

// transformarea liniilor  $i = 1, \dots, n$

- for  $i = 1, \dots, n$

$$\left\{ \begin{array}{l} \gamma = (\gamma_i/\beta) = ((\mathbf{e}_i^T A)\mathbf{u})/\beta = \left( \sum_{j=r+1}^n \mathbf{u}_j a_{ij} \right) / \beta; \\ \text{for } j = r + 1, \dots, n \\ \quad a_{ij} = a_{ij} - \gamma * \mathbf{u}_j. \end{array} \right.$$

# Algoritmul QR pentru aproximarea valorilor proprii

# Algoritmul QR - aproximarea valorilor proprii

Prezentăm în continuare cel mai utilizat algoritm pentru aproximarea valorilor proprii ale unei matrice pătratice oarecare.

## Definiție

Spunem că o matrice  $S \in \mathbb{R}^{n \times n}$  este în *formă Schur reală* dacă este în formă Hessenberg superioară și, în plus, este bloc-diagonală:

$$S = \begin{pmatrix} S_{11} & S_{12} & \cdots & S_{1p} \\ 0 & S_{22} & \cdots & S_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & S_{pp} \end{pmatrix}.$$

# Algoritmul QR - aproximarea valorilor proprii

Blocurile  $S_{ii}$  sunt de două tipuri:

- $S_{ii} \in \mathbb{R}$  - este valoarea proprie reală ;
- $S_{ii} \in \mathbb{R}^{2 \times 2}$  - este bloc corespunzător valorilor proprii complexe

Valorile proprii corespunzătoare blocului  $S_{ii}$ :

$$S_{ii} = \begin{pmatrix} a & b \\ c & d \end{pmatrix}$$

sunt rădăcinile ecuației:

$$\begin{vmatrix} \lambda - a & -b \\ -c & \lambda - d \end{vmatrix} = \lambda^2 - (a + d)\lambda + (ad - bc) = 0$$

Se presupune că această ecuație de gradul 2 are rădăcini complexe.

# Algoritmul QR - aproximarea valorilor proprii

Algoritmul QR de aproximare a valorilor proprii construiește un șir de matrice  $A^{(k)} \in \mathbb{R}^{n \times n}$ , asemenea cu matricea  $A$ :

$$A^{(k)} \sim A, \quad \forall k$$

Acest șir converge către o matrice în formă Schur reală:

$$A^{(k)} \rightarrow S, \quad \text{când } k \rightarrow \infty$$

Matricea limită  $S$  este asemenea cu  $A$ , iar valorile proprii ale lui  $S$  sunt ușor de determinat.

# Algoritmul QR - aproximarea valorilor proprii

*Construcția șirului*

Șirul  $A^{(k)}$  se construiește astfel:

$A^{(0)} = A$ ,  $A^{(0)} = Q_0 R_0$  (descompunere QR calc. pentru matricea  $A^{(0)}$ )

$A^{(1)} := R_0 Q_0$ ,  $A^{(1)} = Q_1 R_1$  (descompunere QR calc. pentru matricea  $A^{(1)}$ )

$A^{(2)} := R_1 Q_1$

$\vdots$

$A^{(k)} = Q_k R_k$  (descompunere QR calc. pentru matricea  $A^{(k)}$ )

$A^{(k+1)} := R_k Q_k$ ,  $k = 0, 1, 2, \dots$

Matricele  $Q_k$  sunt ortogonale ( $Q_k^{-1} = Q_k^T$ ) iar matricele  $R_k$  sunt superior triunghiulare.

## Algoritmul QR - aproximarea valorilor proprii

Matricele  $A^{(k)}$  și  $A^{(k+1)}$  sunt asemenea. Într-adevăr, înmulțind la stânga relația  $A^{(k)} = Q_k R_k$  cu  $Q_k^T$ , avem

$$Q_k^T * A^{(k)} = Q_k R_k \Rightarrow R_k = Q_k^T A^{(k)}.$$

$$A^{(k+1)} = R_k Q_k = Q_k^T A^{(k)} Q_k \Rightarrow A^{(k+1)} \sim A^{(k)}, \forall k.$$

Prin urmare, toate matricele din șirul construit sunt asemenea și au aceleași valori proprii, pe cele ale matricei inițiale  $A = A^{(0)}$ :

$$A = A^{(0)} \sim A^{(1)} \sim \dots \sim A^{(k)} \sim \dots \sim S$$

Dacă matricea  $A^{(k)}$  este în formă Hessenberg superioară, atunci descompunerea QR folosind rotații Givens se simplifică.

# Algoritmul QR - aproximarea valorilor proprii

Reamintim algoritmul lui Givens:

$$R_{n-1,n}(\theta_{n-1,n}) \cdots R_{pn}(\theta_{pn}) \cdots R_{p,p+1}(\theta_{p,p+1}) \cdots R_{12}(\theta_{12})A = R$$

Dacă matricea  $A$  este în formă Hessenberg superioară, atunci în algoritmul lui Givens, din cele  $\frac{n(n-1)}{2}$  înmulțiri cu matrici de rotație, rămân doar  $n-1$ :

$$R_{n-1,n}(\theta_{n-1,n}) \cdots R_{p,p+1}(\theta_{p,p+1}) \cdots R_{23}(\theta_{23})R_{12}(\theta_{12})A = R$$

## Algoritmul QR - aproximarea valorilor proprii

Problema care se pune este dacă, pornind cu o matrice în formă Hessenberg, toate matricele șirului QR rămân în formă Hessenberg:

$$A^{(k)}(\text{în formă Hessenberg}) = H = QR \text{ (cu Givens) } \Rightarrow ?$$

Avem

$$A^{(k+1)} = \bar{H} = RQ = Q^T A^{(k)} Q = Q^T H Q$$

și vrem să arătăm că  $A^{(k+1)}$  este tot în formă Hessenberg.

Avem

$$\bar{H} = Q^T H Q = R R_{12}^T(\theta_{12}) \cdots R_{r r+1}^T(\theta_{r r+1}) \cdots R_{n-1 n}^T(\theta_{n-1 n})$$

# Algoritmul QR - aproximarea valorilor proprii

Notăm:

$$\bar{R} = RR_{12}^T(\theta_{12})$$

pentru care avem:

$$\begin{cases} \bar{r}_{i1} = cr_{i1} + sr_{i2}, \forall i \\ \bar{r}_{i2} = -sr_{i1} + cr_{i2}, \forall i \end{cases} + \begin{cases} \bar{r}_{i1} = 0, \forall i = 2, \dots, n \\ \bar{r}_{i2} = 0, \forall i = 3, \dots, n \end{cases} \Rightarrow \begin{cases} \bar{r}_{i1} = 0, i = 3, \dots, n \\ \bar{r}_{i2} = 0, i = 3, \dots, n. \end{cases}$$

deci coloana 1 se transformă în formă Hessenberg, iar coloana 2 rămâne în formă superior triunghiulară.

## Algoritmul QR - aproximarea valorilor proprii

La pasul  $p$ , avem:

$$(RR_{12}^T(\theta_{12}) \cdots R_{p-1\ p}^T(\theta_{p-1\ p}))R_{p\ p+1}^T(\theta_{pp+1}) = \tilde{R}R_{p\ p+1}^T(\theta_{pp+1}) = \bar{R},$$

$$\tilde{R} = R \cdot R_{12}^T(\theta_{12}) \cdots R_{p-1\ p}^T(\theta_{p-1\ p}).$$

Matricea  $R$  are primele  $p - 1$  coloane în formă Hessenberg, iar restul coloanelor în formă superior triunghiulară. Se arată că, la acest pas, matricea  $\bar{R}$  va avea primele  $p$  coloane în formă Hessenberg, iar restul coloanelor în formă superior triunghiulară.

## Algoritmul QR - aproximarea valorilor proprii

Operația  $\bar{R} := \tilde{R} R_{pp+1}^T(\theta_{pp+1})$  presupune doar modificarea elementelor coloanelor  $p$  și  $p + 1$ :

$$\begin{cases} \bar{r}_{ip} = c\tilde{r}_{ip} + s\tilde{r}_{i\ p+1}, \forall i \\ \bar{r}_{i\ p+1} = -s\tilde{r}_{ip} + c\tilde{r}_{i\ p+1}, \forall i \end{cases} + \begin{cases} \tilde{r}_{ip} = 0, i = p + 1, \dots, n \\ \tilde{r}_{i\ p+1} = 0, i = p + 2, \dots, n \end{cases} \Rightarrow$$

$$\begin{cases} \bar{r}_{ip} = 0, i = p + 2, \dots, n \\ \bar{r}_{i\ p+1} = 0, i = p + 2, \dots, n. \end{cases}$$

## Algoritmul QR - aproximarea valorilor proprii

Observăm din relațiile de mai sus că în matricea  $\bar{R}$ , coloana  $p$  are formă Hessenberg, iar coloana  $p + 1$  rămâne în formă superior triunghiulară. Celelalte elemente ale matricei nu se modifică.

Prin urmare, după pasul  $n - 1$ , matricea

$$\bar{H} = A^{(k+1)}$$

este în formă Hessenberg superioară.

Algoritmul QR de aproximare a valorilor proprii, folosind descompunerea Givens, păstrează forma Hessenberg.

# Algoritmul QR pentru valori proprii

Algoritm:

// Se aduce matricea  $A$  la forma Hessenberg

- $A = \bar{Q}A\bar{Q}^T$ ;
- $k=0$ ;
- while ( $A \neq$  forma Schur reală )
  - $A = QR$ ; // Se calculează cu algoritmul Givens
  - $A = RQ$  sau  $Q^T A Q$ ;
  - $k = k + 1$ .

## Algoritmul QR - aproximarea valorilor proprii

În practică se presupune că matricea  $A$  este în **formă Hessenberg neredusă**, adică:

$$a_{i, i-1} \neq 0, \forall i = 2, \dots, n.$$

Dacă matricea nu este în formă neredusă, problema se decuplează

$$A = \begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix} \begin{matrix} p \\ n - p \end{matrix}$$

$p \quad n - p$

cu  $p = n - 1$  sau  $n - 2$ .

# Algoritmului QR cu deplasare (“shift”) simplă

Algoritmul cu deplasare simplă este următorul:

- $A = \bar{Q}A\bar{Q}^T$ ; // / aducerea la forma Hessenberg neredusă
- $k = 0$ ;
- while ( $A \neq$  forma Schur reală)
  - $A - d_k I_n = QR$ ; // / se calculează cu Givens
  - $A := RQ + d_k I_n$ ;
  - $k = k + 1$ ;

$d_k \in \mathbb{R}$  sunt constantele de deplasare.

# Algoritmul QR cu deplasare simplă

Dacă  $A - dI_n = QR(A^{(k)})$  și  $\bar{A} = RQ + dI_n (A^{(k+1)})$ , se pune problema dacă cele două matrice sunt asemenea ( $A \sim \bar{A}$ ), adică dacă matricele din șirul construit prin pasul QR cu deplasare simplă au aceleași valori proprii.

$$\bar{A} = Q^T QRQ + dQ^T Q = Q^T (QR + dI_n) Q = Q^T A Q \Rightarrow \bar{A} \sim A.$$

Varianta cu deplasare se utilizează pentru a accelera convergența algoritmului.

Dacă  $\lambda_1, \lambda_2, \dots, \lambda_n$  sunt valorile proprii ale matricei  $A$ , ordonate astfel încât:

$$|\lambda_1 - d| \geq |\lambda_2 - d| \geq \dots \geq |\lambda_n - d|.$$

# Algoritmul QR cu deplasare simplă

Rapiditatea cu care elementele subdiagonale tind la zero  $a_{p+1 p}^{(k)} \rightarrow 0, k \rightarrow \infty$  este dată de rata de convergență a

expresiei  $\left| \frac{\lambda_{p+1} - d}{\lambda_p - d} \right|^k$ .

Dacă se alege  $d \approx \lambda_n$  convergența  $a_{n-1 n}^{(k)} \rightarrow 0$  este rapidă.

## Teoremă

Fie  $d$  o valoare proprie a unei matrice Hessenberg neredusă  $H$ . Dacă  $\bar{H} = RQ + dI_n$ , cu  $H - dI_n = QR$  descompunerea QR a matricei  $H - dI_n = QR$ . Atunci

$$\bar{h}_{n n-1} = 0, \bar{h}_{nn} = d.$$

# Algoritmul QR cu deplasare simplă

Algoritmul QR cu deplasare simplă găsește valoarea proprie  $d$  într-un singur pas.

Euristic s-a constatat că la fiecare pas, cea mai bună aproximare a unei valori proprii este  $a_{nn}^{(k)}$ .

$$d_k = a_{nn}^{(k)}.$$

# Algoritmul QR cu deplasare simplă

## Algoritmul QR cu deplasare simplă

- $A = \bar{Q}A\bar{Q}^T$ ; // aducerea la forma Hessenberg neredusă
- $k = 0$ ;
- while ( $A \neq$  forma Schur reală)
  - $A - a_{nn}I_n = QR$ ; // se calc. cu alg. Givens
  - $A := RQ + a_{nn}I_n$ ;
  - $k = k + 1$ ;

# Algoritmul QR cu deplasare ("shift") dublă

În cazul când valorile proprii  $a_1, a_2$  corespunzătoare blocului:

$$G = \begin{pmatrix} a_{pp} & a_{pn} \\ a_{np} & a_{nn} \end{pmatrix}, \quad p = n - 1,$$

sunt complexe,  $a_1, a_2 \in \mathbb{C}$ , abordarea cu deplasare simplă nu mai asigură accelerarea convergenței.

Avem:

$$\begin{aligned} \det(\lambda I_2 - G) &= (\lambda - a_1)(\lambda - a_2) = (\lambda - a_{pp})(\lambda - a_{nn}) - a_{pn}a_{np} \\ &= \lambda^2 - (a_1 + a_2)\lambda + a_1a_2 = \lambda^2 - (a_{pp} + a_{nn})\lambda + a_{pp}a_{nn} - a_{pn}a_{np} \end{aligned}$$

$$a_1 + a_2 = a_{pp} + a_{nn} = \text{trace}(G), \quad a_1a_2 = a_{pp}a_{nn} - a_{pn}a_{np} = \det(G).$$

# Algoritmul QR cu deplasare ("shift") dublă

Algoritmul QR cu deplasare dublă constă în trecerea de la matricea  $A = A^{(k)}$  la matricea  $A_2 = A^{(k+1)}$  realizând doi pași cu deplasare simplă :

$A \rightarrow A_1$ (deplasare simplă  $a_1$ ),  $A_1 \rightarrow A_2$ (deplasare simplă  $a_2$ )

$$A - a_1 I_n = Q_1 R_1$$

$$A_1 = R_1 Q_1 + a_1 I_n$$

$$A_1 - a_2 I_n = Q_2 R_2$$

$$A_2 = R_2 Q_2 + a_2 I_n.$$

# Algoritmul QR cu deplasare ("shift") dublă

Fie matricea:

$$\begin{aligned}M &:= (Q_1 Q_2)(R_2 R_1) = Q_1(Q_2 R_2)R_1 = Q_1(A_1 - a_2 I_n)R_1 \\ &= Q_1(Q_1^T A Q_1 - a_2 I_n)R_1 = Q_1 Q_1^T A Q_1 R_1 - a_2 Q_1 R_1 \\ &= (A - a_2 I_n)Q_1 R_1 = (A - a_2 I_n)(A - a_1 I_n) \\ &= A^2 - (a_1 + a_2)A + a_1 a_2 I_n.\end{aligned}$$

Avem următoarele relații de asemănare:

$$A \sim A_1 = Q_1^T A Q_1 \sim A_2 = Q_2^T A_1 Q_2 = Q_2^T Q_1^T A Q_1 Q_2$$

$$A_2 = (Q_1 Q_2)^T A (Q_1 Q_2) = Q^T A Q, \quad Q := Q_1 Q_2.$$

# Algoritmul QR cu deplasare ("shift") dublă

Matricea  $Q$  care asigură trecerea de la matricea  $A$  la matricea  $A_2$  este matricea ortogonală din descompunerea QR a matricii  $M = (A - a_2 I_n)(A - a_1 I_n)$ .

Pasul QR cu deplasare dublă se face urmând etapele:

1. se calculează matricea  $M = A^2 - sA + qI_n$  cu  
 $s = a_1 + a_2 = a_{pp} + a_{nn}$ ,  $q = a_1 a_2 = a_{pp} a_{nn} - a_{pn} a_{np}$ ;
2. se calculează descompunerea QR a matricii  $M$ ;
3.  $A_2 := Q^T A Q$ .

# Vectori proprii

Considerăm două matrice asemenea  $A$  și  $B$ :

$$A \sim B \iff A = PBP^{-1}, P - \text{matrice nesingulară.}$$

Știm că cele două matrice au același polinom caracteristic,  $p_A(\lambda) \equiv p_B(\lambda)$ , deci au aceleași valori proprii.

Ne interesează care este legătura între vectorii proprii asociați aceleiași valori proprii.

Fie  $\mathbf{u}$  vector propriu asociat valorii proprii  $\lambda$  pentru matricea  $A$  și  $\mathbf{w}$  un vector propriu asociat valorii proprii  $\lambda$  pentru matricea  $B$ .

Care este relația între  $\mathbf{u}$  și  $\mathbf{w}$ ?

# Vectori proprii

$$A\mathbf{u} = \lambda\mathbf{u}, B\mathbf{w} = \lambda\mathbf{w}, A = PBP^{-1} \Rightarrow PBP^{-1}\mathbf{u} = \lambda\mathbf{u}$$

$$\Rightarrow BP^{-1}\mathbf{u} = \lambda P^{-1}\mathbf{u} \Rightarrow \mathbf{w} = P^{-1}\mathbf{u}, \mathbf{u} = P\mathbf{w}.$$

Dacă se aplică algoritmul QR unei matrice simetrice, forma Schur reală la care se ajunge este o matrice diagonală:

$$S = \Lambda = \text{diag}[\lambda_1, \lambda_2, \dots, \lambda_n].$$

Legătura dintre matricea simetrică inițială  $A$  și matricea diagonală este de forma:

$$S = \Lambda = \text{diag}[\lambda_1, \lambda_2, \dots, \lambda_n] = U^T A U$$

cu  $U$  o matrice ortogonală, coloanele matricei  $U$  fiind vectori proprii asociați valorilor proprii  $\lambda_1, \lambda_2, \dots, \lambda_n$  reale.

# Algoritmul $QR$ pentru matrice simetrice (valori+vectori proprii)

Matricea  $U$  se poate calcula astfel:

// se aduce matricea  $A$  la forma Hessenberg

- $A = \bar{Q}A\bar{Q}^T$ ;
- $U = \bar{Q}^T$ ;
- $k = 0$ ;
- while ( $A \neq$  matrice diagonală)
  - $A = QR$ ; // se calc. cu alg. Givens
  - $A = RQ$  sau  $Q^T A Q$ ;
  - $U = UQ$ ;
  - $k = k + 1$ .