

Calcul Numeric

Curs 8

A decorative horizontal band consisting of multiple overlapping, wavy, semi-transparent orange lines that create a sense of motion and depth across the middle of the slide.

Conf. dr. Anca Ignat

Conf. dr. Andreea Arusoai

April 18, 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 λ .

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 λ_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 λ 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 λ , $A\mathbf{u} = \lambda\mathbf{u}$.
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 λ , 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 λ_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 λ_1 , iar coeficienții Rayleigh corespunzători converg către λ_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 λ_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 λ_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 μ 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 λ_I este valoarea proprie cea mai apropiată de μ (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 μ , λ_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 $(A - \lambda I_n)\mathbf{w} = \mathbf{u}^{(k-1)}$;
- $\mathbf{u}^{(k)} = \frac{1}{\|\mathbf{w}\|_2} \mathbf{w}$;
- $\lambda_k = r(\mathbf{u}^{(k)}) = (A\mathbf{u}^k, \mathbf{u}^k)_{\mathbb{R}^n}$;

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 :

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

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

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

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

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

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:

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

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 β 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 λ pentru matricea A și \mathbf{w} un vector propriu asociat valorii proprii λ 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 $Q^T A Q$;
 - $U = UQ$;
 - $k = k + 1$.