

Valori Proprii (2)

Valentin-Ioan VINTILĂ

Facultatea de Automatică și Calculatoare - CTI
Universitatea POLITEHNICA București

04 aprilie 2023 (Lab. 6)



Coeficientul Rayleigh

Definiție (coeficientul Rayleigh)

Fie o matrice pătratică $A \in \mathbb{R}^{n \times n}$, $n \in \mathbb{N}^*$. Dacă $\mathbf{x} \in \mathbb{R}^n$ este un vector asociat matricei A , atunci **coeficientul Rayleigh** se definește drept **scalarul** (funcția $r: \mathbb{R}^n \rightarrow \mathbb{R}$):

$$r(\mathbf{x}) = \frac{\mathbf{x}^T A \mathbf{x}}{\|\mathbf{x}\|^2} = \left(\frac{\mathbf{x}}{\|\mathbf{x}\|} \right)^T A \left(\frac{\mathbf{x}}{\|\mathbf{x}\|} \right)$$



Metoda puterii directe - concluzii

O folosim în practică? NU! Vom vedea de ce preferăm să utilizăm metoda puterii inverse...



Metoda puterii inverse (2)

Teoremă (deplasarea spectrului)

Fie matricea pătratică $A \in \mathbb{R}^{n \times n}$, $n \in \mathbb{N}^*$. Dacă $\mu \in \mathbb{R}$, $\lambda_i \in \lambda(A)$ și $\mathbf{x} \in \mathbb{R}^n$ este vectorul propriu asociat, atunci corespondentul perechii (λ_i, \mathbf{x}) pentru A va fi $(\lambda_i - \mu, \mathbf{x})$ pentru matricea $(A - \mu I_n)$.

Puteți schița acasă o demonstrație ca temă...

Se poate demonstra matematic faptul că cea mai bună alegere a coeficientului μ este chiar λ_1 .

Evident, vom folosi aproximarea sa, $\lambda_1^{(k)}$.



Cuprins

- 1 Scurtă recapitulare
- 2 Metoda puterii inverse
- 3 Metoda deflației Householder
- 4 Metode QR
- 5 Bibliografie



Metoda puterii directe – sinteză

Trecem la algoritm – facem notația: $\mathbf{y}^{(k)} \rightarrow \mathbf{t}$

Algoritm, MPD se poate scrie astfel:

- 1 Se aproximează $\mathbf{y}^{(0)}$ (primește o valoare de început);
- 2 Pentru fiecare pas $k \in \mathbb{N}^*$, procedăm astfel:
 - Se calculează un vector auxiliar: $\mathbf{t} = A \mathbf{y}^{(k-1)}$;
 - Acest vector normalizat va fi chiar $\mathbf{y}^{(k)}$, adică $\mathbf{y}^{(k)} = \frac{\mathbf{t}}{\|\mathbf{t}\|}$;
 - Folosind coeficientul Rayleigh, se poate calcula o nouă aproximare a valorii proprii predominante:

$$\begin{aligned} \lambda_1^{(k)} &= r(\mathbf{y}^{(k)}) = \frac{(\mathbf{y}^{(k)})^T A (\mathbf{y}^{(k)})}{\|\mathbf{y}^{(k)}\|^2} \\ &= (\mathbf{y}^{(k)})^T A (\mathbf{y}^{(k)}) \end{aligned}$$



Metoda puterii inverse (1)

Metoda puterii inverse se referă la trei algoritmi distincți:

- MPI nedepasată;
- MPI deplasată;
- **MPI deplasată cu coeficient Rayleigh.**

Ne vom referi exclusiv la ultimele două!



Metoda puterii inverse – sinteză

Algoritm provine din MPD, deci MPI se poate scrie astfel:

- 1 Se aproximează $\mathbf{y}^{(0)}$ (primește o valoare de început);
- 2 Pentru fiecare pas $k \in \mathbb{N}^*$, procedăm astfel:
 - Se calculează un vector auxiliar: $\mathbf{t} = (A - \lambda_1^{(k-1)} I_n) \cdot \mathbf{y}^{(k-1)}$;
 - Acest vector normalizat va fi chiar $\mathbf{y}^{(k)}$, adică $\mathbf{y}^{(k)} = \frac{\mathbf{t}}{\|\mathbf{t}\|}$;
 - Folosind coeficientul Rayleigh, se poate calcula o nouă aproximare a valorii proprii predominante:

$$\lambda_1^{(k)} = (\mathbf{y}^{(k)})^T A (\mathbf{y}^{(k)})$$



O folosim în practică? Oarecum! Putem folosi alți algoritmi pentru a calcula toate valorile proprii!



Ne amintim forma unui reflector Householder $H \in \mathbb{R}^{n \times n}$:

$$H = I_n - 2 \cdot \frac{\mathbf{u}\mathbf{u}^T}{\|\mathbf{u}\|^2}$$

Să considerăm vectorul \mathbf{u} (aproape) ca la QR:

$$\mathbf{u} = \mathbf{x} \pm \|\mathbf{x}\| \mathbf{e}_1$$

Ne amintim că, aplicând Householder pe \mathbf{x} , se obține:

$$H\mathbf{x} = \mp \|\mathbf{x}\| \mathbf{e}_1$$



Să zicem că vrem să calculăm λ_1 pentru $A \in \mathbb{R}^{n \times n}$.

Ne definim întâi o matrice $G \in \mathbb{R}^{n \times n}$, aparent de nicăieri:

$$G = HAH^{-1} = HAH^T = HAH$$

Să considerăm $\mathbf{x} \in \mathbb{R}^n$ astfel încât $A\mathbf{x} = \lambda_1\mathbf{x}$. Putem prelucra:

$$\begin{aligned} A\mathbf{x} = \lambda_1\mathbf{x} &\Rightarrow H A \mathbf{x} = \lambda_1 H \mathbf{x} \\ &\Rightarrow H A I_n \mathbf{x} = \lambda_1 H \mathbf{x}, \text{ dar } H^2 = H H^T = H^T H = I_n \\ &\Rightarrow (H A H^T)(H \mathbf{x}) = \lambda_1 H \mathbf{x} \\ &\Rightarrow G(H \mathbf{x}) = \lambda_1(H \mathbf{x}) \end{aligned}$$



Am ajuns la relația:

$$G(H\mathbf{x}) = \lambda_1(H\mathbf{x})$$

Știm însă că $H\mathbf{x} = \alpha \mathbf{e}_1$ (am notat $\alpha = \mp \|\mathbf{x}\|$). Deci:

$$\alpha G \mathbf{e}_1 = \lambda_1 \alpha \mathbf{e}_1 \Rightarrow \boxed{G \mathbf{e}_1 = \lambda_1 \mathbf{e}_1}$$

Ce înseamnă asta?

$$G = \begin{bmatrix} \lambda_1 & \square \in \mathbb{R}^{1 \times (n-1)} \\ 0 \in \mathbb{R}^{(n-1) \times 1} & A' \in \mathbb{R}^{(n-1) \times (n-1)} \end{bmatrix}$$



Algoritm, metoda deflației Householder se poate scrie astfel:

- Se calculează λ_1 și vectorul propriu asociat al matricei A folosind MPD sau MPI;
- Se calculează $\mathbf{u} = \mathbf{x} \pm \|\mathbf{x}\| \mathbf{e}_1$;
- Se calculează reflectorul Householder $H = I_n - 2 \cdot \frac{\mathbf{u}\mathbf{u}^T}{\|\mathbf{u}\|^2}$;
- Se calculează matricea $G = HAH$;
- Se extrage λ_1 din colțul din stânga sus și se continuă algoritmul pe submatricea $G(2:n, 2:n)$ pentru a afla restul valorilor proprii.



O folosim în practică? Oarecum! A început să vă placă răspunsul ăsta...

Metoda este instabilă numeric dacă se vrea calcularea a mai mult de 3-4 valori proprii. Trebuie deci să găsim altceva...



Mai există și alte metode de deflație.

Nu insistăm, dar vă amintesc:

- Deflația Wielandt (se discută la curs, resursele pe internet sunt aproape inexistente);
- Cazul său general, deflația Hotelling.



Fie $A \in \mathbb{R}^{n \times n}$ o matrice pătratică, $n \in \mathbb{N}^*$.

Vom nota cu $\mathbf{y}_i^{(k)}$ vectorul propriu (la a k -a iterație) ce este asociat valorii proprii λ_i . Suplimentar, vom considera momentan cunoscut vectorul propriu \mathbf{q}_1 asociat cu λ_1 .

Vrem acum să studiem vectorul $\mathbf{y}_2^{(k)}$.

Întrucât am stabilit deja că $\mathbf{y}_1^{(k)}$ va fi un vector cu norma 1, dorim să îl scriem pe $\mathbf{y}_2^{(k)}$ în aceeași manieră.



Vom simplifica și mai mult lucrurile, cerând:

$$\mathbf{y}'_1^{(k)} \perp \mathbf{y}'_2^{(k)}$$

Cum facem asta? **Gram-Schmidt** – proiecția lui $\mathbf{y}'_2^{(k)}$ pe \mathbf{q}_1 poate fi scrisă sub forma $\langle \mathbf{q}_1, \mathbf{y}'_2^{(k)} \rangle \mathbf{q}_1$, deci:

$$\mathbf{y}'_2^{(k)} \rightarrow \mathbf{y}'_2^{(k)} - \langle \mathbf{q}_1, \mathbf{y}'_2^{(k)} \rangle \mathbf{q}_1$$



Apoi, la fiecare pas $k \geq 1$, se va obține o aproximare tot mai bună astfel:

- Se calculează $\mathbf{y}'_1^{(k)}$: considerăm vectorul auxiliar $\mathbf{t}_1 = A\mathbf{y}'_1^{(k-1)}$.
Normalizat, ne dă: $\mathbf{y}'_1^{(k)} = \frac{\mathbf{t}_1}{\|\mathbf{t}_1\|}$;
- Se calculează $\mathbf{y}'_2^{(k)}$: considerăm $\mathbf{t}_{21} = A\mathbf{y}'_2^{(k-1)}$ a cărei componentă de pe $\mathbf{y}'_1^{(k)}$ va fi eliminată, adică $\mathbf{t}_{22} = \mathbf{t}_{21} - \langle \mathbf{q}_1, \mathbf{y}'_2^{(k)} \rangle \mathbf{q}_1$;
- Prin coeficientul Rayleigh, obținem:

$$\begin{cases} \lambda_1^{(k)} = (\mathbf{y}'_1^{(k)})^T A (\mathbf{y}'_1^{(k)}) \\ \lambda_2^{(k)} = (\mathbf{y}'_2^{(k)})^T A (\mathbf{y}'_2^{(k)}) \end{cases}$$



Vom folosi matricea $\Lambda^{(k)} \in \mathbb{R}^{2 \times 2}$ pentru a dispune valorile proprii calculate la a k -a iterație pe diagonala principală. Astfel, putem restrânge calcularea valorilor λ_1 , respectiv λ_2 , la următorul produs:

$$\begin{bmatrix} \lambda_1^{(k)} & 0 \\ 0 & \lambda_2^{(k)} \end{bmatrix} = \begin{bmatrix} \mathbf{y}'_1^{(k)} \\ \mathbf{y}'_2^{(k)} \end{bmatrix}^T A \begin{bmatrix} \mathbf{y}'_1^{(k)} & \mathbf{y}'_2^{(k)} \end{bmatrix} \Rightarrow \Lambda^{(k)} = (\tilde{\mathbf{Y}}^{(k)})^T A (\tilde{\mathbf{Y}}^{(k)})$$

Acceptăm fără demonstrație că această metodă poate fi generalizată pentru a afla oricâte valori proprii, să zicem $p \in \mathbb{N}^*$.



Anterior, am folosit doar matricea Q din factorizarea QR – o risipă totală față de matricea R !

Vom găsi un algoritm ce folosește această matrice R , un algoritm cu adevărat **fantastic**!

De data aceasta pornim de la algoritm și facem abia după demonstrația.



Am presupus însă cunoscut \mathbf{q}_1 ! În practică, am putea rula în paralel MPD pentru $\mathbf{y}'_1^{(k)}$, adică $\mathbf{q}_1 \approx \mathbf{y}'_1^{(k)}$.

Sintetizat, am avea pentru început:

- $\mathbf{y}'_1^{(0)}$ și $\mathbf{y}'_2^{(0)}$ primesc o aproximare de început;
- Se ortogonalizează $\mathbf{y}'_2^{(0)}$ în raport cu $\mathbf{y}'_1^{(0)}$, adică:

$$\mathbf{y}'_2^{(0)} \rightarrow \mathbf{y}'_2^{(0)} - \langle \mathbf{q}_1, \mathbf{y}'_2^{(0)} \rangle \mathbf{q}_1$$

- Se normalizează $\mathbf{y}'_1^{(0)}$ și $\mathbf{y}'_2^{(0)}$;



De ce am făcut toate astea? Toată discuția anterioară este ca să înțelegem legătura cu QR.

Inițial, am ortonat $\mathbf{y}'_1^{(0)}$ și $\mathbf{y}'_2^{(0)}$. Echivalent, se poate calcula o matrice ortogonală $\tilde{\mathbf{Y}}^{(0)}$ prin QR:

$$(\tilde{\mathbf{Y}}^{(0)}, R) = QR \left(\begin{bmatrix} \mathbf{y}'_1^{(0)} & \mathbf{y}'_2^{(0)} \end{bmatrix} \right) = QR \left(\mathbf{Y}^{(0)} \right)$$

De altfel, în orice pas k , se poate calcula o matrice ortogonală $\tilde{\mathbf{Y}}^{(k)}$:

$$(\tilde{\mathbf{Y}}^{(k)}, R) = QR \left(A \begin{bmatrix} \mathbf{y}'_1^{(k-1)} & \mathbf{y}'_2^{(k-1)} \end{bmatrix} \right) = QR \left(A \tilde{\mathbf{Y}}^{(k-1)} \right)$$



Sintetizată, discuția anterioară devine:

- Se calculează $(\tilde{\mathbf{Y}}^{(0)}, R) = QR \left(\begin{bmatrix} \mathbf{y}'_1^{(0)} & \mathbf{y}'_2^{(0)} & \dots & \mathbf{y}'_p^{(0)} \end{bmatrix} \right)$
- Pentru fiecare pas $k \geq 1$, se va obține o aproximare tot mai bună:
 - Calculăm $(\tilde{\mathbf{Y}}^{(k)}, R) = QR \left(A \tilde{\mathbf{Y}}^{(k-1)} \right)$ (se ignoră valoarea R , aceasta nu este utilă);
 - Se aproximează valorile proprii, adică $\Lambda^{(k)} = (\tilde{\mathbf{Y}}^{(k)})^T A (\tilde{\mathbf{Y}}^{(k)})$.



Algoritm, metoda funcționează astfel:

- Pornim de la $\Lambda^{(0)} = A$, respectiv $\mathbf{Y}^{(0)} = Q^{(0)} = R^{(0)} = I_n$;
- Pentru fiecare pas $k \geq 1$, se va obține o aproximare tot mai bună:
 - Se calculează: $(Q^{(k)}, R^{(k)}) = QR \left(\Lambda^{(k-1)} \right)$;
 - Se aproximează valorile proprii, adică $\Lambda^{(k)} = R^{(k)} Q^{(k)}$;
 - Se calculează vectorii proprii, deci $\mathbf{Y}^{(k)} = \mathbf{Y}^{(k-1)} Q^{(k)}$.



Metoda QR nedepasată – explicație (1)

Deoarece $(Q^{(k)}, R^{(k)}) = QR(\Lambda^{(k-1)})$, știm că $Q^{(k)}R^{(k)} = \Lambda^{(k-1)}$.

Echivalent, $R^{(k)} = (Q^{(k)})^{-1}\Lambda^{(k-1)}$. Înlocuind în calculul valorilor proprii (adică în $\Lambda^{(k)} = R^{(k)}Q^{(k)}$), se obține că:

$$\Lambda^{(k)} = (Q^{(k)})^{-1}\Lambda^{(k-1)}Q^{(k)}$$

Ce e asta? O transformare de asemănare!

$$\Lambda^{(k)} \sim \Lambda^{(k-1)}$$



Metoda QR nedepasată – explicație (2)

Dacă știm:

$$\Lambda^{(k)} \sim \Lambda^{(k-1)}$$

...este evident că putem ajunge la:

$$\Lambda^{(k)} \sim \Lambda^{(k-1)} \sim \dots \sim \Lambda^{(0)}$$

Dat fiind că $\Lambda^{(0)} = A$, obținem că:

$$\Lambda^{(k)} \sim A \Rightarrow \lambda(\Lambda^{(k)}) = \lambda(A)$$



Metoda QR nedepasată – explicație (3)

Amintim încă o dată formula:

$$\Lambda^{(k)} = (Q^{(k)})^T \Lambda^{(k-1)} Q^{(k)}$$

Putem obține treptat ceva interesant:

$$\begin{aligned} \Lambda^{(k)} &= (Q^{(k)})^T \Lambda^{(k-1)} Q^{(k)} \\ &= (Q^{(k)})^T (Q^{(k-1)})^T \Lambda^{(k-2)} Q^{(k-1)} Q^{(k)} \\ &= \dots \\ &= [(Q^{(k)})^T \dots (Q^{(0)})^T] \cdot A \cdot [Q^{(0)} \dots Q^{(k)}] \\ &= (Y^{(k)})^T A Y^{(k)} \end{aligned}$$



Metoda QR nedepasată – explicație (4)

Am mai întâlnit această formulă odată!

Deși incompletă, demonstrația prezentată ar trebui să fie suficientă cât să vă demonstreze că **algoritmul funcționează!**



Metoda QR nedepasată - concluzii

O folosim în practică? **NU!** Este utilă din punct de vedere teoretic, dar are câteva probleme...

De exemplu, nu converge pe:

$$A = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}$$

Puteți demonstra acest lucru ca temă...



Metoda QR deplasată

Cum am îmbunătățit MPD?

Similar, vom folosi niște coeficienți $\mu^{(k)} \in \mathbb{R}$ pentru deplasare!



Metoda QR deplasată – sinteză

Algoritmic, metoda funcționează astfel:

- Pornim de la $\Lambda^{(0)} = A$, respectiv $Y^{(0)} = Q^{(0)} = R^{(0)} = I_n$;
- Pentru fiecare pas $k \geq 1$, se va obține o aproximare tot mai bună:
 - Se calculează cumva $\mu^{(k)}$ – există mai multe strategii, vom vedea imediat câteva dintre ele;
 - Se calculează: $(Q^{(k)}, R^{(k)}) = QR(\Lambda^{(k-1)} - \mu^{(k)}I_n)$;
 - Se aproximează **valorile proprii**, adică $\Lambda^{(k)} = R^{(k)}Q^{(k)} + \mu^{(k)}I_n$;
 - Se calculează **vectorii proprii**, deci $Y^{(k)} = Y^{(k-1)}Q^{(k)}$.



Metoda QR deplasată – alegerea lui μ

Putem calcula $\mu \in \mathbb{R}$ în următoarele moduri:

- **Coefficient Rayleigh:**

$$\mu^{(k)} = r(A_n^{(k)}) = \dots = A_{nn}^{(k)}$$

- **Shiftare Wilkinson:** să notăm cu B matricea 2×2 aflată în colțul din dreapta jos al matricei $A^{(k)}$:

$$B = \begin{bmatrix} a_{m-1} & b_{m-1} \\ b_{m-1} & a_m \end{bmatrix}$$

$$\text{Atunci } \mu^{(k)} = a_m - \text{sign}(\delta) \cdot \frac{b_{m-1}^2}{|\delta| + \sqrt{\delta^2 + b_{m-1}^2}}, \text{ unde } \delta = \frac{a_{m-1} - a_m}{2}$$



O folosim în practică? **DA!** Este o bijuterie numerică!

Toate resursele bibliografice de care aveți nevoie se găsesc în descrierea cu care a venit atașată această prezentare



Metode Numerice Matriceale – concluzii

Metode Numerice Matriceale – feedback

Am încheiat ultimul capitol din metodele numerice matriceale!

Propun un al doilea Kahoot care să treacă prin toate noțiunile!

...dar de data aceasta cu premii!

Acum, o să vă rog pe toți cei prezenți să completați un formular de feedback **diferit**, dedicat metodelor numerice matriceale!



Sfârșit

Mulțumesc frumos pentru atenție!

Vă rog frumos să **completați formularul de feedback!**

