

Usporedba dva algoritma Jacobijevog tipa za svojstvene vrijednosti općih kompleksnih matrica

Mate Kosor¹

¹Pomorski odjel, Sveučilište u Zadru

Seminar za numeričku matematiku i znanstveno računanje
Zagreb, 4. rujna 2014.

Sadržaj predavanja

- 1 Svojstvene vrijednosti
 - Osnovni problem
 - Posebni slučajevi
 - Numeričko rješavanje
- 2 Iterativne metode Jacobijevog tipa za simetrične i druge tipove matrica
 - Simetrične realne matrice
 - Hermitske i antihermitske kompleksne matrice
 - Normalne matrice, Goldstine & Horwitz (1959)
- 3 Iterativne metode Jacobijevog tipa za općenite matrice
 - Eberlein, Ruhe, ...
 - Greenstadt, Mehl, ...
- 4 Diskusija - Zaključak

Svojstvene vrijednosti

- $\lambda \in \mathbb{F}$ svojstvena vrijednosti, a $v \in \mathbb{F}^n$ svojstveni vektor matrice $A \in \mathbb{F}^{n \times n}$ kada:

$$Av = \lambda v.$$

Nultočke karakterističnog polinoma: $\det(A - \lambda I) = 0$

Ovisi o polju \mathbb{F} : \mathbb{R} ili \mathbb{C} . Biramo \mathbb{C} jer je izbor svojstvenih vrijednosti veći (osnovni teorem algebre).

Svojstvene vrijednosti

- $\lambda \in \mathbb{F}$ svojstvena vrijednosti, a $v \in \mathbb{F}^n$ svojstveni vektor matrice $A \in \mathbb{F}^{n \times n}$ kada:

$$Av = \lambda v.$$

Nultočke karakterističnog polinoma: $\det(A - \lambda I) = 0$

Ovisi o polju \mathbb{F} : \mathbb{R} ili \mathbb{C} . Biramo \mathbb{C} jer je izbor svojstvenih vrijednosti veći (osnovni teorem algebre).

- za $D = \text{diag}(\lambda_1, \lambda_2, \dots)$, te $X = [v_1 \ v_2 \ \dots]$ imamo:

$$AX = XD$$

Svojstvene vrijednosti

- $\lambda \in \mathbb{F}$ svojstvena vrijednosti, a $v \in \mathbb{F}^n$ svojstveni vektor matrice $A \in \mathbb{F}^{n \times n}$ kada:

$$Av = \lambda v.$$

Nultočke karakterističnog polinoma: $\det(A - \lambda I) = 0$

Ovisi o polju \mathbb{F} : \mathbb{R} ili \mathbb{C} . Biramo \mathbb{C} jer je izbor svojstvenih vrijednosti veći (osnovni teorem algebre).

- za $D = \text{diag}(\lambda_1, \lambda_2, \dots)$, te $X = [v_1 \ v_2 \ \dots]$ imamo:

$$AX = XD$$

- kada se od svojstvenih vektora može sastaviti baza $X = [v_1 \ v_2 \ \dots \ v_n]$ matricu A nazivamo dijagonalizabilna:

$$A = XDX^{-1}$$

Matricu koje nisu dijagonalizabilna nazivamo defektnom.

Transformacije sličnosti

A dijagonalizabilna:

ako za neku regularnu matricu X i dijagonalnu D vrijedi:

$$A = X D X^{-1}$$

Transformacije sličnosti

A dijagonalizabilna:

ako za neku regularnu matricu X i dijagonalnu D vrijedi:

$$A = X D X^{-1}$$

A i B su unitarno slične:

ako za neku unitarnu matricu Q vrijedi:

$$A = Q B Q^{-1}$$

A i B su slične:

ako za neku regularnu matricu X vrijedi:

$$A = X B X^{-1}$$

Unitarne transformacije sličnosti pokazuju bolja numerička svojstva: ne treba računati inverz $Q^{-1} = Q^*$, čuva se normalnost, hermitičnost, unitarnost, ne povećava se razina perturbacija...

Transformacije sličnosti

A dijagonalizabilna:

ako za neku regularnu matricu X i dijagonalnu D vrijedi:

$$A = X D X^{-1}$$

A i B su slične:

ako za neku regularnu matricu X vrijedi:

$$A = X B X^{-1}$$

A i B su unitarno slične:

ako za neku unitarnu matricu Q vrijedi:

$$A = Q B Q^{-1}$$

A je normalna matrica:

- ako i samo ako: $A^* A = A A^*$
- ako i samo ako je unitarno slična dijagonalnoj:

$$A = Q D Q^*$$

Unitarne transformacije sličnosti pokazuju bolja numerička svojstva: ne treba računati inverz $Q^{-1} = Q^*$, čuva se normalnost, hermitičnost, unitarnost, ne povećava se razina perturbacija...

Matrične dekompozicije koje otkrivaju svojstvene vrijednosti

Schurova forma

Za proizvoljnu kvadratnu matricu A postoji ortogonalno slična trokutasta matrica, tj.

$$A = Q \begin{bmatrix} \lambda_1 & * & * & \cdots & * \\ 0 & \lambda_2 & * & \cdots & * \\ 0 & 0 & \lambda_3 & \cdots & * \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \cdots & \lambda_n \end{bmatrix} Q^*$$

Matrične dekompozicije koje otkrivaju svojstvene vrijednosti

Jordanova forma

Za proizvoljnu kvadratnu matricu A postoji slična blok-dijagonalna matrica (blokovi B_1, \dots, B_k)

$$A = X \begin{bmatrix} B_1 & & & \\ & B_2 & & \\ & & \ddots & \\ & & & B_k \end{bmatrix} X^{-1}$$

gdje su blokovi bidijagonalni oblika $B = \begin{bmatrix} \lambda & 1 & & \\ & \ddots & \ddots & \\ & & \ddots & \\ & & & 1 \\ & & & & \lambda \end{bmatrix}$.

Kako testirati dijagonalizabilnost?

Slika sa podkupovima matrica... TODO

QR metoda za općenite matrice (1961)

Iterativna metoda: $A_1 \stackrel{\text{def}}{=} A$, za $k \in \mathbb{N}$

① napravi QR rastav: $A_k = Q_k R_k$,

$$\begin{aligned} \textcircled{2} \quad A_{k+1} &\stackrel{\text{def}}{=} R_k Q_k \\ &= Q_k^{-1} Q_k R_k Q_k \\ &= Q_k^{-1} A_k Q_k \\ &= Q_k^T A_k Q_k \end{aligned}$$

- numerički stabilna,
- pod određenim uvjetima (sporo) konvergira
- svaka iteracija je skupa: $\mathcal{O}(n^3)$

QR metoda za općenite matrice (1961)

Iterativna metoda: $A_1 \stackrel{\text{def}}{=} A$, za $k \in \mathbb{N}$

① napravi QR rastav: $A_k = Q_k R_k$,

$$\begin{aligned} \textcircled{2} \quad A_{k+1} &\stackrel{\text{def}}{=} R_k Q_k \\ &= Q_k^{-1} Q_k R_k Q_k \\ &= Q_k^{-1} A_k Q_k \\ &= Q_k^T A_k Q_k \end{aligned}$$

- numerički stabilna,
- pod određenim uvjetima (sporo) konvergira
- svaka iteracija je skupa: $\mathcal{O}(n^3)$

Modifikacija:

- svaka iteracija QR metode čuva Hessenbergovu formu

$$A = Q \begin{bmatrix} * & * & \cdots & * \\ * & \ddots & \ddots & \vdots \\ & \ddots & \ddots & * \\ & & * & * \end{bmatrix} Q$$

- Q (hermitska) Hausholderova transformacija
- konačno $\frac{10}{3}n^3 + \mathcal{O}(n^2)$ operacija
- brža, sigurna konvergencija i jeftinije QR iteracije: $6n^2 + \mathcal{O}(n)$

QR metoda nije savršena:

- Čuva Hessenbergovu, tridijagonalnu i neke druge slične forme, ali **nije prilagođena za sve matrične strukture**
 - ne čuva Hamiltonovu formu $H = \begin{bmatrix} A & C \\ D & -A^T \end{bmatrix}$, za C i D simetrične,
 - itd.

QR metoda nije savršena:

- Čuva Hessenbergovu, tridijagonalnu i neke druge slične forme, ali **nije prilagođena za sve matične strukture**
 - ne čuva Hamiltonovu formu $H = \begin{bmatrix} A & C \\ D & -A^T \end{bmatrix}$, za C i D simetrične,
 - itd.
- Stabilna (natrag), svojstvene vrijednosti računa s malom apsolutnom greškom (ovisi o spektralnoj normi, dimenziji matrice i mašinskoj preciznosti),
 - ali izračunate **malene svojstvene vrijednosti mogu imati veliku relativnu grešku**.
 - Redukcija na Hessenbergovu formu može uzrokovati velike relativne greške malenih svojstvenih vrijednosti.
- Paralelizacija...

Svojstvene vrijednosti 2x2 simetrične realne matrice

Theorem

(E. Carlen, *Calculus++*, 2003) Svojstvene vrijednosti matrice

$$A = \begin{bmatrix} a & b \\ b & d \end{bmatrix} \text{ su}$$

$$\lambda_{1,2} = \frac{a+d}{2} \pm \sqrt{b^2 + \left(\frac{a-d}{2}\right)^2}.$$

Svojstveni vektori koji čine ortonormalnu bazu $\{u_1, u_2\}$ mogu se izračunati preko

$$\begin{bmatrix} r_1^T \\ r_2^T \end{bmatrix} = A - \lambda_1 I, \quad u_1 = \frac{1}{|r_1|} r_1^\perp, \quad u_2 = u_1^\perp$$

Jacobijeva metoda za simetričnu realnu matricu (1846,1949)

Na matrici $A = (a_{ij})$ sprovedi:

- Ponavljaj dok A nije skoro dijagonalna (sweep):
 - za $i = 2, \dots, n$, te $j = 1, \dots, i-1$ (redosljed)
 - $A \leftarrow G A G^T$ (iteracija), gdje je $G = G(i, j, \theta)$

1 nakon transformacije sličnosti

$$a_{ij} = a_{ji} = 0$$

2 iteracija mijenja 2 stupca i 2 retka

3 dovoljno je (pažljivo) izračunati

$$c = \cos \theta \text{ i } s = \sin \theta$$

$G(i, j, \theta)$ = Givensova rotacija

$$\begin{bmatrix} 1 & \cdots & 0 & \cdots & 0 & \cdots & 0 \\ \vdots & \ddots & \vdots & & \vdots & & \vdots \\ 0 & \cdots & c & \cdots & -s & \cdots & 0 \\ \vdots & & \vdots & \ddots & \vdots & & \vdots \\ 0 & \cdots & s & \cdots & c & \cdots & 0 \\ \vdots & & \vdots & & \vdots & \ddots & \vdots \\ 0 & \cdots & 0 & \cdots & 0 & \cdots & 1 \end{bmatrix}$$

rotacija u (i, j) ravnini za kut θ

Konvergenca i stabilnost Jacobijeve metode za simetrične matrice

- još 1950-tih prvi rezultati o kvadratičnoj asimptotskoj (lokalnoj) konvergenciji Jacobijeve metode
- temelje se na minimizaciji off-norme

$$\text{off}(A) = \sqrt{\sum_{i \neq j} |a_{ij}|^2}$$

Konvergencija i stabilnost Jacobijeve metode za simetrične matrice

- još 1950-tih prvi rezultati o kvadratičnoj asimptotskoj (lokalnoj) konvergenciji Jacobijeve metode
- temelje se na minimizaciji off-norme

$$\text{off}(A) = \sqrt{\sum_{i \neq j} |a_{ij}|^2}$$

- konvergenciju je moguće ubrzati izborom specifičnog redosljeda iteracija, pa čak pokazati i globalnu konvergenciju
 - npr. Rhee & Hari (1993), *On the global and cubic convergence of quasi-cyclic Jacobi method*, Numerische Mathematik
- nudi relativnu točnost i za malene svojstvene vrijednosti
 - Demmel & Veselić (1992), *Jacobi's method is more accurate than QR*, SIAM J. Matrix Anal. Appl.

Na općoj matrici donedavno nije dokazana niti globalna niti lokalna konvergencija!

Greenstadt (1955): θ t.d. poništi a_{ij} ispod dijagonale \rightarrow Schurova forma

$$\begin{bmatrix} 1 & & & & & & \\ & \overline{u_{ij}} & & & & & \\ & & 1 & & & & \\ & & & 1 & & & \\ & \overline{u_{ij}} & & & \overline{u_{jj}} & & \\ & & & & & & 1 \end{bmatrix} \begin{matrix} \overbrace{\begin{bmatrix} * & * & * & * & * & * \\ \cdot & * & * & * & * & * \\ \cdot & \cdot & * & * & * & * \\ \cdot & \cdot & \cdot & * & * & * \\ \cdot & a_{ij} & \cdot & \cdot & * & * \\ \cdot & \cdot & \cdot & \cdot & \cdot & * \end{bmatrix}}^A \\ \underbrace{\begin{bmatrix} 1 & & & & & & \\ & u_{ij} & & & & & \\ & & 1 & & & & \\ & & & 1 & & & \\ & u_{ji} & & & u_{jj} & & \\ & & & & & & 1 \end{bmatrix}}^G \\ = \end{matrix} \begin{bmatrix} * & * & * & * & * & * \\ * & * & * & * & * & * \\ \cdot & * & * & * & * & * \\ \cdot & * & \cdot & * & * & * \\ * & 0 & * & * & * & * \\ \cdot & * & \cdot & \cdot & * & * \end{bmatrix}$$

Problem: $A = \begin{bmatrix} 1 & 1 & 0 \\ 0 & 1 & 1 \\ \varepsilon & 0 & 1 \end{bmatrix} \rightsquigarrow \begin{bmatrix} 1 & 0 & \varepsilon \\ 1 & 1 & 0 \\ 0 & 1 & 1 \end{bmatrix} \rightsquigarrow \begin{bmatrix} 1 & 1 & 0 \\ 0 & 1 & \varepsilon \\ 1 & 0 & 1 \end{bmatrix}$

$$\rightsquigarrow \begin{bmatrix} 1 & 0 & 1 \\ \varepsilon & 1 & 0 \\ 0 & 1 & 1 \end{bmatrix} \rightsquigarrow \begin{bmatrix} 1 & \varepsilon & 0 \\ 0 & 1 & 1 \\ 1 & 0 & 1 \end{bmatrix} \rightsquigarrow \begin{bmatrix} 1 & 0 & 1 \\ 1 & 1 & 0 \\ 0 & \varepsilon & 1 \end{bmatrix} \rightsquigarrow \begin{bmatrix} 1 & 1 & 0 \\ 0 & 1 & 1 \\ \varepsilon & 0 & 1 \end{bmatrix}$$

Jacobijeva metoda se može generalizirati na hermitske matrice

Kod matrica nad \mathbb{C} Givensove rotacije ovise o dva realna parametra (kuta) ψ i ϕ . U slučaju hermitske matrice A ($a_{ji} = \overline{a_{ij}}$) moguće je “naštimiti” parametre tako da se u k -toj iteraciji ponište pivoti

$$a_{ij}^{(k+1)} = a_{ji}^{(k+1)} = 0.$$

$$\begin{bmatrix} \cos \phi_k & -e^{i\psi_k} \sin \phi_k \\ e^{-i\psi_k} \sin \phi_k & \cos \phi_k \end{bmatrix} \begin{bmatrix} a_{ii}^{(k)} & a_{ij}^{(k)} \\ a_{ji}^{(k)} & a_{jj}^{(k)} \end{bmatrix} \begin{bmatrix} \cos \phi_k & e^{i\psi_k} \sin \phi_k \\ -e^{-i\psi_k} \sin \phi_k & \cos \phi_k \end{bmatrix} = \begin{bmatrix} a_{ii}^{(k+1)} & 0 \\ 0 & a_{jj}^{(k+1)} \end{bmatrix}$$

Jacobijeva metoda se može generalizirati na hermitske matrice

Kod matrica nad \mathbb{C} Givensove rotacije ovise o dva realna parametra (kuta) ψ i ϕ . U slučaju hermitske matrice A ($a_{ji} = \overline{a_{ij}}$) moguće je “naštimiti” parametre tako da se u k -toj iteraciji ponište pivoti

$$a_{ij}^{(k+1)} = a_{ji}^{(k+1)} = 0.$$

$$\begin{bmatrix} \cos \phi_k & -e^{i\psi_k} \sin \phi_k \\ e^{-i\psi_k} \sin \phi_k & \cos \phi_k \end{bmatrix} \begin{bmatrix} a_{ii}^{(k)} & a_{ij}^{(k)} \\ a_{ji}^{(k)} & a_{jj}^{(k)} \end{bmatrix} \begin{bmatrix} \cos \phi_k & e^{i\psi_k} \sin \phi_k \\ -e^{-i\psi_k} \sin \phi_k & \cos \phi_k \end{bmatrix} = \begin{bmatrix} a_{ii}^{(k+1)} & 0 \\ 0 & a_{jj}^{(k+1)} \end{bmatrix}$$

- Jacobijev tip algoritma ima svojstva kao kod simetrične realne matrice
- slično je za antihermitske matrice

Modifikacija Jacobijeve metode za normalne matrice

Test, Goldstine & Horwitz (1959):

$$|a_{ij} + \overline{a_{ji}}|^2 + [\operatorname{Re}(a_{ii} - a_{jj})]^2 \stackrel{?}{\leq} |a_{ij} - \overline{a_{ji}}|^2 + [\operatorname{Im}(a_{ii} - a_{jj})]^2$$

Ako test \geq : odaberi ϕ i ψ t.d

$$\operatorname{Im}(a_{ij} - a_{ji}) \cos \psi - \operatorname{Re}(a_{ij} + a_{ji}) \sin \psi = 0$$

$$\cos \psi \operatorname{Re}(a_{ij} + a_{ji}) \geq 0$$

$$\tan 2\phi = \frac{|a_{ij} + \overline{a_{ji}}|}{\operatorname{Re}(a_{ii} - a_{jj})} \quad \text{i} \quad \sin \phi \operatorname{Re}(a_{ii} - a_{jj}) \geq 0$$

Ako test $<$: odaberi ϕ i ψ t.d

$$\operatorname{Re}(a_{ij} - a_{ji}) \cos \psi + \operatorname{Im}(a_{ij} + a_{ji}) \sin \psi = 0$$

$$\cos \psi \operatorname{Im}(a_{ij} + a_{ji}) \geq 0$$

$$\tan 2\phi = \frac{|a_{ij} - \overline{a_{ji}}|}{\operatorname{Im}(a_{ii} - a_{jj})} \quad \text{i} \quad \phi \text{ opet manji izbor}$$

$$R = \begin{bmatrix} \cos \phi & e^{i\psi} \sin \phi \\ -e^{-i\psi} \sin \phi & \cos \phi \end{bmatrix}$$

Preinaka s normalnih na općenite matrice

- samo za normalnu A vrijedi $\|A\|_F^2 = \sum_{i=1}^n |\lambda_i|^2$ i
 $AA^* - A^*A = O$
- smicanje $S = S(y, \beta) = \begin{bmatrix} \cosh y & -ie^{i\beta} \sinh y \\ -ie^{-i\beta} \sinh y & \cosh y \end{bmatrix}$ generira transformaciju sličnosti (nije unitarna)

Preinaka s normalnih na općenite matrice

- samo za normalnu A vrijedi $\|A\|_F^2 = \sum_{i=1}^n |\lambda_i|^2$ i
 $AA^* - A^*A = O$
- smicanje $S = S(y, \beta) = \begin{bmatrix} \cosh y & -ie^{i\beta} \sinh y \\ -ie^{-i\beta} \sinh y & \cosh y \end{bmatrix}$ generira transformaciju sličnosti (nije unitarna)
- Eberlein (1962): moguće je odabrati smicanje S tako da (globalna konvergencija)

$$\|A\|_F^2 - \|S^{-1}AS\|_F^2 \geq \frac{1}{3} \frac{1}{n(n-1)} \|AA^* - A^*A\|_F^2$$

- Eberlein (1970): “isprepliće” Givensove rotacije za normalne matrice sa transformacijama smicanja:

$$S_k^{-1} R_k^* \dots S_1^{-1} R_1^* A R_1 S_1 \dots R_k S_k \xrightarrow{k} \begin{array}{l} \longrightarrow \text{prostor normalnih matrica} \\ \longrightarrow \text{dijagonalizacija} \end{array}$$

Preinaka s normalnih na općenite matrice

- Eberlein (1962): moguće je odabrati smicanje S tako da (globalna konvergencija)

$$\|A\|_F^2 - \|S^{-1}AS\|_F^2 \geq \frac{1}{3} \frac{1}{n(n-1)} \|AA^* - A^*A\|_F^2$$

- Eberlein (1970): “isprepliće” Givensove rotacije za normalne matrice sa transformacijama smicanja:

$$S_k^{-1}R_k^* \dots S_1^{-1}R_1^* A \underbrace{R_1S_1}_{W_1} \dots \underbrace{R_kS_k}_{W_k} \xrightarrow{k} \begin{array}{l} \longrightarrow \text{prostor normalnih matrica} \\ \longrightarrow \text{dijagonalizacija} \end{array}$$

- dio Wilkinson-Reinsch kolekcije

Preinaka s normalnih na općenite matrice

- Eberlein (1962): moguće je odabrati smicanje S tako da (globalna konvergencija)

$$\|A\|_F^2 - \|S^{-1}AS\|_F^2 \geq \frac{1}{3} \frac{1}{n(n-1)} \|AA^* - A^*A\|_F^2$$

- Eberlein (1970): “isprepliće” Givensove rotacije za normalne matrice sa transformacijama smicanja:

$$S_k^{-1} R_k^* \dots S_1^{-1} R_1^* A \underbrace{R_1 S_1}_{W_1} \dots \underbrace{R_k S_k}_{W_k} \xrightarrow{k} \begin{array}{l} \longrightarrow \text{prostor normalnih matrica} \\ \longrightarrow \text{dijagonalizacija} \end{array}$$

- dio Wilkinson-Reinsch kolekcije
- Ruhe (1968): blaga modifikacija Eberlein algoritma
 - pokazao asimptotsku kvadratičnu konvergenciju za općenite kompleksne matrice

Eberlein (1970) procedura *eigen* (pojednostavljeno)

- Počni sa $W = I$.
- Sigurnosna petlja (35 iterations max)
 - 1 $(\mathcal{O}(n^2))$ pripremi varijable koje mjere konvergenciju
 $\tau = \sum_{i \neq j} |\operatorname{Re}(a_{ij})| + |\operatorname{Im}(a_{ij})|$, $en[j] = \sum_i |\operatorname{Re}(a_{ij})| + |\operatorname{Im}(a_{ij})|$
(1-norma j -tog stupca)
 - 2 $(\mathcal{O}(n^2))$ Sortiraj stupce (i retke) of A (koristi en), promijeni W na odgovarajući način (zamijeni stupce)
 - 3 Ako $\tau < 100\varepsilon$ izađi iz petlje
 - 4 Napravi sweep: $\frac{n^2}{2}$ transformacija (rotacija i smicanja zajedno): NE poredak
 - A) temeljem unosa u stupcima i retcima sa indeksima i, j izračunaj S i R , $(\mathcal{O}(n))$
 - B) $W \leftarrow W S R$, $(\mathcal{O}(n))$
 - C) $A \leftarrow R^* S^{-1} A S R$ $(\mathcal{O}(n))$

Eberlein (1970) implementacija

- Sage: alternativa za Matlab, Mathematicu, itd.
- koristi double na IntelCore i5
- ispisuje $\tau = \sum_{i \neq j} |\operatorname{Re}(a_{ij})| + |\operatorname{Im}(a_{ij})|$ za svaki sweep
- trajanje \approx broj sweepova
- osim originalnog algoritma čiji su rezultati ponovljeni iskušao i neke modifikacije (bez nekog posebnog uspjeha)
- pokazati primjere 2 i 3
- očekivanje $\tau \rightarrow 0$ asimptotski kvadratično

Zašto Jacobi ima problema na općenitim matricama?

Mehl (2008): modifikacija Greenstadt algoritma

$$\begin{array}{l} \Downarrow \\ \text{odozgo} \\ \text{prema} \\ \text{dolje} \end{array} \begin{bmatrix} * & * & * & * & * & * \\ . & \circ & * & * & \circ & * \\ . & \diamond & * & * & \bullet & * \\ . & \diamond & . & * & \bullet & * \\ . & \circ & . & . & \circ & * \\ . & . & . & . & . & * \end{bmatrix} \quad \begin{array}{l} \Uparrow \\ \text{odozdo} \\ \text{prema} \\ \text{gore} \end{array} \begin{bmatrix} * & * & * & * & * & * \\ . & \circ & * & * & \circ & * \\ . & . & * & * & \bullet & * \\ . & . & . & * & \bullet & * \\ . & \circ & . & . & \circ & * \\ . & \diamond & . & . & \triangle & * \end{bmatrix}$$

Legenda: 2×2 problem iz iteracije označen sa \circ , moguće veliki iznosi iznad dijagonale \bullet , poništavano u ranijim iteracijama istog sweepa \diamond , elementi ispod dijagonale za koje se iz prethodnog sweepa očekuje da su maleni \triangle .

Konvergencija Mehl modifikacije

- Mehl je pokazao lokalnu (asimptotski) kvadratnu konvergenciju

Konvergencija Mehl modifikacije

- Mehl je pokazao lokalnu (asimptotski) kvadratnu konvergenciju
- Moja implementacija: Sage + isti laptop
- ispisuje $\tau = \sum_{i>j} |\operatorname{Re}(a_{ij})| + |\operatorname{Im}(a_{ij})|$ za svaki sweep
- trajanje se mjeri brojem sweepova (uzeti u obzir da Eberlein sweep košta oko 1.5 puta više)
- pokazati usporedbe na slučajnom primjeru
- trajanje: Mehl \approx Eberlein $\approx \frac{1}{2}$ Greenstadt

Sličnosti različitih generalizacija Jacobijevog algoritma

- Koristi se transformacija sličnosti prilagođena specifičnom potprostoru
 - Kvadratična konvergencija u “okolini” specifičnog potprostora!
 - Koja je prava mjera “blizine”?
 - Mogućnost: na osnovi udaljenosti od specifičnog potprostora iskorisiti pogodan algoritam
 - Kako ubrzati konvergenciju dok su iteracije “daleko”?

Sličnosti različitih generalizacija Jacobijeveg algoritma

- Koristi se transformacija sličnosti prilagođena specifičnom potprostoru
 - Kvadratična konvergencija u “okolini” specifičnog potprostora!
 - Koja je prava mjera “blizine”?
 - Mogućnost: na osnovi udaljenosti od specifičnog potprostora iskorisiti pogodan algoritam
 - Kako ubrzati konvergenciju dok su iteracije “daleko”?
- Poredak i narav operacija sličnosti ne uzimati “zdravo za gotovo”!
 - Propitivati svaki korak algoritma koji nije dokazano optimalan
 - Npr. prelazak sa 2x2 rotacija na 3x3 rotacije, itd.

Sličnosti različitih generalizacija Jacobijeveg algoritma

- Koristi se transformacija sličnosti **prilagođena** specifičnom potprostoru
 - Kvadratična konvergencija u “okolini” specifičnog potprostora!
 - Koja je prava mjera “blizine”?
 - Mogućnost: na osnovi udaljenosti od specifičnog potprostora iskorisiti pogodan algoritam
 - Kako ubrzati konvergenciju dok su iteracije “daleko”?
- **Poredak i narav operacija sličnosti** ne uzimati “zdravo za gotovo”!
 - Propitivati svaki korak algoritma koji nije dokazano optimalan
 - Npr. prelazak sa 2x2 rotacija na 3x3 rotacije, itd.
- Usporedbe sa QR algoritmom trebaju uzeti u obzir **točnost!**