

# Základné algoritmy pre výpočet vlastných čísiel a vektorov

Ing. Gabriel Okša, CSc.

Matematický ústav  
Slovenská akadémia vied  
Bratislava

Stavebná fakulta STU

# Obsah

- 1 Úvod - základné fakty
- 2 Lokalizácia spektra
- 3 Mocninová metóda, inverzné a Rayleighove iterácie
- 4 Princíp deflácie
- 5 Metóda QR iterácií

## Definícia vlastných čísel a vektorov

- Nech  $A$  je matica rádu  $n \times n$ . Potom  $\lambda$  je **vlastné číslo** matice  $A$ , ak existuje nenulový vektor  $x$  taký, že platí:

$$Ax = \lambda x \Leftrightarrow (A - \lambda I)x = 0.$$

Množina vlastných čísel sa nazýva **spektrum** matice  $A$ . Vektor  $x \neq 0$  sa nazýva **(pravý) vlastný vektor** matice  $A$  prislúchajúci k vlastnému číslu  $\lambda$ .

Vektor  $y \neq 0$ , ktorý vyhovuje rovnici

$$y^T A = \lambda y^T$$

sa nazýva **ľavý vlastný vektor** matice  $A$  prislúchajúci k vlastnému číslu  $\lambda$ .

- Homogénny systém rovníc  $(A - \lambda I)x = 0$  má nenulové riešenie práve vtedy, ak

$$\det(A - \lambda I) = 0.$$

## Základné fakty - 1

- Polynóm premennej  $\lambda$  definovaný ako

$$P_\lambda = \det(A - \lambda I)$$

má stupeň  $n$  a nazýva sa **charakteristický polynóm** matice  $A$ . Takže vlastné čísla matice  $A$  sú *korene jej charakteristického polynómu*.

- Regulárna matica  $A$  má nenulové vlastné čísla. Ak  $(\lambda, x)$  je vlastný pár regulárnej matice  $A$ , potom  $(1/\lambda, x)$  je korešpondujúci vlastný pár matice  $A^{-1}$ ,  $(\lambda - \sigma, x)$  je vlastný pár matice  $A - \sigma I$  a  $(\lambda^k, x)$  je vlastný pár matice  $A^k$ .
- Vlastné čísla trojuholníkovej matice sú jej diagonálne prvky.
- Nech  $T$  je regulárna matica. Potom matice  $A$  a  $TAT^{-1}$  majú rovnaké vlastné čísla (matica  $TAT^{-1}$  je **podobná** matici  $A$ ).

## Základné fakty - 2

- Vlastné vektory prislúchajúce navzájom rôznym vlastným číslam sú lineárne nezávislé.
- Matica  $A$  je podobná diagonálnej matici  $D$  práve vtedy, keď má úplnú množinu  $n$  lineárne nezávislých vektorov.
- Nech  $A$  je hermitovská matica, t.j.  $A = A^H$ , v reálnom prípade  $A = A^T$  (symetrická). Potom platí:
  - 1 Existuje unitárna matica  $U$  tak, že  $U^H A U = D$ , kde  $D$  je diagonálna matica. Prvky  $D$  sú vlastné čísla a stĺpce  $U$  sú vlastné vektory matice  $A$ .
  - 2 Vlastné čísla matice  $A$  sú reálne. Ak je navyše matica  $A$  pozitívne definitná, potom vlastné čísla sú kladné.
  - 3 Vlastné vektory matice  $A$  sú ortonormálne.

## Lokalizácia - Geršgorinove disky

- V niektorých aplikáciach (napr. stabilita dynamických systémov, konvergencia iteračných metód a pod.) nie sú dôležité hodnoty vlastných čísiel, ale ich **lokalizácia** v komplexnej rovine ( $\operatorname{Re}(\lambda) < 0$ ,  $|\lambda| < 1$ ).
- **Geršgorin** (1931): Nech  $A$  je matica rádu  $n$ . Položme

$$r_i = \sum_{j=1, j \neq i}^n |a_{ij}|, \quad i = 1, 2, \dots, n.$$

Potom každé vlastné číslo  $\lambda$  spĺňa aspoň jednu z nasledujúcich nerovností:

$$|\lambda - a_{ii}| \leq r_i, \quad i = 1, 2, \dots, n,$$

t.j. spektrum matice  $A$  leží v zjednotení  $n$  Geršgorinových diskov  $\{z \in \mathbb{C} : |\lambda - a_{ii}| \leq r_i\}$ ,  $i = 1, 2, \dots, n$ .

## Disjunktné Geršgorinove disky

- Nech  $r$  Geršgorinových diskov je disjunktných vzhľadom na zostávajúcich  $n - r$  diskov ( $r < n$ ). Potom zjednotenie týchto  $r$  diskov obsahuje presne  $r$  vlastných čísel matice  $A$ .
- **Príklad:**

$$A = \begin{pmatrix} 1 & 0.1 & 0.2 \\ 0.2 & 4 & 0.3 \\ 0.4 & 0.5 & 8 \end{pmatrix}.$$

Geršgorinove disky:  $\mathcal{D}_1 = \{z : |z - 1| \leq 0.3\}$ ,  $\mathcal{D}_2 = \{z : |z - 4| \leq 0.5\}$ ,  $\mathcal{D}_3 = \{z : |z - 8| \leq 0.9\}$ .

Všetky 3 disky sú *navzájom* disjunktné, takže každý z nich obsahuje práve jedno vlastné číslo

( $\lambda_1 = 0.9834$ ,  $\lambda_2 = 3.9671$ ,  $\lambda_3 = 8.0495$ ).

## Mocninová metóda (MM)

- Je veľa aplikácií, kde potrebujeme poznať iba niekoľko vybraných vlastných čísel a vektorov. **Mocninová metóda** je určená na výpočet **dominantného** VČ a VV.
- Nech  $A$  má VČ:  $|\lambda_1| > |\lambda_2| \geq |\lambda_3| \cdots \geq |\lambda_n|$  a nech  $v_1$  je VV prislúchajúci k  $\lambda_1$ . Nech je  $A$  diagonalizovateľná.

1. Zvoľ  $x_0 \neq 0$ , tol,  $m = 0$ .

2. **do** {

3.  $m = m + 1$ ;

4.  $\hat{x}_m = Ax_{m-1}$ ;

5. Nájsi  $\alpha_m$  tak, že:  $|\alpha_m| = \max_{1 \leq j \leq n} \{|\hat{x}_m^j|\}$ ;  
(definujme:  $\alpha_m = \max(\hat{x}_m)$ );

6.  $x_m = (\alpha_m)^{-1} \cdot \hat{x}_m$ ;

7.  $x_m = x_m / \|x_m\|$ ; //normovanie

8.  $r_m = Ax_m - \alpha_m x_m$ ;

9. } **while** ( $\|r_m\| \geq \text{tol}$ );



## MM - konvergencia - 1/3

**Konvergencia:**  $\alpha_m \rightarrow \lambda_1$  a  $x_m \rightarrow cv_1$ , kde  $c$  je konštanta.

**Dôkaz:**

$A$  je diagonalizovateľná  $\Rightarrow x_0 = \sum_{i=1}^n \beta_i v_i$ ,  $\|v_i\| = 1$ , vektory  $v_i$  sú VV matice  $A$  a tvoria bázu  $\mathbb{R}^n$ . Potom  $x_m = \frac{A^m x_0}{\max(A^m x_0)}$ , kde:

$$\begin{aligned} A^m x_0 &= A^m \left( \sum_{i=1}^n \beta_i v_i \right) = \sum_{i=1}^n \beta_i \lambda_i^m v_i \\ &= \lambda_1^m \left[ \beta_1 v_1 + \beta_2 \left( \frac{\lambda_2}{\lambda_1} \right)^m v_2 + \dots + \beta_n \left( \frac{\lambda_n}{\lambda_1} \right)^m v_n \right], \\ \max(A^m x_0) &= \lambda_1^m \left[ \beta_1 v_1^{j_m} + \beta_2 \left( \frac{\lambda_2}{\lambda_1} \right)^m v_2^{j_m} + \dots + \beta_n \left( \frac{\lambda_n}{\lambda_1} \right)^m v_n^{j_m} \right], \\ v_i^{j_m} &= \text{komponenta } j_m \text{ vektora } v_i. \end{aligned}$$

## MM - konvergenca - 2/3

- $(\lambda_k/\lambda_1)^m \rightarrow 0$ ,  $|v_k^j| \leq 1 \Rightarrow$  existuje  $m_0$  tak, že  $\forall m > m_0$ :

$$\max(A^m x_0) = \lambda_1^m \left[ \beta_1 v_1^\ell + \beta_2 \left( \frac{\lambda_2}{\lambda_1} \right)^m v_2^\ell + \cdots + \beta_n \left( \frac{\lambda_n}{\lambda_1} \right)^m v_n^\ell \right],$$

kde  $|v_1^\ell| = \max_{1 \leq k \leq n} \{|v_1^k|\}$ .

- Potom  $\forall m > m_0$ :

$$x_m = \frac{\lambda_1^m \left[ \beta_1 v_1 + \beta_2 \left( \frac{\lambda_2}{\lambda_1} \right)^m v_2 + \cdots + \beta_n \left( \frac{\lambda_n}{\lambda_1} \right)^m v_n \right]}{\lambda_1^m \left[ \beta_1 v_1^\ell + \beta_2 \left( \frac{\lambda_2}{\lambda_1} \right)^m v_2^\ell + \cdots + \beta_n \left( \frac{\lambda_n}{\lambda_1} \right)^m v_n^\ell \right]},$$

takže  $x_m \rightarrow (v_1^\ell)^{-1} \cdot v_1 \equiv w_1$ .

## MM - konvergenca - 3/3

- Vieme:  $x_m = Ax_{m-1}/\alpha_m \rightarrow w_1$ , takže aj  $x_{m-1} \rightarrow w_1$ , a teda  $Ax_{m-1} \rightarrow Aw_1 = \lambda_1 w_1$ . Nech  $\alpha_m \rightarrow \alpha$ . Potom:

$$x_m - w_1 = \frac{Ax_{m-1}}{\alpha_m} - w_1 \rightarrow \frac{(\lambda_1 - \alpha)w_1}{\alpha} = 0,$$

takže  $\alpha = \lambda_1$ , a teda  $\alpha_m \rightarrow \lambda_1$ . □

- *Rýchlosť konvergenzie*: je daná podielom  $|\lambda_2|/|\lambda_1|$ , ktorý môže byť blízky k 1  $\Rightarrow$  **pomalá** konvergenca.
- Použitie **posuvu**  $\sigma$ : MM sa aplikuje na  $A - \sigma I$ , ktorá má dominantné VČ  $\lambda_1 - \sigma$  a rovnaké VV ako  $A$ . Potom rýchlosť konvergenzie je daná podielom  $|\lambda_2 - \sigma|/|\lambda_1 - \sigma|$ , čo môže byť podstatne menšie ako  $|\lambda_2|/|\lambda_1|$ , takže sa doceli podstatne rýchlejšia konvergenca. Pre voľbu vhodného posuvu  $\sigma$  je dôležitá informácia o **lokálizácii**  $\lambda_1$  a  $\lambda_2 \Rightarrow$  použitie Geršgorinových diskov.

## MM aplikovaná na $A^{-1}$

- Ak  $|\lambda_1| \geq |\lambda_2| \geq |\lambda_3| \geq \dots \geq |\lambda_{n-1}| > |\lambda_n| > 0$ , potom  $A^{-1}$  má VČ  $1/\lambda_j$  a platí:

$$\left| \frac{1}{\lambda_n} \right| > \left| \frac{1}{\lambda_{n-1}} \right| \geq \left| \frac{1}{\lambda_{n-2}} \right| \geq \dots \geq \left| \frac{1}{\lambda_1} \right| > 0,$$

t.j.  $1/\lambda_n$  je dominantné VČ matice  $A^{-1}$ . Vlastné vektory matice  $A^{-1}$  sú **rovnaké** ako VV matice  $A$ .

- Takže MM aplikovaná na  $A^{-1}$  vypočíta vlastný pár  $(1/\lambda_n, x)$ , čiže získame odhad **najmenšieho** VČ  $\lambda_n$  matice  $A$  spolu s VV.
- Kroky č. 4 a 8: vektory  $\hat{x}_m = A^{-1}x_{m-1}$  resp.  $y_m = A^{-1}x_m$  získame riešením rovníc  $A\hat{x}_m = x_{m-1}$  resp.  $Ay_m = x_m$  (priama alebo iteračná metóda).

## Metóda inverzných iterácií (MII)

- Ak je  $k$  dispozícií kvalitná aproximácia  $\sigma$  dominantného VČ  $\lambda_1$ , potom MII efektívne počíta prislúchajúci VV (veľmi rýchla konvergencia).

**Kvalitná aproximácia:**  $|\lambda_1 - \sigma| \ll |\lambda_i - \sigma|, \forall i \neq 1$ . **Presnosť počítača:** konštanta  $\epsilon$ ; pri dvojitej presnosti je  $\epsilon \approx 1.11 \times 10^{-16}$ .

1. Zvoľ  $x_0 \neq 0, \sigma, m = 0$ .
2. **do** {
3.  $m = m + 1$ ;
4. Nájdí  $\hat{x}_m$  vyriešením sústavy:  $(A - \sigma I)\hat{x}_m = x_{m-1}$ ;
5.  $\alpha_m = \max(\hat{x}_m)$ ;
6.  $x_m = (\alpha_m)^{-1} \cdot \hat{x}_m$ ;
7.  $x_m = x_m / \|x_m\|$ ; //normovanie
8.  $r_m = Ax_m - \sigma x_m$ ;
9. } **while** ( $\|r_m\|_\infty \geq \|A\|_\infty \epsilon$ );

## MII - poznámky - 1/2

- MII je vlastne mocninová metóda aplikovaná na maticu  $(A - \sigma I)^{-1}$ , pričom je k dispozícii kvalitná aproximácia  $\sigma$  VČ  $\lambda_1$ , ktorá sa počas iterácií **nemení**.
- Riešenie LS  $(A - \sigma I)\hat{x}_m = x_{m-1}$ : Gaussova eliminácia s parciálnou pivotáciou, t.j. na začiatku:  $P(A - \sigma I) = LU$ , kde  $P$  je permutačná matica ( $P^{-1} = P^T$ ),  $L$  je dolná a  $U$  horná troj., a potom 3 kroky:  
 $z_{m-1} = Px_{m-1}$ ,  $Ly_m = z_{m-1}$ ,  $U\hat{x}_m = y_m$ .
- **Konvergencia**: postupnosť  $\{x_m\}$  konverguje k násobku VV prislúchajúcemu k VČ  $\lambda_1$ , pretože:

$$\hat{x}_m = \frac{1}{(\lambda_1 - \sigma)^m} \left[ \beta_1 v_1 + \beta_2 \left( \frac{\lambda_1 - \sigma}{\lambda_2 - \sigma} \right)^m v_2 + \dots + \beta_n \left( \frac{\lambda_1 - \sigma}{\lambda_n - \sigma} \right)^m v_n \right].$$

## MII - poznámky - 2/2

- **Voľba  $x_0$**  (Wilkinson 1965): Nech  $e = (1, 1, \dots, 1)^T$  a  $P(A - \sigma I) = LU$ . Potom zvoľ:  
 $x_0 = P^T L e$ .
- Iná možnosť: Vypočítať  $M$  iterácií pomocou MM, a potom vziať aproximácie  $x_0 = x_M$  a  $\sigma = \alpha_M$  ako vstupy do MII. Toto je **kombinácia** MM a MII, kde MII slúži na **spresnenie** odhadu VV. Obvykle totiž MM dáva omnoho presnejší odhad VČ než korešpondujúceho VV.
- **Potenciál MII**: Ak máme k dispozícii kvalitný odhad  $\sigma$  **ľubovoľného** VČ  $\lambda_j$  (t.j.  $|\lambda_j - \sigma| \ll |\lambda_k - \sigma|, \forall k \neq j$ ), potom MII spravidla veľmi rýchlo konverguje k VV prislúchajúcemu k  $\lambda_j$ .

## Rayleighov kvocient

Nech  $A$  je **symetrická** matica,  $A = A^T$ . Nech vektor  $x$  je kvalitná aproximácia VV matice  $A$ . Potom tzv. **Rayleighov kvocient**

$$\sigma = \frac{x^T A x}{x^T x} = \min_{\mu} \|(A - \mu I)x\|$$

je dobrá aproximácia VČ príslušného k VV  $x$ .

**Dôkaz:**  $A$  je symetrická  $\Rightarrow$  má ON systém vlastných vektorov  $\{v_i\}$ . Potom  $x = \sum_{i=1}^n c_i v_i$  a nech  $x$  dobre aproximuje  $v_1$ , t.j.  $c_1 \gg c_j, \forall j \neq 1$ . Potom  $Ax = \sum_{i=1}^n \lambda_i c_i v_i$  a

$$\begin{aligned} \sigma &= \frac{x^T A x}{x^T x} = \frac{\lambda_1 c_1^2 + \lambda_2 c_2^2 + \dots + \lambda_n c_n^2}{c_1^2 + c_2^2 + \dots + c_n^2} = \\ &= \lambda_1 \left[ \frac{1 + \left(\frac{\lambda_2}{\lambda_1}\right) \left(\frac{c_2}{c_1}\right)^2 + \dots + \left(\frac{\lambda_n}{\lambda_1}\right) \left(\frac{c_n}{c_1}\right)^2}{1 + \left(\frac{c_2}{c_1}\right)^2 + \dots + \left(\frac{c_n}{c_1}\right)^2} \right] \approx \lambda_1. \end{aligned}$$



## Metóda Rayleighových iterácií (MRI)

Je to kombinácia Rayleighovho kvocientu a metódy inverzných iterácií.

1. Zvoľ  $x_0 \neq 0$ ,  $\|x_0\| = 1$ ,  $\text{tol}$ ,  $m = -1$ ,  $\text{maxiter}$ .
2. **do** {
3.      $m = m + 1$ ;
4.      $\sigma_m = x_m^T A x_m$ ; //Rayleighov kvocient
5.      $r_m = A x_m - \sigma_m x_m$ ;
6.     **if** ( $\|r_m\| < \text{tol}$ ) **exit**;
7.     Nájdi  $\hat{x}_{m+1}$ :  $(A - \sigma_m I)\hat{x}_{m+1} = r_m$ ;
8.      $\alpha_{m+1} = \max(\hat{x}_{m+1})$ ;
9.      $x_{m+1} = (\alpha_{m+1})^{-1} \cdot \hat{x}_{m+1}$ ;
10.      $x_{m+1} = x_{m+1} / \|x_{m+1}\|$ ; //normovanie
11. } **while** ( $m < \text{maxiter}$ );

## MRI - poznámky

- V každom iteračnom kroku sa rieši LS s rôznou maticou sústavy ( $\sigma_m$  sa mení!). Preto je táto metóda je náročná, pokiaľ sa predtým symetrická matica  $A$  nezredukuje na sym. trojdiagonálnu:  $T = Q^T A Q$ , kde  $Q$  je OG (Householderove reflexie). Potom  $T$  má rovnaké VČ ako  $A$ ; ak  $y$  je VV matice  $T$ , potom  $x = Qy$  je VV matice  $A$ . LU faktorizácia matice  $T$  v 7. kroku MRI je rýchla, oba faktory sú bidiagonálne (pozri D-Lanczosov algoritmus pre LS) a pre 7. krok MRI treba iba  $4n - 4$  aritmetických operácií.
- Konvergencia MRI je kubická - t.j. počet presných číslic v riešení sa strojnásobí v každej iterácii.
- Výber  $x_0$ : odporúča sa absolvovať niekoľko iterácií MM a výstup použiť ako vstup do MRI.

## Princíp deflácie - 1/3

- **Deflácia** je metóda na výpočet **subdominantného** vlastného čísla (VČ) a vlastného vektora (VV):  
 $|\lambda_1| > |\lambda_2| > |\lambda_3| \geq \dots \geq |\lambda_n|$ . Pritom sa predpokladá, že k dispozícii je kvalitný odhad dominantného páru  $(\lambda_1, x_1)$ .
- **Householderova matica H** (elementárna reflexia): Nech  $e_1 = (1, 0, \dots, 0)^T$  a nech  $x = (x_1, x_2, \dots, x_n)^T \neq \alpha e_1$ . Potom existuje vektor  $u$ ,

$$u = x + \operatorname{sgn}(x_1) \|x\|_2 e_1$$

tak, že

$$H = I - 2 \frac{uu^T}{u^T u}, \quad Hx = -\operatorname{sgn}(x_1) \|x\|_2 e_1.$$

$H$  je symetrická, ortogonálna,  $H^2 = I$ ,  $H^{-1} = H$ .

## Princíp deflácie - 2/3

- Nech  $(\lambda_1, v_1)$  je dominantný vlastný pár matice  $A$  a nech  $H$  je taká HM, že  $Hv_1 = \alpha e_1$ . Potom

$$A_1 = H^{-1}AH = HAH = \begin{pmatrix} \lambda_1 & c^T \\ 0 & A_2 \end{pmatrix}$$

kde  $A_2$  je rádu  $n - 1$  a má tie isté vlastné čísla ako  $A$  **okrem**  $\lambda_1$ .

**Dôkaz:**  $Av_1 = \lambda_1 v_1 \Rightarrow HAv_1 = \lambda_1 Hv_1 \Rightarrow HAHv_1 = \lambda_1 Hv_1$   
(lebo  $H^2 = I$ ), takže:

$HAH(\alpha e_1) = \lambda_1(\alpha e_1) \Rightarrow HAHe_1 = \lambda_1 e_1$ , čiže prvý stĺpec matice  $HAH$  je  $(\lambda_1, 0, \dots, 0)^T$ .

Druhé tvrdenie:  $\det(HAH - \lambda I) = (\lambda_1 - \lambda) \det(A_2 - \lambda I)$ .  $\square$

- Ak teda  $|\lambda_1| > |\lambda_2| > |\lambda_3| \geq \dots \geq |\lambda_n|$ , potom po **deflačnom kroku**  $A_1 = HAH$  je  $\lambda_2$  dominantné VČ matice  $A_2$ .

## Princíp deflácie - 3/3

Na výpočet **niekoľkých** najväčších resp. najmenších vlastných párov matice  $A$  sa používa nasledujúca kombinácia MM, MII a deflácie:

- 1 Použi mocninovú metódu aplikovanú na  $A$  (resp. mocninovú metódu aplikovanú na  $A^{-1}$ ) na výpočet dobrej aproximácie v absolútnej hodnote najväčšieho (resp. najmenšieho) VČ a príslušného VV.
- 2 Aplikuj metódu inverzných iterácií s aproximovaným VČ (zostáva nemenné) a s aproximovaným VV z kroku 1 ako počiatočným vektorom. Takto sa získa spravidla veľmi spresnený odhad VV.
- 3 Aplikuj defláciu na výpočet ďalšieho vlastného páru.
- 4 Opakuj kroky 1-3 pre požadovaný počet vlastných párov.

## Metóda QR iterácií (MQRI)

- Je určená na výpočet VČ obecnej, hustej matice  $A$ . Patrí v súčasnosti k najčastejšie používaným metódam.
- Je založená na špeciálnych **unitárnych** resp. **ortogonálnych podobnostných transformáciach** originálnej matice  $A$ , ktoré konvergujú k hornej trojuholníkovej resp. k hornej kvázi-trojuholníkovej matici (tzv. Schurova triangularizácia).
- **Schurova triangularizácia**: Ak  $A$  je matica rádu  $n$ , potom existuje unitárna matica  $U$  tak, že  $U^H A U = T$ , kde  $T$  je horná trojuholníková. VČ matice  $T$  sú rovnaké ako VČ matice  $A$  a sú umiestnené na diagonále matice  $T$ .
- Aj keď je  $A$  **reálna**, matice  $U$  a  $T$  sú obecné **komplexné**! Je to preto, že VČ reálnej matice môže byť komplexné. Ak  $\lambda \in \mathbb{C}$  je VČ matice  $A$ , potom aj  $\bar{\lambda}$  je v spektre  $A$ .

## MQRI - reálna Schurova forma (RSF)

- Nech  $A$  je **reálna** matica. Potom existuje **ortogonálna** matica  $Q$  tak, že

$$Q^T A Q = R = \begin{pmatrix} R_{11} & R_{12} & \cdots & R_{1k} \\ 0 & R_{22} & \cdots & R_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & R_{kk} \end{pmatrix},$$

kde každé  $R_{ii}$  je buď skalár alebo blok rádu  $2 \times 2$ . Skalárne diagonálne prvky odpovedajú reálnym VČ a bloky  $2 \times 2$  na diagonále odpovedajú párom komplexne združených VČ.

- **Dôležité:** pri podobnostnej transformácii  $Q^T A Q$  sa nevyžaduje komplexná aritmetika. Počet blokov rádu  $2 \times 2$  na diagonále definuje počet komplexne združených párov VČ matice  $A$ . Komplexná aritmetika nastupuje až pri výpočte koreňov charakteristických polynómov týchto blokov.

## MQRI - RSF - bloky $2 \times 2$

- Diagonálne bloky majú špeciálne charakteristické polynómy  $\rho(\lambda)$ :

$$\begin{aligned}\rho(\lambda) &= \det \begin{pmatrix} r_{11} - \lambda & r_{12} \\ r_{21} & r_{22} - \lambda \end{pmatrix} = (r_{11} - \lambda)(r_{22} - \lambda) - r_{12} r_{21} \\ &= \lambda^2 - (r_{11} + r_{22})\lambda + r_{11} r_{22} - r_{12} r_{21}.\end{aligned}$$

Na druhej strane:

$$\rho(\lambda) = (\lambda - \lambda_j)(\lambda - \bar{\lambda}_j) = \lambda^2 - (\lambda_j + \bar{\lambda}_j)\lambda + \lambda_j \bar{\lambda}_j,$$

takže:

$$\begin{aligned}r_{11} + r_{22} &= \lambda_j + \bar{\lambda}_j = 2 \operatorname{Re}(\lambda_j), \\ r_{11} r_{22} - r_{12} r_{21} &= \lambda_j \bar{\lambda}_j = \left[ \operatorname{Re}(\lambda_j)^2 + \operatorname{Im}(\lambda_j)^2 \right].\end{aligned}$$



## MQRI - základná forma

- MQRI je definovaná postupnosťou dvoch základných krokov: QR rozklad a súčin faktorov v opačnom poradí.
  - 1 Polož  $A_0 = A$  a vypočítaj QR rozklad:  $A_0 = Q_0 R_0$ .
  - 2 Zameň poradie faktorov a vypočítaj:  $A_1 = R_0 Q_0$ .
  - 3 Vypočítaj QR rozklad:  $A_1 = Q_1 R_1$  a následne:  $A_2 = R_1 Q_1$ .
  - 4 **Krok  $k$ :**  $A_k = R_{k-1} Q_{k-1} = Q_k R_k$ .

- Takto vznikne postupnosť matic  $\{A_k\}$ , ktoré sú **ortogonálne podobné** matici  $A$ :

$$\begin{aligned} A_k &= R_{k-1} Q_{k-1} = Q_{k-1}^T A_{k-1} Q_{k-1} = \\ &= (Q_{k-1}^T Q_{k-2}^T) A_{k-2} (Q_{k-2} Q_{k-1}) = \dots = \\ &= (Q_0 Q_1 \dots Q_{k-1})^T A_0 (Q_0 Q_1 \dots Q_{k-1}). \end{aligned}$$

Takže každá  $A_k$  má rovnaké VČ ako  $A$ .

- Ak by postupnosť  $\{A_k\}$  konvergovala k trojuholníkovej matici resp. k RSF, potom by sme dospeli ku všetkým VČ matice  $A$ .

## MQRI - konvergencia - 1/3

- **Wilkinson, 1965**: Nech je matica  $A$  diagonalizovateľná:  $X^{-1}AX = \Lambda = \text{diag}(\lambda_1, \dots, \lambda_n)$ , kde  $|\lambda_1| > |\lambda_2| > \dots > |\lambda_n|$  a nech existuje LU dekompozícia matice  $X^{-1}$ . Potom postupnosť  $\{A_k\}$  konverguje k hornej trojuholníkovej matici.
- Základná verzia MQRI je **príliš nákladná**, pretože v každom kroku sa musí počítať QR rozklad plnej matice  $A_k$ , čo je rádovo  $n^3$  operácií.

## MQRI - konvergencia - 2/3

- **Trik:**  $A_0$  sa zredukuje ortogonálnou podobnostnou transformáciou na hornú Hessenbergovu (pomocou Householderových matic).

Potom sa vypočíta jej QR rozklad (rádovo  $n^2$  operácií) pomocou Givensových rotácií:  $Q_0^T A_0 = R_0$ , kde:

$$Q_0^T = G(n-1, n, \theta_{n-1}) \cdots G(2, 3, \theta_2) G(1, 2, \theta_1).$$

- Matica  $Q_0$  je horná Hessenbergova (lebo  $G(i, i+1, \theta_i)$  má nenulové mimodiag. prvky iba na pozíciách  $(i+1, i)$  a  $(i, i+1)$ ) a matica  $R_0$  je horná trojuholníková  $\Rightarrow A_1 = R_0 Q_0$  je horná Hessenbergova.
- Matematickou indukciou dokážeme, že všetky matice  $A_k$  sú horné Hessenbergove - tzv. **Hessenbergova forma QR iterácií**.

## MQRI - konvergencia - 3/3

- Nech  $A$  je redukovaná na hornú Hessenbergovu maticu:  $H = P^T A P$ , kde  $P$  je súčin Householderových reflexií. Potom QR iterácie produkujú postupnosť  $H_k$  Hessenbergových matic. Nech  $|\lambda_1| > |\lambda_2| > \dots > |\lambda_n|$ .
  - **Rýchlosť konvergencie:** Prvok  $h_{i,i-1}^{(k)}$  matice  $H_k$  konverguje k nule rýchlosťou danou geometrickou postupnosťou  $\left| \frac{\lambda_i}{\lambda_{i-1}} \right|^k$ , čo môže byť **veľmi pomalé**, ak  $\lambda_i \approx \lambda_{i-1}$ .
  - **Trik = posuv:** Nech  $\hat{\lambda}_i$  je aproximácia VČ  $\lambda_i$ . Potom MQRI sa aplikuje na  $H - \hat{\lambda}_i I$ , takže geometrická postupnosť má tvar  $\left| \frac{\lambda_i - \hat{\lambda}_i}{\lambda_{i-1} - \hat{\lambda}_i} \right|^k$ .
- Príklad:**  $\lambda_i = 0.99$ ,  $\lambda_{i-1} = 1.1$ ,  $\hat{\lambda}_i = 1.0$ . Potom  $|\lambda_i|/|\lambda_{i-1}| = 0.9$ , ale  $|\lambda_i - \hat{\lambda}_i|/|\lambda_{i-1} - \hat{\lambda}_i| = 0.1$ .

## MQRI - jednoduchý posuv

- V praxi nie je odhad  $\hat{\lambda}_i$  na začiatku iterácií k dispozícii  $\Rightarrow$  berie sa  $h_{nn}^{(0)}$  (prvok  $(n, n)$  matice  $H = H_0$ ). Tento posun sa **obnovuje** v každom "dvojkroku" MQRI.

1. Transformuj OG podobnostnou transformáciou  $A$  na hornú Hessenbergovu maticu:  $H = P^T A P$ .

2.  $H_0 = H$ ;  $m = 0$ ;

3. **do** {

4.  $H_k - h_{nn}^{(k)} I = Q_k R_k$ ;

5.  $H_{k+1} = R_k Q_k + h_{nn}^{(k)} I$ ;

6. } **while** ( $h_{n,n-1} \neq 0$ );

- Kedy je  $h_{n,n-1}^{(k)} \approx 0$ ? Beresford Parlett (USA) navrhuje:

$$|h_{n,n-1}^{(k)}| \leq \text{tol} \cdot (|h_{nn}^{(k)}| + |h_{n-1,n-1}^{(k)}|),$$

kde  $\text{tol} \ll 1$ .

## MQRI - dvojitý posuv

- Jednoduchý posuv funguje dobre, ak má matica  $A$  iba reálne VČ. Ak má však **reálna** matica  $A$  aj komplexné VČ (vo forme komplexne združených párov), potom:
  - Od určitého štádia MQRI bude jasné, že napr.  $h_{n,n-1}^{(k)}$  nekonverguje k nule, ale spodný blok o rozmere  $2 \times 2$  korešponduje komplexne združenému páru.
  - V takom prípade **reálny** prvok  $h_{nn}^{(k)}$  nemôže byť kvalitnou aproximáciou **komplexného** VČ.
  - Potom je prirodzené použiť **obe** VČ spodného  $2 \times 2$  bloku ako posuv  $\Rightarrow$  **MQRI s dvojitým posuvom**.
- Nech  $k_1$  a  $k_2 = \bar{k}_1$  sú komplexne združené VČ spodného  $2 \times 2$  bloku. Potom jeden iteračný krok MQRI s dvojitým posuvom má tvar:

$$H_s - k_1 I = Q_s R_s; \quad H_{s+1} = R_s Q_s + k_1 I;$$

$$H_{s+1} - k_2 I = Q_{s+1} R_{s+1}; \quad H_{s+2} = R_{s+1} Q_{s+1} + k_2 I;$$

## Dvojitý posuv s reálnou aritmetikou 1/3

- Pretože  $k_1$  a  $k_2$  sú komplexné čísla, implementácia dvojitého posuvu by vyžadovala komplexnú aritmetiku aj pre reálnu východziu maticu (a následné matice  $H_k$  by už boli komplexné!). Dá sa to obísť, t.j. pracovať stále s reálnou aritmetikou.
- Pretože  $k_1 = \bar{k}_2$ , je matica  $N = (H_s - k_2 I)(H_s - k_1 I) = H_s^2 - (k_1 + k_2)H_s + k_1 k_2 I$  **reálna**.
- $(Q_s Q_{s+1})(R_{s+1} R_s)$  je QR faktorizácia matice  $N$ :  
$$\begin{aligned} N &= (H_s - k_2 I)(H_s - k_1 I) = (H_s - k_2 I) Q_s R_s \\ &= Q_s Q_s^H (H_s - k_2 I) Q_s R_s = Q_s (Q_s^H H_s Q_s - k_2 I) R_s \\ &= Q_s [(R_s + k_1 Q_s^H) Q_s - k_2 I] R_s \\ &= Q_s [H_{s+1} - k_1 I + k_1 I - k_2 I] R_s = (Q_s Q_{s+1})(R_{s+1} R_s). \end{aligned}$$

## Dvojitý posuv s reálnou aritmetikou 2/3

- Pretože  $N$  je reálna,  $(Q_s Q_{s+1})$  je tiež reálna a ortogonálna.
- Ďalší krok:  $H_{s+2}$  je OG podobná k  $H_s$  práve cez  $(Q_s Q_{s+1})$ :

$$\begin{aligned}H_{s+2} &= R_{s+1} Q_{s+1} + k_2 I = Q_{s+1}^H (H_{s+1} - k_2 I) Q_{s+1} + k_2 I \\&= Q_{s+1}^H [R_s Q_s + (k_1 - k_2) I] Q_{s+1} + k_2 I \\&= Q_{s+1}^H [Q_s^H (H_s - k_1 I) Q_s + (k_1 - k_2) I] Q_{s+1} + k_2 I \\&= Q_{s+1}^H Q_s^H H_s Q_s Q_{s+1} = (Q_s Q_{s+1})^T H_s (Q_s Q_{s+1}).\end{aligned}$$

Matice  $(Q_s Q_{s+1})$  a  $H_s$  sú reálne  $\Rightarrow H_{s+2}$  je reálna a "preskočili" sme  $H_{s+1}$ !

- **Nakoniec:** Pri formovaní  $N = H_s^2 - (k_1 + k_2)H_s + k_1 k_2 I$  **netreba** počítať komplexné korene  $k_1, k_2$ , lebo potrebujeme iba **reálne** čísla:

$$t = k_1 + k_2 = \text{trace}(2 \times 2 \text{ bloku}) = h_{n-1, n-1}^{(s)} + h_{n, n}^{(s)}$$

$$d = k_1 k_2 = \det(2 \times 2 \text{ bloku}) = h_{n-1, n-1}^{(s)} h_{n, n}^{(s)} - h_{n, n-1}^{(s)} h_{n-1, n}^{(s)}$$



## Dvojitý posuv s reálnou aritmetikou 3/3

- **Konečná podoba** jedného iteračného kroku MQRI s dvojitým posuvom v reálnej aritmetike:
  1.  $t = h_{n-1,n-1}^{(s)} + h_{n,n}^{(s)}$ ;  $d = h_{n-1,n-1}^{(s)} h_{n,n}^{(s)} - h_{n,n-1}^{(s)} h_{n-1,n}^{(s)}$ ;
  2.  $N = H_s^2 - tH_s + dl$ ; //  $N$  **nie je** horná Hessenbergova!
  3.  $N = QR$ ;
  4.  $H_{s+2} = Q^T H_s Q$ .
- Toto sa nazýva **explicitná** QR iterácia s dvojitým posuvom v reálnej aritmetike, pretože sa explicitne počíta matica  $N$  a jej QR rozklad  $\Rightarrow$  jeden iteračný krok vyžaduje rádovo  $n^3$  aritmetických operácií.
- Existuje aj **implicitná** QR iterácia s dvojitým posuvom v reálnej aritmetike, kde sa používa iba prvý stĺpec matice  $N$   $\Rightarrow$  jeden iteračný krok vyžaduje rádovo  $n^2$  aritmetických operácií.