


# Lastne vrednosti simetričnega tenzorja

16. 3. 2022



Zgled: Daloost lastna mahanja in lastne frekvence sistema, ki ga sestavljajo ute  $\tilde{m}_i$  z masami  $m_1, m_2, m_3$ , ki so s štirimi vzmetmi  $k_1, k_2, k_3, k_4$  zaporedno pritrjene med dve nepremični steni in med seboj



Sklopljen sistem morda opišemo s sistemom diferencialnih enačb za tovrstnega:

$$m_1 \ddot{x}_1 = -k_1 x_1 + k_2 (x_2 - x_1)$$

$$m_2 \ddot{x}_2 = -k_2 (x_2 - x_1) + k_3 (x_3 - x_2)$$

$$m_3 \ddot{x}_3 = -k_4 x_3 - k_3 (x_3 - x_2)$$

Oziroma.

$$m_1 \ddot{x}_1 = -(k_1 + k_2) x_1 + k_2 x_2$$

$$m_2 \ddot{x}_2 = -(k_2 + k_3) x_2 + k_3 x_3 + k_2 x_1$$

$$m_3 \ddot{x}_3 = k_3 x_2 - (k_3 + k_4) x_3$$

Resiter sistema, ko bo imal 2 reber frekvenc  $\omega$  nastanemo kot:

$$x_i(t) = y_i \sin(\omega t) \quad \left( \begin{array}{l} \text{amplituda poravnane z reber} \\ \text{amplituda} \\ \text{v predznaku} \end{array} \right)$$

Če se upoštevamo, da je:

$$\ddot{x}_i(t) = -\omega^2 y_i \sin(\omega t),$$

lahko zapišemo:

$$\begin{array}{l} + m_1 y_1 \omega^2 = + (k_1 + k_2) y_1 - k_2 y_2 \\ + m_2 y_2 \omega^2 = + (k_2 + k_3) y_2 - k_3 y_3 - k_2 y_1 \cdot (-1) \\ + m_3 y_3 \omega^2 = -k_3 y_2 + (k_3 + k_4) y_3 \end{array} \Bigg/$$

Sistem lahko zapišemo v matrični obliki kot:

$$\omega^2 \cdot \underbrace{\begin{bmatrix} m_1 & 0 & 0 \\ 0 & m_2 & 0 \\ 0 & 0 & m_3 \end{bmatrix}}_M \cdot \underbrace{\begin{bmatrix} y_1 \\ y_2 \\ y_3 \end{bmatrix}}_{\vec{y}} = \underbrace{\begin{bmatrix} k_1 + k_2 & -k_2 & 0 \\ -k_2 & k_2 + k_3 & -k_3 \\ 0 & -k_3 & k_3 + k_4 \end{bmatrix}}_K \cdot \underbrace{\begin{bmatrix} y_1 \\ y_2 \\ y_3 \end{bmatrix}}_{\vec{y}}$$

Dobitno:

$$\omega^2 M \vec{y} = K \cdot \vec{y} / \cdot M^{-1} ; M^{-1} = \begin{bmatrix} \frac{1}{m_1} & 0 & 0 \\ 0 & \frac{1}{m_2} & 0 \\ 0 & 0 & \frac{1}{m_3} \end{bmatrix}$$

Vpeliemo

$$\omega^2 \underbrace{M^{-1} M}_{I} \vec{y} = \underbrace{M^{-1} K}_A \vec{y} ; A = \begin{bmatrix} \frac{k_1+k_2}{m_1} & -\frac{k_2}{m_1} & 0 \\ -\frac{k_2}{m_2} & \frac{k_2+k_3}{m_2} & -\frac{k_3}{m_2} \\ 0 & -\frac{k_3}{m_3} & \frac{k_3+k_4}{m_3} \end{bmatrix}$$

Dobili smo sistem:

Če  $m_1 = m_2 = m_3 = m$ ,  
potem lahko zmanjšamo.

$$A \vec{y} = \lambda \vec{y} ; \vec{y} \neq 0$$

Dobili smo sistem dimenzijemo linearnih problemov lastnih vrednosti! Ta problem v fiziki pogosto srečamo in tobrat se bomo ukvarjali z reševanjem takšnih linearnih sistemov.

Naloga:

Dobiti želimo lastne vrednosti  $\lambda$  in pripadajoče lastne vektorje  $\vec{y}_i$ , ki rešijo tak sistem!

V našem primeru: Lastne vrednosti  $\lambda = \omega^2$   
bolev lastne frekvence sistema nihal.  
Lastno neličje pa propedežde amplitude  
(in medtem) pazevendi nihal.

"Nedruge" put iskanja lastnih vrednosti:

Velja:

$$A \vec{x} = \lambda \vec{x}$$

identiteta

$$A \vec{x} - \lambda \vec{x} = \underbrace{(A - \lambda I)}_B \vec{x} = 0 \quad (*)$$

Opomba:

$$B = \begin{bmatrix} b_{11} & b_{12} & b_{13} & \dots & b_{1n} \\ b_{21} & b_{22} & \dots & \dots & b_{2n} \\ \dots & \dots & \dots & \dots & \dots \\ b_{m1} & b_{m2} & \dots & \dots & b_{mn} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$

Lahko zapišemo:  $b_{i1} x_1 + b_{i2} x_2 + \dots + b_{in} x_n = 0$

odkremo:  $b_{i1} = b_{i2} \frac{x_2}{x_1} + \dots + b_{in} \frac{x_n}{x_1}$ ,  $i = 1, \dots, n$

Stolpec matrike wor neodvisen, zato je  $\det(B) = 0$

Izraz (\*) velja, če je  $\det(A - \lambda I) = 0$

Determinanta matrike  $n \times n$  nam da t.i.

karakteristični polinom  $n$ -tega reda v  $\lambda$ . Posledično lastne vrednosti sistema (\*) ustrezajo ničlam karakterističnega polnoma:

Torgj:  $p(\lambda) = \det(A - \lambda I) = 0$

Vpajutuv: Ker nemo, da ima polinom stopnje  $N$  vedno  $N$  rodel, ba imel sistem  $(x)$   $N$  lastnih vrednosti. Lastne vrednosti lu ustrezajo vednostnim rodelom, imajo eno degeneracijo lastne vrednosti.

Izled: Izvodnaja lastne vrednosti matrike


$$A = \begin{bmatrix} 2 & -1 & -1 \\ -1 & 2 & 1 \\ -1 & 1 & 4 \end{bmatrix}$$

Zapišimo determinanto:

$$\det(A - \lambda I) = \begin{vmatrix} 2-\lambda & -1 & -1 \\ -1 & 2-\lambda & 1 \\ -1 & 1 & 4-\lambda \end{vmatrix} = \begin{vmatrix} 2-\lambda & -1 & -1 \\ -1 & 2-\lambda & 1 \\ -1 & 1 & 4-\lambda \end{vmatrix} =$$

$$= \underbrace{(2-\lambda)^2}_{\text{razloži}} (4-\lambda) + 2 - 2(2-\lambda) - (4-\lambda) = p(\lambda)$$

$$p(\lambda) = 10 - 17\lambda + 8\lambda^2 - \lambda^3 \quad (= 0)$$



z iskrajem model dobimo:  $\lambda_1 = 1, \lambda_2 = 2, \lambda_3 = 5$ .

Izkuša se tudi, da se preprečijo lastni vrednosti

$$\vec{x}_1 = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 \\ 1 \\ 0 \end{bmatrix}, \quad \vec{x}_2 = \frac{1}{\sqrt{3}} \begin{bmatrix} 1 \\ -1 \\ 1 \end{bmatrix}, \quad \vec{x}_3 = \frac{1}{\sqrt{6}} \begin{bmatrix} -1 \\ 1 \\ 2 \end{bmatrix}$$

Komentar: Model polinoma stopnje  $n \geq 5$  ne znamo ved prebrati analitično. Postopno moramo numerirati. Ta postopek je numerično nestabilen, zato v spletnem tečaju postopek ne uporabljamo za določanje lastnih vrednosti!

$\Rightarrow$  Obstajajo robustnejši tolki.



Neki osnovni pojmovi: (Npr. Branštein, str. 299)

- 1.) Matrica je simetrična, de je enak svoji transponirani matrici:

$$A = A^T \quad \text{otpramo} \quad a_{ij} = a_{ji}$$

- 2.) Hermitska (reči odjungirana) matrica je kvadratna matrica, ki je enak svoji odjungirani matrici:

$$A = A^\dagger \quad \text{ali} \quad a_{ij} = \overline{a_{ji}}$$

↓ komplekono konjugirano!

✓ Lastne vrednosti Hermitske (ali pa realne simetrične) matrice so vse realne!

- 3.) Ortogonalna matrica je matrica, katere inverz je enak svoji transponirani matrici. Velja

$$A \cdot A^T = A^T \cdot A = I \Rightarrow A^{-1} = A^T$$

Velja še:  $\det(A) = \pm 1$

- 4.) Kompleksna matrica je unitarna, de velja

$$A^\dagger = A^{-1} \quad \text{otpramo} \quad A \cdot A^\dagger = A^\dagger \cdot A = I.$$

5.) Matrica je normalna, če velja:

$$A \cdot A^T = A^T \cdot A$$

Ortogonalne in unitarne matrice so normalne.

! Čeprav veljajo normalne matrice drugače nedegenerativne lastne vrednosti, so ortogonalne in napenajo  $N$ -dimenzijski vektorski prostor!

Opomba: Mi se bomo osredotočili na analizo realnih simetričnih matrik.

# Diagonalizacija matrike

Matriko  $A$  se da diagonalizirati, če obstaja invertibilna matrika  $X = [\vec{x}_1, \dots, \vec{x}_n]$  in diagonalna matrika  $\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_n)$ , da velja:

$$\det(X) \neq 0, \quad \underline{X^{-1} A X = \Lambda} \quad | \cdot X \quad (*)$$

odkramo:

$$\underline{A X = X \Lambda} \quad | \cdot X^{-1}$$

odkramo:

$$A = X \Lambda X^{-1}$$

Torej velja, da so diagonalni elementi matrike  $\Lambda$  lastne vrednosti matrike  $A$ , stolpci  $\vec{x}_i$  matrike  $X$  pa njene lastne vektorji.

Transponirajmo zgornjo zvezo:

$$A^T = (X \Lambda X^{-1})^T = (X^{-1})^T \Lambda^T X^T = (X^T)^{-1} \Lambda X^T$$

Če je  $A$  simetrična:

$$A^T = (X^T)^{-1} \Lambda X^T = A = X \Lambda X^{-1}$$

Sledi:  $X^T = X^{-1}$  odtuda  $X^T X = I$ .

Upatljivo smo, da če je  $A$  simetrična, je transformacijska matrika  $X$  ortogonalna. —

Stalpev je matrike razpisa o ortogonalno bazo.  $n$  dimenzionalnega euklidskega prostora in obratno skalarni produkt

Zaključek: Realne simetrične matrike imajo realne lastne vrednosti in realne in ortogonalne lastne vektorje.

(\*) Ker se ukvarjamo s problemom:

$$\underline{X^{-1} A X = \Lambda}$$

problemu iskanja lastnih vrednosti rešimo tudi problem diagonalizacije matrike  $A$ . Če matriko diagonaliziramo, imamo lastne vrednosti.

## Podobnostna transformacija:

linearno transformabilna matrika  $Z$ ,  $\det(Z) \neq 0$   
Transformacija:

$$A \longrightarrow Z^{-1} A Z = B$$

Imenujemo podobnostna transformacija. Metoda da  
da  $B$  preidemo, da sta podobni! Pri podobnosti  
transformaciji se obravnava lastne vrednosti matrike.

$$\begin{aligned} \det(B - \lambda I) &= \det(Z^{-1} A Z - \lambda I) = \\ &= \det(Z^{-1} A Z - \lambda \overbrace{I}^{Z^{-1} Z}) = \det(Z^{-1} (A - \lambda I) Z) \\ &= \det(Z^{-1}) \cdot \det(A - \lambda I) \cdot \det(Z) = \\ &= \underbrace{\det(Z^{-1} Z)}_I \det(A - \lambda I) = \det(A - \lambda I) \end{aligned}$$

Podobnostne relacije igrajo ključno vlogo  
pri reševanju lastnih vrednosti.



## Osnovna ideja:

Matrico  $A$  z zaporednim podobnostnim transformacijam gremo prvo diagonalno obliko.

$$\begin{aligned} A &\longrightarrow Z_1^{-1} A Z_1 \longrightarrow Z_2^{-1} Z_1^{-1} A Z_1 Z_2 \\ &\longrightarrow Z_3^{-1} Z_2^{-1} Z_1^{-1} A Z_1 Z_2 Z_3 \longrightarrow \Lambda \end{aligned}$$

Če nam postopki uspe prvo do diagonalne matrice, potem so lastni vektorji stolpcev celotne transformacije

$$X = Z_1 Z_2 Z_3 Z_4 \dots Z_n$$

## Opomba:

Hi nam treba vedno iti vse do diagonalne matrice. Če nos zračujemo le lastne vrednosti, potem je dovolj, da matrico približujemo v trikotno matrico

To tudi izkoristimo, da se matrice ne da diagonalizirati, pa bi vseeno radi dobili lastne vrednosti.

Pomembno: Postopek diagonalizacije je skladen,  
če so matrike  $Z$  unitarne!  
Glej, Plestenjak, RUM, str. 167.

Schurova formula: Za vsako matriko  $A$  obstaja  
unitarna matrika  $Q$  in zgornje trikotna matrika  
 $R$ , da je  $\underbrace{Q^T A Q}_{\text{Schurov recept}} = \underbrace{R}_{\text{Schurova formula}}$ .

Zakaj tak recept? Če je matrika  $R$  zgornje  
trikotna, so njene lastne vrednosti rovnor  
no diagonalni elementi. Ker je  $R$  podobna  $A$ ,  
so to tudi lastne vrednosti  $A$ !

# Potencijna iterativna metoda:

za reševanje:  $A\vec{x} = \lambda\vec{x}$

## Postopek:

1. Izberemo točen približek  $\vec{x}^{(0)} = (x_{01}, \dots, x_{0n})^T$  tako, da je  $\|\vec{x}^{(0)}\| = \sqrt{x_{01}^2 + \dots + x_{0n}^2} = 1$ .

2. Izračunamo:  $\vec{y}^{(i+1)} = A \cdot \vec{x}^{(i)} \quad ; \quad i = 0, 1, 2, \dots$

3. Izračunamo:  $\alpha^{(i+1)} = \|\vec{y}^{(i+1)}\| \rightarrow$  To konvergira k  
k najmanjši  
lastni vrednosti

$\vec{x}^{(i+1)} = \frac{\vec{y}^{(i+1)}}{\alpha}$

To konvergira k  
lastnemu vektorju

Počkunamo, da  
je vse istočkunamo z  
istim redam!

$\lambda^{(i+1)} = \frac{\vec{x}^{(i+1)} \cdot (A \vec{x}^{(i+1)})}{\|\vec{x}^{(i+1)}\|^2}$

4. Preverjamo 2. in 3. tabelo časi, dajler

$$\|A\vec{x}^{(i+1)} - \lambda^{(i+1)}\vec{x}^{(i+1)}\| < \epsilon$$



Izjava: Zaposredje vektora  $\vec{x}^{(i)}$  konvergira k dominantnemu lastnemu vektorju, zopredje  $\lambda^{(1)}$  pa k dominantni lastni vrednosti.

Dokaz: Predpostavimo, da lahko  $A$  diagonaliziramo kot:  $A = W \Lambda W^{-1}$ , kjer sta

$$\Lambda = \begin{bmatrix} \lambda_1 & & & 0 \\ & \ddots & & \\ & & \ddots & \\ 0 & & & \lambda_n \end{bmatrix}, \quad W = [\vec{w}_1, \vec{w}_2, \dots, \vec{w}_n]$$

Diagonalna matrika lastnih vrednosti

Matrika  $\vec{w}$  lastnih vektorjev!

Im naj večja:  $|\lambda_1| > |\lambda_2| > |\lambda_3| > \dots > |\lambda_n|$   
Vrednje so po velikosti

Rešujemo naš zvečan vektor kot po lastnih vektorjih:

$$\vec{x}^{(0)} = \sum_{j=1}^n \alpha_j \cdot \vec{w}_j$$

V  $i$ -ti iteraciji našega postopka imamo:

↙ Takobnost moe pravilo mnozheniya.

$$\vec{x}^{(i)} = \frac{A^i \vec{x}^{(0)}}{\|A^i \vec{x}^{(0)}\|} = \frac{(W \Lambda^i W^{-1}) \sum_{j=1}^n \alpha_j \vec{w}_j}{\| \dots \|} =$$

Upredstavim:  $A^i = (W \Lambda W^{-1})^i = \underbrace{(W \Lambda W^{-1})(W \Lambda W^{-1}) \dots}_{i}$

$= \underline{W \Lambda^i W^{-1}}$  ← Lozhu relatsiya se ocher skalyrya

$$= \frac{\alpha_1 \lambda_1^i \vec{w}_1 + \dots + \alpha_n \lambda_n^i \vec{w}_n}{\| \alpha_1 \lambda_1^i \vec{w}_1 + \dots + \alpha_n \lambda_n^i \vec{w}_n \|}$$

$$= \frac{\alpha_1 \vec{w}_1 + \alpha_2 \left(\frac{\lambda_2}{\lambda_1}\right)^i \vec{w}_2 + \dots + \alpha_n \left(\frac{\lambda_n}{\lambda_1}\right)^i \vec{w}_n}{\| \alpha_1 \vec{w}_1 + \alpha_2 \left(\frac{\lambda_2}{\lambda_1}\right)^i \vec{w}_2 + \dots + \alpha_n \left(\frac{\lambda_n}{\lambda_1}\right)^i \vec{w}_n \|}$$

$$\xrightarrow{i \rightarrow \infty} \underline{\frac{\vec{w}_1}{\|\vec{w}_1\|}} \blacksquare$$

## Kaj pa ostale lastne vrednosti?

Če  $A$  lahko diagonaliziramo, potem jo lahko zapišemo kot:

$$A = \underbrace{\begin{bmatrix} | & | & | & \dots & | \\ \color{red}{\vdots} & \vdots & \vdots & \dots & \vdots \\ | & | & | & \dots & | \end{bmatrix}}_{\text{Lastnih vektorji}} \begin{bmatrix} \lambda_1 & & & \\ & \ddots & & \\ & & \ddots & \\ & & & \lambda_n \end{bmatrix} \begin{bmatrix} \color{red}{\hline} \\ \color{red}{\hline} \\ \color{red}{\hline} \\ \vdots \\ \color{red}{\hline} \end{bmatrix}$$

Prva lastna vrednost in lastni vektor  $\vec{x}_1$  določata prvi vrstni in stolčni element sistema in pogledamo ostale, ki ostane.

$$A_2 = A - \lambda_1 \cdot (\vec{x}_1 \vec{x}_1^T) = A - \lambda_1 \begin{bmatrix} x_{11}^2 & x_{11}x_{12} & \dots & x_{11}x_{1n} \\ x_{11}x_{12} & x_{12}^2 & \dots & \dots \\ \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & x_{1n}^2 \end{bmatrix}$$

Tenzorski produkt:  $\vec{x}_1 \otimes \vec{x}_1$

Za splošni korak:

$$A_i = A_{i-1} - \lambda_{(i-1)} (\vec{x}_{i-1} \vec{x}_{i-1}^T) \quad ; \quad i = 2, 3, \dots, n$$

Hotellingova redukcija

Deluje za  $A = A^T$

## Inverzna potenska metoda (ali inverzna iteracija):

- Metoda je uporabna, kadar imamo približek za lastno vrednost in prebrskamo še lastni vektor.
- Ideja metode je reševanje sistema:

$$(A - \tau I) \vec{y} = \vec{b}$$

ko je  $\vec{b}$  naključni vektor in  $\tau$  vrednost blizu izbrane lastne  $\lambda_n$ . Tedaj je rešitev sistema  $\vec{y}$  blizu lastnega vektorja  $\vec{x}_n$  z lastno vrednostjo  $\lambda_n$ .

### Algoritem:

1.) Izberemo  $\tau$  blizu lastne vrednosti  $\lambda_n$  in naključni vektor  $\vec{b}_0$ ;  $\|\vec{b}_0\| = 1$ .

2.) Delujemo  $\vec{y}_{i+1}$  z reševanjem sistema:

$$(A - \tau I) \vec{y}_{i+1} = \vec{b}_i \quad ; \quad i = 0, 1, \dots, M$$

↓  $\vec{b}_0$  pomen reševanje sistema linearnih enob.

3.) Izračunamo nove približke:

$$\vec{b}_{i+1} = \frac{\vec{y}_{i+1}}{\|\vec{y}_i\|}$$

← Približek lastnega  
vektora

$$\lambda_{i+1} = \vec{x}_{i+1}^T A \vec{x}_{i+1}$$

← Približek lastne  
vrednosti

4.) Preverjamo 2.), 3.) doblje  $|\lambda_{i+1} - \lambda_i| < \varepsilon$ .

Preveriti  
ustreznost.

Zakaj metoda deluje:

$$\underbrace{(A - \tau I)}_{\tilde{A}} \vec{y}_{i+1} = \vec{b}_i$$

⇓ Ekvivalenčno

$$\vec{y}_{i+1} = \tilde{A}^{-1} \vec{b}_i$$

Opazujemo, da inverzna iteracija ustrezno  
potezemo metodo za matriko  $(A - \tau I)^{-1}$ .

Metoda hammersteina k dominantni lastni vrednosti za  $A^{-1}$ . Lastne vrednosti te matrice so

$$\tilde{\lambda}_i = \frac{1}{d_i - \tau}$$

Dominantna vrednost je  $\tilde{\lambda}_n$ , ker je  $\tau$  najbližje  $d_n$  je  $\tilde{\lambda}_n > \tilde{\lambda}_i$ ,  $i \neq n$ .

Komentar:

- S parametrom  $\tau$  izbiramo, k kateremu lastnemu vektorju bo hammersteina zaporedje  $\vec{y}_{i+1}$ .

- Če  $\tau$  izbiramo dovolj blizu  $d_n$ , bo metoda zelo hitro hammersteina.

- V vsakem krogu moramo reševati sistem enob:  $(A - \tau I) \vec{y}_{i+1} = \vec{b}_i$

To rešimo z uporabo apr. metode LU ali drugimi metodami za reševanje linearnih sistemov enob. Glej.: Plestenjak, RUM. poglavje 3.

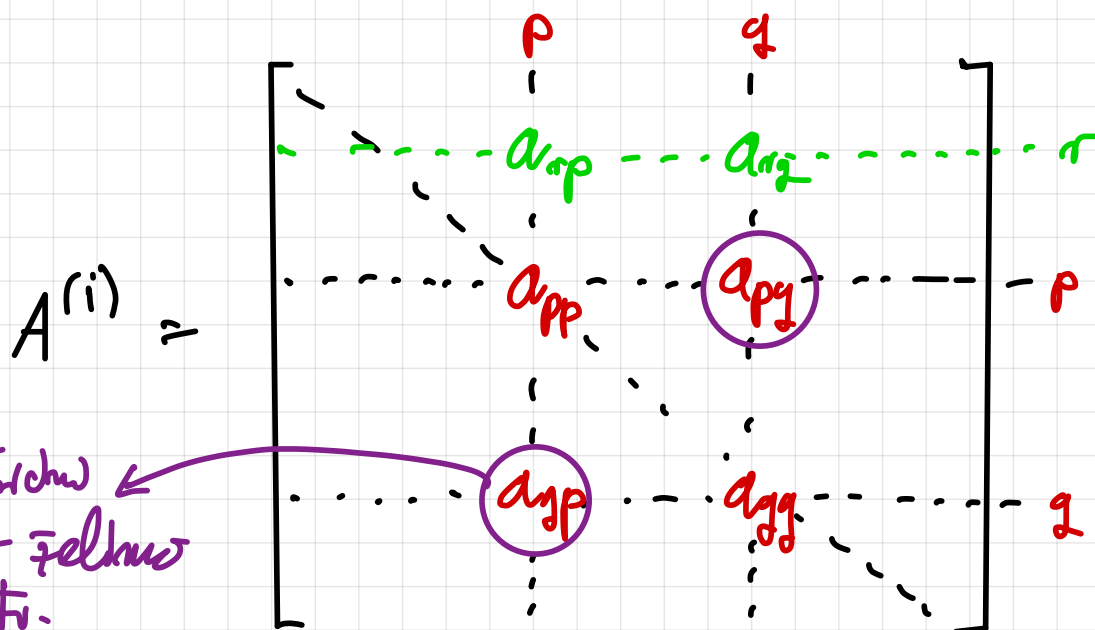
# Jacobijeva metoda:

Uporabna le za iskanje lastnih vrednosti in vektorjev simetričnih matrik!



- Jacobijeva metoda sestoji iz niza ortogonalnih podobnostnih transformacij — rotacij. Z vsako rotacijo poskušamo na 0 spraviti izbrani in neoddiagonalni člen. Vsaka naslednja rotacija raje "pokvari" delo prejšnje rotacije, a neoddiagonalni elementi hitro tekmajo s številom iteracij postopajo vse manjši:  $\rightarrow$  Vse diagonalne in neoddiagonalne elemente ubo manjši od izbrane natančnosti  $\epsilon$ .

V  $i$ -tem koraku imamo matriko:



Ta matrična element želimo manjšati.

$V^{(i+1)}$  koraka želimo znati element  $a_{pq}$ :

$$A^{(i+1)} = R_{pq}^T(\theta) A^{(i)} R_{pq}(\theta)$$

kateri element  
sundryemo

Rotacijski kot.

$$R_{pq}(\theta) = \begin{bmatrix} 1 & & & & & & \\ & 1 & & & & & \\ & & \overset{c}{\cos \theta} & & & & \\ & & & \dots & & & \\ & & & & \overset{s}{-\sin \theta} & & \\ & & & & & \dots & \\ & & & & & & 1 & \\ & & \sin \theta & & & & & \\ & & & & \cos \theta & & & \\ & & & & & & & & 1 & \\ & & & & & & & & & 1 \end{bmatrix}$$

$\uparrow$  p                       $\uparrow$  q                      1                      1

$\leftarrow$  p  
 $\leftarrow$  q

Poglejmo samo dele matrike, ki vključujejo  $a_{pq}$ :

$$A^{(i+1)} = \begin{bmatrix} c & s \\ -s & c \end{bmatrix} \begin{bmatrix} a_{pp} & a_{pq} \\ a_{pq} & a_{qq} \end{bmatrix} \begin{bmatrix} c & -s \\ s & c \end{bmatrix}$$

$$= \begin{bmatrix} c^2 a_{pp} + 2cs a_{pq} + s^2 a_{qq}, & -cs a_{pp} + c^2 a_{pq} - s^2 a_{pq} + cs a_{qq} \\ -cs a_{pp} + c^2 a_{pq} - s^2 a_{pq} + cs a_{qq}, & s^2 a_{pp} - 2sc a_{pq} + c^2 a_{qq} \end{bmatrix}$$

$\underbrace{\hspace{15em}}_{=0}$                        $\underbrace{\hspace{15em}}_{=0}$



$$a_{pg}^{(i+n)} = \underbrace{-cs a_{pp}} + \underbrace{c^2 a_{pg} - s^2 a_{pg}} + \underbrace{sc a_{gg}} =$$

$$= a_{pg} \cos 2\theta - \frac{1}{2} \sin 2\theta (a_{pp} - a_{gg}) = 0$$

Dobitno: 
$$ctg 2\theta = \frac{a_{pp} - a_{gg}}{2 a_{pg}} = \zeta$$

Iz te enočne sedaj določimo natujšo kot  $\theta$ . Da bo še lažje razpisemo:

$$ctg 2\theta = \frac{\cos^2 \theta - \sin^2 \theta}{2 \sin \theta \cos \theta} = \frac{1 - \underbrace{tg^2 \theta}_{=t^2}}{2 \underbrace{tg \theta}_{=t}} = \zeta$$

Dobitno kvadratno enočno, ki jo rešimo:

$$t^2 + 2t\zeta - 1 = 0$$

$$t = \frac{\text{sgn}(\zeta)}{|\zeta| + \sqrt{\zeta^2 + 1}}$$

$$c = \frac{1}{\sqrt{t^2 + 1}}, \quad s = t \cdot c$$

Členi matrice v naslednji iteraciji bodo:

$$a_{pq}^{(i+1)} = a_{qp}^{(i+1)} = 0$$

$$a_{pp}^{(i+1)} = c^2 a_{pp} + s^2 a_{qq} + 2cs a_{pq}$$

$$a_{qq}^{(i+1)} = c^2 a_{qq} + s^2 a_{pp} - 2sc a_{pq}$$

Sprememjijo pa še tudi drugi elementi v matriki  $a_{rp}$  in  $a_{rq}$ , kjer je  $r \neq p$  in  $r \neq q$ .

$$a_{rp}^{(i+1)} = a_{rp} c + a_{rq} s$$

$$a_{rq}^{(i+1)} = a_{rq} c - a_{rp} s$$

Algoritem želimo oblikovati tako, da ne bomo matrike v celoti na novo računali, pov pa da bomo obstoječim elementom dodajali poprave.

$$\begin{aligned} a_{rp}^{(i+1)} &= a_{rp} c + a_{rq} s = a_{rp}^{(i)} - a_{rp} \cdot (1-c) + a_{rq} s \\ &= a_{rp} + s \left( a_{rq} - a_{rp} \frac{1-c}{s} \right) \end{aligned}$$

$$\frac{1-c}{s} = \frac{1-\cos\theta}{\sin\theta} = \frac{\cos^2\frac{\theta}{2} + \sin^2\frac{\theta}{2} - \cos\frac{\theta}{2} + \sin\frac{\theta}{2}}{2\sin\frac{\theta}{2}\cos\frac{\theta}{2}} =$$

$$= \tan\frac{\theta}{2} \equiv \tau$$

Dehnung:

$$a_{rp}^{(i+1)} = a_{rp} + s(a_{rg} - a_{rp}\tau)$$

$$a_{rg}^{(i+1)} = a_{rg} - s(a_{rp} + a_{rg}\tau) \leftarrow \text{17peltigens an dts for evok modulu!}$$

$$a_{pp}^{(i+1)} = c^2 a_{pp} + s^2 a_{gg} + 2cs a_{pg} =$$

$$= a_{pp} - \underbrace{(1-c^2)}_{s^2} a_{pp} + s^2 a_{gg} + 2cs a_{pg}$$

$$= a_{pp} - s^2 \left[ \underbrace{(a_{pp} - a_{gg})}_{2a_{pg} \cdot \frac{1-t^2}{2t}} \right] + 2cs a_{pg}$$

$$= a_{pp} + a_{pg} \cdot \left( \underbrace{2cs}_{\frac{1-s^2}{t}} - \frac{s^2(1-t^2)}{t} \right) =$$

$$= a_{pp} + a_{pg} s^2 \left( \frac{2-1+t^2}{t} \right) = \left| \frac{1+t^2}{t} = \frac{c}{s c^2} \right.$$

$$= a_{pp} + a_{pg} \cdot t$$

Ekvivalentno dobimo še:

$$\begin{aligned}a_{gg}^{(i+1)} &= a_{gg} - (1-c^2)a_{gg} + s^2 a_{pp} - 2sc a_{pg} = \\ &= a_{gg} + s^2(a_{pp} - a_{gg}) - 2sc a_{pg} = \\ &= \underline{a_{gg} - a_{pg} t}\end{aligned}$$

Kako se odločimo, katere elemente bomo uvideli:

- Klasično: V vsakem koraku sumiramo največji člen.  
Najhitrejša konvergenca, a zahteva veliko pomnilnika
- Ciljovna veranta: vedno v enakem vrstnem redu
- Pragovna veranta: v danem vrstnem redu, a uvidujemo le tiste elemente, ki imajo vrednost nad pragom. Prag v vsakem ciklu zmanjšamo.

## Algoritm:

1. Pevāmo nājmācīgu izveidojamā elementu  $a_{pq}$ .
2. Izveidojam rotāciju kā  $\theta$  starpa  $s, c$  ut.
3. Izveidojam pārvērtību k matricu  $A$  un 2. rindā pārvērtinām matricu
4. Pārveidojam 1. - 3. tālāk oām, dāk.

$$\text{eff}(A) = \sum_{\substack{i,j=1 \\ i \neq j}}^n |a_{ij}|^2 < \varepsilon$$

## Lastne vērtību un lastne vērtību:

Po  $n$  iterācijām dāk:

Produkts ortogonālu matricu  
je ortogonāla matrica.

$$A^{(n)} = \underbrace{J_{(n-1)}^T J_{(n-2)}^T \dots J_{(1)}^T}_{J^T} A \underbrace{J_{(1)} J_{(2)} \dots J_{(n-1)}}_J$$

↓  
diagonālu  
elementu sō  
lastne vērtību

↓  
Stabru matricu sō  
lastne vērtību matricu!

## Summary:

- časovna zahtevnost algoritma je  $O(n^3)$  z veliko konstanto.
- Uporaben za  $N \leq 10$ .
- Metoda je robustna.
- Dobro rešuna tudi majhne ločne vrednosti.

## Algoritem QR:

- To je metoda, ki se pogosto uporablja v numeričnih paketih
- Simetrična matrika ni pogoj za delovanje algoritma.
- Metoda temelji na rekurzivnem Schurovem razcepni. matrike  $A$  na ortogonalno matriko  $Q$  in zgornje trikotno matriko  $R$ .

## Algoritem:

1. Določimo prvo približek  $A_0 = A$
2. Izvedemo QR razcep matrike  $A_i$  ;  $i = 0, 1, 2, \dots, n-1$   
 $A_{(i)} = Q_{(i)} R_{(i)}$
3. Izvedemo naslednjo iteracijo matrike:  
 $A_{(i+1)} = R_{(i)} Q_{(i)}$
4. Ko se 2. in 3. postopoma tolko zasukata, določi matrike  $A_{(i)}$  in dovolj podobna zgornje diagonale:  
$$\sum_{\substack{i,j=1 \\ i \neq j}}^n |a_{ij}|^2 < \underline{\varepsilon}$$

izberemo!

## Zakaj algoritem deluje:

$$A^{(i+1)} = R^{(i)} Q^{(i)}$$

Vemo, da je  $A^{(i)} = Q^{(i)} R^{(i)}$ ; ker je  $Q^T = Q^{-1}$   
velja tudi:  $Q_{(i)}^T A^{(i)} = R^{(i)}$

$$A^{(i+1)} = Q_{(i)}^T A^{(i)} Q_{(i)}$$

Dobilo smo znova podobnostno transformacijo.  
Ker je  $Q$  ortogonalna, je algoritem stabilen.

Velja:

V limiti  $i \rightarrow \infty$  matrika  $A^{(i)}$  konvergira  
proti zgornje trikotni matriki. Lastne  
vrednosti ležijo na diagonalnih elementih  
matrike. Lastni vektorji so stolpci matrike

$$Q = Q_1 Q_2 \dots Q_n$$



# Recept QR: (z uporabo Hausdorffovega zrcaljenja)

Izvesti želimo recept:

$$A = QR$$

Ortogonalna

zgoranje trapeza.

Cilj transformacije je našto linearno preslikavo, ki izbrani vektor  $\vec{x}$  preslika v vektor z isto dolžino, a vrdel z izbranimu baznemu vektorja  $\hat{e}_1$ .

Naj bo  $\vec{x}$  prva stolpca matrike  $A$  in  $\hat{e}_1 = (1, 0, 0, \dots, 0)^T$  bazni vektor dimenzije  $n$ .

Vpeljemo:

$$\vec{u} = \vec{x} - \|\vec{x}\| \hat{e}_1$$

$$\vec{v} = \frac{\vec{u}}{\|\vec{u}\|}$$

Transformacija:  $Q_1 = I - 2 \vec{v} \vec{v}^T = P$

Matriko spreminjamo, da v 1. stolpca matrike ostane le 1. vrednost. Ostalo 00 no!

Transformacija  $Q_1$  redimo Hausdorffova  
projekcijska matrica.

Projekcijska matrica dva naslednje lastnosti:


$$\begin{aligned} P^2 &= (I - 2 \vec{v} \vec{v}^T) (I - 2 \vec{v} \vec{v}^T) = \\ &= I - 4 \vec{v} \vec{v}^T + 4 \vec{v} \underbrace{(\vec{v}^T \vec{v})}_{=1} \vec{v}^T \\ &= I - 4 \vec{v} \vec{v}^T + 4 \vec{v} \vec{v}^T = \underline{I} = P \cdot P \end{aligned}$$

Ker  $\vec{v}^T \vec{v} = 1$   
Ker  $\vec{v}^T \vec{v} = 1$ .

Od tod se sledi:  $P^{-1} = P$ , Ker velja  $P^T = P$   
je potem tudi  $P^{-1} = P^T$ .

$$\begin{aligned} P \vec{x} &= (I - 2 \vec{v} \vec{v}^T) \vec{x} = \vec{x} - 2 \vec{v} \frac{(\vec{x}^T - \|\vec{x}\| \hat{e}_1^T) \vec{x}}{\|\vec{x} - \|\vec{x}\| \hat{e}_1\|} \\ &= \vec{x} - 2 \frac{\vec{v} (|\vec{x}|^2 - |\vec{x}| \cdot x_1)}{|\vec{x} - \|\vec{x}\| \hat{e}_1|^2} = \vec{x} - \vec{v} = \underline{\underline{\|\vec{x}\| \hat{e}_1}} \end{aligned}$$

$2|\vec{x}|^2 - 2|\vec{x}|x_1$



Transformacija  $Q_1 = P$   
 zvečalo vektor  $\neq$  preko  
 le simetrične!

Kaj se zgodilo z matriko:

$$A = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & & a_{2n} \\ a_{31} & a_{32} & & a_{3n} \\ \vdots & \vdots & & \vdots \\ a_{n1} & a_{n2} & & a_{nn} \end{bmatrix}$$

Vzamemo 1. stolpce in iz njega naredimo  $\vec{x} \rightarrow Q_1$

$$Q_1 A = \begin{bmatrix} a_{11}' & a_{12}' & \dots & a_{1n}' \\ 0 & a_{22}' & & a_{2n}' \\ 0 & a_{32}' & & a_{3n}' \\ \vdots & \vdots & & \vdots \\ 0 & a_{n2}' & & a_{nn}' \end{bmatrix}$$

$A'$

Za matriko  $A'$  dimenzije  $(N-1) \times (N-1)$  zrova delovni vektor  $\vec{x}'$  dimenzije  $(N-1)$ , bazični vektor  $\hat{e}_1' = (\underbrace{1, 0, \dots, 0}_{N-1})^T$  in delovni  $Q_2'$

Celotna transformacijska matrika je potem:

$$Q_2 = \left[ \begin{array}{c|cccc} 1 & 0 & 0 & \dots & \dots \\ \hline 0 & \boxed{Q_2'} & & & \\ 0 & & & & \\ \vdots & & & & \\ 0 & & & & \end{array} \right]$$

$$Q_2 Q_1 A = \left[ \begin{array}{cc|cccc} a_{11}' & a_{12}' & \dots & \dots & a_{1N}' \\ 0 & a_{22}'' & \dots & \dots & a_{2N}'' \\ \hline 0 & 0 & \boxed{A''} & & \\ \vdots & \vdots & & & \\ \vdots & \vdots & & & \\ 0 & 0 & & & \end{array} \right]$$

↓ in potem lahko naprej

Na kuncu duktora:

$$R = \underbrace{Q_{n-1} \dots Q_2 Q_1}_Q A = Q^T A$$

$$QR = A \quad \blacksquare$$

Opomba:

QR razcep se do nareditve tudi z drugodimenzionalnimi transformacijami, npr. z Givensovo metodo.

Glej: NRC, str. 469.

Plestenjak, Uvod v N.M., str. 136.

## Summary metode QR:

- Če je matrika  $A$  simetrična matrika velikosti  $n \times n$ , potem je matrika  $R$  diagonalna matrika.
- Časovna zahtevnost algoritma je  $O(n^3)$
- Osnovni algoritem se da pokazati tako, da se matriko  $A$  najprej preoblikuje v to diagonavno matriko  $A'$  (z uporabo npr. Householderjevih zrcaljenj), ali pa v Hessenbergovo obliko (z uporabo Givens matrik + ena diagonala)

Grlej, Plestenjak, Uvod v M.M., str. 183 in  
MRC, str. 470.