

Rayleighov poliel, inverzné iterovanie

v tejto lekci sa predstavia dva klasické algoritmy pre vlastné vektory / vl. hodnoty.

Súvisť s oba metódy pre nerišore úlohy, špeciálne inverzné iterovanie pre hľadanie vl. vektora, at porovnanie vl. hodnôt.

Spolu s ňou budú základom pre QR algoritmus, ktorý popíšeme v nasledujúcich dvoch lekciách (časť z tejto prednášky)

Obmedzenie sa na reálne symetrické matice

~~Prezentácia~~ algoritmy numerických lineárnej algebr fungujú pre vektorové matice alebo pre hermitovské, kde si môžeme dovoliť voľbu a štruktúru <sup>iste</sup>  $V$  zjednodušenie.

V prípade hľadacích vl. hodnôt (QR algoritmus) sú však tieto rozdiely dost veľké, preto pre zjednodušenie vkladu budeme uvažovať  $A$  reálnu & symetrickú, v ktorej normy budú  $\| \cdot \|_2$ .

Takže v nasledujúcom budeme mať  $A = A^T \in M_{mm}(\mathbb{R})$ ,  $x \in \mathbb{R}^n$ ,  $x^* = x^T$

$\|x\| = \sqrt{x^T x}$ . Tiež to znamená, že  $A$  má reálne vl. hodnoty.

a je diagonalizovateľná ortogonálne.

(vlastné) hodnoty označíme  $\lambda_1, \lambda_2, \dots, \lambda_n$   
ortogonálne vl. vektory  $p_1, p_2, \dots, p_n$

Príklady z nasledujúcich lekcii sa týkajú fázy 2 pri hľadaní vl. hodnôt, teda matice  $A$  už presta upravami vo fáze 1 a je tridiagonálna.

Ato umožňuje tridiagonálna forma má niektoré matematické výhody, ale hlavné algoritmy. Niektoré body budú totiž 0 (m) namiesto  $\lambda_i$

# Rayleighov podiel

Rayleighov podiel pre vektor  $x \in \mathbb{R}^m$  je podiel

$$r(x) = \frac{x^T A x}{x^T x}$$

Ak je  $x$  vl. vektor, potom  $r(x) = \lambda$  je vl. hodnota.

Pozrime sa na motiváciu v pytani:

Môžeme sa pýtať, "ktorý skalar  $\alpha$  sa pre vektor  $x$  správa "najviac" ako vl. hodnota?"

i. j. kedy je  $\|Ax - \alpha x\|_2$  minimálne? Toto je úloha najmenších

štruktúr  $n$  traver  $x \approx Ax$  ( $x$  je matica,  $x$  usporiadaný vektor  $1 \times 1$  a  $Ax$  pravá strana)

Riešením je práve  $r(x)$ . ~~Rayleighov podiel~~

$R(x)$  je teda prirodzený odhad pre veľkosť vl. hodnôt, ak  $x$  je blízko k vl. vektoru.

Môžeme to kvantifikovať ešte trochu lepšie:

$x \in \mathbb{R}^m$  - premenná  
 $r: \mathbb{R}^m \rightarrow \mathbb{R}$  funkcia.

Pozrime sa na parciálne derivácie podľa súradnice  $x_j$ :

$$\begin{aligned} \frac{\partial r(x)}{\partial x_j} &= \frac{\frac{\partial}{\partial x_j} (x^T A x)}{x^T x} - \frac{(x^T A x) \frac{\partial}{\partial x_j} (x^T x)}{(x^T x)^2} \\ &= \frac{2(Ax)_j}{x^T x} - \frac{(x^T A x) 2x_j}{(x^T x)^2} = \frac{2}{x^T x} (Ax - r(x)x)_j \end{aligned}$$

Spojením parciálnych derivácií dostaneme gradient:

$$\nabla r(x) = \frac{2}{x^T x} (Ax - r(x)x)$$

Pre vl. vektor - bude totižto gradient nulový vzhľadom na  $(r(x) = \lambda)$

Počítame, ak  $\nabla r(x) = \vec{0}$  (pre nenulové  $x$ ), tak  $x$  je vl. vektor.



Geometrický význam:

$v(x)$  závisí od velkosti  $x$ , iba od smeru (je to funkcia na projekčnej sfere)

častejšie sa stačí pozerať na jej hodnoty na 1-tkovej sfere.

V prípade jednoduchých vl. hodnôt (národnosť = 1) budú vlastné hodnoty zodpovedať hodnotám stacionárnych (kritických) bodoch  $v(x)$ .

Viemo povedať ešte viac:

Ak  $q_j$  je vl. vektor, potom  $\nabla v(q_j) = \vec{0}$ , z hladkovosti  $v(x)$  (mimo  $\vec{0}$ ) máme  $v(x) - v(q_j) = O(\|x - q_j\|^2)$  pre  $x \rightarrow q_j$

(Taylorov vzorec)

Teda Rayleighov podiel je kvadraticky presný odhad vl. hodnoty.

Este inak: ak  $x$  je lin. kombináciou vl. vektorov  $q_1, \dots, q_m$

$$\text{tad } x = \sum_{j=1}^m a_j q_j \quad \text{a} \quad v(x) = \frac{\sum_{j=1}^m a_j^2 \lambda_j}{\sum_{j=1}^m a_j^2}$$

Teda  $v(x)$  je vážený priemer vl. hodnôt  $A$  vážený štvorcami

Súkladnicou vektadom na ~~vektorech~~ vlastnú bázu.

čítaj to tiež  $v(x) - v(q_j) = O(\epsilon^2)$  pre  $|a_j/a_j| < \epsilon \quad j \neq j$ .

### Mocninové iterovanie

Zmešme tomu. Predpokladajme, že  $v^{(0)}$  spĺňa  $\|v^{(0)}\| = 1$ .

Pomocou mocninového iterovania, ktoré sme už spomenuli ako nie veľmi dobrého kandidáta na hľadanie vl. vektorov

(leťva 25), dostaneme postupnosť  $v^{(i)}$ , ktorá bude

konvergovať ke vl. vektoru pre najväčšiu vl. hodnotu matice  $A$ .

# Algoritmus 27.1

$v^{(0)}$  = najväčší vektor  $S$   $\|v^{(0)}\| = 1$

pre  $k=1, 2, \dots$

$$w = A v^{(k-1)}$$

pre násobiť  $A$

$$v^{(k)} = w / \|w\|$$

normalizovať

$$\lambda^{(k)} = (v^{(k)})^T A v^{(k)}$$

odhadnúť  $\lambda$  pomocou Rayleigh. podielu

- nebudeme špecifikovať, kedy treba tento algoritmus ukončiť, pretože len "pre  $k=1, 2, \dots$ ". V praxi sú však ukončovacie podmienky veľmi dôležité - preto sú spravidla numerické knižnice výrazne lepšie ako ad-hoc naprogramované programy.

Možnosť iterovania sa dá analyzovať pomerne ľahko.

$v^{(0)}$  napíšme ako kombináciu ortonormálnych v. vektorov  $q_i$ :

$$v^{(0)} = a_1 q_1 + a_2 q_2 + \dots + a_m q_m$$

$v^{(k)}$  je najväčší násobok  $A^k v^{(0)}$ , preto existujú konstanty  $c_k$ :

$$\begin{aligned} v^{(k)} &= c_k A^k v^{(0)} \\ &= c_k (a_1 \lambda_1^k q_1 + a_2 \lambda_2^k q_2 + \dots + a_m \lambda_m^k q_m) \\ &= c_k \lambda_1^k \left( a_1 q_1 + a_2 \left(\frac{\lambda_2}{\lambda_1}\right)^k q_2 + \dots + a_m \left(\frac{\lambda_m}{\lambda_1}\right)^k q_m \right). \end{aligned}$$

Z toho máme

Tvrdenie Nech  $|\lambda_1| > |\lambda_2| \geq \dots \geq |\lambda_m| \geq 0$  a  $q_1^T v^{(0)} \neq 0$ .

Podm. priebežne hodnoty Algoritmu 27.1 spĺňajú odhady:

$$\|v^{(k)} - (\pm q_1)\| = O\left(\left|\frac{\lambda_2}{\lambda_1}\right|^k\right), \quad |\lambda^{(k)} - \lambda_1| = O\left(\left|\frac{\lambda_2}{\lambda_1}\right|^{2k}\right)$$

Pre  $k \rightarrow \infty$ . Znamená to ± znamená, že v každom kroku musíme

~~Dôkaz~~

vybrať jednu z nich, pre vhodnú platí odhad.

Dôkaz Prvý vzťah plynie z vyjadrenia  $v^{(k)}$  ako LK  $q_1, \dots, q_m$ , keďže predpokladáme, že  $q_1 = q_1^T v^{(0)} \neq 0$ .

Druhý odhad vyplýva z kvadratickej presnosti Rayleighovho podielu.



49  $\lambda_1 > 0$ , potom sú všetky znamienka + alebo -, ale 23  
 $\lambda_1 < 0$ , tak alternujú.

z výpočtového hľadiska ± znamienko neprežerá veľmi dobre.  
Môli by sme hovoriť o "projekciivizácii", t.j. konvergencii podpriestoru  
 $\text{span}\langle v^{(k)} \rangle$  a  $\text{span}\langle q_1 \rangle$ , ale to by si vzáduvalo definíciu  
konvergencie podpriestorov.

Mocninové iterovanie má samo o sebe limitovanú zoväčšenosť  
- počtu vl. vektorov pre najväčšiu vl. hodnotu  
- konvergencia je lineárna (t.j. exponent  $\sim O(|\frac{\lambda_2}{\lambda_1}|^k)$ )  
táto je lineárna od 2  
- v závislosti od veľkosti podielu  $|\frac{\lambda_2}{\lambda_1}|$  môžeme mať východu  
konvergenciu at je najväčšia vl. hodnota výrazne vyššia ako  
ostatné, v prípade, že majú podobnú veľkosť, dostaneme  
veľmi pomalú konvergenciu.

Náštastie, toto sa dá opraviť:

### Inverzné iterovanie

Pre  $\mu \in \mathbb{R}$ , ktoré nie je vl. hodnotou matice  $A$  sú vl. vektory  
 $(A - \mu I)^{-1}$  rovnaké ako vl. vektory  $A$ , zodpovedajúce vl. hodnoty  
 $\frac{1}{\lambda_j - \mu}$ , kde  $\{\lambda_j\}$  je spektrum  $A$ .

To vedie k nasledujúcej myšlienke:  
Nech  $\mu$  je blízko niektorým vl. hodnote  $\lambda_j$ . Potom  $(\lambda_j - \mu)^{-1}$   
môže byť výrazne vyššie ako  $(\lambda_j - \mu)$  pre  $\lambda_j \neq \mu$ , teda  
mocninové iterovanie pre  $(A - \mu I)^{-1}$  môže konvergovať  
pomereň východu ku  $q_j$ .

# Algoritmus 27.2 Inverzní iterování

$v^{(0)}$  = výchozí vektor  $\|v^{(0)}\|=1$

pro  $k=1, 2, \dots$

řešíť  $(A - \mu I)w = v^{(k-1)}$  pro  $w$

$v^{(k)} = w / \|w\|$

$\lambda^{(k)} = (v^{(k)})^T A v^{(k)}$

upřesňit  $(A - \mu I)^{-1}$

normalizovat

Rayleighov podíl

Tu přicházejí různé otázky.

co to je  $\mu$  rel. hodnota  $A$  a  $A - \mu I$  je singularna?

co to je  $\mu$  skoro rel. hodnota, t.j.  $A - \mu I$  je velmi ele  
podmíněná (t.j. řešení  $(A - \mu I)w = v^{(k-1)}$  bude z0)  
Zásady nepřesně?

→ kapitla 27.5. (DÚ)

• Až inverzní iterování konverguje lineárně, ale výsledek poměrně  
velho najstí rel. vektorů  $q_j$  pro jiné rel. hodnoty než pro  
největší rel. hodnotu (to kontrolujeme vstupem  $\mu$ ).

Navíc, rychlost lineární konvergence se dá kontrolovat.  
závisí od "kvality"  $\mu$  (a ne <sup>spěšně</sup> spektra  $\{\lambda_j\}$ ).

Náme tvrzení:

Nech  $\lambda_j$  je nejblížeš rel. hodnota  $A$  a  $\lambda_k$  je druhá nejblížeš,

t.j.  $|\mu - \lambda_j| < |\mu - \lambda_k| \leq |\mu - \lambda_l|$  pro  $j \in J$ .

Navíc nech  $q_j^T v^{(0)} \neq 0$ . Pak následky algoritmu 27.2

spínajíť  $\|v^{(k)} - (\pm q_j)\| = O\left(\left|\frac{\mu - \lambda_j}{\mu - \lambda_k}\right|^k\right)$  a  $|\lambda^{(k)} - \lambda_j| = O\left(\left|\frac{\mu - \lambda_j}{\mu - \lambda_k}\right|^{2k}\right)$

pro  $k \rightarrow \infty$ ,  $\pm$  má ~~pevný~~ znaménko určené počtem  $q_j$  v  $v^{(0)}$ .




Ukazuje sa, že inverzné iterovanie je činný nástroj numerickej lineárnej algebry, lebo je to štandardná metóda výpočtu vl. vektorov, ak sú vl. hodnoty (približne) známe. V tomto prípade sa horej algoritmus 27.2 považiva tak, ako je napísaný, s výnimkou výpočtu Rayleighovho podielu.

Iterovanie pomocou Rayleighovho podielu (RQ)

Dobrá sme si užiali metódu odhadu vl. hodnoty pre nejakého kandidáta na vl. vektor (Rayleighov podiel), a inú metódu ako z odhadnutej vl. hodnoty dostať vl. vektor (inverzné iterovanie).

Takže možnosť skombinovať tieto dve metódy sa prirodzene nájde:



Ďalšia hlavná výstižnosť teda je, že v inverznom iterovaní vylepšime tým, že v každom kroku vylepšime odhad vl. hodnoty. Tento algoritmus sa nazýva Rayleigh quotient algorithm (algoritmus pomocou Rayleighovho podielu)

Algoritmus 27.3 (Rayleighov podiel)

$v^{(0)}$  = nejaký vektor s  $\|v^{(0)}\| = 1$

$\lambda^{(0)}$  =  $(v^{(0)})^T A v^{(0)}$  = Rayleighov podiel pre  $v^{(0)}$

pre  $k = 1, 2, \dots$

Riešiť  $(A - \lambda^{(k-1)} I)w = v^{(k-1)}$

$v^{(k)} = w / \|w\|$

$\lambda^{(k)} = (v^{(k)})^T A v^{(k)}$

vynásobiť  $(A - \lambda^{(k-1)} I)^{-1}$   
normalizovať

späťat nový Rayleighov podiel

Konvergenca tohto algoritmu je vjavnje lepsia ako inverzna iteracia - kazda iteracia strojnaso (!) pocet presnych cifier.

Veta <sup>Iterovanie</sup> ~~Algoritmus pomocou~~ Rayleighovho podielu konverguje k parnu vl. vektor/vl. hodnota pre velky pocatocny vektor  $v^{(0)}$  s vplyvom mnoziny miery 0. Ak konverguje, konvergenca je nakoniec kubicka, t.j. az  $\lambda_j$  je vl. hodnota a  $v^{(0)}$  je dostatočne blizko k vl. vektoru  $q_j$ , tak

$$\|v^{(k+1)} - (\pm q_j)\| = O(\|v^{(k)} - (\pm q_j)\|^3)$$

$$\text{a } \|\lambda^{(k+1)} - \lambda_j\| = O(\|\lambda^{(k)} - \lambda_j\|^3)$$

pre  $k \rightarrow \infty$ , znamienka  $\pm$  nemusia byt rovnake  $v$ .

Dokaz Dokaz toho, ze mnozina vektorov, pre ktoru alg. konverguje ma  $\dim \geq 1$  kniha neuradza...

Vkazuje aspu konvergenciu, ked uz k nej ~~pr~~ dochadza:

Nech je (pre jednoduchosť) vl. hodnota  $\lambda_j$  jednoduchá (nasobnosť=1)

Az  $\|v^{(k)} - q_j\| \leq \epsilon$  pre dostatočne male  $\epsilon$ , potom Rayleighov podiel dava odhad  $\lambda^{(k)}$  s presnosťou  $O(\epsilon^2)$ , t.j.  $\|\lambda^{(k)} - \lambda_j\| = O(\epsilon^2)$ .

Potom pri nasledujucom kroku inverznej iteracie ( ~~$v^{(k)}$~~ ,  $\lambda^{(k)}$ ) ma

$$\|v^{(k+1)} - q_j\| = O(\|\lambda^{(k)} - \lambda_j\| \|v^{(k)} - q_j\|) = O(\epsilon^3)$$

Navyse, konstanty vystupujuce v O budu rovnake pre dostatočne male okolia  $\lambda_j$  a  $q_j$ . Takze dostaneme konvergenca v style:

	$\ v^{(k)} - q_j\ $	$\ \lambda^{(k)} - \lambda_j\ $	
$k$	$\epsilon$		$\longrightarrow O(\epsilon^2)$
$k+1$	$O(\epsilon^3)$		$\longrightarrow O(\epsilon^6)$
$k+2$	$O(\epsilon^9)$		$\longrightarrow O(\epsilon^{18})$

z ceho maie tridna vety.



Príklad Kubická konvergencia je tára rýchla, že si zvládne 2-5

príklad.

Uvažujme maticu  $A = \begin{bmatrix} 2 & 1 & 1 \\ 1 & 3 & 1 \\ 1 & 1 & 4 \end{bmatrix}$

a  $v^{(0)} = \frac{1}{\sqrt{3}} \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix}$

ak sa použijú <sup>iterovanie pomocou</sup> Rayleighho podielu pre  $A \cdot v^{(0)}$ , následujúce

hodnoty

$\lambda^{(k)}$ :

$\lambda^{(0)} = 5$

$\lambda^{(1)} = 5.2131\dots$

$\lambda^{(2)} = 5.214319743184\dots$

príčinou presná hodnota ~~je~~ pre ~~ktorý~~ vektor najbližšie k  $v^{(0)}$  je

$\lambda = 5.214319743\beta 77\dots$

→ presnosť na 10 číslic po 3 iteráciách

Po ďalších troch iteráciách pomocou Rayleighho podielu ~~by~~ udarejť presnosť na 270 miest. - ak by sme to od násaj masívny chceli...

## Počty operácií (len zbežne)

Uzavíme túto časť prednášky poznámkou o počte potrebných operácií:

Najprv nech  $A$  je všeobecná <sup>reálna</sup> matica typu  $m \times m$ .

• Každý krok mocninného iterovania si vyžaduje násobenie matica-vektor, t.j.  $O(m^2)$  flopor.

• Každý krok inverzného iterovania si vyžaduje riešenie systému, čo na prvý pohľad dáva  $O(m^3)$  flopor, ale dá sa to znížiť na  $O(m^2)$  ak maticu predupravíme pomocou LU, QR alebo iného rozkladu.

Prí iterovaní pomocou Rayleighho podielu sa vždy matica v každom kroku mení (odpočítavame od  $A$  nie  $\lambda^{(k)} I$ ), teda

Spōsob do vylepsit'  $O(m^3)$  nie je aē taky' priamočiary  
povazit'

Tieto odhady si sū dramatičny zlepsia 7re tričdiagonálnu  
maticu :

Každā z iterácií si vyžaduje len  $O(m)$  flopar v každom  
kroku.

— Ak by sme pracovali s nesymetrickou maticou, musíme  
používať Hessenbergovu tvar z fázy 1 a tieto  
počty stupnu na  $O(m^2)$ .

---



QR algoritmus bez posumar

QR algoritmus pochádza zo začiatku 60 tých rokov a v knihe ho označujú za jeden z "pokladov numerickéj analýzy".  
V tejto lekcii ho prezentujeme v najjednoduchšej forme, ktorá sa dá mimat aj ako stabilný spôsob QR rozkladu matice  $A, A^2, A^3, \dots$

QR algoritmus

Základná verzia QR algoritmu využíva ~~absolútne~~ <sup>numerické</sup> jednoduchosť:

Algoritmus 28.1 "čistý" QR algoritmus

$A^{(0)} = A$

pre  $k=1, 2, \dots$

$Q^{(k)} R^{(k)} = A^{(k-1)}$       najst' QR rozklad  $A^{(k-1)}$

$A^{(k)} = R^{(k)} Q^{(k)}$       prehodit poradie faktorov

§ Všetko, čo sa robí je urobiť QR rozklad, vpredučiť existujúce faktory  $Q, R$  v opačnom poradí  $RQ$  a opakovat'.  
Napriek tomu, za určitých podmienok, tento jednoduchý postup konverguje k Schurovej trau pre všeobecne  $A$ , resp. diagonálnej matici, ak je  $A$  hermitovská.  
Pre zjednodušenie vecí, predpokladajme naďalej, že  $A$  je reálna symetrická, s reálnymi v. hodnotami  $\lambda_j$  a ortonormálnymi v. vektormi  $q_j$ .  
Chceme teda ukázať, že matice  $A^{(k)}$  budú konvergovať k diagonálnej trau.

Aby konvergencia k diagonálnemu tvaru hozej dala vl. hodnoty, ukonané operácie musia byť podobnostné transformácie, čo, že  $A^{(k-1)}$  a  $A^{(k)}$  sú podobné sa ľahko overí:

$$Q^{(k)} R^{(k)} = A^{(k-1)} \quad \text{je to isté ako} \quad R^{(k)} = (Q^{(k)})^T A^{(k-1)}$$

Teda 
$$A^{(k)} = R^{(k)} Q^{(k)} = Q^{(k)T} A^{(k-1)} Q^{(k)}$$

V skutočnosti, táto podobnostná transformácia sa už spomínala v lekcii 26, ako "zla myšlienka", keď sme chceli A redukovat na horný trojuholníkový tvar priamo, v jednom kroku. Napriek tomu, ako krok iterácie sa stále vhodná.

V predstvej lekcii sme videli kubickú konvergenciu <sup>inverznou iteráciou s</sup> Rayleighovho podielom, niečo podobné dosiahneme aj pre QR algoritmus, keď pozmeníme "čistý" QR algoritmus o posuny. Toto je jeden z troch krokov, ktoré myšlienkou posúvajú k úspešnej praxi:

(príprava) 1. Pred začiatkom iterovania, redukovat A na tridiagonálny tvar (lekcii 26)

(posun) 2. Namiesto  $A^{(k)}$ , faktORIZOVAT posunutú maticu  $A^{(k)} - \mu^{(k)} I$ , kde  $\mu^{(k)}$  je najväčší odhad vl. hodnoty

(diflácia) 3. Akedykoľvek to je možné (t.j. keď <sup>keď</sup> najdlhšie vl. hodnoty) rozdelit problém na diagonalizáciu podmatic.

QR algoritmus s týmito vylepšeniami sa dá schematicky popísať:



# Algoritmus 28.2 "Praktický" QR algoritmus

27

$$(Q^{(0)})^T A^{(0)} Q^{(0)} = A$$

$A^{(0)}$  je tridiagonalizácia  $A$

pre  $k=1, 2, \dots$

• vybrať posun  $\mu^{(k)}$

$$Q^{(k)} R^{(k)} = A^{(k-1)} - \mu^{(k)} I$$

$$A^{(k)} = R^{(k)} Q^{(k)} + \mu^{(k)} I$$

každé zvolíme  $\mu^{(k)} = A_{m,m}^{(k-1)}$   
 ťažšie na diagonále

$$QR\text{-vozkad } A^{(k-1)} - \mu^{(k)} I$$

Počít faktory v opačnom poradí

Ak niektoré z mimo-diagonálnych zložiek je dostatočne blízka 0,

$$A_{j,j+1}^{(k)}$$

dot  $A_{j,j+1} = A_{j+1,j} = 0$  a dostať

$$\begin{bmatrix} A_1 & 0 \\ 0 & A_2 \end{bmatrix} = A^{(k)}$$

→ aplikovať QR algoritmus na  $A_1$  a  $A_2$

- Takýto QR algoritmus s dobre zvolenými posunmi bol štandardnou metódou pre výpočet vl. hodnôt od začiatku 60-tych rokov. Až v 90-tych rokoch sa našiel zdatnejší super

- algoritmus "Rozdeľuj & Panuj" (Divide-and-conquer) (Leckia 30)

[ Tridiagonalizácia → leckia 26

[ posuny → leckia 29

[ deflácia → (bez ďalšieho komentára → CS)

pozrieme sa teda na "čistý" QR algoritmus a vysvetlíme si, ako vlastne našle vl. hodnoty.

## Simultánne iterovanie bez normovania

Prístup pri skúšaní QR algoritmu bude taký, že sa pozrieme na inú metódu, o ktorej vieme, že je ekvivalentná.

A tou je Simultánne iterovanie

Ak aplikujeme mocninové iterovanie na viaceré vektory (alebo na blok) dostaneme tzv. simultánne iterovanie, (resp. blokovú mocninovú metódu).

Predpokladajme, že máme  $n$  lin. nezávislých vektorov  $v_1^{(0)}, v_2^{(0)}, \dots, v_n^{(0)}$ .

Ak  $A^k v_1^{(0)}$  pre  $k \rightarrow \infty$  konverguje k vl. vektoru pre najv. vl. hodnotu (mocninové iterovanie), tal podmienkou by bolo, že

$\langle A^k v_1^{(0)}, A^k v_2^{(0)}, \dots, A^k v_n^{(0)} \rangle$  by za istých predpokladov mohol konvergovať k podmienenému  $\langle q_1, q_2, \dots, q_n \rangle$  - generovanému  $n$  vl. vektormi  $q_1, q_2, \dots, q_n$  zodpovedajúcimi  $n$  najväčším vl. hodnotám.

Matice:

$$V^{(0)} = \begin{bmatrix} | & & | \\ v_1^{(0)} & \dots & v_n^{(0)} \\ | & & | \end{bmatrix}$$

potom

$$V^{(k)} = A^k V^{(0)} = \begin{bmatrix} | & & | \\ v_1^{(k)} & \dots & v_n^{(k)} \\ | & & | \end{bmatrix}$$

Keďže nás zaujíma stĺpcový priestor  $V^{(k)}$ , jeho dobrú prácu dostaneme pomocou (regulovaného) QR rozkladu  $V^{(k)}$

$$\begin{matrix} \hat{Q}^{(k)} & \hat{R}^{(k)} & = & V^{(k)} \\ \uparrow & \uparrow & & \uparrow \\ n \times n & n \times n & & m \times n \end{matrix}$$

Teda by sme mohli očakávať, že za nie príliš silných predpokladov by sme mali dostať, že stĺpce

$$\hat{Q}^{(k)}$$
 konvergujú k  $\pm q_1, \pm q_2, \dots, \pm q_n$ .

Toto očakávanie môžeme podporiť analýzou podobných analýze konvergencie mocninového iterovania.



po vyjadrení  $v_j^{(0)}$  a  $v_j^{(k)}$  pomocou vektorov matice  $A$ : (2.8)

$$v_j^{(0)} = a_{1j} q_1 + \dots + a_{mj} q_m$$

$$v_j^{(k)} = \lambda_1^k a_{1j} q_1 + \dots + \lambda_m^k a_{mj} q_m$$

ku konvergencii teda nastaj, dojde za predpokladu, že

$$1) \quad |\lambda_1| > |\lambda_2| > \dots > |\lambda_n| > |\lambda_{n+1}| \geq |\lambda_{n+2}| \geq \dots \geq |\lambda_m|$$

(máme vl. hodnoty v tomto usporiadaní)

2) koeficienty  $a_{ij}$  sú "regulárne" v istom určitom zmysle

$$\rightarrow \text{zvolíme } \hat{Q} = \begin{bmatrix} | & | & & | \\ q_1 & q_2 & \dots & q_n \\ | & | & & | \end{bmatrix}$$

potom preadajme, aby  $n \times n$  matici  $\hat{Q}^T v^{(0)}$  boli  
 hlavné minory regulárne, (t.j. ľavé horné podmatice)

$1 \times 1, 2 \times 2, \dots, n \times n$

(Pozn. - toto je podmienka existencie LU rozkladu)

Tvrdenie Predpokladajme, že pre iterovanie  $v^{(k)} = A^k v^{(0)} = \hat{Q} \Lambda^k R$

sú splnené podmienky 1) a 2). Potom pre  $k \rightarrow \infty$  stĺpce matice

$\hat{Q}^{(k)}$  konvergujú ľavé a vl. vektorom  $A$ :

$$\|q_j^{(k)} - \pm q_j\| = O(c^k)$$

pre  $1 \leq j \leq n$  a ~~existuje~~  $c < 1$  je konštanta  $\max_{1 \leq k \leq n} |\lambda_{k+1}| / |\lambda_k|$ .

(známenko  $\pm$  treba brať ako v minulých lekciách, alebo podľa prvej jej správnosti voľbu).

Dôkaz

Rozšírime  $\hat{Q}$  typu  $n \times n$  na ortogonálnu maticu  $Q$  vl. vektorov,

t.j.  $A = Q \Lambda Q^T$ .  $\hat{Q}$  je zodpovedá prvým  $n$  stĺpcom  $Q$ , vezmime

$\hat{\Lambda}$  ľavé horné podmatice typu  $n \times n$  v matici  $\Lambda$  (teda ľl-minor)  
 tiež diagonálna. (velikosti  $n \times n$ )

Potom:

$$V^{(k)} = A^k V^{(0)} = Q \Delta^k Q^T V^{(0)} = \hat{Q} \hat{\Delta}^k \hat{Q}^T V^{(0)} + O(|\lambda_{n+1}|^k)$$

pre  $k \rightarrow \infty$

Ak predpokladáme regularitu minorov  $\hat{Q}^T V^{(0)}$ , tak aj samotná

$\hat{Q}^T V^{(0)}$  je regulárna, takže môžeme člen  $O(|\lambda_{n+1}|^k)$

vynechať sprava  $(\hat{Q}^T V^{(0)})^{-1} \hat{Q}^T V^{(0)}$  a dostať

$$V^{(k)} = \left( \hat{Q} \Delta^k + O(|\lambda_{n+1}|^k) \right) \hat{Q}^T V^{(0)}$$

$\hat{Q}^T V^{(0)}$  je regulárna  $\Rightarrow$  stĺpcový priestor  $V^{(k)}$  je rovnaký ako

stĺp. priestor  $\hat{Q} \Delta^k + O(|\lambda_{n+1}|^k)$ .

Takže nazaj, stĺpcový priestor bude konvergovať lineárne

k stĺpcovému priestoru matice  $\hat{Q}$ .  
(a rýchlosť zjednodá  $(|\lambda_{n+1}|/|\lambda_n|)^k$ )

(To by sa dalo kvantifikovať  
úhlami medzi podpriestormi  
- vzhľadom na  $\sqrt{Q_i(u_i)}$ )

Predpokladali sme tiež, že veľkou  $\hat{Q}^T V^{(0)}$  je regulárna, ale aj  
jej všetky hlavné minory.

Zoparováním vyššie uvedeného argumentu dostaneme  
podobnú konvergenciu aj pre <sup>liniobaly</sup> prísl. k stĺpcor  $V^{(k)}$  k

priestoru  $\langle q_1, q_2, \dots, q_\ell \rangle$  pre  $\ell = 1, 2, \dots, n$ , z čoho

vyplýva tvrdenie.



### Simultánne iterovanie

Pre  $k \rightarrow \infty$  každý z vektorov  $v_1^{(k)}, v_2^{(k)}, \dots, v_n^{(k)}$  konverguje k násobkom  
dominantného vl. vektora  $q_1$  matice  $A$ , takže napríklad tomu, že

ich obal  $\langle v_1^{(k)}, v_2^{(k)}, \dots, v_n^{(k)} \rangle$  konverguje k niečomu užitočnému,



takéto rekurzy tronia <sup>žlho</sup> veľmi zle - podmienení bázou. 29

Ak by sme takéto iterovanie spravili vo floating-point aritmetike, užitočné "smery" by sa rýchlo stratili zachránením.

Zachráná je však jednoduchá, treba ortonormalizovať v každom kroku, nielen na konci. Takže nebudeme vytvárať  $V^{(k)}$  podľa predpisu, ale budeme rátať s riadkami maticami  $Z^{(k)}$  s rovnakým stĺpcovým priestorom.

**Algoritmus 28.3** Simultánne iterovanie

zvoliť  $\hat{Q}^{(0)} \in M_{\min}(\mathbb{R})$  sortovanými stĺpcami

pre  $k=1, 2, \dots$

$$Z = A \hat{Q}^{(k-1)}$$

$$\hat{Q}^{(k)} \hat{R}^{(k)} = Z$$

redukovaný QR rozklad matice  $Z$

Zo zápisu vidíme, že stĺpcové priestory  $\hat{Q}^{(k)}$  a  $Z$  sú rovnaké a obe sa rovnajú stĺpcovému priestoru  $A^k \hat{Q}^{(0)}$ .

Z matematického hľadiska teda tento nový predpis ~~konverguje~~ pre simultánne iterovanie konverguje rovnako, ako predšlý.

Tvrdenie Algoritmus 28.3 generuje rovnaké matice  $\hat{Q}^{(k)}$  ako iterácia

$$V^{(k)} = A^k V^{(0)} = \hat{Q}^{(k)} \hat{R}^{(k)} \quad (\text{za predpokladu } \hat{Q}^{(0)} \text{ sú rovnaké}).$$

Prí predpoklade usporiadania vl. hodnôt a regularity mikro-  
váne aj konvergenciu z predšlého tvrdenia.

Simultánne iterovanie  $\Leftrightarrow$  QR algoritmus

Teraz sa dostávame k vysvetleniu podstaty QR algoritmu.

Ide o simultánne iterovanie s plnou sadou m. vektorov,

memorie, začne sa s  $Q^{(0)} = I$ .

Keďže matice  $\hat{Q}^{(k)}$  sú kvadrátové, v každom kroku máme úplné QR rozklady a v súlade so znením zo začiatku

knihy (Lekcia 7) môžeme dať pred "strieku".

Mali by sme ale rozlíšiť matice  $\hat{Q}^{(k)}$  zo simultannej iterácie ( $\underline{Q}^{(k)}$ )

a  $Q^{(k)}$  z QR algoritmu.

Pomocou teda tieto dva postupy

a pridáme ešte štvrtý ~~nový~~ vektor pre matice  $A^{(k)}$ ,  
resp.  $\underline{Q}^{(k)}$ .

Simultanne iterácie:

(\*)

$$\begin{aligned} Q^{(0)} &= I \\ z &= A Q^{(k-1)} \\ z &= \underline{Q}^{(k)} R^{(k)} \\ \underline{A}^{(k)} &= (\underline{Q}^{(k)})^T A \underline{Q}^{(k)} \end{aligned}$$

QR algoritmus bez posunov

(\*\*)

$$\begin{aligned} A^{(0)} &= A \\ A^{(k-1)} &= Q^{(k)} R^{(k)} \\ \underline{A}^{(k)} &= R^{(k)} Q^{(k)} \\ \underline{Q}^{(k)} &= Q^{(1)} Q^{(2)} \dots Q^{(k)} \end{aligned}$$

Pre oba algoritmy definujeme ešte  $\underline{R}^{(k)} = R^{(k)} R^{(k-1)} \dots R^{(1)}$ .

o ekvivalencii týchto dvoch algoritmov upevnia tvrdenie:

Tvrdenie Procesy (\*), (\*\*) generujú rovnaké postupnosti matic  $\underline{R}^{(k)}, \underline{Q}^{(k)}$  a  $A^{(k)}$ , ktoré zodpovedajú QR rozkladu maticy matice  $A$ :  
 $A^q = \underline{Q}^{(k)} \underline{R}^{(k)}$



Spolu s projekciou podobnostou.

$$A^{(k)} = (\underline{Q}^{(k)})^T A \underline{Q}^{(k)}$$

Dôkaz postupne indukciou vzhľadom na  $k$ .

Pre  $k=0$  máme:

$$A^0 = \underline{Q}^{(0)} = \underline{R}^{(0)} = \underline{I} \quad \text{a} \quad A^{(0)} = A.$$

Pre  $k \geq 1$  sa pozrieme na simultánu iteráciu (\*)

$$A^k = A A^{k-1} \stackrel{IP}{=} A \underline{Q}^{(k-1)} \underline{R}^{(k-1)} = \underline{Q}^{(k)} \underline{R}^{(k)} \underline{R}^{(k-1)} = \underline{Q}^{(k)} \underline{R}^{(k)}$$

Pre  $k \geq 1$  pre QR algoritmus (\*\*) máme:

$$A^k = A \underline{Q}^{(k-1)} \underline{R}^{(k-1)} = \underline{Q}^{(k-1)} A^{(k-1)} \underline{R}^{(k-1)} = \underline{Q}^{(k-1)} \underline{Q}^{(k)} \underline{R}^{(k)} \underline{R}^{(k-1)}$$

$\underline{Q}^{(k-1)} A^{(k-1)}$

$$= \underline{Q}^{(k)} \underline{R}^{(k)}$$

a tiež

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

### Konvergencia QR algoritmu

Teraz máme všetko potrebné k tomu, aby sme mohli povedať pomere veľa o konvergencii QR algoritmu.

Predchádzajúca veta dáva kvalitatívne odpovede:

- prvá veta hovorí, že konštruujeme ortonomálne bázy stĺpcového priestoru matic  $A^k \rightarrow$  teda by sme mali nájsť v. vektory.
- druhá veta hovorí, že ~~norma~~  $\rho(A^k)$  by sme mali nájsť v. hodnoty.

diagonálne zložky  $A^{(k)}$  sú Rayleighove podiele pre stĺpce matice  $Q^{(k)}$ . Keďže tieto stĺpce konvergujú k vl. vektorom, diagonála (Rayleighove podiele) bude konvergovať (dia krát tak rýchlo) k vl. hodnotám.

Tiež, mimodiagonálne členy zodpovedajú tzv. zotrobenému Rayleighovmu podielu pre rôzne vl. vektory zľava a sprava

$$(q_i^{(k)})^T A q_j^{(k)}$$

z ortogonalít vl. vektorov, tieto by mali ísť k nule.

Forma  $A^k = \underline{Q}^{(k)} \underline{R}^{(k)}$ ,  $A^{(k)} = (\underline{Q}^{(k)})^T A \underline{Q}^{(k)}$

Sú ľahko zapamätateľné a veľmi podstatné o QR-algoritme z nich vyplývajú.

Pre kvantitatívne pochopenie konvergenie máme nasledujúci dôstojný tvrdenia o konvergencii simultánného iterovania:

Tvrdenie Použijeme čistý QR algoritmus na reálnu symetrickú maticu, pre ktorú  $|\lambda_1| > |\lambda_2| > \dots > |\lambda_n|$ , a ktorej matica vlastných vektorov  $Q$  má všetky <sup>hlavné</sup> minory regulárne. Potom pre  $k \rightarrow \infty$   $A^{(k)}$  konverguje lineárne s konštantou  $\max_k |\lambda_{k+1}|/|\lambda_k|$  k diagonálnej matici diag  $(\lambda_1, \lambda_2, \dots, \lambda_n)$  a  $Q^{(k)}$  (s príslušne prispôbenými znamienkami) konverguje ku  $Q$  rovnakou rýchlosťou.