

QR rozklad (faktorizace)

- základní myšlenka: sloupce matice A jsou vektory, jejichž lineární obal tvoří obor hodnot $R(A)$ zobrazení Ax , když volíme x libovolně

neboli

$$\left(\begin{array}{c|c|c|c} a_1 & a_2 & \dots & a_n \end{array} \right) \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} = x_1 \begin{pmatrix} a_1 \end{pmatrix} + x_2 \begin{pmatrix} a_2 \end{pmatrix} + \dots + x_n \begin{pmatrix} a_n \end{pmatrix}$$

A je matice $m \times n$, $m \geq n$

- vektory a_1, \dots, a_n dávají postupně podprostory

$$\mathcal{L}(a_1), \mathcal{L}(a_1, a_2), \dots, \mathcal{L}(a_1, \dots, a_n) = R(A)$$

↑ ↑
lineární obal

příčemž v nich můžeme postupně konstruovat ortonormální bázi q_1, \dots, q_n (za předpokladu úplné hodnosti matice A)

takovou, že $\mathcal{L}(a_1) = \mathcal{L}(q_1)$, $\mathcal{L}(a_1, a_2) = \mathcal{L}(q_1, q_2)$ atd.

příčemž můžeme a_i vyjádřit např. takto (v bázi q_j)

$$\begin{aligned} a_1 &= r_{11} q_1 \\ a_2 &= r_{12} q_1 + r_{22} q_2 \\ &\vdots \\ a_n &= r_{1n} q_1 + \dots + r_{nn} q_n \end{aligned} \Leftrightarrow \left(\begin{array}{c|c|c|c} a_1 & \dots & a_n \end{array} \right) = \left(\begin{array}{c|c|c|c} q_1 & \dots & q_n \end{array} \right) \begin{pmatrix} r_{11} & r_{12} & \dots & r_{1n} \\ 0 & r_{22} & \dots & r_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ 0 & \dots & 0 & r_{nn} \end{pmatrix}$$

t.j. $A = \hat{Q} \hat{R}$, kde \hat{Q} je obecně část (pro $m > n$) ortonormální matice Q splňující $Q^T Q = Q Q^T = I$ a \hat{R} je horní trojúhelníková matice

- tomuto rozkladu se říká redukováný QR rozklad (reduced)

a pokud \hat{Q} doplníme na Q lib. vektory ortogonálními na q_1, \dots, q_n a \hat{R} doplníme řádky s nulami, dostaneme plný QR rozklad

$$\begin{array}{c} m \\ \boxed{A} \\ m \times n \end{array} = \begin{array}{c} n \\ \boxed{\hat{Q}} \\ m \times m \end{array} \cdot \begin{array}{c} n \\ \boxed{\hat{R}} \\ m \times n \end{array}$$

$A(m \times n) = Q(m \times m) \cdot R(m \times n)$

- lze ukázat, že každá matice $A \in \mathbb{C}^{m \times n}$ ($m \geq n$) má QR rozklad, a tedy i $\hat{Q} \hat{R}$
(přímou konstrukcí pomocí Gramovy-Schmidtovy ortogonalizace)

a pokud je hodnost $A = n$ (maximální),
pak existuje právě jeden rozklad $\hat{Q} \hat{R}$ s $r_{jj} > 0$,
tj. r_{jj} je reálné, kladné, čímž fixujeme "fázi" q_j

- Pokud je hodnost $A < n$, pak pro určité j budou vektory q_1, \dots, q_j lineárně závislé, pak bude $r_{jj} = 0$
a jako q_j volíme lib. normovaný vektor kolmý na q_1, \dots, q_{j-1}

• použití na řešení $Ax = b$

- máme-li matici ($m \times m$) A a její rozklad $Q \cdot R$
pak řešení x dostaneme přímou zpětnou substitucí
pro $Rx = Q^+ b$, neboť Q^+ je inverzní k Q

[Pozn: u některých metod (např. Householderova triangularizace)
se Q přímou nekonstruuje (z A dostáváme R)
a v průběhu výpočtu R se počítá i $Q^+ b$]

• výpočet QR rozkladu

- několik metod

- | | |
|--|---------------|
| | počet operací |
| 1) přímá Gramova-Schmidtova ortogonalizace | $\sim 2mn^2$ |
| - není obecně stabilní, ztrácí se ortogonalita
kvůli zaokrouhlovacím chybám | |
| 2) modifikovaná G-S ortogonalizace | $\sim 2mn^2$ |
| - o něco lepší, ale také ne zcela přesně | |

- | | |
|--|-------------------------------|
| 3) <u>Householderova triangularizace</u> | $\sim 2mn^2 - \frac{2}{3}n^3$ |
| - nejlepší metoda, zpětně stabilní | |

- | | |
|--|--------------|
| 4) Givensovy rotace | $\sim 3mn^2$ |
| - o něco pomalejší, ale má své
uplatnění např. v iteračních metodách
(viz např. metoda GMRES v letní - semestru) | |

1) přímá konstrukce pomocí Gramovy-Schmidtovi ortogonalizace

- z $m \times n$ matice A dáva redukovaný QR rozklad
- ortogonalizujeme postupně a_2 na a_1 , pak a_3 na a_1 a a_2 atd.

a zároveň normalizujeme (předpoklad plné hodnoty A , jinak nutno testovat, zda $r_{jj} = 0$ a případně volit q_j jinak)

pro $j=1, \dots, n$

$$q_j = a_j$$

pro $i=1, \dots, j-1$

$$r_{ij} = q_i^T a_j$$

$$q_j = q_j - r_{ij} q_i$$

$$r_{jj} = \|q_j\|_2$$

$$q_j = q_j / r_{jj}$$

zde je $\sim 4m$ operací a opakuje se $\sim \frac{n^2}{2}$ krát celkem $O(2mn^2)$

ortogonalizace, pokud a_j blízko q_i , odečítání 2 blízkých čísel (vektorů) \Rightarrow ztráta přesnosti a ortogonality

normalizace

2) modifikovaná Gramova-Schmidtova metoda

- ve standardní G-S metodě jsou jednotlivé q_j dány $P_j a_j$, tj. projektoem $P_j = I - q_1 q_1^T - \dots - q_{j-1} q_{j-1}^T$ na podprostor kolmý na $\mathcal{L}(q_1, \dots, q_{j-1}) = \mathcal{L}(a_1, \dots, a_{j-1})$ (alespoň v přesné aritmetice)

- tento projektor lze napsat jako součin projektorů

$$P_j = P_{\perp q_{j-1}} P_{\perp q_{j-2}} \dots P_{\perp q_2} P_{\perp q_1}, \text{ kde } P_{\perp q_i} = I - q_i q_i^T$$

díky ortogonalitě vektorů q_i

- takže je to numericky výhodnější, P_j má hodnotu $m - (j-1)$, kdežto $P_{\perp q_i}$ mají stále hodnotu $m-1$

- algoritmus modif. G-S metody:

pro $i=1, \dots, n$

$$q_i = a_i$$

(inicializace všech q_i)

pro $i=1, \dots, n$

$$r_{ii} = \|q_i\|_2$$

$$q_i = q_i / r_{ii}$$

normalizace (opět nešetrujeme) zda $r_{ii} = 0$

pro $j=i+1, \dots, n$

$$r_{ij} = q_i^T q_j$$

$$q_j = q_j - r_{ij} q_i$$

izde je celkem $O(2mn^2)$ operací

opět $\sim 4m$ operací

postupná ortogonalizace všech vektorů q_j najednou (izde ztráta přesnosti, ale méně)

- pozn.: G-S ortogonalizace je vlastně

trojúhelníková ortogonalizace, neboť jde přepsat

$$\text{jako } AR_1 R_2 \dots R_n = \hat{Q}$$

$$\text{kde } R_1 = \begin{pmatrix} 1 & & & & \\ r_{12} & r_{11} & & & \\ 0 & 1 & & & \\ & & \ddots & & \\ 0 & & & 1 & \end{pmatrix} \quad \text{a } R_i = \begin{pmatrix} 1 & & & & \\ & \ddots & & & \\ & & 1 & & \\ & & & r_{ii} & \\ & & & & \ddots & \\ 0 & & & & & & 1 \end{pmatrix}$$

$$\text{a } \hat{R} = R_n^{-1} R_{n-1}^{-1} \dots R_1^{-1}$$

mýšlenka Householderovy a Givensovy metody je opáčná,
a sice jde o ortogonální triangularizaci

3) Householderova triangularizace

- nyní budeme převádět A na normální Δ tvar pomocí
ortogonálních matic Q_1, \dots, Q_n , tj.

$$\underbrace{Q_n \dots Q_1}_{Q^T} A = R$$

a dostaneme tak plný QR rozklad

- matice Q_1, \dots, Q_n musí být takové, aby nulovaly prvky
pod diagonálou, tj.

$$A \xrightarrow{Q_1} \begin{pmatrix} x & x & x & \dots & x \\ 0 & x & & & \\ & & x & & \\ & & & \ddots & \\ 0 & x & \dots & & x \end{pmatrix} \xrightarrow{Q_2} \begin{pmatrix} x & x & x & \dots & x \\ 0 & x & x & & \\ & 0 & x & & \\ & & & \ddots & \\ & & & & 0 & x & \dots & x \end{pmatrix} \quad \text{atd. (x zde značí} \\ \text{obecně nenulovou} \\ \text{hodnotu)}$$

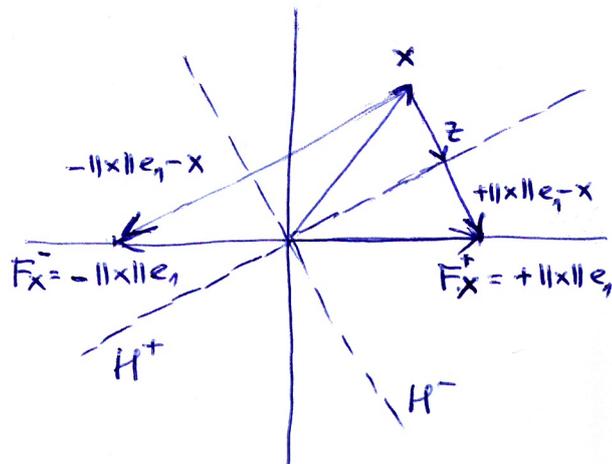
- to lze provést např. Householderovým zrcadlením

$$Q_k = \begin{pmatrix} I & O \\ O & F \end{pmatrix} \begin{matrix} \left. \vphantom{\begin{matrix} I & O \\ O & F \end{matrix}} \right\} k-1 \text{ řádků} \\ \left. \vphantom{\begin{matrix} I & O \\ O & F \end{matrix}} \right\} m-(k-1) \text{ řádků} \end{matrix}$$

kde F je takové, aby z vektoru

$$\begin{matrix} \text{prvky} \\ \text{od diagonály} \\ \text{dolu} \\ \text{v } k\text{-tém} \\ \text{sloupci} \end{matrix} \begin{pmatrix} x_1 \\ \vdots \\ x_p \end{pmatrix} \xrightarrow{F} \begin{pmatrix} \|x\| \\ 0 \\ \vdots \\ 0 \end{pmatrix} = \|x\| e_1$$

↑
jednotkový
vektor



tj. F musí provést zrcadlení v „nadrovíně“ $H^+ \perp v = \|x\| e_1 - x$

(případně v „nadrovíně“ $H^- \perp v = -\|x\| e_1 - x$, pokud je x příliš blízko $\|x\| e_1$)

- projekce do H^+ je dána projektorem $Px = (I - \frac{vv^T}{v^T v})x = x - z$
ovšem my potřebujeme, aby $Fx = x - 2z$

neboli
$$F_x = (I - 2 \frac{vv^T}{v^T v})x$$

- vektor v se obvykle volí podle znaménka x_1 ,

tj. $v = -\text{sign}(x_1) \|x\| e_1 - x$, ale protože F na znaménku vektoru v nezávisí, lze vzít jednoduše

$$v = \text{sign}(x_1) \|x\| e_1 + x \quad (\text{a např. } \text{sign}(0) = 1)$$

- algoritmus pak upravuje A na R takto

pro $k=1, \dots, n$

$$x = A_{k:m, k} \quad (\text{pro-čulivá délka } x!)$$

$$v_k = \text{sign}(x_1) \|x\|_2 e_1 + x \quad (\text{volba } v)$$

$$v_k = v_k / \|v_k\|_2 \quad (\text{normalizace } v)$$

$$A_{k:m, k:n} = A_{k:m, k:n} - 2 v_k (v_k^T A_{k:m, k:n})$$

↑
dvojku lze „schovat“ do v_k

nejnáročnější
část, úprava
 $\sim (m-k) \cdot (n-k)$
prvků, vždy 4 operace

celkem



objem $\frac{1}{2} m n^2 - \frac{1}{6} n^3$
krit 4 operace

$$\sim 2 m n^2 - \frac{2}{3} n^3$$

matice Q se často nekonstruuje, ale počítá se buď $(Q^T = Q_n \dots Q_1)$

$$Q^T b: \text{ pro } k=1, \dots, n$$

$$b_{k:m} = b_{k:m} - 2 v_k (v_k^T b_{k:m})$$

nebo $(Q = Q_1 \dots Q_n, \text{ neboť } Q_i^T = Q_i)$

$$Q b: \text{ pro } k=n, \dots, 1$$

$$b_{k:m} = b_{k:m} - 2 v_k (v_k^T b_{k:m})$$

(zde je nutné uchovat v_k !)

pokud potřebujeme Q , působíme takto

na jednotkovou matici (vektory e_j)

4) Givensovy rotace používají místo zrcadlení otočení, ale nebudeme je zde podrobněji probírat

• lze ukázat, že Householderova triangularizace je zpětně stabilní, tj. pro spóotere' \tilde{Q} a \tilde{R} platí

$$\tilde{Q} \cdot \tilde{R} = A + \delta A, \quad \frac{\|\delta A\|}{\|A\|} = \mathcal{O}(\varepsilon_n) \quad \text{pro vrátě } \delta A \in \mathbb{C}^{m \times n}$$

a též řešení soustavy $Ax = b$ je stabilní,

pokud ji řešíme pomocí $Q \cdot R = A$ a následně $y = Q^T b$

$$\text{a } x = R^{-1} y.$$

- ovšem pozor na podmíněnost úlohy, obecně bude

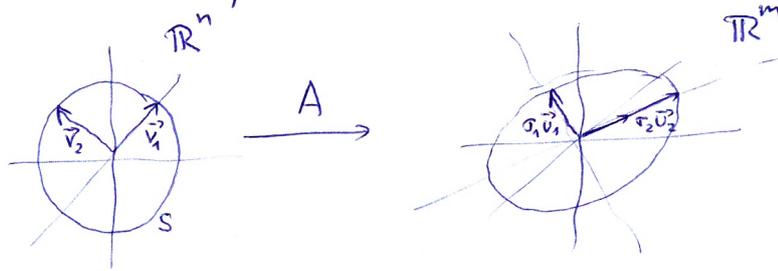
jako \tilde{Q} a \tilde{R} , tak \tilde{x} mít chybu $\mathcal{O}(\kappa(A)\varepsilon_n)$,

kde $\kappa(A) = \|A\| \|A^{-1}\| = \frac{\sigma_1}{\sigma_m}$, kde σ_1 a σ_m jsou největší
a nejmenší singulární hodnoty.

Singulární rozklad matice (Singular Value Decomposition - SVD)

matice $m \times n$ A zobrazuje vektory $x \in \mathbb{R}^n$ do prostoru $\mathcal{R}(A) \subset \mathbb{R}^m$

přitom jednotkové vektory $z \in \mathbb{R}^n$ (1-sféra) zobrazí na hyperelipsu v \mathbb{R}^m



s tím, že některé směry můžou být degenerované $\sigma_i = 0$ (pro matice, které nejsou hodnost n)
ortonormální

- lze najít bázi v \mathbb{R}^n (vektory $\vec{v}_1, \vec{v}_2, \dots$) takovou, že

$$A\vec{v}_i = \sigma_i \vec{u}_i \quad \text{kde } \vec{u}_i \text{ jsou jednotkové vektory ve směrech hlavních poloos hyperelipsy}$$

a σ_i budou seřazeny, tj. $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_n \geq 0$

matricově

$$A \begin{pmatrix} | & | & & | \\ v_1 & v_2 & \dots & v_n \\ | & | & & | \end{pmatrix} = \begin{pmatrix} | & | & & | \\ u_1 & u_2 & \dots & u_m \\ | & | & & | \end{pmatrix} \begin{pmatrix} \sigma_1 & & & 0 \\ & \sigma_2 & & \\ & & \dots & \\ 0 & & & \sigma_n \end{pmatrix}$$

\hat{V} je unitární
 \hat{U} splňuje $\hat{U}^t \hat{U} = I_{n \times n}$

neboli

$$A \hat{V} = \hat{U} \hat{\Sigma} \Rightarrow A = \hat{U} \hat{\Sigma} \hat{V}^t$$

σ_i jsou tzv. singulární hodnoty (reálné n-rozřídil od vlastních čísel)
 u_i jsou levé singulární vektory a v_i jsou pravé singulární vektory

- doplnění báze v \mathbb{R}^m dostaneme tzv. plný sing. rozklad



tj. každá matice je diagonální ve vhodné bázi

- pro $m < n$ se rozkládá A^T doplnění báze

Věta: Každá matice $m \times n$ A má SVD rozklad. Navíc $\{\sigma_i\}$ jsou dány jednoznačně a pokud jsou navzájem různé, pak i $\{u_i\}$ a $\{v_i\}$ jsou dány jednoznačně až na komplexní fázi (± 1 u reálných matic)

Dk: Indukcí: necht' \exists SVD pro matici $(n-1) \times (n-1)$. Položme $\sigma_1 = \|A\|_2 = \sup_{x \neq 0} \frac{\|Ax\|_2}{\|x\|_2}$

určitě existuje v_1 a u_1 takové, že

$$\|v_1\|_2 = 1, \|u_1\|_2 = 1 \text{ a } Av_1 = \sigma_1 u_1$$

doplnění v_1 a u_1 na ortonormální bázi (libovolně) dostaneme U_1 a V_1 unitární matice, pro které

$$U_1^t A V_1 = S = \begin{pmatrix} \sigma_1 & w^t \\ 0 & B \end{pmatrix} \text{ a platí } \left\| \begin{pmatrix} \sigma_1 \\ w \end{pmatrix} \right\|_2 \geq \sigma_1^2 + w^t w = (\sigma_1^2 + w^t w)^{1/2} \left\| \begin{pmatrix} \sigma_1 \\ w \end{pmatrix} \right\|_2 \Rightarrow \|S\|_2 \geq (\sigma_1^2 + w^t w)^{1/2}$$

ale U_1, V_1 jsou unitární \Rightarrow $\|S\|_2 = \|A\|_2 = \sigma_1 \rightarrow w = 0$ (zde indukci)

Základní vlastnosti SVD rozkladu

- SVD vyjadřuje ~~možnou~~ možnou zmenu báze v \mathbb{R}^m a \mathbb{R}^n tak, aby

$$b = Ax \quad \text{přeslo na} \quad b' = \Sigma x', \quad \text{kde } x' = V^T x \quad \text{a} \quad b' = U^T b$$

- rozdíl od vlastních hodnot a vektorů

- ty mají systém jen pro čtvercové matice a rozklad $A = X \Lambda X^{-1}$ existuje

jen pro nedefektní matice (viz později), oba prostory ve stejné bázi

- pokud je matice hermitovská ($A = A^T$), pak λ_i lze volit tak, že $\sigma_i = |\lambda_i|$

- hodnota matice $A =$ hodnota Σ (U i V mají plnou hodnotu) \Rightarrow

\Rightarrow # nenulových σ_i určuje hodnotu A

pokud je r nenul. σ_i , pak $\text{R}(A) = \mathcal{L}(u_1, \dots, u_r)$, $\text{Ker}(A) = \text{null}(A) = \mathcal{L}(v_{r+1}, \dots, v_n)$

- $\|A\|_2 = \sigma_1 = \max \sigma_i = \|\Sigma\|_2$ a dále $\|A\|_F = \left(\sum_{i,j} |a_{ij}|^2 \right)^{1/2} = \sqrt{\sigma_1^2 + \sigma_2^2 + \dots + \sigma_r^2}$

- sestrojí matice $n \times n$ $A^T A$, pak

$$A^T A = (U \Sigma V^T)^T (U \Sigma V^T) = V (\Sigma^T \Sigma) V^T \quad \text{a tedy}$$

$A^T A$ a $\Sigma \Sigma^T$ mají stejná vlastní čísla $\sigma_1^2, \sigma_2^2, \dots, \sigma_n^2$

- pro $m \times m$ matici A je $\det(A) = \prod_{i=1}^m \sigma_i$

- rozepsáním Σ na součet matic $\begin{pmatrix} \sigma_i & & \\ & \sigma_i & \\ & & 0 \end{pmatrix}$ dostaneme $A = \sum_{j=1}^r \sigma_j u_j v_j^T$

\Rightarrow aproximace A omezená na velká σ_i

- „nejlepší“ aproximace A^r pomocí matice určité hodnoty

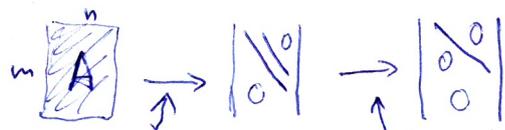
Výpočet SVD rozkladu (nástin)

- přímočaré by bylo najít vlastní čísla $A^T A = V \Lambda V^T$ a spočítat Σ jako

odocinu Λ , pak vyřešit $U \Sigma = A V$ (např. QR faktorizací)

- ovšem ukazuje se, že jde o nestabilní alg., pokud některá $\sigma_k \ll \|A\|$

- stabilní algoritmus založen na převodu na bidiagonální matici



Golubova-Kahanova
bidiagonalizace

$O(mn^2)$

presněji $4mn^2 - \frac{4}{3}n^3$

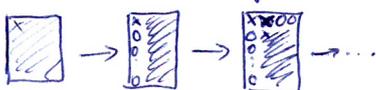
velice efektivní iterativní

metody $O(n^2)$, založené na QR fakt.

nebo rozděla panujících metodě

např. Householderovy reflexe

zleva i zprava



jde to i lépe
pro $m \gg n$

až $2mn^2 + 2n^3$