

Ortogonální matice a QR dekompozice

Důkaz věty z minula:

Alternativně chceme ukázat, že

$$\min \{ \|\delta A\| : A + \delta A \text{ je singulární} \} = \frac{1}{\|A^{-1}\|}.$$

Minimum je alespoň  $\frac{1}{\|A^{-1}\|}$ : Necht'  $\|\delta A\| < \frac{1}{\|A^{-1}\|}$ , neboli platí

$$1 > \|\delta A\| \cdot \|A^{-1}\| \geq \|A^{-1} \delta A\| \quad \text{z multiplikativity normy.}$$


Platí lemma, že pro  $\|X\| < 1$  je  $I - X$  regulární,  
kde  $(I - X)^{-1} = \sum_{i=0}^{\infty} X^i$ . Suma konverguje kvůli  $\|X\| < 1$ .

Proto  $I + A^{-1} \delta A$  je regulární, a tedy  $A + \delta A$  je regulární.

Existuje  $\delta A$ , že  $\|\delta A\| = \frac{1}{\|A^{-1}\|}$  a  $A + \delta A$  je singulární:

Zkonstruujeme. Z definice  $\exists x$ , že  $\|A^{-1}x\| = \|A^{-1}\|$  a  $\|x\| = 1$ .

Položme  $y = \frac{A^{-1}x}{\|A^{-1}x\|} = \frac{A^{-1}x}{\|A^{-1}\|}$ , také platí  $\|y\| = 1$ .



Tedy vezmeme vektor naplňující normu a jeho transformaci maticí  $A^{-1}$ , celkem logické.

Zkonstruujme  $\delta A = \frac{-xy^T}{\|A^{-1}\|}$  a je snadné ověřit, že  $\|\delta A\| = \frac{1}{\|A^{-1}\|}$

a že  $A + \delta A$  je singulární, neboť  $(A + \delta A)y = 0$ . □

Zmiňované dekompozice matic:

$PA = LU$  (maticový zápis Gaussovy eliminace).

$A = Q \Lambda Q^T$  spektrální dekompozice pro  $A^*A = AA^*$ .

$A = SDS^{-1}$  /  $SJS^{-1}$  diagonalizace, Jordanova forma.

$A = QUQ^T$  Schurova dekompozice.

Plán: Chceme vybudovat další dekompozici  $A = QR$ .

24 Motivace: Proč jsou tak zajímavé ortogonální matice?

Matice  $Q$  je ortogonální, když má kolmé sloupce, každý délky jedna. Algebraicky pak platí  $Q^T Q = I_n$ , tedy  $Q^{-1} = Q^T$ .

Geometricky jsou tyto transformace rotace a zrcadlení.

Zachovají normy a skalární součiny:

$$\|Qx\| = x^T Q^T Q x = x^T x = \|x\| \quad \text{a} \quad \langle Qx, Qy \rangle = x^T Q^T Q y = \langle x, y \rangle.$$

Platí  $\|Q\| = \|Q^{-1}\| = 1$ , a tedy  $k(Q) = 1$ , mají numericky nejlepší možnou podmíněnost.  $\leftarrow$  Prakticky třeba 1,001.

Mimochodem tvoří grupu  $O_n$  ortogonálních matic,  $Q_1, Q_2 \in O_n \Rightarrow Q_1 Q_2 \in O_n$ . Její podgrupa pouze rotací  $SO_n$  je také důležitá, řada aplikací v matematice.

Proč je QR dekompozice tak důležitá?

Ortogonální matice mají krasné vlastnosti, které jsme ilustrovali. Důležité ale je, že jsou hodně obecné, což ilustruje existence QR dekompozice libovolné  $A$ . Proto se používají ortogonální matice tak často.

QR dekompozice: Pro každou matici  $A$  existují ortogonální  $Q$  a horní trojúhelníková  $R$ , že  $A = QR$ .

Ukážeme si dva různé důkazy, pomocí dvou konstrukcí založených na různých myšlenkách.

1. konstrukce: Gram-Schmidtova ortogonalizace.

Algoritmus, který  $A \rightsquigarrow Q$ . Podobně jako u LU, získáme  $R$  jako zápis provedených kroků.

Zopakujme si nejprve, jak algoritmus funguje.


Konstruuujeme  $Q = [q_1, \dots, q_n]$  z  $A = [a_1, \dots, a_n]$  postupně po sloupcích zleva doprava.

Příklad:

Od  $a_k$  odečteme ortogonální projekce na  $q_1, \dots, q_{k-1}$  a výsledek normujeme.

$$\hat{q}_k := a_k - \sum_{i=1}^{k-1} \underbrace{a_k^T q_i}_{\text{koeficient}} q_i \quad \text{a} \quad q_k := \frac{\hat{q}_k}{\|\hat{q}_k\|}$$


kolmé projekce



Každá úprava odpovídá násobení horní trojúhelníkovou maticí  $R_k$  zprava:


$$AR_1R_2 \dots R_n = Q, \quad \text{neboli} \quad A = Q \underbrace{R}_{\leftarrow} = R_n^{-1} R_{n-1}^{-1} \dots R_1^{-1}$$

Problém je, že tato metoda výpočtu QR je numericky velice nepřesná, když sloupce  $A$  ukazují podobným směrem. Exaktně:



Když úhel mezi  $\langle q_1, \dots, q_{k-1} \rangle$  a  $a_k$  je malý, potom je norma  $\hat{q}_k$  po odečtení malá. Proto i malá chyba se normováním zvětší!

Numericky:



Chyba před normováním se amplifikuje!

Z pohledu čísla podmíněnosti  $k(AB) \leq k(A) \cdot k(B)$ , ale může být blízko. Pokud  $k(R_i)$  je velké, potom  $k(R)$  může být obrovské, výrazně větší než  $k(A)$ .

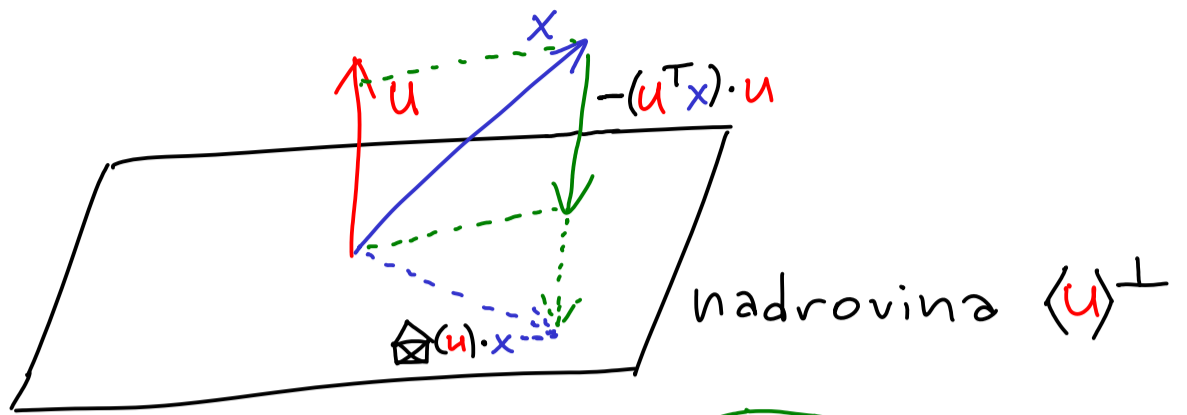
Můžeme však postupovat jinak, místo vyrábění  $Q$  sekvencí  $R_1, \dots, R_n$  můžeme vyrobít  $R$  sekvencí  $Q_1, \dots, Q_k$  s  $k(Q_i) = 1$ .

**26** 2. konstrukce: Householderovy reflexe a Givensovy rotace.

Speciální ortogonální matice, které  $A \rightsquigarrow R$ . Protože  $k(Q) \approx 1$ , platí  $k(A) \approx k(R)$ , a lépe to udělat nejde.

Householderovy reflexe:

Reflexe kolem nadroviny určené normálou  $u$ .



Ortogonalní matice

$$\mathbb{H}(u) = I - 2uu^T$$

$$\mathbb{H}(u) \cdot x = x - 2(u^T x)u$$

Nechť  $A = [a_1, \dots, a_n]$  a  $R = [r_1, \dots, r_n]$ . Chceme najít  $u_1$ , že  $\mathbb{H}(u_1) \cdot a_1 = r_1$ . Musí platit  $\|a_1\| = \|r_1\|$  a  $r_1 = \|a_1\| \cdot e_1 = \begin{pmatrix} \|a_1\| \\ 0 \\ \vdots \\ 0 \end{pmatrix}$ .

Stačí zvolit  $u_1 = \frac{a_1 - r_1}{\|a_1 - r_1\|}$  a dostaneme:

$$\mathbb{H}(u_1) \cdot A = \begin{pmatrix} r_1 & \boxed{?} \\ 0 & \boxed{?} \\ \vdots & \boxed{?} \\ 0 & \boxed{?} \end{pmatrix}$$

Získali jsme první sloupec a řádek R. Další transformace modifikují jen  $\boxed{?}$ . A tak dále, dokud nevynobíme R.


$$\begin{pmatrix} 1 & 0 & \dots & 0 \\ 0 & \mathbb{H}(u_2) & & \\ \vdots & & & \\ 0 & & & \end{pmatrix} \cdot \mathbb{H}(u_1) \cdot A = \begin{pmatrix} r_1 & \boxed{?} \\ 0 & r_2 & \boxed{?} \\ \vdots & 0 & \boxed{?} \\ 0 & 0 & \boxed{?} \end{pmatrix}$$

$$Q_n \dots Q_1 \cdot A = R \Rightarrow A = QR \text{ pro } Q = Q_1^T Q_2^T \dots Q_n^T$$

Givensovy rotace: Jiné jednoduché matice, tentokrát nenulují sloupec, ale pouze jeden koeficient.

Rotace roviny  $\langle e_i, e_j \rangle$  o úhel  $\varphi$ .


$$G(i, j, \varphi) = \begin{pmatrix} \ddots & & & & & \\ & \ddots & & & & \\ & & \cos \varphi & & -\sin \varphi & \\ & & \sin \varphi & & \cos \varphi & \\ & & & \ddots & & \\ & & & & & \ddots \end{pmatrix}$$



Výpočet QR:

Jeden krok:

A nulujeme



$$x = \begin{pmatrix} x_1 \\ \vdots \\ x_i \\ x_j \\ \vdots \\ x_n \end{pmatrix} \xrightarrow{G(i, j, \varphi) \text{ s vhodným } \varphi} \begin{pmatrix} x_1 \\ \vdots \\ \sqrt{x_i^2 + x_j^2} \\ \vdots \\ 0 \\ \vdots \\ x_n \end{pmatrix}$$