

Matematika III

Lineární algebra

Miroslava Dubcová, Drahoslava Janovská, Daniel Turzík

Ústav matematiky

Přednášky LS 2015-2016

Obsah

- 1 Ortogonální transformace**
 - Ortonormální báze
 - Ortogonální podprostory
 - Projekce
 - Řešení ve smyslu nejmenších čtverců
 - Soustava normálních rovnic
- 2 Maticové rozklady**
 - Ortogonální matice
 - Rozklady LR a QR
 - Givensovy matice rovinné rotace
 - Householderovy matice zrcadlení
- 3 Vlastní čísla a vlastní vektory matice**
 - Singulární rozklad matice
- 4 Přeurčené soustavy ještě jednou**
 - Řešení normálních rovnic s využitím singulárního rozkladu
- 5 Literatura**



Ortonormální báze

Systém vektorů v_1, v_2, \dots, v_k tvoří **bázi lineárního prostoru** $V \iff$

1. systém vektorů v_1, v_2, \dots, v_k je lineárně nezávislý,
2. vektory v_1, v_2, \dots, v_k generují celý prostor V .

Báze v_1, v_2, \dots, v_k lineárního prostoru V je **ortonormální** \iff

$$v_i^T v_j = \begin{cases} 0 & i \neq j & \dots & \text{ortogonalita mezi prvky báze} \\ 1 & i = j & \dots & \text{normalizace, tj. } v_i^T v_i = \|v_i\|^2 = 1 \end{cases}$$

Příklad Přirozená báze \mathbb{R}^n :

$$e_1 = \begin{pmatrix} 1 \\ 0 \\ \vdots \\ 0 \end{pmatrix} \in \mathbb{R}^n, \quad e_2 = \begin{pmatrix} 0 \\ 1 \\ \vdots \\ 0 \end{pmatrix} \in \mathbb{R}^n, \quad \dots \quad e_n = \begin{pmatrix} 0 \\ 0 \\ \vdots \\ 1 \end{pmatrix} \in \mathbb{R}^n,$$



$$\mathbf{e}_1^T \mathbf{e}_2 = (1, 0, \dots, 0) \begin{pmatrix} 0 \\ 1 \\ 0 \\ \vdots \\ 0 \end{pmatrix} = 0, \quad \mathbf{e}_3^T \mathbf{e}_3 = (0, 0, 1, 0, \dots, 0) \begin{pmatrix} 0 \\ 0 \\ 1 \\ \vdots \\ 0 \end{pmatrix} = 1$$

\implies přirozená báze je ortonormální.

Pozor na pořadí násobení!

$$\mathbf{e}_1 \cdot \mathbf{e}_2^T = \begin{pmatrix} 1 \\ 0 \\ 0 \\ \vdots \\ 0 \end{pmatrix} \cdot (0, 1, 0, \dots, 0) = \begin{pmatrix} 0 & 1 & 0 & \dots & 0 \\ 0 & 0 & 0 & \dots & 0 \\ \vdots & & & & \vdots \\ 0 & 0 & 0 & \dots & 0 \end{pmatrix} \quad \text{matice } n \times n$$

Poznámka Lineární prostor buď nemá bázi ($\mathcal{C}(\langle a, b \rangle)$) nebo má nekonečně mnoho bází (\mathbb{R}^n).



Ortogonalní podprostory

Podprostory v \mathbb{R}^3 :

triviální: \mathbb{R}^3 , $\dim(\mathbb{R}^3) = 3$

a podprostor obsahující pouze nulový prvek: $\{0\}$, $\dim(\{0\}) = 0$,

netriviální:

přímky p procházející počátkem, $\dim(p) = 1$ a roviny ϱ procházející počátkem, $\dim(\varrho) = 2$.

Přímka může být ortogonalní (kolmá) k jiné přímce nebo k rovině, ale nemůže být kolmá k prostoru, neboť celý prostor \mathbb{R}^3 je kolmý jen k podprostoru $\{0\}$.

Definice Dva **podprostory** V a W prostoru \mathbb{R}^n (téhož) jsou **ortogonalní**



$$v^T w = 0 \quad \forall v \in V \quad \text{a} \quad \forall w \in W.$$



Příklad: Necht V je nadrovina v \mathbb{R}^4 generovaná vektory $v_1 = (1, 0, 0, 0)^T$ a $v_2 = (1, 1, 0, 0)^T$ a necht W je přímka generovaná vektorem $w_1 = (0, 0, 4, 5)^T$. Jsou V a W ortogonální podprostory?

$$v_1^T w_1 = (1, 0, 0, 0) \begin{pmatrix} 0 \\ 0 \\ 4 \\ 5 \end{pmatrix} = 0, \quad v_2^T w_1 = (1, 1, 0, 0) \begin{pmatrix} 0 \\ 0 \\ 4 \\ 5 \end{pmatrix} = 0$$

\Rightarrow V a W jsou ortogonální podprostory.

Proč ?


Projekce

Kdybychom místo přímky měli rovinu nebo obecně libovolný podprostor S prostoru \mathbb{R}^n , zase můžeme hledat bod p v tomto podprostoru, který je nejbližší k b .

Bod p ... projekce bodu b na daný podprostor

Bod p je průsečík kolmé přímky procházející bodem b s daným podprostorem.

Toto je geometrický popis problému **hledání řešení přeurčené soustavy rovnic**, a to **řešení ve smyslu nejmenších čtverců**.

Idea - \mathbb{R}^2 

Označme



$$\alpha = \angle AOQ,$$

$$\theta = \angle BOA,$$

$\beta = \alpha + \theta$. Pak

$$\sin \alpha = \frac{a_2}{\|a\|}, \quad \cos \alpha = \frac{a_1}{\|a\|}, \quad \sin \beta = \frac{b_2}{\|b\|}, \quad \cos \beta = \frac{b_1}{\|b\|},$$

$$\theta = \beta - \alpha \implies \cos \theta = \cos \beta \cos \alpha + \sin \beta \sin \alpha \implies$$



$$\cos \theta = \frac{b_2}{\|b\|} \cdot \frac{a_2}{\|a\|} + \frac{b_1}{\|b\|} \cdot \frac{a_1}{\|a\|} = \frac{a_1 b_1 + a_2 b_2}{\|a\| \cdot \|b\|} \implies$$

Kosinus úhlu libovolných dvou vektorů ... $\cos \theta = \frac{a^T b}{\|a\| \cdot \|b\|}$

Jak tedy spočítáme projekci p bodu b do směru vektoru a ?

Co víme

1. bod p leží na úsečce OA , tj. je nějakým násobkem vektoru a :

$$p = \tilde{x}a, \quad \tilde{x} \in \mathbb{R}$$

2. $(b - \tilde{x}a) \perp a \implies a^T(b - \tilde{x}a) = 0 \iff a^T b = \tilde{x}a^T a$

$$\tilde{x} = \frac{a^T b}{a^T a} \implies p = \frac{a^T b}{a^T a} \cdot a \quad \dots \quad \text{projekce bodu } b \text{ do směru vektoru } a$$

Jaká je vzdálenost bodu b od přímky ve směru vektoru a ?

$$\left\| b - \frac{a^T b}{a^T a} a \right\|^2 = \left(b - \frac{a^T b}{a^T a} a \right)^T \left(b - \frac{a^T b}{a^T a} a \right) =$$
$$b^T b - 2 \frac{(a^T b)^2}{a^T a} + \left(\frac{a^T b}{a^T a} \right)^2 a^T a = \frac{(b^T b)(a^T a) - (a^T b)^2}{a^T a} \geq 0.$$
$$\implies$$

Libovolné dva vektory splňují tzv. **Schwarzovu nerovnost**:

$$|a^T b| \leq \|a\| \|b\| \tag{1}$$

Poznámka Rovnost ve Schwarzově nerovnosti (1) platí $\iff b$ je násobek a . V tom případě je $b \equiv p a$ a vzdálenost je 0.

Řešení přeürčené soustavy ve smyslu nejmenších čtverců

Příklad Přeürčená soustava rovnic: 3 rovnice, 1 neznámá

$$2x = b_1$$

$$3x = b_2$$

$$4x = b_3$$

Tato přeürčená soustava bude řešitelná jen tehdy, budou-li pravé strany v poměru 2:3:4. Jinými slovy řešení bude existovat **jen tehdy**, bude-li $b = (b_1, b_2, b_3)^T$ ležet na přímce generované vektorem $(2, 3, 4)^T$.

V praxi se takovéto rovnice vyskytují a musíme je řešit. Jak?

Jedna možnost je určit x z některé rovnice a ignorovat zbytek rovnic \implies jedna rovnice by byla splněna přesně, ale v ostatních by byly velké chyby - to není nejlepší řešení.



Rozumnější postup: vybereme x tak, abychom minimalizovali "průměrnou" chybu v m rovnicích, obvykle součet čtverců

$$E^2 = (2x - b_1)^2 + (3x - b_2)^2 + (4x - b_3)^2.$$

Pro přesné řešení (b leží na přímce generované vektorem $(2, 3, 4)^T$) bude $E = 0$, jinak je grafem E^2 parabola s minimem v bodě, kde má funkce E^2 minimum. Jde o nejmenší čtverce, stačí spočítat stacionární bod, tj.

$$\frac{dE^2}{dx} = 0 \implies \tilde{x} = \frac{2b_1 + 3b_2 + 4b_3}{29} \dots \text{řešení ve smyslu nejmenších čtverců.}$$

Obecně

$$E = \|ax - b\| = \sqrt{(a_1x - b_1)^2 + \dots + (a_mx - b_m)^2}, \quad \text{t.j.}$$

$$E^2(x) = (ax - b)^T(ax - b) = a^T ax^2 - b^T ax - a^T bx + b^T b.$$

$$(E^2(x))' = 0 \iff x = \frac{a^T b}{a^T a} \implies$$

řešení ve smyslu nejmenších čtverců je identické s řešením \tilde{x} získaným pomocí projekce p .

Více proměnných, tj. více dimenzí. Přeurčená soustava:

$$Ax = b, \quad A \in \mathbb{R}^{m \times n}, \quad m > n, \quad x \in \mathbb{R}^n, \quad b \in \mathbb{R}^m.$$

Chceme minimalizovat chybu $E = \|Ax - b\|$. Platí

$$\begin{aligned} Ax &= \begin{pmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \vdots & & & \vdots \\ a_{m1} & a_{m2} & \dots & a_{mn} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix} = \begin{pmatrix} a_{11}x_1 + a_{12}x_2 + \dots + a_{1n}x_n \\ a_{21}x_1 + a_{22}x_2 + \dots + a_{2n}x_n \\ \vdots \\ a_{m1}x_1 + a_{m2}x_2 + \dots + a_{mn}x_n \end{pmatrix} = \\ &= x_1 \begin{pmatrix} a_{11} \\ a_{21} \\ \vdots \\ a_{m1} \end{pmatrix} + x_2 \begin{pmatrix} a_{12} \\ a_{22} \\ \vdots \\ a_{m2} \end{pmatrix} + \dots + x_n \begin{pmatrix} a_{1n} \\ a_{2n} \\ \vdots \\ a_{mn} \end{pmatrix} \dots \end{aligned}$$

lineární kombinace sloupců $A \forall x \in \mathbb{R}^n \implies$ dostaneme lineární prostor generovaný sloupci matice $A \dots$ tzv.

sloupcový prostor matice A , obvykle označujeme $\mathcal{R}(A)$ (range of A).

Soustava normálních rovnic

Náš cíl: hledáme \tilde{x} tak, aby chyba řešení byla minimální ve smyslu nejmenších čtverců.

Chyba $E = \|Ax - b\|$ je vzdálenost bodu b od bodu $Ax \in \mathcal{R}(A)$. Tedy najít řešení \tilde{x} ve smyslu nejmenších čtverců znamená najít bod $p = A\tilde{x}$, který je nejbliž b ze všech bodů sloupcového prostoru $\mathcal{R}(A)$, tedy p musí být projekce b na $\mathcal{R}(A)$ a vektor chyby $A\tilde{x} - b$ musí být kolmý na sloupcový prostor. Jinak řečeno, každý vektor $Ay \in \mathcal{R}(A)$ musí být kolmý na vektor chyby $A\tilde{x} - b$:

$$(Ay)^T (A\tilde{x} - b) = 0 \implies y^T (A^T A\tilde{x} - A^T b) = 0 \quad \forall y \implies \\ A^T A\tilde{x} - A^T b = 0 \iff A^T A\tilde{x} = A^T b.$$

Řešení libovolného přeurčeného systému rovnic $Ax = b$, $A \in \mathbb{R}^{m \times n}$, $m > n$, splňuje soustavu normálních rovnic

$$A^T A\tilde{x} = A^T b.$$

Věta Vektor $x \in \mathbb{R}^n$ je řešením soustavy $Ax = b$, $A \in \mathbb{R}^{m \times n}$, $m > n$, ve smyslu nejmenších čtverců právě když x řeší normální rovnice. Navíc problém nejmenších čtverců má jediné řešení právě když hodnota $h(A)$ matice A je maximální, tj. $h(A) = n$.

Poznámka Je-li $A \in \mathbb{R}^{m \times n}$, $m \geq n$, pak

$$h(A) = n \iff \det(A^T A) \neq 0.$$

Soustava $Ax = b$ je tedy jednoznačně řešitelná ve smyslu nejmenších čtverců právě když matice $A^T A$ je regulární.

Z normálních rovnic dostáváme

$$\tilde{x} = (A^T A)^{-1} A^T b$$

a má-li matice $A \in \mathbb{R}^{m \times n}$ ortonormální sloupce, t.j. $A^T A = E_n$, kde E_n je jednotková matice řádu n , pak

$$\tilde{x} = A^T b.$$

Příklad Řešte soustavu $Ax = b$ ve smyslu nejmenších čtverců,

$$A = \begin{pmatrix} 1 & 2 \\ 1 & 5 \\ 0 & 0 \end{pmatrix}, \quad b = \begin{pmatrix} 4 \\ 3 \\ 9 \end{pmatrix}, \quad x \in \mathbb{R}^2.$$

Sloupcový prostor matice A :

$$\mathcal{R}(A) = \left\{ v \in \mathbb{R}^3, v = \alpha(1, 1, 0)^T + \beta(2, 5, 0)^T, \alpha, \beta \in \mathbb{R} \right\}$$

... dvoudimenzionální podprostor \mathbb{R}^3 , $(0, 0, 0)^T \in \mathcal{R}(A)$.

Vypočteme projekci $p = A\tilde{x} = A(A^T A)^{-1} A^T b$

$$A^T A = \begin{pmatrix} 2 & 7 \\ 7 & 29 \end{pmatrix}, \quad (A^T A)^{-1} = \frac{1}{9} \begin{pmatrix} 29 & -7 \\ -7 & 2 \end{pmatrix}, \quad p = \begin{pmatrix} 4 \\ 3 \\ 0 \end{pmatrix}.$$

Poznámka Frobeniova věta

Soustava lineárních algebraických rovnic $Ax = b$ má řešení

$$\iff$$

$$h(A) = h(A|b).$$

Počet řešení:

- **Regulární (nesingulární) případ:**

Je-li $h(A) = h(A|b) = n \implies$ soustava má právě jedno řešení

- **Nedourčená soustava**

Je-li $h(A) = h(A|b) < n \implies \dim V_h = n - h(A) > 0 \implies$ soustava má nekonečně mnoho řešení.

- **Přeuročená (nekonsistentní) soustava**

$h(A) < h(A|b) \implies$ Soustava nemá řešení, můžeme najít řešení jen ve smyslu nejmenších čtverců.

Ortogonalní matice

Ortogonalní matice = čtvercová matice s ortonormálními sloupci.

Tedy necht Q je **čtvercová matice** se sloupci q_1, q_2, \dots, q_n

$$Q \text{ je ortogonální} \iff q_i^T q_j = \delta_{ij} = \begin{cases} = 1 & \text{pro } i = j \\ = 0 & \text{pro } i \neq j \end{cases},$$

$$Q^T Q = \begin{pmatrix} \text{---} & q_1^T & \text{---} \\ \text{---} & q_2^T & \text{---} \\ & \vdots & \\ \text{---} & q_n^T & \text{---} \end{pmatrix} \cdot \begin{pmatrix} | & | & & | \\ q_1 & q_2 & \dots & q_n \\ | & | & & | \end{pmatrix} = \begin{pmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ & \ddots & & \\ 0 & 0 & \dots & 1 \end{pmatrix} = E.$$

Vlastnosti ortogonalních matic:

- $Q^T Q = Q Q^T = E$
- Q je regulární, $h(Q) = n \implies \exists Q^{-1}$,

$$Q^T Q = E, \quad \text{tuto maticovou rovnici vynásobím maticí } Q^{-1} \text{ zprava} \implies$$

$$Q^T Q Q^{-1} = Q^{-1} \implies Q^{-1} = Q^T.$$

Permutační matice

Uvedme několik typických příkladů ortogonálních matic.

- Permutační matice** ... v každém řádku i sloupci je právě jedna jednička, všude jinde jsou nuly, ortogonální matice. Např.

$$P = \begin{pmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ 1 & 0 & 0 \end{pmatrix} \implies P \cdot P^T = P^T P = E, \quad P^{-1} = P^T.$$

Proč permutační? Přehodí (permutuje) řádky nebo sloupce dané matice, např.

$$PA = \begin{pmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ 1 & 0 & 0 \end{pmatrix} \begin{pmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{pmatrix} = \begin{pmatrix} a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \\ a_{11} & a_{12} & a_{13} \end{pmatrix}$$

$$AP^T = \begin{pmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{pmatrix} \begin{pmatrix} 0 & 0 & 1 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \end{pmatrix} = \begin{pmatrix} a_{12} & a_{13} & a_{11} \\ a_{22} & a_{23} & a_{21} \\ a_{32} & a_{33} & a_{31} \end{pmatrix}$$

Matice rotace v \mathbb{R}^2

- **Matice rotace v \mathbb{R}^2**

$$\mathbf{G}_{12} = \begin{pmatrix} \cos \varphi & \sin \varphi \\ -\sin \varphi & \cos \varphi \end{pmatrix}, \quad \mathbf{x} = \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \implies \mathbf{G}_{12}\mathbf{x} = \begin{pmatrix} x_1 \cos \varphi + x_2 \sin \varphi \\ -x_1 \sin \varphi + x_2 \cos \varphi \end{pmatrix}.$$

Vhodnou volbou φ lze dosáhnout toho, že se jedna ze složek vektoru \mathbf{x} vynuluje. Např. zvolíme φ tak, aby se druhá složka vynulovala:

$$-x_1 \sin \varphi + x_2 \cos \varphi = 0. \quad \text{Nyní využijeme rovnost} \quad \cos \varphi = \sqrt{1 - \sin^2 \varphi}.$$

Pak

$$x_1^2 \sin^2 \varphi = x_2^2 (1 - \sin^2 \varphi) \implies \sin^2 \varphi = \frac{x_2^2}{x_1^2 + x_2^2} \quad \text{pro } (x_1, x_2) \neq (0, 0).$$

$$\text{Dostaneme:} \quad \sin \varphi = \frac{|x_2|}{\sqrt{x_1^2 + x_2^2}}; \quad \text{obdobně} \quad \cos \varphi = \frac{|x_1|}{\sqrt{x_1^2 + x_2^2}}.$$

(úhel φ znát nepotřebujeme, stačí znát $\sin \varphi$ a $\cos \varphi$).

$\mathbf{G}_{1,2}$... elementární matice rotace.

$\mathbf{G}_{1,2}$ je ortogonalní matice:

$$\mathbf{G}_{1,2}^T \mathbf{G}_{1,2} = \mathbf{G}_{1,2} \mathbf{G}_{1,2}^T = \begin{pmatrix} \cos \varphi & \sin \varphi \\ -\sin \varphi & \cos \varphi \end{pmatrix} \begin{pmatrix} \cos \varphi & -\sin \varphi \\ \sin \varphi & \cos \varphi \end{pmatrix} = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} = \mathbf{E}$$

Položme

$$\sin \varphi = \frac{|x_2|}{\sqrt{x_1^2 + x_2^2}} \quad \text{a} \quad \cos \varphi = \frac{|x_1|}{\sqrt{x_1^2 + x_2^2}}.$$

Pak

$$\mathbf{G}_{1,2} \mathbf{x} = \begin{pmatrix} x_1 \cos \varphi + x_2 \sin \varphi \\ -x_1 \sin \varphi + x_2 \cos \varphi \end{pmatrix} = \begin{pmatrix} \frac{x_1^2}{\sqrt{x_1^2 + x_2^2}} + \frac{x_2^2}{\sqrt{x_1^2 + x_2^2}} \\ \frac{-x_1 x_2}{\sqrt{x_1^2 + x_2^2}} + \frac{x_1 x_2}{\sqrt{x_1^2 + x_2^2}} \end{pmatrix} = \begin{pmatrix} \|\mathbf{x}\| \\ 0 \end{pmatrix}.$$



Příklad Necht $\mathbf{x} = (3, 4)^T$. Položme $\sin \phi = \frac{4}{5}$, $\cos \phi = \frac{3}{5}$. Pak

$$\mathbf{G}_{12}\mathbf{x} = \frac{1}{5} \begin{pmatrix} 3 & 4 \\ -4 & 3 \end{pmatrix} \begin{pmatrix} 3 \\ 4 \end{pmatrix} = (5, 0)^T.$$

Vynásobíme-li vektor \mathbf{x}^T maticí \mathbf{G}_{pq}^T zprava:

$$\mathbf{x}^T \mathbf{G}_{12}^T = \frac{1}{5} (3, 4) \begin{pmatrix} 3 & -4 \\ 4 & 3 \end{pmatrix} = (5, 0).$$

Položíme-li $\sin \phi = \frac{3}{5}$, $\cos \phi = -\frac{4}{5}$, dostaneme

$$\mathbf{G}_{12}\mathbf{x} = \frac{1}{5} \begin{pmatrix} -4 & 3 \\ -3 & -4 \end{pmatrix} \begin{pmatrix} 3 \\ 4 \end{pmatrix} = (0, -5)^T.$$

Obdobně při násobení zprava:

$$\mathbf{x}^T \mathbf{G}_{12}^T = \frac{1}{5} (3, 4) \begin{pmatrix} -4 & -3 \\ 3 & -4 \end{pmatrix} = (0, -5).$$

Householderova matice zrcadlení

- **Householderova matice zrcadlení** ... matice, která vynuluje více složek vektoru najednou.

$$\mathbf{H}_v = \mathbf{E} - 2 \frac{\mathbf{v} \mathbf{v}^T}{\|\mathbf{v}\|^2}, \quad \mathbf{v} \in \mathbb{R}^n, \mathbf{v} \neq \mathbf{0}.$$

$\mathbf{x} \in \mathbb{R}^n \implies \mathbf{H}\mathbf{x} := \mathbf{H}_v\mathbf{x}$ je vektor souměrný s vektorem \mathbf{x} podle nadroviny ρ , která je ortogonální k vektoru \mathbf{v} .

$$\mathbf{H}^T = (\mathbf{E} - 2 \frac{\mathbf{v} \mathbf{v}^T}{\|\mathbf{v}\|^2})^T = \mathbf{H} \implies \mathbf{H} \text{ je symetrická}$$


$$\mathbf{H}^T \mathbf{H} = \mathbf{H}^2 = \mathbf{E} \implies \mathbf{H} \text{ je ortogonální.}$$

Poznámka: $\mathbf{H}\mathbf{x} = \mathbf{x} - \mathbf{v} \implies$ pro $\mathbf{v} = \mathbf{x} - \|\mathbf{x}\|\mathbf{e}_1$ je $\mathbf{H}\mathbf{x} = \|\mathbf{x}\|\mathbf{e}_1$ vektor, který má všechny složky až na první nulové.

Příklad

$$\mathbf{x} = (3, 4)^T, \quad \mathbf{v} = \mathbf{x} - \|\mathbf{x}\|\mathbf{e}_1 = (-2, 4)^T,$$

$$\mathbf{H} = \frac{1}{5} \begin{pmatrix} 3 & 4 \\ 4 & -3 \end{pmatrix}, \quad \mathbf{H}\mathbf{x} = (5, 0)^T.$$



Gram–Schmidtův ortogonalizační proces

Věta Gram–Schmidtův ortogonalizační proces

Každý lineárně nezávislý systém vektorů a_1, a_2, \dots, a_n lze transformovat (převést) na systém ortogonálních vektorů pomocí tzv. Gram–Schmidtova ortogonalizačního procesu:

$$v_1 := a_1$$

a každé další v_i konstruuju tak, aby bylo ortogonální ke všem předchozím v_1, v_2, \dots, v_{i-1} :

$$v_i := a_i - \frac{v_1^T a_i}{v_1^T v_1} v_1 - \dots - \frac{v_{i-1}^T a_i}{v_{i-1}^T v_{i-1}} v_{i-1} ,$$

a vektory q_1, q_2, \dots, q_n , $q_i := \frac{v_i}{\|v_i\|}$, jsou ortonormální.

Příklad

$$a_1 = (1, 1, 0)^T, \quad a_2 = (1, 0, 1)^T, \quad a_3 = (0, 1, 1)^T, \quad v_1 := a_1 = (1, 1, 0)^T$$

$$v_2 = a_2 - \frac{v_1^T a_2}{v_1^T v_1} v_1, \quad v_1^T a_2 = 1, \quad \|v_1\|^2 = v_1^T v_1 = 2$$

$$v_2 = \begin{pmatrix} 1 \\ 0 \\ 1 \end{pmatrix} - \frac{1}{2} \begin{pmatrix} 1 \\ 1 \\ 0 \end{pmatrix} = \begin{pmatrix} 1/2 \\ -1/2 \\ 1 \end{pmatrix}$$

$$v_3 = a_3 - \frac{v_1^T a_3}{v_1^T v_1} v_1 - \frac{v_2^T a_3}{v_2^T v_2} v_2, \quad v_1^T a_3 = 1, \quad v_2^T a_3 = \frac{1}{2}, \quad \|v_2\|^2 = \frac{3}{2},$$

$$v_3 = \begin{pmatrix} 0 \\ 1 \\ 0 \end{pmatrix} - \frac{1}{2} \begin{pmatrix} 1 \\ 1 \\ 0 \end{pmatrix} - \frac{1}{6} \begin{pmatrix} 1 \\ -1 \\ 2 \end{pmatrix} = \frac{2}{3} \begin{pmatrix} -1 \\ 1 \\ 1 \end{pmatrix}$$

Výsledné ortonormální vektory jsou

$$q_1 = \frac{1}{\sqrt{2}}(1, 1, 0)^T, \quad q_2 = \frac{1}{\sqrt{6}}(1, -1, 2)^T, \quad q_3 = \frac{\sqrt{3}}{3}(-1, 1, 1)^T$$

LR rozklad matice

LR nebo také LU rozklad matice ilustrujme nejprve na příkladu (nalevo zápis pomocí rovnic, napravo maticový zápis):

$$\begin{array}{rcl} 2x_1 + x_2 + x_3 & = & 1 \\ 4x_1 + x_2 & = & -2 \\ -2x_1 + 2x_2 + x_3 & = & 7 \end{array} \quad \left(\begin{array}{ccc} 2 & 1 & 1 \\ 4 & 1 & 0 \\ -2 & 2 & 1 \end{array} \right) \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = \begin{pmatrix} 1 \\ -2 \\ 7 \end{pmatrix}$$

Od 2. rovnice odečteme dvojnásobek 1. a ke 3. rovnici přičteme 1.:

$$\begin{array}{rcl} 2x_1 + x_2 + x_3 & = & 1 \\ 0 - x_2 - 2x_3 & = & -4 \\ 0 + 3x_2 + 2x_3 & = & 8 \end{array} \quad \left(\begin{array}{ccc} \mathbf{1} & 0 & 0 \\ -2 & \mathbf{1} & 0 \\ 1 & 0 & \mathbf{1} \end{array} \right) \left(\begin{array}{ccc|c} 2 & 1 & 1 & 1 \\ 4 & 1 & 0 & -2 \\ -2 & 2 & 1 & 7 \end{array} \right) = \left(\begin{array}{ccc|c} 2 & 1 & 1 & 1 \\ 0 & -1 & -2 & -4 \\ 0 & 3 & 2 & 8 \end{array} \right)$$

$$\begin{array}{rcl} 2x_1 + x_2 + x_3 & = & 1 \\ -x_2 - 2x_3 & = & -4 \\ -4x_3 & = & -8 \end{array} \quad \left(\begin{array}{ccc} \mathbf{1} & 0 & 0 \\ 0 & \mathbf{1} & 0 \\ 0 & 3 & \mathbf{1} \end{array} \right) \left(\begin{array}{ccc|c} 2 & 1 & 1 & 1 \\ 0 & -1 & -2 & -4 \\ 0 & 3 & 2 & 8 \end{array} \right) = \left(\begin{array}{ccc|c} 2 & 1 & 1 & 1 \\ 0 & -1 & -2 & -4 \\ 0 & 0 & -4 & -4 \end{array} \right)$$

Zpětný chod $x_3 = 1, \quad x_2 = 2, \quad x_1 = 1.$



Rozklady LR a QR

Vynechme pravou stranu a podívejme se, jaké operace jsme prováděli s maticí soustavy

$$\underbrace{\begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 3 & 1 \end{pmatrix}} \cdot \begin{pmatrix} 1 & 0 & 0 \\ -2 & 1 & 0 \\ 1 & 0 & 1 \end{pmatrix} \begin{pmatrix} 2 & 1 & 1 \\ 4 & 1 & 0 \\ -2 & 2 & 1 \end{pmatrix} = \begin{pmatrix} 2 & 1 & 1 \\ 0 & -1 & -2 \\ 0 & 0 & -4 \end{pmatrix} = R,$$

$$\begin{pmatrix} 1 & 0 & 0 \\ -2 & 1 & 0 \\ -5 & 3 & 1 \end{pmatrix} = \tilde{L} \quad \Longrightarrow \quad \tilde{L} \cdot A = R.$$

\tilde{L} je dolní trojúhelníková matice s jedničkami na diagonále, R je horní trojúhelníková matice. Matice \tilde{L} je regulární, $\det(\tilde{L}) = 1$, a tedy existuje matice \tilde{L}^{-1} . Přesvědčte se, že je také dolní trojúhelníková. Dostali jsme tzv. LR-rozklad matice A :

$$A = \tilde{L}^{-1}R \quad \Longrightarrow \quad A = LR,$$

kde L je dolní trojúhelníková matice s jedničkami na diagonále, R je horní trojúhelníková.

Poznámka Je-li $A = LR$, L dolní trojúhelníková, $L_{ii} = 1$, R horní trojúhelníková, řešme soustavu

$$Ax = b \quad \implies \quad L \underbrace{R x}_y = b,$$

Řešíme nejprve soustavu $Ly = b$ s trojúhelníkovou maticí a pak soustavu $Rx = y$ také s trojúhelníkovou maticí.

Pozor, LR-rozklad nemusí vždy existovat. Co uděláme, narazíme-li při Gaussově eliminaci na nulu na diagonále? Přehodíme (permutujeme) řádky nebo sloupce, to odpovídá vynásobení matice A permutační maticí P . Pak provádíme

$$PA = LR.$$

Toto lze, pokud původní matice není singulární. Pokud je A singulární, žádná permutace nepomůže a matice L má na diagonále jeden nebo více nulových prvků. Výsledný rozklad pak není jednoznačný.

Rozklad QR

QR–rozklad matice A je rozklad matice na součin ortogonální matice Q a horní trojúhelníkové matice R :

$$A = QR, \quad Q^T Q = E, \quad R \text{ je horní trojúhelníková}$$

Řešení soustavy $Ax = b$:

$$QRx = b, \text{ vynásobíme } Q^T \text{ zleva} \implies$$

$$Q^T Q R x = Q^T b, \implies Rx = Q^T b \dots \text{ soustava s trojúhelníkovou maticí}$$

Výhoda: tento rozklad vždy existuje a pro reálné matice je jednoznačný.

Nyní si ukážeme, jak lze pomocí ortogonálních matic transformovat danou matici na žádaný tvar.

Připomeňme: **Elementární matice rotace v \mathbb{R}^2**

$$\mathbf{G}_{12} = \begin{pmatrix} \cos \varphi & \sin \varphi \\ -\sin \varphi & \cos \varphi \end{pmatrix}, \mathbf{x} = \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \implies \mathbf{G}_{12}\mathbf{x} = \begin{pmatrix} x_1 \cos \varphi + x_2 \sin \varphi \\ -x_1 \sin \varphi + x_2 \cos \varphi \end{pmatrix}.$$

Vhodná volba $\varphi \implies$ vynulujeme jednu ze složek vektoru \mathbf{x} .

Givensova matice rovinné rotace v \mathbb{R}^n , $\mathbf{G}_{pq} \in \mathbb{R}^{n \times n}$, je ortogonální matice

$$\mathbf{G}_{pq}^T \mathbf{G}_{pq} = \mathbf{G}_{pq} \mathbf{G}_{pq}^T = \mathbf{E}.$$

Od jednotkové matice \mathbf{E} se liší pouze prvky v pozicích

$$(p, p), (p, q), (q, p) \text{ a } (q, q).$$

Vynásobíme-li libovolnou matici \mathbf{A} maticí \mathbf{G}_{pq} zleva, změní se pouze p -tý a q -tý řádek matice \mathbf{A} , vynásobíme-li matici \mathbf{A} maticí \mathbf{G}_{pq} zprava, změní se pouze p -tý a q -tý sloupec matice \mathbf{A} .

Matice rotace \mathbf{G} pro vektor $\mathbf{x} \in \mathbb{R}^3$?

Idea: vložíme matici $\mathbf{G}_{1,2}$ do jednotkové matice $\mathbf{E}_{3 \times 3}$ - tři možnosti:

- Pro vhodnou volbu φ

$$\tilde{\mathbf{G}}_{12} = \begin{pmatrix} \cos \varphi & \sin \varphi & 0 \\ -\sin \varphi & \cos \varphi & 0 \\ 0 & 0 & 1 \end{pmatrix} \implies \tilde{\mathbf{G}}_{12} \cdot \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = \begin{pmatrix} \tilde{x}_1 \\ 0 \\ x_3 \end{pmatrix}$$

- Pro vhodnou volbu φ

$$\tilde{\mathbf{G}}_{13} = \begin{pmatrix} \cos \varphi & 0 & \sin \varphi \\ 0 & 1 & 0 \\ -\sin \varphi & 0 & \cos \varphi \end{pmatrix} \implies \tilde{\mathbf{G}}_{13} \cdot \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = \begin{pmatrix} \tilde{x}_1 \\ x_2 \\ 0 \end{pmatrix}$$

- Pro vhodnou volbu φ

$$\tilde{\mathbf{G}}_{23} = \begin{pmatrix} 1 & 0 & 0 \\ 0 & \cos \varphi & \sin \varphi \\ 0 & -\sin \varphi & \cos \varphi \end{pmatrix} \implies \tilde{\mathbf{G}}_{23} \cdot \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = \begin{pmatrix} x_1 \\ \tilde{x}_2 \\ 0 \end{pmatrix}$$

Givensovou maticí rovinné rotace lze vždy vynulovat jen jednu složku vektoru.



Nyní položme například:

$$\mathbf{G} := \tilde{\mathbf{G}}_{13} \tilde{\mathbf{G}}_{12} \implies \mathbf{G} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = \tilde{\mathbf{G}}_{13} \begin{pmatrix} \tilde{x}_1 \\ 0 \\ x_3 \end{pmatrix} = \begin{pmatrix} \tilde{\tilde{x}}_1 \\ 0 \\ 0 \end{pmatrix}$$

Postupnou aplikací matic rotace se nám podařilo vynulovat dvě (všechny až na jednu) složky vektoru \mathbf{x} .

\mathbf{G}_{12} je ortogonální matice $\implies \mathbf{G}_{12}^{-1} = \mathbf{G}_{12}^T$

$$\begin{aligned} \mathbf{x}^T \mathbf{G}_{12}^{-1} &= (x_1, x_2) \cdot \mathbf{G}_{12}^{-1} = (x_1, x_2) \cdot \begin{pmatrix} \cos \varphi & -\sin \varphi \\ \sin \varphi & \cos \varphi \end{pmatrix} = \\ &= \left(\frac{(x_1)^2}{\sqrt{x_1^2 + x_2^2}} + \frac{(x_2)^2}{\sqrt{x_1^2 + x_2^2}}, -\frac{x_1 x_2}{\sqrt{x_1^2 + x_2^2}} + \frac{x_2 x_1}{\sqrt{x_1^2 + x_2^2}} \right) = (\|\mathbf{x}\|, 0) \end{aligned}$$

Násobení vektoru \mathbf{x}^T zprava maticí \mathbf{G}_{12}^{-1} vynuluje druhou složku vektoru \mathbf{x}^T .

Pomocí vhodně zvolených Givensových matic lze postupně vynulovat v dané matici $\mathbf{A} \in \mathbb{R}^{n \times n}$ prvky pod diagonálou a transformovat tak matici \mathbf{A} na horní trojúhelníkový tvar. Podstatně záleží na pořadí, v němž prvky nulujeme, neboť chceme, abychom při nulování dalšího prvku dříve získané nuly nezničili.

Sestavme vždy matici \mathbf{G}_{pq} ($p < q$) tak, aby se vynulovala q -tá složka daného vektoru, a násobme postupně matici \mathbf{A} zleva maticemi

$$\begin{array}{cccc} \mathbf{G}_{12} & \mathbf{G}_{13} & \dots & \mathbf{G}_{1n} \\ & \mathbf{G}_{23} & \dots & \mathbf{G}_{2n} \\ & & \ddots & \\ & & & \mathbf{G}_{n-1,n} \end{array} \cdot$$

Po provedení k násobení, $k \leq \frac{1}{2}n(n-1)$ (Givensovu rotaci neaplikujeme na prvek matice, který už nulový je), bude matice \mathbf{A} v horním trojúhelníkovém tvaru \mathbf{R} a matice

$$\mathbf{G} = \mathbf{G}_{n-1,n} \mathbf{G}_{n-2,n} \dots \mathbf{G}_{13} \mathbf{G}_{12}$$

bude ortogonální matice,

$$\mathbf{G}\mathbf{A} = \mathbf{R} \implies \mathbf{A} = \mathbf{G}^T \mathbf{R}.$$

Znáznorněme si **schématicky** Givensovu metodu redukce matice $\mathbf{A} \in \mathbb{R}^{4 \times 4}$ na horní trojúhelníkový tvar (+ značí prvky, které se transformací nemění, * značí prvky, které se změjí):

$$\mathbf{A} = \begin{pmatrix} + & + & + & + \\ + & + & + & + \\ + & + & + & + \\ + & + & + & + \end{pmatrix} \xrightarrow{\mathbf{G}_{12}} \begin{pmatrix} * & * & * & * \\ 0 & * & * & * \\ + & + & + & + \\ + & + & + & + \end{pmatrix} \xrightarrow{\mathbf{G}_{13}} \begin{pmatrix} * & * & * & * \\ 0 & + & + & + \\ 0 & * & * & * \\ + & + & + & + \end{pmatrix} \rightarrow$$

$$\xrightarrow{\mathbf{G}_{14}} \begin{pmatrix} * & * & * & * \\ 0 & + & + & + \\ 0 & + & + & + \\ 0 & * & * & * \end{pmatrix} \xrightarrow{\mathbf{G}_{23}} \begin{pmatrix} + & + & + & + \\ 0 & * & * & * \\ 0 & 0 & * & * \\ 0 & + & + & + \end{pmatrix} \xrightarrow{\mathbf{G}_{24}} \begin{pmatrix} + & + & + & + \\ 0 & * & * & * \\ 0 & 0 & + & + \\ 0 & 0 & * & * \end{pmatrix} \xrightarrow{\mathbf{G}_{34}} \begin{pmatrix} + & + & + & + \\ 0 & + & + & + \\ 0 & 0 & * & * \\ 0 & 0 & 0 & * \end{pmatrix} = \mathbf{R}.$$

Nevýhoda: Givensova matice vynuluje vždy jen jeden prvek v dané matici.

Výhoda (zejména pro práci s řídkými maticemi): Aplikujeme-li Givensovu rotaci na danou matici, pak se v této matici změjí pouze dva řádky nebo sloupce. Ostatní prvky zůstanou nezměněny.

Připomeňme: **Householderova matice zrcadlení**

$$\mathbf{H}_v = \mathbf{E} - 2 \frac{\mathbf{v} \mathbf{v}^T}{\|\mathbf{v}\|^2}, \quad \mathbf{v} \in \mathbb{R}^n, \mathbf{v} \neq \mathbf{0}.$$

Je-li $\mathbf{x} \in \mathbb{R}^n$ a položíme-li $\mathbf{v} = \mathbf{x} - \|\mathbf{x}\| \mathbf{e}_1$, pak $\mathbf{H}\mathbf{x} = \|\mathbf{x}\| \mathbf{e}_1$, tj. vektor $\mathbf{H}\mathbf{x}$ má všechny složky až na první nulové.

Cvičení Ukažte, že pro libovolné dva vektory $\mathbf{x}, \mathbf{y} \in \mathbb{R}^n$, $\|\mathbf{x}\| = \|\mathbf{y}\|$, vede volba $\mathbf{v} = \mathbf{x} - \mathbf{y}$ na takovou Householderovu transformaci, že $\mathbf{H}\mathbf{x} = \mathbf{y}$ a $\mathbf{H}\mathbf{y} = \mathbf{x}$.

Řešení $\mathbf{v} = \mathbf{x} - \mathbf{y}$,

$$\mathbf{H}\mathbf{x} = \mathbf{x} - 2 \frac{(\mathbf{x} - \mathbf{y})(\mathbf{x} - \mathbf{y})^T}{(\mathbf{x} - \mathbf{y})^T(\mathbf{x} - \mathbf{y})} \cdot \mathbf{x} = \mathbf{x} - (\mathbf{x} - \mathbf{y}) \cdot \frac{2(\mathbf{x} - \mathbf{y})^T \mathbf{x}}{(\mathbf{x} - \mathbf{y})^T(\mathbf{x} - \mathbf{y})} = \mathbf{x} - \mathbf{x} + \mathbf{y} = \mathbf{y},$$

protože $\mathbf{x}^T \mathbf{x} = \mathbf{y}^T \mathbf{y}$ a $\frac{2(\mathbf{x}^T \mathbf{x} - \mathbf{y}^T \mathbf{x})}{\mathbf{x}^T \mathbf{x} - 2\mathbf{y}^T \mathbf{x} + \mathbf{y}^T \mathbf{y}} = 1$.

Dokažte, že $\mathbf{H}\mathbf{y} = \mathbf{x}$.

Householderova metoda pro řešení soustavy lineárních algebraických rovnic

$$\mathbf{Ax} = \mathbf{b}, \quad \mathbf{A} \in \mathbb{R}^{n \times n}.$$

Najdeme $n - 1$ Householderových matic $\mathbf{H}_1, \mathbf{H}_2, \dots, \mathbf{H}_{n-1}$, takových, že

$$\mathbf{HA} := \mathbf{H}_{n-1} \cdots \mathbf{H}_2 \cdot \mathbf{H}_1 \cdot \mathbf{A} = \mathbf{R},$$

\mathbf{R} je horní trojúhelníková matice, a pak řešíme soustavu s trojúhelníkovou maticí:

$$\mathbf{HA} = \mathbf{R}, \quad \mathbf{H} \text{ je ortogonální, tedy } \mathbf{H}^T = \mathbf{H}^{-1} \implies \mathbf{A} = \mathbf{H}^T \mathbf{R}.$$

$$\mathbf{H}\mathbf{Ax} = \mathbf{Hb} \implies \mathbf{Rx} = \mathbf{Hb}$$

Opět si **schématicky** znázorníme Householderovu metodu redukce matice $\mathbf{A} \in \mathbb{R}^{4 \times 4}$ na horní trojúhelníkový tvar (+ značí prvky, které se transformací nemění, * značí prvky, které se změňi):

$$\mathbf{A} = \begin{pmatrix} + & + & + & + \\ + & + & + & + \\ + & + & + & + \\ + & + & + & + \end{pmatrix} \xrightarrow{\mathbf{H}_1} \begin{pmatrix} * & * & * & * \\ 0 & * & * & * \\ 0 & * & * & * \\ 0 & * & * & * \end{pmatrix} \xrightarrow{\mathbf{H}_2 \mathbf{H}_1} \begin{pmatrix} + & + & + & + \\ 0 & * & * & * \\ 0 & 0 & * & * \\ 0 & 0 & * & * \end{pmatrix} \xrightarrow{\mathbf{H}_3 \mathbf{H}_2 \mathbf{H}_1} \begin{pmatrix} + & + & + & + \\ 0 & + & + & + \\ 0 & 0 & * & * \\ 0 & 0 & 0 & * \end{pmatrix} = \mathbf{R}.$$

$$\mathbf{H} := \mathbf{H}_3 \mathbf{H}_2 \mathbf{H}_1, \quad \mathbf{H} \mathbf{A} = \mathbf{R}.$$

Výhoda: Householderova matice vynuluje vždy celý sloupec matice až na jeden prvek.

Nevýhoda (zejména pro práci s řídkými maticemi): Aplikujeme-li Householderovu metodu na danou matici, pak se v této matici všechny prvky, kromě právě vynulovaných, zaplní nebo změňi.

Vlastní čísla a vlastní vektory matice

Definice **Vlastním číslem matice \mathbf{A}** (reálné nebo komplexní) se nazývá každé (obecně komplexní) číslo λ , splňující pro některý nenulový vektor \mathbf{x} rovnici

$$\mathbf{Ax} = \lambda \mathbf{x},$$

$\mathbf{x} \neq \mathbf{0}$... **vlastní vektor matice \mathbf{A}** příslušný k vlastnímu číslu λ
Množina všech vlastních čísel matice \mathbf{A} ... **spektrum matice \mathbf{A}**

$\mathbf{Ax} = \lambda \mathbf{x}$... maticová rovnice pro neznámý vektor \mathbf{x}

$\mathbf{Ax} - \lambda \mathbf{x} = \mathbf{0}$, $(\mathbf{A} - \lambda \mathbf{E})\mathbf{x} = \mathbf{0}$, $\mathbf{x} \neq \mathbf{0}$, $\mathbf{A} - \lambda \mathbf{E}$ musí být singulární \implies

$\det(\mathbf{A} - \lambda \mathbf{E}) = 0$... **charakteristická rovnice matice \mathbf{A}**

charakteristický polynom matice \mathbf{A} = polynom stupně n :

$$P(\lambda) = \det(\mathbf{A} - \lambda \mathbf{E}) = (-1)^n (\lambda^n + p_1 \lambda^{n-1} + p_2 \lambda^{n-2} + \dots + p_n), \quad \text{kde}$$

$$-p_1 = a_{11} + a_{22} + \dots + a_{nn} = \text{stopa matice } \mathbf{A}$$

$$p_n = (-1)^n \det \mathbf{A}$$

Pozor! Vlastní čísla reálné matice mohou být imaginární.



Příklad: Vypočtete vlastní čísla a vlastní vektory matice $\mathbf{A} = \begin{pmatrix} 2 & 1 \\ -5 & 0 \end{pmatrix}$.

$$\mathbf{A} - \lambda \mathbf{E} = \begin{pmatrix} 2 - \lambda & 1 \\ -5 & -\lambda \end{pmatrix} \implies \det(\mathbf{A} - \lambda \mathbf{E}) = \lambda^2 - 2\lambda + 5$$

Charakteristická rovnice: $\lambda^2 - 2\lambda + 5 = 0 \implies \lambda_1 = 1 + 2i$, $\lambda_2 = 1 - 2i$,
vlastní čísla matice \mathbf{A} jsou navzájem komplexně sdružená.

Vypočteme vlastní vektor \mathbf{x}_1 příslušný vlastnímu číslu $\lambda_1 = 1 + 2i$, tj. řešíme soustavu se singulární maticí:

$(\mathbf{A} - \lambda_1 \mathbf{E})\mathbf{x}_1 = \mathbf{0}$, $\mathbf{x}_1 = (h_1, h_2) \neq \mathbf{0}$, tedy soustavu

$$\begin{pmatrix} 1 - 2i & 1 \\ -5 & -1 - 2i \end{pmatrix} \begin{pmatrix} h_1 \\ h_2 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$$

Tato soustava má nekonečně mnoho řešení, ale my chceme jen jeden vlastní vektor. Zvolme např. $h_1 = 1$, pak $h_2 = -1 + 2i$. Jsou-li vlastní čísla komplexně sdružená, jsou také komplexně sdružené vlastní vektory.

Dostáváme

$$\mathbf{x}_1 = \begin{pmatrix} 1 \\ -1 + 2i \end{pmatrix}, \quad \mathbf{x}_2 = \begin{pmatrix} 1 \\ -1 - 2i \end{pmatrix}.$$

Odhad spektrálního poloměru

Odhad spektrálního poloměru – **Geršgorinova věta**

Necht $\mathbf{A} = (a_{jk})$ je čtvercová matice $n \times n$. Necht

$K_j = \{\mu \in \mathbb{C}, |\mu - a_{jj}| \leq \sum_{\substack{k=1 \\ k \neq j}}^n |a_{jk}|\}$ je kruh se středem S_j a poloměrem r_j ,

$S_j = a_{jj}$, $r_j = \sum_{\substack{k=1 \\ k \neq j}}^n |a_{jk}|$, t.j poloměr r_j kruhu K_j je roven součtu absolutních


hodnot mimodiagonálních prvků v j -tém řádku.

Pak všechna vlastní čísla matice \mathbf{A} leží ve sjednocení kruhů $\bigcup_{j=1}^n K_j$.

Numerické metody výpočtu vlastních čísel a vlastních vektorů jsou založeny na LU nebo QR rozkladu matice \mathbf{A} .

Příklad

$$\mathbf{A} = \begin{pmatrix} 1 & -1 & 1 & -1 \\ 0 & 1 & -1 & 0 \\ -1 & 0 & 0 & -1 \\ 0 & 1 & 2 & -2 \end{pmatrix}, \quad \begin{array}{l} S_1 = 1 \\ S_2 = 1 \\ S_3 = 0 \\ S_4 = -2 \end{array} \quad \begin{array}{l} r_1 = 3 \\ r_2 = 1 \\ r_3 = 2 \\ r_4 = 3 \end{array}$$



Vlastní čísla jsou

$$1.126575852 \pm 0.7768133722i, \quad -1.126575852 \pm 1.391009448i.$$

Všechna leží v množině $M = K_1 \cup K_2 \cup K_3 \cup K_4$.

Singulární hodnoty matice

$\mathbf{A} \in \mathbb{R}^{m \times n}$, $m \neq n \dots$ libovolná obdélníková matice

Pro obdélníkovou matici není pojem vlastního čísla definován, ale ...

$$\mathbf{A}^T \mathbf{A} \in \mathbb{R}^{n \times n} \implies \mathbf{A}^T \mathbf{A} \text{ je čtvercová}$$

$$(\mathbf{A}^T \mathbf{A})^T = \mathbf{A}^T \mathbf{A} \implies \mathbf{A}^T \mathbf{A} \text{ je symetrická}$$

$$\mathbf{x}^T (\mathbf{A}^T \mathbf{A}) \mathbf{x} = (\mathbf{A} \mathbf{x})^T \mathbf{A} \mathbf{x} = \|\mathbf{A} \mathbf{x}\|^2 \geq 0 \quad \forall \mathbf{x} \in \mathbb{R}^n \implies \mathbf{A}^T \mathbf{A} \text{ je pozitivně semidefinitní}$$

Vlastní čísla $\lambda_1, \lambda_2, \dots, \lambda_n$ matice $\mathbf{A}^T \mathbf{A}$ jsou reálná, nezáporná. Zapišme je ve tvaru $\lambda_k = \sigma_k^2$, $\sigma_k \geq 0$, $k = 1, \dots, n$. Čísla

$\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_n \geq 0$ se nazývají **singulární hodnoty matice \mathbf{A}** .

Pro nejmenší a největší singulární hodnotu matice \mathbf{A} platí:

$$\sigma_1 = \max_{\mathbf{0} \neq \mathbf{x} \in \mathbb{R}^n} \frac{\|\mathbf{A} \mathbf{x}\|}{\|\mathbf{x}\|}, \quad \sigma_n = \min_{\mathbf{0} \neq \mathbf{x} \in \mathbb{R}^n} \frac{\|\mathbf{A} \mathbf{x}\|}{\|\mathbf{x}\|}.$$

Věta Bud $\mathbf{A} \in \mathbb{R}^{m \times n}$ libovolná matice. Pak

- existují ortogonální matice \mathbf{U} typu $m \times m$ a ortogonální matice \mathbf{V} typu $n \times n$ takové, že matice $\mathbf{S} = \mathbf{U}^T \mathbf{A} \mathbf{V}$ typu $m \times n$ má "diagonální" tvar

$$\mathbf{S} = \begin{pmatrix} \mathbf{D} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{pmatrix}$$

$$\mathbf{D} = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_r), \quad \sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r \geq 0,$$

kde $\sigma_1, \sigma_2, \dots, \sigma_r$ jsou nenulové singulární hodnoty matice \mathbf{A} a r je hodnost matice \mathbf{A} ;

- nenulové singulární hodnoty matice \mathbf{A}^T jsou rovněž čísla $\sigma_1, \sigma_2, \dots, \sigma_r$.

Rozklad $\mathbf{A} = \mathbf{U} \mathbf{S} \mathbf{V}^T \dots$ **singulární rozklad matice \mathbf{A} .**

Poznámka $\mathbf{S} = \mathbf{U}^T \mathbf{A} \mathbf{V}$

- sloupce matice $\mathbf{U} \dots m$ ortonormálních vlastních vektorů symetrické matice $\mathbf{A} \mathbf{A}^T$ typu $m \times m$,
- sloupce matice $\mathbf{V} \dots n$ ortonormálních vlastních vektorů symetrické matice $\mathbf{A}^T \mathbf{A}$ typu $n \times n$.

Numerický výpočet

$$\mathbf{A} \in \mathbb{R}^{m \times n}, \quad m \geq n \text{ (w.l.o.g.)}$$

Golubova-Reinschova (Golubova-Kahanova) metoda: dva kroky

- bidiagonalizace matice \mathbf{A} pomocí Householderových matic zrcadlení:

$$\mathbf{A} \longrightarrow \mathbf{J}^{(0)} = \begin{pmatrix} \mathbf{J}_0 \\ \mathbf{0} \end{pmatrix}, \quad \mathbf{J}_0 = \begin{pmatrix} x & x & & & 0 \\ & x & x & & \\ & & \ddots & \ddots & \\ & & & \ddots & x \\ 0 & & & & x \end{pmatrix}.$$

Po n redukčních krocích dostaneme (horní) dvoudiagonální matici $\mathbf{J}^{(0)}$ typu $m \times n$

$$\mathbf{J}^{(0)} = \mathbf{P}_n \mathbf{P}_{n-1} \dots \mathbf{P}_1 \mathbf{A} \mathbf{Q}_1 \mathbf{Q}_2 \dots \mathbf{Q}_{n-2},$$

$\mathbf{P}_k, \mathbf{Q}_k$ jsou Householderovy matice zrcadlení.

$Q := Q_1 Q_2 \cdots Q_{n-2}$, $P := P_1 P_2 \cdots P_n$, P a Q ... ortogonální,

$$J^{(0)} = P^T A Q, \quad (J^{(0)})^T J^{(0)} = J_0^T J_0 = Q^T A^T A Q.$$

Matice J_0 a A jsou podobné a mají tedy tytéž singulární hodnoty. Zbývá provést singulární rozklad dvoudiagonální matice J_0 .

- **singulární rozklad dvoudiagonální matice J_0** , tj. **iterační diagonalizace** pomocí jisté varianty QR metody s posunem spektra s využitím vhodných Givensových matic rovinné rotace

$$J_0 \longrightarrow J_1 \longrightarrow \dots \longrightarrow D, \quad \text{kde } D \text{ je diagonální, } J_{k+1} = S_k^T J_k T_k,$$

S_k a T_k jsou ortogonální matice. Matice T_k vybíráme tak, že posloupnost **třidiagonálních matic $M_k = J_k^T J_k$** konverguje k diagonální matici, kdežto matice S_k vybíráme tak, aby všechny matice J_k byly ve dvoudiagonálním tvaru.

Metoda je rychlá a numericky stabilní. Podrobnostmi se nebudeme zabývat.

Řešení soustavy lineárních rovnic ve smyslu nejmenších čtverců

Připomeňme

Vektor $\mathbf{x} \in \mathbb{R}^n$ je řešením soustavy $\mathbf{Ax} = \mathbf{b}$ ve smyslu nejmenších čtverců právě když \mathbf{x} řeší normální rovnice

$$\mathbf{A}^T \mathbf{Ax} = \mathbf{A}^T \mathbf{b}.$$

Víme také, že soustava $\mathbf{Ax} = \mathbf{b}$ je jednoznačně řešitelná ve smyslu nejmenších čtverců právě když matice $\mathbf{A}^T \mathbf{A}$ je regulární.

Z normálních rovnic dostáváme

$$\mathbf{x} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{b}.$$

Řešení normálních rovnic - teorie

$$\mathbf{A}^T \mathbf{A} \mathbf{x} = \mathbf{A}^T \mathbf{b}, \quad \mathbf{c} := \mathbf{A}^T \mathbf{b}, \quad \mathbf{A}^T \mathbf{A} \text{ regulární} \implies \mathbf{x} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{c}$$

Spektrální analýza matice $\mathbf{A}^T \mathbf{A} \in \mathbb{R}^{n \times n}$:

vlastní čísla $\lambda_i > 0$, vlastní vektory $\mathbf{v}_i \in \mathbb{R}^n$, $\{\mathbf{v}_1, \dots, \mathbf{v}_n\} \dots$ báze $\mathbb{R}^n \implies$

$$\mathbf{x} = \sum_{i=1}^n \alpha_i \mathbf{v}_i, \quad \mathbf{c} = \sum_{i=1}^n \gamma_i \mathbf{v}_i$$

$$\left. \begin{aligned} \mathbf{A}^T \mathbf{A} \left(\sum_{i=1}^n \alpha_i \mathbf{v}_i \right) &= \sum_{i=1}^n \gamma_i \mathbf{v}_i \\ \sum_{i=1}^n \alpha_i \lambda_i \mathbf{v}_i &= \sum_{i=1}^n \gamma_i \mathbf{v}_i \end{aligned} \right\} \implies \alpha_i = \frac{1}{\lambda_i} \gamma_i, \quad i = 1, \dots, n.$$

Co se skrývá za poslední rovností?

Necht vlastní čísla $\lambda_i > 0$, $i = 1, \dots, n$, matice $\mathbf{A}^T \mathbf{A}$ jsou taková, že λ_n je řádově několikrát menší než ostatní vlastní čísla:


$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_{n-1} \gg \lambda_n > 0.$$

Matice $\mathbf{A}^T \mathbf{A}$ zobrazí jednotkovou sféru v \mathbb{R}^n na elipsoid s osami ve směrech vlastních vektorů \mathbf{v}_i . Délka poloosy ve směru \mathbf{v}_n je mnohem menší, než ostatní délky poloos, což znamená, že při zobrazení $\mathbf{A}^T \mathbf{A}$ je n -tá složka libovolného vektoru jednotkové délky zanedbatelná a elipsoid tedy leží v podstatě v \mathbb{R}^{n-1} .


Při řešení normálních rovnic nás zajímá inverzní zobrazení $(\mathbf{A}^T \mathbf{A})^{-1}$. To má stejné vlastní vektory, ale vlastní čísla mají převrácenou hodnotu:

$$(\mathbf{A}^T \mathbf{A})^{-1} \mathbf{v}_i = \frac{1}{\lambda_i} \mathbf{v}_i.$$

Protože $\frac{1}{\lambda_n}$ je mnohem větší než ostatní $\frac{1}{\lambda_i}$, je příslušný elipsoid v podstatě jednodimenzionální.



Zobrazení jednotkové sféry maticí $\mathbf{A}^T \mathbf{A}$; $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_{n-1} \gg \lambda_n > 0$



Zobrazení jednotkové sféry maticí $(\mathbf{A}^T \mathbf{A})^{-1}$; $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_{n-1} \gg \lambda_n > 0$

Numerické řešení normálních rovnic

Jaká je v tomto případě **chyba výpočtu** $E = \|\mathbf{A}^T \mathbf{A} \mathbf{x} - \mathbf{A}^T \mathbf{b}\|$?

V konečné počítačové aritmetice může být vektor $\mathbf{A}^T \mathbf{A} \mathbf{x}$ libovolně nepřesný, protože jednou ztracené cifry nelze získat zpět, a tedy všechny složky kromě poslední jsou zničené nebo úplně ztracené.

Numerické řešení $\mathbf{x} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{b}$:

- pomocí **Choleského rozkladu symetrické, pozitivně definitní matice $\mathbf{A}^T \mathbf{A}$** .
Nevýhoda: museli bychom nejprve explicitně vyčíslit matici $\mathbf{A}^T \mathbf{A}$, tj. vyčíslit mnoho skalárních součinů, čímž již matice $\mathbf{A}^T \mathbf{A}$ může být zatížena značnou chybou. Vyplatí se tedy použít nějakou metodu, která nevyžaduje vytvoření matice $\mathbf{A}^T \mathbf{A}$, ale pracuje přímo s maticí \mathbf{A} .
- **iterační metody**.

Ztrátu platných cifer numerického výpočtu charakterizuje tzv. **číslo podmíněnosti matice**, které je v tomto případě rovno

$$\kappa(\mathbf{A}^T \mathbf{A}) = \frac{\lambda_1}{\lambda_n}.$$

Příklad

$$\mathbf{Ax} = \mathbf{b}$$

$$\begin{pmatrix} 10 & 7 & 8 & 7 \\ 7 & 5 & 6 & 5 \\ 8 & 6 & 10 & 9 \\ 7 & 5 & 9 & 10 \end{pmatrix} \begin{pmatrix} u_1 \\ u_2 \\ u_3 \\ u_4 \end{pmatrix} = \begin{pmatrix} 32 \\ 23 \\ 33 \\ 31 \end{pmatrix}$$

$$\Rightarrow \mathbf{u} = (1, 1, 1, 1)^T$$

$$\mathbf{A}\hat{\mathbf{x}} = \hat{\mathbf{b}}$$

$$\begin{pmatrix} 10 & 7 & 8 & 7 \\ 7 & 5 & 6 & 5 \\ 8 & 6 & 10 & 9 \\ 7 & 5 & 9 & 10 \end{pmatrix} \begin{pmatrix} u_1 \\ u_2 \\ u_3 \\ u_4 \end{pmatrix} = \begin{pmatrix} 32, 1 \\ 22, 9 \\ 33, 1 \\ 30, 9 \end{pmatrix}$$

$$\Rightarrow \mathbf{u} = (9, 2; -12, 6; 4, 5; -1, 1)^T$$

$$\tilde{\mathbf{A}}\tilde{\mathbf{x}} = \mathbf{b}$$

$$\begin{pmatrix} 10 & 7 & 8, 1 & 7, 2 \\ 7, 08 & 5, 04 & 6 & 5 \\ 8 & 5, 98 & 9, 98 & 9 \\ 6, 99 & 4, 99 & 9 & 9, 98 \end{pmatrix} \begin{pmatrix} u_1 \\ u_2 \\ u_3 \\ u_4 \end{pmatrix} = \begin{pmatrix} 32 \\ 23 \\ 33 \\ 31 \end{pmatrix}$$

$$\Rightarrow \mathbf{u} = (-5, 79; 12, 02; -1.57, 2.57)^T$$

Relativní chyba:

$$\varepsilon_{rel}(\hat{\mathbf{b}}) = \frac{\|\hat{\mathbf{b}} - \mathbf{b}\|}{\|\mathbf{b}\|} = 0, 003, \quad \varepsilon_{rel}(\tilde{\mathbf{x}}) = 8, 2$$

$$\varepsilon_{rel}(\tilde{\mathbf{A}}) = \frac{\|\tilde{\mathbf{A}} - \mathbf{A}\|}{\|\mathbf{A}\|} = 0, 009, \quad \varepsilon_{rel}(\tilde{\mathbf{x}}) = 6, 64$$

Matice \mathbf{A} je symetrická, $\det(\mathbf{A}) = 1$, ale $\kappa(\mathbf{A}) = 4488$



Řešení normálních rovnic s využitím singulárního rozkladu

Řešení normálních rovnic s využitím singulárního rozkladu

Necht $\mathbf{A} = \mathbf{USV}^T$, $\mathbf{x} = \arg \min_{\mathbf{y} \in \mathbb{R}^n} \|\mathbf{Ay} - \mathbf{b}\| \implies \mathbf{SV}^T \mathbf{x} = \mathbf{U}^T \mathbf{b}$, kde

$\mathbf{S} = \text{diag}(\sigma_1, \dots, \sigma_p)$, $p = \min(m, n)$. Necht hodnost matice $h(\mathbf{A}) = r < p$. Pak $\sigma_{r+1} = \dots = \sigma_p = 0$, matice \mathbf{S} je singulární a inverzní matice neexistuje. Vynásobíme-li však druhou rovnici maticí \mathbf{S}^+ zleva,

$$\mathbf{S}^+ = \begin{pmatrix} \mathbf{D}^{-1} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{pmatrix}, \quad \mathbf{D}^{-1} = \begin{pmatrix} \frac{1}{\sigma_1} & & \\ & \ddots & \\ & & \frac{1}{\sigma_r} \end{pmatrix},$$

dostaneme pro \mathbf{x} soustavu $\mathbf{V}^T \mathbf{x} = \mathbf{S}^+ \mathbf{U}^T \mathbf{b}$ s ortogonální maticí soustavy \mathbf{V}^T . Matice \mathbf{S}^+ je tzv. **Mooreova-Penroseova pseudoinverzní matice** k matici \mathbf{S} . Pseudoinverzemi v obecném případě se zde nebudeme zabývat. Srovnání:

$$\kappa(\mathbf{A}) = \frac{\sigma_1}{\sigma_r}, \quad \kappa(\mathbf{A}^T \mathbf{A}) = \frac{\lambda_1}{\lambda_r} = \left(\frac{\sigma_1}{\sigma_r} \right)^2 = (\kappa(\mathbf{A}))^2 \implies$$

přímým řešením normálních rovnic ztratíme **dvakrát více** platných cifer než při aplikaci SVD.



Rovnici $\mathbf{A} = \mathbf{USV}^T$ lze přepsat ve tvaru tzv. **singulárního rozvoje matice \mathbf{A}** :

$$\mathbf{A} = \sum_{i=1}^r \sigma_i \mathbf{u}_i \mathbf{v}_i^T, \quad h(\mathbf{A}) = r, \quad h(\mathbf{u}_i \mathbf{v}_i^T) = 1 \quad \implies$$

$$\mathbf{x} \in \mathbb{R}^n \implies \mathbf{Ax} = \sum_{i=1}^r \sigma_i \mathbf{u}_i \mathbf{v}_i^T \mathbf{x} = \sum_{i=1}^r (\mathbf{v}_i^T \mathbf{x} \sigma_i) \mathbf{u}_i \dots$$

lineární kombinace vektorů \mathbf{u}_i , $i = 1, \dots, r$.

Aplikace : Komprese dat

$\mathbf{A} \in \mathbb{R}^{m \times n}$... obsahuje naměřená data. Hledáme aproximaci této matice maticí \mathbf{B} takovou, že $h(\mathbf{B}) = k < \min(m, n)$ a matice \mathbf{B} zachytí **nej důležitější informace obsažené v datech**, tj. v matici \mathbf{A} . Kdybychom například chtěli, aby hodnota matice \mathbf{B} byla rovna jedné, položíme $\mathbf{B} = \sigma_1 \mathbf{u}_1 \mathbf{v}_1^T$.

Pozor! Různá volba k ovlivní kvalitu získaných výsledků.



Příklad Chceme **digitalizovat fotografii** tak, že obraz nahradíme maticí 24×24 pixelů. Prvky matice jsou buď 0 (černá buňka) nebo 1 (bílá buňka). S přesností na 4 desetinná místa získáme 16 nenulových singulárních hodnot, všechny ostatní jsou s touto přesností 0:



9,5403	6,6288	5,6369	3,4756	2,7385	2,2023	1,5835	1,5566
1,4207	1,2006	0,9905	0,9258	0,7479	0,6744	0,6122	0,4698

Hledáme k tak, aby relativní chyba obrazu nebyla větší než 10%, relativní chyba

$$e(k) = 1 - \sqrt{\frac{\sum_{i=1}^k \sigma_i^2}{\sum_{i=1}^{16} \sigma_i^2}}$$

Konkrétně: $e(2) = 0,18$, $e(3) = 0,09 \implies$ tři členy singulárního rozvoje matice \mathbf{A} , \implies

$$\mathbf{B} = \sum_{i=1}^3 \sigma_i \mathbf{u}_i \mathbf{v}_i^T, \quad h(\mathbf{B}) = 3$$



$k = 3$; $k = 5$; $k = 5$, ale prvky \mathbf{B} jsou zaokrouhleny na 0 nebo 1

Literatura

- Turzík D. et all: Matematika II, VŠCHT Praha, 2002.
- Kubíček M., Dubcová M., Janovská D.: Numerické metody a algoritmy, VŠCHT Praha, 2005 (second edition).
- Fiedler M.: Speciální matice a jejich použití v numerické matematice, SNTL, Praha, 1981 .
- Golub G., Van Loan Ch: Matrix computations, The Johns Hopkins University press, Baltimore, 1996 (third edition) .
- Horn R. A. , Johnson Ch. R.: Matrix analysis, Cambridge University Press, 1985 .
- Wilkinson J. H. and Reinsch C.: Linear Algebra, volume II of Handbook for Automatic Computation, SIAM Review 14, 658 (1972).
- Wilkinson J. H., Reinsch C.: Handbook for Automatic Computation, Volume II, Linear Algebra, Part 2, Springer, 1971, ISBN: 0387054146.