

Numerické metody a programování

Lekce 4

Lineární algebra

soustava lineárních algebraických rovnic

$$a_{11}x_1 + a_{12}x_2 + \dots + a_{1,N}x_N = b_1$$

$$a_{21}x_1 + a_{22}x_2 + \dots + a_{2,N}x_N = b_2$$

...

$$a_{M,1}x_1 + a_{M,2}x_2 + \dots + a_{M,N}x_N = b_M$$

zkráceně

$$\mathbf{A} \mathbf{x} = \mathbf{b} \Leftrightarrow b_i = \sum_j a_{ij} x_j$$

základní úlohy lineární algebry

- $N=M$
 - řešení \mathbf{x}
 - inverzní matice \mathbf{A}^{-1}
 - determinant
- $M < N$ nebo degenerace
 - SVD (singular value decomposition)
- $M > N$
 - přeúčtený problém, přibližné řešení

Gaussova-Jordanova eliminace

řešení problému

$$\mathbf{A} [\mathbf{x} \ \mathbf{Y}] = [\mathbf{b} \ \mathbf{1}]$$

řeší zároveň soustavu

$$\mathbf{A} \mathbf{x} = \mathbf{b} \quad \text{a} \quad \mathbf{A} \mathbf{Y} = \mathbf{1}$$

- nahrazení řádku lineární kombinací řádku a jiných řádků nemá vliv řešení problému
- přehození řádků nemá vliv na řešení
- Gaussova-Jordanova eliminace využívá prvního pravidla k redukci matice \mathbf{A} na jednotkovou matici.
- pro zlepšení stability se využívá druhého pravidla (pivotace)

příklad:

$$\begin{aligned} 2x_1 + 1x_2 &= 5 \\ x_1 - x_2 &= -2 \end{aligned}$$

vytvořím

$$\begin{bmatrix} 2 & 1 & 5 & 1 & 0 \\ 1 & -1 & -2 & 0 & 1 \end{bmatrix}$$

vydělím první řádek diagonálním prvkem a_{11} (pivot) a přičtu k ostatním tak, aby $a_{i \neq 1,1} = 0$

$$\begin{bmatrix} 1 & 1/2 & 5/2 & 1/2 & 0 \\ 0 & -3/2 & -9/2 & -1/2 & 1 \end{bmatrix}$$

vydělím druhý řádek diagonálním prvkem a_{22} (pivot) a přičtu k ostatním tak, aby $a_{i \neq 2,2} = 0$

$$\begin{bmatrix} 1 & 0 & 1 & 1/3 & 1/3 \\ 0 & 1 & 3 & 1/3 & -2/3 \end{bmatrix}$$

toto se podle potřeby opakuje

- matice \mathbf{A} je převedena na jednotkovou matici
- z jednotkové matice vznikne inverze \mathbf{A}^{-1}
- z vektoru pravé strany \mathbf{b} vzniklo řešení $x_1=1, x_2=3$
- stabilitu zvýší přehazování řádků/(řádků a sloupců tak, aby nedocházelo k dělení malými čísly (částečná/úplná pivotace)

LU dekompozice

nevýhoda Gaussovy-Jordanovy eliminace:

- všechny pravé strany musí být známy dopředu
- není optimální z hlediska počtu elementárních operací

LU rozklad: rozklad matice \mathbf{A} na součin dolní a horní trojúhelníkové matice

$$\mathbf{L} \mathbf{U} = \mathbf{A}$$

pak platí

$$\mathbf{A} \mathbf{x} = \mathbf{L} (\mathbf{U} \mathbf{x}) = \mathbf{b}$$

takže

$$\mathbf{L} \mathbf{y} = \mathbf{b} \text{ a } \mathbf{U} \mathbf{x} = \mathbf{y}$$

soustavy s trojúhelníkovými maticemi řešíme zpětnou(dopřednou) substitucí např.

$$x_N = \frac{y_N}{u_{NN}},$$
$$x_i = \frac{1}{u_{ii}} \left[y_i - \sum_{j=i+1}^N u_{ij} x_j \right], \quad i = N-1, N-2, \dots, 0$$

inverzi \mathbf{A}^{-1} vypočítáme řešením soustavy pro pravé strany

$$\mathbf{b}_1 = \begin{pmatrix} 1 \\ 0 \\ 0 \\ \vdots \end{pmatrix}, \quad \mathbf{b}_2 = \begin{pmatrix} 0 \\ 1 \\ 0 \\ \vdots \end{pmatrix}, \quad \dots, \quad \mathbf{b}_N = \begin{pmatrix} \vdots \\ 0 \\ 0 \\ 1 \end{pmatrix}$$

vlastní LU dekompozice matice \mathbf{A}

N^2 rovnic pro $N^2 + N$ neznámých

$$i \leq j: l_{i1}u_{1j} + l_{i2}u_{2j} + \dots + l_{ij}u_{ij} = a_{ij} \quad (1)$$

$$i > j: l_{i1}u_{1j} + l_{i2}u_{2j} + \dots + l_{ij}u_{jj} = a_{ij} \quad (2)$$

Croutův algoritmus:

- položíme $l_{ii} = 1, i = 1, \dots, N$
- postupně pro $j = 1, 2, \dots, N$ provedeme
 - nejprve pro $i = 1, 2, \dots, j$ vypočteme u_{ij} z (1)
 - pro $i = j+1, j+2, \dots, N$ použijeme (2) k získání l_{ij}
- pivotace je opět využita ke zlepšení stability

Choleského rozklad

$$\mathbf{L} \mathbf{L}^T = \mathbf{A}$$

pro pozitivní matici $\mathbf{A} > \mathbf{0}$, \mathbf{L} je dolní trojúhelníková matice

- podobně jako LU rozklad řeší systém lineárních rovnic
- asi 2x rychlejší než LU rozklad
- stabilní algoritmus (pivotace není nutná)

Výpočet determinantu

determinant čtvercové matice \mathbf{A}

$$\det(\mathbf{A}) = \sum_{\sigma} \text{sgn}(\sigma) \prod_{i=1}^N a_{i, \sigma_i},$$

kde σ jsou permutace množiny $\{1, 2, \dots, N\}$

determinant matice po LU dekompozici se získá triviálně

$$\det(\mathbf{A}) = \det(\mathbf{L} \mathbf{U}) = \det(\mathbf{L}) \det(\mathbf{U}) = \prod_{j=1}^N u_{jj}$$

Cramérovo pravidlo

řešení soustavy $\mathbf{A} \mathbf{x} = \mathbf{b}$ dostaneme pomocí determinantu takto:

$$x_i = \frac{\det(\mathbf{A}_i)}{\det(\mathbf{A})}, \quad i = 1, 2, \dots, N,$$

kde \mathbf{A}_i vznikne z \mathbf{A} nahrazením i -tého sloupce pravou stranou \mathbf{b}
plyne z

$$\det(\mathbf{A}_i) = \det([\mathbf{a}_1, \dots, \mathbf{b}, \dots, \mathbf{a}_N]) = \sum_j x_j \det([\mathbf{a}_1, \dots, \mathbf{a}_{i-1}, \mathbf{a}_j, \mathbf{a}_{i+1}, \dots, \mathbf{a}_N]) = x_i \det(\mathbf{A})$$

výpočetní čas je srovnatelný s LU rozkladem

iterativní vylepšení řešení lineárních rovnic

- v důsledku zaokrouhlovacích chyb je řešení nepřesné
- max. přesnost ϵ_m obnovíme iterativním postupem

řešme $\mathbf{A} \mathbf{x} = \mathbf{b}$ s nepřesným známým výsledkem $\mathbf{x} + \delta \mathbf{x}$: $\mathbf{A} (\mathbf{x} + \delta \mathbf{x}) = \mathbf{b} + \delta \mathbf{b}$

do $\mathbf{A} \delta \mathbf{x} = \delta \mathbf{b}$ dosadíme za $\delta \mathbf{b}$

výsledná rovnice pro $\delta \mathbf{x}$: $\mathbf{A} \delta \mathbf{x} = \mathbf{A} (\mathbf{x} + \delta \mathbf{x}) - \mathbf{b}$

SVD (Singular Value Decomposition)

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

\mathbf{A} : $M \times N$ reálná (komplexní)

\mathbf{U} : $M \times M$ ortogonální (unitární), $\mathbf{U} \mathbf{U}^T = \mathbf{1}$ ($\mathbf{U} \mathbf{U}^+ = \mathbf{1}$)

\mathbf{S} : $M \times N$ diagonální matice $\mathbf{S} \geq \mathbf{0}$ (singulární čísla s_i)


\mathbf{V} : $N \times N$ ortogonální (unitární)

čtvercová matice $M = N$

regulární, $\min s_i > 0$: $\mathbf{A}^{-1} = \mathbf{V} \text{diag}(1/s_i) \mathbf{U}^T$

singulární, $\min s_i = 0$

- nulový prostor (jádro, *nullspace*) \mathbf{x} : $\mathbf{A} \mathbf{x} = \mathbf{0}$
- obor hodnot (*range*) \mathbf{b} : $\mathbf{A} \mathbf{x} = \mathbf{b}$ pro nějaké \mathbf{x} (obal sloupců \mathbf{a}_i , hodnost)
- ortonormální báze (*nullspace*): sloupce \mathbf{v}_i odpovídající $s_i = 0$
- ortonormální báze (*range*): sloupce \mathbf{u}_i odpovídající $s_i \neq 0$



řešení $A \mathbf{x} = \mathbf{b}$ se singulární A

- homogenní $\mathbf{b} = \mathbf{0}$: každý vektor nullspace
- nehomogenní $\mathbf{b} \neq \mathbf{0}$
 - \mathbf{b} v range: řešení s min. normou $\mathbf{x} = \mathbf{V} \text{diag}(1/s_i) \mathbf{U}^T \mathbf{b}$, kde $1/s_i$ nahrazeno nulou pokud $s_i = 0$ (pseudoinverze); lze přičíst vektor z nullspace
 - \mathbf{b} mimo range: nemá řešení; přibližné řešení ve smyslu $\min |\mathbf{A} \mathbf{x} - \mathbf{b}|$ (metoda nejmenších čtverců) dostaneme opět jako pseudoinverzi

méně rovnic než neznámých $M < N$

- obvykle nekonečně mnoho řešení
- všechna řešení: partikulární řešení plus nullspace

více rovnic než neznámých $M > N$

- obvykle nemá řešení
- metoda nejmenších čtverců

další aplikace SVD

- aproximace matice maticí s hodnotí K : $s_i = 0, i > K$ (podle velikosti)
- separabilní modely (filtry): $\mathbf{A} = \sum_i s_i \mathbf{u}_i \otimes \mathbf{v}_i$
- nejbližší ortogonální matice: $\mathbf{U} \mathbf{V}^T$
- ortonormální báze prostoru N vektorů $\mathbf{a}_j, j = 1, \dots, N$ dimenze M , $N < M$: sloupce matice \mathbf{U} po SVD $M \times N$ matice sloupců \mathbf{a}_j odpovídající $s_j \neq 0$
- Hilbert-Schmidtova norma (Frobeniusova norma): $\|\mathbf{A}\| = (\text{Tr}(\mathbf{A}^T \mathbf{A}))^{1/2} = \left(\sum_i s_i^2 \right)^{1/2}$

Řídké (sparse) matice

- malé množství $a_{ij} \neq 0$
- speciální algoritmy využívají tuto vlastnost
- menší nároky na ukládání a výpočetní čas

Vlastní čísla/vektory

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

- pouze čtvercová matice
- složitý problém, doporučeno používat knihovny (např. LAPACK)
- diagonální prvky trojúhelníkové matice jsou vlastní čísla
- Gaussova-Jordanova eliminace nezachovává vlastní čísla

Von Misesův algoritmus (power iteration):

- iterační postup pro nalezení dominantního vlastního čísla a odpovídajícího vlastního vektoru

$$\mathbf{A} = \lambda_1 \mathbf{x}_1 \mathbf{x}_1^T + \lambda_2 \mathbf{x}_2 \mathbf{x}_2^T + \dots + \lambda_N \mathbf{x}_N \mathbf{x}_N^T, \quad |\lambda_1| > |\lambda_2| > \dots > |\lambda_N|$$

- počáteční volba \mathbf{v}_0 , $\mathbf{v}_0^T \cdot \mathbf{x}_1 \neq 0$

$$\mathbf{v}_{k+1} = \frac{\mathbf{A} \mathbf{v}_k}{\|\mathbf{A} \mathbf{v}_k\|}$$

- iterace konverguje k dominantnímu vlastnímu vektoru

$$\lim_{k \rightarrow \infty} \mathbf{v}_k = \mathbf{x}_1$$

- pro výpočet dalších vlastních čísel pokračujeme s maticí:

$$\mathbf{A} \rightarrow \mathbf{A} - \lambda_1 \mathbf{x}_1 \mathbf{x}_1^T$$

- algoritmus je výhodný pokud potřebujeme jen několik vlastních čísel velké matice – odpadá nutnost faktorizovat celou matici
- využívá např. Google, Twitter pro hledání relevantních webových stránek (PageRank)

QR algoritmus:

- QR rozklad na ortogonální matici \mathbf{Q} a horní trojúhelníkovou matici \mathbf{R}

$$\mathbf{A}_0 = \mathbf{A} \rightarrow \mathbf{A}_k = \mathbf{Q}_k \mathbf{R}_k \rightarrow \mathbf{A}_{k+1} = \mathbf{R}_k \mathbf{Q}_k$$

- iterace zachovává vlastní čísla:

$$\mathbf{A}_{k+1} = \mathbf{R}_k \mathbf{Q}_k = \mathbf{Q}_k^{-1} \mathbf{Q}_k \mathbf{R}_k \mathbf{Q}_k = \mathbf{Q}_k^{-1} \mathbf{A}_k \mathbf{Q}_k$$

- konverguje k trojúhelníkové matici, tj. vlastní čísla na diagonále

Souvislost SVD rozkladu s vlastními čísly/vektory

$$\mathbf{A}^T \mathbf{A} = \mathbf{V} \mathbf{S}^2 \mathbf{V}^T$$

$$\mathbf{A} \mathbf{A}^T = \mathbf{U} \mathbf{S}^2 \mathbf{U}^T$$

t.j. sloupce \mathbf{V} a \mathbf{U} jsou vlastní vektory matic $\mathbf{A}^T \mathbf{A}$ resp. $\mathbf{A} \mathbf{A}^T$

Symetrické (Hermitovské) matice

$$\mathbf{A}^T = \mathbf{A}$$

SVD:

$$\mathbf{A}^2 = \mathbf{A}^T \mathbf{A} = \mathbf{V} \mathbf{S}^2 \mathbf{V}^T$$

$$\lambda_i^2 = s_i^2$$

tj. sloupce \mathbf{V} a \mathbf{U} jsou vlastní vektory \mathbf{A} a singulární čísla jsou absolutní hodnoty vl. čísel