

Přednáška 14 - Lineární algebraické systémy II

Opáčko Lineára 1:

Vektorové normy

- $\|\vec{x}\| = \|\vec{x}\|_2 = \sqrt{x_1^2 + \dots + x_n^2}$... obecněji $\|\vec{x}\|_p := \sqrt[p]{|x_1|^p + \dots + |x_n|^p}$ $p \in \mathbb{N}$
 $\|\vec{x}\|_\infty := \max\{|x_1|, \dots, |x_n|\}$

Maticové normy

- $\|A\| = \|A\|_2 := \max_{\vec{v} \in \mathbb{R}^n \setminus \{0\}} \frac{\|A\vec{v}\|_2}{\|\vec{v}\|_2} = \max_{\substack{\|\vec{v}\|_2 = 1 \\ \vec{v} \in \mathbb{R}^n \setminus \{0\}}} \|A\vec{v}\|_2$

- $\|A\|_p := \max_{\vec{v} \in \mathbb{R}^n \setminus \{0\}} \frac{\|A\vec{v}\|_p}{\|\vec{v}\|_p} = \max_{\substack{\|\vec{v}\|_p = 1 \\ \vec{v} \in \mathbb{R}^n \setminus \{0\}}} \|A\vec{v}\|_p$

Vektorová norma nám měří velikost vektoru \mapsto

\mapsto maticová norma nám měří „velikost matice“ ve smyslu „matice = zobrazení“ \rightarrow „velikost zobrazení \sim jak nejvíce může změnit velikost inputu (relativně).“

- Lze snadno vidět, že:

$$\bullet \|A\vec{v}\|_p \leq \|A\|_p \cdot \|\vec{v}\|_p$$

$$\bullet \|AB\|_p \leq \|A\|_p \cdot \|B\|_p$$

$$\forall p \in \{1, 2, \dots, \infty\}$$

- „velikost matice“ lze měřit i „vektorově“ \rightarrow

\rightarrow tzv. Frobeniova norma $\|A\|_F = \sqrt{a_{11}^2 + a_{12}^2 + \dots + a_{1n}^2 + \dots + a_{n1}^2 + \dots + a_{nn}^2}$

- matice, které zachovávají normu se nazývají unitární

Q je unitární $\Leftrightarrow \forall \vec{v}: \|Q\vec{v}\|_2 = \|\vec{v}\|_2$ \Leftrightarrow sloupce Q tvoří ortonormální posloupnost

Opáčko:

- Gaussova eliminace odpovídá okamžité aplikaci LU faktorizace
- pro obecnou regulární matici A můžeme potřebovat pivotaci
- i s pivotací může být G.E./LU nestabilní, tj. zaokrouhlovací chyby můžou úplně zkreslit a zkažit vypočtené faktory \hat{L}, \hat{U} .
- Pro SPD matice (např. kovarianční matice) lze ukázat, že nepotřebujeme pivotaci a zároveň, že G.E./W je stabilní

É jako přirozené plynou 2 otázky:

1. Existují stabilní (stabilnější) algoritmy pro řešení $A\vec{x} = \vec{b}$?

2. Jak poznáme/vypočteme podmíněnost konkrétního systému $A\vec{x} = \vec{b}$?

→ opáčko: stabilita \equiv jak konkrétní algoritmus ne/akumuluje zaokrouhlovací chyby

podmíněnost \equiv jak je konkrétní matematický problém citlivý na „malé“ perturbace (změny v datech)

→ stabilní algoritmy jsou nakonec k ničemu pro špatně podmíněné problémy \leadsto nestačí se zajímat pouze o stabilita.

Podmíněnost problému $A\vec{x} = \vec{b}$

Mějme tedy malou perturbaci $A\vec{x} = \vec{b}$:

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

$$\text{kde } \frac{\|\tilde{A} - A\|}{\|A\|} \leq \varepsilon_A \quad \& \quad \frac{\|\tilde{b} - b\|}{\|b\|} \leq \varepsilon_b$$

relativní velikosti perturbací $\ll 1$

Pak máme:

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

Tudiž:

$$\begin{aligned} \|\tilde{x} - x\| &\leq \|A^{-1}\| \cdot \left(\sum_A \|A\| \cdot \|\tilde{x}\| + \sum_b \|b\| \right) \leq \\ &\leq \|A^{-1}\| \cdot \left(\sum_A \|A\| \cdot \|\tilde{x}\| + \sum_b \|A\| \cdot \|x\| \right) \\ &\leq \|A^{-1}\| \cdot \|A\| \cdot \left(\sum_A \|\tilde{x} - x + x\| + \sum_b \|x\| \right) \\ &\leq \|A^{-1}\| \cdot \|A\| \cdot \left(\sum_A \|\tilde{x} - x\| + (\sum_A + \sum_b) \|x\| \right) \end{aligned}$$

$$\|\tilde{x} - x\| \cdot \left(1 - \|A^{-1}\| \cdot \|A\| \cdot \sum_A \right) \leq \|A^{-1}\| \cdot \|A\| \cdot (\sum_A + \sum_b) \|x\|$$

$$\frac{\|\tilde{x} - x\|}{\|x\|} \leq$$

velikost změny řešení
na základě perturbace

$$\frac{\|A^{-1}\| \cdot \|A\|}{1 - \|A^{-1}\| \cdot \|A\| \cdot \sum_A}$$

↑
podmíněnost problému $A\vec{x} = \vec{b}$

$$\cdot (\sum_A + \sum_b)$$

velikost perturbace dat

Číslo $\|A^{-1}\| \cdot \|A\|$ je tzv. číslo podmíněnosti matice A

\leadsto klasické značení je $\kappa(A) := \|A\| \cdot \|A^{-1}\|$

Vidíme, že pro obecnou perturbaci dat velikosti ε

lze matematicky očekávat přesnost řešení
přimejlepšíím řádu $\mathcal{O}(\kappa(A) \cdot \varepsilon)$ \leadsto

\leadsto tj. i pro zcela stabilní alg. máme chyby $\mathcal{O}(\kappa(A) \cdot \varepsilon_{\text{mach}})$

Dovětek k efektivitě LU / G.E.

(= sparse)

Viděli jsme, že pro některé aplikace máme A tzv. řádkou
tj. většina prvků A je rovna 0 a ty nenulové prvky jsou

«řádké», např. aproximace druhé derivace vedle na matici $A = \frac{1}{h^2} \begin{bmatrix} -2 & 1 & & 0 \\ & 1 & -2 & 1 \\ & & \ddots & \ddots \\ 0 & & & 1 & -2 \end{bmatrix} n \times n$

$n \times n$ z n^2 prvků jich je pouze $3n-2$ nenulových.

Podobně tomu je pro většinu problémů, které v nějakém smyslu aproximují nebo pracují s derivacemi.

\Rightarrow abychom měli efektivní výpočty, stačí nám pracovat pouze s těmi nenulovými prvky $n \times n$

$n \times n$ tzv. «sparse-matrix algorithms».

Jejich odvozování & implementace je technická a pokročilá, ale jejich používání snadné:

Python demo: sparse vs. dense

storage
&
time

Stabilnější algoritmy

\rightarrow jak nám vznikala nestabilita? Dělení jsme disproporčně velkým nebo malým číslem.

V řeči matic: matice $M^{(k)}$ velmi výrazně měnil normu sloupců & řádků matice $A^{(k-1)}$.

$n \times n$ chtěli bychom navrhnout algoritmy / metody, které převedou A na horní- Δ , ale za použití unitárních maticových transformací, tj. tak, že jejich aplikace nemění normu.

(nebo ne příliš).

