

Iterační metody numerické lineární algebry

- srovnání přímých metod (viz zimní se-estr) a iterativních metod pro $Ax=b$

přímé metody (LU rozklad, QR rozklad)

- + konečný počet kroků $\sim n^3$
- + opakovatelná využitelnost, např. máme-li více pravých stran
- velká paměťová náročnost i pro řídke matice, neboť LU rozklad už nemusí být řídky

iterační metody

- + mnohdy stačí jen výpočet (opakováný) $A \cdot x$, pro řídke matice může být až $O(n)$, někdy není třeba ani matici A ukládat
- + může občas stačit jen několik iterací k dosažení požadované přesnosti \Rightarrow můžou být rychlejší než přímé metody
- není zaručena konvergance pro obecnou soustavu ale často jen pro určité typy matic
- mnohdy nutné tzv. předpomínení, aby byla konvergence dostatečně rychlá, často je „síté na míru“ daného problému

Pozn: pracujeme-li s konečnou aritmetikou, pak kvůli zaokrouhlovacím chybám nedávají ani přímé metody přesné výsledky \Rightarrow iterační metody se používají k zpřesnění přímočích metod

- budeme se zabývat

stacionárními iterativními metodami, na nichž staví pokročilá efektivní metoda multigridu

nestacionárními iter. metodami využívajícími tzv. Krylovovy prostory

stacionární iteracní metody

- základní myšlenka: rozložit $A = M - K$ tak, aby
M byla regulární matici a řešit s ního sponzorit M^{-1}
pak $\exists Ax = Mx - Kx = b$
dostaneme $x = M^{-1}Kx + M^{-1}b = Rx + c$
a hledáme x metodou prosté iterace

$$x_{m+1} = Rx_m + c$$

 s vhodnou volbou x_0
 pokud jsou R a c konstantní během iterace, jde
o stacionární metodu
- konvergence závisí na vlastnostech matici R
 odčteme $x = Rx + c$, kde x je řešení $Ax = b$
 dostaneme $x_{m+1} - x = R(x_m - x)$
 $\|x_{m+1} - x\| \leq \|R\| \|x_m - x\| \leq \|R\|^{m+1} \|x_0 - x\|$
 pokud $\|R\| = \max_{x \neq 0} \frac{\|Rx\|}{\|x\|}$ je operátorová norma
 pro danou vektorovou normu
 vidíme, že $x_m \rightarrow x$ a tedy $\|x_m - x\| \rightarrow 0$
 pokud $\|R\| < 1$
 máme i závazat, že x_n konverguje k řešení $Ax = b$
 pro lib. počítační x_0 a pro lib. pravou stranu b,
 právě když je spektrální polomer matici

$$\rho(R) = \max_{\substack{\text{vlastní} \\ \text{čísla} \\ \lambda(R)}} |\lambda| < 1$$
- rychlosť konvergence $r(R) = -\log_{10} \rho(R)$
 zhruba udává, kolik správných desetinných míst
 přibude v jedné iteraci, neboť $\underbrace{\|x_{m+1} - x\|}_{\text{toto platí pro vekt. normu}} \leq \rho(R) \|x_m - x\|$
 máme $\log_{10} \|x_m - x\| - \log_{10} \|x_{m+1} - x\| \geq r(R)$

- dle iterativních metod:

1) zvolit $M-K$ tak, aby šlo $\tilde{M}^{-1}Kx = Rx$ a $\tilde{M}^{-1}b = c$

současně spočítat (M je typicky diagonální, nebo trojúhelníková matici)

2) a zdrovení tak, aby $\varrho(R)$ byl co nejménší

Bohužel jde o konfliktní požadavky, neboť jsou

2 extrémy: 1) $M=I$ je ideální pro $\tilde{M}^{-1}=I$, ale $\varrho(R)$ může být mnohem větší než 1

2) $M=A$ atedy $K=0 \Rightarrow \varrho(R)=0$

ovšem typicky A^{-1} neuvíme snadno

\Rightarrow nutný kompromis

- Jacobeho metoda

myslenka: vyjádřitme x_j zodpovídající j -té rovnici

příčemž za ostatní x_i dosadíme předchozí hodnoty

$$x_{m+1,j} = \frac{1}{a_{jj}} \left(b_j - \sum_{k \neq j} a_{jk} x_{m,k} \right)$$

(pokud $a_{jj} \neq 0$, pokud ne, tak nutno přeuspordat řádky)

Jde o rozklad $A = M - K = \overline{D} - (\overline{L} + \overline{U})$

diagonální pruky pod a nad diagonálou
pruky vzdále s opačným znakovem

$$\text{atedy } R_{\text{Jac}} = \overline{D}^{-1} (\overline{L} + \overline{U}), \quad c_{\text{Jac}} = \overline{D}^{-1} b$$

Př. Uvažujme matici $A = \underbrace{\begin{pmatrix} 2 & -1 & & 0 \\ -1 & 2 & -1 & \\ & -1 & 2 & \dots \\ 0 & & \dots & -1 \\ & & & -1 & 2 \end{pmatrix}}_n$ jde o matici, která se objeví
pri řešení jednorozměrné Poissonovy
rovnice na gridu (viz evidenční
Mathematica)

Pro tuh matice máme

$$\overline{D} = \begin{pmatrix} \frac{1}{2} & 0 \\ \vdots & \vdots \\ 0 & \frac{1}{2} \end{pmatrix} \quad \text{a } R_{\text{Jac}} = \begin{pmatrix} 0 & \frac{1}{2} & & 0 \\ \frac{1}{2} & 0 & \frac{1}{2} & \\ & \frac{1}{2} & \ddots & \vdots \\ 0 & \vdots & \frac{1}{2} & 0 \end{pmatrix}$$

Pro tuh matice lze ukázat, že $\varrho(R_{\text{Jac}}) = \cos \frac{\pi}{n+1} \approx 1 - \frac{\pi^2}{2(n+1)^2}$

atedy pro $n \rightarrow \infty$ je $\varrho(R_{\text{Jac}}) \rightarrow 1$ a konverguje stále paralejně

např. pro $n=100$ je $\varrho(R_{\text{Jac}}) = 0,999516 \dots$

- Gaußova - Seidelova metoda

modifikace Jacobiho metody: při výpočtu x_j použije-e už „updatované“ hodnoty x_1, \dots, x_{j-1}

neboli

$$x_{m+1,j} = \frac{1}{a_{jj}} \left(b_j - \sum_{k=1}^{j-1} a_{jk} x_{m+1,k} - \sum_{k=j+1}^n a_{jk} x_{m,k} \right)$$

\uparrow nové hodnoty \uparrow staré hodnoty

Ize přepsat maticově

$$(D - \tilde{L}) x_{m+1} = \tilde{U} x_m + b$$

$$\text{a tedy } R_{GS} = (D - \tilde{L})^{-1} \tilde{U}, \quad c_{GS} = (D - \tilde{L})^{-1} b$$

na rozdíl od Jacobiho metody záleží na pořadí, v jakém počítame x_j

někdy vhodné preusporádání může zrychlit konvergenci

Př. opět uvažujme

$$A = \underbrace{\begin{pmatrix} 2 & -1 & 0 \\ -1 & 2 & -1 \\ 0 & -1 & 2 \end{pmatrix}}_n \Rightarrow R_{GS} = \underbrace{\begin{pmatrix} 2 & -1 & 0 \\ -1 & 2 & -1 \\ 0 & -1 & 2 \end{pmatrix}}_{\tilde{D}-\tilde{L}}^{-1} \underbrace{\begin{pmatrix} 0 & 1 & 0 \\ \vdots & \ddots & \vdots \\ 0 & \vdots & 1 \end{pmatrix}}_{\tilde{U}} = \underbrace{\begin{pmatrix} \frac{1}{2} & 0 & 0 \\ \frac{1}{4} & \ddots & \vdots \\ \frac{1}{2^n} & \cdots & \frac{1}{2} \end{pmatrix}}_{\tilde{D}-\tilde{L}^{-1}} \underbrace{\begin{pmatrix} 0 & 1 & 0 \\ \vdots & \ddots & \vdots \\ 0 & \vdots & 1 \end{pmatrix}}_{\tilde{U}} =$$

$$= \underbrace{\begin{pmatrix} 0 & \frac{1}{2} & 0 \\ \vdots & \frac{1}{4} & \vdots \\ 0 & \frac{1}{2^n} & \vdots \end{pmatrix}}_{\tilde{D}-\tilde{L}^{-1} \tilde{U}}$$

a pro $n=100$ máme
 $g(R_{GS}) = 0,999033$
sice $< g(R_{Jac})$, ale stále pouze'

- SOR(ω) = successive overrelaxation (superrelaxační metoda)

Modifikace G-S metody: místo $x_{m+1,j}$ z G-S metody použijeme

vážený průměr $(1-\omega)x_{m,j} + \omega x_{m+1,j}$

neboli

$$x_{m+1,j} = (1-\omega)x_{m,j} + \frac{\omega}{a_{jj}} \left(b_j - \sum_{k=1}^{j-1} a_{jk} x_{m+1,k} - \sum_{k=j+1}^n a_{jk} x_{m,k} \right)$$

a maticově

$$(D - \omega \tilde{L}) x_{m+1} = [(1-\omega)D + \omega \tilde{U}] x_m + \omega b$$

$$R_{SOR(\omega)} = (D - \omega \tilde{L})^{-1} [(1-\omega)D + \omega \tilde{U}]$$

$$c_{SOR(\omega)} = (D - \omega \tilde{L})^{-1} \omega b$$

pro $\omega > 1$ jde o tzv. superrelaxaci \leftarrow toto se používá
pro $\omega = 1$ (G-S metoda) o relaxaci a pro $\omega < 1$ o „under relaxation“

- pro metodu SOR(ω) lze ukázat (viz Demmel), že

1) obecně $\varrho(R_{SOR(\omega)}) \geq |\omega - 1|$ a tedy, aby metoda konvergovala, musí být $0 < \omega < 2$.

2) pokud je A symetrická, pozitivně definitní matici,
 $(y^T A x = x^T A y)$ $(x^T A x > 0 \text{ pro } x \neq 0)$
 pak $\varrho(R_{SOR(\omega)}) < 1$ pro lib. $0 < \omega < 2$
 a tedy SOR(ω) konverguje (tedy i G-S metoda ($\omega=1$))

3) optimální volba

$$\omega_{opt} = \frac{2}{1 + \sqrt{1 - \varrho(R_{Jac})^2}}$$

závisí na spektrálním
poloměru R_{Jac} !

a v tomto případě platí

$$\varrho(R_{SOR(\omega)}) = \left(\frac{\varrho(R_{Jac})}{1 + \sqrt{1 - \varrho(R_{Jac})^2}} \right)^2$$

Př. pro naš standardní problém

$$\text{je } \varrho(R_{Jac}) \approx 1 - \frac{\pi^2}{2(n+1)^2} \quad \text{a tedy } \omega_{opt} \approx \frac{2}{1 + \frac{\pi}{n+1}} \quad \begin{matrix} \text{pro } n \rightarrow \infty \\ w \rightarrow 2 \end{matrix}$$

$$\text{a } \varrho(R_{SOR(\omega)}) \approx 1 - \frac{2\pi}{n+1}$$

pro $n=100$ je $\varrho(R_{SOR(\omega)}) \approx 0,94$ ve srovnání s $\varrho(R_G) = 0,999$
 takže by měla superrelax. metoda konvergovat mnohem
 rychleji.

- obecně ale nemáme $\varrho(R_{Jac})$, takže musíme
 ω odhadovat a SOR(ω) buďžel funguje rychle jen
 pro hodnoty ω blízke ω_{opt}

odhad lze dělat např. na hrubším gridu (pokud matici A
 pochází z diskretizace určité diferenciální rovnice
 nebo z odhadu rychlosti konvergence Jacobiho metody)

Konvergence Jacobeho, G-S a SOR(ω) metody

• pro obecný problém (matici A) záleží na vlastnostech a struktuře A

Def: A je diagonálně dominantní ~~přesně~~, pokud $|a_{ii}| > \sum_{j \neq i} |a_{ij}|$ proti silné (řádkové)

Věta: Pokud je A silně diagonálně dominantní, pak Jacobeho i Gaussova-Seidelova metoda konvergují a matici $\|R_{GS}\|_\infty \leq \|R_{Jac}\|_\infty < 1$.

Pozn: nerovnost $\|R_{GS}\|_\infty \leq \|R_{Jac}\|$ nutně neznamená, že G-S ~~je rychlejší~~ konverguje rychleji než Jacobi, neboť Jacobeho metoda může mít občas „máhodou“ měsíců či desítek kroků.

Dk konvergence: stád' obecně, že

Pr: Ani 1D, ani 2D elipt. problem nedala A silně diagonálně dominantní, avšak jsou slabě diagonálně dominantní

Def: A je slabě diag. dominantní, pokud platí $|a_{ii}| \geq \sum_{j \neq i} |a_{ij}|$ a v alespoň jednom případě platí ostrá nerovnost.

• ovšem tato samo osobě nestrádá na důkaz konvergence Jac. a G-S. metody je zapotřebí ještě tzv. irreducibilita matice A .

Def: A je irreducibilní matici, pokud neexistuje permutační matici P taková, že

$$PAP^T = \begin{pmatrix} A_{11} & A_{12} \\ 0 & A_{22} \end{pmatrix}$$

• vidíme, že po aplikaci na vektor x

$$\begin{pmatrix} A_{11} & A_{12} \\ 0 & A_{22} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} A_{11}x_1 + A_{12}x_2 \\ A_{22}x_2 \end{pmatrix}$$

na pozicích
nejjsou hodnoty x_2 ovlivněny hodnotami x_1 ,
a matic vekt. $\begin{pmatrix} x_1 \\ 0 \end{pmatrix}$ tvoří „hv. podprostor“ při
aplikaci A

• irreducibilita souvisí s grafem matice

Def: Orientovaný graf matice A , značený $G(A)$, je graf s uzly $1, \dots, n$ a hranami $i \rightarrow j$, právě když $a_{ij} \neq 0$.

Pr: $A = \begin{pmatrix} 2 & -1 & 0 \\ -1 & 2 & 0 \\ 0 & 0 & -1 \end{pmatrix} \rightarrow G(A) = \begin{array}{c} \textcircled{1} \leftarrow \textcircled{2} \leftarrow \textcircled{3} \rightarrow \textcircled{4} \end{array}$ silně souvislý

Def: Orient. graf ~~se nazývá~~ silně souvislý, pokud existuje cesta \neq lib. \textcircled{i} do každého \textcircled{j} . Silně souvislá komponenta (část) orient. grafu je podgraf, který je silně souvislý a není možné ho rozšířit na větší silně souvislý podgraf.

Př. $\left(\begin{array}{c|c} A_{11} & A_{12} \\ \hline 0 & A_{22} \end{array} \right)$ průkaz v A_{11} nejsou dosažitelné, startuje se-li z A_{22} , ale $A_{22} \neq A_{11}$ — tím být silně souvisití komponenty.

Věta: A je irreducibilní, právě když $G(A)$ je silně souvisitý

Dk. \Rightarrow jasné z Př.

\Leftarrow pokud $G(A)$ není silně souvisitý, tže převratné řádky a sloupce tak, že silně souvisití komponenty bude na konci a dostane se $\left(\begin{array}{c|c} A & 0 \\ \hline 0 & A \end{array} \right)$

Věta: Pokud je A irreducibilní a slabě diagonálně dominantu, pak

obě Jacobiho a G-S metoda konvergují a něž $\rho(R_{GS}) < \rho(R_J) < 1$

Dk.: viz R.S. Varga: Matrix Iterative Analysis, Prentice-Hall 1962

Př. $AD = 2D$ — odelovací problém vedoucí na irreduc. matici a jsou slabě diag. dominantu \Rightarrow Jacobi i G-S jsou konvergentní.

- i přes tyto výsledky obecně neplatí, že Jacobi a G-S jsou konvergentní pro lib. A , však mohou být nesymetrické matice, pro něž Jacobi nefunguje, ale funguje G-S a naopak

- pokud jde o SOR(ω) metodu, tak platí

Věta: $\rho(R_{SOR(\omega)}) \geq |\omega - 1|$ a proto musí být $0 < \omega < 2$, aby výše metoda konvergentní

Dk.: $R_{SOR(\omega)} = (I - \omega L)^{-1} \cdot [(1-\omega)I + \omega U]$ vždy
 Nechť $\varphi(\lambda) = \det(\lambda I - R_{SOR(\omega)}) = \det \left[\underbrace{(I - \omega L)}_{\text{toto } -1 \text{ však je jednoznačné}} (\lambda I - R_{SOR(\omega)}) \right] =$
 $= \det[(\lambda + \omega - 1)I - \omega \lambda L - \omega U]$ je charakteristický polynom —
 a tedy $\varphi(\lambda) = \prod_{i=1}^n (\lambda - \lambda_i(R_{SOR(\omega)})) \Rightarrow |\varphi(0)| = \prod_{i=1}^n |\lambda_i(R_{SOR(\omega)})| = |\det((\omega - 1)I - \omega U)| =$
 $= |(\omega - 1)^n|$

a tedy $\rho(R_{SOR(\omega)}) = \max_{i=1 \dots n} |\lambda_i(R_{SOR(\omega)})| \geq |\omega - 1|$

Věta: Pokud je A symetrické pozitivně definitní matice, pak $\rho(R_{SOR(\omega)}) < 1$ pro $0 < \omega < 2$, a tedy SOR(ω) konverguje. Pro $\omega = 1$ máme G-S metodu, která tedy pro tuhle A též konverguje.

Def: A je pozitivně definitní symetrické matice, pokud $x^T A x > 0$ pro $\forall x \neq 0$. (pro reálný případ A je — hermitovská matice, pokud $x^H A x > 0$ pro $\forall x \neq 0$.)