

NM3 - Iterační metody pro spd soustavu

5.11.15
①

Soustava lin. rovnic se symetrickou poz. def. (spd) maticí

$$\boxed{A \cdot \bar{u} = \bar{b}}, \quad A \in \mathbb{R}^{n \times n}_{\text{spd}}, \quad \bar{b} \in \mathbb{R}^n$$

Řekneme, že A je řídce řídce řídce, pokud v každém řádku / sloupci počet nenulových prvků je $O(1)$, ~~ne~~ nezávisle na n .


Maticice A a M z 1d, 2d, 3d MKP jsou řídce!

1d stupně volnosti




A, M jsou tridiagonální


2d



$A, M =$



3d



$A, M =$



Gaussova eliminace MKP-matic $\sim \sqrt[3]{m^2}$

1d : $O(n \cdot 1)$ operací / paměti

2d : $O(n \cdot (\sqrt{n})^2) = O(n^2)$ operací / paměti $\rightarrow n < 10^6$ na PC

3d : $O(n \cdot (\sqrt[3]{n^2})^2) = O(n^{7/3})$ operací / paměti $\rightarrow n < 10^5$ na PC

řádce

Násobení MKP-matic \times vektor : $O(n)$ operací / paměti

Iterační metody by měly mít více než $O(n)$ resp. $O(n^{4/3})$ ~~operací / paměti~~

Optimální iterativní metody

Multigrad : $k=O(1/|\log \epsilon|)$ iterací

DDM : $k=O\left(\left(1+\log \frac{m}{N}\right)^2 \cdot |\log \epsilon|\right)$ iterací

kde $\epsilon = \frac{\|r^k\|}{\|r^0\|}$, $r^k := b - A\bar{u}^k$, je rel. přesnost výsledku \bar{u}^k a N je počet paralelních procesů.

Spektrum spd matic

$$A \cdot \bar{v}_i = \lambda_i \bar{v}_i, \quad \|\bar{v}_i\| = 1$$

pročes

$$0 < \lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_n \quad \dots \text{ vlastní čísla } A$$

$$\updownarrow$$

$$\updownarrow$$

$$\updownarrow$$

$\bar{v}_1, \bar{v}_2, \dots, \bar{v}_n$... vlastní vektory tvoří ortonormální bázi \mathbb{R}^n

$$A = \underbrace{\begin{bmatrix} \bar{v}_1 & \dots & \bar{v}_n \end{bmatrix}}_{=: V} \cdot \underbrace{\begin{bmatrix} \lambda_1 & & 0 \\ & \lambda_2 & \\ 0 & & \lambda_n \end{bmatrix}}_{=: D} \cdot V^T \quad \dots \text{ spektrální rozklad}$$

Richardsonova (Picardova) metoda

$\omega > 0$

$$\bar{u}^{k+1} := \bar{u}^k + \omega r^k$$


iterativní polynom

Chyba $e^{k+1} := \bar{u} - \bar{u}^{k+1} \stackrel{\downarrow}{=} (\bar{u} - \bar{u}^k) - \omega (\bar{b} - A\bar{u}^k) = (I - \omega A) e^k$

\parallel \parallel \parallel \parallel \parallel
 $\sum_{i=1}^n \alpha_i^{k+1} \bar{v}_i$ $\sum_{i=1}^n \alpha_i^k \bar{v}_i$
 \parallel \parallel \parallel \parallel \parallel
 $\sum_i \alpha_i^{k+1} \bar{v}_i$ $\sum_i (1 - \omega \lambda_i) \alpha_i^k \bar{v}_i$

$$\sum_i \alpha_i^{k+1} \bar{v}_i = \sum_i (1 - \omega \lambda_i) \alpha_i^k \bar{v}_i$$

i -tá složka chyby se redukuje faktorem $|1 - \omega \lambda_i|$



NM3 - Iterační metody pro SPD soustavu S.11.115

(3)

Richardsonova metoda (pohyb.)

Konvergence je zaručena pro $\omega \in (0, \frac{2}{\lambda_m})$

Optimální konvergence: $\omega_{opt} \lambda_m - 1 = 1 - \omega_{opt} \lambda_1$

$$\omega_{opt} = \frac{2}{\lambda_1 + \lambda_m}$$

$$\omega_{opt} = \arg \min_{\omega} \max_j |1 - \omega \lambda_j|$$

$$\text{konvergenční faktor } \rho_{opt} = \omega_{opt} \lambda_m - 1 = \frac{\kappa(A) - 1}{\kappa(A) + 1}$$

kde $\kappa(A) = \frac{\lambda_m}{\lambda_1}$ je číslo podmíněnosti matice A

Dosažená relativní přesnost ε lze zjistit

po k -iteracích:

$$\frac{\|\bar{e}^k\|}{\|\bar{e}^0\|} \leq (\rho_{opt})^k \leq \varepsilon, \quad 0 < \rho < 1, \quad 0 < \varepsilon < 1$$

$$k \geq \frac{\log \varepsilon}{\log \rho}$$

Pozn. Jelikož $\kappa(M)$ nerůstá na n (na h), Richardsonova metoda je optimální pro soustavu $M \cdot \bar{u} = \bar{b}$, ne však pro soustavu $A \cdot \bar{u} = \bar{b}$, neboť $\kappa(A) = O(h^{-2})$.

Čebyševova semi-iterační metoda

$$\omega^k > 0 \quad \left[\bar{u}^{k+1} := \bar{u}^k + \omega^k r^k \right], \quad i = 1, \dots, k \leq n$$

$$\text{Cyba: } \bar{e}^k = (I - \omega^k A)(I - \omega^{k-1} A) \dots (I - \omega^1 A) \bar{e}^0$$

j -té složky cyby se redukuje faktorem $|\prod_{i=1}^k (1 - \omega^i \lambda_j)|$

Hledáme $\omega_{opt}^1, \dots, \omega_{opt}^k$ tak, že

$$\bar{\omega}_{opt} = \arg \min_{\bar{\omega}} \max_{\delta} \left| \prod_{i=1}^k (1 - \omega^i \lambda_j) \right|$$

polynom $P_k(\lambda)$:
 $P_k(0) = 1$

$$\leq \max_{\lambda \in \langle \lambda_1, \lambda_n \rangle} \left| \prod_{i=1}^k (1 - \omega^i \lambda) \right|$$

(jednosměrně)

Řešením min-max úlohy na intervalu je

Chebyshevův polynom

$$\frac{\chi_k(\lambda)}{\chi_k(0)}, \text{ kde } \chi_k(\lambda) := \begin{cases} \cos \left(k \cdot \arccos \left(\frac{2\lambda - \lambda_n - \lambda_1}{\lambda_n - \lambda_1} \right) \right), & |t| \leq 1 \\ \cosh(k \cdot \operatorname{arccosh} t), & |t| \geq 1 \\ (-1)^k \cosh(k \cdot \operatorname{arccosh}(-t)), & t \leq -1 \end{cases}$$

Veliký $\bar{\omega}_{opt}$ jsou všechny převrácenými hodnotami

kořeni $\chi_k(\lambda)$:

$$\omega_{opt}^i = \left(\frac{\lambda_n - \lambda_1}{2} \cdot x^i + \frac{\lambda_1 + \lambda_n}{2} \right)^{-1}$$

λ_1, λ_n lze nahradit odklady $\lambda \leq \lambda_1, \lambda \geq \lambda_n$ kde $x_i = \cos \frac{\pi(k-i)}{n}$

Nevýhoda

Předem musíme určit počet iterací, proto „semi-iter.“

Konvergenční faktor lze odhadnout takto:

$$\left(\rho_{opt} \right)^k \leq \max_{\lambda \in \langle \lambda_1, \lambda_n \rangle} \left| \frac{\chi_k(\lambda)}{\chi_k(0)} \right| \leq \frac{1}{\left| \cosh \left(k \cdot \operatorname{arccosh} \left(- \frac{\lambda_1 + \lambda_n}{\lambda_n - \lambda_1} \right) \right) \right|}$$

$$= \frac{2}{e^{k \operatorname{arccosh}(t)} + e^{-k \operatorname{arccosh}(t)}} \leq 2 \cdot e^{-k \operatorname{arccosh}(t)}$$

$-\frac{k+1}{k-1} = t: |t| > 1$

$$= 2 \cdot e^{-k \ln(t + \sqrt{t^2 - 1})} = 2 \cdot \left(\frac{1}{t + \sqrt{t^2 - 1}} \right)^k = 2 \cdot \left(\frac{\sqrt{k(A) - 1}}{\sqrt{k(A) + 1}} \right)^k$$

To je nejlepší známá (asymptotická) konvergence iterativních metod.

Metoda největšího spádku

$$A\bar{u} = \bar{b}, \quad A \text{ spd} \iff \bar{u} = \arg \min_{\bar{v}} \varphi(\bar{v}),$$



$$\text{kde } \varphi(\bar{v}) := \frac{1}{2} \bar{v} \cdot A \cdot \bar{v} - \bar{b} \cdot \bar{v}$$

$$\nabla \varphi(\bar{u}^k) = A\bar{u}^k - \bar{b} = -\bar{r}^k$$

\bar{r}^k je směr největšího spádku $\varphi(\bar{u}^k)$

$$\boxed{\bar{u}^{k+1} := \bar{u}^k + \omega^k \bar{r}^k}$$

$$\text{kde } \omega^k := \arg \min_{\omega} \varphi(\bar{u}^k + \omega \bar{r}^k) = \frac{\bar{r}^k \cdot \bar{r}^k}{\bar{r}^k \cdot A \cdot \bar{r}^k}$$

Konvergence může být pomalá, zvolíme lepší směr \bar{r}^k .

Metoda sdružených gradientů (CG)


Krylovovský prostor $K^k(A, \bar{r}^0) := \langle \bar{r}^0, A\bar{r}^0, \dots, A^{k-1}\bar{r}^0 \rangle$

$$\boxed{\bar{u}^{k+1} := \arg \min_{\bar{z} \in \bar{u}^0 + K^k(A, \bar{r}^0)} \|\bar{u} - \bar{z}\|_A = \arg \min_{\bar{z} \in \bar{u}^0 + K^k(A, \bar{r}^0)} \varphi(\bar{z})}$$

Pozorování!

$$\bullet \bar{r}^{k+1} = -\nabla \varphi(\bar{u}^{k+1}) \perp_A K^k(A, \bar{r}^0)$$

Důkaz



$$\bullet \text{Důsledek: } \bar{r}^{k+1} \perp_A K^{k-1}(A, \bar{r}^0)$$

\bullet Důsledek: Je-li $(\bar{p}_0, \dots, \bar{p}_k)$ A-ortogonální báze $K^k(A, \bar{r}^0)$,

$$\text{pak } \bar{p}^{k+1} := \bar{r}^{k+1} + \beta^k \bar{p}^k \perp_A K^{k-1}(A, \bar{r}^0).$$

Stačí tedy A-ortogonalizovat $\bar{r}^{k+1} \perp_A \bar{p}^k \rightsquigarrow \beta^k = -\frac{\bar{r}^{k+1} \cdot A \bar{p}^k}{\bar{p}^k \cdot A \bar{p}^k}$

$$\beta^k = -\frac{\bar{r}^{k+1} \cdot A \bar{p}^k}{\bar{p}^k \cdot A \bar{p}^k}$$

Konvergence: $\|\bar{e}^k\|_A = \min_{P_k(A) \bar{e}^0} \|\bar{e}^0\|_A \leq 2 \cdot \left(\frac{\sqrt{\kappa(A)} - 1}{\sqrt{\kappa(A)} + 1} \right)^k \|\bar{e}^0\|_A$

Předpoklady

(6)

je nenáročná ekvivalentní úprava tak, aby výsledná soustava maticově soustředěná měla ~~společnou~~ ~~blízkost~~ k $\{1\}$ menší $K(A)$.

Mějme spd matici $B =: \hat{A}^{-1} \approx A^{-1}$, ~~společně~~ rozkl. $B = V_B D_B V_B^T$

Následně

$$A \cdot \bar{u} = \bar{b} \quad \text{řešíme}$$

$$\begin{matrix} \parallel \\ B^{1/2} \bar{v} \end{matrix}$$

$$\boxed{B^{1/2} A B^{1/2} \bar{v} = B^{1/2} \bar{b}}$$

spd

kde $B^{1/2} = V_B \sqrt{D_B} V_B^T$

nebo

$$B \cdot A \bar{u} = B \bar{b}$$

Lemma. $\sigma(BA) = \sigma(B^{1/2} A B^{1/2})$

Důkaz. ~~$BA \bar{v} = \lambda \bar{v}$~~ $BA \bar{u} = \lambda \bar{u} \Leftrightarrow \underbrace{B^{1/2} B^{1/2}}_B A \bar{v} = \lambda \underbrace{B^{1/2} \bar{v}}_{\bar{v}}$

$$\Downarrow$$

$$B^{1/2} A B^{1/2} \bar{v} = \lambda \bar{v} \quad \square$$

Lemma. $\exists \lambda, \Delta > 0 \quad \forall \bar{w} \in \mathbb{R}^m: \boxed{\lambda \bar{w} \hat{A} \bar{w} \leq \bar{w} A \bar{w} \leq \Delta \bar{w} \hat{A} \bar{w}}$

$$\sigma(BA) \subset \langle \lambda, \Delta \rangle$$

Idea důkazu.

$$\forall i: A \bar{u}_i = \lambda_i \hat{A} \bar{u}_i$$

$$\Downarrow \checkmark \quad \bar{w} = \sum_{i=1}^m w_i \bar{u}_i$$

$$\forall \bar{w}: A \cdot \sum_i w_i \bar{u}_i = \hat{A} \sum_i \lambda_i w_i \bar{u}_i$$

$$\Downarrow \checkmark \quad \Uparrow \text{ovšem}$$

$$\forall \bar{w}: \lambda_1 \bar{w} \hat{A} \bar{w} \leq \bar{w} A \bar{w} \leq \lambda_n \bar{w} \hat{A} \bar{w}$$

Celý

Důkaz. $\| \cdot \|_{(B^{-1})} = \bar{u} B^{-1} \bar{v}$

$$\lambda \leq \lambda_{\min}(BA) = \min_{\bar{w}} \frac{(BA \bar{w}, \bar{w})_B}{(\bar{w}, \bar{w})_{B^{-1}}}$$

$$\leq \frac{(A \bar{w}, \bar{w})}{(\hat{A} \bar{w}, \bar{w})}$$

$$\Lambda \geq \lambda_{\max}(BA) = \max_{\bar{w}} \frac{(BA \bar{w}, \bar{w})_B}{(\bar{w}, \bar{w})_{B^{-1}}} \geq \frac{(A \bar{w}, \bar{w})}{(\hat{A} \bar{w}, \bar{w})} \quad \square$$

V implementaci stačí umět aplikovat B , $B^{1/2}$ nepoděbujeme.

Např. v Richardsonově metodě:

$$\bar{u}^{k+1} = B^{1/2} \left[\bar{v}^k + \omega (B^{1/2} \bar{b} - \underbrace{B^{1/2} A B^{1/2} \bar{v}^k}_{= \bar{u}^k}) \right] = \underbrace{B^{1/2}}_{\bar{u}^k} \bar{v}^k + \omega \underbrace{B^{1/2} (\bar{b} - A \bar{u}^k)}_{\bar{r}^k}$$

$$\bar{u}^{k+1} = \bar{u}^k + \omega B \bar{r}^k$$

Podobně v PCG.