

MATEMATIKA 3

Dana Černá

<http://kmd.fp.tul.cz>

Katedra matematiky a didaktiky matematiky

Technická univerzita v Liberci

ITERAČNÍ METODY:

Maticové iterační metody:

- Jacobiho
- Gaussova-Seidelova
- Superrelaxační metoda

Gradientní iterační metody:

- Metoda sdružených gradientů

MATICOVÉ ITERAČNÍ METODY: ODVOZENÍ: Soustavu

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

upravíme do tvaru

$$\mathbf{x} = \mathbf{Bx} + \mathbf{c}$$

a definujeme posloupnost vektorů

$$\mathbf{x}^{i+1} = \mathbf{Bx}^i + \mathbf{c},$$

kde \mathbf{x}^0 je zvolený počáteční vektor.

Konstruujeme posloupnost vektorů danou předpisem:

$$\mathbf{x}^{i+1} = \mathbf{B}\mathbf{x}^i + \mathbf{c}, \quad i = 0, 1, \dots,$$

kde \mathbf{x}^0 je zvolený počáteční vektor. Matice \mathbf{B} a vektor \mathbf{c} jsou zvoleny tak, že pro přesné řešení \mathbf{x}^* původní soustavy platí $\mathbf{x}^* = \mathbf{B}\mathbf{x}^* + \mathbf{c}$.

VĚTA: Nutná a postačující podmínka konvergence

Posloupnost \mathbf{x}^i konverguje k přesnému řešení soustavy $\mathbf{Ax} = \mathbf{b}$ právě tehdy, když $\rho(\mathbf{B}) < 1$.

VĚTA: Postačující podmínka konvergence

Posloupnost \mathbf{x}^i konverguje k přesnému řešení soustavy $\mathbf{Ax} = \mathbf{b}$, pokud pro některou maticovou normu $\| \cdot \|$ platí $\|\mathbf{B}\| < 1$.

1. JACOBIHO METODA

Rozložme matici \mathbf{A} :

$$\mathbf{A} = \mathbf{D} + \mathbf{L} + \mathbf{U},$$

kde \mathbf{D} je diagonální matice, \mathbf{L} je dolní trojúhelníková matice s nulami na diagonále a \mathbf{U} je horní trojúhelníková matice s nulami na diagonále. Platí

$$\begin{aligned}\mathbf{Ax} = \mathbf{b} &\Leftrightarrow \mathbf{Dx} + (\mathbf{L} + \mathbf{U})\mathbf{x} = \mathbf{b} \Leftrightarrow \mathbf{Dx} = -(\mathbf{L} + \mathbf{U})\mathbf{x} + \mathbf{b} \\ &\Leftrightarrow \mathbf{x} = -\mathbf{D}^{-1}(\mathbf{L} + \mathbf{U})\mathbf{x} + \mathbf{D}^{-1}\mathbf{b}.\end{aligned}$$

Předpis Jacobiho metody:

$$\mathbf{x}^{i+1} = -\mathbf{D}^{-1}(\mathbf{L} + \mathbf{U})\mathbf{x}^i + \mathbf{D}^{-1}\mathbf{b}, \quad i = 0, 1, \dots,$$

Předpis Jacobiho metody rozepsaný po složkách:

$$x_j^{i+1} = \frac{1}{a_{jj}} \left(b_j - \sum_{k=1}^{j-1} a_{jk} x_k^i - \sum_{k=j+1}^n a_{jk} x_k^i \right)$$

$$\begin{pmatrix} 1 & 1 & 2 & 3 \\ 1 & 4 & 2 & 1 \\ 2 & 2 & 5 & 2 \\ 7 & 5 & -3 & 1 \end{pmatrix} = \underbrace{\begin{pmatrix} 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 2 & 2 & 0 & 0 \\ 7 & 5 & -3 & 0 \end{pmatrix}}_{\mathbf{L}} + \underbrace{\begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 4 & 0 & 0 \\ 0 & 0 & 5 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix}}_{\mathbf{D}} + \underbrace{\begin{pmatrix} 0 & 1 & 2 & 3 \\ 0 & 0 & 2 & 1 \\ 0 & 0 & 0 & 2 \\ 0 & 0 & 0 & 0 \end{pmatrix}}_{\mathbf{U}}$$

V tomto případě je tedy iterační matice dána vztahem
 $\mathbf{B} = -\mathbf{D}^{-1}(\mathbf{L} + \mathbf{U})$ a posloupnost \mathbf{x}^i konverguje k přesnému řešení právě tehdy, když $\rho(-\mathbf{D}^{-1}(\mathbf{L} + \mathbf{U})) < 1$.

Tuto podmínu splňují například ostře diagonálně dominantní matice, tj. matice pro kterou platí

$$|a_{ii}| > \sum_{j=1}^{i-1} |a_{ij}| + \sum_{j=i+1}^n |a_{ij}|, \quad i = 1, \dots, n.$$

2. GAUSSSOVA-SEIDELOVA METODA

Nyní při výpočtu složek vektoru \mathbf{x}^{i+1} použijeme místo složek vektoru \mathbf{x}^i složky vektoru \mathbf{x}^{i+1} , pokud již byly vypočteny.

$$\begin{aligned}\mathbf{Ax} = \mathbf{b} &\Leftrightarrow (\mathbf{D} + \mathbf{L})\mathbf{x} + \mathbf{Ux} = \mathbf{b} \Leftrightarrow (\mathbf{D} + \mathbf{L})\mathbf{x} = -\mathbf{Ux} + \mathbf{b} \\ &\Leftrightarrow \mathbf{x} = -(\mathbf{D} + \mathbf{L})^{-1}\mathbf{Ux} + (\mathbf{D} + \mathbf{L})^{-1}\mathbf{b}.\end{aligned}$$

Předpis Gaussovy-Seidelovy metody:

$$\mathbf{x}^{i+1} = -(\mathbf{D} + \mathbf{L})^{-1}\mathbf{Ux}^i + (\mathbf{D} + \mathbf{L})^{-1}\mathbf{b}, \quad i = 0, 1, \dots,$$

Předpis Gaussovy-Seidelovy metody rozepsaný po složkách:

$$x_j^{i+1} = \frac{1}{a_{jj}} \left(b_j - \sum_{k=1}^{j-1} a_{jk} x_k^{i+1} - \sum_{k=j+1}^n a_{jk} x_k^i \right)$$

V tomto případě tedy posloupnost \mathbf{x}^i konverguje k přesnému řešení právě tehdy, když $\rho \left(-(\mathbf{D} + \mathbf{L})^{-1} \mathbf{U} \right) < 1$. Tuto podmínu splňují ostře diagonálně dominantní matice a také symetrické pozitivně definitní matice.

3. SUPERRELAXAČNÍ METODA (SOR METODA)

Pro zrychlení konvergence je možné použít modifikaci Gaussovy-Seidelovy metody, při které konstruujeme posloupnost vektorů podle vzorce

$$x_j^{i+1} = (1 - \omega) x_j^i + \omega \tilde{x}_j^{i+1},$$

kde \tilde{x}_j^{i+1} vypočteme pomocí jedné G.-S. iterace, tj.

$$\tilde{x}_j^{i+1} = \frac{1}{a_{jj}} \left(b_j - \sum_{k=1}^{j-1} a_{jk} x_k^{i+1} - \sum_{k=j+1}^n a_{jk} x_k^i \right).$$

V maticovém zápisu dostaneme

$$\begin{aligned} \mathbf{Ax} = \mathbf{b} &\Leftrightarrow \omega \mathbf{Ax} = \omega \mathbf{b} \Leftrightarrow ((\omega - 1) \mathbf{D} + \mathbf{D} + \omega \mathbf{L} + \omega \mathbf{U}) \mathbf{x} = \omega \mathbf{b} \Leftrightarrow \\ &(\mathbf{D} + \omega \mathbf{L}) \mathbf{x} = \omega \mathbf{b} - (\omega \mathbf{U} + (\omega - 1) \mathbf{D}) \mathbf{x}, \\ \text{tedy } &(\mathbf{D} + \omega \mathbf{L}) \mathbf{x}^{i+1} = \omega \mathbf{b} - (\omega \mathbf{U} + (\omega - 1) \mathbf{D}) \mathbf{x}^i. \end{aligned}$$

Parametr ω se nazývá relaxační faktor a volí se z intervalu $(0, 2)$, obvykle $\omega \in (1, 2)$. Pro symetrické pozitivně definitní matice soustavy tato volba parametru vede ke konvergenci posloupnosti \mathbf{x}^i k řešení. Volbou $\omega = 1$ dostaneme Gaussovou-Seidelovu metodu.

4. METODA SDRUŽENÝCH GRADIENTŮ

Budeme předpokládat, že matice soustavy \mathbf{A} je symetrická pozitivně definitní. Potom řešení soustavy $\mathbf{Ax} = \mathbf{b}$ je jediným bodem, ve kterém má funkce

$$F(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T \mathbf{Ax} - \mathbf{x}^T \mathbf{b}$$

minimum.

Posloupnost vektorů \mathbf{x}^i budeme konstruovat tak, že v i-tém kroku zvolíme směr \mathbf{v}^i a určíme číslo α_i tak, aby vektor

$$\mathbf{x}^{i+1} = \mathbf{x}^i + \alpha_i \mathbf{v}^i$$

byl bodem minima funkce F na přímce $\mathbf{x}^i + t\mathbf{v}^i$, $t \in \mathbb{R}$.

Volbou \mathbf{v}^i dostaneme konkrétní metodu. V případě metody sdružených gradientů volíme **A-ortogonální vektory**. To jsou vektory, pro které platí:

$$(\mathbf{v}^j)^T \mathbf{A} \mathbf{v}^i = 0, \quad i \neq j, \quad \text{a} \quad (\mathbf{v}^i)^T \mathbf{A} \mathbf{v}^i \neq 0.$$

Vektory konstruujeme postupně pomocí reziduí $\mathbf{r}^i = \mathbf{b} - \mathbf{A}\mathbf{x}^i$:

$$\mathbf{v}^{i+1} = \mathbf{r}^{i+1} + \beta_i \mathbf{v}^i,$$

kde konstanta β_i je zvolena tak, aby byla splněna **A-ortogonalita** vektorů \mathbf{v}^{i+1} a \mathbf{v}^i .

Další iterační metody: MINRES, GMRES, BiCG a jejich modifikace

Algoritmus metody sdružených gradientů:

Je dáno: \mathbf{x}^0 , \mathbf{A} symetrická pozitivně definitní, \mathbf{b} .

$$\mathbf{r}^0 = \mathbf{b} - \mathbf{Ax}^0, \mathbf{v}^0 = \mathbf{r}^0, i = 0$$

while $\|\mathbf{r}^i\|_2 > \epsilon$ and $i < maximum_iteraci$

$$\alpha_i = \frac{(\mathbf{r}^i)^T \mathbf{v}^i}{(\mathbf{v}^i)^T \mathbf{Av}^i}$$

$$\mathbf{x}^{i+1} = \mathbf{x}^i + \alpha_i \mathbf{v}^i$$

$$\mathbf{r}^{i+1} = \mathbf{r}^i - \alpha_i \mathbf{Av}^i$$

$$\beta_i = \frac{(\mathbf{r}^{i+1})^T \mathbf{r}^{i+1}}{(\mathbf{r}^i)^T \mathbf{r}^i}$$

$$\mathbf{v}^{i+1} = \mathbf{r}^{i+1} + \beta_i \mathbf{v}^i$$

$$i = i + 1$$

end

Rychlosť konvergencie metody sdružených gradientov je charakterizovaná odhadom

$$\|\mathbf{x}^k - \mathbf{x}^*\|_A \leq 2 \left(\frac{\sqrt{\kappa_2(\mathbf{A})} - 1}{\sqrt{\kappa_2(\mathbf{A})} + 1} \right)^k \|\mathbf{x}^0 - \mathbf{x}^*\|_A,$$

kde $\|\cdot\|_A$ je energetická norma

$$\|\mathbf{x}\|_A = \sqrt{\mathbf{x}^T \mathbf{A} \mathbf{x}}$$

a κ_2 označuje číslo podmíněnosti vzhledem k $\|\cdot\|_2$ normě

$$\kappa_2(\mathbf{A}) = \|\mathbf{A}\|_2 \|\mathbf{A}^{-1}\|_2.$$

Rychlosť konvergencie metody sdružených gradientov teda závisí na čísle podmínenosťi matice soustavy. Konvergenci môžeme urychliť pomocí [predpodmínení](#). Místo úlohy $\mathbf{Ax} = \mathbf{b}$ budeme řešiť úlohu

$$\mathbf{P}^{-1}\mathbf{AP}^{-T}\mathbf{P}^T\mathbf{x} = \mathbf{P}^{-1}\mathbf{b},$$

tedy

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

kde

$$\tilde{\mathbf{A}} = \mathbf{P}^{-1}\mathbf{AP}^{-T}, \quad \tilde{\mathbf{x}} = \mathbf{P}^T\mathbf{x}, \quad \tilde{\mathbf{b}} = \mathbf{P}^{-1}\mathbf{b}.$$

Matrice \mathbf{P} se nazývá předpodmiňovač a volíme ji tak, aby byla regulární a aby číslo podmíněnosti matice $\mathbf{P}^{-1}\mathbf{A}\mathbf{P}^{-T}$ bylo menší než číslo podmíněnosti matice \mathbf{A} .

Mezi nejjednodušší volbu patří

$$\mathbf{P} = \begin{pmatrix} \sqrt{a_{11}} & 0 & \dots & 0 \\ 0 & \sqrt{a_{22}} & 0 & \\ \vdots & & \ddots & \\ 0 & \dots & 0 & \sqrt{a_{nn}} \end{pmatrix}.$$