

Pokročilé numerické metody I

Systemy lineárních rovnic

Jiří Zelinka

Systém

$$Ax = b$$

převédeme na

$$x = Tx + g$$

\hat{x} – řešení

$\hat{x} = (E - T)^{-1}g$ za předpokladu, že $E - T$ je regulární.

$x^0 \in \mathbb{R}^n$ – libovolná počáteční aproximace. Posloupnost $\{x^k\}_{k=0}^{\infty}$ určená rekurentně vztahem

$$x^{k+1} = Tx^k + g, \quad k = 0, 1, \dots$$

se nazývá **iterační posloupnost** a matice T se nazývá **iterační matice**.

Problémy:

- 1 Jak zvolit iterační matici T , tj. jakým způsobem převést systém $Ax = b$ na systém $x = Tx + g$?
- 2 Za jakých předpokladů posloupnost $\{x^k\}_{k=0}^{\infty}$ konverguje pro libovolnou počáteční aproximaci k přesnému řešení \hat{x} ?

$$x^1 = Tx^0 + g,$$

$$x^2 = Tx^1 + g = T(Tx^0 + g) + g = T^2x^0 + (T + E)g,$$

$$x^3 = Tx^2 + g = T^3x^0 + (T^2 + T + E)g,$$

\vdots

$$x^{k+1} = T^{k+1}x^0 + (T^k + T^{k-1} + \dots + E)g.$$

Definice

Řekneme, že matice H je **konvergentní**, jestliže

$$\lim_{k \rightarrow \infty} H^k = O,$$

kde O je nulová matice, konvergence je bodová.

Věta 1

Následující tvrzení jsou ekvivalentní:

- 1 H je konvergentní matice.
- 2 $\lim_{k \rightarrow \infty} \|H^k\| = 0$ pro nějakou přidruženou maticovou normu.
- 3 $\rho(H) < 1$ ($\rho(H)$ je spektrální poloměr H).
- 4 $\lim_{k \rightarrow \infty} H^k \mathbf{x} = \mathbf{o}$ pro libovolný vektor $\mathbf{x} \in \mathbb{R}^n$.

Lemma

Nechť $\rho(T) < 1$. Pak $E - T$ je regulární a platí

$$(E - T)^{-1} = E + T + T^2 + \dots$$

Věta 2 (Hlavní věta o konvergenci iteračního procesu)

Posloupnost $\{\mathbf{x}^k\}_{k=0}^{\infty}$ určená iteračním procesem $\mathbf{x} = T\mathbf{x} + \mathbf{g}$ konverguje pro každou počáteční aproximaci $\mathbf{x}^0 \in \mathbb{R}^n$ právě tehdy, když $\rho(T) < 1$, přičemž

$$\lim_{k \rightarrow \infty} \mathbf{x}^k = \hat{\mathbf{x}}, \quad \hat{\mathbf{x}} = T\mathbf{x}^* + \mathbf{g}$$

Důsledek

Nechť pro nějakou přidruženou maticovou normu platí $\|T\| < 1$. Pak posloupnost $\{\mathbf{x}^k\}_{k=0}^{\infty}$ generovaná iteračním procesem $\mathbf{x} = T\mathbf{x} + \mathbf{g}$ konverguje k řešení $\hat{\mathbf{x}} = (E - T)^{-1}\mathbf{g}$ pro každou počáteční aproximaci $\mathbf{x}^0 \in \mathbb{R}^n$. Dále platí

$$\begin{aligned} \|\hat{\mathbf{x}} - \mathbf{x}^k\| &\leq \|T\|^k \|\hat{\mathbf{x}} - \mathbf{x}^0\|, \\ \|\hat{\mathbf{x}} - \mathbf{x}^k\| &\leq \frac{\|T\|^k}{1 - \|T\|} \|\mathbf{x}^1 - \mathbf{x}^0\|. \end{aligned}$$

Jacobiova iterační metoda

$$A\mathbf{x} = \mathbf{b}, \quad A = \begin{pmatrix} a_{11} & \cdots & \cdots & a_{1n} \\ a_{21} & & & a_{2n} \\ \vdots & & & \vdots \\ a_{n1} & \cdots & \cdots & a_{nn} \end{pmatrix}$$

Z první rovnice vypočteme x_1 :

$$a_{11}x_1 + a_{12}x_2 + \cdots + a_{1n}x_n = b_1 \Rightarrow x_1 = \frac{1}{a_{11}}(b_1 - a_{12}x_2 - \cdots - a_{1n}x_n)$$

$$x_1^{k+1} = \frac{1}{a_{11}}(b_1 - a_{12}x_2^k - \cdots - a_{1n}x_n^k),$$

z druhé rovnice vypočteme x_2 :

$$x_2^{k+1} = \frac{1}{a_{22}}(b_2 - a_{21}x_1^k - a_{23}x_3^k - \cdots - a_{2n}x_n^k),$$

Obecně z i -té rovnice vypočteme x_i :

$$x_i^{k+1} = - \sum_{\substack{j=1 \\ j \neq i}}^n \frac{a_{ij}}{a_{ii}} x_j^k + \frac{b_i}{a_{ii}},$$

až z n -té rovnice vypočteme x_n .

Na pravé straně jsou vždy všechny prvky Ax kromě diagonálního, kterým se rovnice vydělí.

Maticový zápis:

Matici A zapišme ve tvaru

$$A = D + L + U,$$

kde

$$D = \begin{pmatrix} a_{11} & & 0 \\ & \ddots & \\ 0 & & a_{nn} \end{pmatrix},$$

$$L = \begin{pmatrix} 0 & & & 0 \\ a_{21} & \ddots & & \\ \vdots & \ddots & \ddots & \\ a_{n1} & \cdots & a_{n,n-1} & 0 \end{pmatrix},$$

$$U = \begin{pmatrix} 0 & a_{12} & \cdots & a_{1n} \\ & \ddots & \ddots & \vdots \\ & & \ddots & a_{n-1,n} \\ 0 & & & 0 \end{pmatrix}.$$

D je diagonální matice, L je dolní trojúhelníková matice s nulami na diagonále a U je horní trojúhelníková matice s nulami na diagonále.

$$Ax = (D + L + U)x = b$$

$$Dx = -(L + U)x + b.$$

Pokud $a_{ii} \neq 0$, $i = 1, \dots, n$, je matice D regulární a z předchozí rovnice lze vypočítat

$$x = -D^{-1}(L + U)x + D^{-1}b.$$

$$D^{-1} = \begin{pmatrix} \frac{1}{a_{11}} & & 0 \\ & \ddots & \\ 0 & & \frac{1}{a_{nn}} \end{pmatrix},$$

Maticový tvar Jacobiovy iterační metody

Jacobiova iterační matice: $T_J = -D^{-1}(L + U)$

$$\mathbf{x}^{k+1} = T_J \mathbf{x}^k + D^{-1} \mathbf{b},$$

$T_J = (t_{ij})$, $t_{ij} = -\frac{a_{ij}}{a_{ii}}$ pro $i \neq j$, $t_{ii} = 0$ pro $i = 1, \dots, n$.

$$T_J = \begin{pmatrix} 0 & -\frac{a_{12}}{a_{11}} & \dots & -\frac{a_{1n}}{a_{11}} \\ -\frac{a_{21}}{a_{22}} & 0 & & -\frac{a_{2n}}{a_{22}} \\ \vdots & & \ddots & \vdots \\ -\frac{a_{n1}}{a_{nn}} & -\frac{a_{n2}}{a_{nn}} & \dots & 0 \end{pmatrix}, \quad D^{-1} \mathbf{b} = \begin{pmatrix} \frac{b_1}{a_{11}} \\ \frac{b_2}{a_{22}} \\ \vdots \\ \frac{b_n}{a_{nn}} \end{pmatrix}.$$

Věta 3 (O konvergenci Jacobiovy iterační metody)

Posloupnost $\{\mathbf{x}^k\}_{k=0}^{\infty}$ generovaná metodou $\mathbf{x}^{k+1} = T_J \mathbf{x}^k + D^{-1} \mathbf{b}$ konverguje pro každou počáteční aproximaci $\mathbf{x}^0 \in \mathbb{R}^n$ právě tehdy, když $\rho(T_J) < 1$.

Odhad chyby:

$$\|\hat{\mathbf{x}} - \mathbf{x}^k\|_{\infty} \leq \frac{\|T_J\|_{\infty}^k}{1 - \|T_J\|_{\infty}} \|\mathbf{x}^1 - \mathbf{x}^0\|_{\infty}.$$

Silné řádkové sumační kritérium:

Nechť matice A je ryze řádkově diagonálně dominantní, tj.

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

Pak Jacobiova iterační metoda konverguje pro každou počáteční aproximaci $\mathbf{x}^0 \in \mathbb{R}^n$.

Silné sloupcové sumační kritérium:

Nechť matice A je ryze sloupcově diagonálně dominantní, tj.

$$|a_{kk}| > \sum_{\substack{i=1 \\ i \neq k}}^n |a_{ik}|, \quad k = 1, \dots, n.$$

Pak Jacobiova iterační metoda konverguje pro každou počáteční aproximaci $\mathbf{x}^0 \in \mathbb{R}^n$.

Gaussova-Seidelova iterační metoda

Z první rovnice vypočteme x_1 :

$$a_{11}x_1 + a_{12}x_2 + \dots + a_{1n}x_n = b_1 \Rightarrow x_1 = \frac{1}{a_{11}}(b_1 - a_{12}x_2 - \dots - a_{1n}x_n)$$

$$x_1^{k+1} = \frac{1}{a_{11}}(b_1 - a_{12}x_2^k - \dots - a_{1n}x_n^k),$$

z druhé rovnice vypočteme x_2 , pro x_1 použijme novou iteraci:

$$x_2^{k+1} = \frac{1}{a_{22}}(b_2 - a_{21}x_1^{k+1} - a_{23}x_3^k - \dots - a_{2n}x_n^k),$$

ze třetí rovnice vypočteme x_3 , pro x_1 a x_2 použijme novou iteraci:

$$x_3^{k+1} = \frac{1}{a_{33}}(b_3 - a_{31}x_1^{k+1} - a_{32}x_2^{k+1} - a_{34}x_4^k - \dots - a_{3n}x_n^k),$$

Obecně

$$x_i^{k+1} = - \sum_{j=1}^{i-1} \frac{a_{ij}}{a_{ii}} x_j^{k+1} - \sum_{j=i+1}^n \frac{a_{ij}}{a_{ii}} x_j^k + \frac{b_i}{a_{ii}}, \quad i = 1, \dots, n.$$

Maticový zápis:

$$\begin{aligned} Ax = b &\Rightarrow (D + L + U)x = b \\ &\quad (D + L)x = -Ux + b. \end{aligned}$$

$a_{ii} \neq 0, i = 1, \dots, n,$ \Rightarrow matice $D + L$ je regulární a

$$x = -(D + L)^{-1}Ux + (D + L)^{-1}b.$$

Položme $T_G = -(D + L)^{-1}U$, Gaussova-Seidelova iterační metoda je tvaru

$$x^{k+1} = T_G x^k + g, \quad g = (D + L)^{-1}b.$$

Věta 4

Posloupnost $\{\mathbf{x}^k\}_{k=0}^{\infty}$ generovaná Gaussovou-Seidelovou iterační metodou $\mathbf{x}^{k+1} = -(D + L)^{-1}U\mathbf{x}^k + (D + L)^{-1}\mathbf{b}$ konverguje pro každou počáteční aproximaci $\mathbf{x}^0 \in \mathbb{R}^n$ právě tehdy, když $\rho(T_G) < 1$.

Silné řádkové sumační kritérium:

Nechť matice A je ryze řádkově diagonálně dominantní, tj.

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

Pak Gaussova-Seidelova iterační metoda konverguje pro každou počáteční aproximaci $\mathbf{x}^0 \in \mathbb{R}^n$.

Silné sloupcové sumační kritérium:

Nechť matice A je ryze sloupcově diagonálně dominantní, tj.

$$|a_{kk}| > \sum_{\substack{i=1 \\ i \neq k}}^n |a_{ik}|, \quad k = 1, \dots, n.$$

Pak Gaussova-Seidelova iterační metoda konverguje pro každou počáteční aproximaci $\mathbf{x}^0 \in \mathbb{R}^n$.

Věta 5

Nechť A je pozitivně definitní matice. Pak Gaussova-Seidelova metoda konverguje pro každou počáteční aproximaci.

Věta 6 (Stein-Rosenberg)

Nechť pro prvky matice A platí $a_{ij} \leq 0$ pro všechna $i \neq j$ a $a_{ii} > 0$, $i = 1, \dots, n$. Pak platí právě jedno z následujících tvrzení:

- $0 < \rho(T_G) < \rho(T_J) < 1$
- $1 < \rho(T_J) < \rho(T_G)$
- $\rho(T_J) = \rho(T_G) = 0$
- $\rho(T_J) = \rho(T_G) = 1$.

To znamená, že konvergují-li obě metody, Gaussova-Seidelova metoda konverguje rychleji.

Modifikace Gaussovy–Seidelovy metody, ω – relaxační parametr

$$x_i^{k+1} = (1 - \omega)x_i^k + \frac{\omega}{a_{ii}} \left[b_i - \sum_{j=1}^{i-1} a_{ij}x_j^{k+1} - \sum_{j=i+1}^n a_{ij}x_j^k \right].$$

Relaxační metodu lze maticově zapsat takto

$$\mathbf{x}^{k+1} = (D + \omega L)^{-1}[(1 - \omega)D - \omega U]\mathbf{x}^k + \omega(D + \omega L)^{-1}\mathbf{b}$$

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

Hodnoty parametru ω :

- Pro $0 < \omega < 1$ se iterační metody nazývají **metodami dolní relaxace**. Tyto metody jsou vhodné v případě, že Gaussova-Seidelova metoda nekonverguje.
- Pro $\omega = 1$ je relaxační metoda totožná s Gaussovou-Seidelovou metodou.
- Pro $1 < \omega$ se metody nazývají **metodami horní relaxace**, nebo častěji SOR metodami (SOR = Successive Over-Relaxation). Tyto metody lze užít ke zrychlení konvergence Gaussovy-Seidelovy metody.

Věta 7 (Kahan)

Necht' $a_{ii} \neq 0$, $i = 1, \dots, n$. Pak

$$\rho(T_\omega) \geq |\omega - 1|.$$

Důsledek: Má smysl uvažovat jen $\omega \in (0, 2)$.

Věta 8 (Ostrowski-Reich)

Pro pozitivně definitní matici A platí $\rho(T_\omega) < 1$ pro všechna $\omega \in (0, 2)$.

Třídiagonální matice:

$$A = (a_{ij})_{i,j=1}^n, \quad a_{ij} = 0, \text{ pro } |i - j| > 1$$

Věta 9

Nechť A je třídiagonální pozitivně definitní matice. Pak $\rho(T_G) = \rho^2(T_J) < 1$ a optimální hodnota relaxačního parametru je dána vztahem

$$\omega = \omega_{\text{opt}} = \frac{2}{1 + \sqrt{1 - \rho^2(T_J)}}.$$

Při této volbě je $\rho(T_\omega) = |1 - \omega|$.

Cykly v iteračních metodách

Například pro systémy

$$x_1 + kx_2 = b_1$$

$$x_1 - kx_2 = b_2$$

Jacobiova metoda: cyklus délky 4

Gaussova–Seidelova metoda: cyklus délky 2

Relaxační metody: cykly různých délek

$$x_1 + x_2 = 1$$

$$qx_1 + x_2 = 1.$$

Pro $\omega = 2$:

$$T_2 = \begin{pmatrix} -1 & -2 \\ 2q & 4q - 1 \end{pmatrix}, \quad \lambda_{1,2} = \cos \varphi \pm i \sin \varphi, \quad q = \frac{1}{2}(1 + \cos \varphi)$$

$\varphi = 2\pi l/p$, $0 < l < p/2 \Rightarrow$ existuje cyklus délky p .

Body cyklu leží na elipse se středem v hledaném řešení.

Věta 10

Jestliže A je pozitivně definitní matice, pak řešení systému $Ax = b$ je ekvivalentní minimalizaci kvadratické funkce

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

Tato kvadratická funkce má jediné minimum, kterého nabývá v řešení systému $Ax = b$, tj. pro $\hat{x} = A^{-1}b$.

Důsledek

$$\min Q(x) = Q(\hat{x}) = -\frac{1}{2}b^T A^{-1}b.$$

Geometrická interpretace

Nechť $\hat{\mathbf{x}}$ je řešení systému $A\mathbf{x} = \mathbf{b}$ a necht' $\mathbf{x} = \hat{\mathbf{x}} + \mathbf{s}$. Pak

$$Q(\mathbf{x}) + \frac{1}{2} \hat{\mathbf{x}}^T \mathbf{b} = \frac{1}{2} (\hat{\mathbf{x}} + \mathbf{s})^T A (\hat{\mathbf{x}} + \mathbf{s}) - (\hat{\mathbf{x}} + \mathbf{s})^T \mathbf{b} + \frac{1}{2} \hat{\mathbf{x}}^T \mathbf{b} = \frac{1}{2} \mathbf{s}^T A \mathbf{s}.$$

Plocha o rovnici

$$\frac{1}{2} \mathbf{s}^T A \mathbf{s} = \text{konst.}$$

je hyperelipsoid v proměnných s_1, \dots, s_n se středem v $\mathbf{s} = \mathbf{o}$, tj. v $\hat{\mathbf{x}}$, tedy i rovnice $Q(\mathbf{x}) = \text{konst.}$ představuje hyperelipsoid, směry jeho os jsou dány vlastními vektory matice A , délky poloos vlastními čísly.

Minimalizace funkce Q :

vybereme počáteční aproximaci \mathbf{x}_1 a pak určíme \mathbf{x}_2 tak, že zvolíme nějaký směr \mathbf{v}_1 a vzdálenost t_1 ve směru \mathbf{v}_1 . Obecně

$$\mathbf{x}_{k+1} = \mathbf{x}_k + t_k \mathbf{v}_k, \quad i = 1, 2, \dots$$

Vektory \mathbf{v}_k se nazývají *směrové vektory*.

Metoda maximálního spádu (steepest descent)

\mathbf{x}_1 je počáteční aproximace řešení $\hat{\mathbf{x}}$, položíme $\mathbf{r}_1 = \mathbf{b} - A\mathbf{x}_1$: reziduový vektor. Hledáme takový vektor \mathbf{v}_1 , $\|\mathbf{v}_1\| = \|\mathbf{b} - A\mathbf{x}_1\|$, pro který

$$\left. \frac{\delta}{\delta t} Q(\mathbf{x}_1 + t\mathbf{v}_1) \right|_{t=0} = \min.$$

Výsledek: $\mathbf{v}_1 = \mathbf{r}_1 = \mathbf{b} - A\mathbf{x}_1$.

Dále hledáme minimum Q ve směru $\mathbf{v}_1 = \mathbf{r}_1$ od bodu \mathbf{x}_1 , tedy minimum kvadratické funkce $Q(\mathbf{x}_1 + t\mathbf{r}_1)$ v bodě t_1 .

Výsledek: $t_1 = \frac{\mathbf{r}_1^T \mathbf{r}_1}{\mathbf{r}_1^T A \mathbf{r}_1}$, takže $\mathbf{x}_2 = \mathbf{x}_1 + \frac{\mathbf{r}_1^T \mathbf{r}_1}{\mathbf{r}_1^T A \mathbf{r}_1} \mathbf{r}_1$ a obecně

$$t_{k+1} = \frac{\mathbf{r}_k^T \mathbf{r}_k}{\mathbf{r}_k^T A \mathbf{r}_k}, \quad \mathbf{x}_{k+1} = \mathbf{x}_k + \frac{\mathbf{r}_k^T \mathbf{r}_k}{\mathbf{r}_k^T A \mathbf{r}_k} \mathbf{r}_k.$$

Vlastnosti iteračního procesu:

- 1 $\mathbf{r}_{k+1} = \mathbf{r}_k - \frac{\mathbf{r}_k^T \mathbf{r}_k}{\mathbf{r}_k^T A \mathbf{r}_k} A \mathbf{r}_k = \mathbf{r}_k - t_k A \mathbf{r}_k$
- 2 $(\mathbf{r}_{k+1}, \mathbf{r}_k) = \mathbf{r}_k^T \mathbf{r}_{k+1} = 0$
- 3 $Q(\mathbf{x}_{k+1}) < Q(\mathbf{x}_k), k = 1, 2, \dots$

Rychlost konvergence


Bud' $\hat{\mathbf{x}}$ řešení systému $A\mathbf{x} = \mathbf{b}$. Pak přímým výpočtem dostaneme $Q(\hat{\mathbf{x}}) = -\frac{1}{2} \mathbf{b}^T \hat{\mathbf{x}} = -\frac{1}{2} \mathbf{b}^T A^{-1} \mathbf{b}$.

Věta 11

Označme $E(\mathbf{x}_k) = Q(\mathbf{x}_k) - Q(\hat{\mathbf{x}}) = \frac{1}{2} (\mathbf{x}_k - \hat{\mathbf{x}})^T A (\mathbf{x}_k - \hat{\mathbf{x}})$.

Pak $E(\mathbf{x}_{k+1}) \leq \left(\frac{\lambda_{\max} - \lambda_{\min}}{\lambda_{\max} + \lambda_{\min}} \right)^2 E(\mathbf{x}_k)$

Metoda maxmálního spádu



Metoda sdružených (konjugovaných) gradientů

Nechť $\mathbf{p}_1, \dots, \mathbf{p}_n$ tvoří bázi, $\hat{\mathbf{x}}$ je řešení $A\mathbf{x} = \mathbf{b}$, $\hat{\mathbf{x}} = \sum_{i=1}^n c_i \mathbf{p}_i$.

Pokud jsou \mathbf{p}_i ortogonální, pak $c_i = \frac{(\hat{\mathbf{x}}, \mathbf{p}_i)}{(\mathbf{p}_i, \mathbf{p}_i)}$.

Problém: neznáme $\hat{\mathbf{x}}$.

Výchozí rovnost násobíme maticí A :

$A\hat{\mathbf{x}} = \mathbf{b} = \sum_{i=1}^n c_i A\mathbf{p}_i$. Kdyby platilo

$$(A\mathbf{p}_j, \mathbf{p}_i) = \mathbf{p}_i^T A\mathbf{p}_j = 0 \text{ pro } i \neq j, \text{ pak } c_i = \frac{(\mathbf{b}, \mathbf{p}_i)}{(A\mathbf{p}_i, \mathbf{p}_i)}.$$

Proto definujeme nový skalární součin $(\mathbf{x}, \mathbf{y})_A = (A\mathbf{x}, \mathbf{y})$, vektory, pro něž $(\mathbf{x}, \mathbf{y})_A = 0$, se nazývají A -ortogonální (A -sdružené, A -konjugované).

Cílem metody je sestavit A -ortogonální vektory $\mathbf{p}_1, \dots, \mathbf{p}_n$ podobně jako u Gramova–Schmidtova ortogonalizačního procesu.

Modifikovaný Gramův–Schmidtův ortogonalizační proces:
Z dané báze $\mathbf{r}_1, \dots, \mathbf{r}_n$ vytváříme novou, A -ortogonální bázi.
Položme $\mathbf{p}_1 = \mathbf{r}_1$ a dále

$$\mathbf{p}_k = \mathbf{r}_k + \sum_{i=1}^{k-1} \beta_{k,i} \mathbf{p}_i, \text{ pak } \beta_{k,i} = -\frac{(\mathbf{r}_k, \mathbf{p}_i)_A}{(\mathbf{p}_i, \mathbf{p}_i)_A}.$$

Jako bázi \mathbf{r}_k bereme postupně rezidua, v každém kroku počítáme koeficienty α i β .

Snadno se ověří (viz metoda maximálního spádu), že pro iteraci \mathbf{x}_k a směr daný vektorem \mathbf{p} má funkce Q minimum v

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{p}, \text{ pro } \alpha_k = \frac{\mathbf{p}^T \mathbf{r}_k}{\mathbf{p}^T A \mathbf{p}} = \frac{(\mathbf{r}_k, \mathbf{p})}{(\mathbf{p}, \mathbf{p})_A}.$$

Počáteční krok

\mathbf{x}_1 – počáteční iterace, $\mathbf{p}_1 = \mathbf{r}_1 = \mathbf{b} - A\mathbf{x}_1$.

Následně $\mathbf{x}_2 = \mathbf{x}_1 + \alpha_1\mathbf{p}_1$ pro $\alpha_1 = \frac{(\mathbf{r}_1, \mathbf{p}_1)}{(\mathbf{p}_1, \mathbf{p}_1)_A}$, potom

$\mathbf{r}_2 = \mathbf{b} - A\mathbf{x}_2 = \mathbf{r}_1 - \alpha_1 A\mathbf{p}_1$ a

$\mathbf{p}_2 = \mathbf{r}_2 + \beta_{2,1}\mathbf{p}_1$ pro $\beta_{2,1} = -\frac{(\mathbf{r}_2, \mathbf{p}_1)_A}{(\mathbf{p}_1, \mathbf{p}_1)_A}$.

Obecný krok

Pro iteraci \mathbf{x}_k , reziduum $\mathbf{r}_k = \mathbf{b} - A\mathbf{x}_k$ a směrový vektor \mathbf{p}_k položíme

$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k\mathbf{p}_k$, kde $\alpha_k = \frac{(\mathbf{r}_k, \mathbf{p}_k)}{(\mathbf{p}_k, \mathbf{p}_k)_A}$.

$\mathbf{r}_{k+1} = \mathbf{b} - A\mathbf{x}_{k+1} = \mathbf{r}_k - \alpha_k A\mathbf{p}_k$,

$\mathbf{p}_{k+1} = \mathbf{r}_{k+1} + \sum_{i=1}^k \beta_{k+1,i}\mathbf{p}_i$ pro $\beta_{k+1,i} = -\frac{(\mathbf{r}_{k+1}, \mathbf{p}_i)_A}{(\mathbf{p}_i, \mathbf{p}_i)_A}$.

Věta 12 (Vlastnosti definovaných vektorů)

1. $\mathcal{L}(\mathbf{r}_1, \dots, \mathbf{r}_k) = \mathcal{L}(\mathbf{p}_1, \dots, \mathbf{p}_k)$ pro $k = 1, 2, \dots$
2. Vektory $\mathbf{p}_1, \mathbf{p}_2, \dots$ jsou A -ortogonální.
3. Vektor $\mathbf{r}_k - \mathbf{r}_{k+1}$ je kolmý k \mathbf{p}_i pro $i \neq k$.

Důkaz: $\mathbf{r}_k - \mathbf{r}_{k+1} = \alpha_k A\mathbf{p}_k$, takže pro $i \neq k$ dostáváme
 $(\mathbf{p}_i, \mathbf{r}_k - \mathbf{r}_{k+1}) = \alpha_k (\mathbf{p}_i, A\mathbf{p}_k) = \alpha_k (\mathbf{p}_i, \mathbf{p}_k)_A = 0$.

4. $(\mathbf{r}_k, \mathbf{p}_k)_A = (\mathbf{p}_k, \mathbf{p}_k)_A, \forall k$.

Důkaz indukcí: Pro $k = 1$ platí, necht' platí pro k , pak

$$(\mathbf{r}_{k+1}, \mathbf{p}_{k+1})_A = (\mathbf{p}_{k+1} - \sum_{i=1}^k \beta_{k+1,i} \mathbf{p}_i, \mathbf{p}_{k+1})_A = (\mathbf{p}_{k+1}, \mathbf{p}_{k+1})_A$$

5. Vektory $\mathbf{r}_1, \mathbf{r}_2, \dots$ jsou ortogonální.

Důkaz indukcí: Nejprve dokážeme $(\mathbf{r}_2, \mathbf{r}_1) = 0$:

$$(\mathbf{r}_2, \mathbf{r}_1) = (\mathbf{r}_1, \mathbf{r}_1) - \alpha_1 (A\mathbf{p}_1, \mathbf{r}_1) = (\mathbf{r}_1, \mathbf{r}_1) - \frac{(\mathbf{r}_1, \mathbf{p}_1)}{(\mathbf{p}_1, \mathbf{p}_1)_A} (\mathbf{p}_1, \mathbf{r}_1)_A = 0,$$

neboť $\mathbf{p}_1 = \mathbf{r}_1$.

Dále necht' jsou kolmé vektory $\mathbf{r}_1, \dots, \mathbf{r}_k$ pro $k \geq 2$. Pak

$$\begin{aligned} (\mathbf{r}_{k+1}, \mathbf{r}_k) &= (\mathbf{r}_k, \mathbf{r}_k) - \alpha_k (A\mathbf{p}_k, \mathbf{r}_k) = (\mathbf{r}_k, \mathbf{r}_k) - \\ &- \frac{(\mathbf{r}_k, \mathbf{p}_k)}{(\mathbf{p}_k, \mathbf{p}_k)_A} (\mathbf{p}_k, \mathbf{r}_k)_A \text{ (viz 4.)} = (\mathbf{r}_k, \mathbf{r}_k) - (\mathbf{r}_k, \mathbf{r}_k + \sum_{i < k} \beta_{k,i} \mathbf{p}_i) = \\ &= (\mathbf{r}_k, \mathbf{r}_k) - (\mathbf{r}_k, \mathbf{r}_k + \sum_{i < k} \gamma_i \mathbf{r}_i) = 0 \text{ pro nějaké koeficienty } \gamma_i \end{aligned}$$

vzhledem k vlastnosti 1. a indukčnímu předpokladu.

Nakonec dokážeme $(\mathbf{r}_{k+1}, \mathbf{r}_i) = 0$ pro $i < k$:

$$\begin{aligned} (\mathbf{r}_{k+1}, \mathbf{r}_i) &= (\mathbf{r}_k - (\mathbf{r}_k - \mathbf{r}_{k+1}), \mathbf{r}_i) = (\mathbf{r}_k, \mathbf{r}_i) - \\ &- (\mathbf{r}_k - \mathbf{r}_{k+1}, \mathbf{r}_i) = 0 - (\mathbf{r}_k - \mathbf{r}_{k+1}, \mathbf{p}_i - \sum_{j < i} \beta_{i,j} \mathbf{p}_j) = 0 \end{aligned}$$

vzhledem k vlastnosti 3.

6. Pro nějaké k (nejvýše $k = n + 1$) je $\mathbf{r}_k = 0$.
 Plyne okamžitě z 5., jedná se o teoretický výsledek prakticky nedosažitelný kvůli zaokrouhlovacím chybám.
7. $(\mathbf{r}_k, \mathbf{p}_k) = (\mathbf{r}_k, \mathbf{r}_k)$, $(\mathbf{r}_k, \mathbf{p}_i) = 0 \quad \forall k, \quad \forall i < k$.

Důkaz obou rovností plyne z vlastností 1. a 5. (viz též podobná část v důkazu 5.):

$$(\mathbf{r}_k, \mathbf{p}_k) = (\mathbf{r}_k, \mathbf{r}_k + \sum_{i < k} \beta_{k,i} \mathbf{p}_i) = (\mathbf{r}_k, \mathbf{r}_k).$$

8. $\beta_{k+1,i} = 0$ pro $i < k$

Důkaz plyne z kolmosti reziduí:

$$\beta_{k+1,i} = -\frac{(\mathbf{r}_{k+1}, \mathbf{p}_i)_A}{(\mathbf{p}_i, \mathbf{p}_i)_A},$$

$$(\mathbf{r}_{k+1}, \mathbf{p}_i)_A = (\mathbf{r}_{k+1}, A\mathbf{p}_i) = \frac{1}{\alpha_i} (\mathbf{r}_{k+1}, \mathbf{r}_i - \mathbf{r}_{i+1}) = 0$$

$$9. \beta_{k+1,k} = \beta_{k+1} = \frac{(\mathbf{r}_{k+1}, \mathbf{r}_{k+1})}{(\mathbf{r}_k, \mathbf{r}_k)} = \frac{\mathbf{r}_{k+1}^T \mathbf{r}_{k+1}}{\mathbf{r}_k^T \mathbf{r}_k}$$

Důkaz plyne z vlastnosti 7. a z kolmosti reziduí:

$$\begin{aligned} \beta_{k+1} &= -\frac{(\mathbf{r}_{k+1}, \mathbf{p}_k)_A}{(\mathbf{p}_k, \mathbf{p}_k)_A} = -\frac{\mathbf{r}_{k+1}^T A \mathbf{p}_k}{\mathbf{p}_k^T A \mathbf{p}_k} = -\frac{\frac{1}{\alpha_k} \mathbf{r}_{k+1}^T (\mathbf{r}_k - \mathbf{r}_{k+1})}{\frac{1}{\alpha_k} \mathbf{p}_k^T (\mathbf{r}_k - \mathbf{r}_{k+1})} = \\ &= -\frac{(\mathbf{r}_{k+1}, \mathbf{r}_k) - (\mathbf{r}_{k+1}, \mathbf{r}_{k+1})}{(\mathbf{p}_k, \mathbf{r}_k) - (\mathbf{p}_k, \mathbf{r}_{k+1})} = \frac{(\mathbf{r}_{k+1}, \mathbf{r}_{k+1})}{(\mathbf{r}_k, \mathbf{r}_k)} \end{aligned}$$

Celkový algoritmus metody sdružených gradientů:


\mathbf{x}_1 je počáteční iterace, lze použít $\mathbf{x}_1 = \mathbf{o}$.

$$\begin{aligned}\mathbf{p}_1 &= \mathbf{r}_1 = \mathbf{b} - A\mathbf{x}_1 \\ \text{pro } k &= 1, \dots, n : \\ \alpha_k &= \frac{(\mathbf{r}_k, \mathbf{p}_k)}{(\mathbf{p}_k, \mathbf{p}_k)_A} = \frac{\mathbf{p}_k^T \mathbf{r}_k}{\mathbf{p}_k^T A \mathbf{p}_k} \\ \mathbf{x}_{k+1} &= \mathbf{x}_k + \alpha_k \mathbf{p}_k \\ \mathbf{r}_{k+1} &= \mathbf{b} - A\mathbf{x}_{k+1} = \mathbf{r}_k - \alpha_k A \mathbf{p}_k \\ \beta_{k+1} &= \frac{(r_{k+1}, r_{k+1})}{(r_k, r_k)} = \frac{r_{k+1}^T r_{k+1}}{r_k^T r_k} \\ \mathbf{p}_{k+1} &= \mathbf{r}_{k+1} + \beta_{k+1} \mathbf{p}_k\end{aligned}$$

Algoritmus končíme pokud $\|\mathbf{r}_{k+1}\|$ je dostatečně malá.

Odhad chyby: $\|\hat{\mathbf{x}} - \mathbf{x}_k\|_A \leq 2 \left(\frac{\sqrt{C_p(A)} - 1}{\sqrt{C_p(A)} + 1} \right)^k \|\hat{\mathbf{x}} - \mathbf{x}_1\|_A$

Metoda sdružených gradientů



Metoda bikonjugovaných gradientů

Matice soustavy A nemusí být symetrická. Vytváříme
psloupnost dvojic reziduí $\mathbf{r}_k, \tilde{\mathbf{r}}_k$, které jsou biortogonální, tj.

$$(\mathbf{r}_k, \tilde{\mathbf{r}}_l) = 0, \text{ pro } k \neq l, (\mathbf{r}_k, \tilde{\mathbf{r}}_k) \neq 0,$$

a dvojic směrů $\mathbf{p}_k, \tilde{\mathbf{p}}_k$, které jsou bikonjugované, tj.

$$(A\mathbf{p}_k, \tilde{\mathbf{p}}_l) = 0, \text{ pro } k \neq l, (A\mathbf{p}_k, \tilde{\mathbf{p}}_k) \neq 0.$$

Algoritmus metody:

$$\mathbf{v}_1 = \mathbf{r}_1 = \mathbf{b} - A\mathbf{x}_1$$

$\tilde{\mathbf{r}}_1$ volíme tak, aby $(\mathbf{r}_1, \tilde{\mathbf{r}}_1) \neq 0$, $\tilde{\mathbf{v}}_1 = \tilde{\mathbf{r}}_1$.

Pro $k = 1, \dots, n$:

$$\alpha_k = \frac{(\mathbf{r}_k, \tilde{\mathbf{r}}_k)}{(A\mathbf{p}_k, \tilde{\mathbf{p}}_k)}$$

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{p}_k$$

$$\mathbf{r}_{k+1} = \mathbf{r}_k - \alpha_k A\mathbf{p}_k, \tilde{\mathbf{r}}_{k+1} = \tilde{\mathbf{r}}_k - \alpha_k A^T \tilde{\mathbf{p}}_k$$

$$\beta_k = \frac{(\mathbf{r}_{k+1}, \tilde{\mathbf{r}}_{k+1})}{(\mathbf{r}_k, \tilde{\mathbf{r}}_k)}$$

$$\mathbf{p}_{k+1} = \mathbf{r}_{k+1} + \beta_k \mathbf{p}_k$$

$$\tilde{\mathbf{p}}_{k+1} = \tilde{\mathbf{r}}_{k+1} + \beta_k \tilde{\mathbf{p}}_k$$

Pro metodu bikonjugovaných gradientů je známo jen málo teoretických výsledků. Pro pozitivně definitní matici A je tato metoda ekvivalentní metodě sdružených gradientů za cenu dvojnásobně více výpočtů.

Selhání metody:

$$(\mathbf{r}_k, \tilde{\mathbf{r}}_k) \approx 0 \text{ nebo } (A\mathbf{p}_k, \tilde{\mathbf{p}}_k) \approx 0.$$

Věta 13

Bud' M maximální počet iterací, během nichž metoda bikonjugovaných gradientů neselže. Pak pro $k = 1, \dots, M$ platí $\mathbf{r}_k = \mathbf{b} - A\mathbf{x}_k$

Věta 14

Bud' M maximální počet iterací, během nichž metoda bikonjugovaných gradientů neselže. Pak pro $k = 1, \dots, M$ jsou vektory $\mathbf{r}_k, \tilde{\mathbf{r}}_k$ biortogonální a vektory $\mathbf{p}_k, \tilde{\mathbf{p}}_k$ bikonjugované.

Metoda se dá dobře paralelizovat.

Metoda maximálního spádu

Pro kvadratickou funkci

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

je její gradient roven $\nabla Q = A\mathbf{x} - \mathbf{b} = -\mathbf{r}$, což je směr maximálního růstu. Obecně dává gradient funkce f více proměnných směr maximální růstu, takže při hledání minima funkce můžeme využít směr maximálního spádu $-\nabla f$:

Bud' \mathbf{x}_1 počáteční iterace, položme $\mathbf{v}_1 = -\nabla f(\mathbf{x}_1)$ a hledáme minimum funkce f ve směru \mathbf{p}_1 , tj. $\min f(\mathbf{x}_1 + t\mathbf{p}_1)$ v bodě t_1 . Bod t_1 musíme najít nějakou numerickou jednorozměrnou minimalizační metodou, pak $\mathbf{x}_2 = \mathbf{x}_1 + t_1\mathbf{p}_1$ a podobně pokračujeme dál.

Fletcherova-Reevesova metoda

Algoritmus:

x_1 je počáteční iterace, $\nabla f_1 = \nabla f(x_1)$, $\mathbf{p}_1 = -\nabla f_1$.

Pro $k = 1, 2, \dots$

najdeme α_k po němž je $f(x_k + \alpha_k \mathbf{p}_k)$ minimální,

$$x_{k+1} = x_k + \alpha_k \mathbf{p}_k,$$

určíme $\nabla f_{k+1} = \nabla f(x_{k+1})$ a pak

$$\beta_k = \frac{\nabla f_{k+1}^T \nabla f_{k+1}}{\nabla f_k^T \nabla f_k},$$

$$\mathbf{p}_{k+1} = -\nabla f_{k+1} + \beta_k \mathbf{p}_k.$$