

SOUSTAVY LINEÁRNÍCH ALGEBRAICKÝCH ROVNIC

Metody

- **přímé** (GEM, metoda LU-rozkladu)
- **iterační**
- **gradientní**

Iterační metody najdou přesné řešení *teoreticky* až po nekonečně mnoha krocích.

Pamatujme si, že v numerické praxi používáme pro řešení soustav s plnou maticí přímé metody, zatímco pro speciální (řídke) matice používáme iterační metody.

Toto rozdělení je dáno **výpočetní složitostí** těchto metod, tj. počtem matematických operací sčítání, odčítání, násobení a dělení nutných k získání výsledku.

Poznámka: V případě plné matice je výpočetní cena v každé iteraci řádu n^2 , srovnáme-li toto s celkovou výpočetní cenou přímých metod, tj. řádově $2/3 n^3$, vidíme, že má-li být výpočetní složitost iterační metody stejná jako u přímé metody, musela by iterační metoda najít řešení (s předem zadanou přesností) řádově po n iteracích. Na druhou stranu v případě speciální (řídke) matice je výhodné použít iterační metodu.

Příklad:

Uvažujme rovnici

$$9x = 9$$

Řešení je

$$x^* = 1$$

Rovnici lze přepsat např. na tvar

$$10x - x = 9$$

$$x = \frac{9 + x}{10}$$

- viz metoda prosté iterace pro nelineární rovnice
- nyní uvažujeme lineární rovnice, proto předpis funkce $\phi(x)$ může být lineární
- řešení hledáme pomocí rekurentní formule

$$x^{(k+1)} = \frac{9 + x^{(k)}}{10}$$

kde volíme např. $x^{(0)} = 1$

Dostáváme

$$x^{(1)} = 0.9$$

$$x^{(2)} = 0.99$$

$$x^{(3)} = 0.999$$

$$x^{(4)} = 0.9999$$

Zastavíme např. pomocí $|x^{(4)} - x^{(3)}| < \varepsilon = 0.001$

Uvedený postup realizujeme pro soustavy.

Podobně jako v metodě prosté iterace pro nelineární soustavy přepíšeme soustavu

$$\mathbf{Ax} - \mathbf{b} = \mathbf{o} \quad \longleftrightarrow \quad \mathbf{F}(\mathbf{x}) = \mathbf{o}$$

na tvar

$$\mathbf{x} = \mathbf{Hx} + \mathbf{g} \quad \longleftrightarrow \quad \mathbf{x} = \mathbf{\Phi}(\mathbf{x})$$

Uvažujeme-li soustavu lineárních algebraických rovnic, tj. funkce \mathbf{F} je lineární, můžeme potom najít lineární předpis pro funkci $\mathbf{\Phi}$.

Všechny iterační metody pro řešení soustavy lineárních algebraických rovnic budou používat iterační formuli

$$\boxed{\mathbf{x}^{(k+1)} = \mathbf{H} \cdot \mathbf{x}^{(k)} + \mathbf{g}}$$

samozřejmě s různou iterační maticí \mathbf{H} a vektorem \mathbf{g} a je zřejmé, že o kvalitě metody rozhodují právě vlastnosti matice \mathbf{H} .

Počáteční aproximaci $\mathbf{x}^{(0)}$ zvolíme

a výpočet ukončíme pomocí zastavovací podmínky

$$\|\mathbf{x}^{(k)} - \mathbf{x}^{(k-1)}\| < \varepsilon$$

Jacobiova metoda

Princip:

Z i -té rovnice vyjádříme i -tou složku vektoru \mathbf{x}

$$i\text{-tá rovnice: } a_{i1}x_1 + a_{i2}x_2 + \dots + a_{in}x_n = b_i$$

$$\text{pro } a_{ii} \neq 0: \quad x_i = \frac{1}{a_{ii}} \left(b_i - \sum_{j=1, j \neq i}^n a_{ij}x_j \right)$$

Iterační formule:

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

Gaussova-Seidelova metoda

Princip:

Stejný jako u Jacobiovy metody s tím rozdílem, že jestliže při výpočtu $(k + 1)$ -iterace již známe $(k + 1)$ -iteraci některých složek, tak ji použijeme.

Iterační formule:

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

Relaxační metoda SOR

Princip:

Vyjdeme z Gaussovy-Seidelovy metody jejíž iterační formuli lze psát takto:

$$x_i^{(k+1)} = x_i^{(k)} + r_i^{(k)} \quad \text{kde}$$

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

Abychom urychlili výpočet, nebudeme přičítat $r_i^{(k)}$, ale $\omega r_i^{(k)}$, tj.

$$x_i^{(k+1)} = x_i^{(k)} + \omega r_i^{(k)}$$

Iterační formule:

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

Poznámka:

$(k+1)$ -iterace metody SOR je lineární kombinací $(k+1)$ -iterace získané Gauss-Seidlovou metodou a předchozí k -té iterace.

$$x_i^{(k+1)} = \omega \underbrace{\frac{1}{a_{ii}} \left(b_i - \sum_{j=1}^{i-1} a_{ij} x_j^{(k+1)} - \sum_{j=i+1}^n a_{ij} x_j^{(k)} \right)}_{x_i^{(k+1)} \text{ z Gaussovy-Seidelovy metody}} + (1 - \omega) x_i^{(k)}$$

Maticový zápis iteračních metod

Nejprve rozložíme matici \mathbf{A} :

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

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

Jacobiova metoda:

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

$$\mathbf{x} = \underbrace{-\mathbf{D}^{-1}(\mathbf{L} + \mathbf{U})}_{\mathbf{H}_J} \mathbf{x} + \underbrace{\mathbf{D}^{-1}\mathbf{b}}_{\mathbf{g}_J}$$

Gauss-Seidlova metoda:

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

$$\mathbf{x} = \underbrace{-(\mathbf{L} + \mathbf{D})^{-1}\mathbf{U}}_{\mathbf{H}_{GS}} \mathbf{x} + \underbrace{(\mathbf{L} + \mathbf{D})^{-1}\mathbf{b}}_{\mathbf{g}_{GS}}$$

Relaxační metoda SOR:

$$\begin{aligned} \mathbf{Ax} &= \mathbf{b} \\ \omega \mathbf{Ax} &= \omega \mathbf{b} && / + \mathbf{Dx} \\ (\omega \mathbf{A} + \mathbf{D})\mathbf{x} &= \omega \mathbf{b} + \mathbf{Dx} \\ [\omega(\mathbf{L} + \mathbf{D} + \mathbf{U}) + \mathbf{D}]\mathbf{x} &= \omega \mathbf{b} + \mathbf{Dx} \\ (\omega \mathbf{L} + \mathbf{D})\mathbf{x} &= \omega \mathbf{b} + \mathbf{Dx} - \omega \mathbf{Dx} - \omega \mathbf{Ux} \\ (\omega \mathbf{L} + \mathbf{D})\mathbf{x} &= [(1 - \omega)\mathbf{D} - \omega \mathbf{U}]\mathbf{x} + \omega \mathbf{b} \end{aligned}$$

$$\mathbf{x} = \underbrace{(\omega \mathbf{L} + \mathbf{D})^{-1} [(1 - \omega)\mathbf{D} - \omega \mathbf{U}]\mathbf{x}}_{\mathbf{H}_{SOR}} + \underbrace{(\omega \mathbf{L} + \mathbf{D})^{-1} \omega \mathbf{b}}_{\mathbf{g}_{SOR}}$$

Metoda je dána formulí

$$x^{(k+1)} = Hx^{(k)} + g$$

Pro přímé řešení x^* musí platit

$$\begin{aligned} \bullet \quad x^* &= Hx^* + g \\ \bullet \quad x^* &= A^{-1}b \end{aligned}$$

$$A^{-1}b = H A^{-1}b + g \quad (*)$$

Definice: Iterační metoda $x^{(k+1)} = Hx^{(k)} + g$ má být konvergentní, pokud platí (*).

Poznámka Uvedené metody jsou konvergentní

• např. pro Jacobiho metodu musí platit

$$A^{-1}b = \underbrace{-D^{-1}(L+U)}_{H_1} A^{-1}b + \underbrace{D^{-1}b}_{g_1}$$

$$A^{-1}b = \underbrace{D^{-1}(-L+U+A)}_D A^{-1}b$$

I

OK

• Dvo: Ukáže, že Gauss-Seidelova metoda i metoda SOR jsou konvergentní

Definice : Iterační metoda $x^{(k+1)} = Hx^{(k)} + g$
 se nazývá konvergentní, jestliže po každou
 poč. aproximaci $x^{(0)} \in \mathbb{R}^m$ platí:

$$\lim_{k \rightarrow \infty} x^{(k)} = x^* \quad (= A^{-1}b)$$

Chyba k -té iterace :
$$e^{(k)} = x^{(k)} - x^*$$

Následující podmínka konvergence metody

iterační předpis
$$x^{(k)} = Hx^{(k-1)} + g$$

konstantní metoda
$$x^* = Hx^* + g$$

$$x^{(k)} - x^* = H(x^{(k-1)} - x^*)$$

$$e^{(k)} = H e^{(k-1)}$$

Platí :
$$e^{(k)} = H e^{(k-1)} = H^2 e^{(k-2)} = \dots = H^{(k)} e^{(0)}$$

$$\lim_{k \rightarrow \infty} x^{(k)} = x^*$$

$$\Leftrightarrow \lim_{k \rightarrow \infty} e^{(k)} = 0$$

Věta Dána konverzní iterací metoda $x^{(k+1)} = Hx^{(k)} + g$ konverguje pro libovolné $x^{(0)} \in \mathbb{R}^m$ právě tehdy, když je stabilní, tj.

$$\rho(H) = \max_i |\lambda_i(H)| < 1,$$

kde číslo $\rho(H)$ nazýváme spektrální poloměr matice H a $\lambda_i(H)$ jsou vlastní čísla matice H .

Myslenka důkazu:

Jsou-li $\lambda_1, \lambda_2, \dots, \lambda_m$ vlastní čísla matice H , pak existuje regulární matice T taková, že $H = T J T^{-1}$ kde J je tzv. Jordanova matice, což je blokové diagonální matice s bloky

$$J_i = \begin{bmatrix} \lambda_i & 1 & & \\ & \lambda_i & 1 & \\ & & \ddots & \ddots \\ & & & \lambda_i \end{bmatrix}$$

Platí: $H^2 = T J T^{-1} \cdot T J T^{-1} = T J^2 T^{-1}$

Obecně $H^k = T J^k T^{-1}$

Platí-li: $\max_i |\lambda_i(H)| < 1 \Rightarrow \lim_{k \rightarrow \infty} J^k = 0$, tj.

$$x^{(k)} = H^k x^{(0)} \rightarrow 0$$

Je-li $\lim_{k \rightarrow \infty} H^k = 0$ (metoda konverguje) $\Rightarrow \lim_{k \rightarrow \infty} J^k = 0$



$$|\lambda_i| < 1 \quad \forall i$$



Poznámka

Uvazuje 1 jordanov blok J_i

Gracie S matice
$$\begin{bmatrix} 0 & 1 & & & \\ & 0 & 1 & & \\ & & 0 & 1 & \\ & & & \ddots & \ddots \\ & & & & 1 & \\ & & & & & 0 \end{bmatrix}$$

Potom

$$J_i = \lambda_i I + S$$

Podle binomické věty

$$J_i^k = \sum_{j=0}^k \binom{k}{j} \lambda_i^{k-j} S^j$$

$S^j = 0$ pro $j \geq l$
↑
řád bloku

$$= \sum_{j=0}^{\min(k,l)} \binom{k}{j} \lambda_i^{k-j} S^j$$

$(l = \min(k,l))$

$$= \lambda_i^k I + \binom{k}{1} \lambda_i^{k-1} S + \binom{k}{2} \lambda_i^{k-2} S^2 + \dots + \binom{k}{l} \lambda_i^{k-l} S^l$$

$$S = \begin{bmatrix} 0 & 1 & & & \\ & 0 & 1 & & \\ & & 0 & 1 & \\ & & & \ddots & \ddots \\ & & & & 1 & \\ & & & & & 0 \end{bmatrix}$$

$$S^2 = \begin{bmatrix} 0 & 0 & 1 & & & \\ & 0 & 0 & 1 & & \\ & & 0 & 0 & 1 & \\ & & & \ddots & \ddots & \ddots \\ & & & & 1 & \\ & & & & & 0 \end{bmatrix}$$

$$S^3 = \begin{bmatrix} 0 & 0 & 0 & 1 & & & \\ & 0 & 0 & 0 & 1 & & \\ & & 0 & 0 & 0 & 1 & \\ & & & \ddots & \ddots & \ddots & \ddots \\ & & & & 1 & \\ & & & & & 0 \end{bmatrix} \dots$$

$$J_i^k \rightarrow 0$$

(\Leftrightarrow)

$$\lambda_i^k \rightarrow 0$$

Poznámka Připomeňme souvislost s metodou postk' iterací pro řešení soustav nelineárních rovnic:

Funkce $\Phi(x)$ k přepisu $x = \Phi(x)$ musela splňovat podmínku (b') ... (pokud byla diferencovatelná)

$$\exists q \in (0, 1) \quad ; \quad \|\Phi'(x)\| \leq q \quad \forall x.$$

V našem případě je $\Phi(x) = Hx + q \Rightarrow \Phi'(x) = H.$

Tj. $\|H\| < 1$ Spektrální poloměr $\rho(H)$ je skuteč normou matice H , tj. $\rho(H) < 1$

Přidání věta je silnější (kritérium), \Leftrightarrow

Věta pro postkon iteraci naváděná postačující podmínky \Rightarrow

Poznámka: Uvažoval $\rho(H)$ je celkem obrahe, proto za chvíli uvedeme větu (postačující podmínky) jejíž předpoklady se ovšem snadněji

Definice: Maticovou normu $\|\cdot\|$ nazýváme multiplicativní, splňuje-li pro všechny čtvercové matice A, B rádku n vztah

$$\|A \cdot B\| \leq \|A\| \cdot \|B\|$$

Příklad

Řešme soustavu $Ax = b$ Jacobiovou metodou

$$A = \begin{bmatrix} 1 & 0,9 & 0,9 \\ 0,9 & 1 & 0,9 \\ 0,9 & 0,9 & 1 \end{bmatrix} \quad b = \begin{bmatrix} 2,8 \\ 2,8 \\ 2,8 \end{bmatrix} \quad \left(\begin{array}{l} \text{řesení} \\ x^* = [1, 1, 1]^T \end{array} \right)$$

$$H = \begin{bmatrix} 0 & -0,9 & -0,9 \\ -0,9 & 0 & -0,9 \\ -0,9 & -0,9 & 0 \end{bmatrix} \quad \dots \text{vl. čísla}$$

$-1,8; 0,9; 0,9$

$$\Rightarrow \rho(H) = 1,8 > 1$$
$$\Rightarrow \text{metoda diverguje !!!}$$

Maximální norma $\|H\|_{\infty} = \max_{i,j} |h_{ij}|$

(Dvo. úkote, se $\|\cdot\|_{\infty}$ splňuje vlastnosti normy)

$\|H\|_{\infty} = 0,9 < 1 \quad !!!$

$\|\cdot\|_{\infty}$ není multiplikatívni:

naps:

$$A = \begin{bmatrix} 1 & 1 \\ 1 & 1 \end{bmatrix} \quad B = \begin{bmatrix} 2 & 2 \\ 2 & 2 \end{bmatrix} \quad A \cdot B = \begin{bmatrix} 4 & 4 \\ 4 & 4 \end{bmatrix}$$

$$\|A\|_{\infty} = 1$$

$$\|B\|_{\infty} = 2$$

$$\|A \cdot B\|_{\infty} = 4$$

$$\|A\|_{\infty} \cdot \|B\|_{\infty} = 2 < \|A \cdot B\|_{\infty} = 4$$

!!!

Věta

Pro každou multiplikativní maticovou normu $\|\cdot\|$ a čtvercovou matici A platí:

$$\rho(A) \leq \|A\|$$

Důkaz:

$$\rho(A) = \max_i \{|\lambda_i|\} = \lambda_p$$

- necht' čísla λ_p odpovídá' normovaný' vlastní' vektor v_p ($v(v_p) = 1$)

• potom

$$\rho(A) = |\lambda_p| \cdot v(v_p) = v(\lambda_p v_p) = v(A v_p)$$

$$v(A v_p) \leq \|A\| \cdot \underbrace{v(v_p)}_{=1} = \|A\|$$

→ vlastnost kompatibilní' maticové' a vektorové' normy

Věta: Ke každé' multiplikativní' maticové' normě μ existuje kompatibilní' vektorová' norma v

Dk: dána maticová' norma μ

def: $v(x) = \mu([x, 0, 0, \dots, 0])$... optimální' vlastnost' normy

? kompatibilita:

$$v(Ax) = \mu([Ax, 0, 0, \dots, 0]) = \mu(A[x, 0, 0, \dots, 0]) \leq \mu(A) \mu([x, 0, 0, \dots, 0]) = \mu(A) \cdot v(x)$$

μ je multiplikativní'

Postačija' podminka konvergenca

Vida je-li po multiplikativni normi splnena podminka $\|H\| \leq q < 1$, potom postupnost $\{x^{(k)}\}$ ma' konstantni' formulu $x^{(k)} = H x^{(k-1)} + g$ konverguje ku libovolne' volbe vektoru $x^{(0)} \in \mathbb{R}^m$ a plati:

$$\lim_{k \rightarrow \infty} x^{(k)} = (I - H)^{-1} g = x^*$$

Duikar: Distelet kriteria a predohov' vity (jim' duikar na skriptu)

Odhad chyby

Předpokládáme, že je splněna postačující podmínka konvergence

$$\|\mathbf{H}\| \leq q < 1$$

$$\begin{aligned}\mathbf{x}^{(k)} - \mathbf{x}^* &= \mathbf{H}(\mathbf{x}^{(k-1)} - \mathbf{x}^*) = \\ &= \mathbf{H}(\mathbf{x}^{(k-1)} - \mathbf{x}^{(k)} + \mathbf{x}^{(k)} - \mathbf{x}^*) = \\ &= \mathbf{H}(\mathbf{x}^{(k-1)} - \mathbf{x}^{(k)}) + \mathbf{H}(\mathbf{x}^{(k)} - \mathbf{x}^*)\end{aligned}$$

Odtud dostáváme

$$\|\mathbf{x}^{(k)} - \mathbf{x}^*\| \leq q \|\mathbf{x}^{(k)} - \mathbf{x}^{(k-1)}\| + q \|\mathbf{x}^{(k)} - \mathbf{x}^*\|$$

tj.

$$\underbrace{(1 - q)}_{>0} \|\mathbf{x}^{(k)} - \mathbf{x}^*\| \leq q \|\mathbf{x}^{(k)} - \mathbf{x}^{(k-1)}\|$$

a po vydělení

$$\|\mathbf{x}^{(k)} - \mathbf{x}^*\| \leq \frac{q}{1 - q} \|\mathbf{x}^{(k)} - \mathbf{x}^{(k-1)}\|$$

Jestliže $\|\mathbf{x}^{(k)} - \mathbf{x}^{(k-1)}\| < \varepsilon$, potom

$$\boxed{\|\mathbf{x}^{(k)} - \mathbf{x}^*\| \leq \frac{q}{1 - q} \varepsilon}$$

Príklad Jacobiovou metódou riešte sústavu $Ax = b$:

$$A = \begin{bmatrix} 8 & 4 & 2 \\ 1 & 10 & 1 \\ 0 & 0 & 2 \end{bmatrix} \quad b = \begin{bmatrix} 14 \\ 12 \\ 2 \end{bmatrix} \quad x^{(0)} = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}$$

$$A = \underbrace{\begin{bmatrix} 0 & 0 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}}_L + \underbrace{\begin{bmatrix} 8 & 0 & 0 \\ 0 & 10 & 0 \\ 0 & 0 & 2 \end{bmatrix}}_D + \underbrace{\begin{bmatrix} 0 & 4 & 2 \\ 0 & 0 & 1 \\ 0 & 0 & 0 \end{bmatrix}}_U$$

$$H_j = -D^{-1}(L+U) = \begin{bmatrix} 0 & -0,5 & -0,25 \\ -0,1 & 0 & -0,1 \\ 0 & 0 & 0 \end{bmatrix}$$

$$g = D^{-1}b = \begin{bmatrix} 1,75 \\ 1,2 \\ 1 \end{bmatrix}$$

Provedenie 5 iterácií:

k	x_1^k	x_2^k	x_3^k
0	0	0	0
1	1,75	1,2	1
2	0,9	0,925	1
3	1,0375	1,01	1
4	0,995	0,99625	1
5	1,001875	1,0005	1

$$\underbrace{x^{(5)} - x^{(4)}}_{=r^{(5)}} = \begin{bmatrix} 0,006875 \\ 0,004250 \\ 0,000000 \end{bmatrix}$$


Odhadneme chybu $x^{(5)}$, tj. $\|x^{(5)} - x^*\| \leq \frac{\|H\|}{1 - \|H\|} \cdot \|x^{(5)} - x^{(4)}\|$

Odhad chyby	maticová norma	vektorová norma
$\frac{0,5}{1-0,5} \cdot 0,011125 = 0,011125$	$\ H\ _S = \max_k \left(\sum_i h_{ik} \right) = 0,5$	$\ r^{(5)}\ _1 = \sum_i r_i = 0,011125$
$\frac{0,75}{0,25} \cdot 0,006875 = 0,0206$	$\ H\ _R = \max_i \left(\sum_k h_{ik} \right) = 0,75$	$\ r^{(5)}\ _\infty = \max_i r_i = 0,006875$
$\frac{0,56}{0,44} \cdot 0,0081 = 0,0103$	$\ H\ _{SP} = \max_k \lambda_k^{\frac{1}{2}}(H^H H) = 0,56$	$\ r^{(5)}\ _2 = \sum_i r_i^2 = 0,0081$


Geometrický výkres

• $\|x^{(5)} - x^*\|_2 \leq 0,0103$

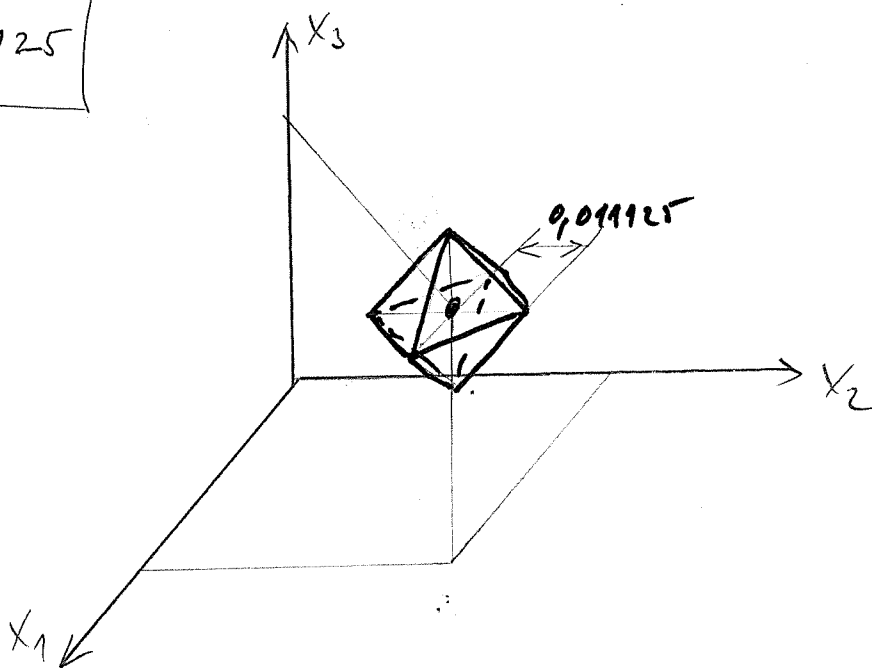
odtálenost $x^{(5)}$ a x^* je
měří nář odhad



• $\|x^{(5)} - x^*\|_\infty \leq 0,0206$



• $\|x^{(5)} - x^*\|_1 \leq 0,01125$



Rychlost konvergence

Lineární rychlost konvergence

$$\exists q \in (0, 1) \quad k_0 \geq 0 \quad k > k_0: \quad \|x^{(k+1)} - x^*\| \leq q \|x^{(k)} - x^*\|$$

Superlineární rychlost konvergence

$$\|x^{(k+1)} - x^*\| \leq q_k \|x^{(k)} - x^*\|$$
$$q_k \rightarrow 0 \quad (k \rightarrow \infty)$$

Konvergence řádku n

$$\|x^{(k+1)} - x^*\| \leq q \|x^{(k)} - x^*\|$$

Pozn:

- Jacobiův m., Gauss-Seidel,SOR ... lineární rychlost konvergence

$$x^{(k+1)} - x^* = H(x^{(k)} - x^*)$$

Během úvodu se používá iterací matice H ,
jedná se o stacionární metody ... $\|H\| \leq q$
↓
rychlota

- Metody se superlineární rychlostí konvergence patří mezi nestacionární procesy

$$x^{(k+1)} = H_k x^{(k)} + g_k$$

V každém kroku se mohou měnit H_k, g_k

Potom $\|H_k\| \leq q_k$, platí-li $q_k \rightarrow 0$ pak jde o superlineární metody.

Definujeme asymptotickou rychlost konvergence

$$R = -\log \frac{\|e^{(k)}\|}{\|e^{(k-1)}\|} \approx \log \|H\|$$

máje počet platných desítných míst rízkových v jednom iteracím kroku

Prakticky:

$$\frac{\|e^{(k)}\|}{\|e^{(k-1)}\|} = \frac{\|x^{(k)} - x^*\|}{\|x^{(k-1)} - x^*\|} \approx \frac{q}{1-q} \frac{\|x^{(k)} - x^{(k-1)}\|}{\|x^{(k-1)} - x^{(k-2)}\|}$$

Pozn Pro metody s lineární rychlostí konvergence (Jacobi, Gauss-Seidel,SOR) lze pro úrydek použít Aitkenovu extrapolaci (formuli (viz dříve))

postupnost dyb je geometrická: $e^{(k)} = H e^{(k-1)}$

$$\frac{e_i^{(k+1)}}{e_i^{(k)}} \approx \frac{e_i^{(k)}}{e_i^{(k-1)}}$$

po úpravě:

$$x_i^* \approx x_i^{(k+1)} - \frac{(x_i^{(k+1)} - x_i^{(k)})^2}{x_i^{(k+1)} - 2x_i^{(k)} + x_i^{(k-1)}}$$

Tři odvození metody SOR jsme se pokusili rychlě
vyjádřit směrnou iterativní maticí H tak, aby měla
menší spektrální poloměr $\rho(H)$.

Čím menší je $\rho(H)$, tím je větší asymptotická
rychlost konvergence.

Lemma Spektrální polynom $\rho(H_{SOR})$ splňuje podmínku

$$\rho(H_{SOR}) \geq |\omega - 1| \quad \forall \omega \in \mathbb{R}$$

Důkaz:

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

Je známo, že součin vlastních čísel je roven determinantu

$$\prod_{i=1}^n \lambda_i = \det(H_{SOR})$$

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

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

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

$$= \det(\underbrace{\omega D^{-1}L + I}^{-1}) \cdot \det(\underbrace{(1-\omega)I - \omega D^{-1}U})$$

▷ matice
s 1 na diagonále

▷ matice s prvky $(1-\omega)$
na diagonále

$$= (1-\omega)^n$$

$$\prod_{i=1}^n \lambda_i = (1-\omega)^n \Rightarrow$$

$$\max_i |\lambda_i| \geq |1-\omega|$$

(Důležité: $\forall \lambda_i \quad |\lambda_i| < |1-\omega| \Rightarrow \prod_{i=1}^n |\lambda_i| < |1-\omega|^n$)

$\rho(H_{SOR})$

Disledek: Agar SOR konvergen, haruslah:

$$|\omega - 1| \leq \boxed{\rho(H_{SOR}) < 1}$$

$$|\omega - 1| < 1 \Rightarrow \boxed{\omega \in (0, 2)}$$

Poznámka:


Parametr ω v relaxační metodě SOR volíme z intervalu $(0, 2)$. Pro $\omega = 1$ přejde relaxační metoda na Gauss-Seidlovu metodu. Volba parametru ω samozřejmě ovlivní rychlost konvergence iteračního procesu metody SOR. Lze ukázat, že existuje optimální hodnota parametru omega

$$\omega_{opt} = \frac{2}{1 + \sqrt{1 - \rho^2}},$$

kde ρ je spektrální poloměr Jacobiovy iterační matice \mathbf{H}_J .


(spektrální poloměr = maximální vlastní číslo v absolutní hodnotě)

Pro spektrální poloměr iterační matice \mathbf{H}_{SOR} relaxační metody lze odvodit následující závislosti:



Obr. 1


Závislost spektrálního poloměru iterační matice metody SOR na relaxačním parametru ω



Obr. 2

Závislost spektrálního poloměru matice metody SOR na spektrálním poloměru iterační matice Jacobiovy metody

GEOMETRICKÝ VÝZNAM JACOBOVY METODY

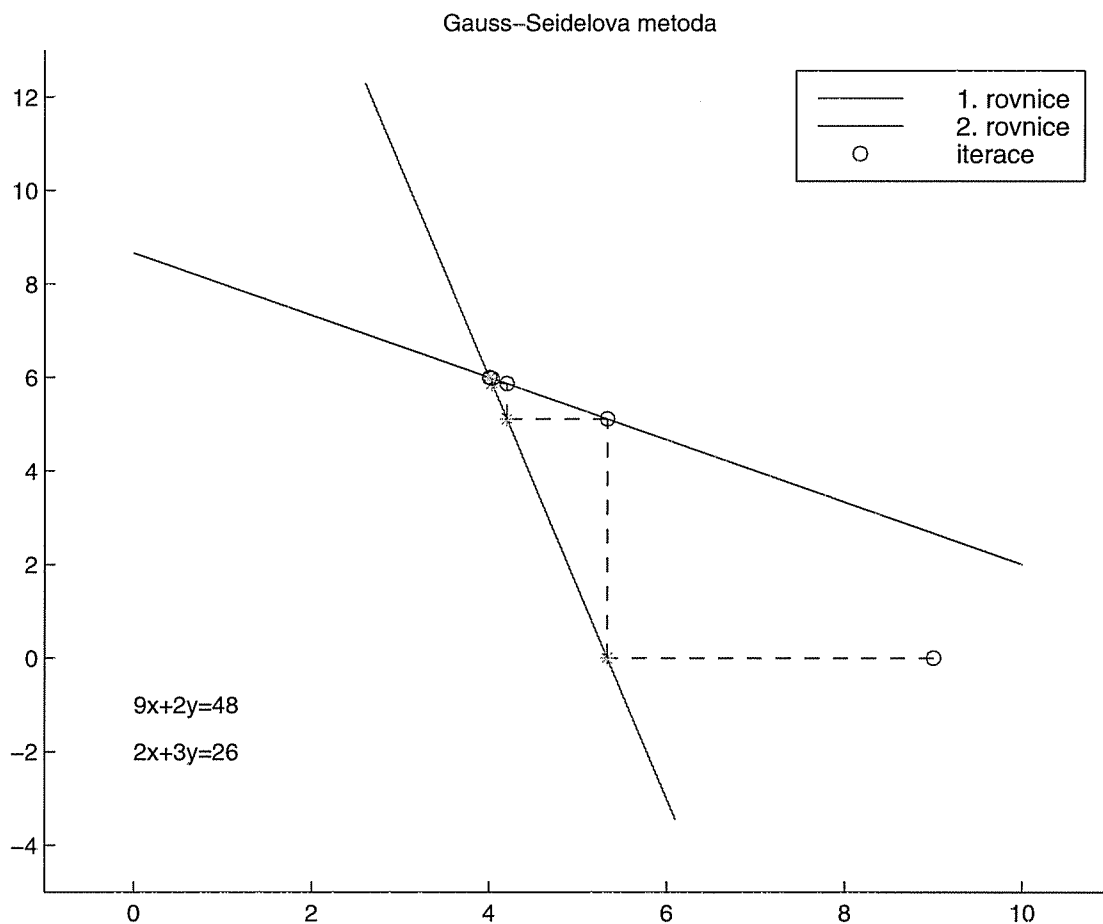


$$x^{(k+1)} = \frac{1}{9}(48 - 2y^{(k)})$$

$$y^{(k+1)} = \frac{1}{3}(26 - 2x^{(k)})$$

k	$x^{(k)}$	$y^{(k)}$
0	9.0000	0
1	5.3333	2.6667
2	4.7407	5.1111
3	4.1975	5.5062
4	4.1097	5.8683
5	4.0293	5.9268

GEOMETRICKÝ VÝZNAM GAUSSOVY-SEIDELOVY METODY




$$x^{(k+1)} = \frac{1}{9}(48 - 2y^{(k)})$$

$$y^{(k+1)} = \frac{1}{3}(26 - 2x^{(k+1)})$$

k	$x^{(k)}$	$y^{(k)}$
0	9.0000	0
1	5.3333	5.1111
2	4.1975	5.8683
3	4.0293	5.9805
4	4.0043	5.9971
5	4.0006	5.9996

GEOMETRICKÝ VÝZNAM METODY SOR ($\omega = 0.8$)

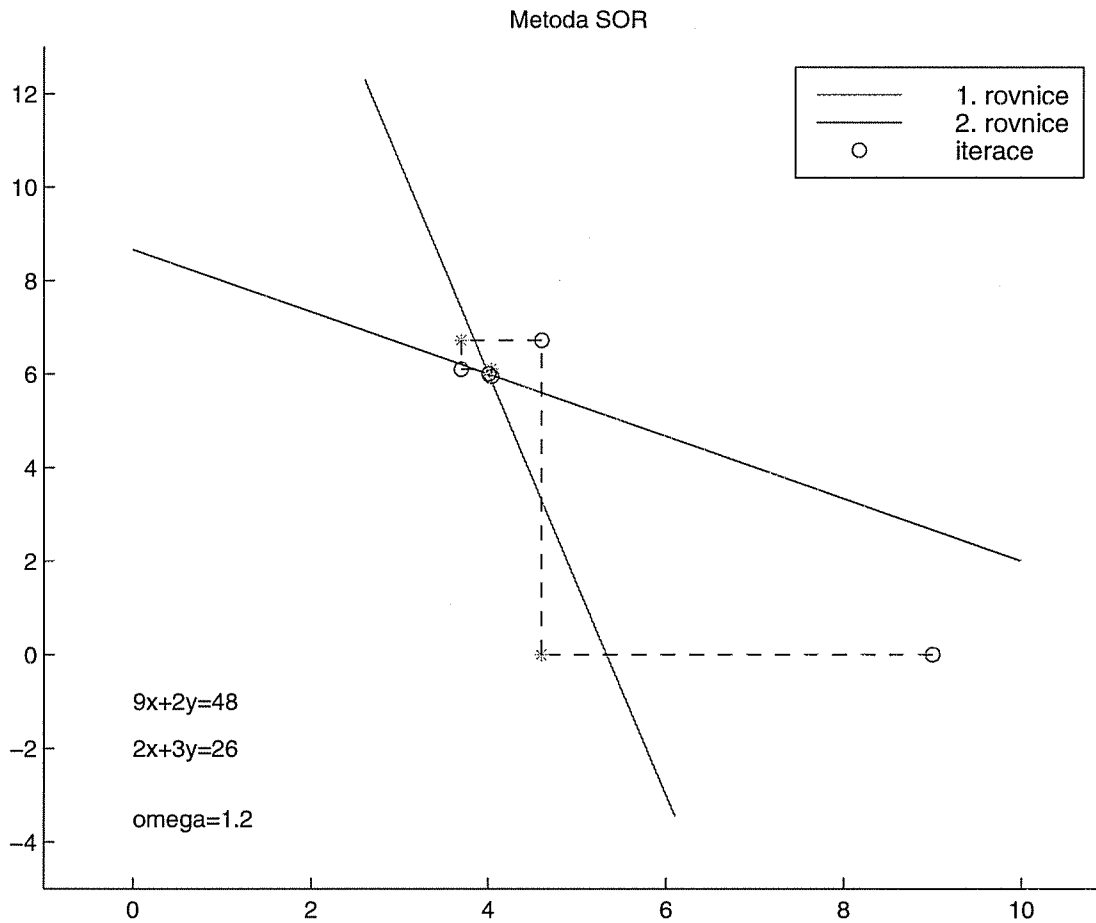


$$x^{(k+1)} = \omega \frac{1}{9}(48 - 2y^{(k)}) + (1 - \omega)x^{(k)}$$

$$y^{(k+1)} = \omega \frac{1}{3}(26 - 2x^{(k+1)}) + (1 - \omega)y^{(k)}$$

k	$x^{(k)}$	$y^{(k)}$
0	9.0000	0
1	6.0667	3.6978
2	4.8226	5.1008
3	4.3244	5.6472
4	4.1276	5.8614
5	4.0502	5.9455

GEOMETRICKÝ VÝZNAM METODY SOR ($\omega = 1.2$)



$$x^{(k+1)} = \omega \frac{1}{9}(48 - 2y^{(k)}) + (1 - \omega)x^{(k)}$$

$$y^{(k+1)} = \omega \frac{1}{3}(26 - 2x^{(k+1)}) + (1 - \omega)y^{(k)}$$

k	$x^{(k)}$	$y^{(k)}$
0	9.0000	0
1	4.6000	6.7200
2	3.6880	6.1056
3	4.0342	5.9515
4	4.0061	6.0048
5	3.9975	6.0010

KONVERGENČNÍ VĚTY

dosud jsme udávali podmínky pro iteraci matice H .
To je ovšem nepraktické. Měděne několik
mádněji ověřitelných podmínek.

- V1) Je-li matice A ostře diagonálně-dominantní,
potom konverguje Jacobiho i Gauss-Seidelova
metoda pro libovolnou volbu $x^{(0)}$
- V2) Je-li matice A symetrická a pozitivně-definitní,
potom Gauss-Seidelova metoda konverguje
pro libovolnou volbu $x^{(0)}$
- V3) Matkou podmínkou konvergence SOR je $0 < \omega < 2$.
Přidáme-li symetrii a pozitivní definitnost
matice A , dostaneme postačující podmínky
konvergence

Díbat V1) po jacobiovu metodu :

$Ax = b$, rozklad matice $A = L + D + U$
 označme-li $C = L + U$, potom $A = C + D$

• jacobiova metoda $x^{(k+1)} = H_J x^{(k)} + g_J$

$H_J = -D^{-1}(L+U) = -D^{-1}C$ a $g_J = D^{-1}b$

• Matice A je ostře diag. dominantní právě

$$|a_{ii}| > \sum_{\substack{j=1 \\ j \neq i}}^n |a_{ij}| \quad i=1, 2, \dots, n$$

• Pro naš rozklad $A = C + D$ tedy platí:

$$|d_{ii}| > \sum_{j=1}^n |c_{ij}| \quad i=1, 2, \dots, n \quad /: |d_{ii}| \neq 0$$

Platí:
 či $\sum_{j=1}^n \frac{|c_{ij}|}{|d_{ii}|} < 1 \quad (*)$

(kdyby $|d_{ii}| = 0$, potom by byl celý řádek nulový
 $\Rightarrow A$... regulární)

$$H_J = -D^{-1}C = - \begin{bmatrix} \frac{1}{d_{11}} & & \\ & \frac{1}{d_{22}} & \\ & & \dots \\ & & & \frac{1}{d_{nn}} \end{bmatrix} \cdot \begin{bmatrix} c_{1j} \\ \\ \\ c_{ij} \\ \\ \\ \end{bmatrix} = - \begin{bmatrix} \frac{c_{1j}}{d_{11}} \\ \\ \\ \frac{c_{ij}}{d_{ii}} \\ \\ \\ \end{bmatrix}$$

Řádková norma matice H_J :

$$\|H_J\| = \max_i \sum_{j=1}^n \left| \frac{c_{ij}}{d_{ii}} \right| < 1 \quad (*)$$

