

## Kapitola 4. SLAR - iterační metody

### Metody na řešení SLAR

- 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 (řídké) matice používáme **iterační metody**.

Toto rozdělení je dán 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 (řídké) matice je výhodné použít iterační metodu.

### Příklad

Uvažujme rovnici

$$9x = 9$$

Přesné 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  $\varphi(x)$  může být lineární
- řešení hledáme pomocí rekurentní formule (volíme např.  $x^{(0)} = 0$ )

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

Dostáváme

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

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

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

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

Zastavíme např. pomocí podmínky na rozdíl dvou po sobě jdoucích iterací  $|x^{(4)} - x^{(3)}| < \varepsilon = 0.001$

Uvedený postup realizujeme pro soustavy.

Podobně jako v metodě prosté iterace pro nelineární soustavy přepíšeme soustavu

$$\mathbf{Ax} - \mathbf{b} = \mathbf{0} \quad \longleftrightarrow \quad \mathbf{F}(\mathbf{x}) = \mathbf{0}$$

na tvar

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

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

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

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

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

Počáteční approximaci  $\mathbf{x}^{(0)}$  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  $\mathbf{x}$

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

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

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

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

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

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

### Iterační formule:

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

## Relaxační metoda SOR

### Princip:

Vyjdeme z Gaussovy-Seidelovy metody jejíž iterační formule je

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

dále vyjádříme  $(k+1)$ -ní iteraci pomocí  $k$ -té iterace a příslušné změny (tj. přičteme a odečteme  $x_i^{(k)}$ )

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

k urychlení výpočtu použijeme ideu, že nepřičteme k předchozí iteraci změnu  $r_i^{(k)}$ , ale její násobek  $wr_i^{(k)}$

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

### Iterační formule:

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

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

$$x_i^{(k+1)} = \omega x_{i GS}^{(k+1)} + (1 - \omega) x_i^{(k)}.$$

## 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

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

### Gauss-Seidlova metoda

$$\begin{aligned} \mathbf{Ax} &= \mathbf{b} \\ (\mathbf{L} + \mathbf{D} + \mathbf{U})\mathbf{x} &= \mathbf{b} \\ (\mathbf{L} + \mathbf{D})\mathbf{x} + \mathbf{Ux} &= \mathbf{b} \\ (\mathbf{L} + \mathbf{D})\mathbf{x} &= \mathbf{b} - \mathbf{Ux} \\ \mathbf{x} &= \underbrace{-(\mathbf{L} + \mathbf{D})^{-1}\mathbf{Ux}}_{\mathbf{H}_{GS}} + \underbrace{(\mathbf{L} + \mathbf{D})^{-1}\mathbf{b}}_{\mathbf{g}_{GS}} \end{aligned}$$

### Relaxační metoda SOR

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

Iterační metoda je dána formulí

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

Pro přesné řešení  $\mathbf{x}^*$  musí platit

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

Definice: Iterační metodu  $\mathbf{x}^{(k+1)} = \mathbf{H}\mathbf{x}^{(k)} + \mathbf{g}$  nazveme **konzistentní**, pokud platí (\*).

Poznámka: Uvedené metody jsou konzistentní.

- např. pro Jacobiovu metodu musí platit:

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

$$\mathbf{A}^{-1}\mathbf{b} = \underbrace{\mathbf{D}^{-1} \left( \underbrace{-(\mathbf{L} + \mathbf{U}) + \mathbf{A}}_{\mathbf{D}} \right)}_{\mathbf{I}} \mathbf{A}^{-1}\mathbf{b}$$

- D.cz: Ukažte, že Gauss-Seidelova metoda a metoda SOR jsou konzistentní.

Definice: Iterační metoda  $\mathbf{x}^{(k+1)} = \mathbf{H}\mathbf{x}^{(k)} + \mathbf{g}$  se nazývá **konvergentní**, jestliže pro každou počáteční approximaci  $\mathbf{x}^{(0)} \in \mathbb{R}$  platí:

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

Chyba  $k$ -té iterace:

$$\mathbf{e}^{(k)} = \mathbf{x}^{(k)} - \mathbf{x}^*.$$

### Nutná a postačující podmínka konvergence metody

iterační předpis

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

konzistentní metoda

$$\mathbf{x}^* = \mathbf{H}\mathbf{x}^* + \mathbf{g}$$

po odečtení dostáváme

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

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

Platí:

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

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

**Věta:** Daná konzistentní iterační metoda  $\mathbf{x}^{k+1} = \mathbf{H}\mathbf{x}^{(k)} + \mathbf{g}$  konverguje pro libovolné  $\mathbf{x}^{(0)} \in \mathbb{R}^n$  právě tehdy, když je **stabilní**, tj.

$$\varrho(\mathbf{H}) = \max_i |\lambda_i(\mathbf{H})| < 1,$$

kde číslo  $\varrho(\mathbf{H})$  nazýváme **spektrální poloměr** matice  $\mathbf{H}$  a  $\lambda_i(\mathbf{H})$  jsou vlastní čísla matice  $\mathbf{H}$ .

Poznámka: Připomeňme souvislost s metodou prosté iterace pro řešení soustav nelineárních rovnic. Funkce  $\Phi(\mathbf{x})$  z přepisu  $\mathbf{x} = \Phi(\mathbf{x})$  musela splňovat podmínuku  $(b') \dots$  (pokud byla diferencovatelná)

$$\exists q \in (0, 1) : \|\Phi'(\mathbf{x})\| \leq q \quad \forall \mathbf{x}$$

V našem případě je

$$\Phi(\mathbf{x}) = \mathbf{H}\mathbf{x} + \mathbf{g} \Rightarrow \Phi'(\mathbf{x}) = \mathbf{H}.$$

Tj.

$$\|\mathbf{H}\| < 1.$$

Spektrální poloměr  $\varrho(\mathbf{H})$  je také normou matice  $\mathbf{H}$ , tj.

$$\varrho(\mathbf{H}) < 1.$$

Předchozí věta je silnější (kritérium)

$$\Leftrightarrow$$

Věta pro prostou iteraci uváděla postačující podmínky

$$\Rightarrow$$

Poznámka: Určovat  $\varrho(\mathbf{H})$  je celkem drahé, proto za chvíli uvedeme větu (postačující podmínky) jejíž předpoklady se ověří snadněji.

Definice:

Maticovou normu  $\|\cdot\|$  nazveme **multiplikativní**, splňuje-li pro všechny čtvercové matice  $\mathbf{A}, \mathbf{B}$  řádu  $n$  vztah

$$\|\mathbf{A} \cdot \mathbf{B}\| \leq \|\mathbf{A}\| \cdot \|\mathbf{B}\|$$

## Příklad 2

Řešme soustavu  $\mathbf{Ax} = \mathbf{b}$  Jacobiovou metodou.

$$\mathbf{A} = \begin{bmatrix} 1 & 0,9 & 0,9 \\ 0,9 & 1 & 0,9 \\ 0,9 & 0,9 & 1 \end{bmatrix}, \quad \mathbf{b} = \begin{bmatrix} 2,8 \\ 2,8 \\ 2,8 \end{bmatrix}, \quad \text{přesné řešení } \mathbf{x}^* = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix}$$

$$\mathbf{H} = \begin{bmatrix} 0 & -0,9 & -0,9 \\ -0,9 & 0 & -0,9 \\ -0,9 & -0,9 & 0 \end{bmatrix}$$

... vlastní čísla jsou  $-1,8; 0,9; 0,9 \Rightarrow \varrho(\mathbf{H}) = 1,8 > 1 \Rightarrow$  metoda diverguje !!!

Uvažujme normu  $\|\mathbf{H}\|_M = \max_{i,j} |h_{ij}|$

D.cz. Ukažte, že  $\|\cdot\|_M$  splňuje vlastnosti normy.

$$\|\mathbf{H}\|_M = 0,9 < 1 \quad !!!$$

$\|\cdot\|_M$  není multiplikativní:

např:

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

$$\|\mathbf{A}\|_M = 1, \quad \|\mathbf{B}\|_M = 2, \quad \|\mathbf{A} \cdot \mathbf{B}\|_M = 4$$

$$\|\mathbf{A}\|_M \cdot \|\mathbf{B}\|_M = 2 \underbrace{<}_{!!!} \|\mathbf{A} \cdot \mathbf{B}\|_M = 4$$

**Věta:** Pro každou multiplikativní maticovou normu  $\|\cdot\|$  a čtvercovou matici  $\mathbf{A}$  platí:

$$\varrho(\mathbf{A}) \leq \|\mathbf{A}\|.$$

Důkaz:

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

- nechť číslu  $\lambda_p$  odpovídá normovaný vlastní vektor  $\mathbf{v}_p \quad (\nu(\mathbf{v}_p) = 1)$
- potom

$$\varrho(\mathbf{A}) = |\lambda_p| \cdot \nu(\mathbf{v}_p) = \nu(\lambda_p \mathbf{v}_p) = \nu(\mathbf{A} \mathbf{v}_p)$$

vlastnost kompatibilní maticové a vektorové normy:

$$\nu(\mathbf{A} \mathbf{v}_p) \leq \|\mathbf{A}\| \cdot \nu(\mathbf{v}_p) = \|\mathbf{A}\| \cdot 1 = \|\mathbf{A}\|$$

Pomocná věta: Ke každé multiplikativní maticové normě  $\mu$  existuje kompatibilní vektorová norma  $\nu$ .

Důkaz: Je dána maticová norma  $\mu$ .

Definujeme  $\nu(\mathbf{x}) = \mu([\mathbf{x}, 0, 0, \dots, 0]) \dots$  splňuje vlastnosti normy

? kompatibilita:

$$\nu(\mathbf{A}\mathbf{x}) = \mu([\mathbf{A}\mathbf{x}, 0, 0, \dots, 0]) = \mu(\mathbf{A}[\mathbf{x}, 0, 0, \dots, 0]) \underset{(*)}{\leq} \mu(\mathbf{A})\mu([\mathbf{x}, 0, 0, \dots, 0]) = \mu(\mathbf{A}) \cdot \nu(\mathbf{x})$$

(\*)  $\mu$  je multiplikativní

### Věta (Postačující podmínka konvergence)

Je-li pro multiplikativní normu splněna podmínka  $\|\mathbf{H}\| \leq q < 1$ , potom posloupnost  $\{\mathbf{x}^{(k)}\}$  určená konzistentní formulí

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

konverguje při libovolné volbě vektoru  $\mathbf{x}^{(0)} \in \mathbb{R}^n$  a platí

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

Důkaz: Důsledek kritéria a předchozí věty (jiný důkaz viz skripta).

### 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

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

### Příklad 3

Jacobiovou metodou řešte soustavu  $\mathbf{Ax} = \mathbf{b}$ .

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

$$\mathbf{A} = \underbrace{\begin{bmatrix} 0 & 0 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}}_{\mathbf{L}} + \underbrace{\begin{bmatrix} 8 & 0 & 0 \\ 0 & 10 & 0 \\ 0 & 0 & 2 \end{bmatrix}}_{\mathbf{D}} + \underbrace{\begin{bmatrix} 0 & 4 & 2 \\ 0 & 0 & 1 \\ 0 & 0 & 0 \end{bmatrix}}_{\mathbf{U}}$$

$$\mathbf{H}_J = -\mathbf{D}^{-1}(\mathbf{L} + \mathbf{U}) = \begin{bmatrix} 0 & -0,5 & -0,25 \\ -0,1 & 0 & -0,1 \\ 0 & 0 & 0 \end{bmatrix}, \quad \mathbf{g}_J = \mathbf{D}^{-1}\mathbf{b} = \begin{bmatrix} 1,75 \\ 1,2 \\ 1 \end{bmatrix}$$

Provedeme 5 iterací:

$k$	$x_1^k$	$x_2^k$	$x_3^k$
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

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

Odhadněme chybu  $\mathbf{x}^{(5)}$ , tj.

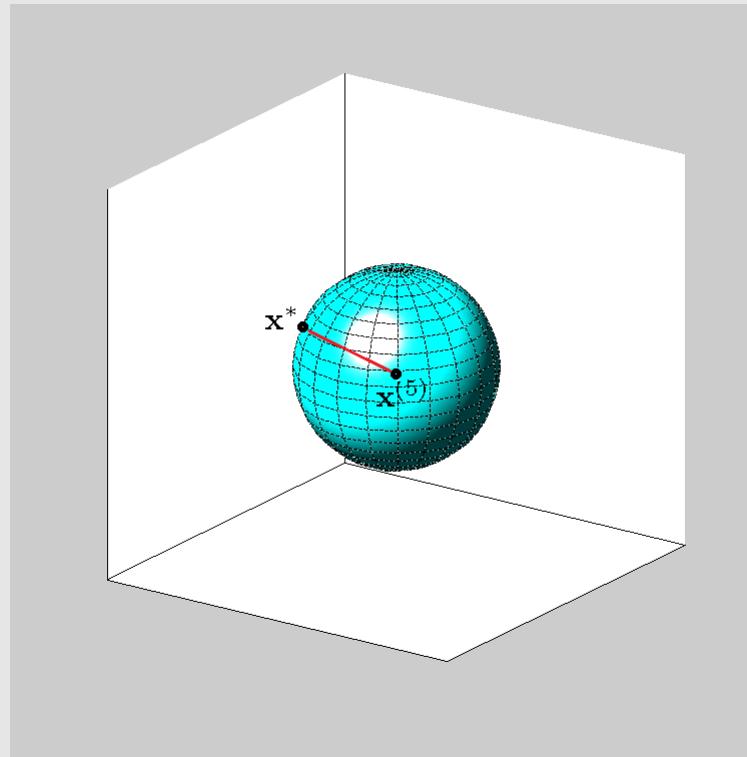
$$\|\mathbf{x}^{(5)} - \mathbf{x}^*\| \leq \frac{\|\mathbf{H}\|}{1 - \|\mathbf{H}\|} \cdot \|\mathbf{x}^{(5)} - \mathbf{x}^{(4)}\|$$

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

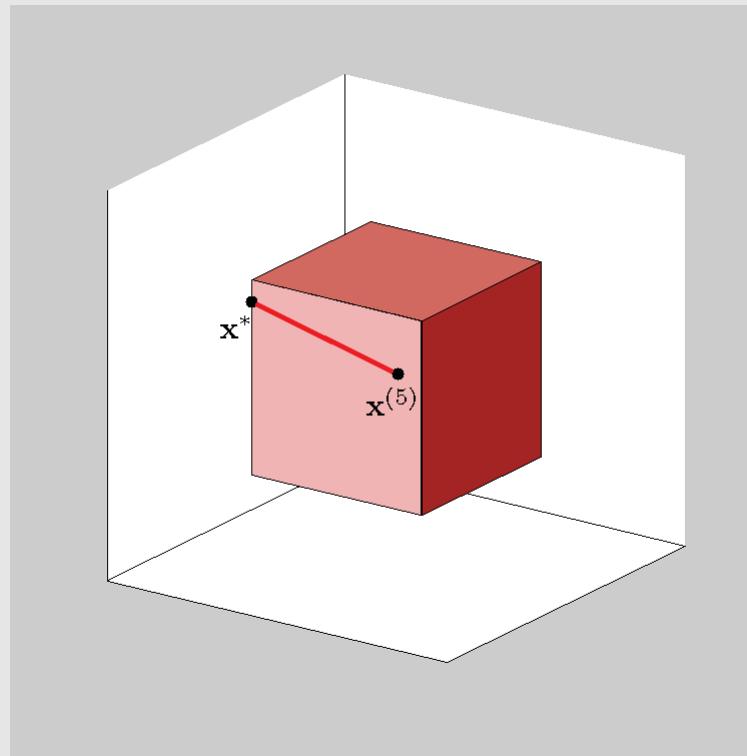
### Geometrický význam

$$\|\mathbf{x}^{(5)} - \mathbf{x}^*\|_2 \leq 0,0103$$

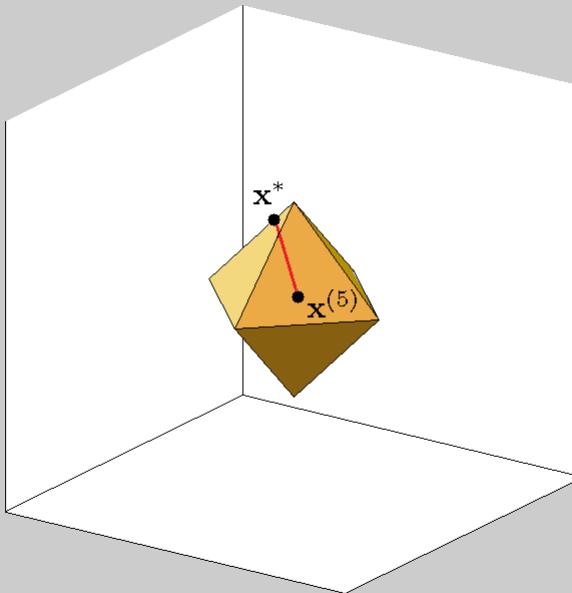
vzdálenost  $\mathbf{x}^{(5)}$  a  $\mathbf{x}^*$  je menší než vypočtená hodnota



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



$$\|\mathbf{x}^{(5)} - \mathbf{x}^*\|_1 \leq 0,011125$$



### Rychlosť konvergencie

- Lineárni rychlosť konvergencie

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

- Superlineárni rychlosť konvergencie

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

- Konvergencie řadu  $r$

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

Poznámka:

- Jacobiova, Gauss-Seidelova i SOR metoda mají lineárni rychlosť konvergencie

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

během výpočtu se nemění iterační matice  $H$ , jedná se o **stacionárni metody**

$$\|H\| \leq q, \quad \|H\| \dots \text{pevné číslo}$$

- Metody se superlineárni rychlosť konvergencie patří mezi **nestacionárni 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 superlineárni metodu.

Definujeme asymptotickou rychlosť konvergencie

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

ta určuje počet platných desetinných míst získaných v jednom iteračním kroku.

Prakticky:

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

**Poznámka:** Pro metody s lineární rychlostí konvergence (Jacobiova, Gauss-Seidelova, SOR metoda) lze pro urychlení použít **Aitkenovu extrapolaci formuli** (viz dříve).

Posloupnost chyb je geometrická

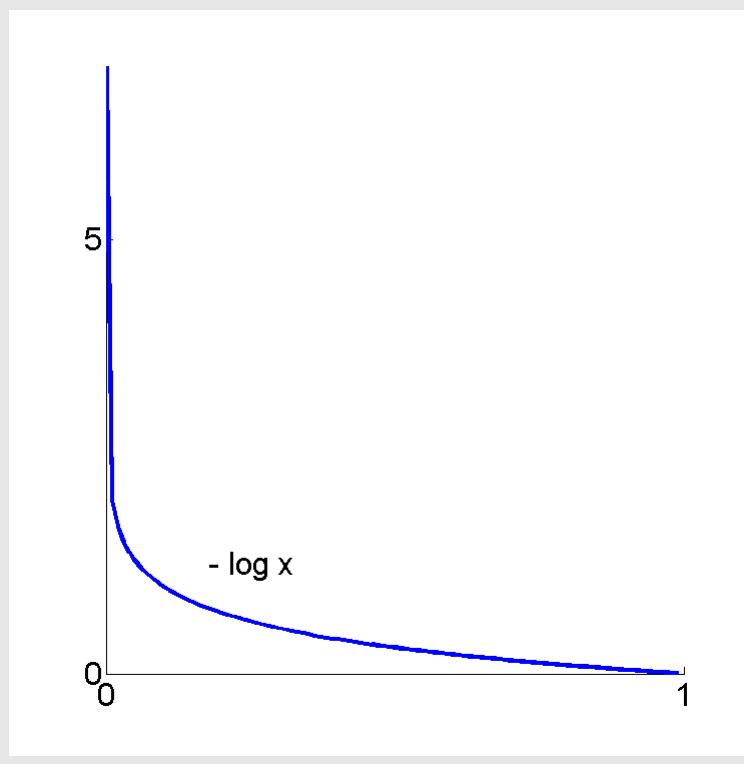
$$\mathbf{e}^{(k)} = \mathbf{H}\mathbf{e}^{(k-1)}$$

$$\frac{\overbrace{x_i^{(k+1)} - x_i^*}^{e_i^{(k+1)}}}{\underbrace{x_i^{(k)} - x_i^*}_{e_i^{(k)}}} \approx \frac{\overbrace{x_i^{(k)} - x_i^*}^{e_i^{(k)}}}{\underbrace{x_i^{(k-1)} - x_i^*}_{e_i^{(k-1)}}}$$

po úpravě:

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

Při odvození metody SOR jsme se pokusili urychlit výpočet změnou iterační matice  $\mathbf{H}$  tak, aby měla menší spektrální poloměr  $\varrho(\mathbf{H})$ . Čím menší je  $\varrho(\mathbf{H})$ , tím je větší asymptotická rychlosť konvergence.



**Věta:** Spektrální poloměr  $\varrho(\mathbf{H}_{SOR})$  splňuje podmínu

$$\varrho(\mathbf{H}_{SOR}) \geq |\omega - 1| \quad \forall \omega \in \mathbb{R}$$

Důkaz:

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

Je známo, že součin vlastních čísel je roven determinantu

$$\prod_{i=1}^n \lambda_i = \det(\mathbf{H}_{SOR})$$

$$\det(\mathbf{H}_{SOR}) = \det [(\omega \mathbf{L} + \mathbf{D})^{-1} [(1 - \omega) \mathbf{D} - \omega \mathbf{U}]] = \det \left[ (\mathbf{D}(\omega \mathbf{D}^{-1} \mathbf{L} + \mathbf{I}))^{-1} \mathbf{D} [(1 - \omega) \mathbf{I} - \omega \mathbf{D}^{-1} \mathbf{U}] \right] =$$

$$= \det \left[ (\omega \mathbf{D}^{-1} \mathbf{L} + \mathbf{I})^{-1} [(1 - \omega) \mathbf{I} - \omega \mathbf{D}^{-1} \mathbf{U}] \right] = \det \underbrace{(\omega \mathbf{D}^{-1} \mathbf{L} + \mathbf{I})^{-1}}_{(*)} \cdot \det \underbrace{[(1 - \omega) \mathbf{I} - \omega \mathbf{D}^{-1} \mathbf{U}]}_{(**)} = (1 - \omega)^n$$

(\*) dolní trojúhelníková matice s 1 na diagonále

(\*\*) horní trojúhelníková matice a prvky  $(1 - \omega)$  na diagonále

$$\prod_{i=1}^n \lambda_i = (1 - \omega)^n \quad \xrightarrow{(***)} \quad \underbrace{\max_i |\lambda_i|}_{\varrho(\mathbf{H}_{SOR})} \geq |1 - \omega|$$

(\*\*\*) Důkaz sporem:  $\forall \lambda_i: |\lambda_i| < |1 - \omega| \quad / \prod_{i=1}^n$

$$\prod_{i=1}^n |\lambda_i| < |1 - \omega|^n$$

**Důsledek:** Aby SOR konvergovala, musí platit:

$$|\omega - 1| \leq \varrho(\mathbf{H}_{SOR}) < 1$$

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

Poznámky:

Parametr  $\omega$  v relaxační metodě SOR volíme z intervalu  $(0, 2)$ .

Pro  $\omega = 1$  přejde relaxační metoda na Gauss-Seidlovu metodu.

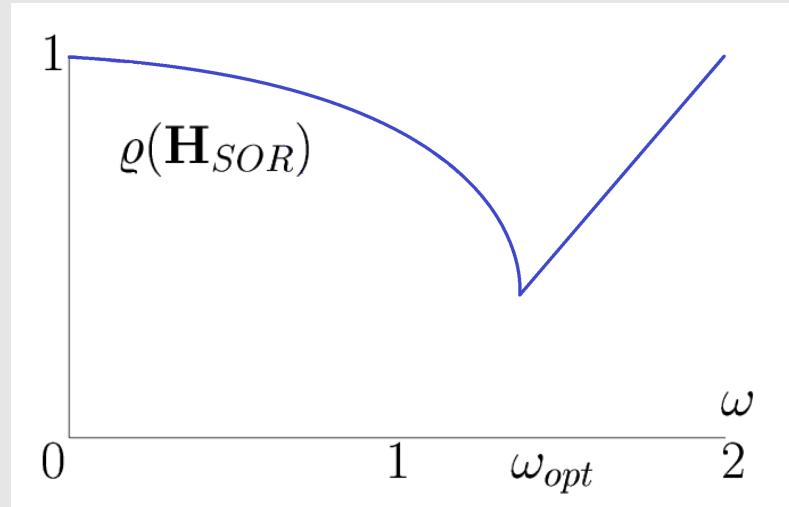
Volba parametru  $\omega$  samozřejmě ovlivní rychlosť konvergence iteračního procesu metody SOR.  
Lze ukázat, že existuje optimální hodnota parametru omega

$$\omega_{opt} = \frac{2}{1 + \sqrt{1 - \varrho^2(\mathbf{H}_J)}},$$

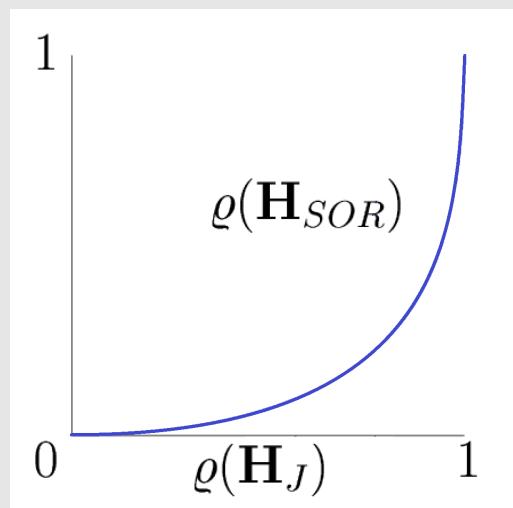
kde  $\varrho(\mathbf{H}_J)$  je spektrální poloměr Jacobovy iterační matice  $\mathbf{H}_J$ .

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

- závislost spektrálního poloměru iterační matice metody SOR na relaxačním parametru  $\omega$



- závislost spektrálního poloměru iterační matice metody SOR na spektrálním poloměru iterační matice Jacobovy metody



## Konvergenční věty

Dosud jsme udávali podmínky pro iterační matici  $\mathbf{H}$ . To je ovšem nepraktické. Uvedeme několik snadněji ověřitelných podmínek.

**Věta 1** Je-li matice  $\mathbf{A}$  ostře diagonálně-dominantní, potom konverguje Jacobova i Gauss-Seidelova metoda pro libovolnou volbu  $\mathbf{x}^{(0)}$ .

**Věta 2** Je-li matice  $\mathbf{A}$  symetrická a pozitivně-definitní, potom Gauss-Seidelova metoda konverguje pro libovolnou volbu  $\mathbf{x}^{(0)}$ .

**Věta 3** Nutnou podmínkou konvergence metody SOR je  $0 < \omega < 2$ . Přidáme-li symetrii a pozitivní definitnost matice  $\mathbf{A}$ , dostaneme postačující podmínky konvergence.

Důkaz Věty 1 pro Jacobovu metodu:

$$\mathbf{A}\mathbf{x} = \mathbf{b}, \quad \text{rozklad matice } \mathbf{A} = \mathbf{L} + \mathbf{D} + \mathbf{U}$$

označíme-li  $\mathbf{C} = \mathbf{L} + \mathbf{U}$ , potom  $\mathbf{A} = \mathbf{C} + \mathbf{D}$

- Jacobiova metoda

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

$$\mathbf{H}_J = -\mathbf{D}^{-1}(\mathbf{L} + \mathbf{U}) = -\mathbf{D}^{-1}\mathbf{C} \quad \text{a} \quad \mathbf{g}_J = \mathbf{D}^{-1}\mathbf{b}$$

- Matice  $\mathbf{A}$  je ostře diagonálně-dominantní, tj. platí

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

- Pro náš rozklad  $\mathbf{A} = \mathbf{C} + \mathbf{D}$  tedy platí:

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

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

- Platí:

$$\boxed{\sum_{j=1}^n \frac{|c_{ij}|}{|d_{ii}|} < 1} \quad \text{pro } i = 1, 2, \dots, n \quad (*)$$

- Pro iterační matici platí:

$$\mathbf{H}_J = -\mathbf{D}^{-1}\mathbf{C} = - \begin{bmatrix} \frac{1}{d_{11}} & & & \\ & \frac{1}{d_{22}} & & \\ & & \ddots & \\ & & & \frac{1}{d_{nn}} \end{bmatrix} \cdot \begin{bmatrix} c_{11} \\ c_{21} \\ \vdots \\ c_{n1} \end{bmatrix} = - \begin{bmatrix} \frac{c_{11}}{d_{11}} \\ \frac{c_{21}}{d_{22}} \\ \vdots \\ \frac{c_{n1}}{d_{nn}} \end{bmatrix}$$

- Řádková norma matice  $\mathbf{H}_J$ :

$$\|\mathbf{H}_J\| = \max_i \sum_{j=1}^n \left| \frac{c_{ij}}{d_{ii}} \right| < 1 \quad \text{plyne z } (*)$$

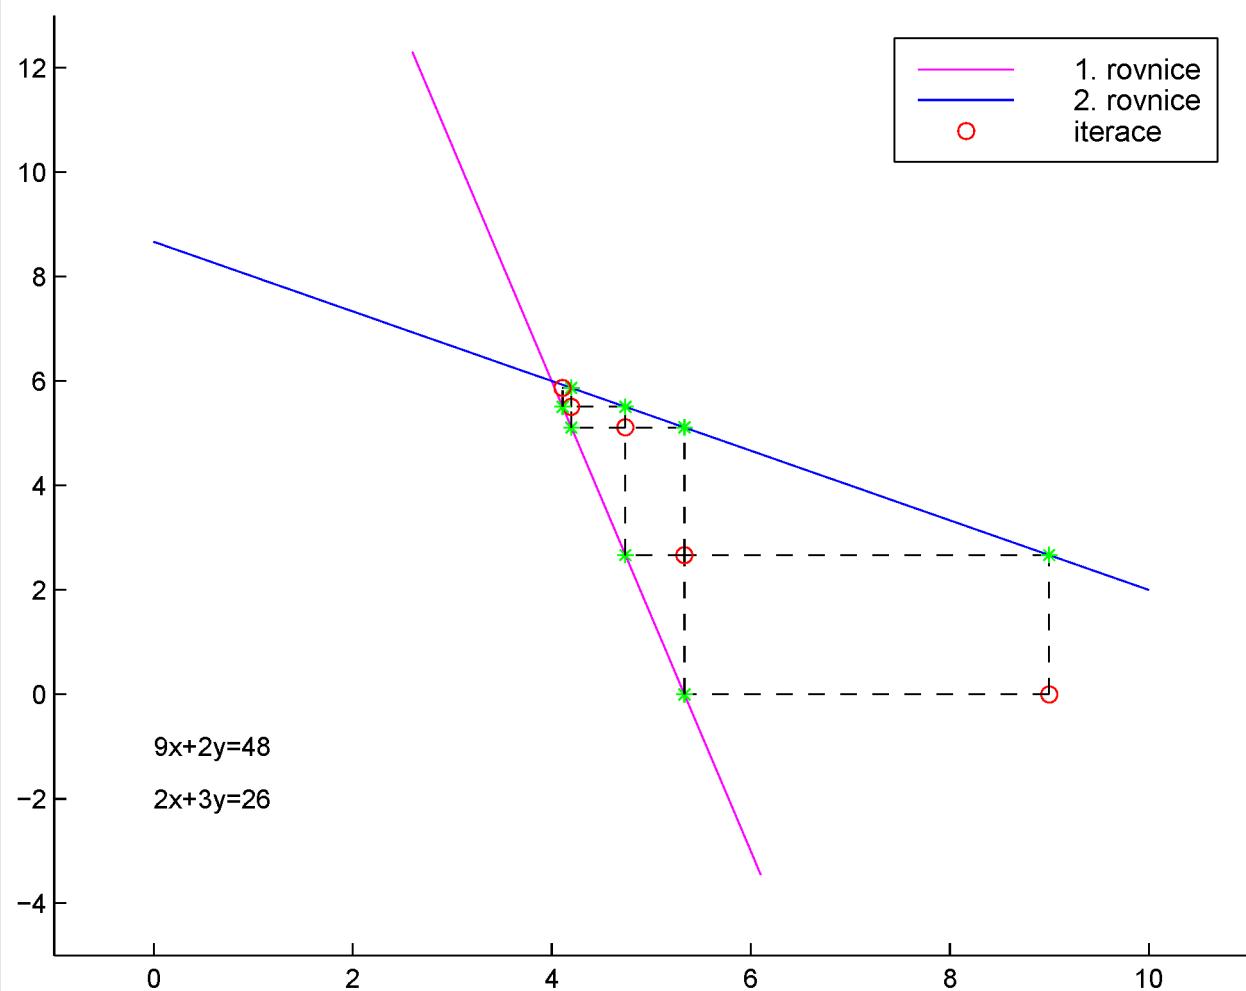
### Geometrický význam Jacobiovy metody

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

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

$k$	$x^{(k)}$	$y^{(k)}$
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

## Jacobiova metoda



## Geometrický význam Gauss-Seidelovy metody

$$9x + 2y = 48$$

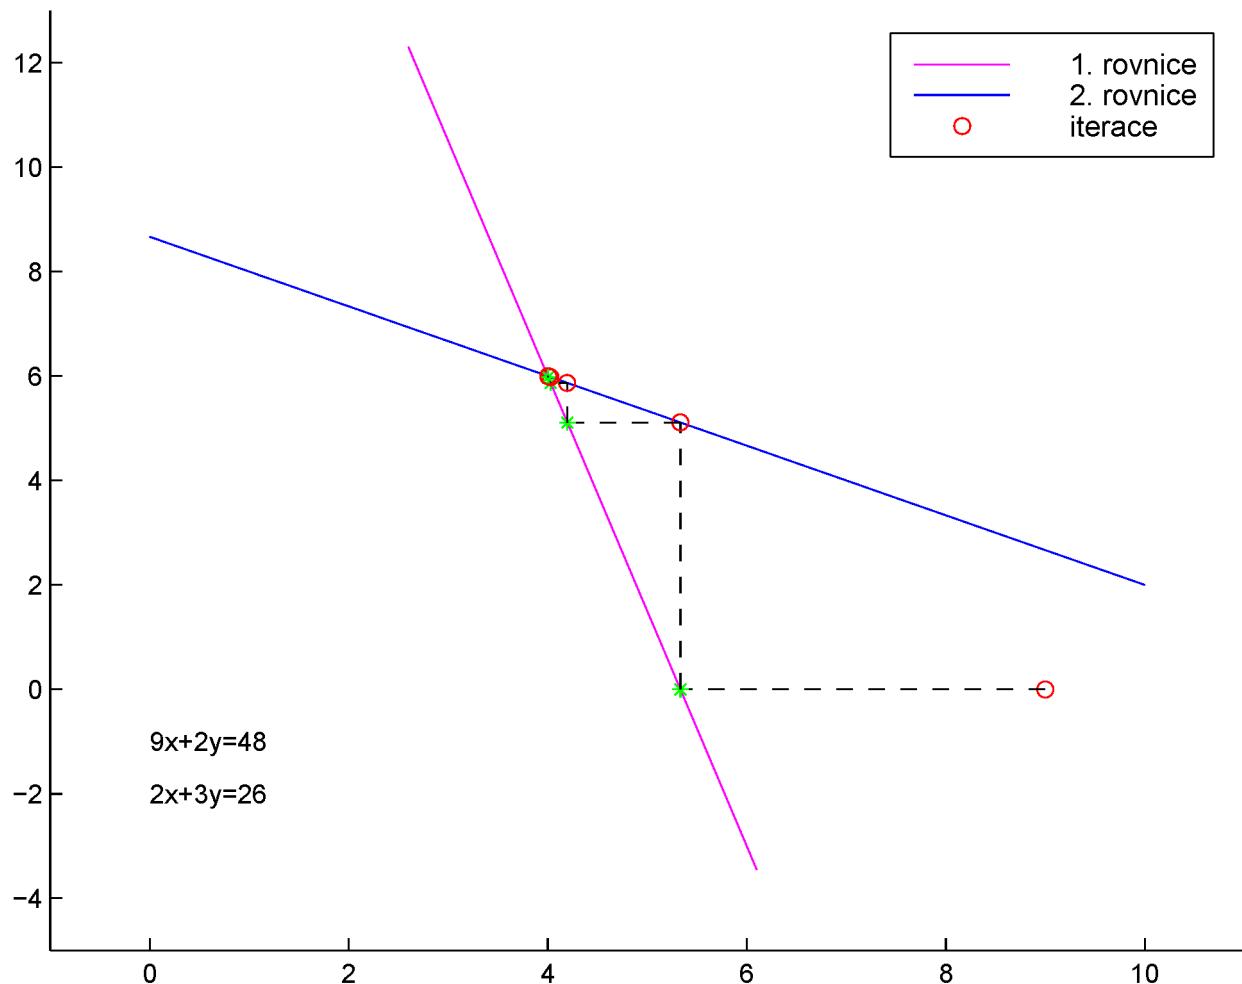
$$x^{(k+1)} = \frac{1}{9}(48 - 2y^{(k)})$$

$$2x + 3y = 26$$

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

$k$	$x^{(k)}$	$y^{(k)}$
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

## Gauss-Seidelova metoda

Geometrický význam metody SOR ( $\omega < 1$ )

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

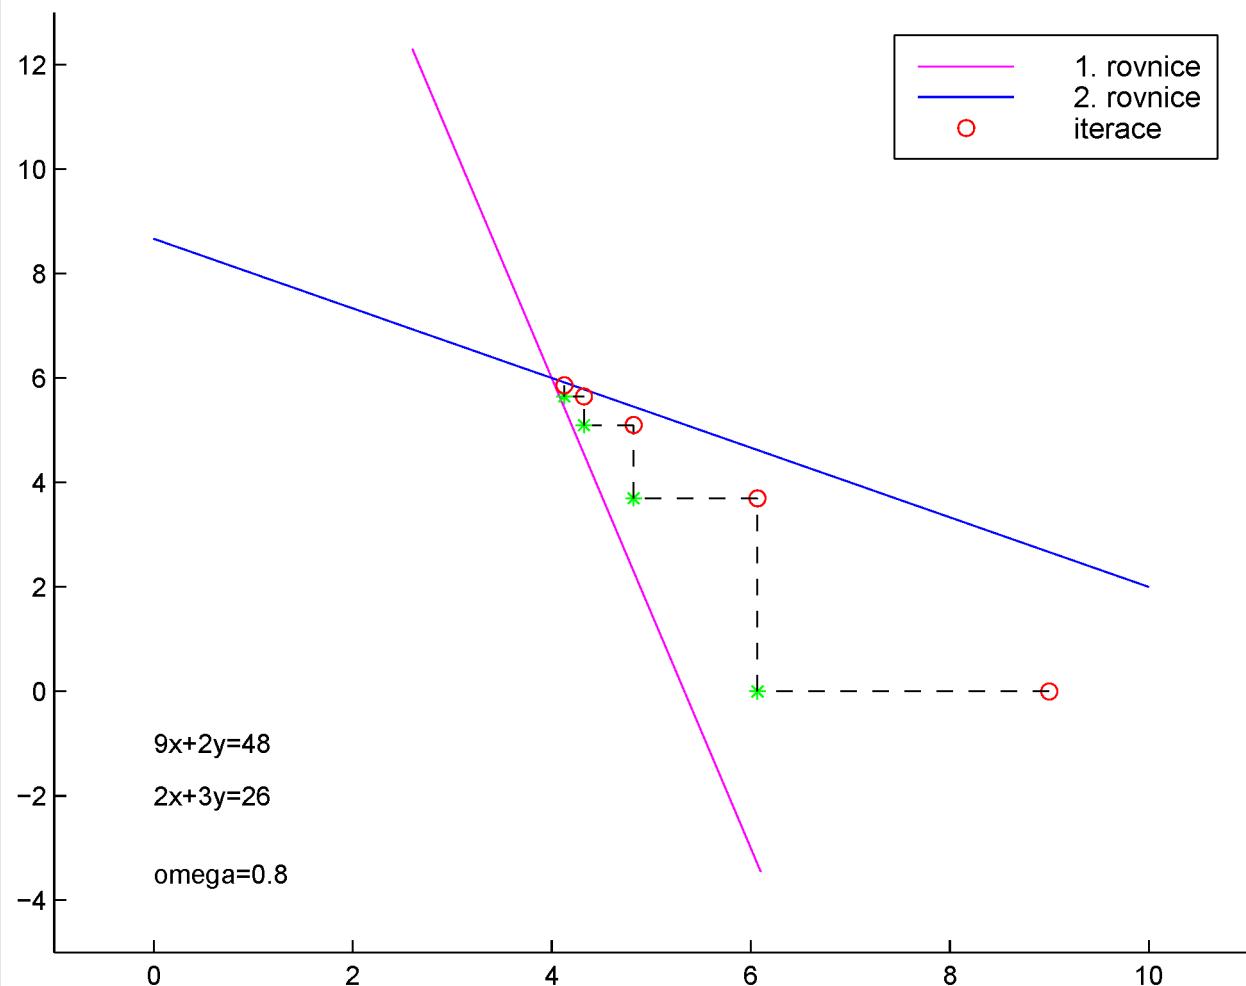
$$2x + 3y = 26 \quad y_{GS}^{(k+1)} = \frac{1}{3}(26 - 2x^{(k+1)})$$

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

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

$k$	$x^{(k)}$	$y^{(k)}$
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

## Metoda SOR

Geometrický význam metody SOR ( $\omega > 1$ )

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

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

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

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

$k$	$x^{(k)}$	$y^{(k)}$
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

## Metoda SOR

