

## Iterační metody řešení soustav lineárních rovnic

Matice je:

- **diagonálně dominantní** právě tehdy, když  $|a_{ii}| > \sum_{j=1, j \neq i}^n |a_{ij}|$
- **pozitivně definitní** (symetrická matice) právě tehdy, když pro  $\forall \vec{x} \neq \vec{0}$  platí  $(\vec{x}, A\vec{x}) > 0$ .

Tyto vlastnosti budou důležité pro zaručení konvergence iteračních metod.

Postup:

- zvolí odhad řešení  $\vec{x}^{(0)}$  (pokud odhad neznáme tak libovolné číslo)
- předpokládáme  $\vec{x}^{(k+1)} = B_k \vec{x}^{(k)} + \vec{c}_k$
- pro správné řešení musí platit  $\vec{x} = B_k \vec{x} + \vec{c}_k$ , tedy  $\vec{x}^{(k+1)} - \vec{x} = B_k (\vec{x}^{(k)} - \vec{x}) = B_k B_{k-1} (\vec{x}^{(k-1)} - \vec{x}) = B_k \dots B_0 (\vec{x}^{(0)} - \vec{x})$  - požadujeme, aby pro rostoucí  $k$  šlo k 0
- pro konvergenci je tedy nutné a stačí, aby  $\lim_{k \rightarrow \infty} B_k \dots B_0 = 0$

Metody:

- **nestacionární** – matice  $B$  v každém kroku jiná
- **stacionární** – matice  $B$  pořád stejná

### Nestacionární metoda – Řízená relaxace

Řešíme soustavu  $A\vec{x} = \vec{b}$ . Na počátku odhadneme řešení libovolně  $\vec{x}^{(0)}$ . Spočítáme reziduum  $A\vec{x}^{(0)} - \vec{b}$  a určíme jeho v absolutní hodnotě maximální složku. Potom volíme matici  $B$  tak, abychom tuto složku vynulovali. Například pro soustavu  $3 \times 3$ , kde maximální je druhá složka, je to  $a_{21}x_1^{(0)} + a_{22}x_2^{(0)} + a_{23}x_3^{(0)} - b_2$ .

Požadujeme tedy, aby v následujícím kroku platilo  $a_{21}x_1^{(1)} + a_{22}x_2^{(1)} + a_{23}x_3^{(1)} - b_2 = 0$ . Z této rovnice vyjádříme i-tou, tedy v tomto případě druhou složku  $x_2^{(1)} = \frac{1}{a_{22}}(b_2 - a_{21}x_1^{(1)} - a_{23}x_3^{(1)})$ .

Matici  $B$  a vektor  $\vec{c}$  volíme tak, aby všechny složky až na i-tou zůstaly a pro i-tou složku aby platil předcházející vztah, tedy v našem případě

$$x_2^{(1)} = \frac{1}{a_{22}}(b_2 - a_{21}x_1^{(0)} - a_{23}x_3^{(0)}) \quad . \text{ To odpovídá volbě } \mathbf{B} = \begin{pmatrix} 1 & 0 & 0 \\ -\frac{a_{21}}{a_{22}} & 0 & -\frac{a_{23}}{a_{22}} \\ 0 & 0 & 1 \end{pmatrix} \text{ a } \vec{c} = \begin{pmatrix} 0 \\ \frac{b_2}{a_{22}} \\ 0 \end{pmatrix} .$$

obecném případě tedy  $\mathbf{B} = \begin{pmatrix} 1 & 0 & \dots & \dots & \dots & 0 \\ 0 & 1 & \dots & \dots & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ -\frac{a_{i1}}{a_{ii}} & -\frac{a_{i2}}{a_{ii}} & \dots & 0 & \dots & -\frac{a_{in}}{a_{ii}} \\ \frac{a_{i1}}{a_{ii}} & \frac{a_{i2}}{a_{ii}} & \dots & 0 & \dots & \frac{a_{in}}{a_{ii}} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & \dots & \dots & \dots & 1 \end{pmatrix} \text{ a } \vec{c} = \begin{pmatrix} 0 \\ 0 \\ \vdots \\ \frac{b_i}{a_{ii}} \\ \frac{a_{i1}}{a_{ii}} \\ \vdots \\ 0 \end{pmatrix} .$

Tato metoda je výpočetně náročná, neboť je v každém kroku nutné hledat maximum rezidua. Proto se v praxi nepoužívá.

### Stacionární metody

#### (Prostá iterace, Jakobiho, Gauss-Seidlova a Superrelaxační metoda)

#### ● Konvergence stacionárních metod

Vlastní číslo  $\lambda$  matice  $\mathbf{B}$  je číslo takové, že k němu existuje nenulový vlastní vektor, pro který platí  $\mathbf{B}\vec{x} = \lambda\vec{x}$ .

Nutná a postačující podmínka konvergence stacionárních iteračních metod je, že spektrální poloměr matice  $\mathbf{B}$  musí být menší než 1. Jinými slovy pro všechna vlastní čísla  $\lambda_i$  matice  $\mathbf{B}$  musí platit  $\rho(\mathbf{B}) = \max_{i=1, \dots, n} |\lambda_i| < 1$ .

Postačující podmínka konvergence metody pak je, že v některé maticové normě platí  $\|\mathbf{B}\| < 1$ .

(Z této podmínky samozřejmě plyne podmínka předcházející, neboť

$$|\lambda| \|\vec{x}\| = \|\lambda \vec{x}\| = \|\mathbf{B} \vec{x}\| \leq \|\mathbf{B}\| \cdot \|\vec{x}\|, \text{ tedy } |\lambda| \leq \|\mathbf{B}\| < 1 .)$$

Proč požadujeme  $\max_{i=1, \dots, n} |\lambda_i| < 1$ ? Nějaká věta říká, že pro matici  $\mathbf{B}$  platí následující ekvivalence  $\lim_{k \rightarrow \infty} \mathbf{B}^k = \mathbf{0} \Leftrightarrow \rho(\mathbf{B}) < 1$ . Pro konvergenci jsme již dříve ukázaly podmínku

$$\lim_{k \rightarrow \infty} \mathbf{B}_k \dots \mathbf{B}_0 = \mathbf{0}, \text{ tedy ve stacionárním případě } \lim_{k \rightarrow \infty} \mathbf{B}_k \dots \mathbf{B}_0 = \lim_{k \rightarrow \infty} \mathbf{B}^k = \mathbf{0} .$$

Přesnost řešení můžeme odhadnout jako

$$\|\vec{x}^{(k)} - \vec{x}\| = \|\vec{x}^{(k)} - \mathbf{A}^{-1} \vec{b}\| = \|\mathbf{A}^{-1} (\mathbf{A} \vec{x}^{(k)} - \vec{b})\| \leq \|\mathbf{A}^{-1}\| \cdot \|\mathbf{A} \vec{x}^{(k)} - \vec{b}\| .$$

#### ● Prostá iterace

Rovnici  $\mathbf{A} \vec{x} = \vec{b}$  můžeme přepsat jako  $\vec{x} = (\mathbf{I} - \mathbf{A}) \vec{x} + \vec{b}$ .

Prostá iterace je založena právě na tomto vzorci, tedy  $\vec{x}^{(k+1)} = (\mathbf{I} - \mathbf{A})\vec{x}^{(k)} + \vec{b}$ .

Jako matice  $\mathbf{B}$  je tedy volena matice  $\mathbf{I} - \mathbf{A}$  a jako vektor  $\vec{c}$  je volen vektor  $\vec{b}$ .

Přesnost můžeme odhadnout následovně:

$$\begin{aligned}\vec{x}^{(k)} &= \mathbf{B}\vec{x}^{(k-1)} + \vec{b} = \\ &= \mathbf{B}(\mathbf{B}\vec{x}^{(k-2)} + \vec{b}) + \vec{b} = \\ &= \mathbf{B}^2\vec{x}^{(k-2)} + \mathbf{B}\vec{b} + \vec{b} = \dots = \\ &= \mathbf{B}^k\vec{x}^{(0)} + \mathbf{B}^{k-1}\vec{b} + \mathbf{B}^{k-2}\vec{b} + \dots + \vec{b}\end{aligned}$$

Platí dále implikace : jestliže  $\rho(\mathbf{B}) < 1$ , pak  $\lim_{m \rightarrow \infty} \mathbf{I} + \mathbf{B} + \mathbf{B}^2 + \dots + \mathbf{B}^m = (\mathbf{I} - \mathbf{B})^{-1}$ .

(v podstatě jde o geometrickou posloupnost matic)

Pro řešení  $\vec{x}$  pak z předchozího platí  $\vec{x} = \mathbf{A}^{-1}\vec{b} = (\mathbf{I} - \mathbf{B})^{-1}\vec{b} = (\mathbf{I} + \mathbf{B} + \mathbf{B}^2 + \dots)\vec{b}$ .

$$\begin{aligned}\|\vec{x}^{(k)} - \vec{x}\| &= \|\mathbf{B}^k\vec{x}^{(0)} + (\mathbf{I} + \mathbf{B} + \dots + \mathbf{B}^{k-1})\vec{b} - (\mathbf{I} + \mathbf{B} + \mathbf{B}^2 + \dots)\vec{b}\| = \\ &= \|\mathbf{B}^k\vec{x}^{(0)} - (\mathbf{B}^k + \mathbf{B}^{k+1} + \dots)\vec{b}\| = \\ &= \|\mathbf{B}^k(\vec{x}^{(0)} - (\mathbf{I} + \mathbf{B} + \mathbf{B}^2 + \dots)\vec{b})\| \leq \\ &\leq \|\mathbf{B}^k\| \cdot \|\vec{x}^{(0)} - (\mathbf{I} + \mathbf{B} + \mathbf{B}^2 + \dots)\vec{b}\| \leq \\ &\leq \|\mathbf{B}\|^k \cdot \|\vec{x}^{(0)} - (\mathbf{I} + \mathbf{B} + \mathbf{B}^2 + \dots)\vec{b}\| \leq \\ &\leq \|\mathbf{B}\|^k \cdot [\|\vec{x}^{(0)}\| + (\|\mathbf{I}\| + \|\mathbf{B}\| + \|\mathbf{B}^2\| + \dots)\|\vec{b}\|] \leq \\ &\leq \|\mathbf{B}\|^k \cdot \left[ \|\vec{x}^{(0)}\| + \frac{\|\vec{b}\|}{1 - \|\mathbf{B}\|} \right]\end{aligned}$$

Metoda prosté iterace se pro systémy lineárních rovnic prakticky nepoužívá.

## ● Jacobiho metoda

V čem metoda spočívá?

Hledáme řešení rovnice  $\mathbf{A} \vec{x} = \vec{b}$ . Napíšeme i-tou rovnici z této soustavy  $\sum_{j=1}^n a_{ij} x_j - b_i = 0$ . Z

této rovnice vyjádříme  $x_i$  jako  $x_i = \frac{1}{a_{ii}} \left( \sum_{j=1, j \neq i}^n a_{ij} x_j - b_i \right)$  a takto provádíme iterace

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

Jinak se to dá pro matici soustavy  $\mathbf{A}$  (řádu 3) formulovat takto.

Matice  $\mathbf{A}$  se rozloží na součet 3 matic podle následujícího vzoru.

$$\mathbf{A} = \begin{pmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{pmatrix} = \mathbf{D} + \mathbf{L} + \mathbf{R} = \begin{pmatrix} d_{11} & 0 & 0 \\ 0 & d_{22} & 0 \\ 0 & 0 & d_{33} \end{pmatrix} + \begin{pmatrix} 0 & 0 & 0 \\ l_{21} & 0 & 0 \\ l_{31} & l_{32} & 0 \end{pmatrix} + \begin{pmatrix} 0 & r_{12} & r_{13} \\ 0 & 0 & r_{23} \\ 0 & 0 & 0 \end{pmatrix}$$

Z těchto tří matic se pak vytvoří matice  $\mathbf{B}$

$$\mathbf{B} = \mathbf{D}^{-1}(\mathbf{L} + \mathbf{R}) = \begin{pmatrix} -\frac{1}{d_{11}} & 0 & 0 \\ 0 & -\frac{1}{d_{22}} & 0 \\ 0 & 0 & -\frac{1}{d_{33}} \end{pmatrix} \times \begin{pmatrix} 0 & r_{12} & r_{13} \\ l_{21} & 0 & r_{23} \\ l_{31} & l_{32} & 0 \end{pmatrix} = \begin{pmatrix} 0 & -\frac{a_{12}}{a_{11}} & -\frac{a_{13}}{a_{11}} \\ -\frac{a_{21}}{a_{22}} & 0 & -\frac{a_{23}}{a_{22}} \\ -\frac{a_{31}}{a_{33}} & -\frac{a_{32}}{a_{33}} & 0 \end{pmatrix}$$

a vektor  $\vec{c}$  se definuje jako

$$\vec{c} = \mathbf{D}^{-1} \vec{b} = \begin{pmatrix} \frac{b_1}{a_{11}} \\ \frac{b_2}{a_{22}} \\ \frac{b_3}{a_{33}} \end{pmatrix}.$$

Iterace se provádí podle obecného vzorce  $\vec{x}^{(k+1)} = \mathbf{B} \vec{x}^{(k)} + \vec{c}$ .

Už z formulace úlohy je patrné, že matice  $\mathbf{A}$  nesmí mít nulové diagonální prvky.

Pro Jakobiho metodu je konvergence zaručená pro matice soustavy  $A$  diagonálně dominantní:

Diagonální dominance je definována  $|a_{ii}| > \sum_{j=1, j \neq i}^n |a_{ij}|$ . Z toho plyne  $\sum_{j=1, j \neq i}^n \left| \frac{a_{ij}}{a_{ii}} \right| < 1$  a tedy pro maximovou normu matice  $B = D^{-1}(L+R)$  platí  $\|B\| < 1$ .

### ● Metoda Gauss-Seidlova

Téměř stejná, jako Jacobiho, jen vždy používáme už všechny nově spočítané složky vektoru  $\vec{x}$ . Konvergence pro poměrně širokou třídu matic  $A$ , ale může být velmi pomalá.

#### Porovnání s předchozími metodami:

Gauss-Seidl 
$$x_i^{(k+1)} = x_i^{(k)} + \frac{1}{a_{ii}} \left( -a_{i1}x_1^{(k+1)} - \dots - a_{ii-1}x_{i-1}^{(k+1)} - a_{ii}x_i^{(k)} - \dots - a_{in}x_n^{(k)} + b_i \right)$$

$$\vec{x}^{(k+1)} = \vec{x}^{(k)} - (D+L)^{-1} (A\vec{x}^{(k)} - \vec{b})$$

$$B = -(D+L)^{-1}R \quad \vec{c} = (D+L)^{-1}\vec{b}$$

konvergence zaručena  $A$  diagonálně dominantní nebo pozitivně definitní

přímá iterace 
$$x_i^{(k+1)} = x_i^{(k)} - a_{i1}x_1^{(k)} - a_{i2}x_2^{(k)} - \dots - a_{in}x_n^{(k)} + b_i$$

$$\vec{x}^{(k+1)} = \vec{x}^{(k)} - (A\vec{x}^{(k)} - \vec{b})$$

$$B = (I-A) \quad \vec{c} = \vec{b}$$

Jacobiho metoda 
$$x_i^{(k+1)} = x_i^{(k)} + \frac{1}{a_{ii}} \left( -a_{i1}x_1^{(k)} - a_{i2}x_2^{(k)} - \dots - a_{in}x_n^{(k)} + b_i \right)$$

$$\vec{x}^{(k+1)} = \vec{x}^{(k)} - D^{-1} (A\vec{x}^{(k)} - \vec{b})$$

$$B = -D^{-1}(L+R) \quad \vec{c} = D^{-1}\vec{b}$$

konvergence zaručena  $A$  diagonálně dominantní

### ● Superrelaxační metoda

Vlastně urychlení konvergence Gauss-Seidlové metody. V Gauss-Seidlově metodě označíme

$$\Delta \vec{x}^{(k)} = \vec{x}^{(k+1)} - \vec{x}^{(k)}. \text{ V Gauss-Seidlově metodě tedy platí } \vec{x}^{(k+1)} = \vec{x}^{(k)} + \Delta \vec{x}^{(k)}.$$

Superrelaxační metoda pak tento vztah přeformuluje takto  $\vec{x}^{(k+1)} = \vec{x}^{(k)} + \omega \Delta \vec{x}^{(k)}$ , kde  $\omega$  je z intervalu  $(0,2)$  ( $\omega < 1$  subrelaxační,  $\omega > 1$  superrelaxační,  $\omega = 1$  Gauss-Seidl).

Relaxační faktor  $\omega$  slouží tedy k urychlení konvergence a jeho optimální hodnotu lze vypočítat

podle vztahu  $\omega_{opt} = \frac{2}{1 + \sqrt{1 - \rho^2(B_{GS})}}$ , kde  $B_{GS} = -(D+L)^{-1}R$  je matice  $B$  z Gauss-

Seidlové metody.

(Upozornění: V některých materiálech se matice  $L$  a  $R$  násobí  $-1$  při odvozování Gauss-Seidlovy a Superrelaxační metody.)

Příklad na Superrelaxační metodu v PASCALU **DEMRELAX.PAS** . Matice MATREL1.DAT , MATREL.DAT .

### Problém vlastních čísel

Vlastní číslo :  $\lambda$  ,  $\exists \vec{x} \neq \vec{0}$  , že  $A \vec{x} = \lambda \vec{x}$  ,  $\lambda$  vlastní číslo,  $\vec{x}$  je vlastní vektor  $A$  .

Řeší se problémy: **úplný** nebo **částečný**

Vlastní čísla lze počítat z **charakteristického polynomu** matice  $A$  -  $\det(A - \lambda I) = 0$  .

Pro matici  $n \times n$  se jedná o polynom  $n$ -tého stupně, který má tedy  $n$  kořenů (mohou být i násobné, komplexně sdružené). Ke každému vlastnímu číslu existuje alespoň jeden vlastní vektor.

Matice je **defektní** – má méně než  $n$  LN vlastních vektorů

**Normální** matice (splňuje vztah  $AA^T = A^T A$  ) má  $n$  LN vlastních vektorů.

**Symetrická** matice (  $A = A^T$  ) má všechna vlastní čísla reálná.

**Trojúhelníková** matice má vlastní čísla na diagonále.

Matice **podobné** (matice  $A$  a  $P^{-1}AP$  ) mají stejná vlastní čísla, neboť  
$$\det(P^{-1}AP - \lambda I) = \det(P^{-1}(A - \lambda I)P) = \det(P^{-1}) \det(A - \lambda I) \det(P) = \det(A - \lambda I)$$
 .

Ke každé matici existuje matice jí podobná v Jordanově normálním tvaru. K normálním maticím existuje dokonce podobná diagonální matice.

Numerické metody řešení úplného problému– transformace na přibližně diagonální nebo trojúhelníkový tvar.

#### ● **Jacobiho transformace**

Najde všechny vlastní čísla symetrické matice. Cílem metody je podobnostními transformacemi postupné zmenšování mimodiagonálních prvků.

Postup:

Nalezení v absolutní hodnotě maximálního mimodiagonálního prvku  $a_{pq}$  .

Podobnostní transformace – pootočení os, aby se čtvercová matice  $\begin{pmatrix} a_{pp} & a_{pq} \\ a_{qp} & a_{qq} \end{pmatrix}$  prvků

matice  $A$  stala diagonální. Matice transformace je  $T_{pq} = \begin{pmatrix} 1 & . & . & . & . & . & 0 \\ . & \ddots & . & . & . & . & . \\ . & . & c & \dots & -s & . & . \\ . & . & \vdots & 1 & \vdots & . & . \\ . & . & s & \dots & c & . & . \\ . & . & . & . & . & \ddots & . \\ 0 & . & . & . & . & . & 1 \end{pmatrix}$ .

Pro koeficienty  $c$ ,  $s$  platí  $c = \cos(\varphi)$ ,  $s = \sin(\varphi)$ . Po  $k$ -té iteraci je prvek matice  $A$   $a_{pq}^{(k)} = (c^2 - s^2)a_{pq}^{(k-1)} - cs(a_{pp}^{(k-1)} - a_{qq}^{(k-1)})$  a abychom ho nulovaly, musíme volit úhel  $\varphi$  jako tak, že  $\tan(2\varphi) = \frac{2a_{pq}}{a_{pp} - a_{qq}}$ .

Příklad v PASCALU **ZKJACOBI.PAS**, matice JAC1.DAT, JAC2.DAT.

## ● LU rozklad

Pomalá konvergence, nutný velký počet operací.

Provádí se rozklad  $A_k = L_k U_k$  a dále se volí  $A_{k+1} = U_k L_k$ . Matice  $U_k$  se volí jako ortogonální, tedy  $U_k^T U_k = I$ . Z toho plyne, že matice  $A_k$  a  $A_{k+1}$  jsou si podobné.

$$A_{k+1} = U_k L_k = U_k L_k U_k U_k^T = L_k U_k = A_k$$

## ● Částečný problém vlastních čísel

Hledá se nejčastěji extrémní vlastní číslo (v absolutní hodnotě největší, nejmenší).

Například metoda:

$$\vec{x}^{(k+1)} = \frac{1}{\rho_k} A \vec{x}^{(k)}, \text{ kde } \rho_k = \vec{e}_1^T A \vec{x}^{(k)} \quad (\rho_k \text{ je první složka } A \vec{x}^{(k)})$$

$$\text{platí } \lim_{k \rightarrow \infty} \rho_k = \lambda \text{ a } \lim_{k \rightarrow \infty} \vec{x}^{(k)} = \vec{x}_1$$

Nejmenší vlastní čísla matice  $A$  jsou největší matice  $A^{-1}$ .

Druhé nejmenší vlastní číslo – redukce matice na řád  $n-1$ .

Vlastní číslo v nějaké oblasti – posun  $(A + \mu I)\vec{x} = (\lambda + \mu)\vec{x}$ .

Příklad v PASCALU **CASTP.PAS**, matice např. MATREL.DAT, MATREL1.DAT ...