

Konzul. 2

Obečná  
iterační  
metoda  
Jacobiova  
metoda  
Gauss-  
Seidelova  
metoda  
SOR  
metoda  
CG  
metoda  
Soustavy  
s obdélní-  
kovou  
maticí  
SVD

## Konzultace 2

- iterační metody řešení úlohy  $Ax = b$  s regulární maticí
- řešení soustav lineárních rovnic s obdélníkovými maticemi

# Obecná iterační metoda (1)

Konzul. 2

Obecná  
iterační  
metodaJacobiova  
metodaGauss-  
Seidelova  
metodaSOR  
metodaCG  
metodaSoustavy  
s obdélní-  
kovou  
maticí

SVD

Uvažujme soustavu lineárních rovnic

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

s regulární čtvercovou maticí  $\mathbf{A} = (a_{ij})$  řádu  $n$ , vektorem pravé strany  $\mathbf{b} = (b_i)$  a vektorem neznámých  $\mathbf{x} = (x_i)$ .

Iterační metody umožňují řešit soustavy lineárních rovnic pomocí postupného přibližování k přesnému řešení. Počítá se posloupnost vektorů aproximací  $\{\mathbf{x}^{(k)}\}$  taková, že

$$\lim_{k \rightarrow \infty} \mathbf{x}^{(k)} = \mathbf{x}, \quad \text{kde } \mathbf{x} \text{ je řešením } \mathbf{Ax} = \mathbf{b}.$$

**Vlastnosti iteračních metod:**

- v každé iteraci známe aproximaci řešení  $\mathbf{x}^{(k)}$ ,
- v každé iteraci je nejpracnější operací násobení matice a vektoru,
- méně citlivé na zaokrouhlovací chyby než metody přímé.

Doporučení: Přímé metody se obvykle používají, je-li matice soustavy malá ( $1 \leq n \leq 10000$ ), plná a dobře podmíněná. Iterační metody lze uplatnit zejména pro velké soustavy ( $n > 10000$ ) s řídkou maticí.

## Obecná iterační metoda (2)

Soustavu  $\mathbf{Ax} = \mathbf{b}$  přepíšeme na ekvivalentní soustavu (obě soustavy mají stejné řešení) v iteračním tvaru

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

kde  $\mathbf{B}$  je iterační matice řádu  $n$  a  $\mathbf{c}$  je sloupcový vektor.

Iterační metody spočívají v konstrukci posloupnosti vektorů, která je dána rekurentním předpisem:

$$\mathbf{x}^{(k+1)} = \mathbf{Bx}^{(k)} + \mathbf{Cb}, \quad k = 0, 1, \dots,$$

kde  $\mathbf{x}^{(0)}$  je zvolený počáteční vektor a matice  $\mathbf{B}$  a  $\mathbf{C}$  splňují  $\mathbf{B} + \mathbf{CA} = \mathbf{I}$ .

Jestliže posloupnost vektorů  $\{\mathbf{x}^{(k)}\}$  konverguje k vektoru  $\mathbf{x}$ , pak limitním přechodem získáme řešení  $\mathbf{Ax} = \mathbf{b}$ . V numerických programech výpočet ukončíme, jestliže aproximace řešení  $\mathbf{x}^{(k)}$  splňuje požadovanou přesnost - ukončovací kritérium

$$\|\mathbf{b} - \mathbf{Ax}^{(k)}\| \leq \varepsilon,$$

kde  $\varepsilon > 0$  je daná přesnost a  $\|\cdot\|$  je vhodná norma.

### Definice (Reziduum soustavy rovnic:)

*Nechť  $\mathbf{x}^{(k)}$  je řešení soustavy  $\mathbf{Ax} = \mathbf{b}$ , které získáme pomocí libovolné iterační metody v  $k$ -tém kroce. Předpisem*

$$\mathbf{r}^{(k)} = \mathbf{b} - \mathbf{Ax}^{(k)}$$

*definujeme tzv. reziduum soustavy.*

## Obecná iterační metoda (3)

### Věta (Nutná a postačující podmínka konvergence iterační metody:)

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

### Věta (Postačující podmínka konvergence iterační metody I:)

*Je-li  $\|\mathbf{B}\| < 1$  pro libovolnou normu matice  $\|\cdot\|$ , potom posloupnost  $\mathbf{x}^{(k)}$  konverguje k přesnému řešení soustavy  $\mathbf{Ax} = \mathbf{b}$ .*

### Věta (Postačující podmínka konvergence iterační metody II:)

*Nechť  $\mathbf{B}$  je iterační matice, která má  $n$  lineárně nezávislých vlastních vektorů. Iterační metoda daná obecným vzorcem konverguje pro každou počáteční aproximaci  $\mathbf{x}^{(0)}$ , právě když všechna vlastní čísla matice  $\mathbf{B}$  jsou v absolutní hodnotě menší než jedna.*

### Algoritmus obecné iterační metody:

Vstup:  $\mathbf{B}$ ,  $\mathbf{c}$ ,  $\mathbf{x}^{(0)}$ ,  $\varepsilon$ .

Opakuji

$$\mathbf{x}^{(k+1)} := \mathbf{B}\mathbf{x}^{(k)} + \mathbf{c};$$

dokud  $\|\mathbf{x}^{(k+1)} - \mathbf{x}^{(k)}\| > \varepsilon$ .

Výstup:  $\mathbf{x}^{(k)}$ .

**Poznámka:** Úpravy, které nemění řešení:

- záměna pořadí rovnic,
- vynásobení rovnice nenulovým číslem,
- přičtení nenulového násobku rovnice k jiné rovnici.

## Jacobiova metoda (1)

Uvažujme následující aditivní rozklad matice  $\mathbf{A} = (a_{ij})$ ,

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

kde

- $\mathbf{L} = (l_{ij})$ ,  $l_{ij} = a_{ij}$ ,  $i > j$ ,  $l_{ij} = 0$ ,  $i \leq j$ , je **dolní trojúhelníková** matice,
- $\mathbf{D} = (d_{ij})$ ,  $d_{ii} = a_{ii}$ ,  $d_{ij} = 0$ ,  $i \neq j$ , je **diagonální** matice,
- $\mathbf{U} = (u_{ij})$ ,  $u_{ij} = 0$ ,  $i \geq j$ ,  $u_{ij} = a_{ij}$ ,  $i < j$ , je **horní trojúhelníková** matice.

Budeme předpokládat, že diagonální prvky matice  $\mathbf{D}$ , nenulové, tj. matice  $\mathbf{A}$  je regulární. Potom můžeme původní soustavu ekvivalentně upravit:

$$\mathbf{A}\mathbf{x} = \mathbf{b} \Leftrightarrow (\mathbf{L} + \mathbf{D} + \mathbf{U})\mathbf{x} = \mathbf{b} \Leftrightarrow \mathbf{D}\mathbf{x} + (\mathbf{L} + \mathbf{U})\mathbf{x} = \mathbf{b} \Leftrightarrow \mathbf{D}\mathbf{x} = -(\mathbf{L} + \mathbf{U})\mathbf{x} + \mathbf{b},$$

a vynásobíme-li zleva poslední rovnici inverzní maticí k matici  $\mathbf{D}$  získáme

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

ze které snadno odvodíme iterační předpis tvaru

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

tzn. iterační matice (dle obecné iterační metody) dána vztahem  $\mathbf{B} = -\mathbf{D}^{-1}(\mathbf{L} + \mathbf{U})$  a vektor  $\mathbf{c} = \mathbf{D}^{-1}\mathbf{b}$ .

## Jacobiova metoda (2)

Jacobiovu metodu můžeme ekvivalentně zapsat i po složkách pomocí rekurentních vzorců

$$x_i^{(k+1)} = \frac{1}{a_{ii}} \left( b_i - \sum_{j=1}^{i-1} a_{ij} x_j^{(k)} - \sum_{j=i+1}^n a_{ij} x_j^{(k)} \right), \quad i = 1, \dots, n, \text{ pro } k = 0, 1, 2, \dots,$$

které bychom analogicky získali tak, že z  $i$ -té rovnice

$$a_{i1}x_1 + a_{i2}x_2 + \dots + a_{in}x_n = b_i, \quad i = 1, \dots, n$$

vyjádříme  $i$ -tou neznámou a položíme  $x_i^{(k+1)} = x_i$  a  $x_j^{(k)} = x_j, j \neq i$ .

Posloupnost vektorů  $\mathbf{x}^{(k)}$  získaná Jacobiovou metodou konverguje k přesnému řešení právě tehdy, když

$$\rho(\mathbf{B}) = \rho(-\mathbf{D}^{-1}(\mathbf{L} + \mathbf{U})) < 1.$$

Tuto podmínku splňují například ostře diagonálně dominantní matice.

### Definice (Ostře diagonálně dominantní matice)

*Nechť  $\mathbf{B} = (b_{ij})$  je čtvercová matice. Řekneme, že matice  $\mathbf{B}$  ostře diagonálně dominantní, je-li splněna následující podmínka*

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

## Gauss-Seidelova metoda (1)

Budeme-li vycházet z iteračního předpisu pro Jacobiovu metodu a uvědomíme-li si, že při výpočtu jednotlivých složek  $x_i^{(k+1)}$  můžeme použít přesnější aproximace  $x_j^{(k+1)}$ ,  $j \leq i$  (tj. použijeme všechny složky vektoru  $\mathbf{x}^{(k+1)}$ , které byly již vypočteny), obdržíme tzv. **Gauss-Seidelovu metodu**.

Gauss-Seidelovu metodu můžeme tedy zapsat po složkách pomocí rekurentních vzorců

$$x_i^{(k+1)} = \frac{1}{a_{ii}} \left( b_i - \sum_{j=1}^{i-1} a_{ij} x_j^{(k+1)} - \sum_{j=i+1}^n a_{ij} x_j^{(k)} \right), \quad i = 1, \dots, n, \quad \text{pro } k = 0, 1, 2, \dots,$$

Analogicky lze odvodit maticový zápis této metody. Původní soustavu ekvivalentně upríme:

$$\mathbf{Ax} = \mathbf{b} \Leftrightarrow (\mathbf{L} + \mathbf{D} + \mathbf{U})\mathbf{x} = \mathbf{b} \Leftrightarrow (\mathbf{D} + \mathbf{L})\mathbf{x} + \mathbf{U}\mathbf{x} = \mathbf{b} \Leftrightarrow (\mathbf{D} + \mathbf{L})\mathbf{x} = -\mathbf{U}\mathbf{x} + \mathbf{b},$$

a vynásobíme-li zleva poslední rovnici inverzní maticí k matici  $(\mathbf{D} + \mathbf{L})$  získáme

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

ze které snadno odvodíme iterační předpis tvaru

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

tzn. iterační matice (dle obecné iterační metody) dána vztahem  $\mathbf{B} = -(\mathbf{D} + \mathbf{L})^{-1}\mathbf{U}$  a vektor  $\mathbf{c} = (\mathbf{D} + \mathbf{L})^{-1}\mathbf{b}$ .

## Gauss-Seidelova metoda (2)

Konzul. 2

Obecná  
iterační  
metoda

Jacobiova  
metoda

Gauss-  
Seidelova  
metoda

SOR  
metoda

CG  
metoda

Soustavy  
s obdélní-  
kovou

maticí

SVD

Posloupnost vektorů  $\mathbf{x}^{(k)}$  získaná Gauss-Seidelovou metodou konverguje k přesnému řešení právě tehdy, když

$$\rho(\mathbf{B}) = \rho(-(\mathbf{D} + \mathbf{L})^{-1}\mathbf{U}) < 1.$$

Tuto podmínku splňují například ostře diagonálně dominantní matice a také symetrické pozitivně definitní matice.

### **Definice (Pozitivně definitivní matice)**

*Nechť  $\mathbf{B} = (b_{ij})$  je čtvercová matice. Řekneme, že matice  $\mathbf{B}$  je pozitivně definitivní, je-li splněna následující podmínka*

$$\mathbf{x}^T \mathbf{B} \mathbf{x} > 0 \text{ pro všechna } \mathbf{x} \neq 0.$$



## Superrelaxační metoda (1)

Modifikací Gaussovy-Seidelovy metody můžeme získat zrychlení konvergence, tuto metodu nazýváme tzv. **superrelaxační** a konstruujeme při ní posloupnost vektorů podle vzorce:

$$\mathbf{x}^{(k+1)} = (1 - \omega)\mathbf{x}^{(i)} + \omega\hat{\mathbf{x}}^{(k+1)},$$

kde

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

Parametr  $\omega$  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  $\mathbf{x}^{(k)}$  k řešení. Volbou  $\omega = 1$  dostaneme Gaussovu-Seidelovu metodu. Po úpravě snadno odvodíme iterační předpis tvaru

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

tz. iterační matice (dle obecné iterační metody) dána vztahem  $\mathbf{B} = (\mathbf{D} + \omega\mathbf{L})^{-1}(-\omega\mathbf{U} + (1 - \omega)\mathbf{D})$  a vektor  $\mathbf{c} = \omega(\mathbf{D} + \omega\mathbf{L})^{-1}\mathbf{b}$ .

Superrelaxační metodu můžeme opět zapsat po složkách pomocí rekurentních vzorců ( $k = 0, 1, \dots$ )

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

## Metoda konjugovaných gradientů (1)

Nechť  $\mathbf{A} \in \mathbf{R}^{n \times n}$  je symetrická pozitivně definitní matice a  $\mathbf{b} \in \mathbf{R}^n$  je vektor pravé strany. Hledáme řešení  $\mathbf{x} \in \mathbf{R}^n$  následujícího lineárního systému:

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

který má jednoznačné řešení.

Tuto úlohu převedeme na problém minimalizace kvadratického funkcionálu:

$$\min_{\mathbf{x} \in \mathbf{R}^n} f(\mathbf{x}) \quad \text{pro} \quad f(\mathbf{x}) = \frac{1}{2}(\mathbf{Ax}, \mathbf{x}) - (\mathbf{b}, \mathbf{x}),$$

kde  $(\cdot, \cdot)$  značí skalární součin a platí  $\nabla f(\mathbf{x}) = \mathbf{Ax} - \mathbf{b}$ .

Řešení v  $k$ -tém kroce konstruujeme podle rekurentní formule:

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \gamma_k \mathbf{p}^{(k)},$$

kde  $\mathbf{p}^{(k)}$  je zvolený směr a koeficient  $\gamma_{k-1} \in \mathbf{R}$  určíme tak, aby vektor  $\mathbf{x}^{(k+1)}$  byl bodem minima funkce  $f$  na přímce  $\mathbf{x}^{(k)} + t\mathbf{p}^{(k)}$ ,  $t \in \mathbf{R}$ , tj.

$$\gamma_k = \frac{(\mathbf{r}^{(k)}, \mathbf{p}^{(k)})}{(\mathbf{p}^{(k)}, \mathbf{A}\mathbf{p}^{(k)})}.$$

## Metoda konjugovaných gradientů (2)

Směrové vektory  $p^{(k)}$  volíme podle následující rekurentní formule:

$$p^{(k)} = r^{(k)} + \beta_k p^{(k-1)},$$

kde  $p^0 = r^0$  a koeficienty  $\beta_k \in \mathbf{R}$  volíme tak, aby posloupnost směrů  $\{p^{(k)}\}$ ,  $k = 0, 1, \dots$  tvořila tzv. **systém A-ortogonálních vektorů** tj. vektorů, pro které platí:

$$(Ap^{(k)}, p^{(l)}) = 0, \quad k \neq l, \quad \text{a} \quad (Ap^{(k)}, p^{(k)}) \neq 0.$$

**Poznámka:** Převedením původní úlohy  $Ax = b$  na problém minimalizace funkcionálu můžeme CGM považovat za iterativní metodu, což dokládají i numerické výpočty, kdy k nalezení dostatečně přesného řešení stačí podstatně menší počet iterací než je hodnost matice  $A$ .

**Poznámka:** Na druhou stranu stranu můžeme na CGM nahlížet jako na metodu finitní (tj. metodu přímou), která končí nejpozději po  $n$  krocích, neboť A-ortogonalita směrů a dimenze prostoru  $R^n$  implikuje  $r^n = 0$ .

# Metoda konjugovaných gradientů (3)

## Algoritmus metody sdružených gradientů:

Vstup:  $\mathbf{A}$ ,  $\mathbf{b}$ ,  $\mathbf{x}^{(0)}$ ,  $\varepsilon$ .

(1)  $\mathbf{r}^0 = \mathbf{b} - \mathbf{A}\mathbf{x}^0$ ,  $\mathbf{p}^0 = \mathbf{r}^0$ ,  $k = 1$

(2) **repeat**

(2a) **if**  $(\mathbf{r}^{k-1})^T \mathbf{r}^{k-1} < \varepsilon$  **then** exit loop **end if**

(2b)

$$\gamma_{k-1} = \frac{(\mathbf{r}^{k-1}, \mathbf{r}^{k-1})}{(\mathbf{p}^{k-1}, \mathbf{A}\mathbf{p}^{k-1})}$$

(2c)

$$\mathbf{x}^k = \mathbf{x}^{k-1} + \gamma_{k-1}\mathbf{p}^{k-1}$$

(2d)

$$\mathbf{r}^k = \mathbf{r}^{k-1} - \gamma_{k-1}\mathbf{A}\mathbf{p}^{k-1}$$

(2e)

$$\beta_k = \frac{(\mathbf{r}^k, \mathbf{r}^k)}{(\mathbf{r}^{k-1}, \mathbf{r}^{k-1})}$$

(2f)

$$\mathbf{p}^k = \mathbf{r}^k + \beta_k\mathbf{p}^{k-1}$$

(2g)  $k = k + 1$

**end repeat**

Výstup:  $\mathbf{x}^{(k)}$ .

## Soustavy s obdélníkovou maticí (1)

Nyní se budeme zabývat numerickým řešením soustavy  $m$  rovnic s  $n$  neznámými pro  $m \neq n$ , tj. soustav s obdélníkovou maticí, kterou můžeme zapsat vektorově:

$$\mathbf{Ax} = \mathbf{b} \quad \text{pro} \quad \mathbf{A} \in \mathbb{R}^{m \times n}, \mathbf{x} \in \mathbb{R}^n, \mathbf{b} \in \mathbb{R}^m.$$

**Věta (Frobeniova věta:)** *Necht'  $\mathbf{Ax} = \mathbf{b}$  představuje soustavu algebraických rovnic typu  $m \times n$ .*

- Je-li  $\text{hod}(\mathbf{A}) \neq \text{hod}(\mathbf{A}_{\mathbf{b}})$ , potom soustava  $\mathbf{Ax} = \mathbf{b}$  nemá řešení.*
- Je-li  $\text{hod}(\mathbf{A}) = \text{hod}(\mathbf{A}_{\mathbf{b}}) = n$ , potom soustava  $\mathbf{Ax} = \mathbf{b}$  má právě jedno řešení.*
- Je-li  $\text{hod}(\mathbf{A}) = \text{hod}(\mathbf{A}_{\mathbf{b}}) < n$ , potom soustava  $\mathbf{Ax} = \mathbf{b}$  má nekonečně mnoho řešení.*

Pro obdélníkové matice lze zobecnit definici inverzní matice (příp. podmíněnosti).

**Definice (Pseudoinverzní matice:)** *Necht'  $\mathbf{A} \in \mathbb{R}^{m \times n}$ . Matice  $\mathbf{A}^+$  se nazývá pseudoinverzní matice k matici  $\mathbf{A}$  nebo také Mooreova - Penroseova inverzní matice, jestliže platí:*

- $\mathbf{A}^+ \mathbf{A} \mathbf{A}^+ = \mathbf{A}^+$ ,
- $\mathbf{A} \mathbf{A}^+ \mathbf{A} = \mathbf{A}$ ,
- $(\mathbf{A}^+ \mathbf{A})^+ = \mathbf{A}^+ \mathbf{A}$ ,
- $(\mathbf{A} \mathbf{A}^+)^+ = \mathbf{A} \mathbf{A}^+$ .

Ke každé matici existuje matice pseudoinverzní. Navíc, je-li matice  $\mathbf{A}$  regulární, potom je pseudoinverzní matice rovna matici inverzní.

## Soustavy s obdélníkovou maticí (2)

**Věta (Číslo podmíněnosti matice:)** *Nechť  $\mathbf{A} \in \mathbb{R}^{m \times n}$  je obdélníková matice. Číslo podmíněnosti matice  $\mathbf{A}$  je definováno předpisem*

$$\kappa(\mathbf{A}) = \|\mathbf{A}\| \cdot \|\mathbf{A}^+\|.$$

**Věta (Otázky řešitelnosti:)** *Pro libovolnou soustavu  $\mathbf{Ax} = \mathbf{b}$  může nastat vždy jen jedna z následujících tří možností:*

- Jestliže soustava  $\mathbf{Ax} = \mathbf{b}$  má nekonečně mnoho řešení, potom  $\mathbf{x}^* = \mathbf{A}^+\mathbf{b}$  je řešení s nejmenší Euklidovskou normou.*
- Jestliže soustava  $\mathbf{Ax} = \mathbf{b}$  má právě jedno řešení, potom  $\mathbf{x}^* = \mathbf{A}^+\mathbf{b}$  je řešení soustavy.*
- Jestliže soustava  $\mathbf{Ax} = \mathbf{b}$  nemá řešení, potom  $\mathbf{x}^* = \mathbf{A}^+\mathbf{b}$  splňuje*

$$\|\mathbf{b} - \mathbf{Ax}^*\|_2 \leq \|\mathbf{b} - \mathbf{Ay}\|_2, \mathbf{y} \in \mathbb{R}^n.$$

V dalším se budeme zabývat případem, kdy soustava nemá řešení a budeme hledat takové řešení  $\mathbf{x}^*$ , pro které je euklidovská norma rezidua  $\|\mathbf{Ax} - \mathbf{b}\|_2$  minimální. V tomto případě obvykle hovoříme o tzv. **řešení soustavy  $\mathbf{Ax} = \mathbf{b}$  ve smyslu nejmenších čtverců**.

## Soustavy s obdélníkovou maticí (3)

**Věta (Soustava normálních rovnic):** *Uvažujme soustavu*

$$\mathbf{Ax} = \mathbf{b} \quad \text{pro} \quad \mathbf{A} \in \mathbb{R}^{m \times n}, \mathbf{x} \in \mathbb{R}^n, \mathbf{b} \in \mathbb{R}^m.$$

*předpokládejme, že  $m > n$  a  $\text{hod}(\mathbf{A}) = n$ . Potom soustava*

$$\mathbf{A}^T \mathbf{Ax} = \mathbf{A}^T \mathbf{b}$$

*má právě jedno řešení  $\mathbf{x}^*$  a toto řešení  $\mathbf{x}^*$  je řešením soustavy  $\mathbf{Ax} = \mathbf{b}$  ve smyslu nejmenších čtverců.*

Řešit původní soustavu pomocí této věty může být vhodné zejména pokud  $n \ll m$ , protože soustava  $\mathbf{A}^T \mathbf{Ax} = \mathbf{A}^T \mathbf{b}$  představuje výrazně menší problém než původní soustava. Tuto novou soustavu nazýváme tzv. **soustavou normálních rovnic**. Matice této soustavy je symetrická pozitivně definitní (pro řešení můžeme použít např. Choleského rozklad).

Nevýhodou tohoto postupu je rostoucí číslo podmíněnosti matice soustavy normálních rovnic v druhé mocnině čísla podmíněnosti matice původní soustavy:

$$\kappa(\mathbf{A}^T \mathbf{A}) = \kappa^2(\mathbf{A}).$$

Ze soustavy normálních rovnic dostaneme vztah pro výpočet pseudo inverzní matice:

$$\mathbf{A}^+ = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T.$$

## Singularní rozklad (1)

**Věta (O singularním rozkladu):** Každou matici  $\mathbf{A} \in \mathbb{R}^{m \times n}$  lze rozložit na součin matic

$$\mathbf{A} = \mathbf{U}\Sigma\mathbf{V}^T,$$

kde  $\mathbf{U} \in \mathbb{R}^{m \times m}$ ,  $\mathbf{V} \in \mathbb{R}^{n \times n}$  jsou ortonormální matice a matice  $\Sigma \in \mathbb{R}^{m \times n}$  je diagonální,

$$\Sigma = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_k), \quad k = \min(m, n),$$

jejíž diagonální prvky splňují

$$\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > \sigma_{r+1} = \dots = \sigma_k = 0,$$

kde  $r = \text{hod}(\mathbf{A})$ .

Diagonální prvky  $\sigma_1, \sigma_2, \dots, \sigma_k$  matice  $\Sigma$  se nazývají **singularní čísla** matice  $\mathbf{A}$ ,  $i$ -tý sloupec matice  $\mathbf{U}$  se nazývá  $i$ -tý **levý singularní vektor**,  $i$ -tý sloupec matice  $\mathbf{V}$  se nazývá  $i$ -tý **pravý singularní vektor**. Zřejmě platí

$$\mathbf{u}_i^T \mathbf{A} = \sigma_i \mathbf{v}_i^T, \quad \mathbf{A} \mathbf{v}_i = \sigma_i \mathbf{u}_i, \quad i = 1, 2, \dots, k.$$

Užití singularního rozkladu:

- výpočet pseudoinverzní matice:

$$\mathbf{A}^+ = \mathbf{V}\Sigma^+\mathbf{U}^T, \quad \Sigma^+ = \text{diag}(\sigma_1^{-1}, \sigma_2^{-1}, \dots, \sigma_k^{-1}, 0, \dots, 0) \in \mathbb{R}^{n \times m}$$

- výpočet spektrální normy matice:  $\|\mathbf{A}\|_2 = \sigma_1$ ,

- výpočet podmíněnosti matice vzhledem ke spektrální normě:  $\kappa(\mathbf{A}) = \frac{\sigma_1}{\sigma_r}$ .