

Numerické řešení soustav lin. rovnic

Mějme regulární matici $A \in \mathbb{R}^{n \times n}$ a vektor $\bar{b} \in \mathbb{R}^n$.

Hledáme $\bar{u} \in \mathbb{R}^n$ tak, že

$$\boxed{A \cdot \bar{u} = \bar{b}}$$

Připomeňme si Gaussov eliminací metodu (bez pivotování) a s ní související LU-rozklad:

```

 $\tilde{L} := I; U := A; \tilde{c} := \bar{b}$ 
for  $i = 1:m-1$ 
  for  $j = 2:m$ 
     $\tilde{L}_{ji} := -\frac{a_{ji}}{a_{ji}}$ 
    for  $k = j:m$ 
       $U_{jk} := U_{jk} - \tilde{L}_{ji} \cdot U_{jk}$ 
    end for
     $c_j := c_j - \tilde{L}_{ji} \cdot c_j$ 
  end for
end for

```

Řešení získáme
zpětným dosazováním

```

for  $i = m:-1:1$ 
   $u_i := c_i / U_{ii}$ 
  for  $j = 1:i-1$ 
     $c_j := c_j - u_i \cdot U_{ji}$ 
  end for
end for

```

Zároveň jsme získali faktory $\tilde{L}, U \in \mathbb{R}^{n \times n}$: $\boxed{\tilde{L} \cdot A = U}$, což nám umožňuje snázeji řešit případnou další soustavu $A \cdot \bar{v} = \bar{d} \Leftrightarrow U \cdot \bar{v} = \tilde{L} \cdot \bar{d}$, kterou vyřešíme zpětným dos.

Budeme se zabývat přibližným řešením.


Lineární iterativní metody

$$\boxed{\bar{u}^{k+1} = M \cdot \bar{u}^k + \bar{b}}$$

Def. Konzistentní metoda $\Leftrightarrow M \cdot \bar{u} + \bar{b} = \bar{u} \Leftrightarrow M = I - N \cdot A$

Konvergentní metoda $\Leftrightarrow \bar{u}^k \rightarrow \bar{u}$ pro $k \rightarrow \infty \Leftrightarrow \|M\| < 1$

Rozložme matici na $A = D + L + U$,



$$\text{např. } A = \begin{pmatrix} 2 & -1 & 0 \\ -1 & 2 & -1 \\ 0 & -1 & 2 \end{pmatrix}$$

$$D = \begin{pmatrix} 2 & 0 & 0 \\ 0 & 2 & 0 \\ 0 & 0 & 2 \end{pmatrix}, L = \begin{pmatrix} 0 & 0 & 0 \\ -1 & 0 & 0 \\ 0 & -1 & 0 \end{pmatrix}$$

$$U = \begin{pmatrix} 0 & -1 & 0 \\ 0 & 0 & -1 \\ 0 & 0 & 0 \end{pmatrix}$$

Jacobijho metoda

$$D \cdot \bar{u}^{k+1} = \bar{b} - (L+U) \cdot \bar{u}^k$$

$$\left[(\bar{u}^{k+1})_i := \frac{1}{a_{ii}} \left[b_i - \sum_{\substack{j=1 \\ j \neq i}}^m a_{ij} (\bar{u}^k)_j \right] \right]$$

$$= \frac{1}{a_{ii}} \left[b_i - \sum_{j < i} a_{ij} (\bar{u}^k)_j - \sum_{j > i} a_{ij} (\bar{u}^k)_j \right] \quad (*)$$

Metoda je konzistentní: $\bar{b} - (L+U) \cdot \bar{u} = D \cdot \bar{u}$

Metoda je konvergentní $\Leftrightarrow \|M\| = \|D^{-1}(L+U)\| < 1$,

což splňuje např. diagonálně dominantní matice:

$$\forall i: |a_{ii}| > \sum_{j \neq i} a_{ij}$$

Gaussova - Seidelova metoda

~~První člen~~ $-\sum_{j < i} a_{ij} (\bar{u}^k)_j$ lze počítat z aktualizace \bar{u}^{k+1} :

$$\left[(\bar{u}^{k+1})_i := \frac{1}{a_{ii}} \left[b_i - \sum_{j < i} a_{ij} (\bar{u}^{k+1})_j - \sum_{j > i} a_{ij} (\bar{u}^k)_j \right] \right]$$

$$\left[(D+L) \bar{u}^{k+1} = \bar{b} - U \cdot \bar{u}^k \right]$$

Metoda je opět konzistentní

a je konvergentní, právě když $\|(D+L)^{-1}U\| < 1$.

Richardsonova metoda

$$\boxed{\bar{u}^{k+1} := \bar{u}^k + \omega \cdot \bar{r}^k}, \text{ kde } \bar{r}^k := \bar{b} - A \bar{u}^k \text{ .. residuum}$$

$\omega > 0$

Metoda je konzistentní pro lib. ω : $\bar{u} + \omega \cdot [\bar{b} - A \cdot \bar{u}] = \bar{u}$

Studujeme konzvergenci pro A symetrickou, pozitivně definitní (spd)

Vl. čísla, vl. vektory $A \cdot \bar{v}_i = \lambda_i \bar{v}_i, \|\bar{v}_i\| = 1$

oplňuje: $0 < \lambda_1 \leq \lambda_2 \leq \lambda_3 \leq \dots \leq \lambda_n$

$$\underbrace{\bar{v}_1 \oplus \bar{v}_2 \oplus \bar{v}_3 \oplus \dots \oplus \bar{v}_n}_{\text{ortonormalní báze } \mathbb{R}^n} = \mathbb{R}^n$$

Residuum \bar{r}^{k+1} (přejme jako chyba $\bar{e}^{k+1} := \bar{u} - \bar{u}^{k+1}$) se čísl. také do:

$$\begin{aligned} \bar{r}^{k+1} &= \bar{b} - A \bar{u}^{k+1} = \bar{b} - A [\bar{u}^k + \omega \bar{r}^k] = \overbrace{(\mathbf{I} - \omega A)}^{=M} \bar{r}^k \\ &\parallel \sum_{i=1}^n \alpha_i^{k+1} \bar{v}_i \qquad \parallel \sum_{i=1}^n \alpha_i^k \bar{v}_i \\ &= \sum_{i=1}^n \underbrace{(1 - \omega \lambda_i)}_{\text{...}} \alpha_i^k \bar{v}_i \end{aligned}$$


Metoda konverguje, právě když

$$\boxed{\forall i: |1 - \omega \lambda_i| < 1}, \rho$$

řídící

konvergenčním faktorem ρ : $\|\bar{r}^{k+1}\| \leq \rho \cdot \|\bar{r}^k\|$

$$\boxed{\rho := \max_{i \in \{1, \dots, n\}} |1 - \omega \lambda_i|}$$



Z obrázku lze vidět, že Richardsonova metoda konverguje pro $\omega \in (0, \frac{2}{\lambda_m})$, přičemž optimální konvergence je dosaženo v ω_{opt} :

$$1 - \omega_{opt} \lambda_m = - (1 - \omega_{opt} \lambda_1)$$

$$\omega_{opt} = \frac{2}{\lambda_1 + \lambda_m}$$

s optimálním konvergenčním faktorem:

$$\rho_{opt} = 1 - \omega_{opt} \lambda_1 = 1 - \frac{2\lambda_1}{\lambda_1 + \lambda_m} = \frac{\lambda_m - \lambda_1}{\lambda_m + \lambda_1} \cdot \frac{1/\lambda_m}{1/\lambda_1} = \frac{\kappa(A) - 1}{\kappa(A) + 1}$$

kde $\kappa(A) := \frac{\lambda_m}{\lambda_1}$ je číslo podmíněnosti A

Počet iterací ~~postupujících~~ k dosažení rel. přesnosti ϵ :

$$\|F^k\| \leq \underbrace{(\rho_{opt})^k \cdot \|F^0\|}_{\rho_{opt}, \epsilon \in (0,1)} \leq \epsilon \cdot \|F^0\| \iff k \geq \frac{\log \epsilon}{\log \rho_{opt}} \cdot \kappa(A)$$

Prakticky platí (viz průběh funkce $\frac{1}{\log \frac{\kappa-1}{\kappa+1}}$):

$$k \geq \frac{\ln 10}{2} \cdot \kappa(A) \cdot |\log \epsilon|$$

tj. s každou další platnou cifrou potřebujeme provést cca $\frac{\ln 10}{2} \cdot \kappa(A)$ iterací.

Čebyševova metoda

$$\boxed{\bar{u}^{k+1} := \bar{u}^k + \omega_k \cdot \bar{r}^k}, \quad \bar{r}^k := \bar{b} - A\bar{u}^k$$

$$\omega_0, \omega_1, \dots, \omega_k > 0$$

Pokračujeme opět pouze spd-matice A .

Reziduum po k -té iteraci vypadá takto:

$$\bar{r}^k = (I - \omega_{k-1}A)\bar{r}^{k-1} = \dots = \underbrace{(I - \omega_{k-1}A) \dots (I - \omega_0A)}_{= M^k} \bar{r}^0$$

Pro glech ~~symetrické~~ symetrické maticice A (symetrická a orthonormální) bdni vl. vektorů α_i :

$$\alpha_i^k = (1 - \omega_{k-1}\lambda_i) \cdot (1 - \omega_{k-2}\lambda_i) \cdot \dots \cdot (1 - \omega_0\lambda_i) \cdot \alpha_i^0$$

Metoda ~~konverguje~~ po k -té iteraci konverguje, pokud

$$\forall i: \underbrace{|(1 - \omega_{k-1}\lambda_i) \cdot \dots \cdot (1 - \omega_0\lambda_i)|}_{= \rho^k} < 1$$

Optimální konvergence je dosaženo pro $\bar{\omega}_{opt} \in \mathbb{R}^k$:

$$\bar{\omega}_{opt} = \arg \min_{\bar{\omega} \in \mathbb{R}^k} \max_{i \in \{1, \dots, n\}} |(1 - \omega_{k-1}\lambda_i) \cdot \dots \cdot (1 - \omega_0\lambda_i)|.$$

To je těžká úloha. Spolujieme se s pseudo-optimumem

$$\bar{\omega}_{opt} = \arg \min_{\bar{\omega} \in \mathbb{R}^k} \max_{\lambda \in \langle \lambda_1, \lambda_n \rangle} \underbrace{|(1 - \omega_{k-1}\lambda) \cdot \dots \cdot (1 - \omega_0\lambda)|}_{= P_k(\lambda)} \in \mathcal{P}_k: P_k(\bar{\omega})(0) = 1$$

Lze (snadno) vidět, viz Chebyshevova interpolace,

že $\bar{\omega}_{opt}$ jsou hodiny ⁻¹ škálovaneho Chebyshevova polynomu:

$$\tilde{T}_k(\lambda) := \frac{T_k\left(\frac{\lambda_n + \lambda_1 - 2\lambda}{\lambda_n - \lambda_1}\right)}{T_k\left(\frac{\lambda_n + \lambda_1}{\lambda_n - \lambda_1}\right)}$$

$$\omega_{opt,i} = \left[\frac{\lambda_1 + \lambda_n}{2} - \frac{\lambda_n - \lambda_1}{2} x_i \right]^{-1},$$

kde $x_i := \cos \frac{(2i+1)\pi}{2k}, i=0, \dots, k-1$

$$\rho_{opt}^k \leq 2 \cdot \left(\frac{\sqrt{\kappa(A)} - 1}{\sqrt{\kappa(A)} + 1} \right)^k \Rightarrow \text{počet iterací} \approx \sqrt{\kappa(A)} \cdot \log \varepsilon$$

Metoda nejvíššího spádu

$A \cdot \bar{u} = b$, A .. spd-matrice



$\bar{u} = \arg \min_{\bar{w} \in \mathbb{R}^n} \left(\frac{1}{2} \bar{w}^T \cdot A \bar{w} - \bar{b}^T \cdot \bar{w} \right)$

$=: \varphi(\bar{w})$.. kvadratická funkce $\mathbb{R}^n \rightarrow \mathbb{R}$



$\nabla \varphi(\bar{u}^0) = -\bar{F}^0$
 \parallel
 $A \cdot \bar{u}^0 - \bar{b}$

$\bar{u}^{k+1} := \bar{u}^k + \alpha_k \cdot \bar{F}^k$

kde $\alpha_k := \arg \min_{\alpha > 0} \varphi(\bar{u}^k + \alpha \bar{F}^k)$

$= \frac{1}{2} (\bar{u}^k + \alpha \bar{F}^k)^T A (\bar{u}^k + \alpha \bar{F}^k) - \bar{b}^T (\bar{u}^k + \alpha \bar{F}^k)$
 $= \frac{1}{2} \alpha^2 \|\bar{F}^k\|_A^2 + \alpha (\bar{u}^k A \bar{F}^k - \bar{b}^T \bar{F}^k) + \dots$
 $= -\|\bar{F}^k\|^2$

Podmínka $\bar{F}^k \neq \bar{0}$, pak je minimum dosaženo v

$\alpha_k := \frac{\|\bar{F}^k\|^2}{\|\bar{F}^k\|_A^2}$

Algoritmus:

Dáno: $A, b, \bar{u}^0, \epsilon \in (0,1)$

```

F^0 := b - A * u^0, k := 0
while ||F^k||_A / ||F^0||_A > epsilon
    alpha_k := ||F^k||^2 / ||F^k||_A^2
    u^{k+1} := u^k + alpha_k * F^k
    F^{k+1} := b - A * u^{k+1}
    k := k + 1
end while
    
```

Konvergence je velmi pomalá!

$\rho_k = \max_{i \in \{1, \dots, n\}} |1 - \alpha_k \lambda_i| = \max_i \left| 1 - \frac{\lambda_i \sum_j (\delta_j^k)^2}{\sum_j \lambda_j (\delta_j^k)^2} \right|$
 $\leq \left| 1 - \frac{\lambda_1}{\lambda_m} \right|$

kde $\bar{F}^k = \sum_{j=1}^m \delta_j^k \bar{v}_j$; $A \bar{v}_j = \lambda_j \bar{v}_j$, $\|\bar{v}_j\| = 1$

Podobně konvergence v A-normě:

$\frac{\|\bar{F}^{k+1}\|_A}{\sqrt{\sum_j \lambda_j (\delta_j^{k+1})^2}} = \frac{\sqrt{\sum_j \lambda_j (1 - \alpha_k \lambda_j)^2 (\delta_j^k)^2}}{\sqrt{\sum_j \lambda_j (\delta_j^k)^2}} \leq \max_i |1 - \alpha_k \lambda_i| \cdot \frac{\sqrt{\sum_j \lambda_j (\delta_j^k)^2}}{\sqrt{\sum_j \lambda_j (\delta_j^k)^2}} = \rho_k$

Metoda sdružených gradientů (A-ord)

Zavedme krylovovský prostor $K^k(A, \bar{r}^0) := \langle \bar{r}^0, A\bar{r}^0, \dots, A^{k-1}\bar{r}^0 \rangle$
 V každé iteraci budeme realizovat minimum (A-ordog. projekce)

$$\bar{u}^{k+1} := \arg \min_{\bar{w} \in \bar{u}^k + K^k(A, \bar{r}^0)} \Psi(\bar{w}) = \arg \min_{\bar{w} \in \bar{u}^k + K^k(A, \bar{r}^0)} \|\bar{u} - \bar{w}\|_A$$

Důkaz. $\frac{1}{2} \|\bar{u} - \bar{w}\|_A^2 = \frac{1}{2} \bar{w}^T A \bar{w} - \underbrace{\bar{b}^T \bar{w}}_{\bar{u}^T A} + \frac{1}{2} \bar{u}^T A \bar{u} \quad \square$
 $= \Psi(\bar{w})$

Zároveň budeme budovat A-ortogonální bázi $\Leftrightarrow \bar{p}_i^T A \bar{p}_j = \delta_{ij}$

$$\langle \bar{p}^0 := \bar{r}^0, \bar{p}^1, \dots, \bar{p}^{k-1} \rangle = K^k(A, \bar{r}^0).$$

Plati:

1) $\bar{r}^{k+1} \perp K^k(A, \bar{r}^0)$ (nebo $\bar{r}^{k+1} = \bar{0}$)

Důkaz. $\bar{r}^{k+1} = -\nabla \Psi(\bar{u}^{k+1})$, přičemž v \bar{u}^{k+1} je dosaženo minime. \square

2) $\bar{r}^{k+1} \perp_A K^{k-1}(A, \bar{r}^0)$

Důkaz. $\bar{r}^{k+1} \perp_A \bar{r}^0 \Leftrightarrow \bar{r}^{k+1} \perp_A \bar{r}^0$
 \vdots
 $\bar{r}^{k+1} \perp_A A^{k-1} \bar{r}^0 \Leftrightarrow \bar{r}^{k+1} \perp_A A^{k-1} \bar{r}^0 \quad \square$

3) Nechtě $(\bar{p}^0, \dots, \bar{p}^k)$ je A-ortogonální báze $K^{k+1}(A, \bar{r}^0)$,

pak $\bar{p}^{k+1} := \bar{r}^{k+1} + \beta_k \bar{p}^k \perp_A K^k(A, \bar{r}^0)$

Důkaz. Příslušný důsledek 1) a 2).

Stejně najít $\beta_k : \bar{p}^{k+1} \perp_A \bar{p}^k \Leftrightarrow \beta_k = - \frac{\bar{r}^{k+1} \cdot A \cdot \bar{p}^k}{\bar{p}^k \cdot A \cdot \bar{p}^k}$

4) $(\bar{p}^0, \dots, \bar{p}^{k+1})$ je A-ortogonální báze $K^{k+1}(A, \bar{r}^0) = \langle \bar{r}^0, \dots, A^k \bar{r}^0 \rangle$

Důkaz. $\bar{p}^{k+1} = \bar{r}^{k+1} + \dots = \bar{b} - A \bar{u}^{k+1} + \dots$

$\forall AK^k \subset \langle \bar{p}^0, \dots, \bar{p}^{k+1} \rangle$ \square

5) $\bar{u}^{k+1} = \bar{u}^k + \alpha_k \bar{p}^{k+1}$, kde $\alpha_k = \frac{\bar{r}^k \cdot \bar{p}^{k+1}}{\bar{p}^{k+1} \cdot A \cdot \bar{p}^{k+1}}$

Důkaz. Pokud $\bar{u}^k \neq \bar{u}$, pak $\bar{u}^{k+1} = \bar{u}^k + \alpha_k \bar{p}^{k+1} \perp_A K^k(A, \bar{r}^0)$

$\forall \epsilon \in \mathbb{R} \quad \forall \bar{v} \in K^k: \|\bar{u} - (\bar{u}^{k+1} + \epsilon \bar{v})\|_A^2 \geq \|\bar{u} - \bar{u}^{k+1}\|_A^2$
 $\xrightarrow{\epsilon > 0} (\bar{u} - \bar{u}^{k+1})^T A \bar{v} \geq 0$
 $\xrightarrow{\epsilon < 0} (\bar{u} - \bar{u}^{k+1})^T A \bar{v} \leq 0 \quad \square$

Dána: A -opd, \bar{b} , \bar{u}^0 , $\varepsilon \in (0, 1)$

$$\bar{r}^0 := \bar{b} - A\bar{u}^0$$

$$\bar{p}^0 := \bar{r}^0$$

$$k := 0$$

while $\|\bar{r}^k\|_A / \|\bar{r}^0\|_A > \varepsilon$

$$\alpha_k := \frac{\bar{r}^k \cdot \bar{p}^k}{\bar{p}^k \cdot A \cdot \bar{p}^k}$$

$$\bar{u}^{k+1} := \bar{u}^k + \alpha_k \bar{p}^k$$

$$\bar{r}^{k+1} := \bar{b} - A\bar{u}^{k+1}$$

$$\beta_k := - \frac{\bar{r}^{k+1} \cdot A \cdot \bar{p}^k}{\bar{p}^k \cdot A \cdot \bar{p}^k}$$

$$\bar{p}^{k+1} := \bar{r}^{k+1} + \beta_k \bar{p}^k$$

$$k := k + 1$$

end while

Konvergence

$$\|\bar{u} - \bar{u}^{k+1}\|_A \leq \|\bar{u} - \bar{u}^0 - P_k(A) \cdot \bar{r}^0\|_A$$

$$= \|(I - P_k(A) \cdot A) \cdot \bar{e}^0\|_A$$

$$= \|q_{k+1}(A) \cdot \bar{e}^0\|_A$$

Podobně $p \rightarrow r^{k+1} = A \cdot \bar{e}^{k+1}$:

$$\|\bar{r}^{k+1}\|_A \leq \|q_{k+1}(A) \cdot \bar{r}^0\|_A$$

$$\bar{r}^0 =: \sum_j \gamma_j^0 \bar{v}_j, \quad \bar{r}^{k+1} =: \sum_j \gamma_j^{k+1} \bar{v}_j$$

$$\|\bar{r}^0\|_A = \sqrt{\sum_j \lambda_j (\gamma_j^0)^2}, \quad \|\bar{r}^{k+1}\|_A = \sqrt{\sum_j \lambda_j (\gamma_j^{k+1})^2}$$

$$\|\bar{r}^{k+1}\|_A = \min_{\substack{q_{k+1} \in \mathcal{P}_{k+1} \\ q_{k+1}(0)=1}} \|q_{k+1}(A) \bar{r}^0\|_A$$

$$= \min \sqrt{\sum_j \lambda_j [q_{k+1}(\lambda_j) \gamma_j^0]^2}$$

$$\leq \min \max_i |q_{k+1}(\lambda_i)| \cdot \|\bar{r}^0\|_A$$

$$\leq 2 \left(\frac{\sqrt{\kappa(A)} - 1}{\sqrt{\kappa(A)} + 1} \right)^{k+1} \cdot \|\bar{r}^0\|_A \quad (\text{deb. met.})$$