

# Přednáška 20 - $A\vec{x} = \vec{b}$ & iterací metody

## Lepší / stabilnější algoritmy?

$\rightarrow$  nejdou, že bychom rádi stabilnější algoritmy -

$\rightarrow$  my bychom rádi měli iterací algoritmy,

tj. algoritmy produkující sekvenci aproximací  $\vec{x}_1, \vec{x}_2, \dots$

přesného řešení  $\vec{x}$ , např. abychom mohli kontrolovat

požadovanou přesnost řešení a/nebo její trade-off s

již uběhlým časem výpočtu

$\rightarrow$  je dobré mít „oba nástroje“ - iterací i přímé

Zatím jsme viděli v principu 1 způsob jak

„vytvořit“ iterací metodu  $\rightarrow$  reformulace na hledání  
pevného bodu  
+  
Banachova věta o kontrakci

$\rightarrow$  idea:

Krok 1: „rozštěpné“ matici  $A$ , například

$$\text{platí } A = D + N \quad \text{kde} \quad \begin{aligned} D &= \text{diag}(A) \\ N &= A - \text{diag}(A) = \text{off-diag}(A) \end{aligned}$$

tzv. stěpné matice (matrix splitting)

Krok 2:  $A\vec{x} = \vec{b} \Leftrightarrow D\vec{x} = \vec{b} - N\vec{x} \Leftrightarrow$

$\Leftrightarrow \vec{x} = D^{-1}(\vec{b} - N\vec{x})$  .....  $\vec{x}$  je pevný bod funkce

$$F: \vec{v} \mapsto D^{-1}(\vec{b} - N\vec{v})$$

Tedy:  $\vec{x}_{k+1} = D^{-1}(\vec{b} - N\vec{x}_k) = D^{-1}(\vec{b} - A\vec{x}_k + D\vec{x}_k) = \vec{x}_k + D^{-1}(\vec{b} - A\vec{x}_k)$

Jak/Kdy konverguje?

→ vezmeme si  $\vec{x}^*$  jako přesné řešení, tj.  $A\vec{x}^* = \vec{b}$  (to je rovnost, nikoliv rovnice)

$$\begin{aligned} \vec{x}_{k+1} - \vec{x}^* &= \vec{x}_k - \vec{x}^* + D^{-1}(\vec{b} - A\vec{x}_k) = (I - D^{-1}A)(\vec{x}_k - \vec{x}^*) = \\ &= (I - D^{-1}A)^2(\vec{x}_{k-1} - \vec{x}^*) = \dots = (I - D^{-1}A)^k(\vec{x}_0 - \vec{x}^*) \end{aligned}$$

stejný postup jako u Banachovy věty o kontrakci

⇒ [konverguje  $\forall \vec{x}_0 \in \mathbb{R}^n \iff (I - D^{-1}A)^k \rightarrow 0$  pro  $k \rightarrow \infty$ ]

Mějme  $T = I - D^{-1}A$  diagonalizovatelnou (následující výpočet projde i pro Jordanův tvar, jen to je krapet složitější vidět)

→  $T = S \Delta S^{-1}$  ...  $S =$  matice vl. vekt.  $\Delta = \text{diag}(d_1, \dots, d_n)$  matice vl. čísel

pak  $T^k = S \Delta S^{-1} S \Delta S^{-1} \dots S \Delta S^{-1} = S \Delta^k S^{-1}$

a tedy  $T^k \xrightarrow{k \rightarrow \infty} 0 \iff \max_{i=1, \dots, n} |d_i| < 1$

$=: \rho(T)$  ... tzv. spektrální poloměr  $A$

⇒ [konverguje  $\forall \vec{x}_0 \in \mathbb{R}^n \iff \rho(I - D^{-1}A) < 1$ ]

Obecné štepíací metody:  $A = M - \underbrace{(M - A)}_{=: N} \quad \forall M$

⇒ pro libovolnou regulární  $M \in \mathbb{R}^{n \times n}$

lze napsat iterační metodu →  $\vec{x}_{k+1} = \vec{x}_k + M^{-1}(\vec{b} - A\vec{x}_k)$   
 $=: \vec{r}_k$  ... tzv. residuum

Richardson method:  $M = I$

Jacobi method:  $M = \text{diag}(A)$

Gauss-Seidel method:  $M = \text{upper-triangle}(A) =$  

## Pozorování pro Richardson method:

$$\vec{x}_{k+1} = \vec{x}_k + \vec{b} - A\vec{x}_k \quad (\Rightarrow) \quad \vec{x}^* - \vec{x}_{k+1} = \vec{x}^* - \vec{x}_k - A(\vec{x}^* - \vec{x}_k) \quad \Rightarrow$$

$$\Rightarrow A(\vec{x}^* - \vec{x}_{k+1}) = (\mathbb{I} - A) \cdot (A(\vec{x}^* - \vec{x}_k)) \Rightarrow \underbrace{\vec{b} - A\vec{x}_{k+1}}_{=: \vec{r}_{k+1}} = (\mathbb{I} - A)^k \underbrace{(\vec{b} - A\vec{x}_0)}_{=: \vec{r}_0}$$

tzv. reziduum v iteraci k+1 nebo 0

$(\mathbb{I} - A)^k$  lze rozepsat jako  $\alpha_0 \mathbb{I} + \alpha_1 A + \dots + \alpha_k A^k$   $\leadsto$  to je polynom v A  $\rightarrow$   
 $\rightarrow (\mathbb{I} - A)^k = \alpha_0 \mathbb{I} + \alpha_1 A + \dots + \alpha_k A^k = p^{\text{Rich}}(A)$  kde  $p^{\text{Rich}}(t) = \sum_{i=0}^k \alpha_i t^i = (1-t)^k$   
 $\rightarrow$  akorát místo skaláru  $t$  akorát mocninnou matici  $A$

$$\Rightarrow \vec{r}_k = p^{\text{Rich}}(A) \cdot \vec{r}_0$$

$\rightarrow$  v praxi  $\vec{r}_k$  často používáme jako ukazatel konvergence:  
 pro  $\vec{x}_k = \vec{x}^*$  máme  $\vec{r}_k = 0$  a tedy  $\|\vec{r}_k\| \approx 0$  často  
indikuje  $\vec{x}_k \approx \vec{x}^*$

$\Rightarrow$  jedna možnost, jak zlepšit Richardsonovu metodu je najít polynom  $p_k^{\text{opt}}(t)$  tak aby:

$$\| p_k^{\text{opt}}(A) \vec{r}_0 \| = \min_{p(t) \text{ je polynom stupně } \leq k} \| p(A) \vec{r}_0 \|$$

Tady ale pozor! Protože  $\vec{r}_k = A(\vec{x}^* - \vec{x}_k)$  tak na základě přednášky 17 víme, že  $\|\vec{x}^* - \vec{x}_k\| \leq \kappa(A) \cdot \|\vec{r}_k\| \Rightarrow$   
 $\Rightarrow$  malé reziduum neznamená vždy přesnou aproximaci - záleží na podmíněnosti matice  $A$

$\rightarrow$  tzv. generalized minimal residual method (GMRES)

## Porovnání s Richardsonem:

- nemá jasné jak z • dostat předpis pro  $\vec{x}_k$
- Richardson používá v každé iteraci stejnou formátku  $\times$
- Richardson velmi často nekonverguje
- Lineární algebra 2: Věta (Caley-Hamilton)  $\forall A \in \mathbb{R}^{n \times n} \exists$  polynom  $q(t)$  stupně  $n$  t, že  $A^n = q(A)$   
 $\Rightarrow$  na papíře dostaneme  $p_n^{\text{opt}}(t) = q(t) \Rightarrow$  na papíře GMRES zkonverguje v  $n$  krocích

Metody "typu GMRES" (= založené na optimálních polynomech) se nazývají Krylovovské metody & jsou "prakticky nejpopulárnější"

