

Metody Krylovových podprostorů a metoda konjugovaných gradientů (podle přednášky Z. Strakoše, rozšířeno).

↳ skvělá kniha Liesen, Strakoš: Krylov Subspace Methods

Nechť A je čtvercová regulární, dva fundamentální problémy jsou $Ax=b$ a $Ax=\lambda x$.

Už jsme se zabývali problémem, jak spočítat vlastní číslo.

- charakteristický polynom, ← nepoužitelné
- nějaký iterativní algoritmus.

Například: Mocninná metoda ze 7. přednášky.

Hledáme vlastní vektor v Krylovově podprostoru

$$\mathcal{K}_n(A, v) = \langle v, A \cdot v, A^2 \cdot v, \dots, A^{n-1} \cdot v \rangle$$

pro nějaký vektor v . Vektory postupně svírají malé úhly, proto chceme nalézt ortogonální bázi.

Arnoldiho algoritmus: Generování $\mathcal{K}_n(A, v)$ s Gram-Schmidtovou ortogonalizací, získáme ortogonální bázi v_1, \dots, v_d , když podprostor přestane růst po d krocích.

$$v_1 = v / \|v\|.$$

pro $n=1, 2, \dots$

$$\hat{v}_{n+1} = Av_n - \sum_{i=1}^n h_{i,n} v_i, \text{ kde } h_{i,n} = v_i^T Av_n.$$

$$h_{n+1,n} = \|\hat{v}_{n+1}\|.$$

$$v_{n+1} = \hat{v}_{n+1} / h_{n+1,n}.$$

→ Zastavit pro $=0$.

Gram-Schmidtova ortogonalizace
klasická, alternativně modifikovaná

Lze elegantně popsat v maticovém zápisu:

$$V_n = \begin{pmatrix} | & | & & | \\ v_1 & v_2 & \dots & v_n \\ | & | & & | \end{pmatrix}$$

a

$$H_n = \begin{pmatrix} h_{1,1} & h_{1,2} & \dots & h_{1,n} \\ h_{2,1} & h_{2,2} & \dots & h_{2,n} \\ \vdots & \vdots & \ddots & \vdots \\ 0 & & h_{n,n-1} & h_{n,n} \end{pmatrix}.$$

horní
Hessenbergova
matice

36] Potom po n krocích algoritmu platí

$$AV_n = V_n H_n + h_{n+1,n} v_{n+1} e_n^T,$$

(AV_1, \dots, AV_n) Vyjádření v₁, ..., v_n a v_{n+1} v posledním sloupci.

Rovnice popisuje vztah mezi vektory v_1, \dots, v_{n+1} a AV_1, \dots, AV_n .

a v posledním kroku $AV_d = V_d H_d$.

$\mathcal{K}_d(A, v)$ je invariantní podprostor zobrazení A , neboť platí $A\mathcal{K}_d(A, v) \subseteq \mathcal{K}_d(A, v)$. Potom H_d je matice zobrazení

$A|_{\mathcal{K}_d(A, v)}$ vůči ortogonální bázi $V_d = [v_1, \dots, v_d]$:

$$V_d^* (V_d V_d^* A) V_d = V_d^* A V_d = H_d.$$

Ortogonální projekce na $\mathcal{K}_d(A, v)$ vůči bázi v_1, \dots, v_d .

Nyní se omezme na symetrické matice $A = A^*$:

→ v řeči skalárního součinu $\langle Ax | y \rangle = \langle x | Ay \rangle$, tedy $\forall x, y: y^* Ax = y^* A^* x \iff A = A^*$.

Existuje spektrální rozklad $A = Q\Lambda Q^*$ na systém ortogonálních 1-dimenzionálních podprostorů, na které můžeme nahlížet zvlášť.

V případě Arnoldiho algoritmu je H_d Hessenbergova symetrická, tedy tridiagonální T_d . Proto v_{n+1} závisí pouze na v_{n-1} a v_n .

$$T_d = \begin{pmatrix} d_1 & \beta_2 & & & \\ \beta_2 & d_2 & & & \\ & & \ddots & & \\ & & & \ddots & \beta_n \\ & & & \beta_n & d_n \end{pmatrix}$$

Lanczosův algoritmus pro $A = A^*$

$$AV_n = V_n T_n + \beta_{n+1} v_{n+1} e_n^T.$$

$$AV_n = \beta_n v_{n-1} + d_n v_n + \beta_{n+1} v_{n+1}.$$

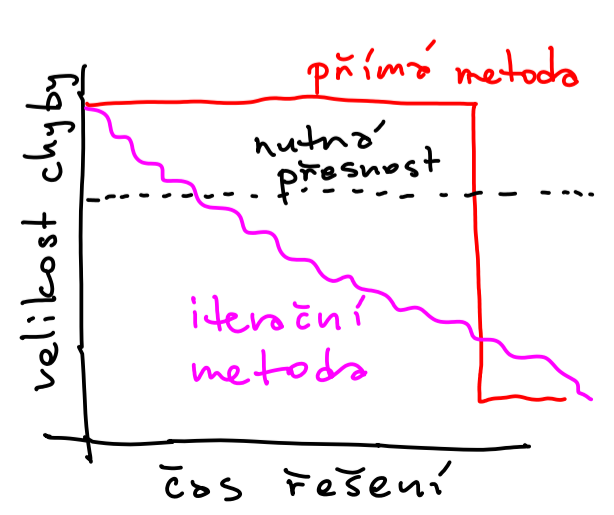
Při zokrouhlování se může ortogonalita ztratit.

krátká rekurence

Řešení soustavy $Ax=b$

→ přímé metody - třeba Choleského rozklad $A = LL^*$; $LL^*x = b$ se řeší $Ly = b$, $L^*x = y$.

→ iterační metody - konstruuje se posloupnost $x_0, x_1, \dots, x_n \rightarrow x$, označme chybu $e_n = x - x_n$ a residuum $r_n = b - Ax_n = Ae_n$.



Příklad iterční metody: stacionární / štěpící metody

$A = M - N$, kde M je snadno invertovatelná matice.

$$Ax = b \Rightarrow Mx = Nx + b.$$

$$x = M^{-1}Nx + M^{-1}b.$$

Poslední rovnost iterujeme $x_n = M^{-1}Nx_{n-1} + M^{-1}b.$

Pokud metoda konverguje, jde $e_n \rightarrow 0$. Konvergence a její rychlost závisí na spektrálním radiu $\rho(M^{-1}N)$.

Bekas, Curioni, Klavík: Metodu lze interpretovat jako aproximaci matice A pomocí M .

Metoda konjugovaných gradientů (CG):

A je symetrická, pozitivně definitní. Jedno z možných odvození:

Chceme $x_n \in x_0 + \mathcal{K}_n(A, r_0)$, tedy $x_n = x_0 + z_n$, $z_n \in \mathcal{K}_n(A, r_0)$.

To volíme tak, aby $r_n \perp \mathcal{K}_n(A, r_0)$. Protože $r_n = Ax_n - b$, ekvivalentně $e_n \perp_A \mathcal{K}_n(A, r_0)$, tedy x_n minimalizuje ze všech vektorů $\mathcal{K}_n(A, r_0)$ normu $\|x - x_n\|_A = \|e_n\|_A$.

V maticovém zápisu podmínky ortogonality:

$$0 = V_n^* r_n = V_n^* (b - Ax_n) = V_n^* (b - Ax_0 - Az_n).$$

Protože $v_1 = r_0 / \|r_0\|$, platí $V_n^* r_0 = \|r_0\| \cdot e_1$. Dále z_n leží v $\mathcal{K}_n(A, r_0)$, lze vyjádřit $z_n = V_n \cdot t_n$. Protože $V_n^* A V_n = T_n$, $0 = \|r_0\| \cdot e_1 - V_n^* A V_n t_n = \|r_0\| \cdot e_1 - T_n t_n$. Pak $x_n = x_0 + V_n t_n$.

Metoda konjugovaných gradientů je redukce $N \times N$ systému $Ax = b$ na $n \times n$ systém $T_n t_n = \|r_0\| \cdot e_1$.

Metoda má vysoce nelineární chování, protože aproximuje řešení $A^{-1}b$ pomocí polynomu $\langle b, Ab, A^2b, \dots, A^{n-1}b \rangle$.

Hrubý obecný odhad konvergence:

$$\frac{\|x - x_n\|_A}{\|x - x_0\|_A} \leq 2 \left(\frac{\sqrt{\kappa(A)} - 1}{\sqrt{\kappa(A)} + 1} \right)^n.$$

Odhad založen na spektru. Ale 1) ignorujeme strukturu spektra, 2) ignorujeme pravou stranu.

Metoda konstruuje nejlepší možný polynom ψ stupně n , že $\psi(0) = 1$ a minimalizujeme maximum $\psi(\lambda_i)$ přes vl. čísla A .

