

Gradientní iterační metody

princip: $Ax = b$

\Leftrightarrow minimum

A sym. pozit. definit

$$\phi(x) \equiv \frac{1}{2} x^T A x - x^T b$$

$-\nabla\phi(x) = b - Ax \equiv r$... reziduum = směr nejrych. klesání

OBECNÁ METODA PŘÍMEK:

odhad x_0 a směr p_0

x_1 ... minimalizuje $\phi(\bar{x}_0 + \alpha_0 \bar{p}_0)$

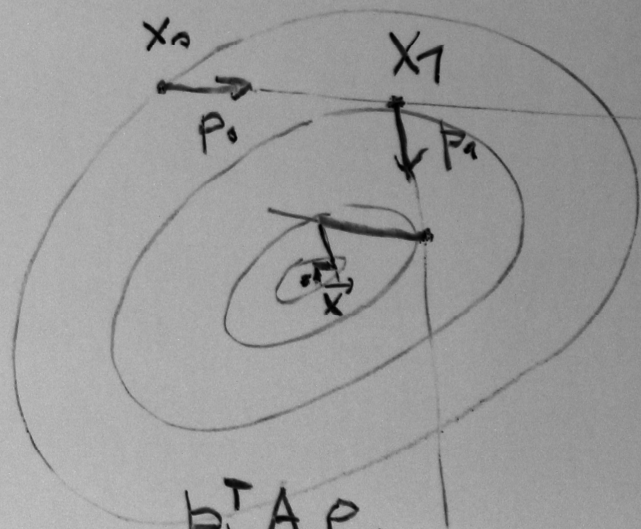
nový směr p_1

postupnost $x_0, x_1, x_2, \dots \rightarrow x$

podm. na min. $\bar{p}_k \cdot \nabla\phi = 0 \rightarrow \alpha_k = \frac{\bar{p}_k^T r_k}{\bar{p}_k^T A \bar{p}_k} = - \frac{\bar{p}_k^T A e_k}{\bar{p}_k^T A \bar{p}_k}$

$e_k \equiv x_k - x$

... chyba řešení



Metoda sdružených gradientů CGM (nebo prostě CG ... Conjugated gradients)

- volba ... $\vec{p}_k = -\nabla\phi(x_k) = \vec{r}_k$... METODA NEJMENŠÍHO SPÁDU
... směr nejrychl. klesání ϕ ... dá se DK, že konverg.
ale pomalu ... problém ... směry se opakují
- náprava: ... Gram-Schmidtova ortogonalizace směrů $-\nabla\phi(x_0), -\nabla\phi(x_1), \dots$
... po N iteracích (rozměr A ... $N \times N$) vyčerpá celý prostor
... ale vící A-součinu $(p_k, p_\ell)_A = p_k^T A p_\ell = \underline{\delta_{k\ell}}$
... motivace $\alpha_k = -\frac{p_k^T A e_k}{p_k^T A p_k}$... složka vektoru chyby
 $e_k = x_k - x$
→ v ∇ iteraci "ukrojíme" z $e_0 = x_0 - x$ jednu složku.
→ konvergence po N iteracích ... NESPOŘEDĚLNÉ
... V PŘESNĚ ARITMETICE

Algoritmus metody CG

$$x_0 = 0, r_0 = b, p_0 = r_0$$

$$m = 1, 2, 3, \dots$$

$$\alpha_{m-1} = \frac{r_{m-1}^T r_{m-1}}{p_{m-1}^T A p_{m-1}}$$

$$x_m = x_{m-1} + \alpha_{m-1} p_{m-1}$$

$$r_m = r_{m-1} - \alpha_m A p_{m-1}$$

$$\beta_m = \frac{r_m^T r_m}{r_{m-1}^T r_{m-1}}$$

$$p_m = r_m + \beta_m p_{m-1}$$

$$r_{m-1} = r_{m-1}^T r_{m-1}$$

$$w_{m-1} = A p_{m-1}$$

OPTIMALIZACE

Složitost...

1x $A p$ na cyklus

minimum podle směru

nová iterace

nové residuum

nový směr

(ortogonální na předchozím)

Krylov space: $\mathcal{K}_m = \mathcal{L} \{ b, Ab, A^2 b, \dots, A^{m-1} b \}$

obsahuje:

$x_1 \dots x_m$

$p_0 \dots p_{m-1}$

$r_0 \dots r_{m-1}$

báze v \mathcal{K}_m OB

vůči $(p_k | p_l)_A$

Vlastnosti CG-iterací:

(v přesné aritmetice)

- Ortogonalita: $p_k^T A p_l = (p_k, p_l)_A = 0$ pro $k < l$ konjugovanost směrů
 $r_k^T r_l = 0$ $k < l$... ortogonalita reziduí
 $r_k^T p_l = 0$ ↗

⇒ konvergence nejpozději po N krocích
(nebo pokud dělení 0 v algoritmu)

- konvergence (optimalita) v A -normě

x_n minimalizuje chybu $\|x_n - x\|_A \rightarrow \mathcal{K}_n$

a tedy $\|e_1\|_A \geq \|e_2\|_A \geq \dots \geq \|e_n\|_A \rightarrow 0$ t; $\|x_n - x\|_A = 0$

pro nějaké $n \leq N = \dim A$

- Souvislost s polynomiální aproximací spektra A

$$\|e_m\|_A = \text{minimum } \forall \text{ polynomy } p_n \text{ st } n \quad \|p_n(A) e_0\|_A$$

... CG hledá polynom st n , který má co nejmenší hodnotu na \forall bodech spektra $\sigma(A)$

→ pokud $\sigma(A)$ jen n ruz. u.e.č. → CG konverguje po n iter.

Vlastnosti CG-iterací:

rychlost konvergence: ... nechť A sym, posit-def.
+ číslo podmíněnosti $\kappa = \frac{\|A\|_2}{\|A^{-1}\|_2}$

pak:
$$\frac{\|x_m - x\|_A}{\|x_0 - x\|_A} \leq \frac{2}{\left(\frac{\sqrt{\kappa}+1}{\sqrt{\kappa}-1}\right)^m + \left(\frac{\sqrt{\kappa}-1}{\sqrt{\kappa}+1}\right)^m} \leq 2 \left(\frac{\sqrt{\kappa}-1}{\sqrt{\kappa}+1}\right)^m$$

DK: Trefethen, Bau Numerical lin. algebra

$\frac{\sqrt{\kappa}-1}{\sqrt{\kappa}+1} \sim 1 - \frac{2}{\sqrt{\kappa}}$... konvergence po $O(\sqrt{\kappa})$ iteracích
horní odhad většinou lepší

OPERATION COUNT:

- nejhorší $O(N^3)$
- prakticky - méně než N iterací
- ... vhodné využít řídkost A
- ... jen Ax_m potřeba

Předpodmínění (preconditioning)

- urychlování konvergence Krylovovských metod

... nahradit $Ax = b$ jinou úlohou se stejným řešením
necht' M regulární matice

$$\Leftrightarrow M^{-1}Ax = M^{-1}b \quad \dots \text{iterujeme } \bar{A} \equiv M^{-1}A$$

požadavky na M :


- rychlý výpočet M^{-1} (resp. řešení $Mx = c$)
- rychlejší konvergence?

... typicky $M^{-1} \approx A^{-1}$ t; $\|M^{-1}A - I\|_2$ malé

Trefethen: - $M^{-1}A$ blízko normální matici

a spektrum $M^{-1}A$ je "clustered" $\lambda \in \mathbb{C}$

viz polynomická
aprox. výše \rightarrow



Předpodmínění (preconditioning)

symetrický preconditioning:

$$M = CC^T \rightarrow M^{-1} = (C^{-1})^T C^{-1}$$

$$M^{-1}x \quad Ax = b \quad \Leftrightarrow \quad \underbrace{C^{-1}A(C^{-1})^T}_{\bar{A}} C^T x = \bar{C}^{-1}b$$

OBLÍBENÉ PŘEDPODMÍNOVACĚ:

$$\bar{A} \bar{y} = \bar{b} \quad \dots \quad x = C^{T^{-1}} \bar{y}$$

- $M = \text{diagonála } A$
- incomplete LU nebo Choleski $R^T R$
- hrubší grid nebo diskretizace nižšího řádu
- Periodická aprox. (nebo nějaká aprox. spec. vlastností)
- Část matice $A = A_1 + A_2$ (např. fyzikálně zanedb. členy-)
- bloková struktura
- střídavé směry

Další Krylovovské metody

- Lanczosovy iterace: ... opět A symetrická (Hermitovská) (ne nutně definitní)

→ konstrukce báze $\{\vec{q}_k\} \sim \mathcal{K}_m$ tak, $\exists e$ A tridiagonální:

$$\vec{q}_k^T \vec{q}_e = \delta_{ke} \quad \vec{q}_k^T A \vec{q}_e = \begin{pmatrix} \alpha_1 & \beta_1 & & & \\ \beta_1 & \alpha_2 & \beta_2 & & \\ & \beta_2 & \alpha_3 & \beta_3 & \\ & & & \ddots & \ddots \\ & & & & \beta_{m-1} & \alpha_m \end{pmatrix}$$

LANCZOSŮV ALGORITMUS:

$$\beta_0 = 0, \vec{q}_0 = 0, \vec{b} \text{ libovol.}$$

$$\vec{q}_1 = \vec{b} / \|\vec{b}\|$$

$$m = 1, 2, 3, \dots: \vec{r} = A \vec{q}_m$$

$$\alpha_m = \vec{q}_m^T \vec{r}$$

$$\vec{r} = \vec{r} - \beta_{m-1} \vec{q}_{m-1} - \alpha_m \vec{q}_m$$

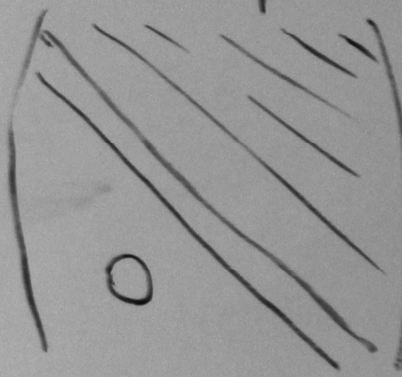
$$\beta_m = \|\vec{r}\|; \vec{q}_{m+1} = \vec{r} / \beta_m$$

Další Krylovovské metody

- Lanczosovy iterace: ... opět A symetrická (Hermitovská)
použití: diagonalizace matic ... n.č. $\begin{pmatrix} \alpha_1 & \beta_1 & & \\ \beta_1 & \alpha_2 & \beta_2 & \\ & \beta_2 & \ddots & \beta_{n-1} \\ & & \beta_{n-1} & \alpha_n \end{pmatrix}$ aproximují
n.č. $A \rightarrow$ Hyleraas-Undheim ... horní odhady Ritz values
... oddělující se vlastnost.

Další Krylovovské metody

Nesymetrické problémy $A^T \neq A$

- Lanczos \longleftrightarrow Arnoldi ... Obáze v \mathcal{K}_m ... q_m
takže $q_i^T A q_j =$ 
Horní Hessenberg \rightarrow
... \rightarrow rychlejší Gauss eliminace $Ax=b$
 \rightarrow rychlejší vl. č. QR-metodu

- CG \longleftrightarrow BiCG
... zavádí levé a pravé směry ... rekurence ... $\vec{q}^T A \vec{p}$... $A^+ \vec{q}$
- GMRES ... iterace na \mathcal{K}_m vycházející
z minimalizace $\|r_m\|_2 \rightarrow 0$