



poznámka: na předp. se řešení (s) je 2x spoj. diferencovatelné  
 lze per. portovat zpět  $\rightarrow \int (u' + f) \varphi v dx = 0 \quad \forall v \Rightarrow (D)$   
 pak jsou +3 formulace ekvivalentní.

- OBECNĚ:
- slabá formulace obecnější ... slabší požadky na řešení u (nemůžeme mít  $u' \in L^2$ , f může být diskrétní)
  - variační formulace vyžaduje pozitivní definitnost.  $a(u, v)$
  - obecně říkáme tvaru DK  $\pm$  a jednoduše řešíme (s) a dodatečně (někdy) DK se řešením je  $C^2$  t; platí (D)
  - aproximace řešení ~~lze~~ lze (s y' bodem) hledat v  $C^2$  např. pro částeck lineární funkce (viz níže).

PŘÍKLADY SLABÉ A VARIACNÍ FORMULACE jiných úloh

PŘ1: (Sturm-Liouville)  

$$\mathcal{D} u \equiv -\frac{d}{dx} [p(x) \frac{d}{dx} u(x)] + q(x) u(x) = f(x) \quad \text{na } x \in (a, b) \quad (D_a)$$

$$\text{ale } p, q, f \text{ spojité } p \text{ kladné; } \exists p_0 > 0: p(x) \geq p_0$$

$$\text{obraz podm. (b)no: } u(a) = u(b) = 0 \quad (D_b)$$

$$(D)$$

násobení test fci:  $a(v, u) = \int_a^b [v \frac{d}{dx} (p u') + v q u] dx$   
 posit. def. sym. bilineal  $= \int_a^b (p v' u' + q v u) dx$   
 $\rightarrow$  slabá formulace  $a(u, v) = \langle f, v \rangle \quad \forall v \in V \quad (S)$   
 což je podm. minim. bilineal  $P[u] \equiv \frac{1}{2} a(u, v) - \langle f, v \rangle \rightarrow (V)$

PŘ2: (rovnice vyššího řádu)

$$\mathcal{D} u \equiv [p(x) u'']'' - [q(x) u']' + r(x) u(x) = f(x)$$

$$\rightarrow a(u, v) = \int_a^b (p u'' v'' + q u' v' + r u v) dx \Rightarrow (S) \text{ a } (V)$$

PŘ3: (nelineární úloha)

$$\mathcal{D} u \equiv -\frac{d}{dx} [p u'] + q u = f(x, u) \quad (D_a)$$

$$a(u, v) \equiv \int (p u' v' + q u v) dx \text{ jako PŘ1, ale}$$

$$(S): a(u, v) = \int_a^b f(x, u) v(x) dx$$

což je podm. extrém. bilineal  $F[u] \equiv \int_a^b \left\{ \frac{1}{2} [p u'^2 + q u^2] - \int_a^{u(x)} f(x, t) dt \right\} dx$   $\rightarrow (V)$   
 pro  $\frac{\partial}{\partial u} f(x, u) \leq 0$   
 jde o minimum

PŘ3: obecná okrajová podmínka:  $\alpha_1 p(a) u'(a) + \beta_1 u(a) = 0$   
 $-\alpha_2 p(b) u'(b) + \beta_2 u(b) = 0$  (D<sub>a</sub>)

(D<sub>b</sub>): ~~to~~ jako PŘ1

Integrace s test. fun. (+ nec. podmínky):

$$\int_a^b [qu + p u' v] dx + \frac{\beta_2}{\alpha_2} v(b) u(b) + \frac{\beta_1}{\alpha_1} v(a) u(a) = \int_a^b v f dx$$

tj. funkcional  $a(u, v) = \int_a^b [p u' v + q u v] dx + \frac{\beta_2}{\alpha_2} v(b) u(b) + \frac{\beta_1}{\alpha_1} v(a) u(a)$

(S):  $a(u, v) = \langle v | f \rangle$  .. sym. sym. funkcional, pozit. definitní

↪ + test. fun. bez podmínek ~~na~~  $v=0$  na krajích

→ (V) .. jako obvykle:  $F[u] = \frac{1}{2} a(u, u) - \langle f | u \rangle$  .. minimum na

PŘ4: formulace eliptické rovnice ve více dimenzích

$$\begin{aligned} \Delta u &\equiv -\partial_x(p \partial_x u) - \partial_y(p \partial_y u) + q u = f & (D_a) \\ &t; -\operatorname{div}(p \nabla u) + q u = f & \text{na } \Omega \end{aligned} \quad \left. \vphantom{\begin{aligned} \Delta u &\equiv -\partial_x(p \partial_x u) - \partial_y(p \partial_y u) + q u = f \\ &t; -\operatorname{div}(p \nabla u) + q u = f \end{aligned}} \right\} (D)$$

+ Dirichletova podmínka  $u=0$  pro  $(x, y) \in \partial\Omega$  (D<sub>b</sub>)

pozn.: Green věta:  $\int \operatorname{div} u \cdot v \, d\Omega = \int u \operatorname{div} v \, d\Omega - \int u \nabla v \cdot \vec{n} \, d\Omega$  3 pi s + v obvy  
 + urobent test. fun.  $v \in V = \{v \text{ spoj. na } \Omega, v' \text{ poc. spoj. na } \Omega, v=0 \text{ na } \partial\Omega\}$  (D<sub>b</sub>)

→ (S)  $a(u, v) \equiv \int_{\Omega} (p \operatorname{div} u \cdot \nabla v + q u v) \, d\Omega = \int_{\Omega} f v \, d\Omega \equiv \langle f | v \rangle \quad \forall v \in V$

(V)  $F[u] \equiv \frac{1}{2} a(u, u) - \langle f | u \rangle$  malý ná minimum přes  $u \in V$

PŘ5: stejná úloha, ale (D<sub>b</sub>):  $p \nabla u \cdot \vec{n} = -k u$  na  $\partial\Omega$

modifikace  $a(u, v) = \int_{\Omega} p \operatorname{div} u \cdot \nabla v + q u v \, d\Omega + \int_{\partial\Omega} k u v \, ds$

Trochu víc matematiky: Prostory pro slabou form. PDE:

.. V byl zbytečně restriktivní

OBECNĚ:

$a(u, v)$  je symetrická bilineární forma na  $V$

+ pozitivně definitní → slabší součin na  $V$  ... Hilbertův prostor

(přesněji: ještě úplnost .. tj. + Cauchy posl.  $v_j$  konverguje ve  $V$ )

Základní prostor  $L_2(a, b) = \{v : \int_a^b v^2 dx < \infty\}$  se slabě konjuguje

$\langle u | v \rangle \equiv \int_a^b u v \, dx$  .. pozn.:  $|\langle u | v \rangle| \leq \|u\| \cdot \|v\| < \infty$  ... OK pro  $u, v \in L_2$

nyší podmínky na prostr. není prostor ...  $a(u, v)$

$$H^1(\langle a, b \rangle) = \{v : v, v' \in L_2\}$$

se skalárním součinem  $(u, v)_H = \int_a^b u v + u' v' dx$  a normou  $\|u\|_H = \sqrt{(u, u)_H}$

pozn:  $H^1$  je větší než  $V$  hledáme používáme

okraj-podm:  $H_0^1(\langle a, b \rangle) = \{v \in H^1; v(a) = v(b) = 0\}$

ve více dim. potřebujeme:

$$L_2(\Omega) = \{v, \int_{\Omega} v^2 dx < \infty\}$$

$$(u, v) = \int_{\Omega} u v d\Omega$$

$$H^1(\Omega) = \{v \in L_2(\Omega); \frac{\partial v}{\partial x_i} \in L_2(\Omega) \forall i=1, \dots, d\}; (u, v)_H = \int_{\Omega} (u v + \nabla u \cdot \nabla v) d\Omega$$

$$H_0^1(\Omega) = \{v \in H^1(\Omega); v=0 \text{ na } \partial\Omega\} \subset H^1(\Omega)$$

pro úlohy s více derivacemi potřebujeme  $H^2(\Omega)$  -- tři druhé derivace  $L_2$   
v 1.0 skalár. součin  $\int (u v + u' v' + u'' v'')$  dx .. více dim. souč L $\cdot$ V úlohy

.. speciální případ Sobolevových prostorů  $W^{k,p}(\Omega)$

vycházejících z  $L^p(\Omega)$  ... norma  $(\int |v|^p dx)^{1/p} = \|v\|$

... úplnosti  $\rightarrow$  Banachův prostor; jen pro  $p=2$  skalár součin  $\rightarrow$  Hilbert.

### Ritzova variační a Galerkinova metoda

aneb použití (V) a (S) formulací pro přibližné řešení PDE

#### Obecná formulace:

- Necht  $V$  je Hilbertův prostor se skal. souč.  $\langle \cdot, \cdot \rangle$  a  $\|\cdot\| = \sqrt{\langle \cdot, \cdot \rangle}$
- Necht  $a$  je bilineární forma na  $V$  splňující
  - symetrická  $a(u, v) = a(v, u)$
  - spojitá, tj;  $\exists \gamma > 0 : |a(u, v)| \leq \gamma \|u\| \cdot \|v\| \forall u, v$   
( $v$   $\in$  dim  $\neq$  lin je spojitá; ode odchod na Annunucci ve  $V$   $\rightarrow$   $\infty$   $\rightarrow$   $\infty$ )
  - $a$  je eliptická na  $V$ , tj;  $\exists \alpha > 0 : a(v, v) \geq \alpha \|v\|^2 \forall v \in V$   
( $\rightarrow$  podobně -- pozit definit lub  $\infty$  dim (ne semi definit))
- Necht  $L$  je spojitéj lin. <sup>forma</sup>  $\rightarrow$   $\exists \lambda > 0 : |L(v)| \leq \lambda \|v\| \forall v \in V$

$\rightarrow$  dá se DK: (S) nalezněte  $u \in V : a(u, v) = L(v) \forall v \in V$

(V) nalezněte  $u \in V : F(u) \leq F(v) \forall v \in V$ , kde

$$F(u) \equiv \frac{1}{2} a(u, u) - L(u)$$

je-li ekvivalentní a ač  $\exists$  ! řešení  $u \in V$ ; navíc  $\|u\| \leq \frac{\Lambda}{\alpha}$

pozn (S) má smysl i pro nesymetrické  $a(\cdot, \cdot)$

Diskretizace problému

nechtě  $V_n \subset V$  je konečné ~~kon~~ komponentů a bází  $\{\varphi_1, \varphi_2, \dots, \varphi_n\}$

$t_j$   $\forall v \in V_n \exists \eta_i \in \mathbb{R} : v = \sum_i \eta_i \varphi_i$

Ritzův variační princip .. minimalizace  $F[v]$  na  $V_n$

$\equiv$  minimalizace funkce  $n$  proměnných  $\eta_i$   
vede na stejnou rovnici jako

Galerkinova metoda ... splnění (S) na  $V_n$

$t_j$  hledáme  $u_n \in V$  (nejlepší odhad řešení  $u$  ve  $V_n \subset V$ )

habe, že  $a(u_n, v) = L(v) \quad \forall v \in V_n$

$t_j$  (lineárně):  $a(u_n, \varphi_j) = L(\varphi_j) \quad \forall j = 1, \dots, n$

+ dosazení  $u_n = \sum \xi_i \varphi_i \rightarrow A \xi = b$ , kde  $A_{ij} = a(\varphi_i, \varphi_j)$   
 $b_j = L(\varphi_j)$

terminologie:  $A$ .. matice tuhosti } matice sym.  
 $b$ .. vektor zatížení } elastič.

pozn: Elliptická ...  $a(v, v) = a(\sum \eta_i \varphi_i, \sum \eta_i \varphi_i) = \eta^T A \eta$

$\Rightarrow A$  je symetrická pozitivně def. matice  $\Rightarrow$  regulární

$\Rightarrow \exists!$  řešení  $\xi = A^{-1} b$

stabilita metody pro  $n \rightarrow \infty$  ... platí  $\|u_n\| \leq \frac{\Lambda}{2}$

neboť  $\alpha \|u_n\|^2 \leq a(u_n, u_n) = L(u_n) \leq \Lambda \|u_n\| \Rightarrow$   
eliptič.

Metoda konečných prvků (FEM)

.. metoda jak systematicky konstruovat  $V_n$  -- rozdělení  $\Omega$  na malé oblasti  $\omega_k$

Požadavky (nároky FEM):

- co nejlepší pokrytí  $V_n \supset V_n$  (.. systematická konstr. bází  $n \rightarrow \infty$  ... polynomů na podoblastech  $\Omega$ )
- Efektivní algoritmus řešení  $A \xi = b$  (kde  $A$  je matice ..  $\varphi_i$  mají malý support a jen mal. členy pro přibližující suppo nemulové)
- Snadná rekonstrukce řešení  $u \approx \sum \xi_j \varphi_j(x)$  ...  
( $x \in \omega_k$  a jen několik  $\varphi_j$  nemulových na  $\omega_k$   
navíc většinou  $\varphi_j(x) = 1$  ve význačných bodech sítě)  
 $\Rightarrow 0$

Implementace FEM pro 1D problém


$\Omega = \langle a, b \rangle$

"triangulace oblasti:"

$\omega_j = \langle x_{j-1}, x_j \rangle$

$V_m =$  prostor  $\mathcal{U}$  spoj. po částech lin. fci

$V_m \subset V$



počet volných parametrů =  $m$  .. měrná base  $\{\phi_i(x_j) = \delta_{ij}\}$   $\text{supp } \phi_i = \omega_i \cup \omega_{i+1}$

v rozkladu  $v(x) = \sum_{j=1}^m \eta_j \phi_j(x)$  jsou koef.  $\eta_j \equiv v(x_j)$

matice křivosti (gramova matice)  $A_{ij} \equiv a(\phi_i, \phi_j)$

... nenulová jen pokud  $i=j$  nebo  $i$  a  $j$  nejbliž. sousedi

např. pro  $a(u, v) = \int (\kappa u'v' + q u v) dx$  stačí int. poly 2. ř.

tj. máš  $\int_{\omega_j} \kappa, \int_{\omega_j} q, \int_{\omega_j} q x, \int_{\omega_j} q x^2$

speciální příklad: Poisson rce na rovnoměrné síti:  $-\Delta u = f$

výsledek  $\frac{1}{h} \begin{pmatrix} 2 & -1 & & & \\ -1 & 2 & -1 & & \\ & -1 & 2 & \ddots & \\ & & \ddots & \ddots & \ddots \\ 0 & & & & 1 \end{pmatrix} \begin{pmatrix} \eta_1 \\ \eta_2 \\ \vdots \\ \eta_m \end{pmatrix} = \begin{pmatrix} b_1 \\ \vdots \\ b_m \end{pmatrix}$  kde  $b_j = \int_a^b f(x) \phi_j(x) dx \approx h f(x_j)$   
 $\rightarrow$  přejde na rovnici co jsme odvodili pro koneč. diference

poznámka: tato formulee má smysl i pro  $\delta$ -pravou stranu

Odhad chyby .. pro aprox. po částech lin. fci

① ověření spjatosti  $a(u, v) \equiv \int_{\Omega} u'v' dx \leq \|v'\|_{L_2} \cdot \|u'\|_{L_2} \leq \|v\|_{H_1} \cdot \|u\|_{H_1}$   
 tj. spjaté s konst  $\gamma = 1$

② ověření eliptičnosti tj.  $\exists \alpha: a(v, v) \geq \alpha \|v\|_{H_1}^2$

plati  $a(v, v) = \int (v')^2 dx$

leba  $\int_0^1 (v')^2 dx$  píšeme  $v(x) = 0 + \int_0^x v' dx \rightarrow |v(x)| = \left| \int_0^x v' dx \right| \leq \int_0^x |v'| dx$

$\Rightarrow |v(x)| \leq \int_0^x |v'| dx \leq \int_0^1 |v'| dx \leq \sqrt{\int_0^1 1 dx} \sqrt{\int_0^1 (v')^2 dx} \Rightarrow |v|^2 \leq \int_0^1 (v')^2 dx$   
 $\Rightarrow \int_0^1 |v|^2 dx \leq \int_0^1 \int_0^1 (v')^2 dx dx = \int_0^1 \int_0^1 (v')^2 dx dx$

tj.  $a(v, v) = \frac{1}{2} \int v'^2 dx + \frac{1}{2} \int v'^2 dx \geq \frac{1}{2} \int (v'^2 + v'^2) dx = \frac{1}{2} \|v\|_{H_1}^2$

tj.  $\alpha = \frac{1}{2}$




Zo becnímí do více Dim:


triangulace + po čístech liníí fce ... 3 parametry na jeden  $\Delta$  + spojitost

$\Rightarrow$  tolik param. kolik vnitřních bodů

báze:



$\rightarrow$  zadání




poly 2. ř. ve 2D:  
 $A + Bx + Cy + Dx^2 + Ey^2 + Fxy$   
 $\rightarrow$  6 param.  
 $\rightarrow$  hocholy 10

Lagrange interpolace ve více D:

vrcholy simpleku

$$P_i = (x_1^{(i)} \dots x_D^{(i)})$$



lineární fce  $\phi(\vec{x})$  taková, že  $\phi(\vec{x}^{(m)}) = 0 \quad \forall m = 0, \dots, D-1$   
 $\phi(\vec{x}^{(D)}) = 1$

$$\pi(\vec{x}) = \begin{vmatrix} x_1 & x_1^{(1)} & \dots & x_1^{(D-1)} \\ \vdots & \vdots & \ddots & \vdots \\ x_D & x_D^{(1)} & \dots & x_D^{(D-1)} \end{vmatrix}$$

uvážujeme:


$$\pi(\vec{x}) = \begin{vmatrix} x_1^{(0)} - x_1 & x_1^{(0)} - x_1^{(1)} & \dots & x_1^{(0)} - x_1^{(D-1)} \\ \vdots & \vdots & \ddots & \vdots \\ x_D^{(0)} - x_D & x_D^{(0)} - x_D^{(1)} & \dots & x_D^{(0)} - x_D^{(D-1)} \end{vmatrix}$$

pak  $\phi(\vec{x}) = \pi(\vec{x}) / \pi(\vec{x}^{(D)})$

Další typ prvky:

**P3** ve 2D:  $P2$  (6 param) +  $ax^3 + bx^2y + cy^2 + dy^3$  (4 param)

albo 10:



- pro  $P4$  přibude 5 param atd ... aritm. posl.



# Gradientní iterační metody

Základní formulace: najít  $x$ :  $Ax = b$

kde  $A$  je symetrická, pozitivně definitní matice

převodem na minimalizaci kvadratické formy:  $\phi(x) = \frac{1}{2} x^T A x - x^T b$   
 $\nabla \phi(x) = \frac{1}{2} (2 x^T A - b) = x^T A - b$  neboť  $\nabla \phi(x) = Ax - b$  tj;  $\nabla \phi = 0 \Leftrightarrow Ax = b$

pozitivní definitnost  $\hookrightarrow$  je minimum

poznámka: pro obecné  $x$  je  $-\nabla \phi(x)$  residuum  $r \equiv b - Ax$

metoda přímek:

- zvolíme  $x_0$ , a směr  $p_0$
- každé další  $x_{k+1}$  hledáme jako minimum funkce  $f(d_k) \equiv \phi(x_{k+1} = x_k + d_k p_k)$

... různé metody podle volby  $p_k$

## Metoda největšího spádu (steepest descent meth.)

praxe pedagog. význam  $\rightarrow$  abychom viděli, že to co nás první napadne není vždy nejlepší a použijí obec. vlast. quad. met.  $\rightarrow$

volíme  $d_k$  v  $\phi(x_k + d_k r_k)$  volba  $p_k = -\nabla \phi = r_k$

$\rightarrow$  voláme nejvíce zmenšujeme  $\phi$ ; navíc  $r^T$  volíme alespoň trochu polehne

... nalezení  $d_k$ :  $\phi(x_k + d_k r_k) = \frac{1}{2} (x_k + d_k r_k)^T A (x_k + d_k r_k) - (x_k + d_k r_k)^T b$

$$\frac{\partial \phi}{\partial d_k} = r_k^T A (x_k + d_k r_k) - r_k^T b = d_k r_k^T A r_k + r_k^T (A x_k - b) = d_k r_k^T A r_k - r_k^T r_k = 0$$

$$\Rightarrow d_k = \frac{r_k^T r_k}{r_k^T A r_k}$$

shrnutí:

$r_k = b - Ax_k$	} dvě matice násobení na jeden krok metody. Možná lépe: $r_{k+1} = b - Ax_{k+1} = b - A(x_k + d_k r_k) = r_k - d_k A r_k$
$d_k = r_k^T r_k / r_k^T A r_k$	
$x_{k+1} = x_k + d_k r_k$	

Algoritmus: volba  $x_0$ ;  $r_0 = b - Ax_0$

$k = 0, 1, \dots$ :  $w_k = A r_k$   
 $d_k = r_k^T r_k / r_k^T w_k$   
 $x_{k+1} = x_k + d_k r_k$   
 $r_{k+1} = r_k - d_k w_k$

$\leftarrow$  jediné matice nás. na iteraci  
navíc málo operací pro téžkou matici

ukončení  $\|r_{k+1}\| \leq \epsilon$  konec

$\rightarrow$  obecný algoritmus; je třeba dodat proceduru nalezení  $A r_k$  (nebo  $-\nabla \phi$  pro obecnější případ)

poznámky: pro analýzu konvergence je vhodné diagonální zrcle  $A$ :

symetrická matice  $\rightarrow A = \sum_i v_i \lambda_i v_i^T$

pozitivně definitní  $\rightarrow \lambda_i > 0 \ \forall i$

pro dybu řešení platí:  $e_k \equiv x_k - x \quad \dots \quad A e_k = -r_k$

• pokud  $e_0$  je vl. vektor  $\dots$  konv. po jedné iteraci

• pokud  $A$  ~~isotropní~~ <sup>trapez</sup>  $\lambda_1 = \lambda_2 = \dots$   
 $\rightarrow$  konvergence po jedné iteraci

• ale obecně může být špatně po špatně podmíněnou matici  $\lambda_{\min} \ll \lambda_{\max}$   
 $\dots$  už ve 2D: minimálně potřebuješ deset iterací  $\dots$  dobré si uvědomit:



$r_{k+1} \perp r_k$   
 (obecně v následě přímek  $r_{k+1} + p_k$ )

OBECKE .. analýza konvergence:  $e_k = \sum_i \alpha_i v_i$

$e_{k+1} = x_{k+1} - x = x_k - x + \alpha_k r_k = e_k + \alpha_k r_k$

konvergence v  $A$ -normě  $\dots \quad \|e_k\|_A \equiv \sqrt{e^T A e}$

$\|e_{k+1}\|_A^2 = (e_k + \alpha_k r_k)^T A (e_k + \alpha_k r_k) = \|e_k\|_A^2 + 2\alpha_k r_k^T A e_k + \alpha_k^2 r_k^T A r_k$

$= \|e_k\|_A^2 - \frac{(r_k^T r_k)^2}{r_k^T A r_k}$  ← skomčit už tady

$= \|e_k\|_A^2 \left( 1 - \frac{(\sum_i \alpha_i^2 \lambda_i^2)^2}{\sum_i \alpha_i^2 \lambda_i^3 \sum_i \alpha_i^2 \lambda_i} \right)$

tohle je zajímavé: skalár součin vektorů  $(\alpha_1 \lambda_{i_1} \dots) \cdot (-\alpha_i \lambda_i)$

$\omega_1$  a  $\omega_2$  kolmé  $\dots$  je-li  $\lambda_1 = \lambda_2 = \dots$   
 (je-li tedy rovnost)  $\equiv \sum_i \alpha_i^2 \lambda_i^2 \leq \|\omega_1\| \|\omega_2\|$

$v_k$  řešení  $\rightarrow$  lepší volba  $p_k$

Podstata problému  $\dots$  v seřizování směru se optimalizuje stejné měry

$\dots$  ve 2D je vidět  $r_{k+1} \perp r_k + r_{k-1}$

řešíme .. navržit, aby se "každý měr pohledával jednou"

obecně: minim se měm  $p$ :  $\phi(x + \alpha p) = \frac{1}{2}(x + \alpha p)^T A (x + \alpha p) - p^T b$

$\frac{\partial \phi}{\partial \alpha} = p^T A (x + \alpha p) - p^T b = p^T (Ax - b) + \alpha p^T A p = -p^T r + \alpha p^T A p = 0$

$\Rightarrow \alpha = \frac{p^T r}{p^T A p}$

dále jsem rovnal biclovžene grad.  $\rightarrow$  rozebrat lépe

+ použít na minimalizaci obecně

... Majit co přesně zavést v algoritmu )

# Metoda sdružených gradientů

hlavní trik: vektor  $d = \frac{p^T A}{p^T A p} = -\frac{p^T A e}{p^T A p}$  je vorem po

skládku vektoru pokud máme skal. rovnici s neznámou danou  $A$   
 $T_j$  je například najít sadu  $A$ -ortogonálních (sdružených) směrů:

$$p_k^T A p_k = \delta_{kk} \quad \dots \quad e_k = \sum_j \beta_j p_j \equiv x_k - x$$

tedy  $d_k \equiv \frac{p_k^T m_k}{p_k^T A p_k} = -\frac{p_k^T A e_k}{p_k^T A p_k} = -\beta_k \frac{p_k^T A p_k}{p_k^T A p_k} = -\beta_k$

tj;  $x_{k+1} = x_k + d p_k = x + \sum_j \beta_j p_j - \beta_k p_k$

→ každý krok odečte jeden člen sumy ... konvergence po  $N$  krocích

konstrukce  $p_k$ ? a gradientů  $\phi(x)$  pomocí Gram-Schmidt ob.

Algoritmus:

① volba  $x_0$

$$r_0 = b - A x_0$$

$$p_0 = r_0 ; \gamma_0 = r_0^T r_0$$

pro  $k=0, 1, \dots$ :

$$w_k = A p_k$$

$$d_k = p_k / (p_k^T w_k)$$

$$x_{k+1} = x_k + d_k p_k$$

$$r_{k+1} = r_k - d_k w_k$$

$$\gamma_{k+1} = r_{k+1}^T r_{k+1}$$

$$\beta_k = \gamma_{k+1} / \gamma_k$$

$$p_{k+1} = r_{k+1} + \beta_k p_k$$

minimalizace  
podél přímky  $A p_k$   
 $x_k + d_k p_k$

konstrukce nového  
měří

poznámky: • je opět jen jedno násobení na jednu iteraci

navíc jeho  $r_k$  lad  $p_k$  leží v Krylovově prostoru

$$\mathcal{L}(r_0, A r_0, A^2 r_0, \dots, A^{k-1} r_0)$$

$$\mathcal{L}(A e_0, \dots, A^k e_0)$$

• platí: 1)  $p_k^T A p_j = 0 \quad \forall j=0, 1, 2, \dots, k-1$

2)  $r_k^T r_j = 0 \quad \forall j=0, \dots, k-1$

3)  $r_k^T p_j = 0 \quad \forall j=0, \dots, k-1$

konjugovanost směrů

mutualita ortogonalita reziduí

tohle by chtělo rozepsat

## Vlastnosti metody CG:

CG4

→  $x_k, p_k, r_k \in \mathcal{L}\{b, Ab, \dots, A^m b\} \equiv K_m$   $n = \begin{cases} k & r, p \\ k-1 & x \end{cases}$

→ "optimalnost CG":

$x_m$  minimalizuje  $\|x_m - x\|_A$  v  $K_m$  a tedy  $\|x_m - x\|_A \leq \|x_{m-1} - x\|_A$

$\|x_m - x\|_A = 0$  pro nějaké  $m \leq N \equiv \dim A$

→ Rychlost konvergence CG:

necht  $A$  posit. def., symmetrická;  $\kappa = \tilde{\sigma}$ . podmíněnosti  $A \equiv \frac{\|A\|_2}{\|A^{-1}\|_2}$

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

"PRECONDITIONING" -- předpodmínění

= Formulace problému jiným způsobem, aby matice kterou iterujeme měla lepší vlastnosti (→ rychlejší konvergence)

PR:  $Ax = b$  ;  $M$  regulární matice

$\Leftrightarrow M^{-1}Ax = M^{-1}b$  ... iterujeme  $(M^{-1}A)$  místo  $A$

terminologie:  $M \equiv$  preconditioner

- musíme umět rychle počítat  $M^{-1}$  (resp. řešit  $My = c$ )

- typicky výhodné, aby  $\|M^{-1}A - I\|_2$  malá

Trefethen "rule of thumb":

$M$  is good if  $M^{-1}A$  not far from normal and its eivals are clustered.

Symetrický "PRECONDITIONING"

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

$\hookrightarrow M^{-1}Ax = M^{-1}b \Leftrightarrow \underbrace{[C^{-1}AC^{-1}]}_{\text{nová matice k iterování}} C^T x = C^{-1}b$

OBLÍBENÉ ZPŮSOBY:

• Diagonální matice  $A = M$

• Incomplete LU .. jako LU ale nečláme

jem prvky, které nulové v  $M$  (nebo Cholesky)  $R^+R$

• Hrubší grid

• Fyzikál. aprox.

• Period. aprox.

• Lokální aprox.

• Blok. precond.

• Diskr nižšího řádu

• Část matice  $A = A_1 + A_2$

• Strídavé směry

# DALŠÍ KRYLOVOVSKÉ METODY

CG5

- CGN - CG aplikované na normální matici

$$Ax = b \rightarrow A^T A x = A^T b$$

→ problém ... zhoršil číslo podmíněnosti, ale někdy smesitelné

- BCG - Biconjugate Gradients

- zavádí levé a pravé směry

Algoritmus:

$$x_0 = 0$$

$$p_0 = r_0 = b$$

$$q_0 = s_0 = \text{libovol.}$$

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

$$d_m = \frac{s_{m-1}^T r_{m-1}}{q_{m-1}^T A p_{m-1}}$$

$$x_m = x_{m-1} + d_m p_{m-1}$$

$$r_m = r_{m-1} - d_m A p_{m-1}$$

$$s_m = s_{m-1} - d_m^* A^T q_{m-1}$$

$$\beta_m = \frac{(s_m^T r_m)}{(s_{m-1}^T r_{m-1})}$$

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

$$q_m = s_m + \beta_m^* q_{m-1}$$

→ platí:  $s_m^T r_j = q_m^T A p_j = 0$  pro  $j < m$

- Lanczos & Arnoldi

→ hledá bázi  $v_0, v_1, \dots, v_{m-1}$  v  $K_m$  tak, že  $\langle v_i, v_j \rangle = \delta_{ij}$

a  $\langle v_i, A v_j \rangle$  je 3-diagonální (upper Hessenberg)

- GMRES: minimalizuje  $\|r_m\|_2$  v  $K_m$

→ ale plná rekurence při ortogonalizaci na předeh