

# OPAKOVÁNÍ: Slabá formulace, Galerkin a FEM


Okrajová úloha:  $\hat{D}u = f$  na  $\vec{x} \in \Omega$   
 $u = 0$  na  $\partial\Omega$

PR:  $-\Delta u(x) = f(x)$   
 $u(x) = 0$   
 na  $(0, 1)$

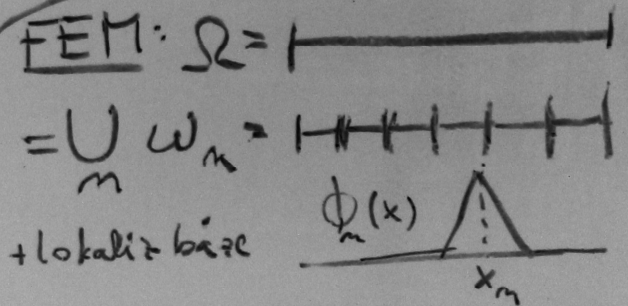
Slabá formulace:  $a(u, v) = L(v) \quad \forall v \in V$   
 na nějakém  $V \dots$  Hilbert s  $(\cdot, \cdot)$  a  $\|\cdot\|$

$\int_0^1 u'(x)v'(x) dx = \int_0^1 f(x)v(x) dx$   
 $V = H_0^1 = \{v \in L_2, v' \in L_2, v(0) = v(1) = 0\}$

Galerkinova metoda:  $V_m = \mathcal{L}\{\phi_1, \phi_2, \dots, \phi_m\} \subset V$   
 ... aproximace  $u_m \in V_m$ :  
 $a(u_m, v) = L(v) \quad \forall v \in V_m$



$\rightarrow A\zeta = b$ ; kde  $A_{mm} = a(\phi_m, \phi_m)$   
 $b_m = L(\phi_m)$   
 $u_m(x) = \sum_m \zeta_m \phi_m(x)$



$\rightarrow$  A řídka matice  
 $\rightarrow \zeta_m \equiv u(x_m)$

# Zvyšování přesnosti - příklady prvků v 1D

ukázali jsme ... Poisson 1D ...  $V_m =$  po částech lin. spoj fce

$$\rightarrow \|u - u_m\|_{H^1} \leq Ch \quad \dots \text{konverguje jako } O(h)$$


odhad pomocí Lax-Milgram věty (ale nemusí bodově  $\nabla$  integ. norma)

... (S) dá nejlepší aprox.  $u$  ma  $V_m \subset V$

... přesnější řešení  $\rightarrow$  zvětšit  $V_m$  ... RŮZNÉ STRATEGIE

- Lagrangeovy prvky :- pomocné body uvnitř každé podoblasti  $\omega_m$
- vyšší polynomy ... nulové ve  $\partial\omega$  bodech mimo  $\Gamma$

PR: kvadratický Lagrange-prvek  $P_2$  ...  $V_m$  po částech kvadraty, spojitě



$$\phi_k(x) = A + Bx + Cx^2$$

pomocné body  $x_0, x_1, x_2$

$$\phi_{m,k}(x_\ell) = \delta_{k\ell}$$

HOTOVÉ BÁZOVÉ FCE


NA  $V_m$  ... spojitě

# Hladší prvky v 1D


zatím  $V_m \dots$  spojité  $\dots$  jinak  $\phi'$  generuje  $\delta$ -členy v  $\int \phi_m \phi_n$   
 pro úlohy vyšších řádů  $\dots V = H^2 \dots (\phi, \psi) = \int (\phi'' \psi'' + \phi' \psi' + \phi \psi)$   
 $\rightarrow$  nutná spojitost 1. derivací jinak  $\delta$ -člen  $\uparrow$

PR: Hermiteovy prvky v 1D  $\dots$  odvozeny z Hermite - aprox.

$V_m = \left\{ \begin{array}{l} \text{po částech kubické; spojité } \omega(x), \omega'(x) \\ \text{(spline)} \end{array} \right\}$   
 $ax^3 + bx^2 + cx + d \leftarrow$  dáno znalostí  $\phi(x_{m-1}), \phi'(x_{m-1})$   
 $\phi(x_m), \phi'(x_m)$



volba  $\dots$  jen 0 a jednota 1:



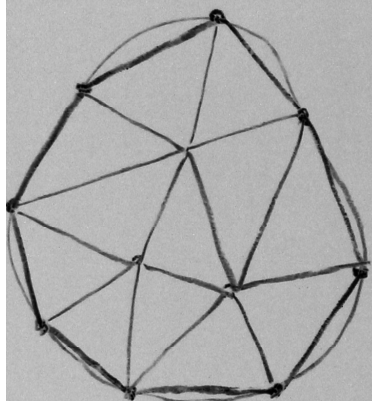
škálování a posun  $\rightarrow$   
 finální báze

$$\begin{aligned} \phi_{m,0}(x_k) &= \delta_{mk} & \phi_{m,0}(x_k) &= 0 \\ \phi'_{m,0}(x_k) &= 0 & \phi'_{m,1}(x_k) &= \delta_{mk} \\ \mu(x) &= \sum_m \sum_l c_{ml} \phi_{ml}(x) \rightarrow \mu(x_k) = c_{k0}; \mu'(x_k) = c_{k1} \end{aligned}$$



# Konečné prvky ve 2 a více dimenzích

Triangulace oblasti  $\Omega$  + prostor:




$$V_m = \{ \text{po částech lineární spojité funkce} \}$$

fce  $v(x)$  na  $\forall$  trojúhelníku  $\omega_k(x)$  daná hodnotami  $v(\vec{x}_i) = v_i$  ve vrcholech

$$\Omega = \bigcup_k \omega_k$$

$\dim V_m = \text{počet vnitř. bodů}$



$\rightarrow$  báze fce lze číslovat vnitř. body


$$\phi_m(\vec{x}) :$$

supp  $\phi_m$  malý

je klauzy  $\phi_m(\vec{x}_k) = \delta_{mk}$

tj;  $v(\vec{x}) = \sum_k c_k \phi_k(\vec{x})$


$\rightarrow c_k = v(\vec{x}_k)$






# Zobecnění do více dimenzí


triangle simplex  $\tau$  :



1D



2D



3D

simplex

mD

$$\dots, \vec{x}^{(0)}, \vec{x}^{(1)}, \dots, \vec{x}^{(D)}$$

Lineární funkce na  $\omega_k$  opět dána  $D+1$  hodnotami  $M(\vec{x}^{(k)}) \equiv M_k$

Lin. interpolace :  $\phi(\vec{x}) = a_0 + c_1 x_1 + c_2 x_2 + \dots + c_D x_D$

najdeme baz. fce  $\phi_m(\vec{x}^{(k)}) = \delta_{km} \sim \delta_{mk} \quad \forall \vec{x} = \vec{x}^{(k)}$

$$\phi_m(\vec{x}) = \begin{vmatrix} x_1^{(m)} - x_1 & x_1^{(m)} - x_1^{(0)} & \dots & x_1^{(m)} - x_1^{(D)} \\ x_2^{(m)} - x_2 & x_2^{(m)} - x_2^{(0)} & \dots & x_2^{(m)} - x_2^{(D)} \\ \vdots & \vdots & \ddots & \vdots \\ x_D^{(m)} - x_D & x_D^{(m)} - x_D^{(0)} & \dots & x_D^{(m)} - x_D^{(D)} \end{vmatrix}$$

$\Delta_m(\vec{x}) \leftarrow$  dupli  $x^{(m)} - x^{(m)}$


$$\Delta_m(\vec{x}^{(m)})$$

$$\vec{x} \rightarrow \vec{x}^{(m)}$$

výraz 0/0  
z odstraněním  
singularitov = 1


# Polynomy vyššího řádu ... Závěrečné D

PŘ: Lagrangeovy prvky 2D pomocné body



$$\omega_k = a + b_1 x + b_2 y + c_1 x^2 + c_2 xy + c_3 y^2 + d_1 x^3 + d_2 x^2 y + d_3 xy^2 + d_4 y^4$$

$$\boxed{\phi_{k,l}(\vec{x}_m) = \delta_{km}}$$



polynom řádu  $N$  v 2D ...  $\binom{N+2}{2}$  pomocných bodů  
 funguje obecně v  $D$  dimenzích  $P_N(\vec{x}) \dots \binom{N+D}{D}$  koeficientů  
 = počet bodů v pyramidě

$$u(\vec{x}) = \sum_{m,l} c_{m,l} \phi_{m,l}(\vec{x})$$

$$\Rightarrow u(\vec{x}_{k,l}) = c_{k,l}$$

# Gradientní iterční metody

Úloha: najít  $x$ :  $Ax = b$   $A$  symetrická, pozit. defin.  
matice  $N \times N$  (řidká)  $\leftarrow$   
• říční metoda ...  $O(N^3)$  FLOPS  
Stejně jako  $A \cdot B \longrightarrow$  představě méně FLOPS

Reformulace: najít  $\vec{x}$  minimalizující  $\phi(\vec{x}) \equiv \frac{1}{2} \vec{x}^T A \vec{x} - \vec{x}^T b$   
(kopíruje (V))

... minimum:  $\nabla \phi(\vec{x}) = A\vec{x} - b = 0$  ... kopíruje (S)

pozn ... reziduum  $\vec{r} \equiv b - A\vec{x} = -\nabla \phi$  ... rychlý výpočet

strategie hledání minima: METODA PŘÍMEK

• volba poč. odhadu  $\vec{x}_0$

• volba směru  $\vec{p}_0$

• další  $\vec{x}_{k+1}$  ... minimalizuje

$$f(\alpha_k) \equiv \phi(\vec{x}_{k+1} = \vec{x}_k + \alpha_k \vec{p}_k)$$

ITRČNÍ:  $\vec{x}_0, \vec{x}_1, \vec{x}_2, \dots$   
různé volby — různé metody



## Metoda největšího spádu

- pedagogický význam - neefektivní  $\nabla$

... volba ...  $p_k = -\nabla \phi(x_k) \equiv r_k$  ... reziduum

... v okolí  $x_k$  zaručuje nejrychlejší pokles  $\phi(x)$

... zaručí vždy zmenšení  $\phi(x_k) \rightarrow \phi(x_{k+1})$

nalezem  $\alpha_k$  ... minimum  $\phi(x_k + \alpha_k r_k) \equiv \frac{1}{2}(x + \alpha r)^T A(x + \alpha r) - (x + \alpha r)^T b$

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

$$\rightarrow \alpha_k = \frac{r_k^T r_k}{r_k^T A r_k}$$

Shrnutí:

$$r_k = b - A x_k$$

$$\alpha_k = r_k^T r_k / r_k^T A r_k$$

$$x_{k+1} = x_k + \alpha_k r_k$$

... OPTIMALIZACE ušetří jedno  $Ax$

$$r_{k+1} = b - A x_{k+1} = b - A(x_k + \alpha_k r_k)$$

$$= r_k - \alpha_k A r_k$$

# Algoritmus (METODA NEJVĚTŠÍHO SPÁDU)

- volím  $\vec{x}_0$

- spočtu  $\vec{r}_0 = \vec{b} - A\vec{x}_0$

-  $k=0, 1, 2, \dots$  :  $\vec{w}_k = A\vec{r}_k$

$$\alpha_k = \vec{r}_k^T \vec{r}_k / \vec{r}_k^T \vec{w}_k$$

$$\vec{x}_{k+1} = \vec{x}_k + \alpha_k \vec{r}_k$$

$$\vec{r}_{k+1} = \vec{r}_k - \alpha_k \vec{w}_k$$

ukončení pokud  $\|\vec{r}_{k+1}\| < \epsilon$

1x maticové násobení  
na 1 cyklus

... navíc stačí dodat  
extra proceduru  
pro  $\vec{y} = A\vec{x}$

... užítí struktury  
matice A



# Konvergence metody nejv. spadu

$A$  .. sym. pozit. def  $\Rightarrow$  spektrální rozklad (diagon. repr.)  $A = \sum_i \pi_i \lambda_i \pi_i^T$   
 $\lambda_i > 0$

pozn. def  $e_k = x_k - x$  .. chyba řešení

• pokud  $e_k$  je vl. vektor  $A \rightarrow$  konvergence po 1 iteraci


• pokud  $A$  isotropní:  
konverg. po jedné iter.



• problém: úzká údolí:

mnoho iterací už pro 2D

..  $A \dots 2 \times 2$



dě se analyzovat podrobněji pomocí  $\lambda_i \rightarrow$  viz pozn na webu



## Atraktivní vlastnosti:

- jen na sobě matici  $A$  ... vyčítá jedna iterace  
pro řídící matici

... snižuje chybu ve smyslu  $\phi(x)$

→ tj. pohybujeme se v prostoru  $\mathcal{L} \{ b, Ab, A^2b, A^3b, \dots \}$   
(volba  $x_0 = 0$ )

Krylov-space

Neúhoda = pomalá konvergence ... moc iterací

důvod .. zvolené směry prohledáváme vícerorát

Východisko: sdružené gradienty .. už prohledaný směr  
nemí třeba znovu řešit

→ po  $k$ -krocích .. přesné řešení  $(V)$  ✓

$$V_k = \{ b, Ab, A^2b, \dots, A^k b \}$$

→ přesné řešení po  $k=N$  krocích pro matici  $N \times N$

# Metoda sdružených gradientů CGM (conjugated gradients)

obecně ... minimum ve směru  $\vec{p}$ :

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

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

$$\rightarrow \alpha = \frac{p^T r}{p^T A p} = - \frac{p^T A e}{p^T A p} \quad \dots \quad e \equiv x_k - x$$

↑ složka vektoru  $\vec{e}$  pro skalární součin  
symetrickou  $A$ :  $(a_{ij})_A = M^T A M$

podstata CGM:

$A$ -ortogonální směry  $p_k^T A p_k = \delta_{kk}$

... metoda přímek najde postupně složky  $\vec{e}_0 = \sum_j \beta_j \vec{p}_j$   
 $\equiv x_0 - x$