

Univerzita Karlova v Praze
Matematicko-fyzikální fakulta

BAKALÁŘSKÁ PRÁCE



Róbert Pathó

Analýza citlivosti při řešení soustav lineárních algebraických rovnic

Katedra numerické matematiky

Vedoucí bakalářské práce: Prof. RNDr. Jaroslav Haslinger, DrSc.
Studijní program: Matematika, obecná matematika

2007

Rád bych poděkoval vedoucímu bakalářské práce, Prof. RNDr. Jaroslavovi Haslingerovi, DrSc. za pravidelné čtení stávajícího se textu, užitečné připomínky a za věnovaný čas vůbec. Vřelý dík dále patří mému bratrovi a rodičům za podporu při psaní práce.

Prohlašuji, že jsem svou bakalářskou práci napsal(a) samostatně a výhradně s použitím citovaných pramenů. Souhlasím se zapůjčováním práce a jejím zveřejňováním.

V Praze dne 4.8.2007

Róbert Pathó

Obsah

1	Analýza citlivosti	5
2	Projekce v Hilbertových prostorech	10
3	Nalezení optimálního dělení	16
4	Numerické experimenty	24
	Literatura	38

Název práce: Analýza citlivosti při řešení soustav lineárních algebraických rovnic

Autor: Róbert Pathó

Katedra (ústav): Katedra numerické matematiky

Vedoucí bakalářské práce: Prof. RNDr. Jaroslav Haslinger, DrSc.

e-mail vedoucího: hasling@karlin.mff.cuni.cz

Abstrakt: V první části práce studujeme řešení soustavy lineárních algebraických rovnic závislé na parametru. Ukážeme, že za jistých předpokladů je řešení spojitě diferencovatelné vzhledem k tomuto parametru a odvodíme vztah pro výpočet její směrové derivaci. Cílem je tyto poznatky aplikovat na úlohu, ve kterém aproximujeme danou funkci v prostoru L^2 , resp. $W^{1,2}$ na intervalu (a, b) po částech lineárními funkcemi: snažíme se najít optimální dělení intervalu při pevném počtu dělicích uzlů. Numerickými experimenty zjišťujeme vliv dělení intervalu na chybu aproximace a řád konvergence.

Klíčová slova: soustava lineárních rovnic závislé na parametru, ortogonální projekce, po částech lineární aproximace

Title: Sensitivity analysis in systems of linear algebraic equations

Author: Róbert Pathó

Department: Department of Numerical Mathematics

Supervisor: Prof. RNDr. Jaroslav Haslinger, DrSc.

Supervisor's e-mail address: hasling@karlin.mff.cuni.cz

Abstract: In the first part of the thesis we show, that under certain conditions, the solution of a system of linear algebraic equations depending on a parameter is a continuously differentiable function of that parameter. We also derive a formula for computing directional derivatives. Our main goal is then to apply these results to the approximation of a given function in L^2 , resp. $W^{1,2}$ in (a, b) by piecewise linear functions. Namely, we try to find a partition of the interval (a, b) that is optimal in a particular sense. Numerical experiments show the effect of found partitions on the approximation error and the rate of convergence.

Keywords: system of linear equations depending on a parameter, orthogonal projection, piecewise linear approximation

Kapitola 1

Analýza citlivosti

Motivace. Každou soustavu n lineárních rovnic s n neznámými lze zapsat ve tvaru:

$$\mathbf{A}x = f,$$

kde $\mathbf{A} \in \mathbb{R}^{n \times n}$ je matice soustavy a $f \in \mathbb{R}^n$ je vektor pravé strany.

Budeme uvažovat soustavu lineárních algebraických rovnic takovou, ve které matice soustavy a pravá strana závisí na parametru $\alpha \in U$, kde $U \subset \mathbb{R}^d$ je neprázdná, otevřená množina:

$$\mathbf{A}(\alpha)x_\alpha = f(\alpha) \tag{1.1}$$

Symbolem x_α jsme označili řešení soustavy (1.1) příslušné hodnotě parametru α . V dalším se nejdřív budeme věnovat diferencovatelnosti zobrazení $x(\alpha) := x_\alpha$ podle tohoto parametru (zatím nevíme ani to, zda je to dobře definované zobrazení!).

Věta 1.1. *Bud' $U \subset \mathbb{R}^d$ neprázdná otevřená množina, dále nechť maticová funkce $\mathbf{A} : U \rightarrow \mathbb{R}^{n \times n}$ a vektorová funkce $f : U \rightarrow \mathbb{R}^n$ splňují následující podmínky:*

- (i) $\forall \alpha \in U : \mathbf{A}(\alpha)$ je regulární;
- (ii) $\mathbf{A} \in C^1(U; \mathbb{R}^{n \times n}), f \in C^1(U; \mathbb{R}^n)$.

Potom existuje funkce $x : U \rightarrow \mathbb{R}^n$ splňující:

$$\mathbf{A}(\alpha)x(\alpha) = f(\alpha) \quad \forall \alpha \in U, \tag{1.2}$$

kteřá je navíc spojitě diferencovatelná na U vzhledem k parametru α a pro směrovou derivaci $x'(\alpha; \beta)$ v bodě $\alpha \in U$ a směru $\beta \in \mathbb{R}^d$ platí:

$$x'(\alpha; \beta) = \mathbf{A}(\alpha)^{-1} (f'(\alpha; \beta) - \mathbf{A}'(\alpha; \beta)x(\alpha)), \quad (1.3)$$

kde $\mathbf{A}'(\alpha; \beta)$ a $f'(\alpha; \beta)$ jsou příslušné derivace \mathbf{A} a f v bodě α a směru β .

Důkaz. Není těžké si rozmyslet, že existenci korektně definovaného zobrazení $x : \alpha \mapsto x_\alpha$ (x_α je jako v (1.1)) nám zaručí již vlastnost (i) (stačí položit $x(\alpha) = \mathbf{A}(\alpha)^{-1}f(\alpha)$). Uvidíme však, že věta o implicitních funkcích dává nejenom existenci funkce $x(\alpha)$, ale také její hladkost.

Zvolme $\alpha_0 \in U$ libovolně. Položme $x_0 = x_{\alpha_0}$, tj. řešení soustavy (1.1) pro $\alpha = \alpha_0$ a definujme zobrazení $F : \mathbb{R}^d \times \mathbb{R}^n \rightarrow \mathbb{R}^n$ vztahem: $F(\alpha, x) = \mathbf{A}(\alpha)x - f(\alpha)$. Potom platí:

- $F(\alpha_0, x_0) = 0$;
- $\det \nabla_x F(\alpha_0, x_0) = \det \mathbf{A}(\alpha_0) \neq 0$, neboť dle předpokladu $\mathbf{A}(\alpha_0)$ je regulární;
- z vlastnosti (ii) a z toho, že $\nabla_x F(\alpha, x) = \mathbf{A}(\alpha)$ vyplývá, že $F \in C^1(U \times \mathbb{R}^n; \mathbb{R}^n)$.

Tím máme ověřené všechny předpoklady věty o implicitních funkcích, tudíž platí: $\exists \mathcal{U}_0 \subset U$ okolí α_0 tak, že rovnice $F(\alpha, x) = 0$, $\alpha \in \mathcal{U}_0$ má právě jedno řešení $x(\alpha)$ a navíc zobrazení $x : \alpha \mapsto x(\alpha)$ je třídy $C^1(\mathcal{U}_0; \mathbb{R}^n)$. Jelikož $\alpha_0 \in U$ bylo zcela libovolné, je $x \in C^1(U; \mathbb{R}^n)$.

K odvození vztahu, který splňuje směrová derivace $x'(\alpha; \beta)$ v bodě α a směru β využijeme definici směrové derivace:

$$\begin{aligned} \mathbf{A}'(\alpha; \beta) &= \lim_{t \rightarrow 0^+} \frac{\mathbf{A}(\alpha + t\beta) - \mathbf{A}(\alpha)}{t}, \\ f'(\alpha; \beta) &= \lim_{t \rightarrow 0^+} \frac{f(\alpha + t\beta) - f(\alpha)}{t}. \end{aligned}$$

Bud' $\beta \in \mathbb{R}^d$ libovolný, $t > 0$ reálné číslo. Potom:

$$\begin{aligned} \mathbf{A}(\alpha + t\beta)x(\alpha + t\beta) &= f(\alpha + t\beta), \\ \mathbf{A}(\alpha)x(\alpha) &= f(\alpha). \end{aligned}$$

Odečtením druhé rovnice od první, rozšířením o člen $\mathbf{A}(\alpha + t\beta)x(\alpha) - \mathbf{A}(\alpha + t\beta)x(\alpha)$ a vydělením číslem t dostaneme rovnost:

$$\mathbf{A}(\alpha + t\beta)\frac{x(\alpha + t\beta) - x(\alpha)}{t} + \frac{\mathbf{A}(\alpha + t\beta) - \mathbf{A}(\alpha)}{t}x(\alpha) = \frac{f(\alpha + t\beta) - f(\alpha)}{t}$$

Nyní stačí provést limitní přechod pro $t \rightarrow 0_+$ a ihned obdržíme hledaný vztah pro směrovou derivaci $x'(\alpha; \beta)$:

$$\mathbf{A}(\alpha)x'(\alpha; \beta) = f'(\alpha; \beta) - \mathbf{A}'(\alpha; \beta)x(\alpha), \quad (1.4)$$

neboť \mathbf{A} , f a x jsou zobrazení třídy C^1 , tudíž příslušné derivace existují. \square

Nechť v dalším platí předpoklady předchozí věty. Bud' $J : U \times \mathbb{R}^n \rightarrow \mathbb{R}$ libovolné zobrazení třídy $C^1(U \times \mathbb{R}^n)$ a definujme funkci $\mathcal{J} : U \rightarrow \mathbb{R}$ jako:

$$\mathcal{J}(\alpha) := J(\alpha, x(\alpha)),$$

kde $x(\alpha)$ je řešení soustavy (1.2).

V předchozím jsme dokázali, že z platnosti (i) a (ii) je $x \in C^1(U; \mathbb{R}^n)$ a tudíž je také $\mathcal{J} \in C^1(U)$ podle věty o derivaci složeného zobrazení. Zvolíme-li tedy libovolný vektor $\beta \in \mathbb{R}^d$, pak podle výše uvedené věty dostaneme:

$$\mathcal{J}'(\alpha; \beta) = \nabla_{\alpha}J(\alpha, x(\alpha))^T\beta + \nabla_xJ(\alpha, x(\alpha))^Tx'(\alpha; \beta). \quad (1.5)$$

Budeme-li chtít počítat $\mathcal{J}'(\alpha; \beta)$ přímo ze vzorce (1.5), musíme pro každý směr $\beta \in \mathbb{R}^d$ navíc vyřešit soustavu (1.4), abychom dostali $x'(\alpha; \beta)$. Tomu se však vyhneme, zavedeme-li pojem tzv. *adjungovaného stavu* a *adjungované soustavy*:

$$\mathbf{A}(\alpha)^Tp(\alpha) = \nabla_xJ(\alpha, x(\alpha)). \quad (1.6)$$

Transponováním a vynásobením $x'(\alpha; \beta)$ dostaneme:

$$\begin{aligned} \nabla_xJ(\alpha, x(\alpha))^Tx'(\alpha; \beta) &= p^T(\alpha)\mathbf{A}(\alpha)x'(\alpha; \beta) \\ &= p^T(\alpha)[f'(\alpha; \beta) - \mathbf{A}'(\alpha; \beta)x(\alpha)]. \end{aligned}$$

V poslední rovnosti jsme využili vztah (1.4) pro derivaci $x'(\alpha; \beta)$. Stačí jenom dosadit odvozenou rovnost do (1.5), čímž získáme výsledný vztah:

$$\mathcal{J}'(\alpha; \beta) = \nabla_{\alpha}J(\alpha, x(\alpha))^T\beta + p^T(\alpha)[f'(\alpha; \beta) - \mathbf{A}'(\alpha; \beta)x(\alpha)]. \quad (1.7)$$

Všimněme si, že adjungovaná soustava (1.6) nezávisí na β , tudíž ji stačí vyřešit pouze jednou, abychom mohli určit směrovou derivaci $\mathcal{J}'(\alpha; \beta)$ pro libovolný směr β !

Poznámka. Jiné odvození vztahu (1.7) založené na metodě Lagrangeových multiplikátorů lze nalézt v knize [1].

Dodatek. Nakonec si ukážeme příklad funkce $\mathcal{J}(\alpha)$, pro kterou nepotřebujeme vyřešit adjungovanou soustavu, abychom spočítali směrovou derivaci $\mathcal{J}'(\alpha; \beta)$ v bodě α a směru β .

Bud' $\mathbf{A} \in \mathbb{R}^{n \times n}$ *symetrická* matice. Potom platí, že vektor $x \in \mathbb{R}^n$ řeší soustavu $\mathbf{A}x = f$ právě když x minimalizuje jistou funkci $J(y)$. Přesněji:

$$\mathbf{A}x = f \iff x = \arg \min_{y \in \mathbb{R}^n} J(y),$$

$$J(y) = \frac{1}{2} \langle y, \mathbf{A}y \rangle - \langle y, f \rangle,$$

kde $\langle \cdot, \cdot \rangle$ značí standardní skalární součin v \mathbb{R}^n definovaný vztahem

$$\langle x, y \rangle := \sum_{i=1}^n x_i y_i \quad \forall x, y \in \mathbb{R}^n.$$

Uvažujeme-li soustavu lineárních algebraických rovnic záviselící na parametru α , předchozí tvrzení můžeme přeformulovat následovně:

$$\mathbf{A}(\alpha)x(\alpha) = f(\alpha) \quad \forall \alpha \in U \iff x(\alpha) = \arg \min_{y \in \mathbb{R}^n} J(\alpha, y) \quad \forall \alpha \in U,$$

$$J(\alpha, y) = \frac{1}{2} \langle y, \mathbf{A}(\alpha)y \rangle - \langle y, f(\alpha) \rangle.$$

Definujme $\mathcal{J}(\alpha)$ takto:

$$\mathcal{J}(\alpha) := J(\alpha, x(\alpha)) = \frac{1}{2} \langle x(\alpha), \mathbf{A}(\alpha)x(\alpha) \rangle - \langle x(\alpha), f(\alpha) \rangle. \quad (1.8)$$

Předpokládejme, že maticová funkce $\mathbf{A}(\alpha)$ a vektorová funkce $f(\alpha)$ splňují podmínky (i) a (ii) z Věty 1.1. Potom je funkce $\mathcal{J}(\alpha)$ spojitě diferencovatelná na množině U , neboť $f \in C^1(U)$, $\mathbf{A} \in C^1(U)$ a $x \in C^1(U)$ díky právě zmíněné větě.

Symetrii matice $\mathbf{A}(\alpha)$ a to, že $x(\alpha)$ splňuje rovnici $\mathbf{A}(\alpha)x(\alpha) = f(\alpha)$

použijeme k odvození směrové derivace $\mathcal{J}'(\alpha; \beta)$:

$$\begin{aligned}
 \mathcal{J}'(\alpha; \beta) &= \frac{1}{2} \underbrace{\langle x'(\alpha; \beta), \mathbf{A}(\alpha)x(\alpha) \rangle}_{=0} + \frac{1}{2} \langle x(\alpha), \mathbf{A}'(\alpha; \beta)x(\alpha) \rangle \\
 &\quad + \frac{1}{2} \underbrace{\langle x(\alpha), \mathbf{A}(\alpha)x'(\alpha; \beta) \rangle}_{=0} - \langle x'(\alpha; \beta), f(\alpha) \rangle - \langle x(\alpha), f'(\alpha; \beta) \rangle \\
 &= \langle x'(\alpha; \beta), \mathbf{A}(\alpha)x(\alpha) \rangle - \langle x'(\alpha; \beta), f(\alpha) \rangle + \frac{1}{2} \langle x(\alpha), \mathbf{A}'(\alpha; \beta)x(\alpha) \rangle \\
 &\quad - \langle x(\alpha), f'(\alpha; \beta) \rangle \\
 &= \langle x'(\alpha; \beta), \underbrace{\mathbf{A}(\alpha)x(\alpha) - f(\alpha)}_{=0} \rangle + \frac{1}{2} \langle x(\alpha), \mathbf{A}'(\alpha; \beta)x(\alpha) \rangle \\
 &\quad - \langle x(\alpha), f'(\alpha; \beta) \rangle \\
 &= \frac{1}{2} \langle x(\alpha), \mathbf{A}'(\alpha; \beta)x(\alpha) - 2f'(\alpha; \beta) \rangle.
 \end{aligned}$$

Kapitola 2

Projekce v Hilbertových prostorech

Úvod. V celé této kapitole dvojice $(X, (\cdot, \cdot))$ bude značit reálný Hilbertův prostor se skalárním součinem (\cdot, \cdot) . Nechť $L \subset\subset X$ je podprostor X konečné dimenze.

Cílem tohoto úvodu je připomenout, jak k danému prvku $x \in X$ nalézt $g \in L$, který je k němu "nejbližší" v normě prostoru L , tj. $\|x - g\| = \min_{z \in L} \|x - z\|$. K tomu uvedeme bez důkazů dvě věty, známé z funkcionální analýzy. Příslušné důkazy lze nalézt například v [2].

Věta 2.1. *Nechť $(X, (\cdot, \cdot))$ je Hilbertův prostor, $L \subset\subset X$ uzavřený podprostor X . Potom:*

$$\forall x \in X \exists! g \in L : \quad \|x - g\| = \min_{z \in L} \|x - z\|.$$

Věta 2.2. *Bud' $(X, (\cdot, \cdot))$ Hilbertův prostor, $L \subset\subset X$ uzavřený podprostor. Nechť $x \in X$ a $g \in L$. Pak*

$$\|x - g\| = \min_{z \in L} \|x - z\| \iff (x - g, z) = 0, \quad \forall z \in L.$$

Označme $\{\varphi_1, \dots, \varphi_n\}$ bázi prostoru L , kde $n = \dim L$. Podle Věty 2.2 stačí najít koeficienty $\alpha_1, \dots, \alpha_n \in \mathbb{R}$ tak, že pro $g = \sum_{i=1}^n \alpha_i \varphi_i$ platí:

$$(x - g, z) = 0 \quad \forall z \in L.$$

Jelikož reálný skalární součin je lineární v druhé složce, stačí nalézt $g \in L$ tak, aby:

$$(x - g, \varphi_j) = 0, \quad \forall j = 1, \dots, n.$$

Tedy:

$$(x - \sum_{i=1}^n \alpha_i \varphi_i, \varphi_j) = 0, \quad \forall j = 1, \dots, n,$$

což je ekvivalentní:

$$\sum_{i=1}^n \alpha_i (\varphi_i, \varphi_j) = (x, \varphi_j), \quad \forall j = 1, \dots, n. \quad (2.1)$$

Soustavu (2.1) můžeme zapsat v maticovém tvaru:

$$\mathbf{A}\alpha = F, \quad (2.2)$$

kde $\alpha = (\alpha_1, \dots, \alpha_n)^T$ je hledaný vektor koeficientů lineární kombinace, $F = ((x, \varphi_1), \dots, (x, \varphi_n))^T$ je vektor pravé strany a $\mathbf{A} = ((\varphi_i, \varphi_j))_{i,j=1}^n$ je matice soustavy, tzv. *Gramova matice*.

Řešitelnost soustavy (2.2) a tudíž také existenci nejbližšího prvku dokazuje následující lemma.

Lemma 2.3. *Gramova matice $\mathbf{A} = ((\varphi_i, \varphi_j))_{i,j=1}^n$ definovaná jako výše je regulární.*

Důkaz. Plyne ihned z lineární nezávislosti bázových vektorů $\varphi_i, i = 1, \dots, n$. □

Nyní ukážeme, že jsme v podstatě zkonstruovali ortogonální projekci prostoru X na jeho konečně dimenzionální podprostor $L = \text{span}\{\varphi_1, \dots, \varphi_n\}$.

Definujme proto zobrazení $P : X \rightarrow L$ předpisem $Px = \sum_{i=1}^n \alpha_i \varphi_i \quad \forall x \in X$, kde koeficienty α_i jsou řešením soustavy (2.2). Potom operátor P je

- lineární (snadno se ověří z (2.1)),
- $\forall x \in L : Px = x \implies P^2 = P$,
- konečně dimenzionální \implies spojitý,
- $\text{Ker } P = \{x \in X : \sum_i \alpha_i \varphi_i = 0\} = \{x \in X : (x, \varphi_i) = 0 \forall i\} = L^\perp = (\text{Rng } P)^\perp$.

Tudíž P je skutečně ortogonální projekce X na L .

Úloha 2.4. Necht' $a, b \in \mathbb{R}$, $a < b$; $n \in \mathbb{N}$. Uvažujme dělení $\Delta_n := \{a = x_0 < x_1 < \dots < x_n = b\}$ intervalu $[a, b]$ a označme L_n prostor všech po částech lineárních, spojitých funkcí na tomto dělení:

$$L_n := L(\Delta_n) = \{\varphi \in C[a, b]; \varphi|_{[x_{i-1}, x_i]} \in P_1 \quad \forall i = 1, \dots, n\},$$

a jeho podprostor:

$$\tilde{L}_n := \tilde{L}(\Delta_n) = \{\varphi \in L_n; \varphi(a) = 0\}.$$

Pro daný $f \in X_1$, resp. X_2 nalezněme jeho ortogonální projekci na L_n resp. \tilde{L}_n , je-li:

(a) $X_1 = L^2(a, b)$ se skalárním součinem:

$$(f, g) = \int_a^b f(x)g(x) dx \quad \forall f, g \in X_1,$$

(b) $X_2 = \{f \in W^{1,2}(a, b); f(a) = 0\}$ se skalárním součinem:

$$(f, g) = \int_a^b f'(x)g'(x) dx \quad \forall f, g \in X_2,$$

kde $W^{1,2}(a, b)$ je Sobolevův prostor $W^{1,2}$ na intervalu (a, b) a $f' \in L^2(a, b)$ značí slabou derivaci funkce $f \in X_2$.

Poznámka. Na reálné přímce platí, že $W^{1,2}(a, b) \hookrightarrow C([a, b])$ v tom smyslu, že pro každou třídu funkcí $f \in W^{1,2}(a, b)$ existuje její reprezentant f^\sharp , který je spojitý na intervalu $[a, b]$ a tudíž má smysl pro něj definovat bodovou hodnotu $f^\sharp(a)$. Prostor X_2 je tedy korektně definován, neboť pro $f \in W^{1,2}(a, b)$ položíme: $f(a) := f^\sharp(a)$.

Lemma 2.5. (a) L_n je lineární podprostor prostoru X_1 , $\dim L = n + 1$. Jeho bázové funkce jsou:

$$\varphi_0(x) := \begin{cases} \frac{x_1 - x}{x_1 - x_0} & , x \in [x_0, x_1], \\ 0 & \text{jinak} \end{cases} \quad (2.3)$$


$$\varphi_j(x) := \begin{cases} \frac{x - x_{j-1}}{x_j - x_{j-1}} & , x \in [x_{j-1}, x_j], \\ \frac{x_{j+1} - x}{x_{j+1} - x_j} & , x \in [x_j, x_{j+1}], \\ 0 & \text{jinak} \end{cases} \quad (2.4)$$

$$\varphi_n(x) := \begin{cases} \frac{x-x_{n-1}}{x_n-x_{n-1}} & , x \in [x_{n-1}, x_n], \\ 0 & \text{jinak,} \end{cases} \quad (2.5)$$


kde $j = 1, \dots, n - 1$.

(b) $\tilde{L}_n \subset\subset X_2$, $\dim \tilde{L}_n = n$ a funkce $\{\varphi_1, \dots, \varphi_n\}$, definované vztahy (2.4) a (2.5) tvoří bázi tohoto prostoru.


Důkaz. Jde jenom o ověření definic, proto jej zde uvádět nebudeme. \square



Obrázek 2.1: Bázová funkce φ_0



Obrázek 2.2: Bázová funkce φ_j , $1 \leq j \leq n - 1$



Obrázek 2.3: Bázová funkce φ_n

Řešení Úlohy 2.4. Reálný skalární součin je symetrický, tudíž každá reálná Gramova matice je symetrická. Navíc z definice bázevých funkcí je ihned patrné, že pro $|i - j| \geq 2$ bude $a_{ij} = 0$, neboť:

$$a_{ij} = (\varphi_i, \varphi_j) = \int_a^b \varphi_i(x)\varphi_j(x) dx = \sum_{k=1}^n \int_{x_{k-1}}^{x_k} \varphi_i(x)\varphi_j(x) dx = 0,$$

neboť v každém sčítanci je aspoň jedna z funkcí $\varphi_i(x)$, $\varphi_j(x)$ nulová.

Obdobně můžeme odvodit totéž pro případ (b).

V obou případech tedy dostáváme symetrickou, třídiagonální Gramovu matici.

Pro její nenulové prvky v případě (a) platí:

$$a_{00} = (\varphi_0, \varphi_0) = \int_{x_0}^{x_1} \left(\frac{x_1 - x}{x_1 - x_0} \right)^2 dx = \frac{x_1 - x_0}{3}, \quad (2.6)$$

$$a_{ii} = (\varphi_i, \varphi_i) = \int_{x_{i-1}}^{x_i} \left(\frac{x - x_{i-1}}{x_i - x_{i-1}} \right)^2 dx + \int_{x_i}^{x_{i+1}} \left(\frac{x_{i+1} - x}{x_{i+1} - x_i} \right)^2 dx = \frac{x_i - x_{i-1}}{3} + \frac{x_{i+1} - x_i}{3} = \frac{x_{i+1} - x_{i-1}}{3} \quad \forall i = 1, \dots, n-1, \quad (2.7)$$

$$a_{nn} = (\varphi_n, \varphi_n) = \int_{x_{n-1}}^{x_n} \left(\frac{x - x_{n-1}}{x_n - x_{n-1}} \right)^2 dx = \frac{x_n - x_{n-1}}{3}. \quad (2.8)$$

Prvky nad diagonálou určíme analogicky:

$$a_{i,i+1} = (\varphi_i, \varphi_{i+1}) = \int_a^b \varphi_i(x)\varphi_{i+1}(x) dx = \int_{x_i}^{x_{i+1}} \frac{x_{i+1} - x}{x_{i+1} - x_i} \cdot \frac{x - x_i}{x_{i+1} - x_i} dx = \frac{x_{i+1} - x_i}{6} \quad \forall i = 0, \dots, n-1. \quad (2.9)$$

Zbývá sestavit vektor pravé strany, pro nějž podle úvodní části platí vztahy:

$$(f, \varphi_0) = \frac{1}{x_1 - x_0} \int_{x_0}^{x_1} f(x)(x_1 - x) dx, \quad (2.10)$$

$$(f, \varphi_i) = \frac{1}{x_i - x_{i-1}} \int_{x_{i-1}}^{x_i} f(x)(x - x_{i-1}) dx + \frac{1}{x_{i+1} - x_i} \int_{x_i}^{x_{i+1}} f(x)(x_{i+1} - x) dx, \quad (2.11)$$

$$(f, \varphi_n) = \frac{1}{x_n - x_{n-1}} \int_{x_{n-1}}^{x_n} f(x)(x - x_{n-1}) dx, \quad (2.12)$$

kde $i = 1, \dots, n - 1$.

V případě (b) postupujeme obdobně:

$$\begin{aligned} a_{ii} = (\varphi_i, \varphi_i) &= \int_a^b (\varphi_i'(x))^2 dx \\ &= \frac{1}{x_i - x_{i-1}} + \frac{1}{x_{i+1} - x_i} \quad \forall i = 1, \dots, n - 1 \end{aligned} \quad (2.13)$$

$$a_{nn} = (\varphi_n, \varphi_n) = \frac{1}{x_n - x_{n-1}} \quad (2.14)$$

$$a_{i,i+1} = (\varphi_i, \varphi_{i+1}) = -\frac{1}{x_{i+1} - x_i} \quad \forall i = 1, \dots, n - 1 \quad (2.15)$$

$$\begin{aligned} (f, \varphi_i) &= \int_{x_{i-1}}^{x_i} \frac{f'(x)}{x_i - x_{i-1}} dx - \int_{x_i}^{x_{i+1}} \frac{f'(x)}{x_{i+1} - x_i} dx \\ &= \frac{f(x_i) - f(x_{i-1})}{x_i - x_{i-1}} - \frac{f(x_{i+1}) - f(x_i)}{x_{i+1} - x_i} \quad \forall i = 1, \dots, n - 1, \end{aligned} \quad (2.16)$$

$$(f, \varphi_n) = \int_{x_{n-1}}^{x_n} \frac{f'(x)}{x_n - x_{n-1}} dx = \frac{f(x_n) - f(x_{n-1})}{x_n - x_{n-1}}. \quad (2.17)$$

Kapitola 3

Nalezení optimálního dělení

Úvod. V této kapitole se budeme zabývat prostorem $(X_1, (\cdot, \cdot))$ a $L_n \subset \subset X_1$, resp. $(X_2, (\cdot, \cdot))$ a $\tilde{L}_n \subset \subset X_2$, definovaných v Úloze 2.4. Jelikož následující úvahy lze provést podobně pro oba případy, dovolujeme si pro přehlednost používat jednotné označení X a L (s patřičným skalárním součinem (\cdot, \cdot)). Nechť je navíc $n \in \mathbb{N}$, tj. počet dílčích intervalů intervalu $[a, b]$ pevná, předem zvolená. Pro zjednodušení dalšího označení budeme používat symbol Δ místo Δ_n .

V předchozí kapitole jsme ukázali, jak pro pevné dělení Δ intervalu $[a, b]$ a danou funkci $f \in X$ nalézt funkci $g \in L$, která nejlépe aproximuje f v normě prostoru X . Všimněme si, že prostor L a tudíž i funkce g závisí na volbě dělení, tj. $L = L(\Delta)$ a $g = g(\Delta)$! To nás motivuje k tomu, abychom hledali "optimální dělení", neboli $\hat{\Delta}$ takové, pro které platí:

$$\hat{\Delta} = \arg \min_{\Delta \in U_{ad}} \|f - g(\Delta)\|, \quad (3.1)$$

kde $U_{ad} \subset \mathbb{R}^{n+1}$ je jistá množina dělení.

Bude-li množina U_{ad} kompaktní a zobrazení $g : U_{ad} \rightarrow L$, $\Delta \mapsto g(\Delta)$, $\Delta \in U_{ad}$ spojitě, máme zaručeno existenci optimálního dělení. Stačí si totiž uvědomit, že za těchto předpokladů je funkce $\Psi(\Delta) := \|f - g(\Delta)\|$ složením spojitých zobrazení, tudíž sama spojitá a každá spojitá funkce na kompaktní množině nabývá svého minima.

Zdůrazněme, že počet dílčích intervalů $n \in \mathbb{N}$ je pevné, hledáme pouze optimální rozložení uzlů x_1, x_2, \dots, x_{n-1} (krajní body $x_0 = a$ a $x_n = b$ se nemění).

Přirozeně se nabízí hledat optimální dělení v množině všech možných dělení intervalu $[a, b]$. Bohužel množina

$$\{(x_0, x_1, \dots, x_n) \in \mathbb{R}^{n+1}; a = x_0 < x_1 < \dots < x_{n-1} < x_n = b\}$$

není uzavřená, tudíž nemůže být ani kompaktní. Proto nemusí existovat optimální dělení ve výše uvedené množině a musíme zúžit obor přípustných dělení.

Bud' $0 < \delta \leq (b - a)/n$. Uvažujme následující dělení intervalu $[a, b]$:

$$U_\delta := \{(x_0, x_1, \dots, x_n) \in \mathbb{R}^{n+1}; x_0 = a, x_1 \geq x_0 + \delta, \dots, x_n \geq x_{n-1} + \delta, x_n = b\}. \quad (3.2)$$

Lemma 3.1. *Množina $U_\delta \subset \mathbb{R}^{n+1}$ je kompaktní.*

Důkaz. Zřejmě $U_\delta \subset [a, b]^{n+1}$, tudíž je omezená. Ke kompaktnosti zbývá ukázat, že U_δ je uzavřená. Mějme proto posloupnost $\{\Delta^k\}_{k=1}^\infty \subset U_\delta$, $\Delta^k = (x_0^k, x_1^k, \dots, x_n^k)$ a předpokládejme, že:

$$\exists \Delta = (x_0, x_1, \dots, x_n) \in \mathbb{R}^{n+1} : \Delta^k \longrightarrow \Delta, \quad k \rightarrow \infty,$$

což je ekvivalentní:

$$\forall i = 0, \dots, n : x_i^k \longrightarrow x_i, \quad k \rightarrow \infty.$$

Podle předpokladu přitom platí:

$$\forall k \in \mathbb{N} \forall i = 0, \dots, n-1 : x_{i+1}^k - x_i^k \geq \delta.$$

Po limitním přechodu pro $k \rightarrow \infty$ dostaneme:

$$\forall i = 0, \dots, n-1 : x_{i+1} - x_i \geq \delta.$$

Tedy $\Delta \in U_\delta$ a tudíž je množina $U_\delta \subset \mathbb{R}^{n+1}$ kompaktní. □

V dalším budeme předpokládat, že $U_{ad} = U_\delta$, kde U_δ je definováno právě pomocí (3.2).

Vyšetřeme nyní spojitost zobrazení $g : U_{ad} \rightarrow L$, $\Delta \mapsto g(\Delta)$ pro $\Delta \in U_{ad}$, kde $g(\Delta)$ je prvek nejlepší lineární aproximace na $\Delta \in U_{ad}$. Dle předchozí kapitoly:

$$g(\Delta) = \sum_i \alpha_i(\Delta) \varphi_i(\Delta) \quad \forall \Delta \in U_{ad}, \quad (3.3)$$

kde vektor koeficientů lineární kombinace $\alpha(\Delta) = (\alpha_0(\Delta), \dots, \alpha_n(\Delta))^T$, resp. $\alpha(\Delta) = (\alpha_1(\Delta), \dots, \alpha_n(\Delta))^T$ řeší soustavu (2.2):

$$\mathbf{A}(\Delta)\alpha(\Delta) = F(\Delta) \quad \forall \Delta \in U_{ad}. \quad (3.4)$$

Prvky matice $\mathbf{A}(\Delta)$ jsou dány vztahy (2.6)-(2.9), resp. (2.13)-(2.15), a prvky vektoru $F(\Delta)$ mají tvar (2.10)-(2.12), resp. (2.16)-(2.17).

Ze vztahu (3.3) je patrné, že zobrazení $g(\Delta)$ bude spojitě na množině U_{ad} jakmile tam budou $\alpha_i(\Delta)$ a $\varphi_i(\Delta)$ spojitě. Není těžké si rozmyslet, že je to pravda jak pro $X = X_1$, tak pro $X = X_2$. Na druhou stranu, budou-li $\mathbf{A}(\Delta)$ a $F(\Delta)$, $\Delta \in U_{ad}$ třídy C^1 , bude zobrazení $\alpha(\Delta)$ třídy C^1 (viz. Větu 1.1). K tomu, abychom mohli použít teoretické výsledky první kapitoly, je zapotřebí mít funkce \mathbf{A} a F alespoň třídy C^1 . Vyšetřeme tedy za jakých podmínek to nastává.

(a) Nechť $X = X_1$ a $L = L_n$. Z (2.6)-(2.9) je hned zřejmé, že maticová funkce $\mathbf{A}(\Delta)$, $\Delta \in U_{ad}$ je spojitě diferencovatelná podle x_i pro každé $i = 1, \dots, n-1$, tudíž je třídy C^1 na U_{ad} . Symbolem $\mathbf{A}'(\Delta; x_i)$ označme derivaci matice $\mathbf{A}(\Delta)$ podle proměnné x_i . Zřejmě v matici $\mathbf{A}'(\Delta; x_i)$ je pouze 6 nenulových členů pro $i = 1, \dots, n-1$ (protože krajní body $x_0 = a$ a $x_n = b$ jsou pevné, budou nás zajímat jenom derivace podle x_i pro $i = 1, \dots, n-1$):

$$\frac{\partial a_{i-1,i-1}}{\partial x_i}(\Delta) = \frac{1}{3}, \quad (3.5)$$

$$\frac{\partial a_{ii}}{\partial x_i}(\Delta) = 0, \quad (3.6)$$

$$\frac{\partial a_{i+1,i+1}}{\partial x_i}(\Delta) = -\frac{1}{3}, \quad (3.7)$$

$$\frac{\partial a_{i-1,i}}{\partial x_i} = \frac{\partial a_{i,i-1}}{\partial x_i}(\Delta) = \frac{1}{6}, \quad (3.8)$$

$$\frac{\partial a_{i,i+1}}{\partial x_i} = \frac{\partial a_{i+1,i}}{\partial x_i}(\Delta) = -\frac{1}{6}, \quad (3.9)$$

pro každé $i = 1, \dots, n - 1$.

Ukažme, že tyto funkce spojitě závisí na $\Delta \in U_{ad}$. K tomu využijeme fakt, že neurčitý Lebesgueův integrál integrovatelné funkce je absolutně spojitý jako funkce integrační meze. Upravme například (3.10) následovně:

$$\begin{aligned} \frac{\partial}{\partial x_i}(f, \varphi_{i-1}(\Delta)) &= \frac{1}{(x_i - x_{i-1})^2} \int_{x_{i-1}}^{x_i} f(x)(x - x_{i-1}) dx \\ &= \frac{1}{(x_i - x_{i-1})^2} \int_a^{x_i} x f(x) dx - \frac{1}{(x_i - x_{i-1})^2} \int_a^{x_{i-1}} x f(x) dx \\ &\quad - \frac{x_{i-1}}{(x_i - x_{i-1})^2} \int_a^{x_i} f(x) dx + \frac{x_{i-1}}{(x_i - x_{i-1})^2} \int_a^{x_{i-1}} f(x) dx. \end{aligned}$$

Tudíž $\frac{\partial}{\partial x_i}(f, \varphi_{i-1}) \in C(U_{ad})$. Analogicky můžeme dokázat, že $\frac{\partial}{\partial x_i}(f, \varphi_j) \in C(U_{ad})$ pro každé $i = 1, \dots, n - 1$ a $j = 0, \dots, n$, tedy $F(\Delta) \in C^1(U_{ad})$.

(b) Je-li $X = X_2$ a $L = \tilde{L}_n$, potom vztahy (2.13)-(2.15) definují C^1 maticovou funkci a její prvky jsou dány vztahy:

$$\frac{\partial a_{i-1, i-1}}{\partial x_i}(\Delta) = -\frac{1}{(x_i - x_{i-1})^2}, \quad (3.13)$$

$$\frac{\partial a_{ii}}{\partial x_i}(\Delta) = -\frac{1}{(x_i - x_{i-1})^2} + \frac{1}{(x_{i+1} - x_i)^2}, \quad (3.14)$$

$$\frac{\partial a_{i+1, i+1}}{\partial x_i}(\Delta) = \frac{1}{(x_{i+1} - x_i)^2}, \quad (3.15)$$

$$\frac{\partial a_{i-1, i}}{\partial x_i} = \frac{\partial a_{i, i-1}}{\partial x_i}(\Delta) = \frac{1}{(x_i - x_{i-1})^2}, \quad (3.16)$$

$$\frac{\partial a_{i, i+1}}{\partial x_i} = \frac{\partial a_{i+1, i}}{\partial x_i}(\Delta) = -\frac{1}{(x_{i+1} - x_i)^2}, \quad (3.17)$$


pro každé $i = 1, \dots, n - 1$. Ostatní prvky matice $\mathbf{A}'(\Delta; x_i)$ jsou nulové.

Naopak diferencovatelnost $F(\Delta)$ v tomto případě vyžaduje, aby funkce f měla spojitou slabou derivaci. Potom analogicky, jako jsme postupovali při odvození (3.10)-(3.12) můžeme určit derivaci $F'(\Delta; x_i)$. K tomu potřebujeme tvar slabých derivací básových funkcí:

$$\varphi'_{i-1}(x) = \begin{cases} \frac{1}{x_{i-1} - x_{i-2}} & , x \in (x_{i-2}, x_{i-1}), \\ \frac{-1}{x_i - x_{i-1}} & , x \in (x_{i-1}, x_i), \\ 0 & \text{jinak} \end{cases}$$

$$\varphi'_i(x) = \begin{cases} \frac{1}{x_i - x_{i-1}} & , x \in (x_{i-1}, x_i), \\ \frac{-1}{x_{i+1} - x_i} & , x \in (x_i, x_{i+1}), \\ 0 & \text{jinak} \end{cases}$$

$$\varphi'_{i+1}(x) = \begin{cases} \frac{1}{x_{i+1} - x_i} & , x \in (x_i, x_{i+1}), \\ \frac{-1}{x_{i+2} - x_{i+1}} & , x \in (x_{i+1}, x_{i+2}), \\ 0 & \text{jinak.} \end{cases}$$



Obrázek 3.1: Slabá derivace bázové funkce φ_i

Potom platí:

$$\begin{aligned} \frac{\partial(f, \varphi_{i-1})}{\partial x_i} &= \frac{\partial}{\partial x_i} \int_{x_{i-1}}^{x_i} f'(x) \varphi'_{i-1}(x) dx = \frac{\partial}{\partial x_i} \left(\frac{-1}{x_i - x_{i-1}} \int_{x_{i-1}}^{x_i} f'(x) dx \right) \\ &= \frac{1}{(x_i - x_{i-1})^2} \int_{x_{i-1}}^{x_i} f'(x) dx - \frac{f'(x_i)}{x_i - x_{i-1}} \\ &= \frac{f(x_i) - f(x_{i-1}) - f'(x_i)(x_i - x_{i-1})}{(x_i - x_{i-1})^2}, \quad (3.18) \end{aligned}$$

a vidíme, že pravá strana spojitě závisí na $\Delta \in U_{ad}$, neboť $f, f' \in C([a, b])$.
Obdobně:

$$\begin{aligned} \frac{\partial(f, \varphi_i)}{\partial x_i} &= - \frac{f(x_{i+1}) - f(x_i) - f'(x_i)(x_{i+1} - x_i)}{(x_{i+1} - x_i)^2} \\ &\quad - \frac{f(x_i) - f(x_{i-1}) - f'(x_i)(x_i - x_{i-1})}{(x_i - x_{i-1})^2}, \quad (3.19) \end{aligned}$$

$$\frac{\partial(f, \varphi_{i+1})}{\partial x_i} = \frac{f(x_{i+1}) - f(x_i) - f'(x_i)(x_{i+1} - x_i)}{(x_{i+1} - x_i)^2}, \quad (3.20)$$

pro $i = 1, \dots, n-1$. Ostatní složky $F'(\Delta; x_i)$ jsou i v tomto případě nulové.

Shrňme dosavadní výsledky do dvou vět.

Věta 3.2. (a) *Nechť $f \in C(a, b)$. Potom maticová funkce $\mathbf{A} : U_{ad} \rightarrow \mathbb{R}^{(n+1) \times (n+1)}$ definovaná vztahy (2.6)-(2.9) a vektorová funkce $F : U_{ad} \rightarrow \mathbb{R}^{n+1}$ definovaná vztahy (2.10)-(2.12) jsou třídy $C^1(U_{ad})$ a její směrové derivace $\mathbf{A}'(\Delta; x_i)$, resp. $F'(\Delta; x_i)$ v bodě $\Delta \in U_{ad}$ a ve směru x_i ($i = 1, \dots, n-1$) splňují (3.5)-(3.9), resp. (3.10)-(3.12).*

(b) *Nechť $f \in X_2$ má spojitou slabou derivaci: $f' \in C([a, b])$. Potom funkce $\mathbf{A} : U_{ad} \rightarrow \mathbb{R}^{n \times n}$ a $F : U_{ad} \rightarrow \mathbb{R}^n$ definované vztahy (2.13)-(2.15) a (2.16)-(2.17) jsou spojitě diferencovatelné na množině U_{ad} a pro její směrové derivace v bodě $\Delta \in U_{ad}$ a ve směru x_i ($i = 1, \dots, n-1$) platí vztahy (3.13)-(3.17), resp. (3.18)-(3.20).*

Věta 3.3. *Nechť $f \in X$ splňuje předpoklady předchozí věty. Potom úloha (3.1) má v množině U_{ad} řešení, t.j. existuje optimální dělení $\widehat{\Delta} \in U_{ad}$ intervalu $[a, b]$ o n uzlech splňující:*

$$\|f - g(\widehat{\Delta})\| = \min_{\Delta \in U_{ad}} \min_{h \in L(\Delta)} \|f - h\|.$$

Je snadno vidět, že řešení úlohy (3.1) je ekvivalentní minimalizaci funkce $\Phi : U_{ad} \rightarrow \mathbb{R}$ definované předpisem:

$$\Phi(\Delta) := \|f - g(\Delta)\|^2 = \|f\|^2 + \|g(\Delta)\|^2 - 2(f, g(\Delta)).$$

První člen v definici $\Phi(\Delta)$ nezávisí na dělení Δ , tudíž k určení optimálního dělení stačí minimalizovat následující funkci:

$$\mathcal{J}(\Delta) := \|g(\Delta)\|^2 - 2(f, g(\Delta)) \quad \forall \Delta \in U_{ad}. \quad (3.21)$$

Po úpravách dostaneme ekvivalentní zápis:

$$\begin{aligned}
\mathcal{J}(\Delta) &= (g(\Delta), g(\Delta)) - 2(f, g(\Delta)) \\
&= \left(\sum_i \alpha_i(\Delta) \varphi_i(\Delta), \sum_j \alpha_j(\Delta) \varphi_j(\Delta) \right) - 2 \left(f, \sum_i \alpha_i(\Delta) \varphi_i(\Delta) \right) \\
&= \sum_{i,j} \alpha_i(\Delta) \alpha_j(\Delta) (\varphi_i(\Delta), \varphi_j(\Delta)) - 2 \sum_i \alpha_i(\Delta) (f, \varphi_i(\Delta)) \\
&= \langle \alpha(\Delta), \underbrace{\mathbf{A}(\Delta) \alpha(\Delta)}_{=F(\Delta)} \rangle - 2 \langle \alpha(\Delta), F(\Delta) \rangle \tag{3.22}
\end{aligned}$$

$$= - \langle \alpha(\Delta), F(\Delta) \rangle. \tag{3.23}$$

Aby nedošlo k nedorozumění o jaký skalární součin se jedná, užili jsme značení $\langle \cdot, \cdot \rangle$ pro standardní skalární součin v \mathbb{R}^{n+1} , resp. \mathbb{R}^n , stejně jako v první kapitole.

Porovnáme-li $\mathcal{J}(\Delta)$ prostřednictvím (3.22) s funkcí definovaným v Dodatku první kapitoly, zjistíme, že se rovnají až na multiplikatívní konstantu. Jsou-li navíc splněny předpoklady Věty 3.2, platí dle zmíněného dodatku vztah pro směrovou derivaci $\mathcal{J}'(\Delta; x_i)$ v bodě $\Delta \in U_{ad}$ a ve směru x_i ($i = 1, \dots, n-1$):

$$\mathcal{J}'(\Delta; x_i) = \langle \alpha(\Delta), \mathbf{A}'(\Delta; x_i) \alpha(\Delta) - 2F'(\Delta; x_i) \rangle. \tag{3.24}$$

Kapitola 4

Numerické experimenty

Úloha nalezení optimálního dělení intervalu byla naprogramována pro Úlohu 2.4 s následujícími daty:

- $(a, b) = (0, 1)$,
- $f(x) = x^\beta$, pro $\beta = 0.51, 0.65, 0.8$,
- $U_{ad} = U_\delta$ pro $\delta = 10^{-4}, 10^{-5}, 10^{-6}$, kde U_δ je dána vztahem (3.2),
- $n = 2, 4, 8, 16, 32, 64, 128$.

Zřejmě $x^\beta = 0$ pro $x = 0$ a $\beta > 0$. K tomu, aby funkce $f(x) = x^\beta \in W^{1,2}(0, 1)$, musí platit následující omezení na parametr β :

$$\|x^\beta\|_{X_2}^2 = \int_0^1 ((x^\beta)')^2 dx = \beta^2 \int_0^1 x^{2\beta-2} dx < \infty \iff 2\beta - 2 > -1$$
$$\iff \beta > \frac{1}{2}.$$

Potom $f \in X_2$ a současně $f \in X_1$, navíc platí:

$$\|f\|_{X_1}^2 = \int_0^1 x^{2\beta} dx = \frac{1}{2\beta + 1},$$
$$\|f\|_{X_2}^2 = \beta^2 \int_0^1 x^{2\beta-2} dx = \frac{\beta^2}{2\beta - 1}.$$

Podle definice z předchozí kapitoly (viz. (3.1)), optimální dělení je dělení $\widehat{\Delta}_n \in U_{ad}$ pro které:

$$\Phi(\widehat{\Delta}_n) = \min_{\Delta_n \in U_{ad}} \Phi(\Delta_n) = \min_{\Delta_n \in U_{ad}} \|f - g(\Delta_n)\|^2 = \|f\|^2 + \min_{\Delta_n \in U_{ad}} \mathcal{J}(\Delta_n),$$

kde funkcionál \mathcal{J} je dán předpisem (3.21), nebo ekvivalentně (3.23).

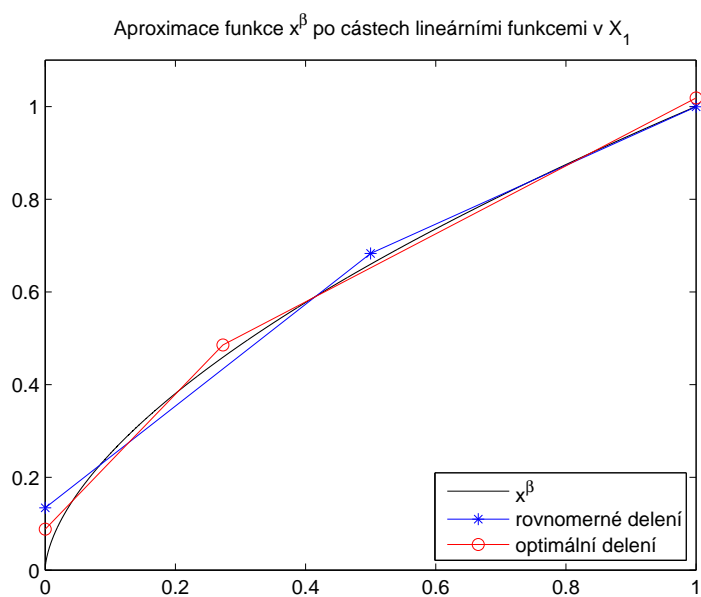
Nazvěme veličinu $\Phi(\Delta_n)$ *chybou aproximace na dělení* $\Delta_n \in U_{ad}$.

Poznámka. Jeden z praktických aspektů definice množiny $U_{ad} := U_\delta$ je to, že sousedící uzly se nemohou dostat "příliš" blízko k sobě: jinak by se mohlo stát, že $x_j \approx x_{j+1}$ a při sestavení matice $\mathbf{A}(\Delta_n)$ na počítači bychom dostali chybové hlášení o dělení nulovou. Abychom se tomu vyhnuli, nabízí se definovat množinu U_{ad} právě vztahem (3.2), který navíc dovoluje uzlům dělení relativně velkou flexibilitu.


Co se týče vlastní realizace, numerické výsledky byly získány pomocí komerčního softwaru MATLAB©, přičemž k minimalizaci funkcionálu $\mathcal{J}(\Delta_n)$ byla použita funkce *fmincon*. Ta je založena na kvazi-Newtonově metodě k nalezení vázaného extrému reálné funkce více proměnných. Pro bližší informace o použité funkci bychom čtenáře odkázali na online help, viz. stránky [3]. Zmíníme se však o jedné důležité vlastnosti funkce *fmincon*, a sice, že jako vstupní hodnotu jí můžeme předat gradient funkce \mathcal{J} . Tím usnadníme minimalizaci, protože díky jednoduchým tvarům matic $\mathbf{A}'(\Delta_n; x_i)$ a vektorů $F'(\Delta_n; x_i)$ je výpočet $\mathcal{J}'(\Delta_n; x_i)$ podle (3.24) zcela nenáročný.

Poznámka. Vzhledem k tomu, jak je norma definována v prostorech X_1 a X_2 , očekáváme, že dělení bude "citlivější" v blízkosti nuly. Tedy uzly optimálního dělení se budou hromadit kolem nuly a to hlavně pro $X = X_2$, neboť tatáž funkce x^β má větší normu v X_2 . Navíc lze předpokládat, že čím bude β blíže hraniční hodnotě $\frac{1}{2}$, tím razantnější bude přemísťování uzlů.

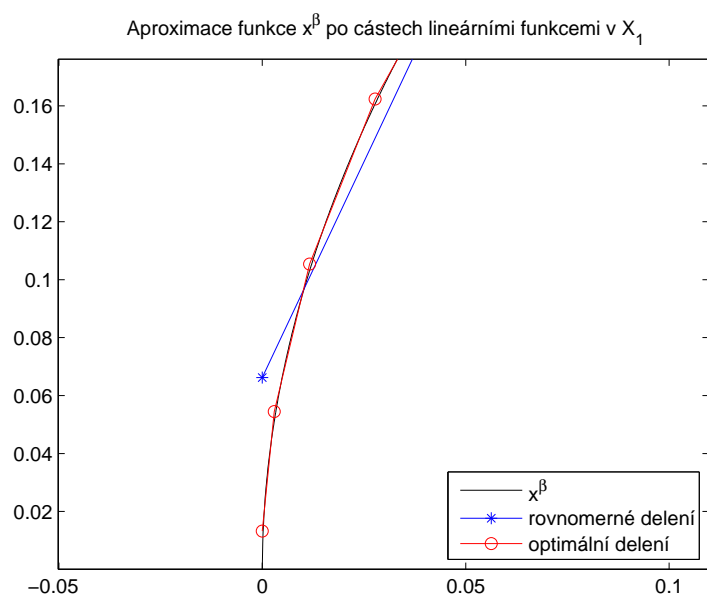
O tom, že tato intuice je správná, svědčí následující čtyři obrázky.



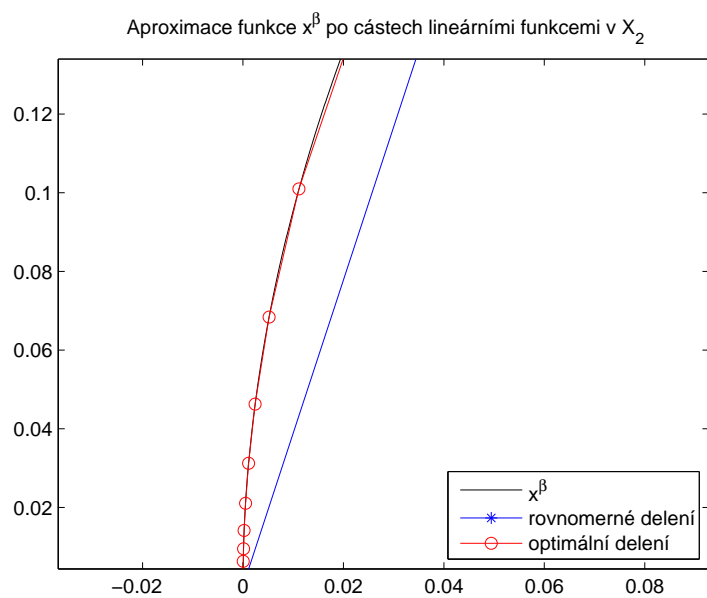
Obrázek 4.1: $\beta = 0.65$, $n = 2$, $\delta = 10^{-5}$



Obrázek 4.2: $\beta = 0.65$, $n = 2$, $\delta = 10^{-5}$



Obrázek 4.3: $\beta = 0.51$, $n = 16$, $\delta = 10^{-5}$ (zvětšený)



Obrázek 4.4: $\beta = 0.51$, $n = 16$, $\delta = 10^{-5}$ (zvětšený)

Zvolíme-li β z intervalu $(\frac{1}{2}, 1)$, bude funkce x^β příliš regulární, jakožto prvek $L^2(0, 1)$ a proto nedostaneme podstatně lepší odhady pomocí optimálního dělení: řád konvergence zůstává stejný, jako při aproximaci na rovnoměrném dělení. Navíc ani posun uzlů není dostatečně markantní, proto jsou výsledky stejné pro $\delta = 10^{-4}, 10^{-5}, 10^{-6}$.

Chyby aproximace na rovnoměrném a optimálním dělení jsou znázorněny v následujících tabulkách, resp. grafech.

Tabulka 4.1: Chyby aproximace pro $\beta = 0.51$ v X_1

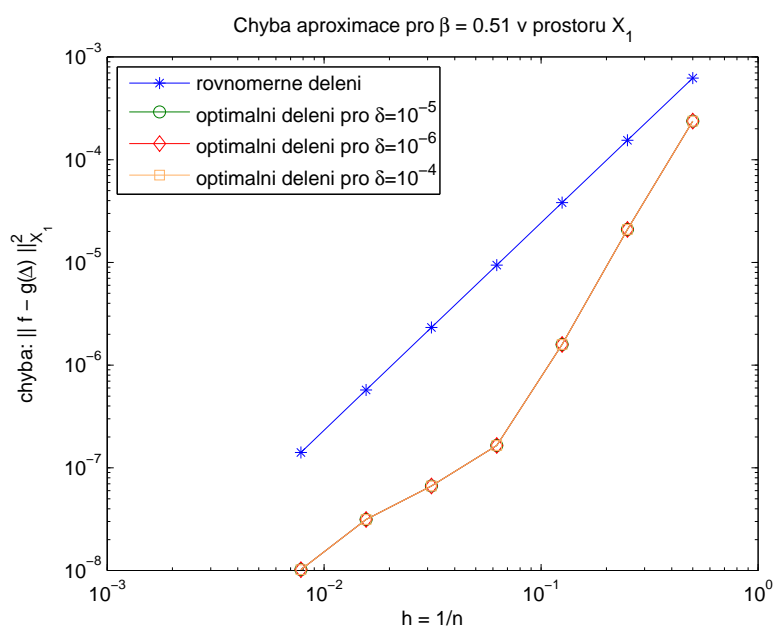
	rovnoměrné dělení	optimální dělení
n = 2	0.00062352225591	0.00023741975036
n = 4	0.00015489119360	0.00002096300694
n = 8	0.00003822152676	0.00000159113760
n = 16	0.00000942580440	0.00000016534591
n = 32	0.00000232413223	0.00000006664978
n = 64	0.00000057304132	0.00000003148067
n = 128	0.00000014128789	0.00000001021295

Tabulka 4.2: Chyby aproximace pro $\beta = 0.65$ v X_1


	rovnoměrné dělení	optimální dělení
n = 2	0.00028398398248	0.00011839512620
n = 4	0.00005823891027	0.00000982820914
n = 8	0.00001184946329	0.00000071893953
n = 16	0.00000240764332	0.00000018807677
n = 32	0.00000048899424	0.00000003828210
n = 64	0.00000009930233	0.00000000777939
n = 128	0.00000002016476	0.00000000200715

Tabulka 4.3: Chyby aproximace pro $\beta = 0.8$ v X_1

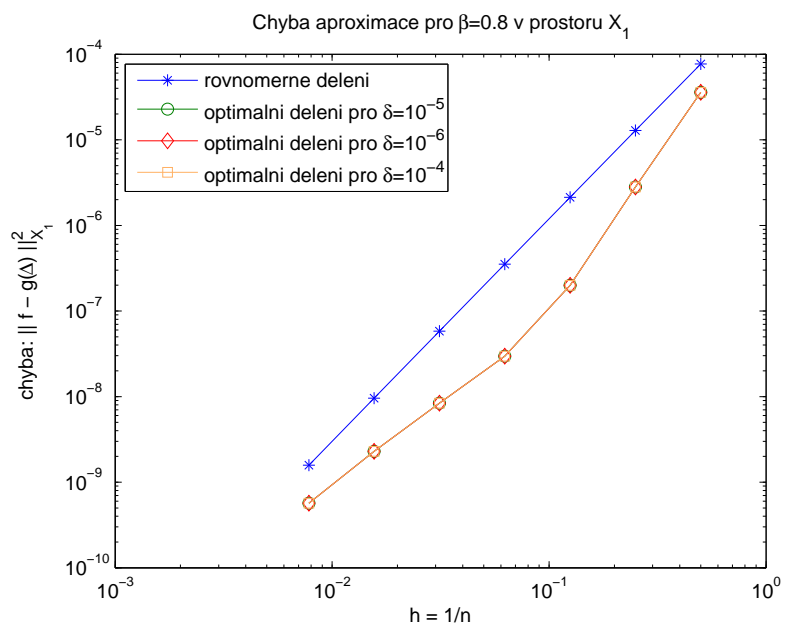
	rovnoměrné dělení	optimální dělení
n = 2	0.00007678955287	0.00003583587987
n = 4	0.00001286030803	0.00000281719338
n = 8	0.00000213134063	0.00000019963875
n = 16	0.00000035217639	0.00000002964207
n = 32	0.00000005812711	0.00000000839131
n = 64	0.00000000958974	0.00000000228827
n = 128	0.00000000158130	0.00000000056859



Obrázek 4.5: $\beta = 0.51$ v prostoru X_1




Obrázek 4.6: $\beta = 0.65$ v prostoru X_1




Obrázek 4.7: $\beta = 0.8$ v prostoru X_1

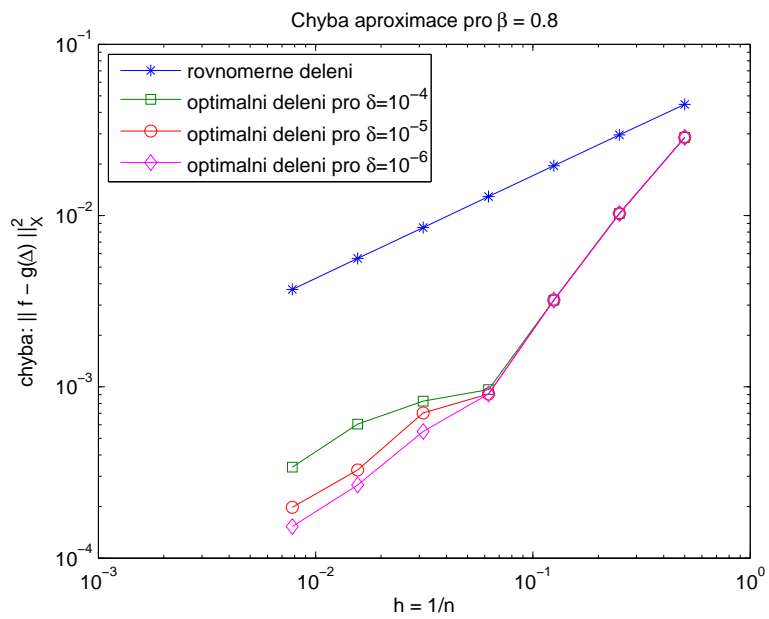
Provedeme-li nyní numerické testy pro stejné funkce x^β v prostoru X_2 , můžeme spatřit více odlišností. Čím je β blíž $\frac{1}{2}$, tím je výraznější vliv volby množiny U_δ . Pro menší δ dostaneme zřejmě lepší aproximace, neboť dovolu-
jeme dělicím uzlům větší svobodu. Při aplikaci se ale brzy dostane podstatná část dělicích bodů (tj. uzly, které jsou blíž místa, kde funkce je "citlivější") δ -blízko k sobě a tím pádem chyba aproximace klesá velmi pomalu. Jak je z obrázků dále patrné, nebude-li funkce x^β "příliš singulární", můžeme pomocí optimálního dělení zlepšit i řád konvergence.



Obrázek 4.8: $\beta = 0.51$ v prostoru X_2



Obrázek 4.9: $\beta = 0.65$ v prostoru X_2



Obrázek 4.10: $\beta = 0.8$ v prostoru X_2

Tabulka 4.4: Chyby aproximace pro $\beta = 0.51$ v X_2

	rovnorné dělení	optimální dělení pro $\delta = 10^{-4}$	optimální dělení pro $\delta = 10^{-5}$	optimální dělení pro $\delta = 10^{-6}$
$n = 2$	11.84142434248926	11.18605046036190	11.18605046061797	11.18605046114404
$n = 4$	11.67886536296823	10.31909658421517	10.11170323189256	9.97703384738671
$n = 8$	11.51819867257026	10.05789955849110	9.67131147609378	9.32924686177665
$n = 16$	11.35965438404583	10.00169222054870	9.56693424926088	9.15879677302799
$n = 32$	11.20327021923588	9.99026332072150	9.54563082499027	9.12089220585063
$n = 64$	11.04903337691056	9.98876410943054	9.54025085888399	9.11394982021114
$n = 128$	10.89691854176243	9.98826042719646	9.54003432969108	9.11075572908037

Tabulka 4.5: Chyby aproximace pro $\beta = 0.65$ v X_2

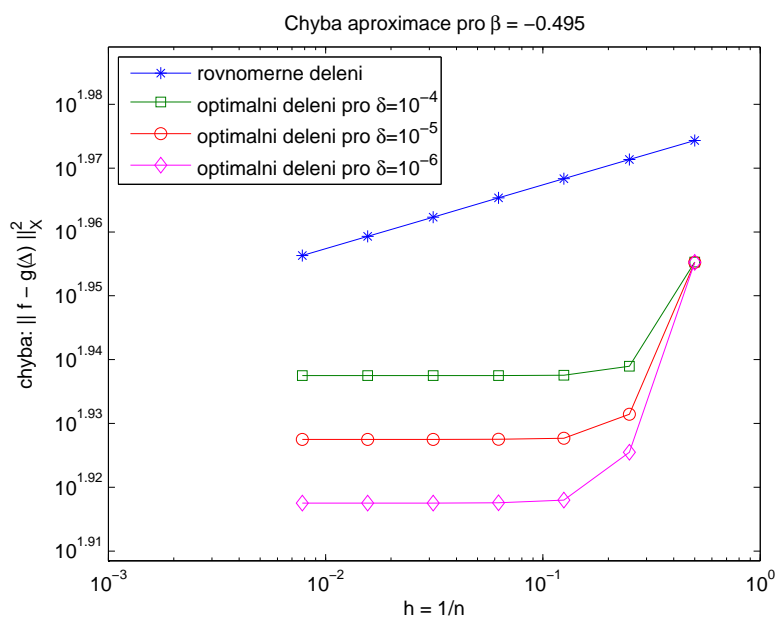
	rovnoměrné dělení	optimální dělení pro $\delta = 10^{-4}$	optimální dělení pro $\delta = 10^{-5}$	optimální dělení pro $\delta = 10^{-6}$
$n = 2$	0.33294979525939	0.22714505836206	0.22714505857262	0.22714505859395
$n = 4$	0.27078464305353	0.10352453452236	0.10352453821588	0.1035245266210
$n = 8$	0.22003387502107	0.04411350034908	0.03909053710078	0.03889509464718
$n = 16$	0.17874528277935	0.02990341114025	0.01894271227061	0.01432676352092
$n = 32$	0.14519185341497	0.02739967057967	0.01478576353340	0.00853886812035
$n = 64$	0.11793382371975	0.02665509616114	0.01453241547296	0.00795158144360
$n = 128$	0.09579237917629	0.02633895826365	0.01389864808287	0.00709512578625

Tabulka 4.6: Chyby aproximace pro $\beta = 0.8$ v X_2

	rovnorné dělení	optimální dělení pro $\delta = 10^{-4}$	optimální dělení pro $\delta = 10^{-5}$	optimální dělení pro $\delta = 10^{-6}$
$n = 2$	0.0445546588784	0.02859997268447	0.02859997268262	0.02859997268245
$n = 4$	0.02954779147936	0.01027896703247	0.01027898905710	0.01027896849152
$n = 8$	0.01953303352185	0.00320644764743	0.00320643198422	0.00320643248219
$n = 16$	0.01289673544257	0.00096336625285	0.00090824488734	0.00090824839835
$n = 32$	0.00851111018095	0.00082557963985	0.00070296864441	0.00054840416250
$n = 64$	0.00561584829385	0.00060530244619	0.00032728215698	0.00026709560721
$n = 128$	0.00370523055880	0.00033983144021	0.00019789475206	0.00015289311169

Na Obrázcích 4.5 - 4.7 jsme viděli, jak se chová chyba aproximace na optimálním dělení pro regulární funkce v prostoru X_1 . Ukážeme nakonec případ, kdy funkce x^β je dost singulární, tj. β je blízko hraniční hodnotě $-\frac{1}{2}$, neboť

$$x^\beta \in L^2(0, 1) \Leftrightarrow \beta > -\frac{1}{2}.$$



Obrázek 4.11: $\beta = -0.495$ v prostoru X_1

Tabulka 4.7: Chyby aproximace pro $\beta = -0.495$ v X_1

	rovnorné dělení	optimální dělení pro $\delta = 10^{-4}$	optimální dělení pro $\delta = 10^{-5}$	optimální dělení pro $\delta = 10^{-6}$
$n = 2$	94.26226896784705	90.21543172644914	90.20521009650783	90.20521009933839
$n = 4$	93.61819670873123	86.88904963759668	85.39391948286800	84.23276243677036
$n = 8$	92.97156445667628	86.60683976229109	84.66151144353450	82.79267761821302
$n = 16$	92.32936299465104	86.59699600660819	84.62674967686891	82.71016414864283
$n = 32$	91.69159750118368	86.59662804575063	84.62599532011830	82.69942290926704
$n = 64$	91.05823737322737	86.59638536318295	84.62535248158771	82.69909706634400
$n = 128$	90.42925218308477	86.59635626227555	84.62526621155854	82.69896216938525

Literatura

- [1] Haslinger J., Mäkinen R. A.: *Introduction to Shape Optimization: Theory, Approximation and Computation*, Advances in Design and Control, SIAM, 2003.
- [2] Lukeš J.: *Zápisky z funkcionální analýzy*, Nakladatelství Karolinum, 2003.
- [3] <http://www.mathworks.com/access/helpdesk/help/toolbox/optim/index.html?access/helpdesk/help/toolbox/optim/ug/fmincon.html>