

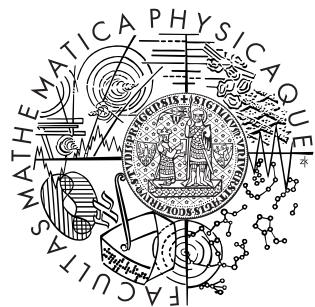
# Numerická matematika

Jiří Felcman

Univerzita Karlova v Praze



Matematicko-fyzikální fakulta



KNM PRESS • PRAHA

2009



# PŘEDMLUVA

## 1. přednáška

1. `felcman@karlin.mff.cuni.cz`
  - Tel. 22191 3392
  - KNM č. dv. 442
  -
2. Numerická matematika - anotace
  - Obecná informatika (Druh, program, ročník, obor: B.I.3.IOI)
3. Požadavky ke zkoušce
  - státnice (prospěl s vyznamenáním), souborná zkouška
  - syllabus
4. Tituly
  - Ph.D. (projekt + angličtina)
  - RNDr.
  - Mgr.
  - Bc
5. Studium v zahraničí - ERASMUS
6. Ceny udělované studentům
7. SVOČ
8. Hodnocení učitelů - srozumitelnost
9. Náhrada
  - 13.03 2009 (Zahraničí)
  - 03.04 2009 (HONOM 2009)
  - 10.04 2009 (?Velký pátek?)
  - 01.05 2009 (Svátek práce)
  - 08.05 2009 (Den vítězství)
10. Zápočet: pátek 15. května 2009
11. Zkouška: pátek 15. května 2009 (Ukončení výuky předmětů, které jsou uvedeny v doporučeném průběhu bakalářského studia pro 6. semestr.)
  - část písemná
  - část ústní

Práce je částí výzkumného projektu MSM 0021620839 financovaného MŠMT. Děkuji panu Michalu Zerolovi, studentu Matematicko-fyzikální fakulty UK v Praze, který napsal v  $\text{\LaTeX}x$ u převážnou část tohoto učebního textu a přispěl tak podstatnou měrou k jeho realizaci.

Praha, 11. února 2009

J. F.

Numerická matematika  
**MAI 042 p1a LS 2008/2009**

1. přednáška Reálné situace, modely, diskretizace, počítačová realizace (folie)  
**Náměty do cvičení:** Zdroje chyb v numerické matematice
2. přednáška Aproximace funkcí, interpolace, aproximační metody nejmenších čtverců, Lagrangeova báze, existence a jednoznačnost Lagrangeova interpolačního polynomu, chyba Lagrangeovy interpolace  
**Náměty do cvičení:** Newtonova báze, monomiální báze, Vandermondova matici a determinant, vyčíslení Lagrangeova interpolačního polynomu v jediném bodě (Aitkenovo-Nevilleovo schéma), Hornerovo schéma, vyčíslení hodnoty derivace polynomu pomocí Hornerova schématu, počet operací při vyčíslení hodnoty polynomu.
3. přednáška Přirozený kubický spline  
**Náměty do cvičení:** Konstrukce přirozeného kubického spline, řešitelnost soustavy rovnic pro momenty
4. přednáška Numerická integrace  
**Náměty do cvičení:** Symboly  $o(h)$  a  $O(h)$ , substituce při výpočtu určitého integrálu (výpočet koeficientů N-C vzorců), odhad chyby N-C vzorců
5. přednáška Numerická integrace  
**Náměty do cvičení:** Rombergova kvadratura, ortogonální polynomy (důkaz věty 2.13), konstrukce ortogonálních polynomů  $p_0, p_1, p_2$  na  $[-1, 1]$ , vyjádření polynomu jako lineární kombinace ortogonálních polynomů
6. přednáška Metody řešení nelineárních rovnic  
**Náměty do cvičení:** půlení intervalu, metoda sečen, metoda tečen, metoda regula falsi, důkaz lemmatu 3.3
7. přednáška Metody řešení nelineárních rovnic  
**Náměty do cvičení:** důkaz konvergence metody postupných aproximačních (věta 3.7), Newtonova metoda jako speciální případ věty o pevném bodě, Hornerovo schéma pro výpočet derivace, zápis algoritmu Hornerova schématu
8. přednáška Soustavy lineárních rovnic  
**Náměty do cvičení:** zápis algoritmu Gaußovy eliminace, počet operací Gaußovy eliminace,
9. přednáška Soustavy lineárních rovnic  
**Náměty do cvičení:** Gaußova eliminace jako  $\mathbb{LU}$  rozklad,  $\mathbb{LU}$  rozklad obecně,  $\mathbb{LU}$  rozklad matice  $4 \times 4$ , číslo podmíněnosti při  $\mathbb{LU}$  rozkladu
10. přednáška Iterační metody řešení soustav lineárních rovnic  
**Náměty do cvičení:** výpočet jedné iterace Gaußovy-Seidelovy metody pro matici  $4 \times 4$
11. přednáška Výpočet vlastních čísel matic

**Náměty do cvičení:** motivace výpočtu vlastních čísel matic, aplikace, metody výpočtu vlastních čísel, vlastní čísla symetrických matic, diagona- lizovatelnost matic, různé varianty mocninné metody

12. přednáška Numerická integrace obyčejných diferenciálních rovnic

**Náměty do cvičení:** Věta o existenci a jednoznačnosti řešení, soustavy obyčejných diferenciálních rovnic, Taylorův rozvoj funkce více proměnných, odvození Rungeovy–Kuttovy metody 2. řádu

13. přednáška Gradientní metody

**Náměty do cvičení:** pojem gradient funkce, motivace gradientních me- tod, odvození metody sdružených gradientů



# OBSAH

<b>Úvod</b>	1
<b>1 Aproximace funkcí v <math>\mathbb{R}</math></b>	2
1.1 Lagrangeův interpolační polynom	4
1.1.1 Chyba Lagrangeovy interpolace	5
1.2 Kubický spline	6
1.2.1 Konstrukce přirozeného kubického spline	7
<b>2 Numerická integrace funkcí</b>	12
2.1 Newtonovy-Cotesovy vzorce	12
2.1.1 Složené Newtonovy-Cotesovy vzorce	14
2.2 Rombergova kvadratura	14
2.3 Gaußova kvadratura	16
<b>3 Metody řešení nelineárních rovnic</b>	19
3.1 Newtonova metoda	19
3.1.1 Důkaz konvergence Newtonovy metody	20
3.1.2 Řád konvergence	23
3.2 Metoda postupných approximací pro nelineární rovnice	24
3.3 Kořeny polynomu	24
3.3.1 Hornerovo schema	24
<b>4 Soustavy lineárních rovnic</b>	27
4.1 Podmíněnost matic	27
4.2 Gaußova eliminace	28
4.2.1 Pivotace	29
4.3 Gaußova eliminace jako faktorizační metoda	30
4.4 LU rozklad v obecném případě	32
4.4.1 Vliv zaokrouhllovacích chyb	34
4.5 Choleského rozklad	34
4.6 QR rozklad	35
<b>5 Iterační metody řešení soustav lineárních rovnic</b>	36
5.1 Klasické iterační metody	37
<b>6 Výpočet vlastních čísel matic</b>	43
6.1 Mocninná metoda	43
<b>7 Numerická integrace obyčejných diferenciálních rovnic</b>	45
7.1 Formulace problému	45
7.2 Jednokrokové metody	45

7.2.1 Metody typu Runge–Kutta	47
<b>8 Gradientní metody</b>	50
8.1 Formulace problému	50
<b>Bibliografie</b>	51
<b>Index</b>	52

## ÚVOD

**Numerická analýza:** Studium algoritmů (jednoznačně definovaná konečná posloupnost aritmetických a logických operací) pro řešení problémů spojené matematiky. L.N. Trefethen, Bulletin IMA 1993

**Numerická matematika:** realizace matematických modelů na počítači

Fyzikální realita → matematický model → numerické řešení, t.j. realizace matematického modelu na počítači.

Validation (solving the right equations) – verification (solving the equations right)

**Literatura k přednášce:** (Quarteroni *et al.*, 2004), (Ueberhuber, 2000), (Segethová, 2000)

**Předpokládané znalosti:** Rolleova věta, definice normy funkce, definice seminormy, vlastní čísla, báze lineárního vektorového prostoru, Taylorova věta

## APROXIMACE FUNKCÍ V $\mathbb{R}$

Jedna ze základních úloh numerické matematiky: approximace dané funkce  $f$  jinou funkcí  $\varphi$

Zadání approximované funkce - analyticky, nebo je k dispozici

- tabulka hodnot  $(x_i, f_i)$ ,  $x_i, f_i \in \mathbb{R}$ ,  $i = 0, \dots, n$ ,  $n \in \mathbb{N}$ ,  $f_i = f(x_i)$  (viz obr. 1.0.1)
- tabulka hodnot derivací do určitého rádu v uzlech  $x_i$

Pro funkci  $f$  definovanou na uzavřeném intervalu  $[a, b]$  uvažujeme *dělení intervalu*  $[a, b]$ ,  $a = x_0 < x_1, \dots < x_n = b$ ,  $n \in \mathbb{Z}^+ = \{0, 1, \dots\}$  a nazýváme ho *sítí*.  $x_i$ ,  $i = 0, \dots, n$  nazýváme *uzly* (ekvidistantní, je-li  $x_i = a + ih$ , kde  $h \in \mathbb{R}$  je krok sítě.)

**Poznámka 1.1** Pojem sít se používá obecně v  $N$ -rozměrném prostoru, viz např. (Feistauer *et al.*, 2003, str. 185): Let  $\Omega \subset \mathbb{R}^N$  be a domain. If  $N = 2$ , then by  $\Omega_h$  we denote a polygonal approximation of  $\Omega$ . This means that the boundary  $\partial\Omega_h$  of  $\Omega_h$  consists of a finite number of closed simple piecewise linear curves. For  $N = 3$ ,  $\Omega_h$  will denote a polyhedral approximation of  $\Omega$ . For  $N = 3$  we set  $\Omega_h = \Omega$ . The system  $\mathcal{D}_h = \{D_i\}_{i \in J}$ , where  $J \subset \mathbb{Z}^+ = \{0, 1, \dots\}$  is an index set and  $h > 0$ , will be called a *finite volume mesh* in  $\Omega_h$ , if  $D_i$ ,  $i \in J$ , are *closed line segments* or *closed polygons* or *polyhedrons*, if  $N = 1$  or  $N = 2$  or  $3$ , respectively, with mutually disjoint interiors such that

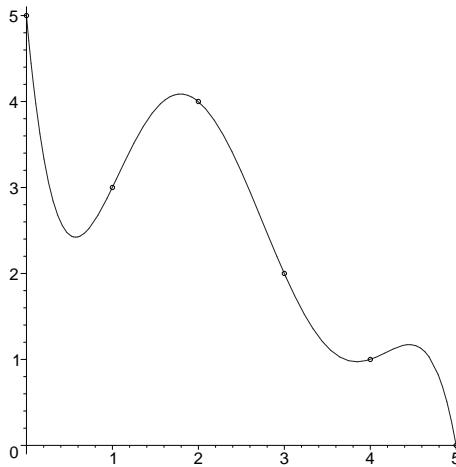
$$\overline{\Omega}_h = \bigcup_{i \in J} D_i.$$

The elements  $D_i \in \mathcal{D}_h$  are called *finite volumes*. Two finite volumes  $D_i$ ,  $D_j \in \mathcal{D}_h$  are either disjoint or their intersection is formed by a common part of their boundaries  $\partial D_i$  and  $\partial D_j$ . If  $\partial D_i \cap \partial D_j$  contains at least one straight segment or a plane manifold, if  $N = 2$  or  $3$ , respectively, then we call  $D_i$  and  $D_j$  *neighbouring finite volumes* (or simply neighbours).

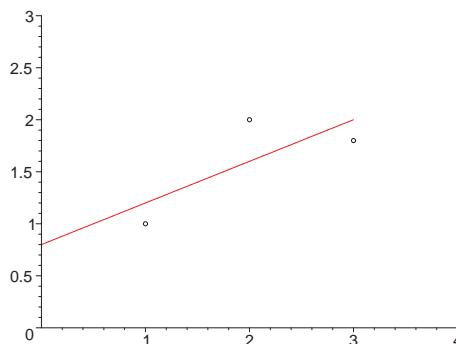
Požadavky na approximující funkci  $\varphi$

(A) jednoduchý tvar, snadno vyčíslitelná

- \* polynom  $\{1, x, x^2, x^3, \dots\}$
- \* trigonometrický polynom  $\{1, \sin x, \cos x, \sin 2x, \cos 2x, \dots\}$
- \* racionální funkce
- \* exponenciální funkce  $ae^{bx}$



OBR. 1.0.1. Interpolaci polynom nabývající v daných uzlech předepsaných hodnot



OBR. 1.0.2. Proložení přímky třemi body (ve smyslu nejmenších čtverců)

- (B)  $\varphi^{(j)}(x_i) = f^{(j)}(x_i), \quad \forall i = 0, \dots, n, j = 0, \dots, c_i$  (rovnost hodnot, event. derivací v uzlech)
- (C)  $\|\varphi - f\|$  ‘malá’, kde  $\|\cdot\|$  značí normu

**Poznámka 1.2** Od požadavku (B) někdy upouštíme (proložit třemi body přímku - viz obr. 1.0.2)

Nejčastější způsoby approximace

1. Interpolace - k funkci  $f$  sestrojíme funkci  $\varphi$  z jisté třídy  $\mathcal{M}$  splňující (B)
2. Aproximace metodou nejmenších čtverců - k funkci  $f$  sestrojíme funkci  $\varphi$  z jisté třídy  $\mathcal{M}$  splňující (B) ve smyslu nejmenších čtverců
  - diskrétní případ

$$\sum_{i=0}^n w_i (f(x_i) - \varphi(x_i))^2 = \min_{\psi \in \mathcal{M}} \sum_{i=0}^n w_i (f(x_i) - \psi(x_i))^2$$

kde  $w_i > 0, i = 0, \dots, n$  jsou zadaná čísla, zvaná váhy. Název ‘nejmenší čtverce’ je patrný z následujícího příkladu:

**Příklad 1.3** Pro dané dělení intervalu  $[a, b]$  a dané kladné váhy  $w_i$  uvažujme normu funkce  $f$  danou vztahem

$$\|f\| := \sqrt{\sum_{i=0}^n w_i (f(x_i))^2}$$

$\varphi \in \mathcal{M}$  se hledá tak, že

$$\|f - \varphi\|^2 = \min_{\psi \in \mathcal{M}} \|f - \psi\|^2$$

- spojitý případ

$$\int_a^b w(x) (f(x) - \varphi(x))^2 dx = \min_{\psi \in \mathcal{M}} \int_a^b w(x) (f(x) - \psi(x))^2 dx$$

$w$  je váhová funkce (skoro všude kladná v  $[a, b]$ ,  $w \in L^2(a, b)$ ). Definice pojmu ‘skoro všude’ a prostoru  $L^2(a, b)$  viz např. (Feistauer et al., 2003, strana ...).

3. Čebyševova (stejnoměrná) approximace - k funkci  $f$  sestrojíme funkci  $\varphi$  z jisté třídy  $\mathcal{M}$  splňující

$$\max_{[a,b]} |\varphi(x) - f(x)| \leq \max_{[a,b]} |\psi(x) - f(x)|$$

pro všechny funkce  $\psi \in \mathcal{M}$ , kde  $\mathcal{M}$  je zvolená množina funkcí.

### 1.1 Lagrangeův interpolační polynom

Hledáme polynom  $L_n$  stupně nejvýše  $n$  (píšeme  $L_n \in \Pi_n$  - prostor polynomů stupně nejvýše  $n$ ) takový že

$$L_n(x_i) = f(x_i) \quad i = 0, \dots, n, \tag{1.1.1}$$

$x_i$  - navzájem různé uzly, obecně neekvidistantní. Takový polynom nazveme *Lagrangeovým interpolačním polynomem*.

**Věta 1.4** Nechť  $x_0, \dots, x_n$  jsou navzájem různé uzly. Pak existuje právě jeden interpolační polynom  $L_n \in \Pi_n$ :

$$L_n(x_i) = f(x_i) \quad i = 0, \dots, n.$$

**Důkaz** 1. Existence

Uvažujme polynomy

$$l_i(x) = \frac{(x - x_0)(x - x_1) \dots (x - x_{i-1})(x - x_{i+1}) \dots (x - x_n)}{(x_i - x_0)(x_i - x_1) \dots (x_i - x_{i-1})(x_i - x_{i+1}) \dots (x_i - x_n)}$$

(tzv. *Lagrangeovy polynomy*).

Platí

$$\begin{aligned} \alpha) \quad & l_i(x) \in \Pi_n, \\ \beta) \quad & l_i(x_j) = \delta_{ij} = \begin{cases} 1, & i = j, \\ 0, & i \neq j. \end{cases} \quad (\text{Kroneckerovo delta}). \end{aligned}$$

Položme

$$L_n(x) = \sum_{i=0}^n f(x_i) l_i(x).$$

## 2. Jednoznačnost

Nechť  $L_n^1, L_n^2 \in \Pi_n$  splňují (viz (1.1.1))

$$L_n^1(x_i) = L_n^2(x_i) = f(x_i) \quad \forall i = 0, \dots, n.$$

Potom  $L_n^1 - L_n^2 \in \Pi_n$  je polynom, který má  $(n+1)$  různých kořenů. Podle základní věty algebry je  $L_n^1 - L_n^2$  nulový polynom.

□

**Poznámka 1.5** Položme

$$\omega_{n+1}(x) = (x - x_0) \dots (x - x_n).$$

Potom platí

$$\ell_i(x) = \frac{\omega_{n+1}(x)}{(x - x_i) \cdot \omega'_{n+1}(x_i)},$$

kde čárka označuje derivaci.

1.1.1 *Chyba Lagrangeovy interpolace*

**Věta 1.6** Nechť  $f \in C^{n+1}(I)$ , kde  $I$  je nejmenší interval obsahující  $x_0, \dots, x_n, x^*$  a  $x_0, \dots, x_n$  jsou navzájem různé uzly. Nechť  $L_n \in \Pi_n$  je Lagrangeův interpolační polynom pro funkci  $f$ . Pak  $\exists \xi \in I$

$$f(x^*) - L_n(x^*) = \frac{f^{(n+1)}(\xi) \cdot \omega_{n+1}(x^*)}{(n+1)!}$$

(chyba Lagrangeovy interpolace v bodě  $x^*$ ).

**Důkaz** Pro  $x^* = x_i$  je důkaz zřejmý. Pro  $x^* \neq x_i$  uvažujme funkci :

$$F(x) = f(x) - L_n(x) - t \cdot \omega_{n+1}(x)$$

kde  $t \in \mathbb{R}$ . Platí:

$$F(x_i) = 0 \quad \forall i = 0, \dots, n.$$

Pro vhodnou volbu

$$t := \frac{f(x^*) - L_n(x^*)}{\omega_{n+1}(x^*)} \quad (1.1.2)$$

platí, že  $F(x^*) = 0$ .  $F$  má tedy  $n + 2$  nulových bodů (uzly  $x_i$  a bod  $x^*$ ). Podle Rolleovy věty:

$F'$  má aspoň  $n + 1$  nulových bodů,  
 $\vdots$   
 $F^{(n+1)}$  má aspoň 1 nulový bod, označme ho  $\xi$ .

$$F^{(n+1)}(\xi) = 0 = f^{(n+1)}(\xi) - 0 - t \cdot (n+1)! \quad \sqrt{\frac{\omega_{n+1}(x^*)}{(n+1)!}}$$

kde jsme využili toho, že  $(n+1)$ -ní derivace  $L_n$  je nulová a  $(n+1)$ -ní derivace  $\omega_{n+1}$  je  $(n+1)!$ . Dosadíme-li za  $t$  ze vztahu (1.1.2), dostaneme

$$f(x^*) - L_n(x^*) = \frac{f^{(n+1)}(\xi) \cdot \omega_{n+1}(x^*)}{(n+1)!}.$$

□

**Zkušební otázka 1.1!** Chyba Lagrangeovy interpolace

2. přednáška

## 1.2 Kubický spline

**Definice 1.7** Nechť je dáno dělení intervalu  $[a, b]$ ,  $a = x_0 < x_1 < \dots < x_n = b$  ( $x_i$  navzájem různé). Řekneme, že funkce  $\varphi : [a, b] \rightarrow \mathbb{R}$  je kubický spline, jestliže

1.  $\varphi''$  je spojitá ( $\in C^2[a, b]$ ),
2.  $\varphi|_{[x_i, x_{i+1}]}$  je kubický polynom, pro  $i = 0, 1, \dots, n - 1$ .

**Poznámka 1.8** Spline - elastické pravítko používané při stavbě lodí

**Poznámka 1.9** Kubický spline je speciálním případem spline  $k$ -tého řádu pro  $k = 3$ . Důvodem častého použití kubického spline je fakt, že lidské oko je schopné rozlišit ještě změny 2. derivace.

**Poznámka 1.10** Kubický spline dobře approximuje funkci, která popisuje tvar s minimální energií. Popíšeme-li tvar pružné laťky funkci  $y = f(x)$ , potom

$$E(y) = \int_a^b \frac{y''(x)}{\left[1 + (y'(x))^2\right]^{3/2}} dx$$

měří její ohybovou energii. Lať se deformeuje tak, že je tato energie minimální (Hamiltonův princip). Dá se ukázat, že mezi všemi funkcemi z  $C^2[a, b]$  approximuje kubický spline  $\varphi :: \varphi(x_i) = f(x_i)$  velmi dobře funkci  $y^*$ , pro kterou se nabývá minima  $E(y)$ :  $\min_y E(y) = E(y^*)$ .

**Věta 1.11** Nechť  $f \in C^2[a, b]$ . Pak pro každý kubický spline  $\varphi$  splňující

$$\varphi(x_i) = f(x_i), \quad i = 0, \dots, n,$$

platí

$$\|\varphi\| \leq \|f\|, \text{ kde } \|u\|^2 := \int_a^b |u''(x)|^2 dx,$$

jestliže je splněna některá z následujících třech podmínek:

- |     |   |         |
|-----|---|---------|
| (a) | $\varphi''(a) = 0 = \varphi''(b)$                               |         |
| (b) | $\varphi'(a) = f'(a) \quad a \quad \varphi'(b) = f'(b)$         | (1.2.1) |
| (c) | $\varphi'(a) = f'(b) \quad a \quad \varphi''(a) = \varphi''(b)$ |         |

**Poznámka 1.12** (Pozor,  $\|\cdot\|$  ve větě 1.11 neznačí normu, ale pouze seminormu v Sobolevově prostoru  $H^2(a, b)$ , která se obvykle značí  $|.|_{H^2(a, b)}$ , detaily viz např. (Feistauer et al., 2003, page ...))

**Důkaz** Viz cvičení k přednášce.  $\square$

**Důsledek 1.13** Ve všech třech případech (a), (b), (c) je kubický spline určen jednoznačně.

### 1.2.1 Konstrukce přirozeného kubického spline

Značení:

$$\begin{aligned} f_i &:= f(x_i) & \forall i = 0, \dots, n, \\ \varphi_i &:= \varphi|_{[x_i, x_{i+1}]} & \forall i = 0, \dots, n-1, \\ h_i &:= x_{i+1} - x_i & \forall i = 0, \dots, n-1. \end{aligned}$$

Kubický polynom  $\varphi_i$  je na intervalu  $[x_i, x_{i+1}]$  určen čtyřmi koeficienty. Počet intervalů je  $n$ , celkem máme tedy pro určení  $\varphi$  počet stupňů volnosti  $4n$ . Pro tyto stupně volnosti sestavíme příslušné rovnice.

Počet neznámých	4 × počet intervalů	4n
Počet rovnic	$\varphi(x_i) = f(x_i), i = 0, \dots, n$	$n+1$
	spojitost $\varphi$ v $x_i, i = 1, \dots, n-1$	$n-1$
	spojitost $\varphi'$ v $x_i, i = 1, \dots, n-1$	$n-1$
	spojitost $\varphi''$ v $x_i, i = 1, \dots, n-1$	$\frac{n-1}{4n-2}$

Počet rovnic je o dvě menší než počet neznámých. Doplníme je proto některou z podmínek (1.2.1), (a)–(b). Uvažujme např. podmínu (1.2.1), (a), tj. podmínu nulových druhých derivací v krajních bodech. Takový spline nazýváme *přirozený kubický splinem*. Pro určení přirozeného kubického splinu hledáme  $\varphi_i$  ve vhodném tvaru. Ukazuje se, že efektivní metoda není založena na vyjádření

$$\varphi_i(x) = a_i x^3 + b_i x^2 + c_i x + d_i \quad (\text{NEVHODNÉ viz cvičení})$$

ani na vyjádření

$$\varphi_i(x) = a_i(x-x_i)^3 + b_i(x-x_i)^2 + c_i(x-x_i) + d_i \quad (\text{MÉNĚ VHODNÉ viz cvičení})$$

ale na vyjádření pomocí tzv. *momentů*, což jsou hodnoty druhé derivace  $\varphi$  v uzlech. Označme je  $M_i$ :

$$M_i := \varphi''(x_i), \quad i = 0, \dots, n$$

a předpokládejme, že tyto momenty známe. Později ukážeme, jak je určit. Platí

- $\varphi_i$  – kubický polynom
- $\varphi'_i$  – parabola
- $\varphi''_i$  – přímka

Z předpokladu spojitosti druhé derivace  $\varphi$  v uzlech dostáváme

$$\begin{aligned} M_i &= \varphi''_i(x_i), \\ M_{i+1} &= \varphi''_i(x_{i+1}). \end{aligned}$$

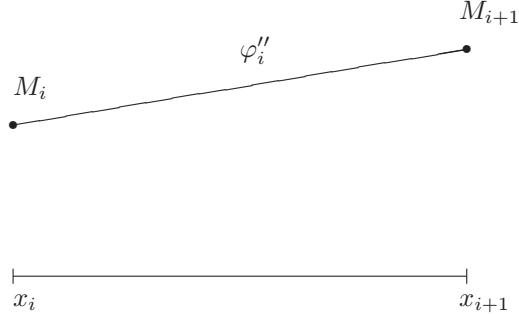
Je tedy  $\varphi''_i$  přímka, procházející body  $(x_i, M_i)$  a  $(x_{i+1}, M_{i+1})$  (viz obr. 1.2.1).

$$\begin{aligned} \varphi''_i(x) &= \frac{(x - x_i) \cdot M_{i+1}}{x_{i+1} - x_i} + \frac{M_i \cdot (x - x_{i+1})}{x_i - x_{i+1}}, \\ \varphi''_i(x) &= -\frac{M_i}{h_i} \cdot (x - x_{i+1}) + \frac{M_{i+1}}{h_i} \cdot (x - x_i). \end{aligned}$$

Integrací odvodíme

$$\begin{aligned} \varphi'_i(x) &= -\frac{M_i}{2h_i} \cdot (x - x_{i+1})^2 + \frac{M_{i+1}}{2h_i} \cdot (x - x_i)^2 + A_i, \\ \varphi_i(x) &= -\frac{M_i}{6h_i} \cdot (x - x_{i+1})^3 + \frac{M_{i+1}}{6h_i} \cdot (x - x_i)^3 + A_i(x - x_i) + B_i. \end{aligned} \quad (1.2.2)$$

vhodný rozpis integrační konstanty ↑

OBR. 1.2.1. Přímka  $\varphi''_i$ 

Ve vyjádření  $\varphi_i$  ve tvaru (1.2.2) nejprve určíme koeficienty  $A_i, B_i, i = 0, \dots, n - 1$  pomocí momentů a potom sestavíme rovnice pro momenty. Využijeme k tomu podmínky

$$\begin{aligned}\varphi_i(x_i) &= f_i, \\ \varphi_i(x_{i+1}) &= f_{i+1}, \quad i = 0, \dots, n - 1.\end{aligned}$$

(Dvě rovnice pro dvě neznámé  $A_i, B_i, i = 0, \dots, n - 1$ .) Dostaneme

$$\begin{aligned}\varphi_i(x_i) &= \frac{M_i}{6} \cdot h_i^2 + B_i = f_i, \\ \rightarrow \quad \textcolor{red}{B_i} &= f_i - \frac{\textcolor{red}{M_i}}{6} \cdot h_i^2, \\ \varphi_i(x_{i+1}) &= \frac{M_{i+1}}{6} \cdot h_i^2 + A_i h_i + f_i - \frac{M_i}{6} \cdot h_i^2 = f_{i+1}, \\ \rightarrow \quad \textcolor{red}{A_i} &= \frac{f_{i+1} - f_i}{h_i} + \frac{\textcolor{red}{M_i} - \textcolor{red}{M_{i+1}}}{6} \cdot h_i.\end{aligned}$$

Rovnice pro momenty sestavíme ekvivalentním vyjádřením podmínky spojitosti derivace kubického spline v uzlech:

$$\varphi'_{i-1}(x_i) = \varphi'_i(x_i), \quad i = 1, \dots, n.$$

Připomeňme si tvar  $\varphi'_i$

$$\varphi'_i(x) = -\frac{M_i}{2h_i} \cdot (x - x_{i+1})^2 + \frac{M_{i+1}}{2h_i} \cdot (x - x_i)^2 + A_i$$

resp.  $\varphi'_{i-1}$

$$\varphi'_{i-1}(x) = -\frac{M_{i-1}}{2h_{i-1}} \cdot (x - x_i)^2 + \frac{M_i}{2h_{i-1}} \cdot (x - x_{i-1})^2 + A_{i-1}.$$

S využitím vyjádření pro  $A_i$ , resp.  $A_{i-1}$  pomocí momentů dostaneme

$$\begin{aligned}\varphi'_{i-1}(x_i) &= 0 + \frac{M_i}{2h_{i-1}} \cdot h_{i-1}^2 + \frac{f_i - f_{i-1}}{h_{i-1}} + \frac{M_{i-1} - M_i}{6} \cdot h_{i-1} \\ &= -\frac{M_i}{2h_i} \cdot h_i^2 + 0 + \frac{f_{i+1} - f_i}{h_i} + \frac{M_i - M_{i+1}}{6} \cdot h_i = \varphi'_i(x_i).\end{aligned}$$

Protože konstruujeme přirozený kubický spline, je  $M_0 = \varphi''(x_0) = 0 = \varphi''(x_n) = M_n$  a dostáváme tak  $n-1$  rovnic ( $i = 1, \dots, n-1$ ) pro neznámé momenty  $M_1, M_2, \dots, M_{n-1}$ . Tyto rovnice lze přepsat ve tvaru

$$\underbrace{\frac{h_{i-1}}{6} M_{i-1} + \left( \underbrace{\frac{h_{i-1}}{2} - \frac{h_{i-1}}{6} + \frac{h_i}{2} - \frac{h_i}{6}}_{\frac{h_{i-1}+h_i}{3}} \right) \cdot M_i + \frac{h_i}{6} M_{i+1}}_{g_i} = -\underbrace{\frac{f_i - f_{i-1}}{h_{i-1}} + \frac{f_{i+1} - f_i}{h_i}}_{g_i}.$$

Maticový zápis vede na soustavu s třídiagonální maticí.

$$\begin{pmatrix} \frac{h_0+h_1}{3} & \frac{h_1}{6} & & & & \\ \ddots & \ddots & \ddots & & & \\ & \ddots & \ddots & \ddots & & \\ & & \frac{h_{i-1}}{6} & \frac{h_{i-1}+h_i}{3} & \frac{h_i}{6} & \\ & & & \ddots & \ddots & \ddots \\ & & & & \ddots & \ddots \\ & & & & & \frac{h_{n-2}}{6} & \frac{h_{n-2}+h_{n-1}}{3} \end{pmatrix} \begin{pmatrix} M_1 \\ \vdots \\ M_{i-1} \\ M_i \\ M_{i+1} \\ \vdots \\ M_{n-1} \end{pmatrix} = \begin{pmatrix} g_1 \\ \vdots \\ g_{i-1} \\ g_i \\ g_{i+1} \\ \vdots \\ g_{n-1} \end{pmatrix}$$

**Zkušební otázka 1.2!** Konstrukce přirozeného kubického spline.

**Příklad 1.14** Pro ekvidistantní dělení s krokem  $h$  má matice soustavy tvar

$$\frac{h}{6} \begin{pmatrix} 4 & 1 & & & & \\ \ddots & \ddots & \ddots & & & \\ & 1 & 4 & 1 & & \\ & & \ddots & \ddots & \ddots & \\ & & & 1 & 4 & \end{pmatrix}$$

Při vyšetřování řešitelnosti této soustavy lze využít následující definici a větu z algebry:

**Definice 1.15** Řekněme, že matice  $\mathbb{A}$  typu  $n \times n, n \geq 2$  je ostře diagonálně dominantní (ODD), jestliže

$$|a_{ii}| > \sum_{j=1, j \neq i}^n |a_{ij}| \quad \forall i = 1, \dots, n.$$

**Věta 1.16** Nechť  $\mathbb{A} \in \mathbb{R}^{n \times n}$  je ODD. Pak  $\mathbb{A}$  je nesingulární.

**Důkaz** pomocí Geršgorinových kruhů, viz (Quarteroni et al., 2004, str. 184).

$\mathbb{A}$  je nesingulární  $\Leftrightarrow \det \mathbb{A} \neq 0 \Leftrightarrow$  rovnice  $\det(\mathbb{A} - \lambda \mathbb{I}) = 0$  nemá kořen  $\lambda = 0 \Leftrightarrow$  nula není vlastním číslem matice  $\mathbb{A}$ . Nechť  $\lambda$  je vlastní číslo matice  $\mathbb{A}$

$$\begin{aligned}\mathbb{A}x &= \lambda x & y := \frac{x}{\|x\|}, \|x\| := \max_i |x_i| \\ \mathbb{A}y &= \lambda y & |y_i| \leq 1, \exists i_0 :: |y_{i_0}| = 1 \\ &\sum_{j \neq i_0} a_{i_0 j} y_j + a_{i_0 i_0} y_{i_0} = \lambda y_{i_0} \\ &\left| \sum_{j \neq i_0} a_{i_0 j} y_j \right| = |\lambda - a_{i_0 i_0}| |y_{i_0}| \\ &|\lambda - a_{i_0 i_0}| \leq \sum_{j \neq i_0} |a_{i_0 j}| \\ &(\text{Geršgorinův kruh o středu } a_{i_0 i_0} \text{ a poloměru } \sum_{j \neq i_0} |a_{i_0 j}|)\end{aligned}$$

Kdyby  $\lambda = 0$  bylo vlastním číslem

$$|a_{i_0 i_0}| \leq \sum_{j \neq i_0} |a_{i_0 j}| \quad \text{Spor s ODD}$$

$\lambda = 0$  tedy není vlastní číslo a matice  $\mathbb{A}$  je nesingulární.  $\square$

Matice soustavy rovnic pro momenty je ODD, soustava je tedy podle výše uvedené věty jednoznačně řešitelná a protože matice soustavy je třídiagonální, lze pro řešení použít např. Gaußovu eliminaci.

# 2

## NUMERICKÁ INTEGRACE FUNKCÍ

### 3. přednáška

Nechť je dáno dělení intervalu  $[a, b]$ ,  $a \leq x_0 < x_1 < \dots < x_n \leq b$  ( $x_i$  navzájem různé). Označme  $h = \max_{i \in \{0, \dots, n-1\}} |x_{i+1} - x_i|$ .

$$\text{Cíl: } I(f) = \int_a^b f(x) dx \approx I_h(f) = \sum_{i=0}^n \alpha_i f(x_i). \quad (2.0.1)$$

Vzorec

$$I_h(f) = \sum_{i=0}^n \alpha_i f(x_i)$$

se nazývá *kvadraturní formule*,  $\alpha_i$  jsou *koeficienty kvadraturní formule* a  $x_i$  jsou *uzly kvadraturní formule*. Motivace hledání approximace určitého integrálu ve tvaru lineární kominace hodnot funkce  $f$  v uzlech  $x_i$  je zřejmá z následujícího odstavce.

### 2.1 Newtonovy-Cotesovy vzorce

Pro dané  $n \in \mathbb{N}$  uvažujme ekvidistantní dělení intervalu  $[a, b]$  s krokem  $h = \frac{b-a}{n}$ ,  $x_i = a + ih$ ,  $i = 0, \dots, n$ . Aproximujeme-li funkci  $f$  Lagrangeovým interpolacním polynomem  $L_n$  pro uzly  $x_0, \dots, x_n$ , lze určitý integrál z funkce  $f$  approximovat následujícím způsobem:

$$\begin{aligned} \int_a^b f(x) dx &\approx \int_a^b L_n(x) dx = \\ \int_a^b \sum_{i=0}^n f(x_i) \overbrace{\frac{(x-x_0)\dots(x-x_{i-1})(x-x_{i+1})\dots(x-x_n)}{(x_i-x_0)\dots(x_i-x_{i-1})(x_i-x_{i+1})\dots(x_i-x_n)}}^{\ell_i(x)} dx &= \\ \sum_{i=0}^n \underbrace{\int_a^b \ell_i(x) dx}_{\alpha_i} f(x_i) \end{aligned} \quad (2.1.1)$$

Tento vzorec nazýváme pro ekvidistantní uzly Newtonův-Cotesův. Pro výpočet koeficientů  $\alpha_i$  použijeme následující substituci

$$\begin{aligned}
&\text{subst. } x = a + th \\
&x_i = a + ih, \quad h = \frac{b-a}{n} \\
\alpha_i := \int_a^b \prod_{j=0, j \neq i}^n \frac{(x - x_j)}{(x_i - x_j)} dx &= \frac{b-a}{n} \int_0^n \prod_{j=0, j \neq i}^n \frac{(t - j)}{(i - j)} dt \quad (2.1.2)
\end{aligned}$$

Z konstrukce Lagrangeovy interpolace  $L_n$  funkce  $f \in \Pi_n$  plyne, že  $L_n(x) = f(x)$ , a tedy N-C vzorec je přesný pro polynomy stupně nejvýše  $n$ . To nás vede k následující definici.

**Definice 2.1** Řekneme, že kvadraturní formule  $\sum_{i=0}^n \alpha_i f(x_i)$  má řád přesnosti  $m$ , jestliže  $m \in \mathbb{N} \cup \{0\}$  je maximální číslo takové, že

$$\int_a^b p(x) dx = \sum_{i=0}^n \alpha_i p(x_i) \quad \forall p \in \Pi_m. \quad (2.1.3)$$

**Zkušební otázka 2.1** Řád kvadraturní formule.

**Lemma 2.2** Je-li kvadraturní formule  $\sum_{i=0}^n \alpha_i f(x_i)$  symetrická, t.j. pro  $i = 0, \dots, n$  platí

$$\begin{aligned}
b - x_{n-i} &= x_i - a, \\
\alpha_i &= \alpha_{n-i},
\end{aligned}$$

a je-li její řád  $\geq n$ ,  $n$  sudé, pak je její řád  $\geq n+1$ .

**Lemma 2.3** Newtonův-Cotesův vzorec je symetrická kvadraturní formule.

**Důsledek 2.4** Pro  $n$  sudé je řád N-C vzorce  $\geq n+1$ .

**Zkušební otázka 2.2** Odvodte Newtonův-Cotesův vzorec.

**Lemma 2.5** (Odhad chyby lichoběžníkového pravidla)

Nechť  $f \in C^2[a, b]$ . Označme  $T_h(f)$  N-C vzorec pro  $n = 1$  (lichoběžníkové pravidlo). Pak  $\exists \xi \in [a, b], :: (při značení I(f) = \int_a^b f(x) dx)$

$$I(f) - T_h(f) = -\frac{f''(\xi)}{2} \cdot \frac{h^3}{6}, \quad h = (b-a). \quad (2.1.4)$$

**Lemma 2.6** (Odhad chyby Simpsonova pravidla)

Nechť  $f \in C^3[a, b]$ . Označme  $S_h(f)$  N-C vzorec pro  $n = 2$  (Simpsonovo pravidlo). Pak  $\exists \xi \in [a, b], ::$

$$I(f) - S_h(f) = -\frac{h^5}{90} \cdot f'''(\xi), \quad h = \frac{(b-a)}{2}. \quad (2.1.5)$$

**Definice 2.7** (zbytek kvadraturního vzorce) *Rozdíl*

$$E_h(f) = I(f) - I_h(f),$$

kde

$$I(f) = \int_a^b f(x) dx, \quad I_h(f) = \sum_{i=0}^n \alpha_i f(x_i),$$

nazýváme zbytek kvadraturního vzorce.

### 2.1.1 Složené Newtonovy–Cotesovy vzorce

Newtonovy–Cotesovy vzorce lze také aplikovat tak, že interval  $[a, b]$  rozdělíme na  $m$  ekvidistantních subintervalů  $[x_i, x_{i+1}]$  velikosti  $H$  a na každém z těchto subintervalů použijeme Newtonův–Cotesův vzorec pro  $n$  ekvidistantních uzlů  $x_i = x_{i_0} < \dots < x_{i_n} = x_{i+1}$  s krokem  $h$

$$x_i = a + iH, \quad H = \frac{b-a}{m}, \quad i = 0, \dots, m, \quad x_{i_j} = x_i + jh, \quad h = \frac{H}{n} \quad m, n \in \mathbb{N}$$

$$I(f) := \sum_{i=0}^{m-1} \int_{x_i}^{x_{i+1}} f(x) dx \approx \sum_{i=0}^{m-1} I_h^i(f) = \sum_{i=0}^{m-1} \sum_{j=0}^n \alpha_{i,j} f(x_{i,j}) =: I_h(f)$$

**Věta 2.8** (složené N-C vzorce) Nechť  $f \in C^{n+1}[a, b]$ . Pak pro složené N-C vzorce platí

$$|I(f) - I_h(f)| \leq ch^{n+1}, \quad (2.1.6)$$

kde  $c > 0$  je konstanta nezávislá na  $h$ .

**Důkaz** plyne z odhadu chyby Lagrangeova interpolačního polynomu □

## 2.2 Rombergova kvadratura

Výpočet  $\int_a^b f(x) dx$  pomocí složeného lichoběžníkového pravidla pro  $n+1$  uzlů.

$$\begin{aligned} m &= n, \\ H &= \frac{b-a}{m}, \\ h &= H. \end{aligned}$$

**Věta 2.9** (Eulerova-MacLaurinova) Nechť  $f \in C^{2N+2}[a, b]$ ,  $h = \frac{b-a}{n}$ ,  $n \in \mathbb{N}$ . Potom pro složené lichoběžníkové pravidlo (označme ho  $CT_h(f)$ ) platí:

$$CT_h(f) = p(h^2) + O(h^{2N+2}) \quad (2.2.1)$$

$$= I(f) + a_1 h^2 + a_2 h^4 + \dots + a_N h^{2N} + O(h^{2N+2}), \quad (2.2.2)$$

kde  $p \in \Pi_N$ ,  $p = p(t) = a_0 + a_1 t + \dots + a_N t$ ,

$$a_0 = p(0) = \int_a^b f(x) dx = I(f).$$

**Důkaz** viz Stör Numerische Mathematik I □

Rombergova kvadratura: konstruujeme lineární kombinaci vzorců  $CT_h(f)$  pro vhodné  $h$  tak, abychom získali vzorec, který je přesnější:

$$\begin{aligned} CT_h(f) &= I(f) + a_1 h^2 + O(h^4) \quad / - 1 \\ CT_{\frac{h}{2}}(f) &= I(f) + a_1 \frac{h^2}{4} + O(h^4) \quad / 4 \\ \frac{4CT_{\frac{h}{2}}(f) - CT_h(f)}{3} &= I(f) + O(h^4) \\ \text{lin. k.} &= I(f) + \text{chyba} \quad (N = 1) \end{aligned}$$

Vhodnou lineární kombinací vzorců, z nichž každý approximuje integrál  $I(f)$  s chybou  $O(h^2)$ , jsme tak odvodili vzorec, který approximuje integrál  $I(f)$  s chybou  $O(h^4)$ . Za předpokladu dostatečné hladkosti funkce  $f$  (viz Eulerova–MacLaurinova věta) můžeme tímto způsobem odvordin vzorec, který approximuje integrál  $I(f)$  s chybou  $O(h^{2N+2})$ . Všimněme si např., jakou roli hraje v tomto postupu vyčíslení Lagrangeova interpolačního polynomu  $L_2$  pro uzly  $\frac{h^2}{16}, \frac{h^2}{4}, h^2$  a hodnoty  $CT_{\frac{h}{4}}, CT_{\frac{h}{2}}, CT_h$  zapsaného ve tvaru  $L_2(0) + b_1 t + b_2 t^2$  (předpokládáme  $h \ll 1$ ).

$Euler\text{--}MacLaurin \downarrow$	$Lagrange \downarrow$	
$CT_h(f) = I(f) + a_1 h^2 + a_2 h^4 + O(h^6) = L_2(0) + b_1 h^2 + b_2 h^4$		(2.2.3)
$CT_{\frac{h}{2}}(f) = I(f) + a_1 \frac{h^2}{4} + a_2 \frac{h^4}{16} + O(h^6) = L_2(0) + b_1 \frac{h^2}{4} + b_2 \frac{h^4}{16}$		(2.2.4)
$CT_{\frac{h}{4}}(f) = I(f) + a_1 \frac{h^2}{16} + a_2 \frac{h^4}{256} + O(h^6) = L_2(0) + b_1 \frac{h^2}{16} + b_2 \frac{h^4}{256}$		(2.2.5)
<hr/> lin. k. $\uparrow =$	$I(f) + 0 + 0 + O(h^6)$	$= L_2(0) + 0 + 0 \quad (N = 2)$

kde  $L_2(t) = \underbrace{b_0}_{L_2(0)} + b_1 t + b_2 t^2$  je Lagrangeův interpolační polynom pro tabulkou

$$\begin{array}{c|c|c|c} 0 & \frac{h^2}{16} & \frac{h^2}{4} & h^2 \\ \hline \text{lin. k.} & CT_{\frac{h}{4}}(f) & CT_{\frac{h}{2}}(f) & CT_h(f) \end{array}$$

Závěr:  $L_2(0)$  approximuje  $\int_a^b f(x) dx$  s chybou  $O(h^6)$ . Při konstrukci  $L_2(0)$  se jedná o tzv. Richardsonovu extrapolaci. Uvedený postup lze provést až do řádu  $2N+2$  pro uzly  $(\frac{h}{2^i})^2$  a hodnoty  $CT_{\frac{h}{2^i}}$ ,  $i = 0, \dots, N$ , pomocí nichž konstruujeme  $L_N$ .

Problém: Vyčíslení Lagrangeova interpolačního polynomu v jediném bodě (zde konkrétně v 0) aniž bychom Lagrangeův interpolační polynom sestavovali. Zde nepotřebujeme tvar Lagrangeova interpolačního polynomu, ale pouze jeho hodnotu v jediném bodě. K tomu se používá Aitkenovo–Nevilleovo schéma.

**Zkušební otázka 2.3!** Odvodte Rombergův kvadraturní vzorec, který approximuje hodnotu  $\int_a^b f(x) dx$  s chybou  $O(h^4)$ . Vysvětlete význam Lagrangeova interpolačního polynomu při konstrukci Rombergova kvadraturního vzorce.

### 2.3 Gaußova kvadratura

4. přednáška

Víme, že N-C vzorce mají řád aspoň  $n$  (pro  $n$  sudé dokonce aspoň  $n + 1$ ). Jakého řádu může být formule typu  $\sum_{i=0}^n \alpha_i f(x_i)$ ? Uvažujme pro dané dělení intervalu  $[a, b]$ ,  $a \leq x_0 < \dots < x_n \leq b$  kvadraturní formuli

$$I_h(f) = \sum_{i=0}^n \alpha_i f(x_i). \quad (2.3.1)$$

**Lemma 2.10** (*Řád kvadraturní formule*) *Řád kvadraturní formule (2.3.1) je nejvíce  $2n + 1$ .*

**Důkaz** Uvažujme polynom  $\tilde{p}(x) = \prod_{i=0}^n (x - x_i)^2 \in \Pi_{2n+2}$ . Tento polynom je nezáporná funkce na intervalu  $[a, b]$  a platí pro něho

$$\int_a^b \tilde{p}(x) dx > 0.$$

Kvadraturní formule typu (2.3.1) dává pro tento polynom

$$\sum_{i=0}^n \alpha_i \tilde{p}(x_i) = 0.$$

Pro polynom  $\tilde{p}$  není tedy kvadraturní formule (2.3.1) přesná a její řád je tedy nejvíce  $2n + 1$ .  $\square$

Gaußova kvadratura je způsob konstrukce vzorce  $\sum_{i=0}^n \alpha_i f(x_i)$ , který je přesný pro všechny polynomy stupně nejvíce  $2n + 1$ .

**Definice 2.11** (*skalární součin polynomů*) *Skalární součin v  $C[a, b]$  je definován*

$$(u, v) = \int_a^b u(x)v(x) dx. \quad (2.3.2)$$

**Definice 2.12** *Množina normovaných polynomů*

$$\tilde{\Pi}_n = \{p \in \Pi_n; \quad p(x) = x^n + a_{n-1}x^{n-1} + \dots + a_0\}. \quad (2.3.3)$$

Myšlenka konstrukce Gaußovy kvadratury:

$x_i$  (uzly): kořeny polynomu  $p_{n+1}$  z množiny ortogonálních polynomů  $\{p_0, p_1, \dots, p_{n+1}\}$ ,

$\alpha_i$  (koeficienty): určíme tak, aby  $\int_a^b q(x) dx = \sum_{i=0}^n \alpha_i q(x_i) \quad \forall q \in \Pi_{2n+1}$ .

**Věta 2.13** (*Ortogonalní polynomy*) Existují jednoznačně určené polynomy  $p_i$ , pro které platí

1.  $p_i \in \tilde{\Pi}_i, \quad i \in \mathbb{N} \cup \{0\},$

$$(p_i, p_j) = 0, \quad i \neq j, \quad (\text{pozn. } p_0(x) = 1)$$

2. Kořeny  $x_0, \dots, x_n$  polynomu  $p_{n+1}$ ,  $n \in \mathbb{N} \cup \{0\}$ , jsou reálné, jednoduché a leží v  $(a, b)$

3.

$$A = \begin{pmatrix} p_0(x_0) & p_0(x_1) & \cdots & p_0(x_n) \\ p_1(x_0) & p_1(x_1) & \cdots & p_1(x_n) \\ & & \ddots & \\ p_n(x_0) & p_n(x_1) & \cdots & p_n(x_n) \end{pmatrix} \quad \text{je nesingulární.}$$

**Důkaz** viz cvičení k přednášce. □

S využitím ortogonálních polynomů  $p_0, \dots, p_{n+1}$  a kořenů  $x_i$  polynomu  $p_{n+1}$  určíme koeficienty  $\alpha_i$  Gaušovy kvadraturní formule tak, aby platilo:

$$\int_a^b q(x) dx = \sum_{i=0}^n \alpha_i q(x_i), \quad \forall q \in \Pi_{2n+1}. \quad (2.3.4)$$

K tomu vyjádříme polynom  $q$  ve tvaru

$$q(x) = r(x)p_{n+1}(x) + s(x), \quad r, s \in \Pi_n,$$

(dělení polynomu  $q$  polynomem  $p_{n+1}$ ) a polynomy  $r(x), s(x) \in \Pi_n$  vyjádříme jako lineární kombinaci ortogonálních polynomů (existence takového vyjádření viz cvičení k přednášce), speciálně nechť

$$s(x) = \sum_{j=0}^n \gamma_j p_j(x).$$

Na základě tohoto vyjádření má výraz na levé straně v (2.3.4) tvar

$$\begin{aligned} \int_a^b q(x) dx &= \underbrace{\int_a^b r(x)p_{n+1}(x) dx}_{=0} + \int_a^b s(x) dx \\ &= \int_a^b \sum_{j=0}^n \gamma_j p_j(x) dx = \int_a^b \sum_{j=0}^n \gamma_j \overbrace{p_0(x)}^{-1} p_j(x) dx \end{aligned}$$

$$= \sum_{j=0}^n \gamma_j \int_a^b p_0(x) p_j(x) dx = \gamma_0 \int_a^b p_0(x) p_0(x) dx = \gamma_0 \int_a^b dx.$$

Levá strana v (2.3.4) je tedy rovna

$$\gamma_0(b-a).$$

Pravá strana v (2.3.4) má na základě výše uvedených vyjádření tvar

$$\sum_{i=0}^n \alpha_i [\underbrace{r(x_i)p_{n+1}(x_i)}_{=0} + s(x_i)] = \sum_{i=0}^n \alpha_i \sum_{j=0}^n \gamma_j p_j(x_i).$$

Vidíme, že levou a pravou stranu v (2.3.4) lze tedy vyjádřit jako lineární kombinací jistých výrazů s koeficienty  $\gamma_j$

$$\begin{aligned} & \gamma_0(b-a) + \gamma_1 \cdot 0 + \cdots + \gamma_n \cdot 0 \\ &= \gamma_0 \sum_{i=0}^n p_0(x_i) \alpha_i + \gamma_1 \sum_{i=0}^n p_1(x_i) \alpha_i + \cdots + \gamma_n \sum_{i=0}^n p_n(x_i) \alpha_i \end{aligned}$$

Porovnáním výrazů u koeficientů  $\gamma_j$  na levé a pravé straně dostaneme rovnice pro určení hledaných koeficientů  $\alpha_i$ :

$$\left. \begin{array}{lcl} \sum_{i=0}^n p_0(x_i) \alpha_i & = & (b-a) \\ \sum_{i=0}^n p_1(x_i) \alpha_i & = & 0 \\ \vdots & & \vdots \\ \sum_{i=0}^n p_n(x_i) \alpha_i & = & 0 \end{array} \right\} \Leftrightarrow \begin{pmatrix} p_0(x_0) & \cdots & p_0(x_n) \\ p_1(x_0) & \cdots & p_1(x_n) \\ \vdots & \ddots & \vdots \\ p_n(x_0) & \cdots & p_n(x_n) \end{pmatrix} \begin{pmatrix} \alpha_0 \\ \alpha_1 \\ \vdots \\ \alpha_n \end{pmatrix} = \begin{pmatrix} b-a \\ 0 \\ \vdots \\ 0 \end{pmatrix}$$

Z hlediska stability je výhodné, že koeficienty  $\alpha_i$  Gaußova kvadraturního vzorce  $\sum_{i=0}^n \alpha_i f(x_i)$  jsou kladné.

**Věta 2.14 (pozitivita  $\alpha_i$ )** Koeficienty  $\alpha_i$  Gaußova kvadraturního vzorce jsou kladné.

**Důkaz** Položme:

$$\begin{aligned} \tilde{p}_k(x) &= \prod_{i=0, i \neq k}^n (x - x_i)^2 \in \Pi_{2n} \\ 0 &< \int_a^b \tilde{p}_k(x) dx = \sum_{i=0}^n \alpha_i \tilde{p}_k(x_i) = \alpha_k \underbrace{\tilde{p}_k(x_k)}_{>0} \\ &\Rightarrow \alpha_k \text{ kladné } \forall k = 0, 1, \dots, n. \end{aligned}$$

□

**Zkušební otázka 2.4!** Odvodte Gaußův kvadraturní vzorec řádu  $2n+1$  na intervalu  $[a, b]$ . Odvodte Gaußův kvadraturní vzorec řádu 3 na intervalu  $[-1, 1]$  (uvažujte ortogonální polynomy  $\{1, x, x^2 - \frac{1}{3}\}$ ).

# 3

## METODY ŘEŠENÍ NELINEÁRNÍCH ROVNIC

### 5. přednáška

Nechť je dáno nelineární zobrazení

$$F : \mathbb{R}^N \rightarrow \mathbb{R}^N.$$

$$\text{Hledáme } \alpha :: F(\alpha) = 0.$$

Metody pro řešení výše uvedené úlohy jsou většinou iterační. Cíl je generovat posloupnost  $\{x^{(k)}\}$  takovou, že  $\lim x^{(k)} = \alpha$ , kde  $F(\alpha) = 0$ .

### 3.1 Newtonova metoda

Problém  $F(x) = 0$  nahradíme posloupností lineárních problémů  $L_k(x) = 0$ ,  $L_k : \mathbb{R}^N \rightarrow \mathbb{R}^N$ ,  $k = 0, 1, \dots$ , takových, že jejich řešení tvoří posloupnost konvergující k řešení problému  $F(x) = 0$ .

$$\alpha \approx x^{k+1}, \text{ kde } L_k(x^{k+1}) = 0.$$

Nechť  $x^{(0)}$  je dáno (později ukážeme, jak ho volit). Pro danou aprixamaci  $x^{(k)}$  uvažujeme  $L_k(x)$  jako lineární část Taylorova rozvoje zobrazení  $F$  v bodě  $x^{(k)} \in \mathbb{R}^N$  ( $J(x)$  značí Jakobiho matici zobrazení  $F$  v bodě  $x$ ):

$$F(x) = \underbrace{F(x^{(k)}) + J(x^{(k)})(x - x^{(k)})}_{L_k(x)} + O(|x - x^{(k)}|^2).$$

(za předpokladu dostatečné hladkosti zobrazení  $F$ ). Nelineární problém nahradíme problémem lineárním

$$\{F(x) = 0\} \approx \underbrace{\{F(x^{(k)}) + J(x^{(k)})(x - x^{(k)}) = 0\}}_{L_k(x)} \quad (3.1.1)$$

$$\text{řešení } \alpha \text{ nelin. pb. approximujeme řešením } x^{(k+1)} \text{ lin. pb.} \quad (3.1.2)$$

$$\alpha \approx x^{(k+1)} := x^{(k)} - J^{-1}(x^{(k)})F(x^{(k)}) \quad (3.1.3)$$

Vzorec v (3.1.3), kterým je definována  $(k+1)$ -ní approximace  $x^{(k+1)}$  řešení nelineárního problému je formální, ve skutečnosti se inverzní matice nepočítá a algoritmus má následující dva kroky:

Algoritmus:

1.  $J(x^{(k)}) \underbrace{(x - x^k)}_{\delta x^{(k)}} = -F(x^{(k)})$  - řešíme lineární úlohu pro  $\delta x^{(k)}$

2.  $x^{(k+1)} := x^{(k)} + \delta x^{(k)}$  - provedeme update předchozí aproximace.

Pro  $N = 1$  (nelineární skalární rovnice pro jednu neznámou) má Newtonova metoda názorný geometrický význam. Nelineární funkci  $f(x)$  nahradíme lineární funkci (přímkou), která je tečnou ke grafu funkce  $f$  v bodě  $(x^{(k)}, f(x^{(k)}))$  (má tedy směrnici  $f'(x^{(k)})$ ) a prochází bodem  $(x^{(k)}, f(x^{(k)}))$ . V tomto případě se Newtonova metoda nazývá metodou tečen.

$N = 1 :$

$$x^{(k+1)} = x^{(k)} - \frac{f(x^{(k)})}{f'(x^{(k)})}, \quad x^{(0)} \text{ dáno, } f'(x^{(k)}) \neq 0.$$

**Zkušební otázka 3.1!** Odvoďte Newtonovu metodu pro soustavy nelineárních rovnic a její algoritmizaci. Popište algoritmus v případě jedné skalární rovnice.

Způsob, jak nahradit funkci  $f$  přímkou procházející bodem  $(x^{(k)}, f(x^{(k)}))$  není jediný. Další možnosti jsou metoda sečen, jednobodová metoda sečen nebo metoda regula falsi (viz cvičení k přednášce).

**Poznámka 3.1** Newtonova metoda je speciálním případem náhrady funkce  $f$  lineární funkcí

$$l_k(x) := f(x^{(k)}) + (x - x^{(k)})q_k,$$

kde směrnice  $q_k$  se volí

$$q_k := f'(x^{(k)}).$$

### 3.1.1 Důkaz konvergence Newtonovy metody

**Věta 3.2** (Konvergence Newtonovy metody pro soustavy) Nechť  $F \in C(D)$ ,  $D \subset \mathbb{R}^N$  konvexní, otevřená množina, která obsahuje  $\alpha :: F(\alpha) = 0$ . Nechť  $\exists J^{-1}(\alpha)$ , nechť  $\exists R > 0, c > 0, L > 0$  :

$$\begin{aligned} \|J^{-1}(\alpha)\| &\leq c, \\ \underbrace{\|J(x) - J(y)\|}_{\text{maticová norma}} &\leq L \underbrace{\|x - y\|}_{\text{vekt. norma}} \quad \forall x, y \in B(\alpha, R), \end{aligned}$$

kde  $B(\alpha, R)$  je koule o středu  $\alpha$  a poloměru  $R$ . Potom  $\exists r, \forall x^{(0)} \in B(\alpha, r)$ , posloupnost 3.1.3 je jednoznačně definována a konverguje k  $\alpha$  a platí

$$\|\alpha - x^{(k+1)}\| \leq cL \|\alpha - x^{(k)}\|^2 \tag{3.1.4}$$

Motivace:  $N = 1$

$$x^{(k+1)} = x^{(k)} - \frac{f(x^{(k)})}{f'(x^{(k)})} \quad \text{Newtonova metoda}$$

Z Taylorova rozvoje dostáváme:

$$f(\alpha) = f(x^{(k)}) + f'(x^{(k)})(\alpha - x^{(k)}) + \frac{f''(\xi)(\alpha - x^{(k)})^2}{2}.$$

Zajímá nás chyba  $(\alpha - x^{(k+1)})$ . Chceme ukázat, že  $|\alpha - x^{(k+1)}| \rightarrow 0$ . Odečtením  $\alpha$  od obou stran vzorce pro Newtonovu metodu získáme vyjádření

$$\alpha - x^{(k+1)} = \alpha - x^{(k)} + \frac{f(x^{(k)})}{f'(x^{(k)})}.$$

Úpravou Taylorova rozvoje (uvědomíme-li si, že  $f(\alpha) = 0$ ) dostaneme

$$0 = \frac{f(x^{(k)})}{f'(x^{(k)})} + (\alpha - x^{(k)}) + \frac{f''(\xi)(\alpha - x^{(k)})^2}{2 \cdot f'(x^{(k)})}.$$

Z předchozích dvou rovnic snadno nahlédneme, že platí

$$\alpha - x^{(k+1)} = -\frac{f''(\xi)(\alpha - x^{(k)})^2}{2 \cdot f'(x^{(k)})}.$$

Předpokládejme nyní, že existuje konstanta  $\tilde{c}$  taková, že podíl derivací na pravé straně předchozího výrazu lze odhadnout

$$\left| \frac{f''(\xi)}{2 \cdot f'(x^{(k)})} \right| < \tilde{c} \quad \forall \xi \forall x^{(k)}.$$

Potom dostaneme

$$\begin{aligned} |\alpha - x^{(k+1)}| &\leq \tilde{c} |\alpha - x^{(k)}|^2 \leq \tilde{c} \left( \tilde{c} |\alpha - x^{(k-1)}|^2 \right)^2 = \frac{1}{\tilde{c}} \left( \tilde{c} |\alpha - x^{(k-1)}| \right)^4 \\ &\leq \dots \leq \frac{1}{\tilde{c}} \left( \tilde{c} |\alpha - x^{(0)}| \right)^{2^{k+1}}. \end{aligned}$$

Pravá strana konverguje k nule pro  $k \rightarrow +\infty$  za předpokladu

$$\tilde{c} |\alpha - x^{(0)}| < 1, \text{ tj. jestliže je } x^{(0)} \text{ dostatečně blízko k } \alpha.$$

Pro důkaz konvergence Newtonovy metody pro jednu skalární rovnici jsme tedy využili tyto předpoklady

1.  $x^{(0)}$  dostatečně blízko  $\alpha$ ,
2.  $f''$  omezená shora
3.  $\frac{1}{f'}$  omezená shora (tj. předpokládáme  $f'(\alpha) \neq 0$ ),

které korespondují s předpoklady Věty 3.2. Jak, to je patrné z následujícího důkazu.

**Důkaz** věty 3.2.  $x^{(0)}$  zvolíme v  $B(\alpha, r)$ , kde  $r$  učíme tak, aby  $J^{-1}(x^{(0)})$  existovala. (Jinými slovy,  $x^{(0)}$  volíme dostatečně blízko  $\alpha$ .) K tomu využijeme následující tvrzení z algebry:

**Lemma 3.3**

$$\|\mathbb{A}\| < 1 \Rightarrow (\mathbb{I} - \mathbb{A})^{-1} \quad \text{existuje a platí}$$

$$\|(\mathbb{I} - \mathbb{A})^{-1}\| \leq \frac{1}{1 - \|\mathbb{A}\|}.$$

**Důkaz** viz cvičení k přednášce.  $\square$

Definujme matici

$$\mathbb{A} := \mathbb{I} - J^{-1}(\alpha)J(x^{(0)})$$

kde  $x^{(0)}$  zvolíme tak (blízko  $\alpha$ ), aby  $\|\mathbb{A}\| < 1$ , konkrétně zvolíme  $x^{(0)}$  tak, aby

$$\|\mathbb{A}\| \leq \frac{1}{2}.$$

K tomu využijeme předpoklady Věty 3.2 týkající se odhadu inverze Jacobiho matice v bodě  $\alpha$  a lipschitzovskosti Jacobiho matice:

$$\left\| \underbrace{\mathbb{I} - J^{-1}(\alpha)J(x^{(0)})}_{\mathbb{A}} \right\| = \|J^{-1}(\alpha)(J(\alpha) - J(x^{(0)}))\| \leq cL \|\alpha - x^{(0)}\|. \quad (3.1.5)$$

$x^{(0)}$  zvolíme tak, aby poslední výraz v (3.1.5)  $\leq \frac{1}{2}$ . Tím dostáváme podmínu na  $x^{(0)}$ :

$$\|\alpha - x^{(0)}\| \leq \frac{1}{cL} \text{ a zároveň } \|\alpha - x^{(0)}\| \leq R \text{ (platnost podmínky lipschitzovskosti).}$$

Pro  $r$  dostáváme

$$r := \min \left( \frac{1}{2cL}, R \right).$$

V množině  $B(\alpha, r)$  existuje podle výše uvedeného tvrzení z algebry  $J^{-1}(x^{(0)})$ . To plyne ze vztahů

$$(\mathbb{I} - \mathbb{A}) = J^{-1}(\alpha)J(x^0), \quad (\mathbb{I} - \mathbb{A})^{-1} = J^{-1}(x^{(0)})J(\alpha).$$

Lze tedy spočítat první iteraci Newtonovy metody a odhadnout její chybu:

$$\alpha - x^{(1)} = \alpha - x^{(0)} + J^{(-1)}(x^{(0)})F(x^{(0)}).$$

Úpravou Taylorova rozvoje (uvědomíme-li si, že  $F(\alpha) = 0$ ) dostaneme

$$0 = F(\alpha) = F(x^{(0)}) + J(x^{(0)})(\alpha - x^{(0)}) + \text{zbytek},$$

$$0 = J^{-1}(x^{(0)})F(x^{(0)}) + (\alpha - x^{(0)}) + J^{-1}(x^{(0)}) \text{ zbytek}.$$

S využitím odhadu zbytku Taylorova rozvoje dostaneme

$$\|\alpha - x^{(1)}\| \leq \|J^{-1}(x^{(0)})\| \overbrace{\frac{1}{2} L \|\alpha - x^{(0)}\|^2}^{\text{odhad zbytku}}$$

a důkaz dokončíme pomocí odhadu normy inverzní maticy

$$\|J^{-1}(x^{(0)})\| = \left\| \underbrace{J^{(-1)}(x^{(0)}) J(\alpha) J^{(-1)}(\alpha)}_{(\mathbb{I} - \mathbb{A})^{-1}} \right\| \leq \underbrace{\frac{1}{1 - \|\mathbb{A}\|}}_{\leq \frac{1}{2}} c \leq 2c.$$

Pro odhad chyby máme tedy vztah

$$\|\alpha - x^{(1)}\| \leq cL \|\alpha - x^{(0)}\|^2 = \underbrace{(cL \|\alpha - x^{(0)}\|)}_{\leq \frac{1}{2}} \|\alpha - x^{(0)}\|,$$

z něhož plyne dále indukcí konvergence Newtonovy metody.  $\square$

**Zkušební otázka 3.2** Dokažte větu o konvergenci Newtonovy metody.

### 6. přednáška

**Poznámka 3.4** Modifikace Newtonovy metody:

- Jacobiho matice se nemění pro  $p \geq 2$  kroků
- nepřesné řešení soustavy lin. rovnic
- vyčíslení Jacobiho matice pomocí diferencí  $f'(x) \approx \frac{f(x+h) - f(x)}{h}$

#### 3.1.2 Řád konvergence

**Definice 3.5** (řád konvergence iterační metody pro řešení  $F(x) = 0$ ) Řekneme, že posloupnost  $\{x^{(k)}\}$  generovaná numerickou metodou konverguje k  $\alpha$  s řádem  $p \geq 1$ , pokud  $\exists c > 0$

$$\frac{\|\alpha - x^{(k+1)}\|}{\|\alpha - x^{(k)}\|^p} \leq c \quad \forall k \geq k_0.$$

V takovém případě se numerická metoda nazývá řádu  $p$ .

Věta 3.2 říká, že Newtonova metoda je kvadraticky konvergentní,

$$\|\alpha - x^{(k+1)}\| \leq cL \|\alpha - x^{(k)}\|^2,$$

pokud je  $x^{(0)}$  dostatečně blízko  $\alpha$  a pokud je  $J(\alpha)$  nesingulární.

### 3.2 Metoda postupných approximací pro nelineární rovnice

Metoda postupných approximací je založena na faktu, že pro dané zobrazení  $F : M \subset \mathbb{R}^N \rightarrow \mathbb{R}^N$  je vždy možné transformovat problém  $F(x) = 0$  na ekvivalentní problém  $x - \phi(x) = 0$ , kde pomocná funkce  $\phi$  je volena tak, aby  $\phi(\alpha) = \alpha$  právě když  $F(\alpha) = 0$ . Nalezení nulových bodů zobrazení  $F$  se tak převede na nalezení pevného bodu zobrazení  $\phi$ , které se realizuje pomocí následujícího algoritmu:

Dáno  $x^{(0)}, x^{(k+1)} := \phi(x^{(k)}), \quad k \geq 0$ .

**Definice 3.6** (kontrahující zobrazení) Řekneme, že zobrazení  $G : D \subset \mathbb{R}^N \rightarrow \mathbb{R}^n$  je kontrahující na  $D_0 \subset D$ , jestliže  $\exists L < 1$  :

$$\|G(x) - G(y)\| \leq L \|x - y\| \quad \forall x, y \in D_0.$$

**Věta 3.7** (věta o pevném bodě) Nechť  $G : D \subset \mathbb{R}^N \rightarrow \mathbb{R}^N$  kontrahující na uzavřené množině  $D_0 \subset D$ ,  $G(x) \in D_0 \quad \forall x \in D_0$ . Pak  $G$  má právě jeden pevný bod. Tento bod je limitou posloupnosti  $x^{(k+1)} = \phi(x^{(k)})$ ,  $x^{(0)} \in D_0$  libovolné.

**Důkaz** jednoznačnost, existence (Cauchyovská posloupnost, spojitost  $G$ ), viz cvičení k přednášce.  $\square$

**Poznámka 3.8** Newtonova metoda jako speciální případ věty o pevném bodě. (Viz cvičení k přednášce.)

### 3.3 Kořeny polynomu

#### Nalezení

- lokalizace kořenů v  $\mathbb{C}$
- approximace kořenů

**Věta 3.9. (Descartes)** Počet kladných kořenů (včetně násobnosti) polynomu  $p_n(\alpha) = a_0 + a_1x + \dots + a_nx^n$  je roven počtu znaménkových změn v posloupnosti  $a_0, a_1, \dots, a_n$ , nebo je o sudé číslo menší.

**Věta 3.10. (Cauchy)** Kořeny polynomu leží v kruhu

$$\Gamma = \left\{ z \in \mathbb{C}; |z| \leq 1 + \eta, \eta = \max_{0 \leq k \leq n-1} \left| \frac{a_k}{a_n} \right| \right\}$$

**Poznámka 3.11**  $1 \ll \eta$ : translace a změna souřadnic

#### 3.3.1 Hornerovo schema

V dalším budeme potřebovat vyčíslení hodnoty polynomu

$$p_n(x) = a_0 + a_1x + \dots + a_nx^n$$

v daném bodě  $x$ . Vyčíslení polynomu:

1. neefektivní

$$r = 1; s = a_0;$$

```

for  $i = 1$  to  $n$  do
     $r = r \cdot x;$ 
     $s = s + a_i \cdot r;$ 
end for
 $p_n(x) = s$ , počet násobení  $2n$ .

```

2. Hornerovo schéma

```

 $s = a_n;$ 
for  $i = n - 1$  downto  $0$  do
     $s = s \cdot x + a_i;$ 
end for
 $p_n(x) = s$ , počet násobení  $n$ .

```

**Poznámka 3.12** Zapišme Hornerovo schéma pro vyčíslení  $p_n(z)$  takto:

```

 $b_n = a_n;$ 
for  $i = n - 1$  downto  $0$  do
     $b_i = b_{i+1} \cdot z + a_i;$ 
end for
 $p_n(z) = b_0.$ 

```

Ukážeme, že tento zápis je vhodný pro vyčíslení derivace  $p'_n$  (a následně použijeme Newtonovu metodu pro určení kořene  $p_n(x)$ ). Pro dělení polynomu polynomem platí

$$(a_n x^n + a_{n-1} x^{n-1} + \dots + a_0) : (x - z) = \underbrace{a_n}_{b_n} x^{n-1} + \underbrace{(a_{n-1} + a_n z)}_{b_{n-1}} x^{n-2} + \dots + b_1 + \text{zbytek}$$

$$p_n(x) = q_{n-1}(x; z)(x - z) + b_0$$

$$\text{kde } q_{n-1}(x; z) = b_n x^{n-1} + b_{n-1} x^{n-2} + \dots + b_1$$

Je-li  $z$  kořen, pak  $b_0 = 0$ .

Nyní aplikujeme Newtonovu metodu pro nalezení kořene polynomu  $p_n$ .

$$\begin{aligned} &\text{Hornerovo sch.} \\ \text{Newtonova metoda: } &x^{(k+1)} = x^{(k)} - \frac{\overbrace{p_n(x^{(k)})}^{\text{Hornerovo sch.}}}{\underbrace{p'_n(x^{(k)})}_{\text{Hornerovo sch.}}}, \quad x^{(0)} \text{ dáno} \end{aligned}$$

Vzorec, který dostaneme s využitím Hornerova schématu, se nazývá **Newtonova-Hornerova metoda**:

$$x^{(k+1)} = x^{(k)} - \frac{p_n(x^{(k)})}{q_{n-1}(x^{(k)}; x^{(k)})}$$

Výraz ve jmenovateli dostaneme z následujících vztahů

$$p'_n(x) = q'_{n-1}(x; z)(x - z) + q_{n-1}(x; z),$$

$$\begin{aligned} p'_n(z) &= q_{n-1}(z; z), \\ z &:= x^{(k)}. \end{aligned}$$

Algoritmus pro nalezení kořenů polynomu  $p_n$ :

**for**  $m = n$  **downto** 1 **do**

Najdi kořen  $r$  polynomu  $p_m$  (Newtonova metoda)

Vyčíslí koeficienty  $q_{m-1}(x; r)$  (pomocí Hornerova schematu)

$p_{m-1} := q_{m-1}$

**end for**

**Zkušební otázka 3.3** Odvoďte Newtonovu-Hornerovu metodu nalezení kořene polynomu.

**Poznámka 3.13** Začít od kořene nejmenšího v absolutní hodnotě (kvůli zao-krouhlovacím chybám).

**Poznámka 3.14** Restartovat algoritmus, t.j. použít původní polynom (je-li  $\tilde{r}_j$  approximace kořene  $r_j$ , jít zpět k  $p_n(x)$  a hledat novou approximaci s  $r_j^{(0)} = \tilde{r}_j$ ).

# 4

## SOUSTAVY LINEÁRNÍCH ROVNIC

Hledáme  $x \in \mathbb{R}^N$  takové, že

$$\mathbb{A}x = b, \quad \mathbb{A} \in \mathbb{R}^{N \times N}, \mathbb{A}\text{-nesingulární.}$$

Metody:

- **přímé** - konečný předem známý počet kroků pro nalezení řešení
- **iterační** - konstruujeme (nekonečnou) posloupnost vektorů konvergujících k řešení

### 4.1 Podmíněnost matic

Matice se nazývá **dobře podmíněná**, jestliže relativně malé změny v koeficienzech způsobí relativně malé změny v řešení. Matice se nazývá **špatně podmíněná**, jestliže relativně malé změny v koeficientech způsobí relativně velké změny v řešení.

Analýza zaokrouhlovacích chyb - chyby ve výpočtu se obvykle reprezentují chybami ve vstupních datech. Vzhledem k zaokrouhlovacím chybám poskytuje numerická metoda přibližné řešení, které splňuje perturbovaný systém. Numerická metoda poskytuje (přesné) řešení  $x + \delta x$  perturbovaného systému

$$(A + \delta A)(x + \delta x) = b + \delta b.$$

$\delta x$  lze ("zhruba") odhadnout následujícím způsobem

$$\begin{aligned} x + \delta x &= (A + \delta A)^{-1}(b + \delta b) = [A(I + A^{-1}\delta A)]^{-1}(b + \delta b) \\ &= (\underbrace{I + A^{-1}\delta A}_{\text{nahradíme}})^{-1}A^{-1}(b + \delta b) \\ &\approx \underbrace{(I - A^{-1}\delta A)}_{\text{motivace } \downarrow}(x + A^{-1}\delta b) = x + A^{-1}\delta b - A^{-1}\delta Ax - A^{-1}\delta A A^{-1}\delta b. \end{aligned}$$

$$f(x) = \frac{1}{1+x} = 1 + xf'(0) + \text{chyba} = 1 + x(-1) + \text{chyba} \quad \left( \frac{1}{1+x} \approx 1-x \right).$$

$$\begin{aligned} \delta x &\doteq A^{-1}\delta b - A^{-1}\delta Ax, \\ \|\delta x\| &\leq \|A^{-1}\| \|\delta b\| + \|A^{-1}\| \|\delta A\| \|x\|, \end{aligned}$$

$$\begin{aligned}\frac{\|\delta x\|}{\|x\|} &\leq \frac{\|A^{-1}\| \|\delta b\|}{\|x\|} + \frac{\|A^{-1}\| \|\delta A\| \|A\|}{\|A\|} \\ &\leq \frac{\|A^{-1}\| \|A\| \|x\| \|\delta b\|}{\|x\| \|b\|} + \frac{\|A^{-1}\| \|\delta A\| \|A\|}{\|A\|}\end{aligned}$$

Závěr:

$$\frac{\|\delta x\|}{\|x\|} \leq \underbrace{\|A\| \|A^{-1}\|}_{\text{číslo podmíněnosti } K(A)} \left( \frac{\|\delta b\|}{\|b\|} + \frac{\|\delta A\|}{\|A\|} \right)$$

**Poznámka 4.1** Nejčastěji používané normy v  $\mathbb{C}^N$ ,  $x \in \mathbb{C}^N$ ,  $A \in \mathbb{C}^{N \times N}$

$$\|x\|_1 = \sum_i |x_i|,$$

$$\|x\|_2 = \sqrt{\left( \sum_i |x_i|^2 \right)} \quad \text{Euklidova,}$$

$$\|x\|_p = \left( \sum_i |x_i|^p \right)^{\frac{1}{p}} \quad 1 \leq p < \infty,$$

$$\|x\|_\infty = \max_i |x_i|,$$

$$\|A\| = \sup_{x \neq 0} \frac{\|Ax\|}{\|x\|},$$

$$\|A\|_1 = \max_j \sum_i \underbrace{|a_{ij}|}_{\text{sloupcový součet}},$$

$$\|A\|_2 = \sqrt{\rho(A^H A)} = \sqrt{\rho(A A^H)},$$

$A^H$  – transponovaná a kompl. združená (hermitovská),

$\rho(B)$  – největší v abs. hodnotě vlastní číslo B (spektrální poloměr),

$$\|A\|_F = \sqrt{\sum_{i,j} |a_{ij}|^2} \quad \text{Frobeniova,}$$

$$\|A\|_\infty = \max_i \sum_j |a_{ij}| \quad \text{řádkový součet,}$$

- $\|I\|_F = \sqrt{N}$
- $\|I\| = 1$ ,  $\|Ax\| \leq \|A\| \cdot \|x\|$
- $\|AB\| \leq \|A\| \|B\|$  sub-multiplikativita

## 4.2 Gaußova eliminace

Cíl:

$$Ax = b \Leftrightarrow Ux = \hat{b}, \quad \text{kde } U \text{ je horní trojúhelníková}$$

**Algoritmus 4.2**

```

for sloupec  $j = 1$  to  $n - 1$  do
    najdi  $a_{pj} \neq 0$ ,  $p \in \{j, \dots, n\}$ 
    if  $a_{pj} = 0 \forall p$  then
        STOP (singularita)
    else
        záměna  $p$  a  $j$ -tého řádku
    end if
    for řádek  $i = j + 1$  to  $n$  do
         $l_{ij} = \frac{a_{ij}}{a_{jj}}$ ;
        for  $k = j + 1$  to  $n$  do
             $a_{ik} = a_{ik} - l_{ij}a_{jk}$ ;
        end for
         $b_i = b_i - l_{ij}b_j$ ;
    end for
end for

```

$u_{ij}, i \leq j$  jsou pak poslední hodnoty  $a_{ij}$   
 $\hat{b}_i$  jsou pak poslední hodnoty  $b_i$

Počet operací	v $j$ -tém kroku	celkem
Hledání $a_{pj} \neq 0$	$n - j + 1$	$\sum_{j=2}^n j = \frac{(2+n)(n-1)}{2}$
Výpočet $l_{ij}$	$n - j$	$\sum_{j=1}^{n-1} j = \frac{n(n-1)}{2}$
Výpočet $a_{ik}$	$2(n - j)^2$	$2 \sum_{j=1}^{n-1} j^2 = 2 \frac{2n^3 - 3n^2 + n}{6}$
Výpočet $b_i$	$2(n - j)$	$2 \sum_{j=1}^{n-1} j = 2 \frac{n(n-1)}{2}$

$$\text{Celkový počet operací: } \frac{2}{3}n^3 + O(n^2)$$

Počet operací pro řešení $Ux = \hat{b}$ :	$\frac{\text{násobení}}{\frac{(n+1)n}{2}}$	$\frac{\text{sčítání}}{\frac{n(n-1)}{2}}$

**Zkušební otázka 4.1** Zdůvodněte odhad počtu operací v Gaušově eliminaci.

#### 4.2.1 Pivottace

Výpočet  $l_{ij} = \frac{a_{ij}}{a_{jj}}$  v Algoritmu 4.2,  $a_{jj} \neq 0$ .

$$\text{Částečná pivotace } |a_{pj}| = \max_{l=j, \dots, n} |a_{lj}| \quad (4.2.1)$$

$$\text{Úplná pivotace } |a_{pj}| = \max_{l, m=j, \dots, n} |a_{lm}| \quad (4.2.2)$$

**Důvod:** I když Guašova eliminace je proveditelná bez záměny řádků a sloupců, mohou malé hodnoty  $a_{jj}$  způsobit velké chyby v řešení.

**Příklad 4.2**

$$\begin{pmatrix} 6 & 1 & & & \\ 8 & 6 & 1 & & \\ & 8 & 6 & 1 & \\ & \ddots & \ddots & \ddots & \\ & & 8 & 6 & \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ \vdots \\ x_{50} \end{pmatrix} = \begin{pmatrix} 7 \\ 15 \\ 15 \\ \vdots \\ 14 \end{pmatrix}, \quad x_{GE} = \begin{pmatrix} 1 \\ 1 \\ 1 \\ \vdots \\ -3 \times 10^7 \end{pmatrix}$$

Gaußova eliminace je numericky nestabilní. Pivotace je podstatná pro stabilitu elim. procesu. Ani velké hodnoty pivotů však nejsou zárukou dostatečně přesného řešení.

**Důvod:** velké změny v koeficientech

**Náprava:** škálování, dělení  $i$ -tého řádku  $d_i = \sum_{j=1}^n |a_{ij}|$ , ale toto dělení opět vnáší zaokrouhlovací chyby.

### 7. přednáška

#### 4.3 Gaußova eliminace jako faktorizační metoda

$$Ax = b \Leftrightarrow LUX = b \quad \begin{cases} UX = \hat{b}, \\ L\hat{b} = b. \end{cases} \quad (4.3.1)$$

Nechť  $P_j$  je matice, která v  $j$ -tému kroku Gaußovy eliminace realizuje záměnu  $p$ -tého a  $j$ -tého řádku matice  $A$  v Algoritmu 4.2

$$j \begin{pmatrix} 1 & & & & & p \\ & \ddots & & & & \\ & 0 & \ddots & & & \\ & & 1 & \ddots & & \\ & & & 1 & \ddots & \\ & & & & 1 & \\ p & & 1 & \ddots & 0 & \\ & & & & & 1 \end{pmatrix} \begin{pmatrix} \times & \times & \times & \times & \times & \times \\ \circ & \circ & \circ & \circ & \circ & \circ \\ \times & \times & \times & \times & \times & \times \\ \times & \times & \times & \times & \times & \times \\ \diamond & \diamond & \diamond & \diamond & \diamond & \diamond \\ \times & \times & \times & \times & \times & \times \\ \times & \times & \times & \times & \times & \times \\ \circ & \circ & \circ & \circ & \circ & \circ \\ \times & \times & \times & \times & \times & \times \end{pmatrix} = \begin{pmatrix} \times & \times & \times & \times & \times & \times \\ \diamond & \diamond & \diamond & \diamond & \diamond & \diamond \\ \times & \times & \times & \times & \times & \times \\ \times & \times & \times & \times & \times & \times \\ \times & \times & \times & \times & \times & \times \\ \circ & \circ & \circ & \circ & \circ & \circ \\ \times & \times & \times & \times & \times & \times \end{pmatrix}$$

a nechť  $L_j$  je matice, pomocí níž se provádí nulování prvků  $j$ -tého sloupce pod diagonálou.

$$\begin{pmatrix} 1 & & & & & & \\ & \ddots & & & & & \\ & & 1 & & & & \\ & & & 1 & & & \\ & & & & -\ell_{43} & 1 & \\ & & & & & 1 & \\ & & & & & & 1 \end{pmatrix} \begin{pmatrix} \times & \times & \times & \times & \times & \times \\ 0 & \times & \times & \times & \times & \times \\ 0 & 0 & \times & \times & \times & \times \\ 0 & 0 & \times & \times & \times & \times \\ 0 & 0 & \times & \times & \times & \times \\ 0 & 0 & \times & \times & \times & \times \end{pmatrix} = \begin{pmatrix} \times & \times & \times & \times & \times & \times \\ 0 & \times & \times & \times & \times & \times \\ 0 & 0 & \times & \times & \times & \times \\ 0 & 0 & 0 & \times & \times & \times \\ 0 & 0 & 0 & \times & \times & \times \\ 0 & 0 & 0 & \times & \times & \times \end{pmatrix}$$

Algoritmus Gaußovy eliminace lze maticově zapsat (GE s částeční pivotací):

$$\underbrace{L_{n-1}P_{n-1} \cdots L_1P_1}_M A = U.$$

Označme

$$P = P_{n-1} \cdots P_1,$$

$$M = L_{n-1} P_{n-1} \cdots L_1 P_1.$$

Potom

$$\begin{aligned} MA &= U, \\ MP^{-1}PA &= U, \\ PA &= \underbrace{PM^{-1}}_L U, \\ PA &= LU. \end{aligned}$$

Lze-li provést Gaušovou eliminaci bez záměny řádků a sloupců, dostáváme

$$A = LU. \quad (4.3.2)$$

**Věta 4.3** Nechť  $A \in \mathbb{R}^{n \times n}$ ,  $A$  regulární. Pak existuje permutační matice  $P \in \mathbb{R}^{n \times n}$ , nesingulární  $U$  a  $L$  s jedničkami na diagonále ::

$$PA = LU \quad (4.3.3)$$

### Algoritmus

Matici  $L$  výše uvedenou dostaneme pomocí Algoritmu 4.2 tak, že  $l_{ij}$  uložíme do  $a_{ij}$ , jejichž hodnoty nejsou v Gaušově eliminaci potřeba a při pivotaci je zaměníme.

Řešení úlohy  $Ax = b$  ve třech krocích

1.  $PA = LU$
2.  $PAx = L \underbrace{Ux}_{\hat{b}} = Pb$
3.  $Ux = \hat{b}$

Měření kvality řešení:  $r = b - A\tilde{x}$  - reziduum

**Věta 4.4** (Odhad rezidua) [Prager/Oettli]

Nechť  $\tilde{x}$  je přibližné řešení  $Ax = b$ ,  $r = b - A\tilde{x}$  reziduum. Nechť je dáno  $0 \leq \delta A \in \mathbb{R}^{n \times n}$ ,  $0 \leq \delta b \in \mathbb{R}^n$ . Pak  $\tilde{x}$  je přesné řešení

$$\tilde{A}\tilde{x} = \tilde{b}, \quad \text{kde} \quad (4.3.4)$$

$$|\tilde{A} - A| \leq \delta A, \quad |\tilde{b} - b| \leq \delta b \quad (\text{po složkách}) \quad (4.3.5)$$

právě když

$$|r| \leq \delta A |\tilde{x}| + \delta b. \quad (4.3.6)$$

**Důkaz** (pouze  $\Rightarrow$ )

Nechť  $\tilde{A}\tilde{x} = \tilde{b}$  ( $\tilde{x}$  je přesné řešení perturbovaného systému) a pro perturbace platí odhad

$$\begin{aligned} |\tilde{A} - A| &\leq \delta A \\ |\tilde{b} - b| &\leq \delta b \end{aligned}$$

$$\begin{aligned} \tilde{A} &= A + \Delta A & |\Delta A| &\leq \delta A \\ \tilde{b} &= b + \Delta b & |\Delta b| &\leq \delta b \end{aligned}$$

$$\begin{aligned} |r| &= |b - A\tilde{x}| = \left| \tilde{b} - \Delta b - \underbrace{\tilde{A}\tilde{x}}_{\tilde{b}} + \Delta A\tilde{x} \right| \leq \\ &\leq |\Delta A\tilde{x} - \Delta b| \leq \delta A |\tilde{x}| + \delta b. \end{aligned}$$

□

#### 4.4 LU rozklad v obecném případě

$$\begin{aligned} A &= \begin{pmatrix} 1 & 2 \\ 1 & 2 \end{pmatrix} & \exists! \text{ LU rozklad} \\ A &= \begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix} & \text{neexistuje LU rozklad} \\ A &= \begin{pmatrix} 0 & 1 \\ 0 & 2 \end{pmatrix} & \text{LU není jednoznačný} \end{aligned}$$

Při konstrukci LU rozkladu matice  $A \in \mathbb{R}^{n \times n}$  postupujeme tak, že postupně počítáme  $m$ -tý řádek matice  $U$  a  $m$ -tý sloupec matice  $L$ ,  $m = 1, \dots, n$ . Příslušné vzorce odvodíme pomocí vzorce pro násobení matic.

$$A = LU,$$

$$a_{ij} = \sum_{k=1}^n l_{ik} u_{kj}.$$

Máme  $n^2$  rovnic pro určení neznámých  $l_{ij}$ ,  $i \leq j$  a  $u_{ij}$ ,  $i \geq j$  (prvků dolní trojúhelníkové matice  $L$  a horní trojúhelníkové matice  $U$ ). Počet neznámých je  $2(1+n)n/2 = n^2 + n$ . Předepíšeme tedy hodnoty některých prvků, například položíme diagonální prvky matice  $L$  rovny jedné. Dostáváme následující vzorce pro  $m = 1, \dots, n$ :

$m$ -tý řádek matice  $U$ ,  $\textcolor{red}{u}_{mj}$ ,  $j \geq m$  (křížky označují již spočtené hodnoty, počítáme prvek  $\diamond$ :

$$m \underbrace{\begin{pmatrix} & & & & & & \\ & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ & \cdot & \cdot & \boxed{\times} & \cdot & \cdot & \cdot \\ & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \end{pmatrix}}_A = m \underbrace{\begin{pmatrix} 1 & & & & & & \\ \times & 1 & & & & & \\ \times & \times & 1 & & & & \\ \times & \times & \cdot & 1 & & & \\ \times & \times & \cdot & \cdot & 1 & & \\ \times & \times & \cdot & \cdot & \cdot & 1 & \end{pmatrix}}_L \underbrace{\begin{pmatrix} & & & & & & \\ \times & \times & \times & \times & \times & \times & \times \\ \times & \times & \times & \times & \times & \times & \times \\ \diamond & \rightarrow & & & & & \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \end{pmatrix}}_U$$

$$a_{mj} = \sum_{k=1}^n l_{mk} u_{kj} = \sum_{k=1}^{m-1} l_{mk} u_{kj} + 1 \cdot \textcolor{red}{u}_{mj}, \quad \textcolor{red}{u}_{mj} = \diamond,$$

$m$ -tý sloupec matice  $L$ ,  $\textcolor{red}{l}_{im}$ ,  $i > m$ :

$$i \underbrace{\begin{pmatrix} & & & & & & \\ & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ & \cdot & \cdot & \boxed{\times} & \cdot & \cdot & \cdot \\ & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \end{pmatrix}}_A = i \underbrace{\begin{pmatrix} 1 & & & & & & \\ \times & 1 & & & & & \\ \times & \times & 1 & & & & \\ \times & \times & \textcolor{red}{\circ} & 1 & & & \\ \times & \times & \downarrow & \cdot & 1 & & \\ \times & \times & \cdot & \cdot & \cdot & 1 & \end{pmatrix}}_L \underbrace{\begin{pmatrix} & & & & & & \\ \times & \times & \times & \times & \times & \times & \times \\ \cdot & \times & \times & \times & \times & \times & \times \\ \cdot & \cdot & \diamond & \diamond & \diamond & \diamond & \diamond \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \end{pmatrix}}_U$$

$$a_{im} = \sum_{k=1}^n l_{ik} u_{km} = \sum_{k=1}^{m-1} l_{ik} u_{km} + \textcolor{red}{l}_{im} \cdot u_{mm}, \quad \textcolor{red}{l}_{im} = \circ.$$

**Zkušební otázka 4.2!** Odvodte vzorce pro konstrukci LU rozkladu matice A.

**Věta 4.5** Nechť  $A \in \mathbb{R}^{n \times n}$  je obecná matice. Faktorizace  $A = LU$  existuje a je

jednoznačná právě když všechny hlavní minory  $A$ , t.j.  $\det \begin{pmatrix} a_{11} & \cdots & a_{1k} \\ & \ddots & \\ a_{k1} & \cdots & a_{kk} \end{pmatrix}$ ,  $k = 1, \dots, n-1$  jsou nenulové.

**Věta 4.6** Je-li matice řádkově nebo sloupcově diagonálně dominantní, t.j.

$$|a_{ii}| \geq \sum_{j=1, j \neq i}^n |a_{ij}|, \quad (\text{řádkově}) \quad (4.4.1)$$

nebo

$$|a_{jj}| \geq \sum_{i=1, i \neq j}^n |a_{ij}|, \quad (\text{sloupcově}) \quad (4.4.2)$$

pak LU rozklad existuje. Speciálně, je-li matice sloupcově diagonálně dominantní, je  $|l_{ij}| \leq 1 \forall i, j = 1, \dots, n$ .

#### 4.4.1 Vliv zaokrouhlovacích chyb

Uvažujeme-li zaokrouhlovací chyby, faktorizační proces produkuje matice  $\hat{L}$ ,  $\hat{U}$  takové, že

$$\hat{L}\hat{U} = A + \delta A. \quad (4.4.3)$$

Lze odhadnout (viz (Higham, 1989))

$$|\delta A| \leq \frac{nu}{1-nu} |\hat{L}| |\hat{U}|, \quad u = \frac{1}{2} \varepsilon_M, \quad (4.4.4)$$

kde  $B = |A|$  znamená matici  $n \times n$  s prvky  $b_{ij} = |a_{ij}|$ ,  $C \leq D$  má význam  $c_{ij} \leq d_{ij}$  (po prvcích),  $i, j = 1, \dots, n$  a  $\varepsilon_M$  je nejmenší číslo číslo takové, že  $1 + \varepsilon_M > 1$  (strojové epsilon, roundoff unit). Z (4.4.4) je vidět ( $l_{ij} = \frac{a_{ij}}{a_{jj}}$ , viz Gaußova eliminace), že přítomnost malých pivotů může způsobit neomezenost pravé strany a v důsledku toho ztrátu kontroly kontroly  $\delta A$ . Je tedy vhodné najít odhad

$$|\delta A| \leq \underbrace{g(u)}_{\text{vhodná funkce}} |A|$$

**Příklad 4.7** Nechť  $\hat{L} \geq 0$ ,  $\hat{U} \geq 0$ , pak  $|\hat{L}| |\hat{U}| = |\hat{L}\hat{U}|$

$$|\hat{L}| |\hat{U}| = |\hat{L}\hat{U}| = |A + \delta A| \leq |A| + |\delta A| \leq |A| + \frac{nu}{1-nu} |\hat{L}| |\hat{U}|$$

Odtud

$$\begin{aligned} |\hat{L}| |\hat{U}| \left(1 - \frac{nu}{1-nu}\right) &\leq |A| \\ |\hat{L}| |\hat{U}| &\leq \left(\frac{1-2nu}{1-nu}\right)^{-1} |A| \end{aligned}$$

a z 4.4.4 dostáváme

$$|\delta A| \leq \underbrace{\frac{nu}{1-2nu}}_{g(u)} |A| \quad (4.4.5)$$

Pivotace umožňuje obdržet odhad obdobný (4.4.5) pro libovolnou matici.

#### 4.5 Choleského rozklad

**Věta 4.8** Pro každou symetrickou, pozitivně definitní ( $x^T Ax > 0$ ,  $\forall x \neq 0$ ,  $x \in \mathbb{R}^n$ ) matici  $A \in \mathbb{R}^{n \times n}$  existuje právě jedna dolní trojúhelníková matici  $L$  s kladnými prvky na diagonále tak, že platí

$$A = L \cdot L^T \quad (4.5.1)$$

**Důkaz** indukcí □

**Věta 4.9** Nechť  $A \in \mathbb{R}^{n \times n}$  je symetrická, ostře diag. dominantní ( $|a_{ii}| > \sum_{j \neq i} |a_{ij}|$ ),  $a_{ii} > 0$ , pak  $A$  je pozitivně definitní.

#### 4.6 QR rozklad

**Věta 4.10** Ke každé nesingulární matici  $A \in \mathbb{R}^{n \times n}$  existuje ortogonální matici  $Q \in \mathbb{R}^{n \times n}$  ( $QQ^T = Q^TQ = I$ ) a nesingulární horní trojúhelníková  $R$  taková, že

$$A = Q \cdot R. \quad (4.6.1)$$

**Poznámka 4.11** Transformace, která (na rozdíl od  $LU$ ) nezvyšuje číslo podmínenosti ( $K(U) \leq 4^{n-1}K(PA)$ ).

# ITERAČNÍ METODY ŘEŠENÍ SOUSTAV LINEÁRNÍCH ROVNIC

## 8. přednáška

$$A \in \mathbb{R}^{n \times n}, b \in \mathbb{R}^n, \det A \neq 0.$$

Hledáme  $x \in \mathbb{R}^n$ :

$$Ax = b. \quad (5.0.1)$$

**Přímé metody** (např. Gaußova eliminace) :

- pro libovolné plné matice
- počet operací  $O(\frac{2}{3}n^3)$

Nevýhoda:

- a) nevyužívají informaci o struktuře matice (řídkost, blokově diagonální)
- b) nákladné, je-li  $n$  velké
- c) pro řídké matice mohou být nevhodné (zaplnění)

**Iterační metody**

- formálně poskytují řešení po nekonečném počtu kroků
- v každém kroku požadují výpočet rezidua, výpočetní náročnost  $O(n^2)$
- mohou soupeřit s přímými metodami, je-li počet iterací k získání řešení s danou tolerancí nezávislý na  $n$  nebo menší než  $n$
- používají se, stačí-li získat řešení pouze s určitou přesností (Fyzika → model → matematický model)

Idea iteračních metod: konstrukce  $\{x^{(k)}\}$

$$x = \lim_{k \rightarrow \infty} x^{(k)}, \quad \text{kde } x \text{ je řešení } Ax=b. \quad (5.0.2)$$

**Poznámka 5.1** Posloupnost  $x^{(0)}, x^{(1)}, \dots, x^{(k)}, \dots$ , je nekonečná, cílem je nalzení řešení  $x^*$  s předepsanou přesností, t.j.  $\|x^* - x^{(k)}\| \leq \varepsilon$ . Otázkou je určení vhodného stopping kriteria (např. omezenost rezidua  $\|b - Ax^{(k)}\| \leq \varepsilon$ ).

Princip iteračních metod je na základě předchozích approximací konstrukce nové approximace

$$x^{(k+1)} = \varphi(x^{(k)}), \quad \text{resp. } x^{(k+1)} = \varphi(x^{(k)}, x^{(k-1)}, \dots, x^{(0)})$$

takové, že

$$x^{(k+1)} \rightarrow x \text{ pro } k \rightarrow \infty,$$

kde  $x$  je hledané řešení. Požadavky:

- rychlá konvergencie
- snadné vyčíslení  $\varphi$  (méně operací než matice  $\times$  vektor, řádově  $O(n)$ )
- řešení s předepsanou přesností

### 5.1 Klasické iterační metody

Idea: věta o pevném bodě

$$Ax = b \Leftrightarrow x = G(x). \quad (5.1.1)$$

Pro dané  $x^{(0)}$  se řešení hledá jako limita posloupnosti  $x^{(k+1)} = G(x^{(k)})$ .

1. Richardsonova metoda

$$\begin{aligned} x &= x + b - Ax, \\ x &= \underbrace{(I - A)}_{B_R} x + b, \\ x^{(k+1)} &= B_R x^{(k)} + b. \end{aligned}$$

2. Jacobiho metoda

$$A = E + D + F, \quad \text{kde}$$

$E$  je ostře dolní trojúhelníková,  
 $D$  je diagonální,  
 $F$  je ostře horní trojúhelníková.

$$\begin{aligned} Ax = b &\Leftrightarrow (E + D + F)x = b, \\ Dx &= -(E + F)x + b, \\ x &= \underbrace{-D^{-1}(E + F)}_{B_J} x + \underbrace{D^{-1}b}_{f_J}, \\ x^{(k+1)} &= B_J x^{(k)} + f_J. \end{aligned}$$

3. Gaußova–Seidelova metoda

$$\begin{aligned} Ax = b &\Leftrightarrow (D + E)x + Fx = b, \\ (D + E)x &= -Fx + b, \\ x &= \underbrace{-(D + E)^{-1}F}_{B_{GS}} x + \underbrace{(D + E)^{-1}b}_{f_{GS}}, \\ x^{(k+1)} &= B_{GS} x^{(k)} + f_{GS}. \end{aligned}$$

**Poznámka 5.2** Porovnejme způsob algoritmizace Jacobiho a Gaußovy–Seidelovy metody. K tomu je třeba si nejprve uvědomit, že

$$D^{-1} = \begin{pmatrix} \frac{1}{a_{11}} & & & & & \\ & \frac{1}{a_{22}} & & & & \\ & & \frac{1}{a_{33}} & & & \\ & & & \ddots & & \\ & & & & \ddots & \\ & & & & & \frac{1}{a_{nn}} \end{pmatrix},$$

$$D^{-1}X = \begin{pmatrix} \frac{1}{a_{11}} \times & \frac{1}{a_{11}} \times \\ \frac{1}{a_{22}} \times & \frac{1}{a_{22}} \times \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \frac{1}{a_{nn}} \times & \frac{1}{a_{nn}} \times \end{pmatrix}.$$

Vyčíslení inverzní matice v Gaußově–Seidelově metodě se vyhneme následujícím způsobem. Na základě vyjádření

$$x^{(k+1)} = \underbrace{-(D+E)^{-1}F}_{B_{GS}} x^{(k)} + \underbrace{(D+E)^{-1}b}_{f_{GS}}$$

přepíšeme Gaußovu–Seidelovu metodu ve tvaru

$$\begin{aligned} (D+E)x^{(k+1)} &= -Fx^{(k)} + b, \\ Dx^{(k+1)} &= -Ex^{(k+1)} - Fx^{(k)} + b, \\ x^{(k+1)} &= -D^{-1}Ex^{(k+1)} - D^{-1}Fx^{(k)} + D^{-1}b, \end{aligned}$$

$$x^{(\textcolor{red}{k+1})} = -D^{-1}E \quad x^{(\textcolor{red}{k+1})} - D^{-1}F \quad x^{(\textcolor{red}{k})} + \underbrace{D^{-1}b}_{f_J}, \quad (5.1.2)$$

t.j.

$$\begin{pmatrix} x^{(k+1)} \\ \times \\ \times \\ \times \\ \times \end{pmatrix} = - \begin{pmatrix} \cdot & & & & \\ \times & \cdot & & & \\ \times & \times & \cdot & & \\ \times & \times & \times & \cdot & \end{pmatrix} \begin{pmatrix} x^{(k+1)} \\ \times \\ \times \\ \times \\ \times \end{pmatrix} - \begin{pmatrix} \cdot & \times & \times & \times \\ \cdot & \times & \times \\ \cdot & \cdot & \times \\ \cdot & \times \end{pmatrix} \begin{pmatrix} x^{(k)} \\ \times \\ \times \\ \times \\ \times \end{pmatrix}$$

$$+ \begin{pmatrix} f_J \\ \times \\ \times \\ \times \\ \times \end{pmatrix}.$$

Při použití Jacobiho metody

$$x^{(k+1)} = B_J x^{(k)} + f_J,$$

t.j.

$$\begin{pmatrix} x^{k+1} \\ \times \\ \times \\ \times \\ \times \end{pmatrix} = - \begin{pmatrix} \cdot & \times & \times & \times \\ \times & \cdot & \times & \times \\ \times & \times & \cdot & \times \\ \times & \times & \times & \cdot \end{pmatrix} \begin{pmatrix} x^k \\ \times \\ \times \\ \times \end{pmatrix} + \begin{pmatrix} f_J \\ \times \\ \times \\ \times \\ \times \end{pmatrix},$$

je třeba si pamatovat celý vektor  $x^{(k)}$  pro výpočet nové iterace  $x^{(k+1)}$ . U metody Gaušovy-Seidelovy se v paměti počítače rezervuje místo pro jediný vektor  $x^{(k)}$ , na jehož místo se postupně ukládají složky vektoru  $x^{(k+1)}$  jak vyplývá z rozepsání po složkách vztahu (5.1.2):

$$\begin{aligned} \sum_{j=1}^n a_{ij} x_j &= b_i, \\ \sum_{j=1}^{i-1} a_{ij} x_j + a_{ii} x_i + \sum_{j=i+1}^n a_{ij} x_j &= b_i, \\ a_{ii} x_i &= -\sum_{j=1}^{i-1} a_{ij} x_j - \sum_{j=i+1}^n a_{ij} x_j + b_i, \\ x_i^{(k+1)} &= \frac{1}{a_{ii}} \left( -\sum_{j=1}^{i-1} a_{ij} x_j^{(k+1)} - \sum_{j=i+1}^n a_{ij} x_j^{(k)} \right) + \frac{b_i}{a_{ii}}. \end{aligned}$$

Dostáváme tak algoritmus **Gaušovy–Seidelovy metody**, který lze vyjádřit následujícím způsobem. Vyjdeme z Jacobiho metody a spočtenou složku  $x_i^{(k+1)}$  uložíme do  $x_i^{(k)}$  a následně počítáme  $x_{i+1}^{(k+1)}$ ,  $i = 1, \dots, n$ .

$$i+1 \begin{pmatrix} x^{k+1} \\ \boxed{\times} \\ \boxed{\times} \\ \times \\ \times \end{pmatrix} = - \begin{pmatrix} \cdot & \times & \times & \times \\ \times & \cdot & \times & \times \\ \times & \times & \cdot & \times \\ \times & \times & \times & \cdot \end{pmatrix} \begin{pmatrix} x^k \\ \boxed{\times} \\ \times \\ \times \end{pmatrix} + \begin{pmatrix} f_J \\ \times \\ \times \\ \times \end{pmatrix}.$$

#### 4. Metoda SOR (superrelaxační)

$$\begin{aligned} Ax &= (E + D + F)x = b, \\ \tilde{x}^{(k+1)} &= -D^{-1}Ex^{(k+1)} - D^{-1}Fx^{(k)} + D^{-1}b, \\ x^{(k+1)} &= x^{(k)} + \omega(\tilde{x}^{(k+1)} - x^{(k)}), \end{aligned}$$

$$\begin{aligned}x^{(k+1)} &= (1 - \omega)x^{(k)} + \omega\tilde{x}^{(k+1)}, \\x^{(k+1)} &= -\omega D^{-1}Ex^{(k+1)} + [(1 - \omega)I - \omega D^{-1}F]x^{(k)} + \omega D^{-1}b,\end{aligned}$$

$$\begin{aligned}x^{(k+1)} &= (D^{-1}ID + \omega D^{-1}E)^{-1}[(1 - \omega)D^{-1}ID - \omega D^{-1}F]x^{(k)} \\&\quad + (D^{-1}ID + \omega D^{-1}E)^{-1}\omega D^{-1}b,\end{aligned}$$

$$\begin{aligned}x^{(k+1)} &= \underbrace{(D + \omega E)^{-1}[(1 - \omega)D - \omega F]}_{B_{SOR}}x^{(k)} \\&\quad + \underbrace{(D + \omega E)^{-1}\omega b}_{f_{SOR}}.\end{aligned}$$

$$\textcolor{red}{x^{(k+1)} = B_{SOR}x^{(k)} + f_{SOR}.}$$

Pro výpočty pomocí výše uvedených metod se používá jejich zápis do složek:

$$\begin{aligned}x_i^{(k+1)} &= \frac{1}{a_{ii}} \left( -\sum_{j=1}^{i-1} a_{ij}x_j^{(k)} - \sum_{j=i+1}^n a_{ij}x_j^{(k)} \right) + \frac{b_i}{a_{ii}}, \quad (\text{Jacobi}) \\x_i^{(k+1)} &= \frac{1}{a_{ii}} \left( -\sum_{j=1}^{i-1} a_{ij}x_j^{(k+1)} - \sum_{j=i+1}^n a_{ij}x_j^{(k)} \right) + \frac{b_i}{a_{ii}}, \quad (\text{Gauß-Seidel}) \\ \tilde{x}_i^{(k+1)} &= \frac{1}{a_{ii}} \left( -\sum_{j=1}^{i-1} a_{ij}x_j^{(k+1)} - \sum_{j=i+1}^n a_{ij}x_j^{(k)} \right) + \frac{b_i}{a_{ii}}, \quad (\text{SOR}) \\x_i^{(k+1)} &= x_i^{(k)} + \omega(\tilde{x}_i^{(k+1)} - x_i^{(k)}).\end{aligned}$$

**Zkušební otázka 5.1!** Odvodte Jacobiho, Gaußovu–Seidelovu a SOR metodu pro řešení úlohy  $Ax = b$ . Zapište je maticově a rozepsané do složek bez použití inverze matic.

Uvažujme iterační metodu

$$x^{(k+1)} = Bx^{(k)} + f. \quad (5.1.3)$$

**Definice 5.3** Řekneme, že iterační metoda  $\textcolor{red}{x^{(k+1)} = Bx^{(k)} + f}$  je konzistentní s  $Ax = b$ , jestliže

$$x = Bx + f, \text{ kde } x \text{ je řešení úlohy } Ax = b.$$

Ekvivalentně

$$f = (I - B)x = (I - B)A^{-1}b.$$

**Věta 5.4** Nechť  $x^{(k+1)} = Bx^{(k)} + f$  je konzistentní metoda. Pak posloupnost  $\{x^{(k)}\}$  konverguje k  $x^*$ , kde  $x^*$  splňuje  $Ax^* = b$ , pro libovolné  $x^{(0)}$ , právě když  $\rho(B)$  (spektrální poloměr matice  $B$ ,  $\rho(B) = \max_{\{\lambda\} \text{vl. č. } B} |\lambda|$ ) je menší než 1.

### Důkaz

$$\begin{aligned} x^* &= Bx^* + f \quad (\text{podmínka konzistence}), \\ x^{(k+1)} &= Bx^{(k)} + f \quad (\text{iterační metoda}), \\ e^{(k+1)} &:= x^* - x^{(k+1)} \quad (\text{chyba v }(k+1)\text{-ní iteraci}). \end{aligned}$$

Chybu v  $k$ -té iteraci lze vyjádřit jako součin  $k$ -té mocniny matice  $B$  a chyby počáteční approximace

$$e^{(k)} = Be^{(k-1)} = B^2e^{(k-2)} = \dots = B^ke^{(0)}.$$

Podle definice limity

$$x^{(k)} \rightarrow x^* \Leftrightarrow \|e^{(k)}\| \rightarrow 0.$$

Platí

$$\|e^{(k)}\| \rightarrow 0 \Leftrightarrow \|B^ke^{(0)}\| \rightarrow 0 \Leftrightarrow \rho(B) < 1.$$

Poslední ekvivalence dokážeme na základě následující věty z algebry. Vyhne se tak klasickému důkazu pomocí převedení matice  $B$  na **Jordanův kanonický tvar**.

**Lemma 5.5** Nechť  $A \in \mathbb{C}^{n \times n}$ ,  $\varepsilon > 0$ . Pak existuje konzistentní ( $\|Ax\| \leq \|A\|\|x\|$ ) maticová norma  $\|\cdot\|_{A,\varepsilon}$  taková, že

$$\|A\|_{A,\varepsilon} \leq \rho(A) + \varepsilon.$$

Pokračování v důkazu předchozí věty

$\Leftarrow$  Nechť  $\rho(B) < 1$ . Potom  $\exists \varepsilon :: \rho(B) < 1 - \varepsilon$  a dále existuje  $\|\cdot\|_{B,\varepsilon} ::$

$$\|B\|_{B,\varepsilon} \leq \rho(B) + \varepsilon < 1$$

a tedy

$$\|B^k\|_{B,\varepsilon} \leq \|B\|_{B,\varepsilon}^k \rightarrow 0.$$

Platí tedy

$$\|e^{(k)}\| = \|B^ke^{(0)}\| \leq \|B^k\| \|e^{(0)}\| \leq \|B\|^k \|e^{(0)}\| \rightarrow 0.$$

$\Rightarrow$  Předpokládejme sporem, že  $\rho(B) > 1$ . Existuje tedy vlastní číslo  $\lambda$  matice  $B$  takové, že  $|\lambda| > 1$ . Zvolme počáteční approximaci  $x^{(0)}$  tak, že  $e^{(0)}$  je vlastní vektor odpovídající vlastnímu číslu  $\lambda$ . Potom

$$e^{(k)} = B^ke^{(0)} = \lambda^k e^{(0)}.$$

V důsledku tohoto vztahu  $e^{(k)}$  nekonverguje k nule (pro danou volbu  $x^{(0)}$ ), protože  $|\lambda| > 1$ .

□

**Poznámka 5.6** Lemma 5.5 jsme využili pro důkaz vztahu  $\rho(B) < 1 \Rightarrow B^k \rightarrow 0$ . Obrácená implikace se dokáže snadno.

Pro důkaz konvergence výše uvedených klasických iteračních metod se využívá řada kritérií, která vychází z přímo z vlastností matice  $A$ . Detaily viz cvičení k přednášce.

# 6

## VÝPOČET VLASTNÍCH ČÍSEL MATIC

### 9. přednáška

$$A \in \mathbb{C}^{n \times n}.$$

Hledáme  $\lambda \in \mathbb{C} :: \exists x \in \mathbb{C}^n, x \neq 0,$

$$Ax = \lambda x. \quad (6.0.1)$$

- aplikace: kvantová mechanika, strukturální vibrace, analýza elektrických sítí, analýza numerických metod (výpočet optimálních parametrů relaxačních metod), analýza stability numerických metod pro řešení soustav obyčejných diferenciálních rovnic
- omezíme se na výpočet dominantního vlastního čísla

### 6.1 Mocninná metoda

$$A \in \mathbb{C}^{n \times n}, A \text{ diagonalizovatelná}$$

$$A = X \Lambda X^{-1}, X = \begin{pmatrix} \vdots & & \vdots \\ x_1 & \cdots & x_n \\ \vdots & & \vdots \end{pmatrix} \in \mathbb{C}^{n \times n},$$

$x_i$  vlastní vektory ( $Ax_i = \lambda_i x_i$ ),  $\|x_i\| = 1$ . Nechť  $|\lambda_1| > |\lambda_2| \geq |\lambda_3| \geq \dots \geq |\lambda_n|$ ,  $\lambda_1$  má násobnost 1. Pak  $\lambda_1$  nazveme dominantním vlastním číslem.

Nechť je dáno  $q^{(0)} \in \mathbb{C}^n$ ,  $\|q^{(0)}\| = 1$  ( $\|\cdot\| := \|\cdot\|_2$  - Euklidovská). Konstruujeme posloupnost vektorů

$$q^{(k)} = \frac{Aq^{(k-1)}}{\|Aq^{(k-1)}\|} = \dots = \frac{A^k q^{(0)}}{\|A^k q^{(0)}\|} \text{ (odtud název mocninná metoda).}$$

Je-li  $A$  diagonalizovatelná, má matice  $X$  za sloupce vlastní vektory matice  $A$ . Tyto vlastní vektory jsou lineárně nezávislé a tvoří bázi  $\mathbb{C}^n$ . Lze tedy psát:

$$q^{(0)} = \sum_{i=1}^n \alpha_i x_i, \alpha_i \in \mathbb{C}, i = 1, \dots, n.$$

Budeme uvažovat takové  $q^{(0)}$ , pro které  $\alpha_1 \neq 0$ . Jinak bychom v dalším postupu narazili na problém dělení nulou. Dále  $Ax_i = \lambda_i x_i$  pro  $i = 1, \dots, n$  a vytkneme-li  $\alpha_1 \lambda_1^k$ , dostaneme

$$q^{(k)} = \frac{\sum_{i=1}^n \alpha_i \lambda_i^k x_i}{\left\| \sum_{i=1}^n \alpha_i \lambda_i^k x_i \right\|} = \frac{\alpha_1 \lambda_1^k (x_1 + y^{(k)})}{|\alpha_1 \lambda_1^k| \|x_1 + y^{(k)}\|}$$

kde  $(\sum_{i=1}^n \alpha_i \lambda_i^k x_i) = \alpha_1 \lambda_1^k (x_1 + \frac{\alpha_2 \lambda_2}{\alpha_1 \lambda_1^k} x_2 + \dots + \frac{\alpha_n \lambda_n}{\alpha_1 \lambda_1^k} x_n)$

$$y^{(k)} = \sum_{i=2}^n \frac{\alpha_i}{\alpha_1} \left( \frac{\lambda_i}{\lambda_1} \right)^k x_i$$

a v důsledku přepokladu, že  $\lambda_1$  je dominantní vlastní číslo matice  $A$  a  $\|x_i\| = 1$ ,

$$\|y^{(k)}\| = \left\| \sum_{i=2}^n \frac{\alpha_i}{\alpha_1} \left( \frac{\lambda_i}{\lambda_1} \right)^k x_i \right\| \leq \underbrace{\sum_{i=2}^n \left| \frac{\alpha_i}{\alpha_1} \right|}_{C} \left| \frac{\lambda_2}{\lambda_1} \right|^k \leq C \left| \frac{\lambda_2}{\lambda_1} \right|^k.$$

Odtud dostáváme

$$y^{(k)} \rightarrow 0 \quad \text{pro } k \rightarrow \infty.$$

Pro  $k \rightarrow \infty$  se tedy směr  $q^{(k)}$  bude blížit směru  $x_1$ . O rychlosti konvergence rozhoduje podíl  $|\lambda_2/\lambda_1|$ .

Uvažujme  $Aq^{(k)}$  a  $q^{(k)H} Aq^{(k)}$  ( $x^H = \bar{x}^T$ ). Ukážeme, že

$$q^{(k)H} Aq^{(k)} \rightarrow \lambda_1 \quad \text{pro } k \rightarrow \infty.$$

$$\begin{aligned} q^{(k)H} &= \frac{\alpha_1 \lambda_1^k (\mathbf{x}_1 + y^{(k)})^H}{|\alpha_1 \lambda_1^k| \|x_1 + y^{(k)}\|}, \quad Aq^{(k)} = \frac{\alpha_1 \lambda_1^k (\lambda_1 \mathbf{x}_1 + Ay^{(k)})}{|\alpha_1 \lambda_1^k| \|x_1 + y^{(k)}\|}, \\ q^{(k)H} Aq^{(k)} &= \frac{(\alpha_1 \lambda_1^k)^2 (\lambda_1 + x_1^H Ay^{(k)} + \lambda_1 y^{(k)H} x_1 + y^{(k)H} Ay^{(k)})}{|\alpha_1 \lambda_1^k|^2 \|x_1 + y^{(k)}\|^2} \rightarrow \lambda_1, \end{aligned}$$

kde jsme využili toho, že  $x_1^H x_1 = 1$ .

**Zkušební otázka 6.1!** Dokažte konvergenci mocninné metody pro výpočet dominantního vlastního čísla matice  $A$ .

Dále ukážeme, že  $q^{(k)} \rightarrow x_1$ . K tomu uvažujme

$$\begin{aligned} Aq^{(k)} - \lambda_1 q^{(k)} &= \frac{\alpha_1 \lambda_1^k (\lambda_1 \mathbf{x}_1 + Ay^{(k)})}{|\alpha_1 \lambda_1^k| \|x_1 + y^{(k)}\|} - \frac{\alpha_1 \lambda_1^k (\lambda_1 \mathbf{x}_1 + \lambda_1 y^{(k)})}{|\alpha_1 \lambda_1^k| \|x_1 + y^{(k)}\|} \\ &= \frac{\alpha_1 \lambda_1^k (Ay^{(k)} - \lambda_1 y^{(k)})}{|\alpha_1 \lambda_1^k| \|x_1 + y^{(k)}\|} \rightarrow 0 \end{aligned}$$

v důsledku toho, že  $y^{(k)} \rightarrow 0$  pro  $k \rightarrow \infty$ .

## NUMERICKÁ INTEGRACE OBYČEJNÝCH DIFERENCIÁLNÍCH ROVNIC

### 7.1 Formulace problému

10. přednáška

Dáno  $f : [a, b] \times \mathbb{R} \rightarrow \mathbb{R}$ ,  $f = f(x, y)$ ,  $x \in [a, b]$ ,  $y \in \mathbb{R}$ . Dána tzv. počáteční podmínka  $\eta \in \mathbb{R}$ . Hledáme zobrazení  $y : [a, b] \rightarrow \mathbb{R}$  splňující

$$\begin{aligned} y'(x) &= f(x, y(x)), \quad x \in [a, b], \\ y(a) &= \eta. \end{aligned}$$

Vyšetřování:

- (lokální) existence a jednoznačnost - matematická analýza: o funkci  $f$  předpokládáme, že je spojitá a dále předpokládáme, že  $f$  je (lokálně) lipschitzovská v druhé proměnné
- nalezení řešení
  - \* analyticky
  - \* numericky

### 7.2 Jednokrokové metody

Uvažujme dělení intervalu  $[a, b]$  s uzly  $x_i = a + ih$ ,  $i = 0, \dots, n$  (s konstantním krokem, obecně lze uvažovat nekonstantní).

Hodnotu řešení  $y(x_i)$  approximujeme pomocí hodnoty  $y_i$ :

$$y(x_i) \approx y_i, \quad i = 0, \dots, n.$$

V uzlu  $x_i$  platí

$$y'(x_i) = f(x_i, y(x_i)).$$

Předpokládejme, že funkce  $y$  je dostatečně hladká. Z Taylorova rozvoje dostaneme

$$y'(x_i) = \frac{y(x_{i+1}) - y(x_i)}{h} + O(h).$$

Dosadíme-li tento vztah do diferenciální rovnice, dostaneme

$$\frac{y(\textcolor{red}{x_{i+1}}) - y(x_i)}{h} + O(h) = f(x_i, y(x_i)).$$

To nás vede k myšlence, zanedbat chybu řádu  $O(h)$  a počítat přibližné hodnoty  $y_i$ ,  $i = 1, \dots, n$  ze vztahu

$$\frac{y_{i+1} - y_i}{h} = f(x_i, y_i)$$

tak, že přibližnou hodnotu funkce  $y$  v uzlu  $x_{i+1}$  vyjádříme pomocí přibližné hodnoty v uzlu  $x_i$ :

$$y_{i+1} = y_i + h f(x_i, y_i), \quad y_0 = \eta \text{ (dáno).}$$

Tato metoda se nazývá **Eulerova metoda** pro řešení úlohy  $y' = f(x, y)$  s danou počáteční podmínkou.

**Zkušební otázka 7.1** Odvoďte Eulerovu metodu pro řešení úlohy  $y' = f(x, y)$ .

Obecně uvažujme metody typu:

$$y_{i+1} = y_i + h \underbrace{\phi(x_i, y_i, h)}_{\text{přírustkové zobrazení}}. \quad (7.2.1)$$

Tato metoda se nazývá jednokroková, protože hodnotu approximace  $y_{i+1}$  počítáme pomocí hodnoty  $y_i$ . Pro Eulerovu metodu máme

$$\phi(x_i, y_i, h) := f(x_i, y_i).$$

Při použití Eulerovy metody dále platí pro hodnoty přesného řešení

$$\underbrace{\frac{y(x+h) - y(x)}{h}}_{\text{přesný relativní přírustek}} = y'(x) + O(h) = f(x, y(x)) + O(h) = \phi(x, y(x), h) + O(h).$$

přesný relativní přírustek

V Eulerově metodě se tedy liší přesný relativní přírustek a přírustkové zobrazení o veličinu řádu  $O(h)$ :

$$\underbrace{\frac{y(x+h) - y(x)}{h}}_{\text{přírustkové zobrazení}} = \phi(x, y(x), h) + O(h).$$

To nás vede k definici řádu metody:

**Definice 7.1** Řekneme, že metoda (7.2.1) je řádu  $p$ , jestliže

$$\frac{y(x+h) - y(x)}{h} = \phi(x, y(x), h) + O(h^p). \quad (7.2.2)$$

Jinými slovy definice říká, že obecná jednokroková metoda (7.2.1) je řádu  $p$ , jestliže přesné řešení splňuje vztah (7.2.1) s chybou  $hO(h^p)$ .

**Definice 7.2** Řekneme, že obecná jednokroková metoda je konvergentní, jestliže

$$\forall i = 0, \dots, n, \quad |y(x_i) - y_i| \leq \varphi(h),$$

kde  $\varphi(h)$  je infinitesimální vzhledem k  $h$ . V takovém případě řekneme, že metoda je konvergentní s řádem  $p$ , jestliže  $\varphi(h) = O(h^p)$ .

**Věta 7.3** Metoda (7.2.1) je konvergentní, právě když  $f(x, y) = \phi(x, y, 0)$ , za předpokladu spojitosti  $f, \phi$  a lipschitzovskosti  $f$  a  $\phi$  v druhé proměnné.

**Věta 7.4** (Odhad chyby) Je-li metoda řádu  $p$ , potom  $\exists$  konstanta  $C \geq 0$  taková, že

$$|y(x_i) - y_i| \leq C \cdot h^p \cdot \frac{e^{L(x_i-x_0)} - 1}{L},$$

za předpokladu spojitosti  $f, \phi$  a lipschitzovskosti  $f$  a  $\phi$  v druhé proměnné. Zde  $L$  je konstanta lipschitzovskosti přírustkového zobrazení  $\phi$ .

**Poznámka 7.5** Obdobně se odvodí jednokrokové metody pro řešení soustav obyčejných diferenciálních rovnic

$$\begin{aligned} y'(x) &= f(x, y(x)), \quad x \in [a, b], \\ y(a) &= \eta, \end{aligned}$$

$$f : [a, b] \times \mathbb{R}^m \rightarrow \mathbb{R}^m, \eta \in \mathbb{R}^m.$$

### 7.2.1 Metody typu Runge–Kutta

Podobně jako při konstrukci Eulerovy metody, která je metodou prvního řádu, můžeme postupovat při odvození metody vyššího řádu. Z Taylorova rozvoje funkce  $y$  dostaneme

$$\begin{aligned} y(x_{i+1}) &= y(x_i) + h y'(x_i) + \frac{1}{2} h^2 y''(x_i) + O(h^3), \\ y(x_{i+1}) &= y(x_i) + h f(x_i, y(x_i)) + \frac{1}{2} h^2 \frac{df}{dx}(x_i, y(x_i)) + O(h^3). \end{aligned}$$

Podle věty o derivaci složené funkce máme

$$\frac{df}{dx} = f_x + f_y f.$$

Můžeme tak zkonstruovat metodu druhého řádu s přírustkovým zobrazením

$$\phi(x, y, h) = f(x, y) + \frac{1}{2} h \left( f_x(x, y) + f_y(x, y) f(x, y) \right),$$

které ale závisí na derivacích zobrazení  $f$ . Proto se používají metody typu **Runge–Kutta**: konstruuje se  $\phi$ , splňující (7.2.2), bez použití derivací  $f$ . Základní myšlenka spočívá v tom, že přírustkové zobrazení se hledá ve speciálním tvaru tak, aby se lišilo od přesného relativního přírustku o veličinu  $O(h^p)$ . Tvar, ve kterém se hledá přírustkové zobrazení, je následující:

$$\phi(x, y, h) = \sum_{i=1}^s \omega_i k_i = \omega_1 k_1 + \omega_2 k_2 + \cdots + \omega_s k_s,$$

kde  $\omega_i$  jsou konstanty. Veličiny  $k_i$  jsou vyjádřeny pomocí hodnot zobrazení  $f$  bez použití jeho derivací.

$$k_1 = f(x, y),$$

$$\begin{aligned}
k_2 &= f(x + \alpha_2 h, y + \beta_{21} h k_1), \\
&\vdots \\
k_i &= f(x + \alpha_i h, y + h \sum_{j=1}^{i-1} \beta_{ij} k_j), \\
&\vdots \\
k_s &= f(x + \alpha_s h, y + h \sum_{j=1}^{s-1} \beta_{sj} k_j),
\end{aligned}$$

kde  $\alpha_i, \beta_{ij}$  jsou konstanty. Ve výše uvedených vzorcích je obecně

$$s \neq p.$$

Pro požadovaný řád metody  $p \leq 4$  lze volit  $s := p$ . Pro  $p > 4$  musí být  $s > p$ .

**7.2.1.1 Rungeova–Kuttova metoda 2. řádu** Ukážeme, jak se určí konstanty  $\omega_i, \alpha_i, \beta_{ij}$  na příkladu odvození Rungeovy–Kuttovy metody 2. řádu, tj. pro  $p = 2$ . Přírustkové zobrazení hledáme ve tvaru

$$\phi(x, y, h) = \omega_1 f(x, y) + \omega_2 f(x + \alpha h, y + \beta h f(x, y)).$$

Cílem je určit konstanty  $\omega_1, \omega_2, \alpha, \beta$  tak, aby metoda byla 2. řádu, tj. aby

$$\frac{y(x+h) - y(x)}{h} = \phi(x, y, h) + O(h^2).$$

Myšlenka je založena na vyjádření přesného relativního přírustku pomocí Taylorova rozvoje ve tvaru

$$\frac{y(x+h) + y(x)}{h} = \text{výraz } 1 + O(h^2)$$

a vyjádření přírustkového zobrazení  $\phi$  ve tvaru

$$\phi(x, y, h) = \text{výraz } 2 + O(h^2).$$

Konstanty  $\omega_1, \omega_2, \alpha, \beta$  ve ‘výraz 2’ nastavíme tak, aby ‘výraz 1 = ‘výraz 2’. Z Taylorova rozvoje funkce  $y$  dostaneme

$$y(x+h) = y(x) + hf + \frac{1}{2}h^2 \left( \underbrace{f_x + f_y f}_{y''(x) = \frac{d}{dx} f(x, y(x)) = f_x + f_y f} \right) + O(h^3),$$

odkud

$$\frac{y(x+h) - y(x)}{h} = \underbrace{\mathbf{f} + \frac{1}{2}h\mathbf{f}_x + \frac{1}{2}h\mathbf{f}_y\mathbf{f}}_{\text{výraz } 1} + O(h^2).$$

Na základě Taylorova rozvoje funkce dvou proměnných  $f$

$$f(x+h_1, y+h_2) = f(x, y) + h_1 \frac{\partial f}{\partial x}(x, y) + h_2 \frac{\partial f}{\partial y}(x, y) + O(|h|^2)$$

pro  $h_1 = \alpha h$ ,  $h_2 = h\beta f$  a definice přírustkového zobrazení v metodě typu Runge–Kutta

$$\phi(x, y, h) = \omega_1 f(x, y) + \omega_2 f(x + \alpha h, y + \beta h f(x, y))$$

vyjádříme přírustkové zobrazení ve tvaru

$$\phi(x, y, h) = \underbrace{\omega_1 f + \omega_2 [f + \alpha h f_x + \beta h f f_y]}_{\text{výraz 2}} + O(h^2).$$

‘výraz 2’ ještě upravíme, abychom ho mohli porovnat s ‘výrazem 1’:

$$\phi(x, y, h) = \underbrace{(\omega_1 + \omega_2) f + \omega_2 \alpha h f_x + \omega_2 \beta h f f_y}_{\text{výraz 2}} + O(h^2).$$

Porovnáním koeficientů u  $f$ ,  $h f_x$  a  $h f f_y$  ve ‘výraz 1’ a ‘výraz 2’ získáme rovnice pro  $\omega_1, \omega_2, \alpha$  a  $\beta$

$$1 = \omega_1 + \omega_2, \quad \frac{1}{2} = \alpha \omega_2, \quad \frac{1}{2} = \beta \omega_2.$$

Odvodili jsme tak 3 rovnice pro 4 neznámé. Zvolíme např.  $\omega_1 = 0$  a určíme zbývající konstanty:

$$\begin{aligned} \omega_2 &= 1, \\ \alpha &= \frac{1}{2}, \quad \beta = \frac{1}{2}. \end{aligned}$$

Runge–Kuttovu metodu 2. řádu lze tedy zapsat ve tvaru

$$y_{i+1} = y_i + h \phi(x_i, y_i, h),$$

$$\phi(x_i, y_i, h) = f\left(x_i + \frac{1}{2}h, y_i + \frac{1}{2}h f(x_i, y_i)\right).$$

**Zkušební otázka 7.2!** Odvodte Rungeovu–Kuttovu metodu 2. řádu.

# 8

## GRADIENTNÍ METODY

### 8.1 Formulace problému

11. přednáška



Pokračování příště.

## BIBLIOGRAFIE

- Feistauer, M., Felcman, J., and Straškraba, I. (2003). *Mathematical and Computational Methods for Compressible Flow*. Oxford University Press, Oxford.
- Higham, N. (1989). The accuracy of solutions to triangular systems. *SIAM J. Appl. Math.*, **26(5)**, 1252–1265.
- Quarteroni, A., Sacco, R., and Saleri, F. (2004). *Numerical Mathematics* (2nd edn), Volume 37 of *Texts in Applied Mathematics*. Springer, Berlin. ISBN 0-387-98959-5.
- Segethová, J. (2000). *Základy numerické matematiky*. Karolinum, Praha.
- Ueberhuber, W. (2000). *Numerical Computation 1, 2: Methods, Software, and Analysis*. Springer, Berlin.

## INDEX

- bod
    - nulový, 6
  - chyba Lagrangeovy interpolace, 5, 6
  - dělení intervalu, 2
  - formule
    - kvadraturní, 12
  - koeficienty kvadraturní formule, 12
  - polynom
    - Lagrangeův, 5
    - Lagrangeův interpolační, 4
  - pravidlo
    - lichoběžníkové, 13
    - Simpsonovo, 13
  - spline
    - $k$ -tého rádu, 6
    - kubický, 6, 7
    - přirozený kubický, 7
  - stupeň volnosti, 7
  - sítí, 2
- uzly
    - kvadraturní formule, 12
    - sítě, 2
  - věta
    - Rolleova, 6
  - zbytek kvadraturního vzorce, 14