

# Základy numerické matematiky

Miloslav Feistauer

Univerzita Karlova v Praze  
Matematicko-fyzikální fakulta



## OBSAH

<b>1 Interpolace funkcí</b>	1
1.1 Po částech polynomiální interpolace	1
1.1.1 Konstrukce kubického splinu	2
1.1.2 Odhad chyby	4
1.1.3 Spline s napětím	5
1.1.4 Hermiteův spline	5
<b>2 Numerické řešení obyčejných diferenciálních rovnic</b>	6
2.1 Příklady diskrétních metod	7
2.1.1 Eulerova metoda	7
2.1.2 Rungeova-Kuttova metoda	7
2.1.3 Dvoukroková metoda	8
2.2 Obecné jednokrokové metody	8
2.2.1 Konvergence jednokrokových metod	10
2.3 Odvození některých jednokrokových metod	12
2.3.1 Metody založené na přímém použití Taylorova vzorce	12
2.3.2 Rungeovy-Kuttovy metody	13
2.4 Použitelnost odhadů chyb	16
2.4.1 Odhad chyby metodou polovičního kroku	17
2.4.2 Zaokrouhlovací chyby	18
2.5 Soustavy lineárních diferenčních rovnic	20
2.5.1 Nalezení fundamentálního systému	22
2.5.2 Nalezení reálného fundamentálního systému	24
2.6 Vícekrokové metody	25
2.7 Některé vlastnosti obecných vícekrokových metod	27
2.8 Odvození některých vícekrokových metod	35
2.8.1 Interpolační polynom a zpětné diference	35
2.8.2 Metody založené na numerické integraci	36
2.8.3 Příklady některých metod	37
2.9 Metoda sítí pro řešení parciálních diferenciálních rovnic	38
<b>3 Numerické metody optimalizace</b>	40
3.1 Základy konvexní analýzy	41
3.2 Numerické metody hledání minima	45
Důkaz:46 Důkaz:47 Důkaz:48 Důkaz:49 Důsledek.50 <b>Rejstřík</b>	51

# 1

## INTERPOLACE FUNKCÍ

V této části se budeme zabývat následujícím problémem: Nechť je dán interval  $[a, b]$ , v něm jsou dány body  $x_0, \dots, x_n$  a předepsané hodnoty  $f(x_0), \dots, f(x_n)$ . Hledáme funkci  $p$  daného typu, která vyhovuje podmínek  $p(x_i) = f(x_i)$ ,  $i = 0, \dots, n$ . Je známo, že existuje právě jeden (Lagrangeův) interpolační polynom  $p_n$  stupně nejvýše  $n$ , pro který je  $p_n(x_j) = f(x_j)$ ,  $j = 0, \dots, n$ . Pro přesnost approximace dostatečně hladké funkce máme následující větu:

**Věta 1** Je-li  $f \in C^{n+1}[a, b]$ ,  $x_0, \dots, x_n \in [a, b]$ , pak pro každé  $x \in [a, b]$  existuje  $\xi \in (a, b)$  tak, že

$$f(x) - p_n(x) = \frac{1}{(n+1)!} f^{(n+1)}(\xi) \prod_{j=0}^n (x - x_j).$$

Je-li approximovaná funkce dokonce třídy  $C^\infty$  a má stejně omezené derivace, dostáváme jednoduše

**Důsledek 2** Bud'  $f \in C^\infty[a, b]$ ,  $|f^{(k)}| \leq K$  v  $[a, b]$ . Pak

$$\max_{x \in [a, b]} |f(x) - p_n(x)| \leq \frac{K^{n+1}(b-a)^{n+1}}{(n+1)!} \xrightarrow{n \rightarrow \infty} 0.$$

Tudíž,  $p_n \rightrightarrows f$  v  $[a, b]$  pro  $n \rightarrow \infty$ .

**Cvičení 1** Uvažujme funkci  $f(x) = \sin x$  na intervalu  $[0, 1]$ . Jaké největší chyby se můžeme dopustit, approximujeme-li  $f$  pomocí  $p_9$ ?

Pokaždé však nedosáhneme tak vynikající approximace. Příkladem může být funkce  $f(x) = \frac{1}{1+x^2}$  na intervalu  $[-5, 5]$ . Dá se dokázat, že pro interpolační polynomy  $p_n$  s uzly v bodech ekvidistantního dělení je posloupnost  $(\|f - p_n\|_{C([a, b])})_{n=1}^\infty$  neomezená.

### 1.1 Po částech polynomiální interpolace

Jednou z nevýhod approximace interpolačním polynomem je skutečnost, že hodnoty interpolačního polynomu jsou silně ovlivněny i hodnotami funkce ve vzdálených uzlech. Řešením je approximovat  $f$  po částech. Při tomto přístupu je naším cílem approximovat funkci  $f$  v intervalu  $[x_0, x_n]$  pomocí funkce  $\varphi$  takové, že  $\varphi|_{[x_i, x_{i+1}]}$  je polynom. Většinou se navíc požaduje, aby  $\varphi$  byla třídy  $C^k$  pro dané  $k$ . Takovou funkci  $\varphi$  nazýváme *spline*.

Nejjednodušším případem ( $k = 0$ ) je approximace pomocí funkce po částech lineární, jejímž grafem je lomená čára. V praxi je většinou třeba lepší approximace. Přijatelným řešením je tzv. *kubický spline*.

**Definice 1** Řekneme, že funkce  $\varphi : [x_0, x_n] \rightarrow I\!\!R$  je *kubický spline*, jestliže

- (i)  $\varphi \in C^2[x_0, x_n]$ ,
- (ii)  $\varphi|_{[x_i, x_{i+1}]}$  je polynom stupně nejvýše 3.

Říkáme, že  $\varphi$  je *kubický interpolační spline* k  $f$  v bodech  $x_0, \dots, x_n$ , jestliže jsou navíc splněny podmínky  $\varphi(x_i) = f(x_i)$ ,  $i = 0, \dots, n$ .

Restrikci  $\varphi$  na  $[x_i, x_{i+1}]$  označíme  $\varphi_i$ . Funkci  $\varphi_i$  lze psát ve tvaru

$$\varphi_i(x) = a_i + b_i(x - x_i) + c_i(x - x_i)^2 + d_i(x - x_i)^3.$$

Funkce  $\varphi$  je tedy určena celkem  $4n$  parametry. Podmínky z definice kubického interpolačního splinu nám však dávají jen  $4n - 2$  podmínek. Dá se tedy očekávat, že budeme muset ještě dva parametry zvolit. Nejčastěji se používají okrajové podmínky v krajních bodech  $x_0$  a  $x_n$ , a to tří typů:

- (α)  $\varphi'(x_0) = f'_0$ ,  $\varphi'(x_n) = f'_n$ ;
- (β)  $\varphi''(x_0) = f''_0$ ,  $\varphi''(x_n) = f''_n$ ;
- (γ)  $\varphi''(x_0) = 0$ ,  $\varphi''(x_n) = 0$ .

Kubický interpolační spline určený podmínkou (γ) se nazývá *přirozený spline*.

### 1.1.1 Konstrukce kubického splinu

Budeme konstruovat spline určený podmínkou (β) (jíž je (γ) speciálním případem). Předpokládejme nejprve, že již známe čísla  $M_i = \varphi''(x_i)$ , tzv. *momenity splinu*. Funkce  $\varphi''$  je spojitá a po částech lineární. Označíme-li tedy  $h_i = x_{i+1} - x_i$ , potom pro  $x \in [x_i, x_{i+1}]$  máme

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

Integrováním dostaneme  $\varphi'_i$  a  $\varphi_i$ :

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

Pomocí (známých) hodnot  $\varphi_i(x_i) = f(x_i)$ ,  $\varphi_i(x_{i+1}) = f(x_{i+1})$  určíme konstanty  $A_i$  a  $B_i$ :

$$f(x_i) = \frac{1}{6} M_i h_i^2 + B_i \quad \implies \quad B_i = f(x_i) - \frac{1}{6} M_i h_i^2,$$

$$f(x_{i+1}) = \frac{1}{6} M_{i+1} h_i^2 + A_i h_i + B_i$$

$\implies$

$$A_i = \frac{1}{h_i} \left( f(x_{i+1}) - \frac{1}{6} M_{i+1} h_i^2 - B_i \right) = \frac{f(x_{i+1}) - f(x_i)}{h_i} - \frac{h_i}{6} (M_{i+1} - M_i).$$

Zbývá určit hodnoty momentů:  $M_0$  a  $M_n$  máme zadané, ostatní vypočteme ze spojitosti první derivace (derivací funkce  $\varphi_i$  v bodech  $x_i$ ,  $x_{i+1}$  se rozumí příslušná jednostranná derivace).

$$\begin{aligned}\varphi'_{i-1}(x_i-) &= \frac{1}{2}M_i h_{i-1} + A_{i-1} = \\ &= \frac{1}{2}M_i h_{i-1} + \frac{f(x_i) - f(x_{i-1})}{h_{i-1}} - \frac{h_{i-1}}{6}(M_i - M_{i-1})\end{aligned}$$

$$\begin{aligned}\varphi'_i(x_i+) &= -\frac{1}{2}M_i h_i + A_i = \\ &= -\frac{1}{2}M_i h_i + \frac{f(x_{i+1}) - f(x_i)}{h_i} - \frac{h_i}{6}(M_{i+1} - M_i).\end{aligned}$$

Z rovnosti obou derivací dostaneme po úpravách

$$M_{i-1} \frac{h_{i-1}}{6} + M_i \left( \frac{h_{i-1}}{3} + \frac{h_i}{3} \right) + M_{i+1} \frac{h_i}{6} = \frac{f(x_{i+1}) - f(x_i)}{h_i} - \frac{f(x_i) - f(x_{i-1})}{h_{i-1}},$$

Označíme-li  $\lambda_i = \frac{h_{i-1}}{h_{i-1} + h_i}$ ,  $\mu_i = 1 - \lambda_i = \frac{h_i}{h_{i-1} + h_i}$ , lze rovnici přepsat ve tvaru

$$\lambda_i M_{i-1} + 2M_i + \mu_i M_{i+1} = g_i,$$

kde  $g_i$  je pravá strana původní rovnice, vynásobená výrazem  $\frac{6}{h_{i-1} + h_i}$ . Dostáváme soustavu

$$\begin{array}{lll} 2M_1 & + \mu_1 M_2 & = g_1 - \lambda_1 f''_0 \\ \lambda_2 M_1 & + 2M_2 & + \mu_2 M_3 = g_2 \\ \lambda_3 M_2 & + 2M_3 & + \mu_3 M_4 = g_3 \\ & \vdots & \\ \lambda_{n-1} M_{n-2} & + 2M_{n-1} & = g_{n-1} - \mu_{n-1} f''_n. \end{array}$$

Dokážeme-li nyní existenci a jednoznačnost řešení, budeme hotovi. Všimněme si, že prvky na diagonále matice soustavy jsou vždy 2, zatímco součet všech ostatních prvků v libovolném řádku je mezi 0 a 1 (s výjimkou prvního a posledního dokonce právě 1). Matice je tedy ostře diagonálně dominantní a tedy i regulární.

**Cvičení 2** Dokažte, že každá ostře diagonálně dominantní matice je regulární.

Navíc je matice soustavy tzv. třídiagonální matice, na které se poměrně jednoduše provádí eliminace. Soustava vypadá takto (uvažujeme obecný případ – matici  $n \times n$ ):

$$\begin{pmatrix} a_1 & c_1 & 0 & \dots & 0 & 0 \\ b_1 & a_2 & c_2 & \dots & 0 & 0 \\ \vdots & & \ddots & & \vdots & \\ 0 & & \dots & b_{n-1} & a_n & \end{pmatrix} \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} = \begin{pmatrix} d_1 \\ d_2 \\ \vdots \\ d_n \end{pmatrix}$$

Při přímém chodu Gaussovy eliminace (tvorba horní trojúhelníkové matice) nám zmizí všechny  $b_j$  a na diagonále se nám postupně objeví členy  $A_{jj} = \eta_j$ , kde

$$\eta_1 = a_1, \quad \eta_2 = a_2 - \frac{b_1}{\eta_1} c_1, \quad \text{obecně } \eta_i = a_i - \frac{b_{i-1}}{\eta_{i-1}} c_{i-1} \quad (i = 2, \dots, n),$$

a ve vektoru pravých stran analogicky vzniknou  $\xi_j$ , kde

$$\xi_1 = d_1, \quad \xi_2 = d_2 - \frac{b_1}{\eta_1} \xi_1, \quad \text{obecně } \xi_i = d_i - \frac{b_{i-1}}{\eta_{i-1}} \xi_{i-1} \quad (i = 2, \dots, n).$$

Dostaneme tedy soustavu

$$\begin{pmatrix} \eta_1 & c_1 & 0 & \dots & 0 & 0 \\ 0 & \eta_2 & c_2 & \dots & 0 & 0 \\ \vdots & & \ddots & & \vdots & \\ 0 & & & \dots & 0 & \eta_n \end{pmatrix} \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} = \begin{pmatrix} \xi_1 \\ \xi_2 \\ \vdots \\ \xi_n \end{pmatrix}$$

z níž už snadno vypočítáme neznámé  $y_j$ :

$$y_n = \frac{\xi_n}{\eta_n}, \quad y_{n-1} = \frac{\xi_{n-1} - c_{n-1} y_n}{\eta_{n-1}}, \quad \text{obecně } y_i = \frac{\xi_i - c_i y_{i+1}}{\eta_i} \quad (i = 1, \dots, n-1).$$

Snadno se ukáže, že pro ostře diagonálně dominantní matici vyjdou po eliminaci prvky na diagonále nenulové, takže nemusíme prohazovat řádky a neznámé přímo vypočítáme podle uvedených vztahů.

### 1.1.2 Odhad chyby

Zabývejme se nyní otázkou, jaké chyby se dopustíme, approximujeme-li funkci interpolačním kubickým splinem. Zhruba řečeno, je-li  $f$  dostatečně hladká v  $[a, b]$  a dělení intervalu neomezeně zjemňujeme *vhodným způsobem*, pak interpolační kubické spliny konvergují stejnomořně k  $f$  (případně i s některými derivacemi). Přesnou formulaci tohoto výsledku dává následující věta, kterou uvedeme bez důkazu.

**Věta 3** *Budě  $f \in C^4[a, b]$ . Pak existuje konstanta  $C > 0$  taková, že platí: Nechť  $K > 0$  je konstanta. Dále uvažujme dělení  $D$  intervalu  $[a, b]$ , které je tvořeno body  $a = x_0 < \dots < x_n = b$  a které splňuje podmínu*

$$\frac{\max h_i}{\min h_i} \leq K,$$

kde  $h_i = x_{i+1} - x_i$ . Dále uvažujme okrajové podmínky pro interpolační kubický spline  $\varphi''(x_0) = f''(x_0)$ ,  $\varphi''(x_n) = f''(x_n)$ . Potom

$$\left| f^{(k)} - \varphi^{(k)} \right| \leq CK h^{4-k}, \quad (k = 0, \dots, 3),$$

kde  $h = \max h_i$ , přičemž v případě  $k = 3$  uvažujeme v dělících bodech derivace zleva nebo zprava.

**Důsledek 4** Máme-li posloupnost dělení  $D'$  takových, že  $h \rightarrow 0$ , dostáváme

$$\varphi^{(k)} \rightrightarrows f^{(k)}.$$

**Poznámka 5** Pokud používáme interpolační spline pro interpolaci několika naměřených hodnot, nemůžeme použít okrajové podmínky ve tvaru rovnosti druhých derivací; hodila by se tedy obdobná věta pro přirozený interpolační spline. Nahradíme-li okrajové podmínky ve větě podmínkami  $\varphi''(x_0) = 0$ ,  $\varphi''(x_n) = 0$ , dostaneme (slabší) odhad

$$|f(x) - \varphi(x)| \leq CK h^2, \quad (x \in [a, b]).$$

#### 1.1.3 Spline s napětím

Ne vždy představuje kubický interpolační spline ideální řešení problému. Například při approximaci nespojitých funkcí nebo funkcí s nespojité derivací dostáváme nepříjemnou oscilaci v okolí nespojitosti. Proto se někdy používá modifikovaná konstrukce tzv. *splinu s napětím*. Při této konstrukci opět požadujeme  $\varphi \in C^2[a, b]$ ,  $\varphi(x_i) = f(x_i)$ , ale požadavek, aby  $\varphi$  byla po částech kubická se nahrazuje požadavkem, aby  $\varphi|_{[x_i, x_{i+1}]}$  byla řešením diferenciální rovnice

$$\varphi^{(4)} - \tau \varphi'' = 0,$$

kde  $\tau \geq 0$  je tzv. *napěťový parametr*. Pokud bychom položili  $\tau = 0$ , dostali bychom přesně polynomy stupně nejvyšše 3. Pro  $\tau > 0$  místo funkcí  $x^2$  a  $x^3$  dostaneme fundamentální řešení  $\cosh(t\sqrt{\tau}) - 1$  a  $\sinh(t\sqrt{\tau})$ . Všimněme si, že při pevné funkci  $f$  a dělení  $D$  pro  $\tau \rightarrow \infty$  dostaneme  $\varphi'' \rightarrow 0$ . Význam napěťového parametru je tedy takový, že pro velké  $\tau$  má spline tendenci být téměř lineární v důsledku většího napětí.

#### 1.1.4 Hermiteův spline

Další modifikací je *Hermiteův spline*. Při této konstrukci požadujeme pouze  $\varphi \in C^1[a, b]$ ,  $\varphi|_{[x_i, x_{i+1}]}$  je opět polynom stupně nejvyšše 3 a  $\varphi(x_i) = f(x_i)$ ,  $\varphi'(x_i) = f'(x_i)$ .

V praxi při interpolaci naměřených hodnot ovšem není derivace  $f'$  známa. V takových případech se hodnota  $f'(x_i)$  nahrazuje výrazem

$$\frac{f(x_{i+1}) - f(x_{i-1})}{x_{i+1} - x_{i-1}}$$

(pro  $i = 1, \dots, n-1$ ). Pokud je totiž  $f \in C^2[a, b]$ , je pro  $h \rightarrow 0$

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

**Cvičení 3** Dokažte platnost vztahu (\*).

**Cvičení 4** Za předpokladu  $f \in C^3[a, b]$  najděte přesnější approximaci  $f'(x_i)$  pro  $i = 1, \dots, n-1$  s chybou  $O(h^2)$ .

## NUMERICKÉ ŘEŠENÍ OBYČEJNÝCH DIFERENCIÁLNÍCH ROVNIC

Protože rovnici vyššího řádu lze vždy jednoduše převést na soustavu rovnic prvního řádu, budeme se v této části zabývat pouze rovnicemi prvního řádu, navíc rozřešenými vzhledem k derivaci, tj. rovnicemi tvaru

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

což může reprezentovat buď jednu rovnici nebo celou soustavu – v tom případě řešení  $y = (y^1, \dots, y^s) : \mathbb{R} \rightarrow \mathbb{R}^s$  a funkce  $f = (f^1, \dots, f^n) : \mathbb{R} \times \mathbb{R}^s \rightarrow \mathbb{R}^s$  jsou vektorové funkce. Numerické metody mají své uplatnění hlavně v situacích, kdy přesné (analytické) řešení nedokážeme najít.

**Příklad 1** *Pohyb částice v silovém poli* Trajektorii pohybu částice lze popsat jednou vektorovou funkcí  $\mathbf{x} = \mathbf{x}(t)$ , kde proměnná  $t$  má fyzikální význam času a  $\mathbf{x}(t)$  je poloha částice v čase  $t$ . Newtonův pohybový zákon pak lze formulovat ve tvaru ( $m_p$  je hmotnost částice)

$$m_p \mathbf{x}'' = \mathbf{F}(\mathbf{x}', \mathbf{x}, t),$$

což je vlastně soustava tří obyčejných diferenciálních rovnic druhého řádu, kterou lze převést na soustavu šesti obyčejných diferenciálních rovnic prvního řádu. Funkce  $\mathbf{F}$  zde vyjadřuje závislost působící síly na čase, poloze částice a její rychlosti. Obecně je však tato závislost natolik složitá, že není šance tuto soustavu vyřešit analyticky. Mnohdy nám však stačí najít numerickými metodami řešení přibližné.

**Příklad 2** I u velmi jednoduchých rovnic se nám může stát, že přesné řešení nedokážeme najít. Typickým příkladem je rovnice

$$y' = x^2 + y^2,$$

o níž je dokázáno, že žádné její řešení nelze vyjádřit pomocí elementárních funkcí a jejich neurčitých integrálů.

**Příklad 3** I v případě, že umíme přesné řešení najít, se může stát, že se bez numerických metod neobejdeme. Rovnice  $y' = 1 - 2xy$  s počáteční podmínkou  $y(0) = 0$  má řešení

$$y(x) = e^{-x^2} \int_0^x e^{t^2} dt.$$

Chceme-li znát jeho hodnotu v nějakém bodě  $x$ , potřebujeme numericky vypočítat určitý integrál.

**Příklad 4** Rovnice

$$y'' + \frac{A}{x} y' + \left( \frac{B}{x^2} + C + Dx^2 \right) y = 0$$

je příkladem rovnice Fuchsova typu. Její řešení lze najít metodou mocninných řad, ale pro většinu argumentů  $x$  řada konverguje pomalu. Nahradíme-li  $Dx^2$  členem  $Dx^3$ , nelze metodu mocninných řad použít.

**2.1 Příklady diskrétních metod**

Uvažujme rovnici  $y' = f(x, y)$  na intervalu  $[a, b]$  s počáteční podmínkou  $y(a) = \eta$ . Nechť  $y : [a, b] \rightarrow \mathbb{R}$  je řešení uvažovaného problému. Uvažujme dělení intervalu  $[a, b]$  tak, že  $a = x_0 < \dots < x_N \leq b$ ,  $x_n = a + nh$ , kde  $h > 0$  nazýváme krokem metody. Budeme se snažit přiřadit bodům  $x_i$  přibližné hodnoty  $y_i$ . Uvedeme zde tři jednoduché příklady.

**2.1.1 Eulerova metoda**

Je to nejjednodušší metoda numerického řešení ODR. Předpokládejme, že máme řešení  $y$  diferenciální rovnice a v intervalu  $[a, b]$  máme dva body  $x_n < x_{n+1}$  uvažovaného dělení. Předpokládejme navíc, že řešení je třídy  $C^2$ . Taylorův vzorec nám dává  $y(x_{n+1}) = y(x_n) + hy'(x_n) + O(h^2)$ . Odtud

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

Zanedbáme-li výraz  $O(h)$  a nahradíme hodnoty  $y(x_i)$  přesného řešení hodnotami  $y_i$  přibližného řešení, dostaneme formuli

$$\frac{1}{h}(y_{n+1} - y_n) = f(x_n, y_n).$$

Dostaváme tedy rekurentní vztahy

$$\begin{aligned} y_0 &= \eta = \text{počáteční podmínka k diferenciální rovnici}, \\ y_{n+1} &= y_n + hf(x_n, y_n), \quad n \geq 0. \end{aligned}$$

**Cvičení 5** Je-li dokonce  $y \in C^3[a, b]$ , lze derivaci approximovat přesněji:

$$y'\left(x_n + \frac{h}{2}\right) = \frac{y(x_{n+1}) - y(x_n)}{h} + O(h^2).$$

**2.1.2 Rungeova-Kuttova metoda**

Vyjdeme-li ze vztahu uvedeného v předchozím cvičení a vztahů

$$\begin{aligned} y'\left(x_n + \frac{h}{2}\right) &= f\left(x_n + \frac{h}{2}, y(x_n + \frac{h}{2})\right), \\ y(x_n + \frac{h}{2}) &= y(x_n) + \frac{h}{2}y'(x_n) + O(h^2), \\ y'(x_n) &= f(x_n, y(x_n)), \end{aligned}$$

dostaneme

$$\frac{1}{h}(y_{n+1} - y_n) = f\left(x_n + \frac{h}{2}, y_n + \frac{h}{2}f(x_n, y_n)\right).$$

Tímto postupem jsme dospěli k rekurentním vztahům

$$y_0 = \eta, \quad y_{n+1} = y_n + hf\left(x_n + \frac{h}{2}, y_n + \frac{h}{2}f(x_n, y_n)\right), \quad n \geq 0.$$

Tato metoda je *Rungeova-Kuttova metoda druhého řádu*. Obecným postupem při odvození Rungeových-Kuttových metod se budeme zabývat později.

### 2.1.3 Dvoukroková metoda

Společnou vlastností obou uvedených metod bylo, že hodnota  $y_{n+1}$  se vypočítávala pouze z jedné předcházející hodnoty  $y_n$  (a samozřejmě z  $x_n$  a  $h$ ). U vícekrokových metod používáme rekurentní vyjádření z více předešlých hodnot.

Mějme nyní opět  $y \in C^3[a, b]$ ,  $x_n, x_{n+1}, x_{n+2}$  tři po sobě jdoucí body ekvidistantního dělení  $[a, b]$  (tedy  $x_n = a + nh$ , kde  $h$  je krok metody). Pak máme

$$y(x_{n+1}) = y(x_n) + hy'(x_n) + \frac{1}{2}h^2y''(x_n) + O(h^3), \quad (1)$$

$$y(x_{n+2}) = y(x_n) + 2hy'(x_n) + 2h^2y''(x_n) + O(h^3). \quad (2)$$

Odečtením čtyřnásobku (1) od (2) dostaneme

$$y(x_{n+2}) - 4y(x_{n+1}) = -3y(x_n) - 2hy'(x_n) + O(h^3),$$

odkud dosazením rovnice  $y'(x_n) = f(x_n, y(x_n))$  dojdeme k rekurentnímu vztahu

$$y_{n+2} - 4y_{n+1} + 3y_n = -2hf(x_n, y_n),$$

kde  $y_0 = \eta$  a  $y_1$  vypočteme pomocí některé jednokrokové metody. Popsaná metoda je dvoukroková – další hodnotu počítáme pomocí dvou předcházejících.

## 2.2 Obecné jednokrokové metody

Při těchto metodách je dán krok  $h > 0$  a počáteční podmínka  $y(x_0) = \eta$ . Uzly jsou  $x_n = a + nh$ ,  $n \geq 0$ . Hodnoty přibližného řešení počítáme podle rekurentního vztahu

$$y_0 = \eta, \quad y_{n+1} = y_n + h\Phi(x_n, y_n, h).$$

Funkce  $\Phi$  (která závisí na  $f$ ) se nazývá *přírůstková funkce*. Například u Eulerovy metody jsme měli  $\Phi(x, y, h) = f(x, y)$ , u Rungeovy-Kuttovy metody druhého řádu je  $\Phi(x, y, h) = f(x + \frac{h}{2}, y + \frac{h}{2}f(x, y))$ .

*Chybou metody* (v bodě  $x_n$ ) rozumíme rozdíl  $e_n = y_n - y(x_n)$ , tzv. *akumulovanou diskretizační chybu*. Naším cílem je

- (1) Najít odhad  $e_n$  v závislosti na  $h$ ;
- (2) ukázat, že v jistém smyslu je  $e_n \rightarrow 0$  pro  $h \rightarrow 0$ .

Abychom měli zaručenu existenci a jednoznačnost řešení, budeme předpokládat, že  $f : [a, b] \times \mathbb{R} \rightarrow \mathbb{R}$  je spojitá a že je lipschitzovská vzhledem k  $y$ , tj. že

$$|f(x, y_1) - f(x, y_2)| \leq L|y_1 - y_2| \quad \forall x \in [a, b], \quad y_1, y_2 \in \mathbb{R}.$$

Z Picardovy věty (viz přednášky z matematické analýzy) vyplývá, že za těchto předpokladů má úloha

$$y' = f(x, y), \quad y(a) = \eta \tag{*}$$

právě jedno řešení  $y : [a, b] \rightarrow \mathbb{R}$ . Navíc předpokládejme (budeme se zabývat jen rozumnými metodami), že i funkce  $\Phi : [a, b] \times \mathbb{R} \times [0, h_0] \rightarrow \mathbb{R}$  je spojitá a splňuje Lipschitzovu podmíinku vzhledem k  $y$ .

**Definice 2** Řekneme, že jednokroková metoda s přírůstkovou funkcí  $\Phi$  je konvergentní, jestliže platí následující tvrzení: kdykoli je  $y : [a, b] \rightarrow \mathbb{R}$  řešením úlohy (\*), je

$$\forall x \in [a, b] : \lim_{\substack{h \rightarrow 0+ \\ x_n=x}} y_n = y(x),$$

kde  $y_n$  je přibližné řešení v uzlu  $x_n$ .

**Definice 3** Jiná definice konvergence Krok  $h > 0$  nám určuje uzly  $x_n$ , k nimž pomocí jednokrokové metody přiřadíme přibližné hodnoty řešení. Označme  $e(h)$  maximální chybu, tj.

$$e(h) = \max_{\substack{x_n \in [a, b] \\ x_n = a + nh}} |e_n|.$$

Řekneme, že metoda je *konvergentní*, jestliže platí následující tvrzení: kdykoli je  $y : [a, b] \rightarrow \mathbb{R}$  řešením úlohy (\*), je

$$\lim_{h \rightarrow 0+} e(h) = 0.$$

**Poznámka 6** Snadno nahlédneme, že konvergence podle druhé definice implikuje konvergenci podle první definice.

Před odvozením některých jednokrokových metod odvodíme jedno pomocné lemma, které nám bude často užitečné.

**Lemma 1** Nechť  $A, B \geq 0$ ,  $N \geq 1$  celé a nechť je splněna podmínka

$$|\xi_{n+1}| \leq A|\xi_n| + B, \quad n = 0, \dots, N-1.$$

Potom platí odhad

$$|\xi_n| \leq A^n |\xi_0| + \begin{cases} \frac{A^n - 1}{A - 1} B & \text{pro } A \neq 1, \\ Bn & \text{pro } A = 1. \end{cases} \tag{*}$$

**Cvičení 6** Dokažte toto lemma.

Při aplikaci lemmatu 1 je často  $A = 1 + \delta$ ,  $\delta > 0$ . Použijeme-li nerovnost  $1 + \delta < e^\delta$ , pak z (\*) plyne

$$|\xi_n| \leq e^{n\delta} |\xi_0| + \frac{e^{n\delta} - 1}{\delta} B. \quad (**)$$

Pro  $L > 0$  a  $x \in \mathbb{R}$  označme

$$E_L(x) = \frac{e^{Lx} - 1}{L}. \quad (***)$$

( $E_L$  je tzv. Lipschitzova funkce.)

### 2.2.1 Konvergance jednokrokových metod

**Předpoklad** ( $P_\Phi$ ): Předpokládejme, že přírůstková funkce  $\Phi : [a, b] \times \mathbb{R} \times [0, h_0] \rightarrow \mathbb{R}$ ,  $\Phi = \Phi(x, y, h)$ , je spojitá a splňuje Lipschitzovu podmíinku vzhledem k  $y$  s konstantou  $L > 0$ :

$$|\Phi(x, y, h) - \Phi(x, y^*, h)| \leq L|y - y^*|, \quad x \in [a, b], \quad y, y^* \in \mathbb{R}, \quad h \in [0, h_0]. \quad (+)$$

**Definice 4** Řekneme, že jednokroková metoda s přírůstkovou funkcí  $\Phi$  pro řešení diferenciální rovnice  $y' = f(x, y)$  je *konsistentní*, jestliže

$$\Phi(x, y, 0) = f(x, y), \quad x \in [a, b], \quad y \in \mathbb{R}.$$

**Věta 7** Jednokroková metoda s přírůstkovou funkcí  $\Phi$  splňující předpoklad ( $P_\Phi$ ) je konvergentní, právě když je konsistentní.

Důkaz vynecháme, protože nás zajímá odhad chyby metody  $e_n$ . Odhad chyby metody provádime ve dvou krocích.

a) Dosadíme přesné řešení do uvažované metody. Dostaneme vztah

$$y(x_n + h) - y(x_n) - h\Phi(x_n, y(x_n), h) = h\delta_n, \quad x_n, x_n + h \in [a, b], \quad h \in (0, h_0).$$

b) Odhadneme  $\delta_n$  a z tohoto odhadu odvodíme odhad chyby  $e_n$ .

Veličinu  $\delta_n$  nazýváme lokální relativní diskretizační chybou v uzlu  $x_n$ . Obecně *lokální relativní diskretizační chybu* (krátce chybu diskretizace) v bodě  $x$  definujeme jako výraz

$$\Delta(x, y(x), h) - \Phi(x, y(x), h),$$

kde

$$\Delta(x, y(x), h) = \frac{y(x + h) - y(x)}{h}, \quad x, x + h \in [a, b], \quad h \in (0, h_0),$$

je tzv. *přesný relativní přírůstek*.

**Věta 8** Nechť  $y : [a, b] \rightarrow I\!\!R$  je přesné řešení úlohy  $y' = f(x, y)$  v intervalu  $[a, b]$ ,  $y(a) = \eta$ ,  $y_n$  pro  $x_n \in [a, b]$  jsou hodnoty přibližného řešení vypočtené pomocí jednokrokové metody s přírůstkovou funkcí  $\Phi$  splňující předpoklad  $(P_\Phi)$ . Nechť navíc existují konstanty  $N, p > 0$  takové, že

$$|\Delta(x, y(x), h) - \Phi(x, y(x), h)| \leq Nh^p, \quad x, x+h \in [a, b], \quad h \in (0, h_0).$$

Potom pro chybu metody (tj. akumulovanou diskretizační chybu)  $e_n = y_n - y(x_n)$  platí odhad

$$|e_n| \leq Nh^p E_L(x_n - a), \quad x_n \in [a, b], \quad h \in (0, h_0). \quad (2.2.1)$$

Důkaz: Zřejmě máme  $e_0 = y_0 - y(x_0) = 0$ . Dále máme vztahy

$$y_{n+1} = y_n + h\Phi(x_n, y_n, h),$$

$$y(x_{n+1}) = y(x_n) + h\Phi(x_n, y(x_n), h) + h\delta_n,$$

kde

$$\delta_n = \Delta(x_n, y(x_n), h) - \Phi(x_n, y(x_n), h)$$

pro  $x_n, x_{n+1} \in [a, b]$ ,  $h \in (0, h_0)$ . Odtud vyplývá odečtením druhé rovnice od první

$$e_{n+1} = e_n + h(\Phi(x_n, y_n, h) - \Phi(x_n, y(x_n), h)) - h(\Delta(x_n, y(x_n), h) - \Phi(x_n, y(x_n), h)).$$

Použijeme-li předpoklad  $(P_\Phi)$  a vztah (2.2.1), dostaneme ihned nerovnost

$$|e_{n+1}| \leq (1 + hL)|e_n| + Nh^{p+1}, \quad x_n, x_{n+1} \in [a, b], \quad h \in (0, h_0).$$

Aplikace lemmatu 1 dává odhad

$$\begin{aligned} |e_n| &\leq \frac{(1 + hL)^n - 1}{hL} Nh^{p+1} \leq \\ &\leq \frac{e^{nhL} - 1}{L} Nh^p = Nh^p E_L(x_n - a), \quad x_n \in [a, b], \quad h \in (0, h_0), \end{aligned}$$

□

**Poznámka 9** Jednokrokové metody mají tu výhodu, že v každém kroku (při přechodu od  $x_n$  k  $x_{n+1}$ ) lze měnit délku kroku. Tzn., že můžeme uvažovat obecné dělení  $a = x_0 < x_1 < \dots \leq b$  intervalu  $[a, b]$ , položit  $h_n = x_{n+1} - x_n$  a definovat

$$y_{n+1} = y_n + h_n \Phi(x_n, y_n, h_n).$$

### 2.3 Odvození některých jednokrokových metod

#### 2.3.1 Metody založené na přímém použití Taylorova vzorce

V tomto odstavci budeme konstruovat jednokrokovou metodu  $p$ -tého řádu za předpokladu, že přesné řešení  $y$  je třídy  $C^{p+1}$ . Z Taylorova vzorce

$$y(x+h) = y(x) + \sum_{k=1}^p \frac{y^{(k)}(x)}{k!} h^p + \frac{y^{(p+1)}(\tilde{x})}{(p+1)!} h^{p+1} \quad (2.3.2)$$

plyne

$$\frac{1}{h}(y(x+h) - y(x)) = \sum_{k=1}^p \frac{y^{(k)}(x)}{k!} h^{k-1} + \frac{y^{(p+1)}(\tilde{x})}{(p+1)!} h^p, \quad (2.3.3)$$

kde  $\tilde{x} \in [x, x+h]$ . Nyní použijeme diferenciální rovnici a pokusíme se vypočítat několik prvních derivací funkce  $y$ :

$$\begin{aligned} y'(x) &= f(x, y(x)), \\ y''(x) &= \frac{d}{dx} f(x, y(x)) = \frac{\partial f}{\partial x}(x, y(x)) + y'(x) \frac{\partial f}{\partial y}(x, y(x)) = \\ &= \frac{\partial f}{\partial x}(x, y(x)) + f(x, y(x)) \frac{\partial f}{\partial y}(x, y(x)), \\ y'''(x) &= \frac{d}{dx} \left\{ \left( \frac{\partial f}{\partial x} + f \frac{\partial f}{\partial y} \right) (x, y(x)) \right\} = \frac{\partial}{\partial x} \{ \dots \} + f \cdot \frac{\partial}{\partial y} \{ \dots \}. \end{aligned}$$

Pro zjednodušení zápisu definujme *diferenciální operátor*<sup>1</sup> takto: pro funkci  $\varphi \in C^1(G)$ , kde  $G \subset \mathbb{R}^2$ , buďž

$$D\varphi = \frac{\partial \varphi}{\partial x} + f \cdot \frac{\partial \varphi}{\partial y}.$$

Mocninou rozumíme skládání, tj.  $D^0\varphi := \varphi$  a pro  $k \geq 0$  klademe  $D^{k+1}\varphi := D(D^k\varphi)$ . Pomocí operátoru  $D$  můžeme snadno vyjádřit derivace funkce  $y$ :

$$\begin{aligned} y'(x) &= (D^0 f)(x, y(x)), \\ y''(x) &= (D^1 f)(x, y(x)), \\ y'''(x) &= (D^2 f)(x, y(x)), \\ &\vdots \\ y^{(k)}(x) &= (D^{k-1} f)(x, y(x)). \end{aligned}$$

Dosazením do (2.3.3) dostaneme

$$\Delta(x, y(x), h) = \sum_{k=1}^p \frac{(D^{k-1} f)(x, y(x))}{k!} h^{k-1} + \frac{y^{(p+1)}(\tilde{x})}{(p+1)!} h^p,$$

<sup>1</sup>Jedná se o zobrazení z jistého prostoru funkcí do nějakého jiného prostoru funkcí.

což nás vede k tomu, abychom použili přírůstkovou funkci

$$\Phi(x, y, h) = \sum_{k=1}^p \frac{(D^{k-1}f)(x, y)}{k!} h^{k-1}.$$

Pak je totiž

$$|\delta(x, h)| = \left| \frac{1}{h} (y(x+h) - y(x)) - \Phi(x, y(x), h) \right| \leq \left| \frac{y^{(p+1)}(\tilde{x})}{(p+1)!} h^p \right| \leq Nh^p,$$

kde

$$N = \max_{x \in [a, b]} \left| \frac{y^{(p+1)}}{(p+1)!} \right|.$$

**Cvičení 7** Vypočtěte  $D^2 f$ ,  $D^3 f$  a pro  $f(x, y) = x^2 + y^2$  vypočtěte  $D^4 f$ .

### 2.3.2 Rungeovy-Kuttovy metody

Získali jsme sice jednokrokovou metodu libovolně vysokého řádu, ale pro praxi je téměř nepoužitelná. Za prvé proto, že počítání mocnin operátoru  $D$  vede brzy k příliš složitému výrazu (viz cvičení 7). Druhý (a hlavní) důvod spočívá v tom, že v definici funkce  $\Phi$  vystupuje nejen funkce  $f$  sama, ale i její parciální derivace. V dalším označme

$$\tilde{\Phi}(x, y, h) = \sum_{k=1}^p \frac{(D^{k-1}f)(x, y)}{k!} h^{k-1}.$$

Tuto přírůstkovou funkci použijeme k odvození *Rungeových-Kuttových metod*, u nichž se  $\Phi$  počítá pouze pomocí hodnot  $f$ . Jejich přírůstková funkce bude ve tvaru

$$\Phi(x, y, h) = \sum_{k=1}^P w_k k_i(x, y, h),$$

kde

$$\begin{aligned} k_1(x, y, h) &= f(x, y), \\ k_2(x, y, h) &= f(x + \alpha_2 h, y + \beta_{21} h k_1(x, y, h)), \\ &\vdots \\ k_i(x, y, h) &= f \left( x + \alpha_i h, y + h \sum_{j=1}^{i-1} \beta_{ij} k_j(x, y, h) \right), \quad i = 2, \dots, P. \end{aligned}$$

Zde  $P$ ,  $w_i$ ,  $\alpha_i$  a  $\beta_{ij}$  jsou vhodně zvolené konstanty (tak, aby výsledná metoda byla řádu  $p$ ). V dalším se budeme snažit určit hodnoty těchto konstant tak, abychom dostali odhad  $\Phi(x, y, h) - \tilde{\Phi}(x, y, h) = O(h^p)$ .

**Příklad 5** Pokusme se odvodit Rungeovu-Kuttovu metodu druhého rádu. Tzn., že  $p = 2$ . Zkusíme zvolit počet členů také  $P = 2$ . Napišme si vztahy pro  $\Phi$  a  $\tilde{\Phi}$ :

$$\begin{aligned}\Phi(x, y, h) &= w_1 f(x, y) + w_2 f(x + \alpha_2 h, y + \beta_{21} h f(x, y)) \\ \tilde{\Phi}(x, y, h) &= f(x, y) + \frac{h}{2} (Df)(x, y) = \\ &= f(x, y) + \frac{h}{2} \left( \frac{\partial f}{\partial x}(x, y) + f(x, y) \frac{\partial f}{\partial y}(x, y) \right).\end{aligned}$$

Dále rozepišme funkční hodnotu z prvního vztahu podle Taylorova vzorce:<sup>2</sup>

$$\begin{aligned}f(x + \alpha_2 h, y + \beta_{21} h f(x, y)) &= f(x, y) + \left( \alpha_2 h \frac{\partial}{\partial x} + \beta_{21} h f \frac{\partial}{\partial y} \right) f(x, y) + \\ &+ \frac{1}{2!} \left( \alpha_2 h \frac{\partial}{\partial x} + \beta_{21} h f \frac{\partial}{\partial y} \right)^2 f(x + \theta h, y + \theta \beta_{21} h f(x, y)) = \\ &= f(x, y) + \alpha_2 h \frac{\partial f}{\partial x}(x, y) + \beta_{21} h f(x, y) \frac{\partial f}{\partial y}(x, y) + \\ &+ \frac{1}{2} \left[ \alpha_2^2 h^2 \frac{\partial^2 f}{\partial x^2} + 2\alpha_2 \beta_{21} h^2 f(x, y) \frac{\partial^2 f}{\partial x \partial y} + \beta_{21}^2 h^2 f^2(x, y) \frac{\partial^2 f}{\partial y^2} \right] \\ &\quad (x + \theta h, y + \theta \beta_{21} h f(x, y)).\end{aligned}$$

Poslední sčítanec na pravé straně ovšem není nic jiného než  $O(h^2)$ . Dostáváme tedy

$$\Phi(x, y, h) = (w_1 + w_2) f(x, y) + w_2 \alpha_2 h \frac{\partial f}{\partial x}(x, y) + w_2 \beta_{21} h f(x, y) \frac{\partial f}{\partial y}(x, y) + O(h^2).$$

Srovnejme nyní koeficienty u  $f$ ,  $\frac{\partial f}{\partial x}$ ,  $f \frac{\partial f}{\partial y}$  ve vyjádření  $\Phi$  a  $\tilde{\Phi}$ . Budou-li stejné, bude i  $\Phi - \tilde{\Phi} = O(h^2)$ . Získáváme vztahy

$$w_1 + w_2 = 1, \quad w_2 \alpha_2 = \frac{1}{2}, \quad w_2 \beta_{21} = \frac{1}{2},$$

což jsou tři rovnice pro čtyři neznámé. Jednu neznámou si tedy můžeme zvolit; zvolme  $w_2 = \alpha \neq 0$  (jinak by nemohl platit vztah  $\alpha_2 w_2 = \frac{1}{2}$ ). Dostaneme

$$w_1 = 1 - \alpha, \quad w_2 = \alpha, \quad \alpha_2 = \beta_{21} = \frac{1}{2\alpha}.$$

<sup>2</sup>Taylorův vzorec pro funkce  $n$  proměnných: bud  $f \in C^k(\Omega)$ ,  $\Omega \subseteq \mathbb{R}^n$  otevřená,  $a, b \in \Omega$  a předpokládejme, že i celá úsečka s krajními body  $a, b$  leží v  $\Omega$ ; potom

$$f(b) = \sum_{j=0}^{k-1} \frac{1}{j!} \left[ \sum_{i=1}^n (b_i - a_i) \frac{\partial}{\partial x_i} \right]^j f(a) + \frac{1}{k!} \left[ \sum_{i=1}^n (b_i - a_i) \frac{\partial}{\partial x_i} \right]^k f(a + \theta(b - a))$$

pro nějaké  $\theta \in [0, 1]$ . Umocňováním hranatých závorek se rozumí umocňování (tedy skládání) tohoto diferenciálního operátoru. K důkazu stačí rozepsat  $g(b)$ , kde  $g(t) = f(a + t(b - a))$ , podle jednorozměrného Taylorova vzorce a vyjádřit  $g^{(j)}$  pomocí  $f$ .

Tyto hodnoty nám dávají celou třídu Rungeových-Kuttových metod druhého řádu. Nejpoužívanější hodnoty parametru  $\alpha$  jsou  $1$ ,  $\frac{3}{4}$  a  $\frac{1}{2}$ .

$$\begin{aligned}\alpha = 1 : \quad & y_{n+1} = y_n + h f(x_n + \frac{h}{2}, y_n + \frac{h}{2} f(x_n, y_n)) \\ \alpha = \frac{3}{4} : \quad & y_{n+1} = y_n + \frac{h}{4} \left( f(x_n, y_n) + 3f(x_n + \frac{2}{3}h, y_n + \frac{2}{3}hf(x_n, y_n)) \right) \\ \alpha = \frac{1}{2} : \quad & y_{n+1} = y_n + \frac{h}{2} (f(x_n, y_n) + f(x_n + h, y_n + hf(x_n, y_n)))\end{aligned}$$

V případě, že máme více metod stejného řádu, vybíráme metodu buď tak, aby koeficienty byly co nejjednodušší (jednoduchá metoda), nebo tak, aby konstanta  $N$  v odhadu

$$|\Delta(x, y(x), h)| \leq Nh^p$$

byla co nejmenší.

#### *Rungeovy-Kuttovy metody 3. řádu*

V tomto případě postačuje  $P = 3$ , tedy  $\Phi(x, y, h) = w_1 k_1 + w_2 k_2 + w_3 k_3$ . Uvedeme dva příklady:

(a)

$$\begin{aligned}y_{n+1} &= y_n + h \left( \frac{2}{9}k_1 + \frac{1}{3}k_2 + \frac{4}{9}k_3 \right) \\ k_1 &= f(x, y) \\ k_2 &= f(x + \frac{h}{2}, y + \frac{h}{2}k_1) \\ k_3 &= f(x + \frac{3}{4}h, y + \frac{3}{4}hk_2)\end{aligned}$$

(b)

$$\begin{aligned}y_{n+1} &= y_n + \frac{h}{6} (k_1 + 4k_2 + k_3) \\ k_1 &= f(x, y) \\ k_2 &= f(x + \frac{h}{2}, y + \frac{h}{2}k_1) \\ k_3 &= f(x + h, y - hk_1 + 2hk_2)\end{aligned}$$

#### *Rungeovy-Kuttovy metody 4. řádu*

Nejčastěji jsou používány metody čtvrtého řádu. U těchto metod máme naposledy  $P = p$ , tedy  $\Phi(x, y, h) = w_1 k_1 + w_2 k_2 + w_3 k_3 + w_4 k_4$ . (U metod vyššího řádu je  $P > p$ .) Uvedeme tři příklady.

*Standardní formule:*

$$\begin{aligned} w_1 &= w_4 = \frac{1}{6}, & w_2 = w_3 &= \frac{1}{3} \\ k_1 &= f(x, y) \\ k_2 &= f\left(x + \frac{h}{2}, y + \frac{h}{2}k_1\right) \\ k_3 &= f\left(x + \frac{h}{2}, y + \frac{h}{2}k_2\right) \\ k_4 &= f(x + h, y + hk_3) \end{aligned}$$

*"Tříosminová" formule:*

$$\begin{aligned} w_1 &= w_4 = \frac{1}{8}, & w_2 = w_3 &= \frac{3}{8} \\ \alpha_2 &= \frac{1}{3}, & \alpha_3 &= \frac{2}{3}, & \alpha_4 &= 1 \\ \beta_{21} &= \frac{1}{3}, & \beta_{31} &= -\frac{1}{3}, & \beta_{32} &= 1 \\ \beta_{41} &= 1, & \beta_{42} &= -1, & \beta_{43} &= 1 \end{aligned}$$

*Gillova formule:*

$$\begin{aligned} w_1 &= w_4 = \frac{1}{6}, & w_2 &= \frac{1}{3}\left(1 - \frac{1}{\sqrt{2}}\right), & w_3 &= \frac{1}{3}\left(1 + \frac{1}{\sqrt{2}}\right) \\ \alpha_2 &= \alpha_3 = \frac{1}{2}, & \alpha_4 &= 1 \\ \beta_{21} &= \frac{1}{2}, & \beta_{31} &= \frac{1}{2}(\sqrt{2} - 1), & \beta_{32} &= 1 - \frac{1}{\sqrt{2}} \\ \beta_{41} &= 0, & \beta_{42} &= -\frac{1}{\sqrt{2}}, & \beta_{43} &= 1 + \frac{1}{\sqrt{2}} \end{aligned}$$

Gillova formule je sice o něco složitější, ale byla u ní provedena optimalizace konstanty  $N$ . Odvozením Rungeových-Kuttových metod řádu  $p > 4$  se zabýval např. prof. Huťa z Bratislavky. Pro  $p > 4$  vyjde  $P > p$  (např. pro  $p = 6$  musíme vzít osm členů), metody jsou tedy složitější, a proto se příliš nepoužívají.

## 2.4 Použitelnost odhadů chyb

Podívejme se nyní na efektivnost odhadu, který jsme získali. Uvažujme např. Eulerovu metodu. Ukázali jsme, že pokud je přesné řešení třídy  $C^2$ , je

$$|e_n| \leq NE_L(x_n - a)h,$$

kde  $N$  je polovina maxima absolutní hodnoty druhé derivace přesného řešení  $y$  na intervalu  $[a, b]$ . Tento odhad se dá o něco zlepšit, uvědomíme-li si, že pro odhad chyby v bodě  $x_n$  stačí řešit rovnici na  $[a, x_n]$  (interval  $(x_n, b]$  nemá žádný vliv).

Můžeme tedy položit  $b = x_n$ ,  $N(x_n) = \frac{1}{2} \max_{[a,x_n]} |y''|$  a dostaneme zlepšený odhad

$$|e_n| \leq N(x_n)E_L(x_n - a)h.$$

Uvažujme dva příklady:

$$\begin{array}{ll} y_0 = 1, y' = y & y_0 = 1, y' = -y \\ y(x) = e^x & y(x) = e^{-x} \\ L = 1 & L = 1 \\ N(x) = \frac{1}{2}e^x & N(x) = \frac{1}{2} \\ E_1(x_n) = e^{x_n} - 1 & E_1(x_n) = e^{x_n} - 1 \\ |e_n| \leq \frac{1}{2}he^{x_n}(e^{x_n} - 1) & |e_n| \leq \frac{1}{2}h(e^{x_n} - 1) \end{array}$$

Řekněme, že pomocí numerického řešení druhé úlohy chceme vypočítat  $e^{-5}$  s přesností  $10^{-3}$ . Chceme tedy najít  $h$  tak, aby

$$\begin{aligned} \frac{1}{2}h(e^5 - 1) &\leq 10^{-3}, \text{ takže} \\ h &\leq \frac{2 \cdot 10^{-3}}{e^5 - 1} \doteq \frac{1}{73707}. \end{aligned}$$

Experimentálně však zjistíme, že při volbě  $h = 2^{-6} = \frac{1}{64}$  vyjde  $e_n = -0,000261$ . Vidíme tedy, že odhad z věty je silně nadzadený; při jeho odvozování se v každém kroku počítá s nejhorší možností. Ve skutečnosti většinou dostáváme výsledky výrazně lepší.

Je ale třeba vzít v úvahu, že konstanta  $N$  závisí na přesném řešení, které obvykle neznáme. Proto odhad z věty 8 nám dává pouze představu o chování chyby v závislosti na kroku metody a není prakticky použitelný. Proto hledáme odhadu jiného typu, které můžeme získat na základě vypočteného přibližného řešení a dat úlohy. Toto jsou tzv. *aposteriorní odhad*. Jedním takovým odhadem se budeme zabývat dále.

#### 2.4.1 Odhad chyby metodou polovičního kroku

Víme, že pokud příručková funkce  $\Phi$  splňuje Lipschitzovu podmínu vzhledem k  $y$  a pokud

$$\left| \frac{1}{h} (y(x+h) - y(x)) - \Phi(x, y(x), h) \right| \leq Nh^p,$$

potom platí

$$|y_n - y(x_n)| \leq NE_L(x_n - a)h^p.$$

Dá se navíc ukázat, že pokud jsou funkce  $f$  a  $\Phi$  dostatečně hladké, existuje funkce  $e : [a, b] \rightarrow \mathbb{R}$  taková, že

$$e_n = h^p e(x_n) + O(h^{p+1}). \quad (2.4.4)$$

Tento vztah chybu neodhaduje, ale approximuje. Funkce  $e$  samozřejmě opět závisí na vlastnostech přesného řešení  $y$ .

Předpokládejme, že na tutéž úlohu použijeme postupně metodu s krokem  $2h$  a  $h$ . Dostaneme uzly a odpovídající hodnoty přibližného řešení:

$$\begin{array}{ll} x_n^{(2h)} = a + n(2h) \dots & y_n^{(2h)} \\ x_n^{(h)} = a + nh \quad \dots & y_n^{(h)} \end{array}$$

Vidíme, že  $x_n^{(2h)} = x_{2n}^{(h)}$ . V těchto bodech můžeme porovnat hodnoty přibližných řešení. Užitím vztahu (2.4.4) dostaneme

$$\begin{aligned} e_n^{(2h)} &= y_n^{(2h)} - y(x_n^{(2h)}) = (2h)^p e(x_n^{(2h)}) + O(h^{p+1}), \\ e_{2n}^{(h)} &= y_{2n}^{(h)} - y(x_{2n}^{(h)}) = h^p e(x_n^{(2h)}) + O(h^{p+1}) \end{aligned}$$

Odtud plyne, že

$$\begin{aligned} y_n^{(2h)} - y_{2n}^{(h)} &= (2^p - 1)h^p e(x_n^{(2h)}) + O(h^{p+1}), \\ h^p e(x_n^{(2h)}) &= \frac{y_n^{(2h)} - y_{2n}^{(h)}}{2^p - 1} + O(h^{p+1}), \\ e_{2n}^{(h)} &= \frac{y_n^{(2h)} - y_{2n}^{(h)}}{2^p - 1} + O(h^{p+1}) \approx \frac{y_n^{(2h)} - y_{2n}^{(h)}}{2^p - 1}. \end{aligned}$$

Aproximaci

$$e_{2n}^{(h)} \approx \frac{y_n^{(2h)} - y_{2n}^{(h)}}{2^p - 1} \quad (2.4.5)$$

nazýváme *odhadem chyby metodou polovičního kroku*. Jedná se o tzv. *aposteriorní odhad chyby*, který získáme na základě přibližného řešení (a případně dat úloh). Numerické experimenty ukazují, že v řadě praktických aplikacích tento odhad dává spolehlivé výsledky.

**Poznámka 10** U jednokrokových metod můžeme v libovolném bodě změnit délku kroku. Pracujeme tak, že počítáme s krokem  $2h$  a  $h$ . Pokud zjistíme, že odhad chyby v nějakém bodě překračuje povolenou mez, pokračujeme od tohoto bodu s polovičním krokem. Naopak, pokud je chyba výrazně nižší než naše tolerance, můžeme krok opět zvětšit (abychom ušetřili časovou náročnost).

Existují dokonce *adaptivní metody*, u nichž se automaticky mění délka kroku a řád metody s cílem minimalizovat chybu a časovou náročnost.

#### 2.4.2 Zaokrouhlovací chyby

Začneme jednoduchým příkladem. Uvažujme soustavu dvou lineárních rovnic

$$\begin{pmatrix} 10^{-6} & 1 \\ 1 & 1 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} 1 \\ 2 \end{pmatrix}.$$

Determinant matice soustavy je  $10^{-6} - 1$ , což je dostatečně daleko od nuly. Matice soustavy je tedy regulární. Použijeme-li Gaussovu eliminaci, dostaneme řešení

$$x_1 = (1 - x_2) \cdot 10^6, \quad x_2 = \frac{2 - 10^6}{1 - 10^6}.$$

Přibližně máme  $x_2 \doteq 0,999999$ . Počítejme nyní na pět platných číslic. Pak ovšem vyjde  $x_2 = 1$ , a odtud  $x_1 = 0$ . Při zkoušce dostaneme v první rovnici  $0 + 1 = 1$ , ale ve druhé  $0 + 1 = 1 \neq 2$ , což je příliš velká nepřesnost. Pokud bychom ale rovnice prohodili, vyšly by přibližné hodnoty  $x_1$  i  $x_2$  rovny jedné, tedy správné (i zkouška by ve zvolené přesnosti vyšla správně). Obecně je vhodné při řešení soustavy lineárních rovnic prohazovat rovnice tak, aby se na hlavní diagonále neobjevovala příliš malá čísla. (Tento proces se nazývá *pivotace*.)

### Zaokrouhlovací chyby u jednokrokových metod

Dosud jsme přepokládali, že při výpočtu přibližného řešení všechny operace probíhají přesně. Nyní se zamyslíme nad vlivem zaokrouhlovacích chyb. Zaokrouhlování modelujeme tak, že každému  $\alpha \in \mathbb{R}$  přiřadíme jeho zaokrouhlenou hodnotu  $\alpha^*$ . Pro jednoduchost předpokládejme, že vstupní data jsou už zaokrouhlená, tedy  $a = a^*$ ,  $h = h^*$ ,  $\eta = \eta^*$ . Přibližné řešení počítané se zaokrouhlováním označme  $\tilde{y}_n$ . Můžeme psát

$$\begin{aligned}\tilde{y}_0 &= \eta = y_0, \\ \tilde{y}_{n+1} &= \tilde{y}_n + h\Phi(x_n, \tilde{y}_n, h) + \varepsilon_{n+1},\end{aligned}$$

kde  $\varepsilon_{n+1}$  se nazývá *lokální zaokrouhlovací chyba*. Zavedeme ještě *akumulovanou zaokrouhlovací chybu* v uzlu  $x_n$  jako  $r_n = \tilde{y}_n - y_n$ .

**Věta 11** *Budě  $\Phi(x, y, h) : [a, b] \times \mathbb{R} \times [0, h_0] \rightarrow \mathbb{R}$  L-lipschitzovská v y. Nechť platí  $|\varepsilon_k| \leq \varepsilon$  pro  $x_k, x_{k+1} \in [a, b]$ . Potom*

$$|r_n| \leq \frac{\varepsilon}{h} E_L(x_n - a), \quad x_n \in [a, b], \quad h \in (0, h_0).$$

*Důkaz:* Máme  $r_0 = 0$  a

$$\begin{aligned}\tilde{y}_{n+1} &= \tilde{y}_n + h\Phi(x_n, \tilde{y}_n, h) + \varepsilon_{n+1}, \\ y_{n+1} &= y_n + h\Phi(x_n, y_n, h).\end{aligned}$$

Tudíž,

$$|r_{n+1}| \leq |r_n + hLr_n| + |\varepsilon_{n+1}| \leq |r_n|(1 + hL) + \varepsilon.$$

Použijeme-li (stejně jako u věty o odhadu diskretizační chyby) „kumulační lemma“ ze cvičení 5, dostaneme

$$|r_n| \leq \frac{(1 + hL)^n - 1}{hL} \varepsilon \leq \frac{e^{nL} - 1}{L} \frac{\varepsilon}{h} = E_L(x_n - a) \frac{\varepsilon}{h}.$$

□

**Poznámka 12** Velikost horního odhadu samozřejmě o ničem nesvědčí. Jedná se o *nejhorší možný scénář* (worst scenario), který může nastat. Numerické experimenty však ukazují, že v praxi je pro malá  $h$  opravdu  $r_n \approx \frac{1}{h}$ . To ve svém důsledku znamená, že zmenšením kroku sice zmenšíme diskretizační chybu metody, ale zvýšíme vliv zaokrouhlovacích chyb.

Hodilo by se tedy najít způsob, jak zjistit velikost zaokrouhlovací chyby. To je možné, pokud můžeme úlohu současně řešit v jednoduché a dvojnásobné přesnosti. Potom bude zaokrouhlovací chyba při dvojnásobné přesnosti zanedbatelná ve srovnání s jednoduchou přesností a můžeme tak získat approximaci zaokrouhlovacích chyb. Převažuje-li diskretizační chyba, je třeba krok zjemnit, převažuje-li zaokrouhlovací chyba, je třeba krok zvětšit.

## 2.5 Soustavy lineárních diferenčních rovnic

Označme  $\mathbb{N} = \{1, 2, 3, \dots\}$ ,  $\mathbb{N}_0 = \{0, 1, 2, \dots\}$ .

**Definice 5** Buď  $k \in \mathbb{N}$ ,  $F_n : \mathbb{R}^{k+1} \rightarrow \mathbb{R}$  (případně  $F_n : \mathbb{C}^{k+1} \rightarrow \mathbb{C}$ ),  $n \in \mathbb{N}_0$ . Pak systém vztahů

$$F_n(y_n, \dots, y_{n+k}) = 0, \quad n \in \mathbb{N}_0 \quad (2.5.6)$$

nazýváme *soustavou diferenčních rovnic*. Řešením soustavy nazveme posloupnost  $(y_n)_{n=0}^{\infty}$  splňující (2.5.6).

**Příklad 6** Mějme soustavu rovnic ( $k = 3$ )

$$y_{n+3}^2 - \left( y_{n+2}^2 - y_{n+1}^2 + \sqrt[3]{y_n^2} \right)^4 = 0, \quad n \in \mathbb{N}_0.$$

Vidíme, že  $y_{n+3}$  lze vypočítat z předchozích tří členů. Vyjdeme-li z hodnot  $y_0, y_1, y_2$ , můžeme postupně vypočítat  $y_3, y_4, \dots$ . Čísla  $y_0, y_1, y_2$  se nazývají *počáteční podmínky*.

**Cvičení 8** Kolik řešení má tato soustava pro pevně zvolené počáteční podmínky  $y_0, y_1, y_2$ ?

**Definice 6** Jsou-li funkce  $F_n$  lineární, mluvíme o *soustavě lineárních diferenčních rovnic*. Můžeme ji psát ve tvaru

$$\sum_{\nu=0}^k \alpha_{\nu n} y_{n+\nu} = \gamma_n, \quad n \in \mathbb{N}_0. \quad (2.5.7)$$

Čísla  $\gamma_n$  se nazývají *pravé strany*. Jsou-li všechny pravé strany nulové, dostaneme homogenní soustavu. Soustavě (2.5.7) můžeme vždy přiřadit homogenní soustavu

$$\sum_{\nu=0}^k \alpha_{\nu n} y_{n+\nu} = 0, \quad n \in \mathbb{N}_0. \quad (2.5.8)$$

**Lemma 2** Uvažujme soustavu (2.5.7) a k ní příslušnou homogenní soustavu (2.5.8). Pak platí:

- (i) Množina  $V$  všech řešení soustavy (2.5.8) je lineární prostor.
- (ii) Jsou-li  $\{y_n\}_{n=0}^{\infty}$  a  $\{z_n\}_{n=0}^{\infty}$  řešení soustavy (2.5.7), je jejich rozdíl řešením soustavy (2.5.8).
- (iii) Je-li  $\{w_n\}_{n=0}^{\infty}$  řešením (2.5.7) a  $\{y_n\}_n \in V$ , pak  $\{w_n + y_n\}_{n=0}^{\infty}$  je řešením soustavy (2.5.7).
- (iv) Je-li  $\{w_n\}_{n=0}^{\infty}$  řešením soustavy (2.5.7), pak k libovolnému řešení  $\{z_n\}_{n=0}^{\infty}$  soustavy (2.5.7) existuje právě jedno  $\{y_n\}_n \in V$  takové, že  $z_n = y_n + w_n$ ; jinak řečeno, označíme-li  $W$  množinu řešení soustavy (2.5.7), můžeme psát  $W = V + w$ .

Důkaz pěnecháme čtenáři.

**Definice 7** Řekneme, že soustava (2.5.7) je řádu  $k$ , jestliže všechny koeficienty  $\alpha_{kn}$ ,  $n \in \mathbb{N}_0$ , jsou nenulové.

**Definice 8** Posloupnosti  $\{y_n^\mu\}_{n \in \mathbb{N}_0} \in V$ ,  $\mu = 1, \dots, m$ , nazveme lineárně nezávislé, jestliže platí:

$$\sum_{\mu=1}^m a_\mu y_n^\mu = 0, \quad \forall n = 0, \dots, k-1 \Rightarrow a_1 = a_2 = \dots = a_m = 0.$$

Je zřejmé, že tato podmínka je splněna, právě když matice

$$\mathbb{M} = (y_n^\mu)_{\substack{n=0, \dots, k-1 \\ \mu=1, \dots, m}}$$

má hodnost  $m$ . Maximální počet lineárně nezávislých prvků z  $V$  je roven  $k$ .

**Definice 9** Systém  $k$  prvků z  $V$  lineárně nezávislých nazveme fundamentálním systémem (FS) soustavy homogenních rovnic.

**Věta 13** Nechť  $\{z_n^\mu\}_{n \in \mathbb{N}_0} \in V$ ,  $\mu = 1, \dots, k$ , je FS řešení soustavy  $k$ -tého řádu a  $\{y_n\}_{n \in \mathbb{N}_0} \in V$ . Pak posloupnost  $\{y_n\}_{n \in \mathbb{N}_0}$  je lineární kombinací posloupností  $\{z_n^\mu\}_{n \in \mathbb{N}_0}$ ,  $\mu = 1, \dots, k$ .

*Důkaz:* Z definice FS plyne, že existují konstanty  $a_1, \dots, a_k$  takové, že

$$y_n = \sum_{\mu=1}^k a_\mu z_n^\mu \quad \text{pro } n = 0, \dots, k-1.$$

Označme

$$z_n = y_n - \sum_{\mu=1}^k a_\mu z_n^\mu, \quad n \in \mathbb{N}_0.$$

Pak  $\{z_n\}_{n \in \mathbb{N}_0} \in V$  a  $z_0 = \dots = z_{k-1} = 0$ . Poněvadž  $\alpha_{kn} \neq 0$  pro všechna  $n \in \mathbb{N}_0$ , nutně  $z_n = 0$  pro všechna  $n \in \mathbb{N}_0$  a tudíž,

$$y_n = \sum_{\mu=1}^k a_\mu z_n^\mu, \quad \forall n \in \mathbb{N}_0.$$

□

**Důsledek 14** Prvky FS tvoří bazi v prostoru V.

### 2.5.1 Nalezení fundamentálního systému

**Definice 10** Soustavou tvaru

$$\sum_{\nu=0}^k \alpha_\nu y_{n+\nu} = 0, \quad n \in \mathbb{N}_0, \quad (2.5.9)$$

nazveme soustavou lineárních diferenčních rovnic s *konstantními koeficienty*. Tudíž,

$$\alpha_{\nu n} = \alpha_\nu, \quad \forall \nu = 0, \dots, k \quad n \in \mathbb{N}_0.$$

Tato soustava je řádu k, jestliže  $\alpha_k \neq 0$ .

Hledejme řešení této soustavy ve tvaru  $y_n = \xi^n$ , kde  $\xi \in C$ . Dosazením do soustavy dostaneme

$$0 = \sum_{\nu=0}^k \alpha_\nu \xi^{n+\nu} = \xi^n \sum_{\nu=0}^k \alpha_\nu \xi^\nu, \quad n \in \mathbb{N}_0,$$

což je ekvivalentní s podmínkou

$$0 = \rho(\xi) = \sum_{\nu=0}^k \alpha_\nu \xi^\nu,$$

kterou nazýváme *charakteristickou rovnicí* a polynom  $\rho$  je tzv. *charakteristický polynom*.

Nechť soustava (2.5.9) je řádu k, tj.  $\alpha_k \neq 0$ . Pak  $\rho$  má stupeň k. Je zřejmé, že  $\{y_n\}_{n \in \mathbb{N}_0} = \{\xi^n\}_{n \in \mathbb{N}_0}$  je řešením soustavy (2.5.9), právě když  $\xi$  je kořenem charakteristického polynomu  $\rho$ . Tento polynom má právě k kořenů, počítáme-li každý tolikrát, kolik činí jeho násobnost.

Rozlišme dva případy

- 1) Polynom  $\rho$  má právě k různých kořenů  $\xi_1, \dots, \xi_k$ .

Pak lze sestrojit k řešení soustavy  $\{y_n^\mu\}_{n \in \mathbb{N}_0}$ ,  $\mu = 1, \dots, k$ , kde  $y_n^\mu = \xi_\mu^n$ .

Podle definice tvoří tato řešení FS, právě když matici

$$\mathbb{M} = \begin{pmatrix} 1 & \xi_1 & \dots & \xi_1^{k-1} \\ 1 & \xi_2 & \dots & \xi_2^{k-1} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & \xi_k & \dots & \xi_k^{k-1} \end{pmatrix}$$

je regulární. Její determinant (známý jako Vandermondeův) má hodnotu

$$\det \mathbb{M} = \prod_{\substack{i < j \\ j=1,\dots,k}} (\xi_j - \xi_i) \neq 0.$$

Tudíž uvažované posloupnosti tvoří FS.

2) *Obecný případ.*

**Věta 15** Nechť  $\xi_1, \dots, \xi_m \in C$  ( $m \leq k$ ) jsou navzájem různé kořeny charakteristického polynomu  $\rho$  s násobnostmi  $p_1, \dots, p_m$  (takže  $k = \sum_{\mu=1}^m p_\mu$ ). Pak k posloupností s prvky

$$(P) \quad \begin{aligned} y_n^{\mu,1} &= \xi_\mu^n, \quad n \in \mathbb{N}_0, \\ y_n^{\mu,2} &= n\xi_\mu^{n-1}, \quad n \in \mathbb{N}_0, \\ &\vdots \\ y_n^{\mu,p_\mu} &= n(n-1)\dots(n-p_\mu+2)\xi_\mu^{n-p_\mu+1}, \quad n \in \mathbb{N}_0, \end{aligned} \quad \mu = 1, \dots, m$$

tvoří FS řešení soustavy (2.5.9) řádu  $k$ . (Je-li  $\xi_\mu = 0$ , pak klademe  $0 \cdot \xi_\mu^{-\nu} = 0$  pro  $\nu > 0$ .)

*Důkaz:* Dokažme, že uvedené posloupnosti jsou řešení uvažované soustavy. Jestliže  $\xi_\mu = 0$ , pak má charakteristický polynom tvar

$$\rho(\xi) = \sum_{\nu=p_\mu}^k \alpha_\nu \xi^\nu$$

(tudíž  $\alpha_0, \dots, \alpha_{p_\mu-1} = 0$ ) a soustava (2.5.9) má tvar

$$\sum_{\nu=p_\mu}^k \alpha_\nu y_{n+\nu} = 0, \quad n \in \mathbb{N}_0.$$

Dosazením snadno ověříme, že posloupnosti  $(P)$  jsou řešeními, poněvadž mají nenulové prvky pouze na pozicích  $n < p_\mu$ .

Nechť  $\xi_\mu \neq 0$  je kořen polynomu  $\rho$  s násobností  $p_\mu$ . Pak  $\xi_\mu$  je kořenem polynomu  $f_n(\xi) = \xi^n \rho(\xi)$  násobnosti  $p_\mu$  pro každé  $n \in \mathbb{N}_0$ . Tudíž,  $p_\mu - 1$  derivací  $f_n$  je rovno nula v bodě  $\xi = \xi_\mu$ , takže

$$\begin{aligned} \sum_{\nu=0}^k \alpha_\nu \xi_\mu^{n+\nu} &= 0, \quad n \in \mathbb{N}_0, \\ \sum_{\nu=0}^k \alpha_\nu (n+\nu) \xi_\mu^{n+\nu-1} &= 0, \quad n \in \mathbb{N}_0, \\ &\vdots \\ \sum_{\nu=0}^k \alpha_\nu (n+\nu)(n+\nu-1)\dots(n+\nu-p_\mu+2) \xi_\mu^{n+\nu-p_\mu+1} &= 0, \quad n \in \mathbb{N}_0, \end{aligned}$$

Tzn., že posloupnosti  $(P)$  jsou řešeními soustavy (2.5.9).

Dokažme nyní, že řešení  $(P)$  jsou lineárně nezávislá, což je ekvivalentní s tím, že příslušná matice  $\mathbb{M}$ , jejíž řádky jsou tvořeny prvními  $k$  prvky posloupnosti  $(P)$ , je regulární. V  $n$ -tém sloupci této matice ( $n = 0, \dots, k-1$ ) se nachází prvky

$$\begin{aligned} & \xi_1^n, n\xi_1^{n-1}, \dots, n(n-1) \dots (n-p_1+2)\xi_1^{n-p_1+1}, \dots, \\ & \xi_m^n, n\xi_m^{n-1}, \dots, n(n-1) \dots (n-p_m+2)\xi_m^{n-p_m+1}. \end{aligned}$$

Matice  $\mathbb{M}$  je regulární, právě když její sloupce jsou lineárně nezávislé  $k$ -rozměrné vektory. Nechť tomu tak není. Pak existují takové koeficienty  $a_n$ ,  $n = 0, \dots, k-1$ , že  $\sum_{n=0}^{k-1} |a_n| > 0$  a

$$\begin{aligned} & \sum_{n=0}^{k-1} a_n \xi_\mu^n = 0, \\ & \sum_{n=0}^{k-1} a_n n \xi_\mu^{n-1} = 0, \\ & \quad \vdots \quad \mu = 1, \dots, m, \\ & \sum_{n=0}^{k-1} a_n n(n-1) \dots (n-p_\mu+2) \xi_\mu^{n-p_\mu+1} = 0, \end{aligned}$$

což znamená, že polynom  $\sum_{n=0}^{k-1} a_n \xi^n$  stupně  $\leq k-1$  má aspoň  $m$  různých kořenů  $\xi_1, \dots, \xi_m$  s násobnostmi  $p_1, \dots, p_m$ , což je spor, protože platí, že  $\sum_{\mu=1}^m p_\mu = k$ .

□

### 2.5.2 Nalezení reálného fundamentálního systému

Uvažujme rovnici

$$\sum_{\nu=0}^k \alpha_\nu y_{n+\nu} = 0$$

s reálnými koeficienty  $\alpha_j$ . Charakteristický polynom má pak také reálné koeficienty, jeho kořeny tedy jsou

$$\xi_1, \dots, \xi_r \in \mathbb{R}$$

$$\gamma_1, \overline{\gamma_1}, \dots, \gamma_s, \overline{\gamma_s} \in \mathbb{C} \setminus \mathbb{R}$$

(všechny kořeny opakujeme tolíkrát, kolik činí jejich násobnost, tedy  $r+2s=k$ ). Fundamentální systém získaný z naší věty je tvořen posloupnostmi (vyplývá z chování aritmetických operací na  $\mathbb{C}$ )

$$\begin{aligned} \{y_n^\mu\}_{n=0}^\infty & \quad \mu = 1, \dots, r & y_n^\mu \in \mathbb{R} \\ \{z_n^\mu\}_{n=0}^\infty & \quad \mu = 1, \dots, s \\ \{\overline{z_n^\mu}\}_{n=0}^\infty & \quad \mu = 1, \dots, s & z_n^\mu \in \mathbb{C} \end{aligned}$$

Reálné posloupnosti z prvního řádku můžeme převzít do našeho nového systému. Jako zbylých  $2s$  posloupností vezmeme

$$\{\operatorname{Re} z_n^\mu\}_{n=0}^\infty, \quad \{\operatorname{Im} z_n^\mu\}_{n=0}^\infty, \quad \mu = 1, \dots, s.$$

Ze vztahů  $\operatorname{Re} z = \frac{1}{2}(z + \bar{z})$ ,  $\operatorname{Im} z = \frac{1}{2i}(z - \bar{z})$  vidíme snadno, že nové posloupnosti jsou lineárními kombinacemi starých, jsou to tedy řešení. K důkazu lineární nezávislosti si stačí uvědomit, že staré posloupnosti lze podobně jednoduše vyjádřit pomocí nových použitím vztahů  $z = \operatorname{Re} z + i \operatorname{Im} z$ ,  $\bar{z} = \operatorname{Re} z - i \operatorname{Im} z$ .

**Poznámka 16** Kniha [H] obsahuje kapitolu věnovanou soustavám diferenčních rovnic. Je vidět, že teorie soustav lineárních diferenčních rovnic s konstantními koeficienty se podobá teorii lineárních diferenciálních rovnic s konstantními koeficienty. Stejně tak existuje i metoda pro nalezení partikulárního řešení nehomogenní soustavy pomocí fundamentálního systému řešení příslušné homogenní rovnice (*Duhamelův princip*). Tato metoda se podobá variaci konstant, blíže viz [H].

## 2.6 Vícekrokové metody

Opět budeme hledat přibližné řešení úlohy

$$y' = f(x, y), \quad y(a) = \eta$$

v uzlech  $x_n = a + nh$ . Na rozdíl od jednokrokových metod budeme tentokrát počítat hodnoty přibližného řešení  $y_n$  pomocí několika předchozích hodnot.

**Příklad 7** Dříve jsme odvodili metodu

$$-y_{n+2} + 4y_{n+1} - 3y_n = 2hf(x_n, y_n).$$

To nás vede k zobecnění: obecnou  $k$ -krokovou metodou rozumíme rekurentní předpis typu

$$\sum_{\nu=0}^k a_\nu y_{n+\nu} = h \sum_{\nu=0}^k \beta_\nu f_{n+\nu}, \quad (2.6.10)$$

kde  $f_j = f(x_j, y_j)$ , za podmínek  $\alpha_k \neq 0$  a  $|\alpha_0| + |\beta_0| > 0$ .

Pomocí předpisu (2.6.10) můžeme počítat hodnoty přibližného řešení až od  $y_k$ . Hodnoty  $y_0 (= \eta), y_1, \dots, y_{k-1}$  se nazývají počáteční podmínky pro  $k$ -krokovou metodu. Hodnoty  $y_1, \dots, y_{k-1}$  vypočteme některou jednokrokovou metodou. Podle způsobu výpočtu je třeba rozlišit dva případy.

V jednodušším případě  $\beta_k = 0$  máme

$$\begin{aligned} \sum_{\nu=0}^k \alpha_\nu y_{n+\nu} &= h \sum_{\nu=0}^{k-1} \beta_\nu f_{n+\nu} = h \sum_{\nu=0}^{k-1} \beta_\nu f(x_{n+\nu}, y_{n+\nu}) \\ y_{n+k} &= \frac{1}{\alpha_k} \sum_{\nu=0}^{k-1} (h\beta_\nu f_{n+\nu} - \alpha_\nu y_{n+\nu}). \end{aligned}$$

Protože lze hodnotu  $y_{n+k}$  přímo vypočítat, mluvíme o *explicitní metodě*. Hlavní výhodou této (např. oproti jednokrokovým metodám vyšších řádů) je to, že

každou z hodnot  $f_j$  stačí vypočítat jednou (v dalších krocích už si ji pamatu jeme). Na jednu hodnotu přibližného řešení tak připadá jedna vypočítaná hodnota funkce  $f$ .

Ve složitějším případě  $\beta_k \neq 0$  máme

$$y_{n+k} = \frac{\beta_k}{\alpha_k} h f(x_{n+k}, y_{n+k}) + \sum_{\nu=0}^{k-1} \left( \frac{\beta_\nu}{\alpha_k} h f(x_{n+\nu}, y_{n+\nu}) - \frac{\alpha_\nu}{\alpha_k} y_{n+\nu} \right).$$

Hodnotu  $y_{n+k}$  tedy přímo nevypočteme, ale dostaneme pro ni pouze rovnici. Mluvíme o *implicitní metodě*. Naše rovnice (obecně nelineární) pro  $y_{n+k}$  je tvaru  $y_{n+k} = F(y_{n+k})$ , kterou řešíme iterační metodou: zvolíme počáteční hodnotu  $y_{n+k}^0$  a pro  $s \geq 0$  počítáme  $y_{n+k}^{s+1} = F(y_{n+k}^s)$ . Pokud  $f$  je  $L$ -lipschitzovská v  $y$ , pak pro dostatečně malé  $h$  je  $F$  kontrakce (lipschitzovské zobrazení s konstantou menší než 1) a podle Banachovy věty o kontrakci je

$$y_{n+k} = \lim_{s \rightarrow \infty} y_{n+k}^s$$

pro libovolnou počáteční hodnotu  $y_{n+k}^0$ .

Pro praktické použití je však třeba odpovědět na dvě otázky: jak volit počáteční hodnotu  $y_{n+k}^0$  a kolik iterací provést. Pro volbu počáteční hodnoty je nejjednodušší vzít buď přímo předchozí hodnotu ( $y_{n+k}^0 = y_{n+k-1}$ ) nebo extrapolovat z předchozích dvou ( $y_{n+k}^0 = 2y_{n+k-1} - y_{n+k-2}$ ). Iterační proces ukončíme, pokud  $|y_{n+k}^s - y_{n+k}^{s+1}| < \varepsilon$ , kde  $\varepsilon$  je předepsaná přesnost.

Počáteční approximaci  $y_{n+k}^0$  lze také získat pomocí explicitní metody

$$\sum_{\nu=0}^k \alpha_\nu^* y_{n+\nu} = h \sum_{\nu=0}^{k-1} \beta_\nu^* f_{n+\nu}.$$

Klademe tedy

$$y_{n+k}^0 = \frac{1}{\alpha_k^*} \left( h \sum_{\nu=0}^{k-1} \beta_\nu^* f_{n+\nu} - \sum_{\nu=0}^{k-1} \alpha_\nu^* y_{n+\nu} \right). \quad (2.6.11)$$

Potom vypočteme několik approximací  $y_{n+k}^s$  uvažované implicitní metody a klademe  $y_{n+k} := y_{n+k}^m$ . Nejjednodušší volba je  $m = 1$ :

$$y_{n+k} = \left( h \beta_k f(x_{n+k}, y_{n+k}^0) + \sum_{\nu=0}^{k-1} \beta_\nu f_{n+\nu} - \sum_{\nu=0}^{k-1} \alpha_\nu y_{n+\nu} \right) / \alpha_k. \quad (2.6.12)$$

Z rovnice (2.6.11) vypočteme  $y_{n+k}^0$ , dosadíme do (2.6.12)) a vypočteme  $y_{n+k}$ . Tato metoda se nazývá *metoda prediktor-korektor*. Explicitní metoda (2.6.11) se nazývá *prediktorová formule*, implicitní metoda (2.6.12) je *korektorková formule*. Metody prediktor-korektor jsou nejfektivnější vícekrokové metody. V každém kroku se počítají pouze dvě hodnoty funkce  $f$ .

**Cvičení 9** Uvažujme metodu danou následujícími formulemi:

$$\begin{aligned} y_{n+1} &= y_n + hf_n && \text{(prediktor)} \\ y_{n+1} &= y_n + \frac{1}{2}h(f_n + f_{n+1}) && \text{(korektor).} \end{aligned}$$

Zapište tuto metodu ve tvaru jednoho vzorce pro výpočet  $y_{n+1}$ . Ukažte, že výsledkem je Rungeova-Kuttova metoda druhého rádu.

## 2.7 Některé vlastnosti obecných vícekrokových metod

Uvažujme obecnou  $k$ -krokovou metodu

$$\sum_{\nu=0}^k \alpha_\nu y_{n+\nu} = h \sum_{\nu=0}^k \beta_\nu f_{n+\nu}, \quad (2.7.13)$$

kde  $\alpha_k \neq 0$ ,  $|\alpha_0| + |\beta_0| > 0$ ,  $n = 0, 1, \dots$  (pokud  $x_{n+k} \in [a, b]$ ). Na začátku výpočtu je třeba určit počáteční podmínky

$$y_0 = \eta, y_1, \dots, y_{k-1}. \quad (2.7.14)$$

Ty se určí pomocí vhodné jednokrokové metody, takže lze psát  $y_\mu = \eta_\mu(h)$ ,  $\mu = 1, \dots, k-1$ .

**Definice 11** Řekneme, že  $k$ -kroková metoda (2.7.13) je *konvergentní*, jestliže pro řešení  $y : [a, b] \rightarrow \mathbb{R}$  úlohy  $y' = f(x, y)$ ,  $y(a) = \eta$  s libovolnou  $f$ , která je spojitá v  $[a, b] \times \mathbb{R}$  a lipschitzovská v  $y$  a pro libovolné  $\eta$  platí následující tvrzení: jestliže  $y_n$  je přibližné řešení získané pomocí metody (2.7.13) s počátečními podmínkami (2.7.14) takovými, že  $\lim_{h \rightarrow 0^+} \eta_\mu(h) = \eta$ , pro  $\mu = 0, 1, \dots, k-1$ , pak platí

$$\forall x \in [a, b] : \lim_{\substack{h \rightarrow 0^+ \\ x_n = x}} y_n = y(x).$$

**Definice 12** Říkáme, že metoda (2.7.13) je *stabilní* (podle Dahlquista), jestliže všechny kořeny polynomu  $\rho(\xi) = \sum \alpha_\nu \xi^\nu$  jsou v absolutní hodnotě nejvýše rovny jedné a všechny kořeny, jejichž absolutní hodnota je rovna jedné, jsou jednoduché.

**Definice 13** Řekneme, že metoda (2.7.13) je *rádu*  $p \geq 0$ , jestliže platí

$$\sum_{\nu=0}^k \alpha_\nu = 0$$

a pro  $p > 0$  navíc

$$\sum_{\nu=0}^k \frac{\alpha_\nu \nu^s}{s!} = \sum_{\nu=0}^k \frac{\beta_\nu \nu^{s-1}}{(s-1)!} \quad (s = 1, \dots, p).$$

Má-li metoda (2.7.13) řád  $p \geq 1$ , říkáme, že je *konsistentní*.

**Věta 17** Každá konvergentní metoda je stabilní.

*Důkaz:* Mějme konvergentní metodu (2.7.13). Přibližné řešení  $y_n$  konverguje za podmínek uvedených v definici k přesnému řešení. Uvažujme úlohu  $y' = 0$ ,  $y(0) = 0$ : její přesné řešení je  $y(x) = 0$  (tato úloha určitě podmínky splňuje). Pak máme

$$\sum \alpha_\nu y_{n+\nu} = 0 \quad n = 0, 1, \dots \quad (2.7.15)$$

$$y_\mu = \eta_\mu(h) \quad \mu = 0, 1, \dots, k-1$$

a za předpokladu  $\eta_\mu(h) \rightarrow 0$  pro  $h \rightarrow 0+$  víme, že

$$\forall x > 0 : \lim_{\substack{h \rightarrow 0+ \\ x_n=x}} y_n = 0.$$

Vztah (2.7.15) je soustava lineárních diferenčních rovnic s konstantními koeficienty a charakteristickým polynomem  $\rho(\xi) = \sum \alpha_\nu \xi^\nu$ . Nechť  $\xi = re^{i\varphi}$  ( $r \geq 0$ ) je kořen polynomu  $\rho$ : pak posloupnost  $\{\xi^n\}_n$  je řešením (2.7.15). Protože koeficienty  $\alpha_\nu$  jsou reálné, víme z teorie, že i  $\{w_n\}_{n=0}^\infty$  a  $\{z_n\}_{n=0}^\infty$ , kde  $w_n = hr^n \cos n\varphi$  a  $z_n = hr^n \sin n\varphi$ , jsou řešení (2.7.15). Jsou to tedy přibližná řešení vyhovující počátečním podmínkám

$$hr^\mu \cos \mu\varphi \xrightarrow{h \rightarrow 0+} 0, \quad hr^\mu \sin \mu\varphi \xrightarrow{h \rightarrow 0+} 0$$

Odtud pro každé  $x > 0$

$$\begin{aligned} \lim_{\substack{h \rightarrow 0+ \\ x_n=x}} z_n &= \lim_{\substack{h \rightarrow 0+ \\ x_n=x}} w_n = 0 \iff \lim_{\substack{h \rightarrow 0+ \\ x_n=x}} |z_n + iw_n| = 0 \iff \lim_{\substack{h \rightarrow 0+ \\ x_n=x}} hr^n = 0 \iff \\ &\iff x \lim_{n \rightarrow \infty} \frac{1}{n} r^n = 0 \iff |\xi| = r \leq 1. \end{aligned}$$

Předposlední ekvivalence vychází z toho, že ta poněkud záhadně vyhlížející limita není ve skutečnosti nic jiného než limita pro  $n \rightarrow \infty$  s dosazením  $h = \frac{x}{n}$ .

Nyní mějme kořen  $\xi = re^{i\varphi}$  násobnosti alespoň dvě. Potom je  $\{n\xi^{n-1}\}_{n=0}^\infty$  řešením (2.7.15). Stejně jako výše vidíme, že i  $z_n$  a  $w_n$ , kde  $z_n = n\sqrt{hr^n} \cos n\varphi$  a  $w_n = n\sqrt{hr^n} \sin n\varphi$  jsou řešení. Jsou to tedy přibližná řešení pro počáteční podmínky

$$\mu\sqrt{hr^\mu} \cos \mu\varphi \rightarrow 0, \quad \mu\sqrt{hr^\mu} \sin \mu\varphi \rightarrow 0 \text{ for } h \rightarrow 0+, \quad \mu = 0, \dots, k-1.$$

Odtud stejným způsobem jako v první části dostaneme

$$\sqrt{x} \lim_{n \rightarrow \infty} r^n \sqrt{n} = 0 \iff |\xi| = r < 1.$$

□

**Věta 18** Je-li metoda (2.7.13) konvergentní, pak je také konsistentní, tj.

$$\sum_{\nu=0}^k \alpha_\nu = 0, \quad \sum_{\nu=0}^k \alpha_\nu \nu = \sum_{\nu=0}^k \beta_\nu.$$

*Důkaz:* Uvažujme úlohu  $y' = 0$  v  $[0, b]$ ,  $b > 0$ , tentokrát s počáteční podmínkou  $y(0) = 1$ . Pro přibližné řešení opět platí (2.7.15), tj.

$$\sum_{\nu=0}^k \alpha_\nu y_{n+\nu} = 0 \quad n = 0, 1, \dots$$

Pro libovolné  $h > 0$  volme počáteční podmínky  $y_0 = y_1 = \dots = y_{k-1} = 1$ . Zřejmě je splněna podmínka  $y_\mu = \eta_\mu(h) = 1 \rightarrow 1$  pro  $h \rightarrow 0+$ . Metoda (2.7.13) je konvergentní, tedy

$$\forall x > 0 : \lim_{\substack{h \rightarrow 0+ \\ x_n = x}} y_n = 1, \quad (2.7.16)$$

přičemž limitu opět chápeme jako limitu pro  $n \rightarrow \infty$ , kde  $y_n$  je hodnota přibližného řešení s krokem  $h = \frac{x}{n}$ . Počáteční podmínky ani koeficienty rovnice (2.7.15) nezávisí na kroku  $h$ , nezávisí na něm tedy ani přibližné řešení. Ze vztahu (2.7.16)

$$\lim_{n \rightarrow \infty} y_n = 1 \implies \lim_{n \rightarrow \infty} y_{n+\nu} = 1 \quad \nu = 0, \dots, k.$$

Provedeme-li tedy limitní přechod v (2.7.15), dostaneme  $\sum \alpha_\nu = 0$ .

Pro druhou podmítku uvažujme úlohu  $y' = 1$ ,  $y(0) = 0$  (řešení je  $y(x) = x$ ). Metoda (2.7.13) tady vypadá takto:

$$\sum_{\nu=0}^k \alpha_\nu y_{n+\nu} = h \sum_{\nu=0}^k \beta_\nu \quad n = 0, 1, \dots \quad (2.7.17)$$

Pro počáteční podmínky vyžadujeme, aby  $y_\mu = \eta_\mu(h) \rightarrow 0$  pro  $h \rightarrow 0+$ ,  $\mu = 0, 1, \dots, k-1$ . Hledejme řešení (2.7.17) ve tvaru  $y_n = Kx_n = Khn$ . Po dosazení do (2.7.17) postupně dostaneme

$$\begin{aligned} Kh \sum_{\nu=0}^k \alpha_\nu (n + \nu) &= h \sum_{\nu=0}^k \beta_\nu, \\ Kh \sum_{\nu=0}^k \alpha_\nu n + Kh \sum_{\nu=0}^k \alpha_\nu \nu &= h \sum_{\nu=0}^k \beta_\nu, \\ K \sum_{\nu=0}^k \alpha_\nu \nu &= \sum_{\nu=0}^k \beta_\nu. \end{aligned}$$

Víme, že  $\sum_{\nu=0}^k \alpha_\nu = 0$ , takže  $\rho(1) = 0$ . Z předcházející věty vyplývá, že 1 je jednoduchým kořenem polynomu  $\rho$ . Tidíž,  $\rho'(1) \neq 0$ , což znamená, že  $\sum_{\nu=0}^k \alpha_\nu \nu \neq 0$ . Můžeme tedy poslední rovnost touto sumou vydělit, načež dostáváme

$$K = \frac{\sum_{\nu=0}^k \beta_\nu}{\sum_{\nu=0}^k \alpha_\nu \nu}.$$

Z výše uvedených úvah plyne, že pro tuto hodnotu  $K$  je  $y_n = Kx_n$ ,  $n = 0, 1, \dots$ , řešením (2.7.17). Zvolíme-li počáteční podmínky metody  $\eta_\mu(h) = K\mu h \rightarrow 0$  pro  $h \rightarrow 0+$ , bude  $y_n = Kx_n$  přibližným řešením, získaným metodou (2.7.13). Protože předpokládáme, že je tato metoda konvergentní, máme pro každé  $x$

$$\lim_{\substack{h \rightarrow 0+ \\ x_n=x}} y_n = y(x) = x \iff K \lim_{n \rightarrow \infty} n \frac{x}{n} = x \iff K = 1 \iff \sum_{\nu=0}^k \alpha_\nu \nu = \sum_{\nu=0}^k \beta_\nu.$$

□

**Příklad 8** Metoda  $-y_{n+2} + 4y_{n+1} - 3y_n = 2hf_n$  není stabilní, neboť polynom  $\rho(\xi) = -\xi^2 + 4\xi - 3$  má kořeny 1 a 3.

**Cvičení 10** Určete řád této metody.

**Příklad 9** Metoda  $y_{n+2} + 4y_{n+1} - 5y_n = h(4f_{n+1} + 2f_n)$  má sice řád 3, ale není stabilní.

#### Význam stability metody

Uvažujme rovnici  $y' = -y$ ,  $y(0) = 1$  s řešením  $y(x) = e^{-x}$ . Aplikujeme-li některou z předchozích metod, zjistíme, že pro rostoucí  $n$  hodnoty přibližného řešení oscilují okolo přesného se zvětšujícím se rozptylem.

#### Význam řádu metody

Definice řádu nijak nenaznačuje, k čemu je tento pojem dobrý. To vyplýne z následující věty. Mějme obecnou  $k$ -krokovou metodu (2.7.13),  $y : [a, b] \rightarrow \mathbb{R}$  buděj přesné řešení naší úlohy. Dosadíme  $y(x_n)$  místo  $y_n$  v (2.7.13):

$$\sum_{\nu=0}^k \alpha_\nu y(x_{n+\nu}) = h \sum_{\nu=0}^k \beta_\nu f(x_{n+\nu}, y(x_{n+\nu})) + h\delta_n. \quad (2.7.18)$$

Veličinu  $\delta_n$  nazveme *lokální relativní diskretizační chybou* v bodě  $x_{n+k}$ .

**Věta 19** Nechť metoda (2.7.13) je řádu  $p$  a nechť přesné řešení je třídy  $C^{p+1}[a, b]$ . Pak existují  $h_0$ ,  $K > 0$  tak, že  $|\delta_n| \leq Kh^p$  pro všechna  $n$  taková, že  $x_n, x_{n+k} \in [a, b]$  a pro všechna  $h < h_0$ .

*Důkaz:* Uvažujme intervaly  $[x_n, x_{n+\nu}] \subset [a, b]$  pro  $\nu = 0, \dots, k$  a  $n = 0, 1, \dots$ . Z Taylorova vzorce plyne:

$$y(x_{n+\nu}) = y(x_n + \nu h) = y(x_n) + \sum_{s=1}^p \frac{y^{(s)}(x_n)}{s!} \nu^s h^s + R_{\nu, p+1}, \quad (2.7.19)$$

$$R_{\nu, p+1} = \frac{y^{(p+1)}(x_{n+\nu})}{(p+1)!} \nu^{p+1} h^{p+1} = O(h^{p+1}), \quad x_{n+\nu} \in [x_n, x_{n+\nu}].$$

Protože  $y$  je řešení rovnice, máme  $f(x_{n+\nu}, y(x_{n+\nu})) = y'(x_{n+\nu})$ ; opět použijme Taylorův vzorec:

$$\begin{aligned} hf(x_{n+\nu}, y(x_{n+\nu})) &= hy'(x_n + \nu h) = \sum_{s=1}^p \frac{y^{(s)}(x_n)}{(s-1)!} \nu^{s-1} h^s + \tilde{R}_{\nu,p+1}, \quad (2.7.20) \\ \tilde{R}_{\nu,p+1} &= \frac{y^{(p+1)}(\tilde{x}_{n,\nu})}{p!} \nu^p h^{p+1} = O(h^{p+1}), \quad \tilde{x}_{n,\nu} \in [x_n, x_{n+\nu}]. \end{aligned}$$

Zbytky  $R, \tilde{R}$  jsou  $O(h^{p+1})$ , protože  $y^{(p+1)}$  je spojitá, a tedy v  $[a, b]$  omezená; označme  $Y$  maximum její absolutní hodnoty. Vztahy (2.7.19) a (2.7.20) dosadíme do (2.7.18) a upravíme pomocí definice rádu metody:

$$\begin{aligned} h\delta_n &= y(x_n) \sum_{\nu=0}^k \alpha_\nu + \sum_{s=1}^p h^s y^{(s)}(x_n) \left( \sum_{\nu=0}^k \alpha_\nu \frac{\nu^s}{s!} - \sum_{\nu=0}^k \beta_\nu \frac{\nu^{s-1}}{(s-1)!} \right) \\ &\quad + \sum_{\nu=0}^k \alpha_\nu R_{\nu,p+1} - \sum_{\nu=0}^k \beta_\nu \tilde{R}_{\nu,p+1} \\ h\delta_n &= h^{p+1} \left( \sum_{\nu=0}^k \alpha_\nu \nu^{p+1} \frac{y^{(p+1)}(x_{n,\nu})}{(p+1)!} - \sum_{\nu=0}^k \beta_\nu \nu^p \frac{y^{(p+1)}(\tilde{x}_{n,\nu})}{p!} \right) \end{aligned}$$

Protože je  $|y^{(p+1)}|$  na  $[a, b]$  odhadnuta konstantou  $Y$ , dostáváme

$$|\delta_n| \leq Y h^p \left( \sum \frac{|\alpha_\nu| \nu^{p+1}}{(p+1)!} - \sum \frac{|\beta_\nu| \nu^p}{p!} \right) = K h^p$$

pro  $x_n, x_{n+\nu} \in [a, b], h \in (0, h_0)$ .  $\square$

*Shrnutí:* Význam této věty je následující: je-li metoda rádu  $p$  a je-li přesné řešení rovnice dostatečně hladké, platí pro chybu  $\delta_n = O(h^p)$ . Bez důkazu uvedeme následující fundamentální výsledek:

**Věta 20** Vícekroková metoda je konvergentní, právě když je stabilní a konsistentní.

Zavedeme nyní opět chybu metody (akumulovanou diskretizační chybu) jako  $e_n = y_n - y(x_n)$ . Následující věta dává odhad této chyby.

**Věta 21** Nechť  $y \in C^{p+1}([a, b])$  je přesným řešením úlohy

$$y' = f(x, y) \text{ v } [a, b], \quad y(a) = \eta,$$

kde  $f \in C([a, b]) \times I\!\!R$  splňuje Lipschitzovu podmíinku s konstantou  $L > 0$  a nechť  $\{y_n\}_{x_n \in [a, b]}$  je přibližné řešení vypočtené pomocí vícekrokové stabilní metody rádu  $p \geq 1$ . Označme

$$\delta = \max_{\mu=0, \dots, b-1} |y(x_\mu) - y_\mu|.$$

Pak existují konstanty  $h_1 > 0$ ,  $\tilde{N} > 0$ ,  $\vartheta > 0$  takové, že pro chybu metody  $e_n = y_n - y(x_n)$  platí odhad

$$|e_n| \leq e^{(x_n-a)\vartheta} \delta + E_\vartheta(x_n - a) \tilde{N} h^p$$

$$\forall x_n \in [a, b], \quad \forall h \in (0, h_1).$$

Úplný důkaz je uveden ve skriptech [1] věta 1.12.4. Zde se omezíme na jednodušší případ tzv. silně stabilních metod.

**Definice 14** Vícekroková metoda je silně stabilní jestliže má tvar

$$y_{n+k} - y_{n+k-1} = h \sum_{\nu=0}^k \beta_\nu f_{n+\nu}. \quad (M)$$

Tzn., že polynom  $\rho$  má pouze kořeny 0 a 1 a kořen 1 je jednonásobný.

Nyní dokážeme předchozí větu o odhadu chyby pro případ silně stabilních metod.

*Důkaz:* Přibližné řešení splňuje vztahy

$$y_{n+k} - y_{n+k-1} = h \sum_{\nu=0}^k \beta_\nu f(x_{n+\nu}, y_{n+\nu}), \quad x_n, x_{n+k} \in [a, b].$$

Pokud je metoda (M) řádu  $p$  a přesné řešení je  $C^{p+1}([a, b])$ , pak

$$y(x_{n+k}) - y(x_{n+k-1}) = h \sum_{\nu=0}^k \beta_\nu f(x_{n+\nu}, y(x_{n+\nu})) + h\delta_n, \quad x_n, x_{n+k} \in [a, b].$$

a

$$|\delta_n| \leq Nh^p, \quad h \in (0, h_0).$$

Označíme-li  $e_{n+\nu} = y_{n+\nu} - y(x_{n+\nu})$  chybu metody, z předchozích vztahů dostaneme

$$e_{n+k} - e_{n+k-1} = h \sum_{\nu=0}^k \beta_\nu \{f(x_{n+\nu}, y_{n+\nu}) - f(x_{n+\nu}, y(x_{n+\nu}))\} - h\delta_n.$$

Poněvadž funkce  $f$  splňuje Lipschitzovu podmíinku, máme

$$|e_{n+k}| \leq |e_{n+k-1}| + hL \sum_{\nu=0}^k |\beta_\nu| |e_{n+\nu}| + h|\delta_n|$$

a tedy

$$|e_{n+k}|(1 - hL|\beta_k|) \leq |e_{n+k-1}|(1 + hL|\beta_{k-1}|) + hL \sum_{\nu=0}^{k-2} |\beta_\nu| |e_{n+\nu}| + Nh^{p+1}.$$

Nechť  $h_1 > 0$  je takové, že

$$1 - h_1 L |\beta_k| \geq \frac{1}{2}.$$

Potom pro  $h \in (0, h_1)$  platí  $1 - hL|\beta_k| \geq 1 - h_1 L |\beta_k| \geq \frac{1}{2}$ . Odtud plyne, že

$$\frac{1}{1 - hL|\beta_k|} \leq 2$$

a

$$\frac{1 + hL|\beta_{k-1}|}{1 - hL|\beta_k|} = \frac{1 - hL|\beta_k| + hL(|\beta_k| + |\beta_{k-1}|)}{1 - hL|\beta_k|} \leq 1 + 2hL(|\beta_k| + |\beta_{k-1}|).$$

Tudíž,

$$|e_{n+k}| \leq |e_{n+k-1}| + h \sum_{\nu=0}^{k-1} \vartheta_\nu |e_{n+\nu}| + \tilde{\vartheta}, \quad (2.7.21)$$

kde

$$\vartheta_{k-1} = 2L(|\beta_k| + |\beta_{k-1}|), \quad \vartheta_\nu = 2L|\beta_\nu|, \quad \nu = 0, \dots, k-2, \quad \tilde{\vartheta} = 2Nh^{p+1}.$$

Nyní použijeme následující výsledek.

**Lemma 3** Nechť  $u_n \geq 0$  pro  $n = 0, \dots, N$ ,  $\vartheta_\nu \geq 0$  pro  $\nu = 0, \dots, k-1$ ,  $\tilde{\vartheta} \geq 0$ ,  $\delta \geq 0$ ,  $h > 0$ ,  $u_0, \dots, u_{k-1} \leq \delta$ ,

$$u_{n+k} \leq u_{n+k-1} + h \sum_{\nu=0}^{k-1} \vartheta_\nu u_{n+\nu} + \tilde{\vartheta} \quad (2.7.22)$$

pro  $n = 0, \dots, N-k$  a nechť  $\vartheta = \sum_{\nu=0}^{k-1} \vartheta_\nu$ . Pak

$$u_n \leq e^{nh\vartheta} \delta + \frac{e^{nh\vartheta} - 1}{\vartheta h} \tilde{\vartheta}, \quad n = 0, \dots, N.$$

Důkaz:

1) Nechť

$$\xi_{n+1} = (1 + h\vartheta)\xi_n + \tilde{\vartheta}, \quad n = 0, \dots, N-1,$$

$$\xi_0 = \delta.$$

Potom podle lemmatu ...

$$\xi_n \leq e^{nh\vartheta} \delta + \frac{e^{nh\vartheta} - 1}{\vartheta h} \tilde{\vartheta}, \quad n = 0, \dots, N.$$

2) Dokažme indukcí, že  $u_n \leq \xi_n$ ,  $n = 0, \dots, N$ . Máme

$$u_0, \dots, u_{k-1} \leq \delta = \xi_0 \leq \xi_1 \leq \dots \leq \xi_{k-1} \leq \xi_k \leq \dots$$

Nechť  $u_j \leq \xi_j$  pro  $j = 0, \dots, n+k-1$ ,  $n \geq 0$ . Potom z (2.7.22) plyne, že

$$\begin{aligned} u_{n+k} &\leq u_{n+k-1} + h\vartheta_{k-1}u_{n+k-1} + \dots + h\vartheta_0u_n + \tilde{\vartheta} \\ &\leq \xi_{n+k-1} + h\vartheta_{k-1}\xi_{n+k-1} + \dots + h\vartheta_0\xi_n + \tilde{\vartheta} \\ &\leq \xi_{n+k-1} \left( 1 + h \sum_{\nu=0}^{k-1} \vartheta_\nu \right) + \tilde{\vartheta} \\ &= \xi_{n+k-1}(1 + h\vartheta) + \tilde{\vartheta} = \xi_{n+k}. \end{aligned}$$

3) Použijeme-li výsledek z 1), dostaneme

$$u_n \leq \xi_n \leq e^{nh\vartheta}\delta + \frac{e^{nh\vartheta} - 1}{\vartheta h}\tilde{\vartheta}, \quad n = 0, \dots, N,$$

což jsme chtěli dokázat.  $\square$

Nyní můžeme pokračovat v důkazu věty tak, že budeme aplikovat lemma na nerovnosti (2.7.21). Vzhledem k tomu, že  $nh = x_n - a$ ,  $\tilde{\vartheta} = \tilde{N}h^{p+1}$ ,  $\tilde{N} = 2N$ , snadno zjistíme, že

$$\begin{aligned} |e_n| &\leq e^{(x_n-a)\vartheta}\delta + \frac{e^{(x_n-a)\vartheta} - 1}{\vartheta h}\tilde{N}h^{p+1} = \\ &= e^{(x_n-a)\vartheta}\delta + E_\vartheta(x_n - a)\tilde{N}h^p, \quad x_n \in [a, b]. \end{aligned}$$

$\square$

Podobným způsobem lze odvodit odhad pro akumulovanou zaokrouhlovací chybu. Stejně jako u jednokrokových metod budeme symbolem  $\tilde{y}_n$  značit přibližné řešení počítané se zaokrouhlováním. Pak lze psát

$$\tilde{y}_{n+k} - \tilde{y}_{n+k-1} = h \sum_{\nu=0}^k \beta_\nu f(x_{n+\nu}, \tilde{y}_{n+\nu}) + \varepsilon_n, \quad x_n, x_{n+k} \in [a, b],$$

kde  $|\varepsilon_n| \leq \varepsilon$  pro  $x_n, x_{n+k} \in [a, b]$  a  $\tilde{y}_\mu = y_\mu$ ,  $\mu = 0, \dots, k-1$ . Přibližné řešení počítané přesně bez zaokrouhlování je dáno předpisem

$$y_{n+k} - y_{n+k-1} = h \sum_{\nu=0}^k \beta_\nu f(x_{n+\nu}, y_{n+\nu}), \quad x_n, x_{n+k} \in [a, b].$$

Nyní lze aplikovat postup jako v důkazu předchozí věty, kde  $\delta = 0$  a  $\tilde{\vartheta} = \varepsilon$ . Dostaneme pak odhad akumulované zaokrouhlovací chyby  $r_n = y_n - \tilde{y}_n$  ve tvaru

$$|r_n| \leq E_\vartheta(x_n - a) \frac{\varepsilon}{h}, \quad x_n \in [a, b].$$

Tento odhad nám dává *nejhorší scénář* pro chování chyby  $r_n$  v závislosti na  $h$ . Numerické experimenty bohužel ukazují, že pro  $h \rightarrow 0+$  zaokrouhlovací chyby mohou růst tak, že znehodnotí výpočet.

## 2.8 Odvození některých vícekrokových metod

### 2.8.1 Interpolaci polynom a zpětné diference

Nechť  $J \subset \mathbb{R}$  je interval,  $z : J \rightarrow \mathbb{R}$  a nechť  $x_0, \dots, x_q \in J$  ( $q \geqq 1$ ) jsou navzájem různé body. Pak existuje právě jeden interpolaci polynom  $P$  takový, že

- a) stupeň  $P \leq q$ ,
- b)  $P(x_i) = z(x_i)$ ,  $i = 0, \dots, q$ .

Polynom  $P$  lze napsat v Lagrangeově vyjádření

$$P(x) = \sum_{i=0}^q \frac{(x - x_0) \dots (x - x_{i-1})(x - x_{i+1}) \dots (x - x_q)}{(x_i - x_0) \dots (x_i - x_{i-1})(x_i - x_{i+1}) \dots (x_i - x_q)} z(x_i).$$

Pokud  $x_i = x_0 + ih$  pro  $i = 0, \dots, q$  a  $h > 0$ , pak lze vyjádřit  $P$  pomocí *zpětných differencí* funkce  $z$ , definovaných následujícím způsobem:

$$\nabla^0 z_i = z_i \quad (\text{diference nultého řádu}),$$

$$\nabla z_i = z_i - z_{i-1} \quad (\text{diference prvního řádu}),$$

dále indukcí

$$\nabla^r z_i = \nabla(\nabla^{r-1} z_i) \quad (\text{diference } r\text{-tého řádu}),$$

pokud mají výrazy vpravo smysl. Platí:

$$\nabla^2 z_i = (z_i - z_{i-1}) - (z_{i-1} - z_{i-2}) = z_i - 2z_{i-1} + z_{i-2}.$$

Obecně lze dokázat vztah

$$\nabla^r z_i = \sum_{m=0}^r (-1)^m \binom{r}{m} z_{i-m}, \quad r = 0, 1, \dots$$

Existuje i inverzní formule

$$z_{i-r} = \sum_{m=0}^r (-1)^m \binom{r}{m} \nabla^m z_i, \quad r = 0, 1, \dots$$

**Lemma 4** Interpolaci polynom  $P$  k funkci  $z$  v bodech  $x_i = x_0 + ih$ , kde  $i$  nabývá hodnot  $p, p-1, \dots, p-q$ , lze napsat ve tvaru

$$P(x) = \sum_{m=0}^q (-1)^m \binom{-s}{m} \nabla^m z_p, \quad (2.8.23)$$

kde  $s = (x - x_p)/h$

$$\binom{-s}{m} = \frac{(-s)(-s-1)\dots(-s-m+1)}{m!}.$$

*Důkaz:* Je zřejmé, že polynom na pravé straně vztahu (2.8.23) je stupně  $\leq q$ . Je-li  $x = x_{p-r}$ , potom  $s = -r$  a  $\binom{r}{m} = 0$  pro  $m > r$ . Pak podle inverzní formule

$$P(x_{p-r}) = \sum_{m=0}^q (-1)^m \binom{r}{m} \nabla^m z_p = \sum_{m=0}^r (-1)^m \binom{r}{m} \nabla^m z_p = z_{p-r}.$$

□

### 2.8.2 Metody založené na numerické integraci

Přesné řešení rovnice  $y' = f(x, y)$  splňuje vztah

$$y(x + \tau) - y(x) = \int_x^{x+\tau} f(t, y(t)) dt,$$

pro  $x, x + \tau \in [a, b]$ . Nyní nahradíme funkci  $f(t, y(t))$  interpolaci polynomem majícím v uzlech  $x_n$  hodnoty  $f_n = f(x_n, y_n)$ , kde  $y_n$  bylo vypočteno nebo má být právě vypočteno. Za interpolaci body vezměme body  $x_p, x_{p-1}, \dots, x_{p-q}$ . Uvažovaný interpolaci polynom má tvar

$$P(x) = \sum_{m=0}^q (-1)^m \binom{-s}{m} \nabla^m f_p, \quad s = \frac{x - x_p}{h}.$$

Zvolme nyní  $x = x_p$ ,  $\tau = h$  a approximujme  $y(x) \approx y_p$ ,  $y(x+\tau) \approx y_{p+1}$ ,  $f(t, y(t)) \approx P(t)$ . Dostaneme formuli

$$y_{p+1} - y_p = \int_{x_p}^{x_{p+1}} P(t) dt = h \sum_{m=0}^q \gamma_m \nabla^m f_m,$$

kde

$$\gamma_m = (-1)^m \frac{1}{h} \int_{x_p}^{x_{p+1}} \binom{-s}{m} dx = (-1)^m \int_0^1 \binom{-s}{m} ds.$$

- $\alpha)$  Takto získaným metodám (pro různá  $q$ ) se říká *Adams-Bashforthovy metody*. Pro zvolené  $q$  dostaneme  $(q+1)$ -krokovou metodu: k výpočtu  $y_{p+1}$  používáme hodnoty  $f$  v  $x_{p-q}, \dots, x_p$ , jedná se tedy o metodu explicitní. Charakteristický polynom  $\rho(\xi) = \xi^{q+1} - \xi^q = \xi^q(\xi - 1)$  má  $q$ -násobný kořen 0 a jednoduchý kořen 1, metody jsou tedy silně stabilní. Většinou mají tyto metody řád  $q+1$ .

- $\beta)$  Položme  $x = x_{p-1}$ ,  $\tau = h$ . Dosadíme do (2.7.13):

$$\begin{aligned} y_p - y_{p-1} &= \int_{x_{p-1}}^{x_p} P(x) dx = \int_{x_{p-1}}^{x_p} \sum_{m=0}^p (-1)^m \binom{-s}{m} \nabla^m f_p dx = \\ &= h \sum_{m=0}^q \gamma_m^* \nabla^m f_p, \\ \text{kde } \gamma_m^* &= \frac{(-1)^m}{h} \int_{x_{p-1}}^{x_p} x_p \binom{-s(x)}{m} dx = (-1)^m \int_{-1}^0 \binom{-s}{m} ds. \end{aligned}$$

V tomto případě dostáváme implicitní  $q$ -krokovou metodu. Tyto metody se nazývají *Adams-Moultonovy*.

Hodnoty zpětných diferencí se počítají poměrně snadno, ale přesto můžeme naše metody přepsat do tvaru, kdy místo hodnot  $\nabla^m f_p$  používáme přímo hodnoty  $f_{p-\rho}$  podle vztahu

$$\nabla^m f_p = \sum_{\rho=0}^m (-1)^\rho \binom{m}{\rho} f_{p-\rho}.$$

Dostaneme pak např. Adams-Bashforthovu metodu ve tvaru

$$\begin{aligned} y_{p+1} - y_p &= \sum_{m=0}^q \gamma_m \nabla^m f_p = h \sum_{m=0}^q \gamma_m \sum_{\rho=0}^m (-1)^\rho \binom{m}{\rho} f_{p-\rho} = \\ &= h \sum_{\rho=0}^q f_{p-\rho} \left( (-1)^\rho \sum_{m=\rho}^q q \binom{m}{\rho} \gamma_m \right). \end{aligned}$$

### 2.8.3 Příklady některých metod

V následující tabulce jsou uvedeny příklady některých metod, které takto dostaneme.

	metoda	$k$	$p$
1.	$y_{n+1} = y_n + hf_n$	1	1
2.	$y_{n+2} = y_{n+1} + \frac{1}{2}h(3f_{n+1} - f_n)$	2	2
3.	$y_{n+3} = y_{n+2} + \frac{h}{12}(23f_{n+2} - 16f_{n+1} + 5f_n)$	3	3
6.	$y_{n+1} = y_n + hf_{n+1}$	1	1
7.	$y_{n+1} = y_n + \frac{h}{2}(f_{n+1} + f_n)$	1	2
8.	$y_{n+2} = y_{n+1} + \frac{h}{12}(5f_{n+2} + 8f_{n+1} - f_n)$	2	3

### Metody prediktor-korektor

Budeme-li chtít využít uvedené metody pro použití v metodách prediktor-korektor, je výhodné vzít kombinace 1-7 a 2-8. Z teoretického rozboru totiž vyplývá, že v případě, kdy jako prediktor použijeme metodu řádu o jedna menšího než je řád korektoru, celková metoda bude mít stejný řád jako korektor. Dostaneme tedy jednokrokovou metodu řádu 2 a dvoukrokovou metodu řádu 3.

### 2.9 Metoda sítí pro řešení parciálních diferenciálních rovnic

Uvedme na závěr jednoduchý příklad numerické approximace parciálních diferenciálních rovnic. Představme si pružnou blánu, na okraji upevněnou, na niž působí kolmo nějaká síla. Modelem bude oblast (otevřená souvislá množina)  $\Omega \subset \mathbb{R}^2$ , sílu budeme reprezentovat hustotou jejího rozložení, tedy funkcí  $f : \Omega \rightarrow \mathbb{R}$  a výchylku blány hledanou funkcí  $u : \Omega \rightarrow \mathbb{R}$ . Za předpokladu, že jsme dosáhli stabilního stavu (a že výchylka je malá) bude  $u$  splňovat vztah  $-\Delta u = f$ , kde  $\Delta$  je takzvaný *Laplaceův operátor* definovaný vztahem

$$\Delta u = \sum_{i=1}^n \frac{\partial^2 h}{\partial x_i^2} \quad (h : \mathbb{R}^n \rightarrow \mathbb{R}).$$

Upevnění na okrajích je vyjádřeno okrajovou podmínkou  $u|_{\partial\Omega} = 0$ . (V případě jednodimensionální analogie místo  $\Omega$  máme interval  $(a, b)$ , rovnici je  $-u'' = f$  a okrajové podmínky  $u(a) = u(b) = 0$ .) Řešme úlohu přibližně pro  $\Omega = (0, 2) \times (0, 1)$ . K tomu potřebujeme situaci diskretizovat: obdélník  $\bar{\Omega}$  si rozdělme na  $2n \times n$  čtverečků o hraně  $h = \frac{1}{n}$ . Souřadnice uzlů označme  $x_i = y_i = ih$ . Hodnoty  $u$ ,  $f$  v uzlu  $(x_i, y_j)$  označme  $u_{ij}$ ,  $f_{ij}$ . Okrajová podmínka dává  $u_{0,j} = u_{2n,j} = u_{i,0} = u_{i,n} = 0$ . Podobně jako derivaci funkce jedné proměnné lze approximovat podle vztahu  $y' \approx \frac{1}{h}(y(x+h) - y(x))$ , lze approximovat nesmišené parciální derivace druhého řádu:

$$\begin{aligned} \frac{\partial^2 u}{\partial x^2}(x_i, y_j) &\approx \frac{1}{h^2} (u(x_{i-1}, y_j) - 2u(x_i, y_j) + u(x_{i+1}, y_j)) \\ \frac{\partial^2 u}{\partial y^2}(x_i, y_j) &\approx \frac{1}{h^2} (u(x_i, y_{j-1}) - 2u(x_i, y_j) + u(x_i, y_{j+1})) \end{aligned}$$

Dosadíme-li tuto diskretizaci do rovnice, dostaneme soustavu lineárních rovnic tvaru

$$-u_{i,j-1} - u_{i,j+1} + 4u_{i,j} - u_{i-1,j} - u_{i+1,j} = h^2 f_{i,j}.$$

Uspořádáme-li neznámé do jednoho sloupkového vektoru  $\mathbf{u} = (u_{1,1}, \dots, u_{1,n-1}, u_{2,1}, \dots, u_{2n-1,n-1})^T$  a stejným způsobem pravé strany do vektoru  $\mathbf{f}$ , dostaneme soustavu  $A\mathbf{u} = \mathbf{f}$ , kde matici  $A$  lze psát rozdělenou na pole ve

$$A = \begin{pmatrix} B & C & 0 & 0 & \dots & 0 \\ C & B & C & 0 & \dots & 0 \\ 0 & C & B & C & \dots & 0 \\ \vdots & & \ddots & \ddots & \vdots \\ 0 & 0 & 0 & 0 & \dots & B \end{pmatrix}, \quad B = \begin{pmatrix} 4 & -1 & 0 & 0 & \dots & 0 \\ -1 & 4 & -1 & 0 & \dots & 0 \\ 0 & -1 & 4 & -1 & \dots & 0 \\ \vdots & & & & \ddots & 0 \\ 0 & 0 & 0 & 0 & \dots & 0 \end{pmatrix}$$

a  $C$  je  $-E$ , kde  $E$  je jednotková matice. Matice  $A$  se skládá z  $(2n - 1) \times (2n - 1)$  bloků typu  $(n - 1) \times (n - 1)$ . Matici s takovou strukturou se říká *blokově třídagonální matici*. Struktura této matice samozřejmě závisí na očislování „políček“. Popsané metodě se nazývá *metoda sítí* nebo též *metoda konečných diferencí*.

# 3

## NUMERICKÉ METODY OPTIMALIZACE

V této kapitole se věnujeme výkladu elementů konvexní analýzy v  $\mathbb{R}^n$  a základním numerickým metodám pro hledání minima (lokálního minima) funkcí více proměnných. Na začátku uvedeme dva příklady.

**Příklad 10** *Prokládání křivek naměřenými daty:* Máme zadány hodnoty  $x_i, y_i$  ( $i = 1, \dots, r, x_1 < \dots < x_r$ ). Hledáme funkci  $f = f(\alpha_1, \dots, \alpha_n, x)$  závislou na konečně mnoha parametrech  $\alpha_1, \dots, \alpha_n$  tak, aby její hodnoty v  $x_i$  byly co nejbliže k  $y_i$ . Použijeme-li metodu nejmenších čtverců, je třeba minimalizovat funkci

$$J(\alpha_1, \dots, \alpha_n) = \sum_{i=1}^r (f(\alpha_1, \dots, \alpha_n, x_i) - y_i)^2.$$

**Příklad 11** *Optimalizace tvaru radiátoru ústředního topení*

Snažíme se najít co nejvhodnější tvar průřezu žebra. Tento tvar můžeme reprezentovat uzavřenou křivkou okolo počátku; protože chceme, aby tato křivka byla symetrická, můžeme ji reprezentovat pomocí nezáporné funkce  $p : [0, b] \rightarrow [0, +\infty)$ . Naše křivka pak vznikne doplněním grafu této funkce o části souměrně s ním sdružené podle počátku a obou os. Rozložení teploty  $T$  bude splňovat rovnici pro vedení tepla ve tvaru<sup>3</sup>

$$\frac{d}{dx} \left( p(x) \frac{dT}{dx} \right) = a \sqrt{1 + \left( \frac{dp}{dx} \right)^2} \cdot T$$

s okrajovými podmínkami  $T(0) = T_0$ ,  $T(b) = T_b$ , kde  $a$  je konstanta závisející na vlastnostech materiálu. Celkové množství tepla uvolněného do okolí je

$$I = 2 \int_0^b kT dx,$$

kde  $k$  je opět jakýsi koeficient. Úkolem je najít funkci  $p$  takovou, aby hodnota funkcionálu  $I(p)$  byla maximální, tedy aby hodnota  $F(p) = -I(p)$  byla minimální. Přesněji řečeno, hledáme funkci  $p^* \in C^1[0, p]$  tak, aby

$$F(p^*) = \min_{p \in C^1[0, p]} F(p)$$

a zároveň  $p(b) = 0$ ,  $p(0) = K > 0$  ( $K$  je zadáno) a  $p > 0$  na  $[0, b]$ . Označíme-li  $U$  množinu všech takových funkcí (bez požadavku minimality), hledáme minimum

<sup>3</sup>tento příklad má pouze ilustrovat, jak se složitější praktický problém převádí na standardní situaci hledání minima funkce několika proměnných

$F$  na  $U$ . Tako formulovaná úloha spadá do odvětví matematiky zvaného *optimální řízení*. Pro použití numerických metod se musíme ještě omezit na nějakou množinu  $\tilde{U} \subset U$  funkci určenou konečně mnoha parametry  $u_1, \dots, u_n$ . Každé takové  $n$ -tici parametrů přiřadíme funkci  $p \in U$ , k té spočítáme teplotu  $T$ , hodnoty  $I(p)$  a  $F(p)$  a položíme  $\tilde{F}(u_1, \dots, u_n) := F(p)$ . Tím už jsme úlohu převedli na problém minimalizace funkce  $\tilde{F} : \mathbb{R}^n \rightarrow \mathbb{R}$ .

V obou případech jsme dospěli k úloze minimalizovat reálnou funkci  $n$  proměnných. Je vidět, že tato úloha má řadu praktických aplikací, a proto byly vyvinuty různé algoritmy pro její řešení.

### 3.1 Základy konvexní analýzy

V této části uvedeme některé základní pojmy a výsledky konvexní analýzy, které se využívají při numerickém hledání extrémů. V dalším bude  $U$  podmnožina  $\mathbb{R}^n$  a  $J$  zobrazení  $U$  do  $\mathbb{R}$ .

**Definice 15** Hodnotu  $J(\bar{u})$ ,  $\bar{u} \in U$  nazveme (absolutním, globálním) *minimem* funkce  $J$  na  $U$ , jestliže  $\forall u \in U : J(u) \geq J(\bar{u})$ . Bod  $\bar{u}$  nazýváme *bod minima*, píšeme  $J(\bar{u}) = \min_U J$  nebo  $\bar{u} = \arg \min_U J$ .

Hodnotu  $J(\bar{u})$ ,  $\bar{u} \in U$  nazveme *lokálním minimem* funkce  $J$ , jestliže existuje okolí  $V(\bar{u})$  takové, že  $J(\bar{u})$  je (globálním) minimem na  $J$  na  $U \cap V(\bar{u})$ . Bod  $\bar{u}$  se pak nazývá *bodem lokálního minima*.

**Věta 22** Budě  $U \subset \mathbb{R}^n$  omezená, uzavřená množina a  $J : U \rightarrow \mathbb{R}$  spojitá funkce. Potom  $J$  nabývá na  $U$  minima.

**Definice 16** Nechť  $U \subset \mathbb{R}^n$  je neomezená množina a  $J : U \rightarrow \mathbb{R}$ . Řekneme, že funkce  $J$  je *koercivní*, jestliže

$$\lim_{\substack{\|u\| \rightarrow \infty \\ u \in U}} J(u) = +\infty.$$

**Věta 23** Nechť  $U \subset \mathbb{R}^n$  je neomezená, uzavřená množina. Budě  $J : U \rightarrow \mathbb{R}$  spojitá a koercivní. Pak  $J$  nabývá na  $U$  minima.

*Důkaz:* Nechť  $a \in U$ . Z podmínky koercivity vyplývá, že existuje takové  $R > 0$ , že

$$a \in B(0, R) \cap U \neq \emptyset, \quad \forall u \in U \setminus B(0, R) : J(u) \geq J(a) + \frac{\pi}{17},$$

kde  $B(0, R)$  označuje uzavřenou kouli se středem v počátku a poloměrem  $R$ . Označíme-li  $K = U \cap B(0, R)$ , nabývá  $J$  na  $K$  podle minulé věty v nějakém bodě  $\bar{u}$  minima. Pak je ale pro  $u \in U \setminus B(0, R)$

$$J(u) \geq J(a) + \frac{\pi}{17} > J(a) \geq J(\bar{u})$$

a hodnota  $J(\bar{u})$  je tedy minimem na celé množině  $U$ . □

*Označení:* Nechť  $U \subset \mathbb{R}^n$  je otevřená,  $J \in C^1(U)$ . Pak pro každé  $u \in U$ ,  $\varphi \in \mathbb{R}^n$  existuje směrová derivace

$$J'(u, \varphi) = \lim_{\theta \rightarrow 0} \frac{(J(u + \theta\varphi) - J(u))}{\theta}.$$

Její hodnota je rovna  $\nabla J(u) \cdot \varphi$ , kde

$$\nabla J(u) = \text{grad } J(u) = \left( \frac{\partial J}{\partial u_1}(u), \dots, \frac{\partial J}{\partial u_n}(u) \right)^T$$

je *gradient* funkce  $J$ .

**Definice 17** Buď  $U \subset \mathbb{R}^n$  konvexní množina. Řekneme, že  $J : U \rightarrow \mathbb{R}$  je *konvexní funkce*, jestliže

$$J(u + \theta(v - u)) \leq J(u) + \theta(J(v) - J(u))$$

pro libovolné  $u, v \in U$ ,  $\theta \in [0, 1]$ . Řekneme, že  $J$  je *ryze konvexní*, jestliže pro  $u \neq v$ ,  $\theta \in (0, 1)$  platí ostrá nerovnost.

**Věta 24**  $U \subset \mathbb{R}^n$  bud otevřená konvexní množina,  $J \in C^1(U)$ . Pak

- (i)  $J$  je konvexní právě tehdy, když  $J(v) \geq J(u) + J'(u, v - u)$  pro každé  $u, v \in U$ ;
- (ii)  $J$  je ryze konvexní právě tehdy, když  $J(v) > J(u) + J'(u, v - u)$  pro každé  $u, v \in U$ ,  $u \neq v$ .

*Důkaz:* Nechť je nejprve  $J$  konvexní na  $U$ . Tzn., že je-li  $u, v \in U$ , potom

$$J(u + \theta(v - u)) \leq J(u) + \theta(J(v) - J(u)), \quad \forall \theta \in (0, 1).$$

Z toho plyne

$$J(v) - J(u) \geq \frac{J(u + \theta(v - u)) - J(u)}{\theta}, \quad \forall \theta \in (0, 1).$$

Nyní uvažujme  $\theta \rightarrow 0+$ , pak

$$J(v) - J(u) \geq \lim_{\theta \rightarrow 0+} \frac{J(u + \theta(v - u)) - J(u)}{\theta} = J'(u, v - u).$$

Opačná implikace: nechť je pro každé  $u, v \in U$  splněna podmínka

$$J(v) \geq J(u) + J'(u, v - u).$$

Z toho plyne

$$\begin{aligned} J(u) &\geq J(u + \theta(v - u)) - J'(u + \theta(v - u), \theta(v - u)) = \\ &= J(u + \theta(v - u)) - \theta J'(u + \theta(v - u), v - u). \end{aligned}$$

Obdobně

$$\begin{aligned} J(v) &\geq J(u + \theta(v - u)) + J'(u + \theta(v - u), (1 - \theta)(v - u)) = \\ &= J(u + \theta(v - u)) + (1 - \theta)J'(u + \theta(v - u), v - u). \end{aligned}$$

Přenásobením prvního vztahu členem  $(1 - \theta)$  a druhého  $\theta$  a sečtením dostaneme

$$(1 - \theta)J(u) + \theta J(v) \geq J(u + \theta(v - u)), \quad \forall u, v \in U, \forall \theta \in [0, 1].$$

Nyní budeme dokazovat druhé tvrzení. Nejprve nechť je

$$J(v) > J(u) + J'(u, v - u), \quad \forall u, v \in U, u \neq v, \theta \in (0, 1).$$

Stejným postupem jako jsme právě užili (uvažujeme-li ostré nerovnosti) dostaneme, že  $f$  je ryze konvexní.

Předpokládejme naopak, že  $f$  je ryze konvexní. Z definice vyplývá, že pro  $\theta \in (0, 1)$ ,  $u \neq v$

$$J(u + \theta(v - u)) < J(u) + \theta(J(v) - J(u))$$

a odtud ihned plyne

$$\begin{aligned} J(v) - J(u) &> \frac{J(u + \theta(v - u)) - J(u)}{\theta} \geq \\ &\geq \frac{J'(u, \theta(v - u))}{\theta} = J'(u, v - u). \end{aligned}$$

□

**Věta 25**  $U \subset \mathbb{R}^n$  budě otevřená,  $J \in C^1(U)$ .

- (i) Je-li  $\bar{u} \in U$  bodem lokálního minima, je  $J'(\bar{u}, \varphi) = 0$  pro každé  $\varphi \in \mathbb{R}^n$  (neboli  $\nabla J(\bar{u}) = 0$ ).
- (ii) Je-li navíc  $U$  konvexní,  $J$  konvexní, potom jsou následující tvrzení ekvivalentní:
  - 1)  $\bar{u}$  je bodem lokálního minima,
  - 2)  $\bar{u}$  je bodem minima,
  - 3)  $\nabla J(\bar{u}) = 0$ .
- (iii) Je-li navíc  $J$  ryze konvexní, má  $J$  na  $U$  nejvýše jeden bod minima.

*Důkaz:* Tvrzení (i) je známé z matematické analýzy. Pro důkaz (ii) předpokládejme, že  $J \in C^1(U)$  a  $J$  je konvexní. Z toho vyplývá, že

$$J(v) \geq J(\bar{u}) + J'(\bar{u}, v - \bar{u}) \quad \forall v \in U. \quad (3.1.1)$$

Jestliže  $\bar{u}$  je bodem lokálního minima, potom  $\nabla J(\bar{u}) = 0$  a  $J'(\bar{u}, \varphi) = 0$  pro každé  $\varphi \in \mathbb{R}^n$ . Odtud a z (3.1.1) plyne, že  $J(v) \geq J(\bar{u})$  pro všechna  $v \in U$ . Tudíž,

$$\bar{u} = \arg \min_U J.$$

Pro důkaz tvrzení (iii) nechť  $J$  je ryze konvexní a předpokládejme, že má v  $U$  dva body minima  $u_1 \neq u_2$ . Potom ale z konvexity máme

$$J(u_2) > J(u_1) + J'(u_1, u_2 - u_1),$$

přičemž  $J'(u_1, u_2 - u_1) = 0$ , protože  $u_1$  je bod minima. To je ovšem spor.  $\square$

Nechť  $J \in C^2(U)$ ,  $U \subset \mathbb{R}^n$ . Pak má  $J$  totální diferenciál druhého řádu v libovolném bodě  $u \in U$  a směrové derivace druhého řádu  $J''(u, \varphi, \psi) = \varphi^T J''(u)\psi$ , kde

$$J''(u) = \left( \frac{\partial^2 J}{\partial u_i \partial u_j}(u) \right)_{i,j=1}^n$$

je *Hessova matici* (která je symetrická). Taylorův vzorec lze psát ve tvaru

$$J(v) = J(u) + J'(u, v - u) + \frac{1}{2} J''(u + \theta(v - u), v - u, v - u)$$

pro nějaké  $\theta \in [0, 1]$ . Použitím tohoto vzorce lze dokázat tuto větu:

**Věta 26** Nechť  $J : \mathbb{R}^n \rightarrow \mathbb{R}$ ,  $J \in C^2$ , nechť existuje  $\alpha > 0$  tak, že  $J''(u, \varphi, \varphi) \geq \alpha \|\varphi\|^2$  pro všechna  $u, \varphi \in \mathbb{R}^n$ . Potom  $J$  je koercivní a ryze konvexní na  $\mathbb{R}^n$ .

*Důkaz:* Nechť  $J$  je dvakrát spojitě diferencovatelná. Nejprve dokážeme koercivitu. Z Taylorova vzorce máme pro  $\theta \in [0, 1]$

$$\begin{aligned} J(u) &= J(0) + J'(0, u) + \frac{1}{2} J''(\theta u, u, u) \geq \\ &\geq J(0) - M\|u\| + \frac{\alpha}{2}\|u\|^2 \xrightarrow{\|u\| \rightarrow \infty} +\infty. \end{aligned}$$

Jest totiž podle Cauchyovy nerovnosti

$$|J'(0, u)| = |\nabla J(0) \cdot u| \leq \underbrace{\|\nabla J(0)\|}_{=M} \|u\|$$

a podle předpokladů je

$$\frac{1}{2} J''(\theta u, u, u) \geq \frac{\alpha}{2} \|u\|^2.$$

Tím jsme dokázali koercivitu. Zbývá dokázat ryzí konvexitu. Nechť  $u, v \in \mathbb{R}^n$ ,  $u \neq v$ . Opět užijeme Taylorův vzorec. Existuje  $\theta \in [0, 1]$  takové, že

$$\begin{aligned} J(v) &= J(u) + J'(u, v - u) + \frac{1}{2} J''(u + \theta(v - u), v - u, v - u) \geq \\ &\geq J(u) + J'(u, v - u) + \frac{1}{2} \alpha \|v - u\|^2 > \\ &> J(u) + J'(u, v - u), \end{aligned}$$

čímž je důkaz hotov.  $\square$

**Důsledek 27** Funkce  $J$  splňující předpoklady věty 26 má právě jedno minimum v  $\mathbb{R}^n$ .

### 3.2 Numerické metody hledání minima

V této části se věnujeme iteračním procesům, které představují numerické minimizační algoritmy.

Nechť  $J : \mathbb{R}^n \rightarrow \mathbb{R}$  a je dán počáteční bod  $u^0 \in \mathbb{R}^n$ . Nechť jsme již určili  $u^k \in \mathbb{R}^n$ . Pak položíme

$$u^{k+1} = u^k + \rho_k \varphi^k,$$

kde  $k \geq 0$ ,  $\varphi^k \in \mathbb{R}^n$ ,  $\rho_k > 0$ . Veličinu  $\varphi$  nazýváme *směr spádu*,  $\rho_k$  určuje vzdálenost – *délku kroku* ve směru  $\varphi^k$ . Pro praktické použití je potřeba zodpovědět dvě základní otázky:

- 1) jak volit směr spádu  $\varphi_k$ ,
- 2) jak volit velikosti kroku.

Směr spádu  $\varphi^k$  volíme tak, aby  $J(u^{k+1}) < J(u^k)$  pro vhodné  $\rho_k > 0$  (např dostačně malé). Směr spádu  $\varphi^k$  můžeme zvolit např. tak, že

$$J'(u^k, \varphi^k) = \nabla J(u^k) \cdot \varphi^k < 0. \quad (3.2.2)$$

**Věta 28** Nechť je  $J \in C^2(\mathbb{R}^n)$  a platí (3.2.2). Potom existuje  $\tilde{\rho}_0 > 0$  takové, že  $J(u^{k+1}) < J(u^k)$ , pokud  $\rho^k \in (0, \tilde{\rho}_0)$ .

*Důkaz:* Z Taylorova vzorce plyne, že

$$J(u^{k+1}) = J(u^k) + \rho_k J'(u^k, \varphi^k) + \frac{1}{2} \rho_k^2 J''(\beta, \varphi^k, \varphi^k),$$

kde  $\beta$  leží na úsečce mezi body  $u^k$  a  $u^k + \rho_k \varphi^k$ . Nechť  $K > 0$ . Potom existuje  $M > 0$  tak, že

$$|J''(\beta, \varphi^k, \varphi^k)| \leq M, \quad \forall \beta = u^k + \rho \varphi^k, \quad \rho \in [0, K].$$

Máme tedy

$$J(u^{k+1}) = J(u^k) + \rho_k \left( \underbrace{J'(u^k, \varphi^k)}_{<0} + \frac{1}{2} \rho_k \underbrace{J''(\beta, \varphi^k, \varphi^k)}_{|J''| \leq M} \right).$$

Odtud plyne, že existuje  $\tilde{\rho}_0 > 0$  tak, že

$$J(u^k, \varphi_k) + \frac{1}{2} \rho_k J''(\beta, \varphi^k, \varphi^k) < 0, \quad \forall \rho_k \in (0, \tilde{\rho}_0).$$

□

**Příklad 12** Směr největšího spádu definujeme jako

$$\varphi^k = -\nabla J(u^k).$$

Pokud  $\nabla J(u^k) \neq 0$ , potom

$$J'(u^k, \varphi^k) = -\nabla J(u^k) \cdot \nabla J(u^k) = -\|\nabla J(u^k)\|^2 < 0.$$

V dalším uvedeme a budeme analyzovat dva typy metody největšího spádu.

*Algoritmus I - metoda největšího spádu s konstantním krokem*

Nechť je dáno:  $u^0 \in \mathbb{R}^n$ ,  $M \geq 1$  celé,  $\varepsilon > 0$ ,  $\rho > 0$  (krok). Pro  $k = 0, 1, \dots, M$  proveděte:

- 1) Položte  $u^{k+1} = u^k - \rho \nabla J(u^k)$
- 2) Jestliže  $\|\nabla J(u^k)\| < \varepsilon$ , jděte na 3.
- 3) Stop.

*Algoritmus II - metoda největšího spádu s optimálním krokem*

Nechť je dáno:  $u_0 \in \mathbb{R}^n$ ,  $M \geq 1$  celé,  $\varepsilon > 0$ . Pro  $k = 0, 1, \dots, M$  proveděte:

- 1) Položte  $\varphi^k = -\nabla J(u^k)$ .
- 2) Vypočtěte  $\rho_k = \arg \min_{\rho > 0} J(u^k + \rho \varphi^k)$
- 3) Položte  $u^{k+1} = u^k + \rho_k \varphi^k$
- 4) Je-li  $\|\nabla J(u^k)\| < \varepsilon$ , pak jděte na 5.
- 5) Stop.

Pokud v předchozích algoritmech zvolíme  $M = \infty$ ,  $\varepsilon = 0$ , dostaneme nekonečné iterační procesy. V dalším se budeme zabývat analýzou konvergence těchto iteračních procesů, tj. konvergence posloupnosti  $\{u^k\}_{k=0}^\infty$  pro  $k \rightarrow \infty$  k bodu minima nebo lokálního minima nebo ke stacionárnímu bodu.

**Věta 29** Nechť  $J \in C^2(\mathbb{R}^n)$  a nechť existují konstanty  $\lambda, \Lambda > 0$  takové, že

$$\lambda \|\varphi\|^2 \leq \varphi^T J''(u) \varphi \leq \lambda \|\varphi\|^2 \quad \forall u, \varphi \in \mathbb{R}^n. \quad (3.2.3)$$

Zvolme  $\rho = \frac{2}{\lambda + \Lambda}$ . Pak posloupnost  $\{u^k\}_{k=0}^\infty$  daná algoritmem 1 s  $M = \infty$  a  $\varepsilon = 0$  konverguje k jednoznačnému řešení úlohy

$$J(\bar{u}) = \min_{u \in \mathbb{R}^n} J(u) \quad (3.2.4)$$

a

$$\|u^k - \bar{u}\| \leq \|u^0 - \bar{u}\| \left( \frac{\Lambda - \lambda}{\Lambda + \lambda} \right)^k, \quad k = 0, 1, \dots \quad (3.2.5)$$

*Důkaz:* Z předpokladů, že  $J \in C^2(\mathbb{R}^n)$  a (3.2.3) plyne, že funkce  $J$  je spojitá, rye konvexní a koercivní. Tedy, existuje právě jeden bod  $\bar{u} = \arg \min_{\mathbb{R}^n} J$  a  $\nabla J(\bar{u}) = 0$ . Podle algoritmu 1,

$$\|u^{k+1} - \bar{u}\| = \|u^k - \rho \nabla J(u^k) + \rho \nabla J(\bar{u}) - \bar{u}\|. \quad (3.2.6)$$

Zabýejme se výrazem  $\nabla J(u^k) - \nabla J(\bar{u})$ . Definujme vektorovou funkci  $f(t) = \nabla J(\bar{u} + t(u^k - \bar{u}))$ ,  $t \in [0, 1]$ . Její derivace má tvar  $f'(t) = J''(\bar{u} + t(u^k - \bar{u})) (u^k - \bar{u})$ . Můžeme psát

$$\begin{aligned} \nabla J(u^k) - \nabla J(\bar{u}) &= f(1) - f(0) = \int_0^1 f'(t) dt \\ &= \int_0^1 J''(\bar{u} + t(u^k - \bar{u})) (u^k - \bar{u}) dt. \end{aligned} \quad (3.2.7)$$

Odtud a z (3.2.6) plyne, že

$$\|u^{k+1} - \bar{u}\| \leq \left\| I - \rho \int_0^1 J''(\bar{u} + t(u^k - \bar{u})) dt \right\| \|u^k - \bar{u}\|, \quad (3.2.8)$$

kde  $I$  je jednotková matice. Je zřejmé, že  $I - \rho \int_0^1 J''(\bar{u} + t(u^k - \bar{u})) dt$  je symetrická matice typu  $n \times n$ .

V dalším budeme potřebovat dva důležité výsledky.

**Lemma 5** *Pro symetrickou reálnou matici  $\mathbb{A}$  platí:*

$$\|\mathbb{A}\| = \sigma(\mathbb{A}), \quad (3.2.9)$$

kde  $\|\mathbb{A}\|$  je norma matice  $\mathbb{A}$  indukovaná eukleidovskou normou  $\|\cdot\|$  v  $\mathbb{R}^n$ :

$$\|\mathbb{A}\| = \sup_{0 \neq u \in \mathbb{R}^n} \frac{\|\mathbb{A}u\|}{\|u\|},$$

a  $\sigma(\mathbb{A})$  je specktrální poloměr matice  $\mathbb{A}$ :

$$\sigma(\mathbb{A}) = \max_{\lambda \in \text{Sp}(\mathbb{A})} |\lambda|.$$

Zde  $\text{Sp}(\mathbb{A}) = \{\lambda; \lambda = \text{vlastní číslo matice } \mathbb{A}\}$  značí spektrum matice  $\mathbb{A}$ .

*Důkaz:* Nechť  $\text{Sp}(\mathbb{A}) = \{\lambda_1, \dots, \lambda_n\}$ , kde  $|\lambda_1| \leq |\lambda_2| \leq \dots \leq |\lambda_n|$ . Poněvadž  $\mathbb{A}$  je symetrická matice, je  $\text{Sp } \mathbb{A} \subset \mathbb{R}$ . Je známo z algebry, že v  $\mathbb{R}^n$  existuje ortonormální báze  $\varphi_1, \dots, \varphi_n$  tvořená vlastními vektory matice  $\mathbb{A}$  k vlastním číslům  $\lambda_1, \dots, \lambda_n$ :  $\mathbb{A}\varphi_i = \lambda_i\varphi_i$ ,  $i = 1, \dots, n$ .

Jestliže  $u \in \mathbb{R}^n$ ,  $u \neq 0$ , pak existují  $c_i \in \mathbb{R}^n$  takové, že  $u = \sum_{i=1}^n c_i\varphi_i$ . Dále snadno zjistíme, že

$$\mathbb{A}u = \sum_{i=1}^n \lambda_i c_i \varphi_i \quad \text{a} \quad \frac{\|\mathbb{A}u\|^2}{\|u\|^2} = \frac{\sum_{i=1}^n \lambda_i^2 c_i^2}{\sum_{i=1}^n c_i^2} \leq \lambda_n^2.$$

Odtud plyne, že  $\|\mathbb{A}\| \leq |\lambda_n| = \sigma(\mathbb{A})$ . Zvolíme-li  $u = \varphi_n$ , pak dostaneme  $\sigma(\mathbb{A}) = |\lambda_n| \leq \|\mathbb{A}\varphi_n\| \leq \|\mathbb{A}\|$ . Tedy  $\sigma(\mathbb{A}) = \|\mathbb{A}\|$ .  $\square$

**Lemma 6** *Nechť*

$$|\varphi^T \mathbb{A} \varphi| \leq \alpha \|\varphi\|^2 \quad \forall \varphi \in \mathbb{R}^n. \quad (3.2.10)$$

Pak

$$|\lambda| \leq \alpha \quad \forall \lambda \in \text{Sp}(\mathbb{A}). \quad (3.2.11)$$

*Důkaz:* Je-li  $\lambda \in \text{Sp}(\mathbb{A})$ , pak existuje  $\varphi \in \mathbb{R}^n$ ,  $\varphi \neq 0$  takové, že  $\mathbb{A}\varphi = \lambda\varphi$ . Tudíž,  $\varphi^T \mathbb{A}\varphi = \lambda\|\varphi\|^2$  a tedy

$$|\lambda| \|\varphi\|^2 = |\varphi^T \mathbb{A}\varphi| \leq \alpha \|\varphi\|^2.$$

Odtud plyne (3.2.11).  $\square$

Nyní budeme pokračovat v důkazu věty 29. Z lemmatu 5 plyne, že

$$\left\| I - \rho \int_0^1 J''(\bar{u} + t(u^k - \bar{u})) dt \right\| = \sigma \left( I - \rho \int_0^1 J''(\bar{u} + t(u^k - \bar{u})) dt \right).$$

Z (3.2.3) plyne, že pro každé  $\varphi \in \mathbb{R}^n$  máme

$$(1 - \rho\Lambda) \|\varphi\|^2 \leq \varphi^T (I - \rho J''(\bar{u} + t(u^k - \bar{u}))) \varphi \leq (1 - \rho\lambda) \|\varphi\|^2.$$

Integrací dostaneme

$$(1 - \rho\Lambda) \|\varphi\|^2 \leq \varphi^T \left( I - \rho \int_0^1 J''(\bar{u} + t(u^k - \bar{u})) dt \right) \varphi \leq (1 - \rho\lambda) \|\varphi\|^2$$

a tedy

$$\left| \varphi^T \left( I - \rho \int_0^1 J''(\bar{u} + t(u^k - \bar{u})) dt \right) \varphi \right| \leq q := \max(|1 - \rho\Lambda|, |1 - \rho\lambda|).$$

Položíme-li  $\rho = \frac{2}{\lambda + \Lambda}$ , dostaneme  $q = (\Lambda - \lambda)/(\Lambda + \lambda)$ . Z lemmat 5 a 6 plyne, že

$$\left\| I - \rho \int_0^1 J''(\bar{u} + t(u^k - \bar{u})) dt \right\| = \sigma \left( I - \rho \int_0^1 J''(\bar{u} + t(u^k - \bar{u})) dt \right) \leq q.$$

Odtud a z (3.2.8) ihned dostaneme (3.2.5).  $\square$

Nevýhodou algoritmu 1 je, že požadavek (3.2.3), který zaručuje konvergenci, vyžaduje znalost čísel  $\lambda$ ,  $\Lambda$ . Ověření podmínky (3.2.3) je v praxi ale obvykle značně obtížné, ne-li nemožné. Proto je často používán algoritmus 2.

**Věta 30** *Nechť v algoritmu 2 je  $M = \infty$  a  $\varepsilon = 0$ . Dále předpokládejme, že  $J \in C^1(\mathbb{R}^n)$  a  $\nabla J$  splňuje lokálně Lipschitzovu podmínu v  $\mathbb{R}^n$ . Pak každý hromadný bod  $\hat{u} \in \mathbb{R}^n$  posloupnosti  $\{u^m\}_{m=0}^\infty$  vypočtené pomocí algoritmu 2 splňuje podmínu*

$$\nabla J(\hat{u}) = 0. \quad (3.2.12)$$

*Důkaz:* Nechť existuje podposloupnost  $\{u^{m_i}\}_{i=0}^{\infty}$  taková, že

$$u^{m_i} \rightarrow \hat{u} \in \mathbb{R}^n \quad \text{pro } i \rightarrow \infty. \quad (3.2.13)$$

Z konstrukce posloupnosti  $\{u^m\}_{m=0}^{\infty}$  plyne, že posloupnost  $\{J(u^m)\}_{m=0}^{\infty}$  je nerostoucí. Tedy, protože  $m_{i+1} \geq m_i + 1$ , máme

$$J(u^{m_{i+1}}) - J(u^{m_i}) \leq J(u^{m_i+1}) - J(u^{m_i}). \quad (3.2.14)$$

Prvek  $u^{m_i+1}$  je vypočten z  $u^{m_i}$  podle algoritmu 2, podle kterého platí

$$J(u^{m_i+1}) - J(u^{m_i}) \leq J(u^{m_i} + \rho \varphi^{m_i}) - J(u^{m_i}) \quad \forall \rho > 0. \quad (3.2.15)$$

Z věty o střední hodnotě plyne existence  $\theta_\rho \in [0, 1]$  takového, že

$$\begin{aligned} & J(J^{m_i} + \rho \varphi^{m_i}) - J(u^{m_i}) \\ &= \rho \nabla J(u^{m_i} + \theta_\rho \rho \varphi^{m_i}) \cdot \varphi^{m_i} \\ &= -\rho \nabla J(u^{m_i} + \theta_\rho \rho \nabla J(u^{m_i})) \cdot \nabla J(u^{m_i}). \end{aligned} \quad (3.2.16)$$

Ze spojitosti  $\nabla J$  a předpokladu, že  $u^{m_i} \rightarrow \hat{u}$  pro  $i \rightarrow \infty$  plyne, že

$$\varphi^{m_i} = -\nabla J(u^{m_i}) \rightarrow -\nabla J(\hat{u}) \quad \text{pro } i \rightarrow \infty. \quad (3.2.17)$$

Dále dokážeme, že existují  $i^{**} \geq 0$  celé a  $\rho > 0$  tak, že

$$\begin{aligned} & \rho \nabla J(u^{m_i} - \theta \rho \nabla J(u^{m_i})) \cdot \nabla J(u^{m_i}) \\ & \geq \frac{\rho}{4} \|\nabla J(\hat{u})\|^2 \quad \forall i > i^{**}, \quad \forall \theta \in [0, 1]. \end{aligned} \quad (3.2.18)$$

Za tím účelem zvolme okolí  $\mathcal{O}_\varepsilon(\hat{u})$  o poloměru  $\varepsilon > 0$ . V důsledku (3.2.13) a (3.2.17) existují  $i^* \geq 0$  celé a  $\hat{\rho} > 0$  takové, že

$$u^{m_i}, u^{m_i} - \theta \rho \nabla J(u^{m_i}) \in \mathcal{O}_\varepsilon(\hat{u}) \quad \forall i > i^*, \quad \forall \rho \in (0, \hat{\rho}), \quad \forall \theta \in [0, 1]. \quad (3.2.19)$$

Dále je zřejmé, že existuje konstanta  $K > 0$  tak, že

$$\|\nabla J(x) - \nabla J(y)\| \leq K \|x - y\| \quad \forall x, y \in \overline{\mathcal{O}_\varepsilon(\hat{u})}. \quad (3.2.20)$$

Odtud a z (3.2.19) vidíme, že

$$\begin{aligned} & \|\nabla J(u^{m_i} - \theta \rho \nabla J(u^{m_i})) - \nabla J(u^{m_i})\| \\ & \leq \rho K \|\nabla J(u^{m_i})\| \quad \forall i > i^*, \quad \forall \rho \in (0, \hat{\rho}), \quad \forall \theta \in [0, 1]. \end{aligned} \quad (3.2.21)$$

V důsledku této nerovnosti platí:

$$\begin{aligned} & \rho \nabla J(u^{m_i} - \theta \rho \nabla J(u^{m_i})) \cdot \nabla J(u^{m_i}) \\ &= \rho \|\nabla J(u^{m_i})\|^2 + \rho \nabla J(u^{m_i}) \cdot (\nabla J(u^{m_i} - \theta \rho \nabla J(u^{m_i})) - \nabla J(u^{m_i})) \\ &\geq \rho \|\nabla J(u^{m_i})\|^2 (1 - \rho K) \quad \forall i > i^*, \quad \forall \rho \in (0, \hat{\rho}), \quad \forall \theta \in [0, 1]. \end{aligned} \quad (3.2.22)$$

Z (3.2.17) plyne, že existuje  $i^{**} \geq i^*$  takové, že

$$\|\nabla J(u^{m_i})\|^2 \geq \frac{1}{2} \|\nabla J(\hat{u})\|^2 \quad \forall i > i^{**}. \quad (3.2.23)$$

Nyní zvolme  $\rho \in (0, \hat{\rho})$  tak malé, že  $\frac{1}{2}(1 - \rho K) \geq \frac{1}{4}$ . Pak

$$\frac{1}{2}\rho \|\nabla J(\hat{u})\|^2 (1 - \rho K) \geq \frac{1}{4}\rho \|\nabla J(\hat{u})\|^2.$$

Odtud, z (3.2.22) a (3.2.23) dostaneme ihned (3.2.18).

Nyní již můžeme dokončit důkaz věty. Shrňme-li (3.2.15), (3.2.16) a (3.2.18), vidíme, že existují  $i^{**} \geq 0$  a  $\rho > 0$  takové, že pro všechna  $i > i^{**}$  platí odhad

$$J(u^{m_{i+1}}) - J(u^{m_i}) \leq -\frac{1}{4}\rho \|\nabla J(\hat{u})\|^2 \leq 0. \quad (3.2.24)$$

Z (3.2.13) a spojitosti funkce  $J$  plyne, že

$$J(u^{m_{i+1}}) - J(u^{m_i}) \rightarrow 0 \quad \text{pro } i \rightarrow \infty.$$

takže  $\|\nabla J(\hat{u})\|^2 = 0$ , což jsme chtěli dokázat.  $\square$

*Důsledek.* Splňuje-li  $J$  předpoklady věty 30 a  $J$  je koercivní, pak z posloupnosti  $\{u^m\}_{m=0}^\infty$  lze vybrat podposloupnost konvergentní k nějakému  $\hat{u} \in \mathbb{R}^n$  a tudíž  $\nabla J(\hat{u}) = 0$ . Potom  $\hat{u}$  je bodem lokálního minima nebo tzv. sedlovým bodem. Je ale nepravděpodobné, že bychom při praktické realizaci dostali konvergenci k sedlovému bodu.

Jestliže  $J$  splňuje předpoklady věty 30 a  $J$  je koercivní a ryze konvexní, pak  $u^m \rightarrow \bar{u} \in \mathbb{R}^n$  pro  $m \rightarrow \infty$  a  $\bar{u}$  je jediným bodem minima funkce  $J$ .

## REJSTŘÍK

- algoritmy
  - numerické minimalizační, 44
- aposteriorní odhady, 17
- aposteriorní
  - odhad chyby, 18
- bod
  - lokálního minima, 40
  - minima, 40
- chyba
  - akumulovaná diskretizační, 8
  - akumulovaná diskretizační, 11, 31
  - diskretizační, 20
  - lokální diskretizační, 10
  - lokální relativní diskretizační, 10, 30
- metody, 8
  - zaokrouhlvací, 20
  - zaokrouhlvací akumulovaná, 19
  - zaokrouhlvací lokální, 19
- chyby
  - zaokrouhlvací, 18
- délka kroku, 44
- derivace
  - směrová, 41
- diference
  - zpětné, 34
- formule
  - Gillova, 16
  - korektoričková, 26
  - prediktorová, 26
  - standardní, 16
  - triosminová, 16
- funkce
  - koercivní, 40
  - konvexní, 41
  - Lipschitzova, 10
  - lipschitzovská, 9
  - přírůstková, 8, 9
  - ryze konvexní, 41
- gradient, 41
- interpolace, 1
- matice, 3
  - blokově třídiagonální, 38
- Hessova, 43
- ostře diagonálně dominantní, 3, 4
- třídiagonální, 3
- metoda
  - obecná  $k$ -kroková, 25
  - dvojkroková, 8
  - Eulerova, 7, 8, 16
  - explicitní, 25
  - implicitní, 25
  - konečných diferencí, 38
  - konsistentní, 10, 27
  - konvergentní, 9, 27
  - největšího spádu
    - s konst. krokem, 45
    - s optimálním krokem, 45
  - poločinného kroku, 17, 18
  - prediktor-korektor, 26
  - Rungeova-Kuttova druhého řádu, 7, 8, 14, 26
  - silně stabilní, 31
  - stabilní, 27
  - sítí, 38
  - vícekroková, silně stabilní, 31
- metody
  - Adams-Bashforthovy, 36
  - Adams-Moultonovy, 36
  - adaptivní, 18
  - diskrétní, 7
  - jednokrokové, 8
  - optimalizace, 39
  - prediktor-korektor, 37
  - Rungeovy-Kuttovy, 13
  - Rungeovy-Kuttovy druhého řádu, 15
  - Rungeovy-Kuttovy třetího řádu, 15
  - Rungeovy-Kuttovy čtvrtého řádu, 15
  - vícekrokové, 25
- minimum
  - absolutní, globální, 40
  - lokální, 40
- moment splinu, 2
- nejhorší scénář, 20
- operátor
  - diferenciální  $D$ , 12
  - Laplaceův, 37
- optimální řízení, 40
- parametr, 5
  - napěťový, 5
- pivotace, 19

- polynom, 1
  - charakteristický, 22, 24
  - Lagrangeův interpolační, 1
- princip
  - Duhamelův, 24
- procesy
  - iterační, 44
- přírůstek
  - přesný relativní, 10
- rovnice, 6
  - Fuchsova typu, 7
  - obyčejné diferenciální, 6
  - charakteristická, 22
  - prvního řádu, 6
  - vyššího řádu, 6
- směr největšího spádu, 44
- směr spádu, 44
- soustava
  - diferenčních rovnic, 20
  - lineárních diferenčních rovnic, 20
  - homogenní, 20
- splajn, kubický interpolační, 4
- spline, 1
  - Hermiteův, 5
  - kubický, 1
  - kubický interpolační, 2, 4
  - přirozený, 2
  - s napětím, 5
- spline, přirozený, 5
- systém
  - reálný fundamentální, 24
  - fundamentální, 21, 24
- Taylorův vzorec, 14
- věta
  - Banachova o kontrakci, 25
  - Picardova, 9
- řád
  - metody, 27
  - soustavy, 21

## LITERATURA

1. Feistauer M.: *Diskrétní metody řešení diferenciálních rovnic*, 1981.
2. Přikryl P.: *Numerické metody matematické analýzy*, (MVŠT 24), SNTL.
3. Vitásek E., Prager E. : *Numerická matematika I., II.*
4. Ralston, A.: *Základy numerické matematiky*.
- [H]. Henrici: *Discrete Variable Methods for ODE's*.