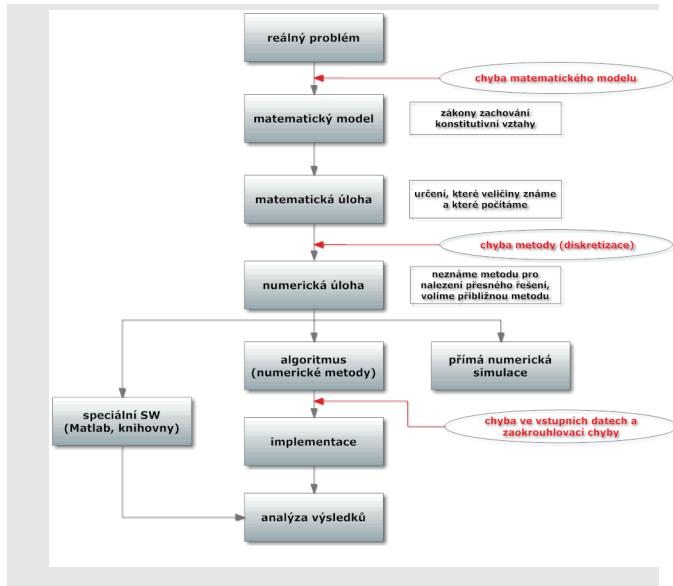


Kapitola 1. Úvod do numerické matematiky

Numerická matematika = věda, která se zabývá řešením matematicky formulovaných úloh pomocí logických operací a aritmetických operací s čísly o konečné délce.



Příklad

Reálný problém ... intravenózní dávkování léku

Matematický model

- nezávisle proměnná je pouze čas t
- šíření látky není závislé na prostorových proměnných

- popis pomocí diferenciální rovnice

$$\frac{dC}{dt} = -k \cdot C$$

kde C je koncentrace látky v krvi a $k > 0$ je absorpční koeficient

- počáteční podmínka

$$C(0) = C_0$$

chyba matematického modelu odpovídá zjednodušujícím předpokladům

Matematická úloha

- chceme vypočítat hodnotu koncentrace látky v čase $t \in [0, T]$

Numerická úloha

- řešení hledáme pouze v konečně mnoha bodech (diskretizujeme čas, $t_0 = 0$, $t_n = n \cdot \frac{T}{N}$, $t_N = T$)
 N je počet dělení intervalu $[0, T]$

chyba diskretizace (metody)

Numerická metoda

- derivaci $\frac{dC}{dt}$ approximujeme poměrnou diferenci

$$\frac{C_{n+1} - C_n}{\frac{T}{N}} = -k \cdot C_n$$

chyba diskretizace (metody)

Výpočet

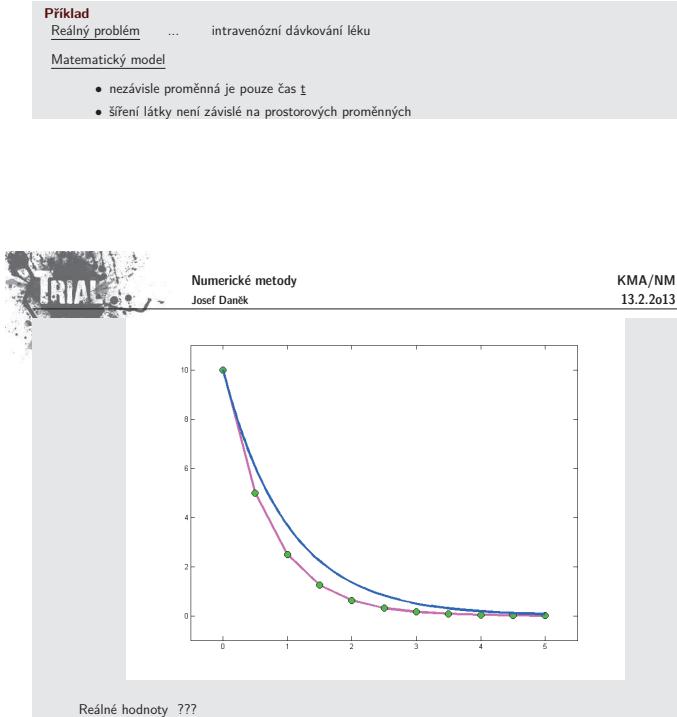
$$C_{n+1} = \left(1 - \frac{T}{N} \cdot k\right) \cdot C_n, \quad C_0 \text{ dán}$$

zaokrouhlovací chyby

Analytické řešení

$$C(t) = C_0 \cdot e^{-kt}$$

např.: $C(0) = 10$, $k = 1$, $T = 5$, $N = 10$



Reálné hodnoty ???

CHYBY

x ... přesná hodnota

\hat{x} ... přibližná hodnota

absolutní chyba ... $A(x) = |x - \hat{x}| \leq \frac{a(x)}{\text{odhad}}$

relativní chyba ... $R(x) = \frac{A(x)}{|x|} \leq \frac{r(x)}{\text{odhad}}$

Pozn.: Při odečítání „blízkých“ čísel roste relativní chyba (ztráta platných číslic)

$$a(x \pm y) = a(x) + a(y)$$

$$|(x \pm y) - (\hat{x} \pm \hat{y})| \leq |x - \hat{x}| + |\hat{y} - y|$$

$$r(x \pm y) = \frac{a(x) + a(y)}{|x \pm y|} \quad |x \pm y| \rightarrow 0_+ \text{ !!!}$$

Pozn.: Násobení a dělení nemohou podstatně zvětšit relativní chybu

$$a(x \cdot y) = |x| \cdot a(y) + |y| \cdot a(x)$$

$$|xy - \hat{xy}| = |xy - \hat{x}\hat{y} + \hat{x}\hat{y} - \hat{xy}| = |y(x - \hat{x}) + \hat{x}(y - \hat{y})| \leq |y| \cdot |x - \hat{x}| + |x| \cdot |y - \hat{y}|$$

$$r(x \cdot y) = r(x) + r(y)$$

$$\begin{aligned} \frac{|x|a(y) + |y|a(x)}{|xy|} &= \frac{a(y)}{|y|} + \frac{a(x)}{|x|} \\ a\left(\frac{x}{y}\right) &= \frac{|x| \cdot a(y) + |y| \cdot a(x)}{y^2} \\ \left|\frac{x}{y} - \frac{\hat{x}}{\hat{y}}\right| &= \left|\frac{1}{y\hat{y}}(x\hat{y} - \hat{x}y)\right| = \left|\frac{1}{y\hat{y}}(\underbrace{x\hat{y}}_{\approx y} - xy + xy - \hat{x}y)\right| = \\ &= \left|\frac{1}{y\hat{y}}(x(\hat{y} - y) + y(x - \hat{x}))\right| \leq \frac{1}{y^2}(|x| \cdot |\hat{y} - y| + |y| \cdot |x - \hat{x}|) \\ r\left(\frac{x}{y}\right) &= r(x) + r(y) \\ \frac{|x|a(y) + |y|a(x)}{|y|} &= \frac{a(y)}{|y|} + \frac{a(x)}{|x|} \end{aligned}$$

Definice: Mějme dány dvě množiny X (vstupní data) a Y (výstupní data). Předpokládejme, že X, Y jsou Banachovy prostory. **Úlohou** rozumíme relaci

$$y = U(x), \quad x \in X, \quad y \in Y.$$

Definice: Řekneme, že úloha je **korektní** na dvojici prostorů (X, Y) , když

- $\forall x \in X \exists y \in Y : y = U(x)$ (zobrazení),

- řešení y spojité závisí na vstupních datech

$$\forall \{x_n\} : x_n \rightarrow x, \quad U(x_n) = y_n : y_n \rightarrow y = U(x).$$

Poznámka: Banachův prostor = **úplný** + **normovaný**

úplný prostor: metrický prostor, kde \forall Cauchyovská posl. $u_n \subset X$ má limitu $u \in X$

normovaný prostor = množina X :

- a) X je lineární;

- b) $\forall u \in X \rightarrow ||u||$:

$$||u|| \geq 0, \quad ||u|| = 0 \Leftrightarrow u = 0;$$

$$||au|| = |a| \cdot ||u|| \quad \forall a \in \mathbb{R};$$

$$||u + v|| \leq ||u|| + ||v||;$$

$$c) d(u, v) = ||u - v||$$

Poznámka: Protože X, Y jsou Banachovy prostory, lze spojitost zaručit podmírkou

$$||y_n - y||_Y \leq L ||x_n - x||_X$$

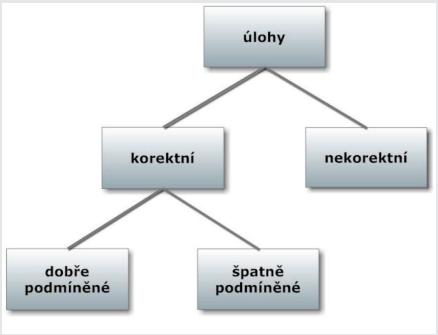
Poznámka: **Nekorektní** úlohy jsou úlohy, které nejsou korektní.
Někdy je nekorektnost způsobena pouze nevhodnou formulací.

Definice: Úloha je **dobře podmíněná**, jestliže malá relativní změna ve vstupních datech vyvolá malou relativní změnu řešení.

Číslo podmíněnosti úlohy $y = U(x)$

$$C_p = \frac{\|\Delta y\|}{\|y\|} / \frac{\|\Delta x\|}{\|x\|}$$

Poznámka: Je-li $C_p \approx 1$ je úloha velmi dobré podmíněná.
V praxi hovoříme o špatně podmíněné úloze pro $C_p \gtrsim 100$.



Příklad 1

Posuďte podmíněnost úlohy určit hodnotu funkce $y = \sin(x)$
a) v bodě 3,14;
b) v bodě -0,01.

- a) Volíme $x = 3,14$, $\Delta x = 0,01 \leftarrow$ malá změna na vstupu
 $(y) = \sin x = \sin 3,14 = 0,0015926$
 $(y + \Delta y) = \sin(x + \Delta x) = \sin 3,15 = -0,0084072$
 $\Delta y = \sin(x + \Delta x) - \sin x = -0,0099998 \leftarrow$ změna na výstupu

$$\text{Relativní chyba na vstupu: } \frac{|\Delta x|}{|x|} \doteq 0,0031847$$

$$\text{Relativní chyba na výstupu: } \frac{|\Delta y|}{|y|} \doteq 6,2789149$$

$$C_p \doteq 1971,6 \rightarrow \text{špatně podmíněná úloha}$$

b) Volíme $x = -0,01$, $\Delta x = 0,01$

$$\begin{aligned} \sin x &= -0,0099998 \\ \sin(x + \Delta x) &= \sin 0 = 0 \\ \Delta y &= 0,0099998 \end{aligned}$$

$$\text{Relativní chyba na vstupu: } \frac{|\Delta x|}{|x|} \doteq 1$$

$$\text{Relativní chyba na výstupu: } \frac{|\Delta y|}{|y|} \doteq 1$$

$$C_p \doteq 1 \rightarrow \text{velmi dobré podmíněná úloha}$$

Poznámka: Podívejme se na předchozí příklad obecnější. Úloha má tvar $y = f(x)$.

Podle věty o střední hodnotě platí:

$$|\Delta y| \approx |f'(x)| \cdot |\Delta x|$$

odtud:

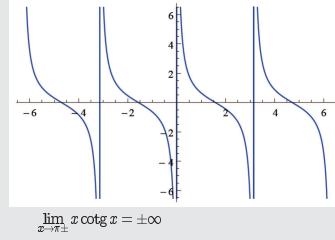
$$\left| \frac{\Delta y}{y} \right| \approx \frac{|f'(x)| \cdot |\Delta x|}{|f(x)|} = \left| \frac{x \cdot f'(x)}{f(x)} \right| \cdot \left| \frac{\Delta x}{x} \right|$$

Tedy

$$C_p \approx \left| \frac{x \cdot f'(x)}{f(x)} \right|$$

$$v \text{ našem případě: } y = \sin x \Rightarrow y' = \cos x$$

$$C_p \approx \left| \frac{x \cos x}{\sin x} \right| = |x \cot g x|$$



$$\lim_{x \rightarrow \pm \pi/2} x \cot x = \pm \infty$$

$$\lim_{x \rightarrow 0^\pm} x \frac{\cos x}{\sin x} = \cos 0 \cdot \lim_{x \rightarrow 0} \frac{x}{\sin x} = 1 \cdot 1 = 1$$

Poznámka: Podobné příklady (posuďte podmíněnost úlohy určit hodnotu):

a) $f(x) = x^\alpha, x \rightarrow 0, x > 0$

$$C_p = \left| \frac{x f'(x)}{f(x)} \right| = \left| \frac{x \alpha x^{\alpha-1}}{x^\alpha} \right| = \alpha$$

b) $f(x) = \arcsin x, x \rightarrow 1, x < 1$

$$C_p = \left| \frac{x f'(x)}{f(x)} \right| = \left| \frac{x \frac{1}{\sqrt{1-x^2}}}{\arcsin x} \right| = \left| \frac{1}{\sqrt{1-x^2}} \left(\frac{x}{\arcsin x} \right)^{-1} \right| \xrightarrow{x \rightarrow 1} \infty$$

c) $f(x) = x - 1, x \rightarrow 1$

$$C_p = \left| \frac{x \cdot 1}{x-1} \right| \rightarrow \infty$$

Příklad 2

Posuďte podmíněnost úlohy řešit soustavu lineárních algebraických rovnic (pro $\alpha \neq \pm 1$)

$$x + \alpha y = 1$$

$$\alpha x + y = 0$$

$$x(1 - \alpha^2) = 1$$

$$x = \frac{1}{1 - \alpha^2}$$

$$y = -\frac{\alpha}{1 - \alpha^2}$$

Nechť vstup je hodnota α a výstup hodnota x .

Pak

$$C_p = \frac{|\Delta x|}{|\alpha|} \approx \left| \frac{\alpha \frac{dx}{d\alpha}}{x} \right| \approx \left| \frac{\alpha \frac{2\alpha}{(1-\alpha^2)^2}}{\frac{1}{1-\alpha^2}} \right| = \frac{2\alpha^2}{1-\alpha^2}$$

\Rightarrow pro $\alpha^2 \rightarrow 1$ je tato úloha špatně podmíněná!

* viz předchozí poznámka

** $\frac{dx}{d\alpha} = \frac{d}{d\alpha} \left(\frac{1}{1-\alpha^2} \right) = -\left(\frac{1}{(1-\alpha^2)^2} (-2\alpha) \right)$

Pozn.: Matice výše uvedené soustavy je pro hodnoty α blízké ± 1 skoro singulární.

„U nestabilní metod (algoritmu) se relativně malé chyby v jednotlivých krocích výpočtu postupně akumulují tak, že dojde ke katastrofální ztrátě přesnosti numerického řešení úlohy.“

– Při výpočtu dochází k zaokrouhlovacím chybám. Je proto vhodné vybírat algoritmy málo citlivé na zaokrouhlovací chyby.

Stabilní algoritmus

- dobré podmíněny - málo citlivý na poruchy ve vstupních datech
- numericky stabilní - málo citlivý na vliv zaokrouhlovacích chyb

Poznámka:

U stabilních metod roste chyba výsledku s počtem kroků N nejvýše lineárně
(v ideálním případě, kdy je znaménko chyby náhodné, zaokrouhlovací chyba roste $\sim \sqrt{N}$).

U nestabilních metod roste zaokrouhlovací chyba rychleji, např. geometrickou řadou $\sim q^N$, kde $|q| > 1$.

Příklad 3

Řešte diferenční rovnici (rekurentní formule, nestabilní rekurzí)

$$x_{n+1} = \frac{13}{3}x_n - \frac{4}{3}x_{n-1}, \quad x_0 = 1, \quad x_1 = \frac{1}{3}$$

Snadno se ukáže, že řešení je $x_n = \frac{1}{3^n}$ (dosazením).

Při numerickém výpočtu dojdeme k problémům (viz obr.). Hodnoty x_n začnou velmi rychle klesat. Pro vysvětlení ukážeme obecné řešení zadání diferenční rovnice.

- charakteristický polynom

$$\lambda^2 = \frac{13}{3}\lambda - \frac{4}{3}$$

$$(předpokládáme řešení λ^n): \quad \lambda^{n+1} = \frac{13}{3}\lambda^n - \frac{4}{3}\lambda^{n-1})$$

- kořeny

$$\lambda_{1,2} = \frac{\frac{13}{3} \pm \sqrt{(\frac{13}{3})^2 - 4 \cdot \frac{4}{3}}}{2} = \frac{\frac{13}{3} \pm \sqrt{\frac{125}{9}}}{2}, \quad \text{tj. } \lambda_1 = \frac{1}{3}, \lambda_2 = 4$$

- obecné řešení

$$x_n = A \cdot \left(\frac{1}{3} \right)^n + B \cdot 4^n$$

$$x_0 = 1 = A \cdot \left(\frac{1}{3} \right)^0 + B \cdot 4^0 = A + B = 1$$

$$x_1 = \frac{1}{3} = A \cdot \left(\frac{1}{3} \right)^1 + B \cdot 4^1 = \frac{1}{3} \cdot A + 4 \cdot B = \frac{1}{3}$$

$$\Rightarrow A = 1, B = 0$$

Přes počáteční podmínu $B = 0$ vznikou vlivem zaokrouhlovacích chyb malé druhé komponenty řešení

Výsledky z MATLABu, FORMAT SHORT, pevná čárka na 5 číslic

```

clc;
clear;
format short;

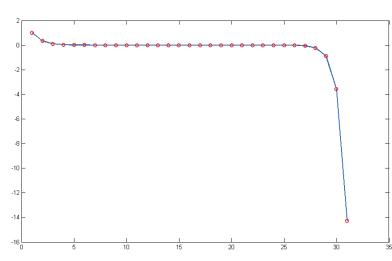
n=30;

x(1)=1;
x(2)=1/3;

for i=2:n
    x(i+1)=13/3*x(i)-4/3*x(i-1);
end

plot(1:n+1,x,'b-',1:n+1,x,'ro');

```

**Příklad 4**

Vypočtěte přibližně hodnotu

$$J_n = \int_0^1 \frac{x^n}{x+5} dx$$

Platí:

$$\int_0^1 x^{n-1} dx = \int_0^1 \frac{x^{n-1}(x+5)}{x+5} dx = \underbrace{\int_0^1 \frac{x^n}{x+5} dx}_{J_n} + 5 \underbrace{\int_0^1 \frac{x^{n-1}}{x+5} dx}_{J_{n-1}}$$

$$\left[\frac{1}{n} x^n \right]_0^1 = \frac{1}{n}$$

Dále:

$$J_0 = \int_0^1 \frac{1}{x+5} dx = [\ln|x+5|]_0^1 = \ln \frac{6}{5}$$

Rekurentní formule:

$$J_0 = \ln \frac{6}{5}$$

$$J_n = -5 \cdot J_{n-1} + \frac{1}{n}$$

Nestabilní algoritmus! ... vždy $\exists n_0 : J_{n_0} < 0$!

Proto je lépe postupovat odzadu:

- dokážeme, že $\lim_{n \rightarrow \infty} J_n = 0$

$$|J_n| = \left| \int_0^1 \frac{x^n}{x+5} dx \right| \leq \int_0^1 \left| \frac{x^n}{x+5} \right| dx \leq \frac{1}{5} \int_0^1 x^n dx = \frac{1}{5(n+1)} \xrightarrow{n \rightarrow \infty} 0$$

- např. zvolíme $J_{100} = 0$ a počítáme $J_{n-1} = -\frac{1}{5}(J_n - \frac{1}{n})$

$$J_{100} = 0$$

$$J_{n-1} = -\frac{1}{5} \cdot J_n + \frac{1}{5n}$$

Výsledky z MATLABu, FORMAT SHORT E

```

clc;
clear;
format short e;

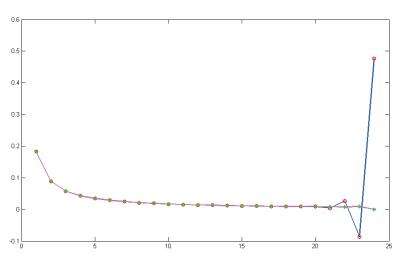
n=24;

J(1)=log(6/5);
JJ(n)=0;

for i=1:n-1
    J(i+1) = -5*J(i) + 1/i;
end
for i=n-1:-1:1
    JJ(i) = (1/i - JJ(i+1)) / 5;
end

[J' JJ']
plot(1:n,J,'b-',1:n,J,'ro');
hold on
plot(1:n,JJ,'m-',1:n,JJ,'g*');

```



J	JJ
1.8232e-001	1.8232e-001
8.8392e-002	8.8392e-002
5.8039e-002	5.8039e-002
4.3139e-002	4.3139e-002
3.4306e-002	3.4306e-002
2.8468e-002	2.8468e-002
2.4325e-002	2.4325e-002
2.1233e-002	2.1233e-002
1.8837e-002	1.8837e-002
1.6926e-002	1.6926e-002
1.5368e-002	1.5368e-002
1.4071e-002	1.4071e-002
1.2977e-002	1.2977e-002
1.2040e-002	1.2040e-002
1.1229e-002	1.1229e-002
1.0522e-002	1.0522e-002
9.8903e-003	9.8903e-003
9.3719e-003	9.3719e-003
8.6960e-003	8.6960e-003
9.1515e-003	9.1515e-003
4.2426e-003	4.2426e-003
2.6406e-002	2.6406e-002
-8.6575e-002	-8.6575e-002
4.7635e-001	0

Zobrazení čísel

Motivace: $\sum_{k=1}^{10000} \frac{1}{10} = 9998,55664$

- Lidé používají desítkovou soustavu.
- Počítače dvojkové.

Komunikace s počítačem

- Zadání v 10-soustavě.
- Převod do 2-soustavy (počítač).
- Výpočet (počítač).
- Zpětný převod do 10-soustavy (počítač).
- Výsledek v 10-soustavě.

Soustavydesítková

$$1563 = (1 \cdot 10^3) + (5 \cdot 10^2) + (6 \cdot 10^1) + (3 \cdot 10^0)$$

obecně

$$N = (a_k \cdot 10^k) + (a_{k-1} \cdot 10^{k-1}) + \dots + (a_1 \cdot 10^1) + (a_0 \cdot 10^0)$$

(N ∈ N), $a_k \in \{0, 1, 2, \dots, 9\}$

znázornění

$$N = a_k a_{k-1} a_{k-2} \dots a_1 a_0$$

dvojková

$$1563 = (1 \cdot 2^9) + (1 \cdot 2^8) + (0 \cdot 2^7) + (0 \cdot 2^6) + (0 \cdot 2^5) + (1 \cdot 2^4) + (1 \cdot 2^3) + (1 \cdot 2^2) + (1 \cdot 2^1)$$

$$[1563]_{10} = (11000011011)_2$$

Binární zlomky

lze vyjádřit jako sumu se zápornými mocninami dvou

$$R \in \mathbb{R} \quad 0 < R < 1 \quad d_j \in \{0, 1\}$$

$$R = (d_1 \cdot 2^{-1}) + (d_2 \cdot 2^{-2}) + \dots + (d_n \cdot 2^{-n}) + \dots$$

$$R = (0, d_1 d_2 \dots d_n \dots)_2$$

Zápis čísel

v desítkové soustavě (vědecká notace)

$$0,000747 = 7,47 \cdot 10^{-4}$$

$$313,815 = 3,13815 \cdot 10^2$$

- Strojová čísla

normalizovaná pohybivá řádová čárka (REAL)

$$x = \pm q \cdot 2^n \quad \frac{1}{2} \leq q < 1 \dots \text{mantisa}, \quad n \dots \text{exponent}$$

Poznámka: Mnoho reálných čísel, které lze v desítkové soustavě zapsat pomocí konečného počtu cifer, pro zápis ve dvojkové soustavě vyžaduje nekonečně mnoho cifer.



$$(0,7)_{10} = (0,10110)_2 = 1 \cdot 2^{-1} + \sum_{k=0}^{\infty} 1 \cdot 2^{-(3+4k)} + \sum_{k=0}^{\infty} 1 \cdot 2^{-(4+4k)} = \\ = 2^{-1} + 2^{-3} \cdot \sum_{k=0}^{\infty} (2^{-4})^k + 2^{-4} \cdot \sum_{k=0}^{\infty} (2^{-4})^k = \frac{1}{2} + \frac{1}{8} \cdot \underbrace{\frac{1}{1-\frac{1}{16}}}_{=\frac{16}{15}} + \frac{1}{16} \cdot \frac{16}{15} = \\ = \frac{1}{2} + \frac{2}{15} + \frac{1}{15} = \frac{15+4+2}{30} = \frac{21}{30} = \frac{7}{10}$$

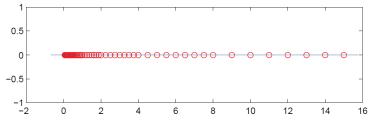
Příklad:

Sestrojte všechna strojová čísla s mantisou délky 4 a exponentem v rozsahu od -3 do 4, tj.
 $x = q \cdot 2^n$, kde $q = 0, d_1 d_2 d_3 d_4$, $n \in \{-3, -2, -1, 0, 1, 2, 3, 4\}$

Abychom si lépe uvědomili jakou mantisu a jakým exponentem je určeno získané číslo, uvedeme si je v následující tabulce.

$q \setminus n$	-3	-2	-1	0	1	2	3	4
0.1000 ₂	0.0625	0.125	0.25	0.5	1	2	4	8
0.1001 ₂	0.0703125	0.140625	0.28125	0.5625	1,125	2,25	4,5	9
0.1010 ₂	0.078125	0.15625	0.3125	0.625	1,25	2,5	5	10
0.1011 ₂	0.0859375	0.171875	0.34375	0.6875	1,375	2,75	5,5	11
0.1100 ₂	0.09375	0,1875	0.375	0.75	1,5	3	6	12
0.1101 ₂	0.1015625	0.203125	0.40625	0.8125	1,625	3,25	6,5	13
0.1110 ₂	0.109375	0.21875	0.4375	0.875	1,75	3,5	7	14
0.1111 ₂	0.1171875	0.234375	0.46875	0.9375	1,875	3,75	7,5	15

Získaná čísla si je také vhodné vykreslit na číselnou osu, získáme tak přehled o jejich rozložení. Snadno zjistíme, že čísla nejsou rozložena rovnoměrně.



pomocná funkce v MATLABu



```
function [A,P]=stroj_cisla(cisel_mantisy,exponent,zobraz);
%
% [A,P]=stroj_cisla(4,-3:4,1);
%
for i=1:length(exponent)
    for j=0:2^(cisel_mantisy)-1
        zaklad=dec2bin(j);
        zakladstr=num2str(zaklad);
        for k=1:cisel_mantisy-length(zakladstr)-1
            zakladstr=strcat('0',zakladstr);
        end;
        zakladstr=strcat('1',zakladstr);
        zaklad=bin2dec(zakladstr)*2^(-cisel_mantisy);
        A(j+1,i)=zaklad*2^exponent(i);
    end;
end;
[k,l]=size(A);
P=sort(reshape(A,1,k*l));
%
if zobraz==1
    figure(1);
    plot(P,zeros(size(P)),'ro');
    pr=(P(k*1)-P(1))/20;
    hold on;
    plot([P(1)-pr,P(k*1)+pr],[0 0],'b-');
    end;
format short g;
```

Příklad 5:

Uvažujme množinu strojových čísel vygenerovanou v předchozím příkladu (tj. strojová čísla s mantisou délky 4 a exponentem v rozsahu od -3 do 4). Předpokládáme, že počítač zobrazí číslo na nejbližší číslo, které lze zobrazit, v případě shody na větší.

Ukažme si, jak se v tomto stroji sečtu čísla $\frac{1}{10}$ a $\frac{1}{5}$.

Výsledky získané z MATLABu



Zobrazení součtu cisel A a B v zadane mnozine strojovych cisel s mantisou delky M a exponentem v rozsahu od Exp_min do Exp_max

```
Cislo A = 0.100000
Cislo B = 0.200000
Pocet cisel mantisy M = 4
Rozsah pro exponent: od -3 do 4

cislo      zapis obrazu      obraz
-----
```

A = 0.100000	0.1101 x 2^-3	0.1015625
B = 0.200000	0.1101 x 2^-2	0.203125
obrazA+obrazB=		0.3046875
		0.1010 x 2^-1
A+B=		0.300000
		0.1010 x 2^-1
		0.3125

Poznámka:

V tomto příkladě se shodoval obraz přesného výsledku s obrazem součtu obrazů jednotlivých sčítanců.

Příklad 6:

Uvažujme množinu strojových čísel vygenerovanou v předchozím příkladu (tj. strojová čísla s mantisou délky 4 a exponentem v rozsahu od -3 do 4). Předpokládáme, že počítač zobrazí číslo na nejbližší číslo, které lze zobrazit, v případě shody na větší.

Ukažme si, jak se v tomto stroji sečtu čísla $\frac{3}{10}$ a $\frac{1}{6}$.

Výsledky získané z MATLABu



Zobrazení součtu cisel A a B v zadane mnozine strojovych cisel s mantisou delky M a exponentem v rozsahu od Exp_min do Exp_max

```
Cislo A = 0.300000
Cislo B = 0.166667
Pocet cisel mantisy M = 4
Rozsah pro exponent: od -3 do 4

cislo      zapis obrazu      obraz
-----
```

A = 0.300000	0.1010 x 2^-1	0.3125
B = 0.166667	0.1011 x 2^-2	0.171875
obrazA+obrazB=		0.484375
		0.1000 x 2^0
A+B=		0.466667
		0.1011 x 2^0
		0.46875

Poznámka:

V tomto příkladě se obraz přesného výsledku s obrazem součtu obrazů jednotlivých sčítanců neshodoval !

Chyba výpočtu:

$$\frac{7}{15} - 0,1000_2 \cdot 2^0 = \frac{14-15}{30} = -\frac{1}{30} = -0,0\overline{3}$$

Relativní:

$$\frac{\frac{1}{30}}{\frac{1}{15}} = \frac{1}{2} = 7,14\% \quad !!!$$

Přesnost počítací

- Vymezíme-li pro mantisu 24 bitů, získáme 7 desetinných míst ($2^{24} = 16777216$).
- Vymezíme-li pro mantisu 32 bitů, získáme 9 desetinných míst ($2^{32} = 4294967296$).

Základní formáty:

Formát	Bytes	Bitů pro mantisu	Bitů pro exponent
Single	4	24	8
Double	8	53	11

Příklad:

- Uvažujme formát SINGLE, tj. 24 bitů pro mantisu.

$$\frac{1}{10} = 0,00011_2 \approx 0,11001100110011001100_2 \cdot 2^{-3}.$$

$$\text{Chyba zobrazení je } 0,1100_2 \cdot 2^{-27} (= \frac{1}{10} \cdot 2^{-24}) \approx 5,96 \cdot 10^{-9}.$$

- Máme-li počítat $\sum_{k=1}^{100000} \frac{1}{10}$, dostaneme ve formátu SINGLE 9,998,55604.

Chyba musí být větší než $100000 \cdot 5,96 \cdot 10^{-9} = 5,96 \cdot 10^{-4}$.

Ve skutečnosti je chyba ještě větší, neboť se v průběhu výpočtu musí částečně suma zaokrouhlovat dolů nebo nahoru, jak sumu roste, později přičítaná čísla $\frac{1}{10}$ jsou oproti sumě menší a jsou tedy počítány s menší přesností (viz následující příklad).

Příklad:

Ve formátu SINGLE sečtěte čísla 10000 a 0,1.

```
-----  
Prevod císla 10000 z 10-soustavy do 2-soustavy na 0 desetinných míst  
Cela cast ..... 10000  
Desetinnna cast ..... 0.000000  
-----  
prevod_cele_casti =  
  
10000 : 2 = 5000 : 2 = 2500 : 2 = 1250 : 2 = 625 : 2 = 312 : 2 =  
0 0 0 0 1 0  
  
= 156 : 2 = 78 : 2 = 39 : 2 = 19 : 2 = 9 : 2 = 4 : 2 = 2 : 2 = 1  
0 0 1 1 1 0 1  
  
Cílo 10000 v 10-soustavě prevedeno do 2-soustavy je 10011100010000.
```

$$(10000)_{10} = (10011100010000)_2 = 0,100111001 \cdot 2^{14} \\ (2^{14} = 16384)$$

$$10000 \dots 0,1001110010000000000000 \cdot 2^{14}$$

$$0,1 \dots 0,110011001100110011001100 \cdot 2^{-3}$$

$$0,1 \text{ po SHIFTU} \dots 0,000000000000000101000110 \cdot 2^{14} \\ = (01100110)_2 \cdot 2^{-24} \cdot 2^{14} = (64 + 32 + 4 + 2) \cdot 2^{-10} = \\ = \frac{102}{1024} = 0,099609375$$

$$10000 + 0,1 \dots 0,100111001000000010100110 \cdot 2^{14}$$

Číslo 10000 je zobrazeno přesně.

Chyba zobrazení 0,1 po SHIFTU je $\frac{1}{10} - \frac{102}{1024} = 0,1 - 0,099609375 = 3,90625 \cdot 10^{-4}$

Shrnutí:

$$10000 + 0,1 \rightarrow \text{výsledek s chybou } 3,90625 \cdot 10^{-4}$$

(v sumě z motivativního příkladu jde o jeden krok)

```
s=0;  
h=single(1/10);  
  
for i=1:100000  
    s=s+h;  
end;  
  
s
```

Kapitola 2. Nelineární rovnice

Formulace:

Je dána funkce $f : \mathbb{R} \rightarrow \mathbb{R}$ definovaná na intervalu $\langle a, b \rangle$. Hledáme $x \in \langle a, b \rangle$ tak, aby $f(x) = 0$. (x ... kořen rovnice)

Poznámka:

Nají přesné řešení analyticky je možné jen ve velmi jednoduchých případech, např. při řešení lineární rovnice $12x - 3 = 0$, při řešení kvadratické rovnice $4x^2 - 5x + 8 = 0$ nebo např. při řešení rovnice $\sin 5x = \pi$. Proto je nutné pro nalezení kořenů použít nějakou numerickou metodu.

Numerické metody, kterými se budeme zabývat, jsou založeny na iteračních principech. Pro každou iterační metodu nás budou zajímat odpovědi na dvě otázky:

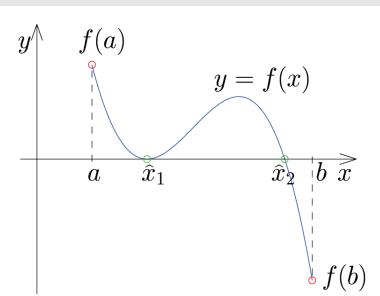
- Konverguje posloupnost iteračí ke hledanému kořenu?
- Jestliže ano, jak rychle?

Věta:

Předpokládejme, že
(i) reálná funkce f je spojitá pro $x \in \langle a, b \rangle$,
(ii) $f(a)f(b) < 0$.

Potom existuje aspoň jedno řešení x rovnice $f(x) = 0$ na $\langle a, b \rangle$.

Větu ilustruje následující obrázek.



Startovací metody

- metoda půlení intervalu

- regula falsi
- metoda prosté iterace

Zpřesňující metody

- Newtonova metoda
- metoda sečen
- Mullerova metoda

Metoda prosté iterace

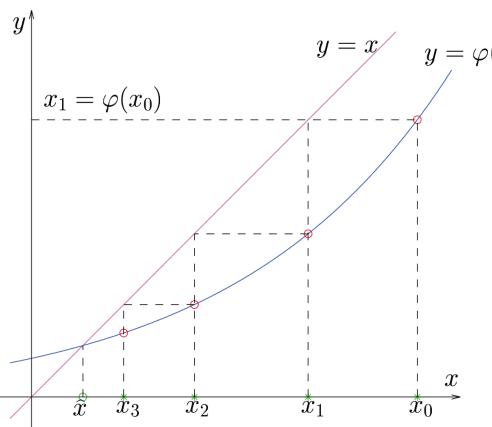
Všechny (jednobodové) iterační metody lze pokládat za speciální případ této metody.

Princip:

- původní rovnici $f(x) = 0$ přepišeme na tvar $x = \varphi(x)$
- existuje celá řada možností, jak to udělat!
- na konkrétní volbě funkce φ závisí konvergence metody rychlosť konvergence

Algoritmus:

- 1) Zadáme $x_0 \in \langle a, b \rangle$, $\varepsilon > 0$
- 2) $x_{k+1} = \varphi(x_k)$
- 3) Je-li $|x_{k+1} - x_k| < \varepsilon$, pak $x = x_{k+1}$, KONEC
jinak jdi na 2)

**Příklad 1**Metodou prosté iterace najděte na intervalu $\langle 1, 4 \rangle$ řešení rovnice

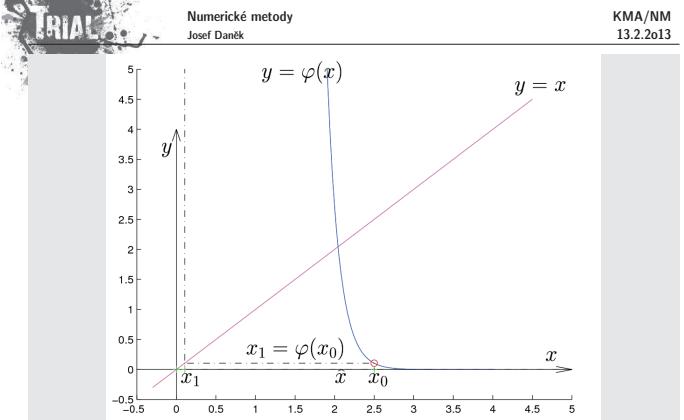
$$x^2 + \ln x - \frac{10}{x} = 0,$$

Za počáteční iteraci volte střed zadaného intervalu, tj. $x_0 = 2,5$.**Řešení**Ukážeme si 4 způsoby přepisu rovnice $f(x) = 0$ na tvar $x = \varphi(x)$.1. způsob:

$$\ln x = \frac{10}{x} - x^2 \Rightarrow x = e^{\left(\frac{10}{x} - x^2\right)} \quad \text{tj. } \varphi(x) = e^{\left(\frac{10}{x} - x^2\right)}$$

k	x_k
0	2.5
1	1.3954
2	4.3852
3	0.4829
4	-20.2122

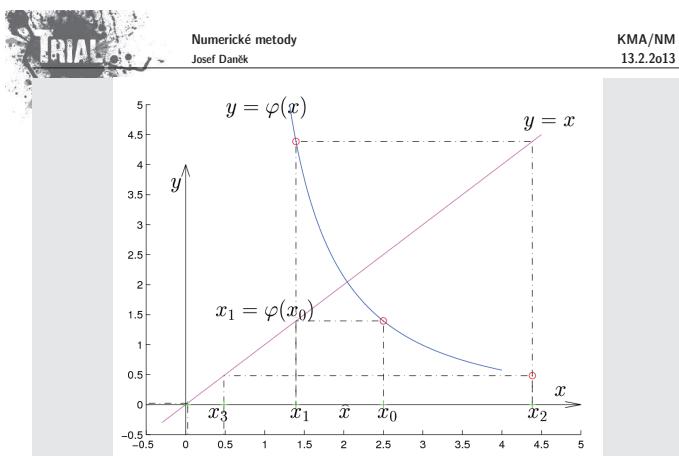
Již první iterace x_1 je mimo zadaný interval, navíc druhá iterace x_2 je velmi velké číslo a proto metoda prosté iterace nekonverguje.

2. způsob:

$$x^2 + \ln x - \frac{10}{x} = 0 \Rightarrow x = \frac{10}{x^2 + \ln x} \quad \text{tj. } \varphi(x) = \frac{10}{x^2 + \ln x}$$

k	x_k
0	2.5
1	1.3954
2	4.3852
3	0.4829
4	-20.2122

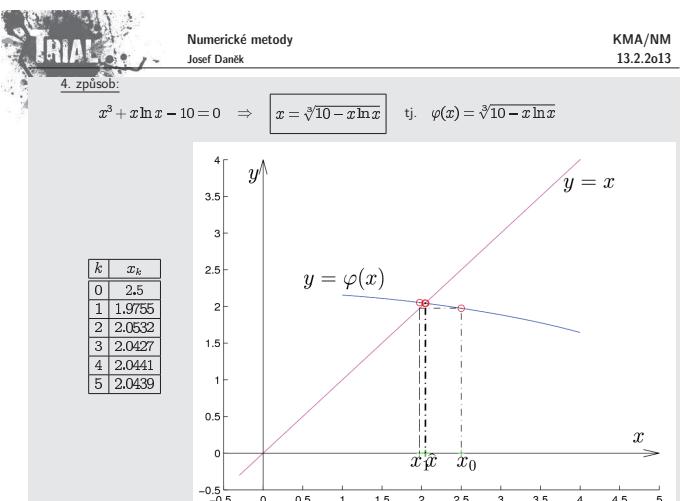
Podobně jako v předchozím případě, zde je 2. iterace x_2 mimo zadaný interval a metoda prosté iterace opět nekonverguje.

3. způsob:

$$x^2 = \frac{10}{x} - \ln x \Rightarrow x = \sqrt{\frac{10}{x} - \ln x} \quad \text{tj. } \varphi(x) = \sqrt{\frac{10}{x} - \ln x}$$

k	x_k
0	2.5
1	1.7560
2	2.2653
3	1.8905
4	2.1524
5	1.9696
6	2.0974
7	2.0067
8	2.0704
9	2.0254
10	2.0571
11	2.0347
12	2.0505
13	2.0393
14	2.0472
15	2.0416
16	2.0455
17	2.0428
18	2.0447
19	2.0434

V tomto případě metoda prosté iterace konvergovala k výsledku \hat{x} , rychlosť "zahušťování" byla ovšem malá.



V tomto posledním případě metoda prosté iterace konvergovala k výsledku \hat{x} velmi rychle. To dokazuje tento fakt, že když použijeme pro zastavení podmínu, aby absolutní hodnota rozdílu dvou po sobě jdoucích iterací byla menší než 10^{-10} potřebovaly bychom k tomu pouze 10 iterací.

Poznámka:

Chování metody prosté iterace je závislé na zvoleném předpisu pro funkci $\varphi = \varphi(x)$. Porovnáním grafů z předchozího příkladu lze usoudit, že je vhodné, aby se funkce $\varphi(x)$ co nejvíce blížila konstantní funkci.

Věta (Postačující podmínky konvergence metody prosté iterace.)

Předpokládejme, že je funkce φ na intervalu $I = \langle a, b \rangle$ spojitá a platí:

(a) $\forall x \in I : \varphi(x) \in I$ (funkce φ zobrazuje I do sebe),

(b) $\exists q \in (0, 1) : |\varphi(x) - \varphi(y)| \leq q|x - y| \quad \forall x, y \in I$ (funkce φ je kontrakce).

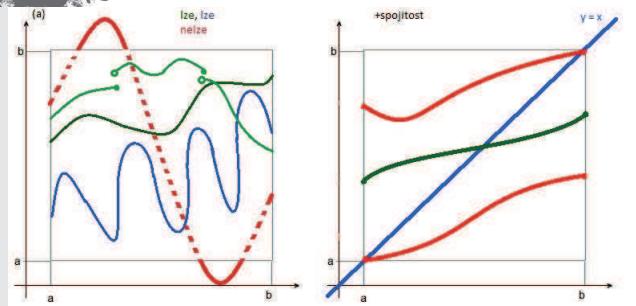
Potom

1) v intervalu I existuje právě jeden kořen α rovnice $x = \varphi(x)$.

2) posloupnost $\{x_k\}_{k=1}^{\infty}$ určená formulí $x_k = \varphi(x_{k-1})$ konverguje pro každé $x_0 \in I$ a $\lim_{k \rightarrow \infty} x_k = \alpha$.

Důkaz

1) [existence] je důsledkem podmínky (a) a spojitosti φ



$$\Rightarrow \varphi(x) \geq a, \varphi(x) \leq b \quad \forall x \in (a, b)$$

musí platit

$$\begin{aligned} \varphi(a) &\geq a, \varphi(b) \leq b \\ \varphi(a) &\leq b, \varphi(b) \geq a \end{aligned}$$

[jednoznačnost] plyne z vlastnosti (b)

DK sporem: Předpokládejme, že existují 2 různé hodnoty $\alpha_1 \neq \alpha_2$ takové, že

$$\alpha_1 = \varphi(\alpha_1), \quad \alpha_2 = \varphi(\alpha_2)$$

Potom platí:

$$|\alpha_2 - \alpha_1| = |\varphi(\alpha_2) - \varphi(\alpha_1)| \underset{(b)}{\overset{\text{spor}}{\leq}} q \cdot |\alpha_2 - \alpha_1| \underset{\text{spor}}{\leq} |\alpha_2 - \alpha_1|$$

2) Platí:

$$\begin{aligned} x_k &= \varphi(x_{k-1}) \\ \alpha &= \varphi(\alpha) \end{aligned}$$

po odečtení:

$$x_k - \alpha = \varphi(x_{k-1}) - \varphi(\alpha)$$

$$|x_k - \alpha| = |\varphi(x_{k-1}) - \varphi(\alpha)| \underset{(b)}{\leq} q \cdot |x_{k-1} - \alpha| \quad (*)$$

(*) \Rightarrow

$$|x_k - \alpha| \leq q \cdot |x_{k-1} - \alpha|$$

$$|x_k - \alpha| \leq q \cdot |x_1 - \alpha| \leq q^2 \cdot |x_0 - \alpha|$$

...

$$|x_k - \alpha| \leq \underbrace{q^k}_{(**) \text{ konst.}} |x_0 - \alpha| \quad \forall x_0 \in (a, b)$$

(**) $q^k \rightarrow 0$ pro $k \rightarrow \infty$ ($|q| < 1$)

Poznámka:

Povídáte se na související předchozí věty a volby funkce φ v jednotlivých případech příkladu 1.

Poznámka:

Pro diferencovatelnou funkci φ lze podmínu (b) nahradit podmínkou

$$(b') \exists q \in (0, 1) : |\varphi'(x)| \leq q \quad \forall x \in I$$

Poznámka:

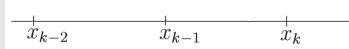
Rychlosť konvergencie metody prosté iteracie je charakterizovaná $|\varphi'(x_k)|$, jelikož lze psať

$$\varphi'(x_k) \approx \frac{\varphi(x_{k+1}) - \varphi(x_k)}{x_{k+1} - x_k} = \frac{x_{k+2} - x_{k+1}}{x_{k+1} - x_k}.$$

Poznámka:

Souvislost "zahušťování iteraci" a hodnoty φ'

$$a) \quad q \lesssim 1 \quad \Rightarrow \quad |x_k - x_{k-1}| \lesssim |x_{k-1} - x_{k-2}|$$

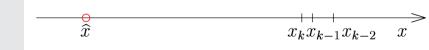


$$b) \quad q \approx 0 \quad \Rightarrow \quad |x_k - x_{k-1}| \ll |x_{k-1} - x_{k-2}|$$



Poznámka:

Jak bylo řečeno hodnota rozdílu dvou po sobě jdoucích iterací neodpovídá obecně chybě přibližného řešení. Geometricky si to lze představit takto:



Odhad chyby metody prosté iteracie

- Máme konvergentní proces $x_k = \varphi(x_{k-1}), k = 1, 2, \dots$
- Přesné řešení α splňuje vztah $\alpha = \varphi(\alpha), \lim_{k \rightarrow \infty} x_k = \alpha$

- Po odečtení dostaneme $x_k - \alpha = \varphi(x_{k-1}) - \varphi(\alpha)$

$$\text{tj. } |x_k - \alpha| = |\varphi(x_{k-1}) - \varphi(\alpha)|$$

←

- Předpokládáme, že φ je lipchitzovská s konstantou $q \in (0, 1)$, tj. musí platit:

$$|\varphi(x_{k-1}) - \varphi(\alpha)| \leq q \cdot |x_{k-1} - \alpha|$$

←

- Dále použijeme Δ nerovnost:

$$|x_{k-1} - \alpha| = |x_{k-1} - x_k + x_k - \alpha| \leq |x_{k-1} - x_k| + |x_k - \alpha|$$

←

- Z posledních 3 vztahů dostaneme:

$$|x_k - \alpha| \leq q \cdot |x_{k-1} - x_k| + q \cdot |x_k - \alpha|$$

$$(1-q) \cdot |x_k - \alpha| \leq q \cdot |x_{k-1} - x_k| \quad / \cdot \frac{1}{1-q} > 0$$

$$|x_k - \alpha| \leq \frac{q}{1-q} \cdot |x_{k-1} - x_k|$$

- Použijeme-li zastavovací podmínu

$$|x_k - x_{k-1}| < \varepsilon,$$

potom platí odhad chyby

$$|x_k - \alpha| \leq \frac{q}{1-q} \varepsilon$$

Příklad 2

Pomocí metody prosté iteracie řešete na intervalu $(0, 4)$ rovnici

$$x - \sqrt{x+4} = 0.$$

přesné řešení:

$$x = \sqrt{x+4} / 2$$

$$x^2 = x + 4$$

$$x^2 - x - 4 = 0$$

$$x_{1,2} = \frac{1 \pm \sqrt{17}}{2} \Rightarrow x_1 \approx 2.5615, x_2 \approx -1.5615 \notin (0, 4)$$

- Rovnicí přepíšeme na tvar: $x = \sqrt{x+4}$

$$\varphi(x)$$

- Ověříme splnění předpokladů věty o postačujících podmínkách konvergence metody prosté iteracie:

$$(a) \quad \forall x \in (0, 4) : 0 \leq \sqrt{x+4} \leq 4$$

$$0 \leq x+4 \leq 16$$

$$-4 \leq x \leq 12$$

$$(b) \quad \forall x \in (0, 4) :$$

$$|\varphi(x)| < 1$$

$$\left| \frac{1}{2\sqrt{x+4}} \right| < 1$$

$$\frac{1}{2\sqrt{x+4}} < 1$$

$$1 < 2\sqrt{x+4}$$

$$1 < 4x + 16$$

$$-15 < 4x$$

- Vlastní výpočet:

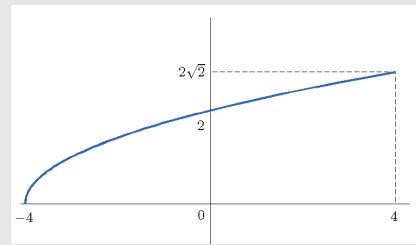
volíme $x_0 = 2$ a pro zastavovací podmínu hodnotu $\varepsilon = 0.001$.

k	x_k
0	2
1	2.4494
2	2.5395
3	2.5572
4	2.5607
5	2.5613

$$\Rightarrow \tilde{x} = x_5 = 2.5613.$$

- Odhadněme velikost chyby přibližného řešení předchozího příkladu.

Graf funkce $\varphi(x)$:



Plati:

$$\varphi' = \frac{1}{2\sqrt{x+4}} \quad \dots \quad \text{kladná klesající funkce}$$

$$(\varphi'') = \left(\frac{1}{2}(x+4)^{-\frac{1}{2}}\right)' = -\frac{1}{4}(x+4)^{-\frac{3}{2}} = -\frac{1}{4(x+4)\sqrt{x+4}} < 0$$

↓

$$\max_{0 \leq x \leq 4} |\varphi'(x)| = |\varphi'(0)| = \frac{1}{4} = q \quad \dots \quad \text{podmínka (b')}$$

Zvolili jsme $\varepsilon = 0,001$ a proto platí odhad chyby:

$$|x_5 - \alpha| \leq \frac{\frac{1}{4}}{1 - \frac{1}{4}} \cdot 0,001 = 0,000333$$

Definice: Říkáme, že posloupnost x_k konverguje k číslu α rychlosť r , jestliže pro $k \rightarrow \infty$

$$|x_{k+1} - \alpha| = c|x_k - \alpha|^r + O(|x_k - \alpha|^{r+1}).$$

Mluvíme o asymptotické rychlosti konvergence ($k \rightarrow \infty$).

Poznámka:

$$f(x) = O(g(x)) \text{ pro } x \rightarrow a \Leftrightarrow \left| \frac{f(x)}{g(x)} \right| \text{ je omezená (a nenulová) pro } x \rightarrow a.$$

Příklady:

$$\begin{aligned} \text{a)} \quad & |x^5 \cdot \sin x| = O(x^5) \text{ pro } x \rightarrow \infty \Leftrightarrow \left| \frac{x^5 \cdot \sin x}{x^5} \right| = |\sin x| \leq 1 \quad \text{pro } x \rightarrow \infty \\ \text{b)} \quad & |x^5 \cdot \sin x| = O(x^6) \text{ pro } x \rightarrow 0 \Leftrightarrow \left| \frac{x^5 \cdot \sin x}{x^6} \right| = \left| \frac{\sin x}{x} \right| \rightarrow 1 \quad \text{pro } x \rightarrow 0 \end{aligned}$$

Rychlosť konvergence metody prosté iterace

Je-li funkce φ dostatečně hladká, můžeme napsat její Taylorův rozvoj v bodě α a potom pro $x = x_{k-1}$ platí:

$$\begin{aligned} \varphi(x_{k-1}) &= \varphi(\alpha) + \varphi'(\alpha)(x_{k-1} - \alpha) + \frac{\varphi''(\alpha)}{2}(x_{k-1} - \alpha)^2 + \frac{\varphi'''(\xi)}{6}(x_{k-1} - \alpha)^3 \\ x_k - \alpha &= \varphi'(\alpha)(x_{k-1} - \alpha) + \frac{\varphi''(\alpha)}{2}(x_{k-1} - \alpha)^2 + \frac{\varphi'''(\xi)}{6}(x_{k-1} - \alpha)^3 \end{aligned}$$

• je-li $\varphi'(\alpha) \neq 0$, potom

$$x_k - \alpha = \varphi'(\alpha)(x_{k-1} - \alpha)^1 + O((x_{k-1} - \alpha)^2)$$

⇒ rychlosť konvergence je řádu 1

• je-li $\varphi'(\alpha) = 0$ a $\varphi''(\alpha) \neq 0$, potom

$$x_k - \alpha = \frac{\varphi''(\alpha)}{2}(x_{k-1} - \alpha)^2 + O((x_{k-1} - \alpha)^3)$$

⇒ rychlosť konvergence je řádu 2

Newtonova metoda

Předpoklady:

Nechť v intervalu $I = (a, b)$ leží jediný jednoduchý kořen \hat{x} rovnice $f(x) = 0$. Jelikož mluvíme o zpřesňující

metodě, předpokládáme, že máme zadánu nultou iteraci $x_0 \in I$, která je relativně blízko hledanému řešení. Vyhádime Taylorův rozvoj funkce f v bodě x_0 . Přitom předpokládáme, že existuje průsíkelné derivace funkce f .

$$f(x) = f(x_0) + f'(x_0)(x - x_0) + \frac{1}{2}f''(\xi)(x - x_0)^2$$

Rovnici $f(x) = 0$ nahradíme lineární rovnici

$$f(x_0) + f'(x_0)(x - x_0) = 0$$

Ta má kořen

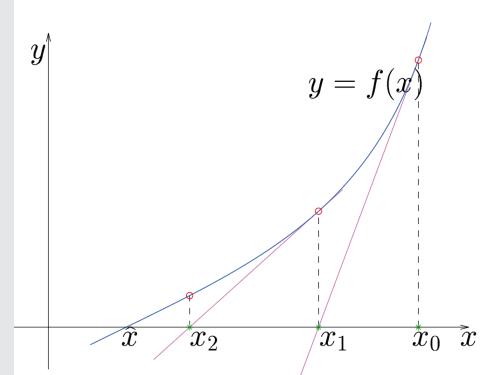
$$x_1 = x_0 - \frac{f(x_0)}{f'(x_0)}$$

Celý postup opakujeme a dostaváme iterační formuli

$$x_{k+1} = x_k - \frac{f(x_k)}{f'(x_k)}$$

Geometrický význam Newtonovy metody:

Křivku $y = f(x)$ nahradíme tečnou ke grafu v bodě x_k a hodnotu x_{k+1} získáme jako průsečík tečny s osou x . Proto se také Newtonova metoda nazývá **metoda tečen** nebo **metoda linearizace**.



Poznámka:

Jako zastavovací podmínu lze např. volit $|x_{k+1} - x_k| < \varepsilon$ nebo $|f(x_k)| < \delta$.

Poznámka:

Algoritmus Newtonovy metody je speciálním případem metody prosté iterace. Za funkci φ jsme volili funkci

$$\varphi(x) = x - \frac{f(x)}{f'(x)},$$

Rychlosť konvergence Newtonovy metody

1. způsob odvození (Newtonova metoda jako speciální případ metody prosté iterace)

Rychlosť konvergence závisí na $\varphi'(\alpha)$, resp. $\varphi''(\alpha) \dots$ (viz dříve).

Platí:

$$\begin{aligned} \varphi(\hat{x}) &= x - \frac{f(x)}{f'(x)} \\ \varphi' &= 1 - \frac{f' \cdot f' - f \cdot f''}{(f')^2} = 1 - 1 + \frac{f \cdot f''}{(f')^2} = \frac{f \cdot f''}{(f')^2} \\ \varphi''(\alpha) &= 0, \quad \text{protože } f(\alpha) = 0 \end{aligned}$$

Platí:

$$\begin{aligned} \varphi'' &= \frac{(f' \cdot f'' + f \cdot f''') \cdot (f')^2 - f \cdot f'' \cdot 2 \cdot f' \cdot f''}{(f')^4} \\ \varphi''(\alpha) &= \frac{(f')^3 \cdot f''}{(f')^4} = \frac{f''(\alpha)}{f'(\alpha)}, \quad \text{protože } f(\alpha) = 0 \end{aligned}$$

Platí tedy $\varphi'(\alpha) = 0$ a obecně $\varphi''(\alpha) \neq 0 \Rightarrow$ rychlosť konvergence je řádu 2.

2. způsob odvození

Pomoci Taylorova rozvoje funkce f v bodě x_0 (nechť existují $f'(x)$ a $f''(x)$ v I):

$$f(x) = f(x_0) + f'(x_0) \cdot (x - x_0) + \frac{1}{2} \cdot f''(\xi_0) \cdot (x - x_0)^2$$

Dosadíme za x přesné řešení α (tj. $f(\alpha) = 0$)

$$\underbrace{f(\alpha)}_{=0} = f(x_0) + f'(x_0) \cdot (\alpha - x_0) + \frac{1}{2} \cdot f''(\xi_0) \cdot (\alpha - x_0)^2$$

Vydělíme $f'(x_0) \neq 0$:

$$\begin{aligned} 0 &= \frac{f(x_0)}{f'(x_0)} + \alpha - x_0 + \frac{1}{2} \frac{f''(\xi_0)}{f'(x_0)} (\alpha - x_0)^2 \\ &= -x_1 \end{aligned}$$

$$x_1 - \alpha = \frac{1}{2} \frac{f''(\xi_0)}{f'(x_0)} (\alpha - x_0)^2$$

Proces opakujeme:

$$\begin{aligned} \underbrace{x_{k+1} - \alpha}_{\text{chyba } k+1 \text{ iterace}} &= \frac{1}{2} \frac{f''(\xi_k)}{f'(x_k)} \underbrace{(\alpha - x_k)^2}_{\text{kvadrát chyby } k\text{-té iterace}} \quad (*) \\ \Rightarrow \text{rychlosť konvergence} &= 2 \end{aligned}$$

Nechť platí

$$\frac{1}{2} \left| \frac{f''(\xi)}{f'(\eta)} \right| \leq C \quad \forall \xi, \eta \in I$$

(Určit C může být obecně problém.)

Označme-li $\varepsilon_k = x_k - \alpha$ chybou k -té iterace, potom z (*) plyne

$$|\varepsilon_{k+1}| \leq C|\varepsilon_k|^2, \quad \text{tj. } |\varepsilon_{k+1}| \leq C|\varepsilon_k|^2$$

$$|\varepsilon_1| \leq C|\varepsilon_0|^2$$

$$|\varepsilon_2| \leq C|\varepsilon_1|^2 \leq (C|\varepsilon_0|^2)^2$$

$$|\varepsilon_3| \leq C|\varepsilon_2|^2 \leq ((C|\varepsilon_0|^2)^2)^2$$

⋮

$$|\varepsilon_k| \leq C|\varepsilon_0|^{2^k}$$

Dostaváme odhad chyby:

$$|\varepsilon_k| \leq \frac{1}{C} |\varepsilon_0|^{2^k}$$

Postačující podmínka konvergence:

$$\text{Platí } |\varepsilon_1| \leq C|\varepsilon_0|^2 = \underbrace{C|\varepsilon_0|}_{\#} |\varepsilon_0|$$

Pokud bude $\# < 1$, dostaneme kontrakci.

$$|\varepsilon_0| = \sqrt{C(\alpha - x_0)} < 1$$

$$|\varepsilon_1| \leq \sqrt{C(\alpha - x_0)} < 1, \quad \text{tj. } |\varepsilon_1| < 1$$

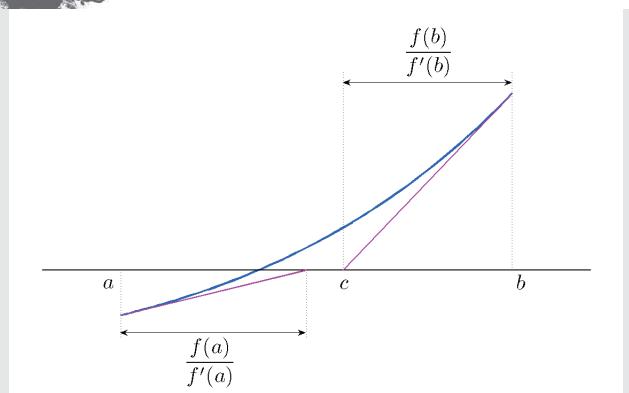
⋮

Pro "velkou" hodnotu C musí být počáteční iterace x_0 "velmi přesná".

Věta (Postačující podmínky konvergence Newtonovy metody)

Je-li $f'(x) \neq 0$, f'' neměří znaménko v $I = (a, b)$, platí-li $f(a) \cdot f(b) < 0$ a $\left| \frac{f(a)}{f'(a)} \right| < b-a$, $\left| \frac{f(b)}{f'(b)} \right| < b-a$, potom Newtonova metoda konverguje $\forall x_0 \in I$

Platnost tvrzení lze ověřit pomocí následujícího obrázku.



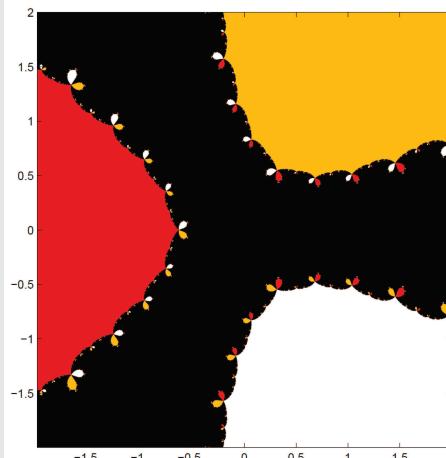
$$\text{např. } \frac{f(b) - f(c)}{b - c} = \overset{=0}{f'(c)} = f'(b) \Rightarrow b - c = \frac{f(b)}{f'(b)}$$

Praktické pravidlo pro odhad přesnosti:

Jel-li $|\alpha - x_k| < 10^{-d}$ potom $|\alpha - x_{k+1}| < 10^{-2d}$.

(pokud jsou splněny předpoklady pro odvození metody)

Rešíme-li danou rovnici Newtonovou metodou pro konkrétní počáteční approximaci ze čtverce $(-2;2) \times (-2;2)$, dostaneme jedno ze čtyř uvedených řešení. Obarvíme-li bod představující počáteční approximaci různou barvou, podle toho k jakému řešení dospejeme, získáme fraktálovou strukturu.



Pokud vykreslíme pro každý počáteční bod počet iterací nutných k rozhodnutí, ke kterému z možných kořenů metoda konverguje, dostaneme následující obrázek (tmavé odstíny znamenají malý počet iterací, světlé odstíny velký počet iterací).

Poznámka:

Dosud jsme řešili nelineární rovnici pouze v \mathbb{R} . Algoritmus Newtonovy metody můžeme však použít i pro řešení dané rovnice v oboru komplexních čísel.

Příklad 1

Newtonovou metodou řešete v komplexním oboru rovnici

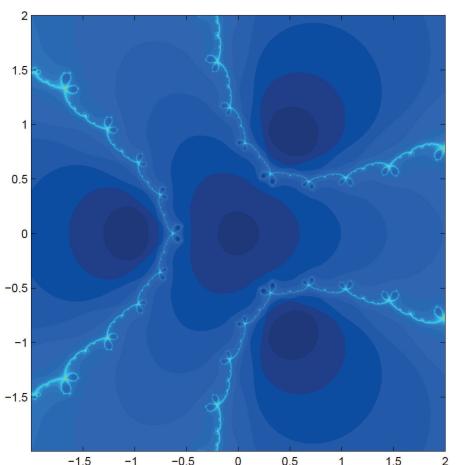
$$z^4 + z = 0, \quad z = x + iy, \quad x, y \in \mathbb{R}$$

Iterační formule bude mít tvar

$$z_{k+1} = z_k - \frac{z_k^4 + z_k}{4z_k^3 + 1}$$

Je zřejmé, že daná rovnice bude mít 4 řešení:

$$0, -1, \frac{1}{2} + \frac{\sqrt{3}}{2}i, \frac{1}{2} - \frac{\sqrt{3}}{2}i$$



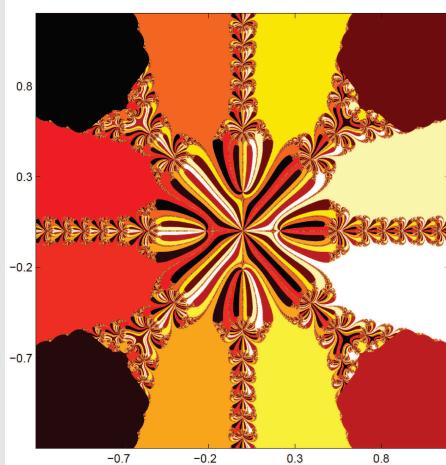
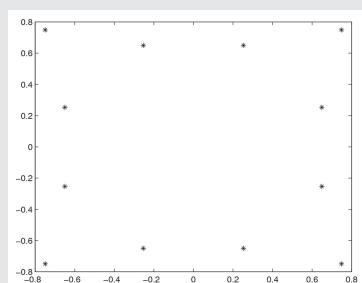
Příklad 2

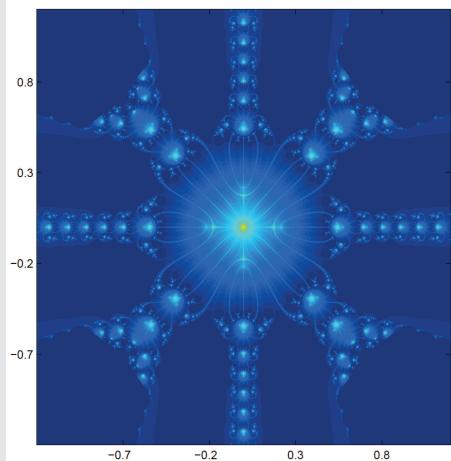
Newtonovou metodou řešete v komplexním oboru na čtverci $(-1.2;1.2) \times (-1.2;1.2)$ rovnici

$$z^{12} + 744/611z^8 - 86/10057z^4 + 25/357 = 0$$

Kořeny:

$$\begin{aligned} &-0.75 + 0.75i \\ &-0.75 - 0.75i \\ &0.75 + 0.75i \\ &0.75 - 0.75i \\ &-0.65 + 0.25i \\ &-0.65 - 0.25i \\ &-0.25 + 0.65i \\ &-0.25 - 0.65i \\ &0.25 + 0.65i \\ &0.25 - 0.65i \\ &0.65 + 0.25i \\ &0.65 - 0.25i \end{aligned}$$



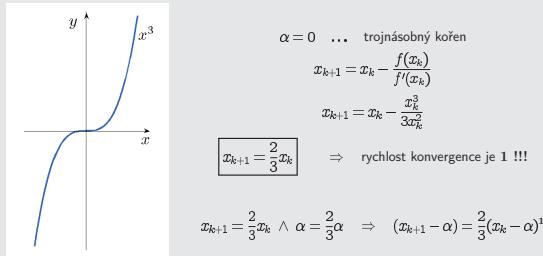


Poznámka:

Při odvozování Newtonovy metody jsme předpokládali, že $f'(\alpha) \neq 0$, tj. α je jednoduchý kořen.

Příklad:

Pomocí Newtonovy metody najděte kořen rovnice $x^3 = 0$.



Definice: Kořen α rovnice $f(x) = 0$ má **násobnost** s , jestliže $0 \neq g(\alpha) < \infty$, kde $g(x) = \frac{f(x)}{(x-\alpha)^s}$

Modifikovaná iterační formule

$$x_{k+1} = x_k - \frac{f(x_k)}{f'(x_k)} \dots \text{ již opět kvadratický iterační proces}$$

pro předchozí příklad: $x_{k+1} = x_k - \frac{3x_k^2}{3x_k^2} = x_k - x_k = 0$
nevýhoda - musíme znát násobnost s

Jiný přístup pro hledání násobných kořenů

Je-li α s -násobný kořen rovnice $f(x) = 0$, potom je α $(s-1)$ -násobným kořenem rovnice $f'(x) = 0$ a tedy jednoduchým kořenem rovnice

$$g(x) = \frac{f(x)}{f'(x)} = 0.$$

D.cv: $g'(x) = ?$

Aitkenův proces

Konverguje-li iterační metoda lineárně, lze pomocí Aitkenova procesu urychlit konvergenci.

Plati:

$$\alpha - x_{k+1} = C_{k+1}(\alpha - x_k), |C_k| < 1$$

kde $|C_k| \rightarrow C$ je asymptotická konstanta chyby.

Jsme-li blízko limity, jsou čísla C_k přibližně stejná a lze psát

$$\alpha - x_{k+1} \approx \tilde{C}(\alpha - x_k), |\tilde{C}| = C$$

Pro další iteraci

$$\alpha - x_{k+2} \approx \tilde{C}(\alpha - x_{k+1})$$

Po vyloučení \tilde{C} :

$$\begin{aligned} \frac{\alpha - x_{k+1}}{\alpha - x_k} &\approx \frac{\alpha - x_{k+2}}{\alpha - x_{k+1}} \\ (\alpha - x_{k+2})(\alpha - x_k) &\approx (\alpha - x_{k+1})^2 \\ \alpha^2 - \alpha(x_k + x_{k+2}) + x_k x_{k+2} &\approx \alpha^2 - 2\alpha x_{k+1} + x_{k+1}^2 \\ x_k x_{k+2} - x_{k+1}^2 &\approx \alpha(x_k - 2x_{k+1} + x_{k+2}) \\ \alpha &\approx \frac{x_k x_{k+2} - x_{k+1}^2}{x_k - 2x_{k+1} + x_{k+2}} \end{aligned}$$

Prakticky:

$$x_0, x_1, x_2 \rightarrow \alpha := x_3$$

$$x_3, x_4, x_5 \rightarrow \alpha := x_6$$

...

Příklad 3

Pomocí **metody prosté iterace** řešete rovnici $x^2 - x = 0$. Použijte přepis $x = \sqrt{x}$, počáteční iteraci $x_0 = 3$ a zastavovací podmínu $|x_k - x_{k-1}| < 10^{-5}$.

výsledky získané v MATLABu

krok	x(k)	dx(k)=x(k)-x(k-1)	dx(k)/dx(k-1)
0	3.000000		
1	1.732051	-1.267949	
2	1.316074	-0.415977	0.328071
3	1.147203	-0.168871	0.405963
4	1.071075	-0.076127	0.450800
5	1.034928	-0.036148	0.474833
6	1.017314	-0.017614	0.487272
7	1.008620	-0.008694	0.493600
8	1.004301	-0.004319	0.496791
9	1.002148	-0.002153	0.498393
10	1.001073	-0.001075	0.499196
11	1.000537	-0.000537	0.499598
12	1.000268	-0.000268	0.499799
13	1.000134	-0.000134	0.499899
14	1.000067	-0.000067	0.499950
15	1.000034	-0.000034	0.499975
16	1.000017	-0.000017	0.499987
17	1.000008	-0.000008	0.499994

Předchozí výpočet urychlete použitím **Aitkenova procesu**.

výsledky získané v MATLABu

Příklad 4

Pomocí **Newtonovy metody** řešete rovnici $x^2 - x = 0$. Použijte počáteční iteraci $x_0 = 3$ a zastavovací podmínu $|x_k - x_{k-1}| < 10^{-5}$.

výsledky získané v MATLABu

krok	x(k)	dx(k)=x(k)-x(k-1)	dx(k)/dx(k-1)
0	3.000000		
1	1.800000	-1.200000	
2	1.246154	-0.553846	0.461538
3	1.040603	-0.205551	0.371134
4	1.001525	-0.039078	0.190113
5	1.000002	-0.001522	0.038959
6	1.000000	-0.000002	0.001522

Rychlosť konvergence Newtonovy metody je 2, tj. pro urychlení nelze použít Aitkenův proces. Pokud bychom jej použili, výpočet se naopak zpomalí.

výsledky získané v MATLABu

Numerické metody				KMA/NM 13.2.2013
Josef Daněk				
Zpráva:				
krok	x(k)	dx(k)=x(k)-x(k-1)	dx(k)/dx(k-1)	
0	3.000000			
1	1.800000	-1.200000		
2	1.246154	-0.553846	0.461538	
Zpřesnění pomocí Aitkenovy formule				
3	0.771429	-0.474725	0.857143	
4	1.096241	0.324812	-0.684211	
5	1.007767	-0.088473	-0.272383	
Zpřesnění pomocí Aitkenovy formule				
6	1.026707	0.018940	-0.214073	
7	1.000677	-0.026030	-1.374350	
8	1.000000	-0.000677	0.025995	
Zpřesnění pomocí Aitkenovy formule				
9	0.999982	-0.000018	0.026688	
10	1.000000	0.000018	-0.974664	
11	1.000000	-0.000000	-0.000018	

Nevýhody Newtonovy metody

- zadaná funkce f musí být diferencovatelná
- derivace se přímo vyskytuje v iterační formuli
- v každé iteraci musíme kromě funkční hodnoty počítat také hodnotu derivace

Pro odbourání poslední vlastnosti můžeme za předpokladu, že se derivace f' na okolí kořene příliš nemění, Newtonovu metodu modifikovat tak, že hodnotu derivace vypočteme pouze jednou, tj. v bodě x_0 a položíme

$$f'(x_k) \approx f'(x_0).$$

Dostaneme iterační formuli **modifikované Newtonovy metody**

$$x_{k+1} = x_k - \frac{f(x_k)}{f'(x_0)}.$$

Chceme-li modifikovat Newtonovu metodu pro funkce, které nejsou diferencovatelné, nahradíme v iterační formuli derivaci $f'(x_k)$ diferenciálním podílem

$$f'(x_k) \approx \frac{f(x_k) - f(x_{k-1})}{x_k - x_{k-1}}.$$

Dostaneme iterační formuli **metody sečen**

$$x_{k+1} = x_k - f(x_k) \frac{x_k - x_{k-1}}{f(x_k) - f(x_{k-1})}.$$

Geometrický význam modifikované Newtonovy metody

Tečny ke grafu v bodech $[x_k, f(x_k)]$ nahrazujeme přímkami rovnoběžnými s tečnou ke grafu funkce $y =$

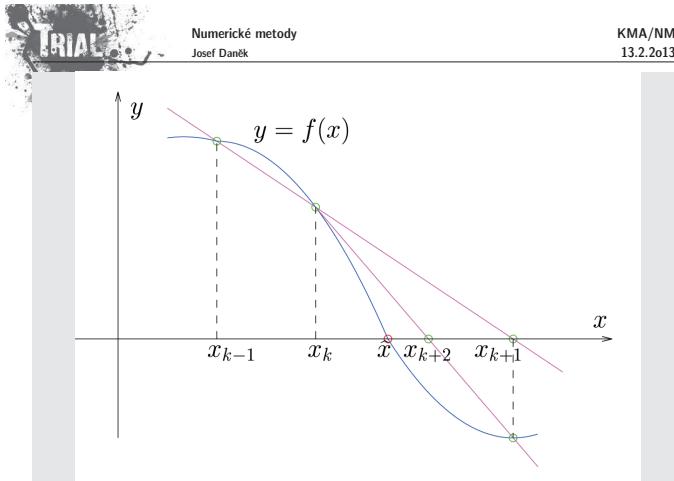
Poznámka:

V této modifikaci počítáme pouze jednu hodnotu derivace $f'(x_0)$, a proto je tento postup vhodný je-li derivace $f'(x)$ složitá. Nemění-li $f'(x)$ a $f''(x)$ znaménko, je možné dokázat konvergenci této metody.

Geometrický význam metody sečen

Mějme dvě dobré aproximace x_{k-1} a x_k kořene \hat{x} rovnice $f(x) = 0$. Křivku $y = f(x)$ nahradíme přímkou (sečnou), která prochází body $[x_{k-1}, f(x_{k-1})]$ a $[x_k, f(x_k)]$.

Další iteraci x_{k+1} získáme jako průsečík sečny s osou x .



Poznámka:

Pro zahájení výpočtu potřebujeme znát 2 počáteční approximace, ale na rozdíl od Newtonovy metody počítáme v každém kroku pouze jednu novou funkční hodnotu, což je úspora času.

Poznámka:

Metoda sečen má obdobný algoritmus jako metoda regula falsi, nepožadujeme však splnění podmínky $f(x_{k-1}) \cdot f(x_k) < 0$.

Rychlosť konvergence metody sečen

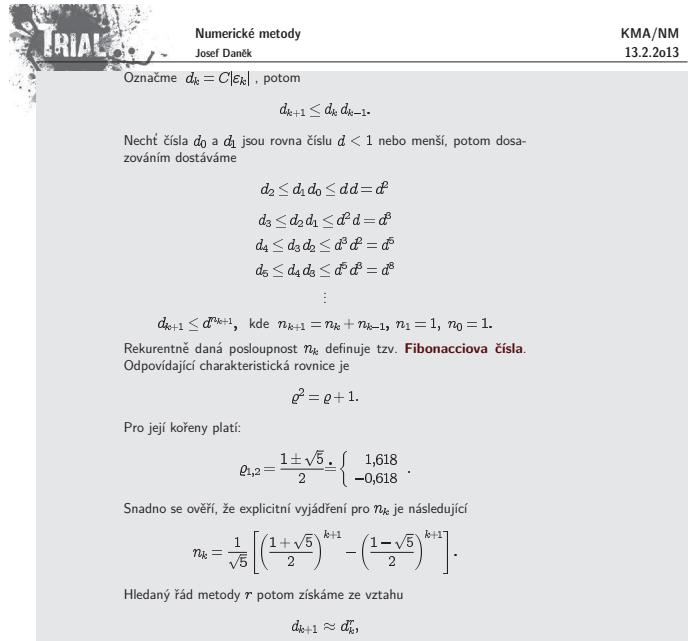
Odvozuje se podobně jako u Newtonovy metody. Nechť platí

$$\frac{1}{2} \left| \frac{f'(\xi)}{f'(\eta)} \right| \leq C \quad \forall \xi, \eta \in I.$$

Potom

$$|\varepsilon_{k+1}| \leq C \cdot |\varepsilon_k| \cdot |\varepsilon_{k-1}|.$$

Náznak odvození:



Pro rychlosť konvergence tedy dostáváme

$$r = \frac{1}{2}(1 + \sqrt{5}) \doteq 1,618 \quad (\text{pro } k \rightarrow \infty).$$

Poznámka:

Metoda sečen je tzv. dvoukroková interpolacní metoda, analogicky lze odvodit tříkrokovou interpolacní metodu, kterou nazýváme **Mullerova metoda**.

Geometrický význam Mullerovy metody

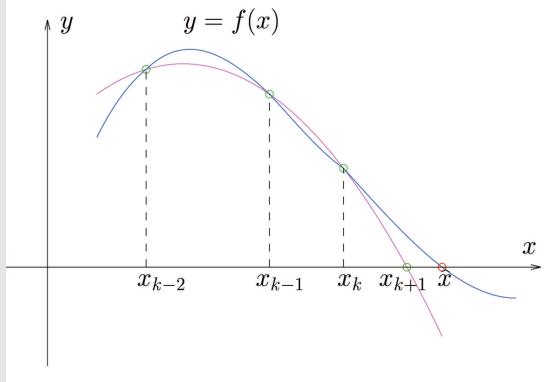
Máme tři dobré approximace x_{k-2} , x_{k-1} a x_k kořene x rovnice

$$f(x) = 0.$$

Křivku $y = f(x)$ nahradíme parabolou (kvadratickou funkci), která prochází body

$$[x_{k-2}, f(x_{k-2})], [x_{k-1}, f(x_{k-1})] \text{ a } [x_k, f(x_k)].$$

Další iteraci x_{k+1} získáme jako přešek paraboly s osou x . (Ten, který je blíže k x_k .)



Prostředky MATLABu pro řešení nelineárních rovnic

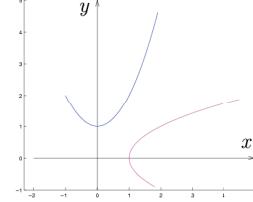
fzero pro obecnou nelineární rovnici
roots pro kořeny polynomu

Příklad:

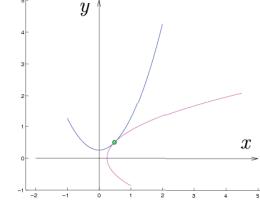
Řešte soustavu dvou rovnic pro dvě neznámé ($a \in \mathbb{R}$... parametr)

$$\begin{aligned} x^2 - y + a &= 0 \\ -x + y^2 + a &= 0 \end{aligned}$$

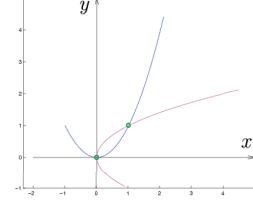
1) $a = 1$



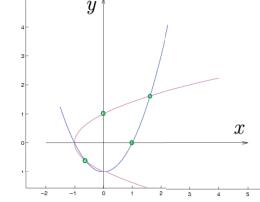
2) $a = \frac{1}{4}$



3) $a = 0$



4) $a = -1$


Formulace:

Jsou dány funkce $F_i : \mathbb{R}^n \rightarrow \mathbb{R}$, $i = 1, \dots, n$ definované na $\langle a_i, b_i \rangle$.

Označme $I = \langle a_1, b_1 \rangle \times \langle a_2, b_2 \rangle \times \dots \times \langle a_n, b_n \rangle$.

Hledáme $\mathbf{x} = (x_1, x_2, \dots, x_n)^T \in I$ tak, aby

$$F_1(\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n) = 0$$

$$F_2(\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n) = 0$$

$$\vdots$$

$$F_n(\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n) = 0$$

Vektorově:

$$\mathbf{F}(\mathbf{x}) = 0, \quad \text{kde } \mathbf{F} = (F_1, F_2, \dots, F_n)^T.$$

Věta (Postačující podmínky konvergence metody prosté iterace.)

Předpokládejme, že je funkce Φ na I spojitá a platí:

- (a) $\forall x \in I : \Phi(x) \in I$ (funkce Φ zobrazuje I do sebe),
- (b) $\exists q \in (0, 1) : ||\Phi(x) - \Phi(y)|| \leq q||x - y|| \quad \forall x, y \in I$ (funkce Φ je kontrakce).

Potom

1. v množině I existuje právě jedno řešení \mathbf{x} soustavy rovnic $\mathbf{x} = \Phi(\mathbf{x})$,
2. posloupnost $\{\mathbf{x}^k\}_{k=1}^{\infty}$ určená formulí $\mathbf{x}^k = \Phi(\mathbf{x}^{k-1})$ konverguje pro každé $\mathbf{x}^0 \in I$ a $\lim_{k \rightarrow \infty} \mathbf{x}^k = \mathbf{x}$.

Metoda prosté iterace

Soustavu rovnic $\boxed{F(\mathbf{x}) = 0}$ nahradíme soustavou rovnic $\boxed{\mathbf{x} = \Phi(\mathbf{x})}$ (více možnosti).

Algoritmus:

- 1) Zadáme $\mathbf{x}^0 \in I$, $\varepsilon > 0$
- 2) $\mathbf{x}^{k+1} = \Phi(\mathbf{x}^k)$
- 3) Je-li $||\mathbf{x}^{k+1} - \mathbf{x}^k|| < \varepsilon$, pak $\mathbf{x} = \mathbf{x}^{k+1}$, KONEC
jinak jdi na 2)

Příklad 5

Řešte metodou prosté iterace soustavu dvou rovnic pro dvě neznámé

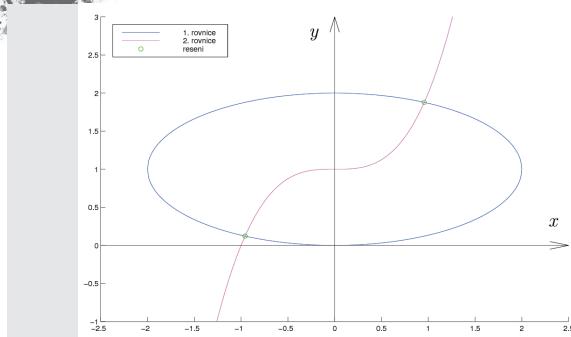
$$x^2 + 4y^2 - 8y = 0$$

$$x^3 - y + 1 = 0$$

1. rovnice je rovnici eclipsy $x^2 + 4(y-1)^2 = 4$

$$\left(\frac{x}{2}\right)^2 + (y-1)^2 = 1$$

2. rovnici upravíme na tvar $y = x^3 + 1$



Z 2. rovnice vyjádříme x :

$$x^3 = y - 1$$

$$x = \sqrt[3]{y-1}$$

Z 1. rovnice vyjádříme y :

$$4y^2 = 8y - x^2$$

$$y = \frac{1}{2}\sqrt{8y - x^2}$$

Rekurentní formule:

$$x_{k+1} = \sqrt[3]{y_k - 1} \quad y_{k+1} = \frac{1}{2}\sqrt{8y_k - x_{k+1}^2}$$

výsledky získané v MATLABu

krok	$x_1(k)$	$x_2(k)$	$ x(k) - x(k-1) $
0	1.000000	1.000000	
1	0.000000	1.322876	1.050832
2	0.686033	1.626577	0.750250
3	0.855706	1.770732	0.222643
4	0.916856	1.832595	0.086985
5	0.940758	1.858772	0.035448
6	0.950516	1.869836	0.014752
7	0.954580	1.874514	0.006197
8	0.956288	1.876492	0.002613
9	0.957009	1.877328	0.001104
10	0.957313	1.877682	0.000467

výsledky získané v MATLABu

Numerické metody				KMA/NM																																																																						
Josef Daněk				13.2.2013																																																																						
<table border="1"> <thead> <tr> <th>krok</th><th>x_1(k)</th><th>x_2(k)</th><th> x(k)-x(k-1) </th><th></th></tr> </thead> <tbody> <tr><td>0</td><td>-1.000000</td><td>0.000000</td><td></td><td></td></tr> <tr><td>1</td><td>0.500000</td><td>0.000000</td><td>1.802776</td><td></td></tr> <tr><td>2</td><td>0.651123</td><td>0.677644</td><td>2.108913</td><td></td></tr> <tr><td>3</td><td>0.670383</td><td>1.241743</td><td>1.749676</td><td></td></tr> <tr><td>4</td><td>0.716783</td><td>1.573937</td><td>1.015477</td><td></td></tr> <tr><td>5</td><td>0.838816</td><td>1.743370</td><td>0.454007</td><td></td></tr> <tr><td>6</td><td>0.906819</td><td>1.820267</td><td>0.181812</td><td></td></tr> <tr><td>7</td><td>0.936234</td><td>1.853465</td><td>0.074113</td><td></td></tr> <tr><td>8</td><td>0.948577</td><td>1.867581</td><td>0.030794</td><td></td></tr> <tr><td>9</td><td>0.953759</td><td>1.873559</td><td>0.012921</td><td></td></tr> <tr><td>10</td><td>0.955941</td><td>1.876088</td><td>0.005446</td><td></td></tr> <tr><td>11</td><td>0.956862</td><td>1.877158</td><td>0.002300</td><td></td></tr> <tr><td>12</td><td>0.957251</td><td>1.877610</td><td>0.000972</td><td></td></tr> </tbody> </table>				krok	x_1(k)	x_2(k)	x(k)-x(k-1)		0	-1.000000	0.000000			1	0.500000	0.000000	1.802776		2	0.651123	0.677644	2.108913		3	0.670383	1.241743	1.749676		4	0.716783	1.573937	1.015477		5	0.838816	1.743370	0.454007		6	0.906819	1.820267	0.181812		7	0.936234	1.853465	0.074113		8	0.948577	1.867581	0.030794		9	0.953759	1.873559	0.012921		10	0.955941	1.876088	0.005446		11	0.956862	1.877158	0.002300		12	0.957251	1.877610	0.000972		
krok	x_1(k)	x_2(k)	x(k)-x(k-1)																																																																							
0	-1.000000	0.000000																																																																								
1	0.500000	0.000000	1.802776																																																																							
2	0.651123	0.677644	2.108913																																																																							
3	0.670383	1.241743	1.749676																																																																							
4	0.716783	1.573937	1.015477																																																																							
5	0.838816	1.743370	0.454007																																																																							
6	0.906819	1.820267	0.181812																																																																							
7	0.936234	1.853465	0.074113																																																																							
8	0.948577	1.867581	0.030794																																																																							
9	0.953759	1.873559	0.012921																																																																							
10	0.955941	1.876088	0.005446																																																																							
11	0.956862	1.877158	0.002300																																																																							
12	0.957251	1.877610	0.000972																																																																							

Poznámka:

Pozor na definiční obory funkcí.
Pozor na zápis funkcí v MATLABu.

```
>> (-8)^(1/3)
ans =
1.0000 + 1.7321i
```

Poznámka: Pokud chceme v předchozím příkladě najít druhé řešení, je třeba zvolit jiný předpis pro funkci

Φ.

výsledky získané v MATLABu

Metoda prosté iterace pro řešení soustavy nelineárních rovnic
 $F(x)=0$ s využitím přepisu na tvar $x=\Phi(x)$
 pro počítání approximaci $x^0=[1,1]$ a
 zastavovací podmínku $\|x(k)-x(k-1)\|<0.001$

Funkce $\Phi(x)$ je zadána takto:

```
function out=Phi(in);
x=in(1);
y=in(2);
if (y-1)>=0
    out(1)=(y-1)^(1/3);
else
    out(1)=-(1-y)^(1/3);
end;
out(2)=(x^2+4*y^2)/8;
out=out';
```

krok	x_1(k)	x_2(k)	x(k)-x(k-1)
0	1.000000	1.000000	
1	0.625000	1.068000	
2	0.195312	0.839436	
3	0.084076	0.236761	
4	0.111677	0.049444	
5	0.124127	0.015879	
6	0.123215	0.004604	
7	0.122020	0.001240	
8	0.121953	0.000440	

Newtonova metoda

Odvodení je opět analogické případu funkce jedné reálné proměnné.
 Vyhádříme si Taylorův rozvoj funkce F v bodě x^k .
 (Předpokládáme, že existují derivace !)

Soustavu rovnic $F(x)=0$ nahradíme soustavou lineárních rovnic

$$F(x^k) + F'(x^k)(x - x^k) = 0$$

Její řešení označíme x^{k+1} , tj.

$$F(x^k) + F'(x^k) \underbrace{(x^{k+1} - x^k)}_{h^k} = 0$$

Dostaváme soustavu

$$F'(x^k)h^k = -F(x^k),$$

která má řešení

$$h^k = -[F'(x^k)]^{-1}F(x^k)$$

Numerické metody				KMA/NM
Josef Daněk				13.2.2013

Novou iteraci x^{k+1} získáme ze vztahu

$$x^{k+1} = x^k + h^k$$

Poznámka:

$F'(x^k)$ je Jacobijovo matice funkce $F(x)$ v bodě x^k .
 Je zřejmé, že musí být regulární (musí existovat matic k ní inverzní).

Příklad 6

Řešte Newtonovou metodou soustavu dvou rovnic pro dvě neznámé

$$\begin{aligned} x^2 + 4y^2 - 8y &= 0 \\ x^3 - y + 1 &= 0 \end{aligned}$$

$$F(x, y) = \begin{bmatrix} x^2 + 4y^2 - 8y \\ x^3 - y + 1 \end{bmatrix}$$

$$\frac{\partial F_1(x, y)}{\partial x} = 2x \quad \frac{\partial F_1(x, y)}{\partial y} = 8y - 8$$

$$\frac{\partial F_2(x, y)}{\partial x} = 3x^2 \quad \frac{\partial F_2(x, y)}{\partial y} = -1$$

$$F'(x, y) = \begin{bmatrix} 2x & 8y - 8 \\ 3x^2 & -1 \end{bmatrix}$$

1. iterace

$$\begin{bmatrix} x^1 \\ y^1 \end{bmatrix} = \begin{bmatrix} x^0 \\ y^0 \end{bmatrix} + \begin{bmatrix} h_1^0 \\ h_2^0 \end{bmatrix}$$

Platí

$$h^0 = -[F'(x^0, y^0)]^{-1}F(x^0, y^0)$$

Abychom nemuseli počítat inverzní matici, vypočteme h^0 jako řešení soustavy

$$F'(x^0, y^0)h^0 = -F(x^0, y^0)$$

$$F(x^0, y^0) = \begin{bmatrix} 4 \\ 7 \end{bmatrix} \quad F'(x^0, y^0) = \begin{bmatrix} 4 & 8 \\ 12 & -1 \end{bmatrix}$$

Dostaneme

$$h^0 = \begin{bmatrix} -0.6 \\ -0.2 \end{bmatrix} \Rightarrow \begin{bmatrix} x^1 \\ y^1 \end{bmatrix} = \begin{bmatrix} x^0 \\ y^0 \end{bmatrix} + \begin{bmatrix} h_1^0 \\ h_2^0 \end{bmatrix} = \begin{bmatrix} 2 \\ 7 \end{bmatrix} + \begin{bmatrix} -0.6 \\ -0.2 \end{bmatrix} = \begin{bmatrix} 1.4 \\ 1.8 \end{bmatrix}$$

2. iterace

Numerické metody				KMA/NM
Josef Daněk				13.2.2013

$$\begin{bmatrix} x^2 \\ y^2 \end{bmatrix} = \begin{bmatrix} x^1 \\ y^1 \end{bmatrix} + \begin{bmatrix} h_1^1 \\ h_2^1 \end{bmatrix}$$

Platí

$$h^1 = -[F'(x^1, y^1)]^{-1}F(x^1, y^1)$$

Abychom nemuseli počítat inverzní matici, vypočteme h^1 jako řešení soustavy

$$F'(x^1, y^1)h^1 = -F(x^1, y^1)$$

$$F(x^1, y^1) = \begin{bmatrix} 0,52 \\ 1,944 \end{bmatrix} \quad F'(x^1, y^1) = \begin{bmatrix} 2,8 & 6,4 \\ 5,88 & -1 \end{bmatrix}$$

Dostaneme

$$h^1 = \begin{bmatrix} -0,3206 \\ 0,0590 \end{bmatrix}$$

$$\begin{bmatrix} x^2 \\ y^2 \end{bmatrix} = \begin{bmatrix} x^1 \\ y^1 \end{bmatrix} + \begin{bmatrix} h_1^1 \\ h_2^1 \end{bmatrix} = \begin{bmatrix} 1,4 \\ 1,8 \end{bmatrix} + \begin{bmatrix} -0,3206 \\ 0,0590 \end{bmatrix} = \begin{bmatrix} 1,0794 \\ 1,8590 \end{bmatrix}$$

Další iterace bychom počítali podobně. V následující tabulce jsou shrnutý 4. iterace Newtonovy metody.

k	x_k	y_k	$\ x_k - x_{k-1}\ $
0	2.0000	2.0000	
1	1.4000	1.8000	0.6325
2	1.0794	1.8590	0.3260
3	0.9703	1.8763	0.1105
4	0.9577	1.8779	0.0127

Normy vektorů a matic

Připomenutí:

- Norma** je zobrazení n lineárního vektorového prostoru L do \mathbb{R}_0^+ :
- $n(x) = 0 \Leftrightarrow x = 0$ (definitnost)
 - $n(\lambda x) = |\lambda|n(x)$ (homogenita)
 - $n(x+y) \leq n(x) + n(y)$ (\triangle nerovnost)

VEKTORY:
 $\|x\|_p = (\sum_i |x_i|^p)^{\frac{1}{p}}$
 ... p -tá vektorová norma

 $\|x\|_1 = \sum_i |x_i|$
 ... první vektorová norma

 $\|x\|_2 = \sqrt{\sum_i x_i^2}$
 ... euklidovská vektorová norma

 $\|x\|_\infty = \max_i |x_i|$
 $= \lim_{p \rightarrow \infty} (\sum_i |x_i|^p)^{\frac{1}{p}}$
 ... maximová norma

MATICE:
 $\|A\|_S = \max_k \{\sum_i |a_{ik}|\}$
 ... sloupcová maticová norma

 $\|A\|_{SP} = \max_k \{\sqrt{\sum_i (A^H A)_{kk}}\}$
 ... spektrální norma

 $\|A\|_R = \max_k \{\sum_i |a_{ik}|\}$
 ... řádková maticová norma

Poznámky:
 A^H ... hermitovsky transponovaná matice; $A^H = [a_{ij}^H] = [\bar{a}_{ji}]$; \bar{a} je komplexně sdržené číslo k číslu a

 Symbol \leftrightarrow značí vazbu mezi vektorovou a maticovou normou.
 Příslušná maticová norma je generována příslušnou vektorovou normou.

Příklad

 Pro zadanou matici A a vektor x určete výše uvedené normy.

$$A = \begin{bmatrix} 2 & -1 \\ 0 & 3 \end{bmatrix}, \quad x = \begin{bmatrix} 6 \\ -1 \end{bmatrix}.$$

$\|A\|_S = \max\{|2| + |0|; |-1| + |3|\} = \max\{2; 4\} = 4$

$\|A\|_R = \max\{|2| + |-1|; |0| + |3|\} = \max\{3; 3\} = 3$

 $\|A\|_{SP}$:

$A^H A = \begin{bmatrix} 2 & 0 \\ -1 & 3 \end{bmatrix} \cdot \begin{bmatrix} 2 & -1 \\ 0 & 3 \end{bmatrix} = \begin{bmatrix} 4 & -2 \\ -2 & 10 \end{bmatrix}$

$\det(A^H A - \lambda I) = \begin{vmatrix} 4-\lambda & -2 \\ -2 & 10-\lambda \end{vmatrix} = (4-\lambda)(10-\lambda) - 4 = \lambda^2 - 14\lambda + 36$

$\lambda_{1,2}(A^H A) = \frac{14 \pm \sqrt{14^2 - 4 \cdot 36}}{2} = 7 \pm \sqrt{7^2 - 36} = 7 \pm \sqrt{13}$

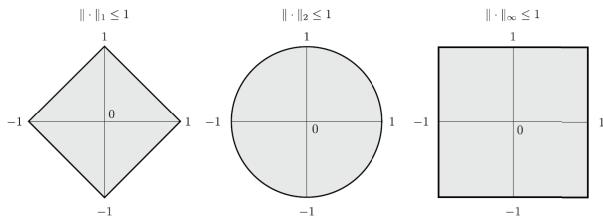
$\max |\lambda_{1,2}| = 7 + \sqrt{13}$

$\|A\|_{SP} = \sqrt{7 + \sqrt{13}} \doteq 3,2566$

$\|x\|_1 = |6| + |-1| = 7$

$\|x\|_\infty = \max\{|6|, |-1|\} = 6$

Geometrický význam vektorových norm

 jednotkové koule v \mathbb{R}^2 ... množina (bodů) prvků s normou ≤ 1 :


$1. \|x\|_1 = \sum_i |x_i| = |x| + |y| \leq 1$

$2. \|x\|_2 = \sqrt{\sum_i x_i^2} = \sqrt{x^2 + y^2} \leq 1$

$3. \|x\|_\infty = \max_i |x_i| = \max\{|x|, |y|\} \leq 1$

Kapitola 3. SLAR - přímé metody

Formulace:

 Je dána čtvercová matice $A = [a_{ij}]_{n \times n}$ a vektor pravé strany $b = [b_1, b_2, \dots, b_n]^T$.

 Hledáme vektor $x = [x_1, x_2, \dots, x_n]^T$ tak, aby platilo

$Ax = b,$

rozepsáno po složkách

$a_{11}x_1 + a_{12}x_2 + \dots + a_{1n}x_n = b_1$

$a_{21}x_1 + a_{22}x_2 + \dots + a_{2n}x_n = b_2$

 \vdots

$a_{n1}x_1 + a_{n2}x_2 + \dots + a_{nn}x_n = b_n$

 Předpokládáme, že je matice **A regulární** (tj. soustava má právě jedno řešení).

Máme dva základní typy soustav:

- soustavy s obecnou maticí
- soustavy se speciální maticí (symetrická, pozitivně definitní, řídká, pásová apod.)

Pro první skupinu se většinou používají přímé metody, pro druhou skupinu metody iterační nebo speciální modifikace přímých metod.

Cramerovo pravidlo

$$\text{neznámá složka řešení} \quad x_i = \frac{\det A_i}{\det A}$$

počet operací:

 Je nutné vypočítat $(n+1)$ determinantů.

 Pro výpočet determinantu je třeba $n!$ sčítání a v každém sčítanci je $(n-1)$ násobení.

Dostáváme:

$(n+1)[(n-1)n! + n!] = n(n+1)!$

 napří: pro $n = 30, 10^6$ operací za sekundu \rightarrow výpočet trvá $7,82 \cdot 10^{21}$ let

Idea dalších přímých metod vychází z faktu, že soustavy

$[Ax = b]$ a $[TAx = Tb]$

 kde T je regulární matice, mají totéž řešení, tj. jsou ekvivalentní.

Touto transformací lze získat trojúhelníkovou soustavu

$Ux = y : \quad U = TA, \quad y = Tb$

pří:

$$\begin{bmatrix} a_{11} & a_{12} & a_{13} \\ 0 & a_{22} & a_{23} \\ 0 & 0 & a_{33} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} b_1 \\ b_2 \\ b_3 \end{bmatrix}$$

 Trojúhelníkovou soustavu lze velmi snadno řešit zpětnou substitucí. Realizovaný proces se nazývá zpětný chod.

Gaussova eliminační metoda

$$Ax = b \quad \text{rozepsáno po složkách} \quad \left[\begin{array}{ccc|c} a_{11} & a_{12} & a_{13} & b_1 \\ a_{21} & a_{22} & a_{23} & b_2 \\ a_{31} & a_{32} & a_{33} & b_3 \end{array} \right]$$

 Definujeme multiplikátory $m_{21} = -\frac{a_{21}}{a_{11}}, \quad m_{31} = -\frac{a_{31}}{a_{11}}$

$r_1^{(1)} = \check{r}_1 \quad b_1^{(1)} = b_1$

$r_2^{(1)} = \check{r}_2 + m_{21}\check{r}_1 \quad b_2^{(1)} = b_2 + m_{21}b_1$

$r_3^{(1)} = \check{r}_3 + m_{31}\check{r}_1 \quad b_3^{(1)} = b_3 + m_{31}b_1$

 Získáme novou soustavu ... **1. fáze eliminace**

$$A^{(1)}x = b^{(1)} \quad \left[\begin{array}{ccc|c} a_{11} & a_{12} & a_{13} & b_1 \\ 0 & a_{22}^{(1)} & a_{23}^{(1)} & b_2^{(1)} \\ 0 & a_{32}^{(1)} & a_{33}^{(1)} & b_3^{(1)} \end{array} \right]$$

 Definujeme multiplikátory $m_{32} = -\frac{a_{32}^{(1)}}{a_{22}^{(1)}}$

$r_1^{(2)} = \check{r}_1^{(1)} \quad b_1^{(2)} = b_1^{(1)}$

$r_2^{(2)} = \check{r}_2^{(1)} \quad b_2^{(2)} = b_2^{(1)}$

$r_3^{(2)} = \check{r}_3^{(1)} + m_{32}\check{r}_2^{(1)} \quad b_3^{(2)} = b_3^{(1)} + m_{32}b_2^{(1)}$

 Získáme novou soustavu ... **2. fáze eliminace**

$$A^{(2)}x = b^{(2)} \quad \left[\begin{array}{ccc|c} a_{11} & a_{12} & a_{13} & b_1 \\ 0 & a_{22}^{(1)} & a_{23}^{(1)} & b_2^{(1)} \\ 0 & 0 & a_{33}^{(2)} & b_3^{(2)} \end{array} \right]$$

 Celý tento postup nazýváme přímý chod. Trojúhelníkovou soustavu řešíme zpětným chodem.



Efektivnost algoritmu GEM

Bereme v úvahu pouze operace násobení a dělení (počet operací sčítání je přibližně stejný).

($N \dots$ je řád matice A)

- Celkem je $N - 1$ fází eliminace. V K -té fázi počítáme $N - K$ multiplikátorů (tj. $N - K$ dělení)

$$\sum_{K=1}^{N-1} (N - K) = (N - 1)N - \sum_{K=1}^{N-1} K = (N - 1)N - \frac{1}{2}(N - 1)N = \underline{\underline{\frac{1}{2}(N - 1)N}}$$

- Každým multiplikátorem vynásobíme $(N - K + 1)$ prvků rozšířené matice (jeden rozšířený řádek), tj. $(N - K)(N - K + 1)$ v K -té fázi

$$\begin{aligned} \sum_{K=1}^{N-1} (N - K)(N - K + 1) &= \sum_{K=1}^{N-1} [(N^2 + N) - K(2N + 1) + K^2] = \\ &= (N - 1)(N^2 + N) - \frac{1}{2}N(N - 1)(2N + 1) + \frac{1}{6}(N - 1)N(2N - 1) = \\ &= N^3 - N^2 + N^2 - N - N^3 + \frac{1}{2}N^2 + \frac{1}{2}N + \frac{1}{3}N^3 - \frac{1}{2}N^2 + \frac{1}{6}N = \\ &= \underline{\underline{\frac{1}{3}N^3 - \frac{1}{3}N}} \end{aligned}$$

- Zpětný chod

$$1 + (\underbrace{\frac{1}{\text{dělení}}}_{\text{výpočet multiplikátorů}} + \underbrace{\frac{1}{\text{násobení}}}_{\text{zpětný chod}}) + (1 + 2) + \dots + (1 + N - 1) = \sum_{K=1}^N K = \underline{\underline{\frac{1}{2}N(N + 1)}}$$

Celkem

$$\frac{1}{2}N(N - 1) + \frac{1}{3}N^3 - \frac{1}{3}N + \frac{1}{2}N(N + 1) = \boxed{\frac{1}{3}N^3 + N^2 - \frac{1}{3}N}$$

Příklad 1

Řešte soustavu rovnic

$$\begin{array}{l} x + 2y + 3z = 14 \\ 2x + 4y + 5z = 25 \\ 7x + 8y + 9z = 50 \end{array}, \quad \text{tj.} \quad \left[\begin{array}{ccc|c} 1 & 2 & 3 & 14 \\ 2 & 4 & 5 & 25 \\ 7 & 8 & 9 & 50 \end{array} \right] \cdot \left[\begin{array}{c} x \\ y \\ z \end{array} \right] = \left[\begin{array}{c} 14 \\ 25 \\ 50 \end{array} \right]$$

Řešení

Pro zápis budeme používat tvar *matice rozšířené*.



$$\left[\begin{array}{ccc|c} 1 & 2 & 3 & 14 \\ 2 & 4 & 5 & 25 \\ 7 & 8 & 9 & 50 \end{array} \right] \xrightarrow{\cdot(-\frac{2}{1})} \left[\begin{array}{ccc|c} 1 & 2 & 3 & 14 \\ 0 & 0 & -1 & -3 \\ 7 & 8 & 9 & 50 \end{array} \right] \xrightarrow{\cdot(-\frac{1}{-1})} \left[\begin{array}{ccc|c} 1 & 2 & 3 & 14 \\ 0 & 0 & 1 & 3 \\ 7 & 8 & 9 & 50 \end{array} \right]$$

$$\left[\begin{array}{ccc|c} 1 & 2 & 3 & 14 \\ 0 & 0 & 1 & 3 \\ 0 & -6 & -12 & -48 \end{array} \right] \xrightarrow{\cdot(-\frac{6}{0})} \left[\begin{array}{ccc|c} 1 & 2 & 3 & 14 \\ 0 & 0 & 1 & 3 \\ 0 & 1 & 2 & 8 \end{array} \right] \quad \text{!!! dělíme 0}$$

- Algoritmus Gaussovy eliminační metody pro tento příklad není realizovatelný.

- Snadno se přesvědčíme, že má daná soustava řešení

$$x = 1, y = 2 \text{ a } z = 3.$$

Gaussova eliminační metoda ale selhala.

Otázka 1: Pro jaké matice A má soustava $\mathbf{Ax} = \mathbf{b}$ právě jedno řešení?

→ matice A musí být regulární, tj.

všechna vlastní čísla musí být různá od nuly

jinak řešeno řádky matice A musí být lineárně nezávislé

jinak řešeno sloupcy matice A musí být lineárně nezávislé

jinak řešeno $\det A \neq 0$

Poznámka: Vlastní číslo matice A je číslo λ splňující rovnici $\mathbf{Av} = \lambda v$, kde v je vlastní vektor odpovídající vlastnímu číslu λ . Číslo λ tedy určitým způsobem charakterizuje matici A.

Otázka 2: Pro jaké matice A je algoritmus Gaussovy eliminační metody realizovatelný?

→ **Věta:** Je-li matice A oště diagonálně dominantní, pak je algoritmus GEM realizovatelný.

Poznámka: Matice $A = [a_{ij}]_{i,j=1,\dots,n}$ je oště diagonálně dominantní, platí-li

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

tj. absolutní hodnota diagonálního prvku je větší než součet absolutních hodnot ostatních prvků v řádku.

Např.:.

$$A = \left[\begin{array}{ccc} 7 & 1 & 2 \\ 1 & 4 & 1 \\ 2 & 4 & 9 \end{array} \right].$$



→ **Věta:** Je-li matice A symetrická a pozitivně definitní, pak je algoritmus GEM realizovatelný.

Poznámka: Matice A je symetrická, platí-li pro její prvky

$$a_{ij} = a_{ji} \quad \forall i, j = 1, 2, \dots, n.$$

Poznámka: Matice A je pozitivně definitní,

má-li všechna vlastní čísla kladná

nebo jinak řečeno $\forall x \neq 0 : x^T A x > 0$.

Poznámka: Pro soustavu s maticí, která splňuje předpoklady některé z uvedených vět, je možné dopředu říci, že půjde řešit pomocí Gaussovy eliminační metody. Obráceně to ovšem neplatí, tj. není-li např. matice soustavy oště diagonálně dominantní, ještě to obecně neznamená, že nepůjde pomocí Gaussovy eliminační metody řešit.

Poznámka: Abychom zaručili, že soustava půjde vyřešit pro libovolnou regulární matici, musíme algoritmus Gaussovy eliminační metody upravit. Zavedeme tzv. **výběr hlavního prvku (pivotaci)**.

Poznámka: **Pivot (hlavní prvek)** ... první nenulový prvek v daném řádku matice.

Příklad 2

Pomoci **GEM** se sloupcovou pivotací vyřešte soustavu rovnic z Příkladu 1, kde selhala klasická GEM, tj. řešíme soustavu $\mathbf{Ax} = \mathbf{b}$, kde

$$A = \left[\begin{array}{ccc} 1 & 2 & 3 \\ 2 & 4 & 5 \\ 7 & 8 & 9 \end{array} \right] \quad \mathbf{a} = \left[\begin{array}{c} 14 \\ 25 \\ 50 \end{array} \right].$$

Řešení

$$\text{1. sloupec} \downarrow \quad \text{vyměň} \left[\begin{array}{ccc|c} 1 & 2 & 3 & 14 \\ 2 & 4 & 5 & 25 \\ 7 & 8 & 9 & 50 \end{array} \right] \rightsquigarrow \left[\begin{array}{ccc|c} 7 & 8 & 9 & 50 \\ 2 & 4 & 5 & 25 \\ 1 & 2 & 3 & 14 \end{array} \right] \xrightarrow{\cdot(-\frac{2}{7})} \left[\begin{array}{ccc|c} 7 & 8 & 9 & 50 \\ 0 & \frac{2}{7} & \frac{5}{7} & \frac{25}{7} \\ 1 & 2 & 3 & 14 \end{array} \right] \xrightarrow{\cdot(-\frac{1}{7})} \left[\begin{array}{ccc|c} 7 & 8 & 9 & 50 \\ 0 & 1 & \frac{5}{7} & \frac{25}{7} \\ 1 & 2 & 3 & 14 \end{array} \right]$$

$$\text{2. sloupec} \downarrow \quad \text{není třeba měnit} \rightarrow \left[\begin{array}{ccc|c} 7 & 8 & 9 & 50 \\ 0 & 1 & \frac{5}{7} & \frac{25}{7} \\ 0 & \frac{6}{7} & \frac{12}{7} & \frac{48}{7} \end{array} \right] \xrightarrow{\cdot(-\frac{6}{7})} \left[\begin{array}{ccc|c} 7 & 8 & 9 & 50 \\ 0 & 1 & \frac{5}{7} & \frac{25}{7} \\ 0 & 0 & \frac{12}{7} & \frac{48}{7} \end{array} \right]$$



$$\left(\begin{array}{ccc|c} 7 & 8 & 9 & 50 \\ 0 & 1 & \frac{5}{7} & \frac{25}{7} \\ 0 & 0 & \frac{12}{7} & \frac{48}{7} \end{array} \right) \implies \mathbf{x} = \left[\begin{array}{c} 1 \\ 3 \\ 4 \end{array} \right]$$

Poznámky:

- Při sloupcové pivotaci jsme postupně v každém sloupci (resp. jeho části pod diagonálou včetně) vybírali číslo, které bylo maximální v absolutní hodnotě a v případě, že toto číslo neleželo na diagonále, vyměnili jsme příslušné 2 rovnice. Dále jsme pokračovali jako v GEM bez pivotace, tj. nulovali jsme koeficienty pod diagonálu.

- Sloupcová pivotace není jediná možnost. Podobně můžeme vybírat i maximální prvek v absolutní hodnotě z příslušného řádku (resp. jeho části) a poté vyměnit příslušné sloupce. Pozor! Je ovšem třeba zaměnit složky ve vektoru řešení. Nevyhodou úplné pivotace je pomalejší výpočet neboť hlavní prvek vyhledáváme z celé dosud neupravené části.

- Další možnost je vybírat maximální prvek v absolutní hodnotě z celé matice A (resp. příslušné podmatrix). V tomto případě hovoříme o **úplné pivotaci**.

- Další možnost je vybírat maximální prvek v absolutní hodnotě z celé matice A (resp. příslušné podmatrix). V tomto případě hovoříme o **úplné pivotaci**.

- Libovolnou pivotací dosáhneme realizovatelnosti GEM pro libovolnou regulární matici A.

Metoda LU-rozkladu

Opět uvažujeme regulární matici A řádu N . Matici A lze rozložit na součin $A = LU$, kde L je dolní trojúhelníková matica řádu N a U je horní trojúhelníková matica řádu N .

Např.:

$$\left[\begin{array}{ccc|c} a_{11} & a_{12} & a_{13} & 50 \\ a_{21} & a_{22} & a_{23} & 15 \\ a_{31} & a_{32} & a_{33} & 25 \end{array} \right] = \left[\begin{array}{ccc|c} l_{11} & 0 & 0 & 50 \\ l_{21} & l_{22} & 0 & 15 \\ l_{31} & l_{32} & l_{33} & 25 \end{array} \right] \cdot \left[\begin{array}{ccc|c} u_{11} & u_{12} & u_{13} & 0 \\ 0 & u_{22} & u_{23} & 0 \\ 0 & 0 & u_{33} & 0 \end{array} \right]$$

Tento rozklad není dán jednoznačně (12 neznámých a 9 podmínek), jednoznačnosti dosáhneme např. tím, že položíme $l_{ii} = 1, i = 1, 2, \dots, N$.

Algoritmus: (viz skripta)

je odvozen z postupného násobení řádků matice L a sloupčů matice U

$$\begin{array}{lll} (1,1) \quad a_{11} = a_{11} & (2,1) \quad a_{21} = l_{21}u_{11} & (3,1) \quad a_{31} = l_{31}u_{11} \\ (1,2) \quad a_{12} = a_{12} & (2,2) \quad a_{22} = l_{21}u_{12} + u_{22} & (3,2) \quad a_{32} = l_{31}u_{12} + l_{32}u_{22} \\ (1,3) \quad a_{13} = a_{13} & (2,3) \quad a_{23} = l_{21}u_{13} + u_{23} & (3,3) \quad a_{33} = l_{31}u_{13} + l_{32}u_{23} + u_{33} \end{array}$$

Rешení soustavy $\mathbf{Ax} = \mathbf{b}$ metodou LU-rozkladu:

- Realizace LU-rozkladu: $\mathbf{A} = \mathbf{LU}$

- Řešení trojúhelníkové soustavy: $\mathbf{Ly} = \mathbf{b}$

- Řešení trojúhelníkové soustavy: $\mathbf{Ux} = \mathbf{y}$

$$\boxed{\mathbf{Ux} = \mathbf{y}}$$

Souvislost GEM a metody LU-rozkladu

Gaussovu eliminaci lze popsat pomocí násobení regulárními maticemi.

$$\text{První fázi popíšeme takto } \dots [A^{(1)} = M_1 A], \text{ kde } M_1 = \begin{bmatrix} 1 & & & & \\ m_{21} & 1 & & & \\ m_{31} & & 1 & & \\ m_{41} & & & 1 & \\ \vdots & & & & \ddots \\ m_{n1} & & & & 1 \end{bmatrix}$$

$$\begin{bmatrix} a_{11} & a_{12} & a_{13} & \dots & a_{1n} \\ m_{21}a_{11} + a_{21} & m_{21}a_{12} + a_{22} & m_{21}a_{13} + a_{23} & \dots & m_{21}a_{1n} + a_{2n} \\ m_{31}a_{11} + a_{31} & m_{31}a_{12} + a_{32} & m_{31}a_{13} + a_{33} & \dots & m_{31}a_{1n} + a_{3n} \\ \vdots & \vdots & \vdots & & \vdots \\ m_{n1}a_{11} + a_{n1} & m_{n1}a_{12} + a_{n2} & m_{n1}a_{13} + a_{n3} & \dots & m_{n1}a_{1n} + a_{nn} \end{bmatrix} =$$

$$= \begin{bmatrix} 1 & & & & \\ m_{21} & 1 & & & \\ m_{31} & & 1 & & \\ m_{41} & & & 1 & \\ \vdots & & & & \ddots \\ m_{n1} & & & & 1 \end{bmatrix} \cdot \begin{bmatrix} a_{11} & a_{12} & a_{13} & \dots & a_{1n} \\ a_{21} & a_{22} & a_{23} & \dots & a_{2n} \\ a_{31} & a_{32} & a_{33} & \dots & a_{3n} \\ \vdots & \vdots & \vdots & & \vdots \\ a_{n1} & a_{n2} & a_{n3} & \dots & a_{nn} \end{bmatrix}$$

$$\text{Druhou fázi popíšeme takto } \dots [A^{(2)} = M_2 A^{(1)}], \text{ kde } M_2 = \begin{bmatrix} 1 & & & & \\ & 1 & & & \\ m_{32} & 1 & & & \\ m_{42} & & 1 & & \\ \vdots & & & & \ddots \\ m_{n2} & & & & 1 \end{bmatrix}$$

$$\text{Nakonec } (n-1) \text{ fázi popíšeme } \dots [A^{(n-1)} = M_{n-1} A^{(n-2)}], \text{ kde } M_{n-1} = \begin{bmatrix} 1 & & & & \\ & 1 & & & \\ & & 1 & & \\ & & & \ddots & \\ & & & & 1 \\ & & & & m_{n,n-1} & 1 \end{bmatrix}$$

Dostali jsme horní trojúhelníkovou matici, označíme ji např. V

$$V = A^{(n-1)} = \underbrace{M_{n-1} M_{n-2} M_{n-3} \dots M_2 M_1}_\text{ozn. M} A \Rightarrow A = M^{-1} V$$

$$M^{-1} = M_1^{-1} M_2^{-1} \dots M_{n-1}^{-1}$$

Jak vypadá např. M_2^{-1} ?

$$M_2 = \begin{bmatrix} 1 & & & & \\ & 1 & & & \\ m_{32} & 1 & & & \\ \vdots & & \ddots & & \\ m_{n2} & & & & 1 \end{bmatrix} \rightarrow M_2^{-1} = \begin{bmatrix} 1 & & & & \\ & 1 & & & \\ -m_{32} & 1 & & & \\ -m_{42} & & 1 & & \\ \vdots & & & & \ddots \\ -m_{n2} & & & & 1 \end{bmatrix}$$

protože po vynásobení:

- i -tý řádek $\times j$ -tý sloupec ($j \neq i$)

$$- bud' \quad m_{2j} \cdot 1 + 1 \cdot (-m_{42}) = 0$$

$$- nebo \quad m_{42} \cdot 0 + 0 \cdot 1 + 1 \cdot 0 = 0$$

- i -tý řádek $\times i$ -tý sloupec

$$- m_{42} \cdot 0 + 1 \cdot 1 = 1$$

$$\text{tj. } M_2 \cdot M_2^{-1} = I$$

Jak vypadá M^{-1} ?

$$M^{-1} = \begin{bmatrix} 1 & & & & \\ -m_{21} & 1 & & & \\ -m_{31} & -m_{32} & 1 & & \\ \vdots & & & & \ddots \\ -m_{n1} & -m_{n2} & -m_{n3} & \dots & 1 \end{bmatrix}$$

Př.:

$$\begin{bmatrix} 1 & 0 & 0 \\ -m_{21} & 1 & 0 \\ -m_{31} & 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & -m_{32} & 1 \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ -m_{21} & 1 & 0 \\ -m_{31} & -m_{32} & 1 \end{bmatrix}$$

Plati

$$A = \underbrace{M^{-1}}_{(*)} \cdot \underbrace{V}_{(**)}$$

(*) dolní trojúhelníková s 1 na diagonále

(**) horní trojúhelníková

$$\Rightarrow \text{jedná se o LU-rozklad (rozklad je jednoznačný)} \quad L = M^{-1} \text{ a } U = V$$

Výpočet determinantů

1. Užití GEM

$$U = M_{N-1} M_{N-2} \dots M_2 M_1 A$$

$$\det U = \underbrace{\det M_{N-1}}_{=-1} \underbrace{\det M_{N-2}}_{=-1} \dots \underbrace{\det M_2}_{=-1} \underbrace{\det M_1}_{=-1} \det A$$

$$\det A = \det U = \prod_{i=1}^N u_{ii}$$

2. Užití LU-rozkladu

$$\det A = \det L \det U = \prod_{i=1}^N u_{ii}$$

Výpočet inverzní matice

1. Užití GEM

$$A X = I \quad (\text{maticová soustava})$$

$$X = A^{-1}$$

2. Užití LU-rozkladu

$$A = L U$$

$$A^{-1} = U^{-1} L^{-1}$$

Numerické aspekty GEM a metody LU-rozkladu

Při numerické realizaci nevyprůčteme přesně matice L a U, ale přibližné matice \tilde{L} a \tilde{U} .

Teoreticky platí $A = LU$.

Označíme $\tilde{A} = \tilde{L}\tilde{U}$... določeno pro získané matice \tilde{L} a \tilde{U} .

Budeme zkoumat rozdíl $\tilde{A} - A$.

Označíme E a F matice chyb takové, že platí:

$$\tilde{L} = L + E, \quad \tilde{U} = U + F$$

Potom:

$$\tilde{A} - A = \tilde{L}\tilde{U} - LU = (L + E)(U + F) - LU = EU + LF + EF$$

Odtud plyně závěr: Pokud jsou multiplikátory v absolutní hodnotě velké, pak prvky L jsou v absolutní hodnotě velké \Rightarrow chyba může být velká. Toto je jeden z důvodů realizace pivotace.

Přímé metody pro soustavy se speciální maticí

Uvažujeme matice:

- symetrická
- symetrická a pozitivně definitní
- diagonálně dominantní
- pásová

Plati: Je-li matice A symetrická a $A^{(k)}$ jsou matice získané GEM v základní verzi, pak podmatice $A^{(k)}$ jsou také symetrické.

př.:

$$\begin{bmatrix} a & b & c \\ b & d & e \\ c & e & f \end{bmatrix} \xrightarrow{\begin{array}{c} / \cdot (-\frac{b}{a}) \\ \leftrightarrow \\ / \cdot (-\frac{c}{a}) \end{array}} \begin{bmatrix} a & b & c \\ 0 & d - \frac{b^2}{a} & e - \frac{bc}{a} \\ 0 & e - \frac{cb}{a} & f - \frac{c^2}{a} \end{bmatrix}$$

Lze pak použít **symetrickou verzi GEM a LU-rozkladu**.

Je-li matice A navíc pozitivně definitní, pak lze realizovat **Choleského metodu** rozkladu $A = U^T U$

Poznámka: V algoritmu je potřeba realizovat výpočet odmocnin a to lze pouze pro pozitivně definitní matice.

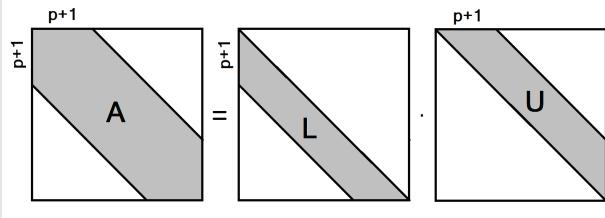
př.:

$$\begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix} = \begin{bmatrix} u_{11} & 0 & 0 \\ u_{21} & u_{22} & 0 \\ u_{31} & u_{32} & u_{33} \end{bmatrix} \cdot \begin{bmatrix} u_{11} & u_{12} & u_{13} \\ 0 & u_{22} & u_{23} \\ 0 & 0 & u_{33} \end{bmatrix}$$

$$(1,1): a_{11} = u_{11}^2 \quad (2,1): a_{21} = u_{11} \cdot u_{12} \quad (3,1): a_{31} = u_{13} \cdot u_{11} \\ (1,2): a_{12} = u_{11} \cdot u_{12} \quad (2,2): a_{22} = u_{22}^2 + u_{12}^2 \quad (3,2): a_{32} = u_{13} \cdot u_{12} + u_{22} \cdot u_{12} \\ (1,3): a_{13} = u_{11} \cdot u_{13} \quad (2,3): a_{23} = u_{12} \cdot u_{13} + u_{22} \cdot u_{13} \quad (3,3): a_{33} = u_{13}^2 + u_{23}^2 + u_{32}^2$$

Metoda LU-rozkladu pro pásové matice

Uvažujeme matici A takovou, že $a_{ij} = 0$ když $|i-j| > p$ (šířka pásu je $2p+1$).



Pokud lze realizovat LU-rozklad, pak

$$l_{ij} = 0, \text{ když } j > i \text{ a } j < i - p,$$

$$u_{ij} = 0, \text{ když } j < i \text{ a } j > i + p.$$

Poznámka: V případě obecné matic však nelze čekat, že matice L a U bude mít nulový prvek v téže pozici jako její měla matic A.

Pro pásovou, symetrickou, pozitivně definitní matice používáme speciální verzi Choleského rozkladu.

Metoda faktorizace pro třidiagonální matici

Uvažujeme soustavu $n+1$ lineárních algebraických rovnic $\boxed{A \cdot Y = F}$ ve tvaru:

$$\begin{pmatrix} c_0 & -b_0 & & & f_0 \\ -a_1 & c_1 & -b_1 & & f_1 \\ -a_2 & c_2 & -b_2 & & f_2 \\ -a_3 & c_3 & -b_3 & & f_3 \\ \vdots & \vdots & \ddots & & \vdots \\ -a_{n-1} & c_{n-1} & -b_{n-1} & & f_{n-1} \\ -a_n & c_n & b_n & & f_n \end{pmatrix}$$

Označíme

$$\alpha_1 = \frac{b_0}{c_0}, \quad \beta_1 = \frac{f_0}{c_0}$$

První dvě rovnice (první rovnice je vydělena c_0) lze psát ve tvaru:

$$\begin{aligned} y_0 - \alpha_1 y_1 &= \beta_1 \quad / \cdot \alpha_1 \quad \leftarrow \\ -a_1 y_0 + c_1 y_1 - b_1 y_2 &= f_1 \quad \leftarrow \\ (c_1 - a_1 \alpha_1) y_1 - b_1 y_2 &= f_1 + a_1 \beta_1 \end{aligned}$$

Přepíšeme (rovnice vydělená koeficientem u y_1) na tvar:

kde

$$\alpha_2 = \frac{b_1}{c_1 - a_1 \alpha_1}, \quad \beta_2 = \frac{f_1 + a_1 \beta_1}{c_1 - a_1 \alpha_1}$$

Po zobecnění:

- PŘÍMÝ CHOD

$$\alpha_i = \frac{b_0}{c_0}$$

$$\beta_1 = \frac{f_0}{c_0}$$

$$\alpha_{i+1} = \frac{b_i}{c_i - a_i \cdot \alpha_i} \quad i = 1, 2, \dots, n-1$$

$$\beta_{i+1} = \frac{f_i + a_i \cdot \beta_i}{c_i - a_i \cdot \alpha_i} \quad i = 1, 2, \dots, n$$

- ZPĚTNÝ CHOD

Pro poslední dvě rovnice získáme:

$$\begin{aligned} y_{n-1} - \alpha_n y_n &= \beta_n \quad / \cdot a_n \quad \leftarrow \\ -a_n y_{n-1} + c_n y_n &= f_n \quad \blacklozenge = f_n \end{aligned}$$

$(c_n - a_n \alpha_n) y_n = f_n + a_n \beta_n$

♣ ve druhé rovnici již není člen $-b_n y_{n+1}$

Vyjádříme poslední složku řešení:

$$y_n = \frac{f_n + a_n \beta_n}{c_n - a_n \alpha_n} =: \beta_{n+1}$$

Zpětně dosazujeme:

$$y_{i-1} = \beta_i + \alpha_i \cdot y_i \quad i = n, n-1, \dots, 1 \quad (*)$$

Efektivnost algoritmu

dělení	$2n+1$	$(1+n-1+1+n)$
násobení	$3n$	$(n+n+n)$
sčítání a odčítání \pm	$3n$	$(n+n+n)$
celkem	$(8n+1)$ operací	

Poznámka: Pokud budeme řešit tuto soustavu pro různé práv strany F, nemusíme již znovu vyjadřovat koeficienty α_i , protože nezávisí na F. Stačí tedy přeypočítat β_i .

Zatím jsme neuvedli předpoklady pro metodu faktorizace

- je třeba zajistit, aby jmenovatel $c_i - a_i \alpha_i$ byl nenulový pro $i = 1, 2, \dots, n$
- y_i se určuje z rekurentní formule (*), přitom může dojít k akumulaci zaokrouhlovacích chyb.

Nechť α_i, β_i jsou dokonce přesně vypočítané a nechť máme $\tilde{y}_n = y_n + \varepsilon_n$ (s chybou ε_n).

Potom postupně vypočítáme podle (*)

$$\tilde{y}_{i-1} = \beta_i + \alpha_i \tilde{y}_i, \quad i = n, n-1, \dots, 1$$

Označme-li $\varepsilon_i = \tilde{y}_i - y_i$ chybu, bude jistě splňovat homogenní rovnici

$$\varepsilon_{i-1} = \alpha_i \varepsilon_i, \quad i = n, n-1, \dots, 1$$

(protože přesné hodnoty y_i splňují $y_{i-1} = \beta_i + \alpha_i y_i$)

⇒ Pokud by byly koeficienty $|\alpha_i| > 1$, dojde k velkému nárůstu chyby ε_0 !!!

Pro $|\alpha_i| \leq 1, i = 1, 2, \dots, n$ je algoritmus stabilní.

Důkaz viz literatura.

Příklady aplikací, které vedou na soustavu s třidiagonální maticí

1. Řešení okrajové úlohy

$$\begin{aligned} (k(x)u'(x))' - q(x)u(x) &= -f(x) \quad x \in (0, l) \\ u(0) &= 0 \\ u(l) &= 0 \\ k(x) &> 0 \\ q(x) &\geq 0 \end{aligned}$$

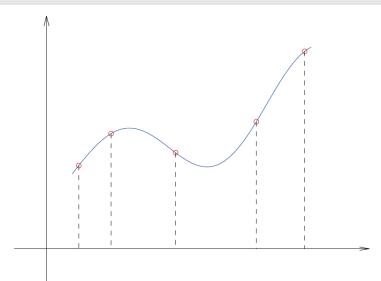
x na $(0, l)$ diskretizujeme ... síť x_i

původní úlohu nahradíme úlohou s diferenční rovnicí a použijeme vzorec pro poměrnou diferenci

2. Diferenční schémata pro rovnici vedení tepla

$$\begin{aligned} \frac{\partial u}{\partial t} &= \frac{\partial^2 u}{\partial x^2} \quad x \in (0, l), \quad t > 0 \\ u(0, t) &= \mu_1(t) \\ u(l, t) &= \mu_2(t) \\ u(x, 0) &= u_0(x) \end{aligned}$$

3. Soustava pro výpočet koeficientů kubického spline
(aproximace funkce) ... budeme probírat



Podmíněnost úlohy řešit SLAR

Uvažujeme opět soustavu $Ax = b$, $A \dots n \times n$ regulární, $b \in \mathbb{R}^n$.

Označení:

$\Delta A \dots$ malá změna matici A

$\Delta b \dots$ malá změna vektoru b

$\Delta x \dots$ odpovídající změna vektoru neznámých

$x^* \dots$ přesné řešení soustavy $Ax = b$

Platí:

$$(A + \Delta A)(x^* + \Delta x) = b + \Delta b$$

1. Uvažujme situaci $\Delta A = 0$, tj. A je zadána přesně

Důkaz: Jakou změnu řešení vyvolá změna práv strany?

$$\begin{aligned} Ax^* + A\Delta x &= b + \Delta b \\ A\Delta x &= \Delta b \end{aligned}$$

$$\Delta x = A^{-1} \Delta b$$

Z vlastností maticové normy plyne:

$$Ax^* = b \Rightarrow \|b\| \leq \|A\| \cdot \|x^*\| \Rightarrow \frac{1}{\|x^*\|} \leq \frac{\|A\|}{\|b\|}$$

$$\Delta x = A^{-1} \Delta b \Rightarrow \|\Delta x\| \leq \|A^{-1}\| \cdot \|\Delta b\|$$

$$\frac{\|\Delta x\|}{\|x^*\|} \leq \frac{\|A^{-1}\| \cdot \|\Delta b\| \cdot \|A\|}{\|b\|}$$

$$C_p = \frac{\|\Delta x\|}{\|x^*\|} \leq \|A^{-1}\| \cdot \|A\|$$

2. Případ, kdy $\Delta b = 0$, tj. b je zadána přesně

$$(A + \Delta A)(x^* + \Delta x) = b$$

$$Ax^* + \Delta Ax^* + A\Delta x + \Delta A\Delta x = b$$

$$A\Delta x = -\Delta A(x^* + \Delta x)$$

$$\Delta x = -A^{-1}\Delta A(x^* + \Delta x)$$

$$\|\Delta x\| \leq \|A^{-1}\| \cdot \|\Delta A\| \cdot \|x^* + \Delta x\| \cdot \frac{\|A\|}{\|A\|}$$

$$\frac{\|\Delta x\|}{\|x^* + \Delta x\|} \leq \underbrace{\|A^{-1}\| \cdot \|A\|}_{\geq C_p} \cdot \frac{\|\Delta A\|}{\|A\|}$$

$$C_p = \frac{\|\Delta x\|}{\|x^* + \Delta x\|} \leq \|A^{-1}\| \cdot \|A\|$$

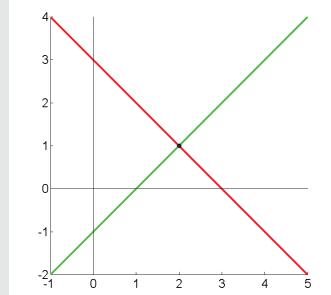
3. Rozmyslete obecný případ $\Delta b \neq 0$, $\Delta A \neq 0$ viz skripta (D.cv.)

Poznámka: Pro symetrické matice je číslo podmíněnosti podíl největší a nejmenší absolutní hodnoty vlastního čísla.

$$C_p = \frac{\|A^{-1}\| \cdot \|A\|}{\lambda_{\min} \lambda_{\max}} = \frac{|\lambda_{\max}|}{|\lambda_{\min}|}$$

Geometrická interpretace - dobré podmíněná úloha (2D)

$$\begin{cases} x + y = 3 \\ x - y = 1 \end{cases} \Rightarrow \begin{cases} y = 3 - x \\ y = x - 1 \end{cases} \quad \text{řešení } x^* = 2, y^* = 1$$



$$A = \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix}, \quad b = \begin{bmatrix} 3 \\ 1 \end{bmatrix}$$

Dobrě podmíněná úloha - malá relativní změna vstupních dat vyvolá malou relativní změnu výstupních dat.

$$C_p = \|A^{-1}\| \cdot \|A\|$$

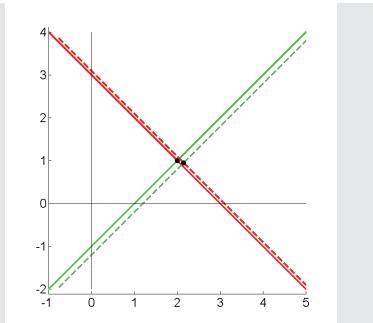
$$A^{-1} = \begin{bmatrix} 0,5 & 0,5 \\ 0,5 & -0,5 \end{bmatrix} = 0,5 A$$

$$C_p = 1 \cdot 2 = 2 \quad (\text{řádková, sloupcová norma}) \quad C_p = \frac{1}{\sqrt{2}} \sqrt{2} = 1 \quad (\text{spektrální norma})$$

$$(A^T A = \begin{bmatrix} 2 & 0 \\ 0 & 2 \end{bmatrix}) \quad \|A\|_{SP} = \sqrt{2}, \quad \|A^{-1}\|_{SP} = \frac{1}{\sqrt{2}}$$

1. změna pravé strany (změna matice $\Delta A = 0$)

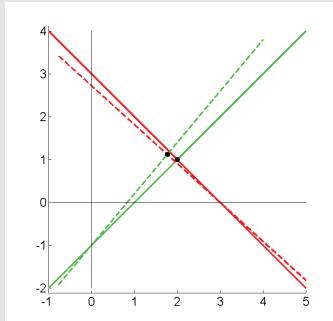
$$\Delta b = \begin{bmatrix} 0,1 \\ 0,2 \end{bmatrix}, \quad b + \Delta b = \begin{bmatrix} 3,1 \\ 1,2 \end{bmatrix}$$



změněná soustava $y = 3,1 - x$; $y = x - 1,2$

2. změna matice soustavy (změna pravé strany $\Delta b = 0$)

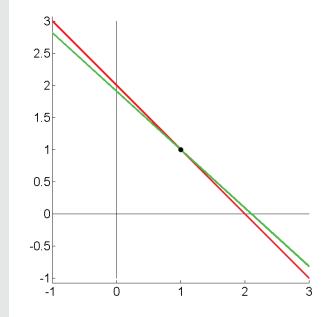
$$\Delta A = \begin{bmatrix} 0 & 0,1 \\ 0,2 & 0 \end{bmatrix}, \quad A + \Delta A = \begin{bmatrix} 1 & 1,1 \\ 1,2 & -1 \end{bmatrix}$$



změněná soustava $y = \frac{1}{1,1}(3 - x)$; $y = 1,2x - 1$

Geometrická interpretace - špatně podmíněná úloha (2D)

$$\begin{cases} x + y = 2 \\ x + 1,1y = 2,1 \end{cases} \Rightarrow \begin{cases} y = 2 - x \\ y = \frac{1}{1,1}(2,1 - x) \end{cases} \quad \text{řešení } x^* = 1, y^* = 1$$



$$A = \begin{bmatrix} 1 & 1 \\ 1 & 1,1 \end{bmatrix}, \quad b = \begin{bmatrix} 2 \\ 2,1 \end{bmatrix}$$

Špatně podmíněná úloha - malá relativní změna vstupních dat vyvolá velkou relativní změnu výstupních dat.

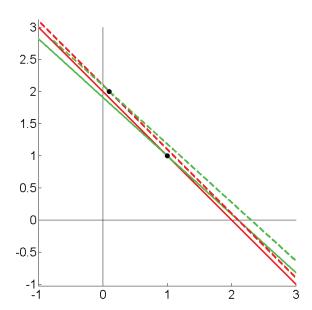
$$C_p = \|A^{-1}\| \cdot \|A\|$$

$$A^{-1} = \begin{bmatrix} 11 & -10 \\ -10 & 10 \end{bmatrix}$$

$$C_p = 2,1 \cdot 21 = 44,1 \quad (\text{řádková, sloupcová norma}) \quad C_p = 2,0512 \cdot 20,5125 = 42,07 \quad (\text{spektrální norma})$$

1. změna pravé strany (změna matice $\Delta A = 0$)

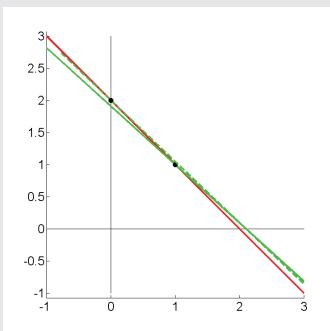
$$\Delta b = \begin{bmatrix} 0,1 \\ 0,2 \end{bmatrix}, \quad b + \Delta b = \begin{bmatrix} 2,1 \\ 2,3 \end{bmatrix}$$



$$\text{změněná soustava } \quad y = 2 - x; \quad y = \frac{1}{1+x}(2-x)$$

2. změna maticy soustavy (změna pravé strany $\Delta b = 0$)

$$\Delta A = \begin{bmatrix} 0 & 0 \\ 0 & -0,05 \end{bmatrix}, \quad A + \Delta A = \begin{bmatrix} 1 & 1 \\ 1 & 1,05 \end{bmatrix}$$



$$\text{změněná soustava } \quad y = 2 - x; \quad y = \frac{1}{1+0.05x}(2,1 - x)$$

Poznámka: Jiný výpočet čísla podmíněnosti (prakticky)

$$Ax = b$$

změna na vstupu ... ΔA

vypočítanou změnu na výstupu ... Δx

$$(A + \Delta A)(x + \Delta x) = b$$

$$C_p = \frac{\|\Delta x\|}{\|x\|}$$

Příklad

$$A = \begin{bmatrix} 50 & -100 \\ 50 & -101 \end{bmatrix}, \quad b = \begin{bmatrix} 0 \\ -1 \end{bmatrix}, \quad x = \begin{bmatrix} 2 \\ 1 \end{bmatrix}$$

změna maticy soustavy

$$\Delta A = \begin{bmatrix} 0 & 0,1 \\ 0,2 & 0 \end{bmatrix} \Rightarrow \tilde{A} = A + \Delta A = \begin{bmatrix} 50 & -99,9 \\ 50,2 & -101 \end{bmatrix}$$

$$\tilde{x} = \tilde{A}^{-1}b = \begin{bmatrix} 2,8527 \\ 1,4278 \end{bmatrix}$$

$$\Delta x = x - \tilde{x} = \begin{bmatrix} 2 \\ 1 \end{bmatrix} - \begin{bmatrix} 2,8527 \\ 1,4278 \end{bmatrix} = \begin{bmatrix} -0,8527 \\ -0,4278 \end{bmatrix}$$

$\ .\ $	1.vektorová / sloupcová	maximová / řádková	euklidovská / spektrální
$\Delta x = \begin{bmatrix} -0,8527 \\ -0,4278 \end{bmatrix}$	1,2805	0,8527	0,9539
$x = \begin{bmatrix} 2 \\ 1 \end{bmatrix}$	3	2	2,2361
$\Delta A = \begin{bmatrix} 0 & 0,1 \\ 0,2 & 0 \end{bmatrix}$	0,2	0,2	0,2
$A = \begin{bmatrix} 50 & -100 \\ 50 & -101 \end{bmatrix}$	201	151	158,7479
C_p	428,97	321,89	338,6

$$\|x\|_1 = \sum_i |x_i|, \quad \|x\|_\infty = \max_i |x_i|, \quad \|x\|_2 = \sqrt{\sum_i x_i^2}$$

$$\|A\|_S = \max_k \sum_i |a_{ik}|, \quad \|A\|_R = \max_i \sum_k |a_{ik}|, \quad \|A\|_{SP} = \max_k \lambda_k^{\frac{1}{2}}(A^H A)$$

(Při použití různých norem dostáváme obecně různá čísla podmíněnosti.)

$$C_p = \|A^{-1}\| \cdot \|A\|$$

$$A^{-1} = \begin{bmatrix} 2,02 & -2 \\ 1 & -1 \end{bmatrix}$$

$$C_p = 151 \cdot 4,02 = 607,02 \quad (\text{řádková } ||.||)$$

$$C_p = 201 \cdot 3,02 = 607,02 \quad (\text{sloupcová } ||.||)$$

$$C_p = 158,7479 \cdot 3,1750 \doteq 504,03 \quad (\text{spektrální } ||.||)$$

Pro špatně podmíněnou úlohu obsahuje A^{-1} velké prvky, které i pro malé hodnoty r mohou znamenat velkou chybou.

pří:

$$A = \begin{bmatrix} 1 & 1 \\ 1 & 0,99999 \end{bmatrix}, \quad b = \begin{bmatrix} 2 \\ 1,99999 \end{bmatrix}$$

přesné řešení: $x^* = [1, 1]^T$

vypočtené může být: $x_c = [-98, 100]^T$

$$r = Ax_c - b = \begin{bmatrix} 2 \\ 1,999 \end{bmatrix} - \begin{bmatrix} 2 \\ 1,99999 \end{bmatrix} = \begin{bmatrix} 0 \\ -0,00099 \end{bmatrix}$$

\Rightarrow je lepší pokoušet se odhadovat $\|x_c - x^*\|$.

Bohužel se v odhadech vždy vyskytuje norma $\|A^{-1}\|$!!! Podrobněji viz literatura.

Poznámky k podmíněnosti

- Stále předpokládáme, že A je regulární matici.

Soustava $Ax = b$ má potom právě jedno řešení.

Předpokládáme, že je matici A normalizována tak, že její max. prvek v absolutní hodnotě je roven 1. Je-li soustava špatně podmíněná, potom matici A^{-1} musí obsahovat velké prvky.

např:

$$A = \begin{bmatrix} 1 & 1 \\ 1 & 0,99999 \end{bmatrix} \Rightarrow A^{-1} = \begin{bmatrix} -99999 & 100000 \\ 100000 & -100000 \end{bmatrix}$$

To odpovídá faktu, že číslo podmíněnosti je velké $|C_p = \|A\| \cdot \|A^{-1}\||$ (norma $\|A^{-1}\|$ je velká).

- Rozbor chyb

$$Ax = b, \quad x^* \dots \text{přesné}, \quad x_c \dots \text{vypočtené}$$

\Rightarrow chybu můžeme měřit pomocí rezidua $r = Ax_c - b$ (pro přesné řešení je $r = Ax^* - b = 0$)

Platí: Je-li x_c blízko x^* \Rightarrow reziduum je malé. Bohužel to neplatí obráceně !!!

$$r = A(x_c - x^*)$$

$$x_c - x^* = A^{-1}r$$

Kapitola 4. SLAR - iterační metody

Metody na řešení SLAR

- přímé (GEM, metoda LU-rozkladu) ✓
- iterační
- gradientní

Iterační metody najdou přesné řešení teoreticky až po nekonečně mnoha krocích.

Pamatujeme si, že v numerické praxi používáme pro řešení soustav s plnou maticí **přímé metody**, zatímco pro speciální (řídké) matice používáme **iterační metody**.

Toto rozdělení je dáný **výpočetní složitostí** těchto metod, tj. počtem matematických operací sčítání, odčítání, násobení a dělení nutných k získání výsledku.

Poznámka: V případě plné matice je výpočetní cena v každé iteraci rádu n^2 , srovnejme-li totiž s celkovou výpočetní cenou přímých metod, tj. rádu $2/3 n^3$, vidíme, že má-li být výpočetní složitost iterační metody stejná jako u přímé metod, musela by iterační metoda najít řešení (s předem zadanou přesností) rádově po n iteracích. Na druhou stranu v případě speciální (řídké) matice je výhodné použít iterační metodu.

Příklad

Uvažujme rovnici

$$9x = 9$$

Přesné řešení je

$$x^* = 1$$

Rovnici lze přepsat např. na tvar

$$10x - x = 9$$

$$x = \frac{9+x}{10}$$

- viz metoda prosté iterace pro nelineární rovnice
- nyní uvažujeme lineární rovnice, proto předpis funkce $\varphi(x)$ může být lineární
- řešení hledáme pomocí rekurentní formule (volíme např. $x^{(0)} = 0$)

$$x^{(k+1)} = \frac{9+x^{(k)}}{10}$$

Dostáváme

$$x^{(1)} = 0,9$$

$$\begin{aligned} x^{(2)} &= 0,99 \\ x^{(3)} &= 0,999 \\ x^{(4)} &= 0,9999 \end{aligned}$$

Zastavíme např. pomocí podmínky na rozdíl dvou po sobě jdoucích iterací $|x^{(4)} - x^{(3)}| < \varepsilon = 0,001$

Uvedený postup realizujeme pro soustavy.

Podobně jako v metodě prosté iterace pro nelineární soustavy přepíšeme soustavu

$$\begin{aligned} Ax - b &= 0 & \leftrightarrow & F(x) = 0 \\ \text{na tvar} & & & \\ x &= Hx + g & \leftrightarrow & x = \Phi(x) \end{aligned}$$

Uvažujeme-li soustavu lineárních algebraických rovnic, tj. funkce F je lineární, můžeme potom najít lineární předpis pro funkci Φ .

Všechny iterační metody pro řešení soustavy lineárních algebraických rovnic budou používat iterační formulu

$$x^{(k+1)} = Hx^{(k)} + g$$

samozejmé s různou iterační maticí H a vektorem g a je zřejmé, že o kvalitě metod rozhodují právě vlastnosti matice H .

Počáteční approximaci $x^{(0)}$ zvolíme a výpočet ukončíme pomocí zastavovací podmínky

$$\|x^{(k)} - x^{(k-1)}\| < \varepsilon$$

Jacobiova metoda
Princip:

Z i -té rovnice vyjádříme i -tu složku vektoru x

$$i$$
-tá rovnice: $a_{1i}x_1 + a_{2i}x_2 + \dots + a_{ni}x_n = b_i$

$$\text{pro } a_{ii} \neq 0: \quad x_i = \frac{1}{a_{ii}} \left(b_i - \sum_{j=1, j \neq i}^n a_{ij}x_j \right)$$

Iterační formule:

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

Gaussova-Seidelova metoda
Princip:

Stejný jako u Jacobiovy metody s tím rozdílem, že jestliže při výpočtu $(k+1)$ -iterace již známe $(k+1)$ -iteraci některých složek, tak ji použijeme.

Z i -té rovnice vyjádříme i -tu složku vektoru x

$$i$$
-tá rovnice: $a_{1i}x_1 + a_{2i}x_2 + \dots + a_{ni}x_n = b_i$

$$\text{pro } a_{ii} \neq 0: \quad x_i = \frac{1}{a_{ii}} \left(b_i - \sum_{j=1, j \neq i}^n a_{ij}x_j^{(k)} \right)$$

Iterační formule:

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

Relaxační metoda SOR
Princip:

Vyjdeme z Gaussovy-Seidelovy metody jejíž iterační formule je

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

dále vyjádříme $(k+1)$ -u iteraci pomocí k -té iterace a příslušné změny $r_i^{(k)}$ (tj. přičteme a odečteme $x_i^{(k)}$)

$$x_i^{(k+1)} = x_i^{(k)} + \frac{1}{a_{ii}} \left(b_i - \underbrace{\sum_{j=1}^{i-1} a_{ij}x_j^{(k+1)}}_{r_i^{(k)}} - \underbrace{\sum_{j=i+1}^n a_{ij}x_j^{(k)}}_{-a_{ii}x_i^{(k)}} \right),$$

k urychlení výpočtu použijeme ideu, že nepřičteme k předešlé iteraci změnu $r_i^{(k)}$, ale její násobek $\omega r_i^{(k)}$

$$x_i^{(k+1)} = x_i^{(k)} + \omega \cdot \frac{1}{a_{ii}} \left(b_i - \sum_{j=1}^{i-1} a_{ij}x_j^{(k+1)} - \underbrace{\sum_{j=i+1}^n a_{ij}x_j^{(k)}}_{-a_{ii}x_i^{(k)}} \right)$$

Iterační formule:

$$x_i^{(k+1)} = (1-\omega)x_i^{(k)} + \omega \frac{1}{a_{ii}} \left(b_i - \underbrace{\sum_{j=1}^{i-1} a_{ij}x_j^{(k+1)}}_{x_j^{(k+1)} \text{ z GS}} - \underbrace{\sum_{j=i+1}^n a_{ij}x_j^{(k)}}_{a_{ij}x_j^{(k)}} \right)$$

Poznámka: $(k+1)$ -iterace metody SOR je lineární kombinací $(k+1)$ -iterace získané Gauss-Seidelovou metodou a předešší k -té iterace metody SOR

$$x_i^{(k+1)} = \omega x_i^{(k+1)} + (1-\omega)x_i^{(k)}.$$

Maticový zápis iteračních metod

Nejprve rozložíme matici A :

$$A = L + D + U$$

kde L je dolní trojúhelníková část maticy A s nulami na diagonále, D je diagonální matici a U je horní trojúhelníková část maticy A s nulami na diagonále.

Jacobiova metoda

$$\begin{aligned} Ax &= b \\ (L + D + U)x &= b \\ Dx + (L + U)x &= b \\ Dx &= b - (L + U)x \\ x &= \underbrace{-D^{-1}(L + U)x}_{H_J} + \underbrace{D^{-1}b}_{g_J} \end{aligned}$$

Gauss-Seidelova metoda

$$\begin{aligned} Ax &= b \\ (L + D + U)x &= b \\ (L + D)x + Ux &= b \\ (L + D)x &= b - Ux \\ x &= \underbrace{-(L + D)^{-1}Ux}_{H_{GS}} + \underbrace{(L + D)^{-1}b}_{g_{GS}} \end{aligned}$$

Relaxační metoda SOR



$$\begin{aligned} Ax &= b \\ \omega Ax &= \omega b \quad / + Dx \\ (\omega A + D)x &= \omega b + Dx \\ [\omega(L + D + U) + D]x &= \omega b + Dx \\ (\omega L + D)x &= \omega b + Dx - \omega D x - \omega U x \\ (\omega L + D)x &= [(1-\omega)D - \omega U]x + \omega b \\ x &= \underbrace{(\omega L + D)^{-1}[(1-\omega)D - \omega U]x}_{H_{SOR}} + \underbrace{(\omega L + D)^{-1}\omega b}_{e_{SOR}} \end{aligned}$$

Iterační metoda je dána formulí

$$x^{(k+1)} = Hx^{(k)} + g$$

Pro přesné řešení x^* musí platit

$$\begin{aligned} \bullet \quad x^* &= Hx^* + g \\ \bullet \quad x^* &= A^{-1}b \end{aligned} \Rightarrow \quad A^{-1}b = HA^{-1}b + g \quad (*)$$

Definice: Iterační metoda $x^{(k+1)} = Hx^{(k)} + g$ nazveme **konzistentní**, pokud platí (*).

Poznámka: Uvedené metody jsou konzistentní.

• např. pro Jacobiovu metodu musí platit:

$$\begin{aligned} A^{-1}b &= \underbrace{-D^{-1}(L+U)}_{H_J} A^{-1}b + \underbrace{D^{-1}b}_{g_J} \\ A^{-1}b &= D^{-1} \left(\underbrace{-(L+U)+A}_D \right) A^{-1}b \end{aligned}$$

• D.c.v.: Ukažte, že Gauss-Seidelova metoda a metoda SOR jsou konzistentní.

Definice: Iterační metoda $x^{(k+1)} = Hx^{(k)} + g$ se nazývá **konvergentní**, jestliže pro každou počáteční approximaci $x^{(0)} \in \mathbb{R}$ platí:

$$\lim_{k \rightarrow \infty} x^{(k)} = x^* \quad (= A^{-1}b).$$

Chyba k -té iterace:

$$e^{(k)} = x^{(k)} - x^*.$$

Nutná a postačující podmínka konvergence metody

iterační předpis

$$x^{(k)} = Hx^{(k-1)} + g$$

konzistentní metoda

$$x^* = Hx^* + g$$



$$H = \begin{bmatrix} 0 & -0,9 & -0,9 \\ -0,9 & 0 & -0,9 \\ -0,9 & -0,9 & 0 \end{bmatrix}$$

... vlastní čísla jsou $-1,8; 0,9; 0,9 \Rightarrow \rho(H) = 1,8 > 1 \Rightarrow$ metoda diverguje !!!

Uvažujme normu $\|H\|_M = \max_{i,j} |h_{ij}|$

D.c.v.: Ukažte, že $\|\cdot\|_M$ splňuje vlastnosti normy.

$$\|H\|_M = 0,9 < 1 \quad !!!$$

$\|\cdot\|_M$ není multiplikativní:

např.

$$A = \begin{bmatrix} 1 & 1 \\ 1 & 1 \end{bmatrix}, \quad B = \begin{bmatrix} 2 & 2 \\ 2 & 2 \end{bmatrix}, \quad A \cdot B = \begin{bmatrix} 4 & 4 \\ 4 & 4 \end{bmatrix}$$

$$\|A\|_M \cdot \|B\|_M = 1 \cdot 2 = 2 \quad \text{!!!} \quad \|A \cdot B\|_M = 4$$

$$\|A\|_M \cdot \|B\|_M = 2 \underset{\text{!!!}}{\leq} \|A \cdot B\|_M = 4$$

Věta: Pro každou multiplikativní maticovou normu $\|\cdot\|$ a čtvercovou matici A platí:

$$\rho(A) \leq \|A\|.$$

Důkaz:

$$\rho(A) = \max_i |\lambda_i| = |\lambda_p|$$

• nechť číslu λ_p odpovídá normovaný vlastní vektor v_p ($\nu(v_p) = 1$)

• potom

$$\rho(A) = |\lambda_p| \cdot \nu(v_p) = \nu(\lambda_p v_p) = \nu(Av_p)$$

vlastnost kompatibilní maticové a vektorové normy:

$$|\nu(Av_p)| \leq \|A\| \cdot |\nu(v_p)| = \|A\| \cdot 1 = \|A\|$$

Pomocná věta: Ke každé multiplikativní maticové normě μ existuje kompatibilní vektorová norma ν .

Důkaz: Je dáná maticová norma μ .

Definujeme $\nu(x) = \mu([x, 0, 0, \dots, 0]) \dots$ splňuje vlastnosti normy

? kompatibilita:



po odečtení dostáváme

$$\begin{aligned} x^{(k)} - x^* &= H(x^{(k-1)} - x^*) \\ e^{(k)} &= He^{(k-1)} = H^2e^{(k-2)} = \dots = H^k e^* \end{aligned}$$

Plati:

$$e^{(k)} = He^{(k-1)} = H^2e^{(k-2)} = \dots = H^k e^*$$

$$\lim_{k \rightarrow \infty} x^{(k)} = x^* \Leftrightarrow \lim_{k \rightarrow \infty} e^{(k)} = 0$$

Věta: Daná konzistentní iteracní metoda $x^{k+1} = Hx^{(k)} + g$ konverguje pro libovolné $x^{(0)} \in \mathbb{R}^n$ právě tehdy, když je **stabilní**.

$$\boxed{\rho(H) = \max_i |\lambda_i(H)| < 1},$$

kde číslo $\rho(H)$ nazýváme **spektrální poloměr** maticy H a $\lambda_k(H)$ jsou vlastní čísla maticy H .

Poznámka: Připomeňme souvislost s metodou prosté iterace pro řešení soustav nelineárních rovnic. Funkce $\Phi(x)$ z přepisu $x = \Phi(x)$ musela splňovat podmínu $(b') \dots$ (pokud byla diferencovatelná)

$$\exists q \in (0, 1) : \|\Phi'(x)\| \leq q \quad \forall x$$

V našem případě je

$$\Phi(x) = Hx + g \Rightarrow \Phi'(x) = H$$

Tj.

$$\boxed{\|H\| < 1}.$$

Spektrální poloměr $\rho(H)$ je také normou maticy H , tj. $\boxed{\rho(H) < 1}$.

Předchozí věta je silnější (kritérium)

Věta pro prostou iteraci uváděla postačující podmínky

Poznámka: Určovat $\rho(H)$ je celkem dražé, proto za chvíli uvedeme větu (postačující podmínky) jejíž předpoklady se ověří snadněji.

Definice:

Maticovou normu $\|\cdot\|$ nazveme **multiplikativní**, splňuje-li pro všechny čtvercové matice A, B řádu n vztah

$$\boxed{\|A \cdot B\| \leq \|A\| \cdot \|B\|}$$

Příklad 2

Řešme soustavu $Ax = b$ Jacobiovou metodou.

$$A = \begin{bmatrix} 1 & 0,9 & 0,9 \\ 0,9 & 1 & 0,9 \\ 0,9 & 0,9 & 1 \end{bmatrix}, \quad b = \begin{bmatrix} 2,8 \\ 2,8 \\ 2,8 \end{bmatrix}, \quad \text{přesné řešení } x^* = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix}$$



$$\nu(Ax) = \mu([Ax, 0, 0, \dots, 0]) = \mu(A[x, 0, 0, \dots, 0]) \stackrel{(*)}{\leq} \mu(A)\mu([x, 0, 0, \dots, 0]) = \mu(A) \cdot \nu(x)$$

(*) μ je multiplikativní

Věta (Postačující podmínka konvergence)

Je-li pro multiplikativní normu splněna podmínka $\boxed{\|H\| \leq q < 1}$, potom posloupnost $\{x^{(k)}\}$ určená konzistentní formulí

$$x^{(k)} = Hx^{(k-1)} + g$$

konverguje při libovolné volbě vektoru $x^{(0)} \in \mathbb{R}^n$ a platí

$$\boxed{\lim_{k \rightarrow \infty} x^{(k)} = (I - H)^{-1}g = x^*}.$$

Důkaz: Důsledek kritéria a předchozí věty (jiný důkaz viz skripta).

Odhad chyby

Předpokládáme, že je splněna postačující podmínka konvergence

$$\boxed{\|H\| \leq q < 1}$$

$$\begin{aligned} x^{(k)} - x^* &= H(x^{(k-1)} - x^*) \\ &= H(x^{(k-1)} - x^{(k)} + x^{(k)} - x^*) \\ &= H(x^{(k-1)} - x^{(k)}) + H(x^{(k)} - x^*) \end{aligned}$$

Odtud dostáváme

$$\begin{aligned} \|x^{(k)} - x^*\| &\leq q \|x^{(k)} - x^{(k-1)}\| + q \|x^{(k)} - x^*\| \\ \text{tj.} \quad \underbrace{(1-q)}_{>0} \|x^{(k)} - x^*\| &\leq q \|x^{(k)} - x^{(k-1)}\| \end{aligned}$$

a po vydělení

$$\boxed{\|x^{(k)} - x^*\| \leq \frac{q}{1-q} \|x^{(k)} - x^{(k-1)}\|}.$$

Jestliže $\|x^{(k)} - x^{(k-1)}\| < \varepsilon$, potom

$$\boxed{\|x^{(k)} - x^*\| \leq \frac{q}{1-q} \varepsilon}.$$

Příklad 3

 Jacobiovou metodou řešte soustavu $\mathbf{A}\mathbf{x} = \mathbf{b}$.

$$\mathbf{A} = \begin{bmatrix} 8 & 4 & 2 \\ 1 & 10 & 1 \\ 0 & 0 & 2 \end{bmatrix}, \quad \mathbf{b} = \begin{bmatrix} 14 \\ 12 \\ 2 \end{bmatrix}, \quad \mathbf{x}^{(0)} = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}$$

$$\mathbf{A} = \underbrace{\begin{bmatrix} 0 & 0 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}}_L + \underbrace{\begin{bmatrix} 8 & 0 & 0 \\ 0 & 10 & 0 \\ 0 & 0 & 2 \end{bmatrix}}_D + \underbrace{\begin{bmatrix} 0 & 4 & 2 \\ 0 & 0 & 1 \\ 0 & 0 & 0 \end{bmatrix}}_U$$

$$\mathbf{H}_J = -\mathbf{D}^{-1}(\mathbf{L} + \mathbf{U}) = \begin{bmatrix} 0 & -0,5 & -0,25 \\ -0,1 & 0 & -0,1 \\ 0 & 0 & 0 \end{bmatrix}, \quad \mathbf{g}_J = \mathbf{D}^{-1}\mathbf{b} = \begin{bmatrix} 1,75 \\ 1,2 \\ 1 \end{bmatrix}$$

Provedeme 5 iterací:

k	x_1^k	x_2^k	x_3^k
0	0	0	0
1	1,75	1,2	1
2	0,9	0,925	1
3	1,0375	1,01	1
4	0,995	0,99625	1
5	1,001875	1,0005	1

$\underbrace{\mathbf{x}^{(5)} - \mathbf{x}^{(4)}}_{= \mathbf{r}^{(5)}} = \begin{bmatrix} 0,006875 \\ 0,004250 \\ 0,000000 \end{bmatrix}$

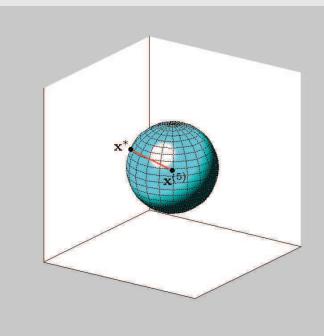
 Odhadněme chybu $\mathbf{x}^{(5)}$, tj.

$$\|\mathbf{x}^{(5)} - \mathbf{x}^*\| \leq \frac{\|\mathbf{H}\|}{1 - \|\mathbf{H}\|} \cdot \|\mathbf{x}^{(5)} - \mathbf{x}^{(4)}\|$$

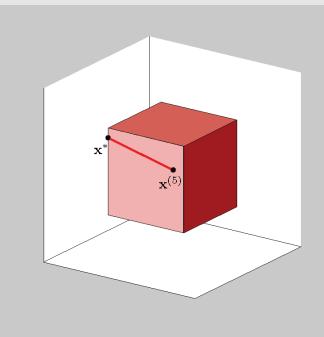
maticová norma	vektorová norma	odhad chyby
$\ \mathbf{H}\ _S = \max_k (\sum_i h_{ik}) = 0,5$	$\ \mathbf{r}^{(5)}\ _1 = \sum_i r_i = 0,011125$	$\frac{0,5}{1 - 0,5} \cdot 0,011125 = \mathbf{0,011125}$
$\ \mathbf{H}\ _R = \max_k (\sum_k h_{ik}) = 0,75$	$\ \mathbf{r}^{(5)}\ _\infty = \max_i r_i = 0,006875$	$\frac{0,75}{0,25} \cdot 0,006875 = \mathbf{0,0206}$
$\ \mathbf{H}\ _{SP} = \max_k \lambda_k^{\frac{1}{2}} (\mathbf{H}^T \mathbf{H}) \doteq 0,56$	$\ \mathbf{r}^{(5)}\ _2 = \sum_i r_i^2 \doteq 0,0081$	$\frac{0,56}{0,44} \cdot 0,0081 = \mathbf{0,0103}$

Geometrický význam

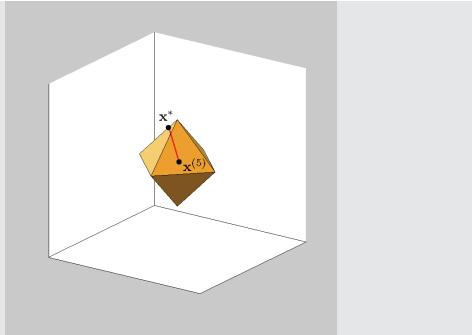
$$\|\mathbf{x}^{(5)} - \mathbf{x}^*\|_2 \leq 0,0103$$

 vzdálenost $\mathbf{x}^{(5)}$ a \mathbf{x}^* je menší než vypočtená hodnota


$$\|\mathbf{x}^{(5)} - \mathbf{x}^*\|_\infty \leq 0,0206$$



$$\|\mathbf{x}^{(5)} - \mathbf{x}^*\|_1 \leq 0,011125$$


Rychlosť konvergencie

- Lineárni rychlosť konvergencie

$$\exists q \in (0, 1) \exists k_0 \geq 0 \forall k > k_0 : \|\mathbf{x}^{(k+1)} - \mathbf{x}^*\| \leq q \|\mathbf{x}^{(k)} - \mathbf{x}^*\|$$

- Superlineárni rychlosť konvergencie

$$\|\mathbf{x}^{(k+1)} - \mathbf{x}^*\| \leq q_k \|\mathbf{x}^{(k)} - \mathbf{x}^*\|, \quad \text{kde } q_k \rightarrow 0 \ (k \rightarrow \infty)$$

- Konvergencie řádu r

$$\|\mathbf{x}^{(k+1)} - \mathbf{x}^*\| \leq q \|\mathbf{x}^{(k)} - \mathbf{x}^*\|^r$$

Poznámka:

- Jacobiova, Gauss-Seidelova i SOR metoda mají lineárni rychlosť konvergencie

$$\mathbf{x}^{(k+1)} - \mathbf{x}^* = \mathbf{H}(\mathbf{x}^{(k)} - \mathbf{x}^*)$$

 během výpočtu se nemění iterační matici \mathbf{H} , jedná se o **stacionární metody**

$$\|\mathbf{H}\| \leq q, \quad \|\mathbf{H}\| \dots \text{pevné číslo}$$

- Metody se superlineárni rychlosť konvergencie patří mezi **nestacionární procesy**

$$\mathbf{x}^{(k+1)} = \mathbf{H}_k \mathbf{x}^{(k)} + \mathbf{g}_k$$

 V každém kroku se mohou měnit \mathbf{H}_k , \mathbf{g}_k .

 Potom $\|\mathbf{H}_k\| \leq q_k$, platí-li $q_k \rightarrow 0$ pak jde o superlineárni metodu.

Definujeme asymptotickou rychlosť konvergencie

$$R = -\log \frac{\|\mathbf{e}^{(k)}\|}{\|\mathbf{e}^{(k-1)}\|} \geq -\log \|\mathbf{H}\|,$$

ta určuje počet platných desetinných míst získaných v jednom iteračním kroku.

Prakticky:

$$\frac{\|\mathbf{e}^{(k)}\|}{\|\mathbf{e}^{(k-1)}\|} = \frac{\|\mathbf{x}^{(k)} - \mathbf{x}^*\|}{\|\mathbf{x}^{(k-1)} - \mathbf{x}^*\|} \approx \frac{\frac{q}{1-q}}{\frac{q}{1-q}} \frac{\|\mathbf{x}^{(k)} - \mathbf{x}^{(k-1)}\|}{\|\mathbf{x}^{(k-1)} - \mathbf{x}^{(k-2)}\|}$$

 Poznámka: Pro metody s lineárni rychlosť konvergencie (Jacobiova, Gauss-Seidelova, SOR metoda) lze pro urychlení použít **Aitkenovu extrapolaci** formuli (viz dříve).

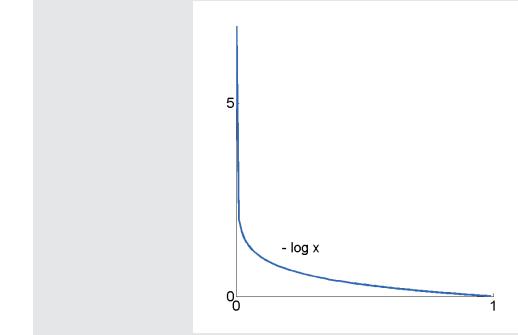
Posloupnost chyb je geometrická

$$\mathbf{e}^{(k)} = \mathbf{H}\mathbf{e}^{(k-1)}$$

$$\frac{\mathbf{e}_i^{(k+1)}}{\mathbf{e}_i^{(k)}} \approx \frac{\mathbf{e}_i^{(k)}}{\mathbf{e}_i^{(k-1)}} \approx \frac{\mathbf{e}_i^{(k)}}{\mathbf{e}_i^{(k-1)}} \frac{\mathbf{e}_i^{(k)}}{\mathbf{e}_i^{(k-2)}}$$

po úpravě:

$$\mathbf{x}^* \approx \mathbf{x}_i^{(k+1)} - \frac{(\mathbf{x}_i^{(k+1)} - \mathbf{x}_i^{(k)})^2}{\mathbf{x}_i^{(k+1)} - 2\mathbf{x}_i^{(k)} + \mathbf{x}_i^{(k-1)}}$$

 Při odvození metody SOR jsme se pokusili urychlit výpočet změny iterační matici \mathbf{H} tak, aby měla menší spektrální poloměr $\rho(\mathbf{H})$. Čím menší je $\rho(\mathbf{H})$, tím je větší asymptotická rychlosť konvergencie.


Věta: Spektrální poloměr $\varrho(\mathbf{H}_{SOR})$ splňuje podmínku

$$\varrho(\mathbf{H}_{SOR}) \geq |\omega - 1| \quad \forall \omega \in \mathbb{R}$$

Důkaz:

$$\mathbf{H}_{SOR} = (\omega \mathbf{L} + \mathbf{D})^{-1} [(1-\omega) \mathbf{D} - \omega \mathbf{U}]$$

Je známo, že součin vlastních čísel je roven determinantu

$$\prod_{i=1}^n \lambda_i = \det(\mathbf{H}_{SOR})$$

$$\begin{aligned} \det(\mathbf{H}_{SOR}) &= \det[(\omega \mathbf{L} + \mathbf{D})^{-1} [(1-\omega) \mathbf{D} - \omega \mathbf{U}]] = \det[(\mathbf{D}(\omega \mathbf{D}^{-1} \mathbf{L} + \mathbf{I}))^{-1} \mathbf{D} [(1-\omega) \mathbf{I} - \omega \mathbf{D}^{-1} \mathbf{U}]] = \\ &= \det[(\omega \mathbf{D}^{-1} \mathbf{L} + \mathbf{I})^{-1} [(1-\omega) \mathbf{I} - \omega \mathbf{D}^{-1} \mathbf{U}]] = \det(\underbrace{\omega \mathbf{D}^{-1} \mathbf{L} + \mathbf{I}}_{(*)})^{-1} \cdot \det[(1-\omega) \mathbf{I} - \omega \mathbf{D}^{-1} \mathbf{U}] = (1-\omega)^n \end{aligned}$$

(*) dolní trojúhelníková matice s 1 na diagonále

(**) horní trojúhelníková matice a prvky $(1-\omega)$ na diagonále

$$\prod_{i=1}^n \lambda_i = (1-\omega)^n \quad \Rightarrow \quad \max_i |\lambda_i| \geq |1-\omega|$$

(***) Důkaz sporem: $\forall \lambda_i: |\lambda_i| < |1-\omega| \quad / \quad \prod_{i=1}^n |\lambda_i| < |1-\omega|^n$

Důsledek: Aby SOR konvergovala, musí platit:

$$|\omega - 1| \leq \varrho(\mathbf{H}_{SOR})$$

$$|\omega - 1| < 1 \Rightarrow \omega \in (0, 2)$$

Poznámky:

Parametr ω v relaxační metodě SOR volíme z intervalu $(0, 2)$.

Pro $\omega = 1$ přejde relaxační metoda na Gauss-Seidlovu metodu.

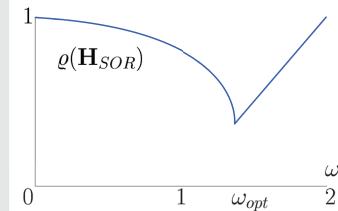
Volba parametru ω samozřejmě ovlivní rychlosť konvergence iteračního procesu metody SOR. Lze ukázat, že existuje optimální hodnota parametru omega

$$\omega_{opt} = \frac{2}{1 + \sqrt{1 - \varrho^2(\mathbf{H}_J)}},$$

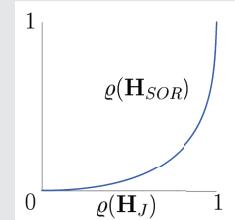
kde $\varrho(\mathbf{H}_J)$ je spektrální poloměr Jacobiových iteračních matic \mathbf{H}_J .

Pro spektrální poloměr iterační maticy \mathbf{H}_{SOR} relaxační metody lze odvodit následující závislosti:

- závislost spektrálního poloměru iterační maticy metody SOR na spektrálním poloměru iterační maticy Jacobiových metody



• závislost spektrálního poloměru iterační maticy metody SOR na spektrálním poloměru iterační maticy Jacobiových metody



Konvergenční věty

Dosud jsme udávali podmínky pro iterační matici \mathbf{H} . To je ovšem nepraktické. Uvedeme několik snadněji ověřitelných podmínek.

Věta 1 Je-li matici \mathbf{A} oštět diagonálně-dominantní, potom konverguje Jacobiová i Gauss-Seidelova metoda pro libovolnou volbu $\mathbf{x}^{(0)}$.

Věta 2 Je-li matici \mathbf{A} symetrická a pozitivně-definitní, potom Gauss-Seidelova metoda konverguje pro libovolnou volbu $\mathbf{x}^{(0)}$.

Věta 3 Nutnou podmínkou konvergence metody SOR je $0 < \omega < 2$. Přidáme-li symetrii a pozitivní definitnost matici \mathbf{A} , dostaneme postačující podmínky konvergence.

Důkaz Věty 1 pro Jacobiovu metodu:

$$\mathbf{Ax} = \mathbf{b}, \quad \text{rozklad matici } \mathbf{A} = \mathbf{L} + \mathbf{D} + \mathbf{U}$$

$$\text{označíme-li } \mathbf{C} = \mathbf{L} + \mathbf{U}, \text{ potom } \mathbf{A} = \mathbf{C} + \mathbf{D}$$

• Jacobiova metoda

$$\mathbf{x}^{(k+1)} = \mathbf{H}_J \mathbf{x}^{(k)} + \mathbf{g}_J$$

$$\mathbf{H}_J = -\mathbf{D}^{-1}(\mathbf{L} + \mathbf{U}) = -\mathbf{D}^{-1}\mathbf{C} \quad \text{a} \quad \mathbf{g}_J = \mathbf{D}^{-1}\mathbf{b}$$

• Matici \mathbf{A} je oštět diagonálně-dominantní, tj. platí

$$|a_{ii}| > \sum_{j=1, j \neq i}^n |a_{ij}| \quad i = 1, 2, \dots, n$$

• Pro náš rozklad $\mathbf{A} = \mathbf{C} + \mathbf{D}$ tedy platí:

$$|d_{ii}| > \sum_{j=1}^n |c_{ij}| \quad i = 1, 2, \dots, n \quad / : |d_{ii}| \neq 0$$

(když $|d_{ii}| = 0$, potom by byl celý řádek nulový ... \mathbf{A} je ale regulární)

)

• Platí:

$$\left| \sum_{j=1}^n \frac{|c_{ij}|}{|d_{ii}|} \right| < 1 \quad \text{pro } i = 1, 2, \dots, n \quad (*)$$

• Pro iterační matici platí:

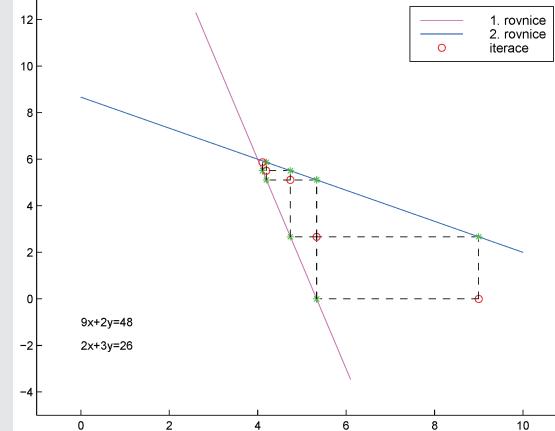
$$\mathbf{H}_J = -\mathbf{D}^{-1}\mathbf{C} = -\begin{bmatrix} \frac{1}{d_{11}} & & & \\ & \frac{1}{d_{22}} & & \\ & & \ddots & \\ & & & \frac{1}{d_{nn}} \end{bmatrix} \cdot \begin{bmatrix} c_{ij} \\ \vdots \\ c_{ij} \end{bmatrix} = -\begin{bmatrix} c_{ij} \\ \vdots \\ c_{ij} \end{bmatrix} \cdot \begin{bmatrix} \frac{1}{d_{11}} & & & \\ & \frac{1}{d_{22}} & & \\ & & \ddots & \\ & & & \frac{1}{d_{nn}} \end{bmatrix}$$

• Řádková norma matici \mathbf{H}_J :

$$\|\mathbf{H}_J\| = \max_i \sum_{j=1}^n \left| \frac{c_{ij}}{d_{ii}} \right| < 1 \quad \text{plyne z (*)}$$

Jacobiova metoda

1. rovnice
2. rovnice
iterace



Geometrický význam Gauss-Seidelovy metody

$$\begin{aligned} 9x + 2y &= 48 & x^{(k+1)} &= \frac{1}{9}(48 - 2y^{(k)}) \\ 2x + 3y &= 26 & y^{(k+1)} &= \frac{1}{3}(26 - 2x^{(k+1)}) \end{aligned}$$

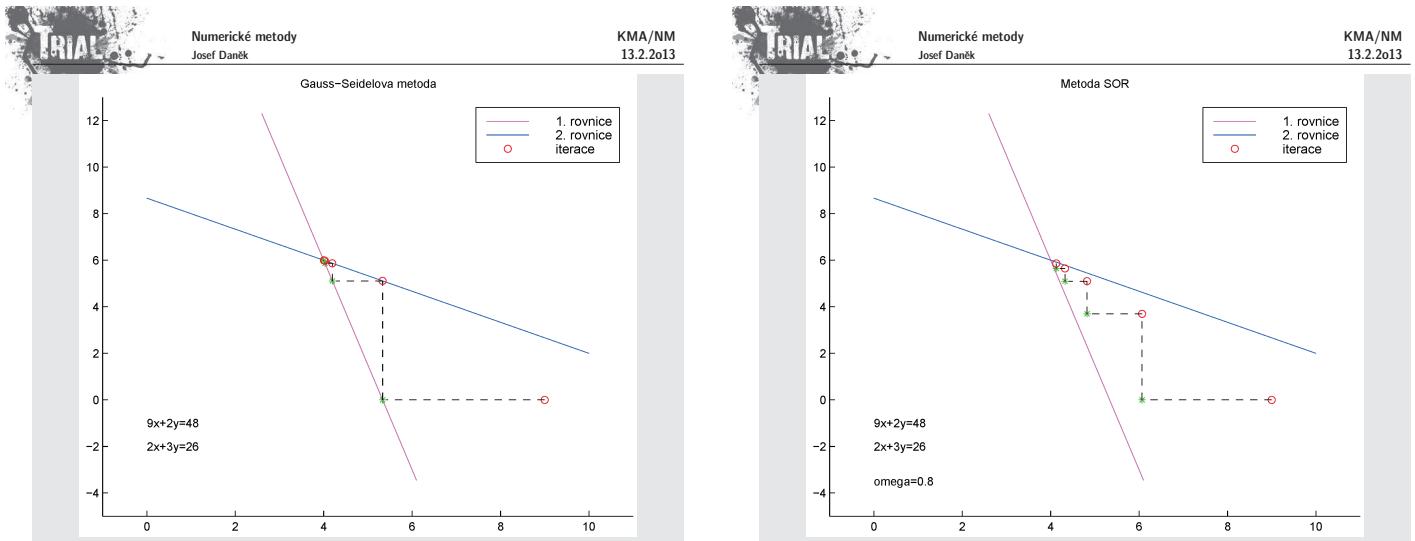
k	$x^{(k)}$	$y^{(k)}$
0	9.0000	0
1	5.3333	5.1111
2	4.1975	5.8683
3	4.0293	5.9805
4	4.0043	5.9971
5	4.0006	5.9996

Geometrický význam Jacobiové metody

k	$x^{(k)}$	$y^{(k)}$
0	9.0000	0
1	5.3333	2.6667
2	4.7407	5.1111
3	4.1975	5.5062
4	4.1097	5.8683
5	4.0293	5.9805

$$\begin{aligned} 9x + 2y &= 48 & x^{(k+1)} &= \frac{1}{9}(48 - 2y^{(k)}) \\ 2x + 3y &= 26 & y^{(k+1)} &= \frac{1}{3}(26 - 2x^{(k+1)}) \end{aligned}$$

$$\begin{aligned} 9x + 2y &= 48 & x^{(k+1)} &= \frac{1}{9}(48 - 2y^{(k)}) \\ 2x + 3y &= 26 & y^{(k+1)} &= \frac{1}{3}(26 - 2x^{(k+1)}) \end{aligned}$$



Geometrický význam metody SOR ($\omega < 1$)

$$9x + 2y = 48 \quad x_{GS}^{(k+1)} = \frac{1}{9}(48 - 2y^{(k)})$$

$$2x + 3y = 26 \quad y_{GS}^{(k+1)} = \frac{1}{3}(26 - 2x^{(k+1)})$$

k	$x^{(k)}$	$y^{(k)}$
0	9.0000	0
1	6.0667	3.6978
2	4.8226	5.1008
3	4.3244	5.6472
4	4.1276	5.8614
5	4.0502	5.9455

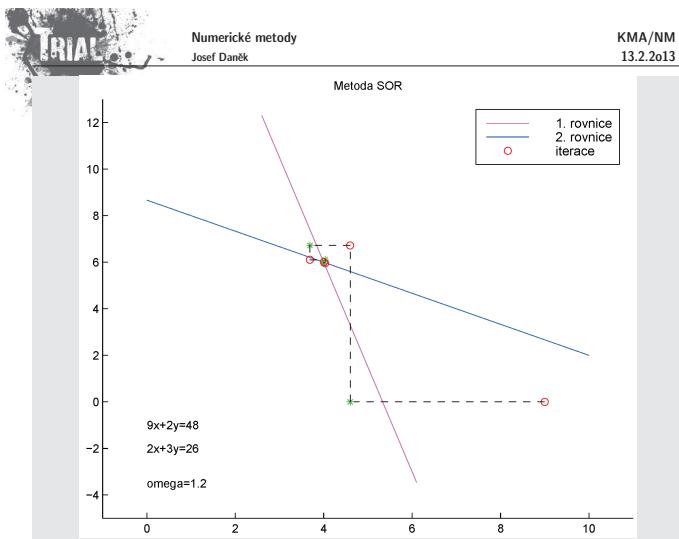
Geometrický význam metody SOR ($\omega > 1$)

$$9x + 2y = 48 \quad x_{GS}^{(k+1)} = \frac{1}{9}(48 - 2y^{(k)})$$

$$2x + 3y = 26 \quad y_{GS}^{(k+1)} = \frac{1}{3}(26 - 2x^{(k+1)})$$

$$\begin{aligned} x^{(k+1)} &= \omega \frac{1}{9}(48 - 2y^{(k)}) + (1 - \omega)x^{(k)} \\ y^{(k+1)} &= \omega \frac{1}{3}(26 - 2x^{(k+1)}) + (1 - \omega)y^{(k)} \end{aligned}$$

k	$x^{(k)}$	$y^{(k)}$
0	9.0000	0
1	4.6000	6.7200
2	3.6880	6.1056
3	4.0342	5.9515
4	4.0061	6.0048
5	3.9975	6.0010



Metody na řešení SLAR

- přímé (GEM, metoda LU-rozkladu) ✓
- iterační (Jacobiho m., Gauss-Seidelova m., metoda SOR) ✓
- gradientní

Motivace

Uvažujme kvadratickou funkci reálné proměnné x :

$$f(x) = \frac{1}{2}ax^2 - bx + c, \quad a > 0.$$

Nutná a postačující podmínka minima funkce $(f'(x) = 0)$ má tvar
 $ax = b$

To znamená, že místo řešení lineární rovnice můžeme řešit úlohu najít minimum konvexní kvadratické funkce $f(x)$ (obě úlohy mají stejná řešení).

Uvědomte si, že v případě funkce více proměnných je třeba splnit další podmínky kladené na matici soustavy A , abychom zaručili konvexitnost příslušné kvadratické funkce.

Uvažujeme soustavu (kde matice A je symetrická, pozitivně definitní)

$$Ax = b$$

Dále uvažujeme kvadratickou formu, tzv. **energetický funkcionál**

$$F(x) = \frac{1}{2}x^T Ax - b^T x.$$

Plati

$$\text{grad } F(x) = A x - b,$$

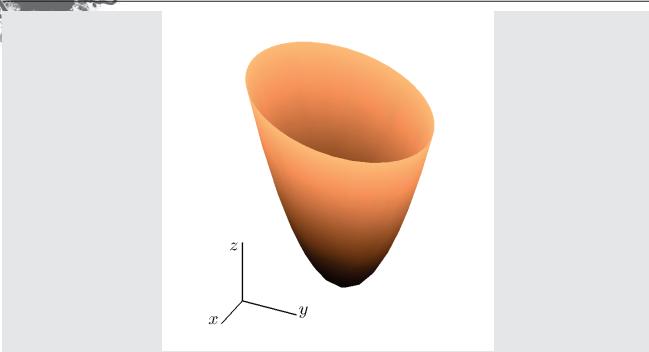
Funkce $F(x)$ je konvexní a kvadratická $\Rightarrow F(x)$ má globální minimum a pro bod minima \tilde{x} platí

$$\text{grad } F(\tilde{x}) = A\tilde{x} - b = 0.$$

Bod minima \tilde{x} je tedy řešením soustavy $Ax = b$.

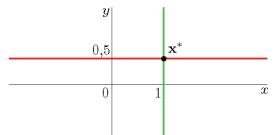
Poznámka: Úlohy najít bod minima funkce F a řešit soustavu $Ax = b$ jsou ekvivalentní.

Poznámka: V případě soustavy 2 rovnic si lze udělat geometrickou představu, neboť pro $x \in \mathbb{R}^2$ je grafem funkce $F(x)$ eliptický paraboloid, jehož vrstevnice jsou elipsy. Minima $F(x)$ se nabývá ve vrcholu paraboloidu.


Příklad 1

Uvažujme velmi jednoduchou soustavu $\mathbf{Ax} = \mathbf{b}$, kde

$$\mathbf{A} = \begin{bmatrix} 25 & 0 \\ 0 & 16 \end{bmatrix}, \quad \mathbf{b} = \begin{bmatrix} 25 \\ 8 \end{bmatrix}, \quad \mathbf{x}^* = \begin{bmatrix} 1 \\ 0,5 \end{bmatrix}.$$



Odpovídající kvadratická funkce je

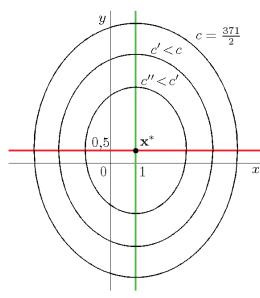
$$F(\mathbf{x}) = \frac{1}{2} \mathbf{x}^T \mathbf{A} \mathbf{x} - \mathbf{b}^T \mathbf{x} = \frac{1}{2} \begin{bmatrix} x & y \end{bmatrix} \begin{bmatrix} 25 & 0 \\ 0 & 16 \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} - \begin{bmatrix} 25 & 8 \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} = \frac{1}{2} (25x^2 + 16y^2) - 25x - 8y.$$

Vrstevnice (hladiny):

$$\begin{aligned} F(\mathbf{x}) &= c \\ \frac{1}{2}(25x^2 + 16y^2) - 25x - 8y &= c \\ 25x^2 + 16y^2 - 50x - 16y &= 2c \\ 25(x-1)^2 + 16(y-\frac{1}{2})^2 &= 2c + 29 \end{aligned}$$

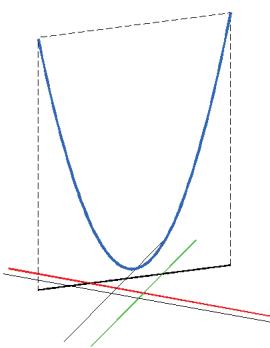
např. pro $c = \frac{371}{2}$:

$$\frac{(x-1)^2}{4^2} + \frac{(y-\frac{1}{2})^2}{5^2} = \frac{2c+29}{400} = 1$$



Řezy svislou rovinou $y = px + q$

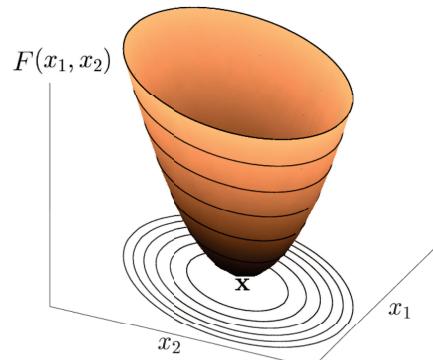
$$\begin{aligned} F(\mathbf{x}) &= \frac{1}{2}(25x^2 + 16y^2) - 25x - 8y = \frac{1}{2}(25x^2 + 16(px+q)^2) - 25x - 8(px+q) = \\ &= \frac{1}{2}(25x^2 + 16(p^2x^2 + 2pxq + q^2)) - 25x - 8(px+q) = \\ &= (\underbrace{\frac{25}{2} + \frac{16}{2}p^2}_{>0})x^2 + (16pq - 25 - 8p)x + 8q^2 - 8q \end{aligned}$$


Princip

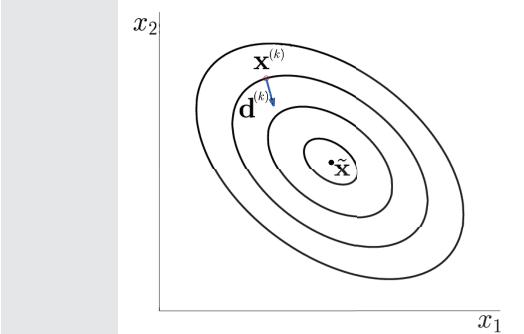
Stejně jako u každé iteracní metody nejprve zvolíme počáteční approximaci řešení $\mathbf{x}^{(0)}$.

Princip gradientních metod spočívá v tom, že zvolíme směr a v tomto směru se budeme chtít co nejvíce přiblížit k přesnému řešení. Gradientní metoda je tedy určena volbou směrů, ve kterých minimalizujeme funkci F .

Během jedné iterace se pohybujeme po povrchu grafu funkce $F(\mathbf{x})$ tak, abychom se dostali na nižší vrstevnici.



V případě soustavy dvou rovnic získáme promítnutím grafu funkce $F(\mathbf{x})$ do roviny proměnných x_1, x_2 systém soustředných elips - hladin (vrstevnic).


Metoda největšího spádu

Metodu největšího spádu získáme, pokud budeme za směrové vektory volit směry největšího spádu, tj. vektory

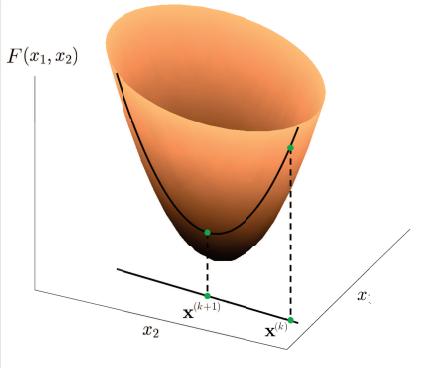
$$\mathbf{d}^{(k)} = -\text{grad } F(\mathbf{x}^{(k)}) = \mathbf{b} - \mathbf{A}\mathbf{x}^{(k)}$$

Iterační formuli volíme ve tvaru

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \mathbf{t}^{(k)} \cdot \mathbf{d}^{(k)}$$

v každém kroku metody určíme směr největšího spádu $\mathbf{d}^{(k)}$ a provedeme jednorozměrnou minimalizaci v tomto směru, tj.

$$\min_{t \geq 0} F(\mathbf{x}^{(k)} + t \mathbf{d}^{(k)}).$$



Minimalizovanou funkci proměnné t označíme $\Psi(t)$.

Potom platí:

$$\begin{aligned} \underbrace{F(\mathbf{x}^{(k)} + t \mathbf{d}^{(k)})}_{\Psi(t)} &= \frac{1}{2} (\mathbf{x}^{(k)} + t \mathbf{d}^{(k)})^T \mathbf{A} (\mathbf{x}^{(k)} + t \mathbf{d}^{(k)}) - \mathbf{b}^T (\mathbf{x}^{(k)} + t \mathbf{d}^{(k)}) = \\ &= \frac{1}{2} \mathbf{x}^{(k)T} \mathbf{A} \mathbf{x}^{(k)} + \frac{1}{2} t \mathbf{x}^{(k)T} \mathbf{A} \mathbf{d}^{(k)} + \frac{1}{2} t \mathbf{d}^{(k)T} \mathbf{A} \mathbf{x}^{(k)} + \frac{1}{2} t^2 \mathbf{d}^{(k)T} \mathbf{A} \mathbf{d}^{(k)} - \mathbf{b}^T \mathbf{x}^{(k)} - t \mathbf{b}^T \mathbf{d}^{(k)} \\ \frac{d\Psi(t)}{dt} &= \frac{1}{2} \mathbf{x}^{(k)T} \mathbf{A} \mathbf{d}^{(k)} + \frac{1}{2} \mathbf{d}^{(k)T} \mathbf{A} \mathbf{x}^{(k)} + t \mathbf{d}^{(k)T} \mathbf{A} \mathbf{d}^{(k)} - \mathbf{b}^T \mathbf{d}^{(k)} \end{aligned}$$

Poznámka: První 2 členy, tj. $\mathbf{x}^{(k)T} \mathbf{A} \mathbf{d}^{(k)}$ a $\mathbf{d}^{(k)T} \mathbf{A} \mathbf{x}^{(k)}$ jsou skaláry a jsou si pro symetrickou matici \mathbf{A} rovny.

$$\mathbf{d}^{(k)T} \mathbf{A} \mathbf{x}^{(k)} = (\mathbf{d}^{(k)T} \mathbf{A} \mathbf{x}^{(k)})^T = (\mathbf{A} \mathbf{x}^{(k)T} \mathbf{d}^{(k)}) = \mathbf{x}^{(k)T} \mathbf{A}^T \mathbf{d}^{(k)}$$

$$\begin{aligned} \frac{d\Psi(t)}{dt} &= t \mathbf{d}^{(k)T} \mathbf{A} \mathbf{d}^{(k)} + \underbrace{\mathbf{x}^{(k)T} \mathbf{A} \mathbf{d}^{(k)} - \mathbf{b}^T \mathbf{d}^{(k)}}_{(\mathbf{x}^{(k)T} \mathbf{A} - \mathbf{b}^T) \mathbf{d}^{(k)}} \\ &\quad - \mathbf{d}^{(k)T} \mathbf{A} \mathbf{d}^{(k)} \\ \frac{d\Psi(t)}{dt} &= t \mathbf{d}^{(k)T} \mathbf{A} \mathbf{d}^{(k)} - \mathbf{d}^{(k)T} \mathbf{A} \mathbf{d}^{(k)} = 0 \\ \mathbf{t}^{(k)} &= \frac{\mathbf{d}^{(k)T} \mathbf{d}^{(k)}}{\mathbf{d}^{(k)T} \mathbf{A} \mathbf{d}^{(k)}} \end{aligned}$$

Poznámka:

Pokud by matice \mathbf{A} nesplňovala podmínu symetrie, jaký výsledek by nám dala metoda největšího spádu?

$$\text{grad } F(\mathbf{x}) = 0$$

$$\begin{aligned} \text{grad } F(\mathbf{x}) &= \text{grad } \left(\frac{1}{2} \mathbf{x}^T \mathbf{A} \mathbf{x} - \mathbf{b}^T \mathbf{x} \right) = \frac{1}{2} (\mathbf{x}^T \mathbf{A})^T + \frac{1}{2} \mathbf{A} \mathbf{x} - \mathbf{b} = \frac{1}{2} \mathbf{A}^T \mathbf{x} + \frac{1}{2} \mathbf{A} \mathbf{x} - \mathbf{b} = 0 \\ &\Rightarrow \boxed{\frac{1}{2} (\mathbf{A}^T + \mathbf{A}) \mathbf{x} = \mathbf{b}} \end{aligned}$$

Algoritmus metody největšího spádu

1. volba $\mathbf{x}^{(0)}, \varepsilon$
2. výpočet směru spádu $\mathbf{d}^{(k)} = \mathbf{b} - \mathbf{A}\mathbf{x}^{(k)}$
3. výpočet koeficientu $\mathbf{t}^{(k)} = \frac{\mathbf{d}^{(k)T} \mathbf{d}^{(k)}}{\mathbf{d}^{(k)T} \mathbf{A} \mathbf{d}^{(k)}}$
4. výpočet nové iterace $\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \mathbf{t}^{(k)} \mathbf{d}^{(k)}$
5. $k = k + 1$ a zpět na 2) pokud $\|\mathbf{x}^{(k+1)} - \mathbf{x}^{(k)}\| > \varepsilon$

Poznámka: Abychom ušetřili operace násobení matice a vektoru, určíme $\mathbf{d}^{(k+1)}$ takto:

$$\mathbf{d}^{(k+1)} = \mathbf{b} - \mathbf{A}\mathbf{x}^{(k+1)} = \mathbf{b} - \mathbf{A}(\mathbf{x}^{(k)} + \mathbf{t}^{(k)} \mathbf{d}^{(k)}) = \mathbf{d}^{(k)} - \mathbf{t}^{(k)} \underbrace{\mathbf{A} \mathbf{d}^{(k)}}_{(*)}$$

(*) toto se počítalo v kroku 3 v předchozí iteraci

Věta: Metoda největšího spádu konverguje (pro symetrickou, pozitivně definitní matici \mathbf{A}) pro libovolnou volbu počáteční approximace $\mathbf{x}^{(0)}$ k přesnému řešení soustavy $\mathbf{Ax} = \mathbf{b}$.

Důkaz:

Konvergenci dokážeme v normě $\|\cdot\|_\mathbf{A} = \sqrt{\mathbf{x}^T \mathbf{A} \mathbf{x}}$ (tzv. energetická norma).

$\|\cdot\|_\mathbf{A}$ je s euklidovskou normou $\|\cdot\|_2$ ekvivalentní, tj. z toho již plyne i konvergence v $\|\cdot\|_2 = \sqrt{\mathbf{x}^T \mathbf{x}}$

(Definice: $X \dots$ lineární prostor, $\|\cdot\|_1$ a $\|\cdot\|_2$... normy na X ;

$\|\cdot\|_1$ a $\|\cdot\|_2$ jsou ekvivalentní, existují-li čísla $c, C > 0$: $\forall \mathbf{x} \in X \quad c \|\mathbf{x}\|_1 \leq \|\mathbf{x}\|_2 \leq C \|\mathbf{x}\|_1$)

tj. má platit

$$c^2 \mathbf{x}^T \mathbf{x} \leq \mathbf{x}^T \mathbf{A} \mathbf{x} \leq C^2 \mathbf{x}^T \mathbf{x}$$

$$\mathbf{x}^T (\mathbf{C}^2 \mathbf{I}) \mathbf{x} \leq \mathbf{x}^T \mathbf{A} \mathbf{x} \leq \mathbf{x}^T (\mathbf{C}^2 \mathbf{I}) \mathbf{x}$$

platí pro $c = |\lambda_{\min}|, C = |\lambda_{\max}|$

\mathbf{x}^* ... přesné řešení $\mathbf{Ax} = \mathbf{b}$

$\mathbf{e}^{(k)} = \mathbf{x}^{(k)} - \mathbf{x}^* \dots$ chyba k -té iterace.

Odvodíme nejprve vztah pro energetickou normu chyby k -té iterace.

$$F(\mathbf{x}^{(k)}) - F(\mathbf{x}^*) = F(\mathbf{x}^* + \mathbf{e}^{(k)}) - F(\mathbf{x}^*) = \dots \quad (*)$$

Obecně pro 2 body $\mathbf{x}, \mathbf{x} + \mathbf{t}\mathbf{d}$ platí:

$$\begin{aligned} \mathbf{F}(\mathbf{x} + \mathbf{t}\mathbf{d}) - \mathbf{F}(\mathbf{x}) &= \frac{1}{2} (\mathbf{x} + \mathbf{t}\mathbf{d})^T \mathbf{A} (\mathbf{x} + \mathbf{t}\mathbf{d}) - \mathbf{b}^T (\mathbf{x} + \mathbf{t}\mathbf{d}) - \frac{1}{2} \mathbf{x}^T \mathbf{A} \mathbf{x} + \mathbf{b}^T \mathbf{x} = \\ &= t \mathbf{x}^T \mathbf{A} \mathbf{d} + \frac{1}{2} t^2 \mathbf{d}^T \mathbf{A} \mathbf{d} - t \mathbf{b}^T \mathbf{d} = \\ &= t \mathbf{d}^T (\mathbf{A} \mathbf{x} - \mathbf{b}) + \frac{1}{2} t^2 \mathbf{d}^T \mathbf{A} \mathbf{d} \end{aligned}$$

Pro nás případ $\mathbf{x} = \mathbf{x}^*, \mathbf{t} = 1, \mathbf{d} = \mathbf{e}^{(k)}$

$$\dots = F(\mathbf{x}^* + \mathbf{e}^{(k)}) - F(\mathbf{x}^*) = \frac{1}{2} \mathbf{e}^{(k)T} \mathbf{A} \mathbf{e}^{(k)} = \|\mathbf{e}^{(k)}\|_\mathbf{A}^2 \quad (**)$$

$(*) + (**)$ \Rightarrow

$$\boxed{F(\mathbf{x}^{(k)}) - F(\mathbf{x}^*) = \frac{1}{2} \mathbf{e}^{(k)T} \mathbf{A} \mathbf{e}^{(k)}} \quad (***)$$

$(***) \Rightarrow$

$$F(\mathbf{x}^{(k+1)}) - F(\mathbf{x}^*) = \frac{1}{2} \mathbf{e}^{(k+1)T} \mathbf{A} \mathbf{e}^{(k+1)} \quad (****)$$

Odečtením (****) a (***)) dostaneme

$$\boxed{F(\mathbf{x}^{(k+1)}) - F(\mathbf{x}^k) = \frac{1}{2} \mathbf{e}^{(k+1)T} \mathbf{A} \mathbf{e}^{(k+1)} - \frac{1}{2} \mathbf{e}^{(k)T} \mathbf{A} \mathbf{e}^{(k)}} \quad (\clubsuit)$$

kde iterace $\mathbf{x}^{(k+1)}$ je vypočtena metodou největšího spádu, tj.

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \mathbf{t}^{(k)} \mathbf{r}^{(k)}.$$

Pro výraz na levé straně opět použijeme **zvýrazněný vztah** pro hodnoty $\mathbf{x} = \mathbf{x}^{(k)}, \mathbf{t} = \mathbf{t}^{(k)}, \mathbf{d} = \mathbf{r}^{(k)}$

$$\mathbf{F}(\mathbf{x}^{(k)} + \mathbf{t}^{(k)} \mathbf{r}^{(k)}) - \mathbf{F}(\mathbf{x}^{(k)}) = \mathbf{t}^{(k)} \mathbf{r}^{(k)T} \left(\underbrace{\mathbf{A} \mathbf{x}^{(k)} - \mathbf{b}}_{-\mathbf{r}^{(k)}} \right) + \frac{1}{2} \mathbf{t}^{(k)2} \mathbf{r}^{(k)T} \mathbf{A} \mathbf{r}^{(k)} =$$

($\mathbf{t}^{(k)}$) jsme počítali podle vztahu $\boxed{\mathbf{t}^{(k)} = \frac{\mathbf{r}^{(k)T} \mathbf{r}^{(k)}}{\mathbf{r}^{(k)T} \mathbf{A} \mathbf{r}^{(k)}}}$)

$$= -\frac{(\mathbf{r}^{(k)T} \mathbf{r}^{(k)})^2}{\mathbf{r}^{(k)T} \mathbf{A} \mathbf{r}^{(k)}} + \frac{1}{2} \frac{(\mathbf{r}^{(k)T} \mathbf{r}^{(k)})^2}{(\mathbf{r}^{(k)T} \mathbf{A} \mathbf{r}^{(k)})^2} \mathbf{r}^{(k)T} \mathbf{A} \mathbf{r}^{(k)} = -\frac{1}{2} \frac{(\mathbf{r}^{(k)T} \mathbf{r}^{(k)})^2}{\mathbf{r}^{(k)T} \mathbf{A} \mathbf{r}^{(k)}} \quad (\spadesuit)$$

Porovnání (\clubsuit) a (\spadesuit) dostaneme

$$\boxed{-\frac{1}{2} \frac{(\mathbf{r}^{(k)T} \mathbf{r}^{(k)})^2}{\mathbf{r}^{(k)T} \mathbf{A} \mathbf{r}^{(k)}} = \frac{1}{2} \mathbf{e}^{(k+1)T} \mathbf{A} \mathbf{e}^{(k+1)} - \frac{1}{2} \mathbf{e}^{(k)T} \mathbf{A} \mathbf{e}^{(k)}} \quad (\heartsuit)$$

Nyní poslední rovnici

a) vynásobíme 2

b) poslední člen převědeme na druhou stranu

c) a vydelíme jím rovnici

Dostaneme

$$\boxed{\frac{\mathbf{e}^{(k+1)T} \mathbf{A} \mathbf{e}^{(k+1)}}{\mathbf{e}^{(k)T} \mathbf{A} \mathbf{e}^{(k)}} = 1 - \frac{(\mathbf{r}^{(k)T} \mathbf{r}^{(k)})^2}{\mathbf{r}^{(k)T} \mathbf{A} \mathbf{r}^{(k)} \mathbf{e}^{(k)T} \mathbf{A} \mathbf{e}^{(k)}}} \quad (\diamondsuit)$$

Plati $\boxed{\mathbf{A} \mathbf{e}^{(k)} = \mathbf{r}^{(k)}}$, protože $\mathbf{A} \mathbf{x}^* - \mathbf{b} = 0$ a $\mathbf{r}^{(k)} = \mathbf{b} - \mathbf{A} \mathbf{x}^{(k)}$

$$\mathbf{r}^{(k)} = \mathbf{b} \underbrace{\mathbf{A} \mathbf{x}^{(k)} + \mathbf{A} \mathbf{x}^* - \mathbf{b}}_{\mathbf{A}(\mathbf{x}^* - \mathbf{x}^{(k)})} \quad \mathbf{e}^{(k)}$$

Dále z $\boxed{\mathbf{A} \mathbf{e}^{(k)} = \mathbf{r}^{(k)}}$ plyne $\mathbf{e}^{(k)} = \mathbf{A}^{-1} \mathbf{r}^{(k)}$ a tedy odhad

$$\|\mathbf{e}^{(k)}\| \leq \|\mathbf{A}^{-1}\| * \|\mathbf{r}^{(k)}\|$$

Pro (\diamondsuit) dostáváme odhad:

$$\frac{\mathbf{e}^{(k+1)T} \mathbf{A} \mathbf{e}^{(k+1)}}{\mathbf{e}^{(k)T} \mathbf{A} \mathbf{e}^{(k)}} \leq 1 - \frac{\|\mathbf{r}^{(k)}\|^4}{\|\mathbf{A}\| \cdot \|\mathbf{r}^{(k)}\|^2 \cdot \|\mathbf{A}^{-1}\| \cdot \|\mathbf{r}^{(k)}\|^2} = 1 - \frac{1}{\|\mathbf{A}\| \cdot \|\mathbf{A}^{-1}\|} = \mathbf{q} < 1$$

Tj.

$$\boxed{\mathbf{e}^{(k+1)T} \mathbf{A} \mathbf{e}^{(k+1)} \leq \mathbf{q} \mathbf{e}^{(k)T} \mathbf{A} \mathbf{e}^{(k)} \quad \forall k.} \quad (\clubsuit)$$

$$\mathbf{e}^{(k+1)T} \mathbf{A} \mathbf{e}^{(k+1)} \leq \mathbf{q} \mathbf{e}^{(k)T} \mathbf{A} \mathbf{e}^{(k)} \quad \forall k$$

Důkaz:

Jde o to odhadnout q v (■).

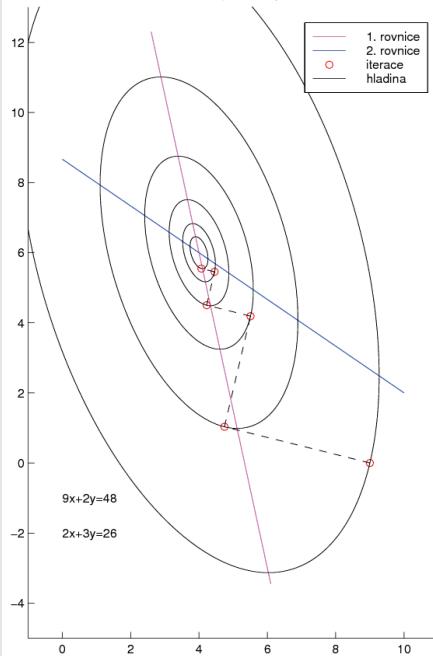
$$\|e^{(k+1)}\|_A^2 \leq q \|e^{(k)}\|_A^2 \quad \Rightarrow \quad \|e^{(k)}\|_A^2 \leq q^k \|e^{(0)}\|_A^2$$

$$q = 1 - \frac{1}{\|A\| \cdot \|A^{-1}\|} = 1 - \frac{1}{\kappa(A)} = \frac{\kappa(A) - 1}{\kappa(A)} \leq \sqrt{\frac{\kappa(A) - 1}{\kappa(A) + 1}}$$

$$= \frac{\kappa(A) - 1}{\lambda_{\max}} = \frac{1}{\lambda_{\min}}$$

Důkaz poslední nerovnosti:

$$\begin{aligned} \frac{(\kappa(A) - 1)^2}{\kappa^2(A)} &\leq \frac{\kappa(A) - 1}{\kappa(A) + 1} \quad / : (\kappa(A) - 1) \\ \frac{\kappa(A) - 1}{\kappa^2(A)} &\leq \frac{1}{\kappa(A) + 1} \quad / \cdot \kappa^2(A)(\kappa(A) + 1) \\ \kappa^2(A) - 1 &\leq \kappa^2(A) \quad \dots OK \end{aligned}$$

Geometrický význam metody největšího spádu
Metoda největšího spádu

Vlastnost rezidui

Všimněme si faktu, že vždy po sobě jdoucí iterace směru spádu, tj. $d^{(k)}$ a $d^{(k+1)}$ jsou na sebe kolmé.

Cvičení: Ukažte, že platí $d^{(k)T} d^{(k+1)} = 0$.

$$\begin{aligned} d^{(k)T} d^{(k+1)} &= d^{(k)T} (b - Ax^{(k+1)}) = \\ &= d^{(k)T} (b - A(x^{(k)} + t^{(k)}d^{(k)})) = \\ &= d^{(k)T} (b - Ax^{(k)} - t^{(k)}A d^{(k)}) = \\ &= d^{(k)T} (d^{(k)} - t^{(k)}A d^{(k)}) = \\ &= d^{(k)T} d^{(k)} - t^{(k)}d^{(k)}d^{(k)T} A d^{(k)} = \\ &= d^{(k)T} d^{(k)} - \frac{d^{(k)T} d^{(k)}}{d^{(k)T} A d^{(k)}} d^{(k)T} A d^{(k)} = \\ &= d^{(k)T} d^{(k)} - d^{(k)T} d^{(k)} = 0 \end{aligned}$$

Poznámka:

V případě, že budou hladiny (elipsy) „velmi protáhlé“, bude obecně metoda největšího spádu konvergovat velmi pomalu, nastane tzv. **cik-cak efekt**.

Na druhou stranu, pokud budou hladiny (elipsy) „skoro kružnice“, bude metoda největšího spádu konvergovat velmi rychle.

Nevýhodu cik-cak efektu odstraní nová metoda, tzv. **metoda sdržených gradientů**, která využívá důmyslnější volby směrů minimalizace, a sice tak, aby se neopakovali, jak k tomu docházelo u metody největšího spádu.

Příklad 1 - pokračování

Uvažovali jsme jednoduchou soustavu $Ax = b$, kde

$$A = \begin{bmatrix} 25 & 0 \\ 0 & 16 \end{bmatrix}, \quad b = \begin{bmatrix} 25 \\ 8 \end{bmatrix}, \quad x^* = \begin{bmatrix} 1 \\ 0,5 \end{bmatrix}.$$

Jedna z vrstevnic měla tvar

$$\frac{(x-1)^2}{4^2} + \frac{(y-\frac{1}{2})^2}{2^2} = 1$$

poměr poloos:

$$\sqrt{\lambda_2} = \sqrt{16} \rightarrow 4 : 5 \leftarrow \sqrt{25} = \sqrt{1}$$

$$\sqrt{\lambda_2} : \sqrt{\lambda_1}$$

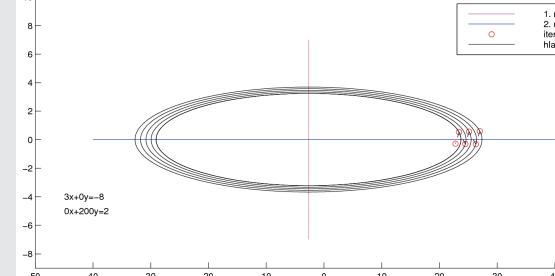
Poznámka:

- Pro případ $\lambda_2 \gg \lambda_1$ získáme protáhlé elipsy
- Pro případ $\lambda_2 \approx \lambda_1$ získáme skoro kružnice

Příklad 2

Pomocí metody největšího spádu řešte soustavu $Ax = b$, kde

$$A = \begin{bmatrix} 3 & 0 \\ 0 & 200 \end{bmatrix}, \quad b = \begin{bmatrix} -8 \\ 2 \end{bmatrix}, \quad \text{počáteční iterace } x^{(0)} = \begin{bmatrix} 27 \\ 0,6 \end{bmatrix}.$$

Metoda největšího spádu


vlastní čísla matice A:

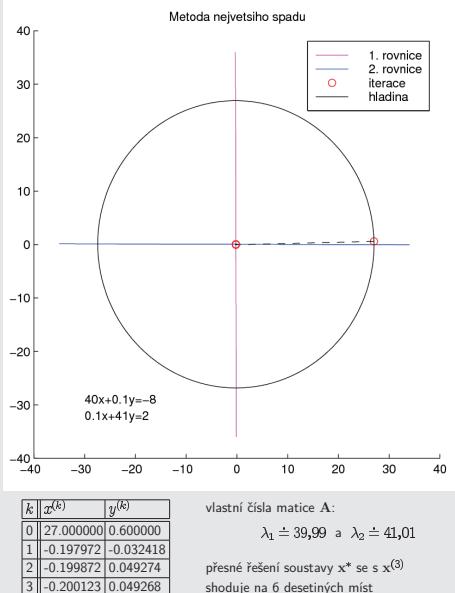
$$\lambda_1 = 3 \quad \text{a} \quad \lambda_2 = 200$$

$$\text{přesné řešení soustavy je } x^* = \begin{bmatrix} -8 \\ \frac{1}{100} \end{bmatrix}$$

Příklad 3

Pomocí metody největšího spádu řešte soustavu $Ax = b$, kde

$$A = \begin{bmatrix} 40 & 0,1 \\ 0,1 & 41 \end{bmatrix}, \quad b = \begin{bmatrix} -8 \\ 2 \end{bmatrix}, \quad \text{počáteční iterace } x^{(0)} = \begin{bmatrix} 27 \\ 0,6 \end{bmatrix}.$$



Poznámky k rychlosti konvergencie:

$$\|x^{(k)} - x^*\|_A = \left(\frac{\kappa(A) - 1}{\kappa(A) + 1}\right)^k \|x^{(0)} - x^*\|_A$$

- Je-li $\kappa(A) \gg 1$, tj. $\lambda_{\max} \gg \lambda_{\min}$, pak metoda největšího spádu konverguje pomalu
- $$\frac{\kappa(A) - 1}{\kappa(A) + 1} = \frac{\kappa(A) - 1 + 1 - 1}{\kappa(A) + 1} = 1 - \frac{2}{\kappa(A) + 1} \underset{\rightarrow \infty \text{ pro } \kappa(A) \rightarrow \infty}{\approx} 1$$
- Je-li $\kappa(A) \lesssim 1$, tj. $\lambda_{\max} \approx \lambda_{\min}$, pak metoda největšího spádu konverguje rychle

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

Script v MATLABu

```
function [vysledky_gs, vysledky_gm]=gs_gm(A,b,x0,iteraci);

%***** Porovnání Gauss-Seidelovy metody a
%***** gradientní metody, kde za směry volíme
%***** jednotkové vektory souřadných os
%***** 

n=size(A,1);

%***** Porovnání Gauss-Seidelova metoda
%***** Gradientní metoda
%***** 

x=x0;
vysledky_gs=x';
D=diag(diag(A)); L=tril(A)-D; U=triu(A)-D;
H=-(L+D)\b';
g=(L+D)\b;

for i=1:iteraci
    x=H*x'; 
    vysledky_gs=[vysledky_gs;x'];
end

%***** Gradientní metoda
%***** 

x=x0;
vysledky_gm=x';

for i=1:iteraci
    for j=1:n
        s=zeros(n,1);
        s(j)=1;
        r=A*x';
        t=(r'*s)/(s'*A*s);
        x=x+t*s;
    end;
    vysledky_gm=[vysledky_gm;x'];
end
```

$$\frac{\kappa(A) - 1}{\kappa(A) + 1} = 1 - \frac{2}{\kappa(A) + 1} \approx 0$$

- Pokud jsou vrstevnice sféry (v \mathbb{R}^2 kružnice), potom metoda největšího spádu naleze řešení (přesné) v jednom kroku.

Poznámka:

Směr, ve kterém provádíme minimalizaci v rámci jednoho kroku metody, můžeme volit i jinak než směr největšího spádu.

Obecně označme používané směry $s^{(k)}$.

Nouvou iteraci hledáme ve tvaru

$$x^{(k+1)} = x^{(k)} + t s^{(k)}$$

Koeficient t získáme z jednorozměrné minimalizace

$$\min_{t \geq 0} \frac{F(x^{(k)} + t s^{(k)})}{\Phi(t)}$$

$$\Phi(t) = \frac{1}{2} (x^{(k)} + t s^{(k)})^T A (x^{(k)} + t s^{(k)}) - b^T (x^{(k)} + t s^{(k)})$$

$$\frac{d\Phi(t)}{dt} = t s^{(k)}^T A s^{(k)} + \frac{x^{(k)T} A s^{(k)} - b^T s^{(k)}}{(x^{(k)T} A - b^T)} s^{(k)} = 0$$

$$\frac{(A x^{(k)} - b)^T}{(A x^{(k)} - b)^T} s^{(k)} = -r^{(k)} \quad (\text{reziendum})$$

$$t^{(k)} = \frac{r^{(k)T} s^{(k)}}{s^{(k)T} A s^{(k)}}$$

Volíme-li za vektory $s^{(k)}$ postupně jednotkové vektory souřadných os, získáme **Gauss-Seidelovu metodu** !!!

Pokud na vektor x aplikujeme 1 iteraci gradientní metody se směrovým vektorem $e_i = [0, \dots, 0, 1, 0, \dots, 0]^T$ (na i -té pozici 1, jinak 0), dostaneme:

$$x := x + \frac{r_i^T e_i}{e_i^T A e_i} e_i. \quad (\bullet)$$

Platí: $e_i^T A \dots i$ -tý řádek maticy A

$$e_i^T A e_i \dots \text{diagonální prvek } a_{ii} \text{ maticy } A$$

$$r = b - Ax \dots \text{reziendum}$$

$$r^T e_i = r_i \dots i$$
-tá složka vektoru r

$$r_i = b_i - \sum_{j=1}^n a_{ij} x_j$$

Vztah (•) zvětší i -tou složku vektoru x o hodnotu r_i , tj.

Úvaha

Při vhodné volbě směrových vektorů $s^{(k)}$ je možné dojít do přesného řešení za konečný počet kroků $\leq n$. Musí existovat n vektorů $s^{(k)}$ tak, že

$$x^* - x^{(0)} = \sum_{k=1}^n t^{(k)} s^{(k)} \quad (*)$$

Jak volit směry $s^{(k)}$?

- Zkusíme takto: nechť $s^{(k)}$ tvoří bázi (ortogonální) n -rozměrného euklidovského prostoru, potom vynásobením (*) skalárem s $s^{(k)}$ a úpravou získáme

$$s^{(k)T} (x^* - x^{(0)}) = t^{(k)} s^{(k)T} s^{(k)}$$

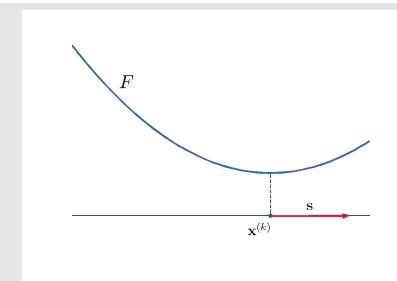
$$t^{(k)} = \frac{s^{(k)T} (x^* - x^{(0)})}{s^{(k)T} s^{(k)}} \dots \text{nešikovné !, obsahuje přesné řešení}$$

- je třeba zvolit lepší strategii volby vektorů $s^{(k)}$

Definice: $x^{(k)}$ je optimální vzhledem ke směru $s \neq 0$, jestliže

$$F(x^{(k)}) \leq F(x^{(k)} + ts) \quad \forall t \in \mathbb{R}$$

(*)



Poznámka: Je-li $x^{(k)}$ optimální vzhledem k libovolnému směru z vektorového prostoru V , říkáme, že je $x^{(k)}$ optimální vzhledem k V .

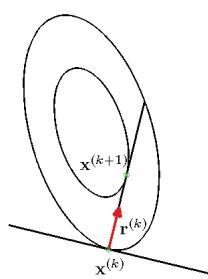
Podle (*) se minima nabývá pro $t = 0$, tzn. že derivaci F podle t je v minimu ($t = 0$) rovna 0:

$$\frac{\partial F}{\partial t} (x^{(k)} + ts) = ts^T A s + s^T (Ax^{(k)} - b)$$

$$\frac{\partial F}{\partial t}(x^{(k)}) = s^T \underbrace{(Ax^{(k)} - b)}_{= r^{(k)}} = 0$$

$$s \perp r^{(k)}$$

Poznámka: Iterace $x^{(k+1)}$ metody největšího spádu je optimální vzhledem k reziduu $r^{(k)} = b - Ax^{(k)}$... směry, ve kterých minimalizujeme.



Naším cílem je, aby se i v dalších iteracích zachovávala optimalita k již použitým směrům.

To pro metodu největšího spádu bohužel neplatí.

Např. pro soustavu ve $2D$ jsme ukažovali, že směry největšího spádu (rezidui) jsou na sebe kolmé,
tj. $r^{(k)} \perp r^{(k+1)}$ a $r^{(k+1)} \perp r^{(k+2)}$ $\Rightarrow [r^{(k)} \parallel r^{(k+2)}] !!!$

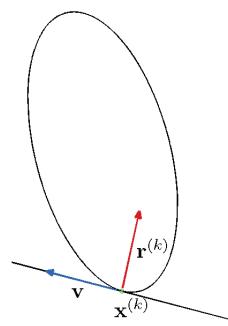
$\Rightarrow x^{(k+2)}$ je optimální vzhledem k $r^{(k+1)}$, ale již není optimální vzhledem k $r^{(k)}$

Existují směry, které udržují optimalitu k předchozím?

Nechť

$$x^{(k+1)} = x^{(k)} + s$$

Předpokládejme, že $x^{(k)}$ je optimální vzhledem k v (tj. $r^{(k)} \perp v$).



Chceme-li, aby bylo i $x^{(k+1)}$ optimální vzhledem k v , (tj. $r^{(k+1)} \perp v$), musí platit:

$$0 = v^T r^{(k+1)} = v^T (b - Ax^{(k+1)}) = v^T (b - A(x^{(k)} + s)) = v^T \left(\underbrace{b - Ax^{(k)}}_{r^{(k)}} - As \right) = v^T (r^{(k)} - As) = -v^T As$$

Závěr

Chceme-li zachovat optimalitu vzhledem ke všem použitým směrům, musí tyto směry splňovat podmínky tzv. **A-ortogonalitu**, tj. pro 2 různé směry s a v musí platit:
 $v^T As = 0$.

Poznámka: Vektorům které jsou **A-ortogonální** se také říká **A-sdružené**.

Metoda sdužených gradientů

Za směry, ve kterých minimalizujeme, budeme brát **A-ortogonální** vektory $s^{(k)}$.

Plati tedy:

$$s^{(k)T} A s^{(l)} = 0, \quad k \neq l.$$

Chceme, aby platilo:

$$s^{(k)T} A \cdot / \quad x^* - x^{(0)} = \sum_{k=1}^n t^{(k)} s^{(k)} \quad (*)$$

$$s^{(k)T} \underbrace{A(x^* - x^{(0)})}_{= 0} = t^{(k)} s^{(k)T} A s^{(k)}$$

$$Ax^* - Ax^{(0)} = \underbrace{Ax^{(0)} - b - Ax^{(0)}}_{= 0} + b$$

$$t^{(k)} = \frac{s^{(k)T} r^{(0)}}{s^{(k)T} A s^{(k)}}$$

Strategie volby směrů

- Máme-li **ortogonální** bázi \mathbb{R}^n , lze z ní procesem **A-ortogonalizace** získat **A-ortogonální** bázi.
 - Za ortogonální bázi budeme volit reziduové vektory.
- Aby proces ortogonalizace vedl k cíli, musíme zaručit, že reziduové vektory tvoří bázi.
Ortomatiku ukážeme vztahem: může se stát, že se některé reziduum anuluje.
Potom ovšem iteracní proces končí - dosáhl jste přesného řešení.
- Provádíme tedy současně 2 procesy:
 - iterační proces
 - proces **A-ortogonalizace**
 - Vektory rezidui budeme značit $r^{(k)}$, získané sdužené směry označíme $s^{(k)}$
 - pro zadání $x^{(0)}$ určíme $r^{(0)} = b - Ax^{(0)}$
 - $s^{(0)}$ položíme rovno $r^{(0)}$
 - určíme $x^{(1)}$ optimální vzhledem k $s^{(0)}$
 - určíme $r^{(1)}$
 - $s^{(1)}$ určujeme z $r^{(1)}$ tak, aby $s^{(1)T} As^{(0)} = 0$
 - atd.

Proces A-ortogonalizace

$$s^{(k)} = r^{(k)} + \sum_{i=1}^{k-1} \beta_{ki} s^{(i)} \quad (\bullet\bullet)$$

(Při určení $s^{(k)}$ vyjdeme z $r^{(k)}$. Přičítáme násobky předchozích $s^{(i)}$ tak, abychom zaručili **A-ortogonalitu**.)

Koeficienty β_{ki} volíme tak, aby

$$s^{(k)T} As^{(i)} = 0, \quad (i < k)$$

($\bullet\bullet$) vynásobíme $s^{(i)T} A \cdot /$

$$\underbrace{s^{(i)T} As^{(k)}}_{= 0} = s^{(i)T} Ar^{(k)} + \beta_{ki} s^{(i)T} As^{(i)}$$

$$\Rightarrow \beta_{ki} = -\frac{s^{(i)T} Ar^{(k)}}{s^{(i)T} As^{(i)}}$$

Z vlastnosti **A-ortogonality** vyplývá řada skutečností.

Věta 1 Platí

$$\begin{cases} r^{(k)T} s^{(j)} = r^{(0)T} s^{(j)} & k \leq j \\ r^{(k)T} s^{(j)} = 0 & k > j \end{cases}$$

Důkaz:

$$\begin{aligned} -b \cdot / \quad A \cdot / \quad x^{(k+1)} &= x^{(k)} + t^{(k)} s^{(k)} \\ \Rightarrow -r^{(k+1)} &= -r^{(k)} + t^{(k)} As^{(k)} \\ \Rightarrow r^{(k)} &= r^{(0)} - \sum_{j=1}^{k-1} t^{(j)} A s^{(j)} \end{aligned}$$

vynásobíme skalárně $s^{(j)}$

$$r^{(k)T} s^{(j)} = r^{(0)T} s^{(j)} - \underbrace{t^{(j)} s^{(j)T} A s^{(j)}}_{(*)}$$

(*) počítáme (viz dříve) takto

$$t^{(j)} = \frac{r^{(0)T} s^{(j)}}{s^{(j)T} As^{(j)}}$$

□

Důkaz:

$$\begin{aligned} \text{vztah } (\bullet\bullet) \text{ vynásobíme skalárně } s^{(j)} \\ s^{(k)} &= r^{(k)} + \sum_{i=1}^{k-1} \beta_{ki} s^{(i)} \\ \underbrace{s^{(j)T} As^{(k)}}_{= 0 \ (k < j)} &= s^{(j)T} Ar^{(k)} + \sum_{i=1}^{k-1} \beta_{ki} \underbrace{s^{(j)T} As^{(i)}}_{\neq 0 \ (k = j)} = 0 \ (k \leq j) \end{aligned} \quad (\bullet\bullet)$$

Důkaz:

Úplnou matematickou indukcí ukážeme, že $r^{(j)T} r^{(k)} = 0 \text{ pro } j > k$.

Plati

$$r^{(k+1)} = b - Ax^{(k+1)} = b - A(x^{(k)} + t^{(k)} r^{(k)}) = r^{(k)} - t^{(k)} Ar^{(k)}$$

1. $j=1 \Rightarrow k=0$

$$\begin{aligned} r^{(1)T} r^{(0)} &= (r^{(0)} + t^{(0)} A s^{(0)})^T r^{(0)} = r^{(0)T} r^{(0)} + t^{(0)} s^{(0)T} A r^{(0)} = r^{(0)T} r^{(0)} - \frac{r^{(0)T} s^{(0)}}{s^{(0)T} A s^{(0)}} s^{(0)T} A r^{(0)} = 0 \\ (r^{(0)} &= s^{(0)}) \end{aligned}$$

2. a) $\forall k < j$ platí: $r^{(j+1)^T} r^{(k)} = 0$

$$r^{(j+1)^T} r^{(k)} = (t^{(j)} + t^{(j)} A s^{(j)})^T r^{(k)} = \underbrace{t^{(j)^T} r^{(k)}}_{=0 \text{ (předpoklad)}} + t^{(j)} s^{(j)^T} A r^{(k)} = 0 \text{ (Věta 2)}$$

 b) $r^{(j+1)^T} r^{(j)} = 0$

$$\begin{aligned} r^{(j+1)^T} r^{(j)} &= (r^{(j)} + t^{(j)} A s^{(j)})^T r^{(j)} = r^{(j)^T} r^{(j)} + t^{(j)} s^{(j)^T} A r^{(j)} = \\ &\quad \underbrace{r^{(j)^T} r^{(j)}}_{s^{(j)^T} A s^{(j)} = s^{(j)^T} A r^{(j)}} - \underbrace{t^{(j)^T} s^{(j)}}_{r^{(j)^T} r^{(j)} = r^{(0)^T} s^{(j)}} \quad (\text{Věta 2}) \\ &\quad r^{(j)^T} r^{(j)} = r^{(0)^T} s^{(j)} \quad (\text{Věta 1}) \end{aligned}$$

□

Důkaz: Platí:

$$\beta_{ki} = -\frac{s^{(i)^T} A r^{(k)}}{s^{(i)^T} A s^{(i)}}$$

Pro čitatel platí:

$$s^{(i)^T} A r^{(k)} = r^{(k)^T} A s^{(i)} = r^{(k)^T} \frac{1}{t^{(i)}} (r^{(i+1)} - r^{(i)}),$$

kde se použil vztah

$$r^{(i+1)} = r^{(i)} + t^{(i)} A s^{(i)}, \quad t^{(i)} \neq 0 \text{ pro } r^{(i)} \neq 0$$

Platí

- pro $i < k-1$: čitatel $\beta_{ki} = r^{(k)^T} (r^{(i+1)} - r^{(i)}) \frac{1}{t^{(i)}} = 0$ (**Tvrzení**)

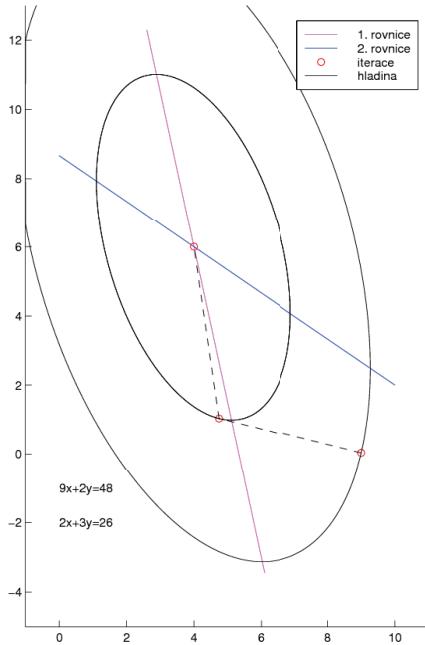
- pro $i = k-1$: čitatel $\beta_{k,k-1} = r^{(k)^T} (r^{(k)} - r^{(k-1)}) \frac{1}{t^{(k-1)}} = r^{(k)^T} r^{(k)} \frac{1}{t^{(k-1)}} \neq 0 \quad (\text{pro } r^{(k)} \neq 0)$

□

Algoritmus (Metoda sdružených gradientů)

- $x^{(0)}, \varepsilon$
- $r^{(0)} = b - A x^{(0)}, \quad s^{(0)} = r^{(0)}$
- $t^{(k)} = \frac{s^{(k)^T} r^{(k)}}{s^{(k)^T} A s^{(k)}}$
- $x^{(k+1)} = x^{(k)} + t^{(k)} s^{(k)}$
- $r^{(k+1)} = r^{(k)} + t^{(k)} A s^{(k)}$
- $\beta_k = -\frac{s^{(k)^T} A r^{(k+1)}}{s^{(k)^T} A s^{(k)}}$
- $s^{(k+1)} = r^{(k+1)} + \beta_k s^{(k)}$
- If $\|x^{(k+1)} - x^{(k)}\| < \varepsilon$ then konec else \rightarrow add 3

Metoda sdružených gradientů



k	$x^{(k)}$	$y^{(k)}$
0	9.0000	0
1	4.7425	1.0321
2	4.0000	6.0000

Poznámka: Gradientní metody patří mezi **nestacionární metody**.

např. pro metodu největšího spádu platí

$$x^{(k+1)} = x^{(k)} + t^{(k)} d^{(k)} = x^{(k)} + t^{(k)} (b - A x^{(k)}) = \underbrace{(1 - t^{(k)} A)}_{H^{(k)}} x^{(k)} + \underbrace{t^{(k)} b}_{g^{(k)}}$$

 V každém kroku se mění matica $H^{(k)}$.

 Platí-li $\|H^{(k)}\| \rightarrow 0$ (pro $k \rightarrow \infty$), dostaneme metody se **superlineární rychlostí konvergence**.

Věta Nechť A je symetrická pozitivně definitní. Potom metoda sdružených gradientů konverguje nejvýše po n krocích. Navíc chybá k -té iterace ($k < n$) je ortogonální na směry $s^{(j)}$, $j = 0, 1, \dots, k-1$ a platí:

$$\|x^{(k)} - x^*\|_A \leq \frac{2C^k}{1+C^k} \|x^{(0)} - x^*\|_A,$$

$$\text{kde } C = \frac{\sqrt{\kappa(A)} - 1}{\sqrt{\kappa(A)} + 1}, \quad \kappa(A) = \frac{\lambda_{\max}}{\lambda_{\min}}.$$

Poznámka: V metode největšího spádu vystupuje ve vztahu pro chybu k -té iterace koeficient

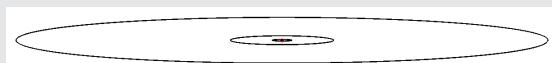
$$\left(\frac{\kappa(A) - 1}{\kappa(A) + 1} \right)^k.$$

 Je zřejmé, že na rychlosť konvergence má vliv číslo $\kappa(A)$, tj. λ_{\max} a λ_{\min} . Čím blíže je λ_{\max} a λ_{\min} , tím rychleji metody konvergují.

Příklad 4

 Řešte soustavu $\boxed{Ax = b}$, kde

$$A = \begin{bmatrix} 1 & 0 \\ 0 & 10000 \end{bmatrix}, \quad b = \begin{bmatrix} 1 \\ 10000 \end{bmatrix}, \quad \text{přesné řešení } x^* = \begin{bmatrix} 1 \\ 1 \end{bmatrix}.$$



- poměr poloelips je $\sqrt{10000} : \sqrt{1} = 100 : 1 !!!$

- $\kappa(A) = \frac{10000}{1} = 10000 \Rightarrow$ pomalá konvergence!

 Vezměme si matici $P^{-1} = \begin{bmatrix} 1 & 0 \\ 0 & \frac{1}{10000} \end{bmatrix}$ ($\det(P^{-1}) \neq 0$) a řešme soustavu

$$\boxed{P^{-1}Ax = P^{-1}b}$$



$$\begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

• $\kappa(P^{-1}A) = \frac{1}{\lambda} = 1 \Rightarrow$ rychlá konvergence (1. iterace). Mluvíme o tzv. **předpodmínování**.

Poznámka:

Chceme-li i novou (předpodmíněnou) soustavu řešit metodou sdružených gradientů, musí být její matice symetrická pozitivně definitní.

Místo matici $P^{-1}A$ vezmeme matici (podobnou A) $P^{-\frac{1}{2}}AP^{-\frac{1}{2}}$ (P ... symetrická pozitivně definitní) a řešíme soustavu

$$\begin{aligned} \bar{A}\bar{x} &= \bar{b} \\ \bar{A} = P^{-\frac{1}{2}}AP^{-\frac{1}{2}}, \quad \bar{x} &= P^{\frac{1}{2}}x, \quad \bar{b} = P^{-\frac{1}{2}}b \end{aligned}$$

Jak volit matici předpodmínění P ?

... řada možností, např. $P = \text{diag}(A)$

Příklad 5

Porovnejte vlastní čísla zadané matici A a matici získané pomocí diagonálního předpodmínění.

$$\begin{aligned} A &= \begin{bmatrix} 1000000 & 200 & 30 & 0 \\ 200 & 10000 & 40 & 0 \\ 30 & 40 & 100 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \\ P &= \begin{bmatrix} 1000000 & 0 & 0 & 0 \\ 0 & 10000 & 0 & 0 \\ 0 & 0 & 100 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \\ P^{-\frac{1}{2}} &= \begin{bmatrix} \frac{1}{\sqrt{1000000}} & 0 & 0 & 0 \\ 0 & \frac{1}{\sqrt{10000}} & 0 & 0 \\ 0 & 0 & \frac{1}{\sqrt{100}} & 0 \\ 0 & 0 & 0 & \frac{1}{\sqrt{1}} \end{bmatrix} = \begin{bmatrix} \frac{1}{1000} & 0 & 0 & 0 \\ 0 & \frac{1}{100} & 0 & 0 \\ 0 & 0 & \frac{1}{10} & 0 \\ 0 & 0 & 0 & \frac{1}{1} \end{bmatrix} \\ \bar{A} = P^{-\frac{1}{2}}AP^{-\frac{1}{2}} &= \begin{bmatrix} \frac{1}{1000} & 0 & 0 & 0 \\ 0 & \frac{1}{100} & 0 & 0 \\ 0 & 0 & \frac{1}{10} & 0 \\ 0 & 0 & 0 & \frac{1}{1} \end{bmatrix} \begin{bmatrix} 1000000 & 200 & 30 & 0 \\ 200 & 10000 & 40 & 0 \\ 30 & 40 & 100 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \frac{1}{1000} & 0 & 0 & 0 \\ 0 & \frac{1}{100} & 0 & 0 \\ 0 & 0 & \frac{1}{10} & 0 \\ 0 & 0 & 0 & \frac{1}{1} \end{bmatrix} = \\ &= \begin{bmatrix} 1 & 0.002 & 0.003 & 0 \\ 0.002 & 1 & 0.04 & 0 \\ 0.003 & 0.04 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \end{aligned}$$

vlastní čísla matici A:



$$\lambda_1 = 1; \quad \lambda_2 = 99,837534233; \quad \lambda_3 = 10000,121161153; \quad \lambda_4 = 1000000,041304614$$

$$\kappa(A) = \frac{1000000,041304614}{1} = 1000000,041304614$$

vlastní čísla matici $\bar{A} = P^{-\frac{1}{2}}AP^{-\frac{1}{2}}$:

$$\tilde{\lambda}_1 = 0,959987454937999; \quad \tilde{\lambda}_2 = 0,999702401514713; \quad \tilde{\lambda}_3 = 1; \quad \tilde{\lambda}_4 = 1,040310143547287$$

$$\kappa(\bar{A}) = \frac{1,040310143547287}{0,959987454937999} = 1,083670560689229$$



Kapitola 6. Vlastní čísla a vlastní vektory

Výpočet vlastních čísel a vlastních vektorů

S pojmem **vlastního čísla** jsme se již setkali například u iteračních metod pro řešení soustav lineárních algebraických rovnic. Velikosti vlastních čísel iterační matici rozhodovaly o konvergenci příslušné iterační metod. S úlohou na vlastní čísla se setkáme i v aplikacích při řešení řady technických a fyzikálních problémů.

Definice: Je dáná čtvercová matice A řádu n. Číslo λ , pro které má soustava

$$Av = \lambda v \quad \text{resp.} \quad (A - \lambda I)v = 0$$

nenulové řešení, se nazývá **vlastní číslo** matice A, jemu odpovídající nenulové řešení v **vlastní vektor** matice A.

Homogenní soustava má nenulové řešení \Leftrightarrow matice soustavy je singulární, tj. její determinant je nulový.

Vlastní čísla $\lambda_1, \lambda_2, \dots, \lambda_n$ jsou kořeny **charakteristické rovnice**

$$p_A(\lambda) = \det(A - \lambda I) = 0.$$

Ke každému vlastnímu číslu λ_i existuje alespoň jeden vlastní vektor v_i .

Poznámka: Charakteristický polynom je stupně n $\Rightarrow \exists n$ vlastních čísel.

Definice: Matici $\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_n)$ nazýváme **spektrální matici** matice A.

Úlohy na nalezení vlastních čísel rozdělíme do dvou skupin:

• **Úplný problém** – úloha najít všechna vlastní čísla

• **Cástečný problém** – úloha najít pouze některá vl. čísla (obvykle s největší absolutní hodnotou)

Úlohu na vlastní čísla si připomeneme na příkladu.

Příklad 1

Stanovte taková čísla λ , pro která má homogenní soustava $Av = \lambda v$ nenulové řešení, dále určete toto řešení, pro matici

$$A = \begin{bmatrix} 2 & 0 & 0 \\ 2 & 2 & 1 \\ 1 & 1 & 2 \end{bmatrix}.$$



Řešíme tedy soustavu

$$(A - \lambda I)v = \begin{bmatrix} 2 - \lambda & 0 & 0 \\ 2 & 2 - \lambda & 1 \\ 1 & 1 & 2 - \lambda \end{bmatrix} \begin{bmatrix} v_1 \\ v_2 \\ v_3 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}.$$

Aby homogenní soustava měla nenulové řešení, musí být determinant soustavy nulový. Hledáme proto taková λ , aby

$$\det(A - \lambda I) = (2 - \lambda)^3 - (2 - \lambda) = (2 - \lambda)[(2 - \lambda)^2 - 1] = (2 - \lambda)(1 - \lambda)(3 - \lambda) = 0.$$

Dostali jsme algebrickou rovnici stupně 3 a pouze pro její kořeny

$$\lambda_1 = 3, \quad \lambda_2 = 2, \quad \lambda_3 = 1$$

bude mít uvažovaná soustava nenulové řešení.

Ke každému vlastnímu číslu λ_k můžeme najít nenulové řešení homogenní soustavy

$$(A - \lambda_k I)v = 0.$$

Např. pro $\lambda_1 = 3$ řešíme soustavu

$$\begin{bmatrix} -1 & 0 & 0 \\ 2 & -1 & 1 \\ 1 & 1 & -1 \end{bmatrix} \begin{bmatrix} v_1 \\ v_2 \\ v_3 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}.$$

Matici soustavy je samozřejmě singulární a proto bude existovat celý systém řešení v závislosti na parametru $r \in \mathbb{R}$. Každý vektor $[0, r, r]^T$ řeší danou soustavu. Ze systému vybereme jednoho zástupce, např. $v^{(1)} = [0, 1, 1]^T$, a říkáme, že $v^{(1)}$ je **vlastní vektor** odpovídající vlastnímu číslu λ_1 . Podobně bychom nalezli vlastní vektor odpovídající vlastním čísly λ_2 a λ_3 .

Poznámka:

Vlastní čísla (horní) trojúhelníkové matice jsou rovna jejím diagonálním prvkům, neboť charakteristický polynom má tvar:

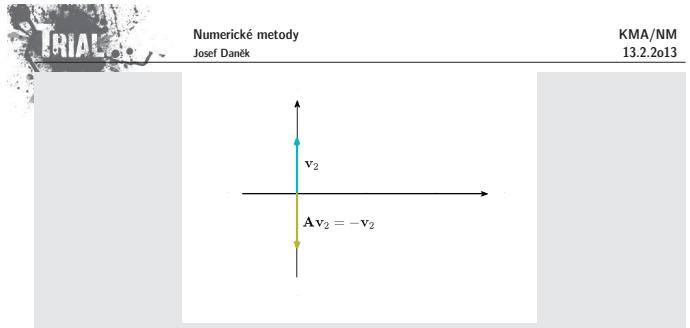
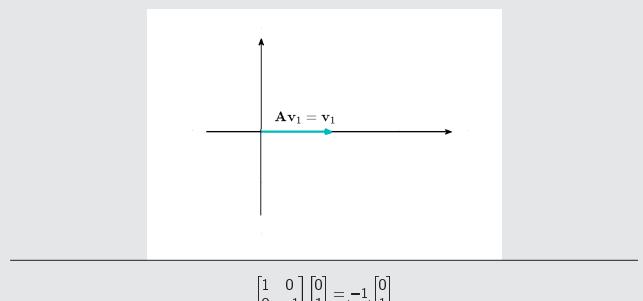
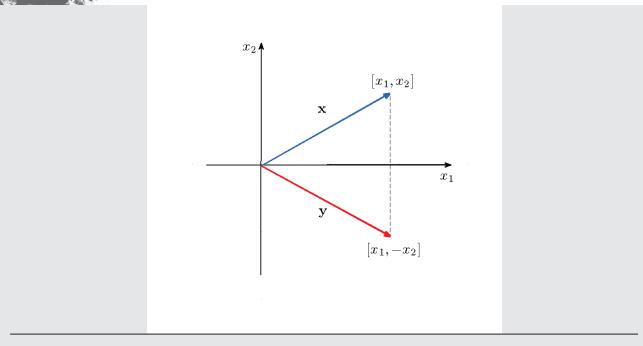
$$p_A(\lambda) = (a_{11} - \lambda)(a_{22} - \lambda) \dots (a_{nn} - \lambda).$$

Motivace

Vlastní vektor je takový vektor, pro který platí, že vynásobíme-li matici A s tímto vektorem, získáme násobek původního vektoru. Mluvíme o **samodružných prvcích**.

Příklad: Osová souměrnost = zobrazení $y = Ax$.

$$\begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$



Příklad: Určete vlastní čísla a vlastní vektory těchto matic:

$$A = \begin{bmatrix} 2 & 0 & 0 \\ 0 & 2 & 0 \\ 0 & 0 & 2 \end{bmatrix}, \quad B = \begin{bmatrix} 2 & 1 & 0 \\ 0 & 2 & 0 \\ 0 & 0 & 2 \end{bmatrix},$$

$$C = \begin{bmatrix} 2 & 0 & 0 \\ 0 & 2 & 1 \\ 0 & 0 & 2 \end{bmatrix}, \quad D = \begin{bmatrix} 2 & 1 & 0 \\ 0 & 2 & 1 \\ 0 & 0 & 2 \end{bmatrix}.$$

Řešení: Všechny zadané matice mají stejný charakteristický polynom

$$p_A(\lambda) = p_B(\lambda) = p_C(\lambda) = p_D(\lambda) = (2 - \lambda)^3,$$

Vidíme, že $\lambda = 2$ je trojnásobné vl. číslo všech čtyř matic.

Vlastní vektory:

$$A: v^{(1)} = [1, 0, 0]^T$$

$$v^{(2)} = [0, 1, 0]^T$$

$$v^{(3)} = [0, 0, 1]^T$$

Pozn.: matice $A - \lambda I$ je nulová, tj. systém všech řešení rovnice $A - \lambda I = 0$ je lin. kombinací $v^{(1)}, v^{(2)}, v^{(3)}$.

$$B: v^{(1)} = [1, 0, 0]^T$$

$$v^{(3)} = [0, 0, 1]^T$$

Pozn.: $B - \lambda I = \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}$

$$C: v^{(1)} = [1, 0, 0]^T$$

$$v^{(2)} = [0, 1, 0]^T$$

Pozn.: $C - \lambda I = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 1 \\ 0 & 0 & 0 \end{bmatrix}$

$$D: v^{(1)} = [1, 0, 0]^T$$

Pozn.: $D - \lambda I = \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ 0 & 0 & 0 \end{bmatrix}$

Poznámka: Počet lineárně nezávislých vlastních vektorů může být menší než je řád matice.

Připomeňme si některé poznatky z lineární algebry.

Definice: Říkáme, že matice A a B jsou podobné, existuje-li regulární matice P taková, že $P^{-1}AP = B$, resp. $A = PBP^{-1}$

Věta Podobné matice mají stejná vlastní čísla.

Věta: Nechť A je reálná symetrická matice. Potom existuje ortogonální matice Q taková, že pro spektrální matici platí

$$\Lambda = Q^T A Q$$

Důkaz:

$$\det(A - \lambda I) = \det(A - \lambda I) \cdot \frac{\det(P)}{\det(P)} = \det(P^{-1}) \cdot \det(A - \lambda I) \cdot \det(P) = \det(P^{-1}(A - \lambda I)P) = \det\left(\frac{P^{-1}AP - \lambda I}{B}\right)$$

□

Věta Je-li v vlastní vektor matice A , potom $P^{-1}v$ je vlastní vektor matice $B = P^{-1}AP$.

Důkaz:

$$Av = \lambda v$$

$$P^{-1} \cdot / \quad PBP^{-1}v = \lambda v$$

$$B \frac{P^{-1}v}{w} = \lambda \frac{P^{-1}v}{w}$$

□

Poznámka: Pokud jsou vlastní vektory v_1, v_2, \dots, v_n lineárně nezávislé, potom platí:

$$X^{-1}AX = \Lambda \quad (\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_n) \text{ ... spektrální matice})$$

Matice A je tedy podobná diagonální matici. Matice X je matice, jejíž sloupce tvoří vlastní vektory

$$AX = X\Lambda$$

$$A \cdot \underbrace{\begin{bmatrix} v_1 & v_2 & \dots & v_n \end{bmatrix}}_X = \underbrace{\begin{bmatrix} v_1 & v_2 & \dots & v_n \end{bmatrix}}_X \cdot \underbrace{\begin{bmatrix} \lambda_1 & & & \\ & \lambda_2 & & \\ & & \ddots & \\ & & & \lambda_n \end{bmatrix}}_A$$

$$\left[\begin{array}{c} \lambda_1 v_1 \\ \lambda_2 v_2 \\ \vdots \\ \lambda_n v_n \end{array} \right]$$

Věta Nechť A je čtvercová matice řádu n , λ její vlastní číslo a v její vlastní vektor, tj. $Av = \lambda v$. Potom platí:

$$(i) k \in \mathbb{N} \quad \lambda(A^k) = [\lambda(A)]^k$$

$$(ii) A \dots \text{regulární} \Rightarrow \lambda(A^{-1}) = [\lambda(A)]^{-1}$$

$$(iii) \lambda(A^H) = \overline{\lambda(A)}$$

(iv) vlastní čísla symetrické (hermitovské) matic jsou reálná

(v) vlastní vektory symetrické matice odpovídající různým vlastním číslům jsou ortogonální

(vi) symetrická pozitivně definitní matice má všechna vlastní čísla kladná

Důkaz:

$$(i) \quad A \cdot / \quad Av = \lambda v \Rightarrow A^2v = \lambda \frac{Av}{\lambda} = \lambda^2v$$

$$A \cdot / \quad A^k v = \lambda^k v \Rightarrow A^{k+1}v = \lambda^k \frac{Av}{\lambda} = \lambda^{k+1}v$$

□

$$(ii) \quad Av = \lambda v \Rightarrow A^{-1}Av = \lambda A^{-1}v$$

$$v = \lambda A^{-1}v \quad / \cdot \frac{1}{\lambda}$$

$$\frac{1}{\lambda}v = A^{-1}v$$

$$(iii) \text{ Označme } B = A - \lambda I. \quad \text{Platí} \quad \det B^H = \overline{\det B^T} = \overline{\det B}$$

$$\det(A^H - \bar{\lambda}I) = \overline{\det(A - \lambda I)} = 0$$

(iv) $A = A^H, \quad Av = \lambda v$

$$\lambda v^H v = v^H (\lambda v) = v^H A v = \underbrace{v^H A^H v}_{\text{číslo}} = \overline{(v^H A^H v)^H} = \overline{v^H} \underbrace{\overline{A} v}_{\overline{\lambda} v} = \overline{\lambda} v^H v \quad (*)$$

přidáme H a

$$v^H v \quad (*) \quad (\overline{v^H v})^H = v^H v \quad \Rightarrow \quad \overline{v^H v} =$$

(v)

$$\left. \begin{array}{l} u^H \cdot / \quad Av = \lambda v \\ v^H \cdot / \quad Au = \mu u \end{array} \right\} \quad \lambda \neq \mu; \quad \lambda = \bar{\lambda}, \quad \mu = \bar{\mu}, \quad A = A^H$$

$$\begin{aligned} u^H A v &= \lambda u^H v \\ v^H A u &= \mu v^H u \\ u^H A^H v &= \mu u^H v \end{aligned}$$

$$0 = (\underbrace{\lambda - \mu}_{\neq 0}) u^H v \quad \Rightarrow \quad \boxed{u^H v = 0}$$

(vi)

$$\begin{aligned} Av &= \lambda v \\ v^T A v &= \lambda v^T v \end{aligned}$$

Platí (pro pozitivně definitní matici A):

$$\forall v \neq 0: \quad v^T A v > 0 \quad \Rightarrow \quad \lambda \underbrace{v^T v}_{>0} > 0 \quad \Rightarrow \quad \boxed{\lambda > 0}$$

- Pro symetrickou matici je $\alpha_k = 0 \Rightarrow \lambda_k = 1$
 $|\lambda_k(\varepsilon) - \lambda_k| \leq \varepsilon \dots \Rightarrow$ dobré podmíněná úloha
- Pro nesymetrickou matici je $\alpha_k \neq 0 \Rightarrow \lambda_k$ může být velmi velké
 $\dots \Rightarrow$ špatně podmíněná úloha

Příklad

script v MATLABu

```
A=[-1 5 0; 0 3 1; 0 0 2]
AH=ctranspose(A)

[v,c]=eig(A,'nobalance')
[vH,cH]=eig(AH,'nobalance')

disp('-----')
disp(' Vlastní vektory A a AH odpovídající vlastnímu číslu lambda,')
disp(' cos uhlu, který svirají k tento uhlu')
for j=1:length(A)
    disp('-----')
    lambda=c(j,j)
    vlastni_vektor_A=v(:,j),
    vlastni_vektor_AH=vH(:,j)'
    cosinus_uhlu=vlastni_vektor_A*vlastni_vektor_AH'...
        /norm(vlastni_vektor_A)/norm(vlastni_vektor_AH)
    uhel=acos(cosinus_uhlu);
    uhel=uhel*180/pi
    pause
end;
```

výsledky v MATLABu

 Poznámka: Ortogonální matice Q: $Q^T Q = I$ / $\cdot Q^{-1}$ $Q^T = Q^{-1}$
Podmíněnost úlohy na vlastní čísla

Omezíme se na případ, kdy matica A má n lineárně nezávislých vlastních vektorů v_1, v_2, \dots, v_n odpovídajících vlastním číslům $\lambda_1, \lambda_2, \dots, \lambda_n$.

- $\Delta a_{ij} \dots$ malé změny v prvcích a_{ij} $|\Delta a_{ij}| \leq \varepsilon$
- porušená matici $A(\varepsilon) = A + \Delta A$ má vlastní čísla $\lambda_k(\varepsilon) = \lambda_k + \Delta \lambda_k$
- dále platí (viz literatura):

$$|\lambda_k(\varepsilon) - \lambda_k| \lesssim \kappa_k \varepsilon, \quad \text{kde } \kappa_k = \frac{1}{|\cos \alpha_k|}$$

kde α_k je úhel v_k a vlastního vektoru A^H odpovídajícímu vlastnímu číslu λ_k

```
A =
-1 5 0
0 3 1
0 0 2

AH =
-1 0 0
5 3 0
0 1 2

v =
1.0000 1.0000 -1.0000
0 0.8000 -0.6000
0 0 0.6000

c =
-1 0 0
0 3 0
0 0 2

vH =
-0.8000 0.0000 -0.0000
1.0000 -1.0000 0.0000
-0.3333 -1.0000 1.0000

cH =
-1.0000 0 0
0 3.0000 0
0 0 2.0000
```

Vlastní vektory A a AH odpovídají vlastnímu číslu lambda, cos uhlu, který svirají k tento uhlu

```
lambda =
-1
vlastni_vektor_A =
1 0 0
vlastni_vektor_AH =
-0.8000 1.0000 -0.3333
cosinus_uhlu =
-0.6046
uhel =
127.1966

lambda =
3
vlastni_vektor_A =
1.0000 0.8000 0
vlastni_vektor_AH =
0.0000 -1.0000 -1.0000
cosinus_uhlu =
-0.4417
uhel =
116.2141

lambda =
2
vlastni_vektor_A =
-1.0000 -0.6000 0.6000
```

Příklad 2

$$A = \begin{bmatrix} 20 & 20 & 20 & 20 \\ 19 & 20 & & \\ 18 & & 20 & \\ & \ddots & \ddots & \ddots \\ & & \ddots & \ddots \\ & & & 2 & 20 \\ \varepsilon & & & & 1 \end{bmatrix}$$

Výpočet determinantu $(A - \lambda I)$ pomocí rozvoje podle posledního řádku:

$$p_A(\lambda) = \det(A - \lambda I) = (20 - \lambda)(19 - \lambda) \dots (1 - \lambda) - 20^{19} \varepsilon$$

• pro $\varepsilon = 0 \Rightarrow \lambda_{\min} = 1$

• pro $\varepsilon = 20! 20^{-19} \approx 4,64 \cdot 10^{-7}$

$$p_A(\lambda) = (20 - \lambda)(19 - \lambda) \dots (1 - \lambda) - 20^{19} 20! 20^{-19} = \lambda \cdot (\dots) = 0 \Rightarrow \lambda_{\min} = 0$$

• Malé změně ε odpovídá velká změna vlastního čísla λ_{\min} .

• Vlastní čísla nesymetrických matic jsou citlivá na změnu prvků (citlivost roste s rostoucí vzdáleností od diagonály).

Mocninová metoda

Chceme určit vlastní číslo matice A s největší absolutní hodnotou (dominantní vlastní číslo).

Předpoklady:

1. A má n-lineárně nezávislých vlastních vektorů

2. vlastní čísla lze seřadit: $|\lambda_1| > |\lambda_2| \geq |\lambda_3| \geq \dots \geq |\lambda_n|$.

Odvození:

1. Zvolíme $y^{(0)}$ jako lineární kombinaci vlastních vektorů

$$y^{(0)} = \alpha_1 v_1 + \alpha_2 v_2 + \dots + \alpha_n v_n.$$

2. Sestrojíme posloupnost

$$\begin{aligned} y^{(k)} &= A y^{(k-1)}, \quad t.j. \quad y^{(k)} = A^k y^{(0)} \\ y^{(k)} &= \alpha_1 A^k v_1 + \alpha_2 A^k v_2 + \dots + \alpha_n A^k v_n. \end{aligned}$$

3. Platí $\mathbf{A}\mathbf{v}_i = \lambda_i \mathbf{v}_i$, proto

$$\mathbf{y}^{(k)} = \alpha_1 \underbrace{\lambda_1^k}_{*} \mathbf{v}_1 + \alpha_2 \lambda_2^k \mathbf{v}_2 + \cdots + \alpha_n \lambda_n^k \mathbf{v}_n.$$

4. Vytkneme dominantní vlastní číslo (viz *)

$$\mathbf{y}^{(k)} = \lambda_1^k \left[\alpha_1 \mathbf{v}_1 + \sum_{i=2}^n \alpha_i \underbrace{\left(\frac{\lambda_i}{\lambda_1} \right)^k}_{\varepsilon_k \rightarrow 0} \mathbf{v}_i \right].$$

5. Analogicky vyjádříme $\mathbf{y}^{(k+1)}$.

6. Vybereme j -tou složku $\mathbf{y}^{(k+1)}$ a $\mathbf{y}^{(k)}$, vydělíme je a provedeme limitní přechod

$$\lim_{k \rightarrow \infty} \frac{y_j^{(k+1)}}{y_j^{(k)}} = \lim_{k \rightarrow \infty} \frac{\lambda_1^{k+1} (\alpha_1 v_{1,j} + \underbrace{\varepsilon_{k+1,j}}_{\rightarrow 0})}{\lambda_1^k (\alpha_1 v_{1,j} + \underbrace{\varepsilon_{k,j}}_{\rightarrow 0})} = \lambda_1$$

Příklad

Mocninnou metodou stanovte dominantní vlastní číslo maticy A, kde

$$A = \begin{bmatrix} 1 & 1 & 0 \\ 1 & 1 & 1 \\ 0 & 1 & 1 \end{bmatrix} \quad \text{a} \quad \mathbf{y}^{(0)} = [1, 1, 1]^T.$$

Řešení: Použijeme iteracní formuli

$$\mathbf{y}^{(k+1)} = \mathbf{A}\mathbf{y}^{(k)}, \quad \text{pro } k = 0, 1, \dots$$

$$\mathbf{y}^{(1)} = [2; 3; 2]^T \quad \lambda_1^{(1)} = \frac{y_1^{(1)}}{y_3^{(1)}} = 3,$$

$$\mathbf{y}^{(2)} = [5; 7; 5]^T \quad \lambda_1^{(2)} = \frac{7}{3} \approx 2,3333,$$

$$\mathbf{y}^{(3)} = [12; 17; 12]^T \quad \lambda_1^{(3)} = \frac{17}{7} \approx 2,4285,$$

$$\mathbf{y}^{(4)} = [29; 41; 29]^T \quad \lambda_1^{(4)} = \frac{41}{17} \approx 2,4117,$$

$$\mathbf{y}^{(5)} = [70; 99; 70]^T \quad \lambda_1^{(5)} = \frac{99}{41} \approx 2,4146.$$

Poznámka:

Abychom zamezili přetečení, resp. podtečení při zobrazení čísel v počítači je vhodné v každém kroku

normovat vektor $\mathbf{y}^{(k)}$ (norma $\mathbf{y}^{(k)}$ roste, resp. klesá pro vlastní číslo v absolutní hodnotě větší, resp. menší než 1).

$$\mathbf{y}^{(k)} := \frac{\mathbf{y}^{(k)}}{\|\mathbf{y}^{(k)}\|}$$

výsledky v MATLABu

```
Mocninná metoda pro výpočet dominantního vlastního čísla matice A

A =
  900   20      1
  20   500   30
      1   30   100

| k |   y(1)_k   |   y(2)_k   |   y(3)_k   || lambda_k |
| 0 | 1.000000e+000 | 1.000000e+000 | 1.000000e+000 ||
| 1 | 9.210000e+002 | 5.500000e+002 | 1.310000e+002 || 921.000000 |
| 2 | 8.400310e+005 | 2.973500e+005 | 3.052100e+004 || 912.0857763 |
| 3 | 7.620054e+008 | 1.663913e+008 | 1.281263e+007 || 907.1158338 |
| 4 | 6.891455e+011 | 9.882011e+010 | 7.035006e+009 || 904.3840077 |
| 5 | 6.222144e+014 | 6.340402e+013 | 4.357249e+012 || 902.8781109 |
| 6 | 5.612654e+017 | 4.427701e+016 | 2.960060e+015 || 902.0450147 |
| 7 | 5.060274e+020 | 3.345262e+019 | 2.185582e+018 || 901.5830307 |
| 8 | 4.560959e+023 | 2.691242e+022 | 1.728164e+021 || 901.3264854 |
| 9 | 4.110263e+026 | 2.262997e+025 | 1.436285e+024 || 901.1839104 |
| 10 | 3.703777e+029 | 1.957860e+028 | 1.233554e+027 || 901.1046393 |
```

výsledky v MATLABu

Mocninná metoda pro výpočet dominantního vlastního čísla matice A s normováním vlastního vektoru v každé iteraci

```
A =
  900   20      1
  20   500   30
      1   30   100

| k |   y(1)_k   |   y(2)_k   |   y(3)_k   || lambda_k |
| 0 | 1.000000 | 1.000000 | 1.000000 || 1
| 1 | 921.000000 | 550.000000 | 131.000000 || 921.000000 |
| 2 | 1.000000 | 0.5971770 | 0.1422367 || 1
| 3 | 912.0857763 | 322.8555917 | 33.1389794 || 912.0857766 |
| 4 | 1.000000 | 0.3539750 | 0.0363332 || 1
| 5 | 907.1158338 | 198.0775114 | 15.2525693 || 907.1158344 |
| 6 | 1.000000 | 0.2183597 | 0.0168144 || 1
| 7 | 904.3840077 | 129.6842642 | 9.2322257 || 904.3840088 |
| 8 | 1.000000 | 0.1433951 | 0.0102083 || 1
| 9 | 902.8781109 | 92.0038151 | 6.3226842 || 902.8781111 |
| 10 | 1.000000 | 0.1019006 | 0.0070028 || 1
| 11 | 902.0450147 | 71.1603809 | 4.7572988 || 902.0450151 |
| 12 | 1.000000 | 0.0788878 | 0.0052739 || 1
| 13 | 901.5830307 | 59.6021361 | 3.8940255 || 901.5830301 |
| 14 | 1.000000 | 0.0661083 | 0.0043191 || 1
| 15 | 901.3264854 | 53.1837310 | 3.4151593 || 901.3264855 |
| 16 | 1.000000 | 0.0590061 | 0.0037890 || 1
| 17 | 901.1839104 | 49.6167046 | 3.1490857 || 901.183910 |
| 18 | 1.000000 | 0.0550572 | 0.0034944 || 1
| 19 | 901.1046393 | 47.6334548 | 3.0011561 || 901.104639 |
| 20 | 1.000000 | 0.0528612 | 0.0033305 || 1
```

výsledky v MATLABu

Mocninná metoda pro výpočet dominantního vlastního čísla matice A

```
A =
  1/1000   -3/10000   -1/2000
  1/5000   1/200      -1/10000
  -1/1000  1/500      3/1000

| k |   y(1)_k   |   y(2)_k   |   y(3)_k   || lambda_k |
| 0 | 1.000000e+000 | 1.000000e+000 | 1.000000e+000 ||
| 1 | 2.000000e-004 | 5.100000e-003 | 4.000000e-003 || 0.0051000 |
| 2 | -3.330000e-006 | 2.514000e-005 | 2.200000e-005 || 0.0049294 |
| 3 | -2.187200e-008 | 1.228340e-007 | 1.196100e-007 || 0.0048860 |
| 4 | -1.185272e-010 | 5.978346e-010 | 6.263700e-010 || 0.0052368 |
| 5 | -6.110626e-013 | 2.902831e-012 | 3.193306e-012 || 0.0050981 |
| 6 | -3.078565e-015 | 1.407261e-014 | 1.599664e-014 || 0.0050094 |
| 7 | -1.529867e-017 | 6.814767e-017 | 7.921371e-017 || 0.0049519 |
| 8 | -7.534983e-020 | 3.297572e-019 | 3.892351e-019 || 0.0049137 |
| 9 | -3.688946e-022 | 1.594793e-021 | 1.902570e-021 || 0.0048880 |
| 10 | -1.798617e-024 | 7.709928e-024 | 9.266189e-024 || 0.0048704 |
```

výsledky v MATLABu



```
Mocninna metoda pro vypocet dominantniho vlastniho cisla matice A
s normovanim vlastniho vektoru v kazde iteraci

A =
1/1000   -3/10000   -1/2000
1/5000    1/200   -1/10000
-1/1000   1/500    3/1000

| k | y(1)_k | y(2)_k | y(3)_k || lambda_k |
-----
| 0 | 1.000000 | 1.000000 | 1.000000 || 0.005100
| 1 | 0.000200 | 0.005100 | 0.004000 || 0.005100
| 2 | 0.0392157 | 1.000000 | 0.7843137 || 0.004929
| 3 | -0.1324582 | 1.000000 | 0.8750994 || 0.004886
| 4 | -0.0008700 | 0.0048860 | 0.0047578 || 0.004886
| 5 | -0.1780614 | 1.000000 | 0.9737532 || 0.005237
| 6 | -0.0009649 | 0.0048670 | 0.005093 || 0.005237
| 7 | -0.1892287 | 0.9544432 | 1.000000 || 0.005098
| 8 | -0.0009756 | 0.0046344 | 0.0050981 || 0.005098
| 9 | -0.1913573 | 0.9090360 | 1.000000 || 0.005098
| 10 | -0.0009641 | 0.0044069 | 0.005094 || 0.005098
| 11 | -0.1924507 | 0.8797227 | 1.000000 || 0.004952
| 12 | -0.1931316 | 0.8603014 | 1.000000 || 0.004952
| 13 | -0.1935843 | 0.8471929 | 1.000000 || 0.004914
| 14 | -0.1938928 | 0.8382309 | 1.000000 || 0.004888
| 15 | -0.1941054 | 0.8320495 | 1.000000 || 0.004870
| 16 | -0.1941054 | 0.8320495 | 1.000000 || 0.004870
```

Poznámka:

Nejlepší approximaci dostaneme, dělíme-li složky, které mají největší absolutní hodnotu.
Obecně nelze použít libovolnou složku vektoru $y^{(k)}$ neboť odpovídající vlastní vektor ji může mít nulovou.

výsledky v MATLABu



```
A =
1   1   0
0   2   0
0   0   3

>> [v,c]=eig(A,'nobalance')

v =
1   1   0
0   1   0
0   0   1

c =
1   0   0
0   2   0
0   0   3

Mocninna metoda pro vypocet dominantniho vlastniho cisla matice A

| k | y(1)_k | y(2)_k | y(3)_k ||lambda_k_is|| 2s || 3s ||
-----
| 0 | 2.000000e+000 | 1.000000e+000 | 1.000000e+000 || 1.5000000000000000 || 2 || 3
| 1 | 3.000000e+000 | 2.000000e+000 | 3.000000e+000 || 1.6666666666666666 || 2 || 3
| 2 | 5.000000e+000 | 4.000000e+000 | 9.000000e+000 || 1.8000000000000000 || 2 || 3
| 3 | 9.000000e+000 | 8.000000e+000 | 2.700000e-01 || 1.8888888888888888 || 2 || 3
| 4 | 1.700000e+001 | 1.600000e+001 | 8.100000e+001 || 1.9411765313389380 || 2 || 3
| 5 | 3.300000e+001 | 3.200000e+001 | 2.430000e+002 || 1.9846154468115200 || 2 || 3
| 6 | 6.500000e+001 | 6.400000e+001 | 7.290000e+002 || 1.9969700000000000 || 2 || 3
| 7 | 1.290000e+002 | 1.280000e+002 | 2.187000e+003 || 1.9996108900000000 || 2 || 3
| 8 | 2.570000e+002 | 2.560000e+002 | 6.561000e+003 || 1.9992248100000000 || 2 || 3
| 9 | 5.130000e+002 | 5.120000e+002 | 1.968300e+004 || 1.9996108900000000 || 2 || 3
| 10 | 1.025000e+003 | 1.024000e+003 | 5.904900e+004 || 1.9998050700000000 || 2 || 3
```

Poznámka:

Při praktickém použití mocninny metody neověřujeme, zda jsou splněny předpoklady odvození.

Zadaná matice nemusí mít jediné dominantní vlastní číslo nebo

počet lineárně nezávislých vlastních vektorů může být menší než řad matice.

Při nesplněných předpokladech odvození může být konvergence pomalá.

Další nevhodnost mocninny metody je potom odhad chyby získané approximace.

výsledky v MATLABu



```
A =
3   1   1
-1   1   0
0   0   1

>> [v,c]=eig(A,'nobalance')

v =
1.0000   -1.0000   0.0000
-1.0000   1.0000  -1.0000
0       0       1.0000

c =
2.0000   0       0
0       2.0000   0
0       0       1.0000
```

Mocninna metoda pro vypocet dominantniho vlastniho cisla matice A

```
| k | y(1)_k | y(2)_k | y(3)_k || lambda_k |
-----
| 0 | 1.000000e+000 | 1.000000e+000 | 1.000000e+000 || 5.0000000000000000
| 1 | 5.000000e+000 | 0.000000e+000 | 1.000000e+000 || 5.0000000000000000
| 2 | 1.600000e+001 | -5.000000e+000 | 1.000000e+000 || 3.2000000000000000
| 3 | 4.400000e+001 | -2.100000e+001 | 1.000000e+000 || 2.7500000000000000
| 4 | 1.120000e+002 | -6.500000e+001 | 1.000000e+000 || 2.5454545454545454
| 5 | 2.720000e+002 | -1.770000e+002 | 1.000000e+000 || 2.4285714285714285
| 6 | 6.400000e+002 | -4.490000e+002 | 1.000000e+000 || 2.3529412352941235
| 7 | 1.472000e+003 | -1.089000e+003 | 1.000000e+000 || 2.3000000000000000
| 8 | 3.328000e+003 | -2.561000e+003 | 1.000000e+000 || 2.2608696260869626
| 9 | 7.424000e+003 | -5.889000e+003 | 1.000000e+000 || 2.2307692230769223
| 10 | 1.638400e+004 | -1.331300e+004 | 1.000000e+000 || 2.2068966206896620
| 150 | 8.556839e+016 | -8.219069e+016 | 1.000000e+000 || 2.0402685204026852
| 100 | 1.914152e+032 | -1.876123e+032 | 1.000000e+000 || 2.0200669202006692
| 150 | 3.225580e+047 | -3.182762e+047 | 1.000000e+000 || 2.0133630201336302
| 200 | 4.836884e+062 | -4.788675e+062 | 1.000000e+000 || 2.0100167201001672
| 250 | 6.802785e+077 | -6.748508e+077 | 1.000000e+000 || 2.0080107200801072
| 300 | 9.187032e+092 | -9.125921e+092 | 1.000000e+000 || 2.0066741200667412
| 1000 | 1.608334e+304 | -1.605120e+304 | 1.000000e+000 || 2.0020007200200072
| 1013 | Inf | -1.332031e+308 | 1.000000e+000 || Inf |
```



Z uvedeného příkladu je dále vidět, že je opravdu vhodné normovat vektor $y^{(k)}$ a zabránit tak přetečení.

Poznámka:

Při praktickém použití mocninny metody použijeme například počáteční volbu vektoru $y^{(0)} = [1, 1, 1, \dots, 1]^T$.

Je-li ovšem vektor $y^{(0)}$ takový, že lineární kombinací vlastních vektorů, že koeficient u vlastního vektoru odpovídající dominantnímu vlastnímu číslu bude roven 0, potom mocninna metoda nevypočte dominantní vlastní číslo, ale nejbližší nižší, u kterého u odpovídajícího vlastního vektoru bude nenulový koeficient.

Pokud bychom prováděli výpočet dostatečně dlouho, dojde vlivem zaokrouhlovacích chyb k tomu, že u příslušné iteraci $y^{(k)}$ bude již zmíněný koeficient u vlastního vektoru odpovídajícího dominantnímu vlastnímu číslu již nenulový a metoda nakonec dominantní vlastní číslo naleze.

výsledky v MATLABu

```
A =
 4   -3    2
 0    2    0
 0   -4    6

>> [v, c]=eig(A,'nobalance')

v =
 1.0000  1.0000 -0.5000
 0       0     -1.0000
 0       1.0000 -1.0000

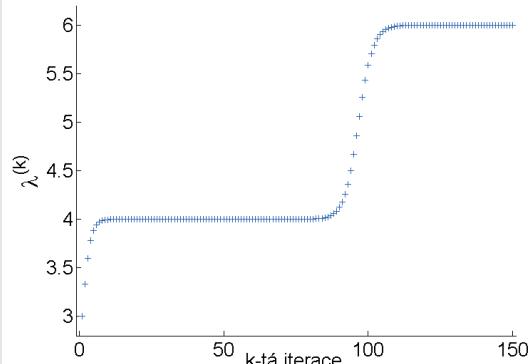
c =
 4   0    0
 0   6    0
 0   0    2

>> y=[1 1 1]';
>> alpha=(v\y);

alpha =
 0.5000      0   -1.0000
```

Mocninna metoda pro vypocet dominantniho vlastniho cisla matice A s normovanim vlastniho vektoru v kazde iteraci

k	y(1)_k	y(2)_k	y(3)_k	lambda_k
0	1.000000	1.000000	1.000000	
1	3.000000	2.000000	2.000000	3.000000
2	1.000000	0.6666667	0.6666667	
3	3.333333	1.3333333	1.3333333	3.333333
4	1.000000	0.4000000	0.4000000	
5	3.600000	0.8000000	0.8000000	3.600000
6	1.000000	0.2222222	0.2222222	
7	3.7777778	0.4444444	0.4444444	3.7777778
8	1.000000	0.1176471	0.1176471	
9	3.8823529	0.2352941	0.2352941	3.882353
10	1.000000	0.0606061	0.0606061	
11	3.9393939	0.1212121	0.1212121	3.939394
12	1.000000	0.0307692	0.0307692	
13	3.9692308	0.0615385	0.0615385	3.969231
14	1.000000	0.0155039	0.0155039	
15	3.9844961	0.0310078	0.0310078	3.984496
16	1.000000	0.0077821	0.0077821	
17	3.9922179	0.0155642	0.0155642	3.992218
18	1.000000	0.0038986	0.0038986	
19	3.9961014	0.0077973	0.0077973	3.996101
20	1.000000	0.0019512	0.0019512	
21	3.9980484	0.0039024	0.0039024	3.998049
22	1.000000	0.0009761	0.0009761	
23	3.9990239	0.0019522	0.0019522	3.999024
24	1.000000	0.0004882	0.0004882	
25	3.9995118	0.0009763	0.0009763	3.999512
26	1.000000	0.0002441	0.0002441	



Poznámka:

Iterační proces ukončujeme použitím zastavovací podmínky ve tvaru

$$|\lambda_1^{(k+1)} - \lambda_1^{(k)}| < \varepsilon$$

Posuďte výsledky získané pro následující příklad. Kde je problém?

výsledky v MATLABu

```
A =
 3   3    0
 0   4    2
 0   0    1

>> [v, c]=eig(A,'nobalance')

v =
 1.0000  1.0000  1.0000
 0       0.3333 -0.6667
 0       0       1.0000

c =
 3   0    0
 0   4    0
 0   0    1

>> y=[3 2 1]';
>> alpha=(v\y);

alpha =
 -5      8      1
```

Mocninna metoda pro vypocet dominantniho vlastniho cisla matice A

k	y(1)_k	y(2)_k	y(3)_k	lambda_k
0	1.000000e+000	1.000000e+000	1.000000e+000	
1	6.000000e+000	6.000000e+000	1.000000e+000	6.000000
2	3.600000e+001	2.600000e+001	1.000000e+000	6.000000

```
>> y=[3 2 1];
>> alpha=(v\y);
```

```
alpha =
 -6      8      1
```

Mocninna metoda pro vypocet dominantniho vlastniho cisla matice A

k	y(1)_k	y(2)_k	y(3)_k	lambda_k
0	3.000000e+000	2.000000e+000	1.000000e+000	
1	1.500000e+001	1.000000e+001	1.000000e+000	5.000000
2	7.500000e+001	4.200000e+001	1.000000e+000	5.000000

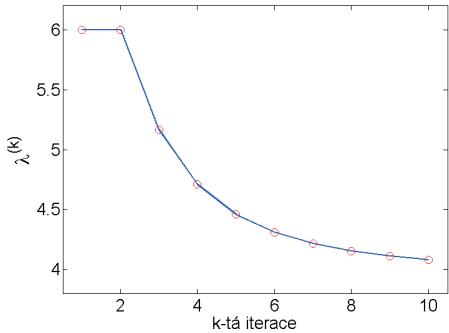
Všechny předpoklady byly splněny, byla použita i vhodná počáteční volba vektoru $y^{(0)}$.

Jediné, co se stalo je skutečnost, že v posloupnosti priblížených řešení generovaných mocninnou metodou se objevily dva po sobě jdoucí stejné členy, které zdaleka nebyly limitou této posloupnosti.

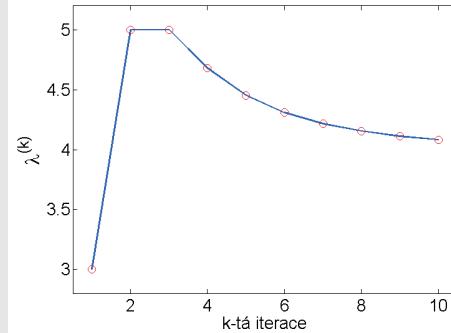
výsledky v MATLABu

Mocninna metoda pro vypocet dominantniho vlastniho cisla matice A

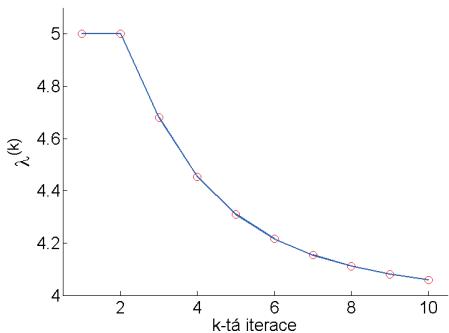
k	y(1)_k	y(2)_k	y(3)_k	lambda_k
0	1.000000e+000	1.000000e+000	1.000000e+000	
1	6.000000e+000	6.000000e+000	1.000000e+000	6.000000
2	3.600000e+001	2.600000e+001	1.000000e+000	6.000000
3	1.860000e+002	1.060000e+002	1.000000e+000	5.1666667
4	8.760000e+002	4.260000e+002	1.000000e+000	4.7096774
5	3.906000e+003	1.706000e+003	1.000000e+000	4.4589041
6	1.683600e+004	6.826000e+003	1.000000e+000	4.3102919
7	7.098600e+004	2.730600e+004	1.000000e+000	4.2163222
8	2.948760e+005	1.092260e+005	1.000000e+000	4.1540022
9	1.212306e+006	4.369060e+005	1.000000e+000	4.112400
10	4.947636e+006	1.747626e+006	1.000000e+000	4.0811775



Mocninna metoda pro vypocet dominantniho vlastniho cisla matici A					
k	y(1)_k	y(2)_k	y(3)_k	lambda_k	
0	1.000000e+000	0.000000e+000	1.000000e+000		
1	3.000000e+000	2.000000e+000	1.000000e+000	3.000000	
2	1.500000e+001	1.000000e+001	1.000000e+000	5.000000	
3	7.500000e+001	4.200000e+001	1.000000e+000	5.000000	
4	3.510000e+002	1.700000e+002	1.000000e+000	4.680000	
5	1.563000e+003	6.820000e+002	1.000000e+000	4.4529915	
6	6.735000e+003	2.730000e+003	1.000000e+000	4.3090211	
7	2.839500e+004	1.092200e+004	1.000000e+000	4.2160356	
8	1.179510e+005	4.369000e+004	1.000000e+000	4.1539356	
9	4.849230e+005	1.747620e+005	1.000000e+000	4.1112242	
10	1.979055e+006	6.990500e+005	1.000000e+000	4.0811737	



Mocninna metoda pro vypocet dominantniho vlastniho cisla matici A					
k	y(1)_k	y(2)_k	y(3)_k	lambda_k	
0	3.000000e+000	2.000000e+000	1.000000e+000		
1	1.500000e+001	1.000000e+001	1.000000e+000	5.000000	
2	7.500000e+001	4.200000e+001	1.000000e+000	5.000000	
3	3.510000e+002	1.700000e+002	1.000000e+000	4.680000	
4	1.563000e+003	6.820000e+002	1.000000e+000	4.4529915	
5	6.735000e+003	2.730000e+003	1.000000e+000	4.3090211	
6	2.839500e+004	1.092200e+004	1.000000e+000	4.2160356	
7	1.179510e+005	4.369000e+004	1.000000e+000	4.1539356	
8	4.849230e+005	1.747620e+005	1.000000e+000	4.1112242	
9	1.979055e+006	6.990500e+005	1.000000e+000	4.0811737	
10	8.034315e+006	2.796202e+006	1.000000e+000	4.0596724	



$$\begin{aligned} \mathbf{A} &= \begin{bmatrix} 100 \\ 99 \\ 11 \end{bmatrix} \dots \text{vlastní čísla } \lambda_1 = 100, \lambda_2 = 99, \lambda_3 = 11 \Rightarrow p_{opt} = \frac{99+11}{2} = 55 \\ \widehat{\mathbf{A}} &= \mathbf{A} - 55\mathbf{I} = \begin{bmatrix} 45 \\ 44 \\ -44 \end{bmatrix} \dots \text{vlastní čísla } \widehat{\lambda}_1 = 45, \widehat{\lambda}_2 = 44, \widehat{\lambda}_3 = -44 \\ \frac{\lambda_2}{\lambda_1} &= \frac{99}{100} = 0,99 \quad \frac{\widehat{\lambda}_2}{\widehat{\lambda}_1} = \frac{44}{45} \doteq 0,9778 \end{aligned}$$

výsledky v MATLABu

n	0.99^n	0.9778^n
1	0.9900	0.9778
2	0.9801	0.9561
3	0.9703	0.9349
4	0.9606	0.9141
5	0.9510	0.8938
6	0.9415	0.8740
7	0.9321	0.8546
8	0.9227	0.8356
9	0.9135	0.8171
10	0.9044	0.7989
11	0.8953	0.7812
12	0.8864	0.7638
13	0.8775	0.7469
14	0.8687	0.7303
15	0.8601	0.7141
16	0.8515	0.6982
17	0.8429	0.6827
18	0.8345	0.6676
19	0.8262	0.6528
20	0.8179	0.6383
21	0.8097	0.6241
22	0.8016	0.6102
23	0.7936	0.5967
24	0.7857	0.5834
25	0.7778	0.5705
26	0.7700	0.5578
27	0.7623	0.5454
28	0.7547	0.5333
29	0.7472	0.5215
30	0.7397	0.5099

Poznámka:

Pro urychlování konvergence metody

- lze použít např. Aitkenův proces.

• pokud platí, že λ_1 a λ_2 jsou si velmi blízká, rychlosť konvergence mocninné metody bude malá; předpokládáme-li např., že jsou všechna vlastní čísla reálná, lze použít Wilkinsonovu metodu:

\mathbf{A} má vlastní čísla $\lambda_1, \lambda_2, \dots, \lambda_n$

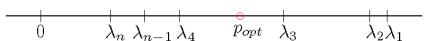
$\widehat{\mathbf{A}} = \mathbf{A} - p\mathbf{I}$ má vlastní čísla $\lambda_1 - p, \lambda_2 - p, \dots, \lambda_n - p$

Uvažujeme pro jednoduchost, že jsou všechny $\lambda_i > 0$.

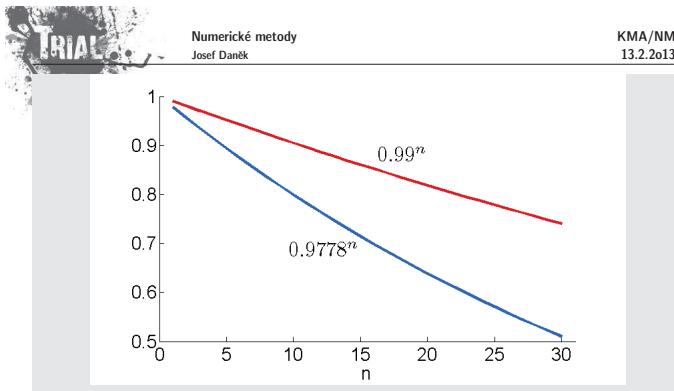
Pomalu konvergenci způsobuje podíl $\left| \frac{\lambda_2}{\lambda_1} \right| \approx 1$.

Chceme tento podíl co nejvíce změnit: $\frac{\lambda_2 - p}{\lambda_1 - p} < \frac{\lambda_2}{\lambda_1}$

Jak musíme volit p ? $p_{opt} = \frac{\lambda_2 + \lambda_1}{2}$... představuje posunutý počátek



Příklad:



Metoda Rayleighova podílu

Chceme určit vlastní číslo matice A s největší absolutní hodnotou (dominantní vlastní číslo). Při odvození metody Rayleighova podílu budeme navíc (oproti mocninné metodě) předpokládat, že matice A je symetrická (reálná). Potom musí být vlastní vektory ortonormální ($v_i^T v_j = 0$ pro $i \neq j$ a $v_i^T v_i = 1$).

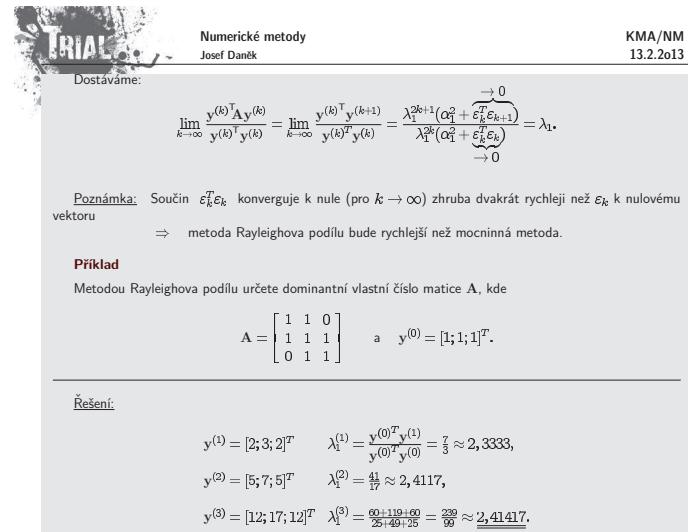
Odvodení:

6. krok z odvození mocninné metody nahradíme vyjádřením součinu $y^{(k)T} y^{(k)}$

$$\begin{aligned} y^{(k)T} y^{(k)} &= \lambda_1^k \left[\alpha_1 v_1^T + \sum_{i=2}^n \alpha_i \left(\frac{\lambda_i}{\lambda_1} \right)^k v_i^T \right] \cdot \lambda_1^k \left[\alpha_1 v_1 + \sum_{i=2}^n \alpha_i \left(\frac{\lambda_i}{\lambda_1} \right)^k v_i \right] = \\ &= \lambda_1^{2k} \left[\alpha_1^2 + \sum_{i=2}^n \alpha_i^2 \left(\frac{\lambda_i}{\lambda_1} \right)^{2k} \right] \\ &\quad \varepsilon_k^T \varepsilon_k \end{aligned}$$

a součinu $y^{(k)T} y^{(k+1)T}$

$$\begin{aligned} y^{(k)T} y^{(k+1)} &= \lambda_1^k \left[\alpha_1 v_1^T + \sum_{i=2}^n \alpha_i \left(\frac{\lambda_i}{\lambda_1} \right)^k v_i^T \right] \cdot \lambda_1^{k+1} \left[\alpha_1 v_1 + \sum_{i=2}^n \alpha_i \left(\frac{\lambda_i}{\lambda_1} \right)^{k+1} v_i \right] = \\ &= \lambda_1^{2k+1} \left[\alpha_1^2 + \sum_{i=2}^n \alpha_i^2 \left(\frac{\lambda_i}{\lambda_1} \right)^{2k+1} \right] \\ &\quad \varepsilon_k^T \varepsilon_{k+1} \end{aligned}$$



Řešení:

$$\begin{aligned} y^{(1)} &= [2; 3; 2]^T & \lambda_1^{(1)} &= \frac{y^{(0)T} y^{(1)}}{y^{(0)T} y^{(0)}} = \frac{7}{3} \approx 2,3333, \\ y^{(2)} &= [5; 7; 5]^T & \lambda_1^{(2)} &= \frac{44}{17} \approx 2,4117, \\ y^{(3)} &= [12; 17; 12]^T & \lambda_1^{(3)} &= \frac{60+119+60}{25+49+25} = \frac{239}{99} \approx \underline{\underline{2,41417}}. \end{aligned}$$

Příklad 3

Pro stejně zadání symetrické matice A porovnejme rychlosť konvergence mocninné metody a metody Rayleighova podílu.

$$A = \begin{bmatrix} 60 & 20 & 10 & 1 \\ 20 & 50 & 10 & 2 \\ 10 & 10 & 30 & 5 \\ 1 & 2 & 5 & 10 \end{bmatrix}, \quad y^{(0)} = \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \end{bmatrix}, \quad \varepsilon = 10^{-5}.$$

výsledky v MATLABu

Numerické metody
Josef Daněk

KMA/NM
13.2.2013

```

A =
60 20 10 1
20 50 10 2
10 10 30 5
1 2 5 10

>> [v,c]=eig(A,'nobalance')

v =
0.029201136324116 0.070393944798935 -0.657594927428575 -0.749507103097250
-0.002755406652908 0.347503151150767 0.720730957555407 -0.599817350945878
-0.241058474917619 -0.907169537175591 0.206770509289230 -0.276007606741715
0.970067272431118 -0.2265650551059880 0.073224003781179 -0.047728910858600

c =
8.781938031360916 0 0 0
0 26.642118061325501 0 0
0 0 34.824093743363321 0
0 0 0 79.751850163950266

>> y=[1 1 1]
>> alpha=(v\y)

alpha =
0.755454527184707 -0.715832992285768 0.343130543197241 -1.673060971643443

```

Mocninná metoda pro výpočet dominantního vlastního čísla matice A

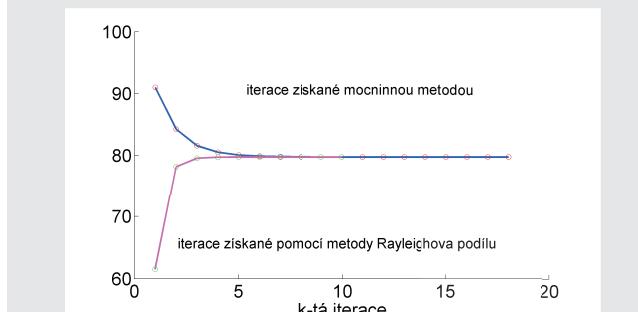
k	y(1)_k	y(2)_k	y(3)_k	y(4)_k	lambda_k
0	1.000000e+000	1.000000e+000	1.000000e+000	1.000000e+000	
1	9.100000e+001	8.200000e+001	5.500000e+001	1.800000e+001	91.000000
2	7.668000e+003	6.506000e+003	3.470000e+003	7.100000e+002	84.2637363
3	6.256100e+005	5.147800e+005	2.493900e+005	4.513000e+004	81.5871153
4	5.037123e+007	4.083536e+007	1.91125e+007	1.911125e+007	3.353420e+006
5	4.033447e+009	3.247012e+009	1.502171e+009	2.611324e+008	80.0744717
6	3.222299e+011	2.585635e+011	1.191754e+011	2.064965e+010	79.8894588
7	2.571747e+013	2.060583e+013	9.486443e+012	1.641730e+012	79.8109287
8	2.051671e+015	1.642789e+015	7.560349e+014	1.307786e+014	79.7773243
9	1.636471e+017	1.309947e+017	6.027953e+016	1.042521e+016	79.7628684
10	1.305194e+019	1.044633e+019	4.806931e+018	8.312864e+017	79.7566267
11	1.040944e+021	8.330871e+020	3.833471e+020	6.629211e+019	79.7539244
12	8.301813e+022	6.643928e+022	3.057218e+022	5.286774e+021	79.7527521
13	6.620882e+024	5.298622e+024	2.438173e+024	4.216253e+023	79.7522427
14	5.280287e+026	4.225737e+026	1.944484e+026	3.362525e+025	79.7520212
15	4.211131e+028	3.370099e+028	1.550760e+028	2.681670e+027	79.7519247
16	3.358456e+030	2.687715e+030	1.236759e+030	2.138680e+029	79.7518827
17	2.678431e+032	2.143502e+032	9.863383e+031	1.705636e+031	79.7518643
18	2.136099e+034	1.709482e+034	7.866230e+033	1.360276e+033	79.7518563

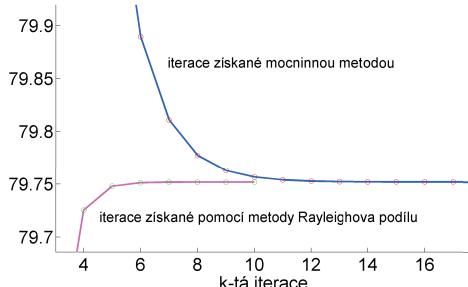
Numerické metody
Josef Daněk

KMA/NM
13.2.2013

Metoda Rayleighova podílu pro výpočet dominantního vlastního čísla matice A

k	y(1)_k	y(2)_k	y(3)_k	y(4)_k	lambda_k
0	1.000000e+000	1.000000e+000	1.000000e+000	1.000000e+000	
1	9.100000e+001	8.200000e+001	5.500000e+001	1.800000e+001	61.500000
2	7.668000e+003	6.506000e+003	3.470000e+003	7.100000e+002	78.1796884
3	6.256100e+005	5.147800e+005	2.493900e+005	4.2493900e+005	79.5606714
4	5.037123e+007	4.083536e+007	1.91125e+007	1.911125e+007	79.7252270
5	4.033447e+009	3.247012e+009	1.502171e+009	1.502171e+009	79.7478446
6	3.222299e+011	2.585635e+011	1.191754e+011	1.191754e+011	79.7512057
7	2.571747e+013	2.060583e+013	9.486443e+012	1.641730e+012	79.7517406
8	2.051671e+015	1.642789e+015	7.560349e+014	1.307786e+014	79.7518308
9	1.636471e+017	1.309947e+017	6.027953e+016	1.042521e+016	79.7518466
10	1.305194e+019	1.044633e+019	4.806931e+018	8.312864e+017	79.7518495



**Poznámka:**

Pokud jsme vypočítali λ_1, \mathbf{v}_1 a chceme určit další vlastní čísla, resp. vlastní vektory $\lambda_2, \mathbf{v}_2, \lambda_3, \mathbf{v}_3, \dots$ (ovšem ne všechny), můžeme použít metody využívající znalosti λ_1, \mathbf{v}_1 atd.

• Maticová redukce

Věta: Nechť λ_1 je vlastní číslo matice \mathbf{A} a \mathbf{v}_1 jemu odpovídající vlastní vektor. Nechť \mathbf{w} je libovolný vektor, pro který $\mathbf{w}^T \mathbf{v}_1 = 1$. Pak matice

$$\mathbf{W}_1 = \mathbf{A} - \lambda_1 \mathbf{v}_1 \mathbf{w}^T$$

má stejná vlastní čísla jako matice \mathbf{A} , s výjimkou vlastního čísla λ_1 , které je nahrazeno číslem 0 (\mathbf{W}_1 ... redukovaná matice).

Otázka: Jak volit vektor \mathbf{w} ?**1. Hotellingova redukce**

w ... levý vlastní vektor vlastního čísla λ_1 (je normalizován: $\mathbf{w}^T \mathbf{v}_1 = 1$)

obvykle levý vlastní vektor neznáme a může být $\mathbf{w}^T \mathbf{v}_1 = 0$

užijeme tuto metodu pro symetrické matice, protože potom $\mathbf{w} = \mathbf{v}_1$

(tj. pravý a levý vlastní vektor odpovídající stejnemu vlastnímu číslu je stejný)

2. Wielandtova redukce

(viz literatura)

3. podobnostní redukce

(viz literatura)

• Anihilaciční postupy

Je-li \mathbf{w} libovolný vektor a λ_1, \mathbf{v}_1 vlastní číslo a vektor matice \mathbf{A} , pak vektor

$$\mathbf{u} = (\mathbf{A} - \lambda_1 \mathbf{I}) \mathbf{w}$$

nemá složku ve směru vektoru \mathbf{v}_1

Cv. vyjádříme vektor \mathbf{w} jako lineární kombinaci vlastních vektorů \mathbf{v}_i a ověříme

$$\begin{aligned} \mathbf{u} = (\mathbf{A} - \lambda_1 \mathbf{I}) \left(\sum_{i=1}^n \beta_i \mathbf{v}_i \right) &= \sum_{i=1}^n (\beta_i \mathbf{A} \mathbf{v}_i - \beta_i \lambda_1 \mathbf{v}_i) = \beta_1 \lambda_1 \mathbf{v}_1 - \beta_1 \lambda_1 \mathbf{v}_1 + \sum_{i=2}^n (\beta_i \lambda_i \mathbf{v}_i - \lambda_1 \beta_i \mathbf{v}_i) = \\ &= 0 \cdot \mathbf{v}_1 + \sum_{i=2}^n \beta_i (\lambda_i - \lambda_1) \mathbf{v}_i \end{aligned}$$

□

- Použijeme-li \mathbf{u} jako vstup do mocninné metody, získáme λ_2, \mathbf{v}_2 (pozor na problém se zaokrouhlovacími chybami).

- Abychom odstranili tento problém, odbouráváme stálé složky ve směru \mathbf{v}_1

$$\mathbf{u} = (\mathbf{A} - \lambda_1 \mathbf{I}) \mathbf{u}$$

Charakteristika metod na řešení úplného problému:

- 1) metody založené na výpočtech vlastních čísel **pomocí charakteristického polynomu**

Nevyhodné pro velká n (řád matice \mathbf{A}), protože je obtížné vypočítat $p_A(\lambda) = \det(\mathbf{A} - \lambda \mathbf{I})$ z definice determinantu.

- 2) **metody využívající podobnosti matic**

Tato kategorie metod využívá faktu, že podobné matice mají stejná vlastní čísla.

Princip: konstruujeme posloupnost navzájem podobných matic, která konverguje k matici, jejíž vlastní čísla se dají jednoduše způsobem určit.

- 3) **snižené metody**

založené na převodu obecné matice na matici třídiagonální (např. Givensova, Householderova a Lanczosova metoda) a následný efektivní výpočet kořenů charakteristického polynomu této upravené matice.

Metoda LU-rozkladu (LR-transformace, LR-algoritmus)

(Lower-Upper, Left-Right)

$\mathbf{A} = \mathbf{L} \mathbf{U}$... rozklad matice \mathbf{A} na dolní trojúhelníkovou matici \mathbf{L} a horní trojúhelníkovou matici \mathbf{U} , kde na diagonále matici \mathbf{L} jsou pro jednoznačnost rokladu jednotky.

Sestrojíme matici \mathbf{B} , která bude podobná matici \mathbf{A} .

$$\mathbf{B} = \mathbf{U} \mathbf{L} \quad (\mathbf{U} = \mathbf{L}^{-1} \mathbf{A} \Rightarrow \mathbf{B} = \mathbf{U} \mathbf{L} = \mathbf{L}^{-1} \mathbf{A} \mathbf{L}).$$

Postup:

Sestrojíme posloupnost matic \mathbf{A}_k :

(i) $\mathbf{A}_0 = \mathbf{A}, k = 0$

(ii) provedeme LU rozklad matice $\mathbf{A}_k = \mathbf{L}_k \mathbf{U}_k$

(iii) sestrojíme matici $\mathbf{A}_{k+1} = \mathbf{U}_k \mathbf{L}_k$

(iv) je-li matice \mathbf{A}_{k+1} horní trojúhelníková \Rightarrow konec,
jinak $k = k + 1$ a jdi na (ii)

Poznámka:

Dá se ukázat, že když matice $\mathbf{B}_k = \mathbf{L}_0 \mathbf{L}_1 \dots \mathbf{L}_k$ konvergují k regulární matici, potom matice \mathbf{A}_k také konvergují, a to k horní trojúhelníkové matici s vlastními čísly na diagonále. Platí

$$\mathbf{A}_{k+1} = \underbrace{\mathbf{L}_k^{-1} \mathbf{A}_k \mathbf{L}_k}_{\mathbf{U}_k}$$

a tedy

$$\mathbf{A}_{k+1} = \underbrace{\mathbf{L}_k^{-1} \mathbf{L}_{k-1}^{-1} \dots \mathbf{L}_0^{-1}}_{\mathbf{B}_{k+1}^{-1}} \mathbf{A}_0 \underbrace{\mathbf{L}_0 \mathbf{L}_1 \dots \mathbf{L}_k}_{\mathbf{B}_{k+1}}$$

Poznámka:

Matice \mathbf{B}_k konvergují k matici, jejíž sloupečky tvoří vlastní vektory matice \mathbf{A} .

Pro symetrickou matici \mathbf{A} je důkaz zřejmý

$$\mathbf{B}_{k+1} \underbrace{\mathbf{A}_{k+1}}_{\rightarrow \Lambda} = \mathbf{AB}_{k+1}.$$

Poznámka:

Je-li matice \mathbf{A} symetrická a pozitivně definitní, provádíme LU-rozklad ve smyslu Choleského rozkladu ($\mathbf{A} = \mathbf{LL}^T$). Potom lze ukázat, že \mathbf{A}_k konverguje k diagonální matici.

Nevýhody:

- pomalá konvergence posloupnosti \mathbf{A}_k
- velký počet operací pro matice větších řádů
- nelze realizovat pro obecné matice \mathbf{A}

Metody ortogonálních transformací

Použijeme podobný princip jako v předchozím případě, tj. sestrojíme posloupnost navzájem podobných matic $\mathbf{A}_0, \mathbf{A}_1, \mathbf{A}_2, \dots$ tak, že

$$\mathbf{A}_{k+1} = \mathbf{Q}_k^T \mathbf{A}_k \mathbf{Q}_k, \quad k = 0, 1, 2, \dots$$

Požadujeme, aby posloupnost \mathbf{A}_k konvergovala k matici, jejíž vlastní čísla lehce určíme. Ortogonální matici \mathbf{Q}_k vybíráme speciálním postupem. Výhodou tohoto algoritmu je **numerická stabilita**.

Poznámka: Pro obecnou matici používáme metodu **QU-rozkladu (QR-transformace)**.

$$\mathbf{A} = \mathbf{Q} \mathbf{U} \quad \text{Q... ortogonální matici } (\mathbf{Q} \mathbf{Q}^T = \mathbf{I}, \text{ tj. } \mathbf{Q}^T = \mathbf{Q}^{-1})$$

$\mathbf{U} \dots$ horní trojúhelníková matici

$$\mathbf{B} = \mathbf{U} \mathbf{Q} \quad (\mathbf{U} = \mathbf{Q}^{-1} \mathbf{A} \Rightarrow \mathbf{B} = \mathbf{Q}^{-1} \mathbf{A} \mathbf{Q} \Rightarrow \mathbf{B} = \mathbf{Q}^T \mathbf{A} \mathbf{Q}).$$

Motivační příklad:

Příkladem ortogonální matice je matice rovinné rotace o úhel α :

$$\mathbf{Q}(\alpha) = \begin{bmatrix} \cos \alpha & -\sin \alpha \\ \sin \alpha & \cos \alpha \end{bmatrix} \stackrel{\text{def.}}{=} \begin{bmatrix} c & -s \\ s & c \end{bmatrix}.$$

Pro matici

$$\mathbf{A} = \begin{bmatrix} 2 & 1 \\ 1 & 3 \end{bmatrix}$$

stanovíme matici $\mathbf{B} = \mathbf{Q}^T(\alpha) \mathbf{A} \mathbf{Q}(\alpha)$ tak, aby $b_{12} = 0$.

Řešení:

Rozepíšeme si prvky matice \mathbf{B} :

$$\begin{aligned} \begin{bmatrix} b_{11} & b_{12} \\ b_{21} & b_{22} \end{bmatrix} &= \begin{bmatrix} c & s \\ -s & c \end{bmatrix} \cdot \begin{bmatrix} 2 & 1 \\ 1 & 3 \end{bmatrix} \cdot \begin{bmatrix} c & -s \\ s & c \end{bmatrix} = \\ &= \begin{bmatrix} 2c + s & c + 3s \\ -2s + c & -s + 3c \end{bmatrix} \cdot \begin{bmatrix} c & -s \\ s & c \end{bmatrix} = \\ &= \begin{bmatrix} 2c^2 + cs + cs + 3s^2 & -2cs - s^2 + c^2 + 3cs \\ -2cs + c^2 - s^2 + 3cs & 2s^2 - cs - cs + 3c^2 \end{bmatrix}. \end{aligned}$$

Pro splnění podmínky $b_{12} = 0$ musí platit

$$-2cs - s^2 + c^2 + 3cs = cs - s^2 + c^2 = 0,$$

tj.

$$\frac{\cos \alpha \sin \alpha - \sin^2 \alpha + \cos^2 \alpha}{2 \sin 2\alpha} = 0.$$

$$\cos 2\alpha = -\frac{1}{2} \sin 2\alpha$$

$$-2 = \tan 2\alpha$$

$$\alpha \doteq -0,5535$$

Po dosazení dostaneme, že

$$\mathbf{B} = \begin{bmatrix} 3,6180 & 0 \\ 0 & 1,3819 \end{bmatrix}.$$

\mathbf{B} je diagonální matici s vlastními čísly na diagonále a stejná vlastní čísla má i matice \mathbf{A} .

□

Poznámka:

Podobně jako v předchozí metodě, pro dostatečně velké k je A_k horní trojúhelníková matic a vlastní vektor jí sou (přibližně) sloupce matic $Q_0 Q_1 \dots Q_{k-1}$.

Poznámka:

Pro symetrickou matici A vede uvedený postup na tzv. **metodu Jacobiovy diagonalizace**.

Jacobiova diagonalizace (speciální případ QR-transformace)

Věta: Je-li A reálná symetrická matic, potom existuje ortogonální matici Q tak, že

$$Q^T A Q = \Lambda$$

(Λ ... spektrální matic = diagonální matic s vlastními čísly na diagonále).

Princip: Matici Q získáme součinem matic $Q_{pq}(\alpha)$, kde

$$Q_{pq}(\alpha) = \begin{bmatrix} 1 & & & & & \\ & 1 & & & & \\ & & \cos\alpha & \dots & \dots & -\sin\alpha \\ & & ; & 1 & & ; \\ & & & \ddots & & \vdots \\ & & & & 1 & \vdots \\ & & & & & \cos\alpha \\ & & & & & \sin\alpha \\ & & & & & 1 \\ & & & & & \vdots \\ & & & & & 1 \end{bmatrix} \quad \leftarrow p\text{-tý řádek} \quad \leftarrow q\text{-tý řádek}$$

$\uparrow \quad \uparrow$
 $p\text{-tý sloupec} \quad q\text{-tý sloupec}$

a parametr α volíme tak, abychom vynulovali prvek v pozici (p, q) a tedy i v pozici (q, p) .

(D. cv. $Q_{pq}^T(\alpha)Q_{pq}(\alpha) = I$.)

$$B \xrightarrow{\text{opr.}} A_1 = Q_{pq}^T(\alpha)A Q_{pq}(\alpha)$$

$$b_{pq} = \underbrace{\left[\dots \cos\alpha \dots \sin\alpha \dots \right]}_{p\text{-tý řádek } Q_{pq}^T} \underbrace{A \left[\dots -\sin\alpha \dots \cos\alpha \dots \right]^T}_{q\text{-tý sloupec } Q_{pq}}$$

$$b_{pq} = a_{pq}(\cos^2\alpha - \sin^2\alpha) + (a_{qq} - a_{pp})\cos\alpha\sin\alpha$$

požadujeme, aby $b_{pq} = 0$:

$$a_{pq}\cos 2\alpha + (a_{qq} - a_{pp})\frac{1}{2}\sin 2\alpha = 0 \quad / \cdot 2$$

$$2a_{pq}\cos 2\alpha = -(a_{qq} - a_{pp})\sin 2\alpha \quad / : \cos 2\alpha \quad / : (a_{qq} - a_{pp})$$

$$-\frac{2a_{pq}}{a_{qq} - a_{pp}} = \tan 2\alpha \quad \Rightarrow \quad \alpha = \dots$$

Poznámka:

Při výpočtech nemusíme určovat úhel α , ale stačí nám vyjádřit $\sin \alpha$ a $\cos \alpha$. Lze odvodit vzorce pro $\sin \alpha = \dots$ a $\cos \alpha = \dots$

Celkovou matici získáme takto

$$Q = \prod_{p,q} Q_{pq}(\alpha)$$

- postupně nulujeme všechny nediagonální prvky.

Poznámka:

Zbývá zvolit strategii na volbu indexů p a q . Nejjednodušší je postupně nulovat všechny mimodiagonální prvky (podobně jako v Gaussové eliminaci metodě pro řešení soustavy lineárních rovnic). Uvědomme si ale, že se získáme nuly z předchozího kroku obecně nezachovají. Další možností je nulovat vždy mimodiagonální prvek, který je největší v absolutní hodnotě (zde je třeba v každé iteraci vyhledat tento prvek, což zpomalí výpočet). Iterační proces zastavíme, je-li norma trojúhelníkové matice pod diagonálu menší než zadáná tolerance.

1. varianta - postupné nulování

2. varianta - nulování největšího prvku (v abs. hodnotě)

Vlastní vektory:

$$A_1 = Q_1^T A Q_1$$

$$A_2 = Q_2^T A_1 Q_2$$

\vdots

$$A_k = Q_k^T A_{k-1} Q_k$$

$$\Rightarrow A_k = \underbrace{Q_k^T Q_{k-1}^T \dots Q_1^T}_P A \underbrace{Q_1 Q_2 \dots Q_k}_P$$

$$P_k \underbrace{A_k}_{(*)} = A \underbrace{P_k}_{(**)}$$

(*) $A_k \rightarrow \Lambda (k \rightarrow \infty)$ (**) $P_k \rightarrow X \dots$ ježíž sloupce jsou vlastní vektory matice A

Givensova transformace

- Slouží pro převod matice A na třídiagonální tvar (předpokládáme, že A je symetrická)
- Opět používáme podobnostní transformace

$$A_{k+1} = Q_k^T A_k Q_k$$

matice Q_k jsou opět maticemi rovinné rotace, ovšem jsou voleny tak, abychom zachovali již anulované prvky

$$Q_1 = \begin{bmatrix} 1 & & & & & \\ & \frac{a_{21}}{d} & -\frac{a_{31}}{d} & & & \\ & \frac{a_{31}}{d} & \frac{a_{21}}{d} & & & \\ & & & 1 & & \\ & & & & \ddots & \\ & & & & & 1 \end{bmatrix} \quad d = \sqrt{a_{21}^2 + a_{31}^2}$$

$A_2 = Q_1^T A Q_1$ bude mít 0 v pozici (3,1) a (1,3)

$$Q_2 = \begin{bmatrix} 1 & & & & & \\ & \frac{a_{21}}{d} & -\frac{a_{41}}{d} & & & \\ & \frac{a_{41}}{d} & \frac{a_{21}}{d} & & & \\ & & & 1 & & \\ & & & & \ddots & \\ & & & & & 1 \end{bmatrix} \quad d = \sqrt{a_{21}^2 + a_{41}^2}$$

$A_3 = Q_2^T A_2 Q_2$ bude mít 0 v pozici (4,1) a (1,4)

atd.

Příklad: Převeďte matici A na třídiagonální tvar.

$$A = \begin{bmatrix} 1 & 4 & 3 \\ 4 & 2 & 6 \\ 3 & 6 & 5 \end{bmatrix}$$

$$a_{21} = 4, \quad a_{31} = 3, \quad d = \sqrt{4^2 + 3^2} = 5$$

$$Q_1 = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \frac{4}{5} & -\frac{3}{5} \\ 0 & \frac{3}{5} & \frac{4}{5} \end{bmatrix}$$

$$Q_1^T Q_1 = I ?$$

$$\begin{bmatrix} 1 & 0 & 0 \\ 0 & \frac{4}{5} & -\frac{3}{5} \\ 0 & \frac{3}{5} & \frac{4}{5} \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 \\ 0 & \frac{4}{5} & \frac{3}{5} \\ 0 & \frac{3}{5} & \frac{4}{5} \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}$$

$$\begin{aligned} Q_1^T A Q_1 &= \begin{bmatrix} 1 & 0 & 0 \\ 0 & \frac{4}{5} & -\frac{3}{5} \\ 0 & \frac{3}{5} & \frac{4}{5} \end{bmatrix} \begin{bmatrix} 1 & 4 & 3 \\ 4 & 2 & 6 \\ 3 & 6 & 5 \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 \\ 0 & \frac{4}{5} & \frac{3}{5} \\ 0 & \frac{3}{5} & \frac{4}{5} \end{bmatrix} = \\ &= \begin{bmatrix} 1 & 4 & 3 \\ 5 & \frac{26}{5} & \frac{39}{5} \\ 0 & \frac{18}{5} & 2 \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 \\ 0 & \frac{4}{5} & \frac{3}{5} \\ 0 & -\frac{3}{5} & \frac{4}{5} \end{bmatrix} = \begin{bmatrix} 1 & 5 & 0 \\ 5 & \frac{221}{25} & \frac{78}{25} \\ 0 & \frac{78}{25} & -\frac{46}{25} \end{bmatrix} \end{aligned}$$

Efektivní výpočet hodnoty charakteristického polynomu pro třídiagonální matici

$$A = \begin{bmatrix} a_1 & c_1 & & & & \\ b_2 & a_2 & c_2 & & & \\ b_3 & a_3 & c_3 & & & \\ \vdots & \vdots & \vdots & \ddots & & \\ b_n & a_n & c_{n-1} & & & \end{bmatrix}$$

$$f_{-1}(\lambda) = 0$$

$$f_0(\lambda) = 1$$

$$f_k(\lambda) = (a_k - \lambda) f_{k-1}(\lambda) - b_k c_{k-1} f_{k-2}(\lambda) \quad k = 1, 2, \dots, n$$

$$f_n(\lambda) = p_A(\lambda)$$

$$\tilde{A} - \lambda I = \begin{bmatrix} a_1 - \lambda & c_1 & & \\ b_2 & a_2 - \lambda & c_2 & \\ & b_3 & a_3 - \lambda & c_3 \\ & & \ddots & \ddots \\ & & b_{n-1} & a_{n-1} - \lambda & c_{n-1} \\ & & & b_n & a_n - \lambda \end{bmatrix}$$

rozvoj podle posledního řádku:

$$\det M = (a_n - \lambda) \det(M_{n-1}) - b_n c_{n-1} \det(M_{n-2})$$

(M_{n-1}, \dots prvních $n-1$ řádků a sloupců z M)

$$M_1 = a_1 - \lambda = \det(M_1)$$

$$M_0 = 1$$

$$M_{-1} = 0$$

Podstata výpočtu vlastních čísel třídiagonální matice pomocí jednoduchého vyjadřování hodnoty charakteristického polynomu metodou bisekce:

Příklad:

$$A = \begin{bmatrix} 2 & -1 & 0 \\ -1 & 2 & -1 \\ 0 & -1 & 2 \end{bmatrix}$$

Zvolíme interval $\langle 0, 5 \rangle$... v něm očekáváme všechna vlastní čísla

Výpočtem snadno určíme

$$f_3(0) = p_A(0) = 4$$

$$f_{-1}(0) = 0$$

$$f_0(0) = 1$$

$$f_1(0) = (\underbrace{a_1 - 0}_{=2}) \underbrace{f_0(0)}_{=1} - b_1 c_0 \underbrace{f_{-1}(0)}_{=0} = 2$$

$$f_2(0) = (\underbrace{a_2 - 0}_{=2}) \underbrace{f_1(0)}_{=2} - \underbrace{b_2}_{=-1} \underbrace{c_1}_{=-1} \underbrace{f_0(0)}_{=1} = 3$$

$$f_3(0) = (\underbrace{a_3 - 0}_{=2}) \underbrace{f_2(0)}_{=3} - \underbrace{b_3}_{=-1} \underbrace{c_2}_{=-1} \underbrace{f_1(0)}_{=2} = 4$$

$$f_3(5) = p_A(5) = -21$$

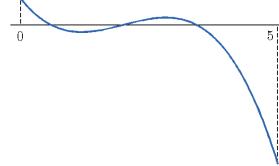
$$f_{-1}(5) = 0$$

$$f_0(5) = 1$$

$$f_1(5) = (\underbrace{a_1 - 5}_{=2}) \underbrace{f_0(5)}_{=1} - b_1 c_0 \underbrace{f_{-1}(5)}_{=0} = -3$$

$$f_2(5) = (\underbrace{a_2 - 5}_{=2}) \underbrace{f_1(5)}_{=3} - \underbrace{b_2}_{=-1} \underbrace{c_1}_{=-1} \underbrace{f_0(5)}_{=1} = 8$$

$$f_3(5) = (\underbrace{a_3 - 5}_{=2}) \underbrace{f_2(5)}_{=8} - \underbrace{b_3}_{=-1} \underbrace{c_2}_{=-1} \underbrace{f_1(5)}_{=1} = -21$$



Vypočteme střed intervalu, $s = \frac{0+5}{2} = 2,5$ a určíme $f_3(2,5) \dots$

Kapitola 7. Aproximace funkcí - I

Motivace

Při numerickém řešení úloh matematické analýzy často nahrazujeme danou funkci f , vystupující v řešené matematické úloze, jinou funkcí φ , kterou v nějakém vhodném smyslu napodobuje funkci f a snadno se přitom matematicky zpracovává či počítá. Tuto funkci φ nazýváme **aproximací funkce**.

Poznámka: Aproximaci funkce jsme již používali u řešení neelineární rovnice. Například v Newtonově metode jsme danou funkci f z řešené rovnice $f(x) = 0$ approximalovaly lineární funkcií (tečnou ke grafu funkce f); podobně tak tomu bylo u metoddy sečení.

Poznámka: Již pouhý výpočet funkčních hodnot některých základních funkcí ($\sin x, e^x, \ln x, \dots$) v počítači či na kalkulačce se provádí užitím approximace těchto funkcí. Tyto approximace jsou ovšem zabudovány do výpočetního systému a uživatel si často ani neuvedomuje, že píše-li v programu např. $y=\sin(x)$, nahrazuje výpočet hodnoty funkce $\sin x$ výpočtem hodnoty jistého polynomu.

Příklady užití:

- numerické metody pro výpočet určitého integrálu
- zpracování výsledků měření

Formule (základní approximací úloha)

Je dána funkce $f = f(x)$, $x \in \langle a, b \rangle$. Zvolíme $(n+1)$ lineárně nezávislých funkcí $\varphi_0, \varphi_1, \dots, \varphi_n$ a hledáme funkci φ definovanou na $\langle a, b \rangle$, kterou lze vyjádřit ve tvare lineární kombinace

$$\varphi(x) = c_0 \varphi_0(x) + c_1 \varphi_1(x) + \dots + c_n \varphi_n(x)$$

a která je v nějakém smyslu blízká funkci f .

• Tento typ approximace se nazývá **lineární approximace**

• Pokud za funkci $\varphi(x)$ volíme polynom, mluvíme o **polynomální approximaci**

• Příkladem **nelineární approximace** je funkce $\varphi(x)$

$$\varphi(x) = \frac{a_0 + a_1 x + \dots + a_n x^n}{1 + b_1 x + \dots + b_n x^n}$$

V tomto případě mluvíme o **racionální approximaci**

měřením), kde nutně nevyžadujeme, aby approximace danými body procházela. Důvodem můžou být např. chyby, se kterými jsme hodnoty naměřili.

Aproximace na okolí bodu

– mluvíme o **aproximaci Taylorovým polynomem**

Předpokládáme, že daná funkce f má v daném bodě x_0 a jeho okolí spojité derivace až do řádu n . Podmínky pro funkci, která co nejlépe napodobuje chování funkce f matematicky zapíšeme takto:

$$f^{(j)}(x_0) = f^{(j)}(x_0), \quad j = 0, 1, \dots, n$$

(Hodnoty derivací funkcií f, φ v bodě x_0 jsou stejně až do řádu n .)

Tuto podmíinku samozřejmě splňuje Taylorův polynom

$$T_n(x) = f(x_0) + \frac{f'(x_0)}{1!}(x - x_0) + \frac{f''(x_0)}{2!}(x - x_0)^2 + \dots + \frac{f^{(n)}(x_0)}{n!}(x - x_0)^n$$

Pro chybu approximace Taylorovým polynomem platí

$$e(x) = f(x) - T_n(x) = f^{(n+1)}(\xi) \frac{(x - x_0)^{n+1}}{(n+1)!}, \quad \xi \in U(x_0)$$

umíme-li odhadnout $(n+1)$ -ní derivaci funkce f na daném okolí bodu x_0 , můžeme provést následující odhad chyby approximace:

$$\text{Platí-li } |f^{(n+1)}(x)| \leq M \quad \forall x \in U(x_0), \quad \text{potom } |e(x)| \leq \frac{M}{(n+1)!}|x - x_0|^{n+1}.$$

Příklad Stanovte odhad chyby approximace Taylorovým polynomem 10. stupně funkce $f(x) = e^x$ v bodě $x_0 = 0$ na intervalu $(-1, 1)$.

$$f^{(j)}(x) = e^x, \quad j = 0, 1, \dots;$$

$$T_{10}(x) = 1 + x + \frac{x^2}{2} + \dots + \frac{x^{10}}{10!}$$

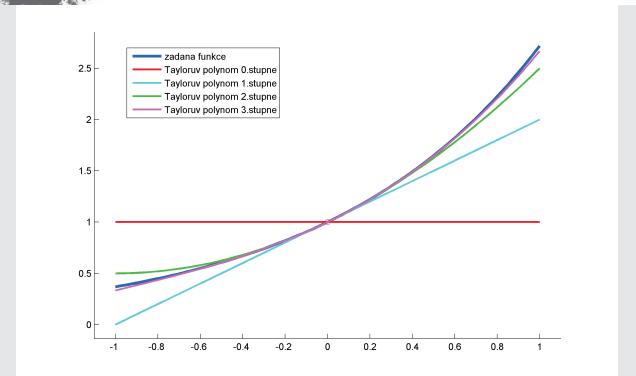
$$e(x) = e^x - T^{10}(x) = \frac{e^{\xi}}{11!}x^{11} \Rightarrow |e(x)| \leq \frac{e}{11!} \leq 7 \cdot 10^{-8}$$

Přístupy k approximaci

Aproximace na okolí bodu – Použijeme, chceme-li approximovat chování funkce v malém okolí bodu. Příkladem může být např. výpočet hodnoty $\sin \frac{\pi}{4}$ na kalkulačce.

Interpolace – Použijeme, chceme-li tabulkou danými body proložit polynom, tj. požadujeme-li, aby approximace přesně procházela zadánými body.

L₂-approximace – Použijeme, hledáme-li funkční závislost mezi tabulkou danými body (získaných například



Příklad Určete stupeň Taylorova polynomu funkce $f(x) = \sin x$ v bodě $x_0 = 0$ tak, aby jeho chyba na intervalu $(-\pi, \pi)$ byla nejvýše 10^{-5} , resp. (10^{-12}) .

Pro chybu platí

$$e(x) = f(x) - T_n(x) = \frac{(x-x_0)^{n+1}}{(n+1)!} f^{(n+1)}(\xi).$$

Zajímá nás chyba na intervalu délky $2\pi \Rightarrow$ odhad pro $|f^{(n+1)}(x)|$ je $\left| \underbrace{f^{(n+1)}(x)}_{(*)} \right| \leq 1 \quad \forall x \in (-\pi, \pi)$

(*) bud $\pm \sin x$ nebo $\pm \cos x$ - tento odhad je vždy nejménší možný

$$\left| \frac{x^{n+1}}{(n+1)!} \right| \leq 10^{-5} \quad \forall x \in (-\pi, \pi)$$

$$\frac{\pi^{n+1}}{(n+1)!} \leq 10^{-5} \quad (\text{resp. } 10^{-12})$$

n	$\frac{\pi^{n+1}}{(n+1)!}$
0	3.141592653589793
1	4.934802200544679
2	5.167712780049969
3	4.058712126416768
4	2.550164039877345
5	1.335262768854589
6	0.599264529320792
7	0.235330630358893
8	0.082145886611128
9	0.025806891390014
10	0.007370430945714
11	0.001929574309404
12	0.000466302805768
13	0.000104638104925
14	0.000021915353448
15	0.000004303069587 $< 10^{-5}$
16	0.000000795205400
17	0.000000138789525
18	0.000000022948429
19	0.000000003604731
20	0.00000000539266
21	0.000000000077007
22	0.000000000010518
23	0.000000000001377
24	0.0000000000000173 $< 10^{-12}$

Jak vypadá Taylorův polynom $T_n(x)$?

$$\begin{aligned} f(x) &= \sin x & f(0) &= 0 \\ f'(x) &= \cos x & f'(0) &= 1 \\ f''(x) &= -\sin x & f''(0) &= 0 \\ f'''(x) &= -\cos x & f'''(0) &= -1 \\ f^{(4)}(x) &= \sin x & f^{(4)}(0) &= 0 \\ &\vdots & &\vdots \\ T_n(x) &= \underbrace{f(x_0)}_{-0} + \underbrace{f'(x_0)(x - x_0)}_{-1} + \frac{1}{2!} \underbrace{f''(x_0)(x - x_0)^2}_{-0} + \dots + \frac{1}{n!} \underbrace{f^{(n)}(x_0)(x - x_0)^n}_{-0} \\ T_{15}(x) &= x - \frac{x^3}{3!} + \frac{x^5}{5!} - \frac{x^7}{7!} + \frac{x^9}{9!} - \frac{x^{11}}{11!} + \frac{x^{13}}{13!} - \frac{x^{15}}{15!} \end{aligned}$$

Má-li kalkulačka vypočítat např. $\sin 0,4$ a má povolenou chybu 10^{-5} , určí $\sin 0,4 \doteq T_{24}(0,4)$.

Pro dodržení chyby 10^{-12} stačí určit $\sin 0,4 \doteq T_{24}(0,4)$, tj. přičíst další 4 členy.

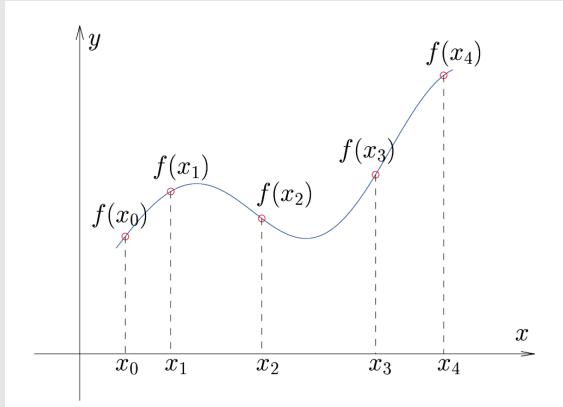
Poznámka:

Stejný postup lze užít i pro výpočet v bodech mimo interval $(-\pi, \pi)$. Stačí využít periodičnosti funkce $\sin x$.

Aproximace interpolačním polynomem

Aproximujeme funkci, která je dána svými hodnotami v $n+1$ bodech x_i , $i = 0, 1, \dots, n$ (body x_i nazýváme užly interpolací), a požadujeme, aby approximace (interpolačním polynomem) procházela zadánymi body.

Aproximace nám potom poslouží k získání přibližné hodnoty zadané funkce v libovolném bodě intervalu (x_0, x_n) .



Interpolační podmínky

$$P_n(x_i) = f(x_i), \quad i = 0, 1, \dots, n$$

Chyba $e(x) = f(x) - P_n(x)$ pak nabývá nulových hodnot v uzlech interpolace.

Věta Interpolační úloha má jediné řešení, pokud jsou uzly x_0, x_1, \dots, x_n navzájem různé.

Důkaz: Interpolační polynom uvažujeme ve tvaru

$$P_n(x) = \sum_{k=0}^n a_k x^k.$$

Dosazením do interpolačních podmínek získáme soustavu $(n+1)$ lineárních rovnic pro koeficienty a_0, a_1, \dots, a_n .

$$\sum_{k=0}^n a_k x_i^k = f(x_i) \quad i = 0, 1, \dots, n$$

Matrice soustavy (Vandermondova matice):

$$V = \begin{bmatrix} 1 & x_0 & x_0^2 & \dots & x_0^n \\ 1 & x_1 & x_1^2 & \dots & x_1^n \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_n & x_n^2 & \dots & x_n^n \end{bmatrix}$$

Soustava má právě jedno řešení, pokud $\det V \neq 0$.

Matici soustavy převedeme na trojúhelníkový tvar

- přičtením násobku řádku k jinému řádku se determinant nezmění
- vynásobíme-li řádek číslem α , pak je determinant α násobkem původního

Od 2. až $(n+1)$ -ního řádku odečteme 1. řádek.

$$V \sim \begin{bmatrix} 1 & x_0 & x_0^2 & x_0^3 & \dots & x_0^n \\ 0 & x_1 - x_0 & x_1^2 - x_0^2 & x_1^3 - x_0^3 & \dots & x_1^n - x_0^n \\ 0 & x_2 - x_0 & x_2^2 - x_0^2 & x_2^3 - x_0^3 & \dots & x_2^n - x_0^n \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & x_n - x_0 & x_n^2 - x_0^2 & x_n^3 - x_0^3 & \dots & x_n^n - x_0^n \end{bmatrix}$$

Vynormujeme – $(j+1)$ -ní řádek vydělíme $(x_j - x_0)$, $j = 1, 2, \dots, n$.

$$V \sim \begin{bmatrix} 1 & x_0 & x_0^2 & x_0^3 & \dots & x_0^n \\ 0 & 1 & \frac{x_1^2 - x_0^2}{x_1 - x_0} & \frac{x_1^3 - x_0^3}{x_1 - x_0} & \dots & \frac{x_1^n - x_0^n}{x_1 - x_0} \\ 0 & 1 & \frac{x_2^2 - x_0^2}{x_2 - x_0} & \frac{x_2^3 - x_0^3}{x_2 - x_0} & \dots & \frac{x_2^n - x_0^n}{x_2 - x_0} \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 1 & \frac{x_n^2 - x_0^2}{x_n - x_0} & \frac{x_n^3 - x_0^3}{x_n - x_0} & \dots & \frac{x_n^n - x_0^n}{x_n - x_0} \end{bmatrix}$$

od 3. až $(n+1)$ -ního řádku odečteme 2. řádek

$$V \sim \begin{bmatrix} 1 & x_0 & x_0^2 & x_0^3 & \dots & x_0^n \\ 0 & 1 & x_1 + x_0 & x_1^2 + x_1 x_0 + x_0^2 & \dots & \dots \\ 0 & 0 & x_2 - x_1 & (*) & \dots & \dots \\ 0 & 0 & x_3 - x_1 & (**) & \dots & \dots \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & x_n - x_1 & \dots & \dots & \dots \end{bmatrix}$$

$$(*) = \frac{x_2^2 - x_0^2}{x_2 - x_0} \cdot \frac{x_1^2 - x_0^2}{x_1 - x_0} = (x_2^2 + 2x_2x_0 + x_0^2) - (x_1^2 + 2x_1x_0 + x_0^2) = x_2^2 - x_1^2 + x_0(x_2 - x_1) = (x_2 - x_1)(x_2 + x_1 + x_0)$$

$$(**) = \frac{x_3^2 - x_0^2}{x_3 - x_0} \cdot \frac{x_1^2 - x_0^2}{x_1 - x_0} = (x_3^2 + 2x_3x_0 + x_0^2) - (x_1^2 + 2x_1x_0 + x_0^2) = x_3^2 - x_1^2 + x_0(x_3 - x_1) = (x_3 - x_1)(x_3 + x_1 + x_0)$$

Vynormujeme – $(j+1)$ -ní řádek vydělíme $(x_j - x_i)$, $j = 2, 3, \dots, n$.

$$\mathbf{V} \sim \begin{bmatrix} 1 & x_0 & x_0^2 & x_0^3 & \dots & x_0^n \\ 0 & 1 & x_1 + x_0 & x_1^2 + x_1x_0 + x_0^2 & \dots & \dots \\ 0 & 0 & 1 & x_2 + x_1 + x_0 & \dots & \dots \\ 0 & 0 & 1 & x_3 + x_1 + x_0 & \dots & \dots \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 1 & x_n + x_1 + x_0 & \dots & \dots \end{bmatrix}$$

Získáme trojúhelníkovou matici s jedničkami na diagonále, tj. výsledná matice má determinant roven 1.

Při úpravách jsme dělili $(x_j - x_i)$, $j > i$

$$\Rightarrow \det \mathbf{V} = \prod_{j>i}^n (x_j - x_i)$$

$$\det \mathbf{V} \neq 0 \Leftrightarrow x_i \neq x_j \quad \forall i \neq j$$

□

Lagrangeův interpolační polynom

Označme si hledaný polynom n -tého stupně $L_n(x)$.

Víme, že musí být splněny interpolační podmínky

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

Lagrangeův interpolační polynom hledáme ve tvaru

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

kde $l_i(x)$ jsou polynomy n -tého stupně takové, že platí

$$l_i(x_j) = \delta_{ij} = \begin{cases} 1, & i=j \\ 0, & i \neq j \end{cases}$$

(snadno se přesvědčíte, že dosadíte-li do předpisu pro $L_n(x)$ užly interpolace, získáte zadané interpolační podmínky).

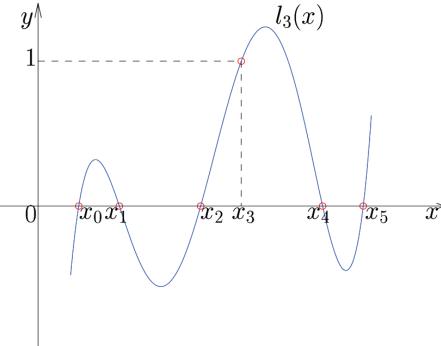
Konkretizujeme nyní dílčí polynomy $l_i(x)$.

Víme, že $l_i(x)$ má kořeny $x_0, x_1, x_{i-1}, x_{i+1}, \dots, x_n$ a nabývá hodnoty 1 v bodě x_i .

Můžeme jej tedy zapsat ve tvaru

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

Na obrázku je ukázán příklad dílčího polynomu $l_3(x)$:



Newtonův interpolační polynom

Označme si hledaný polynom n -tého stupně $N_n(x)$.

Pro jeho odvození použijeme jinou konstrukci. Polynom volíme ve tvaru

$$N_n(x) = a_0 + a_1(x - x_0) + a_2(x - x_0)(x - x_1) + \dots + a_n(x - x_0)(x - x_1) \dots (x - x_{n-1})$$

Opet požadujeme splnění interpolačních podmínek

$$N_n(x_i) = f(x_i), \quad i = 0, 1, \dots, n.$$

Poznámka: Výhodou volby tohoto zdálivného složitého předpisu je fakt, že přidáme-li další bod interpolace $[x_{n+1}; f(x_{n+1})]$, nemusíme celý výpočet opakovat, ale stačí dopočítat příslušný koeficient a_{n+1} (ostatní koeficienty a_i zůstávají beze změny). Při použití Lagrangeova polynomu bychom museli celý výpočet provést znovu.

Ukažme si, co dostaneme dosazováním interpolačních podmínek do předpisu polynomu:

$$N_n(x_0) = a_0 = f(x_0)$$

$$N_n(x_1) = a_0 + a_1(x_1 - x_0) = f(x_1) \Rightarrow a_1 = \frac{f(x_1) - f(x_0)}{x_1 - x_0}$$

$$N_n(x_2) = a_0 + a_1(x_2 - x_0) + a_2(x_2 - x_0)(x_2 - x_1) = f(x_2)$$

$$\Rightarrow a_2 = \frac{f(x_2) - f(x_0) - a_1 \frac{(x_2 - x_0)}{(x_2 - x_0)(x_2 - x_1)}}{(x_2 - x_0)(x_2 - x_1)} =$$

$$= \frac{f(x_2) - f(x_0) - \frac{f(x_1) - f(x_0)}{x_1 - x_0}(x_2 - x_1) - \frac{f(x_1) - f(x_0)}{x_1 - x_0}(x_1 - x_0)}{(x_2 - x_0)(x_2 - x_1)} =$$

$$= \frac{f(x_2) - f(x_1) - \frac{f(x_1) - f(x_0)}{x_1 - x_0}(x_2 - x_1)}{(x_2 - x_0)(x_2 - x_1)}$$

$$\Rightarrow a_2 = \frac{\frac{f(x_2) - f(x_1)}{x_2 - x_1} - \frac{f(x_1) - f(x_0)}{x_1 - x_0}}{x_2 - x_0}$$

Poznámka:

Počítat koeficienty a_i přímo ze soustavy není praktické, budeme je počítat pomocí tzv. **poměrných diferencí**.

Algoritmus (koeficienty Newtonova polynomu)

Pro $i = 0, 1, \dots, n$

$$A_{i0} = f(x_i)$$

Pro $k = 1, 2, \dots, i$

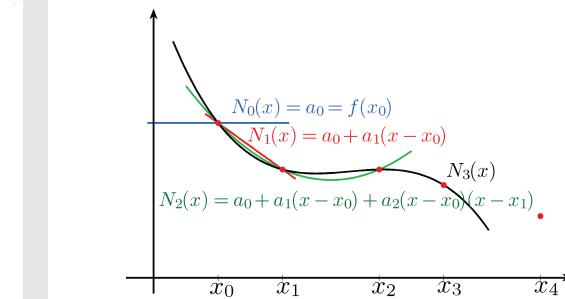
$$A_{ik} = \frac{A_{i,k-1} - A_{i-1,k-1}}{x_i - x_{i-k}}$$

Výstup: A_{ii}

Schéma algoritmu

$$\begin{array}{ll} x_0 | f(x_0) = A_{00} = a_0 \\ x_1 | f(x_1) = A_{10} \quad A_{11} = a_1 \\ x_2 | f(x_2) = A_{20} \quad A_{21} \quad A_{22} = a_2 \\ \vdots \quad \vdots \quad \vdots \quad \vdots \\ x_n | f(x_n) = A_{n0} \quad A_{n1} \quad A_{n2} \quad \dots \quad A_{nn} = a_n \end{array}$$

Poznámka: Vezmu-li z matice A pouze prvních M řádků znamená to, že jsem sestavil Newtonův polynom pro pouze prvních M zadaných tabulkových bodů.



$$N_0(x) = a_0 \quad \text{prochází bodem } [x_0, f(x_0)]$$

$$N_1(x) = a_0 + a_1(x - x_0)$$

prochází bodem $[x_0, f(x_0)]$ a směrnicí má takovou, aby procházel také bodem $[x_1, f(x_1)]$

$$N_2(x) = a_0 + a_1(x - x_0) + a_2(x - x_0)(x - x_1)$$

prochází bodem $[x_0, f(x_0)]$, dále jelikož platí $N_2(x_1) = N_1(x_1)$, prochází i bodem $[x_1, f(x_1)]$ a navíc prochází bodem $[x_2, f(x_2)]$.

$$N_3(x) = \underbrace{a_0 + a_1(x - x_0) + a_2(x - x_0)(x - x_1)}_{(*)} + \underbrace{a_3(x - x_0)(x - x_1)(x - x_2)}_{(**)}$$

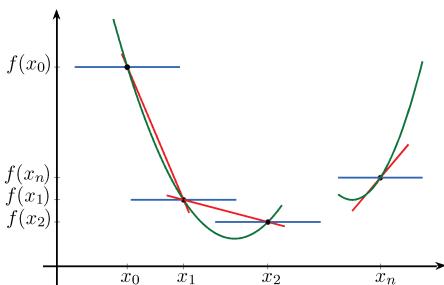
(*) prochází $[x_0, f(x_0)]$

(**) přidáme tento člen tak, aby se zachoval průchod $[x_0, f(x_0)]$ (hodnota pro $x = x_0$ je 0), a_3 se určí tak, aby procházel $[x_1, f(x_1)]$

(***) přidáme tento člen tak, aby se zachoval průchod $[x_0, f(x_0)]$ a $[x_1, f(x_1)]$ (hodnota člena pro $x = x_0$ a $x = x_1$ je nulová), a_2 se určí tak, aby procházel bodem $[x_2, f(x_2)]$

Co znamenají jednotlivá čísla v tabulce?

x_0	$f(x_0) = A_{00}$
x_1	$f(x_1) = A_{10} \quad A_{11}$
x_2	$f(x_2) = A_{20} \quad A_{21} \quad A_{22}$
\vdots	$\vdots \quad \vdots \quad \vdots$
x_n	$f(x_n) = A_{n0} \quad A_{n1} \quad A_{n2}$



Věta Má-li funkce f , k níž přísluší data $f(x_i)$, $i = 0, 1, \dots, n$, spojité derivace v nějakém intervalu $(a, b) \supset \text{int}(x_0, x_1, \dots, x_n)$ do řádu n a derivaci $f^{(n+1)}(x)$ v (a, b) , potom $\forall x \in (a, b) \exists \xi \in (a, b)$ tak, že pro chybu interpolačního polynomu $P_n(x)$ platí:

$$e(x) = f(x) - P_n(x) = \frac{f^{(n+1)}(\xi)}{(n+1)!} (x-x_0)(x-x_1)\dots(x-x_n) \quad \text{polynom } (n+1) \text{ stupně}$$

(Důkaz pomocí věty o střední hodnotě, viz dále.)

Odhad chyby interpolace

Umíme-li stanovit číslo M takové, že $\forall x \in (a, b)$ je $|f^{(n+1)}(x)| \leq M$, pak

$$|e(x)| \leq \frac{M}{(n+1)!} |w(x)| \leq \frac{M}{(n+1)!} \max_{x \in (a,b)} |w(x)|.$$

kde jsme označili $w(x) = (x-x_0)(x-x_1)\dots(x-x_n)$.

\Rightarrow Průběh chyby nezávisí jen na $f^{(n+1)}(x)$, ale i na $w(x)!$

Důkaz: Zvolme bod $x \neq x_i$, $i = 0, 1, \dots, n$ libovolně. Definujme funkci

$$F(t) = f(t) - P_n(t) - \frac{f(x) - P_n(x)}{w_{n+1}(x)} w_{n+1}(t).$$

⊗⊗

Tato funkce proměnné t má $n+2$ nulových bodů:

- x_i , $i = 0, 1, \dots, n$:

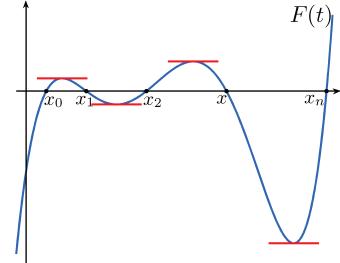
$$F(x_i) = \frac{f(x_i) - P_n(x_i)}{w_{n+1}(x_i)} - \frac{f(x) - P_n(x)}{w_{n+1}(x)} \frac{w_{n+1}(x_i)}{w_{n+1}(x)} = 0$$

- x :

$$F(x) = f(x) - P_n(x) - \frac{f(x) - P_n(x)}{w_{n+1}(x)} w_{n+1}(x) = 0$$

Použijeme-li $(n+1)$ krát **Rollovu větu** zjistíme, že první derivace $F'(t)$ má v (a, b) alespoň $n+1$ nulových bodů.

Rollova věta: Nechť $f(x)$ je v (a, b) spojitá a má v (a, b) derivaci. Nechť $f(a) = f(b)$. Pak existuje alespoň 1 bod $c \in (a, b)$ tak, že $f'(c) = 0$.



Pokračujeme dál a aplikujeme nyní **Rollovu větu** na funkci $F'(t)$ a zjistíme, že $F''(t)$ má v (a, b) alespoň n nulových bodů, atd.

⋮

$F^{(n+1)}(t)$ má v (a, b) alespoň jeden nulový bod a ten označíme $\xi = \xi(x)$.

Vztah ⊗⊗ zdeřívujeme $(n+1)$ krát podle t :

$$\overbrace{F^{(n+1)}(t)}_{(*)} = f^{(n+1)}(t) - \underbrace{\frac{P_n^{(n+1)}(t)}{w_{n+1}(t)}}_{=0 (\bullet\bullet)} - \frac{f(x) - P_n(x)}{w_{n+1}(x)} \frac{w_{n+1}^{(n+1)}(t)}{=(n+1)! (\bullet\bullet)}$$

(*) Víme, že existuje ξ tak, že $F^{(n+1)}(\xi) = 0$

(**) P_n ... polynom n -tého stupně

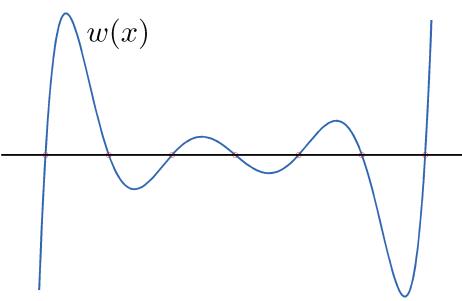
(***) $w_{n+1}(t)$ je polynom $(n+1)$ stupně a u t^{n+1} je koeficient 1

$$0 = f^{(n+1)}(\xi) - \frac{f(x) - P_n(x)}{w_{n+1}(x)} (n+1)! \Rightarrow f(x) - P_n(x) = \frac{f^{(n+1)}(\xi)}{(n+1)!} w_{n+1}(x)$$

□

• Pokud interpolujeme funkci zadanou u ekvidistantních uzlích, mohou mít nepřesnosti ve vstupních datach silný vliv na hodnotu výsledku → úloha je špatně podmíněná

Poznámka: Špatná podmíněnost platí tím více i pro extrapolaci.



• Dobrou strategii je volit x_i tak, aby byly rozloženy stejně jako kořeny Čebyševových polynomů → minimalizuje se tak hodnota $\max |w(x)|$.

Definice (Čebyševa approximace)

K dané spojité funkci $f(x)$, $x \in (a, b)$, chceme najít mezi všemi polynomy $P_n(x)$ stupně nejvýše n takový polynom $P_n^*(x)$, který splňuje:

$$\max_{x \in (a,b)} |f(x) - P_n^*(x)| = \min_{P_n(x)} \max_{x \in (a,b)} |f(x) - P_n(x)|.$$

Poznámka:

Při volbě ekvidistantních uzlů byla úloha špatně podmíněná.

Při vhodné volbě uzlů (kořeny tzv. **Čebyševových polynomů** - viz dále ☺) má interpolační proces pro $n \rightarrow \infty$ vlastnost, že interpolační polynomy konvergují na (a, b) **stejnoměrně** k approximované funkci např. v případě, když existuje spojité první derivace f' na (a, b) .

Stejnoměrná konvergence funkce f_n definované na (a, b)

- varianta 1: posloupnost $\{f_n\}$ je na (a, b) stejnoměrně konvergentní

$$\Leftrightarrow \forall \varepsilon > 0 \exists n_0 \in \mathbb{N}: \text{stejně } \forall x \in (a, b) \text{ tak, že}$$

$$\forall n > n_0 \text{ a } \forall x \in (a, b) : |f_n(x) - f(x)| < \varepsilon$$

- varianta 2: posloupnost $\{f_n\}$ je na (a, b) stejnoměrně konvergentní

$$\Leftrightarrow \lim_{n \rightarrow \infty} \sup_{x \in (a,b)} |f_n(x) - f(x)| = 0$$

Čebyševovy polynomy

$$T_0(x) = 1$$

$$T_1(x) = x$$

$$T_{n+1} = 2x T_n(x) - T_{n-1}(x) \quad \spadesuit$$

Užijeme-li substituci $x = \cos \alpha$, $\alpha = \arccos x$ a goniometrické vzorce, dostaneme

$$T_n(x) = \cos(n \arccos x) \quad x \in (-1, 1) \quad \clubsuit$$

Důkaz:

$$T_0(x) = \cos(0 \arccos x) = 1 \quad \checkmark$$

$$T_1(x) = \cos(1 \arccos x) = x \quad \checkmark$$

$$T_n = \cos(n \arccos x) \quad \dots \quad \text{dosadíme do vztahu} \quad \clubsuit$$

$$\cos((n+1) \arccos x) = 2x \cos(n \arccos x) - \cos((n-1) \arccos x) \quad \clubsuit$$

Platí:

$$\cos \alpha + \cos \beta = 2 \cos \frac{\alpha + \beta}{2} \cos \frac{\alpha - \beta}{2} \quad \checkmark$$

Kořeny polynomů jsou

$$\cos(n \arccos x) = 0$$

$$n \arccos x = \frac{\pi}{2} + k\pi, \quad k \in \mathbb{Z}$$

$$\arccos x_k = \frac{2k+1}{n} \cdot \frac{\pi}{2}$$

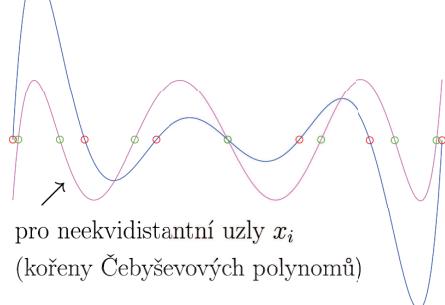
$$x_k = \cos\left(\frac{2k+1}{n} \cdot \frac{\pi}{2}\right), \quad k = 0, 1, \dots, n-1$$

Poznámka: Pro obecný interval $\langle a, b \rangle$ používáme transformaci

$$r_k = \frac{b-a}{2} x_k + \frac{a+b}{2}.$$

$$w(x) = (x - x_0)(x - x_1) \dots (x - x_N)$$

\leftarrow pro ekvidistantní uzly x_i



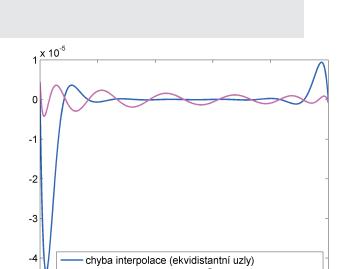
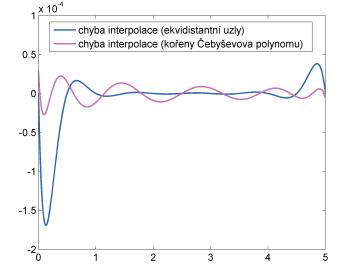
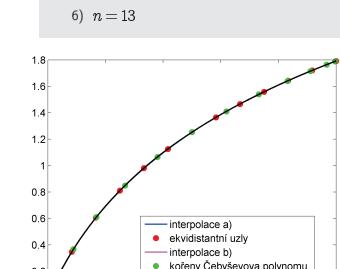
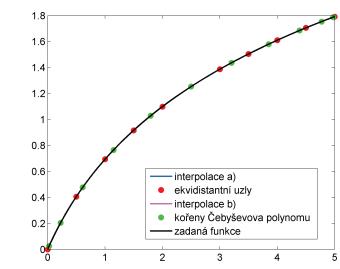
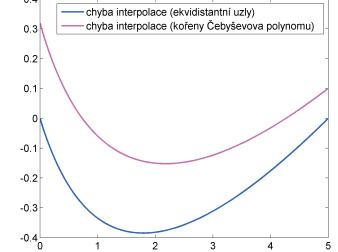
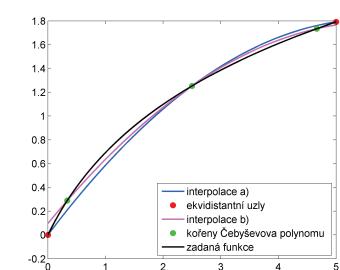
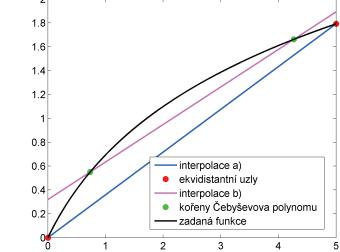
Příklad

Uvažujme funkci $f(x) = \ln(x+1)$ zadanou na intervalu $(0, 5)$.

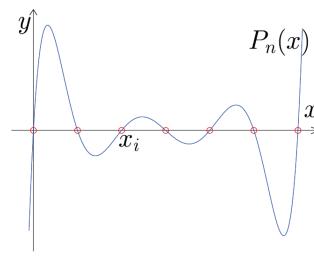
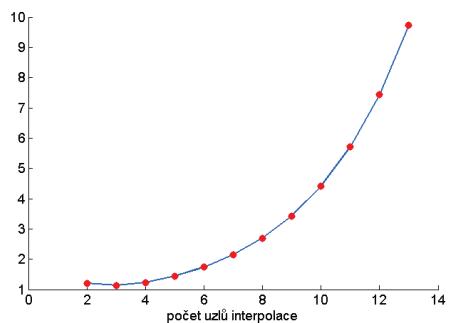
Pro zvolený počet n uzlových bodů proveděte interpolaci zadané funkce pro uzlové body, které jsou
a) ekvidistantní,
b) kořeny Čebyševových polynomů.

Porovnejte chybu získaných interpolačních polynomů.

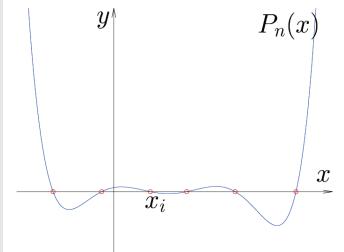
1) $n = 2$



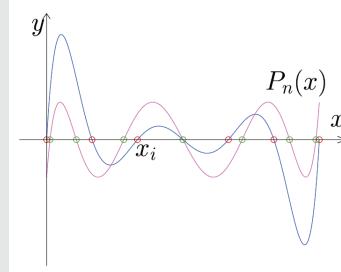
Následující obrázek ukazuje poměr maximové normy chyby interpolačního polynomu vypočteného pro hodnoty v ekvidistantních uzlech k maximové normě chyby interpolačního polynomu vypočteného pro hodnoty v uzlech určených jakožto kořeny Čebyševových polynomů.

**Poznámka:**

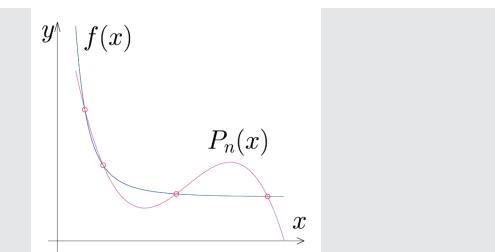
Použijeme-li vhodné zvolené neekvidistantní uzly, můžeme amplitudu chyby minimalizovat.
(Vhodnou volbou jsou uzly zvolené jako kořeny tzv. Čebyševových polynomů.)

**Poznámka:**

Není obecně vhodné interpolovat polynomem funkci, která je dáná velkým počtem svých hodnot. Stupeň interpolacního polynomu by potom byl velký.

**Poznámka:**

Interpolace polynomem není obecně vhodná např. pro funkce, které mají asymptotu.

**Poznámka:**

Princip Nevilleova algoritmu je ukázán v následujícím příkladu.

Příklad Vypočtěte $f(3,5)$, kde funkce $f(x)$ je dáná tabulkou:

x_i	1	2	4	5
$f(x_i)$	1	8	64	125

Řešení:

Uzly x_i je vhodné uspořádat podle rostoucí vzdálenosti od bodu α , v němž chceme stanovit přibližnou hodnotu funkce $f(x)$. Podle rozdílu hodnot $P_{i,i}$ a $P_{i-1,i-1}$ ($i = 1, \dots, n$) lze rozhodnout o předčasném ukončení Nevilleova algoritmu, popř. o hodnoty interpolace pomocí $N_n(x)$.

$\alpha - x_i$	x_i	$f(x_i)$			
-0,5	4	64			
1,5	2	8	$8 + 1,5 \frac{8 - 64}{2 - 4} = 50$		
-1,5	5	125	$125 - 1,5 \frac{125 - 8}{5 - 2} = 66,5$	$66,5 - 1,5 \frac{66,5 - 50}{5 - 4} = 41,75$	
2,5	1	1	$1 + 2,5 \frac{1 - 125}{1 - 5} = 78,5$	$78,5 + 2,5 \frac{78,5 - 66,5}{1 - 2} = 48,5$	$48,5 + 2,5 \frac{48,5 - 78,5}{1 - 4} = 42,875$

Z následujících obrázků je patrný význam hodnot, které dostáváme na diagonále.

Poznámka:

Vyjděme z předpokladu, že máme přibližně interpolovat hodnotu tabulkou dané funkce v libovolném bodě. Pokud nutně netrváme na tom, že v tomto bodě chceme přesně určit hodnotu interpolacního polynomu procházející všemi tabulkovými body, přistupujeme k Nevilleovu algoritmu iterativně, tj. pokud bude rozdíl po sobě jdoucích diagonálních prvků dostatečně malý, ukončíme výpočet.

V tomto případě je ovšem rozumné seřadit uzlové body podle rostoucí vzdálenosti od zadaného bodu, ve kterém interpolujeme hodnotu funkce.

V následujících příkladech jsou demonstrovány výsledky pro stejně zadání, ovšem při použití různých seřazení uzlových bodů:

- 1) od nejbližšího po nejvzdálenější,
- 2) od nejvzdálenějšího po nejbližší.

Příklad 1 Interpolujte hodnotu zadané funkce f v bodě $\alpha = 3,6$.

Při vhodném uzávorkování můžeme výpočet zefektivnit (zmenšíme počet operací sčítání a násobení):

$$N_n(\alpha) = a_0 + (\alpha - x_0) [a_1 + (\alpha - x_1) [a_2 + (\alpha - x_2) [a_3 + \dots [a_n]]]].$$

Tento postup můžeme samozřejmě použít jen tehdy, když už známe koeficienty a_i .

Chceme-li vypočítat pouze hodnotu polynomu $N_n(\alpha)$ v bodě α za co nejmenšího počtu operací a nepotřebujeme-li koeficienty a_i , použijeme tzv. **Nevilleův algoritmus**.

Princip je podobný jako v algoritmu pro určení koeficientů Newtonova polynomu.

Nevilleův algoritmus

$$1. P_{i,0} = f(x_i), \quad i = 0, 1, \dots, n$$

$$2. P_{i,k} = P_{i,k-1} + (\alpha - x_i) \frac{P_{i,k-1} - P_{i-1,k-1}}{x_i - x_{i-k}},$$

x_i	1	2	3	4	5	6	7
$f(x_i)$	-5	14	19	16	12	14	35

Výsledky Nevilleova algoritmu, když uvažujeme uzly seřazené podle vzdálenosti od α **vzestupně**:

výsledky získané v MATLABu

$x(k)$	$f(x_k)$	Aproximace $f(\alpha)$
4.0000	16.0000	
3.0000	19.0000	17.2000
5.0000	12.0000	16.9000
2.0000	14.0000	12.9333
6.0000	14.0000	14.0000
1.0000	-5.0000	4.8800
7.0000	35.0000	12.3333
		-13.0080
		15.2800
		18.9574
		17.6901

Příklad 2 Interpolujte hodnotu zadané funkce f v bodě $\alpha = 3,6$.

x_i	1	2	3	4	5	6	7
$f(x_i)$	-5	14	19	16	12	14	35

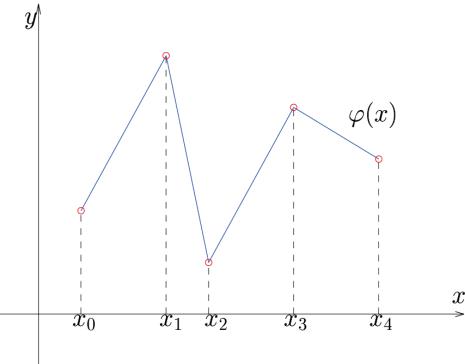
Výsledky Nevilleova algoritmu, když uvažujeme uzly seřazené podle vzdálenosti od α **sestupně**:

výsledky získané v MATLABu

$x(k)$	$f(x_k)$	Aproximace $f(\alpha)$
7.0000	35.0000	
1.0000	-5.0000	12.3333
6.0000	14.0000	4.8800
2.0000	14.0000	14.0000
5.0000	12.0000	12.9333
3.0000	19.0000	16.9000
4.0000	16.0000	17.2000
		17.3200
		17.7120
		17.7228
		17.6901

Poznámka

Jak se dá interpretovat libovolná (tj. i nediagonální) hodnota v trojúhelníkové matici, kterou získáváme Nevilleovým algoritmem?



Máme dánou funkci f tabulkou hodnot $\{x_i, f_i\}$, $i = 0, 1, \dots, n$.

Funkci $s(x)$ definovanou na intervalu $\langle x_0, x_n \rangle$ nazýváme **lineární spline interpolaci** funkce $f(x)$, má-li následující vlastnosti:

(i) na každém intervalu $\langle x_i, x_{i+1} \rangle$, $i = 0, 1, \dots, n-1$ je polynom prvního stupně, tj.

$$s(x) = s_i(x), \quad x \in \langle x_i, x_{i+1} \rangle, \quad \text{kde } s_i(x) = a_i + b_i(x - x_i)$$

(ii) splňuje interpolační podmínky $s(x_i) = f(x_i)$, tj.

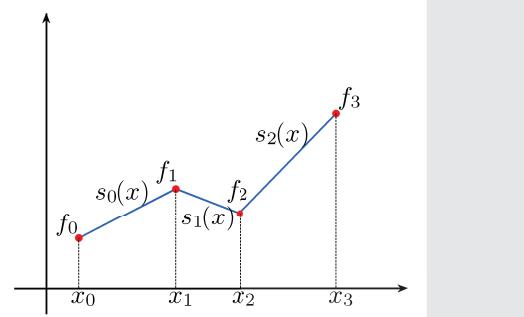
$$\begin{aligned} s_i(x_i) &= f_i, \quad i = 0, 1, \dots, n-1 \\ s_{n-1}(x_n) &= f_n \end{aligned}$$

(iii) je spojitá na $\langle x_0, x_n \rangle$, tj. i v uzlech x_i

$$s_i(x_{i+1}) = s_{i+1}(x_{i+1}), \quad i = 0, 1, \dots, n-2$$

Interpolace spline funkcemi

Nejjednodušší spline funkci je tzv. **lineární spline funkci**; jde vlastně o lomenou čáru spojující zadané interpolované body.



Poznámka: Těmito požadavky je funkce $s(x)$ určena jednoznačně.

(i) ... hledáme $2n$ koeficientů a_i a b_i

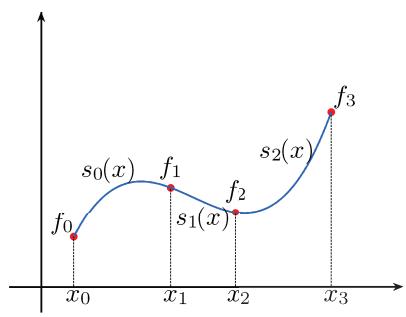
(ii) představuje $(n+1)$ podmínek

(iii) představuje $(n-1)$ podmínek

Platí:
$$s_i(x) = f_i + \frac{f_{i+1} - f_i}{h_i} (x - x_i), \quad h_i = x_{i+1} - x_i, \quad i = 0, 1, \dots, n-1$$

Pokud bychom chtěli, aby byla approximace spline funkci hladká, musíme použít polynom vyššího stupně než 1.

Nejvíce používanou je tzv. **kubická spline interpolace**, která používá polynomy 3 stupně.



Poznámejme zde, že ostatní volby stupně polynomů nepřináší lepší výsledky a výpočty jsou v případě vyšších stupňů složitější.

Kubická spline interpolace

Funkci f je dáná tabulkou $\{x_i, f_i\}$, $i = 0, 1, \dots, n$.

Funkci $s(x)$ definovanou na intervalu $\langle x_0, x_n \rangle$ nazýváme **kubickou spline interpolaci** funkce f , má-li následující vlastnosti:

(i) je na každém intervalu $\langle x_i, x_{i+1} \rangle$, $i = 0, 1, \dots, n-1$ polynomem 3. stupně ve tvaru

$$s_i(x) = a_i + b_i(x - x_i) + \frac{c_i}{2}(x - x_i)^2 + \frac{d_i}{6}(x - x_i)^3$$

(ii) splňuje interpolační podmínky $s(x_i) = f(x_i)$, tj.

$$\begin{aligned} s_i(x_i) &= f_i, \quad i = 0, 1, \dots, n-1 \\ s_{n-1}(x_n) &= f_n \end{aligned}$$

(iii) je spojitá na $\langle x_0, x_n \rangle$, tj. v uzlech x_i platí

$$s_i(x_{i+1}) = s_{i+1}(x_{i+1}), \quad i = 0, 1, \dots, n-2$$

(iv) má spojitu první derivaci na $\langle x_0, x_n \rangle$

$$s'_i(x_{i+1}) = s'_{i+1}(x_{i+1}), \quad i = 0, 1, \dots, n-1$$

(v) má spojitu druhou derivaci na $\langle x_0, x_n \rangle$

$$s''_i(x_{i+1}) = s''_{i+1}(x_{i+1}), \quad i = 0, 1, \dots, n-2$$

Funkce $s(x)$ není podmínkami (ii) – (v) určena jednoznačně:

- (ii) ... $(n+1)$ podmínek
 - (iii) ... $(n-1)$ podmínek
 - (iv) ... $(n-1)$ podmínek
 - (v) ... $(n-1)$ podmínek
- celkem ... $4n-2$ podmínek; (počet koeficientů je ale $4n$)

2 podmínky je nutno dodat:

(A) přirozené podmínky

$$s'(x_0) = s''(x_n) = 0$$

(B) podmínky periodicity (s periodou $T = x_n - x_0$)

$$s(x_0) = s(x_n) \quad \dots \text{ splňena automaticky } (f_0 = f_n)$$

$$[s(x_0) = s'(x_n), \quad s''(x_0) = s''(x_n)]$$

(C) podmínky tečen

$$[s(x_0) = y'_0, \quad s'(x_n) = y'_n], \quad \text{kde } y'_0, y'_n \text{ jsou daná čísla}$$

(D) viz MATLAB

Konstrukce kubické spline funkce

Funkci $s(x)$ lze psát ve tvaru

$$s(x) = \eta_0 s_0(x) + \eta_1 s_1(x) + \dots + \eta_{n-1} s_{n-1}(x)$$

kde $\eta_i = \eta_i(x)$ jsou charakteristické funkce intervalu, tj.

$$\eta_i = 1 \text{ na } \langle x_i, x_{i+1} \rangle, \quad \eta_{n-1} = 1 \text{ na } \langle x_{n-1}, x_n \rangle$$

$$\eta_i = 0 \text{ jinde}$$

Snadno lze odvodit:

$$[s(x_i) = a_i, \quad s'(x_i) = b_i, \quad s''(x_i) = c_i, \quad s'''(x_i+) = d_i, \quad s'''(x_i-) = d_{i-1}]$$

Pomocí těchto vztahů přeplíšeme podmínky (ii) až (v) (označme $h_i = x_{i+1} - x_i$, $i = 0, 1, \dots, n-1$)

(ii) interpolaci podmínky

$$f_i = a_i, \quad i = 0, 1, \dots, n-1$$

$$f_n = a_{n-1} + b_{n-1} h_{n-1} + \frac{c_{n-1}}{2} h_{n-1}^2 + \frac{d_{n-1}}{6} h_{n-1}^3$$

(iii) spojitost

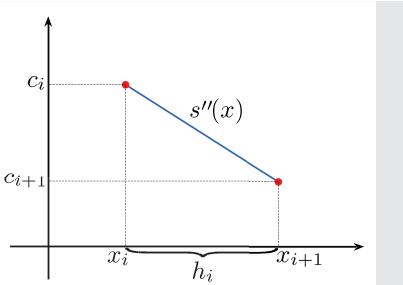
$$f_{i+1} = a_i + b_i h_i + \frac{c_i}{2} h_i^2 + \frac{d_i}{6} h_i^3, \quad i = 0, 1, \dots, n-2$$

$$[s_{i+1}(x_{i+1}) = s_i(x_{i+1})]$$

(iv) spojitost derivace

$$b_i + c_i h_i + \frac{d_i}{2} h_i^2 = b_{i+1}, \quad i = 0, 1, \dots, n-2$$

$$[s'_i(x_{i+1}) = s'_{i+1}(x_{i+1})]$$



Integrací ④ dostaneme

$$\begin{aligned} s_i(x) &= -\frac{c_i(x_{i+1}-x)^2}{2h_i} + \frac{c_{i+1}(x-x_i)^2}{2h_i} + A_i \\ s_i(x) &= c_i \frac{(x_{i+1}-x)^3}{6h_i} + c_{i+1} \frac{(x-x_i)^3}{6h_i} + A_i(x-x_i) + B_i \end{aligned} \quad ④④$$

Z interpolaci podmínek plyne $(s(x_i) = f_i)$:

$$B_i = f_i - \frac{c_i h_i^2}{6}$$

Pro $x = x_{i+1}$

$$f_{i+1} = c_{i+1} \frac{h_i^2}{6} + A_i h_i + f_i - \frac{c_i h_i^2}{6}$$

$$\Rightarrow A_i = \frac{f_{i+1} - f_i - (c_{i+1} - c_i) h_i}{h_i} \quad ④④④$$

Ze spojnosti první derivace $[s'_i(x_{i+1}) = s'_{i+1}(x_{i+1})]$, $i = 0, 1, \dots, n-2$ s užitím ④④ a ④④④ plyne

$$\begin{aligned} s'_i(x_{i+1}) &= \frac{h_i}{2} + \underbrace{\frac{f_{i+1} - f_i - (c_{i+1} - c_i) h_i}{h_i}}_{A_i} \underbrace{\frac{h_{i+1}^2}{2h_{i+1}}}_{A_{i+1}} + \underbrace{\frac{f_{i+2} - f_{i+1} - (c_{i+2} - c_{i+1}) h_{i+1}}{h_{i+1}}}_{A_{i+1}} \\ &= \frac{h_i}{2} + \frac{h_{i+1}}{3} + \frac{h_{i+1}}{2} - \frac{h_{i+1}}{6} \end{aligned}$$

$$\begin{aligned} c_i \frac{h_i}{6} + c_{i+1} \left(\frac{h_i}{2} - \frac{h_i}{6} + \frac{h_{i+1}}{2} - \frac{h_{i+1}}{6} \right) + c_{i+2} \frac{h_{i+1}}{6} &= \frac{f_{i+2} - f_{i+1} - (c_{i+2} - c_{i+1}) h_{i+1}}{h_{i+1}} - \frac{f_{i+1} - f_i}{h_i} \\ &= \frac{h_i}{3} = \frac{h_{i+1}}{3} \end{aligned}$$

Vynásobíme $\frac{6}{h_i + h_{i+1}}$ a dostaneme

(v) spojitost 2. derivace

$$c_i + d_i h_i = c_{i+1}, \quad i = 0, 1, \dots, n-2$$

$$[s''_i(x_{i+1}) = s''_{i+1}(x_{i+1})]$$

Z téhoto podmínek lze sestavit soustavu lineárních algebraických rovnic pro neznámé c_0, \dots, c_n a jejich prostřednictvím vypočítat b_0, \dots, b_n a d_0, \dots, d_n . Po úpravách dostaneme:

$$[\alpha_k c_{k-1} + 2c_k + \beta_k c_{k+1} = g_k, \quad k = 1, 2, \dots, n-1]$$

kde

$$\begin{aligned} \beta_k &= \frac{h_k}{h_k + h_{k-1}} \\ \alpha_k &= 1 - \beta_k \\ g_k &= \frac{6}{h_k + h_{k-1}} \left[\frac{f_{k+1} - f_k}{h_k} - \frac{f_k - f_{k-1}}{h_{k-1}} \right] \end{aligned}$$

Vztahy představují soustavu $n-1$ rovnic pro $n+1$ neznámých. Pro jednoznačnost je třeba přidat jednu z podmínek (A), (B), (C). Soustava bude mít tvar:

$$\begin{bmatrix} 2 & \beta_0 & & & & \\ \alpha_1 & 2 & \beta_1 & & & \\ & \alpha_2 & 2 & \beta_2 & & \\ & & & \ddots & & \\ & & & & 2 & \beta_{n-1} \\ & & & & \alpha_n & 2 \end{bmatrix} \begin{bmatrix} c_0 \\ c_1 \\ c_2 \\ \vdots \\ c_{n-1} \\ c_n \end{bmatrix} = \begin{bmatrix} g_0 \\ g_1 \\ g_2 \\ \vdots \\ g_{n-1} \\ g_n \end{bmatrix} \quad (*)$$

(*) ... první a poslední řádek soustavy představuje podmínka (A) nebo (B).
... použít podmínky (C) znamená vyškrtnout 1. a poslední řádek a sloupec

Poznámka:

Matici soustavy je třídiagonální a ostře diagonálně dominantní ($\alpha_k + \beta_k = 1$). \Rightarrow je regulární \Rightarrow řešení.

Soustavu řešíme GEM pro třídiagonální matici.

Odvození třídiagonální matice pro výpočet koeficientů c_i

Druhá derivace $s''(x) = c_i + d_i(x - x_i)$ je lineární funkci, tj. známe-li $s''(x_i) = c_i$, pak na $\langle x_i, x_{i+1} \rangle$ můžeme psát

$$s''(x) = c_i \frac{x_{i+1} - x}{h_i} + c_{i+1} \frac{x - x_i}{h_i}.$$

(Ověření: $s''_i(x_i) = c_i$, $s''_i(x_{i+1}) = c_{i+1}$, $s''(x)$ je lineární.)

$$\frac{h_i}{h_i + h_{i+1}} c_i + 2c_{i+1} + \frac{h_{i+1}}{h_i + h_{i+1}} c_{i+2} = \frac{6}{h_i + h_{i+1}} \left(\frac{f_{i+2} - f_{i+1}}{h_{i+1}} - \frac{f_{i+1} - f_i}{h_i} \right)$$

Minimální vlastnost a odhad chyby

Označme $S_1((a, b))$ množinu funkcí f , které splňují podmínky (ii) až (v) a podmínek (A) a jsou navíc na $\langle a, b \rangle$ integrovatelné s kvadrátem. Mezi všechny funkciemi $f \in S_1((a, b))$ právě **přirozený kubický spline** udílí nejménší hodnotu integrálu

$$J(f) = \int_a^b |f''(x)|^2 dx.$$

$J(f) \dots$ míra celkové křivosti křivky $y = f(x)$.

Věta

Nechť funkce f má spojité derivace až do řádu 4 a má omezenou 4. derivaci pro $x \in \langle a, b \rangle$. Nechť dále platí:

$$\frac{h}{h_i} \leq K, \quad i = 0, 1, \dots, n-1, \quad h = \max_i |x_{i+1} - x_i|$$

Když $s(x)$ je splyne interpolace funkce f v bodech x_i a splňuje podmínky $s'(a) = f'(a), s'(b) = f'(b)$, potom pro $x \in \langle a, b \rangle$ platí:

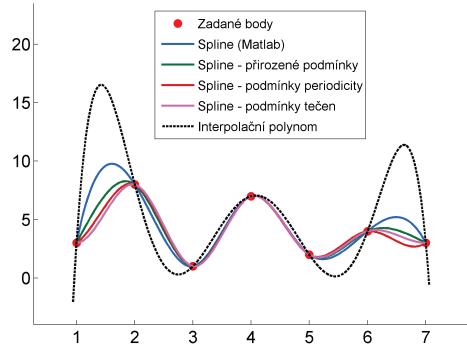
$$\begin{aligned} |f(x) - s(x)| &\leq c_1 K h^4 \\ |f'(x) - s'(x)| &\leq c_2 K h^3 \\ |f''(x) - s''(x)| &\leq c_3 K h^2. \end{aligned}$$

Příklad

Určete kubický spline pro funkci zadánou tabulkou

x_i	1	2	3	4	5	6	7
$f(x_i)$	3	8	1	7	2	4	3

Použijte různé dodatečné podmínky. Pro splíne s podmínkami tečen použijte $f'(1) = 0$ a $f'(7) = 0$.



Kapitola 8. Aproximace funkcí - II

Aproximace funkcí

- Aproximace na okolí bodu - approximujeme chování funkce „v malém okolí bodu“ ✓
- Interpolace - tabulkou danými body prokládáme polynom, tj. požadujeme-li, aby approximace přesně procházela zadanými body. ✓
- L_2 -approximace - použijeme, hledáme-li funkční závislost mezi tabulkou danými body (získaných například měřením), kde nutně nevyžadujeme, aby approximace danými body procházela. Důvodem může být např. chybou, se kterými jsme hodnoty naměřili.
- určíme systém jednoduchých **základních (bázových) funkcí** (ne nutně polynomů) $\varphi_0, \varphi_1, \varphi_2, \dots, \varphi_n$ a funkci f approximujeme lineární kombinací základních funkcí

$$\varphi(x) = c_0\varphi_0(x) + c_1\varphi_1(x) + \dots + c_n\varphi_n(x)$$

- Otázka výběru approximace se tedy převede na určení hodnot parametrů c_0, c_1, \dots, c_n podle nějakého kritéria vhodného pro konkrétní úlohu.

Poznámka: Velmi často budeme za základní funkce volit funkce $1, x, x^2, \dots, x^n$, tj. approximaci φ budeme hledat ve třídě polynomů nejvýše n -tého stupně.

Úvod d diskrétní L_2 -approximace

Myšlenka

Chceme approximovat funkci, která je dána tabulkou $\{[x_i, f(x_i)], i = 0, 1, \dots, n\}$.

V případě, kdy jsou $f(x_i)$ zatíženy chybou (např. výsledky měření) nebo pokud je bodů „mnoho“, není vhodné provádět interpolaci.

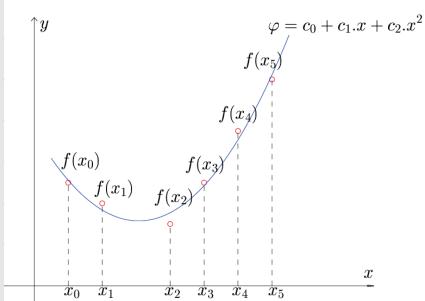
Aproximaci φ hledáme ve tvaru

$$\varphi(x) = c_0\varphi_0(x) + c_1\varphi_1(x) + \dots + c_m\varphi_m(x),$$

kde φ_i jsou zadané funkce a c_i hledané parametry.

- počet bázových funkcí φ_i je menší než počet zadaných bodů ($m < n$)
- v případě rovnosti se může jednat o interpolaci (záleží na zvolených bázových funkciích)
- o interpolaci se může jednat i pokud je $m < n$

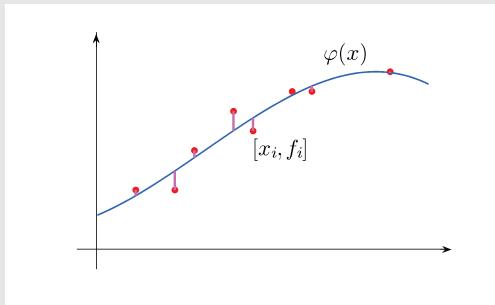
Naším cílem je minimalizovat „odchylku“ funkce φ od zadaných dat.



Uinterpolačí jsme požadovali, aby approximace přímo procházela zadanými body, tj. chyba

$$e_i = f(x_i) - \varphi(x_i) = 0$$

Nyní na tomto netrváme, pouze chceme tu chybu v nějakém smyslu minimalizovat.



Jakou použít normu pro měření chyby e ?

- $\max_{0 \leq i \leq n} \{|f(x_i) - \varphi(x_i)|\}$
- $\frac{1}{n+1} \sum_{i=0}^n |f(x_i) - \varphi(x_i)|$
- $\sqrt{\frac{1}{n+1} \sum_{i=0}^n |f(x_i) - \varphi(x_i)|^2}$

Cílem je chybu minimalizovat \Rightarrow vybereme tu normu, která umožní nejsnazší postup.

Uvažujme příklad:

$$\begin{array}{|c|c|c|} \hline x_i & 1 & 2 & 3 \\ \hline f(x_i) & 1 & 2 & 2 \\ \hline \end{array} \quad \varphi(x) = c_0 + c_1 x$$

Jak by vypadala minimalizace s užitím předešlých norem?

- $\min_{c_0, c_1 \in \mathbb{R}} \max \{|1 - c_0 - c_1|, |2 - c_0 - 2c_1|, |3 - c_0 - 3c_1|\} \dots$ pro počítání nevhodné
- $\min_{c_0, c_1 \in \mathbb{R}} \frac{1}{3} (|1 - c_0 - c_1| + |2 - c_0 - 2c_1| + |3 - c_0 - 3c_1|) \dots$ opět nevhodné
- $\min_{c_0, c_1 \in \mathbb{R}} \sqrt{\frac{1}{3} [(1 - c_0 - c_1)^2 + (2 - c_0 - 2c_1)^2 + (3 - c_0 - 3c_1)^2]} \dots$ zjednodušme

(Nezáporná funkce f nabývá svého minima ve stejném bodě jako nabývá minima funkce \sqrt{f})

$$\min_{c_0, c_1 \in \mathbb{R}} \sqrt{[(1 - c_0 - c_1)^2 + (2 - c_0 - 2c_1)^2 + (3 - c_0 - 3c_1)^2]} \quad (*)$$

(*) ... kvadratická funkce proměnných c_0, c_1 (konvexní) \Rightarrow je hladká, snadno se derivuje

Formulace

Je dána funkce f tabulkou hodnot v $n+1$ bodech x_0, x_1, \dots, x_n $\frac{x_i}{f(x_i)} \dots$

Zvolíme tvar approximující funkce

$$\varphi(x) = c_0\varphi_0(x) + c_1\varphi_1(x) + \dots + c_m\varphi_m(x)$$

s počtem parametrů c_i nejvýše rovným $n+1$.

Diskrétní L_2 -approximace funkce f je potom taková lineární kombinace bázových funkcí $\varphi_i(x)$, jejíž koeficienty splňují podmíinku, že L_2 norma chyby je minimální, tj.

$$R(f, \varphi) = \sum_{i=0}^n [f(x_i) - \varphi(x_i)]^2 = \sum_{i=0}^n \left[f(x_i) - \sum_{j=0}^m c_j \varphi_j(x_i) \right]^2$$

je minimální.

Poznámka:

Tato nejlepší approximace má velmi dobré statistické vlastnosti a vyrovnává vliv náhodných chyb v zadaných (naměřených) funkčních hodnotách.

Diskrétní L_2 -approximace lineárním polynomem

Úkolem je stanovit diskrétní L_2 -approximaci funkce f dané tabulkou $\{x_i, f_i\}, i = 0, 1, \dots, n$ lineárním polynomem, tj. zvolíme např. $\varphi(x) = 1, \varphi_1(x) = x$. Tedy

$$\varphi(x) = c_0 + c_1 x$$

Minimalizujeme funkci

$$R = \sum_{i=0}^n [f_i - c_0 - c_1 x_i]^2$$

Nutná a postačující podmínka minima je

$$\begin{aligned}\frac{\partial R}{\partial c_0} &= -2 \sum_{i=0}^n [f_i - c_0 - c_1 x_i] = 0 \\ \frac{\partial R}{\partial c_1} &= -2 \sum_{i=0}^n [f_i - c_0 - c_1 x_i] x_i = 0\end{aligned}$$

Koeficienty c_0 a c_1 nalezneme jako řešení soustavy

$$\begin{aligned}(n+1)c_0 + \left(\sum_{i=0}^n x_i\right)c_1 &= \sum_{i=0}^n f_i \\ \left(\sum_{i=0}^n x_i\right)c_0 + \left(\sum_{i=0}^n x_i^2\right)c_1 &= \sum_{i=0}^n f_i x_i\end{aligned}$$

Maticově zapsáno

$$Pc = q, \text{ kde } P \text{ je symetrická, pozitivně definitní.}$$

Jiný postup:

Užijeme metodu pro řešení „neřešitelných soustav“.

Plati (mělo by):

$$c_0 + c_1 x_i = f_i, \quad i = 0, 1, \dots, n$$

$$\begin{bmatrix} 1 & x_0 \\ 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_n \end{bmatrix} \begin{bmatrix} c_0 \\ c_1 \end{bmatrix} = \begin{bmatrix} f_0 \\ f_1 \\ f_2 \\ \vdots \\ f_n \end{bmatrix}$$

Maticově zapsáno

$$Qc = F$$

Soustava $Qc = F$ je neřešitelná. Provádíme minimalizaci $r^T r$, kde $r = F - Qc$ je reziduum soustavy. Dosadíme-li, pak platí:

$r^T r = (F - Qc)^T (F - Qc) = F^T F - c^T Q^T F - F^T Qc + c^T Q^T Qc = F^T F - 2c^T Q^T F + c^T Q^T Qc$, protože $\underbrace{(c^T Q^T F)^T}_{\text{číslo}} = \underbrace{(F^T Qc)^T}_{\text{číslo}}$

Matice $Q^T Q$ je symetrická, pozitivně definitní. Nutná a postačující podmínka minima:

$$Q^T Qc - Q^T F = 0 \Rightarrow Q^T Qc = Q^T F$$

tzv. **soustava normálních rovnic**.

Plati:

$$P = Q^T Q \quad \text{a} \quad q = Q^T F$$

Diskrétní L_2 -aproximace kvadratickým polynomem

Funkci f approximujeme kvadratickým polynomem

$$\varphi(x) = c_0 + c_1 x + c_2 x^2$$

Minimalizujeme veličinu

$$R = \sum_{i=0}^n [f_i - c_0 - c_1 x_i - c_2 x_i^2]^2$$

Z nutných a postačujících podmínek minima

$$\frac{\partial R}{\partial c_0} = 0, \quad \frac{\partial R}{\partial c_1} = 0, \quad \frac{\partial R}{\partial c_2} = 0$$

dostaneme soustavu ve tvaru

$$(n+1)c_0 + (\sum x_i)c_1 + (\sum x_i^2)c_2 = \sum f_i$$

$$(\sum x_i)c_0 + (\sum x_i^2)c_1 + (\sum x_i^3)c_2 = \sum f_i x_i$$

$$(\sum x_i^2)c_0 + (\sum x_i^3)c_1 + (\sum x_i^4)c_2 = \sum f_i x_i^2$$

Stejnou soustavu dostaneme i postupem, kdy řešíme neřešitelnou soustavu pomocí minimalizace kvadrátu rezidua.

Poznámka: V případě, že některé hodnoty chceme eliminovat, např. důsledkem špatného měření, je vhodné použít váhy, tj. minimalizovat

$$R(f, \varphi, w_i) = \sum_{i=0}^n [f(x_i) - \varphi(x_i)]^2 w_i,$$

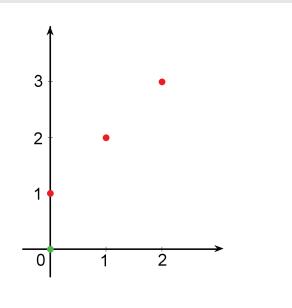
kde $w_i \dots$ váha uzlu x_i .

Příklad

Aproximujte funkci f , která je dána tabulkou

x_i	0	1	2
$f(x_i)$	1	2	3

pomocí funkce $\varphi(x) = c_0 x + c_1 x^2 + c_2 x^3$.



$$Qc = F, \quad Q \dots \text{singulární matice}$$

$$\begin{bmatrix} 0 & 0 & 0 \\ 1 & 1 & 1 \\ 2 & 4 & 8 \end{bmatrix} \begin{bmatrix} c_0 \\ c_1 \\ c_2 \end{bmatrix} = \begin{bmatrix} 1 \\ 2 \\ 3 \end{bmatrix}$$

• první rovnici nelze splnit \Rightarrow soustava nemá řešení

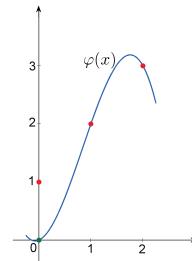
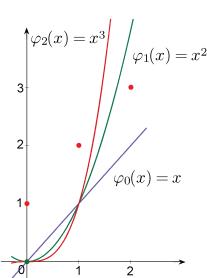
• řešíme metodou nejmenších čtverců

$$Q^T / \quad Qc = F \rightarrow Q^T Qc = Q^T F$$

$$\begin{bmatrix} 5 & 9 & 17 \\ 9 & 17 & 33 \\ 17 & 33 & 65 \end{bmatrix} \begin{bmatrix} c_0 \\ c_1 \\ c_2 \end{bmatrix} = \begin{bmatrix} 8 \\ 14 \\ 26 \end{bmatrix}$$

$$\Rightarrow c_0 = 0,4, \quad c_1 = 2,65, \quad c_2 = -1,05$$

$$\varphi(x) = 0,4x + 2,65x^2 - 1,05x^3$$



$$\varphi(0) = \varphi_1(0) = \varphi_2(0) = 0 \Rightarrow \varphi(0) = 0$$

Řešitelnost úlohy diskrétní L_2 -aproximace

Definice: Řekneme, že systém funkcí $\varphi_j(x), j = 0, 1, \dots, m$, definovaných na $(a, b) \supset \text{int}(x_0, x_1, \dots, x_n)$ je **diskrétně lineárně nezávislý**, jsou-li vektory

$$[\varphi_0(x_0), \varphi_0(x_1), \dots, \varphi_0(x_n)]^T$$

$$[\varphi_1(x_0), \varphi_1(x_1), \dots, \varphi_1(x_n)]^T$$

:

$$[\varphi_m(x_0), \varphi_m(x_1), \dots, \varphi_m(x_n)]^T$$

lineárně nezávislé.

Poznámka:

Tato definice říká, že hodnota matice $\Phi = [\varphi_j(x_i)]_{j=0,1,\dots,m}^{i=0,1,\dots,n}$ je rovna $(m+1)$.

Plati, že $m \leq n$.

Podmíněnost úlohy diskrétní L_2 -aproximace

Budeme-li approximovat na intervalu $(0, 1)$ funkci f a zvolíme-li ekvidistantní dělení a bázové funkce budeme volit $\varphi_j = x^j$, bude matice $P = Q^T Q$ soustavu normálních rovnic blízká Hilbertově matici, která je velmi špatně podmíněná.

Řešení: Za funkce $\varphi_j(x)$ volíme ortogonální polynomy (např. Gramovy polynomy).

Poznámka: Ze systému n -lineárně nezávislých funkcí g_i lze pomocí Gram-Schmidtova ortogonalizačního

procesu zkonstruovat systém ortogonálních funkcí.

Spojité L_2 -aproximace

Definice:

Mějme funkci $w = w(x)$, která je definována na (a, b) a je kladná a omezená. Množinu reálných funkcí $f = f(x)$ definovaných na (a, b) takových, že

$$\int_a^b w(x) [f(x)]^2 dx < \infty$$

označíme $L_2(a, b)$. Skalárním součinem dvou funkcí $f, g \in L_2(a, b)$ nazýváme číslo

$$(f, g) = \int_a^b w(x) f(x) g(x) dx.$$

Číslo

$$\|f\| = \sqrt{(f, f)} = \left(\int_a^b w(x) [f(x)]^2 dx \right)^{\frac{1}{2}}$$

nazýváme normou funkce f v $L_2(a, b)$.

Funkce f, g se nazývají ortogonální, platí-li

$$(f, g) = 0.$$

Chceme tedy minimalizovat veličinu

$$R(f, \varphi) = \left(f - \sum_{j=0}^m c_j \varphi_j, f - \sum_{j=0}^m c_j \varphi_j \right).$$

Nutné a postačující podmínky minima mají tvar

$$\frac{\partial R}{\partial c_k} = 0, \quad k = 0, 1, \dots, m.$$

Derivováním a jednoduchými úpravami dostaneme

$$R(f, \varphi) = (f, f) - 2(f, \sum_{j=0}^m c_j \varphi_j) + (\sum_{j=0}^m c_j \varphi_j, \sum_{j=0}^m c_j \varphi_j)$$

$$\frac{\partial R}{\partial c_k} = 0 - 2(f, \varphi_k) + 2(\varphi_k, \sum_{j=0}^m c_j \varphi_j) = 0$$

$$\sum_{j=0}^m (\varphi_k, c_j \varphi_j) = (f, \varphi_k)$$

$$\sum_{j=0}^m c_j (\varphi_k, \varphi_j) = (f, \varphi_k)$$

Zapsáním všech podmínek dostaneme soustavu

$$(\varphi_0, \varphi_0)c_0 + (\varphi_0, \varphi_1)c_1 + \dots + (\varphi_0, \varphi_m)c_m = (\varphi_0, f)$$

$$(\varphi_1, \varphi_0)c_0 + (\varphi_1, \varphi_1)c_1 + \dots + (\varphi_1, \varphi_m)c_m = (\varphi_1, f)$$

$$(\varphi_m, \varphi_0)c_0 + (\varphi_m, \varphi_1)c_1 + \dots + (\varphi_m, \varphi_m)c_m = (\varphi_m, f)$$

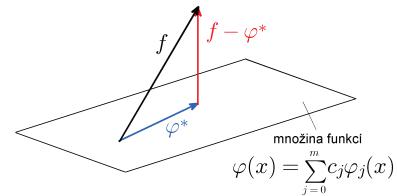
Věta

Jsou-li funkce $\varphi_0, \varphi_1, \dots, \varphi_m$ lineárně nezávislé, má úloha spojité L_2 -aproximace jediné řešení. Koefficienty c_j^* jsou řešením normální soustavy a platí:

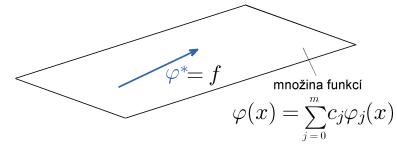
$$(f - \varphi^*, \varphi_j) = 0, \quad j = 0, 1, \dots, m,$$

tj. funkce $f - \varphi^*$ je ortogonální ke všem funkčím φ_j .

Geometrická interpretace



Pokud leží funkce f v množině funkčí $\varphi(x) = c_0 \varphi_0(x) + c_1 \varphi_1(x) + \dots + c_m \varphi_m(x)$, potom



Příklad

Stanovte spojitu L_2 -aproximaci funkce $f(x) = \ln x$ na $\langle 1, e \rangle$ lineární funkci $\varphi(x) = c_1 x + c_0$.

Minimalizujeme funkci

$$r(c_0, c_1) = \int_1^e |f(x) - \varphi(x)|^2 dx = \int_1^e (\ln x - c_0 - c_1 x)^2 dx$$

Podmínky minima

$$\frac{\partial r}{\partial c_0} = -2 \int_1^e (\ln x - c_0 - c_1 x) dx = 0$$

$$\frac{\partial r}{\partial c_1} = -2 \int_1^e (\ln x - c_0 - c_1 x) x dx = 0$$

$$c_0 \int_1^e 1 dx + c_1 \int_1^e x dx = \int_1^e \ln x dx$$

$$c_0 \int_1^e x dx + c_1 \int_1^e x^2 dx = \int_1^e x \ln x dx$$

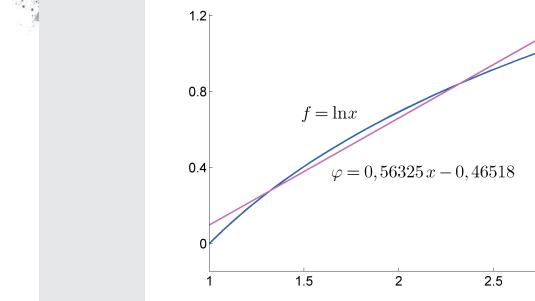
$$\begin{bmatrix} e-1 & \frac{1}{2}(e^2-1) \\ \frac{1}{2}(e^2-1) & \frac{1}{3}(e^3-1) \end{bmatrix} \begin{bmatrix} c_0 \\ c_1 \end{bmatrix} = \begin{bmatrix} 1 \\ e^2+1 \end{bmatrix}$$

$$\int_1^e \frac{\ln x}{v} \frac{1}{u'} dx = \begin{vmatrix} v = \ln x & v' = \frac{1}{x} \\ u' = 1 & u = x \end{vmatrix} = [x \ln x]_1^e - \int_1^e 1 dx = e - e + 1 = 1$$

$$\int_1^e \frac{x}{u'} \frac{\ln x}{v} dx = \begin{vmatrix} v = \ln x & v' = \frac{1}{x} \\ u' = x & u = \frac{x^2}{2} \end{vmatrix} = \left[\frac{x^2}{2} \ln x \right]_1^e - \int_1^e \frac{x^2}{2} \frac{1}{x} dx = \frac{e^2}{2} - \frac{1}{4}(e^2-1) = \frac{e^2}{4} + \frac{1}{4}$$

Řešení: $c_0 \doteq -0,46518, c_1 \doteq 0,56325$

$$|\varphi(x) = 0,56325 x - 0,46518|$$



Podmíněnost úlohy spojité L_2 -aproximace

Příklad: Volíme-li váhu $w(x) \equiv 1$ a approximujeme-li funkci $f = f(x)$ na intervalu $\langle 0, 1 \rangle$ funkci $\varphi = \varphi(x)$ ve tvaru

$$\varphi(x) = c_0 + c_1 x + c_2 x^2 + \dots + c_m x^m,$$

tj. $\varphi_i(x) = x^i$, platí

$$(\varphi_i, \varphi_j) = \int_0^1 x^i x^j dx = \frac{1}{i+j+1}.$$

Soustava normálních rovnic $Pc = g$ je opět spřatně podmíněná, protože P je Hilbertova matice.

Řešení problému: Volíme funkci $\varphi_j(x), j = 0, 1, \dots, m$, ortogonální ve smyslu skalárního součinu

$$(\varphi_i, \varphi_j) = \int_a^b w(x) \rho_i(x) \varphi_j(x) dx.$$

Potom platí: $(\varphi_i, \varphi_j) = 0$ pro $i \neq j$ a soustava normálních rovnic má diagonální matici. Pak lze psát:

$$\begin{cases} c_j^* = \frac{(f, \varphi_j)}{(\varphi_j, \varphi_j)}, & j = 0, 1, \dots, m \\ c_j^* \dots \text{Fourierovy koeficienty.} \end{cases}$$

Gram-Schmidtův ortogonalizační proces

Jsou dány lineárně nezávislé funkce g_1, g_2, \dots, g_n (prvky jistého prostoru).

Hledáme funkce (prvky téhož prostoru), které jsou navzájem po dvou ortogonální.

$$f_1 = g_1$$

f_2 hledáme ve tvaru $f_2 = g_2 + \kappa_{21}f_1$ a použijeme $(f_1, f_2) = 0$

$$\frac{(f_2, f_1)}{=0} = (g_2, f_1) + \kappa_{21}(f_1, f_1) \Rightarrow \kappa_{21} = -\frac{(g_2, f_1)}{(f_1, f_1)}$$

f_3 hledáme ve tvaru $f_3 = g_3 + \kappa_{31}f_1 + \kappa_{32}f_2$ a použijeme $(f_3, f_1) = 0$
 $\quad \quad \quad a (f_3, f_2) = 0$

$$\frac{(f_3, f_1)}{=0} = (g_3, f_1) + \kappa_{31}(f_1, f_1) + \kappa_{32}\frac{(f_2, f_1)}{=0}$$

$$\Rightarrow \kappa_{31} = -\frac{(g_3, f_1)}{(f_1, f_1)}$$

$$\frac{(f_3, f_2)}{=0} = (g_3, f_2) + \kappa_{31}(f_1, f_2) + \kappa_{32}(f_2, f_2)$$

$$\Rightarrow \kappa_{32} = -\frac{(g_3, f_2)}{(f_2, f_2)}$$

Obecně f_k hledáme ve tvaru $f_k = g_k + \kappa_{k1}f_1 + \kappa_{k2}f_2 + \dots + \kappa_{k,k-1}f_{k-1}$

$$a \quad \kappa_{kj} = -\frac{(g_k, f_j)}{(f_j, f_j)} \quad j = 1, 2, \dots, k-1$$

Příklad

Najděte ortogonální bázi prostoru polynomů do stupně 2 na $\langle 0, 10 \rangle$.

Vyjedeme z báze $g_0 = 1$, $g_1 = x$, $g_2 = x^2$.

$$f_0 = 1$$

$$f_1 = x + \kappa_{10}f_0$$

$$\kappa_{10} = -\frac{(x, 1)}{(1, 1)} = -\frac{\int_0^{10} x dx}{\int_0^{10} 1 dx} = -\frac{50}{10} = -5$$

$$f_1 = x - 5$$

$$f_2 = x^2 + \kappa_{20}1 + \kappa_{21}(x - 5)$$

$$\kappa_{20} = -\frac{(x^2, 1)}{(1, 1)} = -\frac{\int_0^{10} x^2 dx}{\int_0^{10} 1 dx} = -\frac{1000}{10} = -100$$

$$f_2 = x^2 - 33,3$$

$$\kappa_{21} = -\frac{(x^2, x - 5)}{(x - 5, x - 5)} = -\frac{\int_0^{10} x^3 - 5x^2 dx}{\int_0^{10} (x - 5)^2 dx} = -\frac{\frac{10000}{4} - 5 \cdot \frac{1000}{3}}{\frac{5^3}{3} + \frac{5^3}{3}} = -\frac{30000 - 20000}{250 \cdot 4} = -10$$

$$f_2 = x^2 - 33,3 - 10(x - 5)$$

$$f_2 = x^2 - 10x + 16,6$$

Příklad

Určete ortogonální bázi prostoru polynomů do stupně 2 pro uzlové body $x_0 = 0$; $x_1 = 0,2$; $x_2 = 0,4$; $x_3 = 0,6$; $x_4 = 0,8$; $x_5 = 1$

Opět použijeme jako výchozí bázi

$$g_0 = 1 \quad t.j. [1; 1; 1; 1; 1]$$

$$g_1 = x \quad t.j. [0; 0,2; 0,4; 0,6; 0,8; 1]$$

$$g_2 = x^2 \quad t.j. [0; 0,04; 0,16; 0,36; 0,64; 1]$$

$$f_0 = g_0 = 1$$

$$f_1 = g_1 + \kappa_{10}f_0$$

$$\kappa_{10} = -\frac{(g_1, f_0)}{(f_0, f_0)} = -\frac{0 + 0,2 + 0,4 + 0,6 + 0,8 + 1}{6} = -\frac{3}{6} = -\frac{1}{2}$$

$$f_1 = x - \frac{1}{2}$$

$$f_2 = g_2 + \kappa_{20}f_0 + \kappa_{21}f_1$$

$$\kappa_{20} = -\frac{(g_2, f_0)}{(f_0, f_0)} = -\frac{0 + 0,04 + 0,16 + 0,36 + 0,64 + 1}{6} = -\frac{2,2}{6} = -\frac{1,1}{3}$$

$$\kappa_{21} = -\frac{(g_2, f_1)}{(f_1, f_1)} = -\frac{[0; 0,04; 0,16; 0,36; 0,64; 1]^T [-0,5; -0,3; -0,1; 0,1; 0,3; 0,5]}{0,25 + 0,09 + 0,01 + 0,01 + 0,09 + 0,25} = -\frac{0 - 0,012 - 0,016 + 0,036 + 0,192 + 0,5}{0,7} = -\frac{0,7}{0,7} = -1$$

$$f_2 = x^2 - \frac{1,1}{3}x + \frac{1}{2}$$

$$f_2 = x^2 - x + \frac{2}{15} = x^2 - x + 0,13$$

Poznámka

Pokud bychom zvolili jiné uzlové body x_i , dostali bychom i obecně jiný systém ortogonálních bázových funkcí.

Např. pro $x_0 = 0$; $x_1 = 0,125$; $x_2 = 0,25$; $x_3 = 0,375$; $x_4 = 0,5$; $x_5 = 0,625$; $x_6 = 0,75$; $x_7 = 0,875$; $x_8 = 1$

bychom získali následující ortogonální bázi prostoru polynomů do stupně 2:

$$f_0 = 1, \quad f_1 = x - \frac{1}{2}, \quad f_2 = x^2 - x + 0,1458 \quad \dots \text{Ověrte (D.cv.).}$$

Poznámka:

Uvažujeme úlohu (spojité) L_2 -aproximace, kde za approximující funkci volíme polynom stupně n .

Jak máme volit stupeň polynomu?

Pokud nemáme další informace, je vhodné řešit normální rovnice postupně pro $m = 0, 1, 2, \dots$ a sledovat hodnotu

$$\sigma_m^2 = \frac{\sum_{i=0}^n (f(x_i) - \varphi(x_i))^2}{n-m},$$

kde $\varphi \dots$ polynom stupně m .

Pokud σ_m^2 s rostoucím m významně klesá, pokračujeme, jinak hodnota po niž nenásleduje výrazný pokles σ_m^2 je ze statistických důvodů vhodným stupněm polynomu.

Volíme-li za $\varphi_j = x^j$

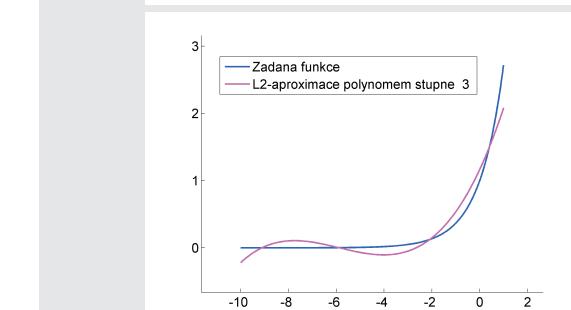
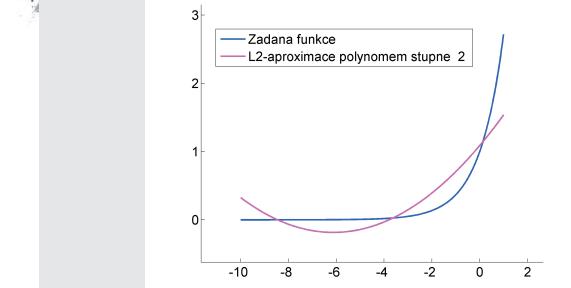
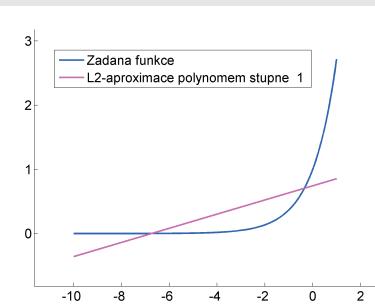
1. musíme řešit soustavu normálních rovnic pro každý stupeň m znova.

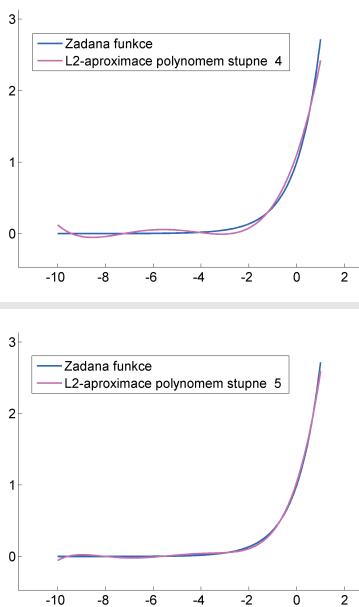
2. špatná podmíněnost

Řešení: Použijeme ortogonální polomy → potom stačí vždy dopočítat pouze 1 koeficient.

Příklad

Určete spojitu L_2 -aproximaci funkce $f(x) = e^x$ na $\langle -10, 1 \rangle$ pomocí polynomů stupně nejvyšše 1, 2, 3, 4 a 5.





Nelineární approximace metodou nejmenších čtverců

Např. volíme-li $\varphi(x) = Ce^{Ax}$

• 1. přístup je metoda linearizace dat: (*) zlogaritmujeme

$$\ln \varphi = \ln C + Ax$$

$$\Phi = Ax + B$$

(původní body $[x_i, f_i]$ je třeba transformovat na body $[x_i, \ln f_i]$)

(*)

získáme A , B a z B vypočteme $C = e^B$.

- 2. přístup minimalizuje L_2 normu chyby přímo

$$R(A, C) = \sum_{i=0}^n (f_i - Ce^{Ax_i})^2$$

parciální derivace:

$$\frac{\partial R}{\partial A} = 2 \sum_{i=0}^n (f_i - Ce^{Ax_i}) (Cx_i e^{Ax_i}) = 0$$

$$\frac{\partial R}{\partial C} = 2 \sum_{i=0}^n (f_i - Ce^{Ax_i}) (e^{Ax_i}) = 0$$

soustava normálních rovnic:

1. rovnice:

$$\sum_{i=0}^n (f_i - Ce^{Ax_i}) (Cx_i e^{Ax_i}) = 0$$

$$C \sum_{i=0}^n f_i x_i e^{Ax_i} - C^2 \sum_{i=0}^n x_i e^{2Ax_i} = 0 \quad / \quad \frac{1}{C} \neq 0$$

$$\sum_{i=0}^n f_i x_i e^{Ax_i} - C \sum_{i=0}^n x_i e^{2Ax_i} = 0$$

2. rovnice:

$$\sum_{i=0}^n (f_i - Ce^{Ax_i}) (e^{Ax_i}) = 0$$

$$\sum_{i=0}^n f_i e^{Ax_i} - C \sum_{i=0}^n e^{2Ax_i} = 0$$

... soustava nelineárních rovnic, pro řešení lze použít např. Newtonovu metodu.

Příklad

Určete disketní L_2 -approximaci funkce f zadané tabulkou

x_i	0	1	2	3	4
$f(x_i)$	1.5	2.5	3.5	5	7.5

funkcí ve tvaru

$$\varphi(x) = Ce^{Ax}$$

Pro řešení použijeme oba předchozí přístupy.

1. přístup

script v MATLABu

```
x=0:4
f=[1.5 2.5 3.5 5 7.5]
F=log(f)'
Q=[x.^0' x.^1']
P=Q'*Q
g=Q'*F
koef=P\g
A=koef(2)
C=exp(koef(1))
```

výsledky v MATLABu

```
x =
0 1 2 3 4
f =
1.5000 2.5000 3.5000 5.0000 7.5000
F =
0.4055
0.9163
1.2528
1.6094
2.0149
Q =
1 0
1 1
1 2
1 3
1 4
P =
5 10
10 30
g =
6.1989
16.3097
koef =
0.4574
0.3912
A =
0.3912
C =
1.5799
```

$$\Rightarrow \varphi_1(x) \doteq 1.5799 e^{0.3912x}$$

2. přístup

script v MATLABu

koef=fminsearch('R',[1 1]);
AA=koef(1)
CC=koef(2)

```
%-----
function out=R(koef);
A=koef(1);
C=koef(2);
out=(C-1.5).^2+(C.*exp(A)-2.5).^2+(C.*exp(2*A)-3.5).^2+...
(C.*exp(3*A)-5).^2+(C.*exp(4*A)-7.5).^2;
```

výsledky v MATLABu

```
AA =
0.3836
CC =
1.6109
```

$$\Rightarrow \varphi_2(x) \doteq 1.6109 e^{0.3836x}$$

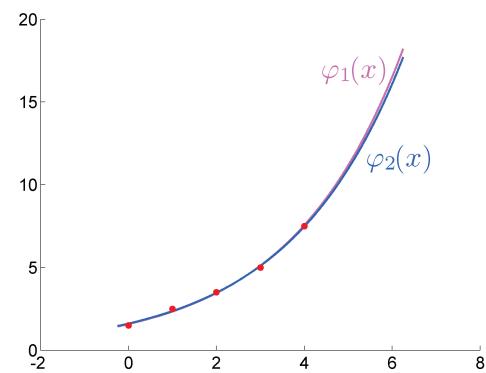


Table 5.6 Change of Variable(s) for Data Linearization

Function, $y = f(x)$	Linearized form, $Y = Ax + B$	Change of variable(s) and constants
$y = \frac{A}{x} + B$	$y = A\frac{1}{x} + B$	$X = \frac{1}{x}, Y = y$
$y = \frac{D}{x+C}$	$y + \frac{-1}{C}(xy) + \frac{D}{C}$	$X = xy, Y = y$ $C = \frac{-1}{A}, D = \frac{-B}{A}$
$y = \frac{1}{Ax+B}$	$\frac{1}{y} = Ax + B$	$X = x, Y = \frac{1}{y}$
$y = \frac{x}{Ax+B}$	$\frac{1}{y} = A\frac{1}{x} + B$	$X = \frac{1}{x}, Y = \frac{1}{y}$
$y = A \ln(x) + B$	$y = A \ln(x) + B$	$X = \ln(x), Y = y$
$y = Ce^{Ax}$	$\ln(y) = Ax + \ln(C)$	$X = x, Y = \ln(y)$ $C = e^B$
$y = Cx^A$	$\ln(y) = A \ln(x) + \ln(C)$	$X = \ln(x), Y = \ln(y)$ $C = e^B$
$y = (Ax + B)^{-2}$	$y^{-1/2} = Ax + B$	$X = x, Y = y^{-1/2}$
$y = Cxe^{-Dx}$	$\ln\left(\frac{y}{x}\right) = -Dx + \ln(C)$	$X = x, Y = \ln\left(\frac{y}{x}\right)$ $C = e^B, D = -A$
$y = \frac{L}{1+Ce^{Ax}}$	$\ln\left(\frac{L}{y} - 1\right) = Ax + \ln(C)$	$X = x, Y = \ln\left(\frac{L}{y} - 1\right)$ $C = e^B$ and L is a constant that must be given

Fourierova analýza

Do této chvíle jsme se zabývali approximacemi funkce pomocí polynomů. V úvodu jsme uvedli, že za bázové funkce můžeme volit libovolné funkce. Například pro approximaci periodických funkcí není vhodné použít polynom (a to jak ve smyslu interpolace tak ve smyslu L_2 -aproximace). Pro approximaci periodických funkcí je vhodné použít nějaký systém periodických bázových funkcí, např. systém tzv. trigonometrických polynomů:

$$\begin{aligned}\varphi_0(x) &= 1 \quad (\text{nebo } \frac{1}{2}) \\ \varphi_{2k-1}(x) &= \cos \frac{2\pi k x}{T} \quad k = 1, 2, \dots \\ \varphi_{2k}(x) &= \sin \frac{2\pi k x}{T} \quad k = 1, 2, \dots,\end{aligned}$$

kde T představuje periodu zadáné funkce (vzdálenost prvního a posledního uzlu v diskrétním případě, resp. délku zadaného intervalu ve spojeném případě).

Pro jednoduchost uvažujeme ekvidistantní uzly (v diskrétním případě).

Počet uvažovaných bázových funkcí volíme buď menší než je počet zadaných bodů (ve smyslu L_2 -aproximace), nebo roven počtu zadaných bodů (ve smyslu interpolace).

Jednoduchým cvičením je ukázat, že systém trigonometrických polynomů je ortogonální jak v diskrétném (pozor na počet) tak ve spojeném případě. Ověřte!

Úlohu najít koeficienty c_i u bázových funkcí φ_i z vyjádření

$$\varphi(x) = c_0\varphi_0(x) + c_1\varphi_1(x) + \dots + c_n\varphi_n(x),$$

nazýváme v tomto případě **Fourierovou analýzou**.

Formálně pouze přeňačíme koeficienty c_i , tj.

$$u \text{ bázové funkce } \varphi_0(x) = 1 \quad \text{použijeme koeficient } A_0,$$

$$u \text{ bázových funkci } \varphi_{2k-1}(x) = \cos(2\pi k x)/T \quad \text{použijeme } \dots A_k$$

$$u \text{ bázových funkci } \varphi_{2k}(x) = \sin(2\pi k x)/T \quad \text{použijeme } \dots B_k$$

Následující jednoduchý příklad ukáže princip Fourierovy analýzy.

Příklad

Aproximujte 2π -periodickou funkci zadanou tabulkou za použití maximálního počtu bázových funkcí (tj. ve smyslu interpolace).

$$\begin{array}{|c|c|c|c|c|} \hline x_i & 0 & \pi/2 & \pi & 3\pi/2 \\ \hline f(x_i) & 12 & -4 & 0 & 4 \\ \hline \end{array}$$

Řešení

Ze zadání je zřejmé, že perioda zadáné funkce je 2π . Aproximující trigonometrický polynom budeme tedy volit ve tvaru

$$\varphi(x) = A_0 + A_1 \cos x + B_1 \sin x + A_2 \cos 2x.$$

Zapíšeme interpolační podmínky

$$\varphi(x_j) = f(x_j), \quad j = 0, 1, 2, 3,$$

tj.

$$\begin{bmatrix} 1 & \cos x_0 & \sin x_0 & \cos 2x_0 \\ 1 & \cos x_1 & \sin x_1 & \cos 2x_1 \\ 1 & \cos x_2 & \sin x_2 & \cos 2x_2 \\ 1 & \cos x_3 & \sin x_3 & \cos 2x_3 \end{bmatrix} \begin{bmatrix} A_0 \\ A_1 \\ B_1 \\ A_2 \end{bmatrix} = \begin{bmatrix} f(x_0) \\ f(x_1) \\ f(x_2) \\ f(x_3) \end{bmatrix},$$

tj.

$$\begin{bmatrix} 1 & \cos 0 & \sin 0 & \cos 0 \\ 1 & \cos \pi/2 & \sin \pi/2 & \cos \pi \\ 1 & \cos \pi & \sin \pi & \cos 2\pi \\ 1 & \cos 3\pi/2 & \sin 3\pi/2 & \cos 3\pi \end{bmatrix} \begin{bmatrix} A_0 \\ A_1 \\ B_1 \\ A_2 \end{bmatrix} = \begin{bmatrix} 12 \\ -4 \\ 0 \\ 4 \end{bmatrix},$$

tj.

$$\begin{bmatrix} 1 & 1 & 0 & 1 \\ 1 & 0 & 1 & -1 \\ 1 & -1 & 0 & 1 \\ 1 & 0 & -1 & -1 \end{bmatrix} \begin{bmatrix} A_0 \\ A_1 \\ B_1 \\ A_2 \end{bmatrix} = \begin{bmatrix} 12 \\ -4 \\ 0 \\ 4 \end{bmatrix}.$$

tj.

$$\begin{bmatrix} 4 & 0 & 0 & 0 \\ 0 & 2 & 0 & 0 \\ 0 & 0 & 2 & 0 \\ 0 & 0 & 0 & 4 \end{bmatrix} \begin{bmatrix} A_0 \\ A_1 \\ B_1 \\ A_2 \end{bmatrix} = \begin{bmatrix} 12 \\ -8 \\ 12 \end{bmatrix}.$$

$Q^T Q$ je diagonální, protože funkce $\varphi_0(x) = \frac{1}{2}$, $\varphi_1(x) = \cos x$, $\varphi_2(x) = \sin x$ jsou diskrétně ortogonální ve smyslu skalárního součinu

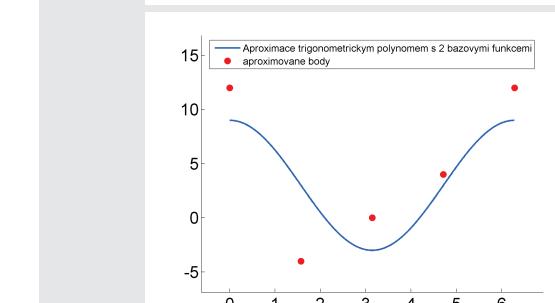
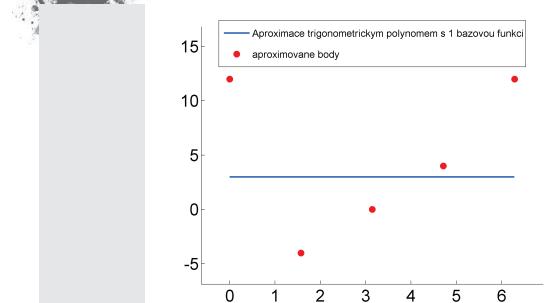
$$(\varphi, \psi) = \sum_{j=0}^2 \varphi(x_j)\psi(x_j) \quad x_j = \frac{2\pi j}{N}, \quad N = 3$$

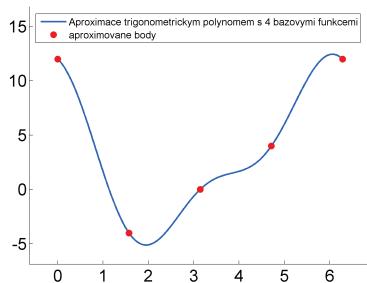
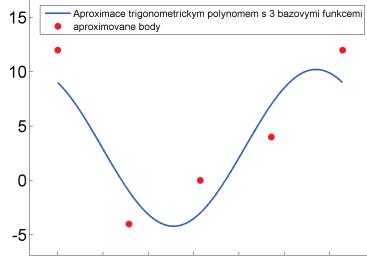
D.c.v.:

$$\begin{aligned}\left(\frac{1}{2}, \cos x\right) &= \dots = 0 \\ \left(\frac{1}{2}, \sin x\right) &= \dots = 0 \\ (\cos x, \sin x) &= \dots = 0\end{aligned}$$

Vyřešením soustavy získáme hledané koeficienty $A_0 = 3$, $A_1 = 6$, $B_1 = -4$, $A_2 = 3$ a tím i approximující trigonometrický polynom

$$\varphi(x) = 3 + 6 \cos x - 4 \sin x + 3 \cos 2x.$$



**Úloha diskrétní Fourierovy analýzy**Řadu T periodických funkcí (integrovatelných) lze vyjádřit ve tvaru **Fourierovy řady**

$$f(x) = \sum_{k=0}^{\infty} \left(a_k \cos \frac{2\pi kx}{T} + b_k \sin \frac{2\pi kx}{T} \right)$$

nebo

$$f(x) = \sum_{k=0}^{\infty} r_k \sin \left(\frac{2\pi kx}{T} + v_k \right), \quad \text{kde } r_k^2 = a_k^2 + b_k^2, \quad v_k = \arctan \frac{a_k}{b_k}$$

Položili jsme $a_k = r_k \sin v_k$, $b_k = r_k \cos v_k$.

$$a \cos \alpha + b \sin \alpha = r \sin v \cos \alpha + r \cos v \sin \alpha = r(\sin v \cos \alpha + \cos v \sin \alpha) = r \sin(\alpha + v).$$

Fourierovou (harmonickou) analýzou rozumíme úlohu určit amplitudy r_k a fáze v_k tzv. harmonických složek $r_k \sin \frac{2\pi kx}{T} + v_k$, je-li dáná funkce $f(x)$.

Fourierovou (harmonickou) syntézou rozumíme úlohu určit funkci f , jsou-li dány fáze v_k a amplitudy r_k .

Tuto úlohu můžeme řešit několika způsoby:

(i) Vyjdeme z úlohy spojité Fourierovy analýzy a numericky vypočteme Fourierovy koeficienty, které jsou dány:

$$a_k = \frac{2}{T} \int_0^T f(x) \cos \frac{2\pi kx}{T} dx$$

$$b_k = \frac{2}{T} \int_0^T f(x) \sin \frac{2\pi kx}{T} dx$$

Užijeme např. **lichoběžníkové** pravidlo (viz další přednáška). Pozor, pro velká k integrandy oscilují!(ii) Funkci f approximujeme (interpolace, diskrétní L_2 -aproximace) přímo vhodnou funkci φ , která má tvar trigonometrického polynomu.

Použijeme přístup (ii) realizovaný v příkladu.

Diskrétní Fourierova analýza - ve smyslu interpolace**Věta** Trigonometrický polynom

$$\varphi(x) = \frac{A_0}{2} + \sum_{k=1}^L (A_k \cos kx + B_k \sin kx), \quad N = 2L+1 \quad (N \text{ liché})$$

resp.

$$\varphi(x) = \frac{A_0}{2} + \sum_{k=1}^{L-1} (A_k \cos kx + B_k \sin kx) + \frac{A_L}{2} \cos Lx, \quad N = 2L \quad (N \text{ sudé})$$

splňuje **interpolaci** podmínky

$$\varphi(x_j) = f(x_j), \quad x_j = \frac{2\pi j}{N}, \quad j = 0, 1, \dots, N-1,$$

právě když koeficienty polynomu $\varphi(x)$ jsou dány pomocí vzorce

$$A_k = \frac{2}{N} \sum_{j=0}^{N-1} f(x_j) \cos kx_j, \quad k = 0, 1, \dots, L$$

$$B_k = \frac{2}{N} \sum_{j=0}^{N-1} f(x_j) \sin kx_j, \quad k = 1, 2, \dots, L$$

$$(A_0 = \frac{2}{N} \sum_{j=0}^{N-1} f_j)$$

Důkaz:

$$(\varphi(x), \cos kx) \rightarrow A_k, \quad (\varphi(x), \sin kx) \rightarrow B_k \quad \text{a využijeme ortogonalitu.}$$

Z těchto vzorců vychází **algoritmus diskrétní Fourierovy analýzy**.**Úloha a řešení Fourierovy analýzy** lze formulovat elegantně použitím **komplexní proměnné**.Uvažujeme pro jednoduchost lichý počet bázových funkcí ($N = 2L+1$) a periodu dané funkce 2π . Potom má approximující funkce tvar

$$\varphi(x) = A_0 + \sum_{k=1}^L (A_k \cos kx + B_k \sin kx). \quad (*)$$

Pomocí Eulerova vzorce

$$e^{ix} = \cos x + i \sin x$$

Ize pro funkce $\sin x$ a $\cos x$ odvodit vztahy

$$\cos x = \frac{e^{ix} + e^{-ix}}{2}, \quad \sin x = \frac{e^{ix} - e^{-ix}}{2i} = -\frac{1}{2}i(e^{ix} - e^{-ix})$$

a tedy

$$\begin{aligned} \varphi(x) &= A_0 + \sum_{k=1}^L \left(\frac{1}{2} A_k (e^{ikx} + e^{-ikx}) - \frac{1}{2} i B_k (e^{ikx} - e^{-ikx}) \right) \\ &= A_0 + \sum_{k=1}^L \left(\frac{1}{2} (A_k - i B_k) e^{ikx} + \frac{1}{2} (A_k + i B_k) e^{-ikx} \right). \end{aligned}$$

Označíme-li

$$C_0 = A_0, \quad C_k = \frac{1}{2} (A_k - i B_k), \quad C_{-k} = \frac{1}{2} (A_k + i B_k)$$

dostaneme

$$\varphi(x) = \sum_{k=-L}^L C_k e^{ikx}$$

Pro koeficienty dostaneme vynásobením (*) jednotlivými bázovými funkciemi, využitím jejich ortogonalnosti a interpolačních podmínek předpis:

$$A_0 = \frac{1}{N} \sum_{j=0}^{N-1} f(x_j)$$

$$A_k = \frac{2}{N} \sum_{j=0}^{N-1} f(x_j) \cos kx_j$$

$$B_k = \frac{2}{N} \sum_{j=0}^{N-1} f(x_j) \sin kx_j$$

$$C_{\pm k} = \frac{1}{2} (A_k \mp i B_k) = \frac{1}{N} \sum_{j=0}^{N-1} f(x_j) \cos kx_j \mp i \frac{1}{N} \sum_{j=0}^{N-1} f(x_j) \sin kx_j =$$

$$= \frac{1}{N} \sum_{j=0}^{N-1} f(x_j) \underbrace{(\cos kx_j \pm i \sin kx_j)}_{e^{\mp ikx_j}}$$

$$C_k = \frac{1}{N} \sum_{j=0}^{N-1} f(x_j) e^{-ikx_j}, \quad k = -L, \dots, L$$

PoznámkaVezmeme-li approximující polynom o menším počtu bázových funkcí než je počet zadaných bodů, jedná se o approximaci ve smyslu nejménších čtverců, tj. diskrétní L_2 -aproximaci. Potom obecně nemohou být splněny interpolační podmínky přesně (jen ve speciálních případech).Výpočet koeficientů C_k představuje sčítání konečné řady.

$$C_k = \frac{1}{N} \sum_{j=0}^{N-1} f(x_j) e^{-ikx_j}, \quad k = -L, \dots, L$$

Uvažujeme-li počet approximujících bázových funkcí N jako mocninu čísla 2 (tj. $N = 2^M$), lze odvodit velmi rychlý a efektivní algoritmus pro výpočet koeficientů C_k .Tento algoritmus se potom nazývá **rychlá Fourierova transformace (Fast Fourier transform - FFT)**.

Princip metody si ukážeme na následujícím příkladě.

PříkladUvažujeme následující zadání funkce f pro $N = 2^2 = 4$ ekvidistantní uzlové body.

x_i	$x_0 = 0$	$x_1 = \frac{\pi}{2}$	$x_2 = \pi$	$x_3 = \frac{3\pi}{2}$
$f(x_i)$	f_0	f_1	f_2	f_3

Počítáme koeficienty C_k .

Plati:

$$C_k = \frac{1}{4} (f_0 + f_1 e^{-ik\frac{\pi}{2}} + f_2 e^{-i2k\pi} + f_3 e^{-ik\frac{3\pi}{2}}), \quad k = 0, 1, 2, 3.$$

Oznáčme

$$w = e^{-i\frac{\pi}{2}}$$

$$F_k = \frac{1}{4} f_k \quad k = 0, 1, 2, 3.$$

Potom

$$C_k = F_0 + F_1 w^k + F_2 w^{2k} + F_3 w^{3k}, \quad k = 0, 1, 2, 3.$$

Uvědomte si, že platí

$$w^4 = 1 \quad (\text{obecně } w^N = 1).$$

$$\begin{aligned} C_0 &= \underbrace{(F_0 + F_2)}_{R_0} + \underbrace{(F_1 + F_3)}_{S_0} \\ C_1 &= \underbrace{(F_0 + w^2 F_2)}_{R_1} + w \underbrace{(F_1 + w^2 F_3)}_{S_1} \\ C_2 &= (F_0 + F_2) + w^2 (F_1 + F_3) \\ C_3 &= (F_0 + w^2 F_2) + w^3 (F_1 + w^2 F_3) \end{aligned}$$

Výpočetní náročnost:

na $R_k, S_k \dots 4S + 2N$

na $C_k \dots 4S + 3N$

$\sum \dots 8S + 5N$

Příklad

Aproximujte periodickou funkci f (perioda $T = 31$) zadanou tabulkou pomocí trigonometrického polynomu (ve smyslu L_2 aproximace, až při použití plného počtu bázových funkcií ve smyslu interpolace).

$$\begin{array}{ll} x_k = 1, 2, \dots, 32 \\ f(x_k) = 1 & \text{pro } k = 1, 2, \dots, 15 \\ = 0 & \text{pro } k = 16 \\ = -1 & \text{pro } k = 17, 18, \dots, 31 \\ = 1 & \text{pro } k = 32 \end{array}$$

Řešení

výsledky v MATLABu

$$\begin{aligned} \text{koefficient A(0)} &= 0.000000 & u \text{bazove funkce phi(0)} &= 1 \\ \text{koefficient A(1)} &= 0.128701 & u \text{bazove funkce phi(1)} &= \cos(2\pi i * 1 * x / 31 - 1) \\ \text{koefficient B(1)} &= 1.265623 & u \text{bazove funkce phi(2)} &= \sin(2\pi i * 1 * x / 31 - 1) \\ \text{koefficient A(2)} &= 0.001321 & u \text{bazove funkce phi(3)} &= \cos(2\pi i * 2 * x / 31 - 1) \\ \text{koefficient B(2)} &= 0.006426 & u \text{bazove funkce phi(4)} &= \sin(2\pi i * 2 * x / 31 - 1) \\ \text{koefficient A(3)} &= 0.126074 & u \text{bazove funkce phi(5)} &= \cos(2\pi i * 3 * x / 31 - 1) \\ \text{koefficient B(3)} &= 0.401825 & u \text{bazove funkce phi(6)} &= \sin(2\pi i * 3 * x / 31 - 1) \\ \text{koefficient A(4)} &= 0.005229 & u \text{bazove funkce phi(7)} &= \cos(2\pi i * 4 * x / 31 - 1) \\ \text{koefficient B(4)} &= 0.012184 & u \text{bazove funkce phi(8)} &= \sin(2\pi i * 4 * x / 31 - 1) \\ \text{koefficient A(5)} &= 0.120926 & u \text{bazove funkce phi(9)} &= \cos(2\pi i * 5 * x / 31 - 1) \\ \text{koefficient B(5)} &= 0.217865 & u \text{bazove funkce phi(10)} &= \sin(2\pi i * 5 * x / 31 - 1) \\ \text{koefficient A(6)} &= 0.011564 & u \text{bazove funkce phi(11)} &= \cos(2\pi i * 6 * x / 31 - 1) \\ \text{koefficient B(6)} &= 0.016614 & u \text{bazove funkce phi(12)} &= \sin(2\pi i * 6 * x / 31 - 1) \\ \text{koefficient A(7)} &= 0.113468 & u \text{bazove funkce phi(13)} &= \cos(2\pi i * 7 * x / 31 - 1) \\ \text{koefficient B(7)} &= 0.132175 & u \text{bazove funkce phi(14)} &= \sin(2\pi i * 7 * x / 31 - 1) \\ \text{koefficient A(8)} &= 0.020067 & u \text{bazove funkce phi(15)} &= \cos(2\pi i * 8 * x / 31 - 1) \\ \text{koefficient B(8)} &= 0.019075 & u \text{bazove funkce phi(16)} &= \sin(2\pi i * 8 * x / 31 - 1) \\ \text{koefficient A(9)} &= 0.104007 & u \text{bazove funkce phi(17)} &= \cos(2\pi i * 9 * x / 31 - 1) \\ \text{koefficient B(9)} &= 0.080507 & u \text{bazove funkce phi(18)} &= \sin(2\pi i * 9 * x / 31 - 1) \\ \text{koefficient A(10)} &= 0.030389 & u \text{bazove funkce phi(19)} &= \cos(2\pi i * 10 * x / 31 - 1) \\ \text{koefficient B(10)} &= 0.018942 & u \text{bazove funkce phi(20)} &= \sin(2\pi i * 10 * x / 31 - 1) \\ \text{koefficient A(11)} &= 0.092929 & u \text{bazove funkce phi(21)} &= \cos(2\pi i * 11 * x / 31 - 1) \\ \text{koefficient B(11)} &= 0.045584 & u \text{bazove funkce phi(22)} &= \sin(2\pi i * 11 * x / 31 - 1) \\ \text{koefficient A(12)} &= 0.042109 & u \text{bazove funkce phi(23)} &= \cos(2\pi i * 12 * x / 31 - 1) \\ \text{koefficient B(12)} &= 0.015594 & u \text{bazove funkce phi(24)} &= \sin(2\pi i * 12 * x / 31 - 1) \\ \text{koefficient A(13)} &= 0.080687 & u \text{bazove funkce phi(25)} &= \cos(2\pi i * 13 * x / 31 - 1) \\ \text{koefficient B(13)} &= 0.020891 & u \text{bazove funkce phi(26)} &= \sin(2\pi i * 13 * x / 31 - 1) \\ \text{koefficient A(14)} &= 0.054747 & u \text{bazove funkce phi(27)} &= \cos(2\pi i * 14 * x / 31 - 1) \\ \text{koefficient B(14)} &= 0.008387 & u \text{bazove funkce phi(28)} &= \sin(2\pi i * 14 * x / 31 - 1) \\ \text{koefficient A(15)} &= 0.067784 & u \text{bazove funkce phi(29)} &= \cos(2\pi i * 15 * x / 31 - 1) \\ \text{koefficient B(15)} &= 0.003438 & u \text{bazove funkce phi(30)} &= \sin(2\pi i * 15 * x / 31 - 1) \end{aligned}$$

Aproximace je dana predpisem :

$$\phi = A(0) + \sum_{k=1}^L [A(k) \cdot \phi(2k-1) + B(k) \cdot \phi(2k)]$$

pro pocet bazovych funkci N=2L+1

$$\phi = A(0) + \sum_{k=1}^{L-1} [A(k) \cdot \phi(2k-1) + B(k) \cdot \phi(2k)] + A(L) \cdot \phi(2L-1)$$

pro pocet bazovych funkci N=2L

Kapitola 9. Numerické derivování

Definice: Existuje-li pro danou funkci $f : \mathbb{R} \rightarrow \mathbb{R}$ vlastní (tj. konečná) limita

$$\lim_{h \rightarrow 0} \frac{f(a+h) - f(a)}{h}$$

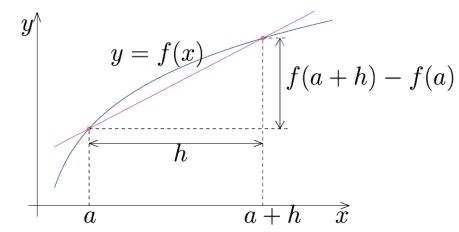
říkáme, že funkce $f(x)$ má v bodě a derivaci.

Příslušnou limitu značíme $f'(a)$.

Poznámka:

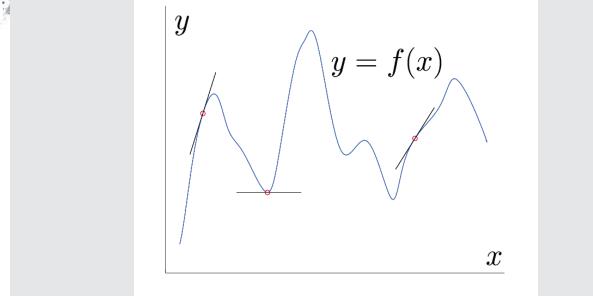
Geometrický význam derivace $f'(a)$ je směrnic tečny křivky dané rovnici $y = f(x)$ v bodě a (nebo tečna v bodě a je limitní polohou sečny pro $h \rightarrow 0$).

Fyzikálně značí derivace funkce $y = f(x)$, kde x je čas a y dráha pohybu, limitu z průměrné rychlosti, tedy okamžitou rychlosť v čase a .



Poznámka:

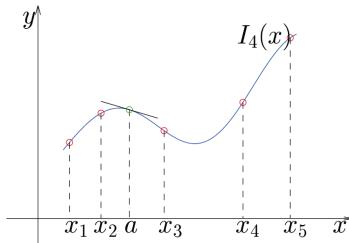
Pro danou funkci $f(x)$ vyjadřuje derivace $f'(x_0)$ míru „stoupání“, resp. „klesání“ v bodě x_0 .



Způsoby odvození vzorů pro výpočet derivace

1. Odvození pomocí interpolačního polynomu

Pro funkci f , která je zadána tabulkou, sestrojíme interpolační polynom a derivaci funkce f v bodě a ztotožněme s derivací tohoto interpolačního polynomu v bodě a .



Poznámky:

- Stupeň polynomu nemůže být nižší než rád počítané derivace.

- Pro jednoduchost hledáme hodnotu derivace v uzlovém bodě a navíc uvažujeme ekvidistantní uzly s krokem h .

2. Odvození pomocí Taylorova rozvoje

Pro dostatečně hladkou funkci f platí (pro $h > 0$):

$$\begin{aligned} f(x_0 + h) &= f(x_0) + hf'(x_0) + \frac{h^2}{2}f''(\xi_1), \quad \xi_1 \in (x_0, x_0 + h) \\ f(x_0 - h) &= f(x_0) - hf'(x_0) + \frac{h^2}{2}f''(\xi_2), \quad \xi_2 \in (x_0 - h, x_0) \end{aligned}$$

Z první rovnice potom plynou vztahy

$$f'(x_0) = \underbrace{\frac{f(x_0 + h) - f(x_0)}{h}}_{= D_P f(x_0, h)} - \frac{1}{2}h f''(\xi_1)$$

Podobně z druhé rovnice

$$f'(x_0) = \underbrace{\frac{f(x_0) - f(x_0 - h)}{h}}_{= D_L f(x_0, h)} + \frac{1}{2}h f''(\xi_2)$$

Obdrželi jsme dva základní **dvooubodové** vzorce $D_P f(x_0, h)$ a $D_L f(x_0, h)$, tzn. pravou a levou poměrnou diferenci.

Podobně odvodíme další vzorce pomocí Taylorova rozvoje vyšších řádů. Platí:

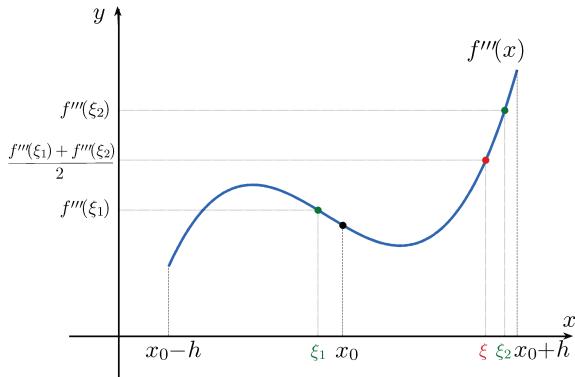
$$\begin{aligned} f(x_0 + h) &= f(x_0) + hf'(x_0) + \frac{h^2}{2}f''(x_0) + \frac{h^3}{6}f'''(\xi_1), \quad \xi_1 \in (x_0, x_0 + h) \\ f(x_0 - h) &= f(x_0) - hf'(x_0) + \frac{h^2}{2}f''(x_0) - \frac{h^3}{6}f'''(\xi_2), \quad \xi_2 \in (x_0 - h, x_0) \end{aligned}$$

Po odečtení obdržíme:

$$f(x_0 + h) - f(x_0 - h) = 2hf'(x_0) + \frac{h^3}{6}(f'''(\xi_1) + f'''(\xi_2))$$

Odtud vyjádříme první derivaci a získáme **tříbodový** vzorec $D_C f(x_0, h)$, tzn. centrální poměrnou diferenci

$$f'(x_0) = \underbrace{\frac{f(x_0 + h) - f(x_0 - h)}{2h}}_{D_C f(x_0, h)} - \underbrace{\frac{h^2(f'''(\xi_1) + f'''(\xi_2))}{12h^2 f'''(\xi)}}_{\frac{h^2}{6} f'''(\xi)}$$



Uvedené vzorce jsou pro výpočet první derivace $f'(x_0)$.

Pro výpočet druhé derivace $f''(x_0)$ lze použít například vzorec, který dostaneme po sečtení vztahů:

$$f(x_0 + h) = f(x_0) + hf'(x_0) + \frac{h^2}{2}f''(x_0) + \frac{h^3}{6}f'''(x_0) + \frac{h^4}{24}f^{(4)}(\xi_1), \quad \xi_1 \in (x_0, x_0 + h)$$

$$f(x_0 - h) = f(x_0) - hf'(x_0) + \frac{h^2}{2}f''(x_0) - \frac{h^3}{6}f'''(x_0) + \frac{h^4}{24}f^{(4)}(\xi_2), \quad \xi_2 \in (x_0 - h, x_0)$$

$$f(x_0 + h) + f(x_0 - h) = 2f(x_0) + \frac{h^2}{2}f''(x_0) + \frac{h^4}{24}(f^{(4)}(\xi_1) + f^{(4)}(\xi_2))$$

Odtud vyjádříme druhou derivaci a získáme **tříbodový** vzorec pro druhou derivaci

$$f''(x_0) = \frac{f(x_0 + h) - 2f(x_0) + f(x_0 - h)}{h^2} - \underbrace{\frac{h^2}{24}(f^{(4)}(\xi_1) + f^{(4)}(\xi_2))}_{\frac{h^2}{12}f^{(4)}(\xi)}$$

Poznámka:

Samozřejmě lze odvadit řadu dalších vzorců, přičemž platí, že čím více bodů použijeme, tím bude řadu chyb vyšší.

Příklad: Pomocí uvedených tří vzorců vypočtěte přibližnou hodnotu první derivace funkce $f(x) = e^x(1-x)$ v bodě $x_0 = 1$. Použijte krok $h = 0,1$.

Řešení:

Nejdříve si pro kontrolu analyticky zjistíme přesnou hodnotu první derivace funkce f bodě x_0 .

$$f(x) = e^x(1-x) + e^x(-1) = -xe^x, \quad t.j. \quad f'(1) = -e^1 = -e \approx -2,7182$$

Nyní použijeme pravou, levou a centrální poměrnou diferenci:

$$1. \quad D_P f(x_0, h) = \frac{f(x_0 + h) - f(x_0)}{h} = \frac{e^{1+1}(1-1,1) - e^1(1-1)}{0,1} = \frac{-0,1e^{1,1}}{0,1} = -e^{1,1} \approx -3,0041 \quad (\text{chyba } 0,2858)$$

$$2. \quad D_L f(x_0, h) = \frac{f(x_0) - f(x_0 - h)}{h} = \frac{e^1(1-1) - e^{0,9}(1-0,9)}{0,1} = \frac{-0,1e^{0,9}}{0,1} = -e^{0,9} \approx -2,4596 \quad (\text{chyba } 0,2586)$$

$$3. \quad D_C f(x_0, h) = \frac{f(x_0 + h) - f(x_0 - h)}{2h} = \frac{e^{1+1}(1-1,1) - e^{0,9}(1-0,9)}{0,2} = \frac{-0,1e^{1,1} - 0,1e^{0,9}}{0,2} = -\frac{e^{1,1} + e^{0,9}}{2} \approx -2,7318 \quad (\text{chyba } 0,0136)$$

Všimněte si velikosti chyb v jednotlivých případech. Potvrzuje se fakt, že chyba prvních dvou (dvoubodových) vzorců je řádu h , tj. v řádu desetin a chyba posledního (tříbodového) vzorce je řádu h^2 , tj. v řádu setin.

Podmíněnost úlohy numerického derivování

Uvažujme nyní např. vzorec s pravou diferencí $D_P f(x_0, h)$, tj. platí

$$f'(x_0) = \underbrace{\frac{f(x_0 + h) - f(x_0)}{h}}_{D_P f(x_0, h)} - \underbrace{\frac{\frac{1}{2}h f''(\xi)}{h}}_{\text{chyba metody}}$$

Chybou metody označme r_1 .

Plati-li $|f''(x)| < M$ pro $x \in (x_0, x_0 + h)$, potom $|r_1| \leq \frac{M}{2}h$.

Musíme uvážit **chybu měření** (zaokrouhlovací chybu) - označíme r_2 .

Označíme-li

$$\begin{aligned} f(x_0), f(x_0 + h) &\dots \text{přesné hodnoty} \\ f'(x_0), f'(x_0 + h) &\dots \text{vstupní hodnoty} \end{aligned}$$

Potom pro r_2 platí

$$r_2 = \underbrace{\frac{f(x_0 + h) - f(x_0)}{h}}_{\text{přesná hodnota vzorce}} - \underbrace{\frac{f'(x_0 + h) - f'(x_0)}{h}}_{\text{vypočtená hodnota vzorce}}$$

A dále

$$\begin{aligned} |r_2| &= \left| \frac{f(x_0 + h) - f^*(x_0 + h) + f^*(x_0 + h) - f(x_0)}{h} + \frac{f^*(x_0 + h) - f^*(x_0)}{h} \right| \leq \\ &\leq \frac{|f(x_0 + h) - f^*(x_0 + h)|}{h} + \frac{|f^*(x_0 + h) - f(x_0)|}{h} \leq \\ &\leq \frac{\varepsilon}{h} + \frac{\varepsilon}{h} = \frac{2\varepsilon}{h} \end{aligned}$$

Využili jsme zde odhady

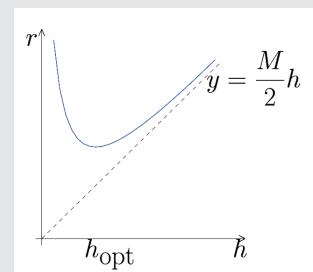
$$|f'(x_0 + h) - f'(x_0)| \leq \varepsilon$$

$$|f^*(x_0) - f(x_0)| \leq \varepsilon$$

číslo ε může představovat např. strojovou přesnost.

Pro celkovou chybu r potom platí

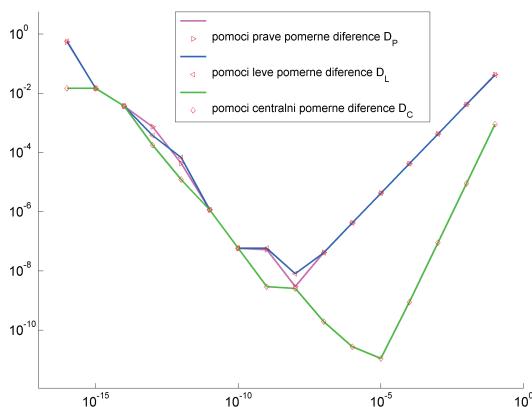
$$|r| \leq |r_1| + |r_2| \leq \frac{M}{2}h + \frac{2\varepsilon}{h}$$



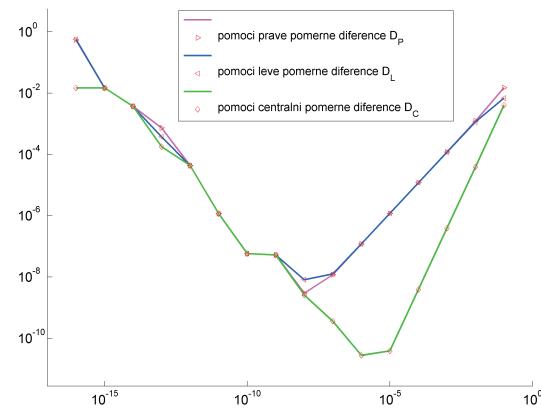
- Úloha numerického derivování je špatně podmíněná! (pro zmenšující se h roste chyba)
- Lze najít optimální krok h_{opt}

V následujících příkladech ukažte chybu 3 odvozených vzorců pro výpočet první derivace funkce $f(x)$ v bodě x_0 při použití kroků $h = 10^{-16}, 10^{-15}, \dots, 10^{-1}$.

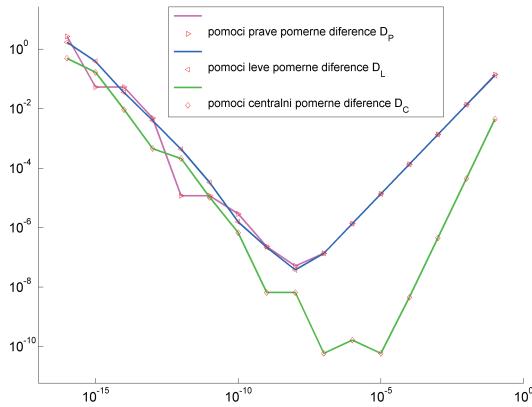
Příklad 1 $f(x) = \sin x, x_0 = 1$.



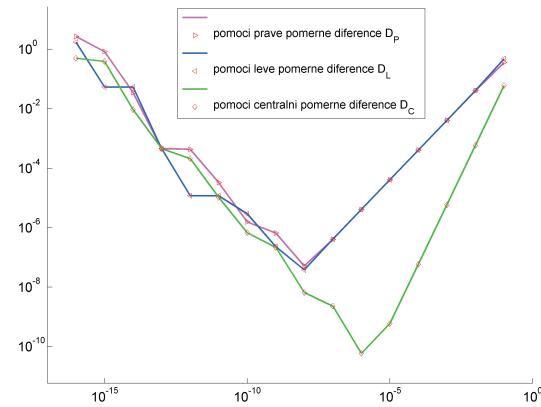
Příklad 2 $f(x) = \sin \frac{1}{x}, x_0 = 1$.



Příklad 3 $f(x) = e^x, x_0 = 1$.



Příklad 4 $f(x) = e^{\frac{1}{x}}, x_0 = 1$.



Poznámka:

Na základě špatné podmíněnosti se zdá, že nebude možné při výpočtu derivace dosáhnout libovolné přesnosti.

Zvýšení přesnosti ale můžeme dosáhnout

- 1) použitím vzorce s chybou vyššího řádu
- 2) použitím tzv. Richardsonovy extrapolače

Richardsonova extrapolačce

Jde o obecný princip, který se používá nejen u numerického derivování.

Myšlenka vychází z toho, že na základě znalosti výrazu pro rozvoj chyby využijeme dvou přibližných výsledků k získání třetího, který bude přesnější.

Tento proces eliminace chyb budeme demonstrovat např. na poměrné centrální diferenci $D_C f(x_0, h)$.

Vyjdeme z Taylorova rozvoje:

$$(1) \quad f(x_0+h) = f(x_0) + h f'(x_0) + \frac{h^2}{2} f''(x_0) + \frac{h^3}{6} f'''(x_0) + \frac{h^4}{24} f^{(4)}(x_0) + \frac{h^5}{5!} f^{(5)}(\xi_1)$$

$$(2) \quad f(x_0-h) = f(x_0) - h f'(x_0) + \frac{h^2}{2} f''(x_0) - \frac{h^3}{6} f'''(x_0) + \frac{h^4}{24} f^{(4)}(x_0) - \frac{h^5}{5!} f^{(5)}(\xi_2)$$

$$(1)-(2) \quad f(x_0+h)-f(x_0-h)=2hf'(x_0)+\frac{h^3}{3}f'''(x_0)+\frac{h^5}{5!}(f^{(5)}(\xi_1)+f^{(5)}(\xi_2)) \\ O(h^5)$$

$$\boxed{\frac{f(x_0+h)-f(x_0-h)}{2h}=f'(x_0)+\frac{h^2}{6}f'''(x_0)+O(h^4)}$$

Stejný vzorec použijeme pro výpočet s krokem $\bar{h}=2h$.

$$D_C f(x_0, \bar{h}) = f'(x_0) + \frac{h^2}{6}f'''(x_0) + O(h^4)$$

$$\boxed{D_C f(x_0, 2h) = f'(x_0) + \frac{h^2}{6}f'''(x_0) + O(h^4)}$$

④④

Podtržené členy chceme eliminovat – rovnici ④ vynásobíme 4

$$4D_C f(x_0, h) = 4f'(x_0) + 4\frac{h^2}{6}f'''(x_0) + O(h^4)$$

Odečteme ④④

$$D_C f(x_0, 2h) = f'(x_0) + \frac{h^2}{6}f'''(x_0) + O(h^4)$$

$$\boxed{4D_C f(x_0, h) - D_C f(x_0, 2h) = 3f'(x_0) + O(h^4)}$$

$$f'(x_0) = \frac{4D_C f(x_0, h) - D_C f(x_0, 2h)}{3} + O(h^4)$$

nebo jinak zapsáno

$$\boxed{f'(x_0) = D_C f(x_0, h) + \frac{D_C f(x_0, h) - D_C f(x_0, 2h)}{3} + O(h^4)}$$

Poznámka:

Tímto způsobem jsme eliminovali chybu řádu h^2 . Algoritmus Richardsonovy extrapolace lze samozřejmě použít opakování pro eliminaci chyb vyšších řádů. Tato metoda je potom velmi efektivní.

Pokud bychom chtěli stejným způsobem eliminovat chybu řádu např. 4, potom bychom dostali:

$$D_C f(x_0, h) = f'(x_0) + Kh^4 \quad / \cdot 2^4 \text{ a odečteme 2. rovnici}$$

$$D_C f(x_0, 2h) = f'(x_0) + K2^4 h^4$$

$$\boxed{f'(x_0) = \frac{2^4 D_C f(x_0, h) - D_C f(x_0, 2h)}{2^4 - 1}}$$

$$\boxed{f'(x_0) = D_C f(x_0, h) + \frac{1}{2^4 - 1} (D_C f(x_0, h) - D_C f(x_0, 2h))}$$

Pro eliminaci chyb vyšších řádů postupujeme analogicky, tj. místo 4 použijeme příslušný řád.

Poznámka:

V názvu metody se objevuje slovo extrapolace. Je to proto, že nová hodnota derivace je lineární kombinací

Při určování rozvoje chyb jednotlivých vzorců vycházíme z Taylorova rozvoje funkce f .

Rozvoj chyby pro $D_P f(x_0, h)$ a $D_L f(x_0, h)$

$$(1) \quad f(x_0+h) = f(x_0) + hf'(x_0) + \frac{h^2}{2}f''(x_0) + \frac{h^3}{6}f'''(x_0) + \frac{h^4}{24}f^{(4)}(x_0) + \frac{h^5}{120}f^{(5)}(\xi_1), \quad \xi_1 \in (x_0, x_0+h)$$

$$(2) \quad f(x_0-h) = f(x_0) - hf'(x_0) + \frac{h^2}{2}f''(x_0) - \frac{h^3}{6}f'''(x_0) + \frac{h^4}{24}f^{(4)}(x_0) - \frac{h^5}{120}f^{(5)}(\xi_2), \quad \xi_2 \in (x_0-h, x_0)$$

$$(1) \Rightarrow f'(x_0) = \frac{f(x_0+h) - f(x_0)}{h} - \frac{h}{2} \frac{f''(x_0)}{c_1 h} - \frac{h^2}{6} \frac{f'''(x_0)}{c_2 h^2} - \frac{h^3}{24} \frac{f^{(4)}(x_0)}{c_3 h^3} - \frac{h^4}{120} \frac{f^{(5)}(\xi_1)}{O(h^4)}$$

$$(2) \Rightarrow f'(x_0) = \frac{f(x_0) - f(x_0-h)}{h} + \frac{h}{2} \frac{f''(x_0)}{c_1 h} - \frac{h^2}{6} \frac{f'''(x_0)}{c_2 h^2} + \frac{h^3}{24} \frac{f^{(4)}(x_0)}{c_3 h^3} - \frac{h^4}{120} \frac{f^{(5)}(\xi_2)}{O(h^4)}$$

Rozvoj chyby pro $D_C f(x_0, h)$

$$f(x_0+h) = f(x_0) + hf'(x_0) + \frac{h^2}{2}f''(x_0) + \frac{h^3}{6}f'''(x_0) + \frac{h^4}{24}f^{(4)}(x_0) + \frac{h^5}{120}f^{(5)}(x_0) + \frac{h^7}{720}f^{(7)}(\xi_1), \quad \xi_1 \in (x_0, x_0+h)$$

$$f(x_0-h) = f(x_0) - hf'(x_0) + \frac{h^2}{2}f''(x_0) - \frac{h^3}{6}f'''(x_0) + \frac{h^4}{24}f^{(4)}(x_0) - \frac{h^5}{120}f^{(5)}(x_0) + \frac{h^6}{720}f^{(6)}(x_0) - \frac{h^7}{7!}f^{(7)}(\xi_2), \quad \xi_2 \in (x_0-h, x_0)$$

Po odečtení:

$$f(x_0+h) - f(x_0-h) = 2hf'(x_0) + \frac{1}{3}h^3f'''(x_0) + \frac{1}{60}h^5f^{(5)}(x_0) + \frac{h^7}{7!}(f^{(7)}(\xi_1) + f^{(7)}(\xi_2)) \\ = O(h^7)$$

$$f'(x_0) = \frac{f(x_0+h) - f(x_0-h)}{2h} - \frac{1}{6} \frac{h^2f'''(x_0)}{c_1 h^2} - \frac{1}{120} \frac{h^4f^{(5)}(x_0)}{c_2 h^4} - \frac{h^6}{7!} \frac{2f^{(7)}(\xi)}{O(h^6)}$$

Algoritmus Richardsonovy extrapolace

Na základě znalosti rozvoje chyby příslušného vzorce můžeme pro zpřesňování hodnoty vypočtené derivace použít následující algoritmus.

Algoritmus (např. pro vzorec $D_C f$)

Pro $s=0,1,2,\dots,S$

$$T_{s,0} = D_C f(x_0, 2^{-s}h)$$

Pro $k=1,2,\dots,s$

$$T_{s,k} = T_{s,k-1} + \frac{T_{s,k-1} - T_{s-1,k-1}}{\frac{4^k}{4^k-1}}$$

(*) $4^k = 2^{2k}$, protože v rozvoji chyby tohoto vzorce jsou pouze sudé mocniny h .

Schéma

$$h \quad T_{00}$$

$$\frac{h}{2} \quad T_{10} \quad T_{11}$$

$$\frac{h}{4} \quad T_{20} \quad T_{21} \quad T_{22}$$

$$\frac{h}{8} \quad T_{30} \quad T_{31} \quad T_{32} \quad T_{33}$$

Poznámka: Pokud se např. rovnají T_{22} a T_{32} , nemusíme počítat T_{33} , protože vyjde stejně.

Příklad:

Použijte opakování Richardsonovy extrapolaci pro výpočet derivace funkce $f(x) = \ln x$ v bodě $x_0 = 3$ pomocí centrální poměrné diference s kroky $h=0,8; 0,4; 0,2; 0,1$.

Řešení:

Ukázali jsme, že pro dostatečně hladkou funkci f platí vztah

$$f'(x_0) = \frac{f(x_0+h) - f(x_0-h)}{2h} + \underbrace{c_1 h^2 + c_2 h^4 + c_3 h^6 + \dots}_{\text{rozvoj chyby}}$$

kde čísla c_1, c_2, c_3 představují kontanty obsahující příslušné derivace.

Výsledky zapíšeme přehledně do tabulky:

h	$f'(x_0, h)$	1. korekce $[\frac{4}{3}, -\frac{1}{3}]$	2. korekce $[\frac{16}{15}, -\frac{1}{15}]$
0,8	0,341589		
0,4	0,335329	$\frac{4}{3}0,335329 - \frac{1}{3}0,341589 = 0,333242$	
0,2	0,333828	$\frac{4}{3}0,333828 - \frac{1}{3}0,335329 = \frac{16}{15}0,333327 - \frac{1}{15}0,333242 = 0,333332$	
0,1	0,333456	$\frac{4}{3}0,333456 - \frac{1}{3}0,333828 = \frac{16}{15}0,333332 - \frac{1}{15}0,33327 = 0,333332$	

Ve výpočtu jsme použili jednak 1. korekci pro eliminaci chybu řádu h^2 , ale dále také 2. korekci, která eliminovala chybu řádu h^4 .

V tabulce chybí sloupec pro 3. korekci. Důvod je ten, že se hodnoty, ze kterých by se extrapolovala nová hodnota, rovnají (dostali bychom to samé číslo).

Pro úplnost dodejme, že přesná hodnota derivace je $f'(x) = \frac{1}{x}$, tj. $f'(3) = \frac{1}{3}$.

Pomocí následujících výsledků lze porovnat efektivitu při použití různých vzorců.

výsledky v MATLABu

```
>> derivace_richardson('D_P', '-sin(exp(x))', 1, 0.4, 3);
```

```
Vypočte hodnotu první derivace zadane funkce
f=-sin(exp(x)) v bode x0=1.000000 s kroky
h=[0.4, 0.2, 0.1, 0.05]
```

Pro výpočet se použije vzorec prave pomerne diference D_P.

Ke zpřesnění se použije Richardsonova extrapolace.

!	h	$D_P(f, x_0, h)$	1. korekce	2. korekce	3. korekce
1	0.40000	3.006234654			
2	0.20000	2.941793905	2.877353156		
3	0.10000	2.737868276	2.533942647	2.419472477	
4	0.05000	2.612795286	2.487722295	2.472315512	2.479864517

Presna hodnota derivace funkce f v bode x0 je 2.478349732955

výsledky v MATLABu

```
>> derivace_richardson('D_L', '-sin(exp(x))', 1, 0.4, 3);
-----  
Vypočte hodnotu první derivace zadane funkce  
f=-sin(exp(x)) v bode x0=1.000000 s kroky  
h=[0.4, 0.2, 0.1, 0.05]  
  
Pro vypocet se použije vzorec leve pomerne diference D_L.  
Ke zpřesnění se použije Richardsonova extrapolace.  
-----  
! h | D_L(f,x0,h) | 1.korekce | 2.korekce | 3.korekce |  
=====|=====  
| 0.4000 | 1.394507747 | | | |
| 0.2000 | 1.912110950 | 2.429714153 |  
| 0.1000 | 2.195575019 | 2.479039089 | 2.495480735 |  
| 0.0500 | 2.338245228 | 2.480915437 | 2.481540886 | 2.479549479 |  
  
Presna hodnota derivace funkce f v bode x0 je 2.478349732955
```

výsledky v MATLABu

```
>> derivace_richardson('D_C', '-sin(exp(x))', 1, 0.4, 3);
-----  
Vypočte hodnotu první derivace zadane funkce  
f=-sin(exp(x)) v bode x0=1.000000 s kroky  
h=[0.4, 0.2, 0.1, 0.05]  
  
Pro vypocet se použije vzorec centralni pomerne diference D_C.  
Ke zpřesnění se použije Richardsonova extrapolace.  
-----  
! h | D_C(f,x0,h) | 1.korekce | 2.korekce | 3.korekce |  
=====|=====  
| 0.4000 | 2.200371201 | | | |
| 0.2000 | 2.426952427 | 2.502479503 |  
| 0.1000 | 2.466721648 | 2.479978054 | 2.478477958 |  
| 0.0500 | 2.475520257 | 2.478453127 | 2.478351465 | 2.478349457 |  
  
Presna hodnota derivace funkce f v bode x0 je 2.478349732955
```

Aproximaci derivace funkce jsme již použili např. u odvození metody sečen z Newtonovy metody.

Newtonova metoda

$$x_{k+1} = x_k - \frac{f(x_k)}{f'(x_k)}$$

$$f(x_k) \approx \frac{f(x_k) - f(x_{k-1})}{x_k - x_{k-1}}$$

metoda sečen

$$x_{k+1} = x_k - \frac{x_k - x_{k-1}}{f(x_k) - f(x_{k-1})}$$

Metoda konečných differencí

... jeden ze způsobů řešení okrajových úloh.

Řešme okrajovou úlohu (ODR 2.řádu)

$$-u'' + q(x)u = f(x) \quad x \in (0,1)$$

$$u(0) = g_0$$

$$u(1) = g_1$$

q, f, \dots dané funkce definované a spojité na $(0,1)$, $q(x) \geq 0$

g_0, g_1, \dots daná čísla

(\Rightarrow úloha má právě 1 klasické řešení)

Interval $(0,1)$ rozdělíme na N stejných podintervalů (ekvidistantní síť)



$$S = \{x_i = ih; \quad i = 0, 1, \dots, N\} \quad \dots \text{ síť}; \quad h \dots \text{krok sítě}.$$

Přibližné řešení konstruujeme jako funkci diskrétního argumentu x_i .

Přibližné řešení je určeno vektorem $U = [U_0, U_1, U_2, \dots, U_{N-1}, U_N]$, kde složky U_i approximují hodnoty $u(x_i)$ přesného řešení v uzlech sítě.

Klasické řešení splňuje rovnici ④ v každém bodě $x \in (0,1)$, tj.

$$-u''(x) + q(x)u(x) = f(x)$$

Na $(0,1)$ jsme zvolili rovnoramennou síť S a v každém vnitřním bodě této sítě musí platit:

$$-u''(x_i) + q(x_i)u(x_i) = f(x_i), \quad i = 1, 2, \dots, N-1$$

④④

druhou derivaci approximujeme druhou pomerou diferenčí

$$u''(x_i) \approx \frac{1}{h} \left[\frac{u(x_i+h) - u(x_i) - u(x_i) + u(x_i-h)}{h} \right] = \frac{1}{h^2} [u(x_i-h) - 2u(x_i) + u(x_i+h)]$$

soustavu ④④ nahradíme soustavou přibližných rovnic

$$-\frac{1}{h^2} [u(x_i-h) - 2u(x_i) + u(x_i+h)] + q(x_i)u(x_i) \approx f(x_i)$$

tj.

$$-\frac{1}{h^2}(U_{i-1} - 2U_i + U_{i+1}) + q(x_i)U_i = f(x_i) \quad i = 1, 2, \dots, N-1$$

$$U_0 = g_0$$

$$U_N = g_1$$

... soustava diferenčních rovnic

$$x_0=0 \quad x_1 \quad x_2 \quad x_3 \quad x_4 \quad x_5 \quad \dots \quad x_{N-1} \quad x_N=1$$

Neznámé hodnoty uvnitř intervalu, tj. v x_1, x_2, \dots, x_{N-1} .

V první rovnici figuruje hodnota U_0 , ta je ale rovna g_0 a tento člen převedeme na pravou stranu. Obdobně pro poslední rovnici, za U_N dosadíme g_1 a převedeme na pravou stranu.

Získaná soustava:

$$\frac{1}{h^2} \begin{bmatrix} 2 + h^2 q_1 & -1 & 0 & \dots & 0 \\ -1 & 2 + h^2 q_2 & -1 & 0 & \dots \\ 0 & -1 & 2 + h^2 q_3 & -1 & \dots \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \vdots & \vdots & 0 & -1 & 2 + h^2 q_{N-2} & -1 \\ 0 & 0 & \dots & 0 & -1 & 2 + h^2 q_{N-1} \end{bmatrix} \begin{bmatrix} U_1 \\ U_2 \\ U_3 \\ \vdots \\ \vdots \\ U_{N-1} \end{bmatrix} = \begin{bmatrix} f_1 + \frac{g_0}{h^2} \\ f_2 \\ f_3 \\ \vdots \\ \vdots \\ f_{N-1} - \frac{g_1}{h^2} \end{bmatrix}$$

Soustava lineárních algebraických rovnic $\boxed{\mathbf{A}\mathbf{U} = \mathbf{F}}$

\mathbf{A} ... symetrická, třidiagonální, pozitivně definitní (\Rightarrow regulární)

- symetrie matic je důsledek symetrie použité diferenční approximace u'' a očislování uzlů (zde je vše přirozené, význam u parciálních diferenciálních rovnic)

- pro regulární matici soustavy \exists řešení

Otzázy:

S jakou přesností přibližné řešení approximuje přesné řešení?

Zmenšuje se chyba přibližného řešení, zjemňujeme-li síť, tj. $h \rightarrow 0$?

Poznámka: Pro approximaci derivací lze samozřejmě použít i jiné vzorce.

Použijeme-li např. vzorec 7, bude výsledná matice soustavy opět pásová, šíře pásu bude nyní 5.

Ukažme si jak postupovat při diskretizaci úlohy s derivací v okrajové podmínce.

Je-li na některém z konců intervalu zadána Neumannova nebo Newtonova okrajová podmínka, musíme předchozí postup modifikovat, neboť neznámé hodnotu $u(0)$ nebo $u(1)$.

V takovém případě musíme sestavit také diferenční approximaci příslušné okrajové podmínky a připojit ji k soustavě diferenčních rovnic, jež ve vnitřních uzlech approximují diferenční rovnici.

Ukážeme tři takové možné approximace pro řešení následující úlohy.

$$-u'' + q(x)u = f(x) \quad x \in (0,1)$$

$$\alpha_0 u(0) - \beta_0 u'(0) = g_0 \quad \beta_0 > 0$$

$$u(1) = g_1$$

Ve vnitřních uzlech sítě approximujeme diferenční rovnici (4) stejnými diferenčními rovnicemi jako v předchozím případě

$$-\frac{1}{h^2}(U_{i-1} - 2U_i + U_{i+1}) + q(x_i)U_i = f(x_i) \quad i = 1, 2, \dots, N-1$$

V těchto rovnících vystupují neznámé $U_0, U_1, \dots, U_{N-1}, U_N$.

Abychom dostali stejný počet rovnic jako neznámých, musíme tedy (na základě okrajových podmínek) k získaným $N-1$ rovnicím ještě 2 rovnice připojit. Jednu z nich dostaneme z Dirichletovy okrajové podmínky v bodě $x=1$ tak, že položíme $\boxed{U_N = g_1}$. Levou okrajovou podmínu (v bodě $x=0$) můžeme zužitkovat různými způsoby.

1.způsob

Aproximujeme-li $u(0)$ pomocí vzorce 1 (tj. pravé poměrné diference), dojdeme k diferenční rovnici

$$\frac{U_1 - U_0}{h} = g_0 \quad (\beta_0 \neq 0)$$

kterou klasické řešení splňuje s chybou velikosti $\mathcal{O}(h)$. Rovnice vynásobíme číslem $1/(h\beta_0)$ a upravíme na tvar

$$\frac{1}{h^2} \left[(1 - \frac{\alpha_0}{\beta_0} h) U_0 - U_1 \right] = \frac{g_0}{h \beta_0}.$$

tuto úpravu děláme proto, aby výsledná matici soustavy síťových rovnic byla symetrická.

Předchozí rovnici přidáme k získaným diferenčním rovnicím a dosadíme g_1 za U_N . Dostaneme opět soustavu lineárních algebraických rovnic se symetrickou třidiagonální maticí (pozor: $U = [U_0, U_1, \dots, U_{N-1}]^T$).

$$\frac{1}{h^2} \begin{bmatrix} 1 + \frac{\alpha_0 h}{\beta_0} & -1 & 0 & \cdots & 0 \\ -1 & 2 + h^2 q_1 & -1 & 0 & \cdots \\ 0 & -1 & 2 + h^2 q_2 & -1 & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \vdots & \vdots & 0 & -1 & 2 + h^2 q_{N-2} & -1 \\ 0 & 0 & 0 & -1 & 2 + h^2 q_{N-1} & -1 \end{bmatrix} \begin{bmatrix} U_0 \\ U_1 \\ U_2 \\ \vdots \\ \vdots \\ U_{N-1} \end{bmatrix} = \begin{bmatrix} \frac{g_0}{h \beta_0} \\ f_1 \\ f_2 \\ \vdots \\ f_{N-2} \\ \frac{g_1}{h^2} \end{bmatrix}$$

Matici soustavy je řádu N a lze dokázat, že je regulární. Přibližné řešení lze proto jednoznačně stanovit a da se ukázat, že jeho chyba je velikosti $O(h)$.

Tato skutečnost, tj. snížení řádu chyby metody, možná překvapí, neboť síťová rovnice pro všechny uzly s výjimkou x_0 approximuje diferenční rovnici s diskretizační chybou $O(h^2)$. Přesto však okolnost, že jsme se v jediné rovnici dopustili diskretizační chybu velikosti $O(h)$, ovlivní velikost chyby metody nejen v blízkosti bodu x_0 , ale ve všech bodech sítě. Jde tu o jev, který je pro užívání diferenční metod typický a ukazuje, že chceme-li využít přesnosti, s níž jsme approximovali diferenční rovnici samotnou, musíme stejně přesně approximovat i okrajové podmínky.

2. způsob

Bezprostředně možnost přesnejší nahradby hodnoty derivace v okrajové podmínce spočívá v užití vzorce 4 a 5 z tabulky. Tyto approximace mají pro $u \in C^3$ diskretizační chybu $O(h^2)$.

Vzniklá soustava diferenčních rovnic však již není třidiagonální, není symetrická a navíc se při jejím řešení standardními metodami mohou vyskytnout numerické problémy. Proto tento postup nedoporučujeme.

3. způsob

Hodnotu $u'(0)$ approximujeme pomocí vzorce 3 (centrální poměrná diference).

$$u'(0) \approx \frac{1}{2h} [u(x_1) - u(x_{-1})],$$

kde $x_{-1} = -h$.

Chyba approximace je druhého řádu. Okrajovou podmínu $\alpha_0 u(0) - \beta_0 u'(0) = g_0$ tak nahradíme diferenční rovnici

$$\alpha_0 U_0 - \beta_0 \frac{U_1 - U_{-1}}{2h} = g_0 \quad (\heartsuit)$$

Je zde však navíc další neznámá U_{-1} a potrebujeme proto připojit ještě jednu rovnici.

Nejjednodušší to provedeme tak, že žádáme platnost rovnice pro vnitřní uzly i pro hraniční uzel x_0 , tj. platnost rovnice

$$-\frac{1}{h^2}(U_{-1} - 2U_0 + U_1) + q(x_0)U_0 = f(x_0). \quad (\diamondsuit)$$

(Jde vlastně o approximaci diferenční rovnice v bodě $x=0$).

Fiktivní hodnotu U_{-1} , která nemá význam approximace přesného řešení naší okrajové úlohy (neboť toto řešení uvažujeme pouze na intervalu $(0,1)$), z rovnic (\heartsuit) , (\diamondsuit) vyloučíme

$$U_{-1} = h^2(g_0 U_0 - f_0) + 2U_0 - U_1,$$

Kapitola 10. Numerické integrování

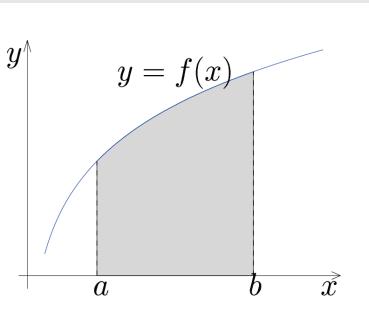
Numerický výpočet hodnoty určitého integrálu

Formulace: Mějme na $\langle a, b \rangle$ dánu integrovatelnou funkci $f = f(x)$. Naším cílem je určit přibližnou hodnotu určitého integrálu

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

Poznámka:

Geometrický význam integrálu $I(f)$ (viz obrázek) je obsah plochy mezi grafem funkce f a osou x na intervalu $\langle a, b \rangle$.



Numerické metody výpočtu integrálu užíváme zejména tehdy, když $I(f)$ není možno spočítat analyticky (velmi častý případ) nebo je sice analytické řešení možné, ale je velmi pracné. V případě, že máme zadánu funkci f tabulkou, není ani jiný přístup možný.

Přirozený princip numerických metod pro výpočet integrálu vychází z approximace funkce. Danou funkci f nahradíme její vhodnou approximací φ a jako approximaci integrálu $I(f)$ prohlásíme hodnotu integrálu $I(\varphi)$, tj.

$$I(f) \approx I(\varphi) = \int_a^b \varphi(x) dx.$$

Poznámka:

Narození od výpočtu derivace je výpočet integrálu stabilní, protože je-li φ dobrou approximací funkce f na intervalu $\langle a, b \rangle$, je integrál $I(\varphi)$ dobrou approximací $I(f)$.

dosadíme

$$\alpha_0 U_0 - \beta_0 \frac{U_1 - U_{-1}}{2h} = g_0$$

a dospějeme k diferenční rovnici

$$(\alpha_0 + \frac{1}{2} \beta_0 h \varphi_0) U_0 - \beta_0 \frac{U_1 - U_0}{h} = g_0 + \frac{1}{2} \beta_0 h \varphi_0,$$

která approximuje okrajovou podmínu v bodě $x_0 = 0$ a kterou dostatečně hladké přesné řešení naší okrajové úlohy splňuje s chybou řádové velikosti $O(h^2)$. Rovnici upravíme na tvar

$$\frac{1}{h^2} \left[(1 + \frac{\alpha_0 h}{\beta_0} + \frac{1}{2} h^2 \varphi_0) U_0 - U_1 \right] = \frac{g_0}{h \beta_0} + \frac{1}{2} \beta_0 h \varphi_0$$

a připojíme ji k diferenčním rovnicím pro vnitřní uzly.

Dá se ukázat, že **chyba přibližného řešení je** v tomto případě velikosti $O(h^2)$.

$$\left| \int_a^b f(x) dx - \int_a^b \varphi(x) dx \right| \leq \int_a^b |f(x) - \varphi(x)| dx \leq (b-a) \underbrace{\sup_{x \in (a,b)} |f(x) - \varphi(x)|}_{\varepsilon}$$

Princip většiny metod na výpočet určitého integrálu

$$\int_a^b f(x) dx$$

je založen na tom, že interval $\langle a, b \rangle$ rozdělíme na N podintervalů $\langle x_k, x_{k+1} \rangle$ tak, že

$$a = x_0 < x_1 < x_2 < \dots < x_{N-1} < x_N = b.$$

Na těchto podintervalech nahradíme funkci f polynomem a integrujeme tento polynom.

Vzorce pro výpočet určitého integrálu (tzv. kvadraturní vzorce) dělíme na:

na intervalech $\langle x_k, x_{k+1} \rangle \dots$ **základní**

přes celý interval $\langle a, b \rangle \dots$ **složený** (složený kv. vzorec je součtem základních kv. vzorců)

Pro jednoduchost předpokládáme, že jsou všechny podintervaly $\langle x_k, x_{k+1} \rangle$ stejně velké.

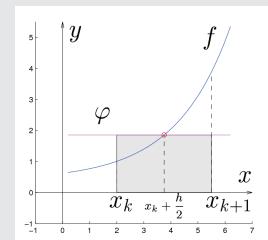
Ekvidistantní uzly potom vyjádříme takto

$$x_k = x_0 + kh, \quad \text{kde } k = 0, 1, \dots, N-1 \quad \text{a } h = \frac{b-a}{N}.$$

Newtonovy-Cotesovy základní kvadraturní vzorce

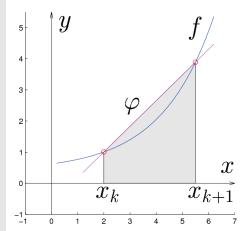
1) Obdélníkové pravidlo (f nahrazujeme konstantní funkcí φ)

$$\int_{x_k}^{x_{k+1}} f(x) dx \approx h \cdot f(x_k + \frac{h}{2}) \equiv R_2(f, h)$$



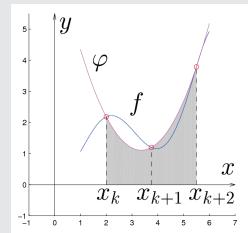
2) Lichoběžníkové pravidlo (f nahrazujeme lineární funkci φ)

$$\int_{x_k}^{x_{k+1}} f(x) dx \approx \frac{h}{2} [f(x_k) + f(x_{k+1})] \equiv T_Z(f, h)$$



3) **Simpsonovo pravidlo** (f nahrazujeme kvadratickou funkci φ)

$$\int_{x_k}^{x_{k+2}} f(x) dx \approx \frac{h}{3} [f(x_k) + 4f(x_{k+1}) + f(x_{k+2})] \equiv S_Z(f, h)$$



Odrození Simpsonova pravidla

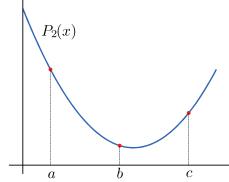
Např. pomocí Lagrangeova interpolačního polynomu:

$$P_2(x) = f(a)l_a(x) + f(b)l_b(x) + f(c)l_c(x)$$

$$l_a(x) = \frac{(x-b)(x-c)}{(a-b)(a-c)} = \frac{(x-b)(x-c)}{2h^2}$$

$$l_b(x) = \frac{(x-a)(x-c)}{(b-a)(b-c)} = \frac{(x-a)(x-c)}{-h^2}$$

$$l_c(x) = \frac{(x-a)(x-b)}{(c-a)(c-b)} = \frac{(x-a)(x-b)}{2h^2}$$



$$\begin{aligned} \int_a^c P_2(x) dx &= \frac{f(a)}{2h^2} \int_a^c (x-b)(x-c) dx - \frac{f(b)}{h^2} \int_a^c (x-a)(x-c) dx + \frac{f(c)}{2h^2} \int_a^c (x-a)(x-b) dx = \\ &= \frac{f(a)}{2h^2} \left[\frac{x^3}{3} - \frac{x^2}{2}(b+c) + bxc \right]_a^c - \frac{f(b)}{h^2} \left[\frac{x^3}{3} - \frac{x^2}{2}(a+c) + axc \right]_a^c + \frac{f(c)}{2h^2} \left[\frac{x^3}{3} - \frac{x^2}{2}(a+b) + xab \right]_a^c = \\ &= \frac{f(a)}{2h^2} \underbrace{\left[\frac{c^3}{3} - \frac{c^2}{3} - \left(\frac{c^2}{2} - \frac{a^2}{2} \right) (b+c) + (c-a)bc \right]}_{(*)} - \frac{f(b)}{h^2} \underbrace{\left[\frac{c^3}{3} - \frac{c^2}{3} - \left(\frac{c^2}{2} - \frac{a^2}{2} \right) (a+c) + (c-a)ac \right]}_{(**)} + \\ &\quad + \frac{f(c)}{2h^2} \underbrace{\left[\frac{c^3}{3} - \frac{c^2}{3} - \left(\frac{c^2}{2} - \frac{a^2}{2} \right) (a+b) + (c-a)ab \right]}_{(***)} \end{aligned}$$

$$\begin{aligned} (*) & \quad \frac{1}{6}(c-a)[2c^2 + ac + 2a^2 - 3(a+c)(b+c) + 6bc] = \\ & = \frac{2h}{6}[2c^2 + 2ac + 2a^2 - 3(a+b)c - 3c^2 - 3ab + 6bc] = \\ & = \frac{2h}{6}[-c^2 - ac + 3bc + 2a^2 - 3ab] = \\ & = \frac{2h}{6}\left[\underbrace{\frac{a^2 - c^2}{a-c}}_{-2h}(a+c) + \underbrace{3b(c-a)}_{2h} + \underbrace{a(a-c)}_{-2h}\right] = \\ & = \frac{2h}{6}[-(a+c)2h + 2h3b - 2ha] = \\ & = -\frac{4h^2}{6}[a+c - 3b+a] = \\ & = -\frac{4h^2}{6}\left(\frac{2a-2b}{-2h} + \frac{c-b}{h}\right) = \\ & = \frac{4h^3}{6} = \frac{2}{3}h^3 \end{aligned}$$

(**) ... = $-\frac{1}{6}(2h)^3$ viz pomocný výpočet pro odvození lichoběžníkového pravidla (slide 10.5.)

(***) ... = $\frac{2}{3}h^3$ stejně jako (*) - plyne ze symetrie

$$\int_a^c P_2(x) dx = \frac{f(a)}{2h^2} \frac{2}{3}h^3 + \frac{f(b)}{h^2} \frac{1}{6}(2h)^3 + \frac{f(c)}{2h^2} \frac{2}{3}h^3 = \frac{h}{3}[f(a) + 4f(b) + f(c)] = T_Z(f, h)$$

Příklad:

Pomocí základních Newtonových-Cotesových vzorců vypočtěte integrál

$$\int_1^{1.2} e^x dx.$$

Řešení:

(Presné řešení je $[e^x]_1^{1.2} = e^{1.2} - e^1 \doteq 0,601835$)

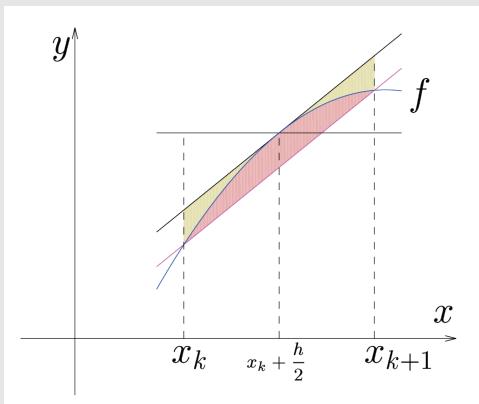
$$T_Z(e^x; 0,2) = 0,2e^{1.1} \doteq 0,600833 \quad \text{chyba: 0,001002}$$

$$T_Z(e^x; 0,2) = \frac{0.2}{2}(e^{1.0} + e^{1.2}) \doteq 0,603839 \quad \text{chyba: 0,002003}$$

$$S_Z(e^x; 0,1) = \frac{0.1}{3}(e + 4e^{1.1} + e^{1.2}) \doteq 0,601835 \quad \text{chyba: 0,000000}$$

Poznámka:

Všimněme si chyb. U obdélníkového pravidla vyšla chyba menší než u lichoběžníkového, přestože u lichoběžníkového pravidla jsme funkci f approximovali „lepší“ funkci φ (lineární). Chyba u Simpsonova pravidla vyšla menší než u ostatních. Tyto výsledky potvrzují vztahy pro chyby jednotlivých vzorců. Fakt, že obdélníkové pravidlo je přesnější než lichoběžníkové můžeme demonstrovat na obrázku:



Základní vzorec se odvodí snadno na základě geometrické interpretace.

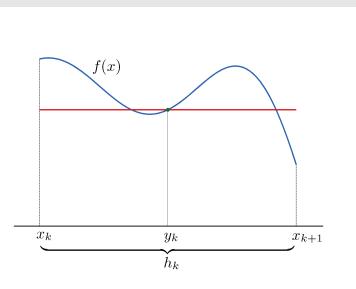
Pokud chceme vyjádřit současně i vztahy pro chyby těchto vzorců, musíme použít k odvození Taylorův rozvoj.

$$\int_{x_k}^{x_{k+1}} f(x) dx = R_Z(f, h) + \frac{h^3}{24} f'''(\xi_k)$$

$$\begin{aligned} \int_{x_k}^{x_{k+1}} f(x) dx &= T_Z(f, h) - \frac{h^3}{12} f'''(\xi) \\ \int_{x_k}^{x_{k+2}} f(x) dx &= S_Z(f, h) - \frac{h^5}{90} f^{(4)}(\xi) \end{aligned}$$

Odrození pro obdélníkové pravidlo

Předpokládejme, že je integrovaná funkce f dostatečně hladká a použijeme Taylorův polynom.



Označíme

$$h_k = x_{k+1} - x_k, \quad y_k = \frac{x_k + x_{k+1}}{2}$$

$$f(x) = f(y_k) + (x - y_k)f'(y_k) + \frac{1}{2}(x - y_k)^2 f''(\xi_k), \quad \xi_k \in \text{int}\{y_k, x\}$$

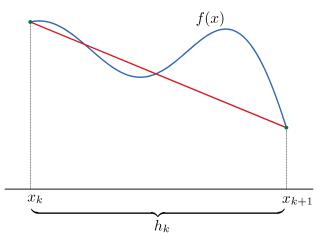
Potom platí:

$$\begin{aligned} \int_{x_k}^{x_{k+1}} f(x) dx &= h_k f\left(\frac{x_k + x_{k+1}}{2}\right) + \frac{1}{2} \left[(x_{k+1} - y_k)^2 - (x_k - y_k)^2 \right] f'\left(\frac{x_k + x_{k+1}}{2}\right) + \\ &\quad + f''(\xi_k) \frac{1}{6} \left[(x_{k+1} - y_k)^3 - (x_k - y_k)^3 \right] \end{aligned}$$

$$\int_{x_k}^{x_{k+1}} f(x) dx = h_k f\left(\frac{x_k + x_{k+1}}{2}\right) + \frac{h_k^3}{24} f''(\xi_k) \quad \text{chyba metody}$$

Odrození pro lichoběžníkové pravidlo

Funkci f approximujeme na $\langle x_k, x_{k+1} \rangle$ lineární funkci, tj. interpolaciálním polynomem 1. stupně.



Z approximací funkce známe:

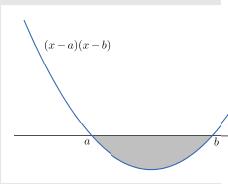
$$f(x) = P_2(x) + \frac{f''(\xi_k)}{2}(x - x_k)(x - x_{k+1}), \quad \xi_k \in (x_k, x_{k+1})$$

Potom platí:

$$\int_{x_k}^{x_{k+1}} f(x) dx = \frac{h_k}{2} (f(x_k) + f(x_{k+1})) + \frac{f''(\xi_k)}{2} \int_{x_k}^{x_{k+1}} (x - x_k)(x - x_{k+1}) dx$$

pomocný výpočet

$$\begin{aligned} \int_a^b (x-a)(x-b) dx &= \int_a^b (x^2 - x(a+b) + ab) dx = \\ &= \frac{b^3}{3} - \frac{a^3}{3} - \left(\frac{b^2}{2} - \frac{a^2}{2} \right) (a+b) + (b-a)ab = \\ &= \frac{1}{3}(b-a)(b^2 + ab + a^2) - \frac{1}{2}(b-a)(a+b)^2 + (b-a)ab = \\ &= \frac{1}{6}(b-a) [2b^2 + 2ab + 2a^2 - 3a^2 - 6ab - 3b^2 + 6ab] = \\ &= \frac{1}{6}(b-a)[-a^2 + 2ab - b^2] = -\frac{1}{6}(b-a)^3 \end{aligned}$$



$$\int_{x_k}^{x_{k+1}} f(x) dx = \frac{h_k}{2} (f(x_k) + f(x_{k+1})) - \frac{h_k^3}{12} f''(\xi_k)$$

chyba metody

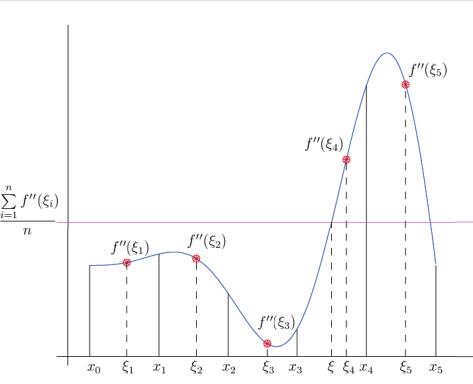
Komentář pro Simpsonovo pravidlo

Funkci f approximujeme na $\langle x_k, x_{k+2} \rangle$ kvadratickou funkci, tj. interpolačním polynomem 2. stupně.

$$f(x) = P_2(x) + \frac{f'''(\xi)}{6}(x - x_k)(x - x_{k+1})(x - x_{k+2})$$

$$\begin{aligned} I(f) &= R(f, h) + (b-a) \frac{h^2}{24} f''(\xi) \\ I(f) &= T(f, h) - (b-a) \frac{h^2}{12} f''(\xi) \\ I(f) &= S(f, h) - (b-a) \frac{h^3}{180} f^{(4)}(\xi) \end{aligned}$$

$$\sum_{k=1}^N \underbrace{\frac{h^3}{24} f''(\xi_k)}_{\text{chyba základního vzorce na } \langle x_{k-1}, x_k \rangle} = \frac{h^3}{24} \sum_{k=1}^N f''(\xi_k) = \frac{h^3}{24} N f''(\xi) = \frac{h^3}{24} \frac{b-a}{h} f''(\xi)$$



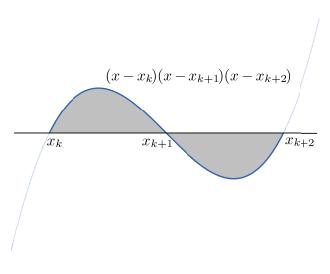
Průměr hodnot leží mezi minimální a maximální hodnotou:

$$\min_k f''(\xi_k) \leq \frac{1}{N} \sum_k f''(\xi_k) \leq \max_k f''(\xi_k)$$

Ze spojitosti funkce $f''(x)$ vyplývá:

$$\exists \xi \in (x_0, x_N) : f''(\xi) = \frac{1}{N} \sum_k f''(\xi_k)$$

$$\int_{x_k}^{x_{k+2}} f(x) dx = S_Z(f, h) + \frac{f'''(\xi)}{6} \int_{x_k}^{x_{k+2}} (x - x_k)(x - x_{k+1})(x - x_{k+2}) dx \dots$$

Ačkoliv u uvedeného vychází, že chyba je řádově měla být h^4 , je chyba o jeden řád vyšší. Důvod je podobný jako u odvození chyby obdélníkového pravidla (integrujeme funkci symetrickou podle středu intervalu).

Jelikož výraz pro chybu základního Simpsonova pravidla obsahuje 4-tou derivaci, je zřejmé, že Simpsonovo pravidlo bude přesně integrovat polynomy až do stupně 3, protože pro ně je 4-tá derivace identicky nulová.

Newton-Cotesovy složené kvadraturní vzorce

Složené kvadraturní vzorce získáme sečtením základních kvadraturních vzorců:

$$\int_a^b f(x) dx = \sum_{k=0}^{N-1} \int_{x_k}^{x_{k+1}} f(x) dx \approx \sum_{k=0}^{N-1} \int_{x_k}^{x_{k+1}} \varphi(x) dx$$

$$\begin{aligned} R(f, h) &\equiv h \cdot \sum_{k=0}^{N-1} f(x_k + \frac{h}{2}) \\ T(f, h) &\equiv \frac{h}{2} [f(x_0) + 2f(x_1) + 2f(x_2) + \dots + 2f(x_{N-1}) + f(x_N)] = \\ &= h \cdot \left[\frac{1}{2} f(x_0) + \sum_{k=1}^{N-1} f(x_k) + \frac{1}{2} f(x_N) \right] \\ S(f, h) &\equiv \frac{h}{3} [f(x_0) + 4f(x_1) + 2f(x_2) + 4f(x_3) + \\ &+ \dots + 2f(x_{N-2}) + 4f(x_{N-1}) + f(x_N)] \end{aligned}$$

Pro chyby složených vzorců potom platí:

Jak dosáhnout požadovanou přesnost?

Ze vzorců lze odhadnout velikost chyby, případně určit krok h tak, aby chyba byla menší než předem zadaná tolerance.Příklad Určete h tak, aby chyba složeného lichoběžníkového pravidla pro výpočet

$$I = \int_{\frac{3}{2}}^3 \frac{1}{(x-1)} dx$$

byla nejvýše 10^{-3} .

Musí platit:

$$\frac{(b-a)h^2}{12} \max_{x \in (2,3)} |f''(x)| \leq 10^{-3}$$

⇒ je nutné odhadnout f'' :

$$f' = -\frac{1}{(x-1)^2}$$

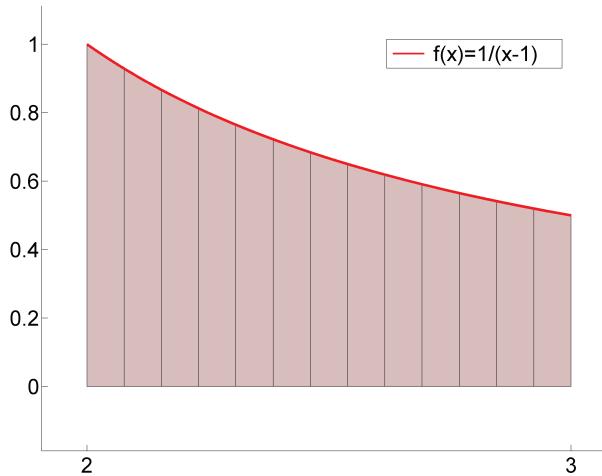
$$f'' = \frac{2}{(x-1)^3} \quad \text{na } (2,3) \quad \text{je } f'' > 0 \text{ (kladná)}$$

$$f''' = -\frac{3}{(x-1)^4} < 0 \Rightarrow f''' \text{ je klesající}$$

$$\Rightarrow \max_{x \in (2,3)} |f''(x)| = f''(2) = \frac{2}{(2-1)^3} = 2$$

$$\frac{1}{12} h^2 \cdot 2 \leq 10^{-3} \Rightarrow h^2 \leq 6 \cdot 10^{-3}$$

$$\Rightarrow N = \frac{b-a}{h} = \frac{1}{\sqrt{6 \cdot 10^{-3}}} \doteq 12,9 \Rightarrow \text{nejbližší vyšší } [N=13] \Rightarrow h = \frac{1}{13}$$



$$T\left(\frac{1}{(x-1)}, \frac{1}{13}\right) = \dots \doteq 0,69352$$

Přesná hodnota: $I = [\ln|x-1|]_2^3 = \ln 2 - \ln 1 = \ln 2 \doteq 0,69315$

Skutečná chyba: $3,7 \cdot 10^{-4} \leq 10^{-3}$

Nevýhody tohoto postupu:

- výrazy pro chybu obsahují derivace (často vysokého řádu), které není lehké odhadnout
- výsledné odhady jsou většinou velmi pesimistické
- Newton-Cotesovy vzorce nejsou konvergentní (zvyšujeme-li řád vzorce, nemusí konvergovat aproximace integrálů k teoretické hodnotě)
- pro odhad chyby je vhodné užít metodu polovičního kroku (Richardsonova extrapolace)

Richardsonova extrapolace

Stručně si připomeňme princip Richardsonovy extrapolace, kterou jsme již používali pro zpřesňování při výpočtu hodnoty derivace funkce.

Předpokládejme, že výraz pro chybu má tvar

$$e(f) = h^k M, \quad h = \frac{b-a}{N}$$

Přesná hodnota integrálu je potom

$$I = K(h) + h^k M. \quad (*)$$

Integrál vypočteme stejným vzorcem, ale s krokem $\frac{h}{2}$. Dostaneme

$$I = K\left(\frac{h}{2}\right) + \underbrace{\left(\frac{h}{2}\right)^k M_1}_{\text{ozn. } \varepsilon} \Rightarrow h^k = \frac{\varepsilon 2^k}{M_1} \quad (**)$$

Dosadíme-li h^k do (*), získáme

$$I = K(h) + \frac{\varepsilon 2^k M}{M_1} \quad (***)$$

Předpokládáme-li, že se hodnota derivace ve výrazu $e(f)$ pro chybu příliš nemění (tj. $M \approx M_1$), potom $\frac{M}{M_1} \approx 1$ a pro (**) a (***) musí platit

$$K\left(\frac{h}{2}\right) + \varepsilon \approx K(h) + 2^k \varepsilon$$

Odtud plyne odhad chyby ε

$$\varepsilon \approx \frac{1}{2^k - 1} [K\left(\frac{h}{2}\right) - K(h)]$$

a přesnejší hodnota integrálu je potom

$$I = K\left(\frac{h}{2}\right) + \frac{1}{2^k - 1} [K\left(\frac{h}{2}\right) - K(h)]$$

$k \dots$ řád eliminované chyby

Algoritmus

(Pro složené lichoběžníkové pravidlo)

Pro $s = 0, 1, 2, \dots, S$	$h_0 = b - a$
$T_{s,0} = T(f, h_s)$	$h_1 = \frac{1}{2} h_0$
Pro $k = 1, 2, \dots, s$	\vdots
$T_{s,k} = T_{s,k-1} + \frac{T_{s,k-1} - T_{s-1,k-1}}{4^k - 1}$	$h_s = \frac{1}{2^s} h_0$

Schéma

h	$T_{0,0}$
$\frac{b}{2}$	$T_{1,0} \quad T_{1,1}$
$\frac{h}{4}$	$T_{2,0} \quad T_{2,1} \quad T_{2,2}$
$\frac{h}{8}$	$T_{3,0} \quad T_{3,1} \quad T_{3,2} \quad T_{3,3}$

Všechny hodnoty $T_{s,k}$ jsou approximacemi původního integrálu.

Pro funkci f integrovatelnou v Riemannově smyslu platí

$$T_{s,k} \rightarrow I(f) \text{ pro } s \rightarrow \infty, k = 0, 1, \dots$$

a také

$$T_{s,k} \rightarrow I(f) \text{ pro } k \rightarrow \infty.$$

Dále se dá ukázat, že celá procedura je numericky stabilní.

Pro kontrolu uveďme přesnou hodnotu integrálu:

$$\int_1^5 \ln x \, dx = \left| \begin{array}{l} u = \ln x \quad v' = 1 \\ u' = \frac{1}{x} \quad v = x \end{array} \right| = [x \ln x]_1^5 - \int_1^5 \frac{1}{x} \, dx = 5 \ln 5 - 4 \doteq 4,04719$$

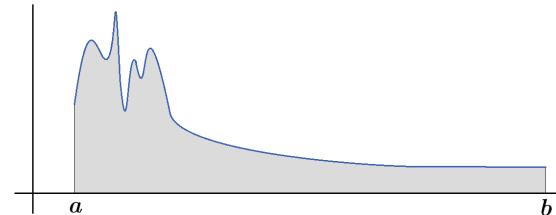
Poznámka

Metoda Richardsonovy extrapolace pro lichoběžníkové pravidlo se nazývá **Rombergova metoda**.

Adaptivní integrování

- intervaly integrace nejsou dány dopředu
- určují se na základě splnění testu chyby založeném na odhadu pomocí metody polovičního kroku

Motivace: Pokud má integrovaná funkce např. tento průběh



je zřejmé, že na druhé části intervalu stačí pro splnění zadané tolerance uvažovat větší kroky, než v první části.

Stavy

S ... interval, na kterém je zajištěno splnění chybějícího testu

A ... aktivní interval integrace

N ... interval, přes který se ještě nezapočítal dílčí integrál

Příklad

Pomocí lichoběžníkového pravidla vypočteťte $\int_1^5 \ln x \, dx$. Ke zpřesnění použijte Richardsonovu extrapolaci.

Řešení: Pro rozvoj chyby lichoběžníkového pravidla platí

$$I = T(f, h) + \underbrace{a_1 h^2}_{\text{tab. k=2}} + \underbrace{a_2 h^4}_{\text{tab. k=4}} + a_3 h^6 + \dots$$

Výsledky opět zapíšeme do tabulky

h	$T(f, h)$	1. zpřesnění ($k = 2$)	2. zpřesnění ($k = 4$)
4	$\frac{4}{2}(\ln 1 + \ln 5) = 3,2188$		
2	$\frac{2}{2}(\ln 1 + 2 \ln 2 + \ln 5) = 3,8066$	$\frac{3,8066 - 3,2188}{3} + 3,8066 = 4,0025$	
1	$\frac{1}{2}(\ln 1 + 2 \ln 2 + 2 \ln 3 + 2 \ln 4 + \ln 5) = 3,9827$	$\frac{3,9827 - 3,8066}{3} + \frac{4,0414 - 4,0025}{15} + 3,9827 = 4,0414$	$\frac{4,0414 - 4,0414}{15} + 4,0414 = 4,04399$

Numerické metody
Josef Daněk

KMA/NM
13.2.2013

Změny stavu:

- (1) Je splněna podmínka na velikost chyby na intervalu A
- (2) Není splněna podmínka na velikost chyby na intervalu A

Test chyby: (pomocí metody polovičního kroku) – interval $\langle \alpha, \beta \rangle$ rozplíme a použijeme stejný vzorec

$$\varepsilon_f(\alpha, \beta) \approx \frac{1}{2^k - 1} \left[I_{\langle \alpha, \beta \rangle} \left(\frac{h}{2} \right) - I_{\langle \alpha, \beta \rangle}(h) \right], \quad k = \text{řad chyby vzorce}$$

$$\varepsilon_f(\alpha, \beta) \leq \varepsilon \frac{\beta - \alpha}{b - a}$$

ε – celková požadovaná přesnost

Algoritmus

na začátku:

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

$$N = \emptyset$$

$$S = \emptyset$$

$$I_S = 0 \quad (I_S \approx \int_a^b f(x) dx)$$

- (1) je splněn TEST CHYBY:
 - (i) $I_S := I_S + I_A$
 - (ii) $S = S \cup A; \quad A = N$
- (2) není splněn TEST CHYBY:

Příklad

Použijte adaptivní přístup pro výpočet

$$\int_0^3 \frac{1}{(0.3x - 0.1)^2 + 0.01} + \frac{1}{(x - 0.5)^2 + 0.04} - 6 dx$$

tak, aby výsledná chyba aproximace integrálu byla menší než 0,25.

Pro výpočet použijte obdélníkové, lichoběžníkové i Simpsonovo pravidlo.

Obdélníkové pravidlo

výsledky v MATLABu

Numerické metody
Josef Daněk

KMA/NM
13.2.2013

```
Adaptivni numericky vypocet urcитеho integralu funkce
f(x)=1 /((0.3*x-.1)^2+.01)+1/((x-.5)^2+.04)-6
na intervalu <0.000000,3.000000>
se zadanou presnosti 0.250000
Pro vypocet se pouzije obdelnikove pravidlo I_0.

Presna hodnota integralu ..... 69.800931
Vypoctena hodnota integralu .... 69.784747
Skutecna chyba ..... 0.016184
Odhadnutia chyba ..... 0.110713
Pocet podintervalu ..... 17
Celkovy pocet deleni intervalu
pro dodrzeni odhadu chyby .... 94
```

Numerické metody
Josef Daněk

KMA/NM
13.2.2013

```
Adaptivni numericky vypocet urcитеho integralu funkce
f(x)=1 /((0.3*x-.1)^2+.01)+1/((x-.5)^2+.04)-6
na intervalu <0.000000,3.000000>
se zadanou presnosti 0.250000
Pro vypocet se pouzije lichobeznikove pravidlo I_L.

Presna hodnota integralu ..... 69.800931
Vypoctena hodnota integralu .... 69.686611
Skutecna chyba ..... 0.114320
Odhadnutia chyba ..... -0.084305
Pocet podintervalu ..... 17
Celkovy pocet deleni intervalu
pro dodrzeni odhadu chyby .... 89
```

Lichoběžníkové pravidlo

výsledky v MATLABu

Simpsonovo pravidlo

výsledky v MATLABu

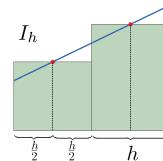
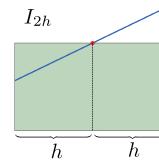
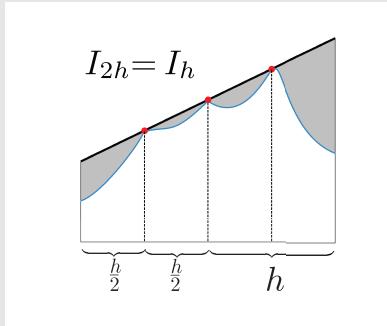
Adaptivní numericky vypocet urcитеho integralu funkce $f(x) = 1 / ((0.3*x - 1)^2 + 0.1) + 1 / ((x - 5)^2 + 0.04) - 6$ na intervalu $<0..000000, 3..000000>$ se zadanou presnosti 0.250000. Pro vypocet se použije Simpsonovo pravidlo I_S.

Presna hodnota integralu 69.800931
Vypočtena hodnota integralu 69.849993
Skutečná chyba -0.049061
Odhadnutá chyba -0.073144
Počet podintervalů 4
Celkový počet delení intervalu pro dodržení odhadu chyby 11

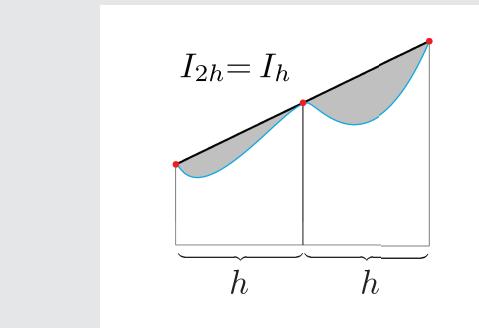
Poznámka:

Odhadujeme-li chybu pomocí metody polovičního kroku, nemusí být skutečná chyba menší než zadaná tolerance.

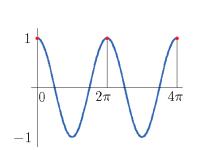
Příklady v nichž je splněno TEST CHYBY, ale chyba je ve skutečnosti větší než zadaná tolerance.
• Obdélníkové pravidlo:



- Lichoběžníkové pravidlo:


Například:

$$\int_0^{4\pi} \cos x \, dx, \quad \text{tolerance } \varepsilon = 10^{-5}$$



$$I_{4\pi} = 1 \cdot 4\pi \quad I_{2\pi} = 1 \cdot 2\pi + 1 \cdot 2\pi = 4\pi$$

Odhad chyby je

$$(I_{2\pi} - I_{4\pi}) \cdot \frac{1}{3} = 0$$

Přesná hodnota je

$$\int_0^{4\pi} \cos x \, dx = 0$$

Chyba skutečná je

$$4\pi$$

Poznámka:

Newton-Cotesovy vzorce používají $(m+1)$ ekvidistantních uzlů a integrují přesně polynomy až do m -tého, případně $(m+1)$ -ního stupně (máme na mysli základní vzorec na intervalu (x_k, x_{k+m})).

Pro zvýšení presnosti se mohlo zdát výhodné použít více uzlů a funkci f approximovat polynomem vyššího řádu. Ze zkušeností z approximace funkce polynomem ovšem víme, že limitní případ polynomu stupně $m \rightarrow \infty$ nemusí odpovídat původní funkci (říkáme, že Newton-Cotesovy vzorce nejsou konvergentní).

Vzorec musí přesně integrovat:

1) konstantu

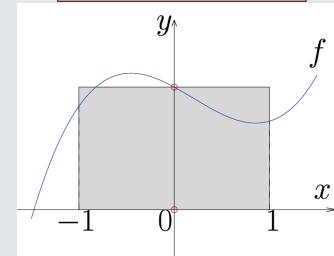
$$\int_{-1}^1 b \, dx = 2b \stackrel{\text{poz}}{=} w_0 \cdot \overbrace{f(x_0)}^b \Rightarrow w_0 = 2.$$

2) lineární funkci

$$\int_{-1}^1 (ax + b) \, dx = \left[a \frac{x^2}{2} + bx \right]_{-1}^1 = \underbrace{\frac{a}{2} - \frac{a}{2}}_0 + 2b \stackrel{\text{poz}}{=} w_0 \cdot \overbrace{f(x_0)}^{\frac{ax_0 + b}{2}} \Rightarrow 2b = 2(ax_0 + b) \Rightarrow x_0 = 0.$$

Jednobodový základní Gaussův kvadraturní vzorec je

$$K(f) = \int_{-1}^1 f(x) \, dx = 2f(0) + \underbrace{\frac{1}{3} f''(\xi)}_{\text{chyba}}$$


Gaussový kvadraturní vzorec

Princip: Snažíme se, aby kvadraturní vzorec integroval přesně polynomy co možná nejvyššího řádu.

Obecně kvadraturní vzorec (základní) uvažujeme v tvaru

$$K(f) = \sum_{i=0}^m w_i f(x_i),$$

kde w_i jsou tzv. **váhy** a x_i jsou **uzly**.

Máme-li na základním intervalu $m+1$ bodů, potom nejvyšší možný stupeň polynomu, který ještě kvadraturní vzorec integruje přesně, je $2m+1$ (mluvíme o tzv. **algebraickém řádu přesnosti**).

Počet parametrů kvadraturního vzorce je $2m+2$

- polovina pro váhy w_i
- polovina pro uzly x_i

(Newton-Cotesovy vzorce integrovaly přesně polynomy do stupně $\sim m$.)

Cenu za vyšší presnost budou ovšem neekvidistantní uzly.

Příklad: Odvoďte pro interval $(-1, 1)$ základní Gaussův kvadraturní vzorec pro $m = 0$ (tj. v intervalu uvažujeme pouze jeden uzel).

Řešení:

Kvadraturní vzorec pro $m = 0$ má tvar

$$K(f) = w_0 f(x_0),$$

kde vystupují 2 neznámé w_0 a x_0 .

Příklad: Odvoďte pro interval $(-1, 1)$ základní Gaussův kvadraturní vzorec pro $m = 1$ (tj. v intervalu uvažujeme 2 uzly).

Řešení:

Kvadraturní vzorec pro $m = 1$ má tvar

$$K(f) = w_0 f(x_0) + w_1 f(x_1),$$

kde vystupují 4 neznámé w_0, w_1, x_0 a x_1 .

Vzorec musí přesně integrovat polynom až 3 stupně:

$$\int_{-1}^1 (ax^3 + bx^2 + cx + d) dx = \left[a\frac{x^4}{4} + b\frac{x^3}{3} + c\frac{x^2}{2} + dx \right]_{-1}^1 = 0 \cdot a + \frac{2}{3} \cdot b + 0 \cdot c + 2 \cdot d \stackrel{\text{pož.}}{=} \\ \stackrel{\text{pož.}}{=} w_0 \underbrace{(ax_0^3 + bx_0^2 + cx_0 + d)}_{f(x_0)} + w_1 \underbrace{(ax_1^3 + bx_1^2 + cx_1 + d)}_{f(x_1)} = K(f).$$

Soustava nelineárních rovnic pro 4 neznámé:

$$a: \quad w_0x_0^3 + w_1x_1^3 = 0 \quad (1)$$

$$b: \quad w_0x_0^2 + w_1x_1^2 = \frac{2}{3} \quad (2)$$

$$c: \quad w_0x_0 + w_1x_1 = 0 \quad (3)$$

$$d: \quad w_0 + w_1 = 2 \quad (4)$$

$$(1) - (3): \quad w_0x_0(x_0^2 - 1) + w_1x_1(x_1^2 - 1) = 0.$$

$$(2) - (4): \quad w_0(x_0^2 - 1) + w_1(x_1^2 - 1) = -\frac{4}{3} \quad / \cdot (-x_1)^t \quad / \cdot (-x_0)^t$$

$$\begin{aligned} \stackrel{t}{:} & \quad \underbrace{w_0(x_0 - x_1)(x_0^2 - 1)}_{w_1(x_1 - x_0)(x_1^2 - 1)} = \frac{4}{3}x_1 \\ \stackrel{t}{:} & \quad \underbrace{w_1(x_1 - x_0)(x_1^2 - 1)}_{w_0(x_0 - x_1)} = \frac{4}{3}x_0 \\ (3) \text{ a } (4) \Rightarrow & \quad \begin{cases} w_1 &= 2 - w_0 \\ w_0x_0 + (2 - w_0)x_1 &= 0 \\ w_0(x_0 - x_1) &= -2x_1 \end{cases} \Rightarrow \end{aligned}$$

$$-2x_1(x_0^2 - 1) = \frac{4}{3}x_1 \Rightarrow -2(x_0^2 - 1) = \frac{4}{3} \Rightarrow x_0^2 - 1 = -\frac{2}{3} \Rightarrow x_0^2 = \frac{1}{3} \\ \Rightarrow x_0 = \pm \sqrt{\frac{1}{3}}$$

analogicky:

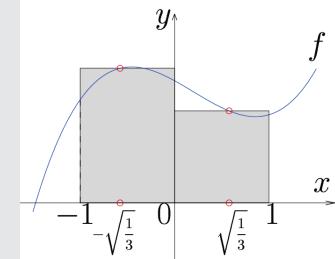
$$(3) \text{ a } (4) \Rightarrow \begin{cases} w_0 &= 2 - w_1 \\ (2 - w_1)x_0 + w_1x_1 &= 0 \\ w_1(x_1 - x_0) &= -2x_0 \end{cases} \Rightarrow$$

$$-2x_0(x_1^2 - 1) = \frac{4}{3}x_0 \Rightarrow -2(x_1^2 - 1) = \frac{4}{3} \Rightarrow x_1^2 - 1 = -\frac{2}{3} \Rightarrow x_1^2 = \frac{1}{3} \\ \Rightarrow x_1 = \pm \sqrt{\frac{1}{3}}$$

$$(3) \text{ a } (4): \quad \begin{matrix} w_0 + w_1 &= 2 \\ \sqrt{\frac{1}{3}}w_0 - \sqrt{\frac{1}{3}}w_1 &= 0 \end{matrix} \Rightarrow w_0 = w_1 \Rightarrow w_0 = w_1 = 1$$

Dvoubodový základní Gaussův kvadraturní vzorec je

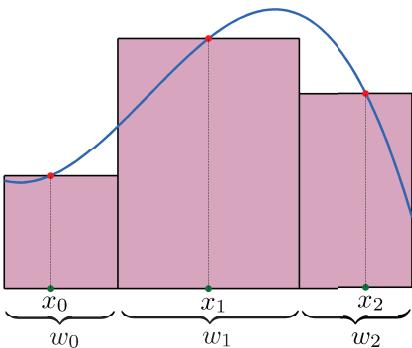
$$K(f) = \int_{-1}^1 f(x) dx = f\left(-\frac{\sqrt{3}}{3}\right) + f\left(\frac{\sqrt{3}}{3}\right) + \frac{1}{135} f^{(4)}(\xi) \quad \text{chyba}$$



Poznámka:

Další základní Gaussův kvadraturní vzorec (tříbodový, tj. pro $m = 2$) vypadá na intervalu $(-1, 1)$ takto:

$$K(f) = \int_{-1}^1 f(x) dx = \frac{5}{9}f\left(-\sqrt{\frac{3}{5}}\right) + \frac{8}{9}f(0) + \frac{5}{9}f\left(\sqrt{\frac{3}{5}}\right) + \frac{1}{1575}f^{(6)}(\xi) \quad \text{chyba}$$



Poznámka: Koeficienty a uzly vzorců vyšších řádů jsou uvedeny v tabulkách.

Poznámka: To, že jsme vyjádřili $\int_{-1}^1 f(x) dx$ neubírá nic na obecnosti, můžeme totiž libovolný interval (a, b) transformovat na $(-1, 1)$ a použít odvozené vztahy.

Poznámka: Gaussovy kvadraturní vzorce jsou konvergentní.

$n = 1$

$$\begin{aligned} \int_1^{1.2} f(x) dx &\approx & x_0 &= 1,1 + 0,1 \cdot \left(-\sqrt{\frac{1}{3}}\right) = \\ &\approx 0,1 \left[f(1,1 - 0,1 \cdot \frac{1}{\sqrt{3}}) + f(1,1 + 0,1 \cdot \frac{1}{\sqrt{3}}) \right] & &= 1,1 - 0,1 \sqrt{\frac{1}{3}}, \\ &\triangleq 0,1 [2,835632 + 3,182716] = & x_1 &= 1,1 + 0,1 \cdot \sqrt{\frac{1}{3}}, \\ &\triangleq 0,601834. & w_0 &= 0,1 \cdot 1 = 0,1, \\ & & w_1 &= 0,1. \end{aligned}$$

$$\text{Přesný výsledek: } e^{1.2} - e \triangleq 0,601835.$$

Poznámka:

Podobně jako u Newton-Cotesových vzorců můžeme definovat složené Gaussovy kvadraturní vzorce

Příklad

Vypočte $\int_0^\pi x^2 \sin 3x dx$ použitím jedno-, dvou- a tříbodového složeného Gaussova kvadraturního vzorce. Počet dílení intervalu $(0, \pi)$ volte $N = 10$, resp. $N = 20$.

Řešení:

výsledky v MATLABu

Numericky vypočet určitého integrálu funkce $f(x) = x^2 \sin(3x)$ na intervalu $[0, \pi]$ s počtem dělení $N=10$

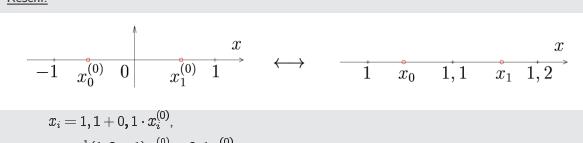
Přesná hodnota integrálu je 3.141720

Priblizná hodnota integrálu	chyba
- pomocí Gaussova vzorce s 1 uzlem	3.266250 0.124530
- pomocí Gaussova vzorce s 2 uzly	3.141191 -0.000529
- pomocí Gaussova vzorce s 3 uzly	3.141721 0.000001

Příklad

Vypočte $\int_1^{1.2} f(x) dx$ použitím jedno- a dvoubodového základního Gaussova kvadraturního vzorce.

Řešení:

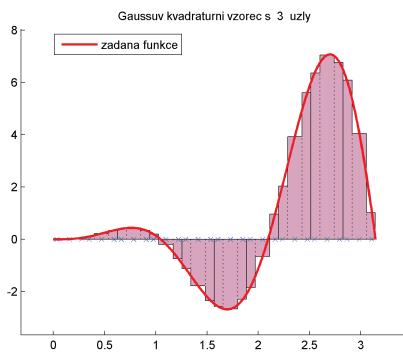
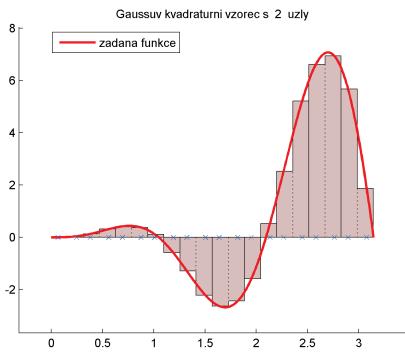
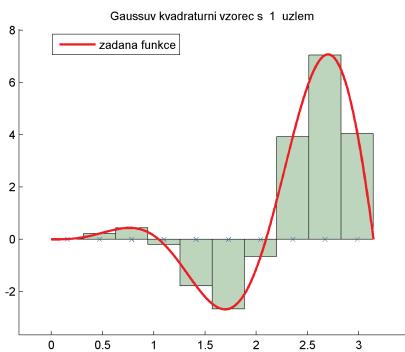


$$x_i = 1,1 + 0,1 \cdot x_i^{(0)}, \\ w_i = \frac{1}{2}(1,2 - 1)w_i^{(0)} = 0,1w_i^{(0)}.$$

$n = 0$

$$\begin{aligned} \int_1^{1.2} f(x) dx &\approx 0,2 \cdot f(1,1) = \\ &= 0,2 \cdot e^{1.1} = \\ &= 0,600833 \end{aligned}$$

$$x_0 = 1,1 + 0,1 \cdot 0 = 1,1 \\ w_0 = 0,1 \cdot 2 = 0,2$$



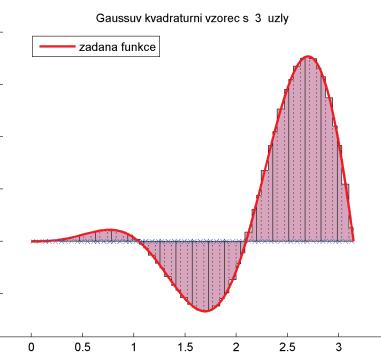
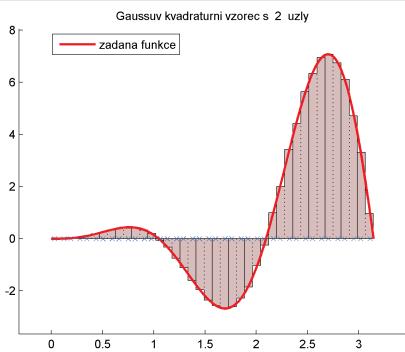
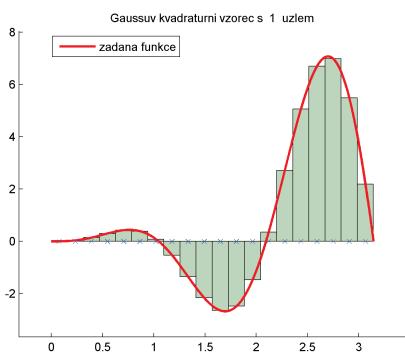
výsledky v MATLABu

Numericky vypocet urcитеho integralu funkce $f(x)=x^2\sin(3x)$ na intervalu $[0, 3]$ s pocitem delení $N=20$

Presna hodnota integralu je 3.141720

Priblizna hodnota integralu

- pomocí Gaussova vzorce s 1 uzlem	3.172331	chyba 0.030612
- pomocí Gaussova vzorce s 2 uzly	3.141687	-0.000033
- pomocí Gaussova vzorce s 3 uzly	3.141720	0.000000



Integrování periodické funkce přes periodu

Pro lichoběžníkové pravidlo platí:

$$T(f, h) = \int_a^b f(x) dx + \frac{h^2}{12} [f'(b) - f'(a)] - \frac{h^4}{720} [f^{(3)}(b) - f^{(3)}(a)] + \dots$$

(tzv. Eulerův - Maclaurinův vzorec)

Souvislost s rozvojem chyby:

$$T(f, h) = \int_a^b f(x) dx + \frac{h^2}{12} \frac{f''(\xi)}{f(b)-f(a)} (b-a) - \frac{h^4}{720} \frac{f^{(4)}(\xi)}{f'''(b)-f'''(a)} (b-a) + \dots$$

Pro kladnou periodickou funkci s periodou na intervalu (a, b) platí:

$$f'(a) = f'(b)$$

$$f^{(3)}(a) = f^{(3)}(b)$$

⋮

Pozor: Obecně nemusí platit, že $T(f, h)$ je přesná hodnota integrálu $\int_a^b f(x) dx$, protože zbytek má tvar

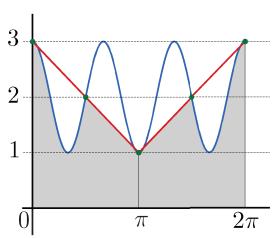
$$(b-a) c_{2m} h^{2m} f^{(2m)}(\xi) \quad \text{a } \xi \text{ neznáme.}$$

Plati však, že chyba je velikosti $O(h^{2m})$ pro libovolné m takové, že f má spojitu $2m$ -tou derivaci. Proto není nutné používat Rombergovu metodu.

Příklad: Vypočte složený lichoběžníkový pravidlo

$$\int_0^{2\pi} (2 + \cos 3x) dx.$$

(Přesná hodnota je 4π .)



Zvolíme krok $h = \pi$, tj. $N = 2$:

$$T(f, \pi) = \frac{\pi}{2} [f(0) + 2f(\pi) + f(2\pi)] = \frac{\pi}{2}(3 + 2 \cdot 1 + 3) = 4\pi.$$

Platí: Složené lichoběžníkové pravidlo s $(k+2)$ uzly integruje přesně trigonometrické polynomy k -tého stupně a stupňů menších (tj. obsahující členy $\cos kz, \sin kz$) přes periodu 2π .

Nevlastní integrály

Při výpočtu integrálu

$$\int_{-\infty}^{\infty} f(x) dx$$

Ize většinou předpokládat, že hodnoty funkce f a nížší derivace f jsou vně nějakého intervalu $(-R, R)$ dostatečně malé. Proto je vhodné použít lichoběžníkové pravidlo pro integrál

$$\int_{-R}^R f(x) dx.$$

Příklad

Vypočte integrál $I = \int_{-\infty}^{\infty} e^{-x^2} dx$.

Pro $|x| \geq 4$ je integrand menší než $0,5 \cdot 10^{-6}$ a jeho první derivace menší než 10^{-6} . Použijeme-li lichoběžníkové pravidlo pro $(-4, 4)$, dostaneme:

$$T(f, 1) = 1,772636$$

$$T(f; 0,5) = 1,772453$$

Přesná hodnota

$$I = \sqrt{\pi} \doteq 1,7724538$$

Poznamenejme, že

$$\left| \int_{-\infty}^{\infty} e^{-x^2} dx - \int_{-4}^4 e^{-x^2} dx \right| < 10^{-7}.$$

Při výpočtu integrálu $\int_0^{\infty} f(x) dx$ můžeme použít transformaci $x = p(t)$.

$$\begin{aligned} \text{a)} \quad & x = -\ln t, \quad dx = -\frac{dt}{t}, \quad \frac{x|0|\infty}{t|1|0} \\ & \int_0^{\infty} f(x) dx = -\int_0^0 f(-\ln t) \frac{dt}{t} = \int_0^1 \frac{f(-\ln t)}{t} dt \\ \text{b)} \quad & x = \frac{t}{1-t}, \quad dx = (1-t)^{-2} dt, \quad \frac{x|0|\infty}{t|0|1} \\ & \int_0^{\infty} f(x) dx = \int_0^1 f\left(\frac{t}{1-t}\right) \frac{dt}{(1-t)^2} \end{aligned}$$

Integrování funkce 2 proměnných

Ovďovte obdélníkové a lichoběžníkové pravidlo pro integrování funkce 2 proměnných na obdélníku $(a, b) \times (c, d)$, tj.

$$\int_a^b \left(\int_c^d f(x, y) dy \right) dx$$

Řešení:

Nevlastní integrály

Při výpočtu integrálu

$$\int_{-\infty}^{\infty} f(x) dx$$

Ize většinou předpokládat, že hodnoty funkce f a nížší derivace f jsou vně nějakého intervalu $(-R, R)$ dostatečně malé. Proto je vhodné použít lichoběžníkové pravidlo pro integrál

$$\int_{-R}^R f(x) dx.$$

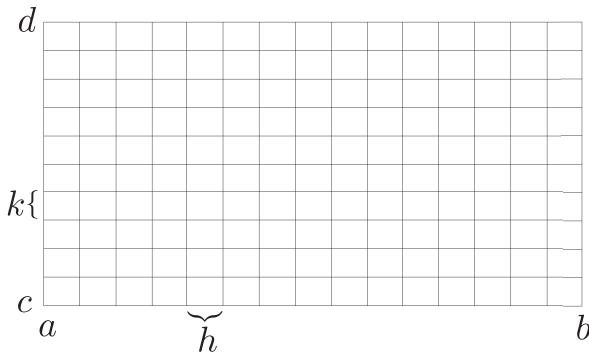
Příklad

Vypočte integrál $I = \int_{-\infty}^{\infty} e^{-x^2} dx$.

Pro $|x| \geq 4$ je integrand menší než $0,5 \cdot 10^{-6}$ a jeho první derivace menší než 10^{-6} . Použijeme-li lichoběžníkové pravidlo pro $(-4, 4)$, dostaneme:

$T(f, 1) = 1,772636$

$T(f; 0,5) = 1,772453$

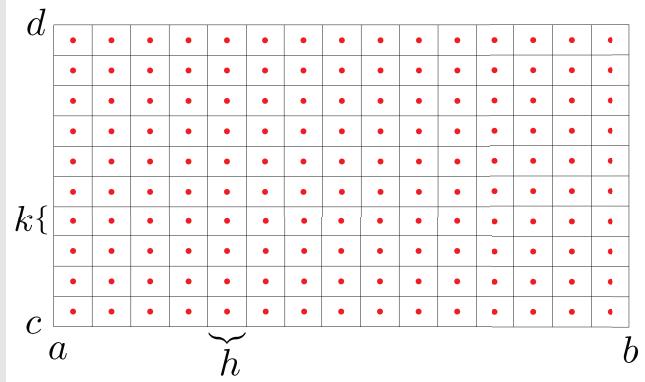


$$h = \frac{b-a}{N}, \quad k = \frac{d-c}{M}, \quad x_i = a + i \cdot h, \quad y_j = c + j \cdot k$$

$$\int_a^b \left(\int_c^d f(x, y) dy \right) dx = \dots$$

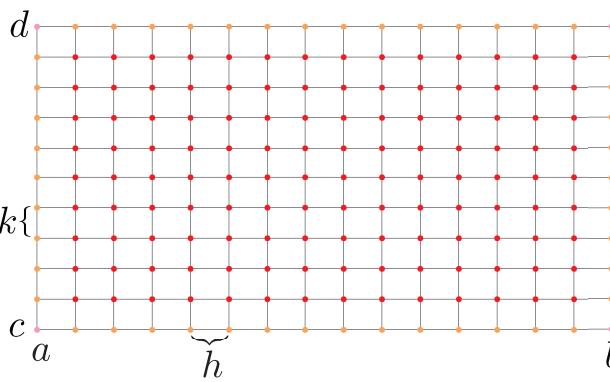
• obdélníkové pravidlo:

$$\dots = h \sum_{i=0}^{N-1} \left(\int_c^d f\left(x_i + \frac{h}{2}, y\right) dy \right) = h \sum_{i=0}^{N-1} \left(k \sum_{j=0}^{M-1} f\left(x_i + \frac{h}{2}, y_j + \frac{k}{2}\right) \right) = hk \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} f\left(x_i + \frac{h}{2}, y_j + \frac{k}{2}\right)$$



• lichoběžníkové pravidlo:

$$\begin{aligned} \dots &= \frac{h}{2} \sum_{i=0}^{N-1} \left(\int_c^d [f(x_i, y) + f(x_{i+1}, y)] dy \right) = \\ &= \frac{h}{2} \sum_{i=0}^{N-1} \left(\frac{k}{2} \sum_{j=0}^{M-1} [f(x_i, y_j) + f(x_{i+1}, y_j)] + \frac{k}{2} \sum_{j=0}^{M-1} [f(x_i, y_{j+1}) + f(x_{i+1}, y_{j+1})] \right) = \\ &= \frac{hk}{2} \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} [f(x_i, y_j) + f(x_i, y_{j+1}) + f(x_{i+1}, y_j) + f(x_{i+1}, y_{j+1})] \end{aligned}$$



Kapitola 11. Počáteční úlohy pro ODR - I

Počáteční úlohy pro obyčejné diferenciální rovnice 1. řádu

Formule:

Je dána funkce dvou proměnných $f = f(x, y)$, $y \in \mathbb{R}$, $x \in \langle a, b \rangle$ a čísla $x_0 \in \langle a, b \rangle$ a $y_0 \in \mathbb{R}$. Chceme najít takovou funkci $y = y(x)$, která na intervalu (x_0, b) vyhovuje rovnici

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

a splňuje počáteční podmíinku

$$y(x_0) = y_0$$

Funkci $y = y(x)$, která splňuje počáteční podmíinku a rovnost $y' = f(x, y(x))$ na příslušném intervalu, nazýváme řešením úlohy.

V některých případech budeme uvažovat speciální úlohu s rovnicí

$$y' = a(x)y + b(x)$$

nebo s rovnicí

$$y' = \lambda y$$

Velmi podstatnou úlohou v našich dalších úvahách bude hrát předpoklad, že funkce f je na nějakém intervalu **lipschitzovsky spojité** (v druhé proměnné), tj. platí:

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

Příklad 1

Uvažujme úlohu

$$y' = y^2$$

$$y(0) = \eta > 0$$

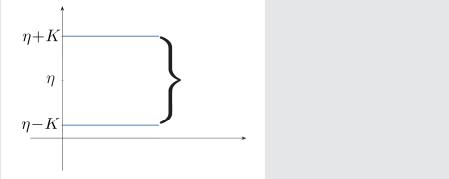
Funkce $f(x, y) = y^2$ je lipschitzovsky spojité na libovolném konečném intervalu $\langle \eta - K, \eta + K \rangle$.

Konstanta $L = 2(\eta + K)$

$$|y_1^2 - y_2^2| \leq 2(\eta + K) |y_1 - y_2|$$

$$|y_1 + y_2| \leq 2(\eta + K) \quad \forall x \in \langle a, b \rangle, \quad \forall y_1, y_2 \in \langle \eta - K, \eta + K \rangle$$

$$|y_1 + y_2| \leq |y_1| + |y_2| \leq \eta + K + \eta + K = 2(\eta + K) \quad \forall x \in \langle a, b \rangle, \quad \forall y_1, y_2 \in \langle \eta - K, \eta + K \rangle$$



Řešíme pomocí separace proměnných

$$\frac{dy}{dx} = y^2$$

$$\frac{dy}{y^2} = dx$$

$$-\frac{1}{y} = x + c$$

$$y = -\frac{1}{x+c}$$

$$y(0) = \eta$$

$$-\frac{1}{c} = \eta$$

$$c = -\frac{1}{\eta}$$

Řešení této úlohy má tvar

$$y(x) = \frac{1}{\frac{1}{\eta} - x}$$

Když $x \rightarrow \left(\frac{1}{\eta}\right)_-$, pak $y \rightarrow \infty$.

⇒ Pro všechna $y_1, y_2 \in \mathbb{R}$ nelze najít jednu konstantu L a

řešení neexistuje pro libovolné x (řešení existuje pouze do určitého času).

Příklad 2

Uvažujme úlohu

$$y' = \sqrt{y}$$

$$y(0) = 0$$

Funkce $f(x, y) = \sqrt{y}$ není lipschitzovsky spojité v okolí 0, protože $\frac{\partial f(x, y)}{\partial y} = \frac{1}{2\sqrt{y}} \rightarrow \infty$ pro $y \rightarrow 0_+$.

Z věty o střední hodnotě plyne:

$$f(x, y_1) - f(x, y_2) = \frac{\partial f(x, \xi)}{\partial y} (y_1 - y_2)$$

Řešení této úlohy není jednoznačné:

$$\begin{aligned} y_1(x) &= 0 \\ y_2(x) &= \frac{1}{4}x^2 \\ \frac{dy}{dx} &= \sqrt{y} \end{aligned}$$

$$1) y \equiv 0 \quad \text{OK}$$

$$2) y \neq 0$$

$$\frac{dy}{\sqrt{y}} = dx$$

$$2\sqrt{y} = x + c$$

$$\sqrt{y} = \frac{x}{2} + c$$

$$y = \left(\frac{x}{2} + c\right)^2$$

$$y(0) = 0$$

$$c^2 = 0$$

$$c = 0$$

$$y = \frac{x^2}{4}$$

Příklad 3

Uvažujme úlohu

$$\begin{aligned} y' &= \lambda y \\ y(0) &= 1 \end{aligned}$$

Funkce $f(x, y) = \lambda y$ je lipschitzovsky spojité pro všechna $y \in \mathbb{R}$ s konstantou $L = \lambda$.

$$|\lambda y_1 - \lambda y_2| = |\lambda| |y_1 - y_2| \leq |\lambda| |y_1 - y_2|$$

Tato úloha má právě jedno řešení pro všechna $x \in (0, \infty)$ ve tvaru

$$y(x) = e^{\lambda x}$$

$$\frac{dy}{dx} = \lambda y$$

$$\frac{dy}{y} = \lambda dx$$

$$\ln|y| = \lambda x + c$$

$$\ln|y| = \ln e^{\lambda x} + \ln c$$

$$y = ce^{\lambda x}$$

$$y(0) = 1$$

$$c = 1$$

$$y = e^{\lambda x}$$

Následující příklady ukazují význam Lipschitzovy konstanty.

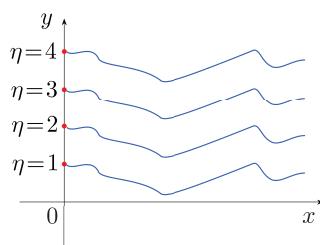
Příklad 4

Uvažujme úlohu ve tvaru

$$\begin{cases} y' = g(x) \\ y(0) = \eta \end{cases}$$

Řešení má tvar $y(x) = \eta + \int_0^x g(\xi) d\xi$ a Lipschitzova konstanta $L = 0$.

Křivky řešení mohou vypadat třeba takto:



Změníme-li počáteční podmítku η , potom nové řešení je pouhě posunutí původního do hodnoty η .

Příklad 5

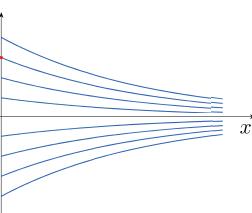
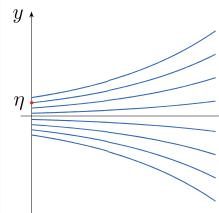
Uvažujme úlohy

$$\begin{cases} y' = 3y \\ y(0) = \eta \end{cases}$$

$$\begin{cases} y' = -3y \\ y(0) = \eta \end{cases}$$

$$\begin{cases} \bar{y}(x) = \eta e^{3x} \\ \bar{y}(x) = \eta e^{-3x} \end{cases}$$

Dostaneme řešení



V obou případech je Lipschitzova konstanta $L = 3$. Její velikost však může ovlivňovat chování konkrétní numerické metody pro konkrétní úlohu.

Věta Nechť funkce $f(x, y)$ má následující vlastnosti:
 (i) je definována v pásu $S = \langle a, b \rangle \times \mathbb{R}$ ($a, b \dots$ konečné),
 (ii) je spojitá v proměnné $x \in \langle a, b \rangle$ pro každé $y \in \mathbb{R}$,

(iii) splňuje Lipschitzovu podmítku v proměnné y , tj. existuje číslo L takové, že platí nerovnost:

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

Potom pro každé $x_0 \in \langle a, b \rangle$ a libovolné $y_0 \in \mathbb{R}$ existuje právě jedna funkce $y = y(x)$ s vlastnostmi:

- a) $y(x)$ je spojitá a spojitě diferencovatelná pro $x \in \langle a, b \rangle$,
- b) platí rovnost $y'(x) = f(x, y(x))$ pro $\forall x \in \langle a, b \rangle$,
- c) $y(x_0) = y_0$.

Numerické metody lze dělit podle různých kritérií:

- A) metody založené na numerické derivaci X na numerické integraci
- B) jednodukové metody X víceukové metody
- C) explicitní metody X implicitní metody
- D) metody s konstantním krokem X metody s proměnným krokem

Princip:

Základem metod je diskretizace proměnných.

Přibližné řešení nehledáme jako spojité funkci, ale generujeme body x_0, x_1, x_2, \dots a určujeme čísla y_0, y_1, y_2, \dots , která approximují $y(x_0), y(x_1), y(x_2), \dots$.
 Pro jednoduchost můžeme uvažovat ekvidistantní dělení, tj. $h = x_{k+1} - x_k, \forall k$.

Eulerova metoda

- nejjednodušší jednoduková explicitní metoda; lze odvodit řadou postupů

- 1. odvození

$y_0 \dots$ dánou

$y_1 \dots$ počítáme extrapolací z hodnoty y_0 , přičemž se na intervalu $\langle x_0, x_1 \rangle$ řešení approximuje přímkou,

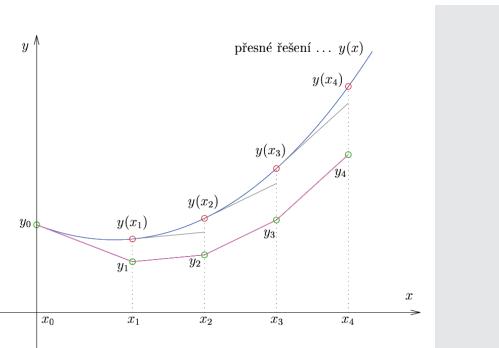
která prochází bodem $[x_0, y_0]$ a má směrnicu $y' = f(x_0, y_0)$.

Ta má rovnici $y - y_0 = (x - x_0)f(x_0, y_0)$. Tj. pro x_1 dostaváme:

$$y_1 = y_0 + \frac{(x_1 - x_0)}{h} f(x_0, y_0)$$

Obecně dostaneme rekurentní vztah

$$y_{k+1} = y_k + h_k f(x_k, y_k), \quad k = 0, 1, 2, \dots$$



- 2. odvození Pomocí Taylorova rozvoje.

$$y(x_{k+1}) = y(x_k) + h_k \underbrace{\frac{y'(x_k)}{1!}}_{=f(x_k, y(x_k))} + \frac{1}{2} h_k^2 \underbrace{\frac{y''(\xi_k)}{2!}}_{(*)}$$

(*) zanedbáme a dostaneme vztah pro přibližné řešení

$$y_{k+1} = y_k + h_k f(x_k, y_k), \quad k = 0, 1, 2, \dots$$

$y_0 \dots$ počáteční podmínka

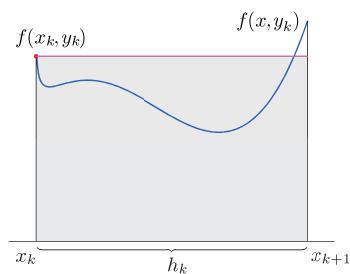
- 3. odvození Původní diferenciální rovnici nahradíme diferenciální rovnici (approximujeme derivaci).

$$y' = f(x, y) \rightarrow \frac{y_{k+1} - y_k}{h_k} = f(x_k, y_k), \quad k = 0, 1, 2, \dots$$

- 4. odvození Původní diferenciální rovnici zintegrujeme a approximujeme určitý integrál.

$$y' = f(x, y) \rightarrow y(x_{k+1}) - y(x_k) = \int_{x_k}^{x_{k+1}} f(x, y(x)) dx$$

(*) $y(x)$ na $\langle x_k, x_{k+1} \rangle$ approximujeme konstantou y .



$$y_{k+1} - y_k = h_k f(x_k, y_k), \quad k = 0, 1, 2, \dots$$

Poznámka:

Eulerova metoda je

- jednoduková metoda ($y_k \rightarrow y_{k+1}$)
 K výpočtu y_{k+1} použijeme pouze předešlou hodnotu y_k .
- explicitní metoda (na pravé straně není y_{k+1})
 V získané formuli je explicitně vyjádřena hodnota y_{k+1} .

Příklad

Pomocí Eulerovy metody řešte následující úlohu na intervalu $\langle 0; 0,6 \rangle$ s konstantními kroky $h = 0,2$ a $h = 0,1$.

$$\begin{cases} y' = x - y \\ y(0) = 1 \end{cases}$$

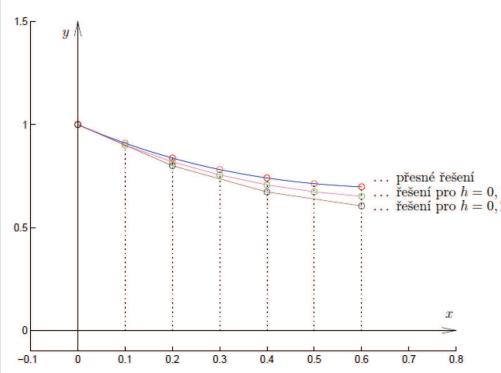
Rешení:

(Přesné řešení: $y(x) = 2e^{-x} + x - 1$.)

Eulerova metoda je dána rekurentním vztahem:

$$y_{k+1} = y_k + h \cdot f(x_k, y_k).$$

		$h = 0,2$		$h = 0,1$	
x_k	$y(x_k)$	\hat{y}_k	e_k	\hat{y}_k	e_k
0	1,000	1,000	0,000	1,000	0,000
0,1	0,910			0,900	0,010
0,2	0,837	0,800	0,037	0,820	0,017
0,3	0,762			0,758	0,024
0,4	0,741	0,680	0,061	0,712	0,029
0,5	0,713			0,681	0,032
0,6	0,698	0,624	0,074	0,663	0,035



Poznámky:

- 1) Vidíme, že je chyba úměrná h .
- 2) Chyba s rostoucím x vzrůstá.

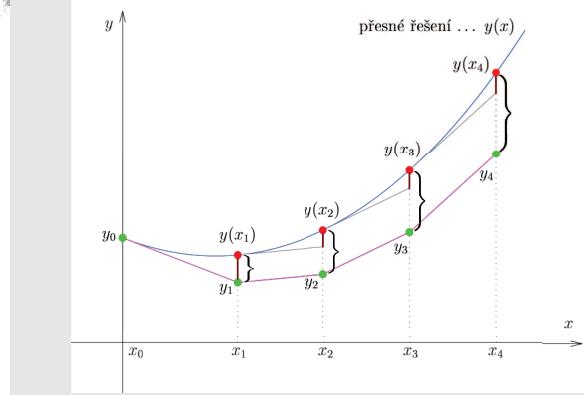
Definice: Lokální diskretizační chyba d_k na intervalu (x_k, x_{k+1}) je nepřesnost, s níž hodnoty teoretického řešení dané úlohy splňují rekurentní vztah, ze kterého se počítá hodnota y_{k+1} .

Pro Eulerovu metodu je lokální diskretizační chyba d_k :

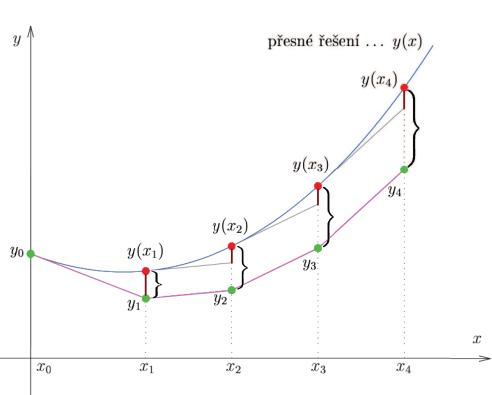
$$y(x_{k+1}) = y(x_k) + h_k f(x_k, y(x_k)) + d_k$$

Poznámka:

Lokální diskretizační chyba se nazývá lokální proto, že d_k lze interpretovat také jako chybu jednoho kroku metody (při výpočtu y_{k+1}) za předpokladu, že všechny hodnoty y_0, y_1, \dots potřebné k výpočtu y_{k+1} jsou přesné.



Definice: Globální diskretizační chyba je $e_k = y(x_k) - \hat{y}_k$, tj. rozdíl teoretické hodnoty řešení a vypočtené hodnoty řešení v daném bodě x_k .



$$e_0 = 0$$

$$e_{k+1} = e_k + h \left(f(x_k, y(x_k)) - f(x_k, y_k) \right) + d_k$$

tj. v každém kroku se ke globální chybě e_k připočítá lokální chyba d_k a člen $h \cdot (\dots)$, který představuje nepřesnost z minulých kroků.

Příklad:

Speciální případ, kdy f nezávisí na y :

$$\begin{aligned} y' &= f(x) \\ y(x_0) &= y_0 \end{aligned} \Rightarrow e_{k+1} = \sum_{m=0}^k d_m \quad \textcircled{R}$$

tj. globální chyba je součtem lokálních chyb.

Poznámka:

Lokální chyba Eulerovy metody je $O(h^2)$ (viz další slide).

Protože \textcircled{R} má k sčítanců a protože pro pevné x je $k = \frac{x-a}{h}$, plyně z \textcircled{R}

$$e(x, h) = \frac{\text{const}}{h} \cdot O(h^2) = O(h)$$

... podobně jako u základních a složených kvadraturních vzorců.

Poznámka:

Lokální i globální diskretizační chyba jsou chyby aproximace, tj. neuvažovali jsme zaokrouhlovací chyby.

Definice: Řád diferenční metody je největší přirozené číslo p takové, že pro danou metodu aplikovanou na libovolou počáteční úlohu s dostatečně hladkým řešením platí při každém pevném k a $h_k \rightarrow 0$ odhad

$$d_k = O(h_k^{p+1}).$$

Globální diskretizační chyba Eulerovy metody (pro konstantní krok h)

Přibližné řešení:

$$y_0 = y(x_0)$$

$$y_{k+1} = y_k + h f(x_k, y_k) \quad k = 0, 1, \dots$$

Přesné řešení:

$$y(x_{k+1}) = y(x_k) + h f(x_k, y(x_k)) + d_k \quad k = 0, 1, \dots$$

Po odečtení:

Řád Eulerovy metody

Ze vztahu pro lokální diskretizační chybu d_k plyne:

$$d_k = y(x_{k+1}) - y(x_k) - h_k \cdot \frac{y'(x_k)}{f(x_k, y(x_k))}$$

$y(x_{k+1})$ vyjádříme pomocí Taylorova rozvoje (předpokládáme, že y má 2. derivaci)

$$y(x_{k+1}) = y(x_k) + h_k y'(x_k) + \frac{1}{2} h_k^2 y''(\xi) \quad \xi \in (x_k, x_{k+1})$$

Po dosazení:

$$d_k = \frac{1}{2} h_k^2 y''(\xi) = O(h_k^2)$$

$$2 = p+1 \Rightarrow \text{řád Eulerovy metody je } p=1.$$

Obecná jednodokrová metoda

Eulerova metoda je sice velmi jednoduchá (řád je 1), ale k dosažení určité přesnosti musíme používat velmi malé kroky h_k . Chceme-li jednodokrovou metodu vyššího řádu, musíme se zříci linearity.

$$y_{k+1} = y_k + h_k f(x_k, y_k) \quad k = 0, 1, 2, \dots$$

$$y_{k+1} = y_k + \Phi(x_k, y_k, h_k, f) \quad k = 0, 1, 2, \dots$$

Metody Taylorova typu

Hodnotu $y(x_{k+1})$ budeme approximovat pomocí Taylorova rozvoje vyššího řádu p (v Eulerově metodě byl použit řád 1), tj.

$$y(x_{k+1}) = y(x_k + h_k) = y(x_k) + h_k y'(x_k) + \frac{h_k^2}{2!} y''(x_k) + \cdots + \frac{h_k^p}{p!} y^{(p)}(x_k) + \frac{h_k^{p+1}}{(p+1)!} y^{(p+1)}(\xi_k) \quad \xi_k \in (x_k, x_{k+1})$$

Je třeba dosadit za derivace y v bodě x_k . Derivace určíme postupným derivováním funkce f .

$$\begin{aligned} y' &= f(x, y) \\ y'' &= \frac{\partial f}{\partial x} + \frac{\partial f}{\partial y} \cdot \frac{dy}{dx} = f_x + f_y \cdot \underbrace{f}_{=y'} \stackrel{\text{def.}}{=} f^{[1]}(x, y) \\ y''' &= \frac{\partial f^{[1]}}{\partial x} + \frac{\partial f^{[1]}}{\partial y} \cdot \frac{dy}{dx} = f_x^{[1]} + f_y^{[1]} \cdot \underbrace{f}_{=y'} \stackrel{\text{def.}}{=} f^{[2]}(x, y) \\ &\vdots \end{aligned}$$

Obecně lze odvodit rekurenci

$$y^{(r+1)} = f^{[r]}(x, y(x)) = f_x^{[r-1]}(x, y(x)) + f_y^{[r-1]}(x, y(x)) \cdot f(x, y(x)) \quad r = 1, 2, \dots$$

Po dosazení (uvažujme konstantní krok h) dostáváme

$$y_{k+1} = y_k + h f(x_k, y_k) + \frac{h^2}{2} f^{[1]}(x_k, y_k) + \cdots + \frac{h^p}{p!} f^{[p-1]}(x_k, y_k)$$

Poznámka:

Metody Taylorova typu se v praxi nepoužívají právě z důvodu nutnosti vyjádřovat derivace y' , y'' , ...

Příklad Odvoďte metodu Taylorova typu 2.řádu pro řešení následující úlohy na intervalu $(0; 0,6)$ s konstantním krokem $h = 0,2$

$$\begin{aligned} y' &= x - y, \\ y(0) &= 1 \end{aligned}$$

Řešení:

(Přesné řešení: $y(x) = 2e^{-x} + x - 1$).

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

$$f^{[1]}(x, y) = f_x + f_y \cdot f = 1 + (-1) \cdot f(x, y) = 1 - x + y.$$

Dostáváme rekurentní vztah:

$$y_{k+1} = y_k + h(x_k - y_k) + \frac{1}{2} h^2 (1 - x_k + y_k)$$

x_k	$y(x_k)$	y_k	$h(x_k - y_k)$	$\frac{h^2}{2} (1 - x_k + y_k)$	e_k
0	1,000	1,000	-0,200	0,040	0,000
0,2	0,837	0,840	-0,128	0,033	-0,003
0,4	0,741	0,745	-0,069	0,027	-0,004
0,6	0,698	0,703			-0,005

Poznámka:

Vidíme, že metoda Taylorova typu 2. řádu pro $h = 0,2$ dává přesnější výsledky než Eulerova metoda s $h = 0,1$.

Metody Runge-Kutta typu

- Univerzálnější metody než metody Taylorova typu.

- Vychází také z Taylorova polynomu, ale nepoužívá se ho přímo, aby nebylo nutné explicitně vyjadřovat derivace funkce $f = f(x, y(x))$ a počítat jejich hodnoty. Hledaná approximace je kombinací několika hodnot funkce f vypočítaných v několika strategicky volených bodech (x, y) na intervalu (x_k, x_{k+1}) .

Poznámka: Těchto metod je velké množství!

Heunova metoda (Runge-Kutta metoda 2. řádu)

- vztah $y' = f(x, y(x))$ zintegrujeme přes interval (x_k, x_{k+1})

$$\int_{x_k}^{x_{k+1}} y'(x) dx = \int_{x_k}^{x_{k+1}} f(x, y(x)) dx$$

$$y(x_{k+1}) - y(x_k) = \int_{x_k}^{x_{k+1}} f(x, y(x)) dx$$

- použijeme lichoběžníkové pravidlo

$$y(x_{k+1}) - y(x_k) = \frac{h}{2} [f(x_k, y(x_k)) + f(x_{k+1}, y(x_{k+1}))] + \underset{\text{viz chyba}}{\mathcal{O}(h^3)}$$

- na pravé straně vystupuje hodnota $y(x_{k+1})$, její approximaci určíme pomocí Eulerovy metody

$$\bar{y}(x_{k+1}) = y(x_k) + h f(x_k, y(x_k)) + O(h^2)$$

- dostáváme metodu ve tvaru

$$\begin{aligned} \bar{y}_{k+1} &= y_k + h f(x_k, y_k) \\ y_{k+1} &= y_k + \frac{h}{2} [f(x_k, y_k) + f(x_{k+1}, \bar{y}_{k+1})] \end{aligned}$$

Poznámka: Lokální diskretizační chyba, tj. chyba jednoho kroku metody, je $d_k = \mathcal{O}(h^3)$. Globální chyba je potom o řád nižší, tj. $e_k = \mathcal{O}(h^2)$, protože chyba metody se zvětšuje lineárně s počtem kroků $k \sim \frac{1}{h}$.

Modifikovaná Eulerova metoda (Runge-Kutta metoda 2. řádu)

- vztah $y' = f(x, y(x))$ opět zintegrujeme přes interval (x_k, x_{k+1})

$$\int_{x_k}^{x_{k+1}} y'(x) dx = \int_{x_k}^{x_{k+1}} f(x, y(x)) dx$$

$$y(x_{k+1}) - y(x_k) = \int_{x_k}^{x_{k+1}} f(x, y(x)) dx$$

- použijeme obdélníkové pravidlo

$$y(x_{k+1}) - y(x_k) = h \cdot f\left(x_k + \frac{h}{2}, y\left(x_k + \frac{h}{2}\right)\right) + \underset{\text{viz chyba}}{\mathcal{O}(h^3)}$$

obd. pr.

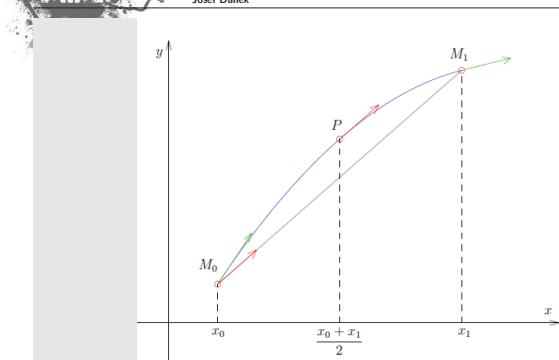
- hodnotu $y(x_k + \frac{h}{2})$ určíme pomocí Eulerovy metody

$$y(x_k + \frac{h}{2}) = y(x_k) + \frac{h}{2} f(x_k, y(x_k)) + O(h^2)$$

- dostáváme metodu ve tvaru

$$\begin{aligned} y_{k+\frac{1}{2}} &= y_k + \frac{h}{2} f(x_k, y_k) \\ y_{k+1} &= y_k + h f(x_k + \frac{h}{2}, y_{k+\frac{1}{2}}) \end{aligned}$$

Poznámka: Lokální diskretizační chyba je opět $d_k = \mathcal{O}(h^3)$. Globální chyba je potom o řád nižší, tj. $e_k = \mathcal{O}(h^2)$, protože chyba metody se zvětšuje lineárně s počtem kroků $k \sim \frac{1}{h}$.


Věta

Nechť oblouk $M_0 M_1$ je částí paraboly. Potom platí:

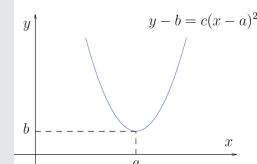
1. Tečna v bodě P je rovnoběžná s tětivou $M_0 M_1$.

2. Směrnice tětivy $M_0 M_1$ je aritmickým průměrem směrnic tečen v M_0 a M_1 .

Důkaz:

Rovnice paraboly (polynomu 2. stupně): $y - b = c(x - a)^2$

$$\begin{aligned} y &= c(x - a)^2 + b \\ &\Rightarrow \\ y' &= 2c(x - a) \end{aligned}$$



1. Směrnice tečny v bodě P :

$$y'\left(\frac{x_0 + x_1}{2}\right) = 2c\left(\frac{x_0 + x_1}{2} - a\right) = \underset{\text{c}}{\cancel{c}}\left(\frac{x_0 + x_1}{2} - a\right)$$

Směrnice tětivy $M_0 M_1$ je:

Ukažme si jiné odvození předchozích dvou Runge-Kuttových metod 2. řádu.

Odvození vychází z geometrické interpretace.

$$\begin{aligned} \frac{y(x_1) - y(x_0)}{x_1 - x_0} &= \frac{c(x_1 - a)^2 + b - c(x_0 - a)^2 - b}{x_1 - x_0} = \\ &= \frac{cx_1^2 - 2acx_1 + a^2c + b - cx_0^2 + 2acx_0 - a^2c - b}{x_1 - x_0} = \\ &= c \left(\frac{x_1^2 - x_0^2 - 2a(x_1 - x_0)}{x_1 - x_0} \right) = c(x_1 + x_0 - 2a). \end{aligned}$$

2. Směrnice tečny v bodě M_0 je:

$$y'(x_0) = 2c(x_0 - a)$$

Směrnice tečny v bodě M_1 je:

$$y'(x_1) = 2c(x_1 - a)$$

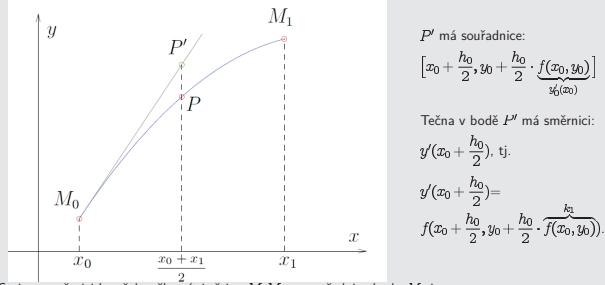
Jejich aritmetický průměr:

$$\begin{aligned} \frac{y'(x_0) + y'(x_1)}{2} &= \frac{2c(x_0 - a) + 2c(x_1 - a)}{2} = \\ &= c(x_0 - a + x_1 - a) = c(x_0 + x_1 - 2a). \end{aligned}$$

□

Nyní použijeme vlastnost 1.

Známe souřadnice bodu M_0 . Jestliže bychom znali y -souřadnici bodu P , pak stačí udělat tečnu a bodem M_0 vést rovnoběžku a dostaneme y -souřadnici bodu M_1 . My ale y -souřadnici bodu P neznáme, takže ji vyjádříme přibližně. Bod P nahradíme bodem P' , který má stejnou x -ovou souřadnici a leží na tečné k M_0 .



Stejnou směrnici by však měla mít i tětiva $M_0M_1 \Rightarrow$ souřadnice bodu M_1 jsou:

$$\begin{aligned} x_1 &= x_0 + h \\ y_1 &= y_0 + h \cdot \overbrace{y'(x_0 + \frac{h}{2})}^{k_2} \end{aligned}$$

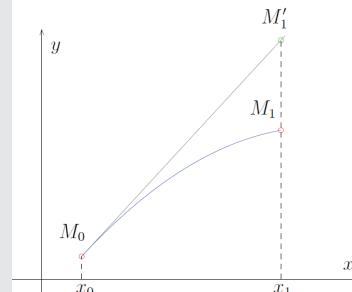
Tento vztah lze přepsat do tvaru (obecně)

$$\begin{aligned} k_1 &= f(x_k, y_k) \\ k_2 &= f(x_k + \frac{h}{2}, y_k + \frac{h}{2} \cdot k_1) \\ y_{k+1} &= y_k + h_k \cdot k_2 \end{aligned}$$

modifikovaná Eulerova metoda

Nyní použijeme vlastnost 2.

Známe souřadnice bodu M_0 . Protože neznáme y -souřadnici bodu M_1 , nahradíme ho bodem M'_1 , který má stejnou x -souřadnici a leží na tečné procházející bodem M_0 .



Bod M'_1 dostaneme z podmínky, že směrnice tětivy M_0M_1 je aritmetickým průměrem směrnic tečen v M_0 a M'_1 , tj.

M'_1 má souřadnice:

$$\begin{aligned} x_1 &= x_0 + h \\ y_1 &= y_0 + h \cdot \frac{1}{2}(k_1 + k_2) \end{aligned}$$

Obecně:

$$\begin{aligned} k_1 &= f(x_k, y_k) \\ k_2 &= f(x_k + h_k, y_k + h_k \cdot k_1) \\ y_{k+1} &= y_k + h_k \cdot \frac{(k_1 + k_2)}{2} \end{aligned}$$

Heunova metoda

Poznámka: Obě tyto metody jsou 2. řádu (aproximovaly jsme parabolou).

Klasická Runge-Kutta metoda 4. řádu

- jedna z nejvíce používaných metod tohoto typu
- předpis metody:

$$\begin{aligned} k_1 &= f(x_k, y_k) \\ k_2 &= f(x_k + \frac{h}{2}, y_k + \frac{h}{2} \cdot k_1) \\ k_3 &= f(x_k + \frac{h}{2}, y_k + \frac{h}{2} \cdot k_2) \\ k_4 &= f(x_k + h, y_k + h \cdot k_3) \\ y_{k+1} &= y_k + \frac{h}{6} \cdot (k_1 + 2k_2 + 2k_3 + k_4) \end{aligned}$$

Poznámka: Lokální diskretizační chyba, tj. chyba jednoho kroku metody, je $d_k = O(h^5)$. Globální chyba je potom o řád nižší, tj. $e_k = O(h^4)$, protože chyba metody se zvětšuje lineárně s počtem kroků $k \sim \frac{1}{h}$.

Příklad

Pomocí Heunovy metody, modifikované Eulerovy metody a klasické Runge-Kutta metody 4. řádu řešte následující úlohu na intervalu $\langle 0; 0,6 \rangle$ s konstantním krokem $h = 0,2$

$$\begin{aligned} y' &= x - y, \\ y(0) &= 1 \end{aligned}$$

Řešení:

(Přesné řešení: $y(x) = 2e^{-x} + x - 1$).

Předpis pro Heunovu metodu:

$$\begin{aligned} k_1 &= f(x_k, y_k) \\ k_2 &= f(x_k + h, y_k + h \cdot k_1) \\ y_{k+1} &= y_k + h \cdot \frac{k_1 + k_2}{2} \end{aligned}$$

x_k	$y(x_k)$	y_k	k_1	k_2	$h \cdot \frac{k_1 + k_2}{2}$	e_k
0	1,000	1,000	-1,000	-0,600	-0,160	0,000
0,2	0,837	0,840	-0,640	-0,312	-0,095	-0,003
0,4	0,741	0,745	-0,345	-0,076	-0,042	-0,004
0,6	0,698	0,703			-0,005	

Předpis pro modifikovanou Eulerovu metodu:

$$\begin{aligned} k_1 &= f(x_k, y_k) \\ k_2 &= f(x_k + \frac{h}{2}, y_k + \frac{h}{2} \cdot k_1) \\ y_{k+1} &= y_k + h \cdot k_2 \end{aligned}$$

x_k	$y(x_k)$	y_k	k_1	k_2	$h \cdot k_2$	e_k
0	1,000	1,000	-1,000	-0,800	-0,160	0,000
0,2	0,837	0,840	-0,640	-0,476	-0,095	-0,003
0,4	0,741	0,745	-0,345	-0,210	-0,042	-0,004
0,6	0,698	0,703			-0,005	

Poznámka:

Vidíme, že výsledky Heunovy i modifikované Eulerovy metody odpovídají výsledkům získaným metodou Taylorova typu 2. řádu (uvedené metody jsou 2. řádu).

Předpis pro klasickou Runge-Kutta metodu 4. řádu:

$$\begin{aligned} k_1 &= f(x_k, y_k) \\ k_2 &= f(x_k + \frac{h}{2}, y_k + \frac{h}{2} \cdot k_1) \\ k_3 &= f(x_k + \frac{h}{2}, y_k + \frac{h}{2} \cdot k_2) \\ k_4 &= f(x_k + h, y_k + h \cdot k_3) \\ y_{k+1} &= y_k + \frac{h}{6} \cdot (k_1 + 2k_2 + 2k_3 + k_4) \end{aligned}$$

x_k	$y(x_k)$	y_k	k_1	k_2	k_3	k_4	e_k
0	1,0000000	1,0000000	-1,0000000	-0,8000000	-0,8200000	-0,6360000	0,0000000
0,2	0,83746150	0,83746666	-0,6374666	-0,473720	-0,490094	-0,339447	0,00000516
0,4	0,74064009	0,74064854	-0,340648	-0,206583	-0,219990	-0,096650	0,00000845
0,6	0,69762327	0,69763364					0,00001037

Několik otázek k zamýšlení:

1. Uveďte příklad počáteční úlohy pro obyčejnou diferenciální rovnici 1. řádu (s nenulovým řešením), pro kterou budou výsledky Eulerovy metody totožné s výsledky metody Taylorova typu 2. řádu.
2. Uveďte příklad počáteční úlohy pro obyčejnou diferenciální rovnici 1. řádu (s nenulovým řešením), pro kterou bude metoda Taylorova typu 2. řádu totožná s metodou Taylorova typu 3. řádu, ale různá od Eulerovy metody.
3. Uveďte příklad počáteční úlohy pro obyčejnou diferenciální rovnici 1. řádu (s nenulovým řešením), pro kterou bude modifikovaná Eulerova metoda totožná s Heunovou metodou, ale různá od Eulerovy metody.

Kapitola 12. Počáteční úlohy pro ODR - II

Vícekrokové metody

V případě jednokrokových metod vystupovaly ve formuli pouze hodnoty y_k, y_{k+1} .
V případě vícekrokových metod vypočítáváme hodnotu y_{k+1} pomocí hodnot

$$y_{k-n}, y_{k-n+1}, \dots, y_{k-1}, y_k, (y_{k+1})$$

Poznámka: Pokud nepoužijeme hodnotu y_{k+1} , jedná se o **explicitní metody**, v opačném případě mluvíme

o **implicitních** metodách.

Opět vyjdeme z rovnosti

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

Musí tedy platit i rovnost integrálů

$$\int_{x_k}^{x_{k+1}} y'(x) dx = \int_{x_k}^{x_{k+1}} f(x, y(x)) dx$$

Tedy

$$y(x_{k+1}) = y(x_k) + \int_{x_k}^{x_{k+1}} f(x, y(x)) dx. \quad (*)$$

Dále postupujeme tak, že funkci $g(x)$ approximujeme interpolačním polynomem $G_n(x)$, který zintegrujeme přesně.

Poznámka: Připomeňme si odvození jednokrokové Eulerovy metody.

Funkci $g(x)$ ze vztahu (*) approximujeme konstantní funkci $G_0(x)$

$$G_0(x) = g(x_k), \quad x \in (x_k, x_{k+1})$$

Dostáváme:

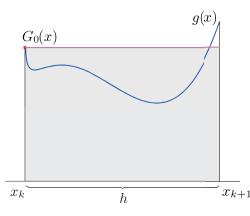
$$y_{k+1} = y_k + \int_{x_k}^{x_{k+1}} G_0(x) dx$$

$$y_{k+1} = y_k + hg(x_k)$$

$$y_{k+1} = y_k + hf(x_k, y_k)$$

Eulerova metoda

... explicitní jednokroková metoda, řád 1



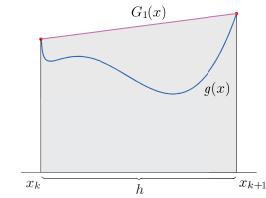
$$G_1(x) = g(x_k) + \frac{g(x_{k+1}) - g(x_k)}{h}(x - x_k), \quad x \in (x_k, x_{k+1})$$

$$\int_{x_k}^{x_{k+1}} G_1(x) dx = g(x_k)h + \frac{h}{2}[g(x_{k+1}) - g(x_k)] = \frac{h}{2}[g(x_k) + g(x_{k+1})]$$

$$y_{k+1} = y_k + \frac{h}{2}[f(x_k, y_k) + f(x_{k+1}, y_{k+1})]$$

Adams-Moultonova metoda

... implicitní dvoukroková metoda, řád 2



Odvození tříkrokových metod

Funkci $g(x)$ ze vztahu (*) approximujeme kvadratickou funkci $G_2(x)$

a)

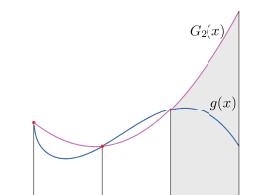
$$G_2(x) = \dots \text{ polynom procházející body } [x_{k-2}, g(x_{k-2})], [x_{k-1}, g(x_{k-1})], [x_k, g(x_k)] \quad x \in (x_k, x_{k+1})$$

$$\int_{x_k}^{x_{k+1}} G_2(x) dx = \dots \text{ D.cv.}$$

$$y_{k+1} = y_k + \frac{h}{12}[23f(x_k, y_k) - 16f(x_{k-1}, y_{k-1}) + 5f(x_{k-2}, y_{k-2})]$$

Adams-Bashforthova metoda

... explicitní tříkroková metoda, řád 3



b)

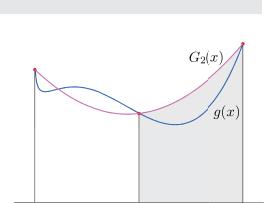
$$G_2(x) = \dots \text{ polynom procházející body } [x_{k-1}, g(x_{k-1})], [x_k, g(x_k)], [x_{k+1}, g(x_{k+1})] \quad x \in (x_k, x_{k+1})$$

$$\int_{x_k}^{x_{k+1}} G_2(x) dx = \dots \text{ D.cv.}$$

$$y_{k+1} = y_k + \frac{h}{12}[5f(x_{k+1}, y_{k+1}) + 8f(x_k, y_k) - f(x_{k-1}, y_{k-1})]$$

Adams-Moultonova metoda

... implicitní tříkroková metoda, řád 3



b)

$$G_0(x) = g(x_{k+1}), \quad x \in (x_k, x_{k+1})$$

Dostáváme:

$$y_{k+1} = y_k + \int_{x_k}^{x_{k+1}} G_0(x) dx$$

$$y_{k+1} = y_k + hg(x_{k+1})$$

$$y_{k+1} = y_k + hf(x_{k+1}, y_{k+1})$$

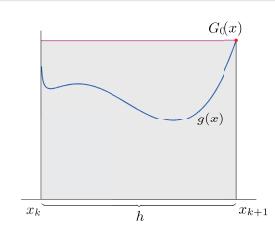
Implicitní Eulerova metoda

... implicitní jednokroková metoda, řád 1

Poznámka:

Při použití implicitní metody je třeba zvolit počáteční approximaci $y_{k+1}^{[0]}$ a dále realizovat iterační proces

$$y_{k+1}^{[l+1]} = y_k + hf(x_{k+1}, y_{k+1}^{[l]})$$



Odvození dvoukrokových metod

Funkci $g(x)$ ze vztahu (*) approximujeme lineární funkci $G_1(x)$

a)

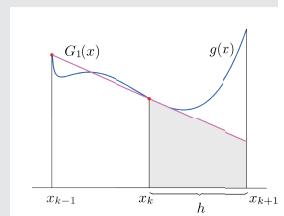
$$G_1(x) = g(x_k) + \frac{g(x_k) - g(x_{k-1})}{h}(x - x_k), \quad x \in (x_k, x_{k+1})$$

$$\int_{x_k}^{x_{k+1}} G_1(x) dx = g(x_k)h + \frac{h}{2}[g(x_k) - g(x_{k-1})] = = \frac{h}{2}[3g(x_k) - g(x_{k-1})]$$

$$y_{k+1} = y_k + \frac{h}{2}[3f(x_k, y_k) - f(x_{k-1}, y_{k-1})]$$

Adams-Bashforthova metoda

... explicitní dvoukroková metoda, řád 2



b)

Poznámky:

(i) U n -krokových metod je třeba znát n hodnot

$$y_{k-n+1}, y_{k-n}, \dots, y_k$$

Na začátku výpočtu však tyto hodnoty, tj. Y_1, \dots, Y_{n-1} , nejsou známy.

Pro jejich výpočet je třeba užít explicitní jednokrokové metody odpovídajícího řádu.

(ii) U implicitních metod je třeba určit approximaci $y_{k+1}^{[0]}$ a realizovat metodu prosté iterace

$$y_{k+1}^{[l+1]} = y_k + \dots y_{k+1}^{[l]}$$

Obecný zápis metod

Vícekrokovou (i jednokrokovou) metodu lze obecně zapsat ve tvaru

$$\sum_{j=0}^r \alpha_j y_{k+j} = h \sum_{j=0}^r \beta_j f(x_{k+j}, y_{k+j}) \approx y'(x_{k+j}).$$

• **Explicitní Eulerova metoda** ($\alpha_0 = -1, \alpha_1 = 1, \beta_0 = 1, \beta_1 = 0$)

$$y_{k+1} - y_k = hf(x_k, y_k)$$

• **Implicitní Eulerova metoda** ($\alpha_0 = -1, \alpha_1 = 1, \beta_0 = 0, \beta_1 = 1$)

$$y_{k+1} - y_k = hf(x_{k+1}, y_{k+1})$$

• **Adams-Bashforthova metoda - dvoukroková**

$$(\alpha_0 = 0, \alpha_1 = -1, \alpha_2 = 1, \beta_0 = -\frac{1}{2}, \beta_1 = \frac{3}{2}, \beta_2 = 0) \quad y_{k+2} - y_{k+1} = \frac{h}{2}[3f(x_{k+1}, y_{k+1}) - f(x_k, y_k)] \quad (k := k+1)$$

• **Adams-Moultonova metoda - dvoukroková**

$$(\alpha_0 = -1, \alpha_1 = 1, \beta_0 = \frac{1}{2}, \beta_1 = \frac{1}{2})$$

$$y_{k+1} - y_k = \frac{h}{2}[f(x_k, y_k) + f(x_{k+1}, y_{k+1})]$$

• **Adams-Bashforthova metoda - tříkroková**

$$(\alpha_0 = 0, \alpha_1 = 0, \alpha_2 = -1, \alpha_3 = 1, \beta_0 = \frac{5}{12}, \beta_1 = -\frac{4}{3}, \beta_2 = \frac{23}{12})$$

Numerické metody
Josef Daněk

KMA/NM
13.2.2013

$y_{k+3} - y_{k+2} = \frac{h}{12} [23f(x_{k+2}, y_{k+2}) - 16f(x_{k+1}, y_{k+1}) + 5f(x_k, y_k)]$ (k := k + 2)

- Adams-Moultonova metoda - tříkroková

$$(\alpha_0 = 0, \alpha_1 = -1, \alpha_2 = 1, \beta_0 = -\frac{1}{12}, \beta_1 = \frac{2}{3}, \beta_2 = \frac{5}{12})$$

$$y_{k+2} - y_{k+1} = \frac{h}{12} [5f(x_{k+2}, y_{k+2}) + 8f(x_{k+1}, y_{k+1}) - f(x_k, y_k)]$$
 (k := k + 1)

Definice: Lokální diskretizační chybou metody rozumíme

$$\tau_k = \frac{1}{h} \left[\sum_{j=0}^r \alpha_j y(x_{k+j}) - h \sum_{j=0}^r \beta_j y'(x_{k+j}) \right].$$

Definice: Řekneme, že metoda je konzistentní, je-li splněna podmínka $\tau_k(h) \rightarrow 0$ pro $h \rightarrow 0$.

Tj. jde vždy polynom v proměnné h ($\Rightarrow \tau_k$).

Dosazením do vztahu pro lokální diskretizační chybou

$$\tau_k = \frac{1}{h} \left[(\alpha_0 y(x_k) + \alpha_1 y(x_{k+1}) + \alpha_2 y(x_{k+2}) + \dots + \alpha_r y(x_{k+r})) - h (\beta_0 y'(x_k) + \beta_1 y'(x_{k+1}) + \dots + \beta_r y'(x_{k+r})) \right],$$

dostaneme

$$\tau_k = \frac{1}{h} \left[\underbrace{y(x_k) \left(\sum_{j=0}^r \alpha_j \right)}_{\text{konstantní členy}} + \underbrace{h y'(x_k) \left(\sum_{j=0}^r (j\alpha_j - \beta_j) \right)}_{\text{lineární členy}} + h^2 y''(x_k) \left(\frac{1}{2} \sum_{j=0}^r j^2 \alpha_j - \sum_{j=0}^r j \beta_j \right) + \underbrace{h^3 y'''(x_k) (\dots) + \dots}_{\text{kubické členy}} \right].$$

Po roznošení:

$$\tau_k = \frac{1}{h} \left[y(x_k) \left(\sum_{j=0}^r \alpha_j \right) + y'(x_k) \left(\sum_{j=0}^r (j\alpha_j - \beta_j) \right) + h (\dots) + h^2 (\dots) + \dots \right]$$

D.c.v.: Ukažte, že dříve odvozené metody jsou konzistentní.

Použijeme-li Taylorov rozvoj, získáme:

$$y(x_k) = y(x_k)$$

$$y(x_{k+1}) = y(x_k) + hy'(x_k) + \frac{1}{2}h^2 y''(x_k) + \dots$$

$$y(x_{k+2}) = y(x_k) + 2hy'(x_k) + \frac{1}{2}(2h)^2 y''(x_k) + \dots$$

$$y(x_{k+3}) = y(x_k) + 3hy'(x_k) + \frac{1}{2}(3h)^2 y''(x_k) + \dots$$

$$\vdots$$

$$y(x_{k+j}) = y(x_k) + jhy'(x_k) + \frac{1}{2}(jh)^2 y''(x_k) + \dots$$

a analogicky pro derivaci (formálně přípíšeme '):

$$y'(x_k) = y'(x_k)$$

$$y'(x_{k+1}) = y'(x_k) + hy''(x_k) + \frac{1}{2}h^2 y'''(x_k) + \dots$$

$$y'(x_{k+2}) = y'(x_k) + 2hy''(x_k) + \frac{1}{2}(2h)^2 y'''(x_k) + \dots$$

$$y'(x_{k+3}) = y'(x_k) + 3hy''(x_k) + \frac{1}{2}(3h)^2 y'''(x_k) + \dots$$

$$\vdots$$

$$y'(x_{k+j}) = y'(x_k) + jhy''(x_k) + \frac{1}{2}(jh)^2 y'''(x_k) + \dots$$

Definice: Polynom v proměnných v a w ve tvaru

$$\rho(v) = \sum_{j=0}^r \alpha_j v^j \quad \text{a} \quad \sigma(w) = \sum_{j=0}^r \beta_j w^j$$

nazýváme charakteristické polynomy metody.

Poznámka: Metoda je konzistentní, platí-li

$$\rho(1) = 0 \quad \text{a} \quad \sigma(1) = c(1)$$

Poznámka:

Nestabilita - do výsledku je vnášena chyba, jejíž vliv zesiluje až celý výpočet znehodnotí.

Příčiny - špatná podmíněnost úlohy (nezávisí na volbě metody); nevhodná metoda nebo příliš velký krok.

Definice: Mějme dánou počáteční úlohu s lipschitzovskou funkcí f :

$$y' = f(x, y), \quad x \in (0, T)$$

$$y(0) = \eta$$

Řekneme, že metoda je konvergentní, když platí:

$$\lim_{h \rightarrow 0} y_N = y(T)$$

$$N h = T$$

a

$$\lim_{h \rightarrow 0} y_k = \eta \quad \text{pro } k = 0, 1, \dots, r-1$$

pro každé pevné T (uvažujeme r -krokovou metodu).

Numerické metody
Josef Daněk

KMA/NM
13.2.2013

Poznámka: Je zřejmé, že nutnou podmínkou konvergence je konzistence metody. Je i podmínkou postačující?

Věta Uvažujme úlohu

$$y' = \lambda y, \quad x \in (0, T)$$

$$y(0) = \eta$$

Eulerova metoda je pro tuto úlohu konvergentní.

Důkaz:

$$y(x_{k+1}) = y(x_k) + h \frac{y(x_k)}{\lambda} + h \tau_k$$

$$y_{k+1} = y_k + h \lambda y_k$$

$$\frac{y(x_{k+1}) - y_{k+1}}{E_{k+1}} = \frac{y(x_k) - y_k}{E_k} + h \lambda \frac{(y(x_k) - y_k)}{E_k} + h \tau_k$$

$$E_{k+1} = E_k (1 + h \lambda) + h \tau_k$$

Tj.

$$E_1 = \frac{0}{E_0 (1 + h \lambda) + h \tau_0}$$

$$E_2 = E_1 (1 + h \lambda) + h \tau_1$$

$$\vdots$$

Obecně lze psát:

(*) $|E_1| = |h \tau_0| \rightarrow 0$ pro $h \rightarrow 0$.
 (***) $\rightarrow 0$ pro $h \rightarrow 0$, protože je Eulerova metoda konzistentní.

Důkaz:

Platí

Numerické metody
Josef Daněk

KMA/NM
13.2.2013

$$y(x_{k+1}) = y(x_k) + h f(x_k, y(x_k)) + h \tau_k$$

$$y_{k+1} = y_k + h f(x_k, y_k)$$

$$\frac{y(x_{k+1}) - y_{k+1}}{E_{k+1}} = \frac{y(x_k) - y_k}{E_k} + h [f(x_k, y(x_k)) - f(x_k, y_k)] + h \tau_k$$

Funkce f je lipschitzovsky spojitá:

$$|f(x_k, y(x_k)) - f(x_k, y_k)| \leq L \cdot |y(x_k) - y_k| \quad \forall x_k \in (0, T)$$

Pak lze psát:

$$|E_{k+1}| \leq |E_k| + h L |E_k| + h |\tau_k|.$$

Dále je důkaz stejný ($|\lambda| = L$)

$$|E_k| \leq e^{Lx} \left[|E_0| + h k \max_{1 \leq m \leq k} |\tau_{m-1}| \right]$$

□

Konvergence vícekrokových metod

Příklad: Uvažujme vícekrokovou metodu ve tvaru

$$y_{k+2} = 3y_{k+1} - 2y_k - h f(x_k, y_k)$$

Obecný zápis byl

$$\sum_{j=0}^r \alpha_j y_{k+j} = h \sum_{j=0}^r \beta_j f(x_{k+j}, y_{k+j}).$$

Platí:

$$\alpha_0 = 2, \quad \alpha_1 = -3, \quad \alpha_2 = 1, \quad \sum_{j=0}^2 \alpha_j = 0$$

$$\beta_0 = -1, \quad \beta_1 = 0, \quad \beta_2 = 0, \quad \sum_{j=0}^2 \beta_j = -1 \stackrel{j}{=} \sum_{j=0}^2 j \alpha_j = 0 \cdot \alpha_0 + 1 \cdot \alpha_1 + 2 \cdot \alpha_2 = 0 + (-3) + 2 = -1$$

\Rightarrow metoda je konzistentní.

Touto metodou budeme řešit počáteční úlohu

$$y' = 0, \quad x \in (0, T)$$

$$y(0) = 0$$

Pro tuto úlohu má metoda tvar

$$y_{k+2} = 3y_{k+1} - 2y_k$$

Obecně lze psát:

$$y_k = 2y_0 - y_1 + 2^k (y_1 - y_0)$$

Důkaz: (pomocí úplné matematické indukce)

1. $k = 2, k = 3$

$$y_2 = 2y_0 - y_1 + 2^2 (y_1 - y_0) = 3y_1 - 2y_0 \quad \checkmark$$

$$y_3 = 2y_1 - y_2 + 2^3 (y_2 - y_1) = 7y_1 - 6y_0 \stackrel{?}{=} 3y_2 - 2y_1 = 3(3y_1 - 2y_0) - 2y_1 \quad \checkmark$$



$$2. \begin{cases} y_k = 2y_0 - y_1 + 2^k(y_1 - y_0) \\ y_{k+1} = 2y_0 - y_1 + 2^{k+1}(y_1 - y_0) \end{cases} \Rightarrow y_{k+2} = 2y_0 - y_1 + 2^{k+2}(y_1 - y_0)$$

$$y_{k+2} = 3y_{k+1} - 2y_k = 3(2y_0 - y_1 + 2^{k+1}(y_1 - y_0)) - 2(2y_0 - y_1 + 2^k(y_1 - y_0)) =$$

$$= 2y_0 - y_1 + \underbrace{(6-2)}_{=2^2} 2^k(y_1 - y_0) \quad \checkmark$$

□

Problém:

Pokud $y_1 = y_0 = y(0) = 0 \Rightarrow y_k = 0 \forall k$. ✓

Pokud se y_1 bude lišit (i když velmi málo) od 0, pak pro $k \rightarrow \infty$: $y_k \rightarrow \infty$. ✗

Považujeme-li rovnost $y_{k+2} = 3y_{k+1} - 2y_k$ za diferenční rovnici, můžeme ji řešit.

Předpokládáme, že $y_k = Cv^k$. Pak lze psát

$$Cv^{k+2} = 3Cv^{k+1} - 2Cv^k$$

$$Cv^2 = 3Cv - 2C$$

$$v^2 - 3v + 2 = 0$$

$$v_{1,2} = \frac{3 \pm \sqrt{9-8}}{2}$$

$$v_1 = 2, \quad v_2 = 1$$

$$y_k = C_1 2^k + C_2$$

Dále víme, že pro

$$k=0: \quad y_0 = C_1 + C_2$$

$$k=1: \quad y_1 = 2C_1 + C_2$$

$$\Rightarrow C_1 = y_1 - y_0$$

$$C_2 = y_0 - C_1 = y_0 - y_1 + y_0 = 2y_0 - y_1$$

$$y_k = (y_1 - y_0)2^k + 2y_0 - y_1$$

$$y_k = (y_1 - y_0) \underbrace{\frac{2^k}{v_1}}_{=v_1} + (2y_0 - y_1) \underbrace{\frac{1}{v_2}}_{=v_2}$$

Připomeňme, že vícekrokou metodou jsme zapisovali ve tvaru

$$\sum_{j=0}^r \alpha_j y_{k+j} = h \sum_{j=0}^r \beta_j f(x_{k+j}, y_{k+j})$$

a charakteristické polynomu jsme definovali

$$\rho(v) = \sum_{j=0}^r \alpha_j v^j \quad \text{a} \quad \sigma(w) = \sum_{j=0}^r \beta_j w^j.$$

O stabilitě výpočtu rozhodují kořeny polynomu $\rho(v)$ (viz (*)).

Pro kořeny η_j polynomu $\rho(v)$ musí platit $|\eta_j| \leq 1$.



Definice: Řekneme, že metoda je **D-stabilní**, pokud kořeny charakteristického polynomu $\rho(v)$ splňují podmínky:

(i) $|\eta_j| \leq 1$ pro $j = 1, 2, \dots, r$,

(ii) je-li η_j násobný kořen, potom $|\eta_j| < 1$.

Poznámky:

- Je-li metoda D-stabilní, nebude v průběhu výpočtu radikálně zvětšovat jednokrokou chybu.

- Uvažujeme Eulerovu metodu

$$y_{k+1} - y_k = h f(x_k, y_k)$$

$$\rho(v) = v - 1 = 0 \Rightarrow \eta = 1$$

⇒ Eulerova metoda je D-stabilní.

Odhad chyby metodou polovičního kroku

Pro globální chybu metody lze psát

$$\boxed{\begin{aligned} y(\bar{x}) &= y(x, h) + E_h + F_h \\ &\text{přesné} \quad (*) \quad Ch^p \quad O(h^r), \quad r > p \end{aligned}}$$

$$(*) \quad y(x, h) = y_k(h), \quad x \in (x_k, x_{k+1}), \quad k = 0, 1, \dots, N-1$$

pro poloviční krok

$$\boxed{y(\bar{x}) = y\left(x, \frac{h}{2}\right) + E_{\frac{h}{2}} + F_{\frac{h}{2}}} \quad (\bullet\bullet)$$

Po odečtení (*) - (bullet\bullet):

$$0 = y(x, h) - y\left(x, \frac{h}{2}\right) + E_h - E_{\frac{h}{2}} + \dots$$

$$0 \approx y(x, h) - y\left(x, \frac{h}{2}\right) + (2^p - 1)E_{\frac{h}{2}}$$

$$\boxed{E_{\frac{h}{2}} = \frac{y(x, \frac{h}{2}) - y(x, h)}{2^p - 1}}$$

$$\Rightarrow y(\bar{x}) \approx y\left(x, \frac{h}{2}\right) + E_{\frac{h}{2}}$$

Poznámka: Opět lze použít Richardsonovu extrapolaci

- aktivní extrapolace

extrapolaci provádíme v každém kroku (extrapolované y_k použijeme pro výpočet y_{k+1})

- pasivní extrapolace

vypočteme y_k , $k = 0, 1, \dots, N-1$ s různými parametry h potom provedeme extrapolaci

Algoritmus prediktor-korektor

Poznámka: Jde o obecné schéma výpočtu.

Princip:



Předpokládáme, že máme dostatečně přesně vypočítány hodnoty y_0, y_1, \dots, y_{k-1} nějakou **explicitní** jednokrokou metodou.

Nyní chceme počítat y_k .

- 1) Nejprve nějakou explicitní metodou určíme nultou iteraci $y_k^{[0]}$ jako vstupní hodnotu pro další výpočet (PREDIKTOR).
- 2) Vypočteme hodnotu pravé strany $F_k^{[s]} = f(x_k, y_k^{[s]})$.
- 3) Vypočteme lepší aproximaci $y_k^{[s+1]}$ pomocí nějaké implicitní metody s využitím $F_k^{[s]} := f_k$ (KOREKTOR).

Pomocí kroků 2) a 3) určíme N iterací $y_k^{[1]}, y_k^{[2]}, \dots, y_k^{[N]}$ (N – dáno).

Na závěr případně $y_k = y_k^{[N]}$.

Stejný postup opakujeme pro y_{k+1}, y_{k+2}, \dots .

Poznámka: Dané schéma lze použít na různé metody. Je žádoucí použít explicitní a implicitní metodu stejného řádu (pro zachování přesnosti). Volba konkrétních metod je nás.

Poznámka: Označíme-li operaci:

- P ... prediktor
- E ... výpočtení (evaluation)
- C ... korektor

Můžeme toto schéma zapsat ve tvaru:

$P(EC)^N$ případně $P(EC)^N E$, vyčislujeme-li ještě $F_k = f(x_k, y_k^{[N]})$ (což je lepší). Dostaneme pak různé varianty tohoto schématu:

$$\begin{array}{l} PEC \\ P(EC)^2 \cdot P(EC)^2 E \\ P(EC)^3 \cdot P(EC)^3 E \\ \vdots \end{array}$$

Příklad: Řešte algoritmem prediktor-korektor založeném na Adamsových metodách druhého řádu na intervalu $\langle 0, 6 \rangle$ počáteční úlohu:

$$\boxed{y' = y + e^x, \quad \text{tj. } f(x, y(x)) = y + e^x \\ y(0) = -1}$$

Přesné řešení: $y = e^x(x - 1)$.

Použijeme algoritmus typu PEC.

Vzorec prediktoru má tvar:

$$y_{n+1}^{[0]} = y_n + \frac{h}{2} (3F_n - F_{n-1})$$

Korektor:

$$y_{n+1} = y_n + \frac{h}{2} (F_{n+1}^{[0]} + F_n)$$

Vzorec krok $h = 0,2$.

TRIAL



n	x_n	$\overbrace{y(x_n)}$	$y_n^{[0]}$	$F_n^{[0]}$	y_n	e_n
0	0	-1		** 0	↔ -1	0
1	0,2	-0,9771		** 0,2425 ↔ -0,9789		0,0018
2	0,4	-0,8950	P -0,9061 ↔ E 0,5857 ↔ C -0,8960			0,0010
3	0,6	-0,7288	P -0,7445 ↔ E 1,0776 ↔ C -0,7296			0,0008

• Pro určení hodnoty y_1 použijeme např. jednokrokou modifikovanou Eulerovu metodu (2. řádu):

$$\begin{aligned} k_1 &= f(x_0, y_0) = y_0 + e^{x_0} = \\ &= -1 + 1 = 0 \\ k_2 &= f(x_0 + h/2, y_0 + h/2 \cdot k_1) = \\ &= -1 + e^{0,1} = 0,1051 \\ y_1 &= y_0 + h \cdot k_2 = \\ &= -1 + 0,2 \cdot 0,1051 = -0,9789 \end{aligned}$$

Určíme hodnoty F_0 a F_1 :

Odhad chyby pomocí algoritmu prediktor-korektor

Za předpokladu, že se hodnota derivace $y^{(p+1)}$, kde p je řád metody, příliš nemění, lze odvodit odhad pro lokální chybę algoritmu

$$d_k \approx \frac{C_{p+1}^p - C_{p+1}^p}{C_{p+1}^p - C_{p+1}^p} (y_{k+1}^p - y_k^p)$$

kde

$C_{p+1}^p, C_{p+1}^p \dots$ konstanty v lokální chybě metody, tj. $d_k = c_{p+1}^p h^{p+1} y^{p+1}(x_k)$

$y_{k+1}^p \dots$ vypočteno korektorem

$y_k^p \dots$ vypočteno prediktorem

Podmíněnost úlohy a stabilita metody

Příklad Řešme počáteční úlohu

$$\boxed{y' = y - \frac{x}{3} - \frac{2}{3}, \quad x \in (0, T) \\ y(0) = 1}$$

řešení této počáteční úlohy má tvar $y = \frac{x}{3} + 1$

obecné řešení dané rovnice je $y = Ae^x + \frac{x}{3} + 1$

TRIAL

⇒ úloha je špatně podmíněná!

$$(y(0) = 1 + \varepsilon \rightarrow y = \varepsilon e^x + \frac{x}{3} + 1)$$

pro řešení je třeba použít metodu vyššího řádu a dostatečně přesnou aritmetiku

Příklad Pomocí Eulerovy metody řešme počáteční úlohu

$$\begin{cases} y' = \lambda y, & x \in (0, T) \\ y(0) = 1 \end{cases} \quad (\clubsuit)$$

přesné řešení úlohy je $y(x) = e^{\lambda x}$
v tomto případě má Eulerova metoda tvar

$$y_{k+1} = y_k + h \lambda y_k$$

$$y_{k+1} = (1 + h\lambda)y_k = \tilde{h}$$

Je-li $|1 + \tilde{h}| < 1$, pak je posloupnost y_k omezená a klesající.

Je-li $|1 + \tilde{h}| > 1$, pak posloupnost y_k neomezeně roste (oscuje).

$$|1 + \tilde{h}| < 1 \Leftrightarrow \tilde{h} = h\lambda \in (-2, 0)$$

Pro konkrétní úlohu:

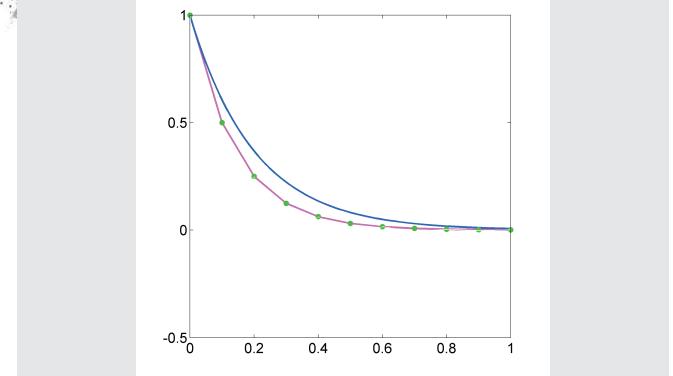
$$\begin{cases} y' = -5y, & x \in (0, 1) \\ y(0) = 1 \end{cases}$$

a krok h pomocí Eulerovy metody dostaneme:

$$1) \quad h = 0,1$$

$$y_{k+1} = \underbrace{(1 - 0,1 \cdot 5)}_{= -0,5} y_k$$

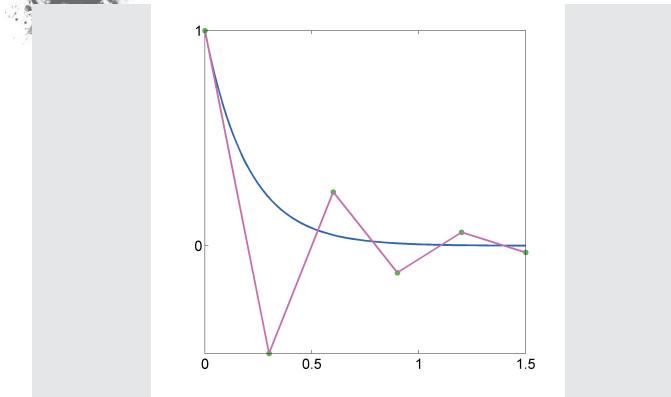
x_k	0	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	1
y_k	1,0000	0,5000	0,2500	0,1250	0,0625	0,0313	0,0156	0,0078	0,0039	0,0020	0,0010



$$2) \quad h = 0,3$$

$$y_{k+1} = \underbrace{(1 - 0,3 \cdot 5)}_{= -0,5} y_k$$

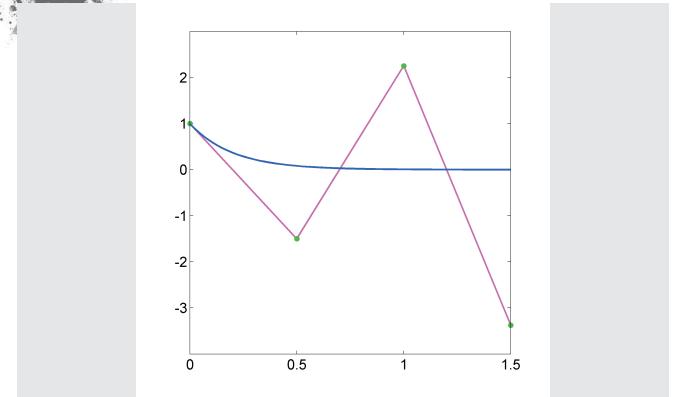
x_k	0	0,3	0,6	0,9	1,2	1,5
y_k	1,0000	-0,5000	0,2500	-0,1250	0,0625	-0,0313



$$3) \quad h = 0,5$$

$$y_{k+1} = \underbrace{(1 - 0,5 \cdot 5)}_{= -1,5} y_k$$

x_k	0	0,5	1,0	1,5
y_k	1,0000	-1,5000	2,2500	-3,3750



$$\text{Tj. v případě velké záporné hodnoty } \lambda = -2000 \rightarrow h < \frac{2}{2000} = 0,0001$$

řešení $y(x) = e^{-2000x} \rightarrow 0$ pro $x \rightarrow \infty$

$$y_k = (1 + h\lambda)^k y_0 = (1 - 2000h)^k \rightarrow 0 \quad \text{pro } k \rightarrow \infty$$

Poznámka:

Řekneme, že metoda je pro λ **absolutně stabilní**, jestliže při h a λ : $h\lambda = \tilde{h}$, všechna přibližná řešení mají pro $k \rightarrow \infty$ limitu rovnou 0 ($y_k \rightarrow 0$).

$$\text{Úlohu } (\clubsuit) \text{ uvažujeme proto, že rovnice } y' = f(x, y) \text{ po linearizování přejde na tvar } y' = \frac{\partial f}{\partial y} y = \lambda y$$

⇒ Stabilita závisí jak na metodě, tak na úloze.

Připomeňme, že platí:

$$\begin{aligned} y(x_{k+1}) &= y(x_k) + h\lambda y(x_k) + h\tau_k \\ y_{k+1} &= y_k + h\lambda y_k \\ E_{k+1} &= E_k + h\lambda E_k + h\tau_k \\ |E_{k+1}| &\leq |1 + h\lambda| \cdot |E_k| + h|\tau_k| \end{aligned}$$

Chceme-li, aby $|E_k| \rightarrow 0$ pro $k \rightarrow \infty$, musíme požadovat

$$|1 + h\lambda| < 1$$

Tuto úvahu můžeme učinit i pro obecnou vícekrokovou metodu

$$\sum_{j=0}^r \alpha_j y_{k+j} = h \sum_{j=0}^r \beta_j \lambda y_{k+j}$$

$$\sum_{j=0}^r (\alpha_j - h\beta_j) y_{k+j} = 0$$

Definujeme **polynom stability**:

$$\Pi(u, h) = \sum_{j=0}^r (\alpha_j - h\beta_j) u^j.$$

Definice: **Oblastí absolutní stability metody** nazýváme množinu

$$\mathcal{A} = \{h \in \mathbb{C} : |\alpha_j| \leq 1 \quad \forall j : \Pi(\alpha_j, h) = 0\}$$

$$|\alpha_j| < 1 \text{ pro násobné kořeny}$$

tj. „množina hodnot h v komplexní rovině, pro které kořeny polynomu $\Pi(u, h)$ splňují podmínku $|\alpha_j| < 1$ “

Příklady

1. (explicitní) Eulerova metoda

$$y_{k+1} - y_k = h f(x_k, y_k)$$

Koeficienty metody

$$\alpha_0 = -1, \alpha_1 = 1, \beta_0 = 1, \beta_1 = 0$$

Polynom stability

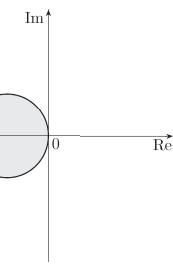
$$\Pi(u, h) = \sum_{j=0}^r (\alpha_j - h\beta_j) u^j$$

$$\Pi(u, h) = (-1 - h) + u = u - 1 - h$$

Kořen

$$u = 1 + h; \quad |u| = |1 + h| \leq 1$$

Oblast absolutní stability metody



2. implicitní Eulerova metoda

$$y_{k+1} - y_k = h f(x_{k+1}, y_{k+1})$$

Koeficienty metody

$$\alpha_0 = -1, \alpha_1 = 1, \beta_0 = 0, \beta_1 = 1$$

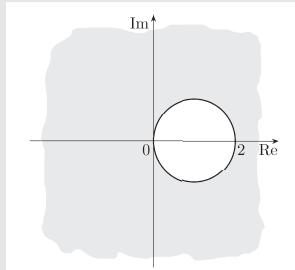
Polynom stability

$$\Pi(u, h) = -1 + (1 - h)u = (1 - h)u - 1$$

Kořen

$$|u| = \frac{1}{|1 - h|} \leq 1; \quad |1 - h| \geq 1$$

Oblast absolutní stability metody



Interval absolutní stability

Eulerova metoda $(-2, 0)$

Implicitní Eulerova metoda $(-\infty, 0) \cup (2, \infty)$

Příklad Stanovte oblast absolutní stability pro tzv. obdélníkové pravidlo, tj. metodu s předpisem

$$y_{k+1} = y_k + 2hf(x_k, y_k).$$

Koeficienty metody

$$\alpha_0 = -1, \alpha_1 = 0, \alpha_2 = 1, \beta_0 = 0, \beta_1 = 2, \beta_2 = 0$$

Polynom stability

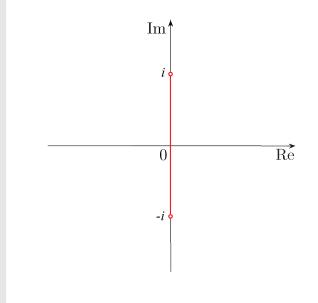
$$\Pi(u, h) = -1 - 2hu + u^2$$

Kořeny

$$u_{1,2} = \frac{2h \pm \sqrt{4h^2 + 4}}{2} = h \pm \sqrt{h^2 + 1}$$

Pro oblast absolutní stability musí platit (D.cv.)

$$|u_1| < 1 \quad \wedge \quad |u_2| < 1$$



Příklad Stanovte oblast absolutní stability pro tzv. líchoběžníkové pravidlo, tj. metodu s předpisem

$$y_{k+1} = y_k + \frac{h}{2} [f(x_k, y_k) + f(x_{k+1}, y_{k+1})].$$

Koeficienty metody

$$\alpha_0 = -1, \alpha_1 = 1, \beta_0 = \frac{1}{2}, \beta_1 = \frac{1}{2}$$

Polynom stability

$$\Pi(u, h) = (-1 - \frac{1}{2}h) + (1 - \frac{1}{2}h)u$$

Kořen

$$u = \frac{2 + h}{2 - h}$$

Plati

$$|u| < 1 \quad \text{pro } \operatorname{Re} h < 0$$

Nebot

$$\left| \frac{2+h}{2-h} \right| < 1 \Leftrightarrow |2+h| < |2-h| \Leftrightarrow |h - (-2)| < |h - 2|,$$

tj. vzdálenost h od -2 je menší než vzdálenost od 2 .

Oblast absolutní stability metody

