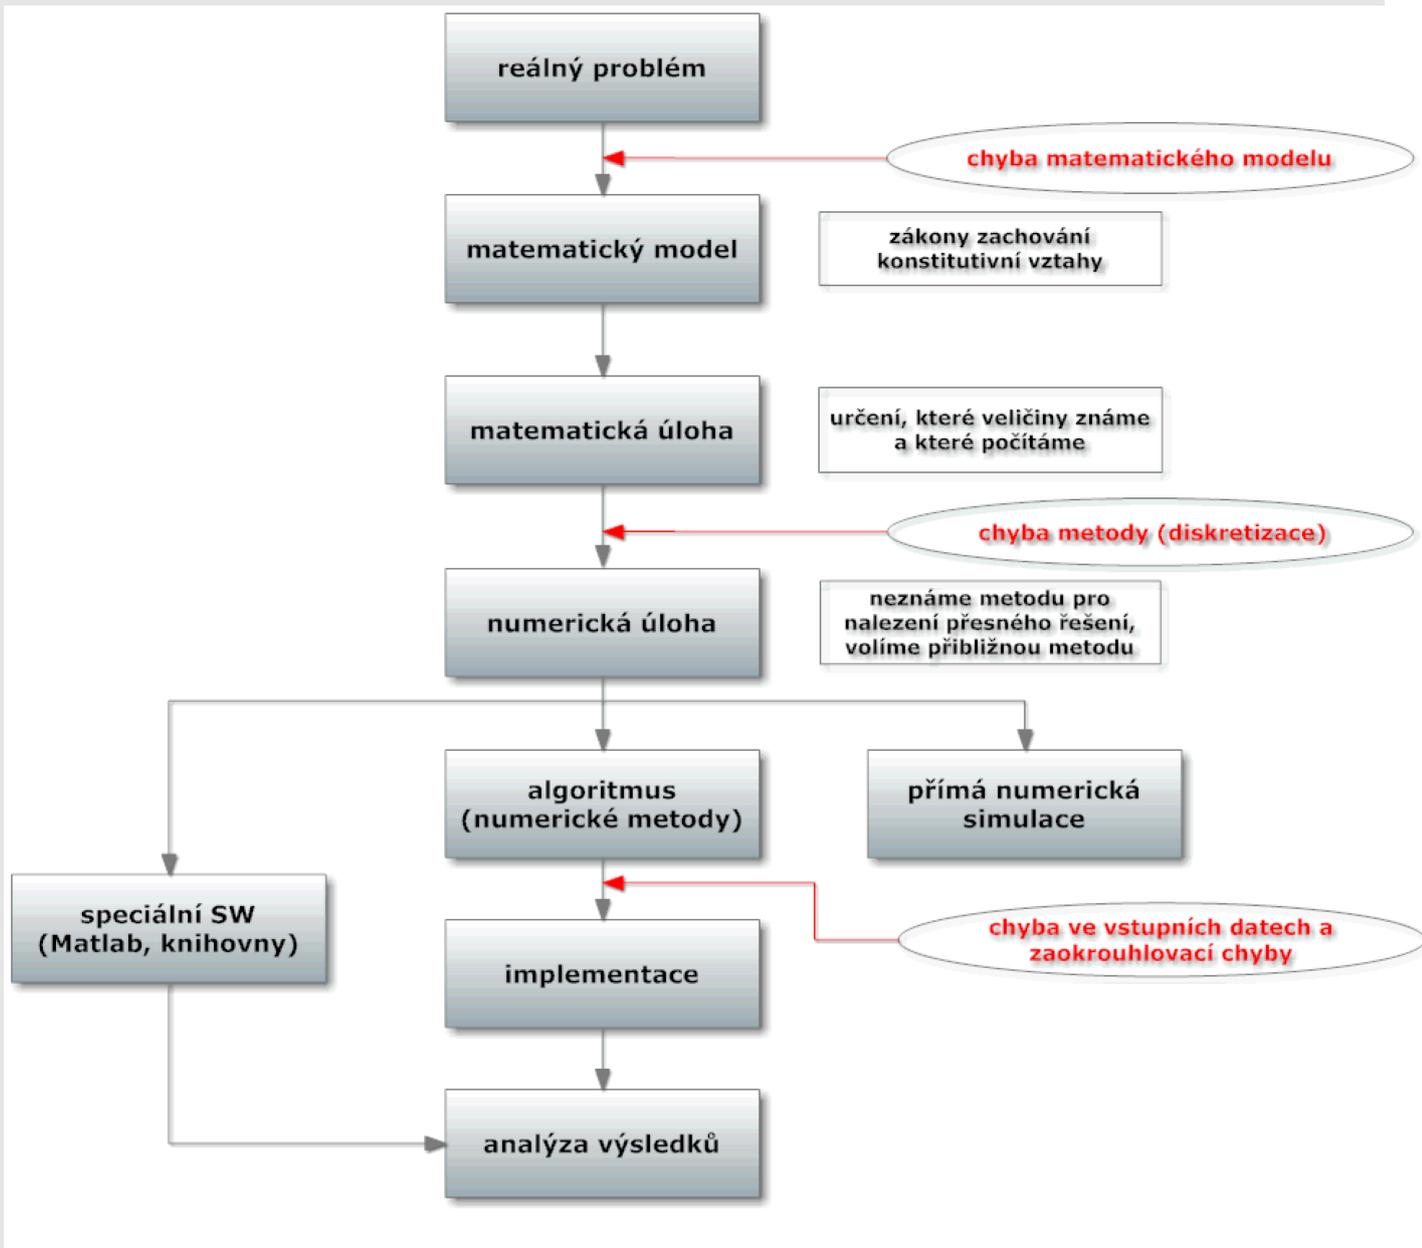




Kapitola 1. Úvod do numerické matematiky

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 $t \in \langle 0, T \rangle$

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 $\langle 0, T \rangle$

chyba diskretizace (metody)

Numerická metoda

- derivaci $\frac{dC}{dt}$ aproximujeme poměrnou diferencí

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

chyba diskretizace (metody)

Výpočet

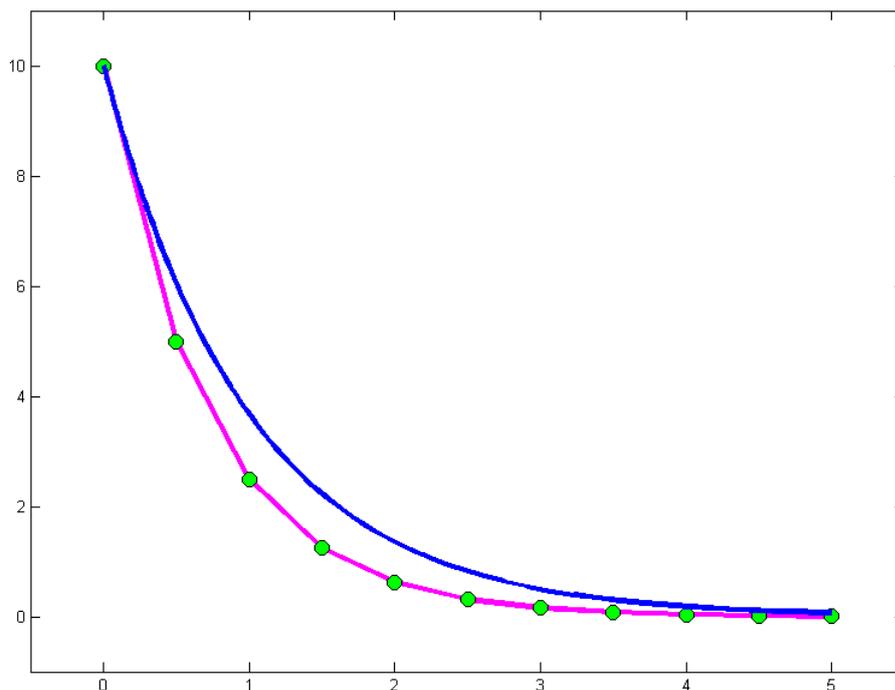
$$C_{n+1} = \left(1 - \frac{T}{N} \cdot k\right) \cdot C_n, \quad C_0 \text{ dáno}$$

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

\tilde{x} ... přibližná hodnota

absolutní chyba ... $A(x) = |x - \tilde{x}| \leq \underbrace{a(x)}_{\text{odhad}}$

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

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

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

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

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

Pozn.: Násobení a dělení nemohou podstatně zvětšit relativní chybu

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

$$|xy - \tilde{x}\tilde{y}| = |xy - \tilde{x}y + \tilde{x}y - \tilde{x}\tilde{y}| = |y(x - \tilde{x}) + \underbrace{\tilde{x}}_{\approx x}(y - \tilde{y})| \leq |y| \cdot |x - \tilde{x}| + |x| \cdot |y - \tilde{y}|$$

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

$$\frac{|x|a(y) + |y|a(x)}{|xy|} = \frac{a(y)}{|y|} + \frac{a(x)}{|x|}$$

$$a\left(\frac{x}{y}\right) = \frac{|x| \cdot a(y) + |y| \cdot a(x)}{y^2}$$

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

$$r\left(\frac{x}{y}\right) = r(x) + r(y)$$

$$\frac{|x|a(y) + |y|a(x)}{y^2} = \frac{a(y)}{|y|} + \frac{a(x)}{|x|}$$

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 spojitě 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 :

- X je lineární;
- $\forall u \in X \rightarrow \|u\|$:

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

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

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

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

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

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

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

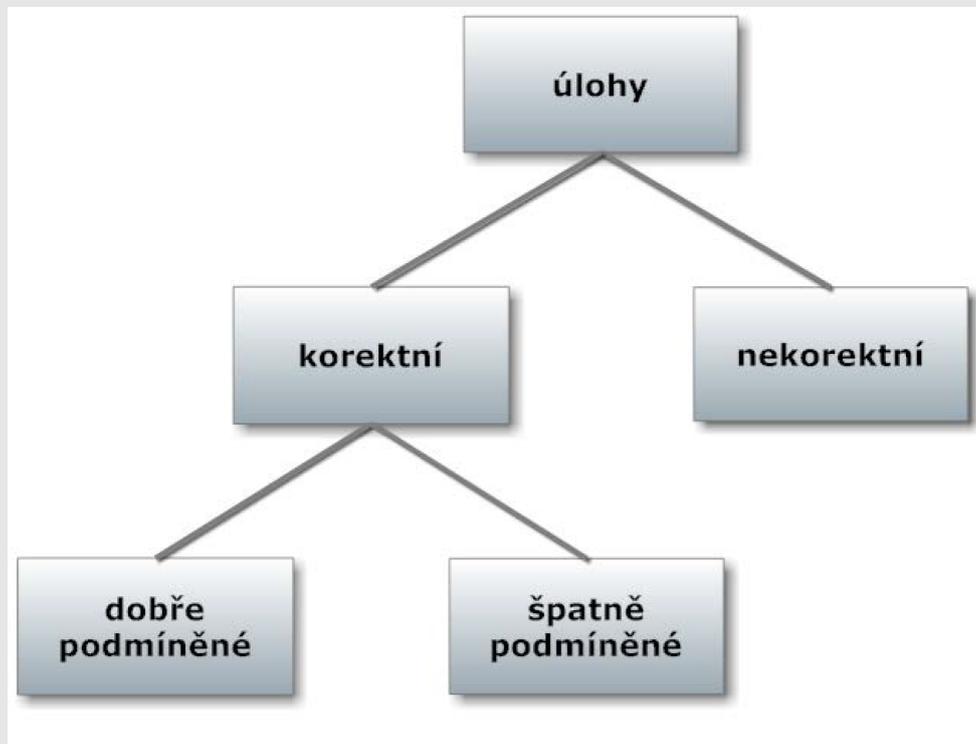
Definice: Úloha je **dobře podmíněná**, jestliže malá relativní změna ve vstupních datech vyvolá malou relativní změnu řešení.

Číslo podmíněnosti úlohy $y = U(x)$

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

Poznámka: Je-li $C_p \approx 1$ je úloha velmi dobře podmíněná.

V praxi hovoříme o špatně podmíněné úloze pro $C_p \gtrsim 100$.



Příklad 1

Posuďte podmíněnost úlohy určit hodnotu funkce $y = \sin(x)$

- v bodě 3,14;
- v bodě -0,01.

a) Volíme $x = 3,14$, $\Delta x = 0,01$ ← *malá změna na vstupu*

$$(y =) \sin x = \sin 3,14 = 0,0015926$$

$$(y + \Delta y =) \sin(x + \Delta x) = \sin 3,15 = -0,0084072$$

$$\Delta y = \sin(x + \Delta x) - \sin x = -0,0099998 \quad \leftarrow \text{změna na výstupu}$$

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

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

$C_p \doteq 1971,6 \rightarrow$ špatně podmíněná úloha

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

$$\sin x = -0,0099998$$

$$\sin(x + \Delta x) = \sin 0 = 0$$

$$\Delta y = 0,099998$$

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

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

$C_p \doteq 1 \rightarrow$ velmi dobře podmíněná úloha

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

Podle věty o střední hodnotě platí:

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

odtud:

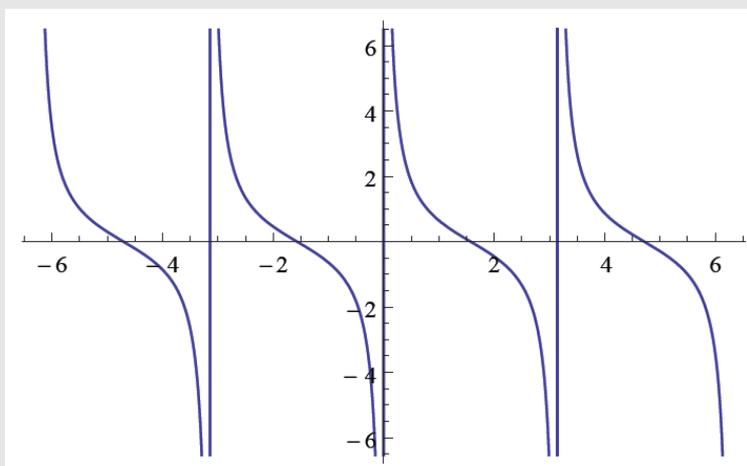
$$\left| \frac{\Delta y}{y} \right| \approx \frac{|f'(x)| \cdot |\Delta x|}{|f(x)|} = \boxed{\left| \frac{x \cdot f'(x)}{f(x)} \right|} \cdot \left| \frac{\Delta x}{x} \right|$$

Tedy

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

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

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



$$\lim_{x \rightarrow \pi^\pm} x \cotg x = \pm\infty$$

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

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

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

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

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

$$C_p = \left| \frac{xf'(x)}{f(x)} \right| = \left| \frac{x \frac{1}{\sqrt{1-x^2}}}{\arcsin x} \right| = \left| \frac{1}{\underbrace{\sqrt{1-x^2}}_{\rightarrow 0+}} \left(\frac{x}{\arcsin x} \right)^{\rightarrow 1} \right| \xrightarrow{x \rightarrow 1} \infty$$

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 $\alpha \neq \pm 1$)

$$\begin{aligned} x + \alpha y &= 1 \\ \alpha x + y &= 0 \\ x(1 - \alpha^2) &= 1 \end{aligned}$$

$$\begin{aligned} x &= \frac{1}{1 - \alpha^2} \\ y &= -\frac{\alpha}{1 - \alpha^2} \end{aligned}$$

Nechť vstup je hodnota α a výstup hodnota x .

Pak

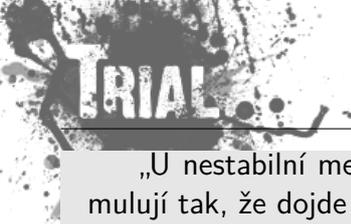
$$C_p = \frac{\left| \frac{\Delta x}{x} \right|}{\left| \frac{\Delta \alpha}{\alpha} \right|} \approx \left| \frac{\alpha \frac{dx}{d\alpha}}{x} \right| \approx \left| \frac{\alpha \frac{2\alpha}{(1-\alpha^2)^2}}{\frac{1}{1-\alpha^2}} \right| = \frac{2\alpha^2}{1-\alpha^2}$$

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

* viz předchozí poznámka

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

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



„U nestabilní metody (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

- dobře podmíněný - 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 rekurze)

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

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 zadané diferenční rovnice.

- charakteristický polynom

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

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

- kořeny

$$\lambda_{1,2} = \frac{\frac{13}{3} \pm \sqrt{\left(\frac{13}{3}\right)^2 - 4 \cdot \frac{4}{3}}}{2} = \frac{\frac{13}{3} \pm \sqrt{\frac{121}{9}}}{2}, \quad \text{tj. } \lambda_1 = \frac{1}{3}, \lambda_2 = 4$$

- 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 podmínku $B = 0$ vzniknou vlivem zaokrouhlovacích chyb malé druhé komponenty řešení

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

```

clc;
clear;
format short;

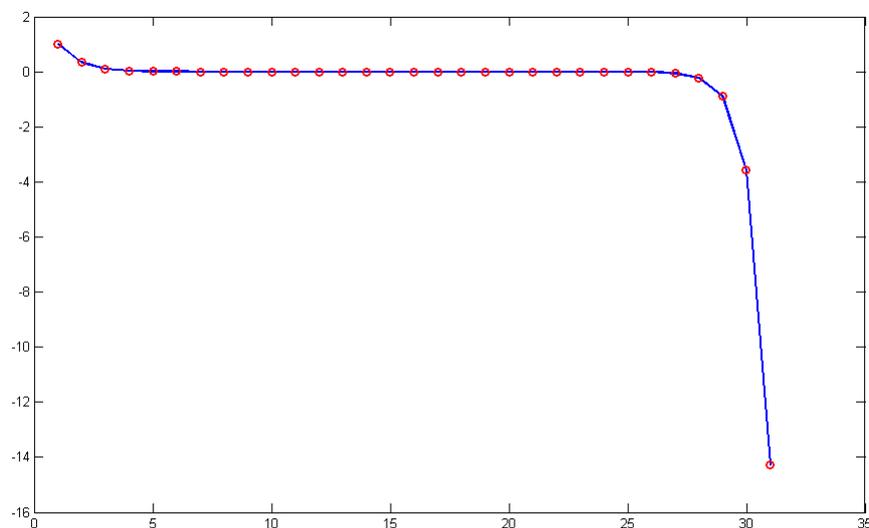
n=30;

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:

$$\underbrace{\int_0^1 x^{n-1} dx}_{\left[\frac{1}{n}x^n\right]_0^1 = \frac{1}{n}} = \int_0^1 \frac{x^{n-1}(x+5)}{x+5} dx = \underbrace{\int_0^1 \frac{x^n}{x+5} dx}_{J_n} + 5 \underbrace{\int_0^1 \frac{x^{n-1}}{x+5} dx}_{J_{n-1}}$$

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;

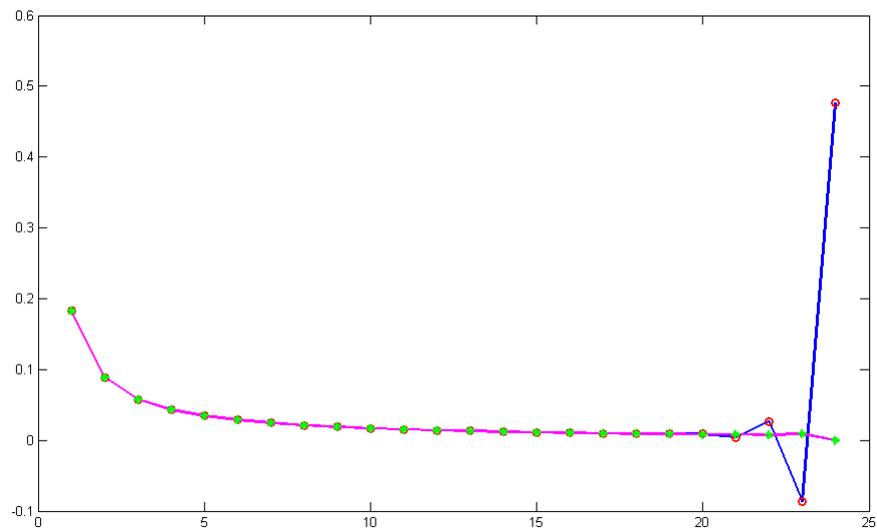
n=24;

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	1.0521e-002
9.8903e-003	9.8964e-003
9.3719e-003	9.3414e-003
8.6960e-003	8.8485e-003
9.1515e-003	8.3893e-003
4.2426e-003	8.0535e-003
2.6406e-002	7.3518e-003
-8.6575e-002	8.6957e-003
4.7635e-001	0

Zobrazení čísel

Motivace:

$$\sum_{k=1}^{100000} \frac{1}{10} = 9998,55664$$

- Lidé používají desítkovou soustavu.
- Počítače dvojkovou.

Komunikace s počítačem

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

Soustavy

• desítková

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

obecně

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

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

značení

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

• dvojková

$$1563 = (1 \cdot 2^{10}) + (1 \cdot 2^9) + (0 \cdot 2^8) + (0 \cdot 2^7) + (0 \cdot 2^6) + (0 \cdot 2^5) + (1 \cdot 2^4) + (1 \cdot 2^3) + (0 \cdot 2^2) + (1 \cdot 2^1) + (1 \cdot 2^0)$$

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

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 pohyblivá 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.



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

Příklad:

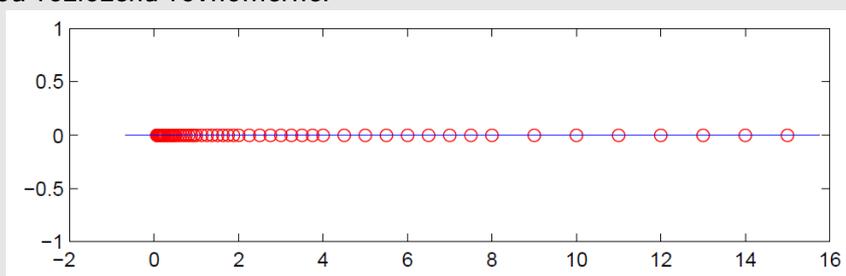
Sestrojte všechna strojová čísla s mantisou délky 4 a exponentem v rozsahu od -3 do 4, tj.

$$x = q \cdot 2^n, \quad \text{kde } q = 0, d_1 d_2 d_3 d_4, \quad n \in \{-3, -2, -1, 0, 1, 2, 3, 4\}$$

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

q \ 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)-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*l)-P(1))/20;
    hold on;
    plot([P(1)-pr,P(k*l)+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 sečtou čísla $\frac{1}{10}$ a $\frac{1}{5}$.

Výsledky získané z MATLABu



 Zobrazení součtu čísel A a B v zadané množině strojových čísel
 s mantisou délky 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	0.1101×2^{-3}	0.1015625
B = 0.200000	0.1101×2^{-2}	0.203125
obrazA+obrazB= 0.3046875	0.1010×2^{-1}	0.3125
A+B= 0.300000	0.1010×2^{-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 sečtou čísla $\frac{3}{10}$ a $\frac{1}{6}$.

Výsledky získané z MATLABu



 Zobrazení součtu čísel A a B v zadané množině strojových čísel
 s mantisou délky M a exponentem v rozsahu od Exp_min do Exp_max

Císlo A = 0.300000
 Císlo B = 0.166667
 Počet čísel mantisy M = 4
 Rozsah pro exponent: od -3 do 4

číslo	zápis obrazu	obraz
A = 0.300000	0.1010×2^{-1}	0.3125
B = 0.166667	0.1011×2^{-2}	0.171875
obrazA+obrazB= 0.484375	0.1000×2^0	0.5
A+B= 0.466667	0.1011×2^0	0.46875

Poznámka:

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

Chyba výpočtu:

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

Relativně:

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

Přesnost počítače

- Vymezíme-li pro mantisu 24 bitů, získáme 7 desetinných míst ($2^{24} = 16\,777\,216$).
- Vymezíme-li pro mantisu 32 bitů, získáme 9 desetinných míst ($2^{32} = 4\,294\,967\,296$).

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.

$$\frac{1}{10} = 0,0001\bar{1}_2 \approx 0,1100\,1100\,1100\,1100\,1100_2 \cdot 2^{-3}.$$

$$\text{Chyba zobrazení je } 0,1\bar{1}00_2 \cdot 2^{-27} (= \frac{1}{10} \cdot 2^{-24}) \approx 5,96 \cdot 10^{-9}.$$



- Máme-li počítat $\sum_{k=1}^{100000} \frac{1}{10}$, dostaneme ve formátu SINGLE 9.998, 55664.

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 suma 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 sečtete čísla 10000 a 0,1.

```
-----
Prevod cisla 10000 z 10-soustavy do 2-soustavy na 0 desetinnych mist
Cela cast ..... 10000
Desetinna 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         0

Cislo 10000 v 10-soustave prevedeno do 2-soustavy je 10011100010000.
```

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

$$(2^{14} = 16384)$$

$$10000 \dots 0,100111001000000000000000 \cdot 2^{14}$$

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

$$0,1 \text{ po SHIFTu} \dots 0,00000000000000001100110 \cdot 2^{14}$$

$$= (01100110)_2 \cdot 2^{-24} \cdot 2^{14} = (64 + 32 + 4 + 2) \cdot 2^{-10} =$$

$$= \frac{102}{1024} = 0,099609375$$

$$10000 + 0,1 \dots 0,10011100100000001100110 \cdot 2^{14}$$

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 motivačního příkladu jde o jeden krok)

skript v MATLABu

```
s=0;
h=single(1/10);

for i=1:100000
    s=s+h;
end;

s
```