

NI-MPI přednáška 7

Strojová čísla

Štěpán Starosta

4. 11. 2024

FIT ČVUT

10. Numerická matematika

- Co to je?
- Chyby podle jejich původu

11. Počítačová aritmetika

- Reprezentace s pohyblivou řádovou čárkou
- Aritmetické operace
- Závěr

10. Numerická matematika

- Co to je?
- Chyby podle jejich původu

11. Počítačová aritmetika

- Reprezentace s pohyblivou řádovou čárkou
- Aritmetické operace
- Závěr

Numerická matematika

Numerická matematika se věnuje matematickým metodám hledajícím přibližná řešení matematických úloh a jejich spolehlivosti.

Zahrnuje například metody pro...

1. řešení soustav lineárních rovnic,
2. řešení (obyčejných i parciálních) diferenciálních rovnic,
3. výpočet integrálů,
4. vyhodnocování funkčních hodnot,
5. odhadování chyb při výpočtech,
6. hledání lokálních a globálních extrémů (optimalizační úlohy),
7. výpočet vlastních čísel a vlastních vektorů,
8. faktorizace matic,
9. ...

Numerická matematika

Numerická matematika se věnuje matematickým metodám hledajícím přibližná řešení matematických úloh a jejich spolehlivosti.

Zahrnuje například metody pro...

1. řešení soustav lineárních rovnic,
2. řešení (obyčejných i parciálních) diferenciálních rovnic,
3. výpočet integrálů,
4. vyhodnocování funkčních hodnot,
5. odhadování chyb při výpočtech,
6. hledání lokálních a globálních extrémů (optimalizační úlohy),
7. výpočet vlastních čísel a vlastních vektorů,
8. faktorizace matic,
9. ...

Typicky k řešení úloh využívá počítačů.

Z dějin neúspěchu...

- Chyba v raketě Patriot

$$(0.1)_{10} = (0.000110011001100110011001100110011 \dots)_2$$



Z dějin neúspěchu...

- Chyba v raketě Patriot (28 mrtvých)

$$(0.1)_{10} = (0.000110011001100110011001100110011 \dots)_2$$



Z dějin neúspěchu...

- Chyba v raketě **Patriot** (28 mrtvých)

$$(0.1)_{10} = (0.000110011001100110011001100110011 \dots)_2$$

- Exploze rakety **Ariane 5** konverze z 64-bitového čísla s plovoucí čárkou na 16-bitové celé se znaménkem.



Z dějin neúspěchu...

- Chyba v raketě Patriot (28 mrtvých)

$$(0.1)_{10} = (0.000110011001100110011001100110011 \dots)_2$$

- Exploze rakety Ariane 5 konverze z 64-bitového čísla s plovoucí čárkou na 16-bitové celé se znaménkem. (\$7 miliard na vývoj, raketa a náklad za půl miliardy.)



Z dějin neúspěchu...

- Chyba v raketě Patriot (28 mrtvých)

$$(0.1)_{10} = (0.000110011001100110011001100110011 \dots)_2$$

- Exploze rakety Ariane 5 konverze z 64-bitového čísla s plovoucí čárkou na 16-bitové celé se znaménkem. (\$7 miliard na vývoj, raketa a náklad za půl miliardy.)



[<http://ta.twi.tudelft.nl/users/vuik/wi211/disasters.html>]

Z dějin neúspěchu...

- Chyba v raketě **Patriot** (28 mrtvých)

$$(0.1)_{10} = (0.000110011001100110011001100110011 \dots)_2$$

- Exploze rakety **Ariane 5** konverze z 64-bitového čísla s plovoucí čárkou na 16-bitové celé se znaménkem. (\$7 miliard na vývoj, raketa a náklad za půl miliardy.)



[<http://ta.twi.tudelft.nl/users/vuik/wi211/disasters.html>]

Neznamená to, že by metody nefungovaly: naopak v naprosté většině případů fungují dobře.

Kategorizace chyb

Při návrhu algoritmu pro hledání chyb budeme používat různé **aproximace**. Budeme se tedy dopouštět různých chyb, které lze rozdělit podle jejich původu:

- 1 chyba **modelu**: matematický model řešené úlohy je nějakým způsobem zjednodušený, např. je zanedbáno tření, nebo se používají průměrné místo aktuálních hodnot.
- 2 chyba **dat**: data často pocházejí z měření, která nemají absolutní přesnost (vesměs všechna měření fyzikálních veličin).
- 3 chyba **algoritmu**: nemusíme mít k dispozici algoritmus, který v konečném počtu kroků najde přesné řešení.
- 4 **zaokrouhlovací** chyba: při samotném výpočtu (v rámci algoritmu) dochází k chybám (např. při aritmetických operacích).

Začneme od zaokrouhlovacích chyb.

10. Numerická matematika

- Co to je?
- Chyby podle jejich původu

11. Počítačová aritmetika

- Reprezentace s pohyblivou řádovou čárkou
- Aritmetické operace
- Závěr

Reprezentace s pohyblivou řádovou čárkou

K ukládání čísel v počítači se většinou používá binární báze, například

$$(6)_{10} = (110)_2, \quad (0.1)_{10} = (0.00011001100110011001100110011001100110011...)_2.$$

¹Často též „mantisa“. Další čtení k této terminologii na Wikipedii.

Reprezentace s pohyblivou řádovou čárkou

K ukládání čísel v počítači se většinou používá binární báze, například

$$(6)_{10} = (110)_2, \quad (0.1)_{10} = (0.00011001100110011001100110011001100110011...)_2.$$

Pro necelá čísla x se používá tzv. **vědecký zápis čísel**, v binární bázi vypadá takto

$$x = \pm q \cdot 2^e,$$

kde

- q je **signifikant**¹ (*significand*) mající pevný počet cifer / pevnou délku, těmto cifrám se také říká **platné cifry**.
- e je **exponent** mající pevný počet cifer / pevnou délku.

¹Často též „mantisa“. [Další čtení k této terminologii na Wikipedii.](#)

Standard IEEE-754 (1985)

Strojové číslo lze reprezentovat znaménkem s a celými kladnými čísly e a m . Označme $(m_2)_2 = m$. Standard IEEE-754 klade na e a m následující podmínky a omezuje tak množinu reprezentovatelných reálných čísel:

Standard IEEE-754 (1985)

Strojové číslo lze reprezentovat znaménkem s a celými kladnými čísly e a m . Označme $(m_2)_2 = m$. Standard IEEE-754 klade na e a m následující podmínky a omezuje tak množinu reprezentovatelných reálných čísel:

přesnost	délka m	$d =$ délka e	parametr b
poloviční (binary16, <i>half precision</i>)	10	5	15
jednoduchá (binary32, <i>single precision</i>)	23	8	127
dvojitá (binary64, <i>double precision</i>)	52	11	1023
čtyřnásobná (binary128, <i>quadruple prec.</i>)	112	15	16383

Reprezentovaná hodnota x se pak určí následujícím způsobem:

- pokud $e = 2^d - 1$ a $m \neq 0$, tak $x = \text{NaN}$ (*Not a Number*)

Standard IEEE-754 (1985)

Strojové číslo lze reprezentovat znaménkem s a celými kladnými čísly e a m . Označme $(m_2)_2 = m$. Standard IEEE-754 klade na e a m následující podmínky a omezuje tak množinu reprezentovatelných reálných čísel:

přesnost	délka m	$d =$ délka e	parametr b
poloviční (binary16, <i>half precision</i>)	10	5	15
jednoduchá (binary32, <i>single precision</i>)	23	8	127
dvojitá (binary64, <i>double precision</i>)	52	11	1023
čtyřnásobná (binary128, <i>quadruple prec.</i>)	112	15	16383

Reprezentovaná hodnota x se pak určí následujícím způsobem:

- pokud $e = 2^d - 1$ a $m \neq 0$, tak $x = \text{NaN}$ (*Not a Number*)
- pokud $e = 2^d - 1$ a $m = 0$, tak $x = (-1)^s \cdot \text{Inf}$

Standard IEEE-754 (1985)

Strojové číslo lze reprezentovat znaménkem s a celými kladnými čísly e a m . Označme $(m_2)_2 = m$. Standard IEEE-754 klade na e a m následující podmínky a omezuje tak množinu reprezentovatelných reálných čísel:

přesnost	délka m	$d =$ délka e	parametr b
poloviční (binary16, <i>half precision</i>)	10	5	15
jednoduchá (binary32, <i>single precision</i>)	23	8	127
dvojitá (binary64, <i>double precision</i>)	52	11	1023
čtyřnásobná (binary128, <i>quadruple prec.</i>)	112	15	16383

Reprezentovaná hodnota x se pak určí následujícím způsobem:

- pokud $e = 2^d - 1$ a $m \neq 0$, tak $x = \text{NaN}$ (*Not a Number*)
- pokud $e = 2^d - 1$ a $m = 0$, tak $x = (-1)^s \cdot \text{Inf}$
- pokud $0 < e < 2^d - 1$, pak $x = (-1)^s \cdot (1.m_2)_2 \cdot 2^{e-b}$ (tzv. **normalizovaná čísla**)

Standard IEEE-754 (1985)

Strojové číslo lze reprezentovat znaménkem s a celými kladnými čísly e a m . Označme $(m_2)_2 = m$. Standard IEEE-754 klade na e a m následující podmínky a omezuje tak množinu reprezentovatelných reálných čísel:

přesnost	délka m	$d =$ délka e	parametr b
poloviční (binary16, <i>half precision</i>)	10	5	15
jednoduchá (binary32, <i>single precision</i>)	23	8	127
dvojitá (binary64, <i>double precision</i>)	52	11	1023
čtyřnásobná (binary128, <i>quadruple prec.</i>)	112	15	16383

Reprezentovaná hodnota x se pak určí následujícím způsobem:

- pokud $e = 2^d - 1$ a $m \neq 0$, tak $x = \text{NaN}$ (*Not a Number*)
- pokud $e = 2^d - 1$ a $m = 0$, tak $x = (-1)^s \cdot \text{Inf}$
- pokud $0 < e < 2^d - 1$, pak $x = (-1)^s \cdot (1.m_2)_2 \cdot 2^{e-b}$ (tzv. **normalizovaná čísla**)
- pokud $e = 0$ a $m \neq 0$, pak $x = (-1)^s \cdot (0.m_2)_2 \cdot 2^{1-b}$ (tzv. **subnormální čísla**)

Standard IEEE-754 (1985)

Strojové číslo lze reprezentovat znaménkem s a celými kladnými čísly e a m . Označme $(m_2)_2 = m$. Standard IEEE-754 klade na e a m následující podmínky a omezuje tak množinu reprezentovatelných reálných čísel:

přesnost	délka m	$d =$ délka e	parametr b
poloviční (binary16, <i>half precision</i>)	10	5	15
jednoduchá (binary32, <i>single precision</i>)	23	8	127
dvojitá (binary64, <i>double precision</i>)	52	11	1023
čtyřnásobná (binary128, <i>quadruple prec.</i>)	112	15	16383

Reprezentovaná hodnota x se pak určí následujícím způsobem:

- pokud $e = 2^d - 1$ a $m \neq 0$, tak $x = \text{NaN}$ (*Not a Number*)
- pokud $e = 2^d - 1$ a $m = 0$, tak $x = (-1)^s \cdot \text{Inf}$
- pokud $0 < e < 2^d - 1$, pak $x = (-1)^s \cdot (1.m_2)_2 \cdot 2^{e-b}$ (tzv. **normalizovaná čísla**)
- pokud $e = 0$ a $m \neq 0$, pak $x = (-1)^s \cdot (0.m_2)_2 \cdot 2^{1-b}$ (tzv. **subnormální čísla**)
- pokud $e = 0$ a $m = 0$, pak $x = (-1)^s \cdot 0$

Všimněme si, že pro normalizované číslo $x = (-1)^s \cdot (1.m_2)_2 \cdot 2^{e-b}$ jsme vlastně uložili o 1 platnou cifru více, než kolik je délka m . (Tedy např. v jednoduché přesnosti uložíme 24 platných cifer.)

Této konvenci se říká různě: skrytá jednička, skrytý bit, vedoucí bit, implicitní bit.

Strojová čísla (1/3)

Reálná čísla, která lze reprezentovat popsaným způsobem, se nazývají **strojová čísla**.

Příklad: Vezměme dvoubitové m , exponent e s třemi bity (tj. $d = 3$) a $b = 3$.

Dostaneme následující množinu strojových čísel (vypisujeme jen nezáporná):

$$\left\{ 0, \frac{1}{16}, \frac{1}{8}, \frac{3}{16}, \frac{1}{4}, \frac{5}{16}, \frac{3}{8}, \frac{7}{16}, \frac{1}{2}, \frac{5}{8}, \frac{3}{4}, \frac{7}{8}, 1, \frac{5}{4}, \frac{3}{2}, \frac{7}{4}, 2, \frac{5}{2}, 3, \frac{7}{2}, 4, 5, 6, 7, 8, 10, 12, 14 \right\}$$

Subnormální strojová čísla jsou zvýrazněna **zeleně**.



Strojová čísla (1/3)

Reálná čísla, která lze reprezentovat popsaným způsobem, se nazývají **strojová čísla**.

Příklad: Vezměme dvoubitové m , exponent e s třemi bity (tj. $d = 3$) a $b = 3$.

Dostaneme následující množinu strojových čísel (vypisujeme jen nezáporná):

$$\left\{ 0, \frac{1}{16}, \frac{1}{8}, \frac{3}{16}, \frac{1}{4}, \frac{5}{16}, \frac{3}{8}, \frac{7}{16}, \frac{1}{2}, \frac{5}{8}, \frac{3}{4}, \frac{7}{8}, 1, \frac{5}{4}, \frac{3}{2}, \frac{7}{4}, 2, \frac{5}{2}, 3, \frac{7}{2}, 4, 5, 6, 7, 8, 10, 12, 14 \right\}$$

Subnormální strojová čísla jsou zvýrazněna **zeleně**.



Množina všech strojových čísel s danou přesností (tj. specifikací m , e a b) nemá nic moc společného s reálnými čísly. Jde o konečnou podmnožinu racionálních čísel.

Strojová čísla (2/3)

Označme množinu strojových čísel symbolem $F \equiv F(|m|, |e|, b)$.

Strojová čísla (2/3)

Označme množinu strojových čísel symbolem $F \equiv F(|m|, |e|, b)$.

Množina F , jakožto konečná podmnožina \mathbb{R} má samozřejmě největší a nejmenší prvek ($\min F$ a $\max F$). Dále jsou zajímavé následující hodnoty:

přesnost	max. č.	min. kladné norm. č.	min. kladné subnorm. č.
single	$(2 - 2^{-23})2^{127}$ $\approx 3.4 \cdot 10^{38}$	2^{-126} $\approx 1.2 \cdot 10^{-38}$	$2^{-126-23} = 2^{-149}$ $\approx 1.4 \cdot 10^{-45}$
double	$(2 - 2^{-52})2^{1023}$ $\approx 1.8 \cdot 10^{308}$	2^{-1022} $\approx 2.2 \cdot 10^{-308}$	$2^{-1022-52} = 2^{-1074}$ $\approx 4.9 \cdot 10^{-324}$

Strojová čísla (2/3)

Označme množinu strojových čísel symbolem $F \equiv F(|m|, |e|, b)$.

Množina F , jakožto konečná podmnožina \mathbb{R} má samozřejmě největší a nejmenší prvek ($\min F$ a $\max F$). Dále jsou zajímavé následující hodnoty:

přesnost	max. č.	min. kladné norm. č.	min. kladné subnorm. č.
single	$(2 - 2^{-23})2^{127}$ $\approx 3.4 \cdot 10^{38}$	2^{-126} $\approx 1.2 \cdot 10^{-38}$	$2^{-126-23} = 2^{-149}$ $\approx 1.4 \cdot 10^{-45}$
double	$(2 - 2^{-52})2^{1023}$ $\approx 1.8 \cdot 10^{308}$	2^{-1022} $\approx 2.2 \cdot 10^{-308}$	$2^{-1022-52} = 2^{-1074}$ $\approx 4.9 \cdot 10^{-324}$

Skutečně, pro **jednoduchou** přesnost máme pro m 23 bitů, e 8 bitů a $b = 127$. Proto

$$\max F = (1.1 \dots 1)_2 \cdot 2^{254-127} = \frac{1 - (1/2)^{24}}{1 - 1/2} \cdot 2^{127} = (2 - 2^{-23}) \cdot 2^{127}$$

$$\text{minimální kladné normalizované} = (1.0 \dots 0)_2 \cdot 2^{1-127} = 2^{-126},$$

$$\text{minimální kladné subnormální} = (0.0 \dots 1)_2 \cdot 2^{1-127} = 2^{-23-126} = 2^{-149}.$$

Strojová čísla (3/3)

F je charakterizováno pomocí **strojové přesnosti** ε_F (*machine epsilon*), což je vzdálenost čísla $1 = +1 \cdot 2^0$ od nejbližšího většího čísla v F , tj.

$$\varepsilon_F = (1.0 \dots 01)_2 \cdot 2^0 - (1.0 \dots 00)_2 \cdot 2^0.$$

Strojová čísla (3/3)

F je charakterizováno pomocí **strojové přesnosti** ε_F (*machine epsilon*), což je vzdálenost čísla $1 = +1 \cdot 2^0$ od nejbližšího většího čísla v F , tj.

$$\varepsilon_F = (1.0 \dots 01)_2 \cdot 2^0 - (1.0 \dots 00)_2 \cdot 2^0.$$

Pro jednoduchou přesnost proto platí $\varepsilon_F = 2^{-23}$ a pro dvojitou $\varepsilon_F = 2^{-52}$.

Strojová čísla (3/3)

F je charakterizováno pomocí **strojové přesnosti** ε_F (*machine epsilon*), což je vzdálenost čísla $1 = +1 \cdot 2^0$ od nejbližšího většího čísla v F , tj.

$$\varepsilon_F = (1.0 \dots 01)_2 \cdot 2^0 - (1.0 \dots 00)_2 \cdot 2^0.$$

Pro jednoduchou přesnost proto platí $\varepsilon_F = 2^{-23}$ a pro dvojitou $\varepsilon_F = 2^{-52}$.

Tvrzení 12.1

Vzdálenost libovolného normalizovaného čísla $x \in F$ od jeho nejbližších sousedů z F je nejméně $\varepsilon_F \frac{|x|}{2}$ a nejvíce $\varepsilon_F |x|$.

Reprezentace reálných čísel (1/3)

Nechť $f_l : \mathbb{R} \rightarrow F$ je zobrazení, které přiřadí každému $x \in \mathbb{R}$ „nejbližší“ strojové číslo. (Zkratka f_l je od slova „float“.)

„Nejbližší“ je určeno podle vybrané strategie zaokrouhlování (k nejbližšímu, k \pm nekonečnu, náhodně)² či usekávání (zaokrouhlování směrem k nule)³.

²Round to nearest, ties to even; Round to nearest, ties away from zero; Round towards +infinity; Round towards -infinity;

Reprezentace reálných čísel (1/3)

Nechť $f_l : \mathbb{R} \rightarrow F$ je zobrazení, které přiřadí každému $x \in \mathbb{R}$ „nejbližší“ strojové číslo. (Zkratka f_l je od slova „float“.)

„Nejbližší“ je určeno podle vybrané strategie zaokrouhlování (k nejbližšímu, k \pm nekonečnu, náhodně)² či usekávání (zaokrouhlování směrem k nule)³.

Při pokusu o reprezentaci čísel mimo rozsah dochází k **přetečení** (*overflow*) respektive **podtečení** (*underflow*).

²Round to nearest, ties to even; Round to nearest, ties away from zero; Round towards +infinity; Round towards -infinity;

Reprezentace reálných čísel (1/3)

Nechť $fl : \mathbb{R} \rightarrow F$ je zobrazení, které přiřadí každému $x \in \mathbb{R}$ „nejbližší“ strojové číslo. (Zkratka fl je od slova „float“.)

„Nejbližší“ je určeno podle vybrané strategie zaokrouhlování (k nejbližšímu, k \pm nekonečnu, náhodně)² či usekávání (zaokrouhlování směrem k nule)³.

Při pokusu o reprezentaci čísel mimo rozsah dochází k **přetečení** (*overflow*) respektive **podtečení** (*underflow*).

Definice 12.2

Nechť číslo $\alpha \in F$ je přibližnou hodnotou čísla $a \in \mathbb{R}$.

- **Absolutní chyba** reprezentace a pomocí α rozumíme hodnotu $|\alpha - a|$.
- Pro $a \neq 0$ je **relativní chyba** reprezentace a pomocí α rovna

$$\frac{|\alpha - a|}{|a|}.$$

²Round to nearest, ties to even; Round to nearest, ties away from zero; Round towards +infinity; Round towards -infinity;

Reprezentace reálných čísel (2/3)

Uvažujme reálné číslo x takové, že lze psát

$$x = q \cdot 2^\ell, \quad \text{kde } 1 \leq q < 2 \text{ a } -126 \leq \ell \leq 126.$$

Hrubě řečeno, x je v rozsahu normalizovaných čísel v jednoduché přesnosti.

Reprezentace reálných čísel (2/3)

Uvažujme reálné číslo x takové, že lze psát

$$x = q \cdot 2^\ell, \quad \text{kde } 1 \leq q < 2 \text{ a } -126 \leq \ell \leq 126.$$

Hrubě řečeno, x je v rozsahu normalizovaných čísel v jednoduché přesnosti.

Jaká je **chyba** vzniknuvší při zaokrouhlení na nejbližší strojové číslo?

Reprezentace reálných čísel (2/3)

Uvažujme reálné číslo x takové, že lze psát

$$x = q \cdot 2^\ell, \quad \text{kde } 1 \leq q < 2 \text{ a } -126 \leq \ell \leq 126.$$

Hrubě řečeno, x je v rozsahu normalizovaných čísel v jednoduché přesnosti.

Jaká je **chyba** vzniknuvší při zaokrouhlení na nejbližší strojové číslo?

Pro jednoduchost budeme *zaokrouhlovat směrem k nule*, tedy usekneme bity přesahující délku signifikandu (x je kladné). Nechť

$$x = (1.m_1m_2m_3m_4\dots)_2 \cdot 2^\ell,$$

pak

$$\text{fl}(x) = (1.m_1m_2\dots m_{23})_2 \cdot 2^\ell,$$

Reprezentace reálných čísel (2/3)

Uvažujme reálné číslo x takové, že lze psát

$$x = q \cdot 2^\ell, \quad \text{kde } 1 \leq q < 2 \text{ a } -126 \leq \ell \leq 126.$$

Hrubě řečeno, x je v rozsahu normalizovaných čísel v jednoduché přesnosti.

Jaká je **chyba** vznikuvší při zaokrouhlení na nejbližší strojové číslo?

Pro jednoduchost budeme *zaokrouhlovat směrem k nule*, tedy usekneme bity přesahující délku signifikandu (x je kladné). Nechť

$$x = (1.m_1m_2m_3m_4\dots)_2 \cdot 2^\ell,$$

pak

$$\text{fl}(x) = (1.m_1m_2\dots m_{23})_2 \cdot 2^\ell,$$

Pro absolutní chybu platí $|x - \text{fl}(x)| \leq 2^{-23+\ell}$ a pro relativní chybu

$$\frac{|x - \text{fl}(x)|}{|x|} \leq \frac{2^{-23+\ell}}{q \cdot 2^\ell} \leq 2^{-23}.$$

Reprezentace reálných čísel (3/3)

Této mezi pro relativní chybu se říká **zaokrouhlovací jednotka** (*unit roundoff error*) a značí se $\mathbf{u} = 2^{-23}$.

⁴nezáleží, jak si poradíme s nerozhodnutelnými právě mezi 2 nejbližšími

Reprezentace reálných čísel (3/3)

Této mezi pro relativní chybu se říká **zaokrouhlovací jednotka** (*unit roundoff error*) a značí se $\mathbf{u} = 2^{-23}$.

Pokud bychom použili *zaokrouhlování směrem k nejbližšímu*⁴, dostaneme $\mathbf{u} = 2^{-24}$.

⁴nezáleží, jak si poradíme s nerozhodnutelnými právě mezi 2 nejbližšími

Reprezentace reálných čísel (3/3)

Této mezi pro relativní chybu se říká **zaokrouhlovací jednotka** (*unit roundoff error*) a značí se $\mathbf{u} = 2^{-23}$.

Pokud bychom použili *zaokrouhlování směrem k nejbližšímu*⁴, dostaneme $\mathbf{u} = 2^{-24}$.

Tvrzení 12.3

Nechť $x \in \mathbb{R}$ leží mezi největším a nejmenším normalizovaným kladným číslem množiny F . Pak platí

$$\text{fl}(x) = x(1 + \delta), \quad \text{kde } |\delta| \leq \mathbf{u}.$$

⁴nezáleží, jak si poradíme s nerozhodnutelnými právě mezi 2 nejbližšími

Reprezentace reálných čísel (3/3)

Této mezi pro relativní chybu se říká **zaokrouhlovací jednotka** (*unit roundoff error*) a značí se $\mathbf{u} = 2^{-23}$.

Pokud bychom použili *zaokrouhlování směrem k nejbližšímu*⁴, dostaneme $\mathbf{u} = 2^{-24}$.

Tvrzení 12.3

Nechť $x \in \mathbb{R}$ leží mezi největším a nejmenším normalizovaným kladným číslem množiny F . Pak platí

$$\text{fl}(x) = x(1 + \delta), \quad \text{kde } |\delta| \leq \mathbf{u}.$$

Poznámka: δ zde závisí na x , tj. $\delta = \delta(x)$. Například pro strojové číslo x je $\delta = 0$.

⁴nezáleží, jak si poradíme s nerozhodnutelnými právě mezi 2 nejbližšími

Aritmetické operace a chyba při jejich provádění

Se strojovými čísly můžeme provádět obvyklé základní číselné operace, např.: $+ : (x, y) \mapsto \text{fl}(x + y)$.

Aritmetické operace a chyba při jejich provádění

Se strojovými čísly můžeme provádět obvyklé základní číselné operace, např.: $+$: $(x, y) \mapsto \text{fl}(x + y)$.

Z předchozího tvrzení o zaokrouhlování ihned plyne:

Tvrzení 12.4

Nechť $x, y \in F$ a \odot značí operaci sčítání, odečítání, násobení nebo dělení. Pokud nedojde k přetečení nebo podtečení (zůstali jsme v intervalu normalizovaných čísel), tak platí

$$\text{fl}(x \odot y) = (x \odot y)(1 + \delta), \quad \text{kde } |\delta| \leq \mathbf{u}.$$

Aritmetické operace a chyba při jejich provádění

Se strojovými čísly můžeme provádět obvyklé základní číselné operace, např.: $+$: $(x, y) \mapsto \text{fl}(x + y)$.

Z předchozího tvrzení o zaokrouhlování ihned plyne:

Tvrzení 12.4

Nechť $x, y \in F$ a \odot značí operaci sčítání, odečítání, násobení nebo dělení. Pokud nedojde k přetečení nebo podtečení (zůstali jsme v intervalu normalizovaných čísel), tak platí

$$\text{fl}(x \odot y) = (x \odot y)(1 + \delta), \quad \text{kde } |\delta| \leq \mathbf{u}.$$

- Uvědomme si, že sčítáním/odečítáním/násobením/dělením dvou strojových čísel nemusíme nutně dostat opět strojové číslo! Obecně jde o reálné číslo, které je potřeba zaokrouhlit. (Tedy nemusí platit $\delta = 0$.)

Aritmetické operace a chyba při jejich provádění

Se strojovými čísly můžeme provádět obvyklé základní číselné operace, např.: $+$: $(x, y) \mapsto \text{fl}(x + y)$.

Z předchozího tvrzení o zaokrouhlování ihned plyne:

Tvrzení 12.4

Nechť $x, y \in F$ a \odot značí operaci sčítání, odečítání, násobení nebo dělení. Pokud nedojde k přetečení nebo podtečení (zůstali jsme v intervalu normalizovaných čísel), tak platí

$$\text{fl}(x \odot y) = (x \odot y)(1 + \delta), \quad \text{kde } |\delta| \leq \mathbf{u}.$$

- Uvědomme si, že sčítáním/odečítáním/násobením/dělením dvou strojových čísel nemusíme nutně dostat opět strojové číslo! Obecně jde o reálné číslo, které je potřeba zaokrouhlit. (Tedy nemusí platit $\delta = 0$.)
- Model je příliš jednoduchý pro dnešní procesory, některé např. umí FMA: Fused Multiply Add, které počítá $(x, y, z) \mapsto x \pm yz$ s jedním zaokrouhlením.

Mějme funkci $f : \mathbb{R}^2 \rightarrow \mathbb{R}$ definovanou takto:

$$f(x, y) = 333.75y^6 + x^2 (11x^2y^2 - y^6 - 121y^4 - 2) + 5.5y^8 + \frac{x}{2y}.$$

Mějme funkci $f : \mathbb{R}^2 \rightarrow \mathbb{R}$ definovanou takto:

$$f(x, y) = 333.75y^6 + x^2 (11x^2y^2 - y^6 - 121y^4 - 2) + 5.5y^8 + \frac{x}{2y}.$$

Vyhodnotíme $f(77617, 33096)$ v různých přesnostech

Aritmetické operace – katastrofická ukázka 2/2

<i>přesnost</i>	$f(77617, 33096)$
-----------------	-------------------

Aritmetické operace – katastrofická ukázka 2/2

<i>přesnost</i>	$f(77617, 33096)$
SageMath (přesnost 23 bitů)	1.17260

Aritmetické operace – katastrofická ukázka 2/2

<i>přesnost</i>	$f(77617, 33096)$
SageMath (přesnost 23 bitů)	1.17260
SageMath (přesnost 24 bitů)	$-6.33825 \cdot 10^{-29}$

Aritmetické operace – katastrofická ukázka 2/2

<i>přesnost</i>	$f(77617, 33096)$
SageMath (přesnost 23 bitů)	1.17260
SageMath (přesnost 24 bitů)	$-6.33825 \cdot 10^{-29}$
SageMath (přesnost 53 bitů)	$-1.18059162071741 \cdot 10^{21}$

Aritmetické operace – katastrofická ukázka 2/2

<i>přesnost</i>	$f(77617, 33096)$
SageMath (přesnost 23 bitů)	1.17260
SageMath (přesnost 24 bitů)	$-6.33825 \cdot 10^{-29}$
SageMath (přesnost 53 bitů)	$-1.18059162071741 \cdot 10^{21}$
SageMath (přesnost 54 bitů)	$1.18059162071741 \cdot 10^{21}$

Aritmetické operace – katastrofická ukázka 2/2

<i>přesnost</i>	$f(77617, 33096)$
SageMath (přesnost 23 bitů)	1.17260
SageMath (přesnost 24 bitů)	$-6.33825 \cdot 10^{-29}$
SageMath (přesnost 53 bitů)	$-1.18059162071741 \cdot 10^{21}$
SageMath (přesnost 54 bitů)	$1.18059162071741 \cdot 10^{21}$
SageMath (přesnost 100 bitů)	1.1726039400531786318588349045

Aritmetické operace – katastrofická ukázka 2/2

<i>přesnost</i>	$f(77617, 33096)$
SageMath (přesnost 23 bitů)	1.17260
SageMath (přesnost 24 bitů)	$-6.33825 \cdot 10^{-29}$
SageMath (přesnost 53 bitů)	$-1.18059162071741 \cdot 10^{21}$
SageMath (přesnost 54 bitů)	$1.18059162071741 \cdot 10^{21}$
SageMath (přesnost 100 bitů)	1.1726039400531786318588349045
SageMath (přesnost 121 bitů)	1.17260394005317863185883490452018371

Aritmetické operace – katastrofická ukázka 2/2

<i>přesnost</i>	$f(77617, 33096)$
SageMath (přesnost 23 bitů)	1.17260
SageMath (přesnost 24 bitů)	$-6.33825 \cdot 10^{-29}$
SageMath (přesnost 53 bitů)	$-1.18059162071741 \cdot 10^{21}$
SageMath (přesnost 54 bitů)	$1.18059162071741 \cdot 10^{21}$
SageMath (přesnost 100 bitů)	1.1726039400531786318588349045
SageMath (přesnost 121 bitů)	1.17260394005317863185883490452018371
SageMath (přesnost 122 bitů)	$-0.827396059946821368141165095479816292$

Aritmetické operace – katastrofická ukázka 2/2

<i>přesnost</i>	$f(77617, 33096)$
SageMath (přesnost 23 bitů)	1.17260
SageMath (přesnost 24 bitů)	$-6.33825 \cdot 10^{-29}$
SageMath (přesnost 53 bitů)	$-1.18059162071741 \cdot 10^{21}$
SageMath (přesnost 54 bitů)	$1.18059162071741 \cdot 10^{21}$
SageMath (přesnost 100 bitů)	1.1726039400531786318588349045
SageMath (přesnost 121 bitů)	1.17260394005317863185883490452018371
SageMath (přesnost 122 bitů)	-0.827396059946821368141165095479816292

Přesný výsledek je $f(77617, 33096) = -\frac{54767}{66192} \approx -0.827396$.

[S. M. Rump: *Algorithms for verified inclusions – theory and practice*, 1988]

Ztráta platných cifer (1/3)

Došlo ke kumulaci chyb při provádění aritmetických operací.

Ztráta platných cifer (1/3)

Došlo ke kumulaci chyb při provádění aritmetických operací.

Velké problémy může způsobit tzv. **krácení** (*cancellation*), které ovšem na první pohled nemusí být patrné.

Ztráta platných cifer (1/3)

Došlo ke kumulaci chyb při provádění aritmetických operací.

Velké problémy může způsobit tzv. **krácení** (*cancellation*), které ovšem na první pohled nemusí být patrné.

Předvedeme si jej na ilustrativním příkladě. Představme si, že počítač počítá v desítkové soustavě a zaokrouhluje na 10 platných cifer.

Chceme vyhodnotit výraz $x - \sin(x)$ pro $x = \frac{1}{15}$.

Ztráta platných cifer (1/3)

Došlo ke kumulaci chyb při provádění aritmetických operací.

Velké problémy může způsobit tzv. **krácení** (*cancellation*), které ovšem na první pohled nemusí být patrné.

Předvedeme si jej na ilustrativním příkladě. Představme si, že počítač počítá v desítkové soustavě a zaokrouhluje na 10 platných cifer.

Chceme vyhodnotit výraz $x - \sin(x)$ pro $x = \frac{1}{15}$.

$$x \leftarrow 6.6666\ 66667 \cdot 10^{-2}$$

Ztráta platných cifer (1/3)

Došlo ke kumulaci chyb při provádění aritmetických operací.

Velké problémy může způsobit tzv. **krácení** (*cancellation*), které ovšem na první pohled nemusí být patrné.

Předvedeme si jej na ilustrativním příkladě. Představme si, že počítač počítá v desítkové soustavě a zaokrouhluje na 10 platných cifer.

Chceme vyhodnotit výraz $x - \sin(x)$ pro $x = \frac{1}{15}$.

$$\begin{aligned}x &\leftarrow 6.6666\ 66667 \cdot 10^{-2} \\ \sin(x) &\leftarrow 6.6617\ 29492 \cdot 10^{-2}\end{aligned}$$

Ztráta platných cifer (1/3)

Došlo ke kumulaci chyb při provádění aritmetických operací.

Velké problémy může způsobit tzv. **krácení** (*cancellation*), které ovšem na první pohled nemusí být patrné.

Předvedeme si jej na ilustrativním příkladě. Představme si, že počítač počítá v desítkové soustavě a zaokrouhluje na 10 platných cifer.

Chceme vyhodnotit výraz $x - \sin(x)$ pro $x = \frac{1}{15}$.

$$\begin{aligned}x &\leftarrow 6.6666\ 66667 \cdot 10^{-2} \\ \sin(x) &\leftarrow 6.6617\ 29492 \cdot 10^{-2} \\ x - \sin(x) &\leftarrow 0.0049\ 37175 \cdot 10^{-2}\end{aligned}$$

Ztráta platných cifer (1/3)

Došlo ke kumulaci chyb při provádění aritmetických operací.

Velké problémy může způsobit tzv. **krácení** (*cancellation*), které ovšem na první pohled nemusí být patrné.

Předvedeme si jej na ilustrativním příkladě. Představme si, že počítač počítá v desítkové soustavě a zaokrouhluje na 10 platných cifer.

Chceme vyhodnotit výraz $x - \sin(x)$ pro $x = \frac{1}{15}$.

$$\begin{aligned}x &\leftarrow 6.6666\ 66667 \cdot 10^{-2} \\ \sin(x) &\leftarrow 6.6617\ 29492 \cdot 10^{-2} \\ x - \sin(x) &\leftarrow 0.0049\ 37175 \cdot 10^{-2} \\ x - \sin(x) &\leftarrow 4.9371\ 75000 \cdot 10^{-5}\end{aligned}$$

Ztráta platných cifer (1/3)

Došlo ke kumulaci chyb při provádění aritmetických operací.

Velké problémy může způsobit tzv. **krácení** (*cancellation*), které ovšem na první pohled nemusí být patrné.

Předvedeme si jej na ilustrativním příkladě. Představme si, že počítač počítá v desítkové soustavě a zaokrouhluje na 10 platných cifer.

Chceme vyhodnotit výraz $x - \sin(x)$ pro $x = \frac{1}{15}$.

$$\begin{aligned}x &\leftarrow 6.6666\ 66667 \cdot 10^{-2} \\ \sin(x) &\leftarrow 6.6617\ 29492 \cdot 10^{-2} \\ x - \sin(x) &\leftarrow 0.0049\ 37175 \cdot 10^{-2} \\ x - \sin(x) &\leftarrow 4.9371\ 75000 \cdot 10^{-5}\end{aligned}$$

Poslední **3 nuly** nejsou *správné* platné cifry. Během výpočtu jsme o ně přišli.

Ztráta platných cifer (1/3)

Došlo ke kumulaci chyb při provádění aritmetických operací.

Velké problémy může způsobit tzv. **krácení** (*cancellation*), které ovšem na první pohled nemusí být patrné.

Předvedeme si jej na ilustrativním příkladě. Představme si, že počítač počítá v desítkové soustavě a zaokrouhluje na 10 platných cifer.

Chceme vyhodnotit výraz $x - \sin(x)$ pro $x = \frac{1}{15}$.

$$\begin{aligned}x &\leftarrow 6.6666\ 66667 \cdot 10^{-2} \\ \sin(x) &\leftarrow 6.6617\ 29492 \cdot 10^{-2} \\ x - \sin(x) &\leftarrow 0.0049\ 37175 \cdot 10^{-2} \\ x - \sin(x) &\leftarrow 4.9371\ 75000 \cdot 10^{-5}\end{aligned}$$

Poslední **3 nuly** nejsou *správné* platné cifry. Během výpočtu jsme o ně přišli.

Spočítejme relativní chybu našeho výpočtu...

Ztráta platných cifer (2/3)

Relativní chyba výpočtu je

$$\frac{\left| \frac{1}{15} - \sin\left(\frac{1}{15}\right) - \text{fl}\left(\text{fl}\left(\frac{1}{15}\right) - \sin\left(\text{fl}\left(\frac{1}{15}\right)\right)\right)\right|}{\left| \frac{1}{15} - \sin\left(\frac{1}{15}\right) \right|} \approx 1.4 \cdot 10^{-7}.$$

Ztráta platných cifer (2/3)

Relativní chyba výpočtu je

$$\frac{\left| \frac{1}{15} - \sin\left(\frac{1}{15}\right) - \text{fl}\left(\text{fl}\left(\frac{1}{15}\right) - \sin\left(\text{fl}\left(\frac{1}{15}\right)\right)\right) \right|}{\left| \frac{1}{15} - \sin\left(\frac{1}{15}\right) \right|} \approx 1.4 \cdot 10^{-7}.$$

To je hodně v porovnání se zaokrouhlovací jednotkou v této aritmetice

$$\frac{|x - \text{fl}(x)|}{|x|} \leq 5 \cdot 10^{-10} = \mathbf{u},$$

kde x je v rozsahu normalizovaných čísel.

Ztráta platných cifer (2/3)

Relativní chyba výpočtu je

$$\frac{\left| \frac{1}{15} - \sin\left(\frac{1}{15}\right) - \text{fl}\left(\text{fl}\left(\frac{1}{15}\right) - \sin\left(\text{fl}\left(\frac{1}{15}\right)\right)\right)\right|}{\left| \frac{1}{15} - \sin\left(\frac{1}{15}\right) \right|} \approx 1.4 \cdot 10^{-7}.$$

To je hodně v porovnání se zaokrouhlovací jednotkou v této aritmetice

$$\frac{|x - \text{fl}(x)|}{|x|} \leq 5 \cdot 10^{-10} = \mathbf{u},$$

kde x je v rozsahu normalizovaných čísel.

Tvrzení 12.5

Nechť x a y jsou normalizovaná strojová čísla a platí $x > y > 0$. Pokud $2^{-p} \leq 1 - \frac{y}{x} \leq 2^{-q}$ pro nějaká kladná celá p a q , tak platí, že nejvíce p a nejméně q platných binárních bitů je ztraceno při provedení odečítání $x - y$.

Ztráta platných cifer (3/3)

Krácení se lze vyhnout několika technikami:

- přeformulováním problému tak, aby nedocházelo k odečítání,
- použitím rozvoju funkcí do řad (např. do Taylorovy řady),
- použitím jiných rovností ...
- (použitím přesné aritmetiky)

Základní potíže při práci s čísly s plovoucí čárkou I

Základní potíže při práci s čísly s plovoucí čárkou II

Implementace funkce sinus v libm

Zaokrouhlovací chyby – shrnutí

Původ zaokrouhlovacích chyb:

- zaokrouhlovací chyby jednotlivých operací a jejich kumulace,
- krácení.

Zaokrouhlovací chyby – shrnutí

Původ zaokrouhlovacích chyb:

- zaokrouhlovací chyby jednotlivých operací a jejich kumulace,
- krácení.

Několik poznámek k zaokrouhlovacím chybám:

- zvýšení přesnosti nemusí dát přesnější výsledek,
- krácení může být někdy výhodné – lze tak vyrušit zaokrouhlovací či jiné chyby,
- málo operací s malými čísly neznamena, že chyba bude malá.

Zaokrouhlovací chyby – shrnutí

Původ zaokrouhlovacích chyb:

- zaokrouhlovací chyby jednotlivých operací a jejich kumulace,
- krácení.

Několik poznámek k zaokrouhlovacím chybám:

- zvýšení přesnosti nemusí dát přesnější výsledek,
- krácení může být někdy výhodné – lze tak vyrušit zaokrouhlovací či jiné chyby,
- málo operací s malými čísly neznamena, že chyba bude malá.

Nebereme v úvahu hardware (např x87 vs SSE2, FMA...).

Zaokrouhlovací chyby – alternativní přístupy

Jeden z **problémů** strojových čísel (IEEE-754 apod.) spočívá v ignoraci vznikuvší chyby při výpočtu.

Možné alternativy (stručně):

Zaokrouhlovací chyby – alternativní přístupy

Jeden z **problémů** strojových čísel (IEEE-754 apod.) spočívá v ignoraci vznikuvší chyby při výpočtu.

Možné alternativy (stručně):

- Použít exaktní aritmetiku \mathbb{Z} , \mathbb{Q} či $GF(p)$ (není vždy možné a vhodné).
- **Intervalová aritmetika** (místo jednoho strojového čísla pracujeme s dvěma reprezentujícími krajní body intervalu, jehož délka představuje neurčitost ve znalosti příslušného „čísla“). (IEEE 1788–2015)
- **Unum**.
- ...