

FPA (Floating Point Arithmetics) **(aritmetika pohyblivej rádovej čiarky)**

Zobrazenie racionálnych čísel – principiálne stačí pracovať s **pevnou rádovou čiarkou (Fixed Point Arithmetic)** (v n-tici bitov stačí zvolit' polohu desatinnej čiarky)

$$3.625_{10} = 11.101 \quad 0011.1010$$

$$6.5_{10} = 110.1 \quad 0110.1000$$

Napríklad súčet je možné formálne realizovať ako pri celých číslach

$$\begin{array}{r} 00111010 \\ + 01101000 \\ \hline 10100010 \end{array} \quad 1010.0010_2 = 10.0125_{10}$$

Nevýhody pevnej rádovej čiarky (malý rozsah zobraziteľných čísel) (napr. pre „súčasné“ zobrazenie hmotnosti slnka a atómu by sme potrebovali 201 bitov (26 bytov)).

Pohyblivá rádová čiarka

$1234.56 = 0.123456 * 10^4$ - zápis čísla v pohyblivej rádovej čiarky (vedecká anotácia)

podobne pre binárne čísla

$11001100.0011011 = 0.110011000011011 * 2^{01000}$

Obidva zápisy sa dajú vyjadriť v tvare

$$N = M * z^E \quad |M| \leq 1 \quad z \in Z$$

M – mantisa (argument), E – exponent (characteristic),
základ (radix)

Na zobrazenie má vplyv

- celkový počet bitov na zobrazenie
- spôsob zobrazenia mantisy
- spôsob zobrazenia exponentu
- rozdelenie bitov pre mantisu a exponent
- poradie mantisy a exponentu....

Pri voľbe počtu bitov pre zobrazenie mantisy a exponentu rozhodujú nasledovné atribúty :

-rozsah (range) hovorí, o najmenšom a najväčšom čísle v absolútnej hodnote rôzne od nuly, ktoré sa dá zobrazit'

- počet platných číslic - rozlišovacia schopnosť (precision) – je to vlastne presnosť zobrazenia čísla napr. číslo π môže byť zobrazené ako 3.142 alebo 3.141592

-presnosť (accuracy) hovorí o blízkosti čísla k správnej hodnote napr. číslo π môže byť zobrazené ako 3.142 alebo 3.241592. Aj keď prvé číslo je zobrazené pomocou menšieho počtu platných číslic, jeho hodnota je bližšia k hodnote čísla π .

Je dôležité sa zaoberať presnosťou najmä aritmetických operácií napr.

$$A = 1432.52 \quad B = 1432.51$$

$$C = \frac{A + B}{A - B} = \frac{1432.52 + 1432.51}{1432.52 - 1432.51} = \frac{2865.03}{0.01}$$

bude hodnota výsledku C stanovená s chybou 100%.

Kódovanie FPA čísel

Kódovanie podľa IEEE 754-1985

- **normalizovaná mantisa** (maximalizácia počtu platných číslíc - bitov (precision) = počet platných bitov mantisy)

$$-2 < x \leq 1 \quad \textit{alebo} \quad x = 0 \quad \textit{alebo} \quad 1 \leq x < 2$$

- posunutý exponent, ak je m-bitový exponent potom je exponent z rozsahu

$$-2^{m-1} \leq e \leq 2^{m-1} - 1$$

Ak k exponentu pripočítame posun 2^{m-1}

potom rozsah hodnôt mantisy bude (1.00000 ...00,
1.1111...11)

- usporiadanie bitov pre znamienko, exponent a mantisu

[1]str.188 Obr. 4.28

- reprezentácia nuly

[1]str.187 Obr. 4.27

Single precision Double precision Quad precision

Field width

in bits

S = sign	1	1	1
E = exponent	8	11	15
L = leading bit	1	1	1
F = fraction	23	52	111
Total width	32	64	128

Exponent

Maximum E	255	2047	32767
Minimum E	0	0	0
Bias	127	1023	16383

Notes

S = sign bit (0 for a negative number, 1 for a positive number)

L = leading bit (always 1 in a normalized, non-zero mantissa)

F = fractional part of the mantissa

The range of exponents is from $\text{Min } E + 1$ to $\text{Max } E - 1$.

The number is represented by $-1^S \times 2^{E - \text{exponent}} \times L.F.$

A signed zero is represented by the minimum exponent, $L = 0$, and $F = 0$, for all three formats.

The maximum exponent has a special function that represents signed infinity for all three formats.

Príklad prevodu do 32-bitového formátu IEEE:

Majme číslo -19.375

Najprv prevedieme celočíselnú časť, a desatinnú časť

$19 \quad 1$

$0.375 \quad 0$

$9 \quad 1$

$0.750 \quad 1$

$4 \quad 0$

$0.500 \quad 1$

$2 \quad 0$

$0.000 \quad koniec$

$1 \quad 1$

$0.375_{10} = 0.011_2$

0

$19_{10} = 10011_2$

$$-19.375_{10} = -10011.011_2 = -1.0011011 \times 2^4$$

$$S = 1$$

$$E = 4 + 127 = 131_{10} = 10000011_2$$

$$M = \underline{1.0011011}$$

$$S \quad E \quad M$$

$$1 \quad 1000001 \quad 1 \quad 0011011 \quad 00000000 \quad 00000000$$

$$C1 \quad 9B \quad 00 \quad 00$$

Číslo -19.375 sa zobrazí v 32-bitovom formáte IEEE do 32-bitového slova s obsahom **C19B0000**_H .

Pre 32-bitové číslo v IEEE formáte je :

Minimálna hodnota

posunutého exponentu $E_{pmin} = 1$ $E_{min} = -126$

Maximálna hodnota

posunutého exponentu $E_{pmax} = 254$ $E_{max} = 127$

Zvláštne hodnoty

$E_p = 0 \wedge M = 0$ (NULA)

$E_p = 0 \wedge M \neq 0$ ($-\infty$) – podtečenie

$E_p = 255 \wedge M = 0$ (NaN)

$E_p = 255 \wedge M \neq 0$ (∞) - pretečenie

NaN – Not a Number

Možné hodnoty 32-bitového FPA čísla IEEE formátu :

- záporné čísla $\langle -(1-2^{-24})x2^{127}, -0.5x2^{-128} \rangle$

- kladné čísla $\langle 0.5x2^{-128}, (1-2^{-24})x2^{127} \rangle$

- záporné čísla menšie ako $-(1-2^{-24})x2^{127}$
nazývame záporné pretečenie

- kladné čísla väčšie ako $(1-2^{-24})x2^{127}$
nazývame kladné pretečenie

- nula, ak všetky bajty sú nulové

Podtečenie nie je problém – výsledok sa vyjadrí „čistou nulou“.

Pretečenie sa signalizuje dvojakým spôsobom :

- ak je NaN potom generuje sa „výnimka“ (nezmyselný výsledok) (je to vec operačného systému)
- ak je signalizované pretečenie je na programátorovi, ako danú situáciu vyrieši

Iné formáty FPA

IBM S/370

- základ 16 (32-bit a 64-bit)
- dôraz na počet platných bitov
- nula = nulové bajty

[2]str.225 Obr. 7.18

Formáty FPA VAX-11

- dve varianty veľkosti exponentu
- nula = nulové bajty

[2]str.225 Obr. 7.18

FPA aritmetika

FPA aritmetika nie je asociatívna !!!!!. Neplatí pre čísla x, y, z v pohyblivej rádovej čiarke

$$(x + y) + z \neq x + (y + z)$$

$$(x \cdot y) \cdot z \neq x \cdot (y \cdot z)$$

nie je ani vždy distributívna !!!!!

$$x \cdot (y + z) \neq (x \cdot y) + (x \cdot z)$$

Algoritmy treba starostlivo analyzovať, či aplikácia pravidiel nemôže viesť k nezmyselnému výsledku. Napr.

$$(1.0e100 - 1.0e100) + 1.0 = 1.0 \quad \text{ale}$$

$$(1.0e100 + 1.0) - 1.0e100 = 0.0$$

Súčet a rozdiel

Princíp :

Majme čísla $A=12345$ a $B=567.89$, ktoré sa dajú zapísať v tvare $A = 0.12345 \times 10^5$ $B = 0.56789 \times 10^3$

Súčet v dekadickom vyjadrení je jednoduchý

$$\begin{array}{r} 12345 \\ + 567.89 \\ \hline 12912.89 \end{array} \quad \begin{array}{l} \text{ale vo FPA formáte} \end{array} \quad \begin{array}{r} 0.12345 \times 10^5 \\ + 0.56789 \times 10^3 \end{array}$$

je potrebné normovať exponenty (zväčšiť menší exponent)

$$\begin{array}{r}
 0.1234500 \times 10^5 \\
 + 0.0056789 \times 10^5 \\
 \hline
 0.1291289 \times 10^5
 \end{array}$$

V prípade binárnych čísel

$$\begin{array}{r}
 1.1001 \times 2^4 \\
 + 1.0001 \times 2^3
 \end{array}$$

normujeme menší exponent

$$\begin{array}{r}
 1.10010 \times 2^4 \\
 + 0.10001 \times 2^4 \\
 \hline
 10.00011 \times 2^4
 \end{array}$$

pretože mantisa nie je normalizovaná, musíme upraviť
výsledok

$$10.00011 \times 2^4 \quad na \quad 1.000011 \times 2^5$$

a upraviť počet platných miest zaokrúhlením

$$1.000011x2^5 \quad na \quad (1.000011 + 0.00001)x2^5 = 1.0001x2^5$$

Postup sčítania a odčítania môžeme formulovať nasledovne :

2. Ak je niektorý z operandov nulový, výsledok je rovný nenulovému operandu s príslušným znamienkom
3. Ak rozdiel exponentov operandov je väčší ako počet bitov matnisy výsledok je rovný operandu s väčším exponentom s príslušným znamienkom
4. Inak

$$A = M_A * z^{E_A} \quad B = M_B * z^{E_B}$$

Potom


$$A + B = \left(M_A * z^{(E_A - E_B)} + M_B \right) * z^{E_B} \quad \text{pre } E_A \leq E_B$$

$$A - B = \left(M_A * z^{(E_A - E_B)} - M_B \right) * z^{E_B} \quad \text{pre } E_A \leq E_B$$


4. Vykoná sa normalizácia výsledku s príslušným zaokrúhľením
5. Testuje sa pretečenie (podtečenie) výsledku


Bloková schéma súčtu/rozdielu

Vyhodnotenie operandov



Úprava mantisy operandu s menším exponentom





Zaokrúhľenie a orezanie čísla

Orezanie čísla na počet platných rádov

Orezaním čísla 0.1101101 (čo je 0,8515625) na 4 platné bity dostaneme 0.1101 (0,8125) s chybou (-0.0390625). Orezaním dostaneme najbližšie číslo zdola. Lepšie je zaokrúhľenie, vykonáme pripočítaním čísla 1 s váhou o 1 menej, ako je posledný platný rád, pre tento prípad je to číslo 0.00001

$$\begin{array}{r} 0.1101101 \\ + 0.0000100 \\ \hline 0.1110001 = 0.1110 \end{array}$$

čo je 0,875 s chybou (0.0234375).

Zaokrúhľenie

- zabezpečuje menšiu chybu výsledkov FPA operácií oproti orezaniu.
- vyžaduje dodatočné operácie s výsledkom
- vyžaduje medzivýpočty s väčším počtom platných číslíc (registre ALU pre FPA obsahujú ochranné bity aby pre normalizáciu a zaokrúhľenie bolo k dispozícii dost' bitov)

Chyby spôsobené konečnou dĺžkou čísla FPA sa prejavia vo výsledkoch operácií

Napr.

```
float a=0.1, b=0.1;
```

```
for( int i=0; i<100000; i++) a*=b;
```

dáva výsledok $a=9998.557$, čo je chyba 0,014%

Obecne fungujú zákony štatistiky, zaokrúhľovaním sú generované chyby s premenlivým znamienkom, čo v strednej hodnote sa môže udržiavať v prijateľných hraniciach. Orezávanie generuje chyby len s jedným znamienkom.

Násobenie a delenie

$$A = M_A * z^{E_A} \quad B = M_B * z^{E_B}$$


Potom


$$A * B = (M_A * M_B) * z^{(E_A + E_B)}$$

$$A / B = (M_A / M_B) * z^{(E_A - E_B)}$$

Bloková schéma násobenia $X*Y$


Vyhodnotenie operandov






Bloková schéma delenia X/Y

Vyhodnotenie operandov





Delenie násobením

Nech $C = \frac{A}{B}$ upravíme B tak, aby

$$C = \frac{A^* L}{B^* L} = \frac{A^*}{B^*}, \text{ tak aby } \frac{1}{2} \leq B^* < 1$$

Definujme $Z = 1 - B^*$ potom $0 < Z \leq \frac{1}{2}$

$$\text{a } K = 1 + Z$$

$$C = \frac{A^* * K}{B^* * K} = \frac{A^* * (1 + Z)}{(1 - Z) * (1 + Z)} = \frac{A^* * (1 + Z)}{1 - Z^2}$$

$$C = \frac{A^* * (1 + Z)}{1 - Z^2} = \frac{A^* * (1 + Z) * (1 + Z^2)}{(1 - Z^2)(1 + Z^2)} = \frac{A^* * (1 + Z) * (1 + Z^2)}{1 - Z^4}$$

⋮

$$C = \frac{A^* * (1 + Z) * (1 + Z^2) * \dots * (1 + Z^{2^{n-1}})}{1 - Z^{2^n}} \quad \text{pre } n \rightarrow \infty \quad Z^{2^n} \rightarrow 0$$

pre 32 platných bitov stačí $n=5$.

Realizácia elementárnych funkcií

Použitie tabuliek

- hodnota argumentu funkcie = adresa do tabuľky (podobný princíp ako pri rýchlych násobičkách) – vhodné pre systémy používajúce čísla s malým počtom bitov
- tabelované sú vybrané body funkcie, hodnota funkcie sa získa interpoláciou medzi dvomi hodnotami uloženými v tabuľke

Aproximácia pomocou polynómov (podielu polynómov)

Napríklad Taylorov rad

$$f(x) \cong \sum_{n=0}^k (x-a)^n \frac{f^{(n)}(a)}{n!} \quad \text{resp.} \quad f(x) \cong \sum_{n=0}^k x^n \frac{f^{(n)}(0)}{n!}$$

požadovaná presnosť sa dosiahne voľbou n . Napr.

$$\sin x = x - \frac{x^3}{3!} + \frac{x^5}{5!} - \frac{x^7}{7!} + \dots = \sum_{n=0}^{\infty} \frac{(-1)^n x^{2n+1}}{(2n+1)!}$$

Iteračné algoritmy

Založené na postupnom výpočte funkčnej hodnoty podľa algoritmu, ktorý zaručuje konvergenciu vypočítaných hodnôt k požadovanej hodnote. Počet krokov určuje presnosť výpočtu.

Príklad (výpočet funkčných hodnôt funkcie $1/x$, tento princíp využíva aj algoritmus delenia)

Výpočet hodnoty funkcie

$$g(x) = \frac{1}{x}$$

pre konkrétnu hodnotu argumentu b to bude

$$g(b) = \frac{1}{b}$$

čo sa dá vyriešiť napr. delením, alebo riešením rovnice

$$f(x) = \frac{1}{x} - b = 0$$

alebo riešením úlohy nájdania takého argumentu $f(x)$, pre ktorý je hodnota funkcie rovná 0.

Na tento typ úloh je vhodná Newtonova iteračná metóda. Iterácia je založená na výpočte

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

$$x_{i+1} = x_i - \frac{\frac{1}{x_i} - b}{-\frac{1}{x_i^2}} = x_i(2 - bx_i)$$

[3]str.178 Obr. 5.5

Podmienkou konvergenzie je normovanie parametra b na interval $(-1,2)$, čo sa dá zabezpečiť úpravou argumentu pred výpočtom, a úpravou výsledku.

Nech $b=1.5$ a $x_0=1$, potom sú postupne medzivýsledky

1.00000000000000000000

0.50000000000000000000

0.62500000000000000000

0.66406250000000000000

0.6666564941406250

0.66666666665114462

0.666666666666666666

Algoritmy využívajúce špecifické vlastnosti funkcií

CORDIC (for **CO**ordinate **R**otation **DI**gital **C**omputer)

[http://en.wikipedia.org/wiki/CORDIC - column-one](http://en.wikipedia.org/wiki/CORDIC_-_column-one) [*]

je jednoduchý a efektívny algoritmus na výpočet trigonometrických a hyperbolických funkcií

Princíp je založený na postupnej rotácii jednotkového vektora v rovine

Vid.[*]

$$v_{n+1} = Rv_n$$

kde v_n , v_{n+1} sú súradnice jednotkového vektora pred a po natočení, R je rotačná matica.

$$R = \begin{pmatrix} \cos \gamma & -\sin \gamma \\ \sin \gamma & \cos \gamma \end{pmatrix}$$

$$v_{n+1} = Rv_n = \cos \gamma \begin{pmatrix} 1 & -\sigma \tan \gamma \\ \sigma \tan \gamma & 1 \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix}$$

kde γ je uhol natočenia a σ nadobúda hodnoty 1 alebo -1 (riadenie smeru natáčania).

$$v_{n+1} = Rv_n = K \begin{pmatrix} 1 & -\sigma 2^{-n} \\ \sigma 2^{-n} & 1 \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} x - \sigma 2^{-n} y \\ x \sigma 2^{-n} + y \end{pmatrix} K$$

volíme také uhly aby $\tan(\gamma)=2^{-n}$. Uhly sú tabelované
Problém je mierka

$$K_n = \prod_{i=0}^{n-1} \cos(\arctan(2^{-i})) = \prod_{i=0}^{n-1} \sqrt{1 + 2^{-2i}}$$

pre konštatný počet krokov je vždy rovnaká. Po skončení výpočtu x-vá zložka sa rovná kosínusu a y-vá zložka sínusu uhla.

Literatúra:

- [1] Clements,A: The Principles of Computer Hardware, Oxford
- [2] Stalling, W.: Computer Organization and Architecture, principles ...,
- [3] Jelšina, M.: Architektúry počítačových systémov,