

B33POS: Počítačové systémy

Lekce 04. Reálná čísla

Petr Štěpán
stepan@fel.cvut.cz



9. října, 2025

Obsah

- 1 Bitové operace
- 2 Reálná čísla – pevná desetinná čárka
- 3 Reálná čísla – plovoucí desetinná čárka

Bitové operace


- V jazyce C a ve strojových instrukcích procesoru jsou definovány bitové operace – and, or, xor, negace.
- Pokud máte proměnnou `int a=-10` a chcete zjistit její nejméně významný bajt, pak můžete použít instrukci bitový and
`unsigned int bajt = a & 0xff;`
- POZOR neplést s operací `&&`, toto je logický and.
- Jak instrukce pracuje, provede "logický" and mezi sobě odpovídajícími bity čísla:

a	=	11111111	11111111	11111111	11110110
		&&&&&&&&	&&&&&&&&	&&&&&&&&	&&&&&&&&
0xff	=	00000000	00000000	00000000	11111111
a&0xff	=	00000000	00000000	00000000	11110110

Bitové operace

Programovací jazyk C umí pracovat s čísly u nichž zadáte jejich bitovou velikost. Struktura s více bitovými položkami může být definována následujícím způsobem:

```
struct pole {  
    int nibble:4;  
    unsigned int male:2;  
    int znam_male:2;  
    unsigned int vetsi:7;  
    unsigned int jeden_bit:1;  
}
```



- položka nibble je číslo se znaménkem a má 4 bity
- položka male je malé číslo bez znaménka o rozsahu 0...3
- položka znam_male je číslo od -2 .. 1
- položka vetsi je číslo od 0 do 127
- položka jeden_bit je buď 0 nebo 1

Bitové operace

Jak bude skutečně definovaná struktura `struct` pole uložena v paměti záleží na překladači.

Struktura bude optimálně uložena ve dvou bajtech, ale může být také uložena ve více bajtech od 5 do 8.

Zarovnávání položek ve strukturách a třídách lze ovlivnit příkazem:

```
#pragma pack(N),
```

kdy `N` definuje na kolik bajtů se jednotlivé položky zarovnávají.

Tento přístup není standardizován, proto je dobré, umět si naprogramovat ukládání do podobné struktury sami.

Bitové operace - zápis hodnoty

Jak uložit hodnotu (value), která má maximálně k-bitů na pozici l bitů od nejméně významného bitu?

Nejdříve je nutno nastavit k-bitů na 0.

```
unsigned short pole=0xffff;
unsigned mask_k = (1<<k)-1;
pole &= (~(mask_k<<l));
```

mask_k je číslo, které má na nejnižších k bitech 1 a jinde 0

mask_k<<l je číslo, které má na odpovídajících k bitech 1 a jinde 0

$\sim$ (mask_k<<l) je bitová negace předchozí hodnoty, na odpovídajících místech je k 0 jinde jsou 1

Nyní můžeme nastavit hodnotu value operací or.

```
pole |= (value & mask_k)<<l;
```

(value & mask_k) pro jistotu ořízneme hodnotu value pouze na k-bitů

(value & mask_k)<<l posuneme hodnotu na správnou pozici

pole |= (value & mask_k)<<l zapíšeme hodnotu na správnou pozici v poli

Bitové operace - zápis hodnoty

příklad, jak to bude vypadat pro $k=5$ a $l=4$

$1 \ll 5 = 0b00000000000100000$

$1 \ll 5 - 1 = 0b0000000000011111 = \text{mask_k}$

$\text{mask_k} \ll 4 = 0b0000000111110000$

$\sim \text{mask_k} \ll 4 = 0b1111111000001111$

$\text{pole} = 0b1111111111111111$

$\text{pole} \& (\sim (\text{mask_k} \ll 4))$
 $= 0b1111111000001111$

$\text{value} = 0b0000010000001101$

$\text{value} \& \text{mask_k} =$
 $= 0b0000000000001101$

$(\text{value} \& \text{mask_k}) \ll 4$
 $= 0b0000000011010000$

$\text{pole} |= (\text{value} \& \text{mask_k}) \ll 4$
 $= 0b1111111011011111$

červená je chyba, value má mít
jen 5 bitů

– oprava chyby

Bitové operace - čtení hodnoty

Jak přečíst hodnotu (value) bez znaménka, která má maximálně k-bitů na pozici l bitů od nejméně významného bitu?

Nejdříve je nutno nastavit k-bitů na 0.

```
value = ((pole>>l) & mask_k);
```

mask_k je číslo, které má na nejnižších k bitech 1 a jinde 0

(pole>>l) je číslo, které má odpovídající bity posunuty na novou správnou pozici

(pole>>l) & mask_k je výsledná hledaná hodnota

příklad:

```
pole = 0b11111111011011111
```

```
pole >>4 = 0b00001111111101101
```

```
pole >>4 & mask_k = 0b000000000001101
```

Bitové operace - čtení hodnoty se znaménkem

Jak přečíst hodnotu (value) se znaménkem, která má maximálně k-bitů na pozici l bitů od nejméně významného bitu?

Podobně jako u čísla bez znaménka, ale nakonec musíme znamínkový bit rozšířit va všechny bit vlevo výsledného typu:

```
mex_bit = 1<<(k-1)
```

```
value = (((pole>>l) & mask_k)^max_bit)-max_bit;
```

$((val) \wedge max_bit) - max_bit$ je znaménkové rozšíření na plnou hodnotu typu value

příklad:

```
value = -1           = 0b1111111111111111
```

```
pole           = 0b1111111111111111
```

```
pole >>4       = 0b0000111111111111
```

```
pole >>4 & mask_k = 0b0000000000001111
```

```
(pole >>4 & mask_k) ^ max_bit  
= 0b00000000000001111
```

```
((pole >>4 & mask_k) ^ max_bit) - max_bit  
= 0b1111111111111111
```

Bitové operace

```
unsigned short pole=0xffff;
```

```
pole &= (~0xf);
```

```
pole |= (nibble &0xf);
```

```
pole &= (~0x30);
```

```
pole |= ((male &0x3)<<4);
```

```
pole &= (~0xc0);
```

```
pole |= ((znam_male &0x3)<<6);
```

```
pole &= (~0x7F00);
```

```
pole |= ((vetsi &0x7F)<<8);
```

```
pole &= (~0x8000);
```

```
pole |= ((jeden_bit &0x1)<<15);
```

```
printf("nibble = %u\n",  
       pole&0xf);
```

```
printf("male = %u\n",  
       (pole>>4)&0x3);
```


```
printf("znam_male = %d\n",  
       (((pole>>6)&0x3)^0x2)-2);
```

```
printf("vetsi = %u\n",  
       (pole>>8)&0x7f);
```

```
printf("jeden bit = %u\n",  
       (pole>>15)&0x1);
```

Bitové pole

Bitové pole se používá často jako nejefektivnější způsob zjištění, zda jsou některé objekty použité nebo nepoužité.




```

unsigned char array[128];
// 1024 bitů uložených v poli 128 bajtů
void set_bit(int index, unsigned char bit) {
    if (bit==0) {
        array[index>>3] &= ~(1<<(index&7));
    } else {
        array[index>>3] |= (1<<(index&7));
    }
}

unsigned char get_bit(int index) {
    return (array[index>>3]>>(index&7))&1u;
}

```



Bitové pole

Použití funkcí je pak již jednoduché:

```
int main() {  
    int i;  
  
    for (i=0; i<1024; i++) {  
        set_bit(i, (i%5)==0);  
    }  
  
    for (i=0; i<1024; i++) {  
        printf("bit %i = %u\n", i , get_bit(i));  
    }  
    return 0;  
}
```

Obsah

- 1 Bitové operace
- 2 Reálná čísla – pevná desetinná čárka
- 3 Reálná čísla – plovoucí desetinná čárka

Reálná čísla

- Celé číslo X v binární soustavě je součet k bitů b_i vynásobených mocninami 2, tedy $X = \sum_{i=0}^{k-1} b_i 2^i$
- Reálné číslo X v binární soustavě je obdobný součet $k + j$ bitů b_i vynásobených mocninami 2, ale začneme již v záporných mocninách:

$$X = \sum_{i=-j}^k b_i 2^i$$
- jistě si všichni pamatujete ze střední školy, že $2^{-j} = \frac{1}{2^j}$

$$\begin{array}{cccccccccccc}
 & & & & & & & \frac{1}{2} & \frac{1}{4} & & & \\
 & & & & & & & \parallel & \parallel & & & \\
 & & & & & & & 4 & 2 & 1 & & \\
 & & & & & & & \parallel & \parallel & \parallel & & \\
 2^i & 2^{i-1} & 2^{i-2} & \dots & 2^2 & 2^1 & 2^0 & 2^{-1} & 2^{-2} & \dots & 2^{-j+1} & 2^{-j} \\
 b_i & b_{i-1} & b_{i-2} & \dots & b_2 & b_1 & b_0 & . b_{-1} & b_{-2} & \dots & b_{-j+1} & b_{-j}
 \end{array}$$

Reálná čísla s pevnou desetinnou čárkou

Čísla s pevnou desetinnou čárkou (fixed point numbers):

- obdoba čísel s posunutou 0
- reálné číslo je reprezentované k -bitovým celým číslem se znaménkem, dále zvolíme pevný počet desetinných míst s bitů, kdy $0 \leq s \leq k$
- reprezentace – kód čísla X je $A(X) = \lceil X \cdot 2^s \rceil$
- rozkódování je funkcí $D(A) = \frac{A}{2^s}$
- rozsah čísel reprezentovaných je $< -\frac{2^{k-1}}{2^s}, \frac{2^{k-1}-1}{2^s} >$
- přesnost reprezentace čísel je $\pm \frac{1}{2^s}$.

Speciální případ:

- pokud chcete reprezentovat reálná čísla z intervalu $< 0, 1)$
- pak můžete nastavit $s = k$ a použít bezznaménkovou reprezentaci celých čísel
- dosáhnete lepší přesnosti než odpovídající float, nebo double

Některé SIMD instrukce používají pevnou desetinnou čárku.

Fixed point – implementace v C

```

#define NUM_POINTS 10
#define NUM_MASK  ((1<<NUM_POINTS)-1)

int fixed_p1, fixed_p2;

fixed_p1 = (15 << NUM_POINTS) + ((21<< NUM_POINTS)/100);
// fixed_p = 15.21 = 15 + 21/100
fixed_p2 = (3 << NUM_POINTS) +
    (((long long int)141592<< NUM_POINTS)/1000000);
// fixed_p2 = 3.141592 = 3 + 141592/1000000

printf("%08x %08x\n", fixed_p1, fixed_p2);
// vytiskne 0000f35c 00003243
printf("%lf %lf\n", fixed_p1/(double)(1<<NUM_POINTS),
    fixed_p2/(double)(1<<NUM_POINTS));
// vytiskne 15.209961 3.141357
// spravne 15.21 3.141592

```

Reálná čísla s pevnou desetinnou čárkou

Počítání s čísly s pevnou desetinnou čárkou:

- součet a rozdíl je součtem a rozdílem celočíselné reprezentace čísel
- násobení je složitější:

$$\blacksquare A(X \cdot Y) = (X \cdot Y) \cdot 2^s = \frac{(X \cdot 2^s) \cdot (Y \cdot 2^s)}{2^s} = \frac{A(X) \cdot A(Y)}{2^s}$$

- dělení je obdobné:

$$\blacksquare A\left(\frac{X}{Y}\right) = \left(\frac{X}{Y}\right) \cdot 2^s = \frac{(X \cdot 2^s) \cdot 2^s}{(Y \cdot 2^s)} = \frac{A(X) \cdot 2^s}{A(Y)}$$

- Nejedná se o výrazné zesložnění, protože násobení číslem 2^s je posun o s bitů doleva a dělení číslem 2^s je posun o s bitů doprava.

Fixed point – matematické operace

```
int fixed_sum, fixed_sub;
```

```
fixed_sum = fixed_p1 + fixed_p2;
fixed_sub = fixed_p1 - fixed_p2;
printf("sum %08x sub %08x \n", fixed_sum, fixed_sub);
// vytiskne sum 0001259f sub 0000c119
printf("%lf %lf\n", fixed_sum/(double)(1<<NUM_POINTS),
        fixed_sub/(double)(1<<NUM_POINTS));
// vytiskne 18.351318 12.068604
// spravne 18,351592 12,068408
```

```
int fixed_mul, fixed_div, fixed_div2;
fixed_mul = ((long long int)fixed_p1*fixed_p2)>>NUM_POINTS;
fixed_div = (fixed_p1/fixed_p2)<<NUM_POINTS; // ztrata presnos
fixed_div2 = ((long long int)fixed_p1<<NUM_POINTS)/fixed_p2;
```

```
printf("mul %x div1 %x div2 %x\n", fixed_mul, fixed_div, fixed_div2);
// vytiskne mul 2fc7a div1 4000 div2 4d78
printf("mul %lf div1 %lf div2 %lf\n", fixed_mul/(double)(1<<NUM_POINTS),
        fixed_div/(double)(1<<NUM_POINTS), fixed_div2/(double)(1<<NUM_POINTS));
// vytiskne mul 47.779785 div1 4.000000 div2 4.841797
// spravne mul 47,78361432 div 4,841494376
```

Obsah

- 1 Bitové operace
- 2 Reálná čísla – pevná desetinná čárka
- 3 Reálná čísla – plovoucí desetinná čárka**

Plovoucí desetinná čárka

Plovoucí desetinná čárka (floating point numbers)

Obdoba vědeckého zápisu reálných čísel:

$$-123000000000000.0 = -1.23 \cdot 10^{14} = -1.23\text{E}14$$

$$0.000000000000123 = -1.23 \cdot 10^{-13} = -1.23\text{E} - 13$$

Binární reprezentace používá obdobně mocninu 2:

$$110110000000000.0 = 1.1011 \cdot 2^{14} = 1.1011\text{E}14 = 29696_{10}$$

$$\begin{aligned} -0.0000000000000011101 &= -1.1101 \cdot 2^{-16} = -1.1101\text{E} - 16 \approx \\ &\approx 0.00002765_{10} \end{aligned}$$

Všimněte si, že každé reálné číslo (kromě 0) začíná v binárním vědeckém zápisu jedničkou.

IEEE-754

Standard IEEE-754 definuje, jakým způsobem zakódovat reálné číslo do 32, 64 bitů.

Reálné 32-bitové číslo obsahuje:

- 1 bit znaménko (pozn. existuje 0 i -0)
- 8 bit hodnota exponentu s posunutou nulou o 127
- 23 bitů hodnota mantisy, tedy cifer reprezentujících hodnotu

Reálné 64-bitové číslo obsahuje:

- 1 bit znaménko (pozn. existuje 0 i -0)
- 11 bitů hodnota exponentu s posunutou nulou o 1023
- 52 bitů hodnota mantisy, tedy cifer reprezentujících hodnotu

IEEE-754


Příklad: Reálné číslo $0.828125_{(10)} = 0.5 + 0.25 + 0.0625 + 0.015625 = 2^{-1} + 2^{-2} + 2^{-4} + 2^{-6} = 0.110101_{(2)}$.

Číslo převedeme do vědecké notace: $0.110101 = 1.10101E - 1$.

Exponent $e = -1$, reprezentace s posunutou nulou o 127 je

$$A(-1) = -1 + 127 = 126.$$

Abychom neplýtvali zbytečně bity, pro normalizovaná čísla se první 1 mantisy neukládá do binární reprezentace čísla:



Zkuste si

<https://www.h-schmidt.net/FloatConverter/IEEE754.html>

IEEE-754

Normalizované číslo, je každé číslo, které lze zapsat jako $1.XXXXX E \text{ exp}$, kde exp je číslo od -126 do 127, tedy jehož reprezentace je od 1 do 254.

Denormalizovaná čísla jsou čísla, která lze zapsat jako $0.XXXXX E -126$, tedy například 0.0, nebo všechna čísla v intervalu $(-1.17549E - 38, 1.17549E - 38)$, tedy od $(-2^{-126}, 2^{-126})$.

Pokud je reprezentace exponentu nastavena na samé 1, tedy 255, tzn. hodnota exponentu je 128, pak se jedná o speciální čísla.

- pokud je mantisa 0, pak se jedná o nekonečno, podle znaménka *-inf*, nebo *inf*.
- pokud je mantisa nenulová, pak se jedná o speciální výraz *NaN* – Not a Number, tedy chybná hodnota čísla, například po výpočtu odmocniny záporného čísla

IEEE-754

Přehled reálných čísel:

Exponent	Mantisa	Hodnota
00000000	0	0.0 – čistá nula
00000000	nenulová	Denormalizovaná čísla blízka 0
00000001	0	nejmenší normalizované číslo se skrytou 1 v mantise
1 až 254	cokoliv	normalizovaná čísla, skrytá 1 v mantise
11111111	0	nekonečno
11111111	nenulová	NaN chybná hodnota

Denormalizované číslo s nejmenší absolutní hodnotou různé od 0 je:

- exponent = 0 (-126), mantisa=000...0001, hodnota = $2^{-23+(-126)} \approx 1.4\text{E} - 45$

Normalizované číslo s nejmenší absolutní hodnotou:

- exponent = 1 (-126), mantisa=000...0000, hodnota = $2^{-126} \approx 1.17\text{E} - 38$

Normalizované číslo s největší absolutní hodnotou:

- exponent = 255 (127), mantisa=111...1111, hodnota = $(2 - 2^{-23})2^{127} \approx 3.4\text{E}38$

Float point decode – implementace v C

Dekódování normalizovaných čísel v jazyce C

```
#include <stdio.h>

#define SIGN(x)
    (((*(unsigned int*)&x)>>31)&0x1)?'+':'-')

#define EXP(x)
    (((*(unsigned int*)&x)>>23)&0xff)

#define MANTISA(x)
    ((*((unsigned int*)&x)&0x7FFFFFFF)

int main() {
    float a = 0.125;
    float b = -0.1;

    printf("Hodnota %f znamenko %c exp %i(%i) mantisa %x\n", a,
        SIGN(a), EXP(a)-127, EXP(a), MANTISA(a));
    printf("Hodnota %f znamenko %c exp %i(%i) mantisa %x\n", b,
        SIGN(b), EXP(b)-127, EXP(b), MANTISA(b));
}
```

Rozumíte definovaným makrům?

IEEE-754 revize 2008

Standard IEEE-754 navíc definuje reálné číslo s 16 bity (half precision) a s 128 bity (quad precision).

Reálné 16-bitové číslo obsahuje:

- 1 bit znaménko
- 5 bitů hodnota exponentu s posunutou nulou o 15
- 10 bitů hodnota mantisy, (plus 11tý bit skrytý neukládáný)

Reálné 128-bitové číslo obsahuje:

- 1 bit znaménko
- 15 bitů hodnota exponentu s posunutou nulou o 16383
- 112 bitů hodnota mantisy, (plus 113 bit skrytý)

IEEE-754

Porovnání reálných čísel na velikost:

- Kladná čísla jsou vždy větší než záporná
- Po odstranění znamének, lze absolutní hodnoty čísel porovnat tak, jak jsou uložené v paměti jako celé číslo bez znaménka
 - To je možné díky zvolené reprezentaci exponentu jako čísla s posunutou nulou
 - Větší exponent větší číslo, při rovnosti exponentů větší mantisa znamená větší číslo

IEEE-754

Sčítání nebo odčítání dvou reálných čísel ve vědecké notaci

- 1 Převést mantisy čísel na společný exponent, který má hodnotu největšího exponentu (porušíme notaci)
- 2 Provést součet, nebo rozdíl mantis i se skrytými jedničkami
- 3 Výsledné číslo normalizovat
 - při sčítání se může exponent zvětšit
 - při odčítání se exponent může zmenšit

IEEE-754

Příklad: Sčítání dvou reálných čísel $31.5 + 0.75$

$$31.5_{(10)} = 11111.1_{(2)} = 1.11111E4 \quad 0.75_{(10)} = 0.11_{(2)} = 1.1E-1$$

Obě čísla převedeme na stejný exponent 4 a sečteme:

$$\begin{array}{r} 1.11111 \\ 0.000011 \\ \hline 10.000001 \end{array}$$

Výsledné číslo musíme znormalizovat zvýšením exponentu na 5 a tím posunutím desetinné čárky vlevo:

$$10.000001E4 = 1.0000001E5$$

Toto číslo je reprezentací čísla 32.25.

IEEE-754

Příklad: Sčítání dvou reálných čísel $31.5 + 0.75$

$$31.5_{(10)} = 11111.1_{(2)} = 1.11111E4 \quad 0.75_{(10)} = 0.11_{(2)} = 1.1E-1$$

Obě čísla převedeme na stejný exponent 4 a sečteme:

$$\begin{array}{r} 1.11111 \\ 0.000011 \\ \hline 10.000001 \end{array}$$

Výsledné číslo musíme znormalizovat zvýšením exponentu na 5 a tím posunutím desetinné čárky vlevo:

$$10.000001E4 = 1.0000001E5$$

Toto číslo je reprezentací čísla 32.25.

Float point sčítání – implementace v C

Algoritmus sčítání v jazyce C (bez uvážení znamének)

```
#include <stdio.h>
#define SIGN(x)
    (((*(unsigned int*)&x)>>31)&0x1)?'+':'-')
#define EXP(x)
    (((*(unsigned int*)&x)>>23)&0xff)
#define MANTISA(x)
    (*(unsigned int*)&x)&0x7FFFFFFF

int main() {
    float a = 31.5;
    float b = 0.75;
    float c = a+b;
    int e_a, e_b, e_c;
    unsigned int man_a, man_b, man_c;
    int shift;

    e_a = EXP(a);
    e_b = EXP(b);

    man_a = MANTISA(a)|0x800000;
    man_b = MANTISA(b)|0x800000;

    if (e_a>e_b) {
        shift = e_a-e_b;
        e_c = e_a;
        man_b=(man_b>>shift);
    } else {
        shift = e_b-e_a;
        e_c = e_b;
        man_a=(man_a>>shift);
    }
    man_c = man_a+man_b;

    if ((man_c&0x1000000)!=0) {
        man_c = man_c>>1;
        e_c++;
    }
    man_c = (man_c & 0x7FFFFFFF);
    printf("C %i %06x, spocteno %i %06x\n",
        EXP(c), MANTISA(c), e_c, man_c);
}
```

Uměli byste přidat vztít v úvahu znaménko?

IEEE-754 – Násobení

Násobení dvou reálných čísel:

- 1 Exponent výsledku je součet exponentů čísel
- 2 Mantisa výsledku je součin mantis čísel (i se skrytými jedničkami)
- 3 Výsledné číslo normalizovat
 - podle výsledku násobení mantis je někdy nutné zvýšit exponent o 1 a vyrotovat mantisu doprava

IEEE-754 – Násobení

Příklad: Vynásobíme čísla $0.375 \cdot 1.25$

$$0.375_{(10)} = 0.011_{(2)} = 1.1E-2 \quad 1.25_{(10)} = 1.01_{(2)} = 1.01E0$$

Součin mantis je:

11 odpovídá 1.1
*101 odpovídá 1.01

11
00
11

1111
odpovídá 1.111, výsledek má 3
desetinná čísla.

375 odpovídá 0.375
*125 odpovídá 1.25

1875
750
375

46875
odpovídá 0.46875, výsledek má
5 desetinná čísla

Exponent vychází $-2 + 0 = -2$ a hodnota čísla je tedy $1.111E-2$ tedy
 $0.01111_{(2)} = 0.25 + 0.125 + 0.0625 + 0.03125 = 0.46875_{(10)}$

Float point násobení – implementace v C

Algoritmus násobení v jazyce C (bez uvážení znamének)

```
#include <stdio.h>
#define SIGN(x)
    (((*(unsigned int*)&x)>>31)&0x1)?'+':'-')
```

```
#define EXP(x)
    (((*(unsigned int*)&x)>>23)&0xff)
#define MANTISA(x)
    ((* (unsigned int*)&x)&0x7FFFFFFF)
```

```
int main() {
    float a = 0.375;
    float b = 1.25;
    float c = a*b;
    int e_a, e_b, e_c;
    uint32_t man_a, man_b, man_c;
    int shift;
```

```
    e_a = EXP(a);
    e_b = EXP(b);
    e_c = e_a + e_b - 127;
```

```
    man_a = MANTISA(a) | 0x800000;
    man_b = MANTISA(b) | 0x800000;
    man_c = (((uint64_t)man_a)*man_b)>>23;
```

```
    while ((man_c&0x1000000)!=0) {
        man_c = man_c>>1;
        e_c++;
    }
    man_c = (man_c & 0x7FFFFFFF);
    printf("C %i %06x, spocteno %i %06x\n",
        EXP(c), MANTISA(c), e_c, man_c);
```

Uměli byste přidat vzít v úvahu znaménko?

IEEE-754

Reálná čísla shrnutí:

- reálná čísla s plovoucí čárkou umí reprezentovat čísla ve velmi velkém rozsahu:
 - float – absolutní hodnota čísel od $1.175494351E - 38$ do $3.402823466E + 38$
 - double – absolutní hodnota čísel od $2.2250738585072014E - 308$ do $1.7976931348623158E + 308$
- přesnost čísla se udává na počet validních cifer:
 - float – v desítkové soustavě 6-7 platných cifer
 - double – v desítkové soustavě 15-16 platných cifer

POZOR: Následující while cyklus neskončí:

```
float a=1.0, step=5e-8;
while (a*a<1.01) {
    a+=step;
}
```