

# Slankaus kablelio skaičiai

Saulius Gražulis

Vilnius, 2021

Vilniaus universitetas, Matematikos ir informatikos fakultetas  
Informatikos institutas



Šį skaidrių rinkinių galima kopijuoti, kaip nurodyta Creative Commons  
[Attribution-ShareAlike 4.0 International](#) licencijoje



# Eksponentinis skaičių užrašymas

$$602 \underbrace{00 \dots 0}_{21 \text{ kartų}} = 6.02 \times 10^{23}$$

$$\pm d_0.d_1d_2\dots d_{p-1} \times \beta^e = \sum_{i=0}^{p-1} d_i \beta^{-i} \times \beta^e, (0 \leq d_i < \beta)$$

$$\underbrace{602 \times 10^{21}}_{\text{nenormalizuotas}} = \underbrace{6.02 \times 10^{23}}_{\text{normalizuotas}} = \underbrace{0.602 \times 10^{24}}_{\text{nenormalizuotas}}$$

# Slankaus kablelio skaičiai

$$\pm d_0.d_1d_2\dots d_{p-1} \times \beta^e = \pm \sum_{i=0}^{p-1} d_i \beta^{-i} \times \beta^e, (0 \leq d_i < \beta)$$

$$\beta = 2$$

$$0.1_{10} \approx +1.10011001100110011001101_2 \times 2^{-4}$$

- (Trupmenos) ženklas
- Laipsnio rodiklis
- Trupmena (mantisė; angl. “significand”)

# IEEE 754 standartas

- Dvejetainiai ( $\beta = 2$ , (IEEE 1985)) ir dešimtainiai ( $\beta = 10$ , (IEEE 2008)) formatai
- Viengubo, dvigubo tikslumo (IEEE 1985), pusinio, keturgubo pagrindiniai bei aštuongubo tikslumo ir ilgesni mainų standartai (IEEE 2008)
- Specialios reikšmės: neskaičiai (NaN), begalybės ( $\pm\infty$ ), nuliai ( $\pm 0$ )
- Denormalizuoti skaičiai
- Apvalinimo valdymas
- Maskuojamos išimtinės situacijos
- Nustato operacijų tikslumą

# IEEE 754 standarto kodavimas

- Mantisė: *absoliutus dydis su ženklu*
- Eksponentė: *skaičius su postūmiu* ( $\text{postūmis} = 2^{n-1} - 1$  n bitų eksponentei)
- Eksponentės diapazonas:  $-(2^{n-1} - 2) - +(2^{n-1} - 1)$  (pvz. 8 bitų eksponentei:  $-126 - +127$ )
- Trupmena (mantisė): normalizuotiems skaičiams „paslėptas“ bitas

$$0.1_{10} \approx 1.10011001100110011001101_2 \times 2^{-4}$$

Pavyzdys: 0.1 viengubo tikslumo s.k.:

p:  $23 + 1$  bitas e:  $-126 - 127$  (8 bitai); postūmis =  
 $2^{8-1} - 1 = 128 - 1 = 127$  f = 1.  
e =  $127 + (-4) = 123_{10} = 01111011_2$

0 01111011 10011001100110011001101

# Normalizuoti skaičiai

$$0.15625_{10} = \underbrace{0.00101_2}_{\text{nenormalizuotas}} = \pm 1.01 \times 2^{-3}$$

$$e = 127 + (-3) = 124_{10} = 01111100_2$$

Atvaizdavimas:

Float 32 (float; single precision):

0 01111100 01 00...0  
21 nulis

# Denormalizuoti skaičiai

$$1.0_2 \times 2^{-130_{10}}$$

Viengubo tikslumo slankiam kableliui,

$$e_{\min} = -126_{10} \Rightarrow \text{Neįmanoma normalizuoti!}$$

Atkreipkite dėmesį, kad:

$$e_{\min} + \text{postūmis} = 127_{10} + (-126_{10}) = 1 = 0000\_0001_2$$


Pastumtai eksponentei 0000\_0000, interpretacija pasikeičia:

$$0\ 0000\ 0000\ 0001\underbrace{00\dots 0}_{19 \text{ nulių}} = +0.0001_2 \times 2^{-126_{10}} = +0.0625_{10} \times 2^{-126_{10}}$$

eksponentė yra  $-126$ , **ne**  $-127$  !

# Kam reikalingi denormalizuoti skaičiai

Palaipsninis tikslumo praradimas



(Engelen 2008)

```
if (a != b) { x = a/(a-b); }
```

# Nuliai

$$0 \text{ } 0000 \text{ } 0000 \underbrace{00 \dots 0}_{23 \text{ nuliai}} = 0$$

$$1 \text{ } 0000 \text{ } 0000 \underbrace{00 \dots 0}_{23 \text{ nuliai}} = -0$$

$$\frac{1}{0} = \infty$$

$$\frac{1}{-0} = -\infty$$

```
if (a > b) { x = log(a-b); }
```

(Engelen 2008)

# Begalybės

Liko nepanaudota eksponentė su visais vienetais, 1111\_1111

$$0 \ 1111 \ 1111 \underbrace{00\dots 0}_{23 \text{ nuliai}} = \infty$$

$$1 \ 1111 \ 1111 \underbrace{00\dots 0}_{23 \text{ nuliai}} = -\infty$$

$$\frac{1}{0} = +\infty; \quad \frac{1}{+\infty} = +0$$

$$\frac{1}{-0} = -\infty; \quad \frac{1}{-\infty} = -0$$

# Neskaičiai: NaN

0 1111 1111      11...0      = qNaN  
ne visi 23 bitai yra nuliai

0 1111 1111      01...0      = sNaN  
ne visi 23 bitai yra nuliai

Operacijos, kurios grąžina NaN:

Operacija	NaN grąžina
+	$\infty + (-\infty)$
$\times$	$0 \times \infty$
/	$0/0, \infty/\infty$
rem	0 rem 0, $\infty$ rem $\infty$
$\sqrt{x}$	$\sqrt{x} \quad \forall x < 0$

(Goldberg 1991)

# NaN palyginimas


- Bet koks palyginimas su NaN grąžina False, todėl kai  $x < \text{NaN}$  yra neteisingas, dar nereiškia kad  $x \geq \text{NaN}$
- $!(x < y) \not\Rightarrow x \geq y$
- $(x == y) == \text{FALSE}$  kai  $x == \text{NaN}$
- Negalima surikiuoti realių skaičių masyvo su NaN

(Engelen 2008)

# NaN panaudojimas

Viengubo tikslumo skaičiams, NaN reikšmės turi 21 "laisvų" bitų

Dvigubo tikslumo skaičiams, NaN reikšmės turi 50 "laisvų" bitų



- Dinaminės kalbos (pvz. JavaScript) naudoja "boxed NaN" reikšmes
- sNaN naudingi neinicializuotoms reikšmėms pagauti
- qNaN gali atvaizduoti nežinomas reikšmes


# Apibendrinimas: IEEE 754 specialios reikšmės

Eskponentė	Trupmena	Reiškia
$e = e_{\min} - 1$	$f = 0$	$\pm 0$
$e = e_{\min} - 1$	$f \neq 0$	$\pm 0.f \times 2^{e_{\min}}$
$e_{\min} \leq e \leq e_{\max}$	$f = \forall n$	$\pm 1.f \times 2^e$
$e = e_{\max} + 1$	$f = 0$	$\pm \infty$
$e = e_{\max} + 1$	$f \neq 0,$	NaN

(Goldberg 1991)

# Viengubo tikslumo skaičiai


## 32-bitų skaičius



Vectorization: [Stannered](#), CC BY-SA 3.0 via Wikimedia Commons


# Dvigubo tikslumo skaičiai

## 64-bitų skaičius



[https://en.wikipedia.org/wiki/File:IEEE\\_754\\_Double\\_Floating\\_Point\\_Format.svg](https://en.wikipedia.org/wiki/File:IEEE_754_Double_Floating_Point_Format.svg)


# Intel 80 bitų išplėsto tikslumo skaičiai



BillF4, CC BY-SA 3.0, via Wikimedia Commons

- Nėra paslėpto bito
- Pakankamas tikslumas suskaičiuoti  $x^y$
- Skirti tarpiniams rezultatams

# Intel x87 slankaus kablelio registrai



**Figure 6-2. x87 Physical and Stack Registers**

(AMD 2017)

# Slankaus kablelio būsenos registrai

15 14 13 12 11 10 9 8 7 6 5 4 3 2 1 0															
B	C	TOP	C	C	C	E	S	F	P	U	O	Z	D	I	E
3	2	1	0	S	F	E	E	E	E	E	E	E	E	E	E
<b>Bits Mnemonic Description</b>															
15	B	x87 Floating-Point Unit Busy													
14	C3	Condition Code													
13:11	TOP	Top of Stack Pointer 000 = FPR0 111 = FPR7													
10	C2	Condition Code													
9	C1	Condition Code													
8	C0	Condition Code													
7	ES	Exception Status													
6	SF	Stack Fault													
<b>Exception Flags</b>															
5	PE	Precision Exception													
4	UE	Underflow Exception													
3	OE	Overflow Exception													
2	ZE	Zero-Divide Exception													
1	DE	Denormalized-Operand Exception													
0	IE	Invalid-Operation Exception													

Figure 6-3. x87 Status Word Register (FSW)

# Slankaus kablelio valdymo registrai

Bits	Mnemonic	Description
12	Y	Infinity Bit (80287 compatibility)
11:10	RC	Rounding Control
9:8	PC	Precision Control
		<b>#MF Exception Masks</b>
5	PM	Precision Exception Mask
4	UM	Underflow Exception Mask
3	OM	Overflow Exception Mask
2	ZM	Zero-Divide Exception Mask
1	DM	Denormalized-Operand Exception Mask
0	IM	Invalid-Operation Exception Mask

Figure 6-4. x87 Control Word Register (FCW)

(AMD 2017)

# Slankaus kablelio savybės

- Garantuotas atskirų operacijų tikslumas

*Except where stated otherwise, every operation shall be performed as if it first produced an intermediate result correct to infinite precision and with unbounded range, and then rounded that result according to one of the attributes in this clause.*

(IEEE 2019), sect. 4.3

- Kiekvienas išreiškiamas skaičius atvaizduojamas vieninteliu būdu
- FP skaičiai surikiuoti kaip sveiki skaičiai modulio su ženklu atvaizdavime!

*All of the possible single-precision entities are well ordered in the natural lexicographic ordering of their machine representations interpreted as sign-magnitude binary integers*

(Cody 1981)

# Pavyzdys: 16-bitų SK kodas

```
gcc -c -S \
-m16 -O3 --omit-frame-pointer \
-o single-precision.asm single-precision.c
```

```
float parallel( float x, float y )
{
    return x*y/(x + y);
}
```

```
parallel:
.LFBO:
    .cfi_startproc
    flds    4(%esp)
    flds    8(%esp)
    fld     %st(1)
    fmul   %st(1), %st
    fxch   %st(2)
    faddp  %st, %st(1)
    fdivrp %st, %st(1)
    ret
```

# Pavyzdys: 64-bitų SK kodas

```
gcc -c -S \
-O3 --omit-frame-pointer \
-o single-precision.asm single-precision.c
```

```
float parallel( float x, float y )
{
    return x*y/(x + y);
}
```

```
parallel:
.LFBO:
    .cfi_startproc
    movaps  %xmm0, %xmm2
    addss  %xmm1, %xmm0
    mulss  %xmm1, %xmm2
    divss  %xmm0, %xmm2
    movaps  %xmm2, %xmm0
    ret
```

# Alternatyvos

- Racionalių skaičių aritmetika
- Kintamo ilgio slankaus kablelio aritmetika
- J. Gustafsono Unum skaičių sistema (Gustafson 2015)
- Logaritminės skaičių sistemos (Coleman et al. 2008; Ismail et al. 2011)

# Apibendrinimas

- Slankaus kablelio skaičiai yra realių skaičių artiniai
- Iprastose situacijose naudojami normalizuoti skaičiai
- Naudojami specialūs kodai denormalizuotiems skaičiams, begalybei,  $\text{NaN} \pm 0$
- Kiekvienas IEEE 754 slankaus kablelio (s.k.) objektas turi unikalų atvaizdavimą, ir kiekvienas dvejetainis kodas vaizduoja s.k. objektą
- Kai kurie s.k. objektai (pvz.  $\text{NaN}$ ) turi savybes, kurios skiriasi nuo įprastų realių skaičių savybių
- Aktyviai tyrinėjamos naujos s.k. skaičių alternatyvos

- AMD (Dec. 2017). *AMD64 Architecture Programmer's Manual, Volume 1: Application Programming*, revision 3.22. AMD. URL: <https://www.amd.com/system/files/TechDocs/24592.pdf>.
- Cody, W. J. (Mar. 1981). "Analysis of proposals for the floating-point standard". In: *Computer* 14.3, pp. 63–68. DOI: [10.1109/c-m.1981.220379](https://doi.org/10.1109/c-m.1981.220379).
- Coleman, John N. et al. (2008). "The European Logarithmic Microprocesor". In: *IEEE Transactions on Computers* 57.4, pp. 532–546. DOI: [10.1109/tc.2007.70791](https://doi.org/10.1109/tc.2007.70791).
- Engelen, Robert van (2008). *Floating point operations and SIMD extensions*. URL: <http://www.cs.fsu.edu/~engelen/courses/HPC-adv-2008/FP.pdf>.
- Goldberg, David (1991). "What every computer scientist should know about floating-point arithmetic". In: *ACM Comput. Surv.* 23, pp. 5–48. ISSN: 0360-0300. DOI: [10.1145/103162.103163](https://doi.acm.org/10.1145/103162.103163). URL: <http://doi.acm.org/10.1145/103162.103163>.
- Gustafson, John L. (Aug. 2015). *The End of Error Unum Computing by Gustafson, John L.* Vol. 1. CRC Press. ISBN: 978-14-8223-987-4.
- IEEE (Oct. 1985). *IEEE standard for binary floating-point arithmetic*. IEEE. DOI: [10.1109/ieeestd.1985.82928](https://doi.org/10.1109/ieeestd.1985.82928).
- (2008). *IEEE standard for floating-point arithmetic*. DOI: [10.1109/ieeestd.2008.4610935](https://doi.org/10.1109/ieeestd.2008.4610935).
- (2019). *IEEE standard for floating-point arithmetic*. IEEE. DOI: [10.1109/ieeestd.2019.8766229](https://doi.org/10.1109/ieeestd.2019.8766229).
- Ismail, R. Che et al. (July 2011). "ROM-less LNS". In: *2011 IEEE 20th Symposium on Computer Arithmetic*. IEEE, pp. 43–51. DOI: [10.1109/arith.2011.15](https://doi.org/10.1109/arith.2011.15).