

① Representações de números no computador

- \* bit : → 0 ou 1 (com ou sem sinal)
- menor unidade de informação
- números binários

\* Representações dos números :

$$(1328)_{10} = 1 \times 10^3 + 3 \times 10^2 + 2 \times 10^1 + 8 \times 10^0 \\ = 1000 + 300 + 20 + 8$$

⇒ em qualquer base:

$$(a_3 a_2 a_1 a_0)_\beta = (a_3 \beta^3 + a_2 \beta^2 + a_1 \beta^1 + a_0 \beta^0)_{10}$$

onde  $0 \leq a_i \leq \beta - 1$

$$\Rightarrow \text{base } 2: (10010)_2 = (1 \times 2^4 + 0 \times 2^3 + 0 \times 2^2 + 1 \times 2^1 + 0 \times 2^0)_{10} \\ = (16 + 2)_{10} = (18)_{10}$$

$$\bullet (0)_2 = (0 \times 2^0)_{10} = (0)_{10}$$

$$\bullet (1)_2 = (1 \times 2^0)_{10} = (1)_{10}$$

$$\bullet (10)_2 = (1 \times 2^1 + 0 \times 2^0)_{10} = (2)_{10}$$

$$\bullet (11)_2 = (1 \times 2^1 + 1 \times 2^0)_{10} = (3)_{10}$$

$$\bullet (100)_2 = (1 \times 2^2 + 0 \times 2^1 + 0 \times 2^0)_{10} = (4)_{10}$$

•  $(28)_{10} = ?$

$= (11100)_2$

$$\begin{array}{r} 28 \\ \underline{14} \\ \underline{7} \\ \underline{3} \\ \underline{1} \\ \underline{0} \end{array}$$

•  $x = 2 \rightarrow (10)_2 \rightarrow 2$  bits

•  $x = 0,25 ?$

•  $x = 1/3 = 0,333 \quad ?$

•  $x = \sqrt{2} \quad ?$

↳ irracional,  $\neq \frac{A}{B}$

} não tem solução exata no computador

números reais  $\xrightarrow[\text{inteiros } \mathbb{Z}]{\text{infinitos}} \mathbb{R}$  (infinitos)  
 $\xrightarrow{\text{float}} \mathbb{F} \rightarrow$  ponto flutuante  
 $\mathbb{Z}$   
 (infinitos contáveis  $\rightarrow \mathbb{N}$ )

$\Rightarrow \mathbb{F} \rightarrow$  ponto flutuante  $\rightarrow$  número finito de casas decimais  
 ↳ arredondamento

$x = 1/3 = 0,3333$

$x = 2/3 = 0,6667$

$\Rightarrow$  posição do número decimal não é fixa

$$x = (-1)^s (0.\underbrace{a_1 a_2 \dots a_t}_m) \beta^e = (-1)^s m \beta^{e-t}$$

•  $\beta = \text{base} \geq 2$  (inteiros)

•  $m = \text{mantissa}$  (inteiros)  $0 \leq a_i \leq \beta-1$

•  $e = \text{exponente}$  (inteiros)

•  $s = \text{signo}$   $\begin{cases} 0 & \oplus \\ 1 & \ominus \end{cases}$

$$\text{ex}) \cdot 250 = (-1)^0 0,25 \cdot 10^3 = (-1)^0 \textcircled{25} \cdot 10^{\textcircled{1}}$$

$$\cdot -0,33 = (-1)^1 0,33 \cdot 10^0 = (-1)^1 \textcircled{33} \cdot 10^{\textcircled{-2}}$$

$$\cdot 0,001 = (-1)^0 0,1 \cdot 10^{-2} = (-1)^0 \textcircled{1} \cdot 10^{\textcircled{-3}}$$

obs: se  $a_1 \neq 0$ , representação é única.

### \* Padrão IEEE 754

$$(-1)^s \textcircled{1} \cdot m \times 2^{e-b}$$


$\hookrightarrow$  implícito

nível

$$E = e - b$$

- byte = 8 bits
- half = 16 bits (2 bytes)
- single = 32 bits (4 bytes)
- double = 64 bits (8 bytes)

half:



Cases especiais:

0 00000	0000000000	$\rightarrow (0)_{10}$
0 11111	"	$\rightarrow +\infty$
1 11111	"	$\rightarrow -\infty$

$$\text{obs: } e = \begin{cases} 00000 \\ 11111 \end{cases} \quad \text{são casos especiais}$$

$$(1)_{10} = (1)_2 \Rightarrow 0 01111 0000000000$$

$$= 1 \times 2^0 = (-1)^0 1.0 \cdot 2^0 \quad s=0, m=0, E=0$$

④

$\Rightarrow$  half: 16 bits: 1(s), 5(e), 10(m)  $F(2, 11, -14, 15)$

- $e_{\max} = (11110)_2 = (30)_{10}$

- $e_{\min} = (00001)_2 = (1)_{10}$

- $e = [1, 30] \Rightarrow b=15 \Rightarrow E=[-14, 15]$

múltiplos pequenos  
↓

↑ múltiplos grandes

- $|x|_{\max} = 0111101111111111$

$$= (-1)^0 (1, 1111111111) \times 2^{(11110)_2 - (15)_{10}}$$

$$= [1 \times 2^0 + (1 - 2^{-10})] \times 2^{15}$$

$$= (2 - 2^{-10}) 2^{15} = 65504 = 6,55 \times 10^4$$

- $|x|_{\min} = 000001000000000$

$$= (-1)^0 1,0 \times 2^{(00001)_2 - (15)_{10}}$$

$$= 1 \times 2^{-14} = 1/16384 = 6,10 \times 10^{-5}$$

- precisão: 10 (mantissa) + 1 = 11 bits

$$p_{10} = 3$$

(5)

$\Rightarrow$  single: 32 bits: 1(s), 8(e), 23(m)

$$F(2, 24, -126, 127)$$

- $e_{\max} = (1111111110)_2 = (254)_{10}$
- $e_{\min} = (0000000001)_2 = (1)_{10}$
- $e = [1, 254] \Rightarrow b = 127 \Rightarrow E = [-\underline{126}, \underline{127}]$
- $|x|_{\max} = (2 - 2^{-23}) \cdot 2^{\underline{127}} = 3,4028235 \times 10^{38}$
- $|x|_{\min} = 1 \times 2^{-\underline{126}} = 1,1754944 \times 10^{-38}$
- $p_{10} = 7 \quad (24 \text{ bits em } \beta=10)$

$\Rightarrow$  double: 64 bits: 1(s), 11(e), 52(m)  $F(2, 53, -1022, 1023)$

- $e_{\max} = (111111111110)_2 = (2046)_{10}$
- $e_{\min} = (000000000001)_2 = (1)_{10}$
- $e = [1, 2046] \Rightarrow b = 1023 \Rightarrow E = [-1022, 1023]$
- $|x|_{\max} = (2 - 2^{-52}) 2^{1023} = 1,797693 \dots \times 10^{308}$
- $|x|_{\min} = 1 \times 2^{-1022} = 2,2250 \dots \times 10^{-308}$
- $p_{10} = 15 \quad (53 \text{ bits em } \beta=10)$

$$F(\beta, t, L, U) \quad L \leq E \leq U$$

obs: Quaternions:  $F(2, 53, -1021, 1024) \Rightarrow (-1)^s 0.1 m 2^{e-b}$

## Aula 2

①

① Representações de números no computador

⇒ ponto flutuante:  $F(\beta, t, L, U)$ ,  $L \leq E \leq U$

\* Padrão IEEE 754:  $x = (-1)^s \underbrace{1.m}_{\text{decimal}} \cdot 2^{e-b}$   $\leftarrow$  bias  
implícito

$$\begin{cases} \beta = \text{base} = 2 \\ t = \text{precisão binária} = m+1 \quad (m = \text{mantissa}) \\ E = \text{exponente} = e-b \end{cases}$$

• half:  $F(2, 11, -14, 15)$   $\begin{cases} 16 \text{ bits: } 1(s), 5(e), 10(m) \\ b = 15 \end{cases}$

• single:  $F(2, 24, -126, 127)$   $\begin{cases} 32 \text{ bits: } 1(s), 8(e), 23(m) \\ b = 127 \end{cases}$

• double:  $F(2, 53, -1022, 1023)$  64 bits: 1(s), 11(e), 52(m)

ex:  $\begin{cases} n = (1)_{10} \\ n = (1)_2 \end{cases}$   $n = (-1)^0 1,0 \cdot 2^0$   $s = 0, E = 0, m = 0$   
 $e = E + b = 0 + 15 = (15)_{10}$   
 $e = 1111$

$$n_{\text{half}} = 0\ 01111\ 0000000000$$

obs: Quaternoni: ~~single~~ <sup>double</sup>:  $F(2, 53, -1021, 1024)$

$$\text{pois } n = (-1)^s 0,1_m \cdot 2^{e-b}$$

$$|n|_{\min} = 2^L, \quad |n|_{\max} = (2 - 2^{-m}) 2^U$$

\* precisão em decimal:

- half : 11 bits em  $\beta=2 \Rightarrow (1111111111)_2 = (2047)_{10}$   
 $p_{10} = 3$  (até 999)
- single: 24 bits em  $\beta=2 \Rightarrow (111\dots11)_2 = 16.777.215$   
 $p_{10} = 7$  (até 999.999)
- double: 53 bits em  $\beta=2 \Rightarrow (111\dots11)_2 = ?$   
 $p_{10} = 15$

$$\left\{ \begin{array}{l} * |x| > |x|_{\max} \Rightarrow \text{overflow } (\pm\infty) \\ * |x| < |x|_{\min} \Rightarrow \text{underflow } (\text{zero}) \end{array} \right.$$


\* exemplo memória: 1 milhão de dados

- half :  $10^6 \times 2 \text{ bytes} \approx 2 \text{ Mb}$
- single:  $10^6 \times 4 \text{ bytes} \approx 4 \text{ Mb}$
- double:  $10^6 \times 8 \text{ bytes} \approx 8 \text{ Mb}$

↳ usado pela RAM ou armazenamento binário

↳ ASCII → caracteres que representam números  $\Rightarrow \sim 3 \times$  arquino binário.

1.1 Erro em ponto flutuante:



- $EA_n = |x - \hat{x}| \rightarrow$  erro absoluto, minimizado na escolha de  $\hat{x}$  (arredondamento)

- $ER_n = \frac{|x - \hat{x}|}{|x|} \rightarrow$  erro relativo,  $\sim$  constante em ponto flutuante

$$\text{ex}) \quad \beta = 10, \quad p_{10} = 4$$

$\Rightarrow$  ponto fixo:

$$\left. \begin{array}{l} a) \quad n = 3507,6 \\ \hat{n} = 3508 \end{array} \right\} \quad EA_n = 0,4$$

$$ER_n = \frac{0,4}{3507,6} \approx 1,1 \times 10^{-4}$$

$$\left. \begin{array}{l} b) \quad n = 0,0035076 \\ \hat{n} = 0,004 \end{array} \right\} \quad EA_n = 0,0004924$$

$$EA_n \approx 0,14$$

$\Rightarrow$  ponto flutuante:


$$\left. \begin{array}{l} a) \quad n = 3507,6 = 3,5076 \times 10^3 \\ \hat{n} = 3,508 \times 10^3 \end{array} \right\} \quad EA_n = 0,4$$

$$ER_n \approx \underline{1,1 \times 10^{-4}}$$

$$\left. \begin{array}{l} b) \quad n = 0,0035076 = 3,5076 \times 10^{-3} \\ \hat{n} = 3,508 \times 10^{-3} \end{array} \right\} \quad EA_n = 0,0004 \times 10^{-3}$$

$$ER_n = \frac{0,0004 \times 10^{-3}}{3,5076 \times 10^{-3}} \approx \underline{1,1 \times 10^{-4}}$$

obs: quanto maior o valor absoluto, maior o erro absoluto e o deslocamento na reta  $\mathbb{R}$



\* operações aritméticas com ponto flutuante

$$\text{a) associativa: } (2 + 3) + 4 = 2 + (3 + 4)$$

$$(2 \cdot 3) \cdot 4 = 2 \cdot (3 \cdot 4)$$

$\times \quad \mathbb{F}$

b) comutativa:  $x + y = y + x$  ✓ F  
 $xy = yx$

c) distributiva:  $2(1+3) = 2 \cdot 1 + 2 \cdot 3$  X F

erros de arredondamento a cada operação.

ex)  $\left\{ \begin{array}{l} (23,4 + 5,18) + 3,05 = 31,7 \\ 23,4 + (5,18 + 3,05) = 31,6 \end{array} \right.$

ex)  $\left\{ \begin{array}{l} 3,18 (5,05 + 11,4) = 52,5 \\ 3,18 \cdot 5,05 + 3,18 \cdot 11,4 = 52,4 \end{array} \right.$

ex)  $\frac{(1+n)-1}{n} = 1$

se  $n = 1 \times 10^{-15}$  (próximo da precisão de máquina)

$$\frac{(1+n)-1}{n} = 1,1102\dots \text{ erro de } 11\% \quad \text{D}$$

obs: trabalhe com números na ordem de 1 !

- Cap 1 Quaternioni: