

② Representações de números no computador:
 ↴
 (Quaternomi, polif)

~~Eng. Amb. 2024
Aula ①~~

* bit (0 ou 1), com ou sem corrente elétrica

→ menor unidade de informação

→ números binários

* representação de números:

$$(1238)_{10} = 1 \times 10^3 + 2 \times 10^2 + 3 \times 10^1 + 8 \times 10^0 \\ = 1 \times 1000 + 2 \times 100 + 3 \times 10 + 8 \times 1 = 1238$$

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

$$(\text{número } 0 \text{ e } 1) = 1 \times 16 + 0 \times 8 + 0 \times 4 + 1 \times 2 + 0 \times 1 \\ = 16 + 2 = (18)_{10}$$

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

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


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

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

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

;

$$\text{ex}) (28)_{10} \quad \begin{array}{r} 28 \\ \textcircled{0} \end{array} \quad \begin{array}{r} 2 \\ | \\ 14 \end{array} \quad \begin{array}{r} 2 \\ | \\ 0 \end{array} \quad = (11100)_2$$



precisamos de 5 bits,
 para representar $(28)_{10}$
 na computador.

* Números reais: $\longrightarrow \mathbb{R}$ (infinitos)

$$n = 0,25$$

$$n = \frac{1}{3} = 0,333\dots$$

$$n = \sqrt{2} \text{ (irracional, } \neq \frac{A}{B})$$

\Rightarrow Ponto flutuante: número finito de casas decimais

$$n = (-1)^s \cdot 0.\underbrace{a_1 a_2 \dots a_t}_{\text{mantissa } m} \times \beta^e$$

$$\begin{cases} s \rightarrow \text{signo} \\ m \rightarrow \text{mantissa} \\ e \rightarrow \text{exponente} \end{cases} \quad \beta \rightarrow \text{base}$$

$$\text{ex)} \cdot 250,32 \Rightarrow (-1)^0 \underbrace{0,25032}_{0,25032} \times 10^3$$

$$\cdot -0,33 \Rightarrow (-1)^1 \underbrace{0,33}_{0,33} \times 10^0$$

$$\cdot 0,001 \Rightarrow (-1)^0 \underbrace{0,1}_{0,1} \times 10^{-2}$$

obs: se $a_1 \neq 0$, representações são únicas

* Padrão IEEE 754: base 2, armazena: S (0 ou 1)


$\begin{matrix} m \\ e \end{matrix} \left. \right\} \text{em binário}$

- byte = 8 bits

- half = 16 bits (2 bytes)

- single = 32 bits (4 bytes)

- double = 64 bits (8 bytes)



* half: . 5 bits e, 10 bits m (16 total)

- $|x_{\max}| = 0,655 \times 10^5$
- $|x_{\min}| = 0,610 \times 10^{-4}$
- precisão decimal: 3 casas

* single: . 8 bits e, 23 bits m (32 total)

- $|x_{\max}| = 0,3402824 \times 10^{39}$
- $|x_{\min}| = 0,1175494 \times 10^{-37}$
- precisão decimal: 7 casas

* double: . 11 bits e, 52 bits m (64 total)


- $|x_{\max}| = 0,1797693\dots \times 10^{309}$
- $|x_{\min}| = 0,22250\dots \times 10^{-307}$
- precisão decimal: 15 casas

Obs: se $|x| < |x_{\min}| \rightarrow x = 0$ (underflow)

se $|x| > |x_{\max}| \rightarrow \pm\infty$ (overflow)

* exemplo de memória: 1 milhões de dados:

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

* erro em ponto flutuante: 

• arredondamento: minimiza o erro absoluto $|x - \hat{x}|$.

• erro relativo: $\frac{|x - \hat{x}|}{|x|}$ é aprox. constante para qualquer x .

ex) precisão de 4 casas decimais:

\Rightarrow ponto fixo:

$$\left. \begin{array}{l} a) x = 3507,6 \\ \hat{x} = 3507 \end{array} \right\} \begin{array}{l} |x - \hat{x}| = 0,4 \quad (\text{erro absoluto}) \\ \frac{|x - \hat{x}|}{|x|} \approx 1,1 \times 10^{-4} \quad (\text{erro relativo}) \end{array}$$

$$\left. \begin{array}{l} b) x = 0,0035076 \\ \hat{x} = 0,004 \end{array} \right\} \begin{array}{l} |x - \hat{x}| = 0,0004924 \quad (\text{erro absoluto}) \\ \frac{|x - \hat{x}|}{|x|} \approx 0,14 \quad (\text{erro relativo}) \end{array}$$

\Rightarrow ponto flutuante:

$$\left. \begin{array}{l} a) x = 3507,6 = 0,35076 \times 10^4 \\ \hat{x} = 0,3508 \times 10^4 \end{array} \right\} \begin{array}{l} |x - \hat{x}| = 0,4 \\ \frac{|x - \hat{x}|}{|x|} \approx 1,1 \times 10^{-4} \end{array}$$

$$\left. \begin{array}{l} b) x = 0,0035076 = 0,35076 \times 10^{-2} \\ \hat{x} = 0,3508 \times 10^{-2} \end{array} \right\} \begin{array}{l} |x - \hat{x}| = 0,0004 \\ \frac{|x - \hat{x}|}{|x|} \approx 1,1 \times 10^{-4} \end{array}$$

erro relativo da ordem da precisão

* operações aritméticas com ponto flutuante:

a) associativa $(x+y)+z \neq (x+z)+y \times \text{em F}$

b) comutativa: $x+y = y+x \checkmark$

$$xy = yx \checkmark$$

c) distributiva: $x(y+z) \neq xy + xz \times \text{em F}$

obs: trabalhe com números na ordem de 1 !

ex) $\frac{(1+x)-1}{x}$

Revisão: • números em computador: ponto flutuante

$$n = (-1)^s 0.m \times 2^e \quad \begin{matrix} s \\ 1 \end{matrix} \text{ e } \begin{matrix} m \\ 1 \end{matrix} \text{ bits (binário)}$$

• single: 32 bits (4 bytes), $(-1)^s \underbrace{0, a_1 a_2 a_3 a_4 a_5 a_6 a_7}_7 \times \underline{10}^e$
 $-37 \leq e \leq 39$ 7 casas em decimal

• double: 64 bits (8 bytes), $(-1)^s \underbrace{0, a_1 a_2 \dots a_{15}}_{15} \times \underline{10}^e$
 $-307 \leq e \leq 309$ 15 casas em decimal

\Rightarrow ordem das operações importa \Rightarrow uso de arredondamento

\Rightarrow trabalhar com números na ordem de 1