

1

~~2023~~ CÁLCULO NÚMÉRICO "existem 10 tipos de pessoas no mundo..."

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

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

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

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

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

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

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

• $(28)_{10} = ?$

$= (11100)_2$

$$\begin{array}{r} 28 \quad |2 \\ \textcircled{0} \quad 14 \quad |2 \\ \textcircled{0} \quad 7 \quad |2 \\ \textcircled{1} \quad 3 \quad |2 \\ \textcircled{1} \quad 1 \quad |2 \\ \textcircled{1} \quad 0 \end{array}$$

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

• $x = 0,25 ?$

• $x = 1/3 = 0,333 \quad ?$

• $x = \sqrt{2} \quad ?$

↳ irracional, $\neq \frac{A}{B}$

} não tem solução exata no computador

números reais $\xrightarrow{\text{inteiros}} \mathbb{R}$ (infinitos)

$\underbrace{\dots}_{\text{inteiros}} \mathbb{F} \rightarrow \text{ponto flutuante}$

\mathbb{Z}

(infinitos contínuos $\rightarrow \mathbb{N}$)

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

$$x = 1/3 = 0,3333$$

$$x = 2/3 = 0,6667$$

\Rightarrow posição do número decimal não é fixa

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

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

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

• $e = \text{exponente}$ (inteiro)

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

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

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

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

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

* Padrão IEEE 754

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


\hookrightarrow implícito

niés

$$E = e - b$$

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

half:



Cases especiais:

$$\left\{ \begin{array}{lll} 0 & 00000 & 0000000000 \rightarrow (0)_{10} \\ 0 & 11111 & " \rightarrow +\infty \\ 1 & 11111 & " \rightarrow -\infty \end{array} \right.$$

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

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

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

⇒ half: 16 bits: 1(s), 5(e), 10(m) ④
 $F(2, 11, -14, 15)$

- $e_{\max} = (11110)_2 = (30)_{10}$
 - $e_{\min} = (00001)_2 = (1)_{10}$ números pequenos
 - $e = [1, 30] \Rightarrow b=15 \Rightarrow E=[-14, 15]$
- \downarrow
 \uparrow
números grandes

$$\begin{aligned}
 \bullet |x|_{\max} &= 011110 \quad 111111111111 \\
 &= (-1)^0 (1, 111111111111)_2 \times 2^{(11110)_2 - (15)_{10}} \\
 &= [1 \times 2^0 + (1 - 2^{-10})] \times 2^{15} \\
 &= (2 - 2^{-10}) 2^{15} = 65504 = 6,55 \times 10^4
 \end{aligned}$$

$$\begin{aligned}
 \bullet |x|_{\min} &= 000001 \quad 0000000000 \\
 &= (-1)^0 1,0 \times 2^{(00001)_2 - (15)_{10}} \\
 &= 1 \times 2^{-14} = 1/16384 = 6,10 \times 10^{-5}
 \end{aligned}$$

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

$$\varphi_{10} = 3$$

(5)

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

$$\mathbb{F}(2, 24, -126, 127)$$

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

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

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

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

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

Aula 2

(1)

- ① Representações de números no computador

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

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

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

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

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

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

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

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

obs: Quaternoni: ~~single~~ ^{double}: $F(2, 53, -1021, 1024)$

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

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

* 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 9.999.999)

- 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 $\Rightarrow \sim 3 \times$ arquivos binários.

1.1 Erros 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:

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


$$\left. \begin{array}{l} b) \quad n = 0,0035076 \\ \hat{n} = 0,004 \end{array} \right\} \begin{array}{l} EA_n = 0,0004924 \\ EA_n \approx 0,14 \end{array}$$

\Rightarrow ponto flutuante:

$$\left. \begin{array}{l} a) \quad n = 3507,6 = 3,5076 \times 10^3 \\ \hat{n} = 3,508 \times 10^3 \end{array} \right\} \begin{array}{l} EA_n = 0,4 \\ ER_n \approx 1,1 \times 10^{-4} \end{array}$$

$$\left. \begin{array}{l} b) \quad n = 0,0035076 = 3,5076 \times 10^{-3} \\ \hat{n} = 3,508 \times 10^{-3} \end{array} \right\} \begin{array}{l} EA_n = 0,0004 \times 10^{-3} \\ ER_n = \frac{0,0004 \times 10^{-3}}{3,5076 \times 10^{-3}} \approx 1,1 \times 10^{-4} \end{array}$$

obs: quanto maior o valor absoluto, maior o erro absoluto e o espaçamento na reta \mathbb{F}



* operações aritméticas com ponto flutuante

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

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

$\times \quad \mathbb{F}$

(4)

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 $n = 1 \cdot 10^{-15}$ (próximo da preciso de máxima)

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

obs: trabalhe com números na ordem de 1 !

- Cap 1 Quaternioni: