

ARITMETICA di MACCHINA

$$x = 123456.789$$

\uparrow \uparrow \uparrow
 10^1 10^0 10^{-1}
 10^{-2}

notazione posizionale

forme esponentiali

$$x = 0.\underbrace{123456789}_{\substack{\text{mantissa} \\ \in \mathbb{Z}}} \cdot 10^6$$

esponente delle base
base di rapp.
 $\in \mathbb{Z}$

$$x = 1.23456789 \cdot 10^5$$

forma esponentiale

$$\parallel x = (-1)^s 0.a_1a_2 \dots a_t \cdot \beta^e \parallel$$

forma esponentiale

con $s \in \{0,1\}$ $a_i \in \{0, 1, \dots, \beta-1\}$

β = base di rappresentazione

t = n° cifre mantissa


$e \in \mathbb{Z}$ esponente delle base

Sistema FLOATING POINT

$$\mathbb{F}(\beta, t, L, U) = \left\{ x = (-1)^s 0.a_1a_2 \dots a_t \cdot \beta^e \text{ con } s \in \{0,1\}, a_i \in \{0, 1, \dots, \beta-1\} \text{ per } i=1, \dots, t, \underbrace{a_1 \neq 0,}_{a_1 \neq 0} L < 0, U > 0, L \leq e \leq U \right\} \cup \{0\}$$

• Sistemi F semplice precisione

$B=2$ registro di 4 Byte



float in C, C++

$$\text{Se } \alpha_1 \neq 0 \Rightarrow \alpha_1 = 1$$

23 bit per m, ma $t=24$
L, U


• Sistemi doppia precisione

$B=2$ 8 Byte = 64 bit double in C, C++



$$.52 \text{ bit per m} \Rightarrow t=53$$

$$L = \underline{-1021} \quad U = 1024 \quad 1021 + 1 + 1024 = 2046$$



F è simmetrico rispetto a 0

è limitato

è finito (condizionalità finita)

$$\text{card}(F) = 2 \beta^{t-1} (\beta-1) (U-L+1)$$

i floating point non sono equamente distribuiti

Esempio

$$F(\beta=2, t=3, L=-2, U=3)$$

$$x = (-1)^s \cdot a_1 a_2 a_3 \cdot \beta^e$$

$$-2 \leq e \leq 3$$

$x_{\min} = \underbrace{0.100}_{\text{base 2}} \cdot \underbrace{2^{-2}}_{\text{-leggo in base 10}} = \frac{1}{2} \cdot \frac{1}{4} = \frac{1}{8} = \frac{4}{32}$

$$0.\underline{101} \cdot 2^{-2} = \left(\frac{1}{2} + \frac{1}{8} \right) \cdot \frac{1}{4} = \frac{5}{8} \cdot \frac{1}{4} = \frac{5}{32}$$

$$0.110 \cdot 2^{-2} = \left(\frac{1}{2} + \frac{1}{4} \right) \cdot \frac{1}{4} = \frac{3}{4} \cdot \frac{1}{4} = \frac{3}{16} = \frac{6}{32}$$

$$0.111 \cdot 2^{-2} = \left(\frac{1}{2} + \frac{1}{4} + \frac{1}{8} \right) \cdot \frac{1}{4} = \frac{7}{8} \cdot \frac{1}{4} = \frac{7}{32}$$

$$0.\underline{100} \cdot 2^{-1} = \frac{1}{2} \cdot \frac{1}{2} = \frac{1}{4} = \frac{8}{32} = \frac{4}{16}$$

$$0.\underline{101} \cdot 2^{-1} = \frac{5}{8} \cdot \frac{1}{2} = \frac{5}{16}$$


$$\frac{6}{16}$$

$$\frac{7}{16}$$

$$\frac{8}{16}$$

$$2$$

$$\frac{8}{16} = \frac{4}{8} = \frac{1}{2}$$



precisione di macchine

$\tilde{\epsilon}$ la distanza tra 1 e il $t+1$ numero di F

maggiorre di fatto di 1.

26/09 /2023

$$1 = 0.100 \cdot \beta^1$$

$$a = 0.101 \cdot \beta^1$$

$$\underline{\epsilon_n = a - 1 = 0.001 \cdot \beta^1 = \beta^{-t} \cdot \beta^1 = \beta^{1-t}}$$

↑
posiz. t

$$\boxed{\epsilon_n = \beta^{1-t}}$$

Nell'esempio avevo $\beta=2$ e $t=3 \Rightarrow \epsilon_n = 2^{-2} = \frac{1}{4}$

in semplice precisione $\epsilon_n = 2^{1-24} \sim 10^{-7}$


in doppia precisione $\epsilon_n = 2^{1-53} = 2^{-52} \sim 2.22 \cdot 10^{-16}$

(eps)

$x \in \mathbb{R}$,

$$\boxed{1 < x < 1 + \epsilon_n}$$

$\Rightarrow x \notin \mathbb{F}$



$$fl_t(x) = 1$$

$fl_t(x)$ è l'arrotondimento di x in \mathbb{F}

$$|x - fl_t(x)| \leq \frac{1}{2} \epsilon_n$$

$$u = \frac{1}{2} \epsilon_n$$

entità di arrotondamento

(roundoff unit)

Più in generale :

$$|x - f_{lt}(x)| \leq \frac{1}{2} \varepsilon_{fl} \cdot |x|$$

se $x \neq 0$

$$\frac{|x - f_{lt}(x)|}{|x|} \leq \frac{1}{2} \varepsilon_{fl}$$

errore di arrotondamento relativo

Proprietà dell'aritmetica classica
che codice in \mathbb{F}

1) $\exists !$ lo zero come elemento neutro
delle somme

cioè $\exists x \in \mathbb{F}$ con $x \neq 0$: $1+x=1$

es: $x = \beta^{-2t} = 2^{-106} \in \mathbb{F}$
 $(t=53)$

$$1 = 0.1\ldots0 \overset{+}{\underset{t}{\cdot}} \beta^1$$

$$x = 0.1\ldots0 \cdot \beta^{-2t+1}$$

Allora vedo gli esponenti fra:

$$1 = 0.1\ldots0 \cdot \beta^1$$

si perde nel fare la somma

$$x = 0.0\ldots0 \cdot \beta^{-2t+1}$$

↑
t-cifre
↑
2t-cifre

$$1+x = 0.1\ldots0 \cdot \beta^1$$

2) See F code is non associative
 di + e -

prop. are : $(a_1 + a_2) + a_3 = a_1 + (a_2 + a_3)$
 $(a_1 \cdot a_2) \cdot a_3 = a_1 \cdot (a_2 \cdot a_3)$

(es)

$$a_1 = 10^{308}$$

$$a_2 = 10^{308}$$

$$a_3 = -4 \cdot 10^{307}$$

F doppia precisione

$$x_{\max} \approx 1.7 \cdot 10^{308}$$

$$(a_1 + a_2) + a_3 = \underbrace{2 \cdot 10^{308}}_{> x_{\max}} - 4 \cdot 10^{307} = \text{NaN}$$

NaN

$$a_1 + (a_2 + a_3) = 10^{308} + \underbrace{\left(10^{308} - 4 \cdot 10^{307}\right)}_{< x_{\max}}$$

Es 2 $x \neq 0$

$$\frac{1 + (-1 + x)}{x} = \frac{(1-1)+x}{x} = 1 \quad \text{ne center}$$



Propagazione degli errori di arroto aritmetico

(+)

$$x, y \in \mathbb{R}$$

$$\bar{x} = \text{fl}_t(x)$$

$$\bar{y} = \text{fl}_t(y)$$

$$\text{ma c'è} \quad x+y \quad \leftarrow \\ \text{in } \mathbb{F} \quad \text{ho} \quad \text{fl}_t(\bar{x}+\bar{y}) \leftarrow$$

$$\frac{|\text{fl}_t(\bar{x}+\bar{y}) - (x+y)|}{|x+y|}$$

si riesce a dimo

$$\leq \left(\frac{|x| + |y|}{|x+y|} + 1 \right) u$$

$$\text{se } \underline{x} = 1 + 10^{-15} \quad \underline{y} = -1$$

$$\sim \frac{2}{10^{-15}} + 1$$

$$\sim 2 \cdot 10^{15}$$

$$\leq 2 \cdot 10^{15} \cdot 10^{-16}$$

$$\sim \underline{2 \cdot 10^{-1}}$$

la somma è un'operazione
potenzialmente
instabile

$$\textcircled{1} \quad \frac{|f_{\bar{x}}(\bar{x} \cdot \bar{y}) - (x \cdot y)|}{|x \cdot y|} \leq 3 u$$

Il prodotto è un'op. stabile
e piccoli errori sui dati corrispondono
piccoli errori nella soluzione