

Corso di Calcolatori Elettronici

Rappresentazione dei numeri reali in un calcolatore

Prof. Roberto Canonico



Università degli Studi di Napoli Federico II
Dipartimento di Ingegneria Elettrica e
delle Tecnologie dell'Informazione

Rappresentazione di numeri reali

- Con un numero finito di cifre non è possibile rappresentare esattamente un qualsiasi numero reale
- Con un numero finito di cifre è possibile rappresentare solo un sottoinsieme finito di numeri razionali
- *Dato un numero reale arbitrario r , con un numero finito di cifre è possibile rappresentare un numero razionale r' che approssima con un certo errore il numero reale r*
- Nelle macchine digitali vengono usate due notazioni:

A) Notazione in virgola fissa

Dedica parte delle cifre alla parte intera e le altre alla parte frazionaria

± XXX.YY

B) Notazione in virgola mobile

Dedica alcune cifre a rappresentare un esponente della base che indica l'ordine di grandezza del numero rappresentato

Numeri reali: rappresentazione in virgola fissa

- Quando di un numero frazionario si rappresentano separatamente la parte intera e la parte frazionaria si parla di rappresentazione in *virgola fissa*
 - La rappresentazione dei due contributi può essere realizzata secondo una delle tecniche viste in precedenza
 - La parte frazionaria è rappresentata con un numero finito m di cifre binarie, scalata di un fattore 2^m che la rende intera
 - La posizione della virgola è fissa e resta sottintesa
-

Numeri reali in virgola fissa

- La stringa

$$,b_{-1}b_{-2}\dots b_{-m}$$

si interpreta come

$$b_{-1}2^{-1} + b_{-2}2^{-2} + \dots + b_{-m}2^{-m}$$

- Esempio:

$$.1011$$

si interpreta come

$$2^{-1} + 2^{-3} + 2^{-4} = 1/2 + 1/8 + 1/16 = 0,5 + 0,125 + 0,0625 = 0,6875$$

ovvero come

$$11 / 16 = 0,6875$$

- La stringa 1011 è rappresentativa dell'intero $(11)_{10}$ che va scalato del fattore 2^{-4}
-

Numeri reali: rappresentazione in virgola mobile

- Un numero reale x può essere rappresentato dalla tripla

$$(s, m, e)$$

tale che:

$$x = (-1)^s \cdot m \cdot b^e$$

- s è il segno ($s=0$ positivo, $s=1$ negativo)
 - m è detta *mantissa*
 - e è detto *esponente*
 - b è la base di numerazione adottata
- In macchina sia m che e hanno un numero prefissato di cifre
 - intervalli limitati ed errori di arrotondamento
-

Vantaggi della rappresentazione in virgola mobile

- La notazione a virgola mobile permette di rappresentare un ampio intervallo di valori con un numero di cifre prefissato, grazie alla **flessibilità della posizione della virgola**, che dipende dal valore dell'esponente
 - Esempi (in base 10):
considerando 3 cifre per la mantissa e 2 per l'esponente
 - PI Greco: 0.314×10^1
 - Massa di un Elettrone (kg): 0.911×10^{-30}
 - Massa della Via Lattea (kg): 0.136×10^{43}

Rappresentazione finita e discreta dei numeri reali

- In un intervallo, comunque piccolo, esistono infiniti numeri reali
 - i numeri reali formano un continuo
 - I numeri rappresentabili con un numero finito di cifre costituiscono invece un sottoinsieme finito
 - Ciascun elemento di questo sottoinsieme sarà chiamato a rappresentare i numeri reali che si trovano "nell'intorno"
 - In altri termini, diviso l'insieme dei numeri reali in intervalli di fissata dimensione, si ha che ogni $x \in [X_i, X_{i+1}[$ viene rappresentato con il valore $X = X_i$
 - Nota: gli intervalli $[X_i, X_{i+1}[$ non hanno tutti la stessa ampiezza a causa della finitezza del numero di cifre della mantissa
-


Normalizzazione

- Per ciascun numero esistono infinite coppie mantissa-esponente che lo rappresentano
 - Esempio (b=10):
 - 346.09801 è rappresentato da
 - » $m = 346.09801$, $e = 0$ oppure
 - » $m = 346098.01$, $e = -3$ oppure
 - » $m = 0.034609801$, $e = 4$ ecc...
 - Per **rappresentazione normalizzata** del numero si intende convenzionalmente quella in cui la mantissa ha la prima cifra a destra della virgola diversa da zero
 - ovvero: $1/b \leq m < 1$
 - Esempio:
 $m = 0.34609801$, $e = 3$
-

Esempio: intervallo di rappresentazione

- Con $b=10$, usando 4 cifre per m e 2 per e (più due bit per i relativi segni), l'insieme rappresentabile (utilizzando solo rappresentazioni normalizzate) è:

$$[-0.9999 \times 10^{99}, -0.1000 \times 10^{-99}] \cup \{0\} \cup [+0.1000 \times 10^{-99}, +0.9999 \times 10^{99}]$$




Con le stesse $6=4+2$ cifre in virgola fissa $\pm \text{XXXX} . \text{YY}$:

- L'intervallo scende **$[-9999.99, +9999.99]$**
- Ma si hanno **6** cifre significative invece di **4**

La discretizzazione di \mathbb{R}

- Essendo l'insieme reale **denso**, per ogni coppia di elementi distinti di \mathbb{R} vi è sempre un elemento compreso tra i due
 - I valori rappresentabili di \mathbb{R}^* sono un sottoinsieme che contiene un numero finito di valori reali



I valori rappresentabili **NON** sono equidistanti nell'intervallo di rappresentazione!

Ogni elemento in \mathbb{R}^* approssima un intervallo di valori del continuo

Approssimazione


- Errore assoluto: $e_A = |r - r'|$
 - Errore relativo: $e_R = |r - r'| / |r|$
 - Nella rappresentazione in virgola mobile l'errore assoluto non è costante
 - L'errore di approssimazione è piccolo in prossimità dello zero e va aumentando progressivamente a mano a mano che il numero aumenta (in valore assoluto)
 - Ad esempio:
 - in prossimità dello zero l'errore massimo che può essere commesso è $0.1001 * 10^{-99} - 0.1000 * 10^{-99} = \mathbf{0.0001 * 10^{-99}}$
 - in prossimità dell'estremo superiore dell'intervallo di rappresentazione, invece, l'errore massimo che si può commettere è $0.9999 * 10^{99} - 0.9998 * 10^{99} = \mathbf{0.0001 * 10^{99}}$
 - Si commettono quindi “errori piccoli” su “numeri piccoli” ed “errori grandi” su “numeri grandi”
 - Quello che resta inalterato è invece l'errore relativo, costante su tutto l'asse di rappresentabilità
-

Overflow e Underflow


- L'errore relativo dipende dal numero di cifre della mantissa
 - Gli estremi dell'intervallo di rappresentazione dipendono dal numero di cifre dell'esponente
 - Nel caso precedente di 2 cifre per l'esponente, si ha overflow per numeri maggiori (in modulo) di 10^{99} e si ha underflow per numeri minori (in modulo) di 10^{-99}
-

Standard IEEE 754 (1985)

- Formato standard indipendente dall'architettura
- Precisione semplice a 32 bit:




- Precisione doppia a 64 bit



| Argomento | Precisione singola 32 Bit | Precisione doppia 64 bit |
|------------------------------|------------------------------|-----------------------------|
| Bit del segno | 1 | 1 |
| Bit per l'esponente | 8 | 11 |
| Bit per la mantissa | 23 | 52 |
| Cifre decimali mantissa | Circa 7 (23/3.3) | Circa 15 (52/3.3) |
| Esponente (rappresentazione) | base 2 ad eccesso 127 | base 2 ad eccesso 1023 |
| Esponente (valori) | [-126, 127] | [-1022, 1023] |

IEEE 754 a 32 bit



$$x = (-1)^S \times 1.\text{fraction} \times 2^{\text{exponent}-\text{bias}}$$

- **ESPONENTE**

- Rappresentato in eccesso 127 (bias = 127)
- I valori di esponente ammessi sono nell'intervallo [-126, +127]
- **I valori -127 e +128 sono riservati per rappresentazioni speciali**

- **MANTISSA**

- Se ne rappresenta *solo la parte frazionaria*

$$\begin{cases} N = (-1)^S \times 1.\text{fraction} \times 2^{\text{exponent}-127}, & 1 \leq \text{exponent} \leq 254 \\ N = (-1)^S \times 0.\text{fraction} \times 2^{\text{exponent}-126}, & \text{exponent} = 0 \end{cases}$$

IEEE 754: forma normalizzata

- La mantissa binaria normalizzata deve presentare un 1 a sinistra della virgola binaria. L'esponente deve essere aggiustato di conseguenza
 - Essendo sempre presente tale cifra non è informativa così come la virgola binaria; esse vengono considerate implicitamente presenti e non vengono memorizzate
 - Per evitare confusione con una frazione tradizionale la combinazione dell'1 implicito della virgola binaria e delle 23/52 cifre significative vengono chiamate **significando** (invece che frazione o mantissa)
 - Tutti i numeri normalizzati hanno un esponente $e > 0$
 - Tutti i numeri normalizzati hanno un significando $s = 1.f$ tra $1 \leq s < 2$
 - I numeri normalizzati non possono avere un esponente composto da soli 1. Tale configurazione serve per modellare il valore infinito (∞)
-

IEEE 754: forma denormalizzata

- La mantissa binaria denormalizzata può assumere qualsiasi configurazione. Questa rappresentazione viene utilizzata per rappresentare valori inferiori a 2^{-126}
 - Tutti i bit dell'esponente sono posti a 0 (questa configurazione indica l'utilizzo della forma denormalizzata)
 - Il bit della mantissa a sinistra della virgola binaria è posto implicitamente a 0 per i numeri in forma denormalizzata
 - Il numero più piccolo rappresentabile in questa configurazione è composto da una mantissa con tutti 0 a eccezione del bit più a destra
-

Esempio

$$\begin{aligned} -\left(6 + \frac{5}{8}\right) &= -\left(4 + 2 + \frac{4}{8} + \frac{1}{8}\right) = -\left(4 + 2 + \frac{1}{2} + \frac{1}{8}\right) \\ &= -\left(1 \times 2^2 + 1 \times 2^1 + 0 \times 2^0 + 1 \times 2^{-1} + 0 \times 2^{-2} + 1 \times 2^{-3}\right) \\ &= -(110.101_2) = -(1.10101_2 \times 2^2) \end{aligned}$$

Esponente:

$$\text{exponent} - 127 = 2 \Rightarrow \text{exponent} = 129$$

Rappresentazioni speciali

Esponente $255 = 11111111_2$ indica un valore speciale

Esponente $255 = 11111111_2$ ed $f = 0 \rightarrow$ valore rappresentato $\pm \infty$

Esponente $255 = 11111111_2$ ed $f \neq 0 \rightarrow$ valore rappresentato
Not a Number (NaN)

Not a Number (NaN) indica un valore indefinito

Esso è impiegato per rappresentare il risultato di operazioni di calcolo non definite,
come la divisione $0 / 0$
o la radice quadrata di un numero negativo

Rappresentazione di zero

- esponente tutti 0
- mantissa tutti zero
- Segno: sia + che -

+0: 0 00000000 00000000000000000000000000000000

-0: 1 00000000 00000000000000000000000000000000

Da decimale a floating point

- Caso semplice:
numero razionale con denominatore potenza di 2
- Esempio: $- \frac{3}{4} = -0.75_{10} = -0.11_2$
- Forma normalizzata: $-1.10_2 \cdot 2^{-1}$
- Rappresentazione IEEE 754 a singola precisione:

$$x = (-1)^s \times 1.\text{fraction} \times 2^{\text{exponent-bias}}$$

$s = 1$

$\text{exponent-bias} = -1 \rightarrow \text{exponent} = \text{bias} - 1 = 127 - 1 = 126 = 01111110_2$

$\text{fraction} = 1000\dots00$ (23 bit)



Da decimale a floating point

- Esempio: $+ 1/3 = +0.3333\dots_{10} = + 0.01010101\dots_2$
- Forma normalizzata: $+ 1.010101\dots_2 \cdot 2^{-2}$
- Rappresentazione IEEE 754 a singola precisione:

$$x = (-1)^s \times 1.\text{fraction} \times 2^{\text{exponent-bias}}$$

$s = 0$

$\text{exponent-bias} = -2 \rightarrow \text{exponent} = \text{bias} - 2 = 127 - 2 = 125 = 01111101_2$

$\text{fraction} = 0101\ 0101\ 0101\ 0101\ 0101\ 010\ (23\ \text{bit})$

