

## Avviso

I contenuti di queste annotazioni non sono esaustivi ai fini del buon esito dell'esame. Fare riferimento alle lezioni tenute in aula ed ai testi consigliati:

- G. Monegato, Fondamenti di Calcolo Numerico. Ed. CLUT
- A. Quarteroni, F. Saleri, 'Calcolo Scientifico, esercizi e problemi risolti con Matlab e Octave' Springer.

## Obiettivi dell'Analisi Numerica

Trovare **algoritmi** che risolvono un problema matematico:

- **nel minor tempo possibile**
- **con la massima accuratezza possibile**

“L'analisi numerica è l'arte di dare risposta numerica ad un problema matematico *ben-posto* mediante un calcolatore automatico digitale.”

Un problema è **ben posto** se **esiste un'unica soluzione** e questa dipende un modo **continuo** dai dati del problema.

## Risoluzione numerica di un modello

- **Modello Matematico**: rappresentazione matematica di un problema reale.
- **Metodo Numerico**: tecnica per calcolare quantità matematiche complesse.
- **Algoritmo Numerico**: Sequenza di istruzioni che realizzi il metodo numerico.
- **Implementazione dell'algoritmo numerico**: traduzione in un linguaggio per una determinata architettura hardware/software.
- Interpretazione **corretta** dei risultati.

## Analisi Numerica e Calcolo Scientifico

- **Analisi Numerica**: Studio matematico di **metodi numerici** (tecnicamente non è necessario il calcolatore).
- **Calcolo Scientifico**: **Ricerca di Algoritmi** che siano affidabili, flessibili, portabili.

Questa distinzione non è rigorosa: L'analista numerico si occupa anche della scrittura degli algoritmi.

# Calcolo Numerico e Simbolico

- Calcolo Simbolico:  $(a + b)^2 = a^2 + 2ab + b^2$ .
- Calcolo Numerico:  $2 + 3.34 = 5.34$ .  
Nel calcolo numerico si effettuano approssimazioni:

$$1/3 = 0,3333\dots$$

non si possono scrivere tutte le cifre!

# Metodo numerico ed algoritmi

- **metodo numerico**: descrizione **matematica** dei calcoli da effettuare per risolvere il problema matematico.
- **algoritmo**: sequenza precisa di azioni (tipicamente istruzioni per il calcolatore) per ottenere il risultato.

Ad ogni metodo numerico, possono corrispondere più algoritmi che lo implementano.

## Gli Errori

Una scienza si dice esatta quando...  
si conoscono gli errori!

Sorgenti di errore:

- Semplificazioni del modello
- Errori nei dati
- Errori di troncamento del metodo numerico
- Errori di approssimazione nei dati e nei calcoli

## Nomenclatura degli Errori

Sia  $\tilde{x}$  il valore vero di una certa quantità e  $x$  il suo valore affetto da errore:

- Errore assoluto:  $\varepsilon_a = |x - \tilde{x}|$ .
- Errore relativo:  $\varepsilon_r = \frac{|x - \tilde{x}|}{|\tilde{x}|}$ .
- Errore relativo percentuale:  $\varepsilon_{\%} = 100 \frac{|x - \tilde{x}|}{|\tilde{x}|}$ .

il risultato di un calcolo si scrive:

$$x \pm \varepsilon_a \Leftrightarrow x - \varepsilon_a \leq \tilde{x} \leq x + \varepsilon_a$$

# Propagazione degli errori

In seguito ad operazioni di calcolo, gli errori tendono ad accumularsi.

- Somma e sottrazione: l'errore assoluto del risultato è la somma degli errori assoluti degli addendi:

$$C = A \pm B \implies \varepsilon_{a,C} = \varepsilon_{a,A} + \varepsilon_{a,B}$$

- Moltiplicazione (e divisione): l'errore relativo del risultato è la somma degli errori relativi dei fattori:

$$C = AB \implies \varepsilon_{r,C} = \varepsilon_{r,A} + \varepsilon_{r,B}$$

# Sistemi di numerazione

Sistema posizionale: ad ogni cifra si assegna un peso a seconda della posizione. Il peso è specificato dalla **base** del sistema che si utilizza, e dall'esponente, che corrisponde alla posizione della cifra. Il valore del numero è dato dalla somma delle cifre pesate.

Nella base 10 scrivere il numero 23.75, significa:

$$2 \cdot 10^1 + 3 \cdot 10^0 + 7 \cdot 10^{-1} + 5 \cdot 10^{-2}$$

Lo stesso numero nella base 2 (binaria) si scrive 10111.11, ossia:

$$1 \cdot 2^4 + 0 \cdot 2^3 + 1 \cdot 2^2 + 1 \cdot 2^1 + 1 \cdot 2^0 + 1 \cdot 2^{-1} + 1 \cdot 2^{-2}$$

Altre basi usate in ambito informatico sono la 8 (ottale) e 16 (esadecimale).

# I numeri nel calcolatore

Comunemente i numeri sono memorizzati nel calcolatore secondo la base binaria. Nella pratica si utilizzano due schemi di memorizzazione in base al "tipo" di numero da memorizzare:

- I numeri interi sono memorizzati come multipli di byte.
- I numeri reali (floating-point), secondo un opportuno schema.

# I numeri nel calcolatore 2

Un numero reale  $a \in R$ , può essere trascritto come:

$$a = m \times N^q,$$

dove

- $N$  è la base scelta per la rappresentazione
- $m$  la mantissa (o frazione)
- $q$  l'esponente.

Nel caso dei numeri reali,  $N^q$  è un fattore moltiplicativo ed  $m$  "contiene l'informazione principale" del numero reale  $a$ .

Se  $N^{-1} \leq |m| < 1$  la rappresentazione si dice normalizzata.

# Rappresentazione in virgola mobile

$$\pm 0.mmmmmmmmm... \times N^{qqq}$$

- Numeri di cifre mantissa ed esponente fissati
- IEEE 754: floating point in base 2 (1985, 7 anni per decidere!)
- IEEE 854: floating point in base arbitraria (1987)  
<http://standards.ieee.org/findstds/standard/854-1987.html>
- IEEE 754-2008: ha incluso i due precedenti standard  
<http://standards.ieee.org/findstds/standard/754-2008.html>

# Approssimazione dei numeri

Esistono due tecniche di approssimazione dei numeri:

1. Troncamento: si escludono i bits a destra dell'ultimo bit di  $m$ .
2. Arrotondamento: si aggiunge  $\frac{1}{2}N^{-bit_m}$  alla mantissa e poi si esegue il troncamento.

$bit_m$  è il numero di bit che sono messi a disposizione per memorizzare la mantissa dei numeri floating-point. I numeri di mantissa rappresentabili sono separati della quantità  $N^{-bit_m}$  (granularità della mantissa).

## Approssimazione dei numeri - Esempio

Supponiamo di avere un 'computer esempio' con 2 byte per la mantissa. Vediamo come viene memorizzato il numero

$$a = 0.1$$

La rappresentazione di  $a$  in cifre binarie è la seguente:

$$a = 0.00011001100110011001100\dots$$

si tratta di un numero periodico. Il primo passo è la normalizzazione:

$$a = 0.11001100110011001100\dots \times 2^{-3}$$

## Approssimazione dei numeri - Esempio

poi considerare i primi 16 bit della parte decimale, ed effettuare un troncamento:

$$\bar{a} = 0.1100110011001100 \times 2^{-3}$$

Questo è il numero arrotondato che è memorizzato nel calcolatore.

Se ora lo rappresentiamo nuovamente nella base decimale si ha:

$$\bar{a} = 0.09999847412109\dots$$

## Approssimazione dei numeri - Esempio

Il numero differisce, seppur di poco, da quello originale.  
Vediamo l'effetto sull'errore assoluto  $\varepsilon_a$ :

$$|a - \bar{a}| = 1.5258789 \dots 10^{-6} \leq 2^{-3-16} = 1.9073486 \dots 10^{-6}$$

## Spaziatura dei numeri macchina

$$\bar{a} = 0.1100110011001100 \times 2^{-3}$$

Il numero macchina successivo a questo si ottiene aggiungendo un bit all'ultimo della mantissa:

$$\bar{a}_1 = 0.1100110011001101 \times 2^{-3}$$

che in rappresentazione decimale corrisponde a:

$$\bar{a}_1 = 0.1000003814697 \dots$$

Come si vede il numero 0.1 non è rappresentabile sul calcolatore e si ha:

$$\bar{a} < 0.1 < \bar{a}_1$$

## Spaziatura dei numeri macchina 2

Nella rappresentazione floating point la spaziatura dei numeri macchina non è uniforme, perchè dipende anche dall'esponente.

Se  $a = \pm 0.mmmmmmmmmmm \times N^{qqqq}$ , la spaziatura nell'intorno di  $a$  è  $N^{-bit_m} \times N^{qqqq}$ .

Ad esempio, in binario quando la mantissa passa da 0.111111111 a 0.100000000 la spaziatura raddoppia.

## Operazioni macchina

● In generale la proprietà associativa non vale:

$$(a \oplus b) \oplus c \neq a \oplus (b \oplus c)$$

● la proprietà commutativa continua a valere:

$$a \oplus b = b \oplus a$$

dove il simbolo  $\oplus$  indica la somma effettuata al calcolatore. Si sottolinea che questo non dipende da "errori di calcolo"

nella somma bit a bit, ma sempre dal fatto che si ha a disposizione un numero limitato di cifre binarie che costringe all'arrotondamento.

## Operazioni macchina - Esempio

Si vuole eseguire la somma  $0.1 + 0.00001$ . Il primo addendo lo abbiamo già scritto, il secondo ( $b = 1 \times 10^{-5}$ ) è:

$$b = 0.1010011111000101101011 \dots \times 2^{-16}$$

che sul 'computer esempio' è approssimato da (troncamento):

$$\bar{b} = 0.1010011111000101 \times 2^{-16}$$

che corrisponde a  $\bar{b} = 0.99984 \dots 10^{-5}$ . Per effettuare la somma dobbiamo riportare (operazione di *allineamento*) questo numero allo stesso esponente di  $\bar{a}$ , per cui:

$$\bar{b} = 0.0000000000001010011111000101 \times 2^{-3}$$

## Operazioni macchina - Esempio

purtroppo abbiamo a disposizione solo 16 bit per la mantissa e si deve fare una seconda approssimazione.

$$\bar{\bar{b}} = 0.000000000000101 \times 2^{-3}$$

che in decimale corrisponde a  $\bar{\bar{b}} = 0.95367 \dots 10^{-5}$ . Si capisce che c'è un ulteriore peggioramento nella rappresentazione di  $b$ .

Il risultato finale della somma sarà

$$\bar{a} + \bar{\bar{b}} = 0.1000080108 \dots$$

L'effetto del secondo arrotondamento è tanto più marcato quanto più è grande il rapporto tra gli addendi della somma.

## Precisione di macchina

Questi effetti degli arrotondamenti si possono formalizzare con il concetto di *precisione macchina*.

La **precisione macchina** è il più grande numero  $u$  in virgola mobile tale che:

$$1 \oplus x = 1 \quad \text{se} \quad x \leq u$$

Il simbolo  $\oplus$  specifica che l'operazione di addizione è stata effettuata sul calcolatore.

## Precisione di macchina 2

Si ha

$$1 \oplus u = 1$$

Conseguenze sulla proprietà associativa:

$$(1 \oplus u) \oplus u = 1$$

mentre

$$1 \oplus (u \oplus u) = 1 \oplus 2u \neq 1$$

## Precisione di macchina 3

La precisione macchina viene anche chiamata **precisione relativa**: Fissa un **ordine di grandezza** oltre il quale i numeri più piccoli non sono sentiti nelle operazioni di somma algebrica.

$$|\bar{b}| \leq |\bar{a}| \mathbf{u} \implies \bar{a} \oplus \bar{b} = \bar{a}$$

Stima a priori della precisione macchina:

$$\mathbf{u} = \frac{1}{2} N^{-bit_{m+1}}$$

Nota: le moderne FPU sono provviste dei *guard digits* oltre la mantissa, per eseguire più correttamente le operazioni.

## Cancellazione sottrattiva

Perdita di cifre significative quando si sottraggono due numeri quasi uguali.

Esempio in base decimale con 7 digit di mantissa:

$$a = 0.123456789 \quad b = 0.123456666$$

$$a - b = 0.123 \times 10^{-6}$$

$$\bar{a} = 0.1234567 \quad \bar{b} = 0.1234566$$

$$\bar{a} - \bar{b} = 0.1 \times 10^{-6}$$

che significa 1 sola cifra di accuratezza. L'accuratezza delle 7 cifre iniziali è andata perduta.

## Cancellazione sottrattiva 2

Vediamo con un altro esempio come si può superare l'inconveniente in un caso specifico. Calcolare

$$x = a - \sqrt{a^2 - b}$$

se  $|b| \ll |a|$ ,  $x$  è la differenza di due numeri quasi uguali: c'è cancellazione sottrattiva (se  $a > 0$ ). Per evitare il problema:

$$x = a - \sqrt{a^2 - b} = \frac{a + \sqrt{a^2 - b}}{a + \sqrt{a^2 - b}} \frac{b}{a + \sqrt{a^2 - b}} = \frac{b}{a + \sqrt{a^2 - b}}$$

## Cancellazione

La cancellazione si verifica particolarmente in:

- moltissime somme di quantità "piccole" (rispetto al totale).
- somme i cui addendi sono molto differenti in ordine di grandezza.
- molte somme i cui addendi hanno segno variabile.