

NUMERI MACCHINA *

A. SOMMARIVA[†]

Conoscenze richieste. Equazioni di secondo grado, successioni, formula di Taylor in una e due variabili, integrali di Riemann.

Conoscenze ottenute. In questa sezione analizziamo la rappresentazione floating point di un numero. Di seguito introduciamo il concetto di errore assoluto e relativo, condizionamento, stabilità e complessità computazionale con esempi.

1. Numeri macchina e loro proprietà. Fissato un numero naturale $\beta > 1$ è possibile vedere che ogni numero reale $x \neq 0$ ha una unica rappresentazione del tipo

$$x = \text{sign}(x)\beta^e \sum_{k=1}^{+\infty} d_k \beta^{-k}, \quad 0 < d_1, 0 \leq d_k \leq \beta - 1, e \in \mathbb{Z} \quad (1.1)$$

dove

$$\text{sign}(y) = \begin{cases} 1, & y > 0 \\ -1, & y < 0 \\ 0, & y = 0. \end{cases}$$

è la funzione segno.

Osserviamo che storicamente, la scelta della base β è risultata molto eterogenea:

- la base utilizzata dalla maggior parte dei computer attuali è $\beta = 2$,
- il computer russo SETUN (≈ 1957) usava la base $\beta = 3$,
- il PDP-10 (≈ 1965), Burroughs 570 e 6700 utilizzavano la base ottale, cioè $\beta = 8$,
- la base che usiamo nella vita di tutti i giorni è $\beta = 10$, ed è stata una scelta comune anche per computer del passato come l'HP-11C, HP-15C (≈ 1980) o Eniac (≈ 1947),
- esistono popoli in Nigeria, India, Nepal, la cui è base $\beta = 12$,
- molti computers, come l'IBM 360, l'IBM 3033 (≈ 1977), usavano la base $\beta = 16$,
- i Maya usavano la base $\beta = 20$.
- in tavolette babilonesi si utilizzava la base $\beta = 60$.

Dall'avvio dello standard IEEE 754-1985, in cui venne realizzato lo standard per l'aritmetica binaria floating point, la base più utilizzata risulta $\beta = 2$. [3].

Vediamo quale esempio come rappresentare il numero π al variare di due classiche scelte di β :

- base 10: 3,141592653589793238462643383279502884197169399... secondo la rappresentazione sopra descritta e'

$$+1 \cdot 10^1 \cdot (3 \cdot 10^{-1} + 1 \cdot 10^{-2} + 4 \cdot 10^{-3} + \dots)$$

che viene spesso denotato come

$$\pi = (+1) \cdot (0.3141592653589793238462643383279502884197169399\dots)_{10} \cdot 10^1;$$

*Ultima revisione: 26 settembre 2018

[†]Dipartimento di Matematica, Università degli Studi di Padova, stanza 419, via Trieste 63, 35121 Padova, Italia (alvise@math.unipd.it). Telefono: +39-049-8271350.

- base 2: 11,0010010000111111011010101000100010000101... secondo la rappresentazione sopra descritta e'

$$+1 \cdot 2^2 \cdot (1 \cdot 2^{-1} + 1 \cdot 2^{-2} + 0 \cdot 2^{-3} \dots + 0 \cdot 2^{-4} + 1 \cdot 2^{-5} \dots) = +4(1/2 + 1/4 + 1/32 + \dots),$$

che viene spesso denotato come

$$\pi = (+1) \cdot (0.110010010000111111011010101000100010000101\dots)_2 \cdot 2^2.$$

La particolarità della sommatoria in (1.1), ovvero

$$x = \text{sign}(x) \beta^e \sum_{k=1}^{+\infty} d_k \beta^{-k}, \quad 0 < d_1, 0 \leq d_k \leq \beta - 1, e \in \mathbb{Z} \quad (1.2)$$

è ovviamente tale che x potrebbe essere non rappresentabile esattamente dal calcolatore se esistono infiniti $d_k > 0$, in quanto il calcolatore è capace di immagazzinare solo un numero finito di tali d_k .

Ad esempio, non è difficile vedere che:

- i numeri irrazionali come π , indipendentemente dalla base β , hanno sempre un numero infinito di cifre d_k ;
- in base 10 alcuni numeri razionali hanno comunque un numero infinito di cifre d_k (si pensi ai numeri periodici come $1/3 = 0.333\dots$, ma comunque in certe basi possono avere una rappresentazione finita (nel nostro esempio $1/3 = 1 \cdot 3^{-1}$ per $\beta = 3$)).

In virtù di di considerazioni sulla finitezza delle cifre immagazzinabili, ipotesi necessaria perché il numero sia utilizzabile da un computer, risulta naturale la seguente

DEFINIZIONE 1.1. *L'insieme dei numeri macchina $F(\beta, t, L, U)$ di \mathbb{R} è costituito da quei numeri y che sono 0 oppure sono rappresentati con il sistema a virgola mobile normalizzata o floating point normalizzato da*

$$y = \text{sign}(y) \cdot (0.d_1 \dots d_t)_{\beta} \beta^e = \text{sign}(y) \cdot \beta^e \sum_{k=1}^t d_k \beta^{-k}, \quad d_1 > 0, 0 \leq d_k \leq \beta - 1$$

con

- $\beta > 1$ numero naturale detto base, t numero prefissato di cifre di mantissa,
- $e \in \mathbb{Z}$ l'esponente intero tale che $L \leq e \leq U$.

La parola *normalizzato* sottolinea che $d_1 > 0$. Si può provare che $\sum_{k=1}^t d_k \beta^{-k} < 1$ e quindi $e = \text{floor}(1 + \log_{\beta}(x))$.

Ogni elemento di $F(\beta, t, L, U)$ è detto numero macchina, ed evidentemente è un numero razionale.

NOTA 1.2. Osserviamo che se $e > 0$ allora

$$\begin{aligned} y &= \text{sign}(y) \cdot (0.d_1 \dots d_t)_{\beta} \beta^e = \text{sign}(y) \cdot \beta^e \sum_{k=1}^t d_k \beta^{-k} \\ &= \text{sign}(y) \cdot \left(\underbrace{\sum_{k=1}^e d_k \beta^{e-k}}_{\text{parte intera}} + \underbrace{\sum_{k=e+1}^t d_k \beta^{e-k}}_{\text{parte frazionaria}} \right) \end{aligned}$$

dove l'ultima somma è nulla per definizione se $t < e + 1$.

NOTA 1.3. Si osservi che il sistema floating-point è solo una delle scelte possibili, in quanto una volta si utilizzava un sistema a virgola fissa, ovvero con un numero fissato di cifre prima della virgola e un certo numero di cifre dopo la virgola, abbandonato (nonostante presentasse alcuni vantaggi) perchè l'intervallo di valori rappresentati è modesto e la precisione dei numeri frazionari scarsa.

Di ogni numero macchina si immagazzinano

- una cifra per il segno (ovvero 0 per positivo e 1 per negativo),
- le cifre della mantissa,
- le cifre dell'esponente.

Ognuna di queste cifre è detta *bit*. Ogni numero è registrato in un vettore detto *parola* di un certo numero di M bits.

1.1. Precisione singola e doppia. Descriviamo di seguito i più comuni insiemi di numeri floating-point. Usualmente se M è il numero di bits necessari per un numero in precisione *singola*, nel caso di precisione *doppia* questo è usualmente composto da 2 parole di M bits.

Classici esempi sono per quanto riguarda i processori che seguono lo standard IEEE754

- per la precisione singola $F(2, 24, -126, 127)$ in cui ogni numero macchina occupa 32 bit (o 4 byte essendo un byte pari a 8 bit)
- per la doppia $F(2, 53, -1022, 1023)$ in cui ogni numero macchina occupa 64 bit.

NOTA 1.4. In altri sistemi il numero di cifre per esponente e mantissa sono risultati molteplici, ad esempio su

- Zuse Z1 (≈ 1936), la mantissa corrispondeva a 22 cifre (14 per la mantissa e 8 per l'esponente),
- IBM 3033 in precisione doppia si aveva, oltre alla base $\beta = 16$, una mantissa di 14 cifre,
- PRIME 850, che lavorava in base $\beta = 2$, si aveva in precisione singola 23 cifre di mantissa, mentre in precisione doppia 47 cifre di mantissa, [1, p.13].

Vediamo cosa serve immagazzinare in precisione doppia. Essendo un numero non nullo di segno $+1$ o -1 , basta un solo bit per il segno. Delle 53 cifre della mantissa, solo 52 devono essere ricordate (la prima per forza è 1 in virtù della normalizzazione). Infine, per l'esponente, vista una trattazione particolare che tiene conto anche di possibili problemi, servono 11 bit.

Osserviamo che

- per $e \geq t$ con t numero di cifre della mantissa, essendo $\beta > 1$ un numero naturale, allora

$$\pm \beta^e \sum_{k=1}^t d_k \beta^{-k} = \pm \sum_{k=1}^t d_k \beta^{e-k}$$

è un numero intero, essendo $e - k > 0$. Di conseguenza i numeri macchina più grandi in valore assoluto sono interi;

- l'insieme dei numeri macchina $F(\beta, t, L, U)$ ha un numero finito di elementi e si può dimostrare che la sua cardinalità è

$$2(\beta - 1)\beta^{t-1}(U - L + 1) + 1.$$

Di conseguenza

- in singola precisione $F(2, 24, -126, 127)$ i numeri sono circa $4.3 \cdot 10^9$;
- in precisione doppia $F(2, 53, -1022, 1023)$ sono circa $1.8 \cdot 10^{19}$.
- ponendo $d_1 = 1, d_2 = \dots = d_t = 0$ ed $e = L$ otteniamo che il più piccolo numero macchina (e quindi normalizzato!) positivo rappresentabile è β^{L-1} .
- ponendo $d_k = \beta - 1$, per $k = 1, \dots, t$ ed $e = U$ otteniamo che il massimo numero macchina rappresentabile è

$$\beta^U (1 - \beta^{-t});$$

- essendo un numero macchina del tipo

$$x = \pm \beta^e \sum_{k=1}^t d_k \beta^{-k}$$

con $d_1 > 0$ e $0 \leq d_k \leq \beta - 1$, da

$$\sum_{k=1}^t \gamma^k = \frac{\gamma^{t+1} - 1}{\gamma - 1} - 1$$

si vede subito essendo $1 - \beta^{-t} < 1$ che

$$\begin{aligned} |x| &= \beta^e \sum_{k=1}^t d_k \beta^{-k} \leq \beta^e \sum_{k=1}^t (\beta - 1) \beta^{-k} \\ &= \beta^e (\beta - 1) \sum_{k=1}^t \beta^{-k} = \beta^e (\beta - 1) \left(\frac{1 - \beta^{-(t+1)}}{1 - \beta^{-1}} - 1 \right) \\ &= \beta^e (\beta - 1) \left(\frac{\beta(1 - \beta^{-(t+1)})}{\beta - 1} - 1 \right) \\ &= \beta^e (\beta - 1) \left(\frac{\beta(1 - \beta^{-(t+1)}) - (\beta - 1)}{\beta - 1} \right) \\ &= \beta^e (1 - \beta^{-t}) < \beta^e \end{aligned} \tag{1.3}$$

e da

$$\sum_{k=1}^t d_k \beta^{-k} = \frac{|x|}{\beta^e} < \frac{\beta^e}{\beta^e} < 1$$

deduciamo che la somma relativa alla mantissa, cioè $\sum_{k=1}^t d_k \beta^{-k}$, è minore di 1.

Se x è il numero reale

$$x = \text{sign}(x)(0.d_1, \dots, d_t, \dots)_{\beta} \beta^e = \text{sign}(x) \beta^e \sum_{k=1}^{+\infty} d_k \beta^{-k}, \quad d_1 > 0$$

allora con $\text{fl}(x)$ denotiamo

$$\text{fl}(x) = \text{sign}(x)(0.d_1, \dots, d_{t-1}, \overline{d_t}) \beta^e = \text{sign}(x) \beta^e \left(\sum_{k=1}^{t-1} d_k \beta^{-k} + \overline{d_t} \beta^{-t} \right)$$

in cui se si effettua il troncamento

$$\overline{d}_t = d_t$$

mentre se viene effettuato l'arrotondamento.

$$\overline{d}_t = \begin{cases} d_t, & d_{t+1} < \beta/2 \\ d_t + 1, & d_{t+1} \geq \beta/2 \end{cases}$$

La scelta tra troncamento o arrotondamento è eseguita a priori dal sistema numerico utilizzato dal calcolatore. L'ultima, è la più diffusa.

ESEMPIO 1.5. Si consideri

$$\pi = (+1) \cdot (0.31415926535 \dots)_{10} \cdot 10^1.$$

Se lo tronchiamo alla quarta cifra decimale otteniamo

$$fl(\pi(+1)) = +1 \cdot (0.3141)_{10} \cdot 10^1,$$

mentre se lo arrotondiamo

$$fl(\pi(+1)) = +1 \cdot (0.3142)_{10} \cdot 10^1.$$

Evidentemente, per effettuare un arrotondamento, il calcolatore deve immagazzinare in un extra-bit la cifra d_{t+1} (rifletterci un po').

Se l'esponente e del numero x è minore di L si commette un'errore di *underflow*, mentre se è maggiore di U si commette un'errore di *overflow*. Se invece $e \in [L, U]$, $x = \pm \beta^e \sum_{k=1}^{+\infty} d_k \beta^{-k}$ e per qualche $t^* > t$ si ha $d_{t^*} > 0$ allora si commette un errore di troncamento o arrotondamento a seconda si effettui l'uno o l'altro.

NOTA 1.6. In generale la cardinalità dei numeri macchina è molto alta, spesso ordini di grandezza maggiore di quanto sia necessaria nelle scienze applicate [16].

On a computer, the interval $[1, 2]$, for example, is approximated by about 10^{16} numbers. It is interesting to compare the fineness of this discretization with that of the discretizations of physics. In a handful of solid or liquid or a balloonful of gas, the number of atoms or molecules in a line from one point to another is on the order of 108 (the cube root of Avogadro's number). Such a system behaves enough like a continuum to justify our definitions of physical quantities such as density, pressure, stress, strain, and temperature. Computer arithmetic, however, is more than a million times finer than this. Another comparison with physics concerns the precision to which fundamental constants are known, such as (roughly) 4 digits for the gravitational constant G , 7 digits for Planck's constant h and the elementary charge e , and 12 digits for the ratio μ_e/μ_B of the magnetic moment of the electron to the Bohr magneton. At present, almost nothing in physics is known to more than 12 or 13 digits of accuracy. Thus IEEE numbers are orders of magnitude more precise than any number in science. (Of course, purely mathematical quantities like π are another matter.)

1.2. La precisione di macchina. Una delle costanti rilevanti all'interno del sistema floating point è la precisione di macchina.

DEFINIZIONE 1.7. Si dice *precisione di macchina*, quel numero eps che rappresenta la distanza tra 1 ed il successivo numero in virgola mobile.

Calcoliamo tale valore. Necessariamente il numero successivo a 1 ha per mantissa $d_1 = 0, \dots, d_{t-1} = 0, d_t = 1$ e esponente $e = 1$ (perchè deriva da (1.3)?) e quindi è

$$x = \beta^1 \cdot \beta^{-t} = \beta^{1-t}.$$

Si sottolinea che la precisione di macchina eps non coincide in generale con il più piccolo numero positivo rappresentabile dal calcolatore, in quanto se $t \neq -L$, come usualmente accade, allora

$$\beta^{1-t} \neq \beta^{L-1}.$$

In Matlab ad esempio,

- il valore minimo in modulo è

$$x_{\min} = 2.225073858507201 \cdot 10^{-308},$$

- il valore massimo è

$$x_{\max} = 1.7976931348623158 \cdot 10^{+308},$$

- la precisione di macchina è

$$\text{eps} = 2.220446049250313 \cdot 10^{-16}.$$

Quindi x_{\min} è molto inferiore di eps .

NOTA 1.8. Usualmente

- un numero macchina più piccolo di x_{\min} produce il cosiddetto underflow,
- un numero macchina più grande di $\pm x_{\max}$ produce il cosiddetto overflow.

Osserviamo che esistono numeri denormalizzati, il cui range estende quello dei normalizzati. Il più piccolo numero positivo denormalizzato è $0.494 \cdot 10^{-323}$, permettendo di passare gradualmente dall'underflow allo 0.

NOTA 1.9. Per quanto riguarda numeri speciali

- per rappresentare $+\text{inf}$ si utilizza il segno pari a 0, tutti gli esponenti uguali a 1 e tutta la mantissa uguale a 0;
- per rappresentare $-\text{inf}$ si utilizza il segno pari a 1, tutti gli esponenti uguali a 1 e tutta la mantissa uguale a 0;
- per rappresentare lo 0 si distingue $+0$ da -0 (generalmente utilizzati per denotare un numero troppo piccolo in modulo che viene arrotondato a 0, pur mantenendo il segno); a parte il segno (positivo di default), tutte le altre cifre di esponente e mantissa sono uguali a 0;
- per rappresentare con NaN il risultato di un'operazione (numerica) stata eseguita su operandi non validi (specialmente in calcoli in virgola mobile). Secondo IEEE 754 i NaN sono rappresentati con il campo dell'esponentiale riempito di "1" e un numero diverso da zero nel campo della mantissa.

1.3. Errori relativi e assoluti. Fissato un numero da approssimare

$$x^* \in \mathbb{R},$$

si definisce

1. errore *assoluto* tra x e x^* la quantità

$$|x - x^*|$$

2. errore *relativo* tra x e $x^* \neq 0$ la quantità

$$\frac{|x - x^*|}{|x^*|}.$$

Si noti che se $|x^*| = 0$, cioè $x^* = 0$ per la proprietà del valore assoluto [1, p.481], allora non ha senso la scrittura propria dell'errore relativo.

NOTA 1.10. *Fissato un vettore da approssimare*

$$x^* = (x_1^*, \dots, x_n^*) \in \mathbb{R}^n,$$

si definisce

1. errore *assoluto* tra x e x^* la quantità

$$\|x - x^*\|$$

dove

$$\|y\| = \sqrt{\sum_{i=1}^n y_i^2}, \quad y = (y_1, \dots, y_n);$$

2. errore *relativo* tra x e $x^* \neq 0$ la quantità

$$\frac{\|x - x^*\|}{\|x^*\|}.$$

Si noti che se $\|x^*\| = 0$, cioè $x^* = 0$ per la proprietà delle norme [1, p.481], allora non ha senso la scrittura propria dell'errore relativo. Inoltre se il vettore ha un solo componente, allora la norma $\|\cdot\|$ coincide con l'usuale valore assoluto $|\cdot|$. \square

Sia

$$x = \text{sign}(x)\beta^e \sum_{k=1}^{+\infty} d_k \beta^{-k} \neq 0, \quad d_1 > 0$$

un numero reale e

$$fl(x) = \text{sign}(x)(0.d_1, \dots, d_{t-1}, \overline{d_t})\beta^e = \text{sign}(x)\beta^e \left(\sum_{k=1}^{t-1} d_k \beta^{-k} + \overline{d_t} \beta^{-t} \right), \quad d_1 > 0$$

la sua approssimazione in virgola mobile.

L'errore relativo compiuto nell'approssimare x con $fl(x)$, visto che $|x| \geq |d_1 \beta^{e-1}| \geq |\beta^{e-1}|$ poichè $d_1 > 0$, verifica

$$\begin{aligned} \frac{|x - fl(x)|}{|x|} &\leq \frac{|\text{sign}(x) \beta^e \sum_{k=1}^{+\infty} d_k \beta^{-k} - (\text{sign}(x) \beta^e (\sum_{k=1}^{t-1} d_k \beta^{-k} + \bar{d}_t \beta^{-t}))|}{|\beta^{e-1}|} \\ &= \beta \cdot \left| \sum_{k=t}^{+\infty} d_k \beta^{-k} - \bar{d}_t \beta^{-t} \right| \end{aligned} \quad (1.4)$$

Nel caso si effettui il troncamento abbiamo $d_t = \bar{d}_t$ e quindi, essendo $\text{eps} = \beta^{1-t}$ la precisione di macchina

$$\beta \cdot \left| \sum_{k=t}^{+\infty} d_k \beta^{-k} - \bar{d}_t \beta^{-t} \right| = \beta \cdot \left| \sum_{k=t+1}^{+\infty} d_k \beta^{-k} \right| < \beta \cdot (\beta \cdot \beta^{-t-1}) = \beta^{1-t} = \text{eps}$$

mentre se si effettua l'arrotondamento abbiamo dopo alcuni calcoli che

$$\frac{|x - fl(x)|}{|x|} < \frac{\beta^{1-t}}{2} = \frac{\text{eps}}{2}.$$

Il minor errore relativo compiuto nell'approssimare x con $fl(x)$ via arrotondamento, suggerisce perchè quest'ultimo sistema sia più utilizzato.

NOTA 1.11. *Da questo si deduce che i numeri in virgola mobile non sono dunque un insieme denso, come sono invece i numeri reali, bensì un insieme discreto di valori sull'asse reale, in posizioni non equispaziate (se così fosse, visto che i numeri più grandi sono interi, pure eps lo sarebbe).*

2. Operazioni con i numeri macchina. Per quanto concerne le quattro operazioni aritmetiche, si può dimostrare che la divisione e la moltiplicazione di tipo floating-point producono un errore relativo piccolo rispetto al risultato esatto, cosa che non succede sempre per somma e sottrazione.

Più precisamente se $fl(x)$ è il numero macchina che *corrisponde* a x , denotiamo con

$$x \oplus y := fl(fl(x) + fl(y)) \quad (2.1)$$

$$x \ominus y := fl(fl(x) - fl(y)) \quad (2.2)$$

$$x \otimes y := fl(fl(x) \cdot fl(y)) \quad (2.3)$$

$$x \oslash y := fl(fl(x) : fl(y)) \quad (2.4)$$

e per \odot una delle operazioni precedentemente introdotte, cioè una tra $\oplus, \ominus, \otimes, \oslash$ corrispondenti a op cioè una tra $+, -, \cdot, :$. Inoltre porremo

$$\epsilon_x := \frac{|x - fl(x)|}{|x|} \quad (2.5)$$

$$\epsilon_{x,y}^{\odot} := \frac{|(x \text{ op } y) - (x \odot y)|}{|x \text{ op } y|} \quad (2.6)$$

NOTA 2.1. *Osserviamo, che a volte nei manuali si trova qualcosa di diverso. Ad esempio,*

$$x \oplus y = fl(x + y)$$

In realtà il sistema floating point, utilizzando ulteriori bits nei calcoli, garantisce che sia

$$x \oplus y = fl(fl(x) + fl(y)) = fl(x + y).$$

In effetti, da [7]

The IEEE standard requires that the result of addition, subtraction, multiplication and division be exactly rounded. That is, the result must be computed exactly and then rounded to the nearest floating-point number (using round to even). The section Guard Digits pointed out that computing the exact difference or sum of two floating-point numbers can be very expensive when their exponents are substantially different. That section introduced guard digits, which provide a practical way of computing differences while guaranteeing that the relative error is small. However, computing with a single guard digit will not always give the same answer as computing the exact result and then rounding. By introducing a second guard digit and a third sticky bit, differences can be computed at only a little more cost than with a single guard digit, but the result is the same as if the difference were computed exactly and then rounded. Thus the standard can be implemented efficiently.

Altre volte si trova equivalentemente [16]

if $$ is one of these four operations in its ideal form and \odot is the same operation as realized on the computer, then for any floating-point numbers x and y , assuming that there is no underflow or overflow,*

$$x \odot y = (x * y)(1 + \epsilon).$$

Here ϵ is a very small quantity, no greater in absolute value than a number known as machine epsilon, denoted by ϵ_{mach} , that measures the accuracy of the computer. In the IEEE system, $\epsilon_{mach} = 2^{-53} \approx 1.1 \times 10^{-16}$.

2.1. Proprietà commutativa, associativa e distributiva delle operazioni floating point.

Per prima cosa osserviamo che alcune proprietà caratteristiche di $+$, $-$, \cdot e $:$ non valgono per i corrispettivi \oplus , \ominus , \otimes , \oslash . Infatti per la somma \oplus e il prodotto \otimes vale la proprietà commutativa ma non vale quella associativa, e nemmeno quella distributiva.

ESEMPIO 2.2. *Mostriamo come non valga la proprietà associativa della somma. Consideriamo $F(10, 4, -10, +10)$ con fl basato sul troncamento. Sia $a = 2000$, $b = 2.5$, $c = 7.8$. Allora:*

$$(a \oplus b) \oplus c = 0.2002 \cdot 10^4 \oplus 0.7800 \cdot 10^1 = 0.2009 \cdot 10^4$$

$$a \oplus (b \oplus c) = 0.2000 \cdot 10^4 \oplus 0.1030 \cdot 10^2 = 0.2010 \cdot 10^4$$

e quindi $(a \oplus b) \oplus c \neq a \oplus (b \oplus c)$.

Per quanto riguarda la proprietà distributiva, in $F(10, 4, -10, +10)$, posti $a = 0.800000 \cdot 10^9$, $b = 0.500009 \cdot 10^4$, $c = 0.500008 \cdot 10^4$

$$a \otimes (b \ominus c) = 0.800000 \cdot 10^9 \otimes 0.1 \cdot 10^{-2} = 0.800000 \cdot 10^9$$

$$(a \otimes b) \ominus (a \otimes c) = (0.800000 \cdot 10^9 \otimes b = 0.500009 \cdot 10^4) \ominus$$

$$\ominus (0.800000 \cdot 10^9 \otimes b = 0.500008 \cdot 10^4) \rightarrow \text{overflow} \quad (2.7)$$

(l'overflow è dovuto alla sequenza di operazioni da compiere).

2.2. Errori nelle operazioni e loro propagazione. Consideriamo ora come si propagano gli errori in $\oplus, \ominus, \otimes, \oslash$. Si mostra che (cf. [4, p.78])

$$\epsilon_{x,y}^{\oplus} \leq \left| \frac{x}{x+y} \right| \epsilon_x + \left| \frac{y}{x+y} \right| \epsilon_y \quad (2.8)$$

$$\epsilon_{x,y}^{\ominus} \leq \left| \frac{x}{x-y} \right| \epsilon_x + \left| \frac{y}{x-y} \right| \epsilon_y \quad (2.9)$$

$$\epsilon_{x,y}^{\otimes} \lesssim \epsilon_x + \epsilon_y \quad (2.10)$$

$$\epsilon_{x,y}^{\oslash} \leq |\epsilon_x - \epsilon_y| \quad (2.11)$$

Proviamo di seguito sotto opportune ipotesi il caso della somma, sottrazione e della moltiplicazione, lasciando al lettore quello della divisione. Con $a \lesssim b$ si intende a inferiore o uguale circa a b .

2.2.1. Errore nella somma. Per quanto riguarda la somma, supposti $x + y \neq 0, x \neq 0, y \neq 0$, e $\text{fl}(\text{fl}(x) + \text{fl}(y)) = \text{fl}(x) + \text{fl}(y)$ (cioè $\text{fl}(x) + \text{fl}(y)$ numero macchina, richiesta non eccessiva, vuol dire semplicemente che il risultato è ancora nell'insieme dei numeri macchina), ricordato che $\epsilon_x = \frac{|x - \text{fl}(x)|}{|x|}$ ed $\epsilon_y = \frac{|y - \text{fl}(y)|}{|y|}$, abbiamo

$$\begin{aligned} \epsilon_{x,y}^{\oplus} &= \frac{|(x+y) - (x \oplus y)|}{|x+y|} = \frac{|(x+y) - \text{fl}(\text{fl}(x) + \text{fl}(y))|}{|x+y|} = \frac{|(x - \text{fl}(x)) + (y - \text{fl}(y))|}{|x+y|} \\ &\leq \frac{|x|}{|x+y|} \cdot \frac{|x - \text{fl}(x)|}{|x|} + \frac{|y|}{|x+y|} \cdot \frac{|y - \text{fl}(y)|}{|y|} = \left| \frac{x}{x+y} \right| \epsilon_x + \left| \frac{y}{x+y} \right| \epsilon_y \end{aligned} \quad (2.12)$$

Il caso in cui $\text{fl}(\text{fl}(x) + \text{fl}(y)) \neq \text{fl}(x) + \text{fl}(y)$ è più complicato ma i risultati restano simili dal punto di vista teorico.

Il punto chiave è che per $x + y \approx 0$ abbiamo che per piccoli errori sui dati ϵ_x, ϵ_y possono aversi errori rilevanti in $\epsilon_{x,y}^{\oplus}$.

Per quanto riguarda la sottrazione, con una analisi simile, si vede che

$$\begin{aligned} \epsilon_{x,y}^{\ominus} &= \frac{|(x-y) - (x \ominus y)|}{|x-y|} = \frac{|(x-y) - \text{fl}(\text{fl}(x) - \text{fl}(y))|}{|x-y|} = \frac{|(x - \text{fl}(x)) - (y - \text{fl}(y))|}{|x-y|} \\ &\leq \frac{|x|}{|x-y|} \cdot \frac{|x - \text{fl}(x)|}{|x|} + \frac{|y|}{|x-y|} \cdot \frac{|y - \text{fl}(y)|}{|y|} = \left| \frac{x}{x-y} \right| \epsilon_x + \left| \frac{y}{x-y} \right| \epsilon_y \end{aligned} \quad (2.13)$$

Nuovamente, per $x - y \approx 0$ abbiamo che per piccoli errori sui dati ϵ_x, ϵ_y possono aversi errori rilevanti in $\epsilon_{x,y}^{\ominus}$. Qualora ciò accada, si parla di *fenomeno di cancellazione*.

ESEMPIO 2.3. Consideriamo il sistema $F(10, 5, -5, +5)$ (con arrotondamento) e i due numeri

$$a = 0.73415776, \quad b = 0.73402350.$$

Naturalmente,

$$\text{fl}(a) = 0.73416, \quad \text{fl}(b) = 0.73402$$

e quindi

$$a - b = 0.00013426, \quad a \ominus b = 0.00014 = 10^{-3} \cdot 0.14000$$

con un errore relativo pari a

$$|(a - b) - (a \ominus b)|/|a - b| \approx 4.3/100$$

cioè molto grande (oltre il 4 per cento!).

2.2.2. Errore nel prodotto. Nel caso del prodotto,

- supposti $x \cdot y \neq 0$, $x \neq 0$, $y \neq 0$, $|fl(y)|/|y| \approx 1$,
- supposto $fl(fl(x) \cdot fl(y)) = fl(x) \cdot fl(y)$ (cioè $fl(x) \cdot fl(y)$ numero macchina),
- ricordato che $\epsilon_x = \frac{|x - fl(x)|}{|x|}$ ed $\epsilon_y = \frac{|y - fl(y)|}{|y|}$,

abbiamo

$$\begin{aligned} \epsilon_{x,y}^{\otimes} &= \frac{|x \cdot y - x \otimes y|}{|x \cdot y|} = \frac{|x \cdot y - fl(fl(x) \cdot fl(y))|}{|x \cdot y|} = \frac{|x \cdot y - fl(x) \cdot fl(y)|}{|x \cdot y|} \\ &= \frac{|x \cdot y - x \cdot fl(y) + x \cdot fl(y) - fl(x) \cdot fl(y)|}{|x \cdot y|} \\ &\leq \frac{|x \cdot (y - fl(y))| + |fl(y) \cdot (x - fl(x))|}{|x \cdot y|} \\ &= \frac{|y - fl(y)|}{|y|} + \frac{|fl(y) \cdot (x - fl(x))|}{|x \cdot y|} \\ &\approx \epsilon_x + \epsilon_y \end{aligned} \tag{2.14}$$

dove si ricorda che

$$\frac{|fl(y)|}{|x \cdot y|} \approx \frac{1}{|x|}.$$

NOTA 2.4. Per stabilità di una generica operazione macchina op (si pensi ad esempio $*$ come alla somma oppure al prodotto), si intende che se \odot è l'omologa versione floating-point allora esiste $C > 0$ tale che

$$\epsilon_{x,y}^{\odot} \leq C(\epsilon_y \text{ op } \epsilon_x)$$

per ogni x, y per cui la scrittura abbia significato.

Ne consegue che la somma e la sottrazione non sono stabili mentre lo sono il prodotto e la divisione [11, p.10].

NOTA 2.5. Osserviamo che dalla formula di Taylor in due variabili, posto per brevità di notazione $f'_x = \partial f / \partial x$, $f'_y = \partial f / \partial y$,

$$f(x, y) \approx f(\bar{x}, \bar{y}) + f'_x(\bar{x}, \bar{y})(x - \bar{x}) + f'_y(\bar{x}, \bar{y})(y - \bar{y}) \tag{2.15}$$

necessariamente, se $x, y, f(x, y) \neq 0$ allora posti $\epsilon_x = |x - \bar{x}|/|x|$, $\epsilon_y = |y - \bar{y}|/|y|$ gli errori relativi sui dati

$$\begin{aligned} \frac{|f(x, y) - f(\bar{x}, \bar{y})|}{|f(x, y)|} &\lesssim \frac{|f'_x(\bar{x}, \bar{y})||x - \bar{x}|}{|f(x, y)||x|} + \frac{|f'_y(\bar{x}, \bar{y})||y - \bar{y}|}{|f(x, y)||y|} \\ &= \frac{|f'_x(\bar{x}, \bar{y})||x|}{|f(x, y)|} \cdot \epsilon_x + \frac{|f'_y(\bar{x}, \bar{y})||y|}{|f(x, y)|} \cdot \epsilon_y \end{aligned} \tag{2.16}$$

Da (2.16), si possono ottenere risultati simili ai precedenti per \oplus , \otimes . Uno dei vantaggi è che si possono studiare operazioni più generali come ad esempio cosa succeda se si esegue $\exp(x + y)$.

3. Alcune problematiche numeriche. Si consideri un problema scientifico che abbia a che fare con una procedura di calcolo. Sussistono varie tipologie di errore nei calcoli:

- errori di modellizzazione: vengono utilizzate equazioni per rappresentare un evento fisico, e il modello matematico è solo una semplificazione di quello reale;
- errori di tabulazione: vengono immessi dal programmatore o dal programma dati errati (cosa che ad esempio era comune una volta quando bisognava tabulare manualmente numeri con molte cifre); un errore di questo tipo ha causato nel 1996 la perdita del razzo Ariane 5 per una cattiva conversione di un numero;
- errori dovuti a misure fisiche: sono dovuti a una imprecisa osservazione sperimentale, spesso dovuta agli strumenti utilizzati, ad esempio la velocità della luce nel vuoto è

$$c = (2.997925 + \epsilon) \cdot 10^{10} \text{ cm/s}, \quad |\epsilon| \leq 0.000003$$

e quindi nei calcoli che hanno a che vedere con c necessariamente si compie un errore;

- errori di rappresentazione e di aritmetica di macchina: sono errori dovuti all'arrotondamento o troncamento di un numero, e sono inevitabili quando si usa l'aritmetica floating-point; sono la sorgente principale di errore di alcuni problemi come ad esempio la soluzione di sistemi lineari.

Di seguito vediamo alcune problematiche dovute agli errori di rappresentazione e di aritmetica di macchina. Per una buona serie di esempi si veda [2, p.46].

4. Valutazione di una funzione. Nel valutare una funzione continua $f : \Omega \subseteq \mathbb{R} \rightarrow \mathbb{R}$ in un punto $x \in \Omega$ bisogna tener conto che il dato x può essere per varie ragioni affetto da errori, tipicamente di misura o di rappresentazione al calcolatore, così da essere approssimato con un certo \bar{x} . Di conseguenza, invece di $f(x)$ si valuta $f(\bar{x})$ e ci si domanda se ci siano considerevoli differenze.

Una funzione f risulta difficile da valutare al calcolatore nel punto $x \neq 0$ in cui $f(x) \neq 0$ qualora a piccoli errori (relativi) sui dati

$$|x - x_c|/|x|$$

corrispondano grandi errori (relativi) sui risultati

$$|f(x) - f(x_c)|/|f(x)|.$$

Quindi è importante discutere la quantità

$$\mathcal{K}(f, x, x_c) = \frac{|f(x) - f(x_c)|/|f(x)|}{|x - x_c|/|x|}.$$

La valutazione di f in un punto x si dice *bencondizionata* se a piccole variazioni relative sui dati corrispondono piccole variazioni sui risultati, *malcondizionata* se ciò non avviene. Se f è derivabile con continuità nel più piccolo intervallo \mathcal{I} aperto contenente x ed x_c , per il teorema della media, essendo

$$f(x) - f(x_c) = f'(\xi) \cdot (x - x_c), \quad \xi \in \mathcal{I},$$

e quindi da $|f(x) - f(x_c)|/|x - x_c| = f'(\xi) \approx f'(x)$ ricaviamo facilmente che

$$\mathcal{K}(f, x, x_c) \approx \mathcal{K}(f, x) := \frac{|x \cdot f'(x)|}{|f(x)|}.$$

La quantità $\mathcal{K}(f, x)$ si chiama *condizionamento* di f nel punto x . Più piccola risulta $\mathcal{K}(f, x)$ e meno la funzione amplifica un piccolo errore sul dato x . Naturalmente la funzione può essere *bencondizionata* su un certo dato $x_1 \in \Omega$ e *malcondizionata* su un certo altro $x_2 \in \Omega$. Osserviamo che il condizionamento di una funzione non dipende dall'algoritmo con cui viene valutata, ma è inerente alla funzione stessa f e al dato x .

ESEMPIO 4.1. *Data la funzione*

$$f_1(x) = 1 - \sqrt{1 - x^2}$$

calcoliamo analiticamente il condizionamento

$$\mathcal{K}(f_1, x) = \frac{|x \cdot f_1'(x)|}{|f_1(x)|}$$

Ricordiamo che

$$f_1'(x) = \frac{1}{2\sqrt{1-x^2}}(-2x)$$

da cui per $x \in (-1, 1)$

$$\mathcal{K}(f_1, x) = \frac{|x \cdot f_1'(x)|}{|f_1(x)|} = \frac{|x \cdot \frac{1}{2\sqrt{1-x^2}}(-2x)|}{|1 - \sqrt{1-x^2}|} = \frac{x^2}{|1 - \sqrt{1-x^2}|\sqrt{1-x^2}}.$$

Dal grafico di tale funzione nella Figura 4.1, si vede che la funzione f_1 è ben condizionata in $(-0.9, 0.9)$, ma non lo è per valori prossimi a 1.




FIGURA 4.1. A sinistra il grafico di $\mathcal{K}(f_1, x)$ in $(-1, 1)$, a destra quello di $\mathcal{K}(f_1, x)$ in $(1 - 10^{-4}, 1)$ (malcondizionamento per $|x| \approx 1$).

ESEMPIO 4.2. *Consideriamo quale esempio*

$$f_2(x) = 1 - x.$$

Non è difficile vedere che $f_2'(x) = -1$ e quindi

$$\mathcal{K}(f_2, x) = \frac{|x \cdot f_2'(x)|}{|f_2(x)|} = \frac{|x \cdot (-1)|}{|1 - x|} = \frac{|x \cdot (-1)|}{|1 - x|}.$$

Dal grafico di tale funzione nella Figura 4.2, si vede che la funzione f_2 è ben condizionata ovunque eccetto per valori prossimi a 1. Si osservi che per vicini a tale valore, in effetti, si ha il fenomeno di cancellazione.




FIGURA 4.2. Il grafico di $\mathcal{K}(f_2, x)$ in $(-2, 2)$ (malcondizionamento per $x \approx 1$).

5. Stabilità. Nella sezione precedente abbiamo analizzato il condizionamento di una funzione continua f in un punto x del suo dominio. In particolare, abbiamo supposto che f sia valutabile esattamente e quindi il bencondizionamento dipende esclusivamente da f e dal dato x e non dall'algoritmo utilizzato. Un algoritmo per la risoluzione di un certo problema si dice *stabile* se amplifica *poco* gli errori di arrotondamento introdotti dalle singole operazioni. Il problema non è necessariamente la valutazione di una funzione continua in un punto, ma può essere la risoluzione di una equazione di secondo grado, il calcolo di π greco, la valutazione di una successione, etc. Osserviamo inoltre che nel caso della valutazione in un punto x di una funzione f bencondizionata, si possono ottenere risultati non sufficientemente corretti se il problema è affrontato con un algoritmo instabile.

5.1. Esempio 1: Calcolo di una radice in una equazione di secondo grado. Vediamo un esempio concreto in cui l'introdurre una sottrazione potenzialmente pericolosa conduce effettivamente a problemi di instabilità della soluzione e come rimediare. Dato il polinomio di secondo grado $x^2 + 2px - q$, con $\sqrt{p^2 + q} \geq 0$ calcoliamo la radice

$$y = -p + \sqrt{p^2 + q}. \quad (5.1)$$

Osserviamo che essendo $\sqrt{p^2 + q} \geq 0$ le radici

$$y = -p \pm \sqrt{p^2 + q}. \quad (5.2)$$

dell'equazione sono reali. La soluzione descritta in (5.1) è la maggiore delle 2, ed è non negativa se e solo se $q \geq 0$. Consideriamo la funzione che fissato $q \geq 0$, mappa un numero reale p in $-p \pm \sqrt{p^2 + q}$. Si osserva subito che (5.1) è potenzialmente instabile per $p \gg q$ a causa della sottrazione tra p e $\sqrt{p^2 + q}$. A tal proposito, dopo averla implementata in Matlab, verificheremo numericamente la perdita di accuratezza per opportune scelte dei coefficienti p e q . Ripetiamo poi lo stesso tipo di indagine con una formula alternativa (e stabile) che si ottiene razionalizzando la formula (5.1). In altri termini

$$y = -p + \sqrt{p^2 + q} = \frac{(-p + \sqrt{p^2 + q})(p + \sqrt{p^2 + q})}{(p + \sqrt{p^2 + q})} = \frac{q}{(p + \sqrt{p^2 + q})} \quad (5.3)$$

Ricordiamo ora che un problema si dice *bencondizionato* (o *malcondizionato*) a seconda che nel particolare contesto le perturbazioni sui dati non influenzino (o influenzino) eccessivamente i risultati. Nel caso di un algoritmo, per indicare un simile comportamento rispetto

alla propagazione degli errori dovute alle perturbazioni sui dati, si parla di *algoritmo bencondizionato* (o *algoritmo malcondizionato*) anche se è più usuale il termine di stabilità [4, p. 66].

Seguendo [4, p. 10], [4, p. 78], il problema (e non l'algoritmo!) è *bencondizionato* per $q > 0$ e *malcondizionato* per $q \approx -p^2$.

Usando dei classici ragionamenti dell'analisi numerica si mostra che (cf. [14], p. 21, [5], p. 11)

1. il primo algoritmo (5.2) non è *numericamente stabile* qualora $p \gg q > 0$;
2. il secondo algoritmo (5.3) è *numericamente stabile* qualora $p \gg q > 0$.

Vediamo alcuni casi rilevanti, effettuati in doppia precisione.

- In [14, p.22], si suggerisce un test interessante per

$$p = 1000, q = 0.018000000081$$

la cui soluzione esatta è $0.9 \cdot 10^{-5}$. Si ha $p \gg q$. Lavorando in doppia precisione otteniamo

algoritmo	valore	err. rel.
1	0.0000089999999772772	$2.52 \cdot 10^{-9}$
2	0.0000090000000000000	0

- Secondo [5, p.11], è notevole l'esperimento in cui

$$p = 4.99999999995 \cdot 10^{+4}, q = 10^{-2}$$

avente soluzione esatta 10^{-7} . Nuovamente $p \gg q$.

algoritmo	valore	err. rel.
1	0.0000001000007614493	$7.61 \cdot 10^{-6}$
2	0.0000001000000000000	0

5.2. Esempio 2: Approssimazione di π . Storicamente sono state scoperte diverse successioni convergenti sempre più rapidamente a π (cf. [23]). In questa sezione ci interesseremo a tre di queste mostrando sia come le velocità di convergenza possano essere diverse, sia come possano insorgere questioni di instabilità [6, p. 16].

Studiamo le successioni $\{u_n\}$, $\{z_n\}$, definite rispettivamente come

$$\begin{cases} s_1 = 1, & s_2 = 1 + \frac{1}{4} \\ u_1 = 1, & u_2 = 1 + \frac{1}{4} \\ s_{n+1} = s_n + \frac{1}{(n+1)^2} \\ u_{n+1} = \sqrt{6 s_{n+1}} \end{cases}$$

e

$$\begin{cases} z_1 = 1, & z_2 = 2 \\ z_{n+1} = 2^{n-\frac{1}{2}} \sqrt{1 - \sqrt{1 - 4^{1-n} \cdot z_n^2}} \end{cases}$$

che *teoricamente* convergono a $\pi = 3, 141592653589793238462643383279502884197169399 \dots$

Implementiamo di seguito una terza successione, diciamo $\{y_n\}$, che si ottiene *razionalizzando* z_n , cioè moltiplicando numeratore e denominatore per

$$\sqrt{1 + \sqrt{1 - 4^{1-n} \cdot z_n^2}}$$

e calcoliamo u_m , z_m e y_m per $m = 2, 3, \dots, 40$ (che teoricamente dovrebbero approssimare π).

Si ottengono i seguenti risultati, che tabuliamo per semplicità esclusivamente per $n = 5, 10, 15, 20, 25, 30, 35, 40$.

m	u_n	z_n	y_n
5	2.963387701038571	3.121445152258050	3.121445152258053
10	3.049361635982070	3.141572940365566	3.141572940367093
15	3.079389826032086	3.141592633463248	3.141592634338565
20	3.094669524113704	3.141594125195191	3.141592653570997
25	3.103923391700576	3.142451272494133	3.141592653589779
30	3.110128728141262	4.000000000000000	3.141592653589798
35	3.114578862293132	0.000000000000000	3.141592653589798
40	3.117926198299378	0.000000000000000	3.141592653589798




FIGURA 5.1. Le tre successioni u_n (puntino nero), z_n (punto magenta), y_n (cerchietto rosso). Risulta evidente che z_n diverge, nonostante fino a $n \approx 14$ dia circa gli stessi valori di y_n che invece converge.

Dalla figura e dalla tabella, consegue che

1. la convergenza della prima successione è estremamente lenta;
2. la seconda successione non convergente numericamente, seppure converga teoricamente; il principale problema è la cancellazione che si ha nell'argomento della radice quadrata più esterna di

$$z_{n+1} = 2^{n-\frac{1}{2}} \sqrt{1 - \sqrt{1 - 4^{1-n} \cdot z_n^2}};$$

A tal proposito, nella tabella che segue, evidenziamo i valori assunti da $\sqrt{1 - 4^{1-n} \cdot z_n^2}$, per $n = 5, 10, 15, \dots, 40$.

n	$\sqrt{1 - 4^{1-n} \cdot z_n^2}$
5	9.8078528040323054160154470e - 01
10	9.9998117528260110908888691e - 01
15	9.9999998161642922323011362e - 01
20	9.999999998204724960260137e - 01
25	9.99999999998245847621092e - 01
30	1.000000000000000000000000e + 00
35	1.000000000000000000000000e + 00
40	1.000000000000000000000000e + 00

3. la terza successione risulta rapidamente convergente.

5.3. Esempio 3: Successione ricorrente. In questa sezione mostriamo come alcune formule di ricorrenza in avanti possano essere instabili, mentre d'altro canto le relative versioni all'indietro possono essere stabili [12, Esercizio 1.9, p.35]. Problemi simili con una precisa discussione della propagazione dell'errore sono trattati pure in [6, p. 23, problema 11]

Sia

$$I_n = e^{-1} \int_0^1 x^n e^x dx \quad (5.4)$$

Per $n = 0$ si ha

$$I_0 = e^{-1} \int_0^1 e^x dx = e^{-1}(e^1 - 1).$$

Per $n = 1$, è facile verificare che, essendo

$$\int x \exp(x) dx = (x - 1) \exp(x) + c,$$

dal secondo teorema del calcolo integrale (cf. [19]) si ha che $I_1 = e^{-1}$ e più in generale integrando per parti che

$$I_{n+1} = e^{-1} \left(x^{n+1} e^x \Big|_0^1 - (n+1) \int_0^1 x^n e^x dx \right) = 1 - (n+1) I_n. \quad (5.5)$$

Da (5.4) essendo l'integranda $x^n \exp x > 0$ per $x \in (0, 1]$ si ha

$$I_n > 0.$$

Inoltre $x \leq 1$ implica $x^2 \leq x$ e più in generale $x^{n+1} \leq x^n$ da cui $x^{n+1} \exp(x) \leq x^n \exp(x)$ e quindi

$$I_{n+1} \leq I_n.$$

La successione I_n è positiva e non crescente e quindi ammette limite L finito. Da (5.5), calcolando il limite L per $n \rightarrow \infty$ ad ambo i membri si ottiene portando 1 a primo membro

$$L - 1 = -\lim_n (n+1) I_n.$$

L'unica possibilità affinché $\lim_n (n+1) I_n$ esista e sia finito è che sia

$$L = \lim_n I_n = 0.$$

Infatti se il limite L fosse non nullo, si avrebbe

$$L - 1 = \lim_n (n + 1) I_n = \lim_n (n + 1) \lim_n I_n = +\infty,$$

il che è assurdo essendo $L < +\infty$ e quindi $L - 1 < +\infty$.

1. Come primo tentativo calcoliamo I_n per $n = 1, \dots, 100$ mediante la successione *in avanti*

$$\begin{cases} s_1 = e^{-1} \\ s_{n+1} = 1 - (n + 1) s_n \end{cases}$$

2. Come alternativa, fissato $m = 500$, si calcoli la successione *all'indietro* $\{t_n\}_{n=1, \dots, 100}$ definita come

$$\begin{cases} t_{2m} = 0 \\ t_{n-1} = \frac{1-t_n}{n} \end{cases}$$

Si osservi che per raggiungere tale obiettivo bisogna calcolare i termini

$$t_m, t_{m-1}, \dots, t_{100}, t_{99}, \dots, t_2, t_1.$$

Notiamo che tale successione all'indietro deriva dall'osservare che per n sufficientemente grande $I_n \approx 0$. Quindi, posto per n sufficientemente grande $I_n = 0$ riscrivendo la successione in avanti come successione all'indietro (cioè I_n in funzione di I_{n+1}), abbiamo

$$I_n = \frac{1 - I_{n+1}}{n + 1}.$$

Dopo aver eseguito i calcoli otteniamo per $n = 10, 20, \dots, 100$ la seguente tabella

n	$\sqrt{1 - 4^{1-n} \cdot z_n^2}$	
10	$8.387707005829270e - 02$	$8.387707010339417e - 02$
20	$-3.019239488558378e + 01$	$4.554488407581805e - 02$
30	$-3.296762455608386e + 15$	$3.127967393216808e - 02$
40	$-1.014081007335147e + 31$	$2.382272866903348e - 02$
50	$-3.780092725853228e + 47$	$1.923775443433938e - 02$
60	$-1.034194991387092e + 65$	$1.613316466384628e - 02$
70	$-1.488787166378969e + 83$	$1.389153285400528e - 02$
80	$-8.895191521232202e + 101$	$1.219691454831806e - 02$
90	$-1.846559775027300e + 121$	$1.087083605943215e - 02$
100	$-1.159928542966359e + 141$	$9.804855005376052e - 03$

La tabella mostra che

1. s_n non converge numericamente seppure lo faccia teoricamente,
2. t_n converge numericamente e teoricamente, qualora per calcolare t_n , $n < N$ si parta da un valore $m \gg N$. Nel nostro esempio, per $N = 100$, siamo partiti da $m = 500$.

La motivazione di tale comportamento consiste nel fatto che la prima successione, cioè quella in avanti, amplifica enormemente l'errore in avanti mentre la seconda, detta all'indietro, fa esattamente il contrario.

In effetti anche se operassimo in aritmetica esatta, per quanto concerne la successione in avanti I_n , se $I_0^* = I_0 + \epsilon$ allora la successione calcolata $I_{n+1}^* = 1 - (n + 1)I_n^*$ è tale che $I_n^* - I_n = n!\epsilon$, giustificando i risultati ottenuti.

5.4. Esempio 4: sulla somma $\frac{(1+\eta)-1}{\eta}$. Calcoliamo l'errore relativo tra 1 e il valore che si ottiene valutando in doppia precisione

$$f(\eta) = \frac{(1+\eta)-1}{\eta}$$

con $\eta = 10^{-1}, 10^{-2}, \dots, 10^{-15}$. Ovviamente il risultato esatto di questa divisione è sempre 1, per qualsiasi η .

Notiamo che il calcolatore effettuerà invece $f^*(\eta)$ ottenuta

1. valutando $a_1 = fl(fl(1) + fl(\eta))$;
2. valutando $a_2 = fl(fl(a_1) - fl(1))$;
3. valutando $a_3 = fl(fl(a_2) : fl(\eta))$.

in cui ovviamente $fl(1) = 1$, $fl(a_1) = a_1$, $fl(a_2) = a_2$ visto che a_1, a_2 sono numeri floating point.

I risultati ottenuti nel valutare $f^*(\eta)$ sono potenzialmente diversi da $f(\eta) = 1$ (ma non per gli interi, perchè?).

Ricordando la notazione esponenziale in cui ad esempio $3.1e-02 = 3.1 \cdot 10^{-2}$, e che l'errore relativo risulta

$$\frac{|f(\eta) - f^*(\eta)|}{|f(\eta)|} = \frac{|1 - f^*(\eta)|}{1} = |1 - f^*(\eta)|$$

abbiamo

η	$f^*(\eta)$	rel.err.
$1.00e-01$	$1.000000000000001e+00$	$8.881784e-16$
$1.00e-02$	$1.000000000000001e+00$	$8.881784e-16$
$1.00e-03$	$9.99999999998899e-01$	$1.101341e-13$
$1.00e-04$	$9.99999999998899e-01$	$1.101341e-13$
$1.00e-05$	$1.000000000006551e+00$	$6.551204e-12$
$1.00e-06$	$9.99999999177334e-01$	$8.226664e-11$
$1.00e-07$	$1.000000000583867e+00$	$5.838672e-10$
$1.00e-08$	$9.99999939225290e-01$	$6.077471e-09$
$1.00e-09$	$1.000000082740371e+00$	$8.274037e-08$
$1.00e-10$	$1.000000082740371e+00$	$8.274037e-08$
$1.00e-11$	$1.000000082740371e+00$	$8.274037e-08$
$1.00e-12$	$1.000088900582341e+00$	$8.890058e-05$
$1.00e-13$	$9.992007221626409e-01$	$7.992778e-04$
$1.00e-14$	$9.992007221626409e-01$	$7.992778e-04$
$1.00e-15$	$1.110223024625157e+00$	$1.102230e-01$

La perdita di precisione è dovuta essenzialmente al fenomeno di cancellazione, visto che $1 + \eta \approx 1$. Ricordato che eps è un numero macchina e che per numeri più piccoli η in modulo di eps si ha $1 + x = 1$ non sorprende inoltre sia

η	$f^*(\eta)$	rel.err.
eps	$1.000000000000000e+00$	$0.000000e+00$
$\text{eps}/2$	$0.000000000000000e+00$	$1.000000e+00$
$\text{eps}/3$	$0.000000000000000e+00$	$1.000000e+00$

In effetti, per questi ultimi valori η più piccoli in modulo di eps , visto che comunque $fl(\eta) > 0$ (pensarci su!),

$$\frac{(1 + fl(\eta)) - 1}{fl(\eta)} = \frac{1 - 1}{fl(\eta)} = 0.$$

5.5. Esempio 5: Sulla valutazione di $\tan(\arctan(x)) = x$. Siano $f := \tan$ e $g := \arctan$. Si consideri la funzione composta

$$f \cdot g(x) := f(g(x)) = \tan(\arctan(x)) = x, \quad x \in (-\infty, +\infty).$$

Ci domandiamo se l'implementazione numerica di questa funzione goda ancora di questa proprietà.

Valutiamo la funzione g numericamente, mediante la corrispettiva versione numerica g^* per

$$x = 10^k, \text{ per } k = -20 + 40h, \text{ e } h = 0, 0.1, 0.2, \dots, 1$$

e valutiamo l'errore relativo compiuto, ovvero $|g(x) - g^*(x)|/|g(x)|$, notando che $g(x) \neq 0$ visto che nei casi in questione si ha $x \neq 0$. Descriviamo questi risultati nella tabella che segue.

x	$g^*(x)$	rel.err.
$1.0e - 20$	$1.0000000000000000e - 20$	$0.00000e + 00$
$1.0e - 16$	$1.0000000000000000e - 16$	$0.00000e + 00$
$1.0e - 12$	$1.0000000000000000e - 12$	$0.00000e + 00$
$1.0e - 08$	$1.0000000000000004e - 08$	$0.00000e + 00$
$1.0e - 04$	$1.0000000000000000e - 04$	$0.00000e + 00$
$1.0e + 00$	$9.999999999999999e - 01$	$1.11022e - 16$
$1.0e + 04$	$9.99999999990539e + 03$	$9.46056e - 13$
$1.0e + 08$	$9.99999999542369e + 07$	$4.57631e - 11$
$1.0e + 12$	$1.000071916854289e + 12$	$7.19117e - 05$
$1.0e + 16$	$1.633123935319537e + 16$	$3.87677e - 01$
$1.0e + 20$	$1.633123935319537e + 16$	$6.12223e + 03$

Osserviamo che i valori critici sono tra 1 e 10^4 . In effetti un'ulteriore analisi propone

x	$g^*(x)$	rel.err.
$1.0000000000000000e + 00$	$9.999999999999999e - 01$	$1.11022e - 16$
$2.511886431509580e + 00$	$2.511886431509580e + 00$	$0.00000e + 00$
$6.309573444801933e + 00$	$6.309573444801929e + 00$	$7.03834e - 16$
$1.584893192461114e + 01$	$1.584893192461114e + 01$	$1.12081e - 16$
$3.981071705534973e + 01$	$3.981071705534988e + 01$	$3.56961e - 15$
$1.0000000000000000e + 02$	$1.000000000000010e + 02$	$1.00897e - 14$
$2.511886431509580e + 02$	$2.511886431509614e + 02$	$1.38042e - 14$
$6.309573444801930e + 02$	$6.309573444802187e + 02$	$4.07210e - 14$
$1.584893192461114e + 03$	$1.584893192461186e + 03$	$4.54778e - 14$
$3.981071705534973e + 03$	$3.981071705533795e + 03$	$2.95849e - 13$
$1.0000000000000000e + 04$	$9.99999999990539e + 03$	$9.46056e - 13$

Quindi numericamente g e g^* non coincidono, anche per valori non eccessivi di x .

6. Facoltativo: Rappresentazione IEEE 754 dei numeri al calcolatore. La rappresentazione numerica nei moderni calcolatori rispetta in genere lo standard IEEE 754 che andiamo brevemente a descrivere.

Si intende per *bit* una cifra nel sistema (usualmente binario) usato [4, p. 48], [13, p. 47].

Nello standard IEEE 754, i numeri in virgola mobile a precisione singola sono memorizzati in un vettore detto *parola* di 32 bits, mentre quelli a precisione doppia occupano due

parole consecutive da 32 bits. Un numero *non nullo-normalizzato* si scrive come

$$x = (-1)^S \cdot 2^{E-Bias} \cdot (1 + F) \quad (6.1)$$

dove $S = 0$ oppure $S = 1$ determina il *segno*, $E - Bias$ è l'*esponente* cui va sottratto il valore del BIAS ed F la *mantissa* con $F = \sum_{k=1}^{+\infty} a_k 2^{-k}$, con $a_k = 0$ oppure $a_k = 1$. Evidentemente, in un calcolatore non si possono immagazzinare un numero infinito di a_k , e ci si limita ai cosiddetti *numeri macchina*

$$x = (-1)^S \cdot 2^{E-Bias} \cdot (1 + F) \quad (6.2)$$

con E intero tale che $|E| < 2^{N_E}$ per un certo prefissato N_E e $F = \sum_{k=1}^{N_F} a_k 2^{-k}$,
Alcuni esempi

Precisione	N_E	N_F	Bias
Singola	8	23	127
Doppia	11	52	1023

Partiamo con un esempio semplice. Il numero 12 corrisponde in singola precisione a

$$[0 \mid 10000010 \mid 1000000000000000000000]$$

Cerchiamo di comprenderne il significato:

1. 0 determina il segno. Poichè $(-1)^0 = 1$ il segno è +.
2. 10000010 determina il valore della potenza di 2. Essendo il BIAS uguale a 127 e (si legga da destra a sinistra!) $E = 10000010 = 0 \cdot 2^0 + 1 \cdot 2^1 + 0 \cdot 2^2 + 0 \cdot 2^3 + 0 \cdot 2^4 + 0 \cdot 2^5 + 0 \cdot 2^6 + 1 \cdot 2^7 = 2 + 128 = 130$, l'esponente vale $130 - 127 = 3$. Quindi $2^{E-Bias} = 2^3 = 8$.
3. $F = 1000000000000000000000$ è la componente relativa alla mantissa. La quantità, letta da sinistra a destra, riguarda la parte decimale F in (6.2). Quindi $F = 1 \cdot 2^{-1} + 0 \cdot 2^{-2} + \dots = 0.5$. Ora $(1 + F)$ si legge come $1 + F = 1.5$.

In altre parole la rappresentazione di 12 è esatta ed il numero è rappresentato come $12 = 8 \cdot 1.5$.

Non convinti, proviamo un altro esempio, ad esempio 126 che corrisponde in singola precisione a

$$[0 \mid 10000101 \mid 1111100000000000000000]$$

1. 0 determina il segno. Poichè $(-1)^0 = 1$ il segno è +.
2. 10000101 determina il valore. Essendo il BIAS uguale a 127 e (si legga da destra a sinistra!) $E = 10000101 = 1 \cdot 2^0 + 0 \cdot 2^1 + 1 \cdot 2^2 + 0 \cdot 2^3 + 0 \cdot 2^4 + 0 \cdot 2^5 + 0 \cdot 2^6 + 1 \cdot 2^7 = 1 + 4 + 128 = 133$, l'esponente vale $133 - 127 = 6$. Quindi $2^{E-Bias} = 2^6 = 64$. Viene da chiedersi perchè introdurre il BIAS. La risposta è che rappresenta un'alternativa all'introduzione di un bit di segno per l'esponente.

3. $F = 111110000000000000000000$ è la componente relativa alla mantissa. La quantità, letta da sinistra a destra, riguarda la parte decimale F in (6.2). Quindi $F = 1 \cdot 2^{-1} + 1 \cdot 2^{-2} + 1 \cdot 2^{-3} + 1 \cdot 2^{-4} + 1 \cdot 2^{-1} + \dots = 0.5 + 0.25 + 0.125 + 0.0625 + 0.03125 = 0.96875$. Ora $(1 + F)$ si legge come $1 + F = 1.96875$.

In altre parole la rappresentazione di 126 è esatta ed il numero è rappresentato come $126 = 64 \cdot 1.96875$.

La distanza tra un numero in virgola mobile x^- ed il successivo x^+ , è

$$2^{-N_F} \cdot 2^{E-bias}.$$

Per convincersene, supponiamo che siano

$$x^- = (-1)^S \cdot 2^{E-Bias} \cdot (1 + F^-), \quad x^+ = (-1)^S \cdot 2^{E-Bias} \cdot (1 + F^+).$$

Allora, essendo $F^+ - F^- = 2^{-N_F}$ (pensarci su!) facilmente

$$|x^+ - x^-| = 2^{E-Bias} \cdot (F^+ - F^-) = 2^{-N_F} \cdot 2^{E-bias}.$$

La cardinalità dei numeri macchina in IEEE 754 è piuttosto elevata. Ad esempio, in doppia precisione sono

$$2^{64} \approx 1.844674407370955e + 019.$$

La *precisione di macchina*, cioè quel numero che rappresenta la distanza tra 1 ed il successivo numero in virgola mobile. Per avere un'idea del suo ordine di grandezza, tale valore eps in Matlab 7.6.0 vale

```
>> format long
>> eps
ans =
    2.220446049250313e-16
>>
```

6.1. Facoltativo: Su eps, realmax, realmin, overflow e underflow in IEEE754. I numeri nella rappresentazione floating-point stanno in un intervallo limitato, quindi l'*infinitamente piccolo* e l'*infinitamente grande* non sono rappresentabili come numeri in virgola mobile, nel calcolatore. Quando si raggiunge un valore talmente piccolo da non essere più distinto dallo zero, si parla di *underflow*, mentre quando si eccede il massimo numero rappresentabile, si parla di *overflow*. Il limite inferiore (che non sia *denormalizzato*!) è pari a 2^{1-bias} ed in Matlab è espresso dalla variabile `realmin`. Il limite superiore è pari a $2^{2^N_E - 2 - bias} \cdot (1 + (1 - 2^{-Fbits}))$ ed in Matlab è espresso dalla variabile `realmax`. Verifichiamolo.

1. Dalla tabella, in precisione doppia, si ha che $bias=1023$ e quindi

$$2^{1-1023} = 2^{-1022} = 2.225073858507201e - 308$$

Se digitiamo nella shell di Matlab il comando `realmin` otteniamo proprio questo valore.

2. Dalla tabella, in precisione doppia, si ha che $bias = 1023$, $N_E = 11$, ed $N_F = 52$.
Conseguentemente

$$\begin{aligned} \text{realmax} &= 2^{2^{N_E} - 2 - bias} \cdot (1 + (1 - 2^{-N_F})) \\ &= 2^{2^{11} - 2 - 1023} \cdot (1 + (1 - 2^{-52})) \\ &= 2^{2^{11} - 2 - 1023} \cdot (2 - 2^{-52}) = \\ &= 1.797693134862316e + 308 \end{aligned}$$

Per convincercene, digitiamo nella shell di Matlab/Octave

```
>> s=2^11-1025;
>> m=2-2^(-52)
m =
    2.0000
>> m=2-2^(-52);
>> t=(2^s)*m
t =
    1.7977e+308
>> realmax
ans =
    1.7977e+308
>> t-realmax
ans =
     0
>>
```

Quindi digitando `realmax` nella shell di Matlab otteniamo proprio questo valore.

Osserviamo che in realtà `realmin` non sembra essere il numero più piccolo in valore assoluto. Testiamolo sulla shell di Matlab.

```
>> help realmax
```

```
REALMAX Largest positive floating point number.
x = realmax is the largest floating point number representable
on this computer. Anything larger overflows.
```

```
See also EPS, REALMIN.
```

```
Overloaded methods
help quantizer/realmax.m
```

```
>> a=realmax \cdot 2
a =
    Inf
>> help realmin
```

```
REALMIN Smallest positive floating point number.
x = realmin is the smallest positive normalized floating point
number on this computer. Anything smaller underflows or is
an IEEE "denormal".
```

```
See also EPS, REALMAX.
```

```

Overloaded methods
    help quantizer/realmin.m

>> realmin/(2^51) == 0
ans =
    0
>> realmin/(2^52) == 0
ans =
    0
>> realmin/(2^53) == 0
ans =
    1
>>

```

Siccome in un costrutto logico il valore 1 corrisponde a `true`, si ricava che

$$\text{realmin}/(2^{52}) \approx 4.940656458412465\text{e} - 324$$

è ancora un numero macchina, ma che fa parte dei cosiddetti *numeri denormalizzati* (cf. [13], p.49) e cioè del tipo

$$x = (-1)^S \cdot 2^{E-Bias} \cdot (0.F). \quad (6.3)$$

Per curiosità vediamo il codice Matlab che implementa `realmin`:

```

function xmin = realmin
%REALMIN Smallest positive floating point number.
%   x = realmin is the smallest positive normalized floating point
%   number on this computer. Anything smaller underflows or is
%   an IEEE "denormal".
%
%   See also EPS, REALMAX.
%
%   C. Moler, 7-26-91, 6-10-92.
%   Copyright 1984-2001 The MathWorks, Inc.
%   $Revision: 5.8 $   $Date: 2001/04/15 12:02:27 $

minexp = -1022;

% pow2(f,e) is f \cdot 2^e, computed by adding e to the exponent of f.

xmin = pow2(1,minexp);

```

Per quanto concerne `pow2`:

```

>> help pow2

POW2   Base 2 power and scale floating point number.
       X = POW2(Y) for each element of Y is 2 raised to the power Y.

       X = POW2(F,E) for each element of the real array F and a integer
       array E computes X = F . \cdot (2 .^ E). The result is computed
       quickly by simply adding E to the floating point exponent of E.

```





FIGURA 7.1. Grafico che illustra le suddivisioni considerate dall'algoritmo di Archimede, per $p = 3$, $p = 4$.

This corresponds to the ANSI C function `ldexp()` and the IEEE floating point standard function `scalbn()`.

See also `LOG2`, `REALMAX`, `REALMIN`.

>>

7. Alcuni esercizi in Matlab.

1. **Esercizio facoltativo difficile.** Esistono più successioni che approssimano π e sono attribuite ad Archimede. Ad esempio, osservato che questi non è altro che l'area del cerchio avente raggio 1, si inscrivono nel cerchio al variare di $p = 2, 3, \dots$ dei poligoni regolari aventi 2^p lati. Osserviamo che per $p = 2$, si deve determinare l'area del quadrato inscritto, che con facili conti è uguale a 2.

Nel caso generale, si osserva che il poligono consiste di 2^p triangoli in cui un lato corrisponde ad un lato del poligono e un vertice con il centro del cerchio (si confronti con le figure).

Se indichiamo con θ l'angolo al centro di ogni triangolo, si verifica che la sua area è $\frac{\sin(\theta)}{2}$. In particolare per un poligono di 2^p lati, si ha $\theta_p = \frac{2\pi}{2^p}$ e l'area del poligono inscritto, costituito da 2^p triangoli uguali, è

$$I_p = 2^p \frac{\sin(\theta_p)}{2} = 2^p \frac{\sin(\frac{2\pi}{2^p})}{2}.$$

In realtà Archimede usò questa ed altre idee per cercare di approssimare π con stime dall'alto e dal basso, via anche poligoni circoscritti. Come citato in [18]:

Nel breve lavoro "La misura del cerchio" viene dimostrato anzitutto che un cerchio è equivalente a un triangolo con base eguale alla circonferenza e altezza eguale al raggio.

Tale risultato è ottenuto approssimando arbitrariamente il cerchio, dall'interno e dall'esterno, con poligoni regolari inscritti e circoscritti.

Con lo stesso procedimento Archimede espone un metodo con il quale può approssimare arbitrariamente il rapporto tra circonferenza e diametro di un cerchio dato, rapporto che oggi si indica con π . Le stime esplicitamente ottenute limitano questo valore fra $22/7$ e $3 + 10/71$.

Secondo [24], Archimede usò un altro algoritmo per approssimare π .

Visto che 2π non è altro che la lunghezza della circonferenza del cerchio avente raggio uguale a 1 e questa è maggiore del perimetro a_k di un qualsiasi poligono regolare di $n = 6 \cdot 2^k$ lati inscritto e minore del perimetro di un qualsiasi poligono regolare di $n = 6 \cdot 2^k$ lati circoscritto b_k , misurando a_k e b_k si può affermare che

$$a_k \leq 2\pi \leq b_k.$$

Si può inoltre provare che

$$a_k = 2n \sin\left(\frac{\pi}{n}\right),$$

$$b_k = 2n \tan\left(\frac{\pi}{n}\right).$$

Stimare π come

$$a_k \leq 2\pi \leq b_k.$$

Per quale n si riesce a determinare π con 10 cifre decimali esatte? Pensare se sia giusto dire $b_k - a_k < 10^{-10}$ allora π è approssimato da a_k con 10 cifre decimali esatte.

A. Si approssimi π usando il primo algoritmo di Archimede (basato sull'area di poligoni regolari inscritti) per $p = 2 : 20$. Si stampi l'errore assoluto e relativo compiuto.

B. Stimare π come

$$a_k \leq \pi \leq b_k$$

mediante l'algoritmo di Archimede basato sulla valutazione dei perimetri a_k, b_k di alcuni poligoni regolari. Per quale n si riesce a determinare π con 10 cifre decimali esatte? Per $k = 0, \dots, 4$ si ha

$$3.00000 \leq \pi \leq 3.46410 \quad (7.1)$$

$$3.10583 \leq \pi \leq 3.21539 \quad (7.2)$$

$$3.13263 \leq \pi \leq 3.15966 \quad (7.3)$$

$$3.13935 \leq \pi \leq 3.14609 \quad (7.4)$$

$$3.14103 \leq \pi \leq 3.14271 \quad (7.5)$$

NOTA 7.1. Il fatto che ci sia un π nei secondi membri di alcune espressioni non è un gatto che si morde la coda. Infatti è solo una trascrizione in radianti di un angolo che ha un significato geometrico indipendente dalla quantità π . In questi esercizi, per semplificare la questione si usa però π per calcolare π , cosa che dimostra una volta in più l'abilità di Archimede, che calcolò tali quantità con metodi elementari e geometrici.

Si cita il fatto che per $k = 4$ Archimede riuscì ad affermare che

$$\frac{223}{71} \leq \pi \leq \frac{22}{7}.$$

2. **Esercizio, facile facoltativo.** Posto $h = 10^{-1}, 10^{-2}, \dots, 10^{-15}$, si approssimi la derivata di $\exp(1)$ con il rapporto incrementale

$$\frac{\exp(1+h) - \exp(1)}{h}$$

e quindi si valuti l'errore assoluto compiuto (rispetto alla soluzione $\exp(1)$). L'approssimazione migliora al diminuire di h ?

3. **Esercizio, facile facoltativo.** Si esegua una tabella in cui si studino a due a due le somme, prodotti, divisioni di NaN, Inf, 0, 1 e confrontarle con i noti risultati di indeterminazione della teoria dei limiti.
4. **Esercizio, facile facoltativo.** Fissato $\theta = 0 : (2\pi/1001) : 2\pi$, si valuti $\sin^2(\theta) + \cos^2(\theta)$ e si calcoli l'errore assoluto rispetto il valore 1.

8. **Online.** Alcuni siti utili per la comprensione della lezione:

1. <http://it.wikipedia.org/wiki/Archimede>
2. <http://utenti.quipo.it/base5/numeri/pigreco.htm>
3. http://it.wikipedia.org/wiki/Pi_greco
4. http://it.wikipedia.org/wiki/Teorema_fondamentale_del_calcolo_integrale
5. http://it.wikipedia.org/wiki/Floating_point
6. http://it.wikipedia.org/wiki/IEEE_754r
7. http://it.wikipedia.org/wiki/IEEE_754
8. https://en.wikipedia.org/wiki/IEEE_754-1985
9. <http://mathworld.wolfram.com/ArchimedesAlgorithm.html>

RIFERIMENTI BIBLIOGRAFICI

- [1] K. Atkinson, *An Introduction to Numerical Analysis*, Wiley, (1989).
- [2] K. Atkinson and W. Han, *Elementary Numerical Analysis*, third edition, Wiley, (2004).
- [3] N. Brisebarre and collaborators *Floating-Point Arithmetic*, 2009.
<https://perso.ens-lyon.fr/jean-michel.muller/chapitre1.pdf>
- [4] V. Comincioli, *Analisi Numerica, metodi modelli applicazioni*, Mc Graw-Hill, 1990.
- [5] V. Comincioli, *Problemi di analisi numerica*, Mc Graw-Hill, 1991.
- [6] M. Frontini e E. Sormani, *Fondamenti di Calcolo Numerico, problemi in laboratorio*, Apogeo, 2005.
- [7] D. Goldberg, *What Every Computer Scientist Should Know About Floating-Point Arithmetic*, Association for Computing Machinery, Inc, Computing Surveys, March 1991.
- [8] T. Huckle, <http://www.zenger.informatik.tu-muenchen.de/persons/huckle/bugse.html>.
- [9] J.H. Mathews e K.D. Fink, *Numerical Methods using Matlab*, Prentice Hall, 1999.
- [10] Network Theory, GNU Octave Manual Version, http://www.network-theory.co.uk/docs/octave3/octave_160.html.
- [11] A. Quarteroni, *Elementi di calcolo numerico*, seconda edizione, Progetto Leonardo, 1999.
- [12] A. Quarteroni e F. Saleri, *Introduzione al calcolo scientifico*, Springer Verlag, 2006.
- [13] A. Quarteroni, R. Sacco e F. Saleri, *Matematica Numerica*, Springer Verlag, 1998.
- [14] J. Stoer, *Introduzione all'analisi numerica*, Zanichelli, 1984.
- [15] The MathWorks Inc., *Numerical Computing with Matlab*, <http://www.mathworks.com/moler>.
- [16] L.N. Trefethen, *Numerical Analysis*, <http://people.maths.ox.ac.uk/trefethen/NAessay.pdf>.
- [17] Web Page, <http://utenti.quipo.it/base5/numeri/pigreco.htm>.

- [18] Wikipedia (Archimede),
<http://it.wikipedia.org/wiki/Archimede>
- [19] Wikipedia (Teorema Fondamentale del Calcolo Integrale),
http://it.wikipedia.org/wiki/Teorema_fondamentale_del_calcolo_integrale
- [20] Wikipedia (Floating Point),
http://it.wikipedia.org/wiki/Floating_point
- [21] Wikipedia (IEEE 754),
http://it.wikipedia.org/wiki/IEEE_754
- [22] Wikipedia (IEEE 754r),
http://it.wikipedia.org/wiki/IEEE_754r
- [23] Wikipedia (Pi Greco),
http://it.wikipedia.org/wiki/Pi_greco
- [24] Wolfram (Archimedes' Algorithm),
<http://mathworld.wolfram.com/ArchimedesAlgorithm.html>