

Numeri macchina

Alvise Sommariva

Università degli Studi di Padova
Dipartimento di Matematica Pura e Applicata

6 marzo 2019

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

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

dove

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

è la funzione segno.

- Nello standard IEEE 754-1985 la base più utilizzata risulta $\beta = 2$,
- Usualmente scriviamo i numeri nel sistema decimale, ovvero con $\beta = 10$.

Numeri macchina e loro proprietà

Esempi particolari di

$$x = \operatorname{sgn}(x)\beta^e \sum_{k=1}^{+\infty} d_k \beta^{-k}, \quad 0 < d_1, 0 \leq d_k \leq \beta - 1, e \in \mathbb{Z} \quad (2)$$

■ In base 2,

$$x = \operatorname{sgn}(x) \cdot 2^e \sum_{k=1}^{+\infty} d_k \cdot 2^{-k}, \quad d_1 = 1, d_k = 0, 1, e \in \mathbb{Z}$$

■ In base 10,

$$x = \operatorname{sgn}(x) \cdot 10^e \sum_{k=1}^{+\infty} d_k \cdot 10^{-k}, \quad d_1 = 1, \dots, 9, d_k = 0, \dots, 9, e \in \mathbb{Z}$$

Numeri macchina e loro proprietà : esempio 1.

Esempio.

Rappresentare il numero

$$\pi = 3,141592653589793238 \dots$$

nella forma

$$\operatorname{sgn}(\pi)\beta^e \sum_{k=1}^{+\infty} d_k \beta^{-k}, \quad 0 < d_1, 0 \leq d_k \leq \beta - 1, e \in \mathbb{Z}$$

per $\beta = 10$ e $\beta = 2$.

Numeri macchina e loro proprietà : esempio 1.

Base 10: 3,141592653589793238... secondo la rappresentazione

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

risulta

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

che viene spesso denotato come

$$\pi = (+1) \cdot (0.3141592653589793238 \dots)_{10} \cdot 10^1;$$

Base 2: il numero π , si scrive come

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

che viene spesso denotato come

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

Numeri macchina e loro proprietà : esempio 2.

Esempio.

Rappresentare il numero

$$\exp(10) = 22026.46579480671789497137 \dots$$

nella forma

$$\operatorname{sgn}(\exp(10))\beta^e \sum_{k=1}^{+\infty} d_k \beta^{-k}, \quad 0 < d_1, 0 \leq d_k \leq \beta - 1, e \in \mathbb{Z}$$

per $\beta = 10$.

Per quanto visto

$$\exp(10) = (+1) \cdot 10^5 \cdot (2 \cdot 10^{-1} + 2 \cdot 10^{-2} + 0 \cdot 10^{-3} + 2 \cdot 10^{-4} + \dots).$$

Numeri macchina e loro proprietà

La particolarità della sommatoria in (1), ovvero

$$x = \operatorname{sgn}(x)\beta^e \sum_{k=1}^{+\infty} d_k \beta^{-k}, \quad 0 < d_1, 0 \leq d_k \leq \beta - 1, e \in \mathbb{Z} \quad (3)$$

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 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 $\beta = 3$).

Numeri floating point

Definizione (Numeri macchina)

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

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

con $0 \leq d_k \leq \beta - 1$ dove

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

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

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

Numeri floating point

Osserviamo che se $e > 0$ allora

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

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

In altri termini, se $e > 0$, **le prime "e" cifre determinano la parte intera, le altre la parte frazionaria.**

Nota.

Si noti che la parte intera ha potenze non negative di β e quindi effettivamente è un numero naturale, mentre la parte frazionaria è somma di potenze negative di β , che si mostra con un po' di tecnica essere un numero in $[0, 1)$.

Numeri floating point

Esempio.

Con riferimento a

$$\text{exp}(10) = (+1) \cdot 10^5 \cdot (2202646579480671789497137)_{10}.$$

visto che $e = 5 > 0$, le prime 5 cifre della mantissa sono relative alla parte intera, le altre alla parte frazionaria.

In effetti

$$\text{exp}(10) = 22026.46579480671789497137 \dots$$

Nota.

*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.*

Numeri floating point

Di ogni numero macchina si immagazzinano

- una cifra per il segno (ovvero 0 per positivo e 1 per negativo),
- le cifre dell'esponente, diciamo m ,
- le cifre della mantissa, diciamo t .

segno	esponente	mantissa
1 cifra	m cifre	t cifre

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

Numeri floating point

Nota.

Nella notazione binaria normalizzata, immagazzinate le cifre $(1, d_1, \dots, d_{t-1})_\beta$ e l'esponente "e", a volte si intende

$$y = \operatorname{sgn}(y) \cdot (1.d_2 \dots d_t)_\beta \beta^e = \operatorname{sgn}(y) \cdot \beta^e \left(1 + \sum_{k=2}^t d_k \beta^{-k}\right) \quad (4)$$

e non come in precedenza

$$\begin{aligned} y &= \operatorname{sgn}(y) \cdot (1.d_1 \dots d_{t-1})_\beta \beta^e \\ &= \operatorname{sgn}(y) \cdot \beta^e \left(\beta^{-1} + \sum_{k=2}^t d_{k-1} \beta^{-k}\right). \end{aligned} \quad (5)$$

Questo potenzialmente può creare qualche confusione. Scegliamo di utilizzare (5) perchè più frequente nei manuali di analisi numerica.

Alcune proprietà di $F(\beta, t, L, U)$

Vediamo di seguito, alcune proprietà di $F(\beta, t, L, U)$.

Proposizione.

Il più piccolo numero macchina positivo (normalizzato) è β^{L-1} .

Dimostrazione.

Ponendo $d_1 = 1$, $d_2 = \dots = d_t = 0$ ed $e = L$ in $\beta^e \sum_{k=1}^t d_k \beta^{-k}$ otteniamo che il più piccolo numero macchina (e quindi normalizzato!) positivo rappresentabile è β^{L-1} . △

Alcune proprietà di $F(\beta, t, L, U)$

Proposizione.

Il più grande numero macchina (normalizzato) è $\beta^U(1 - \beta^{-t})$, dove t è il numero di cifre della mantissa.

Dimostrazione facoltativa.

Ponendo $d_k = \beta - 1$, per $k = 1, \dots, t$ ed $e = U$ in $\beta^e \sum_{k=1}^t d_k \beta^{-k}$ otteniamo che il massimo numero macchina rappresentabile è

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

In effetti, essendo $\sum_{k=1}^t \gamma^k = \frac{1 - \gamma^{t+1}}{1 - \gamma} - 1$, dopo qualche conto otteniamo:

$$\sum_{k=1}^t (\beta - 1) \beta^{-k} = \dots = (\beta - 1) \left(\frac{\beta^{-(t+1)} - 1}{\beta^{-1} - 1} - 1 \right) = \dots = 1 - \beta^{-t}.$$



Alcune proprietà di $F(\beta, t, L, U)$

Proposizione.

La somma relativa alla mantissa, cioè $\sum_{k=1}^t d_k \beta^{-k}$, appartiene all'intervallo $(0, 1 - \beta^{-t}]$ e quindi positiva e strettamente minore di 1.

Dimostrazione facoltativa.

Il ragionamento è lo stesso visto nella dimostrazione precedente prendendo quale esponente 0 invece di U .



Alcune proprietà di $F(\beta, t, L, U)$

Proposizione.

L'insieme dei numeri macchina $F(\beta, t, L, U)$ ha un numero finito di elementi e la sua *cardinalità* è

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

Dimostrazione facoltativa.

Per una fissata mantissa, a t cifre, il numero più piccolo che possiamo scrivere è $(10\dots 00)_\beta$ mentre il più grande è

$$\underbrace{(\beta - 1 \beta - 1 \dots \beta - 1 \beta - 1)}_t)_\beta.$$

Così non è difficile vedere che i numeri scrivibili con t cifre di mantissa sono quelli in cui la prima cifra va da 1 a $\beta - 1$ e le altre da 0 a $\beta - 1$, e quindi la loro cardinalità risulta

$$(\beta - 1) \cdot \underbrace{\beta \dots \beta}_{t-1} = (\beta - 1)\beta^{t-1}.$$

Quindi, al variare dell'esponente e in $L, L + 1, \dots, U - 1, U$, e del segno $+$ o $-$, i numeri floating-point sono $2(\beta - 1)\beta^{t-1}(U - L + 1)$.



Alcune proprietà di $F(\beta, t, L, U)$

Proposizione.

- 1 I numeri macchina sono numeri *razionali*.
- 2 I numeri macchina che hanno esponente $e \geq t$ sono *interi*.

Dimostrazione facoltativa.

La scrittura dei numeri floating-point come somma di un numero finito di numeri frazionari implica che i numeri risultanti siano razionali.

Per vedere se $e \geq t$ allora sono interi, da

$$x = \text{sgn}(x)\beta^e \sum_{i=1}^t d_i \beta^{-i} = \text{sgn}(x) \sum_{i=1}^t d_i \beta^{e-i}$$

visto che per $i = 1, \dots, t \geq e$ che β^{e-i} è intero, come d'altra parte i d_i , lo è anche x .

△

Alcune proprietà di $F(\beta, t, L, U)$

Proposizione.

L'insieme dei numeri macchina $F(\beta, t, L, U)$ *non consiste di punti equispaziati.*

Dimostrazione facoltativa.

Per capirlo, il numero positivo più piccolo, e quindi più vicino a 0 è $\beta^{1-L} \ll 1$ mentre i numeri floating-point che hanno esponente $e \geq t$ sono interi e quindi la distanza di due tali numeri successivi è sicuramente maggiore o uguale 1.

In definitiva, due numeri successivi vicino a 0 distano molto poco, e due numeri successivi con esponente molto grande distano molto, e quindi l'insieme dei floating-point non consiste di punti equispaziati. △

Alcune proprietà di $F(\beta, t, L, U)$

Esempio.

In Matlab, in precisione doppia,

- il numero successivo a 0 è circa $2.2251 \cdot 10^{-308}$,
- i due numeri piú grandi distano l'uno dall'altro $\approx 1.9958 \cdot 10^{+292}$.

Di conseguenza l'insieme numerico del Matlab non consiste di punti equispaziati perchè

$$1.9958 \cdot 10^{292} \gg 2.2251 \cdot 10^{-308}.$$

Riassunto delle proprietà di $F(\beta, t, L, U)$

- Il piú piccolo numero macchina positivo (normalizzato) é β^{L-1} .
- Il piú grande numero macchina (normalizzato) é $\beta^U(1 - \beta^{-t})$, dove t é il numero di cifre della mantissa.
- L'insieme dei numeri macchina $F(\beta, t, L, U)$ ha un numero finito di elementi e la sua cardinalità è

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

- I numeri macchina sono numeri **razionali**.
- I numeri macchina che hanno esponente $e \geq t$ sono **interi**.
- L'insieme dei numeri macchina $F(\beta, t, L, U)$ **non consiste di punti equispaziati**.

Alcune proprietà di $F(\beta, t, L, U)$. Osservazione facoltativa.

Osservazione. (facoltativa)

Nel caso della notazione

$$y = \operatorname{sgn}(y) \cdot (1.d_2 \dots d_t)_\beta \beta^e = \operatorname{sgn}(y) \cdot \beta^e \left(1 + \sum_{k=2}^t d_k \beta^{-k}\right) \quad (6)$$

abbiamo i seguenti risultati per $F(\beta, t, L, U)$:

- *la somma degli elementi della mantissa $(1, d_1 \dots d_{t-1})$ è un numero nell'intervallo $[1, 2 - \beta^{-(t-1)}] \subset [1, 2)$;*
- *Il più piccolo numero positivo è β^L (usare quale mantissa $(1.0 \dots 0)$);*
- *Il più grande numero positivo è $(2 - \beta^{-(t-1)}) \cdot \beta^U$;*

Gli altri asserti sono uguali a quelli visti per la notazione classica.

Matlab utilizza questa notazione e quindi per quanto riguarda ad esempio la precisione doppia $F(2, 53, -1022, 1023)$:

- *la somma degli elementi della mantissa $(1, d_1 \dots d_{52})$ è un numero nell'intervallo $[1, 2 - \beta^{-(52)}] \approx [1, 2 - 2.22 \cdot 10^{-16}]$;*
- *Il più piccolo numero positivo è $\beta^L = 2^{-1022} \approx 2.225073858507201e - 308$;*
- *Il più grande numero positivo è $(2 - \beta^{-(t-1)}) \cdot \beta^U = (2 - \beta^{-(52)}) \cdot 2^{1023} = 1.797693134862316e + 308$.*

Alcune proprietà di $F(\beta, t, L, U)$. Osservazione facoltativa.

Di seguito faremo esempi di queste quantità relativamente agli insiemi $F(2, 24, -126, 127)$ e $F(2, 53, -1022, 1023)$.

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) 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.

Precisione singola e doppia

Descriviamo di seguito i più comuni insiemi di numeri floating-point.

1. 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.
2. Classici esempi sono per quanto riguarda i processori che seguono lo standard IEEE754 (inizialmente proposto da INTEL, studiato dal 1977 e introdotto nel 1985), e i successivi aggiornamenti fino all'attuale versione 2008 e alle proposte di IEEE854,
 - 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.

Precisione singola

Nel caso della precisione singola $F(2, 24, -126, 127)$,

- Si usa la base 2.
- Si usa un bit per il **segno**.
- Si usa una **mantissa di 24 cifre binarie**, ma visto che si utilizza la notazione normalizzata, solo 23 sono necessarie.
- Visto che si compone di 32 bits, di cui 24 per mantissa e segno, **8** possono essere dedicate all'**esponente** (quindi si possono rappresentare numeri interi da 0 a 255).
 - (a) Dato che i numeri 0 e 255 vengono utilizzati per significati speciali, sono utilizzati esclusivamente gli interi N_e da 1 a 254.
 - (b) Fissato $\text{bias}=127 = 2^7 - 1$ per ottenere gli esponenti e li si codifica con N_e tale che $e = N_e - \text{bias}$.

Evidentemente

- il piú piccolo esponente $e_{min} = 1 - 127 = -126$,
- il piú grande esponente é $e_{max} = 254 - 127 = 127$.

Precisione singola

Nell'implementazione Matlab,

- Il minimo numero positivo in precisione singola é

$$x_{min} = 1.1754944e - 38;$$

- Il massimo numero positivo in precisione singola é

$$x_{max} = 3.4028235e + 38;$$

- la cardinalità dell'insieme $F(2, 24, -126, 127)$ è

$$\approx 4.2950e + 09.$$

Precisione doppia

Nel caso della precisione singola $F(2, 53, -1022, 1023)$,

- Si usa la base 2.
- Si usa un bit per il **segno**.
- Si usa una **mantissa di 53 cifre binarie**, ma visto che si utilizza la notazione normalizzata, solo 52 sono necessarie.
- Visto che si compone di 64 bits, di cui 53 per mantissa e segno, **11** possono essere dedicate all'**esponente** (quindi si possono rappresentare numeri interi da 0 a 2047).
 - (a) Dato che i numeri 0 e 2047 vengono utilizzati per significati speciali, sono utilizzati esclusivamente gli interi N_e da 1 a 2046.
 - (b) Fissato $\text{bias}=1023 = 2^{10} - 1$ per ottenere gli esponenti e li si codifica con N_e tale che $e = N_e - \text{bias}$.

Evidentemente

- il piú piccolo esponente è $e_{min} = -(1 - 1023) = -1022$
- il piú grande esponente è $e_{max} = 2046 - 1023 = 1023$.

Precisione doppia

Nell'implementazione Matlab,

- Il minimo numero positivo in precisione doppia é

$$x_{min} = 2.225073858507201e - 308;$$

- Il massimo numero positivo in precisione doppia é

$$x_{max} = 1.797693134862316e + 308;$$

- la cardinalità dell'insieme $F(2, 53, -1022, 1023)$ è $\approx 3.7038e + 19$.

Precisione doppia. Nota facoltativa

Osservazione. (facoltativa)

Si può credere che i numeri utilizzati per le precisioni singole e doppie siano sempre stati questi, ma non è così. In altri sistemi, differentemente da IEEE754, 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, [2, p.13].*

Troncamento e arrotondamento

Se x è il numero reale

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

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

$$\operatorname{fl}(x) = \operatorname{sgn}(x)(0.d_1, \dots, d_{t-1}, \overline{d}_t)_\beta \beta^e = \operatorname{sgn}(x)\beta^e \left(\sum_{k=1}^{t-1} d_k \beta^{-k} + \overline{d}_t \beta^{-t} \right)$$

in cui

- se si effettua il **troncamento**

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

- 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.

Troncamento e arrotondamento: base 10

Se in particolare la base è 10 e

$$x = \text{sgn}(x)(0.d_1, \dots, d_t, \dots)_{10}10^e = \text{sgn}(x) \cdot 10^e \sum_{k=1}^{+\infty} d_k \cdot 10^{-k}, \quad d_1 > 0$$

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

$$\text{fl}(x) = \text{sgn}(x)(0.d_1, \dots, d_{t-1}, \overline{d}_t) \cdot 10^e = \text{sgn}(x)10^e \left(\sum_{k=1}^{t-1} d_k \cdot 10^{-k} + \overline{d}_t \cdot 10^{-t} \right)$$

in cui se viene effettuato l'**arrotondamento**.

$$\overline{d}_t = \begin{cases} d_t, & d_{t+1} < 5 \\ d_t + 1, & d_{t+1} \geq 5 \end{cases}$$

Troncamento e arrotondamento: esempio

Esempio.

Si consideri

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

Se lo tronchiamo alla quarta cifra decimale otteniamo che il corrispondente numero *floating point* è

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

mentre se lo arrotondiamo

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

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

Troncamento e arrotondamento: osservazione

Se l'esponente e del numero x è

- minore del minimo esponente L , si commette un'errore di **underflow**,
- maggiore del massimo esponente U , si commette un'errore di **overflow**.

Se invece

- $e \in [L, U]$,
- $x = \pm \beta^e \sum_{k=1}^{+\infty} d_k \beta^{-k}$,
- 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.

Osservazione.

*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.*

La precisione di macchina

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

Definizione

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 $e = 1$ e quindi è $x = 1 + \beta^1 \cdot \beta^{-t} = 1 + \beta^{1-t}$, per cui

$$\text{eps} = \beta^{1-t}.$$

La precisione di macchina

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 (supposto si usi la precisione doppia), x_{min} è molto inferiore di eps, in quanto

- il più piccolo numero positivo in modulo è

$$x_{min} = 2^{-1022} = 2.225073858507201 \cdot 10^{-308},$$

- la precisione di macchina è

$$\text{eps} = 2^{-52} = 2.220446049250313 \cdot 10^{-16}.$$

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

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

Osservazione.

Si noti che se $|x^| = 0$, cioè $x^* = 0$, allora non ha senso la scrittura propria dell'errore relativo.*

Errori relativi e assoluti

Esempio.

Si consideri $\pi = 3.141592653589793 \dots$

In precisione singola

$$\text{fl}(\pi) = 3.1415927$$

e abbiamo che

- l'errore assoluto è $|\pi - \text{fl}(\pi)| \approx 8.7422777 \cdot 10^{-8}$
- l'errore relativo è $\frac{|\pi - \text{fl}(\pi)|}{\pi} \approx 2.7827534 \cdot 10^{-8}$.

Si osservi che la precisione di macchina per precisione singola di Matlab è $\text{eps}_S \approx 1.1920929 \cdot 10^{-7}$ e si ha

$$2.7827534 \cdot 10^{-8} \approx \frac{|\pi - \text{fl}(\pi)|}{\pi} \leq \text{eps}_S/2 \approx 5.9604645 \cdot 10^{-8}.$$

Errori relativi e assoluti

Fissato un vettore $x^* = (x_1^*, \dots, x_n^*) \in \mathbb{R}^n$, approssimato da x si definisce

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

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

dove

- $\|\cdot\|$ è una norma (cf. [27]), ad esempio se $y = (y_1, \dots, y_n)$ allora $\|y\| = \sqrt{\sum_{i=1}^n y_i^2}$,
- se $x = (x_1, \dots, x_n)$ allora $x - x^* = (x_1 - x_1^*, \dots, x_n - x_n^*)$.

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

$$\|x - x^*\| / \|x^*\|.$$

Osservazione.

Si noti che se $\|x^\| = 0$, cioè $x^* = 0$ per la proprietà delle norme [2, 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 $|\cdot|$.*

Errori relativi e assoluti

Sia

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

un numero reale e

$$fl(x) = \operatorname{sgn}(x)(0.d_1, \dots, d_{t-1}, \bar{d}_t)\beta^e = \operatorname{sgn}(x)\beta^e \left(\sum_{k=1}^{t-1} d_k \beta^{-k} + \bar{d}_t \beta^{-t} \right), \quad d_1 > 0$$

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

$$\begin{aligned} \frac{|x - fl(x)|}{|x|} &\leq \frac{|\operatorname{sgn}(x)\beta^e \sum_{k=1}^{+\infty} d_k \beta^{-k} - (\operatorname{sgn}(x)\beta^e (\sum_{k=1}^{t-1} d_k \beta^{-k} + \bar{d}_t \beta^{-t}))|}{|\beta^{e-1}|} \\ &= \beta \cdot \left| \sum_{k=t}^{+\infty} d_k \beta^{-k} - \bar{d}_t \beta^{-t} \right| \end{aligned} \quad (7)$$

Errori relativi e assoluti

Da $\frac{|x - fl(x)|}{|x|} \leq \beta \cdot \left| \sum_{k=t}^{+\infty} d_k \beta^{-k} - \bar{d}_t \beta^{-t} \right|$, nel caso si effettui

- il troncamento abbiamo $d_t = \bar{d}_t$ e quindi, essendo $\text{eps} = \beta^{1-t}$,

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

- l'arrotondamento abbiamo dopo alcuni calcoli che

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

La quantità $\frac{\text{eps}}{2}$ è detta **unità di arrotondamento**.

Osservazione.

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

Operazioni con i numeri macchina

Indicato con $\text{fl}(x)$ il numero macchina che **corrisponde** a “ x ”, denotiamo con

$$x \oplus y := \text{fl}(\text{fl}(x) + \text{fl}(y)) \quad (8)$$

$$x \ominus y := \text{fl}(\text{fl}(x) - \text{fl}(y)) \quad (9)$$

$$x \otimes y := \text{fl}(\text{fl}(x) \cdot \text{fl}(y)) \quad (10)$$

$$x \oslash y := \text{fl}(\text{fl}(x) : \text{fl}(y)) \quad (11)$$

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

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

Operazioni con i numeri macchina

Osservazione.

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

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

Proprietá 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**,
- non valgono quella **associativa** e **distributiva**.

Quindi l'**ordine** in cui sono eseguite le operazioni può variare il risultato.

Inoltre esistono l'**elemento neutro** della moltiplicazione, divisione, addizione e sottrazione, come pure l'**opposto** di ogni numero floating-point.

Proprietá commutativa, associativa e distributiva delle operazioni floating point: esempio

Mostriamo come non valga la proprietá **associativa** della somma.

Esempio.

Consideriamo $F(10, 4, -10, +10)$ con **fl** basato sul troncamento. Sia $a = 2000$, $b = 2.5$, $c = 7.8$. Allora non è vero che

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

in quanto

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

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

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

Proprietá commutativa, associativa e distributiva delle operazioni floating point: esempio

Mostriamo come non valga la proprietá **distributiva**.

Esempio.

In $F(10, 6, -10, +10)$, posti

- $a = 0.800000 \cdot 10^9$,
- $b = 0.500009 \cdot 10^4$,
- $c = 0.500008 \cdot 10^4$,

Allora non è vero che $a \otimes (b \ominus c) = (a \otimes b) \ominus (a \otimes c)$ in quanto

$$\begin{aligned} a \otimes (b \ominus c) &= 0.800000 \cdot 10^9 \otimes 0.1 \cdot 10^{-2} = 0.800000 \cdot 10^9 \\ (a \otimes b) \ominus (a \otimes c) &= (0.800000 \cdot 10^9 \otimes 0.500009 \cdot 10^4) \ominus \\ &\quad \ominus (0.800000 \cdot 10^9 \otimes 0.500008 \cdot 10^4) \\ &\rightarrow \text{overflow} \end{aligned}$$

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

Errori nelle operazioni e loro propagazione

Teorema (cf. [5, p.78])

Valgono le seguenti stime

$$\epsilon_{x,y}^{\oplus} \leq \left| \frac{x}{x+y} \right| \epsilon_x + \left| \frac{y}{x+y} \right| \epsilon_y, \quad x+y \neq 0 \quad (12)$$

$$\epsilon_{x,y}^{\ominus} \leq \left| \frac{x}{x-y} \right| \epsilon_x + \left| \frac{y}{x-y} \right| \epsilon_y, \quad x-y \neq 0 \quad (13)$$

$$\epsilon_{x,y}^{\otimes} \lesssim \epsilon_x + \epsilon_y \quad (14)$$

$$\epsilon_{x,y}^{\oslash} \leq |\epsilon_x - \epsilon_y| \quad (15)$$

dove per ogni operazione floating point \odot relativamente alla generica operazione op (ovvero $+$, $-$, $*$, $/$)

$$\epsilon_x = |x - fl(x)|/|x|,$$

$$\epsilon_y = |y - fl(y)|/|y|,$$

$$\epsilon_{x,y}^{\odot} = |(x \odot y) - (x \text{ op } y)|/|x \text{ op } y|$$

Errori nelle operazioni e loro propagazione

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

Proposizione.

Se,

- $x + y \neq 0, x \neq 0, y \neq 0,$
- $fl(fl(x) + fl(y)) = fl(x) + fl(y),$
- $\epsilon_x = |x - fl(x)|/|x|,$
- $\epsilon_y = |y - fl(y)|/|y|,$
- $\epsilon_{x,y}^{\oplus} = |(x \oplus y) - (x + y)|/|x + y|$

allora

$$\epsilon_{x,y}^{\oplus} \leq \left| \frac{x}{x+y} \right| \epsilon_x + \left| \frac{y}{x+y} \right| \epsilon_y.$$

Errori nelle operazioni e loro propagazione

Dimostrazione.

Nelle ipotesi precedenti, visto che

$$\blacksquare \epsilon_x = |x - fl(x)|/|x|,$$

$$\blacksquare \epsilon_y = |y - fl(y)|/|y|,$$

abbiamo, visto che $fl(fl(x) + fl(y)) = fl(x) + fl(y)$,

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

△

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 $\epsilon_{x,y}^{\oplus}$ (tale fenomeno è noto come **cancellazione**).

Errori nelle operazioni e loro propagazione

Nota. (Facoltativa e tecnica)

Nel precedente asserto, abbiamo supposto che

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

A essere pignoli, richiesto che si effettui l'arrotondamento per determinare l'approssimante floating-point, si ha che per qualche $\delta \in [0, \text{eps}/2)$, dove $\text{eps}/2$ è l'unità di arrotondamento,

$$fl(fl(x) + fl(y)) = (fl(x) + fl(y))(1 + \delta)$$

ma il risultato che otteniamo, a parte di aumentare la difficoltà nei calcoli, è essenzialmente lo stesso.

Errori nelle operazioni e loro propagazione

Proposizione.

Se,

- $x - y \neq 0, x \neq 0, y \neq 0,$
- $fl(fl(x) - fl(y)) = fl(x) - fl(y)$
- $\epsilon_x = |x - fl(x)|/|x|,$
- $\epsilon_y = |y - fl(y)|/|y|,$
- $\epsilon_{x,y}^{\ominus} = |(x \ominus y) - (x + y)|/|x + y|$

allora

$$\epsilon_{x,y}^{\ominus} \leq \left| \frac{x}{x-y} \right| \epsilon_x + \left| \frac{y}{x-y} \right| \epsilon_y.$$

Errori nelle operazioni e loro propagazione

Facoltativa.

Nelle ipotesi precedenti, visto che

$$\blacksquare \epsilon_x = |x - fl(x)|/|x|,$$

$$\blacksquare \epsilon_y = |y - fl(y)|/|y|,$$

abbiamo, visto che $fl(fl(x) - fl(y)) = fl(x) - fl(y)$,

$$\begin{aligned}\epsilon_{x,y}^{\ominus} &= \frac{|(x - y) - (x \ominus y)|}{|x - y|} = \frac{|(x - y) - fl(fl(x) - fl(y))|}{|x - y|} \\ &= \frac{|(x - fl(x)) - (y - fl(y))|}{|x - y|} \leq \frac{|x|}{|x - y|} \cdot \frac{|x - fl(x)|}{|x|} + \frac{|y|}{|x - y|} \cdot \frac{|y - fl(y)|}{|y|} \\ &= \left| \frac{x}{x - y} \right| \epsilon_x + \left| \frac{y}{x - y} \right| \epsilon_y\end{aligned}\tag{16}$$

△

Errori nelle operazioni e loro propagazione

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 nuovamente di **fenomeno di cancellazione**.

Esempio. (Cancellazione)

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!).

Errori nelle operazioni e loro propagazione: prodotto

Proposizione.

Se,

- $x \cdot y \neq 0, x \neq 0, y \neq 0, |fl(y)|/|y| \approx 1,$
- $fl(fl(x) \cdot fl(y)) = fl(x) \cdot fl(y),$

posto

- $\epsilon_x = \frac{|x - fl(x)|}{|x|},$
- $\epsilon_y = \frac{|y - fl(y)|}{|y|},$
- $\epsilon_{x,y}^{\otimes} = |x \otimes y - x \cdot y|/|x \cdot y|$

allora

$$\epsilon_{x,y}^{\otimes} \lesssim \epsilon_x + \epsilon_y.$$

dove \lesssim significa *inferiore o circa uguale*.

Errori nelle operazioni e loro propagazione: prodotto

Dimostrazione.

Nelle ipotesi precedenti abbiamo

$$\begin{aligned}\epsilon_{x,y}^{\otimes} &= \frac{|x \cdot y - x \otimes y|}{|x \cdot y|} = \frac{|x \cdot y - \text{fl}(\text{fl}(x) \cdot \text{fl}(y))|}{|x \cdot y|} = \frac{|x \cdot y - \text{fl}(x) \cdot \text{fl}(y)|}{|x \cdot y|} \\ &= \frac{|x \cdot y - x \cdot \text{fl}(y) + x \cdot \text{fl}(y) - \text{fl}(x) \cdot \text{fl}(y)|}{|x \cdot y|} \\ &\leq \frac{|x \cdot (y - \text{fl}(y))| + |\text{fl}(y) \cdot (x - \text{fl}(x))|}{|x \cdot y|} \\ &= \frac{|x|}{|x|} \frac{|y - \text{fl}(y)|}{|y|} + \underbrace{\frac{|\text{fl}(y)|}{|y|}}_{\approx 1} \cdot \frac{|x - \text{fl}(x)|}{|x|} \approx \epsilon_x + \epsilon_y.\end{aligned}$$



Errori nelle operazioni e loro propagazione: divisione

Facoltativo.

Per quanto riguarda la divisione x/y , forniamo una traccia. Basta

- *studiare il caso $1/y$,*
- *ricordare i risultati del prodotto $x \cdot \frac{1}{y}$.*

Errori nelle operazioni e loro propagazione: divisione

Osservazione. (Difficile, necessario aver seguito il corso di Analisi II)

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

$$f(x, y) \approx f(\bar{x}, \bar{y}) + f'_x(\bar{x}, \bar{y})(x - \bar{x}) + f'_y(\bar{x}, \bar{y})(y - \bar{y}) \quad (17)$$

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

$$\begin{aligned} \frac{|f(x, y) - f(\bar{x}, \bar{y})|}{|f(x, y)|} &\approx \frac{|f'_x(\bar{x}, \bar{y})||x - \bar{x}||x|}{|f(x, y)||x|} + \frac{|f'_y(\bar{x}, \bar{y})||y - \bar{y}||y|}{|f(x, y)||y|} \\ &= \frac{|f'_x(\bar{x}, \bar{y})||x|}{|f(x, y)|} \cdot \epsilon_x + \frac{|f'_y(\bar{x}, \bar{y})||y|}{|f(x, y)|} \cdot \epsilon_y \end{aligned} \quad (18)$$

Da (18), 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 $\exp(x + y)$.

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).

Errori di questo tipo hanno causato nel 1996 la perdita del razzo Ariane 5 per una cattiva conversione di un numero, il crollo di una piattaforma petrolifera nel mare del Nord (Norvegia) nel 1991 e la distruzione del veicolo spaziale Mars Climate orbiter nel 1999 (cf. [1], [11]).

Alcune problematiche numeriche

- **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 [3, p.46].

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

- misura e/o
- di rappresentazione al calcolatore,

così da essere approssimato con un certo x_C .

Di conseguenza, **invece di $f(x)$ si valuta $f(x_C)$** e ci si domanda se ci siano considerevoli differenze nei risultati.

Valutazione di una funzione

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

$$\frac{|x - x_c|}{|x|}$$

corrispondano grandi errori (relativi) sui risultati

$$\frac{|f(x) - f(x_c)|}{|f(x)|}$$

Quindi è importante discutere la quantità

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

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.

Valutazione di una funzione

Se f è derivabile con continuità nel più piccolo intervallo \mathcal{I} aperto contenente x ed x_c , per il teorema della media (o di [Lagrange](#)) abbiamo

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

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

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

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 $x_2 \in \Omega$.

Osservazione.

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 .

Valutazione di una funzione: esempio 1

Esempio.

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 $x \in (-1, 1)$

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

Valutazione di una funzione: esempio 1

Dal grafico di tale funzione nella Figura, 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: 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 $|x| \approx 1$).

Valutazione di una funzione: esempio 2

Esempio.

Consideriamo quale esempio

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

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

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

Dal grafico di tale funzione nella Figura, 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.

Valutazione di una funzione: esempio 2




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

Stabilità

Nell'analisi del condizionamento $\mathcal{K}(f, x)$ di una funzione continua f in un punto x del suo dominio, abbiamo supposto che f sia valutabile esattamente e quindi che $\mathcal{K}(f, x)$ non dipenda dall'algoritmo utilizzato.

Definizione (Algoritmo stabile)

*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.

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.

Esempio.

Dato il polinomio di secondo grado $x^2 + 2px - q$, con $\sqrt{p^2 + q} \geq 0$ calcolare la radice

$$y = -p + \sqrt{p^2 + q}. \quad (19)$$

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

$$y = -p \pm \sqrt{p^2 + q}. \quad (20)$$

dell'equazione sono reali. La soluzione descritta in (19) è la maggiore delle 2, ed è non negativa se e solo se $q \geq 0$.

Esempio 1: Calcolo di una radice in una equazione di secondo grado

- 1 Si osserva subito che (19) 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 .
- 2 Ripetiamo poi lo stesso tipo di indagine con una formula alternativa (e stabile) che si ottiene razionalizzando la formula (19). In altri termini

$$\begin{aligned} y &= -p + \sqrt{p^2 + q} = \frac{(-p + \sqrt{p^2 + q})(p + \sqrt{p^2 + q})}{(p + \sqrt{p^2 + q})} \\ &= \frac{q}{(p + \sqrt{p^2 + q})}. \end{aligned} \quad (21)$$

Esempio 1: Calcolo di una radice in una equazione di secondo grado e condizionamento

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 rispettivamente di

- **algoritmo bencondizionato** o stabile,
- **algoritmo malcondizionato** o instabile [5, p. 66].

Importante.

Seguendo [5, p. 10], [5, p. 78], indipendentemente dall'algoritmo utilizzato, il problema della determinazione della radice

$y = -p + \sqrt{p^2 + q}$ è

- **bencondizionato** per $q > 0$,
- **malcondizionato** per $q \approx -p^2$.

Esempio 1: Calcolo di una radice in una equazione di secondo grado e condizionamento

Usando dei classici ragionamenti dell'analisi numerica si mostra che (cf. [17], p. 21, [6], p. 11)

- 1 il primo algoritmo (20) non è **numericamente stabile** qualora $p \gg q > 0$;
- 2 il secondo algoritmo (21) è **numericamente stabile** qualora $p \gg q > 0$.

nonostante in queste ipotesi il problema sia stabile.

Esempio 1: Calcolo di una radice in una equazione di secondo grado, test 1

Vediamo alcuni casi rilevanti, effettuati in doppia precisione.

1. In [17, 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	0.00000899999999772772	$2.52 \cdot 10^{-9}$
2	0.00000900000000000000	0

Esempio 1: Calcolo di una radice in una equazione di secondo grado, test 2

2. Secondo [6, p.11], è notevole l'esperimento in cui

$$p = 4.999999999995 \cdot 10^{+4}, q = 10^{-2}$$

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

Lavorando in doppia precisione otteniamo

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

Esempio 2: Approssimazione di π

Esempio.

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 $\pi = 3,141592653589793238\dots$

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).

Esempio 2: Approssimazione di π

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

n	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

Esempio 2: Approssimazione di π




Figura: 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.

Esempio 2: Approssimazione di π

Dalla figura e dalla tabella, consegue che

- la convergenza della **prima successione** è estremamente lenta, mentre quella della terza è più rapida;
- la **seconda successione** non converge numericamente, seppure converga teoricamente; il principale problema è la cancellazione che si ha nell'argomento della radice quadrata più esterna di

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

Esempio 2: Approssimazione di π

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

n	$\sqrt{1 - 4^{1-n} \cdot z_n^2}$	$\sqrt{1 - \sqrt{1 - 4^{1-n} \cdot z_n^2}}$
5	9.8078528040323054160154470e - 01	1.38617e - 01
10	9.9998117528260110908888691e - 01	4.33875e - 03
15	9.999998161642922323011362e - 01	1.35586e - 04
20	9.999999998204724960260137e - 01	4.23707e - 06
25	9.99999999998245847621092e - 01	1.32444e - 07
30	1.000000000000000000000000e + 00	0.00000e + 00
35	1.000000000000000000000000e + 00	0.00000e + 00
40	1.000000000000000000000000e + 00	0.00000e + 00

L'ultima colonna evidenzia che per $n \geq 30$ si ha che $z_n = 0$, in quanto

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

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 [15, Esercizio 1.9, p.35].

Problemi simili con una precisa discussione della propagazione dell'errore sono trattati pure in [7, p. 23, problema 11]

Esempio.

Si valuti numericamente la successione

$$I_n = e^{-1} \int_0^1 x^n e^x dx \quad (22)$$

Proposizione.

La successione I_n è positiva, decrescente e infinitesima (cioè $\lim_n I_n = 0$). Inoltre

$$I_{n+1} = 1 - (n+1) I_n, \quad I_0 = 1 - e^{-1}.$$

Esempio 3: Successione ricorrente

Osserviamo che da

$$l_{n+1} = 1 - (n + 1) l_n$$

abbiamo

$$(n + 1) l_n = 1 - l_{n+1}$$

e di conseguenza

$$l_n = \frac{1 - l_{n+1}}{n + 1}$$

per cui visto che per n^* molto grande $l_{n^*} \approx 0$, visto che la successione è infinitesima, si può considerare la successione **all'indietro**

$$l_n = \frac{1 - l_{n+1}}{(n + 1)}, \quad n = n^* - 1, \dots, 1.$$

Esempio 3: Successione ricorrente

Riassumendo, se desideriamo calcolare I_1, \dots, I_{100} :

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 $m = 500$, calcoliamo la successione **all'indietro** $\{t_n\}_{n=1, \dots, 500}$ definita come

$$\begin{cases} t_{500} = 0 \\ t_{n-1} = \frac{1-t_n}{n} \end{cases}$$

Si osservi che per raggiungere tale obiettivo bisogna calcolare i termini

$$t_{500}, t_{499}, \dots, t_{100}, t_{99}, \dots, t_2, t_1.$$

Esempio 3: Successione ricorrente

Dopo aver eseguito i calcoli otteniamo per $n = 10, 20, \dots, 100$ la seguente tabella in cui si evince che in effetti s_n a differenza di l_n non è infinitesima, positiva e decrescente, mentre lo è t_n .

n	s_n	t_n
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	$-1.159928542966359e + 141$	$9.804855005376052e - 03$

Esempio 3: Successione ricorrente

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.

Esempio 3: Successione ricorrente

Osservazione. (Facoltativa)

In effetti anche se operassimo in aritmetica esatta, per quanto concerne la successione in avanti l_n , se $l_0^ = l_0 + \epsilon$ allora la successione calcolata*

$$l_{n+1}^* = 1 - (n + 1)l_n^*$$

è tale che $l_n^ - l_n = n!\epsilon$, giustificando i risultati ottenuti.*

Osserviamo infatti che ragionando per induzione,

- *l'asserto $l_n^* - l_n = n!\epsilon$ vale per $n = 0$, in quanto $l_0^* = l_0 + 0!\epsilon = l_0 + \epsilon$;*
- *se supponiamo $l_n^* - l_n = n!\epsilon$, ovvero $l_n^* = l_n - n!\epsilon$ allora*

$$\begin{aligned} l_{n+1}^* &= 1 - (n + 1)l_n^* = 1 - (n + 1)(l_n - n!\epsilon) \\ &= 1 - (n + 1)l_n + (n + 1) \cdot (n!\epsilon) \\ &= l_n^* + (n + 1)!\epsilon. \end{aligned} \tag{23}$$

Esempio 4: sulla somma $\frac{(1+\eta)-1}{\eta}$

Esempio.

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 .

Si tratta di una **funzione ben condizionata** visto che $f(x) = 1$, che però può essere valutata in forme diverse, più o meno favorevoli (come nel nostro caso).

Risulta quindi importante capire che nell'esempio in questione, il fatto che avremo **risultati inaspettati**, differentemente da quanto visto per funzioni f malcondizionate, **sarà dovuto all'algoritmo di calcolo**.

Esempio 4: sulla somma $\frac{(1+\eta)-1}{\eta}$

- 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.

- Per $\eta \approx 0$, avremo problemi a calcolare correttamente il numeratore $(1 + \eta) - 1$, causa il fenomeno di cancellazione.

Esempio 4: sulla somma $\frac{(1+\eta)-1}{\eta}$

η	$f^*(\eta)$	rel.err.
1.00e - 01	1.0000000000000001e + 00	8.881784e - 16
1.00e - 02	1.0000000000000001e + 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	1.00000082740371e + 00	8.274037e - 08
1.00e - 10	1.00000082740371e + 00	8.274037e - 08
1.00e - 11	1.00000082740371e + 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

Esempio 4: sulla somma $\frac{(1+\eta)-1}{\eta}$

Nota. (Facoltativa)

La perdita di precisione è dovuta essenzialmente al fenomeno di cancellazione, visto che per $\eta \approx 0$ si ha $1 + \eta \approx 1$.

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	1.0000000000000000e + 00	0.000000e + 00
eps/2	0.0000000000000000e + 00	1.000000e + 00
eps/3	0.0000000000000000e + 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!),

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

Esempio 5: Sulla valutazione di $\tan(\arctan(x)) = x$

Esempio.

Siano $f := \tan$ e $g := \arctan$. Si consideri la funzione composta

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

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

Valutiamo la funzione $F = f \circ g$ numericamente, mediante la corrispettiva versione numerica F^* per

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

nonchè l'errore relativo `rel.err.` compiuto, ovvero

$$\text{rel.err.} := |F(x) - F^*(x)| / |F(x)|,$$

notando che $F(x) \neq 0$ visto che nei casi in questione si ha $x \neq 0$.

Esempio 5: Sulla valutazione di $\tan(\arctan(x)) = x$

Descriviamo questi risultati nella tabella che segue.

x	$F^*(x)$	rel.err.
$1.0e - 20$	$1.0000000000000000e - 20$	$0.00000e + 00$
$1.0e - 16$	$1.0000000000000000e - 16$	$0.00000e + 00$
$1.0e - 12$	$1.0000000000000000e - 12$	$0.00000e + 00$
$1.0e - 08$	$1.0000000000000004e - 08$	$0.00000e + 00$
$1.0e - 04$	$1.0000000000000000e - 04$	$0.00000e + 00$
$1.0e + 00$	$9.999999999999999e - 01$	$1.11022e - 16$
$1.0e + 04$	$9.999999999990539e + 03$	$9.46056e - 13$
$1.0e + 08$	$9.999999999542369e + 07$	$4.57631e - 11$
$1.0e + 12$	$1.000071916854289e + 12$	$7.19117e - 05$
$1.0e + 16$	$1.633123935319537e + 16$	$3.87677e - 01$
$1.0e + 20$	$1.633123935319537e + 16$	$6.12223e + 03$

Esempio 5: Sulla valutazione di $\tan(\arctan(x)) = x$

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

x	$F^*(x)$	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 F e F^* non coincidono, anche per valori non eccessivi di x .

Complessità computazionale

Descriviamo in questa sezione alcuni problemi in cui mostriamo come pur fornendo in aritmetica esatta lo stesso risultato, abbiano **complessità computazionale** diversa, ovvero compiono un numero diverso di operazioni.

Tipicamente, visto che nei primi computer il costo tra operazioni moltiplicative e somme era molto diverso, si considerano solo prodotti (e quindi potenze) e divisioni.

Valutazione di polinomi: algoritmo 1

Si supponga di dover valutare il polinomio di grado $n = 4$

$$p_4(x) = a_0 + a_1x + a_2x^2 + a_3x^3 + a_4x^4.$$

1. Se si implementa un metodo brutale, necessitano
 - 4 somme;
 - 3 potenze, e visto che $x^2 = x \cdot x$, $x^3 = x \cdot x \cdot x$, $x^4 = x \cdot x \cdot x \cdot x$, necessitano $1 + 2 + 3$ prodotti;
 - 4 prodotti del tipo $a_k \cdot x^k$.

Valutazione di polinomi

Con questa tecnica in generale servono per valutare un polinomio di grado n

$$p_n(x) = a_0 + a_1x + \dots + a_nx^n.$$

nel generico punto x

- n somme;
- $n - 1$ potenze, e visto che $x^k = x \cdot \dots \cdot x$, necessitano $1 + \dots + (n - 1) = (n - 1)n/2$ prodotti.
- n prodotti del tipo $a_k \cdot x^k$.

e quindi $\frac{(n-1)n}{2} + n = \frac{(n+1)n}{2} \approx \frac{n^2}{2}$ operazioni moltiplicative.

Valutazione di polinomi: algoritmo 2

Facendo un pó di attenzione è facile osservare che in realtà, per valutare p_4 servono

- 4 somme;
- 3 potenze, e visto che $x^2 = x \cdot x$, $x^3 = x^2 \cdot x$, $x^4 = x^3 \cdot x$, necessitano solo 3 prodotti;
- 4 prodotti del tipo $a_k \cdot x^k$.

Quindi, il numero di operazioni moltiplicative con un algoritmo più furbo è pari a 7.

In generale, si vede che con questa tecnica servono **$2n - 1$ operazioni moltiplicative** per valutare un polinomio p di grado esattamente n , nel generico punto x .

Valutazione di polinomi

Osserviamo che nel caso dell'esempio del polinomio di grado 4,

$$\begin{aligned} p_4(x) &= a_0 + a_1x + a_2x^2 + a_3x^3 + a_4x^4 \\ &= a_0 + x(a_1 + a_2x + a_3x^2 + a_4x^3) \\ &= a_0 + x(a_1 + x(a_2 + a_3x + a_4x^2)) \\ &= a_0 + x(a_1 + x(a_2 + x(\underbrace{a_3 + a_4x}_{b_3}))) \\ &\quad \underbrace{\hspace{10em}}_{b_2} \\ &\quad \underbrace{\hspace{15em}}_{b_1} \\ &\quad \underbrace{\hspace{20em}}_{b_0} \end{aligned}$$

e quindi posti

- $b_3 := a_3 + a_4x,$
- $b_2 := a_2 + b_3x,$
- $b_1 := a_1 + b_2x,$
- $b_0 := a_0 + b_1x,$

otteniamo $p_4(x) = b_0$.

Valutazione di polinomi

Quindi per valutare il polinomio nel generico punto x servono **4 somme e solo 4 prodotti**, operazioni necessarie per calcolare nell'ordine b_3, \dots, b_0 , contro

- le 4 somme e i 10 prodotti del primo algoritmo precedente,
- le 4 somme e i 7 prodotti del secondo algoritmo precedente.

Non è difficile vedere che in generale, con questa regola, usualmente detta di **Ruffini-Horner** [29], occorrono **n operazioni moltiplicative** per valutare il polinomio p di grado n nel generico punto x , quindi in numero inferiore rispetto

- ai $\frac{(n+1)n}{2}$ prodotti del primo algoritmo precedente,
- ai $2n - 1$ prodotti del secondo algoritmo precedente.

Valutazione di polinomi

Esempio.

Valutare il polinomio $p_3(x) = 2x^3 + 4x^2 + 5x + 7$ nel punto $x = 2$, mediante l'algoritmo di Ruffini-Horner.

La **valutazione diretta** comporta che per $x = 2$

$$x^2 = 4, \quad x^3 = x^2 \cdot x = 4 \cdot 2 = 8.$$

Quindi

$$p_3(2) = 2 \cdot 2^3 + 4 \cdot 2^2 + 5 \cdot 2 + 7 = 16 + 16 + 10 + 7 = 49.$$

Se contiamo i prodotti eseguiti, sono 2 per le potenze e 3 per la valutazione del polinomio, ovvero 5 moltiplicazioni.

Valutazione di polinomi

Valutiamo ora il polinomio $p_3(x) = 2x^3 + 4x^2 + 5x + 7$ nel punto $x = 2$, mediante l'algoritmo di **Ruffini-Horner**.

Essendo $a_0 = 7$, $a_1 = 5$, $a_2 = 4$, $a_3 = 2$, valutiamo in sequenza:

- $b_2 := a_2 + a_3x = 4 + 2 \cdot 2 = 8$,
- $b_1 := a_1 + b_2x = 5 + 8 \cdot 2 = 21$,
- $b_0 := a_0 + b_1x = 7 + 21 \cdot 2 = 49$,

raggiungendo il risultato con 3 moltiplicazioni (invece delle 5 del metodo diretto).

Calcolo delle potenze

Esempio.

Si calcoli a^n dove $a \in \mathbb{R}$ e $n \in \mathbb{N}$.

1. Un metodo brutale, osservato che

$$a^n = a \cdot \dots \cdot a$$

richiede $n - 1$ operazioni moltiplicative.

2. Sia $n = \sum_{j=0}^m c_j 2^j$ con $m = \lfloor \log_2 n \rfloor$, la codifica binaria di n , allora

$$a^n = a^{\sum_{j=0}^m c_j 2^j} = \prod_{j=0}^m a^{c_j 2^j} = a^{c_0} \cdot (a^2)^{c_1} \cdot (a^2)^{c_2} \dots (a^{2^m})^{c_m}$$

Notiamo che $a^2 = a \cdot a$, $a^4 = a^2 \cdot a^2$, e in generale

$$a^{2^k} = a^{2^{k-1}} \cdot a^{2^{k-1}}$$

e quindi per calcolare **tutte** le potenze a^2, a^4, \dots, a^{2^m} necessitano $m = \lfloor \log_2 n \rfloor$ prodotti.

Calcolo delle potenza

Osserviamo inoltre che

- se $c_j = 0$ allora $a^{c_j 2^j} = 1$,
- se $c_j = 1$ allora $a^{2^j c_j} = a^{2^j}$.

I prodotti di termini della forma $(a^{2^k})^{c_k}$ in (24) sono infine m .

Un codice che implementa la conversione da decimale in binario è

```
function c=dec2bin(n)
j=1; t=n;
while t > 0
    q=t/2; t=floor(q);
    if t == q
        c(j)=0;
    else
        c(j)=1;
    end
    j=j+1;
end
```

che richiede $m + 1$ divisioni per determinare i coefficienti c_k , $m + 1$ somme e $m + 1$ parti intere che sono indicate con `floor` e hanno un costo molto inferiore alla divisione e alla somma.

Calcolo delle potenza

Ne ricaviamo che per calcolare la potenza richiesta servono $3m + 1 = 3\lfloor \log_2(n) \rfloor + 1$ operazioni moltiplicative, visto che

- la valutazione dei coefficienti c_0, \dots, c_m richiede $m + 1$ divisioni;
- la valutazione delle potenze a^{2^k} , $k = 0, \dots, m$ consta di m operazioni moltiplicative (notare che per $k = 0$ non serve fare calcoli);
- calcolate le potenze, la valutazione finale di (24), necessita al più m operazioni moltiplicative (alcuni coefficienti c_j potrebbero essere nulli e quindi $a^{c_j 2^j} = 1$).

Calcolo delle potenza

In tabella descriviamo n che è circa la complessità del primo algoritmo e $3m + 1 = 3\lfloor \log_2(n) \rfloor + 1$, che mostra come per esponenti relativamente grandi il secondo algoritmo sia di gran lunga da preferire visto che $3\lfloor \log_2(n) \rfloor + 1 \ll n - 1$. Con un po' più di attenzione, si vede che ciò accade per $n > 11$.

n	$3\lfloor \log_2(n) \rfloor + 1$
1.0e + 01	10.96578428466209
1.0e + 02	20.93156856932417
1.0e + 03	30.89735285398626
1.0e + 04	40.86313713864835
1.0e + 05	50.82892142331043
1.0e + 06	60.79470570797253
1.0e + 07	70.76048999263460
1.0e + 08	80.72627427729670
1.0e + 09	90.69205856195879
1.0e + 10	100.6578428466209

Calcolo delle potenze

Osservazione. (Facoltativa)

Notiamo che se B, C sono due matrici quadrate di ordine s , il prodotto $B \cdot C$ richiede s^2 moltiplicazioni e $(s - 1)s \approx s^2$ somme. Quindi per determinare

$$A^n = \underbrace{A \cdot \dots \cdot A}_n$$

servono $n - 1$ prodotti di matrici di dimensione " s " ovvero $(n - 1)s^2$ moltiplicazioni. Se usiamo il secondo algoritmo

- la valutazione dei coefficienti c_0, \dots, c_m richiede $m + 1$ divisioni;
- la valutazione delle potenze a^{2^k} , $k = 0, \dots, m$ necessita la determinazione di " m " potenze di matrici (si noti che non si devono fare calcoli per ricavare $A^0 = I$, $A^1 = A$) e quindi ms^2 moltiplicazioni (e circa le stesse somme);
- calcolate le potenze, la valutazione finale di (24), necessita al più m prodotti di matrici (alcuni coefficienti c_j potrebbero essere nulli e quindi $a^{c_j 2^j} = 1$), e bisogna eseguire circa ms^2 operazioni moltiplicative come pure additive.

Di conseguenza l'applicazione del secondo algoritmo richiede al più

$$(m + 1) + 2ms^2 \approx 2ms^2 = 2\lfloor \log_2(n) \rfloor s^2$$

operazioni moltiplicative come pure additive. Quindi il secondo metodo è da preferirsi qualora $2\lfloor \log_2(n) \rfloor s^2 < (n - 1)s^2$ ovvero quando $2\lfloor \log_2(n) \rfloor < n - 1$, che si verifica per $n > 4$ mentre per $n = 4$ la complessità è la stessa.

Calcolo delle potenza

Esempio.

Valutare 3^9 .

Utilizzando il metodo diretto, mediante 8 prodotti abbiamo

$$3 \cdot 3 = 19683.$$

Dalla rappresentazione in binario di 9

$$9 = 1 \cdot 2^0 + 0 \cdot 2^1 + 0 \cdot 2^2 + 1 \cdot 2^3$$

abbiamo

$$3^9 = 3 \cdot (3^2)^0 \cdot (3^4)^0 \cdot (3^8)^1$$

Essendo

$$3^2 = 9, \quad 3^4 = 3^2 \cdot 3^2 = 9 \cdot 9 = 81, \quad 3^8 = 3^4 \cdot 3^4 = 81 \cdot 81 = 6561$$

abbiamo

$$3^9 = 3 \cdot 1 \cdot 1 \cdot (3^8)^1 = 3 \cdot (3^8) = 3 \cdot 6561 = 19683.$$

Così abbiamo eseguito solo 4 prodotti per ottenere 3^9 .

Valutazione dell'esponenziale

Esempio.

Si valuti $f(x) = e^x$, per $x > 1$.

Metodo 1. Posto

$$S_n^{(1)}(x) = \sum_{i=0}^n \frac{x^i}{i!}.$$

abbiamo che, dal teorema di Lagrange,

$$E_n^{(1)}(x) = |f(x) - S_n^{(1)}(x)| = \frac{\xi^{n+1}}{(n+1)!}, \quad \xi \in (1, x)$$

e se x è grande, il numeratore potrebbe essere abbastanza rilevante da rendere l'errore $E_n^{(1)}(x)$ non troppo piccolo, vista la presenza di $\xi > 1$.

Valutazione dell'esponenziale

Metodo 2. Per un numero naturale $m \geq x$ possiamo scrivere

$$e^x = (e^{x/m})^m$$

e quindi procedere valutando prima $a = e^{x/m}$ e poi eseguire a^m con l'algoritmo mostrato nell'esempio precedente.

Quindi valutiamo

$$S_{n,m}^{(2)}(x) = \left(\sum_{i=0}^n \frac{(x/m)^i}{i!} \right)^m \approx e^x. \quad (24)$$

Si noti che dal teorema di Lagrange,

$$\left| \exp(x/m) - \sum_{i=0}^n \frac{(x/m)^i}{i!} \right| = \frac{\xi^{n+1}}{(n+1)!}, \quad \xi \in [0, 1]$$

che è molto favorevole rispetto alla stima del metodo precedente.

Valutazione dell'esponenziale, facoltativo

Teorema (Facoltativo)

Sia $x > 1$ e $m > \lceil x \rceil$. Poniamo

$$S_{n,m}^{(2)}(x) = \left(\sum_{i=0}^n \frac{x^i}{i! m^i} \right)^m.$$

Allora

$$|f(x) - S_{n,m}^{(2)}(x)| \approx \frac{m}{e^x} \cdot \frac{\xi_2^{n+1}}{(n+1)!}, \quad \xi_2 \in (1/m, x/m).$$

Nota. (Facoltativa)

La quantità

$$\frac{m}{e^x} \cdot \frac{\xi_2^{n+1}}{(n+1)!}, \quad \xi_2 \in (1/m, x/m).$$

è favorevole perchè

- $\xi_2 \in (1/m, x/m) \subset (1/m, 1)$ e quindi la potenza ξ_2^{n+1} diventa *piccola* al crescere di n ;
- se scegliamo $x < m < e^x$ abbiamo $m/e^x < 1$.

Valutazione dell'esponenziale, facoltativo

Quale esempio calcoliamo

$$e^{10 \cdot \pi} \approx 4.403150586063198e + 13,$$

con il primo e il secondo algoritmo, in cui utilizziamo quali parametri $m_1 = 32$, $m_2 = 36$, $m_3 = 41$, che sono maggiori di $10\pi \approx 31.4$. In tabella, mostriamo al variare di n gli errori **relativi**

$$\begin{aligned}\tilde{E}_n^{(1)} &= E_n^{(1)} / e^{10 \cdot \pi} \\ \tilde{E}_{n,m_k}^{(2)} &= E_{n,m_k}^{(2)} / e^{10 \cdot \pi}, \quad k = 1, 2, 3,\end{aligned}$$

che evidenziano i vantaggi del secondo approccio.

n	$\tilde{E}_n^{(1)}$	$\tilde{E}_{n,m_1}^{(2)}$	$\tilde{E}_{n,m_2}^{(2)}$	$\tilde{E}_{n,m_3}^{(2)}$
5	1.0e + 00	1.6e - 02	1.0e - 02	5.7e - 03
10	1.0e + 00	2.4e - 07	8.2e - 08	2.5e - 08
15	1.0e + 00	3.7e - 13	6.6e - 14	5.9e - 15
20	9.8e - 01	6.6e - 15	9.0e - 15	2.7e - 15

Calcolo del determinante, facoltativo

Esempio.

Sia la matrice quadrata $A = (a_{i,j}) \in \mathbb{R}^{n \times n}$. Si calcoli il suo determinante $\det(A)$.

Sia

- $A_{ij}^{(n-1)} \in \mathbb{R}^{(n-1) \times (n-1)}$, la sottomatrice estratta da A cancellando la i -esima riga e la j -esima colonna.
- $\det(A_{ij}^{(n-1)})$, il **minore complementare** di indici (i, j) ;
- $(-1)^{i+j} \det(A_{ij}^{(n-1)})$, il **complemento algebrico** di indici (i, j)

Il primo teorema di Laplace afferma che $\det(A)$ (cf. [23]) è la somma dei prodotti degli elementi di una riga qualsiasi (o una colonna qualsiasi) per i rispettivi complementi algebrici, cioè vale la **formula ricorsiva di Laplace**

$$\det(A) = \sum_{j=1}^n (-1)^{i+j} a_{ij} \det(A_{ij}^{(n-1)}), \quad i, j = 1, \dots, n.$$

il cui costo computazionale è maggiore di $n!$ flops.

Calcolo del determinante, facoltativo

Se $A = LU$ come dalla fattorizzazione LU senza pivoting (cf. [22]), con

- $L = (l_{i,j})$ triangolare inferiore, ovvero $l_{i,j} = 0$ se $i < j$, con componenti diagonali uguali a 1,
- $U = (u_{i,j})$ triangolare superiore, ovvero $u_{i,j} = 0$ se $i > j$,

per il teorema di Binet

$$\det(A) = \det(LU) = \det(L) \cdot \det(U).$$

Osserviamo che

- visto che il determinante di una matrice triangolare $T = (t_{i,j}) \in \mathbb{R}^{n \times n}$ è

$$\det(T) = \prod_{k=1}^n t_{k,k}$$

abbiamo che da $l_{k,k} = 1$, $k = 1, \dots, n$, si ricava $\det(L) = 1$, e quindi

$$\det(A) = \prod_{k=1}^n u_{k,k}.$$

Calcolo del determinante, facoltativo

In definitiva, visto che $\prod_{k=1}^n u_{k,k}$ necessita solo di $n - 1$ operazioni moltiplicative, mentre la fattorizzazione $A = LU$ ha complessità dell'ordine di $n^3/3$, il calcolo del determinante può essere effettuato con circa $n^3/3$ operazioni moltiplicative.

Nella tabella paragoniamo il tempo di calcolo necessario a un supercomputer come Summit che eroga 200 petaflops, ovvero $2 \cdot 10^{17}$ operazioni al secondo, per calcolare il determinante di una matrice generica di ordine n .

Si tenga conto che si presume che l'età dell'universo sia di circa $13.82 \cdot 10^9$ anni.

Calcolo del determinante, facoltativo

n	CPU_L	CPU_{LU}	n	CPU_L	CPU_{LU}
5	$6.0e - 16$ sec	$2.1e - 16$ sec	75	$1.2e + 92$ anni	$7.0e - 13$ sec
10	$1.8e - 11$ sec	$1.7e - 15$ sec	100	$4.7e + 140$ anni	$1.7e - 12$ sec
25	$9.0e + 02$ anni	$2.6e - 14$ sec	125	$9.4e + 191$ anni	$3.3e - 12$ sec
50	$1.8e + 42$ anni	$2.1e - 13$ sec	150	$2.9e + 245$ anni	$5.6e - 12$ sec

Tabella: In questa tabella paragoniamo il tempo di calcolo CPU_L , CPU_{LU} necessario a un supercomputer come Summit che eroga 200 petaflops, ovvero $2 \cdot 10^{17}$ operazioni al secondo, per calcolare il determinante di una matrice generica di ordine n , rispettivamente con la regola di Laplace e via fattorizzazione $PA = LU$.

Bibliografia I

- ▶ D. Arnold, <http://www.ima.umn.edu/~arnold/disasters/>
- ▶ K. Atkinson, *An Introduction to Numerical Analysis*, Wiley, (1989).
- ▶ K. Atkinson and W. Han, *Elementary Numerical Analysis*, third edition, Wiley, (2004).
- ▶ N. Brisebarre and collaborators *Floating-Point Arithmetic*, 2009. <https://perso.ens-lyon.fr/jean-michel.muller/chapitre1.pdf>
- ▶ V. Comincioli, *Analisi Numerica, metodi modelli applicazioni*, Mc Graw-Hill, 1990.
- ▶ V. Comincioli, *Problemi di analisi numerica*, Mc Graw-Hill, 1991.
- ▶ M. Frontini e E. Sormani, *Fondamenti di Calcolo Numerico, problemi in laboratorio*, Apogeo, 2005.
- ▶ W. Gautschi, *Numerical Analysis*, second edition, Birkhäuser, 2012.
- ▶ D. Goldberg, *What Every Computer Scientist Should Know About Floating-Point Arithmetic*, Association for Computing Machinery, Inc, Computing Surveys, March 1991.
- ▶ T. Huckle, <http://www.zenger.informatik.tu-muenchen.de/persons/huckle/bugse.html>.
- ▶ Mars Program,
<http://marsprogram.jpl.nasa.gov/msp98/orbiter>
- ▶ J.H. Mathews e K.D. Fink, *Numerical Methods using Matlab*, Prentice Hall, 1999.
- ▶ Network Theory, *GNU Octave Manual Version*, http://www.network-theory.co.uk/docs/octave3/octave_160.html.
- ▶ A. Quarteroni, *Elementi di calcolo numerico*, seconda edizione, Progetto Leonardo, 1999.
- ▶ A. Quarteroni e F. Saleri, *Introduzione al calcolo scientifico*, Springer Verlag, 2006.
- ▶ A. Quarteroni, R. Sacco e F. Saleri, *Matematica Numerica*, Springer Verlag, 1998.
- ▶ J. Stoer, *Introduzione all'analisi numerica*, Zanichelli, 1984.
- ▶ The MathWorks Inc.,
Numerical Computing with Matlab, <http://www.mathworks.com/moler>.

Bibliografia II

- ▶ L.N. Trefethen, **Numerical Analysis**,
<http://people.maths.ox.ac.uk/trefethen/NAessay.pdf>.
- ▶ Web Page ,
<http://utenti.quipo.it/base5/numeri/pigreco.htm>.
- ▶ Wikipedia (Archimede),
<http://it.wikipedia.org/wiki/Archimede>
- ▶ Wikipedia (Decomposizione LU),
<https://it.wikipedia.org/wiki/Decomposizione.LU>
- ▶ Wikipedia (Determinante),
<https://it.wikipedia.org/wiki/Determinante>
- ▶ Wikipedia (Floating Point),
http://it.wikipedia.org/wiki/Floating_point
- ▶ Wikipedia (IEEE 754),
<http://it.wikipedia.org/wiki/IEEE.754>
- ▶ Wikipedia (IEEE 754r),
<http://it.wikipedia.org/wiki/IEEE.754r>
- ▶ Wikipedia (Norma),
[https://it.wikipedia.org/wiki/Norma_\(matematica\)](https://it.wikipedia.org/wiki/Norma_(matematica))
- ▶ Wikipedia (Pi Greco),
<http://it.wikipedia.org/wiki/Pi-greco>
- ▶ Wikipedia (Regola di Horner),
https://it.wikipedia.org/wiki/Regola_di_Horner
- ▶ Wikipedia (Teorema di Laplace),
https://it.wikipedia.org/wiki/Teorema_di_Laplace.

Bibliografia III

- ▶ Wikipedia (Teorema Fondamentale del Calcolo Integrale),
http://it.wikipedia.org/wiki/Teorema_fondamentale_del_calcolo_integrale
- ▶ Wolfram (Archimedes' Algorithm),
<http://mathworld.wolfram.com/ArchimedesAlgorithm.html>