

# Capitolo 1

## Teoria degli errori

### 1.1 Rappresentazione dei numeri

Scelto un qualunque numero intero  $\beta > 1$ , ogni numero non nullo  $x \in \mathbb{R}$  ammette una *rappresentazione in base  $\beta$*

$$x = \text{sign}(x) \beta^b \sum_{i=1}^{\infty} \alpha_i \beta^{-i},$$

dove  $b \in \mathbb{Z}$  e ogni  $\alpha_i$  è un intero tale che  $0 \leq \alpha_i \leq \beta - 1$ ,  $i = 1, 2, \dots$ , ( $\text{sign}(x)$  è definita come una funzione che assume valore 1 se  $x > 0$  e valore  $-1$  se  $x < 0$ ). Il numero  $\beta$  dicesi appunto la *base*,  $b$  l'*esponente* e i numeri  $\alpha_i$  si dicono le *cifre* della rappresentazione.

Vale il seguente teorema.

**Teorema 1.1.1** (di rappresentazione) *Data una base intera  $\beta > 1$  e un qualunque numero reale  $x$  diverso da zero, esiste un'unica rappresentazione in base  $\beta$  tale che:*

1. sia  $\alpha_1 \neq 0$ ,
2. non vi sia un intero  $k$  per cui si abbia  $\alpha_j = \beta - 1$ ,  $\forall j > k$ .

La rappresentazione definita dal teorema precedente dicesi *rappresentazione in virgola mobile normalizzata* del numero reale  $x$ .

Fissato  $\beta$ , sono quindi univocamente determinati i numeri  $b$  e  $\alpha_i$ ,  $i = 1, 2, \dots$ , della rappresentazione normalizzata e la serie  $\sum_{i=1}^{\infty} \alpha_i \beta^{-i}$  è detta

*mantissa* del numero  $x$ ; è immediato verificare che

$$\frac{1}{\beta} \leq \sum_{i=1}^{\infty} \alpha_i \beta^{-i} < 1.$$

All'interno di un calcolatore si possono rappresentare solo un certo numero  $m$  di cifre della mantissa di  $x$ . La rappresentazione sul calcolatore corrisponde perciò al numero  $y = tr(x)$  oppure a  $y = rd(x)$  dove  $tr(x)$  ed  $rd(x)$  sono approssimazioni di  $x$ , definite dai seguenti due criteri

$$y = tr(x) = sign(x) \beta^b \sum_{i=1}^m \alpha_i \beta^{-i}, \quad (1.1)$$

$$y = rd(x) = \begin{cases} tr(x) & \text{se } 0 \leq \alpha_{m+1} < \frac{\beta}{2} \\ sign(x) \beta^b [\sum_{i=1}^m \alpha_i \beta^{-i} + \beta^{-m}] & \text{se } \frac{\beta}{2} \leq \alpha_{m+1} < \beta \end{cases}. \quad (1.2)$$

Nel caso particolare in cui risulti  $\alpha_1 = \alpha_2 = \dots = \alpha_m = \beta - 1$  e  $\alpha_{m+1} \geq \beta/2$ , nella seconda delle (1.2) la normalizzazione porta ad aumentare di una unità l'esponente  $b$ . Per esempio, con  $\beta = 10$  e  $m = 3$ , se  $x = 0.9997 \times 10^5$  si ha  $rd(x) = 0.100 \times 10^6$ .

La (1.1) si chiama rappresentazione per *troncamento* del numero reale  $x$  mentre la (1.2) fornisce la rappresentazione per *arrotondamento*. Si può dimostrare che  $|tr(x) - x| < \beta^{b-m}$  e  $|rd(x) - x| \leq \frac{1}{2} \beta^{b-m}$ , per cui, tra le due, la rappresentazione per arrotondamento è, in generale, una migliore approssimazione del numero reale  $x$ .

Si indichi con  $M$  l'insieme dei numeri  $z$  rappresentabili all'interno di un calcolatore, comunemente chiamati *numeri di macchina*.

$M$  è un insieme finito; infatti, fissati  $\beta$  ed  $m$  e supposto  $L \leq b \leq U$  ( $L, U \in \mathbb{Z}$ ), la cardinalità di  $M$  risulta  $2(\beta^m - \beta^{m-1})(U - L + 1) + 1$ . Spesso l'insieme  $M$  viene indicato con il simbolo  $F(\beta, m, L, U)$  per meglio evidenziare le caratteristiche della macchina.

Dato un qualunque numero reale  $x \neq 0$ , non è assicurata l'esistenza di  $rd(x)$  fra i numeri di macchina.

Sia, per esempio,  $F(10, 3, -99, 99)$  e  $x = 0.9998 \times 10^{99}$ ; si ha  $rd(x) = 0.1 \times 10^{100}$  che non rientra nell'insieme dei numeri di macchina considerato. In questo caso si ha una situazione di *overflow* e cioè il numero da rappresentare è "troppo grande" e non appartiene a  $M$  (tutti i calcolatori segnalano il presentarsi di un overflow, alcuni arrestano l'esecuzione del programma, altri proseguono con  $rd(x) = sign(x) \max_{y \in M} |y|$ ).

Per contro, si abbia il numero  $x = 0.01 \times 10^{-99}$ ; risulta  $rd(x) = 0.1 \times 10^{-100}$  che non è un numero di macchina. In questo caso si ha una situazione di *underflow*, cioè il numero da rappresentare è "troppo piccolo" e non appartiene a  $M$  (non tutti i calcolatori segnalano questa situazione e nel caso in cui proseguano l'esecuzione del programma pongono  $rd(x) = 0$ ).

Si dimostra che  $rd(x)$  soddisfa la relazione

$$|rd(x) - x| \leq |z - x|, \quad \forall z \in M,$$

per cui, se  $rd(x) \in M$ , esso, in valore assoluto, differisce da  $x$  meno di qualunque altro numero di macchina.

Si definisce *errore assoluto* della rappresentazione del numero reale  $x$  il valore

$$\delta_x = rd(x) - x$$

ed *errore relativo* il valore

$$\epsilon_x = \frac{rd(x) - x}{x} = \frac{\delta_x}{x}.$$

Dalle precedenti considerazioni si ricavano le limitazioni

$$|\delta_x| \leq \frac{1}{2} \beta^{b-m},$$

$$|\epsilon_x| < \frac{1}{2} \beta^{1-m}.$$

Il numero  $u = \frac{1}{2} \beta^{1-m}$  si dice *precisione di macchina*. In generale quando l'errore relativo di una approssimazione non supera  $\frac{1}{2} \beta^{1-k}$  si dice che l'approssimazione è corretta almeno fino alla  $k$ -esima cifra significativa. Da quanto sopra segue quindi che  $rd(x)$  approssima  $x$  almeno fino alla  $m$ -esima cifra significativa.

Se si assume la base  $\beta = 2$  ogni cifra della rappresentazione di un numero ha valore 0 o 1 e si dice *bit*<sup>1</sup> (binary digit), mentre si dice *parola* di lunghezza  $t$  l'insieme dei  $t$  bit rappresentanti un numero. Per ragioni tecniche si usa spesso una base  $\beta = 2^n$  ( $n > 1$ ) in cui ciascuna cifra, tradotta in rappresentazione binaria, richiede  $n$  bit.

Si distinguono la rappresentazione dei numeri interi da quella dei reali e l'aritmetica che opera solo con numeri interi da quella che opera indifferentemente con numeri interi e reali.

In 1.1.1, 1.1.2, 1.1.3, si farà riferimento al caso  $t = 32$ .

---

<sup>1</sup>Il termine bit è usato nel seguito in forma invariata anche al plurale.

### 1.1.1 Numeri interi

Per rappresentare un numero intero i 32 bit della parola vengono così utilizzati: un bit fornisce il segno del numero (per esempio 0 se il numero è positivo e 1 se è negativo), i restanti 31 bit servono a rappresentare in base 2 le cifre del numero dato. E' evidente che il massimo intero rappresentabile è, in valore assoluto,  $2^{31} - 1 = 2147483647$ .

### 1.1.2 Numeri reali (precisione semplice)

Nella rappresentazione dei numeri reali una situazione caratteristica è la seguente: la base è 16 (sistema esadecimale), un bit è riservato al segno del numero, sette bit sono riservati alla rappresentazione dell'esponente  $b$ , i restanti 24 bit sono utilizzati per le cifre  $\alpha_i$  della mantissa che, in base 16, sono 6 in quanto occorrono 4 bit per rappresentare in binario una cifra esadecimale compresa tra 0 e 15. L'esponente  $b$  non è rappresentato in segno ma in traslazione rispetto a 64 e cioè viene rappresentato il numero  $b^* = b+64$ ; ne segue che  $b$  è compreso tra  $-64$  e  $63$ .

Di conseguenza, indicando con  $F$  la cifra esadecimale che corrisponde al numero  $15^2$ , il massimo numero rappresentabile (in precisione semplice) è  $0.FFFFFFF \times 16^{63} \simeq 7.23 \times 10^{75}$ , il minimo numero non negativo rappresentabile risulta  $0.1 \times 16^{-64} \simeq 5.39 \times 10^{-79}$  e la precisione di macchina è  $u_s = \frac{1}{2}16^{-5} \simeq 4.75 \times 10^{-7}$ .

### 1.1.3 Numeri reali (doppia precisione)

I numeri reali si dicono in doppia precisione quando sono rappresentati con una doppia parola e quindi con 64 bit. Rispetto alla precisione semplice cambia solo il numero delle cifre esadecimali della mantissa che da 6 divengono 14 in quanto essa viene ad includere i 32 bit aggiunti. L'insieme dei numeri rappresentabili non cambia molto mentre cambia la precisione di macchina che diviene  $u_d = \frac{1}{2}16^{-13} \simeq 1.11 \times 10^{-16}$ .

È possibile anche l'uso di precisioni multiple in cui si incrementa ulteriormente il numero delle cifre della mantissa, migliorando di conseguenza la precisione di macchina.

---

<sup>2</sup>Le cifre della rappresentazione in base 16 sono: 0, 1, 2, 3, 4, 5, 6, 7, 8, 9, A, B, C, D, E, F.

## 1.2 Le operazioni di macchina

Nell'insieme  $M$  non tutte le proprietà delle quattro operazioni elementari risultano verificate, in quanto il risultato di una operazione deve essere ricondotto ad un numero di macchina: perciò le operazioni elementari all'interno di una macchina sono diverse dalle corrispondenti operazioni ordinarie. Si indicano nel seguente modo le quattro *operazioni di macchina*:

- $\oplus$  addizione
- $\ominus$  sottrazione
- $\otimes$  moltiplicazione
- $\oslash$  divisione.

Un esempio in cui l'addizione ( $\oplus$ ) non gode della proprietà associativa è il seguente.

Sia  $F(10, 3, -99, 99)$  e sia  $x = 0.135 \times 10^{-4}$ ,  $y = 0.258 \times 10^{-2}$ ,  $z = -0.251 \times 10^{-2}$ ; si ha

$$\begin{aligned} x \oplus (y \oplus z) &= 0.135 \times 10^{-4} \oplus (0.258 \times 10^{-2} \oplus -0.251 \times 10^{-2}) \\ &= 0.135 \times 10^{-4} \oplus 0.700 \times 10^{-4} \\ &= 0.835 \times 10^{-4}, \end{aligned}$$

mentre

$$\begin{aligned} (x \oplus y) \oplus z &= (0.135 \times 10^{-4} \oplus 0.258 \times 10^{-2}) \oplus -0.251 \times 10^{-2} \\ &= 0.259 \times 10^{-2} \oplus -0.251 \times 10^{-2} \\ &= 0.800 \times 10^{-4}. \end{aligned}$$

In modo analogo si possono dare esempi in cui l'operazione  $\otimes$  non gode della proprietà distributiva rispetto alla addizione.

Quando si sottraggono due numeri di macchina dello stesso segno che hanno lo stesso esponente  $b$  e con le mantisse che differiscono di poco, si incorre in una perdita di cifre significative nel risultato. Tale fenomeno, detto *cancellazione*, produce, come si vedrà più avanti, una notevole amplificazione degli errori relativi.

## 1.3 Errore nel calcolo di una funzione

Una funzione non razionale  $\varphi$  viene sempre sostituita, all'interno di un calcolatore, da una funzione razionale  $f$ , il cui uso comporta un errore  $f - \varphi$  che si dice *errore di troncamento*. Tale errore, all'occorrenza è facilmente maggiorabile.

Tuttavia anche nel calcolo di una funzione razionale  $f(x_1, x_2, \dots, x_n)$  in un punto assegnato  $P_0 = (x_1^{(0)}, x_2^{(0)}, \dots, x_n^{(0)})$ , in generale, non si ottiene il valore  $f(P_0)$  cercato, a causa delle approssimazioni che si introducono.

Tali approssimazioni producono due tipi di errore.

Un primo errore nasce dal fatto che le operazioni aritmetiche che compaiono nella  $f(P)$  devono essere sostituite con le corrispondenti operazioni di macchina e organizzate in un certo algoritmo e ciò equivale in definitiva alla sostituzione di  $f(P)$  con un'altra funzione  $f_a(P)$  che la approssimi.

Un secondo tipo di errore si presenta quando non è possibile rappresentare esattamente le coordinate del punto  $P_0$  e quindi si devono approssimare tali coordinate con numeri di macchina (basti pensare, per esempio, al punto  $P_0 = (\sqrt{2}, \pi)$ ).

### 1.3.1 Errore assoluto

Assegnato il punto  $P_0 \in \mathbb{R}^n$  di coordinate  $x_i^{(0)}$ ,  $i = 1, 2, \dots, n$ , nel quale si vuole calcolare la funzione  $f(P)$ , si consideri l'insieme

$$D = \{P \in \mathbb{R}^n \mid a_i \leq x_i \leq b_i, i = 1, 2, \dots, n\}$$

dove  $a_i, b_i \in \mathbb{R}$  e si supponga che sia  $a_i \leq x_i^{(0)} \leq b_i$ ,  $i = 1, 2, \dots, n$ ;  $D$  si dice *insieme di indeterminazione* del punto  $P_0$ .

In effetti il valore cercato  $f(P_0)$  viene sostituito dal valore calcolato  $f_a(P_1)$  dove  $P_1$ , di coordinate  $x_i^{(1)}$ ,  $i = 1, 2, \dots, n$ , appartiene a  $D$  e quindi l'errore commesso risulta  $f_a(P_1) - f(P_0)$ ; di questo errore, detto *errore totale*, si può dare una stima.

Si pone

$$f_a(P_1) - f(P_0) = f_a(P_1) - f(P_1) + f(P_1) - f(P_0)$$

dove la differenza  $f_a(P_1) - f(P_1)$  è detta *errore algoritmico* mentre la differenza  $f(P_1) - f(P_0)$  è detta *errore trasmesso dai dati*.

L'errore algoritmico, una volta fissato l'algoritmo che fornisce  $f_a(P)$ , risulta definito e stimabile.

All'errore trasmesso, nell'ipotesi che  $f(P) \in C^1(D)$ , si può dare una rappresentazione generale: dalla formula di Taylor arrestata al primo termine e con punto iniziale  $P_0$  si ottiene

$$f(P_1) - f(P_0) = \sum_{i=1}^n \frac{\partial f}{\partial x_i}(x_i^{(1)} - x_i^{(0)}) \quad (1.3)$$

dove le derivate parziali della funzione  $f(P)$  sono calcolate in un punto opportuno. Indicando con

$$\begin{aligned} \delta_f &= f_a(P_1) - f(P_0) && \text{l'errore totale,} \\ \delta_a &= f_a(P_1) - f(P_1) && \text{l'errore algoritmico,} \\ \delta_d &= f(P_1) - f(P_0) && \text{l'errore trasmesso dai dati,} \end{aligned}$$

risulta

$$\delta_f = \delta_a + \delta_d.$$

Ponendo poi

$$\delta_{x_i} = x_i^{(1)} - x_i^{(0)}, \quad \rho_i = \frac{\partial f}{\partial x_i},$$

la (1.3) diventa

$$\delta_d = \sum_{i=1}^n \rho_i \delta_{x_i}.$$

I valori  $\rho_i$  sono detti *coefficienti di amplificazione* degli errori  $\delta_{x_i}$ .

Una limitazione per il modulo dell'errore assoluto  $f_a(P_1) - f(P_0)$  è

$$|f_a(P_1) - f(P_0)| \leq E_a + E_d$$

dove si è posto

$E_a$  = massimo modulo dell'errore assoluto dovuto  
al particolare algoritmo usato,

$$E_d = \sum_{i=1}^n A_{x_i} |\delta_{x_i}|, \quad (1.4)$$

con

$$A_{x_i} \geq \sup_{x \in D} \left| \frac{\partial f}{\partial x_i} \right|, \quad i = 1, 2, \dots, n. \quad (1.5)$$

Se si conosce una stima dell'errore di troncamento e degli errori  $\delta_{x_i}$  nonché le  $A_{x_i}$ , si può stabilire a posteriori un confine superiore per l'errore assoluto con cui si è calcolata la funzione nel punto desiderato; questo problema è detto *problema diretto*.

Il *problema inverso* consiste nel richiedere a priori che il valore  $f_a(P_1)$  sia tale che l'errore assoluto  $|f_a(P_1) - f(P_0)|$  risulti minore di un valore prefissato, per cui si deve cercare sia un algoritmo  $f_a(P)$  sia un opportuno punto  $P_1$  che soddisfino la richiesta.

### 1.3.2 Errore relativo

L'*errore relativo* che si commette nel calcolo di una funzione  $f(P)$  in un assegnato punto  $P_0$  è definito da

$$\epsilon_f = \frac{f_a(P_1) - f(P_0)}{f(P_0)}.$$

Si verifica facilmente che

$$\epsilon_f = \frac{f(P_1) - f(P_0)}{f(P_0)} + \frac{f_a(P_1) - f(P_1)}{f(P_1)} \left( 1 + \frac{f(P_1) - f(P_0)}{f(P_0)} \right)$$

per cui, indicando con

$$\epsilon_a = \frac{f_a(P_1) - f(P_1)}{f(P_1)}$$

l'*errore relativo algoritmico* e con

$$\epsilon_d = \frac{f(P_1) - f(P_0)}{f(P_0)}$$

l'*errore relativo trasmesso dai dati*, si ottiene

$$\epsilon_f = \epsilon_a + \epsilon_d + \epsilon_a \epsilon_d. \quad (1.6)$$

Nella (1.6) si trascura il termine  $\epsilon_a \epsilon_d$  in quanto di ordine superiore.

Quanto all'errore relativo trasmesso dai dati, dalla relazione (1.3) si ricava

$$\epsilon_d = \frac{f(P_1) - f(P_0)}{f(P_0)} = \sum_{i=1}^n \frac{\partial f}{\partial x_i} \frac{(x_i^{(1)} - x_i^{(0)})}{f(P_0)}$$

ed ancora, definendo  $\epsilon_{x_i} = \frac{x_i^{(1)} - x_i^{(0)}}{x_i^{(0)}}$ ,

$$\epsilon_d = \sum_{i=1}^n \frac{x_i^{(0)}}{f(P_0)} \frac{\partial f}{\partial x_i} \epsilon_{x_i}.$$

Infine, ponendo  $\gamma_i = \frac{x_i^{(0)}}{f(P_0)} \frac{\partial f}{\partial x_i}$ , si ha

$$\epsilon_d = \sum_{i=1}^n \gamma_i \epsilon_{x_i},$$

dove i valori  $\gamma_i$  sono detti *coefficienti di amplificazione* degli errori relativi.

Se i coefficienti  $\gamma_i$  sono tali che l'errore  $\epsilon_d$  risulta dello stesso ordine degli errori  $\epsilon_{x_i}$  il problema del calcolo della funzione si dice *ben condizionato*; si dice invece *mal condizionato* se a piccoli errori relativi  $\epsilon_{x_i}$  corrisponde un errore  $\epsilon_d$  rilevante.

Dalla (1.6) si vede che all'errore  $\epsilon_f$  concorre anche l'errore algoritmico  $\epsilon_a$ : se l'algoritmo è tale da produrre errori accettabilmente limitati nella sua applicazione, si dice *stabile*, mentre è detto *instabile* nel caso contrario.

## 1.4 Gli errori nelle quattro operazioni

Analizzando le quattro operazioni fondamentali per quanto riguarda gli errori trasmessi dai dati si ottiene la seguente tabella:

operazione	$\delta_d$	$\epsilon_d$
$x \oplus y$	$\delta_x + \delta_y$	$\frac{x}{x+y} \epsilon_x + \frac{y}{x+y} \epsilon_y$
$x \ominus y$	$\delta_x - \delta_y$	$\frac{x}{x-y} \epsilon_x - \frac{y}{x-y} \epsilon_y$
$x \otimes y$	$y \delta_x + x \delta_y$	$\epsilon_x + \epsilon_y$
$x \oslash y$	$\frac{1}{y} \delta_x - \frac{x}{y^2} \delta_y$	$\epsilon_x - \epsilon_y$

Si deduce che le operazioni di addizione e sottrazione non danno problemi per quanto riguarda l'errore assoluto, mentre possono rendere grande l'errore relativo nel caso in cui i due termini dell'operazione siano molto vicini in valore assoluto, in quanto può accadere che i denominatori che compaiono nei coefficienti di amplificazione dell'errore relativo siano molto piccoli in valore assoluto (fenomeno della cancellazione già accennato in 1.2). La moltiplicazione non amplifica l'errore relativo e comporta un errore assoluto che

dipende dall'ordine di grandezza dei fattori; anche la divisione non produce amplificazione per quanto riguarda l'errore relativo, mentre l'errore assoluto diminuisce se aumenta (in valore assoluto) il divisore.

## 1.5 Complementi ed esempi

Si riportano due esempi sul calcolo degli errori assoluti e relativi.

**Esempio 1.5.1** Si vuole calcolare la funzione  $f(x_1, x_2) = x_1/x_2$  nel punto assegnato  $P_0 = (\sqrt{5}, \pi)$ .

Si assuma  $D = \{(x_1, x_2) \in \mathbb{R}^2 | 2.23 < x_1 < 2.24, 3.14 < x_2 < 3.15\}$  come insieme di indeterminazione del punto  $P_0$  (dalle (1.4) e (1.5) si ricava che più si riduce l'insieme  $D$  e più stringente è la maggiorazione dell'errore assoluto).

### Problema diretto

Si calcola il rapporto  $x_1/x_2$  arrotondando il risultato alla seconda cifra decimale, ottenendo quindi un errore  $E_a \leq \frac{1}{2}10^{-2}$ .

Assumendo  $P_1 = (2.235, 3.145)$  si ha sicuramente  $|\delta_{x_1}|, |\delta_{x_2}| \leq \frac{1}{2}10^{-2}$ .

Dalla funzione e dall'insieme  $D$  si traggono le maggiorazioni

$$\sup_{x \in D} \left| \frac{\partial f}{\partial x_1} \right| \leq A_{x_1} = 0.32,$$

$$\sup_{x \in D} \left| \frac{\partial f}{\partial x_2} \right| \leq A_{x_2} = 0.23;$$

da cui si ha il massimo errore assoluto

$$E_a + E_d \leq \frac{1}{2}10^{-2} + (0.32 + 0.23)\frac{1}{2}10^{-2} = 0.775 \times 10^{-2}.$$

### Problema inverso

Si vuole avere un valore che differisca dal valore esatto  $f(P_0)$  meno di un prefissato errore  $E = 10^{-2}$ .

Si può imporre che  $E_a$  ed  $E_d$  siano, ciascuno, non superiore a metà dell'errore totale richiesto e quindi che sia  $E_a \leq \frac{1}{2}10^{-2}$  e  $E_d \leq \frac{1}{2}10^{-2}$ .

Per l'errore di troncamento è sufficiente arrotondare il risultato della divisione alla seconda cifra decimale.

Poiché l'errore trasmesso dai dati è formato dalla somma di due addendi, si suddivide ancora il contributo a tale errore in due parti uguali per cui si ha

$$A_{x_1} | \delta_{x_1} | \leq \frac{1}{4} 10^{-2},$$

$$A_{x_2} | \delta_{x_2} | \leq \frac{1}{4} 10^{-2};$$

assumendo per  $A_{x_1}$  e  $A_{x_2}$  i valori calcolati in precedenza si ottiene

$$| \delta_{x_1} | \leq \frac{1}{4} 10^{-2} \frac{1}{0.32} \simeq 0.0078,$$

$$| \delta_{x_2} | \leq \frac{1}{4} 10^{-2} \frac{1}{0.23} \simeq 0.0109,$$

per cui si può porre  $P_1 = (2.24, 3.14)$ .

Si ha quindi  $f_a(P_1) = 0.71$  che differisce da  $f(P_0)$  meno di  $E$ .  $\square$

**Esempio 1.5.2** Si vuole stimare l'errore relativo commesso nel calcolo della funzione  $f(x, y, z, w) = x(y/z - w)$ .

Si può ricorrere all'uso dei *grafi*; si calcola la funzione eseguendo una operazione dopo l'altra e stabilendo per ciascuna di esse l'entità degli errori relativi.

In questo esempio la sequenza delle operazioni è

$$r_1 = \frac{y}{z}, \quad r_2 = r_1 - w, \quad r_3 = xr_2.$$

Il grafo in Fig. 1.1 evidenzia per ogni operazione i coefficienti di amplificazione lungo i cammini orientati. Gli errori relativi dei dati sono  $\epsilon_x, \epsilon_y, \epsilon_z, \epsilon_w$ , mentre  $\epsilon_{r_i}$  va inteso come l'errore relativo per la funzione  $r_i$  e si calcola dalla (1.6) senza l'ultimo termine.

Per stimare l'errore relativo totale si procede a ritroso seguendo il grafo. Indicando con  $\epsilon_i$  l'errore algoritmico della  $i$ -esima operazione si ha

$$\begin{aligned} \epsilon_f &= \epsilon_{r_3} \\ &= \epsilon_3 + \epsilon_x + \epsilon_{r_2} \\ &= \epsilon_3 + \epsilon_x + \epsilon_2 + \frac{y}{y-zw} \epsilon_{r_1} - \frac{zw}{y-zw} \epsilon_w \\ &= \epsilon_3 + \epsilon_x + \epsilon_2 + \frac{y}{y-zw} (\epsilon_1 + \epsilon_y - \epsilon_z) - \frac{zw}{y-zw} \epsilon_w \\ &= \epsilon_3 + \epsilon_2 + \frac{y}{y-zw} \epsilon_1 + \epsilon_x + \frac{y}{y-zw} (\epsilon_y - \epsilon_z) - \frac{zw}{y-zw} \epsilon_w. \end{aligned}$$

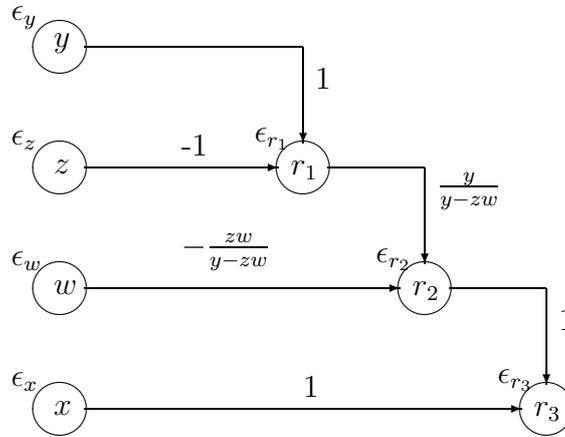


Figura 1.1: Esempio di grafo.

Se ne conclude che l'errore algoritmico è

$$\epsilon_a = \epsilon_3 + \epsilon_2 + \frac{y}{y - zw} \epsilon_1$$

e l'errore trasmesso è

$$\epsilon_d = \epsilon_x + \frac{y}{y - zw} (\epsilon_y - \epsilon_z) - \frac{zw}{y - zw} \epsilon_w .$$

□

**Osservazione 1.5.1** L'errore relativo calcolato nell'Esempio 1.5.2 dipende dall'algoritmo seguito per il calcolo della funzione  $f(x, y, z, w)$ ; seguendo un altro algoritmo si trova, in generale, un errore relativo diverso.

**Bibliografia:** [1], [5], [28], [29].