Esempio 1: virgola mobile

- Rappresentazione binaria in virgola mobile a 16 bit:
  - 1 bit per il segno (0=positivo)
  - 8 bit per l'esponente, in eccesso 128
  - 7 bit per la parte frazionaria della mantissa normalizzata tra 1 e 2
- Calcolare gli estremi degli intervalli rappresentati, i numerali corrispondenti, e l’ordine di grandezza decimale.
- Rappresentare in tale notazione il numero *n* rappresentato in compl. a 2 dai tre byte FF5AB9.
- Calcolare l’errore relativo ed assoluto che si commette rappresentando il *n* nella notazione data.

Esempio 2: virgola mobile

- Rappresentazione binaria in virgola mobile a 16 bit:
  - 1 bit per il segno (0=positivo)
  - 8 bit per l'esponente, in eccesso 128
  - 7 bit per la parte frazionaria della mantissa normalizzata tra 1 e 2
- Dato il numero razionale *m* rappresentato in tale notazione dai due byte 41A5, calcolare l'intero *n* che approssima *m* per difetto, e rappresentarlo in complemento a 2 con 16 bit.

Esempio 3: virgola mobile

- Rappresentazione binaria in virgola mobile a 16 bit:
  - 1 bit per il segno (0=positivo)
  - *e* bit per l'esponente, in eccesso 2^{e-1}
  - 15- *e* bit per la parte frazionaria della mantissa normalizzata tra 1 e 2
- Calcolare il valore minimo e_{min} di bit per l'esponente che consenta di rappresentare il numero *n* rappresentato in compl. a 2 dai tre byte FF5AB9

Esempio 4: virgola mobile

- Rappresentazione binaria in virgola mobile a 16 bit:
  - 1 bit per il segno (0=positivo)
  - 7 bit per l'esponente, in eccesso 64
  - 8 bit per la parte frazionaria della mantissa normalizzata tra 1 e 2
- Dati *m* e *n* rappresentati in tale notazione dalle stringhe esadecimali FA53 e F9F2:
- Calcolare la somma di *m* e *n* e fornire la stringa esadecimale che la rappresenta nella notazione suddetta.

Soluzione esercizio 1

Per l'esponente,essendo n=8, in eccesso 128 l'intervallo da considerare è:

$$[-2^{n-1}, 2^{n-1}-1].$$

Quindi per l'esponente l'intervallo è: [-128, 127]

Il numerale positivo più grande rappresentabile sarà quindi:

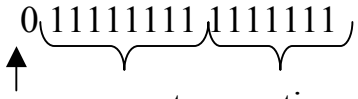

Poiché la mantissa è normalizzata tra 1 e 2, la stringa 1111111 può essere approssimata a 2 per cui il numero positivo più grande rappresentabile è (esponente * mantissa) $2^{127} * 2 = \sim 2^{128}$.

Il numerale positivo più piccolo rappresentabile sarà:

0 00000000 0000000

In questo caso essendo la mantissa pari a 1,00000000, il numero positivo più piccolo è $2^{-128} * 1$ (esponente * mantissa).

Quindi gli estremi dell'intervallo rappresentabile sono 2^{128} e 2^{-128}.

Per simmetria dell'intervallo dei numeri negativi,l'insieme dei numeri rappresentabili è: $(-2^{128}, -2^{-128}], [2^{-128}, 2^{128})$. Gli intervalli sono aperti in quanto la mantissa e' leggermente piu' piccola di 2.

Per quanto riguarda l'ordine di grandezza decimale,sapendo che $2^{10} \approx 10^3$ è possibile calcolare gli ordini di grandezza mediante la seguente proporzione:

$$10 : 3 = 128 : x$$

$x = (128 * 3)/10 \approx 38$

Gli ordini di grandezza in decimale sono quindi 10^{-38} e 10^{38}.

Il numero da rappresentare è:

F	F	5	A	B	9
1111	1111	0101	1010	1011	1001

dove il 1° bit è il segno.

Lasciando invariati i bit fino al primo 1 e complementando poi i successivi si ottiene il modulo del numero in questione:

000000010100101010000111

Si può notare come si potrebbe arrivare allo stesso risultato ignorando tutti i bit piu' significativi a 1 tranne l'ultimo, cioè considerando solo il complemento di:

~~1111~~10101101010111001

Volendo normalizzare il numero complementato 000000010100101010000111, è necessario spostare la virgola a sinistra di 15 posti.

Quindi dividendo e moltiplicando per 2^{15} si ottiene:

$$1{,}010010101000111 * 2^{15}$$

L'esponente in eccesso 128 è quindi 15+128 = 143.

Il numero in notazione 16 bit è:

1 10001111 0100101

Notiamo che la parte residua non rappresentata del numero è:

$$0{,}000000001000111 * 2^{15}$$

e corrisponde quindi all'errore assoluto ($\varepsilon_a = n - n'$), dato dalla differenza fra il numero da rappresentare ed il numero rappresentato.

Per quanto riguarda l'errore relativo invece,è possibile calcolarlo valutando la distanza fra il bit più significativo della parte non rappresentata ed il bit piu' significativo della parte rappresentat:

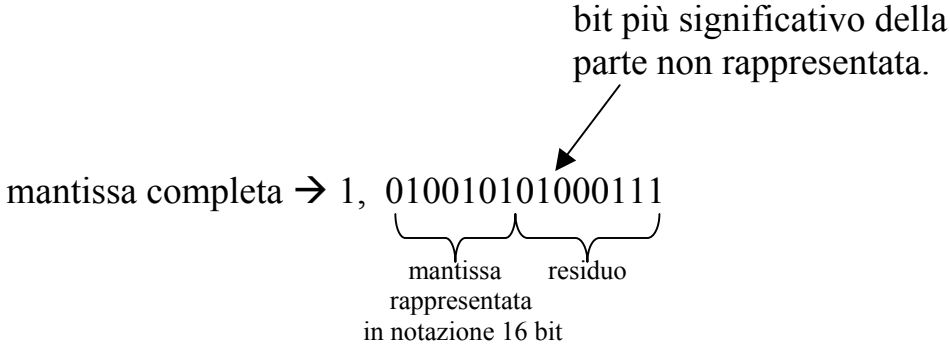

Come si può vedere,la distanza del bit più significativo della parte non rappresentata dista 9 posizioni dal bit a sinistra della virgola per cui l'errore relativo è:

$$\varepsilon_r = 2^{-9}$$

L'errore relativo massimo,essendo la mantissa normalizzata, è costante per l'insieme dei numeri rappresentati ed è pari alla potenza associata al bit meno significativo della mantissa, cioè 2^{-7}.

Soluzione esercizio 2

Il numero m è:

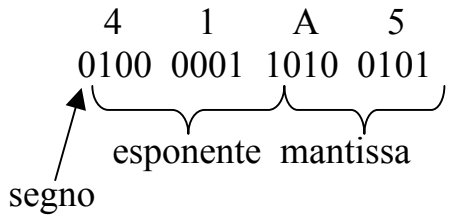

Quindi l'esponente in eccesso 128 è 10000011.
Complementando il bit più significativo si ha 00000011 che equivale a $(3)_{10}$.
La mantissa è 1,0100101 per cui il numero rappresentato è:

1010,0101 approssimato per difetto da 1010, la cui rappresentazione in CP2 con 16 bit e:

0000000000001010

Soluzione esercizio 3

Il numero n è:

F	F	5	A	B	9
~~1111~~	~~111~~1	0101	1010	1011	1001

Trascurando i bit piu' significativi posti a 1 (tranne l'ultimo) e lasciando invariati i bit fino al primo 1 e complementando poi i successivi si ottiene il modulo del numero in questione:

01010010101000111

Spostando la virgola a sinistra di 15 posti (dividendo e moltiplicando per 2^{15}) risulta:

$$1{,}010010101000111 * 2^{15}$$

Quindi l'esponente da rappresentare è $(15)_{10}$.
15 ricade nell'intervallo [-16, +15] per cui si ricava che il numero *e* di bit minimo per la rappresentazione dell'esponente in eccesso 2^{e-1} è dato da: $e = 5$.
La mantissa sarà rappresentata da $15 - e = 10$ bit.
Il numero rappresentato è quindi:

1 11111 0100101010

La parte non rappresentata è $0{,}000000000000111 * 2^{15}$ e coincide con l'errore assoluto, mentre l'errore relativo è $\varepsilon_r = 2^{-13}$.

Soluzione esercizio 4

I numeri da rappresentare sono:

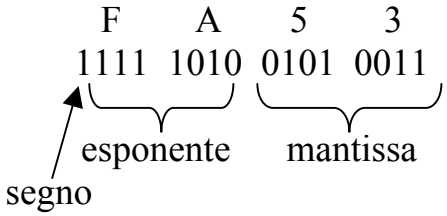

L'esponente in eccesso 64 è 1111010 e in complemento a due equivale a complementare il bit più significativo, quindi 0111010 che in decimale vale 58.
In definitiva $m = 1{,}01010011 * 2^{58}$

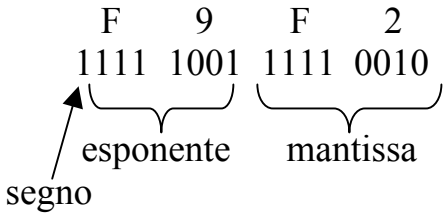

L'esponente in eccesso 64 è 1111001 e in complemento a due equivale a complementare il bit più significativo, quindi 0111001 che in decimale vale 57.
In definitiva $n = 1{,}11110010 * 2^{57}$
Per eseguire la somma è necessario trasformare uno dei due numeri al fine di ottenere lo stesso esponente.
Trasformando il più piccolo (n) si ha:
$n = 0{,}111110010 * 2^{58}$
A questo punto è possibile sommare le mantisse:

$$\begin{array}{r} 1{,}01010011+ \\ \underline{0{,}11111001} \\ 10{,}01001100 \end{array}$$

Si ha dunque: $h = m + n = 10{,}01001100 * 2^{58} = 1{,}001001100 * 2^{59}$
L'esponente del numero da rappresentare in eccesso 64 è

$$(59+64)_{10} = (123)_{10} = (1111011)_2$$

Il numero nella rappresentazione considerata è quindi

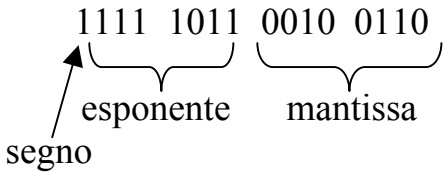

che in esadecimale diventa FB26.

Consideriamo ora un'altra coppia di numeri:

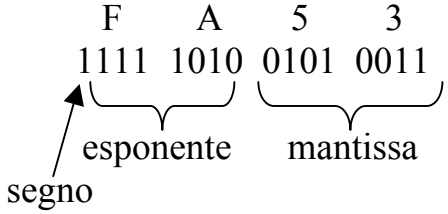

L'esponente in eccesso 64 è 1111010 che in complemento a due equivale a complementare il bit più significativo,quindi 0111010 che in decimale vale a 58.
In definitiva m = 1,01010011 * 2^{58}

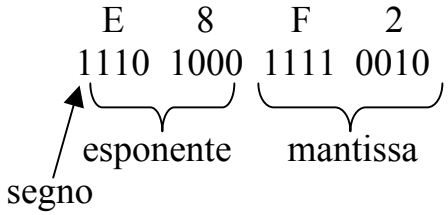

L'esponente in eccesso 64 è 0101000 e in complemento a due equivale a complementare il bit più significativo,quindi 0111001 che in decimale vale a 40.
In definitiva n = 1,11110010 * 2^{40}
Come prima,per poter eseguire la somma è necessario trasformare uno dei due numeri al fine di ottenere lo stesso esponente.
Trasformando il più piccolo (n) si ha (spostando la virgola a sinistra di 18 posti):
n = 0,00000000000000000111110010 * 2^{58}
A questo punto è possibile sommare le mantisse:

$$\begin{array}{r} 1{,}01010011+ \\ \underline{0{,}00000000} \\ 1{,}01010011 \end{array}$$

Si ha dunque: h = m + n = 1,01010011 * 2^{58} che è proprio uguale al numero più grande.

Quello che si vuole mettere in evidenza in questo esercizio è che se gli esponenti dei due numeri rappresentati m ed n differiscono per un valore maggiore del numero di bit utilizzati per rappresentare l'esponente, il risultato della somma è pari al numero più grande rappresentato (in questo caso m).