

# Problemi di approssimazione

Corso di Laboratorio  
di Calcolo

# La somma di N numeri

```
#define N 10000000
float x = 7., Sf = 0.;
int i, k = 7, Si = 0 ;
for (i = 0; i < N; i++) {
    Sf += x;
    Si += k;
}
printf("%d %.0f\n", Si, Sf) ;
```

$$\sum_{i=1}^{10^7} 7 = 7 \times 10^7 = 70M$$

# La somma di N numeri

```
#define N 10000000
float x = 7., Sf = 0.;
int i, k = 7, Si = 0 ;
for (i = 0; i < N; i++) {
    Sf += x;
    Si += k;
}
printf("%d %.0f\n", Si, Sf) ;
```

$$\sum_{i=1}^{10^7} 7 = 7 \times 10^7 = 70M$$

```
> gcc -o somma.exe somma.c
> ./somma.exe
> 70000000 77603248
```



# Cosa avviene in memoria

$$x=7=2^2 (1+2^{-1}+2^{-2})=2^2 2^{22} (2^{-22}+2^{-23}+2^{-24})$$

$$i=2396746 \quad sf=16777222=2^{24} (1+2^{-22}+2^{-23})$$

 sposta di 21 bit

$$x = 0 \text{ 10010111 (0) 0000000000000000000000000111}$$


  $2^{24}$

$$S = 0 \text{ 10010111 (1) 0000000000000000000000000011}$$




# Perché S è maggiore di 70 milioni?


La FPU usa 80 bit




# Perché S è maggiore di 70 milioni?



# Perché S è maggiore di 70 milioni?



# Perché S è maggiore di 70 milioni?



# Come si controlla?(1)

```
float sum=0., corr=0., x=7.;
int i;
for (i=0; i<N; i++) {
    float tmp, y;
    y = corr + x;  x=7, y=7
    tmp = sum + y; tmp = 7 tmp = 14
    corr = (sum - tmp) + y; corr = 0
    sum = tmp; sum = 7 sum = 14
}
sum += corr;
```

# Come si controlla?(2)

```
float sum=0., corr=0., x=7.;
int i;
for (i=0; i<N; i++) {
    float tmp, y;
    y = corr + x;    /* corr = 0 → y = x */
    tmp = sum + y;  /* tmp = sum + x */
    corr = (sum - tmp) + y; /* sum - sum - x + x */
    sum = tmp;      /* sum = tmp */
}
sum += corr;
```

# Come si controlla?(3)

```
float sum=0., corr=0., x=7.;
int i;
for (i=0; i<N; i++) {
    float tmp, y;
    y = corr + x;
    tmp = sum + y;
    corr = (sum - tmp) + y;
    sum = tmp;
}
sum += corr;
```

Se  $tmp = sum + x + \delta$

$corr = sum - (sum + x + \delta) + x = -\delta$

Al ciclo successivo  $y = -\delta + x$

# Come si controlla?(4)

```
float sum=0., corr=0., x=7.;
int i;
for (i=0; i<N; i++) {
    float tmp, y;
    y = corr + x; /* corr=0, y=7 */
    tmp = sum + y; /* sum=16777222, tmp=16777228 */
    corr = (sum - tmp) + y; /*corr=(16777222-
                            16777228)+7=1 */
    sum = tmp; /* sum=16777228 */
}
sum += corr;
```

# Come si controlla?(5)

```
float sum=0., corr=0., x=7.;
int i;
for (i=0; i<N; i++) {
    float tmp, y;
    y = corr + x; /* corr=1, y=8 */
    tmp = sum + y; /* sum=16777228, tmp=16777236 */
    corr = (sum - tmp) + y; /*corr=(16777228-
                            16777236)+7=-1 */
    sum = tmp; /* sum=16777236 */
}
sum += corr;
```

# Come si controlla?(6)

```
float sum=0., corr=0., x=7.;
int i;
for (i=0; i<N; i++) {
    float tmp, y;
    y = corr + x; /* corr=-1, y=6 */
    tmp = sum + y; /* sum=16777236, tmp=16777242 */
    corr = (sum - tmp) + y; /*corr=(16777236-
                            16777242)+7=1 */
    sum = tmp; /* sum=16777242 */
}
sum += corr;
```