

# Fondamenti di Architettura degli Elaboratori

Francesco Giacomini  
INFN – CNAF

Bologna, 21 dicembre 2015

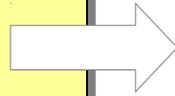
tratto da: <http://www.unife.it/scienze/informatica/insegnamenti/architettura-elaboratori>



# Obiettivo della lezione

- Comprendere gli elementi essenziali dell'interfaccia offerta da un sistema di calcolo per l'esecuzione, corretta ed efficiente, di un programma scritto in un linguaggio di alto livello

```
void swap(int* l, int* r)
{
    int t = *l;
    *l = *r;
    *r = t;
}
```



# Argomenti trattati

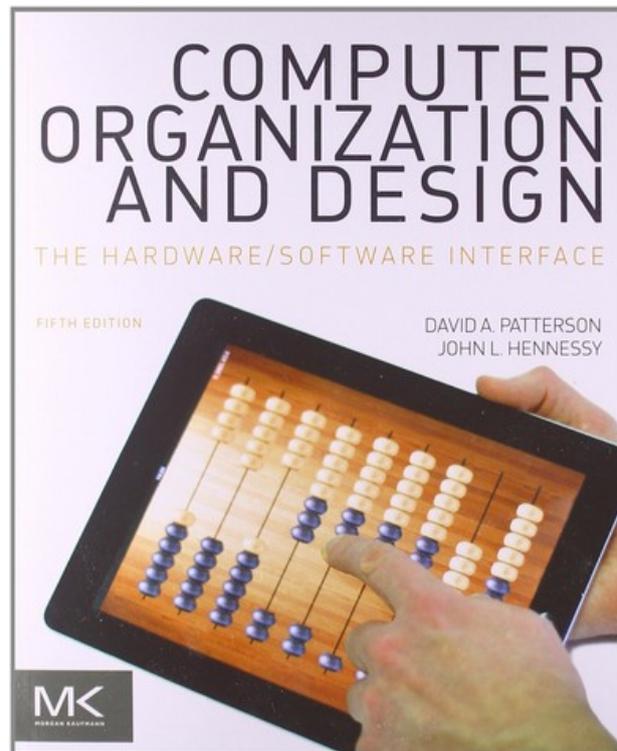
- Rappresentazione binaria dell'informazione
- Il processore
  - Clock
  - Registri
  - Datapath
  - Pipeline
- La memoria
  - Spazio indirizzabile di un processo
  - Gerarchia di memoria, cache

# Per approfondire

## **Computer Organization and Design** The Hardware/Software Interface

*D. Patterson, J. Hennessy*

5th Edition, Elsevier, 2013



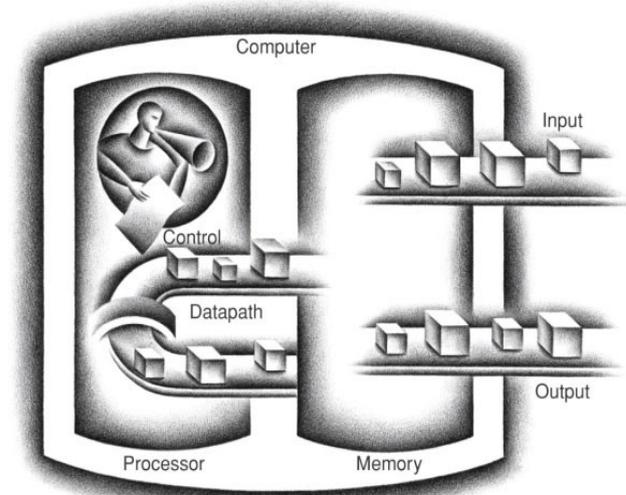
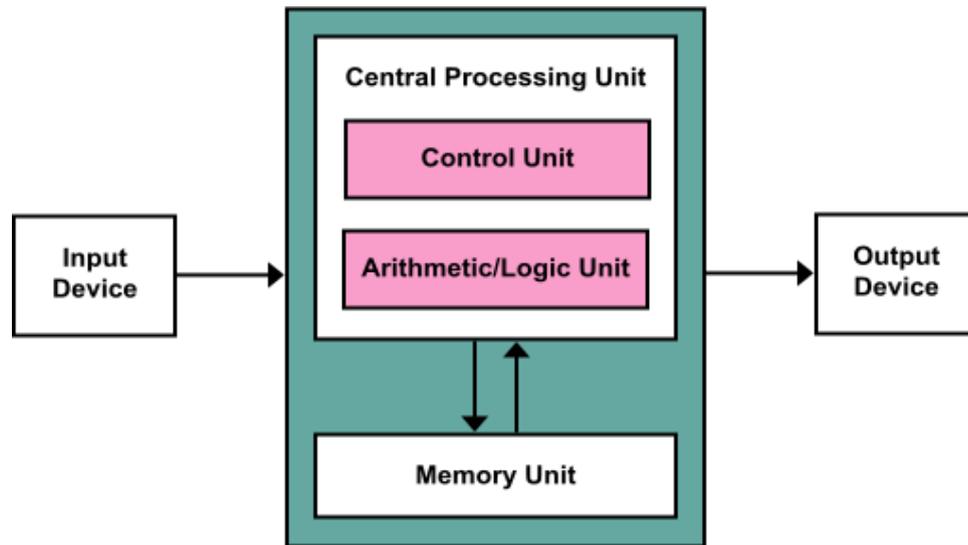
## **Struttura e Progetto dei Calcolatori**

4ª edizione italiana, condotta sulla 5ª  
edizione americana

Zanichelli, 2015



# Architettura di von Neumann



- Concetto di *stored program*
  - le istruzioni di un programma sono mantenute in memoria, così come i dati

# Rappresentazione binaria

- In un sistema di calcolo digitale qualsiasi informazione viene mantenuta e manipolata in forma binaria
  - la rappresentazione consiste in una sequenza di 0 e 1
  - ogni elemento della sequenza viene chiamato bit
- Alcune sequenze hanno nomi specifici
  - un byte è una sequenza di 8 bit
  - una parola (word) indica una sequenza di alcuni byte, ad es. 4 byte (32 bit)

# Operazioni logiche

- Su una sequenza di bit sono definite alcune operazioni logiche di base

- shift left

00111010 << 3 =  
11010000

- shift right

00111010 >> 3 =  
00000111

- bit-by-bit AND

0011 1000 &  
0101 0101 =  
0001 0000

- bit-by-bit OR

0011 1000 |  
0101 0101 =  
0111 1101

- bit-by-bit NOT

~0011 1000 =  
1100 0111

# Sistema numerico posizionale

- Un sistema di numerazione si dice posizionale se i simboli (cifre) usati per scrivere i numeri assumono valori diversi a seconda della posizione che occupano nella notazione

3564 = 3 migliaia, 5 centinaia, 6 decine, 4 unità

$$3564 = 3 \cdot 1000 + 5 \cdot 100 + 6 \cdot 10 + 4 \cdot 1 =$$

$$= 3 \cdot 10^3 + 5 \cdot 10^2 + 6 \cdot 10^1 + 4 \cdot 10^0$$

- Nell'esempio il sistema è anche decimale
  - nella notazione si usano dieci cifre, da 0 a 9
  - potenze di dieci
  - la base dieci non è speciale, ci è semplicemente più familiare
    - ovvero, le tabelline le conosciamo in base dieci

# Sistema numerico posizionale

- In generale (per numeri interi):

$$- (c_n c_{n-1} \dots c_1 c_0)_P = c_n \cdot P^n + c_{n-1} \cdot P^{n-1} + \dots + c_1 \cdot P^1 + c_0 \cdot P^0$$

- Esempi

$$- (456)_{\text{otto}} = (4 \cdot 8^2 + 5 \cdot 8^1 + 6 \cdot 8^0)_{\text{dieci}} = (302)_{\text{dieci}}$$

$$\begin{aligned} - (302)_{\text{dieci}} &= (3 \cdot 12^2 + 0 \cdot 12^1 + 2 \cdot 12^0)_{\text{otto}} \\ &= (3 \cdot 144 + 2)_{\text{otto}} = (454 + 2)_{\text{otto}} = (456)_{\text{otto}} \end{aligned}$$

$$- (1011)_{\text{due}} = (1 \cdot 2^3 + 0 \cdot 2^2 + 1 \cdot 2^1 + 1 \cdot 2^0)_{\text{dieci}} = (11)_{\text{dieci}}$$

$$- (1011)_{\text{cinque}} = (1 \cdot 5^3 + 0 \cdot 5^2 + 1 \cdot 5^1 + 1 \cdot 5^0)_{\text{dieci}} = (131)_{\text{dieci}}$$

$$- (\text{FA9})_{\text{sedici}} = (15 \cdot 16^2 + 10 \cdot 16^1 + 9 \cdot 16^0)_{\text{dieci}} = (4009)_{\text{dieci}}$$

$$A \rightarrow (10)_{\text{dieci}}$$

$$B \rightarrow (11)_{\text{dieci}}$$

$$C \rightarrow (12)_{\text{dieci}}$$

$$D \rightarrow (13)_{\text{dieci}}$$

$$E \rightarrow (14)_{\text{dieci}}$$

$$F \rightarrow (15)_{\text{dieci}}$$

# Da base P a base B

- $(c)_P = (c_n c_{n-1} \dots c_1 c_0)_P = (b_m b_{m-1} \dots b_1 b_0)_B$   
 $= b_m \cdot B^m + b_{m-1} \cdot B^{m-1} + \dots + b_1 \cdot B + b_0$
- Se divido  $(c)_P$  per  $B$  e prendo il resto ottengo  $b_0$   
 $= B \cdot (b_m \cdot B^{m-1} + b_{m-1} \cdot B^{m-2} + \dots + b_1) + b_0$
- Se divido  $q_0$  per  $B$  e prendo il resto ottengo  $b_1$  e  $q_1$
- Continuo fino a quando il quoziente non è zero
- Esempi (con  $P = \text{dieci}$ )

$$\begin{array}{l}
 131 / 5 = 26 \text{ resto } 1 \uparrow \\
 26 / 5 = 5 \text{ resto } 1 \uparrow \\
 5 / 5 = 1 \text{ resto } 0 \\
 1 / 5 = 0 \text{ resto } 1 \uparrow
 \end{array}$$

$$\begin{array}{l}
 131 / 16 = 8 \text{ resto } 3 \uparrow \\
 8 / 16 = 0 \text{ resto } 8 \uparrow
 \end{array}$$

$$(131)_{\text{dieci}} = (1011)_{\text{cinque}} = (83)_{\text{sedici}}$$

# Numerazione binaria

- Base due, due simboli (cifre) disponibili: 0 e 1
- Esempi

$$\begin{array}{l} 11 / 2 = 5 \text{ resto } 1 \\ 5 / 2 = 2 \text{ resto } 1 \\ 2 / 2 = 1 \text{ resto } 0 \\ 1 / 2 = 0 \text{ resto } 1 \end{array}$$

$$\begin{array}{l} 32 / 2 = 16 \text{ resto } 0 \\ 16 / 2 = 8 \text{ resto } 0 \\ 8 / 2 = 4 \text{ resto } 0 \\ 4 / 2 = 2 \text{ resto } 0 \\ 2 / 2 = 1 \text{ resto } 0 \\ 1 / 2 = 0 \text{ resto } 1 \end{array}$$

$$(11)_{\text{dieci}} = (1011)_{\text{due}}$$

$$(32)_{\text{dieci}} = (2^5)_{\text{dieci}} = (100000)_{\text{due}}$$

- Spesso è comodo rappresentare i numeri in base  $2^p$ , con  $p$  tipicamente 3 (base 8) o 4 (base 16)
  - si raggruppano le cifre binarie in gruppi di  $p$

$$(111 \ 011)_{\text{due}} = (73)_{\text{otto}} = \mathbf{0}73 \quad (0110 \ 1111)_{\text{due}} = (6F)_{\text{sedici}} = \mathbf{0}x6F$$

# Rappresentazione dei numeri interi

- In un sistema di calcolo un numero ha una rappresentazione finita
- I numeri interi sono tipicamente rappresentati con un numero di cifre binarie (bit) che è una potenza di 2
  - in C/C++ corrispondono ai tipi `char`, `short`, `int`, ... con lunghezze che vanno tipicamente da 8 a 32 o 64 bit
  - con segno (`signed`) e senza segno (`unsigned`)
  - anche un puntatore `T*` si può entro certi limiti considerare come un intero, di lunghezza 32 o 64 bit

# Numeri senza segno

- Per i numeri naturali (interi **senza segno**) la rappresentazione tipica corrisponde a una sequenza di bit corrispondente alla notazione in base 2

$$0000 \ 0000 = 0$$

$$0000 \ 0001 = 1$$

$$0000 \ 0010 = 2$$

$$0000 \ 0011 = 3$$

...

$$1111 \ 1110 = 254$$

$$1111 \ 1111 = 255 = 2^8 - 1$$

Most Significant Bit (MSB)

Least Significant Bit (LSB)

- Con n bit si possono rappresentare  $2^n$  numeri, da 0 a  $2^n - 1$

# Numeri con segno

- Per i numeri interi **con segno** si sono inventate diverse rappresentazioni. Quella universalmente usata ora è **“complemento a 2”**

- complemento a potenza di 2
- il bit più significativo (MSB) rappresenta il segno
  - 0 positivo, 1 negativo
- gli altri bit rappresentano il modulo

secondo il seguente schema (per  $n = 4$ )

$$0111 = 7 = 2^3 - 1$$

$$0110 = 6$$

$$0101 = 5$$

$$0100 = 4$$

$$0011 = 3$$

$$0010 = 2$$

$$0001 = 1$$

$$0000 = 0$$

$$1111 = -1 = -8 + 7$$

$$1110 = -2 = -8 + 6$$

$$1101 = -3 = -8 + 5$$

$$1100 = -4 = -8 + 4$$

$$1011 = -5 = -8 + 3$$

$$1010 = -6 = -8 + 2$$

$$1001 = -7 = -8 + 1$$

$$1000 = -8 = -2^3 = -8 + 0$$

# Opposto di un numero in C2

- $x + \sim x + 1 = 0 \pmod{2^n} \rightarrow -x = \sim x + 1$
- $\sim x$  significa il valore negato (bit-by-bit NOT)
- per calcolare l'opposto di un numero in C2, si nega la sequenza di bit corrispondente al numero e si aggiunge 1

$$0011 (+3) + 1100 + 1 = \cancel{1}0000 \rightarrow 1101 (-3) = 1100 + 1$$

$$1101 (-3) + 0010 + 1 = \cancel{1}0000 \rightarrow 0011 (+3) = 0010 + 1$$

# Range dei numeri con segno

- Con  $n$  bit si possono rappresentare  $2^n$  numeri interi, da  $-2^{n-1}$  a  $2^{n-1}-1$ 
  - $n = 8 \rightarrow [-2^7, 2^7-1] = [-128, 127]$
  - $n = 16 \rightarrow [-2^{15}, 2^{15}-1] = [-32768, 32767]$
  - $n = 32 \rightarrow [-2^{31}, 2^{31}-1] = [-2147483648, 2147483647]$
- Attenzione ad eseguire operazioni che coinvolgano contemporaneamente numeri con segno e numeri senza segno

```
int i = -1;
unsigned u = 0;
std::cout << std::boolalpha << (i < u) << '\n'; // false
std::cout << i + u << '\n'; // 4294967295 (0xFFFFFFFF)
```

# Estensione del segno in C2

- Un numero in C2 a  $n$  bit si può trasformare in un numero in C2 a  $m$  bit (con  $m > n$ ) estendendo il bit del segno negli  $m - n$  bit più significativi

0011 (+3 a 4 bit) → 0000 0011 (+3 a 8 bit)

1101 (-3 a 4 bit) → 1111 1101 (-3 a 8 bit)

# Rappresentazione di caratteri

- Oltre ai numeri è necessario rappresentare anche caratteri
- Esistono molte codifiche, tra cui la più diffusa è l'ASCII
  - 127 caratteri
  - ogni carattere è codificato con 7 bit  
→ sta in 8 bit (byte)

(sono mostrati solo i caratteri stampabili)

```
      2 3 4 5 6 7
      -----
0:    0 @ P ` p
1:    ! 1 A Q a q
2:    " 2 B R b r
3:    # 3 C S c s
4:    $ 4 D T d t
5:    % 5 E U e u
6:    & 6 F V f v
7:    ' 7 G W g w
8:    ( 8 H X h x
9:    ) 9 I Y i y
A:    * : J Z j z
B:    + ; K [ k {
C:    , < L \ l |
D:    - = M ] m }
E:    . > N ^ n ~
F:    / ? 0 _ o DEL
```

# Floating point

- Rappresentazione di numeri non interi
- Consideriamo solo la parte “decimale”
  - sappiamo già gestire la parte intera

$$\dots \cdot C_{-1} C_{-2} \dots C_{-n} \dots = \dots + C_{-1} \cdot B^{-1} + C_{-2} \cdot B^{-2} + \dots + C_{-n} \cdot B^{-n} + \dots$$

# Conversione di base

- Esempi

$$(0.456)_{\text{otto}} = (4 \cdot 8^{-1} + 5 \cdot 8^{-2} + 6 \cdot 8^{-3})_{\text{dieci}} = (0.58984375)_{\text{dieci}}$$

$$(0.456)_{\text{otto}} = (4 \cdot 8^{-1} + 5 \cdot 8^{-2} + 6 \cdot 8^{-3})_{\text{sedici}} = (0.97)_{\text{sedici}}$$

$$(0.1101)_{\text{due}} = (1 \cdot 2^{-1} + 1 \cdot 2^{-2} + 1 \cdot 2^{-4})_{\text{dieci}} = (0.8125)_{\text{dieci}}$$

$$(0.8125)_{\text{dieci}} = (8 \cdot A^{-1} + 1 \cdot A^{-2} + 2 \cdot A^{-3} + 5 \cdot A^{-4})_{\text{sedici}} = (0.D)_{\text{sedici}}$$

$$(0.75)_{\text{dieci}} = (111 \cdot 1010^{-1} + 101 \cdot 1010^{-2})_{\text{due}} = (0.11)_{\text{due}}$$

# Conversione di base

- $.f = (0.b_{-1}...b_{-m}...)_{\text{B}}$   
 $= b_{-1} \cdot B^{-1} + b_{-2} \cdot B^{-2} + b_{-3} \cdot B^{-3} + \dots$
- Se moltiplico  $.f$  per  $B$  e prendo la parte intera ottengo  $b_{-1}$   
 $.f \cdot B = b_{-1} + b_{-2} \cdot B^{-1} + b_{-3} \cdot B^{-2} + \dots = (b_{-1}.b_{-2}b_{-3}...)_{\text{B}}$
- Se moltiplico per  $B$  la parte decimale di  $.f \cdot B$  e prendo la parte intera ottengo  $b_{-2}$  e così via
- In generale la procedura non termina e ci si ferma quando si raggiunge il numero di cifre voluto

# Conversione di base

- Esempi

$$\begin{array}{l} 0.8125 \cdot 2 = 1.625 \rightarrow 1 \\ 0.625 \cdot 2 = 1.25 \rightarrow 1 \\ 0.25 \cdot 2 = 0.5 \rightarrow 0 \\ 0.5 \cdot 2 = 1 \rightarrow 1 \end{array} \quad \downarrow \quad \begin{array}{l} 0.8125 \cdot 16 = 13 \rightarrow D \end{array}$$

$$(0.8125)_{10} = (0.1101)_2 = (0.D)_{16}$$

$$\begin{array}{l} 0.2 \cdot 2 = 0.4 \rightarrow 0 \\ 0.4 \cdot 2 = 0.8 \rightarrow 0 \\ 0.8 \cdot 2 = 1.6 \rightarrow 1 \\ 0.6 \cdot 2 = 1.2 \rightarrow 1 \\ 0.2 \cdot 2 = 0.4 \dots \end{array} \quad \downarrow \quad \begin{array}{l} 0.2 \cdot 5 = 1 \rightarrow 1 \end{array}$$

$$(0.2)_{10} = (0.\overline{0011})_2 = (0.1)_5$$

# Rappresentazione floating point

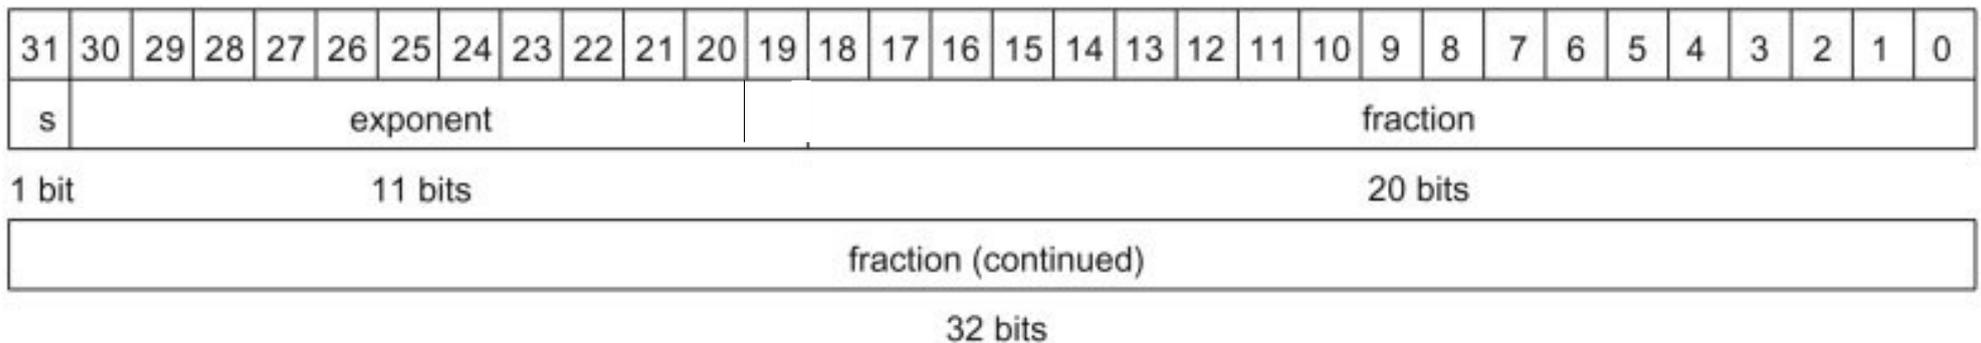
- Necessariamente un'approssimazione dei numeri reali
  - tipi `float` e `double` in C/C++
- Notazione scientifica
  - $-4.8744 \cdot 10^{-9}$
  - $-1343.8383 \cdot 10^5$
  - $+0.0002$
- Notazione scientifica normalizzata
  - $\pm d.dddd \cdot 10^e$  (decimale)
  - $\pm 1.bbbb \cdot 2^e$  (binaria)
- Definita nello standard IEEE 754
  - singola (32 bit) e doppia (64 bit) precisione

# Rappresentazione floating point

## 32 bit



## 64 bit



# Rappresentazione floating point



$$v = (-1)^s \cdot (1 + \text{fraction}) \cdot 2^{(\text{exponent} - \text{bias})}$$

- $s$  è il sign bit (1 → numero negativo, 0 → non negativo)
- Il bit prima della virgola è implicito a 1
  - $1 + \text{fraction} = \text{significand}$
  - $1.0 \leq |\text{significand}| < 2.0$
- L'esponente è in notazione *biased*: valore + bias
  - $00\dots00$  è il valore più piccolo, *bias* rappresenta lo 0,  $11\dots11$  è il valore più grande
  - SP: bias = 127 (0111 1111); DP: bias = 1023 (011 1111 1111)
- La rappresentazione consente di confrontare i floating point come se fossero interi in complemento a 2

# Floating point: esempio

- Rappresentare il numero  $(-0.75)_{10} = (-0.11)_2$   
 $(-0.11)_2 = (-1)^1 \cdot 1.1 \cdot 2^{-1}$
- $S = 1$
- Fraction = 10000...0000
- Exponent =  $-1 + \text{bias}$ 
  - SP:  $-1 + 127 = 126 = (01111110)_2$
  - DP:  $-1 + 1023 = 1022 = (011111111110)_2$
- SP: 1 01111110 100000...000000000000
- DP: 1 011111111110 100000...000000000000

# Floating point: esempio

- Che numero è rappresentato dal SP float?

1 10000001 01000...00

- $S = 1$
- Fraction = 01000...00
- Exponent = 10000001 =  $(129)_{10}$

$$\begin{aligned}v &= (-1)^s \cdot (1 + \text{fraction}) \cdot 2^{(\text{exponent} - \text{bias})} \\&= (-1)^1 \cdot (1 + 0.01)_2 \cdot 2^{(129 - 127)} \\&= -1.25 \cdot 2^2 \\&= -5 \text{ (come FP)}\end{aligned}$$

# Riepilogo codifica floating point

Single precision		Double precision		Object represented
Exponent	Fraction	Exponent	Fraction	
0	0	0	0	0
0	Nonzero	0	Nonzero	$\pm$ denormalized number
1–254	Anything	1–2046	Anything	$\pm$ floating-point number
255	0	2047	0	$\pm$ infinity
255	Nonzero	2047	Nonzero	NaN (Not a Number)

# Intervallo singola precisione

- Esponenti 00000000 e 11111111 sono riservati
- Valore più piccolo (in valore assoluto)
  - Esponente: 00000001  
→ esponente reale =  $1 - 127 = -126$
  - Frazione: 000...00 → significand = 1.0
  - $\pm 1.0 \cdot 2^{-126} \approx \pm 1.2 \cdot 10^{-38}$  ( $38 \approx 126 \cdot \log_{10}(2) \approx 126 \cdot 0.3$ )
  - Sotto è underflow (denormal a parte)
- Valore più grande
  - Esponente: 11111110  
→ esponente reale =  $254 - 127 = +127$
  - Frazione: 111...11 → significand  $\approx 2.0$
  - $\pm 2.0 \cdot 2^{+127} \approx \pm 3.4 \cdot 10^{+38}$
  - Sopra è overflow

# Intervallo doppia precisione

- Esponenti 000000000000 e 111111111111 sono riservati
- Valore più piccolo
  - Esponente: 000000000001
    - esponente reale =  $1 - 1023 = -1022$
  - Frazione: 000...00 → significand = 1.0
  - $\pm 1.0 \cdot 2^{-1022} \approx \pm 2.2 \cdot 10^{-308}$
  - Sotto è underflow (denormal a parte)
- Valore più grande
  - Esponente: 111111111110
    - esponente reale =  $2046 - 1023 = +1023$
  - Frazione: 111...11 → significand  $\approx 2.0$
  - $\pm 2.0 \cdot 2^{+1023} \approx \pm 1.8 \cdot 10^{+308}$
  - Sopra è overflow

# Rappresentazione istruzioni

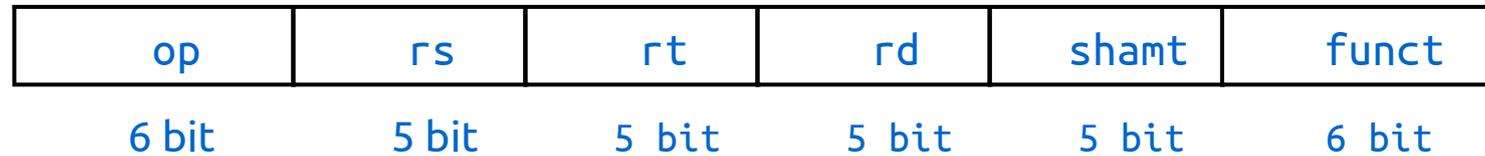
- Anche il programma sta in memoria e le istruzioni che lo compongono sono rappresentate in forma binaria

```
(gdb) x/4 0x02000000
0x2000000: 0xa0100000 0x29008004 0x81c52000 0x01000000
(gdb) disassemble 0x02000000 0x20000010
Dump of assembler code from 0x20000000 to 0x20000010:
0x20000000: mov %g0, %l0
0x20000004: sethi %hi(0x2001000), %l4
0x20000008: jmp %l4
0x2000000c: nop
(gdb) x/4 0x02009ab8
0x2009ab8: 0x00000001 0x00000000 0x40340000 0x00000000
(gdb) disass 0x02009ab8 0x02009ac8
Dump of assembler code from 0x2009ab8 to 0x2009ac8:
0x2009ab8: unimp 0x1
0x2009abc: unimp 0
0x2009ac0: call 0x2d09ac0
0x2009ac4: unimp 0
End of assembler dump.
(gdb) x 0x2d09ac0
0x2d09ac0: Cannot access memory at address 0x2d09ac0.
(gdb)
```

# Instruction Set Architecture

- Nel corso degli anni sono state definite molte architetture, molte delle quali ancora in uso
  - i386, x86\_64, SPARC, MIPS, ARM, VAX, Alpha, PowerPC, ...
- Un'ISA definisce l'interfaccia principale tra l'HW e il SW
  - istruzioni e loro significato
  - registri disponibili
  - convenzioni per la chiamata di funzioni
  - interrupt
  - layout in memoria
  - ...

# MIPS - Formato R



- Campi
  - op: codice dell'operazione (opcode) – sempre a 0 per R
  - rs: numero del primo registro sorgente
  - rt: numero del secondo registro sorgente
  - rd: numero del registro destinazione
  - shamt: numero di bit dello shift
  - funct: codice della funzione (estende l'opcode)

$R[rd] = R[rs] \text{ op/funct } R[rt]$

$R[rd] = R[rt] \ll \text{shamt}$

# Formato R - esempio

op	rs	rt	rd	shamt	funct
6 bit	5 bit	5 bit	5 bit	5 bit	6 bit

add \$t0, \$s0, \$s1

R-format	16	17	8	0	add
----------	----	----	---	---	-----

000000	10000	10001	01000	00000	100000
--------	-------	-------	-------	-------	--------

0000 0010 0001 0001 0100 0000 0010 0000 = 0x02114020

# Indicatori di performance

```
$ perf stat -d ./a.out
```

```
Performance counter stats for './a.out':
```

```
1992.419970 task-clock (msec)      #    0.999 CPUs utilized
      215 context-switches         #    0.108 K/sec
        5 cpu-migrations           #    0.003 K/sec
      368 page-faults              #    0.185 K/sec
4,139,391,573 cycles                #    2.078 GHz                    [44.54%]
2,207,522,429 stalled-cycles-frontend #  53.33% frontend cycles idle   [44.67%]
2,182,353,973 stalled-cycles-backend #  52.72% backend  cycles idle   [44.79%]
2,302,995,011 instructions         #    0.56  insns per cycle
                                     #    0.96  stalled cycles per insn [55.85%]
657,124,588 branches               # 329.812 M/sec                   [55.85%]
155,694,678 branch-misses          #   23.69% of all branches       [55.67%]
329,767,307 L1-dcache-loads        # 165.511 M/sec                   [55.45%]
 20,723,322 L1-dcache-load-misses  #    6.28% of all L1-dcache hits [55.25%]
   200,896 LLC-loads               #    0.101 M/sec                  [44.15%]
<not supported> LLC-load-misses:HG

1.994174760 seconds time elapsed
```

# Performance

- Come si definisce il concetto di “performance”?
  - Tempo di esecuzione di un programma
    - Wall-clock time
      - tiene conto anche di I/O e delle attese dovute alla condivisione delle risorse con altri programmi
    - **CPU time**
      - tiene conto solo del tempo in cui il programma usa la CPU
      - user time + system time
  - *throughput*
    - numero di task/transazioni eseguiti per unità di tempo
  - ...

$$\text{performance} = 1 / \text{CPU time}$$

# Cosa influenza il CPU time

- Algoritmo e qualità di implementazione
- Linguaggio di programmazione
- Compilatore
- Instruction Set Architecture
- Processore
- Memoria

# CPU time

$$\text{CPU time} = \# \text{istruzioni} \times \text{CPI} \times \text{Clock cycle}$$

- #istruzioni: numero di istruzioni nel programma
- CPI: numero medio di cicli di clock per istruzione
- Clock cycle: durata di un ciclo di clock
  
- Per ridurre il tempo di CPU si può intervenire su ognuno dei fattori
  - I fattori non sono indipendenti!

# Logic design

- L'elettronica all'interno dei calcolatori moderni è digitale
  - basata su due livelli validi di tensione elettrica
    - livelli intermedi sono transitori, bisogna attendere la stabilizzazione della tensione prima di leggere un valore valido
  - motivo per cui si usa la rappresentazione binaria per le entità da manipolare: numeri, lettere, istruzioni, ecc.
    - alto – basso
    - vero – falso
    - 1 – 0
- La manipolazione di tali valori binari (bit) è basata sull'algebra di Boole

# Algebra booleana

- Algebra definita su un insieme di due valori  $\{0, 1\}$ , con le seguenti operazioni:
  - “addizione” – OR  
 $A + B = 1$  se almeno uno tra A e B è uguale a 1
  - “moltiplicazione” – AND  
 $A \cdot B = 1$  solo se entrambi A e B sono uguali a 1
  - complemento – NOT  
 $\bar{A} = 1$  se  $A = 0$ ;  $\bar{A} = 0$  se  $A = 1$
- Corrispondenza con operazioni tra insiemi (unione, intersezione, complemento)

# Algebra booleana

- Proprietà dell'algebra booleana

- identità

$$A + 0 = A$$

$$A \cdot 1 = A$$

- 0 e 1 elementi assorbenti

$$A + 1 = 1$$

$$A \cdot 0 = 0$$

- inversione

$$A + \bar{A} = 1$$

$$A \cdot \bar{A} = 0$$

- commutativa

$$A + B = B + A$$

$$A \cdot B = B \cdot A$$

- associativa

$$(A + B) + C = A + (B + C)$$

$$(A \cdot B) \cdot C = A \cdot (B \cdot C)$$

- distributiva

$$A \cdot (B + C) = (A \cdot B) + (A \cdot C)$$

$$A + (B \cdot C) = (A + B) \cdot (A + C)$$

- De Morgan

$$\overline{A + B} = \bar{A} \cdot \bar{B}$$

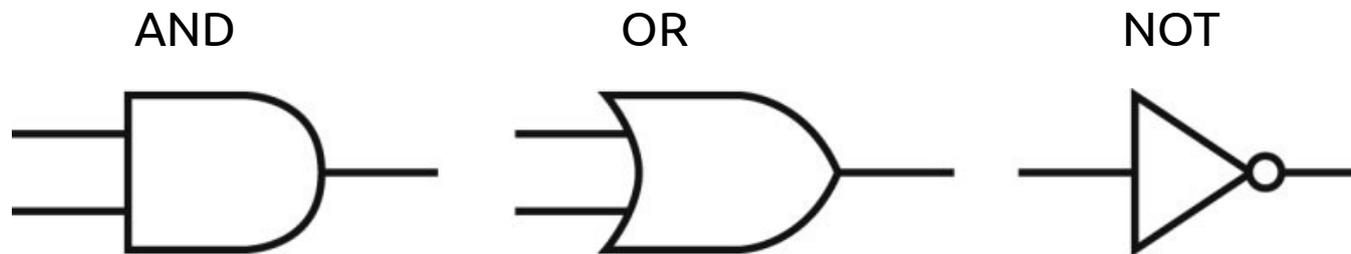
$$\overline{A \cdot B} = \bar{A} + \bar{B}$$

# Espressioni logiche

- Un'espressione che coinvolge variabili logiche e operatori logici
  - $D = A + B + C$
  - $E = ((A \cdot B) + (A \cdot C) + (B \cdot C)) \cdot (\overline{A \cdot B \cdot C})$
  - $F = A \cdot B \cdot C$
  - D, E e F sono funzioni logiche di A, B e C.

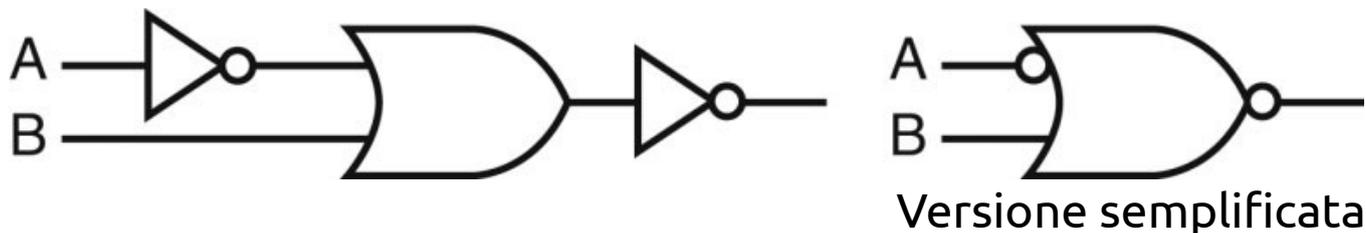
# Porte logiche

- Le operazioni fondamentali dell'algebra di Boole sono implementate con dei circuiti logici elementari (porte logiche), che sono astrazioni di dispositivi elettronici veri e propri basati tipicamente su transistor



- Una funzione logica si può esprimere con un blocco logico fatto di AND, OR e NOT

-  $\overline{A + B}$

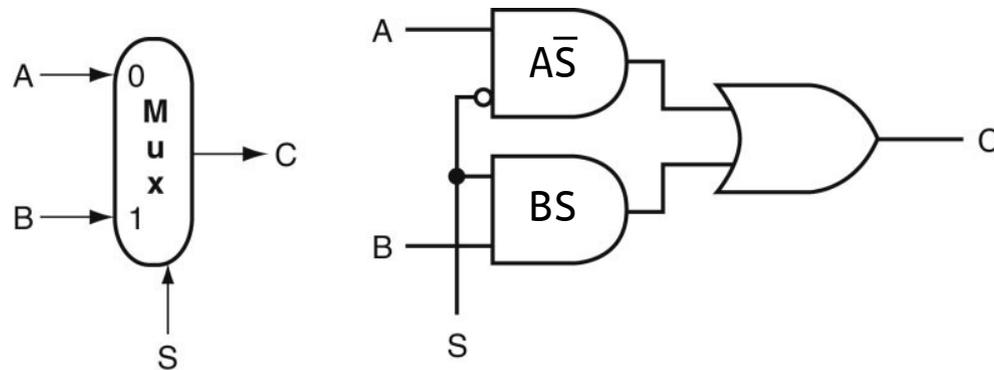


# Blocchi logici

- A partire dalle porte logiche elementari si possono costruire circuiti (blocchi) logici arbitrariamente complessi
- Due tipi di blocchi logici:
  - logica combinatoria: l'output del circuito dipende solo dall'input
  - logica sequenziale: l'output del circuito dipende dall'input e dallo stato
    - il blocco ha una memoria interna

# Multiplexor (o selector)

- Funzione logica di base che replica in output una delle variabili di input in base al valore di una o più variabili di controllo



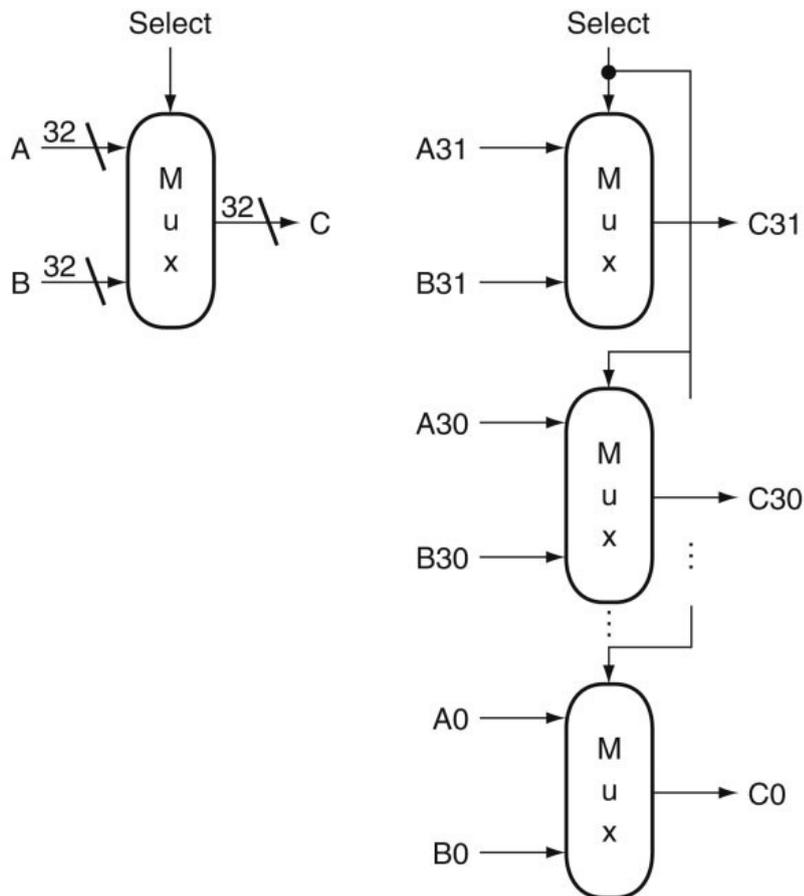
- $S = 0 \rightarrow C = A, S = 1 \rightarrow C = B$

$$C = A\bar{S} + BS$$

- N controlli possono selezionare uno di  $2^N$  input

# Array di blocchi logici

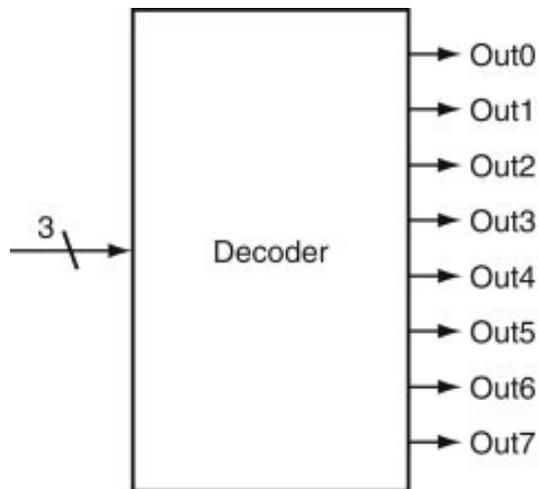
- In molti casi la stessa operazione logica deve essere applicata non a un singolo bit (per operando) ma, ad esempio, a un'intera parola di 32 bit



Esempio per un multiplexor, implementato come array di 32 multiplexor, uno per ogni coppia di bit, controllati tutti dallo stesso selettore

# Decoder

- Un circuito logico con  $n$  segnali di input e  $2^n$  segnali di output, dove solo un segnale è alto per ogni combinazione di input



a. A 3-bit decoder

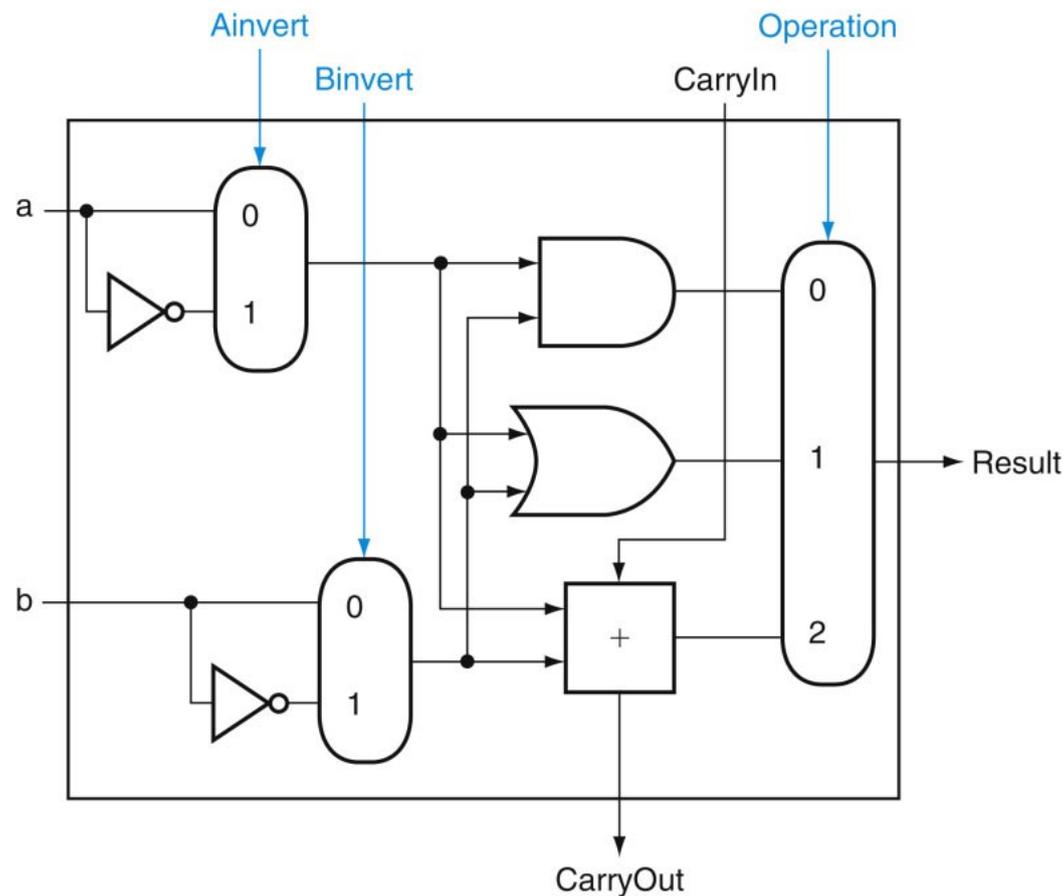
Inputs			Outputs							
12	11	10	Out7	Out6	Out5	Out4	Out3	Out2	Out1	Out0
0	0	0	0	0	0	0	0	0	0	1
0	0	1	0	0	0	0	0	0	1	0
0	1	0	0	0	0	0	0	1	0	0
0	1	1	0	0	0	0	1	0	0	0
1	0	0	0	0	0	1	0	0	0	0
1	0	1	0	0	1	0	0	0	0	0
1	1	0	0	1	0	0	0	0	0	0
1	1	1	1	0	0	0	0	0	0	0

b. The truth table for a 3-bit decoder

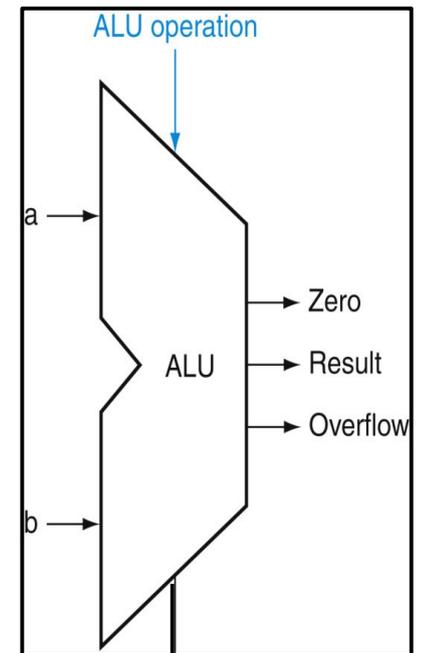
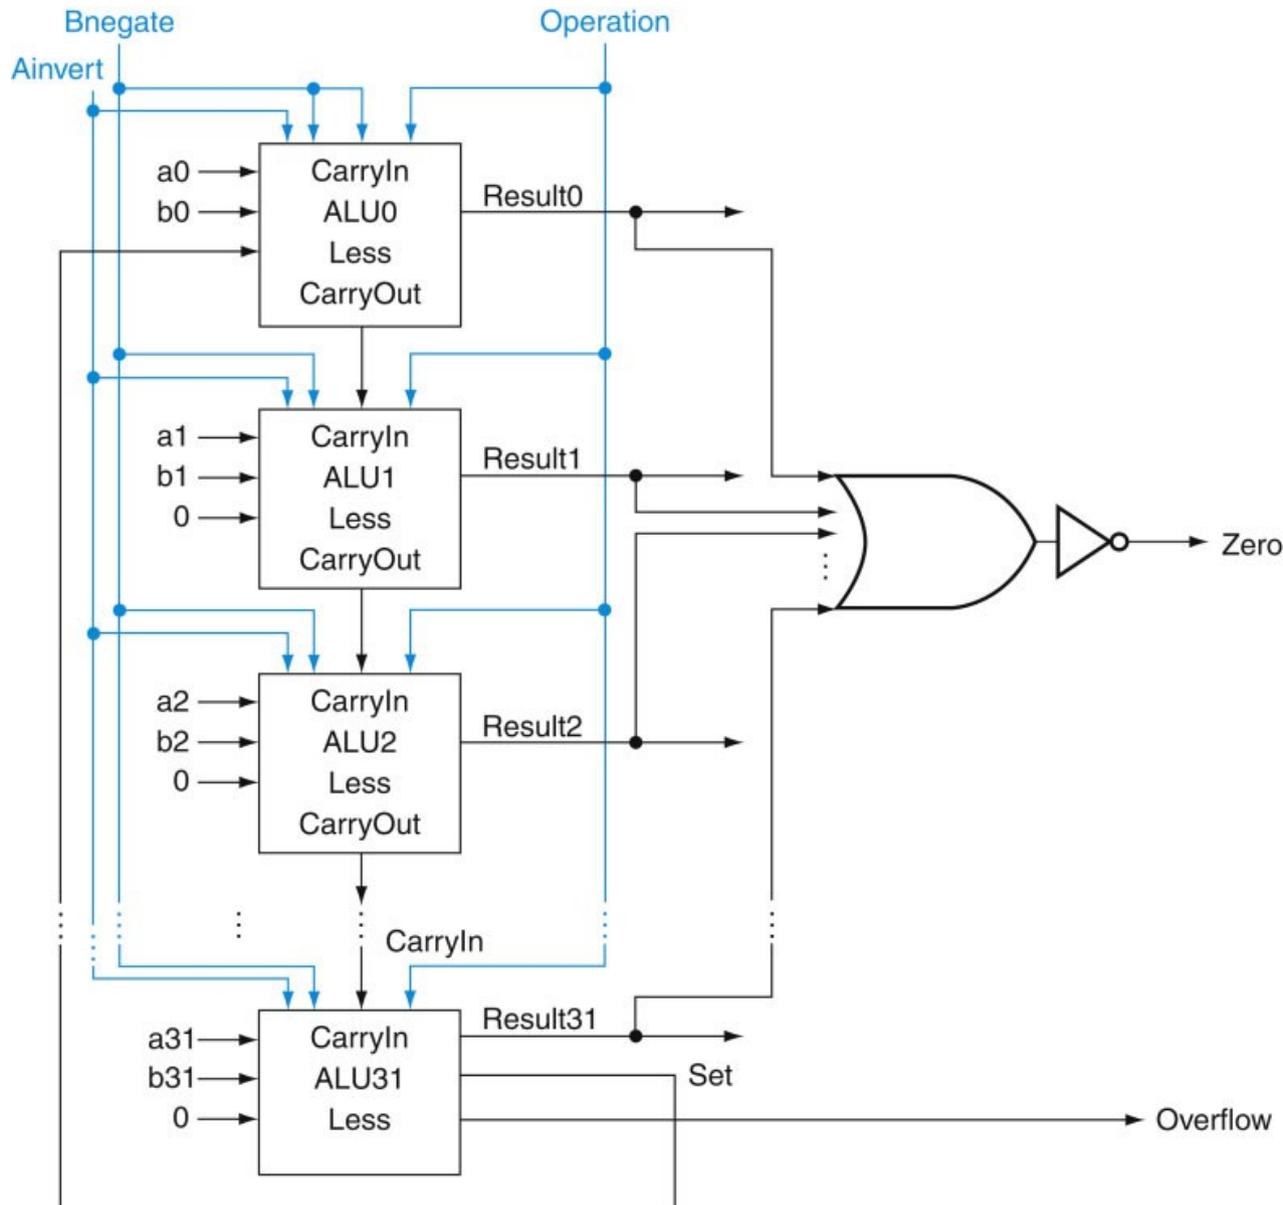
# 1-bit ALU

- Arithmetic Logic Unit

- dispositivo che all'interno di un processore compie le operazioni logiche (AND, OR) e aritmetiche (ADD, SUB, ...)

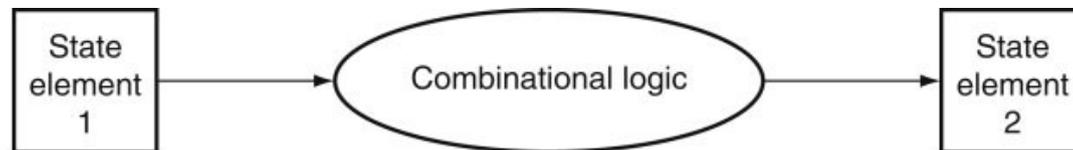


# 32-bit ALU



# Logica sequenziale

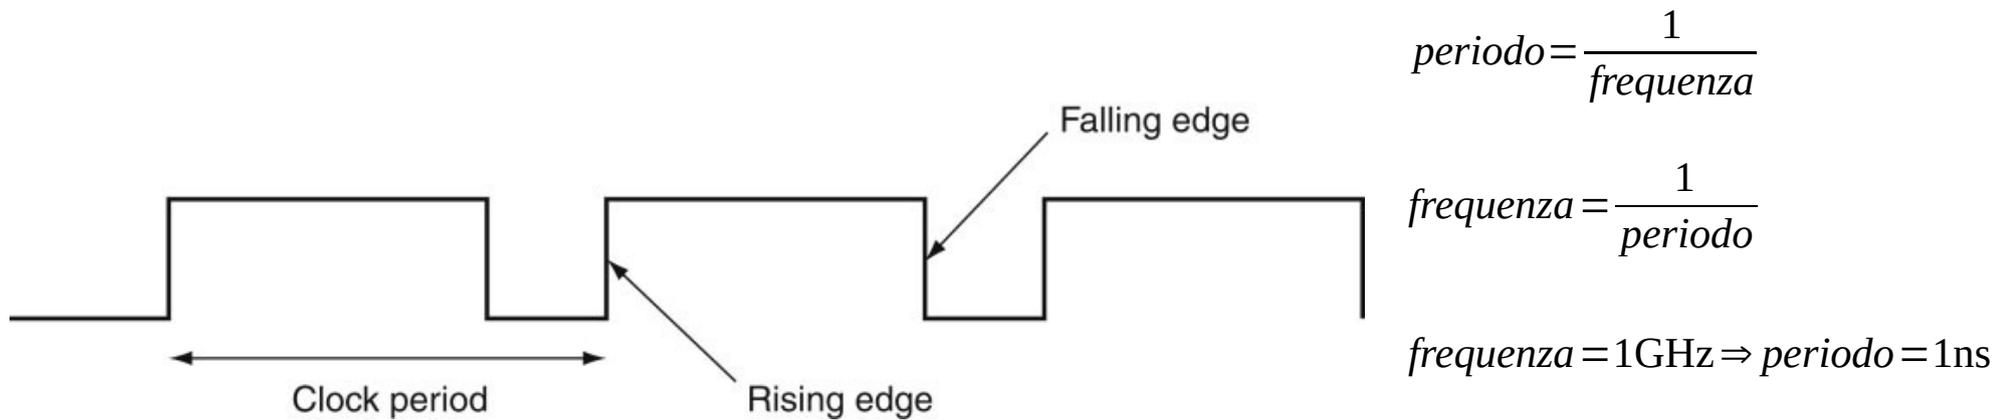
- L'output del circuito dipende dall'input **e dallo stato**
  - il blocco ha una memoria interna
- Vogliamo combinare logica combinatoria e sequenziale in questo modo:



- Come si implementa un circuito che ricorda un valore?
- Quando è ora di aggiornare l'elemento di stato?

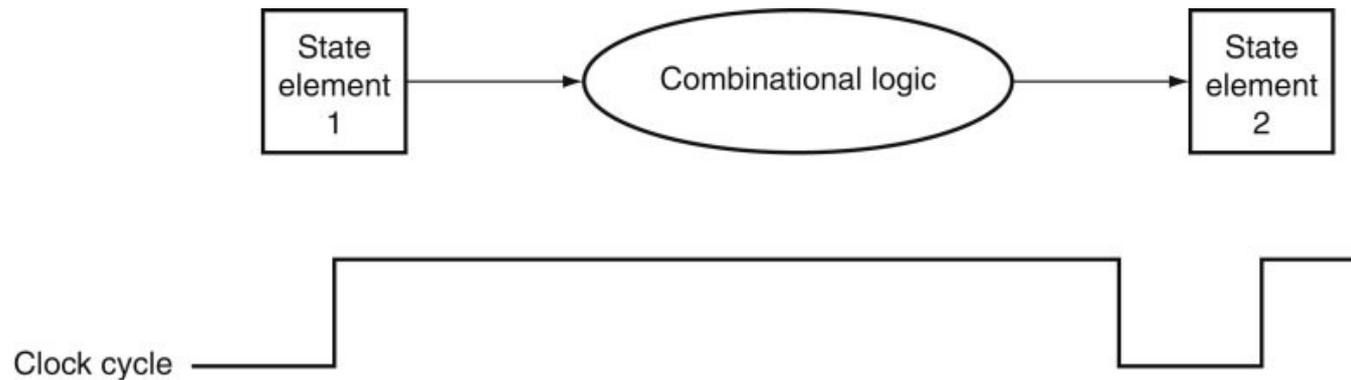
# Clock

- Segnale che oscilla periodicament tra due valori, uno alto e uno basso



- Il clock è usato come segnale di campionamento

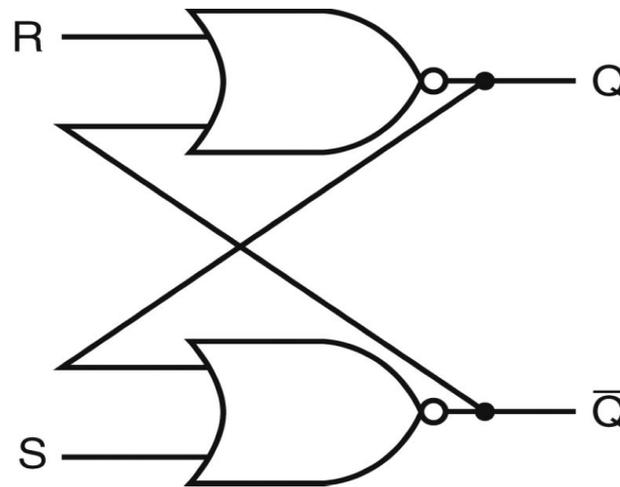
# Clock



- Il primo elemento di stato fornisce gli input al circuito logico combinatorio, il cui output è usato per modificare il secondo elemento di stato
- La durata di un ciclo di clock deve essere sufficientemente lungo affinché i segnali in input riescano a propagarsi all'interno del circuito logico (**ogni** circuito logico) e generare un segnale di output stabile

# S-R latch

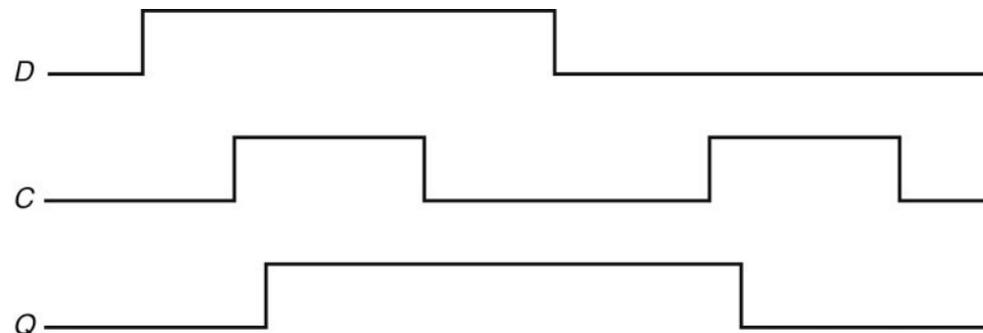
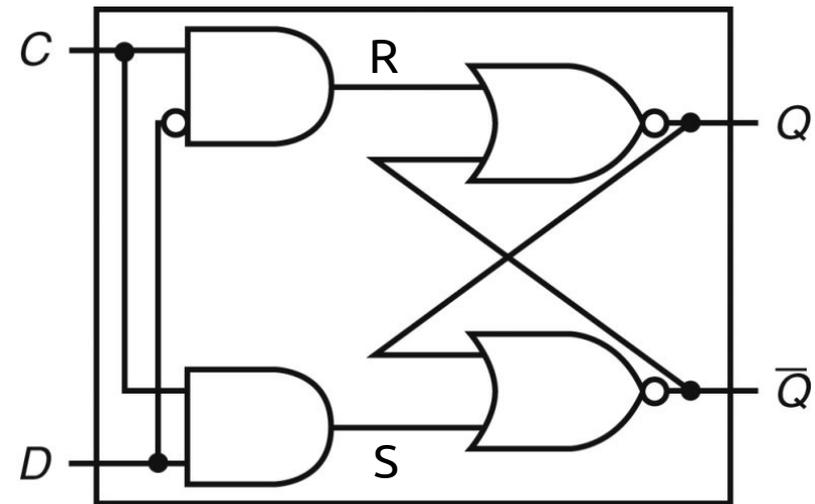
- Set-Reset latch
- E' la base per elementi di memoria più complessi
- Costituito da due NOR incrociati



- $S = 1, R = 0 \rightarrow Q = 1$
- $S = 0, R = 1 \rightarrow Q = 0$
- $S = 0, R = 0 \rightarrow Q$  mantiene il proprio valore

# D latch

- Clocked latch
  - C clock, D input, Q output
- $C = 0 \rightarrow S = R = 0$ 
  - Q mantiene il valore precedente
- $C = 1 \rightarrow S = D, R = \bar{D}$ 
  - $Q = D$
- Il latch è *trasparente*
  - se C è alto, Q assume “immediatamente” il valore di D

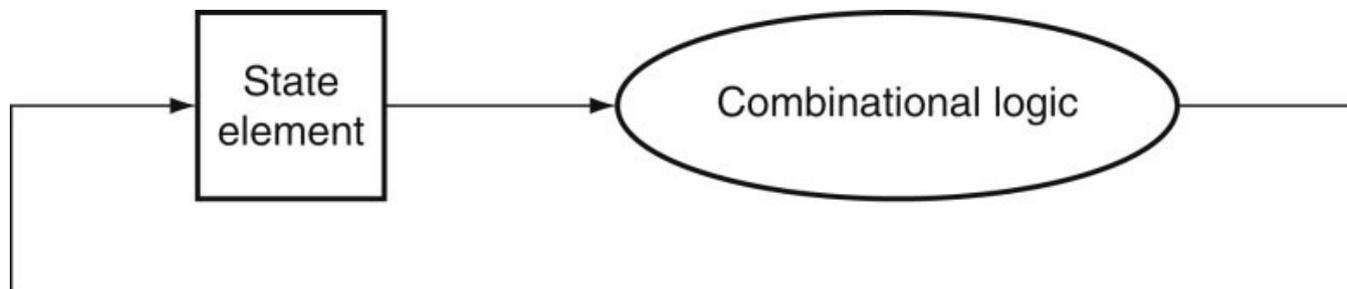


supponiamo Q inizialmente a 0

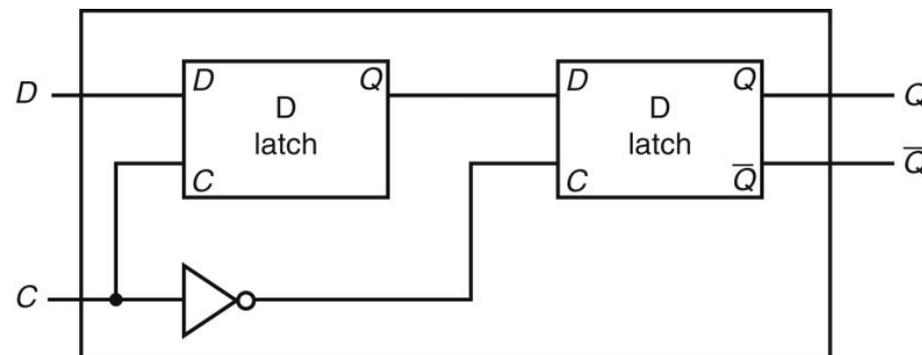
# D flip-flop

- Elemento di stato che può fornire sia i segnali di input sia essere usato per salvare i segnali di output di un circuito

add  $\$s0$ ,  $\$s0$ ,  $\$s1$

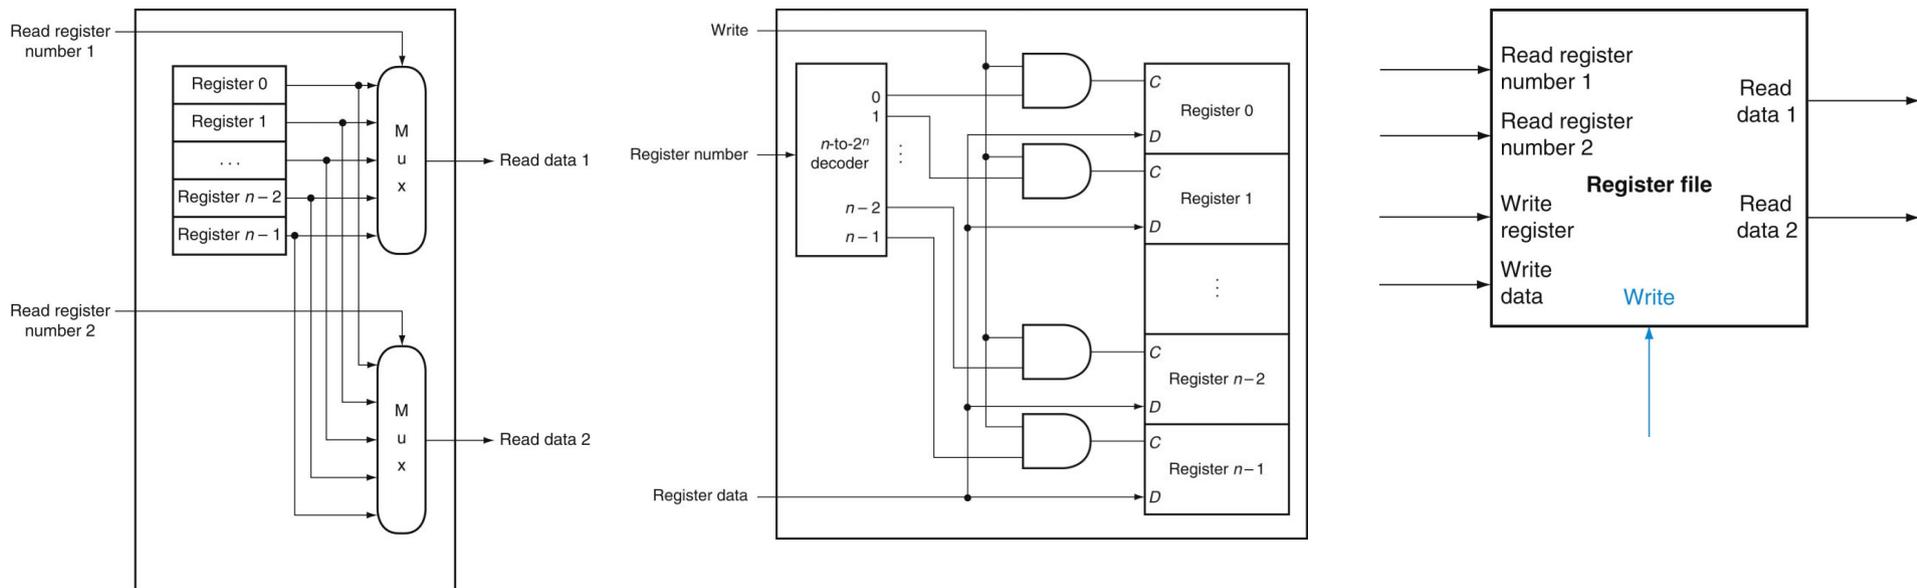


- Costituito a partire da due D latch



# Registri e file di registri

- Un flip-flop memorizza 1 bit
- Un array di 32 flip-flop memorizza una parola di 32 bit
  - registro
- Un insieme di registri costituisce un *register file*



# Altre memorie

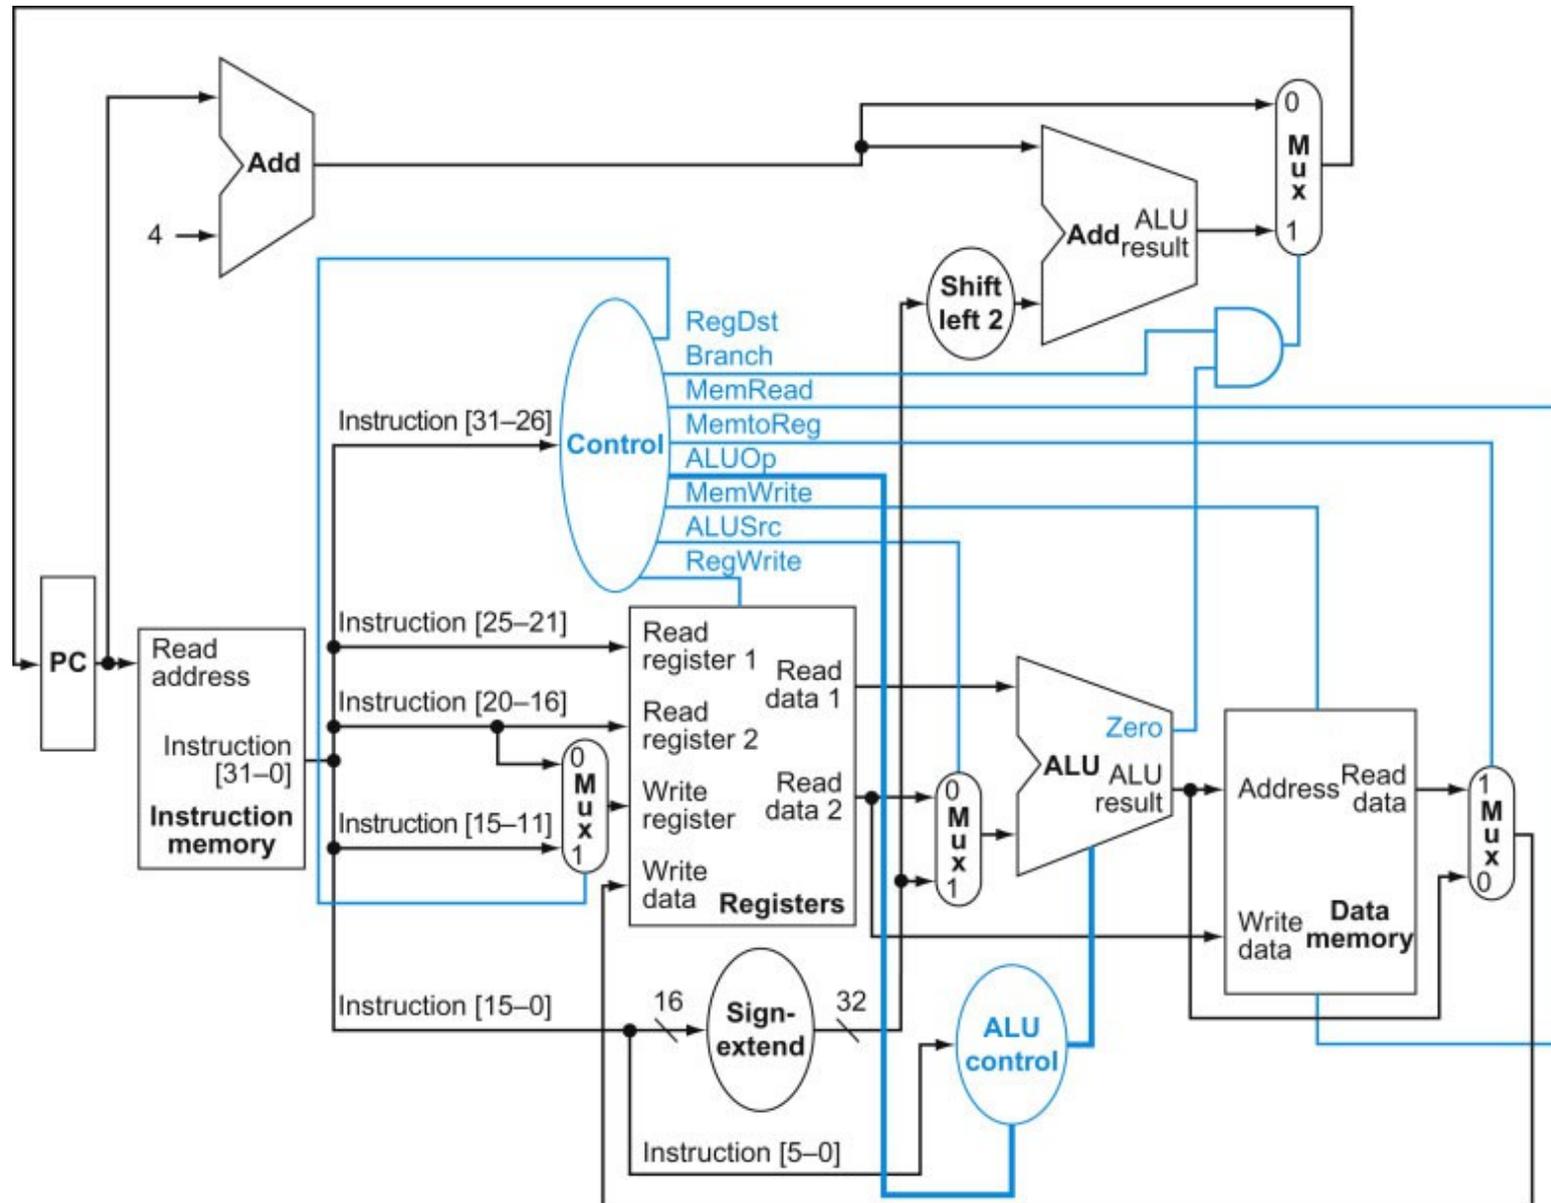
- Non è economicamente sostenibile avere memorie di dimensioni molto superiori a un register file implementate usando flip-flop
- Esistono tecnologie alternative che permettono di avere
  - + densità e capacità maggiori
  - + costi inferiori
  - prestazioni inferiori

Memory technology	Typical access time	\$ per GiB in 2012
SRAM semiconductor memory	0.5–2.5 ns	\$500–\$1000
DRAM semiconductor memory	50–70 ns	\$10–\$20
Flash semiconductor memory	5,000–50,000 ns	\$0.75–\$1.00
Magnetic disk	5,000,000–20,000,000 ns	\$0.05–\$0.10

# Come lavora un processore

- (Discussione semplificata basata su MIPS)
- Per ogni istruzione:
  - legge (*fetch*) dalla memoria l'istruzione il cui indirizzo è nel Program Counter
  - legge dei registri in base a quanto specificato nell'istruzione
- A seconda dell'istruzione:
  - usa la ALU per eseguire calcoli
  - accede alla memoria per load/store
  - aggiorna il Program Counter con l'indirizzo della prossima istruzione da eseguire

# Datapath



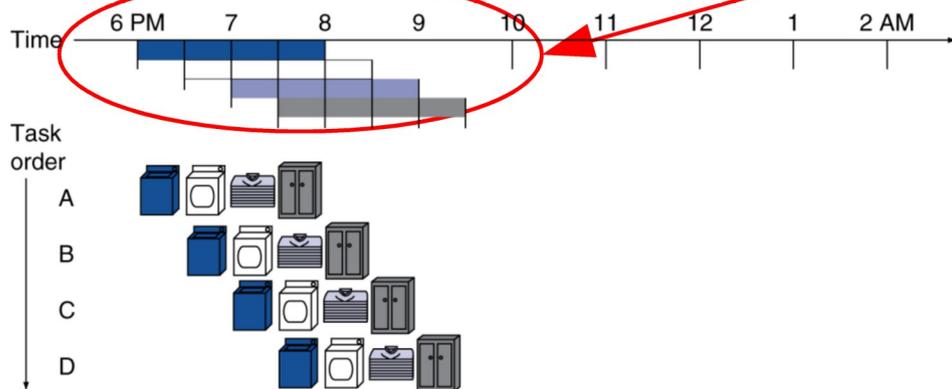
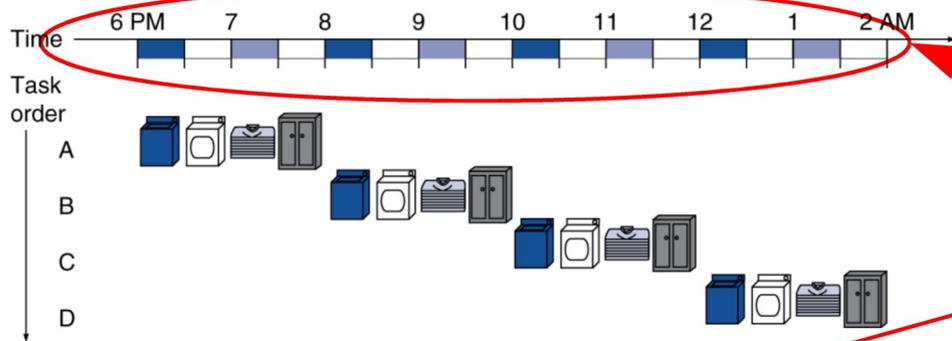


# Pipelining

- L'implementazione di un datapath basata su un singolo ciclo di clock è inefficiente
  - il ciclo di clock deve essere sufficiente ad eseguire l'intera istruzione più lenta
    - tipicamente accesso in memoria
  - $CPI = 1$ , ma ciclo di clock molto alto
  - può andare bene solo per instruction set molto semplici
- Il **pipelining** è una tecnica implementativa in cui le esecuzioni di più istruzioni sono sovrapposte nel tempo

# Esempio

- Basato su una lavanderia
  - lava, asciuga, piega, metti via
  - in un dato momento ogni carico usa una risorsa diversa



- Speed-up

- 4 carichi

$$8 / 3.5 = 2.3$$

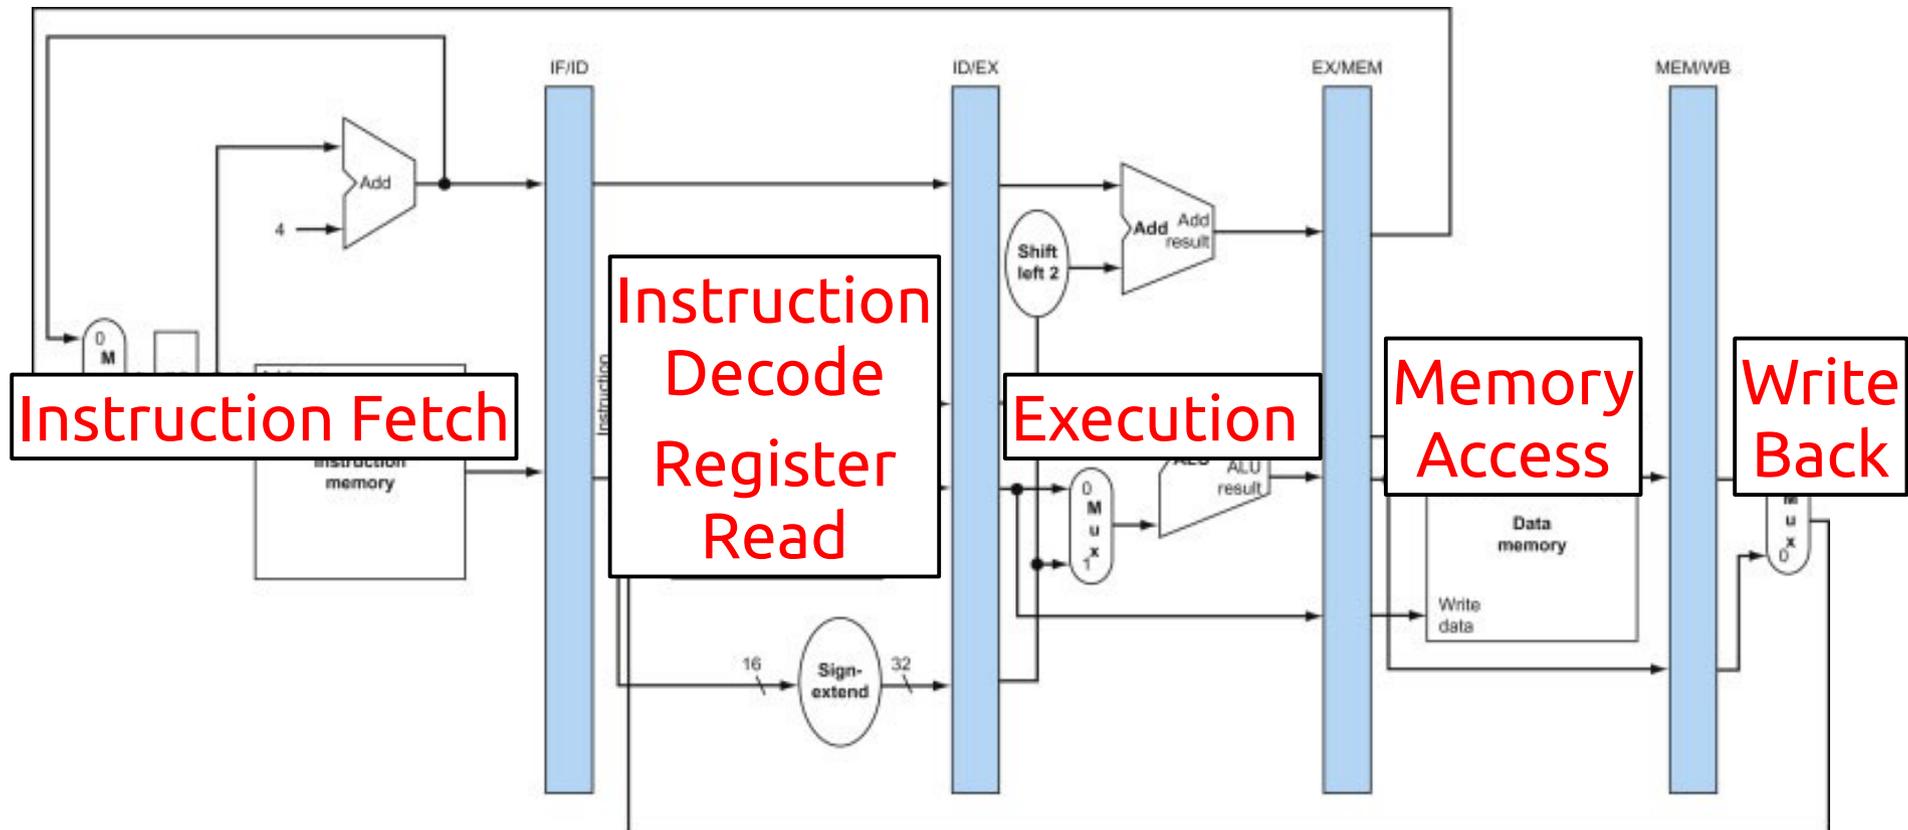
- N carichi

$$2N / (0,5N + 1,5) \rightarrow 4$$

= numero di passi (stadi)

- Aumenta il numero di carichi eseguiti per unità di tempo (throughput), non la durata di un singolo carico (latenza)

# Pipelined datapath



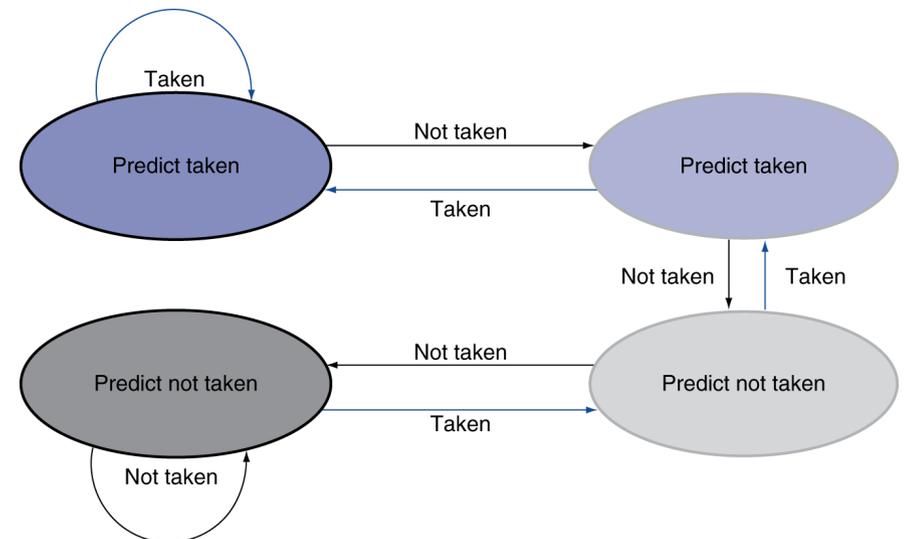
- Il ciclo di clock ora corrisponde allo stadio più lungo
- Se gli stadi non sono perfettamente bilanciati
  - lo speed-up massimo non è dato dal numero di stadi
  - la latenza della singola istruzione può aumentare

# Criticità

- Situazioni che impediscono la partenza dell'istruzione successiva nel ciclo successivo
- Criticità strutturali: una risorsa necessaria all'esecuzione di una istruzione è occupata
- Criticità sui dati: un'istruzione dipende da un valore non ancora disponibile
- Criticità sul controllo: una decisione di controllo dipende dal risultato di un'istruzione non ancora conclusa
- La soluzione generale in caso di criticità è **aspettare**
  - spreco di cicli di clock → stalli

# Branch prediction

- Per mitigare la perdita di tempo dovuta all'attesa del risultato di un branch si può provare a indovinare
- Dynamic branch prediction
  - L'hardware misura il comportamento recente effettivo
- Se la predizione è sbagliata
  - **branch miss**
  - i risultati parziali vanno scartati
  - si carica l'istruzione corretta
  - si aggiorna la storia



# Indicatori di performance

```
$ perf stat -d ./a.out
```

```
Performance counter stats for './a.out':
```

```
1992.419970 task-clock (msec)      #    0.999 CPUs utilized
      215 context-switches         #    0.108 K/sec
        5 cpu-migrations           #    0.003 K/sec
      368 page-faults              #    0.185 K/sec
4,139,391,573 cycles                #    2.078 GHz                    [44.54%]
2,207,522,429 stalled-cycles-frontend #  53.33% frontend cycles idle   [44.67%]
2,182,353,973 stalled-cycles-backend #  52.72% backend  cycles idle   [44.79%]
2,302,995,011 instructions         #    0.56  insns per cycle
                                     #    0.96  stalled cycles per insn [55.85%]
657,124,588 branches               # 329.812 M/sec                    [55.85%]
155,694,678 branch-misses          #   23.69% of all branches       [55.67%]
329,767,307 L1-dcache-loads        # 165.511 M/sec                    [55.45%]
 20,723,322 L1-dcache-load-misses  #    6.28% of all L1-dcache hits [55.25%]
   200,896 LLC-loads               #    0.101 M/sec                    [44.15%]
<not supported> LLC-load-misses:HG

1.994174760 seconds time elapsed
```

# Instruction-level parallelism (ILP)

- Per aumentare il grado di ILP
  - pipeline con più stadi (più profonde)
    - singoli stadi più semplici → **riduzione ciclo di clock**
  - multiple issue
    - più istruzioni sono iniziate contemporaneamente
    - replicare la pipeline o alcuni stadi della pipeline
    - processore “superscalare”
    - in questo modo si può ridurre il CPI a un valore  $< 1$ 
      - uso di **Instructions Per Cycle**  $IPC = 1 / CPI$
    - efficacia limitata dalle criticità
      - dipendenze e condivisione di risorse

# Indicatori di performance

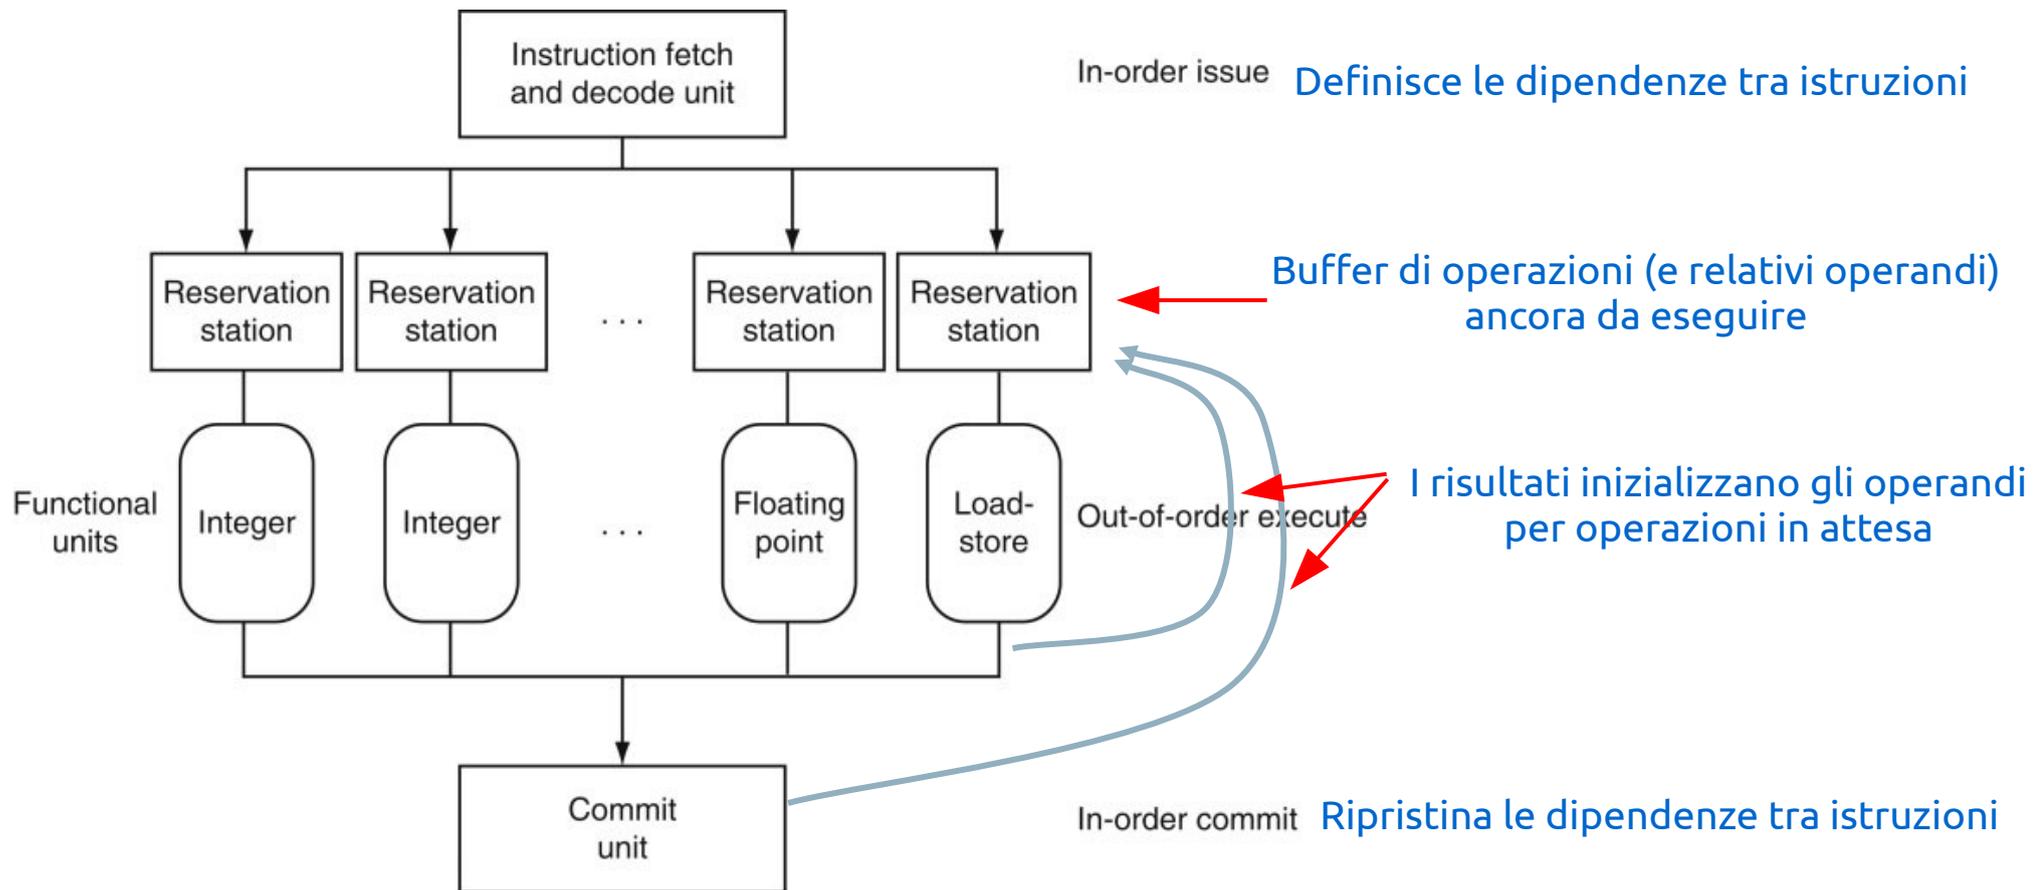
```
$ perf stat -d ./a.out
```

```
Performance counter stats for './a.out':
```

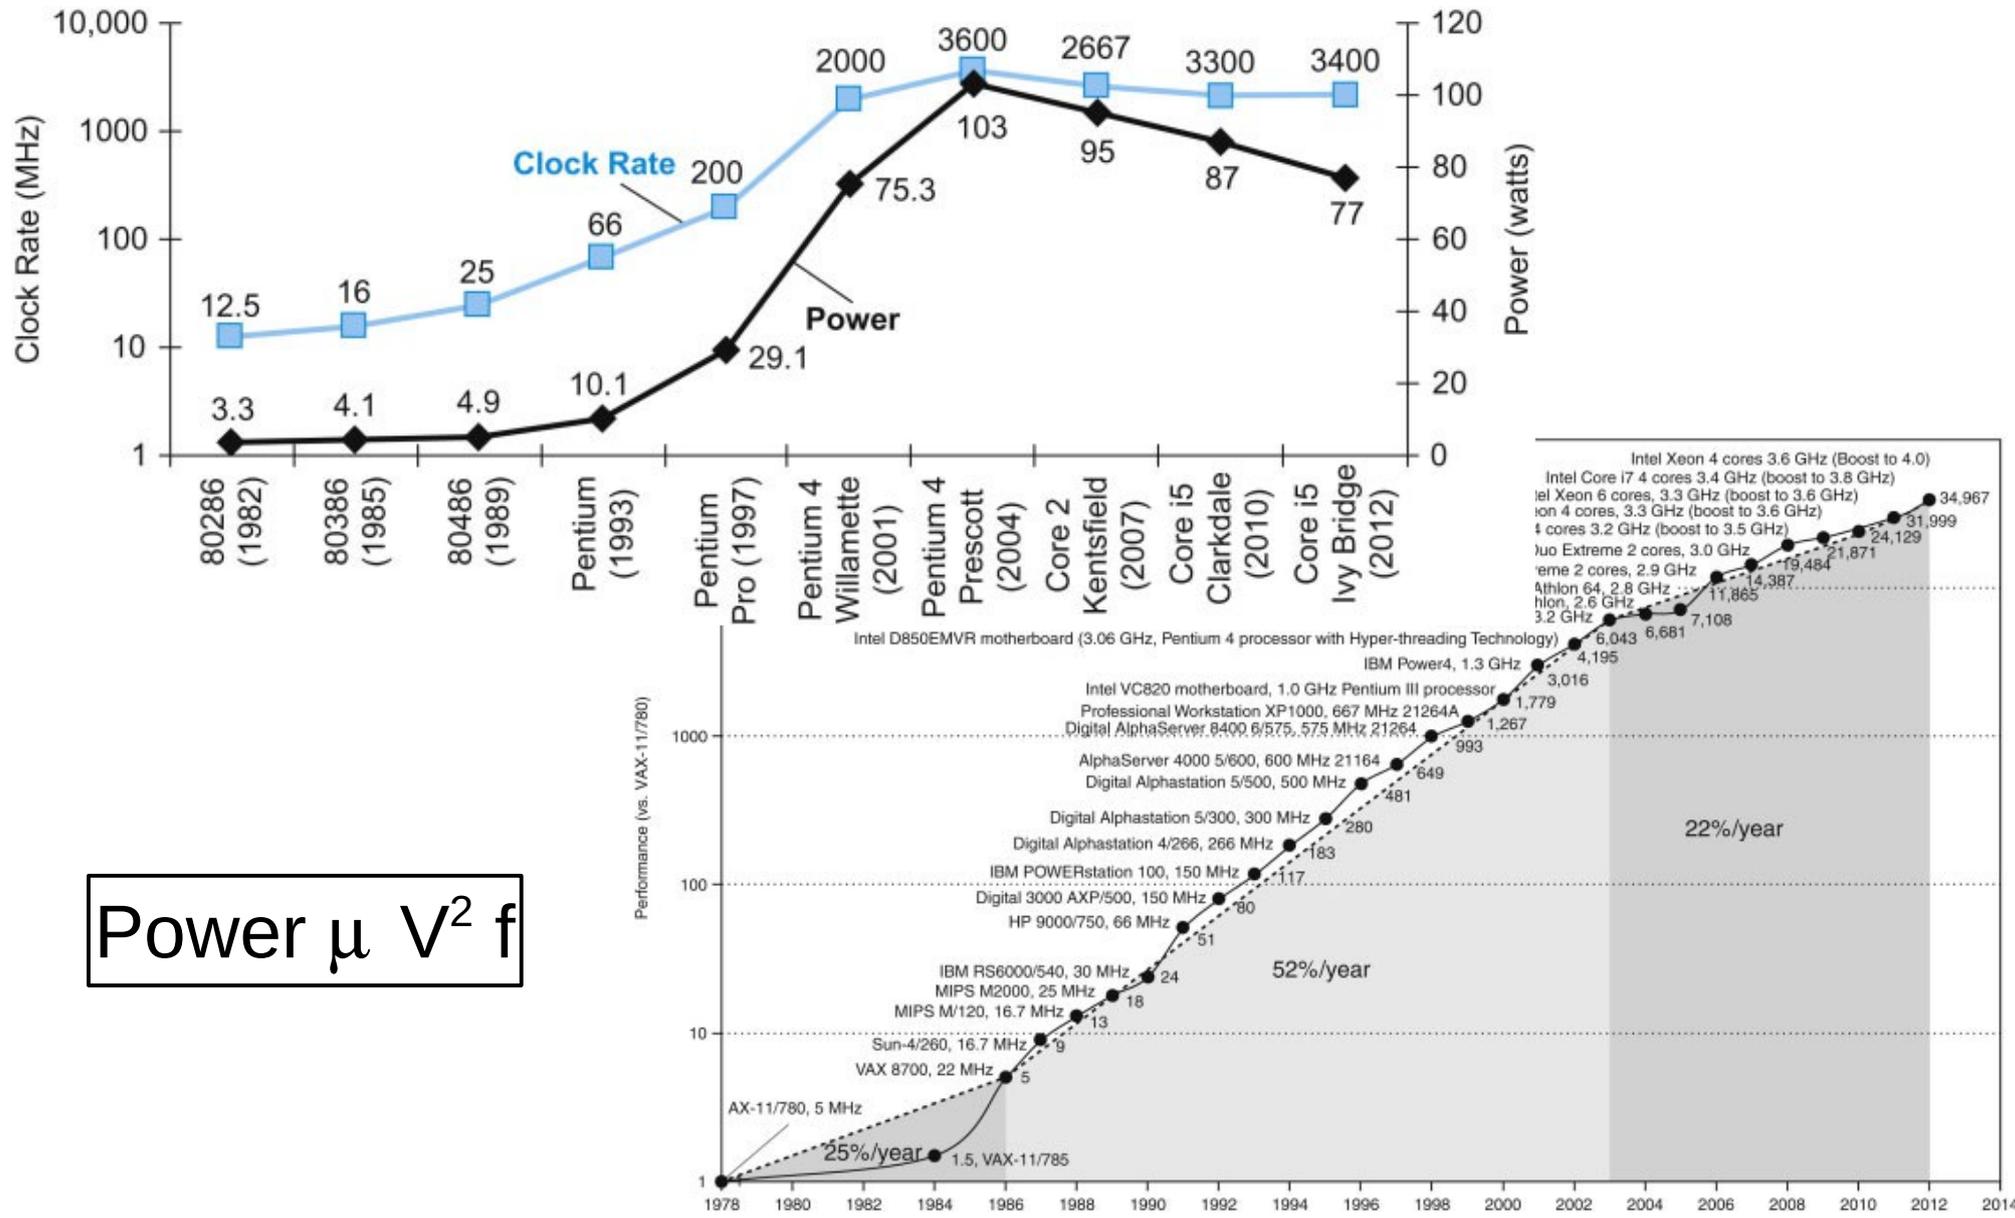
```
1992.419970 task-clock (msec)      #    0.999 CPUs utilized
      215 context-switches         #    0.108 K/sec
        5 cpu-migrations           #    0.003 K/sec
      368 page-faults              #    0.185 K/sec
4,139,391,573 cycles                #    2.078 GHz                    [44.54%]
2,207,522,429 stalled-cycles-frontend #  53.33% frontend cycles idle   [44.67%]
2,182,353,973 stalled-cycles-backend #  52.72% backend  cycles idle   [44.79%]
2,302,995,011 instructions          #    0.56  insns per cycle
                                     #    0.96  stalled cycles per insn [55.85%]
657,124,588 branches                # 329.812 M/sec                    [55.85%]
155,694,678 branch-misses           #   23.69% of all branches       [55.67%]
329,767,307 L1-dcache-loads         # 165.511 M/sec                    [55.45%]
 20,723,322 L1-dcache-load-misses   #    6.28% of all L1-dcache hits  [55.25%]
   200,896 LLC-loads                 #    0.101 M/sec                    [44.15%]
<not supported> LLC-load-misses:HG

1.994174760 seconds time elapsed
```

# Dynamic pipeline scheduling



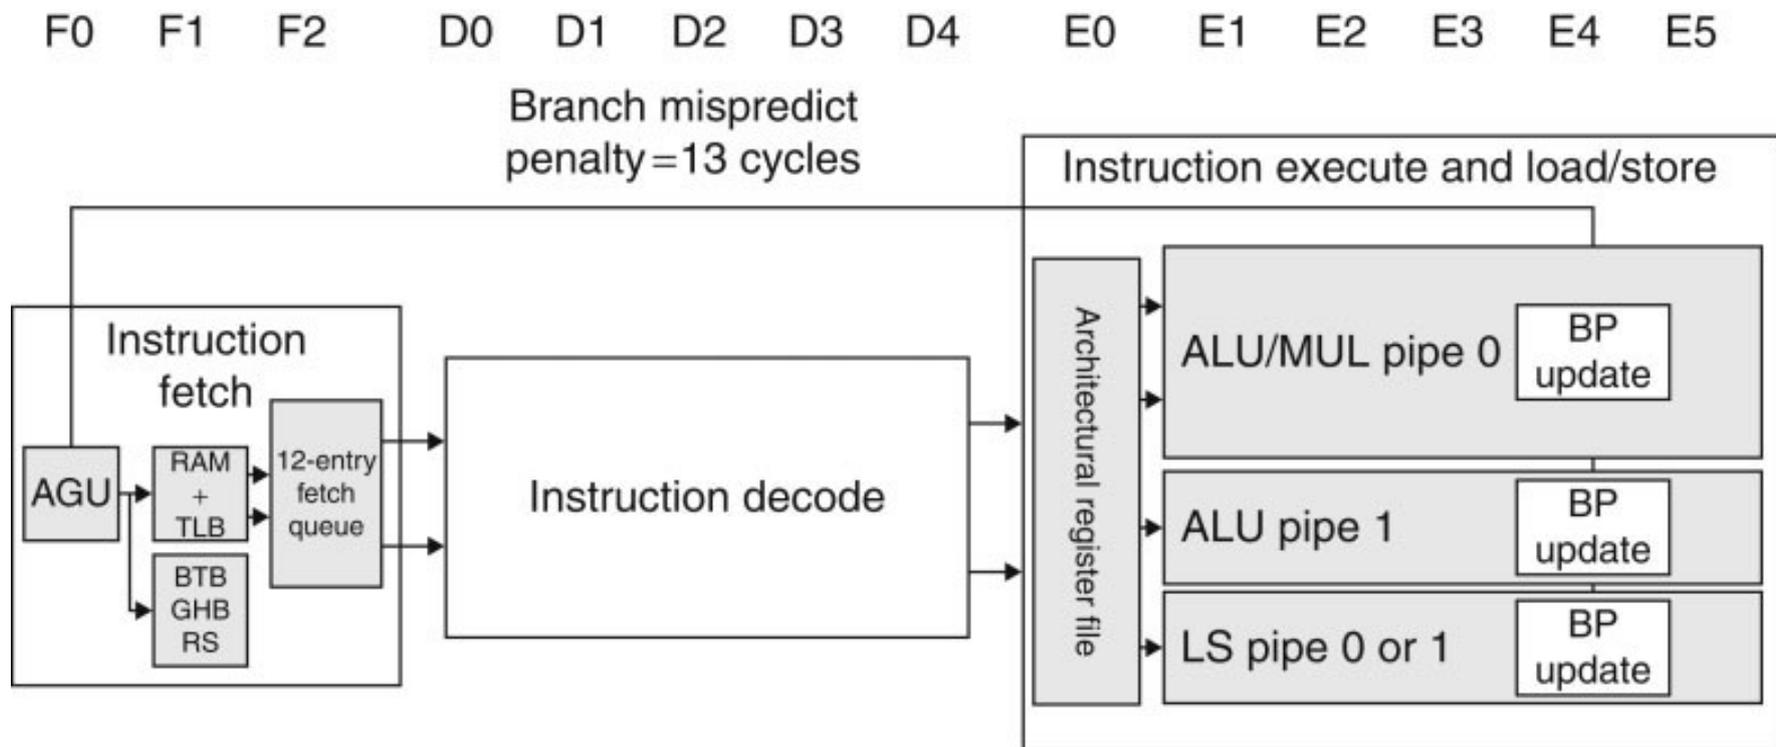
# A proposito di clock cycle



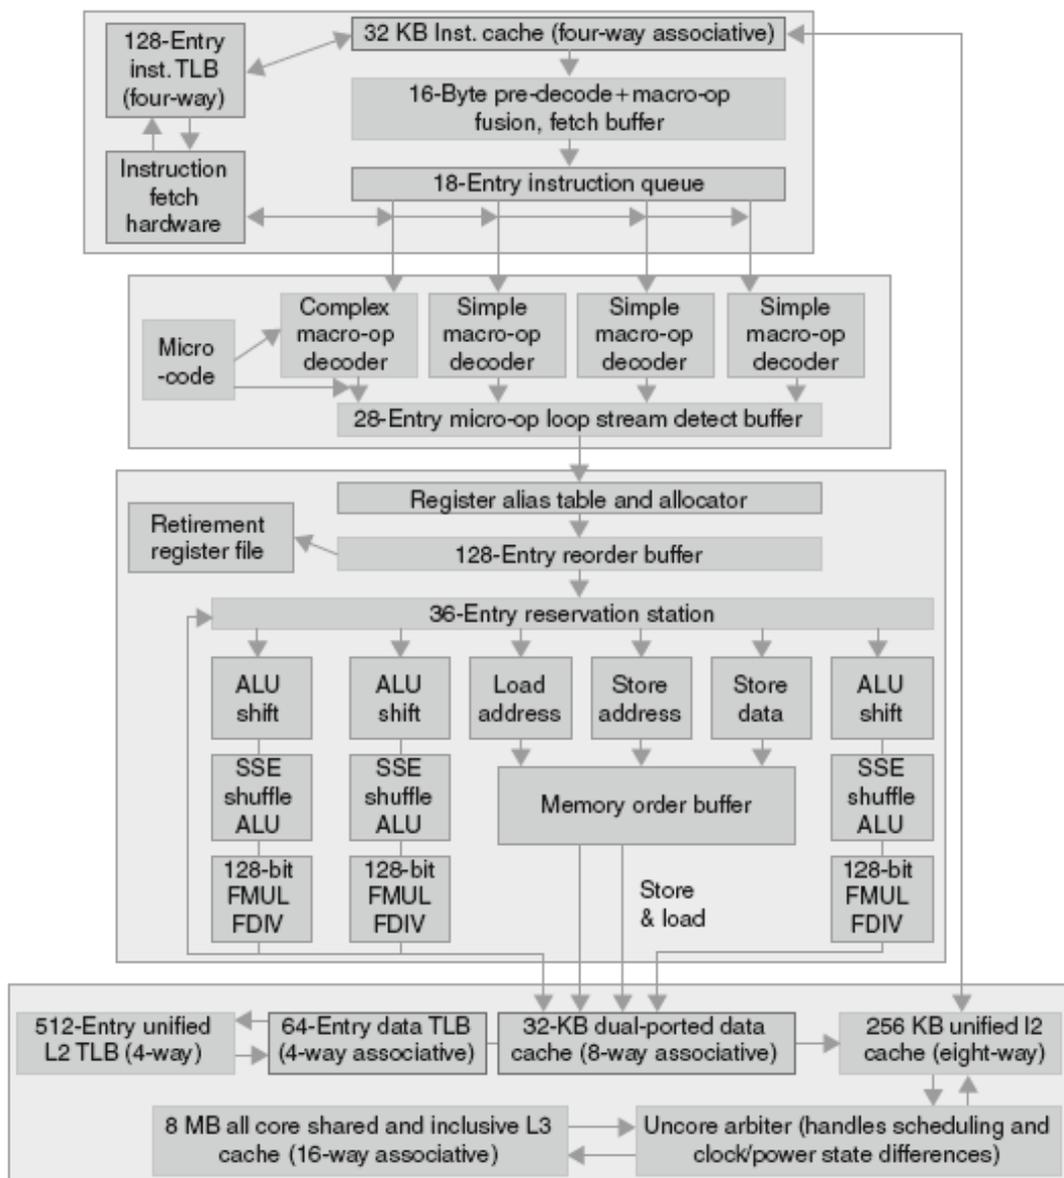
# ARM A8 e Intel Core i7

Processor	ARM A8	Intel Core i7 920
Market	Personal Mobile Device	Server, Cloud
Thermal design power	2 Watts	130 Watts
Clock rate	1 GHz	2.66 GHz
Cores/Chip	1	4
Floating point?	No	Yes
Multiple Issue?	Dynamic	Dynamic
Peak instructions/clock cycle	2	4
Pipeline Stages	14	14
Pipeline schedule	Static In-order	Dynamic Out-of-order with Speculation
Branch prediction	2-level	2-level
1st level caches / core	32 KiB I, 32 KiB D	32 KiB I, 32 KiB D
2nd level cache / core	128–1024 KiB	256 KiB
3rd level cache (shared)	–	2–8 MiB

# A8 pipeline



# Intel i7 pipeline

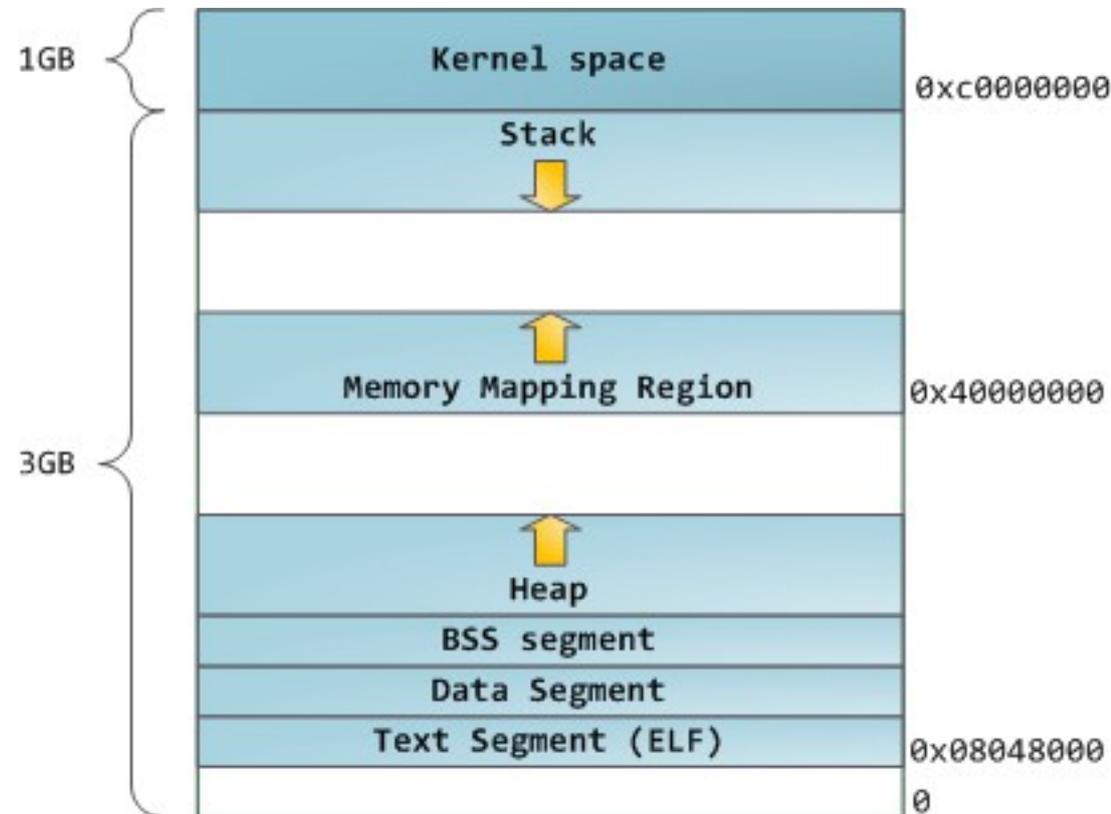


# Memoria

- La memoria può essere vista come una sequenza mono-dimensionale di *locazioni*, ognuna associata a un *indirizzo*
  - Di solito la minima unità indirizzabile è il byte
- Ad ogni processo viene allocata un'area di memoria dedicata
  - la memoria è virtuale
    - ad es. se l'area è di 4 GB, ogni processo può usare indirizzi nell'intervallo [0x00000000, 0xFFFFFFFF], ma questi non corrispondono necessariamente agli stessi indirizzi in memoria fisica
  - la memoria fisica viene allocata quando necessario
  - esiste un meccanismo di mapping tra indirizzi virtuali e fisici

# Memory layout di un processo

- Text
  - istruzioni del programma
- Data e BSS Segment
  - variabili globali e *static* inizializzate e non (= 0)
- Heap
  - allocazioni con `malloc` e `new`
- Stack
  - es. variabili locali di una funzione



# Chiamata di funzione

```
void swap(int* i, int* j) { ... }
int max(int* A, int N) { ... }
int increment(int i) { ... }

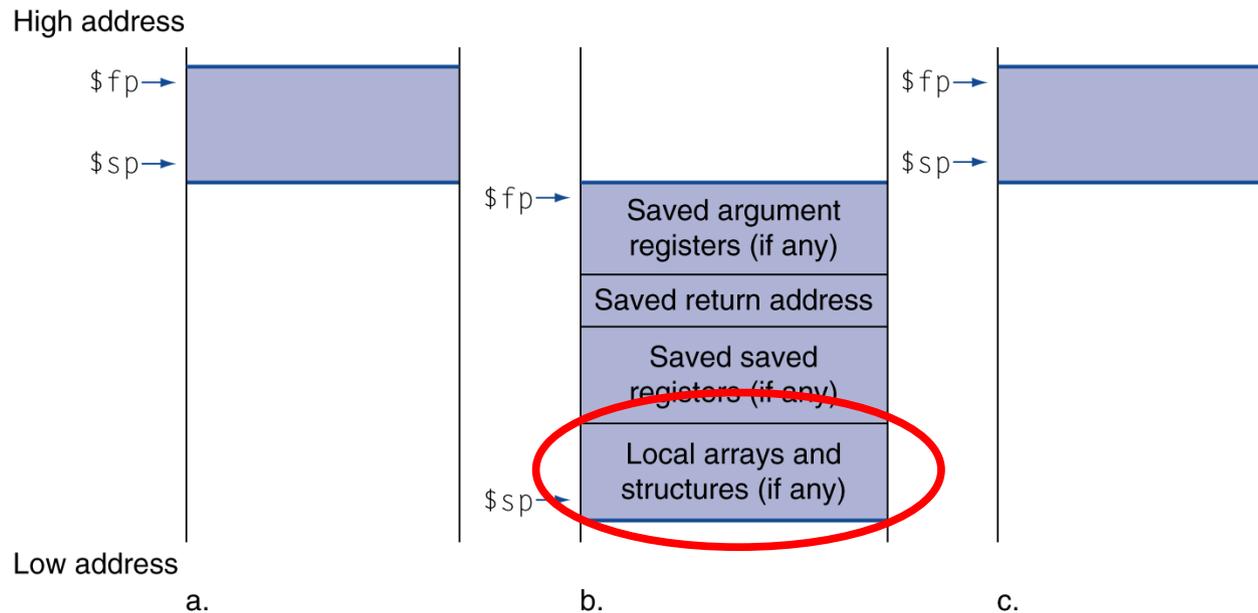
int main()
{
    int const N = ...;
    int A[N] = { ... };
    int i = ...;

    int o = increment(i);
    swap(&o, &i);
    int m = max(A, N);
}
```

# Chiamata di funzione

- Passi necessari
  - Mettere i parametri dove la funzione chiamata li possa accedere
  - Trasferire il controllo alla funzione
  - Acquisire spazio di memoria per l'esecuzione della funzione
  - Eseguire le operazioni della funzione
  - Mettere il risultato dove la funzione chiamante lo possa accedere
  - Ritornare il controllo al chiamante

# Stack



NB: questa disposizione è un esempio

- Stack: coda LIFO (Last-In, First-Out)
- Lo stack di solito cresce verso il basso
  - da indirizzi alti a indirizzi bassi
- Per ogni chiamata di funzione viene allocata sullo stack un'area dedicata (*frame* o *activation record*)
  - il frame viene deallocato alla fine della chiamata

# Cosa ci va in uno stack frame?

- Dipende dall'hardware, dal compilatore, ...
- Dati necessari per la gestione della catena delle chiamate
- Argomenti passati alla funzione
  - ma alcuni di solito sono passati attraverso i registri per evitare accessi in memoria
- Registri da preservare durante una chiamata di funzione
  - il numero di registri è limitato
- Variabili locali (automatiche)

Tutte queste informazioni sono note al compile time

⇒ l'allocazione di un frame consiste nell'incremento dello stack pointer

# Stack vs Heap

- Runtime overhead

```
void allocazione_stack() sorgente
{
    int m{123};
}

void allocazione_heap()
{
    int* m = new int{123};
    delete m;
}
```

```
allocazione_stack: assembler
    subq %4, %rsp
    movl $123, (%rsp)
    addq $4, %rsp
    ret

allocazione_heap:
    subq $8, %rsp
    movl $4, %edi
    call operator new(unsigned long)
    movl $123, (%rax)
    movl $4, %esi
    movq %rax, %rdi
    call operator delete(void*, unsigned long)
    addq $8, %rsp
    ret
```

- Frammentazione heap



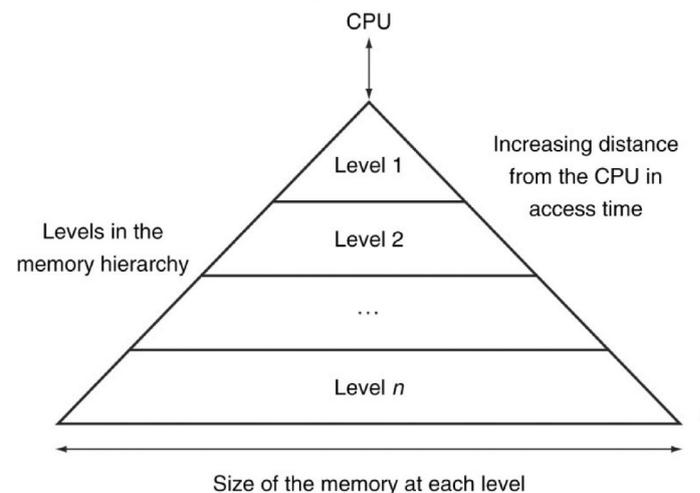
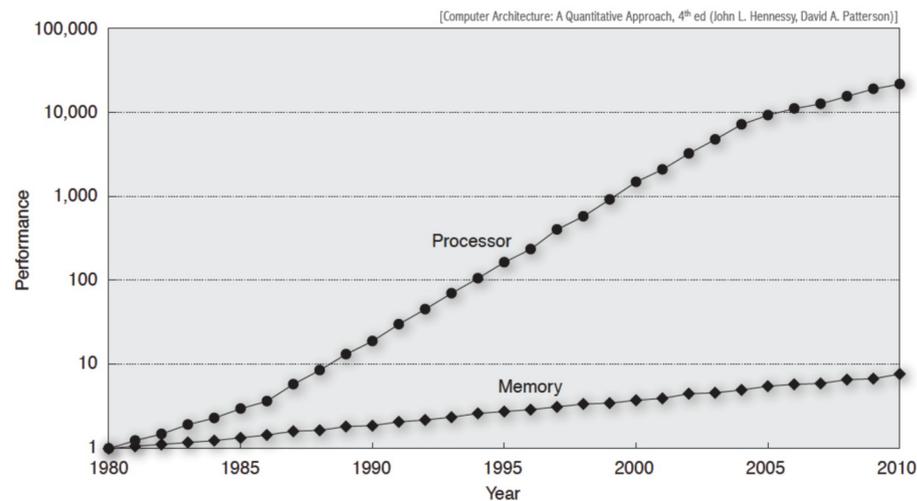
Used  
memory

Free  
memory

# Qual è la memoria ideale?

Memory technology	Typical access time	\$ per GiB in 2012
SRAM semiconductor memory	0.5–2.5 ns	\$500–\$1000
DRAM semiconductor memory	50–70 ns	\$10–\$20
Flash semiconductor memory	5,000–50,000 ns	\$0.75–\$1.00
Magnetic disk	5,000,000–20,000,000 ns	\$0.05–\$0.10

- La memoria ideale dovrebbe avere le prestazioni della SRAM e la capacità e il costo del disco
- Possiamo approssimare la situazione ideale
  - usando una gerarchia di memorie
  - sfruttando il principio di località



# Principio di località

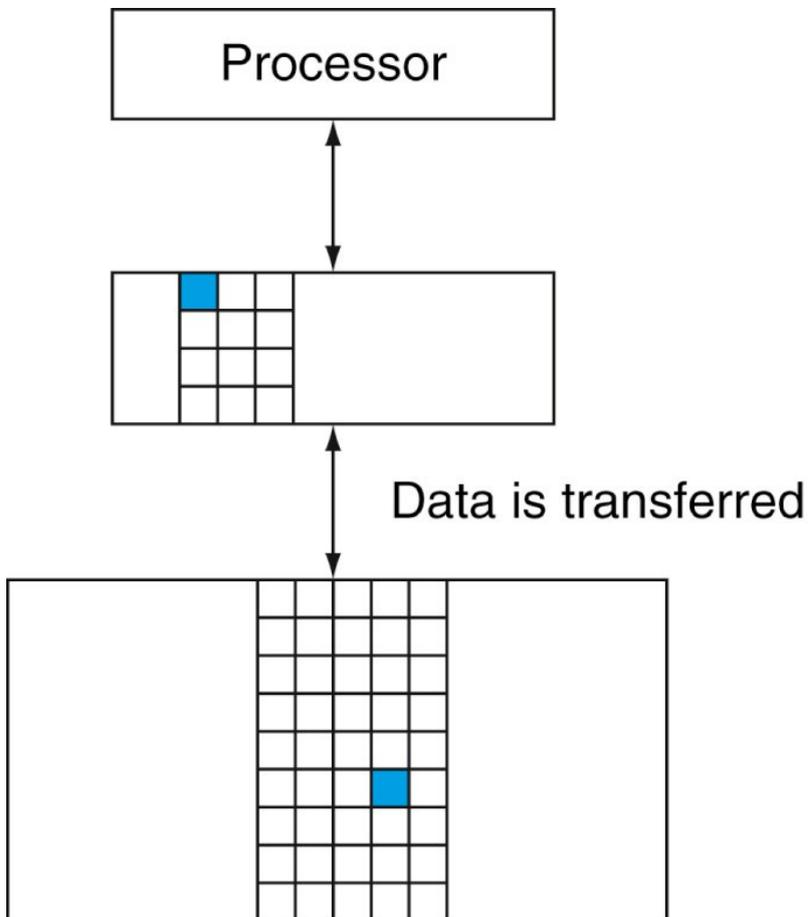
```
size_t strlen(char const* s)
{
    size_t l = 0;
    while (*s++) ++l;
    return l;
}
```

- Dati
  - Accessi ripetuti alla variabile `l`
  - Scansione dell'array `s`
- Istruzioni
  - Ripetizione delle espressioni/istruzioni `*s++` e `++l`
  - Esecuzione di istruzioni consecutive

# Principio di località

- In un dato intervallo limitato di tempo, un programma accede a una piccola parte del proprio spazio indirizzabile
- Località temporale
  - Elementi acceduti recentemente tendono ad essere acceduti nuovamente nel prossimo futuro
  - Esempi: istruzioni e variabili contatore in un loop
- Località spaziale
  - Elementi vicini a quelli acceduti recentemente tendono ad essere acceduti nel prossimo futuro
  - Esempi: accesso sequenziale a istruzioni, dati in un array

# Livelli di gerarchia

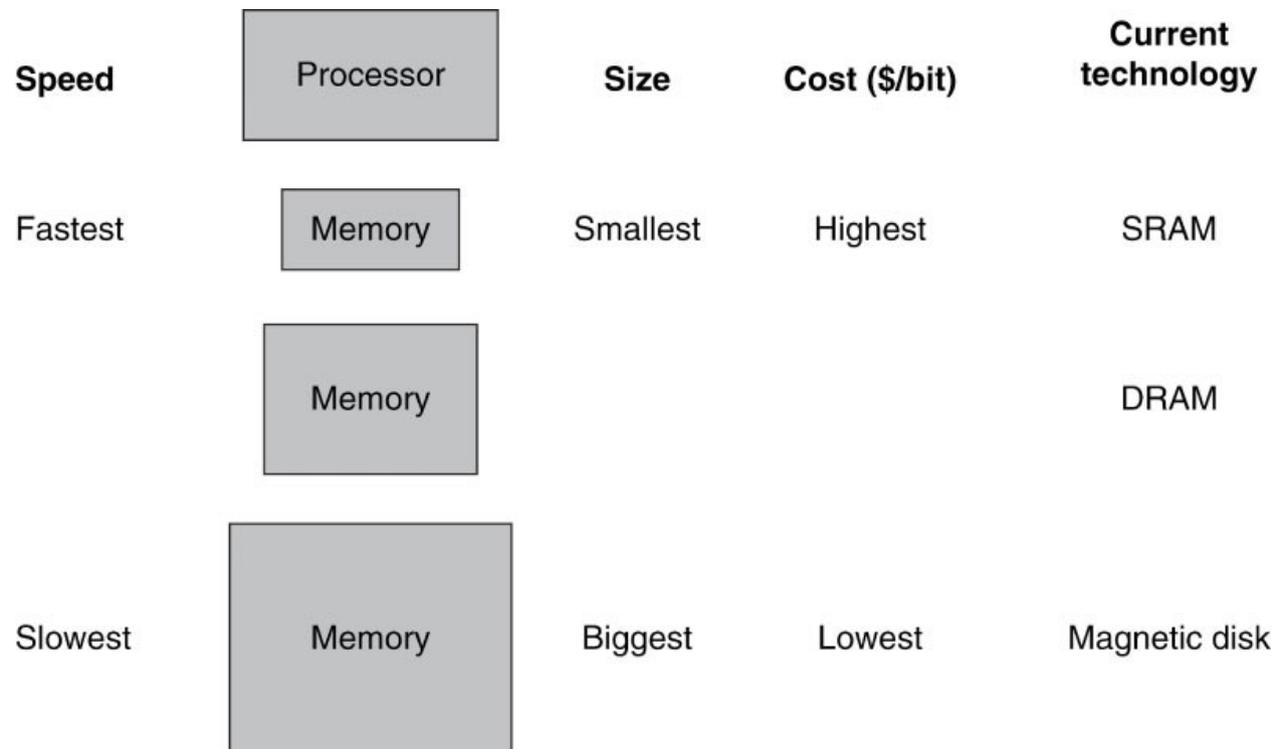


- Il dato cercato è **presente** nel livello superiore
  - *hit*  
hit rate = hits / accessi
- Il dato cercato **non è presente** nel livello superiore
  - *miss*: il dato è cercato nel livello inferiore e da lì copiato  
miss rate = misses / accessi = 1 - hit rate
  - miss penalty: tempo impiegato per ricerca e copia
  - una volta copiato nel livello superiore, il dato è acceduto come se fosse un hit
  - un miss causa stall nella pipeline (mitigabile con multiple issue, speculation, out-of-order, ...)
- Di solito non viene copiato il singolo dato ma un blocco (*cache line*) di più byte (es. 64 byte)

$$\text{Memory-stall time} = \text{Memory accesses} \times \text{Miss rate} \times \text{Miss penalty}$$

# Livelli di gerarchia

- Configurazione tipica



- Illusione di avere memoria contemporaneamente capace, veloce e a costi accettabili

# Memoria cache

- Livello della gerarchia di memoria più vicino al processore
- Capacità limitata ma accesso veloce
- Dati gli accessi  $X_1, X_2, \dots, X_n$

$X_4$
$X_1$
$X_{n-2}$
$X_{n-1}$
$X_2$
$X_3$

a. Before the reference to  $X_n$

$X_4$
$X_1$
$X_{n-2}$
$X_{n-1}$
$X_2$
$X_n$
$X_3$

b. After the reference to  $X_n$

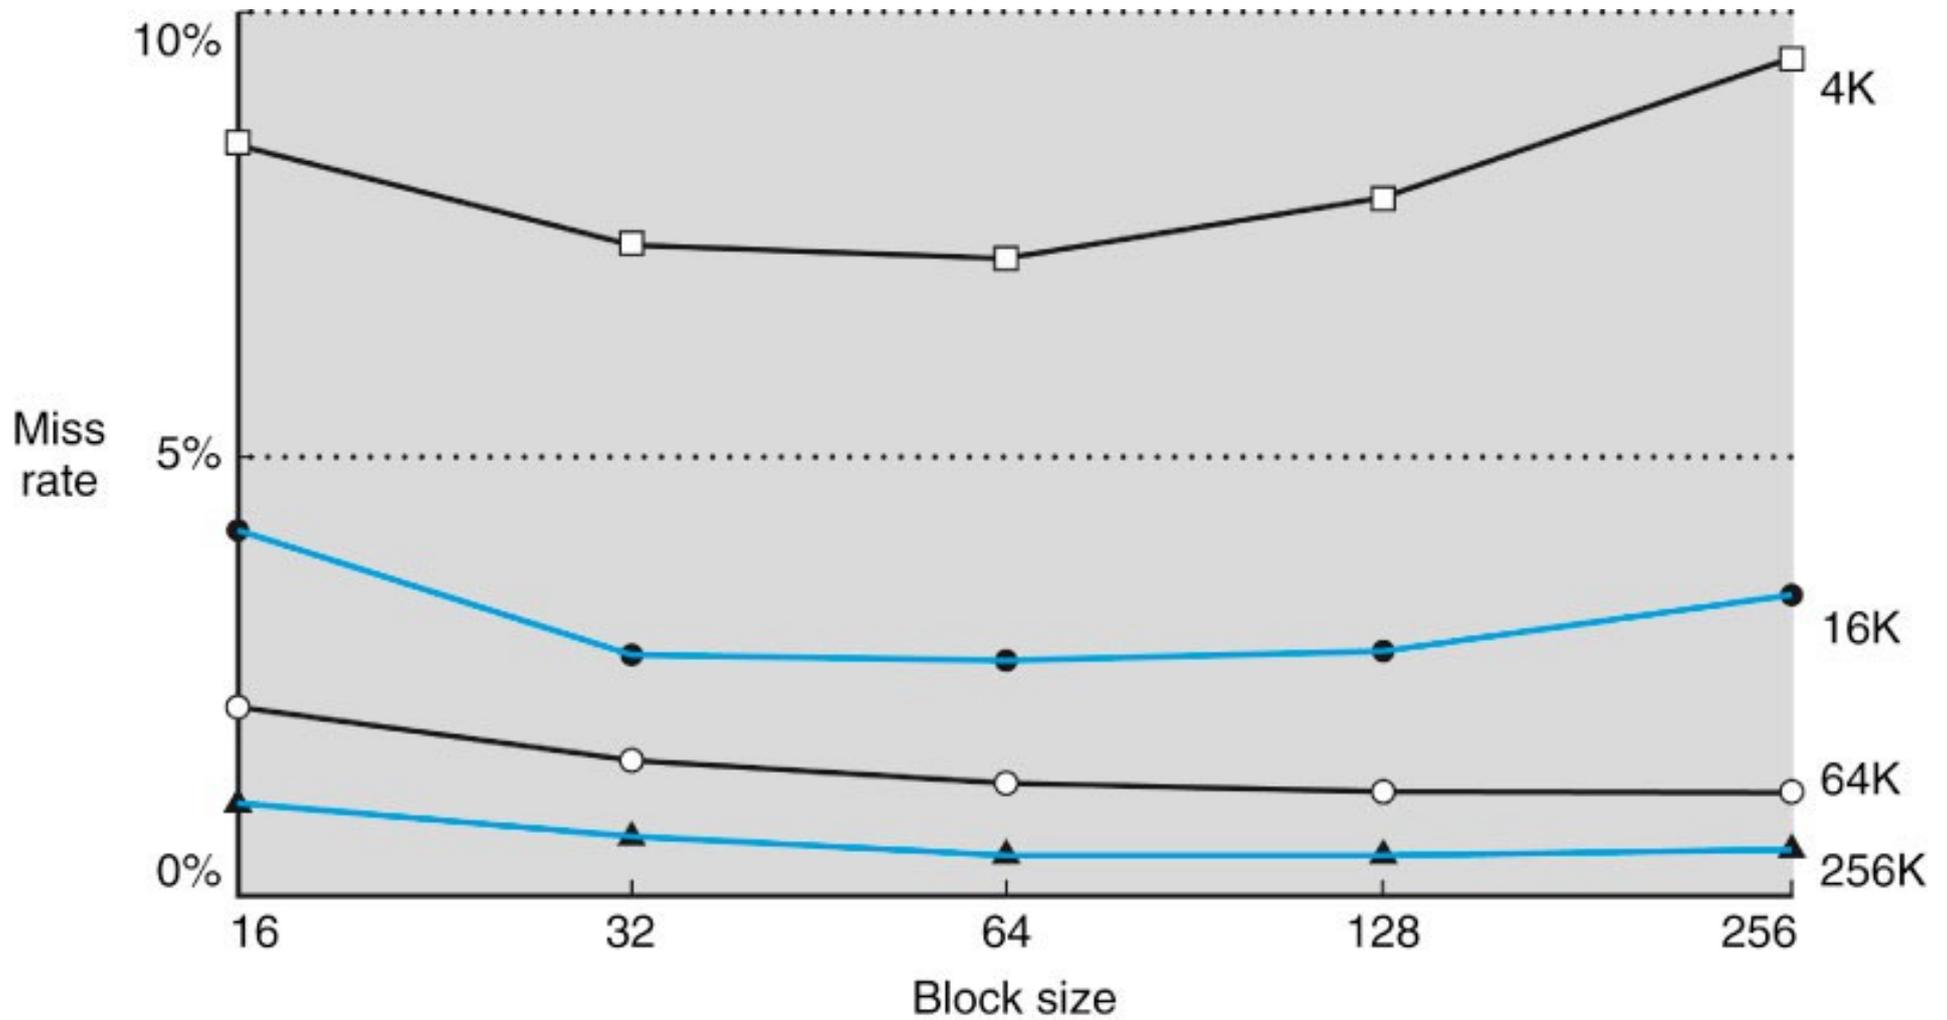
- Come sappiamo se un dato è già nella cache?
- Se è nella cache, dove sta?
- Diverse soluzioni possibili, ma in generale la posizione dipende dall'indirizzo

Il primo accesso a  $X_n$  causa un cache miss

# Dimensione del blocco

- Qual è la dimensione ideale del blocco?
- Blocchi più grandi sfruttano la località spaziale → maggiore hit rate
- Ma...
  - blocco più grande → meno blocchi → più competizione → minore hit rate
    - a parità di dimensione della cache
  - blocco più grande → più dati da trasferire per ogni miss → maggiore miss penalty

# Miss rate vs block size



# Prestazioni della cache

Average memory access time = Hit time + Miss rate × Miss penalty

- Come si può migliorare la prestazione della cache?
- Si può aumentare l'hit rate/ridurre il miss rate
  - introduzione di meccanismi più flessibili nell'allocazione dei blocchi in una cache → *associatività*
- Si può ridurre la penalizzazione dovuta a un miss
  - introduzione di cache a più livelli

# Indicatori di performance

```
$ perf stat -d ./a.out
```

```
Performance counter stats for './a.out':
```

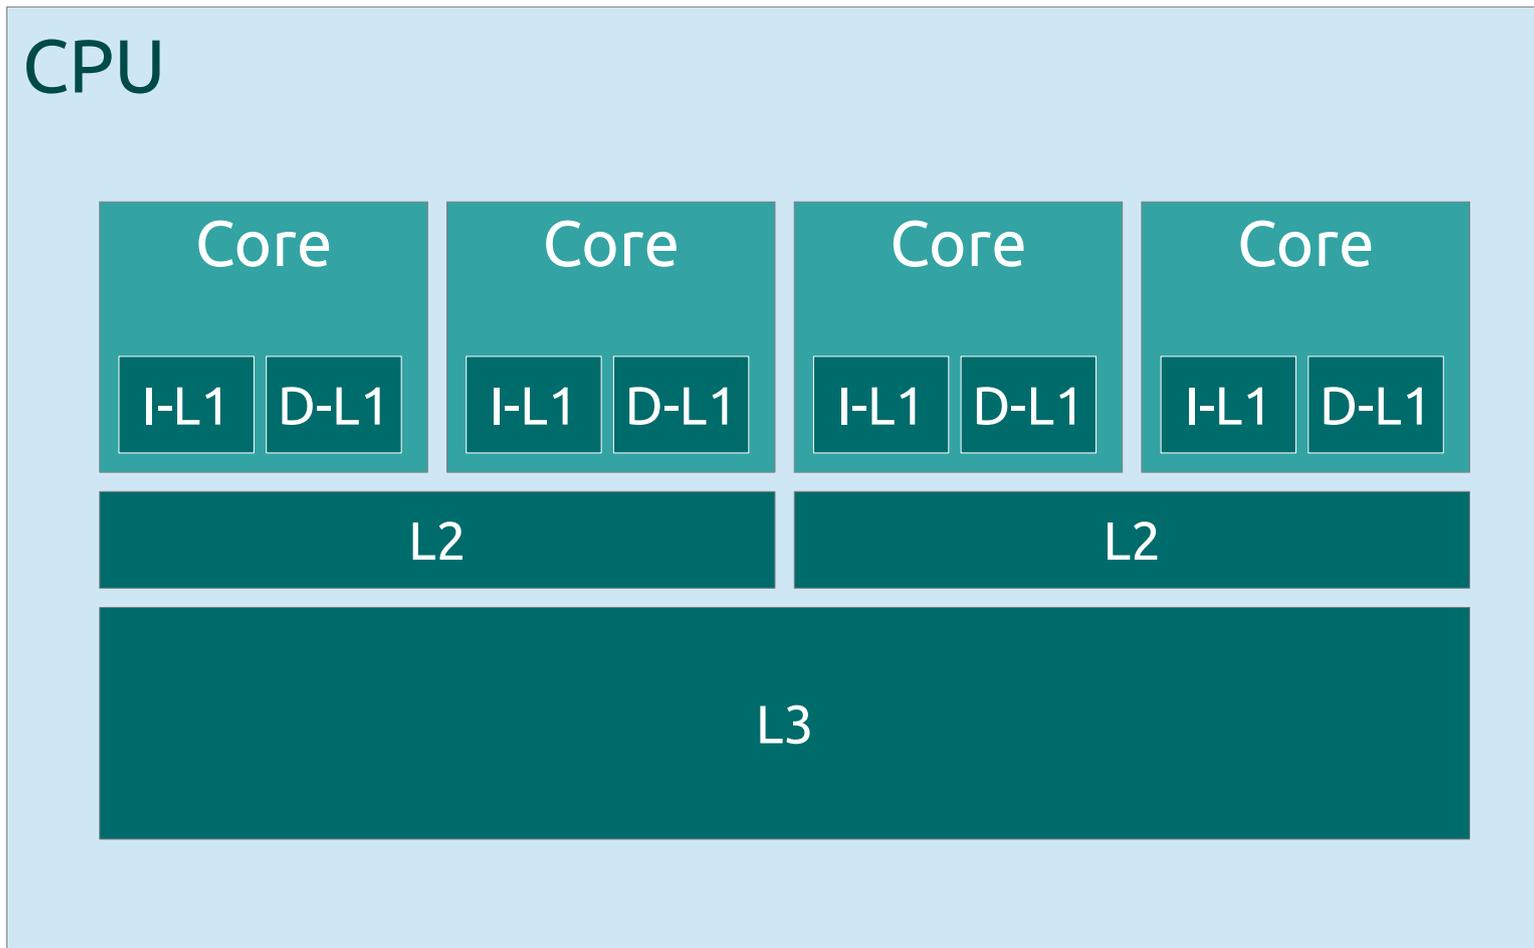
```
1992.419970 task-clock (msec)      #    0.999 CPUs utilized
          215 context-switches      #    0.108 K/sec
           5  cpu-migrations         #    0.003 K/sec
          368 page-faults           #    0.185 K/sec
4,139,391,573 cycles                 #    2.078 GHz                    [44.54%]
2,207,522,429 stalled-cycles-frontend #  53.33% frontend cycles idle   [44.67%]
2,182,353,973 stalled-cycles-backend #  52.72% backend  cycles idle   [44.79%]
2,302,995,011 instructions          #    0.56  insns per cycle
                                           #    0.96  stalled cycles per insn [55.85%]
657,124,588 branches                 # 329.812 M/sec                    [55.85%]
155,694,678 branch-misses            #   23.69% of all branches        [55.67%]
329,767,307 L1-dcache-loads          # 165.511 M/sec                    [55.45%]
 20,723,322 L1-dcache-load-misses    #    6.28% of all L1-dcache hits  [55.25%]
   200,896 LLC-loads                 #    0.101 M/sec                    [44.15%]
<not supported> LLC-load-misses:HG

1.994174760 seconds time elapsed
```

# Cache a più livelli

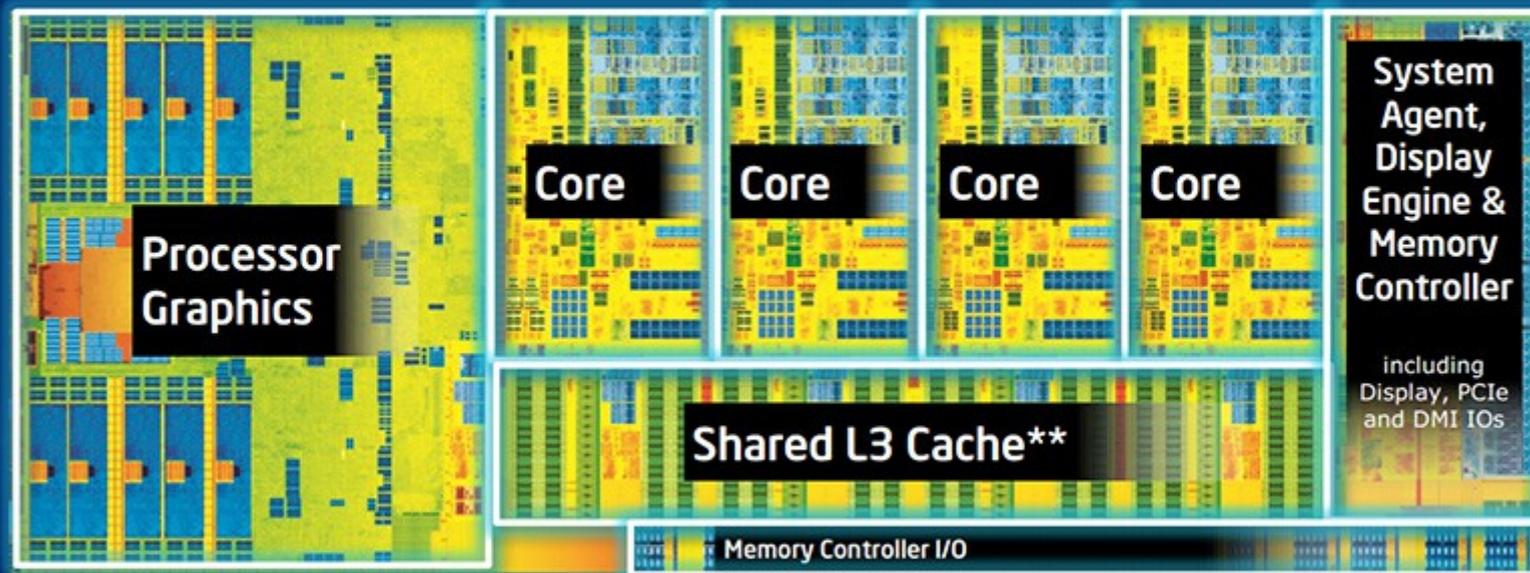
- Per ridurre miss rate e miss penalty si può usare una cache a più livelli (2 o anche 3)
- Il principio è lo stesso: se un dato è disponibile nel livello di cache superiore (hit) lo si usa, altrimenti (miss) si cerca nel livello inferiore
  - il dato esiste sicuramente nel livello più basso
- Man mano che ci si allontana dalla CPU la cache diventa più capiente ma più lenta a rispondere
- Scopi diversi:
  - cache L1 progettata per minimizzare il tempo di accesso in caso di hit
  - cache L2 progettata per minimizzare il miss rate e quindi gli accessi in memoria

# Cache a più livelli



# Cache a più livelli

## 4th Generation Intel® Core™ Processor Die Map *22nm Tri-Gate 3-D Transistors*



Quad core die shown above

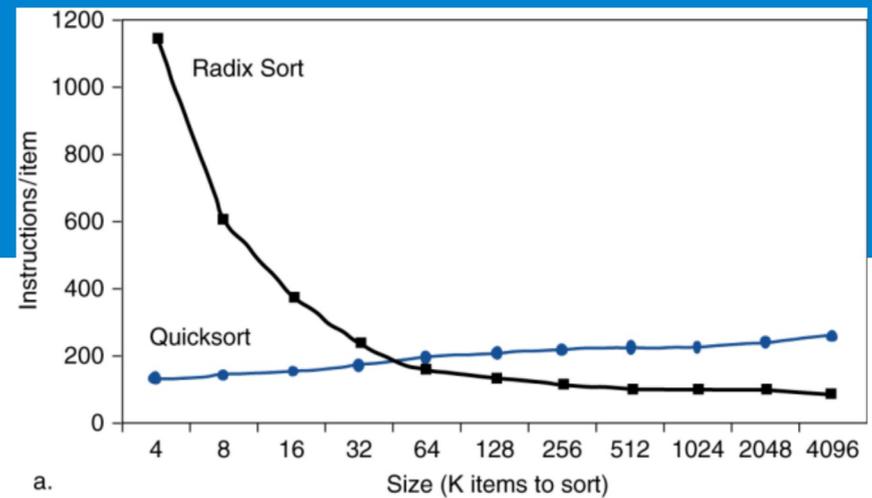
Transistor count: 1.4 Billion

Die size: 177mm<sup>2</sup>

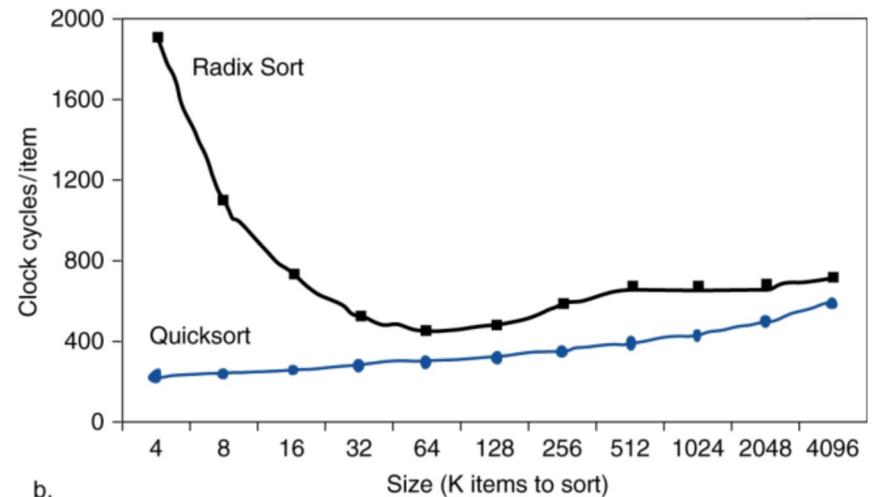
\*\* Cache is shared across all 4 cores and processor graphics

# Effetto cache

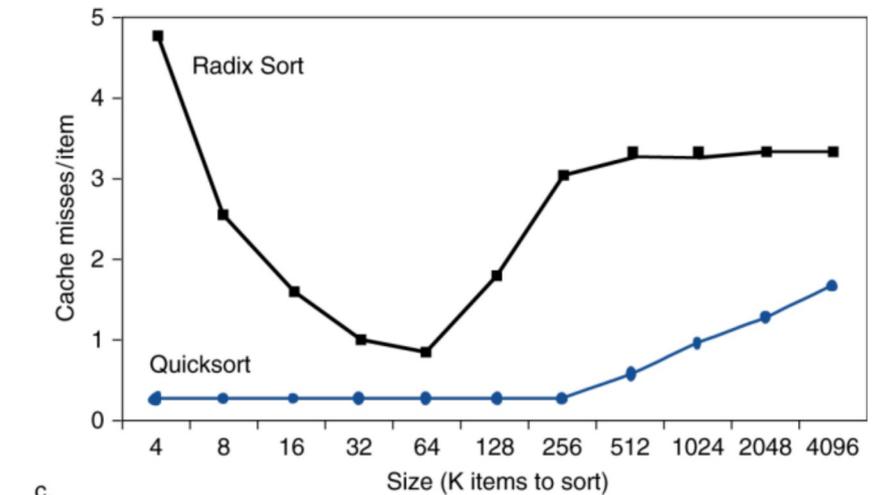
- L'efficienza di un programma non dipende solo dalla complessità computazionale dell'algoritmo...



a.



b.



c.

# ARM A8 vs Intel Nehalem

Characteristic	ARM Cortex-A8	Intel Nehalem
L1 cache organization	Split instruction and data caches	Split instruction and data caches
L1 cache size	32 KiB each for instructions/data	32 KiB each for instructions/data per core
L1 cache associativity	4-way (I), 4-way (D) set associative	4-way (I), 8-way (D) set associative
L1 replacement	Random	Approximated LRU
L1 block size	64 bytes	64 bytes
L1 write policy	Write-back, Write-allocate(?)	Write-back, No-write-allocate
L1 hit time (load-use)	1 clock cycle	4 clock cycles, pipelined
L2 cache organization	Unified (instruction and data)	Unified (instruction and data) per core
L2 cache size	128 KiB to 1 MiB	256 KiB (0.25 MiB)
L2 cache associativity	8-way set associative	8-way set associative
L2 replacement	Random(?)	Approximated LRU
L2 block size	64 bytes	64 bytes
L2 write policy	Write-back, Write-allocate (?)	Write-back, Write-allocate
L2 hit time	11 clock cycles	10 clock cycles
L3 cache organization	-	Unified (instruction and data)
L3 cache size	-	8 MiB, shared
L3 cache associativity	-	16-way set associative
L3 replacement	-	Approximated LRU
L3 block size	-	64 bytes
L3 write policy	-	Write-back, Write-allocate
L3 hit time	-	35 clock cycles

# Non-uniform memory access

