

**ELABORATORE x86-64  
E PRINCIPI DI PROGRAMMAZIONE**

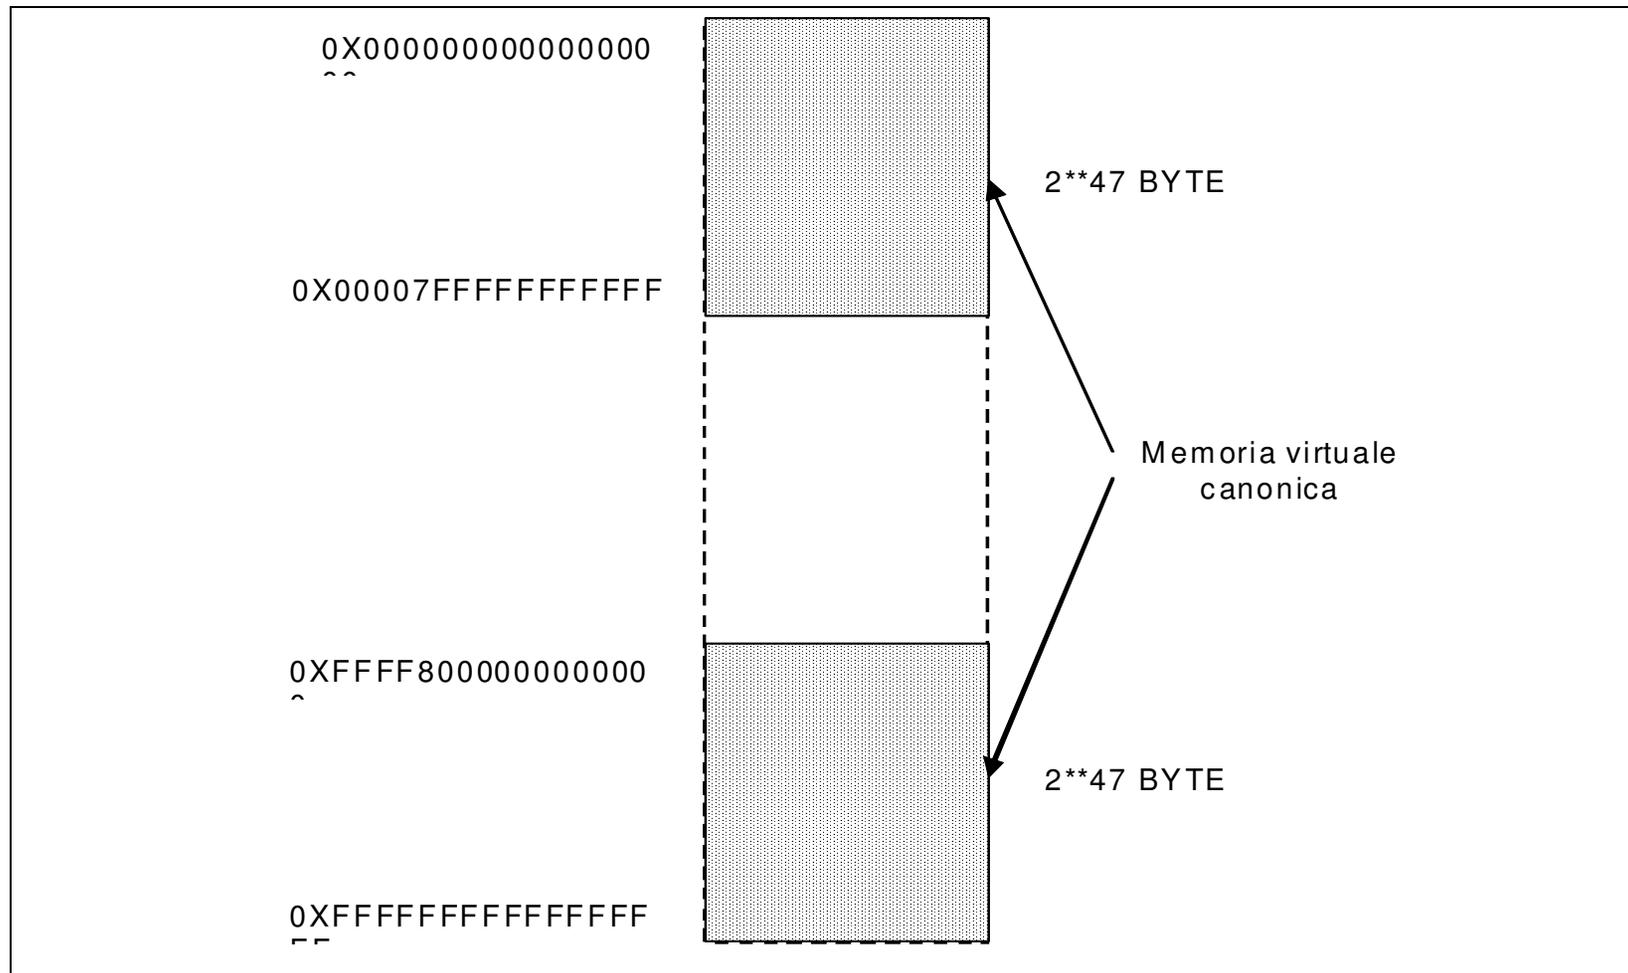
# Caratteristiche del processore x86-64

- **Processore schematizzato x86-64 (Processore PC):**
  - processore didattico;
  - schematizzazione (software compatibile) dei processori a 64 bit della famiglia INTEL, funzionanti in modo protetto (x86-64);
  - costituito da 2 tipi di unità di elaborazione visibili al programmatore:
    - la ALU (*Aritmetic and Logic Unit*), che esegue le istruzioni generali e quelle sui numeri naturali e interi;
    - la FPU (*Floating Point Unit*), che esegue le istruzioni sui numeri reali.
- **Operandi manipolati dalle istruzioni della ALU:**
  - lunghi 8 bit (byte), 16 bit (parola), 32 bit (parola intera o lunga), 64 bit (parola quadrupla).
- **Operandi manipolati dalle istruzioni della FPU:**
  - lunghi 80 bit.
- **In questo corso esamineremo solo la ALU e non la FPU (e quindi le elaborazioni sui numeri reali).**

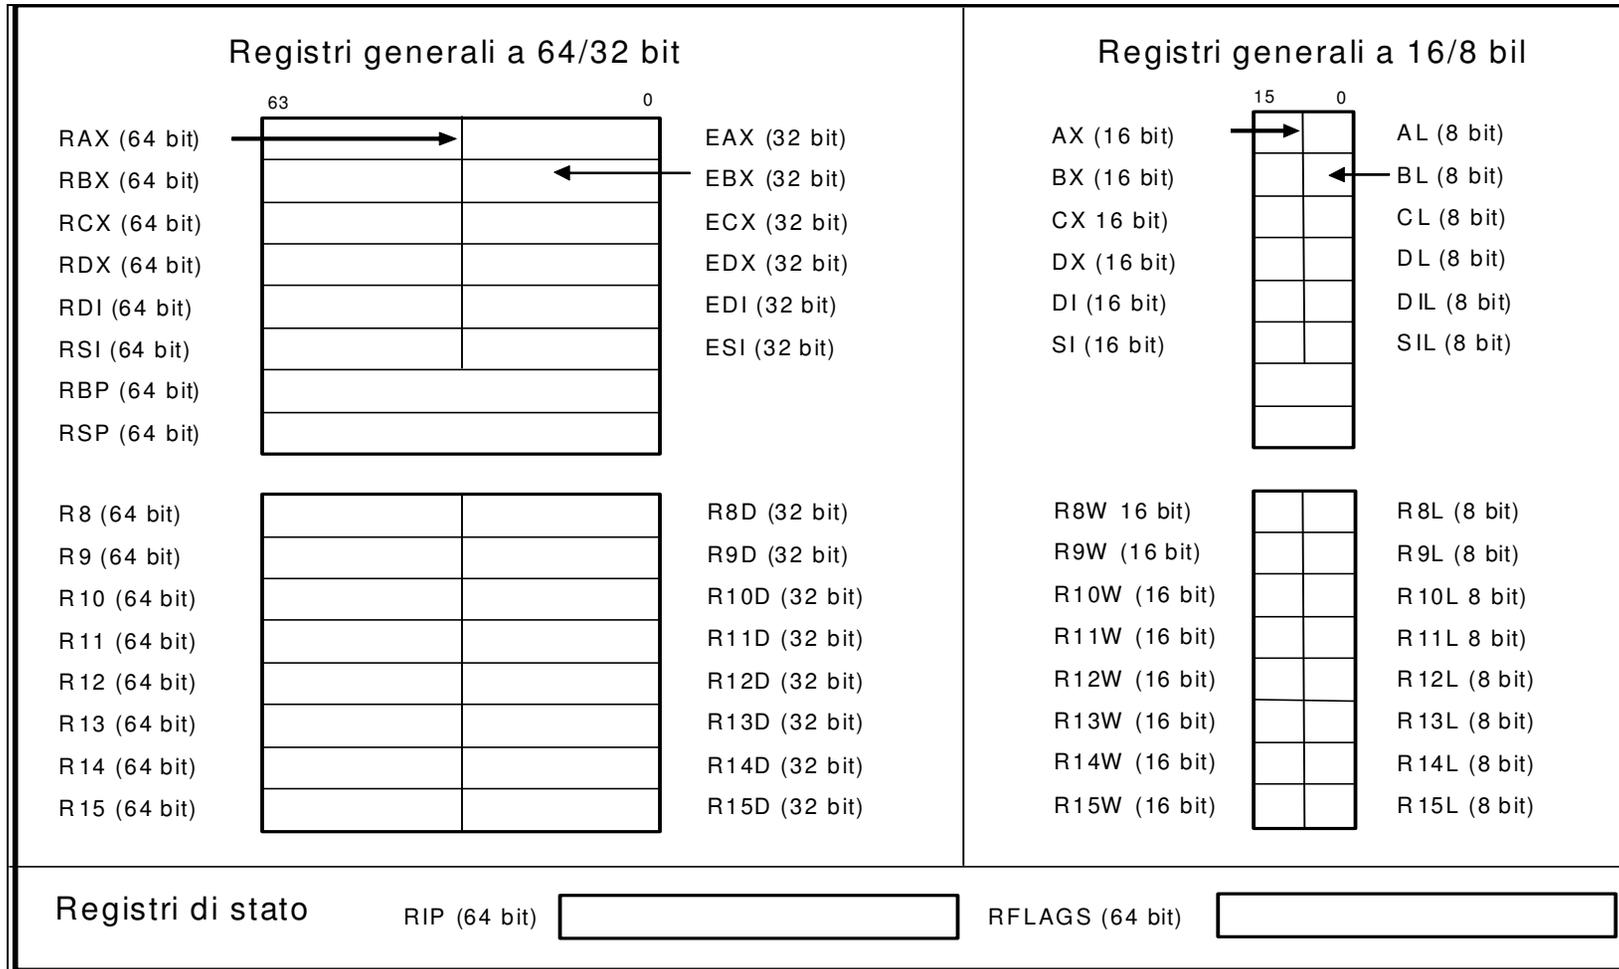
# Spazi di indirizzamento

- **Funzionamento del Processore x86-64:**
  - alla partenza, in modalità x86-16 (come il processore 8086);
  - dopo un'apposita istruzione, in modalità x86-64, con memoria virtuale.
- **Spazio di memoria in modalità x86-64 (virtuale):**
  - indirizzo lineare e costituito da 64 bit;
  - $2^{48}$  dei  $2^{64}$  possibili indirizzi sono detti canonici (hanno i 16 bit più significativi, tutti di valore 0 o tutti di valore 1, uguali al valore del bit alla loro destra):
    - individuano 2 sottospazi di  $2^{47}$  bit ciascuno, all'inizio e alla fine di tutto lo spazio di indirizzamento, con indirizzi:  
0x0000000000000000-0x00007FFFFFFFFFFFFFFF  
0xFFFF800000000000-0xFFFFFFFFFFFFFFFF
  - gli indirizzi utilizzati dal programmatore (per istruzioni e dati) devono essere canonici.
- **Spazio di I/O in modalità x86-64 (senza memoria virtuale):**
  - lineare, e costituito da  $2^{16}$  porte di un byte, il cui indirizzo va da 0x0000 a 0xFFFF;
  - le porte di un byte possono essere associate due a due (porte di 16 bit) o quattro a quattro (porte di 32 bit).

# Spazio di memoria (virtuale)



# Registri della ALU (1)

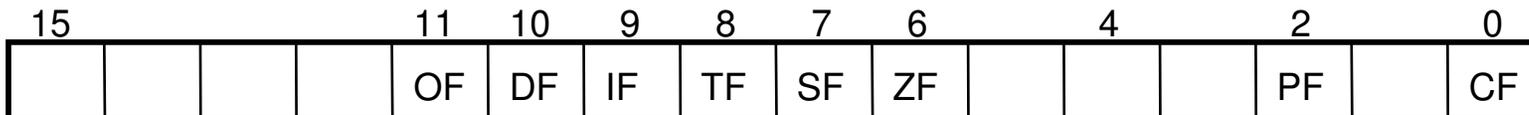


## Registri della ALU(2)

- **Registri generali:**
  - **registri generali a 64 bit:**
    - sono 16;
    - possono venir indifferentemente utilizzati per memorizzare operandi e per contenere indirizzi di memoria;
    - alcuni di essi svolgono specifiche funzioni:
      - registri RSP, RBP,: servono a indirizzare la pila (RSP funge da puntatore alla cima della pila, ed RBP funge da registro base per una zona della pila);
      - registri RAX, RDX: RAX funge principalmente da accumulatore, ed RDX da estensione dell'accumulatore;
  - **registri generali a 32 bit, 16 bit, 8 bit:**
    - parti meno significative, rispettivamente, dei corrispondenti registri a 64 bit, a 32 bit, a 16 bit.
- **Registri di stato:**
  - **registro RIP: contatore istruzioni (64 bit).**
  - **registro RFLAGS: registro delle condizioni (64 bit).**

## Registri della ALU (3)

- **Registro di stato RIP (o registro contatore):**
  - contiene l'indirizzo della prossima istruzione.
- **Registro di stato RFLAGS (o registro delle condizioni):**
  - i due byte meno significativi contengono:
    - i flag aritmetici PF (Parity), ZF (zero), CF (Carry), SF (Sign), OF (Overflow);
    - i flag IF e TF relativi al meccanismo di interruzione;
    - il flag DF utilizzato dalle istruzioni sulle stringhe.



# Codifica delle istruzioni

Codice operativo OC (include la lunghezza operandi)	Individuazione registri coinvolti e modi indirizzamento	Spiazzamento DISP 0/4 byte	Operando immediato IMM 0/8 byte
---	---	-------------------------------	------------------------------------

- **Codice operativo (OC):**
  - specifica il codice operativo e la lunghezza degli operandi;
  - il secondo campo contiene informazioni aggiuntive.
- **Spiazzamento (DISPlacement):**
  - assente
  - 1, 2 oppure 4 byte.
- **Operando immediato (IMMediate):**
  - assente
  - da 1 a 4 byte
  - di 8 byte solo per l'istruzione **MOVABSQ**.

# Indirizzamenti per le istruzioni operative

- **Indirizzamento di registro:**
  - operando in un registro del processore.
- **Indirizzamento immediato:**
  - operando nell'istruzione (campo IMM).
- **Indirizzamento di memoria assoluto per le istruzioni operative (una o due componenti possono mancare):**

$$\text{INDIRIZZO} = | \text{BASE} + \text{INDICE} * \text{SCALA} + \text{DISP} | \text{ modulo } 2^{**}64$$

- *BASE* è il contenuto di uno dei registri generali di 64 bit;
  - *INDICE* è il contenuto di uno dei registri generali di 64 bit;
  - *SCALA* è un fattore che può valere 1, 2, 4 oppure 8;
  - *DISP* è un numero intero, di 8 bit, di 16 bit o di 32 bit, esteso a 64 bit.
- **Indirizzamento di memoria relativo rispetto a RIP per le istruzioni operative:**
    - *RIP*: contiene l'indirizzo dell'istruzione successiva a quella attualmente in esecuzione;
    - *DISP* è un numero intero, di 8 bit, di 16 bit o di 32 bit, esteso a 64 bit.

# Indirizzamenti per istruzioni di controllo e di I/O

- **Indirizzamento per le istruzioni di controllo:**

- **relativo:**

- $$\text{INDIRIZZO} = | \text{RIP} + \text{DISP} | \text{ modulo } 2^{**}64$$

- *RIP*: contiene l'indirizzo dell'istruzione successiva a quella attualmente in esecuzione;
    - *DISP* è un numero intero, di 8 bit, 16 bit o di 32 bit, esteso a 64 bit.

- **indiretto:**

- $$\text{INDIRIZZO} = \text{CONTENUTO DI UN REGISTRO};$$

- possibile solo per le istruzioni di salto incondizionato e di chiamata.

- **Indirizzamento di una porta di I/O:**

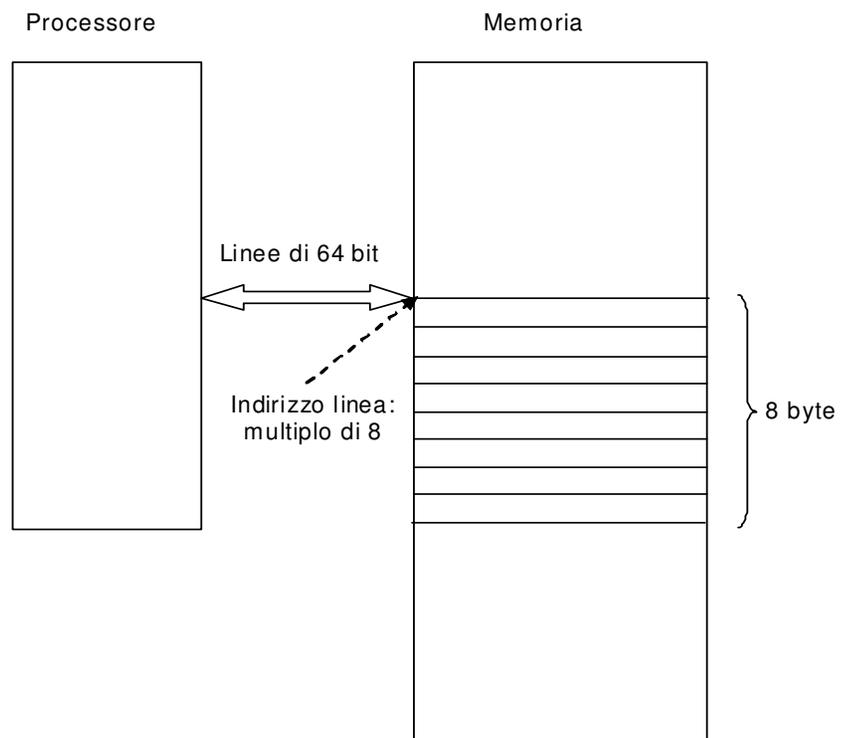
- l'indirizzo può essere specificato nell'istruzione;
  - l'indirizzo può essere contenuto nel registro *DX*;
  - **prima forma:**
    - possibile solo per indirizzi minori di 256.

# Indirizzo di memoria

- **Spiazzamento:**
  - è un intero, rappresentato al più su 32 bit.
- **Indirizzo assoluto:**
  - a partire dal contenuto di un registro base RBASE (da 0 se il registro base è assente), consente di indirizzare una zona di memoria che va da  $|RBASE - 2^{31}|$  modulo  $2^{64}$  a  $|RBASE + 2^{31} - 1|$  modulo  $2^{64}$  ;
    - il registro indice viene tipicamente utilizzato per gli array, i cui elementi possono essere lunghi 1, 2, 4 oppure 8 byte.
  - caricamento del registro base:
    - si effettua con l'istruzione MOVABSQ con un operando immediato di 64 bit, che può rappresentare qualunque indirizzo di memoria.
- **Indirizzo relativo:**
  - a partire dal contenuto del registro RIP, consente di indirizzare una zona di memoria che va da  $|RIP - 2^{31}|$  modulo  $2^{64}$  a  $|RIP + 2^{31} - 1|$  modulo  $2^{64}$ .

# Organizzazione della memoria

- **Organizzazione hardware della memoria:**
  - a linee, di 8 byte ciascuna;
  - si possono leggere o scrivere in un solo ciclo uno o più byte della stessa linea;
  - il tempo di accesso riguarda l'intera linea (è lo stesso qualunque sia il numero di byte della linea letto o scritto).

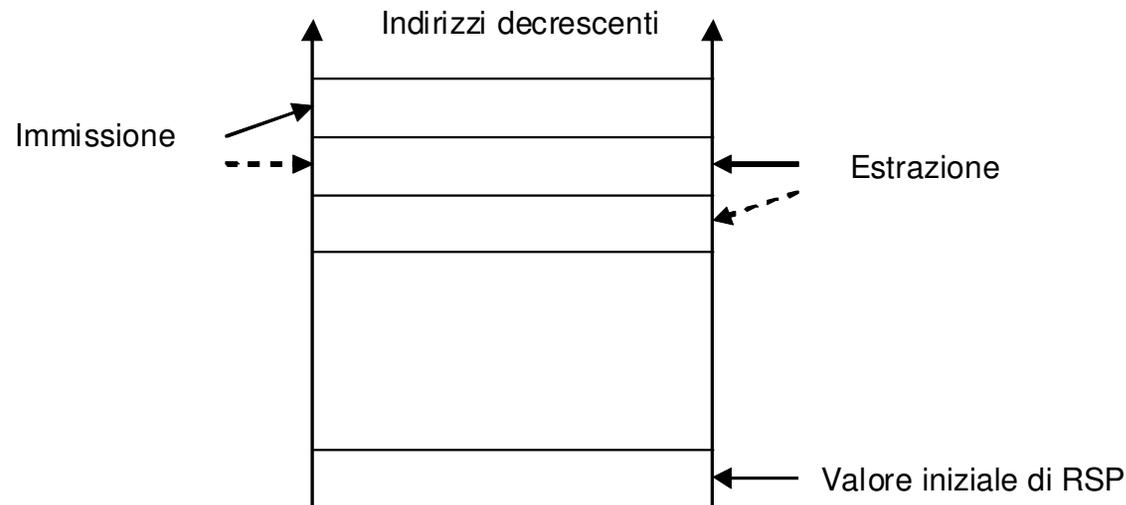


# Indirizzo di istruzioni e di operandi

- **Istruzioni:**
  - l'indirizzo di un'istruzione è quello del primo byte del Codice Operativo.
    - le istruzioni non possono venir allineate (sono memorizzate in sequenza);
  - vengono prelevate a linee, e poi separate all'interno del processore, e viene effettuata la gestione dei salti (vedi "Struttura interna del processore").
- **Operandi:**
  - lunghi 1, 2, 4 o 8 byte;
  - i byte dell'operando sono memorizzati in ordine inverso;
  - l'indirizzo dell'intero operando è quello del byte meno significativo dell'operando stesso.
- **Allineamento degli operandi:**
  - un operando può stare a partire da qualunque indirizzo di memoria;
  - viene in genere allineato a indirizzi multipli della sua lunghezza, in modo che sia memorizzato in un sola linea, così da minimizzare il tempo richiesto per l'accesso all'operando stesso.

# La Pila

- **Pila:**
  - organizzata a 64 bit, utilizzando come puntatore il registro RSP;
  - immissione (PUSHQ, CALL, ...): decremento di 8 di RSP, quindi scrittura nella parola quadrupla indirizzata da RSP;
  - estrazione (POPQ, RET, ...): lettura della parola quadrupla indirizzata da RSP, quindi incremento di 8 di RSP.
- **Registro base per indirizzare locazioni della pila: RBP.**



# UNIX e ambiente di programmazione GCC

- **Ambiente di programmazione GCC (GNU Compiler Collection):**
  - collezione di software di sviluppo del sistema GNU;
  - comprende l'Assemblatore, il Compilatore C, il Compilatore C++, il Collegatore, il Caricatore.
  - può essere utilizzato in un calcolatore con processore INTEL x86-64 e sistema operativo UNIX.
- **Programma Assembler:**
  - costituito, oltre che da commenti, da istruzioni, pseudo-istruzioni (per definire operandi), direttive (comandi per l'Assemblatore);
  - può utilizzare i servizi UNIX (*primitive*), in particolare quelli per leggere da tastiera e per scrivere su video.
  - i letterali si scrivono come in C++.

# Assembler GCC (1)

- **Forma di un commento:**
  - dal carattere # alla fine della linea corrente
- **Forma di un'istruzione Assembler:**

*identificatore:      codice-operativo      sorgente, destinatario*

  - **identificatore, sorgente, destinatario:** possono anche mancare;
  - **identificatore:**
    - rappresenta un indirizzo simbolico;
    - lettere minuscole o lettere maiuscole sono differenti.
  - **codice operativo:**
    - specifica l'operazione e la lunghezza degli operandi (b: byte; w: parola; l: parola lunga; q: parola quadrupla);
    - lettere minuscole o lettere maiuscole sono equivalenti.
  - **operandi (sorgente e destinatario):**
    - %: specifica il nome di un registro;
    - \$: specifica un operando immediato;
    - \*: specifica un'indirizione (istruzioni *jmp* e *call*);
    - nel nome di un registro, lettere minuscole o lettere maiuscole sono equivalenti.

## Assembler GCC (2)

- **Forma di una pseudo-istruzione Assembler:**

*identificatore: codice operandi*

- l'identificatore può anche mancare;
  - rappresenta un indirizzo simbolico;
  - lettere minuscole o lettere maiuscole sono differenti;
- il codice inizia con . (punto) ;
  - lettere minuscole o lettere maiuscole sono equivalenti.

- **Esempi di pseudo-istruzioni più utilizzate :**

<b>.byte</b>	<b>valore</b>	<b># numero naturale o intero di 8 bit, o letterale carattere</b>
<b>.word</b>	<b>valore</b>	<b># numero naturale o intero di 16 bit</b>
<b>.long</b>	<b>valore</b>	<b># numero naturale o intero di 32 bit</b>
<b>.quad</b>	<b>valore</b>	<b># numero naturale o intero di 64 bit</b>
<b>.space</b>	<b>numero-byte</b>	
<b>.fill</b>	<b>numero-componenti, numero-byte-per-componente</b>	
<b>.ascii</b>	<b>letterale stringa</b>	

- **Osservazione:**

- le prime 4 pseudo-istruzioni consentono di memorizzare o un numero naturale o la codifica di un numero intero in complemento a 2, rispettando gli intervalli di rappresentazione;
- ricordare che nella codifica dei numeri interi in complemento a 2, le operazioni di somma e sottrazione sui numeri interi si effettuano con le stesse operazioni sulle loro codifiche.

# Assembler GCC (3)

- **Forma di una direttiva Assembler:**

*codice*            *operandi*

- **il codice inizia con . (punto);**

- lettere minuscole o lettere maiuscole sono equivalenti.

- **Esempi di direttive più utilizzate:**

<b>.text</b>		<b># sezione testo</b>
<b>.data</b>		<b># sezione dati</b>
<b>.include</b>	<b>&lt;id_file&gt;</b>	<b># identificatore del file di libreria da includere</b>
<b>.include</b>	<b>"id_file"</b>	<b># identificatore del file utente da includere, # con eventuale percorso</b>
<b>.global</b>	<b>identificatore, ...</b>	<b># identificatore globale (vedi slide successive)</b>
<b>.globl</b>	<b>identificatore, ...</b>	<b># come sopra</b>
<b>.extern</b>	<b>identificatore, ...</b>	<b># identificatore esterno (vedi slide successive)</b>
<b>.align</b>	<b>n</b>	<b># allineamento a un indirizzo multiplo di n, potenza di 2</b>
<b>.balign</b>	<b>n</b>	<b># come sopra</b>

## Assembler GCC (4)

- **Espressione Assembler:**
  - **contiene valori numerici e identificatori (simbolici);**
    - **espressione-indirizzo: contiene almeno un identificatore (simbolico).**
- **Fase di traduzione del programma (traduzione vera e propria e collegamento):**
  - **agli identificatori viene fatto corrispondere un valore numerico (indirizzo di memoria);**
  - **un'espressione produce un risultato numerico.**

# Assembler GCC (5)

- **Istruzioni operative con indirizzo di memoria assoluto:**
  - **indicazione Assembler dell'indirizzo dell'operando in memoria:**  
*spiazzamento( base, indice, scala)*
    - *spiazzamento*: espressione che viene calcolata in fase di traduzione, il cui risultato viene memorizzato nel campo DISP dell'istruzione macchina;
    - *base e indice*: registri generali a 64 bit;
    - *scala*: numero naturale che può valere 1, 2, 4, 8, e se viene omesso vale 1.
- **Esempi:**

<code>movl spiazzamento, %lreg</code>	ind. diretto
<code>movl (%rbase), %lreg</code>	ind. indiretto
<code>movl spiazzamento(%rbase), %lreg</code>	ind. modificato con registro base
<code>movl spiazzamento(, %rind, 4), %lreg</code>	ind. modificato con registro indice
<code>movl (%rbase, %rind, 4), %lreg</code>	ind. bimodificato senza displacement
<code>movl spiazzamento(%rbase, %rind, 4), %lreg</code>	ind. bimodificato con displacement

## Assembler GCC (6)

- **Registri base e indice:**
  - se il registro base e il registro indice sono assenti, il campo **DISP** rappresenta l'indirizzo dell'operando in memoria, che può spaziare in una zona limitata ;
  - il registro base può essere caricato con un operando immediato (istruzione *movabsq*), costituito da un qualunque espressione indirizzo, in particolare da un identificatore *ind*, consentendo di indirizzare qualunque operando di memoria:

```
movabsq  $ind,  %rreg  
movl     (%rreg), %reg
```

## Assembler GCC (7)

- **Istruzioni operative con indirizzamento di memoria relativo:**
  - **indicazione Assembler dell'indirizzo dell'operando in memoria:**  
`movl ind( %rip), lreg`
    - *ind* è un'espressione che individua (nel caso più semplice coincide con) l'identificatore dell'operando
    - in fase di traduzione, viene calcolato il valore del campo **DISP** dell'istruzione macchina come *ind* – *rip*;
    - si può indirizzare un operando solo in una zona limitata a cavallo di **RIP**

## Assembler GCC (8)

- **Istruzioni di salto con indirizzamento di memoria relativo:**
  - indicazione Assembler dell'indirizzo di salto:  
`jmp ind` (RIP è implicito)
    - *ind* è un'espressione che individua (nel caso più semplice coincide con) l'identificatore dell'istruzione a cui avviene il salto;
    - in fase di traduzione, viene calcolato il valore del campo DISP dell'istruzione macchina come *ind - rip*
    - si può saltare solo in una zona limitata a cavallo di RIP.
- **Istruzioni di salto indiretto (solo *jmp* e *call*):**
  - `movabsq $ind, %rax`  
`call *%rax`
  - il registro può venir caricato con l'istruzione *movabsq*, per cui si può saltare a qualunque indirizzo.

# Modello PIC

- **Programmi Assembler sviluppati nel seguito:**
  - utilizzazione del modello PIC (*Position Independent Code*).
- **Istruzioni operative:**
  - operando di memoria individuato da un identificatore:
    - utilizzo dell'indirizzamento relativo rispetto a RIP.
- **Istruzioni di controllo:**
  - indirizzo di salto individuato da un identificatore:
    - utilizzo dell'indirizzamento relativo rispetto a RIP.
- **Programmi indipendenti dalla posizione:**
  - tutte le espressioni indirizzo *ind* vengono tradotte come  $DISP = ind - RIP$ , per cui **DISP** rimane costante con lo spostamento di tutto il programma.

# Struttura di un semplice programma Assembler (1)

- **Programma Assembler:**
  - costituito da due sezioni, una sezione dati (statici) e una sezione testo, oltre che dalla pila e dalla memoria dinamica (*heap*), contenenti dati temporanei (tipicamente, creati e distrutti dinamicamente);
  - memorizzato su uno o più file, ciascuno detto *file sorgente*.
    - in ogni file, sono presenti nessuna, una o più parti della sezione dati (ciascuna inizia con la pseudo-istruzione *.data*), e nessuna, una o più parti della sezione testo (ciascuna inizia con la pseudo-istruzione *.text*).
- **Inizio del programma:**
  - identificatore *\_start*, che deve essere dichiarato globale (direttiva *.global*).
- **Fine del programma:**
  - risultato per il Sistema Operativo UNIX: va lasciato nel registro EBX;
    - per convenzione, quando vale 0 tutto si è svolto correttamente, mentre quando è diverso da 0, il valore costituisce la codifica di un errore.
  - il valore di ritorno precedente è visibile (utilizzando il linguaggio di script *bash*) attraverso la variabile *\$?* (comando per vederne il valore: *echo \$?*).
- **Istruzioni di ritorno a UNIX:**

```
movl    ..., %ebx
movl    $1, %eax          # numero d'ordine della primitiva UNIX exit
int     $0x80            # servizio UNIX 0x80
```

## Struttura di un semplice programma Assembler (2)

```
.data
    ...
    dati
    ...

.text
# sottoprogramma
sottop:    ...
          ret

# programma principale
.global   _start
_start:   ...
          call    sottop
          ...

uscita:   movl    ..., %ebx
          movl    $1, %eax
          int     $0x80
```

# Sviluppo di un programma Assembler (1)

- **Un file sorgente:**
  - deve avere estensione *s*;
  - viene tradotto separatamente dagli altri, dando luogo a un nuovo file, il file *oggetto* (estensione *o*).
- **Traduzione:**
  - avviene attraverso il programma *Assemblatore*;
  - comando (l'opzione *-o* specifica il nome del file oggetto, che deve avere estensione *o*):  

```
as id_file.s -o id_file.o
```
- **File listato (contiene anche la traduzione provvisoria):**
  - viene generato con l'opzione *-a*:  

```
as id_file.s -o id_file.o -a > id_file.l
```
  - l'eventuale ridirezione *> id\_file.l* fa sì che l'uscita standard del comando *as* non sia *cout* (comunemente associato al terminale), ma il file specificato.

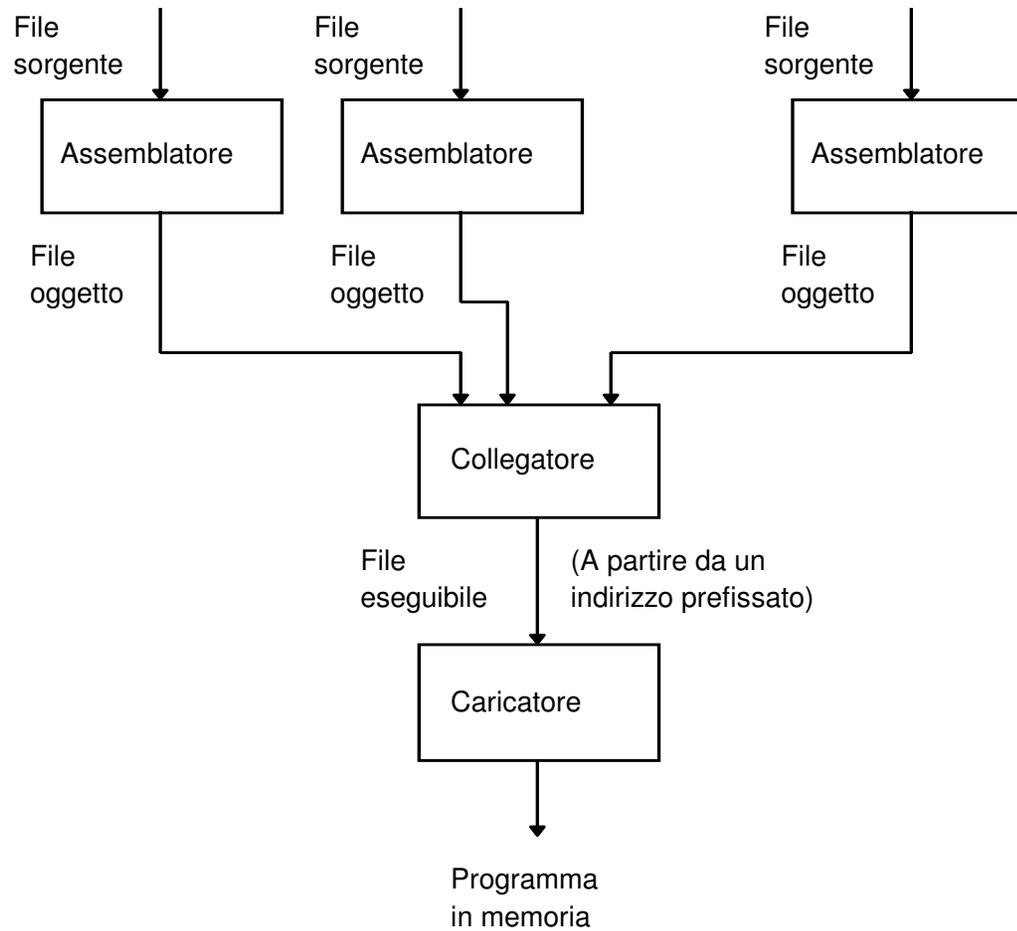
## Sviluppo di un programma Assembler (2)

- **File oggetto ottenuti dalle traduzioni:**
  - devono essere collegati insieme per formare un unico file *eseguibile* (senza estensione);
  - programma eseguibile (contenuto nel file eseguibile):
    - viene composto a partire da determinati indirizzi della sezione dati e della sezione testo;
    - se tutti gli indirizzi di memoria sono relativi a *rip*, il programma eseguibile è *indipendente dalla posizione*.
- **Collegamento:**
  - avviene attraverso il programma *Collegatore (Linker)*;
  - comando (l'opzione *-o* specifica il nome del file eseguibile, che non ha estensione):  
`ld id_file1.o .... id_fileN.o -o id_file`
  - l'opzione *-o* può essere omessa, ed in questo caso l'identificatore del file eseguibile è per default *a.out* (non esistendo l'estensione, tutti i caratteri presenti costituiscono l'identificatore del file).
- **File mappa (contiene informazioni di collegamento):**
  - viene generato con l'opzione *-M*:  
`ld id_file.o -o id_file -M > id_file.m`
  - l'eventuale ridirezione `> id_file.m` fa sì che l'uscita standard del comando *ld* non sia *cout* (comunemente associato al terminale), ma il file specificato.

## Sviluppo di un programma Assembler (3)

- **Rilocazione e Caricamento:**
  - il programma collegato, eventualmente rilocato se le sezioni `.text` e `.data` vengono allocate in zone indipendenti della memoria, poi caricato in memoria, e quindi eseguito;
  - comando:  
    `./id_file`
  - la rilocazione non avviene se tutti gli indirizzi di memoria sono relativi a *rip*.
- **Esecuzione del programma:**
  - il Caricatore:
    - inizializza il puntatore di pila;
    - pone in pila il valore del nuovo contatore di programma (corrispondente all'identificatore `_start`), e di altri registri (CPL ed EFLAGS trattati in seguito);
    - esegue l'istruzione IRET.
- **Programma costituito da un solo file:**
  - viene sviluppato secondo le fasi sopra elencate;
  - il collegamento viene comunque effettuato, eventualmente con alcuni programmi di libreria, già tradotti una volta per tutte.
- **Fase di traduzione (in senso lato):**
  - costituita dalla traduzione vera e propria, dal collegamento, ed eventualmente dalla rilocazione.

# Rappresentazione grafica



# File *ser.s* (1)

- **Contiene due sottoprogrammi *tastiera* e *video*:**
  - *tastiera*: legge il successivo carattere battuto a tastiera e pone il suo codice ASCII nel registro AL;
  - *video*: scrive su video il carattere il cui codice ASCII è contenuto in BL;
  - *tastiera* e *video* utilizzano il servizio UNIX 0x80, con opportuni parametri in RAX, RBX, RCX, RDX.
- **Contiene una routine *uscita*:**
  - restituisce il controllo al Sistema Operativo (registro ebx: se contiene 0. non ci sono stati errori), utilizzando anch'essa il servizio UNIX 0x80:

```
uscita:  movl    $0, %ebx
         movl    $1, %eax
         int     $0x80
```
- **Sottoprogrammi *tastiera* e *video*: effettuano ingresso/uscita a linee (il servizio UNIX 0x80 gestisce l'I/O in modo bufferizzato):**
  - i caratteri battuti a tastiera, che compaiono in eco su video, vengono effettivamente letti quando da tastiera viene premuto il tasto *Enter*:
    - in lettura, *Enter* viene riconosciuto come carattere '\n' (nuova linea);
  - i caratteri inviati su video vengono effettivamente visualizzati quando viene inviato su video il carattere '\n' (nuova linea):
    - viene automaticamente inserito anche il carattere '\r' (ritorno carrello).

## File *ser.s* (2)

- File *ser.s* (da includere nei programmi Assembler):

```
# file ser.s
.data
buff:      .byte 0
.text
tastiera:
    ...
    ret
video:
    ...
    ret
uscita:   movl $0, %ebx    # restituisce 0
          movl $1, %eax    # primitiva exit
          int  $0x80
```

- Sottoprogrammi tastiera e video:
  - salvano e ripristinano i registri utilizzati.

# Lettura di un carattere

- **Lettura di un carattere da tastiera e suo trasferimento in AL:**
  - **utilizzo del servizio UNIX 0x80, con parametri in RAX, RBX, RCX, RDX.**

tastiera:

```
pushq %rbx
pushq %rcx
pushq %rdx
movq $3, %rax          # primitiva read
movq $0, %rbx          # ingresso standard
leaq buff(%rip), %rcx  # indirizzo buffer di ingresso
movq $1, %rdx          # numero di byte da leggere
int $0x80
movb buff(%rip), %al
popq %rdx
popq %rcx
popq %rbx
ret
```

## Scrittura di un carattere

- **Scrittura su video del carattere contenuto in BL:**
  - **utilizzo del servizio UNIX 0x80, con parametri RAX, RBX, RCX, RDX.**

**video:**

```
pushq %rax
pushq %rbx
pushq %rcx
pushq %rdx
movb %bl, buff(%rip)
movq $4, %rax          # primitiva write
movq $1, %rbx         # uscita standard
leaq buff(%rip), %rcx # indirizzo buffer di uscita
movq $1, %rdx         # numero byte da scrivere
int $0x80
popq %rdx
popq %rcx
popq %rbx
popq %rax
ret
```

# Programma *codifica* (1)

```
# programma codifica, file codifica.s
.include "ser.s"
.text
.global _start
_start:
ancora: call    tastiera
        cmpb   $'\n', %al          # carattere nuova linea
        je     fine                # carattere letto
        movb  %al, %bl
        call  video
        movb  $' ', %bl           # carattere spazio
        call  video
```

## Programma *codifica* (2)

```
ciclo:    movb    $0, %cl          # cl funge da contatore
          testb   $0x80, %al    # esame del bit piu' significativo di al
          jz     zero
          movb   $'1', %bl
          call   video
          jmp    avanti
zero:     movb   $'0', %bl
          call   video
avanti:   shlb   $1, %al        # traslazione sinistra di al
          incb   %cl
          cmpb   $8, %cl
          jb     ciclo
          movb   $'\n', %bl     # carattere nuova riga
          call   video
fine:     jmp    ancora
          jmp    uscita
```

## Programma *codifica* (3)

- **File precedente:**
  - deve essere prima tradotto;
  - il file tradotto deve essere poi collegato.
- **Questo si ottiene con i comandi:**
  - `as codifica.s -o codifica.o`
  - `ld codifica.o -o codifica`
- **Il file eseguibile (*codifica*) può essere caricato e mandato in esecuzione con il comando:**
  - `./codifica`

## Identificatori esterni e globali (o pubblici)

- **In un file si possono utilizzare identificatori definiti in altri file:**
  - tali identificatori, per chiarezza, possono essere dichiarati esplicitamente *esterni*.
    - se non vengono esplicitamente dichiarati esterni, vengono implicitamente considerati tali;
  - identificatori dichiarati esterni:
    - si utilizza la direttiva *.extern*:  
*.extern identificatore, ...*
- **Alcuni identificatori definiti in un file possono essere utilizzati da altri file:**
  - tali identificatori, obbligatoriamente, vanno dichiarati globali;
  - identificatori dichiarati globali:
    - si utilizza la direttiva *.global* (o *.globl*):  
*.global identificatore, ...*

# Punto di inizio

- **File sorgente Assembler:**
  - contiene uno spezzone di programma, che può prevedere il punto di inizio (*entry\_point*) dell'intero programma (identificatore *\_start*).
- **File principale:**
  - contiene *l'entry\_point*;
  - ne deve esistere uno e uno solo.
- **File secondari:**
  - altri file.
- **Situazione comune:**
  - il file principale contiene alcuni dati e il programma principale, con alcuni sottoprogrammi, mentre un file secondario contiene solo altri dati e altri sottoprogrammi.
- **Indirizzo iniziale (identificatore *\_start*):**
  - occorre dichiararlo globale, per renderlo visibile al Caricatore (consentendo ad esso di trasferire tale indirizzo in pila, e quindi, tramite l'istruzione IRET, di inizializzare opportunamente il registro RIP).
- **In un file, gli identificatori non dichiarati globali sono propri di quel file:**
  - uno stesso identificatore può essere utilizzato in file diversi e identifica entità diverse.

# Registri

- **Chiamante e registri:**
  - può lasciarvi informazioni, purché non vengano alterate dal programma chiamato.
- **Chiamato e registri:**
  - può utilizzarli per memorizzarvi informazioni, purché non contengano dati utili al chiamante.
- **Convenzioni:**
  - in genere, nella realizzazione di programmi su più file, il sistema di sviluppo stabilisce convenzioni sui registri utilizzabili dal chiamante e dal chiamato.
- **Convenzione *certamente sicura*:**
  - il chiamante non lascia informazioni nei registri, ma solo in locazioni di memoria, presupponendo che il chiamato utilizzi qualunque registro;
  - il chiamato salva e poi ripristina il valore dei registri utilizzati.
- **Programmi sviluppati nelle slide di questo capitolo:**
  - utilizzano la convenzione *certamente sicura*.

# Programma *codifica1* (1)

- **Programma *codifica1*:**
  - due file: il primo contiene il programma principale, il secondo il sottoprogramma *esamina*, utilizzato dal primo file.
- **Programma principale:**
  - legge caratteri fino al fine linea;
  - per ogni carattere, oltre a stamparlo, richiama il sottoprogramma *esamina*, quindi stampa il risultato prodotto da quest'ultimo.
- **Sottoprogramma *esamina*:**
  - restituisce otto caratteri, corrispondenti agli 8 bit della codifica del carattere ricevuto.
- **Trasmissione dei dati fra programma e sottoprogramma:**
  - due variabili *alfa* e *beta* definite nel secondo file (esterne nel primo file e globali nel secondo);
    - *alfa*: contiene il codice del carattere, che il sottoprogramma deve esaminare;
    - *beta*: contiene l'indirizzo di una variabile array di 8 byte dove il sottoprogramma deve porre il risultato.
  - il programma principale pone i dati in *alfa* e *beta*, quindi chiama *esamina*.

## Programma *codifica1* (2)

```
# programma codifica1, file codifica1a.s
#include "ser.s"
# .extern  alfa, beta, esamina
.data
kappa:   .fill      8, 1

.text
.global  _start
_start:
ancora:  call       tastiera
         cmpb      '$\n', %al
         je        fine
         movb     %al, %bl
         call     video
         movb     '$ ', %bl
         call     video
         movb     %al, alfa(%rip)
         leaq    kappa(%rip), %rax
         movq    %rax, beta(%rip)
         call    esamina

         leaq    kappa(%rip), %rax
         movq    $0, %rsi
ripeti:  movb    (%rax, %rsi), %bl
         call    video
         incq    %rsi
         cmpq    $8, %rsi
         jb     ripeti
         movb    '$\n', %bl
         call    video
         jmp     ancora
fine:    jmp     uscita
```

## Programma *codifica1* (3)

```
# programma codifica1, file codifica1b.s
.data
.global   alfa, beta
alfa:     .byte    0
beta:     .quad   0

.text
.global   esamina
esamina:  pushq    %rax
          pushq    %rbx
          pushq    %rsi
          movb     alfa(%rip), %al    # I dato
          movq     beta(%rip), %rbx   # II dato
          movq     $0, %rsi
ciclo:    testb    $0x80, %al
          jz       zero
          movb     $'1', (%rbx, %rsi)
          jmp      avanti
zero:     movb     $'0', (%rbx, %rsi)
```

```
avanti:   shlb     $1, %al
          incq     %rsi
          cmpq    $8, %rsi
          jb      ciclo
          popq    %rsi
          popq    %rbx
          popq    %rax
          ret
```

## Programma *codifica1* (4)

- **File precedenti:**
  - devono essere prima tradotti;
  - i file tradotti devono essere poi collegati.
- **Questo si ottiene con i comandi:**
  - as `codifica1a.s -o codifica1a.o`
  - as `codifica1b.s -o codifica1b.o`
  - ld `codifica1a.o codifica1b.o -o codifica1`
- **Il file eseguibile (*codifica1*) può essere caricato e mandato in esecuzione con il comando:**
  - `./codifica1`

# Comando `g++` (1)

- **Il comando:**

`g++ id_file1.s ... id_fileN.s -o id_file`

- richiama singolarmente l'Assemblatore per i file *id\_file1.s*, ..., *id\_fileN.s*, producendo *N* file oggetto aventi uguale identificatore ed estensione *o*;
- richiama il Collegatore per gli *N* file oggetto precedenti e alcuni file di libreria, producendo il file eseguibile *id\_file*;
- l'opzione `-o id_file` può essere omessa, ed in questo caso l'identificatore del file eseguibile è *a.out*.

## Comando g++ (2)

- **Uno dei file di libreria collegati:**
  - contiene l'entry\_point *\_start* (identificatore esplicitamente dichiarato globale);
  - richiama il sottoprogramma *main()* (identificatore esterno);
    - il sottoprogramma *main()* produce un risultato intero che lascia in EAX;
  - al ritorno dal sottoprogramma *main()*, restituisce il controllo a UNIX con le istruzioni:

```
movl    %eax, %ebx
movl    $1, %eax
int     $0x80
```
  - utilizzando il comando g++, occorre pertanto organizzare il programma principale come un sottoprogramma, avente identificatore *main* e che lascia il risultato in EAX.
- **Organizzazione del programma principale:**

```
.data
...
.text
.include "ser.s"
.global main
main:
...
movl $0, %eax
ret
```

# Programma *codifica2* (1)

```
# programma codifica2, file codifica2a.s
.include "ser.s"
# .extern  alfa, beta, esamina
.data
kappa:   .fill      8, 1

.text
.global  main
main:
ancora:  call        tastiera
         cmpb       $'\n', %al
         je         fine
         movb      %al, %bl
         call      video
         movb      $' ', %bl
         call      video
         movb      %al, alfa(%rip)
         leaq     kappa(%rip), %rax
         movq     %rax, beta(%rip)
         call     esamina

ripeti:  leaq     kappa(%rip), %rax
         movl     $0, %rsi
         movb     (%rax, %rsi), %bl
         call     video
         incq    %rsi
         cmpq    $8, %rsi
         jb     ripeti
         movb     $'\n', %bl
         call     video
         jmp     ancora
fine:    movl     $0, %eax
         ret
```

## Programma *codifica2* (2)

```
# programma codifica2, file codifica2b.s
# uguale al file secondario codifica1b.s
.data
.global   alfa, beta
alfa:     .byte    0
beta:     .quad   0

.text
.global   esamina
esamina:  pushl    %rax
          ...
          ret
```

- **Sviluppo ed esecuzione del programma:**

```
g++ codifica2a.s codifica2b.s -o codifica2
./codifica2
```

# Programmi C++ su più file

- **Regole di collegamento semplificate:**
  - in un file, gli identificatori delle variabili definite al di fuori delle funzioni e gli identificatori di funzioni:
    - sono implicitamente globali;
  - in un file si possono riferire identificatori definiti in altri file, purché:
    - siano esplicitamente dichiarati esterni;
    - siano globali nei file dove sono definiti.
- **Dichiarazione di identificatori esterni (simbolo *extern*):**
  - **variabile:**  
`extern type var1, var2 ...;`
  - **nella dichiarazione di una funzione:**  
`extern type fun(type1,..., typeN);`
  - **nella definizione di una funzione:**  
`extern type fun(type1 par1,..., typeN parN) { }`
  - per le funzioni (dichiarazione o definizione), il simbolo *extern* può essere omissso.

# Programmi misti (1)

- **Programma GCC organizzato su più file:**
  - può essere scritto utilizzando linguaggi *differenti* per i vari file (Assembler, C, C++);
  - ciascun file viene tradotto con il proprio traduttore, e tutti i traduttori producono file oggetto della stessa forma;
  - viene utilizzato un unico Collegatore, che produce il programma eseguibile.
- **GCC, comando `g++`:**
  - richiama i traduttori per i vari file;
    - singoli file con estensione *c*: richiama il Compilatore C;
    - singoli file con estensione *cc* o *cpp*: richiama il compilatore C++;
  - il compilatore richiamato produce un file Assembler, avente lo stesso identificatore di quello tradotto e estensione *s*;
  - singoli file con estensione *s*, compresi quelli generati nei punti precedenti:
    - richiama l'Assembler, che produce un file avente lo stesso identificatore di quello tradotto e estensione *o*;
  - richiama il Collegatore, inserendo anche il file di libreria che contiene l'entry point `_start` e, se inclusi, i file della libreria di I/O.

## Programmi misti (2)

- **Compilatori C/C++ (traducono in Assembler):**
  - inseriscono le variabili globali, non modificando i loro identificatori, nella sezione dati;
  - inseriscono le funzioni nella sezione testo: il compilatore C non modificando i loro identificatori, il compilatore C++ modificandoli;
  - utilizzano determinati standard per l'aggancio delle funzioni;
    - i parametri e le variabili locali delle funzioni coinvolgono registri e locazioni della pila.
- **Intero programma:**
  - consistente solo se i differenti linguaggi utilizzati:
    - fanno uso della stessa modalità di rappresentare i dati;
    - utilizzano gli stessi identificatori;
    - utilizzano lo stesso standard per l'aggancio delle funzioni (in Assembler, sottoprogrammi).
- **Linguaggio C++ e Assembler:**
  - i file Assembler (che consentono di avere notevole elasticità) dovranno utilizzare le stesse regole del compilatore C++ (che invece possiede convenzioni rigide) .

# Identificatori C e Identificatori C++

- **Identificatori di variabili e di funzioni C:**
  - sono uguali agli identificatori Assembler.
- **Identificatori di variabili C++:**
  - sono uguali agli identificatori Assembler (come per il C).
- **Identificatori di funzioni C++:**
  - per assicurare la possibilità di avere *overloading*, vengono tradotti con identificatori Assembler ottenuti secondo regole che tengono conto del numero, del tipo e dell'ordine degli argomenti formali;
  - possono essere tradotti con gli stessi identificatori Assembler (avere la corrispondenza del compilatore C), purché vengano dichiarati (in dichiarazioni o definizioni di funzioni) *extern "C"*.
- **Ipotesi per gli identificatori di funzione:**
  - al momento, verrà utilizzata la corrispondenza C (uguaglianza di identificatori), rinunciando ad avere *overloading*;
    - tale corrispondenza non può essere applicata alle funzioni membro di classi, non essendo le classi previste in C;
  - in un secondo momento, verranno illustrate le regole seguite dal compilatore C++.

## Identificatori di funzioni C++ uguali agli identificatori C (e Assembler)

- **Identificatori delle funzioni C++ tradotti come se fossero identificatori di funzioni C:**
  - nelle dichiarazioni e nelle definizioni occorre aggiungere la specifica *extern "C"*;
  - pertanto:
    - le funzioni esterne C++ vanno dichiarate, prima di essere utilizzate, nel seguente modo:  
extern "C" type fun( ...);
    - le funzioni globali C++ vanno definite nel seguente modo:  
extern "C" type fun( ... )  
{ // ...  
}
- **Corpi delle funzioni C++:**
  - non vengono modificati dalla specifica *extern "C"*;
- **La funzione C++ *main()* è implicitamente definita *extern "C"*.**

# Dati discreti (non reali) in C++

- **Tipi di dato considerati:**
  - tipo *int*: 4 byte, in complemento a 2;
  - tipo *long int*: 8 byte, in complemento a 2;
  - tipo *bool*: un byte, con l'intero 0 equivalente a *false* e l'intero 1 equivalente a *true*;
  - tipo *char*: un byte, in codifica ASCII (il bit più significativo vale 0);
  - tipi *enumerati*: un tipo *int*, con il valore di ogni enumeratore dato dal suo numero d'ordine, a partire da 0;
  - tipi *riferimento*: 8 byte (indirizzo completo di memoria);
  - tipi *puntatore*: 8 byte (indirizzo completo di memoria);
  - tipi *array* (monodimensionale): codifica dei singoli elementi;
  - tipi *struttura o unione*: codifica dei singoli campi;
  - tipi *classe*: codifica dei singoli campi dato (come un tipo struttura).

# Allineamento delle variabili (semplificato)

- **Variabili singole:**
  - allineate a indirizzi multipli della loro lunghezza (2, 4, 8);
- **Variabile di un tipo array:**
  - allineata come richiesto dal primo elemento;
  - all'interno dell'array, tutti gli elementi sono in sequenza.
- **Variabile di un tipo struttura o unione:**
  - allineata come il campo avente vincoli maggiori;
    - all'interno della struttura, ogni campo è allineato secondo i suoi vincoli.
- **Variabile di un tipo classe:**
  - allineata come richiesto dall'insieme dei campi dato, considerati come struttura;
    - all'interno dei campi dato della classe, ogni campo è allineato secondo i suoi vincoli.
- **Allineamento in pila:**
  - variabili più lunghe di 4 byte, allineate a indirizzi multipli di 8.

# Programma misto *codifica3* (1)

```
// programma codifica3, file codifica3a.cpp
using namespace std;
#include <iostream>
extern char alfa;
extern char* beta;
extern "C" void esamina();
char kappa[8];
int main()
{   char al;
    for(;;)
    {   cin.get(al);
        if (al == '\n') break;
        cout << al << ' ';
        alfa = al; beta = &kappa[0];      // anche beta = kappa;
        esamina();
        for (int i=0; i<8; i++) cout << kappa[i];
        cout << endl;
    };
    return 0;
}
```

## Programma misto *codifica3* (2)

```
# programma codifica3, file codifica3b.s, uguale al file codifica2b.s
.data
.global    alfa, beta
alfa:     .byte    0
beta:     .long    0

.text
.global esamina
esamina:  pushl    %eax
          ...
          ret
```

## Programma misto *codifica4* (1)

```
# programma codifica4, file codifica4a.s, uguale al file codifica2a.s
.include "ser.s"
# .extern  alfa, beta, esamina
.data
kappa:   .fill      8, 1
.text
.global  main
main:
ancora:  call       tastiera
        ...
fine:    movl      $0, %eax
        ret
```

## Programma misto *codifica4* (2)

```
// programma codifica4, file codifica4b.cpp
char alfa;
char* beta;
extern "C" void esamina()
{   for(int i = 0; i < 8; i++)
    { if ((alfa & 0x80) == 0)
        *(beta+i) = '0'; else *(beta+i) = '1'; // anche beta[i]
      alfa = alfa<<1;
    }
}
```

# Programma *codifica5*

```
// programma codifica5, file codifica5a.cpp: uguale al file codifica3a.cpp
using namespace std;
#include <iostream>
extern char alfa;
extern char* beta;
extern "C" void esamina();
char kappa[8];
int main()
{
    ...
}
```

```
Programma codifica5, file codifica5b.cpp: uguale al file codifica4b.cpp
char alfa;
char* beta;
extern "C" void esamina()
{
    ...
}
```

## Sviluppo delle versioni miste 3 e 4 e della versione 5

- **Sviluppo della versione 3**

```
g++ codifica3a.cpp codifica3b.s -o codifica3  
./codifica3
```

- **Sviluppo della versione 4:**

```
g++ codifica4a.s codifica4b.cpp -o codifica4  
./codifica4
```

- **Sviluppo della versione 5:**

```
g++ codifica5a.cpp codifica5b.cpp -o codifica5  
./codifica5
```

# Modelli di memoria

- **Parti di un programma:**
  - come detto sono 4, ossia sezione *.text*, sezione *.data*, *pila*, *heap*;
  - la pila e lo heap possono essere memorizzati ovunque (a indirizzi canonici), poiché vengono indirizzati (con un indirizzo assoluto) utilizzando un registro base (la pila viene indirizzata tramite i registri RSP o RBP e la zona per la memoria dinamica tramite puntatori).
- **Modello grande:**
  - la sezione *.text* e la sezione *.data* possono essere memorizzate ovunque (ovviamente, a indirizzi canonici).
- **Modello PIC (*Position Independent Code*):**
  - la sezione *.text* e la sezione *.data* devono essere memorizzate in non più di 2 Gbyte consecutivi di memoria, posizionati ovunque (ovviamente, a indirizzi canonici).
- **Modello piccolo:**
  - la sezione *.text* e la sezione *.data* devono essere memorizzate nei primi 2 Gbyte di memoria.
- **Istruzioni e modelli:**
  - con il modello grande, viene utilizzata l'istruzione *movabsq* per caricare un registro base oppure per effettuare un salto indiretto (non condizionato);
  - con il modello PIC, per le istruzioni operative con indirizzamento simbolico di operando e per le istruzioni di controllo viene utilizzato l'indirizzamento di memoria relativo;
  - con il modello piccolo, per le istruzioni operative può essere utilizzato anche il campo *DISP*, e per le istruzioni di controllo viene utilizzato l'indirizzamento relativo.

# Modelli di memoria: esempio (1)

- Programma C++:

```
int i; int ar[8];
extern "C" void fai()
{ }
int main
{
    ...
    i = 5;
    ar[i] = 10;
    fai();
    ...
}
```

```
# modello grande
# variabili i e ar indirizzate con registro base
# funzione fai chiamata con una call indiretta
.data
i:      .long      0
ar:     .fill     8, 4
.text
.global fai
fai:    ...
.global main
main:   ...
        movabsq   $i, %rax
        movl     $5, (%rax)
        movabsq   $ar, %rax
        movabsq   $i, %rbx
        movslq   (%rbx), %rcx
        movl     $10, (%rax, %rcx, 4)
        movabsq   $fai, %rax
        call    *%rax
        ...
```

## Modelli di memoria: esempio (2)

- **Programma C++:**

```
int i; int ar[8];
extern "C" void fai()
{ }
int main
{
    ...
    i = 5;
    ar[i] = 10;
    fai();
    ...
}
```

```
# modello PIC
# variabili i e ar indirizzate tramite RIP
# funzione fai chiamata con una call tramite RIP
.data
i:      .long      0
ar:     .fill      8, 4
.text
.global fai
fai:    ...
.global main
main:   ...
        movl      $5, i(%rip)
        leaq     ar(%rip), %rax
        movslq   i(%rip), %rcx
        movl     $10, (%rax, %rcx, 4)
        call    fai
        ...
```

## Modelli di memoria: esempio (3)

- Programma C++:

```
int i; int ar[8];
extern "C" void fai()
{ }
int main
{
    ...
    i = 5;
    ar[i] = 10;
    fai();
    ...
}
```

# modello piccolo  
# *i* e *ar* indirizzate col solo DISP  
# funzione *fai* chiamata con una *call* tramite RIP

```
.data
i:      .long      0
ar:     .fill      8, 4
.text
.global fai
fai:    ...
.global main
main:   ...
        movl      $5, i
        leaq     ar, %rax
        movslq   i, %rcx
        movl     $10, (%rax, %rcx, 4)
        call    fai
        ...
```

# Modello PIC e ambiente GNU

- **Sistema di sviluppo GNU:**
  - si possono utilizzare i modelli grande e piccolo (senza specifiche, il modello è quello piccolo);
  - non viene supportato il modello PIC;
  - utilizzando il comando `g++` si può specificare che il file eseguibile sia PIC (opzione `-fpic`):
    - in questo caso tale file risulta indipendente dalla posizione in cui verrà caricato, senza altri vincoli sulle istruzioni utilizzate.
- **Programmi riportati nel seguito:**
  - non vengono specificate opzioni per il modello (il modello è quindi piccolo);
  - sono di dimensione modesta, per cui la zona dati e la zona testo sono sicuramente contenute nei primi 2 Gbyte di memoria;
  - in Assembler, si utilizza codice PIC.

# Opzioni comuni per il comando g++

- **Comando g++:**
  - **Opzioni per il modello di memoria:**
    - mmodel=large*
    - mmodel=small*
  - **Opzione per il collegamento dei file di libreria:**
    - nostdlib*
      - non collega implicitamente nessun file di libreria, ma solo quelli esplicitamente elencati;
      - in questo caso, se il programma principale è in Assembler, deve avere la struttura vista per il comando *as* (entry point *\_start*).
  - **Opzione per la sola traduzione in Assembler di un file C++:**
    - S*
      - serve a esaminare come il compilatore traduce un file C++;
      - può essere utile ai fini della preparazione dell'esame scritto, anche se il file tradotto non è di semplice comprensione, in quanto il Compilatore applica regole generali;
      - non va comunque utilizzata in fase di esame scritto, in quanto viene rilevata e lo scritto annullato.