


Dal sorgente all'eseguibile
I programmi Assembly

Prof. Alberto Borghese
Dipartimento di Scienze dell'Informazione
alberto.borghese@unimi.it

Riferimenti sul Patterson: Cap. 2.10 + Appendice B, tranne B.7


Le istruzioni in linguaggio macchina

- Linguaggio di programmazione direttamente comprensibile dalla macchina
  - Le parole di memoria sono interpretate come *istruzioni*
  - Vocabolario è *l'insieme delle istruzioni (instruction set)*

Programma in linguaggio ad alto livello (C)

```
a = a + c
b = b + a
var = m [a]
```

Programma in linguaggio macchina

```
011100010101010
000110101000111
000010000010000
001000100010000
```

Le istruzioni di un'ISA

Devono contenere tutte le informazioni necessarie ad eseguire il ciclo di esecuzione dell'istruzione. Registri, comandi, ...

Ogni architettura di processore ha il suo linguaggio macchina

- Architettura definita dall'insieme delle istruzioni elementari.
  - **ISA (Instruction Set Architecture)**
- Due processori con lo stesso linguaggio macchina hanno la stessa architettura delle istruzioni anche se le implementazioni hardware possono essere diverse.
- Consente al SW di accedere direttamente all'hardware di un calcolatore

Dai simboli ai numeri binari

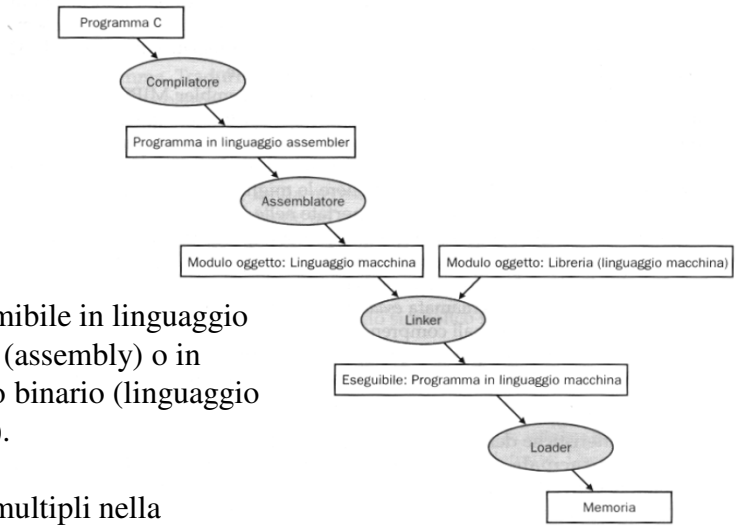

ISA esprimibile in linguaggio simbolico (assembly) o in linguaggio binario (linguaggio macchina).

Passaggi multipli nella traduzione.

Dall'assembly all'eseguibile

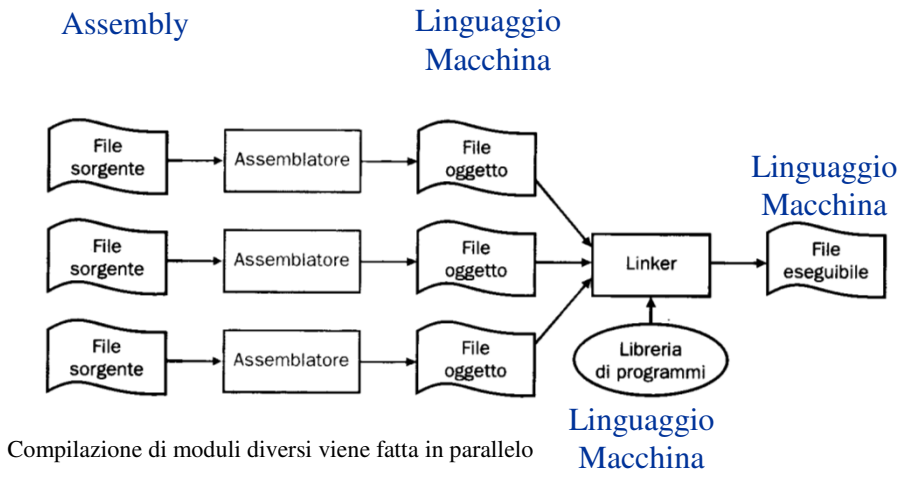

Compilazione di moduli diversi viene fatta in parallelo

Organizzazione logica della memoria

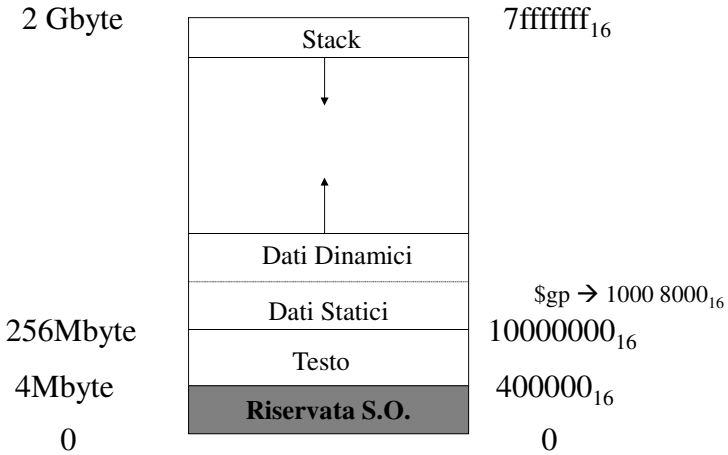

MIPS: Software conventions for Registers

0	zero	constant 0
1	at	reserved for assembler
2	v0	expression evaluation &
3	v1	function results
4	a0	arguments
5	a1	
6	a2	
7	a3	
8	t0	temporary: caller saves
. . .		(callee can clobber)
15	t7	
16	s0	callee saves
. . .		(caller can clobber)
23	s7	
24	t8	temporary (cont'd)
25	t9	
26	k0	reserved for OS kernel
27	k1	
28	gp	Pointer to global area
29	sp	Stack pointer
30	fp	frame pointer (s8)
31	ra	Return Address (HW)

$gp punta a metà del primo segmento dati: da 256,000 kByte a 256,064kByte, cioè all'indirizzo (256,032) Kbyte. Accesso alla memora come ***lw rt, Offset($gp)***.
(NB Offset è espresso in complemento a 2 su 16 bit ed è compreso tra -2^{15} -1 e $+2^{15}$-1).

Impostazione corretta del $gp e dell'offset

La memoria viene letta/scritta con indirizzamento mediante Indirizzo_base + offset
(ad esempio lw $t0, Offset(<Registro_contenente_indirizzo_base>)

Il $gp punta solitamente ad un indirizzo 32kbyte sopra il limite inferiore del segmento dati:

Segmento dati: 256Mbyte = 0x1000 0000 byte.
Offset: 32Kbyte = 0x8000byte

```
$gp = 0x1000 0000 + 0x8000 = 0x1000 8000 byte.
```

Indirizzo della prima posizione in memoria (Mmin = 256Mbyte) riservabile ai dati, espressa in funzione di $gp (base + offset):
Base address: $gp = 0x1000 0000 + 0x8000 = 0x1000 8000 byte.
Offset: -32Kbyte = numero su 16 bit con segno = 0x8000.
Mmin = `0x8000($gp)`

Ogni altro indirizzo può essere facilmente individuato sommando lo spiazzamento relativo a Mmin = 0x1000 0000 e quindi riducendo lo spiazzamenti rispetto a $gp.

Esempio:
Indirizzo 256,000,016 byte => 256,032Kbyte – 32Kbyte + 16byte.
In Hex: 0x1000 0010 = 0x1000 8000 – 0x8000 + 0x10
(la somma viene effettuata modulo 64Kbyte)

Il compilatore

Dal codice sorgente C all'assembly (dipende dall'ISA dell'HW)

Il numero di linee aumenta notevolmente

Le strutture degli oggetti vengono tradotte in codice che gestisce la memoria riservata all'oggetto (base + offset).

L'assemblatore

Adatta il codice Assembly all'ISA (Assembly) dell'Architettura e quindi codifica in linguaggio macchina.

Esempi di adattamento del codice Assembly:

Sviluppo delle pseudo-istruzioni:

- move $t0, $t1 → add $t0, $zero, $t1?
- blt (branch on less than) → slt + bne
- far branch → branch + jump

Conversione delle costanti da una qualsiasi base in base Hex.

Traduzione in linguaggio macchina (creazione del file oggetto).

Compilatore ed assemblatore possono essere uniti in un un'unica fase.

L'assemblatore: i file oggetto

L'assemblaggio produce:
- L'insieme delle istruzioni in linguaggio macchina
- I dati statici
- Le informazioni necessarie per inserire le istruzioni in memoria correttamente.

Un file oggetto è così costituito:
- Header. Posizione e dimensione dei vari pezzi che costituiscono il file oggetto.
- Segmento testo. Contiene le istruzioni.
- Segmento dati statici. Contiene i dati relativi al file oggetto.
- Informazione di rilocazione. Identifica istruzioni, etichette e dati che dipendono dall'indirizzo a partire dal quale viene caricato il programma in memoria.
- La tabella dei simboli. Contiene le etichette che non sono definite (ad esempio riferimenti esterni, di altri moduli oggetto o librerie).
- Informazioni di debug. Consente di associare ai costrutti Assembly i costrutti C (la traduzione non è uno a uno).

Il linker

Consente di fare ricompilare ed assemblare solo i moduli che vengono modificati (*Rebuild*).

Il linker è costituito da 3 step:
1. Disporre i moduli di codice ed i dati (statici).
2. Identificare gli indirizzi dei dati e delle isrtuzioni di salto "critiche".
3. Risolvere le etichette interne ai moduli ed esterne (trovare la corrispondenza). Questo passo è equivalente a compilare una tabella di rilocazione.

Nei passi 2 e 3, il linker utilizza le informazioni di rilocazione degli oggetti e le tabelle dei simboli.

Quali sono i simboli da risolvere?
- Etichette di salto (branch o jump)
- Indirizzo dei dati (e.g. A[0]).

Dopo avere risolto tutte le etichette (sostituito le corrispondenze), occorre trovare gli indirizzi assoluti associati alle etichette.
Vengono cioè **rilocati** (riposizionati) gli oggetti al loro indirizzo finale.

Viene creato il file eseguibile. Ha lo stesso formato del file oggetto ma non ha riferimenti non risolti e gli indirizzi sono assoluti (rilocazione).

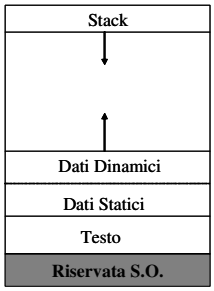

Esempio

Analizziamo due procedure:

Proc A

```
0: Proc_A:    lw $a0, 8000($gp)
4:            jal B
8:            add $t2, $t1, $t0
              …
```

Proc B

```
0: Proc_B:    sw $a1, 8000($gp)
4:            jal A
              …
              …
```

NB In questo caso $gp punta a metà del primo segmento di 64Kbyte dell'area dati (256 Mbyte + 32Kbyte)

Header Proc A
Text Size 100hex (=256byte)
Data Size 20hex (=32 byte)
…

Header Proc B
Text Size 200hex (=512byte)
Data Size 32hex (=48byte)

Esempio

Object file header			
	Name	**Procedure A**	
	Text Size	100_{hex} (=256byte)	
	Data Size	20_{hex} (=32 byte)	
Text Segment	Address	Instruction	
	0	lw $a0, 0($gp)	
	4	jal Proc_B	
		add $t2, $t1, $t0	
	….	…	
Data Segment	0	(X)	
	…	…	
Relocation info	Address	Instruction type	Dependency
	0	lw	X
	4	jal	Proc_B
Symbol table	Label	Address	
	X	--	
	Proc_B	--	

Object file header			
	Name	**Procedure B**	
	Text Size	200_{hex} (=512byte)	
	Data Size	30_{hex} (=48 byte)	
Text Segment	Address	Instruction	
	0	sw $a1, 0($gp)	
	4	jal Proc_A	
	….	…	
Data Segment	0	(Y)	
	…	…	
Relocation info	Address	Instruction type	Dependency
	0	sw	Y
	4	jal	Proc_A
Symbol table	Label	Address	
	Y	--	
	Proc_A	--	

Il funzionamento del linker

Per prima cosa vengono posizionate nella posizione desiderata le 2 procedure (A sotto e B sopra): copia delle istruzioni e dei dati.

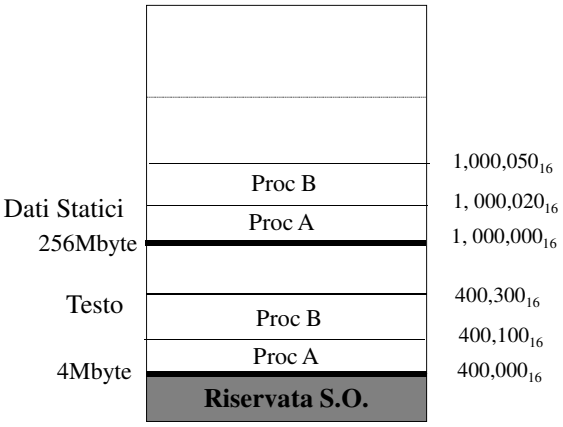

Calcoli degli indirizzi testo

Segmento testo:

Inizia dopo il segmento riservato al S.O., indirizzo 0x400 000 = 0100 0000 0000 0000 0000 0000 binario = 1x 2^{22} = 4Mbyte.

Procedura A. Inizia subito dopo. Indirizzo 0 della procedura è l'indirizzo 0x400 000.

Procedura B. Inizia dopo la procedura A. Indirizzo 0 della procedura B è: 0x400 000 + 0x100 (dimensione della procedura B) = 0x400 100.

Queste osservazioni consentono di sostituire le etichette di salto a procedura (jal).

Risoluzione delle etichette sul codice

Executable file header		
	Text Size	300_{hex} (=768byte)
	Data Size	50_{hex} (=80 byte)
Text Segment	Address	Instruction
Proc A	400,000	lw $a0, 8000($gp)
	400,004	jal 400,100
	400,008	add $t2, $t1, $t0
	…	…
Proc B	400,100	sw $a1, 8000($gp)
	400,104	jal 400,000
	….	…
Data Segment	Address	Data
	0	(X)
	0	(Y)
….	….	….

j, jr si comportano in modo analogo

Come si comportano beq e bne?

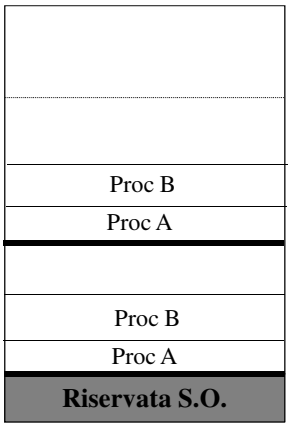

Risoluzione delle etichette sui dati

Executable file header		
	Text Size	300_{hex} (=768byte)
	Data Size	50_{hex} (=80 byte)
Text Segment	Address	Instruction
Proc A	400,000	lw $a0, 8000($gp)
	400,004	jal 400,100
	400,008	add $t2, $t1, $t0
	…	…
Proc B	400,100	sw $a1, 8020($gp)
	400,104	jal 400,000
	….	…
Data Segment	Address	
	10,000,000	(X)
	10,000,020	(Y)

$gp = $10,008,000_{hex}$ = 256Mbyte + 32Kbyte

$gp = 0001 0000 0000 0000 0100 0000 0000 0000

Il valore di $gp è comune a tutti i moduli.

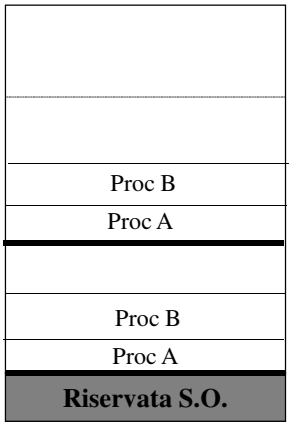

Il loader

Dalla memoria su disco alla memoria principale (Unix).

• Lettura dello header del file eseguibile per determinare le dimensioni del segmento testo e dati (statici).

• Creazione di uno spazio in memoria sufficientemente ampio per contenere il testo ed i dati.

• Copia delle istruzioni e dei dati da disco alla memoria. In questa fase agli indirizzi assoluti dell'eseguibile viene aggiunto l'offset assegnato ai segmenti dati e testo per la presenza di altri programmi in esecuzione in memoria.

• Copia dei parametri (che devono essere passati al programma) in cima allo stack (abbassamento dello stack).

• Inizializza i registri della macchina.

• Trasferimento del programma ad una procedura (di sistema) che trasferisce i parametri dallo stack ai registri argomento e chiama (salta) alla prima istruzione della procedura main.

• Al termine del programma verrà eseguita una syscall (exit).

I problemi del linker

Viene creato un unico file eseguibile che contiene:

Le funzioni di libreria vengono inserite all'interno dell'eseguibile.

Tutte i moduli "linkati" vengono inseriti.

Il file eseguibile diventa molto grosso (static link).

Soluzione DLL (dynamic link).