Guião II - Níveis de Abstração

Níveis de Abstração

Níveis em que se representa a informação:

- Linguagem de alto nível (por exemplo C)
- Linguagem *assembly*
- Código objeto/máquina recolocável
- Código objeto executável

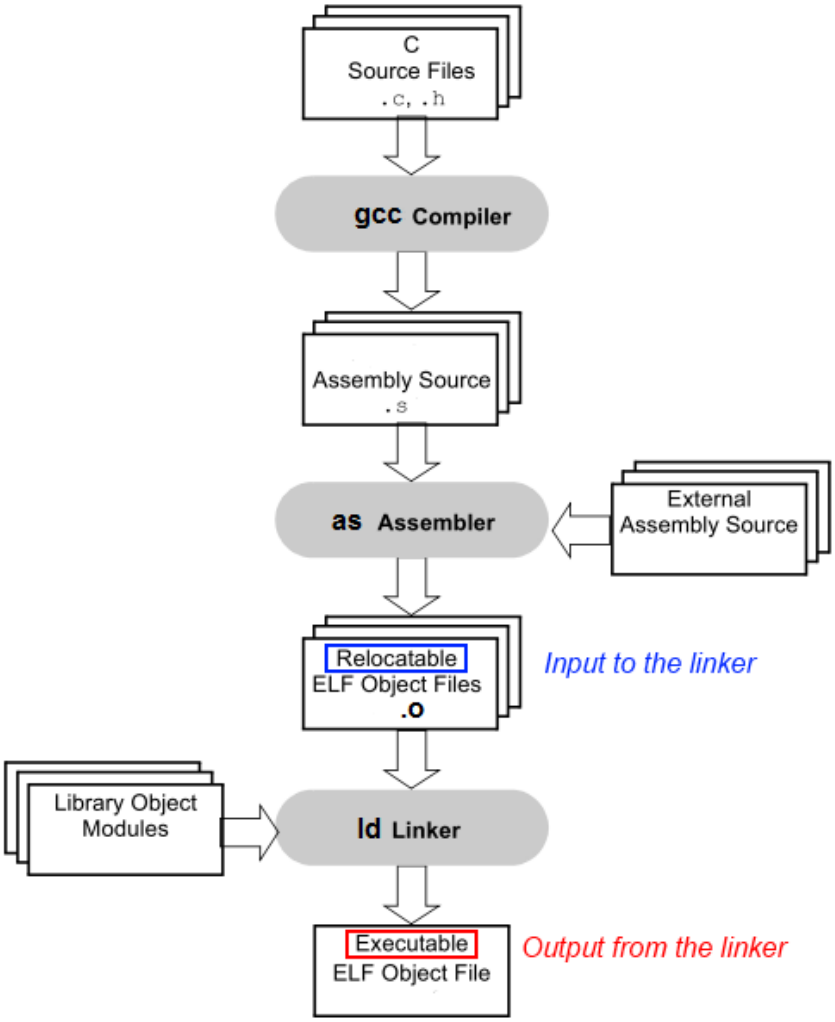

Ficheiro Objeto Recolocável (*Relocatable Object File*)

Um **ficheiro objeto recolocável** não contém endereços de memória absolutos, é apenas uma sequência de código binário com deslocamentos de memória. Por exemplo, pode usar-se um deslocamento em relação ao início da função `main`. Enquanto um **ficheiro objeto executável** contém endereços e não apenas deslocamentos em relação a qualquer função.

Outra **diferença** fundamental entre os ficheiros objeto **recolocáveis** e **executáveis**, resulta de os executáveis incluírem código de inicialização/arranque e os recolocáveis não.

O processo de recolocação corrige os endereços das etiquetas e os símbolos que foram criados no código.

1. Edição de programas

Editar os ficheiros **main.c** e **soma.c** com o conteúdo seguinte:

main.c
```
main ()
{
int x;
soma (x);
}
```

soma.c
```
int accum=0;
void soma (int p)
{
accum += p;
}
```

1.a) Identifique o formato de representação dos ficheiros **.c** usando o comando **file:**

* **file main.c** → `main.c: ASCII text`

* **file soma.c** → `soma.c: ASCII text`

Ambos os ficheiros estão no formato **texto**, ou seja, cada elemento incluído nos ficheiros representa um carater codificado em ASCII.

1.b) Que relação existe entre aqueles dois módulos?

Na função **main()** é chamada a função **soma()**.

2. Ferramentas

Usar o comando ***man*** *<util>* para conhecer os utilitários **gcc**, **gdb** e **objdump.**

3. Compilação

Compile os módulos `soma.c` e `main.c` usando o comando:

gcc -Wall -O2 -S soma.c main.c

3.a) Identifique as diferentes opções usadas no comando acima.

-Wall → opção que ativa todas (*all*) as mensagens de aviso (*Warning*) por parte do `gcc`;

-02 → opção que indica ao `gcc` para ativar o nível 2 de otimização;

-S → faz com que o processo de compilação termine antes do processo de montagem.

Outras opções que controlam a otimização de código:

-O, **-O1** → O compilador tenta reduzir o tamanho do código e o tempo de execução, sem efetuar otimizações que ocupem muito tempo de compilação.

-O2 → Otimizar ainda mais. O `gcc` efetua quase todas as otimizações suportadas e que não exijam ter que assumir um compromisso entre espaço-desempenho. Em comparação com -O, esta opção aumenta o tempo de compilação e o desempenho do código gerado.

-O3 → Otimizar ainda mais. Ativa todas as otimizações especificadas por `-O2` e também ativa: `-finline-functions`,`-funswitch-loops`, `-ftree-loop-vectorize`, etc.

-O0 → Reduz o tempo de compilação e permite que a depuração produza os resultados esperados. Esta é a opção por omissão.

3.b) Identifique o formato dos ficheiros produzidos.

```
main.s: ASCII assembler program text
soma.s: ASCII assembler program text
```

Tal como os ficheiros originais também os ficheiros produzidos continuam a estar no formato **texto**. No entanto, uma análise da informação neles contida permite-nos concluir que os mesmos contêm **código *assembly* IA32**.

3.c) Visualize os ficheiros gerados e interprete o respetivo conteúdo, determinando o nível de abstração implícito.

soma.s

```
      .file     "soma.c"
.globl accum
      .data
      .align    4
      .type     accum,@object
      .size     accum,4
accum:
      .long     0
      .text
.globl soma
      .type     soma,@function
soma:
      pushl     %ebp
      movl      accum, %eax
      movl      %esp, %ebp
      addl      8(%ebp), %eax
      movl      %eax, accum
      leave
      ret
      ...
```

main.s

```
      .file     "main.c"
      .text
.globl main
      .type     main,@function
main:
      pushl     %ebp
      movl      %esp, %ebp
      subl      $8, %esp
      andl      $-16, %esp
      subl      $12, %esp
      pushl     %eax
      call      soma
      leave
      ret
      ...
```

O código *assembly* é constituído por **mnemónicas** que identificam as operações que o CPU executa (por ex., `movl`, `subl`, `addl`, `pushl`) seguidas da identificação dos operandos fonte e/ou destino (através do seu valor ou da localização).

Os **valores** são normalmente numéricos, e as **localizações** são (i) endereços de memória, (ii) nomes de registos (que começam por "**%**"), ou (iii) especificação de endereços de memória usando constantes e 1 a 2 nomes de registos entre parênteses.

No código *assembly* também está presente **informação simbólica**:

- As linhas que começam com "**.**" são **diretivas** (comandos) para o programa de montagem e especificam (i) onde começa o bloco de informação que contém o código do módulo ("**.text**"), (ii) onde são definidas as variáveis globais ("**.bss**" ou "**.data**"), ou (iii) que uma determinada sequência de caracteres (nome de função ou variável) é única no programa e foi definida neste módulo, podendo ser acedida a partir de qualquer outro módulo que seja posteriormente ligado a este e que lhe faça referência. Exemplo: "**.global <nomeFunc | nomeVar>**".
- As linhas que terminam com "**:**" são **etiquetas** que indicam
  - a localização de um dado pedaço de código dentro do bloco **.text** ou
  - a localização de uma dada variável dentro do bloco que contém as variáveis globais.
- As **sequências de caracteres no meio do código** de montagem, associadas normalmente ao nome de uma variável ou função, indicam a localização em memória onde ela irá tomar os diversos valores ao longo da execução de um programa (as etiquetas referidas antes).

4. Montagem

Executar o comando: **`gcc -Wall -O2 -c soma.s`**

4.a) Qual o objetivo de usar a opção **`-c`** ?

Utilizando a opção **`-c`** o `gcc` irá **compilar** e fazer a **montagem** do código fonte terminando imediatamente antes de fazer a **ligação** de módulos.

4.b) Identifique o formato do ficheiro resultante.

O ficheiro está em **formato objeto**, em que parte do seu conteúdo é já o **código em linguagem máquina** do IA32.

soma.o: ELF 32-bit LSB relocatable, Intel 80386, version 1 (SYSV), not stripped

4.c) Obteria o mesmo resultado se usasse como entrada o ficheiro `soma.c` ?

```
gcc -Wall -O2 -c soma.c
```

```
gcc -Wall -O2 -c soma.s
```

Os comandos anteriores produzem o mesmo resultado, o ficheiro objeto **`soma.o`**

4.d) Qual o nível de abstração implícito?

O nível de abstração do resultado (`soma.o`) é o do **código objeto**.

4.e) O ficheiro `soma.o` pode ser executado diretamente pela máquina?

`soma.o` é um ficheiro objeto, em que parte do seu conteúdo é já o código do programa em linguagem máquina do IA32. Contudo, olhando para os endereços de cada uma das instruções (que começam no endereço "0") pode concluir-se que o código ainda não está pronto para ser executado, para além de se saber que ainda falta ligar com `main.o` para produzir um programa final. Também não possui código de interação com o sistema operativo.

5. Desmontagem/*Disassembly*

Executar o comando: **`objdump -d soma.o`**
Resultado:

```
-----------------------------------------------------------
Disassembly of section .text:
soma.o: file format elf32-i386
00000000 <soma>:
   0:   55                      push   %ebp
   1:   a1 00 00 00 00          mov    0x0,%eax
   6:   89 e5                   mov    %esp,%ebp
   8:   03 45 08                add    0x8(%ebp),%eax
   b:   a3 00 00 00 00          mov    %eax,0x0
  10:   c9                      leave
  11:   c3                      ret
-----------------------------------------------------------
```

5.a) O ficheiro contém informação simbólica?

O ficheiro não contém informação simbólica. "`soma`" é guardado na tabela de símbolos.

5.b) Identifique as diferentes representações das instruções presentes quanto ao tamanho.

```
push   %ebp                  ocupa 1 byte
mov    0x0,%eax              ocupa 5 bytes
mov    %esp,%ebp             ocupa 2 bytes
add    0x8(%ebp),%eax        ocupa 3 bytes
mov    %eax,0x0              ocupa 5 bytes
leave                        ocupa 1 byte
ret                          ocupa 1 byte
```

Identifique as diferentes representações das instruções presentes quanto ao formato.

```
push   Reg
mov    Addr, Reg
mov    regS, regD
add    Imm(regB), regD
mov    Reg, Addr
leave
ret
```

6. Desmontagem/*Disassembly*

Baseado na visualização do conteúdo do resultado produzido pelo comando:

```
objdump -d soma.o
```

6.a) Que relação existe entre a informação observada acima e a presente no ficheiro `soma.s`?

```
======= soma.s =========      ====== disassembly de soma.o =====
pushl   %ebp                   0: push   %ebp
movl    accum, %eax            1: mov    0x0,%eax
movl    %esp, %ebp             6: mov    %esp, %ebp
addl    8(%ebp), %eax          8: add    0x8(%ebp),%eax
movl    %eax, accum            B: mov    %eax,0x0
leave                         10: leave
ret                           11: ret
========================      ================================
```

A variável global **`accum`** já não aparece como informação simbólica: foi convertida num número que representa o endereço de memória onde irá ficar alojada. O endereço de memória é "0" e coincidente com o endereço do início do código da função **`soma()`**. A razão para essa coincidência resulta do facto de o endereço especificado para a variável indicar a sua localização dentro do bloco das variáveis globais (i.e., é a primeira variável global) enquanto que o endereço 0 do código da função **`soma()`** indica a localização desse código dentro do bloco **.text** do ficheiro.

6.b) Identifique o código relativo à representação da variável **`accum`**?

```
1:    a1 00 00 00 00          mov    0x0,%eax
B:    a3 00 00 00 00          mov    %eax,0x0
```

Apresente razões para o modo de representação usado.

A variável **`accum`** é representada pelo endereço de memória onde irá ficar alojada ('0' neste caso). O endereço '0' indica a localização relativa dentro do bloco das variáveis globais, ou seja, é a primeira variável global.

7. Desmontagem/*Disassembly*

Execute o comando: **`gdb soma.o`**

7.a) Identifique o resultado do comando do `gdb`: **`x/23xb soma`** (mostra 23 bytes da função `soma` em hexadecimal)

```
0x0 <soma>:      0x55  0xa1  0x00  0x00  0x00  0x00  0x89  0xe5
0x8 <soma+8>:    0x03  0x45  0x08  0xa3  0x00  0x00  0x00  0x00
0x10 <soma+16>: 0xc9  0xc3  Cannot access memory at address 0x12
```

7.b) Identifique o resultado do comando do `gdb`: **`disass soma`** (*disassembly* da função `soma`)

```
Dump of assembler code for function soma:
0x00000000 <soma+0>:    push   %ebp
0x00000001 <soma+1>:    mov    0x0,%eax
0x00000006 <soma+6>:    mov    %esp,%ebp
0x00000008 <soma+8>:    add    0x8(%ebp),%eax
0x0000000b <soma+11>:   mov    %eax,0x0
0x00000010 <soma+16>:   leave
0x00000011 <soma+17>:   ret
End of assembler dump.
```

8. Ligação e execução de módulos

Execute o comando: **`gcc -Wall -O2 -o prog main.c soma.o`**

8.a) Identifique o formato do ficheiro resultante, através do comando: **`file prog`**

`prog``: ELF 32-bit LSB executable, Intel 80386, version 1 (SYSV), for GNU/Linux 2.6.9, dynamically linked (uses shared libs), for GNU/Linux 2.6.9, not stripped`

Este ficheiro contém toda a informação necessária para poder ser executado no computador: código em linguagem máquina dos dois módulos, incluindo o código das funções de bibliotecas (do C, do sistema operativo, etc), e os valores inicializados das variáveis globais (por ex., mensagens de erro).

8.b) Como procederia para executar o programa?

`./prog`

Dado que o caminho para o executável **`prog`** não se encontra listado na variável de ambiente `$PATH` é necessário inserir o caminho, neste caso o diretório atual '.'

9. Depuração de programas

Executar o comando: **objdump -d prog**

```
-----------------------------------------------
...
08048354 <main>:
8048354:       55                    push   %ebp
8048355:       89 e5                 mov    %esp,%ebp
8048357:       83 ec 08              sub    $0x8,%esp
804835a:       83 e4 f0              and    $0xfffffff0,%esp
804835d:       83 ec 0c              sub    $0xc,%esp
8048360:       50                    push   %eax
8048361:       e8 02 00 00 00        call   8048368 <soma>
8048366:       c9                    leave
8048367:       c3                    ret

08048368 <soma>:
8048368:       55                    push   %ebp
8048369:       a1 bc 95 04 08        mov    0x80495bc,%eax
804836e:       89 e5                 mov    %esp,%ebp
8048370:       03 45 08              add    0x8(%ebp),%eax
8048373:       a3 bc 95 04 08        mov    %eax,0x80495bc
8048378:       c9                    leave
8048379:       c3                    ret
...
-----------------------------------------------
```

9.a) Repita o exercício 6 para o resultado obtido pelo comando anterior.

A variável **accum** e o código da função **soma** deixaram de ser referenciados pelo endereço "0", foram recolocados em endereços distintos (8048368 - **soma**, 80495bc - **accum**), compatíveis com a execução num sistema real.

9.b) Relacione a representação da variável **accum** com os conceitos de little/big-endian.

```
----- código binário -----      ---- código assembly ----
8048369: a1 bc 95 04 08         mov 0x80495bc,%eax
```

Analisando lado a lado o código binário e o código *assembly* pode verificar-se que a forma como o endereço de **accum** é guardado em memória corresponde a uma arquitetura com ordenação *little endian*: o LSB (0x**bc**) é guardado no endereço menor (0x**08048370**) e o MSB (0x**08**) é guardado no endereço maior (0x**08048373**).

10. Depuração de programas

Execute o comando: **gdb prog**

10.a1) Identifique o resultado do comando do gdb: **disass soma**

```
-------------------------------------------------
0x08048368 <soma+0>:    push   %ebp
0x08048369 <soma+1>:    mov    0x80495bc,%eax
0x0804836e <soma+6>:    mov    %esp,%ebp
0x08048370 <soma+8>:    add    0x8(%ebp),%eax
0x08048373 <soma+11>:   mov    %eax,0x80495bc
0x08048378 <soma+16>:   leave
0x08048379 <soma+17>:   ret
-------------------------------------------------
```

10.a2) Identifique o resultado do comando do gdb: **disass main**

```
-------------------------------------------------
0x08048354 <main+0>:    push   %ebp
0x08048355 <main+1>:    mov    %esp,%ebp
0x08048357 <main+3>:    sub    $0x8,%esp
0x0804835a <main+6>:    and    $0xfffffff0,%esp
0x0804835d <main+9>:    sub    $0xc,%esp
0x08048360 <main+12>:   push   %eax
0x08048361 <main+13>:   call   0x8048368 <soma>
0x08048366 <main+18>:   leave
0x08048367 <main+19>:   ret
-------------------------------------------------
```

10.b) Identifique no código acima a passagem do controlo à função **soma**.

```
0x08048361 <main+13>:  call 0x8048368 <soma>
```

A análise do código do **main** mostra a existência de uma instrução **call** seguida de um endereço de memória que corresponde precisamente ao início da função **soma**.

10.c) Execute o programa, usando o comando **run** do gdb

```
Starting program: /state/partition1/home/aje/aula5/prog
```