

Brazilian Portuguese text placeholder

1 Padrões de códigos	1
2 Brazilian Portuguese text placeholder	29
3	30
4	31
5	32
Afterword	34
Brazilian Portuguese text placeholder	36
Brazilian Portuguese text placeholder	37
Índice	38

Conteúdo

1 Padrões de códigos	1
1.1 O método	1
1.2 Brazilian Portuguese text placeholder	2
1.2.1 Uma breve introdução a CPU	2
1.3 A mais simples função	3
1.3.1 x86	3
1.4	3
1.4.1 x86	3
1.4.2 x86-64	5
1.4.3 Conclusão	6
1.4.4 Exercícios	6
1.5 Cabeçalhos e rodapés de funções	6
1.5.1 Recursividade	6
1.6 Pilha	6
1.6.1 Por que a pilha “cresce” para trás?	7
1.6.2 Para que a pilha é usada?	7
1.6.3 Um modelo típico de pilha	11

1.6.4 Exercícios	11
1.7 printf() com vários argumentos	11
1.7.1 x86	11
1.7.2 ARM	13
1.7.3 Conclusão	13
1.7.4 A propósito	14
1.8 scanf()	14
1.8.1 Exemplo simples	14
1.8.2 Variáveis globais	17
1.8.3 Checagem de resultados do scanf()	20
1.8.4 Exercício	25
1.9 switch()/case/default	25
1.9.1	25
1.9.2 Exercícios	26
1.10 Laços	26
1.10.1 Exercícios	26
1.11 Brazilian Portuguese text placeholder	26
1.11.1 strlen()	26
1.12 Substituição de instruções aritméticas por outras	26
1.12.1 Exercício	26
1.13 Matriz	26
1.13.1	26
1.13.2	27
1.13.3 Exercícios	27
1.14 Estruturas	27
1.14.1 UNIX: struct tm	27
1.14.2	27
1.14.3 Exercícios	27
1.15	27
1.15.1	27
1.16	28
1.16.1	28
2 Brazilian Portuguese text placeholder	29
3	30
4	31
4.1 Linux	31
4.2 Windows NT	31
4.2.1 Windows SEH	31
4.3	31
4.4	31
5	32
Afterword	34
5.1 Questions?	34
Brazilian Portuguese text placeholder	36
Brazilian Portuguese text placeholder	37
Índice	38

Capítulo 1

Padrões de códigos

1.1 O método

Quando o autor deste livro começou a aprender C e depois C++, ele escrevia pequenos pedaços de código, os compilava e então observava o output em Assembly. Isso fez com que ele entendesse facilmente o que acontecia com o código que ele tinha escrito. Ele fez isso várias vezes, vendo que relação havia entre o código em C/C++ e o que o compilador produzia, gravando assim profundamente em sua mente. Agora é fácil para ele imaginar instantaneamente a aparência e a função de um esboço de um código em C/C++. Talvez essa técnica possa ser útil para outras pessoas.

A propósito, há um ótimo site onde você pode fazer o mesmo, com vários compiladores, em vez de instalá-los: <http://godbolt.org/>.

Exercícios

Quando o autor deste livro estudou a linguagem Assembly, ele também frequentemente compilou pequenas funções em C e então as reescreveu gradativamente em Assembly, tentando deixar os códigos o menor possível. Isso provavelmente não vale a pena ser feito no cotidiano, por que é difícil competir com os últimos compiladores em termos de eficiência. No entanto, isso é um bom meio de adquirir um melhor entendimento de Assembly. Sinta-se a vontade, portanto, para pegar qualquer código Assembly desse livro e tentar deixá-lo menor. No entanto, não se esqueça de testar o que você escreveu.

Níveis de otimização e informações de debug (depuração)

Código fonte pode ser compilado por diferentes compiladores com vários níveis de otimização. Um típico compilador tem praticamente esses três tipos níveis, onde o nível zero significa que a otimização é completamente deficiente. Otimização pode ser também direcionada ao tamanho do código ou à sua velocidade. Um compilador não otimizado é mais rápido e produz mais códigos inteligíveis (embora extensos), no entanto, um compilador otimizado é mais lento e tenta produzir códigos que rodem mais rápidos (mas não necessariamente mais compacto). Ainda em relação aos níveis de otimização, um compilador pode incluir algumas informações de debug (depuração) nos resultados do arquivo, produzindo um código que é fácil depurar. Uma das mais importantes características do código 'debug' é que ele deve conter ligações entre linha do código fonte e seus respectivos endereços de código de máquina. Compiladores otimizados, por outro lado, tendem a produzir uma saída (output) onde linhas inteiras de código podem ser otimizadas e portanto nem mesmo estar presente no resultado do código de máquina. Engenheiros reversos pode encontrar cada versão, simples por que alguns desenvolvedores ligam os marcadores de otimização do compilador enquanto outros não. O por que disso, nós vamos tentar trabalhar no exemplo de ambos 'debug' e lançar versões de código apresentados neste livro, sempre que possível. As vezes alguns antigos compiladores são usados neste livro, a fim de obter menores (ou mais simples) trechos de códigos possível. De fato, ele ainda faz isso quando ele não pode entender o que um pedaço em particular de código faz.

1.2 Brazilian Portuguese text placeholder

1.2.1 Uma breve introdução a CPU

A CPU¹ é o dispositivo que executa o código de máquina do qual consiste um programa.

Um glossário resumido:

Instrução : Um comando primário da CPU. Os exemplos mais simples incluem: mover informação entre os registradores, trabalhar com memória, operações primárias de aritmética. Como regra, cada CPU tem sua própria arquitetura do conjunto de instruções (ISA²).

Código de máquina : Código que a CPU processa diretamente, cada instrução geralmente é codificada por vários bytes.

Linguagem assembly : Códigos mnemônicos e algumas extensões como macros que tem por intenção facilitar a vida do programador.

Registrador da CPU : Cada CPU tem um conjunto fixo de registradores de propósito geral (GPR³). Aproximadamente 8 na arquitetura x86, 16 na x86-64, 16 na ARM. A maneira mais fácil de entender um registrador é imaginá-lo como uma variável temporário sem tipo. Imagine que você está trabalhando em uma linguagem de alto nível e pudesse usar somente oito variáveis de 32-bit (ou 64). Ainda assim uma gama de coisas podem ser feitas usando somente estes!

Você pode pensar por quê há a necessidade dessa diferença entre código de máquina e linguagens de programação de alto nível. A resposta está no fato de humanos e CPUs não se parecerem nada — é muito mais fácil para um humano usar uma linguagem de alto nível como C/C++, Java, Python, etc., mas para a CPU é mais fácil usar um nível muito mais baixo de abstração. Talvez seja possível inventar uma CPU que pode executar códigos em linguagem de alto nível, mas ela seria muitas vezes mais complexa que as CPUs que conhecemos hoje. De uma maneira similar, é muito mais inconveniente para humanos escreverem em linguagem assembly, devido ao fato dela ser tão baixo nível e difícil de se escrever sem cometer um alto número de erros irritantes. O programa que converte linguagem de alto nível em código assembly é chamado de compilador.

Algumas palavras a respeito de diferentes ISAs

O ISA x86 sempre possuiu opcodes de tamanho variável, então com a chegada da era do 64-bit, as extensões x64 não impactaram a ISA de forma muito significativa. De fato, o ISA x86 ainda contém uma série de instruções que surgiram inicialmente na CPU 8086 16-bit, mas ainda são encontradas nas CPUs de hoje em dia. ARM é uma CPU RISC⁴ desenvolvido com a idéia de opcodes com tamanho constante, o que trouxe algumas vantagens no passado. Bem no início, todas as instruções ARM foram codificadas em 4 bytes⁵. Este é atualmente referenciado como «ARM mode». Então concluiu-se que não era tão econômico quanto se imaginou a princípio. Na verdade, as instruções de CPU mais utilizadas⁶ em aplicações do mundo real podem ser codificadas usando menos informação. Foi adicionado então outro ISA, chamado Thumb, onde cada instrução era codificada em apenas 2 bytes. Este é conhecido como «Thumb mode». No entanto, nem *all* instruções ARM podem ser codificadas em apenas 2 bytes, então o conjunto de instruções Thumb é de certa forma limitado. É interessante notar que códigos compilados para os modos ARM e Thumb podem, conforme esperado, coexistir num mesmo programa. Os criadores do ARM concluíram que o Thumb poderia ser estendido, dando origem ao Thumb-2, que apareceu no ARMv7. Thumb-2 ainda usa instruções de 2 bytes, mas possui algumas novas instruções com 4 bytes de tamanho. Há um equívoco comum que Thumb-2 é uma mistura de ARM e Thumb. Isso é incorreto. Em vez disso, Thumb-2 foi estendido para suportar completamente todos os recursos de processador de forma que ele pudesse competir com o modo ARM—um objetivo que foi claramente alcançado, uma vez que a maioria das aplicações para iPod/iPhone/iPad são compiladas para o conjunto de instruções do Thumb-2 (admitidamente, principalmente devido ao fato que o Xcode faz isso por padrão). Posteriormente o ARM 64-bit foi lançado. Este ISA tem opcodes de 4 bytes, e descarta a necessidade de qualquer modo Thumb adicional. No entanto, os requisitos de 64-bit afetaram o ISA, resultando em termos atualmente três

¹Central Processing Unit

²Instruction Set Architecture

³General Purpose Registers

⁴Reduced Instruction Set Computing

⁵A propósito, instruções de tamanho fixo são úteis porque se pode calcular o endereço da próxima instrução (ou da anterior) sem esforço. Esta característica será discutida na seção do operador switch() (?? on page ??).

⁶São estas MOV/PUSH/CALL/jcc

1.3. A MAIS SIMPLES FUNÇÃO

conjuntos de instruções ARM: ARM mode, Thumb mode (incluindo Thumb-2) e ARM64. Estes ISAs se interseccionam parcialmente, porém podemos dizer que são ISAs diferentes, ao invés de variações do mesmo. Portanto, gostaríamos de tentar adicionar pedaços de código dos três ISAs do ARM neste livro. Existem, a propósito, muitos outros RISC ISAs com opcodes de tamanho fixo de 32-bit, como MIPS, PowerPC **Brazilian Portuguese text placeholder** Alpha AXP.

1.3 A mais simples função

A função mais simples possível é indiscutivelmente aquela que simplesmente retorna um valor constante: Aqui está:

Listing 1.1: **Brazilian Portuguese text placeholder**

```
int f()
{
    return 123;
};
```

Vamos compilar!

1.3.1 x86

Aqui está o que ambos compiladores, GCC com otimização e MSVC produzem na plataforma x86:

Listing 1.2: Com otimização GCC/MSVC (saída do assembly)

```
f:
    mov     eax, 123
    ret
```

Há somente duas instruções: a primeira coloca o valor 123 no registrador EAX, que é usado por convenção para guardar o valor de retorno e a segunda é a RET, que retorna a execução para onde a função foi chamada.

O resultado será obtido no registrador EAX.

1.4

Vamos usar o famoso exemplo do livro [Brian W. Kernighan, Dennis M. Ritchie, *The C Programming Language*, 2ed, (1988)]:

```
#include <stdio.h>

int main()
{
    printf("hello, world\n");
    return 0;
}
```

1.4.1 x86

MSVC

Vamos compilar esse código no MSVC 2010:

```
cl 1.cpp /Fa1.asm
```

(A opção /Fa instrui o compilador para gerar o arquivo de listagem em assembly)

```

CONST SEGMENT
$SG3830 DB 'hello, world', 0AH, 00H
CONST ENDS
PUBLIC _main
EXTRN _printf:PROC
; Function compile flags: /Odtp
_TEXT SEGMENT
_main PROC
    push    ebp
    mov     ebp, esp
    push    OFFSET $SG3830
    call   _printf
    add     esp, 4
    xor     eax, eax
    pop     ebp
    ret     0
_main ENDP
_TEXT ENDS

```

Brazilian Portuguese text placeholder ?? on page ??.

O compilador gerou o arquivo 1.obj, que está ligado a 1.exe. No nosso caso, o arquivo contém dois segmentos: CONST (para informações que são constantes) e _TEXT (para o código).

A string hello, word em C/C++ tem seu tipo const const char[] [Bjarne Stroustrup, *The C++ Programming Language, 4th Edition*, (2013)p176, 7.3.2], mas não tem um nome. O compilador precisa lidar com essa string de alguma maneira, definindo então o nome de \$SG3830 para ela.

Assim, o código pode ser reescrito da seguinte maneira:

```

#include <stdio.h>

const char $SG3830[]="hello, world\n";

int main()
{
    printf($SG3830);
    return 0;
}

```

Vamos voltar para a listagem em assembly. Como podemos ver, a string é delimitada por um byte de valor zero, o que é padrão para strings em C/C++. Mais sobre strings em C/C++: ?? on page ??.

No segmento de código _TEXT, só há uma função por enquanto: main(). A função main() começa com um código como cabeçalho e termina com outro como rodapé (quase como qualquer outra função) ⁷.

Depois do cabeçalho da função, podemos ver a chamada para a função printf(): CALL _printf. Antes da chamada, o endereço da string (ou um ponteiro para o mesmo) contendo nossa saudação ("Hello, world!") é colocado na stack com a ajuda a instrução PUSH.

Quando o a função printf() retorna o controle para a função main(), o endereço da string (ou o ponteiro para a mesma) ainda está na stack. Como não precisamos mais dela, o apontador da stack (registrador ESP) precisa ser corrigido.

ADD ESP, 4 significa adicionar 4 para o valor do registrador ESP.

Mas por que 4? Como esse é um programa de 32-bits, nós precisamos exatamente 4 bytes para endereço passando pela stack. ADD ESP, 4 é equivalente a um POP mas sem precisar de nenhum registrador⁸.

Pelos mesmos motivos, alguns compiladores (como o Intel C++ Compiler) podem emitir POP ECX ao invés de ADD (esse padrão pode ser observado no código do Oracle RDBMS pois ele é compilado com o Intel C++ Compiler). Essa instrução tem quase o mesmo efeito mas o conteúdo de ECX seria apagado. O Intel C++ provavelmente usa POP ECX pois o opcode é menor do que ADD ESP, x (1 byte para POP ao invés de 3 para ADD).

Aqui está um exemplo do uso de POP ao invés de ADD do Oracle RDBMS:

⁷ [Brazilian Portuguese text placeholder \(1.5 on page 6\)](#).

⁸ [TBT⁹](#): CPU flags worden echter wel aangepast

1.4.

Listing 1.4: Oracle RDBMS 10.2 Linux (app.o file)

```
.text:0800029A      push     ebx
.text:0800029B      call    qksfroChild
.text:080002A0      pop     ecx
```

Depois de chamar `printf()`, o código original em C/C++ contém a declaração `return 0` — `return 0` como o resultado da função `main()`.

No código gerado, isso é implementado pela instrução `XOR EAX, EAX`.

`XOR` é a condição lógica “ou exclusivo”¹⁰ que os compiladores geralmente usam ao invés de `MOV EAX, 0` — de novo por causa de um pequeno decréscimo no número de bytes necessários (2 bytes para `XOR` contra 5 para a instrução `MOV`).

Alguns compiladores também usam `SUB EAX, EAX`, que significa, SUBtrair o valor contido em `EAX` do valor em `EAX`, que, em qualquer caso, resultará em zero.

A última instrução `RET` retorna o controle para onde a função foi chamada. Geralmente, isso é código C/C++ `CRT`¹¹, que retorna o controle para o sistema operacional.

1.4.2 x86-64

MSVC: x86-64

Vamos tentar também o MSVC 64-bits:

Listing 1.5: MSVC 2012 x64

```
$SG2989 DB      'hello, world', 0AH, 00H

main      PROC
          sub     rsp, 40
          lea    rcx, OFFSET FLAT:$SG2989
          call   printf
          xor    eax, eax
          add    rsp, 40
          ret    0
main      ENDP
```

No `x86-64`, todos os registradores foram estendidos para 64-bits e agora seus nomes contém um `R-` no prefixo. A fim de diminuir a frequência com que a `stack` (pilha) é usada (em outras palavras, para acessar memória externa/cache menos vezes), existe uma maneira popular de passar argumentos para funções através dos registradores (*fastcall*) ?? on page ??. Por exemplo, uma parte dos argumentos da função é passada nos registradores, o resto pela `stack`. No `Win64`, 4 argumentos de funções são passados através dos registradores `RCX`, `RDX`, `R8`, `R9`. Que é o que nós vemos, um ponteiro para a string para o `printf()` não é passado pela `stack`, mas no registrador `RCX`. Os ponteiros são 64-bits agora, então, eles são passados através dos registradores de 64-bits (que tem prefixo `R-`). Entretanto, para compatibilidade, ainda é possível acessar partes de 32-bits, usando o prefixo `E-`. É assim que os registradores `RAX/EAX/AX/AL` se parecem no `x86-64`:

Brazilian Portuguese text placeholder	
Brazilian Portuguese text placeholder	
RAX ^{x64}	
EAX	
AX	
AH	AL

A função `main()` retorna um valor do tipo inteiro, que em C/C++ é melhor para compatibilidade com versões anteriores e portabilidade, de 32-bits, por isso o registrador `EAX` é limpo no final da função (a parte de 32-bits do registrador) ao invés de `RAX`. Há também 40 bytes alocados na pilha local. Que é chamado de “`shadow space`”, o qual falaremos mais tarde: ?? on page ??.

¹⁰[wikipedia](#)

¹¹C Runtime library

1.4.3 Conclusão

A principal diferença entre os códigos em x86/ARM e x64/ARM64 é que o ponteiro para a string é agora 64-bits de tamanho. De fato, CPUs modernas agora são de 64-bits devido a redução do custo da memória e a demanda mais alta devido a aplicações mais modernas. Nós podemos adicionar muito mais memória nos nossos computadores do que ponteiros de 32-bits são capazes de endereçar. Como tal, todos os ponteiros são agora 64-bits.

1.4.4 Exercícios

- <http://challenges.re/48>
- <http://challenges.re/49>

1.5 Cabeçalhos e rodapés de funções

Um cabeçalho de uma função é uma sequência de instruções no começo da função. Ele geralmente se parece com algo como o código a seguir:

```
push    ebp
mov     ebp, esp
sub     esp, X
```

O que essas instruções fazem: salvam o valor no registrador EBP, mudam o valor de EBP para o valor em ESP e então aloca espaço na pilha para variáveis locais.

O valor em EBP continua o mesmo depois do período de execução da função e é para ser usado para variáveis locais e acessos de argumentos. Para o mesmo propósito pode ser usado o ESP, mas considerando que ele muda com o tempo, essa abordagem não é muito conveniente.

O rodapé da função libera o espaço alocado na pilha, retorna o valor do registrador EBP de volta ao seu estado inicial e retorna o controle de volta para a chamada da função:

```
mov     esp, ebp
pop     ebp
ret     0
```

Os cabeçalhos e rodapés das funções geralmente são detectados na desassemblagem para a delimitação das funções.

1.5.1 Recursividade

TBT

TBT

Epilogues and prologues can negatively affect the recursion performance.

More about recursion in this book: ?? on page ??.

1.6 Pilha

A pilha é uma das estruturas mais fundamentais na ciência da computação. ¹². AKA¹³ LIFO!¹⁴.

Tecnicamente, é só um bloco de memória junto com os registradores ESP ou RSP em x86 e x64, ou o SP¹⁵ no ARM, como um ponteiro para aquele bloco.

¹²wikipedia.org/wiki/Call_stack

¹³ Brazilian Portuguese text placeholder

¹⁴ LIFO!

¹⁵stack pointer. SP/ESP/RSP em x86/x64. SP em ARM.

1.6. PILHA

As instruções mais frequentes para o acesso da pilha são PUSH e POP (em ambos x86 e x64). PUSH subtrai de ESP/RSP/SP 4 no modo 32-bits (ou 8 no modo 64-bits) e então escreve o conteúdo desse operando único para o endereço de memória apontado por ESP/RSP/SP.

POP é a operação reversa: recupera a informação da localização de memória que é apontada por SP, carrega a mesma no operando da instrução (geralmente um registrador) e então adiciona 4 (ou 8) para o ponteiro da pilha.

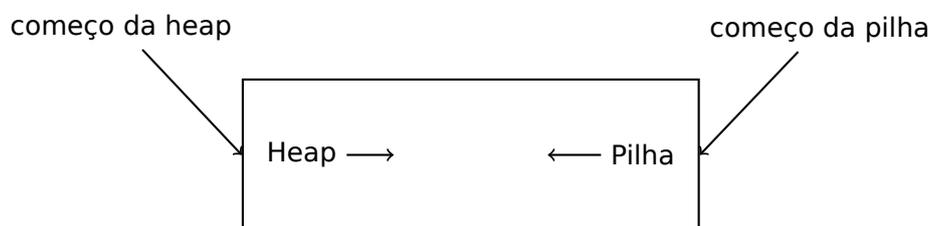
Depois da alocação da pilha, o ponteiro aponta para o fundo da pilha. PUSH decrementa o ponteiro da pilha e POP incrementa. O fundo da pilha está na verdade no começo do bloco de memória alocado para ela. Pode parecer estranho, mas é a maneira como é feita.

ARM: [Brazilian Portuguese text placeholder](#)

1.6.1 Por que a pilha “cresce” para trás?

Intuitivamente, nós podemos pensar que a pilha cresce para frente, em direção a endereços mais altos, como qualquer outra estrutura de informação.

O motivo da pilha crescer para trás é provavelmente histórico. Quando os computadores eram grandes e ocupavam um cômodo todo, era mais fácil dividir a memória em duas partes, uma para a ‘heap’ e outra para a pilha. Logicamente, era desconhecido o quão grande a heap e a pilha seriam durante a execução do programa, então essa solução era a mais simples possível.



No [D. M. Ritchie and K. Thompson, *The UNIX Time Sharing System*, (1974)]¹⁶ nós podemos ler:

A parte relacionada ao usuário é dividida em três segmentos lógicos. O segmento de texto do programa começa na localização 0 no espaço virtual de endereçamento. Durante a execução, esse segmento é protegido para não ser reescrito e uma única cópia dele é compartilhado entre todos os processos executando o mesmo programa. Começando no limite de 8Kbytes acima do segmento de texto do programa no espaço de endereçamento virtual começa um segmento de informação gravável, não compartilhável e de um tamanho que pode ser estendido por uma chamada do sistema. Começando no endereço mais alto no espaço de endereçamento virtual está a pilha, que automaticamente cresce para trás conforme o ponteiro da pilha do hardware se altera.

Isso pode ser análogo a como um estudante escreve notas de duas matérias diferentes em um caderno só: as notas para a primeira matéria são escritas como de costume e as notas para a segunda são escritas do final do caderno, virando o mesmo. As anotações de uma matéria podem encontrar as da outra no meio, no caso de haver falta de espaço.

1.6.2 Para que a pilha é usada?

Salvar o endereço de retorno de uma função

x86

Quando você chama outra função utilizando a instrução CALL, o endereço do ponto exato onde a instrução CALL se encontra é salvo na pilha e então um jump incondicional para o endereço no operando de CALL é executado.

A instrução CALL é equivalente a usar o par de instruções PUSH endereço_depois_chamada / JMP.

RET pega um valor da pilha e usa um jump para ele — isso é equivalente a usar POP tmp / JMP tmp.

¹⁶Também disponível como <http://go.yurichev.com/17270>

1.6. PILHA

Estourar uma stack é fácil. Só execute alguma recursão externa:

```
void f()
{
    f();
};
```

O compilador MSVC 2008 informa o problema:

```
c:\tmp6>cl ss.cpp /Fass.asm
Microsoft (R) 32-bit C/C++ Optimizing Compiler Version 15.00.21022.08 for 80x86
Copyright (C) Microsoft Corporation. All rights reserved.

ss.cpp
c:\tmp6\ss.cpp(4) : warning C4717: 'f' : recursive on all control paths, function will cause ↵
↳ runtime stack overflow
```

...mas gera o código de qualquer maneira:

```
?f@@YAXXZ PROC                ; f
; File c:\tmp6\ss.cpp
; Line 2
    push    ebp
    mov     ebp, esp
; Line 3
    call   ?f@@YAXXZ          ; f
; Line 4
    pop     ebp
    ret     0
?f@@YAXXZ ENDP                ; f
```

...também, se ativarmos a otimização do compilador (opção /Ox) o código otimizado não vai estourar a pilha e funcionará *corretamente* ¹⁷:

```
?f@@YAXXZ PROC                ; f
; File c:\tmp6\ss.cpp
; Line 2
$LL3@f:
; Line 3
    jmp     SHORT $LL3@f
?f@@YAXXZ ENDP                ; f
```

Brazilian Portuguese text placeholder

Passando argumento de funções

A maneira mais comum de se passar parâmetros no x86 é chamada «cdecl»:

```
push arg3
push arg2
push arg1
call f
add esp, 12 ; 4*3=12
```

Uma função chamada recebe seus argumentos pelo ponteiro da pilha.

Portanto, é assim que os valores dos argumentos são alocados na pilha antes da execução das primeiras instruções da função f():

ESP	endereço de retorno
ESP+4	argumento#1, Marcado no IDA¹⁸ como arg_0
ESP+8	argumento#2, Marcado no IDA como arg_4
ESP+0xC	argumento#3, Marcado no IDA como arg_8
...	...

¹⁷ironia aqui

1.6. PILHA

Brazilian Portuguese text placeholder

Vale ressaltar que nada obriga o programador a passar os argumentos pela pilha. Não é um requerimento. Você pode implementar qualquer outro método usando a pilha da maneira que desejar.

Por exemplo, é possível alocar um espaço para argumentos na [heap](#), preencher e passar para a função via um ponteiro para esse bloco no registrador EAX.

Isso vai funcionar, entretando, é de senso comum no x86 e ARM a usar a pilha para esse fim.

A propósito, a função chamada não tem nenhuma informação sobre quantos argumentos foram passados. Funções em C com um número variável de argumentos (como `printf()`) determina seu número usando formatações específicas de string (que começam com o símbolo %).

Se nós escrevermos algo como:

```
printf("%d %d %d", 1234);
```

`printf()` vai mostrar 1234, e então dois números aleatórios, que estariam próximos a `stack`¹⁹.

É por isso que não é muito importante como declaramos a função `main()`: como `main()`, `main(int argc, char *argv[])` ou `main(int argc, char *argv[], char *envp[])`.

Na verdade, o código da C Runtime Library está chamando grosseiramente `main()` dessa maneira:

```
push envp
push argv
push argc
call main
...
```

Se você declarar `main()` como `main()` sem argumentos, mesmo assim eles ainda estarão presentes na pilha, mas não são usados. Se você declarar `main()` como `main(int argc, char *argv[])`, você será capaz de utilizar os primeiros dois argumentos e o terceiro vai continuar «invisível» para a sua função. Da mesma maneira, é possível declarar a `main()` como `main(int argc)` e ainda assim vai funcionar.

Armazenamento de variáveis locais

Uma função poderia alocar espaço na pilha para suas variáveis locais simplesmente decrementando o ponteiro da pilha.

Consequentemente, é muito rápido, não importando quantas variáveis locais serão definidas. Também não é um requisito armazenar variáveis locais na pilha. Você pode armazenar variáveis locais onde você quiser, mas, tradicionalmente, é assim que é feito.

x86: a função `alloca()`

A função `alloca()`²⁰ funciona da mesma maneira que `malloc()`, mas aloca memória diretamente na pilha. O bloco de memória alocado não precisa ser limpo através da chamada da função `free()`, desde que o rodapé da função ([1.5 on page 6](#)) retorna ESP de volta para seu estado inicial e a memória alocada é simplesmente desassociada. Sobre como a função `alloca()` é implementada, em termos simples, essa função só desloca ESP para baixo (em direção ao fundo da pilha) pelo número de bytes que você precisa e define o ESP como um ponteiro para o bloco alocado.

Vamos tentar:

```
#ifdef __GNUC__
#include <alloca.h> // GCC
#else
#include <malloc.h> // MSVC
#endif
#include <stdio.h>

void f()
{
```

¹⁹TBT

²⁰No MSVC, a implementação da função pode ser encontrada nos arquivos `alloca16.asm` e `chkstk.asm` em `C:\Program Files (x86)\Microsoft Visual Studio 10.0\VC\crt\src\intel`

1.6. PILHA

```
char *buf=(char*)alloca (600);
#ifdef __GNUC__
    snprintf (buf, 600, "hi! %d, %d, %d\n", 1, 2, 3); // GCC
#else
    _snprintf (buf, 600, "hi! %d, %d, %d\n", 1, 2, 3); // MSVC
#endif

    puts (buf);
};
```

A função `_snprintf()` funciona exatamente como `printf()`, mas ao invés de jogar o resultado em `stdout` (terminal ou console, por exemplo), ela escreve no buffer `buf`. A função `puts()` copia o conteúdo para um `buf` do `stdout`. Lógico, essas duas chamadas de funções podem ser substituídas por um `printf()`, mas nós temos que ilustrar o uso pequeno do buffer.

MSVC

Vamos compilar (MSVC 2010):

Listing 1.6: MSVC 2010

```
...
mov     eax, 600 ; 00000258H
call   __alloca_probe_16
mov     esi, esp

push   3
push   2
push   1
push   OFFSET $SG2672
push   600 ; 00000258H
push   esi
call   __snprintf

push   esi
call   _puts
add    esp, 28
...
```

O único argumento da função `alloca()` é passado via `EAX` (ao invés de ser empurrado na pilha) ²¹.

Depois da chamada de `alloca()`, `ESP` aponta para o bloco de 600 bytes que nós podemos usar como memória para o array.

GCC + Sintaxe Intel

Brazilian Portuguese text placeholder

(Windows) SEH

SEH²² também são guardados na pilha (se estiverem presentes). Brazilian Portuguese text placeholder: (4.2.1 on page 31).

Proteção contra estouro de buffer

Mais sobre aqui (1.13.2 on page 27).

²¹Isso é devido ao fato de que `alloca()` é mais nativa do compilador do que uma função normal (?? on page ??). Um dos motivos que se faz necessário o separamento da função ao invés de um pouco de linhas de código no código, é porque a implementação da `alloca()` no MSVC também tem código que é lido da memória que acabou de ser alocada, para deixar o sistema operacional mapear a memória física para essa região da memória virtual.

²²Structured Exception Handling

Brazilian Portuguese text placeholder

Talvez, o motivo para armazenar variáveis locais e registros SEH na pilha é que eles são desvinculados automaticamente depois do fim da função, usando somente uma instrução para corrigir o ponteiro da pilha (geralmente é ADD). Argumentos de funções, como podemos dizer, são também desalocados automaticamente com o fim da função. Como contraste, tudo armazenado na memória heap tem de ser desalocado explicitamente.

1.6.3 Um modelo típico de pilha

Um modelo típico de pilha em um ambiente 32-bits no início de uma função, antes da execução da primeira instrução, se parece com isso:

...	...
ESP-0xC	Variável local#2, Marcado no IDA como var_8
ESP-8	Variável local#1, Marcado no IDA como var_4
ESP-4	Valor salvo deEBP
ESP	Endereço de retorno
ESP+4	argumento#1, Marcado no IDA como arg_0
ESP+8	argumento#2, Marcado no IDA como arg_4
ESP+0xC	argumento#3, Marcado no IDA como arg_8
...	...

1.6.4 Exercícios

- <http://challenges.re/51>
- <http://challenges.re/52>

1.7 printf() com vários argumentos

Agora vamos estender o nosso exemplo (1.4 on page 3), trocando printf() no corpo da função main() () por isso:

```
#include <stdio.h>

int main()
{
    printf("a=%d; b=%d; c=%d", 1, 2, 3);
    return 0;
};
```

1.7.1 x86**x86: 3 argumentos****MSVC**

Quando compilamos esse código com o MSVC 2010 Express temos:

```
$SG3830 DB      'a=%d; b=%d; c=%d', 00H

...

    push    3
    push    2
    push    1
    push    OFFSET $SG3830
    call    _printf
    add     esp, 16                ; 00000010H
```

1.7. PRINTF() COM VÁRIOS ARGUMENTOS

Quase a mesma coisa, mas agora nós podemos ver que os argumentos da função `printf()` são empurrados na pilha na ordem reversa. O primeiro argumento é empurrado por último.

A propósito, variáveis do tipo `int` em ambientes 32-bits tem 32-bits de largura, isso é 4 bytes.

Então, nós temos quatro argumentos aqui, $4 * 4 = 16$ — eles ocupam exatamente 16 bytes na pilha: um ponteiro de 32-bits para uma string e três números do tipo `int`.

Quando o ponteiro da pilha (registrador ESP) volta para seu valor anterior pela instrução `ADD ESP, X` depois de uma chamada de função, geralmente o número de argumentos pode ser obtido simplesmente por se dividir `X`, o argumento da função `ADD`, por 4.

Lógico que isso é por causa da convenção de chamada do `cdecl` e somente para ambientes 32-bits.

x64: 8 argumentos

Para ver como outros argumentos são passados pela pilha, vamos mudar nosso exemplo novamente aumentando o numero de argumentos para 9 (`printf()` + 8 variáveis `int`):

```
#include <stdio.h>

int main()
{
    printf("a=%d; b=%d; c=%d; d=%d; e=%d; f=%d; g=%d; h=%d\n", 1, 2, 3, 4, 5, 6, 7, 8);
    return 0;
};
```

MSVC

Como mencionado anteriormente, os primeiros 4 argumentos tem de ser passados pelos registradores RCX, RDX, R8, R9 no Win64, enquanto o resto pela pilha. Isso é exatamente o que veremos aqui. Entretanto, a instrução `MOV`, ao invés de `PUSH`, é usada para preparar a pilha, portanto os valores são armazenados de uma maneira direta.

Listing 1.7: MSVC 2012 x64

```
$SG2923 DB      'a=%d; b=%d; c=%d; d=%d; e=%d; f=%d; g=%d; h=%d', 0aH, 00H

main PROC
sub     rsp, 88

        mov     DWORD PTR [rsp+64], 8
        mov     DWORD PTR [rsp+56], 7
        mov     DWORD PTR [rsp+48], 6
        mov     DWORD PTR [rsp+40], 5
        mov     DWORD PTR [rsp+32], 4
        mov     r9d, 3
        mov     r8d, 2
        mov     edx, 1
        lea    rcx, OFFSET FLAT:$SG2923
        call   printf

        ; return 0
        xor     eax, eax

        add     rsp, 88
        ret     0
main    ENDP
_TEXT  ENDS
END
```

Um leitor observativo pode se indagar por que são alocados 8 bytes para valores `int` quando 4 já é suficiente? Sim, mas lembre-se: 8 bytes são alocados para qualquer tipo de informação menor do que 64 bits. Isso é estabelecido com o objetivo de ser conveniente: é mais fácil calcular o endereço de um argumento arbitrário. Além do mais, eles são alocados em endereços de memórias alinhados. Da mesma maneira no 32-bits: 4 bytes são reservados para todos os tipos de informação.

Brazilian Portuguese text placeholder

1.7.2 ARM

1.7.3 Conclusão

Aqui está uma estrutura bem rústica da chamada da função

Listing 1.8: x86

```
...  
PUSH 3rd argument  
PUSH 2nd argument  
PUSH 1st argument  
CALL function  
; modify stack pointer (if needed)
```

Listing 1.9: x64 (MSVC)

```
MOV RCX, 1st argument  
MOV RDX, 2nd argument  
MOV R8, 3rd argument  
MOV R9, 4th argument  
...  
PUSH 5th, 6th argument, etc. (if needed)  
CALL function  
; modify stack pointer (if needed)
```

Listing 1.10: x64 (GCC)

```
MOV RDI, 1st argument  
MOV RSI, 2nd argument  
MOV RDX, 3rd argument  
MOV RCX, 4th argument  
MOV R8, 5th argument  
MOV R9, 6th argument  
...  
PUSH 7th, 8th argument, etc. (if needed)  
CALL function  
; modify stack pointer (if needed)
```

Listing 1.11: ARM

```
MOV R0, 1st argument  
MOV R1, 2nd argument  
MOV R2, 3rd argument  
MOV R3, 4th argument  
; pass 5th, 6th argument, etc., in stack (if needed)  
BL function  
; modify stack pointer (if needed)
```

Listing 1.12: ARM64

```
MOV X0, 1st argument  
MOV X1, 2nd argument  
MOV X2, 3rd argument  
MOV X3, 4th argument  
MOV X4, 5th argument  
MOV X5, 6th argument  
MOV X6, 7th argument  
MOV X7, 8th argument  
; pass 9th, 10th argument, etc., in stack (if needed)  
BL function  
; modify stack pointer (if needed)
```

Listing 1.13: MIPS (O32 calling convention)

```
LI $4, 1st argument ; AKA $A0  
LI $5, 2nd argument ; AKA $A1  
LI $6, 3rd argument ; AKA $A2  
LI $7, 4th argument ; AKA $A3  
; pass 5th, 6th argument, etc., in stack (if needed)
```

1.8. SCANF()

```
LW temp_reg, address of function
JALR temp_reg
```

1.7.4 A propósito

A propósito, a diferença entre os argumentos passados em x86, x64, fastcall, ARM e MIPS é uma boa demonstração do fato de como a CPU é indiferente sobre como os argumentos são passados para as funções. Também é possível criar um compilador hipotético capaz de passar argumentos por alguma outra estrutura especial sem usar a pilha de nenhuma maneira.

Brazilian Portuguese text placeholder

A CPU não está ciente de convenções de chamada de funções.

Agora nós podemos também lembrar de dos programadores novatos de assembly passando argumentos para outras funções: geralmente via registradores, sem nenhuma sequência explícita, ou mesmo por variáveis globais. Logicamente, também funciona.

1.8 scanf()

Agora vamos usar a função scanf().

1.8.1 Exemplo simples

```
#include <stdio.h>

int main()
{
    int x;
    printf ("Enter X:\n");

    scanf ("%d", &x);

    printf ("You entered %d...\n", x);

    return 0;
};
```

Não é muito inteligente usar scanf() para interações com o usuário nos dias de hoje. Mas nós podemos, de qualquer maneira, ilustrar passando um ponteiro para uma variável do tipo *int*.

Sobre ponteiros

Ponteiros são um dos conceitos mais fundamentais na ciência da computação. Com frequência, passar um array grande, estrutura ou objeto como um argumento para outra função é muito custoso, enquanto passar o endereço de onde ele está é bem mais rápido e gasta menos recursos. Ainda mais se a função chamada precisa modificar alguma coisa em um array grande ou estrutura recebida como parâmetro e retornar de volta a estrutura inteira se torna perto de absurdo fazer dessa maneira. Então a coisa mais simples a se fazer é passar o endereço do array ou estrutura para a função chamada e deixar ela fazer as mudanças necessárias.

Um ponteiro em C/C++ é somente um endereço de alguma localização de memória.

Em x86, o endereço é representado como um número de 32-bits (ele ocupa 4 bytes), enquanto no x86-64 é um número de 64-bits (ocupando 8 bytes). A propósito, essa é a razão da indignação de algumas pessoas em relação a trocar para x86-64 todos os ponteiros na arquitetura x64, exigindo o dobro de espaço, incluindo memória cache, que é um lugar “caro”.

É possível ainda se trabalhar com ponteiros sem tipos, como a função padrão em C `memcpy()`, que copia um block de uma localização de memória para outro, ela recebe como argumento dois ponteiros do tipo

1.8. SCANF()

void*, uma vez que é impossível de se prever o tipo de informação que você gostaria de copiar. Tipos não são importantes, só o tamanho do bloco de memória é que importa.

Ponteiros são também largamente usados quando uma função precisa retornar mais de um valor (nós vamos voltar nisso depois) (?? on page ??).

scanf() é um desses casos.

Além do fato de que a função precisa indicar quantos valores foram lidos com sucesso, ela também precisa retornar todos esses valores.

Em C/C++ os tipos dos ponteiros só são necessários para checagem em tempo de compilação.

Internamente, no código compilado não tem nenhuma informação sobre os tipos de cada ponteiro.

x86

MSVC

Aqui está o que o resultado depois de se compilar com o MSVC 2010:

```
CONST    SEGMENT
$SG3831  DB      'Enter X:', 0aH, 00H
$SG3832  DB      '%d', 00H
$SG3833  DB      'You entered %d...', 0aH, 00H
CONST    ENDS
PUBLIC   _main
EXTRN   _scanf:PROC
EXTRN   _printf:PROC
; Function compile flags: /Odtp
_TEXT   SEGMENT
_x$ = -4                                ; size = 4
_main   PROC
    push    ebp
    mov     ebp, esp
    push    ecx
    push    OFFSET $SG3831 ; 'Enter X:'
    call   _printf
    add     esp, 4
    lea    eax, DWORD PTR _x$[ebp]
    push    eax
    push    OFFSET $SG3832 ; '%d'
    call   _scanf
    add     esp, 8
    mov    ecx, DWORD PTR _x$[ebp]
    push    ecx
    push    OFFSET $SG3833 ; 'You entered %d...'
    call   _printf
    add     esp, 8

    ; return 0
    xor    eax, eax
    mov    esp, ebp
    pop    ebp
    ret    0
_main   ENDP
_TEXT   ENDS
```

x é uma variável local.

De acordo com os padrões de C/C++ ela só deve ser visível nessa função e não além dela. Tradicionalmente, variáveis locais são guardadas na pilha. Provavelmente há outras maneiras de alocá-las, mas no x86 é assim que é feito.

O objetivo da instrução que se segue após o cabeçalho da função, PUSH ECX, não é para salvar o valor de ECX (perceba que não há a instrução POP ECX no fim da função).

Na verdade, esse PUSH aloca 4 bytes na pilha para guardar a variável x.

1.8. SCANF()

x é para ser acessada com a ajuda do macro `_x$` (que é igual a `-4`) e o registrador EBP apontando para a posição atual.

Conforme a execução da função avança, EBP está apontando para a posição atual da pilha, sendo possível acessar variáveis locais e argumentos da função via `EBP+offset`.

Também é possível usar ESP para o mesmo objetivo, mas não é muito conveniente pois ele se altera com frequência. O valor de EBP pode ser visto como uma cópia do valor de ESP no começo da execução da função.

Aqui está a aparência típica de uma pilha em um ambiente de 32-bits:

...	...
EBP-8	variável local #2, Marcado no IDA como <code>var_8</code>
EBP-4	variável local #1, Marcado no IDA como <code>var_4</code>
EBP	valor salvo de EBP
EBP+4	Endereço de retorno
EBP+8	argumento#1, Marcado no IDA como <code>arg_0</code>
EBP+0xC	argumento#2, Marcado no IDA como <code>arg_4</code>
EBP+0x10	argumento#3, Marcado no IDA como <code>arg_8</code>
...	...

A função `scanf()` no nosso exemplo tem dois argumentos.

O primeiro é um ponteiro para a string contendo `%d` e a segunda é o endereço da variável `x`.

Primeiro, o endereço da variável `x` é carregado no registrador EAX pela instrução `lea eax, DWORD PTR _x$[ebp]..`

Brazilian Portuguese text placeholder

Nós podemos dizer que nesse caso, `LEA` simplesmente armazena a soma do valor em EBP e o macro `_x$` no registrador EAX.

É a mesma coisa que `lea eax, [ebp-4]`.

Então, 4 está sendo subtraído do registrador EBP e o resultado é carregado no registrador EAX. Depois, o valor em EAX é empurrado para dentro da pilha e o `scanf()` é chamado.

`printf()` é chamado depois disso com seu primeiro argumento — um ponteiro para a string: `You entered %d...\n`.

O segundo argumento é preparado com: `mov ecx, [ebp-4]`. A instrução armazena o valor de `x` e não o seu endereço, no registrador ECX.

Depois, o valor em ECX é armazenado na pilha e o último `printf()` é chamado.

Brazilian Portuguese text placeholder

A propósito, esse simples exemplo é a demonstração do fato de que o compilador traduz a lista de expressões em C/C++ em uma lista sequencial de instruções. Não há nada entre as expressões em C/C++, como também no código de máquina resultante, não há nada, o controle de fluxo passa de uma expressão para a outra diretamente.

x64

A situação aqui é parecida, mas com a diferença de que os registradores, ao invés da pilha, são usados para passar argumentos.

MSVC

Listing 1.14: MSVC 2012 x64

```
_DATA SEGMENT
$SG1289 DB 'Enter X:', 0aH, 00H
$SG1291 DB '%d', 00H
$SG1292 DB 'You entered %d...', 0aH, 00H
_DATA ENDS
```

1.8. SCANF()

```
_TEXT SEGMENT
x$ = 32
main PROC
$LN3:
    sub     rsp, 56
    lea    rcx, OFFSET FLAT:$SG1289 ; 'Enter X:'
    call   printf
    lea    rdx, QWORD PTR x$[rsp]
    lea    rcx, OFFSET FLAT:$SG1291 ; '%d'
    call   scanf
    mov    edx, DWORD PTR x$[rsp]
    lea    rcx, OFFSET FLAT:$SG1292 ; 'You entered %d...'
    call   printf

    ; return 0
    xor    eax, eax
    add    rsp, 56
    ret    0
main ENDP
_TEXT ENDS
```

GCC

Listing 1.15: Com otimização GCC 4.4.6 x64

```
.LC0:
.string "Enter X:"
.LC1:
.string "%d"
.LC2:
.string "You entered %d...\n"

main:
    sub     rsp, 24
    mov     edi, OFFSET FLAT:.LC0 ; "Enter X:"
    call   puts
    lea    rsi, [rsp+12]
    mov     edi, OFFSET FLAT:.LC1 ; "%d"
    xor    eax, eax
    call   __isoc99_scanf
    mov     esi, DWORD PTR [rsp+12]
    mov     edi, OFFSET FLAT:.LC2 ; "You entered %d...\n"
    xor    eax, eax
    call   printf

    ; return 0
    xor    eax, eax
    add    rsp, 24
    ret
```

1.8.2 Variáveis globais

E se a variável `x` do último exemplo não fosse local, mas sim global? Então ela teria que ser acessível de qualquer ponto, não somente pelo corpo da função. Variáveis globais são consideradas maus hábitos, mas pelo bem do experimento, nós faremos isso.

```
#include <stdio.h>

// now x is global variable
int x;

int main()
{
    printf ("Enter X:\n");
```

1.8. SCANF()

```
scanf ("%d", &x);

printf ("You entered %d...\n", x);

return 0;
};
```

MSVC: x86

```
_DATA    SEGMENT
_COMM    _x:DWORD
$SG2456  DB    'Enter X:', 0aH, 00H
$SG2457  DB    '%d', 00H
$SG2458  DB    'You entered %d...', 0aH, 00H
_DATA    ENDS
PUBLIC   _main
EXTRN   _scanf:PROC
EXTRN   _printf:PROC
; Function compile flags: /Odtp
_TEXT   SEGMENT
_main   PROC
    push    ebp
    mov     ebp, esp
    push    OFFSET $SG2456
    call    _printf
    add     esp, 4
    push    OFFSET _x
    push    OFFSET $SG2457
    call    _scanf
    add     esp, 8
    mov     eax, DWORD PTR _x
    push    eax
    push    OFFSET $SG2458
    call    _printf
    add     esp, 8
    xor     eax, eax
    pop     ebp
    ret     0
_main    ENDP
_TEXT    ENDS
```

Nesse caso, a variável `x` é definida no segmento `_DATA` e nenhuma memória é alocada na pilha local. Ela é acessada diretamente, não através da pilha. Variáveis globais não inicializadas não ocupam espaço no arquivo executável (realmente, ninguém precisa alocar espaço para uma variável inicialmente valendo zero), mas quando alguém acessa o endereço delas, o sistema operacional vai alocar um bloco contendo somente zeros nele. ²³

Agora vamos definir um valor para a variável:

```
int x=10; // default value
```

Nós temos:

```
_DATA    SEGMENT
_x       DD    0aH

...
```

Aqui nós vemos um valor `0xA` do tipo `DWORD` (`DD` significa `DWORD` = 32 bits) para essa variável.

Se você abrir o `.exe` compilado no [IDA](#), você pode ver a variável `x` colocada no começo do segmento `_DATA`, e depois disso você pode ver as strings.

Se você abrir o `.exe` compilado no exemplo anterior no [IDA](#), onde o valor de `x` não foi declarado, você poderá ver algo assim:

²³TBT: That is how a [VM²⁴](#) behaves

1.8. SCANF()

Listing 1.16: IDA

```
.data:0040FA80 _x          dd ?    ; DATA XREF: _main+10
.data:0040FA80          ; _main+22
.data:0040FA84 dword_40FA84 dd ?    ; DATA XREF: _memset+1E
.data:0040FA84          ; unknown_libname_1+28
.data:0040FA88 dword_40FA88 dd ?    ; DATA XREF: ___sbh_find_block+5
.data:0040FA88          ; ___sbh_free_block+2BC
.data:0040FA8C ; LPVOID lpMem
.data:0040FA8C lpMem      dd ?    ; DATA XREF: ___sbh_find_block+B
.data:0040FA8C          ; ___sbh_free_block+2CA
.data:0040FA90 dword_40FA90 dd ?    ; DATA XREF: _V6_HeapAlloc+13
.data:0040FA90          ; __calloc_impl+72
.data:0040FA94 dword_40FA94 dd ?    ; DATA XREF: ___sbh_free_block+2FE
```

_x está marcada com ? juntamente com o resto das variáveis que não precisam ser inicializadas. Isso implica que após carregar o .exe para a memória, um espaço para todas essas variáveis será alocado e preenchido com zeros [ISO/IEC 9899:TC3 (C C99 standard), (2007)6.7.8p10]. Mas no arquivo .exe essas variáveis não inicializadas não ocupam nenhum espaço. Isso é conveniente para arrays grandes, por exemplo.

GCC: x86

Brazilian Portuguese text placeholder

MSVC: x64

Listing 1.17: MSVC 2012 x64

```
_DATA SEGMENT
COMM  x:DWORD
$SG2924 DB      'Enter X:', 0aH, 00H
$SG2925 DB      '%d', 00H
$SG2926 DB      'You entered %d...', 0aH, 00H
_DATA  ENDS

_TEXT SEGMENT
main  PROC
$LN3:
    sub     rsp, 40

    lea    rcx, OFFSET FLAT:$SG2924 ; 'Enter X:'
    call   printf
    lea    rdx, OFFSET FLAT:x
    lea    rcx, OFFSET FLAT:$SG2925 ; '%d'
    call   scanf
    mov    edx, DWORD PTR x
    lea    rcx, OFFSET FLAT:$SG2926 ; 'You entered %d...'
    call   printf

    ; return 0
    xor    eax, eax

    add    rsp, 40
    ret    0
main  ENDP
_TEXT ENDS
```

O código é quase o mesmo que no x86. Por favor, perceba que o endereço da variável x é passado para scanf() usando uma instrução LEA, enquanto os valores das variáveis são passadas para o segundo printf() usando uma instrução MOV. DWORD PTR é uma parte da linguagem assembly (sem relação com o código de máquina), indicando que o tamanho da informação da variável é de 32-bits e que a instrução MOV tem de ser codificada de acordo.

1.8.3 Checagem de resultados do scanf()

Como dito anteriormente, está meio fora de moda usar `scanf()` atualmente, mas nós temos que fazer. Precisamos ao menos testar se a função `scanf()` termina corretamente sem nenhum erro.

```
#include <stdio.h>

int main()
{
    int x;
    printf ("Enter X:\n");

    if (scanf ("%d", &x)==1)
        printf ("You entered %d...\n", x);
    else
        printf ("What you entered? Huh?\n");

    return 0;
};
```

Por padrão, a função `scanf()`²⁵ retorna o número de campos que ela leu com sucesso.

No nosso caso, se tudo ocorrer bem e o usuário entrar com um número, `scanf()` retornará 1, ou em caso de erro (ou EOF²⁶) — 0.

Vamos adicionar um pouco de código em C para checar o valor de retorno de `scanf()` e imprimir uma mensagem no caso de um erro.

Isso funciona com o desejado:

```
C:\...>ex3.exe
Enter X:
123
You entered 123...

C:\...>ex3.exe
Enter X:
ouch
What you entered? Huh?
```

MSVC: x86

Aqui está o a saída em assembly (MSVC 2010):

```
    lea    eax, DWORD PTR _x$[ebp]
    push  eax
    push  OFFSET $SG3833 ; '%d', 00H
    call  _scanf
    add   esp, 8
    cmp   eax, 1
    jne   SHORT $LN2@main
    mov   ecx, DWORD PTR _x$[ebp]
    push  ecx
    push  OFFSET $SG3834 ; 'You entered %d...', 0aH, 00H
    call  _printf
    add   esp, 8
    jmp   SHORT $LN1@main
$LN2@main:
    push  OFFSET $SG3836 ; 'What you entered? Huh?', 0aH, 00H
    call  _printf
    add   esp, 4
$LN1@main:
    xor   eax, eax
```

A função que chamou (`main()`) precisa do resultado da função chamada (`scanf()`), então a função chamada retorna esse valor no registrador EAX.

²⁵`scanf`, `wscanf`: [MSDN](#)

²⁶End of File

1.8. SCANF()

Nós verificamos com a ajuda da instrução `CMP EAX, 1` (*CoMP*arar). Em outras palavras, comparamos o valor em `EAX` com `1`.

O jump condicional `JNE` está logo depois da instrução `CMP`. `JNE` significa *Jump if Not Equal* ou seja, ela desvia se o valor não for igual ao comparado.

Então, se o valor em `EAX` não é `1`, a `CPU` vai passar a execução para o endereço contido no operando de `JNE`, no nosso caso `$LN2@main`. Passando a execução para esse endereço resulta na `CPU` executando `printf()` com o argumento `What you entered? Huh?`. Mas se tudo estiver correto, o jump condicional não será efetuado e outra chamada do `printf()` é executada, com dois argumentos: ``You entered %d...'` e o valor de `x`.

Como nesse caso o segundo `printf()` não tem que ser executado, tem um `JMP` precedendo ele (jump incondicional). Ele passa a execução para o ponto depois do segundo `printf()` e logo antes de `XOR EAX, EAX`, que implementa `return 0`.

Então, podemos dizer que comparar um valor com outro é geralmente realizado através do par de instruções `CMP/Jcc`, onde `cc` é código condicional. `CMP` compara dois valores e altera os registros da `CPU` (flags)²⁷. `Jcc` checa esses registros e decide passar a execução para o endereço específico contido no operando ou não.

Isso pode parecer meio paradoxal, mas a instrução `CMP` é na verdade `SUB` (subtrair). Todo o conjunto de instruções aritméticas alteram os registros da `CPU`, não só `CMP`. Se comparamos `1` e `1`, `1 - 1` é `0` então `ZF` (zero flag) será acionado (significando que o último resultado foi zero). Em nenhuma outra circunstância `ZF` pode ser acionado, exceto quando os operandos forem iguais. `JNE` verifica somente o `ZF` e desvia só não estiver acionado. `JNE` é na verdade um sinônimo para `JNZ` (jump se não zero). `JNE` e `JNZ` são traduzidos no mesmo código de operação. Então, a instrução `CMP` pode ser substituída com a instrução `SUB` e quase tudo estará certo, com a diferença de que `SUB` altera o valor do primeiro operando. `CMP` é `SUB` sem salvar o resultado, mas afetando os registros da `CPU`.

MSVC: x86: IDA

Brazilian Portuguese text placeholder

²⁷TBT: x86 flags, see also: [wikipedia](#).

Esse exemplo também pode ser usado como uma maneira simples de exemplificar o patch de arquivos executáveis. Nós podemos tentar rearranjar o executável de forma que o programa sempre imprima a saída, não importando o que inserirmos.

Assumindo que o executável está compilado com a opção /MD²⁸ (MSVCR*.DLL), nós vemos a função main no começo da seção .text. Vamos abrir o executável no Hiew e procurar o começo da seção .text (Enter, F8, F6, Enter, Enter).

Nós chegamos a isso:

```

Hiew: ex3.exe
C:\Polygon\ollydbg\ex3.exe  FRO ----- a32 PE .00401000 Hie
.00401000: 55          push     ebp
.00401001: 8BEC       mov     ebp,esp
.00401003: 51         push     ecx
.00401004: 6800304000 push    000403000 ;'Enter X:' --[1]
.00401009: FF1594204000 call    printf
.0040100F: 83C404     add     esp,4
.00401012: 8D45FC     lea    eax,[ebp][-4]
.00401015: 50         push     eax
.00401016: 680C304000 push    00040300C --[2]
.0040101B: FF158C204000 call    scanf
.00401021: 83C408     add     esp,8
.00401024: 83F801     cmp     eax,1
.00401027: 7514       jnz    .0040103D --[3]
.00401029: 8B4DFC     mov     ecx,[ebp][-4]
.0040102C: 51         push     ecx
.0040102D: 6810304000 push    000403010 ;'You entered %d...'
.00401032: FF1594204000 call    printf
.00401038: 83C408     add     esp,8
.0040103B: EB0E       jmps   .0040104B --[5]
.0040103D: 6824304000 3push   000403024 ;'What you entered?'
.00401042: FF1594204000 call    printf
.00401048: 83C404     add     esp,4
.0040104B: 33C0      5xor    eax,eax
.0040104D: 8BE5      mov     esp,ebp
.0040104F: 5D        pop     ebp
.00401050: C3        retn   ; _^_ ^_ ^_ ^_ ^_ ^_ ^_ ^_ ^_ ^_ ^_ ^_ ^_ ^_ ^_ ^_
.00401051: B84D5A0000 mov     eax,00005A4D ;' ZM'
1Global 2FilBlk 3CryBlk 4ReLoad 5OrdLdr 6String 7Direct 8Table 91byte 10Leave 11Nak

```

Figura 1.1: Brazilian Portuguese text placeholder

Hiew encontra strings em ASCIIZ²⁹ e as exibe, como faz com os nomes de funções importadas.

²⁸isso também é chamada “linkagem dinâmica”

²⁹ASCII Zero (Brazilian Portuguese text placeholder)

1.8. SCANF()

quando trabalhamos com ponteiros, as partes dos registradores de 64-bits são usadas, prefixadas com R-.

Listing 1.18: MSVC 2012 x64

```
_DATA SEGMENT
$SG2924 DB 'Enter X:', 0aH, 00H
$SG2926 DB '%d', 00H
$SG2927 DB 'You entered %d...', 0aH, 00H
$SG2929 DB 'What you entered? Huh?', 0aH, 00H
_DATA ENDS

_TEXT SEGMENT
x$ = 32
main PROC
$LN5:
    sub    rsp, 56
    lea   rcx, OFFSET FLAT:$SG2924 ; 'Enter X:'
    call  printf
    lea   rdx, QWORD PTR x$[rsp]
    lea   rcx, OFFSET FLAT:$SG2926 ; '%d'
    call  scanf
    cmp   eax, 1
    jne   SHORT $LN2@main
    mov   edx, DWORD PTR x$[rsp]
    lea   rcx, OFFSET FLAT:$SG2927 ; 'You entered %d...'
    call  printf
    jmp   SHORT $LN1@main
$LN2@main:
    lea   rcx, OFFSET FLAT:$SG2929 ; 'What you entered? Huh?'
    call  printf
$LN1@main:
    ; return 0
    xor   eax, eax
    add   rsp, 56
    ret   0
main ENDP
_TEXT ENDS
END
```

MIPS

Listing 1.19: Com otimização GCC 4.4.5 (IDA)

```
.text:004006A0 main:
.text:004006A0
.text:004006A0 var_18 = -0x18
.text:004006A0 var_10 = -0x10
.text:004006A0 var_4 = -4
.text:004006A0
.text:004006A0 lui $gp, 0x42
.text:004006A4 addiu $sp, -0x28
.text:004006A8 li $gp, 0x418960
.text:004006AC sw $ra, 0x28+var_4($sp)
.text:004006B0 sw $gp, 0x28+var_18($sp)
.text:004006B4 la $t9, puts
.text:004006B8 lui $a0, 0x40
.text:004006BC jalr $t9 ; puts
.text:004006C0 la $a0, aEnterX # "Enter X:"
.text:004006C4 lw $gp, 0x28+var_18($sp)
.text:004006C8 lui $a0, 0x40
.text:004006CC la $t9, __isoc99_scanf
.text:004006D0 la $a0, aD # "%d"
.text:004006D4 jalr $t9 ; __isoc99_scanf
.text:004006D8 addiu $a1, $sp, 0x28+var_10 # branch delay slot
.text:004006DC li $v1, 1
.text:004006E0 lw $gp, 0x28+var_18($sp)
.text:004006E4 beq $v0, $v1, loc_40070C
.text:004006E8 or $at, $zero # branch delay slot, NOP
```

1.9. SWITCH()/CASE/DEFAULT

```
.text:004006EC      la      $t9, puts
.text:004006F0      lui     $a0, 0x40
.text:004006F4      jalr   $t9 ; puts
.text:004006F8      la     $a0, aWhatYouEntered # "What you entered? Huh?"
.text:004006FC      lw     $ra, 0x28+var_4($sp)
.text:00400700      move  $v0, $zero
.text:00400704      jr     $ra
.text:00400708      addiu  $sp, 0x28

.text:0040070C      loc_40070C:
.text:0040070C      la     $t9, printf
.text:00400710      lw     $a1, 0x28+var_10($sp)
.text:00400714      lui     $a0, 0x40
.text:00400718      jalr   $t9 ; printf
.text:0040071C      la     $a0, aYouEnteredD___ # "You entered %d...\n"
.text:00400720      lw     $ra, 0x28+var_4($sp)
.text:00400724      move  $v0, $zero
.text:00400728      jr     $ra
.text:0040072C      addiu  $sp, 0x28
```

Exercício

Brazilian Portuguese text placeholder

1.8.4 Exercício

- <http://challenges.re/53>

1.9 switch()/case/default

1.9.1

```
#include <stdio.h>

void f (int a)
{
    switch (a)
    {
        case 0: printf ("zero\n"); break;
        case 1: printf ("one\n"); break;
        case 2: printf ("two\n"); break;
        default: printf ("something unknown\n"); break;
    };
};

int main()
{
    f (2); // test
};
```

Conclusão

Brazilian Portuguese text placeholder??.

1.9.2 Exercícios

Exercício #1

1.10 Laços

1.10.1 Exercícios

- <http://challenges.re/54>
- <http://challenges.re/55>
- <http://challenges.re/56>
- <http://challenges.re/57>

1.11 Brazilian Portuguese text placeholder

1.11.1 strlen()

```
int my_strlen (const char * str)
{
    const char *eos = str;

    while( *eos++ ) ;

    return( eos - str - 1 );
}

int main()
{
    // test
    return my_strlen("hello!");
};
```

ARM

1.12 Substituição de instruções aritméticas por outras

1.12.1 Exercício

- <http://challenges.re/59>

1.13 Matriz

1.13.1

```
#include <stdio.h>

int main()
{
    int a[20];
    int i;

    for (i=0; i<20; i++)
        a[i]=i*2;

    for (i=0; i<20; i++)
```

1.14. ESTRUTURAS

```
    printf ("a[%d]=%d\n", i, a[i]);  
  
    return 0;  
};
```

1.13.2

1.13.3 Exercícios

- <http://challenges.re/62>
- <http://challenges.re/63>
- <http://challenges.re/64>
- <http://challenges.re/65>
- <http://challenges.re/66>

1.14 Estruturas

1.14.1 UNIX: struct tm

1.14.2

1.14.3 Exercícios

- <http://challenges.re/71>
- <http://challenges.re/72>

1.15

1.15.1

Listing 1.20: : <http://go.yurichev.com/17364>

```
* and that int is 32 bits. */  
float sqrt_approx(float z)  
{  
    int val_int = *(int*)&z; /* Same bits, but as an int */  
    /*  
    * To justify the following code, prove that  
    *  
    * 
$$(((\text{val\_int} / 2^m) - b) / 2) + b * 2^m = ((\text{val\_int} - 2^m) / 2) + ((b + 1) / 2) * 2^m$$
  
    *  
    * where  
    *  
    * b = exponent bias  
    * m = number of mantissa bits  
    *  
    * .  
    */  
  
    val_int -= 1 << 23; /* Subtract  $2^m$ . */  
    val_int >>= 1; /* Divide by 2. */  
    val_int += 1 << 29; /* Add  $((b + 1) / 2) * 2^m$ . */  
  
    return *(float*)&val_int; /* Interpret again as float */  
}
```

1.16

1.16.1

Dominic Sweetman, *See MIPS Run, Second Edition*, (2010).

Capítulo 2

Brazilian Portuguese text placeholder



Capítulo 3

Capítulo 4

4.1 Linux

4.2 Windows NT

4.2.1 Windows SEH

SEH

[Matt Pietrek, *A Crash Course on the Depths of Win32™ Structured Exception Handling*, (1997)]¹, [Igor Skochinsky, *Compiler Internals: Exceptions and RTTI*, (2012)]².

4.3

4.4

[Pierre Capillon - Black-box cryptanalysis of home-made encryption algorithms: a practical case study.](#)

¹También disponible como <http://go.yurichev.com/17293>

²También disponible como <http://go.yurichev.com/17294>

Capítulo 5

Afterword

5.1 Questions?

Não hesite em enviar qualquer pergunta ao autor:

<dennis@yurichev.com>. Você tem alguma sugestão sobre novos conteúdos para o livro? Por favor, não hesite em enviar quaisquer correções (inclusive gramaticais (nota quão horrível meu INglês é?)), etc.

O autor está trabalhando muito no livro, de modo que as numerações de página e dos códigos, etc., estão mudando muito rapidamente. Por favor, não referencie a página e aos números de código nos seus e-mails para mim. Existe um método muito mais simples: faça uma captura de tela da página, em um editor gráfico e sublinhe o local onde você vê o erro, e envie para o autor. Ele vai corrigi-lo muito mais rápido. E se você conhece o git e \LaTeX você pode corrigir o erro diretamente no código-fonte:

[GitHub](#).

Não se preocupe em me incomodar ao me escrever sobre qualquer erro insignificante que você encontrar, mesmo que você não esteja muita confiante. Estou escrevendo para iniciantes, afinal, as opiniões e os comentários dos iniciantes são cruciais para o meu trabalho.

**Brazilian Portuguese text
placeholder**

SP stack pointer . SP/ESP/RSP em x86/x64. SP em ARM.....	6
IDA Brazilian Portuguese text placeholder	
AKA Brazilian Portuguese text placeholder	6
CRT C Runtime library.....	5
CPU Central Processing Unit.....	2
RISC Reduced Instruction Set Computing	2
ISA Instruction Set Architecture.....	2
SEH Structured Exception Handling	10
NOP No Operation	23
ASCIIZ ASCII Zero (Brazilian Portuguese text placeholder).....	22
VM Virtual Memory	
GPR General Purpose Registers.....	2
EOF End of File	20
TBT To be Translated. The presence of this acronym in this place means that the English version has some new/modified content which is to be translated and placed right here.	

Glossário

Brazilian Portuguese text placeholder . [9](#)

Brazilian Portuguese text placeholder Brazilian Portuguese text placeholder. [36](#)

Índice

Brazilian Portuguese text placeholder, 6

Alpha AXP, 3

ARM

Instruções

POP, 6

PUSH, 6

Modo ARM, 2

Modo Thumb-2, 2

Modo Thumb, 2

Biblioteca padrão C

alloca(), 9

memcpy(), 14

scanf(), 14

strlen(), 26

Buffer Overflow, 27

cdecl, 12

Compiler intrinsic, 10

Elementos da linguagem C

const, 4

Ponteiros, 14

return, 5, 21

switch, 25

while, 26

fastcall, 5, 14

Hex-Rays, 27

Hiew, 22

Intel C++, 4

MIPS, 3

Instruções

BEQ, 25

O32, 13, 14

Oracle RDBMS, 4

Pilha, 6

Brazilian Portuguese text placeholder, 15

Brazilian Portuguese text placeholder
Brazilian Portuguese text placeholder, 7

PowerPC, 3

Recursividade, 6, 7

Variáveis globais, 17

Windows

Structured Exception Handling, 10, 31

x86

Instruções

ADD, 4, 12

CALL, 4, 7

CMP, 20, 21

JMP, 7

JNE, 21

LEA, 16

MOV, 5

POP, 4, 6, 7

PUSH, 4, 6, 7, 15

RET, 3, 5, 7

SUB, 5, 21

XOR, 5, 21

Registradores

EAX, 20

EBP, 15

ESP, 12, 16

Flags, 21

ZF, 21

x86-64, 5, 12, 14, 16, 23