Pokročilé operační systémy

Systémová volání I & Binární soubory

Petr Krajča

Katedra informatiky
Univerzita Palackého v Olomouci

Rozhraní OS

- několik úrovní abstrakce
- příklad otevření souboru:

unix

1. proces volá funkci `fopen` standardní knihovny C, tj.
   `FILE *fopen(const char *path, const char *mode);`

2. `fopen` volá funkci `open`, která představuje rozhraní jádra:
   `int open(const char *path, int oflag, ...);`
   širší možnosti (viz `man 3p open`)

3. funkce `open` provede systémové volání (předá argumenty jádru, vyvolá službu v privilegovaném režimu)

Rozhraní OS

Windows

1. proces volá funkci `fopen` standardní knihovny C, tj.
   `FILE *fopen(const char *path, const char *mode);`
2. `fopen` volá funkci (kernel32.dll)

```
CreateFileA(
  [in]           LPCSTR                lpFileName,
  [in]           DWORD                 dwDesiredAccess,
  [in]           DWORD                 dwShareMode,
  [in, optional] LPSECURITY_ATTRIBUTES lpSecurityAttributes,
  [in]           DWORD                 dwCreationDisposition,
  [in]           DWORD                 dwFlagsAndAttributes,
  [in, optional] HANDLE                hTemplateFile);
```

v API ještě použito makro `CreateFile`, které se expanduje buď na `CreateFileA` nebo `CreateFileW` podle toho, jestli se pracuje s ASCII nebo UNICODE řetězci

Windows (dokončení)

3. funkce `CreateFile[AW]` volá `NtCreateFile` (ntdll.dll), která provede systémové volání (předá argumenty jádru, vyvolá službu v privilegovaném režimu)

```
__kernel_entry NTSTATUS NtCreateFile(
  [out]           PHANDLE            FileHandle,
  [in]            ACCESS_MASK        DesiredAccess,
  [in]            POBJECT_ATTRIBUTES ObjectAttributes,
  [out]           PIO_STATUS_BLOCK   IoStatusBlock,
  [in, optional] PLARGE_INTEGER      AllocationSize,
  [in]            ULONG              FileAttributes,
  [in]            ULONG              ShareAccess,
  [in]            ULONG              CreateDisposition,
  [in]            ULONG              CreateOptions,
  [in]            PVOID              EaBuffer,
  [in]            ULONG              EaLength);
```

Rozhraní OS

- rozhraní OS často popsáno formou volání funkcí vyššího prog. jazyka (C), např. `open`, `NtCreateFile`
- jednotné ABI (např. cdecl) kompatibilní se zbytkem platformy
- snadná integrace do dalších prog. jazyků
- lepší přenositelnost
  - hardwarová (různě implementovaná systémová volání)
  - softwarová (různé rozhraní jádra OS)
- možnost emulovat rozhraní jiného OS (WindowsNT a POSIX)

Systémová volání na platformě x86

- nutné přepnout procesor z neprivilegovaného režimu do privilegovaného (z ring3 do ring0)
- identifikovat požadovanou službu jádra OS
- předat argumenty

přerušení

- tradiční řešení
- číslo služby OS je uloženo do registru EAX
- argumenty v registrech EBX, ECX, ...
- služba jádra vyvolána softwarovým přerušením, tj. instrukcí `int`, např.
  - `int 0x80` (Linux)
  - `int 0x2e` (WindowsNT)
- návratová hodnota uložena v EAX

Volací brány

- obecný mechanismus postavaný na segmentaci
- DPL kódového segmentu (CS) udává úroveň oprávnění
- přechod mezi různými kódovými segmenty (pomocí vzdálených skoků)
- využití GDT (musí být chráněný přístup)
- umožňuje přechod i do dalších úrovní oprávnění (ring1, ring2)

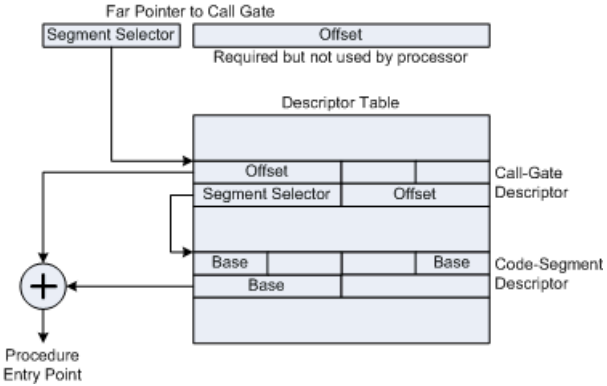

Dedikované instrukce

- dedikované páry instrukcí pro přepnutí do/z privilegovaného režimu
- Intel: SYSENTER/SYSENTER
- AMD: SYSCALL/SYSRET
- adresa vstupního bodu jádra určena pomocí MSR (Model Specific Register)
- přístup k MSR přes instrukce `rdmsr` a `wrmsr`

Použití systémových volání

Nejmenší program v Linuxu

```
mov eax, 1    ;; sys_exit
mov ebx, 42   ;; vysledek
int 0x80      ;; systemove volani
```

```
./min-app; echo $?
```

další systémová volání

```
;; int sys_read(unsigned int fd, const char *buf, unsigned int size);
sys_read:
   push ebx
   mov eax, SYS_READ_NR    ;; 3
   mov ebx, [esp + 8]      ;; file descriptor
   mov ecx, [esp + 12]     ;; buffer
   mov edx, [esp + 16]     ;; size
   int 0x80                ;; čtení souboru
   pop ebx
   ret
```

Další systémová volání

- viz přiložené soubory (`sys-calls/*`)
- přehledný seznam: `https://chromium.googlesource.com/chromiumos/docs/+/master/constants/syscalls.md#x86-32_bit`

Binární a objektové soubory

- binární soubory obsahují různé typy dat
  - spustitelný kód (`.text`)
  - data pouze pro čtení (`.rodata`, např. konstanty, řetězcové literály)
  - inicializovaná data (`.data`, např. globální a statické proměnné)
  - neinicializovaná data (`.bss`, např. globální a statické proměnné)
- binární soubory obsahují různé typy metadat
  - umístění jednotlivých částí paměti
  - vstupní bod programu
  - oprávnění k jednotlivým oblastem (např. povolení zápisu, provádění kódu)
  - informace pro přesun kódu, dynamické načítání
- různé formáty s přibližně stejným obsahem
  - Executable and Linkable Format – Linux
  - Portable Executable (PE) – Window
  - Mach-O – OS od Applu

Binární a objektové soubory

- binární a objektové soubory obsahují velmi podobná data, proto se používá stejný formát pro oba účely (spuštění programu i kompilace)

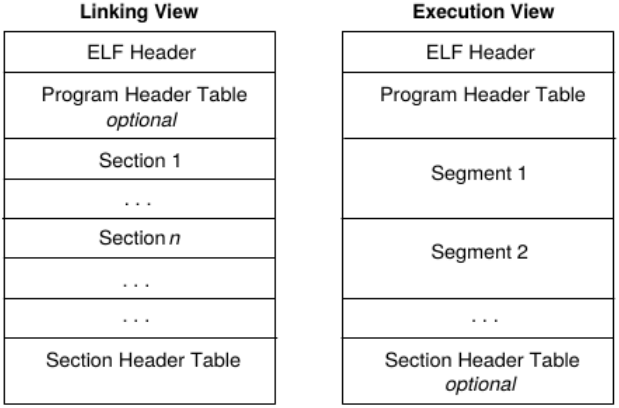

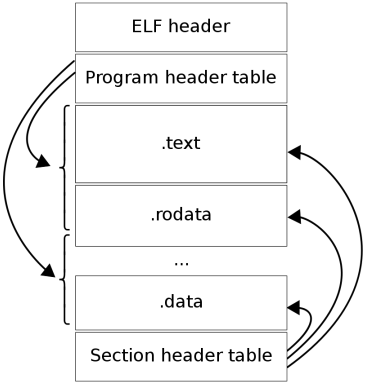

Podrobnosti o formátu

- https://refspecs.linuxfoundation.org/elf/elf.pdf
- viz přiložené zdrojové kódy
- pěkný rozbor formátu ELF: https://raw.githubusercontent.com/corkami/pics/28cb0226093ed57b348723bc473cea0162dad366/binary/elf101/elf101-64.svg

Úkoly

1. vyberte si minimálně jedno systémové volání jádra Linuxu, naprogramujte jeho volání a ověřte, že funguje správně

2. s pomocí různých voleb nástroje `objdump` se podívejte na obsah binárních a objektových souborů
   - užitečné volby `objdump -x`
   - užitečné volby `objdump -d -M intel`
   - srovnejte výstup staticky a dynamicky přeloženého programu