Übung zu Betriebssystemtechnik

Aufgabe 4: Trennung von Kern & Anwendungen

11. Juni 2025

Dustin Nguyen, Maximilian Ott & Phillip Raffeck

Lehrstuhl für Informatik 4
Friedrich-Alexander-Universität Erlangen-Nürnberg

Lehrstuhl für Informatik 4
Systemsoftware

Friedrich-Alexander-Universität
Technische Fakultät

Anwendungen sollen (sowohl bei Übersetzung als auch bei Ausführung) vom Kernel getrennt werden

Ziel dieser Aufgabe

Bisher:

- Anwendungen im **Kernel** inkludiert
- Ausführung im Kerneladressbereich

Ab dieser Aufgabe:

- Anwendungen in einem **Boot Module** (losgelöst vom Kernel)
- Ausführung im Userspace

- Kernel vor Zugriff aus Ring 3 geschützt

→ **vollständige Isolation der Anwendungen**

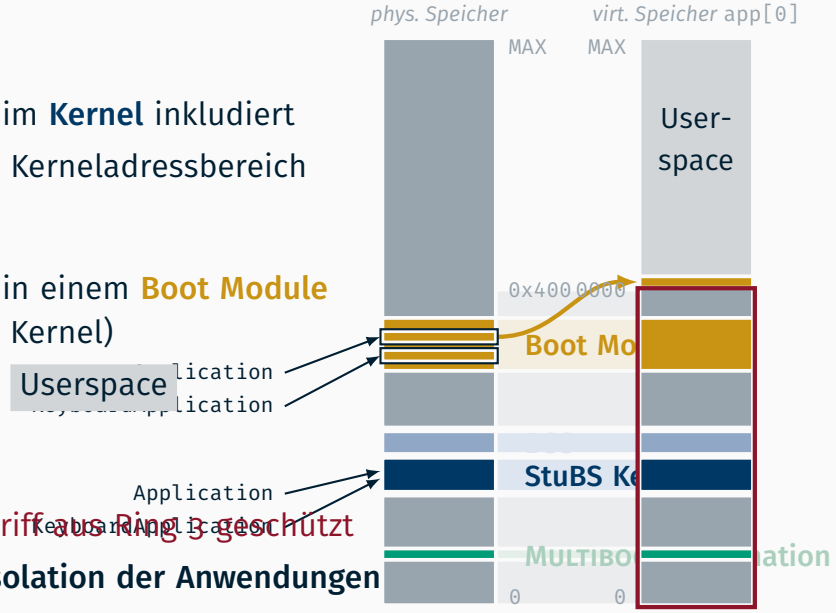

Restrukturierung der Quellen

Organisation der Dateien

Bisher:

- Anwendungscode und Betriebssystemcode vermischt
  → alles in einer großen `system[64]`-Datei

Nun Aufteilung des Codes in unterschiedliche Verzeichnisse:

`kernel/` nur der Betriebssystemkern
→ `system[64]`

`libsys/` Unterstützung für Anwendungen
→ statische Bibliothek `libsys.a`

`user/` enthält **mehrere** Anwendungen
Jede Anwendung wird gegen `libsys` gelinkt
und zu einer eigenen Binärdatei kompiliert
→ Archiv `initrd.img` mit den einzelnen Binärdateien

libsys

`$ g++ -fno-builtin -nodefaultlibs -nostdlib -nostdinc …` → `$CXXFLAGS` aus `tools/build.mk` berücksichtigen → oder gleich `tools/common.mk` in `Makefile` einbinden `$ ar rcs libsys.a libsys/*.o`

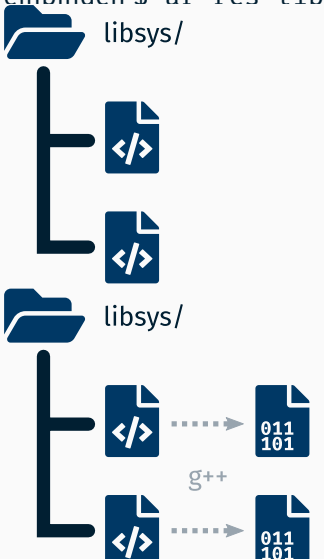

Linkerskript user/sections.ld mit 0x40000000 (64 MiB) als Einsprungpunkt $
g++ $CXXFLAGS -Wl,T sections.ld -o app1.elf $LDFLAGS init.o […] $
objcopy -O binary --set-section-flags \

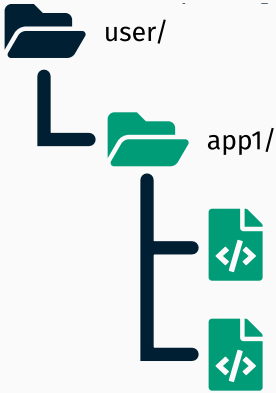

C/C++ Laufzeitumgebung

- `crti.o` und `crtn.o` für C Funktionsprologe
  - für Initialisierungs- (`_init`) und Beendigungsroutine (`_fini`)
    (siehe `compiler/crti.asm` sowie `compiler/crtn.asm`)
- `init.o` setzt die Laufzeitumgebung auf
  1. Einsprungspunkt ist `void start()`
  2. Ausführung der C Startup Initialisierungssroutinen
     (`__preinit_array`, `_init()` und `__init_array`, siehe `compiler/libc.cc`)
  3. Übergabe an `main` der App
  4. bei Rückkehr Deinitialisierung
     (`__fini_array`, `_fini()` und Endlossschleife)
  - Bereitstellung der für C++ benötigten Funktionen
    (Dummies für `__cxa_pure_virtual()` und `__cxa_atexit()`, siehe `compiler/libcxx.cc`)

Beim Linken muss `init.o` die erste Objektdatei sein, damit `start()` die erste Funktion (am Einsprungspunkt an Adresse `0x400 0000`) ist!

Flat Binaries und Image Builder *(für 5 ECTS)*

Erstellung einer flachen Binärdatei

Man nehme eine ELF-Datei

0. prüfe, ob `start` an der Einsprungsadresse liegt
   `$ nm app1.elf | grep -q "4000000 T start" || echo "Fehler"`
1. integriere **BSS** in die **Datensektion**
   objcopy Argument: `--set-section-flags .bss=alloc,load,contents`
2. werfe alles außer **Code** & **Datensektion** weg

   objcopy Argument: `-O binary`

Zack fertig: **Flat Binary**

➔ initiales Speicherabbild einer Anwendung ohne Metainformationen

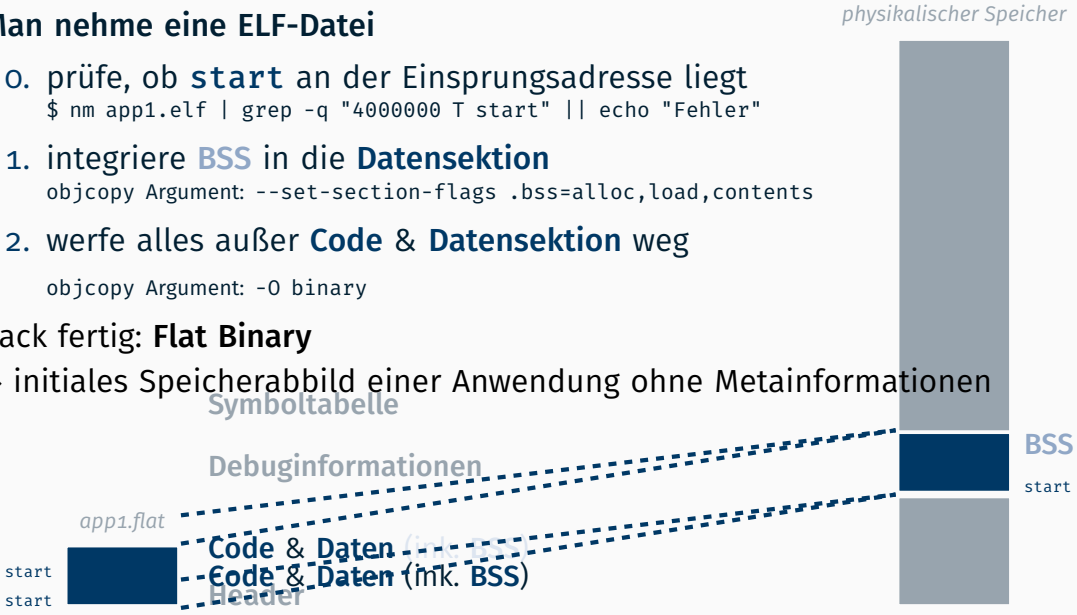

Anwendungsabbildarchiv als Boot Module

```
$ ./imgbuilder app1.flat app2.flat appx.flat > initrd.img
```

appx.flat

app2.flat

app1.flat

Image Builder Format

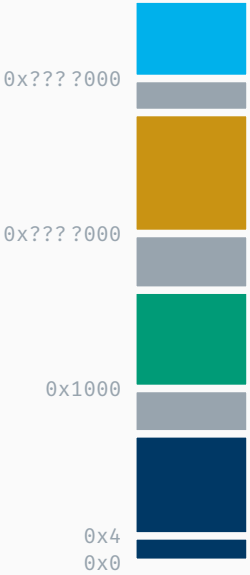

Anwendung x

`.text`, `.data`, `.bss`

Füller / Ausrichten auf 4 KiB

Anwendung 2

`.text`, `.data`, `.bss`

Füller / Ausrichten auf 4 KiB

Anwendung 1

`.text`, `.data`, `.bss`

Füller / Ausrichten auf 4 KiB

Informationen zu den Abbildern

```
uint32_t appSize[appCount];
uint32_t appCount;
```

ELF und TAR *(für 7.5 ECTS)*

Executable and Linking Format

- 1993 vom *Tool Interface Standard (TIS)* Committee) spezifiziert
- Nachfolger von *a.out* (*Assembler output*, ab 1971) und *coff* (*Common Object File Format*, ab 1983)
- Standardformat auf unixoiden Systemen
- inzwischen plattformübergreifender Einsatz
- vielfältige Einsatzgebiete

  relocatable Objektdateien (`.o`)

  executable (statische) Programme

  dynamic dynamische Programme und [geteilte] Bibliotheken (`.so`)
- durch Sektionen flexibel erweiterbar
- bei Bedarf Einbettung von *DWARF* Debuginformationen

Die Vorgabe enthält unter `util/` bereits das Grundgerüst (Parser) für einen einfachen ELF-Loader. Dieser soll

- Beschränkt sich auf statische Binärdateien (ohne Relok.) unterstützen
- Berechtigungen (Writeable / Executable) berücksichtigen
- (ELF) Quelldaten in neue (Userspace) Zielseiten **kopieren** und Attribute wie lese-, schreib- und ausführbar
- *optional* unter bestimmten Bedingungen auch Quellseite **einblenden**

Program Header Table

```
$ readelf -W user/app1/build/app1.elf
Entry point 0x1000000
There are 3 program headers, starting at offset 64

Type           Offset   VirtAddr           PhysAddr           FileSiz  MemSiz   Flg Align
LOAD           0x001000 0x01000000 0x01000000 0x000aa0   0x000aa0   R E 0x1000
LOAD           0x002000 0x04001000 0x04001000 0x003720   0x006369   RW  0x1000
GNU_STACK      0x000000 0x00000000 0x00000000 0x000000   0x000000   RWE 0x10
```

app1.elf

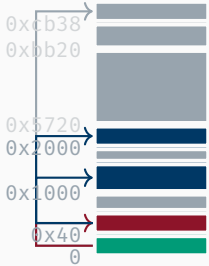

Section Header Table
Symboltabelle

Debuginformationen

Datensektion
Code & Datensektion
Code

Program Header Table

Header
ELF Header

ELF[101] a Linux executable walkthrough

ANGE ALBERTINI
CORKAMI.COM

DISSECTED FILE

```
$ uname -m
x86_64
$ ./simple64.elf
Hello World!
```

SIMPLE64.ELF

HEADER[1/2]
TECHNICAL DETAILS FOR IDENTIFICATION AND EXECUTION

ELF HEADER
IDENTIFY AS AN ELF FILE TYPE
SPECIFY THE ARCHITECTURE

PROGRAM HEADER TABLE
EXECUTION INFORMATION

SECTIONS
CONTENTS OF THE EXECUTABLE

CODE
EXECUTABLE INFORMATION

DATA
INFORMATION USED BY THE CODE

SECTIONS' NAMES

HEADER[2/2]
TECHNICAL DETAILS FOR LINKING
IGNORED FOR EXECUTION

SECTION HEADER TABLE
LINKING CONSTRUCTING PROGRAM TABLE'S SECTIONS' INFORMATION

HEXADECIMAL DUMP / ASCII DUMP

FIELDS / VALUES / EXPLANATION

1 e_ident
- EI_MAG — 0x7F, "ELF" — CONSTANT SIGNATURE
- EI_CLASS, EI_DATA — 2 — 64BITS, LITTLE-ENDIAN
- EI_VERSION — 1 — ALWAYS 1

- e_type — 2 — EXECUTABLE
- e_machine — 0x3E — AMD64 (AMD LATER)
- e_version — 1 — ALWAYS 1
- e_entry — 0x10000000
- e_phoff — 0x40 — PROGRAM HEADERS OFFSET
- e_shoff — 0x98 — SECTION HEADERS OFFSET
- e_ehsize — 0x40 — ELF HEADERS SIZE
- e_phentsize — 0x38 — SIZE OF A SINGLE PROGRAM HEADER
- e_phnum — 1 — COUNT OF PROGRAM HEADERS
- e_shentsize — 0x40 — SIZE OF A SINGLE SECTION HEADER
- e_shnum — 4 — COUNT OF SECTION HEADERS
- e_shstrndx — 3 — INDEX OF THE NAMES SECTION IN THE TABLE

3 ADDRESS WHERE EXECUTION STARTS

2 p_type — 1 — THE SEGMENT SHOULD BE LOADED IN MEMORY
- p_flags — 7 — READABLE AND EXECUTABLE
- p_offset — 0 — OFFSET WHERE IT SHOULD BE READ
- p_vaddr — 0x10000000 — VIRTUAL ADDRESS WHERE IT SHOULD BE LOADED
- p_paddr — 0x10000000 — PHYSICAL ADDRESS WHERE IT SHOULD BE LOADED
- p_filesz — 0xD8 — SIZE ON FILE
- p_memsz — 0xD8 — SIZE IN MEMORY

3 X64 ASSEMBLY

```
mov rdx, 0xD
mov rsi, 0x10000060
mov rdi, 1
mov rax, 1
syscall
mov rdi, 1
mov rax, 0x3C
syscall
```

EQUIVALENT C CODE

```
write(STDOUT_FILENO, "Hello World!\n", len("Hello World!\n"));
exit(0);
```

STRINGS

```
"Hello World!\n", 0
```

SECTION NAMES

```
"" .shrtrtab .text .rodata
```

SECTION HEADER TABLE

INDEX	NAME	TYPE	FLAGS	ADDRESS	OFFSET	SIZE
0	<null>	0x0				
1	.text	1 PROGBITS	6 ALLOC, EXECINSTR	0x10000060	0x60	0x48
2	.rodata	1 PROGBITS	2 ALLOC	0x100000C0	0xC0	0x00
3	.shrtrtab	3 STRTAB	0		0xC0	0x19

FOR MORE DETAILS ON FLAGS, TYPES AND OTHER VALUES, SEE THE ELF SPECIFICATION

THESE THE WHOLE FILE; HOWEVER, MOST ELF FILES CONTAIN MANY MORE ELEMENTS.
EXPLANATIONS ARE SIMPLIFIED FOR CONCISENESS.

Bandarchivierer (TAPE ARCHIVER)

- 1979 eingeführte Archivdatei
  - *klebt* Dateien (unkomprimiert/unmodifiziert) aneinander
  - ausgerichtet an 512 Byte Grenzen
  - jeweils mit Kopfeintrag (beinhaltet Dateiname, Größe, Berechtigungen)
  - aber kein Index über alle Inhalte!
- für Bandlaufwerke (= sequentielle Ein-/Ausgabe) gedacht
- 1988 POSIX-Standardisierung und Einführung der *UStar* (= *Unix Standard*) Erweiterung (mehr Attribute, längere Dateinamen)
  - zusätzliche Informationen im Kopfeintrag
  - Format bleibt aber weiterhin kompatibel
- 1997 *pax* (= *portable archive formats*) Erweiterung
  - in großen Teilen kompatibel zu *UStar*
  - zur Befriedung der *Tar-Wars* (mit dem konkurrierenden *cpio*)

Bandarchivierer (TAPE ARCHIVER) Verwendung

```
$ tar -cf initrd.tar app1.elf app2.elf appx.elf
```

appx.elf

app2.elf

app1.elf

TAR Format

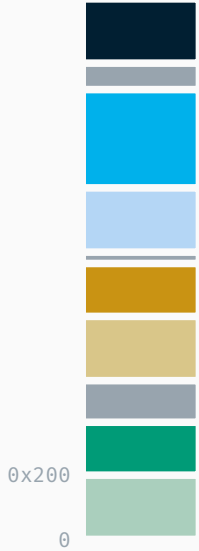

Dateiende mit `char name[100] = { '\0' };`

Füller / Ausrichten auf 512 Bytes

Anwendung x – `appx.elf`

Kopf zu **Anwendung x**

Füller / Ausrichten auf 512 Bytes

Anwendung 2 – `app2.elf`

Kopf zu **Anwendung 2**

Füller / Ausrichten auf 512 Bytes

Anwendung 1 – `app1.elf`

Kopf zu **Anwendung 1**

```
char name[100]; // uvm
```

→ (rudimentärer) TAR-Parser bereits in Vorgabe (unter `utils/`) enthalten!

TAPE ARCHIVE

ANGE ALBERTINI
http://www.corkami.com

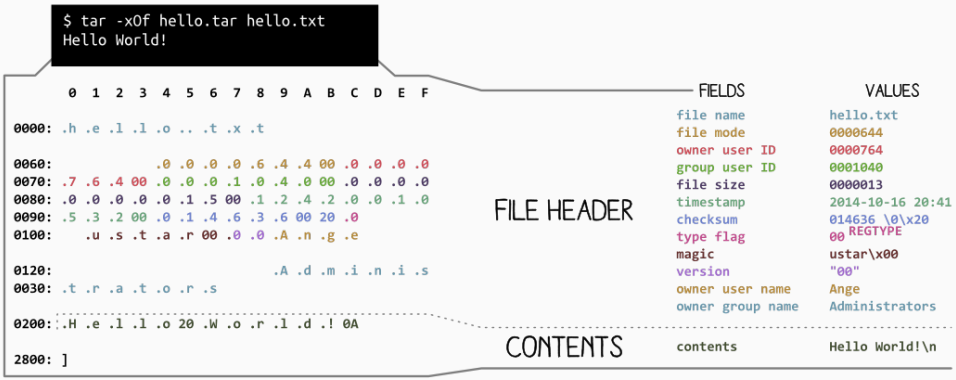

TAR WAS INITIALLY DESIGNED FOR TAPE DRIVES, IN 1979:
- NO COMPRESSION, BLOCK ALIGNED
- NUMERIC VALUES ARE STORED IN OCTAL, ENCODED IN ASCII
TAR IS OFTEN COMBINED WITH GZIP, BZIP2 OR LZMA.
THE TAR FORMAT EVOLVED:
THIS EXAMPLE IS A "USTAR" FILE, AS DEFINED IN 1988

Unsere `Makefile` unterstützt bereits ein Bootmodul, dessen Pfad in der Variable `INITRD` definiert werden muss.

Beim Target `netboot` wird diese Datei nach `/proj/i4stubs/student/LOGIN/initrd.img` kopiert und automatisch vom Bootloader geladen

(d.h. die Angabe in `Multiboot::Module::getCommandLine()` ist nicht sonderlich aussagekräftig, sondern beim Benutzer immer gleich)

Dynamisch wachsender Stapel

Dynamisch wachsender Anwendungsstapel

Ablauf:

- initial z.B. 4 KiB Userspace Stack
- sobald Stack voll → Seitenfehler
- Behandlungsroutine allokiert mehr Speicher (und setzt Ausführung fort)
- bis zu einem vorgegebenen Maximum

Umsetzung mittels neuem `pagefault_handler`

- Verwendung von `cr2` und `error_code`
- bei Änderung des aktiven Mappings an das Spülen des TLBs (z.B. via `invlpg`) denken!

Protipp: Initial gar keinen Stack allokieren!

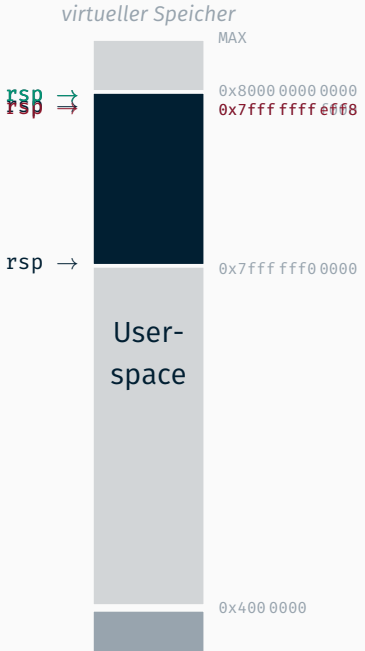

Der Stack muss bei Funktionsaufrufen (d.h. vor `call`) an 16 Byte ausgerichtet sein!

- gemäß System V ABI 3.2.2
- für FPU & SSE Instruktionen wichtig
- einfache Überprüfung mittels `cmpxchg16b` Instruktion:

```
__int128 x = 0;
__sync_val_compare_and_swap(&x, 0, 1);
```

  und mit zusätzlichem GCC Parameter `-mcx16` übersetzen
  → *Protection Fault* bei unausgerichtetem Stack!

Optional: Fließkommazahlen

Geschichte der Fließkommazahlen auf dem x86

Gleitkomma-Operationen beim **x86** entweder in Software oder

- Anfangs Koprozessor (*Intel 8087* → **x87**)
- ab 486er Gleitkommaeinheit integriert in CPU
  - acht 80 bit Datenregister (16 bit Exponent + 64 bit Mantisse)
    → organisiert als Stack (`st0` – `st7`)
  - zudem weitere Kontrollregister
  - Befehle für Stack- und Rechenoperationen
    → Parallele Ausführung, Fehler als Exceptions
- später Erweiterungen *Multi Media Extension (MMX)*, *Streaming SIMD Extensions (SSE)* [1…4] und *Advanced Vector Extensions (AVX)*
  - x64 unterstützen immer (mindestens) SSE2
  - min. sechzehn 128 bit Register (`xmmm0` – `xmmm15`)
  - Nutzung (nach System V ABI 3.2.3) auch für Parameterübergabe

→ Zustandssicherung beim Kontextwechsel notwendig!

Zustandssicherung

Früher:

Sicherung der zusätzlichen Register beim Kontextwechsel ist teuer, aber viele Programme brauchen eigentlich gar keine FPU…

- OS schaltet FPU standardmäßig aus und sichert beim Kontextwechsel nur die üblichen *general purpose* Register
- falls ein Prozess die FPU benutzt, gibt es eine Exception
- OS aktiviert FPU, führt die Instruktion nochmal aus und kümmert sich bei diesem Programm von nun an auch um die FPU Register

Heute:

- Übersetzer nutzen standardmäßig auch `xmm`-Register
- schnelle Spezialbefehle (wie `fxsave` & `fxrstor`)
  - hochoptimiert (84 & 44 Zyklen)
  - für alle FPU / MMX / SSE Register (512 bytes)

➔ standardmäßig im Userspace aktiviert

FPU-Umsetzung in StuBSmi

- FPU / MMX / SSE bei Übersetzung von Userspace Apps aktivieren (→ CXXFLAGS_NOFPU) – aber Kernel soll weiterhin ohne FPU laufen!
- beim Systemstart pro Kern FPU initialisieren (→ `FPU::init()`)
  1. Bits für *Software Emulation* (`CR0_EM`) und *Task Switched* (`CR0_TS`) in Kontrollregister 0 (`cr0`) löschen, *Monitor coprocessor* (`CR0_MP`) setzen
  2. FPU selbst auf Standardwerte initialisieren (`fninit`), Statuswort (muss `0` sein) sowie Kontrollwort prüfen (muss `0x37f` sein)
  3. Bits für *Enable SSE Instructions* (`CR4_OSFXSR`) und *Enable SSE Exceptions* (`CR4_OSXMMEXCPT`) in Kontrollregister 4 (`cr4`) setzen
- pro Thread Speicher für FPU-Zustand reservieren (→ `FPU::State`)
- beim Kontextwechsel aktuellen Zustand sichern (→ `FPU::State::save()`) und neuen laden (→ `FPU::State::restore()`)
- optional auch Unterstützung für `float` und `double` im Ausgabestrom der **`libsys`**

Fragen?