UNIX

Programování a správa systému I

Jan Kasprzak (kas@fi.muni.cz)

Virtual memory is like
a game you can't win;
however, without VM
there's truly nothing to lose.
—Rik van Riel

Úvodní informace

Předpoklady

- **Programování v C** – syntaxe, paměťový model, průběh kompilace.
- **UNIX z uživatelského hlediska** – shell, soubory, procesy.

Cíle kursu

- **Programování pod UNIXem** – rozhraní dle Single UNIX Specification.
- **Jádro UNIXu** – principy činnosti, paměťový model, procesy.

Ukončení předmětu

- **Test** – 20 otázek.
- **Hodnocení**: –1 až 4 body na otázku, na kolokvium je potřeba 40 bodů a více.

Obsah přednášky

- **Základy programování pod UNIXem** – nástroje.
- **Normy API pro jazyk C pro UN*X**
- **Program podle ANSI C** – limity, start a ukončení programu, argumenty, proměnné prostředí, práce s pamětí, vzdálené skoky. Hlavičkové soubory a knihovny. Sdílené knihovny.
- **Jádro** – start jádra, architektura jádra, paměťový model, komunikace s jádrem, knihovna versus systémové volání.
- **Proces** – paměťový model, vznik a zánik procesu, program na disku.
- **Vstupní/výstupní operace** – deskriptor, operace s deskriptory.
- **Soubory a adresáře** – i-uzel, operace s ním. Architektura souborového systému.
- **Komunikace mezi procesy** – roura, signály.
- **Pokročilé V/V operace** – zamykání souborů, scatter-gather I/O, soubory mapované do paměti, multiplexování vstupů a výstupů.

Materiály ke studiu

- **Slidy z přednášek:** `http://www.fi.muni.cz/~kas/p065/`

- **Maurice J. Bach:** *Principy Operačního Systému UNIX*, Softwarové Aplikace a Systémy, 1993, ISBN 80–901507–0–5
- **Uresh Vahalia:** *UNIX Internals – the New Frontiers*, Prentice Hall 1996, ISBN 0–13–101908–2
- **J. Brodský, L. Skočovský:** *Operační systém UNIX a jazyk C*, SNTL 1989, ISBN 80–03–00049–1
- **W. Richard Stevens:** *Advanced Programming in the UNIX Environment*, Addison-Wesley 1992, ISBN 0–201–56317–7
- **IEEE Std. 1003.1:** *Information Technology – Portable Operating System Interface (POSIX) – Part 1: System API (C language)*, IEEE 1996, ISBN 1–55937–573–6
- **Andrew Josey:** *The UNIX System Today – The Authorized Guide to Version 2 of the Single UNIX Specification*, The Open Group 2000, ISBN 1–85912–296–5, `www.opennc.org/onlinepubs/7908799/`

Vývojové prostředí

Rychlý start

```
$ cat >richie.c
#include <stdio.h>
main() { printf("Hello, world!\n"); }
^D
$ cc richie.c
$ ./a.out
Hello, world!
$
```


Kompilace C-programu

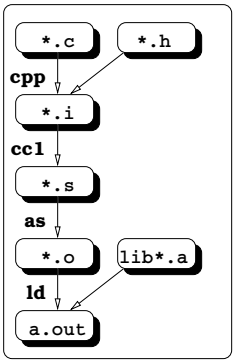

Kompilátor `cc`

- **Vývojové prostředí** – obvykle za příplatek.
- **GNU C/C++**
- **Spouští další programy** – `cpp(1)`, `comp/cc1`, `as(1)`, `ld(1)`.
- Lze spouštět i jen jednotlivé části překladu.

- **Start kompilace** se řídí příponou souboru.

- **Konec kompilace:**

`-E` – jen preprocesor.
`-S` – až po assembler.
`-c` – včetně assembleru.
`-o` ⟨*jméno*⟩ – jméno výstupního souboru.

- **Parametry preprocesoru:**

`-D`⟨*makro*⟩
`-D`⟨*makro*⟩**`=`**⟨*hodnota*⟩
– nadefinuje makro pro preprocesor.
`-U`⟨*makro*⟩ – ruší definici makra.
`-I`⟨*adresář*⟩ – adresář pro hlavičkové soubory.
`-I-` – vypíná standardní adresáře (`/usr/include`).

- **Parametry kompilátoru:**

`-O`[⟨*číslo*⟩] – zapíná optimalizaci.
`-g` – zapíná generování ladících informací.
`-p` – profilovací informace pro `prof(1)`.
`-pg` – profilovací informace pro `gprof(1)`.

- **Parametry linkeru:**

`-L`⟨*adresář*⟩ – adresář pro knihovny.
`-nostdlib` – bez standardních knihoven.
`-l`⟨*knihovna*⟩ – přidá soubor `lib`⟨*knihovna*⟩`.a`, případně `.so`.
`-static` – statické linkování.
`-shared` – sdílené knihovny.
`-s` – odstranit tabulku symbolů.

◇ **Úkol:** Napište triviální program, který bude volat funkci `printf(3)` se dvěma parametry. Program zkompilujte s výstupem do assembleru bez optimalizace a s optimalizacemi. Jaké změny udělal optimalizující kompilátor? Vyzkoušejte dle možnosti různé verze kompilátoru a různé platformy.

Opakování – jazyk C

Program v paměti

- **Text** – vlastní strojový kód (obvykle jen pro čtení/provádění).
- **Data** – čtení i zápis.
- **Zásobník** – čtení i zápis, zvětšuje se směrem k nižším adresám.

```
char znak;
int funkce(int argument) {
    int cislo;
    /* ... */
}
```

Zde `&funkce` je adresa do textu programu, `&znak` do datové části a `&cislo` na zásobník.

◇ **Úkol:**Kam padne adresa `&argument`?

Umístění proměnných v paměti

- **Na zásobníku** – automatické, deklarované uvnitř funkce.
- **V datové části** – `static` nebo mimo funkce.

```
int jezek;
void funkce() {
    int ptakopysk;
    static int tucnak;
    /* ... */
```

Na zásobníku je uložena proměnná `ptakopysk`. Ostatní dvě jsou v datové části.

Viditelnost proměnných

- **Statické** – `static` – jen uvnitř modulu.
- **Globální** – mimo funkce a bez `static` – viditelné ze všech modulů.

```
/* data.c */
int odpoved;
static char *otazka;
```

```
/* thought.c */
hlubina_mysleni() {
    odpoved = 42;
    sleep(60*60*24*365*10000000);
    otazka = "Co dostaneme, když "
        "vynásobíme šest devíti?";
}
```

```
$ cc -c data.c
$ cc -c thought.c
$ cc -o hlubina data.o thought.o main.o
```

Linkování selže. Po zrušení klíčového slova `static` v `data.c` projde.

Program `make`

- **Řízená kompilace z více modulů**
- **Soubor `Makefile`**

`-f` ⟨*Makefile*⟩ – soubor místo `makefile` nebo `Makefile`.
`-i` – ignoruj chyby.
`-n` – vypiš příkazy, ale neprováděj.
`-s` – nevypisuj prováděné příkazy.

Proměnné

⟨*proměnná*⟩`=`⟨*hodnota*⟩

```
CC=gcc -g
CFLAGS=$(OPT_FLAGS) $(DEBUG_FLAGS)
```

Závislosti

⟨*cíl*⟩`:` ⟨*zdroj*...⟩

```
program.o: program.c program.h
```

Akce

⟨*tabulátor*⟩⟨*příkaz*⟩

```
	$(CC) -c program.c
```

Příklad `Makefile`

```
CFLAGS=-O2
LDFLAGS=-s
# CFLAGS=-g
# LDFLAGS=-g
all: program
clean:
	-rm *.o a.out core
program: modul1.o modul2.o
	$(CC) -o $@ modul1.o modul2.o $(LDFLAGS)
	@echo "Kompilace hotova."
modul1.o: modul1.c program.h
modul2.o: modul2.c program.h
	$(CC) -c $(CFLAGS) modul2.c
```

- **Implicitní pravidla** – převod souborů podle přípon (GNU make umí i podle obecnějších pravidel).

Další programy

`nm(1)` . . . . . Výpis tabulky symbolů

```
$ nm ⟨program⟩
$ nm richie.o
00000000 t gcc2_compiled.
00000000 T main
         U printf
```

`strip(1)` . . . . . Odstranění tabulky symbolů

```
$ strip ⟨executable⟩
```

`size(1)` . . . . . Velikost objektového souboru

```
$ size ⟨objfile⟩
$ size x.o
text data bss     dec     hex     filename
20   3    0       23      17      x.o
```

`ar(1)` . . . . . Archivace programů

Program `ar(1)` se používá při vytváření statických knihoven (knihovna je v podstatě arovský archív s tabulkou symbolů – `ranlib(1)`).

`ranlib(1)` . . . . . Index archívu

Program vytvoří index všech symbolů ve všech objektových souborech daného archívu. Tento index přidá do archívu.

V některých systémech – totéž co `ar -s`.

`objdump(1)` . . . . . Vypisuje obsah objektového souboru

- Program vypisuje různé informace z objektového souboru (`*.o`).
- Může sloužit i jako disassembler.

Knihovny

- **Sada funkcí a proměnných** s pevně definovaným rozhraním.
- **Definice rozhraní** – hlavičkový soubor.
- **Umístění** – adresáře `/lib`, `/usr/lib`.
- **Statické versus sdílené**
- **Linkování v době kompilace/v době běhu**.

Statické knihovny

- **Statická knihovna** – stane se součástí spustitelného souboru.
- **Formát** – archív programu `ar(1)`.
- **Tabulka symbolů** – pro urychlení linkování – vytvářená pomocí `ranlib(1)`.
- Některé systémy vyžadují spuštění `ranlib` při vytváření knihovny.
- **GNU `ar`** – umí generovat tabulku symbolů sám.
- **Staticky linkovaný program** – je větší, neumí sdílet kód s jinými programy, ale je v podstatě nezávislý.

Sdílené knihovny

- **Dynamicky linkované knihovny/moduly** – části kódu, které jsou přičleněny k programu až po jeho spuštění. Obvykle jde o sdílené knihovny nebo tzv. plug-iny.
- **Dynamický linker** – `/lib/ld.so` – program, který je dynamicky přičleněn jako první. Stará se dynamické linkování knihoven.

Proměnné pro dynamický linker

`LD_LIBRARY_PATH`
– seznam adresářů, oddělený dvojtečkami. Určuje, kde se budou hledat dynamicky linkované knihovny.

`LD_PRELOAD` – cesta k dynamicky linkovanému objektu, který bude přilinkován jako první. Je možno použít například pro předefinování knihovní funkce nebo ke vnucení jiné verze knihovny.

- U set-uid a set-gid programů dynamický linker ignoruje výše uvedené proměnné.

`/etc/ld.so.conf`
– globální konfigurace.

Linkování v době kompilace

- **Linux libc4 (a.out), SunOS 4, SVr3**
- **Umístění** – na pevně dané adrese v adresním prostoru procesu.
- **Run-time** – pouze přimapování sdílené knihovny.
- **Výhody** – rychlý start programu.
- **Nevýhody** – složitá výroba, nemožnost linkování v době běhu, omezená velikost adresního prostoru (4GB pro 32-bitové systémy, musí vystačit pro všechny existující sdílené knihovny), problém s verzemi.

Linkování v době běhu – formát ELF

- **Extended Loadable Format**
- **AT&T/USRG SVR4, Linux libc5+**
- **Křížové odkazy** – řešeny v době běhu.
- **Problém** – nesdílitelné části kódu (křížové odkazy).
- **Řešení** – kód nezávislý na umístění (*position independent code, PIC*).
- **Verze symbolů** – při změně způsobu volání funkce apod.
- **Výhody** – dynamické linkování (např. plug-iny), možnost předefinovat symbol v knihovně.
- **Nevýhody** – pomalejší start programu, potenciálně pomalejší běh PIC kódu (je nutno alokovat jeden registr jako adresu začátku knihovny).

`ldd(1)` . . . . . Loader dependencies

```
$ ldd [-dr] ⟨program⟩
$ ldd /usr/bin/vi
  libtermcap.so.2 => /lib/libtermcap.so.2.0.8
  libc.so.5 => /lib/libc.so.5.4.36
```

Vypíše, se kterými dynamickými knihovnami bude program linkován.

`-d` Provede doplnění křížových odkazů a ohlásí chybějící funkce.

`-r` Totéž, případné chyby hlásí nejen u funkcí, ale i u datových objektů.

◇ **Úkol:** Zjistěte, které programy jsou v systémových adresářích `/bin` a `/sbin` (nebo `/etc`) staticky linkované.

Hlavičkové soubory

- **Definice rozhraní ke knihovnám** – typové kontroly a podobně.
- **Definice konstant** – `NULL`, `stdin`, `EAGAIN` ...
- **Definice maker** – `isspace()`, `ntohl()`, ...
- Neobsahují vlastní definice funkcí, jen deklarace prototypů.
- **Umístění:** – adresář `/usr/include` a podadresáře.
- **Poznámka k privátním symbolům:** Symboly, jejichž jméno začíná podtržítkem, jsou privátní symboly operačního systému a můžou být definovány v libovolné podobě. Proto je zakázáno používat a definovat v uživatelských programech jakékoli symboly, začínající podtržítkem.

◇ **Úkol:** Je v systému definována konstanta pro π? Ve kterém hlavičkovém souboru? Jak se jmenuje tato konstanta? Návod: projděte hlavičkové soubory.

◇ **Úkol:** Napište program, který v době běhu zjistí, jde-li o big-endian nebo little-endian systém.

Ladění programu

- **Ladící informace** – přepínač `-g` u kompilátoru.
- **Soubor `core`** – obraz paměti procesu v době havárie. Lze vytvořit i uměle například zasláním signálu `SIGQUIT` (`Ctrl-\`). Slouží k posmrtné analýze programu.
- Ladění programu probíhá přes službu jádra `ptrace(2)`, nebo přes souborový systém `/proc`.

Debuggery

`sdb` – symbolic debugger. Dostupný na starších UNIXech. Jednoduché řádkové ovládání.

`adb` – assembler debugger. Slouží k ladění programu ve strojovém kódu. Umí i disassemblovat. Ovládání podobné jako u `sdb(1)`.

`dbx` – pochází ze SVR4. Širší možnosti, ovládání příkazy ve formě slov.

`gdb` – GNU debugger. Nejrozšířenější možnosti (volání funkcí z programu, změna volací sekvence na zásobníku, atd.).

`xxgdb` – grafický front-end pro `gdb(1)`.

`ddd` – grafický front-end pro `gdb(1)` nebo `dbx(1)`.

Rozsáhlé projekty

- **`Makefile`** – závislé na systému.
- **Existence/umístění knihoven** – závislé na konkrétní instalaci.
- **Cílový adresář (adresáře)** – závislé na lokálních zvyklostech.
- **Potřeba stavět software různým způsobem**

- **GNU Autoconf**
- **GNU Automake**
- **Imake**
- **Confgen**

- **GNU Libtool** – výroba sdílených knihoven.

Normy API

ANSI C

Schváleno 1989 – ANSI Standard X3.159–1989. Jazyk C plus standardní knihovna (15 sekcí knihovny podle 15 hlavičkových souborů). Základní přenositelnost programů v C. Oproti UN*Xu nedefinuje proces ani vztahy mezi procesy.

IEEE POSIX

Portable Operating System Interface – IEEE 1003. Některé části schváleny IEEE a ISO, další se připravují. Nejdůležitější sekce normy POSIX:

- **POSIX.1** – Basic OS Interfaces: Schváleno IEEE a ISO
- **POSIX.1a** – Miscellaneous extensions.
- **POSIX.2** – Commands (sh a další): Schváleno IEEE a ISO.
- **POSIX.3** – Test methods: Schváleno IEEE.
- **POSIX.4 (1b)** – Real-time extensions: IEEE 1003.1b-1993.
- **POSIX.4a (1c)** – Threads extensions.
- **POSIX.4b (1d)** – More real-time extensions.
- **POSIX.5** – ADA binding to POSIX.1: Schváleno IEEE.
- **POSIX.6 (1e)** – Security extensions.

Další normy

- **X/Open XPG3,4** X/Open Portability Guide – rozšíření POSIX.1.
- **FIPS 151-1 a 151-2** – Federal Information Processing Standard. Upřesnění normy POSIX.1.
- **SVID3** – System V Interface Description – norma AT&T, popisující System V Release 4.
- **BSD** – označení pro extenze z 4.x BSD.

Single UNIX Specification

- **`www.unix-systems.org`**
- **Verze** – z roku 1995 a 1998 (Single-UNIX Spec. v2), tzv. UNIX 95 a 98.
- **V současné době používaná „definice UNIXu“**

Limity

- **Volby při kompilaci** (podporuje systém řízení prací?)
- **Limity při kompilaci** (jaká je maximální hodnota proměnné typu `int`?)
- **Limity při běhu** (kolik nejvíce znaků může mít soubor v tomto adresáři?)

ANSI C Limity

- Všechny jsou zjistitelné při kompilaci.
- Hlavičkový soubor `<limits.h>`: `INT_MAX`, `UINT_MAX`, atd.
- `<float.h>` – podobné limity pro reálnou aritmetiku.
- `<stdio.h>` – konstanta `FOPEN_MAX`.

POSIX.1 a POSIX.4 limity

```
#define _POSIX_SOURCE
#define _POSIX_C_SOURCE  199309
#include <unistd.h>
```

Konstanta `_POSIX_VERSION` pak určuje verzi normy POSIX, kterou systém splňuje:

- **Nedefinováno** – systém není POSIX.1.
- **198808** – POSIX.1 je podporován (FIPS 151-1).
- **199009** – POSIX.1 je podporován (FIPS 151-2).
- **199309** – POSIX.4 je podporován.
- **více než 199309** – POSIX.4 plus další možná rozšíření.

POSIX.4 vlastnosti jsou všechny volitelné v čase kompilace. Některé POSIX.1 konstanty: `ARG_MAX`, `CHILD_MAX`, `PIPE_BUF`, `LINK_MAX`, `_POSIX_JOB_CONTROL`.

sysconf . . . . . Run-time limity v POSIX.1

```
#include <unistd.h>
long sysconf(int name);
```

Slouží k získání limitů pro dobu běhu, nezávislých na souboru (maximální délka cesty, maximální počet argumentů).

pathconf, fpathconf . . . . . Limity závislé na souboru

```
#include <unistd.h>
long pathconf(char *path, int name);
long fpathconf(int fd, int name);
```

Získání run-time limitů závislých na souboru (maximální délka jména souboru, maximální počet odkazů a podobně).

Run-time limitům definovaným přes `sysconf(2)` a `[f]pathconf(2)` odpovídají i compile-time konstanty: Například `sysconf(_SC_CLK_TCK)` versus `CLK_TCK`.

◇ **Úkol:** Zjistěte a srovnejte POSIX.1 run-time a compile-time limity různých systémů.

Start programu

- **Linkování programu** – `crt0.o`, objektové moduly, knihovny, `libc.a` (nebo `libc.so`).
- **Vstupní bod** – závislý na binárním formátu. Ukazuje obvykle do `crt0.o`.
- **Mapování sdílených knihoven** – namapování dynamického linkeru do adresového prostoru procesu; spuštění dynamického linkeru.
- **Inicializace** – například konstruktory statických proměnných v C++. V GCC voláno z funkce `__main`.
- **Nastavení globálních proměnných (`environ`)**.
- **Volání funkce `main()`**.

main . . . . . Vstupní bod programu

```
int main(int argc, char **argv, char **envp);
```

argc – počet argumentů programu + 1.
argv – pole argumentů.
envp – pole proměnných z prostředí procesu (⟨*jméno*⟩=⟨*hodnota*⟩).

- Uložení stavu procesu do `argv[]` – nejčastěji přepsáním `argv[0]`. Nutné u programů, které akceptují heslo na příkazové řádce.
- Platí `argv[argc] == (char *)0`.

Ukončení programu

Proces vrací volajícímu procesu návratovou hodnotu – obvykle osmibitové celé číslo se znaménkem. Jednou z možností ukončení procesu je ukončení funkce `main()`.

exit . . . . . Ukončení procesu

```
#include <stdlib.h>
void exit(int status);
```

Knihovní funkce; pokusí se uzavřít otevřené soubory, zavolat destruktory statických objektů (v C++) a ukončit proces.

atexit . . . . . Vyvolání funkce při `exit()`

```
#include <stdlib.h>
int atexit(void (*function)(void));
```

Zařadí `function()` do seznamu funkcí, které se mají vyvolat při ukončení procesu pomocí `exit()`.

_exit . . . . . Ukončení procesu

```
#include <unistd.h>
void _exit(int status);
```

Služba jádra pro ukončení procesu. Je volána například ze standardní funkce `exit()`.

abort . . . . . Násilné ukončení

```
#include <stdlib.h>
void abort(void);
```

Ukončí proces zasláním signálu `SIGABRT` a uloží obraz adresového prostoru procesu do souboru `core`.

◇ **Úkol:** Napište program, který zavolá nějakou interní funkci, nastaví nějakou svoji proměnnou a zavolá `abort(3)`. Přeložte s ladícími informacemi a spusťte. Debuggerem vyzkoušejte zjistit, ve které funkci a na kterém řádku došlo k havárii a jaký byl stav proměnných.

Práce s argumenty programu

Bývá zvykem akceptovat přepínače (volby) s následující syntaxí:

-⟨*písmena*⟩
-⟨*písmeno*⟩ ⟨*argument*⟩
-- (ukončení přepínačů)
--⟨*slovo*⟩
--⟨*slovo*⟩ ⟨*argument*⟩
--⟨*slovo*⟩=⟨*argument*⟩

◇ **Příklad:**

```
$ diff -uN --recursive --ifdef=PRIVATE -- \
        linux-2.0.0 linux
```

◇ **Úkol:** Jak smažete soubor jménem `-Z`?

getopt . . . . . Zpracování přepínačů

```
int getopt(int argc, char **argv,
           char *optstring);
extern char *optarg;
extern int optind, opterr, optopt;
```

◇ **Příklad:**

```
while((c=getopt(argc, argv, "ab:-"))!=-1){
    switch (c) {
    case 'a':
           opt_a = 1;
           break;
    case 'b':
           option_b(optarg);
           break;
    case '?':
           usage();
    }
}
```

getopt_long . . . . . Zpracování dlouhých přepínačů

Není součástí standardu POSIX.1. Je použito například v GNU programech.

- **POPT** – knihovna na procházení příkazové řádky.
  `ftp://ftp.redhat.com/pub/redhat/code/popt/`

errno . . . . . Chybová hodnota služby jádra

```
#include <errno.h>
extern int errno;
```

V případě chyby v průběhu služby jádra je sem uloženo číslo chyby. Viz `<sys/errno.h>`, `<linux/errno.h>` a stránky `errno(3)` a `errno(7)`.

◇ **Příklad:**

```
retry: if (somesyscall(args) == -1) {
       switch(errno) {
       case EACCES:
             permission_denied();
             break;
       case EAGAIN:
             sleep(1);
             goto retry;
       case EINVAL:
             blame_user();
             break;
       }
}
```


perror . . . . . Tisk chybového hlášení

```
void perror(char *msg);
```

vytiskne zprávu `msg` a textovou informaci na základě proměnné `errno`.

◇ **Příklad:**

```
if (somesyscall(args) == -1) {
      perror("somesyscall() failed");
      return -1;
}
```

Tento kód při spuštění a chybě `ENOENT` vypíše tento chybový výstup:

```
somesyscall() failed: No such file or directory
```

strerror . . . . . Získání chybové zprávy

```
char *strerror(int errnum);
```

Funkce `perror(3)` a `strerror(3)` používají hlášení v poli zpráv `sys_errlist`, které má `sys_nerr` položek:

```
#include <errno.h>
extern char *sys_errlist[];
extern int sys_nerr;
```


Proměnné prostředí

Environment variables. Pole řetězců tvaru ⟨*jméno*⟩=⟨*hodnota*⟩. Je dostupné přes třetí argument funkce `main()` nebo přes globální proměnnou `environ`:

```
extern char **environ;
```

Této proměnné používat pouze pro získání obsahu všech proměnných prostředí. Jinak používat následující knihovní funkce:

getenv . . . . . Získání obsahu proměnné

```
char *getenv(char *name);
```

K jménu proměnné vrátí obsah proměnné.

putenv . . . . . Nastavení proměnné

```
int putenv(char *str);
```

Do prostředí zařadí danou proměnnou (řetězec `str` má opět syntaxi ⟨*proměnná*⟩=⟨*hodnota*⟩).

Funkce `getenv(3)` a `putenv(3)` odpovídají normě POSIX.1. Kromě toho lze ještě nalézt tyto funkce:

```
int setenv(char *name, char *value,
           int rewrite);
int unsetenv(char *name);
```

◇ **Úkol:** Zjistěte, ve které části adresového prostoru procesu jsou uloženy jeho argumenty a jeho proměnné prostředí. Mění se umístění proměnných, přidáváte-li do prostředí nové proměnné?

Práce s pamětí

malloc, calloc, realloc, free . . . . . Alokace paměti

```
#include <stdlib.h>
void *malloc(size_t size);
```

Funkce vrátí ukazatel na prostor o velikosti minimálně `size` bajtů paměti. Ukazatel je zarovnán pro libovolný typ proměnné.

```
void *calloc(size_t nmemb, size_t size);
```

Funkce alokuje místo pro `nmemb` objektů velikosti `size`. Toto místo je inicializováno nulami.

```
void *realloc(void *ptr, size_t size);
```

Změna velikosti dříve alokovaného místa. Tato funkce může přemístit data na jiné místo, není-li na stávajícím místě prostor pro rozšíření.

```
void free(void *ptr);
```

Uvolní místo, alokované dříve pomocí výše uvedených funkcí. Pozor: Některé systémy neakceptují `free(NULL)`.

alloca . . . . . Alokace na zásobníku

```
#include <stdlib.h>
void *alloca(size_t size);
```

Alokuje dočasné místo v zásobníkové oblasti volající funkce. Po ukončení této funkce je místo automaticky uvolněno. Funkce `alloca(3)` není dostupná na všech systémech.

brk, sbrk . . . . . Změna velikosti datového segmentu

```
#include <unistd.h>
int brk(void *end_of_data_segment);
void *sbrk(int increment);
```

Tyto služby jádra slouží k nastavení velikosti datového segmentu. Jsou používány například funkcemi typu `malloc()`.

Alokace paměti je častým zdrojem chyb (uvolnění paměti, která předtím nebyla alokována, překročení přiděleného rozsahu paměti, uchovávání ukazatelů po realloc, atd.)

Ladící prostředky pro odhalení podobných chyb: ElectricFence, předefinování `malloc()` a `free()` a kontrola argumentů `free()`.

Většina implementací `malloc(3)` neumí vracet uvolněnou paměť zpět operačnímu systému.

Nelokální skoky

Tento mechanismus lze použít pro násilné ukončení několika vnořených funkcí (například v případě fatálních chyb programu).

setjmp . . . . . Inicializace skoku

```
#include <setjmp.h>
int setjmp(jmp_buf env);
```

- **Inicializuje návratové místo**
- **Při prvním volání vrací nulu**
- **Struktura `jmp_buf`** – návratová adresa, vrchol zásobníku.

longjmp . . . . . Nelokální skok

```
#include <setjmp.h>
void longjmp(jmp_buf env, int retval);
```

- **Skok na místo volání `setjmp()`**
- **Návratová hodnota je tentokrát `retval`**

Příklad použití vzdáleného skoku

```
#include <setjmp.h>
jmp_buf env;
int main()
{
      if (setjmp(env) != 0)
           dispatch_error();
      ...
      somewhere_else();
      ...
}
void somewhere_else()
{
      ...
      if (fatal_error)
           longjmp(env, errno);
      ...
}
```


Dynamické linkování

- Přidávání kódu k programu za běhu.
- Sdílené knihovny, plug-iny.
- Knihovna `libdl`, přepínač `-ldl` při linkování.

`dlopen(3)` . . . . . Otevření dynamického objektu

```
#include <dlfcn.h>
void *dlopen(char *file, int flag);
```

Otevře dynamicky linkovaný objekt, přidá jej k procesu a případně vyřeší křížové odkazy. Je-li v objektu definován symbol `_init`, zavolá jej jako funkci (používá se např. u konstruktorů statických proměnných v C++). `flag` může být jedno z následujících:

`RTLD_NOW` – volání vyřeší křížové odkazy a vrátí chybu, jsou-li nedefinované symboly.

`RTLD_LAZY` – křížové odkazy se řeší až v okamžiku, kdy je kód z knihovny poprvé proveden. Právě jeden z těchto dvou flagů musí být použit.

`RTLD_GLOBAL` – globální symboly z knihovny jsou dány k dispozici dalším později linkovaným knihovnám.

`dlclose(3)` . . . . . Uzavření dynamické knihovny

```
#include <dlfcn.h>
int dlclose(void *handle);
```

Uzavře a odmapuje dynamický objekt. Toto se stane až poté, co je `dlclose(3)` na tento objekt zavoláno tolikrát, kolikrát bylo předtím spuštěno `dlopen(3)`. Obsahuje-li dynamický objekt symbol `_fini`, je interpretován jako funkce a tato je zavolána před odmapováním knihovny (použití: destruktory statických proměnných v C++).

`dlsym(3)` . . . . . Získání symbolu z knihovny

```
#include <dlfcn.h>
void *dlsym(void *handle, char *symbol);
```

Vrátí adresu daného symbolu v dynamické knihovně.

`dlerror(3)` . . . . . Chybové hlášení dynamického linkeru

```
#include <dlfcn.h>
char *dlerror();
```

Vrátí řetězec s chybovým hlášením v případě, že nastala chyba u některé funkce pro dynamické linkování, nebo NULL. Další volání téže funkce vrací opět NULL.

◇ **Příklad:** Načte matematickou knihovnu a vypíše kosinus 1.0.

```
#include <dlfcn.h>
#include <stdio.h>
main() {
    void *knihovna = dlopen("/lib/libm.so",
        RTLD_LAZY);
    double (*kosinus)(double) =
        dlsym(knihovna, "cos");
    printf ("%f\n", (*kosinus)(1.0));
    dlclose(knihovna);
}
```

◇ **Úkol:** Vytvořte následující program:

```
$ callsym ⟨knihovna⟩ ⟨symbol⟩
```

Tento program načte jmenovanou knihovnu a zavolá ⟨*symbol*⟩ jako funkci bez parametrů. Doplňte program o testování návratových hodnot funkcí `dl*` a v případě chyby vypisujte chybové hlášení pomocí `dlerror(3)`.

Lokalizace

- **Přizpůsobení národnímu prostředí**
- **Bez nutnosti rekompilace programu**
- **Možnost nastavovat na úrovni uživatele**
- **Možnost nastavovat různé kategorie**

Kategorie lokalizace

LC_COLLATE – třídění řetězců.
LC_CTYPE – typy znaků (písmeno, číslice, nepísmenný znak, převod velká/malá písmena, atd).
LC_MESSAGES – jazyk, ve kterém se vypisují zprávy (viz též GNU gettext).
LC_MONETARY – formát měnových řetězců (znak měny, jeho umístění, počet desetinných míst, atd).
LC_NUMERIC – formát čísla (oddělovač desetin, oddělovač tisícovek apod.)
LC_TIME – formát času, názvy dní v týdnu, měsíců atd.

Názvy locales

⟨*jazyk*⟩[_⟨*teritorium*⟩][.⟨*charset*⟩][@⟨*modifikátor*⟩]

- **Jazyk** – dle ISO 639 (pro nás `cs`)
- **Teritorium** – dle ISO 3316 (pro nás `CZ`)
- **Znaková sada** – například (ISO8859-2 nebo UTF-8)
- **Příklady** `cs_CZ.ISO8859-2, cs, cs_CZ, en_GB.UTF-8`

setlocale(3) . . . . . Nastavení lokalizace

```
#include <locale.h>
char *setlocale(int category, char *locale);
```

Nastavení/zjištění hodnoty locale. Pokud je `locale` rovno `NULL`, jen vrátí stávající nastavení. Pokud je `locale` rovno `""`, nastaví hodnotu podle proměnných prostředí. Jinak nastaví hodnotu podle textu v řetězci `locale`.

Po startu programu je nastaveno locale `"C"`. Program by měl po startu volat následující funkci:

```
setlocale(LC_ALL, "");
```


Proměnné prostředí

LANG – implicitní hodnota pro všechny kategorie.
LC_* – nastavení jednotlivých kategorií.
LC_ALL – přebíjí výše uvedená nastavení pro všechny kategorie.

strcoll(3) . . . . . Porovnávání řetězců podle locale

```
#include <string.h>
int strcoll(const char *s1, const char *s2);
```

Funguje podobně jako `strcmp(3)`, jen bere ohled na nastavení hodnoty `LC_COLLATE`.

strxfrm(3) . . . . . Trabsformace řetězce podle locale

```
#include <string.h>
size_t strxfrm(char *dest, char *src, size_t len);
```

Převede řetězec `src` na řetězec `dest` délky maximálně `len` tak, že výsledek porovnání takto získaných řetězců pomocí `scmp(3)` je ekvivalentní porovnání původních řetězců pomocí `strcoll(3)`.

Pokud je potřeba alespoň `len` znaků, je hodnota `dest` nedefinována.

◇ **Úkol:** Napište pomocí `strxfrm(3)` program pro třídění standardního vstupu (podobný programu `sort(1)`).

Katalogy zpráv

- **P**ro kategorii `LC_MESSAGES`.
- **G**NU `gettext` – překladové tabulky, vyhledávání řetězců.

Další programy

locale(1) . . . . . Lokalizačně specifické informace

Bez parametrů vypíše informace o právě nastavých locales. S parametrem `-a` vypíše všechny definované locales. Jako parametr lze dát konkrétní vlastnost locale, například:

```
$ locale charmap
UTF-8
$ locale mon
leden;únor;březen;duben;květen;...
```

localedef(8) . . . . . Kompilace lokalizačního souboru

`$ localedef` [`-f` ⟨*charmap*⟩] [`-i` ⟨*inputfile*⟩] ⟨*outdir*⟩

Vytvoří binární podobu locale pro přímé použití v aplikacích.

Start systému

Firmware

- Uloženo v paměti ROM.
- Na PC odpovídá BIOSu.
- Test hardware.
- Zavedení systému z vnějšího média.
- Často poskytuje příkazový řádek (PROM monitor).
- Sériová konzola?

Primární zavaděč systému

- Program v boot bloku disku; pevná délka; zavádí sekundární zavaděč.

Sekundární zavaděč systému

- Načítá jádro, předává mu parametry.
- Někdy poskytuje příkazový řádek.
- Někdy umí číst souborový systém.
- Používá firmware k zavedení jádra.

Start jádra

Parametry jádra

- Systémová konzola a kořenový disk.
- Parametry pro ovladače zařízení.
- Ostatní parametry předány do uživatelského prostoru.

Průběh inicializace jádra

- Virtuální paměť – co nejdříve.
- Inicializace konzoly.
- Inicializace sběrnic. (Autokonfigurovaná zařízení.)
- Inicializace CPU.
- Inicializace zařízení.
- Vytvoření procesu číslo 0 (idle task, swapper, scheduler).
- Start kernel threadů (`kflushd`, `kswapd`).
- Inicializace ostatních CPU (a start idle procesů).
- Připojení kořenového systému souborů.
- Start procesu číslo 1 v souboru `/sbin/init`.

Inicializace zařízení

- **UNIX v7** – bloková/znaková zařízení, statické tabulky (`bdevsw[]`, `cdevsw[]`).
- **Linux** – bloková/znaková/SCSI/síťová zařízení, dynamické tabulky.
- **Obsluha zařízení** – funkce pro otevření, čtení, zápis, řídící operace, atd. Privátní data zařízení.

Detekce zařízení

- **Autokonfigurovaná zařízení** – např. PCI, SBUS a podobně.
- **Empirické testy** – ISA. Zápis na nějaký port, očekávání reakce zařízení. Záleží na pořadí testů, může dojít až k zablokování sběrnice (síťové karty NE 2000).
- **Hot-swap zařízení** – konfigurace počítače se mění v době provozu (CardBus, USB, hot-swap SCSI, atd).


```
Linux version 2.4.0-test9 (kron@pyrrha.fi.muni.cz) \
(gcc version egcs-2.91.66 19990314/Linux (egcs-1.1.2 \
release)) #1 Mon Oct 9 08:32:07 CEST 2000
BIOS-provided physical RAM map:
 BIOS-e820: 000000000009fc00 @ 0000000000000000 (usbl)
 BIOS-e820: 0000000000000400 @ 000000000009fc00 (rsvd)
 BIOS-e820: 0000000000010000 @ 00000000000f0000 (rsvd)
 BIOS-e820: 0000000007ef0000 @ 0000000000100000 (usbl)
On node 0 totalpages: 32752
zone(0): 4096 pages.
zone(1): 28656 pages.
Kernel command line: auto BOOT_IMAGE=linux ro \
root=1601 console=ttyS1,38400n8
Initializing CPU#0
Detected 677.944 MHz processor.
Console: colour VGA+ 80x25
Calibrating delay loop... 1353.32 BogoMIPS
Memory: 126748k/131008k available (1225k kernel code, \
3872k reserved, 73k data, 176k init, 0k highmem)
```



```
Dentry-cache hash table entries: 16384 (order: 5, \
131072 bytes)
Buffer-cache hash table entries: 4096 (order: 2, \
16384 bytes)
VFS: Diskquotas version dquot_6.4.0 initialized
CPU: L1 I Cache: 64K  L1 D Cache: 64K (64 bytes/line)
CPU: L2 Cache: 512K
CPU: AMD Athlon(tm) Processor stepping 01
Checking 'hlt' instruction... OK.
mtrr: v1.36 (20000221) Richard Gooch
PCI: PCI BIOS revision 2.10 entry at 0xfdaf1, lbus=1
PCI: Using configuration type 1
PCI: Probing PCI hardware
PCI: Using IRQ router default [1022/740b] at 00:07.3
Linux NET4.0 for Linux 2.4
NET4: Unix domain sockets 1.0/SMP for Linux NET4.0.
NET4: Linux TCP/IP 1.0 for NET4.0
IP Protocols: ICMP, UDP, TCP
IP: routing cache hash table of 512 buckets, 4Kbytes
TCP: Hash tables configured (established 8192 bind 8192)
```



```
Starting kswapd v1.8
pty: 256 Unix98 ptys configured
Uniform Multi-Platform E-IDE driver Revision: 6.31
ide: Assuming 33MHz system bus speed for PIO modes; \
override with idebus=xx
AMD7409: IDE controller on PCI bus 00 dev 39
    ide0: BM-DMA at 0xf000-0xf007, BIOS settings: \
    hda:DMA, hdb:pio
hda: QUANTUM FIREBALLP LM10.2, ATA DISK drive
ide0 at 0x1f0-0x1f7,0x3f6 on irq 14
hda: 20066251 sectors (10274 MB) w/1900KiB Cache, \
CHS=1249/255/63, UDMA(66)
Partition check:
 /dev/ide/host0/bus0/target0/lun0: p1 p2 p3
Serial driver version 5.02 (2000-08-09) with \
MANY_PORTS SHARE_IRQ SERIAL_PCI enabled
ttyS00 at 0x03f8 (irq = 4) is a 16550A
eepro100.c:v1.09j-t 9/29/99 Donald Becker
eth0: Intel Corporation 82557 [Ethernet Pro 100], \
00:D0:B7:6B:4A:B2, IRQ 11.
```



```
  Board assembly 721383-008, Physical connectors \
  present: RJ45
  Primary interface chip i82555 PHY #1.
Linux agpgart interface v0.99 (c) Jeff Hartmann
agpgart: Maximum main memory to use for agp memory: 94M
agpgart: Detected AMD Irongate chipset
agpgart: AGP aperture is 64M @ 0xe0000000
devfs: v0.102 (20000622) Richard Gooch
devfs: boot_options: 0x2
kmem_create: Forcing size word alignment - nfs_fh
VFS: Mounted root (ext2 filesystem) readonly.
Freeing unused kernel memory: 176k freed
```

Hlášení jádra lze vypsat příkazem `dmesg(8)`.

Konfigurace jádra

- **System V** konfigurace jádra (`/etc/system`, `/etc/conf/`).
- **BSD** konfigurace jádra (`/sbin/config`, konfigurační soubory, adresáře pro kompilaci).
- **Linux** – jako jiné programy (používá `make`).

Monolitické jádro

- Jeden soubor na disku.
- Všechny používané ovladače jsou uvnitř jádra.
- Často bez autodetekce zařízení.
- Paměť dostupná všem částem jádra stejně.

Mikrokernel

- CMU Mach, OSF Mach, minix, NT HAL, QNX.
- Co nemusí být v kernelu, dát mimo něj.
- Procesy (servery) pro správu virtuální paměti, ovládání zařízení, disků a podobně.
- Dobře definovatelné podmínky činnosti.
- Předávání zpráv – malá propustnost, velká latence.

Modulární jádro

- Části (moduly), přidávané do jádra za běhu (odpovídá dynamicky linkovaným knihovnám v uživatelském prostoru).
- Ovladače, souborové systémy, protokoly, ...
- Přidávání ovladačů pouze při startu systému – AIX, Solaris.

Modulární jádro v Linuxu

- Dynamické přidávání ovladačů podle potřeby.
- Kernel daemon/`kmod`.
- Závislosti mezi moduly (`depmod(8)`).
- Dynamická registrace modulů: `register_chrdev()`, `register_blkdev()`, `register_netdev()`, `register_fs()`, `register_binfmt()` a podobně.

Bootování s ramdiskem

- Obsah ramdisku načten sekundárním zavaděčem do paměti spolu s jádrem.
- Jádro nemusí mít v sobě žádné ovladače kromě konzoly a souborového systému, který je na ramdisku.
- Inicializace a přilinkování modulů.
- Případné odmontování ramdisku.
- Dále pokračuje start systému připojením kořenového souborového systému a spuštěním `init`u.

Ramdisk v Linuxu

- **Komprimovaný soubor**
- **Obraz souborového systému**
- **Startovací skript `/linuxrc`**
- **Mimo jiné určení kořenového svazku**
- **Po ukončení** – přemontování jako `/initrd`.

Architektura jádra

- **Při startu** – kontext procesu číslo 0 – později idle task. Idle task nemůže být zablokován uvnitř čekací rutiny.
- **Kontext** – stav systému, příslušný běhu jednoho procesu.
- **Přepnutí kontextu** – výměna právě běžícího procesu za jiný.
- **Linux** – `struct task_struct`, `current`.

- **Problém:** Pod jakým kontextem mají běžet služby jádra?
- **UNIX** – použije se kontext volajícího procesu. Proces pak má dva režimy činnosti – user-space a kernel-space.
- **Mikrokernel** – předá se řízení jinému procesu (serveru).

- **Problém:** Pod jakým kontextem lze provádět přerušení?
- **Zvláštní kontext** – nutnost přepnutí kontextu $\longrightarrow$ zvýšení doby odezvy (latence) přerušení. Navíc je nutno případně mít více kontextů pro možná paralelně běžící přerušení.
- **UNIX** (ve většině implementací): Přerušení se provádí pod kontextem právě běžícího procesu. Obsluha přerušení nesmí zablokovat proces.

Přerušení

- **Žádost o pozornost hardwaru**
- **Obsluha** – nepřerušitelná nebo priority.
- **Horní polovina** – co nejkratší, nepřerušitelná. Např. přijetí packetu ze sítě, nastavení vyslání dalšího packetu. Interrupt time.
- **Spodní polovina** – náročnější úkoly, přerušitelné. Obvykle se spouští před/místo předání řízení do uživatelského prostoru. Například: směrování, výběr dalšího packetu k odvysílání. Softirq time.

- **Peemptivní/nepreemptivní jádro** – může dojít k přepnutí kontextu kdekoli v jádře?

Odložené vykonání kódu

- **Funkce, vykonaná později** (po návratu z přerušení, při volání scheduleru, atd.)
- **Spodní polovina** obsluhy přerušení.
- **Časově nekritický kód**
- **Může být přerušen**
- **Linux** – bottom half (serializováno globálně). Tasklety (serializovány pouze vzhledem k sobě).

Virtuální paměť

- **Virtuální adresa** – adresa z hlediska instrukcí CPU.
- **Překlad mezi virtuální a fyzickou adresou** – stránková tabulka (obvykle dvou- nebo tříúrovňová). Každý proces má svoji virtuální paměť $\Longrightarrow$ každý proces má svoji stránkovou tabulku.
- **Výpadek stránky** (page fault) – stránka není v paměti, stránkový adresář neexistuje, stránka je jen pro čtení a podobně.
- **Obsluha výpadku stránky** – musí zjistit, jestli jde (například) o copy-on-write, o žádost o natažení stránky z odkládacího prostoru, o naalokování stránky, nebo jestli jde o skutečné porušení ochrany paměti procesem.
- **TLB** – translation look-aside buffer – asociativní paměť několika posledních použitých párů *(virtuální adresa, fyzická adresa)*.
- **Přepnutí kontextu** – vyžaduje vyprázdnění TLB, v případě virtuálně adresované cache také vyprázdnění cache. Proto je přepnutí mezi vlákny rychlejší.
- **Softwarový TLB** – OS-specifický formát stránkových tabulek.

Virtuální paměť z hlediska jádra

- **Kód a paměť jádra** – mapován obvykle na konec adresního prostoru.
- **Přepnutí do režimu jádra** – zpřístupnění horních (virtuálních) adres.
- **Fyzická paměť** – mapována také 1:1 do paměťové oblasti jádra (Linux bez `CONFIG_HIGHMEM`).
- **Zásobník** – pro každý thread/kontext (Linux – 1 stránka/thread, nastavitelné 2 stránky/thread).

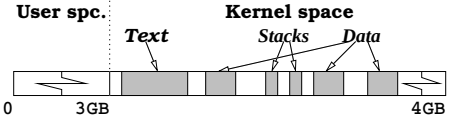

- **Jiný přístup** – přepnutí stránkové tabulky při přepnutí do jádra (rozdělení 4:4 GB na 32-bitových systémech).
- **Použití víc než 4 GB paměti na 32-bitových systémech** – Intel PAE, 36-bitová fyzická adresa.

Paměť z hlediska hardwaru

- **Fyzická adresa** – adresa na paměťové sběrnici, vycházející z CPU (0 je to, co CPU dostane, vystaví-li nuly na všechny bity adresové sběrnice).
- **Virtuální adresa** – interní v CPU. Instrukce adresují paměť touto adresou.
- **Sběrnicová adresa** – adresa místa v paměti tak, jak je vidí ostatní zařízení. V některých případech stejná jako fyzická, u některých architektur vlastní MMU pro sběrnici (Sun 4M IOMMU), případně vlastní MMU na zařízení.

◇ **Příklad:** PowerPC Reference Platform (PRep):

- **Z hlediska CPU**: 0–2GB fyzická paměť, 2GB–3GB system I/O (ekvivalent adres I/O portů pro `inb()` a `outb()` na x86, 3GB–4GB I/O memory (sdílená paměť na I/O sběrnici; ekvivalent sdílené paměti mezi 640 KB a 1 MB na x86).
- **Z hlediska HW**: Fyzická paměť je na 2GB–4GB, I/O adresy jsou v prvních dvou GB.

◇ **Příklad:** Intel Xeon PAE (36-bitová fyzická paměť, virtuální i sběrnicová adresa je ale 32-bitová).

Přístup do uživatelského prostoru

- Není možný uvnitř ovladače přerušení (aktuální kontext není v žádném vztahu k probíhající operaci).
- Je nutné kontrolovat správnost ukazatelů z uživatelského prostoru.
- Chybná uživatelská data nesmí způsobit pád jádra.
- Problémy ve vícevláknových programech (přístup versus změna mapování v jiném vláknu).

Řešení Linuxu

```
status = get_user(result, pointer);
status = put_user(result, pointer);
get_user_ret(result, pointer, ret);
put_user_ret(result, pointer, ret);
copy_user(to, from, size);
copy_to_user(to, from, size);
copy_from_user(to, from, size);
...
```


Implementace v Linuxu

- **Využití hardwaru CPU** – kontrola přístupu do paměti. Přidání kontroly do `do_page_fault()`.
- **Makra preprocesoru**
- **Tabulka výjimek** – adresa instrukce, která může způsobit chybu, opravný kód.
- **Normální běh** – cca 10 instrukcí bez skoku.
- **ELF sekce**

Paralelní stroje

- **SMP** – symetrický multiprocesing. Společný přístup všech CPU k paměti.
- **NUMA** – hierarchická paměť – z určitých CPU rychlejší přístup než z jiných (cc-NUMA – cache coherent).
- **Multipočítače** – na částech systému běží zvláštní kopie jádra (clustery a podobně).
- **Problémy** – cache ping-pong, zamykané přístupy na sběrnici, afinita přerušení.

Paralelní stroje

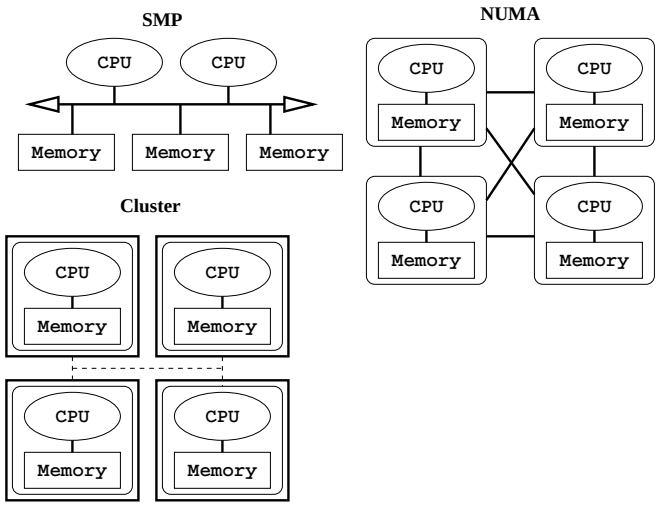

Zamykání kódu

- **Paralelismus** – v jednom okamžiku mohou tytéž data modifikovat různé procesy (kontexty).
- **Na jednom CPU** – v kterémkoli okamžiku může být proces přerušen a tentýž kód může provádět i jiný proces.
- **Problém** – manipulace s globálními datovými strukturami (alokace paměti, seznam volných i-uzlů, atd.).

Na jednom CPU

- **Postačí ochrana proti přerušení**
- **Zákaz přerušení na CPU** – instrukce `cli` a `sti`, v Linuxu funkce `cli()` a `sti()`.
- **Problém** – proměnná doba odezvy systému.

Na paralelním systému

- **Large-grained (hrubozrnný) paralelismus** – jeden zámek kolem celého jádra (Linux: `lock_kernel()`, `unlock_kernel()`). Paralelismus možný pouze v uživatelském prostoru. Jednodušší na implementaci, méně výkonný.
- **Fine-grained paralelismus** – zámky kolem jednotlivých kritických sekcí v jádře. Náročnější na implementaci, možnost vzniku netriviálně detekovatelných chyb. Vyšší výkon (několik IRQ může běžet paralelně, několik procesorů zároveň běžících v kernelu).
- **Zamykání v SMP** – nutnost atomických instrukcí (test-and-set) nebo detekce změny nastavené hodnoty (MIPS). Zamčení sběrnice (prefix `lock` na i386).

Semafory

- **Exkluzivní přístup ke kritické sekci**
- **Určeno i pro dlouhodobé čekání**
- **Lze volat pouze s platným uživatelským kontextem**
- **Linux** – `up()`, `down()`, `down_interruptible()`.

Spinlocky

- **Krátkodobé zamykání**
- **Nezablokuje proces** – proces čeká ve smyčce, až se zámek uvolní.
- **V Linuxu** – `spin_lock_init(lock)`, `spin_lock_irqsave(lock)`, `spin_unlock_irqrestore(lock)` a podobně.

R/W zámky

- **Paralelní čtení – exkluzivní zápis**
- **Linux** – `struct rwlock`, `struct rwsem`.
- **Problémy** – priority? upgrade r-zámku na w-zámek (deadlock).

Read-copy-update

- **RCU** – původně Sequent (Dynix/PTX), později IBM, implementace i v Linuxu.
- **Atomické instrukce** – pomalé (stovky taktů; přístup do hlavní paměti).
- **Obvyklá cesta** (např. čtení) by měla být rychlá.
- **Kód bez zamykání** – ale omezující podmínky (například držení odkazu na strukturu).
- **Linux** – omezující podmínka – přepnutí kontextu na všech procesorech. Odložené vykonání funkce po splnění podmínky.
- **Slabě uspořádané architektury** – instrukce čtení (někde i instrukce zápisu) mohou být přeuspořádány. Nutnost explicitních paměťových bariér (speciální instrukce CPU).

Read-copy-update – příklad

◇ **Příklad:** Rušení prvku ze seznamu

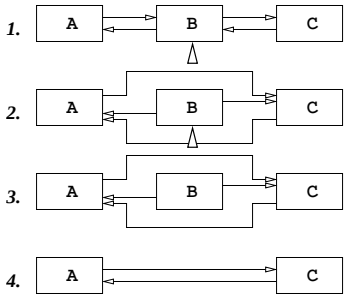

- **Čekání na splnění omezující podmínky** – bezi body 2. a 3. Využívá se odloženého spuštění kódu.

Časovače

- **Časovač** – nutnost vyvolat přerušení po určité době.
- **Atributy** – čas a funkce, která se vyvolá po vypršení času.
- **Funkce v Linuxu** – `add_timer()`, `del_timer()`.
- **Zablokování procesu** – `current->timeout`.

Čekací fronty

- **Wait queues** – seznam procesů, zablokovaných čekáním na určitou událost (načtení bufferu, dokončení DMA, atd.)
- **Čekající proces** – zařazen do fronty pomocí funkce `sleep_on(q)` nebo `interruptible_sleep_on(q)`.
- **Probuzení procesů** – `wake_up(q)` které zavolá jiný proces nebo IRQ handler. Probudí všechny procesy ve frontě.
- **Přepnutí kontextu** – funkce `schedule()`.

Procesy

- **Proces** – běžící program.
- **Proces** – kontext procesoru se samostatnou VM.
- **Thread** – kontext bez samostatné VM.

Paměť procesu:

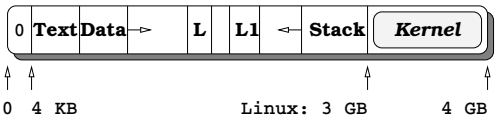

- **Paměť jádra** – přístupná pouze v režimu jádra.
- **Zero page** – zachycení použití neplatných pointerů. U 64-bitových systémů obvykle mezi 0 a 4 GB.
- **Hlavička procesu** – System V (Bach): Záznam v tabulce procesů (viditelný z jádra všem procesům), *u-oblast* – viditelná jen procesu samotnému.

Stavy procesu

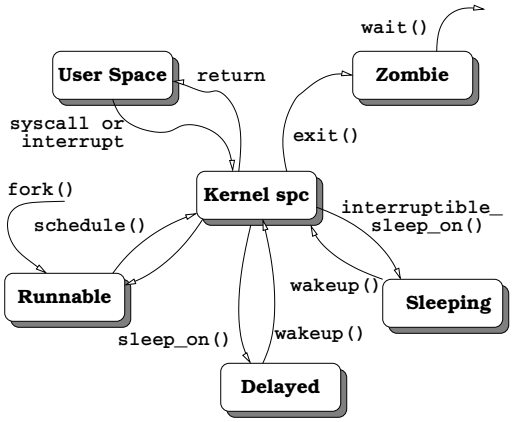

Atributy procesu

- **Stav procesu**
- **Program counter** – čítač instrukcí; místo, kde je proces zablokován.
- **Číslo procesu** – PID.
- **Rodič procesu** – PPID (rovno 1, pokud neexistuje).
- **Vlastník procesu** – (real) UID.
- **Skupina procesu** – (real) GID.
- **Skupina procesů, session** – seskupování procesů do logických celků.
- **Priorita procesu**
- **Reakce na signály, Čekající signály**
- **Časy běhu**
- **Pracovní a kořenový adresář**
- **Tabulka otevřených souborů**
- **Odkazy na potomky**
- **Limity** – na velikost souboru, max. spotřebovaný čas, max. počet otevřených souborů atd (`setrlimit(2)`).

Atributy procesu lze číst programem `ps(1)`. Funguje nad virtuálním souborovým systémem `/proc` nebo nad `/dev/mem`.

Služba jádra

- **Kód definován v jádře**
- **Přepnutí oprávnění CPU**
- **Charkaterizována svým číslem**
- **Glue funkce** v knihovně.
- **Mechanismus** – software interrupt, call gate.
- **Nastavení `errno`**
- **Přerušitelné/nepřerušitelné služby jádra** – `EINTR`.
- **Druhá kapitola referenční příručky**

Knihovní funkce

- **Kód definován v adresním prostoru procesu**
- **Lze předefinovat (napsat vlastní funkci)**
- **Možnost příchodu signálu během provádění**
- **Nemusí být reentrantní**
- **Třetí kapitola referenční příručky**

Vznik procesu

`fork(2)` . . . . . Vytvoření procesu

```
#include <sys/types.h>
#include <unistd.h>
pid_t fork();
```

- Vytvoří potomka procesu.
- Rodiči vrátí číslo potomka.
- Potomkovi vrátí nulu.

Potomek dědí téměř vše od rodiče. Vyjímkou jsou čísla PID, PPID, zámky na souborech, návratová hodnota `fork(2)`, signál od časovače, čekající signály, hodnoty spotřebovaného strojového času.

`vfork(2)` . . . . . Virtuální fork()

```
#include <sys/types.h>
#include <vfork.h>
pid_t vfork();
```

Vytvoří potomka bez kopírování adresového prostoru. Rodič je pozastaven dokud potomek nevyvolá `exec(2)` nebo `_exit(2)`.

Zavedeno původně jako BSD extenze.

Čekání na ukončení potomka

```
#include <sys/types.h>
#include <sys/wait.h>
pid_t wait(int *status);
pid_t waitpid(pid_t pid, int *status,
                            int options);
```

Počká na ukončení potomka. Pokud je `status` nenulový ukazatel, uloží do něj informace o změně stavu potomka:

`WIFEXITED(status)`
– proces skončil pomocí `_exit(2)`. Návratový kód zjistíme pomocí `WEXITSTATUS(status)`.

`WIFSIGNALED(status)`
– potomek byl ukončen signálem. Číslo signálu zjistíme pomocí `WTERMSIG(status)`. Navíc SVR4 i 4.3BSD (ale ne POSIX.1) definují makro `WCOREDUMP(status)`, které nabývá hodnoty pravda, byl-li vygenerován `core` soubor.

`WIFSTOPPED(status)`
– proces byl pozastaven. Důvod pozastavení zjistíme makrem `WSTOPSIG(status)`.

Parametr `options` je nula nebo logický součet následujících:

`WNOHANG` – nezablokouje se čekáním.
`WUNTRACED` – i při pozastavení nebo ladění potomka.

`wait3(2)`, `wait4(2)` . . . . . Čekání na ukončení potomka

```
#include <sys/types.h>
#include <sys/time.h>
#include <sys/resource.h>
#include <sys/wait.h>
pid_t wait3(int *status, int opts,
                struct rusage *rusage);
pid_t wait4(pid_t pid, int *status, int opts,
                struct rusage *rusage);
```

Počká na potomka a zároveň získá informace o jeho využití systémových prostředků. Viz též `getrusage(2)`.

◇ **Příklad:** Použití `fork()` a `wait()`

```
switch(pid=fork()) {
case 0:
    potomek();
    break;
case -1:
    perror("fork() failed");
    exit(1);
default:
    rodic(pid);
    break;
}
potomek() {
    ...
    exit(status);
}
rodic(pid) {
    int status;
    waitpid(pid, &status, 0);
    ...
}
```

Spuštění programu

exec(3) . . . . . Spuštění procesu

```
#include <unistd.h>
extern char **environ;
int execl(char *path, char *arg, ...);
int execlp(char *path, char *arg, ...);
int execle(char *path, char *arg, ...,
        char **envp);
int execv(char *path, char **argv);
int execvp(char *path, char **argv);
int execve(char *path, char **argv,
        char **envp);
```

Nahradí text procesu jiným textem a začne tento text vykonávat. Uzavře deskriptory, které mají flag `FD_CLOEXEC`. Tento flag je zejména normou POSIX.1 vyžadován u adresářových deskriptorů.

Obvykle je `execve(2)` a zbytek jsou knihovní funkce implementované pomocí `execve(2)`. Všechny funkce jsou označovány souhrnně jako `exec(2)` nebo `exec(3)`.

system(3) . . . . . Vyvolání příkazu shellu

```
#include <stdlib.h>
int system(char *string);
```

Spustí příkaz `/bin/sh -c string` jako potomka a počká na jeho dokončení.

`fork(2)` v moderních systémech

- **Systém bez stránkování** – nutnost kopírování celého adresního prostoru. Ve většině případů následuje `exec(2)` ⟶ nový adresní prostor se znovu přepíše.

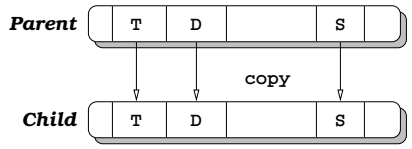

- **Systém se stránkováním** – kopíruje se jen stránková tabulka (několik KB). Stránky se nastaví jako r-only a kopírují se až při zápisu.

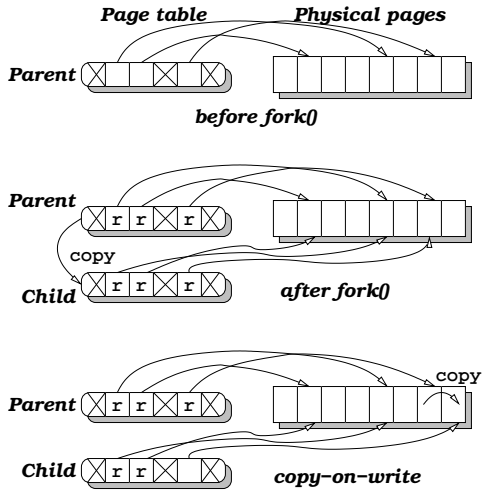

Systémy se stránkováním

- **Unifikovaný systém diskových bufferů a virtuální paměti** – některé stránky mohou být sdíleny s diskovými buffery – stránka má svůj *obraz v souboru*.
- **`fork(2)`** – sdílení dat mezi rodičem a potomkem, copy-on-write.
- **Další možnosti sdílení**

Sdílení textu programu

- **Sdílení s diskovými buffery** – o určité stránce se např. ví, že je to stránka ze souboru `/bin/sh`, offset 8192 bajtů. Takto může být stránka namapována do adresního prostoru více procesů.
- **Sdílené knihovny** – úplně stejný mechanismus.

Stránkování na žádost

- **Demand-paging**
- **Text procesu** se nenačítá do paměti, pouze se pro každou stránku v textové části adresního prostoru označí, kde má své místo v souboru.
- **Přístup k textu** ⟶ výpadek stránky; stránka se načte ze souboru.
- **Při nedostatku paměti** lze stránky v textu přímo rušit (bez zápisu na odkládací zařízení). Později je možno je zase načíst ze souboru. *Text file busy*.
- **Výhoda** – nenačítá se celý text, který se možná ani nevyužije (případ chybných parametrů na příkazové řádce a podobně).

I/O operace

- **`mmap(2)`** – nemusí se načítat soubor do paměti, načtou se jen jednotlivé stránky v případě potřeby.
- **`read(2)`** – v případě, že čteme do bufferu zarovnaného s velikostí stránky, může systém pouze namapovat (copy-on-write) stránku z buffer cache.

Alokace paměti

- **Služba `sbrk(2)`** pouze posune konec dat, ale nealokuje nové stránky.
- **Přístup k nově alokovanému prostoru** – výpadek stránky, obsluha přidělí novou stránku, namapuje ji a restartuje instrukci, která způsobila výpadek.
- **Výhody** – paměť se přiděluje až v okamžiku použití. Viz pole ve Fortranu.
- **Memory overcommitment** – má systém počítat, kolik paměti ještě „dluží“ procesům? Ano ⟶ nedojde tak brzo k vyčerpání zdrojů, většina programů stejně všechnu přidělenou paměť nevyužije. Ne ⟶ nenastane situace, kdy OS nemůže dostát svým slibům a musí násilně ukončit proces.

Výhody stránkovacích systémů

- **Šetří se systémové zdroje** – demand paging, alokace paměti až v případě použití.
- **Zvýšení rychlosti** – ušetří se kopírování paměti, které je úzkým místem současných počítačů.
- **Sdílení paměti** – unifikovaný systém VM a diskových bufferů lépe využívá paměť.

Program na disku

- **Binární formát** – Určuje strukturu souboru, ze kterého se bere text programu
- **Rozpoznání formátu** – magické číslo na začátku souboru. Z user-space příkaz `file(1)`, soubor `/etc/magic`.

Starší binární formáty

- **Jména** – `a.out`, `x.out`, `COFF` – common object file format.
- **Minimálně čtyři sekce** – hlavička, text, inicializovaná data, neinicializovaná data (BSS).
- **Velikost základních částí** – vypisuje program `size(1)`.
- **Další sekce** – ladící informace, tabulka symbolů a podobně.

Binární formát script

- **Hlavička** – `0x2123` (nebo `0x2321` na big-endian systému). Textová podoba – `#!`. Následuje jméno (cesta) interpreteru, který se na daný soubor spustí, plus jeho parametry.
- **Příklad** – `#!/usr/bin/perl -ne`, program v Perlu.
- **Jméno scriptu** – předáno interpreteru jako další parametr. Takto lze psát spustitelné soubory i ve formě scriptů, nejen jako binární programy ve strojovém kódu.

Binární formát ELF

- **Extended Linkable Format**
- **Stejný formát** pro `*.o` soubory i pro spustitelné programy.
- **Sekce** – mají textová jména, lze přidávat další sekce. Lze specifikovat, kam se která sekce má instalovat do paměti.
- **Možná rozšíření** – několik sekcí pro kód, z jednoho sekvenčního assemblerového textu lze generovat několik sekvencí kódu. Ikona spustitelného souboru, a podobně.

Změna práv procesu

- Pro UID a GID platí podobná pravidla.
- Reálné a efektivní UID.
- Saved UID (pokud je `_POSIX_SAVED_IDS`).
- Většina přístupových práv se prověřuje proti efektivnímu UID.
- Typy `uid_t` a `gid_t`, 16 nebo 32 bitů.

`getuid(2)`, `getgid(2)` . . . . . Vlastník/skupina procesu

```
#include <sys/types.h>
#include <unistd.h>

uid_t getuid();
uid_t geteuid();
gid_t getgid();
gid_t getegid();
```

Zjištění reálného a efektivního UID případně GID procesu.

`setuid(2)`, `setgid(2)` . . . . . Změna efektivního UID/GID

```
#include <sys/types.h>
#include <unistd.h>
int setuid(uid_t uid);
int setgid(gid_t gid);
```

- Pokud proces má superuživatelská práva, nastaví služba `setuid(2)` reálné, efektivní i uložené UID na `uid`.
- Pokud proces nemá práva superuživatele, ale `uid` je rovno reálnému nebo uloženému UID, změní `setuid(2)` pouze efektivní UID na `uid`.
- Jinak končí s chybou a proměná `errno` je nastavena na `EPERM`.

`setreuid(2)` . . . . . Výměna reálného za efektivní ID

```
#include <sys/types.h>
#include <unistd.h>
int setreuid(uid_t ruid, uid_t euid);
int setregid(gid_t rgid, gid_t egid);
```

Funkce definovaná v 4.3BSD. Umožňuje výměnu reálného a efektivního UID v systémech bez uloženého UID.

Uložené ID

- Pokud je definováno `_POSIX_SAVED_IDS`
- SVR4 podporuje uložená ID.
- FIPS 151–1 vyžaduje tuto vlastnost.

- Pouze superuživatel může měnit reálné UID.
- Efektivní UID je nastaveno funkcí `exec(2)`, pokud má příslušný program nastavený set-uid bit. Jinak se efektivní UID nemění.
- Při `exec(2)` se kopíruje uložené UID z efektivního UID.

◇ **Příklad:** Mějme set-uid program, který patří uživateli číslo 1 a je spuštěn uživatelem číslo 2. UID procesu se může měnit například takto:

Akce	real UID	effective UID	saved UID
Start programu	2	1	1
`setuid(2)`	2	2	1
`setuid(1)`	2	1	1
`exec()`	2	1	1
nebo:			
`setuid(2)`	2	2	1
`exec()`	2	2	2

`seteuid(2)` . . . . . Nastavení efektivního UID

```
#include <sys/types.h>
#include <unistd.h>
int seteuid(uid_t uid);
int setegid(gid_t gid);
```

Navrhovaná změna normy POSIX.1: Umožní superuživatelskému procesu změnit efektivní UID beze změny ostatních dvou UID. Vyžaduje systém, podporující uložené UID.

Doplňková GID

- **Starší verze UNIXu** – při přihlášení uživatele: UID a GID podle souboru `/etc/passwd`, změna GID pomocí `newgrp(1)`.
- **4.2 BSD** – doplňková GID. Proces má kromě reálného, efektivního a uloženého GID navíc ještě seznam *doplňkových GID (supplementary GIDs)*, který se inicializuje při přihlášení podle `/etc/group`.
- **Přístupová práva** – kontrolují se vzhledem k efektivnímu GID a všem doplňkovým GID.
- **POSIX.1** – doplňková GID jsou volitelnou vlastností. Konstanta `NGROUPS_MAX` určuje, kolik max. doplňkových GID může být. Je-li rovna nule, systém nepodporuje doplňková GID.
- **SVR4 a 4.3+BSD** – podporují doplňková GID.
- **FIPS 151–1** – vyžaduje podporu doplňkových GID a hodnotu `NGROUPS_MAX` aspoň 8.

`getgroups(2)` . . . . . Získání doplňkových GID

```
#include <sys/types.h>
#include <unistd.h>
int getgroups(int size, gid_t grouplist[]);
```

Do pole `grouplist[]` uloží doplňková GID až do počtu `size`. Vrátí počet skutečně zapsaných položek pole `grouplist[]`. Speciální případ: je-li `size` nulové, vrátí počet doplňkových GID pro daný proces.

`setgroups(2)` . . . . . Nastavení doplňkových GID

```
#include <sys/types.h>
#include <unistd.h>
int setgroups(int size, gid_t grouplist[]);
```

Nastaví doplňková GID pro proces. Tuto funkci smí používat pouze superuživatel.

`initgroups(3)` . . Nastavení doplňkových GID podle `/etc/group`

```
#include <grp.h>
#include <sys/types.h>
int initgroups(char *user, gid_t group);
```

Nastaví doplňková GID podle `/etc/group`. Navíc do seznamu skupin přidá skupinu `group`. Používá se při přihlašování. Tato knihovní funkce volá `setgroups(2)`.

Další atributy procesu

`getpid(2)`, `getppid(2)` . . . . . Čísla procesu

```
#include <sys/types.h>
#include <unistd.h>
pid_t getpid();
pid_t getppid();
```

Zjištění čísla procesu a čísla rodičovského procesu.

Skupiny procesů

- **Každý proces je v právě jedné skupině**
- **V každé skupině je jeden vedoucí proces**
- **Číslo skupiny je číslo vedoucího procesu**
- **Použití** – zasílání signálu, přístup k terminálu (viz `termios(4)`).

`setpgid(2)`, `setpgrp(2)` . . . . . Nastavení kupiny procesů

```
#include <unistd.h>
int setpgid(pid_t pid, pid_t pgid);
pid_t setpgrp(void);
```

`pid` je číslo procesu, `pgid` je číslo skupiny procesů. Je-li některé z nich 0, bere se PID aktuálního procesu.
`setpgrp()` je totéž co `setpgid(0, 0)`.

`getpgid(2)`, `getpgrp(2)` . . . . . Zjištění skupiny procesů

```
#include <unistd.h>
pid_t getpgid(pid_t pid);
pid_t getpgrp(void);
```

Zjistí číslo skupiny procesu (nebo procesu samotného, je-li `pid` = 0). `getpgid(0)` je totéž co `getpgrp()`.

Systémové zdroje

`times(2)` . . . . . Získání časových informací o procesu

```
#include <sys/times.h>
clock_t times(struct tms *buf);
struct tms {
   time_t tms_utime;
   time_t tms_stime;
   time_t tms_cutime;
   time_t tms_cstime;
}
```

Spotřebovaný čas v uživatelském prostoru a v prostoru jádra (v rámci procesu a včetně potomků).

`getrusage(2)` . . . . . Spotřebované systémové zdroje

```
#include <sys/time.h>
#include <sys/resource.h>
#include <unistd.h>
int getrusage(int who, struct rusage *r);
```

Zjistí spotřebované systémové zdroje. Parametr `who` je buďto `RUSAGE_SELF` nebo `RUSAGE_CHILDREN`.

`getrlimit(2)`, `setrlimit(2)` . . . . Limity systémových zdrojů

```
#include <sys/time.h>
#include <sys/resource.h>
#include <unistd.h>
int getrlimit(int resource, struct rlimit *rlim);
int setrlimit(int resource, struct rlimit *rlim);
```

Parametr `resource` může být jeden z následujících:

`RLIMIT_CORE`	velikost souboru `core`
`RLIMIT_CPU`	strojový čas
`RLIMIT_FSIZE`	velikost vygenerovaného souboru
`RLIMIT_DATA`	velikost datové oblasti
`RLIMIT_STACK`	velikost zásobníku
`RLIMIT_RSS`	resident set size (většinou neimplementováno)
`RLIMIT_NPROC`	počet procesů daného uživatele
`RLIMIT_NOFILE`	počet otevřených souborů
`RLIMIT_MEMLOCK`	uzamčená paměť
`RLIMIT_AS`	velikost virtuální paměti

Není součástí normy POSIX.1, ale je v BSD 4.3 a SVr4.

time(2) . . . . . Systémový čas

```
#include <time.h>
time_t time(time_t *t);
```

Získá systémový čas v sekundách od 1. ledna 1970. Lze použít pro měření reálného času.

Priorita procesu

nice(2) . . . . . Změna priority procesu

```
#include <unistd.h>
int nice(int inc);
```

Přičte `inc` k prioritě volajícího procesu. Pouze superuživatel může uvést negativní inkrement.

sched_yield(2) . . . . . Kooperativní multitasking

```
#include <sched.h>
int sched_yield();
```

Předá řízení jinému procesu, pokud je takový proces k dispozici.

getpriority(2) . . . . . Čtení priority procesu

```
#include <sys/time.h>
#include <sys/resource.h>
int getpriority(int which, int who);
int setpriority(int which, int who, int pri);
```

Služba `getpriority(2)` čte prioritu procesu. Hodnota parametru `which` je jedna z následujících:

PRIO_PROCESS – priorita procesu.
PRIO_PGRP – priorita skupiny procesů.
PRIO_USER – priorita procesů daného uživatele.

Nulová hodnota parametru `who` značí volající proces, skupinu procesů nebo uživatele.

Služba `setpriority(2)` nastavuje prioritu procesu/skupiny procesů/uživatelových procesů na `pri`.

Službu `setpriority(2)` používá například program `renice(1)`.

I/O operace

- **Soubor** – základní jednotka při zpracování I/O operací z pohledu služeb jádra.
- **Deskriptor** – malé celé číslo – odkaz na otevřený soubor.
- **Standardní deskriptory** – 0, 1, 2 (podle normy POSIX.1 je nutné používat symbolické konstanty `STDIN_FILENO`, `STDOUT_FILENO` a `STDERR_FILENO`).

open(2), creat(2) . . . . . Otevření souboru

```
#include <sys/types.h>
#include <sys/stat.h>
#include <fcntl.h>
int open(char *path, int flags);
int open(char *path, int flags, mode_t mode);
int creat(char *path, mode_t mode);
```

Vrací deskriptor, příslušný souboru `path`. Parametr `flags` je jedno z `O_RDONLY`, `O_WRONLY` nebo `O_RDWR`, plus logický součet některých z konstant:

O_CREAT – vytvoření souboru, pokud neexistuje.
O_EXCL – chyba, pokud soubor existuje.
O_TRUNC – zarovnání souboru na nulovou délku.
O_APPEND – před každým zápisem do souboru je ukazatel pozice v souboru nastaven na konec souboru (jako u `lseek(2)`).
O_NONBLOCK, O_NDELAY – otevření v neblokujícím režimu.
O_SYNC – synchronní výstup.

close(2) . . . . . Uzavření deskriptoru

```
#include <unistd.h>
int close(int fd);
```

Uzavře deskriptor (a uvolní případné zámky, které proces měl pro tento deskriptor). Uzavření provádí jádro automaticky také při ukončení procesu.

lseek(2) . . . . . Nastavení pozice v souboru

```
#include <unistd.h>
off_t lseek(int fd, off_t offset, int odkud);
```

Nastaví ukazatel aktuální pozice v souboru. Parametr `odkud` nabývá těchto hodnot:

SEEK_SET – offset od začátku souboru.
SEEK_CUR – offset od aktuální pozice souboru.
SEEK_END – offset od konce souboru.

V některých systémech existuje i služba `llseek(2)`, která má parametr `offset` typu `long long`. Slouží pro přístup k souborům větším než `1«31` bajtů.
Na některé typy souborů nelze použít `lseek()`.

read(2) . . . . . Čtení souboru

```
#include <unistd.h>
ssize_t read(int fd,void *buf,size_t count);
```

Načte nejvýše `count` bajtů ze souboru do bufferu `buf`. Vrátí –1 v případě chyby, 0 na konci souboru nebo počet načtených bajtů.

write(2) . . . . . Zápis do souboru

```
#include <unistd.h>
ssize_t write(int fd,void *buf,size_t count);
```

Pokusí se zapsat nejvýše `count` bajtů do souboru. Zápis začíná na současné pozici v souboru; u souborů otevřených s parametrem `O_APPEND` se před zápisem aktuální pozice přesune na konec souboru.

◇ **Příklad:**

```
#include <unistd.h>
#include <fcntl.h>
#include <stdio.h>
...
#define BUFFER     (1«14)
char *name1, *name2, *p, buffer[BUFFER];
int fd1, fd2, l1, l2;
...
if ((fd1=open(name1,O_RDONLY)) == -1) {
     perror("Opening input file");
     exit(1);
}
```

```
if ((fd2=open(name2,O_WRONLY|O_CREAT, 0777))==-1){
     perror("Opening output file");
     exit(2);
}
while((l1=read(fd1,buffer,BUFFER))>0) {
     for(p=buffer; (l2=write(fd2,p,l1))>0; p+=l2)
          if(!(l1-=l2))
               break;
     if (l2 <= 0) {
          perror("Writing output file");
          exit(3);
     }
}
if (l1 < 0) {
     perror ("Reading input file");
     exit(4);
}
close(fd1);
close(fd2);
```


Zápis na konec souboru

Bit `O_APPEND` při otevírání souboru nelze v UN*Xu dobře emulovat. Viz následující dva úseky kódu:

```
if ((fd=open(filename,O_WRONLY)) == -1) {
      perror("open");
      exit(1);
}
if (lseek(fd, 0L, SEEK_END) == -1) {
      perror("lseek");
      exit(2);
}
if (write(fd, buffer, size) == -1) {
      perror("write");
      exit(3);
}
```



```
if ((fd=open(filename,O_WRONLY|O_APPEND)) == -1) {
      perror("open");
      exit(1);
}
if (write(fd, buffer, size) == -1) {
      perror("write");
      exit(3);
}
```

Problém nastává v případě zápisu více procesy do téhož souboru – pokud v prvním případě dojde k přepnutí kontextu mezi voláním `lseek(2)` a `write(2)`, nemusí dojít k zápisu na skutečný konec souboru.

◇ **Úkol:**

Otevřete-li soubor s `O_RDWR|O_APPEND`, můžete pomocí `lseek(2)` číst data z kteréhokoli místa souboru? A můžete také měnit soubor v kterémkoli jeho místě? Napište program, který toto ověří a pokuste se odhadnout, jakým způsobem je `O_APPEND` flag obsluhován v jádře systému.

Tabulka otevřených souborů

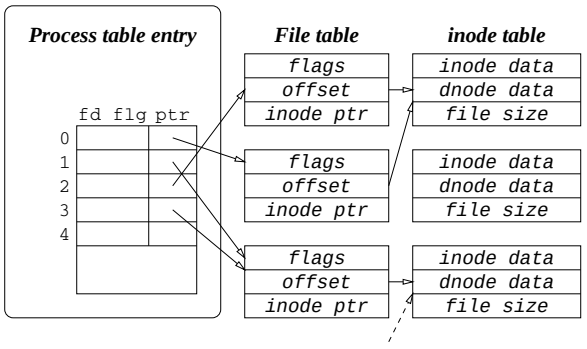

dup(2),dup2(2) . . . . . Duplikace deskriptoru

```
#include <unistd.h>
int dup(int oldfd);
int dup2(int oldfd, int newfd);
```

Duplikuje deskriptor – vytvoří nový odkaz do tabulky otevřených souborů na strukturu `file`. Použití: přesměrování v shellu.

◇ **Úkol:** Jak se liší funkce následujících dvou úseků kódu?
Varianta 1:

```
fd1=open("file",O_WRONLY|O_CREAT,0777);
fd2=dup(fd1);
write(fd1,"Hello, world\n",13);
write(fd2,"Hello, world\n",13);
close(fd1); close(fd2);
```

Varianta 2:

```
fd1=open("file",O_WRONLY|O_CREAT,0777);
fd2=open("file",O_WRONLY|O_CREAT,0777);
write(fd1,"Hello, world\n",13);
write(fd2,"Hello, world\n",13);
close(fd1); close(fd2);
```


fcntl(2) . . . . . Změna vlastností deskriptoru

```
#include <sys/types.h>
#include <unistd.h>
#include <fcntl.h>
int fcntl(int fd, int cmd);
int fcntl(int fd, int cmd, long arg);
```

Služba `fcntl(2)` provádí různé akce nad otevřeným deskriptorem. Hodnota `cmd` může být následující:

F_DUPFD – duplikuje deskriptor `fd` do `arg`, podobně jako `dup2(2)`.
F_GETFD – čte flagy deskriptoru (momentálně pouze `FD_CLOEXEC`).
F_SETFD – nastavuje flagy deskriptoru (`FD_CLOEXEC`).
F_GETFL – čte flagy struktury `file`. Tyto odpovídají druhému parametru volání `open(2)`, kterým byla tato struktura vtvořena, nebo předchozímu `fcntl( ,F_SETFL, )`.
F_SETFL – nastavuje flagy struktury `file`. Lze nastavovat pouze `O_APPEND`, `O_NONBLOCK`, `O_ASYNC` a `O_SYNC`.
F_GETLK, F_SETLK – zamykání části souboru.

ioctl(2) . . . . . Práce s I/O zařízením

```
#include <unistd.h> /* SVR4 */
#include <sys/ioctl.h> /* SVR4 */
int ioctl(int fd, int cmd, long arg);
```

Tato služba slouží k nastavení I/O zařízení, ke čtení jeho stavu a k posílání příkazů do zařízení. Není v POSIX.1.

◇ **Příklad:** Nastavení signálu DTR na sériové lince na log. 1:

```
open("/dev/ttyS0", O_RDWR);
ioctl(fd, TIOCMGET, &set_bits);
set_bits |= TIOCM_DTR;
ioctl(fd, TIOCMSET, &set_bits);
```


Organizace souborových systémů

Systém souborů musí zajišťovat:

- **Efektivní přístup k souborům** – adresářové operace (vyhledání souboru, přejmenování, atd.).
- **Efektivní operace nad soubory** – čtení/zápis (malá fragmentace etc.)
- **Spolehlivé zotavení po havárii**
- **Co nejmenší prostor na režii** – velikost metadat.

Svazek (systém souborů) je reprezentován blokovým zařízením. Většinou jde o diskovou oblast.

- **Boot block** je první blok svazku. Zavádí se z něj operační systém, nebo je prázdný.
- **Super block** – další blok svazku. Obsahuje sumární informace o svazku.
- **Tabulka i-uzlů** – informace o souborech.
- **Datové bloky**

i-uzly

i-uzel (identifikační uzel, inode) je struktura na disku, která popisuje soubor.

Následující atributy i-uzlů je možno zjišťovat na příkazové řádce příkazem `ls`, v programu voláním jádra `stat()`:

- **Délka souboru**
- **Typ souboru**
- **UID a GID vlastníka**
- **Časy** – čas přístupu, modifikace, a změny stavu.
- **Přístupová práva**
- **Počet odkazů** – klesne-li na nulu, je i-uzel uvolněn a jeho datové bloky také.

i-uzel a datové bloky

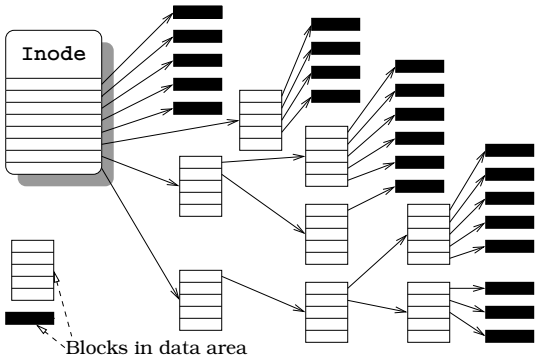

- i-uzel obsahuje 13 položek – odkazů na datové bloky.
- **Položky 1–10** ukazují přímo na datové bloky.
- **Položka 11** ukazuje na blok, kde jsou odkazy na datové bloky (první nepřímý odkaz).
- **Položka 12** ukazuje na blok, kde jsou odkazy na bloky odkazů na datové bloky (druhý nepřímý odkaz)
- **Položka 13** je třetí nepřímý odkaz.

- **Výhoda** – přímý přístup ke kterémukoli místu souboru.
- **Díry v souborech** – `/var/log/lastlog`, `core`.

◇ **Úkol:** Má-li souborový systém velikost bloku 1 KB a bloky jsou v i-uzlu indexovány 32-bitovým celým číslem bez znaménka, jaká je maximální teoretická velikost souboru?

Práce se soubory

stat(2) . . . . . Informace o i-uzlu

```
#include <sys/types.h>
#include <sys/stat.h>
int stat(char *path, struct stat *st);
int lstat(char *path, struct stat *st);
int fstat(int fd, struct stat *st);
```

Tyto služby systému zjišťují informace, uložené v diskovém i-uzlu. Příkaz `ls -l` používá služby jádra `lstat(2)`.

Služba `lstat(2)` není součástí standardu POSIX.1, ale stane se pravděpodobně součástí standardu POSIX.1a.

Struktura `struct stat` má tyto položky:

st_dev	– zařízení, na kterém se i-uzel nachází.
st_ino	– číslo i-uzlu.
st_mode	– typ souboru a přístupová práva.
st_nlink	– počet odkazů na i-uzel.
st_uid	– vlastník souboru.
st_gid	– skupina, které soubor patří.
st_rdev	– zde je uloženo hlavní a vedlejší číslo, jde-li o speciální soubor.
st_size	– velikost souboru.
st_blksize	– preferovaná velikost bloku pro I/O operace.
st_blocks	– počet bloků, odkazovaných z i-uzlu (viz soubory s děrami).
st_atime	– čas posledního přístupu.
st_ctime	– čas poslední změny i-uzlu.
st_mtime	– čas poslední změny obsahu souboru.

Přístupová práva

Typ souboru lze z položky `st_mode` získat těmito makry:

`S_ISREG()` – běžný soubor.
`S_ISDIR()` – adresář.
`S_ISCHR()` – znakový speciální soubor.
`S_ISBLK()` – blokový speciální soubor.
`S_ISFIFO()` – roura nebo pojmenovaná roura.
`S_ISLNK()` – symbolický link (není v POSIX.1).
`S_ISSOCK()` – pojmenovaný socket (není v POSIX.1).

Přístupová práva lze z `st_mode` získat těmito maskami:

`S_ISUID, S_ISGID, S_ISVTX`
– set-uid bit, set-gid bit a sticky bit.
`S_IRUSR, S_IWUSR, S_IXUSR`
– práva vlastníka souboru.
`S_IRGRP, S_IWGRP, S_IXGRP`
– práva skupiny.
`S_IROTH, S_IWOTH, S_IXOTH`
– práva ostatního světa.

`access(2)` . . . . . Ověření přístupových práv

```
#include <unistd.h>
int access(char *path, int mode);
```

Služba ověří, jestli vlastník procesu (to jest reálné UID/GID) má přístup k souboru. Parametr `mode` určuje typ přístupu – maska z jedné nebo více hodnot z `F_OK`, `R_OK`, `W_OK` a `X_OK`.

POZOR: Nebezpečí změny práv mezi voláním `access(2)` a skutečným přístupem. Potenciální bezpečnostní problém.

◇ **Úkol:** Ověřte, jak se služba `access(2)` chová, je-li argumentem symbolický link, resp. symbolický link ukazující do prázdna.

Nově vytvářené soubory

Vlastník souboru, který vznikne pomocí `open(2)` nebo `creat(2)` je nastaven podle efektivního UID procesu, který tento soubor vytvořil.

U skupiny souboru připouští POSIX.1 jednu ze dvou možností:

- Skupina je přidělena podle efektivního GID procesu, který soubor vytvořil.
- Skupina je přidělena podle GID adresáře, ve kterém je soubor vytvářen.

První varianta je v SVR4, druhá v BSD systémech (a vyžaduje ji FIPS 151-1). V SVR4 lze druhé varianty dosáhnout přidáním set-gid bitu do přístupových práv adresáře.

`umask(2)` . . . . . Maska přístupových práv

```
#include <sys/stat.h>
int umask(int newmask);
```

Služba nastavuje masku přísupových práv pro nově vytvářené soubory. Vrací předchozí nastavení této masky. Bity, které jsou v masce nastaveny na 1, se u nově vytvářeného souboru nulují.

◇ **Příklad:** Je-li `umask` rovno `022` a třetí parametr `open(2)` je roven `0776`, má výsledný soubor práva `0776 & ~022 = 0754`.

Změna práv souboru

V některých systémech (4.3 BSD) může vlastníka souboru měnit jen superuživatel (hlavním důvodem jsou diskové kvóty).

V POSIX.1 je toto volitelné – v době kompilace podle makra `_POSIX_CHOWN_RESTRICTED`, nebo v době běhu pomocí funkce `fpathconf(3)`, resp. `pathconf(3)`.

Skupinu může měnit i běžný proces, pokud jsou splněny zároveň tyto podmínky:

- Efektivní UID procesu je totožné s UID vlastníka souboru.
- Nemění se zároveň s GID také UID vlastníka souboru.
- Nové GID je totožné s efektivním GID procesu nebo s některým z dodatkových GID procesu.

Některé systémy (BSD 4.4 a z něj odvozené) nulují set-uid a set-gid bity v okamžiku zápisu do souboru procesem, který nemá práva superuživatele. Vždy jsou tyto bity nulovány také při změně vlastníka nebo skupiny souboru.

`chmod(2)` . . . . . Změna přístupových práv

```
#include <sys/types.h>
#include <sys/stat.h>
int chmod(char *path, mode_t mode);
int fchmod(int fd, mode_t mode);
```

Nastaví přístupová práva na soubor. Služba `fchmod(2)` není součástí POSIX.1, ale BSD i SVR4 systémy ji podporují.

`chown(2)` . . . . . Změna vlastníka/skupiny souboru

```
#include <sys/types.h>
#include <unistd.h>
int chown(char *path,uid_t owner,gid_t grp);
int lchown(char *path,uid_t owner,gid_t grp);
int fchown(int fd,uid_t owner,gid_t grp);
```

Změní vlastníka a skupinu souboru. Je-li jeden z parametrů `owner` nebo `grp` roven -1, neprovádí se změna tohoto údaje.

`fchown(2)` není součástí POSIX.1. Podporováno SVR4 i tak i 4.3+ BSD.

`lchown(2)` je pouze v SVR4. V ostatních systémech mění `chown(2)` práva symbolického linku a ne souboru, na který tento link ukazuje (bezpečnost!).

`truncate(2)` . . . . . Nastavení velikosti souboru

```
#include <sys/types.h>
#include <unistd.h>
int truncate(char *path, off_t length);
int ftruncate(int fd, off_t length);
```

Nastaví velikost souboru na `length`. Některé systémy (například 4.3 BSD a novější) nedovolí zvětšit velikost souboru. Tyto služby nejsou v POSIX.1, ale SVR4 i BSD je podporují.

SVR4 implementuje navíc `fcntl(F_FREESP)` – vytvoření díry v již existujícím souboru.

◇ **Úkol:** Napište program, který vytvoří soubor s dírou. Vyzkoušejte, které UN*Xové programy (např. `cp(1)`, `tar(1)`, `gtar(1)`, `cpio(1)`) umí takto vytvořený soubor zkopírovat včetně díry.

◇ **Úkol:** Zjistěte, které ze tří časů evidovaných v i-uzlu se mění při volání `truncate(2)`.

link(2) . . . . . Vytvoření odkazu na i-uzel

```
#include <unistd.h>
int link(char *path, char *newpath);
```

Vytvoří další odkaz na i-uzel (tzv. *pevný link*). POSIX.1 specifikuje, že `link(2)` může skončit s chybou, pokud `path` a `newpath` nejsou na tomtéž svazku.

unlink(2) . . . . . Zrušení odkazu na i-uzel

```
#include <unistd.h>
int unlink(char *path);
```

Zruší odkaz na i-uzel. Pokud je počet odkazů na i-uzel nulový, systém i-uzel smaže a uvolní příslušné datové bloky. Pozor: Za odkaz se považuje také odkaz z tabulky otevřených souborů.

◇ **Příklad:** Vytvoření anonymního dočasného souboru:

```
fd = open("file",O_CREAT|O_RDWR|O_EXCL);
unlink("file");
```


remove(3) . . . . . Zrušení souboru/adresáře

```
#include <stdio.h>
int remove(char *path);
```

Smaže soubor nebo adresář. Tato funkce je součástí normy ANSI C.

rename(2) . . . . . Přejmenování souboru/adresáře

```
#include <unistd.h>
int rename(char *oldpath, char *newpath);
```

Funkce je definována v POSIX.1 i v ANSI C (zde jen pro soubory). Atomické přejmenování/přesunutí souboru v rámci jednoho svazku.

utime(2) . . . . . Nastavení časů souboru

```
#include <sys/types.h>
#include <utime.h>
int utime(char *path, struct utimbuf *times);
struct utimbuf {
    time_t actime;
    time_t modtime;
}
```

Nastavení času posledního přístupu/modifikace. Používá například program `touch(1)`. Pokud je druhý parametr nulový ukazatel, jsou oba časy nastaveny na současný systémový čas.

Nastavovat čas smí pouze vlastník souboru (nebo superuživatel). Právo zápisu k tomuto nestačí.

◇ **Úkol:** Napište program, který nastaví délku zadaného souboru na nulu, ale zachová jeho čas posledního přístupu i modifikace.

Symbolické linky

- Symbolický odkaz na soubor pomocí cesty.
- Relativní versus absolutní symbolické linky.
- Nejsou v POSIX.1 (ale jsou součástí POSIX.1a).

symlink(2) . . . . . Vytvoření symbolického linku

```
#include <unistd.h>
int symlink(char *sympath, char *path);
```

Vytvoří symbolický link `path`, obsahující řetězec `sympath`.

readlink(2) . . . . . Čtení symbolického linku

```
#include <unistd.h>
int readlink(char *path,char *buf,size_t sz);
```

Přečte obsah symbolického linku (provádí ekvivalent služeb jádra `open(2)`, `read(2)` a `close(2)`). Obsah bufferu není ukončen nulovým znakem.

Symbolické linky a přístup k souborům

Služby jádra, které neprocházejí symbolické linky: `chown(2)` (pokud v systému neexistuje `lchown(2)`), `lchown(2)`, `lstat(2)`, `readlink(2)`, `rename(2)` a `unlink(2)`.

◇ **Úkol:** Co bude výsledkem těchto tří příkazů na různých systémech?

```
$ touch ježek
$ ln -s ježek tučňák
$ ln tučňák ptakopysk
```


Vytváření dočasných souborů

- **Adresář `/tmp`, `/var/tmp`**
- **Sticky bit**
- **Exkluzivita**
- **Bezpečnostní problém se symbolickými linky**
- **Linux** – `O_CREAT|O_EXCL`
- **FreeBSD** – `O_NOFOLLOW`
- **Ze shellu** – `mktemp(1)`.

mkstemp(3) . . . . . Vytvoření dočasného souboru

```
#include <stdlib.h>
int mkstemp(char *template);
int mkstemp("/tmp/mail.XXXXXX");
```

Vytvoří dočasný soubor podle dané masky. Vrátí deskriptor na tento soubor, do parametru zapíše skutečné jméno.

Adresáře v UNIXu

- **Adresář** – soubor, obsahující záznamy tvaru (*název, i-uzel*).
- **Položka „`.`“** – odkaz na sebe.
- **Položka „`..`“** – odkaz na nadřazený adresář; v kořenovém adresáři ukazuje na sebe.
- **Implementace** – položky „`.`“ a „`..`“ jsou často implementovány na úrovni OS, nikoli nutně fyzicky na disku.
- **Soubor pod více jmény** – ne adresáře (nejasný význam „`..`“ v adresáři).
- **Délka jména** – záleží na FS. Původní UNIX - 14, dnes většinou aspoň 252.
- **Délka struktury** – pevná nebo proměnná.
- **Organizace adresáře** – seznam, pole, strom.
- Každý adresář má aspoň dva odkazy.
- Sémantika konstrukce „`//`“.

Struktura adresáře

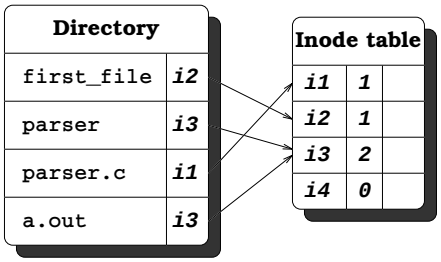

`mkdir(2)` . . . . . Vytvoření adresáře

```
#include <sys/types.h>
#include <sys/stat.h>
int mkdir(char *path, mode_t mode);
```

Vytvoří nový prázdný adresář s právy `mode` (modifikovanými podle `umask(2)`).

`rmdir(2)` . . . . . Smazání adresáře

```
#include <unistd.h>
int rmdir(char *path);
```

Smaže prázdný adresář. S adresářem je možné nadále pracovat, má-li jej v této době některý proces otevřený.

Čtení adresáře

V některých systémech je možné adresář číst přímo pomocí služby `read(2)`. POSIX.1 definuje přístup k adresáři pomocí následujícího rozhraní:

```
#include <sys/types.h>
#include <dirent.h>
DIR *opendir(char *path);
struct dirent *readdir(DIR *dp);
void rewinddir(DIR *dp);
int closedir(DIR *dp);
struct dirent {
    ino_t d_ino;
    char d_name[NAME_MAX+1];
}
```

POSIX.1 definuje pouze položku `d_name`. Pořadí jmen souborů (struktur `dirent`) vrácených při čtení adresáře závisí na implementaci.

◇ **Úkol:** Napište program, který vypíše obsah adresáře pomocí výše uvedených funkcí. Je pořadí souborů pokaždé stejné? Je výpis setříděn? Jsou vypsány i soubory, začínající tečkou?

Adresáře procesu

`getcwd(2)` . . . . . Jméno pracovního adresáře

```
#include <unistd.h>
char *getcwd(char *buf, size_t sz);
```

Vrátí cestu k pracovnímu adresáři. Je-li `sz` příliš malé, skončí s chybou. (Pozor na rozdíl mezi `pwd` a `/bin/pwd`).

`chdir(2)` . . . . . Změna pracovního adresáře

```
#include <unistd.h>
int chdir(char *path);
int fchdir(int fd);
```

Změní pracovní adresář na zadaný adresář (kontrola přístupových práv). Služba `fchdir(2)` není v POSIX.1 – jde o BSD rozšíření. (Proč neexistuje `cd(1)`?)

`chroot(2)` . . . . . Změna kořenového adresáře procesu

```
#include <unistd,h>
int chroot(char *path);
```

Změní kořenový adresář procesu. Povoleno pouze superuživateli.

◇ **Úkol:** Co všechno je potřeba k tomu, aby proces mohl „uniknout“ z prostředí se změněným kořenovým adresářem?

`sync(2)` . . . . . Synchronizování disků

```
#include <unistd.h>
void sync(void);
```

Synchronizování diskových bufferů. Tyto operace zařadí buffery které se mají ukládat na disk do fronty pro okamžitý zápis a nastartují tento zápis (obvykle speciální thread jádra).

`fsync(2)`, `fdatasync(2)` . . . . . Synchronizace deskriptoru

```
#include <unistd.h>
int fdatasync(int fd);
int fsync(int fd);
```

Zapíše všechny modifikované části souboru na disk. Služba `fdatasync(2)` nezapisuje metadata souboru (čas modifikace, ...).

mknod(2) . . . . . Vytvoření souboru

```
#include <sys/types.h>
#include <sys/stat.h>
#include <fcntl.h>
#include <unistd.h>
int mknod(char *path,mode_t mode,dev_t dev);
```

Vytvoří soubor daného jména. Parametr `mode` specifikuje přístupová práva a typ souboru (jedna z konstant `S_IFREG`, `S_IFCHR`, `S_IFBLK` nebo `S_IFIFO`, viz `stat(2)`).

mkfifo(2) . . . . . Vytvoření pojmenované roury

```
#include <sys/types.h>
#include <sys/stat.h>
int mkfifo(char *path, mode_t mode);
```

Vytvoří pojmenovanou rouru. Ve starších BSD systémech nebylo volání `mknod(2)`; pojmenovaná roura se vytvářela touto službou jádra.

Zotavení po havárii

- **Možné nekonzistence** – pořadí zápisových operací, write-back cache, změny dat/metadat, ale i chyby HW nebo OS.
- **Kontrola konzistence** `fsck(8)`. Časově náročné.
- **Synchronní zápis metadat?** – problémy se starými daty v souborech (bezpečnost!).
- **BSD Soft-updates** – závislosti mezi diskovými operacemi. Omezení počtu typů nekonzistencí $\longrightarrow$ rychlejší `fsck(8)`. Ale: problém pořadí data versus metadata; neřeší se chyba OS nebo HW.
- **Žurnálování** – transakční přístup. Změny nejprve zapsány do logu (žurnálu) a pak provedeny. Po havárii – přehrání celých transakcí. Někdy i rychlejší než nežurnálovaný FS. Většinou o něco pomalejší. Žurnál jen metadat nebo i dat. Chyba OS nebo HW se řeší pomocí `fsck(8)`.

Access Control Lists

- **Řízení přístupu pomocí GID** – dostatečně silné, ale vyžaduje spoluúčast superuživatele.
- **ACL** – plné řízení přístupu vlastníkem souboru.
- **ACL** – seznam položek tvaru ⟨*typ*⟩`:`[⟨*hodnota*⟩]`:`[`r`][`w`][`x`]
- **Implicitní položky** – typ `u`, `g`, `o` s prázdnnou hodnotou.
- **Další položky** – typ `u` a `g` s neprázdnou hodnotou. Je-li aspoň jedna takováto položka, je povinná další položka typu `m` – maska.
- **Příklady** – `u::rwx,g::r-x,o::r--`
  `u::rwx,g::r-x,o:---,u:bob:rwx,g:wheel:rw-,m:r-x`
- **Vyhodnocování** – hledá se shoda efektivního UID procesu, pokud se nenalezne, tak efektivní GID a doplňková GID, pokud se ani tady nenalezne, použije se položka `o:`. U nepovinných položek log. součin s maskou.
- **Omezení** – právě jedna položka od typu `u::`, `g::`, `o::`. Nejvýše jedna položka `m::`. Nejvýše jeden záznam pro každého uživatele a skupinu.
- **Korespondence s UNIXovými právy** – práva vlastníka souboru = položka `u::`, práva skupiny souboru = položka `m::`; není-li, pak `g::`.
- **Implicitní ACL** – u adresářů. Použije se pro nově vytvářené soubory.
- **Programy** – `getfacl(1)`, `setfacl(1)`, `chacl(1)`. Též `acl(5)`.

FAT

- Nemá i-uzly (nelze mít soubor ve více adresářích, nemá UNIXová přístupová práva).
- Pomalý přímý přístup k souboru (sekvenční procházení přes FAT).
- Fragmentace už při současném zápisu do dvou souborů.
- Fragmentace při rušení souboru.
- Na větších FS velká délka bloku $\longrightarrow$ špatné využití místa.
- Výhody – na menších FS malá režie, jednoduchá implementace.

UFS

- **FFS, EFS, UFS** – původně v 4.x BSD.
- Cylinder groups. Nutná znalost geometrie disku.
- Snížení fragmentace, 4–8 KB bloky.
- Fragmenty – lepší využití místa na disku.
- Kopie superbloku.
- Rezervované místo pro superuživatele
- Synchronní zápis metadat; novější implementace (FreeBSD) umí i asynchronní.
- Soft updates – zachování pořadí (některých) změn v datech a metadatech. Jednodušší `fsck(8)` – pevně dané typy nekonzistencí.
- Kontrola disku na pozadí.

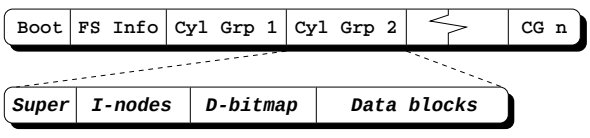

- **Implementace** – *BSD, Solaris (+ žurnálování), Linux.

LINUX ext2 filesystem

- Skupiny bloků (block groups) – místo CG u FFS. Není nutná znalost geometrie disku $\longrightarrow$ jednodušší implementace, využití celých bloků.
- Obvykle 1 KB (až 4 KB) bloky – rychlejší než FFS s 4 KB bloky.
- Alokační strategie: Předalokované bloky, alokace dat poblíž příslušných metadat, zamezení zaplnění jedné skupiny bloků.
- Bitmapa volných i-uzlů.
- Téměř neexistuje fragmentace.
- Priorita zápisu metadat (ale data se zapisují zároveň).
- Asynchronní zápis metadat; na požádání umí i synchronní.
- Velikost až do 4 TB dat. Velká odolnost proti havárii.
- Rychlé symbolické linky.
- No-atime volba.
- Maximum mount count. `tune2fs(8)`.
- Možnosti při chybě – panic, remount r-only, ignore.
- `libe2fs` – knihovna pro přístup k e2fs. `e2defrag`.

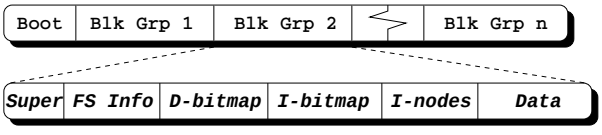

LINUX ext3 filesystem

- Struktury na disku – zpětně kompatibilní s ext2.
- **Žurnálování** – změny zapisovány přes transakční log.
- **Žurnálování dat** – `journal`, `ordered`, `writeback`.
- **Rozšířené atributy** – další metadata (např. security context).
- **Access control lists** – rozšíření přístupových práv (viz dále).
- **Adresáře** – lineární struktura nebo strom.

LINUX ReiserFS, Reiser4

- **Všechna data v jednom B+ stromu** (R4 – „dancing tree“).
- **Alokace místa** – i menší kousky než jeden sektor.
- **I-uzly** – alokace podle potřeby.
- Efektivní i při velkém množství souborů v adresáři nebo velkém množství malých souborů.

Navíc v Reiser4:

- **Plug-iny** souborového systému (např. vyhledávání/indexace).
- **Soubory s více proudy dat** (např. metadata) – každý soubor je také adresář.
- **Transakce** – více datových operací může být spojeno do jedné atomické transakce.

SGI XFS

- **Plně 64-bitový**
- **Rozdělení svazku** – kousky velikosti 0.5 až 4 GB.
- **Organizace dat** – B+ strom
- **DMAPI** – data manipulation API – zpřístupnění vlastností B-stromu (vkládání/rušení dat uprostřed souboru).
- **ACL** – viz dále.
- **Žurnálování**
- **Real-time extenze** – možnost alokace šířky pásma; garantovaná propustnost.
- **O_DIRECT** – přístup bez cachování.
- **Allocate on flush** – další snížení fragmentace.
- **CXFS** – nadstavba pro clustery (za příplatek).
- **Implementace** – IRIX, Linux.

Další služby FS

- **Synchronní/asynchronní zápis dat nebo metadat** – často volitelné.
- **Komprese dat** – celý FS nebo jen určité soubory.
- **Fragmenty** – FFS/UFS.
- **Obnova smazaných souborů**.
- **Bezpečné mazání souborů** – LINUX ext[23]fs.
- **Nepřemistitelné soubory** – LINUX ext[23]fs.
- **Soubory, umožňující pouze přidávat data** – append-only.
- **Změna velikosti svazku za běhu** – AIX jfs, Tru64 advfs, ...
- **Kontrolní součty dat** – Sun/Solaris ZFS.

Virtual file system

VFS je vrstva jádra, zajišťující stejný přístup zbytku jádra k různým souborovým systémům. Tato vrstva leží mezi vstupním bodem jádra (obsluha systémových volání) a jednotlivými implementacemi FS.

Původní idea VFS pochází od Sun Microsystems (z důvodů implementace NFS). Dnes je VFS vrstva ve většině systémů.

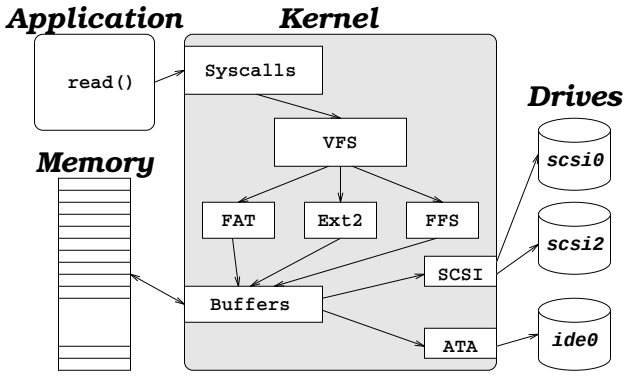

Správa logických svazků

- **Logical Volume Manager (lvm)**
- **Spojení více fyzických zařízení do jednoho**

Struktura

- **Physical volume (pv)** – disk, disková oblast. Skládá se z
- **Physical extent (pe)** – část diskové oblasti, pevná délka (např. 4 MB).
- **Volume group (vg)** – obsahuje několik PV, jejichž PE jsou v ní zpřístupněny jako
- **Logical extent (le)** – odpovídá příslušnému PE.
- **Logical volume (lv)** – odpovídá blokovému zařízení. Skládá se z několika LE v rámci jedné VG. Na LV se vytvoří souborový systém a používá se.

Výhody LVM

- **Změna velikosti VG** – přidání/odebrání několika PV.
- **Změna velikosti LV** – přidání/odebrání několika LE. Musí navazovat změna velikosti souborového systému.
- **Odebrání PV** – transparentní.
- **Klon LV** – atomický snímek, nezabírá mnoho místa, copy-on-write.

Komunikace mezi procesy

Nepojmenovaná roura

- Zasílání dat mezi příbuznými procesy.
- Implementace – kruhový buffer velikosti `PIPE_BUF`.

`pipe(2)` . . . . . Vytvoření roury

```
#include <unistd.h>
int pipe(int fd[2]);
```

Vrátí dva deskriptory – `fd[0]` pro čtení a `fd[1]` pro zápis. Využití: Proces otevře rouru pomocí `pipe(2)` a pak vytvoří potomka pomocí `fork(2)`. Roura je využívána ke komunikaci mezi rodičem a potomkem.

Pojmenovaná roura

- **Vznik** – službou jádra `mknod(2)`.
- **Otevření** – služba `open(2)` s příslušnou cestou.
- **Vlastnosti** – stejné jako u nepojmenované roury.
- Pomocí pojmenované roury mohou spolu komunikovat i nesouvisející procesy.

Vlastnosti roury

- Zápis až do velikosti `PIPE_BUF` je atomický.
- Otevření (pojmenované) roury pro zápis se zablokuje do doby, než některý jiný proces otevře rouru pro čtení.
- Čtení z roury vrátí konec souboru (služba `read(2)` vrátí nulu), pokud žádný proces nemá otevřený zápisový konec roury a v bufferu nejsou žádná data.
- Zápis do roury způsobí zaslání `SIGPIPE`, nemá-li žádný proces rouru otevřenou pro čtení.

◇ **Příklad:** Použití roury:

```
#include <unistd.h>
...
int r, fd[2];
int buf[PIPE_BUF];
...
if (pipe(fd)==-1) {
    perror("pipe()");
    exit(1);
}
```



```
switch(fork()) {
case -1:
    perror("fork()");
    exit(1);
case 0: /* Potomek */
    close(fd[0]);
    write(fd[1],"Manipulační svěrka\n", 19);
    exit(0);
default: /* Rodič */
    close(fd[1]);
    while((r=read(fd[0], buf, PIPE_BUF))>0)
        write(1, buf, r);
    wait(NULL);
    exit(0);
}
```


Signály

- Asynchronní událost.
- Akce při vzniku signálu – ignorovat, zachytit ovladačem (*handler*), implicitní akce.

`signal(2)` . . . . . Nastavení reakce na signál

```
#include <signal.h>
void (*signal(int sig, void (*hndlr)(int)))(int);
```

nebo také jinak:

```
typedef void SigHandler(int);
SigHandler *signal(int sig, SigHandler *hndlr);
```

Nainstaluje ovladač signálu, vrátí jeho předešlou hodnotu. Hodnoty parametru `hndlr`:

`SIG_IGN` – ignorovat signál.
`SIG_DFL` – nastavit implicitní hodnotu.
`funkce` – nastaví se jako ovladač signálu. V okamžiku vyvolání signálu dostane funkce jako parametr číslo signálu.

`kill(2)`, `raise(2)` . . . . . Zaslání signálu

```
#include <sys/types.h>
#include <signal.h>
int kill(pid_t pid, int signo);
int raise(int signo);
```

Činnost služby `kill(2)` závisí na hodnotě `pid` takto:

`pid > 0` Signál je zaslán procesu s číslem `pid`.
`pid == 0` Signál je zaslán procesům ze stejné skupiny, jako je volající proces.
`pid < 0` Signál je zaslán procesům ze skupiny, jejíž číslo je rovno absolutní hodnotě `pid`.
`pid == -1` POSIX.1 zde ponechává nespecifikovaný výsledek.

Pokud je číslo signálu 0, vrátí `kill(2)` hodnotu -1 a `errno` bude mít hodnotu `ESRCH`, pokud proces daného `pid` neexistuje. Pokud existuje, je vrácena nula nebo `errno` nastaveno na `EPERM`.

Funkce `raise(3)` je součástí ANSI C – v UNIXu způsobí zaslání signálu stejnému procesu.

Tabulka signálů

A – ANSI C
P – POSIX.1
J – POSIX.1, systém podporuje job control
S – System V Release 4
B – 4.3BSD

Jméno	Popis	Norma	Akce
SIGABRT	Abnormální ukončení	APSB	core
SIGALRM	Časovač	PSB	ukončení
SIGBUS	Hardwarová chyba	SB	core
SIGCHLD	Změna stavu potomka	JSB	ignorování
SIGCONT	Pokračování po `STOP`	JSB	znovuspuštění
SIGEMT	Hardwarová chyba	SB	core
SIGFPE	Chyba reálné aritmetiky	APSB	core
SIGHUP	Zavěšení linky	PSB	ukončení
SIGILL	Neplatná instrukce	APSB	core
SIGINFO	Získání stavu z terminálu	B	ignorování
SIGINT	Přerušení z terminálu	APSB	ukončení
SIGIO	Asynchronní I/O	SB	core
SIGIOT	Hardwarová chyba	SB	core

SIGKILL	Ukončení procesu	PSB	ukončení
SIGPIPE	Rouru nikdo nečte	PSB	ukončení
SIGPOLL	Sledovatelná událost	S	ukončení
SIGPROF	Profilovací časovač	SB	ukončení
SIGPWR	Výpadek napájení	S	ignorování
SIGQUIT	Znak `Quit` na terminálu	PSB	core
SIGSEGV	Chyba segmentace	APSB	core
SIGSTOP	Pozastavení procesu	JSB	pozastavení
SIGSYS	Neplatná služba jádra	SB	core
SIGTERM	Výzva k ukončení	APSB	ukončení
SIGTRAP	Hardwarová chyba	SB	core
SIGTSTP	Znak `Stop` na terminálu	JSB	pozastavení
SIGTTIN	Pokus o čtení z terminálu	JSB	pozastavení
SIGTTOU	Pokus o zápis na terminál	JSB	pozastavení
SIGURG	Urgentní událost	SB	ignorování
SIGUSR1	Uživatelský signál 1	PSB	ukončení
SIGUSR2	Uživatelský signál 2	PSB	ukončení
SIGVTALRM	Virtuální časovač	SB	ukončení
SIGWINCH	Změna velikosti okna	SB	ignorování
SIGXCPU	Překročení strojového času	SB	core
SIGXFSZ	Překročení velikosti souboru	SB	core

pause(2) . . . . . Čekání na signál

```
#include <unistd.h>
int pause();
```

Čeká na příchod signálu, který není ignorován. Služba vrací vždy hodnotu -1.

◇ **Úkol:** Zjistěte, jakou hodnotu `errno` nastavuje služba jádra `pause(2)`.

Vlastnosti signálů

- **Z hlediska procesu** – signál je v podstatě vnější (obvykle asynchronní) přerušení.
- **Z hlediska CPU** – zasílaný signál neodpovídá žádnému přerušení, některé generované signály odpovídají interním přerušením (exception) CPU.
- **Nejsou atomické operace** – příchod signálu mezi instalací ovladače a službou `pause(2)`.
- **Nespolehlivost** – více vygenerovaných signálů může být doručeno jako jeden signál.

Spolehlivé signály

- **Nová sémantika**
- **Vygenerování signálu** – v okamžiku volání `kill(2)`, vypršení časovače, chybě segmentace a podobně.
- **Doručení signálu** (*delivery*) – okamžik, kdy se vykoná reakce na signál podle stavu procesu.
- **Čekající signál** (*pending*) – stav signálu mezi vygenerováním a doručením.
- **Blokování signálu** – proces má možnost dočasně odložit doručení signálu. Zablokovaný signál zůstává ve stavu *pending* dokud proces nezruší blokování nebo dokud nenastaví reakci na signál na ignorování signálu.
- **Signál vygenerován vícekrát** – v původním rozhraní se mohl doručit jednou nebo vícekrát. Novější systémy mohou mít více čekajících signálů stejného čísla. Signály *čekají ve frontě* (*queued signals*).
- **Restartování služeb jádra** – systém umí po příchodu signálu restartovat některé služby jádra místo toho, aby vrátily chybu a `EINTR`.

Množiny signálů

- **Množina signálů** – nový datový typ. Slouží ke změně reakcí na více signálů jednou (atomickou) službou jádra.
- **Operace nad množinou** – funkce/makra `sigemptyset(3)`, `sigfillset(3)`, `sigaddset(3)`, `sigdelset(3)` a `sigismember(3)`.

sigsetops(3) . . . . . Operace nad množinou signálů

```
#include <signal.h>
int sigemptyset(sigset_t *set);
int sigfillset(sigset_t *set);
int sigaddset(sigset_t *set, int signo);
int sigdelset(sigset_t *set, int signo);
int sigismember(sigset_t *set, int signo);
```


sigprocmask(2) . . . . . Blokování signálů

```
#include <signal.h>
int sigprocmask(int how, sigset_t *set,
    sigset_t *old);
```

Je-li `old` nenulový ukazatel, uloží se sem původní množina blokovaných signálů. Je-li `set` nenulový ukazatel, změní se maska blokovaných signálů podle hodnoty parametru `how`:

SIG_BLOCK – nová množina je sjednocením původní množiny a `set`.

SIG_UNBLOCK – nová množina je průnikem původní množiny a doplňku `set`.

SIG_SETMASK – nová množina je rovna `set`.

Čeká-li na proces nějaký signál, který je odblokovaný voláním `sigprocmask(2)`, je aspoň jeden takový signál doručen před návratem ze `sigprocmask(2)`.

sigpending(2) . . . . . Dotaz na čekající signály

```
#include <signal.h>
int sigpending(sigset_t *set);
```

Do množiny `set` uloží signály, které v daném okamžiku čekají na doručení.

sigsuspend(2) . . . . . Čekání na signál

```
#include <signal.h>
int sigsuspend(sigset_t *set);
```

Dočasně nahradí masku blokovaných signálů za `set` a zablokuje proces, dokud jeden z těchto signálů nepřijde.

sigaction(2) . . . . . Změna reakce na signál

```
#include <signal.h>
int sigaction(int signum, struct sigaction
    *act, struct sigaction *old);
struct sigaction {
    void (*sa_handler)(int);
    sigset_t sa_mask;
    int sa_flags;
}
```

Je-li `act` nenulový ukazatel, změní podle něj reakci na signál. Původní reakce je uložena do `old`, je-li toto nenulový ukazatel.

sa_handler specifikuje reakci na signál. Může být `SIG_IGN` pro ignorování signálu, `SIG_DFL` pro implicitní hodnotu nebo ukazatel na funkci pro obsluhu signálu.

sa_mask specifikuje masku signálů, které mají být zablokovány během provádění obslužné funkce `sa_handler` pro daný signál. Navíc signál sám je blokován během provádění svého ovladače, pokud není nastaven flag `SA_NODEFER` nebo `SA_NOMASK`.

sa_flags dále nastavuje vlastnosti reakce na signál. Jeho hodnota je log. součet některých z následujících konstant:

SA_NOCLDSTOP – pokud je `signum` rovno `SIGCHLD`, proces nedostane tento signál při pozastavení potomka, ale jen při jeho ukončení.

SA_ONESHOT nebo **SA_RESETHAND** – po prvním vyvolání ovladače nastaví reakci zpět na `SIG_DFL` (stejně se chová ovladač instalovaný pomocí `signal(2)`).

SA_ONSTACK – byl-li nastaven alternativní zásobník pro provádění signálů (pomocí `sigaltstack(2)`), použije se pro tento ovladač tento alternativní zásobník.

SA_NOCLDWAIT – je-li `signum` rovno `SIGCHLD`, proces nečeká na potomky a potomci nevytvářejí zombie.

SA_NODEFER nebo **SA_NOMASK** – během provádění ovladače není zablokováno doručení stejného signálu.

SA_RESTART – restartuj případnou přerušitelnou službu jádra, je-li přerušena tímto signálem (namísto chyby `EINTR`).

I/O multiplexing

Čtení z jedoho deskriptoru a zápis na druhý:

```
while ((n=read(0, buf, bufsiz))>0)
    if (write(1, buf, n) < 0)
        error_message("write to stdout");
```

- Blokující I/O operace.
- Co když chceme číst ze dvou deskriptorů zároveň?
- Program pro komunikaci s modemem.
- Polling.
- Asynchronní I/O.
- Selektivní čekání.

select – BSD interface.
poll – SysV interface.

select(2) . . . . . Selektivní čekání

```
#include <sys/time.h>
#include <sys/types.h>
#include <unistd,h>
struct timeval {
    long tv_sec; /* sekundy */
    long tv_usec; /* mikrosekundy */
};
FD_CLR(int fd, fd_set *set);
FD_SET(int fd, fd_set *set);
FD_ISSET(int fd, fd_set *set);
FD_ZERO(fd_set *set);
int select(int n, fd_set *rdset, fd_set *wrset,
     fd_set *exset, struct timeval *timeout);
```

Čekání na připravenost ke čtení, připravenost k zápisu, případně výjimku na deskriptoru. Parametr `n` je 1 + nejvyšší číslo deskriptoru, nastavené v kterékoli ze tří množin.

Vrací počet deskriptorů, na kterých nastala požadovaná situace. Do příslušných množin nastaví deskriptory, připravené k I/O operaci.

◇ **Příklad:** Použití `select(2)`.

```
static int done=0;
int dualcopy(int ttyfd, int modemfd)
{
    fd_set rfds, wfds, xfds;
    char mbuffer[BUFSIZE], tbuffer[BUFSIZE];
    char *mptr, *tptr;
    int mlen=0, tlen=0;
    int nfds, i;

    int maxfd=1+(ttyfd>modemfd?ttyfd:modemfd);
    while(!done) {
        FD_ZERO(&rfds);
        FD_ZERO(&wfds);
        FD_ZERO(&xfds);
        FD_SET(modemfd, &xfds);
        FD_SET(ttyfd, &xfds);
        if (mlen) FD_SET(ttyfd, &wfds);
            else FD_SET(modemfd, &rfds);
```



```
        if (tlen) FD_SET(modemfd, &wfds);
            else FD_SET(ttyfd, &rfds);
        nfds = select(maxfd, &rfds, &wfds,
            &xfds, NULL);
        if (nfds == -1)
            switch(errno) {
            case EBADF:
                printf("invalid fd!\n");
                return -1;
            case EINTR:
                /* Dostali jsme signál. */
                continue;
            case ENOMEM:
                printf("not enough memory!\n");
                return -2;
            case EINVAL:
                printf("Internal error!\n");
                return -3;
```



```
            default:
                printf("Invalid errno=%d\n",
                    errno);
                return -4;
            }
        if (nfds == 0)
            /* Toto se stane jen při timeoutu. */
            contintue;
        if (FD_ISSET(ttyfd, &xfds)) {
            printf("Exception on tty\n");
            return 0;
        }
        if (FD_ISSET(modemfd, &xfds)) {
            printf("Exception on modem\n");
            return 0;
        }
```

```
            if (FD_ISSET(ttyfd, &rfds)) {
                tlen=read(ttyfd, tbuffer, BUFSIZE);
                tptr=tbuffer;
            }
            if (FD_ISSET(modemfd, &rfds)) {
                mlen=read(modemfd, mbuffer, BUFSIZE);
                mptr=mbuffer;
            }
            if (FD_ISSET(ttyfd, &wfds)) {
                i=write(ttyfd, mptr, mlen);
                mptr+=i; mlen-=i;
            }
            if (FD_ISSET(modemfd, &wfds)) {
                i=write(modemfd, tptr, tlen);
                tptr+=i; tlen-=i;
            }
        }
        /* NOTREACHED */ return 0;
    }
```



```
#include <stropts.h>
#include <poll.h>
int poll(struct pollfd fdarray[],
    unsigned long nfds, int timeout);
struct pollfd {
    int fd;
    short events;
    short revents;
};
```

Vezme seznam deskriptorů a zjistí, jestli nastala některá z událostí `events`. Pokud ano, nastaví příslušný bit v `revents`. Pokud ne, čeká na příchod události minimálně po `timeout` milisekund. Je-li `timeout` rovno -1, čeká neomezeně dlouho na příchod události nebo na příchod signálu. `poll(2)` není ovlivněno flagy `O_NDELAY` nebo `O_NONBLOCK` na deskriptoru.

Návratová hodnota -1 značí chybu, 0 znamená vypršení časového limitu, kladná hodnota značí počet deskriptorů, u nichž služba nastavila nenulovou hodnotu `revents`.

Parametr `events` a `revents` je logický součet některých z následujících hodnot:

POLLIN – data jiné než vysoké priority mohou být čtena bez blokování.

POLLRDNORM – data normální priority (priorita 0) mohou být čtena bez blokování.

POLLRDBAND – data nenulové priority mohou být čtena bez blokování.

POLLPRI – data s vysokou prioritou mohou být čtena bez blokování.

POLLOUT – data normální priority mohou být zapsána bez blokování.

POLLWRNORM – totéž jako `POLLOUT`.

POLLWRBAND – data s vysokou prioritou (> 0) mohou být zapsána bez blokování.

Následující typy událostí jsou v `revents` vraceny vždy bez ohledu na nastavení v `events`:

POLLERR – došlo k chybě na příslušném deskriptoru.

POLLHUP – došlo k zavěšení linky.

POLLNVAL – deskriptor tohoto čísla není otevřen.

Pokročilé I/O operace

Zamykání souborů

- **Zamykání pro čtení nebo pro zápis** – zámek pro čtení znamená, že selže pokus o vytvoření zámku pro zápis, ale ne dalšího zámku pro čtení. Zámek pro zápis je jednoznačný v celém systému.
- **Nepovinné a povinné zamykání** – *advisory/mandatory locking*. Nepovinné – jen vzhledem k dalším zámkům; povinné – i vzhledem k I/O operacím. Povinné jen v SVR3 a SVR4 (plus některé další, např. Linux). Povinné – s-gid bit na souboru, který není přístupný pro provádění pro skupinu. POSIX.1 – jen nepovinné.
- **Metody zamykání** – `fcntl(2)` (POSIX.1, SysV, 4.4BSD), `lockf(2)` (SysV), `flock(2)` (BSD).

- Zámek souvisí s procesem a se souborem (struktura `inode`). Pokud proces skončí, jsou jeho zámky zrušeny. Pokud se uzavře soubor, jsou také zámky zrušeny.
- Zámek se nedědí na potomky při `fork(2)`.
- Zámek přetrvá přes volání `exec(2)`.

◇ **Úkol:** Zjistěte, jak se chovají zámky při duplikování deskriptoru pomocí `dup(2)`, a při uzavření některého z takto získaných deskriptorů.

Zamykání přes `fcntl(2)`

```
#include <sys/types.h>
#include <unistd.h>
#include <fcntl.h>
int fcntl(int fd, int cmd, long arg);
struct flock {
    short l_type;
    off_t l_start;
    short l_whence;
    off_t l_len;
    pid_t l_pid;
};
```

Jako `cmd` se uvede jedna z hodnot `F_GETLK`, `F_SETLK` nebo `F_SETLKW`, `arg` je ukazatel na strukturu `flock`. Položky struktury `flock` mají tento význam:

l_type – jedno z `F_RDLCK` (zámek pro čtení), `F_WRLCK` (zámek pro zápis) nebo `F_UNLCK` (pro zrušení zámku).

l_start – offset prvního bajtu zamykaného regionu.

l_whence – jedno z `SEEK_SET`, `SEEK_CUR` nebo `SEEK_END` (viz `lseek(2)`).

l_len – délka zamykaného regionu. Je-li nulové, značí zámek od `l_start` do konce souboru.

l_pid – PID procesu, který drží zámek (vrací `F_GETLK`).

Jednotlivé příkazy fungují takto:

F_GETLK – zjistí, jestli je vytvoření zámku blokováno nějakým jiným zámkem. Pokud takový zámek existuje, je struktura `flock` naplněna popisem tohoto zámku. Pokud neexistuje, je `l_type` změněno na `F_UNLCK`.

F_SETLK – nastaví nebo zruší zámek. Není-li možno zámek vytvořit, vrátí -1 s `errno` rovno `EACS` nebo `EAGAIN`.

F_SETLKW – blokující verze `F_SETLK`. Pokusí se nastavit zámek. Pokud to není možné, zablokuje se do doby, než bude možné zámek vytvořit nebo než přijde signál.

Scatter-gather I/O

- **Čtení do nesouvislého datového prostoru**
- **Zápis z nesouvislého datového prostoru**
- **Jedna služba jádra** – ušetří se přepnutí do jádra a zpět (nebo kopírování dat do souvislého bufferu).
- **Moderní hardware** – umí scatter/gather přímo.

readv(2) . . . . . scatter read

```
#include <sys/types.h>
#include <sys/uio.h>
ssize_t readv(int fd, struct iovec iov[],
    int iovcount);
struct iovec {
    void *iov_base;
    size_t iov_len;
};
```

Přečte ze vstupního deskriptoru data do bufferů popsaných v poli struktur `iovec`. Vrací celkový počet přečtených bajtů.

writev(2) . . . . . gather write

```
#include <sys/types.h>
#include <sys/uio.h>
ssize_t writev(int fd, struct iovec iov[],
    int iovcount);
```

Zapíše na výstupní deskriptor obsah bufferů popsaných v poli `iov[]`. Vrací celkový počet zapsaných bajtů.

Memory-mapped I/O

- **Mapování (části) souboru do paměti**
- **Sdílená paměť mezi programy**
- **Urychlení I/O** – ušetří se kopírování dat.
- **Alokace paměti** – namapování `/dev/zero`.
- **Nevýhoda** – zneplatnění TLB při změně mapování.

mmap(2) . . . . . Mapování souboru do paměti

```
#include <unistd.h>
#include <sys/mman.h>
#ifdef _POSIX_MAPPED_FILES
void *mmap(void *start, size_t length,
    int prot, int flags, int fd,
    off_t offset);
int munmap(void *start, size_t length);
#endif
```

Služba `mmap(2)` je součástí POSIX.4 (1b). Požádá systém o namapování `length` bajtů ze souboru `fd` od offsetu `offset` dále do paměti s tím, že systém se bude snažit tento blok dat namapovat do paměti na adresu `start`. Tento údaj je ale brán pouze jako doporučení; systém může namapovat soubor i jinam. Parametr `prot` určuje přístupová práva k nově mapovaným stránkám. Může být logický součet několika následujících hodnot:

PROT_EXEC – stránky mohou být prováděny.
PROT_READ – stránky jsou přístupné pro čtení.
PROT_WRITE – do stránek lze zapisovat.
PROT_NONE – ke stránkám nelze přistupovat.

Parametr `flags` specifikuje typ mapovaného objektu a to, jestli se jeho modifikace mají projevit i navenek nebo mají být považovány za soukromé. Hodnota je logický součet některých z následujících konstant:

MAP_FIXED – zakazuje jádru zvolit jinou adresu pro mapování než `start`. Parametr `start` pak musí být zarovnán na velikost stránky (viz `sysconf(2)`). Používání této volby se nedoporučuje z důvodu přenositelnosti.
MAP_SHARED – zápis do mapované oblasti se projeví v namapovaném souboru i v paměti dalších procesů, které si tento úsek souboru namapovaly.
MAP_PRIVATE – mapovaná oblast je copy-on-write kopií obsahu mapovaného souboru. Změny provedené procesem se neprojeví jinde.

Služba `mmap(2)` vrací v případě úspěchu ukazatel na první bajt namapovaného regionu.

Služba `munmap(2)` odmapuje příslušnou část mapovaného regionu. Další přístup k odmapované části je ilegální (způsobí zaslání signálu `SIGBUS` nebo `SIGSEGV`).

msync(2) . . . . . Synchronizace regionu

```
#include <unistd.h>
#include <sys/mman.h>
#ifdef _POSIX_MAPPED_FILES
#ifdef _POSIX_SYNCHRONIZED_IO
int msync(const void *start, size_t length,
    int flags);
#endif
#endif
```

Tato služba uloží změny v namapovaném souboru zpět na disk. Uložení změn se týká paměti od adresy `start` velikosti `length`. Parametr `flags` může být log. součet následujících:

MS_SYNC – služba počká na dokončení zápisu na disk.
MS_ASYNC – služba nastartuje zápis, ale skončí bez čekání na dokončení diskových operací.
MS_INVALIDATE – zruší platnost namapovaných stránek tohoto souboru, takže stránky jsou případně znovu načteny z diskové kopie.

Právě jedno z `MS_SYNC` a `MS_ASYNC` musí být nastaveno.

mprotect(2) . . . . . Nastavení přístupu k regionu

```
#include <sys/mman.h>
int mprotect(const void *addr, size_t len,
    int prot);
```

Nastavuje přístupová práva pro oblast paměti od adresy `addr` velikosti `len`. Přístupová práva se nastaví parametrem `prot` jako log. součet jedné nebo více hodnot z `PROT_NONE`, `PROT_READ`, `PROT_WRITE` a `PROT_EXEC` s významem stejným jako u `mmap(2)`. Stará hodnota přístupových práv nemá vliv na nový stav. Parametr `addr` musí být zarovnán na velikost stránky. POSIX.4 (1b) říká, že `mprotect(2)` může být použito pouze na regiony získané pomocí `mmap(2)`.

mlock(2), munlock(2) . . . . . Zákaz stránkování v regionu

```
#include <sys/mman.h>
int mlock(const void *addr, size_t len);
int munlock(const void *addr, size_t len);
```

Zakáže/povolí stránkování v daném rozsahu operační paměti. Stránkování na odkládací prostor je zakázáno do doby, než proces skončí nebo změní dané nastavení. Toto nastavení se nedědí přes `fork(2)` a `exec(2)`.

Využití – real-time aplikace, kryptografické aplikace.

mlockall(2), munlockall(2) . Zamčení celého adresního prostoru

```
#include <sys/mman.h>
int mlockall(int flags);
int munlockall();
```

Zamče všechny stránky paměti procesu. Stránky nejsou odkládány na odkládací zařízení. `flags` je logický součet některých z následujcích konstant:

MCL_CURRENT – zamče všechny stránky, které jsou momentálně namapovány v paměti procesu.

MCL_FUTURE – regiony, mapované v budoucnu, budou zamčeny. Pokud dojde k překročení limitu, další pokus o mapování vrátí `ENOMEM`. V případě neúspěšného pokusu o zvětšení zásobníku proces dostane `SIGSEGV`.

Vícenásobné zamčení téže stránky se zvlášť nepočítá. K odemčení stačí jediné `munlockall(2)` nebo `munlock(2)`.

◇ **Úkol:** Jak předalokovat dostatečně velký prostor na zásobníku?

Vícevláknové aplikace

- **Vlákno** – thread – *light-weight process*.
- **Kontext činnosti procesoru** – podobně jako procesy.
- **Vlákno versus proces** – vlákna (jednoho procesu) běží nad stejnou VM, mají stejné deskriptory a další věci.
- **Proč vlákna** – využití více procesorů.
- **Kdy ne vlákna** – tam kde lze použít událostně řízené programování (GUI aplikace) nebo samostatné procesy (síťové servery). John Ousterhout: Why Threads Are A Bad Idea (for most purposes).
- **Vlákna v UNIXu** – IEEE POSIX 1003.1c (POSIX threads).

Kontexty jádra versus vlákna

- **1:N** (user-level threads) – například balík `pthreads`.
- **1:1** (kernel-level threads) – `LinuxThreads` a `NPTL`.
- **M:N** – kombinace obojího – např. scheduler activations ve FreeBSD; IRIX.

pthread_create(3) . . . . . . Vytvoření vlákna

```
#include <pthread.h>
int pthread_create(pthread_t *thread,
      pthread_attr_t *attr,
      void (*start_routine)(void *), void *arg);
```

Vytvoření vlákna. Identifikace vlákna je uložena do `thread`. Parametr `attr` určuje další vlastnosti vlákna. Nastavuje se následujícími funkcemi: `pthread_attr_init(3)`, `pthread_attr_destroy(3)`, `pthread_attr_setdetachstate(3)`, `pthread_attr_setschedparam(3)` a další.

pthread_exit(3) . . . . . . Ukončení vlákna

```
void pthread_exit(void *retval);
```

Ukončí vlákno, zavolá registrované funkce pro dobu ukončení a uvolní lokální data vlákna. Viz též `pthread_cleanup_push(3)` a další funkce `pthread_cleanup_*(3)`.

pthread_join(3) . . . . . . Čekání na ukončení vlákna

```
int pthread_join(pthread_t tid, void **retval);
```


Synchronizace vláken

- **Mutex** – vzájemné vyloučení vláken.
- **Stavy** – odemčený zámek/zamčený zámek.
- **Vzájemné vyloučení** – v jednu chvíli může držet zámek zamčený nejvýše jedno vlákno.

```
pthread_mutex_t fmutex =
     PTHREAD_MUTEX_INITIALIZER;
pthread_mutex_t rmutex =
     PTHREAD_RECURSIVE_MUTEX_INITIALIZER_NP;
pthread_mutex_t emutex =
     PTHREAD_ERRORCHECK_MUTEX_INITIALIZER_NP;

inr pthread_mutex_lock(pthread_mutex_t *mutex);
inr pthread_mutex_trylock(pthread_mutex_t *mutex);
inr pthread_mutex_unlock(pthread_mutex_t *mutex);
inr pthread_mutex_destroy(pthread_mutex_t *mutex);
```


Podmínkové proměnné

- **Podmínková proměnná** – hlášení o události jinému vláknu.
- **Strany komunikace** – vlákno čeká na podmínku, vlákno signalizuje podmínku.

```
pthread_cond_t cond = PTHREAD_COND_INITIALZIER;
int pthread_cond_wait(pthread_cond_t *cond,
       pthread_mutex_t *mutex);
int pthread_cond_timedwait(pthread_cond_t *cond,
       pthread_mutex_t *mutex,
       struct timespec *abstime);
int pthread_cond_signal(pthread_cond_t *cond);
int pthread_cond_broadcast(pthread_cond_t *cond);
int pthread_cond_destroy(pthread_cond_t *cond);
```

- **Čekání na podmínku** – atomické odemčení mutexu a zablokování vlákna. Mutex musí být předem zamčený. Při ukončování funkce se mutex opět zamče.

Soukromá data vlákna

- **Globální proměnná** – ale v každém vlákně s jinou hodnotou.
- **Důvod použití** – není nutno předávat jako argument od všech funkcí.
- **Klíč** – konkrétní kus dat, v každém vlákně s jinou hodnotou.
- **Destruktor** – při ukončení vlákna se volá pro jeho nenulové klíče.

◇ **Příklad:**

```
pthread_key_t list_key;
extern void* cleanup_list(void*);
pthread_key_create(&list_key, cleanup_list);

int* p_num = (int*)malloc(sizeof(int));
(*p_num) = 4; /* Nejaka hodnota */
pthread_setspecific(list_key, (void*)p_num);

/* Nekde uplne jinde */
int* p_keyval = (int*)pthread_getspecific(list_key);

/* a nakonec */
pthread_key_delete(list_key);
```

Vlákna – další vlastnosti

- **Zrušení vlákna** – `pthread_cancel(3)`. Vlákno může být zrušitelné jen v některých bodech.
- **Odpojení vlákna** – `pthread_detach(3)`. Není pak možno/nutno vlákno připojovat přes `pthread_join(3)`.
- **Jednorázová inicializace** – `pthread_once(3)`. Zavolání pouze při prvním použití.
- **Identifikace vlákna** – `pthread_self(3)`.

Signály

- **Zaslání signálu** – `pthread_kill(3)`.
- **Cekání na signál** – `sigwait(3)`.
- **Synchronní signál** – doručen vláknu které signál vygenerovalo.
- **Asynchronní signál** – doručen některému vláknu, které signál neblokuje.
- **Maska blokovaných signálů** – pro každé vlákno zvlášť – viz `pthread_sigmask(3)`.