Programování v UNIXu

(NSWI015)

verze: 24. října 2017

SISAL MFF UK, Malostranské nám. 25, 118 00 Praha 1

Obsah

- úvod, vývoj UNIXu a C, programátorské nástroje
- základní pojmy a konvence UNIXu a jeho API
- přístupová práva, periferní zařízení, systém souborů
- manipulace s procesy, spouštění programů
- signály
- synchronizace a komunikace procesů
- síťová komunikace
- vlákna, synchronizace vláken
- ??? - bude definováno později, podle toho kolik zbyde času

Obsah

- **úvod, vývoj UNIXu a C, programátorské nástroje**
- základní pojmy a konvence UNIXu a jeho API
- přístupová práva, periferní zařízení, systém souborů
- manipulace s procesy, spouštění programů
- signály
- synchronizace a komunikace procesů
- síťová komunikace
- vlákna, synchronizace vláken
- ??? - bude definováno později, podle toho kolik zbyde času

Literatura v češtině

1. Skočovský, L.: **Principy a problémy operačního systému UNIX**. Science, 1993
2. Skočovský, Luděk: **UNIX, POSIX, Plan9**. L. Skočovský, Brno, 1998
3. Jelen, Milan: **UNIX V - programování v systému**. Grada, Praha 1993
4. **Linux - Dokumentační projekt**. Computer Press, 1998; http://www.cpress.cz/knihy/linux
5. Herout, Pavel: **Učebnice jazyka C**. 2 díly. Kopp, České Budějovice, 2004 (4., respektive 2. přepracované vydání)

Literatura - design a principy systému

1. Uresh Vahalia: **UNIX Internals: The New Frontiers**. Prentice Hall; 1st edition, 1995
2. Bach, Maurice J.: **The Design of the UNIX Operating System**. Prentice Hall, 1986
3. McKusick, M. K., Neville-Neil, G. V.: **The Design and Implementation of the FreeBSD Operating System**. Addison-Wesley, 2004
4. McDougall, R.; Mauro, J.: **Solaris Internals**. Prentice Hall; 2nd edition, 2006.
5. **Linux Documentation Project**. http://tldp.org/

Literatura - programování

1. Stevens, W. R., Rago, S. A.: **Advanced Programming in UNIX(r) Environment**. Addison-Wesley, 2nd edition, 2005.
2. Rochkind, M. J.: **Advanced UNIX Programming**, Addison-Wesley; 2nd edition, 2004
3. Stevens, W. R., Fenner B., Rudoff, A. M.: **UNIX Network Programming, Vol. 1 – The Sockets Networking API**. Prentice Hall, 3rd edition, 2004
4. Butenhof, D. R.: **Programming with POSIX Threads**, Addison-Wesley; 1st edition, 1997
5. UNIXové specifikace, viz http://www.unix.org
6. manuálové stránky (zejm. sekce 2, 3)

Literatura - historie UNIXu

- Peter Salus: **A Quarter Century of UNIX**, Addison-Wesley; 1st edition (1994)
- Libes D., Ressler, S.: **Life With Unix: A Guide for Everyone**, Prentice Hall (1989)
- **Open Sources: Voices from the Open Source Revolution**, kapitola **Twenty Years of Berkeley Unix From AT&T-Owned to Freely Redistributable**; O'Reilly (1999); on-line na webu: http://oreilly.com/openbook/opensources/book/index.html

... mnoho materiálů na webu; často však obsahující ne zcela přesné informace

(Pre)historie UNIXu

- 1925 – **Bell Telephone Laboratories** – výzkum v komunikacích (např. 1947: transistor) v rámci AT&T
- 1965 – BTL s General Electric a MIT vývoj OS **Multics** (MULTIplexed Information and Computing System)
- 1969 – Bell Labs opouští projekt, **Ken Thompson** píše assembler, základní OS a systém souborů pro PDP-7
- 1970 – Multi-cs $\Rightarrow$ Uni-cs $\Rightarrow$ Uni-x
- 1971 – UNIX V1, a portován na PDP-11
- prosinec 1971 – první edice *UNIX Programmer's Manual*

Historie UNIXu, pokračování

- únor 1973 – UNIX V3 obsahoval *cc* překladač (jazyk C byl vytvořen **Dennisem Ritchiem** pro potřeby UNIXu)
- říjen 1973 – UNIX byl představen veřejnosti článkem *The UNIX Timesharing System* na konferenci ACM
- listopad 1973 – **UNIX V4 přepsán do jazyka C**
- 1975 – UNIX V6 byl první verzí UNIXu běžně k dostání mimo BTL
- 1979 – UNIX V7, pro mnohé "the last true UNIX", obsahoval *uucp*, Bourne shell; velikost kernelu byla pouze 40KB !!!
- 1979 – UNIX V7 portován na 32-bitový VAX-11
- 1980 – Microsoft přichází s XENIXem, který je založený na UNIXu V7

Divergence UNIXu

- pol. 70. let – uvolňování UNIXu na univerzity: především **University of California v Berkeley**
- 1979 – z UNIX/32V (zmíněný port na VAX) poskytnutého do Berkeley se vyvíjí **BSD Unix (Berkeley Software Distribution)** verze 3.0; poslední verze 4.4 v roce 1993
- 1982 **AT&T**, vlastník BTL, může vstoupit na trh počítačů (zakázáno od roku 1956) a přichází s verzí *System III* (1982) až *V.4* (1988) – tzv. *SVR4*
- vznikají UNIX International, OSF (Open Software Foundation), X/OPEN, ...
- 1991 – Linus Torvalds zahájil vývoj OS Linux, verze jádra 1.0 byla dokončena v r. 1994

Současné UNIXy

Hlavní komerční unixové systémy:

- Sun Microsystems: **SunOS** (není již dále vyvíjen), **Solaris**
- Apple: **macOS** (dříve Mac OS X)
- SGI: **IRIX** (není již dále vyvíjen)
- IBM: **AIX**
- HP: **HP-UX**, **Tru64 UNIX** (Compaq)
- SCO: **SCO Unix**
- Xinuos (kdysi Novell): **UNIXware**

Open source:

- **FreeBSD**, **NetBSD**, **OpenBSD**
- **Linux** distribuce

Standardy UNIXu

- **SVID** (System V Interface Definition)
  - „fialová kniha", kterou AT&T vydala poprvé v roce 1985
  - dnes ve verzi SVID3 (odpovídá SVR4)
- **POSIX** (Portable Operating System based on UNIX)
  - série standardů organizace IEEE značená P1003.xx, postupně je přejímá vrcholový nadnárodní orgán ISO
- **XPG** (X/Open Portability Guide)
  - doporučení konsorcia X/Open, které bylo založeno v r. 1984 předními výrobci platforem typu UNIX
- **Single UNIX Specification**
  - standard organizace The Open Group, vzniklé v roce 1996 sloučením X/Open a OSF
  - dnes Version 4 (**SUSv4**)
  - splnění je nutnou podmínkou pro užití obchodního názvu UNIX

POSIX

- tvrzení "tento systém je POSIX kompatibilní" nedává žádnou konkrétní informaci
  - asi podporuje POSIX1990 a možná i něco dalšího (co?)
- dotyčný buď neví co je POSIX nebo si myslí, že to nevíte vy
- jediná rozumná reakce je otázka "jaký POSIX?"
- POSIX je **rodina standardů**
- prvním dokumentem je *IEEE Std POSIX1003.1-1988*, později po vzniku dalších rozšíření neformálně odkazovaný jako POSIX.1
- poslední verze POSIX.1 je *IEEE Std 1003.1, 2004 Edition*
  - obsahuje v sobě již i to, co dříve definoval POSIX.2 (Shell and Utilities) a různá, dříve samostatná rozšíření

Jazyk C

- téměř celý UNIX je napsaný v C, pouze nejnižší strojově závislá část v assembleru ⇒ poměrně snadná přenositelnost
- navrhl Dennis Ritchie z Bell Laboratories v roce 1972.
- následník jazyka B od Kena Thomsona z Bell Laboratories.
- vytvořen jako prostředek pro přenos OS UNIX na jiné počítače – silná vazba na UNIX.
- varianty jazyka:
  - původní K&R C
  - standard ANSI/ISO C
- **úspěch jazyka C daleko přesáhl úspěch samotného UNIXu**

Formáty dat

- pořadí bajtů – závisí na architektuře počítače

  big endian: 0x11223344 =

	11	22	33	44
`addr +`	0	1	2	3

  little endian: 0x11223344 =

	44	33	22	11
`addr +`	0	1	2	3

- řádky textových souborů končí v UNIXu znakem **LF** (nikoliv `CRLF`). Volání `putc('\n')` tedy píše pouze jeden znak.
- big endian – SPARC, MIPS, síťové pořadí bajtů
- little endian – Intel

Deklarace a definice funkce

- K&R
  - deklarace

    ```
    návratový_typ indentifikátor();
    ```

  - definice

    ```
    návratový_typ indentifikátor(par [,par...])
    typ par;...
    { /* tělo funkce */ }
    ```

- ANSI
  - deklarace

    ```
    návratový_typ indentifikátor(typ par [,typ par...]);
    ```

  - definice

    ```
    návratový_typ indentifikátor(typ par [,typ par...])
    { /* tělo funkce */ }
    ```

C style

- věc zdánlivě podřadná, přitom extrémně důležitá – úprava zdrojových kódů programu
- mnoho způsobů jak ano:

```
int
main(void)
{
        char c;
        int i = 0;

        printf("%d\n", i);
        return (0);
}
```

C style (cont.)

- mnoho způsobů jak **NE** (tzv. assembler styl):

```
int main(void) {
int i = 0; char c;
printf("%d\n", i);
return (0);
}
```

- nebo (schizofrenní styl):

```
int main(void) {
        int i = 0; char c;
        if (1)
        printf("%d\n", i);i=2;
return (0);
}
```

Utility

cc, **c99***, **gcc**†	překladač C
CC, **g++**†	překladač C++
ld	spojovací program (linker)
ldd	pro zjistění závislostí dynamického objektu
cxref*	křížové odkazy ve zdrojových textech v C
sccs*, **rcs**,**cvs**	správa verzí zdrojového kódu
make*	řízení překladu podle závislostí
ar*	správa knihoven objektových modulů
dbx, **gdb**†	debuggery
prof, **gprof**†	profilery

* SUSv3 † GNU

Konvence pro jména souborů

`*.c`	jména zdrojových souborů programů v C
`*.cc`	jména zdrojových souborů programů v C++
`*.h`	jména hlavičkových souborů (headerů)
`*.o`	přeložené moduly (object files)
`a.out`	jméno spustitelného souboru (výsledek úspěšné kompilace)

`/usr/include`	kořen stromu systémových headerů
`/usr/lib/lib*.a`	statické knihovny objektových modulů
`/usr/lib/lib*.so`	umístění dynamických sdílených knihoven objektových modulů

Princip překladu

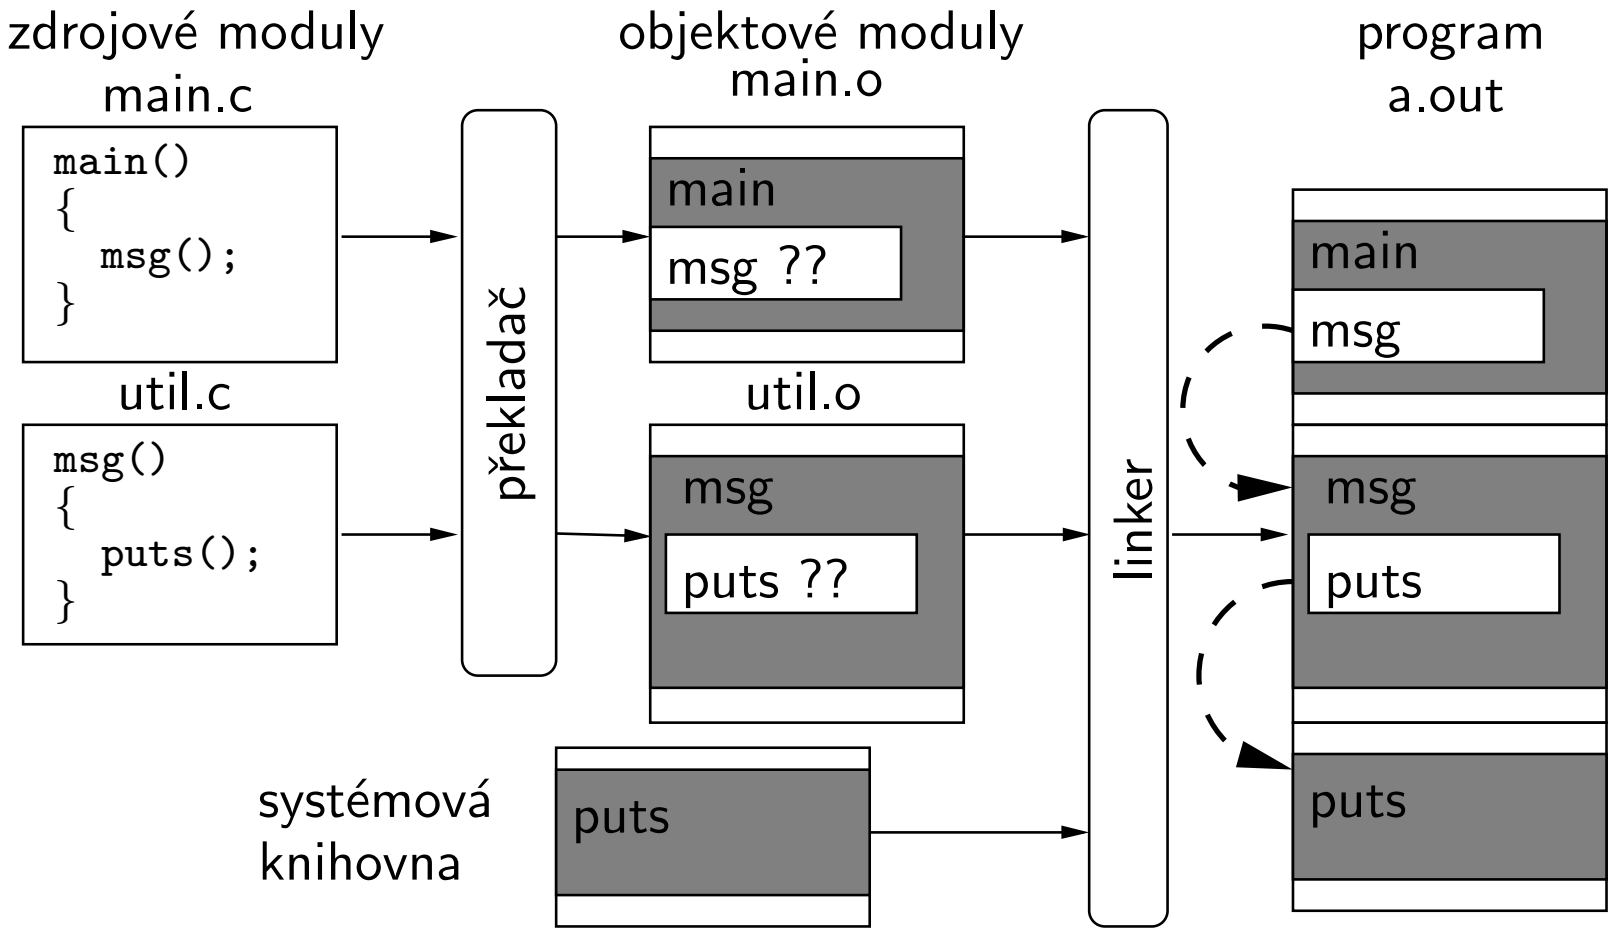

Překlad jednoho modulu (preprocesor)

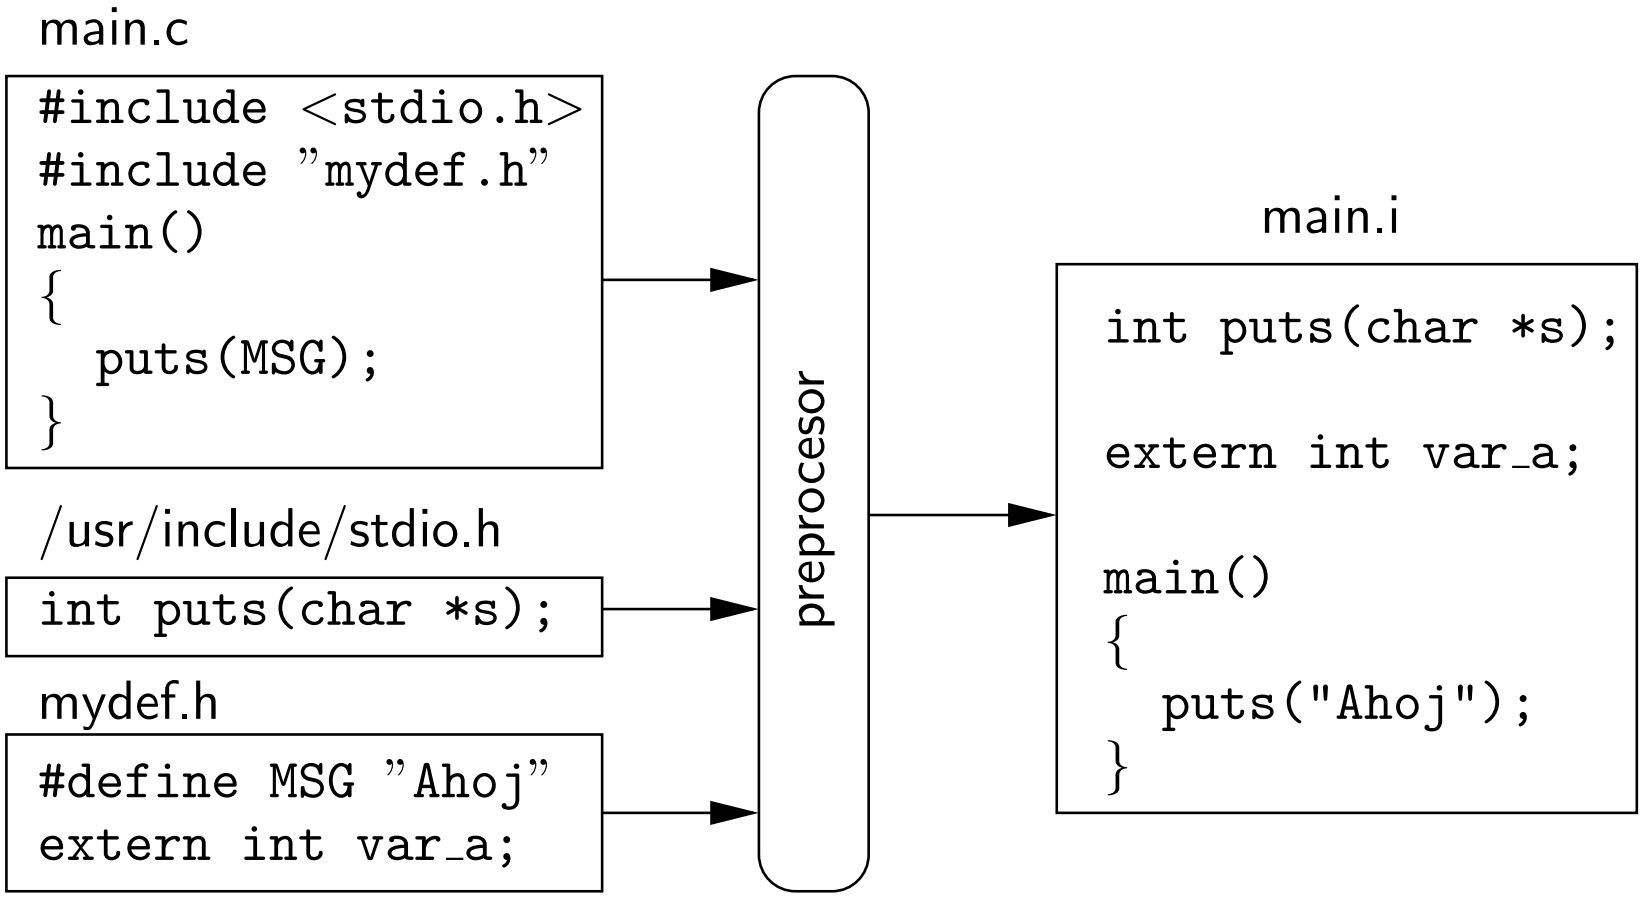

Překlad jednoho modulu (kompilátor)

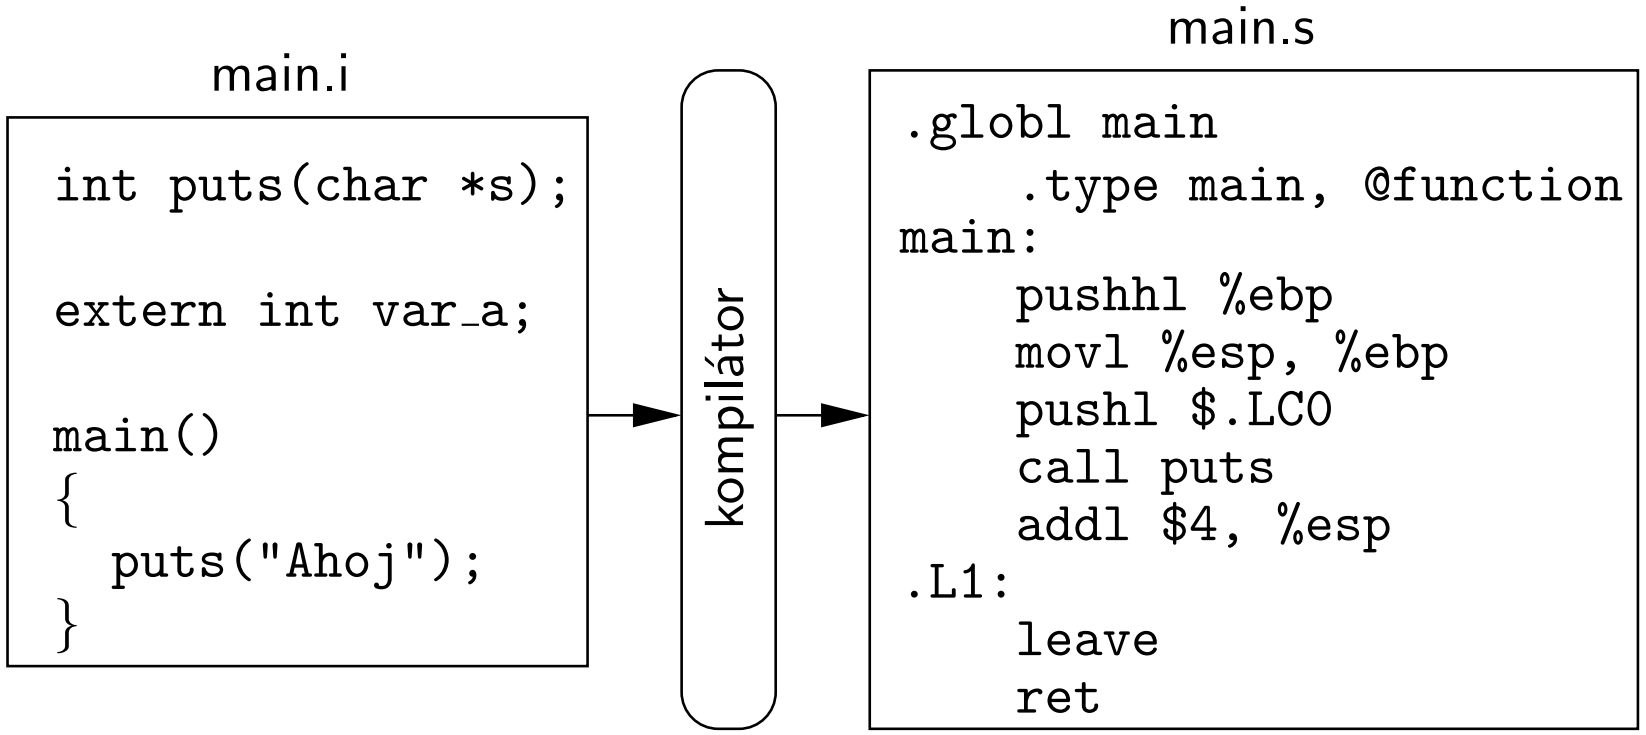

Překlad jednoho modulu (assembler)

main.s

```
.globl main
    .type main, @function
main:
    pushhl %ebp
    movl %esp, %ebp
    pushl $.LC0
    call puts
    addl $4, %esp
.L1:
    leave
    ret
```

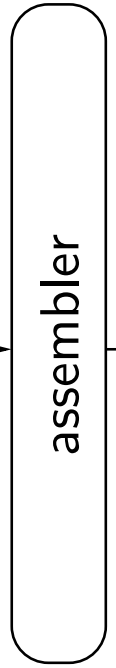

main.o

```
457f 464c 0101 0001
0000 0000 0000 0000
0001 0003 0001 0000
0000 0000 0000 0000
00ec 0000 0000 0000
0034 0000 0000 0028
```

Kompilátor

- volání:

  `cc [`*`options`*`] `*`soubor ...`*

- nejdůležitější přepínače:

`-o` *`soubor`*	jméno výsledného souboru
`-c`	pouze překlad (nelinkovat)
`-E`	pouze preprocesor (nepřekládat)
`-l`	slinkuj s příslušnou knihovnou
`-L`*`jméno`*	přidej adresář pro hledání knihoven z `-l`
`-O`*`level`*	nastavení úrovně optimalizace
`-g`	překlad s ladicími informacemi
`-D`*`jméno`*	definuj makro pro preprocesor
`-I`*`adresář`*	umístění `#include` souborů

Předdefinovaná makra

`__FILE__`, `__LINE__`, `__DATE__`, `__TIME__`, `__cplusplus`, apod.	jsou standardní makra kompilátoru C/C++
`unix`	vždy definováno v Unixu
`mips`, `i386`, `sparc`	hardwarová architektura
`linux`, `sgi`, `sun`, `bsd`	klon operačního systému
`_POSIX_SOURCE`, `_XOPEN_SOURCE`	překlad podle příslušné normy

pro překlad podle určité normy by před prvním `#include` měl být řádek s definicí následujícího makra. Pak načtěte `unistd.h`.

UNIX 98	`#define _XOPEN_SOURCE 500`
SUSv3	`#define _XOPEN_SOURCE 600`
SUSv4	`#define _XOPEN_SOURCE 700`
POSIX1990	`#define _POSIX_SOURCE`

Link editor (linker)

- Volání:

  `ld [`*`options`*`] `*`soubor`*` ...`

  `cc [`*`options`*`] `*`soubor`*` ...`

- Nejdůležitější přepínače:

`-o `*`soubor`*	jméno výsledného souboru (default `a.out`)
`-l`*`lib`*	linkuj s knihovnou `lib`*`lib`*`.so` nebo `lib`*`lib`*`.a`
`-L`*`path`*	cesta pro knihovny (`-l`*`lib`*)
`-shared`	vytvořit sdílenou knihovnu
`-non_shared`	vytvořit statický program

Řízení překladu a linkování (make)

- **zdrojové texty**

main.c

```
#include "util.h"
main()
{
  msg();
}
```

util.h

```
void msg();
```

util.c

```
#include "util.h"
msg()
{
  puts();
}
```

- **závislosti**

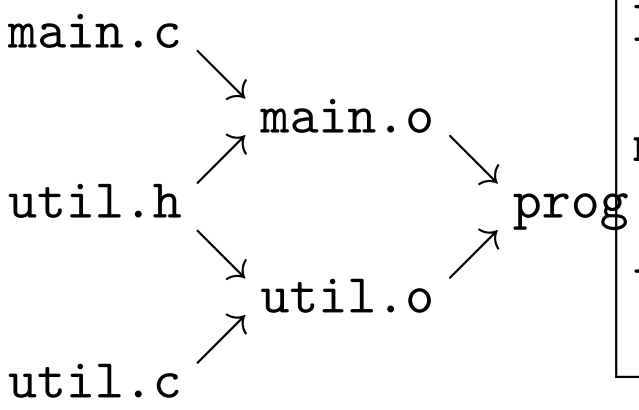

- **soubor** Makefile

```
prog : main.o util.o
        cc -o prog main.o util.o
main.o : main.c util.h
        cc -c main.c
util.o : util.c util.h
        cc -c util.c
```

Syntaxe vstupního souboru (`make`)

- popis závislostí cíle: *targets* : [*files*]
- prováděné příkazy: <Tab>*command*
- komentář: #*comment*
- pokračovací řádek: *line-begin*\
  line-continuation

Makra (`make`)

- definice makra:

  `name = string`

- pokračování vkládá mezeru
- nedefinovaná makra jsou prázdná
- nezáleží na pořadí definic různých maker
- definice na příkazové řádce:

  `make` *`target name=string`*

- vyvolání makra:

  `$`*`name`* (pouze jednoznakové *`name`*),

  `${`*`name`*`}` nebo `$(`*`name`*`)`

- systémové proměnné jsou přístupné jako makra

Dynamický linker (loader)

- překlad vyžaduje všechny potřebné dynamické knihovny pro kontrolu dosažitelnosti použitých symbolů
- **sestavení kompletního programu v paměti se ale provede až při spuštění**. To je úkol pro **dynamický linker** (*run-time linker*, *loader*)
- seznam dynamických knihoven zjistí ze sekce `.dynamic`
- systém má nastaveno několik cest, kde se automaticky tyto knihovny hledají
- v sekci `.dynamic` je možné další cesty ke knihovnám přidat pomocí tagů `RUNPATH`/`RPATH`
- nalezené knihovny se připojí do paměťového procesu pomocí volání **mmap**() (bude později)

API versus ABI

API – Application Programming Interface

- rozhraní použité pouze ve zdrojovém kódu
- rozhraní **zdrojáku** vůči systému, knihovně či vlastnímu kódu, tj. např. `exit(1)`, `printf("hello\n")` nebo `my_function(1, 2)`
- ... aby se stejný **zdrojový kód** mohl přeložit na všech systémech podporující dané API

ABI – Application Binary Interface

- low-level rozhraní **aplikace** vůči systému, knihovně či jiné části sama sebe
- ... aby se **objektový modul** mohl použít všude tam, kde je podporováno stejné ABI

Debugger `dbx`

- Volání:

  `dbx [` *`options`* `] [` *`program`* `[` *`core`* `] ]`

- Nejběžnější příkazy:

`run [`*`arglist`*`]`	start programu
`where`	vypiš zásobník
`print` *`expr`*	vypiš výraz
`set` *`var`* `=` *`expr`*	změň hodnotu proměnné
`cont`	pokračování běhu programu
`next`, `step`	proveď řádku (bez/s vnořením do funkce)
`stop` *`condition`*	nastavení breakpointu
`trace` *`condition`*	nastavení tracepointu
`command` *`n`*	akce na breakpointu (příkazy následují)
`help [`*`name`*`]`	nápověda
`quit`	ukončení debuggeru

GNU debugger gdb

- Volání:

  `gdb [ options ] [ program [ core ] ]`

- Nejběžnější příkazy:

`run [arglist]`	start programu
`bt`	vypiš zásobník
`print expr`	vypiš výraz
`set var = expr`	změň hodnotu proměnné
`cont`	pokračování běhu programu
`next`, `step`	proveď řádku (bez/s vnořením do funkce)
`break condition`	nastavení breakpointu
`help [name]`	nápověda
`quit`	ukončení debuggeru

Obsah

- úvod, vývoj UNIXu a C, programátorské nástroje
- **základní pojmy a konvence UNIXu a jeho API**
- přístupová práva, periferní zařízení, systém souborů
- manipulace s procesy, spouštění programů
- signály
- synchronizace a komunikace procesů
- síťová komunikace
- vlákna, synchronizace vláken
- ??? - bude definováno později, podle toho kolik zbyde času

Standardní hlavičkové soubory (ANSI C)

`stdlib.h`	...	základní makra a funkce
`errno.h`	...	ošetření chyb
`stdio.h`	...	vstup a výstup
`ctype.h`	...	práce se znaky
`string.h`	...	práce s řetězci
`time.h`	...	práce s datem a časem
`math.h`	...	matematické funkce
`setjmp.h`	...	dlouhé skoky
`assert.h`	...	ladicí funkce
`stdarg.h`	...	práce s proměnným počtem parametrů
`limits.h`	...	implementačně závislé konstanty
`signal.h`	...	ošetření signálů

Standardní hlavičkové soubory (2)

`unistd.h`	...	symbolické konstanty, typy a základní funkce
`sys/types.h`	...	datové typy
`fcntl.h`	...	řídící operace pro soubory
`sys/stat.h`	...	informace o souborech
`dirent.h`	...	procházení adresářů
`sys/wait.h`	...	čekání na synovské procesy
`sys/mman.h`	...	mapování paměti
`curses.h`	...	ovládání terminálu
`regex.h`	...	práce s regulárními výrazy

Standardní hlavičkové soubory (3)

`semaphore.h`	...	semafory (POSIX)
`pthread.h`	...	vlákna (POSIX threads)
`sys/socket.h`	...	síťová komunikace
`arpa/inet.h`	...	manipulace se síťovými adresami
`sys/ipc.h`	...	společné deklarace pro System V IPC
`sys/shm.h`	...	sdílená paměť (System V)
`sys/msg.h`	...	fronty zpráv (System V)
`sys/sem.h`	...	semafory (System V)

Funkce `main()`

- při spuštění programu je předáno řízení funkci `main()`.
- `int` **`main`** `(int` *`argc`*`, char *`*`argv`*`[]);`
  - `argc` ... počet argumentů příkazové řádky
  - `argv` ... pole argumentů
    - podle konvence je `argv[0]` jméno programu (bez cesty)
    - poslední prvek je `argv[argc] == NULL`
  - návrat z `main()` nebo volání `exit()` ukončí program
  - standardní návratové hodnoty `EXIT_SUCCESS` (0) a `EXIT_FAILURE` (1)

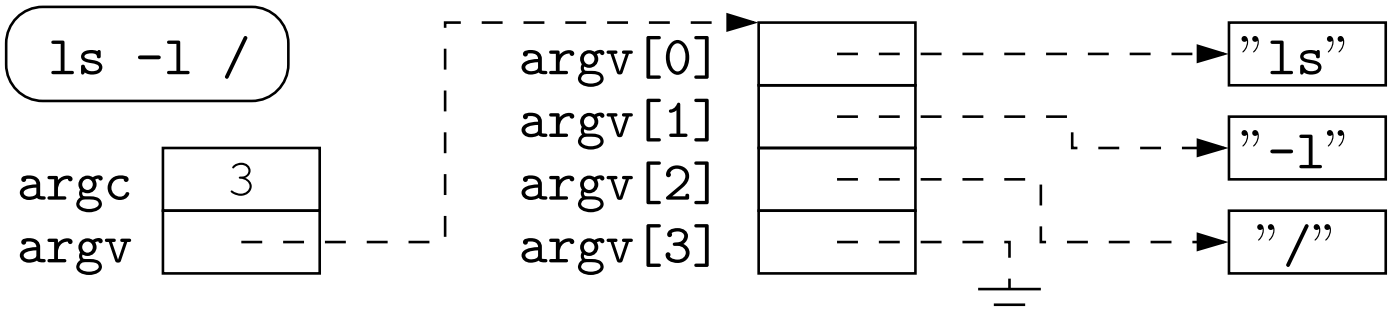

Proměnné prostředí

- seznam všech proměnných prostředí (*environment variables*) se předává jako proměnná

  `extern char **environ;`

- je to pole ukazatelů (ukončené NULL) na řetězce ve tvaru:

  `proměnná=hodnota`

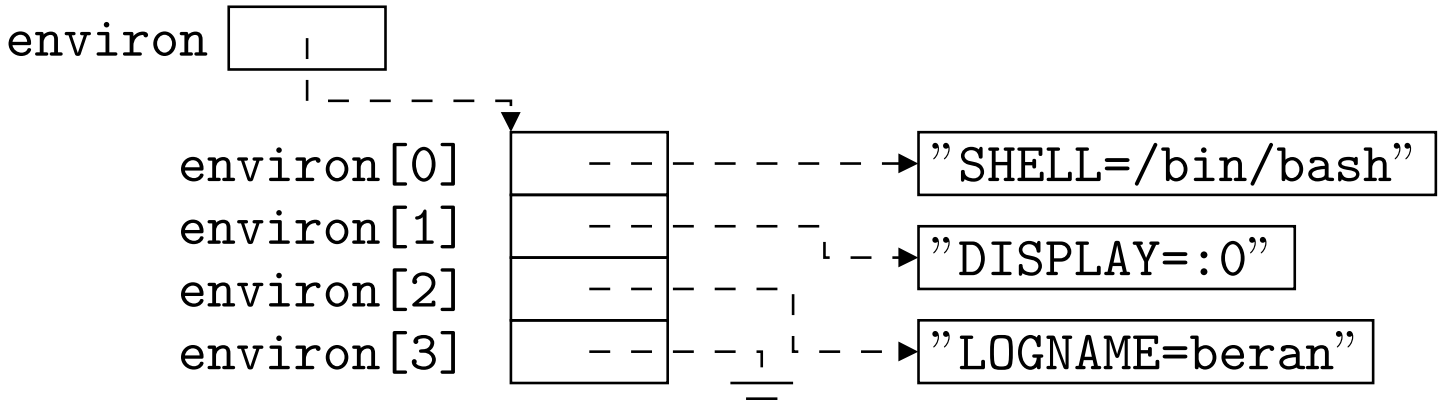

Manipulace s proměnnými prostředí

- je možné přímo měnit proměnnou `environ`, SUSv3 to ale nedoporučuje
- `char *getenv (const char *name);`
  - vrátí hodnotu proměnné name
- `int putenv (char *string);`
  - vloží string ve tvaru *jméno=hodnota* do prostředí (přidá novou nebo modifikuje existující proměnnou)
- změny se přenášejí do synovských procesů
- změny v prostředí syna samozřejmě prostředí otce neovlivní
- existují i funkce **setenv**() a **unsetenv**()

Zpracování argumentů programu

- obvyklý zápis v shellu: `program -přepínače argumenty`
- přepínače tvaru `-x` nebo `-x` *`hodnota`*, kde `x` je jedno písmeno nebo číslice, *`hodnota`* je libovolný řetězec
- několik přepínačů lze sloučit dohromady: `ls -lRa`
- argument '`--`' nebo první argument nezačínající '`-`' ukončuje přepínače, následující argumenty nejsou považovány za přepínače, i když začínají znakem '`-`'.
- tento tvar argumentů požaduje norma a lze je zpracovávat automaticky funkcí `getopt`.

Zpracování přepínačů: `getopt()`

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

- funkce dostane parametry z příkazového řádku, při každém volání zpracuje a vrátí další přepínač. Pokud má přepínač hodnotu, vrátí ji v `optarg`.
- když jsou vyčerpány všechny přepínače, vrátí `-1` a v `optind` je číslo prvního nezpracovaného argumentu.
- možné přepínače jsou zadány v `optstring`, když za znakem přepínače následuje '`:`', má přepínač povinnou hodnotu.
- při chybě (neznámý přepínač, chybí hodnota) vrátí '`?`', uloží znak přepínače do `optopt` a když `opterr` nebylo nastaveno na nulu, vypíše chybové hlášení.

Příklad použití getopt()

```
struct {
    int a, b; char c[128];
} opts;
int opt; char *arg1;

while((opt = getopt(argc, argv, "abc:")) != -1)
    switch(opt) {
        case 'a': opts.a = 1; break;
        case 'b': opts.b = 1; break;
        case 'c': strcpy(opts.c, optarg); break;
        case '?': fprintf(stderr,
            "usage: %s [-ab] [-c Carg] arg1 arg2 ...\n",
            basename(argv[0])); break;
    }
arg1 = argv[optind];
```

Dlouhý tvar přepínačů

- poprvé se objevilo v GNU knihovně `libiberty`:

  `--jméno nebo --jméno=hodnota`

- argumenty se permutují tak, aby přepínače byly na začátku, např. `ls * -l` je totéž jako `ls -l *`, standardní chování lze docílit nastavením proměnné `POSIXLY_CORRECT`.

- zpracovávají se funkcí **getopt_long()**, která používá pole struktur popisujících jednotlivé přepínače:

```
struct option {
    const char *name; /* jméno přepínače */
    int has_arg; /* hodnota: ano, ne, volitelně */
    int *flag; /* když je NULL, funkce vrací val, jinak vrací 0
                  a dá val do *flag */
    int val; /* návratová hodnota */
};
```

Dlouhé přepínače (pokračování)

```
int getopt_long(int argc, char * const argv[],
                const char *optstring,
                const struct option *longopts,
                int *longindex);
```

- `optstring` obsahuje jednopísmenné přepínače, `longopts` obsahuje adresu pole struktur pro dlouhé přepínače (poslední záznam pole obsahuje samé nuly)
- pokud funkce narazí na dlouhý přepínač, vrací odpovídající `val` nebo nulu (pokud `flag` nebyl `NULL`), jinak je chování shodné s `getopt`.
- do `*longindex` (když není `NULL`) dá navíc index nalezeného přepínače v `longopts`.

Struktura klasického OS UNIX

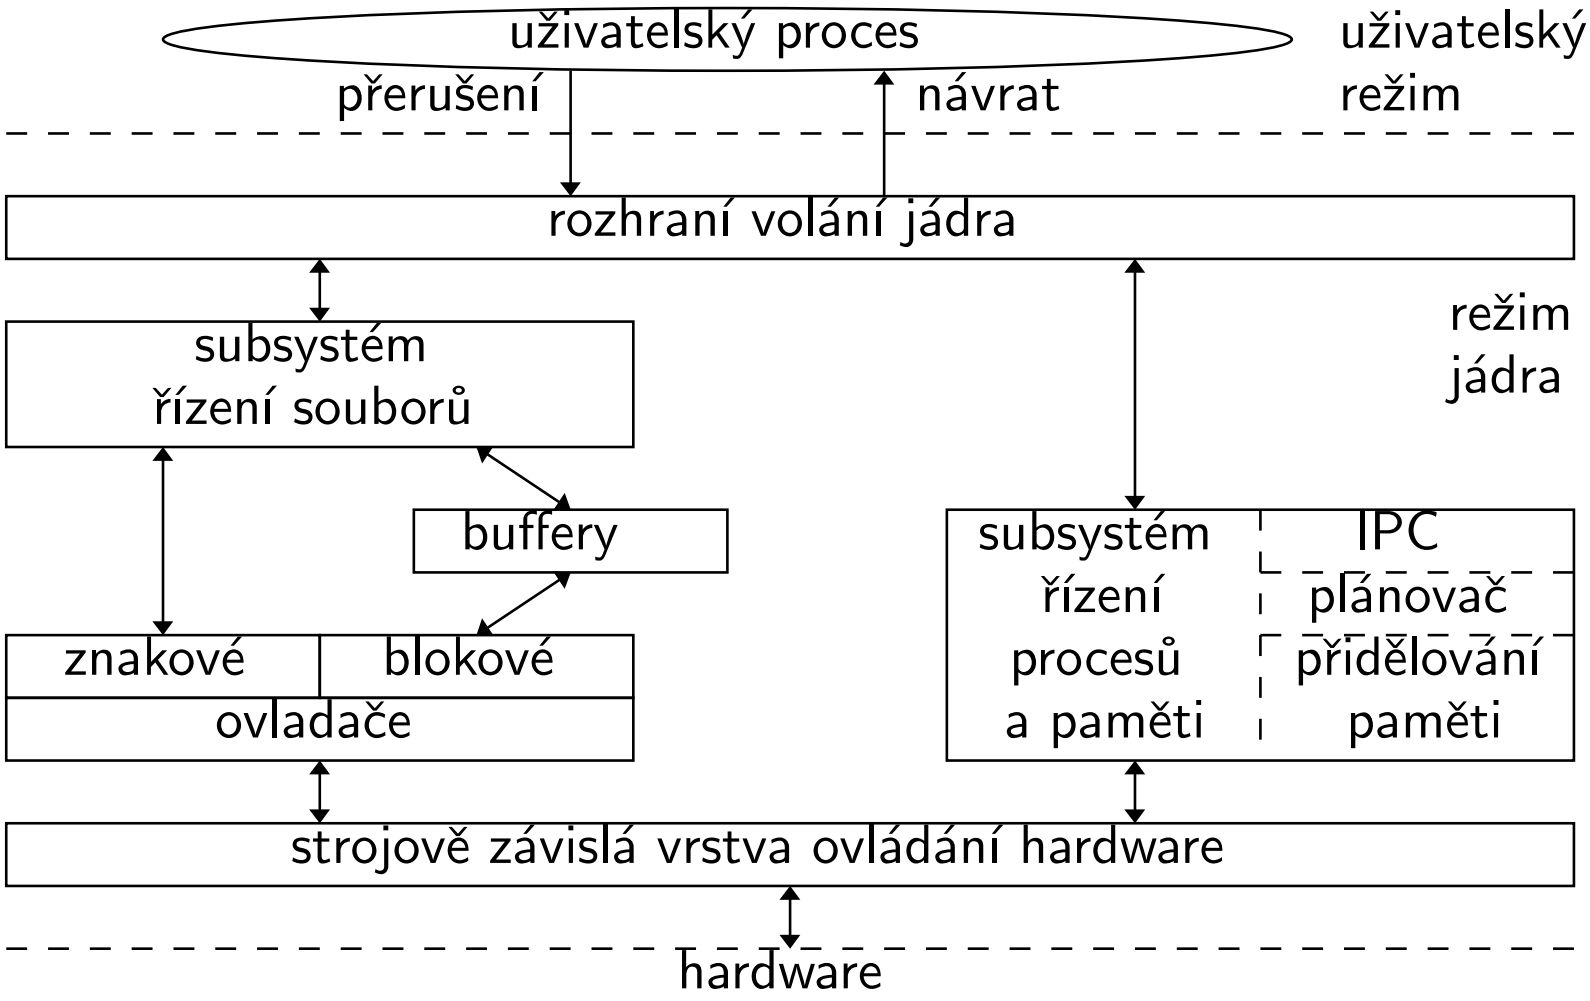

Procesy, vlákna, programy

- **proces** je systémový objekt charakterizovaný svým kontextem, identifikovaný jednoznačným číslem (**process ID**, **PID**); jinými slovy ,,kód a data v paměti"
- **vlákno (thread)** je systémový objekt, který existuje uvnitř procesu a je charakterizován svým stavem. Všechna vlákna jednoho procesu sdílí stejný paměťový prostor kromě registrů procesoru a zásobníku; ,,linie výpočtu", ,,to, co běží"
- **program** ... soubor přesně definovaného formátu obsahující instrukce, data a služební informace nutné ke spuštění; ,,spustitelný soubor na disku"
  - **paměť** se přiděluje **procesům**.
  - **procesory** se přidělují **vláknům**.
  - vlákna jednoho procesu mohou běžet na různých procesorech.

Jádro, režimy, přerušení (klasický UNIX)

- procesy typicky běží v uživatelském režimu
- systémové volání způsobí přepnutí do režimu jádra
- proces má pro každý režim samostatný zásobník
- jádro je částí každého uživatelského procesu, není to samostný proces (procesy)
- přepnutí na jiný proces se nazývá *přepnutí kontextu*
- obsluha přerušení se provádí v kontextu přerušeného procesu
- klasické jádro je nepreemptivní

Volání služeb a komunikace mezi procesy

- UNIX

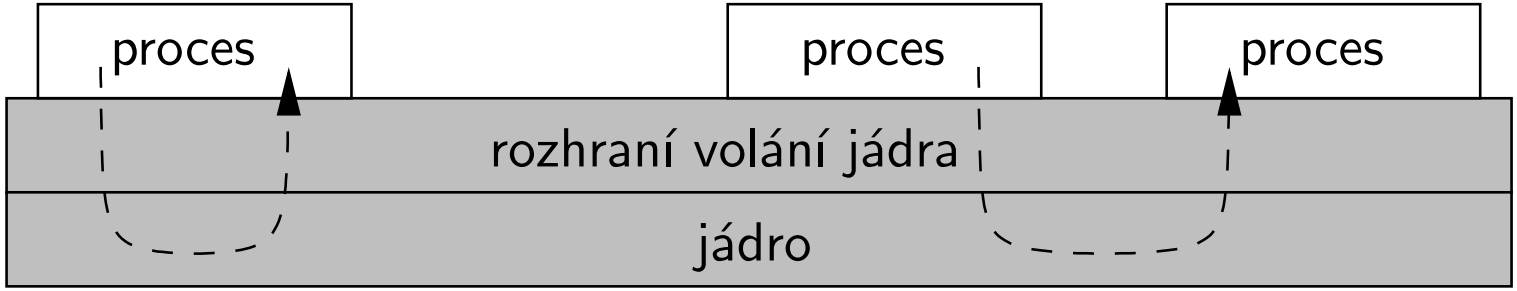

- distribuovaný OS

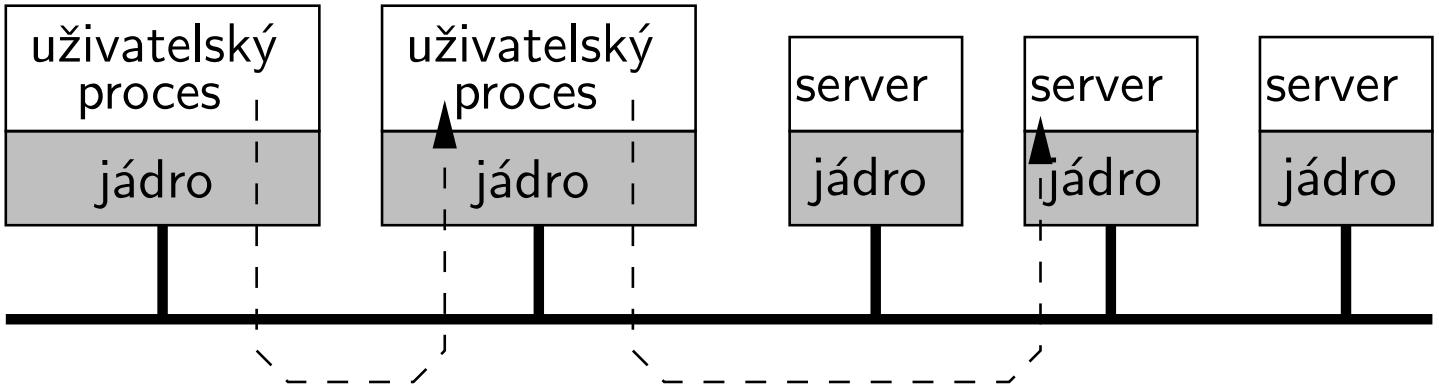

Systémová volání, funkce

- v UNIXu se rozlišují **systémová volání** a **knihovní funkce**. Toto rozlišení dodržují i manuálové stránky: sekce **2** obsahuje systémová volání (*syscalls*), sekce **3** knihovní funkce (*library functions*).
  - knihovní funkce se vykonávají v uživatelském režimu, stejně jako ostatní kód programu.
  - systémová volání mají také tvar volání funkce. Příslušná funkce ale pouze zpracuje argumenty volání a předá řízení jádru pomocí instrukce synchronního přerušení. Po návratu z jádra funkce upraví výsledek a předá ho volajícímu.
- standardy tyto kategorie nerozlišují – z hlediska programátora je jedno, zda určitou funkci provede jádro nebo knihovna.

Návratové hodnoty systémových volání

- celočíselná návratová hodnota (`int`, `pid_t`, `off_t`, apod.)
  - `>= 0` ... operace úspěšně provedena
  - `== -1` ... chyba
- návratová hodnota typu ukazatel
  - `!= NULL` ... operace úspěšně provedena
  - `== NULL` ... chyba
- po neúspěšném systémovém volání je kód chyby v globální proměnné `extern int errno;`
- úspěšné volání nemění hodnotu v `errno`! Je tedy třeba nejprve otestovat návratovou hodnotu a pak teprve `errno`.
- chybové hlášení podle hodnoty v `errno` vypíše funkce `void perror(const char *s);`
- textový popis chyby s daným číslem vrátí funkce `char *strerror(int errnum);`

Skupina funkcí z `err(3)`

- pomocné funkce pro výpis chybových hlášení a případné ukončení programu
- místo `perror()` a `exit()` vám stačí jedna funkce
- `void` **`err`**`(int` *`status`*`, const char *`*`fmt`*`, ...);`
  - vypíše jméno programu, formátovaný řetězec, a chybu podle aktuální hodnoty `errno`
  - ukončí program s návratovou hodnotou ze *`status`*
- `void` **`warn`**`(const char *`*`fmt`*`, ...);`
  - stejné jako **err**(), ale program neukončí
- existují další podobné funkce, viz manuálová stránka
- funkce pocházejí ze 4.4BSD

Obsah

- úvod, vývoj UNIXu a C, programátorské nástroje
- základní pojmy a konvence UNIXu a jeho API
- **přístupová práva, periferní zařízení, systém souborů**
- manipulace s procesy, spouštění programů
- signály
- synchronizace a komunikace procesů
- síťová komunikace
- vlákna, synchronizace vláken
- ??? - bude definováno později, podle toho kolik zbyde času

Users and groups

```
beran:x:1205:106:Martin Beran:/home/beran:/bin/bash
```

The fields, in order from left to right: user name, hashed password (today in `/etc/shadow` or elsewhere), user ID (aka UID); primary group ID (aka GID), full name, home directory, login shell

Note that a superuser (root) has always UID 0.

```
sisal:*:106:forst,beran
```

The fields, in order from left to right: group name, group password (not used today), group ID (GID), list of group members

Name service switch

- today's systems are not confined to only using `/etc/passwd` and `/etc/groups`
- such systems have *databases* (passwd, groups, protocols, ...)
- database data come from *sources* (files, DNS, NIS, LDAP, ...)
- file `nsswitch.conf` defines what databases use what sources
- library functions must support this, obviously
- it is possible to combine some sources, eg. users may be first be searched in `/etc/passwd`, then in LDAP
- came first with Solaris, other systems took over the idea

Získávání údajů o uživatelích/skupinách

- `struct passwd *`**`getpwnam`**`(const char *name)`

  vrací strukturu reprezentující uživatele.

- `struct passwd *`**`getpwuid`**`(uid_t uid)`

  vrací strukturu reprezentující uživatele podle UID.

- `void` **`setpwent`**`(void)`

- `void` **`endpwent`**`(void)`

- `struct passwd *`**`getpwent`**`(void)`

  slouží k procházení položek v databázi uživatelů. **setpwent** nastaví pozici na začátek, **getpwent** získá další položku, **endpwent** dealokuje prostředky použité pro procházení seznamu.

Testování přístupových práv

- uživatel je identifikován číslem uživatele (**UID**) a čísly skupin, do kterých patří (**primary GID**, **supplementary GIDs**).
- tuto identifikaci dědí každý proces daného uživatele.
- soubor S má vlastníka (UID_S) a skupinového vlastníka (GID_S).
- algoritmus testování přístupových práv pro proces $P(UID_P, GID_P, SUPG)$ a soubor $S(UID_S, GID_S)$:

Jestliže	pak *P*roces má vůči *S*ouboru
`if(`UID_P `== 0)`	... všechna práva
`else if(`UID_P `==` UID_S`)`	... práva vlastníka
`else if(`GID_P `==` GID_S `||` $GID_S \in SUPG$`)`	... práva člena skupiny
`else`	... práva ostatních

Reálné a efektivní UID/GID

- u každého procesu se rozlišuje:
  - **reálné UID** (RUID) – skutečný vlastník procesu
  - **efektivní UID** (EUID) – uživatel, jehož práva proces používá
  - **uschované UID** (saved SUID) – původní efektivní UID
- podobně se rozlišuje reálné, efektivní a uschované GID procesu.
- obvykle platí `RUID==EUID && RGID==EGID`.
- **propůjčování práv** ... spuštění programu s nastaveným SUID (**set user ID**) bitem změní EUID a saved UID procesu na UID vlastníka programu, RUID se nezmění.
- podobně SGID bit ovlivňuje EGID procesu.
- **při kontrole přístupových práv se používají vždy EUID, EGID a supplementary GIDs**

Identifikace vlastníka procesu

- `uid_t` **getuid**`(void)`

  vrací reálné user ID volajícího procesu.

- `uid_t` **geteuid**`(void)`

  vrací efektivní user ID volajícího procesu.

- `gid_t` **getgid**`(void)`

  vrací reálné group ID volajícího procesu.

- `gid_t` **getegid**`(void)`

  vrací efektivní group ID volajícího procesu.

- `int` **getgroups**`(int` *`gidsz`*`, gid_t` *`glist`*`[])`

  – do `glist` dá nejvýše `gidsz` supplementary group IDs volajícího procesu a vrátí počet všech GIDs procesu.

Změna vlastníka procesu

- `int` **setuid**`(uid_t` *uid*`);`
  - v procesu s EUID == 0 nastaví RUID, EUID i saved-SUID na `uid`
  - pro ostatní procesy nastavuje jen EUID, a `uid` musí být buď rovné RUID nebo uschovanému SUID
- `int` **setgid**`(gid_t` *gid*`);`
  obdoba `setuid`, nastavuje group-IDs procesu.
- `int` **setgroups**`(int` *ngroups*`, gid_t *`*gidset*`)`
  nastavuje supplementary GIDs procesu, může být použito jen superuživatelským procesem.

Systém souborů

- adresáře tvoří strom, spolu se soubory acyklický graf (na jeden soubor může existovat více odkazů).
- každý adresář navíc obsahuje odkaz na sebe '`.`' (tečka) a na nadřazený adresář '`..`' (dvě tečky).
- pomocí rozhraní systému souborů se přistupuje i k dalším entitám v systému:
  - periferní zařízení
  - pojmenované roury
  - sokety
  - procesy (`/proc`)
  - paměť (`/dev/mem`, `/dev/kmem`)
  - pseudosoubory (`/dev/tty`, `/dev/fd/0`,...)
- z pohledu jádra je každý obyčejný soubor pole bajtů.
- všechny (i síťové) disky jsou zapojeny do jednoho stromu.

Jednotný hierarchický systém souborů

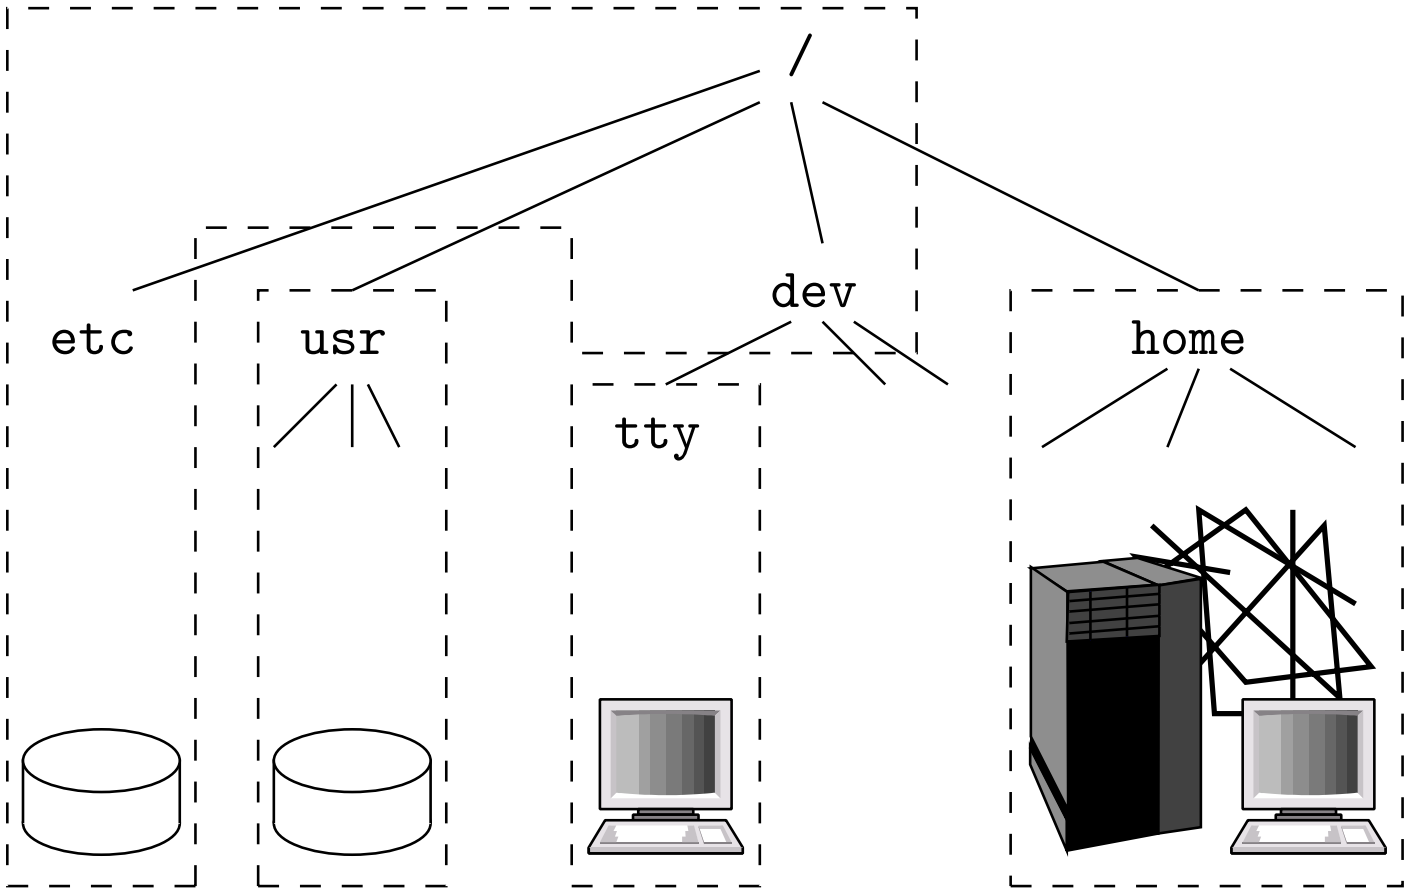

Typická skladba adresářů

`/bin`	...	základní systémové příkazy
`/dev`	...	speciální soubory (zařízení, devices)
`/etc`	...	konfigurační adresář
`/lib`	...	základní systémové knihovny
`/tmp`	...	veřejný adresář pro dočasné soubory
`/home`	...	kořen domovských adresářů
`/var/adm`	...	administrativní soubory (ne na BSD)
`/usr/include`	...	hlavičkové soubory pro C
`/usr/local`	...	lokálně instalovaný software
`/usr/man`	...	manuálové stránky
`/var/spool`	...	spool (pošta, tisk,...)

Přístup k periferním zařízením

- adresář `/dev` obsahuje speciální soubory zařízení. Proces otevře speciální soubor systémovým voláním `open()` a dále komunikuje se zařízením pomocí volání `read()`, `write()`, `ioctl()`, apod.
- speciální soubory se dělí na
  - **znakové** ... data se přenáší přímo mezi procesem a ovladačem zařízení, např. sériové porty
  - **blokové** ... data prochází systémovou vyrovnávací pamětí (buffer cache) po blocích pevně dané velikosti, např. disky
- speciální soubor identifikuje zařízení dvěma čísly
  - **hlavní (major) číslo** ... číslo ovladače v jádru
  - **vedlejší (minor) číslo** ... číslo v rámci jednoho ovladače

Fyzické uložení systému souborů

- **systém souborů** (svazek, **filesystem**) lze vytvořit na:
  - **oddílu disku** (**partition**) – část disku, na jednom disku může být více oddílů
  - **logickém oddílu** (**logical volume**) – takto lze spojit více oddílů, které mohou být i na několika discích, do jednoho svazku.
- další možnosti: striping, mirroring, RAID

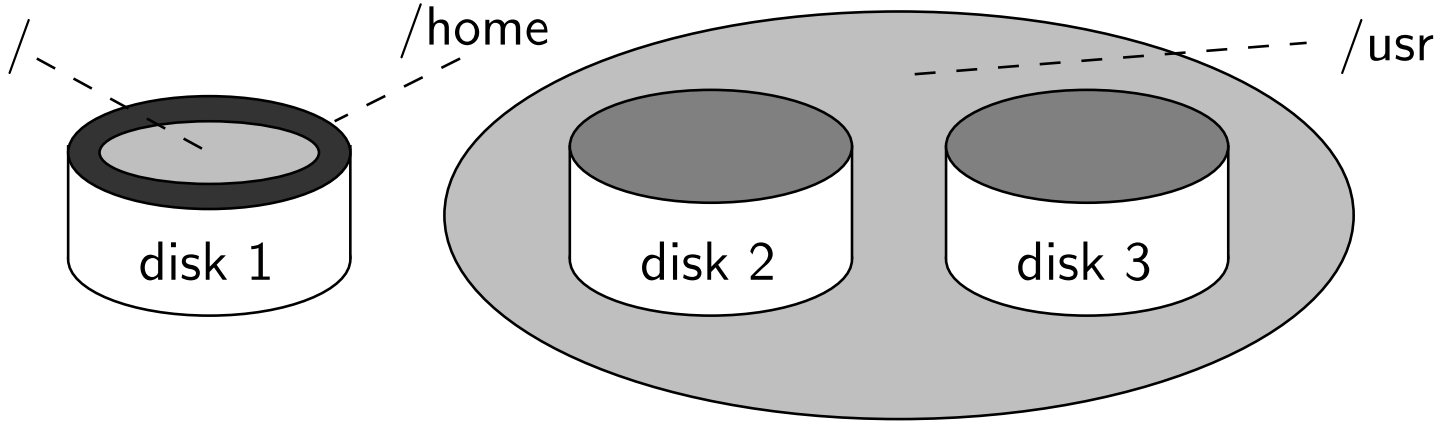

Organizace systému souborů s5

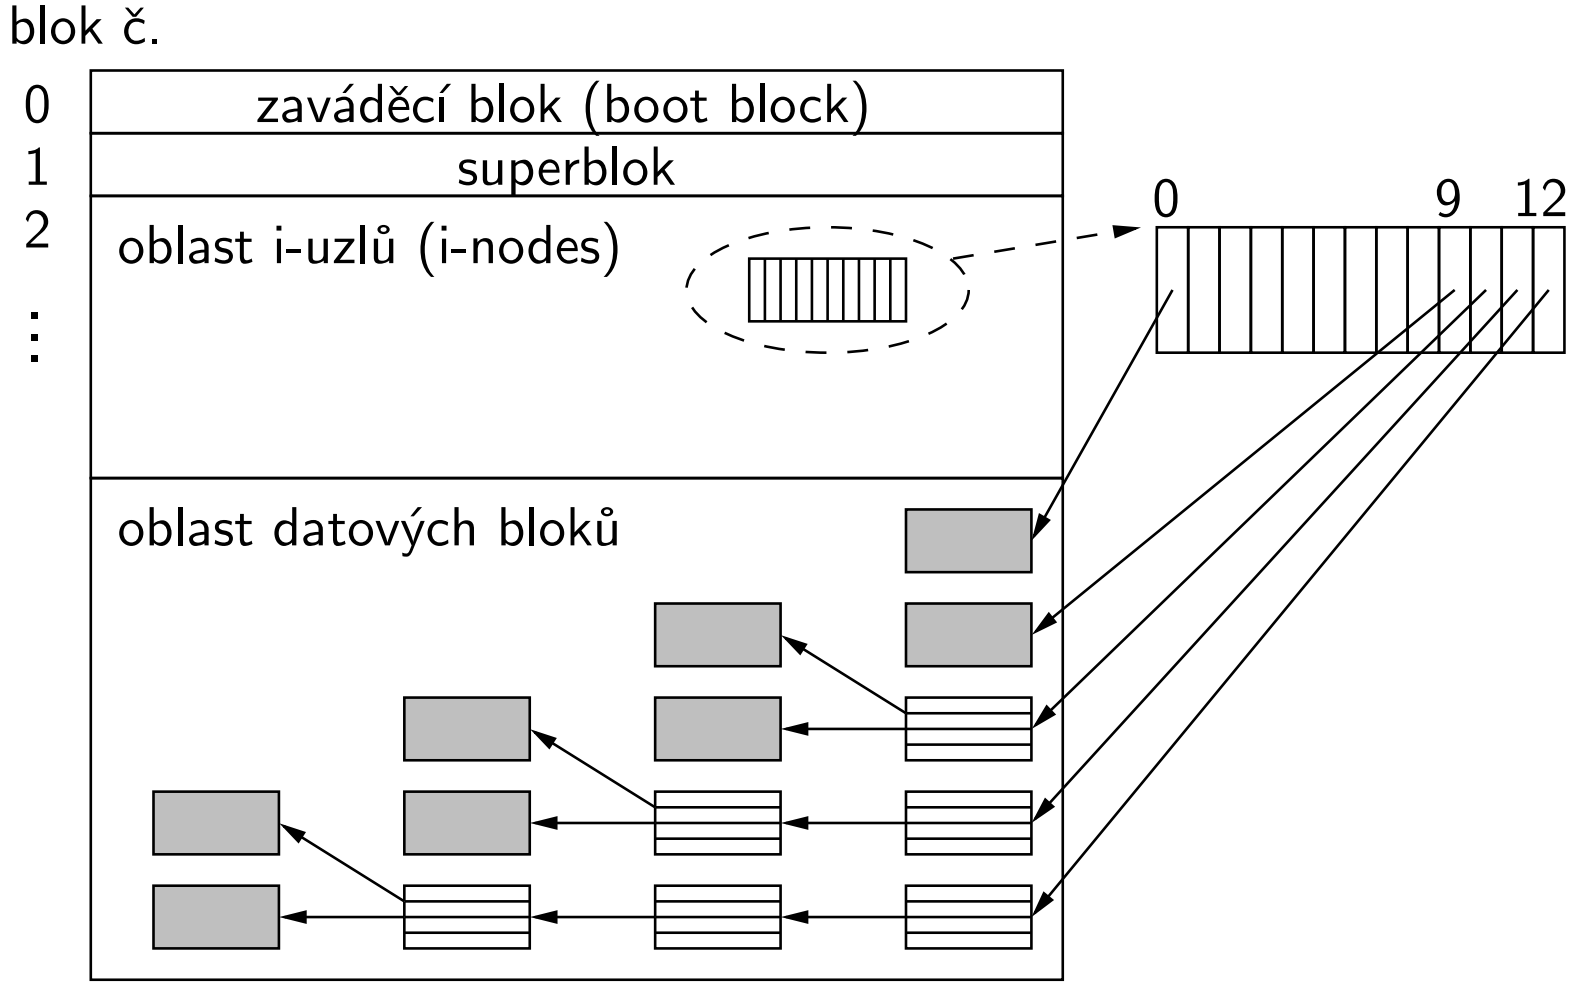

Navigace v adresářové struktuře

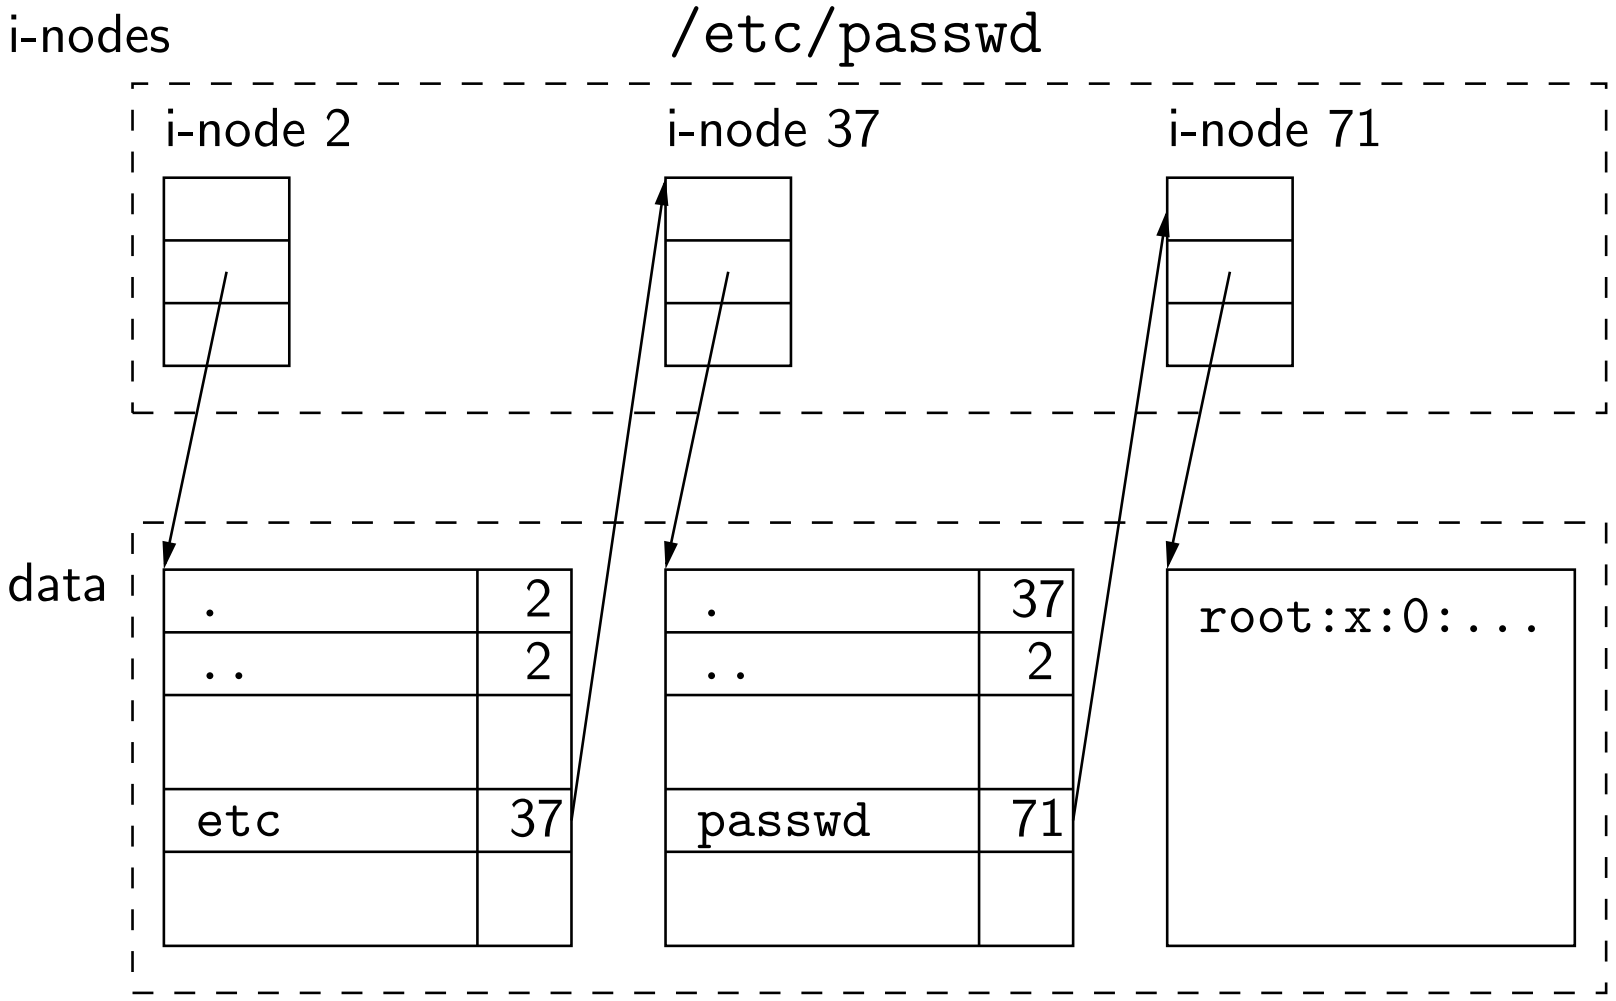

Linky

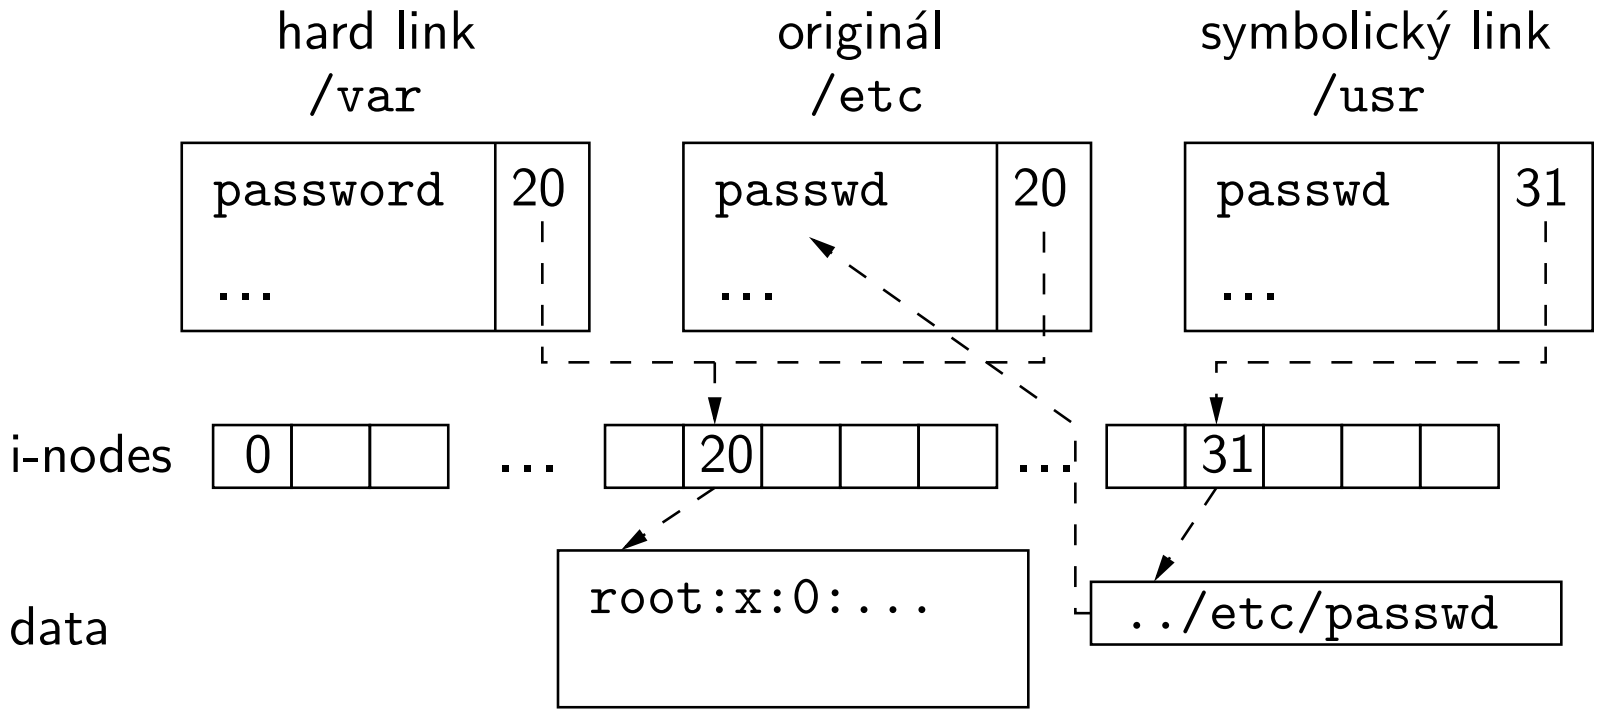

Hard linky lze vytvářet pouze v rámci jednoho (logického) filesystému.

Vylepšení systému souborů

- cíl: snížení fragmentace souborů, omezení pohybu hlav disku umístěním i-uzlů a datových bloků blíž k sobě
- UFS (Unix File System), původně Berkeley FFS (Fast File System)
- členění na skupiny cylindrů, každá skupina obsahuje
  - kopii superbloku
  - řídicí blok skupiny
  - tabulku i-uzlů
  - bitmapy volných i-uzlů a datových bloků
  - datové bloky
- bloky velikosti 4 až 8 kB, menší části do fragmentů bloků
- jména dlouhá 255 znaků

Vývoj ve správě adresářových položek

- maximální délka jména souboru 14 znaků nebyla dostačující
- FFS – délka až 255; každá položka zároveň obsahuje i její délku
- nové filesystémy používají pro vnitřní strukturu adresářů různé varianty B-stromů
  - výrazně zrychluje práci s adresáři obsahující velké množství souborů
  - XFS, JFS, ReiserFS, ...
- UFS2 zavádí zpětně kompatibilní tzv. *dirhash* pro zrychlení přístupu k adresářům s velkým počtem souborů

Virtuální systém souborů (Virtual File System)

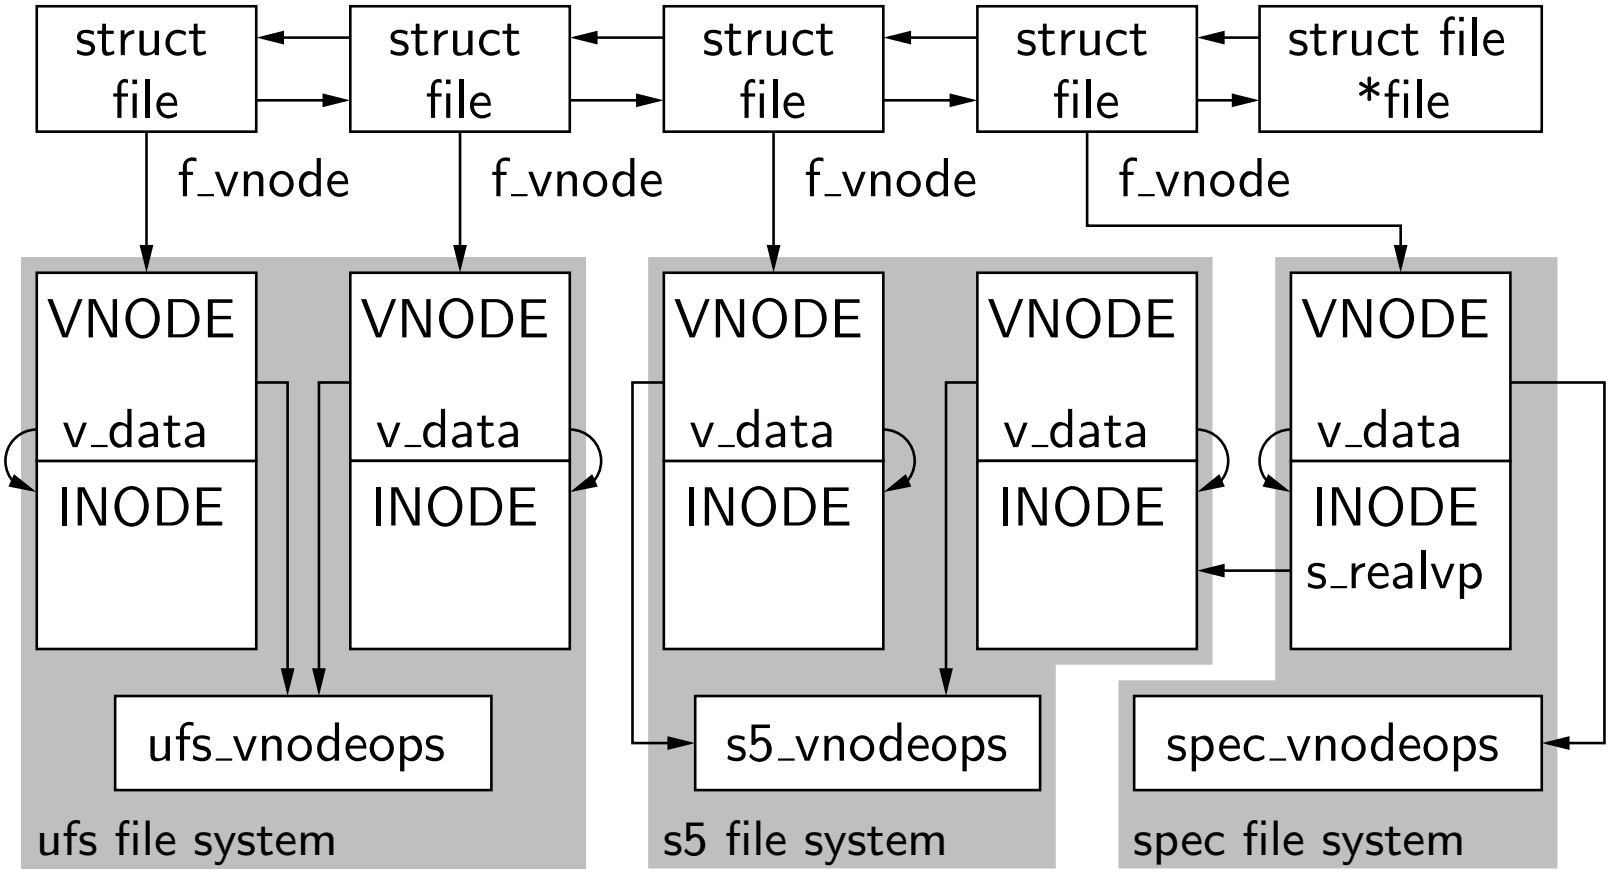

Hierarchie souborových systémů

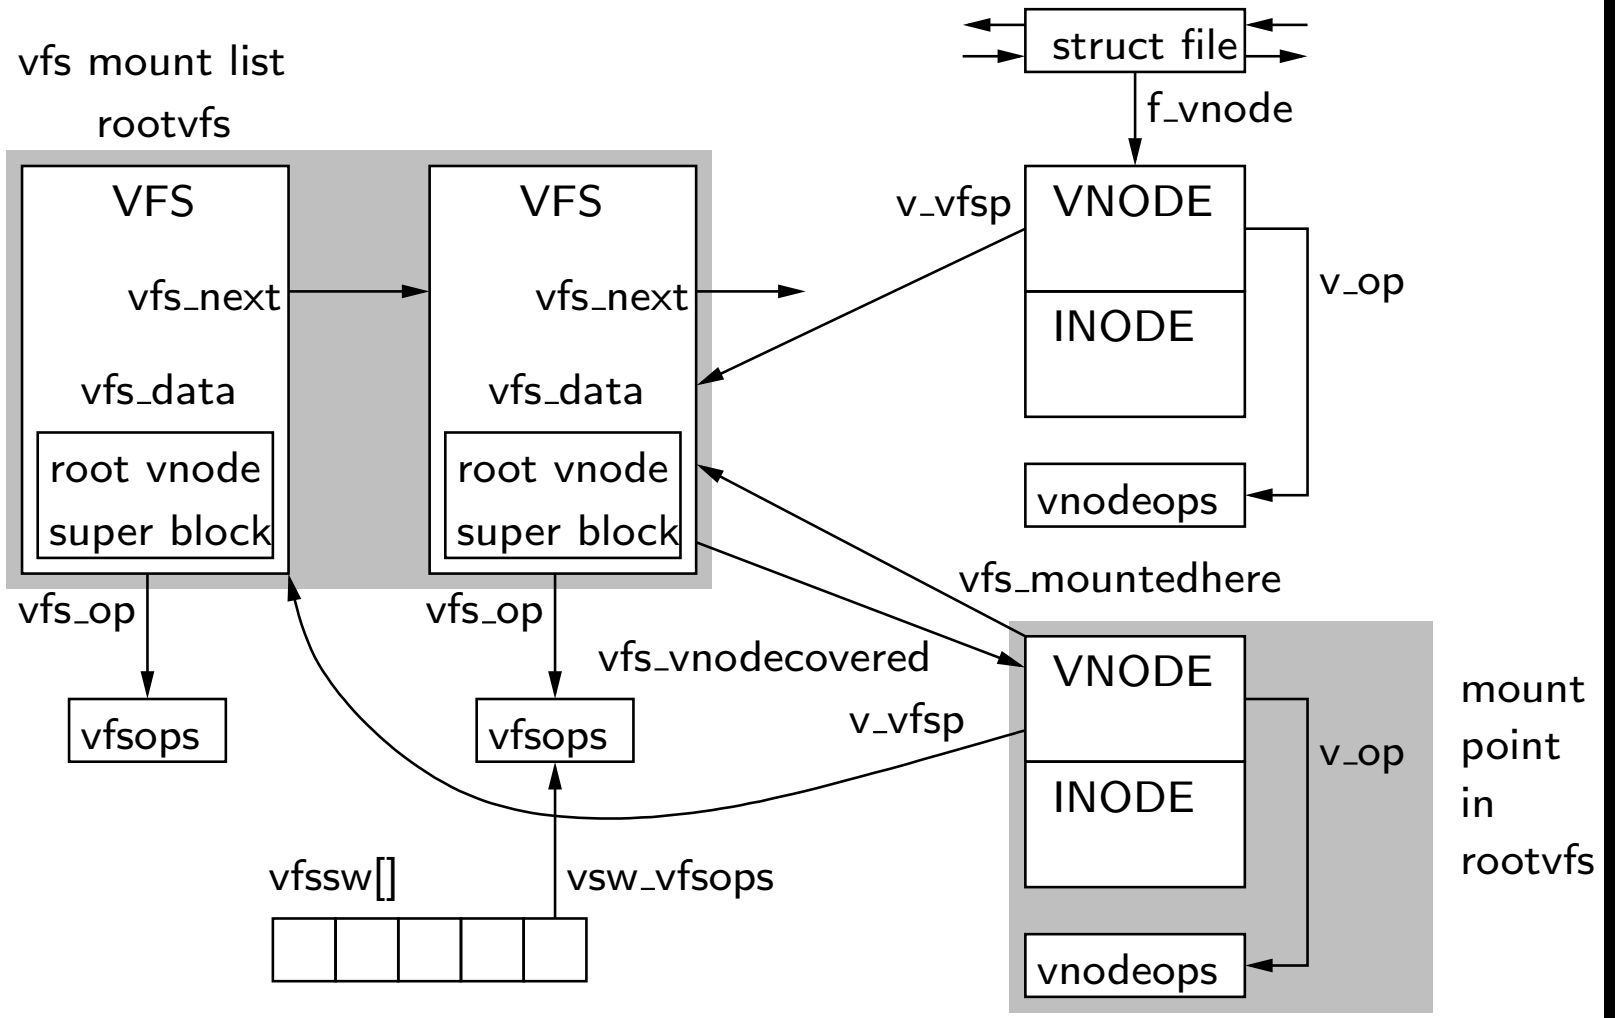

Otevřené soubory z pohledu jádra I.

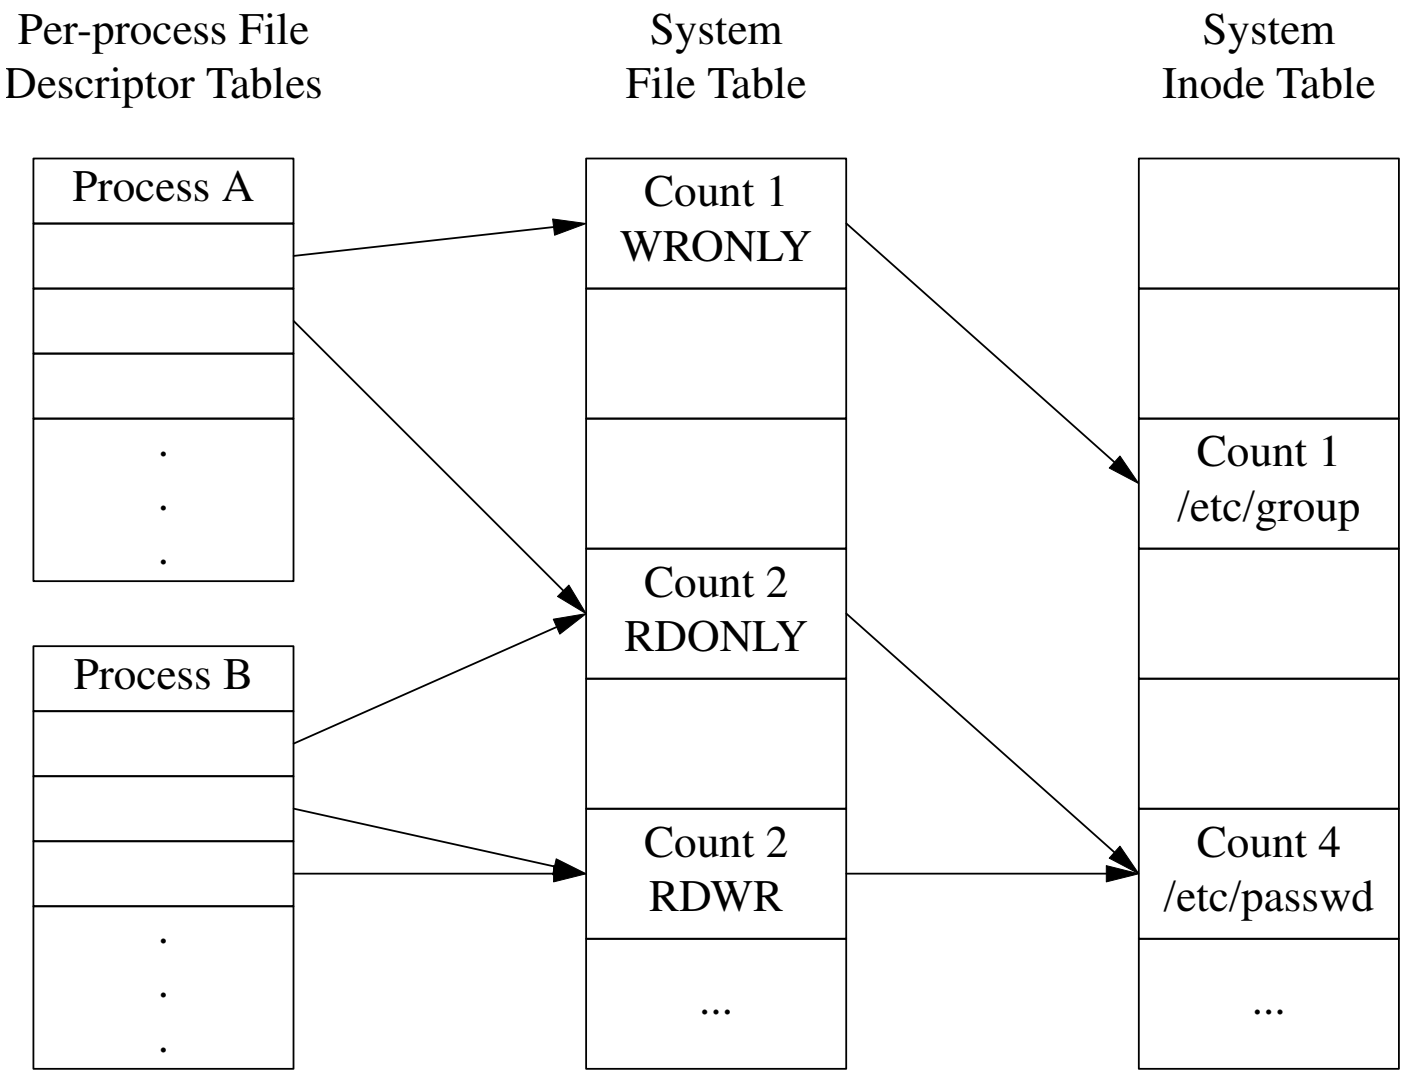

Otevřené soubory z pohledu jádra II.

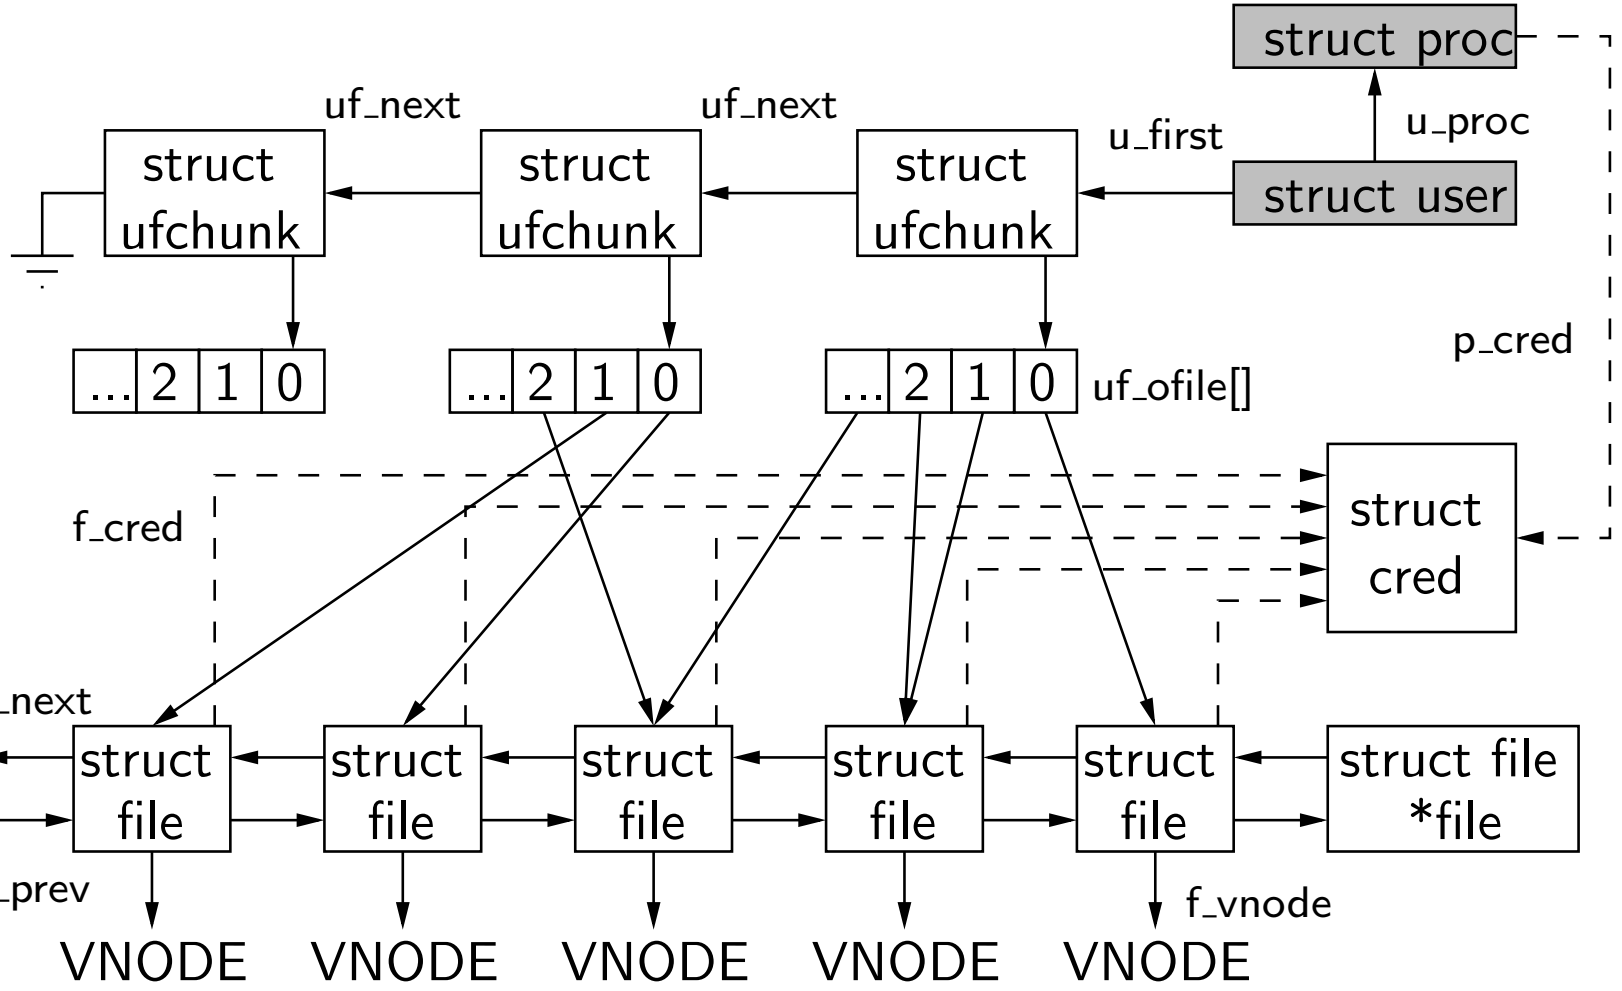

Oprava konzistence souborového systému

- pokud není filesystém před zastavením systému korektně odpojen, mohou být data v nekonzistentním stavu.
- ke kontrole a opravě svazku slouží příkaz `fsck`. Postupně testuje možné nekonzistence:
  - vícenásobné odkazy na stejný blok
  - odkazy na bloky mimo rozsah datové oblasti systému souborů
  - špatný počet odkazů na i-uzly
  - nesprávná velikost souborů a adresářů
  - neplatný formát i-uzlů
  - bloky které nejsou obsazené ani volné
  - chybný obsah adresářů
  - neplatný obsah superbloku
- operace `fsck` je časově náročná.
- žurnálové (např. XFS v IRIXu, Ext3 v Linuxu) a transakční (ZFS) systémy souborů nepotřebují `fsck`.

Další způsoby zajištění konzistence filesystému

- tradiční UFS – synchronní zápis metadat
  - aplikace vytvářející nový soubor čeká na inicializaci inode na disku; tyto operace pracují rychlostí disku a ne rychlostí CPU
  - asynchronní zápis ale častěji způsobí nekontistenci metadat
- řešení problémů s nekonzistencí metadat na disku:
  - *journalling* – skupina na sobě závislých operací se nejdříve atomicky uloží do žurnálu; při problémech se pak žurnál může "přehrát"
  - bloky metadat se nejdříve zapíší do non-volatile paměti
  - *soft-updates* – sleduje závislosti mezi ukazately na diskové struktury a zapisuje data na disk metodou *write-back* tak, že data na disku jsou vždy konzistentní
  - *ZFS* je nový filesystém v Solarisu, který používá *copy-on-write* transakční model

Přístupová práva

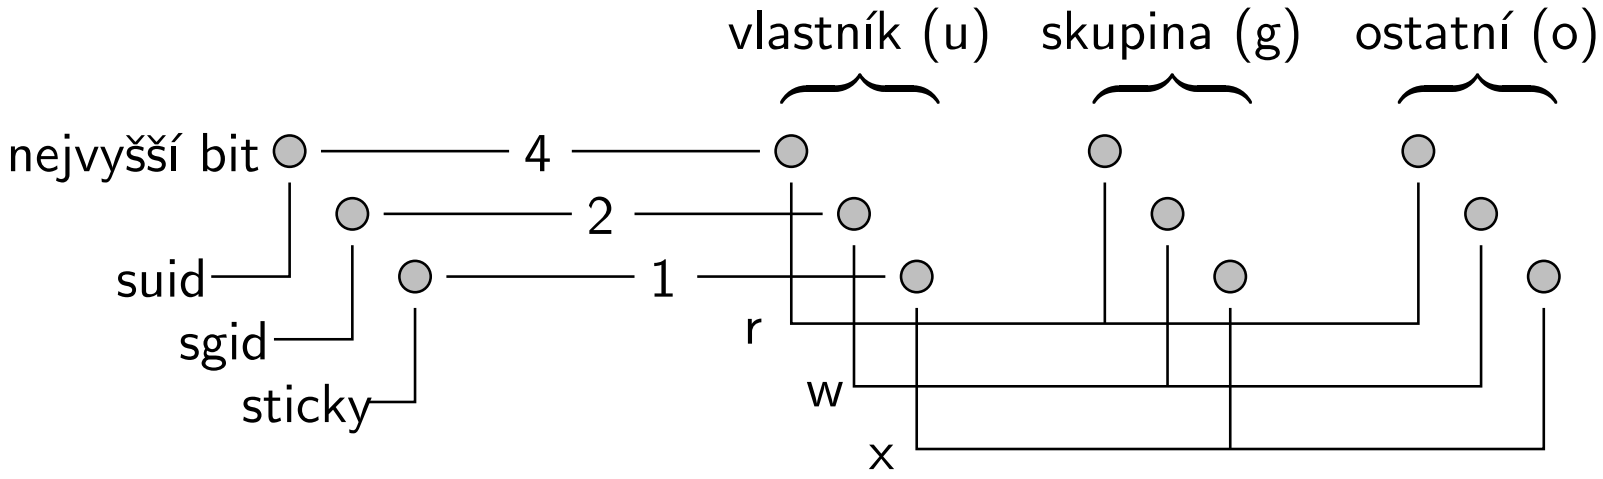

- **SGID** pro soubor bez práva spuštění pro skupinu v System V: kontrola zámků při každém přístupu (**mandatory locking**)
- **sticky bit** pro adresáře: právo mazat a přejmenovávat soubory mají jen vlastníci souborů
- **SGID** pro adresář: nové soubory budou mít stejnou skupinu jako adresář (System V; u BSD systémů to funguje jinak, viz poznámky)

API pro soubory

- před použitím musí proces každý soubor nejprve otevřít voláním `open()` nebo `creat()`.
- otevřené soubory jsou dostupné přes **deskriptory souborů** (file descriptors), číslované od 0, více deskriptorů může sdílet jedno **otevření souboru** (mód čtení/zápis, ukazatel pozice)
- standardní deskriptory:
  - 0 ... standardní vstup (jen pro čtení)
  - 1 ... standardní výstup (jen pro zápis)
  - 2 ... chybový výstup (jen pro zápis)
- čtení a zápis z/do souboru: `read()`, `write()`
- změna pozice: `lseek()`, zavření: `close()`, informace: `stat()`, řídicí funkce: `fcntl()`, práva: `chmod()`, ...

Otevření souboru: `open()`

```
int open(const char *path, int oflag, ... );
```

- otevře soubor daný jménem (cestou) `path`, vrátí číslo jeho deskriptoru (použije první volné), `oflag` je OR-kombinace příznaků
  - `O_RDONLY`/`O_WRONLY`/`O_RDWR` ... otevřít pouze pro čtení / pouze pro zápis / pro čtení i zápis
  - `O_APPEND` ... připojování na konec
  - `O_CREAT` ... vytvořit, když neexistuje
  - `O_EXCL` ... chyba, když existuje (použití s `O_CREATE`)
  - `O_TRUNC` ... zrušit předchozí obsah (právo zápisu nutné)
  - ...
- při `O_CREAT` definuje třetí parametr `mode` přístupová práva

Vytvoření souboru

`int` **creat**`(const char *`*path*`, mode_t` *mode*`);`

- `open()` s příznakem `O_CREAT` vytvoří soubor, pokud ještě neexistuje. V zadané hodnotě přístupových práv se vynulují bity, které byly nastaveny pomocí funkce
  `mode_t` **umask**`(mode_t` *cmask*`);`
- funkce je ekvivalentní volání
  `open(path, O_WRONLY|O_CREAT|O_TRUNC, mode);`

`int` **mknod**`(const char *`*path*`, mode_t` *mode*`, dev_t` *dev*`);`

- vytvoří speciální soubor zařízení.

`int` **mkfifo**`(const char *`*path*`, mode_t` *mode*`);`

- vytvoří pojmenovanou rouru.

Čtení a zápis souborů: `read()`, `write()`

`ssize_t` **`read`**`(int` *`fildes`*`, void *`*`buf`*`, size_t` *`nbyte`*`);`

- z otevřeného souboru s číslem deskriptoru `fildes` přečte od aktuální pozice max. `nbyte` bajtů dat a uloží je od adresy `buf`.
- vrací počet skutečně přečtených bajtů (`<= nbyte`), 0 znamená konec souboru.

`ssize_t` **`write`**`(int` *`fildes`*`, const void *`*`buf`*`, size_t` *`nbyte`*`);`

- do otevřeného souboru s číslem deskriptoru `fildes` zapíše na aktuální pozici max. `nbyte` bajtů dat uložených od adresy `buf`.
- vrací velikost skutečně zapsaných dat (`<= nbyte`).

Uzavření souboru: `close()`

`int` **close**`(int` *`fildes`*`);`

- uvolní deskriptor `fildes`, pokud to byl poslední deskriptor, který odkazoval na otevření souboru, zavře soubor a uvolní záznam o otevření souboru.
- když je počet odkazů na soubor 0, jádro uvolní data souboru. Tedy i po zrušení všech odkazů (jmen) mohou se souborem pracovat procesy, které ho mají otevřený. Soubor se smaže, až když ho zavře poslední proces.
- když se zavře poslední deskriptor roury, všechna zbývající data v rouře se zruší.
- při skončení procesu se automaticky provede `close()` na všechny deskriptory.

Example: copy files

```
#include <fcntl.h>
#include <unistd.h>

int main(int argc, char *argv[])
{
    char buf[4096];
    int inf, outf;
    ssize_t ilen;

    inf = open(argv[1], O_RDONLY);
    outf = creat(argv[2], 0666);
    while ((ilen = read(inf, buf, sizeof (buf))) > 0)
            write(outf, buf, ilen);

    close(inf); close(outf);
    return (0);
}
```

Working with a named pipe (FIFO)

- it may not be possible to create a FIFO on a distributed filesystem (eg. NFS or AFS)
- you need to know the semantics of opening a FIFO
  - opening a FIFO for just reading will block until a writer (aka producer) shows up, unless one already exists.
  - opening a FIFO for just writing will block until a reader (aka consumer) shows up, unless one already exists.
  - this behavior can be adjusted using a flag `O_NONBLOCK`
- semantics for reading and writing is a bit more complicated, see the notes below this slide.
  - same as for a conventional, unnamed, pipe (will be later)

Setting file position: `lseek()`

`off_t` **lseek**`(int` *`fildes`*`, off_t` *`offset`*`, int` *`whence`*`);`

- will reposition the file offset for reading and writing in an already opened file associated with a file descriptor *fildes*
- based on value of `whence`, the file offset is set to:
  - `SEEK_SET` ... the value of *offset*
  - `SEEK_CUR` ... current position plus *offset*
  - `SEEK_END` ... size of the file plus *offset*
- returns the resulting offset (ie. from the file beginning)
- `lseek(fildes, 0, SEEK_CUR)` only returns the current file position

Change file size: `truncate()`

```
int truncate(const char *path, off_t length);
int ftruncate(int fildes, off_t length);
```

- causes the regular file to be truncated to a size of precisely *length* bytes.
- if the file was larger than *length*, the extra data is lost
- if the file previously was shorter, it is extended, and the extended part reads as null bytes

Descriptor duplication: `dup()`, `dup2()`

`int` **`dup`**`(int` *`fildes`*`);`

- creates a copy of the file descriptor *fildes*, using the lowest-numbered unused descriptor. Returns the new descriptor.
- same as `fcntl(fildes, F_DUPFD, 0);` (will be later)

`int` **`dup2`**`(int` *`fildes`*`, int` *`fildes2`*`);`

- duplicates `fildes` to `fildes2`.
- same as

```
close(fildes2);
fcntl(fildes, F_DUPFD, fildes2);
```

Example: implement shell redirection

- `$ program < in > out 2>> err`

```
close(0);
open("in", O_RDONLY);
close(1);
open("out", O_WRONLY | O_CREAT | O_TRUNC, 0666);
close(2);
open("err", O_WRONLY | O_CREAT | O_APPEND, 0666);
```

- `$ program > out 2>&1`

```
close(1);
open("out", O_WRONLY | O_CREAT | O_TRUNC, 0666);
close(2);
dup(1);
```

Manipulate file descriptors and devices: `fcntl()`, `ioctl()`

`int` **`fcntl`**`(int` *`fildes`*`, int` *`cmd`*`, ...);`

- provides file descriptor duplication, setting descriptor and file status flags, and advisory and possibly mandatory locking.

  Example: close standard error output on program execution (exec call)

  ```
  fcntl(2, F_SETFD, FD_CLOEXEC);
  ```

`int` **`ioctl`**`(int` *`fildes`*`, int` *`request`*`, ... );`

- manipulates the underlying device parameters of special files
- used as a universal interface for manipulating devices. Each device defines a set of requests it understands.

Get file status information: `stat()`

```
int stat(const char *path, struct stat *buf);
int fstat(int fildes, struct stat *buf);
```

- for a file specified by a path or a file descriptor, returns a struct containing file information, such as:
  - `st_ino` ... i-node number
  - `st_dev` ... ID of device containing file
  - `st_uid`, `st_gid` ... user/group ID of owner
  - `st_mode` ... file type and mode
  - `st_size`, `st_blksize`, `st_blocks` ... total size in bytes, preferred blocksize for filesystem I/O, and number of 512B blocks allocated
  - `st_atime`, `st_mtime`, `st_ctime` ... time of last access, last modification, and last i-node modification
  - `st_nlink` ... number of hard links

Get file status information (2)

- for a file type, in `<sys/stat.h>` there are constants `S_IFMT` (bit mask for the file type bit field), `S_IFBLK` (block device), `S_IFCHR` (character device), `S_IFIFO` (FIFO), `S_IFREG` (regular), `S_IFDIR` (directory), `S_IFLNK` (symlink).
- macros for file type checking: `S_ISBLK(m)`, `S_ISCHR(m)`, `S_ISFIFO(m)`, `S_ISREG(m)`, `S_ISDIR(m)`, and `S_ISLNK(m)`.
- access right masks: `S_IRUSR` (owner has read permission), `S_IWGRP` (group has write permission), etc.

`int` **lstat**`(const char *`*path*`, struct stat *`*buf*`);`

- if *path* is a symlink, `stat()` returns informace on the file the symlink refers to. This function returns information about the link itself.

Setting file times

`int` **utime**`(const char *`*path*`, const struct utimbuf *`*times*`);`

- changes file last access and modification times
- cannot change i-node access time (ctime)
- calling process must have write permission for the file

Check permissions for access: `access()`

```
int access(const char *path, int amode);
```

- checks whether the calling process can access the file *path*
- *amode* is an OR-combination of contants
  - `R_OK` ... read permission test
  - `W_OK` ... write permission test
  - `X_OK` ... execution permission test
  - `F_OK` ... file existence test
- in contrast to `stat()`, the result depends on the process's RUID and RGID
- **never use this call, it cannot be used in a safe way. See below.**

Setting file permissions

`int` **chmod**`(const char *`*path*`, mode_t` *mode*`);`

- changes permissions of file *path* to *mode*.
- can be used by the file owner or root

`int` **chown**`(const char *`*path*`, uid_t` *owner*`, gid_t` *group*`);`

- changes file owner and group for *path*. Value of `-1` means do not change that ID.
- only root change change owners so that users could not work around quotas to disown their files
- a regular user can change a group of files he/she owns, and must belong to the target group

File name manipulations

`int` **link**`(const char *`*path1*`, const char *`*path2*`);`

- creates a new link (aka hard link), ie. a directory entry, named *path2* to file *path1*. Hard links cannot span filesystems (use **symlink** for that).

`int` **unlink**`(const char *`*path*`);`

- deletes a name (ie. a directory entry) and after deleting the last link to the file and after closing the file by all processes, delete the file data.

`int` **rename**`(const char *`*old*`, const char *`*new*`);`

- change the file name (ie. one specific link) from *old* to *new*. Works within the same filesystem only.

Symbolic links

`int` **symlink**`(const char *`*path1*`, const char *`*path2*`);`

- make a new symbolic name from *path2* $\rightarrow$ *path1*.
- *path1* may span filesystems, and may not exist at all

`int` **readlink**`(const char *`*path*`, char *`*buf*`, size_t` *bufsz*`);`

- put maximum of *bufsz* bytes from the symlink target path to *buf*
- returns the number of bytes written to *buf*.
- *buf* is **not** terminated by `'\0'`

Working with directories

`int` **mkdir**`(const char *`*path*`, mode_t` *mode*`);`

- attempts to create an empty directory *path* with entries '.' a '..'

`int` **rmdir**`(const char *`*path*`);`

- deletes directory *path*. The directory **must** be empty.

`DIR *`**opendir**`(const char *`*dirname*`);`
`struct dirent *`**readdir**`(DIR *`*dirp*`);`
`int` **closedir**`(DIR *`*dirp*`);`

- sequentially reads directory entries
- structure `dirent` contains:
  - `d_ino` ... i-node number
  - `d_name` ... file name

Example: read a directory

```
int main(int argc, char *argv[])
{
    DIR *d;
    struct dirent *de;

    for(int i = 1; i < argc; i++) {
        d = opendir(argv[i]);
        while(de = readdir(d))
            printf("%s\n", de->d_name);
        closedir(d);
    }
    return (0);
}
```

Change working directory

- every process has its current working directory. When a process refers to a file using a relative path, the reference is interpreted relative to the current working directory of the process.
- the working directory is inherited from the process parent

```
int chdir(const char *path);
int fchdir(int fildes);
```

- changes working directory for the process

```
char *getcwd(char *buf, size_t size);
```

- stores the absolute path to the current working directory to *buf*, its *size* must be at least one byte longer than the path length.

Obsah

- úvod, vývoj UNIXu a C, programátorské nástroje
- základní pojmy a konvence UNIXu a jeho API
- přístupová práva, periferní zařízení, systém souborů
- **manipulace s procesy, spouštění programů**
- signály
- synchronizace a komunikace procesů
- síťová komunikace
- vlákna, synchronizace vláken
- ??? - bude definováno později, podle toho kolik zbyde času

Paměť procesu v uživatelském režimu

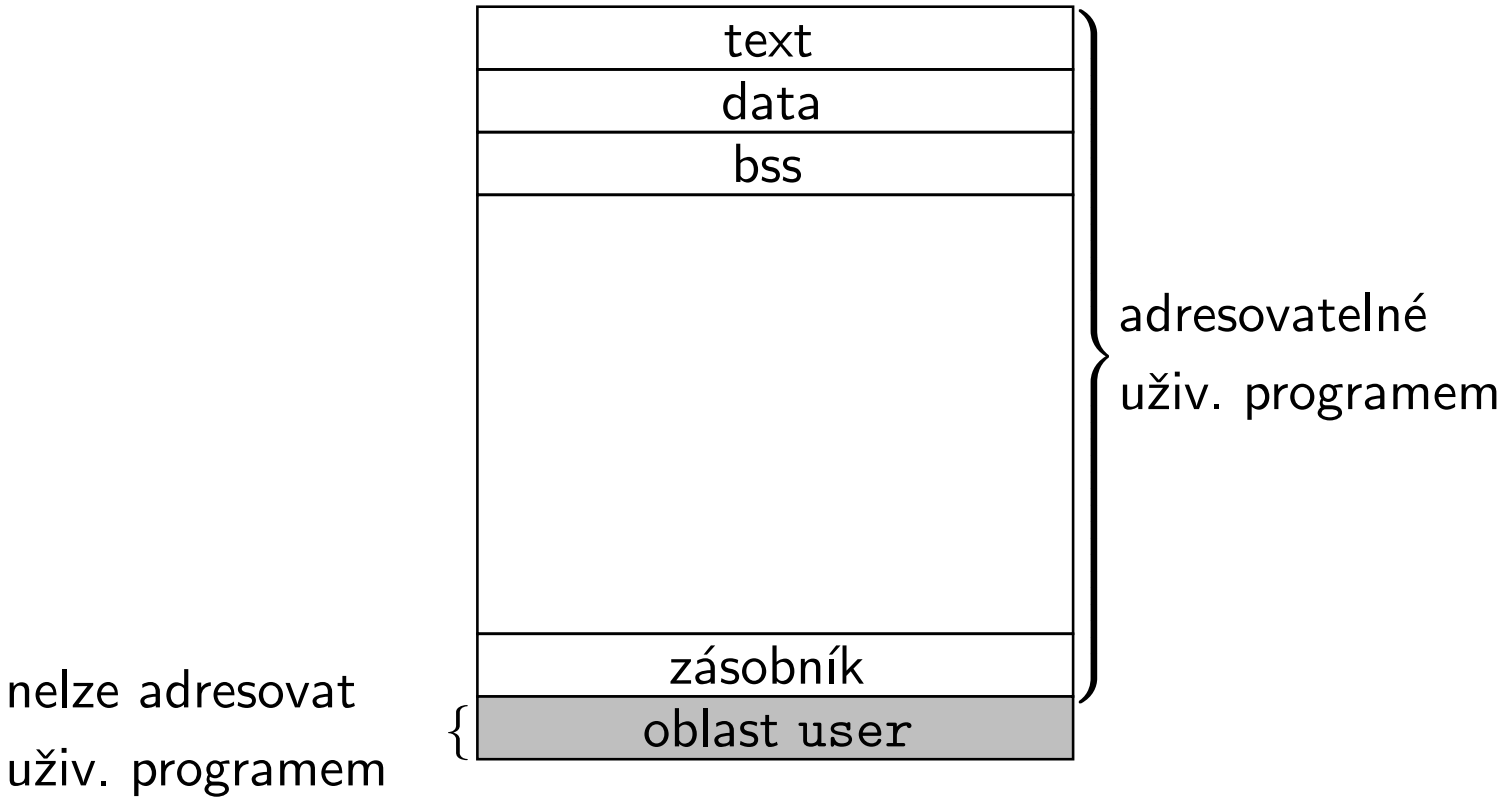

Příklad: Solaris 11 x86 32-bit

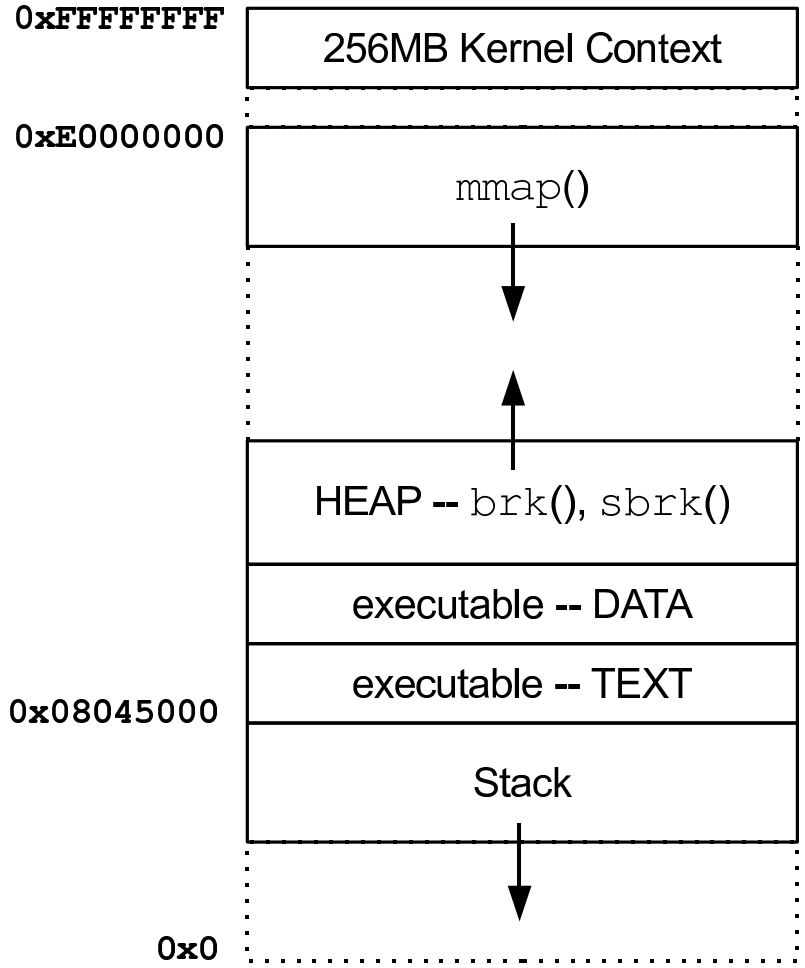

Paměť procesu v režimu jádra

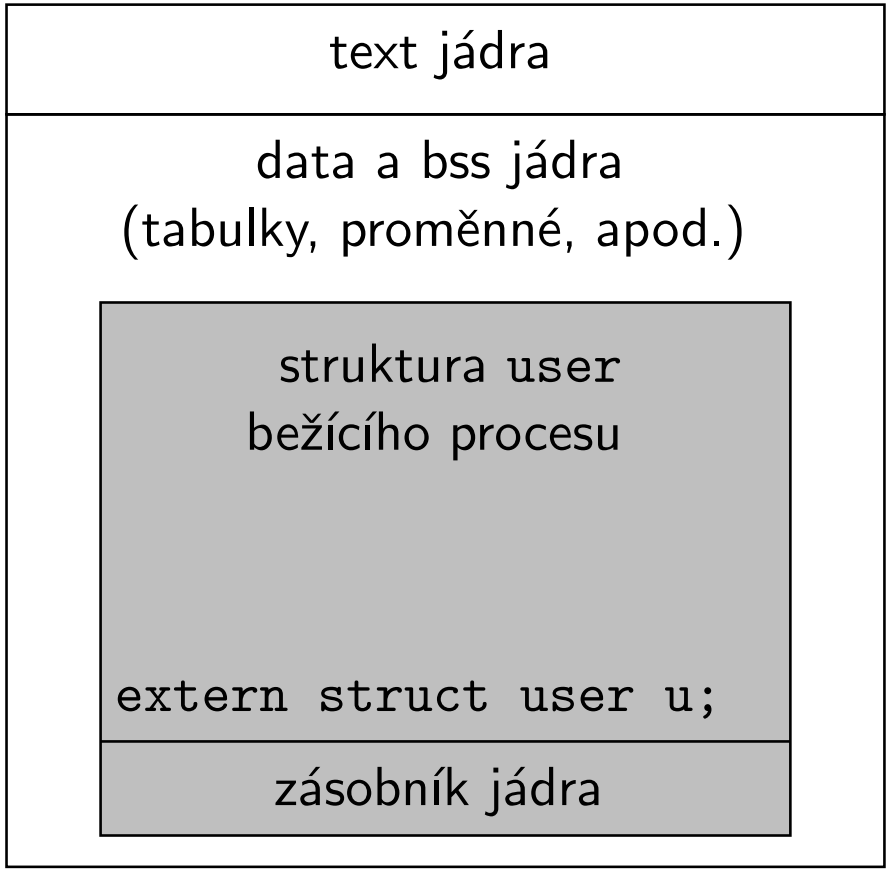

Paměťové segmenty procesu

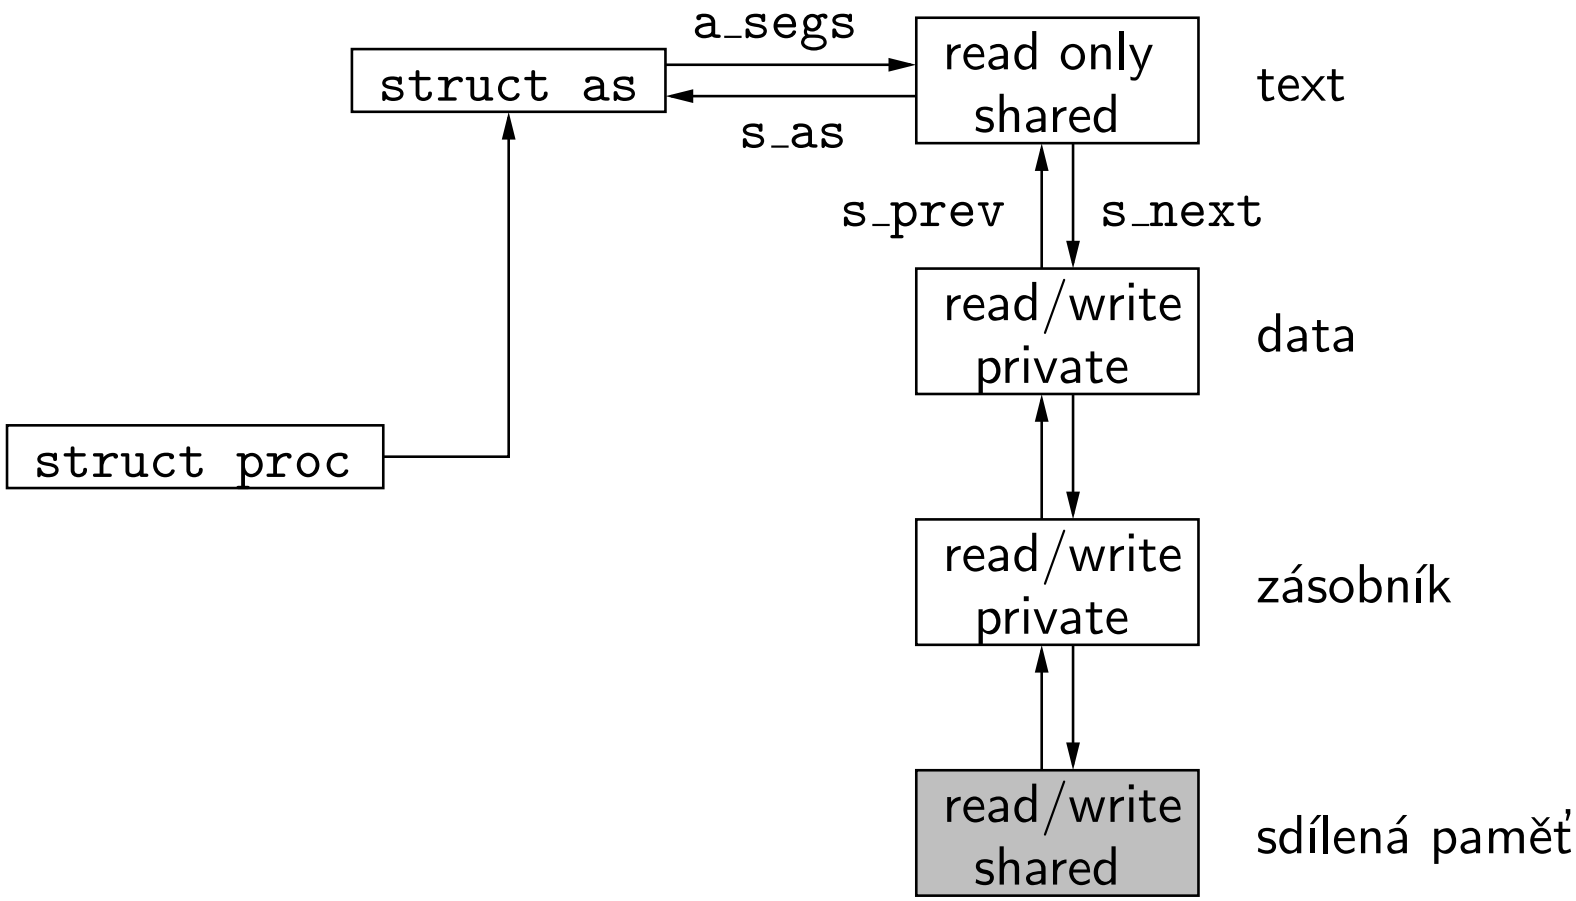

Virtuální paměť

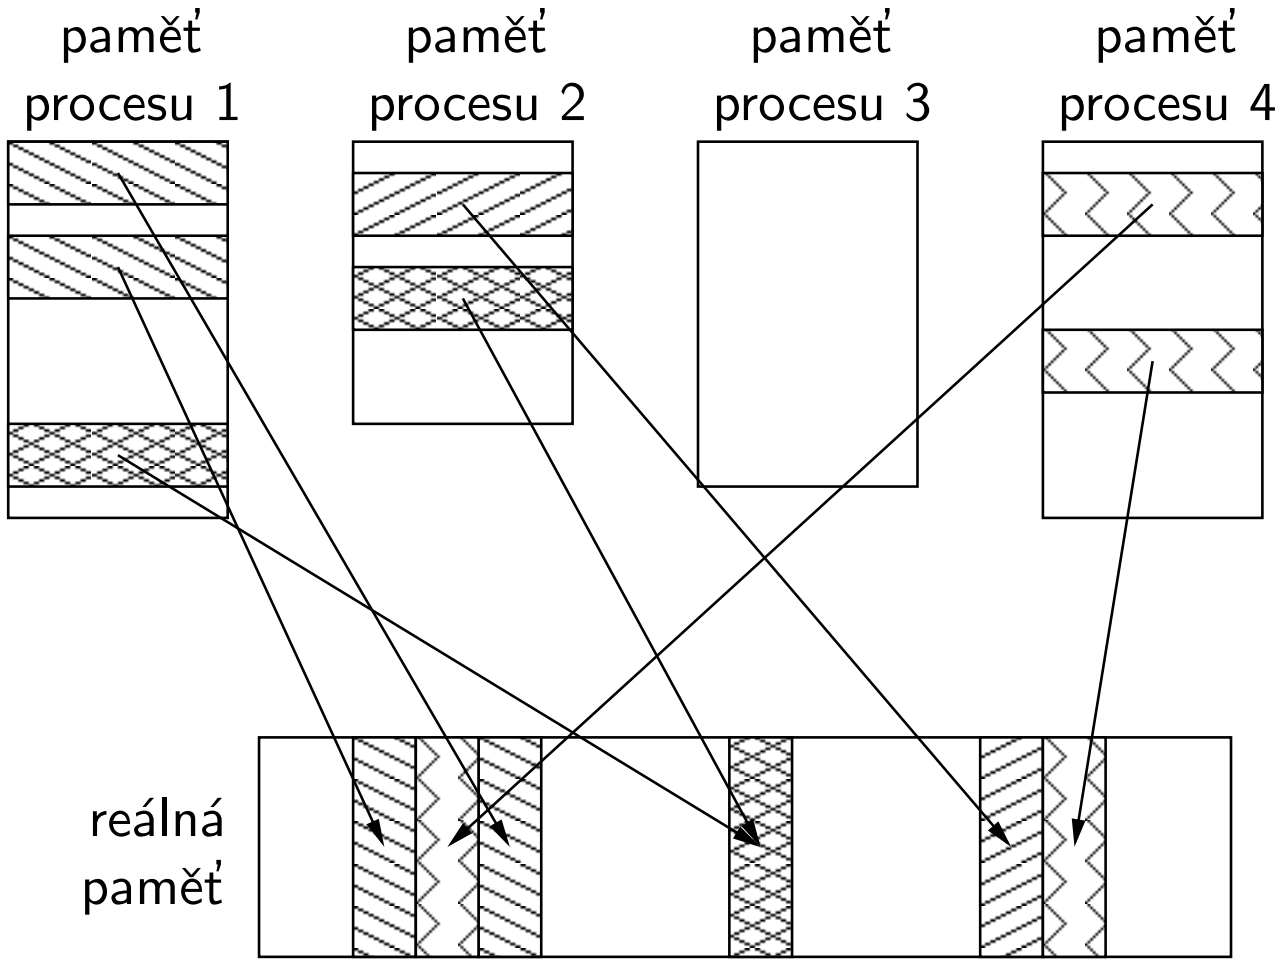

Implementace virtuální paměti

- procesy v UNIXu používají k přístupu do paměti virtuální adresy, které na fyzické adresy převádí hardware ve spolupráci s jádrem systému.
- při nedostatku volné paměti se odkládají nepoužívané úseky paměti do odkládací oblasti (**swap**) na disk.
- před verzí SVR2 se procesem `swapper` (nyní `sched`) odkládaly celé procesy.
- od verze SVR2 se používá stránkování na žádost (**demand paging**) a **copy-on-write**. Stránky se alokují až při prvním použití a privátní stránky se kopírují při první modifikaci. Uvolňování a odkládání jednotlivých stránek provádí proces `pageout`, odkládání celých procesů nastupuje až při kritickém nedostatku paměti.

Stavy procesu

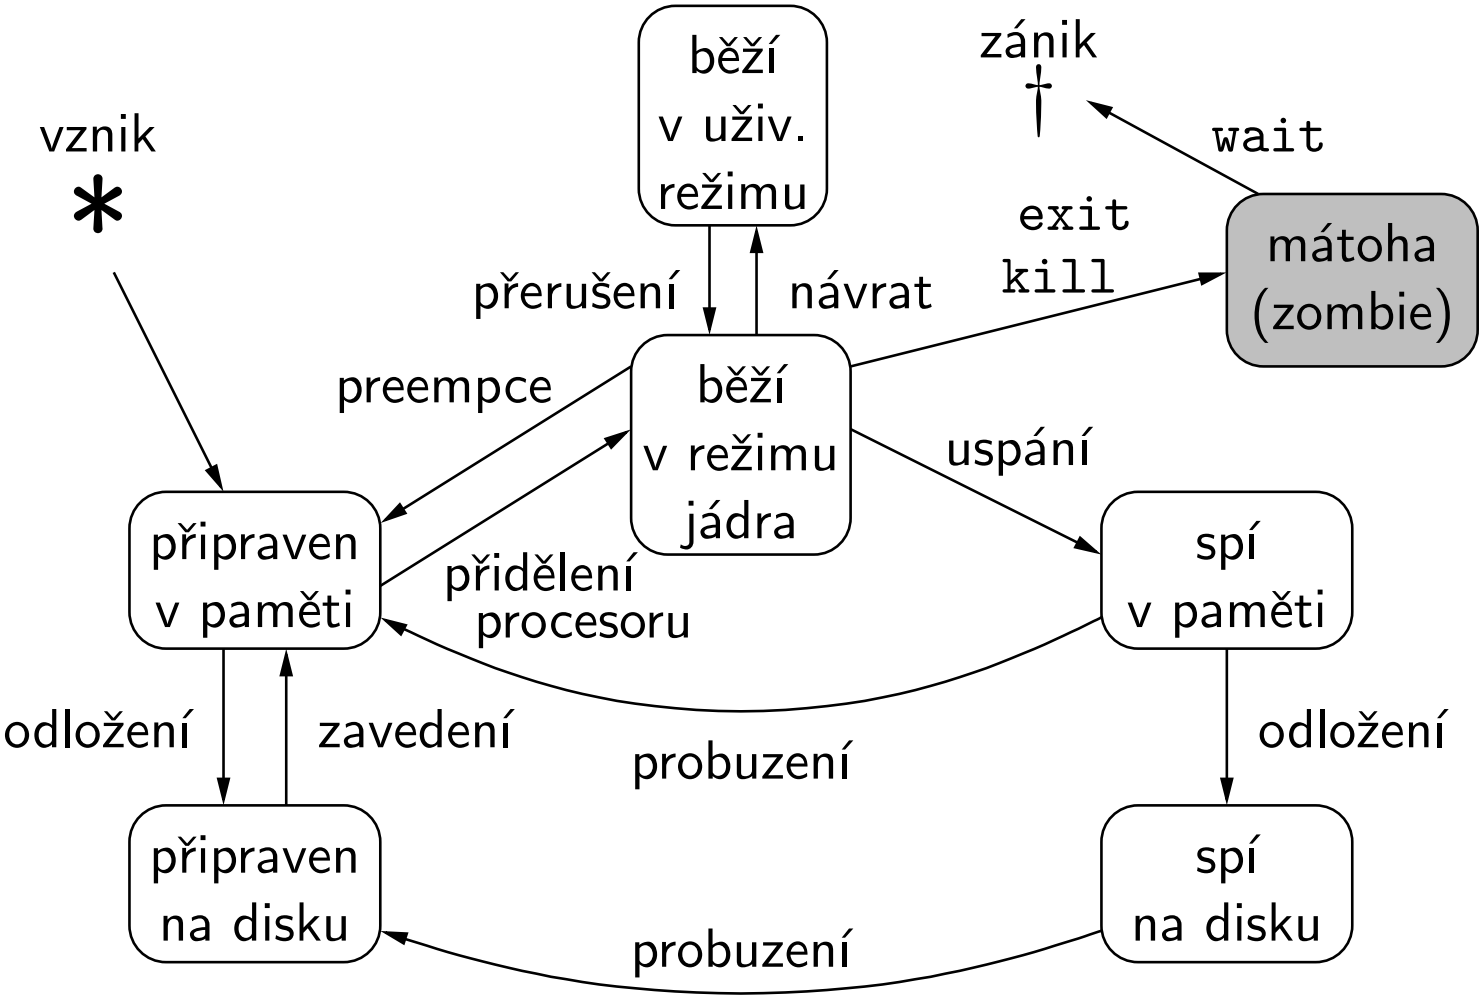

Plánování procesů

- *preemptivní plánování* – jestliže se proces nevzdá procesoru (neuspí se čekáním na nějakou událost), je mu odebrán procesor po uplynutí časového kvanta.
- procesy jsou zařazeny do front podle priority, procesor je přidělen vždy prvnímu připravenému procesu z fronty, která má nejvyšší prioritu.
- v SVR4 byly zavedeny prioritní třídy a podpora procesů reálného času (real-time) s garantovanou maximální dobou odezvy.
- na rozdíl od předchozích verzí znamená v SVR4 vyšší číslo vyšší prioritu.

Prioritní třídy

- **systémová**
  - priorita 60 až 99
  - rezervována pro systémové procesy (`pageout`, `sched`, ...)
  - pevná priorita
- **real-time**
  - priorita 100 až 159
  - pevná priorita
  - pro každou hodnotu priority definováno časové kvantum
- **sdílení času (time-shared)**
  - priorita 0 až 59
  - proměnná dvousložková priorita, pevná uživatelská a proměnná systémová část – pokud proces hodně využívá procesor, je mu snižována priorita (a zvětšováno časové kvantum)

Skupiny procesů, řízení terminálů

- každý proces patří do skupiny procesů, tzv. *process group*
- každá skupina může mít vedoucí proces, tzv. *group leader*
- každý proces může mít řídící terminál (je to obvykle login terminál), tzv. *controlling terminal*
- speciální soubor `/dev/tty` je asociován s řídícím terminálem každého procesu
- každý terminál je asociován se skupinou procesů, tato skupina se nazývá řídící skupina (*controlling group*)
- kontrola jobů (*job control*) je mechanizmus, jak pozastavovat a probouzet skupiny procesů a řídit jejich přístup k terminálům
- *session* (relace) je kolekce skupin procesů vytvořená pro účely řízení jobů

Identifikace procesu

`pid_t` **`getpid`**`(void);`

- vrací proces ID volajícího procesu.

`pid_t` **`getpgrp`**`(void);`

- vrací ID skupiny procesů, do které patří volající proces.

`pid_t` **`getppid`**`(void);`

- vrací proces ID rodiče.

`pid_t` **`getsid`**`(pid_t` *`pid`*`);`

- vrací group ID vedoucího procesu session (sezení, terminálové relace) pro proces `pid` (0 znamená pro volající proces)

Nastavení skupiny/sezení

`int` **setpgid**`(pid_t` *pid*`, pid_t` *pgid*`);`

- nastaví process group ID procesu s pid na pgid.

`pid_t` **setsid**`(void);`

- vytvoří novou session, volající proces se stane vedoucím sezení i skupiny procesů.

Vytvoření procesu: `fork()`

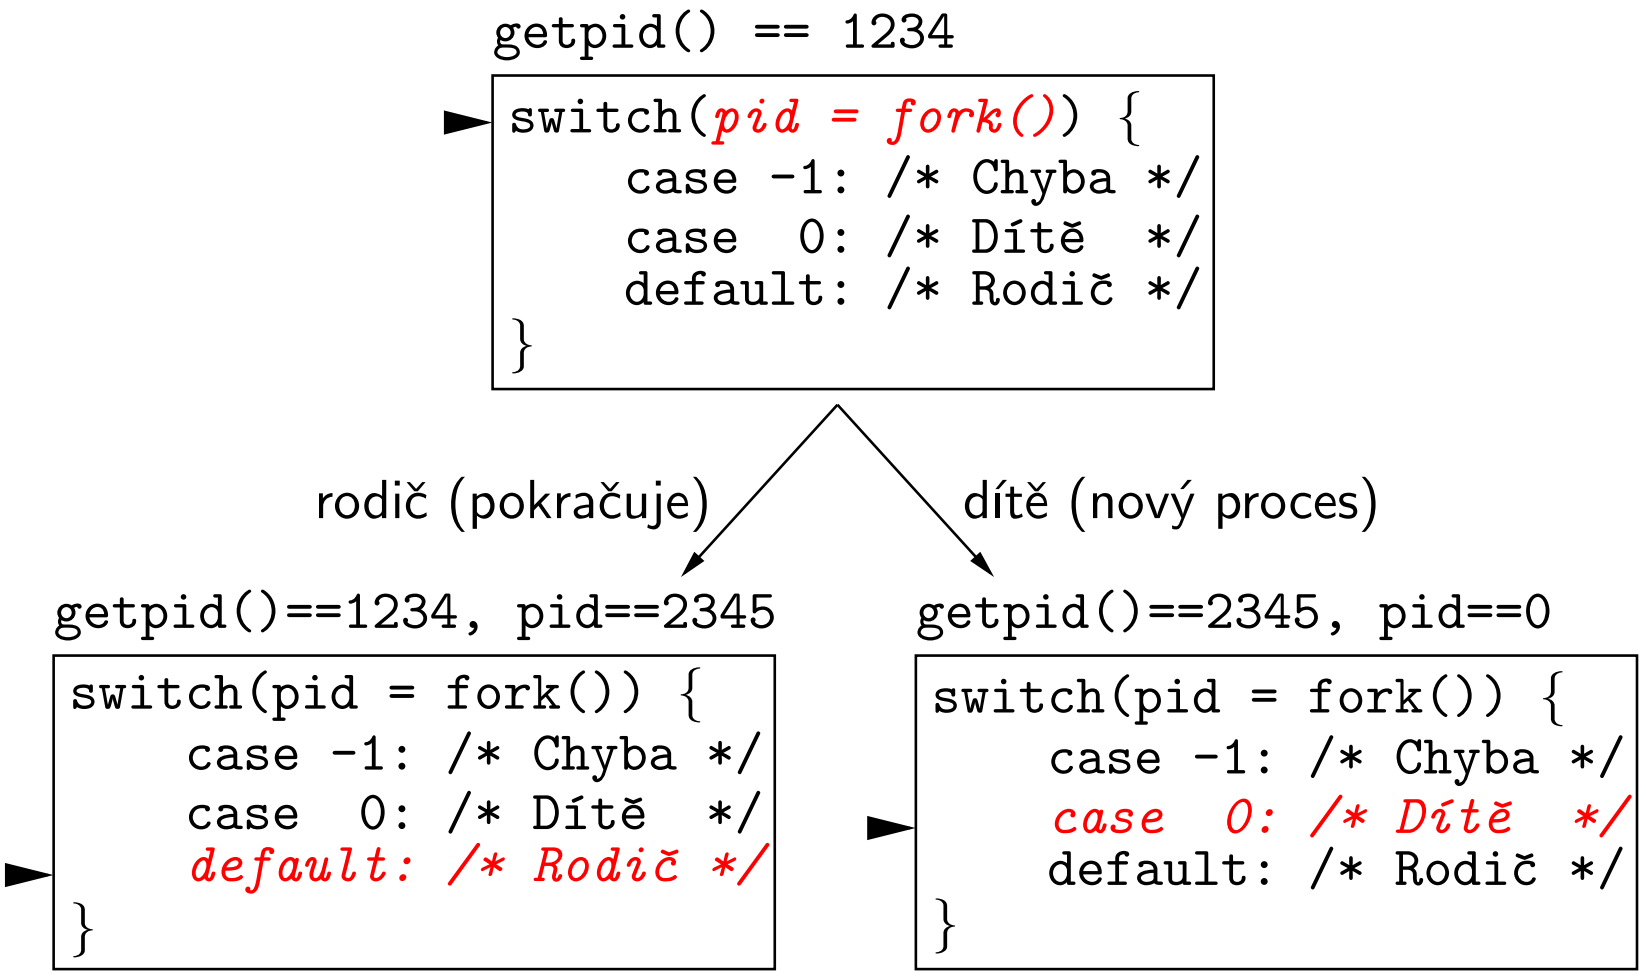

Spuštění programu: `exec`

```
extern char **environ;
int execl(const char *path, const char *arg0, ... );
```

- spustí program definovaný celou cestou `path`, další argumenty se pak předají programu v parametrech `argc` a `argv` funkce `main`. Seznam argumentů je ukončen pomocí `(char *)0`, tj. `NULL`. `arg0` by měl obsahovat jméno programu (tj. ne celou cestu)
- úspěšné volání `execl` se nikdy nevrátí, protože spuštěný program zcela nahradí dosavadní adresový prostor procesu.
- program dědí proměnné prostředí, tj. obsah `environ`.
- handlery signálů se nahradí implicitní obsluhou
- zavřou se deskriptory souborů, které mají nastavený příznak `FD_CLOEXEC` (implicitně není nastaven).

Varianty služby exec

```
int execv(const char *path, char *const argv[]);
```

- obdoba `execl()`, ale argumenty jsou v poli `argv`, jehož poslední prvek je `NULL`.

```
int execle(const char *path, const char *arg0, ... ,
           char *const envp[]);
```

- obdoba `execl()`, ale místo `environ` se použije `envp`.

```
int execve(const char *path, char *const argv[],
           char *const envp[]);
```

- obdoba `execv()`, ale místo `environ` se použije `envp`.

```
int execlp(const char *file, const char *arg0, ...);
int execvp(const char *file, char *const argv[]);
```

- obdoby `execl()` a `execv()`, ale pro hledání spustitelného souboru se použije proměnná `PATH`.

Formát spustitelného souboru

- **Common Object File Format (COFF)** – starší System V
- **Extensible Linking Format (ELF)** – nový v SVR4
- často se mluví o **a.out** formátu, protože tak se jmenuje (pokud není použit přepínač `-o`) výstup linkeru.
- Formát ELF:

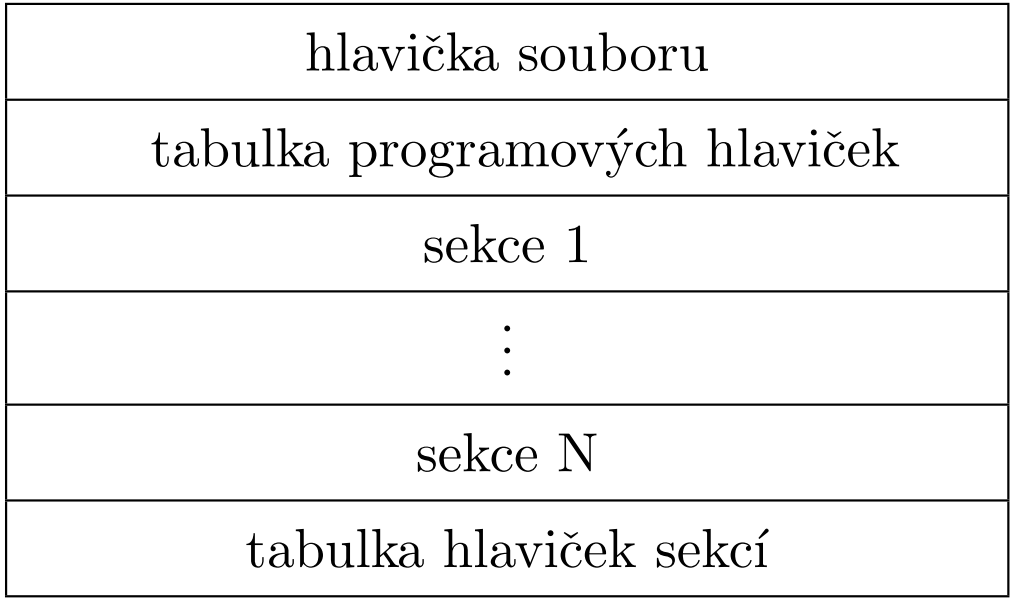

Ukončení procesu

`void` **exit**`(int` *status*`);`

- ukončí proces s návratovým kódem `status`.
- nikdy se nevrátí na instrukci následující za voláním.

`pid_t` **wait**`(int *`*stat_loc*`);`

- počká, až skončí některý synovský proces, vrátí jeho PID a do `stat_loc` uloží návratový kód, který lze dále testovat:
  - `WIFEXITED(stat_val)` ... proces volal `exit()`
  - `WEXITSTATUS(stat_val)` ... argument `exit()`
  - `WIFSIGNALED(stat_val)` ... proces dostal signál
  - `WTERMSIG(stat_val)` ... číslo signálu
  - `WIFSTOPPED(stat_val)` ... proces pozastaven
  - `WSTOPSIG(stat_val)` ... číslo signálu

`pid_t` **waitpid**`(pid_t` *pid*`, int *`*stat_loc*`, int` *opts*`);`

- čekání na jeden proces.

Příklad: spuštění programu a čekání

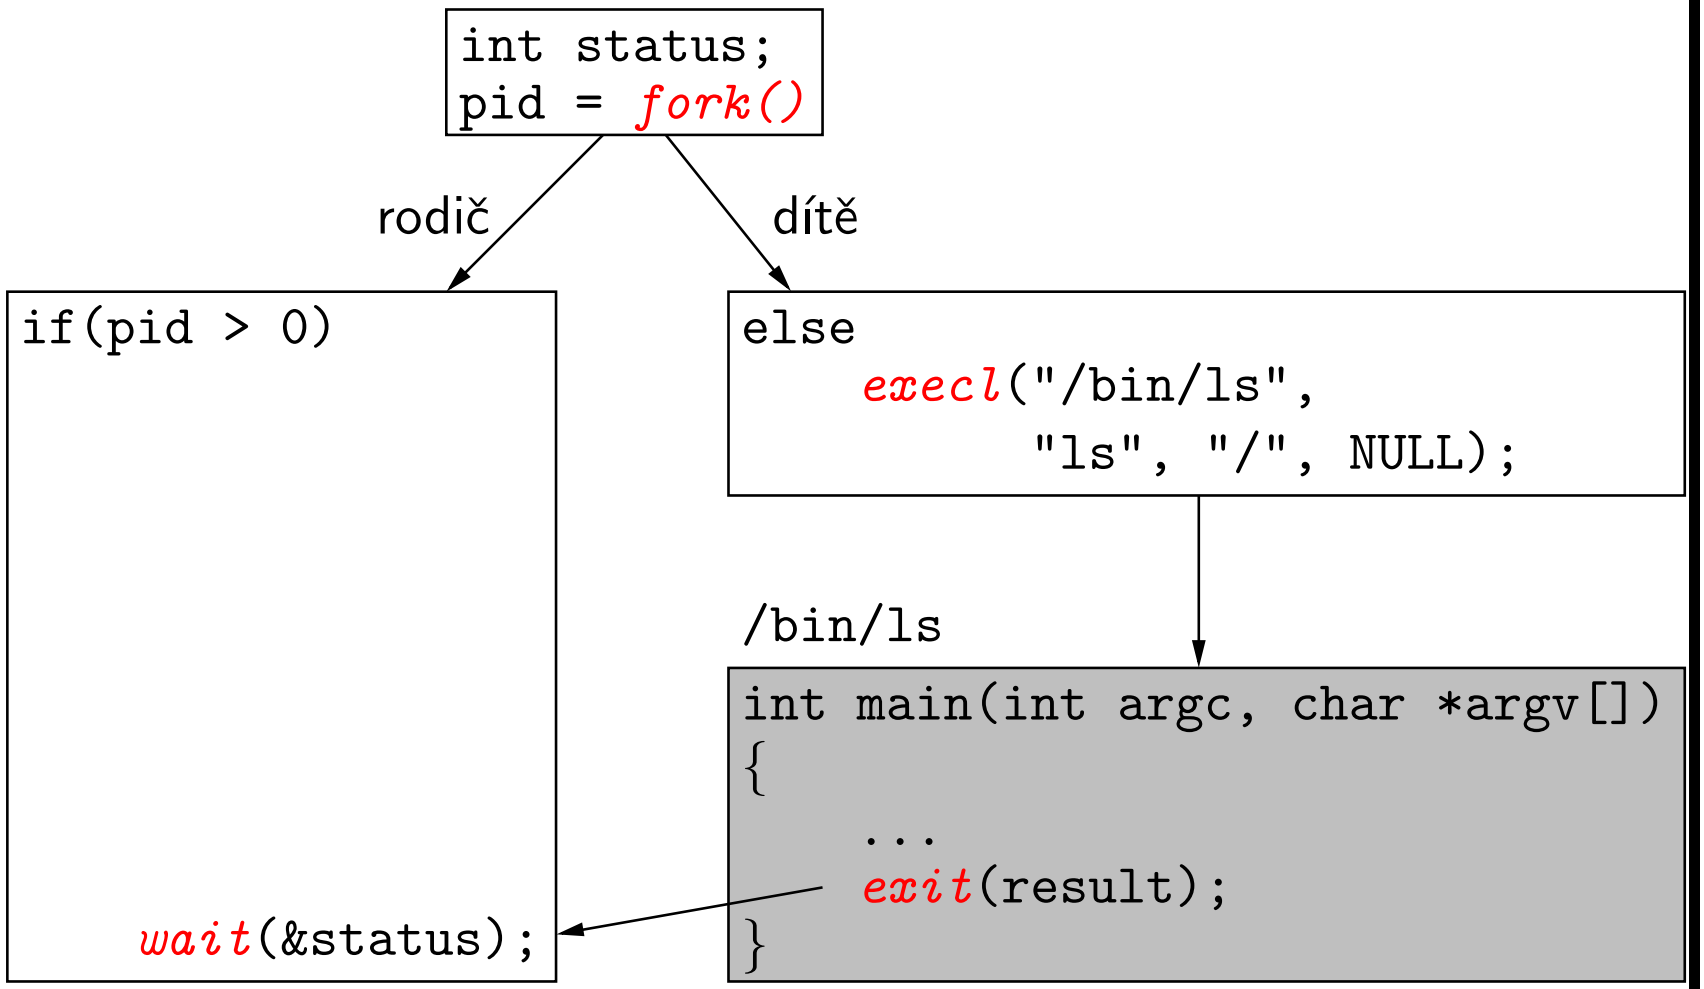

Roura: `pipe()`

`int` **pipe**`(int` *fildes*`[2]);`

- vytvoří rouru a dva deskriptory
  - `fildes[0]` ... čtení z roury
  - `fildes[1]` ... zápis do roury
- roura zajišťuje synchronizaci čtení a zápisu:
  - zapisující proces se zablokuje, když je roura plná,
  - čtoucí proces se zablokuje, když je roura prázdná.
- čtoucí proces přečte konec souboru (tj. `read()` vrátí `0`), pokud jsou uzavřeny všechny kopie `fildes[1]`.
- pojmenovaná roura (vytvořená voláním `mkfifo()`) funguje stejně, ale má přidělené jméno v systému souborů a mohou ji tedy používat libovolné procesy.

Příklad: roura mezi dvěma procesy

shell: `ls / | more`

```
int pd[2];
pipe(pd);
switch(fork()) {
```

producent (dítě)

```
case 0:
  close(1);
  dup(pd[1]);
  close(pd[0]);
  close(pd[1]);
  execl("/bin/ls", "ls",
        "/", NULL);
```

konzument (rodič)

```
default:
  close(0);
  dup(pd[0]);
  close(pd[0]);
  close(pd[1]);
  execl("/bin/more",
        "more", NULL);
```

Sdílená paměť – úvod

- pajpy a soubory jako metody meziprocesové komunikace vyžadují systémová volání
- výhoda: procesy nemohou poškodit adresový prostor jiného procesu
- nevýhoda: velká režie pro systémová volání, typicky **read**, **write**
- sdílená paměť je namapování části paměti do adresového prostoru více procesů
- odstranění nevýhody, ztráta dosavadní výhody
- synchronizace přístupu do sdílené paměti
  - System V semafory
  - POSIX semafory bez nutnosti systémového volání v běžném případě

Mapování souborů do paměti (1)

```
void *mmap(void *addr, size_t len, int prot, int flags,
           int fildes, off_t off);
```

- do paměťového prostoru procesu od adresy `addr` (`0` ... adresu přidělí jádro) namapuje úsek délky `len` začínající na pozici `off` souboru reprezentovaného deskriptorem `fildes`.
- vrací adresu namapovaného úseku nebo `MAP_FAILED`.
- v `prot` je OR-kombinace `PROT_READ` (lze číst), `PROT_WRITE` (lze zapisovat), `PROT_EXEC` (lze spouštět), nebo `PROT_NONE` (nelze k datům přistupovat).
- ve `flags` je OR-kombinace `MAP_PRIVATE` (změny jsou privátní pro proces, neukládají se do souboru), `MAP_SHARED` (změny se ukládají do souboru), `MAP_FIXED` (jádro nezmění addr).

Mapování souborů do paměti (2)

`int` **msync**`(void *`*addr*`, size_t` *len*`, int` *flags*`);`

- zapíše změněné stránky v úseku len bajtů od adresy addr do souboru. Hodnota flags je OR-kombinace
  - `MS_ASYNC` ... asynchronní zápis
  - `MS_SYNC` ... synchronní zápis
  - `MS_INVALIDATE` ... zrušit namapovaná data, která se liší od obsahu souboru

`int` **munmap**`(void *`*addr*`, size_t` *len*`);`

- zapíše změny, zruší mapování v délce `len` od adresy `addr`.

`int` **mprotect**`(void *`*addr*`, size_t` *len*`, int` *prot*`);`

- změní přístupová práva k namapovanému úseku souboru. Hodnoty prot jsou stejné jako u `mmap()`.

Příklad: mapování souborů do paměti

```
int main(int argc, char *argv[])
{
    int fd, fsz; char *addr, *p1, *p2, c;

    fd = open(argv[1], O_RDWR);
    fsz = lseek(fd, 0, SEEK_END);
    p1 = addr = mmap(0, fsz, PROT_READ|PROT_WRITE,
                     MAP_SHARED, fd, 0);
    p2 = p1 + fsz - 1;
    while(p1<p2) {
        c = *p1; *p1++ = *p2; *p2-- = c;
    }
    munmap(addr, fsz);
    close(fd);
    return (0);
}
```

Dynamický přístup ke knihovnám

`void *`**dlopen**`(const char *`*file*`, int` *mode*`);`

- zpřístupní knihovnu v souboru `file`, vrátí **handle** nebo `NULL`.
- v *mode* je OR-kombinace `RTLD_NOW` (okamžité relokace), `RTLD_LAZY` (odložené relokace), `RTLD_GLOBAL` (symboly budou globálně dostupné), `RTLD_LOCAL` (nebudou globálně dostupné).

`void *`**dlsym**`(void *`*handle*`, const char *`*name*`);`

- vrátí adresu symbolu zadaného jména z knihovny.

`int` **dlclose**`(void *`*handle*`);`

- ukončí přístup ke knihovně.

`char *`**dlerror**`(void);`

- vrátí textový popis chyby při práci s knihovnami.

Příklad: zpřístupnění knihovny

```
char *err;
void *handle;
double y, x = 1.3;
double (*fun)(double);
char *libname = "libm.so", *fn_name = "sin";

if ((handle = dlopen(libname, RTLD_NOW)) == NULL) {
        fprintf(stderr, "%s\n", dlerror()); exit(1);
}
fun = dlsym(handle, fn_name);
if ((err = dlerror()) != NULL)
        fprintf(stderr, "%s\n", err); exit(1);
y = fun(x);
dlclose(handle);
```

Obsah

- úvod, vývoj UNIXu a C, programátorské nástroje
- základní pojmy a konvence UNIXu a jeho API
- přístupová práva, periferní zařízení, systém souborů
- manipulace s procesy, spouštění programů
- **signály**
- synchronizace a komunikace procesů
- síťová komunikace
- vlákna, synchronizace vláken
- ??? - bude definováno později, podle toho kolik zbyde času

Signály

- informují proces o výskytu určité události
- na uživatelské úrovni zpřístupňují mechanizmy přerušení
- kategorie signálů:
  - **chybové události** generované běžícím procesem, např. pokus o přístup mimo přidělenou oblast paměti (`SIGSEGV`)
  - **asynchronní události** vznikající mimo proces, např. signál od jiného procesu, vypršení nastaveného času (`SIGALRM`), odpojení terminálu (`SIGHUP`), stisk `Ctrl-C` (`SIGINT`)
- nejjednodušší mechanizmus pro komunikaci mezi procesy – nesou pouze informaci o tom, že nastala nějaká událost.
- většinou se zpracovávají asynchronně – příchod signálu přeruší běh procesu a vyvolá se obslužná funkce, tzv. *handler signálu*

Poslání signálu

`int` **kill**`(pid_t` *pid*`, int` *sig*`);`

- pošle signál s číslem `sig` procesu (nebo skupině procesů) podle hodnoty `pid`:
  - `> 0` ... procesu s číslem pid
  - `== 0` ... všem procesům ve stejné skupině
  - `== -1` ... všem procesům, kromě systémových
  - `< -1` ... procesům ve skupině `abs(pid)`
- `sig == 0` znamená, že se pouze zkontroluje oprávnění poslat signál, ale žádný signál se nepošle.
- právo procesu poslat signál jinému procesu závisí na UID obou procesů.

Ošetření signálů

- pokud proces neřekne jinak, provede se v závislosti na konkrétním signálu implicitní akce, tj. buď:
  - ukončení procesu (**exit**)
  - ukončení procesu plus coredump (**core**)
  - ignorování signálu (**ignore**)
  - pozastavení procesu (**stop**)
  - pokračování pozastaveného procesu (**continue**)
- proces také může nastavit ignorování signálu
- nebo signál ošetření uživatelsky definovanou funkcí (**handler**), po návratu z handleru proces pokračuje od místa přerušení

signály `SIGKILL` a `SIGSTOP` vždy vyvolají implicitní akci (zrušení, resp. pozastavení).

Přehled signálů (1)

signály je možné logicky rozdělit do několika skupin...

detekované chyby:

`SIGBUS`	přístup k nedef. části paměťového objektu (core)
`SIGFPE`	chyba aritmetiky v pohyblivé čárce (core)
`SIGILL`	nepovolená instrukce (core)
`SIGPIPE`	zápis do roury, kterou nikdo nečte (exit)
`SIGSEGV`	použití nepovolené adresy v paměti (core)
`SIGSYS`	chybné systémové volání (core)
`SIGXCPU`	překročení časového limitu CPU (core)
`SIGXFSZ`	překročení limitu velikosti souboru (core)

Přehled signálů (2)

generované uživatelem nebo aplikací:

`SIGABRT`	ukončení procesu (core)
`SIGHUP`	odpojení terminálu (exit)
`SIGINT`	stisk speciální klávesy `Ctrl-C` (exit)
`SIGKILL`	zrušení procesu (exit, **nelze ošetřit ani ignorovat**)
`SIGQUIT`	stisk speciální klávesy `Ctrl-\` (core)
`SIGTERM`	zrušení procesu (exit)
`SIGUSR1`	uživatelsky definovaný signál 1 (exit)
`SIGUSR2`	uživatelsky definovaný signál 2 (exit)

Přehled signálů (3)

job control:

`SIGCHLD`	změna stavu synovského procesu (ignore)
`SIGCONT`	pokračování pozastaveného procesu (continue)
`SIGSTOP`	pozastavení (stop, **nelze ošetřit ani ignorovat**)
`SIGTSTP`	pozastavení z terminálu `Ctrl-Z` (stop)
`SIGTTIN`	čtení z terminálu procesem na pozadí (stop)
`SIGTTOU`	zápis na terminál procesem na pozadí (stop)

- součástí nepovinného POSIX rozšíření, existují pouze když v `<unistd.h>` je definováno makro `_POSIX_JOB_CONTROL`

Přehled signálů (4)

časovače:

`SIGALRM`	plánované časové přerušení (exit)
`SIGPROF`	vypršení profilujícího časovače (exit)
`SIGVTALRM`	vypršení virtuálního časovače (exit)

různé:

`SIGPOLL`	testovatelná událost (exit)
`SIGTRAP`	ladicí přerušení (core)
`SIGURG`	urgentní událost na soketu (ignore)

Nastavení obsluhy signálů

`int` **sigaction**`(int` *sig*`, const struct sigaction *`*act*`, struct sigaction *`*oact*`);`

- nastaví obsluhu signálu `sig` podle `act` a vrátí předchozí nastavení v `oact`.
- obsah struktury `sigaction`:
  - `void (*`*sa_handler*`)(int)` ... `SIG_DFL`, `SIG_IGN`, nebo adresa handleru
  - `sigset_t` *sa_mask* ... signály blokované v handleru, navíc je blokován signál `sig`
  - `int` *sa_flags* ... `SA_RESETHAND` (při vstupu do handleru nastavit `SIG_DFL`), `SA_RESTART` (restartovat přerušená systémová volání), `SA_NODEFER` (neblokovat signál `sig` během obsluhy)

Příklad: časově omezený vstup

```
void handler(int sig)
{ write(2," !!! TIMEOUT !!! \n", 17); }

int main(void)
{
    char buf[1024]; struct sigaction act; int sz;
    act.sa_handler = handler;
    sigemptyset(&act.sa_mask);
    act.sa_flags = 0;
    sigaction(SIGALRM, &act, NULL);
    alarm(5);
    sz = read(0, buf, 1024);
    alarm(0);
    if (sz > 0)
        write(1, buf, sz);
    return (0);
}
```

Blokování signálů

- blokované signály budou procesu doručeny a zpracovány až po odblokování.

```
int sigprocmask(int how, const sigset_t *set,
                sigset_t *oset);
```

- nastaví masku blokovaných signálů a vrátí starou masku.
- *how* – `SIG_BLOCK` pro přidání signálů co se mají blokovat, pro odebrání `SIG_UNBLOCK`, pro kompletní změnu masky `SIG_SETMASK`
- pro manipulaci s maskou signálů slouží funkce: `sigaddset()`, `sigdelset()`, `sigemptyset()`, `sigfillset()`, `sigismember()`

```
int sigpending(sigset_t *set);
```

- vrátí čekající zablokované signály.

Příklad: blokování signálů

```
sigset_t sigs, osigs; struct sigaction sa;
sigfillset(&sigs); sigprocmask(SIG_BLOCK, &sigs, &osigs);
switch(cpid = fork()) {
    case -1: /* Chyba */
        sigprocmask(SIG_SETMASK, &osigs, NULL);
        ...
    case 0: /* Synovský proces */
        sa.sa_handler = h_cld; sigemptyset(&sa.sa_mask);
        sa.sa_flags = 0;
        sigaction(SIGINT, &sa, NULL);
        sigprocmask(SIG_SETMASK, &osigs, NULL);
        ...
    default: /* Rodičovský proces */
        sigprocmask(SIG_SETMASK, &osigs, NULL);
        ...
}
```

Čekání na signál

`int` **pause**`(void);`

- pozastaví volající proces do příchodu (neblokovaného) signálu

`int` **sigsuspend**`(const sigset_t *`*sigmask*`);`

- jako `pause()`, ale navíc po dobu čekání masku blokovaných signálů změní na `sigmask`

`int` **sigwait**`(const sigset_t *`*set*`, int *`*sig*`);`

- čeká na příchod signálu z množiny `set` (tyto signály musí být předtím zablokované), číslo signálu vrátí v `sig`. Vrací 0 nebo číslo chyby.
- nevolá se handler signálu (to ale není v normě jednoznačně definováno)

Obsah

- úvod, vývoj UNIXu a C, programátorské nástroje
- základní pojmy a konvence UNIXu a jeho API
- přístupová práva, periferní zařízení, systém souborů
- manipulace s procesy, spouštění programů
- signály
- **synchronizace a komunikace procesů**
- síťová komunikace
- vlákna, synchronizace vláken
- ??? - bude definováno později, podle toho kolik zbyde času

Problém: konflikt při sdílení dat

- máme strukturu `struct { int a, b; } shared;`
- ```
  for( ; ; ) {
      /* neatomická operace */
      a = shared.a; b = shared.b;
      if (a != b) printf("NEKONZISTENTNÍ STAV");
      /* neatomická operace */
      shared.a = val; shared.b = val;
  }
  ```
- jestliže tento cyklus spustíme ve dvou různých procesech (nebo vláknech), které obě sdílejí stejnou strukturu shared a mají různé hodnoty `val`, bude docházet ke konfliktům.
- příčina: operace na zvýrazněných řádcích nejsou atomické.
  ```

Scénář konfliktu

Procesy **A**`(val==1)` a **B**`(val==2)`

1. počáteční stav struktury
2. proces **A** zapíše do položky `a`
3. proces **B** zapíše do položky `a`
4. proces **B** zapíše do položky `b`
5. proces **A** zapíše do položky `b`
6. struktura je v nekonzistentním stavu a jeden z procesů to zjistí.

	`a`	`b`
1.	?	?
2.	1	?
3.	2	?
4.	2	2
5.	2	1

Řešení: vzájemné vyloučení procesů

- je potřeba zajistit atomicitu operací nad strukturou, tzn. jeden proces provádí modifikaci a dokud neuvede strukturu do konzistentního stavu, druhý proces s ní nemůže manipulovat.

Procesy **A**`(val==1)` a **B**`(val==2)`

		`a`	`b`
1.	počáteční stav struktury	?	?
2.	proces **A** zapíše do položky `a`	1	?
3.	proces **B** musí čekat	1	?
4.	proces **A** zapíše do položky `b`	1	1
5.	proces **B** zapíše do položky `a`	2	1
6.	proces **B** zapíše do položky `b`	2	2
7.	Struktura je v konzistentním stavu.		

Problém: konflikt zapisovatelů a čtenářů

- několik běžících procesů zapisuje protokol o své činnosti do společného log-souboru. Nový záznam je připojen vždy na konec souboru.
- pokud zápis záznamu není proveden atomickou operací, může dojít k promíchání více současně zapisovaných záznamů.
- zapisovat smí vždy pouze jeden proces.
- další procesy čtou data z log-souboru.
- při přečtení právě zapisovaného záznamu obdržíme nesprávná (neúplná) data.
- během operace zápisu ze souboru nelze číst. Když nikdo nezapisuje, může více procesů číst současně.

Řešení: zamykání souborů

- zapisující proces zamkne soubor pro zápis. Ostatní procesy (zapisovatelé i čtenáři) se souborem nemohou pracovat a musí čekat na odemčení zámku.
- čtoucí proces zamkne soubor pro čtení. Zapisovatelé musí čekat na odemčení zámku, ale ostatní čtenáři mohou také zamknout soubor pro čtení a číst data.
- v jednom okamžiku může být na souboru aktivní nejvýše jeden zámek pro zápis nebo libovolně mnoho zámků pro čtení, ale ne oba typy zámků současně.
- z důvodu efektivity by každý proces měl držet zámek co nejkratší dobu a pokud možno nezamykat celý soubor, ale jen úsek, se kterým pracuje. Preferované je pasivní čekání, aktivní čekání je vhodné jen na velmi krátkou dobu.

Synchronizační mechanismy

- teoretické řešení – algoritmy vzájemného vyloučení (Dekker 1965, Peterson 1981)
- zákaz přerušení (na 1 CPU stroji), speciální *test-and-set* instrukce
- **lock-soubory**
- nástroje poskytované operačním systémem
  - **semafory** (součást System V IPC)
  - **zámky pro soubory** (`fcntl()`, `flock()`)
  - synchronizace vláken: **mutexy** (ohraničují kritické sekce, pouze jedno vlákno může držet mutex), **podmínkové proměnné** (zablokují vlákno, dokud jiné vlákno nesignalizuje změnu podmínky), **read-write zámky** (sdílené a exkluzivní zámky, podobně jako pro soubory)

Lock-soubory

- pro každý sdílený zdroj existuje dohodnuté jméno souboru. Zamčení zdroje se provede vytvořením souboru, odemčení smazáním souboru. Každý proces musí otestovat, zda soubor existuje, a pokud ano, tak počkat.

```
void lock(char *lockfile) {
    while( (fd = open(lockfile,
                      O_RDWR|O_CREAT|O_EXCL, 0600)) == -1)
        sleep(1);  /* Čekáme ve smyčce na odemčení */
    close(fd);
}

void unlock(char *lockfile) {
    unlink(lockfile);
}
```

Zamykání souborů: `fcntl()`

`int` **`fcntl`**`(int` *`fildes`*`, int` *`cmd`*`, ...);`

- k nastavení zámků pro soubor `fildes` se používá `cmd`:
  - `F_GETLK` ... vezme popis zámku z třetího argumentu a nahradí ho popisem existujícího zámku, který s ním koliduje
  - `F_SETLK` ... nastaví nebo zruší zámek popsaný třetím argumentem, pokud nelze zámek nastavit, ihned vrací -1
  - `F_SETLKW` ... jako `F_SETLK`, ale uspí proces, dokud není možné nastavit zámek (`W` znamená "wait")
- třetí argument obsahuje popis zámku a je typu ukazatel na `struct flock`

Zamykání souborů: `struct flock`

- `l_type` ... typ zámku
  - `F_RDLCK` ... sdílený zámek (pro čtení), více procesů
  - `F_WRLCK` ... exkluzivní zámek (pro zápis), jeden proces
  - `F_UNLCK` ... odemčení
- `l_whence` ... jako u `lseek()`, tj. `SEEK_SET`, `SEEK_CUR`, `SEEK_END`
- `l_start` ... začátek zamykaného úseku vzhledem k `l_whence`
- `l_len` ... délka úseku v bajtech, 0 znamená do konce souboru
- `l_pid` ... PID procesu držícího zámek, používá se jen pro `F_GETLK` při návratu

Deadlock (aka uváznutí)

- máme dva sdílené zdroje `res1` a `res2` chráněné zámky `lck1` a `lck2`. Procesy `p1` a `p2` chtějí každý výlučný přístup k oběma zdrojům.

p1

```
lock(lck1); /* OK */

lock(lck2); /* Čeká na p2 */
```

p2

```
lock(lck2); /* OK */

lock(lck1); /* Čeká na p1 */
```

Deadlock

```
use(res1, res2);
unlock(lck2);
unlock(lck1);
```

```
use(res1, res2);
unlock(lck2);
unlock(lck1);
```

- **pozor na pořadí zamykání!**

System V IPC

- **IPC** je zkratka pro *Inter-Process Communication*
- komunikace mezi procesy **v rámci jednoho systému**, tj. nezahrnuje síťovou komunikaci
- **semafory** ... použití pro synchronizaci procesů
- **sdílená paměť** ... předávání dat mezi procesy, přináší podobné problémy jako sdílení souborů, k řešení lze použít semafory
- **fronty zpráv** ... spojují komunikaci (zpráva nese data) se synchronizací (čekání procesu na příchod zprávy)
- prostředky IPC mají podobně jako soubory definovaná **přístupová práva** (pro čtení a zápis) pro vlastníka, skupinu a ostatní.

Semafory

- zavedl je E. Dijkstra
- semafor s je datová struktura obsahující
  - celé nezáporné číslo `i` (volná kapacita)
  - frontu procesů `q`, které čekají na uvolnění
- operace nad semaforem:

  init(s, n)

  vyprázdnit `s.q; s.i = n`

  P(s)

  ```
  if(s.i > 0) s.i-- else
  uspat volající proces a zařadit do s.q
  ```

  V(s)

  ```
  if(s.q prázdná) s.i++ else
  odstranit jeden proces z s.q a probudit ho
  ```

Vzájemné vyloučení pomocí semaforů

- jeden proces inicializuje semafor

```
sem s;
init(s, 1);
```

- kritická sekce se doplní o operace nad semaforem

```
...
P(s);
kritická sekce;
V(s);
...
```

API pro semafory

`int` **semget**`(key_t` *key*`, int` *nsems*`, int` *semflg*`);`

- vrátí identifikátor pole obsahujícího `nsems` semaforů asociovaný s klíčem `key` (klíč `IPC_PRIVATE` ... privátní semafory, při každém použití vrátí jiný identifikátor). `semflg` je OR-kombinace přístupových práv a konstant `IPC_CREAT` (vytvořit, pokud neexistuje), `IPC_EXCL` (chyba, pokud existuje).

`int` **semctl**`(int` *semid*`, int` *semnum*`, int` *cmd*`, ...);`

- řídicí funkce, volitelný čtvrtý parametr `arg` je typu `union semun`.

`int` **semop**`(int` *semid*`, struct sembuf *`*sops*`, size_t` *nsops*`);`

- zobecněné operace P a V.

API pro semafory: `semctl()`

- `semnum` ... číslo semaforu v poli
- možné hodnoty `cmd`:
  - `GETVAL` ... vrátí hodnotu semaforu
  - `SETVAL` ... **nastaví semafor na hodnotu** `arg.val`
  - `GETPID` ... PID procesu, který provedl poslední operaci
  - `GETNCNT` ... počet procesů čekajících na větší hodnotu
  - `GETZCNT` ... počet procesů čekajících na nulu
  - `GETALL` ... uloží hodnoty všech semaforů do pole `arg.array`
  - `SETALL` ... nastaví všechny semafory podle `arg.array`
  - `IPC_STAT` ... do `arg.buf` dá počet semaforů, přístupová práva a časy posledních `semctl()` a `semop()`
  - `IPC_SET` ... nastaví přístupová práva
  - `IPC_RMID` ... zruší pole semaforů

API pro semafory: `semop()`

- operace se provádí atomicky (tj. buď se povede pro všechny semafory, nebo pro žádný) na `nsops` semaforech podle pole `sops` struktur `struct sembuf`, která obsahuje:
  - `sem_num` ... číslo semaforu
  - `sem_op` ... operace
    - `P(sem_num, abs(sem_op))` pro `sem_op < 0`
    - `V(sem_num, sem_op)` pro `sem_op > 0`
    - čekání na nulovou hodnotu semaforu pro `sem_op == 0`
  - `sem_flg` ... OR-kombinace
    - `IPC_NOWAIT` ... když nelze operaci hned provést, nečeká a vrátí chybu
    - `SEM_UNDO` ... při ukončení procesu vrátit operace se semaforem

Vytváření prostředků IPC

- jeden proces prostředek vytvoří, ostatní se k němu připojí.
- po skončení používání je třeba prostředek IPC zrušit.
- funkce `semget()`, `shmget()` a `msgget()` mají jako první parametr klíč identifikující prostředek IPC. Skupina procesů, která chce komunikovat, se musí domluvit na společném klíči. Různé skupiny komunikujících procesů by měly mít různé klíče.

`key_t` **`ftok`**`(const char *`*`path`*`, int `*`id`*`);`

- vrátí klíč odvozený ze zadaného jména souboru `path` a čísla `id`. Pro stejné `id` a libovolnou cestu odkazující na stejný soubor vrátí stejný klíč. Pro různá `id` nebo různé soubory na stejném svazku vrátí různé klíče.

Další prostředky IPC

- POSIX a SUSv3 definují ještě další prostředky komunikace mezi procesy:
  - **signály** ... pro uživatelské účely lze využít signály `SIGUSR1` a `SIGUSR2`
  - **POSIXová sdílená paměť** přístupná pomocí `shm_open()` a `mmap()`
  - **POSIXové semafory** ... `sem_open()`, `sem_post()`, `sem_wait()`, ...
  - **POSIXové fronty zpráv** ... `mq_open()`, `mq_send()`, `mq_receive()`, ...
- Z BSD pochází **sokety (sockets)** umožňující komunikaci v doménách `AF_UNIX` (komunikace v rámci jednoho počítače) a `AF_INET` (komunikace na jednom počítači nebo po síti).

Obsah

- úvod, vývoj UNIXu a C, programátorské nástroje
- základní pojmy a konvence UNIXu a jeho API
- přístupová práva, periferní zařízení, systém souborů
- manipulace s procesy, spouštění programů
- signály
- synchronizace a komunikace procesů
- **síťová komunikace**
- vlákna, synchronizace vláken
- ??? - bude definováno později, podle toho kolik zbyde času

Síťová komunikace

UUCP (UNIX-to-UNIX Copy Program) – první aplikace pro komunikaci UNIXových systémů propojených přímo nebo přes modemy, součást Version 7 UNIX (1978)

sokety (sockets) – zavedeny ve 4.1aBSD (1982); soket je jeden konec obousměrného komunikačního kanálu vytvořeného mezi dvěma procesy buď lokálně na jednom počítači, nebo s využitím síťového spojení

TLI (Transport Layer Interface) – SVR3 (1987); knihovna zajišťující síťovou komunikaci na úrovni 4. vrstvy referenčního modelu ISO OSI

RPC (Remote Procedure Call) – SunOS (1984); protokol pro přístup ke službám na vzdáleném stroji, data přenášena ve tvaru XDR (External Data Representation)

TCP/IP

- protokoly
  - **IP (Internet Protocol)** – přístupný jen pro uživatele `root`
  - **TCP (Transmission Control Protocol)** – streamový, spojovaný, spolehlivý
  - **UDP (User Datagram Protocol)** – datagramový, nespojovaný, nespolehlivý
- **IP adresa** – 4 bajty (IPv4) / 16 bajtů (IPv6), definuje síťové rozhraní, nikoliv počítač
- **port** – 2 bajty, rozlišení v rámci 1 IP adresy, porty s číslem menším než 1024 jsou rezervované (jejich použití vyžaduje práva uživatele `root`)
- **DNS (Domain Name System)** – převod mezi symbolickými jmény a numerickými IP adresami

Spojované služby (TCP), sekvenční obsluha

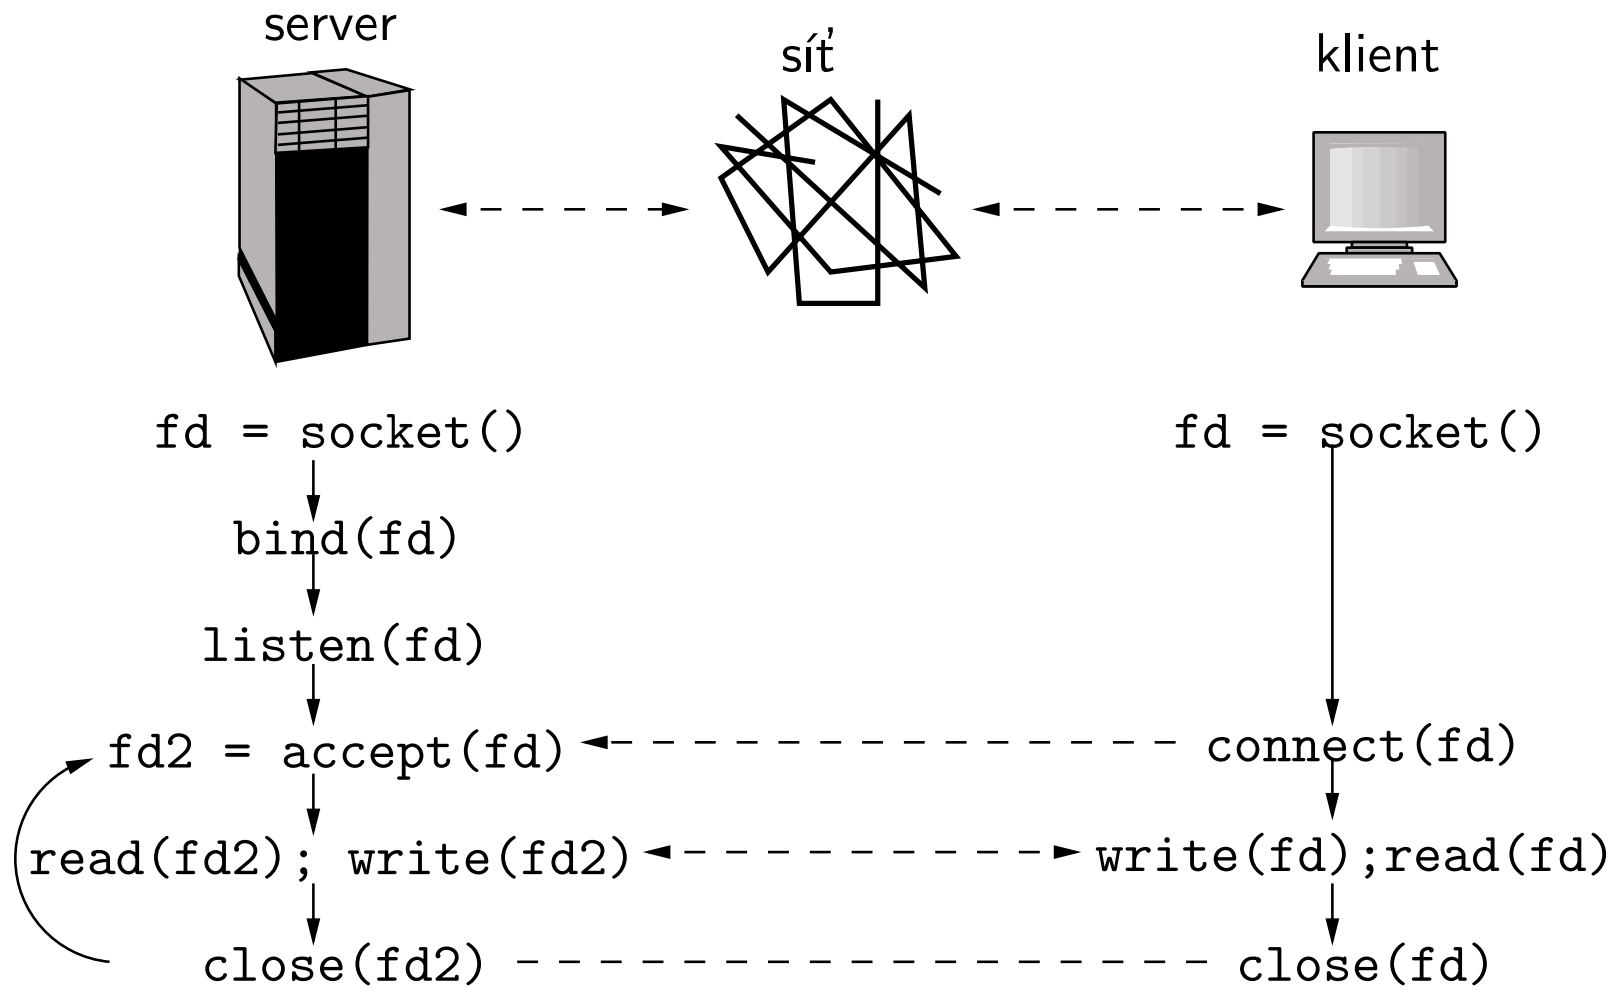

Spojované služby (TCP), paralelní obsluha

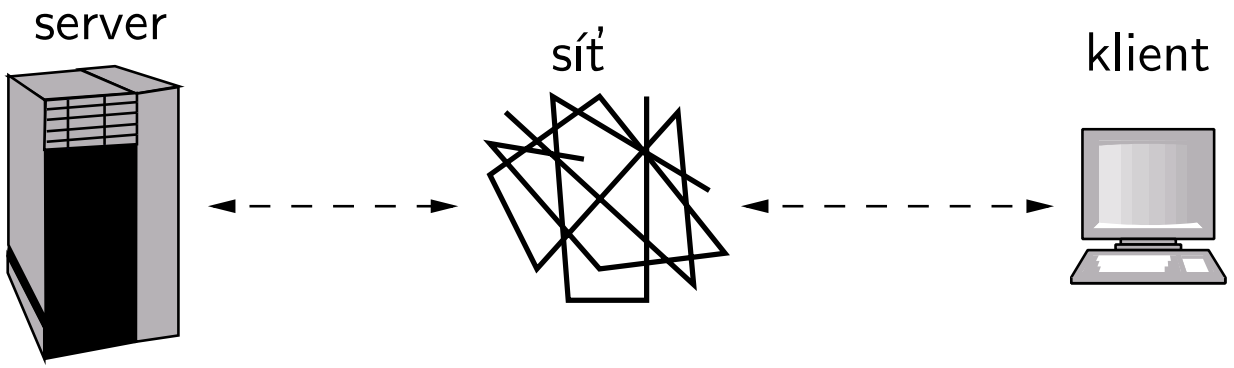


```
fd = socket()                    fd = socket()
   bind(fd)                          |
  listen(fd)                         |
fd2 = accept(fd) <---------------- connect(fd)
   fork()                            |
     |                               |
close(fd2)          syn              |
while(waitpid(    read(fd2)          |
  -1, stat,       write(fd2)  <---> write(fd);read(fd)
  WNOHANG)>0) ;     exit(0)         |
                    ---------- close(fd)
```

Spojované služby, paralelní `accept()`

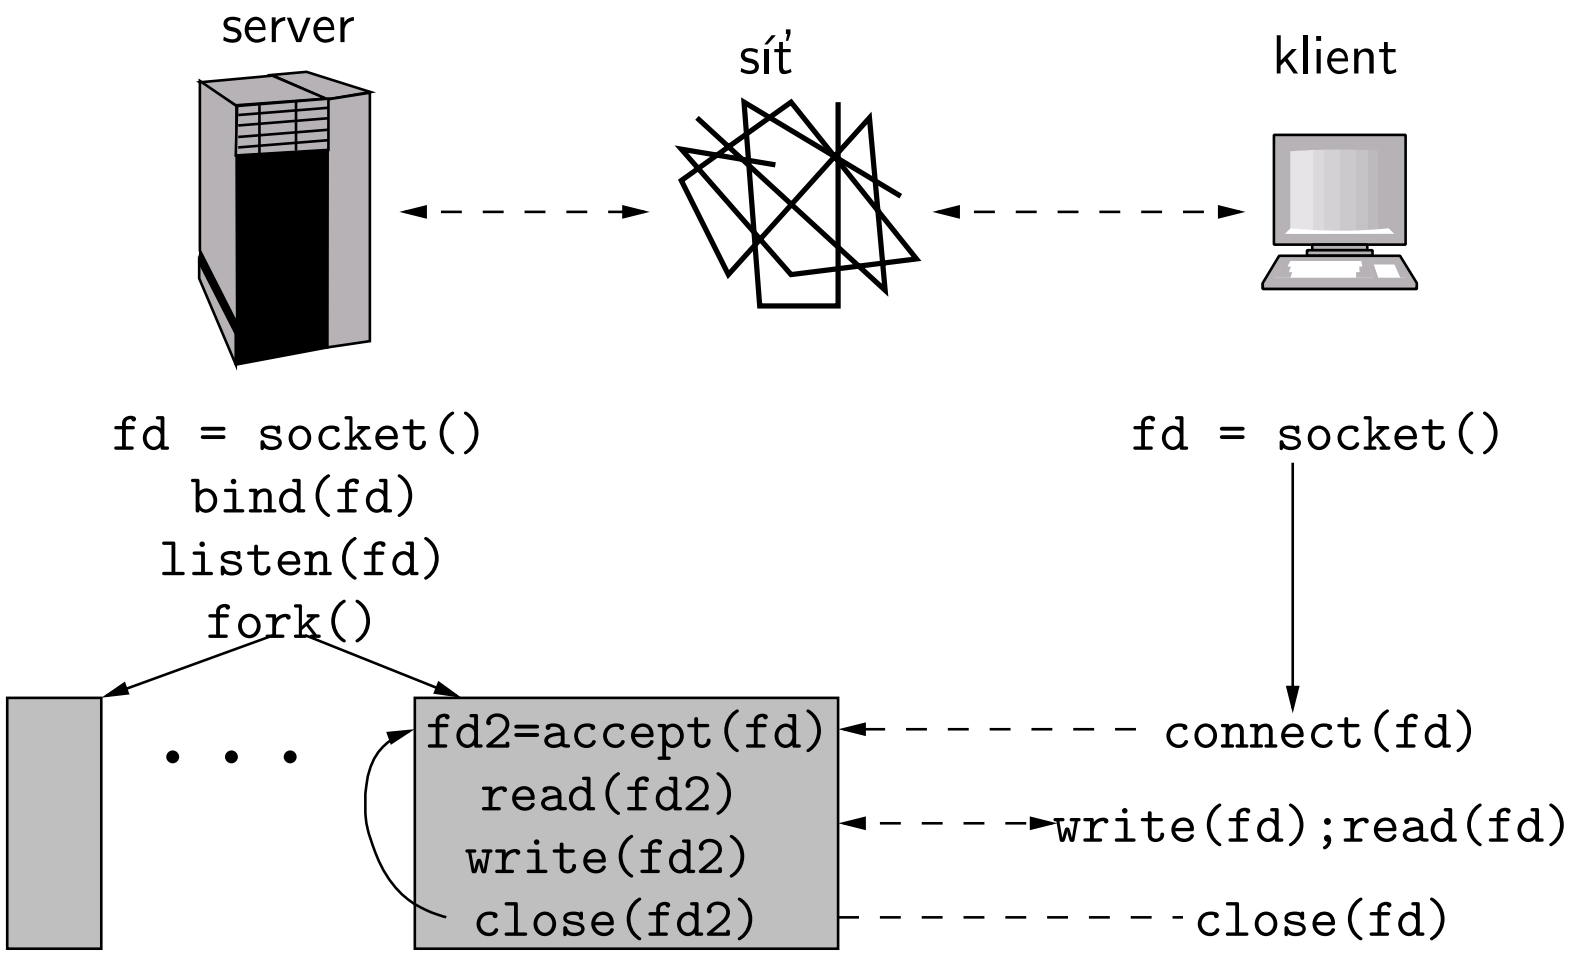

Datagramové služby (UDP)

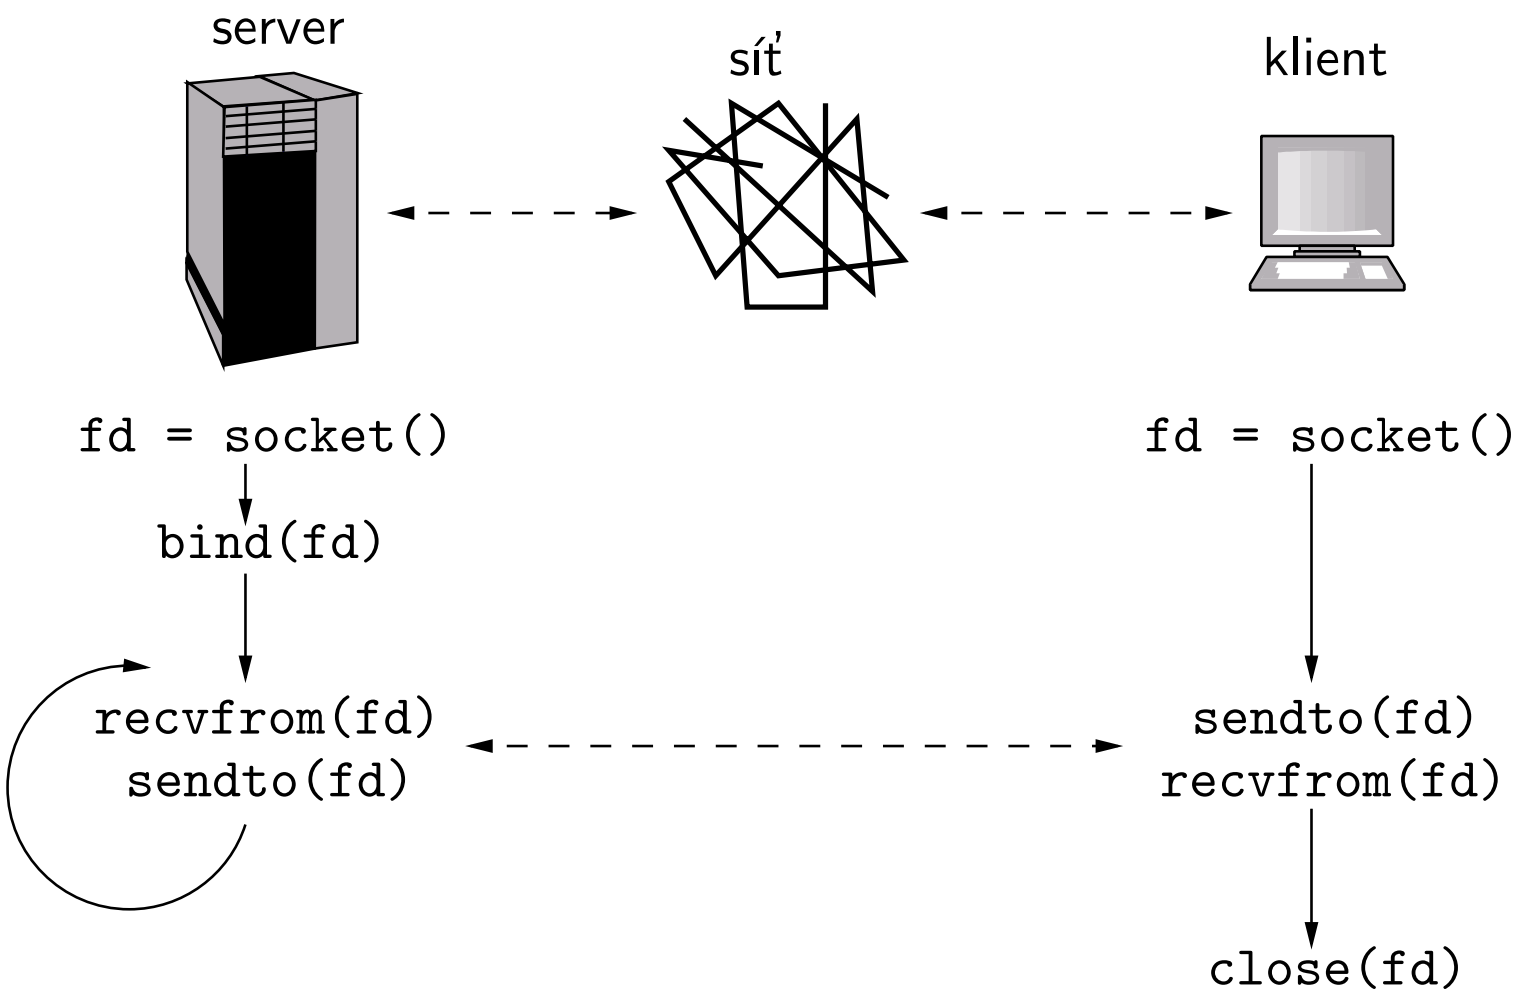

Vytvoření soketu: `socket()`

`int` **socket**`(int` *domain*`, int` *type*`, int` *protocol*`);`

- vytvoří soket a vrátí jeho deskriptor.
- `domain` – „kde se bude komunikovat”:
  - `AF_UNIX` ... lokální komunikace, adresa je jméno souboru
  - `AF_INET`, `AF_INET6` ... síťová komunikace, adresa je dvojice (IP adresa, port)
- `type`:
  - `SOCK_STREAM` ... spojovaná spolehlivá služba, poskytuje obousměrný sekvenční proud dat
  - `SOCK_DGRAM` ... nespojovaná nespolehlivá služba, přenos datagramů
- `protocol`: `0` (default pro daný `type`) nebo platné číslo protokolu (např. `6` = TCP, `17` = UDP)

Pojmenování soketu: `bind()`

```
int bind(int socket, const struct sockaddr *address,
         socklen_t address_len);
```

- přiřadí soketu zadanému deskriptorem `socket` adresu
- obecná `struct sockaddr`, nepoužívá se pro vlastní zadávání adres:
  - `sa_family_t sa_family` ... doména
  - `char sa_data[]` ... adresa
- pro `AF_INET` se používá `struct sockaddr_in`:
  - `sa_family_t sin_family` ... doména (`AF_INET`)
  - `in_port_t sin_port` ... číslo portu (16 bitů)
  - `struct in_addr sin_addr` ... IP adresa (32 bitů)
  - `unsigned char sin_zero[8]` ... výplň (*padding*)

Struktura pro IPv4 adresy

- každá adresní rodina má svoji strukturu a svůj hlavičkový soubor
- použitou strukturu pak ve volání `socket` přetypujete na `struct sockaddr`

```
#include <netinet/in.h>
struct sockaddr_in in; /* IPv4 */

bzero(&in, sizeof (in));
in.sin_family = AF_INET;
in.sin_port = htons(2222);
in.sin_addr.s_addr = htonl(INADDR_ANY);

if (bind(s, (struct sockaddr *)&in, sizeof (in)) == -1) ..
```

Čekání na spojení: `listen()`

`int` **`listen`**`(int` *`socket`*`, int` *`backlog`*`);`

- označí soket zadaný desktriptorem `socket` jako akceptující spojení a systém na soketu začne poslouchat.
- maximálně `backlog` žádostí o spojení může najednou čekat ve frontě na obsloužení (implementace může hodnotu `backlog` změnit, pokud není v podporovaném rozsahu). Žádosti, které se nevejdou do fronty, jsou odmítnuty (tj. volání `connect` skončí s chybou).
- soket čeká na spojení na adrese, která mu byla dříve přiřazena voláním `bind`.

Akceptování spojení: `accept()`

```
int accept(int socket, struct sockaddr *address,
           socklen_t *address_len);
```

- vytvoří spojení mezi lokálním soketem `socket` (který dříve zavolal `listen`) a vzdáleným soketem, žádajícím o spojení pomocí `connect`. Vrátí deskriptor (nový soket), který lze používat pro komunikaci se vzdáleným procesem. Původní soket může hned přijímat další spojení pomocí `accept`.
- v `address` vrátí adresu vzdáleného soketu.
- `address_len` je velikost struktury pro uložení adresy v bajtech, po návratu obsahuje skutečnou délku adresy.

Práce s IPv4 a IPv6 adresami

- binární reprezentace adresy se nám špatně čte
- a reprezentaci adresy řetězcem nelze použít při práci se `sockaddr` strukturami

```
int inet_pton(int af, const char *src, void *dst);
```

- převede řetězec na binární adresu, tj. to co je možné použít v `in_addr` nebo `in6_addr` položkách `sockaddr` struktur
- vrací 1 (OK), 0 (chybně zadaná adresa) nebo -1 (a nastaví `errno`)

```
cont char *inet_ntop(int af, const void *src,
                     char *dst, size_t size);
```

- opak k `inet_pton`; vrací *dst* nebo `NULL` (a nastaví `errno`)
- pro obě volání platí, že `af` je `AF_INET` nebo `AF_INET6`

Navázání spojení: `connect()`

```
int connect(int sock, struct sockaddr *address,
            socklen_t address_len);
```

- naváže spojení lokálního soketu `sock` se vzdáleným procesem, který pomocí `listen` a `accept` čeká na spojení na adrese `address` (o délce `address_len`).
- jestliže pro soket `sock` nebyla definována adresa voláním `bind`, je mu přiřazena nějaká nepoužitá adresa dle zvolené rodiny protokolů.
- pokud se spojení nepovede, je soket v nedefinovaném stavu. Před novým pokusem o spojení by aplikace měla zavřít deskriptor `sock` a vytvořit nový soket.

Přijetí zprávy: `recvfrom()`

```
ssize_t recvfrom(int sock, void *buf, size_t len,
                 int flg, struct sockaddr *address,
                 socklen_t *address_len);
```

- přijme zprávu ze soketu `sock`, uloží ji do bufferu `buf` o velikosti `len`, do `address` dá adresu odesílatele zprávy, do `address_len` délku adresy. Vrátí délku zprávy. Když je zpráva delší než `len`, nadbytečná data se zahodí (`SOCK_STREAM` nedělí data na zprávy, data se nezahazují).
- ve `flg` mohou být příznaky:
  - `MSG_PEEK` ... zpráva se bere jako nepřečtená, další `recvfrom` ji vrátí znovu
  - `MSG_OOB` ... přečte urgentní (out-of-band) data
  - `MSG_WAITALL` ... čeká, dokud není načten plný objem dat, tj. `len` bajtů

Poslání zprávy: `sendto()`

```
ssize_t sendto(int socket, void *msg, size_t len,
               int flags, struct sockaddr *addr,
               socklen_t addr_len);
```

- prostřednictvím soketu `socket` pošle zprávu `msg` o délce `len` na adresu `addr` (o délce `addr_len`).
- parametr `flags` může obsahovat příznaky:
  - `MSG_EOB` ... ukončení záznamu (pokud je podporováno protokolem)
  - `MSG_OOB` ... poslání urgentních (out-of-band) dat, jejichž význam je závislý na protokolu

Další funkce pro sokety

```
int setsockopt(int socket, int level, int opt_name,
               const void *opt_value, socklen_t option_len);
```

- nastavení parametrů soketu

```
int getsockopt(int socket, int level, int opt_name,
               void *opt_value, socklen_t *option_len);
```

- přečtení parametrů soketu

```
int getsockname(int socket, struct sockaddr *address,
                socklen_t *address_len);
```

- zjištění (lokální) adresy soketu

```
int getpeername(int socket, struct sockaddr *address,
                socklen_t *address_len);
```

- zjištění adresy vzdáleného soketu (druhého konce spojení)

Uzavření soketu: `close()`

`int` **`close`**`(int fildes);`

- zruší deskriptor, při zrušení posledního deskriptoru soketu zavře soket.
- pro `SOCK_STREAM` soket záleží na nastavení příznaku `SO_LINGER` (default je `l_onoff == 0`, mění se funkcí `setsockopt`).
  - `l_onoff == 0` ... volání `close` se vrátí, ale jádro se snaží dál přenést zbylá data
  - `l_onoff == 1 && l_linger != 0` ... jádro se snaží přenést zbylá data do vypršení timeoutu `l_linger` v sekundách, když se to nepovede, `close` vrátí chybu, jinak vrátí OK po přenesení dat.
  - `l_onoff == 1 && l_linger == 0` ... provede se reset spojení

Uzavření soketu: `shutdown()`

`int` **shutdown**`(int` *socket*`, int` *how*`);`

- Uzavře soket (ale neruší deskriptor) podle hodnoty `how`:
  - `SHUT_RD` ... pro čtení
  - `SHUT_WR` ... pro zápis
  - `SHUT_RDWR` ... pro čtení i zápis

Pořadí bajtů

- síťové služby používají pořadí bajtů, které se může lišit od pořadí používaného na lokálním systému. Pro převod lze použít funkce (makra):
  - `uint32_t` **`htonl`**`(uint32_t` *`hostlong`*`);`
    host → síť, 32 bitů
  - `uint16_t` **`htons`**`(uint16_t` *`hostshort`*`);`
    host → síť, 16 bitů
  - `uint32_t` **`ntohl`**`(uint32_t` *`netlong`*`);`
    síť → host, 32 bitů
  - `uint16_t` **`ntohs`**`(uint16_t` *`netshort`*`);`
    síť → host, 16 bitů
- síťové pořadí bajtů je big-endian, tj. nejprve vyšší bajt. Používá se hlavně ve funkcích pracujících s adresami a čísly portů.

Čísla protokolů a portů

```
struct protoent *getprotobyname(const char *name);
```

- v položce `p_proto` vrátí číslo protokolu se jménem *name* (např. pro `"tcp"` vrátí 6).
- čísla protokolů jsou uložena v souboru `/etc/protocols`.

```
struct servent *getservbyname(const char *name,
                              const char *proto);
```

- pro zadané jméno služby `name` a jméno protokolu `proto` vrátí v položce `s_port` číslo portu.
- čísla portů jsou uložena v souboru `/etc/services`.

funkce vrací `NULL`, když v databázi není odpovídající položka.

Převod hostname na adresy: `getaddrinfo()`

- ze zadaných parametrů přímo generuje `sockaddr` struktury
- pracuje s adresami i s porty
- její chování je ovlivnitelné pomocí tzv. *hintů*

```
int getaddrinfo(const char *nodename,
                const char *servicename,
                const struct addrinfo *hint,
                struct addrinfo **res);
```

- položky struktury `addrinfo`: `ai_flags` (pro hinty), `ai_family` (address family), `ai_socktype`, `ai_protocol`, `ai_addrlen`, `struct sockaddr *ai_addr` (výsledné adresy), `char *ai_canonname`, `struct addrinfo *ai_next` (další prvek v seznamu)

Převod adresy na hostname: `getnameinfo()`

- protějšek k funkci `getaddrinfo`
- jako vstup pracuje s celými `sockaddr` strukturami, tedy funguje s IPv4 i IPv6 adresami, narozdíl od funkce `gethostbyaddr`.

```
int getnameinfo(const struct sockaddr *sa,
                socklen_t *sa_len,
                char *nodename,
                socketlen_t *nodelen,
                char *servicename,
                socketlen_t *servicelen,
                unsigned flags);
```

Příklad: TCP server

```
struct sockaddr_storage ca; int nclients = 10, fd, nfd;
struct addrinfo *r, *rorig, hi;
memset(&hi, 0, sizeof (hi)); hi.ai_family = AF_UNSPEC;
hi.ai_socktype = SOCK_STREAM; hi.ai_flags = AI_PASSIVE;
getaddrinfo(NULL, portstr, &hi, &rorig);
for (r = rorig; r != NULL; r = r->ai_next) {
    fd = socket(r->ai_family, r->ai_socktype,
        r->ai_protocol);
    if (!bind(fd, r->ai_addr, r->ai_addrlen)) break;
}
freeaddrinfo(rorig); listen(fd, nclients);
for (;;) { sz = sizeof(ca);
    nfd = accept(fd, (struct sockaddr *)&ca, &sz);
    /* Komunikace s klientem */
    close(newsock);
}
```

Příklad: TCP klient

```
int fd; struct addrinfo *r, *rorig, hi;
memset(&hi, 0, sizeof (hi)); hi.ai_family = AF_UNSPEC;
hi.ai_socktype = SOCK_STREAM;
getaddrinfo(hoststr, portstr, &hi, &r);
for (rorig = r; r != NULL; r = r->ai_next) {
    fd = socket(r->ai_family, r->ai_socktype,
        r->ai_protocol);
    if (connect(fd, (struct sockaddr *)r->ai_addr,
        r->ai_addrlen) == 0)
            break;
}
freeaddrinfo(resorig);
/* Komunikace se serverem */
close(fd);
```

Čekání na data: `select()`

```
int select(int nfds, fd_set *readfds,
           fd_set *writefds, fd_set *errorfds,
           struct timeval *timeout);
```

- zjistí, které ze zadaných deskriptorů jsou připraveny pro čtení, zápis, nebo na kterých došlo k výjimečnému stavu. Pokud žádný takový deskriptor není, čeká do vypršení času `timeout` (`NULL` ... čeká se libovolně dlouho). Parametr `nfds` udává rozsah testovaných deskriptorů (`0, ..., nfds-1`).
- pro nastavení a test masek deskriptorů slouží funkce:
  - `void` **`FD_ZERO`**`(fd_set *fdset)` ... inicializace
  - `void` **`FD_SET`**`(int fd, fd_set *fdset)` ... nastavení
  - `void` **`FD_CLR`**`(int fd, fd_set *fdset)` ... zrušení
  - `int` **`FD_ISSET`**`(int fd, fd_set *fdset)` ... test

Příklad: použití `select()`

- Deskriptor `fd` odkazuje na soket, přepisuje síťovou komunikaci na terminál a naopak.

```
int sz; fd_set rfdset, efdset; char buf[BUFSZ];
for(;;) {
    FD_ZERO(&rfdset); FD_SET(0, &rfdset);
    FD_SET(fd, &rfdset); efdset = rfdset;
    select(fd+1, &rfdset, NULL, &efdset, NULL);
    if(FD_ISSET(0, &efdset))
        /* Výjimka na stdin */ ;
    if(FD_ISSET(fd, &efdset))
        /* Výjimka na fd */ ;
    if(FD_ISSET(0, &rfdset)) {
        sz = read(0, buf, BUFSZ); write(fd, buf, sz); }
    if(FD_ISSET(fd, &rfdset)) {
        sz = read(fd, buf, BUFSZ); write(1,buf,sz); }
}
```

Čekání na data: `poll()`

`int` **`poll`**`(struct pollfd` *`fds`*`[], nfds_t` *`nfds`*`, int` *`timeout`*`);`

- čeká na událost na některém z deskriptorů v poli `fds` o `nfds` prvcích po dobu `timeout` ms (`0` ... vrátí se hned, `-1` ... čeká se libovolně dlouho).
- prvky struktury `pollfd`:
  - `fd` ... číslo deskriptoru
  - `events` ... očekávané události, OR-kombinace `POLLIN` (lze číst), `POLLOUT` (lze psát), atd.
  - `revents` ... události, které nastaly, příznaky jako v `events`, navíc např. `POLLERR` (nastala chyba)

Správa síťových služeb: `inetd`

- servery síťových služeb se spouští buď při startu systému, nebo je startuje démon `inetd` při připojení klienta.
- démon `inetd` čeká na portech definovaných v `/etc/inetd.conf` a když detekuje příchozí spojení/datagram, spustí příslušný server a přesměruje mu deskriptory.
- příklad obsahu `/etc/inetd.conf`:

```
ftp stream tcp nowait root /usr/etc/ftpd ftpd -l
shell stream tcp nowait root /usr/etc/rshd rshd -L
login stream tcp nowait root /usr/etc/rlogind rlogind
exec stream tcp nowait root /usr/etc/rexecd rexecd
finger stream tcp nowait guest /usr/etc/fingerd fingerd
ntalk dgram udp wait root /usr/etc/talkd talkd
tcpmux stream tcp nowait root internal
echo stream tcp nowait root internal
```

Formát souboru `/etc/inetd.conf`

`služba soket proto čekání uživ server argumenty`

- `služba` ... jméno síťové služby podle `/etc/services`
- `soket` ... `stream` nebo `dgram`
- `proto` ... komunikační protokol (`tcp`, `udp`)
- `čekání` ... `wait` (`inetd` čeká na ukončení serveru před akceptováním dalšího klienta), `nowait` (`inetd` akceptuje dalšího klienta hned)
- `uživatel` ... server poběží s identitou tohoto uživatele
- `server` ... úplná cesta k programu serveru nebo `internal` (službu zajišťuje `inetd`)
- `argumenty` ... příkazový řádek pro server, včetně `argv[0]`

Obsah

- úvod, vývoj UNIXu a C, programátorské nástroje
- základní pojmy a konvence UNIXu a jeho API
- přístupová práva, periferní zařízení, systém souborů
- manipulace s procesy, spouštění programů
- signály
- synchronizace a komunikace procesů
- síťová komunikace
- **vlákna, synchronizace vláken**
- ??? - bude definováno později, podle toho kolik zbyde času

Vlákna

- vlákno (*thread*) = linie výpočtu (*thread of execution*)
- vlákna umožňují mít více linií výpočtu v rámci jednoho procesu
- klasický unixový model: jednovláknové procesy
- vlákna nejsou vhodná pro všechny aplikace
- výhody vláken:
  - zrychlení aplikace, typicky na víceprocesorech (vlákna jednoho procesu mohou běžet současně na různých procesorech)
  - modulární programování
- nevýhody vláken:
  - není jednoduché korektně napsat složitější kód s vlákny
  - obtížnější debugging

Implementace vláken

library-thread model

- vlákna jsou implementována v knihovnách, jádro je nevidí.
- run-time knihovna plánuje vlákna na procesy a jádro plánuje procesy na procesory.

$\oplus$ menší režie přepínání kontextu

$\ominus$ nemůže běžet více vláken stejného procesu najednou.

kernel-thread model

- vlákna jsou implementována přímo jádrem.

$\oplus$ více vláken jednoho procesu může běžet najednou na různých procesorech.

$\ominus$ plánování threadů používá systémová volání místo knihovních funkcí, tím více zatěžuje systém.

hybridní modely

- vlákna se multiplexují na několik jádrem plánovaných entit.

POSIX vlákna (pthreads)

- definované rozšířením POSIX.1c
- volání týkající se vláken začínají prefixem `pthread_`
- tyto funkce vrací 0 (OK) nebo přímo číslo chyby
  - ... a nenastavují `errno`!
  - nelze s nimi proto použít funkce `perror` nebo `err`
- POSIX.1c definuje i další funkce, například nové verze k těm, které nebylo možné upravit pro použití ve vláknech bez změny API, např `readdir_r`, `strtok_r`, atd.
  - `_r` znamená *reentrant*, tedy že funkci může volat více vláken najednou bez vedlejších efektů

Vytvoření vlákna

```
int pthread_create(pthread_t *thread,
                   const pthread_attr_t *attr,
                   void *(*start_fun)(void*), void *arg);
```

- vytvoří nové vlákno, do `thread` uloží jeho ID.
- podle `attr` nastaví jeho atributy, např. velikost zásobníku či plánovací politiku. `NULL` znamená použít implicitní atributy.
- ve vytvořeném vláknu spustí funkci `start_fun`() s argumentem `arg`. Po návratu z této funkce se zruší vlákno.
- s objekty `pthread_attr_t` lze manipulovat funkcemi `pthread_attr_init()`, `pthread_attr_destroy()`, `pthread_attr_setstackaddr()`, atd...

Soukromé atributy vláken

- čítač instrukcí
- zásobník (automatické proměnné)
- thread ID, dostupné funkcí
  `pthread_t` **`pthread_self`**`(void);`
- plánovací priorita a politika
- hodnota `errno`
- klíčované hodnoty – dvojice (`pthread_key_t` *`key`*`, void *`*`ptr`*`)`
  - klíč vytvořený voláním `pthread_key_create()` je viditelný ve všech vláknech procesu.
  - v každém vláknu může být s klíčem asociována jiná hodnota voláním `pthread_setspecific()`.

Ukončení vlákna

`void` **`pthread_exit`**`(void *`*`val_ptr`*`);`

- ukončí volající vlákno, je to obdoba `exit` pro proces

`int` **`pthread_join`**`(pthread_t `*`thr`*`, void **`*`val_ptr`*`);`

- počká na ukončení vlákna `thr` a ve `val_ptr` vrátí hodnotu ukazatele z `pthread_exit` nebo návratovou hodnotu vláknové funkce. Pokud vlákno skončilo dříve, funkce hned vrací příslušně nastavené `val_ptr`.
- obdoba čekání na synovský proces pomocí `wait`

`int` **`pthread_detach`**`(pthread_t `*`thr`*`);`

- nastaví okamžité uvolnění paměti po ukončení vlákna, na vlákno nelze použít `pthread_join`.

Inicializace

```
int pthread_once(pthread_once_t *once_control,
                 void (*init_routine)(void));
```

- V parametru `once_control` se předává ukazatel na staticky inicializovanou proměnnou
  `pthread_once_t once_control = PTHREAD_ONCE_INIT;`
- První vlákno, které zavolá `pthread_once()`, provede inicializační funkci `init_routine()`. Ostatní vlákna už tuto funkci neprovádějí, navíc, pokud inicializační funkce ještě neskončila, zablokují se a čekají na její dokončení.
- Lze použít např. na dynamickou inicializaci globálních dat v knihovnách, jejichž kód může zavolat více vláken současně, ale je třeba zajistit, že inicializace proběhne jen jednou.

Zrušení vlákna

`int` **pthread_cancel**`(pthread_t` *thread*`);`

- požádá o zrušení vlákna `thread`. Závisí na nastavení

`int` **pthread_setcancelstate**`(int` *state*`, int *`*old*`);`

- nastaví nový stav a vrátí starý:
  - `PTHREAD_CANCEL_ENABLE` ... povoleno zrušit
  - `PTHREAD_CANCEL_DISABLE` ... nelze zrušit, žádost bude čekat na povolení

`int` **pthread_setcanceltype**`(int` *type*`, int *`*old*`);`

- `PTHREAD_CANCEL_ASYNCHRONOUS` ... okamžité zrušení
- `PTHREAD_CANCEL_DEFERRED` ... žádost čeká na vstup do určitých funkcí (např. `open()`, `read()`, `wait()`), nebo na volání

`void` **pthread_testcancel**`(void);`

Příklad: vlákna

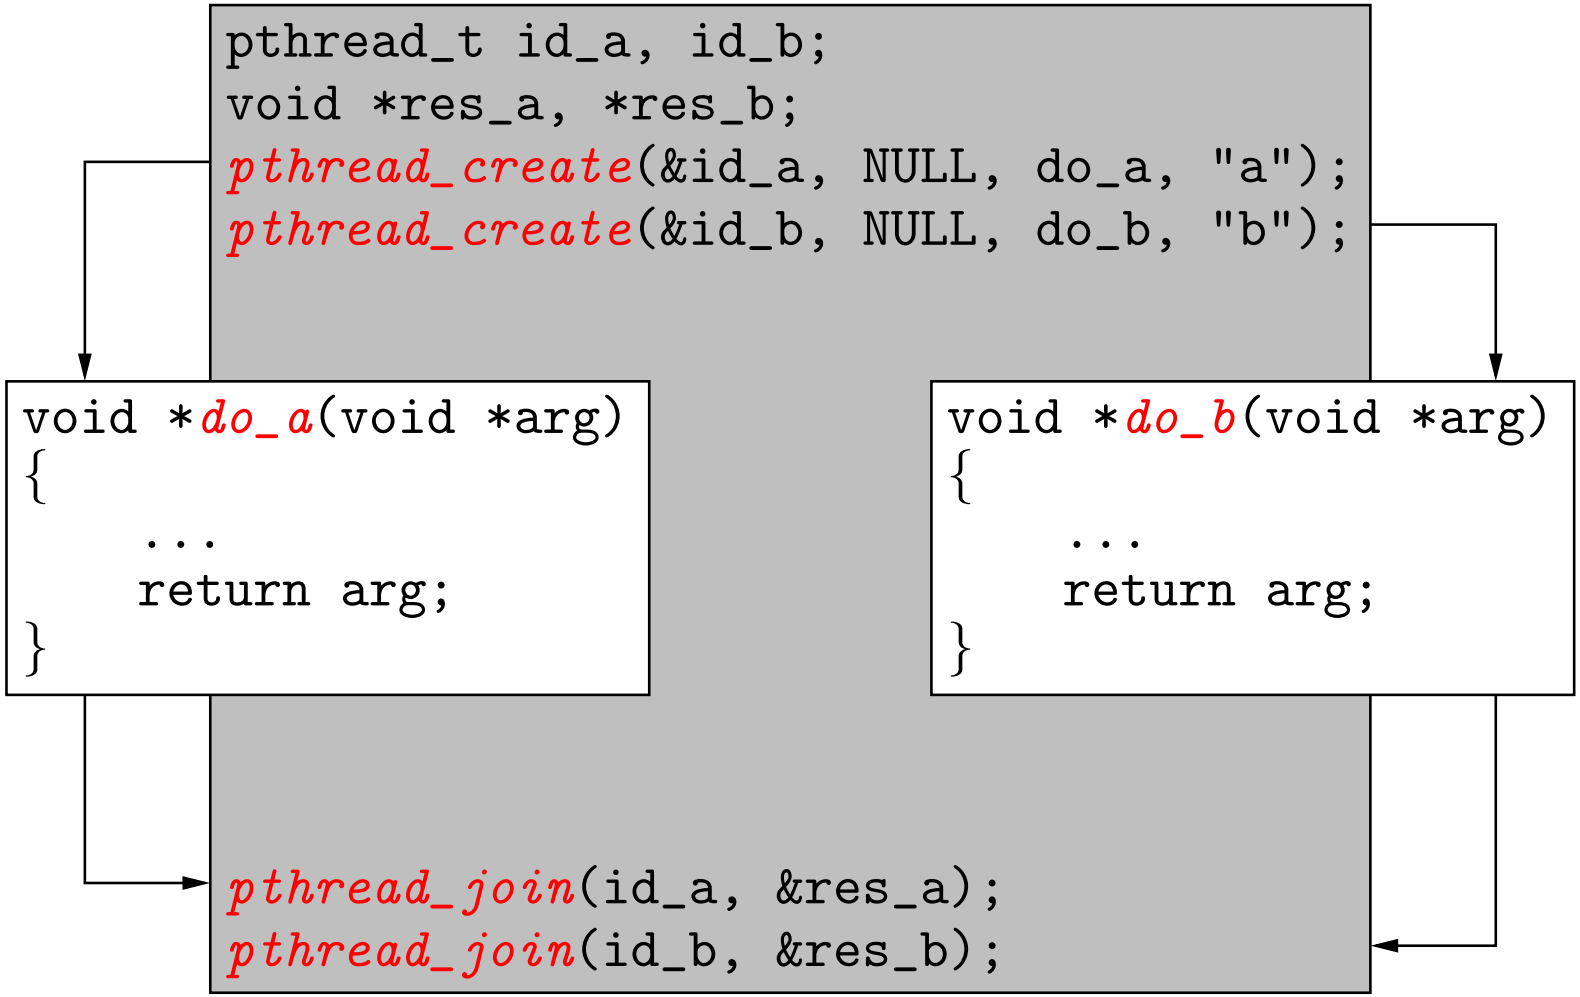

Globální proměnné pro vlákno

```
int pthread_key_create(pthread_key_t *key,
                       void (*destructor)(void *));
```

- vytvoří klíč, který lze asociovat s hodnotou typu `(void *)`. Funkce `destructor()` se volají opakovaně pro všechny klíče, jejichž hodnota není `NULL`, při ukončení vlákna.

```
int pthread_key_delete(pthread_key_t key);
```

- zruší klíč, nemění asociovaná data.

```
int pthread_setspecific(pthread_key_t key,
                        const void *value);
```

- přiřadí ukazatel `value` ke klíči `key`.

```
void *pthread_getspecific(pthread_key_t key);
```

- vrátí hodnotu ukazatele příslušného ke klíči `key`.

Úklid při ukončení/zrušení vlákna

- vlákno má zásobník úklidových handlerů, které se volají při ukončení nebo zrušení vlákna funkcemi `pthread_exit` a `pthread_cancel` (ale ne při `return`). Handlery se spouští v opačném pořadí než byly vkládány do zásobníku.
- po provedení handlerů se volají destruktory privátních klíčovaných dat vlákna (pořadí není specifikované)

```
void pthread_cleanup_push(void (*routine)(void *),
                          void *arg);
```

- vloží handler do zásobníku.

```
void pthread_cleanup_pop(int execute);
```

- vyjme naposledy vložený handler ze zásobníku. Provede ho, pokud je `execute` nenulové.

`fork()` a vlákna (POSIX)

- je nutné definovat sémantiku volání `fork` v aplikacích používajících vlákna. Norma definuje, že:
  - nový proces obsahuje přesnou kopii volajícího vlákna, včetně případných stavů mutexů a jiných zdrojů
  - ostatní vlákna v synovském procesu neexistují
  - pokud taková vlákna měla naalokovanou paměť, zůstane tato paměť naalokovaná (= ztracená)
  - obdobně to platí pro zamčený mutex již neexistujícího vlákna
- vytvoření nového procesu z multivláknové aplikace má smysl pro následné volání `exec` (tj. včetně volání `popen`, `system` apod.)

Signály a vlákna

- signály mohou být generovány pro proces (voláním `kill`), nebo pro vlákno (chybové události, volání `pthread_kill`).
- nastavení obsluhy signálů je stejné pro všechna vlákna procesu, ale masku blokovaných signálů má každé vlákno vlastní, nastavuje se funkcí

```
int pthread_sigmask(int how, const sigset_t *set,
                    sigset_t *oset);
```

- signál určený pro proces ošetří vždy právě jedno vlákno, které nemá tento signál zablokovaný.
- lze vyhradit jedno vlákno pro synchronní příjem signálů pomocí volání `sigwait`. Ve všech vláknech se signály zablokují.

Synchronizace vláken obecně

- většina programů používajících vlákna mezi nimi sdílí data
- nebo vyžaduje, aby různé akce byly prováděny v jistém pořadí
- ... toto vše potřebuje **synchronizovat** aktivitu běžících vláken
- jak bylo zmíněno u implementace vláken, u procesů je pro sdílení dat nutné vynaložit jisté úsilí, u vláken naopak musíme investovat do toho, abychom přirozené sdílení dat uhlídali
- my se vzhledem k vláknům budeme zabývat:
  - mutexy
  - podmínkovými proměnnými
  - read-write zámky

Synchronizace vláken: mutexy (1)

- nejjednodušší způsob zajištění synchronizovaného přístupu ke sdíleným datům mezi vlákny je použitím mutexu
- inicializace staticky definovaného mutexu:

```
pthread_mutex_t mutex = PTHREAD_MUTEX_INITIALIZER;
```

- inicializace dynamicky alokovaného mutexu `mx` s atributy `attr` (nastavují se pomocí `pthread_mutexattr_...`; a je-li místo `attr` použit `NULL`, vezmou se defaultní atributy)

```
int pthread_mutex_init(pthread_mutex_t *mx,
                       const pthread_mutexattr_t *attr);
```

- po skončení používání mutexu je možné ho zrušit:

```
int pthread_mutex_destroy(pthread_mutex_t *mx);
```

Mutexy (2)

- pro zamčení a odemčení mutexu použijeme volání:

```
int pthread_mutex_lock(pthread_mutex_t *mx);
```

a

```
int pthread_mutex_unlock(pthread_mutex_t *mx);
```

- pokud je mutex již zamčený, pokus o zamknutí vyústí v zablokování vlákna. Je možné použít i volání:

```
int pthread_mutex_trylock(pthread_mutex_t *mx);
```

... které se pokusí zamknout mutex, a pokud to nelze provést, skončí s chybou

Podmínkové proměnné (1)

- mutexy slouží pro synchronizaci přístupu ke sdíleným datům
- podmínkové proměnné pak k předání informací o těchto sdílených datech – například že se hodnota dat změnila
- ... a umožní tak vlákna podle potřeby uspávat a probouzet
- z toho plyne, že **každá podmínková proměnná je vždy asociována s právě jedním mutexem**
- jeden mutex ale může být asociován s více podmínkovými proměnnými
- společně pomocí mutexů a podmínkových proměnných je možné vytvářet další synchronizační primitiva – semafory, bariéry, ...

Podmínkové proměnné (2)

```
int pthread_cond_init(pthread_cond_t *cond,
                      const pthread_condattr_t *attr);
```

- Inicializuje podmínkovou proměnnou `cond` s atributy `attr` (nastavují je funkce `pthread_condattr_...()`), `NULL` = default.

```
int pthread_cond_destroy(pthread_cond_t *cond);
```

- zruší podmínkovou proměnnou.

```
int pthread_cond_wait(pthread_cond_t *cond,
                      pthread_mutex_t *mutex);
```

- čeká na podmínkové proměnné dokud jiné vlákno nezavolá **pthread_cond_signal()** nebo **pthread_cond_broadcast()**.

Podmínkové proměnné (3)

`int` **`pthread_cond_signal`**`(pthread_cond_t *`*`cond`*`);`

- probudí jeden proces čekající na podmínkové proměnné `cond`.

`int` **`pthread_cond_broadcast`**`(pthread_cond_t *`*`cond`*`);`

- probudí všechny procesy čekající na podmínkové proměnné `cond`.

```
int pthread_cond_timedwait(pthread_cond_t *cond,
                           pthread_mutex_t *mutex,
                           const struct timespec *atime);
```

- čeká na `pthread_cond_signal()` nebo `pthread_cond_broadcast()`, ale maximálně do doby než systémový čas dosáhne hodnoty dané `atime`.

Použití podmínkových proměnných

```
pthread_cond_t cond; pthread_mutex_t mutex;
...
pthread_mutex_lock(&mutex);
while (!podminka(data))
    pthread_cond_wait(&cond, &mutex);
process_data(data, ...);
pthread_mutex_unlock(&mutex);
...
pthread_mutex_lock(&mutex);
produce_data(data, ...);
pthread_cond_signal(&cond);
pthread_mutex_unlock(&mutex);
```

Read-write zámky (1)

```
int pthread_rwlock_init(pthread_rwlock_t *l,
                        const pthread_rwlockattr_t *attr);
```

- vytvoří zámek s atributy podle `attr` (nastavují se funkcemi `pthread_rwlockattr_...()`, $NULL$ = default)

```
int pthread_rwlock_destroy(pthread_rwlock_t *l);
```

- zruší zámek

```
int pthread_rwlock_rdlock(pthread_rwlock_t *l);
int pthread_rwlock_tryrdlock(pthread_rwlock_t *rwlock);
```

- zamkne zámek pro čtení (více vláken může držet zámek pro čtení), pokud má někdo zámek pro zápis, uspí volající vlákno (`rdlock()`) resp. vrátí chybu (`tryrdlock()`).

Read-write zámky (2)

`int` **`pthread_rwlock_wrlock`**`(pthread_rwlock_t *`*`rwlock`*`);`

- zamkne zámek pro zápis; pokud má někdo zámek pro čtení nebo zápis, čeká.

`int` **`pthread_rwlock_trywrlock`**`(pthread_rwlock_t *`*`rwlock`*`);`

- jako `pthread_rwlock_wrlock()`, ale když nemůže zamknout, vrátí chybu.

`int` **`pthread_rwlock_unlock`**`(pthread_rwlock_t *`*`rwlock`*`);`

- odemkne zámek

Atomické aritmetické operace

- pro architektury, kde operace sčítání není atomická
- výrazně rychlejší než jiné mechanismy pro získání exkluzivního přístupu díky použití instrukcí na dané platformě zajišťujících atomicitu.
- některé systémy dodávají funkce pro atomické operace, (např. `atomic_add(3c)` v Solarisu), obecně je lepší použít podporu v C11 standardu přes *stdatomic.h*.
- sada volání pro různé typy a operace, např. sčítání:

```
#include <stdatomic.h>

atomic_int acnt;
atomic_fetch_add(&acnt, 1);
```

Bariéra

- bariéra (*barrier*) je způsob, jak udržet členy skupiny pohromadě
- všechna vlákna čekají na bariéře, dokud ji nedosáhne poslední vlákno; pak mohou pokračovat
- typické použití je paralelní zpracování dat

`int` **`pthread_barrier_init`**`(pthread_barrier_t *`*`barrier`*`, `*`attr`*`, unsigned `*`count`*`);`

- inicializuje bariéru pro *count* vstupů do ní

`int` **`pthread_barrier_wait`**`(pthread_barrier_t *`*`barrier`*`);`

- zablokuje se dokud není zavolána *count*-krát

`int` **`pthread_barrier_destroy`**`(pthread_barrier_t *`*`barrier`*`);`

- zruší bariéru

Semafory

- semafory pochází z POSIX-1003.1b (real-time extensions)
- jména funkcí nezačínají **pthread_**, ale **sem_** (`sem_init`, `sem_post`, `sem_wait`, ...)
- je možné je použít s vlákny

Typické použití vláken

- **pipeline**
  - každé z vláken provádí svoji operaci nad daty, která se postupně předávají mezi vlákny
  - každé vlákno typicky provádí jinou operaci

  ... zpracování obrázku, kde každé vlákno provede jiný filtr
- **work crew**
  - vlákna provádějí stejnou operaci, ale nad jinými daty

  ... zpracování obrázku dekompozicí – každé vlákno zpracovává jinou část obrázku, výsledkem je spojení zpracovaných dat ze všech vláken; zde se hodí řešení s bariérou
- **client – server**

Thread-safe versus reentrantní

- *thead-safe* znamená, že kód může být volán z více vláken najednou bez destruktivních následků
  - do funkce, která nebyla navržena jako thread-safe, je možné přidat jeden zámek – na začátku funkce se zamkne, na konci odemkne
  - tento způsob ale samozřejmě není příliš efektivní
- slovem *reentrantní* se typicky myslí, že daná funkce byla navržena s přihlédnutím na existenci vláken
  - ... tedy že funkce pracuje efektivně i ve vícevláknovém prostředí
  - taková funkce by se měla vyvarovat použití statických dat a pokud možno i prostředků pro synchronizaci vláken, protože běh aplikace zpomalují

Nepřenositelná volání

- nepřenositelná volání končí řetězcem `_np` (*non-portable*) a jednotlivé systémy si takto definují vlastní volání
- FreeBSD
  - **`pthread_set_name_np(pthread_t tid, const char *name)`**

  → umožňuje pojmenovat vlákno
- Solaris
  - **`pthread_cond_reltimedwait_np(...)`**

  → jako timedwait, ale časový timeout je relativní
- OpenBSD
  - `int` **`pthread_main_np(void)`**

  → umožňuje zjistit, zda volající vlákno je hlavní (= `main()`)

The End.