

Programování v UNIXu

Jan Pechanec

verze: 17. prosince 2007

(c) 1999 – 2004 Martin Beran

(c) 2005 – 2007 Jan Pechanec

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

jp@devnull.cz

Organizační věci:

- tento předmět je 2/1, cvičení bude jednou za dva týdny v laboratoři UNIX
- všechny informace které budete potřebovat a materiály k přednášce jsou na <http://www.devnull.cz/mff>, včetně aktuální verze těchto poznámkových slajdů
- je potřeba se zapsat na cvičení na webu
- zápočet je za zápočtový program
- zkouška má písemnou a ústní část, je nutné získat zápočet **před zkouškou**, včetně předtermínů
- zkoušet se bude to, co bude odpředneseno (kromě témat na vyplnění případně zbylého času). Většina informací je ve slajdech, ale řada důležitých podrobností může chybět.
- předpoklady:
 - uživatelská znalost UNIXu, programování v shellu na úrovni přednášky „Úvod do UNIXu a TCP/IP“
 - znalost jazyka C
 - znalost základních pojmů teorie operačních systémů
- tento text je průběžně doplňován, ChangeLog začíná na straně 207.

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

- budeme se zabývat hlavně principy UNIXu a programováním pro UNIX pouze v jazyce C.
- **přednáška je převážně o systémových voláních, tj. rozhraním mezi uživatelským prostorem a jádrem**
- při popisu API se budeme držet normy *Single UNIX Specification, version 3*. Systémy podporující tuto specifikaci mohou používat označení UNIX 03. V současné době (09/2007) jsou to poslední verze systémů Solaris, AIX, HP-UX a Mac OS X.
- pro konkrétní příklady budu používat většinou systémy FreeBSD a Solaris.

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)

Ohledně Unixu doporučuji spíše literaturu v anglickém jazyce.

1. všestranný úvod do UNIXu, ale dost stručná; Skočovský je autorem více českých knih o Unixu, ale dnes jsou již více nebo méně zastaralé
2. pokročilejší pohled, ale předpokládá předběžné znalosti, místy těžko stravitelná
3. programování v C pro UNIX System V, práce se soubory a s procesy, System V IPC, nepopisuje např. vlákna a sítě
4. o Linuxu bylo samozřejmě v češtině vydáno mnoho dalších knih
5. vynikající knihy o jazyce C

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/>

Tyto knihy se zabývají stavbou Unixu, použitými algoritmy, strukturami apod., nejsou to knihy o programování pod tímto systémem.

1. skvělá kniha, zabývá se obecnými myšlenkami UNIXu a porovnává systémy SVR4.2, 4.4BSD, Solarix 2.x a Mach. 12/2005 mělo vyjít druhé, doplněné vydání. Termín se však několikrát posunul, a nyní (stav k 12/2007) toto druhé vydání stále ještě není k dispozici a aktuální plánovaný termín je 03/2008. Těžko ale říci, jestli k tomu ještě někdy vůbec dojde.
2. klasická kniha o UNIXu, popis struktury a funkcí jádra UNIX System V Rel. 2, částečně i 3; přestože je to kniha z dnešního pohledu již zastaralá, lze ji pořád jednoznačně doporučit protože to je jedna z nejlepších knih, co byla kdy o UNIXu napsána. V roce 1993 vyšel český překlad, **Principy operačního systému UNIX**, SAS.

3. popis struktury a funkcí jádra FreeBSD 5.2; tato kniha navazuje na klasickou knihu **The Design and Implementation of the 4.4 BSD Operating System** od stejného autora (resp. jeden ze čtyř, uvedený jako první)
4. nejlepší kniha o operačním systému Solaris. Obsahuje podrobné informace o tom, jak tento systém funguje včetně nejnovějších věcí z verze 10 jako jsou zóny, Crypto Framework, DTrace, Least Privilege model a další.
5. domovská strana Linux dokumentačního projektu

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)

1. pravděpodobně není lepší knihy o programování pod Unixem (neobsahuje síťové programování, to je v knize 3)
2. aktualizované vydání další z klasických knih o programování pod Unixem. Obsahuje i síťové programování a ač samozřejmě není tak podrobná jako spojení knih 1 a 3, může to být někdy naopak výhodou. Tuto knihu jednoznačně doporučuji, pokud chcete něco kupovat.
3. klasická kniha o síťovém programování, jedna z nejlepších k tomuto tématu; existuje i druhý díl **UNIX Network Programming, Volume 2: Interprocess Communications**, která se zabývá komunikací mezi procesy (roury, POSIX IPC, System V IPC, synchronizace vláken, RPC).
4. velmi dobrá a podrobná kniha o programování s vlákny
5. domovská stránka posledních specifikací rozhraní UNIXu
6. podrobný popis jednotlivých funkcí (v Linuxu běžně ne zcela dostačující; manuálové stránky v tomto systému jsou často horší kvality než u systémů ostatních)

- ... a spousta dalších knih, online dokumentací a internetových zdrojů, poslední dobou vychází poměrně hodně knih o Linuxu, zaměřených na používání i programování
- ... jděte na <http://www.amazon.com/> a zadejte klíčové slovo “unix”. Pokud byste z Amazonu něco kupovali, dejte pozor na to, že mnoho knih má aktualizovaná vydání i po několika málo letech, někdy i levnější než ta původní, která jsou však stále na skladu a v on-line nabídce; tak ať zbytečně nekoupíte starší vydání než to aktuální. Navíc se vyplatí zkontrolovat i u příslušného vydavatelství, že není v brzké době naplánováno vydání nové – tato informace někdy na Amazonu je, někdy ne.
- ... na Amazonu se může vyplatit nakoupit knihy z druhé ruky, protože jsou často výrazně levnější než knihy nové. Problém je, že většinou není možné je poslat přímo do ČR, ale musí vám je někdo přivést.

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

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

- kapitola o BSD Unixu napsaná Marshalllem Kirk McKusickem je opravdu výborná

(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 ⇒ Uni-cs ⇒ Uni-x
- 1971 – UNIX V1, a portován na PDP-11
- prosinec 1971 – první edice *UNIX Programmer's Manual*

- AT&T = American Telephone and Telegraph Company
- po odchodu BTL z projektu Multics prodala GE svoji počítačovou divizi firmě Honeywell včetně projektu Multics, který se pak pod její patronací dále vyvíjel (virtuální paměť, multiprocesory, ...). Poslední instalace Multics-u fungovala na kanadském Ministerstvu obrany (Canadian Department of National Defence) a systém byl například ještě aktivně používán pro vojenské operace během války v Perském zálivu. Definitivní *shutdown* byl proveden 31. října 2000. Více informací na <http://www.multicians.org>.
- před počátkem práce na vývojovém prostředí pro PDP-7 napsal Thompson program *Space Travel*, který byl vyvinut na jiném prostředí (Honeywell 635) a na pásce přenesen na PDP-7.
- celkem bylo 10 edicí tohoto manuálu, korespondující deseti verzím UNIXu vzniklých v BTL.
- UNIX V1 neměl `pipe()` !!!
- za povšimnutí stojí, že UNIX je zhruba o 10 let starší než DOS
- systém Multics měl 9 hlavních cílů, jak popsáno v článku *Introduction and Overview of the Multics System* z roku 1965. Za nejzajímavější cíl bych považoval požadavek na nepřerušovaný běh systému.
- Multics byl napsaný v jazyce PL/I (Programming Language #1), tedy dříve než byl UNIX přepsaný do C !
- Multicsu byl v roce 1980 udělen jako prvnímu systému level B2. Po několik let to byl jediný systém s tímto bezpečnostím levellem.

- GE byla založena v roce 1892 sloučením dvou společností, z nichž jedna byla Edison General Electric Company založená roku 1879 Thomasem Alvou Edisonem (vynálezce žárovky, filmové kamery, ...); v současné době její dceřinné společnosti pokrývají mnoho oblastí, včetně dodávky jednoho ze dvou typů motorů pro Airbus 380 nebo bankovníctví.
- PDP = Programmed Data Processor. První typ, *PDP-1*, se prodávala za \$120.000 v době, kdy se jiné počítače prodávaly za ceny přes milión. To byla také strategie fy DEC - pojem *computer* tehdy znamenal drahou věc, potřebující sál a tým lidí, který se o to všechno bude starat. Proto DEC své mašiny nenazýval počítači, ale právě slovem *PDPs*.
- PDP-11 je legendární mašina od firmy DEC, postupně vznikaly verze PDP-1 až PDP-16, kromě PDP-2, PDP-13. Existují PDP-11 systémy, které ještě dnes běží, a také firmy, které pro ně vyrábějí náhradní díly.

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

- ACM = Association for Computing Machinery, založena 1947.
- **akt přepsání UNIXu do jazyka C byl možná nejvýznamnějším momentem v historii tohoto systému** ⇒ UNIX mohl být mnohem jednodušeji portován na jiné architektury
- na verzi 6 je založena legendární kniha *A commentary on the Unix Operating System*, jejíž autorem je John Lions.
- Microsoft neprodával XENIX přímo, ale licencoval ho OEM výrobcům (Original Equipment Manufacturer) jako byl Intel, SCO a jiní. Jiné firmy pak XENIX dále portovaly na 286 (Intel) a 386 (SCO, 1987). Na webu je možné najít zajímavé informace popisující tuto dobu a tehdy kladný vztah Microsoftu k UNIXu.

- pokud vás více zajímá historie unixu, podívejte se na wikipedii na heslo “unix” a skrz odkazy máte na dlouho co číst.

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

- UNIX je univerzální operační systém fungující na široké škále počítačů od embedded a handheld systémů (Linux), přes osobní počítače až po velké servery a superpočítače.
- UNIX V3 = *UNIX verze 3*, UNIX V.4 = *system 5 release 4* atd., tj. UNIX V3 != SVR3.
- UNIX System III tedy není UNIX V3; v této době (pozdní 70. léta) bylo v BTL několik skupin, které přispívaly do vývoje UNIXu. Vx verze byly vyvíjeny v rámci *Computer Research Group*, další skupiny byly *Unix System Group* (USG), *Programmer's WorkBench* (PWB). Další větví UNIXu byl Columbus UNIX též v rámci BT. Na těchto různých verzích je právě založena verze System III. Zájemce o více informací odkazují na web.
- UNIX se rozštěpil na dvě hlavní větve: AT&T a BSD, jednotliví výrobci přicházeli s vlastními modifikacemi. **Jednotlivé klony od sebe navzájem přebíraly vlastnosti.**
- Berkeley univerzita získala jako jedna z prvních licenci UNIXu v roce 1974. Během několika let studenti (jedním z nich byl Bill Joy, pozdější zakladatel firmy Sun Microsystems a autor C-shellu) vytvořili SW balík *Berkeley Software Distribution* (BSD) a prodávali ho v roce 1978 za \$50. Tyto počáteční verze BSD obsahovaly pouze SW a utility (první verze: Pascal překladač, editor *ex*), ne systém ani žádné jeho změny. To přišlo až s verzí 3BSD. verze 4BSD vzniká roku 1980 již jako projekt financovaný agenturou DARPA a vedený Billem Joyem. Trpí problémy spojenými s nedostatečným výkonem a vzniká tak vyladěný systém 4.1BSD dodávaný od roku 1981.

- 4.1BSD mělo být původně 5BSD, ale poté, co AT&T vzneslo námitky, že by si zákazníci mohli plést 5BSD se systémem System V, přešlo BSD na číslování 4.xBSD. Běžnou věcí bylo, že než psát vlastní kód, vývojáři z Berkeley se raději nejdříve podívali kolem, co je již hotové. Tak BSD například převzalo virtuální paměť z Machu a nebo NFS-compatible kód vyvinutý na jedné kanadské univerzitě.
- výrobci hardware dodávali varianty UNIXu pro své počítače a komercializace tak ještě zhoršila situaci co týče diverzifikace UNIXu
- v 80-tých letech se proto začaly objevovat snahy o standardizaci. Standard říká, jak má vypadat systém navenek (pro uživatele, programátora a správce), nezabývá se implementací. Cílem je přenositelnost aplikací i uživatelů. všechny systémy totiž z dálky vypadaly jako UNIX, ale z blízka se lišily v mnoha důležitých vlastnostech. System V a BSD se např. lišily v použitém file-systému, síťové architektuře i v architektuře virtuální paměti.
- když v roce 1987 firmy AT&T a Sun (jehož tehdejší SunOS byl založený na BSD) spojily svoje úsilí na vyvinutí jednoho systému, který by obsahoval to nejlepší z obou větví, kromě nadšených reakcí to vzbudilo i strach u mnoha dalších výrobců unixových systémů, kteří se báli, že by to pro obě firmy znamenalo obrovskou komerční výhodu. Vzniká proto Open Software Foundation (nezaměňovat za FSF), a zakládajícími členy byly mimo jiné firmy Hewlett-Packard, IBM a Digital. Z toho vzešlý systém OSF/1 ale nebyl příliš úspěšný, a dodával ho pouze Digital, který ho přejmenoval na Digital UNIX. Zajímavostí je, že systém je postavený na mikrojádru Mach. Po akvizici Digitalu Compaqem byl systém přejmenován na Tru64 a s tímto jménem je dále podporován firmou Hewlett-Packard, která se v roce 2002 s Compaqem spojila. Mezitím firmy AT&T a Sun kontrovaly založením UNIX International. Toto období přelomu 80-tých a 90-tých let se nazývá **Unix Wars** – boj o to, co bude “standardním unixem”.
- OSF a UI se staly velkými rivaly, ale velmi rychle se střetly s nečekaným protivníkem - s firmou Microsoft.
- (1992) 386BSD založené na *Networking Release 2*; Bill Jolitz vytvořil 6 chybějících souborů a dal tak dohromady funkční BSD systém pro i386. Tento systém se stal základem systémů *NetBSD* a *FreeBSD* (a dalších, z těchto dvou systémů vycházejících).
- (1995) 4.4BSD-Lite Release 2, po které následuje rozpuštění CSRG, která skoro 20 let pilotovala vývoj BSD větve. Více již zmíněná kapitola o BSD Unixu.

Současné UNIXy

Hlavní komerční unixové systémy:

- Sun Microsystems: **SunOS** (není již dále vyvíjen), **Solaris**
- SGI: **IRIX**
- IBM: **AIX**
- HP: **HP-UX**
- HP (předtím Compaq): **Tru64 UNIX**
- SCO: **SCO Unix**
- Novell: **UNIXware**

Open source:

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

- když jsem cca v roce 1998 projel nmapem všechny DNS root servery, abych zjistil na kterých systémech běží, bylo 80% z nich na SunOS/Solaris. IRIX je zase systém, který po mnoho let ovládal televizní/filmový průmysl (např. Pixar studio kde na IRIXu vznikly filmy jako *A Bug's Life*, *Toy Story* a další). A na AIX například běžel *Blue Deep*, paralelní superpočítač, který v roce 1997 porazil v šesti fascinujících zápasech 3.5 ku 2.5 úřadujícího velmistra šachu Garriho Kasparova. Jinými slovy – každý systém má svoje úspěchy.
- jak již bylo zmíněno, Tru64 UNIX vychází z OSF/1 firmy DEC. Ta předtím dodávala Ultrix, založený na BSD unixu.
- OpenSolaris je projekt vzniklý v červnu 2005 a je založen na podmnožině zdrojových textů vývojové verze Solarisu (kernel, knihovny, příkazy) k datu uvedení. Oficiální distribuce založená na OpenSolarisu se jmenuje *Solaris Express*. Distribuce vzešlé z komunity jsou například LiveCD *BeleniX*, *SchilliX* a *Nexenta*.
- pozor na to, že Linux je pouze jádro, ne systém, na rozdíl třeba od FreeBSD. OpenSolaris je něco mezi tím, jádro + drivery, základní příkazy a knihovny, a v binární podobě to má něco přes 100MB. V obou případech je tedy správné používat spojení “Linux (OpenSolaris) distribuce”, když se bavíme o celém systému.
- každá komerční varianta vycházela z jednoho ze dvou hlavních systémů – UNIX V nebo BSD, a přidávala si své vlastnosti
- vzniká velký počet různých standardů (viz následující strana), skoro jako počet různých verzí UNIXů. Nakonec se většina výrobců shodla na několika základních standardech.

- graf znázorňující historii Unixu a závislosti mezi systémy na 19-ti A4 listech ve formátu PS/PDF je k nalezení na <http://www.levenez.com/unix>

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 3 (**UNIX 03**), předchází Version 2 (**UNIX 98**)
 - splnění je nutnou podmínkou pro užití obchodního názvu UNIX

- AT&T dovolila výrobcům nazývat svoji komerční UNIX variantu “System V” pouze pokud splňovala podmínky standardu SVID. AT&T také publikovala *System V Verification Suite* (SVVS), které ověřilo, zda daný systém odpovídá standardu.
- POSIX (Portable Operating System Interface) je standardizační snaha organizace IEEE (Institute of Electrical and Electronics Engineers). Prvním dokumentem je *IEEE Std POSIX1003.1-1988*, dříve označovaný prostě jako POSIX, dnes známý spíše jako *POSIX.1*, protože POSIXem se nyní míní sada vzájemně souvisejících standardů. POSIX.1 obsahuje programovací API, tj. práce s procesy, signály, soubory, časovači atd. S malými změnami byl převzat organizací ISO, a označovaný jako POSIX1990. Tento standard byl sám o sobě velký úspěch, ale stále ještě nespojoval tábory System V a BSD, protože v sobě například nezahrnoval BSD sockety nebo IPC (semaforey, zprávy, sdílená paměť) ze System V. Označení POSIX vymyslel Richard Stallman, tedy člověk, který v roce 1983 založil GNU projekt. Součástí standardu je i “POSIX conformance test suite (PCTS)”, který je volně k dispozici.
- SUSV3 je společný standard The Open Group, IEEE (Std. 1003.1, 2003 Edition) a ISO (ISO/IEC 9945-2003).
- dnes je asi nejdůležitější Single UNIX Specification, které se budeme držet i my. Tato norma je podmínkou pro užití názvu UNIX, Je postavena na bázi POSIXu. Popis datových struktur a algoritmů jádra v tomto materiálu bude většinou vycházet ze System V Rel. 4.

Jazyk C

- téměř celý UNIX je napsaný v C, pouze nejnižší strojově závislá část v assembleru \Rightarrow 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**

- CPL \Rightarrow BCPL \Rightarrow B (Thompson, interpret) \Rightarrow C
- K&R C – jazyk C tak, jak je popsán v klasické knize Brian W. Kernighan, Dennis M. Ritchie: The C Programming Language (Prentice-Hall, 1978).
- v roce 1983 ANSI (American National Standards Institute) zformoval výbor pro vytvoření C standardu. Po dlouhém a pracném procesu byl v roce 1989 standard konečně hotov, a je známý nejčastěji jako “ANSI C”, případně jako C89 (například překladač pro tuto normu se v Sun Studiu jmenuje `c89`, jelikož i to samotné jméno programu musí být podle normy). Druhé vydání K&R knihy (1988) je již upravené právě pro nadcházející ANSI C. V roce 1990 bylo ANSI C adoptováno organizací ISO jako ISO/IEC 9899:1990; tento C standard tak může být někdy označován i jako C90.
- se C standardem se pak nějakou dobu nehýbalo, až na konci 90-tých let prošel další revizí v rámci ISO a vzniká ISO 9899:1999, častěji označovaný jako C99. V roce 2000 pak naopak tento standard převzal ANSI.
- rozdíly mezi C89 a C99 jsou mimo jiné zahrnutí inline funkcí, definicí proměnných například i do `for` konstrukce, jednořádkových komentářů pomocí `//`, nových funkcí jako `snprintf()` apod.

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

- velký pozor na výstupy programů typu `hexdump`, které defaultně vypisují soubor ve 2-bajtových číslech, což svádí vidět soubor jinak, než jak je opravdu zapsaný na disku; viz příklad (i386, FreeBSD):

```
$ echo -n 1234 > test
$ hexdump test
00000000 3231 3433
00000004
```

je samozřejmě možné použít jiný formát výstupu:

```
$ hexdump -C test
00000000 31 32 33 34 |1234|
00000004
```

- UNIX norma příkaz `hexdump` nemá, ale definuje `od` (octal dump), takže zde je jeho `hexdumpu` ekvivalentní formát výpisu na SPARCu (Solaris); všimněte si změny oproti výpisu pod FreeBSD!

```
$ od -tx2 test
00000000 3132 3334
00000004
```

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 */ }
```

- používejte pouze novější (ANSI) typ deklarací a vždy deklarujte prototypy funkcí, tj. inkludujte hlavičkové soubory. Výjimkou může asi jen to, pokud budete pracovat s kódem, který byl napsaný podle K&R.
- různými zápisy deklarací se dostáváme rovnou i k různým stylům psaní zdrojových textů. Některé systémy to příliš neřeší (Linux), jiné systémy mají velmi striktní pravidla pro psaní zdrojových textů (např. Solaris, viz on-line *C Style and Coding Standards for SunOS*). Skoro každý UNIXový systém má program `indent(1)`, který vám pomocí přepínačů přeformátuje jakýkoli C zdrojový text do požadovaného výstupu.

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);
}
```

- u C stylu je nejdůležitější to, aby byl konzistentní. Pokud skupina programátorů pracuje na jednom projektu, není zas až tak důležité, na jakém stylu se dohodnout (pokud je alespoň trochu rozumný), ale aby se dohodli. Jednotný a dobře zvolený styl šetří čas a brání zbytečným chybám.

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);
}
```

- pamatujte na to, že dobrý styl zdrojových kódů je i vizitkou programátora. Když se v rámci přijímacích pohovorů odevzdávají i ukázkové kódy, tak hlavní důvod není ten, aby se zjistilo, že vám daný program funguje... Úprava samotného zdrojového textu je jedním z kritérií, protože to přeneseně může svědčit i o dalších skutečnostech – někdo např. bude odhadovat, že pokud píšete nečistý a neupravený kód, tak jste možná ještě nepracovali na něčem opravdu složitém či něčem zahrnujícím spolupráci s více programátory, protože v tom případě je rozumně čistý kód jednou z podmínek úspěchu a jednou ze zkušeností, které z takové spolupráce vycházejí. Toto je samozřejmě zčásti subjektivní názor, ale čistým kódem nic nezkazíte, minimálně nezkazíte oči svým cvičícím.

Utility

cc , c99 [*] , gcc [†]	překladač C
CC , g++ [†]	překladač C++
ld	spojovací program (linker)
ldd	pro zjištění 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 [†]	debugery
prof , gprof [†]	profilery

* UNIX 03 † GNU

UNIX 03

- standardní příkaz volání kompilátoru a linkeru C je **c99** (podle ISO normy pro C z roku 1999)
- **cb** (C program beautifier) není
- pro správu verzí je **sccs**
- debugery a profilery nejsou

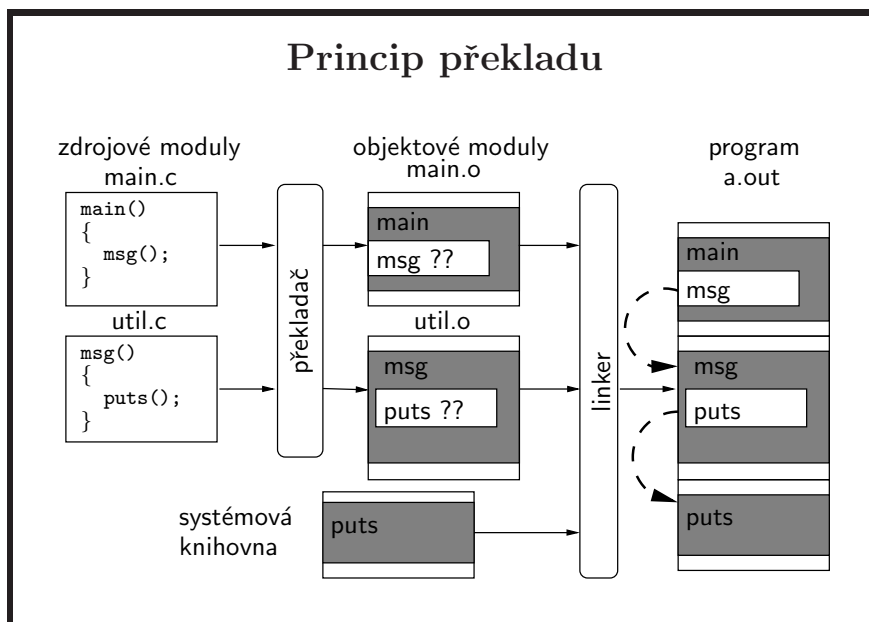
Konvence pro jména souborů

<code>*.c</code>	jména zdrojových souborů programů v C
<code>*.cc</code>	jména zdrojových souborů programů v C++
<code>*.h</code>	jména hlavičkových souborů (headerů)
<code>*.o</code>	přeložené moduly (object files)
<code>a.out</code>	jméno spustitelného souboru (výsledek úspěšné kompilace)
<code>/usr/</code>	kořen stromu systémových headerů
<code>/usr/lib/lib*.a</code>	statické knihovny objektových modulů
<code>/usr/lib/lib*.so</code>	umístění dynamických sdílených knihoven objektových modulů

statické knihovny – při linkování se stanou součástí výsledného spustitelného programu. Dnes se už moc nepoužívá.

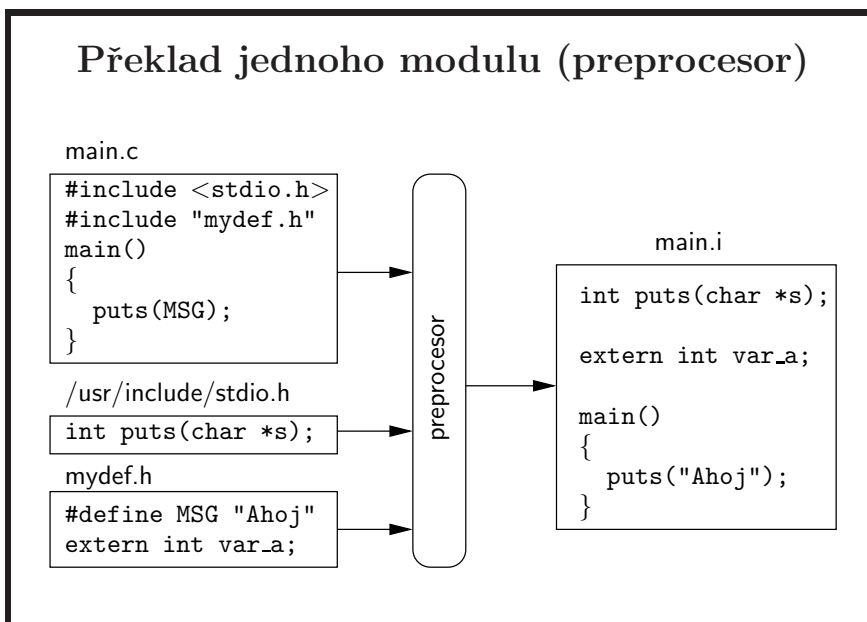
sdílené knihovny – program obsahuje pouze odkaz na knihovnu, při spuštění programu se potřebné knihovny načtou do paměti ze souborů `*.so` a přilinkují.

- dnes se většinou používají sdílené knihovny, protože nezabírají tolik diskového prostoru (knihovna je na disku jednou, není součástí každého spustitelného souboru) a snadněji se upgradují (stačí instalovat novou verzi knihovny, není třeba přelinkovat programy). Poslední verze Solarisu už například vůbec neobsahuje `libc.a`, díky čemuž již programátor nemůže vytvořit statickou binárku, aniž by neměl dostatečné znalosti systému.
- někdy se bez statických knihoven neobejdeme. V některých situacích není možné použít knihovny dynamické, spustitelné soubory jsou takzvané *standalone binaries* a použití naleznou například při bootování operačního systému.



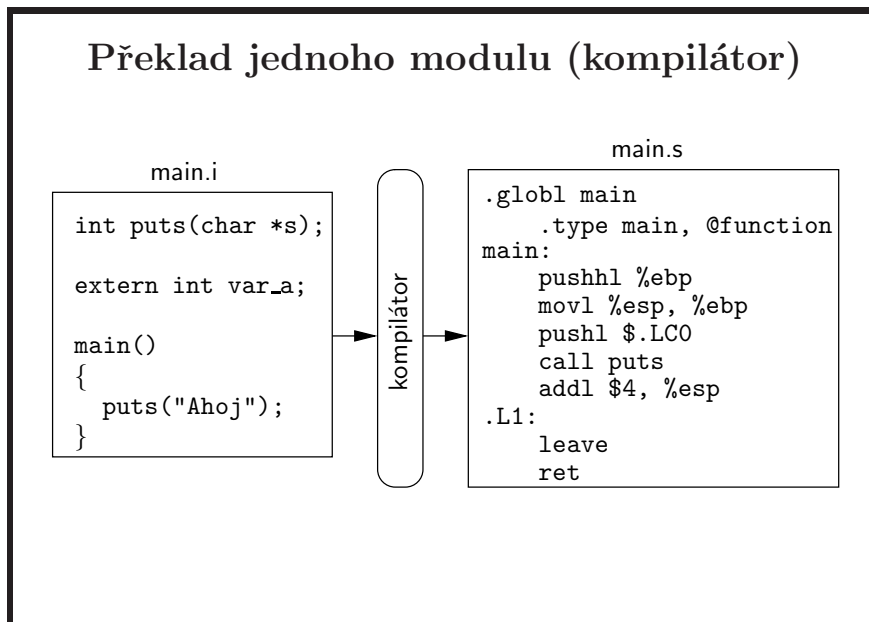
- u složitějších programů bývá zvykem rozdělit zdrojový text programu do několika modulů, které obsahují příbuzné funkce a tyto moduly se pak mohou překládat zvlášť (dokonce každý modul může být v jiném jazyce a překládán jiným překladačem). Výhodou je jednak urychlení překladač (překládají se vždy jen moduly změněné od posledního překladač) a jednak flexibilita (některé moduly se mohou používat v různých programech). Pro řízení překladač se obvykle používá utilita `make`.
- *překladač* jednotlivé zdrojové moduly přeloží do tvaru tzv. *objektových modulů*, jež obsahují kód programu (včetně volání lokálních funkcí), ale namísto volání externích funkcí obsahují jen tabulku jejich jmen.
- po fázi překladač nastupuje *spojovací program* (též *linker* editor nebo *loader*), který zkompletuje výsledný program včetně vyřešení externích odkazů mezi moduly a systémovými knihovnami resp. mezi moduly navzájem.
- použité statické knihovny jsou zkopírovány do spustitelného souboru. Na sdílené knihovny jsou ve spustitelném souboru pouze odkazy a linkuje je runtime linker při každém spuštění programu. Více viz dynamický linker na straně 31.
- pomocí parametrů linkeru lze určit, zda se budou používat statické nebo dynamické knihovny. Zdrojový kód je v obou případech stejný. Existuje i mechanismus (`dlopen()`, `dlsym()`...), pomocí kterého se za běhu programu vybere sdílená knihovna a dají se volat její funkce. Tímto způsobem můžete také zjistit, zda v systému je přítomna příslušná funkcionalita a pokud ne, zachovat se podle toho.

Překlad jednoho modulu (preprocessor)



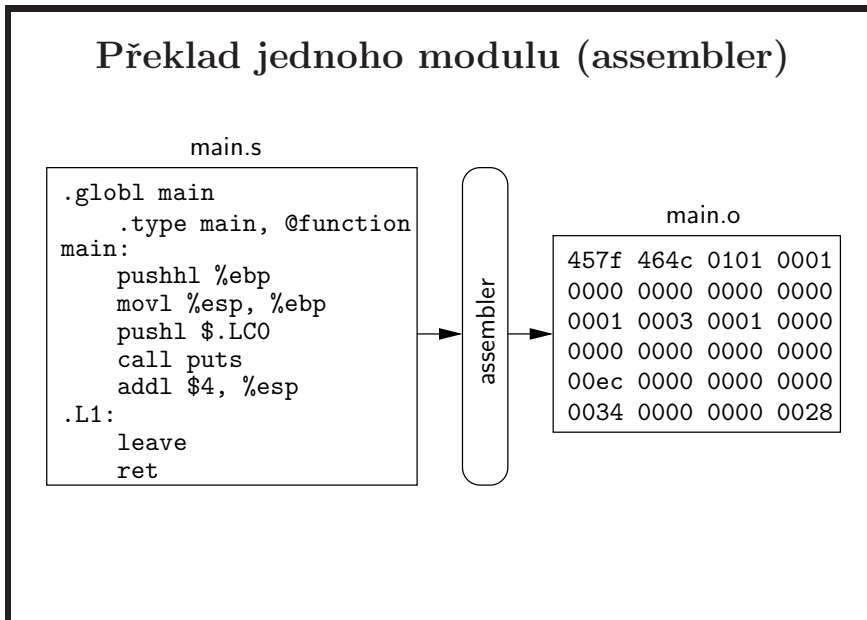
- preprocessor provádí expanzi maker, čtení vložených () souborů a vynechává komentáře.
- výstup preprocessoru lze získat pomocí `cc -E` případně přímo zavoláním `cpp`, nemusí to být ale vždy totéž protože některé překladače mají preprocessor integrován v sobě. Preprocessor můžete samozřejmě používat i pro jiné projekty, které s překladem zdrojových souborů v jazyce C nemusí mít vůbec nic společného.
- použití preprocessoru se může velmi hodit v situaci, kdy potřebujete zasáhnout do cizího kódu, plného podmínečných vkládání různých hlavičkových souborů a různých definic závislých na daných podmínkách. Při hledání původce chyby vám právě může hodně pomoci samostatného zpracování vstupního souboru pomocí preprocesuru, kde problém již většinou rozpoznáte snadno.
- `cpp` vám dokáže na standardní chybový výstup zobrazit i celý strom vkládaných souborů, což opět při podmínečných překladech může být velmi užitečná věc. Stačí pro to použít volbu `-H` a přesměrovat výstup do `/dev/null` čímž dostanete pouze hierarchii vkládaných hlavičkových souborů.

Překlad jednoho modulu (kompilátor)



- překlad z C do assembleru
- výstup této fáze překladu lze získat pomocí `cc -S`.

Překlad jednoho modulu (assembler)



- překlad z assembleru do strojového kódu
- objektový modul je výsledkem příkazu `cc -c`.

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

- -l/-L jsou přepínače linker editoru, tj. kompilátor příslušné informace předá, ale jsou používány tak často, že jsou vloženy i do tohoto slajdu.
- kompilátor a linker mají mnoho dalších přepínačů ovlivňujících generovaný kód, vypisování varovných hlášení nebo variantu jazyka (K&R/ANSI). Je třeba nastudovat dokumentaci konkrétního produktu.

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 načtete `unistd.h`.

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

- funguje to tak, že pomocí konkrétních maker definujete co chcete (např. `_POSIX_SOURCE`) a podle nastavení jiných maker (např. `_POSIX_VERSION`) pak zjistíte, co jste dostali. Musíte ale vždy po nastavení maker nainkludovat `unistd.h`. Například se pokusíme přeložit program, který vyžaduje SUS3, na systému podporujícím SUS3 (Solaris 10), ale překladačem, který podporuje pouze SUS2 (UNIX03 překladač je c99).

```
$ cat standards.c
#define _XOPEN_SOURCE 600
/* you must #include at least one header !!! */
#include <stdio.h>
int main(void)
{
    return (0);
}
$ cc standards.c
"/usr//sys/feature_tests.h", line 336: #error: "Compiler or
options invalid; UNIX 03 and POSIX.1-2001 applications require
the use of c99"
cc: acomp failed for standards.c
```

- zdroj maker pro standard tedy může být `/usr//sys/feature_tests.h` na Solarisu. Buď ho najdete přímo na Solaris systému nebo přes code browser na www.opensolaris.org.
- v dokumentaci konkrétního kompilátoru je možné najít, která další makra se používají. Množství maker je definováno také v systémových hlavičkových souborech.

- POSIX.1 v sobě zahrnuje ANSI C; tedy C89, ne C99 (o C standardech více na straně 13).
- co se týče maker k jednotlivým standardům, velmi dobrá je kapitola 1.5 v [Rochkind]. Také doporučuji C program `c1/svreq.c` k této kapitole, který je možné najít i na mých stránkách v sekci ukázkových příkladů.
- malý příklad na podmíněný překlad:

```
int
main(void)
{
#ifdef unix
    printf("yeah\n");
#else
    printf("grr\n");
#endif
    return (0);
}
```

Linker

- Volání:
`ld [options] soubor ...`
`cc [options] soubor ...`
- Nejdůležitější přepínače:
 - o *soubor* jméno výsledného souboru (default `a.out`)
 - l*lib* linkuj s knihovnou `liblib.so` nebo `liblib.a`
 - L*path* cesta pro knihovny (`-llib`)
 - shared vytvořit sdílenou knihovnu
 - non_shared vytvořit statický program

- linker je program, který vezme typicky více objektů vygenerovaných překladačem a vytvoří z nich binární program, knihovnu nebo další objekt vhodný pro další fázi linkování.
- pozor na to, že na různých systémech se některé přepínače mohou lišit, například `ld` na Solarisu nezná přepínače `-shared` a `-non_shared`, je nutné použít jiné.
- u malých programů (v jednom souboru) lze provést překlad a linkování jedním příkazem `cc`. U větších programů skládajících se z mnoha zdrojových

souborů a knihoven se obvykle odděluje překlad a linkování a celý proces je řízen utilitou `make`.

Řízení překladu a linkování (make)

- zdrojové texty

<pre>main.c #include "util.h" main() { msg(); }</pre>	<pre>util.h void msg();</pre>	<pre>util.c #include "util.h" msg() { puts(); }</pre>
---	-------------------------------	---

- závislosti

```
main.c  \
         \  main.o
util.h   /
         /  /
util.c   /  /  util.o
         /  /  /
         /  /  /  prog
```

- 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
```

- program je možné také přeložit a slinkovat jedním voláním kompilátoru, nebo definovat postup překladu a linkování pomocí shellového skriptu. Důvodem pro použití `make` je to, že vyhodnocuje závislosti mezi soubory a po změně některého zdrojového souboru překládá jenom to, co na něm závisí. Častý způsob překladu softwaru po aplikování změn způsobem “`make clean; make all`” je v situaci, kdy celý překlad trvá minuty (desítky minut, hodiny...), trochu nevhodný – právě proto je důležité mít dobře napsaný `Makefile`.
- řádek “`prog : main.o util.o`” definuje, že se má nejprve rekurzivně zajistit existence a aktuálnost souborů `main.o` a `util.o`. Pak se zkontroluje, zda soubor (cíl) `prog` existuje a je aktuální (datum poslední modifikace souboru je mladší než `main.o` a `util.o`). Pokud ano, nedělá se nic. Když ne, provede se příkaz na následujícím řádku.
- `make` se spouští typicky s parametrem určující příslušný cíl (*target*); při spuštění bez parametrů se vezme první target. Ten typicky bývá `all`, což většinou podle unixové konvence přeloží vše, co se přeložit má. Následuje pak třeba zavolání `make` s parametrem `install` apod.
- `make` je samozřejmě univerzální nástroj, použitelný i jinde než u překladů

Syntaxe vstupního souboru (make)

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

- **pozor na to, že řádek s příkazem začíná tabulátorem, nikoliv mezerami.** Každý příkazový řádek se provádí samostatným shellem, pokud je potřeba provést více řádků pomocí jednoho shellu, musí se všechny až na poslední ukončit backslashem (shell je dostane jako jeden řádek). Viz příklad, ve kterém dva poslední echo příkazy jsou součástí jednoho if příkazu, který je spuštěn samostatným shellem:

```
$ cat Makefile
# Makefile test

all:
    @echo $$$$
    @echo $$$$
    @if true; then \  
        echo $$$$; \  
        echo $$$$; \  
    fi

$ make
5513
5514
5515
5515
```

- zdvojením \$ se potlačí speciální význam dolaru (viz následující slajd)
- znak @ na začátku řádku potlačí jeho výpis – make jinak standardně vypisuje nejdříve to, co bude vykonávat.

- znak `-` na začátku řádku způsobí ignorování nenulové návratové hodnoty; jinak `make` vždy v takové situaci zahlásí chybu a okamžitě skončí.
- `test1:`
`false`
`echo "OK"`
- `test2:`
`-false`
`echo "OK"`

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

- když je stejné makro definováno vícekrát, platí poslední definice.
- makra není možné definovat rekurzivně.

```
$ cat Makefile
M=value1
M=$(M) value2
all:
    echo $(M)
$ make
Variable M is recursive.
```

- často se používají různé rozšířené verze `make` (např. GNU, BSD), které umí, podmíněně sekce v `Makefile`, redefinice proměnných, apod.
- napsat `Makefile` který bude fungovat najednou pro různé verze `make` nemusí být jednoduché, proto existují projekty jako je např. GNU automake. Pro jednoduchý podmíněčný překlad v závislosti na systému a kde se dají očekávat

různé verze příkazu make, je možné použít například následující kód, který mi fungoval na všech v něm zmíněných systémech (znak ' je zpětná uvozovka, a ' je normální uvozovka):

```
CFLAGS='x=\`uname\`; \  
    if [ $$x = FreeBSD ]; then \  
        echo '-Wall'; \  
    elif [ $$x = SunOS ]; then \  
        echo '-v'; \  
    elif [ $$x = Linux ]; then \  
        echo '-Wall -g'; \  
    fi \  
  
all: \  
    @echo "$ (CFLAGS)"
```

- v ostatních situacích je vhodné, případně nezbytné použít programy typu autoconf nebo automake
- make je velmi silný nástroj, stačí se podívat do systémových Makefile souborů jakéhokoli Unixového systému. Typickou společnou vlastností je to, že neexistuje dokumentace jak je daný makefile framework postaven.

Dynamický linker

Při překlada je nutné mít všechny potřebné dynamické knihovny, protože se kontroluje dosažitelnost použitých symbolů, **sestavení kompletního programu 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)

Následující příkazy a příklady se týkají Solarisu. Pokud to nebude fungovat na jiných systémech, tak mají ekvivaletní nástroje s podobnou funkcionalitou.

- proces spuštění dynamicky slinkovaného programu probíhá tak, že kernel ve volání `exec()` namapuje daný program do paměti a zjistí, jaký dynamický linker se má použít (viz dále). Před tím, než jádro předá linkeru kontrolu, linker

namapuje do paměťového prostoru spouštěného procesu. Linker z hlavičky programu zjistí, jaké dynamické knihovny se mají dále namapovat, provede to a teprve pak předá řízení vašemu programu. Váš program může za běhu dále využívat dynamický linker pomocí volání typu `dlopen()` a spol. (k tomu se také dostaneme později). Uvědomte si, že dynamický linker zde nepracuje jako samostatný proces, jeho kód se používá v rámci paměťového prostoru vašeho procesu; váš program, linker a knihovny dohromady tvoří jeden proces.

- seznam sekcí se zjistí pomocí `elfdump -c` (GNU má příkaz `readelf`). O programových sekcích bude více na straně 115.
- jaký dynamický linker se použije kernel zjistí ze sekce `.interp`, viz "`elfdump -i`" a "`ld -I`". To znamená, že si můžete napsat vlastní linker a pomocí `-I` pro `ld` ho pak nastavit jako dynamický linker pro váš program.
- dynamická sekce se vypíše pomocí `elfdump -d`, dynamické knihovny jsou označené tagem `NEEDED`
- závislosti na dynamických knihovnách je možné dobře zjistit pomocí příkazu `ldd`, který zjistí konkrétní cesty ke knihovnám. Tento příkaz řeší závislosti rekurzivně, tj. uvidíte tedy i nepřímé závislosti - tj. takové knihovny, které jsou použité knihovnami, které příslušný program používá přímo. Zjistit co je přesně závislé na čem je možné pomocí volby `-v`.
- jaké knihovny byly při spuštění nakonec použity může být jiné než co ukáže příkaz `ldd`, a to třeba díky mechanismu `LD_PRELOAD`, na Solarisu proto existuje příkaz `pldd`, který pomocí čísla procesu ukáže závislosti konkrétního spuštěného programu.
- více viz manuálová stránka pro dynamický linker v Solarisu, `ld.so.1`, případně *Linker and Libraries Guide* na `docs.sun.com`. Na FreeBSD se dynamický linker nazývá `ld-elf.so.1`, na Linuxu `ld-linux.so.1`, na IRIXu `rld` atd.
- dynamický linker se typicky dá konfigurovat pomocí nastavení proměnných, například si zkuste na Solarisu spustit toto:

```
LD_LIBRARY_PATH=/tmp LD_DEBUG=libs,detail date
```

a pro všechny možnosti jak debugovat dynamický linker použijte:

```
LD_DEBUG=help date
```

- jiný příklad, kdy linker hledá knihovny i jinde než v defaultních adresářích:

```
$ cp /lib/libc.so.1 /tmp
$ LD_LIBRARY_PATH=/tmp sleep 100 &
[1] 104547
$ pldd 104547
104547: sleep 100
/tmp/libc.so.1
/usr/lib/locale/cs_CZ.IS08859-2/cs_CZ.IS08859-2.so.3
```


API vers 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 text* 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

- příkladem API je třeba API definované normou POSIX.1
- ABI definuje konvenci volání (to jak program předá parametry funkci a jak od ní převezme návratovou hodnotu), jaká jsou čísla systémových volání, jak se systémové volání provede či formát objektového modulu či přijímaných argumentů, viz příklad dole.
- ABI knihovny pak definuje mimo jiné množinu volání která jsou knihovnou definována, jejich parametry a typy těchto parametrů
- následná ukázka je příklad na to, kdy vývojář změní velikost argumentů v bajtech (tj. změní ABI knihovny), a nahradí novou verzí tu starou. Všimněte si, že dynamický linker toto nezjistí; nemá totiž jak, řídí se podle jména knihovny v dynamické sekci programu, a to se nezměnilo. Uvedená změna je sice i změna v API a problém by se odstranil, kdybychom `main.c` znovu přeložili se změněným řádkem deklarace funkce `add()`. To je ale často problém (překládejte celý systém jen kvůli tomu), proto je tak důležité dodržovat zpětnou kompatibilitu v ABI u knihoven.

Výsledek následujícího překladu knihovny, programu a jeho spuštění je jak bychom očekávali (použit `cc` ze SunStudio, pro `gcc` použijte místo `-G` volbu `-shared`; novější `gcc` navíc neznají `-R` a je místo toho nutné použít `-Xlinker -R -Xlinker ..`

```
$ cat main.c
int my_add(int a, int b);

int
main(void)
```

```
{
    printf("%d\n", my_add(128, 1));
    return (0);
}
```

```
$ cat add.c
int
my_add(int a, int b)
{
    return (a + b);
}
```

```
$ cc -G -o libadd.so add.c
$ cc -L. -ladd -R. main.c
$ ./a.out
129
```

Nyní ale přišla další verze knihovny se stejným jménem, a ve funkci `add()` nastala změna v typu argumentů. Program ale o ničem neví, nechá se spustit a vrátí chybnou hodnotu:

```
$ cat add2.c
int
my_add(char a, char b)
{
    return (a + b);
}
```

```
$ cc -G -o libadd.so add2.c
$ ./a.out
-127
```

- zde pak přichází ke slovu verzování knihoven, tj. je nutné “něco” změnit tak, aby po instalaci nové knihovny nešlo program spustit bez jeho rekompilace.

Debugger dbx

- Volání:
dbx [*options*] [*program* [*core*]]
- Nejběžnější příkazy:

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

- základní řádkový symbolický debugger, aby bylo možné ho plně využít, musí být program přeložen s ladicími informacemi (cc -g). Laděný program se startuje z debuggeru příkazem run, nebo se debugger připojí k již běžícímu procesu. Pomocí dbx lze analyzovat i havarovaný program, který vygeneroval soubor core.
- je možné ho najít např. na Solarisu, na Linuxu a FreeBSD defaultně není.
- pro debugging se zdrojovými kódy nestačí použít volbu -g, je zároveň nutné mít i zdrojáky a objektové moduly tam, kde byly při překladu. To je typicky běžná situace, protože ladíte na stroji, kde zároveň i vyvíjíte. Pokud tomu tak není, je nutné si zdrojáky a objektové moduly zajistit, pokud k nim vede jiná cesta, lze použít dbx příkaz pathmap.
- gdb-kompatibilní mód se spustí přes gdb on. Pokud vás zajímá, jaký má dbx ekvivalentní příkaz ke konkrétnímu gdb příkazu, pomůže vám help FAQ; hned první otázka je "A.1 Gdb does <something>; how do I do it in dbx?"

GNU debugger gdb

- Volání:
`gdb [options] [program [core]]`
- Nejběžnější příkazy:

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

- GNU obdoba `dbx`. Mód kompatibilní s `dbx` spustíte přes `-dbx`.
- na různých platformách existují i debugery s grafickým rozhraním, např. `debugger` (Solaris), `cvd` (IRIX), `xxgdb` (GNU), `ddd` (GNU). Často fungují jako nadstavby nad `dbx`, `gdb`.

- ```
#include <stdio.h>
int main(void) {
 printf("hello, world\n");
 return 0;
}
$ cc -g main.c
$ gdb -q a.out
(gdb) break main
Breakpoint 1 at 0x8048548: file main.c, line 4.
(gdb) run
Starting program: /share/home/jp/src/gdb/a.out

Breakpoint 1, main () at main.c:4
4 printf("hello, world\n");
(gdb) next
hello, world
5 return 0;
(gdb) c
Continuing.
Program exited normally.
(gdb) q
```

- debugery jsou výbornými pomocníky pokud váš program končí na chyby

typu “segmentation error” – tj. když zkusíte nekorektně přistoupit do paměti, například tam kde nemáte co dělat. Když při překladu použijete option `-g`, ukáže vám pak debugger přesně číslo řádku, kde nastal problém. Konkrétní příklad (proč se vlastně tento program chová jak se chová??? Hint: zkuste přeložit na Solarisu překladačem `cc` a spustit):

```
$ cat -n main.c
 1 int
 2 main(void)
 3 {
 4 char *c = "hey world";
 5 c[0] = '\0';
 6 return (0);
 7 }
}
$ gcc -g main.c
$./a.out
Bus error (core dumped)
$ gdb a.out a.out.core
...
Core was generated by 'a.out'.
Program terminated with signal 10, Bus error.
...
#0 0x080484e6 in main () at main.c:5
5 c[0] = '\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

## Standardní hlavičkové soubory (ANSI C)

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

- hlavičkový soubor (*header file*) je soubor s deklaracemi funkcí (*forward declaration*), proměnných a maker. Z pohledu preprocesoru je to obyčejný soubor napsaný v jazyce C.
- pozor na to, že tyto hlavičkové soubory nejsou specifické pro UNIX. Jsou součástí standardu ANSI C, který jak již víme (strana 13), je zahrnut v POSIX.1.
- příslušný hlavičkový soubor pro konkrétní funkci najdete v manuálové stránce dané funkce, toto je začátek manuálové stránky na Solarisu pro `memcpy()`:

Standard C Library Functions memory(3C)

### NAME

`memory`, `memcpy`, `memchr`, `memcmp`, `memcpy`, `memmove`, `memset` -  
memory operations

### SYNOPSIS

```
#include <string.h>
...
...
```

- jednotlivá makra obsažená v těchto souborech většinou nejsou vysvětlena, význam jednotlivých maker je ale možné si vyhledat v příslušných specifikacích, které jsou on-line. Na některých systémech (Solaris) mají jednotlivé hlavičkové soubory svoji vlastní manuálovou stránku (`man stdlib.h`).
- makro `assert()` je možné z během kompilace odstranit pomocí makra `NDEBUG`

## Standardní hlavičkové soubory (2)

|                          |     |                                   |
|--------------------------|-----|-----------------------------------|
| <code>unistd.h</code>    | ... | nejpoužívanější systémová volání  |
| <code>sys/types.h</code> | ... | datové typy používané v API UNIXu |
| <code>fcntl.h</code>     | ... | řídící operace pro soubory        |
| <code>sys/stat.h</code>  | ... | informace o souborech             |
| <code>dirent.h</code>    | ... | procházení adresářů               |
| <code>sys/wait.h</code>  | ... | čekání na synovské procesy        |
| <code>sys/mman.h</code>  | ... | mapování paměti                   |
| <code>curses.h</code>    | ... | ovládání terminálu                |
| <code>regex.h</code>     | ... | práce s regulárními výrazy        |

- tyto headery už patří do UNIXu.
- zajímavé může být podívat se do `sys/types.h`

## Standardní hlavičkové soubory (3)


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

- dokončení nejdůležitějších UNIXových headerů. Existují samozřejmě ještě další.



## 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]` cesta k programu
    - \* poslední prvek je `argv[argc] == NULL`
  - návrat z `main()` nebo volání `exit()` ukončí program
  - standardní návratové hodnoty `EXIT_SUCCESS (0)` a `EXIT_FAILURE (1)`



- první parametr (typu `int`) udává počet argumentů na příkazovém řádku (včetně parametru 0 – jména programu) a druhý parametr (typu `char**`) je pole ukazatelů na tyto řetězce. Za posledním řetězcem je ještě `NULL` pointer – a to je něco jiného než prázdný řetězec.
- při spuštění programu předá kód dynamického linkeru řízení funkci `main()`, viz strana 31. Staticky slinkovanému programu se řízení předá přímo. Nepřítomnost `main()` v programu způsobí chybu při překladu na úrovni linkeru. Této funkci se předá jméno spuštěného programu, argumenty z příkazové řádky a případně i proměnné prostředí. Ukončení této funkce znamená konec programu a návratová hodnota se použije jako kód ukončení programu pro OS. Jinou možností ukončení programu je použití funkce `exit()` nebo `_exit()`, kterou lze použít kdykoliv, nejen ve funkci `main()`. V C lze používat obě metody ukončení programu.
- předání proměnných prostředí třetím parametrem typu `char**` není součástí normativní části C standardu, pouze informativní. Překladače to ale typicky podporují. Varianta `main()` s proměnnými prostředí pak vypadá takto:  
`int main(int argc, char *argv [], char *envp []);`
- návratový typ funkce `main` by měl být vždy `int`; překladač si jinak bude stěžovat. Z této hodnoty se ale použije pouze nejnižších 8 bitů. Pozor na to, že na rozdíl od jazyka C návratová hodnota 0 má v shellu význam `true` (úspěch) a nenula význam `false` (neúspěch).
- rozdíl mezi funkcemi `exit()` a `_exit()` je v tom, že `exit()` před ukončením programu ještě zavře streamy `stdio` a volá funkce zaregistrované pomocí `atexit()`. V závislosti na systému to mohou být i další akce. Například ve FreeBSD je `_exit()` systémové volání a `exit()` knihovní funkce. V Solarisu jsou obě systémovými voláními.

## 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*



- shell předává spuštěnému programu ty proměnné, které jsou označeny jako exportované (Bourne-like shellech příkazem `export variable`). Po změně obsahu již jednou exportované proměnné samozřejmě není potřeba proměnnou znovu exportovat. Příkazem `env` vám shell vypíše aktuální proměnné prostředí, a přidat proměnnou do prostředí spouštěného programu pak stačí provést na příkazové řádce, aniž byste museli měnit prostředí vašeho shellu:

```
$ date
Sun Oct 7 13:13:58 PDT 2007
$ LC_TIME=fr date
dimanche 7 octobre 2007 13 h 14 PDT
```

- při nahrazení aktuálního obrazu procesu obrazem jiným se předává, pokud se neřekne jinak, synovským procesům celé pole `environ` automaticky. Je možné ve volání příslušné varianty funkce `exec` předat pole jiné.
- jaké proměnné prostředí konkrétní příkaz používá (a jak je používá) by mělo být v manuálové stránce. Typicky v sekci nazvané *ENVIRONMENT* nebo *ENVIRONMENT VARIABLES*
- `man` například používá `PAGER`, `vipw` pak proměnnou `EDITOR` apod.
- pokud je `envp` třetím parametrem funkce `main`, tak je to stejná hodnota co je v ukazatelu `environ`.

## Manipulace s proměnnými prostředí

- je možné přímo změnit proměnnou `environ`
- `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()`

- u `putenv()` se vložený řetězec stane součástí prostředí (jeho pozdější změna tak změní prostředí) a nesmíte proto používat řetězce v automatických proměnných, toto řeší `setenv()`, který hodnotu proměnné zkopíruje
- důležité je zapamatovat si, že synovský proces zdědí v okamžiku svého vzniku od rodiče všechny proměnné prostředí, ale jakákoliv manipulace s nimi v synovi je lokální a do otce se nepřenáší. Každý proces má svou kopii proměnných, proto ani následná změna prostředí otce nezmění proměnné již existujícího potomka.
- další rozdíl mezi `putenv` a `setenv` je ten, že v `setenv` mohou definovat, zda existující proměnnou chci nebo nechci přepsat. `putenv` vždy přepisuje.
- ```
int
main(void)
{
    printf("%s\n", getenv("USER"));
    return 0;
}
$ ./a.out
jP
```
- jelikož víte, že proměnná `environ` je obyčejné pole ukazatelů na řetězce, můžete s tímto polem pracovat přímo. Pozor však na to, že v takovém případě pak již nesmíte používat zde uvedené funkce, jinak se můžete dostat do problémů s jejich konkrétní implementací.

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()`.

- argumenty lze samozřejmě zpracovávat vlastní funkcí, ale standardní funkce je pohodlnější.
- argumenty se typicky mohou opakovat, ale to má smysl jen v některých situacích
- pořadí přepínačů může být důležité a je na aplikaci, aby toto specifikovala
- UNIX norma definuje pomocí 13 pravidel velmi přesně, jak by měly vypadat názvy příkazů a formát přepínačů. Například jméno příkazu by mělo být pouze malými písmeny, dlouhé 2–9 znaků, z přenositelné znakové sady. Přepínače bez argumentů by mělo být možné dát do skupiny za jedním znakem `'-`. Atd.
- používat číslice jako přepínače je zastaralé; je to někde v normě UNIX 03, i když já to v ní nenašel.
- pozor na Linux a jeho (poněkud zvláštní a nestandardní) permutování argumentů (viz další slidy).
- přepínač `-W` by měl být rezervovaný pro vendor options, tj. pro nepřenositelná rozšíření

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.

- obvykle se nejprve pomocí `getopt()` načtou přepínače a pak se vlastními prostředky zpracují ostatní argumenty (často jsou to jména souborů).
- je konvencí, že volby v parametru `optstring` jsou seříděné.

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];
```

- dobrým zvykem je při detekování neznámého přepínače (nebo špatného zápisu parametrů programu) vypsát stručnou nápovědu (případně s odkazem na podrobnější dokumentaci) a ukončit program s chybou, tj. s nenulovou návratovou hodnotou.
- příklad také ukazuje nebezpečné použití funkce **strcpy()**
- z použití funkce **getopt()** je vidět, že je stavová. Zpracovat další pole argumentů, případně znovuzpracovat původní, je možné nastavením externí proměnné **optreset** na 1.
- standardní **getopt()** zachová pořadí přepínačů při zpracování
- při použití nedefinovaného přepínače funkce vypíše chybu; to lze potlačit nastavením **opterr** na 0.

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 */
};
```

verze jak se objevila ve FreeBSD (funkce `getopt_long()` není standardizovaná), má následující vlastnosti:

- pokud všechny dlouhé přepínače mají nastaveny krátkou variantu ve `val`, je chování `getopt_long()` kompatibilní s `getopt()`
- je možné zadávat argument k dlouhému přepínači i s mezerou (například `--color green`)
- pokud je nastaven `flag`, tak `getopt_long()` vrací 0, čímž se tyto dlouhé přepínače bez krátké varianty zpracují v jedné větvi příkazu `case`
- existuje i volání `getopt_long_only()`, které povoluje i dlouhé přepínače uvozené jednou uvozovkou (`-option`)
- funkci `getopt_long()` je možné používat dvěma způsoby. První způsob je, že každý dlouhý přepínač má korespondující krátký – takto lze jednoduše přidat dlouhé přepínače do existujícího programu a je **kompatibilní s `getopt`**. Druhý způsob umožňuje mít samostatné dlouhé přepínače. V tom případě funkce vrací vždy 0 (nekompatibilita s `getopt`) a proměnná `*flag` se nastaví na `val`.
- na konkrétním příkladu na následující stránce je vidět, jak to celé funguje

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 `-1` nalezeného přepínače v `longopts`.

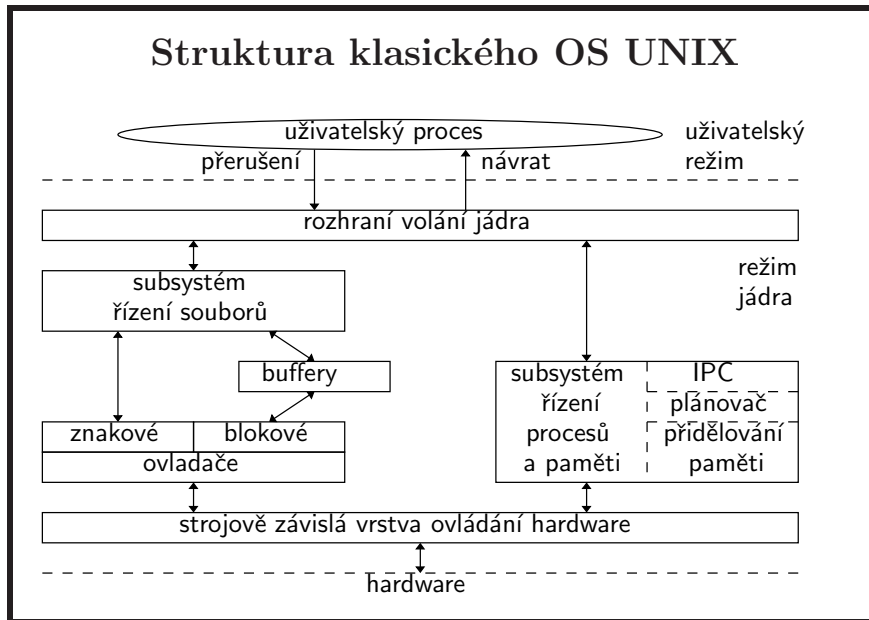
- toto je upravený příklad z manuálové stránky na FreeBSD:

```
#include <stdio.h>
#include <getopt.h>
#include <fcntl.h>

int ch, fd, daggerset, bflag = 0;

static struct option longopts[] = {
    { "buffy",      no_argument,      NULL,          'b' },
    { "fluoride",   required_argument, NULL,          'f' },
    { "daggerset",  no_argument,      &daggerset,    1 },
    { NULL,         0,                NULL,          0 };
};

int main(int argc, char **argv)
{
    while ((ch = getopt_long(argc, argv, "bf:", longopts, NULL)) != -1)
        switch (ch) {
            case 'b':
                bflag = 1; break;
            case 'f':
                if ((fd = open(optarg, O_RDONLY, 0)) == -1)
                    printf("unable to open %s", optarg);
                break;
            case 0:
                if (daggerset) {
                    printf("Buffy will use her dagger to "
                           "apply fluoride to dracula's teeth\n");
                }
                break;
            default: printf("usage: ... \n");
        }
    argc -= optind; argv += optind;
    return 0;
}
```

- toto schéma je převzato z [Bach86], viz literatura. Zdůrazňuje dva ústřední pojmy v modelu systému UNIX – soubory a procesy. V praxi se jádro od modelu typicky odlišuje, ale zde je důležitá základní představa.
- UNIX rozlišuje dva režimy běhu procesoru: *uživatelský režim* a *režim jádra*. V uživatelském režimu nejsou přístupné privilegované instrukce (např. mapování paměti, I/O, maskování přerušení). Tyto dva režimy musí být podporovány na hardwarové úrovni (procesorem).
- procesy běží obvykle v uživatelském režimu, do režimu jádra přechází buď instrukcí synchronního přerušení (trap) pro volání služby jádra, nebo na základě asynchronních přerušení (hodiny, I/O). Dále se v režimu jádra ošetřují výjimečné stavy procesoru (výpadek stránky, narušení ochrany paměti, neznámá instrukce apod.). Některé speciální akce jsou zajišťovány systémovými procesy, které běží celou dobu v režimu jádra.
- klasické UNIXové jádro je tvořeno monolitickým kódem. Původně bylo potřeba vygenerovat (tj. přeložit ze zdrojových textů a slinkovat) jádro při změně některého parametru nebo přidání ovladače zařízení. V novějších implementacích je možno nastavovat parametry jádra, někdy i za běhu, pomocí systémových utilit bez nutnosti rekompilace jádra. Moderní UNIXy umožňují rozšiřovat kód jádra za běhu pomocí tzv. modulů jádra (*loadable kernel modules*). Například systém FreeBSD 5.4-RELEASE má 392 takových modulů.
- existují dva způsoby práce s perifériemi: bloková (*block devices*) a znaková zařízení (*character, raw devices*). Data z blokových zařízení (např. disky) procházejí přes vyrovnávací paměti (*buffers*) po blocích, znaková zařízení (např. terminály) umožňují pracovat s jednotlivými bajty a nepoužívají vyrovnávací paměť.

- **jádro není samostatný proces**, ale je částí každého uživatelského procesu. Když jádro něco vykonává, tak vlastně proces, běžící v režimu jádra, něco provádí.

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.

- *kontext* je paměťový prostor procesu, obsah registrů a datové struktury jádra týkající se daného procesu
- jinak řečeno – *kontext* procesu je jeho stav. Když systém vykonává proces, říká se, že běží v kontextu procesu. Jádro (klasické) obsluhuje přerušení v kontextu přerušeného procesu.
- vlákna se dostala do UNIXu až později, původně v něm existovaly pouze procesy (s jediným hlavním vláknem). Možnost použít v procesu více vláken byla zavedena, protože se ukázalo, že je vhodné mít více paralelních linií výpočtu nad sdílenými daty.
- paměťové prostory procesů jsou navzájem izolované, ale procesy spolu mohou komunikovat (později se dozvíme, že mohou i částečně sdílet paměť).
- procesy jsou entity na úrovni jádra, vlákna mohou být částečně nebo zcela implementována knihovními funkcemi (tj. vlákna nemusí jádro vůbec podporovat). S vlákny je spojena menší režie než s procesy.
- systémový proces, který běží na pozadí obvykle po celou dobu běhu systému a zajišťuje některé systémové služby (**inetd**, **cron**, **sendmail**...) se nazývá *démon* (angl. *daemon*). Systém BSD tedy nemá ve znaku čerta, ale démona.

Jádro, režimy, přerušení (klasický UNIX)

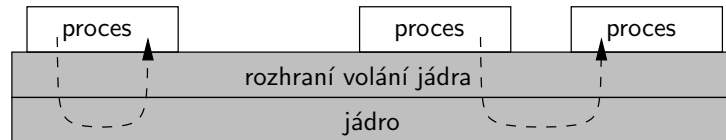
- procesy typicky běží v uživatelském režimu
- systémové volání způsobí přepnutí do režimu jádra
- proces má pro každý režim samostatný zásobník
- jádro je částí každého uživatelského procesu, není to samostatný proces (procesy)
- přepnutí na jiný proces se nazývá *přepnutí kontextu*
- obsluha přerušení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

- **jádro není oddělená množina procesů, běžících paralelně s uživatelskými procesy, ale je částí každého uživatelského procesu.**
- přechod mezi uživatelským režimem a režimem jádra není přepnutí kontextu – proces běží pořád v tom samém
- přerušenoý proces nemusel přerušení vůbec způsobit
- v režimu jádra může proces přistupovat i k adresám jádra, která z uživatelského režimu přístupná nejsou; taktéž může přistupovat k instrukcím (např. instrukce manipulující se stavovým registrem), jejichž vykonání v uživatelském režimu vede k chybě
- přerušovací rutina se nemůže zablokovat, protože tím by zablokovala proces; proces se totiž může zablokovat jen ze své vlastní vůle. Moderní Unixy dnes používají interrupt vlákna, v jejichž kontextu se **mohou** drivery zablokovat.
- to, že klasické unixové jádro je nepreemptivní znamená, že **jeden proces nemůže zablokovat jiný proces**
- při obsluze přerušení se může stát, že nastane další přerušení. Pokud je jeho priorita větší, je procesorem přijmuto. Posloupnost přijmutých přerušení je uchována v *zásobníku kontextových vrstev*.


-
- u moderních kernelů je situace často velmi rozdílná – obsluha přerušení, preceptivnost kernelu atd.; k některým věcem se možná dostaneme později během semestru

Volání služeb a komunikace mezi procesy

- UNIX



- distribuovaný OS



- pokud unixový proces vyžaduje provedení systémové služby, pomocí systémového volání předá řízení jádru. Jádro je kus kódu sdílený všemi procesy (ovšem přístupný jen pro ty, které jsou právě v režimu jádra). Jádro tedy není samostatný privilegovaný proces, ale vždy běží v rámci některého procesu (toho, který požádal jádro o službu, nebo toho, který běžel v okamžiku příchodu přerušení).
- komunikace mezi procesy v UNIXu je řešena pomocí systémových volání, je tedy zprostředkováná jádrem.
- aby to nebylo tak jednoduché, mohou existovat systémové procesy (označované jako *kernel threads*), které běží celou dobu v režimu jádra. Naprostá většina systémových procesů však běží v uživatelském režimu a liší se jen tím, že mají větší přístupová práva. Plánovač procesů přepíná mezi procesy a tím umožňuje běh více procesů současně i na jednom procesoru. Na multiprocessorových počítačích pak funguje skutečný paralelismus procesů a vláken (dokonce se proces může při přeplánování dostat i na jiný procesor).
- v distribuovaném operačním systému má jádro obvykle formu mikrojádra, tj. zajišťuje pouze nejzákladnější služby řízení procesoru, přidělování paměti a komunikace mezi procesy. Vyšší systémové služby, které jsou v UNIXu součástí jádra (např. přístup k systému souborů) jsou realizovány speciálními procesy (servery) běžícími v uživatelském režimu procesoru. Jádro předá požadavek uživatelského procesu příslušnému serveru, který může běžet i na jiném uzlu sítě.
- dostupných mikrokernelů je v dnešní době mnoho. Můžete zkusit například Minix (unix-like výukový systém), případně systém HURD, který běží nad mikrojádrem Mach.

Systemová volání, funkce

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

- zjednodušeně lze říci, že systemové volání je funkce, která jen upraví své argumenty do vhodné podoby, přepne režim procesoru a skutečnou práci nechá na jádru. Nakonec zase upraví výsledek. Knihovní funkce může a nemusí volat jádro, ale vždy sama dělá nějakou netriviální činnost v uživatelském režimu.
- v assembleru je možné zavolat volání jádra přímo
- API jádra je definované na úrovni volání funkcí standardní knihovny, nikoliv na úrovni přerušování a datových struktur používaných těmito funkcemi pro předání řízení jádru. Mechanismus přepnutí mezi uživatelským režimem a režimem jádra se totiž může lišit nejen v závislosti na hardwarové platformě, ale i mezi různými verzemi systému na stejném hardwaru.

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)`;

- funkce pro práci s vlákny `pthread_*()` nenastavují `errno`, ale vrací buď nulu (úspěch) nebo přímo kód chyby.
- pro některá volání může mít smysl i návratová hodnota `-1`. Pak je třeba nejprve nastavit `errno = 0` a po návratu zkontrolovat, zda se `errno` změnilo. Např. funkce `strtol()` vrací při chybě `0`, což je platná hodnota i pro správný výsledek (a `-1` je samozřejmě platný výsledek také).
- je tedy vždy nutné si přečíst manuálovou stránku pro příslušné volání nebo knihovní funkci
- pozn.: úspěšnost funkcí ze `stdio.h` je třeba testovat pomocí `int ferror(FILE *stream)`; , protože jinak nelze rozlišit mezi chybou a koncem streamu. Vzhledem k tomu, že tyto funkce nepoužíváme (kromě `printf/fprintf` na `stdout/stderr`), neměli byste ji potřebovat.

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

Uživatelé a skupiny

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

význam jednotlivých polí: uživatelské jméno, zakódované heslo (nově v `/etc/shadow`), číslo uživatele (UID); superuživatel (root) má UID 0, číslo primární skupiny (GID), plné jméno, domovský adresář, login-shell

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

význam jednotlivých polí: jméno skupiny, heslo pro přepnutí do skupiny, číslo skupiny (GID), seznam členů skupiny

- informace o uživateli v souborech `/etc/passwd`, a `/etc/group` jsou zpracovávány různými systémovými programy, např. `login` (přihlášení do systému na základě uživatelského jména a hesla) nebo `su` (změna identity). **Jádro o těchto souborech nic neví, používá pouze numerickou identifikaci uživatele a skupiny.**
- dnes již hesla nejsou z bezpečnostních důvodů přímo v `/etc/passwd`, ale například v `/etc/shadow`, který běžnému uživateli přístupný není. A např. na FreeBSD se soubor `/etc/passwd` generuje ze souboru `/etc/master.passwd`, který zakóduje hesla.
- existují i jiné systémy, které (nejen) pro autentizaci `/etc/passwd` nemusí vůbec používat, například NIS (Network Information Service).
- skupina uživatele uvedená v `/etc/passwd` je primární. Tuto skupinovou identifikaci dostanou např. soubory vytvořené procesy uživatele. Další skupiny, ve kterých je uživatel uveden v souboru `/etc/group`, jsou doplňkové (*supplementary*) a rozšiřují přístupová práva uživatele: skupinový přístup je povolen ke všem objektům, jejichž skupinový vlastník je roven buď primární, nebo jedné z doplňkových skupin.
- původně měl v UNIXu každý uživatel vždy aktivní pouze jednu skupinovou identitu. Po nalogování byl ve své primární skupině, pro získání práv jiné skupiny bylo třeba se do ní přepnout příkazem `newgrp` (skupinová obdoba `su`, řídí se obsahem souboru `/etc/group`), který spustil nový shell.
- v novějších UNIXech není třeba pro přístup k souborům měnit primární skupinovou identitu procesu, pokud uživatel patří do potřebné skupiny. Změna identity je nutná, pouze když chceme vytvářet soubory s jinou skupinovou identitou než je primární skupina uživatele. Lokálně pro určitý adresář toho lze dosáhnout nastavením skupinového vlastníka adresáře na požadovanou skupinu a nastavením bitu SGID v přístupových právech adresáře – to platí pro systémy založené na System V. U BSD stačí změnit požadovanou skupinu u adresáře.
- druhá položka v řádcích `/etc/group` obsahuje zakóduvané skupinové heslo používané příkazem `newgrp`, to se již dnes nepoužívá. Například na FreeBSD je příkaz `newgrp` přístupný už jen superuživateli (kvůli volání `setgroups`).

Name service switch

- dnešní systémy nejsou omezeny na používání `/etc/passwd` a `/etc/groups`
- systém používá *databáze* (`passwd`, `groups`, `protocols`, ...)
- data databází pocházejí ze *zdrojů* (soubory, DNS, NIS, LDAP, ...)
- soubor `nsswitch.conf` definuje jaké databáze používají jaké zdroje
- knihovni funkce toto samozřejmě musí explicitně podporovat
- je možné některé zdroje kombinovat, například uživatel se nejdříve může hledat v `/etc/passwd` a poté v NISu
- poprvé se objevilo v Solarisu, poté převzato dalšími systémy

- systémy mají typicky manuálovou stránku `nsswitch.conf(5)`, kde lze nalézt podrobnosti v závislosti na konkrétním operačním systému
- zde je část skutečného souboru `nsswitch.conf` ze stroje `u-us`:

```
passwd:    files ldap
group:     files ldap
```

```
# You must also set up the /etc/resolv.conf file for DNS name
# server lookup. See resolv.conf(4).
```

```
hosts:     files dns
```

```
# Note that IPv4 addresses are searched for in all of the
# ipnodes databases before searching the hosts databases.
```

```
ipnodes:   files dns
```

```
networks:  files
protocols: files
rpc:       files
ethers:    files
```

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 Proces má vůči Souboru
<code>if(UID_P == 0)</code>	... všechna práva
<code>else if(UID_P == UID_S)</code>	... práva vlastníka
<code>else if(GID_P == GID_S GID_S ∈ SUPG)</code>	... práva člena skupiny
<code>else</code>	... práva ostatních

- procesy superuživatele `root` mohou měnit svoji uživatelskou a skupinovou identitu. Toho využívá např. proces `login`, který běží jako `root` a po zkontrolování jména a hesla spustí shell s uživatelskou identitou (pomocí volání `setuid()` – viz další slajdy).
- z algoritmu plyne, že pro `roota` není relevantní nastavení práv (má vždy neomezený přístup). Pokud se shoduje uživatel, nepoužijí se nikdy práva skupiny nebo ostatních, i když povolují více než uživatelská práva. Podobně práva ostatních se nepoužijí, jestliže se shoduje skupinová identita. Tedy pokud má můj soubor nastaveny práva `---rwxrwx`, nemohu ho číst, zapisovat ani spustit (dokud nastavení práv nezměním).
- některé systémy se odklánějí od klasického modelu, kdy mnoho procesů běželo pod uživatelem s UID 0 a při bezpečnostní chybě v takové aplikaci často útočník získal vládu nad celým systémem a zavádějí modely jako je *least privilege model* v Solarisu 10, *sysrtrace* v OpenBSD, ...

Reálné a efektivní UID/GID

- u každého procesu se rozlišuje:
 - **reálné UID** (RUID) – kdo je skutečným vlastníkem 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 změni EUID 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.

- bity SUID a SGID se používají u programů, které potřebují větší přístupová práva, než má uživatel, jenž je spouští. Příkladem je program `passwd`, který musí aktualizovat soubory `/etc/passwd` a `/etc/shadow`, kde ten první nemůže běžný uživatel měnit a druhý z nich ani číst. Další příklad je program `su`. Ten musí mít právo libovolně změnit uživatelskou a skupinovou identitu, což je privilegium procesů s UID 0.
- SUID a SGID programy by měly být pečlivě naprogramovány, aby dovolily pouze ty operace, pro které jsou určeny, a neumožnily zneužít jejich privilegia pro neoprávněné akce (např. spuštění rootovského shellu). Zkušenost ukazuje, že tyto programy jsou jednou z nejčastějších příčin bezpečnostních problémů UNIXových systémů.
- základním pravidlem pro SUID programy je: **nepište je** pokud to není opravdu nezbytné. Je to typické místo pro generování bezpečnostních chyb protože dobře (= bezpečně) napsat složitější SUID program není jednoduché.
- toto jsou pravidla pro změny:
 - běžný uživatel nemůže změnit své RUID nebo uschované SUID (vyjímka je při volání `exec()`, viz strana 113)
 - proces může vždy změnit své EUID na to z RUID nebo z uschovaného UID. Toto zaručuje, že v SUID programu je možné libovolně měnit EUID mezi tím původním kterým proces získal práva vlastníka a mezi UID skutečného uživatele který daný proces spustil)
 - root může všechno, a když změní RUID, tak se zároveň změní i uchované UID – nemělo by smysl měnit jen jedno z nich když kterékoli můžete použít pro nastavení EUID.

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.

- `getgroups()`: když `gidsz == 0`, jen vrátí počet skupin. Když $0 < gidsz < \#skupin$, vrátí `-1`.
- v UNIXu je mnoho typů jako `uid_t`, `gid_t`, `size_t`, apod. Vesměs jsou to celočíselné typy, často je najdete v `/usr//sys/types.h`

Změna vlastníka procesu

- `int setuid(uid_t uid);`
 - v procesu s `EUID == 0` nastaví RUID, EUID i saved-SUID na `uid` (viz také poznámky na straně 59).
 - 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.

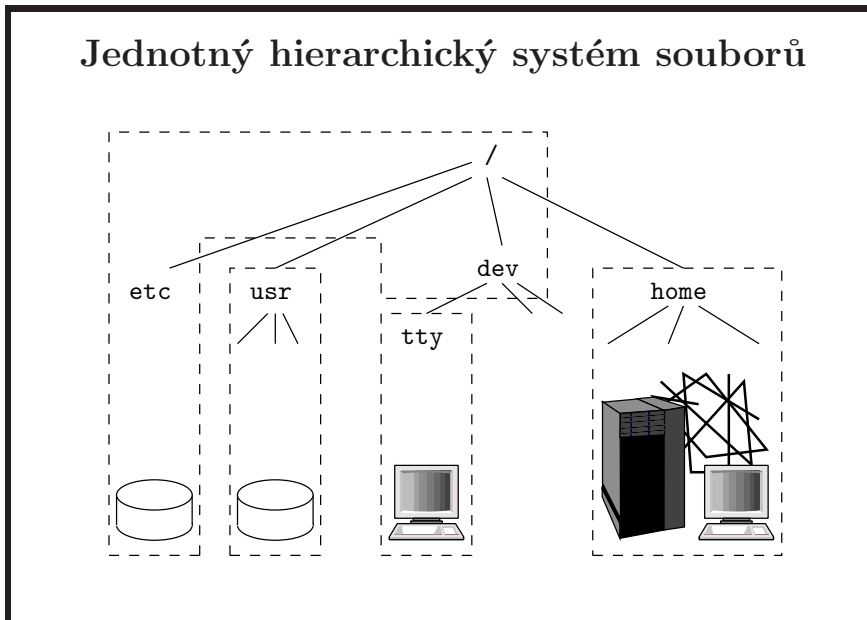
- co výše uvedené tedy znamená: proces s efektivními právy superuživatele může libovolně měnit identitu. Ostatní procesory mohou pouze střídat svá reálná a efektivní práva.
- program *login* využívá volání `setuid()`
- pokud chce process s `UID == 0` změnit svou identitu, musí nejprve volat `setgid()` a `setgroups()`. Teprve pak lze zavolat `setuid()`. Při opačném pořadí volání by proces po provedení `setuid` už neměl práva na `setgid()` a `setgroups()`.
- `setgroups()` není uvedeno v UNIX 98 ani UNIX 03.
- RUID/EUID jsou uloženy v záznamu tabulky procesů pro příslušný proces a zároveň v tzv. *u-area* (viz například [Bach]). EUID v tabulce procesů se nazývá již zmíněné uschované UID, neboli *saved UID*. Jak již bylo řečeno, uschované UID se používá pro kontrolu, když se proces chce vrátit k EUID, se kterým byl spuštěn (po té, co dočasně nastavil své EUID na UID uživatele, který proces spustil, tj. na RUID).
- pokud tedy jako root vytvoříte SUID program a v něm zavoláte `setuid()` pro jakéholi UID mimo 0, již se v programu k `EUID==0` nemůžete vrátit. V tom případě byste museli použít volání `seteuid()`, které nastavuje pouze EUID.

System 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.

- root může v některých systémech strukturu adresářů zacyklit, ale tím zmate utility pro procházení filesystému; moc se cyklické struktury nepoužívají. Symbolické linky na adresáře fungují všude.
- pojmenované roury (viz strana 81) lze použít i mezi procesy, které nejsou příbuzensky spřízněné. Jinak fungují stejně jako nepojmenované roury.
- zmiňované sokety jsou v doméně UNIX, tj. slouží pro komunikaci v rámci jednoho systému. Sokety z domény INET, přes které probíhá síťová komunikace, se v systému souborů neobjevují. Síťová komunikace začíná na straně 155.
- debugery používají paměťové obrazy procesů dostupné v /proc. Ve většině unix-like systémů obsahuje podstrom /proc údaje o jádru systému a běžících procesech ve formě textových souborů.
- dnešní moderní unixy mívají speciální filesystém *devfs*, jehož obsah odráží aktuální konfiguraci systému co se týče připojených zařízení. Tj. např. při připojení USB sticku se v /dev objeví příslušné diskové zařízení. Po fyzickém odpojení zařízení odkaz z adresářové struktury opět zmizí.

Jednotný hierarchický systém souborů



- svazek (angl. *file system*) je část souborového systému, kterou lze samostatně vytvořit, připojit, zrušit... Každý filesystem může mít jinou vnitřní strukturu (`s5`, `ufs`, `ext2`, `xfs`, atd.) a může být uložen na lokálním disku nebo na jiném počítači a přístupný po síti (`nfs`, `afs`).
- po startu jádra je připojený jen kořenový filesystem, další filesystemy se zapojují do hierarchie na místa adresářů příkazem `mount`. Tento příkaz je možné spustit ručně (uživatel `root` libovolně, ostatní pouze na některých systémech a s omezeními) nebo automaticky během inicializace systému (řídí se obsahem souboru `/etc/fstab`). Před zastavením systému se filesystemy odpojují příkazem `umount`.
- další možnost je připojení filesystemu na žádost (při prvním přístupu) a jeho odpojení po určité době nečinnosti. Tuto funkci zajišťuje démon *automounter* (`autofs`, `automount`, `amd`).
- UNIX nemá žádné A, B, C, D... disky apod.

Typická skladba adresářů

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


- v `/bin`, `/lib`, `/sbin` jsou příkazy a knihovny potřebné při startu systému, kdy je připojen pouze kořenový filesystem. Ostatní příkazy a knihovny jsou typicky v `/usr/bin`, `/usr/lib` a `/usr/sbin` (`/usr` bývá často samostatný filesystem, čímž jeho obsah není dostupný během startu systému).
- podstrom `/usr` obsahuje soubory, které se nemění při běžném provozu a nejsou závislé na konkrétním počítači. Proto by měl být sdílet read-only. Na své stanici doma ho ale samozřejmě budete mít read-write.
- v podstromu `/var` jsou data, která se za provozu mění a jsou specifická pro každý počítač.
- různé systémy (i instalace jednoho systému) se často liší.
- `hier(7)` na FreeBSD popisuje adresářovou hierarchii tohoto systému, Solaris má `filesystem(5)`.

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
-
- vyrovnávací paměti urychlují periferní operace. Při čtení se data hledají nejprve v bufferu. Teprve když nejsou k dispozici, tak se čtou z disku. Při příštím čtení stejného bloku jsou data v bufferu. Při zápisu se data uloží do bufferu. Na disk je systém přepíše později. Lze si vynutit i okamžitý zápis dat na disk.
 - disky v UNIXu jsou obvykle přístupné přes znakové (používané při `mkfs` – vytvoření svazku – a `fsck` – kontrola konzistence) i blokové rozhraní (používané při normálním provozu systému souborů). Některé systémy (FreeBSD) ale už v `/dev` vůbec soubory pro bloková zařízení nemají, pouze znaková.
 - dříve musel administrátor systému po změně hardwarové konfigurace upravit obsah adresáře `/dev` skriptem `MAKEDEV` nebo ručně. Dnes (Linux, IRIX, FreeBSD, Solaris, ...) již speciální soubory dynamicky vznikají a zanikají podle toho, jak jádro detekuje přidání nebo odebrání hardwarových komponent (viz *devfs* na straně 62).
 - okamžitý zápis na disk lze vynutit přes `O_DIRECT` command ve volání `fcntl()`

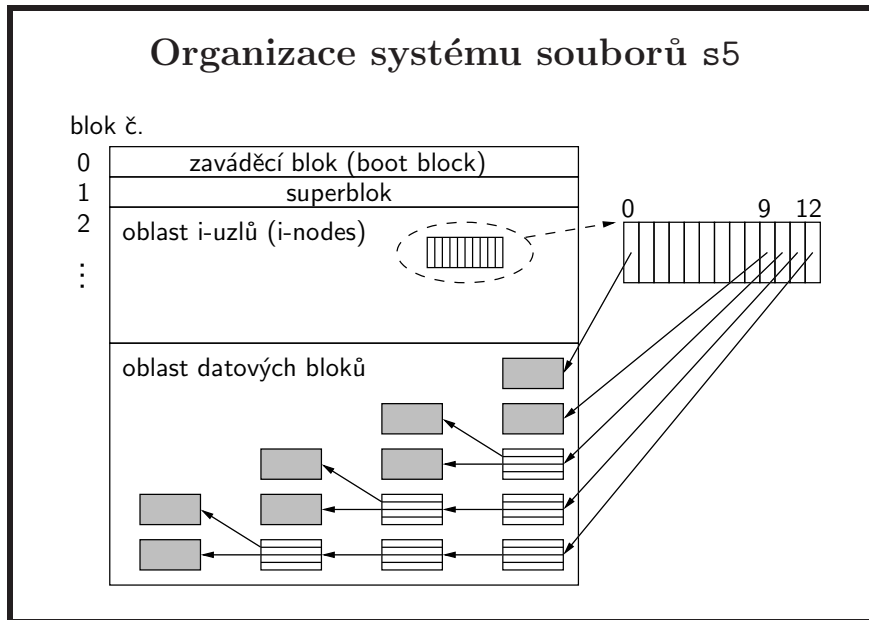
Fyzické uložení systému souborů

- **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



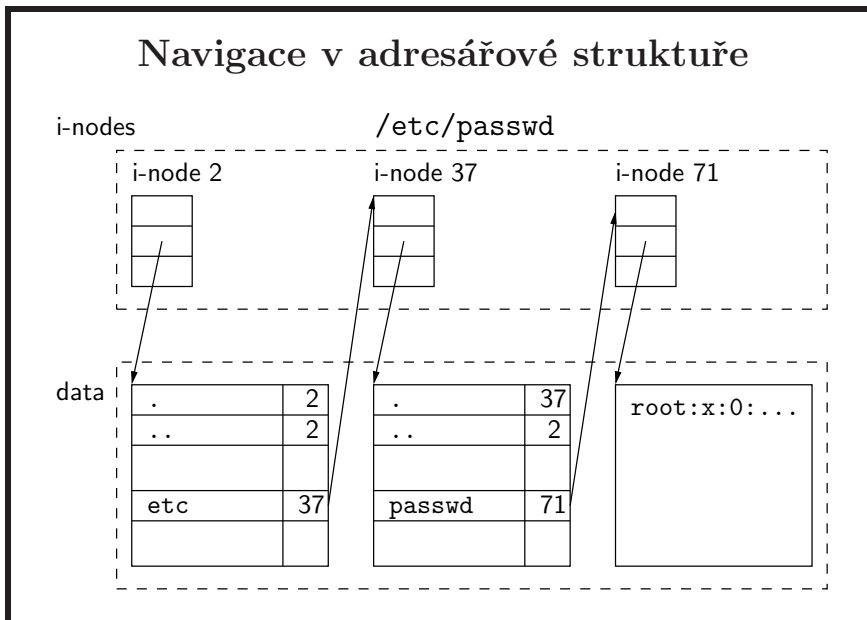
- výraz systém souborů se používá v několika významech:
 - jeden filesystem, tj. to, co vyrobí příkaz `mkfs`
 - celá hierarchie připojených svazků v systému (výstup příkazu `mount`)
 - způsob organizace svazku (tj. typ fs) a tomu odpovídající modul jádra, který s daty manipuluje (UFS2, Ext3, XFS, ...)
- striping je od slova stripe, ne strip; podle toho se také vyslovuje. Znamená, že za sebou následující bloky dat se ukládají paralelně na různé disky a tím se zvyšuje přenosová rychlost.
- mirroring ukládá kopie dat pro případ havárie primárního disku.
- paritní disky: data se ukládají na dva disky, na třetí se ukládá XOR prvních dvou, po havárii libovolného disku jsou všechna data stále čitelná.
- jednotlivé úrovně RAID (Redundant Array of Inexpensive Disks) zahrnují striping, mirroring a využití paritních disků.
- na terminologii je třeba dát velký pozor. Např. to, co se v DOS světě nazývá *partition*, se v BSD nazývá *slice*. Tam jsou pak partitions definovány v rámci jednoho slice a v nich se vytvářejí filesystemy.
- pokud vás to zajímá nebo se s tím setkáváte v praxi, doporučuji vaší pozornosti ZFS, což je filesystem a manažer logických oddílů v jednom. Ze Solarisu se již dostal do FreeBSD od verze 7.0 a také do Mac OS X Leopard (který byl oficiálně vydán v říjnu 2007). Můžete okamžitě zapomenout na jednotlivé disky, co je důležité je pouze celková disková kapacita v systému.

Organizace systému souborů s5

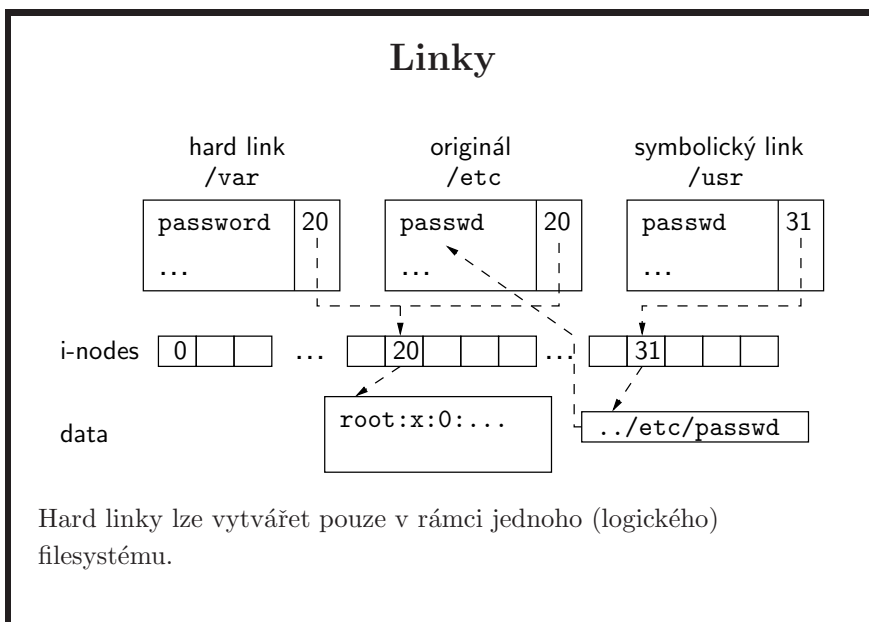


- původní UNIXový systém souborů standardně používaný do verze System V Release 3; v BSD se primárně používal do verze 4.1
- vlastnosti:
 - bloky délky 512, 1024 nebo 2048 bajtů
 - jediný (neduplikovaný) superblok
 - datový prostor pevně rozdělený na oblast *i-uzlů* a oblast *datových bloků*
 - při velikosti bloku 1024 bajtů byla teoretická velikost filesystému přes 16 GB
- *boot block* – pro uložení zavaděče OSu
- *superblok* – základní informace o svazku: počet bloků pro i-uzly, počet bloků svazku, seznam volných bloků (pokračuje ve volných blocích), seznam volných i-uzlů (po vyčerpání se prohledává tabulka i-uzlů), zámky pro seznamy volných bloků a i-uzlů, příznak modifikace (pro kontrolu korektního odpojení svazku), čas poslední aktualizace, informace o zařízení
- *i-uzel* – typ souboru, přístupová práva, vlastník, skupina, časy posledního přístupu, modifikace dat a modifikace i-uzlu (čas vytvoření souboru není uložen), počet odkazů na soubor, velikost souboru, 10 odkazů na datové bloky a 3 odkazy na nepřímé bloky
- maximální velikost souboru: 2113674 bloků, tj. přibližně 1 GB při použití bloků velikosti 512 B
- jména souborů – max. 14 znaků ($14 + 2 = 16$, tedy mocnina dvou a tedy bezproblémové uložení adresářových položek do bloků)

- při použití tohoto filesystému byla výkonnost disků využita jen cca na 2% a rychlost čtení byla v řádu jen několika desítek kilobajtů za sekundu (!!!)
- pro srovnání – MS-DOS 2.0 z roku 1983 podporoval pouze FAT12, počítající s maximální velikostí filesystému 16 MB. Velikost svazku do 2 GB byla umožněna až ve verzi 4.0 (1988); tato verze zároveň zavedla diskové vyrovnávací paměti, tedy to, co UNIX má od svého vzniku v roce 1970...



- když cesta začíná znakem `'/'`, začíná navigace v kořenovém adresáři, jinak začne v pracovním adresáři procesu.
- kořenový adresář má typicky číslo 2. 0 je pro označení prázdného uzlu a 1 byla dříve používána pro soubor, do kterého se vkládaly vadné bloky, aby je systém už dále nepoužíval.
- cesta ve které je více lomítek za sebou je stále platná, tj. `///a///b///c` je ekvivalentní `/a/b/c`.



hardlink

- odkaz na stejný i-uzel
- vlastně druhé jméno souboru
- není rozdíl mezi originálem a hardlinkem
- lze vytvářet jen v rámci filesystemu
- nelze vytvářet pro adresáře

symbolický link (symlink, softlink)

- pouze odkaz na skutečnou cestu k souboru jiného typu (`ls -l` ho označuje 'l'), tj. symbolický link je typem odlišný od běžného souboru a jeho data obsahují obyčejný řetězec – jméno cesty, ať již relativní nebo absolutní
- odlišné chování pro originál a link (např. při mazání)
- pozor na relativní a absolutní cesty při přesouvání symbolického linku
- může ukazovat i na adresář nebo na neexistující soubor

Nejjednodušší způsob jak si ověřit, zda dané dva linky ukazují na stejný soubor na disku je použít `-i` přepínač příkazu `ls`.

```
$ ls -i /etc/passwd
172789 /etc/passwd
```

Vylepšení systému souborů

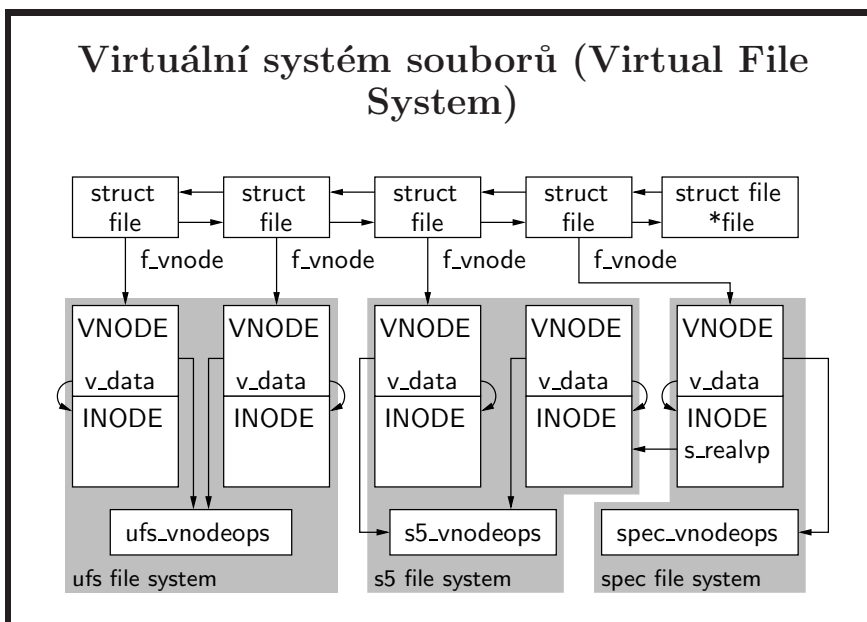
- cíl: snížení fragmentace souborů, omezení pohybu hlav disku umístěním i-uzlů a datových bloků blíž k sobě
- UFS (Unix File System), původně Berkeley FFS (Fast File System)
- členění na skupiny cylindrů, každá skupina obsahuje
 - kopii superbloku
 - řídicí blok skupiny
 - tabulku i-uzlů
 - bitmapy volných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

- superblok v každé cylinder skupině posunut tak, aby superbloky nebyly na stejné plotně
- další typy filesystémů: UFS2, Ext3, ReiserFS, XFS, ZFS aj.
- v <http://www.devnull.cz/mff/pvu/common/docs/filesystems.ps> je porovnání osmi různých filesystémů podle různých implementačních kritérií; nezahrnuje v sobě ale vývoj posledních let.
- UFS byl stále 32-bitový, což se odráželo na maximální délce souboru i na maximální velikosti filesystému
- žurnálování (XFS, Ext3, ReiserFS) – snaha o zmenšení nebezpečí ztráty dat v případě havárie, urychlení zotavení po havárii
- ZFS – moderní 128-bitový filesystém vyvinutý Sunem, nyní open-source, v Solarisu 10, teď již také v Mac OS X 10.5 a FreeBSD 7.

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 filesystemy 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

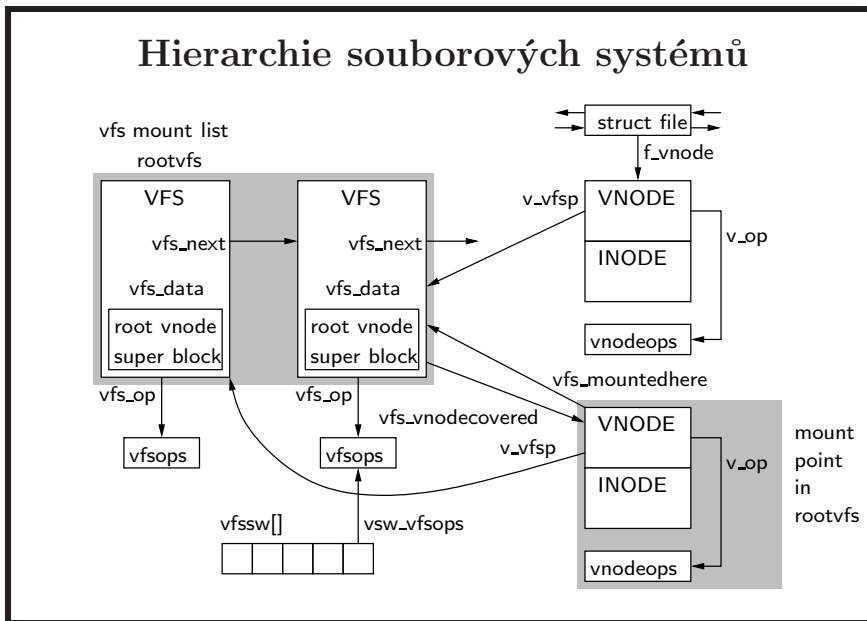
- *dirhash* pracuje tak, že při prvním přečtení adresáře se vytvoří v paměti hash struktura, následné přístupy do adresáře jsou pak srovnatelné se systémy používající B-stromy. Tímto způsobem je dosaženo zlepšení bez toho, aby se měnila struktura filesystemu na disku. Nelze to ale takto dělat do nekonečna, bude zajímavé jestli FreeBSD v budoucnu přejde na ZFS jako jejich hlavní filesystem.
- malé soubory se často ukládají v i-nodech, čímž se ušetří další přístupy na disk



- *FFS* uvedený ve 4.2BSD byl historicky druhý unixový filesystem. Někteří dodavatelé unixových systémů ho začali preferovat vzhledem k jeho lepšímu výkonu a novým možnostem, jiný zůstávali dále u *s5fs* z důvodu zpětné kompatibility. To dále prohlubovalo problém již tak nedostatečné interoperability mezi různými unixovými systémy. Některým aplikacím navíc plně nevyhovoval ani jeden z těchto filesystemů. Postupně se také objevovala potřeba pracovat s ne-unixovými filesystemy, např. *FAT*. A s rostoucí popularitou počítačových sítí se zvyšovala poptávka po sdílení souborů mezi jednotlivými systémy, což mělo za následek vznik distribuovaných filesystemů – např. *NFS* (Network File System).
- *FFS* zavedený do systému s *VFS* se začal nazývat *UFS*.
- vzhledem k výše popsané situaci bylo jen otázkou času, kdy dojde k fundamentálním změnám v infrastruktuře systému souborů, aby současně podporoval více typů filesystemů. Vzniklo několik různých implementací od různých výrobců, až se nakonec de facto standardem stala *VFS/vnode* architektura od firmy Sun Microsystems. V dnešní době prakticky všechny unixové a unix-like systémy podporují *VFS*, i když často se vzájemně nekompatibilními úpravami. *VFS* se poprvé objevilo v roce 1985 v Solarisu 2.0; brzy bylo převzato BSD – *FFS* s podporou *VFS* je právě *UFS*.
- hlavní myšlenka: každému otevřenému souboru v systému přísluší struktura *file* (to by vlastně byl jeden slot v naší již známé systémové tabulce otevřených souborů). Ta ukazuje na *vnode* (*virtual node*). *Vnode* obsahuje část nezávislou na konkrétním systému souborů a část závislou, což může být například struktura *inode*. Ta je specifická pro každý typ souborového systému. **Každý typ filesystemu implementuje pevně danou**

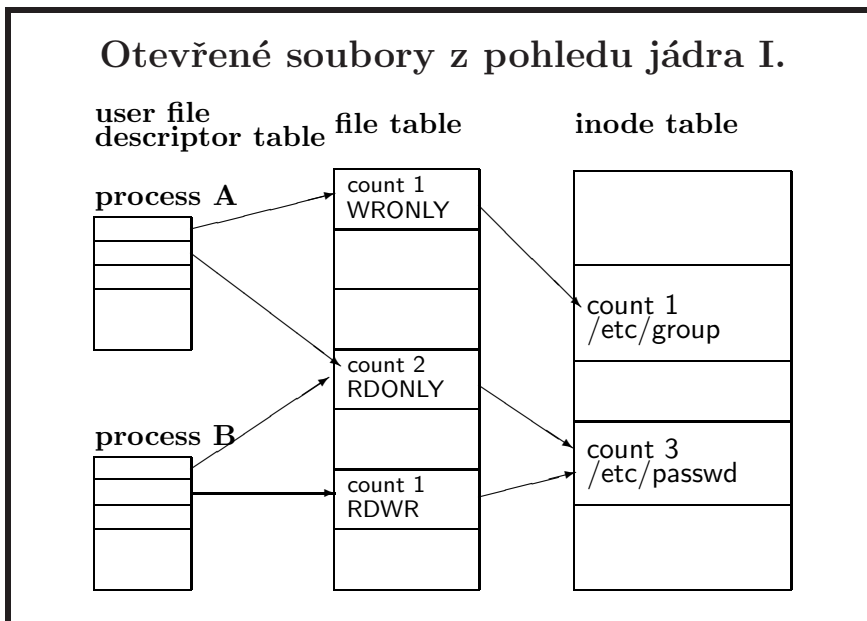
sadu funkcí pro jednotlivé operace nad soubory, na kterou se odkazují všechny virtuální uzly odpovídající danému typu filesystemu. **Tato sada funkcí tedy definuje vnode interface.** Když tedy zavoláte například `open()`, jádro zavolá příslušnou implementaci v závislosti na typu filesystemu (např. z modulu `ext2fs`). Implementačně závislá část struktury `vnode` je přístupná pouze z funkcí příslušného typu filesystemu; jádro do ní tedy „nevidí“ přímo. Jak uvidíte na dalším slajdu, existuje ještě jedna sada funkcí, která se týká práce s filesystemy jako takovými. Ta pak definuje VFS interface. Tyto dvě sady společně tvoří `vnode/VFS` rozhraní, kterému se běžně říká jen VFS.

- (nebudu zkoušet) – u speciálních souborů je situace složitější, v SVR4 struktura `file` ukazuje na `snode` (*shadow-special-vnode*), který definuje operace se zařízením (pomocí souborového systému `spec`) a prostřednictvím ukazatele `s_realvp` se odkazuje na reálný `vnode` pro operace se speciálním souborem; ten je potřeba například pro kontrolu práv přístupu. Každému zařízení může odpovídat více speciálních souborů, a tedy více `snodes` a příslušných reálných `vnodes`. Všechny takové `snodes` pro jedno zařízení mají ukazatel `s_commonvp` na jeden společný `snode` (toto není na obrázku zachyceno). Při otevření speciálního souboru se hledá v hash tabulce `snodes` otevřených zařízením položka odpovídající speciálnímu souboru (podle major a minor čísla zařízením). Když `snode` není nalezen, vytvoří se nový. Tento `snode` se pak používá při operacích se zařízením. Více viz například [Vahalia].



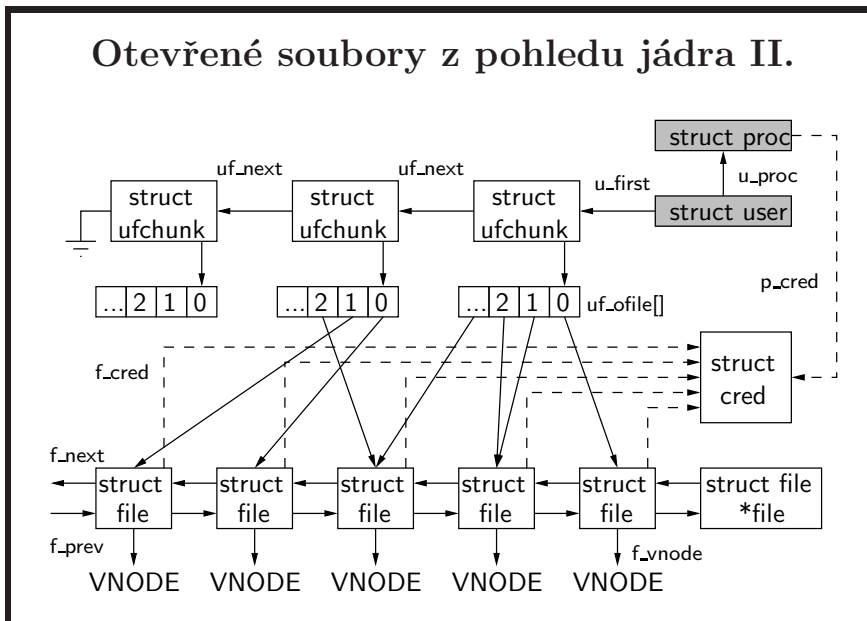
- struktura `vfs` obsahuje implementačně nezávislé informace o filesystemu, nezávislé na konkrétním typu filesystemu (podobně jako `vnode` funguje pro soubory). Tato struktura nereprezentuje konkrétní typ filesystemu, ale filesystem přimontovaný do hierarchie souborů. V tomto vázaném seznamu tedy může být více struktur stejného typu souborového systému.

- `rootvfs` – odkaz na root file system
- `vfssops` – tabulka funkcí pro konkrétní typ systému souborů
- `vfssw[]` – pole odkazů na tabulky `vfssops` pro všechny systémem podporované typy filesystémů, z tabulky se vybírá při připojování svazku podle typu filesystému zadaného při volání `mount()`
- `v_vfsp` – odkaz z `vnode` na filesystém (strukturu `vfs`), na kterém leží soubor reprezentovaný pomocí `vnode`
- `v_vfsmountedhere` – pouze ve `vnode`, který reprezentuje mount point (adresář, na kterém je připojen kořen jiného filesystému); odkazuje na strukturu `vfs` reprezentující připojený filesystém
- `v_vnodecovered` – odkaz na `vnode` adresáře, na kterém je filesystém připojen



- toto je nejjednodušší pohled na tabulky v jádře které se týkají souborů, je to převzato z [Bach]; dnes to je o něco složitější, myšlenka je ale pořád stejná. Realitě více se podobající obrázek je na příštím slajdu.
- každý proces má svoji tabulku souborových deskriptorů (*user file descriptor table*)
- z této tabulky je odkazováno na systémovou tabulku otevřených souborů systému (*file table*; ano, tato tabulka je pouze jedna). Zde je mód otevření souboru a také **aktuální pozice v souboru**.
- z tabulky otevřených souborů je odkazováno do tabulky načtených inodů v paměti (dnes jsou to tzv. *vnodes* – *virtual nodes*, ale to nám nyní může být úplně jedno)

- tabulka otevřených souborů systému, která vlastně vytváří o jednu úroveň odkazů navíc, je zde proto, aby různé procesy mohly sdílet stejnou aktuální pozici v souboru.
- při otevření souboru pomocí volání `open()` se vždy alokuje nový slot v tabulce deskriptorů a také v systémové tabulce otevřených souborů (to je důležité!). Sdílení se pak v rámci jednoho procesu dosáhne duplikací deskriptorů, kdy více deskriptorů sdílí stejný slot v tabulce otevřených souborů systému nebo v případě různých procesů pak pomocí vytvoření nového procesu pomocí volání `fork()`, viz strana 119.



- struktury `proc` a `user` vytváří jádro pro každý proces a drží v nich služební informace o procesu.
- struktura `ufchunk` obsahuje `NFPCHUNK` (obvykle 24) deskriptorů souborů, po zaplnění se alokuje další `ufchunk`.
- struktura `file` (otevření souboru) obsahuje mód souboru (otevřen pro čtení, zápis, atd.), počet deskriptorů, které se na ni odkazují, ukazatel na `vnode` a pozici v souboru. Jedno otevření souboru může být sdíleno více deskriptory, jestliže byl původní deskriptor zkopírován, např. voláním `fork()` nebo `dup()`.
- struktura `cred` obsahuje uživatelskou a skupinovou identitu procesu, který otevřel soubor.
- jeden `vnode` odpovídající jednomu souboru může být sdílen několika strukturami `file`, pokud byl daný soubor vícekrát otevřen.
- ne všechny `vnodes` jsou asociovány s tabulkou otevřených souborů. Např. při spuštění programu je potřeba přistupovat do spustitelného souboru a proto se alokuje `vnode`.

Oprava konzistence souborového systému

- pokud není filesystem 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 systémy souborů (např. XFS v IRIXu, Ext3 v Linuxu) nepotřebují `fsck`.

- data se přepisují na disky z vyrovnávacích pamětí se zpožděním. Uložení všech vyrovnávacích pamětí lze vynutit systémovým voláním `sync()`. Periodicky vyrovnávací paměti ukládá zvláštní systémový proces (démon).
- zde je ukázka `fsck` na **odpojený** filesystem:

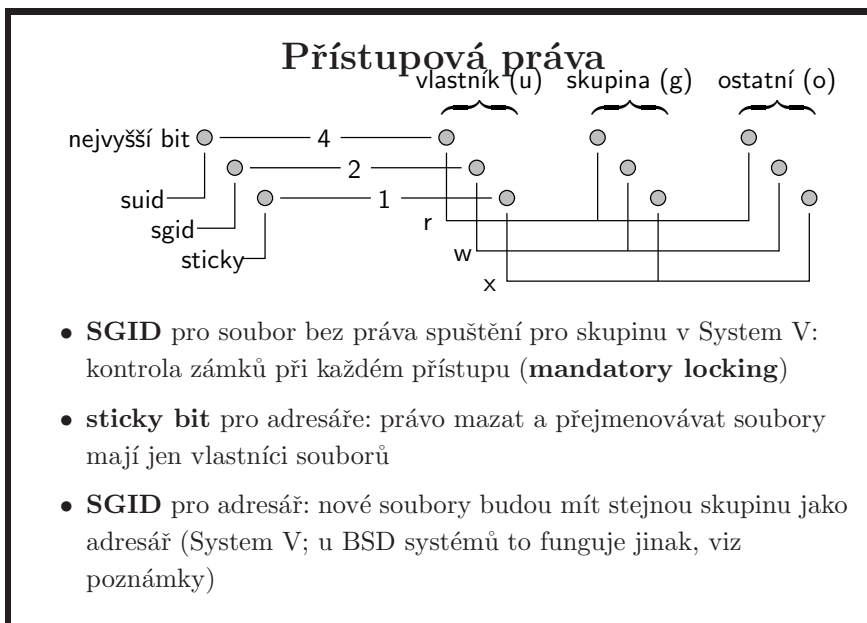
```
toor@shewolf:~# fsck /dev/ad0a
** /dev/ad0a
** Last Mounted on /mnt/flashcard
** Phase 1 - Check Blocks and Sizes
** Phase 2 - Check Pathnames
** Phase 3 - Check Connectivity
** Phase 4 - Check Reference Counts
** Phase 5 - Check Cyl groups
24 files, 8848 used, 12951 free (7 frags, 1618 blocks, 0.0% fragmentation)
```

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 nekonzistenci 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 zapíše do non-volatile paměti
 - *soft-updates* – sleduje závislosti mezi ukazateli 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*

- filesystem *metadata* = inodes, directories, free block maps
- *ext2* dokonce defaultně používá asynchronní zápis metadat a je při použití synchronního zápisu výrazně pomalejší než UFS
- závislé operace jsou například smazání položky z adresáře a smazání diskového inode. Pokud by se stalo, že se nejdříve smaže diskový inode a pak teprve položka v adresáři, při výpadku mezi těmito dvěma operacemi vniká nekonzistence – link ukazuje na diskový soubor, který neexistuje. Není problém se tomuto vyhnout při synchronním zápisu metadat (víme kdy a co zapisujeme, určujeme tedy pořadí zápisu), ale při metodě *write-back* je již nutné řešit závislosti jednotlivých bloků na sebe, protože při klasické synchronizaci vyrovnávacích pamětí na disk jádro nezájímá, který blok se zapíše dřív a který později.
- často jsou bloky na sobě závislé ve smyčce. *Soft updates* dokáže takovou smyčku rozbít tím, že provede *roll-back* a po zápisu pak *roll-forward*
- výkon *soft updates* je srovnatelný výkonu UFS filesystému s asynchronním zápisem metadat
- teoreticky *soft updates* zaručují, že po rebootu není potřeba použít *fsck*, tj. že filesystém bude v takovém stavu, že je možné naboootovat. Je však nutné použít tzv. *background fsck* pro opravy nezávažných chyb – to je považováno stále za velkou nevýhodu *soft updates* zvláště s tím, jak rostou velikosti běžně používaných disků. Takovou chybou, která nebrání naboootování, ale je nutné ji odstranit je například blok, který je označen jako použitý, ale žádný soubor ho nepoužívá.

- soft updates nejsou vždy doporučovány pro root filesystem. Problém je to, že ztráta metadat na root filesystemu (viz 30-ti sekundová perioda zápisu) může být výrazně větší hrozbou zde než na `/usr`, `/home` atd. Další nevýhodou může být i to, že u soft updates mi smazání velkého souboru hned neuvolní místo.
- příklad: na bezpečnou operaci rename potřebuju při synchronním zápisu metadat 4 zápisy – zvýšení počtu odkazů v inode, vytvoření nové adresářové položky, smazání staré, a opětné snížení počtu odkazů v inode. Kdykoli by systém spadnul, nenastane nebezpečná situace. Například 2 odkazy z adresářů na inode s referenčním počtem 1 je problém, protože po zrušení jednoho odkazu to bude vypadat, že soubor je stále na disku, když už bys jeho data dávno smazána. Není těžké si asi představit, co by to mohlo znamenat v případě, že soubor obsahoval opravdu důležitá data – například zálohu. Opačná situace, tj. jeden odkaz na inode s referencí 2 sice také není správná situace, ale neohrožuje to možnost filesystem namontovat a normálně používat. V nejhorším se stane, že soubor vypadá že již na disku není a přitom stále existuje. U soft updates operace rename vytvoří kružnici, protože nejdříve je potřeba zapsat zvýšení počtu referencí, pak adresářové bloky a poté snížení referencí. A protože zvýšení/snížení se týká stejného inode, tak je při zápisu třeba udělat roll-back na (řekněme) 2, zapsat inode na disk, zapsat bloky adresářů a pak roll-forward na počet referencí 1. Při této akci je nad inodem držen zámek, takže nikdo nenačte starší data. Je jednoduché ukázat, že nelze zapsat žádný z těch tří bloků v kružnici tak, jak to je na konci operace rename, že je opravdu nutný ten roll-back – mohli bychom uvažovat, že inode se vlastně nezměnil a není třeba řešit zda se může/nemůže zapsat; zápis nového adresářového odkazu bez zvýšení počtu odkazů v inodu by nás totiž mohl dostat přesně do situace, která je popsána o pár řádků výše.



- **SGID** pro adresáře u BSD systémů způsobí, že soubory a podadresáře vytvořené v tomto adresáři budou mít stejného majitele jako je majitel daného adresáře. Nutným předpokladem je dále to, že daný UFS filesystém musí být namontován s `suiddir` příznakem a v jádru je option `SUIDDIR` (a to není default). Navíc to nefunguje pro `roota`. Tato možnost existuje kvůli Sambě a Nettalku.
- sticky bit pro adresáře: přejmenovat nebo smazat soubor může jen jeho vlastník (v některých implementacích stačí i právo zápisu do souboru), nestačí právo zápisu do adresáře. Toto nastavení se používá pro veřejné adresáře (např. `/tmp`).
- původně měl sticky bit význam i pro spustitelné soubory: program s nastaveným sticky bitem zůstal po ukončení v paměti a jeho opětovné spuštění bylo rychlejší. Dnes se sticky bit v tomto významu už nepoužívá.
- některé filesystémy (XFS, AFS, UFS2, ZFS) mají tzv. access control lists (ACL's), které dovolují jemnější přidělování práv jednotlivým uživatelům a skupinám.

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, ukazovátka 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()`, ...

- každá funkce, která alokuje deskriptory (nejen `open()` a `creat()`, ale např. i `pipe()`, `dup()`, `socket()`) alokuje vždy volné deskriptory s nejnižším číslem.
- proces dědí otevřené soubory od rodiče, tyto soubory nemusí znovu otvírat. Obvykle (ale ne vždy) proces dostane otevřené alespoň deskriptory 0, 1 a 2.
- funkce ze souboru `stdio.h` (např. `fopen()`, `fprintf()`, `fscanf()`) a odkazy na soubory pomocí ukazatele na `FILE` jsou definovány ve standardní knihovně a pro svojí činnost používají volání jádra (např. `open()`, `write()`, `read()`). My se nebudeme knihovnou `stdio` zabývat.

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_CREAT`)
 - `O_TRUNC` ... zrušit předchozí obsah (právo zápisu nutné)
 - ...
- při `O_CREAT` definuje třetí parametr `mode` přístupová práva

- při použití `O_CREAT` se `mode` ještě modifikuje podle `umask`.
- `mode` nemá defaultní hodnotu, tj. vezme se to, co je na zásobníku i když tento parametr není přítomen! Příznaky i mód jsou uloženy v systémové tabulce otevřených souborů.
- pokud se znovu použije dříve využívaná položka v tabulce deskriptorů nebo v tabulce otevřených souborů, vše potřebné se vynuluje (pozice v souboru, flagy deskriptoru, ...)
- existují ještě další nastavitelné příznaky:
 - `O_SYNC` (`O_DSYNC`, `O_RSYNC` – není na BSD) ... operace se souborem skončí až po fyzickém uložení dat (synchronized I/O)
 - `O_NOCTTY` ... při otvírání terminálu procesem, který nemá řídicí terminál, se tento terminál nestane řídicím terminálem procesu
 - `O_NONBLOCK` ... pokud nelze čtení nebo zápis provést okamžitě, volání `read()/write()` skončí s chybou místo zablokování procesu
- v přístupových právech se vynulují ty bity, které jsou nastavené pomocí `umask()`.
- pro čtení a zápis nelze použít `O_RDONLY | O_WRONLY`, protože implementace použily 0 pro read-only flag. Norma proto definuje, že aplikace musí použít právě jeden z těchto tří flagů.
- je možné otevřít a zároveň vytvořit soubor pro zápis tak, že jeho mód zápis nedovoluje. Při příštím otevření souboru se ale již tento mód uplatní při kontrole přístupu a pro zápis ho otevřít nepůjde. Pro `O_TRUNC` také platí, že musíte mít pro daný soubor právo zápisu.

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.

- volání vrací nejnižší deskriptor, který v dané chvíli nebyl otevřený pro proces
- **open()** dokáže otevřít regulární soubor, zařízení i pojmenovanou rouru, ale vytvořit dokáže jen regulární soubor; pro ostatní typy souborů je nutné použít speciální volání.
- test, zda soubor existuje, a jeho případné vytvoření je atomická operace. Toho se využívá při používání lock souborů.
- speciální soubory může vytvářet pouze root, protože se pomocí nich definují přístupová práva k periferním zařízením.
- hodnoty pro `mode` je možné nalézt většinou v manuálové stránce pro `chmod`

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

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

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

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

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

- pro UNIX je každý soubor posloupnost bajtů bez další vnitřní struktury.
- chování `read()` a `write()` závisí na typu souboru (regulární, zařízení, roura, soket) a na tom, zda je soubor v blokujícím nebo neblokujícím módu (flag `O_NONBLOCK` při otevření souboru).
- volání `read()` vrátí nenulový počet bajtů menší než `nbyte`, pokud v souboru zbývá méně než `nbyte` bajtů, nebo volání bylo přerušeno signálem, nebo soubor je roura, zařízení či soket a aktuálně je k dispozici méně než `nbyte` bajtů. Při neexistenci dat se blokující `read()` zablokuje, dokud se nějaká data neobjeví, neblokující `read()` vrátí `-1` a nastaví `errno` na `EAGAIN`.
- volání `write()` vrátí nenulový počet bajtů menší než `nbyte`, jestliže se do souboru nevejde víc dat (např. zaplněný disk), zápis je přerušeno signálem nebo je nastaveno `O_NONBLOCK` a do roury, soketu nebo zařízení se vejde pouze část zapisovaných dat. Bez `O_NONBLOCK` se čeká, dokud se nepodaří zapsat vše. Pokud nelze aktuálně zapsat nic, blokující `write()` se zablokuje, dokud není možné zapisovat, neblokující `write()` vrátí `-1` a nastaví `errno` na `EAGAIN`.
- **důležité výjimky vzhledem k rourám** jsou uvedeny na straně 85.
- když `read()` nebo `write()` vrátí méně než `nbyte` z důvodu chyby, opakované volání téže funkce vrátí `-1` a nastaví kód chyby v `errno`.
- přerušeno `read()`, `write()` signálem dřív, než se podaří přečíst, resp. zapsat aspoň jeden bajt, způsobí návrat s hodnotou `-1` a nastavení `errno` na `EINTR`.
- příznak otevření souboru `O_APPEND` zajistí atomický zápis na konec souboru (pouze na lokálním disku), tj. **každý** zápis se provede na konec souboru.

Uzavření souboru: `close()`

```
int close(int filides);
```

- uvolní deskriptor `filides`, 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 roure se zruší.
- při skončení procesu se automaticky provede `close()` na všechny deskriptory.

- pokud proces potřebuje dočasný soubor, může ho vytvořit, ihned smazat a pak s ním pracovat přes existující deskriptor (tento deskriptor lze předat synovským procesům). Když je takový soubor zavřen všemi procesy, jádro smaže jeho data z disku.
- i operace `close()` může selhat. Např. některé filesystémy zapisují data na disk až v okamžiku zavření souboru, když zápis skončí chybou, `close()` vrátí `-1`.
- otevírání souborů a nezavírání je při ukončení práce s nimi vede k alokované paměti, kterou již nemáme jak uvolnit (ztratili jsme na ni odkaz) – situace kde takto paměť “ztrácíme” se nazývá *memory leak*

Příklad: kopírování souborů

```
#include <fcntl.h>
#include <unistd.h>
int main(int argc, char *argv[])
{
    char buf[4096];
    int inf, outf, ilen;
    inf = open(argv[1], O_RDONLY);
    outf = creat(argv[2], 0666);
    while ((ilen = read(inf, buf, 4096)) > 0)
        write(outf, buf, ilen);
    close(inf);
    close(outf);
    exit(0);
}
```

- je neefektivní číst a zapisovat soubor po jednotlivých bajtech, lepší je najednou zpracovávat rozumně velké bloky.
- pokud potřebujete pracovat s malými částmi/buffery, je lepší použít stream orientované knihovní funkce **fopen()**, **fread()**, ... které data vnitřně bufferují

Práce s pojmenovanou rourou

- nemusí být možné vytvořit FIFO na síťovém filesystému (NFS, AFS)
- je nutné znát sémantiku otevírání pojmenované roury:
 - otevření roury pouze pro čtení se zablokuje do té doby, dokud se neobjeví zapisovatel (pokud již neexistuje)
 - otevření roury pouze pro zápis se zablokuje do té doby, dokud se neobjeví čtenář (pokud již neexistuje)
 - toto chování je možné ovlivnit flagem `O_NONBLOCK`
- sémantika čtení a zápisu je ještě o něco složitější, věnujte velkou pozornost poznámkám pod tímto slajdem
 - a je to stejné jako u nepojmenované roury (strana 118)

- je možné otevřít rouru pro zápis i čtení stejným procesem najednou, aniž by předtím existoval čtenář nebo zapisovatel
- pokud rouru nemá žádný proces otevřenou pro zápis, pro okamžité vrácení deskriptoru pouze pro čtení je nutné **otevřít** rouru s flagem `O_NONBLOCK`, proces se jinak na rouře zablokuje čekáním na zapisovatele. Pozor ale na to, že pokus o **čtení** z roury bez zapisovatele okamžitě vrátí 0 jako indikaci konce souboru; **proces se nezablokuje čekáním na zapisovatele**. Při **zápisu** do roury bez čtenáře (tj. zapisovatel otevřel rouru ještě v době, kdy čtenář existoval) pošle kernel procesu signál `EPIPE` (“broken pipe”).
- v případě otevírání pouze pro zápis s `O_NONBLOCK` bez existujícího čtenáře se vrátí chyba a `errno` se nastaví na `ENXIO`. Tato asymetrie je snahou, aby v rouře nebyla data, která nebudou v krátké době přečtena – systém nemá způsob, jak uschovávat data v rouře bez časového omezení. Bez `O_NONBLOCK` flagu se proces zablokuje.
- z uvedeného tedy vyplývá, že pokud chcete vytvořit proces, který čeká na pojmenované rouře a vykonává požadavky, musíte ji otevřít s flagem `O_RDWR` i když do roury nehodláte zapisovat; jinak po prvním zablokování v `open()` při čekání na otevření roury zapisovatelem by další volání `read()` pro akceptování dalšího požadavku typicky vrátilo 0, pokud by náhodou roura nebyla mezitím pro zápis otevřena dalším procesem.
- zápis maximální velikosti `PIPE_BUF` (`limits.h`) je zaručený jako atomický. Např. v OpenSolarisu to je to 5120 bajtů, ve FreeBSD 5.4 je to 512 bajtů. Pokud zapisujete více, může `write()` provést částečný zápis (a vrátí tak menší číslo než velikost dat která se měla zapsat).
- roura nemá pozici v souboru, zápis tak vždy přidává na konec.

- stejně se vzhledem ke čtení a zápisu chová i nepojmenovaná roura, viz strana 118.

Nastavení pozice: `lseek()`

```
off_t lseek(int filides, off_t offset, int whence);
```

- nastaví pozici pro čtení a zápis v otevřeném souboru daném číslem deskriptoru `filides` na hodnotu `offset`.
- podle hodnoty `whence` se `offset` počítá:
 - `SEEK_SET` ... od začátku souboru
 - `SEEK_CUR` ... od aktuální pozice
 - `SEEK_END` ... od konce souboru
- vrací výslednou pozici počítanou od začátku souboru.
- `lseek(filides, 0, SEEK_CUR)` pouze vrátí aktuální pozici.

- lze se přesunout i na pozici za koncem souboru. Pokud se pak provede zápis, soubor se prodlouží a v přeskočené části budou samé nuly (samotné `lseek()` nestačí). Některé filesystémy takové bloky celých nul pro úsporu místa neukládají.
- velikost souboru je možné zjistit pomocí `lseek(filides, 0, SEEK_END)`.
- nejčastější operace s `lseek` jsou **tři**: nastavení konkrétní pozice od začátku souboru, nastavení pozice na konec souboru a zjištění aktuální pozice v souboru (0 společně se `SEEK_CUR`)
- při použití `lseek` se žádné I/O neprovede, žádný příkaz se nepošle na řadič disku
- `lseek` nemusí sloužit jen pro operace `read` a `write`, ale také pro následnou operaci `lseek`
- ukládání nul může vést k problémům se zálohami

Změna velikosti: truncate()

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

- změní délku souboru zadaného cestou nebo číslem deskriptoru na požadovanou hodnotu.
- při zkrácení souboru zruší nadbytečná data.
- standard ponechává nspecifikované, jestli funguje prodloužení souboru (s vyplněním přidaného úseku nulami). Proto je lepší k prodloužení souboru použít

```
char buf = '\0';  
lseek(fildes, length-1, SEEK_SET);  
write(fildes, buf, 1);
```

- zrušit veškerý obsah souboru při otevření se dá příznakem `O_TRUNC` ve funkci `open()`.
- podrobnosti je třeba hledat v manuálové stránce, např. ve FreeBSD v sekci BUGS nalezneme toto: *Use of `truncate()` to extend a file is not portable.*

Duplikace deskriptoru: dup(), dup2()

```
int dup(int filde);
```

- duplikuje deskriptor *filde* na první volný deskriptor, vrátí nový deskriptor, který odkazuje na stejné otevření souboru.
- ekvivalent `fcntl(filde, F_DUPFD, 0);`

```
int dup2(int filde, int filde2);
```

- duplikuje deskriptor *filde* na deskriptor *filde2*.
- ekvivalent
`close(filde2);`
`fcntl(filde, F_DUPFD, filde2);`

- první volný deskriptor se použije i u otevírání a vytváření souborů, viz strany 80 a 81.
- duplikovaný a původní deskriptor sdílí stejné otevření souboru a tedy i aktuální pozici a mód čtení/zápis.
- ekvivalent pro `dup2` není zcela ekvivalentní, např. pokud je *filde* rovný *filde2*. Více viz norma.

Příklad: implementace shellového přesměrování

- `$ 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);
```

- další příklad použití `dup()` uvidíme, až se budeme zabývat rourami.
- je potřeba si dát pozor na stav deskriptorů. Druhý příklad nebude fungovat, když bude deskriptor 0 uzavřen, protože `open()` vrátí deskriptor 0 (první volný) a `dup()` vrátí chybu (pokus o duplikaci uzavřeného deskriptoru). Možné řešení:

```
close(1);
if((fd = open("out", O_WRONLY | O_CREAT | O_TRUNC, 0666)) == 0)
    dup(0);
close(2);
dup(1);
if(fd == 0)
    close(0);
```

nebo

```
fd = open("out", O_WRONLY | O_CREAT | O_TRUNC, 0666);
if(fd != 1) {
    dup2(fd, 1);
    close(fd);
}
dup2(1, 2);
```

Řídicí funkce souborů a zařízení: `fcntl()`, `ioctl()`

```
int fcntl(int fildev, int cmd, ...);
```

- slouží pro duplikaci deskriptorů, nastavování zámků, testování a nastavování různých příznaků souboru.

příklad: zavření standardního vstupu při spuštění programu (volání typu `exec`)

```
fcntl(0, F_SETFD, FD_CLOEXEC);
```

```
int ioctl(int fildev, int request, ... );
```

- rozhraní pro řídicí funkce periferních zařízení
- používá se jako univerzální rozhraní pro ovládání zařízení, každé zařízení definuje množinu příkazů, kterým rozumí.

- možné hodnoty `cmd` ve funkci `fcntl()`:
 - `F_DUPFD` ... duplikace deskriptoru
 - `F_GETFD` ... zjištění příznaků deskriptoru (`FD_CLOEXEC` – uzavření při `exec`). `FD_CLOEXEC` je jediný flag pro deskriptory, definovaný v normě UNIX 03.
 - `F_SETFD` ... nastavení příznaků deskriptoru
 - `F_GETFL` ... zjištění módu čtení/zápis a příznaků otevření souboru (jako u `open()`)
 - `F_SETFL` ... nastavení příznaků otevření souboru (`O_APPEND`, `O_DSYNC`, `O_NONBLOCK`, `O_RSYNC`, `O_SYNC`). Nemohu nastavit příznaky pro `ro/rw` a ani příznaky pro vytvoření, zkrácení nebo exkluzivní přístup k souboru.
 - `F_GETLK`, `F_SETLK`, `F_SETLKW` ... nastavování zámků
- je důležité si uvědomit, že jsou dva druhy příznaků – příznak(y) pro souborový deskriptor a příznaky pro otevřený soubor – tj. příznaky jsou uloženy ve dvou různých tabulkách.
- periferní zařízení podporují čtení a zápis dat pomocí `read()`, `write()` a mapování dat do paměti (`mmap()`), veškeré další operace se zařízením (např. nastavení parametrů, zamčení nebo `eject`) se dělají funkcí `ioctl()`.
- při nastavování příznaků nejdříve vždy zjistěte, jaké byly předtím. I když jste si jisti, že v dané chvíli jsou nulové a je tedy možné provést `fcntl(fd, O_APPEND)`, nemůžete vědět, co se může změnit (například o pár řádků výše nějaký flag přidáte, aniž byste věděli, že jste ovlivněni kódem dole). Tedy vždy použijte například toto:

```

flags = fcntl(fd, F_GETFL);
if (fcntl(fd, F_SETFL, flags | O_APPEND) == -1)
    ...

```

... a podobně pro odebrání flagu – je špatné řešení nastavit hodnotu flagů na nulu, místo toho je třeba použít bitového jedničkového doplňku příslušného flagu

Informace o souboru: stat()

```

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

```

- pro soubor zadaný cestou, resp. číslem deskriptoru, vrátí strukturu obsahující informace o souboru, např.:
 - `st_ino` ... číslo i-uzlu
 - `st_dev` ... číslo zařízení obsahujícího soubor
 - `st_uid`, `st_gid` ... vlastník a skupina souboru
 - `st_mode` ... typ a přístupová práva
 - `st_size`, `st_blksize`, `st_blocks` ... velikost souboru v bajtech, velikost bloku a počet bloků
 - `st_atime`, `st_mtime`, `st_ctime` ... časy posledního přístupu, modifikace souboru a modifikace i-uzlu
 - `st_nlink` ... počet odkazů na soubor

- *metadata* jsou informace o souboru – tedy mód, časy přístupu, délka, vlastník a skupina atd. Nepatří mezi ně skutečná data souboru, a ani jméno, které není uloženo v rámci daného souboru, ale v adresáři či v adresářích.
- metadata je možné přečíst, i když proces nemá práva pro čtení obsahu souboru.
- touto funkcí nezískám flagy deskriptoru ani flagy z pole tabulky otevřených souborů v systému, zde jde o informace ohledně souboru uloženého na paměťovém médiu.
- `c_time` není čas vytvoření soubor (creation time), ale čas změny (change time)
- norma nspecifikuje pořadí položek ve struktuře ani nezakazuje přidat další

Informace o souboru (2)

- pro typ souboru jsou v `<sys/stat.h>` definovány konstanty `S_IFMT` (maska pro typ), `S_IFBLK` (blokový speciální), `S_IFCHR` (znakový speciální), `S_IFIFO` (FIFO), `S_IFREG` (obyčejný), `S_IFDIR` (adresář), `S_IFLNK` (symlink).
- typ lze testovat pomocí maker `S_ISBLK(m)`, `S_ISCHR(m)`, `S_ISFIFO(m)`, `S_ISREG(m)`, `S_ISDIR(m)`, `S_ISLNK(m)`.
- konstanty pro přístupová práva: `S_IRUSR` (čtení pro vlastníka), `S_IWGRP` (zápis pro skupinu), atd.

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

- když je zkoumaný soubor symlink, `stat()` vrátí informace o souboru, na který ukazuje. Tato funkce vrací informace o symlinku.

- typ a práva souboru jsou uložena společně v `st_mode`, proto existují zmiňovaná makra.
- `S_IFMT` specifikuje tu část bitů, které jsou věnované typu souboru, makra pro jednotlivé typy pak nejsou masky, ale hodnoty, takže test na typ souboru je nutné udělat takto: `(st_mode & S_IFMT == S_IFREG)`. Všechna makra jsou v normě, takže jejich používáním zaručíme přenositelný kód.

Nastavení časů souboru

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

- nastaví čas poslední modifikace souboru a čas posledního přístupu k souboru.
- nelze změnit čas poslední modifikace i-uzlu.
- volající proces musí mít právo zápisu pro soubor.

- tuto funkci používají hlavně kopírovací a archivační programy, aby zajistily stejné časy kopie a originálu.
- shellové rozhraní pro funkci `utime()` představuje příkaz `touch`.

Test přístupových práv: `access()`

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

- otestuje, zda volající proces má k souboru `path` práva daná OR-kombinací konstant v `amode`:
 - `R_OK` ... test práva na čtení
 - `W_OK` ... test práva na zápis
 - `X_OK` ... test práva na spuštění
 - `F_OK` ... test existence souboru
- na rozdíl od `stat()`, výsledek závisí na RUID a RGID procesu
- toto volání se nedá použít bezpečně, proto ho nikdy nepoužívejte procesu

- volání `access()` aplikuje mechanismus testování přístupových práv k zadanému souboru pro volající proces a vrátí výsledek.
- funkce `access()` volání byla pro `setuid` proces, aby si mohl ověřit, zda uživatel běžící daný `setuid` proces by měl za normálních okolností k příslušnému souboru přístup. Z toho vyplývá, že toto volání je **security hole** – mezi testem a následnou akcí se soubor může změnit, což proces nemůže nikdy ošetřit. Řešením je vrátit se zpátky k reálným UID/GID a přístup vyzkoušet.

Nastavení přístupových práv

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

- změní přístupová práva souboru `path` na hodnotu `mode`.
- tuto službu může volat pouze vlastník souboru nebo superuživatel (`root`).

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

- změní vlastníka a skupinu souboru `path`. Hodnota `-1` znamená zachovat vlastníka, resp. skupinu.
- měnit vlastníka může jen superuživatel, aby uživatelé nemohli obcházet nastavené `quoty` tím, že své soubory předají někomu jinému.
- běžný uživatel může měnit skupinu svých souborů a musí přitom patřit do cílové skupiny.

- parametr `mode` zde samozřejmě neobsahuje typ souboru, jako tomu je například u volání `stat()`. Hodnoty `mode` viz `chmod(2)`.
- pokud nejsem vlastník, nemohu celkem logicky změnit mód ani u souboru s nastaveným přístupem `rw-rw-rw-`
- v některých implementacích může vlastník souboru předat vlastnictví někomu jinému, např. v IRIXu je chování `chown()` nastavitelné jako parametr jádra.
- není běžné volat funkci `chmod()` z uživatelských aplikací, na to se používají flagy u volání `open()`, hlavní použití je v aplikaci `chmod(1)`

Manipulace se jmény souborů

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

- vytvoří nový odkaz (položku adresáře) `path2` na soubor `path1`.
Funguje pouze v rámci jednoho svazku.

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

- zruší odkaz na soubor. Po zrušení posledního odkazu na soubor a uzavření souboru všemi procesy je soubor smazán.

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

- změní jméno souboru (přesně odkazu na soubor) z `old` na `new`.
Funguje pouze v rámci jednoho svazku.

- volání `link()` vytváří hardlinky, tj. zobrazení ze jména souboru na číslo i-uzlu. Číslo i-uzlů jsou jednoznačná pouze v rámci svazku, proto pro linky mezi filesystémy je nutné použít symlinky.
- parametr `path2` nesmí existovat, tedy nelze takto přejmenovávat
- `unlink()` nefunguje na adresáře
- shellový příkaz `mv` používá `rename` pro přesuny v rámci jednoho svazku. Přesun souboru mezi filesystémy vyžaduje nejprve soubor zkopírovat a pak smazat originál voláním `unlink`.
- `rename()` funguje nad symlinky, ne nad soubory, na které symlink ukazuje

Symbolické linky

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

- vytvoří symbolický link `path2` → `path1`.
- cíl symbolického linku může být i na jiném svazku, popřípadě nemusí vůbec existovat.

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

- do `buf` dá max. `bufsize` znaků z cesty, na kterou ukazuje symlink `path`.
- vrátí počet znaků uložených do `buf`.
- obsah `buf` není zakončen nulou (znakem `'\0'`)!

- shellový příkaz `ln` volá `symlink()` nebo `link()`, podle toho, jestli je použit přepínač `-l` nebo ne.
- smazání hardlinku nesmaže soubor, pokud na něj vede ještě jiný hardlink. Naopak soubor (položku adresáře i data) je možné smazat, i když na něj ukazují nějaké symlinky.
- `readlink()` je použitelný v situaci, pokud chci smazat soubor, na který daný symlink ukazuje
- `bufsize` se typicky dává o 1 menší než velikost bufferu, to pro ukončení znakem `'\0'`

Manipulace s adresáři

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

- vytvoří nový prázdný adresář, (bude obsahovat pouze položky '.' a '..').

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

- smaže adresář `path`. Adresář musí být prázdný.

```
DIR *opendir(const char *dirname);
```

```
struct dirent *readdir(DIR *dirp);
```

```
int closedir(DIR *dirp);
```

- slouží k sekvenčnímu procházení adresářů.
- struktura `dirent` obsahuje položky
 - `d_ino` ... číslo i-uzlu
 - `d_name` ... jméno souboru

- položky adresáře nejsou nijak uspořádány, `readdir()` je může vracet v libovolném pořadí.
- v některých implementacích (např. FreeBSD) lze adresář otevřít pro čtení (ne pro zápis) jako normální soubor a číst ho pomocí `read()`, ale je třeba znát jeho vnitřní organizaci. Proto je `readdir()` pro zpracování obsahu adresáře lepší než `read()`, který vrací raw data adresáře. Kromě toho, norma nevyžaduje, aby adresář bylo možné číst funkcí `read()`, Linux to například nedovolí.
- `readdir()` je stavová funkce. Pro vrácení se na začátek je možné použít funkci `rewinddir()`. S vlákny pak používat `readdir_r()`, protože struktura `dirent` je statická.
- `d_ino` není moc užitečné, protože v případě, kdy daný adresář je mount point, tak ukazuje na adresář, na který je další filesystem namontován, ne na kořen namontovaného filesystemu
- `rmdir` nefunguje na neprázdný adresář, je možné použít například toto:
`system("rm -r xxx")`

Příklad: procházení adresáře

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

- příkaz `ls` je založen na takovéto smyčce, navíc provádí např. třídění jmen souborů a zjišťování dalších informací pomocí `stat()`.
- konec adresáře se pozná tak, že `readdir()` vrátí `NULL`. To však vrátí i v případě, pokud nastala chyba. V takovém případě je kód chyby v proměnné `errno`, v případě prvním je `errno` nezměněna. Proto by `errno` mělo být vždy nastavené na nulu před voláním `readdir()`. V příkladu tomu tak není, protože z důvodu málo místa nekontrolujeme `errno` vůbec.

Aktuální adresář procesu

- každý proces má svůj aktuální (pracovní) adresář, vůči kterému jsou udávány relativní cesty k souborům. Počáteční nastavení pracovního adresáře se dědí od otce při vzniku procesu.

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

```
int fchdir(int fd);
```

- nastaví nový pracovní adresář procesu.

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


- uloží absolutní cestu k aktuálnímu adresáři do pole `buf`, jeho délka (`size`) musí být aspoň o 1 větší než délka cesty.

- funkci `fchdir()` se předává deskriptor získaný voláním `open()` na adresář.
- funkce `getcwd()` může vrátit jinou cestu než tu, po které jsme se do aktuálního adresáře dostali, jestliže část cesty v `chdir()` byl symlink nebo došlo k přesunu (přejmenování) některého adresáře na cestě od kořene. U současných ů by se to ale už stát nemělo.

Obsah

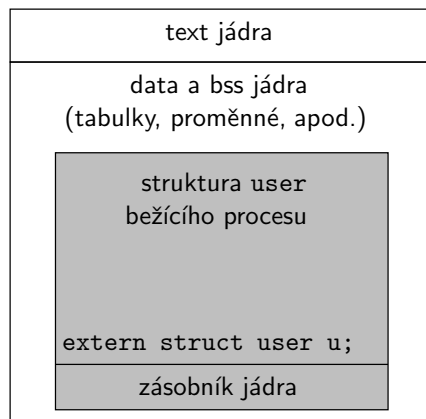
- úvod, vývoj UNIXu a C, programátorské nástroje
- základní pojmy a konvence UNIXu a jeho API
- přístupová práva, periferní zařízení, systém souborů
- **manipulace s procesy, spouštění programů**
- signály
- synchronizace a komunikace procesů
- síťová komunikace
- vlákna, synchronizace vláken
- ??? -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

Paměť procesu v uživatelském režimu



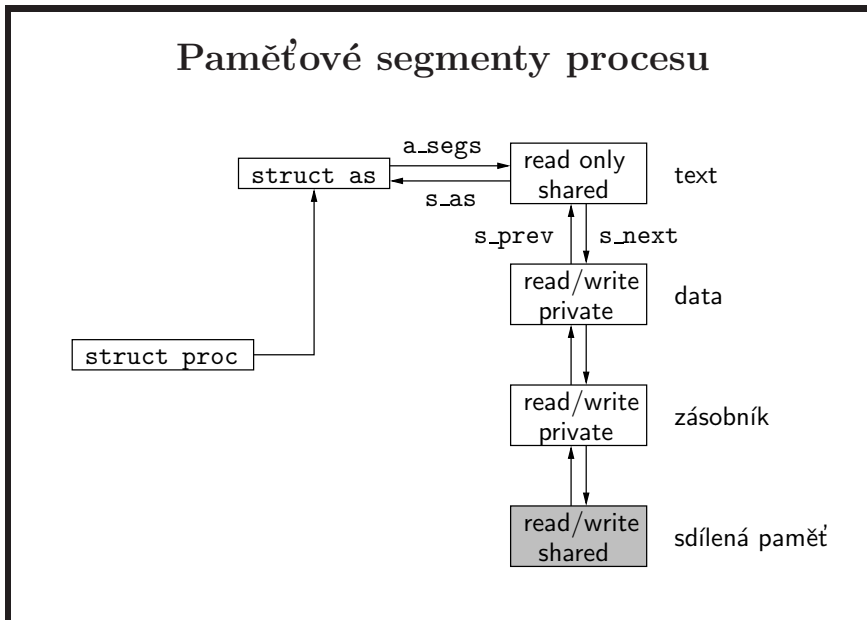
- *text* ... kód programu
- *data* ... inicializované proměnné
- sekce **text** a **data** jsou uloženy ve spustitelném souboru
- *bss* ... neinicializované proměnné (*bss* pochází z assembleru IBM 7090 a znamená „block started by symbol“). Za běhu programu tvoří sekce **data** a **bss** dohromady datový segment procesu. Velikost datového segmentu lze měnit pomocí systémových volání `brk()` a `sbrk()`.
- (*uživatelský*) *zásobník* ... automatické proměnné, parametry funkcí, návratové adresy. Každý proces má dva zásobníky, jeden pro uživatelský režim a jeden pro režim jádra. Uživatelský zásobník procesu automaticky roste podle potřeby (neplatí, pokud se používají vlákna).
- *oblast user (u-area)* ... obsahuje informace o procesu používané jádrem, které nejsou potřebné, když je proces odložen na disk (počet otevřených souborů, nastavení ošetření signálů, počet segmentů sdílené paměti, argumenty programu, proměnné prostředí, aktuální adresář, atd.). Tato oblast je přístupná pouze pro jádro, které vždy vidí právě jednu u-oblast patřící právě běžícímu procesu. Další informace o procesu, které jádro může potřebovat i pro jiný než právě běžící proces, nebo i když je proces odložen, jsou ve struktuře `proc`. Struktury `proc` pro všechny procesy jsou stále rezidentní v paměti a viditelné v režimu jádra.

Paměť procesu v režimu jádra

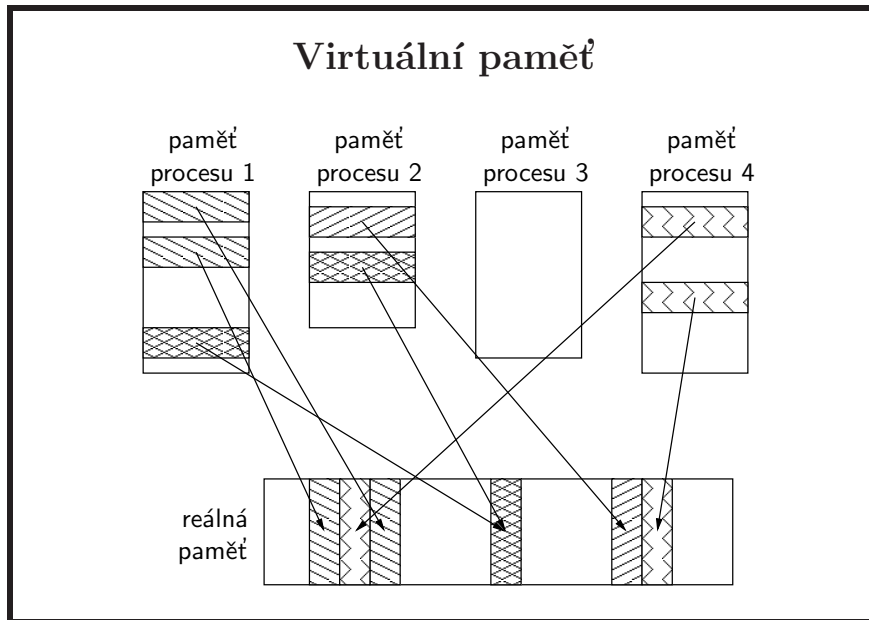


- proces se dostane do režimu jádra buď příchodem *přerušeni vyvolaného procesorem* (výpadek stránky, neznámá instrukce,...), *časovačem* (v pravidelných intervalech je potřeba aktivovat plánovač procesů), *periferním zařízením*, nebo instrukcí synchronního přerušeni (standardní knihovna takto předává řízení jádru, aby obsloužilo *systemové volání*).
- v paměti je pouze jedna kopie kódu a dat jádra, sdílená všemi procesy. Kód jádra je vždy celý rezidentní v paměti, není odkládán na disk.
- *text jádra* ... kód jádra operačního systému, zavedený při startu systému a rezidentní v paměti po celou dobu běhu systému. Některé implementace umožňují přidávat funkční moduly do jádra za běhu (např. při přidání nového zařízení se do jádra dynamicky přidá nový ovladač), není proto třeba kvůli každé změně regenerovat jádro a restartovat systém.
- *data a bss jádra* ... datové struktury používané jádrem, součástí je i u-oblast právě běžícího procesu.
- *zásobník jádra* ... samostatný pro každý proces, je prázdný, jestliže je proces v uživatelském režimu (a tedy používá uživatelský zásobník).

Paměťové segmenty procesu



- každý proces má tři základní segmenty (paměťové segmenty, nemluvíme o hardwarových segmentech):
 - text
 - data
 - zásobník
- dále lze do adresového prostoru připojit segmenty sdílené paměti (`shmat()`) nebo soubory (`mmap()`).
- text je sdílen všemi procesy, které provádí stejný kód. Datový segment a zásobník jsou privátní pro každý proces.
- základním rysem této architektury je tzv. *memory object*, což je abstrakce mapování mezi kusem paměti a místem, kde jsou data normálně uložena (tzv. *backing store* nebo *data object*). Takové místo uložení může být například swap nebo soubor. Adresový prostor procesu je pak množina mapování na různé datové objekty. Existuje i *anonymní objekt*, který nemá místo trvalého uložení (používá se například pro zásobník). Fyzická paměť pak slouží jako cache pro data těchto namapovaných datových objektů.
- tato zde velmi hrubě popsaná architektura se nazývá VM (od *Virtual Memory*), a objevila se v SunOS 4.0. Na této architektuře je založena architektura virtuální paměti v SVR4. Více informací viz [Vahalia], původní článek z roku 1987 představující tuto architekturu: Gingell, R. A., Moran J. P., Shannon, W. A. – *Virtual Memory Architecture in SunOS* nebo přednáška o operačních systémech na MFF ve čtvrtém (?) ročníku.



- každý proces vidí svůj adresový prostor jako souvislý interval (virtuálních) adres od nuly po nějakou maximální hodnotu. Přístupné jsou pouze ty adresy, na kterých je namapován některý segment procesu (to je právě to mapování, o kterém se mluví na předchozím slajdu).
- jádro dále rozděluje paměť procesu na stránky. Každá stránka má své umístění v rámci fyzické paměti. Toto umístění je dáno stránkovacími tabulkami jádra a stránky mohou být v rámci libovolně promíchány vůči jejich pořadí ve virtuální adresovém prostoru.
- pokud není stránka právě používána, může být také odložena na disk.
- paměťový manager jádra zajišťuje mapování mezi virtuálními adresami používanými kódem uživatelských procesů i jádra na fyzické adresy a načtení odložených stránek z disku při výpadku stránky.

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.

překlad adres: přístup na neplatnou adresu nebo pokus o zápis do paměti pouze pro čtení vyvolá signál **SIGSEGV**.

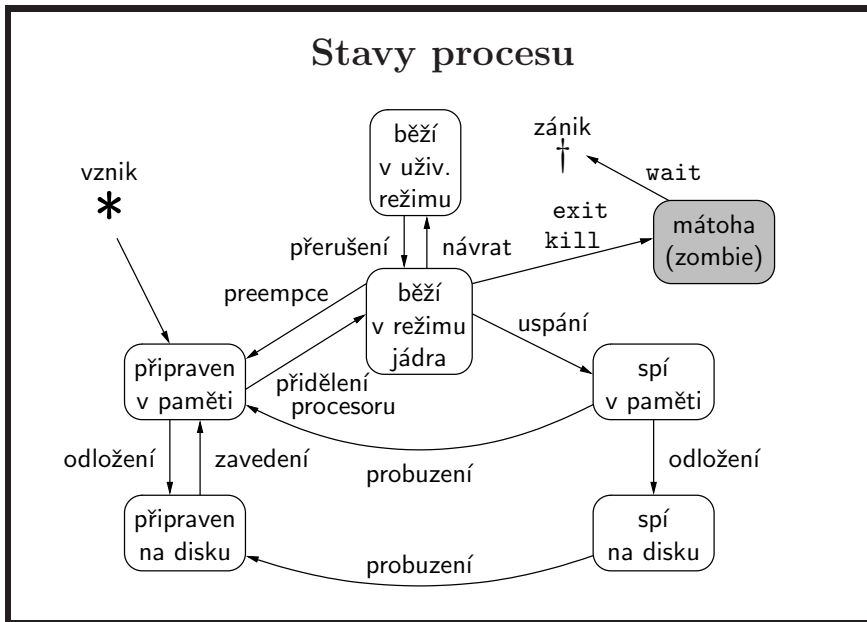
swap: odkládací prostor se vytváří na samostatném oddílu disku, od SVR4 může být i v souboru.

swapper: proces **swapper** se snaží odložit na disk nějaký proces, který není zamčen v paměti, a na uvolněné místo zavést dříve odložený proces.

demand paging: při žádosti procesu o paměť se pouze upraví tabulka stránek. První instrukce adresující obsah stránky vyvolá výjimku. Jádro ji ošetří tím, že alokuje stránku.

copy-on-write: více procesů může sdílet zapisovatelnou fyzickou stránku, která je ale logicky privátní pro každý proces (tato situace nastane např. po vytvoření procesu voláním **fork()**). Dokud procesy z paměti pouze čtou, přistupují ke sdílené stránce. Pokud se proces pokusí obsah stránky změnit, vyvolá výjimku. Jádro zkopíruje stránku, přidělí procesu kopii, která už je privátní a proces ji může dále libovolně měnit. Ostatní procesy používají stále nezměněnou původní stránku.

stránky k odložení se hledají algoritmem *NRU* (not recently used): každá stránka má příznaky **referenced** a **modified**, na začátku vynulované. Při prvním přístupu se nastaví **referenced**, při změně **modified**. Oba příznaky se periodicky nulují. Přednostně se uvolňují stránky, které nejsou modifikované ani použité. Stránky kódu programu a mapovaných souborů se neukládají do odkládacího prostoru, ale obnovují se z příslušného souboru.



- po ukončení procesu voláním `exit()` nebo v reakci na signál přechází proces do stavu mátoha (zombie), protože jádro si musí pamatovat k číslu procesu jeho návratovou hodnotu. Celá paměť procesu je uvolněna, zbývá pouze struktura `proc`. Proces lze definitivně zrušit, až když se jeho rodič zeptá na návratovou hodnotu voláním typu `wait()`.
- v dnešních UNIXech se obvykle do odkládací oblasti na disku (swap area) neodkládají celé procesy, ale jednotlivé stránky paměti.
- proces je *uspán*, když o to sám požádá, např. začne čekat na dokončení periferní operace. *Preempce* je naopak nedobrovolné odebrání procesoru plánovačem.

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.

- základem preemptivního plánování jsou pravidelná přerušování od časovače, která odeberou procesor běžícímu procesu a předají řízení jádru (aktivuje se plánovač procesů).
- jiná varianta je nepreemptivní (kooperativní) plánování, kdy proces běží, dokud se sám nevzdá procesoru, tj. dokud nezavolá takovou systémovou funkci, která přepne kontext na jiný proces. Nevýhodou kooperativního plánování je, že jeden proces může stále blokovat procesor a ostatní procesy se nikdy nedostanou na řadu.
- UNIX používá pouze preemptivní plánování pro uživatelské procesy.
- tradiční UNIXové jádro funguje kooperativním způsobem, tj. proces běžící v režimu jádra není přeplánován, dokud se sám nevzdá procesoru. Jádra moderních UNIXů jsou již preemptivní – je to hlavně kvůli real-time systémům; tam je potřeba mít možnost běžící proces zbavit procesoru okamžitě, nečekat na to, až se vrátí z režimu jádra nebo se sám uspí.
- při preemptivním plánování může být proces kdykoliv přerušen a řízení předáno jinému procesu. Proces si proto nikdy nemůže být jistý, že určitou operaci (více než jednu instrukci, kromě systémových volání se zaručenou atomičností) provede atomicky, bez ovlivnění ostatními procesy. Pokud je třeba zajistit atomičnost nějaké akce, musí se procesy navzájem synchronizovat. Při kooperativním plánování problém synchronizace odpadá (atomická posloupnost operací se zajistí tím, že se proces během ní nevzdá procesoru).

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)

- systémová třída je používána pouze jádrem, uživatelský proces běžící v režimu jádra si ponechává svou plánovací charakteristiku.
- procesy ve třídě reálného času mají nejvyšší prioritu, proto musí být správně nakonfigurovány, aby nezablokovaly zbytek systému.
- jestliže je proces ve třídě sdílení času uspán a čeká na nějakou událost, je mu dočasně přiřazena systémová priorita. Po probuzení se takový proces dostane na procesor dříve, než ostatní procesy, které nespí.
- pevná část priority procesu ve třídě sdílení času se dá nastavit pomocí `int setpriority(int which, id_t who, int nice);`
nebo `int nice(int 1);`

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 řídicí terminál (je to obvykle login terminál), tzv. *controlling terminal*
- speciální soubor `/dev/tty` je asociován s řídicím terminálem každého procesu
- každý terminál je asociován se skupinou procesů, tato skupina se nazývá řídicí skupina (*controlling group*)
- kontrola jobů (*job control*) je mechanismus, jak pozastavovat a probouzet skupiny procesů a řídit jejich přístup k terminálům
- *session* (relace) je kolekce skupin procesů vytvořená pro účely řízení jobů

- když se uživatel přihlásí do systému, je vytvořena nová relace, která se skládá z jedné skupiny procesů, ve které je jeden proces – ten který vykonává uživatelův shell. Tento proces je zároveň vedoucí této jediné skupiny procesů a také je vedoucí relace. V případě, že job control je povolen, každý příkaz nebo kolona příkazů vytvoří novou skupinu procesů, jeden z procesů v každé skupině se vždy stane vedoucím procesem dané skupiny. Jedna ze skupin může běžet na popředí, ostatní běží na pozadí. Signály které jsou generované z klávesnice (tj. stiskem kombinace kláves, nemyslí se tím spuštění příkazu `kill!`) jsou zaslány pouze skupině, která běží na popředí.
- pokud job control není zapnut, znamená spuštění příkazu na pozadí pouze to, že shell nečeká na jeho ukončení. Existuje pouze jedna skupina procesů, signály z klávesnice se posílají všem procesům běžícím na popředí i na pozadí. Nelze přesouvat procesy z pozadí na popředí a naopak.
- když proces, který má kontrolní terminál, otevře soubor `/dev/tty`, tak se asociuje se svým kontrolním terminálem. Tj. pokud dva různé procesy z různých relací otevrou tento soubor, přistupují oba k různým terminálům.

Identifikace procesu

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

- vrací process ID volajícího procesu.

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

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

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

- vrací process ID rodiče.

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

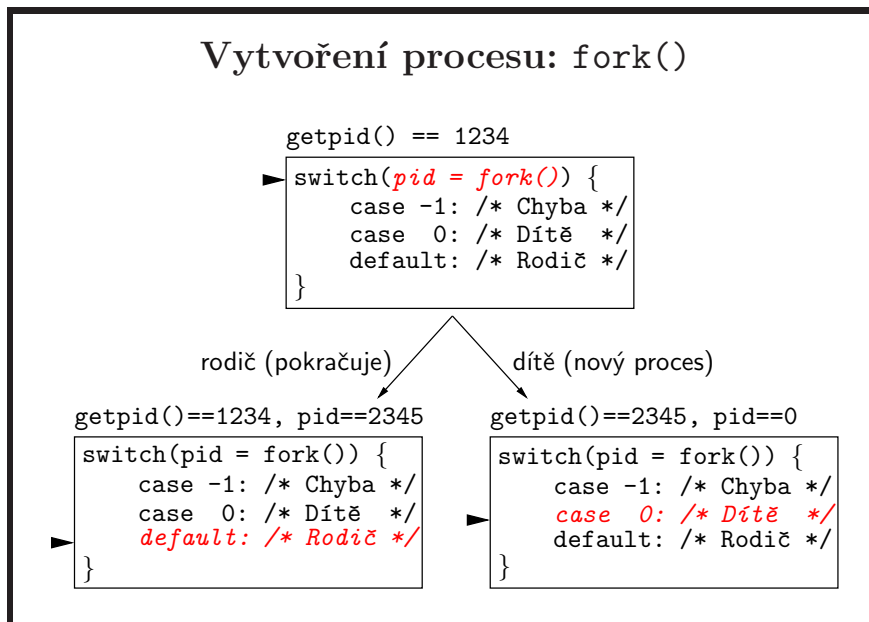
- vrací group ID vedoucího procesu session (sezení, terminálové relace) pro proces `pid` (0 znamená pro volající proces)

skupiny procesů umožňují posílat signály najednou celé skupině.

session (relace, sezení) je kolekce procesů vytvořená pro účely řízení prací (*job control*). Procesy sezení sdílejí jeden *řídící terminál*. Session zahrnuje jednu nebo více skupin procesů. Max. jedna skupina v rámci sezení běží na popředí (*foreground process group*) a má přístup k řídicímu terminálu pro vstup i výstup, ostatní běží na pozadí (*background process groups*) a mají k řídicímu terminálu přístup volitelně jen pro výstup nebo vůbec (nepovolená operace s terminálem pozastaví proces). Proces, který ještě není vedoucím skupiny procesů, se může stát vedoucím sezení a zároveň skupiny procesů voláním `setsid()`. Jestliže proces už je vedoucím skupiny, `setsid()` selže, pak je třeba provést `fork()` a `setsid()` zavolat v synovském procesu. Takový proces nemá řídicí terminál, může ho získat otevřením terminálu, který ještě není řídicím terminálem sezení, když při `open()` neuvěde příznak `O_NOCTTY`, nebo jiným implementačně závislým způsobem.

rodičovský proces: Každý proces (kromě `swapperu`, `pid == 0`) má rodiče, tj. proces, který ho stvořil voláním `fork()`. Jestliže rodič skončí dříve než dítě, adoptivním rodičem se stává proces `init` s `pid == 1`, který se také postará o uklizení zombie po skončení procesu.

Vytvoření procesu: fork()



- dítě je téměř přesnou kopií rodiče, liší se *PID*, dále *parent PID* a některé další podrobnosti (účetovací časy se nastaví na 0, nedědí se nastavení `alarm()` a zámky souborů). A pokud měl rodič více vláken, má syn pouze to, které zavolalo `fork()`; o tom více později až se dostaneme k vláknům. Tyto informace by měly být v manuálové stránce `textttfork(2)`.
- pro urychlení a menší spotřebu paměti se adresový prostor nekopíruje, ale používá se mechanismus *copy-on-write*.
- je logické, že otec dostane jako návratovou hodnotu volání `fork` PID syna a syn 0; syn si může velmi jednoduše svůj vlastní PID zjistit. Otec by ale již neměl možnost jednoduše zjistit, jaký je PID syna který byl právě vytvořen, navíc v situaci, kdy již vytvořil dříve syny jiné.

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`.
- `handlers` signálů se nahradí implicitní obsluhou.
- zavřou se deskriptory souborů, které mají nastavený příznak `FD_CLOEXEC` (implicitně není nastaven).

- v `path` musí být celá (absolutní nebo relativní) cesta ke spustitelnému souboru. Obsah proměnné prostředí `PATH` se používá jen při voláních `execle()` a `execvp()`, když argument `path` neobsahuje znak `'/'`.
- někdy se používá `argv[0]` různé od jména spustitelného souboru. Např. `login` vloží na začátek jména spouštěného shellu znak `'-'`. Shell podle toho pozná, že má fungovat jako `login-shell`, tj. spustit `/etc/profile`.
- `exec()` nepředá kontrolu načtenému programu v paměti přímo, ale přes dynamický linker (též nazývaný *loader*), poté co ho (= toho *loadera*) namapuje do adresového prostoru procesu. Loader následně namapuje potřebné dynamické objekty a teprve poté předá kontrolu aplikaci. Viz také strana 31. Pro jednoduché ověření stačí vytvořit program obsahující pouze třeba volání `open()`. Tento program pak spustíte pomocí `truss(1)` takto: `truss ./a.out`. Uvidíte, která volání se použijí ještě předtím, než se zavolá `open()`.
- `exec()` nezmění hodnoty `RUID` a `RGID`. A pokud je to program s nastaveným `SUID` bitem, tak se `EUID` a uschované `UID` nastaví na `UID` majitele spustitelného souboru.
- dnešní unixové systémy umí spouštět i skripty, které začínají řádkem `#!/interpreter_path/interpreter_name [args]`

Varianty služby exec

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

- obdoba `execl()`, ale argumenty jsou v poli `argv`, jehož poslední prvek je `(char *)0`.

```
int execl(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`.

- **l** = list, **v** = vector, **e** = environment, **p** = PATH.
- kromě `execlp()` a `execvp()` je nutné vždy zadávat celou cestu.
- všechny varianty kromě `execl()` a `execve()` předávají spouštěnému programu své aktuální prostředí, tj. obsah pole `environ`.
- z nějakých historických důvodů neexistuje volání s **p** a **e** dohromady.

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:

hlavička souboru
tabulka programových hlaviček
sekce 1
⋮
sekce N
tabulka hlaviček sekcí

- hlavička souboru (*ELF header*) obsahuje základní informace o souboru.
- tabulka programových hlaviček (*program header table*) je přítomna pouze u souborů obsahujících spustitelné programy. Obsahuje informaci o rozvržení virtuální paměti procesu.
- sekce obsahují instrukce, data, tabulku symbolů, relokační data, apod.
- tabulka hlaviček sekcí (*section header table*) obsahuje služební informace pro linker.

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);
```

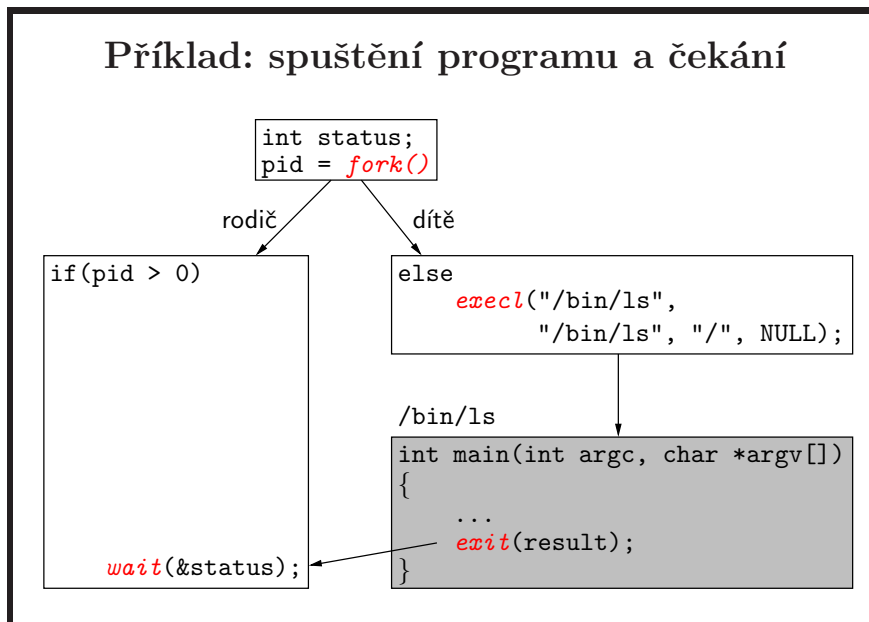
- počká, až skončí některý synovský proces, vrátí jeho PID a do `stat_loc` uloží návratový kód, který lze dále testovat:
 - `WIFEXITED(stat_val)` ... proces volal `exit()`
 - `WEXITSTATUS(stat_val)` ... argument `exit()`
 - `WIFSIGNALED(stat_val)` ... proces dostal signál
 - `WTERMSIG(stat_val)` ...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

- `_exit()` ... jako `exit()`, ale neprovádí se flush stdio streamů a nevolají se funkce nastavené pomocí `atexit()`
- ve standardu je ještě `WIFCONTINUED(stat_val)` ... pokračování po zastavení
- `opts` ve `waitpid()` – OR-kombinace:
 - `WCONTINUED` ... vrátí status procesu, který nebyl testován od pokračování procesu po zastavení
 - `WNOHANG` ... nečeká, pokud není status okamžitě k dispozici
 - `WUNTRACED` ... vrátí status zastaveného procesu, který nebyl testován po jeho zastavení
- `pid` ve `waitpid()`:
 - `== -1` ... libovolné dítě
 - `> 0` ... jedno dítě
 - `== 0` ... dítě ve stejné skupině procesů jako volající proces
 - `< -1` ... dítě ve skupině `abs(pid)`
- rodič by měl vždy na své děti zavolat `wait()` nebo `waitpid()`, protože jinak se v systému hromadí *zombie* (ukončené procesy, které pouze čekají, až si rodič přečte jejich návratovou hodnotu).

Příklad: spuštění programu a čekání



- toto je klasický způsob jak spustit nějaký program a po jeho skončení pokračovat. Rodič nemusí jen čekat na ukončení potomka, ale může vykonávat dál svůj kód.
- pozor na to, že ačkoli to na obrázku tak vypadá, návratová hodnota je pouze součástí toho, co dostanete z volání `wait()`. Na její získání je potřeba použít makra z předchozího slajdu.

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.

- nepojmenovanou rouru vytváří jeden proces a může ji předat pouze svým potomkům (pomocí deskriptorů zděděných při `fork()`). Toto omezení se dá obejít pomocí předání otevřeného deskriptoru přes unix-domain socket.
- jestliže funkce `write()` zapíše do roury nejvýše `PIPE_BUF` (systémová konstanta) bajtů, je zaručeno, že zápis bude atomický, tj. tato data nebudou proložena daty zapisovanými současně jinými procesy.
- v normě UNIX03 není specifikováno, zda `fildes[0]` je také otevřený pro zápis a zda `fildes[1]` je též otevřený pro čtení. Pozor na to, že například FreeBSD a Solaris mají roury obousměrné, ale Linux (když jsem se naposledy díval) ne. Je proto velmi vhodné počítat pouze s jednosměrnými rourami.
- **důležité:** pro čtení/zápis z/do roury platí stejné podmínky jako pro pojmenovanou rouru, viz strana 85. To také znamená, že jediný způsob, jak čtenářovi “poslat” end-of-file je, že všichni zapisovatelé zavřou příslušný deskriptor pro zápis.

Příklad: roura mezi dvěma procesy

shell: ls / | more

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

producent (dítě)

konzument (rodič)

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

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



- zavření zápisového deskriptoru `pd[1]` (ozn. \triangleright) v procesu konzumenta je nutné, protože jinak se na rourě nikdy nedetekuje konec souboru.
- čtecí deskriptor v procesu producenta `pd[0]` je také vhodné zavírat (ozn. \triangleright), protože když konzument předčasně skončí, dostane producent signál `SIGPIPE`. Kdyby deskriptor v producentovi nebyl zavřen, producent se nedozví, že konzument skončil, a po naplnění bufferu roury v jádru se zablokuje.
- pokud nemáme jistotu, že před voláním `pipe()` byl otevřen deskriptor 0, musíme v producentovi použít `dup2(pd[1], 1)`, protože `dup(pd[1])` by mohl vrátit deskriptor 0 místo požadovaného 1. Také je třeba testovat, zda neplatí `pd[1] == 1`, abychom si nechtěně nezavřeli rouru. Podobně je třeba otestovat `pd[0] == 0` v konzumentovi.
- je lepší vytvářet rouru od syna k otci, protože typicky nejdřív skončí proces zapisující do roury, čtoucí proces přečte zbylá data, zpracuje je, něco vypíše a teprve pak skončí.
shell čeká na otce, takže když směřuje roura od otce k synovi, otec skončí, shell vypíše prompt, ale pak ještě syn vypíše výstup. Možným řešením je čekání otce na skončení syna, jenže to se nedá zajistit, pokud otec provede `exec`.
- původní *Bourne shell* staví rouru tak, že poslední proces v rourě vytvoří předposlední jako svého syna, ten vytvoří předchozí proces a tak se postupuje až k začátku roury.
- v shellu `bash` jsou všechny procesy v rourě přímo potomky shellu (shell volá `fork()` tolikrát, jak dlouhá je roura). Shell před vypsáním promptu čeká, až všechny procesy roury skončí.

Sdílená paměť – úvod

- pípjy 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 semaforey
 - POSIX semaforey bez nutnosti systémového volání v běžném případě

- mapování souborů do paměti je jednou z implementací sdílené paměti. Pro popis úseku sdílené paměti používá soubor.
- takto implementovaná sdílená paměť je tedy pravidelně zapisována na disk
- pro sdílení bez režie zápisu změněných dat na disk je možné použít *memory based* filesystem, například *tmpfs* (Solaris, NetBSD – zde byl *tmpfs* napsán v roce 2005 jako součást *Summer of Code* sponzorovaného firmou Google, FreeBSD má podobnou vlastnost pod názvem *memory disk*). Jako tzv. *backing store* pro paměťové stránky patřící těmto filesystemům je obecně možné použít swap oblast na disku.

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 je alternativou ke zpracování souborů pomocí `read()`, `write()`, `lseek()`. Po namapování lze se souborem pracovat jako s datovou strukturou v paměti. Soubor se nekopíruje celý do paměti, alokují se pouze stránky na které se přistupuje. Pokud je potřeba stránku uvolnit, obsah se ukládá zpět do souboru (při `MAP_SHARED`) nebo do swapu – používá se mechanismus copy-on-write (při `MAP_PRIVATE`).
- při použití `MAP_PRIVATE` vidím na Solarisu všechny změny provedené jinými procesy, které namapovaly sdíleně, až do té doby, kdy do stránky zapíšu – v tom okamžiku se vytvoří kopie stránky a další takové změny již nevidím. Na FreeBSD tyto změny nevidím ani před zápisem. Viz specifikace: „*It is unspecified whether modifications to the underlying object done after the MAP_PRIVATE mapping is established are visible through the MAP_PRIVATE mapping.*”
- hodnota `off+len` může překračovat aktuální velikost souboru, za konec souboru ale nelze zapisovat a soubor tak prodloužit - proces by obdržel signál `SIGSEGV` nebo `SIGBUS`. Signál dostanu stejně tak v situaci, kdy do read-only namapovaného segmentu zkusím zapsat (je to logické, přiřazení nemá návratovou hodnotu kterou byste mohli otestovat).
- mapuje se vždy po celých stránkách, hodnoty `off` (a při `MAP_FIXED` i `addr`) musí být správně zarovnané. Poslední stránka je za koncem souboru doplněna nulami a tento úsek se nikdy nepřepisuje do souboru.
- přístup do namapovaného úseku, ale za poslední existující stránku namapovaného objektu, způsobí signál `SIGBUS` nebo `SIGSEGV`.
- namapování souboru nahradí případné předchozí mapování stránek v rozsahu `addr` až `addr+len`.

- existující rozšíření (nejsou součástí UNIX03):
 - příznak `MAP_ANON` ve FreeBSD a Solarisu – vytvoření anonymního segmentu bez vazby na soubor, deskriptor musí být `-1`. Mapuje se tak anonymní objekt, který jak víme má místo fyzického uložení na swapu (tedy není trvalé). Linux má podobnou funkcionalitu přes `MAP_ANONYMOUS`.
 - v IRIXu lze pomocí `MAP_AUTOGROW` automaticky zvětšit namapovaný objekt při přístupu za jeho stávající konec.

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()`.

- uložení změn do souboru na disk je zaručené až po provedení `msync()` nebo `munmap()`, ale ostatní procesy, které mají soubor namapován, vidí změny hned.
- mapování paměti a nastavování přístupových práv používá např. knihovna Electric Fence, která slouží pro ladění chyb při práci s dynamickou pamětí.

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);
    exit(0);
}
```

Tento program otočí pořadí znaků v souboru (zapiše soubor od konce k začátku).

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.

- pomocí těchto funkcí lze implementovat dynamicky nahrávané plug-in moduly načítané aplikací podle potřeby (např. podle obsahu jejího konfiguračního souboru).
- dynamickým načítáním knihoven se také dá vyřešit situace, kdy potřebujeme využít několik knihoven, které definují symbol se stejným jménem. Jedna knihovna se přímo přilinkuje k programu, k ostatním se přistupuje pomocí `dlopen()`.
- soubor musí být ve správném formátu (sdílená knihovna `.so` ve formátu `ELF`), například u `gcc` to znamená použít přepínač `-shared`.
- konstanty pro *mode*:
 - `RTLD_NOW` ... všechny relokace (vyřešení všech odkazů) jsou provedeny okamžitě po natažení knihovny, aplikace má jistotu, že jsou všechny symboly přístupné
 - `RTLD_LAZY` ... relokace mohou být odloženy až do chvíle použití symbolu
 - `RTLD_GLOBAL` ... symboly z knihovny mohou být použity při zpracování relokací v ostatních knihovnách a jsou dostupné pomocí `dlopen(0, RTLD_GLOBAL)`
- speciální handle `RTLD_NEXT` hledá symbol pouze v knihovnách nahraných po knihovně, ve které je volání `dlsym()`. Hodí se pro předefinování existujících funkcí, pokud v redefinované funkci potřebujeme volat původní. Knihovna s novou funkcí se nahrává jako první (např. pomocí proměnné `LD_PRELOAD`), adresu původní funkce získá voláním `dlsym(RTLD_NEXT, fn_name)`.

- všechny tyto funkce jsou součástí dynamického linkeru, který má každá dynamicky slinkovaná aplikace namapovaný ve svém adresovém prostoru. Viz také strany 31 a 113.

Příklad: zpřístupnění knihovny

```
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()) {
    fprintf(stderr, "%s\n", err); exit(1);
}
y = fun(x);
dlclose(handle);
```

- zde se volá funkce `sin()` z matematické knihovny `libm.so`.
- funkce `dlsym()` vrátí adresu symbolu daného jména, ale vždy jako ukazatel na `void`, neprobíhá žádná typová kontrola ani není k dispozici žádná informace o typu symbolu. Ten, kdo tuto adresu používá, musí zajistit její správné přetypování.
- při použití knihoven v C++ je třeba si uvědomit, že C++ používá *name mangling*, tj. do jména funkce (metody) je zakódováno případné jméno třídy nebo namespace a typy parametrů.

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 mechanismy 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 mechanismus pro komunikaci mezi procesy – nesou pouze informaci o tom, že nastala nějaká událost.
- zpracovávají se asynchronně – příchod signálu přerušuje běh procesu a vyvolá handler.

- se signálem není svázána žádná jiná informace než číslo signálu.
- po návratu z handleru (pokud k němu dojde) proces pokračuje od místa přerušení.
- historicky signály vznikly jako mechanismus pro „násilné“ ukončení procesu. Z toho vyplynul i název funkce `kill()` pro poslání 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.

- proces s EUID `== 0` může poslat signál libovolnému procesu.
- ostatní procesy:
 - Linux, Solaris: RUID nebo EUID procesu, který poslal signál, se musí shodovat s reálným UID nebo saved set-user-ID cílového procesu.
 - FreeBSD: musí se shodovat EUID obou procesů.
 - IRIX: RUID nebo EUID procesu, který poslal signál, se musí shodovat s reálným nebo efektivním UID nebo saved set-user-ID cílového procesu.

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).

- vytvoření core dumpu znamená uložení kompletního obsahu paměti procesu do souboru, typicky se jménem **core**
- většina signálů implicitně ukončí proces, některé navíc vytvoří již zmiňovaný core dump, který je možné následně použít pro ladicí účely.

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)

- generování těchto signálů vychází z chyb programu
- pro signály BUS, FPE, ILL a SEGV není normou přesně definována příčina, ale obvykle jsou to chyby detekované hardwarem
- pro tyto čtyři signály také platí tato speciální pravidla (podrobnosti viz kapitola 2.4 *Signal Concepts* v normě UNIX03):
 - pokud byly nastavené jako ignorované voláním `sigaction`, je chování programu po té, co je mu takový signál poslán, normou nedefinováno
 - návratová hodnota handleru je nedefinována
 - následek situace, kdy jeden z těchto signálů je maskován v okamžiku jeho vygenerování je nedefinovaný
- jinými slovy – pokud je hardwarem detekovaná chyba reálná (signál není poslán přes kill), váš program se přes tuto chybu nemusí vůbec dostat. Není bezpečné chybu ignorovat, pokračovat v běhu po návratu z handleru nebo oddálit řešení pomocí zamaskování. Pokud máte pro tyto signály handler, **je potřeba pořešit danou situaci jak uznáte za vhodné a pak ukončit program.**
- poznámka: pokud je něco normou nedefinováno (*undefined*), obecně to znamená, že se neočekává, že by programátor potřeboval znát přesné chování v takové situaci. Pokud je to potřeba, pravděpodobně je ve vašem programu něco špatně. Jako vždy, určité by se našly výjimky potvrzující pravidlo.

Přehled signálů (2)

generované uživatelem nebo aplikací:

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

- `SIGINT` a `SIGQUIT` jsou obvykle generovány z terminálu (`Ctrl-C` a `Ctrl-\`) a lze je předefinovat příkazem `stty` nebo pomocí funkce `tcsetattr()`.
- `SIGTERM` je defaultní signál pro příkaz `kill`
- `SIGUSR1` a `SIGUSR2` nejsou použity žádným systémovým voláním a jsou plně k dispozici uživateli
- `SIGALRM` a související funkce `alarm()` se používají pro odměřování časových intervalů v uživatelském procesu (např. při implementaci `timeoutů`).
- signál `SIGHUP` se často používá jako způsob, jak oznámit běžícímu démonu, že se změnil jeho konfigurační soubor a má si ho proto znovu načíst.
- zajímavost: FreeBSD 5.3 obsahuje chybu, která dovolí za jistých okolností zachytit signál `SIGKILL`.

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)
- platí, že nikdy není povoleno více procesům najednou číst z kontrolního terminálu, ale více procesů najednou může na terminál zapisovat.

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)

- když je `act == NULL`, pouze se zjistí nastavení obsluhy, nemění se. Jestliže nás předchozí nastavení nezajímá, lze použít `oact == NULL`.
- pokud není nastaveno `SA_RESTART`, systémová volání aktivní v bodě příchodu signálu skončí s chybou `EINTR`. Restartování nemusí fungovat pro všechna systémová volání, např. na FreeBSD je `select()` přerušeno signálem vždy, i když je nastaveno `SA_RESTART` (pozn: nemusí být pravda u současných verzí, nezkoušel jsem to na nich).
- pozor na problém vzájemného vyloučení mezi procesem a handlerem, popř. mezi handlersy pro různé signály. Jestliže je nastaveno `SA_NODEFER`, měl by být handler reentrantní.
- v signálovém handleru by se měly používat pouze funkce, které jsou pro takové použití bezpečné. Musí buď být reentrantní, nebo je nutné zajistit, aby nepřišel signál v nevhodnou dobu (např. uvnitř funkce přijde signál, v jehož handleru se volá stejná funkce). Bezpečné funkce ze systémové knihovny jsou vyjmenovány v manuálové stránce k funkci `sigaction()` (v SUSv3 jsou v kapitole *System Interfaces: General Information, Signal Concepts*).
- funkce `sigaction()` je obecnější než starší funkce `signal()` a `sigset()`.
- pro výskok z handleru signálu jinam než na místo vzniku signálu se dají použít funkce `sigsetjmp()` a `siglongjmp()`. Pozor na to, že v tomto případě si musíme být jisti, že v okamžiku příchodu signálu není program uvnitř nereentrantní funkce. Výskokem z handleru do hlavního programu není vykonávání takové funkce ukončeno a mohou nastat stejné problémy jako při volání nereentrantní funkce přímo z handleru.

Příklad: časově omezený vstup

```
#define BUFSZ 4096

void handler(int sig)
{ fprintf(stderr, " !!! TIMEOUT !!! \n"); }

int main()
{
    char buf[BUFSZ]; 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, BUFSZ);
    if(sz > 0)
        write(1, buf, sz);
    exit(0);
}
```

- lze používat i časovače s jemnějším rozlišením než 1 s. Nastavují a testují se funkcemi `setitimer()` a `getitimer()`. Při vypršení posílají signály procesu, který časovače nastavil:
 - `ITIMER_REAL` ... měří reálný čas, posílá `SIGALRM`
 - `ITIMER_VIRTUAL` ... měří virtuální čas (pouze čas, kdy proces běží), posílá `SIGVTALRM`
 - `ITIMER_PROF` ... měří virtuální čas a čas, kdy systém běží na konto procesu, posílá `SIGPROF`
- pozn: v příkladu je drobný problém: funkce `fprintf()` není bezpečná pro použití v handleru signálu.

Blokování signálů

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

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

- nastaví masku blokováných 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.

- je rozdíl mezi ignorováním a blokováním signálu. Ignorovaný signál jádro zahodí a proces ho nedostane, blokový signál proces dostane po jeho odblokování.
- závisí na implementaci, zda při vícenásobném doručení stejného signálu procesu, který má tento signál zablokovaný, bude signál po odblokování ošetřen jednou nebo vícekrát.

Příklad: blokování signálů

```
sigset_t sigs, osigs; structure 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);
        ...
}
```

- blokování je vhodné použít tam, kde ošetření přerušení uprostřed posloupnosti operací by bylo příliš složité, nebo kde korektní ošetření není jinak možné.
- př.: proces vytváří potomky pomocí `fork()` a je potřeba, aby potomci měli jiný handler signálů než rodičovský proces.
- v uvedeném příkladě by bez blokování signálů mohl synovský proces dostat signál dříve, než stihne změnit handler.
- další příklad je proces, který při vypršení timeoutu přeruší prováděnou posloupnost operací voláním `siglongjmp()` zevnitř handleru signálu. Je potřeba zablokovat signál `SIGALRM` během provádění atomických podposloupností (tj. takových, které se musí provést buď celé, nebo vůbec ne).

Čekání na signál

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

- pozastaví volající proces do příchodu signálu. Volání se vrátí po návratu z handleru.

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

- jako `pause()`, ale navíc po dobu čekání masku blokových 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`.
- nevolá se handler signálu (to ale není v normě jednoznačně definováno).

- pomocí těchto funkcí a blokování signálů se implementuje synchronní obsluha signálů. Proces nejprve zablokuje signály, které ho zajímají, a pak na ně ve vhodných chvílích buď čeká, nebo jen testuje (pomocí `sigpending()`), zda signál přišel, a pokud ne, pokračuje dál.

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.

- ani operace, kterou lze v C zapsat jedním příkazem, nemusí být atomická. Příklad: na RISCových procesorech se příkaz `a++` typicky přeloží jako sekvence:

```
load reg, [a]
inc reg
store [a], reg
```

a to z toho důvodu, že na této architektuře nelze inkrementovat číslo přímo v paměti. Pro tyto případy má například Solaris sadu funkcí `atomic_add(3c)`, jejichž použití je mnohem rychlejší než klasické zamykací mechanismy. Více viz strana 201.

- obecně obdobný problém nastává, když více procesů sdílí nějaký systémový zdroj.

### 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 |

- další možnost:
  1. struktura je v konzistentním stavu, např. (1, 1)
  2. proces B zapíše 2 do položky a
  3. proces A přečte hodnotu struktury (2, 1) dříve, než proces B stihne zapsat položku b

## 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)

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

| a | b |
|---|---|
| ? | ? |
| 1 | ? |
| 1 | ? |
| 1 | 1 |
| 2 | 1 |
| 2 | 2 |

- je třeba zajistit vzájemné vyloučení i při čtení, aby čtoucí proces nepřčetl nekonzistentní obsah struktury uprostřed změn. Při zápisu je nutné vyloučit všechny ostatní procesy, ale při čtení stačí vyloučit jen zápis, současné čtení více procesy nevadí.
- *kritická sekce* – kus kódu, který by měl provádět pouze jeden proces (vlákno), jinak může dojít k nekonzistencím (špatně pospojovaný vázaný seznam, neodpovídající si indexy v databázi, ...). Kritická sekce by měla být co nejkratší, aby ostatní procesy (vlákna) žádající o vstup do této sekce čekaly co nejkratší možnou dobu.

## 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.

na lokálním disku lze pro synchronizaci zapisovatelů použít řešení pomocí příznaku `O_APPEND`, které ale nemusí fungovat např. na vzdáleném disku přístupném přes NFS nebo v případě, že zápis jedné logovací zprávy je proveden více než jedním voláním `write()`. Navíc to neřeší synchronizaci čtenářů – lze číst i v průběhu zápisu.

## 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.

dva způsoby čekání:

**aktivní (busy waiting)** – proces v cyklu testuje podmínku, na kterou čeká, dokud není splněna

**pasivní** – proces se zaregistruje v jádru jako čekající na podmínku a pak se uspí, jádro ho probudí, když dojde ke splnění podmínky

## Synchronizační mechanismy

- teoretické řešení – algoritmy vzájemného vyloučení (Dekker 1965, Peterson 1981)
- zákaz přerušení (na 1 CPU stroji), speciální instrukce (*test-and-set*)
- **lock-soubory**
- nástroje poskytované operačním systémem
  - **semaforey** (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 splnění podmínky), **read-write zámky** (sdílené a exkluzivní zámky, podobně jako pro soubory)

- obě řešení potřebovala k dosažení požadovaného výsledku **pouze sdílenou paměť**, tj. několik proměnných sdílených oběma procesy
- Dekkerovo řešení se udává jako první řešení problému vzájemného vyloučení dvou procesů, aniž by bylo nutné aplikovat naivní algoritmus striktního střídání, tj. pokud druhý proces nevykazoval zájem o vstup do kritické sekce, mohl tam první (a naopak) proces vstoupit tolikrát za sebou, kolikrát chtěl. Dekkerovo řešení není vůbec triviální, porovnejte s o 16 let mladším řešením Petersonovým, například na [en.wikipedia.org](http://en.wikipedia.org) (hledejte “Dekker’s algorithm”, “Peterson’s algorithm”)
- my se nebudeme zabývat teoretickými algoritmy vzájemného vyloučení ani nebudeme popisovat hardwarové mechanismy používané jádrem. Zaměříme se pouze na použití lock souborů (které využívají atomičnosti některých souborových operací) a speciálních synchronizačních nástrojů poskytovaných jádrem.
- podmínkové proměnné = *conditional variables*

## 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)
 ; /* Čekáme ve smyčce na odemčení */
 close(fd);
}

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

- klíčem k úspěchu je samozřejmě použití flagu `O_EXCL`
- při havárii procesu nedojde ke zrušení případných zámeků a ostatní procesy by čekaly věčně. Proto je vhodné si do lock-souboru poznamenat PID procesu, který zámek vytvořil. Proces, který čeká na odemčení, může testovat, zda proces, kterému zámek patří, stále běží. Když ne, lze zámek zrušit a znovu zkusit vytvořit. User level příkaz který toto umí a dovoluje používat lock soubory z shellových skriptů je například **shlock**(1) (na FreeBSD v `/usr/ports/sysutils/shlock`), teoreticky by však mohl způsobit situaci z následujícího odstavce.
- *POZOR*: jestliže více procesů najednou zjistí, že proces držící zámek už neexistuje, může dojít k následující chybě: Jeden proces smaže zámek a znovu ho vytvoří se svým PID. Další proces udělá totéž, protože operace přečtení obsahu souboru a jeho následného smazání není atomická. Teď si ale oba procesy myslí, že získaly zámek!
- *problém*: funkce `lock()` obsahuje aktivní čekání na uvolnění zámku. Lze řešit např. tak, že proces, který získá zámek, otevře pro zápis pojmenovanou rouru. Čekající procesy se uspí tím, že zkusí číst z roury. Součástí `unlock()` bude i zavření roury a tím uvolnění čekajících procesů.

## Zamykání souborů: `fcntl()`

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

- k nastavení zámků pro soubor `fil`des 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 zámeček popsaný třetím argumentem, pokud nelze zámeček nastavit, ihned vrátí `-1`
  - `F_SETLKW` ... jako `F_SETLK`, ale uspí proces, dokud není možné nastavit zámeček
- třetí argument obsahuje popis zámku a je typu `struct flock *`

- zamykání souborů sdílených přes NFS zajišťuje démon `lockd`.
- zámečky jsou obecně dvou typů:
  - advisory locks** – pro správnou funkci musí všechny procesy pracující se zámčenými soubory kontrolovat zámečky před čtením nebo zápisem souboru; jsou více používané
  - mandatory locks** – jestliže je na souboru zámeček, budou čtecí a zápisové operace se souborem automaticky zablokovány, tj. zámeček se uplatní i v procesech, které ho explicitně nekontrolují
    - nedoporučují se, ne vždy fungují (např. `lockd` implementuje pouze advisory locking)
    - pro určitý soubor se zapne nastavením bitu `SGID` a zrušením práva spuštění pro skupinu (tj. nastavení, které jinak nemá smysl - mít set UID executable bit na souboru, který není spustitelný). Systém, který mandatory locking implementuje, je například Solaris nebo Linux, FreeBSD tuto vlastnost naopak nepodporuje.



## Zamykání souborů: struct flock

- `l_type` ... typ zámku
  - `F_RDLCK` ... sdílený zámeček (pro čtení), více procesů
  - `F_WRLCK` ... exkluzivní zámeček (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, 0 znamená do konce souboru
- `l_pid` ... PID procesu držícího zámeček, používá se jen pro `F_GETLK` při návratu

- soubory se dají zamykat po částech a dá se zjistit, který proces drží zámeček. Při ukončení procesu se automaticky uvolní všechny jeho zámky.
- pokud při použití `F_GETLK` není příslušná část souboru zamčená, je struktura `flock` vrácena bez změny kromě první položky, která je nastavena na `F_UNLCK`.
- zamykání přes `fcntl` i `lockf` má jednu důležitou vlastnost, kterou výstižně popisuje například manuálová stránka pro `fcntl` v systému FreeBSD:

This interface follows the completely stupid semantics of System V and IEEE Std 1003.1-1988 ("POSIX.1") that require that all locks associated with a file for a given process are removed when any file descriptor for that file is closed by that process. This semantic means that applications must be aware of any files that a subroutine library may access. For example if an application for updating the password file locks the password file database while making the update, and then calls `getpwnam(3)` to retrieve a record, the lock will be lost because `getpwnam(3)` opens, reads, and closes the password database.

## Deadlock

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

| p1                                                                                        | p2                                                                                        |
|-------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------|
| <code>lock(lck1); /* OK */</code>                                                         | <code>lock(lck2); /* OK */</code>                                                         |
| <code>lock(lck2); /* Čeká na p2 */</code>                                                 | <code>lock(lck1); /* Čeká na p1 */</code>                                                 |
| Deadlock                                                                                  |                                                                                           |
| <code>use(res1, res2);</code><br><code>unlock(lck2);</code><br><code>unlock(lck1);</code> | <code>use(res1, res2);</code><br><code>unlock(lck2);</code><br><code>unlock(lck1);</code> |

- pozor na pořadí zamykání!

- obecně deadlock vznikne, jestliže proces čeká na událost, která nemůže nastat. Zde např. na sebe dva procesy čekají navzájem, až ten druhý uvolní zámek, ale k tomu nikdy nedojde. Další možností je deadlock jednoho procesu, který čte z roury a předtím zapomněl uzavřít zápisový konec roury. Jestliže rouru nemá už nikdo další otevřenou, pokus o čtení ze zablokuje, protože nejsou zavřeny všechny kopie zápisového deskriptoru a tedy nenastane konec souboru na rouře, ale čtoucí proces svůj zápisový deskriptor nemůže zavřít, protože čeká.
- `fcntl()` provádí kontrolu a při výskytu deadlocku vrátí chybu `EDEADLK`.
- je vhodné se deadlocku snažit vyvarovat správným naprogramováním a nespolehat se na kontrolu systému.

## System V IPC

- **IPC** je zkratka pro **Inter-Process Communication**
- komunikace mezi procesy v rámci jednoho systému, tj. nezahrnuje síťovou komunikaci
- **semaforey** ... použití pro synchronizaci procesů
- **sdílená paměť** ... předávání dat mezi procesy, přináší podobné problémy jako sdílení souborů, k řešení lze použít semaforey
- **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.

- prostředky IPC existují i poté, kdy skončí proces, který je vytvořil. O jejich zrušení je nutno explicitně požádat (ze shellu lze zjistit seznam IPC prostředků příkazem `ipcs` a smazat je příkazem `ipcrm`). Stav a obsah existujících prostředků IPC zůstává v platnosti, i když s nimi právě nepracuje žádný proces (např. data ve sdílené paměti zůstávají, i když ji nemá žádný proces připojenou).
- **další dva prostředky System V IPC, které se běžně v unixových systémech vyskytují a jsou součástí normy, tj. sdílená paměť a zasílání zpráv, nebudeme probírat. Pro sdílenou paměť je možné použít již probrané volání `mmap`, místo zasílání zpráv je možné použít sockety (budou v některé z příštích přednášek).**

## Semaforey

- 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

- **P** je z holandského „proberen te verlagen” – zkus dekrementovat, **V** pak ze slova „verhogen” – inkrementovat.
- operace **P(s)** a **V(s)** lze zobecnit: hodnotu semaforu je možné měnit o libovolnou hodnotu  $n \dots$  **P(s, n)**, **V(s, n)**.
- Allen B. Downey: *The Little Book of Semaphores*, Second Edition, on-line na <http://greenteapress.com/semaphores/>
- *binární semafor* má pouze hodnotu 0 nebo 1

## 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);
...
```

inicializace semaforu na hodnotu  $n$  dovolí vstoupit do kritické sekce  $n$  procesům. Zde semafor funguje jako zámek, vždy ho odemyká (zvyšuje hodnotu) stejný proces, který ho zamknul (snížil hodnotu).

## API pro semaforey

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

- vrátí identifikátor pole obsahujícího `nsems` semaforů asociovaný s klíčem `key` (klíč `IPC_PRIVATE` ... privátní semaforey, 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.

- největší zajímavost na System V implementaci semaforů je skutečnost, že daný syscall neoperuje nad jedním semaforem, ale nad polem semaforů, atomicky. Většinou však budete potřebovat pouze jeden semafor, tj. pole o jednom prvku.
- další důležitá informace je, že System V semaforey jsou bohužel značně složité
- přístupová práva jsou jen pro čtení a zápis.
- podobné schéma API funkcí (funkce na vytvoření, řízení a operace) dodržují i ostatní System V IPC mechanismy.
- jakmile je jednou pole semaforů jedním procesem vytvořeno, mohou i ostatní procesy použít `semctl()` a `semop()`, aniž by předtím volaly `semget()`. To platí i pro semaforey vytvořené s klíčem `IPC_PRIVATE`, pro které nelze volat `semget()`, protože by se tím vytvořilo nové pole semaforů.

## API pro semafore: `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 semaforey 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

volání `semctl(semid, semnum, SETVAL, arg)` odpovídá obecné semaforové inicializační operaci `init(s, n)`.

## API pro semaforey: semop()

- operace se provádí atomicky (tj. buď se povede pro všechny semaforey, 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

- atomičnost zajistí, že nedojde k deadlocku v následující situaci: dva procesy *A* a *B* budou používat dva semaforey k řízení přístupu (zamykání) ke dvěma systémovým zdrojům. Proces *A* je bude zamykat v pořadí (0,1) a proces *B* v pořadí (1,0). Ve chvíli, kdy proces *A* zamkne semafor 0 a *B* zamkne 1, dojde k deadlocku, protože ani jeden proces nemůže pokračovat (potřeboval by zamknout druhý semafor). Při použití atomické operace zamčení obou semaforů najednou bude úspěšný vždy právě jeden proces, který získá oba semaforey, druhý bude čekat.
- `SEM_UNDO` zajistí, že při ukončení procesu dojde k odemčení semaforů (použitých jako zámky), které tento proces měl zamčené.



## 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.

Poznámky k `ftok()`:

- Z `id` se použije jen nejnižších 8 bitů.
- Není specifikováno, zda bude stejný klíč vrácen i po smazání a znovuvytvoření souboru.
- Různé klíče pro různé soubory nejsou vždy zaručené. Např. na Linuxu se klíč získá kombinací 16 bitů čísla `i-uzlu`, 8 bitů `id` a 8 bitů vedlejšího čísla zařízení. Stejný klíč pro různé soubory je vrácen, pokud se čísla `i-uzlů` shodují na spodních 16 bitech.

## Další prostředky IPC

- POSIX a UNIX98 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 semaforey** ... 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).

- POSIXové IPC používá pro pojmenování jednotlivých IPC objektů řetězce místo numerických identifikátorů, proto do značné míry odpadají problémy s identifikací známé ze System V IPC (kde se řeší např. funkcí ftok()).
- sokety se z BSD rozšířily i do ostatních UNIXových systémů a dostaly se i do normy UNIX 98.

## 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

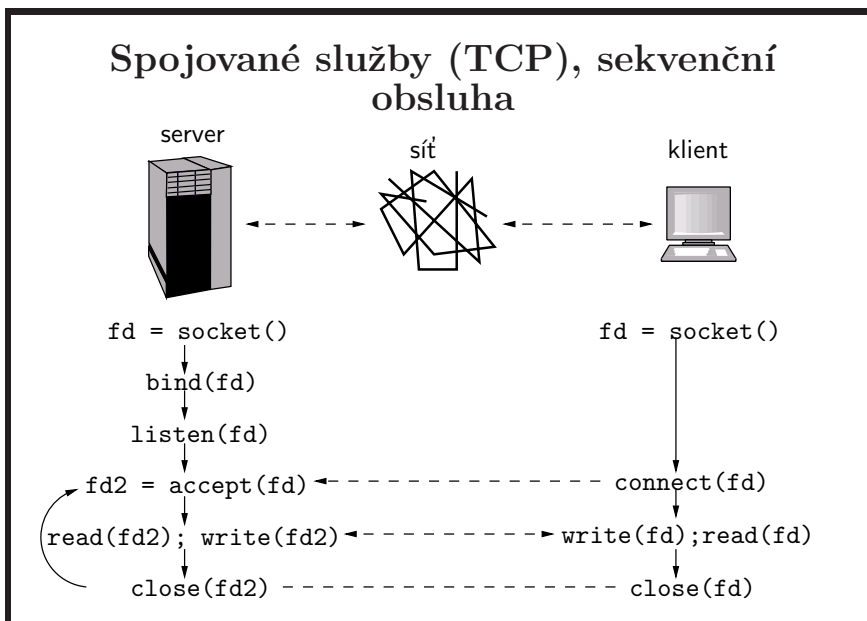
**RPC (Remote Procedure Call)** – SunOS (1984); protokol pro přístup ke službám na vzdáleném stroji, data přenášena ve tvaru XDR (External Data Representation)

- ISO (International Standards Organization) OSI (Open Systems Interconnect) – vrstvy (layers):
  1. fyzická (physical)
  2. linková (data link)
  3. síťová (network)
  4. transportní (transport)
  5. relační (session)
  6. prezentační (presentation)
  7. aplikační (application)
- UUCP je tvořeno aplikačními programy, nevyžaduje žádnou podporu v jádru. Implementace soketů a TLI jsou součástí jádra. TLI je ve verzi SVR4 implementováno s využitím mechanismu STREAMS. RPC existuje jako knihovna linkovaná k aplikacím, která využívá sokety (funguje nad protokoly TCP a UDP). RPC bylo vyvinuto jako komunikační protokol pro NFS (Networked File System).
- existuje více (vzájemně nekompatibilních) implementací RPC
- komunikační kanál je specifikován adresami dvou soketů.
- sokety pro komunikaci pouze v rámci jednoho počítače jsou v doméně AF\_UNIX a jejich jména jsou jména speciálních souborů, které reprezentují sokety v systému souborů.
- sokety AF\_UNIX jsou něco jiného než lokální TCP/IP komunikace přes loopback rozhraní localhost (127.0.0.1).

## TCP/IP

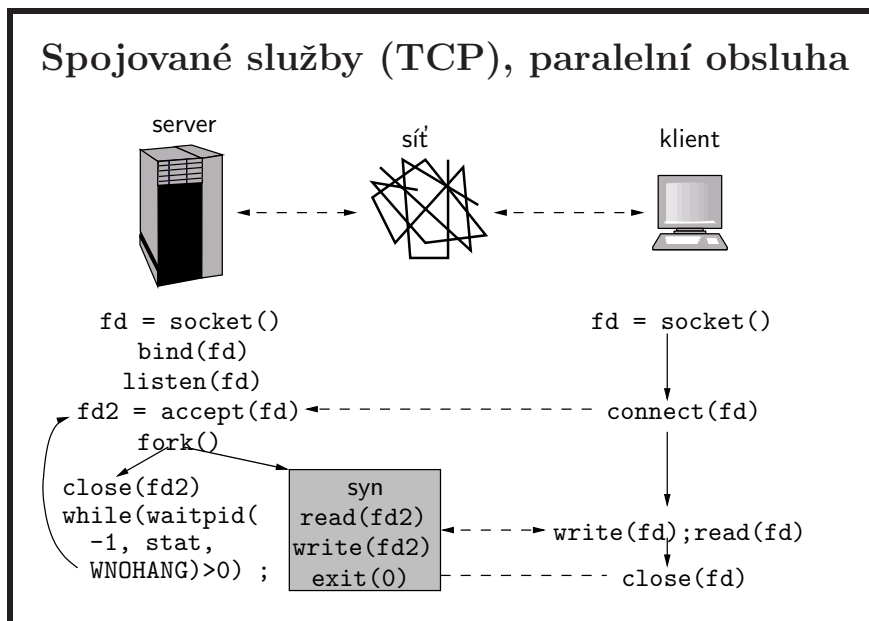
- protokoly
  - **IP (Internet Protocol)** – přístupný jen pro uživatele root
  - **TCP (Transmission Control Protocol)** – streamový, spojovaný, spolehlivý
  - **UDP (User Datagram Protocol)** – datagramový, nespojovaný, nespolehlivý
- **IP adresa** – 4 bajty, definuje síťové rozhraní, nikoliv počítač
- **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

- UNIX používá pro síťovou komunikaci nejčastěji rodinu protokolů TCP/IP. Pro účely programování aplikací nás budou zajímat především protokoly TCP (spojovaná spolehlivá komunikace) a UDP (nespojovaná nespolehlivá komunikace). V obou protokolech je jeden konec komunikačního kanálu (odpovídá soketu v doméně AF\_INET) identifikován IP adresou síťového rozhraní a číslem portu (pomocí portů se rozlišují síťové služby běžící na jednom počítači).
- *IP* – protokol 3. vrstvy, zajišťuje přenos paketů (datagramů) mezi rozhraními identifikovanými IP adresou; je nespolehlivý (nezaručuje doručení dat). RFC 791. Nedílnou součástí IP je Internet Control Message Protocol (ICMP), RFC 792.
- *UDP* – jednoduchá nadstavba nad IP, přidává čísla portů, zůstává nespolehlivý a datagramově orientovaný
- *TCP* – vytváří obousměrné spojení mezi dvěma body (IP+port), poskytuje tok dat (stream) bez rozdělení na zprávy, zajišťuje řízení toku dat a spolehlivé doručování
- *DNS* – hierarchicky organizovaná databáze, její struktura nemusí mít nic společného se strukturou IP adres



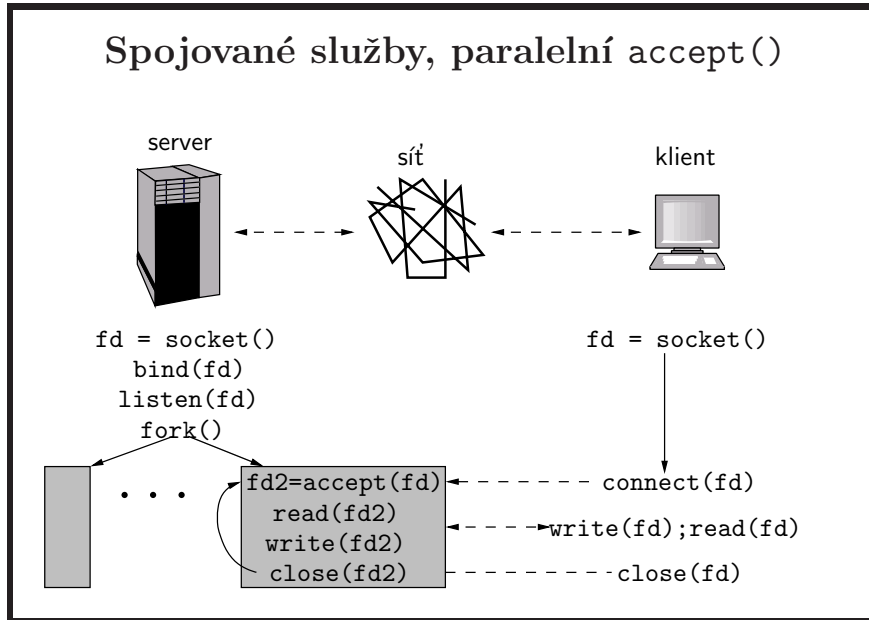
- server vytvoří jedno spojení, teprve po jeho ukončení akceptuje dalšího klienta.
- systémová volání:
  - `socket()` – vytvoří soket, vrátí jeho deskriptor

- `bind()` – definuje adresu soketu (IP adresu a číslo portu), musí to být buď adresa jednoho ze síťových rozhraní počítače, na kterém je vytvořen soket (pak bude soket přijímat žádosti klientů pouze přes toto rozhraní), nebo je to speciální hodnota „libovolná adresa“ (pak soket přijímá požadavky prostřednictvím všech síťových rozhraní)
  - `listen()` – oznámí jádru, že soket bude přijímat požadavky klientů
  - `accept()` – uspí proces, dokud nebude k dispozici nějaká žádost klienta o spojení, vytvoří spojení a vrátí nový deskriptor, přes který bude probíhat další komunikace s klientem, původní deskriptor lze použít k novému volání `accept()` pro obsluhu dalšího klienta
  - `close()` – ukončí komunikaci
  - `connect()` – žádost klienta o navázání spojení, IP adresa a číslo portu serveru se zadávají jako parametry, komunikace probíhá přes deskriptor `fd` (na rozdíl od `accept()` nevytváří nový deskriptor)
- klient nemusí volat `bind()`, v takovém případě mu jádro přidělí některý volný port. Existují služby (např. `rsh`), které vyžadují, aby se klient spojoval z privilegovaného portu. Takový klient pak musí provést `bind()` (a navíc běžet s rootovskými právy alespoň do okamžiku provedení `bind()`).

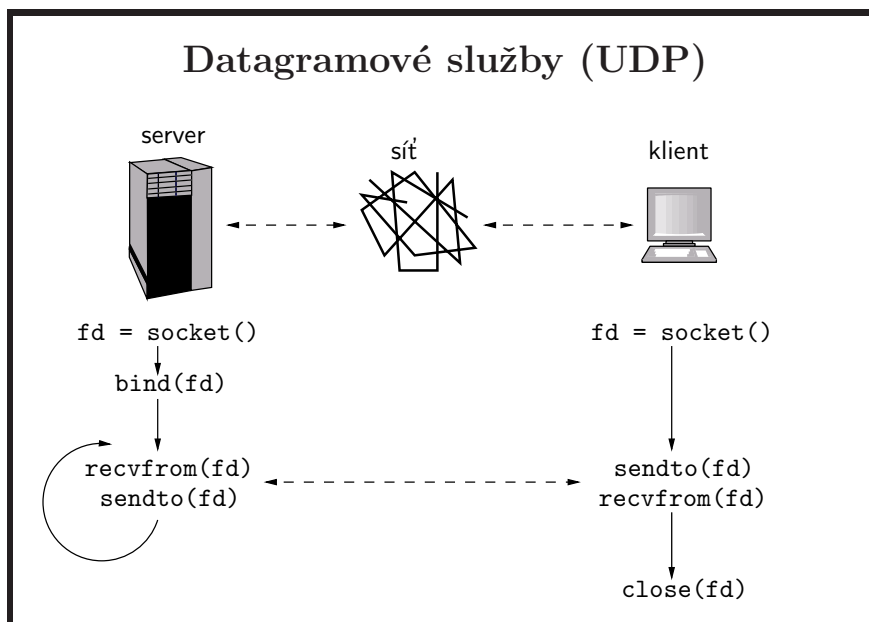


- server akceptuje spojení od klienta a na vlastní komunikaci vytvoří nový proces, který po uzavření spojení s klientem skončí. Rodičovský proces může mezitím akceptovat další klienty a spouštět pro ně obslužné procesy. Současně je tedy obsluhováno více klientů.
- po provedení `fork()`, ale před zahájením obsluhy spojení, může synovský proces provést `exec` – takto funguje např. `inetd`.

- volání `waitpid()` v cyklu odstraňuje ze systému zombie. Jinou možností je využití signálu `SIGCHLD`, jehož explicitní ignorování zabrání vzniku živých mrtvých, popř. lze instalovat handler, v němž se volá `wait()`.



- po `bind()` a `listen()` se vytvoří několik synovských procesů a každý v cyklu volá `accept()` a obsluhuje klienty. Jádro vybere (nedeterministicky) pro každý požadavek jeden proces, v němž `accept()` naváže spojení.
- jednotlivé procesy serveru mezi sebou mohou komunikovat, aby v případě, že současných požadavků je více než serverových procesů, se tato skutečnost zjistila a hlavní server mohl dynamicky vytvořit další serverový proces.
- takto funguje např. webový server Apache.
- všechny tři uvedené způsoby činnosti serveru fungují se stejným klientem – činnost klienta nezávisí na variantě serveru.



- z pohledu volaných síťových funkcí je funkce serveru a klienta shodná. Klient je zde ten, kdo pošle první datagram.
- stejně jako v případě TCP, klient nemusí dělat `bind()`, jestliže mu nezáleží na tom, jaké číslo portu bude používat. Server zjistí jeho port z obsahu adresní části prvního datagramu.
- výhodou nespojované služby je menší režie a to, že přes jeden soket lze komunikovat s více procesy (při spojované komunikaci je spojení vždy navázáno s jedním procesem).
- pro UDP je možné volat `connect()`. Tím se nenaváže spojení, ale soket se nastaví tak, že může nadále komunikovat pouze s adresou a portem specifikovanými ve volání `connect()`. Místo `sendto()` a `recvfrom()` se pak používají funkce `send()` a `recv()`.



## Vytvoření socketu: `socket()`

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

- vytvoří socket a vrátí jeho deskriptor.
- `domain`:
  - `AF_UNIX` ... lokální komunikace, adresa je jméno souboru
  - `AF_INET` ... 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)

- sockety jsou přístupné přes deskriptory souborů. Po navázání spojení je (spojovaná) komunikace přes socket podobná komunikaci pomocí roury.
- v některých implementacích se rozlišují konstanty začínající `PF_` (protocol family, např. `PF_INET`, `PF_UNIX`) používané v `socket()` a konstanty `AF_` (address family, např. `AF_INET`, `AF_UNIX`) používané při zadávání adres socketů. Hodnoty odpovídajících konstant `AF_` a `PF_` jsou typicky stejné.
- existují další typy socketů pro přístup k IP, ICMP, nebo k informacím z routovací tabulky.

## Pojmenování socketu: bind()

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

- přiřadí socketu zadanému deskriptorem `socket` adresu `address` o velikosti `address_len` bajtů.
- `struct sockaddr`:
  - `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

- volání `bind()` přiřazuje socketu *lokální adresu*, tj. zdrojovou adresu odesílaných dat a cílovou adresu přijímaných dat. Vzdálená adresa (adresa druhého konce komunikačního kanálu) se nastavuje pomocí `connect()`.
- jeden socket lze spojit se všemi lokálními adresami nastavením `sin_addr` na `INADDR_ANY`.
- nelze spojit více socketů s jednou dvojicí (adresa, port).
- volání `bind()` lze vynechat, jádro pak socketu (v případě TCP, UDP) přiřadí adresu `INADDR_ANY` a některý volný port. Obvykle `bind()` volá pouze server, protože klienti očekávají, že bude poslouchat na pevném portu. Naopak klient pevný port nepotřebuje, server se port klienta dozví při navázání spojení nebo z prvního přijatého datagramu.
- **adresa i port musí být do struktury uloženy v síťovém pořadí bajtů.** Pořadí bajtů bylo vysvětleno na straně 15, další informace pak budou na straně 171.
- v doméně `AF_UNIX` se používá adresová struktura `struct sockaddr_un`:
  - `sa_family_t sun_family` ... doména
  - `char sun_path []` ... jméno socketu
  - délka jména není ve standardu definována, závisí na implementaci. Obvyklé hodnoty jsou mezi 92 a 108.

## Čekání na spojení: `listen()`

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

- označí soket zadaný deskriptorem `socket` jako akceptující spojení.
- maximálně `backlog` žádostí o spojení může najednou čekat ve frontě na obsluhu (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()`. Pro doménu `AF_INET` stačí zadat číslo portu a IP adresu `INADDR_ANY`, která znamená libovolnou adresu.

- hodnota `INADDR_ANY` se používá nejčastěji. Konkrétní IP adresa serveru se zadává tehdy, jestliže je potřeba rozlišit, přes které síťové rozhraní přišel požadavek na spojení (pro každé rozhraní máme jeden soket). Tuto možnost využívají web servery, které podle IP adresy rozlišují virtuální servery. Obvykle se na takovém serveru jednomu fyzickému rozhraní přiřazuje několik IP adres (IP aliasing). Novější rozlišení virtuálních serverů podle HTTP hlavičky „Host:” už nepotřebuje IP aliasy.

## 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, který žádal o spojení pomocí `connect()`. Vrátí deskriptor (nový soket), který lze používat pro komunikaci se vzdáleným procesem. Původní deskriptor `socket` umožňuje přijímat další spojení pomocí `accept()`.
- v `address` vrátí adresu vzdáleného soketu.
- `address_len` je velikost struktury pro uložení adresy, po návratu obsahuje skutečnou délku adresy.
- podobně jako `bind()` i `accept()` používá pro adresy v doméně `AF_INET` strukturu `sockaddr_in`.

- vytvoření druhého deskriptoru pro komunikaci umožňuje na tom původním ihned znovu volat `accept()`.
- jestliže se více klientů ze stejného počítače najednou připojí k jednomu serveru (tj. na jednu serverovou IP adresu a jeden port), jsou jednotlivá spojení rozlišena jen číslem portu na klientské straně.
- `address` může být zadána jako `NULL`, čímž oznamujeme, že nás konkrétní adresa našeho nového soketu nezajímá. V tomto případě by i `address_len` mělo být 0.
- `socket` vrácený z volání `accept()` si můžeme představit tak, že reprezentuje ten konec spojení, na kterém poslouchá a z kterého čte druhá strana.

## Navázání spojení: `connect()`

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

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

- po úspěšném navázání spojení mohou server i klient pro komunikaci používat běžná souborová volání `write()` a `read()`, nebo funkce `send()`, `recv()`, `sendmsg()`, `recvmsg()`. Chování funkcí pro zápis a čtení dat je podobné jako `write()` a `read()` pro roury.
- i pro nespojované služby (UDP) se dá volat `connect()`, tím se nenaváže spojení, ale pouze se omezí adresa protistrany, se kterou může socket komunikovat. V tomto případě mohou `connect()` volat obě strany komunikace.
- pokud je socket nastaven jako neblokující, viz strana 170, `connect()` se nezablokuje čekáním na spojení. Místo toho vrátí `-1` s `errno` nastavené na `EINPROGRESS` (= “nelze vytvořit spojení okamžitě”), a žádost o spojení se uloží do systémové fronty pro následné vyřízení. Do té doby, než je spojení připraveno, volání `connect()` vrací `-1`, nyní ale s chybou `EALREADY`. Není ale takto vhodné testovat připravenost spojení, protože pokud `connect()` skončí s chybou, další volání `connect()` provede nový pokus o spojení a jsme opět tam, kde jsme byli. . . Je možné ale použít `select()` nebo `poll()` pro čekání na zápis (ne čtení) do socketu, viz strany 176, 178. Zda spojení proběhlo úspěšně se pak dozvíte z funkce `getsockopt()` s `opt_name` nastavené na `SO_ERROR`, viz strana 170.

## 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

- používá se hlavně pro sokety typu `SOCK_DGRAM`, protože v této situaci máme pouze socket reprezentující naši stranu spojení; viz poznámka u slajdu k `accept()`. Musíme proto specifikovat adresu protistrany. Pro **datagramovou** službu se navíc data berou jako nedělitelná, tj. buď se akceptují celá, nebo se volání zablokuje – neexistuje částečný zápis. Stejně jako je tomu u souborových deskriptorů, je i zde možné socket nastavit jako neblokující, viz strana 170.
- místo `sendto()` se dá použít obecnější funkce `sendmsg()`.
- pro sokety, na které bylo voláno `connect()`, se místo `sendto()` může použít `send()`.
- úspěšný návrat z libovolné funkce zapisující data do soketu **neznamena úspěšné doručení zprávy protistraně**, ale pouze uložení dat do lokálního bufferu odeslaných dat.
- pokud použijete `sendto()` na streamovanou službu, je to možné, ale adresa se ignoruje. Jediný důvod proč nepoužít přímo `write()` by tak byla možnost použít flagy. V tom případě je ale jednodušší použít `send()`.

## 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. Vrátil 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

- používá se hlavně pro sokety typu `SOCK_DGRAM`. V takové situaci opět čeká na celou zprávu (tj. nevrátí vám půlku datagramu); opět je možné nastavit socket jako neblokující.
- místo `recvfrom()` se dá použít obecnější funkce `recvmsg()`.
- pro sokety, na které bylo voláno `connect()`, se místo funkce `recvfrom()` volá `recv()`.
- `address_len` **musí** být inicializovaná velikostí bufferu.
- po úspěšném návratu z `recvfrom()` je možné `address` a `address_len` beze změny použít pro následné volání `sendto()`.
- stejně jako `sendto()`, je i `recvfrom()` možné použít pro spojovanou službu. Získat adresu protistrany je ale asi jednodušší přes volání `getsockbyname()`, viz strana 170.

## Uzavření socketu: close()

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

- zruší deskriptor, při zrušení posledního deskriptoru socketu zavře socket.
- pro SOCK\_STREAM socket 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`, když se to nepovede, `close()` vrátí chybu, jinak vrátí OK po přenesení dat.
  - `l_onoff == 1 && l_linger == 0` ... provede se reset spojení

- po uzavření může TCP socket zůstat po nějakou dobu v přechodném stavu (který je definován protokolem TCP při ukončování spojení). Než je socket zcela zrušen, nelze použít jiný socket na stejném portu (pokud toto nebylo povoleno nastavením příznaku SO\_REUSEADDR pomocí funkce `setsockopt()`, viz strana 170).
- při použití SO\_REUSEADDR se dá po uzavření poslouchajícího serverového socketu znovu spustit server – volat `socket()`, `bind()`, `listen()` a `accept()` na stejné adrese a portu – i když ještě dobíhají spojení vytvořená předchozí instancí serveru:

```
int opt = 1;
setsockopt(fd, SOL_SOCKET, SO_REUSEADDR, opt, sizeof(opt));
```

- reset spojení je abnormální ukončení spojení. V TCP se použije paket s nastaveným příznakem RST. Na druhé straně se normální ukončení spojení projeví jako konec souboru (při čtení), reset způsobí chybu ECONNRESET.



## 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

- Při normálním ukončení spojení na úrovni protokolu TCP každá strana signalizuje, že už nebude nic zapisovat. To platí i v případě použití `close()` nebo `shutdown(fd, SHUT_RDWR)`. Při použití `shutdown(fd, SHUT_WR)` lze ze soketu dál číst. Druhá strana dostane EOF při čtení, ale může dál zapisovat.

## 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)

- hodnota `level` v `getsockopt()` a `setsockopt()` je obvykle `SOL_SOCKET`. U `getsockopt()`, `option_len` musí být inicializována na velikost `opt_value`.
- funkce `getsockname()` se používá, když nevoláme `bind()` a potřebujeme zjistit, jaká (lokální!) adresa byla jádrem soketu přidělena.
- volání `getsockopt(sock, SOL_SOCKET, SO_ERROR, &val, &len)` vrátí (a vymaže) příznak chyby na soketu. Asi nejužitečnější je při zjišťování, jak dopadl neblokující `connect()`, viz strana 165.
- příklad na `setsockopt()` je na straně 168.

## 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.

- Pokud lokální systém používá stejné pořadí bajtů jako síť, nedělají převodní funkce nic.

## 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.

- v uvedených souborech je definováno mapování mezi jmény a čísly pro standardní protokoly a služby.
- pozor na to, že protokolem zde nemyslíme `www`, `SSH`, `telnet` nebo `FTP` – to jsou zde *služby*, reprezentované čísly portů. Protokol je `TCP`, `UDP`, `OSPF`, `GRE` apod., tedy to, co je přenášeno v IP paketu v položce `Protocol`, viz RFC 791.

## Jména a IP adresy

```
struct hostent *gethostbyname(const char *name);
```

- pro dané jméno vrátí v poli `char **h_addr_list` seznam příslušných síťových adres. Za poslední adresou je ukazatel `NULL`. Délka jedné adresy je v položce `h_length`.

```
struct hostent *gethostbyaddr(const char *addr,
 size_t len, int type);
```

- pro danou adresu `addr` o délce `len` v doméně `type` vrátí jméno v položce `h_name` a případné aliasy v nulou ukončeném poli `h_aliases`.
- při vyhodnocování dotazů na adresy a jména se používá DNS a lokální databáze uložená v souboru `/etc/hosts`.
- vrací `NULL`, když v databázi není hledaný záznam.

- lze stanovit, zda má prioritu DNS nebo lokální databáze adres.
- jméno domény a adresy name serverů jsou v souboru `/etc/resolv.conf`.
- místo zde uvedených funkcí se doporučuje používat obecnější volání `getaddrinfo()`.

## Příklad: TCP server

```
int nclients = 10, fd, newsock, sz;
struct servent *sp; struct protoent *pp;
struct sockaddr_in sa,ca;
sp = getservbyname(argv[1], "tcp");
pp = getprotobyname("tcp");
fd = socket(AF_INET, SOCK_STREAM, pp->p_proto);
sa.sin_family = AF_INET; sa.sin_port=sp->s_port;
sa.sin_addr.s_addr = INADDR_ANY;
bind(fd,(struct sockaddr *)&sa,sizeof(sa));
listen(fd, nclients);
for(;;) {
 sz = sizeof(ca); newsock = accept(fd, &ca, &sz);
 /* Komunikace s klientem */
 close(newsock);
}
```

- Toto je obecná kostra serveru. Jméno služby se zadává jako parametr programu, odpovídající číslo portu hledá funkce `getservbyname()`.

## Příklad: TCP klient

```
char *host; struct servent *se;
struct hostent *ha; struct protoent *pp;
int sockfd; struct sockaddr_in sa;
host = argv[1];
se = getservbyname(argv[2], "tcp");
ha = gethostbyname(host);
pp = getprotobyname("tcp");
sockfd = socket(AF_INET, SOCK_STREAM, pp->p_proto);
sa.sin_family = AF_INET; sa.sin_port = se->s_port;
memcpy(&sa.sin_addr.s_addr, ha->h_addr_list[0],
 ha->h_length);
connect(sockfd, &sa, sizeof(sa));
/* Komunikace se serverem */
close(sockfd);
```

- V příkladu využíváme automatického přidělení volného portu systémem při volání `connect()`, kterému nepředcházela `bind()`.

## Čekání na data: select()

```
int select(int nfd, 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 libovolně dlouho). Parametr `nfd` udává rozsah testovaných deskriptorů (0, ..., `nfd-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

- **motivace:** jestliže chceme číst data z více deskriptorů, jde nastavit příznak `O_NONBLOCK` a neblokujícím `read()` střídavě testovat jednotlivé deskriptory, mezi každým kolem testů pak třeba použít `sleep(1)`. Lepší řešení, tj. bez aktivního čekání a testování, je použít `select()` a následně `read()` na ty deskriptory, které `select()` ohlásí jako *připravené*.
- *připravený* (*ready*) znamená, že `read` nebo `write` s vynulovaným příznakem `O_NONBLOCK` by se nezablokovalo, tedy ne nutně že nějaká data jsou připravena (`read` např. může vrátit 0 pro end-of-file)
- množina `errorfds` je pro výjimky v závislosti na typu deskriptoru; pro socket to je například příchod urgentních dat (flag U u TCP). Neznamená to, že na daném deskriptoru došlo k chybě! Chyba s nastaveným `errno` se zjistí z ostatních množin po návratovém kódu -1 provedeného volání, tj. například `read()`.
- při volání jsou v množinách deskriptory, které chceme testovat, po návratu zůstanou nastavené jen ty deskriptory, na kterých nastala testovaná událost. **Je nutné je tedy před dalším voláním select() znovu nastavit.** Typicky to jsou bitové masky, ale nemusí tomu být tak; z pozice programátora je to samozřejmě jedno.
- funkce `select()` je použitelná i pro čekání na možnost zápisu do roury nebo socketu – čeká se, až druhá strana něco přečte a uvolní se místo v bufferu pro další data.
- místo množiny pro deskriptory je možné uvést NULL, speciální případ při nastavení všech množin na NULL je volání, které se pouze zablokuje do příchodu signálu nebo do vypršení time-outu.



- po návratu je nutné otestovat každý deskriptor zvlášť, není k dispozici volání, které by vám vytvořilo množinu připravených deskriptorů.
- pokud obsluhuje síťový server více portů, může volat `select()` na příslušné deskriptory soketů a následně `accept()` na deskriptory, pro které `select()` ohlásil příchod žádosti klienta (připravenost ke čtení).
- volání `connect()` na neblokujícím soketu se hned vrátí, navázání spojení ohlásí následný `select()` jako připravenost k zápisu.
- další možnost použití `select()` je síťový server, který v jednom procesu obsluhuje paralelně několik klientů. Pomocí `select()` se testuje stav deskriptorů odpovídajících spojení s jednotlivými klienty a přes deskriptory připravené pro čtení/zápis se komunikuje. Aby se mohli připojovat noví klienti, testuje se i deskriptor soketu, který se používá pro `accept()`. Využívá se toho, že `select()` ohlásí deskriptor s čekající žádostí klienta o spojení jako připravený pro čtení. Na takový deskriptor je možné volat `accept()`.
- jako výjimečnou událost (množina `errorfds`) `select()` ohlásí příchod out-of-band dat.
- pozor na to, že `select` může změnit strukturu `timeval`, existuje nové volání `pselect`, které (mimo jiné) strukturu pro timeout nezmění.
- pro `nfds` je možné použít `FD_SETSIZE`, což je systémová konstanta pro maximální počet deskriptorů. Typicky to však nebude příliš efektivní, protože tato konstanta je většinou 1024 na 32-bitových systémech, na Solarisu to však pro 64-bitové architektury je už 65536.
- pokud se čas nastaví na 0 (tj. teď nemluvíme o nastavení ukazatele na NULL), `select` se dá použít pro tzv. *polling* – zjistí současný stav a hned se vrátí.

## 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 libovolně dlouho).
- prvky `fds`:
  - `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)

- tato funkce je obdoba volání `select()`.
- na Solarisu je to systémové volání, `select` pak knihovní funkce implementovaná pomocí `poll`, `poll` je zde preferováno. Je nutné `poll` použít v případě, že chcete testovat deskriptor větší nebo rovno než `FD_SETSIZE`.
- čas nastavený na -1 je to samé jako `NULL` u `select`.

### 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);
 }
}

```

- zde je typické použití `select()`, kdy je třeba číst data současně ze dvou zdrojů.
- před každým voláním `select()` se musí znovu nastavit množiny deskriptorů.
- lepší řešení je nastavit oba deskriptory jako neblokující a používat `select()` i na zápis. Logika řízení je pak taková, že pro každý směr datové komunikace máme samostatný buffer. Příslušný čtecí deskriptor bude v množině pro čtení v `select()`, právě když je buffer prázdný. Naopak zápisový deskriptor bude v množině pro zápis, právě když je buffer neprázdný.

## 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 připojení klienta, naváže spojení, spustí příslušný server a přesměruje mu deskriptory 0, 1 a 2 do socketu, přes který lze komunikovat s klientem.
- 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
talk dgram udp wait root /usr/etc/talkd talkd
tcpmux stream tcp nowait root internal
echo stream tcp nowait root internal
```

- start přes `inetd` šetří prostředky, protože příslušný server běží pouze po čas, kdy jsou jeho služby opravdu potřeba. Nehodí se tedy pro spouštění vytížených služeb (`www`) nebo služeb kde je velký overhead při inicializaci (např. SSH kvůli generování klíče).
- typicky se pomocí `inetd` spouští servery, které se používají málo nebo jejichž inicializace je relativně nenáročná (`telnetd`, `ftpd`). Silně vytížené a dlouho startující servery (`httpd`) se obvykle startují ze systémových inicializačních skriptů a běží stále.
- často má cenu `inetd` mít vypnutý úplně. Pokud na vašem stroji běží např. pouze SSH, tak pro to se `inetd` ve většině případů nepoužívá, `inetd` by byl jen dalším serverem běžícím na stroji a zdroj potenciálního nebezpečí, pokud by se v něm objevila bezpečnostní chyba.

## Formát souboru `/etc/inetd.conf`

`služba socket proto čekání uživ server argumenty`

- `služba ...` jméno síťové služby podle `/etc/services`
- `socket ...` `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]`

- soket typu `stream`:
  - `wait ...` server dostane soket, na který musí aspoň jednou zavolat `accept()`. Teprve tím získá nový soket, přes který může komunikovat s klientem. Po skončení serveru přebírá řízení soketu zpět `inetd`.
  - `nowait ...` `inetd` zavolá `accept()` a získaný soket předá serveru, server tedy může rovnou komunikovat (může používat standardní vstup a výstup) a nemusí vědět, že komunikuje po síti. Mezitím `inetd` čeká na další klienty a podle potřeby spouští další instance serveru.
- pro soket typu `dgram` má smysl pouze `wait`. Server musí přecíst ze soketu aspoň jeden datagram.
- jestliže `inetd` restartuje server (kromě `stream nowait`) příliš často (cca jednou za sekundu), usoudí, že nastala chyba a po určité době (asi 10 minut) službu zablokuje (nespouští server a odmítá spojení). Ostatní servery spouští normálně dál.

## 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 používající vlákna
  - obtížnější debugging

- pro aplikace, kde každý krok závisí na kroku předcházejícím, nemají vlákna příliš velký smysl.
- debugery typicky mají podporu vláken, ale debugging změny timing, takže to co v reálu dělá problém se při debuggingu vůbec nemusí projevit. Toto samozřejmě není problémem u klasických 1-vláknových procesů.
- jak bylo uvedeno na slajdech s doporučenou literaturou, k vláknům to je [Butenhof]. On-line pak je třeba dostupná velmi dobrá a obsáhlá kniha **Multi-threaded Programming Guide** na <http://docs.sun.com>.

## 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.
- ⊕ menší režie přepínání kontextu
- ⊖ nemůže běžet více vláken stejného procesu najednou.

### kernel-thread model

- vlákna jsou implementována přímo jádrem.
- ⊕ více vláken jednoho procesu může běžet najednou na různých procesorech.
- ⊖ plánování threadů používá systémová volání místo knihovnických funkcí, tím více zatěžuje systém.

### hybridní modely

- vlákna se multiplexují na několik jádrem plánovaných entit.

- původně UNIX s vlákny nepracoval a první implementace byly čistě knihovní, bez účasti jádra. Dnes se používá spíše implementace vláken v jádru nebo smíšený model.
- existují i jiné typy implementace vláken než jsou zde uváděná POSIXová vlákna (např. systémové volání `proc()` v IRIXu, Cthreads, Solaris threads, ...).
- **zatímco při práci s více procesy je nutné vyvinout jisté úsilí proto, aby dané procesy mohly data sdílet, u vláken je naopak nutné řešit situaci, jak přirozené sdílení dat uhlídat.**
- vlákna implementována pouze v knihovně mohou být preemptivní i nepreemptivní. Pro preemptivnost je možné použít časovače a signály. Pokud *multithreading* (= použití vláken v aplikaci) není použit pro zvýšení výkonu aplikace, typicky není problém s použitím nepreemptivních vláken. Střídání vláken se automaticky dosáhne používáním blokujících systémových volání.

- pokud se volání v library-thread modelu zablokuje, zablokuje se celý proces, tj. žádné vlákno nemůže běžet. To vyplývá z toho, že jádro v tomto modelu o pojmu vlákno nic neví. Knihovní funkce jsou proto přepsány tak, že místo blokujeících volání se použijí neblokuující a kontext se přepne na jiné vlákno.

## 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.
- nastaví atributy (velikost zásobníku, plánovací politika) podle `attr` (použije implicitní atributy při `attr == NULL`).
- 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_getstackaddr()`, `pthread_attr_setstackaddr()`, ...

- pozor na konstrukce typu:

```
for(i = 0; i < N; i++)
 pthread_create(&tid, attr, start_routine, &i);
```

na první pohled takto předáme každému vláknu jeho `i`. Jenže plánovač může způsobit to, že než si nově spuštěné vlákno stačí přečíst hodnotu `i`, příkaz `for` provede další iteraci a hodnota se změní. Obecně vlákno může dostat místo správné hodnoty `i` libovolnou větší.

- co ale je možné použít, pokud potřebujeme předat pouze jednu hodnotu, je toto:

```
assert(sizeof(void *) >= sizeof(int));
for(i = 0; i < N; i++)
 pthread_create(&tid, attr, start_routine, (void *) i);
```

... a ve funkci `void *start_routine(void *arg)` pak přetypovat ukazatel zpátky na `integer` a máme potřebný identifikátor vlákna:

```
printf("thread %d started\n", (int) arg);
```

- pokud potřebujeme předat více bajtů než je velikost ukazatele, tak už opravdu musíme předat ukazatel na paměť s příslušnými předávanými daty nebo použít globální proměnné.

## 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 vlákně může být s klíčem asociována jiná hodnota voláním `pthread_setspecific()`.

- každé vlákno má zásobník pevné velikosti, který se automaticky nezvětšuje.
- běžné globální proměnné (a také dynamicky alokovaná data) jsou společné pro všechna vlákna. Klíčované hodnoty představují způsob, jak vytvořit globální proměnnou, která je ale lokální v rámci vlákna.
- každé vlákno má ještě vlastní signálovou masku, k tomu se také dostaneme



## Ukončení vlákna

```
void pthread_exit(void *value_ptr);
```

- Ukončí volající vlákno.
- Obdoba `exit()` pro proces

```
int pthread_join(pthread_t thread, void **value_ptr);
```

- počká na ukončení vlákna `thread` a ve `value_ptr` vrátí hodnotu ukazatele `value_ptr` z volání `pthread_exit()` nebo návratovou hodnotu hlavní funkce vlákna.
- obdoba čekání na synovský proces pomocí `wait()`

```
int pthread_detach(pthread_t thread);
```

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

- pokud nemáme v úmyslu po skončení vlákna volat `pthread_join()`, je třeba zavolat `pthread_detach()`. Jinak po ukončeném vláknu zbydou v paměti data nutná pro zjištění jeho výsledku pomocí `pthread_join()`. To je podobná situace, jako když rodičovský proces nepoužívá `wait()` a v systému se hromadí zombie. Ve funkci pro vlákno doporučuji použít toto:

```
pthread_detach(pthread_self());
```

- čekat na ukončení vlákna může libovolné jiné vlákno, nejen to, které ho spustilo.

## 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.

- variantou je inicializace globálních dat ještě předtím, než se proces rozdělí na vlákna, což je běžnější způsob inicializace.
- není definováno, co se má stát, pokud je `once_control` automatická proměnná nebo nemá požadovanou hodnotu.

## 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

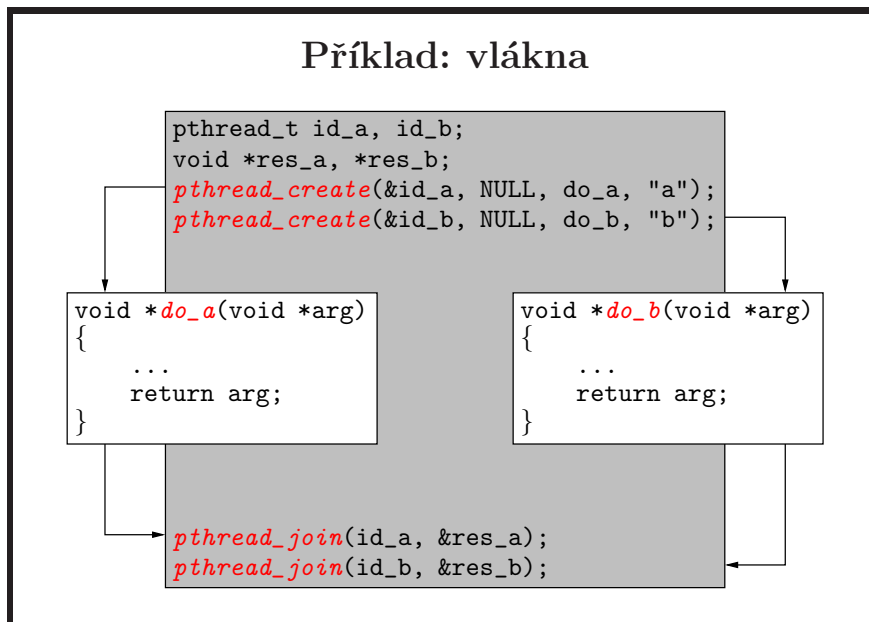
```
int pthread_setcanceltype(int type, int *old);
```

- `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);
```

- vlákna je možné zvenku „násilně“ rušit (obdoba ukončení procesu pomocí signálu) buď okamžitě, nebo jen v určitých voláních (tzv. *cancellation points*). To znamená, že v takovém případě je možné vlákno zrušit v čase, kdy je vlákno vykonává danou funkci. Pokud vlákno zrovna takovou funkci nevykonává, informace o zrušení se “doručí” během vykonání první takové funkce od té doby.
- funkce `pthread_cancel()` se podobá zrušení procesu signálem poslaným voláním `kill()`.
- funkce `pthread_setcancelstate()` a `pthread_setcanceltype()` jsou obdobou zakázání a povolení zrušení procesu signálem pomocí manipulace s maskou blokových signálů (`sigprocmask()`).
- při zrušení vlákna se zavolají úklidové *handlers*; viz dále.

## Příklad: vlákna



- toto je triviální příklad, kdy proces (hlavní vlákno) vytvoří dvě další vlákna a počká na jejich ukončení.

## Soukromé klíčované hodnoty ve vláknech

```
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`.

- při vytvoření klíče je s ním asociována hodnota NULL.
- při ukončení nebo zrušení vlákna se volají destruktory (v nspecifikovaném pořadí) pro všechny klíče s hodnotou různou od NULL. Aktuální hodnota je destruktoru předána v parametru. Jestliže po skončení všech destruktorech zůstávají klíče s hodnotou různou od NULL, znovu se volají destruktory. Implementace může (ale nemusí) zastavit volání destruktorech po `PTHREAD_DESTRUCTOR_ITERATIONS` iteracích. Destruktor by tedy měl nastavit hodnotu na NULL, jinak hrozí nekonečný cyklus.
- destruktory si musí sám zjistit klíč položky, ke které patří, a zrušit hodnotu voláním `pthread_setspecific(key, NULL)`.
- SUSv3 tento nesmyslný požadavek odstraňuje, protože definuje, že před vstupem do destruktora je hodnota automaticky nastavená na NULL; destruktory se následně vyvolá s předchozí hodnotou klíče.

## Úklid při ukončení/zrušení vlákna

- vlákno má zásobník úklidových handlerů, které se volají při ukončení nebo zrušení vlákna funkcemi `pthread_exit()` a `pthread_cancel()`. Jako první se spouští naposledy vložený handler.
- po provedení handlerů se volají destruktory privátních klíčovaných dat vlákna.

```
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.

- handlers se volají jako `routine(arg)`.
- tyto handlers se dají používat např. na úklid lokálních dat funkcí (obdoba volání destruktorků pro automatické proměnné v C++).

## 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.)

- pokud mělo již neexistující vlákno zamčený mutex, tak je přístup k příslušným sdíleným datům ztracen, protože zamčený mutex může odemknout pouze to vlákno, které ho zamknulo.
- ostatní vlákna přestanou existovat, nevolají se žádné rutiny jako při volání `pthread_exit`, `pthread_cancel` nebo destruktory klíčovaných dat
- je možné použít handlers pro `fork` pomocí funkce `pthread_atfork`. To my potřebovat nebudeme, zájemce odkazují například na [Butenhof].
- pozor na to, že chování `fork()` také závisí na použité knihovně a verzi systému, například na Solarisu před verzí 10 znamenalo `fork()` v knihovně `libthread` (jiná knihovna než `libpthread`) to samé co `forkall()`

## 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 blokováných 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()`. V ostatních vláknech se signály zablokují.

- jestliže je pro signál nastaveno ukončení procesu, skončí celý proces, nejen jedno vlákno.
- vytvořené vlákno dědí nastavení signálové masky od vlákna, které ho vytvořilo
- při použití `sigwait` tak vlastně zablokujete příslušné signály ve všech vláknech, včetně vlákna, ve kterém chcete zpracovávat signály. Viz přednáška o signálech. Tento způsob zpracování signálů bývá často jediný opravdu doporučený pro vlákna, navíc je i nejsnáze implementovatelný.
- v reálné aplikaci není rozumné blokovat všechny signály, tj. včetně signálů posílaných jako oznámení chyb – SEGV, FPE atd. Viz přednáška o signálech.



## Synchronizace vláken: mutexes (1)

- nejjednodušší způsob zajištění synchronizovaného přístupu ke sdíleným datům mezi vlákny je použitím mutexu
- statické vers. dynamické mutexy
- statická inicializace mutexu:

```
pthread_mutex_t mutex = PTHREAD_MUTEX_INITIALIZER
```

- inicializace mutexu `mx` s atributy `attr` (nastavují se pomocí `pthread_mutexattr_...()`, `NULL` = default)

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

- po skončení používání mutexu je nutné ho zrušit:

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

- mutex = *mutual exclusion* (vzájemné vyloučení)
- je to speciální forma Dijkstrových semaforů – rozdíl mezi mutexy a binárními semaforů je ten, že zamčený mutex může odemknout pouze to vlákno, které ho zamklo. To u semaforů neplatí.
- mutexy jsou určeny pouze ke krátkodobému držení a měly by fungovat rychle. Slouží pro implementaci kritických sekcí, podobně jako lock-soubory nebo semaforey (použité jako zámky).
- inicializace statického mutexu pomocí zmíněného makra nastaví pro mutex jeho defaultní atributy.
- dynamické mutexy můžeme potřebovat například v situaci, kdy dynamicky alokujeme datovou strukturu, jejíž součástí je i mutex, který sdílená data struktury chrání. I zde, před zavoláním funkce `free` na datovou strukturu, by se mělo použít volání pro zrušení mutexu.
- je možné dynamicky inicializovat i statické mutexy, ale je třeba zajistit, že se vždy inicializují před použitím (to samozřejmě platí i pro dynamické mutexy) a že se inicializují pouze jednou
- kopírovat mutexy není korektní – výsledek takové operace není definován. Je možné samozřejmě zkopírovat ukazatel na mutex a s tímto ukazatelem pak dále pracovat.

## Mutexes (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

- nelze zamknout mutex, pokud ho dané vlákno již zamčené má. Někdy může dojít i k self dead-locku.
- nelze odemknout nezamčený mutex
- nelze odemknout mutex, který zamknulo jiné vlákno. Pokud je toto potřeba, použijte binární semafor.
- při vytváření aplikace, kde je efektivita klíčovým faktorem, je nutné rozmyslet, jak, kde a kolik mutexů používat. Z knihovny, která nebyla napsaná pro použití v aplikacích používající vlákna, je možné udělat thread-safe knihovnu tak, že před zavoláním jakékoli funkce knihovny zamknu jeden giant mutex a po skončení funkce ho odemknu. Mám tedy pouze jeden mutex a šetřím tak čas, ale vlákna používající tuto knihovnu často spí při čekání na přístup. Na druhou stranu, pokud zamykám přístup ke konkrétním, malým sekcím, mohu potřebovat spoustu mutexů a hodně času strávím ve funkcích které s mutexy pracují. Je proto často nutné podle situace zvolit vhodný kompromis.

## Podmínkové proměnné (1)

- mutexy slouží pro synchronizaci přístupu ke sdíleným datům
- podmínkové proměnné pak k předání informací o těchto sdílených datech
- z toho plyne, že **každá podmínková proměnná je vždy asociována s jedním mutexem**
- jeden mutex může být asociován s více podmínkovými proměnnými
- společně pomocí mutexů a podmínkových proměnných je možné vytvářet další synchronizační primitiva
  - semaforey
  - bariéry
  - ...

- jinými slovy – podmínkové proměnné se používají v situaci, kdy vlákno potřebuje otestovat nějakou podmínku nad **sdílenými** daty (např. stav čítače položek ve frontě), a uspat se, když není splněna. Spící vlákno může být probuzeno jiným vláknem, které změní datovou strukturu tak, že podmínka bude splněna. Dané vlákno však musí explicitně oznámit, že data změnilo.
- není to tak, že při deklaraci podmínkové proměnné, což je pro programátora zcela transparentní typ, definujete podmínku např. “*n je větší než 7*”. Podmínkovou proměnnou totiž můžete přirovnat k praporu nějaké barvy, a pokud ho zvednete, znamená to, že ta vlákna, která čekají až s tímto praporem někdo zamává nad hlavou, jsou o této situaci informována a mohou se podle toho zařídit. Některá vlákna tak mohou čekat na to, až *n* bude větší než 7, jiná mohou čekat pouze na to, až se *n* jakkoli změní. Je pouze na programátorovi, zda pro každou konkrétní situaci použije jednu podmínkovou proměnnou, nebo jednu pro všechny situace dohromady. Pro druhou situaci platí, že vlákna čekající na nějakou událost musí vždy otestovat, která ze situací nastala. Pokud ne ta, na kterou vlákno čeká, znovu se uspí. Jak je však uvedeno dále, z implementačních důvodů je nutné podmínku otestovat vždy, i když pro ni používáte samostatnou podmínkovou proměnnou – může se stát, že systém tím praporem zamává sám, aniž by to udělalo to vlákno, které v naší názorné situaci ten čítač *n* mění a následně to oznamuje.

## 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()`.

- je nutné, aby po té, co vlákno zamkne mutex a dříve, než vlákno zavolá `pthread_cond_wait`, otestovat podmínku. Pokud tuhle operaci vlákno neprovede, mohlo by se uspat na neurčitou dobu, protože hláška o splnění podmínky od jiného vlákna by prošla “bez povšimnutí”. Jinak řečeno, nesmím se uspat při čekání na situaci, která už mezitím nastala. Nefunguje to jako signály, které pro vás systém drží, pokud je máte například zablokované. Co je důležité je to, že ten test provádíte pod ochranou mutexu, tedy si opravdu můžete být jistí hodnotou našeho čítače `n`.

## Podmínkové proměnné (3)

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

- čeká na `pthread_cond_signal()` nebo `pthread_cond_broadcast()`, ale maximálně do vypršení timeoutu `abstime`.

```
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`.

- v parametru `abstime` funkce `pthread_cond_timedwait()` se předává absolutní čas, tj. timeout vyprší, když systémový čas dosáhne hodnoty větší nebo rovné `abstime`. Pro absolutní čas bylo rozhodnuto proto, aby programátor nemusel při případných probuzeních, kdy následně zjistí, že daná podmínka neplatí, přepočítávat časový rozdíl.
- jak již bylo řečeno, jedna podmínková proměnná může být použita pro hlášení několika rozdílných situací najednou – například při vložení prvku do fronty i při jeho vyjmutí. Z toho důvodu je nutné po probuzení otestovat podmínku, na kterou se čeká. Další věc, která z toho vychází je ta, že v takovém případě musíte použít `broadcast`. Stačí si představit následující situaci – čekáte na podmínku “změnil se stav fronty”, na které čekají čtenáři i zapisovatelé (předpokládejme, že jednu frontu používá více čtenářů i více zapisovatelů). Pokud po vložení zprávy pouze vypustíte jednu signalizaci, tak se může stát, že tato signalizace probudí jiného zapisovatele, který ale samozřejmě čeká na situaci, kdy čtenář z fronty zprávu odebere. Tím se stane, že ve frontě zůstane zpráva, která může být vytlačena až další signalizací.
- vlákno může být probuzeno jiným vláknem i v případě, že čeká na jednu konkrétní událost, která však po probuzení vlákna již neplatí a přitom pro jiné události příslušná podmínková proměnná není použita (a přitom nebyl použit `broadcast`!). Představte si, že těsně po té, kdy jiné vlákno zahlásí splnění podmínky, může další vlákno zamknout mutex a nějakou akcí, např. vyjmutím prvku z fronty, zrušit platnost podmínky “ve frontě je zpráva”. To vlákno, které je probuzeno, tak najde frontu prázdnou. Další důvod pro to, že podmínkové proměnné je nutné **vždy** testovat v cyklu.
- v řídkých případech je možné, že se vlákno probudí a podmínka není platná i díky konkrétní implementaci. Z toho opět vyplývá nutnost použití cyklu.

## Použití podmínkových proměnných

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

- pro zopakování – ke každé podmínkové proměnné je potřeba mít ještě mutex.
- funkce `pthread_cond_wait()` atomicky odemkne mutex a uspí vlákno. Když je vlákno probuzeno, nejprve se znovu zamkne mutex (tj. toto zamknutí se provede v rámci příslušné implementace podmínkových proměnných!) a teprve pak se volání `pthread_cond_wait()` vrátí.
- když signalizujeme, že se něco změnilo, neznamená to ještě, že po změně bude platit podmínka. Navíc, `pthread_cond_wait()` se může vrátit, i když nebylo voláno ani `pthread_cond_signal()` ani `pthread_cond_broadcast()`. K probuzení vlákna a návratu z `pthread_cond_wait()` může tedy dojít, i když podmínka není splněna, proto je potřeba znovu otestovat podmínku a případně obnovit čekání.
- všimněte si, že odemknutí zámku následuje až po signalizaci podmínky

## Read-write zámky (1)

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

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

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

- zruší zámeček

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

```
int pthread_rwlock_tryrdlock(pthread_rwlock_t *rwlck);
```

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

- najednou může mít zámeček buď několik vláken zamčeno pro čtení, nebo maximálně jedno vlákno zamčeno pro zápis (a nikdo pro čtení).
- read-write zámky jsou obdobou zamykání souborů pomocí `fcntl()`.

## Read-write zámky (2)

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

- zamkne zámeček pro zápis, pokud má někdo zámeček 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 zámeček

- *Zvláštnost:* pokud vlákno čekající na zámeček dostane signál, po návratu z handleru se vždy pokračuje v čekání, tj. nenastane chyba `EINTR`. Takto se chovají i mutexy a podmínkové proměnné.
- SUSv3 k probraným mechanismům synchronizace vláken přidává ještě bariérovou synchronizaci (funkce `pthread_barrier_wait()` a několik pomocných funkcí).



## atomic\_add(3c)

- pro architektury, kde operace sčítání není atomická
- od Solarisu 10
- výrazně rychlejší než jiné mechanismy pro získání exkluzivního přístupu
- nutné použít hlavičkový soubor `atomic.h`
- sada volání pro různé celočíselné typy, například:

```
void atomic_add_int(volatile uint_t *target, int delta);
void atomic_add_8(volatile uint8_t *target, int8_t delta);
...a další
```

příklad: program spustí dvě vlákna, každé vlákno pracuje se stejnou globální proměnnou `x`, do které v cyklu postupně přičte čísla od jedné do velikosti parametru, které program dostane na vstupní řádce. Vlákna běží paralelně.

```
for (i = 0; i < arg; ++i)
 x = x + i;
```

poté se sčítání pro kontrolu provede v hlavním vláknu, a dvojnásobek se porovná s diskutovanou globální proměnnou. Pokud nejsou výsledky stejné, došlo k souběhu (přetečení proměnné můžeme v této situaci zcela ignorovat). Zde jsou výsledky a časy běhu pro situace, kdy program použil obyčejné sčítání, poté funkci `atomic_add_int()` a následně zamykání pomocí mutexů. Testováno na multiprocesorovém stroji UltraSparc T1000, zdroják je v sekci ukázkových příkladů v adresáři `race-condition` pod jménem `atomic-add.c`:

```
$ time ./a.out 99999999
RACE DETECTED
result is 193053170
should be 1574919426
```

```
real 0m2.816s
user 0m4.807s
sys 0m0.009s
```

```
$ time ./a.out -a 99999999
everything OK, no race detected
result is 1574919426
should be 1574919426
```

```
real 0m9.628s
user 0m18.431s
sys 0m0.010s
```

```
$ time ./a.out -m 99999999
everything OK, no race detected
result is 1574919426
should be 1574919426
```

```
real 1m23.558s
user 2m45.978s
sys 0m0.088s
```

## Bariéra, semaforey

- 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 na multiprocsorech
- bariéry nemají API, je možné je vytvořit pomocí mutexů a podmínkových proměnných
- semaforey pochází přímo z POSIXu
- jména funkcí nezačínají **pthread\_**, ale **sem\_** (**sem\_init**, **sem\_post**, **sem\_wait**, ...)
- je možné je použít s vlákny

- bariéru můžete využít např. v situaci, kdy mezi jednotlivými fázemi zpracování je potřeba provést jistou inicializaci, vlákna před ní tedy na sebe vždy musí počkat, protože inicializace další fáze může začít až tehdy, kdy skončí fáze předchozí.
- podmínka pro bariéru je třeba hodnota čítače rovnající se nule. Každé vlákno, které dosáhne bariéry, sníží čítač, který je na začátku inicializován na počet vláken. Pokud vlákno po dekrementování čítače zjistí, že ještě není roven nule, uspí se na podmínkové proměnné. Pokud dané vlákno je tím vláknem, které sníží čítač na nulu, místo zavolání **pthread\_cond\_wait** pošle broadcast, který následně probudí všechna vlákna spící na bariéře (signalling zde nestačí, chcete probudit všechna vlákna, ne jen jedno!). Před spuštěním další fáze zpracování se čítač reinitializuje na původní hodnotu. I zde je nutné řešit různé problémy, například není možné jen tak reinitializovat čítač poté, co bariéry dosáhne poslední vlákno, protože jak již víme, vlákna po probuzení

z `pthread_cond_wait` musí vždy otestovat, zda čítač je opravdu nulový a pokud není, opět se uspí. Takže by se vám mohlo stát, že by se probudila jen některá vlákna, nebo taky žádná. Jak byste to řešili?

- funkce pro semaforey se drží klasické UNIXové sémantiky – při chybě vracejí `-1` a nastaví `errno`

## 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**

- dané rozdělení je jen orientační, použití vláken je samozřejmě neomezené, toto jsou asi ty tři nejčastější použití

## Thread-safe, reentrantní funkce

- *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 efektivní. . .
- slovem *reentrantní* se často myslí, že daná funkce byla navržena s přihlédnutím na existenci vláken
  - . . . tedy že daná funkce pracuje efektivně i ve vícevláknovém prostředí
  - taková funkce by se měla vyvarovat použití statických dat a pokud možno i prostředků pro synchronizaci vláken, které jinak zpomalují běh aplikace

- v dnešní době thread-safe většinou znamená reentrantní, tj. funkce jsou přepsány tak, aby pracovaly efektivně i s vlákny, ale je dobré vědět, že někdy to může vyjadřovat rozdíl.

## Nepřenositelná volání

- nepřenositelná volání končí řetězcem `_np` (*non-portable*)
- 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()`)

- tyto informace jsou pro zajímavost, abyste věděli, že se s podobnými věcmi můžete setkat. Nepřenositelná volání by se měla používat spíše pro ladící účely. Nikdy nevíte, kdo bude potřebovat váš kód spustit na jiném systému, což se stane typicky a nečekaně po té, co zrovna opustíte vaši společnost a nemáte již čas to opravit.
- zjistit, jaká nepřenositelná volání váš systém poskytuje je jednoduché, třeba pomocí `apropos _np`

## 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
- **UNIX z pohledu správce**
- ??? - bude definováno později, podle toho kolik zbyde času

tato kapitola bude pravděpodobně  
nahrazena

## ChangeLog

- 2007-12-12** přidáno mnoho nových poznámek ke slajdům o síťové komunikaci.
- 2007-12-09** přidán slajd pro `atomic_add(3c)` v sekci synchronizace vláken, p201.
- 2007-11-21** různá malá doplnění k signálům (ve slajdech i poznámkách)
- 2007-11-18** opraveny další výskyty znaku '0' místo řetězce 'len', tentokrát na slajdech k `mmap` volání.
- 2007-11-07** doplněny poznámky o soft updates (přidán konkrétní příklad)
- 2007-10-23** nový slajd „API vers ABI“, p33, a doplnění poznámek k zápisu do pojmenované roury, p85
- 2007-10-15** doplněny poznámky ke slajdům o proměnných prostředí a čtení/zápisu z/do roury (tam byly i faktické chyby).
- 2007-10-07** částečně přepsány poznámky ke slajdům o historii unixu, standardech a současných systémech; doplněny poznámky k dynamickému linkeru, debuggerům a C.
- 2007-09-16** vyřazena kapitola o administraci, bude nahrazeno něčím jiným, pravděpodobně aplikací `autoconf`.
- 2007-09-16** opravy překlepů, gramatických chyb a pod. (díky frido at devnull dot cz)
- 2007-07-18** generování tohoto textu bylo přesunuto z FreeBSD na Solaris a také jsem přešel z CsLaTeX na Babel. Může to ovlivnit některé fonty a tím i sazbu textu.

**Konec**