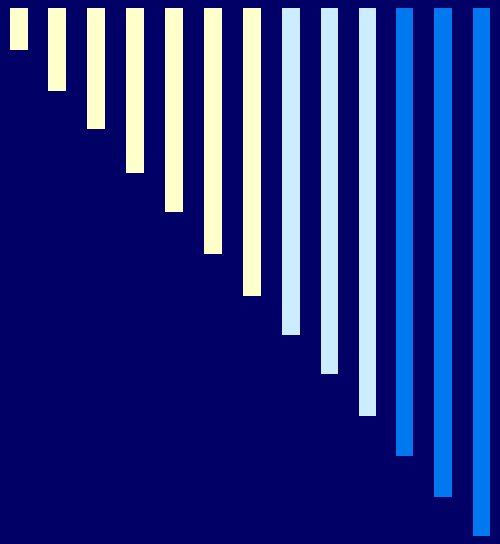

11., 12.
Správa I/O
Správa souborů

ZOS 2012, L. Pešička

Doplnění

- Alokace paměti pro procesy
  - explicitní správa paměti
  - čítání referencí
  - garbage collection

viz pdf s dodatkem – přečíst (!)

pamatuj !!

v C o paměť žádáme malloc() a máme ji uvolnit free()

paměť nám přidělí knihovna – alokátor paměti, která spravuje volnou paměť

pokud paměť nemá alokátor k dispozici, požádá operační systém systémovým voláním o přidělení další části paměti (další stránky)

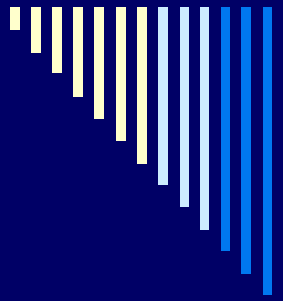

malloc, brk, sbrk

- malloc není systémové volání, ale knihovní funkce
  viz man 3 malloc x man 2 fork
- malloc alokuje pamět z haldy
- velikost haldy se nastaví dle potřeby systémovým voláním sbrk
- brk – syscall – nastaví adresu konce datového segmentu procesu
- sbrk – syscall – zvětší velikost datového segmentu o zadaný počet bytů (0 – jen zjistím současnou adresu)

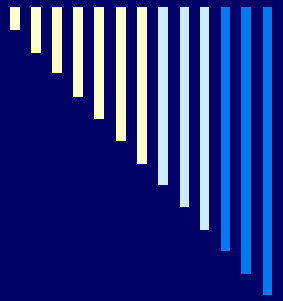

používané vs. nepoužívané objekty

```
Object x = new Foo();
Object y = new Bar();
x = new Quux();
/* víme, že Foo object původně přiřazený x nebude nikdy dostupný,
jde o  syntactic garbage */

if  ( x.check_something() )
      { x.do_something(y); }
 System.exit(0);
/* y  může být semantic garbage, ale nevíme, dokud
x.check_something() nevrátí návratovou hodnotu  */
```

zdroj: http://en.wikipedia.org/wiki/Garbage_collection_%28computer_science%29

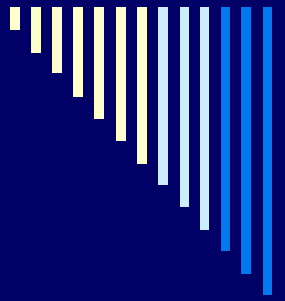

Velikost stránky v OS

Standardní velikost je 4096 bytů (4KB)

huge page size: 4MB

large page size: 1GB

Zjištění velikosti stránky - Linux

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

int main(void) {

  printf("Velikost stranky je %ld bytu.\n",
    sysconf(_SC_PAGESIZE) );

  return 0;

}
```

příkazem na konzoli:
getconf PAGESIZE

man sysconf

eryx.zcu.cz: 4096
ares.fav.zcu.cz: 4096

Zjištění velikosti stránky - WIN

```
#include "stdafx.h"
#include <stdio.h>
#include <Windows.h>

int _tmain(int argc, _TCHAR* argv[])   {

SYSTEM_INFO si;
GetSystemInfo(&si);
printf("Velikost stranky je %u bytu.\n", si.dwPageSize);

printf("Pocet procesoru: %u\n", si.dwNumberOfProcessors);

getchar();  return 0;      }
```

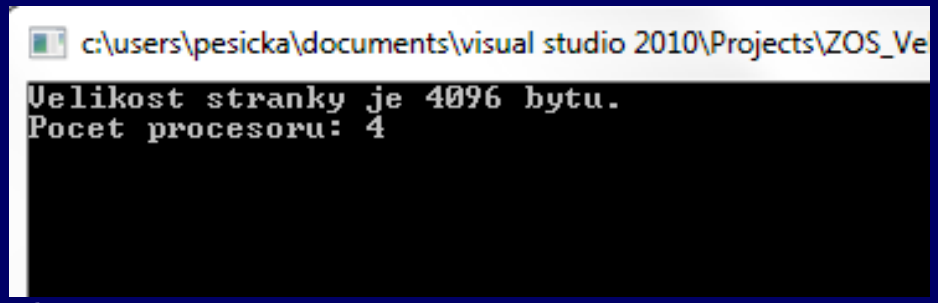

zdroj: http://en.wikipedia.org/wiki/Page_size#Page_size_trade-off

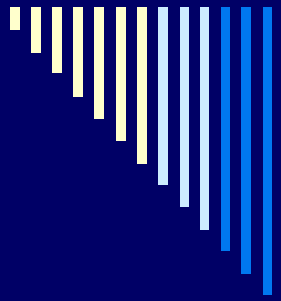

OS

- Modul pro správu procesů
- Modul pro správu paměti
- **Správa i/o**
- Správa souborů
- síťování

Vývoj rozhraní mezi CPU a zařízeními

1. CPU řídí přímo periferii
2. CPU – řadič – periferie
   aktivní čekání CPU na dokončení operace
3. řadič umí vyvolat přerušení
4. řadič umí DMA
5. I/O modul
6. I/O modul s vlastní pamětí

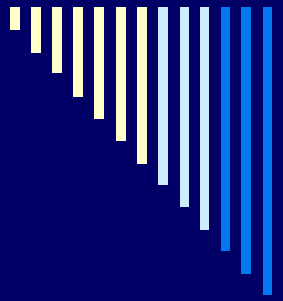

1. CPU řídí přímo periferii

- CPU přímo vydává potřebné signály
- CPU dekóduje signály poskytovaném zařízením
- Nejjednoduší HW
- Nejméně efektivní využití CPU

- Jen v jednoduchých mikroprocesorem řízených zařízeních (dálkové ovládání televize)

2. CPU – řadič - periférie

Řadič (device controller)

- Převádí příkazy CPU na elektrické impulzy pro zařízení
- Poskytuje CPU info o stavu zařízení
- Komunikace s CPU pomocí registrů řadiče na známých I/O adresách
- HW buffer pro alespoň 1 záznam (blok, znak, řádka)
- Rozhraní řadič-periférie může být standardizováno (SCSI, IDE, …)

2. řadič – příklad operace zápisu

- CPU zapíše data do bufferu,
  Informuje řadič o požadované operaci
- Po dokončení výstupu zařízení nastaví příznak, který může CPU otestovat
- if přenos == OK, může vložit další data

- CPU musí dělat všechno (programové I/O)
- Významnou část času stráví CPU čekáním na dokončení I/O operace

3. Řadič umí vyvolat přerušení

- CPU nemusí testovat příznak dokončení
- Při dokončení I/O vyvolá řadič přerušení
- CPU začne obsluhovat přerušení
  - Provádí instrukce na předdefinovaném místě
  - Obslužná procedura přerušení
  - Určí co dál
- Postačuje pro pomalá zařízení, např. sériové I/O

4. Řadič může přistupovat k paměti pomocí DMA

- DMA přenosy mezi pamětí a buffery
- CPU vysílá příkazy,
  při přerušení analyzuje status zařízení

- CPU inicializuje přenos, ale sám ho nevykonává
- Bus mastering – zařízení převezme kontrolu nad sběrnicí a přenos provede samo (PCI sběrnice)

- Vhodné pro rychlá zařízení – řadič disků, síťová karta, zvuková karta, grafická karta atd.

5. I/O modul umí interpretovat speciální I/O programy

- I/O procesor
- Interpretuje programy v hlavní paměti
- CPU spustí I/O procesor
  I/O procesor provádí své instrukce samostatně

6. I/O modul s vlastní pamětí

- I/O modul provádí programy
- Má vlastní paměť(!)
  - Je vlastně samostatným počítačem
- Složité a časově náročné operace
  grafika, šifrování, …

Komunikace CPU s řadičem

- Odlišné adresní prostory
  - CPU zapisuje do registrů řadiče pomocí speciálních I/O instrukcí
  - Vstup: IN R, port
  - Výstup: OUT R, port
- 1 adresní prostor
- Hybridní schéma

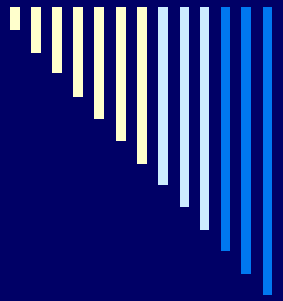

Ad – 1 adresní prostor

- Používá **vyhrazené** adresy
- Nazývá se *paměťově mapované I/O*
- HW musí pro dané adresy umět vypnout cachování

- Danou oblast můžeme namapovat do virtuálního adresního prostoru nějakého procesu (zpřístupnění I/O zařízení)

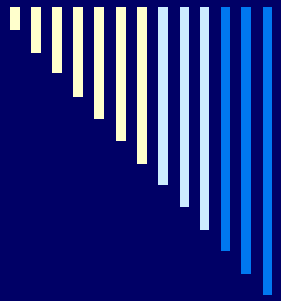

Ad – hybridní schéma

- Řídící registry
  - Přístup pomocí I/O instrukcí
- HW buffer
  - Mapován do paměti
- Např. PC
  (buffery mapovány do oblasti 640K až 1MB)

RAID

- pevný disk
  - elektronická část + mechanická
  - náchylost k poruchám
  - cena dat >> cena hw
- odstávka při výměně zařízení
  - náhrada hw, přenos dat ze zálohy - prostoje
  - SLA 24/7
- větší disková kapacita než 1 disk
- RAID
  - Redundant Array of Independent (Inexpensive) disks

RAID – používané úrovně

- RAID 0, 1, 5
- RAID 10 .. kombinace 0 a 1
- RAID 6 .. zdvojená parita

- pojmy:
  - SW nebo HW RAID
  - hot plug
  - hot spare
  - Degradovaný režim – jeden (či více dle typu RAIDu) z disků v poli je porouchaný, ale RAID stále funguje

RAID 0

Dva režimy RAID 0:
zřetězení a prokládání

- není redundantní, neposkytuje ochranu dat
- ztráta 1 disku – ztráta celého pole nebo části (dle režimu)
- důvod použití – může být výkon při režimu prokládání (např. střih videa)
- Dva režimy – zřetězení nebo prokládání (stripping)

RAID 0

- Zřetězení
  - Data postupně ukládána na několik disků
  - Zaplní se první disk, pak druhý, atd.
  - Snadné zvětšení kapacity, při poruše disku ztratíme jen část dat
- Prokládání
  - Data ukládána na disky cyklicky po blocích (stripy)
  - Při poruše jednoho z disků – přijdeme o data
  - Větší rychlost čtení / zápisu
    - Jeden blok z jednoho disku, druhý blok z druhého disku

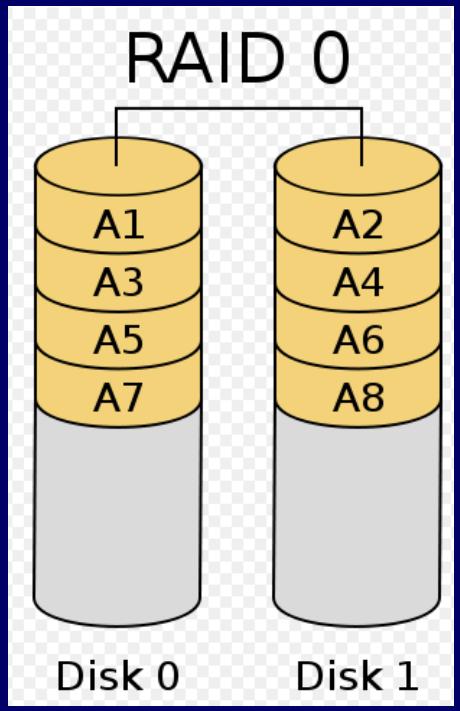

Na obrázku je režim prokládání, zdroj: wikipedia (i u dalších obrázků)

RAID 1

- mirroring .. zrcadlení
- na 2 disky stejných kapacit totožné informace
- výpadek 1 disku – nevadí
- jednoduchá implementace – často čistě sw
- nevýhoda – využijeme jen polovinu kapacity
- zápis – pomalejší (stejná data na 2 disky)
- čtení – rychlejší
  (řadič - lze střídat požadavky mezi disky)

RAID 1

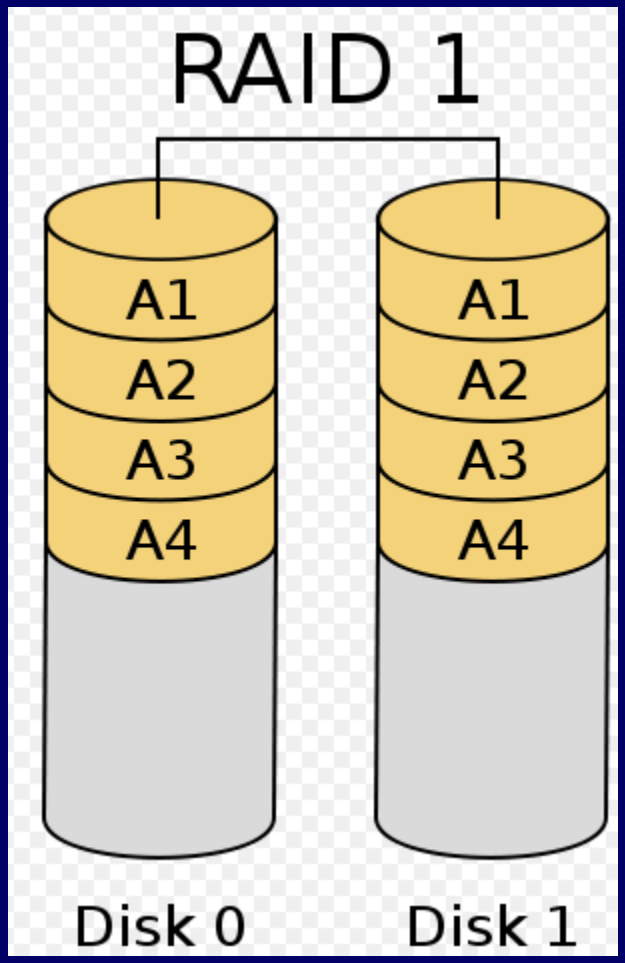

RAID 5

- redundantní pole s distribuovanou paritou
- minimálně 3 disky
- režie: 1 disk z pole n disků
  - 5 disků 100GB : 400GB pro data
- výpadek 1 disku nevadí
- čtení – výkon ok
- zápis – pomalejší
  1 zápis – čtení starých dat, čtení staré parity, výpočet nové parity, zápis nových dat, zápis nové parity

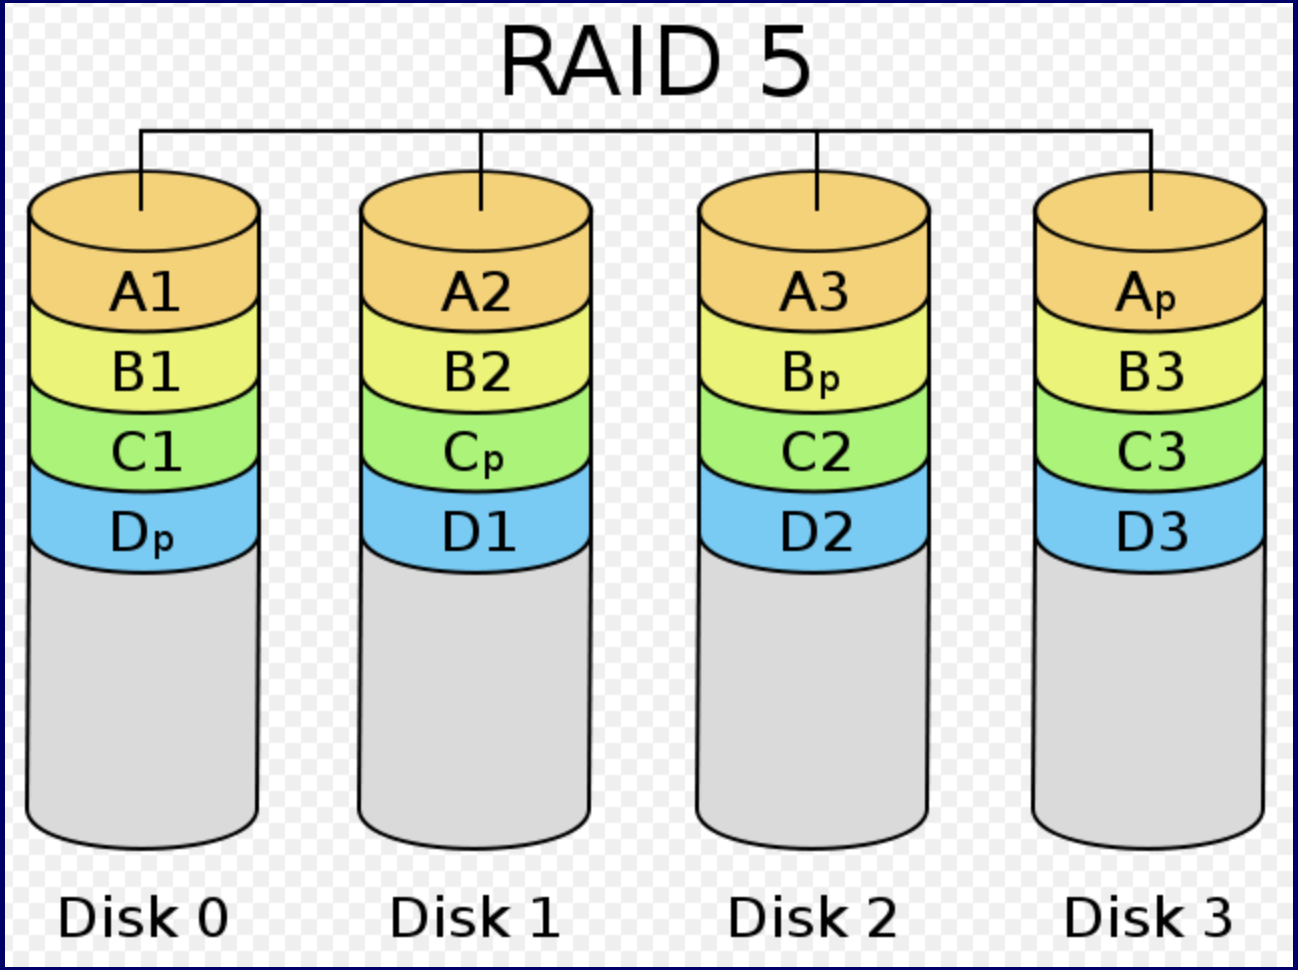

Např. RAID 5 z 4 disků 1TB, výsledná kapacita: 3 TB
Může vypadnout 1 z disků a o data nepřijdeme

RAID 5

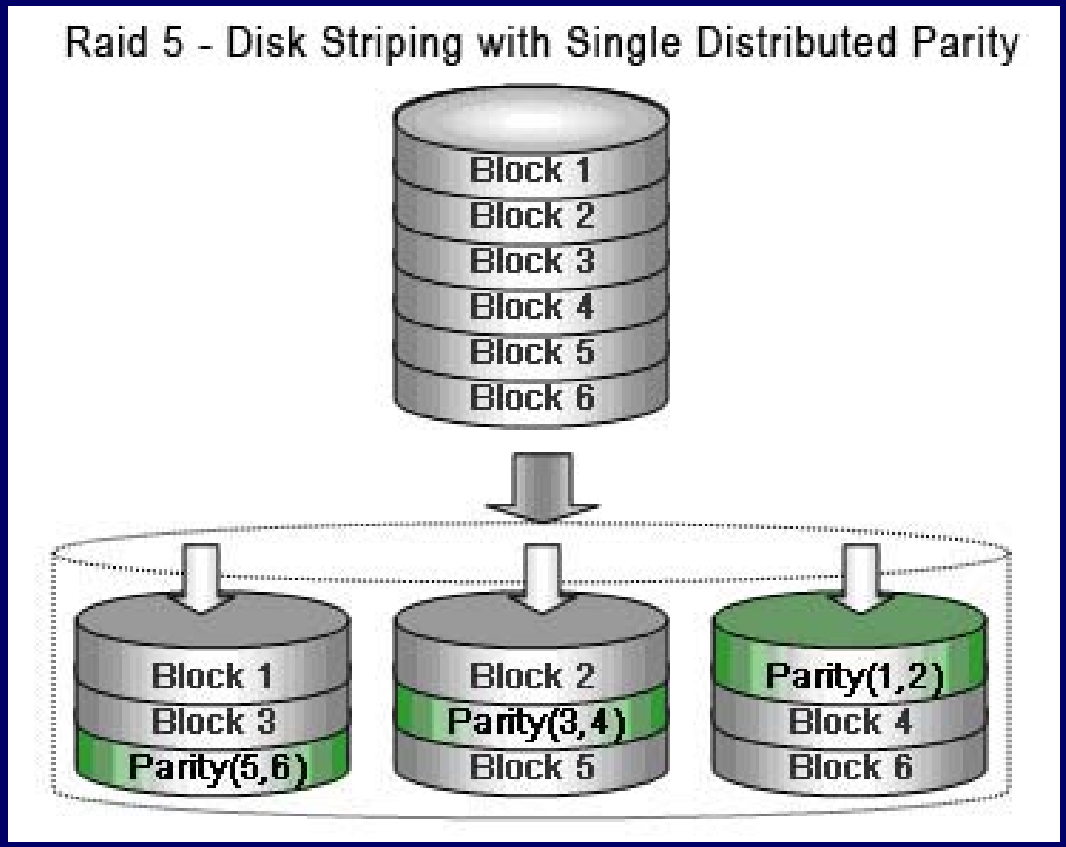

Zdroj:
http://www.partitionwizard.com/resize-partition/resize-raid5.html

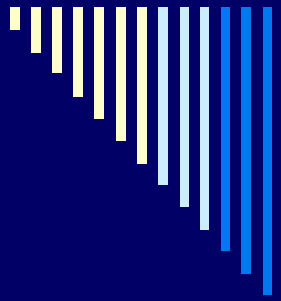

RAID 5

- nejpoužívanější

- detekce poruchy v diskovém poli
- hot spare disk
- použití hot plug disků

RAID 6

- RAID 5 + navíc další paritní disk
- odolné proti výpadku dvou disků
- Rychlost čtení srovnatelná s RAID 5
- Zápis pomalejší

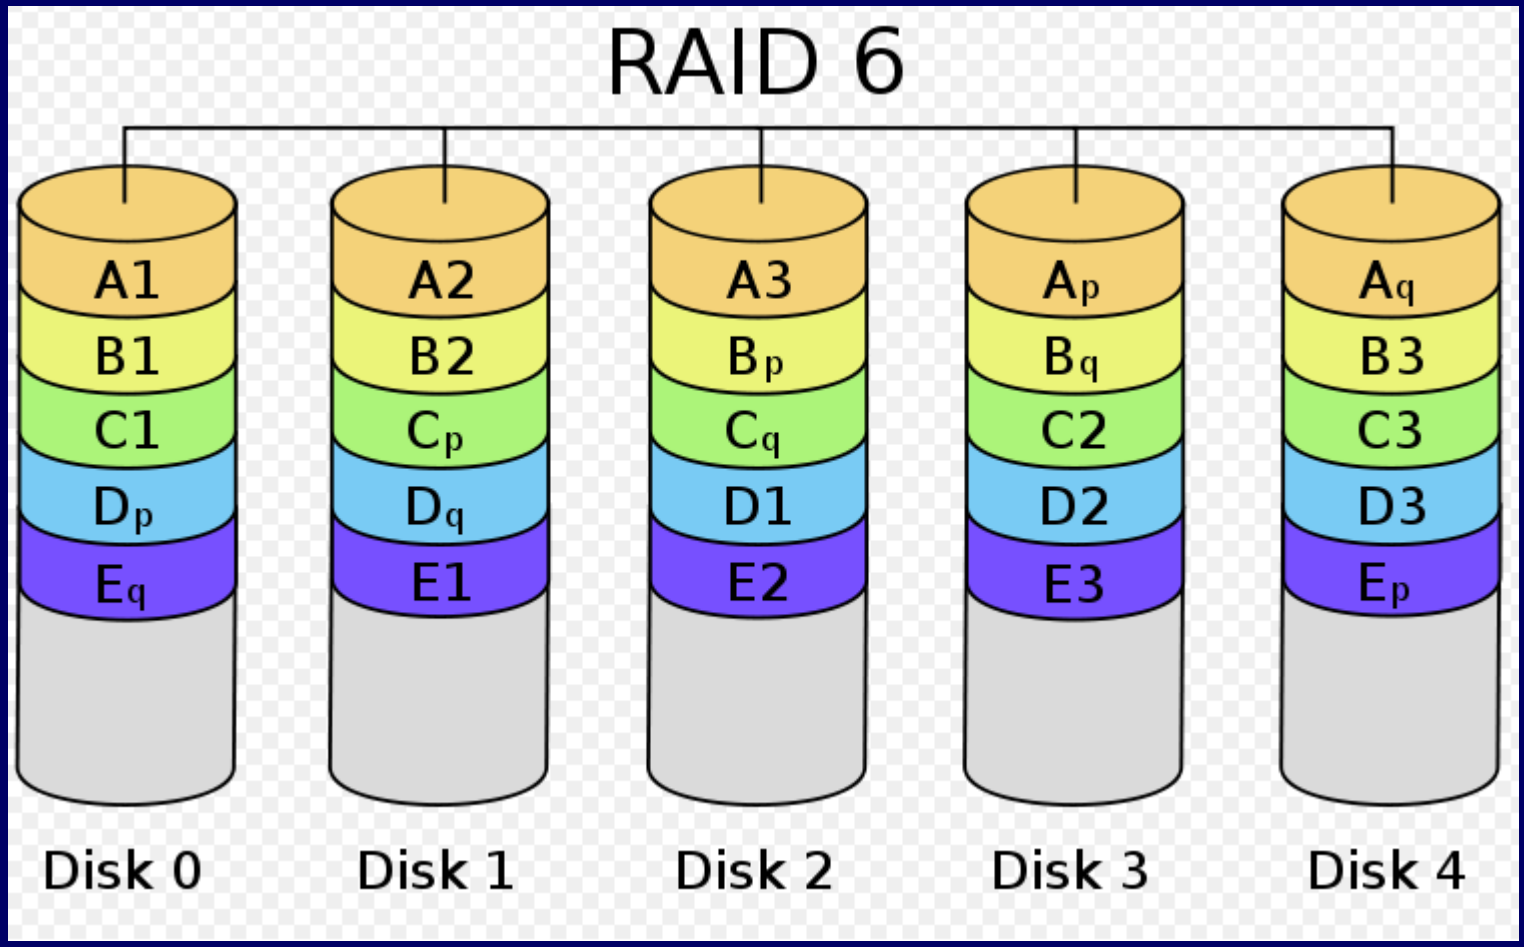
RAID 6
A1
B1
C1
Dp
Eq
A2
B2
Cp
Dq
E1
A3
Bp
Cq
D1
E2
Ap
Bq
C2
D2
E3
Aq
B3
C3
D3
Ep
Disk 0
Disk 1
Disk 2
Disk 3
Disk 4

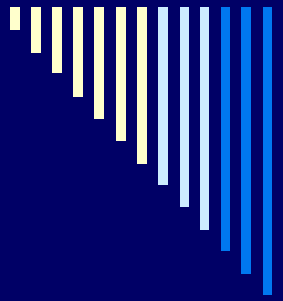

RAID 10

- kombinace RAID 0 (stripe) a RAID 1 (zrcadlo)
- min. počet disků 4
- režie 100% diskové kapacity navíc
- nejvyšší výkon v bezpečných typech polích
- podstatně rychlejší než RAID 5, při zápisu
- odolnost proti ztrátě až 50% disků x RAID 5

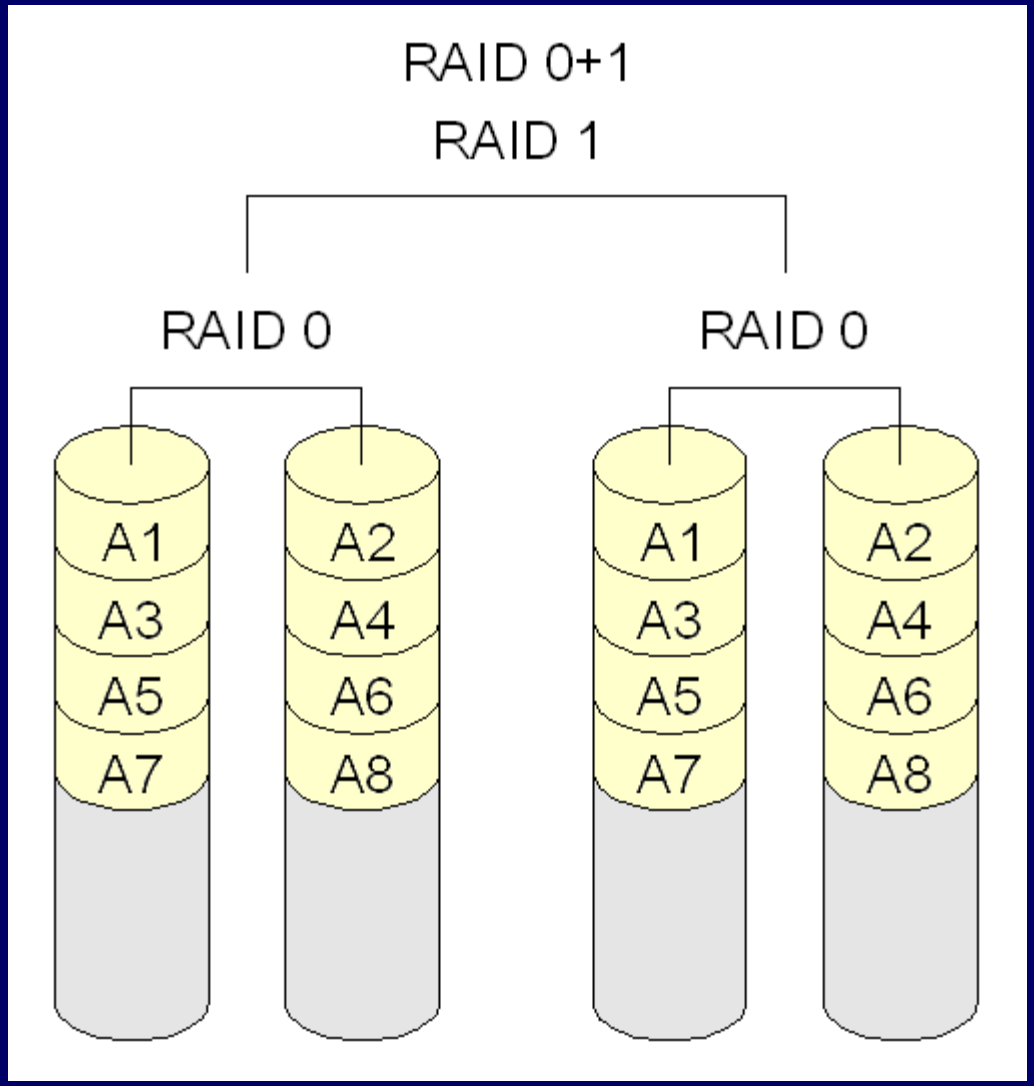
RAID 0+1
RAID 1
RAID 0
RAID 0
A1
A3
A5
A7
A2
A4
A6
A8
A1
A3
A5
A7
A2
A4
A6
A8

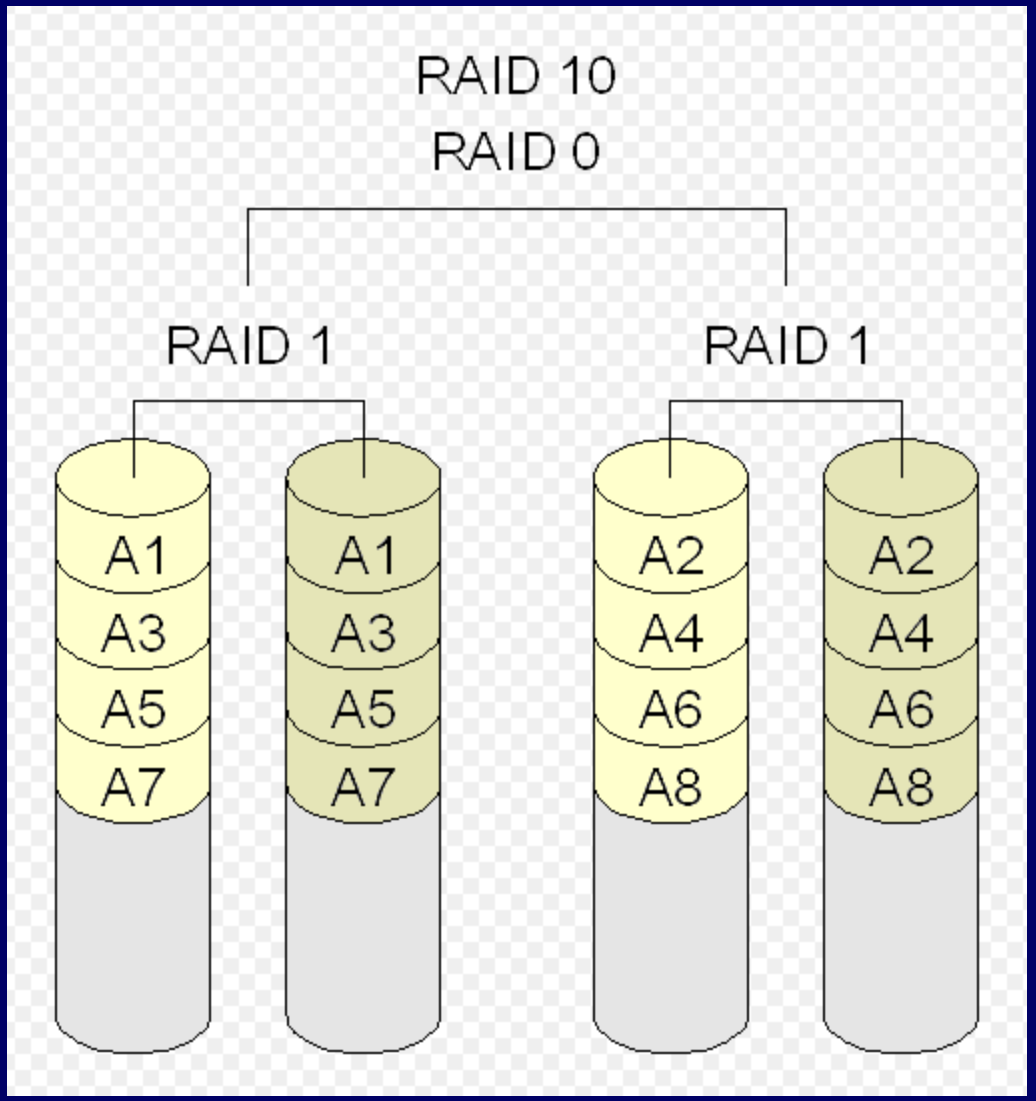
RAID 10
RAID 0
RAID 1
RAID 1
A1
A3
A5
A7
A1
A3
A5
A7
A2
A4
A6
A8
A2
A4
A6
A8

RAID 50

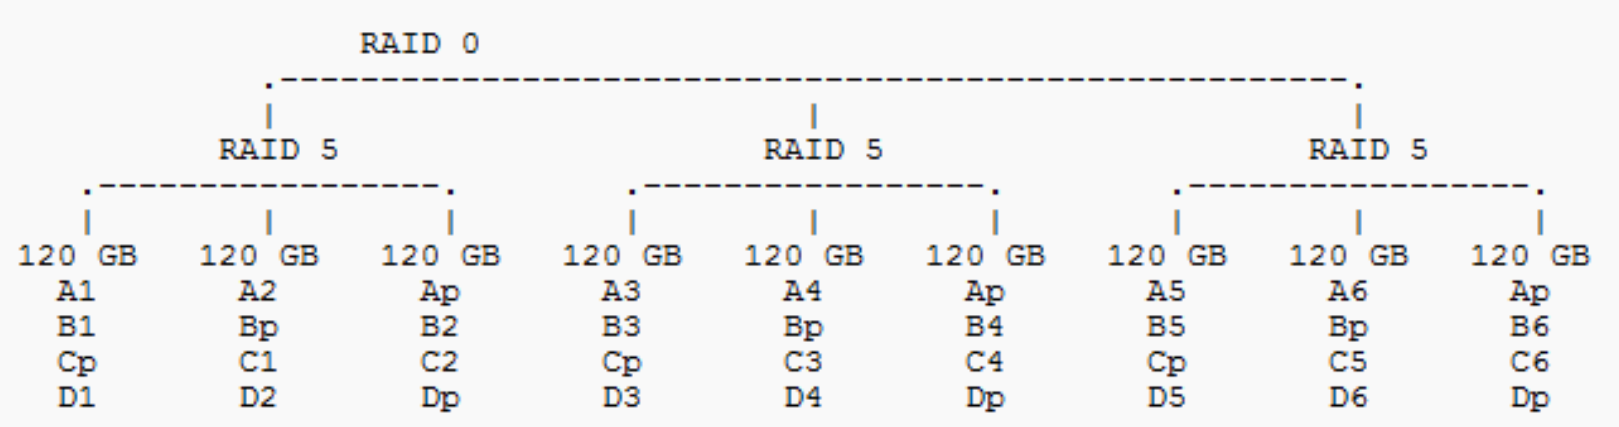

Zdroj obrázků a doporučená literatura:
http://cs.wikipedia.org/wiki/Raid

RAID 2

- Data po bitech stripována mezi jednotlivé disky
- Rotačně synchronizované disky
- Zabezpečení Hammingovým kódem
- Např. 7 disků
  - 4 bity datové
  - 3 bity Hammingův kód

RAID 2

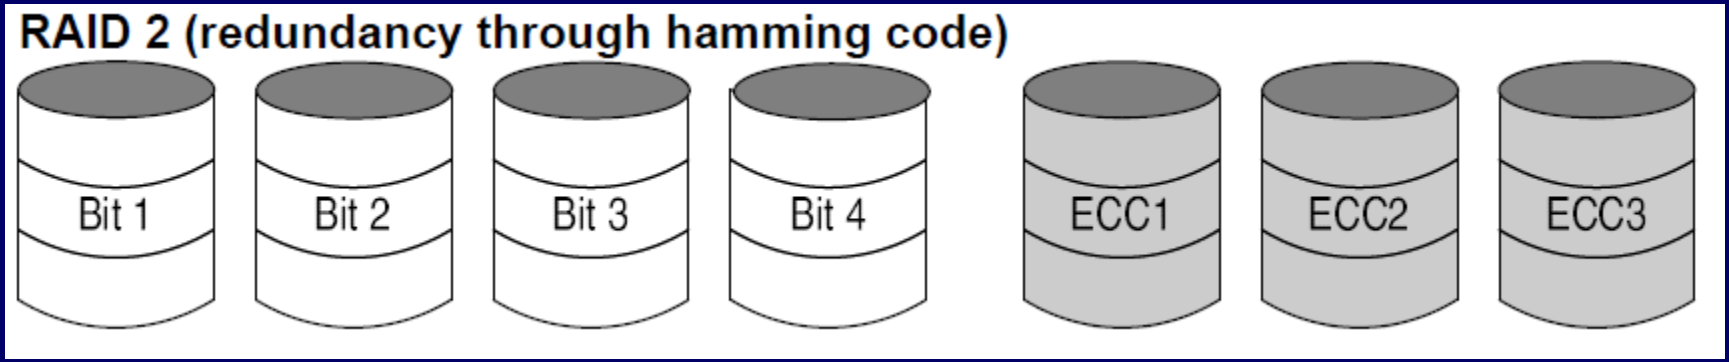
RAID 2 (redundancy through hamming code)
Bit 1
Bit 2
Bit 3
Bit 4
ECC1
ECC2
ECC3

RAID 3

- N+1 disků, bitové prokládání
- Rotačně synchronizované disky
- Na N data, poslední disk XOR parita
- Jen 1 disk navíc
- Paritní disk vytížen při zápisu na libovolný disk – vyšší opotřebení

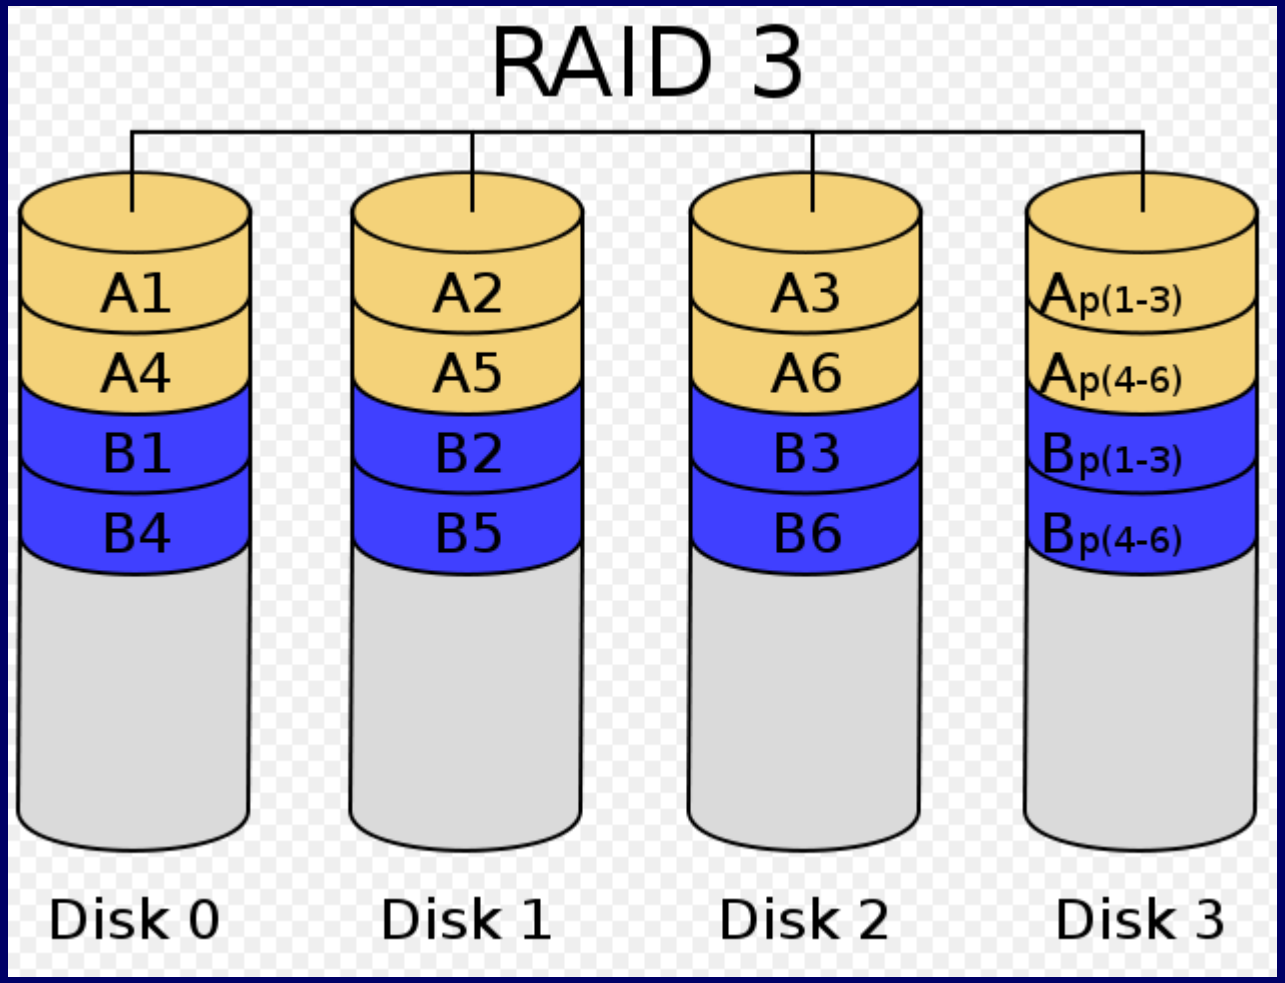
RAID 3
A1
A4
B1
B4
A2
A5
B2
B5
A3
A6
B3
B6
Ap(1-3)
Ap(4-6)
Bp(1-3)
Bp(4-6)
Disk 0
Disk 1
Disk 2
Disk 3

RAID 4

- Disky stripovány po blocích, ne po bitech
- Parita je opět po blocích

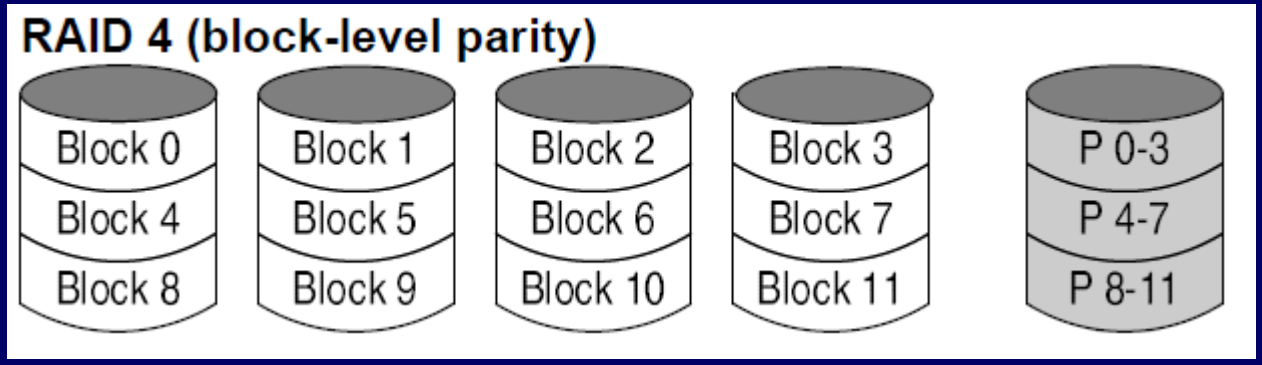

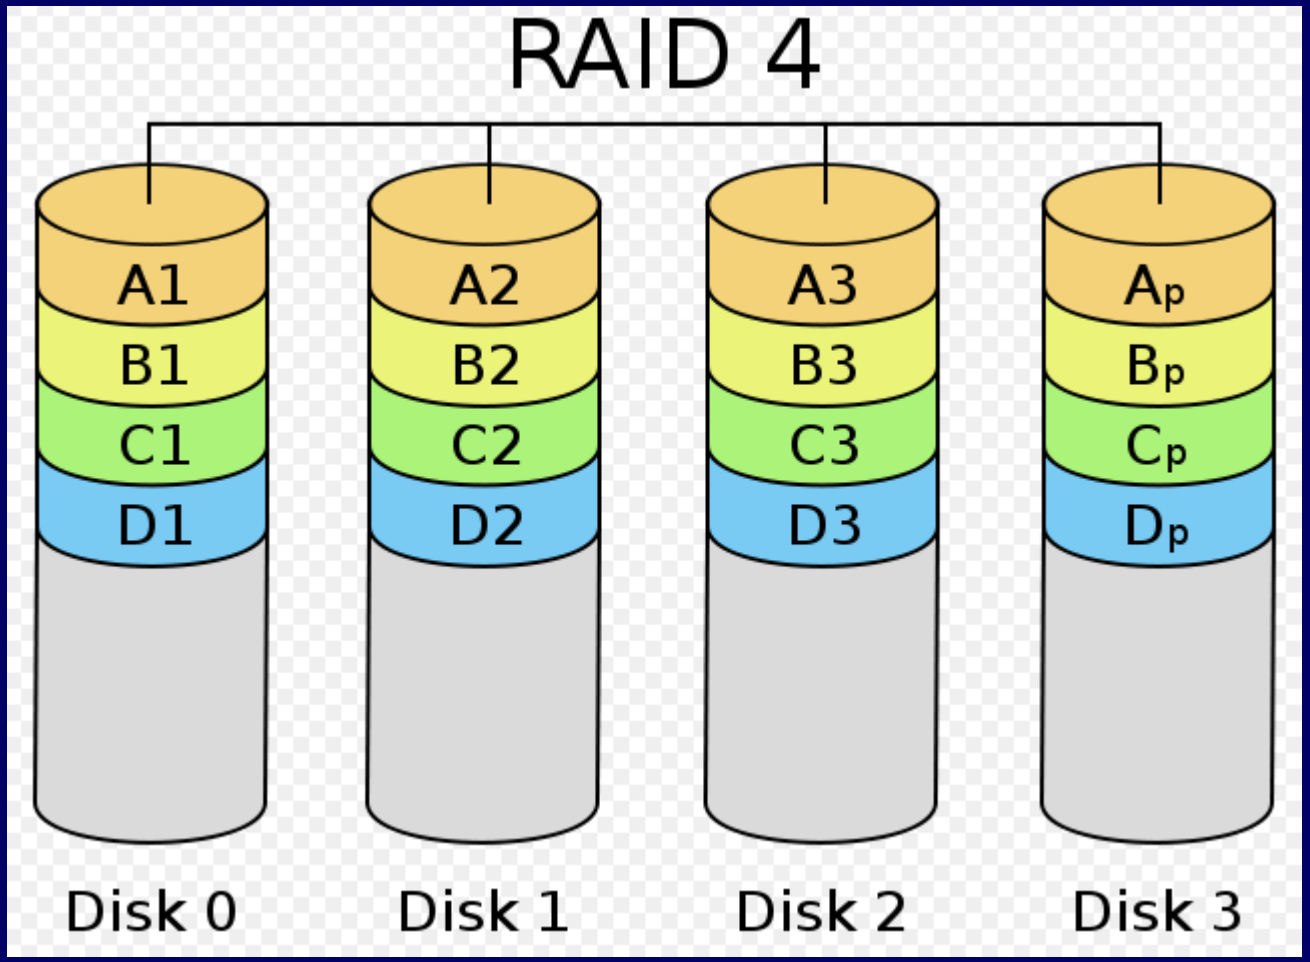
RAID 4
A1
B1
C1
D1
A2
B2
C2
D2
A3
B3
C3
D3
Ap
Bp
Cp
Dp
Disk 0
Disk 1
Disk 2
Disk 3

Problém rekonstrukce pole

- rekonstrukce pole při výpadku – trvá dlouho
  - po dobu rekonstrukce není pole chráněno proti výpadku dalšího disku
  - náročná činnost – může se objevit další chyba, řadič disk odpojí a … přijdeme o data…

HOT SPARE

- při výpadku disku v poli automaticky aktivován hot spare disk a dopočítána data
- minimalizace rizika (časové okno)
  - Pole je degradované a je třeba vyměnit disk
- hot spare disk lze sdílet pro více polí

HOT PLUG

- Snadná výměna disku za běhu systému
- Není třeba vypnout server pro výměnu disku
- „šuplík z přední strany serveru“

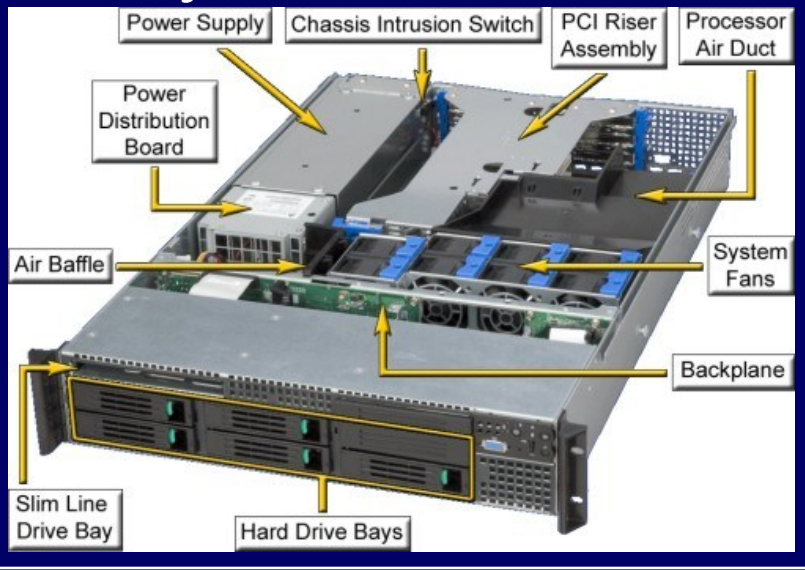

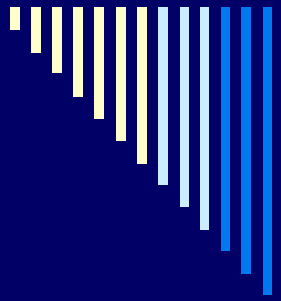

Ukládání dat

- DAS
- SAN
- iSCSI

DAS

- Directly attached storage
- ukládací zařízení přímo u serveru
- nevýhody
  - porucha serveru – data nedostupná
  - některé servery prázdné, jiné – dat.prostor skoro plný
  - rozšiřitelnost diskové kapacity
- disky přímo v serveru
- externí diskové pole přes SCSII (vedle serveru)

DAS

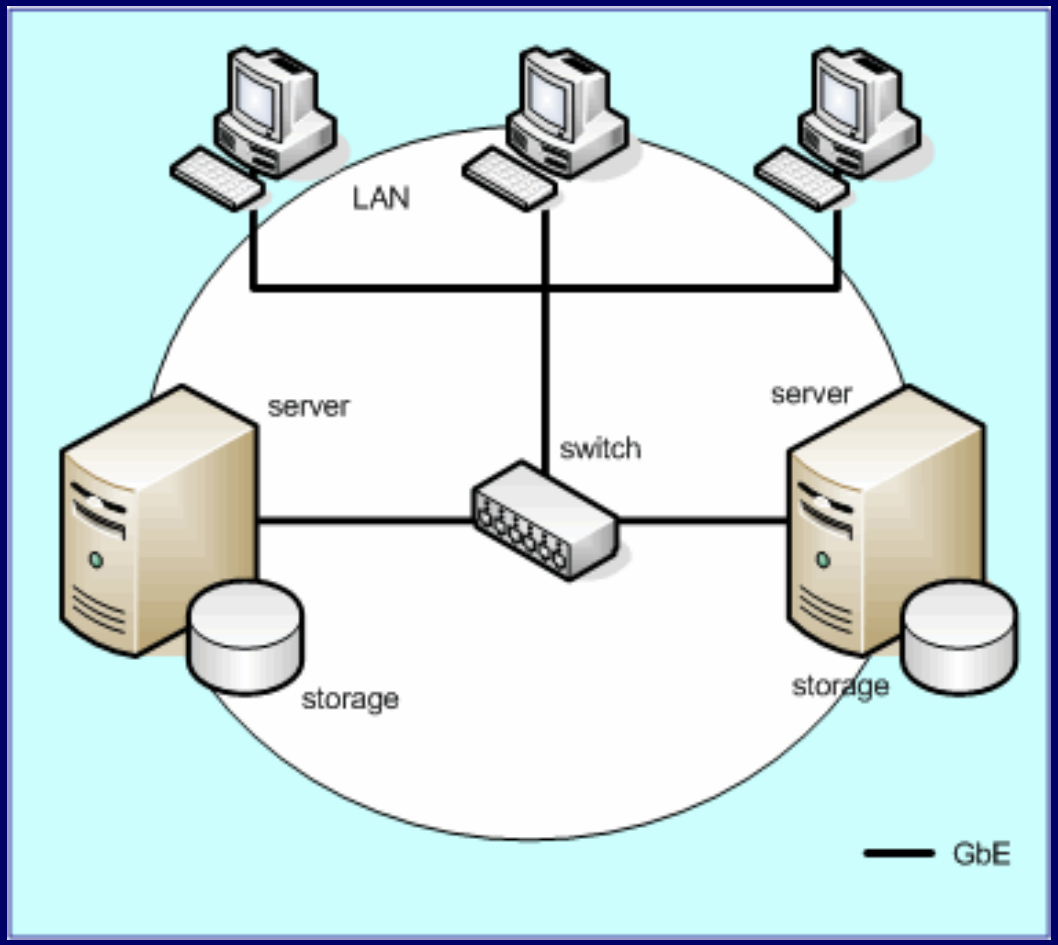

SAN

- Storage Area Network
- oddělení storage a serverů
- Fibre Channel – propojení, optický kabel

- např. clustery, společná datová oblast
- high availability solution

SAN

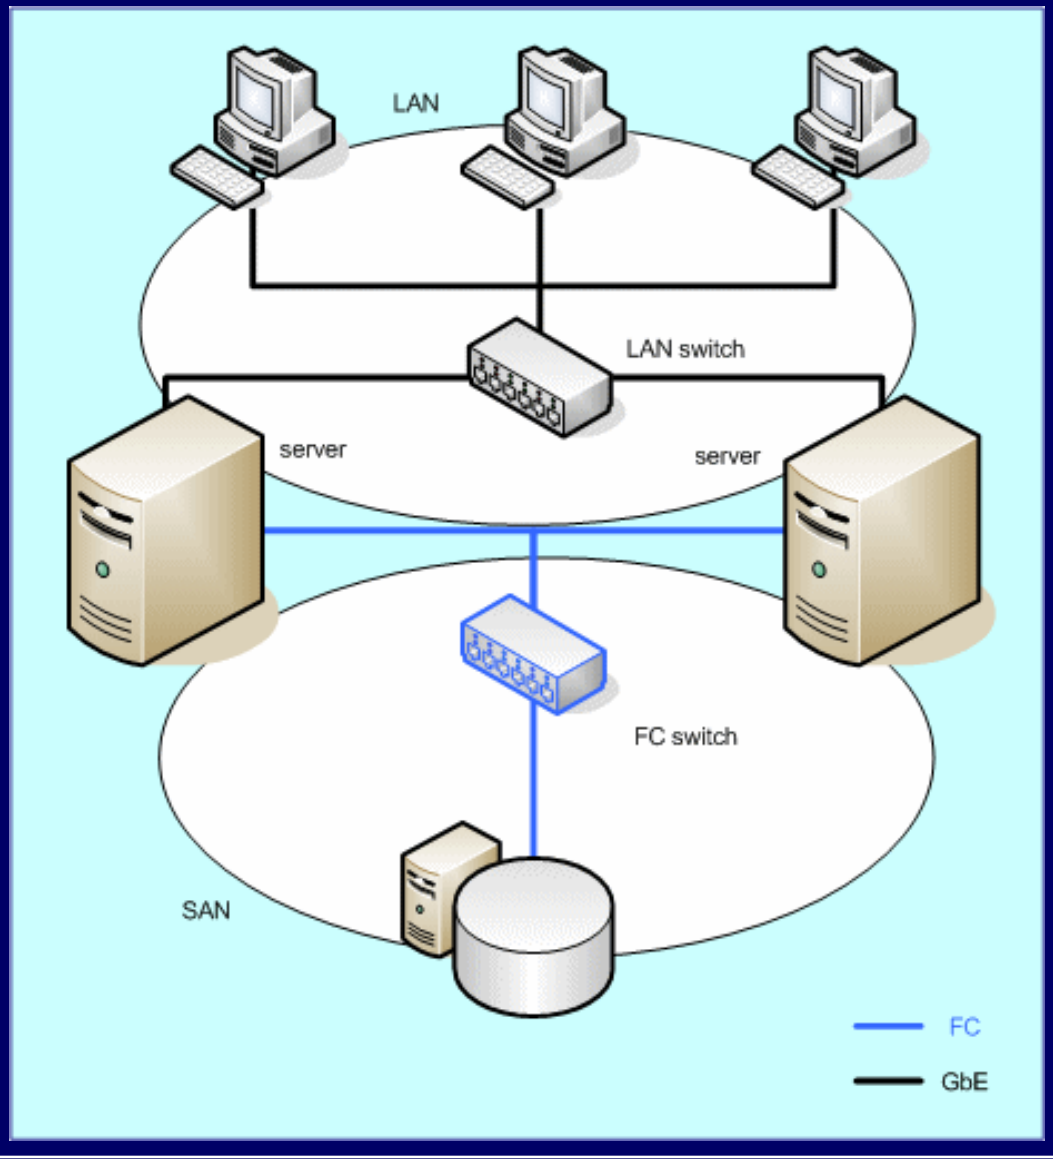

SAN

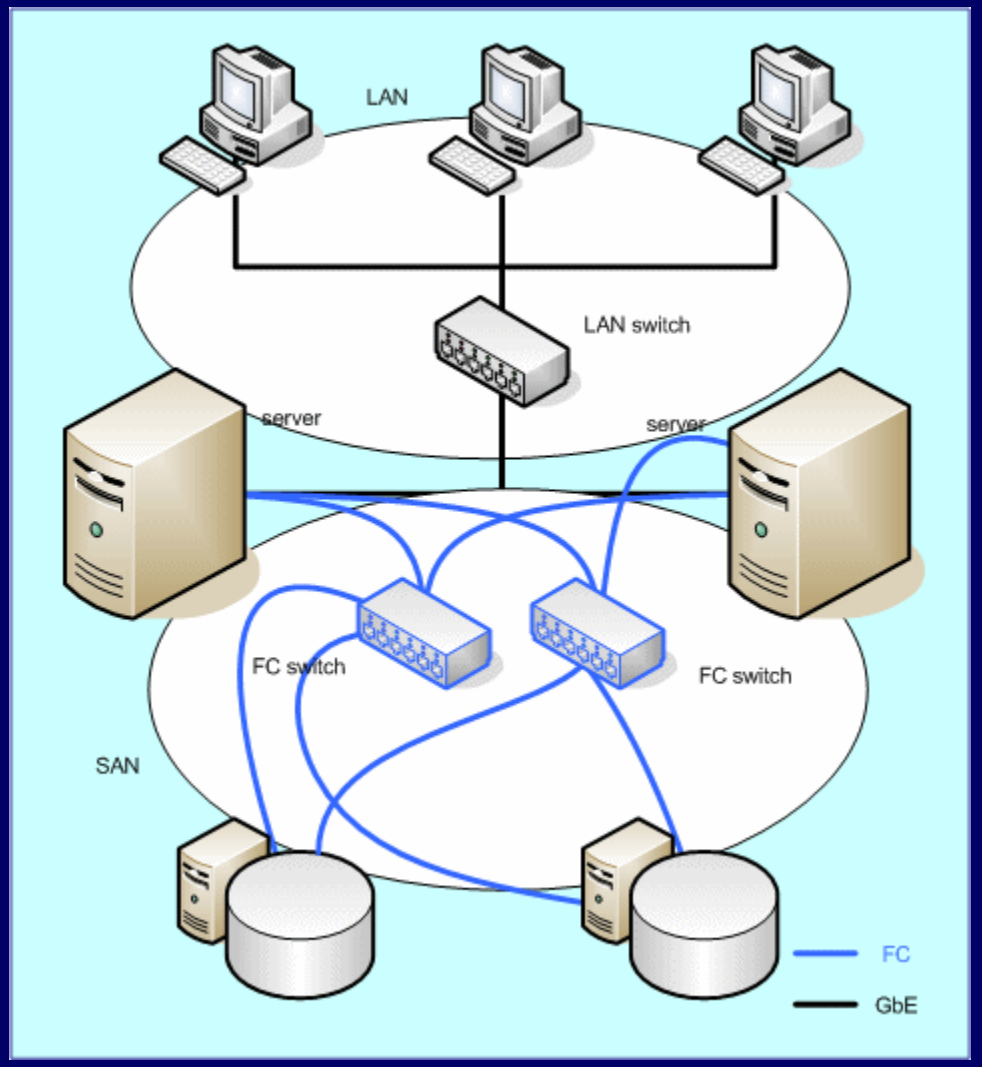

iSCSI

- SCSI + TCP/IP
- SCSI
  - protokol, bez fyzické vrstvy (kabely, konektory)
  - zapouzdření do protokolů TCP/IP
- gigabitový Ethernet vs. drahý Fibre Channel

- SCSI – adaptér, disk
- iSCSI – initiator (adapter), target (cílové zař. disk/pole)

iSCSI

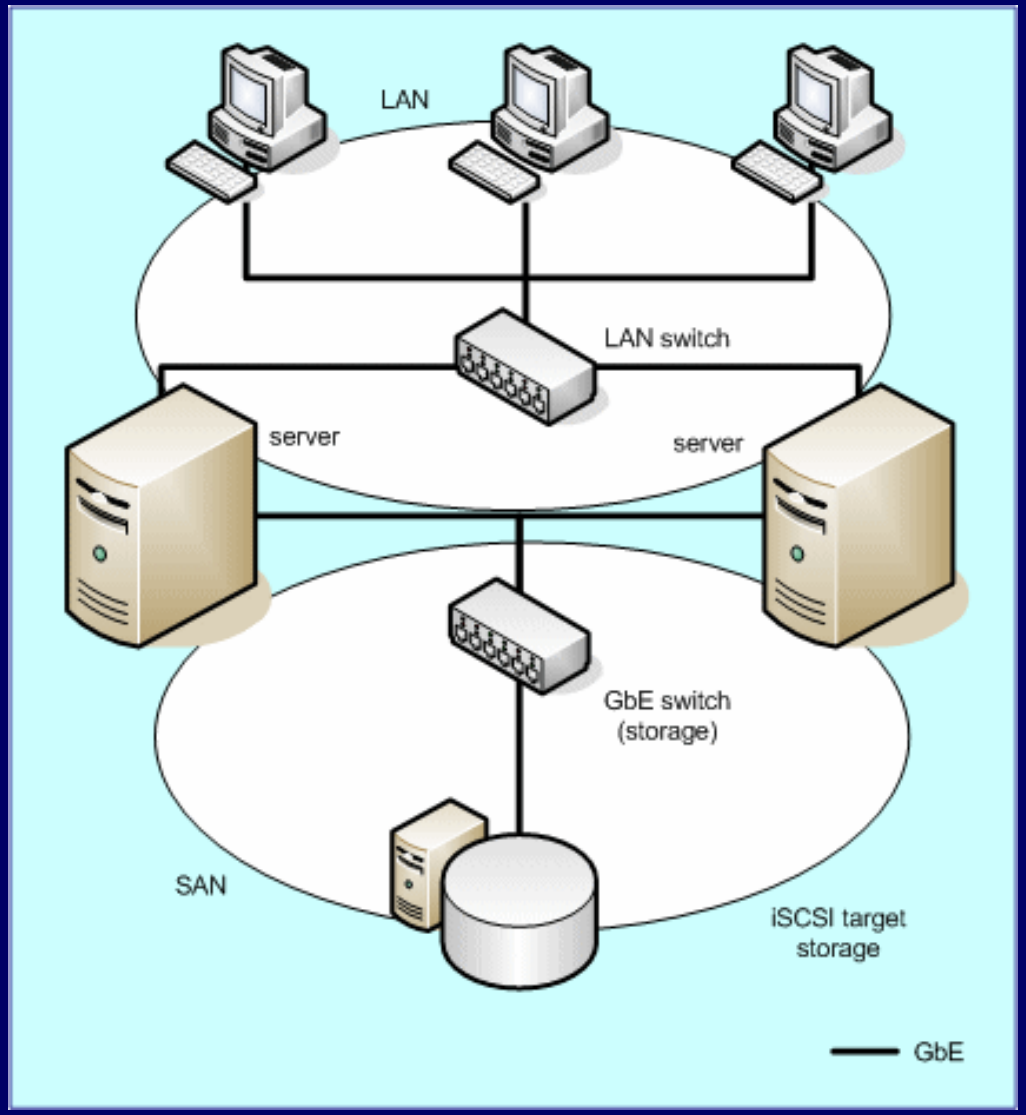
LAN
LAN switch
server
server
GbE switch
(storage)
SAN
iSCSI target
storage
GbE

Použité odkazy a další

- http://www.vahal.cz/html/raid.html

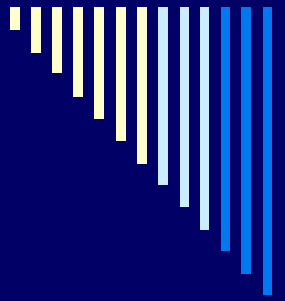

Principy I/O software

- typicky strukturován do 4 úrovní

1. obsluha přerušení (nejnižší úroveň v OS)
2. ovladač zařízení
3. SW vrstva OS nezávislá na zařízení
4. uživatelský I/O SW

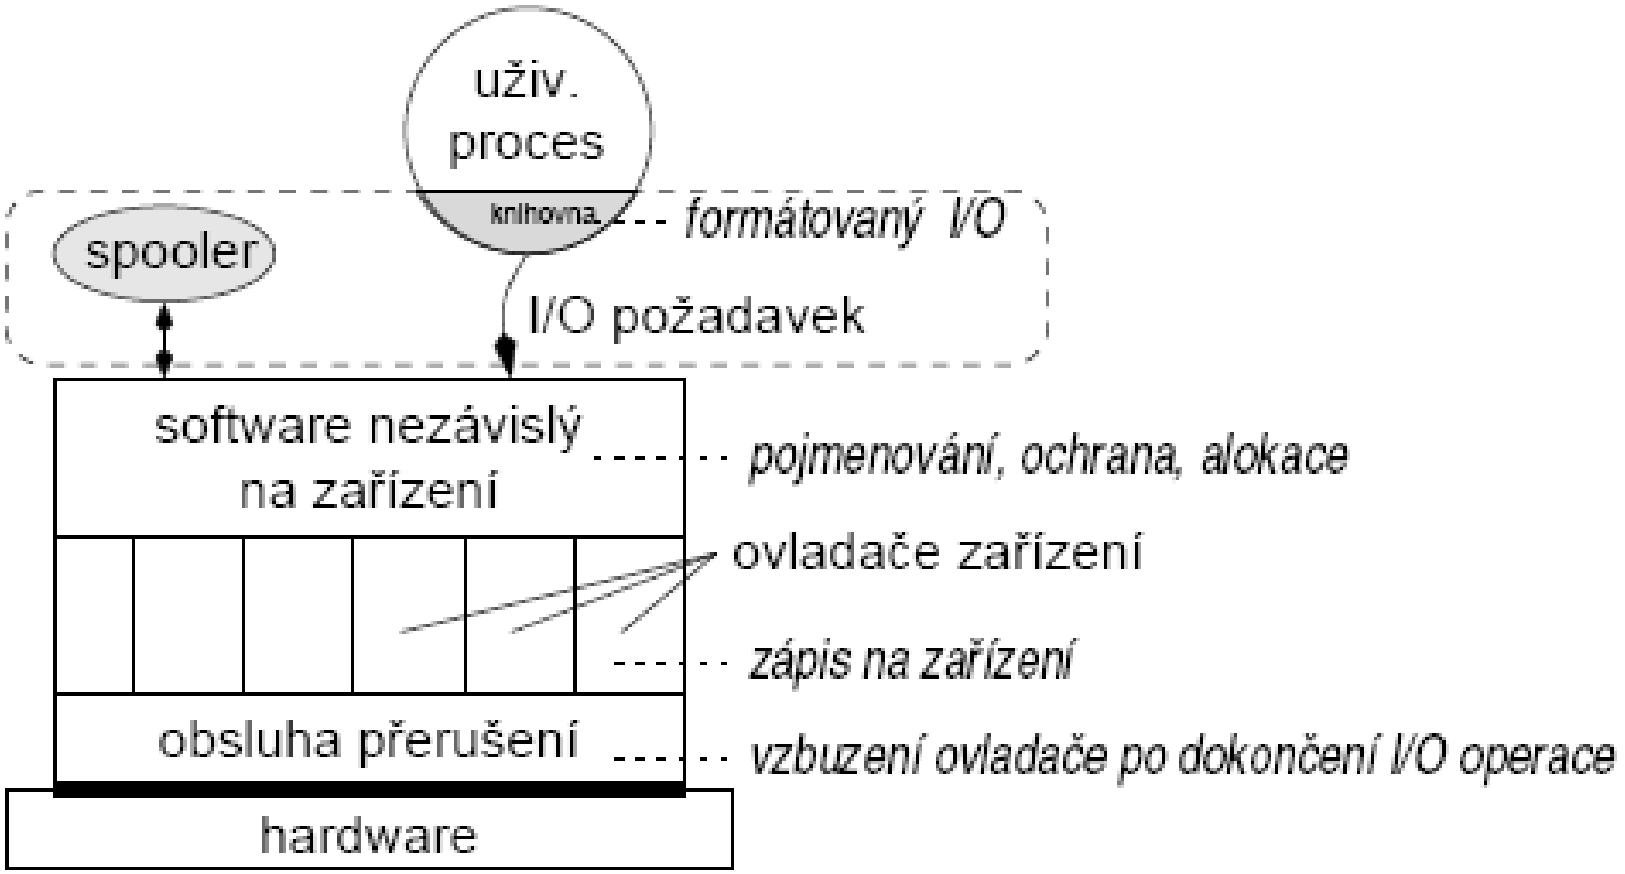
uživ.
proces
knihovna
formátovaný I/O
spooler
I/O požadavek
software nezávislý
na zařízení
pojmenování, ochrana, alokace
ovladače zařízení
zápis na zařízení
obsluha přerušení
vzbuzení ovladače po dokončení I/O operace
hardware

1. Obsluha přerušení

- řadič vyvolá přerušení ve chvíli dokončení I/O požadavku
- snaha, aby se přerušením nemusely zabývat vyšší vrstvy

- ovladač zadá I/O požadavek, usne (p(sem))
- po příchodu přerušení ho obsluha přerušení vzbudí (v)

- časově kritická obsluha přerušení – co nejkratší

2. Ovladače zařízení

- obsahují veškerý kod závislý na I/O zařízení
- ovladač zná jediný hw podrobnosti
  - způsob komunikace s řadičem zařízení
  - zná detaily – např. ví o sektorech a stopách na disku, pohybech diskového raménka, start & stop motoru
- ovládá všechna zařízení daného druhu nebo třídu příbuzných zařízení
  - např. ovladač SCSI disků – všechny SCSCI disky

Funkce ovladače zařízení

- ovladači předán příkaz vyšší vrstvou
  - např. zapiš data do bloku n
- nový požadavek zařazen do fronty
  - může ještě obsluhovat předchozí
- ovladač zadá příkazy řadiči (požadavek přijde na řadu)
  - např. nastavení hlavy, přečtení sektoru
- zablokuje se do vykonání požadavku
  - neblokuje při rychlých operacích – např. zápis do registru
- vzbuzení obsluhou přerušení (dokončení operace) – zkontroluje, zda nenastala chyba

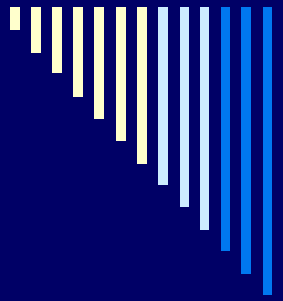

Funkce ovladače zařízení – pokrač.

- pokud OK, předá výsledek (status + data) vyšší vrstvě
  - status – datová struktura pro hlášení chyb
- další požadavky ve frontě – jeden vybere a spustí

- ovladače často vytvářejí výrobci HW
  - dobře definované rozhraní mezi OS a ovladači
- ovladače podobných zařízení – stejná rozhraní
  - např. sítové karty, zvukové karty, ...

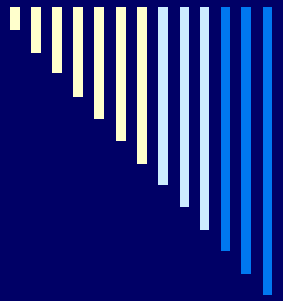

3. SW vrstva OS nezávislá na zařízení

- I/O funkce společné pro všechna zařízení daného druhu
  - např. společné fce pro všechna bloková zařízení
- definuje rozhraní s ovladači
- poskytuje jednotné rozhraní uživatelskému SW

- viz další slide…

Poskytované funkce

- pojmenování zařízení
  - LPT1 x /dev/lp0
- ochrana zařízení (přístupová práva)
- alokace a uvolnění vyhrazených zařízení
  - v 1 chvíli použitelná pouze jedním procesem
  - např. tiskárna, plotter, magnetická páska
- vyrovnávací paměti
  - bloková zařízení – bloky pevné délky
  - pomalá zařízení – čtení / zápis s využitím bufferu

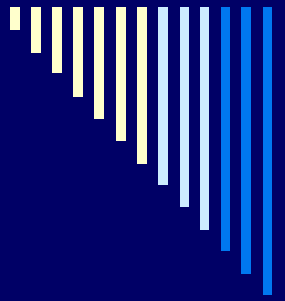

Poskytované funkce – pokračování

- hlášení chyb
- jednotná velikost bloku pro bloková zařízení

v moderních OS se zařízení jeví jako
objekty v souborovém systému
(v mnoha OS je tato vrstva součástí logického
souborového systému)

4. I/O sw v uživatelském režimu

- programátor používá v programech I/O funkce nebo příkazy jazyka
  - např. printf v C, writeln v Pascalu
  - knihovny sestavené s programem
  - formátování - printf("%.2d:%.2d\n", hodin, minut)
  - často vlastní vyrovnávací paměť na jeden blok
- spooling
  - implementován pomocí procesů běžících v uživ. režimu
  - způsob obsluhy vyhrazených I/O zařízení (multiprogram.)
  - např. proces by alokoval zařízení a pak hodinu nic nedělal

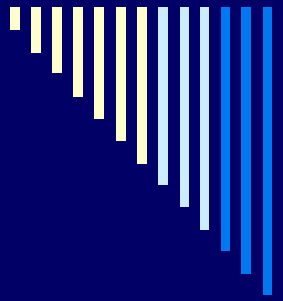

Příklad spoolingu – tisk Unix

- k tiskárně přístup – pouze 1 speciální proces
  - daemon lpd
- proces vygeneruje celý soubor, lpd ho vytiskne
  - proces chce tisknout, spustí lpr a naváže s ním komunikaci
  - proces předává tisknutá data programu lpr
  - lpr zapíše data do souboru v určeném adresáři
    - spooling directory – přístup jen lpr a lpd
  - dokončení zápisu – lpr oznámí lpd, že soubor je připraven k vytisknutí, lpd soubor vytiskne a zruší

tisk Unix

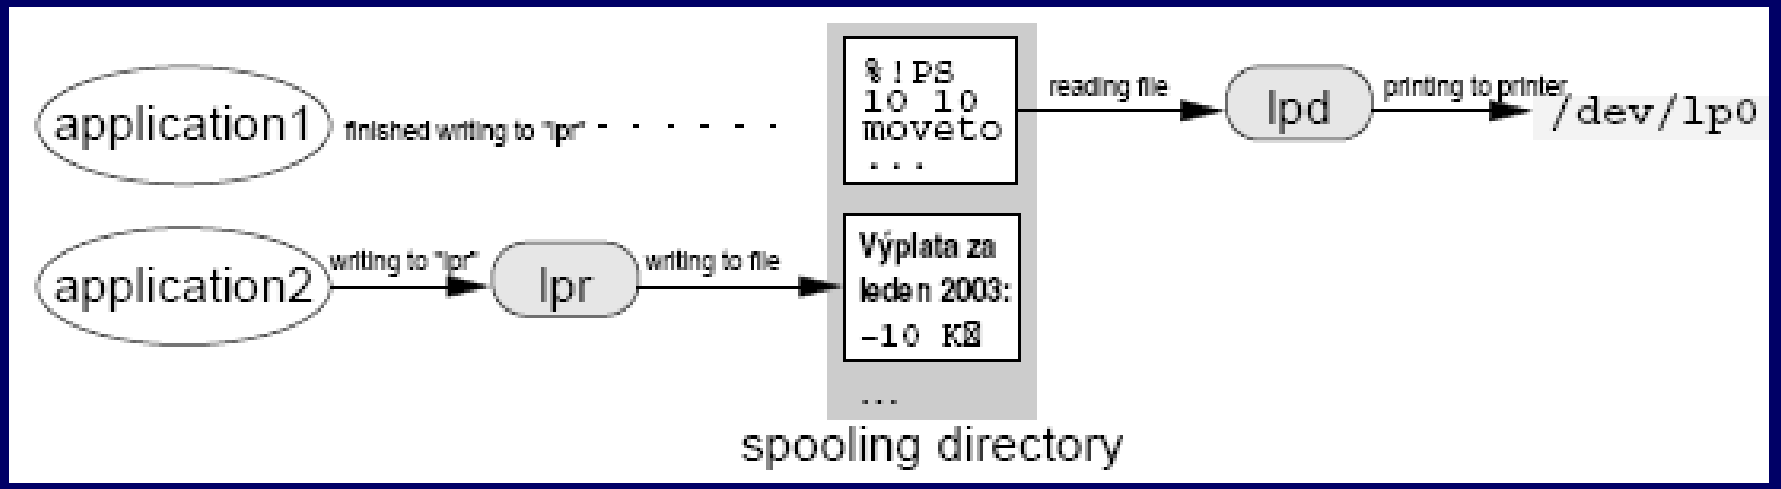

i další aplikace, spooling lze použít např. i pro přenos elektronické pošty

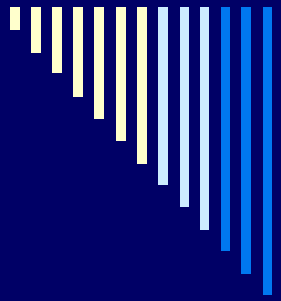

Souborové systémy

- potřeba aplikací trvale uchovávat data
- hlavní požadavky
  - možnost uložit velké množství dat
  - informace zachována i po ukončení procesu
  - data přístupná více procesům
- společné problémy při přístupu k zařízení
  - alokace prostoru na disku
  - pojmenování dat
  - ochrana dat před neoprávněným přístupem
  - zotavení po havárii (výpadek napájení)

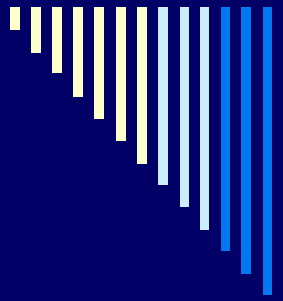

Soubor

- OS pro přístup k mediim poskytuje abstrakci od fyzických vlastností média – soubor
- soubor = pojmenovaná množina souvisejících informací
- souborový systém (file system, fs)
  - konvence pro ukládání a přístup k souborům
    - datové struktury a algoritmy
  - část OS, poskytuje mechanismus pro ukládání a přístup k datům, implementuje danou konvenci

File system

- Současné OS – implementují více fs
  - kompatibilita (starší verze, ostatní OS)
- Windows XP, Vista, 7, 8
  - základní je NTFS
  - ostatní: FAT12, FAT16, FAT32, ISO 9660 (CD-ROM)
- Linux
  - ext2, ext3, ext4, ReiserFS, JFS, XFS
  - ostatní: FAT12 až 32, ISO 9660, Minix, VxFS, OS/2 HPFS, SysV fs, UFS, NTFS

Historický vývoj

- první systémy
  - vstup – děrné štítky, výstup – tiskárna
  - soubor = množina děrných štítků
- později magnetické pásky
  - vstup i výstup – pásky
  - soubor = množina záznamů na magnetické pásce

Historický vývoj - pokračování

- nyní – data na magnetických a optických discích
  - ISO 2382-4:1987
  - soubor – pojmenovaná množina záznamů, které lze zpracovávat jako celek
  - záznam – strukturovaný datový objekt tvořený konečným počtem pojmenovaných položek

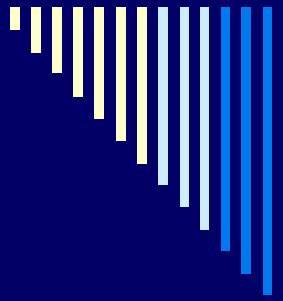

Uživatelské rozhraní fs

- vlastnosti fs z pohledu uživatele
  - konvence pro pojmenování souborů
  - vnitřní struktura souboru
  - typy souborů
  - způsob přístupu
  - atributy a přístupová práva
  - služby OS pro práci se soubory

Konvence pro pojmenování souborů

- vytvoření souboru – proces určuje jméno souboru
- různá pravidla pro vytváření jmen – různé OS
- Windows NT, XP x Unix a Linux

- rozlišuje systém malá a velká písmena?
  - Win32API nerozlišuje: ahoj, Ahoj, AHOJ stejná
  - UNIX rozlišuje: ahoj, Ahoj, AHOJ rozdílná jména

Pojmenování souborů

- jaká může být délka názvu souboru?
  - WinNT 256 znaků NTFS
  - UNIX obvykle alespoň 256 znaků (dle typu fs)
- množina znaků?
  - všechny běžné – názvy písmena a číslice
  - WinNT – znaková sada UNICODE
    - βετα – legální jméno souboru
  - Linux – všechny 8bitové znaky kromě / a char(0)

Pojmenování souborů

- přípony?
  - MS DOS – jméno souboru 8 znaků + 3 znaky přípona
  - WinNT, Unix – i více přípon
- další omezení?
  - WinNT – mezera nesmí být první a poslední znak

Typy souborů

- OS podporují více typů souborů
- obyčejné soubory – převážně dále rozebírány
  - data zapsaná aplikacemi
  - obvykle rozlišení textové x binární
  - textové - řádky textu ukončené CR (MAC), LF(UNIX), nebo CR+LF (MS DOS, Windows)
  - binární – všechny ostatní
  - OS rozumí struktuře spustitelných souborů

Typy souborů

- adresáře
  - systémové soubory, udržují strukturu fs
- Linux , UNIX ještě:
  - znakové speciální soubory
  - blokové speciální soubory
    - rozhraní pro I/O zařízení, /dev/lp0 – tiskárna
  - pojmenované roury
    - pro komunikaci mezi procesy
  - symbolické odkazy

Vnitřní struktura (obyčejného) souboru

- 3 časté způsoby
  - nestrukturovaná posloupnost bytů
  - posloupnost záznamů
  - strom záznamů

- nestrukturovaná posloupnost bytů
  - OS obsah souboru nezajímá, interpretace je na aplikacích
  - maximální flexibilita
    - programy mohou strukturovat, jak chtějí

Vnitřní struktura (obyčejného) souboru – pokrač.

- posloupnost záznamů pevné délky
  - každý záznam má vnitřní strukturu
  - operace čtení –vrátí záznam, zápis – změní / přidá záznam
  - v historických systémech
  - záznamy 80 znaků obsahovaly obraz děrných štítků
  - v současných systémech se téměř nepoužívá

Vnitřní struktura (obyčejného) souboru – pokrač.

- strom záznamů
  - záznamy nemusejí mít stejnou délku
  - záznam obsahuje pole klíč (na pevné pozici v záznamu)
  - záznamy seřazeny podle klíče, aby bylo možné vyhledat záznam s požadovaným klíčem
  - mainframy pro komerční zpracování dat

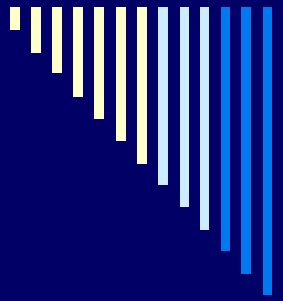

Způsob přístupu k souboru

- sekvenční přístup
  - procesy mohou číst data pouze v pořadí, v jakém jsou uloženy v souboru
  - tj. od prvního záznamu, nemohou přeskakovat
  - možnost přetočit a číst opět od začátku, rewind()
  - v prvních OS, kde data na magnetických páskách

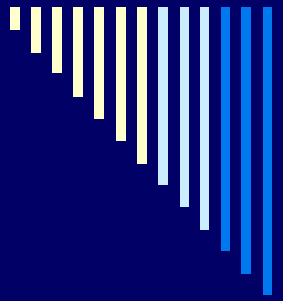

Způsob přístupu k souboru

- přímý přístup (random access file)
  - čtení v libovolném pořadí nebo podle klíče
  - přímý přístup je nutný např. pro databáze
  - určení začátku čtení
    - každá operace určuje pozici
    - OS udržuje pozici čtení / zápisu, novou pozici lze nastavit speciální operací „seek“

Způsob přístupu k souboru

- v některých OS pro mainframy – při vytvoření souboru se určilo, zda je sekvenční nebo s přímým přístupem
  - OS mohl používat rozdílné strategie uložení souboru
- všechny současné OS – soubory s přímým přístupem

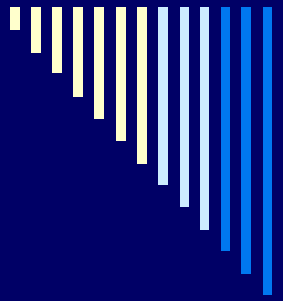

Atributy

- informace sdružená se souborem
- některé atributy interpretuje OS, jiné systémové programy a aplikace
- významně se liší mezi jednotlivými OS

- ochrana souboru
  - kdo je vlastníkem, množina přístupových práv, heslo, ...

Atributy - pokračování

- příznaky
  - určují vlastnosti souboru
  - hidden – neobjeví se při výpisu
  - archive – soubor nebyl zálohován
  - temporary – soubor bude automaticky zrušen
  - read-only, text/binary, random access
- přístup k záznamu pomocí klíče
  - délka záznamu, pozice a délka klíče
- velikost, datum vytvoření, poslední modifikace, poslední přístup

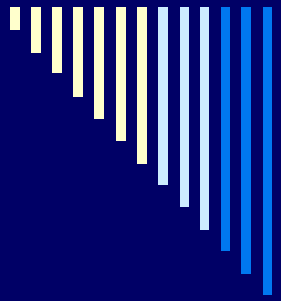

Služby OS pro práci se soubory

- většina současných – základní model dle UNIXu
- základní filozofie UNIXu – méně je někdy více

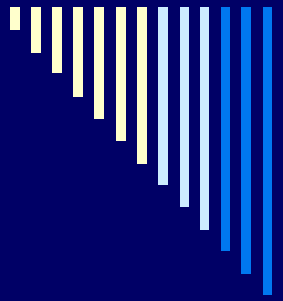

Několik jednoduchých pravidel

- veškerý I/O prováděn pouze pomocí souborů
  - obyčejné soubory – data, spustitelné programy
  - zařízení – disky, tiskárny
  - se všemi typy zacházení pomocí **stejných** služeb systému
- obyčejný soubor – uspořádaná posloupnost bytů
  - význam znají pouze programy, které s ním pracují
  - interní struktura souboru OS nezajímá
- jeden typ souboru – seznam souborů – adresář
  - adresář je také soubor
  - soubory a adresáře koncepčně umístěny v adresáři

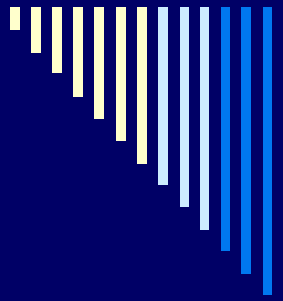

Jednotný přístup nebyl vždy

- speciální soubory – pro přístup k zařízením
  - DOS – PRN:, COM1:
- Poznámka – před příchodem UNIXu toto samozřejné nebylo
- většina systémů před UNIXem – samostatné služby pro čtení / zápis terminálu, na tiskárnu do souboru
- mnoho systémů před i po UNIXu – mnoho různých druhů souborů s různou strukturou a metodami přístupu

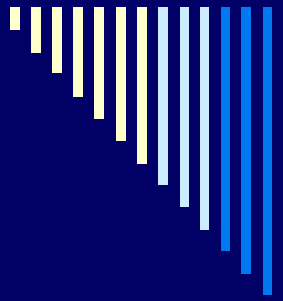

Poznámky

- systémy poskytovaly „více služeb“ x model podle UNIXu – podstatně menší složitost
- téměř všechny moderní systémy základní rysy modelu převzaly

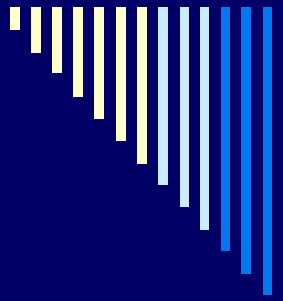

Základní služby pro práci se soubory

- otevření souboru
  - než s ním začneme pracovat
  - úspěšné – vrátí služba pro otevření souboru – popisovač souboru (file descriptor) – malé celé číslo
  - popisovač souboru používáme v dalších službách
    - čtení apod.

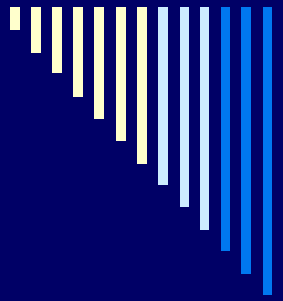

Základní služby pro práci se soubory

otevření souboru:

- *fd = open (jmeno, způsob)*
  - jméno – řetězec pojmenovávající soubor
  - způsob – pouze pro čtení, zápis, obojí
  - fd – vrácený popisovač souboru

- otevření souboru nalezne informace o souboru na disku a vytvoří pro soubor potřebné datové struktury
- popisovač souboru – index to tabulky souborů uvnitř OS

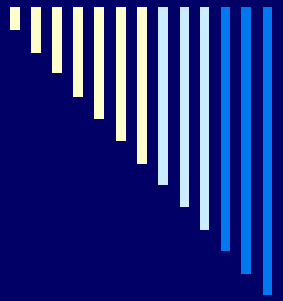

Základní služby pro práci se soubory

vytvoření souboru:

- fd=creat(jméno, práva)
  - vytvoří nový soubor s daným jménem a otevře pro zápis
  - pokud soubor existoval – zkrátí na nulovou délku
  - fd – vrácený popisovač souboru

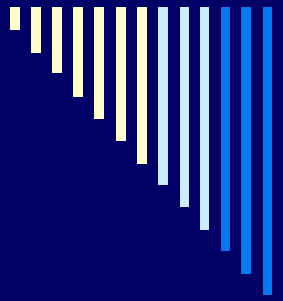

Základní služby pro práci se soubory

- operace **čtení** ze souboru:

- read(fd, buffer, počet_bytů)
  - přečte *počet_bytů* ze souboru *fd* do *bufferu*
  - může přečíst méně – zbývá v souboru méně
  - přečte 0 bytů – konec souboru

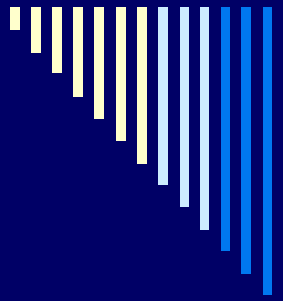

Základní služby pro práci se soubory

- operace **zápisu** do souboru
- write (fd, buffer, počet_bytů)
  - význam parametrů jako u read
  - Uprostřed souboru – přepíše, konec – prodlouží
- read() a write()
  - vrací počet skutečně zpracovaných bytů
  - jediné operace pro čtení a zápis
  - samy o sobě poskytují sekvenční přístup k souboru

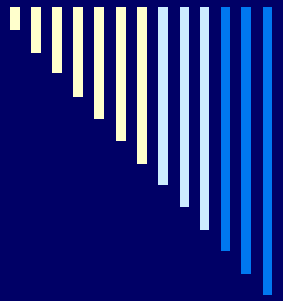

Základní služby pro práci se soubory

- **nastavení pozice** v souboru:
- lseek (fd, offset, odkud)
- nastaví offset příští čtené/zapisované slabiky souboru
- odkud
  - od začátku souboru
  - od konce souboru (záporný offset)
  - od aktuální pozice
- poskytuje přímý přístup k souboru

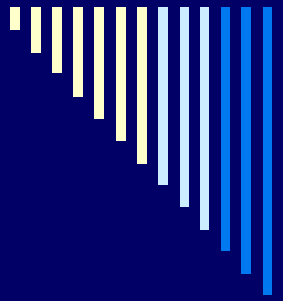

Základní služby pro práci se soubory

- **zavření** souboru
- close (fd)
- uvolní datové struktury alokované OS pro soubor

Příklad použití rozhraní – kopírování souboru

```
int src, dst, in;
src = open(”puvodni”, O_RDONLY);          /* otevreni zdrojoveho */
dst = creat(”novy”, MODE);                /* vytvoreni ciloveho */
while (1)
{
in = read(src, buffer, sizeof(buffer));    /* cteme */
if (in == 0)                              /* konec souboru? */
  {
     close(src);                          /* zavreme soubory */
     close(dst);
     return;                              /* ukončení */
  }
write(dst, buffer, in);                   /* zapiseme prectena data */
}
```

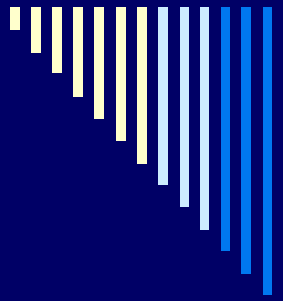

Další služby pro práci se soubory

- změna přístupových práv, zamykání, ...
- závislé na konkrétních mechanismech ochrany
- např. UNIX

  - **zamykání** fcntl (fd, cmd)

  - **zjištění informací** o souboru (typ, příst. práva, velikost)
  - stat (file_name, buf), fstat (fd, buf)
  - *man stat, man fstat*

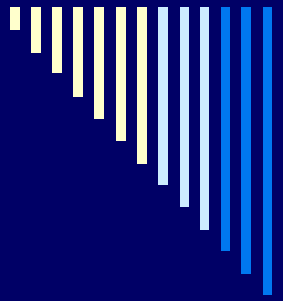

Paměťově mapované soubory

- někdy se může zdát open/read/write/close nepohodlné
- možnost mapování souboru do adresního prostoru procesu
- služby systému mmap(), munmap()
- mapovat je možné i jen část souboru

Paměťově mapované soubory - příklad

- délka stránky 4KB
- soubor délky 64KB
- chceme mapovat do adresního prostoru od 512KB
- 512 * 1024 = 524 288 .. od této adresy mapujeme
- 0 až 4KB souboru bude mapováno na 512KB – 516KB
- čtení z 524 288 čte byte 0 souboru atd.

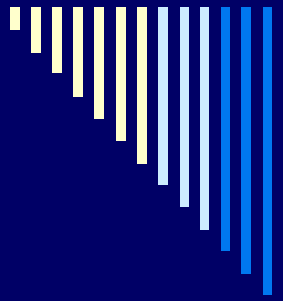

Implementace paměťově mapovaných souborů

- OS použije soubor jako odkládací prostor (swapping area) pro určenou část virtuálního adresního prostoru
- čtení / zápis na adr. 524 288 způsobí výpadek stránky
- do rámce se načte obsah první stránky souboru
- pokud je modifikovaná stránka vyhozena (nedostatek volných rámců), zapíše se do souboru
- po skončení práce se souborem se zapíší všechny modifikované stránky

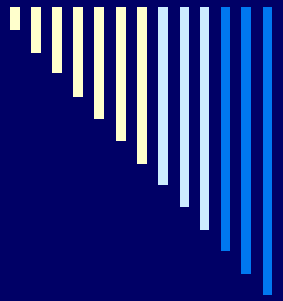

Problémy pam. map. souborů

- není známa přesná velikost souboru, nejmenší jednotka je stránka
- problém nekonzistence pohledů na soubor, pokud je zároveň mapován a zároveň se k němu přistupuje klasickým způsobem

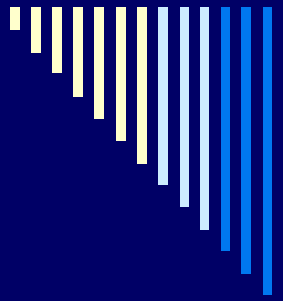

Adresářová struktura

- jedna oblast (partition) disku obsahuje jeden fs
- fs – 2 součásti:
  - množina souborů, obsahujících data
  - adresářová struktura – udržuje informace o všech souborech v daném fs
- adresář překládá jméno souboru na informace o souboru (umístění, velikost, typ ...)

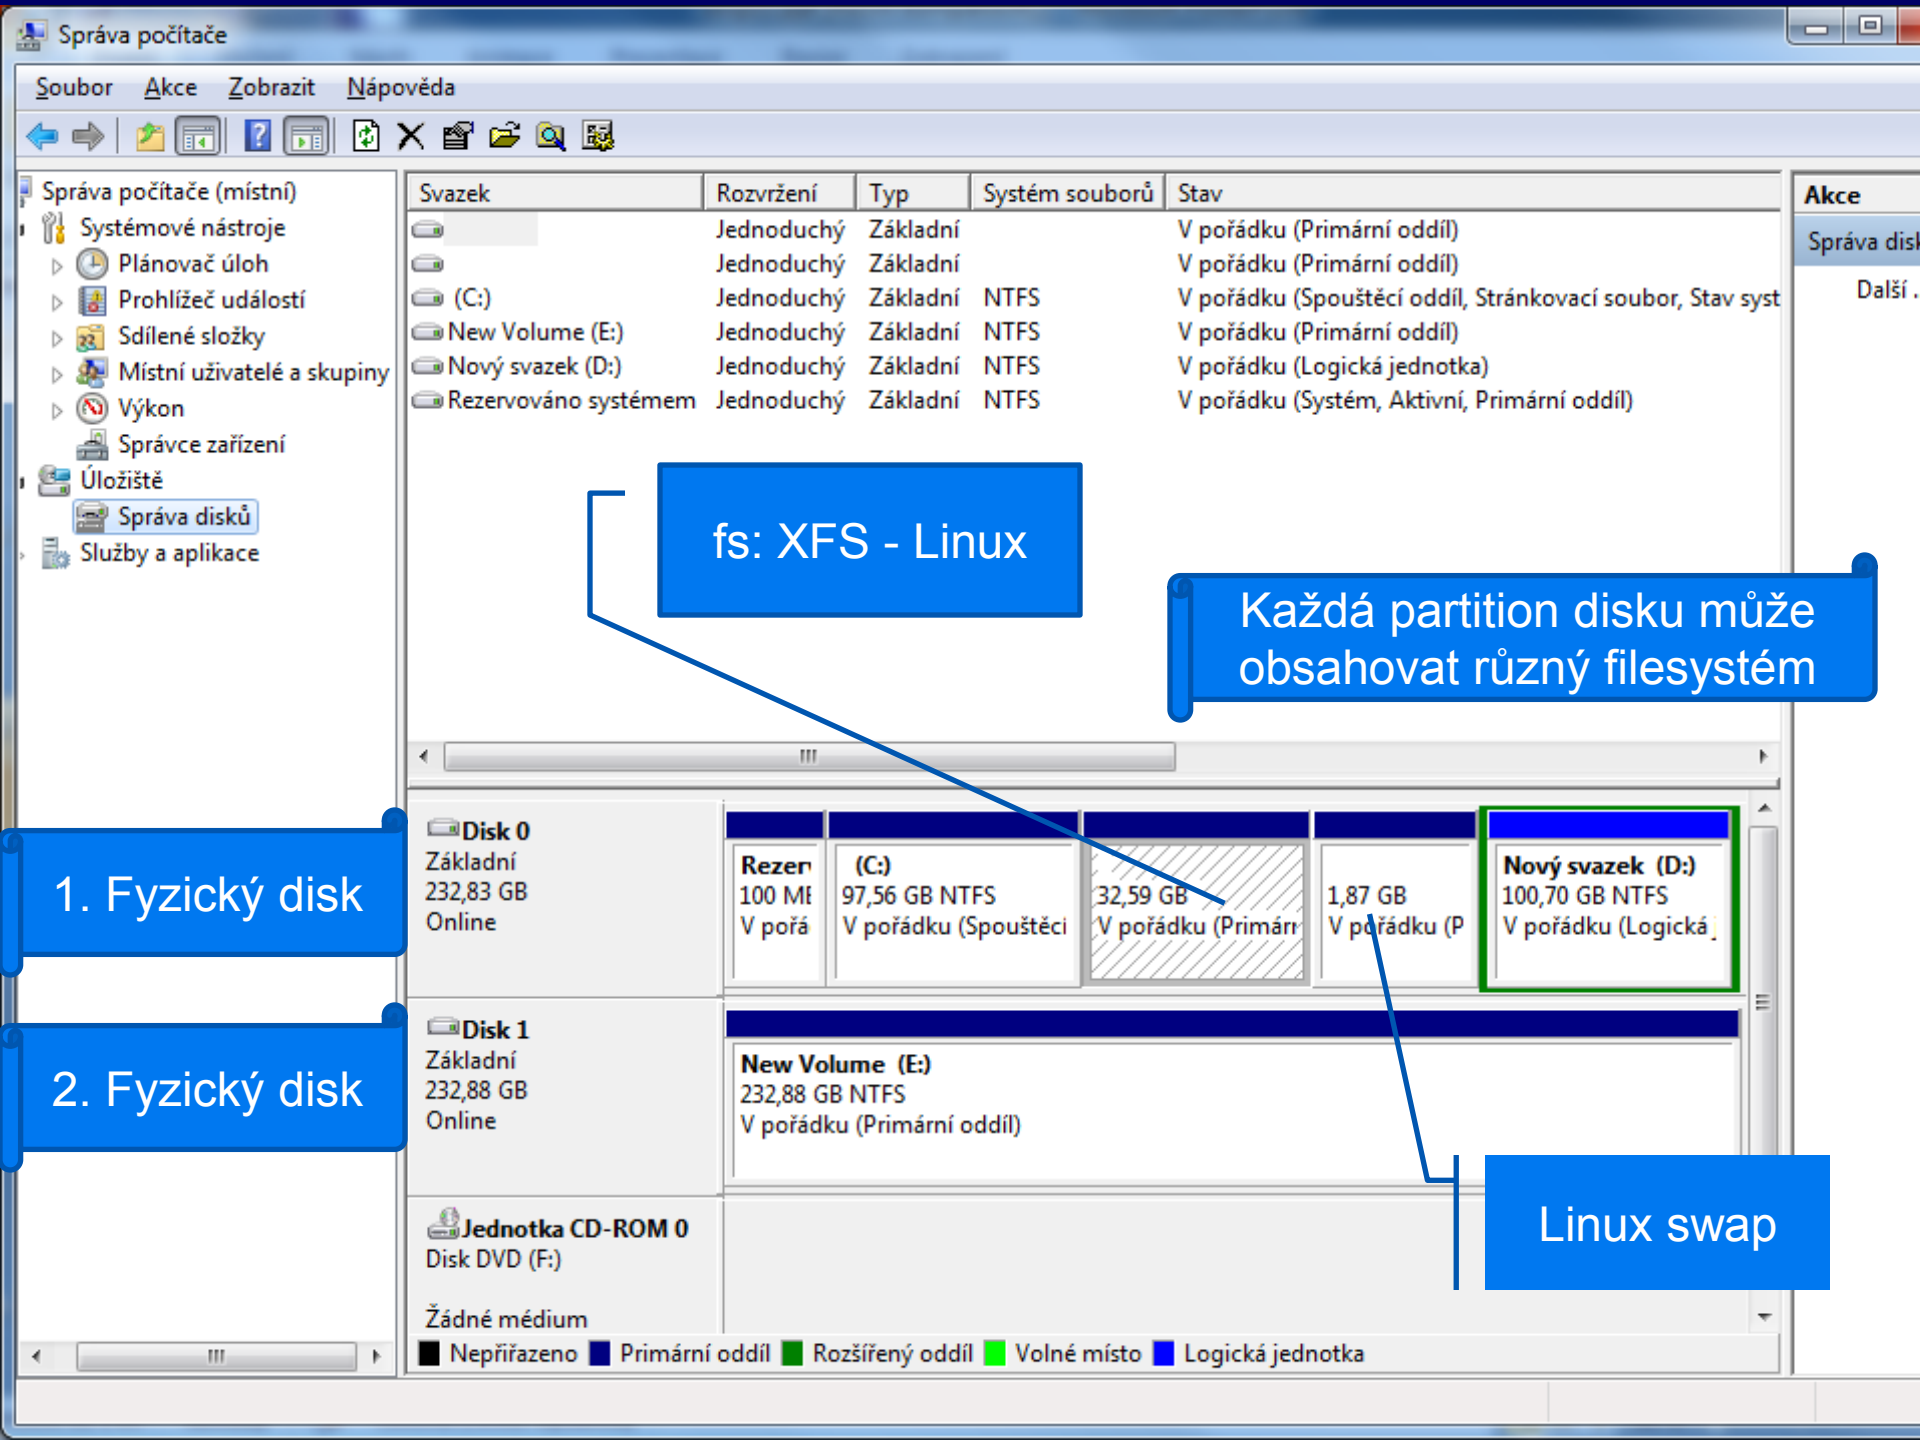
Správa počítače
Soubor Akce Zobrazit Nápověda
Správa počítače (místní)
Systémové nástroje
Plánovač úloh
Prohlížeč událostí
Sdílené složky
Místní uživatelé a skupiny
Výkon
Správce zařízení
Úložiště
Správa disků
Služby a aplikace
Svazek | Rozvržení | Typ | Systém souborů | Stav
Jednoduchý Základní V pořádku (Primární oddíl)
Jednoduchý Základní V pořádku (Primární oddíl)
(C:) Jednoduchý Základní NTFS V pořádku (Spouštěcí oddíl, Stránkovací soubor, Stav syst
New Volume (E:) Jednoduchý Základní NTFS V pořádku (Primární oddíl)
Nový svazek (D:) Jednoduchý Základní NTFS V pořádku (Logická jednotka)
Rezervováno systémem Jednoduchý Základní NTFS V pořádku (Systém, Aktivní, Primární oddíl)
Akce
Správa disk
Další
fs: XFS - Linux
Každá partition disku může obsahovat různý filesystém
1. Fyzický disk
Disk 0
Základní
232,83 GB
Online
Rezer
100 MB
V pořá
(C:)
97,56 GB NTFS
V pořádku (Spouštěcí
32,59 GB
V pořádku (Primár
1,87 GB
V pořádku (P
Nový svazek (D:)
100,70 GB NTFS
V pořádku (Logická
2. Fyzický disk
Disk 1
Základní
232,88 GB
Online
New Volume (E:)
232,88 GB NTFS
V pořádku (Primární oddíl)
Linux swap
Jednotka CD-ROM 0
Disk DVD (F:)
Žádné médium
Nepřiřazeno Primární oddíl Rozšířený oddíl Volné místo Logická jednotka

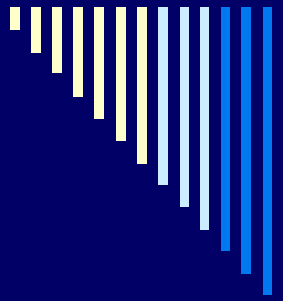

Základní požadavky na adresář

- procházení souborovým systémem (*cd*)
- výpis adresáře (*ls*)
- vytvoření a zrušení souboru
- přejmenování souboru

- dále schémata logické struktury adresářů
  - odpovídá historickému vývoji OS

Schémata logické struktury adresářů

- jednoúrovňový adresář
- původní verze MS DOSu
- všechny soubory jsou v jediném adresáři
- všechny soubory musejí mít jedinečná jména
- problém zejména pokud více uživatelů

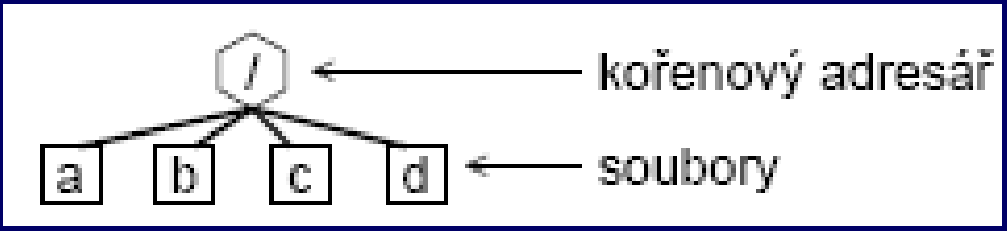

nelze mít dva soubory priklad.c

Dvouúrovňový adresář

- adresář pro každého uživatele (User File Directory, UFD)
- OS prohledává pouze UFD , nebo pokud specifikováno adresář jiného uživatele [user] file
- systémové příkazy – spustitelné soubory – speciální adresář
  - příkaz se hledá v adresáři uživatele
  - pokud zde není, vyhledá se v systémovém adresáři

Dvouúrovňový adresář – pokr.

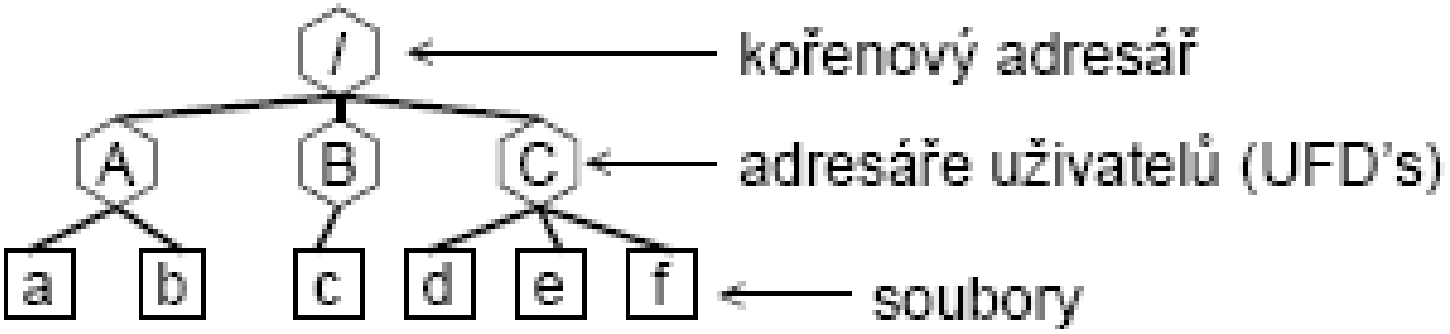

každý uživatel může být nanejvýš jeden soubor nazvaný priklad.c

Adresářový strom

- zobecnění předchozího
- dnes nejčastější, MS DOS, Windows NT
- adresář – množina souborů a adresářů
- souborový systém začíná kořenovým adresářem „/“
- MS DOS „\“, znak / se používal pro volby
- cesta k souboru – jméno v open, creat
  - absolutní
  - relativní

Cesta k souboru

absolutní cesta začíná:
/ (Linux)
C:\ (windows)

- absolutní
  - kořenový adresář a adresáře, kudy je třeba projít, název souboru
  - oddělovače adresářů – znak „/“
  - např. /home/user/data/v1/data12.txt
- relativní
  - aplikace většinou přistupují k souborům v jednom adresáři
  - defaultní prefix = pracovní adresář
  - cesta nezačíná znakem /
  - př. *data12.txt* , *data/v1/data12.txt*

Acyklický graf adresářů

- např. týmová spolupráce na určitém projektu
- sdílení společného souboru nebo podadresáře
  - stejný soubor (adr.) může být viděn ve dvou různých adresářích

- flexibilnější než strom, komplikovanější
- rušení souborů / adresářů – kdy můžeme zrušit?
  - se souborem sdružen počet odkazů na soubor z adresářů
  - každé remove sníží o 1, 0 = není odkazován
- jak zajistit aby byl graf acyklický?
  - algoritmy pro zjištění, drahé pro fs

Acyklický graf adresářů

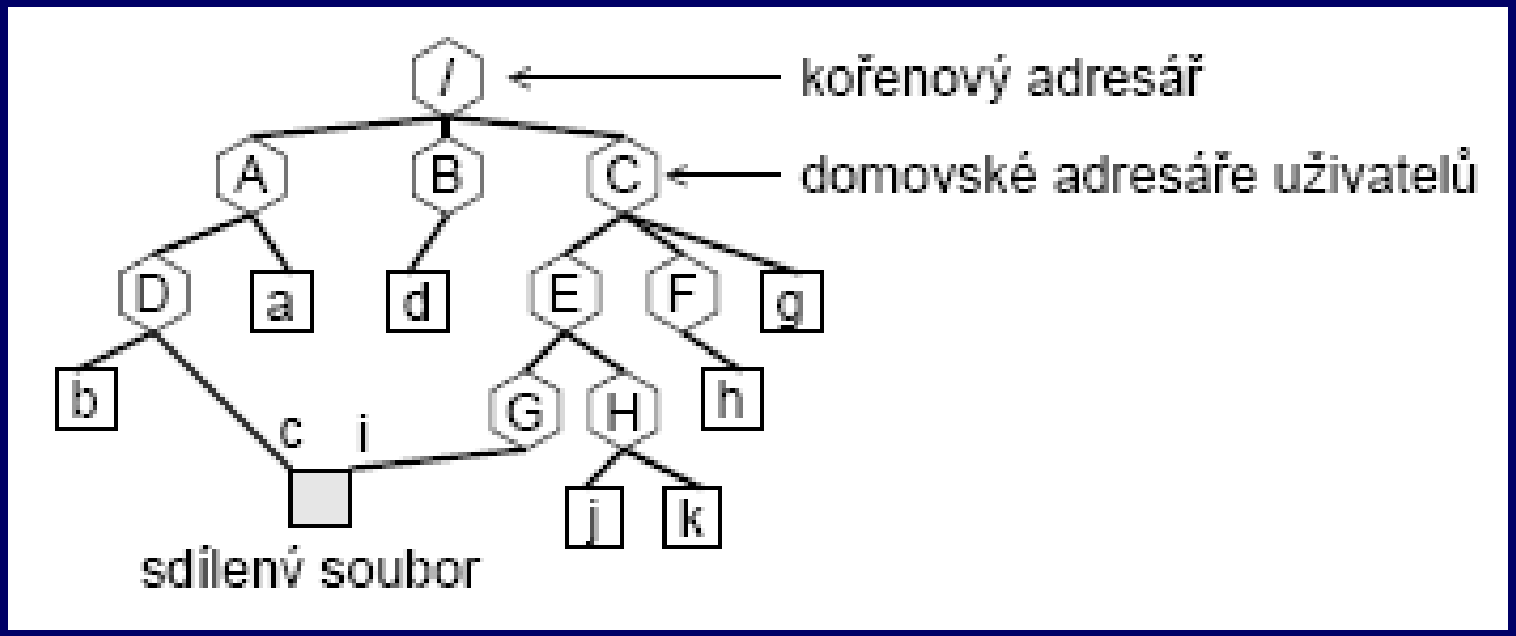

stejný soubor viděný v různých cestách

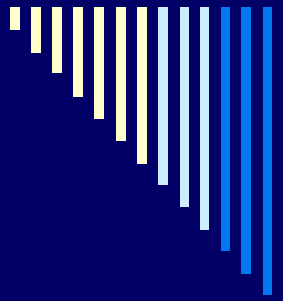

Obecný graf adresářů

- obtížné zajistit, aby graf byl acyklický
- prohledávání grafu
  - omezení počtu prošlých adresářů (Linux)
- rušení souboru
  - pokud cyklus, může být počet odkazů > 0 i když je soubor již není přístupný
  - garbage collection – projít celý fs, označit všechny přístupné soubory; zrušit nepřístupné; (drahé, zřídka používáno)

Nejčastější použití

- nejčastěji adresářový strom (MS DOS)
- UNIX od původních verzí acyklický graf
  hard links – sdílení pouze souborů – nemohou vzniknout cykly

POZOR!

Je nutné si uvědomit rozdíl mezi pojmy adresářový strom a acyklický graf.

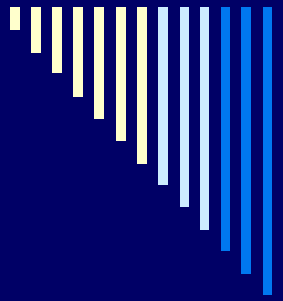

Základní služby pro práci s adresáři

- téměř všechny systémy dle UNIXu
- pracovní adresář – služby:
- chdir (adresář)
  - nastavení pracovního adresáře
- getcwd (buffer, počet_znaků)
  - zjištění pracovního adresáře

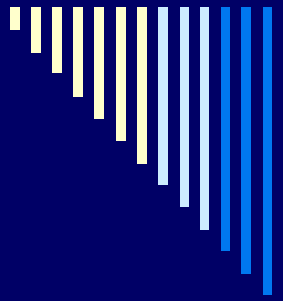

Práce s adresářovou strukturou

- vytváření a rušení adresářů
  - mkdir (adresář, přístupová_práva)
  - rmdir (adresář) – musí být prázdný
- zrušení souboru
  - remove (jméno_souboru)
- přejmenování souboru
  - rename (jméno_souboru, nové_jméno)
  - provádí také přesun mezi adresáři

Práce s adresářovou strukturou

- čtení adresářů – UNIX / POSIX
  - DIRp = opendir (adresář)
    - otevře adresář
  - položka = readdir (DIRp)
    - čte jednotlivé položky adresáře
  - closedir (DIRp)
    - zavře adresář
  - stat (jméno_souboru, statbuf)
    - info o souboru, viz man 2 stat
- př. DOS: findfirst / findnext

ke všem uvedeným voláním získáte v Linuxu podrobnosti pomocí:

man 2 opendir
man 2 readdir
man 2 stat

Implementace souborových systémů (!!!)

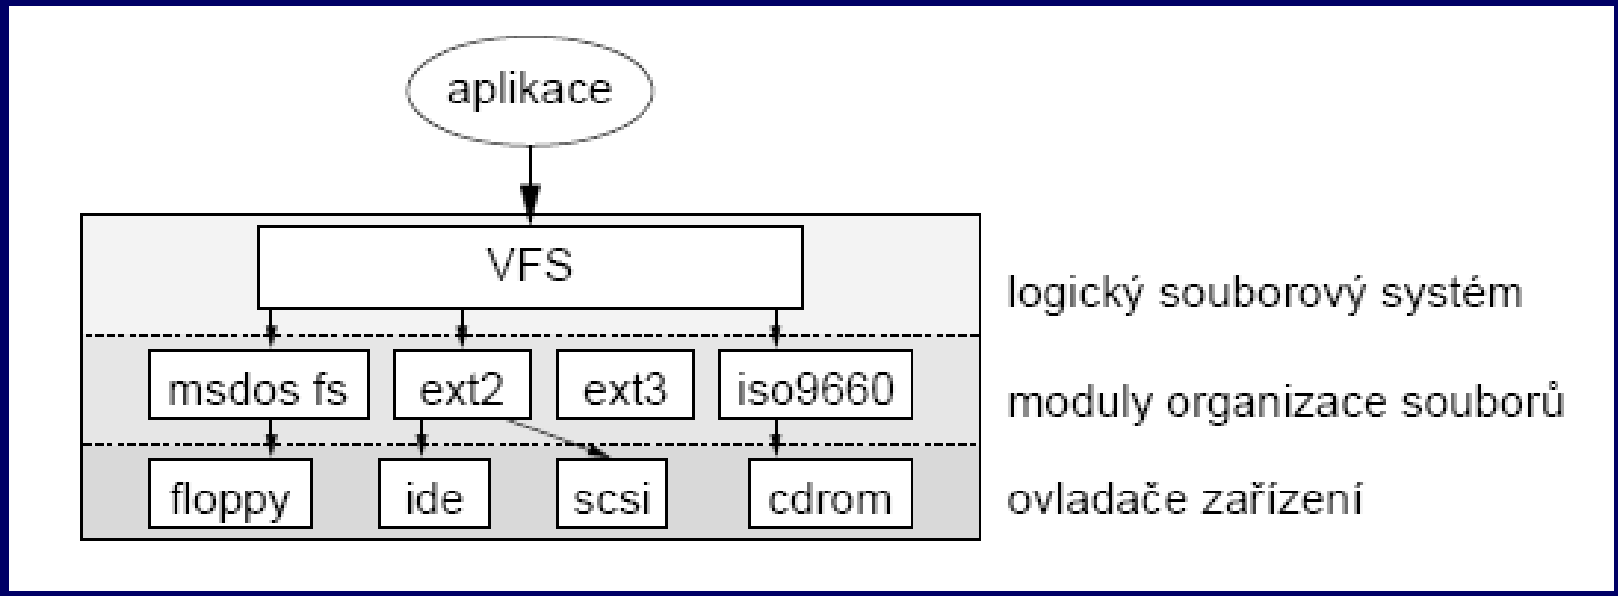

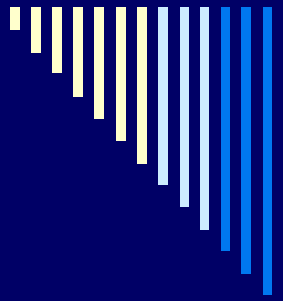

Implementace fs - vrstvy

1. Logický (virtuální) souborový systém
   - Volán aplikacemi
2. Modul organizace souborů
   - Konkrétní souborový systém (např. ext3)
3. Ovladače zařízení
   - Pracuje s daným zařízením
   - Přečte/zapíše logický blok

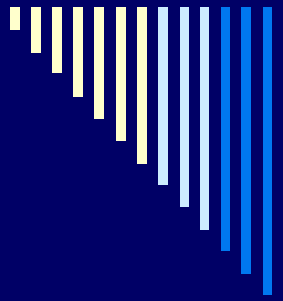

Ad 1 – virtuální fs

- Volán aplikacemi
- Rozhraní s moduly organizace souborů
- Obsahuje kód společný pro všechny typy fs
- Převádí jméno souboru na informaci o souboru
- Udržuje informaci o otevřeném souboru
  - Pro čtení / zápis (režim)
  - Pozice v souboru
- Ochrana a bezpečnost (ověřování přístupových práv)

Ad 2 – modul organizace souborů

- Implementuje konkrétní souborový systém
  - ext3, xfs, ntfs, fat, ..
- Čte/zapisuje datové bloky souboru
  - Číslovány O až N-1
  - Převod čísla bloku na diskovou adresu
  - Volání ovladače pro čtení – zápis bloku
- Správa volného prostoru + alokace volných bloků
- Údržba datových struktur filesystému

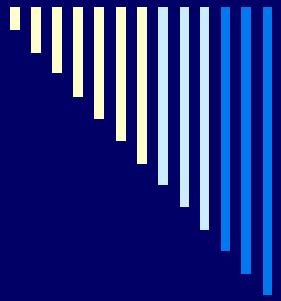

Ad 3 – ovladače zařízení

- Nejnižší úroveň
- Floppy, ide, scsi, cdrom
- Interpretují požadavky:
  přečti logický blok 6456 ze zařízení 3

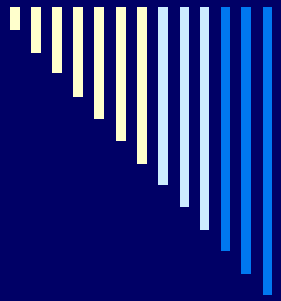

Implementace souborů

- Nejdůležitější:
  které diskové bloky patří kterému souboru ☺
- Předpokládáme:
  fs je umístěn v nějaké disk partition
  bloky v oblasti jsou očíslovány od 0

Kontinuální alokace

- Soubor jako kontinuální posloupnost diskových bloků
- Př.: bloky velikosti 1KB, soubor A (4KB) by zabíral 4 po sobě následující bloky
- Implementace
  - Potřebujeme znát číslo prvního bloku
  - Znát celkový počet bloků souboru (např. v adresáři)
- Velmi rychlé čtení
  - Hlavičku disku na začátek souboru, čtené bloky jsou za sebou

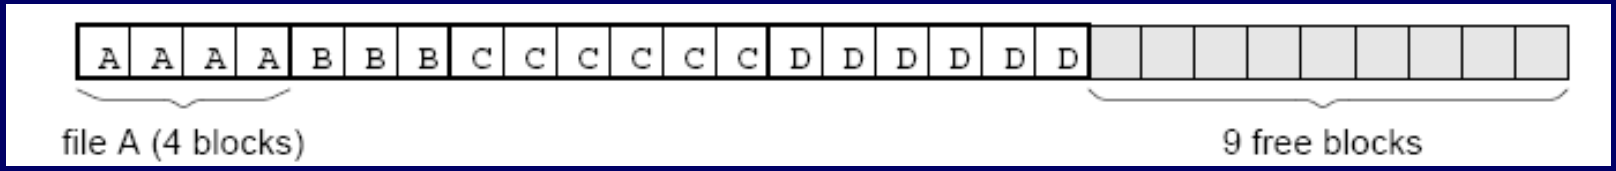

Kontinuální alokace

- Problém – dynamičnost OS
  – soubory vznikají, zanikají, mění velikost

- Nejprve zapisovat sériově do volného místa na konci
- Po zaplnění využít volné místo po zrušených souborech
- Pro výběr vhodné díry – potřebujeme znát konečnou délku souboru – většinou nevíme..

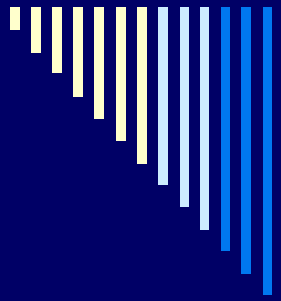

Lze dnes využít kontinuální alokaci?

- Dnes se používá pouze na read-only a write-once médiích
- Např. v ISO 9660 pro CD ROM

Seznam diskových bloků

- Svázat diskové bloky do seznamu – nebude vnější fragmentace
- Na začátku diskového bloku je uložen odkaz na další blok souboru, zbytek bloku obsahuje data souboru
- Pro přístup k souboru stačí znát pouze číslo prvního bloku souboru (může být v adresáři)

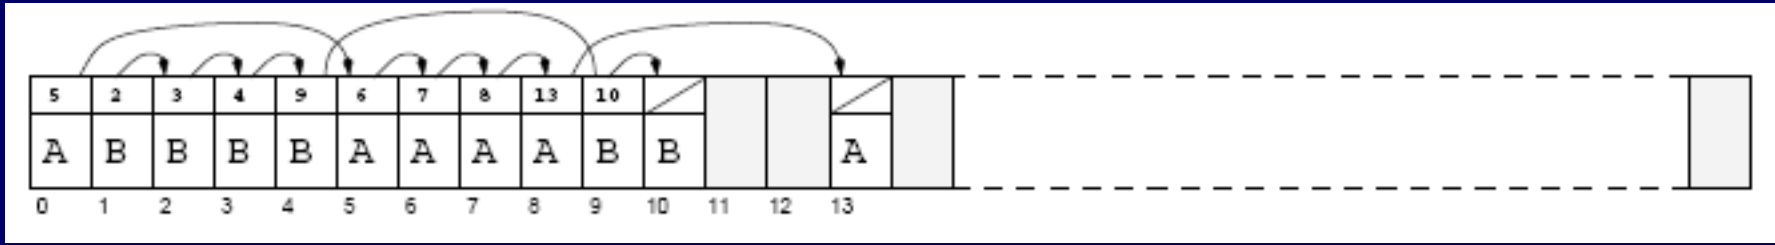

Seznam diskových bloků

- Sekvenční čtení – bez potíží
- Přímý přístup – simulován sekvenčním, pomalé (musí dojít ke správnému bloku)

- Velikost dat v bloku není mocnina dvou
  - Část bloku je zabraná odkazem na další blok
  - Někdy může být nevýhodou

FAT (!!)

- Přesunutí odkazů do samostatné tabulky FAT
- FAT (File Allocation Table)
  - Každému diskovému bloku odpovídá jedna položka ve FAT tabulce
  - Položka FAT obsahuje číslo dalšího bloku souboru (je zároveň odkazem na další položku FAT!)
  - Řetězec odkazů je ukončen speciální značkou, která není platným číslem bloku

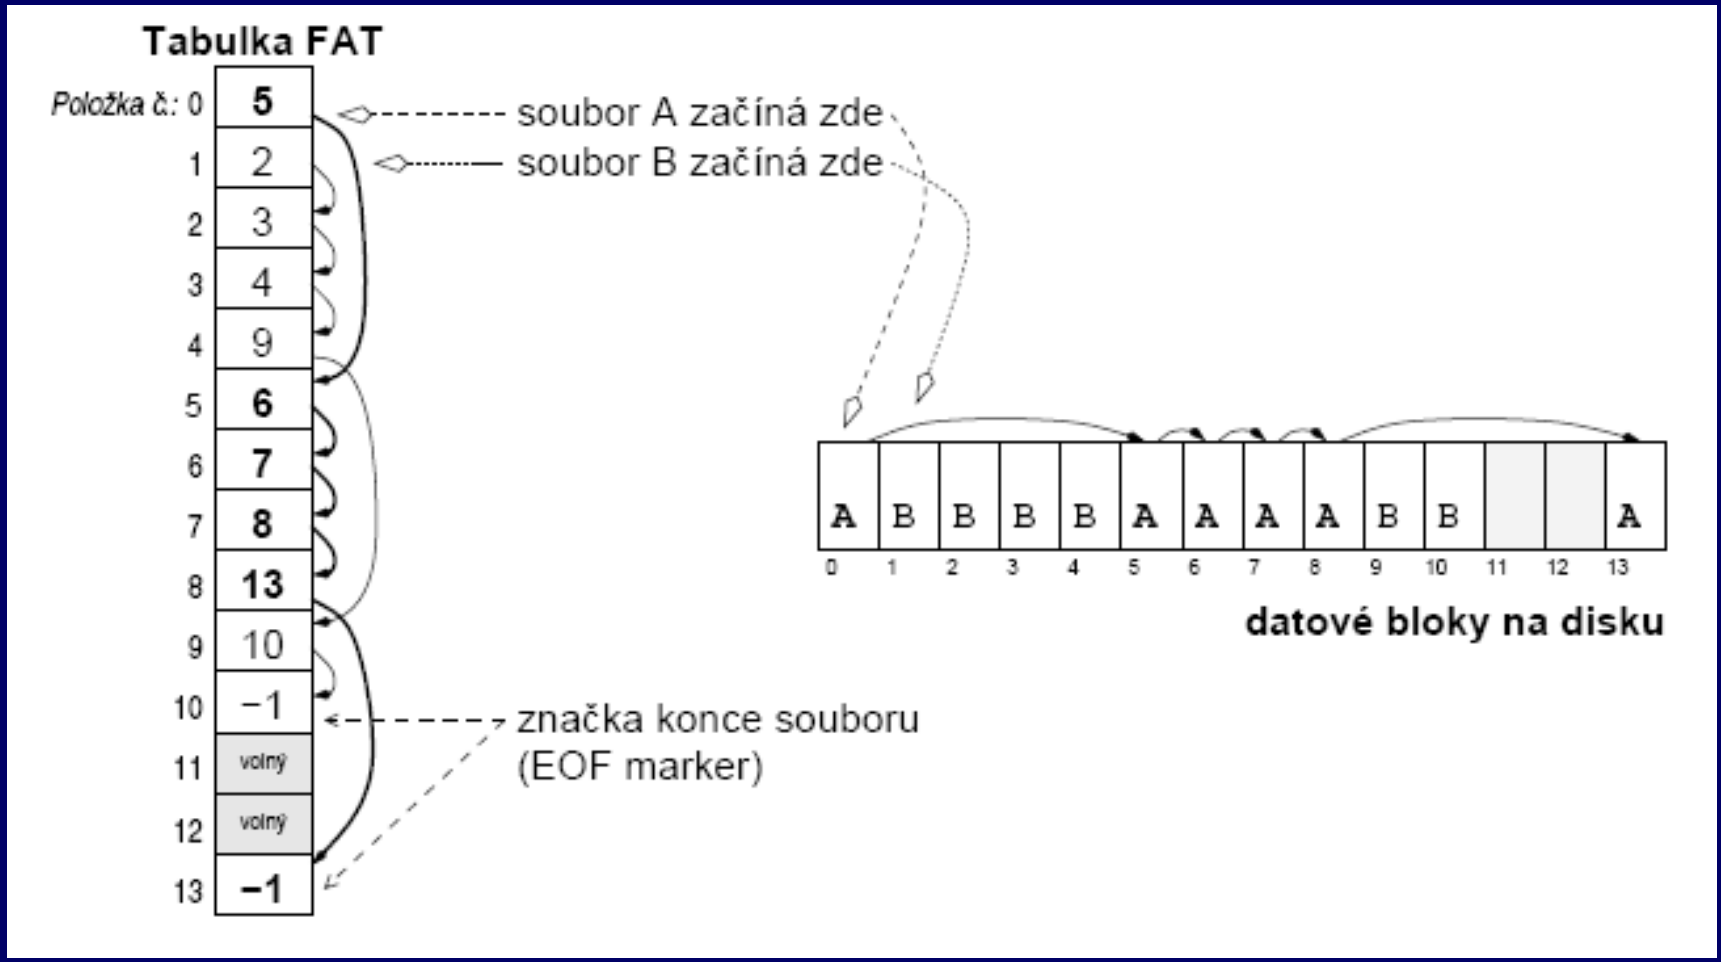

Položce číslo X ve FAT odpovídá datový blok X na disku
Položka ve FAT obsahuje odkaz na další datový blok na disku a tedy i na další položku ve FAT tabulce

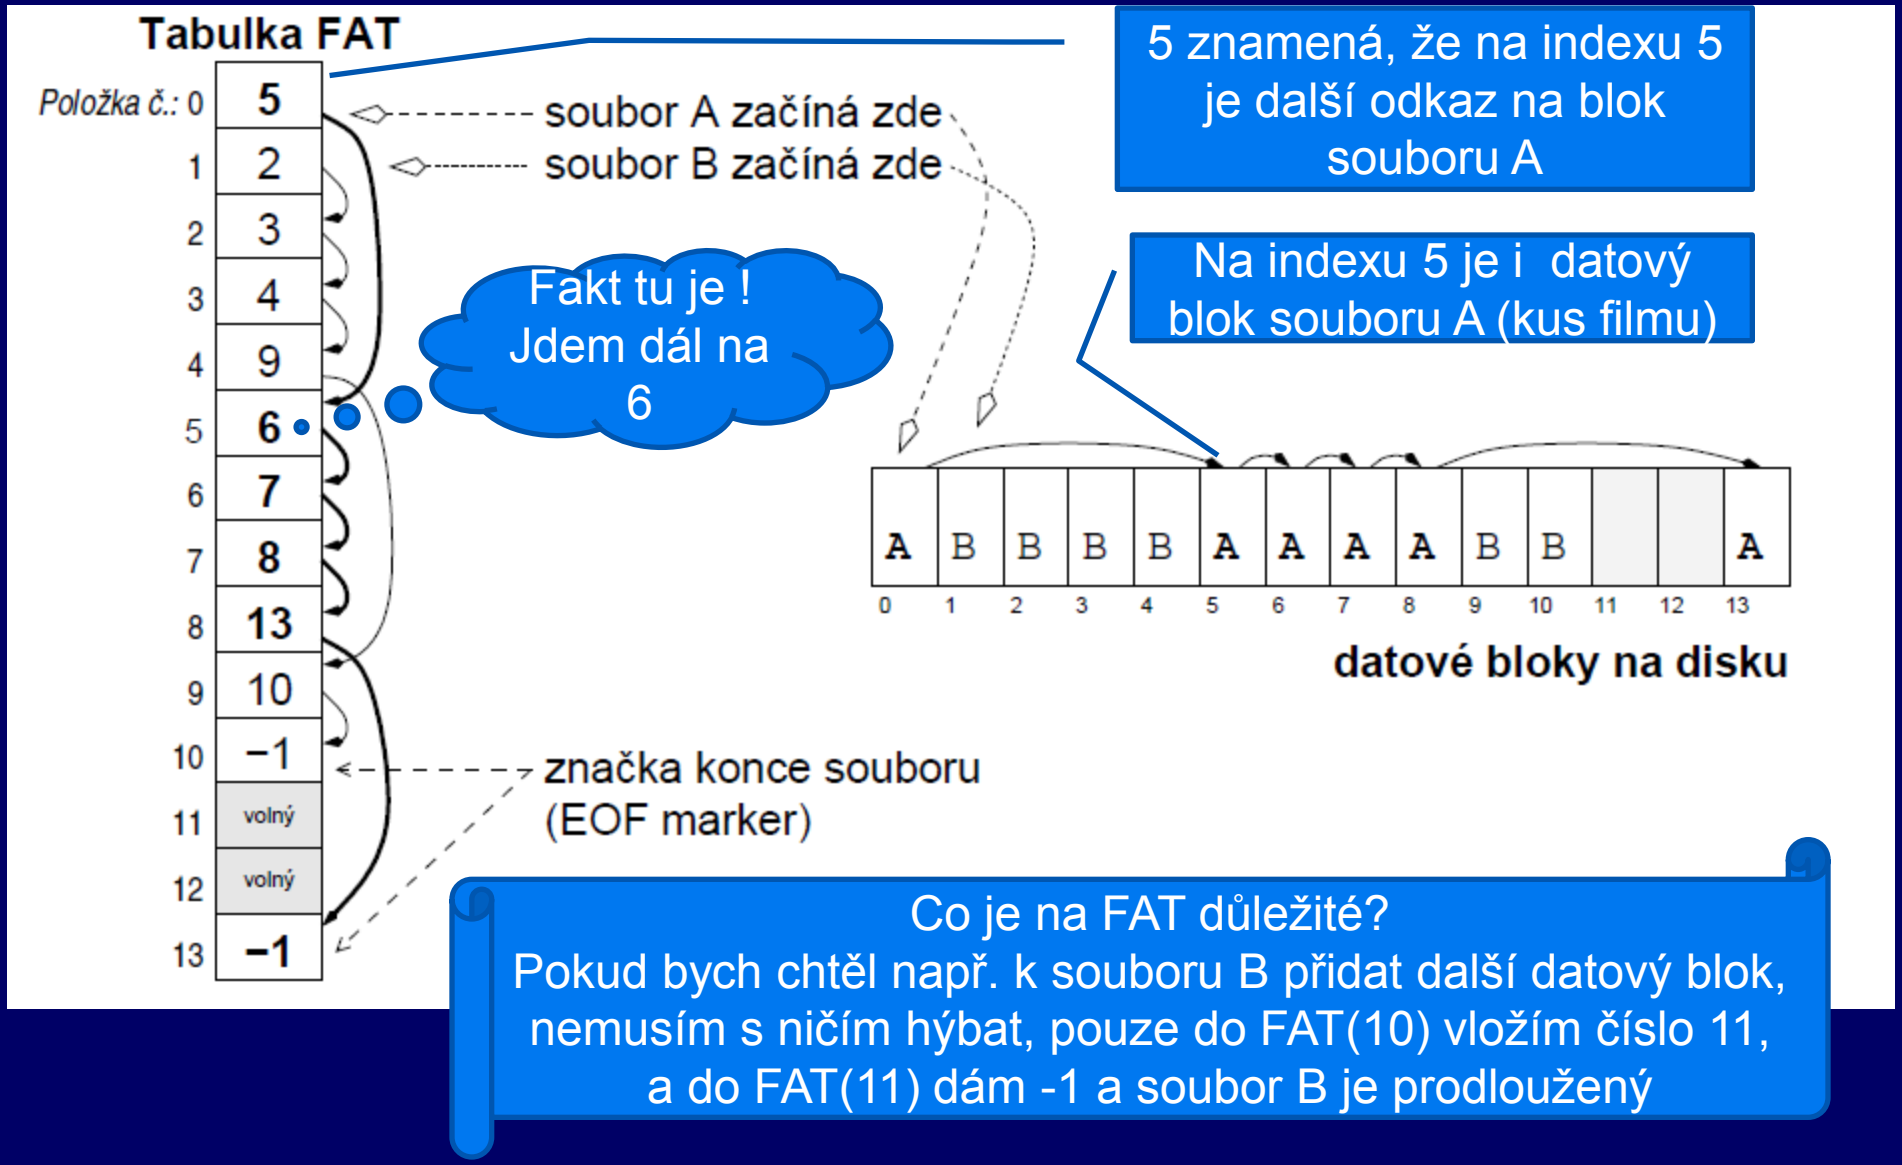
Tabulka FAT
Položka č.: 0
5
1
2
2
3
3
4
4
9
5
6
6
7
7
8
8
13
9
10
10
−1
11
volný
12
volný
13
−1
soubor A začíná zde
soubor B začíná zde
značka konce souboru
(EOF marker)
Fakt tu je !
Jdem dál na
6
5 znamená, že na indexu 5
je další odkaz na blok
souboru A
Na indexu 5 je i datový
blok souboru A (kus filmu)
A B B B B A A A A B B A
0 1 2 3 4 5 6 7 8 9 10 11 12 13
datové bloky na disku
Co je na FAT důležité?
Pokud bych chtěl např. k souboru B přidat další datový blok,
nemusím s ničím hýbat, pouze do FAT(10) vložím číslo 11,
a do FAT(11) dám -1 a soubor B je prodloužený

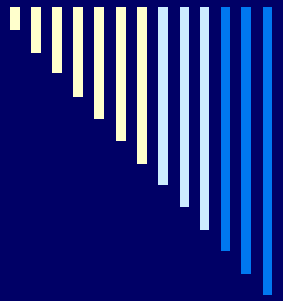

FAT

- FAT je ukázka implementace souborového systému, kde v jedné části máme datové bloky (obsahující např. části jednoho filmu)
  a v druhé části máme indexy, které nám říkají, pod jakým číslem se nalézá další odkaz
- Výhodou je, že s určitým souborem můžeme manipulovat, zrušit ho, prodloužit, atd., aniž bychom ovlivnili pozici ostatních souborů na disku

Příklady filesystémů (!!!)

- **FAT**
  - Starší verze Windows, paměťové karty
  - Nepoužívá ACL – u souborů není žádná info o přístupových právech
  - snadná přenositelnost dat mezi různými OS
- **NTFS**
  - Používá se ve Windows XP/Vista/7
  - Používají ACL: k souboru je přiřazen seznam uživatelů, skupin a jaká mají oprávnění k souboru (!!!!)
- **Ext2**
  - Použití v Linuxu, nemá žurnálování
  - Nepoužívá ACL – jen standardní nastavení (vlastní,skupina, others), což ale není ACL (to je komplexnější)
- **Ext3**
  - Použití v Linuxu, má žurnál (rychlejší obnova konzistence po výpadku)

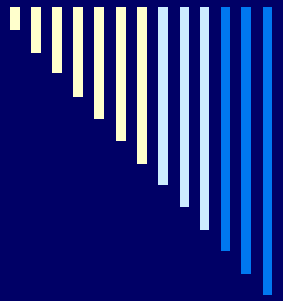

Příklady filesystémů

- ext4
  - stejně jako ext2, ext3 používá inody
  - extenty – souvislé logické bloky
    - může být až 128MB oproti velkému počtu 4KB bloků
- xfs
- jfs

Vlastnosti FAT

- Nevýhodou je velikost tabulky FAT
  - 80GB disk, bloky 4KB => 20 mil. položek
  - Každá položka alespoň 3 byty => 60MB FAT
  - Výkonnostní důsledky (FAT nebude celá v paměti)

- Použití
  - DOS, Windows 98, ME, podporují Win NT/2000/XP
  - FAT12, 12 bitů, 2^12 = 4096 bloků, diskety
  - FAT16, 16 bitů, 2^16 = 65536 bloků
  - FAT32, 2 ^28 bloků, blok 4-32KB, cca 8TB

NTFS

- nativní fs Windows od NT výše
- žurnálování
  všechny zápisy na disk se zapisují do žurnálu, pokud uprostřed zápisu systém havaruje, je možné dle stavu žurnálu zápis dokončit nebo anulovat => konzistentní stav
- access control list
  přidělování práv k souborům (x FAT)
- komprese
  na úrovni fs lze soubor nastavit jako komprimovaný

NTFS pokračování

- šifrování
  EFS (encrypting file system),
  transparentní – otevřu ahoj.txt, nestarám se, zda je šifrovaný
- diskové kvóty
  max. velikost pro uživatele na daném oddíle
  dle reálné velikosti (ne komprimované)
- pevné a symbolické linky

NTFS struktura

- 64bitové adresy klusterů .. cca 16EB
- systém jako obří databáze
  záznam odpovídá souboru
- základ 11 systémových souborů - metadat
  hned po formátování svazku
- $Logfile – žurnálování
- $MFT (Master File Table)
  záznamy o všech souborech, adresářích, metadatech
  hned za boot sektorem, za ním se udržuje zóna volného místa

NTFS struktura

- $MFTMirr – uprostřed disku, obsahuje část záznamů $MFT, při poškození se použije tato kopii
- $Badclus – seznam vadných clusterů
- $Bitmap – sledování volného místa
  0 – volný
- $Boot, $Volume, $AttrDef, $Quota, $Upcase, .

podrobnosti:

http://technet.microsoft.com/en-us/library/cc781134%28WS.10%29.aspx

NTFS atributy souborů

- $FILE_NAME
  - jméno souboru
  - velikost
  - odkaz na nadřazený adresář
  - další
- $SECURITY_DESCRIPTOR
  - přístupová práva k souboru
- $DATA
  - vlastní obsah souboru

NTFS

- adresáře
  - speciální soubory
  - B-stromy se jmény souborů a odkazy na záznamy v MFT
- alternativní datové proudy (ADS)
  - notepad poznamky.txt**:tajny.txt**
  - často útočiště virů, škodlivého kódu
- zkopírováním souboru z NTFS na FAT
  - ztratíme přístupová práva a alternativní datové proudy

NTFS – způsob uložení dat (!!!)

- kódování délkou běhu
- od pozice 0 máme např. uloženo:
  A1, A2, A3, B1, B2, A4, A5, C1, …
- soubor A bude popsaný fragmenty
- fragment
  - index
  - počet bloků daného souboru
- v našem příkladě:
  - 0, 3 (od indexu 0 patří tři bloky souboru A)
  - 5, 2 (od indexu 5 patří dva bloky souboru A)

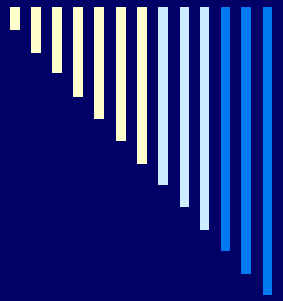

I-uzly (!!)

- S každým souborem sdružená datová struktura i-uzel (i-node, zkratka z index-node)
- i-uzel obsahuje
  - Atributy souboru
  - Diskové adresy prvních N bloků
  - 1 či více odkazů na diskové bloky obsahující další diskové adresy (případně obsahující odkazy na bloky obsahující adresy)
- Používá tradiční fs v Unixu UFS (Unix File System) a z něj vycházející v Linuxu, dnes např. ext2, ext3, ext4

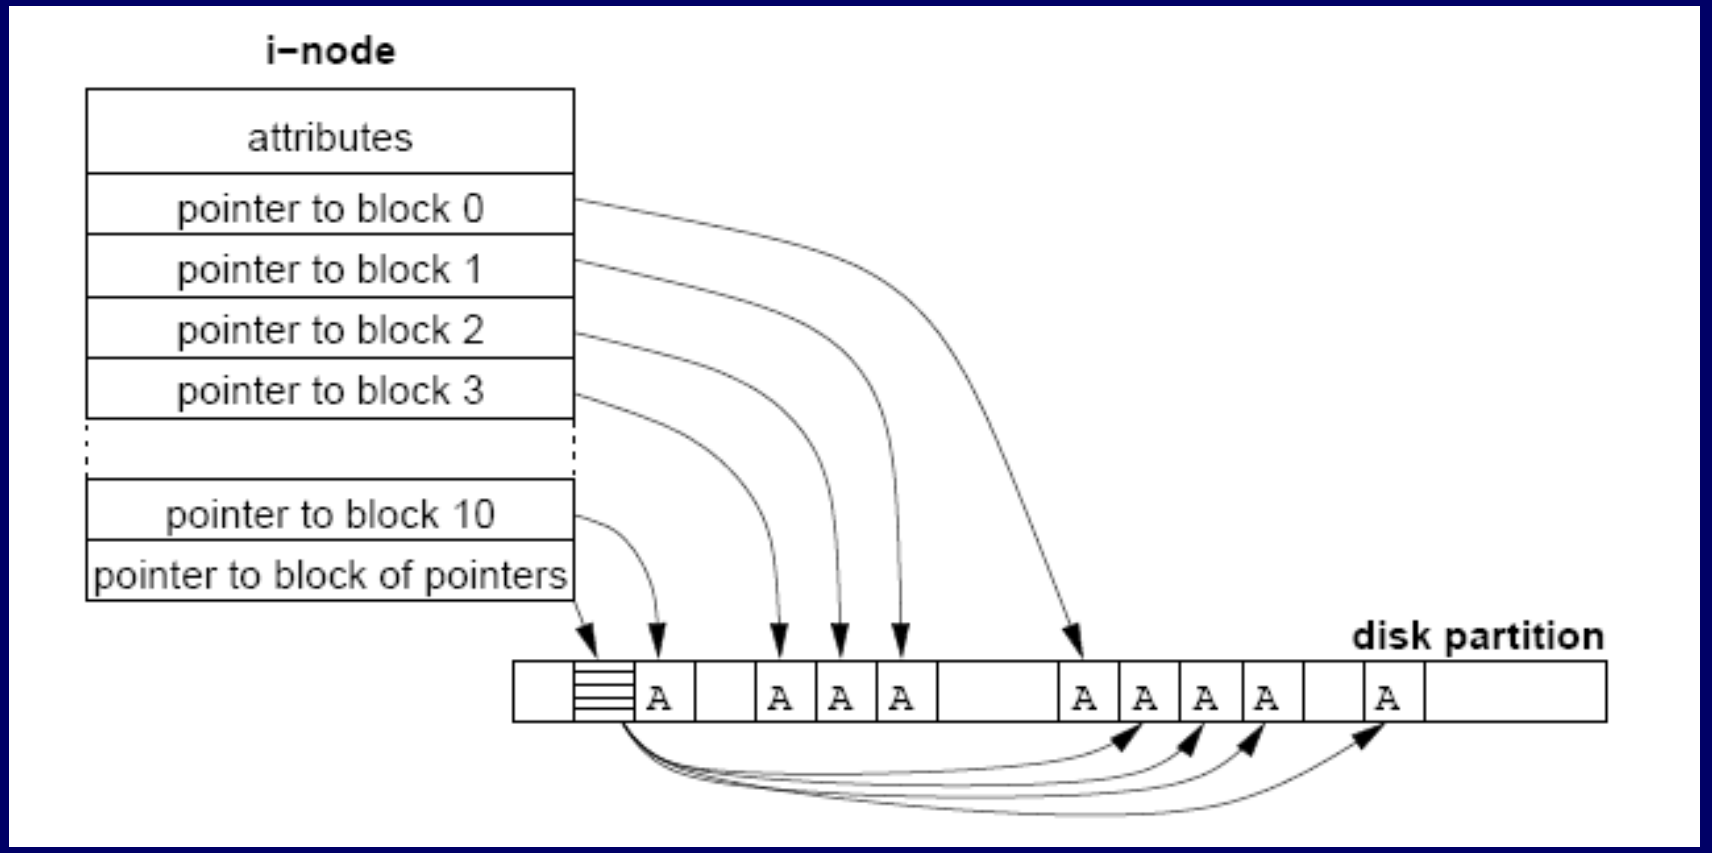
i–node
attributes
pointer to block 0
pointer to block 1
pointer to block 2
pointer to block 3
pointer to block 10
pointer to block of pointers
disk partition
A
A
A
A
A
A
A
A
A

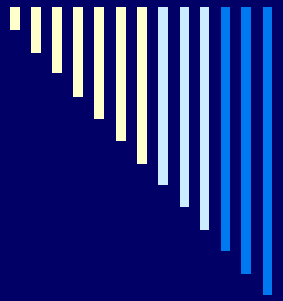

I-uzly - výhoda

Po otevření souboru můžeme zavést i-uzel a případný blok obsahující další adresy do paměti => zrychlení přístupu k souboru

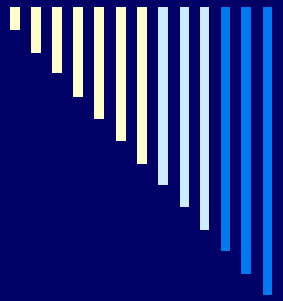

i-uzly dle normy Posix

- MODE – typ souboru, přístupová práva (u,g,o)
- REFERENCE COUNT – počet odkazů na tento objekt
- OWNER – ID vlastníka
- GROUP – ID skupiny
- SIZE – velikost objektu
- TIME STAMPS
  - atime – čas posledního přístupu (čtení souboru, výpis adresáře)
  - mtime – čas poslední změny
  - ctime – čas poslední změny i-uzlu (metadat)

i-uzly dle normy POSIX

- DIRECT BLOCKS – 12 přímých odkazů na datové bloky (data v souboru)
- SINGLE INDIRECT – 1 odkaz na datový blok, který místo dat obsahuje seznam přímých odkazů na datové bloky obsahující vlastní data souboru
- DOUBLE INDIRECT – 1 odkaz 2. nepřímé úrovně
- TRIPLE INDIRECT – 1 odkaz 3. nepřímé úrovně

v linuxových fs (ext*) ještě FLAGS, počet použitých datových bloků a rezervovaná část – doplňující info (odkaz na rodičovský adresář, ACL, rozšířené atributy)

Implementace adresářů

- Před čtením je třeba soubor otevřít
- *open (jméno, režim)*
- Mapování jméno -> info o datech poskytují adresáře !

- Adresáře jsou často speciálním typem souboru
- Typicky pole datových struktur, 1 položka na soubor

2 základní uspořádání adresáře (!!!)

1. Adresář obsahuje jméno souboru, atributy, diskovou adresu souboru (např. adresa 1.bloku) (implementuje DOS, Windows)

2. Adresář obsahuje pouze jméno + odkaz na jinou datovou strukturu obsahující další informace (např. i-uzel) (implementuje UNIX, Linux)

Běžné jsou oba dva způsoby i kombinace

2 základní uspořádání adresáře (!!)

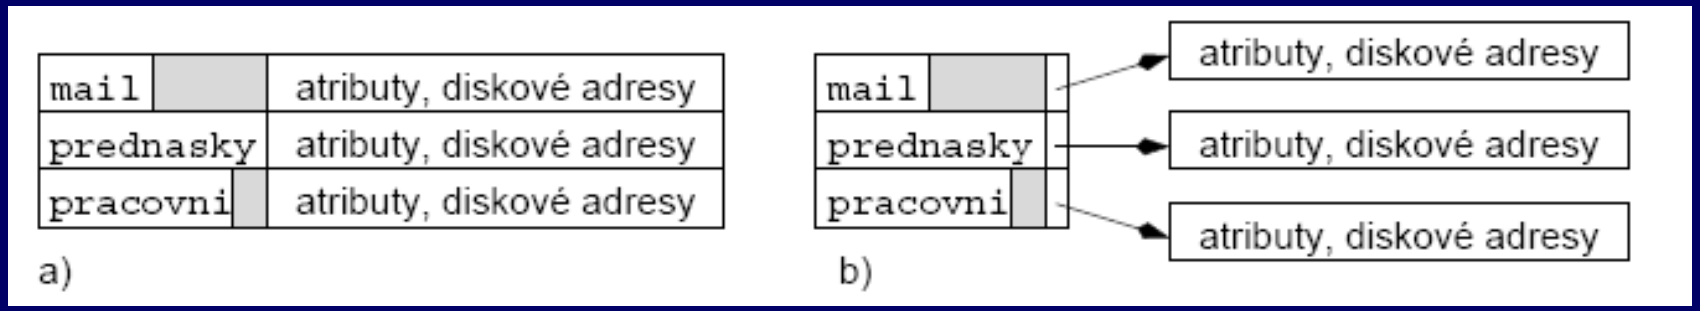

Příklad fs (Unix v7)

- Struktura fs na disku
  - Boot blok – může být kód pro zavedení OS
  - Superblok – informace o fs
    (počet i-uzlů, datových bloků,..)
  - i-uzly – tabulka pevné velikosti, číslovány od 1
  - Datové bloky – všechny soubory a adresáře

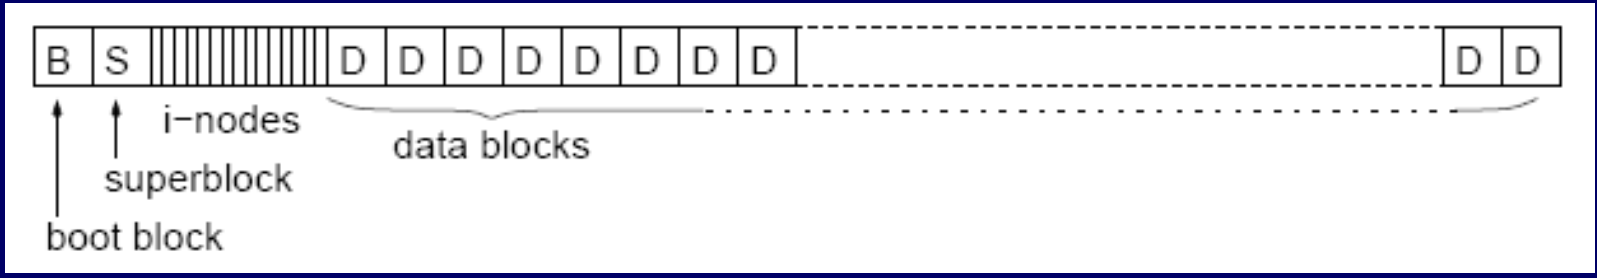

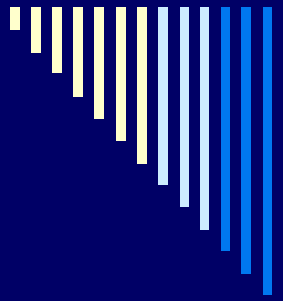

Implementace souborů – i-uzly

i-uzel obsahuje:

- Atributy
- Odkaz na prvních 10(až 12) datových bloků souboru
- Odkaz na blok obsahující odkazy na datové bloky (nepřímý odkaz)
- Odkaz na blok obsahující odkazy na bloky obsahující odkazy na datové bloky (dvojitě nepřímý odkaz)
- Trojitě nepřímý odkaz

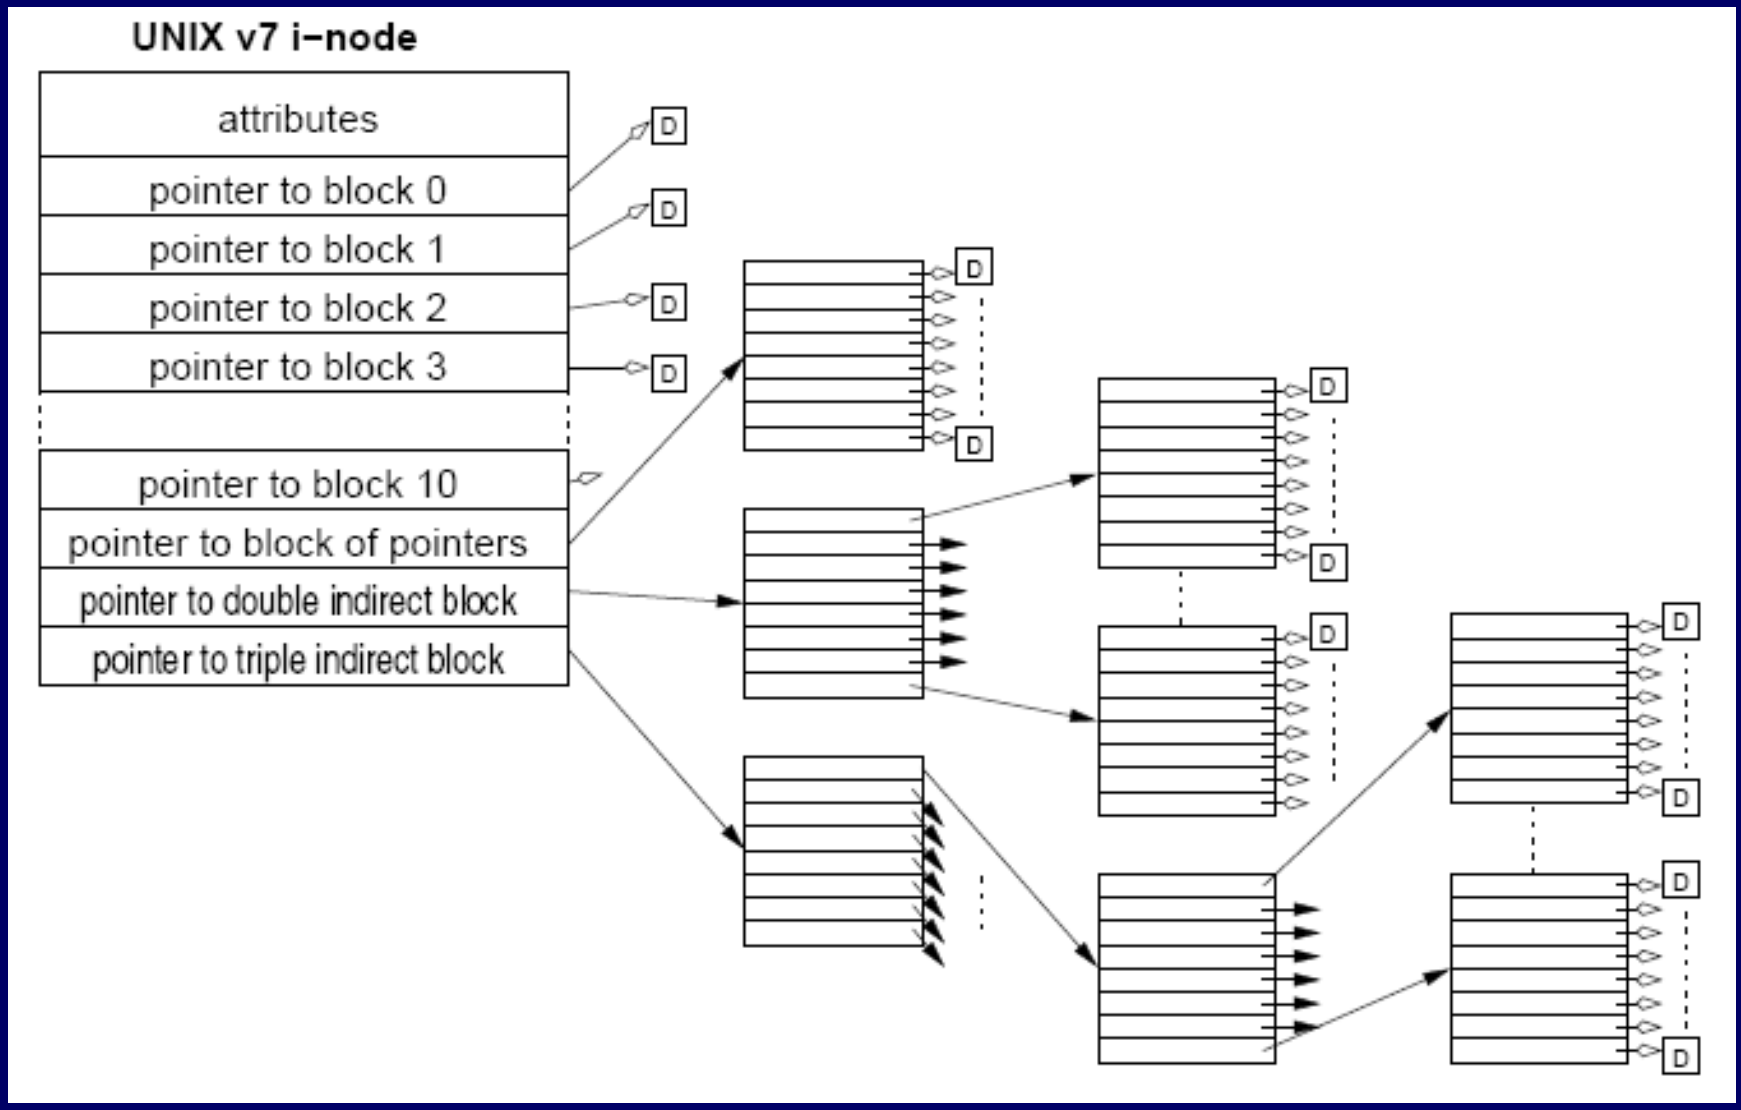
UNIX v7 i-node
attributes
pointer to block 0
pointer to block 1
pointer to block 2
pointer to block 3
pointer to block 10
pointer to block of pointers
pointer to double indirect block
pointer to triple indirect block
D

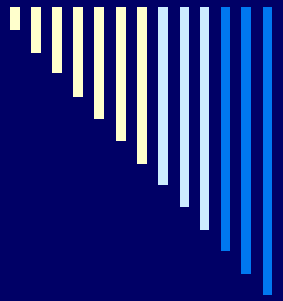

Pokračování příkladu

- Implementace adresářů:
  tabulka obsahující jméno souboru a číslo jeho i-uzlu
- Info o volných blocích
  seznam, jeho začátek je v superbloku

- Základní model, současné fs jsou na něm založeny

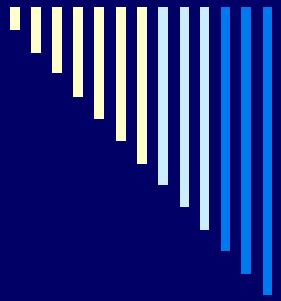

Adresáře v UNIX v7

- adresář: jméno souboru a číslo i-uzlu
- Číslo i-uzlu je indexem do tabulky i-uzlů na disku
- Každý soubor a adresář: právě 1 i-uzel
- V i-uzlu: všechny atributy a čísla diskových bloků
- Kořenový adresář: číslo i-uzlu 1

- Nalezení cesty k souboru /etc/passwd
  - V kořenovém adresáři najdeme položku „etc“
  - i-uzel číslo 9 obsahuje adresy diskových bloků pro adresář etc
  - V adresáři etc (disk blok 132) najdeme položku passwd
  - i-uzel 30 obsahuje soubor /etc/passwd

  - (uzel, obsah uzlu, uzel, obsah uzlu)

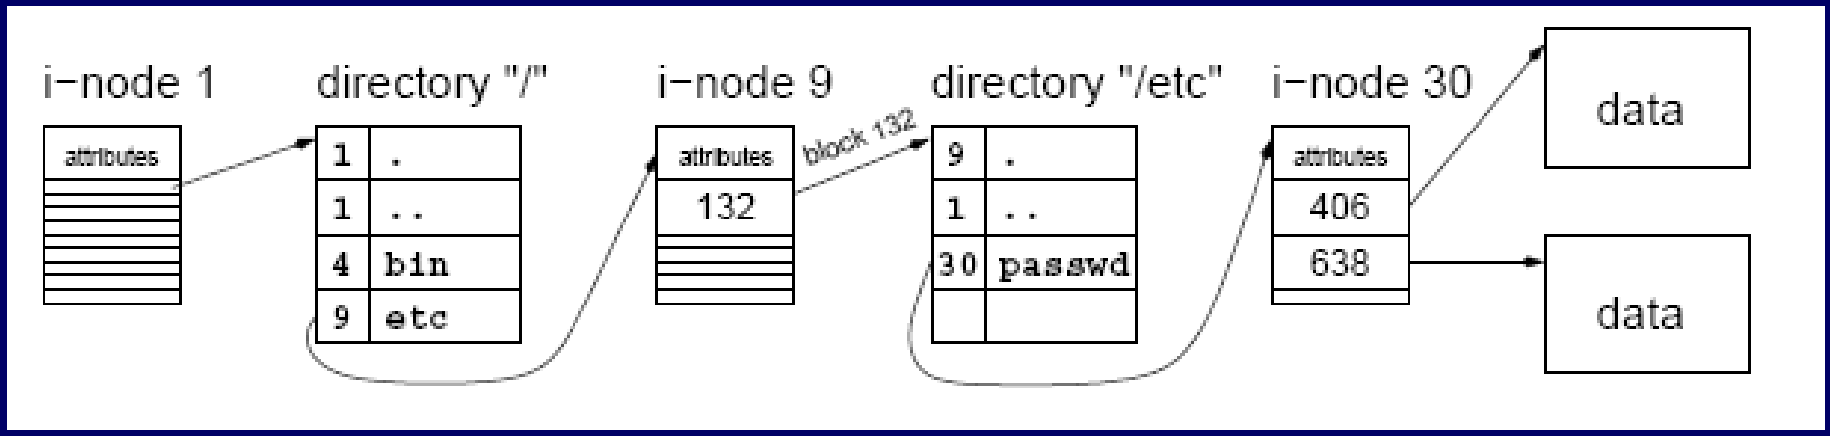

Příklad – adresář win 98

* položka adresáře obsahuje:
  - jméno souboru (8 bytů) + příponu (3 byty)
  - atributy (1)
  - NT (1) - Windows 98 nepoužívají (rezervováno pro WinNT)
  - datum a čas vytvoření (5)
  - čas posledního přístupu (2)
  - horních 16 bitů počátečního bloku souboru (2)
  - čas posledního čtení/zápisu
  - spodních 16 bitů počátečního bloku souboru (2)
  - velikost souboru (4)
* dlouhá jména mají pokračovací položky

* veškeré "podivnosti" této struktury jsou z důvodu kompatibility s MS DOSem

Sdílení souborů

- Soubor ve více podadresářích nebo pod více jmény
- Hard links (pevné odkazy)
  - Každý soubor má datovou strukturu, která ho popisuje (i-uzel), můžeme vytvořit v adresářích více odkazů na stejný soubor
  - Všechny odkazy (jména) jsou rovnocenné
  - V popisu souboru (i-uzlu) musí být počet odkazů
  - Soubor zanikne při zrušení posledního odkazu

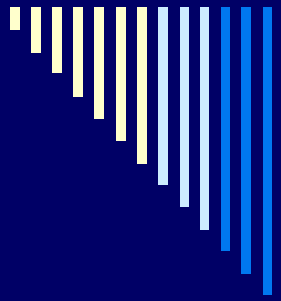

Sdílení souborů

- Symbolický link
  - Nový typ souboru, obsahuje jméno odkazovaného souboru
  - OS místo symbolického odkazu otevře odkazovaný soubor
  - Obecnější – může obsahovat cokoliv
  - Větší režie

Správa volného prostoru

- Info, které bloky jsou volné
- Nejčastěji – seznam nebo bitová mapa

- Bitová mapa
  - Konstantní velikost
  - Snažší vyhledávání volného bloku s určitými vlastnostmi
  - Většina současných fs používá bitovou mapu

Správa volného prostoru

- Seznam diskových bloků
  - Blok obsahuje odkazy na volné bloky a adresu dalšího bloku …
  - Uvolnění bloků - Přidáme adresy do seznamu, pokud není místo blok zapíšeme
  - Potřebujeme bloky pro soubor – používáme adresy ze seznamu, pokud nejsou přečteme další blok adres volných bloků
  - Pokud není na disku volné místo, seznam volných bloků je prázdný a nezabírá místo
  - Problém najít volný blok s určitými vlastnostmi (např. ve stejném cylindru), prohledávat seznam, drahé,…

Seznam diskových bloků

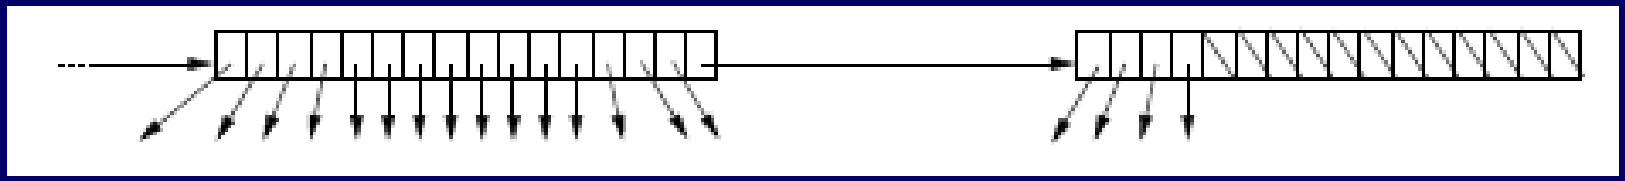

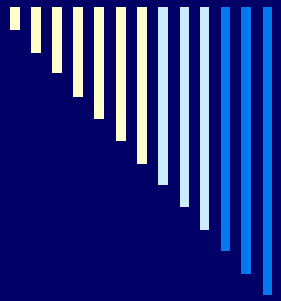

Kvóty

- Maximální počet bloků obsazených soubory uživatele
- Ve víceuživatelských OS, servery

- Hard a soft kvóty

Spolehlivost souborového systému

- Ztráta dat má často horší důsledky než zničení počítače
  - diplomová – bakalářská práce
  - Fotografie za posledních 10 let
- Filesystém musí být jedna z nejspolehlivějších částí OS, snaha chránit data
  - Správa vadných bloků (hlavně dříve)
  - Rozprostřít a duplikovat důležité datové struktury, čitelnost i po částečném poškození povrchu

Konzistence fs

- Blokové zařízení
  OS přečte blok souboru, změní ho, zapíše
- Nekonzistentní stav
  může nastat při havárii (např. výpadek napájení) předtím, než jsou všechny modifikované bloky zapsány
- Kontrola konzistence fs
  Windows: scandisk, **chkdsk**
  UNIX: fsck , fsck.ext3, e2fsck .. viz man
- Kontrolu spustí automaticky po startu, když detekuje nekorektní ukončení práce se systémem

Testy konzistence fs

- Konzistence informace o diskových blocích souborů
  - Blok (obvykle) patří jednomu souboru nebo je volný
- Konzistence adresářové struktury
  - Jsou všechny adresáře a soubory dostupné?

důležité pochopit rozdíl:
-kontrola konzistence souboru
-kontrola, zda je soubor dostupný z nějakého adresáře

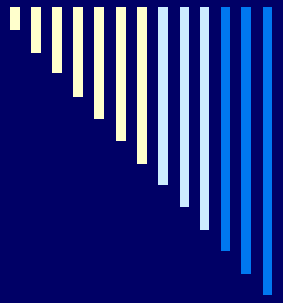

Konzistence informace o diskových blocích souborů

- Tabulka počtu výskytů bloku v souboru
- Tabulka počtu výskytů bloku v seznamu volných bloků

- Položky obou tabulek inicializovány na 0
- Procházíme informace o souborech (např. i-uzly), inkrementujeme položky odpovídající blokům souboru v první tabulce
- Procházíme seznam nebo bitmapu volných bloků a inkrementujeme příslušné položky ve druhé tabulce

Konzistentní fs

Číslo bloku	0	1	2	3	4	5	6	7	8
Výskyt v souborech	1	0	1	**0**	**1**	**0**	**2**	0	1
Volné bloky	0	1	0	**0**	**1**	**2**	**0**	1	0

Blok je buď volný, nebo patří nějakému souboru, tj. konzistentní hodnoty v daném sloupci jsou buď (0,1) nebo (1,0)
Vše ostatní jsou chyby různé závažnosti

Možné chyby, závažnosti

- (0,0) – blok se nevyskytuje v žádné tabulce
  - Missing blok
  - Není závažné, pouze redukuje kapacitu fs
  - Oprava: vložení do seznamu volných bloků
- (0,2) – blok je dvakrát nebo vícekrát v seznamu volných
  - Problém – blok by mohl být alokován vícekrát !
  - Opravíme seznam volných bloků, aby se vyskytoval pouze jednou

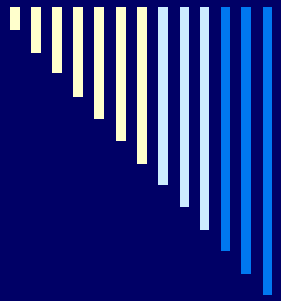

Možné chyby, závažnosti

- (1,1) – blok patří souboru a zároveň je na seznamu volných
  - Problém, blok by mohl být alokován podruhé !
  - Oprava: blok vyjmeme ze seznamu volných bloků
- (2,0) – blok patří do dvou nebo více souborů
  - Nejzávažnější problém, nejspíš už došlo ke ztrátě dat
  - Snaha o opravu: alokujeme nový blok, problematický blok do něj zkopírujeme a upravíme i-uzel druhého souboru
  - Uživatel by měl být informován o problému

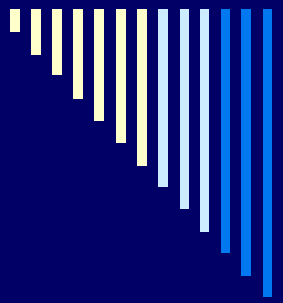

Je zde nějaká chyba? A když tak jaká?

	číslo bloku:	0	1	2	3	4	5	6	7	8	9	11	12	13	14	15
výskyt	v souborech:	1	1	0	0	1	0	0	1	1	1	1	0	1	0	0
	volné bloky:	0	0	1	1	0	1	1	0	0	0	0	1	0	1	1

	číslo bloku:	0	1	2	3	4	5	6	7	8	9	11	12	13	14	15
výskyt	v souborech:	1	2	0	0	1	0	0	1	1	1	1	1	1	0	0
	volné bloky:	0	0	1	1	0	0	1	0	0	0	0	1	0	1	1

Kontrola konzistence adresářové struktury

- Tabulka čítačů, jedna položka pro každý soubor
- Program prochází rekurzivně celý adresářový strom
- Položku pro soubor program zvýší pro každý výskyt souboru v adresáři
- Zkontroluje, zda odpovídá počet odkazů v i-uzlu (i) s počtem výskytů v adresářích (a)
- i == a ☺ pro každý soubor

Možné chyby

- **i > a**
  soubor by nebyl zrušen ani po zrušení všech odkazů v adresářích
  není závažné, ale soubor by zbytečně zabíral místo
  řešíme nastavením počtu odkazů v i-uzlu na správnou hodnotu (a)

Možné chyby

- **i < a**

  soubor by byl zrušen po zrušení i odkazů, ale v adresářích budou ještě jména

  velký problém – adresáře by ukazovaly na neexistující soubory

  řešíme nastavením počtu odkazů na správnou hodnotu

Možné chyby

- **a=0 , i > 0**
  ztracený soubor, na který není v adresáři odkaz
  ve většině systémů program soubor zviditelní
  na předem určeném místě
  (např. adresář lost+found)

Další heuristické kontroly

- Odpovídají jména souborů konvencím OS?
  - Když ne, soubor může být nepřístupný, změníme jméno
- Nejsou přístupová práva nesmyslná?
  - Např. vlastník nemá přístup k souboru,…
- Zde byly uvedeny jen základní obecné kontroly fs

Journaling fs

- Kontrola konzistence je časově náročná
- Journaling fs
  - Před každým zápisem na disk vytvoří na disku záznam popisující plánované operace, pak provede operace a záznam zruší
  - Výpadek – na disku najdeme žurnál o všech operacích, které mohly být v době havárie rozpracované, zjednodušuje kontrolu konzistence fs

Výkonnost fs

- Přístup k tradičnímu disku řádově pomalejší než přístup do paměti
  - Seek 5-10 ms
  - Rotační zpoždění – až bude požadovaný blok pod hlavičkou disku
  - Rychlost čtení (x rychlost přístupu do paměti)
- Použití SSD disků
  - Rychlé, lehké, malá spotřeba (výdrž notebooků)
  - menší kapacita, drahé
  - 60GB cca 3-4 tisíce Kč

Výkonnost fs, cachování

- Cachování diskových bloků v paměti
- Přednačítání (read-ahead)
  do cache se předem načítají bloky, které se budou potřebovat při sekvenčním čtení souboru

- Redukce pohybu diskového raménka pro po sobě následující bloky souboru,…

Mechanismy ochrany

- Chránit soubor před neoprávněným přístupem
- Chránit i další objekty
  - HW (segmenty paměti, I/O zařízení)
  - SW (procesy, semafory, …)
- Subjekt – entita schopná přistupovat k objektům (většinou proces)
- Objekt – cokoliv, k čemu je potřeba omezovat přístup pomocí přístupových práv (např. soubor)
- Systém uchovává informace o přístupových právech subjektů k objektům

ACL x capability list

- Dvě různé podoby
- ACL – s objektem je sdružen seznam subjektů a jejich přístupových práv
- Capability list [kejpa-] – se subjektem je sdružen seznam objektů a přístupových práv k nim

ACL (Access Control Lists)

- S objektem je sdružen seznam subjektů, které mohou k objektu přistupovat
- Pro každý uvedený subjekt je v ACL množina přístupových práv k objektu

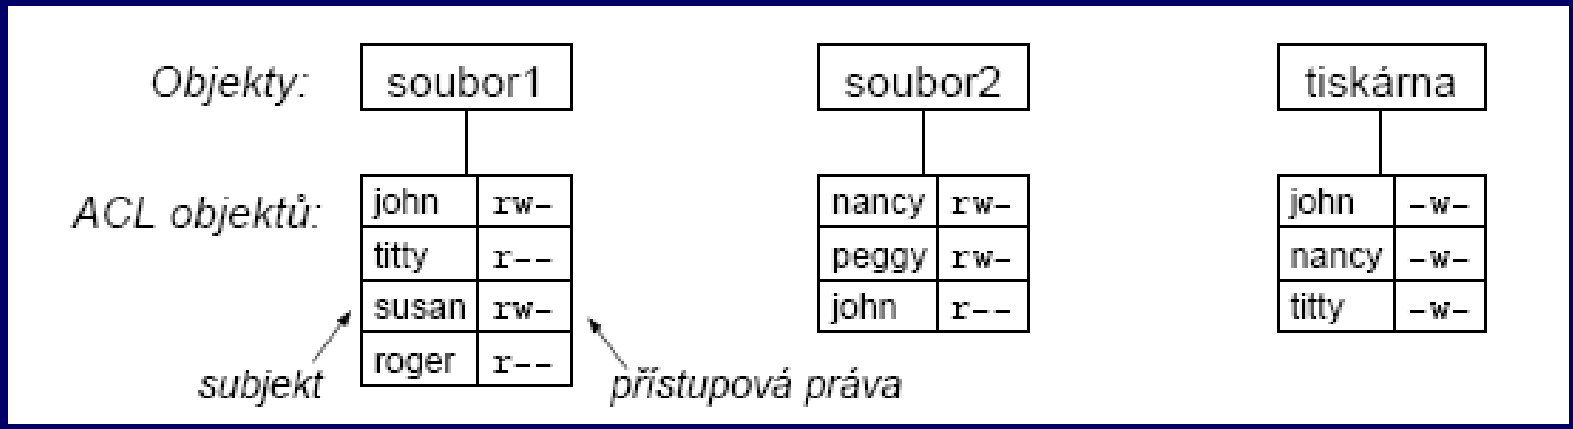

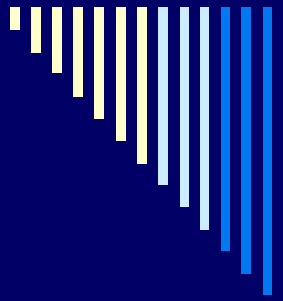

ACL

- Sdružování subjektů do tříd nebo do skupin
  - Studenti
  - Zamestnanci
- Skupiny mohou být uvedeny na místě subjektu v ACL
- Zjednodušuje administraci
  - Nemusíme uvádět všechny studenty jmenovitě
- ACL používá mnoho moderních filesystémů (ntfs, xfs, …)

Úloha: jak doimplementovat ACL do i-uzlu?

- V i-uzlu by byla část tabulky ACL, pokud by se nevešla celá do i-uzlu, tak odkaz na diskový blok obsahující zbytek ACL
- Každá položka ACL
  - Subjekt: id uživatele či id skupiny + 1 bit rozlišení uživatel/skupina
  - Přístupové právo Nbitovým slovem
    1 – právo přiděleno, 0 – právo odejmuto

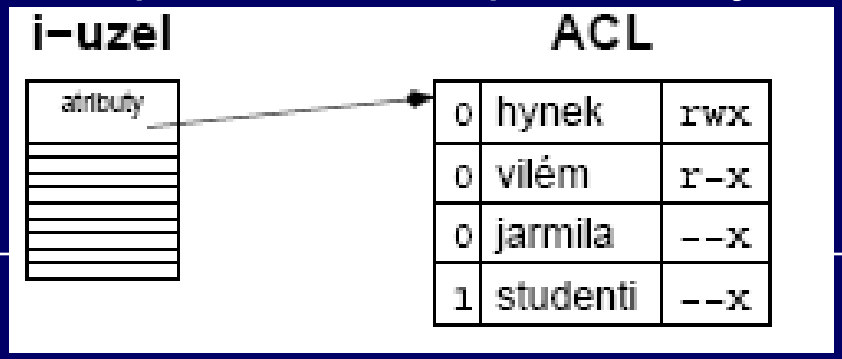

Mechanismus capability lists (C-seznamy)

- S každým subjektem (procesem) sdružen seznam objektů, kterým může přistupovat a jakým způsobem (tj. přístupová práva)

- Seznam se nazývá capability list (C-list)
- Jednotlivé položky - capabilities

Struktura capability

- Struktura capability
  - Typ objektu
  - Práva – obvykle bitová mapa popisující dovolené operace nad objektem
  - Odkaz na objekt, např. číslo uzlu, segmentu, atd..

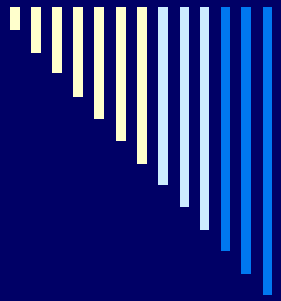

Capability

- Problém – zjištění, kdo všechno má k objektu přístup
- Zrušení přístupu velmi obtížné – najít pro objekt všechny capability + odejmout práva
- Řešení: odkaz neukazuje na objekt, ale na nepřímý objekt
  systém může zrušit nepřímý objekt, tím zneplatní odkazy na objekt ze všech C-seznamů

Capability list

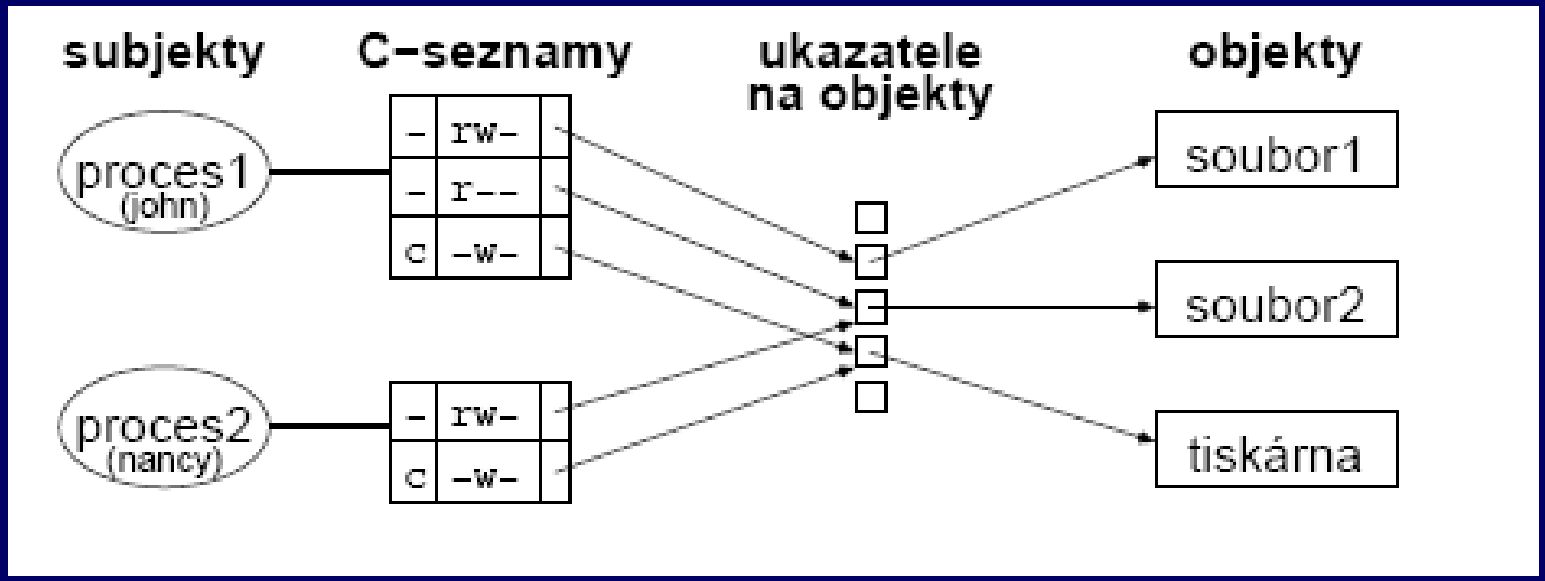

Capability list

Pokud jsou jediný způsob odkazu na objekt (bezpečný ukazatel, capability-based addressing):

- Ruší rozdíl mezi objekty na disku, v paměti (segmenty) nebo na jiném stroji (objekty by šlo přesouvat za běhu)
- Mechanismus C-seznamů v některých distribuovaných systémech (Hydra, Mach,…)

Přístupová práva

- FAT – žádná
- ext2
  - klasická unixová práva (není to ACL)
  - vlastník, skupina, ostatní (r,w,x,s,…)
  - lze přidat ACL
- NTFS
  - ACL
  - lze měnit grafické UI, příkaz icacls, …
  - explicitně udělit / odepřít práva
  - zdědit práva, zakázat dědění