

Operační systémy

Souborové systémy

Petr Krajča



Katedra informatiky
Univerzita Palackého v Olomouci

I/O: zařízení

- zásadní složka Von Neumannova architektury
- různé pohledy na I/O zařízení: inženýrský (dráty, motory) vs. programátorský (rozhraní)
- různé rychlosti od 10 B/s (klávesnice) po 1 GB/s (PCI Express)
- různé druhy přístupu

Bloková zařízení

- data jsou přenášena v blocích stejné velikosti (typicky 512 B až 32 kB)
- možné nezávisle adresovat/zapisovat/číst data po jednotlivých blocích
- HDD, SSD, CD, DVD, páiska?, ...

Znaková zařízení

- proud znaků/bytů (nelze se posouvat)
- klávesnice, myš, tiskárna, terminál

Ostatní

- nespadají ani do jedné z kategorií
- hodiny (přerušení), grafické rozhraní (mapovaná paměť)

Bloková zařízení: HDD

- disk – plotny, stopy (\Rightarrow cylindry), sektory (typicky 4 kB, dříve 512 B)
- původně se adresovaly sektory ve formě CHS (praktická omezení, mj. velikost disku)
- nahrazeno LBA (logical block addressing)
- low-level formát \Rightarrow hlavička + data + ECC
- připojené typicky přes (P)ATA, SATA
- rychlosť přístupu ovlivňuje
 - nastavení hlavičky na příslušný cylindr (seek time; nejzásadnější)
 - rotace (nastavení sektoru) pod hlavičku
 - přenosová rychlosť
- nezávislá cache (hromadí požadavky \Rightarrow eliminuje přesuny)

HDD: optimalizace

- více požadavků se bude řešit najednou
- místo sektorů se pracuje s clustery sektorů (velikost podle velikosti disku)
- cache disku
- cache OS \Rightarrow společně s VM; cachuje se na úrovni FS
- odpovídající algoritmy – LRU, LFU, ..., jejich kombinace
- zjednodušení OS \Rightarrow otevření souboru namapování do cache; demand paging
- write-through cache: data se po zapsaní zapisují přímo na disk
- write-back cache: data se zapisují až po čase (možnost optimalizací zápisu)
- vynucené uložení cache (flush)
- sekvenční čtení
 - read-ahead – data se načítají dopředu
 - free-behind – proaktivně uvolňuje stránky, při načítání nových
- „spolupráce“ – OS & HW (spoon-feeding); databáze

Bloková zařízení: RAID

- SLED: Single Large Expensive Disk
- RAID: Redundant Array of Inexpensive/Independent disks
- Mean Time to Failure: $MTTF_{pole} = \frac{MTTF_{disk}}{N}$
- hardware vs. software RAID
- RAID-0 (stripping): zvýšení propustnosti, problém selhání pořád existuje
- RAID-1 (mirroring): zvýšení propustnosti (kopie), řeší problém selhání
- RAID-2: dělí data na po bitech; Hammingův kód; disk pro paritu (napoužívá se)
- RAID-3: dělí data po bytech; XOR; disk pro paritu (zátěž); zvládne výpadek jednoho disku
- RAID-4: jako RAID-3 používá bloky (zátěž)
- RAID-5: jako RAID-4; paritní bloky jsou ale distribuovány
- RAID-6: jako RAID-5; Reed-Solomon kód; dva paritní bloky; výpadek až dvou disků
- kombinace: RAID-0+1, RAID-1+0

Bloková zařízení: SSD, CD, DVD

Solid-state Drives

- flash paměti; rozhraní jako HDD
- bez rotujících částí \Rightarrow rychlý přístup (výrazně více IOPS)
- problematický zápis
 - omezení na počet přepsání jednoho místa
 - paměť musí být nejdřív vymazána
 - často lze zapisovat po stránkách, ale mazat je nutné po blocích \Rightarrow rychlejší zápis než přepis
- wear levelling
 - žádný – data se přepisují na místě
 - dynamický – změněné bloky označeny jako neplatné a data zapsány jinam (USB)
 - statický – jako dynamický, ale přesouvá i nezměněné data (SSD)
 - hardwarová vs. softwarová implementace (JFFS2, LogFS)
- garbage collection + TRIM

Compact Disc (CD)

- data umístěna ve spirále \Rightarrow pomalé vyhledávání; rychlé sekvenční čtení
- vysoká redundancy dat
- symbol - k zakodávání 8 b se používá 14 b
- 42 symbolů tvoří rámec o velikosti 588 b (192 b data, zbytek ECC)
- jeden sektor obsahující 2048 B dat je tvořen 98 rámci (zahrnuje 16 B hlavičku a 288 B pro ECC)
- efektivita 28%!

DVD, BR-D

- analogicky jako CD

Souborové systémy: Motivace

- potřeba uchovávat větší množství dat (primární paměť nemusí dostačovat)
- data musí být perzistentní (musí přežít ukončení procesu)
- k souborům musí být umožněn souběžný přístup
 - ⇒ řešení v podobě ukládání dat na vnější paměť (např. disk)
 - ⇒ data ukládána do souborů tvořící souborový systém (File System/FS)
- soubor jako proud bytů (doprovázen doplňujícími informacemi)
- souborový systém jako abstrakce (odstínění od implementačních detailů)
- ⇒ Unix

Operace se soubory (1/2)

- `create` – vytvoření souboru
- `write/append` – zápis do souboru (na konec, popř. přepis); souvislý bloky vs. postupný zápis
- `read` – čtení ze souboru (do přichystaného bufferu)
- `seek` – změna pozice
- `erase` – odstranění souboru (uvolnění místa); (`link & unlink`)
- `truncate` – zkrátí daný soubor na požadovanou velikost
- ne všechny souborové systémy (a zařízení podporují všechny operace); např. CD+ISO 9660
- operace dostatečně obecné ⇒ přístup k zařízením (disk, klávesnice, terminál); ovládání systému
- ⇒ lze používat existující nástroje pro práci se soubory
- např. využítí při správě OS (`procfs`, `devfs`, `sysfs`)
- `roury`, `FIFO`

Operace se soubory (2/2)

- open – otevře soubor, aby s ním šlo manipulovat přes popisovač (file descriptor, file handle)
- ukazatel na strukturu v jádře
- přístup přes jméno neefektivní
- „soubory“ nemusí mít jméno
- jeden soubor může být otevřen vícekrát (více ukazatelů na pozici v souboru)
- close – uzavře soubor
- get/set attribute – práce s atributy (metadaty)

Typy souborů

- běžné soubory, adresáře, (Unix: speciální soubory pro blokové a znakové zařízení)
- binární vs. ASCII soubory (ukončení řádků)

Organizace souborů (1/3)

- soubory jsou rozlišovány podle nazvů (často specifické pro daný OS nebo FS)
- rozlišování velkých a malých písmen (Unix vs. MS-DOS a Windows)
- MS-DOS: požadavek na jméno souboru ve tvaru 8+3 (jméno + přípona)
- rozlišení obsahu souboru
 - podle přípony (Windows – asociace s konkrétní aplikací)
 - magická čísla (Unix – podle úvodních bytů je možné identifikovat typ)
 - podle metadat (informace o souboru jsou uloženy vedle souboru, jako součást FS)
- typicky se soubory organizují do adresářů (složek)
- každý adresář může obsahovat běžné (popř. speciální) soubory i další adresáře ⇒ stromová struktura (používaly se i omezenější systémy – žádné, jedna, dvě úrovně)
- v zápisu cesty ve stromě se používá lomítek
 - Unix: /usr/local/bin
 - Windows: \usr\local\bin

Organizace souborů (2/3)

- k přístupu k souboru se používají
 - absolutní cesty /foo/bar/baz.dat
 - relativní cesty foo/bar.dat ⇒ každý proces má aktuální adresář
- operace s adresáři: Create, Delete, OpenDir, CloseDir, ReadDir, Rename
- speciální adresáře v každém adresáři „..“ a „...“ (aktuální adresář, nadřazený adresář)
⇒ nutné pro navigaci v hierarchii adresářů
- struktura nemusí být hierarchická ⇒ obecný graf (acyklický, cyklický)
 - hardlink – ukazatel na soubor (jeho tělo/obsah)
 - symlink – soubor je odkaz na jiný soubor (specifikovaný cestou)
- v Unixech běžné, ve Windows delší dobu (ale chybělo rozhraní)

Dělení disku

- každý fyzický disk se skládá z jedné nebo více logických částí (partition; oddíl);
popsané pomocí partition table daného disku
- v každé partition může existovat souborový systém (označovaný jako svazek)
- v Unixech je každý svazek připojen (mounted) jako adresář (samostatný svazek pro /, /home, /usr)
- \Rightarrow Virtual File System (VFS)
 - využití abstrakce \Rightarrow umožňuje kombinovat různé FS do jednoho VFS
 - specializované FS pro správu systému (procfs, sysfs) \Rightarrow API OS
 - možnost připojit běžný soubor jako svazek (i svazek je soubor)
 - síťové disky (NFS, CIFS)
- ve Windows jednotlivé svazky označeny (a:, b:, c:, ...) ; ale funguje i mountování (preferovaný jeden svazek pro vše)

Struktura souborů

- často je soubor chápán jako proud bytů
- sekvenční vs. náhodný přístup
- někdy může být výhodná jiná struktura
- rozdělení jednoho souboru na více proudů (např. spoustitelný soubor – kód + data)
- potřebná podpora ze strany FS i OS \Rightarrow streamy v NT
- společně s daty jsou k souboru připojena metadata (atributy)
 - vlastník souboru
 - přístupová práva
 - velikost souboru
 - příznaky (skrytý, archivace, spustitelný, systémový)
 - čas vytvoření, čas posledního přístupu

Přístup k souborům

Zamykání

- sdílený přístup
- omezení přístupu – současné čtení (zabránění zápisu)

Sémantika konzistence

- chování systému při současné přístupu
- v Unixech změny okamžitě viditelné
- immutable-shared-file – pokud je soubor sdílený nejde jej měnit (jednoduchá implementace)

Práva přístupu

- ACL (access control list)
 - seznam uživatelů a jejich přístupových práv (3 byty pro každý přístup)
 - udržovat seznam může být netriviální (možnost doplnit role)
 - Denied ACL
- UNIX
 - „ACL“ – pro vlastníka, skupinu, zbytek

Implementace souborových systémů: očekávané vlastnosti

- (budeme předpokládat souborové systémy pro práci s disky)
- schopnost pracovat se soubory a disky adekvátní velikosti
- efektivní práce s místem (evidence volného, nízká fragmentace)
- rychlý přístup k datům
- eliminace roztroušení dat na disku
- odolnost proti poškození při pádu systému (výpadku napájení) \implies rychlé zotavení

Další vlastnosti

- snapshoty
- komprese dat
- možnost zvětšovat/zmenšovat FS za běhu
- kontrolní součty
- defragmentace za běhu
- správa oprávnění
- atd.

Struktura disku

- pro jednoduchost předpokládáme, že struktura disku je lineární
- MBR – master boot record: informace o rozdělení disku na svazky + zavaděč
- nověji GPT (GUID Partition Table)
- Tan. 400
- *sektor disku* – obvykle velikost 4 kB, 512 B
- ⇒ pracuje se s většími bloky 1-32 kB (často 4 kB)
- ⇒ optimální velikost bloku? (rychlosť vs. úspora místa)
- jednotlivé svazky obsahují souborový systém (vlastní organizace dat)
- VFS – virtualní souborový systém (Sta. 567)
- je potřeba si udržovat informace o jednotlivých souborech (FCB, inody)
- cache

Alokace diskového prostoru

Alokace souvislých bloků

- soubory jsou ukládány na disk za sebe v souvislých blocích
- rychlé sekvenční čtení, problém s uvolněnými soubory
- CD?

Soubor jako spojový seznam

- FS je rozdelený na bloky
- každý blok má ukazatel na následující
- rychlé sekvenční čtení; problematický náhodný přístup (nutnost číst vše) + poškození disku
- varianta: uchovávání odkazů na bloky ve spec. tabulce (FAT)

Indexová alokace

- soubor si nese informaci o svém uložení v blocích (struktura na začátku souboru)
- problém s velkými soubory \Rightarrow víceúrovňové tabulky

Evidence volného místa

- je potřeba udržovat informace o volném místě
- použití spojového seznamu volných bloků (možné použít volné bloky); jako u souborů
- vylepšení \Rightarrow rozsahy volných bloků (problém při fragmentaci)
- bitmapy – každý bit udává, jestli je daný blok volný (nutné místo – obvykle méně než promile kapacity)

Přidělování volného místa

- je žádoucí zapisovat data do souvislých volných bloků \Rightarrow eliminace přesunů hlavičky
- heuristické algoritmy (složité na testování)
- problematické zaplnění disku nad 95 % a současné zapisování více velkých souborů

Adresáře

- organizace adresářů \Rightarrow vliv na výkon
- různé struktury
 - spojový seznam – jednoduchá implementace; větší složitost
 - hash tabulka (komplikace s implementací)
 - varianty B-stromů (časté u moderních FS)
- umístění informací o souborech
 - součást adresáře
 - součást souboru (UNIX) \Rightarrow problém: listování adresáře \times možnost mít soubor ve více nebo žádném adresáři

Cache a selhání systému

- kvůli rychlejšímu přístupu nejsou často data zapisována přímo na disk \Rightarrow nejdřív do cache
- při výpadku (pád systému, výpadek napájení) nemusí být data ve write-back cache zapsána \Rightarrow poškození FS
- potřeba opravit FS (fsck, chkdsk) \Rightarrow časově náročné
- případné narušení systému
 - jeden uživatel zapíše data na disk a smaže je
 - druhý uživatel vytvoří velký soubor a potom zapsaní metadat vyvolá výpadek
 - po restartu čte data prvního uživatele

Řešení

- synchronní zápis \Rightarrow zpomalení, konzistence nemusí být zaručena
- soft updates – uspořádání zápisů podle určitých pravidel (*BSD)
- žurnálování

Žurnálování

- data se zapisují v transakcích (přesun FS z jednoho konzistentního stavu do druhého)
- nejdřív se transakce zapíše do žurnálu (logu)
- po zapsání do žurnálu je záznam označen spec. značkou a data se můžou zapsat na disk
- po zapsání na disk je zápis z žurnálu odstraněn
- při připojení FS se kontroluje stav žurnálu
 - zápis záznamu do žurnálu nebyl dokončen (transakce se nepovede)
 - případně, transakce se provede podle informací ze žurnálu
- často se žurnálují jen metadata
- žurnál je cyklický; při zaplnění se zapíší/uvolní data ze začátku
- je potřeba atomických zápisů na disk
- cache & buffery komplikují implementaci

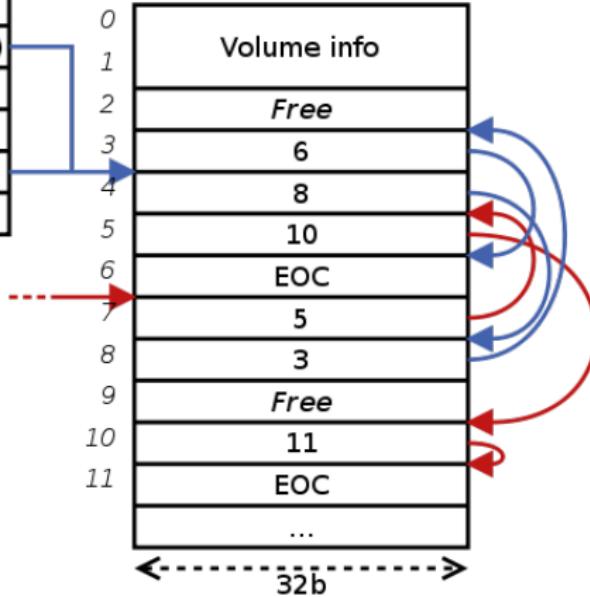
FAT

- souborový systém pro MSDOS (přežil se až do Windows ME)
- jednoduchý design
- soubory se jmény ve tvaru 8.3, nepodporuje oprávnění
- nemá metody proti poškození dat
- disk rozdělený na bloky (clustery)
- soubory popsány pomocí File Allocation Table (FAT) – spojový seznam
- disk rozdělen na úseky:
 - bootsector (rezervovaná oblast) + informace o svazku
 - 2x FAT
 - kořenový adresář
 - data
- adresáře jako soubory; kořenový adresář je vytvořen při inicializaci
- původní FAT nepodporoval adresáře

Directory table entry (32B)

Filename (8B)
Extension (3B)
Attributes (1B)
Reserved (1B)
Create time (3B)
Create date (2B)
Last access date (2B)
First cluster # (MSB, 2B)
Last mod. time (2B)
Last mod. date (2B)
First cluster # (LSB, 2B)
File size (4B)

File allocation table



FAT: varianty

- FAT12, 16, 32: podle velikosti clusteru; (max. kapacity – 32 MB, 2 GB, 8 TB)
- další omezení na velikost souboru

Virtual FAT

- podpora dlouhých jmen (LFN)
- až 256 znaků
- soubor má dvě jména – dlouhé a ve tvaru 8.3
- dlouhá jména uložena jako další záznamy v adresáři

exFAT

- určen pro flash paměti
- podpora větších disků (512 TB/64 ZB)
- podpora v novějších Windows (povedně Windows CE 6)
- zatížen patenty

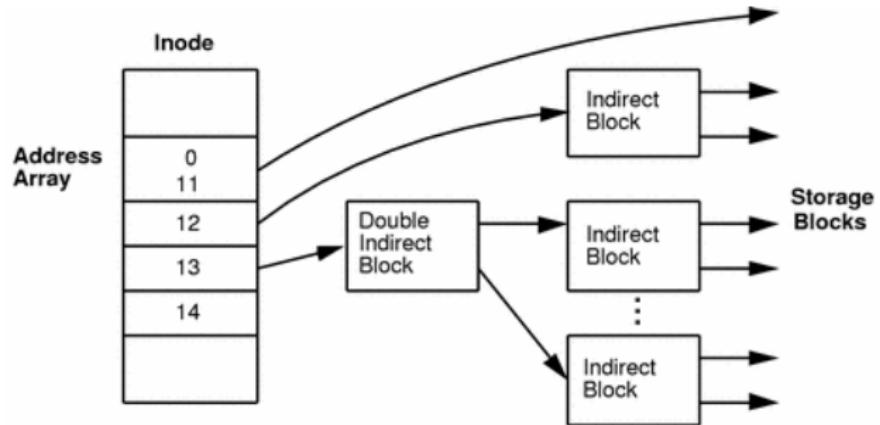
UFS: Unix File System (1/2)

- v různých variantách přítomný v unixových OS – *BSD, Solaris, System V, Linux (ext[234])
- disk se skládá:
 - bootblock – místo pro zavaděč OS
 - superblock – informace o souborovém systému
 - místo pro inody
 - místo pro data

Inoda

- struktura popisující soubor
- informace o souboru
 - typ souboru, vlastníka (UID, GID), oprávnění (rwx)
 - časy (vytvoření, přístup)
 - počet ukazatelů, počet otevřených popisovačů
- informace o uložení dat
 - patnáct ukazatelů na bloky na disku
 - bloky 0-11 ukazují na bloky dat
 - blok 12 – nepřímý blok 1. úrovně
 - blok 13 – nepřímý blok 2. úrovně
 - blok 14 – výkazník

Inode



UFS: Unix File System (2/2)

- struktura inody umožňuje mít *řídké soubory*
- adresář je soubor obsahující sekvenci dvojic (jméno souboru, číslo inody)
- k evidenci volného místa a inod se používají bitmapy
- svazek může být rozdělný na několik tzv. skupin – každá mající vlastní inody, bitmapy, atd. + kopie superblocku \Rightarrow sloučení souvisejících dat \Rightarrow eliminace přesunů hlavičky
- velikost bloku \Rightarrow rychlejší přístup k větším souborům vs. nevyužité místo
- možnost rozdělit blok na několik fragmentů
- konkrétní detaily se mohou lišit
- např. FreeBSD přidává možnost dělat snapshoty

Inode

Directory inode (128B)

Type	Mode
User ID	Group ID
File size	# blocks
# links	Flags
Timestamps (x3)	
Direct blocks (x12)	
Single indirect	
Double indirect	
Triple indirect	

Directory block

.	inode #
..	inode #
passwd	inode #
fstab	inode #
...	...

Indirect block

Direct blocks (x512)

Block # of
block with
512 double
indirect
entries

Block # of
block with
512 single
indirect
entries

File inode (128B)

Type	Mode
User ID	Group ID
File size	# blocks
# links	Flags
Timestamps (x3)	
Direct blocks (x12)	
Single indirect	
Double indirect	
Triple indirect	

File data block

Data

Block #s of
more
directory
blocks

FS v Linuxu

- Linux nemá jeden hlavní FS
- nejčastěji se používá: Ext2/3/4
- název souboru může mít až 256 znaků (s vyjímkou znaků / a \0)
- vychází z UFS
- ext2: maximální velikost souboru 16 GB–2 TB, disku: 2 TB – 16 TB
- ext3: přidává žurnál (3 úrovně – journal, ordered, unordered), binárně kompatibilní s ext2
- ext4: přidává vylepšení
 - maximální velikost souboru 16 TB–2 TB, disku: 1 EB
 - podpora extentů (místo mapování bloků je možné alokovat blok až do velikosti 128 MB)
 - optimalizace alokací
 - lepší práce s časem
- další FS: ReiserFS, Btrfs, JFS, XFS, ...

NTFS: Úvod

- hlavní souborový systém Windows NT
- kořeny v OS/2 a jeho HPFS (vyvíjen od roku 1993)
- velikost clusteru podle velikosti svazku (512 B–4 KB) \Rightarrow max. velikost disku 256 TB
max. velikost souboru 16 TB
- oproti FAT (souborovému systému W9x) ochrana před poškozením + práva
- žurnálování a transakce
- podpora více streamů v jednom souboru
- dlouhé názvy (255 znaků) + unicode
- podpora standardu POSIX; hardlinky, symlinky
- komprese a řídké soubory

Adresáře

- opět technicky soubory; jména v B+ stromech
- některá metadata souborů jsou součástí adresáře

NTFS: Struktura disku (1/2)

- na začátku disku: boot sector
- 12 % MFT (Master File Table); 88 % data souborů
- MFT je soubor popisující všechny soubory na FS (MFT je taky soubor)
- MFT se skládá ze záznamů o velikosti 1 KB
- každý soubor je popsán tímto záznamem
- 32 prvních souborů má speciální určení (\$MFT, \$MFTMirr, \$LogFile, \$Volume, \$Bitmap, \$Boot, \$BadClus, ...)
- informace o souborech včetně jména, časů, atd. uloženy jako záznam v MFT jako dvojice *atribut-hodnota*
- tělo souboru je taky atribut \Rightarrow uniformní přístup; možnost uložit malé soubory přímo do MFT
- alternativní proudy \Rightarrow opět atributy
- v případě potřeby může jeden soubor zabrat více záznamů v MFT
- případně lze použít místo mimo MFT (rezidentní a nerezidentní atributy)

Master file table

0	\$MFT
1	\$MFTMirr
2	\$LogFile
3	\$Volume
4	\$AttrDef
5	.
6	\$Bitmap
7	\$Boot
8	\$BadClus
9	\$Secure
10	\$UpCase
11	\$Extend
12..15	<i>Reserved</i>
16..	<i>User files/directories</i>

File record (1KiB)

Standard information	
Filename	
Data stream	Extents
Attr. 1	Resident
Attr. 2.	Extents
...	...

NTFS: Struktura disku (2/2)

- data v souboru jsou popsána pomocí (atributu) tabulky mapující VCN (virtual cluster number) na LCN (logical cluster number)
- VCN – číslo clusteru v souboru (indexováno od nuly)
- LCN – číslo clusteru ve svazku
- každý záznam v tabulce je ve tvaru: VCN, LCN, počet clusterů, např.

VCN	LCN	počet
0	42	4
4	123	8
32	456	15

Komprese

- řídké soubory
- možnost transparentně komprimovat obsah (vždy po 16 clusterech) \Rightarrow bloky dat zarovnány na 16 clusterů; pokud zabírá míň místa, je komprimován
- čtení i zápis provádí (de)kompresi (LZ77) \Rightarrow dopad na výkon

ISO-9660

- souborový systém pro CD-ROM; podpora všech OS
- zápis jen jednou; sekvenční čtení \Rightarrow není potřeba dělat kompromisy
- logický sektor 2048 B (může být i větší)
- na disku může být více logických svazků; svazek může být na více discích
- na začátku 16 rezervovaných bloků + 1 blok (Primary Volume Descriptor) \Rightarrow informace o disku; odkaz na kořenový adresář
- adresář popsán pomocí záznamů proměnlivé délky (viz Tan. 432)
 - textová data v ASCII
 - binární 2x (little- i big-endian)
- možnosti formátu určeny úrovněmi a rozšířeními
- **Level 1** – soubory 8.3; všechny soubory spojité; 8 úrovní adresářů
- **Level 2** – jména až 31 znaků
- **Level 3** – nespojité soubory (jednotlivé souvislé bloky se mohou opakovat)

ISO-9660: Rozšíření

Rock Ridge

- kompatibilita s unixy
- přidává dlouhá jména
- neomezené zanoření adresářů
- unixová oprávnění
- podpora symbolických odkazů; možnost mít na disku soubory zařízení

Joliet

- kompatibilita s Windows
- přidává dlouhá jména + podporu Unicode
- neomezené zanoření adresářů

UDF: Universal Disk Format

- náhrada za ISO-9660
- používán převážně pro DVD a Blue-ray disky
- dlouhé názvy, soubory až 1EB
- různé varianty formátu:
 - **Plain build** – základní formát (data lze přepisovat pokud médium podporuje; přepis konkrétních sektorů – DVD-RAM, DVD+RW)
 - **Virtual Allocation Table** – inkrementální zápisy (CD-R)
 - **Spare build** – pokud to médium podporuje, lze data přepisovat; zahrnuta obrana proti opotřebení sektorů