B4B35OSY: Operační systémy

Souborové systémy

Michal Sojka[1]

2023-12-07

[1]michal.sojka@cvut.cz

Obsah I

Co je souborový systém?

- Způsob organizace dat na pevném disku
- Data uložená v pojmenovaných souborech
- Soubory v adresářích (složkách)
- Hierarchická struktura adresářů

Terminologie

- Data = obsah souborů
- Metadata = pomocné informace ukládané souborovým systémem (bitmapy, inody, superblok, ...)

Požadavky na souborový systém

- Efektivita (nízká režie) – metadata zaberou méně než *X* % kapacity disku
- Rychlost
- Nízká fragmentace – souvisí s rychlostí (viz dále)
- Spolehlivost (data zůstanou čitelná i po neočekávaném pádu systému) – data mohou být velmi cenná.

Pevný disk

- Trvalé uložení dat (i bez napájení)
- Rotační (HDD), Flash (SSD)
- Posloupnost bloků (sektorů) určité velikosti
- Každý blok je identifikován číslem

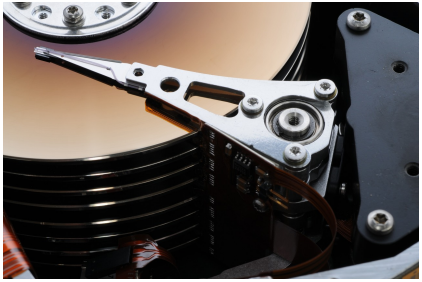

Oddíly (partitions)

- Fyzický disk lze rozdělit na víc logických disků (oddílů, partitions)
- Na začátku disku je tabulka definující typ, (jméno), počáteční a koncový sektor oddílu
  - **Master Boot Record (MBR)** – pozůstatek MS-DOSu, 1. sektor na disku (512 B), obsahuje místo pro 4 oddíly.
  - **GUID Partition Table (GPT)** – modernější, více informací, „neomezený“ počet oddílů.
- Většina souborových systémů využívá jeden logický disk
- Ve zbytku přednášky budeme mluvit o logických discích

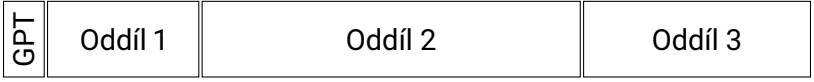

Otázky

- Jak ukládat adresáře?
- Jak zjistit, ve kterých blocích jsou data daného souboru?
- Jak alokovat bloky na disku při vytváření/zvětšování souborů?
- Jak se vypořádat s chybami a pády systému?
- Jak optimalizovat souborové systémy pro rotační disky a Flash paměti?

Adresáře

- Adresář je seznam dvojic (*«jméno souboru», «umístění»*)
- Jméno:
  - V UNIXu všechny znaky kromě / a NUL
  - Ve Windows nesmí obsahovat znaky /\:*”?<>|
- Umístění: kde jsou uložena data daného souboru – viz dále
- Třídění seznamu (položek v adresáři):
  - Seznam není uložen setříděný; třídění provádí až program zobrazující adresář uživateli podle jím zadaných kritérií
    - Třídění podle názvu, data přístupu, typu souboru
    - Pomalé otevírání souborů ve velkých adresářích
  - Vyhledávací B-strom
    - Rychlejší

Rozložení dat na disku

- Souborový systém definuje velikost bloku (např. 4 KiB)
  - Prostor na disku je vždy alokován v násobcích velikosti bloku
- Superblok určuje umístění kořenového adresáře a další informace o souborovém systému
  - Vždy na předem známém místě (např. 1. blok na disku)
  - Často uložen ve více kopiích
- Informace o volných blocích
  - OS musí mít přehled, který blok je volný a který obsazený
  - Podobné jako v alokátorech paměti – např. freelist
  - Typicky bitová mapa (1 bit na blok)
  - Kopie v paměti pro urychlení přístupu (cache)
- Bloky ukládající obsah souborů
  - Existuje mnoho způsobů, jak je organizovat

Překlad cesty k souboru

- Co se děje při otevírání souboru „/jedna/dva/tři“?
  1. Otevře se kořenový adresář „/“ (vždy se ví, kde se najde – superblok)
  2. Najde se v něm záznam „jedna“ a zjistí se jeho *umístění*
  3. Otevře se adresář „jedna“ a najde se záznam „dva“ a jeho *umístění*
  4. Otevře se adresář „dva“, najde se záznam „tři“ a jeho *umístění*
  5. Otevře se soubor „tři“
- Procházení cesty a adresářů po cestě může trvat dlouho
  - Proto je volání `open` odděleno od `read` / `write`
  - Cesta se prochází jen při `open`
  - Položky adresářů se ukládají do vyrovnávací paměti (dentry cache v Linuxu)

Základní možnosti uložení obsahu souboru

- Obsah souboru je typicky uložen ve více blocích (do jednoho se nemusí vejít)
- Jak se zjistí, které bloky to jsou? Více možností:
  - Souvislé bloky
  - Spojové seznamy
  - Indexové struktury

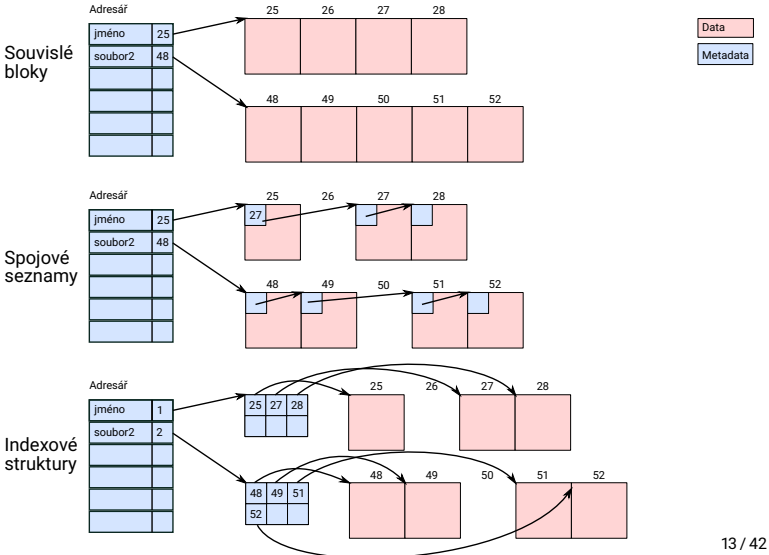

Základní možnosti uložení obsahu – vlastnosti

- Soubor je vždy uložen v souvislém úseku bloků
  - Podobné alokaci paměti
  - Rychlý přístup k datům (lokalita)
  - Neflexibilní, způsobuje fragmentaci a nutnost přemisťovat soubory
- Spojové seznamy
  - Každý blok obsahuje kromě dat i odkaz na další blok, adresář odkazuje na 1. blok souboru
  - Výhodné pro sekvenční přístup k souborům, nevýhodné pro vše ostatní
  - Nemožnost „mapovat“ data z disku přímo do paměti
  - Jeden špatný sektor na disku (porucha) může způsobit „ztrátu“ zbytku souboru
- Indexové struktury
  - „Indexový blok“ obsahuje ukazatele (čísla bloků) na mnoho jiných bloků
  - Vhodnější pro náhodný přístup, stále poměrně dobré pro sekvenční přístup
  - Může být potřeba použít více indexových bloků

Souborový systém FAT

File Allocation Table

- Starý souborový systém s mnoha nedostatky a omezeními.
- Něco mezi spojovými seznamy a indexovou strukturou.
- Základní jednotka „cluster“ (4–32 KiB)
- Max. počet clusterů: FAT12: 2^{12}, FAT16: 2^{16}, FAT32: 2^{28}, exFAT: $2^{32} - 10$
- Rozložení disku:

  - MBR – master boot record (info o soub. systému, tj. velikost, jméno, počet kopií FAT tabulek atd.)
  - FAT1, 2 – dvě kopie FAT tabulky (redundance)
- Specifikace poslední verze FAT (exFAT):
  `https://learn.microsoft.com/en-us/windows/win32/fileio/exfat-specification`

Tabulka FAT

Adresář

jméno	0
soubor2	3
soubor3	7
soubor4	34

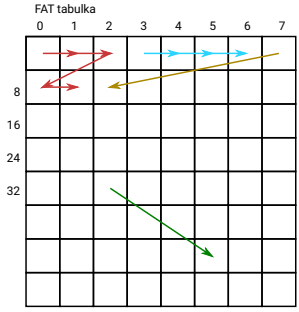

- Jedna položka FAT tabulky má 12/16/32 bitů a odpovídá jednomu clusteru na disku
- Hodnota položky udává číslo následujícího clusteru (konec šipky) nebo -1 značící konec souboru.
- Číslo 1. clusteru se najde v položce adresáře
- Pro urychlení přístupu je tabulka uchovávána v paměti

Nevýhody

- Fragmentace
- Omezená velikost (např. $2^{32} \times 4$KiB)
- Nutnost procházet FAT položky sekvenčně (zpomaluje náhodný přístup u velkých souborů)

Indexový souborový systém

Základ mnoha UNIXových souborových systémů (např. Linuxový ext2 – ext4).

- Metadata o jednotlivých souborech jsou uložena v datové struktuře zvané inode.
- Položka adresáře obsahuje kromě jména souboru i číslo (pořadí) inode
- inode obsahuje pevný počet odkazů na datové bloky
  - Z offsetu (pozice v souboru) lze jednoduše spočítat, který odkaz použít pro přístup k datům (dobré pro náhodný přístup)
- Několik inode se vejde do 1 bloku (velikost inode bývá např. 128 B)

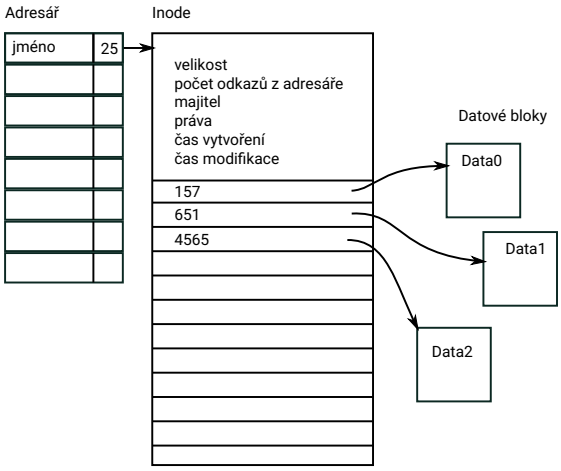

Nepřímé bloky

- Co když je soubor větší, než počet odkazů na datové bloky v inode?
- Odkaz na další bloky nepřímo, přes blok odkazů
- Nepřímé bloky mohou být i v dalších úrovních
  - I u nepřímých bloků lze jednoduše spočítat, který odkaz použít pro přístup k datům (n-ární vyhledávací strom – dobré pro náhodný přístup)

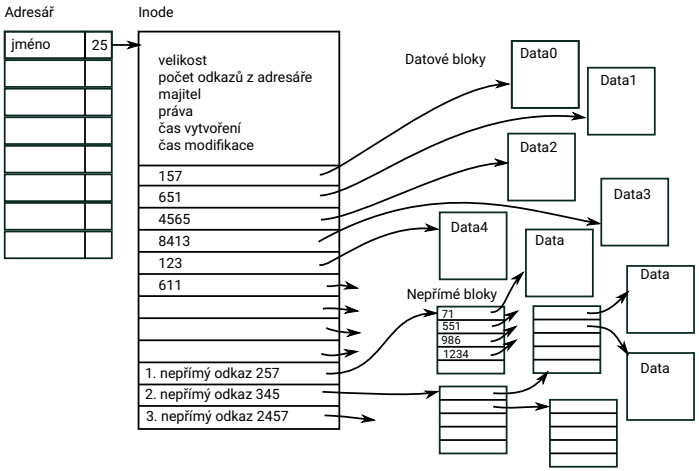

Rozložení na disku

- Pevný počet inodů
- inode lze nalézt na základě jeho indexu v tabulce
- inode je zkratka *index node*
- Superblok – informace o souborovém systému
  - celková délka, počet inode, …
  - počet volných bloků a inode
  - odkaz na záložní kopii superbloku
- Kořenový adresář: např. v inode č. 0

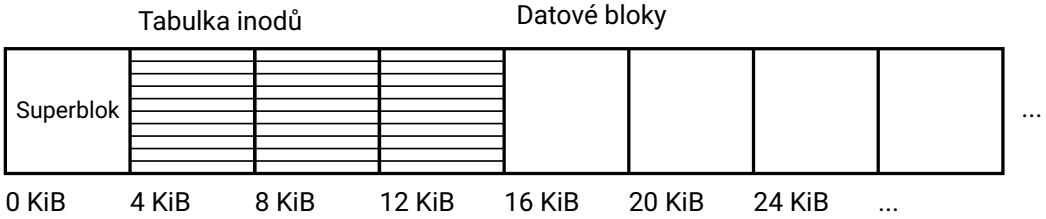

Hledání volného místa

- Jak poznat, který inode je volný (např. při vytváření nového souboru)?
  - Např. sekvenčním procházením všech inode (neefektivní, ale fungovalo by to)
- Jak poznat, který datový blok je volný?
  - Těžko – i blok plný nul může být platným obsahem souboru
- Bitové mapy pro inode a datové bloky
  - každý bit udává obsazenost inodu nebo datového bloku
  - místo prohledávání inodů prohledávám jen bity (rychlejší - např. jedna instrukce = 64 porovnání)

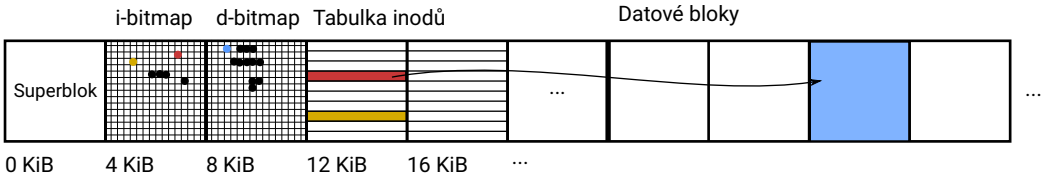

Skupiny (ext2–4)

- Při práci se souborem je potřeba pracovat s bitmapou, inodem a datovými bloky
- Disky (zejména rotační, ale částečně i SSD) přistupují rychleji k blokům uložených blízko sebe
- Co když datové bloky budou až na konci disku?
  - Hlavičky disků musí pořád jezdit mezi začátkem (bitmapy, tab. inode) a koncem disku (data)
- Řešení: skupiny
  - Souborový systém se snaží alokovat datové bloky ve stejné skupině jako inode souboru

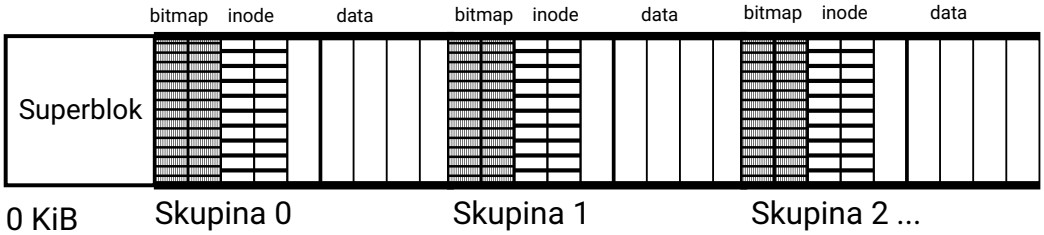

Extents

- Tabulky bloků nejsou efektivní pro obrovské soubory, velká režie
- Moderní souborové systémy mohou odkazovat místo na jednotlivé bloky na celé souvislé skupiny bloků
- Odkazovaná skupina s více než jedním blokem se nazývá extent
- Implementováno v: ext4, NTFS, btrfs, …

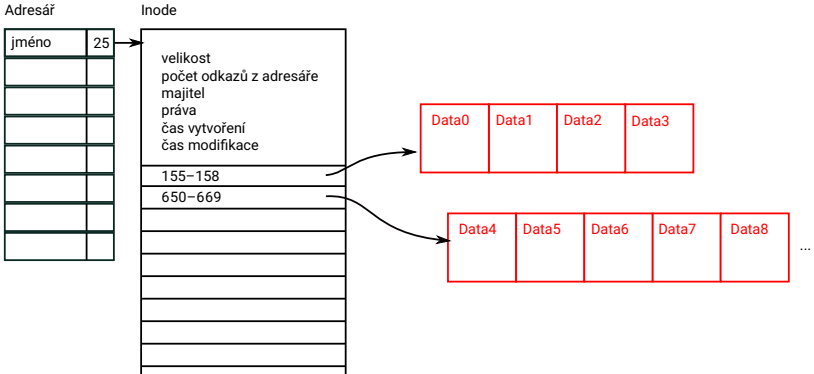

Konzistence dat

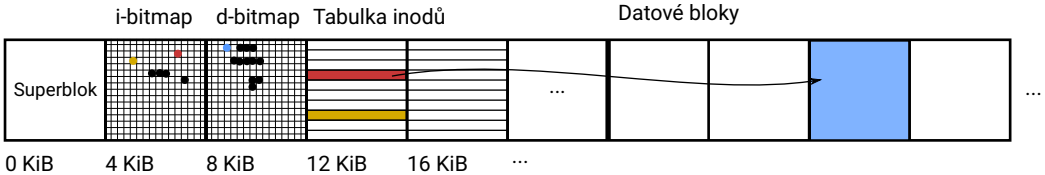

- Při zápisu do souboru je potřeba měnit: bitmapy, inode/nepřímé bloky a data
- Hardware disku garantuje atomický zápis pouze jednoho sektoru
- V jakém pořadí bloky zapisovat na disk?
- Co se stane, když dojde k pádu či vypnutí systému v průběhu zapisování při následujících pořadích zápisu?
  - bitmapa, inode/nepřímé bloky, data
  - inode, data, bitmapa
  - bitmapa, data, inode
- Vždy může vzniknout v datech nějaká nekonzistence!
  (bude porušena integrita souborového systému)
  - Např. můžu zajistit konzistenci při vytváření či zvětšování souborů, ale zkracování

Anketa – prodlužování souboru

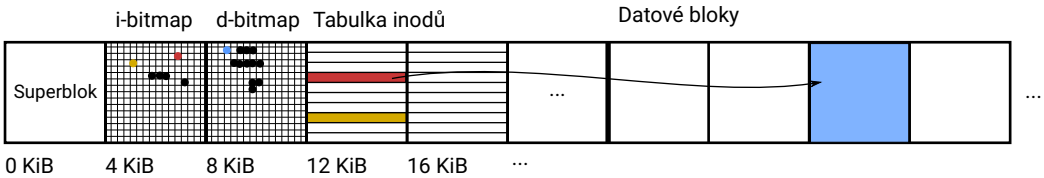

Uvažujme, že souborový systém zapisuje v pořadí:
1) bitmapa, 2) inode, 3) datový blok.

Co se stane, když připojuji data na konec souboru X a dojde k pádu systému mezi 2) a 3)?

A Při zápisu dat do jiného souboru může dojít k přepsání části X.

B Na konci souboru se objeví „náhodná data“.

C Soubor X bude nečitelný.

Anketa 2 – zkracování souboru

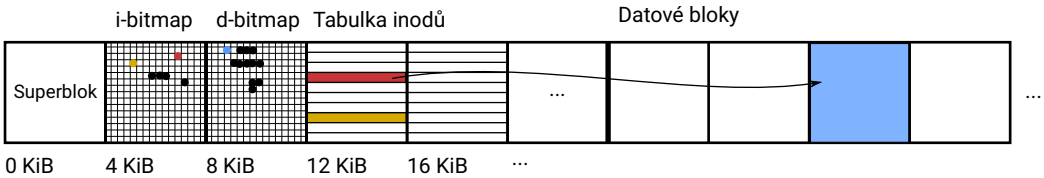

Uvažujme, že souborový systém zapisuje v pořadí:
1) bitmapa, 2) inode, 3) datový blok.

Co se stane, když zkracuji soubor X na 0 (truncate) a dojde k pádu systému mezi 1) a 2)?

A Při zápisu dat do jiného souboru může dojít k přepsání části X.

B Na konci souboru se objeví „náhodná data“.

C Soubor X bude nečitelný.

Možná řešení problémů s integritou souborového systému

1. Kontrola souborového systému při startu počítače
   - projdu všechny inode a nepřímé bloky
   - zjistím, jestli bitmapa volných inode souhlasí se stavem tabulky inode
   - zjistím, jestli bitmapa datových bloků souhlasí s informacemi v inode
   - zjistím, jestli dva inode neodkazují na stejné bloky
   - …
   - Pomalé, zejména na velkých discích!
2. Žurnálování
3. Souborové systémy používající copy-on-write (btrfs, ...)

Žurnálovací systém souborů

- Před tím, než se začne souborový systém modifikovat, se uloží seznam potřebných modifikací na vyhrazené místo – žurnál
- Pokud dojde k pádu systému, zkontroluje se žurnál, změny disku v něm nalezené se provedou dodatečně
- Žurnálování se někdy nazývá „dopředné logování“
- Implementováno: NTFS, ext3, …

Struktura žurnálovacího systému souborů (ext3)

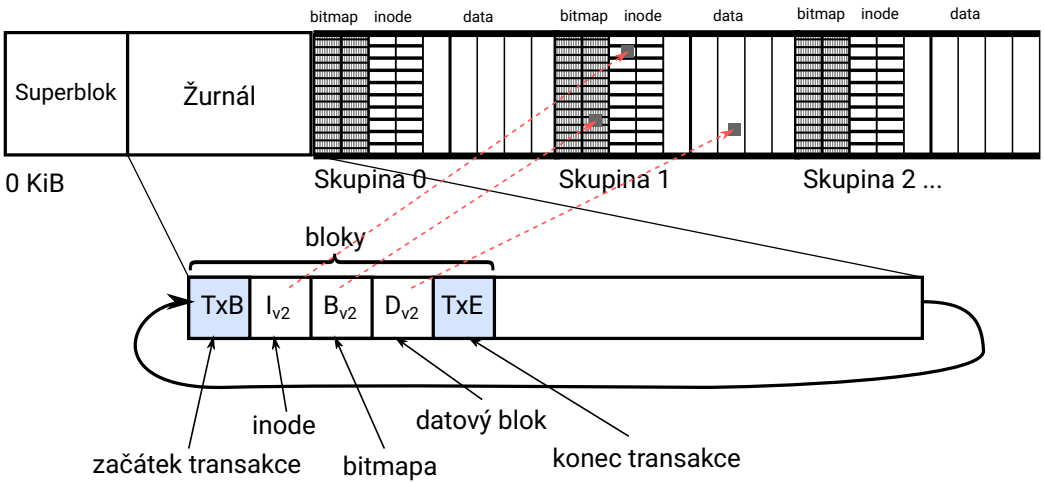

Bezpečný způsob změny souborového systému

1. Commit – zapsání transakce do žurnálu
   - *TxB*: obsahuje id transakce a čísla bloků měněného inode, bitmap a dat
   - I_{v2}: nová verze bloku s inode
   - B_{v2}: nová verze bloku bitmapy
   - D_{v2}: nový datový blok
   - *TxE*: id transakce, kontrolní součet
2. Checkpoint – provedení změn
   1. aktualizace bloků v souborovém systému (inode, bitmapy, data)
   2. odstranění transakce z žurnálu

Možné scénáře pádu systému a následné obnovy souborového systému

1. Do žurnálu se zapíše pouze část transakce
   - Souborový systém (SS) je konzistentní a obsahuje původní data
   - Při startu OS se zjistí, že transakce v žurnálu není kompletní (viz další slide) a ignoruje se.
2. Do žurnálu zapíšeme celou transakci, ale neaktualizují se bloky SS
   - Při startu OS aktualizujeme bloky SS podle informací v žurnálu
3. Zapíšeme celou transakci, aktualizujeme bloky systému, ale neodstraníme transakci ze žurnálu
   - Při startu OS se bloky přepíší ze žurnálu – žádná změna, už zapsané byly a transakce se odstraní ze žurnálu
4. Do žurnálu se zapíše pouze část transakce (např. *TxB*, I_{v2} a *TxE*, bez B_{v2} a D_{v2})
   - Problém!
   - HW disků se snaží provádět optimalizace a může změnit pořadí vykonávání příkazů zaslaných OS
   - OS musí disku posílat speciální příkazy (tzv. bariéry), aby se data skutečně zapsala v potřebném pořadí
   - Bariéra garantuje, že příkazy zaslané před bariérou budou vykonány před příkazy zaslanými po bariéře
   - Při zápisu transakce do žurnálu se tedy disku posílá sekvence příkazů:
     TxB, I_{v2}, B_{v2}, D_{v2}, bariéra, *TxE*

Nalezení a aktualizace nevyřízených transakcí

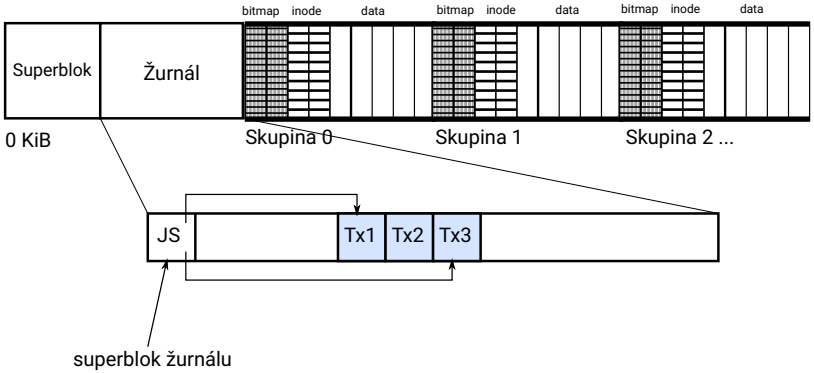

- V jednom okamžiku může vypadat žurnál např. takto (kruhový buffer)
- Superblok obsahuje odkazy na první a poslední platnou transakci v žurnálu
- Commit transakce nebo její smazání se provede atomickým zápisem superbloku se změněnými odkazy do žurnálu

Rychlost žurnálu

- Pomalé
  - Commit: zápis metadat a dat do žurnálu
  - Checkpoint: aktualizace inode, bitmapy a dat podle transakce
  - Vše se zapisuje na disk dvakrát!
- Rychlejší:
  - Zapsání dat přímo do daného bloku + bariéra
  - Commit metadat: Když jsou data uložena, zapsání transakce pro změnu metadat do žurnálu
  - Checkpoint: Aktualizace inode a bitmap podle transakce
  - Jaké chyby v SS mohou nastat při pádu systému?
    - Data budou částečně aktualizována, ale ne např. velikost souboru
- Ještě rychlejší:
  - Zapsání dat přímo do daného bloku
  - Commit metadat: zapsání transakce pro změnu metadat do žurnálu
  - Checkpoint: Aktualizace inode a bitmap podle transakce (doufáme, že data zapsána také)
  - Jaké chyby v SS mohou nastat při pádu systému?
    - V souboru se mi mohou objevit náhodná data (odjinud)

Všechny módy zajišťují základní integritu SS – nekonzistentní budou maximálně soubory, se kterými se pracovalo při pádu, ne celý SS.

Souborový systém ext4/jbd2

- Uživatel si může zvolit, jaký mód žurnálování se použije
  - journal: všechna data i metadata se zapisují skrze žurnál
  - ordered (výchozí nastavení): data se zapisují přímo, metadata skrze žurnál po zapsání dat
  - writeback: data se zapisují přímo, ale jejich zápis nemusí proběhnout před zápisem metadat (skrze žurnál)
- Typická velikost žurnálu: 128 MiB

Vlastnosti Flash pamětí

- Zapisovat lze pouze do vymazaného bloku
- Zapsat na jedno místo lze pouze jednou
- Mazací blok bývá mnohem větší (např. 4 MiB) než blok souborového systému (4 KiB)
- Každý blok garantuje pouze určitý počet přepsání – např. 100 tisíc

Důsledky pro „tradiční“ souborový systém?

- Často se měnící data (např. bitmapy, či FAT tabulka) drasticky snižují životnost paměti
- Změna jednoho bytu v souboru znamená smazání a znovu zapsání 4 MiB
- Garance poskytované žurnálovacím souborovým systémem neplatí pro Flash
  - Commit žurnálu musí vymazat 4 MiB data okolo commitované transakce
  - Pokud systém havaruje mezi smazáním a zápisem, přijdeme o data v žurnálu

Řešení

1. Nepoužívat Flash čipy samostatně, ale v kombinaci s řadičem, implementující „Flash Translation Layer“ (FTL)
   - Mapuje logická čísla sektorů zaslaných OS na bloky flash pamětí tak, aby nedocházelo k nežádoucím jevům (např. neustálé přepisování stejného bloku)
   - Implementováno v SSD dicích, SD kartách, USB pamětech apod.
   - SD karty/USB paměti mají FTL často optimalizovaný pro souborový systém FAT.
     - Pokud se použije jiný souborový systém, je to pomalé a paměť dlouho nevydrží
2. Použít speciální souborové systémy pro Flash paměti
   - Většinou používají princip „copy-on-write“
   - UBIFS, JFFS2, NILFS, …

Protokolovací souborové systémy

Log-Structured file systems

- Data se čtou převážně z vyrovnávací paměti (page cache)
- Stačí se zaměřit na operace zápisu – snaha je zapisovat data rovnoměrně po celé oblasti disku
  - Zapisuje se „od začátku do konce“ disku, starší data se nikdy nemění, ale jejich změněné kopie se zapíší na konec.
  - Zápis velkých souvislých bloků dat je velmi efektivní (není třeba znovu zapisovat nezměněná data v mazacím bloku)
- Stav celého souborového systému je dán zaznamenaným protokolem událostí
  Příklad: zápis dvou souborů na disk a modifikace prvního z nich

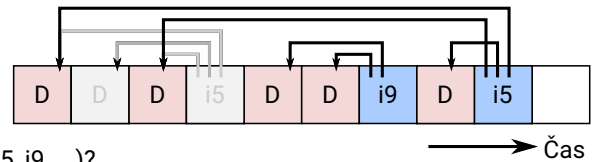

- Jak najdeme inody (i5, i9, ...)?
  - Sekvenčně projdeme celý disk a najdeme je. Pomalé :-(

Mapa inodů

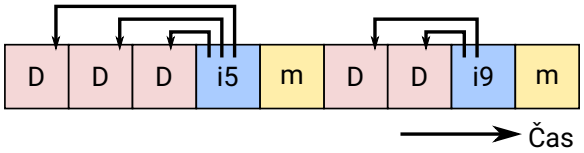

- Abychom nemuseli při startu systému procházet celý disk, můžeme si po každé změně SS uložit aktuální „mapu inodů“ (m)
- Mapa inodů obsahuje tabulku pro převod čísel inodů na čísla bloků
- Jak zjistíme, která verze mapy je poslední?

Kontrolní region

Check region (CR)

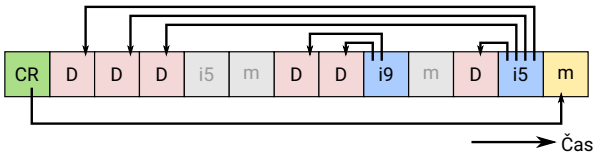

Čtení souboru

- Přečti kontrolní region
- Najdi pozici mapy inodů (m)
- Najdi inode
- Přečti datové bloky

Zápis souboru

- Zapiš datové bloky
- Zapiš změněnou kopii inode
- Zapiš změněnou kopii mapy inodů
- Aktualizuj kontrolní region

- CR se pořád přepisuje – nevadí to?
  - Nevadí, pokud máme např. SD kartu optimalizovanou pro FAT (viz slide 39), která je optimalizovaná pro častý přepis počátečních bloků s FAT tabullkou
  - Využíváno např. F2FS (Samsung)