



Operačné systémy / Súborový systém

Dušan Bernát

`bernat@fmph.uniba.sk`

- Súbory a typy súborov,
- adresárová štruktúra,
- prístupové práva,
- atribúty,
- i-uzol,
- štruktúra súborového systému *ext2* (superblok, mapa voľných blokov, mapa voľných i-uzlov, tabuľka i-uzlov, dátové bloky),
- *inotify*.

Čo je súbor?

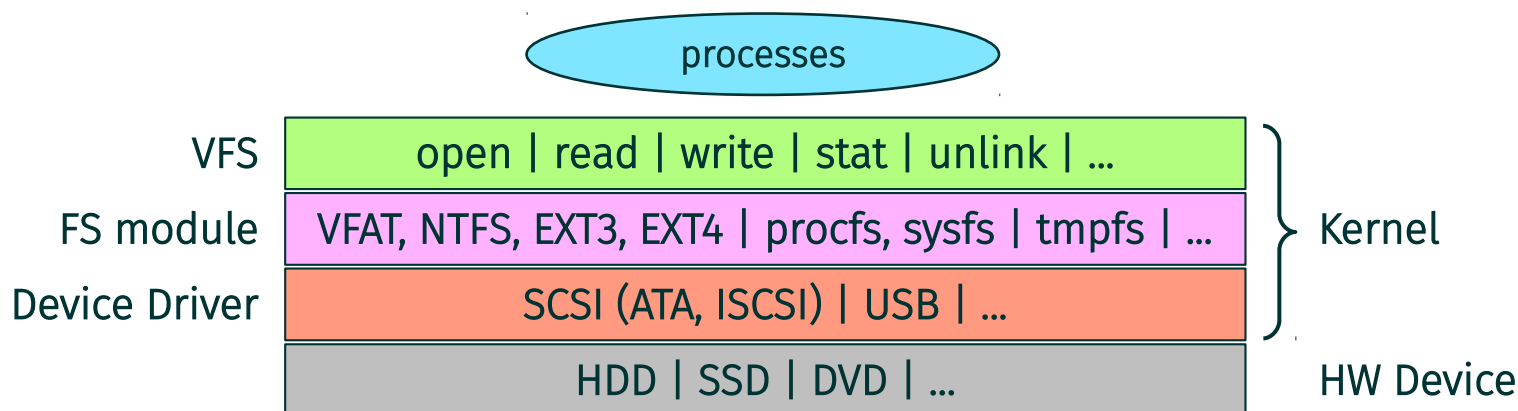
- Poskytuje abstraktný pohľad na súbor ako **postupnosť bajtov**.
 - Táto abstrakcia umožňuje pomocou súboru reprezentovať nie len dáta na disku, ale aj sieťové spojenia, vstup a výstup procesu, zariadenia (terminál), ...
- Transformuje požiadavky na operácie so súbormi na operácie s diskovými blokmi.
- Organizuje:
 - bloky do súborov, sektory do blokov, bloky do skupín (fyzická organizácia),
 - súbory do adresárov (logická organizácia).
- Spravuje informácie o súboroch.
- Riadi prístup k súborom.

- Operačný systém poskytuje procesom jednotné rozhranie pre prácu so súbormi, bez ohľadu na konkrétnu organizáciu.
 - Túto abstrakciu zabezpečuje vrstva **VFS** (*Virtual File System*).
 - open, read, write, seek, unlink, stat, mkdir, rmdir, lock, ...
 - Prevádza názvy súborov na potrebné údaje, spravuje otvorené súbory, riadi prístup.
- Súborových systémov, teda spôsobov **organizácie** súborov do blokov, môže byť mnoho (FAT, NTFS, ZFS, EXT4, UFS, ...).
 - Dátové bloky sú číslované, konvertuje číslo bloku na sektor.
 - Spravuje voľné bloky, alokuje bloky, udržiava potrebné štruktúry.
- Dáta súborov môžu byť uložené na rôznych fyzických médiách (harddisky, SSD, DVD, sieťové disky, ...).
 - Prístup ku konkrétnemu hardvéru zabezpečujú ovládače zariadení.

Hierarchia súborového systému OS



- Vrstvu VFS má implementovanú viacero operačných systémov.
- Poskytuje operácie rovnaké pre všetky FS.



- Implementácia súborov – súborový systém musí vedieť, ktoré dátové bloky patria k súboru.
- Využíva k tomu štruktúry, tiež uložené na médiu ktoré je rozdelené na bloky (číslované od 0).
- Možných spôsobov usporiadania je viacero, napríklad:
 - 1) Súvislé oblasti po sebe idúcich blokov.
 - 2) Zoznam blokov.
 - 3) Alokácia založená na i-uzloch.

1) Súvislá alokácia



- Dáta súboru sú umiestňované v po sebe idúcich blokoch.
- Implementácia je jednoduchá. Pre každý súbor stačí poznať číslo prvého bloku a veľkosť (počet blokov).
 - Môže byť uchovávané v adresári s názvom súboru.
- Čítanie je rýchle. Najmä sekvenčné, z HDD. Po nastavení hlavičky idú dáta za sebou.
- Súbory majú rôznu veľkosť → Ako vznikajú a zanikajú, voľné miesto podlieha fragmentácii.
- Pri vytváraní súboru je potrebné nájsť vhodné miesto. Konečná veľkosť súboru však nemusí byť pri vytváraní známa.
- Dnes sa používa pre súborové systémy určené pre RO (respektíve *Write-once*) médiá, napr. CD, DVD a pod.
 - Veľkosti všetkých súborov sú známe. Odpadá aj problém s fragmentáciou.

2) Zoznam blokov




- Každý dátový blok súboru obsahuje odkaz na nasledujúci blok.
 - Riadiace informácie zaberaajú aj časti dátových blokov (napr. prvé slovo).
 - Veľkosť miesta pre dáta v bloku už nemusí byť mocninou dvoch.
- Sekvenčný prístup je jednoduchý a rýchly.
- Náhodný (priamy) prístup k dátam súboru nie je možné realizovať bez prečítania všetkých predchádzajúcich dátových blokov.
 - Veľmi neefektívne.
- Zoznamy blokov tvoriacich súbor môžu byť umiestnené v samostatnej tabuľke, mimo dátové bloky.
 - Tým sa uvedené nevýhody odstránia.
 - Tabuľka sa nazýva FAT (*File Allocation Table*).

- Každému bloku zodpovedá jedna položka v tabuľke FAT.
 - Bez ohľadu na to, či je blok využitý.
- Položka obsahuje číslo nasledujúceho bloku (položky), alebo značku konca súboru (neplatné číslo bloku).
- Položky blokov jedného súboru sú roptýlené po celej tabuľke. Pre prístup k jednému súboru je teda potrebná celá tabuľka.
- Pre veľké disky (a veľký počet blokov) sa tabuľka stáva príliš veľkou.
 - Nepoužíva sa pre disky väčšie než 200 MB.
- Napríklad:
 - Veľkosť disku $S = 128 \text{ GB}$, veľkosť bloku $BS = 4 \text{ kB}$, veľkosť položky $S_e = 4 \text{ B}$.
 - Počet blokov: $n = S / BS = 128 \cdot 2^{30} / 4 \cdot 2^{10} = 32 \cdot 2^{20} = 32 \text{ M}$
 - Veľkosť FAT (réžia): $S_{\text{FAT}} = n \cdot S_e = 32 \cdot 2^{20} \cdot 4 \text{ B} = 128 \text{ MB}$

FAT (File Allocation Table)



- FAT sa používala v MSDOS, FAT12 (32MB), FAT16 (2GB), FAT32 (2TB) vo Windows. Linux poskytuje RW podporu cez FS VFAT.
- Názvy súborov boli obmedzené na 8.3, resp. 255 znakov.
- Súborový systém obsahoval dve identické kópie FAT.



3) Alokácia založená na i-uzloch



- Tzv. i-uzol (*i-node*) je dátová štruktúra reprezentujúca súbor.
 - Každému súboru prislúcha práve jeden i-uzol.
 - Obsahuje všetky metadáta súboru:
 - prístupové práva, vlastníka, skupinu, príznaky,
 - veľkosť, počet blokov, počet liniek,
 - časy modifikácie obsahu súboru, modifikácie i-uzla, prístupu, zmazania, ...
 - Neobsahuje meno súboru.
- Obsahuje zoznam odkazov na bloky s dátami súboru.
 - Niekoľko priamych a zopár nepriamych, dvojitonepriamych, ...
 - Nepriame bloky sa nealokujú, pokiaľ nie sú potrebné (pre menšie súbory).
- Pre prístup k súboru postačujú informácie z jeho i-uzla.
 - Pri otvorení súboru môže byť skopírovaný do pamäte pre urýchlenie ďalších operácií.
 - Pri prístupe k väčším súborom je potrebné načítať aj bloky ukazovateľov.
- Tento spôsob využívajú všetky unixové OS, tiež Windows NTFS.



- Aká je maximálna veľkosť súboru?
- Koľko miesta zaberajú odkazy?
- Aký vplyv na dobu prístupu majú nepriame bloky?
- Koľko by malo byť jednotlivých typov odkazov v i-uzle?
- Koľko by malo byť i-uzlov?
- Aký je vzťah veľkosti súborového systému a veľkosti čísla bloku?

Alokácia blokov

- Aby bolo čítanie súboru čo najrýchlejšie, je výhodné alokovať dátové bloky v súvislých skupinách.
 - Fragmentácia dát zvyšuje dobu prístupu.
 - Platí to najmä pre klasické harddisky, pre SSD to nemusí byť tak.
- Veľkosť súboru nemusí byť vopred známa. Ako dosiahnuť súvislú alokáciu blokov?
- Prealokácia – pri alokácii bloku sa priamo v i-uzle vyhradí aj niekoľko (8) nasledujúcich. Využijú sa neskôr, pri zväčšovaní súboru.
 - Využívalo sa v ext2, nebolo kompatibilné so žurnálmi ext3.
- Rezervačné okno – pri alokácii blokov jadro vyhradí v pamäti súvislý rozsah blokov z ktorého prideľuje len jednému i-uzlu. Okná rôznych i-uzlov sa neprekrývajú.

- Bloky určené na zápis do súboru sa nezapíšu, až kým nie je potrebné uvoľniť pamäť (*allocate on flush*).
- Zvyšuje sa tým šanca, že v čase skutočného zápisu bude možné alokovať na jedekrát už všetky potrebné bloky.
 - Znižuje sa potreba viacnásobnej alokácie pre jeden súbor.
- Dočasné súbory sa možno vôbec nedostanú na disk, čo môže podstatne šetriť čas.
- Problém so stratou dát pri páde.

- Objem metadát potrebných na uchovanie zoznamu všetkých dátových blokov patriacich súboru môže byť pre veľké súbory značný.
 - Tiež veľká réžia pri odstraňovaní veľkých súborov.
- V prípade, že súbor má alokované súvislé oblasti blokov, môže byť výhodnejšie uchovávať pre každý úsek číslo začiatočného a koncového bloku úseku.
- Takýto súvislý blok sa nazýva *extent*.
 - Napr. ext4 ich využíva, čo je indikované atribútom “e” súboru.
 - *mount option* **EXT4_FEATURE_INCOMPAT_EXTENTS**
- Pri veľkej fragmentácii súboru môžu byť tiež potrebné dodatočné bloky pre zoznam úsekov.

- Nie je možné alokovať menej než jeden blok.
- Posledný blok súboru typicky nebude obsadený celý. Malé súbory nezaplnia ani jeden blok.
- Čím väčšia veľkosť bloku, tým väčšia interná fragmentácia.
- *Tail-merging* – spájanie koncov súborov.
 - Koncové časti viacerých súborov sú umiestnené v jednom bloku.
 - Zvyšuje to efektívnosť využitia diskového priestoru (znižuje to fragmentáciu voľného miesta), zároveň zvyšuje fragmentáciu dát, čo môže viesť k potrebe viacerých čítaní pri prístupe k dátam.
 - Je to výhodné najmä pre skupiny malých súborov. V tomto prípade je pravdepodobné, že *read-ahead* stratégia preniesie blok s koncami pri jednom čítaní spolu s predchádzajúcimi blokmi súborov.


Príklad: Štruktúra i-uzla v EXT2




```
#include <ext2fs/ext2_fs.h>
struct ext2_inode {
    __u16 i_mode;           /* File mode */
    __u16 i_uid;            /* Low 16 bits of Owner Uid */
    __u32 i_size;           /* Size in bytes */
    __u32 i_atime;          /* Access time */
    __u32 i_ctime;          /* Creation time */
    __u32 i_mtime;          /* Modification time */
    __u32 i_dtime;          /* Deletion time */
    __u16 i_gid;            /* Low 16 bits of Group Id */
    __u16 i_links_count;    /* Links count */
    __u32 i_blocks;         /* Blocks count */
    __u32 i_flags;          /* File flags */
    __u32 i_block[EXT2_N_BLOCKS]; /* Pointers to blocks */
    __u32 i_generation;     /* File version (for NFS) */
    __u32 i_file_acl;       /* File ACL */
    __u32 i_dir_acl;        /* Directory ACL */
    __u32 i_faddr;          /* Fragment address */
    ...
}
```

Adresárová štruktúra

- Adresár združuje viacero súborov.
 - Obsahuje názvy súborov, ktoré do neho patria.
- Spája tiež názov súboru s jeho umiestnením na disku.
 - Priradzuje názvu súboru pozíciu vo FAT, alebo číslo i-uzla.
- Adresáre môžu byť usporiadané, väčšinou tvoria strom.
- Položka adresára v MS DOS:
 - Konštantná veľkosť, obmedzený názov súboru.
 - Bloky sú alokované súvislo.



- Položka adresára v CP/M:
 - V systéme bol len jeden adresár (nájsť súbor bolo jednoduché).
 - Konštantná veľkosť, obmedzený názov súboru.
 - Obsahuje zoznam blokov tvoriacich súbor.
 - Ak bol súbor väčší, alokovalo sa viacero položiek. Položky toho istého súboru sa usporiadavali cez pole **Extent**.



- Pôvodný System V Unix mal 16 bajtovú položku adresára. Obsahovala len 2B pre číslo i-uzla a 14B pre názov súboru.
- Dnešné systémy umožňujú premenlivú dĺžku názvu súboru.
 - Položka nemá konštantnú veľkosť. Adresár je pole štruktúr (položiek).
- Keď sa položka vymaže, zlúči sa s predchádzajúcou (zväčší sa jej dĺžka).
- Adresár je tiež súbor (má vlastný i-uzol aj dátové bloky). Ide však o súbor zvláštného typu. Jeho štruktúra je daná.



- Adreserárová štruktúra je strom. Má jeden koreň, označuje sa /.
- Názov súboru nemôže obsahovať znak / (s výnimkou koreňového adresára) a znak s kódom 0.
 - Znak / sa používa ako oddelovač adresárov v ceste, 0 názov vždy ukončí (OS je naprogramovaný v C).
- Absolútna cesta k súboru sa začína vždy od koreňového adresára. Je jednoznačná.
 - Napr: `/etc/sysconfig/network-scripts/ifcfg-eth0`
- Relatívna cesta sa začína v aktuálnom adresári. Každý proces má vždy práve jeden aktuálny adresár (*current working directory*).
 - Aktuálny adresár je súčasťou PCB ((`task_struct`) `current` → `fs` → `pwd`).
 - Nastavuje sa systémovým volaním `chdir()`, dá sa zistiť cez `getcwd()`.

- Priradenie názvu súboru k číslu i-uzla v adresári sa nazýva linka (*hard link*).
 - Na jeden súbor, čiže jeden i-uzol, môžu odkazovať aj viaceré názvy z toho istého, alebo aj rôznych adresárov. Jeden súbor tak môže mať viacero rovnocenných názvov, obsah je len jeden.
 - Počet odkazov (počet liniek) je súčasťou i-uzla. Volania `link()` a `unlink()`.
 - Keď počet liniek klesne na nulu (teda keď sa zmaže aj posledný názov tohto súboru) a súbor sa nepoužíva, dátové bloky sa uvoľnia a i-uzol sa označí ako voľný.
- Každý adresár, aj prázdny, obsahuje minimálne dve položky.
 - Jedna ukazuje na seba “.” a druhá na rodičovský adresár “..”, teda na adresár, ktorý obsahuje tento adresár. Výnimkou je koreňový adresár, kde sú obe položky zhodné.
 - Napr: `./a.out`, `../../etc/hosts`, `/etc/../../etc/sysconfig/network-scripts/` alebo `/etc/./sysconfig/../../network-scripts/`
- `i_links_count` má 16 bitov, čo limituje maximálny počet podadresárov.

- V súborovom systéme je zvyčajne niekoľko i-uzlov obsadených bez toho, že by mali priradené meno.
- Číslo prvého použiteľného i-uzla je v superbloku (`__u32 s_first_ino`), typicky 11.


```
#include <ext2fs/ext2_fs.h>

#define EXT2_BAD_INO          1      /* Bad blocks inode */
#define EXT2_ROOT_INO        2      /* Root inode */
#define EXT2_ACL_IDX_INO     3      /* ACL inode */
#define EXT2_ACL_DATA_INO    4      /* ACL inode */
#define EXT2_BOOT_LOADER_INO 5      /* Boot loader inode */
#define EXT2_UNDEL_DIR_INO   6      /* Undelete directory
                                     inode */


#define EXT2_RESIZE_INO       7      /* Reserved group
                                     descriptors inode */

#define EXT2_JOURNAL_INO     8      /* Journal inode */
```

Štruktúra adresárov a i-uzol



Hard linka



- Jadro OS udržiava tabuľku používaných v-uzlov (**vnode**).
- Štruktúra **vnode**, na rozdiel od i-uzla, je nezávislá od konkrétného súborového systému.
 - Napríklad FS na MS Dose nemal žiadne i-uzly.
 - Štruktúra **vnode** reprezentuje súbor ľubovoľného súborového systému.
 - Štruktúra **vnode** existuje vždy len v pamäti, i-uzol na disku.
- Štruktúra **vnode** obsahuje:
 - Počet odkazov na tento vnode (**vn_refcount**), koľkokrát je práve otvorený (**vn_opencount**), zoznam zámkov pre výlučný prístup (**vn_countlock**), ukazovateľ na súborový systém ktorý súbor obsahuje (**vn_fs**), metadáta súboru konkrétného FS (**vn_data**, napr. i-uzol), operácie nad týmto súborom (**vn_ops**).
- Operácie (open, read, write, ...) môžu byť špecifické pre daný súborový systém.

Vnode table



Process A descriptor table

0	●
1	●
2	●
3	●
4	
5	

open("/tmp/A.txt", O_RDONLY);
→ 3

System file table

refcount	seek	mode	vnode
1	0	r	●
2	0	w	●
1	0	r	●

Vnode table

struct vnode
vn_refcount (2), ... ●
vn_refcount (1), ... ●

i-node #342

i-node #7242

Per process

System wide

Typy súborov

- Položka `i_mode`, (16 bitov), horné 4 bity.
- Určuje typ súboru z pohľadu OS (nie formát dát používateľa).

```
#include <ext2fs/ext2fs.h>


#define LINUX_S_IFSOCK    0140000 // UNIX domain socket (s)
#define LINUX_S_IFLNK     0120000 // symbolická linka (l)
#define LINUX_S_IFREG     0100000 // obyčajný súbor s dátami (f)
#define LINUX_S_IFBLK     0060000 // blokové zariadenie (b)
#define LINUX_S_IFDIR     0040000 // adresár (d)
#define LINUX_S_IFCHR     0020000 // znakové zariadenie (c)
#define LINUX_S_IFIFO     0010000 // pomenovaný dátovod/named pipe (p)
...
#define LINUX_S_ISREG(m) ((m) & LINUX_S_IFMT) == LINUX_S_IFREG)
#define LINUX_S_ISDIR(m) ((m) & LINUX_S_IFMT) == LINUX_S_IFDIR)
```

- Bežný súbor, jeho úlohou je v dátových blokoch na disku uchovávať používateľské dáta.
- Obyčajný súbor obsahuje dáta ktorých význam pozná len používateľ, resp. aplikácia. Pre OS nemajú význam.
- Názov súboru taktiež nemá pre OS žiadny význam.
- Tzv. prípona je dobrovoľná. V názve môže byť aj viacero bodiek.
 - Niektoré aplikácie považujú názvy začínajúce bodkou za skryté a nezobrazujú ich.
 - Príkaz `file` sa snaží odhadnúť formát dát (text, zdrojový kód, obrázok, zvuk, ...) podľa databázy známych signatúr. Teda z obsahu, nie podľa názvu.
- Typ súboru z hľadiska OS uvedený v i-uzle nemá nič spoločné s typom, resp. formátom dát ktoré súbor obsahuje.

- Adresár je súbor.
- Obsah súboru typu adresár (d) má význam pre OS.
 - Dátové bloky obsahujú pole štruktúr adresárových položiek (**dirent**).
- Na manipuláciu s obsahom súboru typu “d” nie je možné použiť volania **read** a **write**.
- Narába sa s nimi pomocou zvláštnych volaní: **mkdir**, **rmdir**, **opendir**, **closedir**, **readdir**, **getdents**, **seekdir**, **telldir**, **rewinddir**, ...
- Optimalizácia:
 - Položka adresára môže obsahovať aj typ súboru. Ušetrí sa tým čítanie i-uzla v prípade, že operácia závisí od typu.
 - *mount option* **EXT3_FEATURE_INCOMPAT_FILETYPE**.

- Symbolická linka je súbor.
 - Má svoj názov a má svoj obsah. (A má typ “l”.)
 - V dátovom bloku obsahuje názov (iného) súboru.
- Vytvorí sa volaním **`symlink()`**.
- Operácia požadovaná pre názov súboru typu “l” sa namiesto toho vykoná so súborom ktorého názov linka obsahuje.
- Prístupové práva symbolickej linky sa neberú do úvahy.
- Optimalizácia: Pokiaľ je obsah linky krátky a zmestí sa na miesto odkazov na bloky v i-uzle, ušetrí sa pri prístupe jedno čítanie z disku.
- Hard linka je vlastnosť štruktúry súborového systému. Symbolická linka je súbor.

Symbolická linka



- Súbory ostatných typov (b, c, p, s) nevyužívajú dátové bloky.
- Odkazy v i-uzle môžu využívať iným spôsobom.
 - Špeciálne súbory blokových a znakových zariadení v nich uchovávajú hlavné a vedľajšie číslo zariadenia (*major/minor device number*).
 - *Inline data*, do 60 bajtov, ak to FS podporuje (*mount option*).
- Súbor daného typu (okrem d a l) je možné vytvoriť volaním `mknod()`. Pomenovaný dátovod tiež `mkfifo()`.

Prístupové práva

- Prístupové práva k súboru sa viažu na používateľa, ktorý operáciu vykonáva.
- Štruktúra i-uzla obsahuje identifikáciu vlastníka a vlastniacej skupiny súboru.
- Sú uložené v položkách:

```
__u16  i_uid; /* Low 16 bits of Owner Uid */  
__u16  l_i_uid_high;  
__u16  i_gid; /* Low 16 bits of Group Id */  
__u16  l_i_gid_high;
```

- Pre vlastníka (UID), skupinu (GID) a ostatných má každý súbor v i-uzle určené práva prístupu na čítanie, zápis a vykonávanie.

- Položka `i_mode`, (16 bitov), dolných 9 bitov.

```
#include <ext2fs/ext2fs.h>
```

```
#define LINUX_S_IRWXU 00700 // všetky práva pre vlastníka
#define LINUX_S_IRUSR 00400 // právo čítať pre vlastníka
#define LINUX_S_IWUSR 00200 // právo zapisovať pre vlastníka
#define LINUX_S_IXUSR 00100 // právo vykonávať pre vlastníka

#define LINUX_S_IRWXG 00070 // všetky práva pre skupinu
#define LINUX_S_IRGRP 00040 // Read pre skupinu
#define LINUX_S_IWGRP 00020 // Write pre skupinu
#define LINUX_S_IXGRP 00010 // eXecute pre skupinu

#define LINUX_S_IRWXO 00007 // všetky práva pre ostatných
#define LINUX_S_IROTH 00004 // Read pre ostatných
#define LINUX_S_IWOTH 00002 // Write pre ostatných
#define LINUX_S_IXOTH 00001 // eXecute pre ostatných
```

- Položka `i_mode`, bity 9–11.

```
#include <ext2fs/ext2fs.h>
#define LINUX_S_ISUID 0004000    // Set UID
#define LINUX_S_ISGID 0002000    // Set GID
#define LINUX_S_ISVTX 0001000    // Sticky bit
```

- SUID a SGID:

- Na súbore spôsobia, že program sa bude vykonávať s efektívnymi právami vlastníka, resp. skupiny súboru.
- Na adresári spôsobia, že nové súbory v ňom vytvárané, budú mať nastaveného vlastníka, resp. skupinu ako tento adresár.

- *Sticky bit*:

- Na súbore sa väčšinou ignoruje.
- Na adresári spôsobí, že súbor v ňom môže vymazať len vlastník (používa sa v `/tmp`).

Príznaky súborov

- Položka `i_flags` (32 bitov) určuje, ako má jadro pristupovať k tomuto i-uzlu.
- Určuje jeho špecifické vlastnosti.
- Mnohé sú implementačne závislé, nie všetky sú podporované.
- Secure deletion (s), `EXT2_SECRM_FL 0x00000001`
 - Po odstránení súboru sa jeho dátové bloky prepíšu náhodným (nulovým) obsahom.
- Undelete (u), `EXT2_UNRM_FL 0x00000002`
 - Po odstránení bude súbor presunutý do zvláštneho adresára s vymazanými súbormi.
- Compress file (c), `EXT2_COMPR_FL 0x00000004`
 - Transparentná kompresia obsahu súboru.
 - Obsah súboru je komprimovaný. Použitý kompresný algoritmus je nastavený v superbloku `s_algo_bitmap`.

- Synchronous Updates (S), `EXT2_SYNC_FL 0x00000008`
 - Všetky zmeny sa zapíšu do súboru hneď ako aplikácia robí operáciu **write** (synchronne).
 - Vhodné pre súbory ktorých obsah by nemal byť stratený ani pri páde.
 - Zvyšuje pravdepodobnosť zachovania integrity obsahu súboru.
 - Celý súborový systém je možné pripojiť s voľbou **sync**.
- Immutable (i), `EXT2_IMMUTABLE_FL 0x00000010`
 - Systém nedovolí zmeny v i-uzle (žiadne nové linky, žiadne zmeny v dátach). Navyše súbor nemôže byť premenovaný ani zmazaný.
 - Tento atribút môže meniť len *root*.
 - Bloky súboru by sa nemali presúvať ani pri defragmentácii. Vhodné pre systémové súbory (napr. Jadro, bootloader).
 - Ak je *securelevel* jadra zvýšená, tento príznak je možné odstrániť len v “*single-user móde*”.

- Append Only (a), `EXT2_APPEND_FL 0x00000020`
 - Obsah súboru už nemôže byť odstránený. Súbor je možné otvoriť len v režime *append*.
 - K doterajšiemu obsahu súboru je možné len pridávať .
 - Ak ide o adresár, súbory je možné vytvárať , nie však mazať.
 - Vhodné napríklad pre súbory log-ov.
 - Navyše ak je *securelevel* jadra zvýšená, tento príznak je možné odstrániť len v “*single-user móde*”.
- No Dump (d), `EXT2_NODUMP_FL 0x00000040`
 - Program **dump** pre vytváranie záloh súborového systému bude tento i-uzol ignorovať.
 - Vhodné pre dočasné súbory s nepodstatným obsahom.

- No atime (A), `EXT2_NOATIME_FL` `0x00000080`
 - Pre tento súbor sa nebude aktualizovať `a_time`.
 - Môže znížiť réžiu, následne možno aj spotrebu.
- No Tail (t), `EXT2_NOTAIL_FL` `0x00008000`
 - Koniec súboru, ktorý nezaberá celý blok, sa nebude pripájať ku koncu iného súboru (ktorý má v poslednom bloku miesto).
 - Vhodné napr. pre súbory bootloader-a, ktorý má implementovanú podporu `ext2`, ale nepozná *tail-merging*.
- Journalled (j), `EXT3_JOURNAL_DATA_FL` `0x00004000`
 - Obsah súboru by mal byť “žurnálovaný”.


- B-tree Format Directory/Hash-indexed directory (**EXT3_FEATURE_COMPAT_DIR_INDEX**)
 - Keďže organizovanie súborov v adresároch pomocou zreťazených zoznamov je veľmi neefektívne pri veľkých adresároch, je možné použiť inú organizáciu.
 - Adresár na začiatku obsahuje hlavičku (dĺžka hlavičky, typ indexu, verzia *hash* funkcie, hĺbka stromu), potom nasledujú dvojice (*hash*, blok).
 - Koniec adresára – list stromu – vyzerá ako zvyčajne (kompatibilita).
 - Postup pri hľadaní i-uzla k názvu súboru:
 - Pri prístupe k súboru sa najskôr vypočíta k názvu súboru *hash* hodnota.
 - Binárnym vyhľadávaním sa nájde blok “listu stromu” ktorý by mohol obsahovať hľadané meno súboru.
 - Toto sa opakuje až po najnižšiu úroveň stromu. V tomto bloku (liste stromu) sa hľadá zvyčajným spôsobom – tento blok má aj pôvodnú štruktúru.
 - Ak sa nenájde a ide o kolíziu, prehľadávanie pokračuje v uzle nasledovníka.
 - Vkladanie, rozdeľovanie uzlov (vyvažovanie), kolízie kľúčov, ...

- Synchronous Directory Updates (D), `EXT2_DIRSYNC_FL` `0x00010000`
 - Obsah adresára sa zapisuje synchrónne.
- Top of Directory Hierarchies (T), `EXT2_TOPDIR_FL` `0x00020000`
 - Využíva sa pri alternatívnom spôsobe alokovania blokov (Orlov).
- Inodes Uses Extents (e), `EXT3_EXTENTS_FL` `0x00080000`
- Manipulácia s príznakmi
 - Zobrazenie príznakov súborov: `lsattr` – podobne ako `ls`
 - Zmena príznakov: `chattr [-R] +=[AsacDdIijsTtu] files`

- **i_ctime** – *inode change time*, čas poslednej zmeny obsahu i-uzla (čiže metaúdajov o súbore, nie obsahu súboru),
- **i_mtime** – *modification time*, čas poslednej modifikácie obsahu súboru (jeho dátových blokov),
- **i_atime** – *access time*, čas posledného prístupu k obsahu súboru (čítanie/zápis dátových blokov),
- **i_dtime** – *deletion time*, čas vymazania tohoto i-uzla; ak sa nejedná o vymazaný i-uzol, je nastavený na 0.
- Všetky časy sú uchovávané v počte sekúnd od začiatku roku 1970.
- *ext4* už podporuje nanosekundové časy (**EXTRA_ISIZE**).

Štruktúra súborového systému *ext*

- Súborový systém je rozdelený na niekoľko skupín blokov.
- Každá sa začína kópiou superbloku a štruktúrami pre evidenciu voľných i-uzlov a dátových blokov.



- Štruktúra, nachádzajúca sa na pozícii 1024 bajtov od začiatku média (diskového oddielu). Má veľkosť 1kB.
- Obsahuje informácie potrebné pri interpretácii štruktúry a obsahu FS, okrem iného:
 - verziu FS, (zoznam podporovaných vlastností),
 - veľkosť bloku, počet blokov a i-uzlov v skupine,
 - počet blokov a i-uzlov (všetkých a voľných), veľkosť i-uzla,
 - čas pripojenia, modifikácie a poslednej kontroly,
 - stav, počet pripojení od poslednej kontroly,
 - počete rezervovaných blokov, UID a GID pre koho sú vyhradené,
 - UUID, názov, ...
- Všetky hodnoty majú usporiadanie *little endian*.
- Manipulácia so superblokom: **tune2fs**.

Príklad: Ukážka superbloku



```
#include <ext2fs/ext2_fs.h>
```


```
struct ext2_super_block {  
    __u32 s_inodes_count;      /* Total fs Inodes count */  
    __u32 s_blocks_count;      /* Total fs Blocks count */  
    __u32 s_free_blocks_count; /* Free blocks count */  
    __u32 s_free_inodes_count; /* Free inodes count */  
    __u32 s_first_data_block;  /* First Data Block */  
                                /* beginning of first block group */  
    __u32 s_r_blocks_count;     /* Reserved blocks count */  
    __u16 s_def_resuid;         /* Default uid for reserved blocks */  
    __u16 s_def_resgid;         /* Default gid for reserved blocks */  
    ...  
}
```

- Udáva sa v bajtoch, ako mocnina 2, od 1024, ($block_size = 1024 \cdot 2^{s_log_block_size}$)
- Prípustné hodnoty teda sú 1024, 2048, 4096, ?
- Ak je priemerná veľkosť súboru väčšia (niekoľko sto bajtov a viac), veľké bloky znižujú počet potrebných I/O operácií a teda aj réžiu.
- Ak sú súbory menšie, výhodné sú menšie bloky, pretože sa tým zmenšuje interná fragmentácia.
- Bloky sa môžu deliť na fragmenty. Menšie časti viacerých súborov sú v jednom bloku.
- Fragment môže byť väčší aj menší než 1024.
- Prakticky sa v *ext2fs* fragmenty nepoužívajú, veľkosť fragmentu je rovnaká ako veľkosť bloku.

```
__u32 s_log_block_size; /* Block size */  
__s32 s_log_frag_size; /* Fragment size */
```

- Štruktúra súborových systémov založených na *ext2* umožňuje bezpečne pridávať nové vlastnosti bez narušenia kompatibility so staršími verziami.
- Superblok obsahuje tri bitové mapy vlastností, ktoré určujú správanie sa jadra v prípade, že danú vlastnosť nepozná (nemá implementovanú).
- COMPAT: vlastnosti kompatibilné so staršími verziami. Nemenia pôvodnú štruktúru, len pridávajú nové možnosti, ktoré staršie jadro môže bezpečne ignorovať aj pri R/W prístupe (napr. `HAS_JOURNAL`, `DIR_PREALLOC`, `IMAGIC_INODES`, `EXT_ATTR`, `RESIZE_INODE`, `DIR_INDEX`).
- RO_COMPAT: vlastnosti kompatibilné pri čítaní, ale zapisovanie staršieho jadra by súborový systém poškodilo, preto sa pripája len na čítanie (read-only), (napr. `SPARSE_SUPER`, `LARGE_FILE`).
- INCOMPAT: vlastnosti, ktoré menia štruktúru FS tak, že staršie jadro ho ani neprečíta (napr. `COMPRESSION`, `FILETYPE`, `EXTENTS`), preto ak takéto vlastnosti nepozná, tak FS nepripojí.

- Bloky sa zlučujú do skupín, aby sa zmenšila fragmentácia dát a znížil čas prístupu (nastavenia hlavy disku) pri čítaní dlhých sekvencií.
- Metadáta a dáta jedného súboru sú umiestnené v rovnakej skupine.



- Počet skupín sa určí z hodnôt v superbloku (počet blokov, fragmentov a i-uzlov v skupine):
 - $bg_nr = s_blocks_count / s_blocks_per_group$, kde $s_blocks_per_group = 8 \cdot block_size$
- Pri vytváraní FS sa počet blokov v skupine zvolí tak, aby sa bitová mapa zmestila do jedného bloku (pri 4kB bloku je to 32768).
- Umiestnenie deskriptora skupiny **group_num**:
 - $gd_offset = (1 + sb \cdot s_first_data_block) \cdot block_size + sizeof(struct\ ext2_group_desc) \cdot group_num$
- Každá skupina blokov sa začína kópiou superbloku (ak nie je SPARSE_SUPER) a kópiou tabuľky deskriptorov (všetkých) skupín.
- Jadro používa informácie len z prvej skupiny. Do ostatných sa zmeny zapíšu len pri kontrole programom **e2fsck**. Ak sa údaje v prvej skupine poškodia, z ďalších kópií je ich pravdepodobne možné obnoviť.

```
struct ext2_group_desc
{
    __u32 bg_block_bitmap;      /* Blocks bitmap block */
    __u32 bg_inode_bitmap;     /* Inodes bitmap block */
    __u32 bg_inode_table;      /* Inodes table block */
    __u16 bg_free_blocks_count; /* Free blocks count */
    __u16 bg_free_inodes_count; /* Free inodes count */
    __u16 bg_used_dirs_count;   /* Directories count */
    __u16 bg_pad;
    __u32 bg_reserved[3];
};
```

- Obsahuje čísla blokov s bitmapami voľných dátových blokov a i-uzlov a tabuľkou i-uzlov.
- Ostatné štatistické údaje používa jadro na rovnomerné rozmiestňovanie údajov na disku.

- *Data Block Bitmap*: Každý bit takéhoto bloku označuje, či príslušný dátový blok je voľný, alebo alokovaný pre nejaký súbor.
- Hodnota 1 označuje obsadené bloky, 0 voľné. Prvý blok v skupine je opísaný nultým bitom nultého bajtu v bloku bitmapy.
- Analogicky bitmapa i-uzlov (*inode bitmap*) udáva či sú jednotlivé i-uzly z tabuľky i-uzlov v danej skupine blokov voľné pre nové súbory, alebo už obsadené existujúcimi súbormi.
- Tabuľku i-uzlov (*inode table*) tvorí pole štruktúr i-uzlov umiestnené v súvislej skupine blokov.
- Každému i-uzlu zodpovedá jeden bit v bitovej mape.
- Pozíciu i-uzla je možné vypočítať z jeho čísla a parametrov súborového systému.

- Celkový počet i-uzlov a teda aj súborov v súborovom systéme *ext2fs* je daný napevno, v čase jeho tvorby.
- Zadávajú sa v pomere počtu bajtov na i-uzol (čiže na súbor) – priemerná veľkosť súboru.
- Napríklad:
 - FS má 2GB, hustota i-uzlov je 4096 B/i-uzol,
 - Počet i-uzlov: $2G/4096 = 524288$ i-uzlov,
 - pri 128B i-uzle to je: $524288 \cdot 128 = 64MB$, čo predstavuje 3.125%.
- Nevýhody:
 - Ak ich vytvoríme veľa, zostanú nevyužitú a zbytočne zaberať miesto,
 - Bežne na zaplnených systémoch sa použije len niekoľko percent i-uzlov, rádovo desiatky až stovky MB zostávajú teda nevyužitú (ale robí sa to).
 - Ak ich vytvoríme málo a minú sa, nedajú sa vytvárať ďalšie súbory.
 - Počet i-uzlov nie je možné zvýšiť.
 - Ide o vážne obmedzenie.

Synchronizácia

- Súborový systém (na rozdiel napríklad od databáz), nie je transakčný. Viaceré procesy môžu mať súčasne otvorený ten istý súbor.
 - Aj na zápis. Poradie v akom sa zmeny zapíšu nie je dané.
- Zápis sa robí na aktuálnu pozíciu (*seek*), ktorá je uložená v globálnej tabuľke otvorených súborov.
 - Ak bol súbor otvorený s príznakom *append* (doplňanie), **write** najskôr vždy atomicky posunie ukazovateľ na koniec (**lseek/SEEK_END**) a potom zapisuje.
 - Ak je súbor otvorený na zápis len ako *append* (všetkými procesmi), žiadne dáta sa neprepíšu. Inak to zaručené nie je.
- Operácia **write** nemusí zapísať celý *buffer*. Vráti počet skutočne zapísaných bajtov.
- Dôsledky:
 - Zápisy od rôznych procesov sa môžu vo výsledku rôzne “prekrývať”.
 - Zápis súvislého bloku dát (napríklad štruktúry) nie je atomický.
 - Rôzne zápisy môžu prepisovať rovnaké miesto súboru (ak nie je nastavený príznak *append*).
 - Pokiaľ záleží na dodržaní poradia zápisu od rôznych procesov, je potrebná synchronizácia.

- Synchronizáciu prístupu k súborom je možné dosiahnuť pomocou tzv. zámkov spojených so súbormi.
 - Súborový systém je “viditeľný” všetkými procesmi (netreba spoločnú pamäť).
 - Väčšina OS dnes takúto možnosť ponúka.
- Ak nie, ako zámok môže slúžiť prázdny súbor so známym názvom.
 - Ak (zámok) existuje, súbor je už používaný, treba čakať alebo skúsiť neskôr.
- Otestovať či súbor existuje, ak nie, vytvoriť ho? → Nie je to atomické!
- Vytvorenie súboru je atomické.
 - Operácia `open` s príznakmi (`O_CREAT | O_EXCL`) zlyhá (`EEXIST`), pokiaľ daný súbor už existuje. Ak nie, vytvorí ho.
- Výhoda: prenositeľnosť. Nevýhoda: *polling*.

- Pre deskriptor otvoreného súboru je možné nastaviť zámok.
- Volanie: `int flock(int fd, int operation);`
- Operácie so zámkami (*advisory lock*):
 - LOCK_SH - zdieľaný zámok, viacero procesov môže mať takýto zámok súčasne pre ten istý súbor (na čítanie),
 - LOCK_EX - exkluzívny, pre daný súbor ho súčasne môže mať len jeden súbor (na zápis),
 - LOCK_UN - uvoľnenie zámku.
- Ak bude v type operácie nastavený bit LOCK_NB, žiadosť o uzamknutie už zamknutého súboru sa nezablokuje (vráti EWOULDBLOCK).
- Prístupové práva sa pri tomto volaní nekontrolujú.

- **Shared lock**

- Viaceré procesy môžu získať zdieľaný zámok súčasne.
- Ak má niektorý proces takýto zámok, exkluzívny zámok už nemôže byť získaný.
- Čítacie procesy pred prístupom musia získať zdieľaný zámok.

- **Exclusive lock**

- Ak má niektorý proces takýto zámok, žiadny proces nemôže získať ani exkluzívny, ani zdieľaný zámok.
- Zapisujúci proces pred prístupom musí získať exkluzívny zámok.

- **Advisory lock** - tieto zámky majú len “odporúčací” charakter.
 - Implementuje ich volanie `flock()`.
 - Síce umožňujú zabezpečiť konzistentný prístup k súborom, ale nezaručujú ho.
 - Ak niektorý proces zámky ignoruje (nepoužije vôbec funkciu `flock()`), k súboru pristupovať môže.
- **Mandatory lock** - stav týchto zámkov kontroluje OS pri kažej operácii so súborom (open, read, write, ...) pre všetky procesy.
 - Pri zamknutom zámku operácia môže byť zablokovaná, alebo vráti EAGAIN.
 - Musí ich podporovať súborový systém.
 - Linux: Mount option: mand, kombinácia bitov v prístupových právach súboru (g+s, g-x). Zámky nemajú vplyv na volania `rename()` a `unlink()`. Nespoľahlivé (obmedzená implementácia, možný súbeh).
- Rozhranie `fcntl()` môže byť použité pre oba druhy zámkov.

- Okrem prístupu k dátam je možné so súbormi robiť aj ďalšie operácie.
- Volanie: `int fcntl(int fd, int cmd, /* arg */ );`
- Operácie:
 - Duplikácia deskriptora na prvý voľný.
 - Uzamknutie časti súboru.
 - Notifikácia o zmene obsahu adresára alebo súborov v ňom (dnotify).
 - Čítanie a nastavenie príznakov (FD_CLOEXEC) a stavu deskriptora.
 - Notifikácia o prístupe iného procesu k súboru (leases).
 - Zmena kapacity dátovodu.

- Operácia `F_SETLK` umožňuje procesu uzamknúť na čítanie alebo zápis (`l_type`) istý rozsah súboru (`l_whence`, `l_start`, `l_len`).
 - Toto volanie je neblokujúce a v prípade, že zámok nie je možné získať (napríklad ak daný rozsah je už zamknutý iným procesom), vráti chybový kód.
- Operácia `F_SETLKW` bude čakať, až kým nebude možné zámok získať.
- Samostatné rozhranie pre zámky POSIX (ktoré môže využívať `fcntl`) poskytuje `lockf()`.
- Informácie o aktuálnych zámkoch (Linux):
 - `/proc/locks`
 - FLOCK/POSIX, ADVISORY/MANDATORY, READ/WRITE, PID, MAJOR:MINOR:INODE, START, END/EOF
 - Názov súboru pre INODE sa dá zistiť napríklad v `/proc/PID/fd`.

To je zatiaľ všetko
