Διάλεξη 11: Είσοδος/Έξοδος Χαμηλού Επιπέδου (Low-Level I/O)

Κεφάλαιο 3 (Stevens & R*ago)*

Κεφάλαιο 5 (Stevens & R*ago για επανάληψη)*

Δημήτρης Ζεϊναλιπούρ

Περιεχόμενο Διάλεξης

- Διαχείριση Λαθών με την <errno.h>
- **Δίσκοι και RAID**
- Εισαγωγή στα **Αρχεία** και **Συστήματα Αρχείων** στο Unix (Τύποι Αρχείων, Partitions, i-nodes, blocks)
- **Μέθοδοι Επεξεργασίας Αρχείων**: Standard I/O vs. Χαμηλού Επιπέδου I/O
- **Χαμηλού Επιπέδου I/O** (System Calls I/O): Θεωρία και Πρακτική.
- Παραδείγματα Χρήσης

Διαχείριση Λαθών στην C

- ***Πως διαχειρίζεστε τα λάθη στην C εάν αυτά είναι Run-time Errors? Με printf? debugging?***

- Είναι γενικά αποδεκτό ότι δεν μπορούμε να γνωρίζουμε την αιτία όλων των λαθών **εάν αυτά δεν οφείλονται στην λογική του προγράμματος μας.**

  π.χ., ένα λάθος στο σύστημα αρχείων, ο δίσκος έχει χαλάσει, το αρχείο στο οποίο προσπαθούμε να γράψουμε είναι κλειδωμένο από άλλο χρήστη, κτλ…)

  Νόμος του Murphy: "If anything can go wrong, it will"

- **Στόχος:** Εάν συμβεί κάποιο λάθος να δώσουμε στον χρήστη ένα μήνυμα λάθους το οποίο να αντικατοπτρίζει την πραγματική αιτία.

Διαχείριση Λαθών #include <errno.h>

- **Η βιβλιοθήκη <errno.h> : System Error Numbers (/usr/include/errno.h)**
- Μετά από κάθε κλήση συνάρτησης, η errno περιέχει **ένα ακέραιο (errno),** το οποίο εκφράζει τι λάθος έχει προηγηθεί.
- Υπάρχουν **περισσότερα από 100 errno** (ακέραιοι, δες "man errno") οι οποίοι προσδιορίζουν τα διάφορα είδη λαθών.
- Το **errno** τίθεται από τις συναρτήσεις που καλούμε (π.χ., fopen).
- Εάν μια συνάρτηση δεν το θέτει ρητά τότε το **errno** διατηρεί την υφιστάμενη του τιμή μέχρι να το θέσει κάποια εντολή στο πρόγραμμα μας (errno=0;)
- Στην συνέχεια εκτυπώνουμε αυτά λάθη με την συνάρτηση:

  void perror(char *str)
  - Εκτυπώνει την συμβολοσειρά **str** και την περιγραφή του **errno**
  - Εάν θέλετε να εκτυπώσετε κάποιο μορφοποιημένο str, χρησιμοποιήσετε την γνωστή sprintf(), π.χ.,
    - char string[50]; int file_number = 0;
    - sprintf(string, "file.%d", file_number);
    - perror(string);

Διαχείριση Λαθών #include <errno.h>

- Τα ακόλουθα προγράμματα προσπαθούν να ανοίξουν ένα αρχείο σε write mode με την Standard I/O.
- Προφανώς υπάρχουν πάρα πολλά ενδεχόμενα λάθη: δικαιώματα πρόσβασης, προβλήματα πρόσβασης, το αρχείο δεν υπάρχει, κτλ.
- Το αριστερό πρόγραμμα δεν δίνει κάποιο κατατοπιστικό μήνυμα λάθους ενώ το δεξιά (με την perror) επιστρέφει την ακριβή αιτία.

```c
#include <stdio.h>
int main () {
  FILE * pFile;
  char *filename="/home/a.txt";
  pFile = fopen (filename,"w");
  if (pFile==NULL)   {
    printf("Unable to open %s",
      filename);
    exit(1);
  }
  return 0;
}
```

```c
#include <stdio.h>
#include <errno.h>

int main () {
  FILE * pFile;
  char *filename="/home/a.txt";
  pFile = fopen (filename,"w");
  if (pFile==NULL)   {
    perror(filename);
    exit(1);
  }
  return 0;
}
```

Εάν δεν μπορεί να δημιουργηθεί το αρχείο τότε εκτυπώνει (κωδικό 13) :
$ ./program
/home/a.txt: Permission Denied

Σημείωση: Εάν το **errno==0** τότε η perror(filename) εκτυπώνει **"No Error"**;

Διαχείριση Λαθών #include <errno.h>

- Μερικές, από τις πάρα πολλές, σταθερές που βρίσκονται μέσα στο αρχείο header **errno.h**.
  - EPERM: Operation not permitted
  - ENOENT (2): **No such file or directory**
  - EINTR: Interrupted system call
  - EIO: I/O Error
  - EBUSY: Device or resource busy
  - EEXIST: File exists
  - EINVAL: Invalid argument
  - EMFILE: Too many open files
  - ENODEV: No such device
  - EISDIR: Is a directory
  - ENOTDIR: Isn't a directory
  - …..

Διαχείριση Λαθών Παράδειγμα Εκτέλεσης

```
/* File: errors_demo.c */
#include <stdio.h> /* For fopen, printf */
#include <errno.h> /* For errno variable */

main() {
   FILE *fp = NULL;
   char *p = NULL;
   int stat;

  # Εντολή Α
   fp = fopen("non_existent_file", "r");
   if (fp == NULL) {
             /* Check for error */
             printf("errno = %d\n", errno);
             perror("fopen");
   }
Συνέχεια…
```

```
Συνέχεια… # Εντολή Β
 p = (char *) malloc(400000000); // ~400MB
   if (p == NULL) {
             /* Check for error */
             printf("errno = %d\n", errno);
             perror("malloc");
   }
# Εντολή Γ
   /***** BE CAREFUL: unlink tries to remove a
file so do not run this under root*/
   stat = unlink("/etc/motd");
   if (stat == -1) {
             /* Check for error */
             printf("errno = %d\n", errno);
             perror("unlink");
   }
}
```

/etc/motd: *greeting displayed whenever a user logs on to the system*

Αποτέλεσμα Εκτέλεσης

```
errno = 2
fopen: No such file or directory
errno = 12
malloc: Not enough space
errno = 13
unlink: Permission denied
```

Αυτό ισχύει μόνο στον aias@, ενώ στις μηχανές του εργαστηρίου δεν υπάρχει όριο στην malloc

Τα όρια των προγραμμάτων Έλεγχος με την **ulimit**

- Αν και δεν έχει άμεση σχέση με την συζήτηση, τα όρια μιας διεργασίας είναι ενδιαφέρον και πολύ χρήσιμα.
- Η εντολή **ulimit** (bash built-in) θέτει/διαβάζει τα όρια (limitations) στις πηγές του συστήματος που είναι διαθέσιμες σε κάθε διεργασία του συστήματος

```
dzeina@aias> ulimit -a
core file size        (blocks, -c) 1048575
data seg size         (kbytes, -d) 131072
file size             (blocks, -f) 1048575
max memory size       (kbytes, -m) 32768
open files                    (-n) 2000
pipe size          (512 bytes, -p) 64
stack size            (kbytes, -s) 32768
cpu time             (seconds, -t) unlimited
max user processes            (-u) 128
virtual memory        (kbytes, -v) unlimited
```

```
dzeina@cs4030> ulimit -a
core file size          (blocks, -c) 0
data seg size           (kbytes, -d) unlimited
max nice                        (-e) 0
file size               (blocks, -f) unlimited
pending signals                 (-i) 16239
max locked memory       (kbytes, -l) 32
max memory size         (kbytes, -m) unlimited
open files                      (-n) 1024
pipe size            (512 bytes, -p) 8
POSIX message queues     (bytes, -q) 819200
max rt priority                 (-r) 0
stack size              (kbytes, -s) 10240
cpu time               (seconds, -t) unlimited
max user processes              (-u) 16239
virtual memory          (kbytes, -v) unlimited
```

Magnetic Disks
(Μαγνητικοί Δίσκοι)

spindle

platter

arm

head

Controller

HDD (Hard Disk Drive)

SSD (Solid State Disk)

RAID: Redundant Array of Independent* Disks (*Εφεδρικές Συστοιχίες Ανεξαρτήτων Δίσκων*)

- **Disk Array:** Arrangement of several disks that gives **abstraction** of a **Single**, **Large Disk**!
- **Goals:**
  – Increase **Performance (Επίδοση);**
    - Why? Disk: a mechanical component that is inherently slow!
  – Increase **Reliability (Αξιοπιστία)**.
    - Why? Mechanical and Electronic Components tend to fail!

* Historically used to be **Inexpensive**

RAID: Key Concepts (RAID: Βασικές Αρχές)

A. **Striping (Διαχωρισμός):** the splitting of data across more than one disk using a round-robin (i mod disks);

- Improving **Performance (Επίδοση)** and **Load Balancing** (εξισορρόπηση φόρτου)!
- **NOT** improving **Reliability (αξιοπιστία)!** (if one disk fails all data is useless)

Disk A: 1, 2, 3, 4 → Disk A: 1, 3 / Disk C: 2, 4

A) Striping

B. **Mirroring (Κατοπτρισμός) or Shadowing (Σκίαση):** the copying of data to more than one disk

- Improving **Reliability (Αξιοπιστία)!**
- Improving **Read Performance** but NOT **Write Performance** (same as 1 disk!) / **Wasting space**

Disk A: 1, 2, 3, 4 → Disk B: 1, 2, 3, 4

B) Mirroring

C. **Error Detection/Correction (Εντοπισμός/Διόρθωση Σφαλμάτων):** the storage of additional information, either on same disks or on redundant disk, allowing the **detection (parity, CRC)** and/or **correction** (Hamming/Reed-Solomon) of failures.

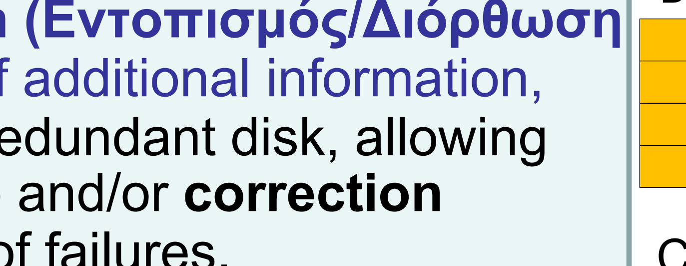

Disk A: 1, 2, 3, 4 → Disk B: 1, 2, 3, 4, 1

C) Error Detection

RAID levels combine the above basic concepts: 0 (striping), 1 (mirroring), 4,5 (parity)

Εισαγωγή στα Αρχεία και τα Συστήματα Αρχείων

- *Τώρα ας μελετήσουμε αναλυτικότερα τα **συστήματα αρχείων (filesystem)** και την **διαχείριση αρχείων** στο UNIX.*
- ***Αντίστοιχες** αρχές ισχύουν και σε άλλα λειτουργικά συστήματα, επομένως **ΜΗΝ** θεωρήσετε ότι αυτά βρίσκουν εφαρμογή μόνο στο UNIX.*

Τι είναι ένα Αρχείο;

- **Μια ακολουθία από bytes**, χωρίς καμιά δομή όσο αφορά το λειτουργικό σύστημα (δηλ., το ΛΣ δεν αντιλαμβάνεται την **σημασιολογία** αυτών των bytes).
- Οι βασικές λειτουργίες είναι αυτές της ανάγνωσης **read()** δεδομένων και της γραφής **write()** δεδομένων.
- **File Structure:** Η αναγνώριση της δομής των δεδομένων εναπόκειται αποκλειστικά στην εφαρμογή (π.χ. το Acrobat γνωρίζει την εσωτερική δομή ενός PDF αλλά όχι ενός DOC).

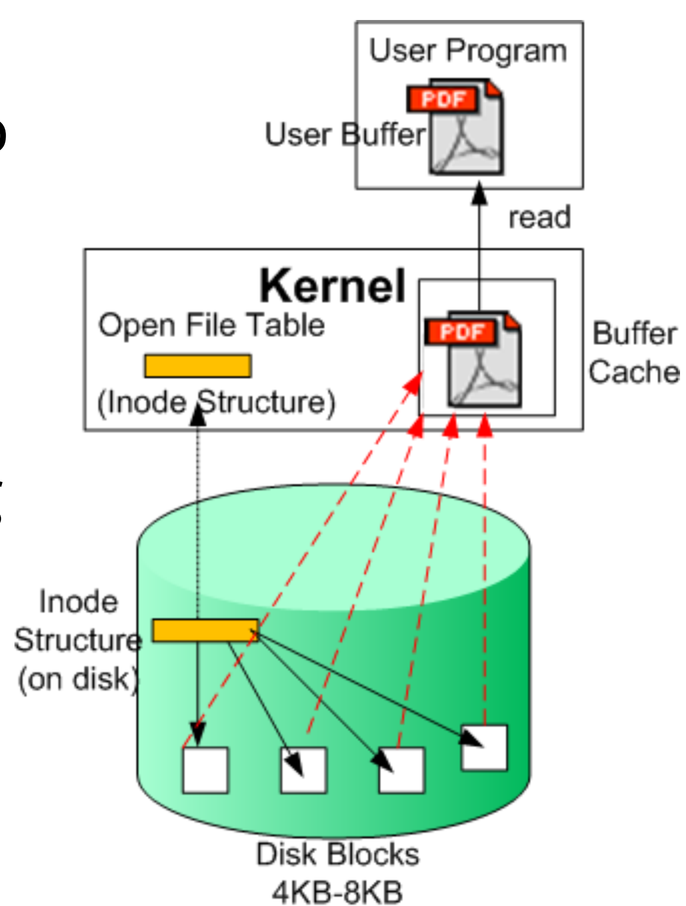

Τι είναι ένα Αρχείο: Παράδειγμα GIF

Ας δούμε πως **είναι κωδικοποιημένο** ένα αρχείο εικόνας PDF (Graphics Interchange Format).

$ hexdump –C filename.pdf # dump contents of file

Magic number

```
$ hexdump -C short-math-guide.pdf  | more
00000000  25 50 44 46 2d 31 2e 33  0a 33 20 30 20 6f 62 6a  |%PDF-1.3.3 0 obj|
00000010  20 3c 3c 0a 2f 4c 65 6e  67 74 68 20 31 30 32 35  | <<./Length 1025|
00000020  35 20 20 20 20 20 0a 3e  3e 0a 73 74 72 65 61 6d  |5     .>>.stream|
00000030  0a 31 20 30 20 30 20 31  20 31 37 38 2e 33 35 37  |.1 0 0 1 178.357|
00000040  20 36 37 36 2e 32 33 31  20 63 6d 0a 42 54 0a 2f  | 676.231 cm.BT./|
```

Το σχήμα δείχνει ότι οι εικόνες (όπως και ΌΛΑ τα αρχεία) είναι ουσιαστικά μια σειρά από bytes αποθηκευμένα στον μαγνητικό δίσκο.

Τύποι Αρχείο στο Unix “Everything in Unix is a File”

- **Regular Files**: Αρχεία Δεδομένων (txt, pdf, jpg,…)
  - $ ls -al ~/.profile
    -rwxr----- 1 dzeina faculty 281 Jan 19 12:46 …. profile
- **Directory Files:** Αρχεία συστήματος για την διατήρηση της δομής του συστήματος αρχείων.
  - $ ls -al ~ | grep public_html
    drwxr-sr-x 8 dzeina faculty 4096 Feb 19 22:53 public_html
- **Character-Special Files:** Χρησιμοποιούνται για να αναπαραστήσουν Serial I/O συσκευές (terminals, printers και networks)
  - $ ls -al \`tty\`
    crw--w---- 1 dzeina tty 136, 1 Feb 21 11:36 /dev/pts/1
- **Block Special Files :** Χρησιμοποιούνται για να αναπαραστήσουν Μαγνητικούς Δίσκους, Cdroms, flash drives στα οποία η ανάγνωση/γραφή δεδομένων γίνεται σε Blocks (π.χ. 512 - 8192 bytes)
  - $ ls -al /dev/hdc # το /dev/cdrom
    brw-rw---- 1 root disk 22, 0 Feb 21 10:09 /dev/hdc
- **Symbolic link Files:** Το αρχείο είναι ένας σύνδεσμος που δείχνει σε κάποιο άλλο αρχείο (hard links are regular files)
  - $ ln -s public_html/index.html index.lnk ; ls -al index.lnk
    lrwxrwxrwx 1 dzeina faculty 22 Feb 21 12:07 index.lnk -> public_html/index.html
- **Named Pipes (FIFO):** Χρησιμοποιείται για επικοινωνία μεταξύ διεργασιών Θα τα δούμε αργότερα στο μάθημα.
  - $ mkfifo pipef; ls -al | grep pipef
    prw-r--r-- 1 dzeina faculty 0 Feb 21 11:42 pipef

Πως αποθηκεύονται τα αρχεία;

- Τα αρχεία αποθηκεύονται πάνω στις συσκευές αποθήκευσης (Μαγνητικούς Δίσκους, FLASH, Ταινίες, Cdrom, DVDs, etc).
- **File-System (Σύστημα Αρχείων):**

  Μέρος του πυρήνα το οποιο υλοποιεί ένα σύνολο από δομές δεδομένων **κυρίας** και **δευτερεύουσας** μνήμης για την αποθήκευση, ιεραρχική οργάνωση, ανάκτηση και επεξεργασία δεδομένων.

- Το file system σε μερικά Λ.Σ
  - Windows NT,2000,XP,Vista,7: FAT, FAT32, NTFS, Windows Future Storage (WinFS: File Org. with DBs!)
  - Linux Local Ext2, Ext3, Ext4, Linux Distributed: NFS, AFS, MacOS: Hierarchical FS+, Google's Non-kernel: MacFuse
  - CDROMs: ISO9960,
  - Φωτογραφικές & Κινητά με Flash Memory : FAT

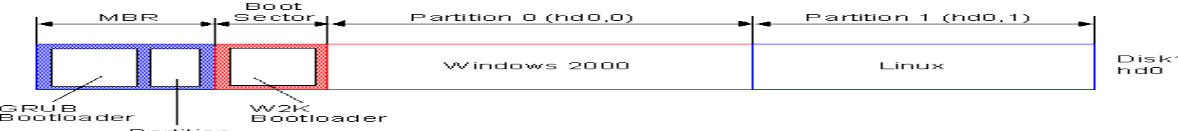

|512 bytes|: Master Boot Record (or Volume Boot Record)

Disk Partitions

- Ο δίσκος χωρίζεται σε partitions
- Για να βρούμε τα partitions στο UNIX χρησιμοποιούμε την εντολή **df**

```
$ df
Filesystem             1K-blocks      Used Available Use% Mounted on
/dev/mapper/VolGroup00-LogVolRoot
                         2031440    609380   1317204  32% /
/dev/mapper/VolGroup00-LogVolTmp
                         1015704     94252    869024  10% /tmp
/dev/mapper/VolGroup00-LogVolVar
                         2031440    391220   1535364  21% /var
/dev/mapper/VolGroup00-LogVolUsr
                         5078656   3409680   1406832  71% /usr
/dev/mapper/VolGroup00-LogVolOpt
                         2031440   1378252    548332  72% /opt
/dev/mapper/VolGroup00-LogVolUsrLocal
                          507748     36197    445337   8% /usr/local
/dev/sda1                 101086     23619     72248  25% /boot
tmpfs                     517108         0    517108   0% /dev/shm
csfs7.cs.ucy.ac.cy:/home/students
                       164288512 129185280  35103232  79% /home/students
csfs1.cs.ucy.ac.cy:/home/faculty
                       278673504 242194208  27323520  90% /home/faculty
```

NFS-mounted (Network File System) drives!

Linux Filesystems
ext: Extended file system

Features	Ext2	Ext3	Ext4
Individual file size	16GB-2TB	16GB-2TB	16GB-16TB
Volume file system size	4TB-32TB	4TB-32TB	4TB-1EB
Default inode size	128 bytes	128 bytes	256 bytes
Time Stamp	No support	Second	Nanosecond
Defragmentation	No	No	Yes
Directory Indexing	Disabled	Disabled	Enabled
Multiple Block Allocation	Basic	Basic	Advanced
Preallocation	No	In-core reservation	For extent file
Delayed Allocation	No	No	Yes

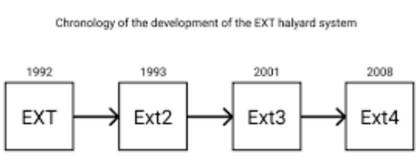

Ext5?
- The ext4 file system can support volumes with sizes up to 1 Exabyte (EB)
- 1 EB = 1000 PB = 10^6 TB … which is a lot, so ext5 might actually never happen given that for larger volume sizes there is already HDFS (Hadoop File Systems)

Android?
- Before Android 2.3 it used the YAFFS2 file system which was specifically designed for NAND fla storage.
- But the drawback to YAFFS2 was that it was single-threaded and this meant it would become a bottle neck for mutli-core mutli-threaded hardware. So in 2010 they decided to make the switch. Linux distros such as Ubuntu typically uses EXT3 and EXT4 file systems. Android can also manage FAT and exFAT file systems for it's removable SD cards.

Windows File Systems

New Technology (NT) File System

	FAT16	FAT32	NTFS	exFAT
Advantages	It can be used in very old OS like MS-DOS, Windows 95/98/NT/2000.	It supports partition of 2TB and most of Windows OS, Mac, and other OS and devices.	It provides faster speed and allows large space. And it has better security to resist data loss.	It has better compatibility then NTFS. It can be used in Mac and Linux OS with full write/read.
Limitations	Can only support partition smaller than 2GB, and it causes waste of space.	FAT32 has lower faulty tolerance, security, compared with NTFS.	It doesn't support OS older than Windows XP, and can be only read in Mac, and some other OS.	exFAT has extra features that NTFS provided
Ideal use	Only in very old OS.	Some removable device that don't need to contain a file larger than 4GB.	Use it for Windows hard drives	Use it for flash memory, like USB drive, SD card.

FEATURE	FAT32	NTFS
Max. Partition Size	2TB	2TB
Max. File Name	8.3 Characters	255 Characters
Max. File Size	4GB	16TB
File/Folder Encryption	No	Yes
Fault Tolerance	No	Auto Repair
Security	Only Network	Local and Network
Compression	No	Yes
Conversion	Possible	Not Allowed
Compatibility	Win 95/98/2K/2K3/XP	Win NT/2K/XP/Vista/7

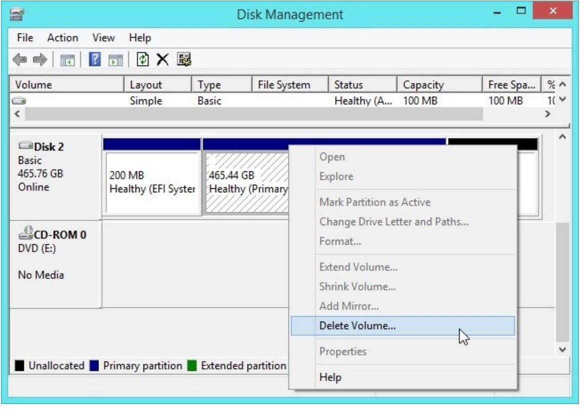

Apple File Systems
HFS, HFS+, APFS

	Mac OS Extended (HFS+)	Apple File System (APFS)
Number of allocation blocks	2^{32} (4 billion)	2^{63} (9 quintillion)
File IDs	32-bit	64-bit
Maximum file size	2^{63} bytes	2^{63} bytes
Time stamp granularity	1 second	1 nanosecond
Copy-on-write		✓
Crash protected	Journaled	✓
File and directory clones		✓
Snapshots		✓
Space sharing		✓
Native encryption		✓
Sparse files		✓
Fast directory sizing		✓

Apple File Systems Utilities

- Apple allows formatting disks complying to the DoD 5220.22-M specification.
  - The Department of Defense 5220.22-M requires 3 overwrites passes (0's, 1's, Random) with a 100% verification pass.

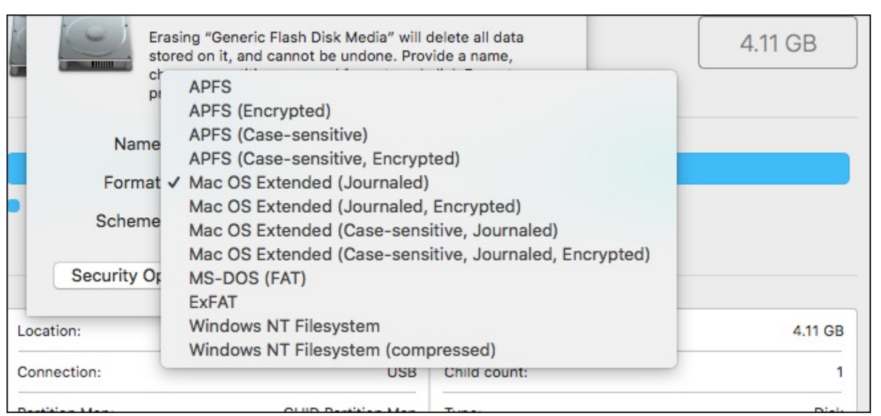

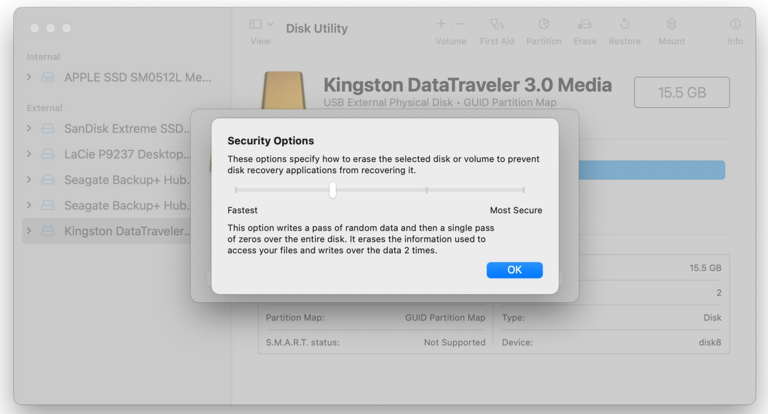

- With a solid-state drive (SSD), secure erase options are not available in Disk Utility.
  - For more security, consider turning on FileVault encryption when you start using your SSD drive.

Network File Systems (nfs, smb and cifs)

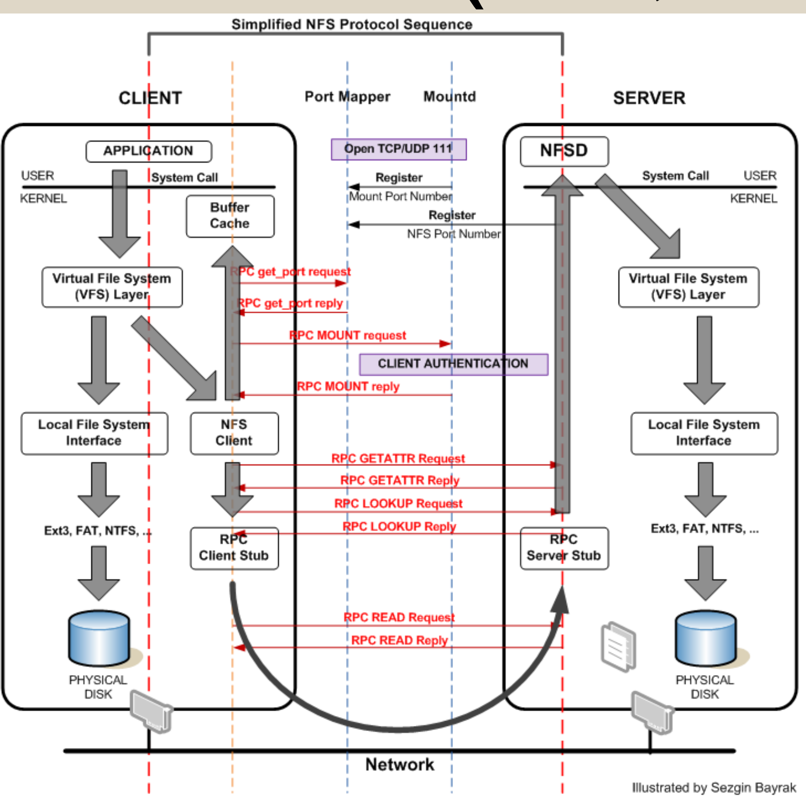

NFS Internals example

	NFS	SMB	CIFS
Environment	Optimized for Unix-like systems	Optimized for Windows systems	Optimized and support for older Windows systems
Cross-Platform	Supported	Supported	Supported
Authentication	Host-based Authentication and Kerberos	User-based Authentication and Kerberos	User-based Authentication
Encryption	Not enabled by default	AES enabled by default	Not supported
File Locking	Advisory and Mandatory locking handled by NLM	Opportunistic locking (oplocks)	Opportunistic locking (oplocks)
Network Resources	File sharing and Network Block Devices (NBD)	File sharing and print sharing	File sharing and print sharing

Large-Scale File Systems (Hadoop File System – HDFS, S3, etc)

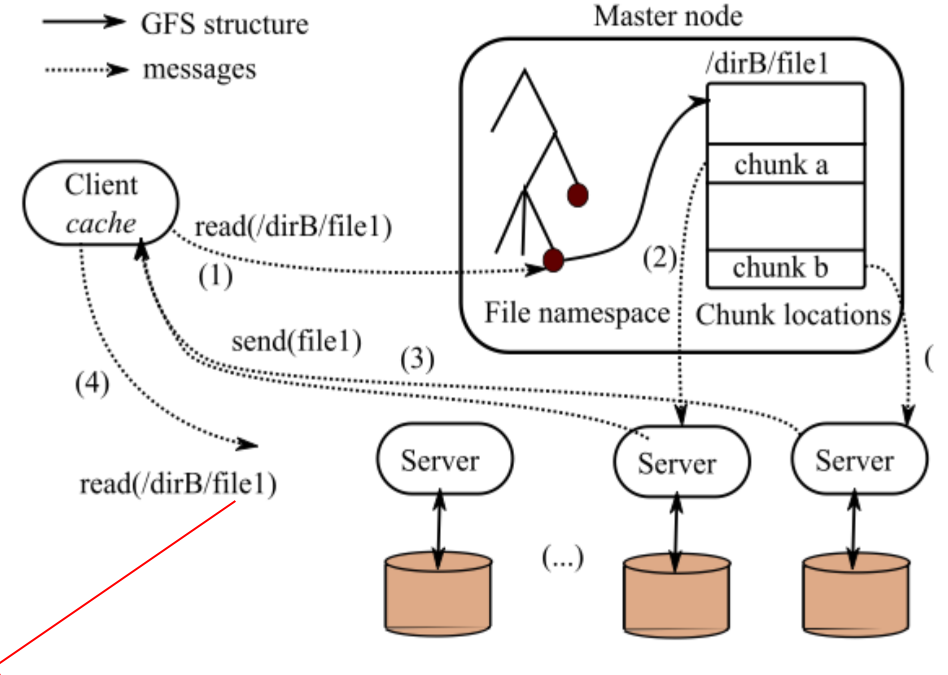

Namespace lookup are fast (1 Master enough!) [1GB Metadata = 1PB Data]

In **NFS Metadata + Transfers going** through same server => **Not Scalable**

HDFS designed for **unreliable hardware** (2-3 failures / 1000 nodes / day)

New Hardware: 3x more unreliable!!!

Partitions

- Διαφορετικά partitions μπορούν να έχουν διαφορετικά συστήματα αρχείων.
- Ένα partition στο UNIX έχει την πιο κάτω μορφή:

disk drive | partition | partition | partition

filesystem | boot block(s) | super block | i-list | directory blocks and data blocks

i-node | i-node | . . . | i-node

Super block (Filesystem Metadata)
File system type, Size, Status
Information about other metadata structures

i-nodes

- Στην αρχή κάθε partition βρίσκεται μια λίστα με i-nodes, τα οποία αναγνωρίζουν μοναδικά τα αρχεία του συγκεκριμένου partition.
- Ένα **i-node** περιέχει τις πληροφορίες (μια συλλογή από διευθύνσεις δίσκου) έτσι ώστε να γνωρίζει ο πυρήνας από πού να ανακτήσει τα data/directory blocks κάποιου αρχείου
- Για να βρείτε το i-node number ενός αρχείου δώστε την εντολή "**ls -i**".

  - Από ένα πρόγραμμα μπορούμε να βρούμε το i-node μέσω του system call **stat()…**αργότερα….

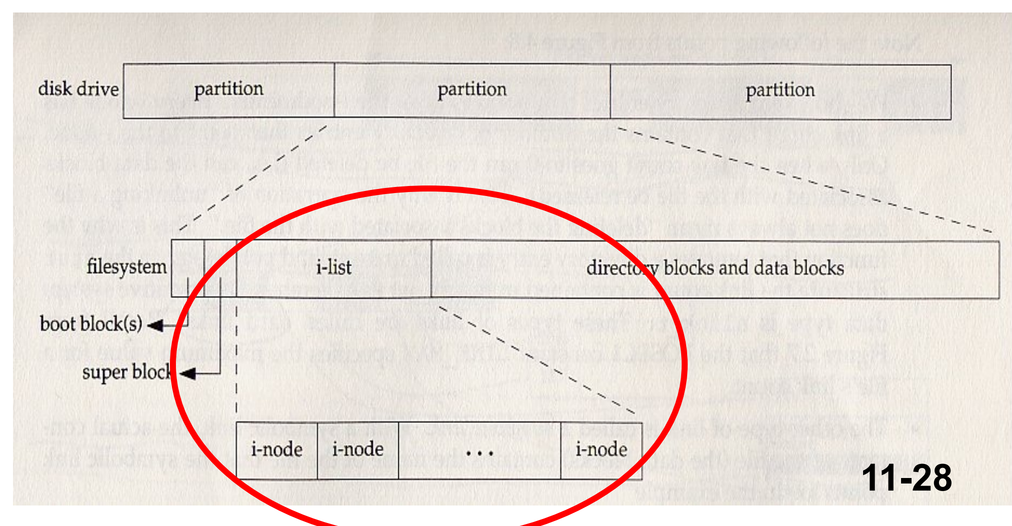

Data/Directory Blocks

- Ένα αρχείο (regular ή directory) αποτελείται από μια σειρά "**blocks**" και ονομάζεται **"data block" και "directory block"** αντίστοιχα.
- Το **data-block** αποθηκεύει
  - Μέρος των πραγματικών δεδομένων ενός αρχείου.
- Το **directory-block** αποθηκεύει
  - I-node number και filename για κάθε αρχείο ή υποκατάλογο.

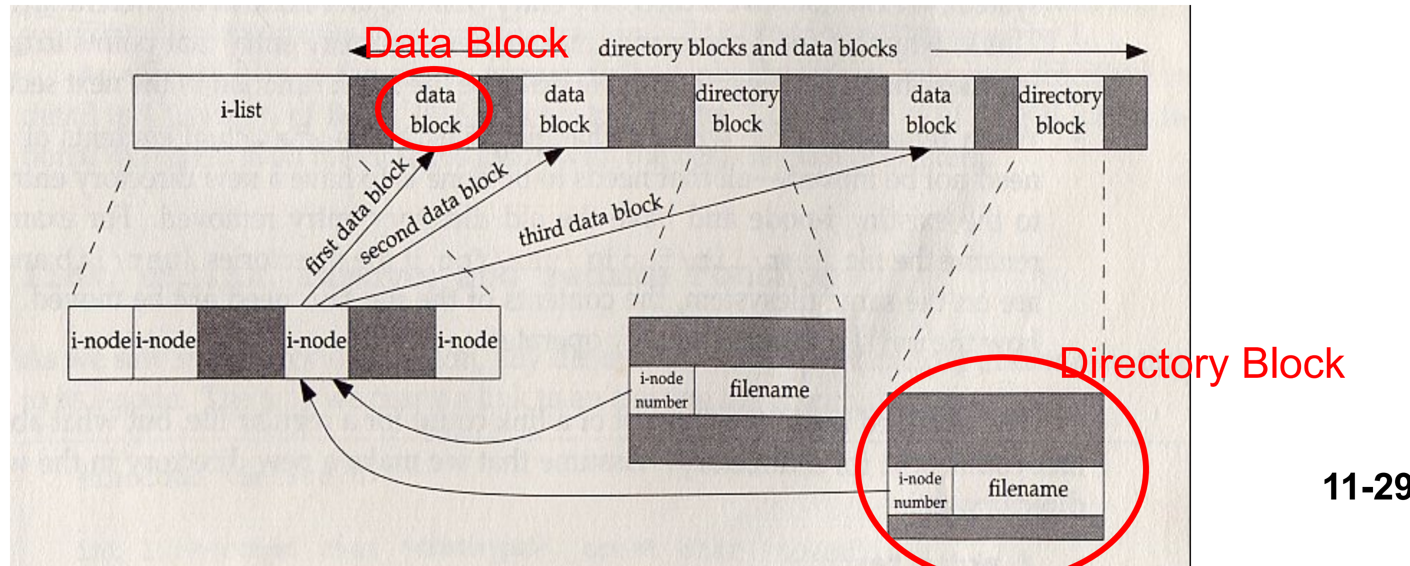

Παράδειγμα Εύρεσης Αρχείου με i-nodes

- **Πως βρίσκει το λειτουργικό σύστημα (το υποσύστημα αρχείων) τα περιεχόμενα ενός αρχείου /usr/test.c ?**
- Ξεκινά από το directory block με i-node 2 (πρώτο διαθέσιμο i-node στο i-list, το οποίο αντιστοιχεί στο / folder)
- Από εκεί βρίσκει ότι το usr έχει ως i-node to 200.
- Στην συνέχεια

  => 4 => 202 => 6 =>
- Τέλος βρίσκει ότι τα data blocks με i-nodes 204 και 206 περιέχουν τα δεδομένα του αρχείου.

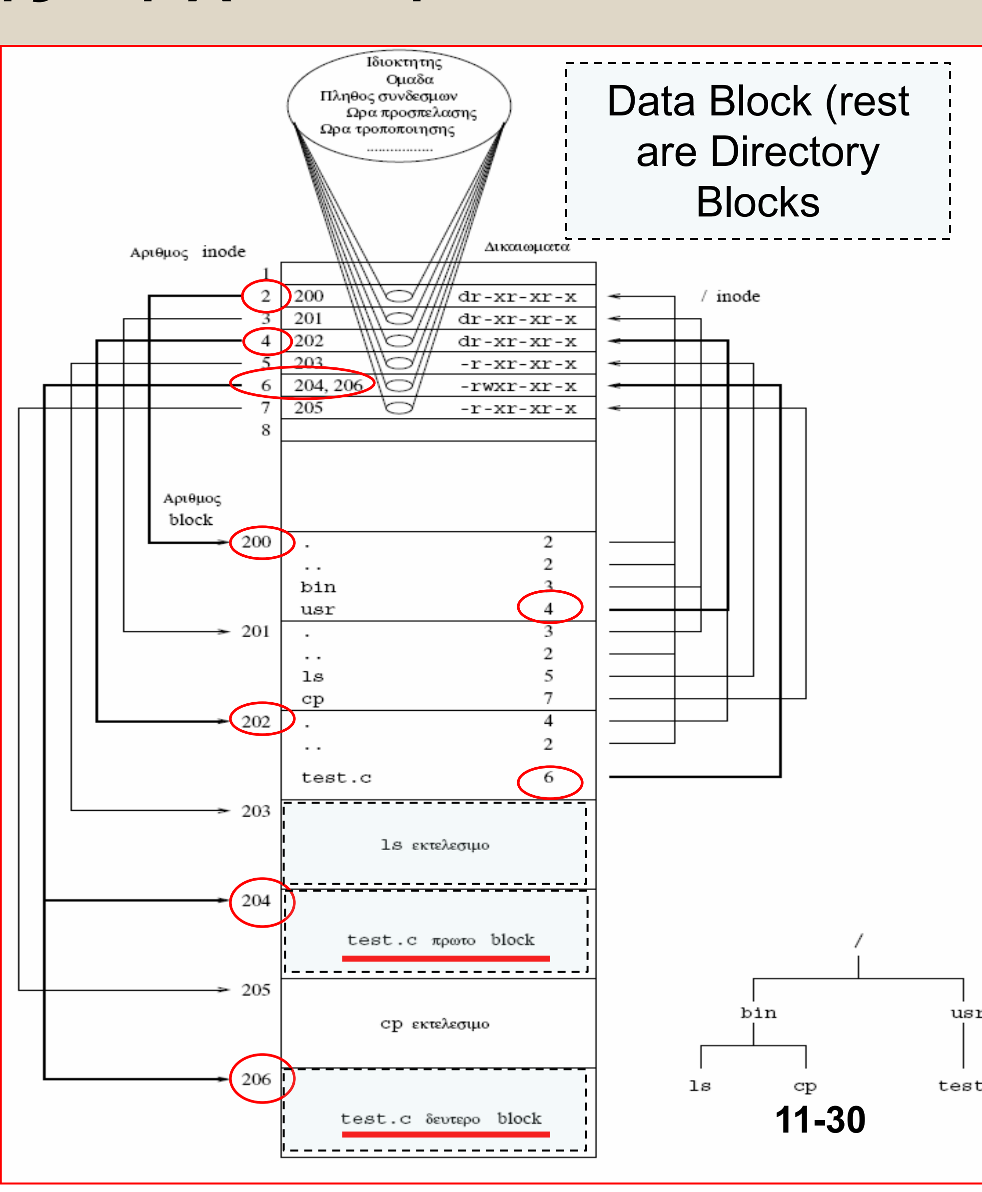

Παράδειγμα Εύρεσης Αρχείου με i-nodes

- Στο προηγούμενο παράδειγμα το αρχείο **/usr/test.c** με i-node 6 περιείχε μονάχα **2 blocks** (με i-node 204 και 206).
- **Τι γίνεται εάν ένα αρχείο έχει πολλά blocks**;
- Υπάρχει **αρκετός χώρος** για να αποθηκευτούν **όλα τα i-nodes** των blocks που συσχετίζονται με το αρχείο;
- Το Υποσύστημα Αρχείων χρησιμοποιεί ένα **ιεραρχικό σχήμα** το οποίο αποτελείται από δένδρα δεικτών βάθους 0 (direct, αυτό το οποίο είδαμε ήδη), 1 (single), 2 (double), και 3 (triple)

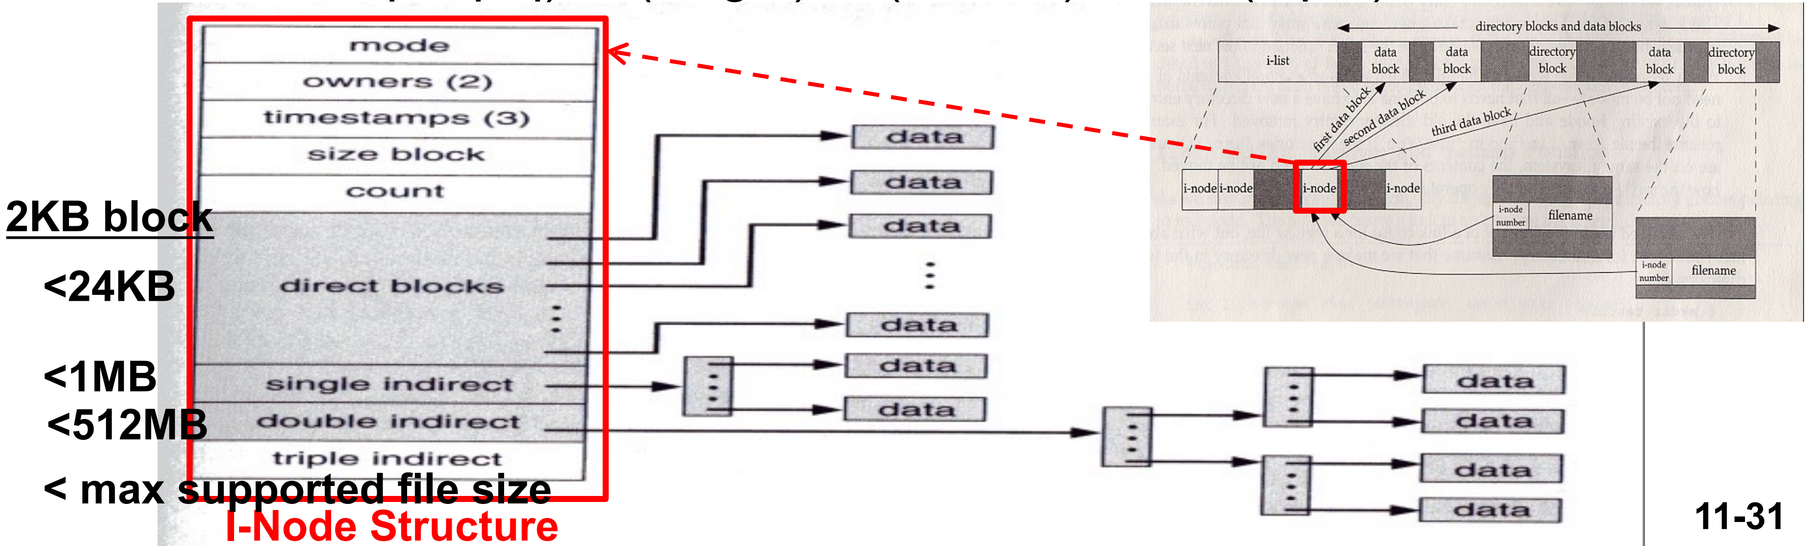

I-Node Structure

(περισσότερα για την δομή αυτή στην επόμενη διάλεξη)

Μέθοδοι Επεξεργασίας Αρχείων

- Τώρα θα δούμε μεθόδους επεξεργασίας του περιεχομένου των αρχείων.
- Το χαμηλού επιπέδου I/O διεκπεραιώνεται εκτελώντας ***system calls (κλήσεις συστήματος)***.
- ***I/O System Call:*** *κλήσεις προς τον πυρήνα του λειτουργικού συστήματος ο οποίος μας επιστρέφει ένα* **File Descriptor (FD)** *(ορολογία Unix) ή* **File Handle** *(ορολογία Windows).*
- *Όλη η επεξεργασία στην συνέχεια γίνεται μέσω του FD.*

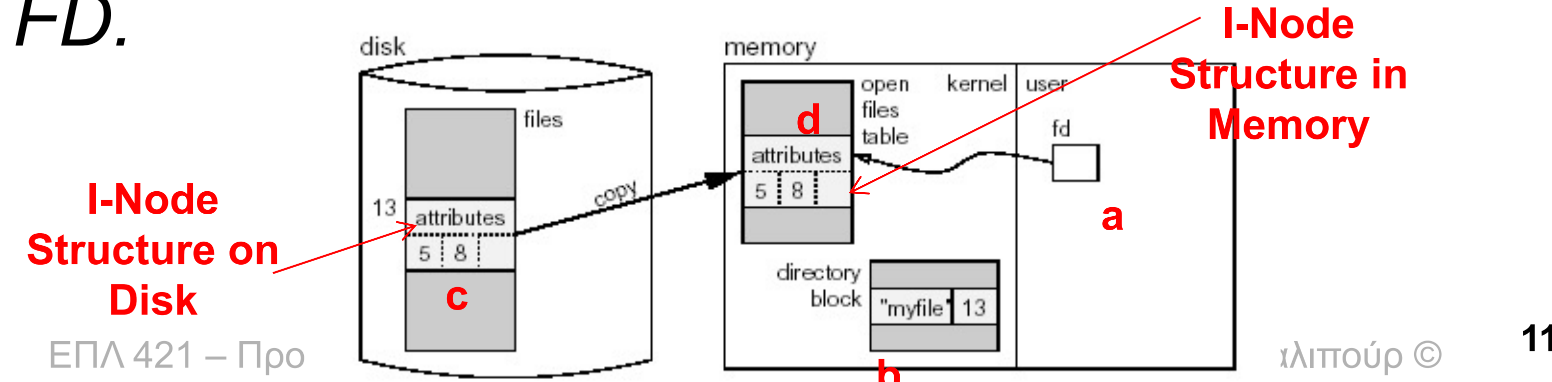

Διεργασίες και Αρχεία

Μέσα στην Διεργασία

- **File Descriptor Table**: Ένα για κάθε διεργασία. Κάθε εγγραφή του, ή οποία αναγνωρίζεται από το fd (0,1,…), περιέχει ένα δείκτη στο open files table. (ελέγξετε το /proc/$$/fd/)

Μέσα στον Πυρήνα

- **Open Files Table:** Μια εγγραφή δημιουργείται όποτε εκτελέσουμε open(). Η εγγραφή περιέχει i) **δείκτη στο inode table**, ii) **offset** μέσα στο αρχείο (το επόμενο read εκτελείται από το offset); iii) **status** (π.χ. read, write, append) με το οποίο ανοίξαμε το αρχείο.
- **Inode Table:** Κάθε αρχείο εμφανίζεται μόνο μια φορά σε αυτό τον πίνακα.

Διεργασίες και Αρχεία

parent process

fd table

opened before fork

fork

child process

fd table

inherited

opened after fork

other process

fd table

opened same file twice

KERNEL

open files table

pointer

pointer

pointer

pointer

inode table

inode 13

inode 7

Ένα Ανοικτό αρχείο

Θα μελετηθεί αργότερα ξανά

Μέθοδοι Επεξεργασίας Αρχείων

Από τα προγράμματα εφαρμογών μπορούμε να ανακτήσουμε τα δεδομένα των αρχείων με δυο τρόπους:

α) Standard I/O Library (Procedure) Calls

fopen, fclose, fread, putc, readc, etc.

… αυτά τα οποία χρησιμοποιούσατε μέχρι τώρα στα διάφορα μαθήματα προγραμματισμού με χρήση δομής FILE. Αυτή η μέθοδος συνιστάται μόνο για τα regular αρχεία (όχι άλλους τύπους)

β) Κλήσεις Συστήματος (System Calls)

(e.g., open, close, read, write, lseek) μέσω File Descrip. (int)

- Τα οποία μοιάζουν με **library calls (κλήσεις συναρτήσεων βιβλιοθήκης),** με την διαφορά ότι τα system calls εκτελούνται μέσα στο **kernel space αντί στο user space.**
- Επομένως κλήση σε ένα system call δεν σημαίνει απλά ότι θα κάνουμε **jump σε μια άλλη εντολή** ορισμένη αλλού στο πρόγραμμα αλλά ότι θα γίνει **context switching** (εναλλαγή διεργασιών), έτσι ώστε να εκτελέσει το kernel την αίτηση σας.
- Βέβαια στο τέλος όλες οι **λειτουργίες επεξεργασίας** ενός αρχείου εκτελούνται από τον πυρήνα, ωστόσο με τις κλήσεις βιβλιοθήκης μπορεί να γίνεται αυτό με κάποια καθυστέρηση (δηλ., buffering)

Standard IO vs. Systems Calls

- **Τα Standard I/O stdio.h (ANSI C99)** είναι μια βιβλιοθήκη συναρτήσεων για πρόσβαση σε αρχεία από προγράμματα C (χρησιμοποιείται πέρα από το UNIX)
  - Τα Standard I/O κάνουν **κλήση συνάρτησης της ιδίας της διεργασίας** ενώ τα System Calls καλούν λειτουργίες του πυρήνα.
  - Τα Standard I/O calls **υλοποιούνται και αυτά μέσω** των System Calls!
  - Τα Standard I/O **είναι πιο εύκολα**
  - Η Standard I/O δημιουργεί ένα **Stream (FILE *)** ενώ τα System Calls ένα **File Descriptor**
  - Η Standard I/O κάνει buffering (BUFSIZE την stdio.h).

…. **αλλά δίδουν λιγότερη ελευθερία ☹, ή οποία χρειάζεται στο Systems Programming**

- **System Call** / **Standard I/O call**

> **Επανάληψη Standard I/O Calls: Κεφάλαιο 5 – Stevens & Rago**
> Man stdio

System Call	Standard I/O call	
open	fopen	
close	fclose	
read/write	fread/fwrite	// used for binary I/O chunks of bytes rather char or line
	getchar/putchar	// read a character from **STDIN**
	getc/putc	// …>>………>>…..from file
	fgetc/fputc	// identical to getc/putc
	gets/puts	// read a string from **STDIN**
	fgets/fputs	// >> > > > > > from file
	scanf/printf	// read formatted input from **STDIN**
	fscanf/fprintf	// >> > > > > > from file
lseek	fseek	// move to a specific location in a file

Πλεονέκτημα των System Calls

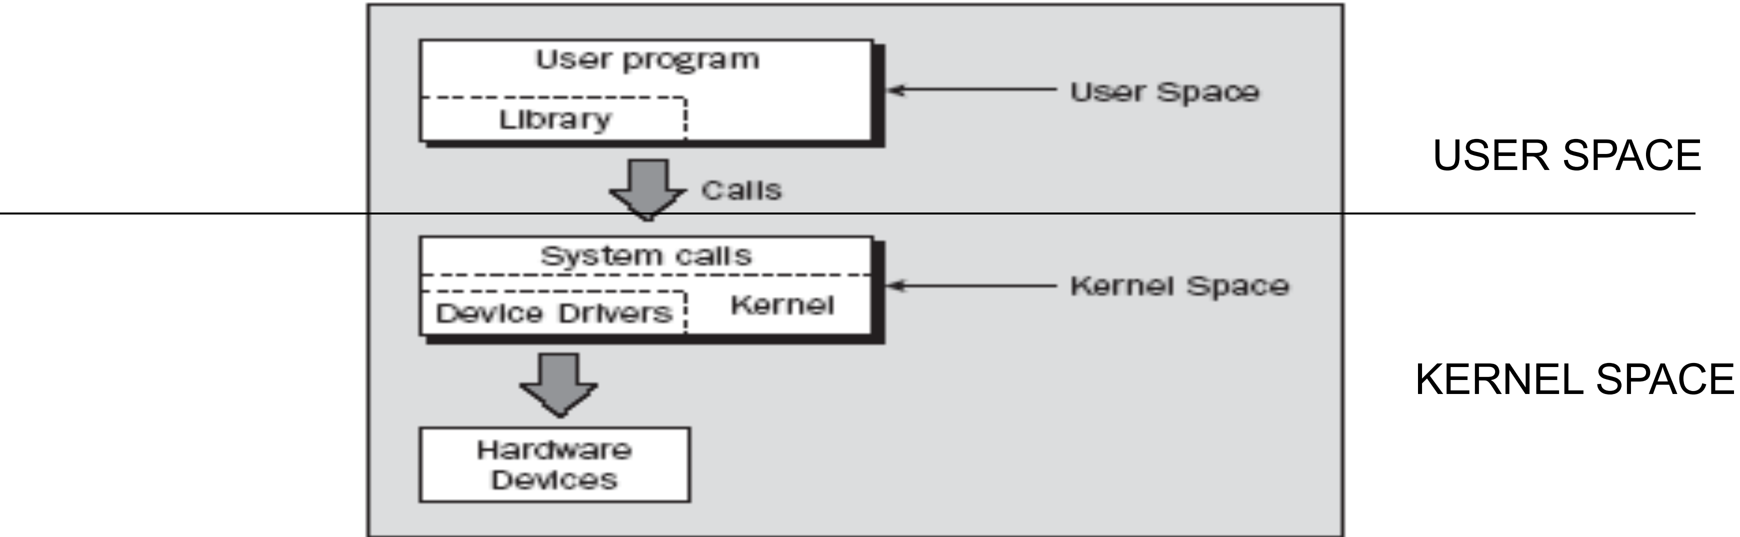

Πλεονέκτημα System Call: Πλήρες Έλεγχος!

- Υλοποίηση Λειτουργιών που δεν προσφέρονται από τα Standard I/O (locking, buffering, IPC)
- **Έλεγχος του Buffering:** Το οποίο είναι πολύ σημαντικό σε συστήματα βάσεων δεδομένων όπου θέλουμε να χειριστούμε το buffering μέσα στην ιδία την εφαρμογή και όχι το standard I/O.
- **Interprocess Communication:** Όταν προγραμματίζεται επικοινωνία μεταξύ διεργασιών με χρήση σωλήνων και υποδοχών (θα μας απασχολήσουν αργότερα στο μάθημα …)

Μειονεκτήματα των System Calls

- **Είναι Πολύ Ακριβά! :** Ενώ ένα procedure call θέλει μόνο μερικές εντολές μηχανής ενώ ένα system call θα κάνει τα εξής:
  - Η υπό εκτέλεση διεργασία διακόπτεται και το state της φυλάγεται.
  - Το Kernel (ΛΣ) παίρνει τον έλεγχο του CPU και εκτελεί το system call.
  - Το Kernel (ΛΣ) διακόπτεται και το state της φυλάγεται ενώ ταυτόχρονα δίδει τον έλεγχο πίσω στην διεργασία.

  Όμως, η ορθολογιστική χρήση των system calls οδηγεί σε αυξημένη Απόδοση κάτι το οποίο είναι πολύ σημαντικό.

- **System Dependent:** Διαφορετικές Υλοποιήσεις Λ.Σ υποστηρίζουν διαφορετικές λειτουργίες. Οπόταν τίθεται θέμα **μεταφερσιμότητας** (Portability) του πηγαίου κώδικα με τα system calls.

- **Δυσκολότερος Προγραμματισμός:** Με την standard I/O, η βιβλιοθήκη οργανώνει τις κλήσεις προς τον πυρήνα με έτσι τρόπο που τα δεδομένα θα μεταφέρονται σε **πλήρη blocks** από τον δίσκο στην μνήμη, ενώ με τα System Calls πρέπει να το χειριστούμε μόνοι μας.

System Calls for I/O

- Υπάρχουν 5 βασικά system calls τα οποία παρέχει το **Unix για <u>file I/O</u>** (ελέγξετε το man –s 2 open)
  - `int open(char *path, int flags [ , int mode ] );`
  - `int close(int fd);`
  - `int read(int fd, void *buf, int size);`
  - `int write(int fd, void *buf, int size);`
  - `off_t lseek(int fd, off_t offset, int whence);`
- Για να έχουμε πρόσβαση σε αυτές τις συναρτήσεις μέσω των προγραμμάτων εφαρμογών χρειάζεται να συμπεριλάβουμε τις ακόλουθες βιβλιοθήκες

```
// file control options:
#include <fcntl.h>
// standard symbolic constants and types for unix
#include <unistd.h>
```

1) System Calls: **Open()/Close()**

Άνοιγμα Αρχείου για ανάγνωση/γραφή δεδομένων

 # Returns: File Descriptor if OK, -1 on error
int open(const char *path, int flags [, int mode])
 # Returns: 0 if OK, -1 on error
int close(int filedes);

- '**path** ': Απόλυτο η σχετικό μονοπάτι προς το αρχείο
- Τα **flags** και **mode** δηλώνουν πως θέλουμε να χρησιμοποιήσουμε το αρχείο (επόμενη διαφάνεια)
- Εάν ο πυρήνας αποδεχθεί την αίτηση μας, τότε δημιουργείται ο μικρότερος δυνατό ``***file descriptor (FD)***'' (το οποίο είναι μια ακέραια τιμή για αρχείο). Οποιεσδήποτε μελλοντικές αναφορές στο αρχείο γίνονται μέσω του FD. (θα εξηγηθεί αναλυτικότερα στην συνέχεια)
- Το Linux 2.4.22 θέτει ένα hard limit από 1,048,576 FDs ανά διεργασία. Αυτό ορίζεται από την σταθερά OPEN_MAX στην βιβλιοθήκη limits.h (όπως την εντολή $ulimit –n)
- Εάν η open επιστρέψει -1, τότε δεν ικανοποιήθηκε η αίτηση και μπορούμε να ελέγξουμε την τιμή της μεταβλητής "**errno**" για να βρούμε γιατί (με την **perror()**).
- Θυμηθείτε ότι όταν ανοίγει ένα πρόγραμμα τότε τρεις FDs είναι ήδη ανοικτοί (0:stdin, 1:stdout, 2:stderr).

Open/close: Απλό Παράδειγμα

```
#include <fcntl.h>
#include <stdio.h> // for printf
int main(){
  int fd1, fd2;

 if(( fd1 = open("foo.txt", O_RDONLY)) < 0){
    perror("opening file");
    exit(1);
 }

 printf("The File Descriptor is : %d", fd1);

 if (close(fd1) < 0) {
    perror("closing file");
    exit(1);
 }
}
```

1) System Calls: **Open()/Close()**

Flags (σταθερές μέσα στη fcntl.h) : Υποχρεωτικές και προαιρετικές επιλογές.

Υποχρεωτικές: **O_RDONLY** (open for reading only) ,**O_WRONLY** (writing), **O_RDWR** (read/write)

Προαιρετικές: **O_APPEND** (append to the end of file), **O_TRUNC** (if file exists in WR or RDWR then truncate its size to 0), **O_CREAT** (create if file does not exist – we have to set MODE variables – see below),

Mode (σταθερές sys/stat.h) : Προσδιορίζει τα δικαιώματα εάν δημιουργούμε αρχείο. Το mode είναι ακέραιος (ιδία λογική με Unix file permissions).

Mode

S_IRUSR: Read permission, owner
S_IWUSR: Write permission, owner
S_IXUSR: Execute permission, owner
S_IRGRP: Read permission, group
S_IWGRP: Write permission, group
S_IXGRP: Execute permission, group
S_IROTH: Read permission, others
S_IWOTH: Write permission, others
S_IXOTH: Execute permission, others

Σημείωση: Τα **Flags** και το **Mode** εκφράζονται μπορούν να δοθούν σαν διάζευξη συμβολικών ονομάτων, π.χ.,

open("test.txt", O_WRONLY | O_CREAT, S_IRUSR | S_IWUSR | S_IRGRP | S_IROTH);

Εξήγηση: Το ORing θετει τα bits :
rwxrwxrwx = 110100100
(δηλ. 100000000 | 010000000 | …)

1) System Calls: **Open()/Close()** Μηχανισμός Εκτέλεσης

Opening "myfile" (Inode:13)

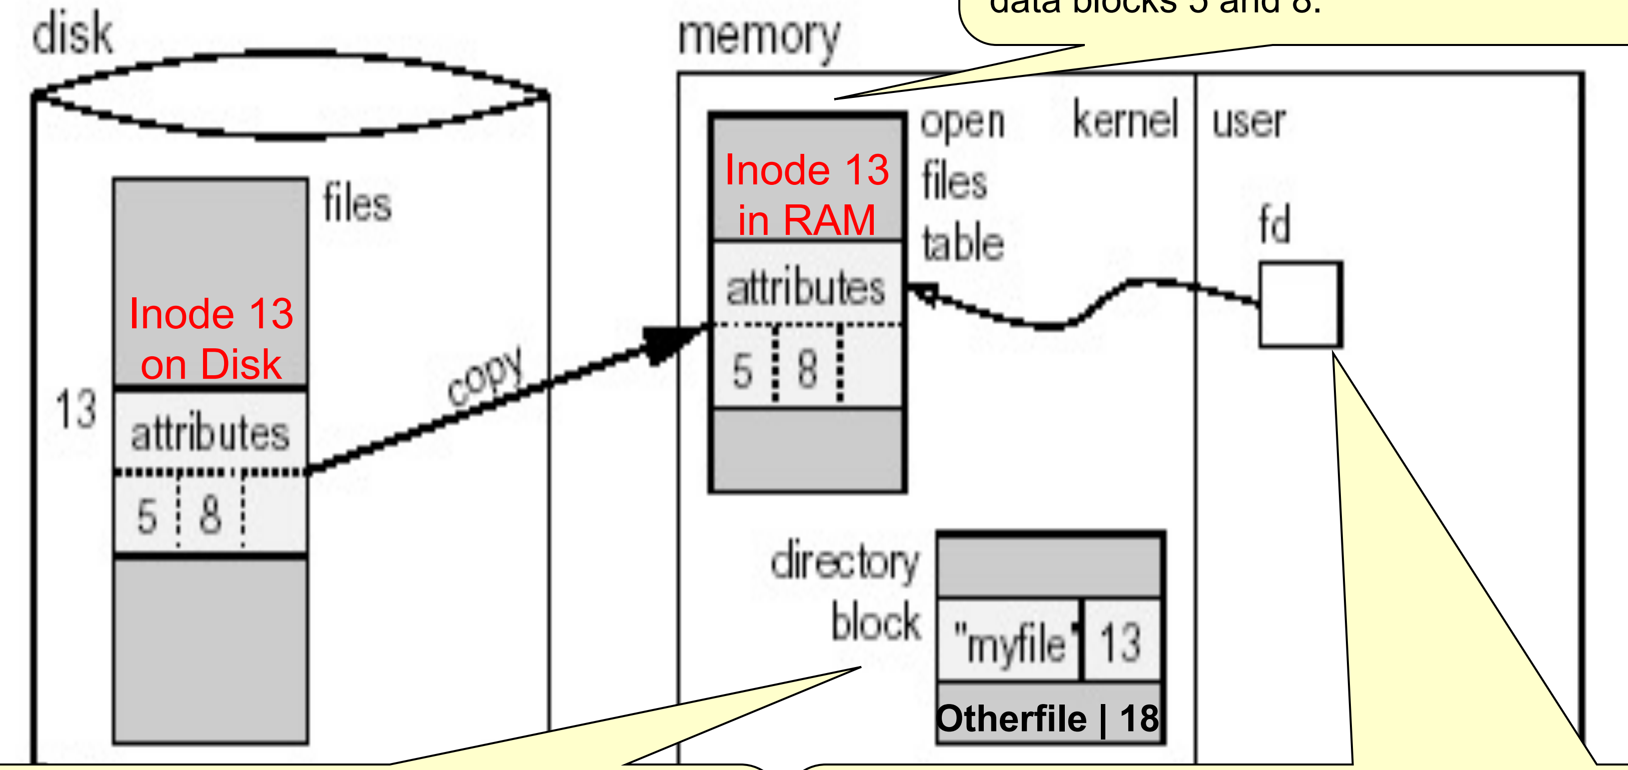

B) Entry 13 from that data structure is read from the disk and copied into the kernel's open files table. That consists of data blocks 5 and 8.

A) The file system reads the current directory, and finds that "**myfile**" is represented internally by **entry 13** in the list of files maintained on the disk.

C) User's **access rights** are checked (through Inode attributes) and the user's variable fd is made to point to the allocated entry in the open files table

2) System Call: **Creat()**

Δημιουργία Αρχείου

int creat(const char * *filename*, int *mode*);

ή εναλλακτικά open(filename, O_WRONLY | O_CREAT | O_TRUNC, mode);

 # Returns: File Descriptor for O_WRONLY if OK, -1 on error

- Ο Dennis Ritchie ερωτήθηκε κάποτε πιο είναι το μοναδικό πράγμα που έχει μετανιώσει για την C. Αυτός απάντησε *"leaving off the 'e' on creat()"*.
- Μειονέκτημα της creat() είναι ότι δεν μπορούμε να διαβάσουμε από το αρχείο που δημιουργήσαμε.
- Για να το διορθώσουμε και να έχουμε Δημιουργία + Read/Write χρησιμοποιήστε το ακόλουθο:

open(filename, O_RDWR | O_CREAT | O_TRUNC, mode);

Creating Files on command line (Creating inode vs. inode+data)

$ touch test.txt # Creating an inode

$ stat test.txt # print test.txt inode info - will see in a while

File: 'test.txt'

Size: 0 **Blocks: 0** IO Block: 1048576 **regular empty file**

Device: 3fh/63d Inode: 6670939443 Links: 1

…

$ echo "" > test2.txt # Creating an inode+data

$ stat test2.txt # print test2.txt inode info - will see in a while

File: 'test2.txt'

total size of all files in the list (measured in 512 B) => 4KB block size

Size: 1 **Blocks: 8** IO Block: 1048576 regular file

…

$ hexdump -C test.txt

$ hexdump -C test2.txt

00000000 0a |.|

00000001

3) System Call: **Read()**
Ανάγνωση από κάποιο FD

*int read(int fd, void *buf, int size)*

Returns: αριθμό bytes που διαβάστηκαν, 0:EOF, -1:ERROR

- Διαβάζει size bytes από την οντότητα (αρχείο, συσκευή, άκρο σωλήνα ή υποδοχή) που αντιστοιχεί στον περιγράφει **fd** και τα αντιγραφεί στο **buf**.
- Περιμένει (blocking wait) μέχρι συμπληρωθεί το **buf** η μέχρι φτάσει το **EOF**.
- Προϋποθέτει ότι η εφαρμογή σας έχει δεσμεύσει αρκετό χώρο (malloc) στο **buf**. Τι θα συμβεί στην αντίθετη περίπτωση;
- Σημειώστε ότι το **buf** είναι *Posix-compliant (**void ***) παρά τον παραδοσιακό ορισμό **char *buf**)*

3) System Call: **Read()** Μηχανισμός Εκτέλεσης

A) The argument fd identifies the open file by pointing into the kernel's open files table.

B) the system gains access to the list of blocks that contain the file's data.

C) The file system therefore reads disk block number 5 into its *buffer cache*, then block number 8.

D) the desired range of 100 bytes is copied into the user's memory at the address indicated by buf.

4) System Call: **Write()**
Ανάγνωση από κάποιο FD

*int write(int fd, void *buf, int size)*

Returns: αριθμό bytes που γράφτηκαν, -1:ERROR

- **Γράφει** size bytes από το buf στην οντότητα (αρχείο, συσκευή, άκρο σωλήνα ή υποδοχή) που αντιστοιχεί στον περιγράφει fd.
- **Επιστρέφει** τον αριθμό από bytes που γραφτήκαν.
- Αυτό μπορεί να είναι λιγότερο από την αίτηση **(size)** εάν υπήρξε κάποιο πρόβλημα με τον file descriptor
  - Π.χ., size=100 αλλά η write καταφέρνει να γράψει μόνο 10.
- Εάν επιστρέψει 0, τότε δεν γράφτηκε τίποτα.
- Εάν επιστρέψει -1, τότε ελέγξετε τον κωδικό λάθους **errno.**

4) System Call: **Write()** Μηχανισμός Εκτέλεσης

β) The kernel then might flush (best to be done by programmer) the newly written data to disk (assuming that block#8 has adequate space).
Else a new block is allocated and the data is written there as well.

α) Our program calls write(fd,buf, sizeof(buf)); and the data is copied to kernel space

Παράδειγμα 1: Υλοποίηση του cat

*Να υλοποιήσετε σε C και με χρήση κλήσεων συστήματος, ένα απλό πρόγραμμα το οποίο να προσομοιώνει την εντολή **cat** (χωρίς παραμέτρους)*

π.χ.

./mycat < filename

ls | ./mycat

./mycat (επαναλαμβάνει ότι γράφουμε)

Παράδειγμα 1: Υλοποίηση του cat

// Η βιβλιοθήκη stdio.h περιλαμβάνεται μόνο για την μεταβλητή BUFSIZE (αν κάναμε και printf/scanf επίσης), η οποία παίρνει την πιο καλή τιμή (με βάση το υπάρχων σύστημα), παρά να την θέταμε μόνοι μας.

```
#include <unistd.h>  // STDIN_FILENO, STDOUT_FILENO
#include <stdio.h>  // BUFSIZE
#include <error.h>  // perror
int main(int argc, char * argv []) {
        char buf[BUFSIZ];     // BUFSIZE 8192
        int n;

        while((n = read(STDIN_FILENO, buf, sizeof(buf))) > 0)
            if ( write(STDOUT_FILENO, buf, n)  != n )
                perror ("write error");

        if (n < 0)
            perror("read error");
        return 0;
}
```

- Ερώτηση: Γιατί δεν χρειαστήκαμε να ανοίξουμε τους περιγραφείς FD#0 και FD#1;

Παράδειγμα 2: Read/Write Demo

Να υλοποιήσετε σε C και με χρήση κλήσεων συστήματος, ένα απλό πρόγραμμα το οποίο i) ***δημιουργεί*** *ένα, αρχείο, ii)* ***γράφει*** *κάποια συμβολοσειρά,* ***iii) κλείνει*** *το αρχείο,* ***iv) ανοίγει*** *και* ***γράφει*** *κάποια άλλη συμβολοσειρά,* ***v) κλείνει*** *το αρχείο και τέλος* ***vi) διαβάζει*** *το αρχείο και το* ***εκτυπώνει*** *στην οθόνη. Κάθε βήμα να τυπώνει τον αριθμό των bytes.*

Παράδειγμα 2: Read/Write Demo

```
/* File: io_demo.c */
#include <stdio.h> /* For printf, BUFSIZE*/
#include <fcntl.h> /* For O_RDONLY, O_WRONLY,O_CREAT, O_APPEND */
#include <string.h> /* strlen */
main() {
    int fd, bytes;
    char buf[BUFSIZ];
    char *filename = "temp.txt";
    char *line1 = "First write. \n";
    char *line2 = "Second write. \n";

    // 0600 <==> S_IRUSR | S_IWUSR  <==>  -,rw-,---,---
    if ((fd = open(filename, O_WRONLY | O_CREAT | O_TRUNC, 0600)) == -1) {
        perror("open");
        exit(1);
    }
    // Προσοχή: Γράφουμε μόνο το strlen(line1), αντί strlen(line1)+1 για να
    // αποφύγουμε τα ανεπιθύμητα \0 ( "First write. \n\0 Second write. \n\0" )
    bytes = write(fd, line1, strlen(line1)); /* Data out */
    printf("%d bytes were written\n", bytes);
    close(fd);
```

Create file and enable us to write to the file

Ανεπιθύμητο

Παράδειγμα 2: Read/Write Demo

```
    if ((fd = open(filename, O_WRONLY | O_APPEND)) == -1) {
            perror("open");
            exit(1);
    }
    bytes = write(fd, line2, strlen(line2)); /* Data out */
    printf("%d bytes were written\n", bytes);
    close(fd);


    if ((fd = open(filename, O_RDONLY)) == -1) {
            perror("open");
            exit(1);
    }
    bytes = read(fd, buf, sizeof(buf)); /* Data in */
    printf("%d bytes were read\n", bytes);
    close(fd);
    buf[bytes] = '\0';
    printf("%s", buf);
}
```

```
$ ./a.exe
14 bytes were written
15 bytes were written
29 bytes were read
First write.
Second write.
```

Παράδειγμα 3: Υλοποίηση Concat Αρχείων

Να υλοποιήσετε σε C και με χρήση κλήσεων συστήματος, ένα απλό πρόγραμμα το οποίο να προσομοιώνει την λειτουργία της πιο κάτω εντολής κελύφους cat file1 >> file2

Το πρόγραμμα σας εκτελείται με τον ακόλουθο τρόπο.

$concat file1 file2

Παράδειγμα 3: Υλοποίηση Concat Αρχείων

```
/* File: append_file.c */
#include <fcntl.h> /* For O_RDONLY. O_WRONLY, O_CREAT, O_APPEND */
#include <unistd.h> // STDERR_FILENO
#include <string.h> // strlen

main(int argc, char *argv[])
{
    int n, fromFD, toFD;
    char buf[1024]={};

    if (argc != 3) {
        /* Check for proper usage */

        sprintf(buf, "Usage: %s from-file to-file", argv[0]) ;
        write(STDERR_FILENO, buf, strlen(buf));
        exit(1);
    }
```

Παράδειγμα 3: Υλοποίηση Concat Αρχείων

```
if ((fromFD = open(argv[1], O_RDONLY)) < 0) {
        /* Open from-file */
        perror("open");
        exit(1);
}

if ((toFD = open(argv[2], O_WRONLY | O_CREAT | O_APPEND, 0660)) < 0) {
        /* Open to-file */
        perror("open");
        exit(1);
}

while ((n = read(fromFD, buf, sizeof(buf))) > 0)
        if (write(toFD, buf, n) != n) { /* Copy data */
                perror("copy error");
        }

close(fromFD); /* Close from-file */
close(toFD);   /* Close to-file */

}
```

Append mode

```
$ cat file1
First write.
$cat file 2
Second write.
$concat file1 file2
$cat file2
Second write.
First write.
```

5) System Call: **lseek()**

Τυχαία (Random) Μετακίνηση μέσα στο Αρχείο

off_t lseek(int fd, off_t offset, int whence)

Returns: new file offset if OK, -1 on error

- **off_t** δηλώνεται μέσα στο **sys/types.h**
- **Offset (από πού):** Ορίζει την θέση (position)
- **Whence :** Ορίζει πως χρησιμοποιείται το offset.
  - **SEEK_SET:** relative to beginning of file
  - **SEEK_CUR:** relative to the current position
  - **SEEK_END:** relative to end of file

- Η συνάρτηση lseek μας επιτρέπει να μετακινηθούμε μέσα στο αρχείο με τυχαίο τρόπο. (Random Access).
- Κάθε αρχείο έχει ένα «current file offset» το οποίο είναι ένας θετικός ακέραιος ο οποίος μετρά τον αριθμό από bytes από την αρχή του αρχείου.
  - Εάν ανοίξει το αρχείο το offset είναι 0.
  - Μετά από ανάγνωση m bytes, το offset γίνεται m.
- Το “l”seek προέρχεται από το “long”seek διότι το offset είναι ένας long integer.

5) System Call: **lseek()**

Τυχαία (Random) Μετακίνηση μέσα στο Αρχείο

- Το lseek δηλώνει το offset μέσα στο kernel χωρίς να προκαλέσει οποιονδήποτε I/O. Το I/O θα γίνει μόνο στο επόμενο write.
- Εάν εκτελέσουμε το πιο κάτω εντολή τότε η επόμενη γραφή (ή ανάγνωση) θα γίνει 100 bytes δεξιότερα από την παρούσα θέση:

  lseek(filedesc, 100, SET_CUR);
- Επομένως ένα αρχείο μπορεί να έχει «τρύπες» με κενά.
- Αυτές οι τρύπες είναι ουσιαστικά συνεχόμενα 0 (NULs) και καταλαμβάνουν 1 byte ανά Nul.
- Το offset μπορεί να πάρει θετικές και αρνητικές τιμές, εάν και εφόσον οι συσκευές το υποστηρίζουν (π.χ. σε ένα αρχείο γίνεται άλλα όχι σε ένα socket).

Παράδειγμα 4: Υλοποίηση Απλού Database

Να υλοποιήσετε σε C και με χρήση κλήσεων συστήματος, μια απλή δυαδική βάση δεδομένων ή οποία γράφει πέντε εγγραφές της μορφής

```
typedef struct person{
    int id;
    char sex;
    char name[40];
} __attribute__((packed)) PERSON;
```

Το __attribute__((packed)) του σημαίνει ότι δεν θέλουμε ο GCC compiler να προσθέσει padding στην δομή για να την κάνει align στην μνήμη.

Εάν δεν το χρησιμοποιήσουμε πρέπει να κάνουμε τις εγγραφές των στοιχείων μια-μια

συνεχόμενα σε ένα αρχείο user.db, στην συνέχεια αφήνει 3 εγγραφές κενές και μετά γράφει ακόμη 5 εγγραφές. Τέλος διαβάζει από το αρχείο όλες τις εγγραφές και τις τυπώνει στην οθόνη.

Παράδειγμα 4: Υλοποίηση Απλού Database

```
main(int argc, char *argv[])
{
	int n, fd, i;
	PERSON p;
	char *filename="users.db";
	int offset;

	if ((fd = open(filename, O_RDWR | O_CREAT, 0660)) < 0) {
		/* Open to-file */
		perror("open db");
		exit(1);
	}

	// set the values in the p structure
	p.sex = 'm';
	strcpy(p.name, "Costas");

	// write 5 tuples to the file
	for (i=0; i<5; i++) {
		p.id = i;
		write(fd, (void *) &p, sizeof(p));
	}
```

Παράδειγμα 4: Υλοποίηση Απλού Database

```
// seek the file descriptor three sizeof(p) positions to the right (from SEEK_CUR)
lseek(fd, 3*sizeof(p), SEEK_CUR);

// write another 5 tuples to the file
for (i=0; i<5; i++) {
        p.id = i;
        write(fd, (void *) &p, sizeof(p));
}

// rewind the file descriptor to the beginning of the file
lseek(fd, 0, SEEK_SET);

// Now read and print the respective tuples
while((n = read(fd, (void *) &p, sizeof(p))) > 0) {
   if ( sizeof(p) != n )
       perror ("read error");
           printf("<%d,%c,%s>\n", p.id, p.sex, p.name);
}

close(fd);
}
```

Παράδειγμα 4: Υλοποίηση Απλού Database

$dbtest
<0,m,Costas>
<1,m,Costas>
<2,m,Costas>
<3,m,Costas>
<4,m,Costas>
<0, ,>
<0, ,>
<0, ,>
<0,m,Costas>
<1,m,Costas>
<2,m,Costas>
<3,m,Costas>
<4,m,Costas>

Το μέγεθος του αρχείου είναι 585 bytes (13 records * 45 bytes)

Παράδειγμα 5: Δημιουργία Άδειου Αρχείου Μεγάλου μεγέθους

```
#include <fcntl.h> /* For O_RDONLY. O_WRONLY,
O_CREAT, O_APPEND */
#include <unistd.h> // STDERR_FILENO

typedef struct person{
int id;
char sex;
char name[40];
} __attribute__((packed)) PERSON;

int main(int argc, char *argv[]) {
        int fd;  PERSON p;
        char *filename="users.db";
        if ((fd = open(filename, O_RDWR |
O_CREAT, 0660)) < 0) {
                perror("open db");return 1;
        }
        lseek(fd, 10000*sizeof(p), SEEK_CUR);
        write(fd, "", 1);
        close(fd);
        return 0;
```

Like truncate, no real data blocks just void pointers

```
$ stat users.db
  File: ‘users.db’
  Size: 450001     Blocks:
8 IO Block: 1048576 …
```

```
1)dzeina@b103ws1> hexdump -c users.db
0000000  \0  \0  \0  \0  \0  \0  \0  \0
\0  \0  \0  \0  \0  \0  \0  \0
*
006ddd0  \0

006ddd1
```

```
^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@^@
...
"users.db" [noeol] 1L, 450001C
```

Δημιουργία Άδειου Αρχείου Μεγάλου Μεγέθους στο Shell

- **A) dd - convert and copy a file**
  - Create inode + initialize with '\0' the data blocks

```
$ df
# Filesystem        1K-blocks   Used      Available   Use%  Mounted on
/home/faculty  1091260416 876950528 214309888  81% /home/faculty
$ dd if=/dev/zero of=./test.img bs=4k iflag=fullblock,count_bytes
count=1000000000  # 1GB
244140+1 records in
244140+1 records out
1000000000 bytes (1.0 GB) copied, 12.6773 s, 78.9 MB/s

$ stat test.img #
  File: 'test.img'
  Size: 1000000000 Blocks: 1953128
$ df
/home/faculty  1091260416 877926400 213334016  81% /home/faculty
```

The disk has shrunk by 1GB!

Δημιουργία Άδειου Αρχείου Μεγάλου Μεγέθους στο Shell

- **B) truncate – make a file smaller/larger**
  - Make/Modify i-node size but doesn't allocate disk pages on disk (slim file)
  - Mainly used to **shrink** log files to a certain size:

```
$ truncate -s 100K /var/log/syslog
```

If a FILE is larger than the specified size, the extra data is lost. If a FILE is shorter, it is extended and the extended part (hole) reads as zero bytes.

```
$ df
home/faculty      1091260416 876950528 214309888  81% /home/faculty
...

$ truncate -s 10G test.img
stat test.img   File: 'test.img'  Size: 10737418240 Blocks: 2048

$ df
home/faculty      1091260416 876950528 214309888  81% /home/faculty
...
$ ls -al test.img
-rw------- 1 dzeina faculty 10737418240 Oct 30 10:34 test.img
```

Slim file, no disk is lost