LUENTO 15

Levy I/O
Linux ja W2000 levy I/O

Ch 11.5-11 [Stal 05]

Ch 20.8 [DDC 04]

1

Sisältö

- RAID
- Lohkopuskurit (disk cache)
- Esimerkit: Linux, W2K

2

Siirrännän hierarkia

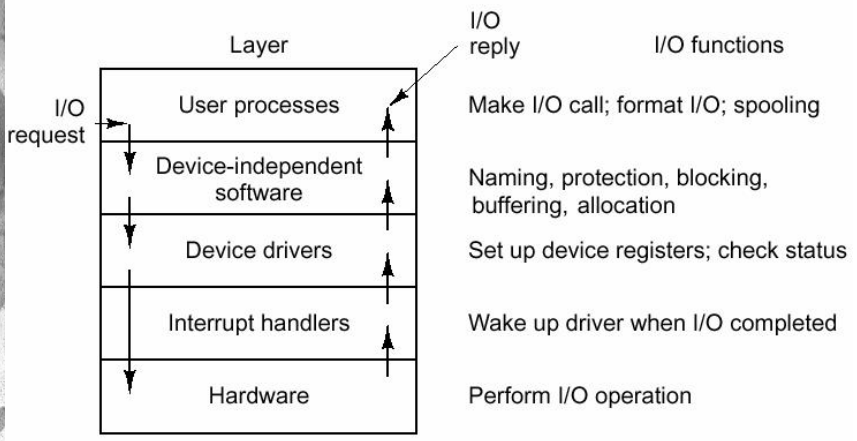

(Fig 5-16 [Tane01])

3

RAID -Redundant Array of Independent Disks (vai Inexpensive Disks)

Ch 11.6 [Stal 05]

4

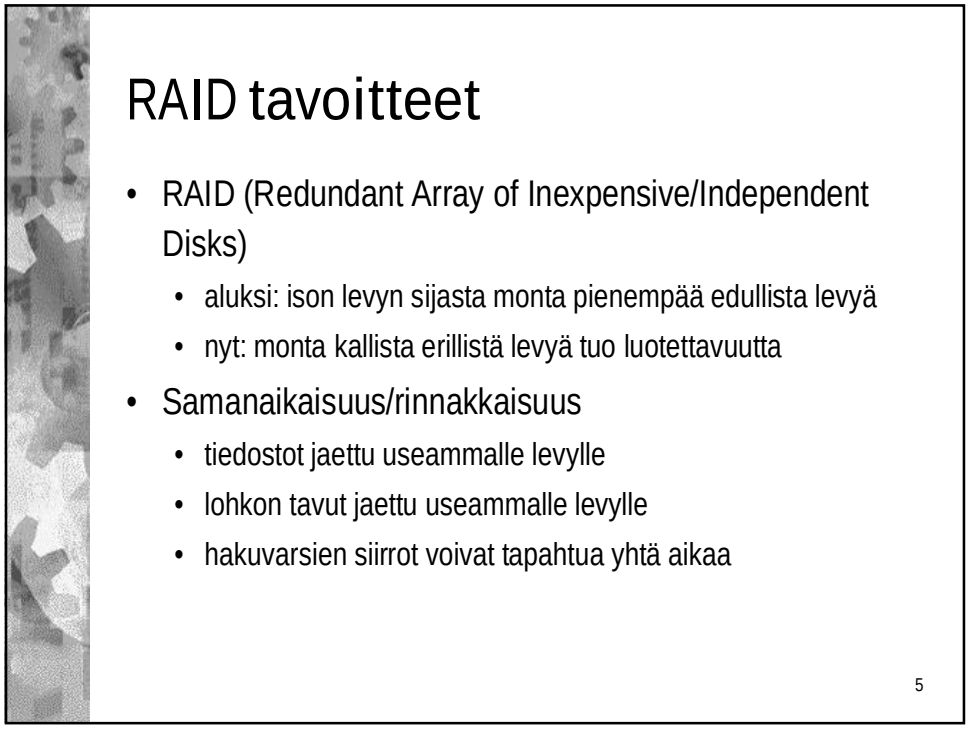
RAID tavoitteet
• RAID (Redundant Array of Inexpensive/Independent Disks)
• aluksi: ison levyn sijasta monta pienempää edullista levyä
• nyt: monta kallista erillistä levyä tuo luotettavuutta
• Samanaikaisuus/rinnakkaisuus
• tiedostot jaettu useammalle levylle
• lohkon tavut jaettu useammalle levylle
• hakuvarsien siirrot voivat tapahtua yhtä aikaa
5


RAID tavoitteet
• Koko levyjoukko näkyy KJ:lle yhtenä isona levynä
• Vikasietoisuus
• vaikka levy hajoaa, sillä ollut tieto voidaan (toivottavasti) luoda uudelleen muiden levyjen perusteella
• pariteetti, Mirror, Hamming, XOR ECC
• ei RAID 0:ssa (onko siis edes RAID?)
• “luku nolla tarkoittaa ei mitään”
• RAID 0 antaa suorituskykyä, ei redundanssia
6

RAID tavoitteet

- Tavallisen levyohjaimen sijasta levyä ohjaa ’älykkäämpi’ RAID-ohjain
  - ei tarvita muutoksia KJ:ään
  - huolehtii pariteetista
  - jos levy hajoaa, korjaa ’lennosta’ bittijonoa, käyttäjä ei huomaa
    - levy irti, uusi tilalle, eheytä se
- Myös ohjelmallisia toteutuksia (SW RAID)
  - yksi vikaantuva komponentti (RAID-ohjain) vähemmän
  - RAID-ohjain KJ:n ajurina
  - redundanssisuuslaskenta CPU:lla erillissuorittimen (levyohjain) asemesta
  - sama funktionaalisuus kuin HW RAID-ohjaimella

7

RAID 0 (ei redundanssia, ei toisintoja)

Fig 11.8a [Stal 05]

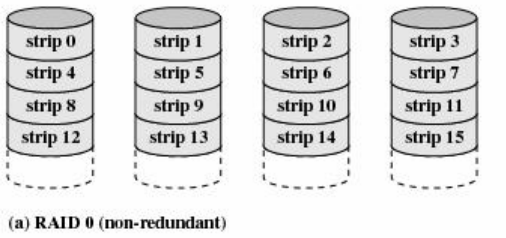

- Monta levyä, fiksusti organisoituna
  - usean levyn optimointiratkaisu
- Ei redundanssia, Data hajautettu usealle levylle
- Etu: nopeus, samanaikaiset haut eri levyiltä

8

Stripe

- Stripe raita
  - looginen levy jaettu saman kokoisiin strip-lohkoihin (levylohkon monikerta)
  - peräkkäiset strip-lohkot eri levyille
    - yhden tiedoston peräkkäiset sripit eri levyillä
  - samassa kohtaa eri levyillä olevat strip-lohkot muodostavat stripe raidan
  - tasapainottaa levykuormaa automaattisesti

9

RAID 1 (mirror, kahdennettu)

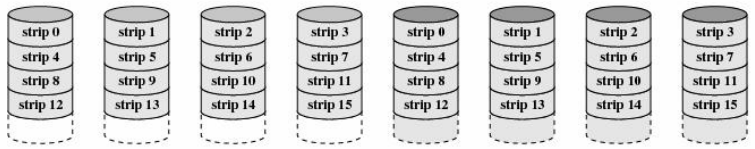

(b) RAID 1 (mirrored)

- Levyt tuplattu redundanssin vuoksi
  - mirror-levy
  - alkuaan tavalliset levylohkot, ei stripe'ja
- Levy rikkoutuu?
  - vaihda levy, päivitä tiedot "mirror"-levyltä

10

RAID 1 **(mirror)**

Fig 11.8b [Stal 05]

- Stripe-lohkot suorituskyvyn lisäämiseksi
  - oikeastaan ”RAID 0-1” tällöin (kun stripe-lohkot mukana)
- Suorituskykyetu
  - luku kummalta tahansa levyltä (levyjoukolta, stripe’lta)
    - kummalla lyhyempi saantiaika?
  - kirjoitus molempiin (samanaikaisesti)
  - samanaikaisuutta eri levyviitteissä
- Tilakustannus?
  - 50% levytilasta (iso!)
- Usein käytössä, normaali optio levyohjaimessa (”mirror disk”)

11

RAID 2 (Hamming)

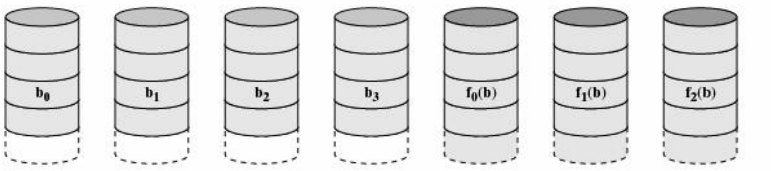

(c) RAID 2 (redundancy through Hamming code)

- Kaikki levyt aina käytössä, strip-lohkon koko 1 bitti
- Hamming koodi
  - 4 data bittiä -> 3 pariteettibittiä, 4 levyä datalle ja 3 pariteeteille
- Redundanssi
  - korjaa lennossa 1 bitin virheet, havaitsee 2 bitin virheet
- Levy rikkoontuu?
  - vaihda levy, laske bitit Hammingin avulla, alusta levy

12

RAID 2 (Hamming)

- Ei suorituskykyetua – päinvastoin?
  - luku aina kaikilta levyiltä yhtä aikaa, ja sitten tarkistus
  - kirjoitus kaikille levyille
  - ei samanaikaisuutta eri levyviitteissä
- Tilakustannus?
  - Hamming-koodin mukaan
  - 7 levyä: 3 pariteettilevyä eli 42%
  - 15 levyä: 4 pariteettilevyä eli 27%
  - yleensä liikaa

13

RAID 3 (pariteettibitti)

Fig 11.8d [Stal 05]

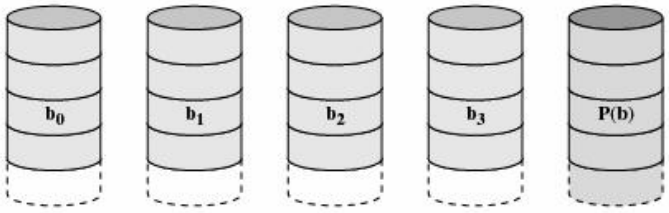

(d) RAID 3 (bit-interleaved parity)

- Pelkkä pariteettibitti, strip-lohkon koko 1 bitti
- Redundanssi
  - havaitsee 1 bitin virheet
  - korjaa lennossa
- Levy rikkoontuu?
  - vaihda levy, laske bitit pariteetin avulla, alusta levy

14

RAID 3 (pariteettibitti)

- Suorituskykyetu
  - luku ja kirjoitus aina kaikista levyistä (mutta rinnakkain)
  - jonotusaika ei vähene, mutta siirtonopeus kasvaa
  - ei samanaikaisuutta eri levyviitteissä
- Tilakustannus?
  - aina 1 levy
- Ei paljon käytössä, koska huono suorituskyky

15

RAID 4 (pariteettilohko)

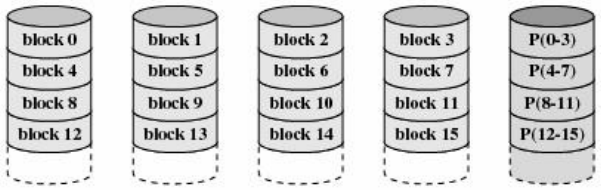

(e) RAID 4 (block-level parity)

- Pariteettilohko, strip-lohkon koko iso
- Redundanssi, jos levy rikkoontuu
  - korjaa lennossa 1 bitin virheet
  - vaihda levy, laske lohkot pariteetin avulla, alusta levy

Fig 11.8e [Stal 05]

16

RAID 4 (pariteettilohko)

- Suorituskykyetu
  - luku rinnakkain eri levyistä, levyt toimivat itsenäisesti
  - kirjoituksessa yhteen lohkoon muut saman stripe'n lohkot pitää ensin lukea pariteettilohkonlaskemista varten
    - tai sitten lue ensin vanha lohko ja laske siitä
  - kirjoituksessa pitää aina kirjoittaa myös pariteettilohko
  - jonotusaika vähenee, siirtonopeus kasvaa
  - samanaikaisuutta eri levyviitteissä
- Tilakustannus?
  - aina 1 levy
- Ei paljon käytössä, koska pariteettilevy on pullonkaula

17

RAID 5 (hajautettu pariteettilohko)

Fig 11.8f [Stal 05]

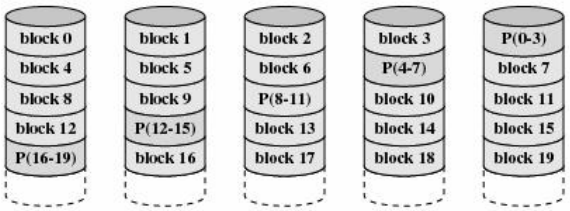

(f) RAID 5 (block-level distributed parity)

- Kuten RAID 4, mutta pariteettilohko vuorotellen eri levyille
  - kirjoittamisen yhteydessä ei enää pariteettilevyn pullonkaulaa
- Yleisesti käytössä oleva

18

RAID 6 (2 haj. pariteettilohkoa)

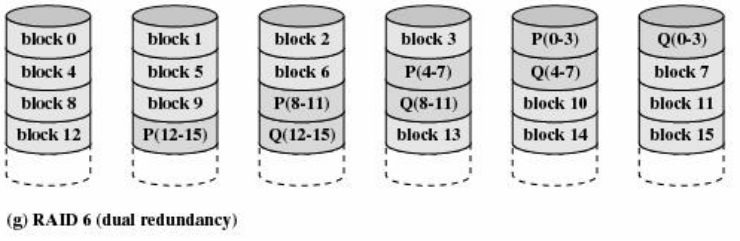

Fig 11.6g [Stal 05]

- kuten RAID 5, mutta tarkistuslohkot laskettu kahdella eri menetelmällä
- Redundanssi
  - korjaa lennossa 2 bitin virheet
- 1 tai 2 levyä rikkoontuu?
  - vaihda levyt, laske lohkot eri menetelmillä, alusta levyt

19

RAID 6 ja muut

- Ei niin standardoitu kuin RAID 0, … RAID 5
- RAID 6 (2 hajautettua pariteettilohkoa)
  - tilakustannus?
    - aina kaksi tarkistuslohkolevyä
- On muitakin…
  - RAID 0+1, RAID 0+3, RAID 0+5, RAID 1+5, RAID 10, RAID 50,
    RAID 51, RAID 53, …
  - RAID 7, Storage Computer'in patentti
    - nopeampi kuin RAID 3 tai RAID 5, luotettava, kallis
    - yksi pariteettilevy, levyohjaimessa suuri cache

20

RAID yhteenveto

Tbl 11.4 [Stal 05]

21

RAID ja TKTL (K2006)

- Tiedostopalvelimet group ja fs
  - 2 kpl 7 (+ 1 hot spare) levyn RAID 5 serveriä, á 2 TB
  - /group, /fs (mm. verkkopalvelua)

RAID kust. 14% (1/7)

RAID kust: 20% (1/5)

- 8 kpl 5 levyn (á 146 GB) RAID 5 servereitä, á 550 GB
  - */fs-0, /fs-1, /fs-2, /fs-3* (tavalliset tiedostopalvelimet)
  - *backup* varmuuskopioita varten
    - kopioi /fs-i tänne ja stream'aa 2 nauharobotille
    - SW RAID 5 Linuxin ytimessä, koska nauharobotit eivät sopineet yhteen RAID-ohjaimen kanssa
  - *db.cs.helsinki.fi* (tietokantapalvelin)
  - *winserver.cs.helsinki.fi* (Windows 2003 Terminal Server)
  - *courier.cs.helsinki.fi* (postipalvelin)

22

RAID ja TKTL (K2006)

- 2 krt 2 levyn RAID-1 nimipalvelin (Hydra)

RAID kust: 50% (1/2)
redund. kust 50%

- 4 levyn RAID 5 serveri, á 0.9 TB (Bioinformatiikka)
- 4 levyn RAID 5 serveri, á 0.45 TB (CoSCO)

RAID kust: 25% (1/4)

- 2 kpl 5 levyn RAID 5 serveriä, á 0.6 TB (Vera, Chuck)
  - Varsinaisesti laskentapalvelimia, levytila toissijaista

23

Lohkopuskurit

Ch 11.7 [Stal 05]

24

Lohkopuskurit, levypuskurit

- myös nimellä levyvälimuisti **(disk cache)**
- Buffer cache, block cache, disk cache
- KJ:n data-alueella oleva puskuri muistiinluettuja levylohkoja varten
  - jos viitattu lohko muistissa, ei levynoutoa
  - jokainen I/O-pyyntö ei aiheuta levyliikennettä
    - useimmat eivät
- Tasaa erot kerralla käsiteltävän yksikön koossa
  - ohjelma lukee/kirjoittaa tavuja
  - levyohjain lukee/kirjoittaa lohkoja

Ranskan kielen sana ”*cacher*” tarkoittaa piilottamista

25

Lohkopuskurit

- Paikallisuusperiaate pätee myös levyä käytettäessä
  - tiedostoa käydään läpi yleensä peräkkäisjärjestyksessä
  - seuraava viite todennäköisesti samaan lohkoon
- Ennaltanouto
  - kun tiedosto avataan, hae ens. lohko heti lohkopuskuriin
  - seuraavan nouto, heti kun edellistä käsitellään
  - (usean) seuraavan nouto samalla kertaa
- Viivästetty kirjoitus
  - talleta ensin levypuskuriin
  - kirjoita vasta täysi puskuri levylle …
  - … tai kirjoita muuttuneet esim. 30 sek välein levylle

vrt. virt.muistin cleanup

26

UNIX: Lohkopuskuri

Tan01 6-27

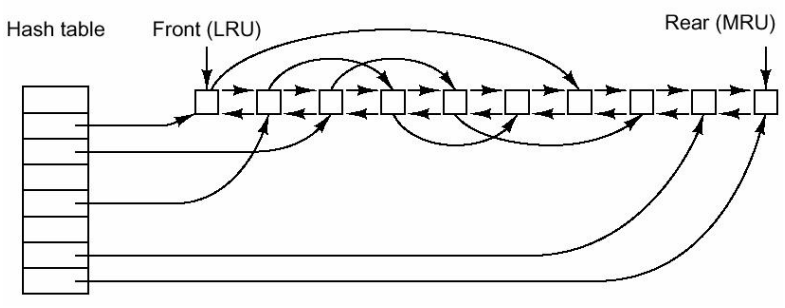

- Tunnussolmu
- laite#, lohko#, linkkejä, Modified, Free
- Puskurit kokonaisina erillisellä alueella
- tunnussolmussa viite varsinaiseen puskuriin
- Hajautustaulu etsinnän nopeuttamiseksi
- avaimena laite#, lohko#

27

Lohkopuskurin poistoalgoritmi

- Tilaa varattu rajallisesti
  - UNIX: esim 100 ... 1000 puskuria
  - Linux: koko vapaana oleva muisti (usein 50% muistista)
- Kun ei enää tilaa uusille lohkoille, joku lohko poistettava puskurista
- Samat ongelmat kaikessa puskuroinnissa
  - TLB: mikä alkio korvataan?
  - välimuisti: mikä muistilohko korvataan?
  - levypuskuri: mikä levylohko korvataan?
  - virtuaalimuisti: mikä sivutila / segmentti korvataan?
- Jos poistettava lohko on muuttunut, se täytyy kirjoittaa takaisin levylle

28

LRU: Least Recently Used

- Poista lohko, johon viittaamisesta kulunut kauimmin aikaa
- Loogisesti ajatellen:
  - levyvälimuisti on jono lohkoja
  - viimeksi viitattu lohko jonon viimeisenä
    - päivitys joka viittauskerralla?
  - poista jonon ensimmäinen lohko
- Toteutus: jonossa osoittimia lohkoihin
  - lohkoja ei tarvitse järjestellä
  - tietyn lohkon etsinnän tehokkuus?
- Poistettava voi silti olla tarpeellinen - sitä käyttävä prosessi sattui olemaan Blocked-tilassa
  - seuraus: pitää lukea levyltä pian uudelleen

29

LFU: Least Frequently Used

- Poista lohko, johon vähiten viittauksia
- Tarvitaan lohkokohtainen viitelaskuri
  - kasvata aina, kun lohkoon viitataan
  - laskurin nollaus aika-ajoin
- Lohko, jonka viitelaskuri on suuri, saattaa silti olla tarpeeton
  - prosessin vaihe, jossa lohkoa tarvittiin, on jo mennyt

30

Most Recently Used – MRU FIFO (Frequency Based Replacement)

- Yrittää huomioida molemmat edelliset ideat (LRU + LFU)
- Most Recently Used – MRU FIFO
  - jos uusi viite äskettäin viitattuun lohkoon (jonon loppuosassa)
    - lohko jonon perään
    - älä kasvata viitelaskuria
    - useat peräkkäiset viitteet kasvattavat laskuria vain kerran
  - jos viite kauan sitten viitattuun lohkoon (jonon alkuosassa)
    - lohko jonon perään
    - kasvata viitelaskuria
  - poista loppuosasta (old section) lohko, jonka viitelaskuri pienin
    - jos useilla sama arvo, poista takimmaisempi (LRU)

31

Most Recently Used – MRU FIFO

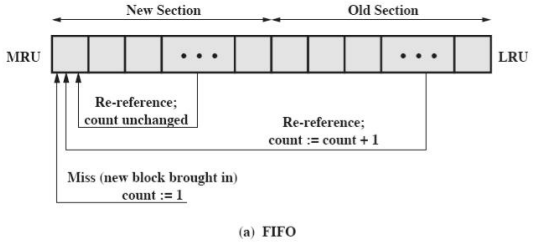

(a) FIFO

Fig 11.9 (a) [Stal 05]

- Most Recently Used – MRU FIFO
  - ajatus hyvä 10, mutta vain vähän parannusta
  - kun lohkoon viitataan se säilyy alkuosassa
  - kun viittaukset loppuvat, lohko putoaa loppuosaan
  - viimeksi loppuosaan joutuneella lohkolla pieni viitelaskurin arvo
    - vaikka käytetty viimeksi, perällä olevista joutuu helpoimmin poiston kohteeksi, ellei siihen viitata pian uudestaan

32

Most Recently Used – MRU Three Sections

- Most Recently Used – MRU Three Sections
  - parannus: jaa jono kolmeen osaan
    - poistot aina viimeisestä osasta
    - etuosasta pudonneelle jää aikaa vanheta
  - tulos: parempi algoritmi kuin LRU tai LFU

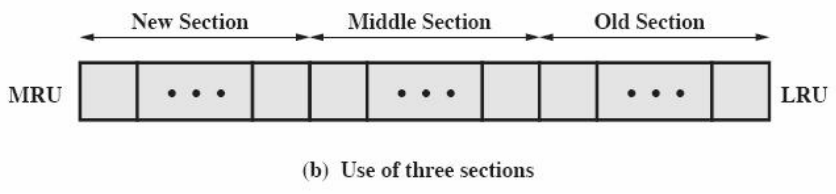

(b) Use of three sections

Fig 11.9 (b) [Stal 05]

33

Linux siirräntä (kernel 2.6)

Deitel Ch 20.8 [DDC 04]

Deitel, Deitel & Choffnes: Operating Systems, 3rd ed., Pearson Prentice Hall, 2004.

34

Linux Device Drivers

- Loadable kernel modules
  - more than 50% kernel space?
- Devices in device special files in /dev
  - major id number (= device type)
    - determines driver
    - device drivers in /proc/devices
  - minor id number (device)
    - separates individual devices in same class
  - read/write/seek/ioctl to file invokes driver
  - device operations look like file ops
- Hot swappable devices ("plug-and-play" in Linux-land)
  - on enumerable bus positions (e.g., USB)
  - poll each position every now and then, find new device, identify it, and load kernel module for it

35

Linux Disk Scheduling

- Many algorithms provided
- Default algorithm: elevator variation
  - sort requests by track
  - try to merge with existing requests
  - LSTF – Least-Seek-Time-First

36

Linux Elevator Starvation Avoidance

- Problem: no guarantee of fast service, request can starve
  - busy writer can block lazy reader
- Solution #1: deadline scheduler — deadline vuorotus
  - each request has deadline (*read* 500 ms, *write* 5 s)
  - deadlines expire, expired requests will be serviced first
  - *read/write* FIFO queues to find expired requests quickly
  - group expired *read*s (and *write*s) together to minimize seeks
- Solution #2: anticipatory scheduler — ennakoiva vuorotus
  - synchronous (successive) *read*s happen usually once per timeslice
  - after each *read* wait for 6 ms (aver seek latency) for another *read* to arrive
    - if it arrives, service it first and avoid one seek
  - advantageous only if new reads more than 50% of the time
    - collect history data to decide if this method is used
  - performance gain 5x-100x

37

Linux I/O Interrupts

- Each device has registered interrupt handler
  - interrupt handlers do not have context
  - interrupt handlers are not tasks (processes)
    - they can not be suspended or preempted
    - they can not cause exceptions
  - want to minimize time in interrupt handler
- top half — yläpuolisko
  - the real interrupt handler, fast, not a task, no context
  - schedules bottom half
- bottom half — alapuolisko
  - software interrupt handler, has context (e.g., device driver)
    - softirqs are suitable for SMP's, many concurrently
    - tasklets are suitable for mutex situations, one at a time
  - scheduled immediately after top half with high priority
    - if too many, all done one a time with low priority

38

Linux Page Cache (for block devices)

- Same cache for VM pages and for memory mapped files
- If data is not in cache, place a request to a device request list
  - kernel sorts (may sort) requests by sector
  - kernel can optimize list for the device before submitting (part of) it
  - bio structure (Block I/O) maps memory to each request
- Kernel calls device driver with request list
  - device completes all requests in list
  - data transfer via kernel buffer cache
- HW RAID devices are given requests directly
- SW RAID implemented in kernel (included in std kernel)
- Linux Direct I/O does not use Page Cache (disk buffer)
  - direct copying from device to user space
    - no need to copy through kernel buffer cache
  - driver still suspends while waiting

39

Windows 2000 I/O

Ch 11.10 [Stall 05]
Ch 11.6 [Tane 01]

40

W2K I/O-manager

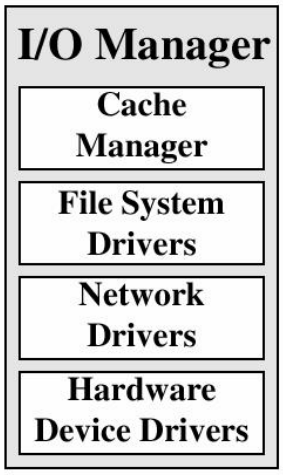

(Fig 11.15 [Stal05])

- Device independent API for all devices
  - many different API's for all kinds of devices (device types)
- Dynamically loadable
- Cache
  - common for all file systems and networks
  - size varies dynamically
  - lazy *write* and *commit*
- Device drivers
  - access device registers via generic HAL interface
    - DLL for each platform

41

W2K Device Drivers

- Windows Driver Model
  - plug-and-play
  - re-entrant code, SMP supported
  - for each device, device object created in directory \??
  - W2000 and W98 support
- New device?
  - plug-and-play manager queries it for manufacturer and model
  - if recognized, load driver to memory from disk
  - if not recognized, ask for CD (or floppy), and then load it
- IRP (I/O Request Packet) for all I/O requests
- Drivers may be stacked
- Filter driver can do transformations for other drivers

Fig 11-30 [Tane01]

42

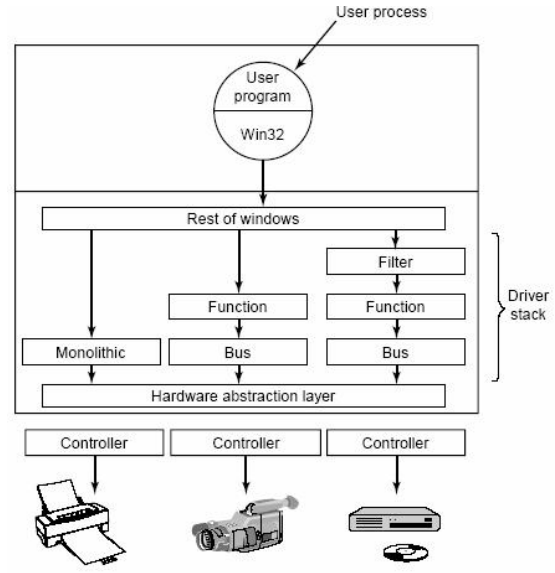

([Tane01]) Fig. 11-30. Windows 2000 allows drivers to be stacked.

43

W2K I/O

- File system
  - technically just a device with its own device driver
- SW RAID1
  - disk mirroring
    - shared device controller
  - disk duplexing
    - dedicated device controllers
- SW RAID 5
- Synchronous I/O
  - wait blocked until I/O completed
- Asynchronous I/O
  - send request and continue
  - later on, check that I/O completed and possibly wait
  - what can I do while waiting for I/O?

44

W2K Asynchronous I/O

- Send request and proceed
- Later on, check that I/O completed and possibly wait
  - signal via device kernel object
    - just one per device, so can wait for just one I/O request
  - signal via newly created event kernel object
    - any combination possible, because of many events
  - signal via thread APC queue (Asynchronous Procedure Call)
    - result of I/O-op to APC queue
    - APC executed later on (and signals thread requesting I/O?)
  - signal via specific I/O completion ports
    - fast
    - ready pool of ports

45

W2K I/O Interrupts

(W XP, Ch 21.5 [DDC04])

- Fast response time by splitting interrupt handling to two parts
- Time critical in hardware interrupt service procedure
  - (same or lower level) interrupts disabled
  - no context
  - acknowledge interrupt, save interrupt state
  - invoke DPC or APC by triggering lowest level interrupts for them
- Rest in software interrupts DPC or APC (explained in next slides)
  - DPC (Deferred Procedure Call)
  - APC (Asynchronous Procedure Call)

Compare to Linux Top Half and Bottom Half!

46

W2K DPC

(W XP, Ch 21.5 [DDC04])

- DPC (Deferred Procedure Call)
- Software interrupts
- No own context, use interrupted thread context
  - for cases where context is not important
- Must not block in DPC
  - no context
- DPC queue at each processor
- Most of interrupt processing here

47

W2K APC

(W XP, Ch 21.5 [DDC04])

- APC (Asynchronous Procedure Call)
- Belongs to some thread, have context
  - invoke a procedure to be executed by someone else!
  - give thread something to do when he wakes up next time
  - usually I/O interrupt handler's not-so-time-critical part
- Special APC's have priority in execution order
  - before normal APC's
- Kernel mode APC (joka säikeellä jono)
  - software interrupts, generated by kernel mode components
  - executed only when owning thread is scheduled
  - all APC's done before thread can continue
- User mode APC (joka säikeellä jono)
  - threads can select when to execute APC's (if ever)
  - if thread never enters *alertable wait state*, then APC is never executed

48

(Ch 11.9 [Tane01])

W2K Cache Manager (Tiedostovälimuisti)

- One cache shared for all file systems
  - NTFS, FAT-32, FAT-16, CD-ROM, ...
  - sits on on top of the file systems
  - based on logical files (file, offset)
    - not on physical files (partition, block)

Fig 11-45 [Tane01]

- All files are mapped to memory (in kernel address space)
  - access through virtual memory manager
    - read op: copy from kernel address space to user addr. space
  - access to disk buffer looks just like any memory access
  - page fault to cache manager handled just like any other page fault
    - cache manager does not know about it
    - cache manager does not even see physical memory
      - physical memory handled by VM in 256 KB chunks

49

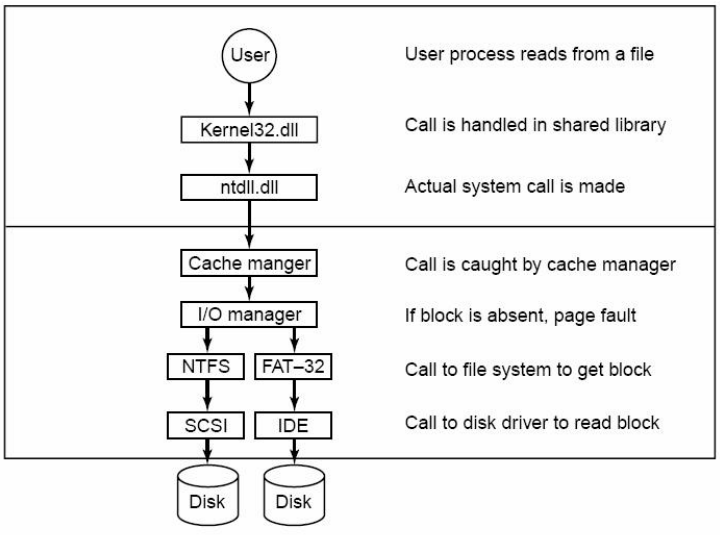

[Tane01] Fig. 11-45. The path through the cache to the hardware.

50