LUENTO 10

Muistinhallinnan esimerkit
UNIX, Solaris, Linux, W2000

Ch 8.3-8.6 [Stal 05]
Ch 10-11 [Tane 01]

1

UNIX / Solaris (+4BSD)
MUISTINHALLINTA

2

UNIX / Solaris (SVR4)

- Vanhoissa UNIXeissa ei virtuaalimuistia
  - heittovaihtoivat aina kokonaisia prosesseja
- Sivutus
  - tarvenouto
  - osittain ytimessä
  - osittain pagedaemon-prosessissa (pid=2)
    - käynnistyy aika-ajoin (esim. 250 ms:n välein) tarkistamaan, onko riittävästi vapaita sivutiloja (25%?)
- Heittovaihto
  - swapper-prosessi (pid=0)
  - pagedaemon käynnistää tarvittaessa
  - vain PCB (user structure) ja sivutaulu jää muistiin

3

UNIX/Solaris: Tietorakenteita

Page table - jokaisella prosessilla oma
- alkio per virt. muistin looginen sivu

Tbl 8.5 [Stal05]

Missä sivu keskusmuistissa?

Page frame number	Age	Copy on write	Mod-ify	Refe-rence	Valid	Pro-tect

(a) Page table entry

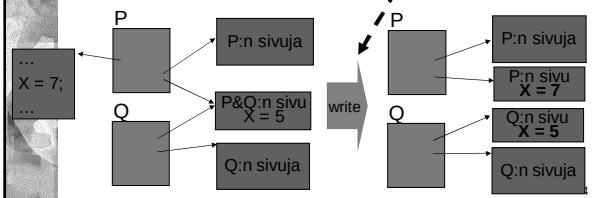

4

UNIX/Solaris: Tietorakenteita

Disk block descriptor - alkio per virt. muistin looginen sivu

Missä sivu tukimuistissa (eli levyllä)?

Swap device number	Device block number	Type of storage

(b) Disk block descriptor

Tbl 8.5 [Stal05]

5

UNIX/Solaris: Tietorakenteita

Tbl 8.5 [Stal05]

Page frame data table - alkio per fyysinen sivukehys,
vapaat sivutilat lisäksi free-listassa

Muistin sivukehyksen tila?

Page state	Reference count	Logical device	Block number	Pfdata pointer

(c) Page frame data table entry

Swap-use table - alkio per levyllä oleva sivu

Tukimuistissa olevan sivun tiedot?

Reference count	Page/storage unit number

(d) Swap-use table entry

6

UNIX/4BSD: Sivukehystaulu (core map)

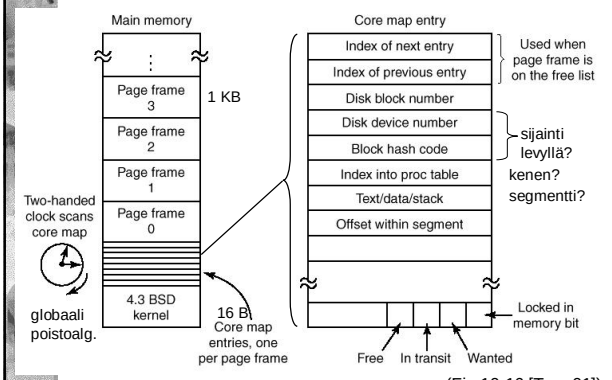

(Fig 10-16 [Tane01])

UNIX SVR4: Korvausalgoritmi

- Kaksiviisarinen globaali Clock poistoalgoritmi
  - tutki sivukehystaulua
  - prosessille annettujen sivukehysten (sivutilojen) lkm vaihtelee
  - etummainen viisari asettaa *Reference count* = 0
  - perässä tuleva viisari siirtää vapautettavaksi ne, joiden *Reference count* == 0 (edelleen?)

Kaksiviisarinen Clock

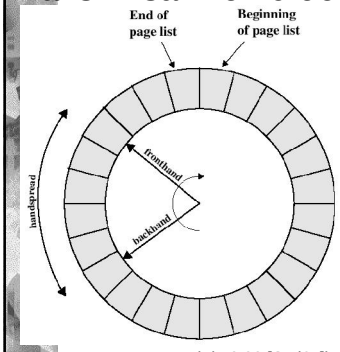

(Fig 8.23 [Stal05])

Fronthand:
set Reference = 0

Backhand:
if (Reference == 0)
page out

Idea: jos ei viittausta viime aikoina (eli viisarien pyyhkimisaikavälillä), niin kehyksessä oleva sivu ei kuulu käyttöjoukkoon

Miten nopeasti (frame/sec) viisarit liikkuvat? Montako kehystä on viisareiden väli?

Unix SVR4: korvausalgoritmi

Fig 8.23 [Stal05]

- Kaksiviisarinen clock
  - viisarien nopeus (scanrate) välillä [slowscan, fastscan]
    - molemmat viisarit etenevät samaa tahtia kehys kerrallaan, kunnes tarpeeksi vapaata tilaa
      - reset (fronthand); jos U(backhand)==0, vapauta se ; etene
  - gap (handspread) viisarien välissä
    - jos spread on pieni, vain hyvin usein viitattuihin sivuihin ehtii tulla viitebitti päälle
    - Jos gap = 359°, niin sama kuin 1-viisarinen clock (Fig. 8.16)
  - sopii paremmin suurille muisteille, nopeampi kuin tavallinen clock

(UNIX 4BSD)

Unix SVR4: korvausalgoritmi

- Ylläpidä: minfree < vapaiden sivutilojen lkm < maxfree
- Jos lkm < minfree, käynnistä swapper heittovaihtamaan prosesseja, jolloin sivutiloja vapautuu äkkiä paljon
  - pisimmän aikaa vähintään 20 sek. idle'nä ollut prosessi?
  - 4 suurimmasta prosessista kauiten muistissa ollut prosessi?
- Jos lkm lähellä minfree-arvoa
  - kasvata scanrate-arvoa (vapauta herkemmin, käynnistä algoritmi useammin)
- Jos lkm lähellä maxfree-arvoa,
  - pienennä scanrate-arvoa (viitebitin asetukselle aikaa lisää)

UNIX/Solaris: ytimen (kernel) muisti

- Perusvaraus sivutusta käyttäen
- Sivuja voi lukita muistiin
- Ydin varaa ja vapauttaa paljon pieniä alueita ja puskureita
  - tiedoston polkunimen selvitys
  - zombie-prosessista jälkeenjäävät tiedot
  - dynaaminen varaus: proc, vnode, tiedostokuvaaja
- Ydin varaa ja vapauttaa myös sivun osia
  - sivun sisällä tehtäviä varauksia hallitaan dynaamista tilanvarausta käyttäen (Ch 7 [Stal05])
  - varaus ja vapautus oltava tehokkaita

=> Laiska Buddy System (Lazy Buddy)

- lohkojen yhdistelyä viivästetään, kunnes vapaita lohkoja on "liikaa"

Buddy System (& lazy buddy system)

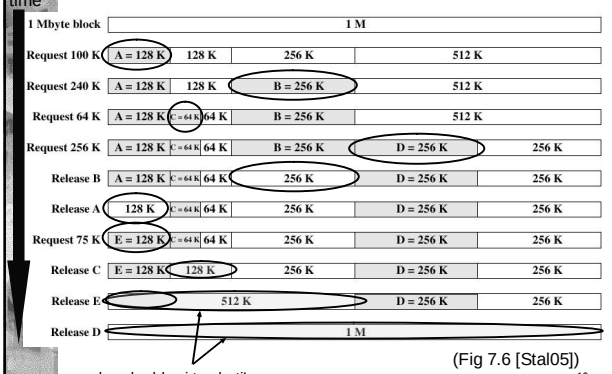

(Fig 7.6 [Stal05])

Muistiinkuvatut tiedostot

- Memory-mapped files
- Tiedostovälimuisti on muistissa
- Mapataan (kuvataan) virtuaalimuistialue tiedostovälimuistin päälle
- Tiedoston luku/kirjoitus muistin luku/kirjoitus-operaatioilla
  - nopea!
- Monta prosessia voi mapata helposti saman alueen
  - yhteiskäyttöiset tiedostot (koodi ja/tai data)
  - ks. kuva seuraavalla sivulla
- VM hallinnoi tiedostoja, ei File System!
  - VM voi siirtää sivun levylle, kun FS pitäisi sen muistissa
  - FS suunniteltu tiedostojen käyttöä varten, VM ei

Muistiinkuvattu tiedosto

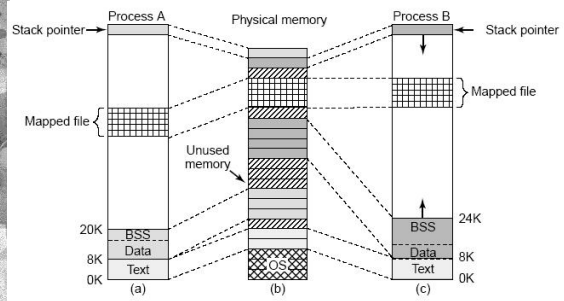

Fig. 10-14. Two processes can share a mapped file. [Tane01]

Linux MUISTINHALLINTA

Ch 8.4 [Stal 05]

Linux: muistinhallinta

- 32-bittisissä arkkitehtuureissa
  - 3 GB:n virtuaaliavaruus prosesseille
  - 1 GB ytimelle (mm. sivutaulut)
    - fyysisesti todellisen muistin alussa
  - etuoikeutetussa tilassa viitattavissa 4 GB
    - prosessin oma 3 GB
    - ytimen 1 GB
- Virtuaalinen osoiteavaruus jaettu yhtenäisiin alueisiin, joilla joka sivulla samat suojaukset ja ominaisuudet
  - vrt. segmentti
- Ytimen pienin allokoinnin yksikkö: slab (<< sivu)
  - ei ole tehokasta varata aina kokonaisia sivuja
  - vain ytimen käyttöön, joka tarvitsee paljon pieniä muistialueita

Linux: sivutus

- Laitteistoriippumaton toteutus
  - Alpha: 64b osoitteet, tuki 3:lle tasolle, sivu 8KB
    - offset 13 bittiä
  - x86: 32b osoitteet, käyttää 2-tasoa, sivu 4KB
    - offset 12 bittiä
- 3-tasoinen sivutaulu
  - page directory (PD), 1 sivu
  - page middle directory (PMD), monta sivua
  - page table (PT), monta sivua
- Ylin taso aina muistissa
  - säikeen vaihdossa fyysinen osoite MMU:hun (PD)
  - muut voivat olla tukimuistissa!

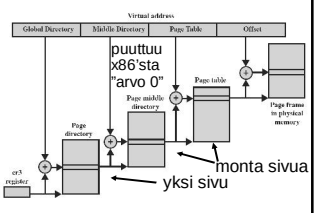

(Fig 8.25 [Stal05])

Linux: osoitemuunnos

- Jaa osoite 4:ään osaan
  - indeksi ylimmän tason hakemistoon (PD-offset)
  - indeksi välitason hakemistoon (PMD-offset)
  - indeksi sivutauluun (PT-offset)
  - siirtymä sivun sisällä (offset)

```
PMD_base  = PD_base   + PD[PD_offset]
PT_base   = PMD_base  + PMD[PMD_offset]
Page_base = PT_base   + PT[PT_offset]
fyys.os   = Page-base + offset
```

- X86-jippo
  - välitason hakemiston (PMD) koko vain yksi alkio!
  - laitteisto tulkitsee ylimmän tason (PD) alkion osoittavan suoraan alimman tason sivutauluun (PT)
  - sopii muillekin laitteistoille, joissa vain 2 tasoa

19

Linux: varausalgoritmi

- Varaa yhtenäinen lohko (area, region) peräkkäisille sivuille
  - tehostaa levyltä noutoa ja takaisin kirjoitusta
  - optimoi siis levyn käyttöaikaa (tilan kustannuksella)
- Buddy System: 1, 2, 4, 8, 16 tai 32 sivutilaa
  - toteutus: taulukko, jossa osoittimet koon mukaisiin vapaiden listoihin
  - paljon sisäistä pirstoutumista
    - tarvitset 18 sivua, mutta varaat 32 sivua!

20

Linux: noutoalgoritmi

- Tarvenouto
  - ei ennaltanoutoa, ei käyttöjoukon algoritmeja
- Toisaalta, lohkon usea sivu voidaan ehkä hakea kerralla (buddy system)
  - ennakoiva nouto?
    - ei viitepaikallisuuden vaan levypaikallisuuden mukaan (alueellinen paikallisuus)
    - toivon mukaan lähellä toisiaan

21

Linux: korvausalgoritmi

- Globaali Clock M-bitillä + eräänlainen LRU
  - prosessilla dynaaminen varattujen sivutilojen lkm
- 8 bitin ikälaskuri (age) vrt. U-bitti
  - MMU kasvattaa, kun sivuun viitataan
  - taustaprosessi (kswapd) tutkii ja vähentää sekunnin välein
    - vähentää 1 ikälaskurista jokaisella tutkintakerralla
    - jos vapaana liian vähän, vapauttaa sivutiloja
- Mitä suurempi ikälaskuri, sitä tiuhempaan sivuun viitattu
- Jos ikälaskuri = 0, sivuun ei ole viitattu
- Korvaa se, jonka laskuri pienin
- Käyttää sivujen puskurointia (pagebuffer)

22

Linux memory manager

```
260 * For choosing which pages to swap out, inode pages carry a
261 * PG_referenced bit, which is set any time the system accesses
262 * that page through the (mapping,index) hash table. This referenced
263 * bit, together with the referenced bit in the page tables, is used
264 * to manipulate page->age and move the page across the active,
265 * inactive_dirty and inactive_clean lists.
266 *
267 * Note that the referenced bit, the page->lru list_head and the
268 * active, inactive_dirty and inactive_clean lists are protected by
269 * the pagemap_lru_lock, and *NOT* by the usual PG_locked bit!
```

(include/linux/mm.h)

23

Linux daemon *kswapd* [Stal 05]

- Suorittaa kerran sekunnissa. Jos tarvitaan lisää vapaita sivukehyksiä, niin käy kaikki käytössä olevat sivut läpi, max 6 kierrosta, kunnes tarpeeksi vapaita
  - etsi käyttämättömiä sivuja modifioidulla clock'illa sivupuskurista (page buffer) ja tiedostovälimuistista
  - etsi yhteiskäytössä olevia käyttämättömiä sivuja
  - etsi tavallisista käytössä olevista sivuista
    - käy sivut läpi 1 prosessi kerrallaan
    - poista käyttämättömät puhtaat heti
    - pistä käyttämättömät likaiset levyjonoon
    - pistä käytössä olevat likaiset sivupuskuriin

24

Linux daemon *bdflush*

- Herää henkiin aika ajoin, tai explisiittisesti
- Jos ”liikaa” likaisia sivuja, rupea kirjoittamaan niitä levylle

25

Linux page cache

http://home.earthlink.net/~jknapka/linux-mm/vmoutline.html

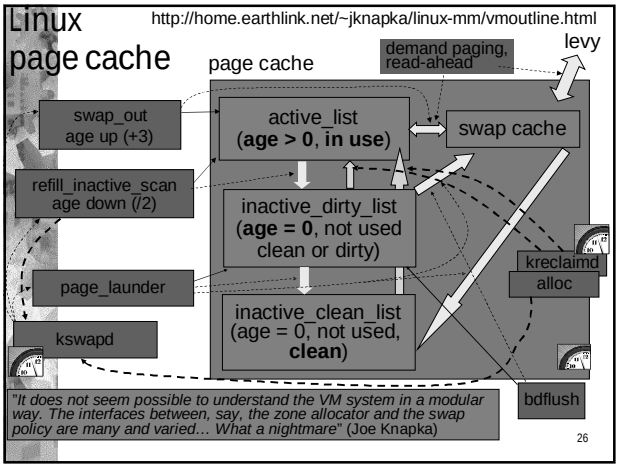

”*It does not seem possible to understand the VM system in a modular way. The interfaces between, say, the zone allocator and the swap policy are many and varied… What a nightmare*” (Joe Knapka)

26

Linux: tilanvaraus ytimessä

- Ydin lukittu pysyvästi muistiin
- Dynaaminen varaus sivuittain
- Dynaamisesti ladattavat moduulit kokonaisina ytimen muistialueelle — kmalloc()
  - buddy system sivutilatasolla
- Ytimessä usein tarvetta myös pienille lyhytaikaisille varauksille, slab’eille
  - yksittäinen sivu leikattavissa pienempiin osiin (slab)
  - buddy system sivun sisäisesti
    - x86: 32, 64, 128, 252, 508, 2040, 4080 tavua (sivu 4KB)

Slab: laatta, leikata laatoiksi, kattaa laatoilla

27

Slap allocation

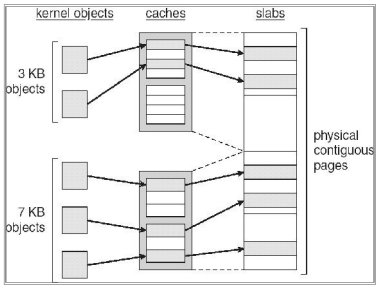

Fig 9.27 – Silberschatz, Galvin & Gagne: Operating system concepts with Java

28

Windows 2000 MUISTINHALLINTA

Ch 8.5 [Stal 05]
Ch 11.5 [Tane 01]

29

W2K

- **32-bittiset osoitteet => 4 GB virt. os.**
- **Sivukoko 4K - 64K**
  Pentium: 4KB
  Alpha: 8K

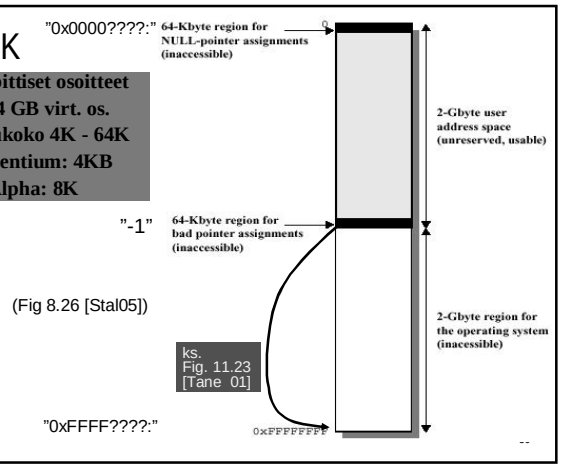

(Fig 8.26 [Stal05])

ks. Fig. 11.23 [Tane 01]

--

W2K: Sivutus

- Ei segmentointia
- Vaihtuva määrä sivukehyksiä / prosessi
  - aluksi kiinteä määrä (muistin määrän mukaan)
    - minimi 20-50, maksimi 45-345 (muistin koosta riippuen)
  - jos vapaata paljon, prosessi voi saada lisää
    - ahneen pitää jättää viimeiset 512 kehystä muille prosesseille
  - jos vapaan muistin määrä vähenee, prosessikohtaista sivutilamäärää vähennetään
- Tarvenouto
  - ei ennaltanoutoa
- Levy I/O isompina paloina
  - 1-8 sivua kerrallaan
  - eli siis myös jonkin asteen ennaltanouto!

31

W2K: Sivutus

(Fig 11.26 [Tane01])

- Sivutaulun alkioissa eroja eri järjestelmissä

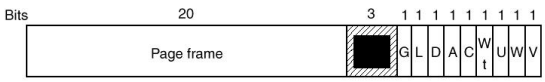

G: Page is global to all processes
L: Large (4-MB) page
D: Page is dirty
A: Page has been accessed
C: Caching enabled/disabled
Wt: Write through (no caching)
U: Page is accessible in user mode
W: Writing to the page permitted
V: Valid page table entry

Pentium

- Sivun tilat
  - Available
  - Reserved:
    - varaus, jota ei vielä laskettu prosessin osuuteen
    - nopea allokointi, kun tarvitaan (esim. pino)
  - Committed: käytössä, tila myös tukimuistissa

Fig 11.24 [Tane01] (seur. kalvo)

32

W2K osoite-avaruus

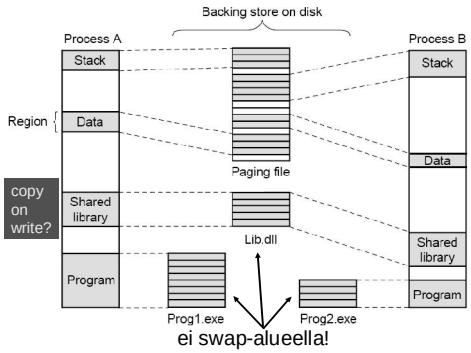

[Tane01]
Fig. 11-24. Mapped regions with their shadow pages on disk. The *lib.dll* file is mapped into two address spaces at the same time.

33

W2K: Korvausalgoritmi

- Käyttöjoukkoalgoritmi, lokaali korvaus
  - käyttöjoukko per prosessi, ei per säie
- Balance set manager -daemon
  - tutkii 1 sek välein, onko riittävästi vapaita sivutiloja
- Working set manager
  - käynnistyy tarvittaessa
  - käyttöjoukon koko määräytyy dynaamisesti
  - vapauttaa prosessikohtaisia sivutiloja
  - aloittaa isoista idle-prosesseista
- Swapper-daemon
  - ajetaan 4 sek välein: etsi prosesseja, joiden kaikki säikeet olleet passiivisia kauan aikaa
- Osa KJ:sta ja puskuriallas lukittu muistiin
- Vapautettujen sivujen puskurointi

34

W2K Poistettavan sivun valinta

- Joka sivulla laskuri – kauanko sivu käyttämättä
- Yksi suoritin

vrt. Linux Age

  - jos ei viitettä, lisää laskuria
  - jos viite, nollaa laskuri
  - modifioitu Clock?
- Monta suoritinta
  - viitebitit eivät toimi, koska lokaaleja suorittimelle!
  - FIFO-järjestys (onko hyvä? nyt yleinen tapaus!)
- Neljä ”vapaiden sivujen” listaa
  - dirty, clean, free, zeroed free (ja bad)
- Kukin fyysinen sivu
  - jossakin käyttöjoukossa
  - jossakin vapaiden sivujen joukossa
    - silti prosessin käytettävissä?

Fig 11.27 [Tane01] (seur. kalvo)

35

W2K: Vapaat sivutilat

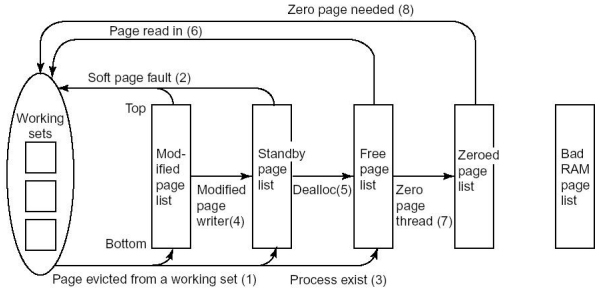

(Fig 11.27 [Tane01])

36

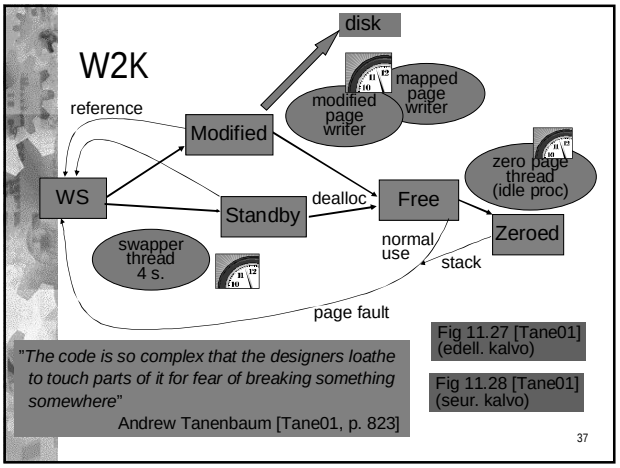
W2K
disk
reference
Modified
modified page writer
mapped page writer
WS
Standby
dealloc
Free
zero page thread (idle proc)
Zeroed
swapper thread 4 s.
normal use
stack
page fault
"The code is so complex that the designers loathe to touch parts of it for fear of breaking something somewhere"
Andrew Tanenbaum [Tane01, p. 823]
Fig 11.27 [Tane01] (edell. kalvo)
Fig 11.28 [Tane01] (seur. kalvo)
37

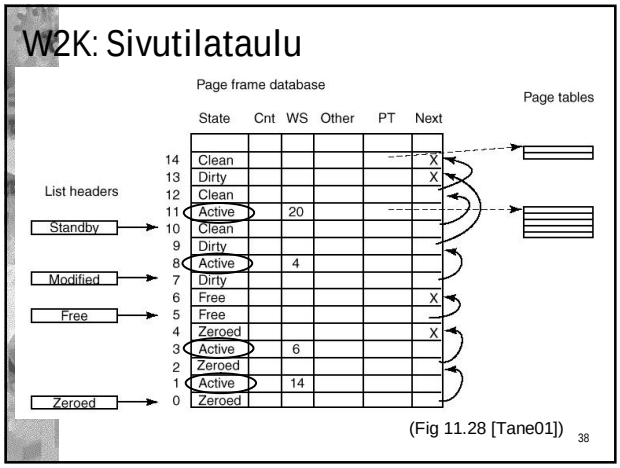
W2K: Sivutilataulu
Page frame database
Page tables
State Cnt WS Other PT Next
List headers
Standby
Modified
Free
Zeroed
14 Clean X
13 Dirty X
12 Clean
11 Active 20
10 Clean
9 Dirty
8 Active 4
7 Dirty
6 Free X
5 Free
4 Zeroed X
3 Active 6
2 Zeroed
1 Active 14
0 Zeroed
(Fig 11.28 [Tane01])
38