PB 169 Počítačové sítě a operační systémy

I/O systém

Vnější paměti

Hardware

- HW pro I/O je značně rozmanitý
- Existují však určité běžně používané prvky
  - port
  - sběrnice (bus)
  - řadič (host adapter, controller)
- I/O zařízení jsou řízeny I/O instrukcemi (IN, OUT)
- Adresy I/O zařízení
  - uváděné přímo v I/O instrukcích (např. IN AL, DX : DX port, AL získaný bajt)
  - I/O se mapuje na přístup k paměti (např. grafická karta, videopaměť)
- Základní způsoby ovládání I/O
  - polling, programované I/O operace
    - aktivní čekání na konec operace
  - přerušení
  - DMA

Rozmístění I/O portů v PC

I/O address range (hexadecimal)	device
000–00F	DMA controller
020–021	interrupt controller
040–043	timer
200–20F	game controller
2F8–2FF	serial port (secondary)
320–32F	hard-disk controller
378–37F	parallel port
3D0–3DF	graphics controller
3F0–3F7	diskette-drive controller
3F8–3FF	serial port (primary)

Techniky provádění I/O

- Programovaný I/O (busy-waiting)
  - opakovaně se ptám na stav zařízení
    - připraven
    - pracuje
    - chyba
- I/O řízený přerušením
  - zahájení I/O pomocí I/O příkazu
  - paralelní běh I/O s během procesoru
  - I/O modul oznamuje přerušením konec přenosu
- Direct Memory Access (DMA)
  - kopírování bloků mezi pamětí a I/O zařízením na principu kradení cyklů paměti
  - přerušení po přenosu bloku (indikace konce)

Přerušení

- Přerušení obsluhuje ovladač přerušení (kód OS)
- Maskováním lze některá přerušení ignorovat nebo oddálit jejich obsluhu
- Patřičný ovladač přerušení se vybírá přerušovacím vektorem
  - některá přerušení nelze maskovat
  - přerušení mohou být uspořádána podle priorit
- Přerušení se používá i pro řešení výjimek (nejsou asynchronní)

DMA

- Přímý přístup do paměti (Direct Memory Access - DMA)
  - nahrazuje programovaný I/O při velkých přesunech dat
  - vyžaduje speciální DMA řadič
  - při přenosu dat se obchází procesor, přístup do paměti zajišťuje přímo DMA řadič
  - procesor a DMA soutěží o přístup k paměti

DMA: příklad

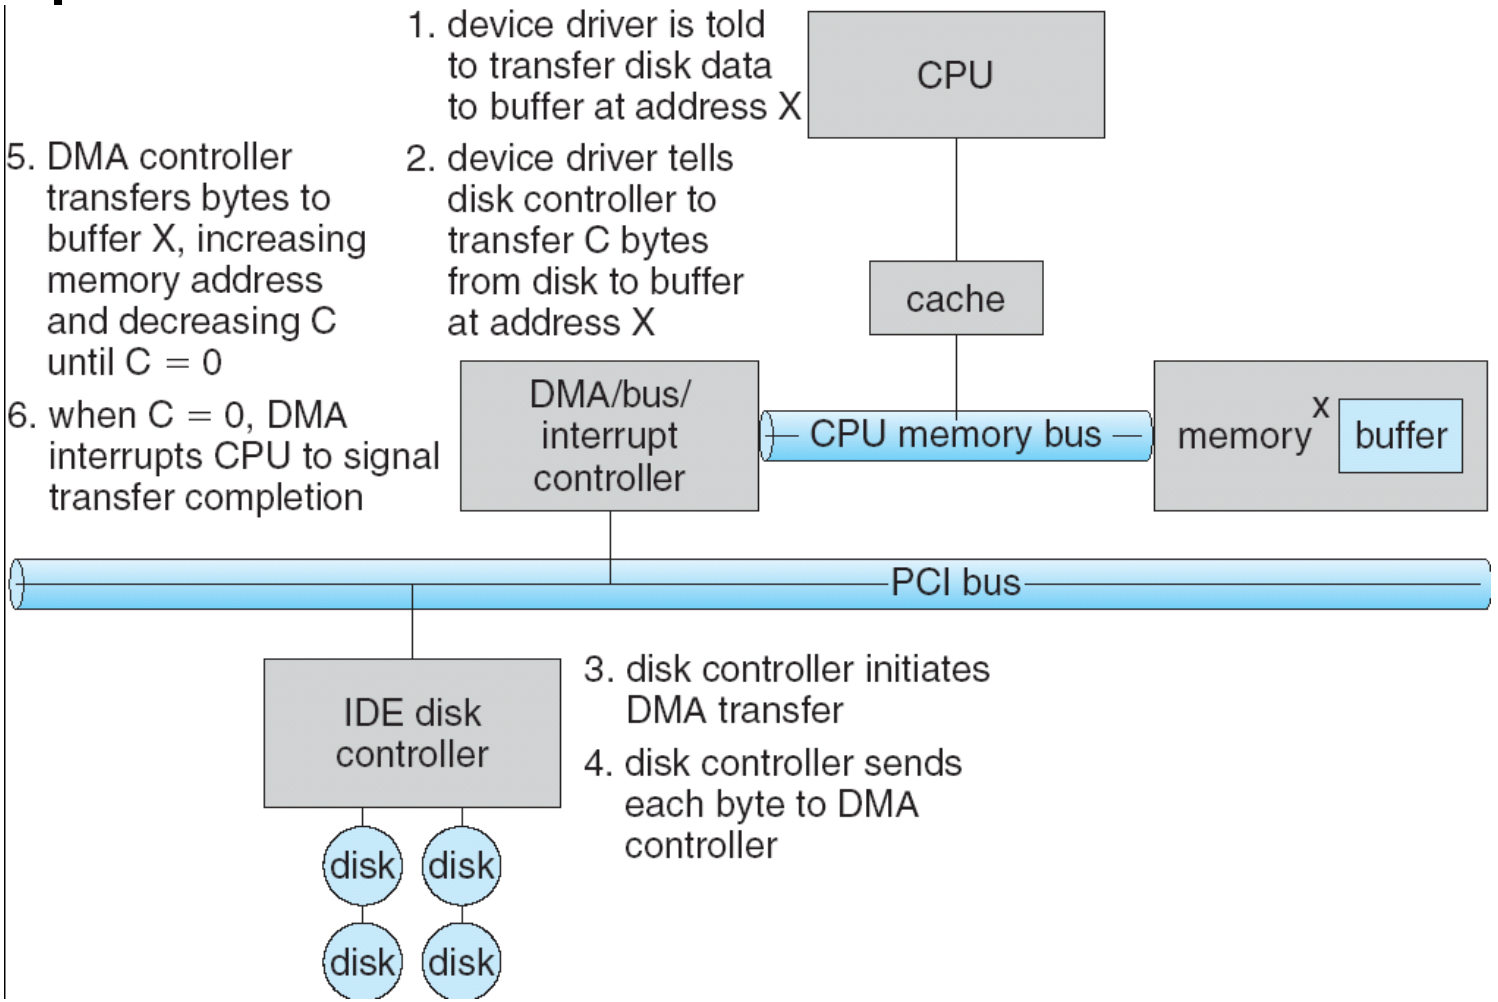
1. device driver is told to transfer disk data to buffer at address X
2. device driver tells disk controller to transfer C bytes from disk to buffer at address X
3. disk controller initiates DMA transfer
4. disk controller sends each byte to DMA controller
5. DMA controller transfers bytes to buffer X, increasing memory address and decreasing C until C = 0
6. when C = 0, DMA interrupts CPU to signal transfer completion
CPU
cache
DMA/bus/ interrupt controller
CPU memory bus
memory
x
buffer
PCI bus
IDE disk controller
disk
disk
disk
disk

Aplikační rozhraní I/O

- Jádro OS se snaží skrýt rozdíly mezi I/O zařízeními a programátorům poskytuje jednotné rozhraní
- Dále vrstva ovladačů ukrývá rozdílnost chování I/O řadičů i před některými částmi jádra
- Některé vlastnosti I/O zařízení
  - mód přenosu dat: znakové (terminál) / blokové (disk)
  - způsob přístupu: sekvenční (modem) / přímý (disk)
  - sdílené/dedikované: klávesnice / páska
  - rychlost přenosu: vystavení, přenos, ...
  - read-write, read only, write only

Bloková a znaková zařízení

- Bloková zařízení – typicky disk
  - příkazy: read, write, seek
  - logický způsob přístupu: obecný I/O nebo souborový systém
  - možný přístup formou souboru mapovaného do paměti
- Znaková – klávesnice, myš, sériový port
  - příkazy: get, put
  - nad nimi knihovní podprogramy pro další možnosti (např. řádková editace)

Síťová zařízení

- Přístup k nim se značně liší jak od znakových, tak od blokových zařízení
  - proto mívají samostatné rozhraní OS
- Unix i Windows obsahující rozhraní nazývané „sockets“
  - separují síťové protokoly od síťových operací
  - přístup jako k souborům (včetně funkce *select*)
- Existuje celá řada přístupů k síťovým službám
  - Pipes (roury), FIFOs, streams, queues, mailboxes

Blokující a neblokující I/O

- Blokující
  - z hlediska procesu synchronní
  - proces čeká na ukončení I/O
  - snadné použití (programovaní), snadné porozumění (po provedení operace je hotovo to co jsem požadoval)
  - někdy však není dostačující (z důvodu efektivity)
- Neblokující
  - řízení se procesu vrací co nejdříve po zadání požadavku
  - vhodné pro uživatelské rozhraní, bufferovaný I/O
  - bývá implementováno pomocí vláken
  - okamžitě vrací počet načtených či zapsaných znaků
- Asynchronní
  - proces běží souběžně s I/O
  - konec I/O je procesu hlášen signály
  - obtížné na programovaní, složité používání, ale v případě vhodně promyšleného programu velice efektivní

I/O subsystém v jádru

- Plánování
  - některé I/O operace požadují řazení do front na zařízení
  - některé OS se snaží o „spravedlnost“
- Vyrovnání (vyrovnávací paměti), buffering
  - ukládání dat v paměti v době přenosu k/ze zařízení
  - řeší rozdílnost rychlosti
  - řeší rozdílnost velikosti datových jednotek

Příklad: Sun Enterprise 6000

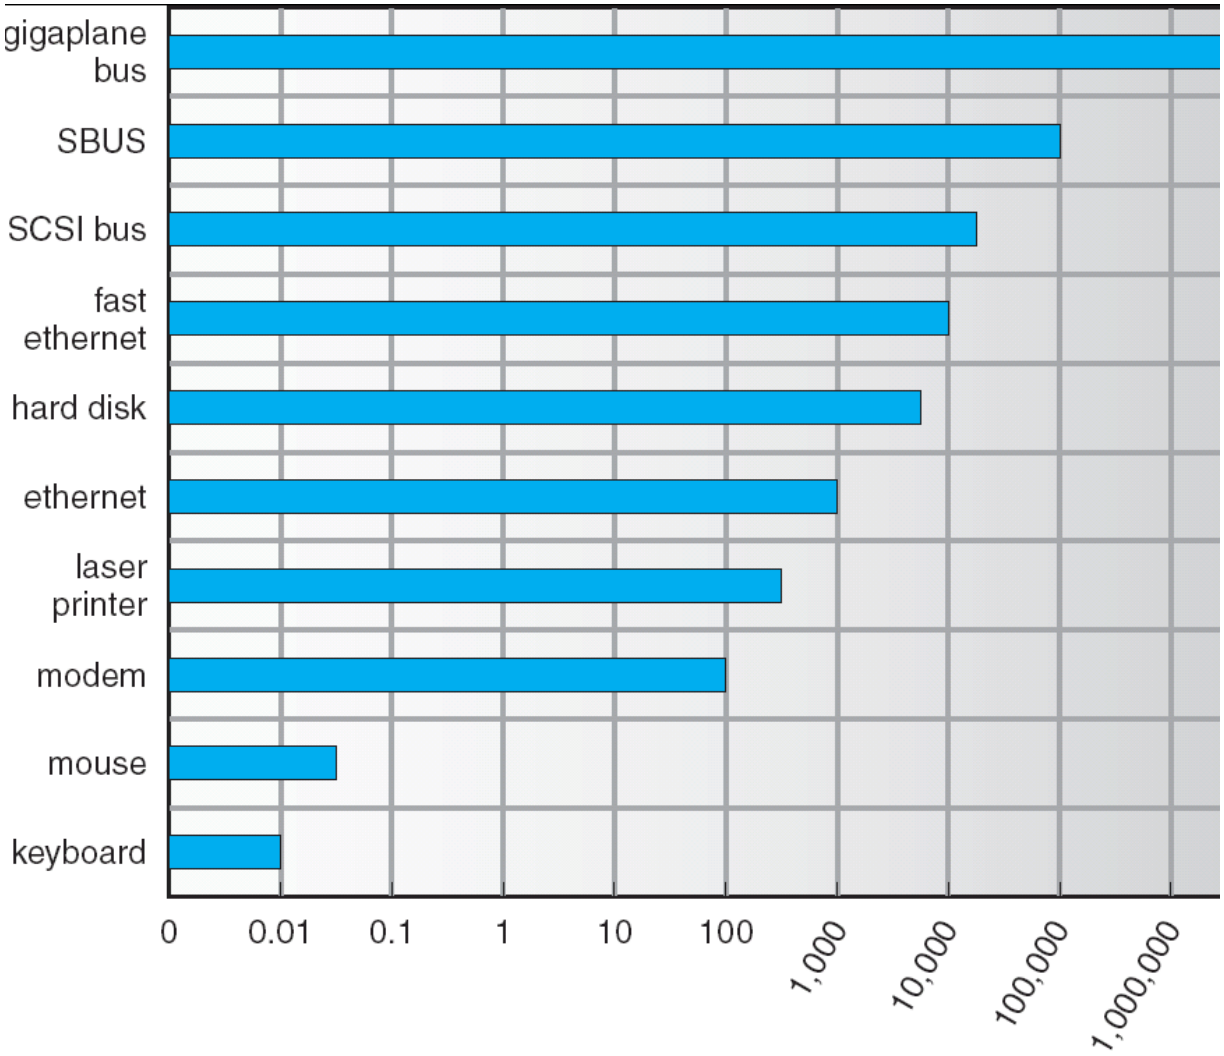

I/O Subsystém v jádru

- Caching
  - rychlá paměť udržuje kopii dat
  - vždy pouze *kopii*
  - caching je klíčem k dosažení vysokého výkonu
- Spooling
  - udržování *fronty dat* určených k výpis na zařízení
  - pokud zařízení může vyřizovat požadavky pouze sekvenčně
  - typicky tiskárna
- Rezervace zařízení
  - exkluzivita přístupu k zařízení pro proces
  - rezervace / uvolnění – volání systému
  - pozor na uváznutí (deadlock)

Výkon

- I/O je nejvýznamnějším faktorem výkonu celého systému
  - CPU musí provádět ovladače a programy I/O části jádra
  - při přerušení se přepíná kontext
  - provádí se kopírování dat
  - zvláště významný je síťový provoz

Příklad: Síťová aplikace

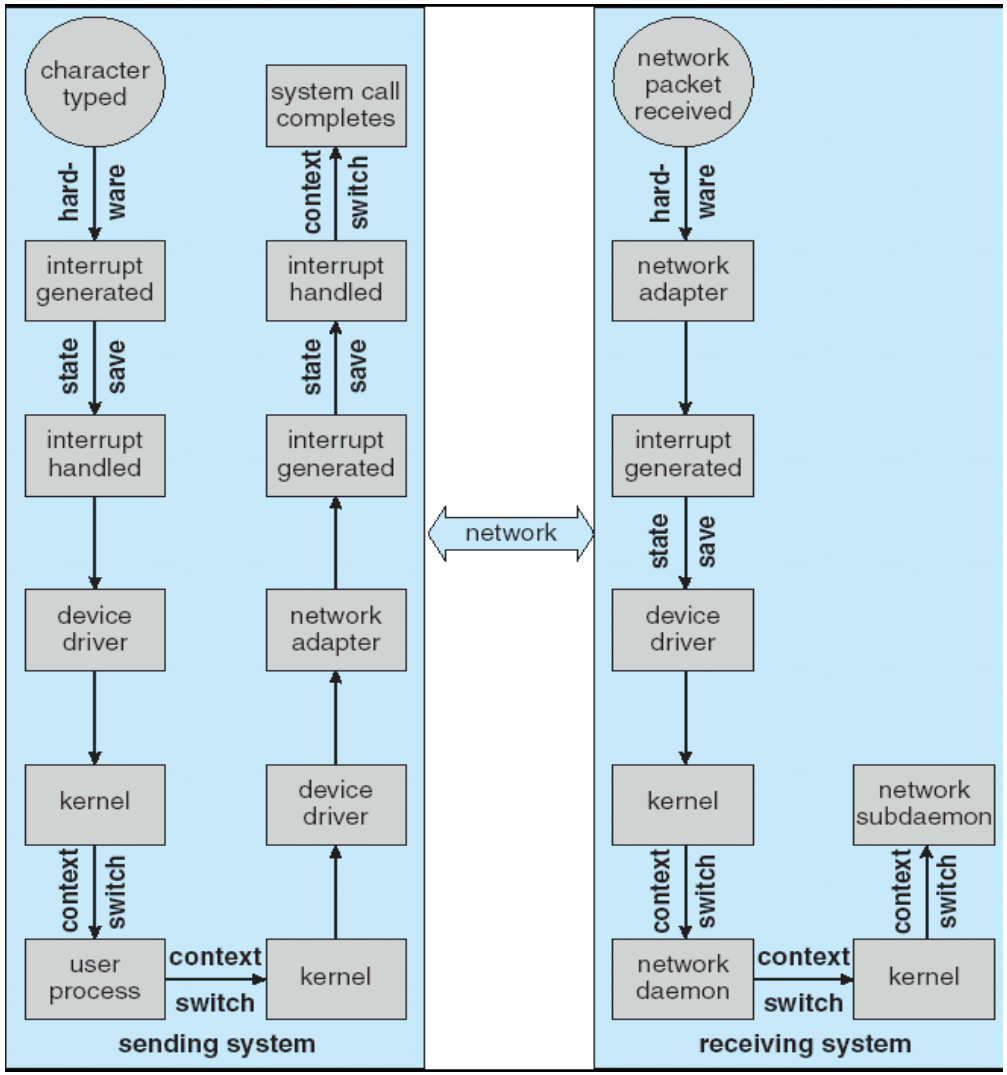

Zvyšování výkonu

- Omezujeme počet přepnutí kontextu
- Omezujeme zbytečné kopírování dat
- Omezujeme počet přerušení tím, že přenášíme delší bloky
- Využíváme všech výhod (funkcí) moderních řadičů
- Používáme co nejvíce DMA
- Všechny komponenty kombinujeme s cílem dosažení co nejvyšší propustnosti
  - CPU, paměť, sběrnice, I/O zařízení

Paměťová hierarchie

- Primární paměti
  - nejrychlejší
  - energeticky závislé
  - Cache, hlavní (operační) paměť
- Sekundární paměti
  - středně rychlé
  - energeticky nezávislé
  - Také nazývané „on-line storage“
  - flash disky, magnetické disky
- Terciální paměti
  - levná typicky vyměnitelná média
  - pomalé
  - energeticky nezávislé
  - také nazývané „off-line storage“
  - floppy disky, magnetické pásky, optické disky

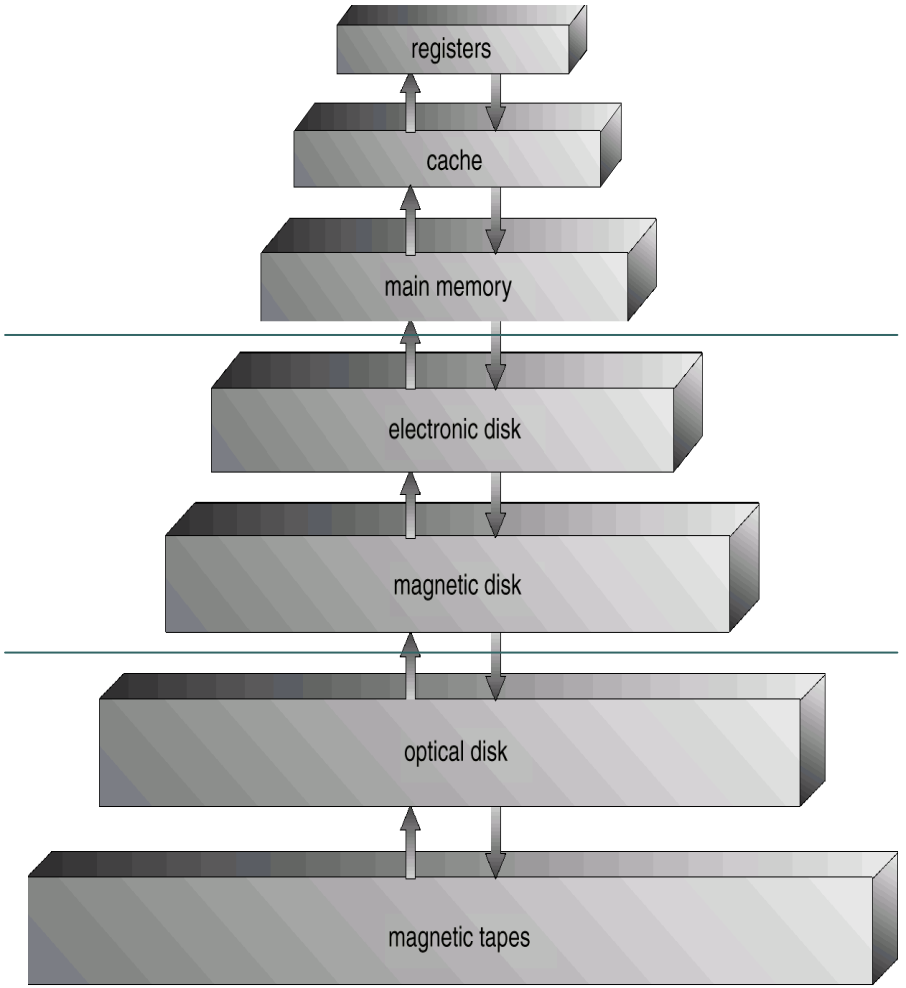

Magnetické disky

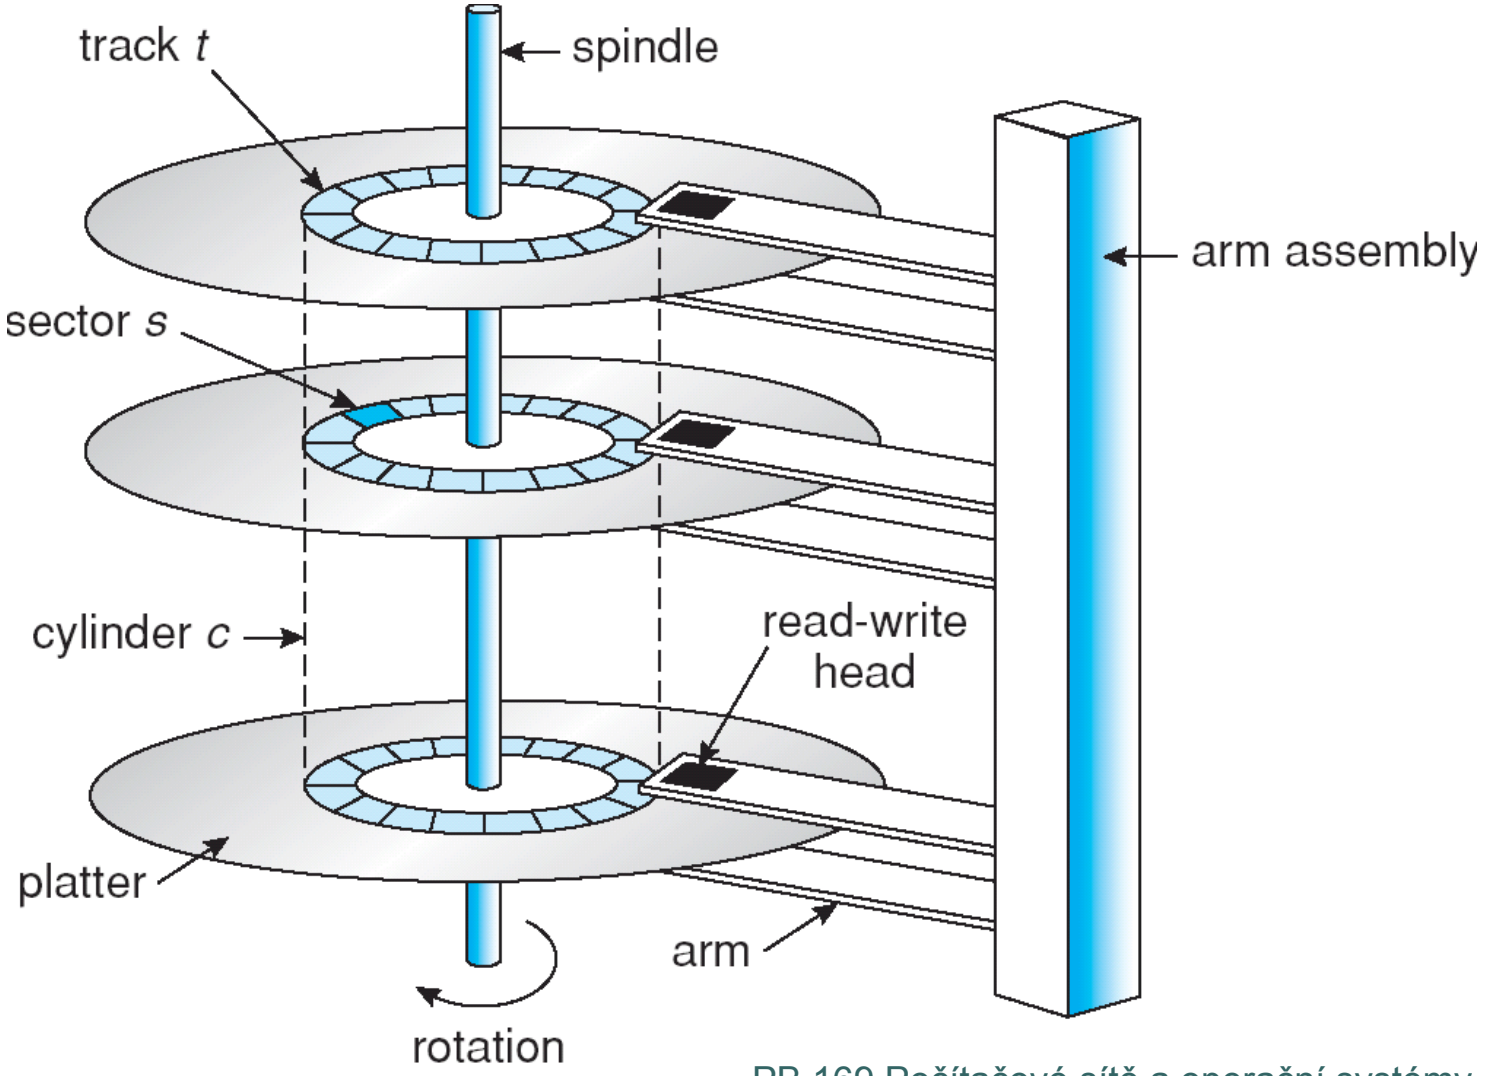

Struktura disku

- Diskové mechanismy se adresují jako velká 1-dimensionální pole logických bloků
  - logické bloky jsou nejmenší jednotkou přenosu dat
- 1-dimensionální pole logických bloků je zobrazováno do sektorů disku sekvenčně
  - sektor 0
    - první sektor na první stopě vnějšího cylindru
  - zobrazování pokračuje po této stopě,
    potom po ostatních stopách tohoto cylindru,
    a potom po cylindrech směrem ke středu

Plánování disku

- OS je odpovědný za efektivní používání hardware
  - pro disky: co nejrychlejší přístup a co největší šířka pásma
- Doba přístupu (*access time*) je dána:
  - dobou vystavení (*seek time*) – na cylindr se stopou s adresovaným sektorem
  - dobou rotačního zpoždění – dodatečná doba do průchodu adresovaného sektoru pod čtecí/zápisovou hlavou
- Minimalizace doby vystavení
  - doba vystavení ≈ vystavovací vzdálenosti
  - řeší plánování činnosti disku
- Rotační zpoždění
  - shora omezeno konstantou
- Šířka pásma
  - počet přenesených bytů / doba od zadání skupiny požadavků do jejich ukončení
  - převzatý pojem z telekomunikací

Plánování disku

- Existuje celá řada algoritmů pro plánování přístupu na disk.
- Příklad: vzorová fronta požadavků na přístup k disku (máme cylindry 0-199).

98, 183, 37, 122, 14, 124, 65, 67

Hlavička disku vystavena na pozici 53

FCFS

- Celkem přesun o 640 cylindrů

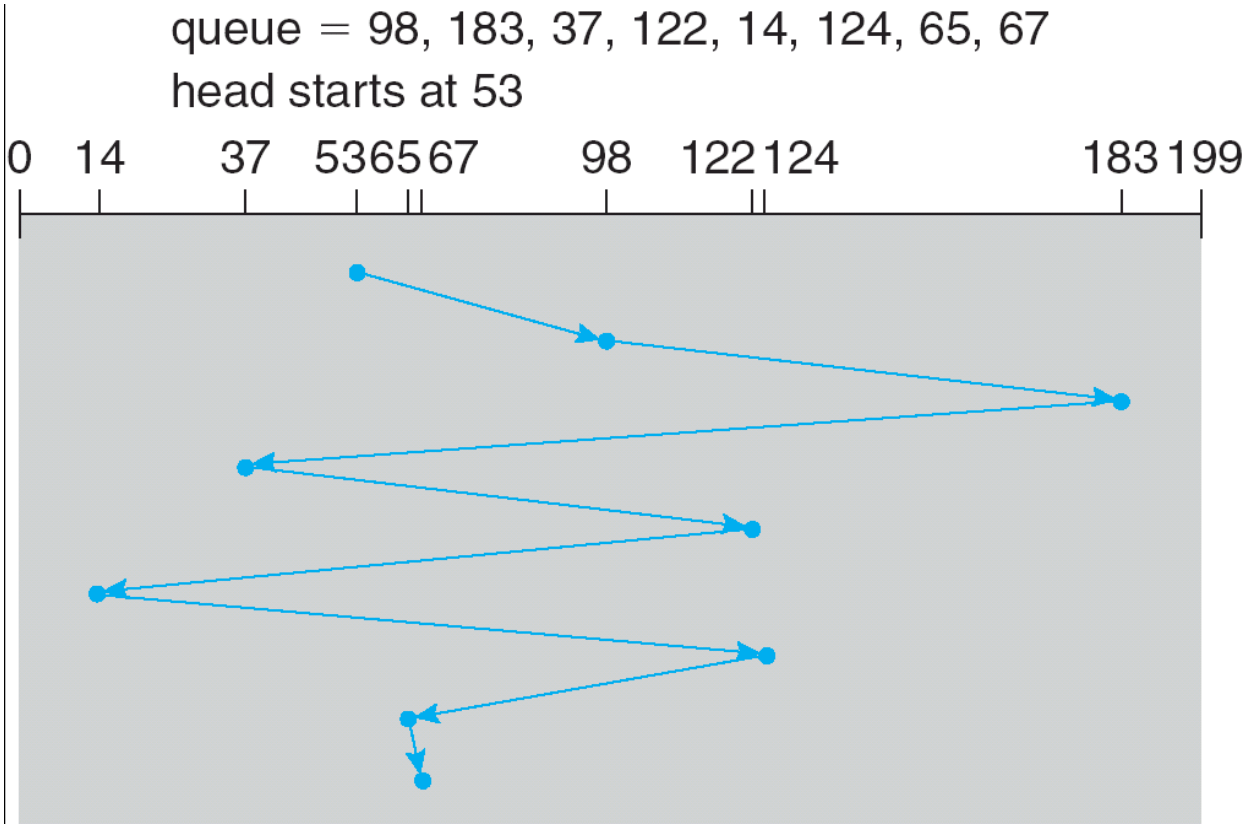

SSTF

- Z fronty požadavků vybírá ten požadavek, který vyžaduje minimální dobu vystavení od současné pozice hlavičky
- SSTF (*shortest seek time first*) algoritmus je variantou algoritmu SJF (*shortest job first*); může způsobit stárnutí požadavků.
- Náš příklad vyžaduje přesun o 236 cylindrů

SSTF

queue = 98, 183, 37, 122, 14, 124, 65, 67

head starts at 53

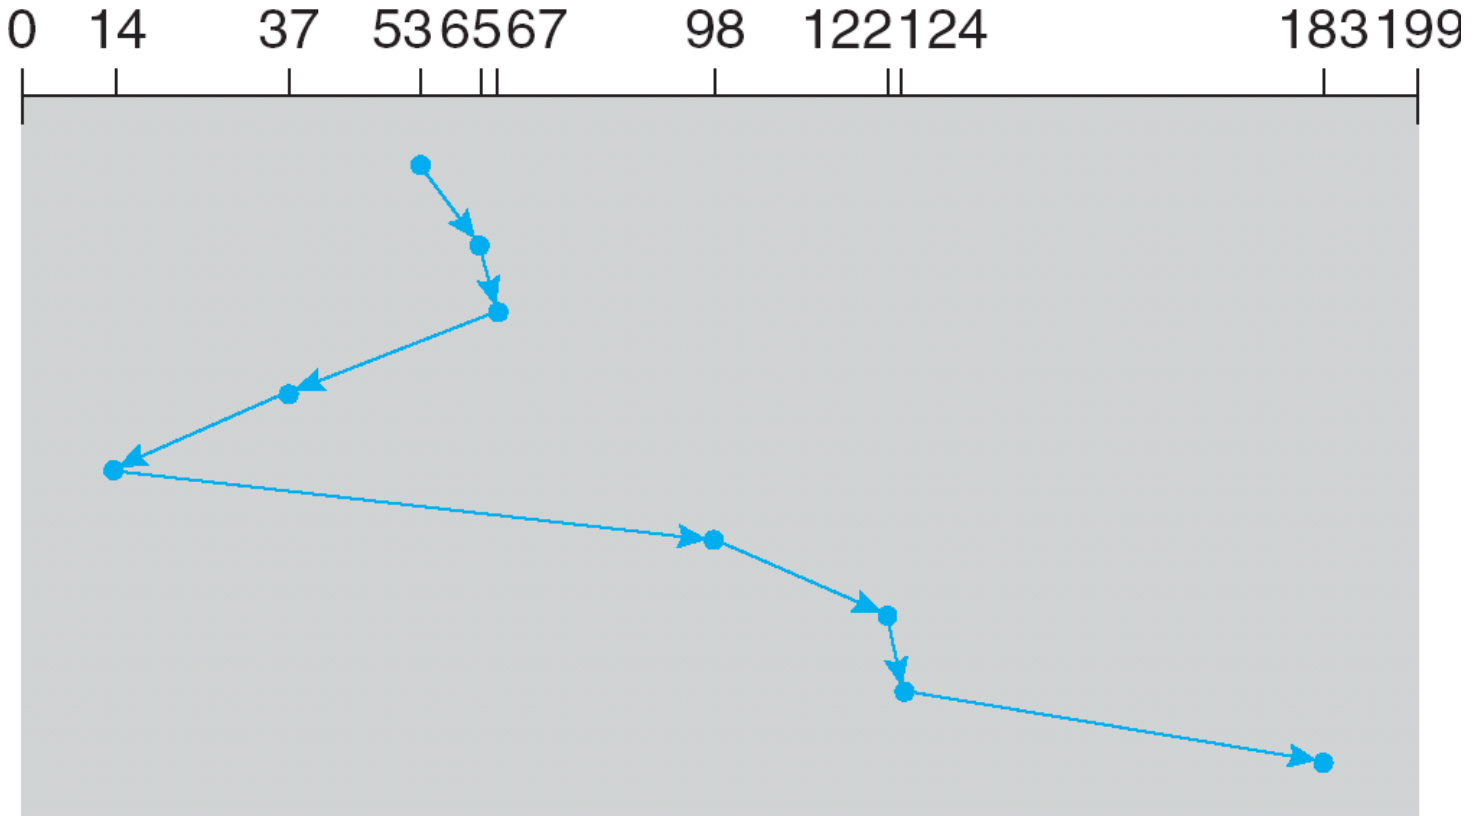

SCAN

- Hlavička disku začíná na jedné straně disku a přesunuje se při splňování požadavků ke druhé straně disku. Pak se vrací zpět a opět plní požadavky.
- Někdy nazývané *algoritmus typu výtah*.
- Náš příklad vyžaduje přesun o 208 cylindrů.

SCAN

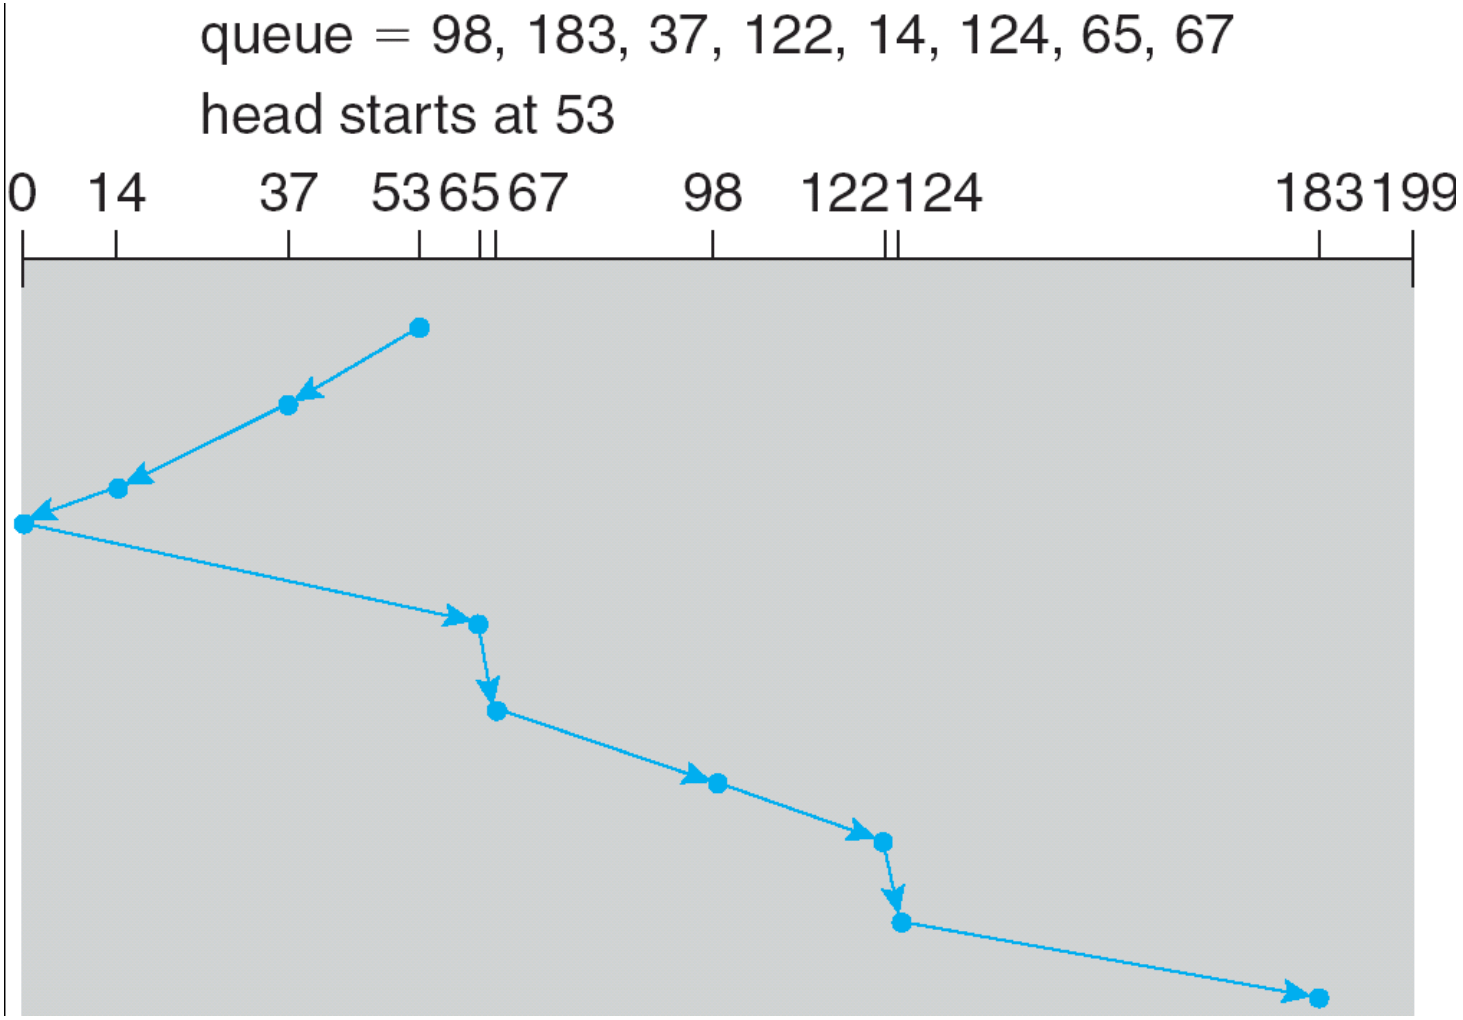
queue = 98, 183, 37, 122, 14, 124, 65, 67
head starts at 53
0
14
37
53
65
67
98
122
124
183
199

C-SCAN

- Poskytuje jednotnější čekací dobu než SCAN
- Hlavička se posouvá z jednoho konce disku na druhý a zpracovává požadavky. Potom se vrací zpět bez vyřizování požadavků a opět začíná vyřizovat požadavky z prvního konce.
- Cylindry považuje za kruhový seznam, který za posledním cylindrem pokračuje opět prvním cylindrem.

C-SCAN

queue = 98, 183, 37, 122, 14, 124, 65, 67

head starts at 53

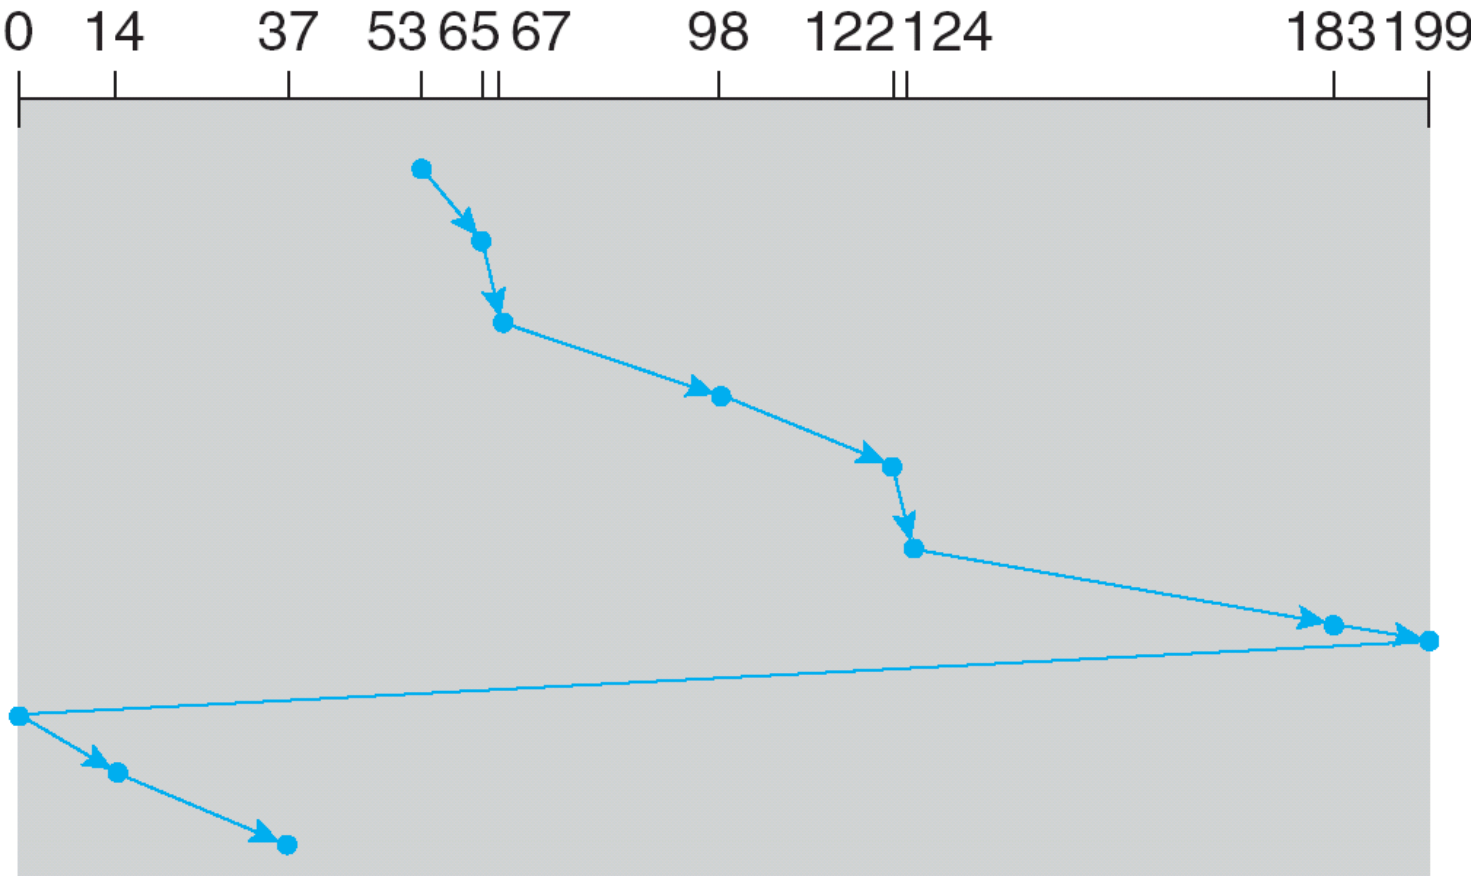

C-LOOK

- Obdoba C-SCAN, ale hlavička jen potud do kraje, pokud existují požadavky.
- Pak se vrací zpět

C-LOOK

queue 98, 183, 37, 122, 14, 124, 65, 67

head starts at 53

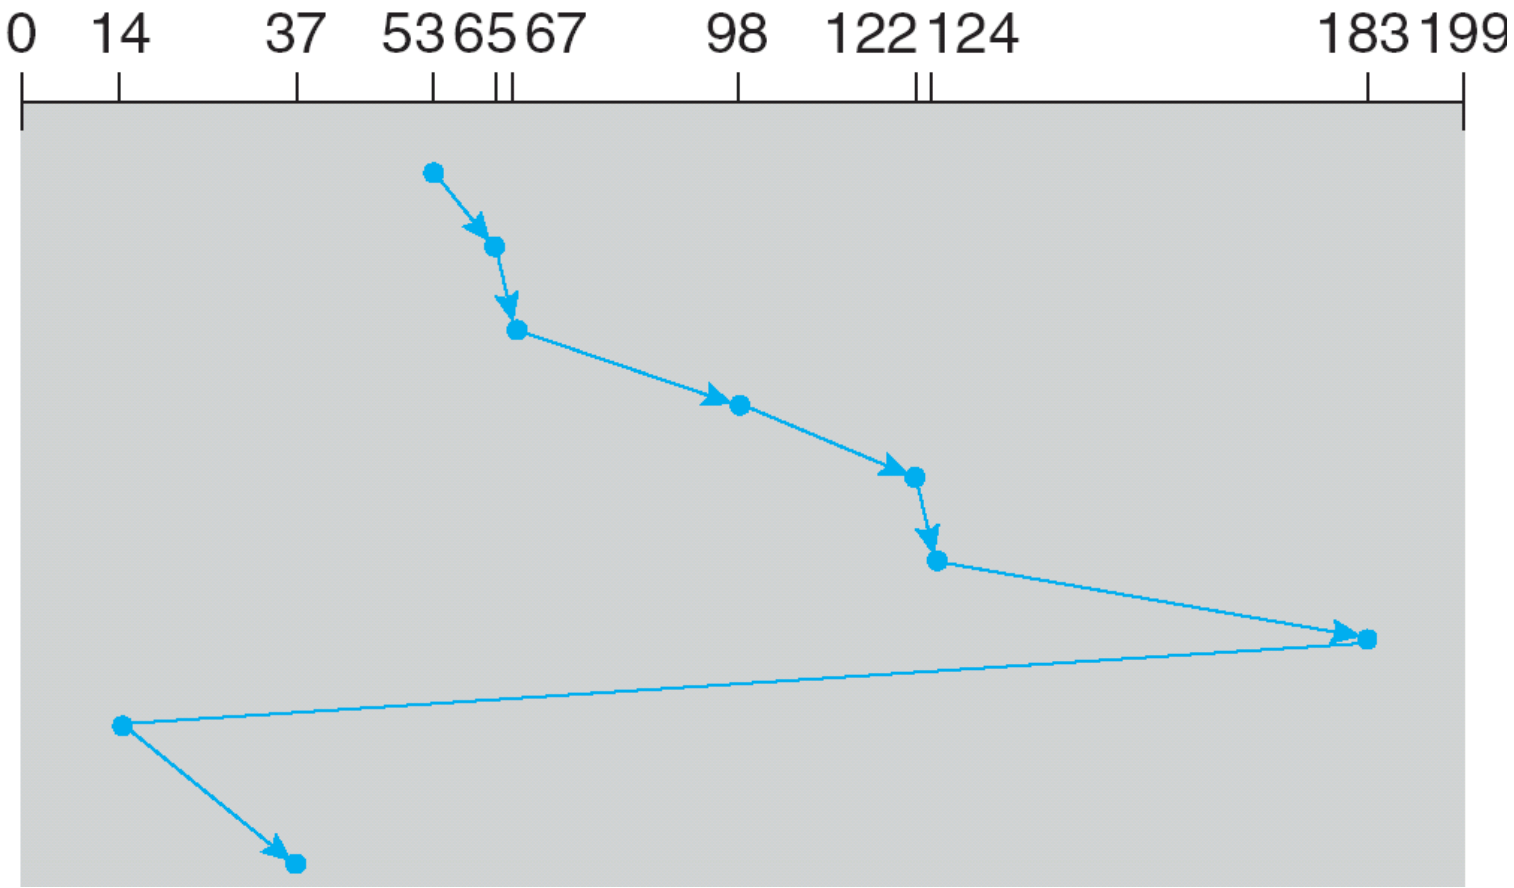

Výběr algoritmu

- SSTF je přirozený, má přirozené chápání
- SCAN a C-SCAN jsou vhodnější pro těžkou zátěž disku
- Výkon závisí na počtu a typech požadavků
- Požadavky na disk mohou být ovlivněny metodami organizace souborů v souborovém systému
- Plánovací algoritmus by měl být napsán jako samostatný modul, aby plánovací algoritmus OS bylo možné zaměňovat
- Častá implicitní volba bývá SSTF nebo LOOK

Moderní HW

- U moderních disků nemusí být známé mapování logických bloků na fyzické adresy
- Disku předáme skupinu požadavků a disk si pořadí optimalizuje sám
- OS přesto může mít zájem na vlastním řazení požadavků
  - priorita I/O operací z důvodu výpadků stránek
  - Pořadí operací zápisu dat a metadat souborového systému

Technologie RAID

- RAID: Redundant Arrays of Independent (Inexpensive) Disks
  - organizace disků řízená tak, že poskytuje objem jednoho disku
    - s velkou kapacitou a rychlostí díky tomu, že mnoho disků pracuje paralelně
    - s velkou spolehlivostí, data se uchovávají redundantně, lze je obnovit i po poruše některého z disků
- Pravděpodobnost, že některý disk z množiny N disků selže je mnohem vyšší, než pravděpodobnost, že selže jediný disk
  - N = 100 disků, každý má MTTF = 100 000 hodin (cca 11 let), celý systém bude mít MTTF = 1000 hodin (cca 41 dní)
  - techniky na bázi redundance chránící před ztrátou dat jsou pro systémy s velkým počtem komponent (disků) kritické
- Původní záměr
  - levná alternativa nahrazující velké drahé disky
  - „I“ je interpretováno jako „independent“

RAID: zvýšení spolehlivosti

- Redundance
  - nadbytečnost, doplňková informace použitelná pro obnovu informace po poruše (disku)
- Zrcadlení (stínování), Mirroring (shadowing)
  - každý disk je duplikován, 1 logický disk je tvořen 2 fyzickými disky
  - každý zápis se provede na obou discích, čte se z jednoho disku
  - jestliže se jeden disk porouchá, data jsou k dispozici na druhém disku
    - ke ztrátě dat dojde při výpadku obou disků, když zrcadlový disk selže dříve, než se systém opraví
  - průměrná doba do ztráty dat závisí na průměrné době do poruchy a průměrné doby opravy
    - Např. MTTF = 100 000 hodin, průměrná doba opravy 10 hodin, dává u zrcadlené dvojice disků průměrnou dobu ztráty dat $500*10^6$ hodin (čili 57 000 let), když budeme ignorovat požáry apod.

RAID: zvýšení výkonu

- Dva hlavní cíle paralelismu v diskových systémech
  - zvýšení propustnosti vyvážením zátěže malými přístupy
  - paralelizace velkých přístupů s cílem zkrácení doby odpovědi
- Zvýšení přenosové rychlosti paralelním zápisem do více disků (dělení, striping)
  - bit-level striping
    - dělení bitů každého bytu mezi samostatné disky
    - v poli 8 disků se zapisuje bit i každého bytu na disk i
    - čtení dat probíhá 8x rychleji než z jednoho disku
    - vystavení je delší než v případě jednoho disku
    - dnes se bit-level striping de facto už nepoužívá
  - blok-level striping
    - systém s n disky, blok souboru i se zapisuje na disk (i mod n) + 1
    - požadavky na různé bloky se mohou realizovat paralelně, jestliže bloky leží na různých discích
    - požadavek na dlouhou posloupnost bloků může použít všechny disky paralelně

Úrovně RAID, přehled

- RAID Level 0: Žádná redundance, jen souběžnost
- RAID Level 1: Spolehlivost dosažená zrcadlením disků
- RAID Level 2: Hamming code error correction
- RAID Level 3: 1 kontrolní disk na skupinu, dělení bitů
- RAID Level 4: Nezávislé operace read/write, dělení bloků
- RAID Level 5: Data/parity přes všechny disky (více souběžný přístup)
- RAID Level 6: Odolnost při více než jedné poruše disku

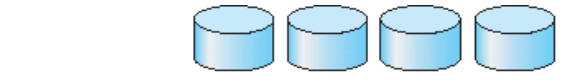

(a) RAID 0: non-redundant striping.

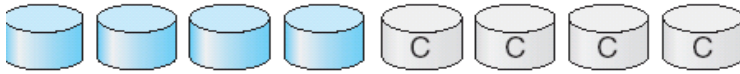

(b) RAID 1: mirrored disks.

(c) RAID 2: memory-style error-correcting codes.

(d) RAID 3: bit-interleaved parity.

(e) RAID 4: block-interleaved parity.

(f) RAID 5: block-interleaved distributed parity.

(g) RAID 6: P + Q redundancy.

API

- Většina OS pracuje s vyměnitelnými disky (např. disketami, ZIP disky) stejně jako s pevnými disky
  - nový svazek je formátován a na disku se generuje prázdný souborový systém
- Pásky
  - jsou prezentované jako „holé“ (*raw*) paměťové médium
  - aplikace na páskách nemají k dispozici souborový systém
  - otevírají celý páskový mechanismus jako zařízení
  - páskové mechanismy se vesměs nesdílejí, jsou dedikované konkrétní aplikaci
  - OS nepodporují na páskách souborové systémy, aplikace musí samy řešit jak používat bloky dat
    - pásku pak obvykle může používat pouze aplikace, pro kterou byla páska vytvářena (protože jako jediná zná strukturu dat na pásce)

Cena MB RAM (1981 – 2004)

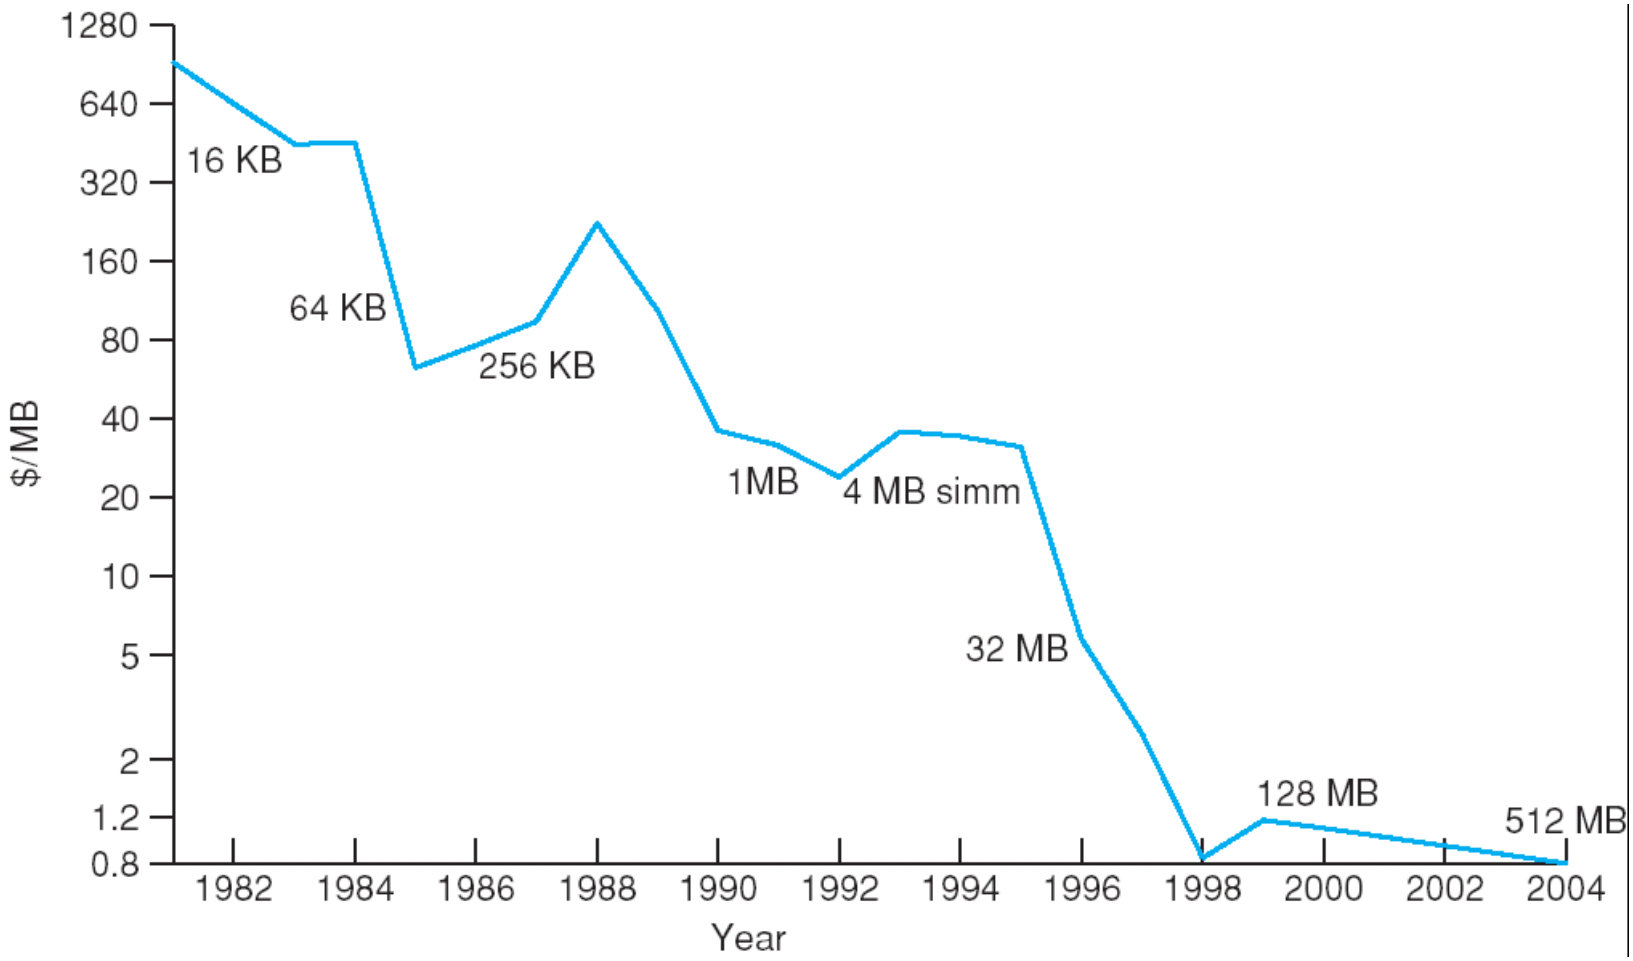

Dnes: asi $0.025/MB (4GB)

Cena MB pevných disků (1981 – 2004)

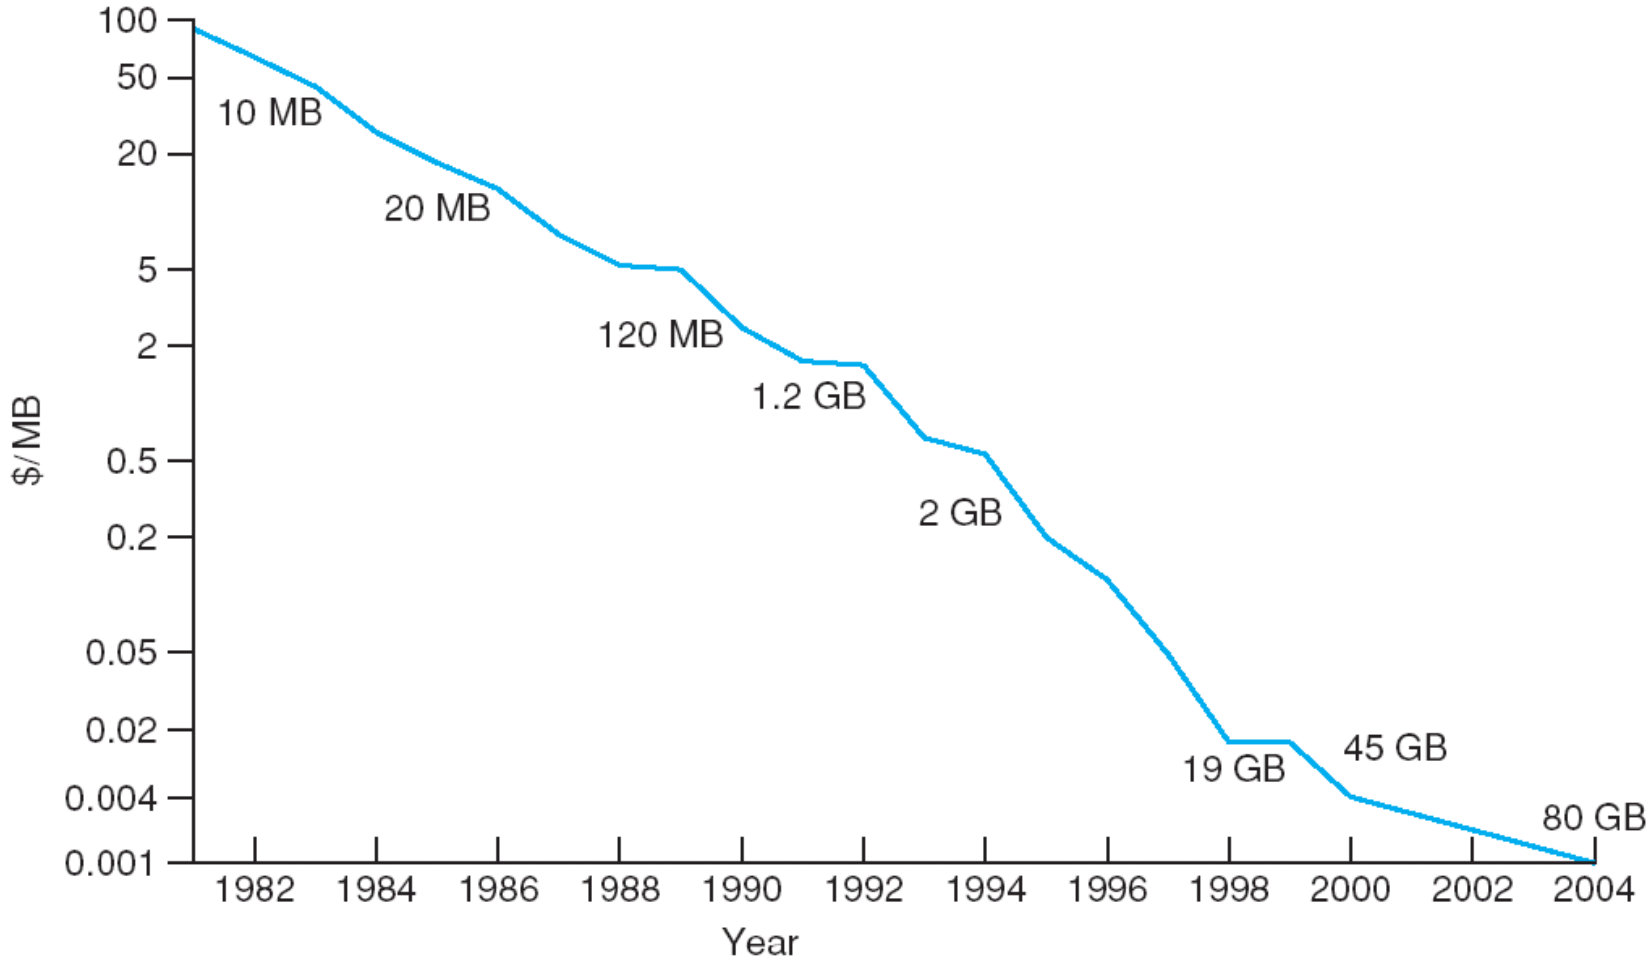

Dnes: asi 0,000125$/MB (1TB)

Cena MB pásek (1981 -2004)

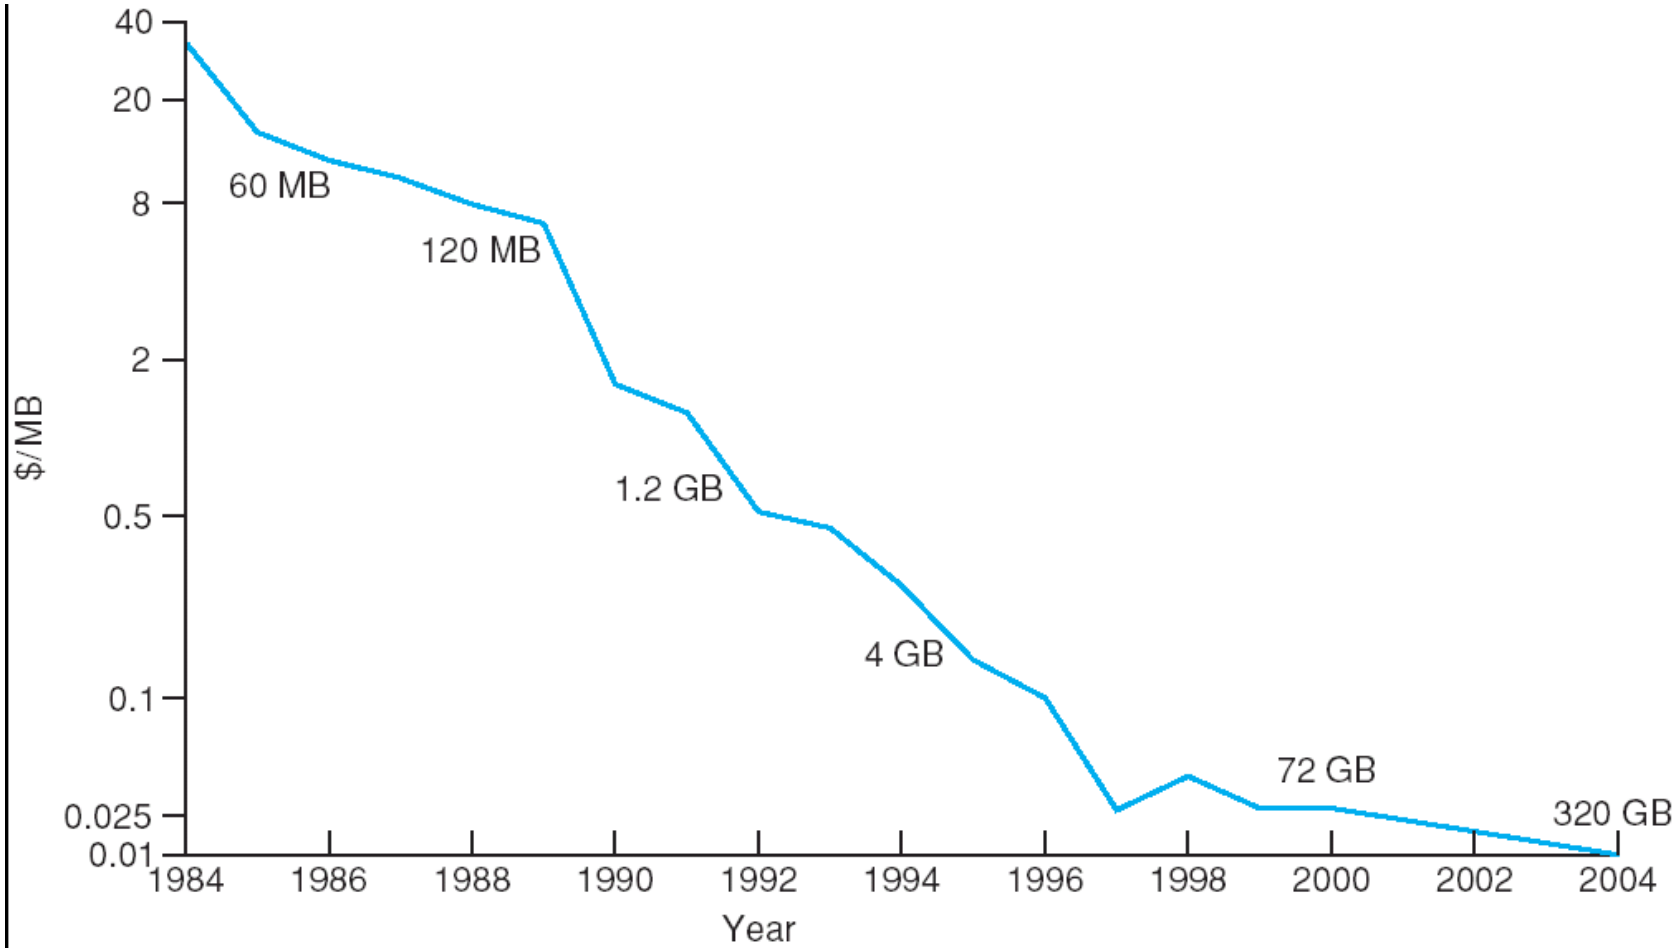

Dnes: asi 0,000125$/MB (0.8TB)