PB153
OPERAČNÍ SYSTÉMY A JEJICH ROZHRANÍ

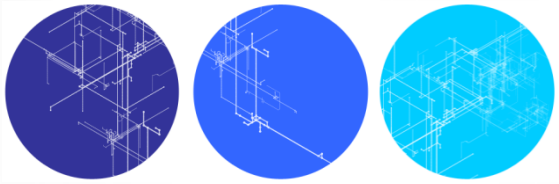

Vnější paměti

13

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

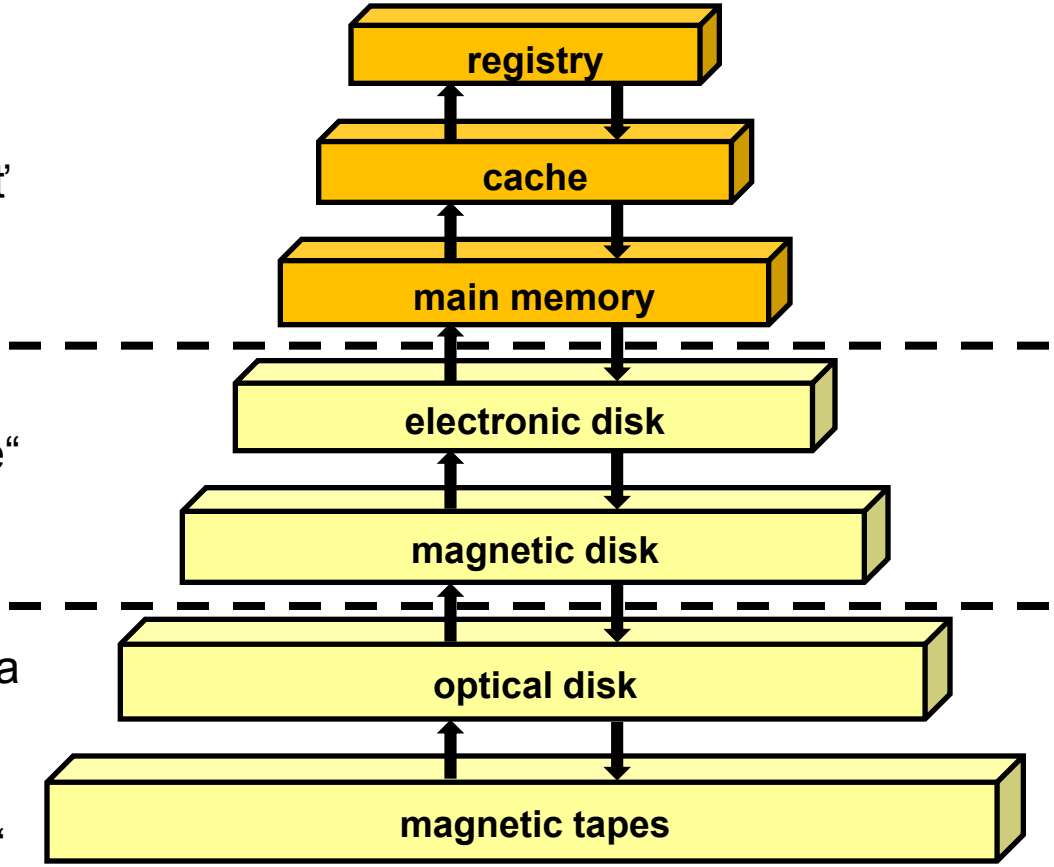

MAGNETICKÉ DISKY

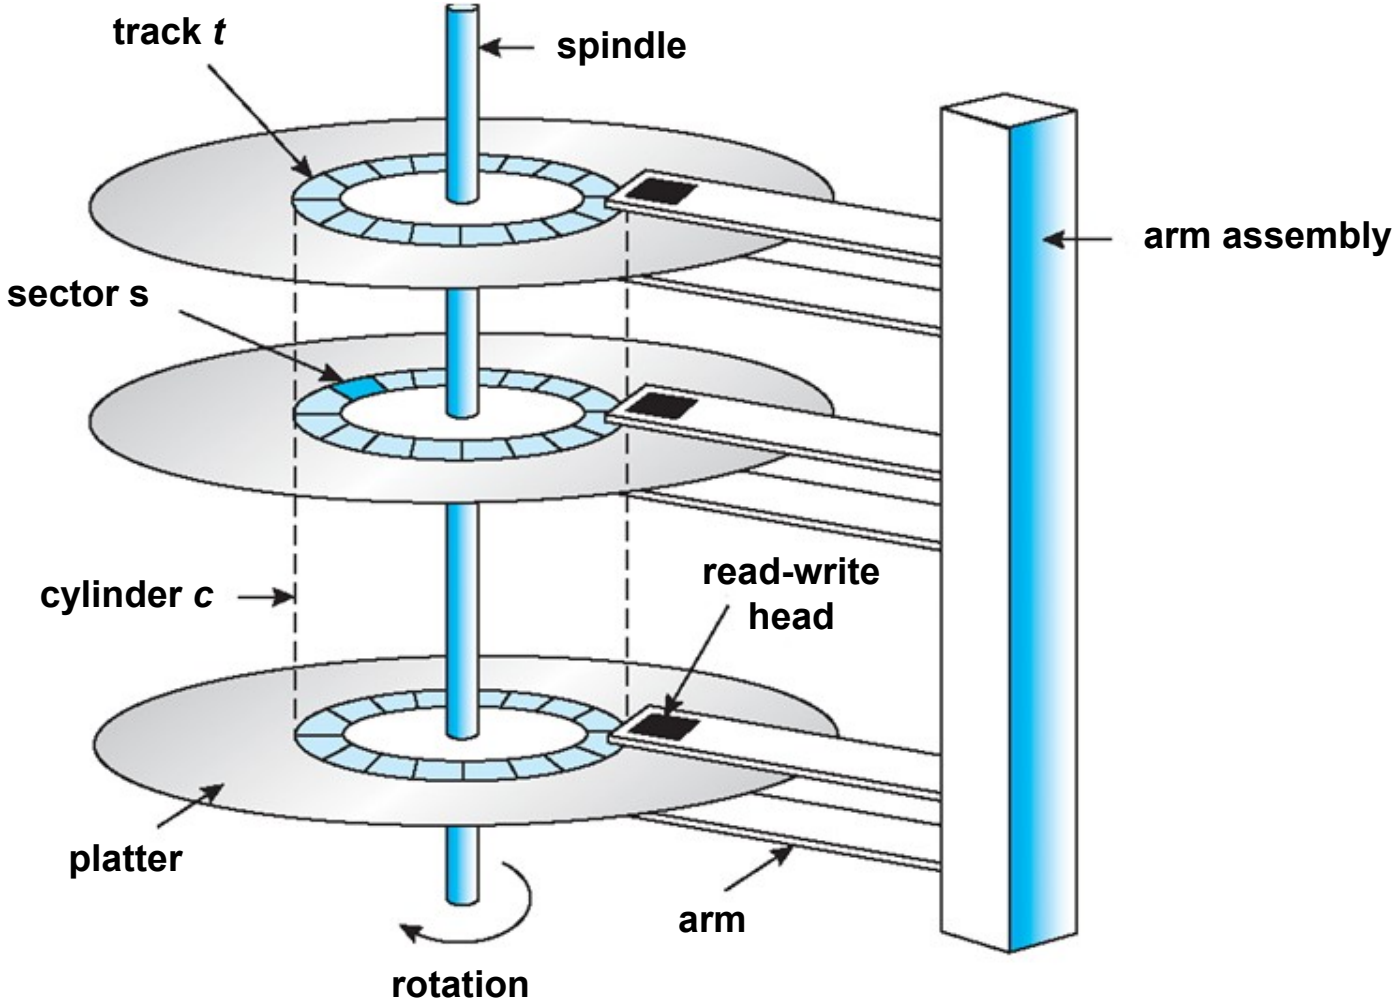

STRUKTURA DISKU

- 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.
  - „Disk scheduling“
- 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

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

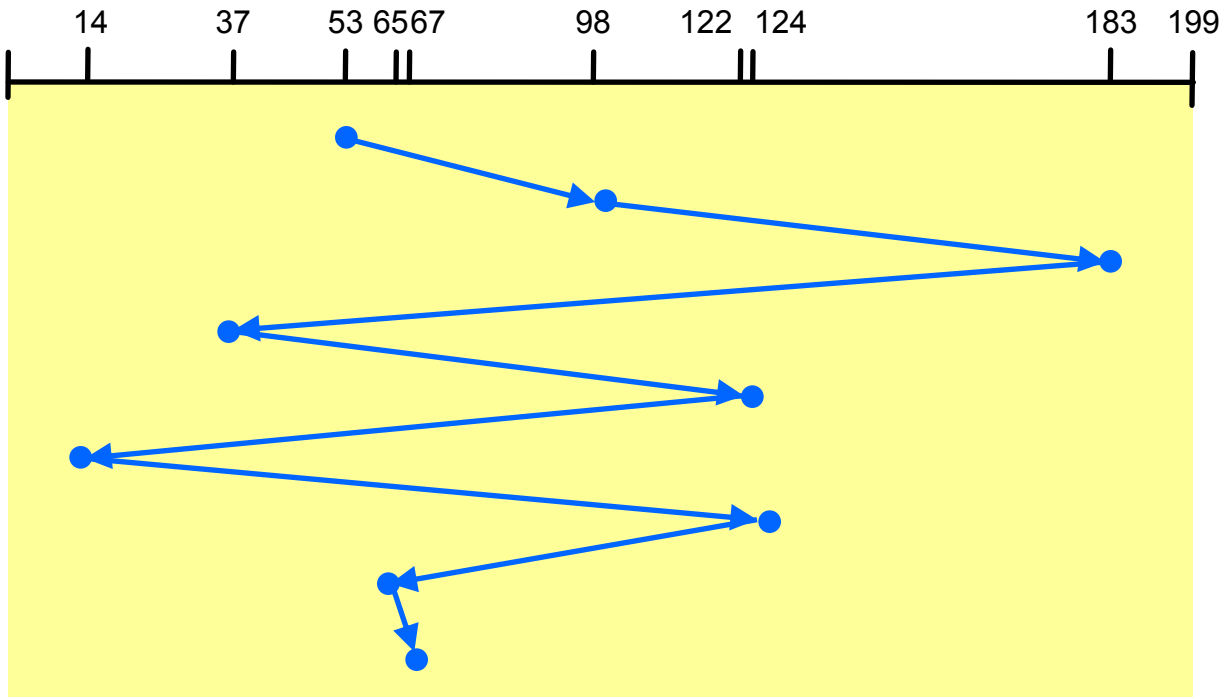

SSTF

- 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

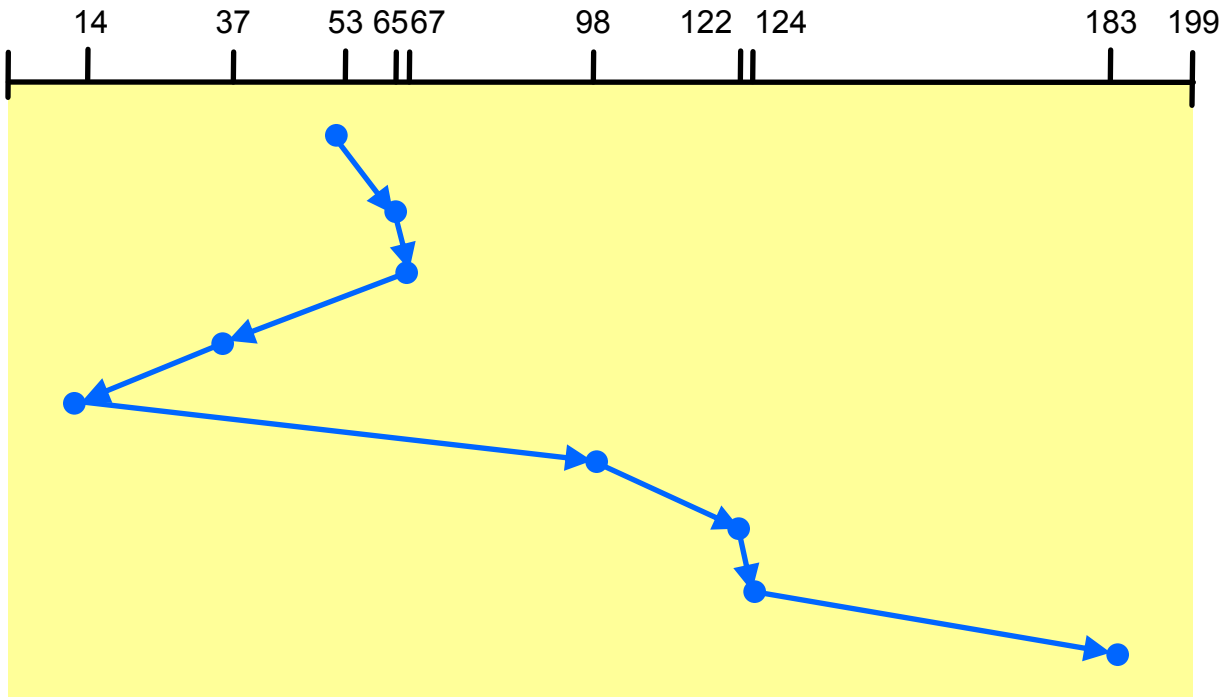

SCAN

- 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 (elevator)*.
- Náš příklad vyžaduje přesun o 208 cylindrů.

SCAN

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

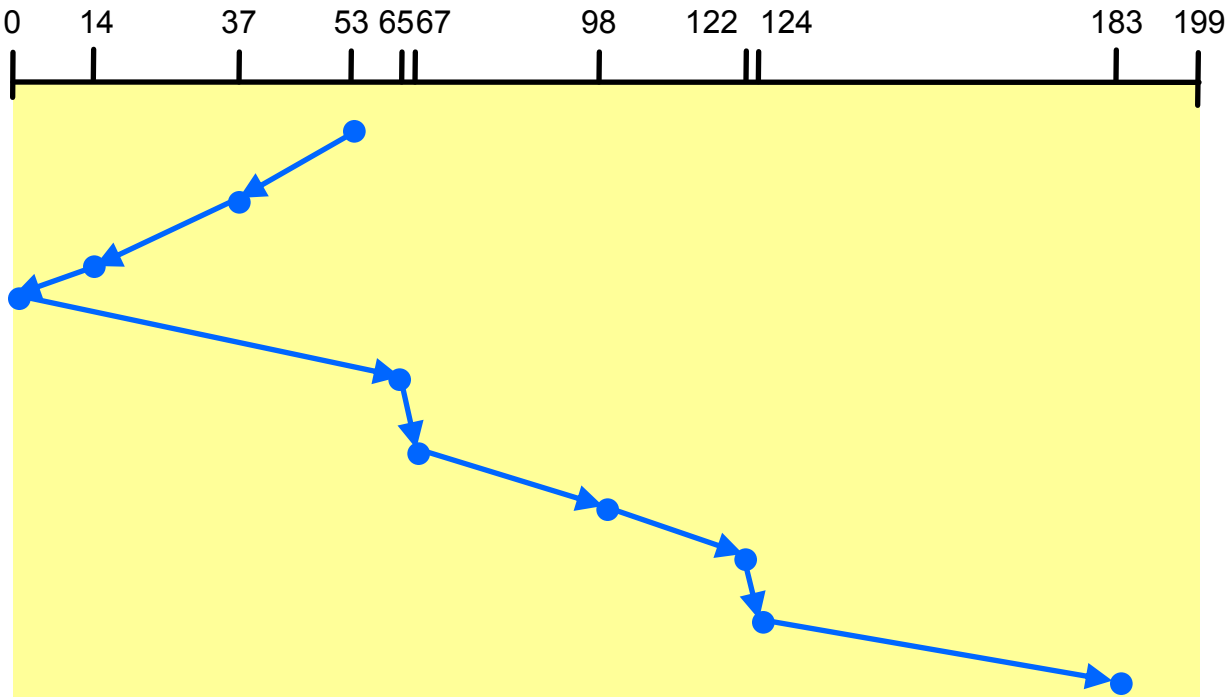

C-SCAN

- 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

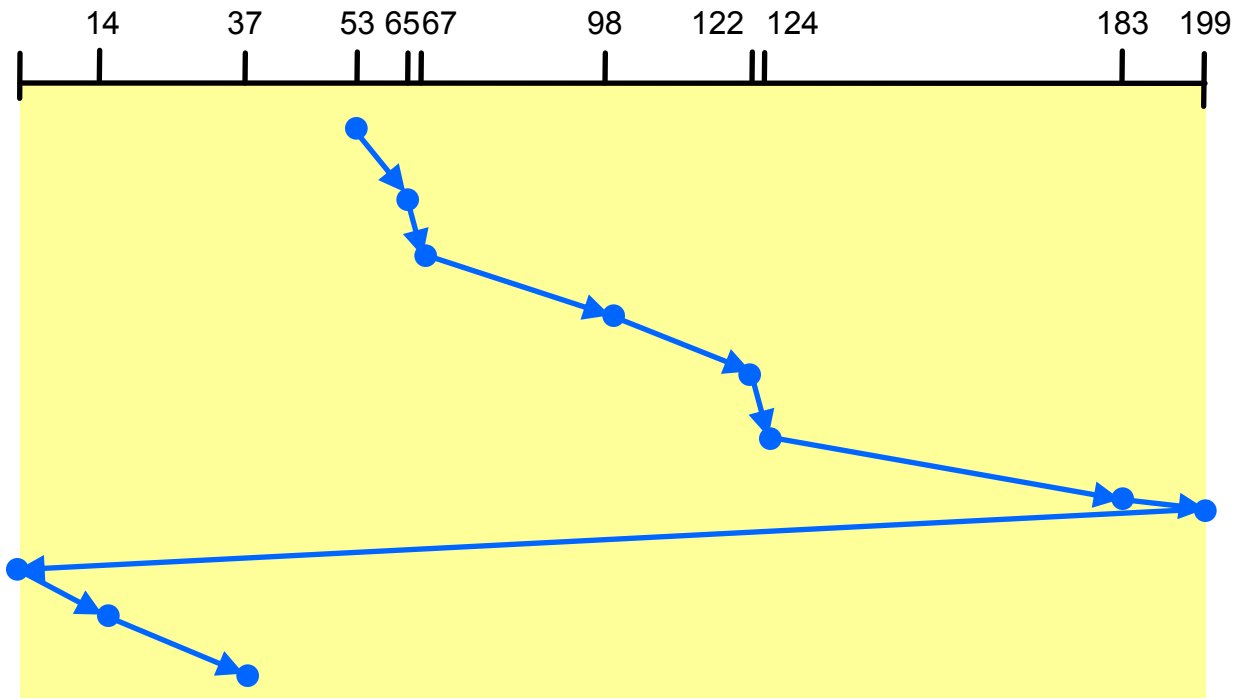

C-LOOK

- 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

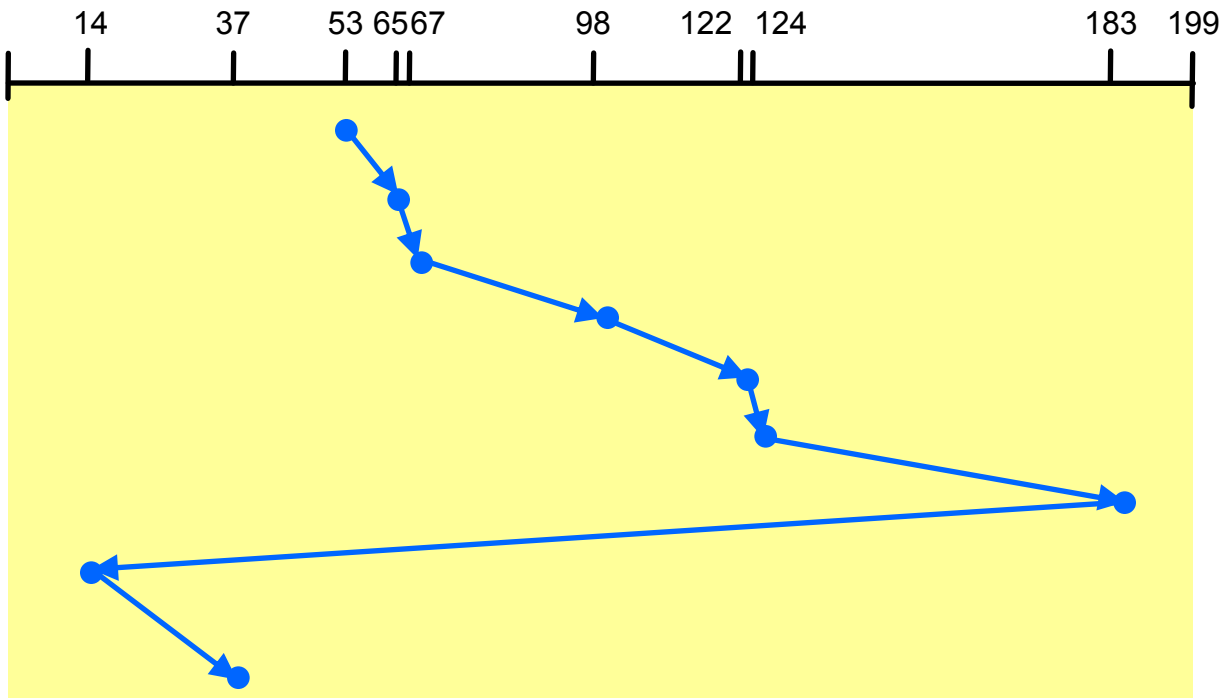

VÝBĚR ALGORITMU

- 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

PŘÍKLAD: LINUX

- K dispozici několik plánovacích algoritmů

```
# cat /sys/block/sda/queue/scheduler
noop anticipatory deadline [cfq]

# echo noop >/sys/block/sda/queue/scheduler
```

- Fronty v řadiči disku mohou měnit pořadí od OS
  - Fronta na desítky až stovky požadavků
- Algoritmy
  - Noop
  - Anticipatory
  - Deadline
  - CFQ (Completely Fair Queue)

NOOP

- Nemění pořadí požadavků
- Jen pokud nově příchozí navazuje na předchozí požadavek, požadavky budou sloučeny
  - To stejně obvykle řeší už vrstva blokového zařízení nebo vrstva souborového systému.

DEADLINE

- Vychází z algoritmu SCAN
- Přidává deadline (do kdy má být požadavek vyřízen)
- Po dávce požadavků se vzrůstajícími čísly sektorů (SCAN) kontroluje deadline
  - Pokud je třeba vytvoří speciální dávku pro vyřešení požadavků s expirovaným deadline.
- Upřednostňuje čtení před zápisem

ANTICIPATORY SCHEDULER (AS)

- Jako deadline, ale přidává očekávání, že při sekvenčním přístupu k souboru přijde po jednom požadavku brzy požadavek následující. Proto chvíli vyčká (opravdu) …
- Umožňuje i krátké přesuny zpět
  - Penalizuje dvojnásobnou vzdáleností
- Neodlišuje požadavky čtení a zápisu
- Odlišuje asynchronní požadavky od synchronních
- Neobjevuje se v linuxovém jádře od verze 2.6.33

COMPLETELY FAIR QUEUING

- Snaží se být spravedlivý k *procesům*
- Každý proces dostává určitý časový díl (slice) kdy má exkluzivní přístup pro synchronní požadavky
- Parametry
  - slice_sync – délka slice v ms (bere v úvahu I/O prioritu procesu)
  - quantum – počet požadavků
- 17 front (pro každou prioritu jedna) pro asynchronní požadavky
- Každá fronta získává určitý slice a fronty jsou obsluhovány algoritmem RR

CFQ PARAMETRY

Turnable	Defalt value	Purpose
back_seek_max	16384	(KiB) Max. backward seek
back_seek_penalty	2	reverse seek bias
fifo_expire_sync	125	(ms) deadline for synchronous requests
fifo_expire_async	250	(ms) deadline for asynch requests
quantum	4	Maximum requests to service in each batch in each round
slice_async	40	(ms) base time slise for asynch. requests
slice_sync	100	(ms) base time slise for synch. requests
slice_async_rq	2	base number of async requests per round
slice_idle	8	(ms) maximum idle time between requests

I/O PRIORITA PROCESŮ

- Příkaz ionice (od 2.6.13 pro CFQ)

```
NAME
       ionice - get/set program io scheduling class and priority

SYNOPSIS
       ionice [-c] [-n] [-p] [COMMAND [ARG...]]
```

Schedulling class	Number	Possible priority
real time	1	8 priority levels are defined denoting how big a time slice a given process will receive on each schedulling window.
best-effort	2	0–7, with lower number being higher priority
idle	3	Nil (does not také a priority argument)

RYCHLOST TERCIÁLNÍCH PAMĚTÍ

- Dva aspekty
  - šířka pásma, bandwidth
  - zpoždění, latency
- Šířka pásma se měří v B/s
  - podporovaná šířka pásma
    - průměrná rychlost přenosu dat během velkého přenosu
    - počet B / doba přenosu
  - efektivní šířka pásma
    - Průměr za celou dobu I/O operace, vč. vystavení, nalezení umístění, přepnutí svazku atd.

RYCHLOST TERCIÁLNÍCH PAMĚTÍ

- Zpoždění při přístupu
  - doba potřebná pro vyhledání dat
    - na disku – vystavení, natočení, určitě < 35 ms
    - na pásce – vč. přetočení pásky na požadovaný blok, desítky až stovky sekund
    - pásky jsou typicky 1000x pomalejší než disky
- Nízká cena terciární paměti je dána tím, že se pracuje s mnoha levnými svazky v malém počtu drahých mechanismů
- Vyměnitelná knihovna se nejlépe využije pro ukládání řídce používaných dat
  - uspokojuje se malý počet I/O požadavků

SPOLEHLIVOST

- Pevný disk je *asi* spolehlivější než vyměnitelný disk nebo páska
- Optický disk je *asi* spolehlivější než magnetický páska
- Padnutí hlav v pevném disku *obvykle* znamená zničení dat
- Porucha pásky nebo optického disku *obvykle* neznamená zničení všech dat

CENA

- Operační paměť je mnohem dražší než disková paměť
- Cena MB na pevném disku je srovnatelná s cenou MB na pásce (dříve pásky levnější)
- Kapacity magnetických pásek nedržely v posledních letech krok s nárůstem kapacit pevných disků
- Terciální paměť může ušetřit peníze pouze když se používá mnohem více svazků než mechanismů

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, PŘEHI

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

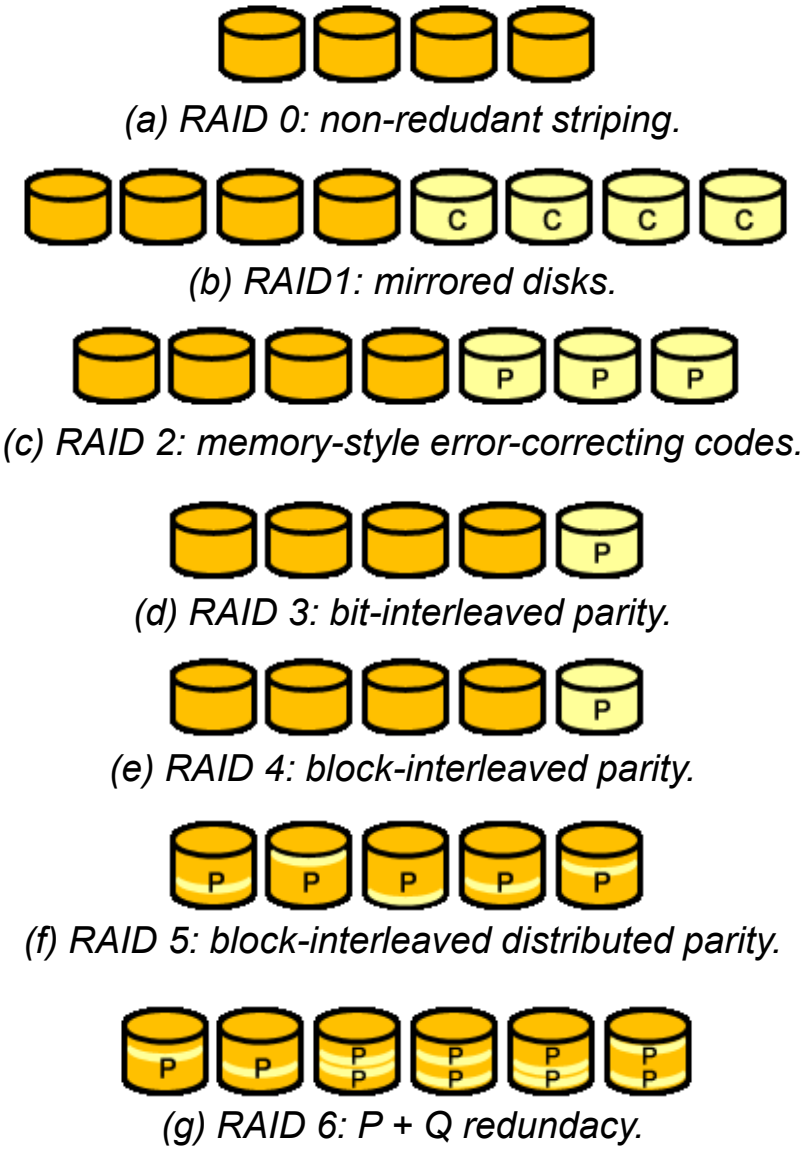

(a) RAID 0: non-redudant striping.

(b) RAID1: 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.

BĚŽNĚ POUŽÍVANÝ RAID

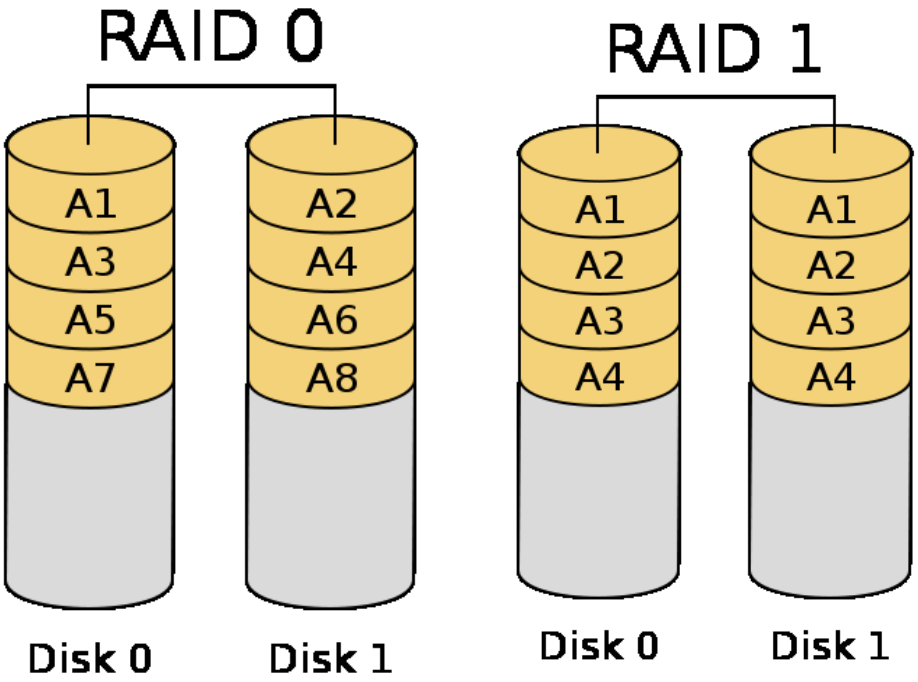

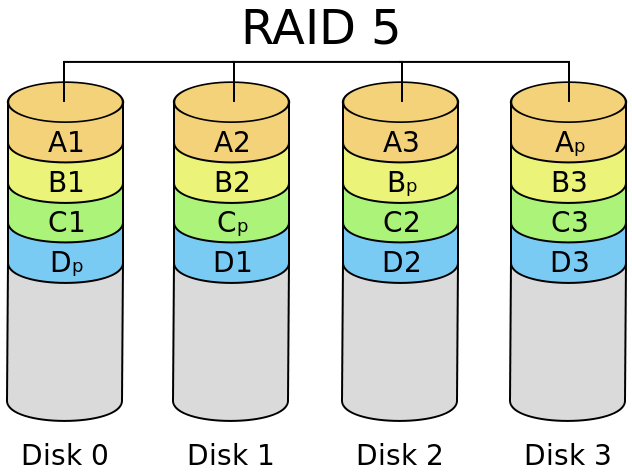

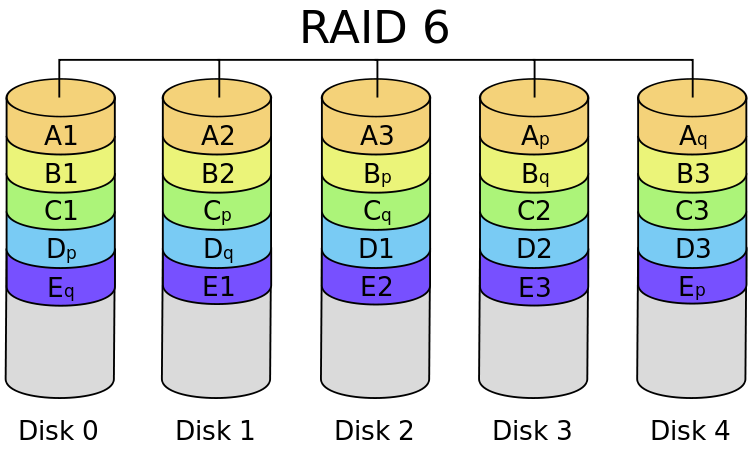

Zdroj: en.wikipedia.org

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)

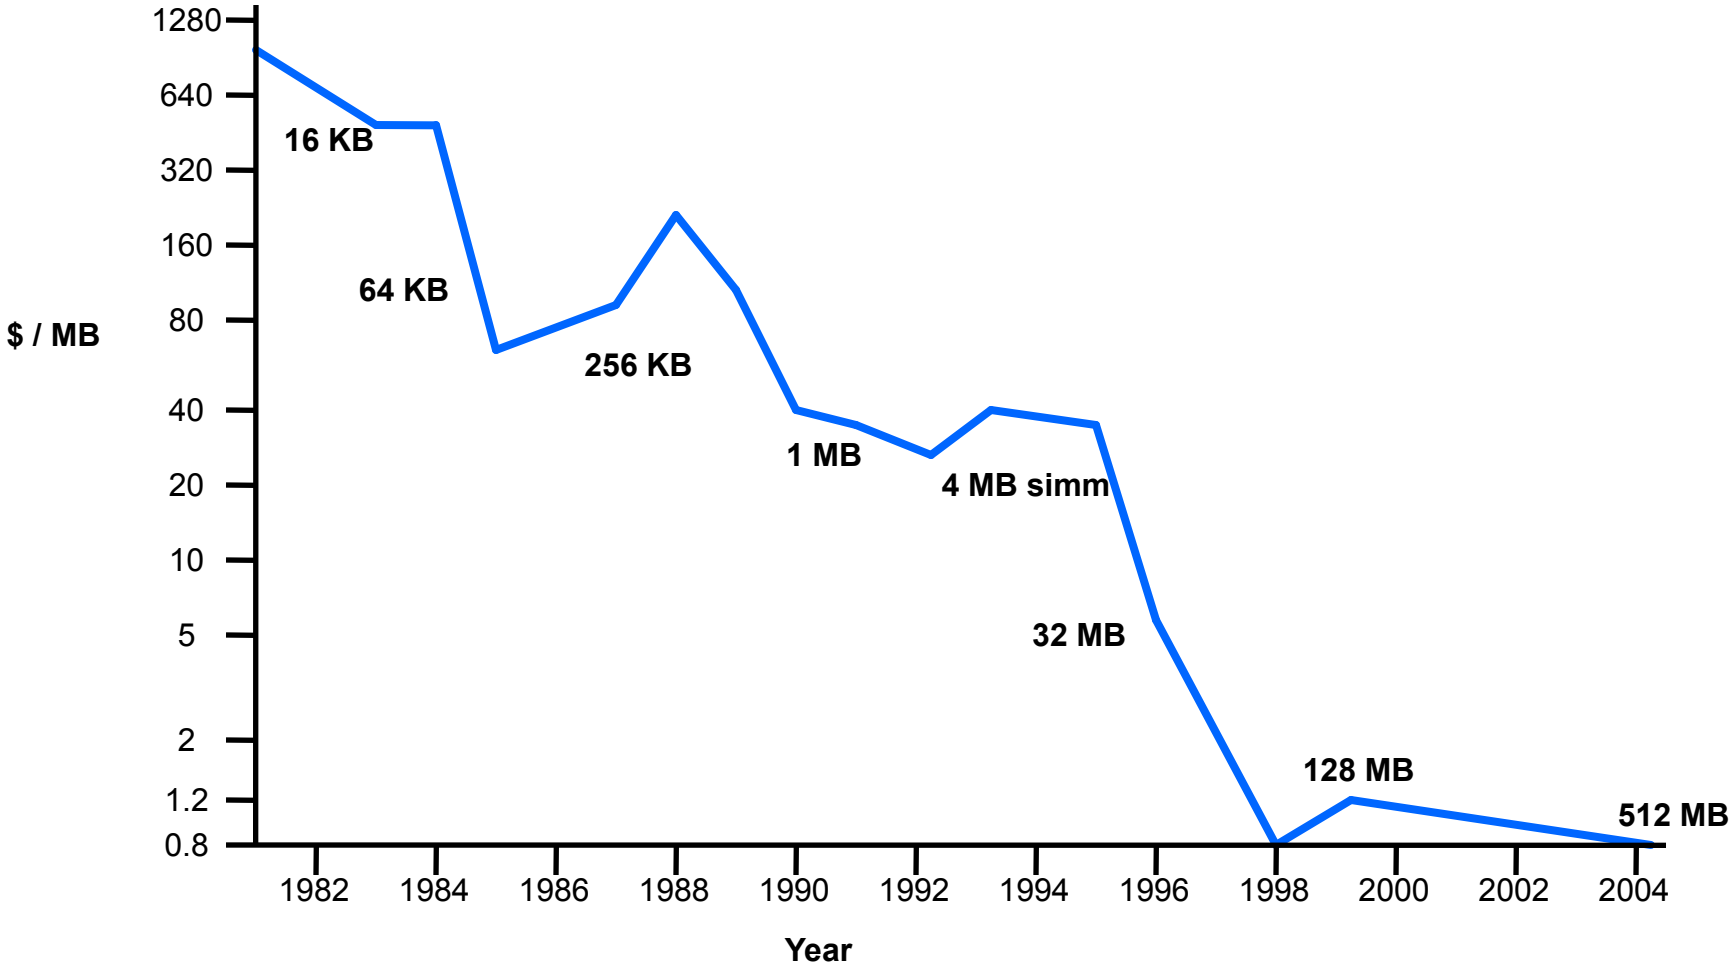

Dnes: asi $0.025/MB (4GB)

CENA MB PEVNÝCH DISKŮ (1981-2004)

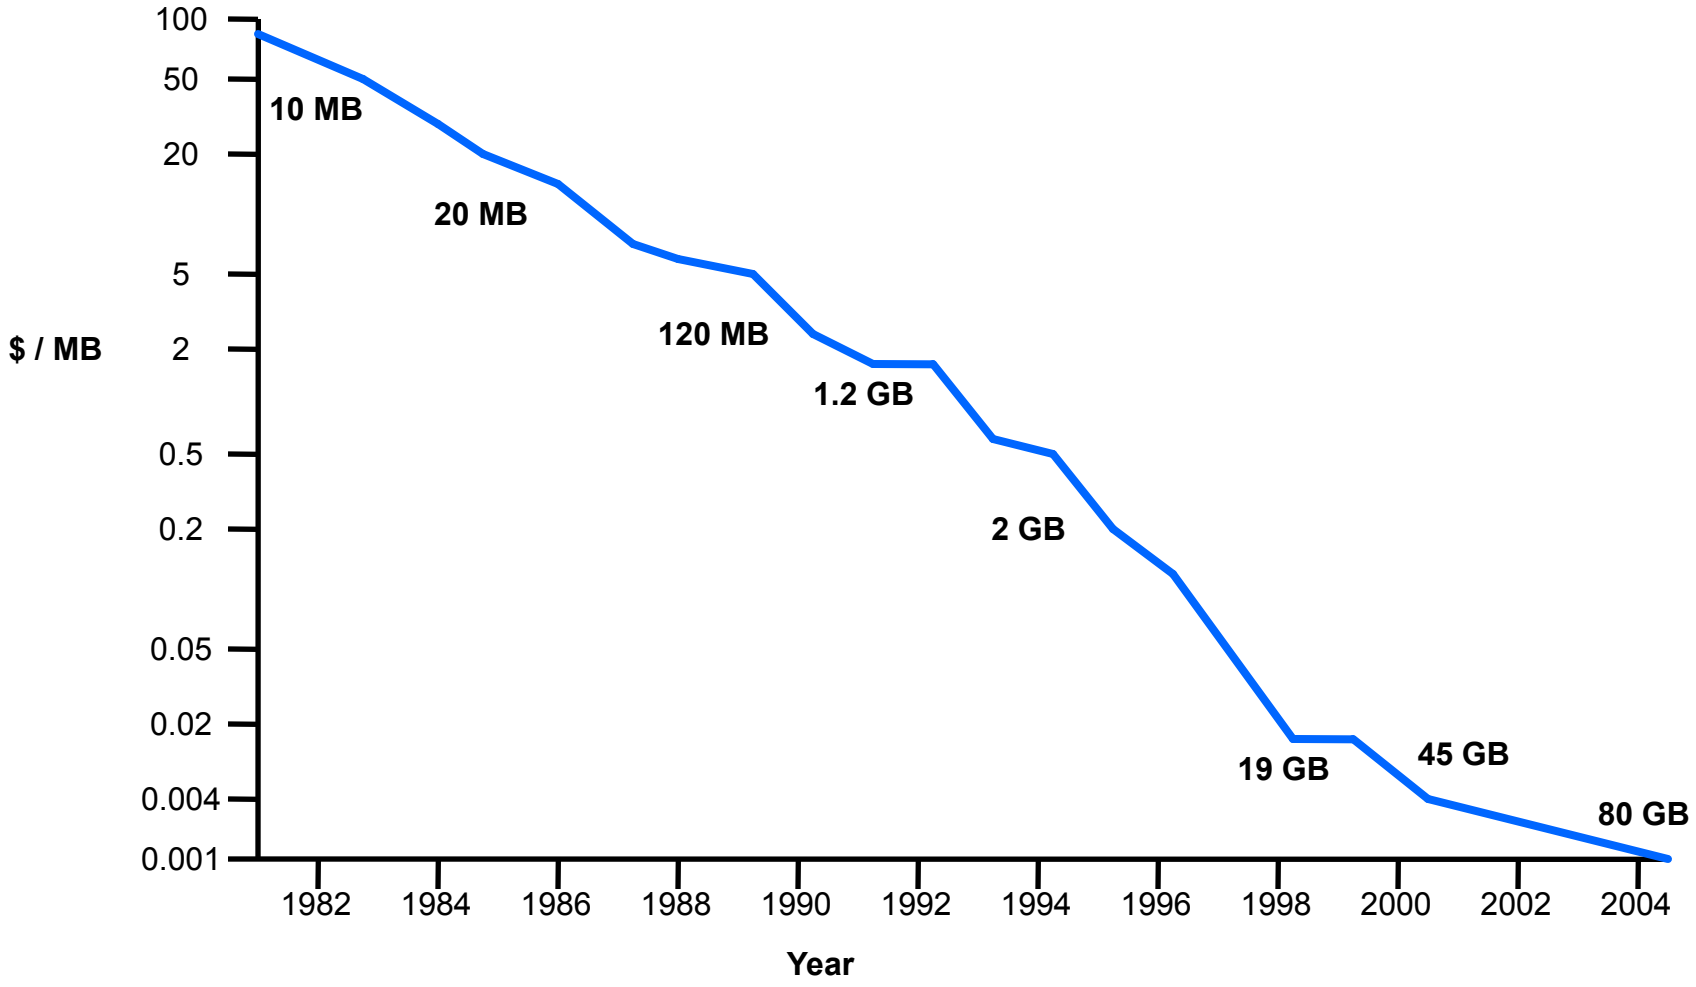

Dnes: asi 0,0001$/MB (1TB)

CENA MB PÁSEK (1981-2004)

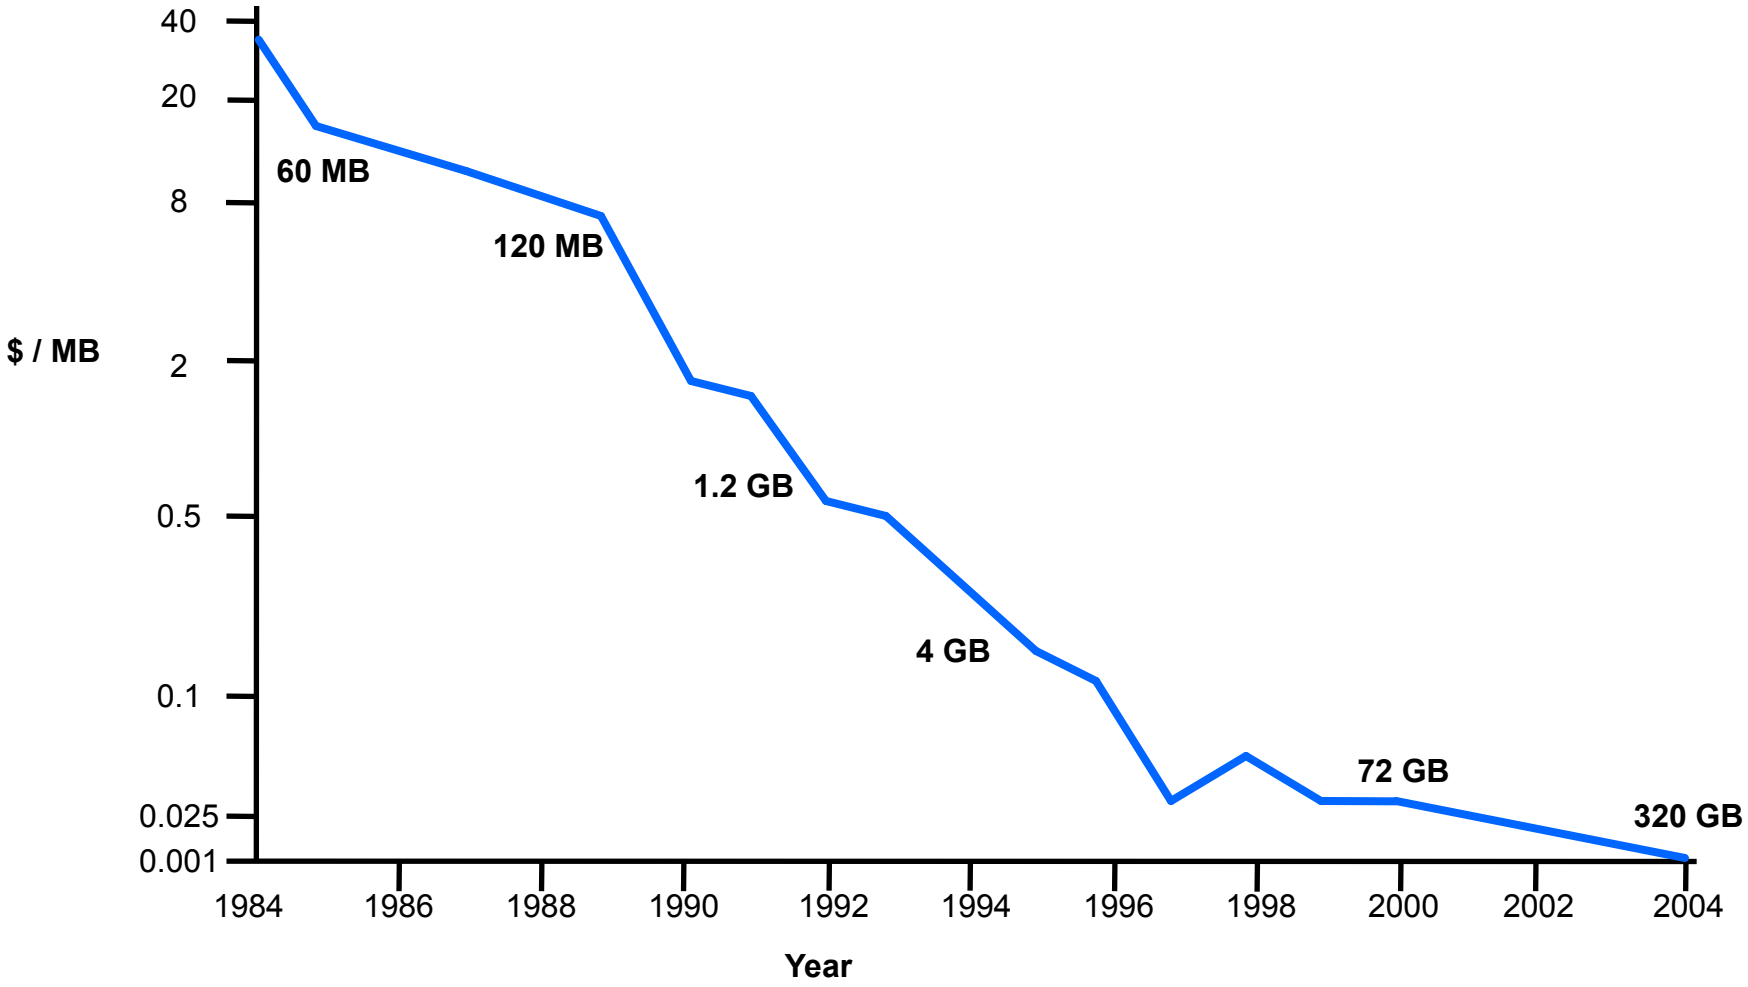

Dnes: asi 0,0001$/MB (0.8TB)

Výukovou pomůcku zpracovalo

Servisní středisko pro e-learning na MU

CZ.1.07/2.2.00/28.0041
Centrum interaktivních a multimediálních studijních opor pro inovaci výuky a efektivní učení

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ