



HÁLÓZATI RENDSZEREK
ÉS SZOLGÁLTATÁSOK
TANSZÉK



Budapest,
2025.02.20.

SZÁMÍTÓGÉP ARCHITEKTÚRÁK

Háttértárak

Horváth Gábor, Belső Zoltán


BME Hálózati Rendszerek és Szolgáltatások Tanszék
ghorvath@hit.bme.hu, belso@hit.bme.hu

- Minden számítógép részét képezik
- Teljesítményük a rendszer egészének teljesítményére kihat
- Fontos szerepet játszanak a virtuális tárkezelésben
- Amiről tanulunk:
 - HDD: **merevlemez alapú háttértárak**
 - SSD: **félvezető alapú háttértárak**
 - Van még más is:
 - Optikai lemezek: sok, a HDD-nél látott megoldás visszaköszön
 - Pen-drive: alapja ugyanaz a flash memória, ami az SSD-ben van
 - Stb.



Adattárolás merevlemezen (HDD)

- Részei:
 - Lemez(ek)
 - 1 vagy több adathordozó felület
 - Ezen tároljuk az adatot
→ mágneses elven
 - A fej
 - Olvassa/írja az adatokat
- Adatok elérése:
 - 1) A fejet a kívánt radiális távolságba toljuk
 - Ez a **seek**
 - 2) A lemezt a kívánt pozícióba forgatjuk
 - 3) Megtörténik az írás/olvasás
 - HDD → mágneses elven
 - CD/DVD/BR → optikai elven





- <https://youtu.be/3owqymMf6No>

- Domináns megoldás: fix méretű blokkok
→ **szektor** (tipikusan 512 bájt)
- Hivatkozás a szektorokra: lineáris címmel (0-tól)
 - **Logical Block Addressing (LBA)**
 - Leképzés a lemezek geometriájára → a diszk dolga


Szektorok elhelyezkedése:

- Merevlemezen:
 - Koncentrikus körökben
→ neve: **sáv**
 - Forgás: állandó szögsebességgel
CAV: Constant Angular Velocity
- Optikai lemezek:
 - Spirálisan
 - Forgás: állandó lineáris sebességgel a spirál mentén
CLV: Constant Linear Velocity




- **Ha a sávonkénti szektorok száma fix** az egész diszkre:
 - Minden szektort ugyanannyi ideig tart elolvasni
 - A belső szektorokban nagyobb az adatsűrűség → a külsőkben pazarló
- **Ha az adatsűrűség fix** az egész diszkre:
 - Kifelé haladva minden sávban egyre több szektor lesz
 - Külső sávok felé haladva egyre gyorsabban kell olvasni
 - Sávonként olvasási sebességet váltani → nem megoldható
- Arany középút: nem váltunk sebességet minden sávban, csak zónánként
→ **zóna rendszerű adattárolás (ZBR, Zoned Bit Recording)**
 - Egy zónán belül minden sávban ugyanannyi szektor van
 - Egy zónán belül fix az adatleolvasási sebesség


ZBR nélkül:



ZBR-rel:



- Szeretnénk egy szektorsorozatot átvinni
 - A kérés a kiszolgálása előtt egy bufferbe kerül, ott várja a sorát
 - Régen: op. rendszer menedzselte
 - Ma: diszk menedzseli → **command queueing**
 - A számára kényelmes (és gyors) sorrendben szolgálja ki őket



Kiszolgálás érkezési sorrendben


Kiszolgálási sorrend optimalizálása

- **Kiszolgálási idő**

- 5 komponensből áll:

- Példa:

- Forgási sebesség: 10.000 fordulat/perc
- Átlag seek idő: 4.5 ms,
- Parancsfeldolgozási késleltetés: 0.3 ms
- A keresett sávban legyen 600 db 512 bájtos szektor
- Illesztőfelület sebessége legyen 100 MB/s
- Mennyi ideig tart egy 4 kB-os adatátvitel?
 - Forgási késleltetés: 1 fordulat: 6 ms.
→ Véletlen időpontban átlag 3 ms-ot kell várni, hogy a keresett adat fölé kerüljön a fej
 - Adat leolvasása: 4 kB = 8 szektor. 1 szektor átvitele: $6 \text{ ms} / 600 = 0.01 \text{ ms}$.
 - Adat átvitele az illesztőfelületen: átlapolható!
Leolvasási idő + az utolsó szektor átvitele: $512 \text{ bájt} / 100 \text{ MB/s} = 0.005 \text{ ms}$
 - Összesen: $0.3 + 4.5 + 3 + 0.08 + 0.005 = 7.885 \text{ ms}$
- A forgási és a seek idő dominál!
- **Érdemes sok adatot egyszerre átvinni!** Seek és forgási idő csak egyszer adódik hozzá!



- **Átviteli sebesség (throughput)**

- Kétféle megadás:
 - Kérések számában mérve: IOPS: [kiszolgált kérések száma/sec]
 - Adatsebességben mérve: IOPS x átlag átvitt adatmennyiség [byte/sec]
- Kis blokkmérettel mérve: **véletlen átviteli sebesség**
 - Seek idő, forgási késleltetés dominál
- Nagy, folytonos blokkméretekkel mérve: **folytonos átviteli sebesség**
 - Az adatleolvasási idő dominál



- Példa:

- Véletlen (4 kB blokkméret):
 - Előbb kijött: 7.885 ms/kérés $\rightarrow$ 126.823 IOPS/s $\approx$ 0.52 MB/s
 $\rightarrow$ Nagyon lassú!
- Folytonos (16 MB blokkméret):
 - Előbbihez hasonlóan: 335.485 ms/kérés $\rightarrow$ 2.98 IOPS/s $\approx$ 50 MB/s
 $\rightarrow$ Sokkal gyorsabb!




Félvezető alapú háttértárak (SSD)

- Flash memória alapja a lebegő gate-es tranzisztor
 - A lebegő gate-be elektronok zárhatók
 - Benne is maradnak (táp nélkül)
 - Megváltoztatják a tranzisztor viselkedését
- Adatok reprezentálása:
 - Egy tranzisztor 1 bitet tárol (egyelőre)
 - Vannak elektronok: **0**, nincsenek: **1**
- Váltás 1-ből 0-ba: **programozás**
 - Elektronokat tömünk a lebegő gate-be
- Váltás 0-ból 1-be: **törlés**
 - Kiszivattyúzzuk az elektronokat a lebegő gate-ből
- Mindkét művelet nagy stresszt jelent a tranzisztornak!
- A programozás és törlés mellékhatása:**
 - A lebegő gate-be és onnan ki mászkáló elektronok beragadhatnak a szigetelőbe (örökre)
 - A szigetelőréteg egyre kevésbé fog szigetelni
 - Öregedés!**



- Eddig 2 töltöttségi állapot volt: nincs töltés $\rightarrow$ 1, van $\rightarrow$ 0
- Miért ne használnánk több töltöttségi szintet?
 - **N bit tárolásához 2^N töltöttségi szintet kell megkülönböztetni**
 - SLC flash: 1 tranzisztor $\rightarrow$ 1 bit
 - MLC flash: 1 tranzisztor $\rightarrow$ több (tipikusan 2) bit
 - Újabban a gyártók máshogy értelmezik az MLC-t:
 - SLC: $N=1$ – leggyorsabb, legdrágább
 - MLC: $N=2$
 - TLC: $N=3$
 - QLC: $N=4$ – leglassabb, legolcsóbb
- Minél nagyobb N , annál gyorsabban öregszik! Elviselt törlési ciklusok száma:
 - SLC: kb. 100.000
 - MLC: kb. 10.000
 - TLC: kb. 1.000 – 3.000
 - QLC: kb. 100 – 750 (!)
 - Példa: Intel SSD 670p 1TB, QLC, 144 rétegű, TBW = 320TB (Terabytes Written)

- A tranzisztorokat 2D rácsba rendezzük
- De hogyan?
- **NOR flash:**
 - Byte szinten címezhető
 - Utasításmemóriaként használható (BIOS, firmware, stb.)
- **NAND flash:**
 - Kezdetektől fogva háttértárnak szánták
 - Olvasás és írás egységei: **lapok**
 - Lap: a tárolómező egy sorának bitjei
 - Az egész tárolómező neve: **blokk**
 - **Törölni csak teljes blokkot lehet, lapokat egyesével nem**
 - Tárolási hierarchia:
 - 1 lebegő gate-es tranzisztor: 1 – 3 bitet tárol
 - 1 lap: 512 byte – 8 kB
 - 1 blokk: 128 – 256 lap
 - 1 tárolósík: 1024 blokk
 - 1 szilíciumlapka: 1 – 4 tárolósík
 - 1 tok: 1 – 4 szilíciumlapka



Az Intel 8 GB-os 2-bites MLC NAND flash lapkája


- **Olvasás**

- LBA címéből → fizikai elhelyezkedés, kiolvasás, kész.


- **Írás**

- HDD-nél: Ha egy fájlt többször mentünk, HDD felülírja a régit
- SSD-nél: Nem tud lapot felülírni!!!
- Minden új változatot új, szűz helyre tesz, a régit érvénytelennek jelöli
- Új szűz lapok generálása: ha egy teljes blokkon már nincs hasznos adat, törli (akár 2 MB!)
- Minden laphoz állapotot tárol:
 - „Használt”
 - „Érvénytelen”
 - „Törölt”


- Minden írási művelet az **írási front**ra vonatkozik
- Ha az írási front megtelik, újat választ a törölt blokkok közül
- Példa: írási kérések a 8, 12, 1 LBA címekre




- Minden írási művelet az **írási front**ra vonatkozik
- Ha az írási front megtelik, újat választ a törölt blokkok közül
- Példa: írási kérések a 8, 12, 1 LBA címekre



- Minden írási művelet az **írási front**ra vonatkozik
- Ha az írási front megtelik, újat választ a törölt blokkok közül
- Példa: írási kérések a 8, 12, 1 LBA címekre




- Minden írási művelet az **írási front**ra vonatkozik
- Ha az írási front megtelik, újat választ a törölt blokkok közül
- Példa: írási kérések a 8, 12, 1 LBA címekre



- Ha fogynak törölt blokkok → **szemétgyűjtés**

- Kinéz egy blokkot
- „Használt” lapjait → írási frontra
- Törli az egész blokkot


- Példa:



- Ha fogynak törölt blokkok → **szemétygyűjtés**

- Kinéz egy blokkot
- „Használt” lapjait → írási frontra
- Törli az egész blokkot

- Példa:




- A működés következménye:
 - **Az SSD idővel lassul!**
 - Mert amikor új, nem kell szemetet gyűjtenie
- Korszerű SSD-k megoldása:
 - *Ráérő idejükben szemetet gyűjtögetnek*
 - Csínján kell bánni a lapok rendezgetésével – koptatja az SSD-t!
 - Csak akkor megy, ha van ráérő idő. Ha nincs (pl. terhelt szerver), drasztikus a lassulás.
 - *Kopás-kiegyenlítés*
 - Minden blokk egyformán kopjon (statikus és változékony egyaránt)
 - *Adattömörítés*
 - Ha az adatokat tömörítjük, kevesebbet kell írni (lassul az öregedés)
 - *Több írási kérés bevárása*
 - Hátha jön 1-2 kérés, ami ugyanarra a lapra vonatkozik
 - Ezek egyetlen írási művelettel végrehajthatók
- Működés következménye: *Többletírás*
 - A meghajtó többet ír, és **jobban kopik**, mint amennyit mi kezdeményezünk!!!




Tárolótömbök

- SLED: Single Large Expensive Disk – Nagy tárolókapacitás, drágán
- Ötlet: Használjunk sok, olcsó diszket, és vonjuk őket össze logikailag!
- Probléma: hibatűrés
 - MTTF: Mean Time To Failure
 - Pl. Ha 1 diszkre MTTF = 100.000 óra, akkor 100 diszkes tömbre $100.000/100 = 1000$ óra
 - Azaz: átlagosan 1000 óránként meghibásodik egy diszk
- Megoldás: redundancia
 - Legyen kisebb a hasznos kapacitás, mint a teljes → a különbségből a hibatűrést javítjuk
- Ez a RAID – Redundant Array of { Inexpensive | Independent } Disks
- A redundancia mikéntje alapján:
 - **RAID 0**, **RAID 1**, **RAID 2**, **RAID 3**, **RAID 4**, **RAID 5**, **RAID 6**
 - Ezek kombinációi: RAID 10, RAID 0+1



- RAID 0: a diszkek összefogása a kapacitás növelése érdekében, redundancia nélkül
- ...de nem akárhogy: striping
 - Blokkok felváltva a diszkek között
- Előnyök:
 - Nagy tárolókapacitás
(felkínált kapacitás = diszkek kapacitásának összege)
 - Nagy átviteli sebesség – terhelés megoszlik a diszkek között
 - Egyszerű megvalósítás
- Hátrányok:
 - Alacsony rendelkezésre állás (MTTF)
 - Már 1 diszk hibája is katasztrofális





- RAID 1: adatok tükrözése több diszken
- Előnyök:
 - Olvasási műveletek: N-szeres átviteli sebesség
 - Írási műveletek: mint 1 diszk (nem gyorsabb)
 - Egyszerű
- Hátrányok:
 - Nagy (N-szeres) overhead
→ N diszkkapacitás = 1 felkínált kapacitás




- RAID 0+1 és RAID 1+0 (=10)
- RAID 1+0 jobb, mert meghibásodáskor csak a RAID 1 rész érintett




- Tükrözés túl pazarló
- Vannak jó hibajavító kódok (lásd: információelmélet)
- PI. Hamming kód ilyen
 - PI. (7, 4) kódolással 4 bites üzeneteből 7 bit lesz, bármelyik bit kijavítható
 - Ennél kisebb overhead is elérhető
 - RAID-2 alapja
 - de nincs kereskedelmi implementáció
- Paritásbit:
 - Nem alkalmas hibajavításra, csak 1 hiba jelzésére
 - Hacsak nem tudjuk a hiba helyét!
 - Mert akkor a paritásbit 1 hibát javítani is tud
 - Márpedig a diszkek szólnak, ha sikertelen egy művelet
- RAID-3 és 4
 - Dedikált paritásdiszk (szűk keresztmetszet)
 - Különböző adataegységek



- RAID 5: hibajavítás paritásbittel
- N blokknyi adatot N+1 diszken tároljuk → a +1 a paritás
- Hibajavítás:
 - Tudható, ha egy diszk meghibásodik
 - Az összes blokk visszaállítható a többi diszkről
 - Akár a paritás sérült, akár bármely másik
- Előnyök:
 - Paritásinformáció eloszlik a diszkek között
 - Nem egy diszket terhel → szűk keresztmetszet lenne
 - Olvasási műveletek: nagy átviteli sebesség
 - N diszk dolgozik párhuzamosan
- Hátrányok:
 - Komplex hardveres implementáció
 - Adatok felülírása: lassabb
 - Felülírunk – minden diszket olvassuk – paritást számolunk – paritást írunk
 - Visszaállítás közbeni újabb hiba ellen nem véd
 - Márpedig nagy diszkek esetén valós veszély



- RAID 6: mint RAID-5, de két paritásbittel
- N blokknyi adatot N+2 diszken tároljuk → a +2 a paritás
- Előnyök:
 - Olvasási műveletek: nagy átviteli sebesség (diszkek párhuzamos elérése)
 - Két diszk meghibásodása ellen is véd
 - Visszaállítás alatt is lesz védelem
- Hátrányok:
 - Nagyobb overhead
 - Felülírás: még lassabb (lásd: RAID-5)
 - Komplexitás



- Áramkimaradás írás közben
 - RAID Write Hole Effect: Inkonzisztens állapot – nem helyreállítható a tömb
 - Hardveres RAID vezérlő megoldása:
 - Írási cache akkumulátorral védve
- Hot Swap
 - Diszk csere a rendszer leállítása nélkül
- Hot Spare
 - Bekötött tartalék diszk a RAID tömbben
 - Hiba esetén azonnal indul a helyreállítás
 - Nem kell megvárni az operátort



HÁLÓZATI RENDSZEREK
ÉS SZOLGÁLTATÁSOK
TANSZÉK

