Memória és perifériák virtualizációja

Kovács Ákos

Forrás, BME-VIK

Virtualizációs technológiák

https://www.vik.bme.hu/kepzes/targyak/VIMIAV89/

Emlékeztető: A három virtualizációs lehetőség

- **Virtualizáció –** az utasításokat (egy részüket) változatlanul hagyja végrehajtani, csak a problémás privilegizáltakkal kell valamit kezdeni
  - **Szoftveres virtualizáció** (Trap & emulate + bináris fordítás)
  - **Paravirtualizáció** (módosítjuk a vendég OS forrását)
  - **Hardveres virtualizáció** (Trap & emulate, teljesen hardveres támogatással)

Tartalom

- Előző rész tartalmából:
  - CPU virtualizáció
  - A három alap virtualizációs megközelítés
- Memória virtualizáció
  - **Virtuális memória az operációs rendszerekben**
  - Virtuális memória a platform virtualizációban
  - Virtuális memóriakezelés speciális képességei: megosztás, késleltetett allokáció, memória-ballon
- Perifériák virtualizációja
  - Perifériák programozói felülete általában
  - Periféria virtualizációs architektúrák

Virtuális memóriakezelés

- Modern CPU-k tartalmaznak memóriakezelő egységet (MMU – *memory management unit*)
  - Feladata „virtuális” memóriacímeket leképezni „fizikaira”
  - Mi is az a virtuális memóriacím? Hol használható?
  - CPU felhasználói (pl. ring 1-3) módjaiban virtuális címekkel dolgozik (nem feltétlenül, de a modern OS-eknél ez igaz)
  - A folyamatok nem a fizikai memóriacímeket látják
    - Cél: áthelyezhető legyen az oprendszer felett futó alkalmazások kódja, ne csak fix bedrótozott helyen tudjon futni (akár szoftveresen is megoldható lenne…)
    - Cél2: eközben a teljesítmény ne romoljon számottevően (ehhez már hardver támogatás is kell)

Virtuális memóriakezelés

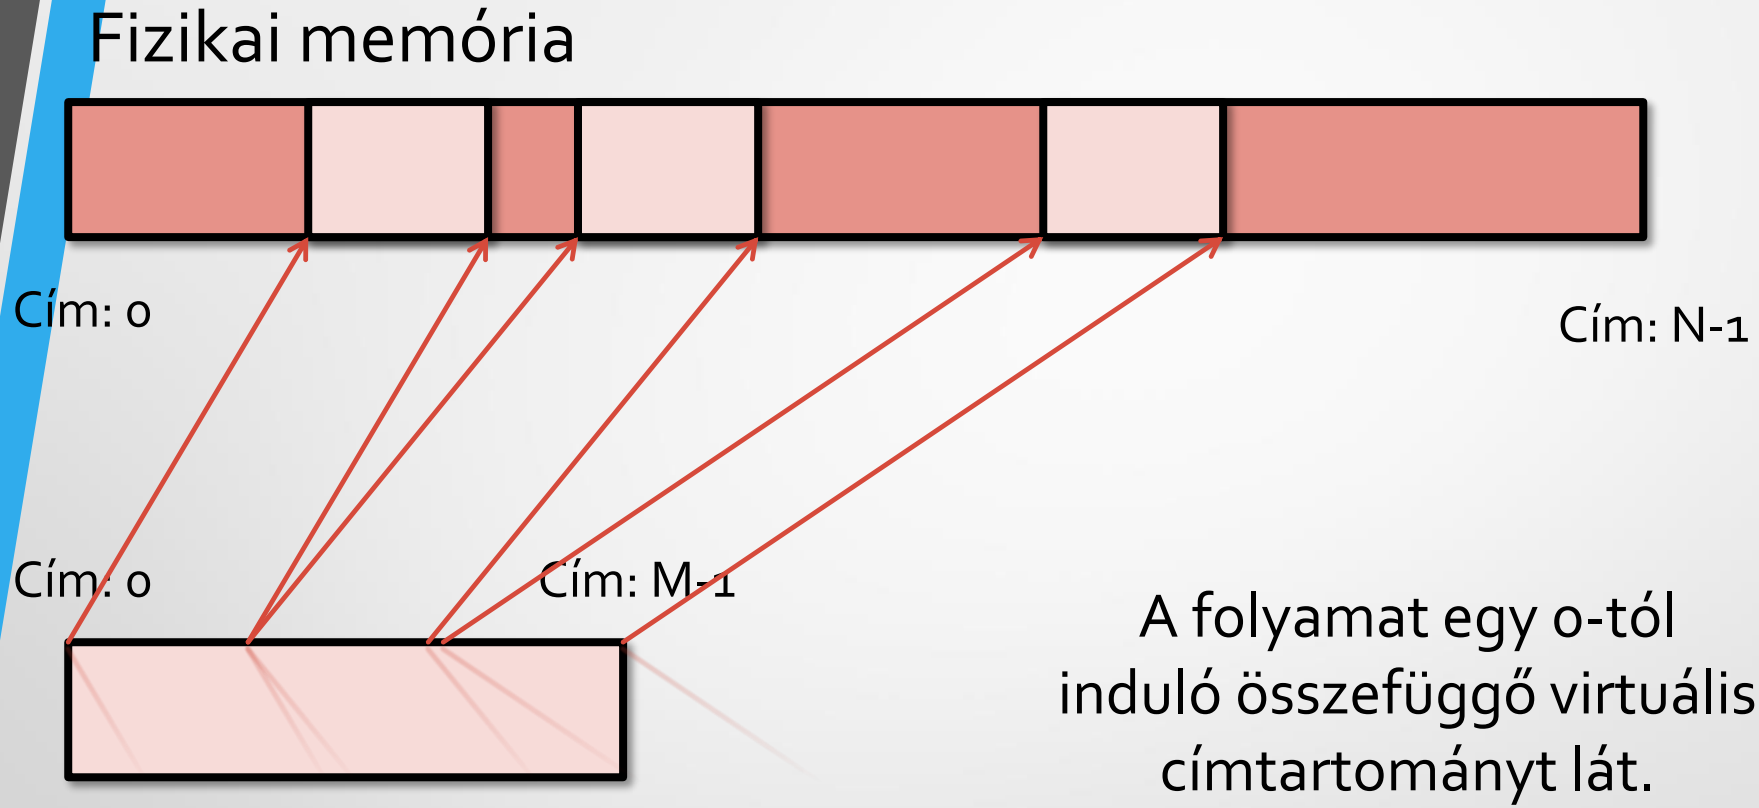

A folyamat egy 0-tól induló összefüggő virtuális címtartományt lát.
Tehát minden pointer a virtuális címtartományban értelmezett.

Virtuális memóriakezelés

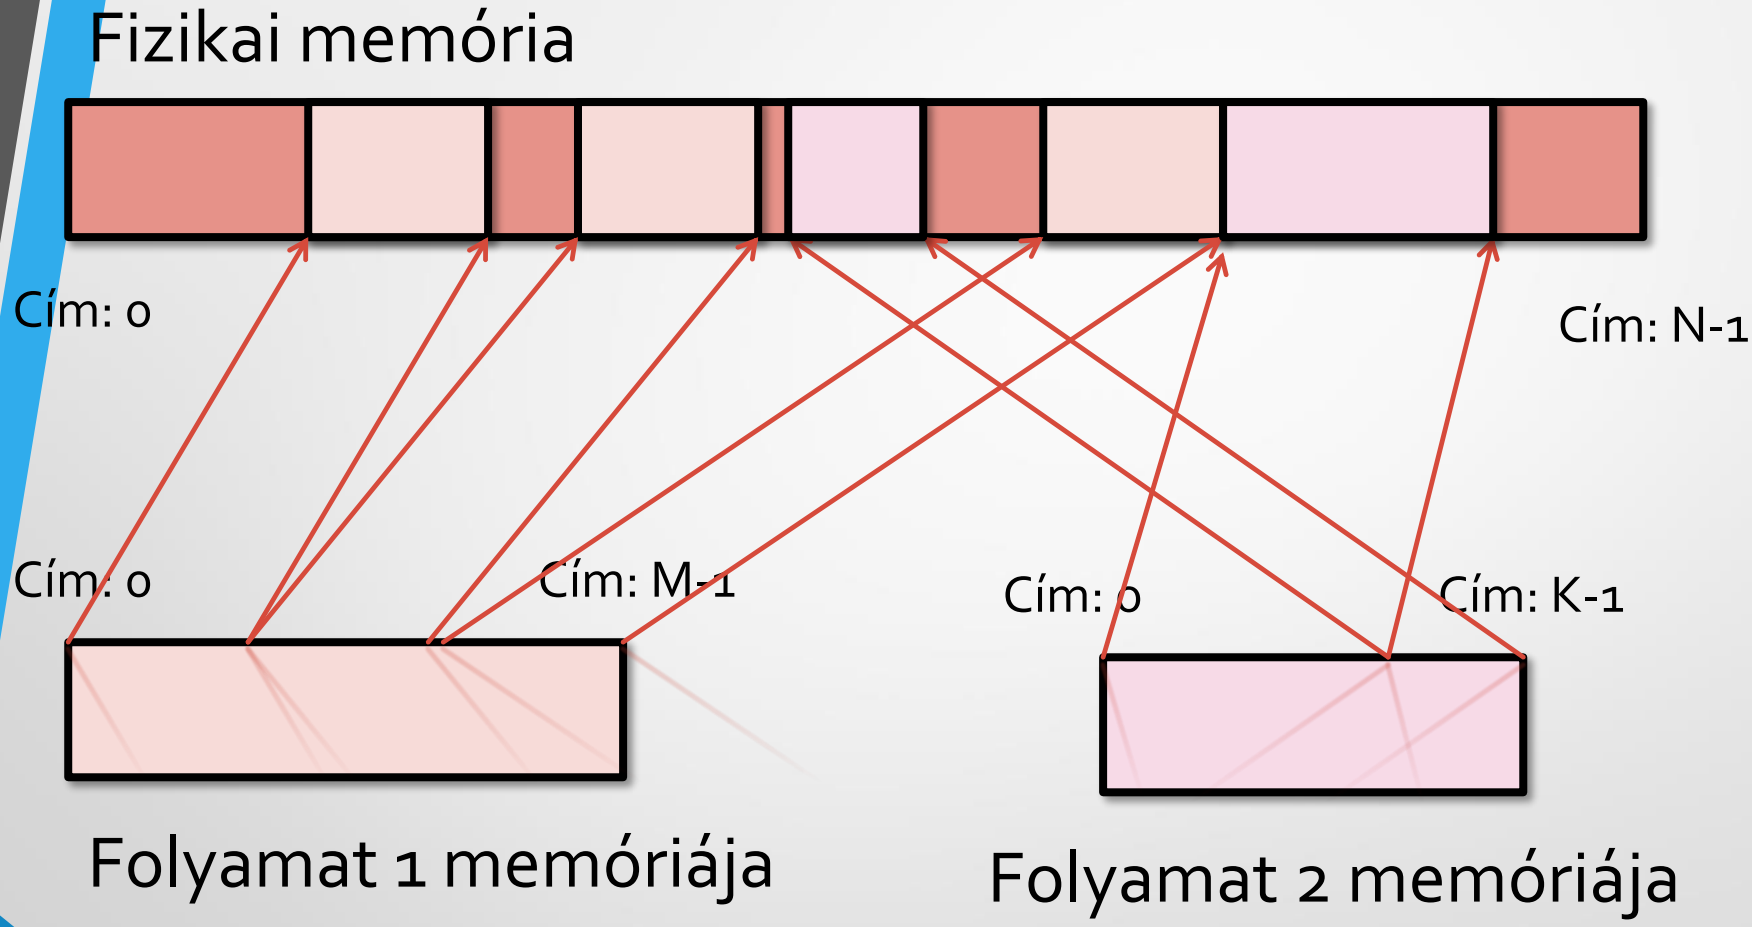

Ez minden folyamatra igaz

Virtuális memória megvalósítása lapokkal

- Memória **lapok** (*pages*)
  - Virtuális → fizikai memória cím hozzárendelés
  - Tipikusan (x86) 4 kB méretű allokációs egységekben
  - A cím utolsó 12 bitje a lapon belüli cím
  - A cím első 20 bitje kétszintű (10-10 bit) laptábla cím
    - Létezik óriás lap üzemmód is, ilyenkor csak egyszintű laptábla van, ezen belül 22 bit (4MB) pozíciócím

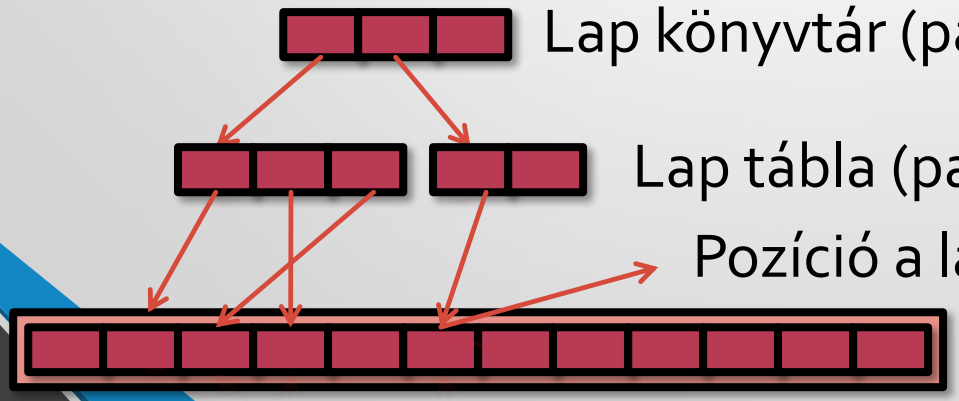

Virtuális memória megvalósítása lapokkal

További jellegzetességek:

- A laptáblák is a fizikai memóriában foglalnak helyet
- Csak az operációs rendszer kernel módosíthatja őket
- Minden folyamathoz másik táblakészlet tartozik, a kernel kontextus váltáskor cseréli ki mindig a megfelelőre
- Az MMU a CPU laptábla regisztere alapján tudja, hogy hol kell keresni legfelső szintű lap könyvtárat
- Automatikusan feloldja a virtuális címeket fizikaira, a virtuális címeket használó kód módosítás nélkül fut
- A virtuális címtartományból kicímzés vagy read-only bittel jelölt lapra írás hibát (fault) vált ki a CPU-ban

Tartalom

- Előző rész tartalmából:
  - CPU virtualizáció
  - A három alap virtualizációs megközelítés
- Memória virtualizáció
  - Virtuális memória az operációs rendszerekben
  - **Virtuális memória a platform virtualizációban**
  - Virtuális memóriakezelés speciális képességei: megosztás, késleltetett allokáció, memória-ballon
- Perifériák virtualizációja
  - Perifériák programozói felülete általában
  - Periféria virtualizációs architektúrák

Memória virtualizálása

- A Ring 0-tól eltérő futó folyamatok virtuális memóriát látnak
  - A virtuális -> fizikszintekenai cím feloldása hardverben történik laptáblák alapján. Gyors, TLB cache-eli fizikai-virtuális cím hozzárendelést.
- Használhatjuk-e ezt a vendég gépek memóriájához?
  - Több szint kell: a VM-ben is kell saját laptábla a saját alkalmazásokhoz
  - De a CPU ilyet nem támogat

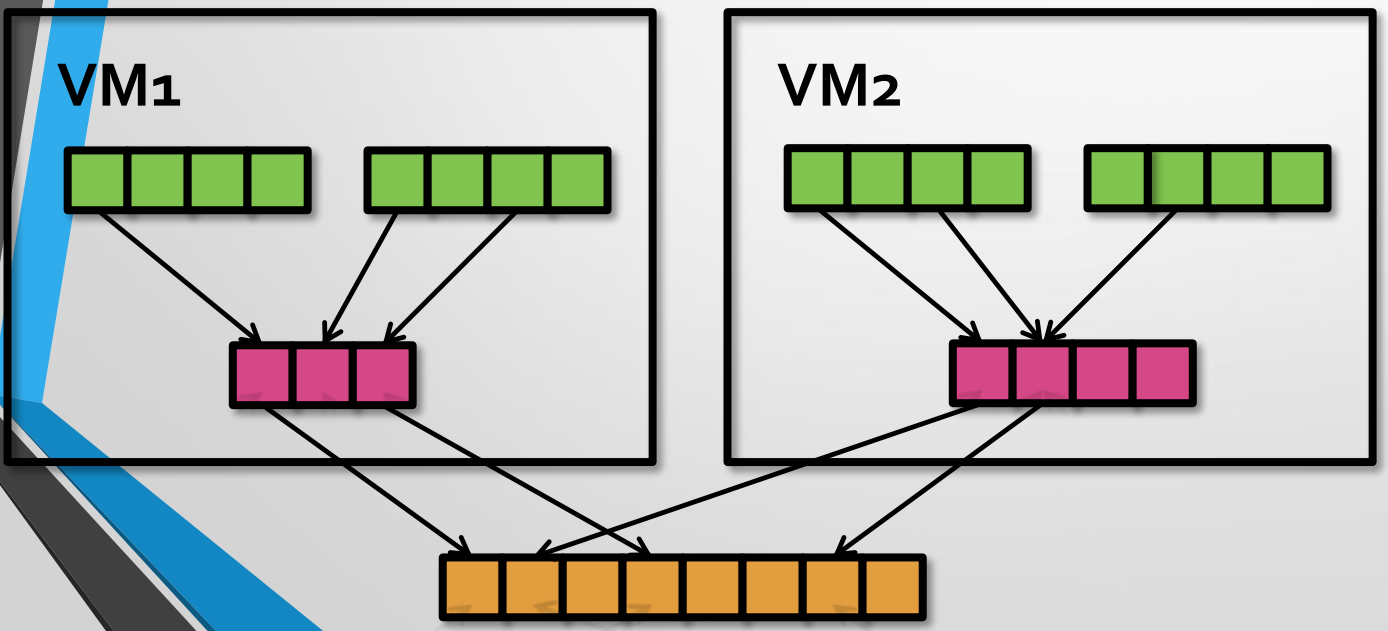

Vendég: virtuális memória

Vendég: „fizikai” memória

Gazda: fizikai memória

Memória virtualizálása

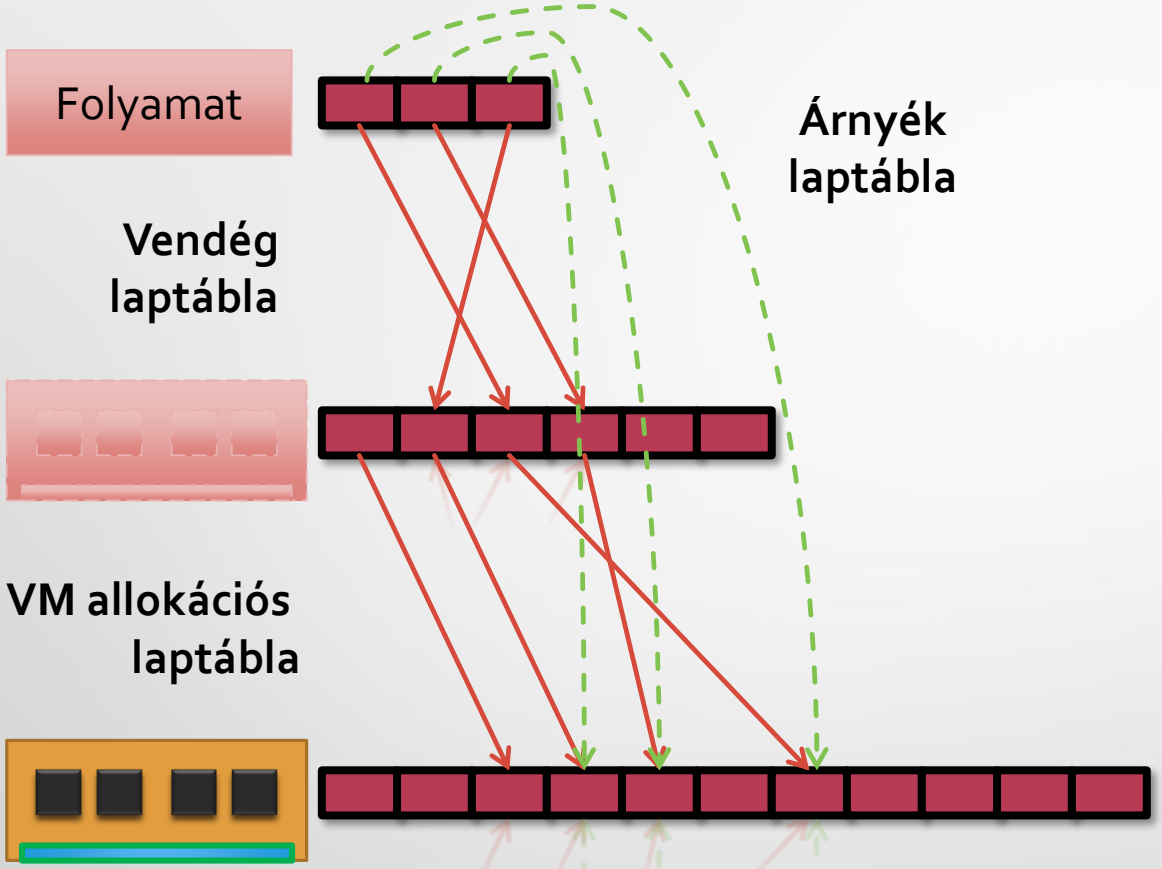

A virtuális gépben futó folyamat virtuális memóriája

A virtuális gép „fizikai” memóriája

Fizikai memória a hardverben

Memória virtualizálása

- Mi van, ha vendég kernel módosítani akarja a laptábláját?
  - Megfelelően frissíteni kell az árnyék táblát is
- **1.** Természetesen Trap and emulate, de hogyan?
  - Read-only-ra állítjuk a vendég kernel számára látható laptáblákat, ha azt módosítani akarja, akkor jön a kivétel, átkerül a vezérlés a VMM-hez ami biztonságosan elvégzi a módosítást az árnyék táblán is
- **2.** „természetesen?! trap and emulate?”
  - A vendég kernel egyszerűen ne maga akarja módosítani a laptáblát, *kérje meg* a VMM-et erre ☺
- **3.** Hardveres kiegészítés több szintű laptáblák kezelésére
  - Core i7 és Phenom processzoroktól kezdve van (EPT / RVI)
  - Az egész árnyék tábla frissítési problémát hardveresen lekezeli

Tartalom

- Előző rész tartalmából:
  - CPU virtualizáció
  - A három alap virtualizációs megközelítés
- Memória virtualizáció
  - Virtuális memória az operációs rendszerekben
  - Virtuális memória a platform virtualizációban
  - **Virtuális memóriakezelés speciális képességei: megosztás, késleltetett allokáció, memória-ballon**
- Perifériák virtualizációja
  - Perifériák programozói felülete általában
  - Periféria virtualizációs architektúrák

Extra memória virtualizálási lehetőségek

- Memórialap deduplikáció
  - azonos tartalmú memórialapok megosztása több vendég VM között
  - hasonlóképpen azonos lapok megosztása egy vendégen belül is
  - gyakorlati haszna főleg speciális alkalmazásokban (Virtual Desktop Infrastructure), tipikusan több példány fut azonos OS-ből
  - Megvalósítása
    - gyors hash számítás, ez alapján egyezés keresés
    - közösített lapok megbontása beleíráskor, copy-on-write elv
- Hasonló: memória tömörítés
  - Egészen új lehetőség VMM-ekben (az ötlet persze régi)
  - CPU költsége nagyon nagy lenne, ezért:
  - az inaktív, amúgy háttértárra kilapozásra ítélt lapokat szokás tömöríteni -> a ki/be tömörítés még így is gyorsabb a merevlemeznél
  - Nem csodaszer… kompromisszumot kell kötni a tömörítetlen és tömörített lapoknak fenntartott memória mérete között, csak korlátozott méretben előnyös

Extra memória virtualizálási lehetőségek

- Dinamikus allokáció:
  - Ami memóriát nem használ a vendég, azt ne is kapja meg
  - Gyakorlati haszna önmagában elenyésző, a legtöbb OS az összes szabad memóriát disk cache-nek használja
  - Háttértárra swappelhetők a lapok a vendég OS tudta nélkül
- Memória felfújás (memory ballooning)
  - Ha kifogy a host memóriája, akkor „elvesz” a vendégtől
  - Egy ágens vagy driver a vendég kernelben (paravirtualizációs szemléletmód) elkezd memóriát foglalni a VMM utasítására. A VMM az ágens által „foglalt” memórialapok mögé nem is allokál fizikai memóriát, így nyer vissza helyet
  - Egyrészt a vendég fel fog adni a disk cache-ből,
  - Másrészt el fog kezdeni kilapozni a saját swap területre, elkerüli, hogy a host is swappeljen

Kitekintés: VMware ESXi memóriakezelés

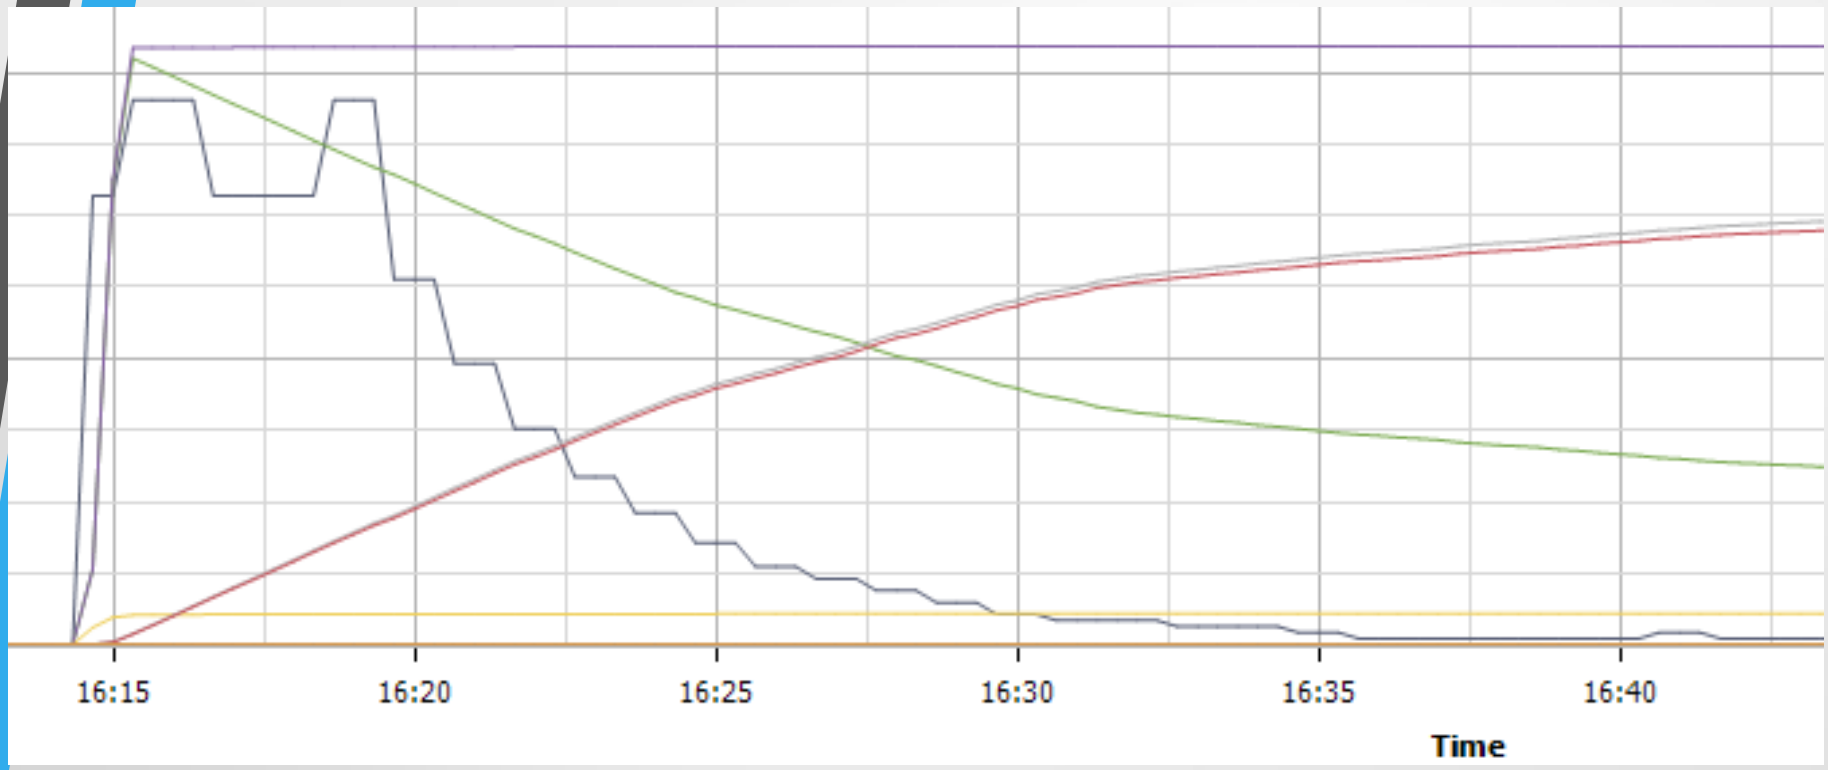

Jelmagyarázat:
granted (lila) active (kék) overhead (sárga) zero (piros) consumed (zöld) shared (szürkés-kék)

Tartalom

- Előző rész tartalmából:
  - CPU virtualizáció
  - A három alap virtualizációs megközelítés
- Memória virtualizáció
  - Virtuális memória az operációs rendszerekben
  - Virtuális memória a platform virtualizációban
  - Virtuális memóriakezelés speciális képességei: megosztás, késleltetett allokáció, memória-ballon
- **Perifériák virtualizációja**
  - **Perifériák programozói felülete általában**
  - Periféria virtualizációs architektúrák

Perifériákról általában

- A perifériák kezelése jellegzetesen
  - CPU felprogramozza a perifériát, regiszterek átírása
  - Periféria eseményt jelez a CPU felé, megszakítás
    - Ilyenkor valamilyen módon le kell kezelni az eseményt, valamit reagálni kell rá (driver felelőssége)
  - Periféria maga elvégzi a feladatát, közvetlen memória hozzáférés
    - Kiolvas elküldendő adatot, vagy berak beérkező adatot a memóriába
    - Külön lefoglalt fizikai memóriaterület kell erre a célra

Perifériákról általában

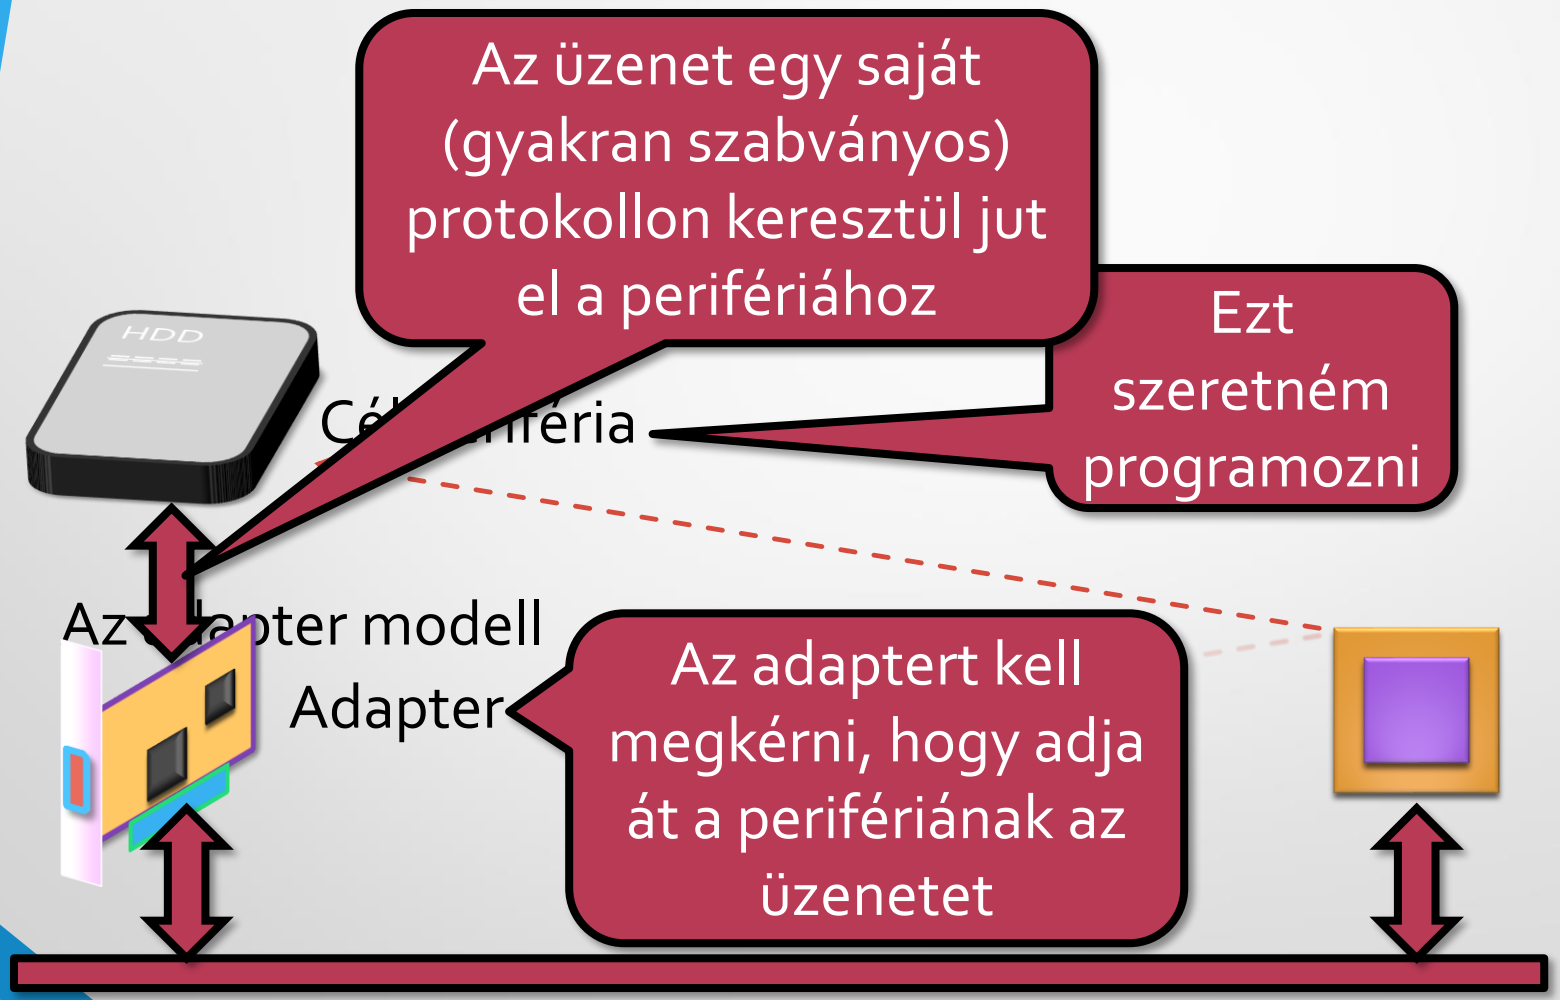

Perifériákról általában

Perifériának szánt konkrét utasítás, adat

Periféria protokollja

Adapter programozás

Rétegzett programozási modell (pl. USB, SCSI, SATA):

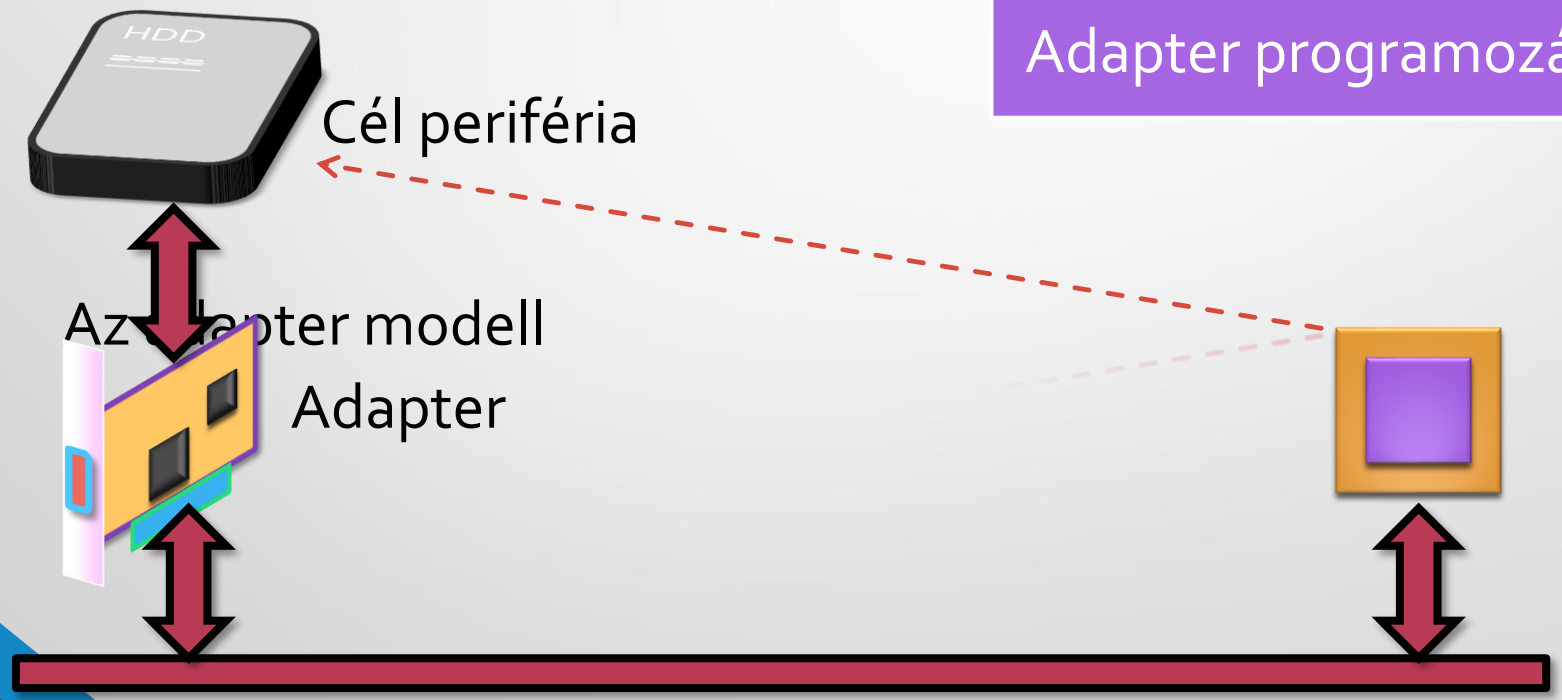

Tartalom

- Előző rész tartalmából:
  - CPU virtualizáció
  - A három alap virtualizációs megközelítés
- Memória virtualizáció
  - Virtuális memória az operációs rendszerekben
  - Virtuális memória a platform virtualizációban
  - Virtuális memóriakezelés speciális képességei: megosztás, késleltetett allokáció, memória-ballon
- **Perifériák virtualizációja**
  - Perifériák programozói felülete általában
  - **Periféria virtualizációs architektúrák**

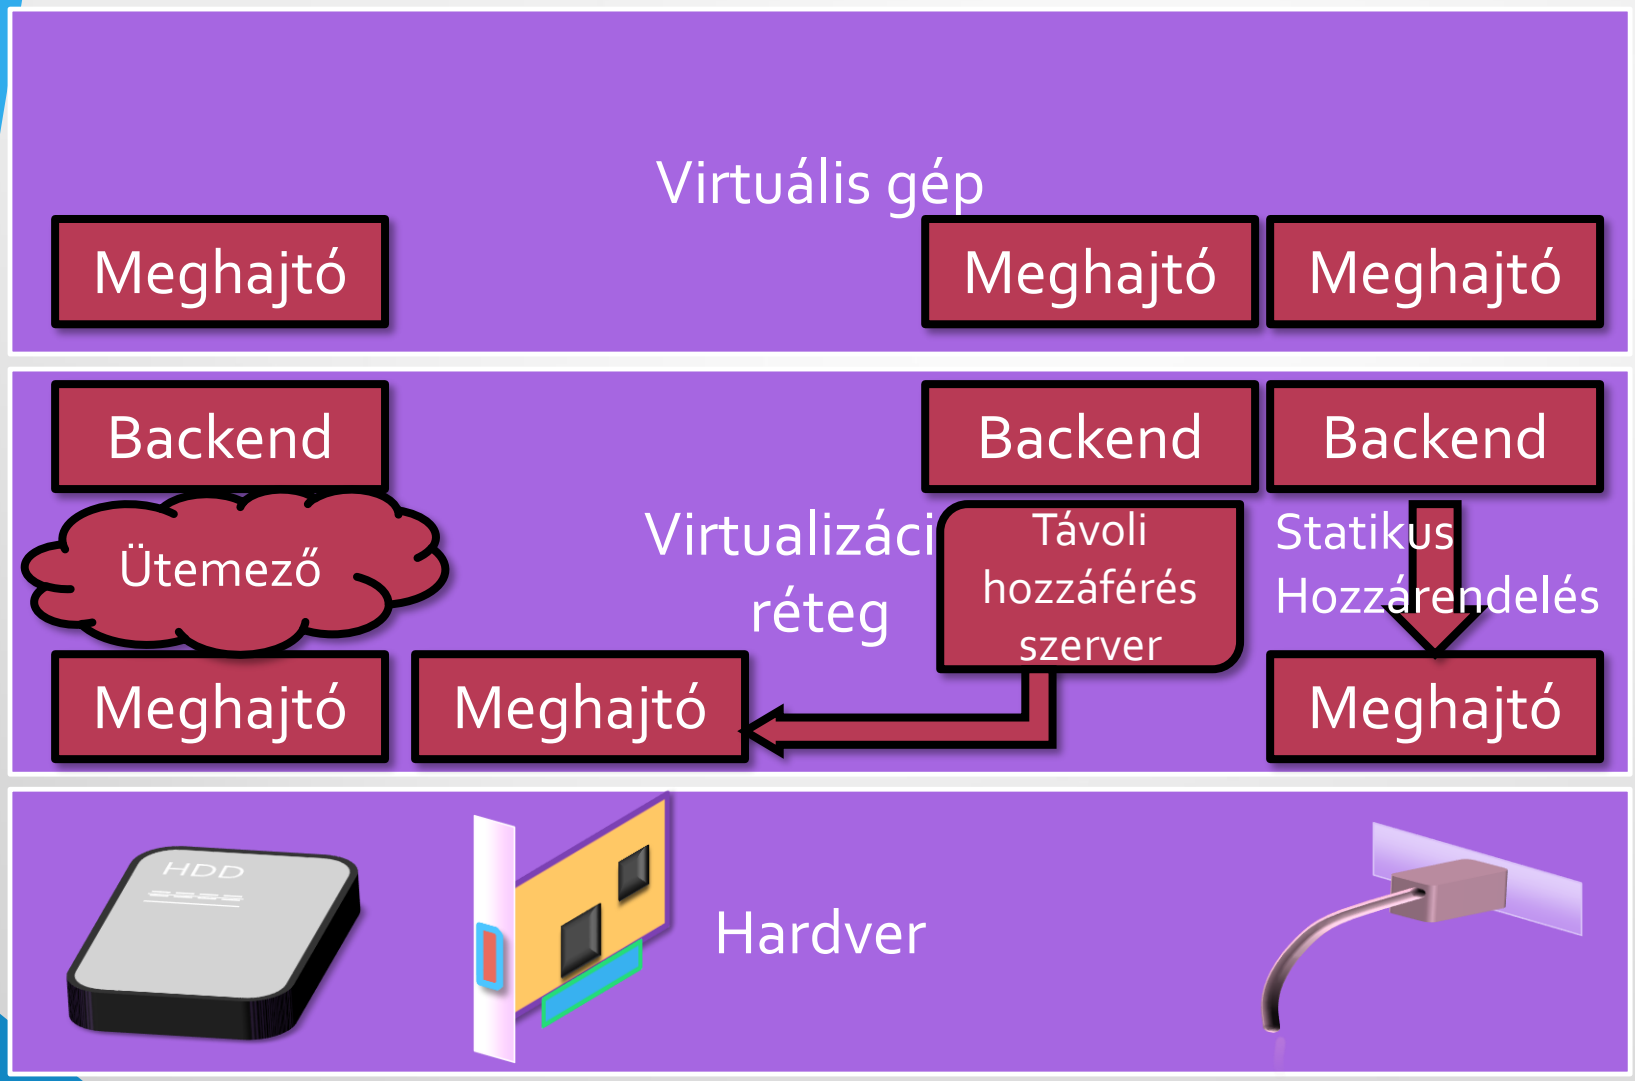
Virtuális gép
Meghajtó
Meghajtó
Meghajtó
Backend
Backend
Backend
Ütemező
Virtualizáci
réteg
Távoli
hozzáférés
szerver
Statikus
Hozzárendelés
Meghajtó
Meghajtó
Meghajtó
HDD
Hardver

Lehetőségek perifériák virtualizációjára I.

Emuláció

- Trap and emulate -> az I/O műveleteket kell elfogni
  - Adódik: ring 1-3-ban az I/O műveleteket elfogja a CPU
  - Memóriatartományba illesztett periféria:
    read-only memórialappal fogható el
- Valamilyen létező hardver működését emuláljuk
  - Szoftveres komponens segítségével: *backend*
  - Hardver pontos emulálása (regiszterek, megszakítás, DMA)
  - Vendégben használható a klasszikus meghajtó program
- Minden I/O művelet egy kör a VMM-ben -> lassú

Lehetőségek perifériák virtualizációjára II.

Paravirtualizáció

- Egyszerűsítsük az emulált hardvert, tervezzünk „nem létező fajta” hardvert, amit a legkevesebb művelettel lehet vezérelni
- Egy összetett művelet akár csak egy VMM hívás
- Saját „hardverek”, amik magas szintű műveleteket végeznek
  - Pl. hoszt fájlrendszerhez hozzáférés
  - Itt kezd keveredni a virtualizáció és az OS…
- Speciális meghajtót kell telepíteni a VM-ben!

Paravirtualizált I/O eszközök

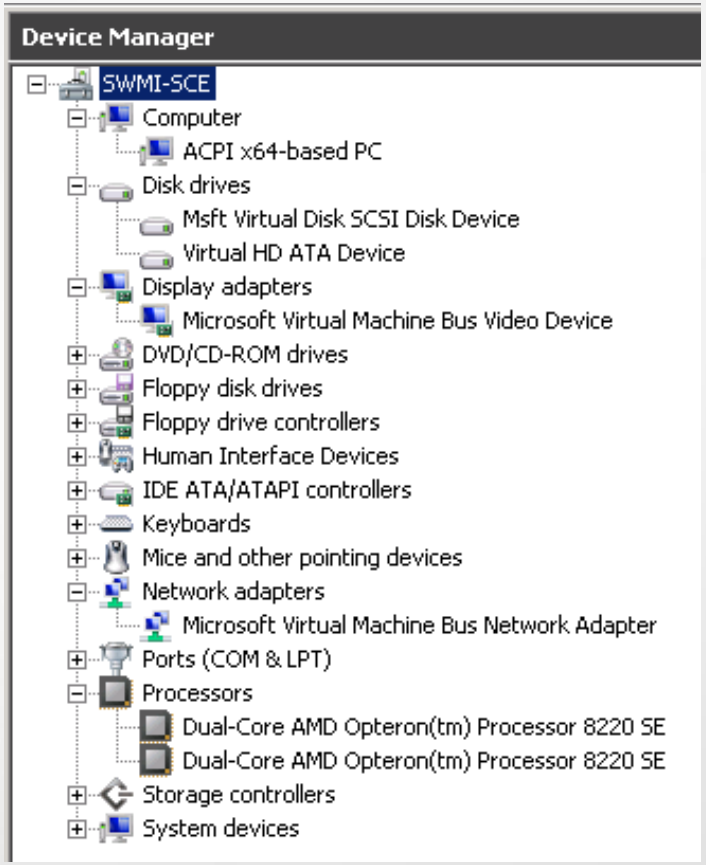

(VMware Tools, Hyper-V Integration Components kell)

További információ

- Carl Waldspurger and Mendel Rosenblum. I/O virtualization. *Commun. ACM* 55, 1 (January 2012), 66-73. DOI=10.1145/2063176.2063194
- Abramson, D. *et al*. "Intel® Virtualization Technology for Directed I/O." Intel Technology Journal. (August 2006).

- Darvas Dániel, Horányi Gergő. „Intel és AMD technológiák a hardveres virtualizáció megvalósítására”, virttech házi feladat, 2010.
- Garaczi Tamás. Intel VT-d (IOMMU) technológia részleteinek megismerése, virttech HF, 2010.