Virtualizációs Technológiák

Operációs rendszer szintű virtualizáció

Konténerek

Forrás, BME-VIK

Virtualizációs technológiák

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

Koncepció

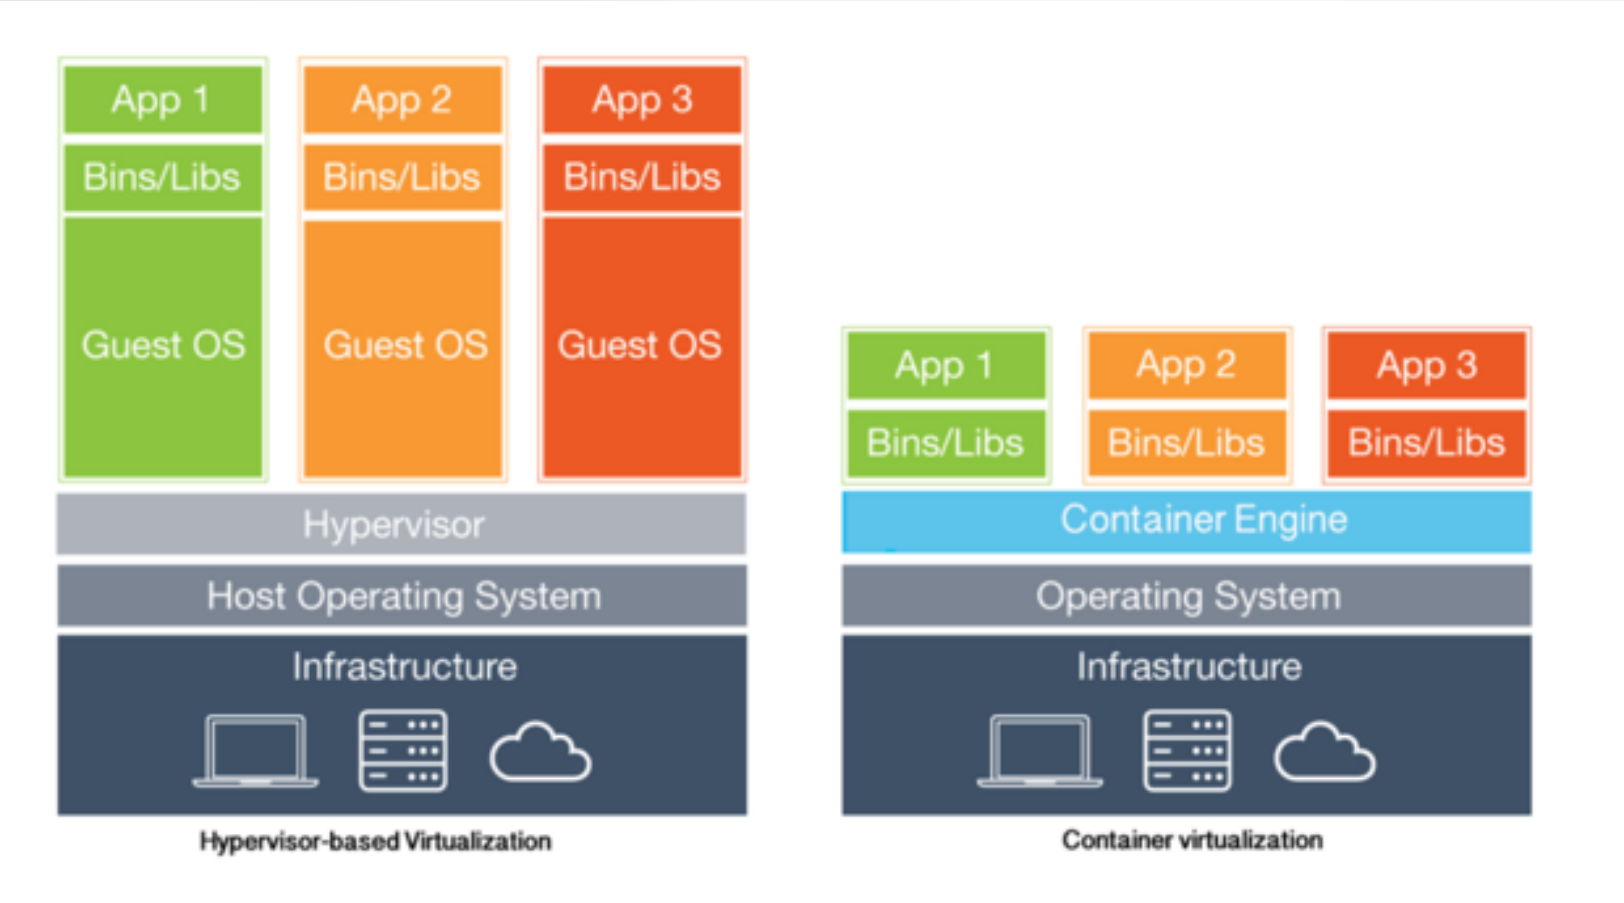

- Ha megfelel, hogy azonos az OS kernel a vendég gépek között
- Ha csak izoláció, erőforrás-korlátozás kell
- nem kell VMM, elég az OS alkalmazás szétválasztása

Nincs új a nap alatt

- Operációs rendszer szintű virtualizáció – más néven konténer alapú virtualizáció
  - BSD-ken: Jail
  - Solaris: Containers, Zones
  - Linux alatt: OpenVZ (Parallels Virtuozzoból a Linux kernel módú részei), Linux VServer
  - AIX: WPAR (workload partitions)
  - Windows: Parallels Virtuozzo

Konténerek

- nagyon kis költségű
  - elvileg nem 0 – csak éppen nem lehet kimérni olyan kicsi ☺
  - konténerenként nincsenek további vendég kernelek
- erőforrás virtualizációs és
- erőforrás gazdálkodási szempontból problémamentes
  - nincs fixen lefoglalt memória, nem kell trükközés ballonozással stb.
  - nincs fixen lefoglalt háttértár – a hoszt fájlrendszere fájl szinten elérhető
- biztonsági szempontból kevésbé jó izoláció
- közös kernellel kell élni (azonos verzió, fordítási paraméterek)

Hypervisor vs. konténerek

- Hypervisor
  - Egy fizikai, számos virtuális hardver
  - Vegyes operációs rendszerek
  - Kisebb sűrűség
  - Kisebb teljesítmény
- OS szintű virtualizáció
  - Egy fizikai hardver, nincs virtuális
  - Egy kernel, userspace példányok
  - Nagy sűrűség
  - Közel natív teljesítmény

Réges-rég egy messzi-messzi galaxisban

- UML (User Mode Linux) 2.2.0-ás kerneltől !!!!!!!!!
  - Külön rendszer létrehozása debootstrappal
  - Nem privilégizált linux processzként fut
- Jail/chroot
  - Egy adott processz izolálása a rendszertől
  - Minden amire szükség lehet újra létrehozni egy külön könyvtárban
  - Chroot -> a könyvtárban voálá
  - Konténer = egy szimpla jail szteroidokkal ☺

Megvalósítás

- Kezdetben volt a *chroot*…
  - A fájlrendszer gyökerét átirányíthatjuk egy alkönyvtárra (egy processzre vonatkozik!)
  - Cél:
    - Általában: az abszolút fájl elérési útvonalak módosítása nélkül tudjunk több példányt fenntartani egy-egy fájlból
    - Kicsit „antipattern” alkalmazás: biztonság növelése
  - Ez nem teljes körű izoláció, de sok esetben működik
    - Kernel minden adatszerkezete közös (processz lista, hálózati interfész, IP, routing, sysctl beállítások…)
    - A chrootból ráadásul ki is lehet navigálni a VFS adatszerkezeten keresztül…
  - Hogy is néz ki:
    - egy teljes alap OS installációt készítünk egy alkönyvtárba, ami kicsit eltérő is lehet az eredetitől
    - Általában véve a programkönyvtáraknak, konfig fájloknak meg kell lenniük a chroot-on belül is
  - Problémás globális könyvtárak: /proc, /sys, /dev, /tmp, /var, …
    - Lehet mount binddal trükközni, de nem lesz tökéletes…

Alkotóelemek

- Kernel
  - Névterek: virtualizáció és izoláció
  - Cgroups: erőforrás menedzsment
  - Checkpoint/Restart: live migration
- Userspace eszközök
  - Konténer menedzsment parancssori eszközök
- OS sablonok

Erőforrások

- CPU – a kernel beépített ütemezője, prioritáskezelője
- Memória – a kernel beépített memóriakezelője, *rlimit*-tel megadható maximális foglalások)
- Háttértár – a fájlrendszer egy alkönyvtára, *quota* rendszerrel korlátozható foglalás
- Hálózat – a kernel beépített Ethernet hídja vagy routing táblája, pl. IPtables QoS paraméterekkel korlátozható
- Egyéb perifériák – a kernelben lévő meghajtón keresztül

Erőforrás-gazdálkodás

- Azt szeretnénk, ha a konténerre vonatkozna a korlátozás, nem pedig az egyes folyamatokra
- Hierarchikus erőforrás foglalás:
  - A folyamatok fa hierarchiába szervezettek (nemcsak Unix, Windows alatt is)
  - Ún. Beancounter rendszer, ami csoportok szerint összesíti a foglalást
- A memóriafoglalás elég sokrétű probléma:
  - Alkalmazás virtuális/fizikai memórialapok
  - Cache lapok
  - Pufferek (socketek, hálózati kapcsolatok)
  - Megosztott lapok „igazságos” költségelszámolása
  - Néhány alkalmazás elég „zűrös” memóriafoglaló (Java VM) – kézi beállítást igényelhet

Checkpointing/Migration

- Teljes konténer állapot
  - Menthető
    - Futó folyamatok
    - Megnyitott fájlok
    - Hálózati kapcsolatok
    - Memória szegmensek
  - Visszaállítható
  - Visszaállítható másik szerveren

Hozzáférés a vendég „gépekhez”

- Szöveges konzol elérés van
- Grafikus felület
  - általában nehéz, mert globális erőforrásokhoz (Unix alatt X Server, socket) igényel hozzáférést
  - Gyakorlatban használt megoldás: távoli elérés szerver indítása a konténerben, tipikusan VNC szerver
- Fájlrendszer
  - Konténeren kívülről belátunk a konténer fájlrendszerébe
  - Konténeren belülről nem látunk kifelé
- Folyamatok
  - Mint a fájlrendszernél…

Hálózat

- Pont-pont kapcsolat a konténer és a hoszt között
- A hoszt hálózati interfészei között lehetőség van NAT vagy Bridged jellegű beállításra

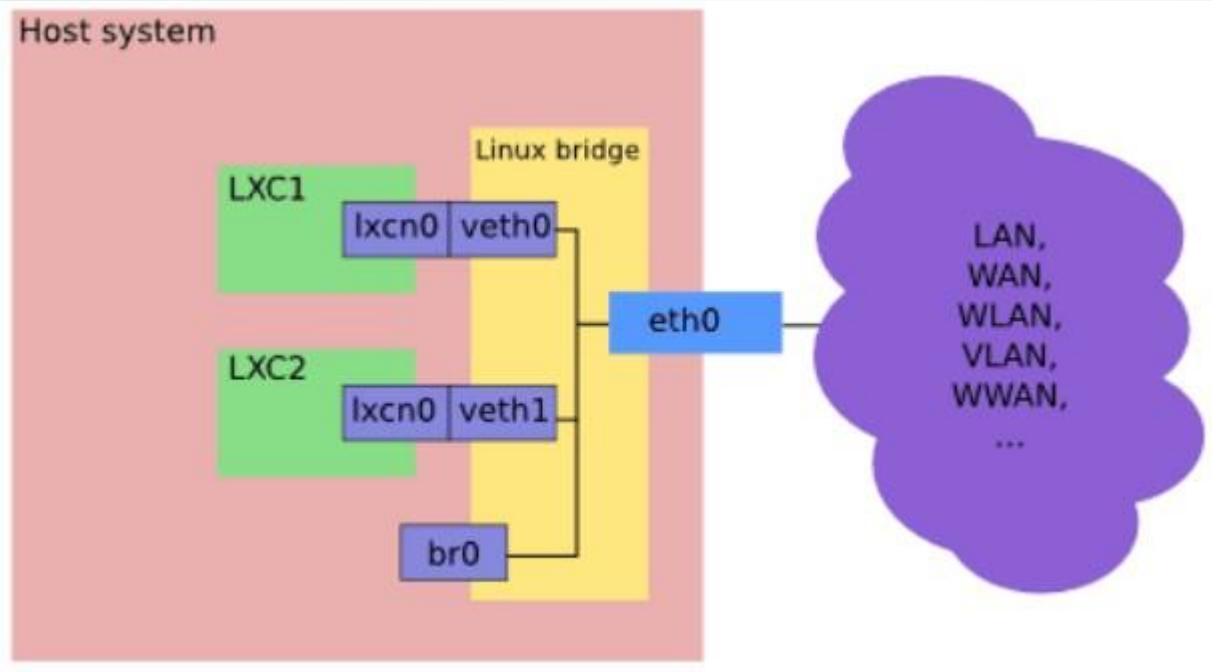

Docker

- 2013-ban vált nyílt forrásúvá a Docker nevű konténer platform amely kezdetben a korábban létező LXC (Linux Containers) technológiát használta a konténerek futtatására.
- Később ezt lecserélték egy saját implementációra, de a Docker valódi célja nem ez volt hanem, hogy létrehozzanak egy olyan rendszert amely nagyban leegyszerűsíti a konténerek menedzselését a rendszerüzemeltetők és a végfelhasználók számára.
- Ennek a rendszernek két fő komponense van: egy linux operációs rendszerekre elérhető eszközkészlet és a hozzá tartozó szerverprogram (docker daemon) amely a konténerek futtatását végzi, illetve egy web alapú konténer könyvtár (dockerhub) ahová a felhasználók által létrehozott konténereket találjuk.

Singularity

- Singularity egy új megközelítése a konténer technológiáknak.
- Futtatásához nincs szükség rendszergazdai jogosultságokra így kiválóan alkalmas megosztott rendszereken való használatra. A kifejezetten HPC (High Performance Computing) környezetbe szánt
- Ez által a speciális gyorsítókártyák és videókártyák valamint a HPC környezetben gyakran használatos interconnect technológiák mint például az Infiniband minden akadály nélkül használhatóak.
- Továbbá a hálózati meghajtója is közvetlenül a fizikai host interfészét használja így nagyobb sebességre képes alapértelmezett beállítások mellett, mint a Docker.
- A dockerhubbal kompatibilis, így a Docker-nek szánt konténerek gond nélkül futtathatóak Singularityvel is.

CGroups

- A control groups-ot a google két mérnöke Paul Menage és Rohit Seth fejlesztette még 2006-ban azzal a céllal, hogy a Linuxon futtatott különböző processzek és folyamatok között megfelelő elszigetelést hozzanak létre. A cgroups a következő főbb feladatokat látja el:
- **Erőforrás limitáció**
  - A group-oknak be lehet állítani memória és processzoridő limiteket
- **Priorizálás**
  - A prioritást élvező group-ok nagyobb részt kaphat processzoridőből és Lemez Írás/Olvasás műveletekből
- **Számvitel**
  - Méri az egyes group-ok erőforráshasználatát amelyet akár későbbi számlázáshoz is fel lehet használni
- **Vezérlés**
  - Megállíthatja, újraindíthatja az egyes processzeket, akár ellenörzőpontokat is létrehozhat későbbi folytatáshoz

Fájlrendszer

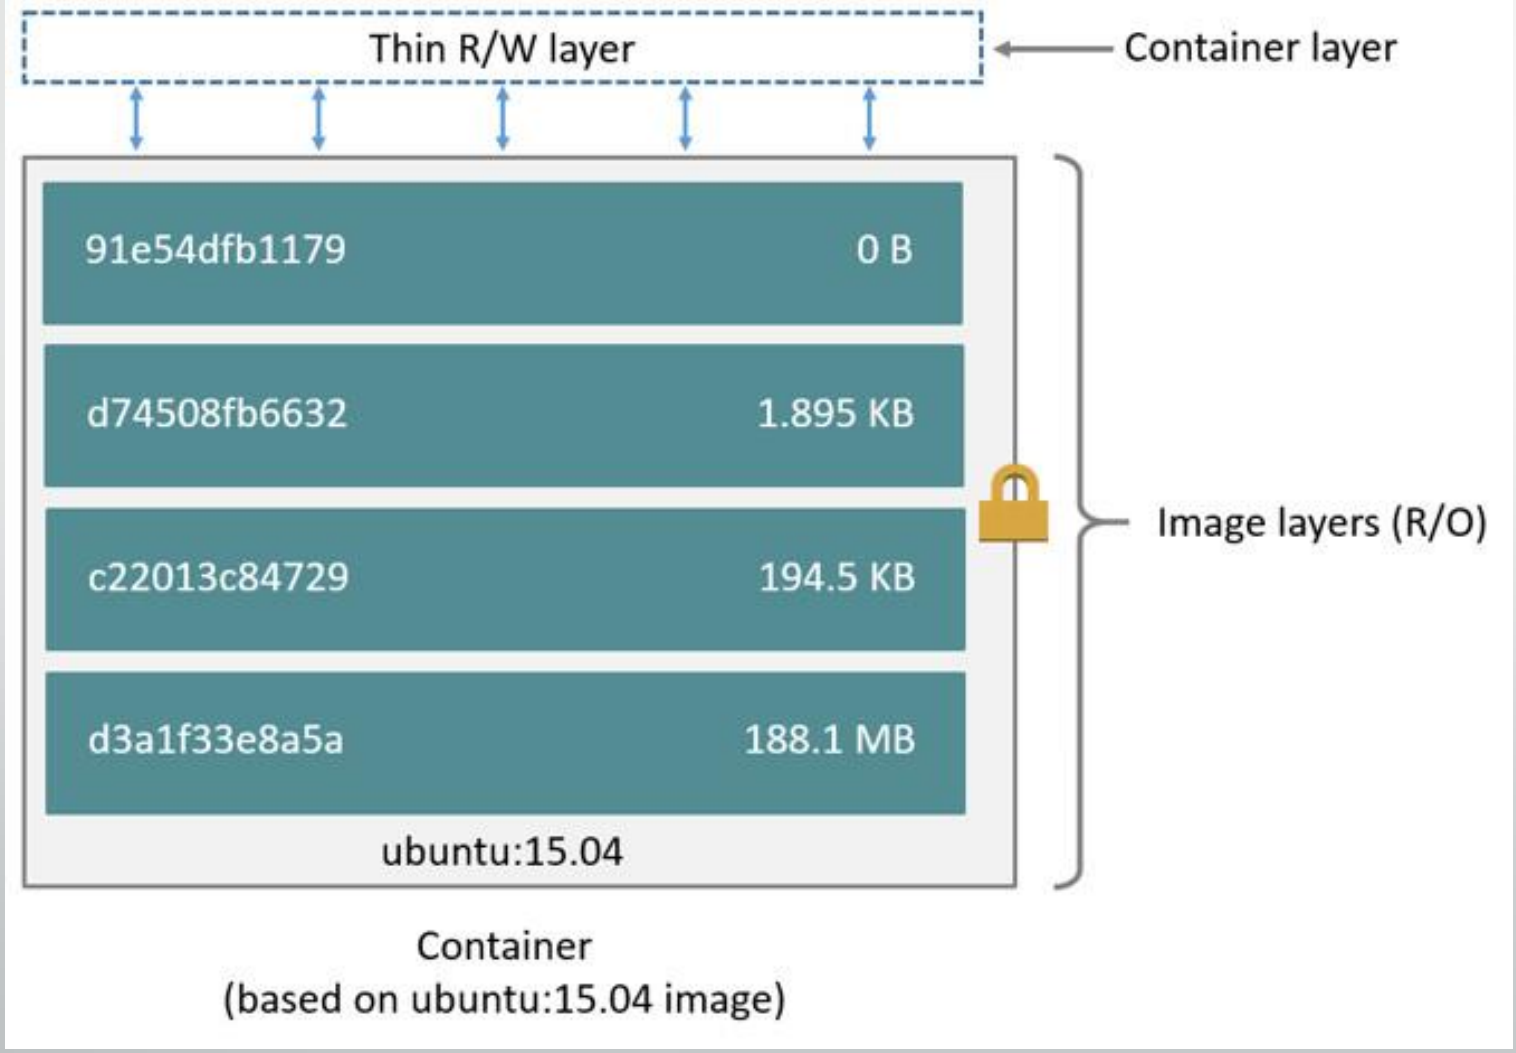

Konténer leírófájl

```
FROM ubuntu:16.10 # meghatározzuk a base imaget
COPY . /app # a fájlrendszerünkből bemásoljuk az app mappát
RUN make /app # elindítjuk az app könyvtárban található make fájlt
CMD python /app/app.py # elindítjuk az app könyvtárban található app.py-t
```

“Hátrányok”

- Docker csak egy processzt használ (multiprocess bukta)
- Több konténer egy szolgáltatáshoz
  - Nginx konténer
  - Mysql konténer
  - PHP konténer stb…
- Nincs login script, SSH daemon, monitoring agent stb.
- Read-only konténer (snapshot jellegű működés)

Konténer menedzsment

- Több konténer egy szolgáltatáshoz
  - Docker compose: https://docs.docker.com/compose/
  - Konténerek és paramétereik egy leírófájlban: docker-compose.yaml (YAML)
  - docker-compose parancs ami ez alapján készíti/indítja/leállítja

```
version: "3.9"
  services:
    web:
        build: .
        ports:
            - "8000:5000"
     redis:
        image: "redis:alpine"
```

Konténer menedzsment

- Több konténer egy szolgáltatáshoz
- HA, failover stb.
  - Kubernetes https://kubernetes.io/
  - 1 szolgáltatás = 1 konténer = 1 POD
  - Node: olyan gép amin futhatnak a podok (VM vagy fizikai vas)
  - Cluster: több Node-ból álló üzemeltetési egység
  - Deployment: 1 futó POD:
    - Automatikus újraindítás
    - HA: legalább x példány mindig fut (node failure-t is kezel)
  - "szabványos" API:
    - több ingyenes és fizetős termék amivel Kubernetes cluster-t lehet kezelni
      - Pl.: RedHat OpenShift
      - Helm (https://helm.sh/)

Összefoglalás

- Konténer alapú virtualizáció - eltérő koncepció a platform virtualizációtól
  - Közös kernel
  - Kisebb erőforrás igény
  - Operációs rendszer szintű erőforrásokat virtualizál
  - Jellemzően a host felől nézve a konténer átlátszó, belülről nézve átlátszatlan (!!!!!)
- OpenVZ, Parallels Virtuozzo, LXC, Docker
  - Linux illetve Windows környezetben nagyon hasonló megoldások
  - Konténerek példányosítása sablonokból

Gyakorlat

- wget http://dev2.tilb.sze.hu/docker.sh
- chmod 777 docker.sh
- ./docker.sh
- docker run hello-world
- docker ps -a

Gyakorlat

- https://gitlab.tilb.sze.hu/teach/virt-tech/docker-example