LVM2 – logical volume management

Milan Brož
mbroz@redhat.com

LinuxAlt 2007, 3.listopadu 2007, Brno

Proč virtualizace diskových oddílů ?

- **Abstrakce** nad omezení fyzických disků
- **Jednotné ovládání**
- **Vysoká dostupnost** (operace za běhu, HA)
- **Flexibilita** – změna parametrů, optimalizace, ...
- **Škálovatelnost**
- **Bezpečnost dat -** RAID, snímky obsahu
- **Celkové snížení nákladů na provoz**

redhat

Virtualizace diskového prostoru v Linuxu

Přehled technologií

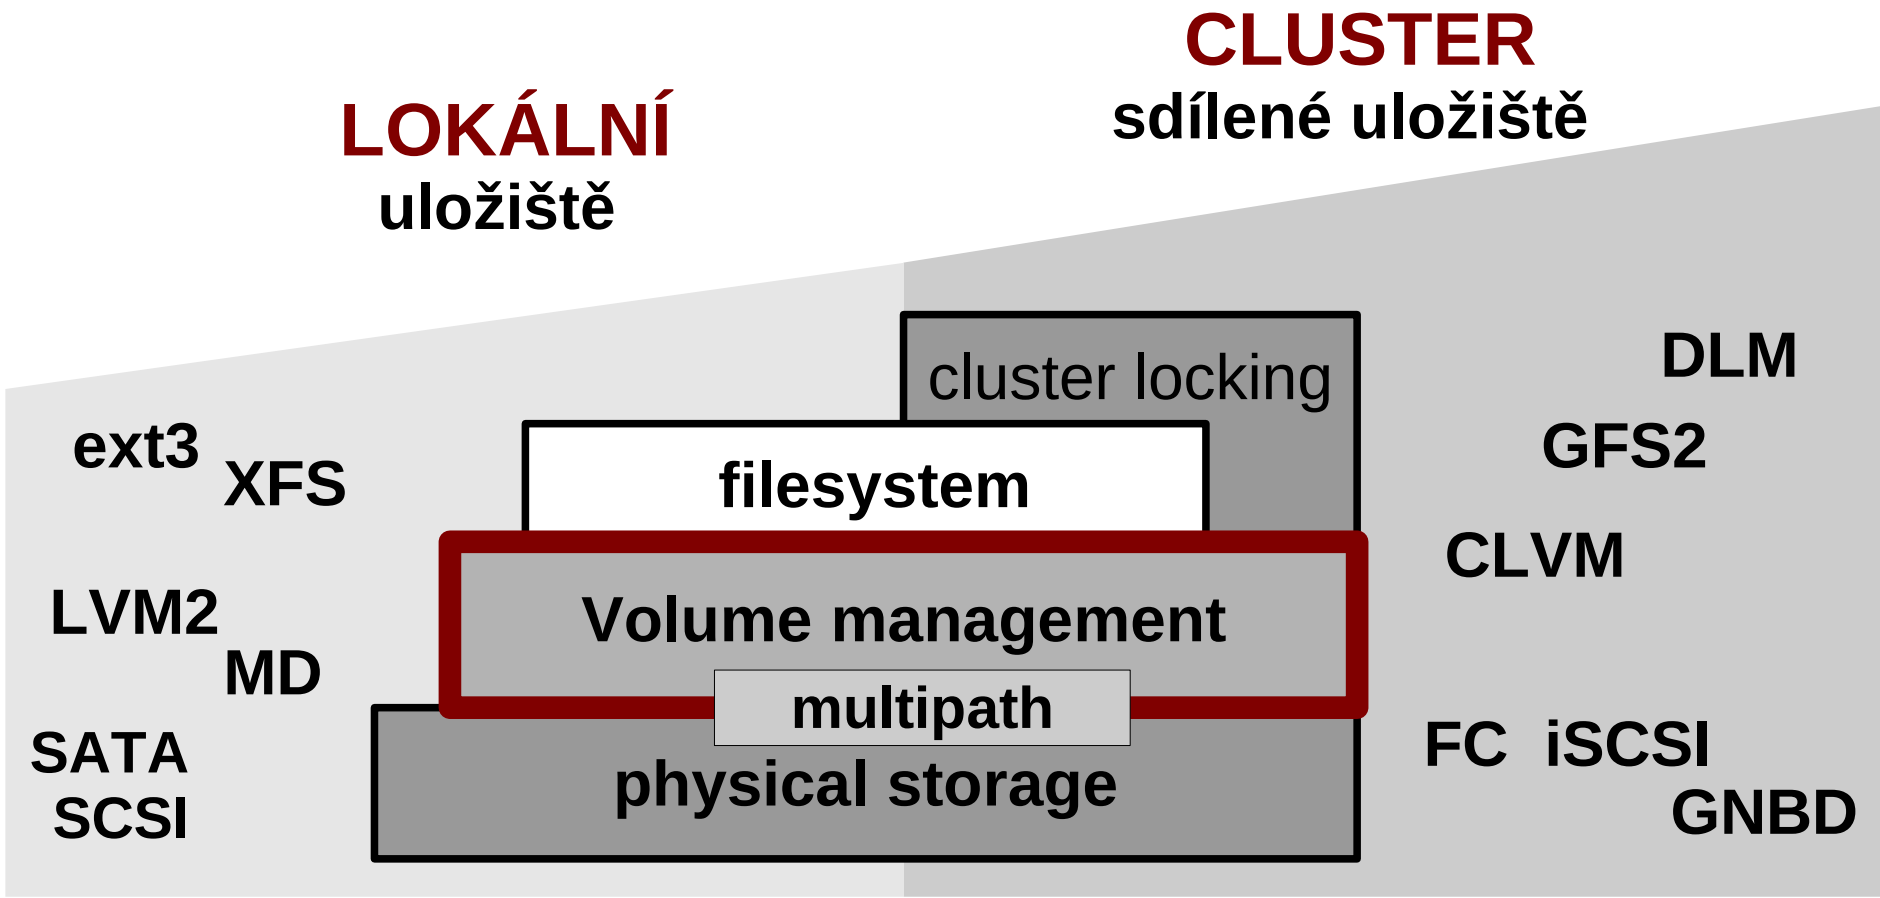

MD versus LVM2

- **MD (multi-disk) je jaderný ovladač**
  - umožňuje vytvořit nové blokové zařízení nad existujícími disky
  - umožňuje použít RAID 0,1,4,5,6
  - stabilní, logika implementována v jádře, ovládání přes mdadm
- **DM (device mapper) je jaderný ovladač**
  - zcela obecný ovladač pro mapování blokových zařízení
  - umožňuje kombinovat všechny dostupné typy mapování a vytvořit z nich nové blokové zařízení
- **LVM2 je správce logických oddílů**
  - umožňuje kombinovat a spravovat fyzické disky, MD a DM zařízení a mapovat je do logických oddílů
  - vyžaduje funkční DM v jádře

LVM2 nad MD ?

- **MD RAID ?**
  - MD poskytuje stabilní sw RAID 1,5,6
  - LVM2 umí RAID 0,1, RAID 4,5 není zatím v jádře
    - vyžaduje userspace démona (dmeventd) pro rekonfigurace
    - zatím není podporováno v distribucích, potenciální problémy
- **LVM2 nad MD RAID**
  - momentálně nejlepší kompromis
  - výkonostní problémy – odstranění je jedna z priorit vývoje LVM
  - MD RAID nad LVM2 oddíly – možné, ale prakticky nemá smysl
- **DMRAID**
  - sw RAID - využívá pouze device-mapper bez LVM vrstvy
  - smysl má pouze při sdílení uložiště s jiným OS

DMRAID

- **nástroj pro zpřístupnění diskových polí vytvořených pomocí sw RAID řadičů**
  ATARAID – levné sw RAID řadiče (SiL, Highpoint, Promise, VIA, ...) často s vlastním BIOSem (s nástroji umožňujícími vytvářet raid pole a speciálními ovladači poskytujícími RAID funkce)

- **software RAID pole**, hw RAID nepotřebuje speciální ovladače a nepoužívá systémový procesor pro výpočet paritních bloků
  více na *http://linux-ata.org/faq-sata-raid.html*

- **speciální metadata** převádí na DM zařízení
  - linear, JBOD (just bunch of disks)
  - RAID 0,1
  - RAID 4,5 (nemá zatím podporu ve stabilním jádře)

DMRAID – základní příkazy

`dmraid -r [...]` – **vypíše všechna nalezená mapování**

jméno disku, ovladač pro metadata, stav, ...

`dmraid -a [y|n] [name]` – **aktivuje/deaktivuje raid**

vytvoří nové dm blokové zařízení podle nalezených metadat na disku /dev/mapper/<drivername>_<devicename>

`dmraid -s [...]` – **vypíše parametry raid pole**

typ RAIDu, počet zařízení, velikost bloku, ...

`dmraid -l [...]` – **vypíše podporované formáty metadat**

*k aktivaci je třeba **dm raid jaderný ovladač** (nikoliv md/raid456)*
dm raid5 není ve stabilním jádře dmraid nevytvoří mapování, ačkoliv formátu metadat rozumí !

kpartx

- zpřístupní jednotlivé diskové oddíly (podle tabulky oddílů) jako samostatná bloková zařízení

kpartx - příklad

`kpartx -l device` – **seznam nalezených oddílů**

`kpartx -a device` – **vytvoří mapování oddílů**
`kpartx -d device` – **odstraní mapování oddílů**

zpřístupnění oddílů (particií) z obrazu disku v souboru

```
losetup /dev/loop0 file
kpartx -a /dev/loop0
```

a oddíly jsou přístupné pod /dev/mapper/loop0p1,p2,...

LVM2 – správa logických oddílů

- **Abstraktní vrstva** nad fyzickými zařízeními
- Umožňuje vytvářet **logické oddíly (LV)**

  nad kterými lze použít například souborový systém
- Logický oddíl je **blokové zařízení**

  ~ zhruba odpovídá fyzickému oddílu na disku

Linux LVM

- **LVM1 – pouze pro Linux jádro 2.4**
  většina funkcí se provádí přímo v jádře

- **LVM2 – nový, obecný návrh**
  - zpětně podporuje LVM1 příkazy a formáty metadat
  - v jádře je jen nezbytná část kódu
  - logicky má tedy 2 části
    - **Modulární jaderný ovladač (DM)**
    - **Uživatelské nástroje (LVM2)**

- **EVMS**
  - Enterprise Volume Management System (IBM)
  - mimo jiné podporuje částečně i LVM metadata, používá DM

Aplikace nad jaderným DM

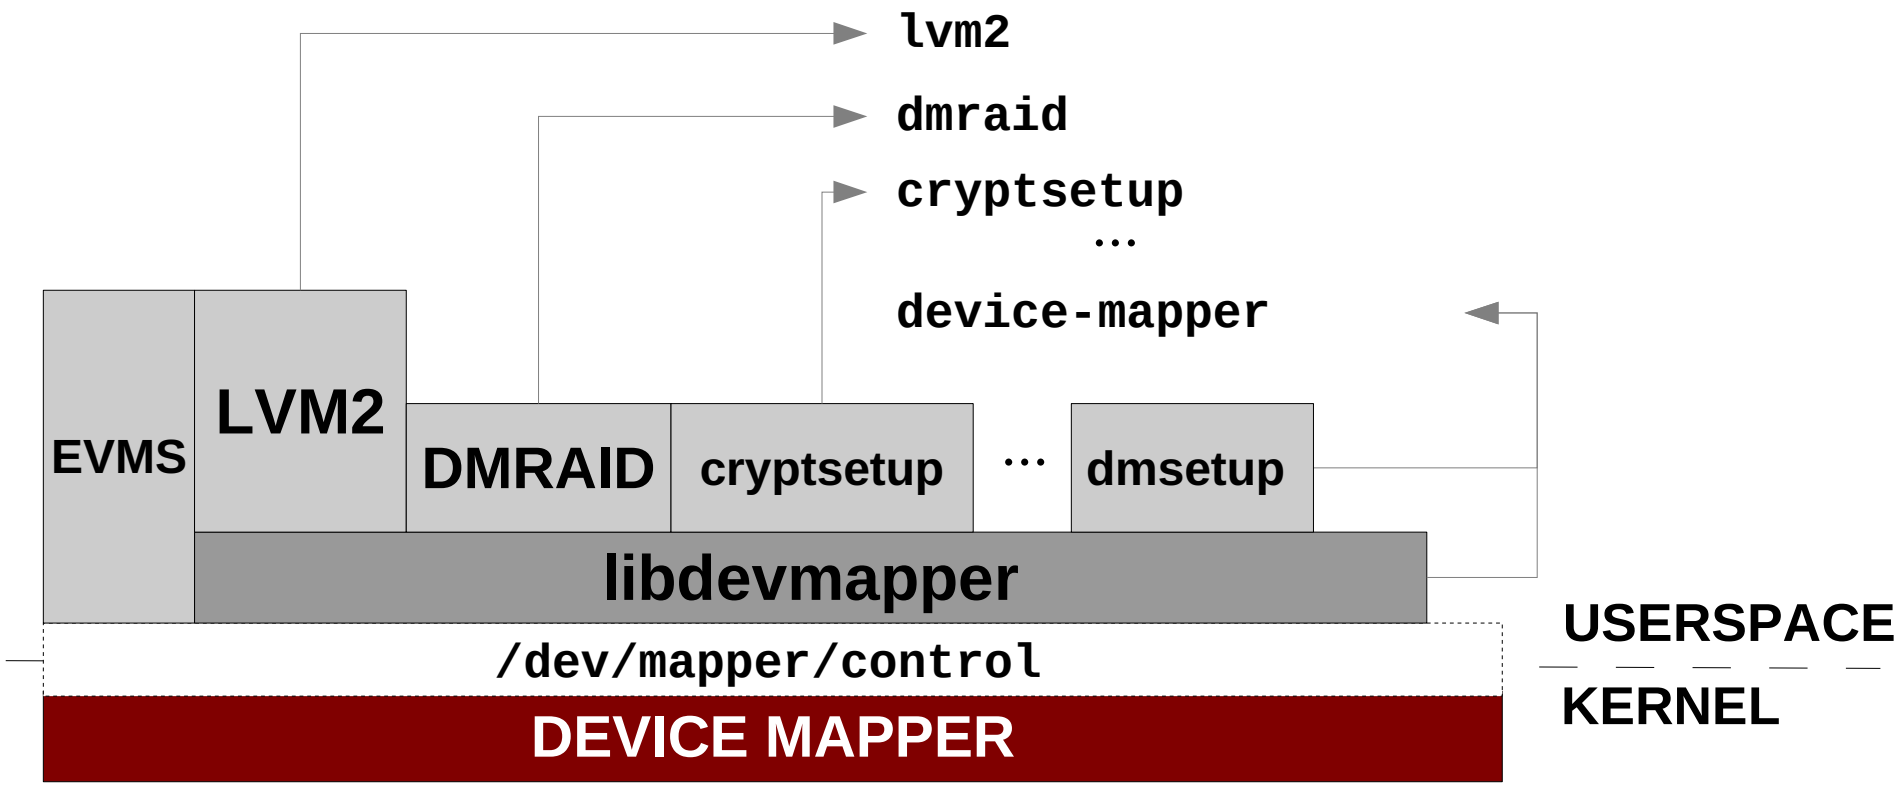

LVM2 – správa logických oddílů

(Logical Volume Manager – abstraktní vrstva nad DM)

3 VRSTVY

FYZICKÉ ODDÍLY (PHYSICAL VOLUMES) – **PV**

fyzická uložiště ~ DISKY

jsou seskupeny

SKUPINY ODDÍLŮ (VOLUME GROUPS) – **VG**

logické disky

úložná kapacita VG je přidělena pro

LOGICKÉ ODDÍLY (LOGICAL VOLUMES) – **LV**

logické diskové oddíly ~ PARTICIE

LVM2 – schéma

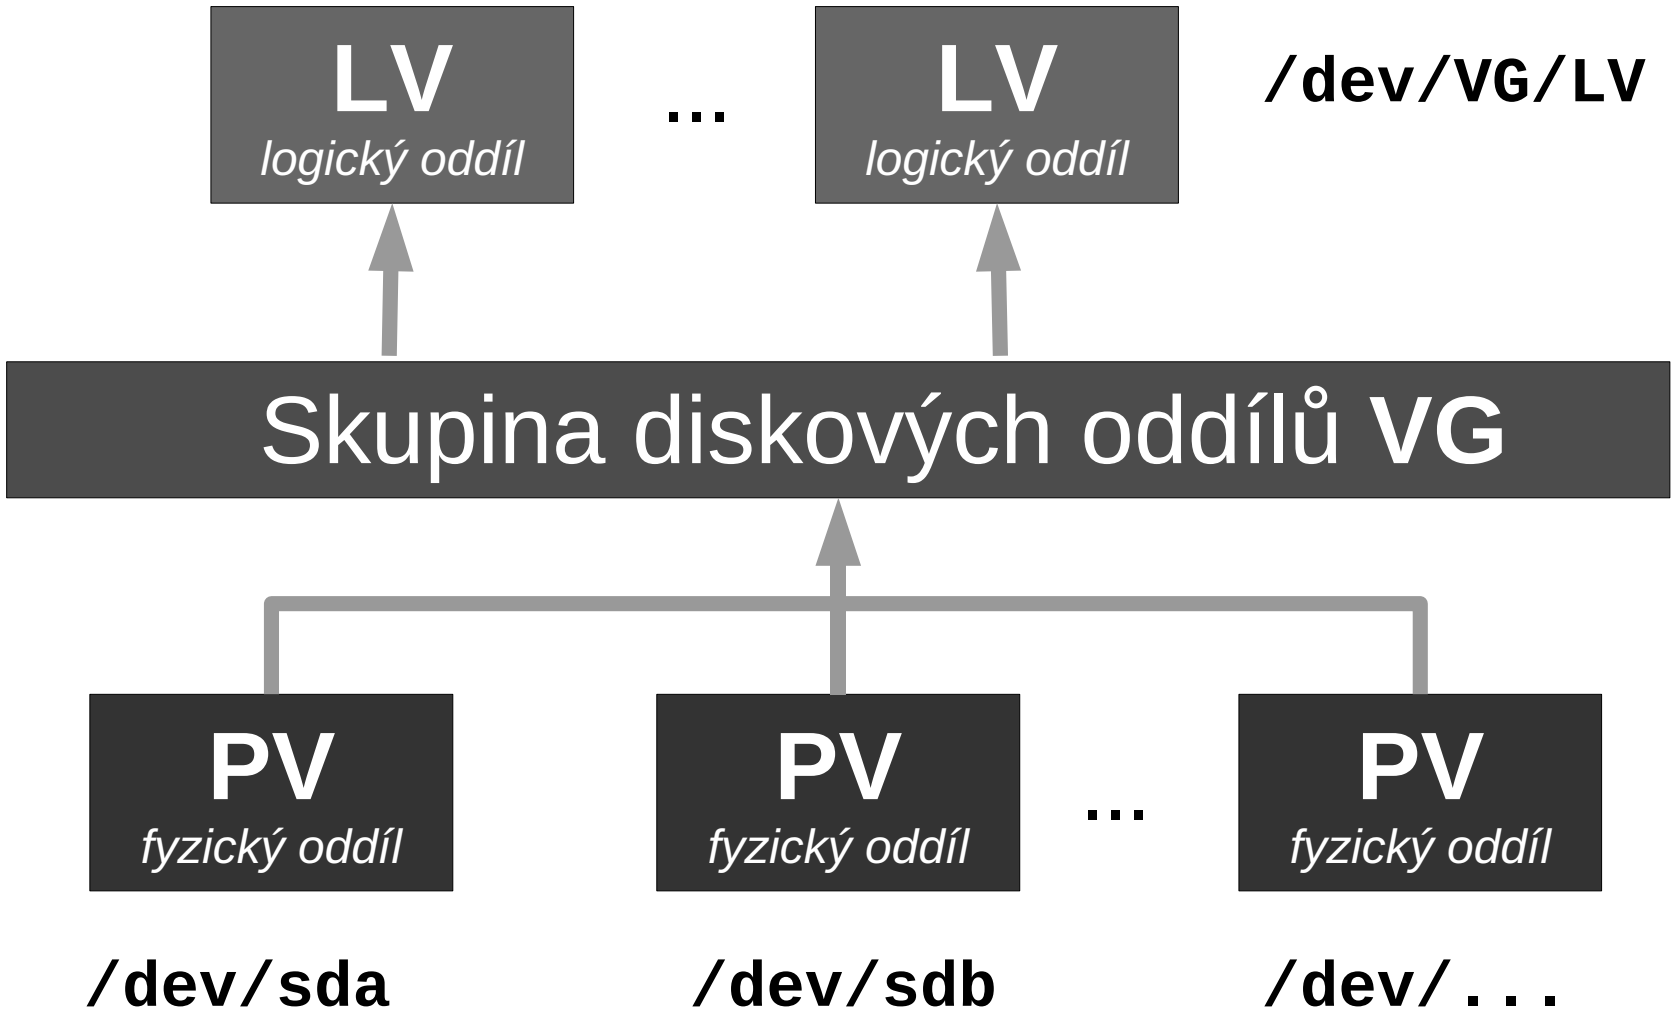
LV
logický oddíl
...
LV
logický oddíl
/dev/VG/LV
Skupina diskových oddílů VG
PV
fyzický oddíl
PV
fyzický oddíl
...
PV
fyzický oddíl
/dev/sda
/dev/sdb
/dev/...

LVM2 – příkazy

- předpona: **pv***, **vg***, **lv***
- kompletní přehled příkazů: **lvm help**
- popis a přehled atributů: **pvs -o help**
- **man lvm, man <command>**

- **lvm –** jeden binární soubor (ostatní jsou symbolické linky), interaktivní mód
  - [pv,vg,lv] ***s**[how] [*display], ***scan**, ***create**, ***remove**, ***change**
  - [vg,lv] ***reduce**, ***extend**, ***rename**
  - [pv,lv] ***resize**
  - **pvmove**
  - **vgmerge, vgsplit**
  - **lvconvert**
  - **lvmdiskscan**

- [vg] ***cfgbackup/restore, *import/export, *convert, *ck, *mknodes**

- Reportování problému - **lvmdump** (vytvoří archív se všemi potřebnými daty pro analýzu)

LVM2 – /etc/lvm, lvm.conf

- kofigurace je uložena v souboru **/etc/lvm/lvm.conf**

- **popis parametrů přímo v konfiguračním souboru**
  příklady:
  - (devices) `filter = [ "a/loop/", "r/.*/" ]`
    nastavení zařízení, na kterých se budou hledat oddíly

  - `cache_dir = "/etc/lvm/cache"`
    adresář, kde LVM udržuje cache
    (lze smazat, jen pro urychlení některých operací)

  - (global) `locking_type = 1`
    typ zamykání metadat – lokální, pro cluster (clvmd), ...

- `/etc/lvm/backup, archive -` historie změn metadat (vgcfgrestore, vgcfgbackup)

LVM2 – METADATA obsahující popis logických oddílů

Kde LVM ukládá metadata ?

- **PV** (blokové zařízení) **obsahuje hlavičku**
- metadata mají **textový formát** – plain ASCII
- **zálohy metadat** jsou v adresáři **/etc/lvm** (dle konfigurace)
- všechny **objekty mají jednoznačné UUID**

  (které lze použít místo jména v případě duplicity)

- Metadata jsou **uložena na každém PV** (redundance)
  (lze explicitně zakázat – v případě desítek PV jde o výrazné zrychlení práce při změně metadat)
- obnovení mapování může být při fyzickém selhání disku a ztrátě metadat poměrně komplikované
  Je velmi vhodné metadata zálohovat !

LVM2 – ukázka formátu METADAT

```
creation_time = ...
...
vg_strip { id = "xxxxxx-xxxx-xxxx-xxxx-xxxx-xxxx-xxxxxx"
        ...
        physical_volumes {
            pv0 {    id = "xxxxxx-xxxx-xxxx-xxxx-xxxx-xxxx-xxxxxx"
                     device = "/dev/sdb1"  # Hint only
                     ...
                     pe_start = 384
                     pe_count = 50   # 200 Megabytes }
            pv1 { ... }
        }
        logical_volumes {
            lv_strip {   id = "xxxxxx-xxxx-xxxx-xxxx-xxxx-xxxx-xxxxxx"
                         ...
                         segment1 {
                             start_extent = 0
                             extent_count = 100 # 400 Megabytes
                             type = "striped"
                             stripe_count = 2
                             stripe_size = 128  # 64 Kilobytes
                             stripes = [  "pv0", 0,
                                          "pv1", 0 ]
                         }
            }
        }
}
```

LVM2 – RAID0 (striped) zařízení

fdisk /dev/sd[bc] → oddíly sdb1,sdc1 typu 0x8e [LVM, není nutné]

pvcreate /dev/sdb1 /dev/sdc1 – vytvoření PV

vgcreate vg_strip /dev/sdb1 /dev/sdc1 – VG

pvs

vgs

lvcreate -L 400M -i 2 -n lv_strip vg_strip – LV

ls -l /dev/mapper

ls -l /dev/vg_strip/lv_strip

mke2fs /dev/vg_strip/lv_strip – formátování, připojení

mount /dev/vg_strip/lv_strip /mnt/tst

...

umount /mnt/tst

lvremove vg_strip lv_strip – odstranění LV, VG, PV

vgremove vg_strip

pvremove /dev/sdb1 /dev/sdc1

PVMOVE – přesun dat mezi PV

- **přesun libovolného rozsahu**
- **online operace** – využívá kcopyd (v jádře)
- operaci je možné znovu spustit
  (i po pádu systému)
  metadata obsahují informace o průběhu
- vytváří dočasný RAID1 – **dm-mirror**
- pvmove spustí operaci, dále jen monitoruje
- přesun root – potenciální problémy

redhat

LVM2 – příklad PVMOVE

/dev/sdc1 → /dev/sdd1

pvcreate /dev/sdd1 – rozšíření VG o nový disk

lvs -o +devices

pvs

vgextend vg_strip /dev/sdd1

pvmove /dev/sdc1 /dev/sdd1 – vlastní přesun

pvs

vgreduce vg_strip /dev/sdc1 – odstranění disku

pvremove /dev/sdc1

Užitečné parametry pvmove

- **pvmove --abort** – přeruší probíhající operaci
- **pvmove src:PE-PE dst:PE-PE** – konkrétní rozsah PE
- **pvmove** – (bez parametrů) – pokračuje v poslední operaci

LVM2 snímky (snapshots)

- **(zapisovatelné) snímky na úrovni blokového zařízení** (nezávislé na souborovém systému)
- používá COW (**Copy On Write**) uložiště
- COW je uloženo na disku (specialní LV)
  - prostor pro uložení změněných bloků (**menší než původní LV**)
  - Pozor: zaplněné snímky jsou automaticky zneplatněny !
- LVM2 zatím nepodporuje inkrementalní (diferenciální) snímky
  - vícenásobné snímky stejného LV = obrovské zpomalení
- snímek zatím nelze vrátit na původní LV

redhat

SNAPSHOT I/O

read
- if block unchanged – read origin LV
- otherwise read COW space

write = overwrite old blocks

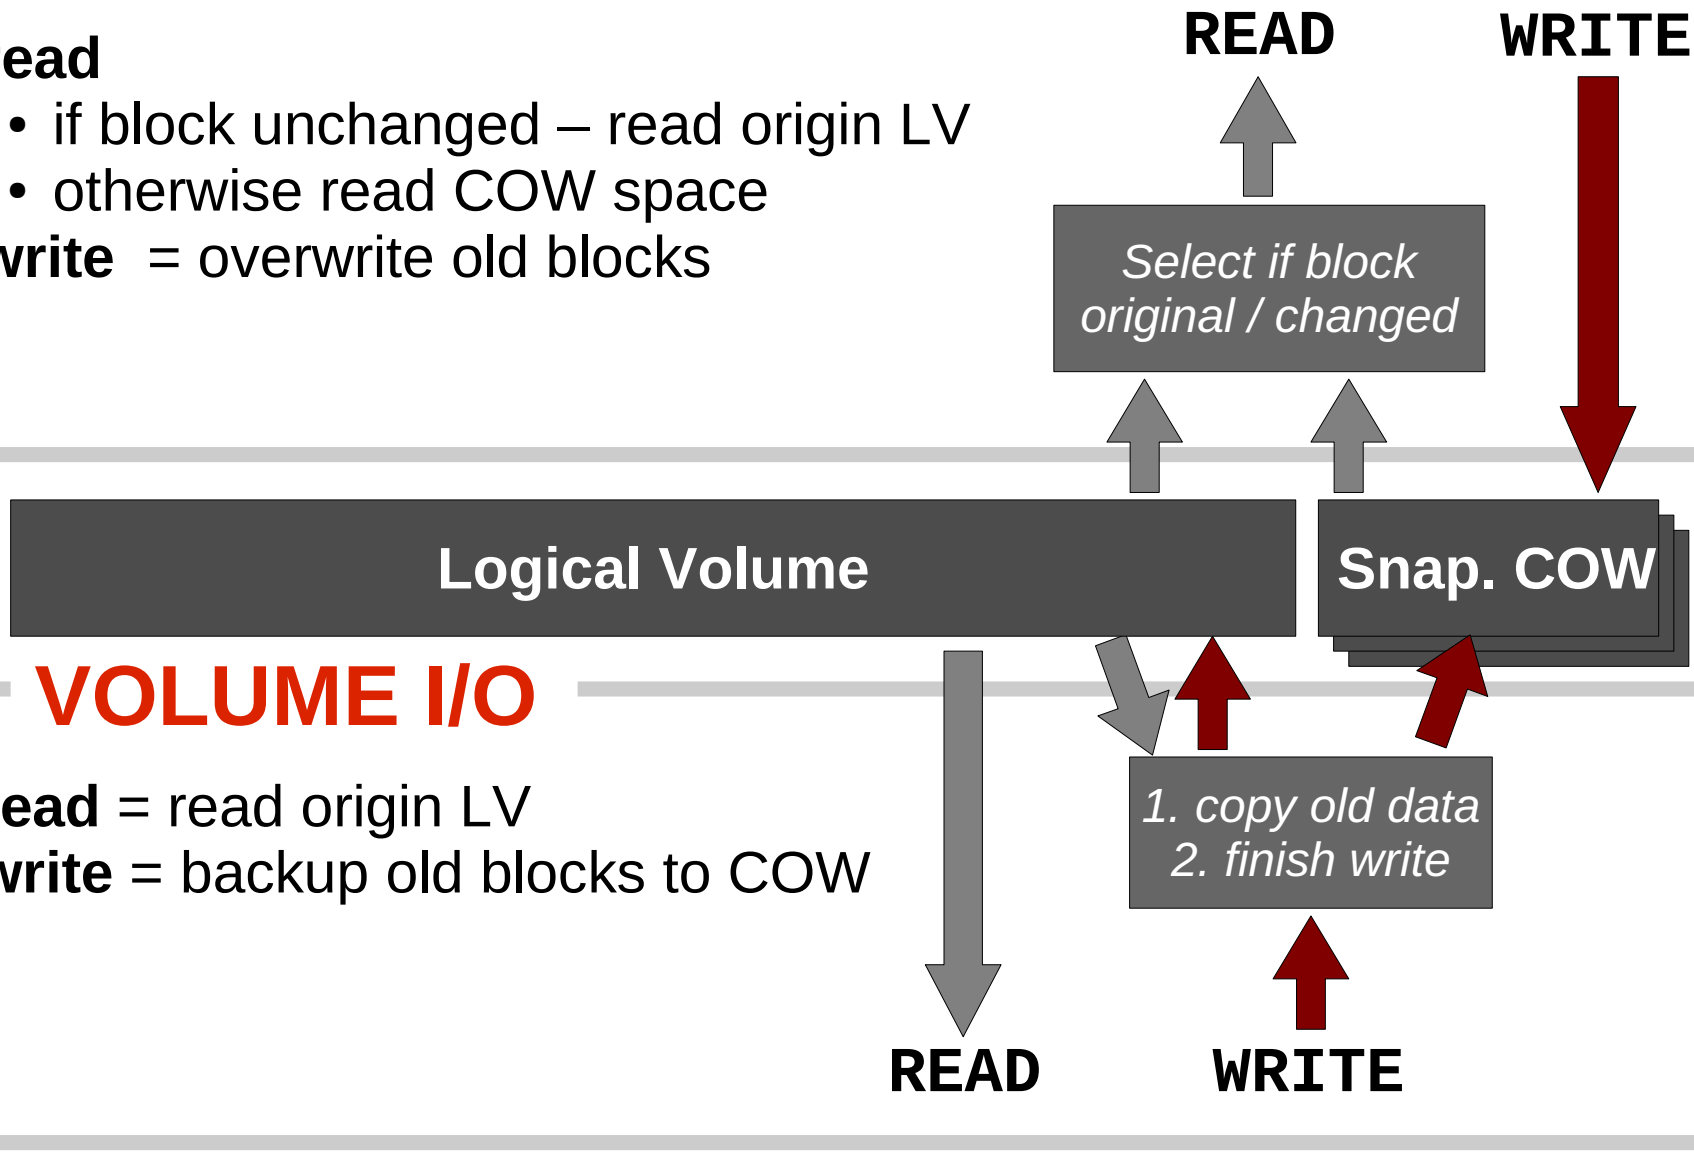

VOLUME I/O

read = read origin LV
write = backup old blocks to COW

LVM2 – vytvoření snímku

`vgextend vg_strip /dev/sdc1` – příprava místa VG (pro snímek)

Vytvoření snímku o velikosti <size> nad lv_strip LV

```
lvcreate -s -L<size> -n lv_snap vg_strip/lv_strip
```

```
mount /dev/vg_strip/lv_snap ...
```

`lvs` – výpis aktivních logických oddílů

- `/dev/vg_strip/lv_strip` – původní oddíl
- `/dev/vg_strip/lv_snap` – zapisovatelný snímek

Změna velikosti logického oddílu

- Je nutné dodržet pořadí operací !

- **Zvětšení logického oddílu**

  (1. rozšíření skupiny oddílů o nové uložiště - disk)
  2. zvětšení logického oodílu
  3. zvětšení souborového systému na logickém oddílu (online)

- **Zmenšení logického oddílu**

  1. zmenšení souborového systému (pokud jde online, jinak offline)
  2. zmenšení logického oddílu

  (3. odstranění prázdného uložistě ze skupiny oddílů)

LVM2 – změna velikosti oddílu ext3

zmenšení na <size>

```
pvs --units k
resize2fs -p /dev/vg_strip/lv_strip <size>K
lvresize -L <size>k /dev/vg_strip/lv_strip
```

použité jednotky se musí shodovat (velikost parametru k a K se zde opravdu liší !)

mount /dev/vg_strip/lv_strip ...

zvětšení na maximum

```
lvresize -l +100%FREE /dev/vg_strip/lv_strip
lvs
df -h
resize2fs -p /dev/vg_strip/lv_strip
df -h
```

Boot proces & LVM2

- **GRUB**
  - částečná podpora LVM2 je až v GRUB2 zavaděči
  - dnešní distribuce používají oddělený startovací (boot) oddíl a initramdisk

- **initrd**
  - obsahuje a zavede ovladače pro fyzické diskové řadiče
  - vytvoří potřebné záznamy v /dev/ (device nodes)
  - zavede ovladače pro device-mapper (a MD)
  - spustí **vgchange -a y** čímž aktivuje logické oddíly
  - nebo spustí **dmraid** a aktivuje ATARAID mapování
  - připojí nový root (který teď již může být na LVM2)

- System boot (součást init skriptů)
  - spustí **vgchange -a y** a aktivuje LVM monitoring démon **dmeventd** (Fedora, RHEL)

Cluster LVM (CLVM)

- **Rozšiřuje funkce o podporu LVM2 v rámci clusteru.**

- Poskytuje infrastrukturu pro manipulaci v rámci sdíleného uložiště, **aktivaci logických oddílů a správu LVM metadat**.

- **clvmd démon**
  vyžaduje DLM (distributed lock manager) a běžící cluster management sw (CMAN, ...)

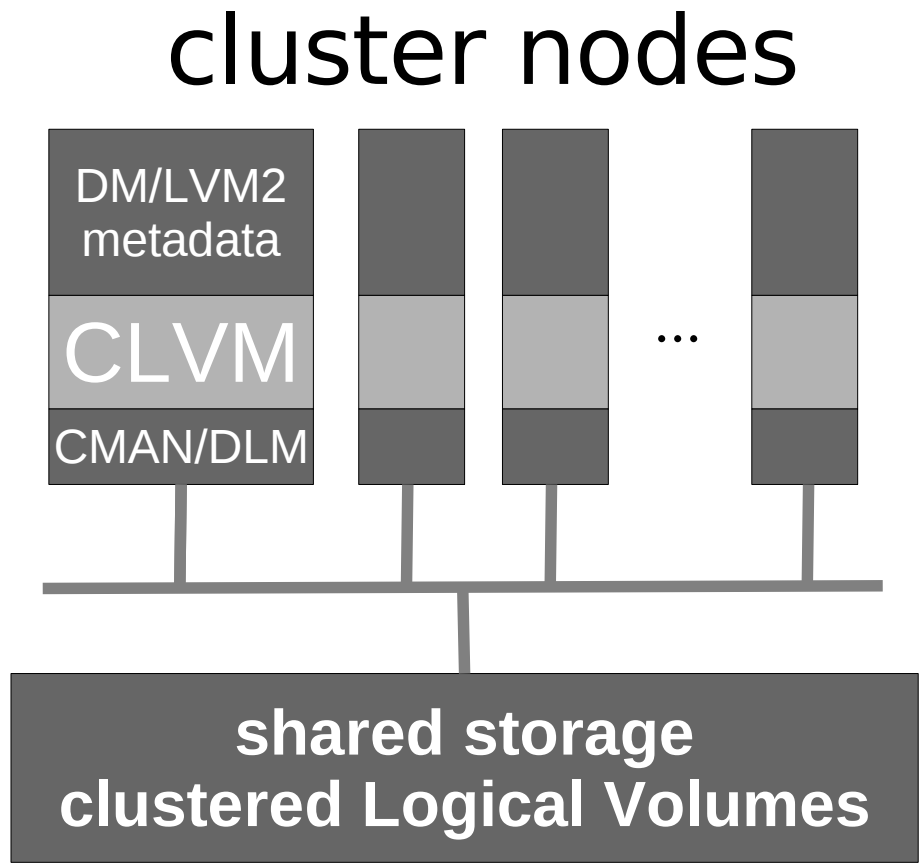

Co je třeba pro LVM v clusteru ?

- **Sdílené uložiště** (blokové zařízení)
  - **SAN** přímo připojený k uzlům (FC)
  - **iSCSI**
  - **GNBD** (Global Network Block Device)
- Volume management – **CLVM**
- clusterový souborový systém, např. **GFS**
- (existují řešení bez CLVM, kdy není třeba současné aktivace)
  - musí se vyhnout konfliktům při přístupu k LVM
  - např. striktní aktivací na jednom uzlu a neměnnými LVM metadaty

Odkazy

Device mapper	http://sources.redhat.com/dm/
LVM2	http://sources.redhat.com/lvm2/
LVM wiki	http://sources.redhat.com/lvm2/wiki
Cluster suite	http://sources.redhat.com/cluster/
dmraid	http://people.redhat.com/heinzm/sw/dmraid/
multipath	http://christophe.varoqui.free.fr/wiki/
dm-crypt	http://www.saout.de/misc/dm-crypt/
EVMS	http://evms.sourceforge.net/