Tecniche per la salvaguardia della disponibilità ed integrità dei sistemi di elaborazione e delle informazioni

1. affidabilità e flessibilità dello storage

Marco Prandini
Università di Bologna

Disponibilità / Downtime

- La *disponibilità* o *availability* di un sistema è il rapporto tra il tempo per cui eroga correttamente i servizi (*uptime*) rispetto al tempo per cui ci si attende che lo faccia (tempo di osservazione)

  A=U/O

- Il tempo durante il quale il servizio non è erogabile viene chiamato *downtime*

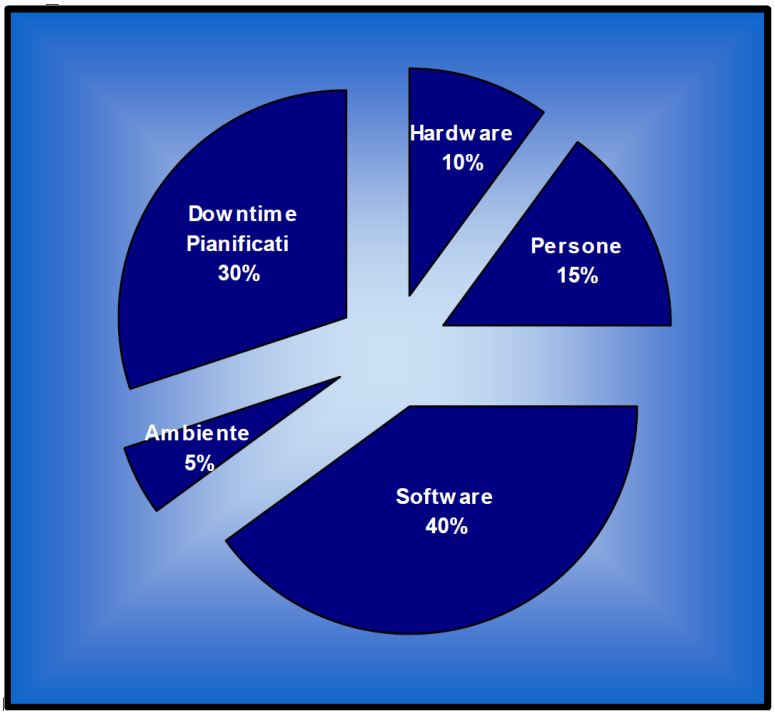

Cause di downtime per incidenza sul totale

Livelli di disponibilità

- Comunemente la disponibilità viene indicata in modo sintetico col "numero di 9" nella percentuale di uptime
  - aggiungere un 9 significa dividere per 10 il downtime

disponibilità %	downtime per anno	downtime per mese	downtime per settimana
98%	7,3 giorni	14,4 ore	3,36 ore
99%	3,65 giorni	7,20 ore	1,68 ore
99,5%	1,83 giorni	3,60 ore	50,4 minuti
99,9%	8,76 ore	43,2 minuti	10,1 minuti
99,99%	52,6 minuti	4,32 minuti	1,01 minuti
99,999%	5,26 minuti	25,9 secondi	6,05 secondi
99,9999%	31,5 secondi	2,59 secondi	0,605 secondi

Service Level Agreement

- La disponibilità è un indicatore sintetico ma non esaustivo
- Un contratto sul livello di servizio (*Service Level Agreement*) può prevedere vincoli più stringenti
  - Sulla distribuzione del downtime (es.: "four nines" nell'arco dell'anno ma in frazioni non superiori a *n* minuti consecutivi)
  - Su parametri di servizio non collegati al downtime
    - Prestazioni dei servizi
    - Tipologie di assistenza previste e loro caratteristiche
    - …
- Oggetto del contratto tipicamente è anche Il contratto stesso
  - Modalità di aggiornamento
  - Reportistica periodica sulle variabili monitorate

Ambiente

Prima di affrontare gli aspetti più propriamente sistemistici, uno sguardo a quel che c'è intorno

- **Per erogare con continuità un servizio, il sistema deve essere acceso e connesso!**
  - Le infrastrutture che garantiscono un ambiente affidabile sono complesse e molto costose → indispensabile condividerle
- ***Data center*** **o** ***server farm*** **sono i luoghi in cui vengono ospitati in grande quantità i sistemi di calcolo**
  - Housing o Co-location: fornitura di spazio e connettività per sistemi acquistati e gestiti dal cliente
  - Managed housing: fornitura dei sistemi in housing (su hardware comunque dedicato al cliente) e loro gestione sistemistica
  - Hosting: fornitura di uno o più servizi specifici (storage, web, posta, …) su hardware condiviso tra più clienti
    - Il modello cloud è un caso speciale dell'hosting tradizionale

Problematiche principali di un data center

- Resistenza della struttura
  - cause naturali: terremoti, inondazioni, …
  - cause artificiali: incidenti aerei e ferroviari, terrorismo, …
  - cause interne: incendi, da controllare con sistemi che consentano l'intervento anche quando l'incendio stesso li danneggia parzialmente
- Sicurezza e controllo degli accessi
- Condizionamento dell'aria
  - gestione di temperatura e umidità con sistemi tolleranti ai guasti e alle interruzioni di erogazione dell'energia elettrica
- Condizionamento dell'alimentazione elettrica
  - erogazione su almeno due linee indipendenti per ogni apparato
  - pulizia della sinusoide per allungare la vita degli apparati
  - sistemi di continuità ad intervento istantaneo e di durata prolungata
    - combinano motogeneratori che possono sopperire a giorni di mancata erogazione, ma richiedono 15-20 minuti per l'avviamento, a sistemi a batteria ad intervento istantaneo ma di bassa capacità
- Connettività di rete
  - connessione tramite provider indipendenti
  - collocazione fisica dei cavi su percorsi indipendenti

Per avere un'idea: http://fibertown.com/houston-colocation-data-center/

Disponibilità – scopo ed estensione

- Disponibilità di un sistema o di un'informazione è la possibilità di accedervi quando necessario → il riferimento temporale è importante nelle scelte progettuali
  - disponibilità istantanea o continua
  - disponibilità a lungo termine
- Per garantire la disponibilità continua di un sistema si può agire
  - sulla costruzione dei componenti
    - es. tecnologia meccanica, grading dei componenti elettronici
    - riduce il Mean Time To Failure (MTTF) o Mean Time Between Failures (MTBF)
  - sull'architettura
    - eliminazione dei **single point of failure** per mezzo della **replicazione**
    - introduce complessità, oltre certi limiti richiede una riprogettazione globale
  - ove possibile, si agisce sull'architettura, ma in modo da produrre componenti autocontenuti che non differiscano "ai morsetti" da quelli tradizionali
    - es. memorie ECC, wear-leveling SSD

Disponibilità continua dei dati

- Cosa vedremo in questa parte di presentazione

1) Un rapido sommario delle tecniche di replicazione ed accesso ai dati
   - RAID
   - Multipath
   - Filesystem distribuiti
2) Un'illustrazione dei principali strumenti di Linux per implementarle
   - md/dm
   - DRBD
   - NFS
   - GFS

RAID

- Il componente più soggetto a guasti è quello sollecitato meccanicamente: l'hard disk
- La tecnologia più diffusa per proteggere un sistema dal guasto di un disco è RAID (Redundant Array of Independent Disks)
  - il costo di un disco cresce più rapidamente del MTTF
  - per quanto sofisticato, un disco cede spesso senza preavviso
  - anzichè investire su di un disco più robusto, si combinano N dischi economici in modo che il fallimento di uno di essi non comprometta il funzionamento dell'unità logica risultante
  - complessità aggiuntiva: gestione dei metadati di allocazione dati
- Implementazioni
  - HW: il controller sgrava la CPU dei calcoli necessari e nasconde al sistema operativo i dettagli, mostrando l'analogo di un disco; può assistere nel mantenere la coerenza dei dati in caso di crash
  - SW: economico, sfrutta i cicli idle della CPU

RAID levels

Tutte le immagini sono tratte da Wikipedia (http://en.wikipedia.org/wiki/RAID), realizzate da Colin M.L. Burnett (http://en.wikipedia.org/wiki/User:Cburnett), e pubblicate in accordo alla licenza CC Attribution-Share Alike

- RAID0 – STRIPING
  - distribuisce, non replica, i dati tra tutti i dischi dell'array
    - un guasto corrompe l'intero array → non esattamente un RAID
  - usato per incrementare le prestazioni
    - se il collo di bottiglia è il throughput del singolo disco, *B* bytes scritti dal sistema incidono per *B/N* bytes su ciascuno degli N dischi

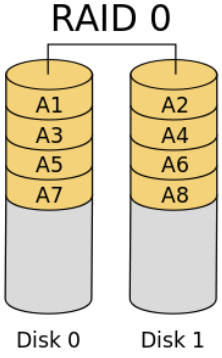

- RAID1 – MIRRORING
  - replica ogni dato identico su tutti i dischi dell'array
    - basta che un solo disco sopravviva per mantenere i dati
    - fornisce un incremento di velocità in lettura perchè dati diversi possono essere letti contemporaneamente da dischi diversi
    - costoso in termini di capacità

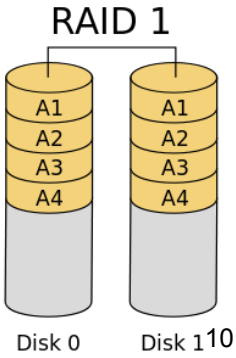

RAID levels

- Striping con ridondanza
  - mutuato dal RAID0
    - un dato viene suddiviso in “striscioline” destinate a diversi dischi
  - a partire dalle diverse **stripe** (o segment), un algoritmo genera uno o più dati aggiuntivi, che vengono scritti su altrettanti dischi aggiuntivi, e permettono di ricalcolare una o più stripe originarie in caso di perdita
  - per le prestazioni è cruciale la relazione tra dimensioni delle stripe, dimensioni dei blocchi gestiti su disco, ed algoritmo di calcolo

RAID levels

- RAID2/3/4 – diversi tipi di sistemi a correzione d'errore
  - 2: Hamming code per correggere anche errori multipli
  - 3: bytewise striping con parità su disco dedicato
  - 4: blockwise striping con parità su disco dedicato
  - sostanzialmente in disuso
  - caratterizzati dalla presenza di dischi dedicati ai dati e dischi dedicati alle informazioni per la correzione degli errori
    → **collo di bottiglia**

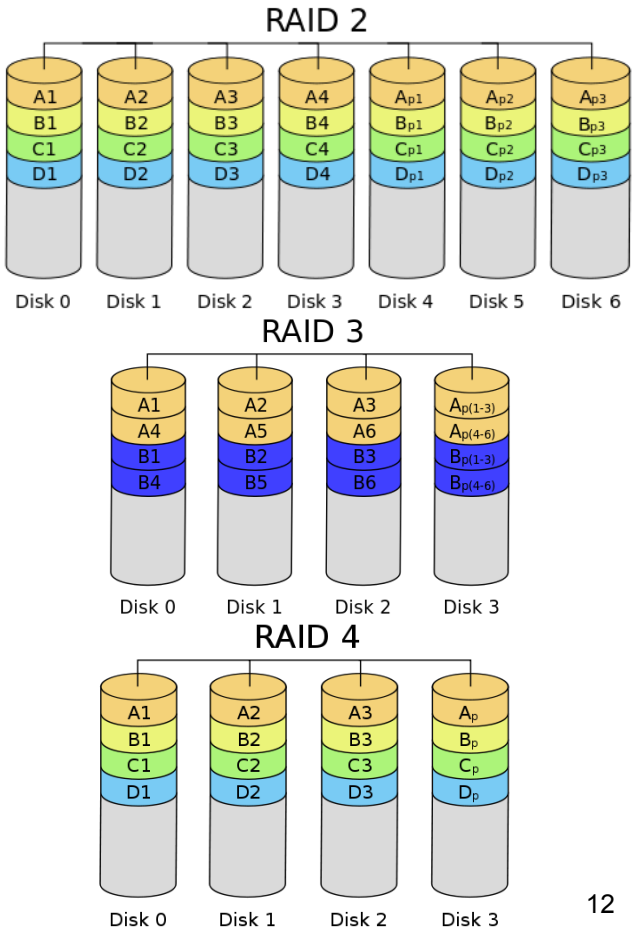

RAID levels

- RAID5 – DISTRIBUTED PARITY
  - ogni blocco di dati viene elaborato per produrre 1 blocco di parità
  - con N-1 frammenti qualunque, si può ricostruire il blocco originario
    - prestazioni simili allo striping, ma con tolleranza al guasto di un disco
- Read-in
  - Per aggiornare la parità "p" quando cambia un dato "d" si esegue: new_p = old_p ⊕ old_d ⊕ new_d
  - due letture e due scritture di intere stripe
  - molto penalizzante per scritture piccole (dim. blocco << dim. stripe)

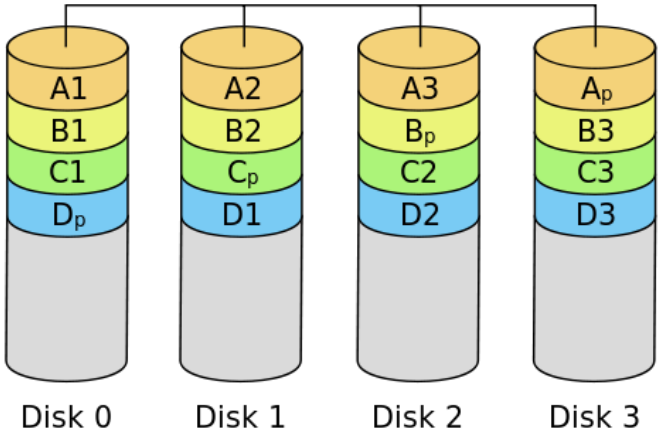

Recovery & Reconstruction

- Quando un disco si guasta, l'array funziona in degraded mode
- Ogni lettura deve coinvolgere tutti dischi e deve essere ricalcolato il dato perso applicando l'algoritmo di correzione d'errore
  - Fa eccezione il RAID1 in cui ogni disco ha una copia di tutti I dati
- Se si tratta di una disconnessione temporanea, alla riconnessione si avvia la procedura di resync
  - se i metadati sono coerenti e aggiornati, si identificano solo i blocchi da aggiornare ricalcolandoli dagli altri dischi
- Quando il disco deve essere sostituito, la procedura di recovery viene applicata all'intero contenuto dell'array per ripopolare il nuovo disco: reconstruction o rebuild
  - con le dimensioni dei dischi attuali può richiedere decine di ore
  - carico elevato, su dischi tipicamente identici per marca, modello ed età

  → rischio di ulteriore guasto, irrecuperabile in RAID5
  - basta anche UN settore illeggibile, che è quasi una certezza nei sistemi low-end caratterizzati da grandi dischi poco costosi (i sistemi di fascia media e alta tipicamente usano dischi più performanti ma per questo più piccoli, ma l'avanzamento tecnologico sta chiudendo il gap)
    - URE (unrecoverable read error rate) tipico dischi SATA = 1 ogni $2*10^8$ settori
    - in un array da 6 dischi x 2TB ci sono circa $2*10^{10}$ settori…
    - soluzione: controllo periodico dei settori danneggiati (pesante ma salvifico)

RAID levels

- **RAID6 – DISTRIBUTED DOUBLE PARITY**
  - ogni blocco di dati viene elaborato per produrre 2 *sindromi*
  - con N-2 frammenti qualunque si può ricostruire il blocco originario
    → tolleranza al guasto contemporaneo di due dischi

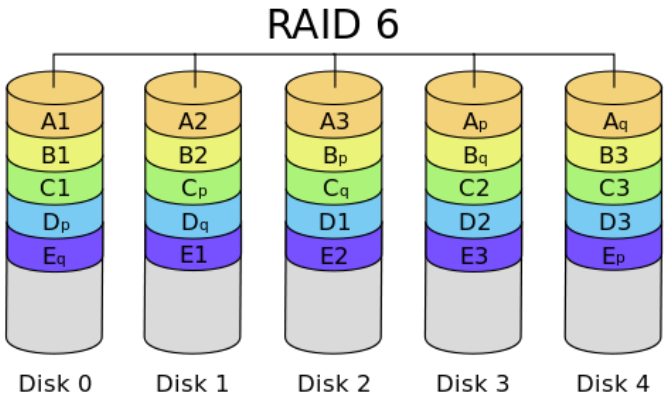

RAID – tabella riassuntiva

LIVELLO	CAPACITA'	GUASTI TOLLERATI	PRESTAZIONI TEORICHE	TASSO DI GUASTO	Esempio per r=1% e N=6
0	N	0	Nx(R*,W)	$1-(1-r)^N$	5.8%
1	1	N-1	Nx(R)	r^N	10^{-12}
5	N-1	1	(N-1-oh)x(R*,W^)	$(1/2)N(N-1)r^2$	0.15%
6	N-2	2	(N-2-oh)x(R*,W^)	$(1/6)N(N-1)(N-2)r^3$	0.002%

N=numero dischi
R=velocità base in lettura
W=velocità base in scrittura
oh=overhead computazionale
r=tasso di guasto del singolo disco

* ma attenzione al seek time
^ a volte molto peggiori se necessario read-in, specialmente per RAID6

RAID – livelli composti

- Con un elevato numero di dischi non è sensato comporre un unico array
  - con RAID0 intollerabile rischio di guasto
  - con RAID1 intollerabile spreco di capacità
  - con RAID5 discreto rischio di guasto doppio e problemi di calcolo
- Un RAID viene visto come un block device → può essere trattato come un disco con cui costruire un altro RAID
- Tipicamente
  - un livello è RAID0
    - aggrega i dischi senza spreco di capacità
    - moltiplica il transfer rate
  - un livello sopperisce alla diminuita robustezza
    - RAID1 (→ RAID 10) o RAID5 (→ RAID 50)

RAID – spare disks

- Negli aggregati composti da un gran numero di dischi, le probabilità di fallimenti multipli contemporanei sono significative
  - casi particolarmente gravi: design difettoso su banchi di dischi tutti dello stesso modello
- Problema: intervenire in tempi rapidi (→ automaticamente) alla segnalazione di un fail
  - RAID6
    - penalità di prestazioni rispetto al RAID5
    - non risolve il problema oltre un certo numero di dischi
  - HOT SPARES: dischi presenti nell'array ma non normalmente usati, che sostituiscono automaticamente un disco failed
    - richiesto tempo di rebuild
    - nessun impatto durante il funzionamento normale
    - condivisibili tra molti array per ottimizzare i costi

RAID – quanti dischi e quale layout?

- RAID5 è il miglior compromesso prezzo-prestazioni ma con le dimensioni attuali può essere molto rischioso
- RAID6 è meno efficiente e comunque è consigliabile uno spare disk per sostituire immediatamente un failed disk
- Tipica enclosure da 12 slot:

  - 2 array RAID6 + spare: 6 dischi utili + 5 o 6 di sicurezza

Data	Data	Data	Parity	Parity	Data	Data	Data	Parity	Parity	Spare	Empty/ Spare

  - Alternativa RAID10 (striping su 5 mirror di 2 dischi + spare)
    - Capacità -16%
    - Tasso di guasto molto simile
    - Minori problemi di rebuild
    - Prestazioni più omogenee per pattern di uso variegati

Multipath

- Oltre alla ridondanza dei dischi, può essere necessario prevedere tolleranza ai guasti
  - dei componenti di controllo
  - dei percorsi di connessione
- Necessario:
  - hardware che permette di creare più percorsi di accesso allo stesso disco
  - supporto O.S. per gestire correttamente la molteplicità di percorsi
    - in Linux sia *md* che *dm* (oltre a driver proprietari)

Multipath – hardware necessario

- Percorso disco-controller
  - Dischi FC-AL: due connettori in/out per predisporre un loop
  - Dischi SAS *dual port*: due porte da innestare su due backplane
  - Porte diverse possono andare a porte multiple del controller o a controller separati

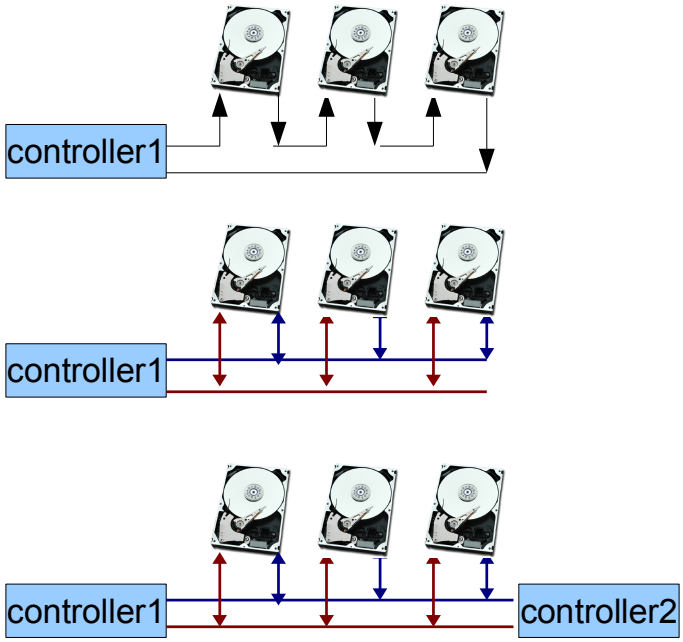

Multipath – hardware necessario

- Controller
  - Può essere installato in locale sull'host o essere collegabile in rete
    - Può disporre di una molteplicità di porte di rete

- Percorso controller-host via rete
  - Raramente diretto, solitamente via switch
  - Se sono presenti più porte di rete per controller e per host, possibilità di duplicare gli switch

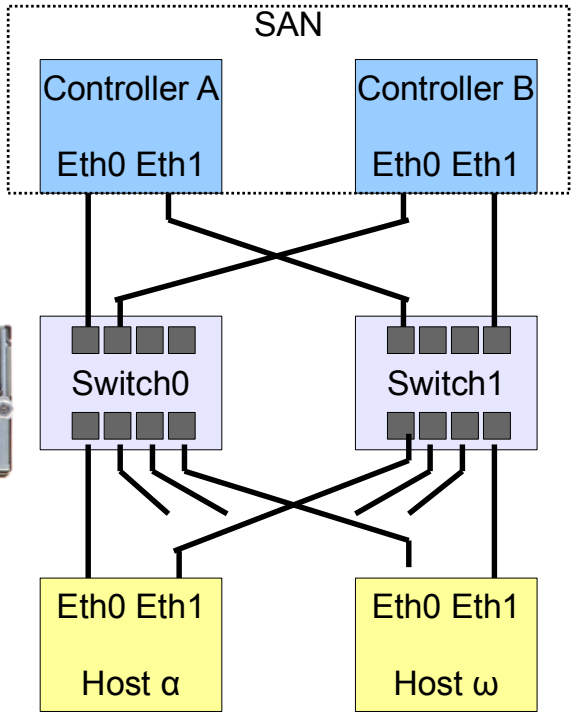

Distributed Filesystems

- Un componente essenziale per la realizzazione di sistemi scalabili ed affidabili è un sistema di storage condiviso
- Esistono due grandi approcci: NAS e SAN
- NAS
  - i dati sono su di un sistema che li conserva in un ***filesystem*** locale
  - i dettagli del filesystem sono pressochè trasparenti ai client
  - esiste un protocollo client/server per l'erogazione dei ***file***
  - i client operano senza cooperare tra loro
    - punto di forza: la cooperazione può essere complessa e dare problemi di consistenza in caso di guasto
  - L'implementazione classica di NAS cambia a seconda del S.O.
    - Nel mondo UNIX è fatta tipicamente tramite il protocollo NFS
    - Nel mondo Microsoft tramite il protocollo CIFS

Distributed Filesystems

- SAN
  - i dati sono su di un sistema che li conserva allo ***stato grezzo***
  - esiste un protocollo client/server per l'erogazione dei ***blocchi***
    - punto di forza: il protocollo è più leggero, ed esistono implementazioni per garantire alta efficienza, scalabilità e robustezza in HW (trasparente al S.O.)
  - il filesystem è quindi definito dai client, che devono cooperare perchè l'accesso concorrente al dispositivo non causi inconsistenza e corruzione dei dati
    - per mezzo di sistemi di locking distribuito ...
      - CLVM (Clustered Logical Volume Manager)
    - ... ed eventualmente di *cluster filesystem*
      - RedHat GFS (Global File System)
      - IBM GPFS (General Parallel File System)
      - Oracle OCFS (Oracle Cluster File System)
  - Le tecnologie SAN più diffuse sono
    - AoE (ATA over Ethernet), economico, molto efficiente, solo LAN, MAC auth.
    - iSCSI, instradabile, auth sofisticata, pesante, un po' più costoso
    - FC-AL, molto scalabile, infrastruttura dedicata costosissima

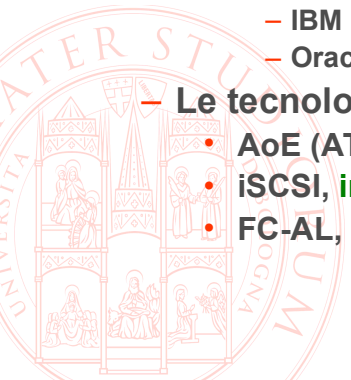

Supporto multi-device in Linux

- multi-device support: una generalizzazione del RAID
  - far cooperare più dispositivi reali per presentare all'utente un dispositivo virtuale con caratteristiche migliori
- Linux offre due sistemi di driver
  - md (multiple devices)
    - erede degli storici raidtools
    - orientato alla costruzione di RAID software
    - supporto al multipath
    - *http://www.linuxfoundation.org/collaborate/workgroups/linux-raid*
  - dm (device mapper)
    - architettura più generale
    - fondazione per diverse funzionalità
      - multipath
      - logical volume management (LVM)
      - volumi cifrati
    - supporto RAID limitato a 0, 1, linear
      - tool per l'integrazione con i controller ATARAID
    - *http://sources.redhat.com/dm/*

Software RAID in Linux con md

- md supporta nativamente
  - linear
  - raid level standard 0, 1, 4, 5, 6
  - raid 10 (sperimentale)
    - più efficiente che sovrapporre manualmente uno strato di striping ad una serie di coppie di dischi in mirror
    - resta comunque la possibilità di combinare dispositivi md per formare altri livelli composti
  - multipath
  - faulty
    - per testing, o far pratica con situazioni di guasto
- driver modulare nel kernel
  - si possono caricare singolarmente, oltre al modulo base, i moduli per i diversi livelli
    - 4/5/6 sono in un unico modulo

Software RAID in Linux con md

- Il driver permette di combinare qualsiasi *block device* per formare un nuovo *md block device*, che può essere usato come se fosse un normale disco

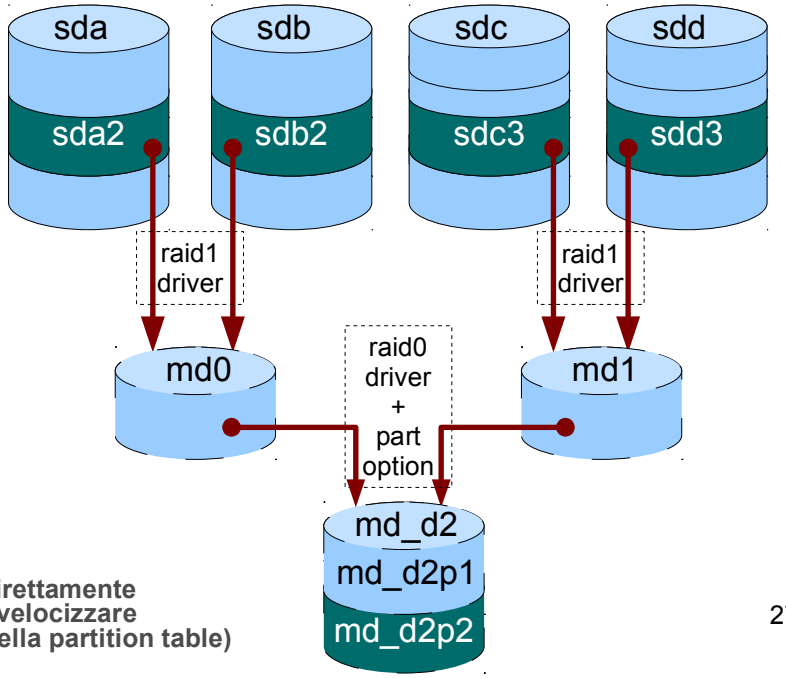

  - può rientrare come device membro di un altro array md
  - può essere partizionato purchè predisposto alla creazione

(di solito si creano md per usarli direttamente come volumi, quindi il default è di velocizzare l'accesso eliminando la gestione della partition table)

Software RAID in Linux con md

- Il tool per la configurazione e gestione degli array è *mdadm*. Opera in 7 modi diversi:
  - *Create*: creazione di un nuovo array ed inizializzazione dei superblock
  - *Assemble*: avvio di un array esistente (tipicamente al reboot)
  - *Follow/Monitor*: monitoraggio continuo dello stato dell'array
  - *Build*: creazione di un nuovo array senza inizializzazione dei superblock (non potrà essere riassemblato automaticamente successivamente – solo per casi particolari)
  - *Grow*: riconfigurazione della geometria, es:
    - cambiamento della dimensione dei componenti di un RAID 1/4/5/6
    - cambiamento del numero di device attivi in un RAID1.
  - *Manage*: aggiunta di nuovi dischi spare, rimozione di dischi failed
  - *Misc*: everything else...

Software RAID in Linux con md

- Il persistent superblock
  - è presente su tutti i dischi dell'array
  - contiene metadati
    - sulla struttura dell'array
    - sullo stato dell'array
    - sullo stato di consistenza del disco rispetto all'array
  - consente la rilevazione automatica
    - riassemblaggio senza bisogno di ricorrere a file di configurazione
    - uso di UUID: indipendenza dai nomi fisici dei dispositivi
    - ancora il default, ma deprecato
- È sempre bene avere un file `/etc/mdadm.conf` allineato alla configurazione del sistema
  - può essere creato con
    `mdadm --detail --scan > /etc/mdadm.conf`

Software RAID in Linux con md

- Esempi di base
  - inizializzazare un array:

```
mdadm --create --verbose /dev/md0 --level=0 –raid-devices=2  /dev/sdb1 /dev/sdc1
```

  - avviare un array già inizializzato

```
mdadm -As /dev/md0 /dev/sdb1 /dev/sdc1
```

  - arrestare un array

```
mdadm -S /dev/md0
```

  - rimuovere un disco da un array

```
mdadm /dev/md0 --fail /dev/sdc1 --remove /dev/sdc1
```

  - aggiungere “in corsa” un disco ad un array senza cambiarne la struttura
    - riaggiungere un disco precedentemente rimosso
    - aggiungere un hot spare

```
mdadm /dev/md0 --add /dev/sdc1
```

  - avviare il demone di monitoring

```
mdadm --monitor -f --mail=root@localhost --delay=1800 /dev/md0
```

Software RAID in Linux con md

- Per vedere lo stato degli array in funzione:

```
# cat /proc/mdstat
   Personalities : [raid0] [raid1]
   md0 : active raid0 sdc1[1] sdb1[0]
        20352 blocks 64k chunks
```

- Maggiori dettagli
  - su di un array

```
mdadm --detail /dev/md0
```

  - su di un componente

```
mdadm --examine /dev/sdc1
```


Software RAID in Linux con md

- Quando le cose vanno male, ma non troppo (i.e. è fallito un numero di dischi che, in virtù del livello di RAID scelto, consente all'array di continuare ad operare
  - *recovery*: si popola un nuovo disco da cima a fondo coi dati letti dagli altri
  - *resync*: si aggiorna un disco che già faceva parte dell'array con i soli dati cambiati
- Quando si sfiora il disastro (i.e. risulta fallito un numero di dischi che, in virtù del livello di RAID scelto, non lascia dati sufficienti per il funzionamento)
  - può capitare se il fail multiplo è causato ad esempio da un canale del controller (ovviamente se sono veramente rotti i dischi non c'è nulla da fare)
  - il disallineamento dei superblock previene l'assemblaggio dell'array
  - si può tentare un recovery forzato
    1) si rendono nuovamente accessibili i dischi
    2) con `mdadm -E` si verifica quale ha (quali hanno per raid6) l'event count più basso e lo/li si marca failed nel file di configurazione
    3) con `mdadm --assemble --force` si forza il riassemblaggio; se i danni non sono gravi, dai dischi più aggiornati si può ricostruire l'array

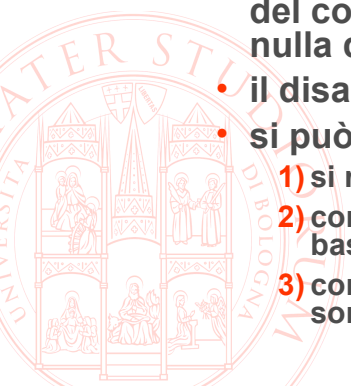

Device mapper

- Il device mapper (dm) è un modulo del kernel che, in termini generali, mappa un block device su altri secondo una data politica.
  - un *target driver*
    - espone un block device virtuale (*mapped device*)
    - è associato a dei block device virtuali o reali sottostanti (*target devices*)
  - in userspace si definisce la politica per *mappare i singoli blocchi del mapped device sui blocchi dei target*
  - i device sono pienamente impilabili

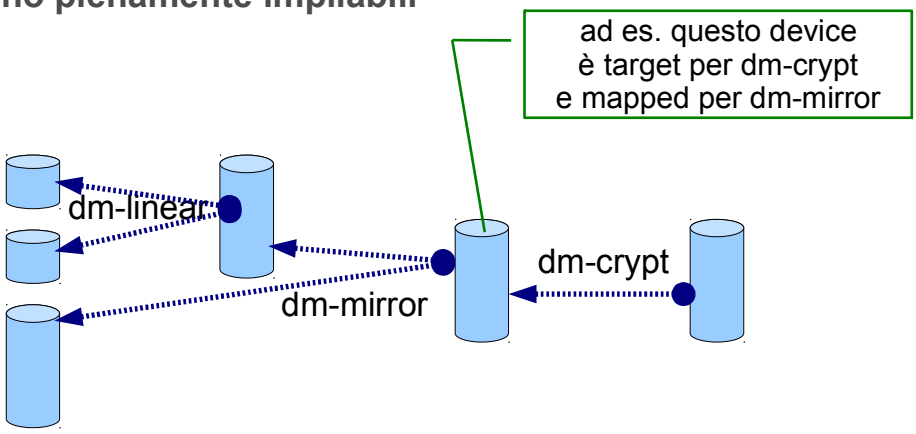

Device mapper

Essenzialmente: tramite tool userspace

- **si scelgono i target**
- **si mappano i blocchi dei mapped sui target**

Userspace Architecture

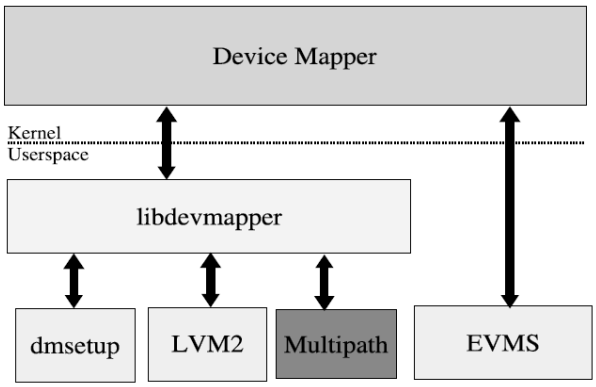

Device Mapper Kernel Architecture

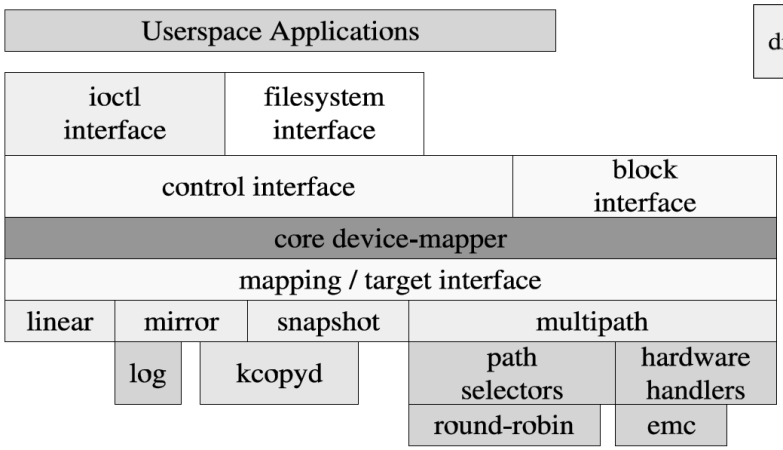

... poi i moduli kernel si occupano di smistare i dati

- **secondo un certo algoritmo**
- **sui target configurati**
- **seguendo le mappe**

Device mapper

- Il tool userspace di base è dmsetup; dati in ingresso
  - un target driver
  - un elenco di target device
  - una tabella di mapping compatibile col driver

  configura un mapped device su cui si può leggere e scrivere, provocando in realtà letture e scritture sui target device in accordo alla tabella di mapping

  e naturalmente può deconfigurarlo, dare informazioni, ...
- I target driver attualmente disponibili sono
  - *linear*: concatenazione di target device
  - *striped*: distribuzione di blocchi attraverso i target device
  - *mirror*: replicazione di blocchi sui target device
  - *multipath*: selezione del percorso di accesso ai target device
  - *snapshot*: stacking di target device con accesso copy-on-write
  - *crypt*: cifratura e decifrazione trasparente dei dati sul target dev.
  - *error:* simulazione di errori ai fini di testing

Device mapper

- Esempio 1
  (tabelle da preparare per il comando `dmsetup create mydev <tabella>`, che crea il mapped device `/dev/mapper/mydev` – supponiamo di disporre di un disco hda di 1028160 settori ed un disco hdb di 3903762 settori)
- unire i dischi hda ed hdb insieme uno di seguito all'altro

```
0          1028160 linear    /dev/hda     0
1028160    3903762 linear    /dev/hdb     0
```

mydev start | num sectors | target driver | target device | target dev. start sector

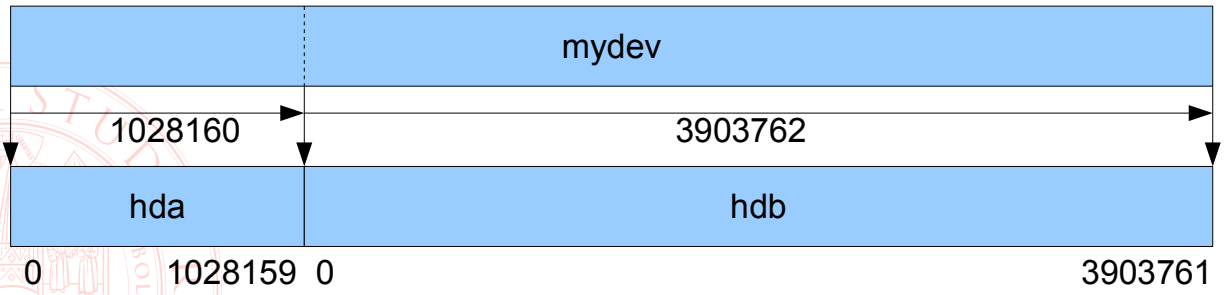

Device mapper

- Esempio 2
  (tabelle da preparare per il comando `dmsetup create mydev <tabella>`, che crea il mapped device `/dev/mapper/mydev` – supponiamo di disporre di un disco hda di 1028160 settori ed un disco hdb di 3903762 settori)
- distribuire i dati in striping tra hda ed hdb ed aggiungere in coda lo spazio residuo di hdb

num stripes

chunk size

=1028160*2

```
0        2056320 striped 2 32 /dev/hda 0 /dev/hdb 0
2056320  2875602 linear /dev/hdb 1028160
```

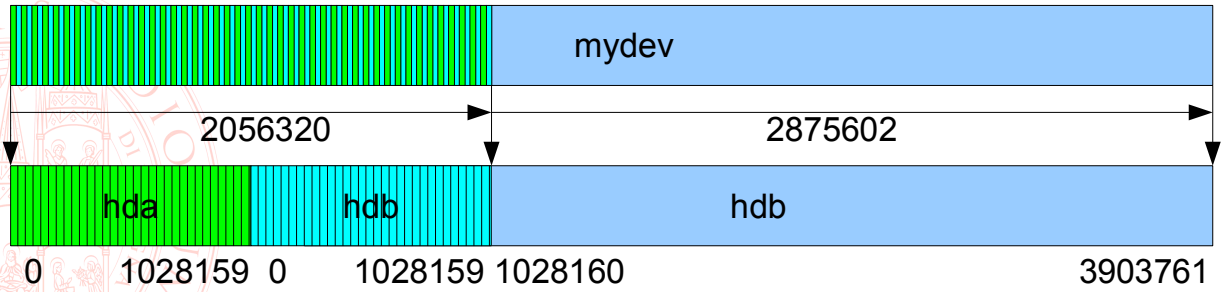

Device mapper – target applications

- Sebbene sia possibile utilizzare dmsetup direttamente anche per fini complessi, esistono alcune applicazioni di più alto livello che permettono di gestire in modo potente task di particolare utilità
- Per l'alta disponibilità:
  - dmraid (specifico per l'utilizzo di controller ATARAID)
  - *dm-multipath*
- Per sicurezza e flessibilità d'uso dei device
  - dmcrypt
  - *LVM2*

Device mapper – multipath

- Percorsi multipli di accesso allo storage:
  - Il kernel riconosce ogni path come un block device indipendente
  - Il comando **`multipath`** interroga i device, riconosce che sono "incarnazioni" della stessa periferica, e genera un block device virtuale
  - Il demone **`multipathd`** reindirizza il traffico in caso di path failure

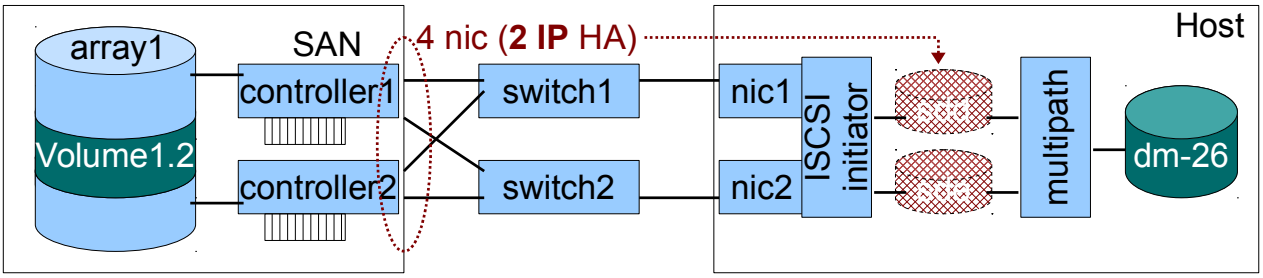


```
# multipath -v 2 -l
mpath5 (36006048c6f2a4f0ca673c9d09e909be5) dm-26 EMC,Celerra
[size=1.0T][features=0][hwhandler=0][rw]
\_ round-robin 0 [prio=0][active]
 \_ 24:0:0:0 sdd 8:48  [active][undef]
\_ round-robin 0 [prio=0][enabled]
 \_ 25:0:0:0 sde 8:64  [active][undef]
```

Device virtuale

Politica di accesso

Device reali

Device mapper – multipath

- Esempi di aspetti parametrizzabili (`/etc/multipath.conf`)
  - Come determinare lo stato di salute di un path
    - Con che frequenza testare
    - Con che metodo (lettura disco, driver hw specifici, ...)
  - Come smistare il traffico in condizioni normali e di path failure
    - Politiche di bilanciamento
    - Politiche di priorità
    - Accodamento in caso di total failure vs. segnalazione errore
  - Come gestire la riattivazione di un path
    - Failback immediato o manuale
  - Quali device (non) testare per verificare se rappresentano path alternativi verso un unico storage

Device mapper – LVM2

- Tutti i sistemi visti
  - mettono a disposizione un disco fisico
  - il disco viene rigidamente partizionato in unità logiche
- Manca la cosa forse più semplice: astrarre la gestione dello spazio disponibile
- LVM (Logical Volume Manager)
  - vede i device come PV
  - raggruppa i PV in VG
  - preleva flessibilmente spazio dai VG per definire LV

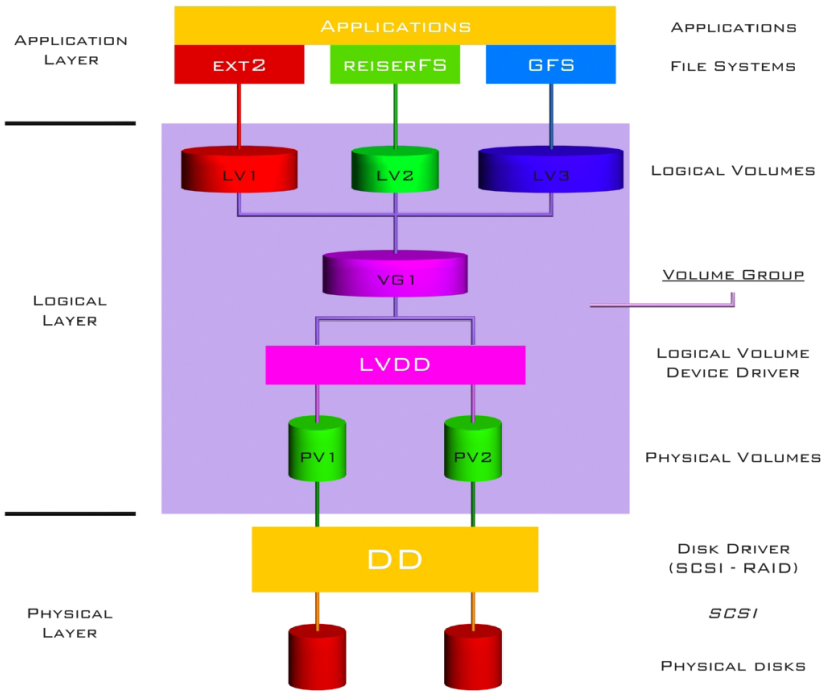

Device mapper – LVM2: elementi

- Physical Volume (PV)
  - l'astrazione LVM dei dischi fissi o partizioni o loopback device o md device
  - sono semplicemente i block device inizializzati con metadati nel settore Volume Group Descriptor Area (VGDA)
- Volume Group (VG)
  - la più alta astrazione di volume ottenibile con LVM.
  - unisce sotto di se una collezione di Logical Volume (LV) e Physical Volume (PV) in un unica unità amministrativa
  - visto dal sistema come un grande disco logico, scomponibile in più partizioni, anch'esse logiche, come i Logical Volume (LV) formati dallo spazio fisico dei PV che compongono il VG.
- Logical Volume (LV)
  - estende il concetto di partizione standard
  - il sistema riconosce i LV come normali block device locali
  - sui LV vengono creati i file system

Device mapper – LVM2: mappature

- I VG sono visti come collezioni di Physical Extent (PE)
  - i PE sono materialmente sui PV
- I LV sono visti come sequenze di Logical Extent (LE)
  - i LE sono in corrispondenza 1:1 con i PE

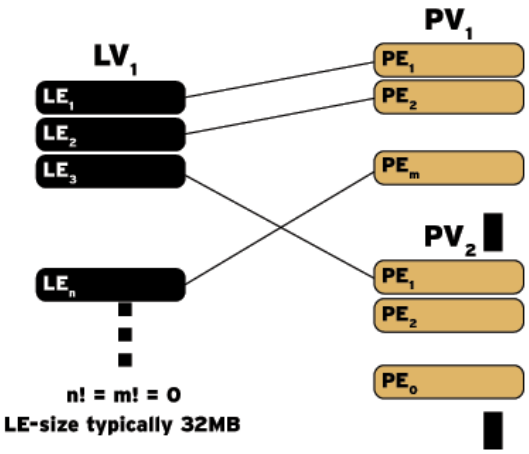

  - la mappatura può essere di vari tipi, es:
    - lineare

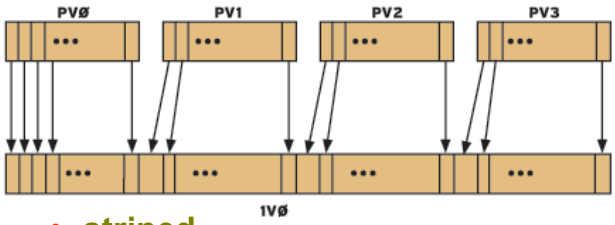

    - striped

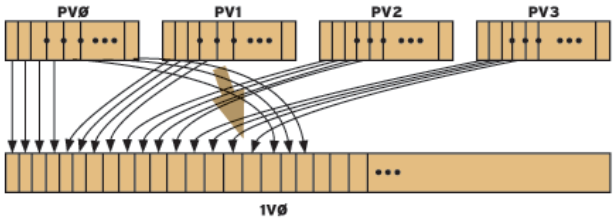

Device mapper – LVM2: vantaggi

- LVM è basato su dm e quindi può avvalersi delle sue funzioni
  - mappature orientate alla ridondanza o alle prestazioni
  - snapshot
- LVM ha un'interfaccia userspace molto più ricca di dmsetup
  - implementa tali funzioni, che richiederebbero lunghe ed accurate sequenze di comandi, in modo semplice e robusto
- LVM presenta ai gestori dei filesystem device
  - che possono essere ridimensionati online
  - i cui guasti fisici (se tollerabili) possono essere riparati trasparentemente
    - è possibile sostituire i PV che compongono un LV mentre questo funziona

Device mapper – LVM2: creazione di volumi

```
fdisk → tag sda2 0x8e
pvcreate /dev/sda2
pvcreate /dev/sdb
pvcreate /dev/sdc
vgcreate vg1 /dev/sda2 /dev/sdb
lvcreate -n lv1 --size 2G vg1
vgextend vg1 /dev/sdc
lvcreate -n lv2 --size 20G vg1
mkfs.ext3 /dev/mapper/vg1-lv1
mkfs.ext3 /dev/mapper/vg1-lv2
mount /dev/mapper/vg1-lv1 /
mount /dev/mapper/vg1-lv2 /home
mount /dev/sda1 /boot
lvextend -L+2G /dev/vg1/lv2
resize2fs /dev/vg1/lv2
```

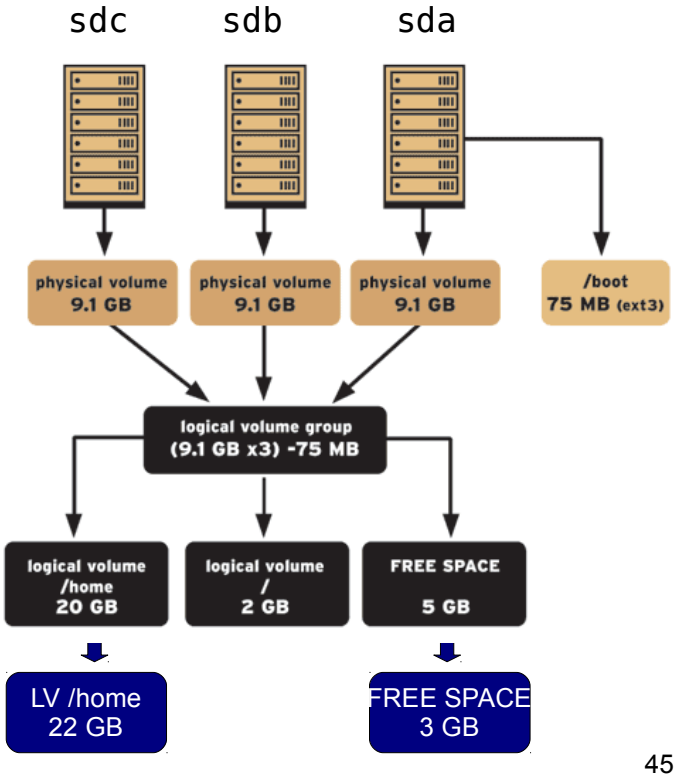

Device mapper – LVM2: altri comandi utili

- Visualizzare le risorse
  - [pv|vg|lv]display
- Rimuovere risorse
  - [pv|vg|lv]remove
- Scansione dei dischi alla ricerca di elementi LVM
  - [pv|vg|lv]scan
- Operazioni sui LV
  - lvconvert (per snapshot o gestione mirror)
  - lvresize

Device mapper – LVM2: snapshot

- Snapshot: creazione di una copia virtuale di un LV che fotografa il suo contenuto in quell'istante
  - ad es. per fare backup senza problemi di inconsistenza dei file

```
lvcreate -L592M -s -n dbbackup /dev/ops/databases
```

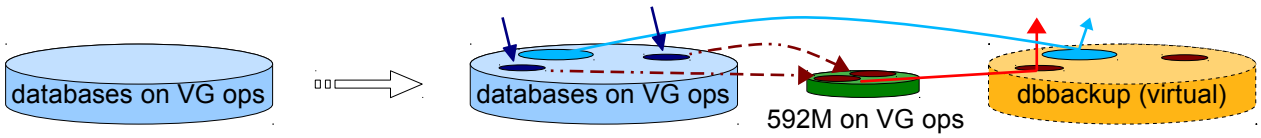

ogni scrittura su databases provoca il salvataggio del settore originale sullo spazio di snapshot
la lettura su dbbackup di un settore modificato viene fatta dallo snapshot
la lettura su dbbackup di un settore non modificato viene fatta da databases

  - al termine, si prosegue ad operare semplicemente rimuovendo dbbackup
  - è possibile attivare in sequenza vari snapshot
    - si possono implementare politiche di rollback point-in-time

Device mapper – LVM2: snapshot

- è possibile accedere in RW agli snapshot
  - uso opposto al precedente
    - non tocco l'originale (potrebbe essere RO, utile per creare tanti filesystem poco differenziati su una base comune)
    - le scritture sullo snapshot sono allocate sullo "spazio a perdere" (quindi in questo caso la rimozione è un rollback allo stato iniziale)

```
lvcreate -L592M -s -n domU.1 /dev/ops/xenbase
lvcreate -L588M -s -n domU.2 /dev/ops/xenbase
```

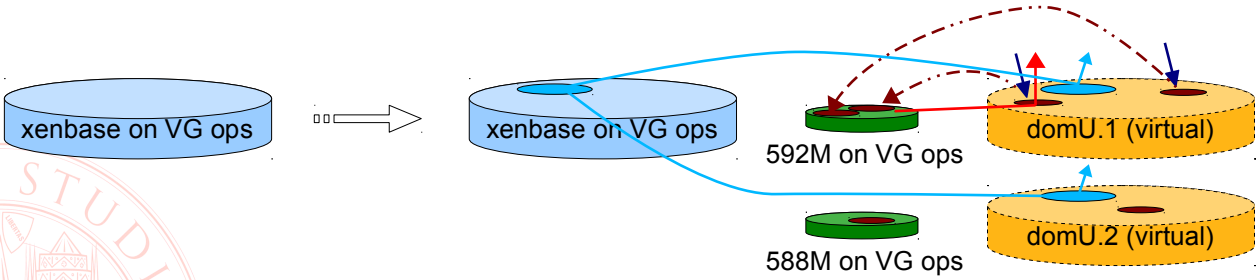

ogni scrittura su domU.1 viene fatta sullo spazio di snapshot
la lettura su domU.1 di un settore modificato viene fatta dallo snapshot
la lettura su domU.1 di un settore non modificato viene fatta da xenbase