Stockage Réseau

Le stockage s'échappe du système pour devenir une fonction réseau

Philippe Latu / Université Toulouse III - Paul Sabatier / www.inetdoc.net

Philippe.latu(at)inetdoc.net

Les enjeux

- Besoins en progression constante
- Migration DAS vers (SAN | NAS)
- Hétérogénéité et Interopérabilité
- Continuité de service

Les termes

- Manageability
- Availability
- Scalability

Les acronymes

- DAS : Direct Attached Storage
- SAN : Storage Area Network
- NAS : Network Attached Storage

Différences entre modes d'accès : fichier ou bloc

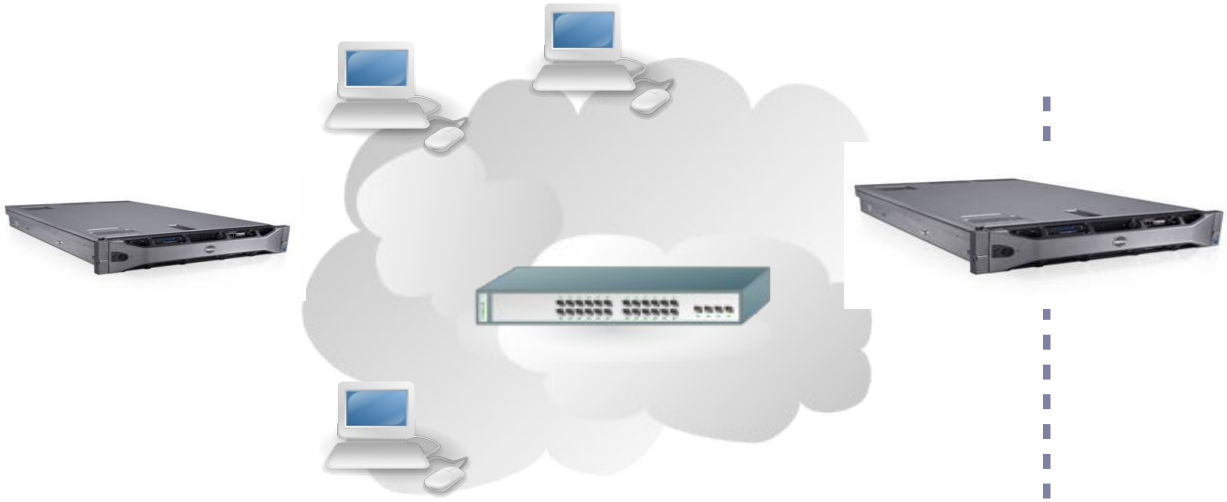

Réseau IP «frontal»

- Hôte ↔ hôte
- Application ↔ système de fichiers
- Client ↔ Serveur
- NFS / CIFS
- NAS

Réseau de stockage «dorsal»

- Hôte ↔ stockage
- Système de fichiers ↔ périphérique
- Application ↔ périphérique
- Virtual FS / Ext4 / NTFS
- SAS / SATA / SCSI / PATA
- SAN

- Caractéristiques
  - Évolutions
    - SCSI ⟶ SAS
    - PATA ⟶ SATA
    - FC (ANSI) ⟶ FCOE

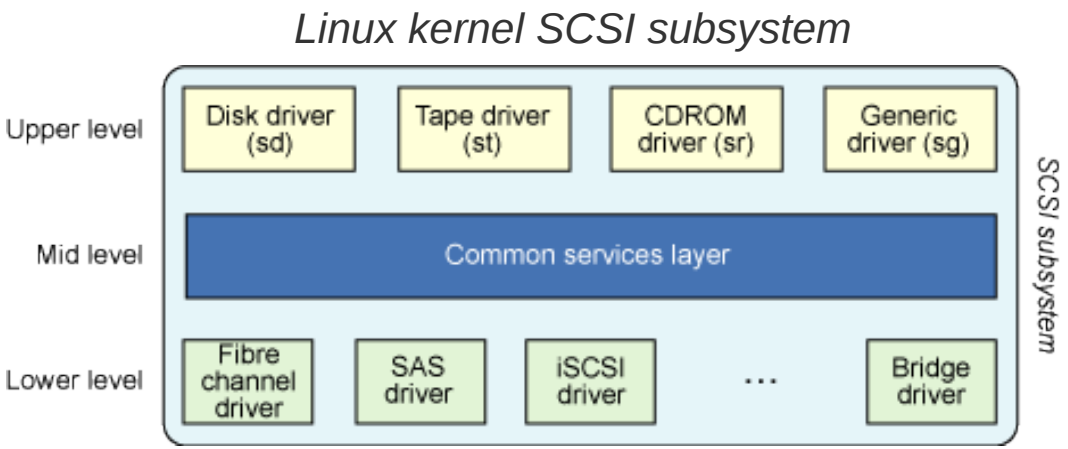

  - Limitations
    - Distance entre système et périphériques
    - Nombre de disques par châssis
    - Partage de périphériques entre systèmes
    - Dimensionnement serveur vs. Capacité de stockage
    - Retour sur investissement (ROI)

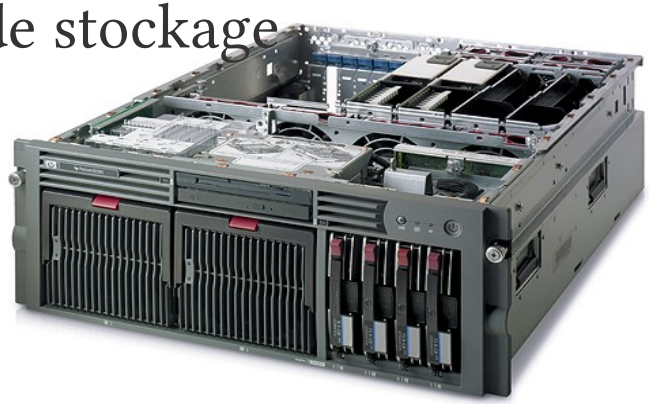

Network Attached Storage - NAS

- Caractéristiques
  - Hôte connecté au réseau IP
  - Accès en «mode fichier»
  - Évolutions
    - Systèmes de fichiers réseau NFS ou CIFS
    - Système de fichiers partageable entre serveurs
    - Liens redondants possibles
  - Limitations en performances
    - Réseau
    - Système de fichiers
    - Système d'exploitation

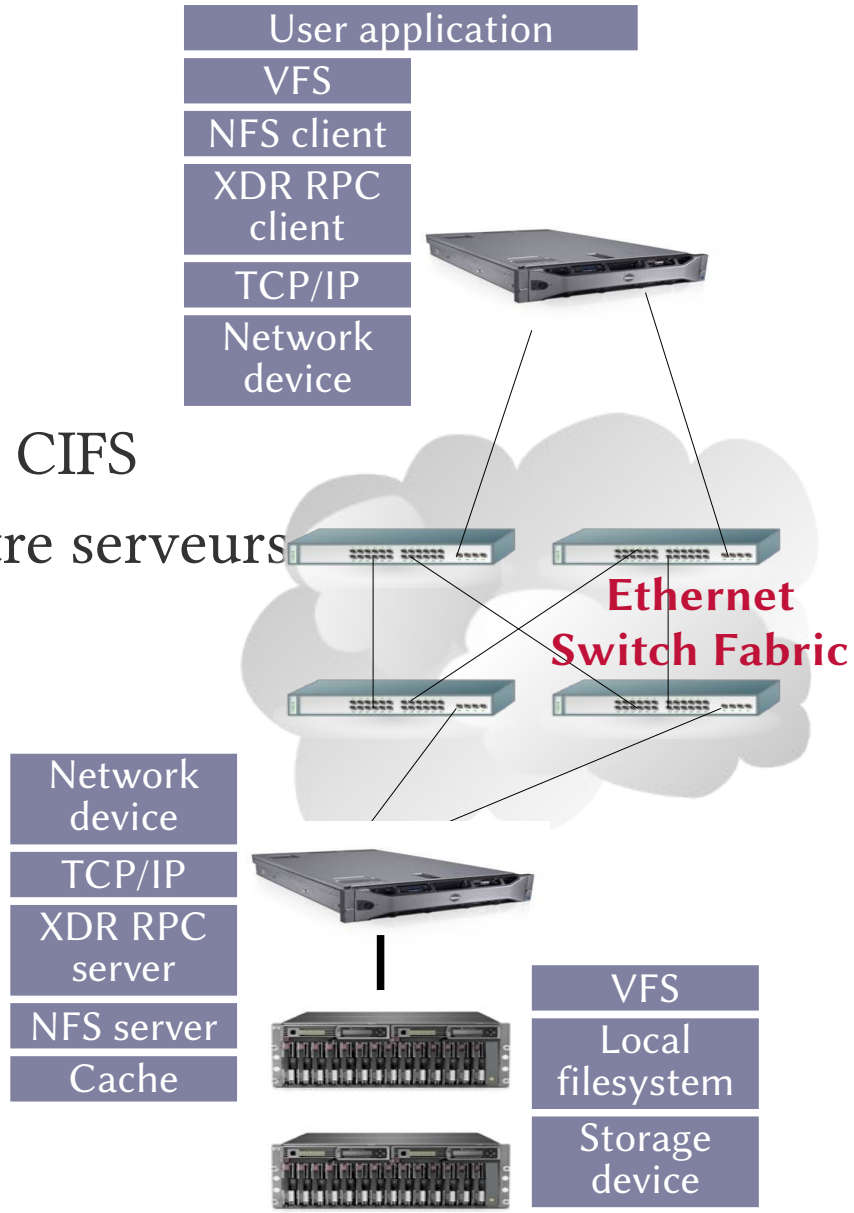

- Caractéristiques
  - Hôte connecté à un commutateur
  - Accès en «mode bloc»
  - Évolutions
    - Fiber Channel over Ethernet (FCoE)
    - Sous-système partageable entre serveurs
    - Liens redondants possibles
  - Limitations en performances
    - Coût du port de commutateur
    - Choix d'interfaces (HBA/FC) limité

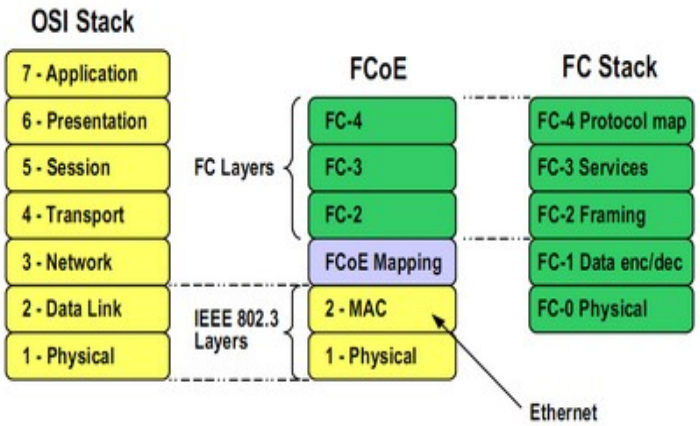

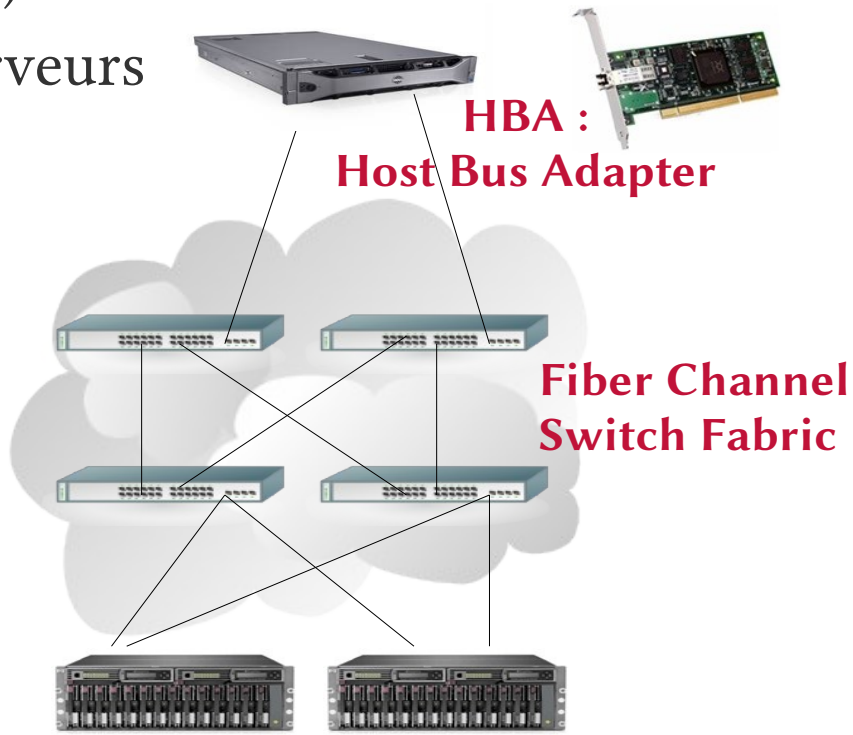

Caractéristiques système

	DAS	NAS	SAN
Accès	Mode bloc	Mode fichier	Mode bloc
Connexion	Série – SAS Parallèle - SCSI	Ethernet	Fiber Channel
Performances d'accès	Très bonnes	Moins bonnes	Très bonnes
Limite des performances	Sous-système SCSI du noyau	Système de fichiers NFS / CIFS	Commutation Fiber Channel
Augmentation de capacité	Arrêt du système obligatoire	Très facile	Complexe suivant l'architecture
Évolutivité et Continuité d'exploitation	Faible	Moyenne	Élevée

Caractéristiques réseau

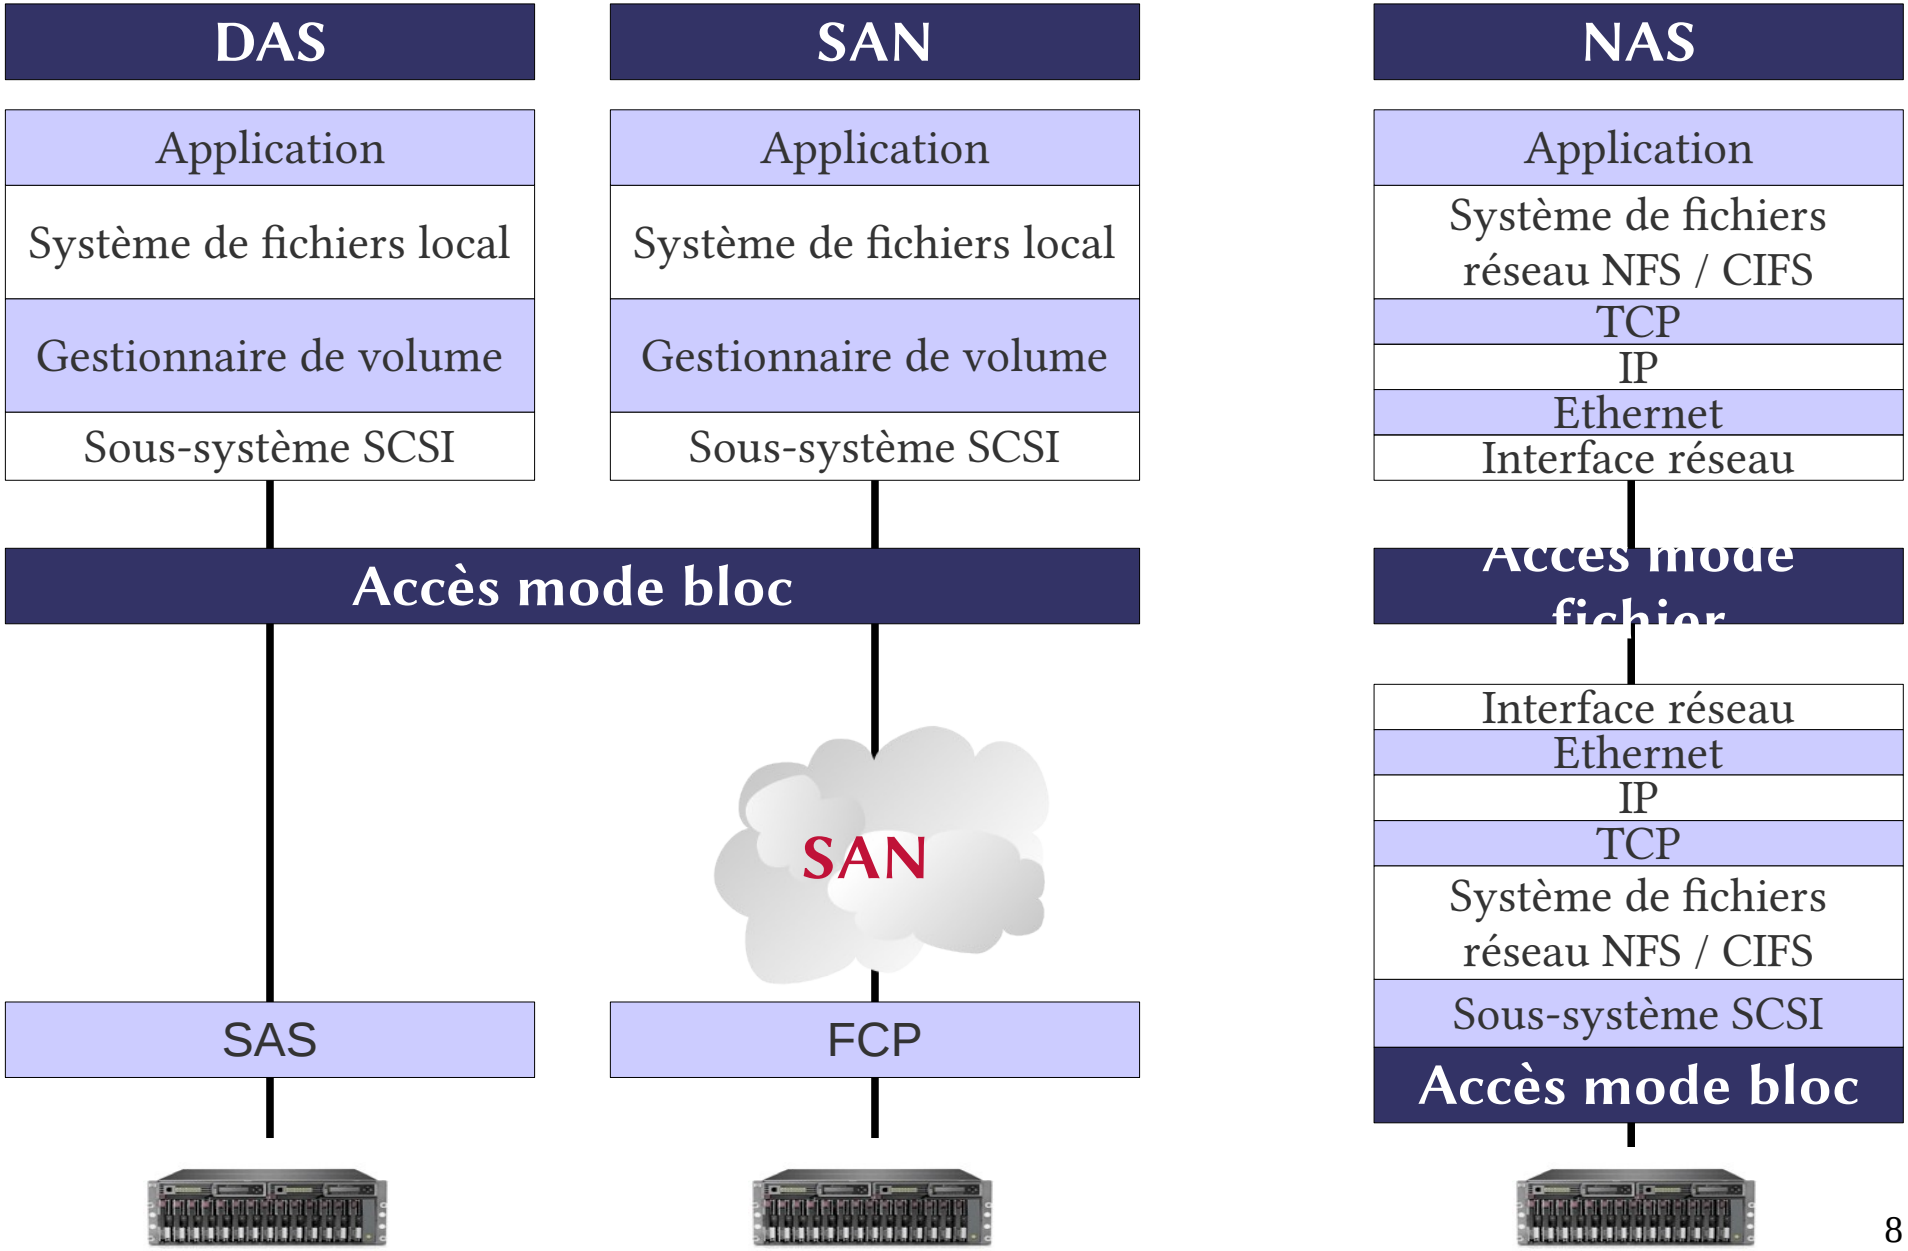

- Caractéristiques
  - Accès en «mode bloc» sur lien Ethernet
  - Évolutions
    - Algorithmes TCP adaptés (HTCP)
    - Balance de charge multi-liens (LACP)
  - Limitations
    - Performances réseau
    - Conflits entre fonctions TCP accès «mode
  - Termes
    - *Initiators* : HBAs ou NICs côté serveurs (maîtres)
    - *Targets / LUNs* : HBAs ou NICs côté stockage (esclaves)
    - *TOE* : TCP Offload Engine

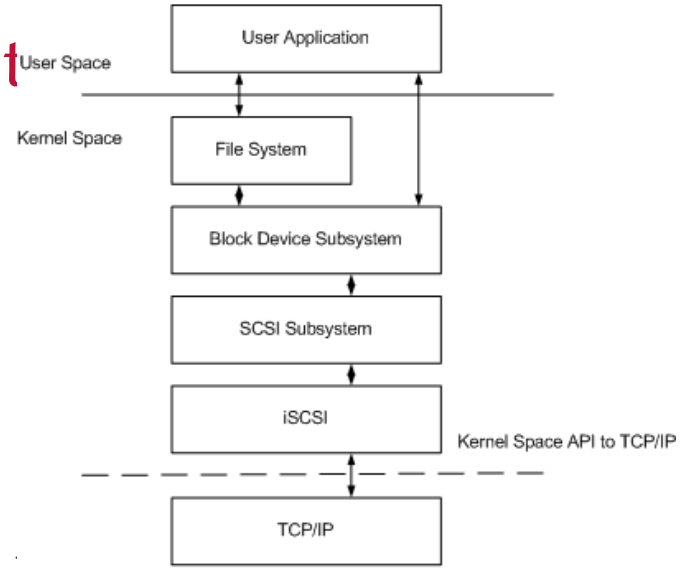

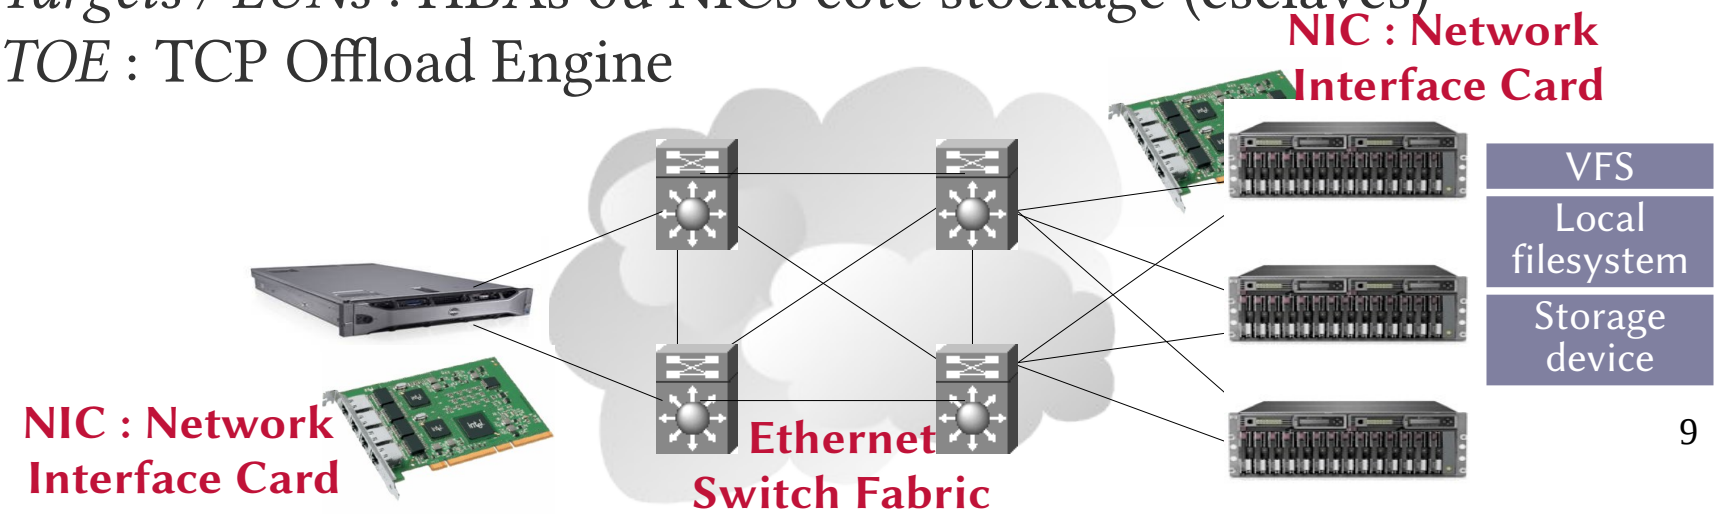

- Caractéristiques
  - Accès en «mode bloc» sur réseau IP
  - Évolutions
    - Commutation unifiée
      - LAN + SAN
    - Interfaces 10Gbps unifiées
      - réseau + stockage
  - Limitations
    - Spécifications trop récentes
    - Absence de retour d'expérience
    - Coût des commutateurs

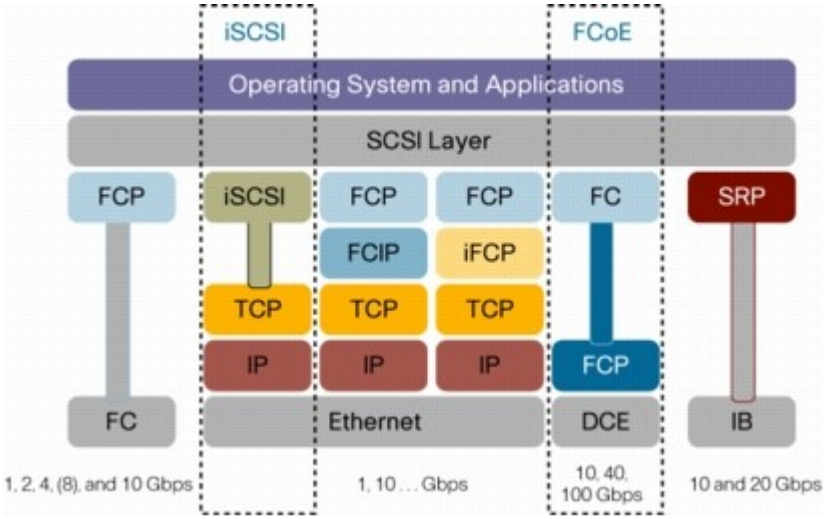

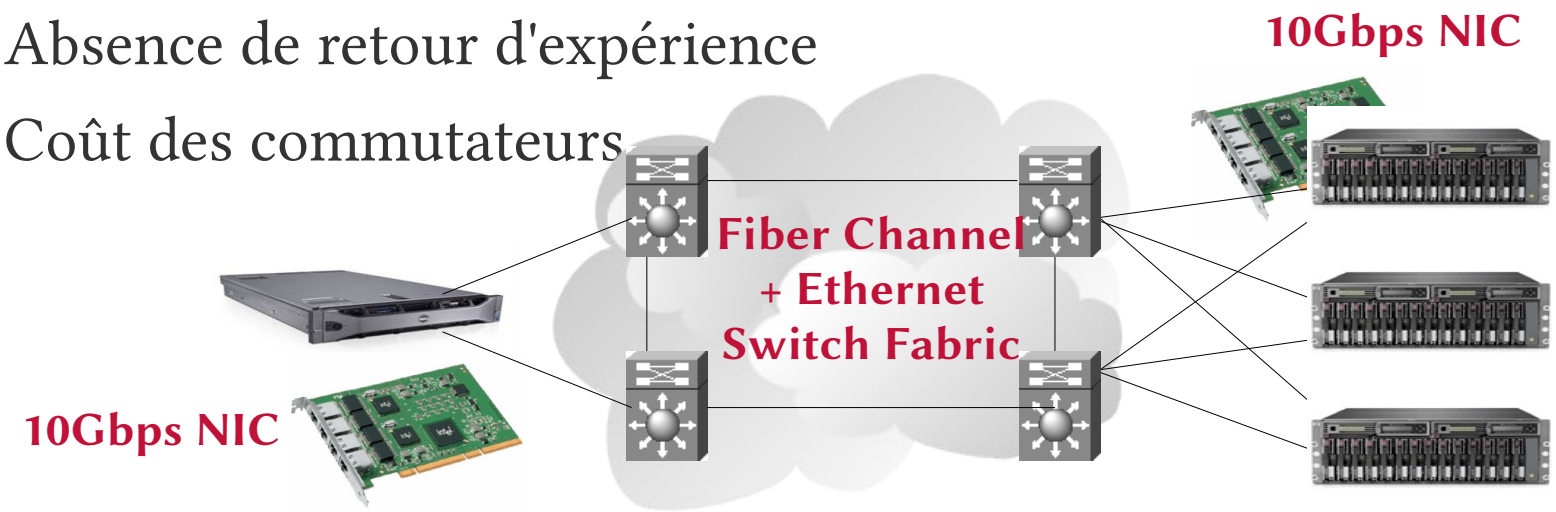

- Contraintes
  - Reprise de service en cas de panne
    - Catastrophes naturelles
    - Erreurs humaines
  - Sauvegarde
    - Opérations de maintenance
    - Pannes et défauts matériels
  - Accès multi-liens
    - Redondance
    - Balance de charge
    - Qualité de service (QoS)
  - Réplication
    - Disponibilité
    - Sauvegarde

- *Redundant Array of Independent Disks* (RAID)
  - Deux types d'implémentation
    - Logicielle – sous-système «*device manager*» du noyau Linux
    - Matérielle – carte contrôleur avec un système propre «*firmware*»

Niveau RAID	Description	Nombre minimum de disques	Capacité utile (nombre de disques)
0	*Striping* / Concaténation	2	N
1	Miroir	2	N/2
1 + 0	Miroir puis *Striping* / Concaténation	4	N/2
5	*Stripes* avec parité distribuée et E/S aléatoires	3	N - 1
6	*Stripes* avec deux calculs de parité différents distribués et E/S aléatoires	4	N - 2

Accès redondant aux unités de stockage

- Entrées/Sorties redondantes - *Multipath I/O*
  - Tolérance aux pannes dynamique
    - *Failover / Recovery*
    - Optimisation du coût d'administration
  - Choix entre deux modes
    - Actif / Passif
      - Tolérance aux pannes
      - Détection d'erreur automatique
    - Actif / Actif
      - Augmentation de performance
      - Augmentation des débits

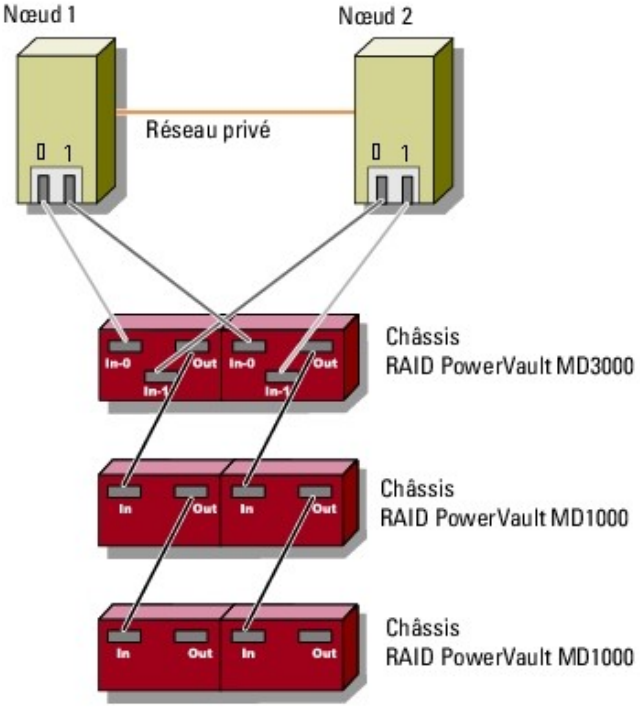

Réplication des volumes de stockage

- Deux modèles distincts
  - Niveau système ou noyau
    - Synchrone ou asynchrone
    - Pilotage au niveau serveur
      - LVM | cron | rsync
  - Niveau sous-système
    - Synchrone ou asynchrone
    - Pilotage au niveau contrôleu
      - *Mirroring*
      - Performances réseau imposées
      - Distances limitées

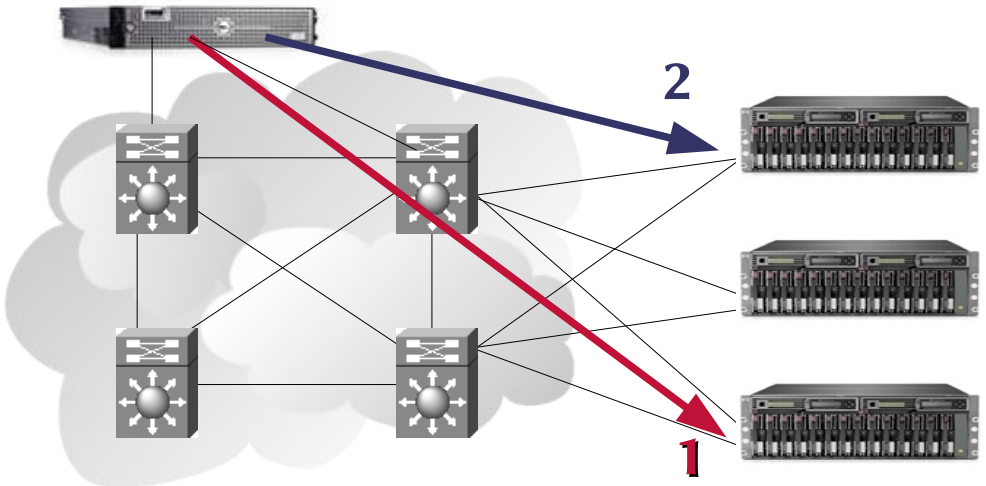

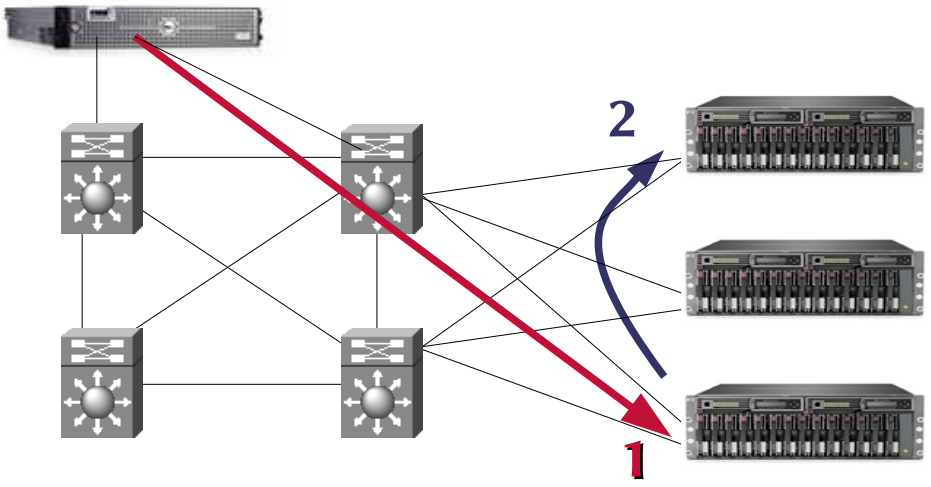

- Types de sauvegarde
  - Complète
    - Volume ou système de fichiers complet
    - Temps et consommation de bande passante très importants
  - Incrémentale
    - Différence depuis la dernière sauvegarde
    - Temps et consommation de bande passante peu importants
  - Différentielle
    - Différence depuis la dernière sauvegarde complète
    - Temps et consommation de bande passante moins importants
  - Hors ligne
    - Fenêtre de blocage des écritures imposée
    - Impact important sur l'architecture des services
  - En ligne
    - Contrôle d'intégrité difficile
    - Conflits potentiels entre services et sauvegarde

- Types d'opérations
  - Ajout/Retrait d'unités de disques
    - Maintenance avec utilisation temporaire de disques
  - Augmentation/Diminution de la capacité de stockage
    - Transferts entre volumes logiques sur un même système
  - Redimensionnement dynamique
    - Extension d'un système de fichiers en ligne
  - Déplacements de données entre unités de disque
    - Préparation à l'extraction d'unités de disque
  - *Snapshots*
    - Copie instantanée de l'état d'un volume logique
  - Réplication
    - Copie entre volumes logiques

- *Device mapper*
  - Cartographie des requêtes sur les unités de disque
    - Redirection
    - Mise en attente
    - Chiffrement
    - Gestion de lien
  - Gestionnaire de périphériques en mode bloc
    - Ajout/Retrait d'unités en mode bloc au dessus de périphériques de stockage physiques

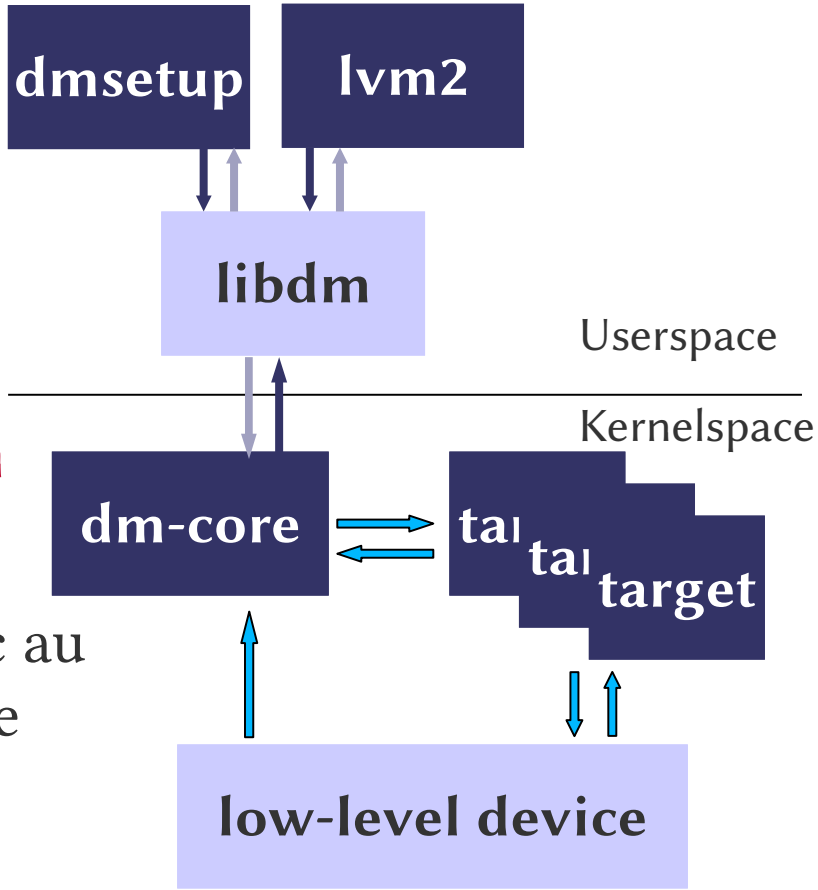

- *Logical Volume Manager*
  - Gestionnaire de périphérique mode bloc au niveau système
    - Partitions d'unités de disque
    - Unités SAS/SATA/PATA
    - LUNs iSCSI
    - Réseau FCoE
  - Vue système homogène
    - N Périphériques physiques vus comme un périphérique logique
  - Analogie entre volume et partition
    - Formatage et création d'un système de fichiers
    - Partition d'échange (*swap*)
    - Accès directs depuis un gestionnaire de bases de données
  - Changements dynamiques de configuration

- Linux LVM2
  - Espace noyau
    - *Device mapper modules*
  - Espace utilisateur
    - Paquet lvm2
  - *Striping* en option

```
-*- Multiple devices driver support (RAID and LVM)
< >   RAID support
<M>   Device mapper support
[ ]     Device mapper debugging support
<M>     Crypt target support
<M>     Snapshot target
<M>     Mirror target
<M>     Zero target
<M>     Multipath target
<M>     I/O delaying target (EXPERIMENTAL)
[*]     DM uevents (EXPERIMENTAL)
```

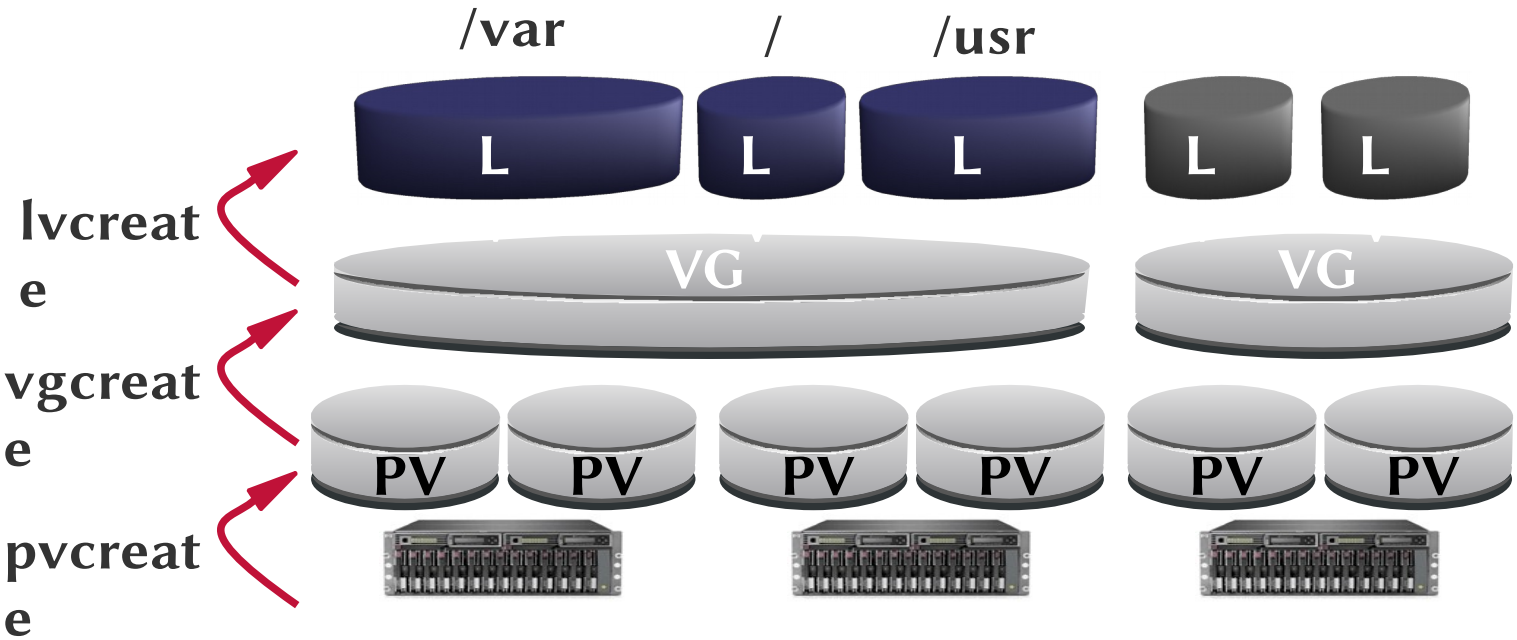

Exemples de manipulations pratiques

- Réplication synchrone
  - RAID1 logiciel entre DAS et SAN
    - Une unité de disque locale
    - Une unité de disque iSCSI
    - RAID1 entre les deux unités
- Réplication asynchrone
  - *Snapshot* LVM entre DAS et SAN
    - Une unité de disque locale
    - Une unité de disque iSCSI
    - *Snapshots* périodiques entre les deux unités

- Réplication synchrone – phase 0

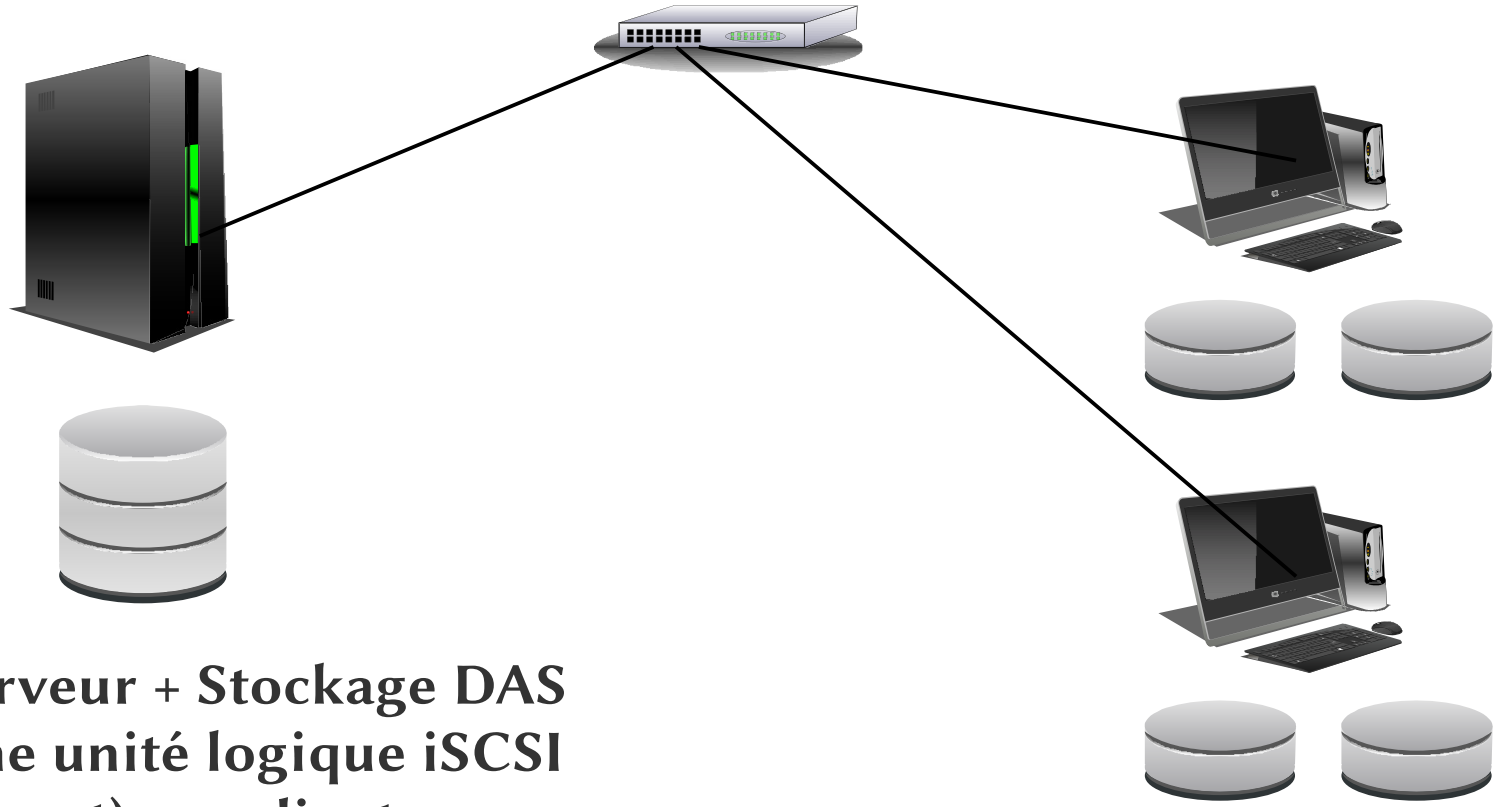

- Serveur + Stockage DAS
- Une unité logique iSCSI (target) par client

- Client + Stockage DAS
- deux unités physiques par poste

Réplication synchrone – phase 1

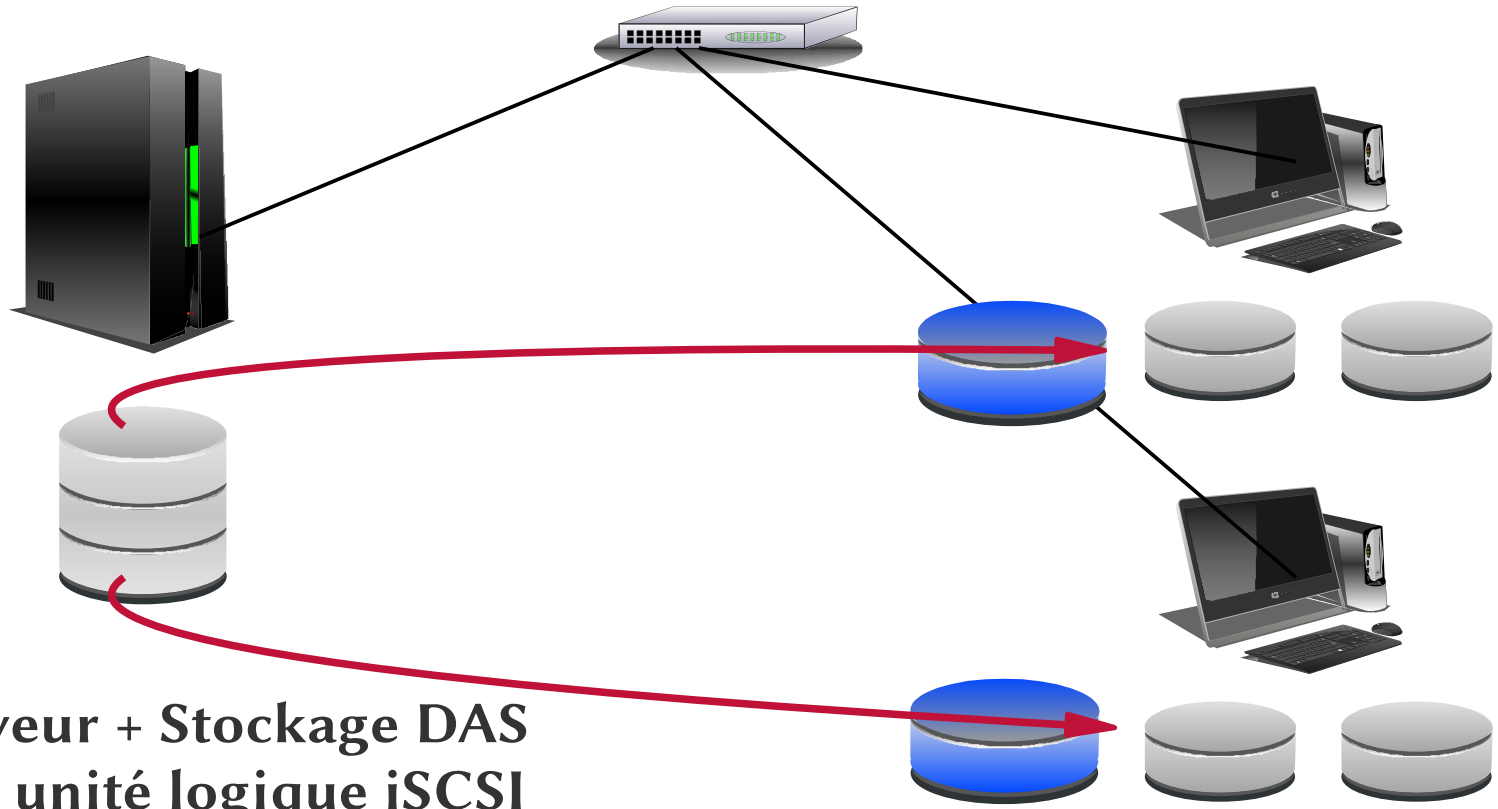

- Serveur + Stockage DAS
- Une unité logique iSCSI (target) par client

- Client + Stockage DAS
- deux unités physiques par poste
- une unité logique iSCSI (initiator)

- Réplication synchrone – phase 2

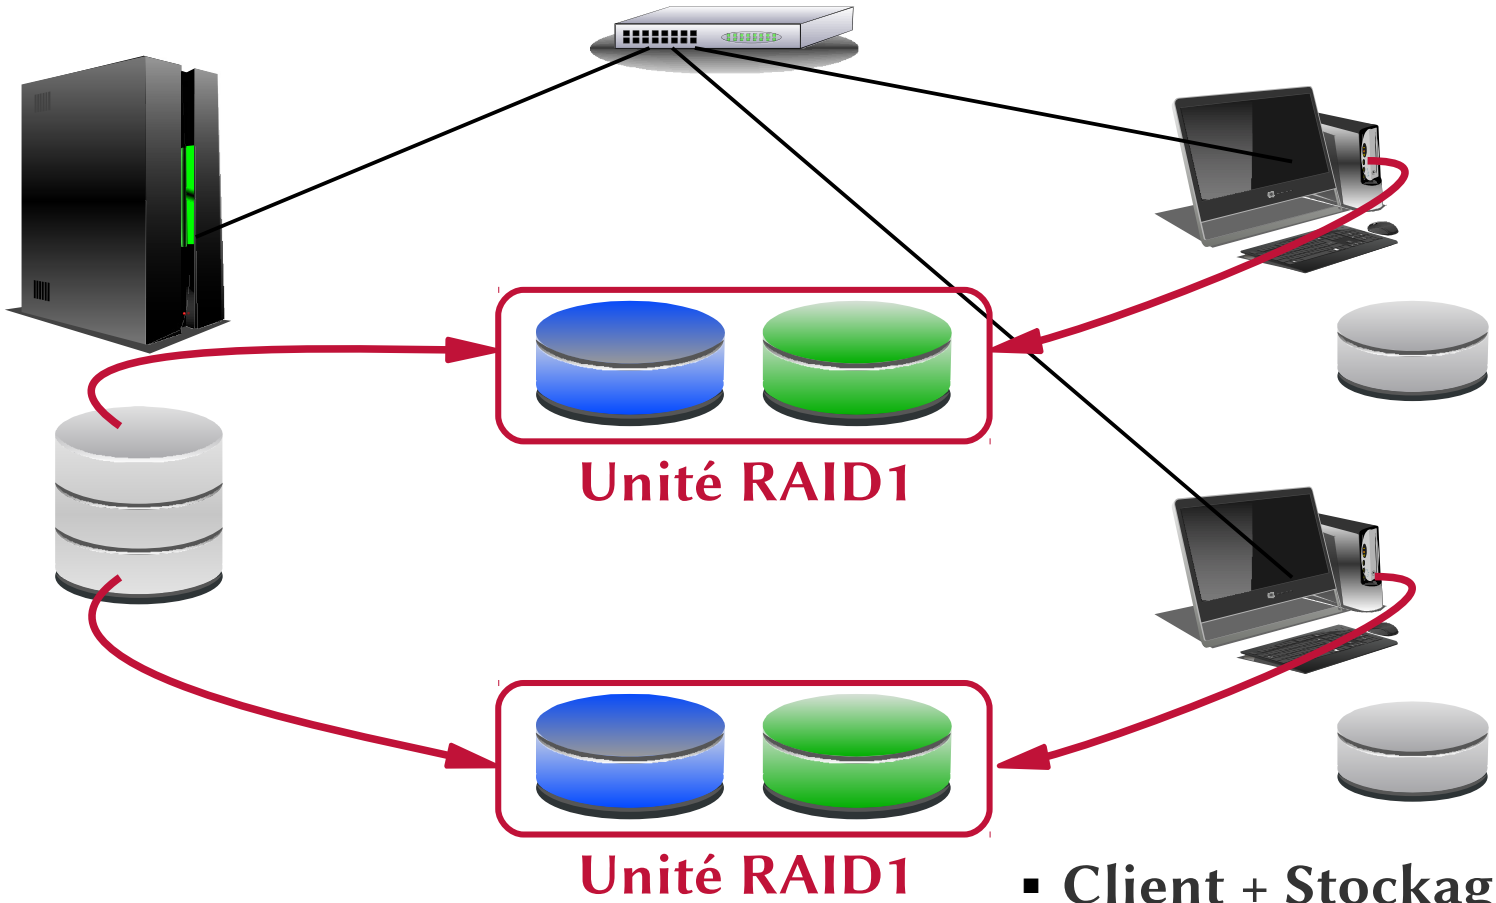

RAID1 avec DAS + SAN

=

Réplication synchrone

- **Client + Stockage DAS**
- **une unité physique par poste**
- **une unité logique RAID1**

- Réplication asynchrone – phase 3

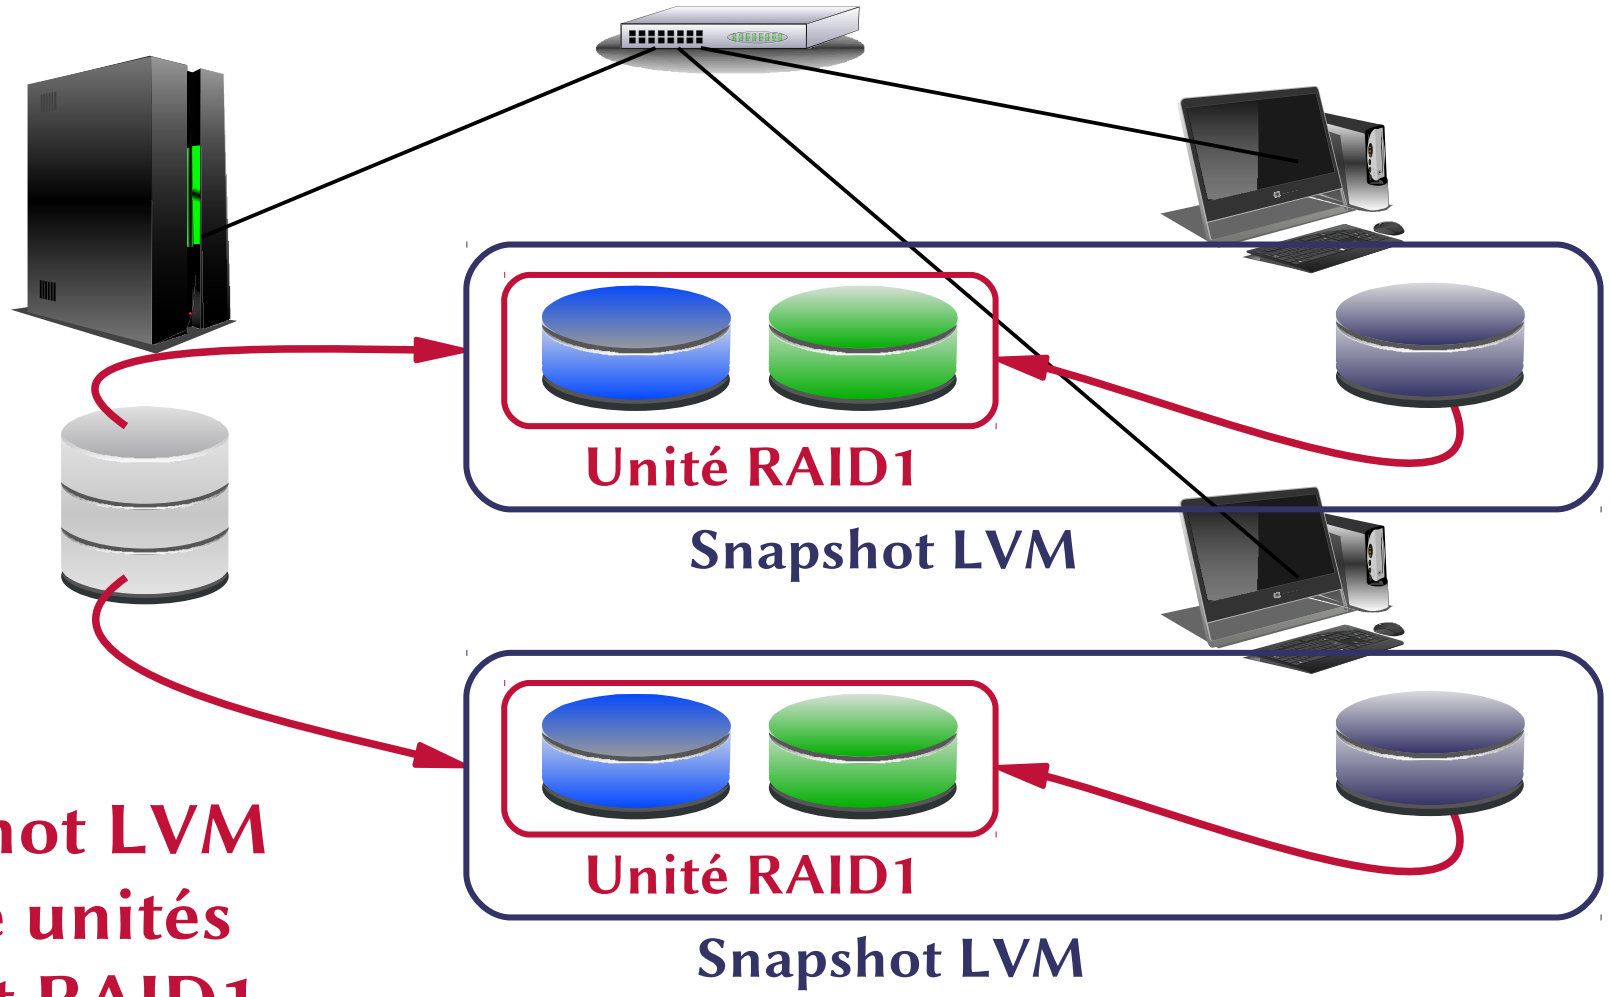

Snapshot LVM entre unités DAS et RAID1

=

Réplication asynchrone

Ressources

- Travaux pratiques
  - Introduction au réseau de stockage iSCSI
  - http://www.linux-france.org/prj/inetdoc/cours/admin.reseau.iscsi/
- Technologies
  - NAS : http://fr.wikipedia.org/wiki/Stockage_en_réseau_NAS
  - SAN : http://fr.wikipedia.org/wiki/Storage_Area_Network
  - FcoE : http://fr.wikipedia.org/wiki/FCoE
  - iSCSI : http://fr.wikipedia.org/wiki/ISCSI
  - LVM : http://fr.wikipedia.org/wiki/Gestion_par_volumes_logiques
- Documentation
  - LVM : http://tldp.org/HOWTO/LVM-HOWTO/
  - Wiki : http://sources.redhat.com/lvm2/wiki/