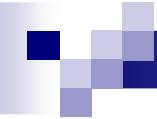


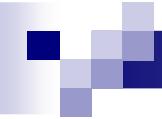
virtualisation XEN avec Linux CentOS à l'Université Montpellier 2

CUME - 13 mars 2008



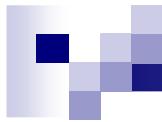
Quelques missions de l'équipe Réseau CR2I UM2

- Gestion du réseau fédérateur jusqu'au laboratoire
 - environ 110 switchs
 - 5600 machines
- Gestion des services "réseaux" (pas les applicatifs "gestion")
 - DNS
 - WWW (environ 170 sites hébergés)
 - FTP
 - Proxy
 - Courrier électronique (environ 5600 comptes)
 - ...
- → environ 40 serveurs
- → 2 administrateurs système/réseaux



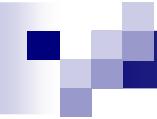
Problématique Système et Sécurité

- 1 service / serveur → sécurité accrue
(l'exploitation d'une faille de sécurité ne compromet qu'1 serveur)
- 1 service / serveur → maintenance facilitée
(éviter des "surprises" lors de maj. système)
- MAIS :
 - 1 service / serveur → cher !
 - redondance : plusieurs serveurs pour 1 service → cher !
 - 1 service / serveur → coûteux en temps (si pas de solution de clonage)
 - 1 service / serveur → une machine peut passer son temps à ne rien faire
(DNS, Radius, ... sur un Xeon Quad-Core ???)



Problématique Système et Sécurité

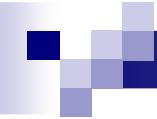
- une solution : la (para-)virtualisation
 - plusieurs serveurs virtuels / serveur physique (coût diminué)
 - NE PAS anticiper les besoins (augmentation de la puissance d'une machine virtuelle quand le besoin s'en fait sentir)
 - déploiement facilité (temps de mise en œuvre réduit)
 - fiabilité des services améliorée (plus rapide de "réinstaller" une machine virtuelle qu'une machine physique)



les techniques de la (para-)virtualisation

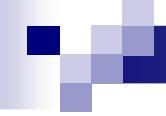
- différents niveaux d'exécution sur un OS non-virtualisé :
 - 0 = système d'exploitation (système "hardware" = système "utile")
 - 1 = application

- 1 niveau d'exécution supplémentaire sur un OS virtualisé :
 - -1 = système d'exploitation hôte (système "hardware")
 - 0 = système d'exploitation invité/virtualisé (système "utile")
 - 1 = application



les techniques et fonctionnalités de la (para-)virtualisation

- → OS hôte :
 - Couche d'abstraction matérielle (réseau, mémoire, disque, ...)
 - Partitionnement, isolation et/ou partage des ressources physiques
 - Gestion des "images" des OS invités
 - Clonage, sauvegarde et restauration des "images" des OS invités
 - Démarrage, arrêt, gel, migration d'un OS invité d'une machine physique vers une autre
- → OS invité :
 - architecture matérielle connue différente de l'architecture matérielle réelle
 - Avec des pilotes
 - Génériques (virtualisation)
 - Adaptés à l'OS hôte (para-virtualisation)



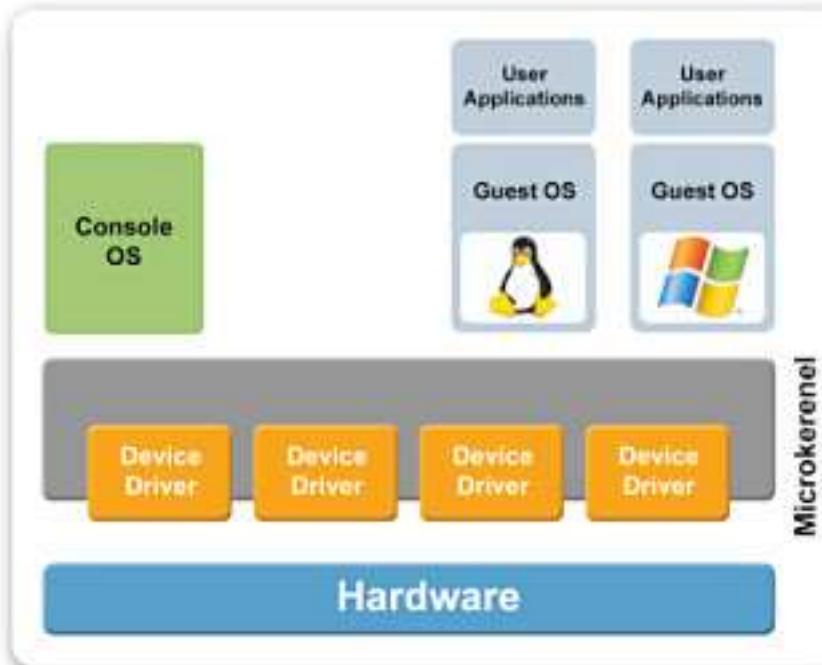
Virtualisation vs ParaVirtualisation

- Virtualisation (émulation)
 - Pilotes génériques
 - Interception et traduction des appels système des OS invités
 - → CPU consommée

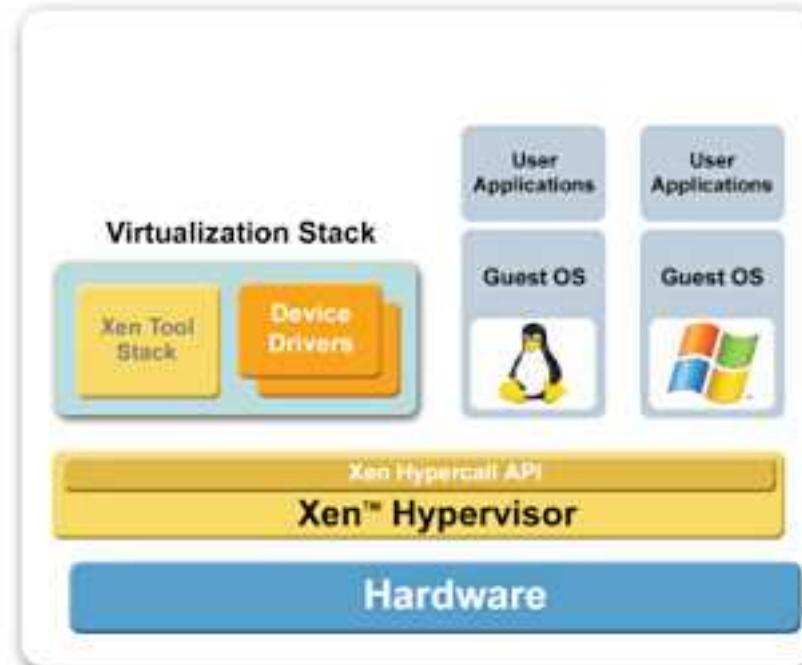
- ParaVirtualisation
 - Accès « direct » au matériel via des pilotes adaptés/spécifiques à l'hyperviseur

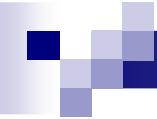
Virtualisation vs ParaVirtualisation

Emulation



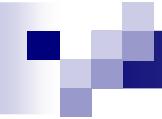
Paravirtualization





XEN – principes

- XEN = noyau Linux modifié + outils (hyperviseur)
 - si Intel VT ou AMD Pacifica,
Xen 3.x peut héberger des OS invités non modifiés (QEMU)
(virtualisation complète mais pas plus rapide)
 - sinon, les OS invités doivent être modifiés (Linux, NetBSD et OpenBSD)
 - Isolation complète entre les machines virtuelles
 - Performances pour les machines virtuelles proches d'un système natif
 - machine virtuelle = domaine
 - dom0 : domaine avec privilèges
 - domU : domaine sans privilèges (machines virtuelles invitées)



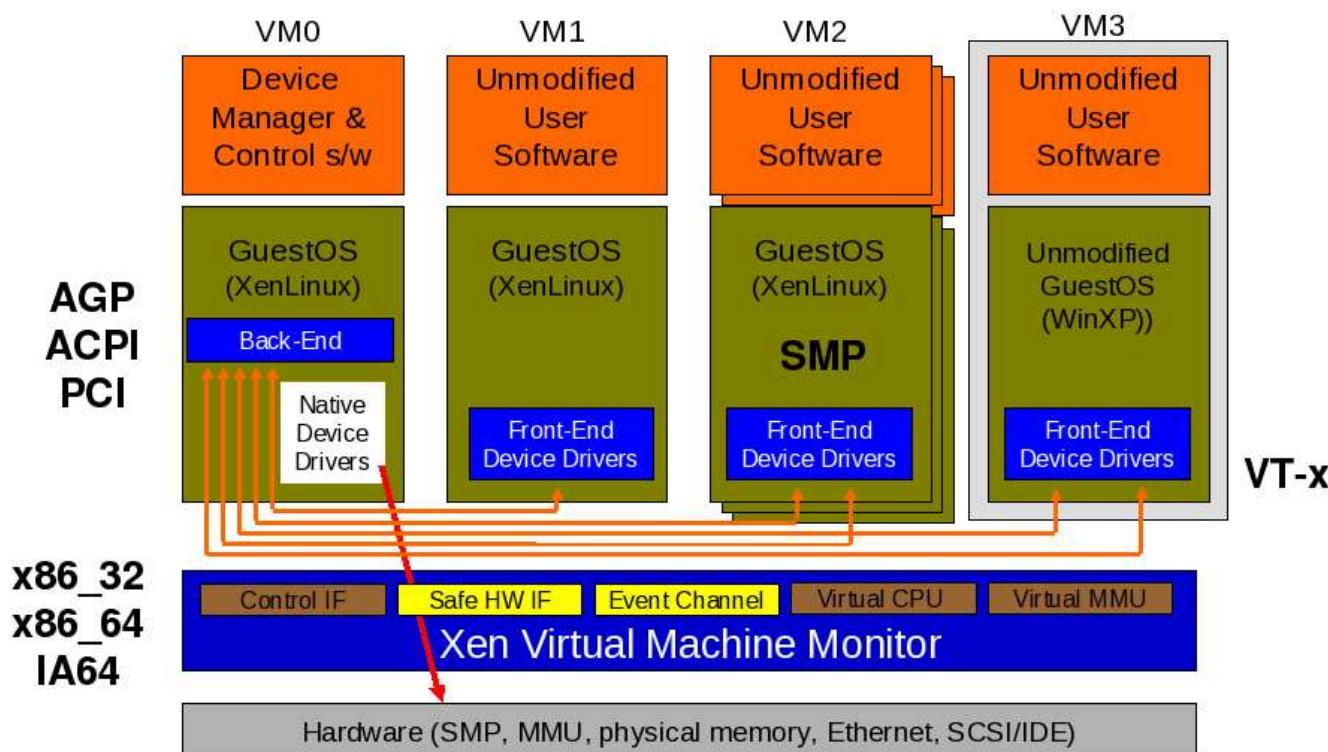
XEN – principes

- dom0 (domaine privilégié) + Hyperviseur
 - lancé automatiquement au boot
 - gestion du hardware (via les pilotes standards du noyau Linux)
→ le seul à pouvoir interagir directement avec le matériel
 - Gestion du temps d'utilisation de la machine hôte par les domaines invités
 - gestion de la mémoire
 - Gestion des tâches d'administration du système
via le daemon xend dans l'espace utilisateur
(création, démarrage, arrêt, restauration ou migration des domaines)
 - accès natif au matériel (pilotes "backend")
 - Fonction de switch Ethernet virtuel

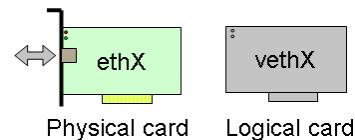
XEN – principes

- domU (domaine non privilégié)
 - contrôlé(s) par le dom0
 - noyau modifié et pilotes virtuels ("frontend") qui communiquent avec les pilotes "backend" du dom0
→ noyau "xenifié" (sauf si Intel VT ou AMD Pacifica)
 - "xenblk" : mode bloc pour les disques
 - "xennet" : cartes réseaux virtuelles

XEN – principles



XEN – principes (réseau)

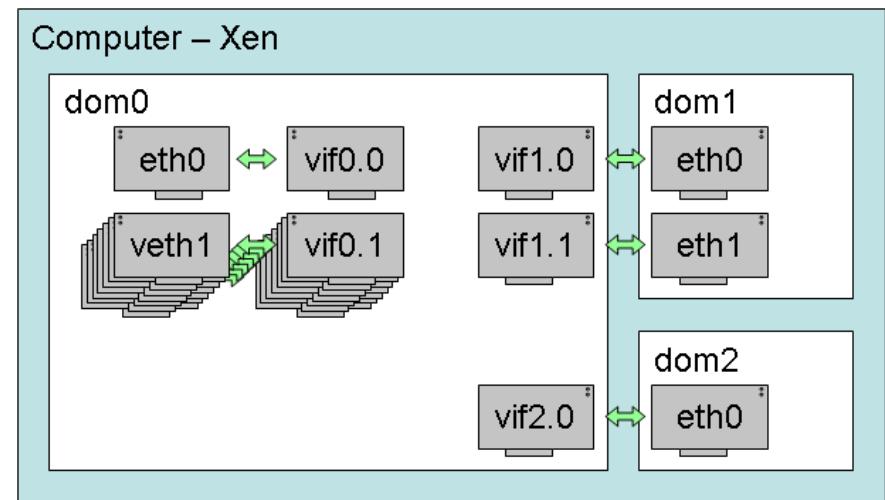


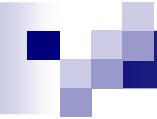
■ réseau virtuel

□ paires d'interface virtuelles

Ethernet utilisées par le dom0

- une partie de chaque paire est dans le domU (eth0)
- l'autre partie est dans le dom0 (vif<id_domaine>.0)





XEN – principes (réseau)

■ réseau virtuel

- adresse MAC aléatoire pour chaque interface réseau virtualisée des domU
(sauf si précisée dans le fichier de configuration de la machine virtuelle)
- possibilité d'utiliser des VLANs
 - support du 802.1q par le dom0
 - un bridge par VLAN
 - les domU n'ont pas connaissance des VLANs
- Le réseau (@IP) du domU peut être configuré depuis le dom0

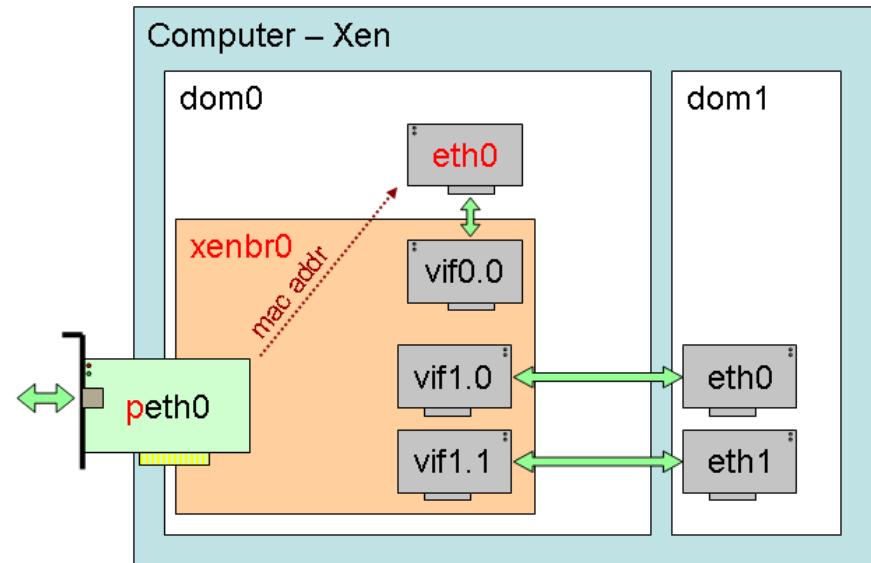
XEN – principes (réseau)

■ réseau virtuel

- différents modes

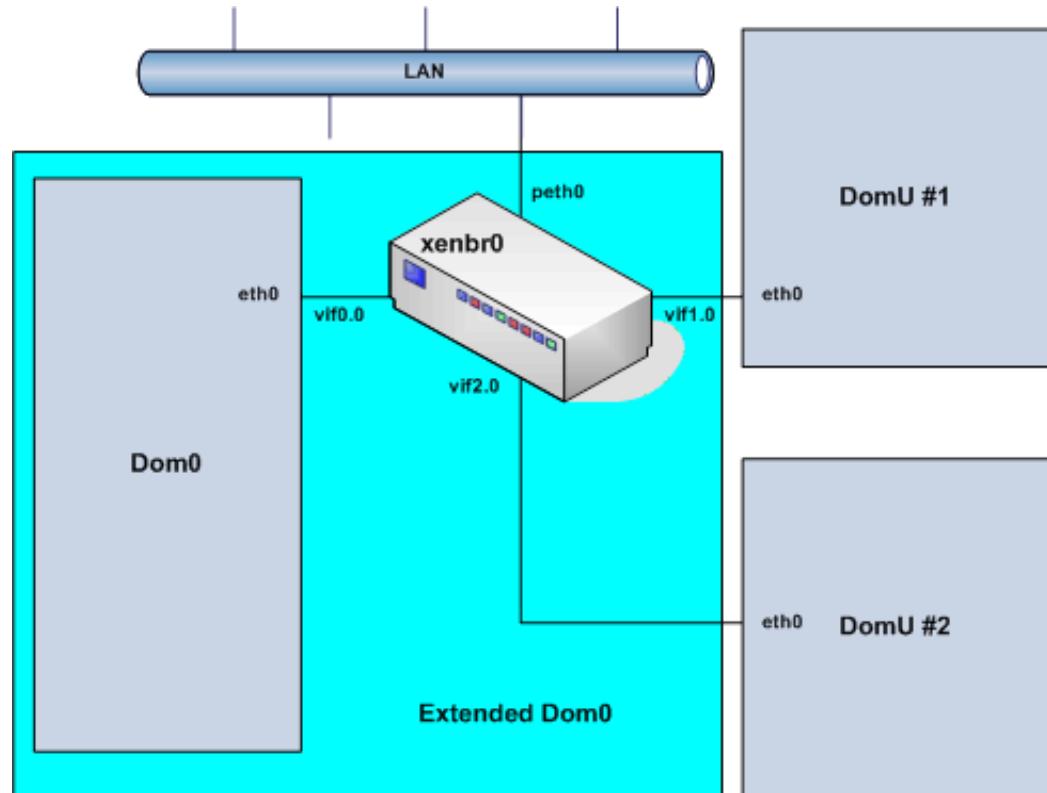
- Bridge

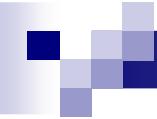
- pont entre cartes virtuelles et carte physique
 - les vifX.Y n'ont PAS d'adresse IP
 - pas de contrôle au niveau du dom0 (ebtables ?)
 - eth0 du dom0 devient peth0, veth0 renommée en eth0, peth0 et vif0.0 attachées au bridge xenbr0
 - → attention au SpanningTree



XEN – principes (réseau)

- réseau virtuel
 - différents modes
 - Bridge





XEN – principes (réseau)

■ réseau virtuel

- différents modes

- NAT

- dom0 joue le rôle de passerelle pour les domU
 - règles iptables applicables à ces cartes sur dom0

- Route

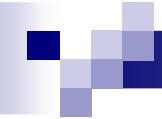
- les vifX.Y ont pour adresse IP celle des cartes dans les domU
 - elles ne voient pas passer les paquets

XEN – principes

■ Mémoire

- quantité de mémoire donnée à un OS invité n'est pas définitive
 - (modification de la quantité de mémoire attribuée à un système invité tout en continuant son exécution)
 - (impossibilité de diminuer la quantité de mémoire d'une machine virtuelle en dessous de la quantité initialement donnée)

→ balloon driver



XEN – principes

■ CPU

- VCPU = Virtual Central Process Unit
- 1 processeur = 1 VCPU
 - (1 thread = 1 VCPU)
 - (1 cœur = 1 VCPU)

XEN - administration

■ gestion des ressources CPU

□ Ajout/suppression à la volée de CPU virtuelles

- cat /proc/cpuinfo |grep 'processor' |wc -l
1

```
xm vcpu-set domU 4
```

```
cat /proc/cpuinfo |grep 'processor' |wc -l  
4
```

□ Affectation des CPU virtuelles aux CPU physiques

- xm vcpu-pin domU 0 1

XEN - administration

■ Gestion des ressources mémoire

- xm mem-max # Sets the maximum amount of memory
for a domain
- xm mem-set # Sets the current memory usage
for a domain

■ Gestion des ressources disque

- xm block-attach # Creates a new virtual block device
- xm block-detach # Destroys a domain's virtual
block device

■ Gestion des ressources réseaux

- xm network-attach # Creates a new network device
- xm network-detach # Destroys a network device

XEN - administration

■ gestion des domU

□ xm create domU	# créer et démarrer un domU
□ xm shutdown domU	# arrêter un domU
□ xm destroy domU	# arrêter (BRUTALEMENT) un domU
□ xm reboot domU	# redémarrer un domU
□ xm pause domU	# mise en pause du domaine # consommation mémoire # pas de consommation CPU
□ xm unpause domU	
□ xm save domU hiberfile.sys	# "hibernation" du domaine # aucune consommation mémoire/CPU
□ xm restore hiberfile.sys	#

XEN - administration

■ gestion des domU

```
□ xm migrate --live domU dom0B      # transfert d'un domU  
                                         # d'un dom0  
                                         # vers un autre dom0
```

- déplacement de la mémoire non utilisée en écriture
- pause du domU (60 à 300ms)
- déplacement de la mémoire utilisée en écriture
- réveil du domU
- → connexions réseau ouvertes conservées !
- → les 2 dom0 doivent avoir accès à l'image disque du domU (SAN) et doivent avoir la même version de Xen

XEN - administration

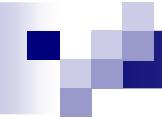
■ gestion des domU

- xm migrate --live domU dom0B

- ping domU

```
64 bytes from 162.38.101.222: icmp_seq=30 ttl=64 time=0.169 ms
64 bytes from 162.38.101.222: icmp_seq=31 ttl=64 time=0.176 ms
64 bytes from 162.38.101.222: icmp_seq=37 ttl=64 time=0.176 ms
64 bytes from 162.38.101.222: icmp_seq=38 ttl=64 time=0.187 ms
```

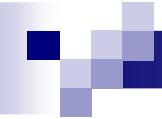
le domU a été déplacé



XEN - administration

- État des domU

- xm uptime
- xm top
- xm list
- xm vcpu-list
- xm network-list
- xm block-list
- xm dmesg
- xm log



XEN - administration

■ Mise à jour d'un domU

- `lvcreate --snapshot --size 128m --name domU-snap /dev/vglocal/domU`
`xm create -c domUsnap`
...
`xm shutdown domUsnap`
`dump/restore`
`xm shutdown domU`
`lvremove / dev/vglocal/domU`
`lvrename / dev/vglocal/domU-snap / dev/vglocal/domU`
`xm create -c domU`

XEN - administration

■ Sauvegarde d'un domU

```
□ lvcreate --snapshot \
    --size 128m \
    --name  domU-snap /dev/vglocal/domU

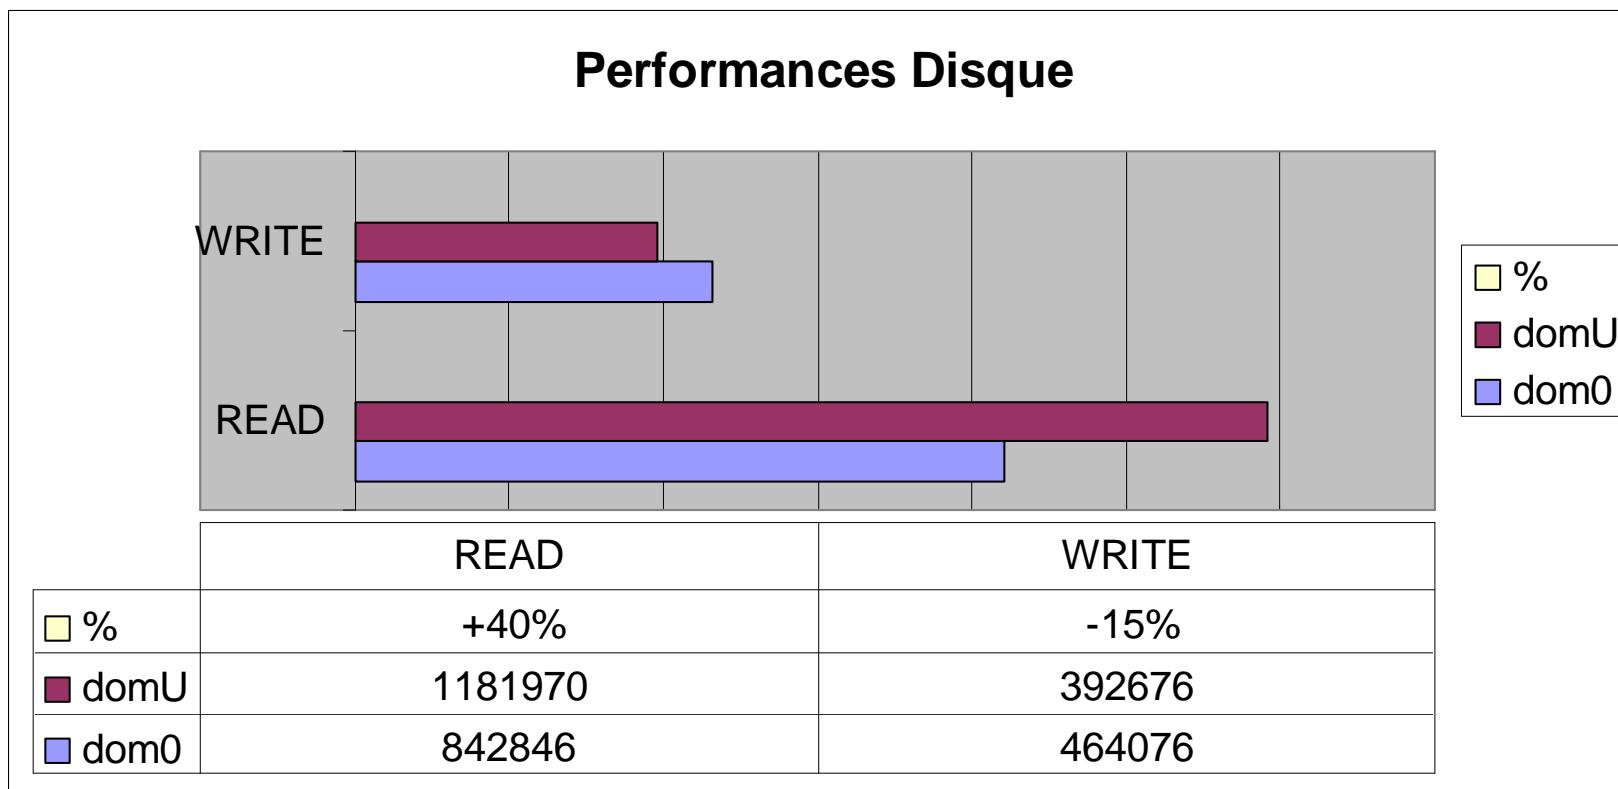
□ dump 0ufz9 - /dev/vglocal/domU-snap \
    | ssh -i sshkey cr2i@dom0B restore xf - .
```

XEN - performances

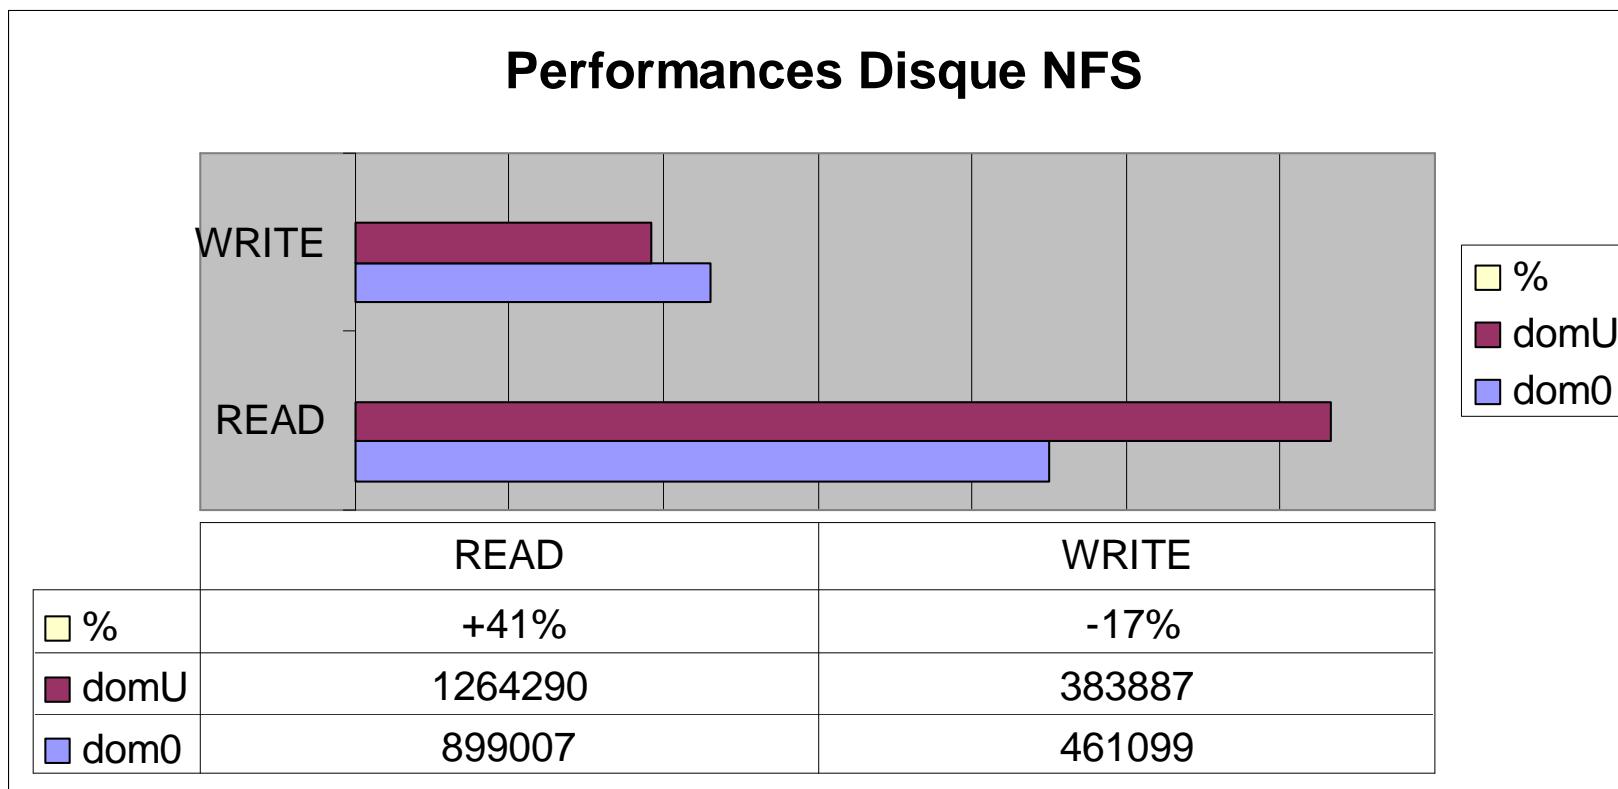
- Re-démarrage d'un domU

- xm shutdown domU -w ; xm create domU
 - 64 bytes from 192.168.1.222: icmp_seq=68 ttl=64 time=0.158 ms
 - 64 bytes from 192.168.1.222: icmp_seq=113 ttl=64 time=1496 ms
 - 64 bytes from 192.168.1.222: icmp_seq=114 ttl=64 time=496 ms
 - 64 bytes from 192.168.1.222: icmp_seq=115 ttl=64 time=0.190 ms
- → 47 secondes

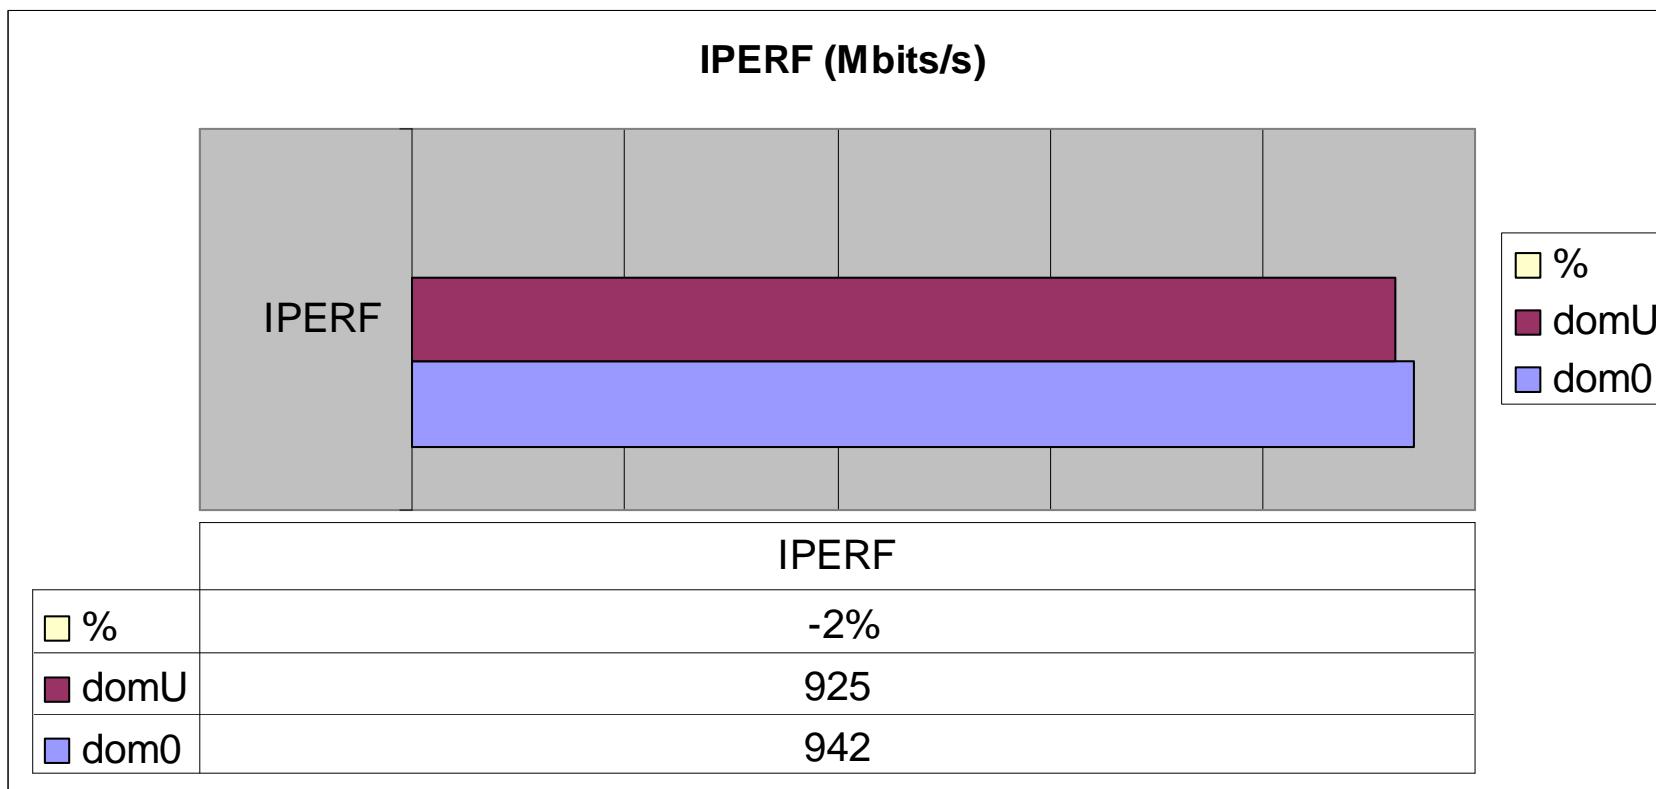
XEN - performances



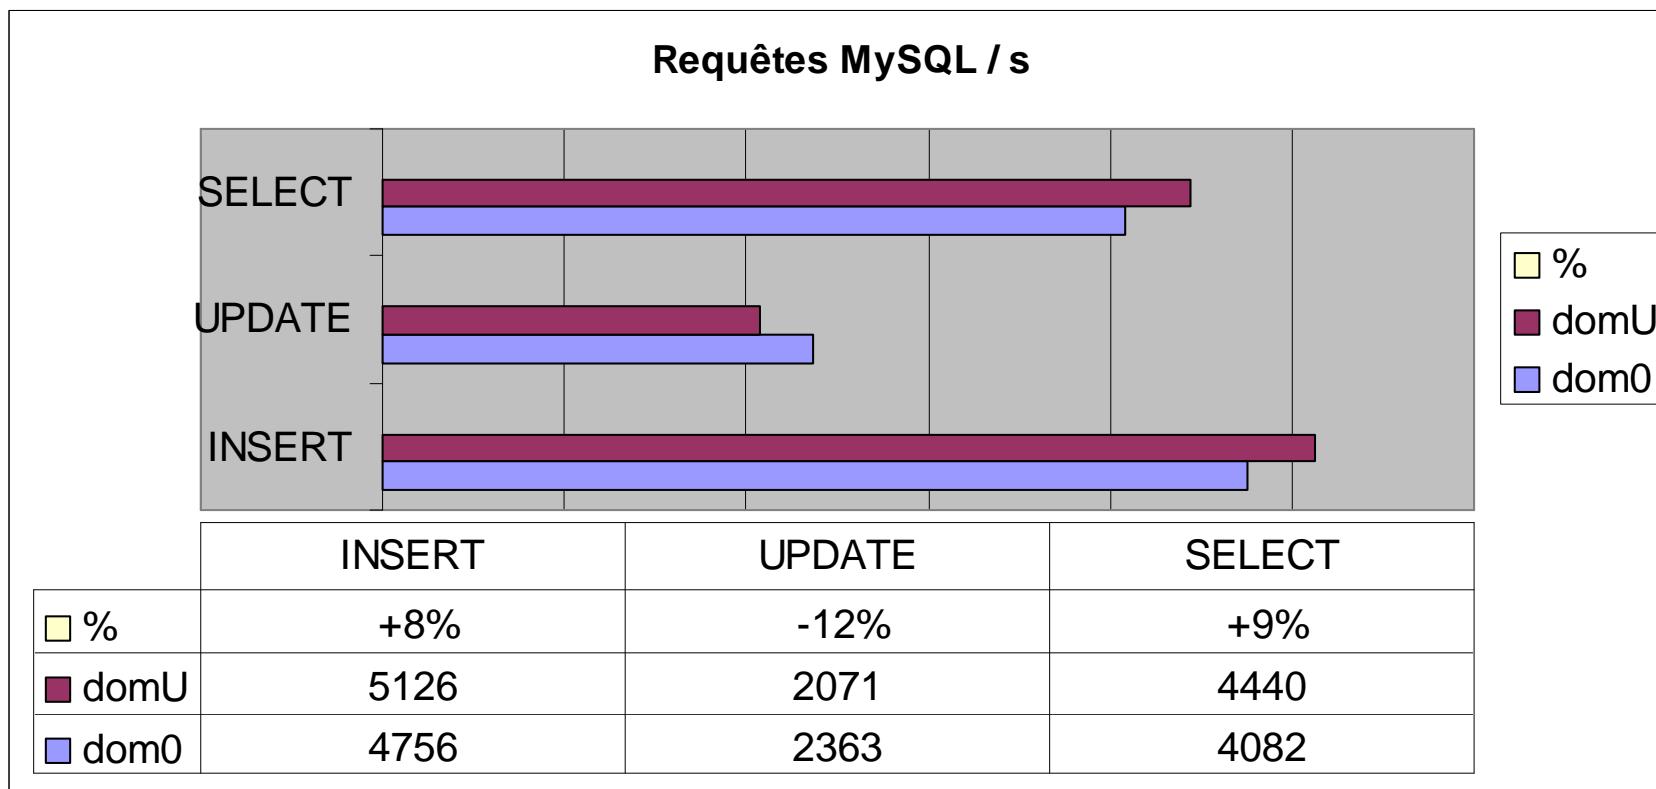
XEN - performances



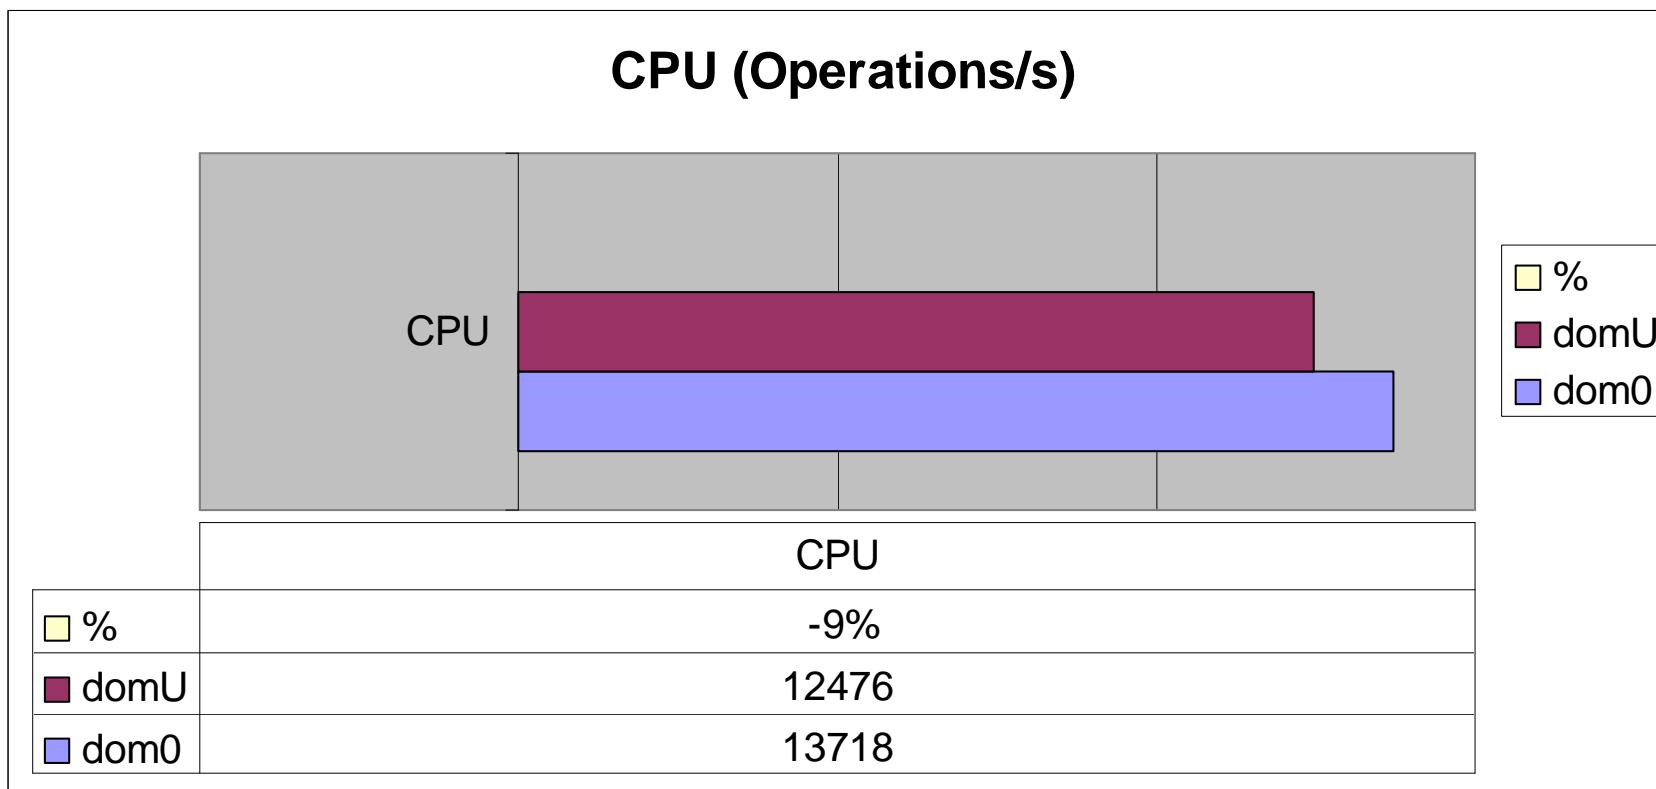
XEN - performances



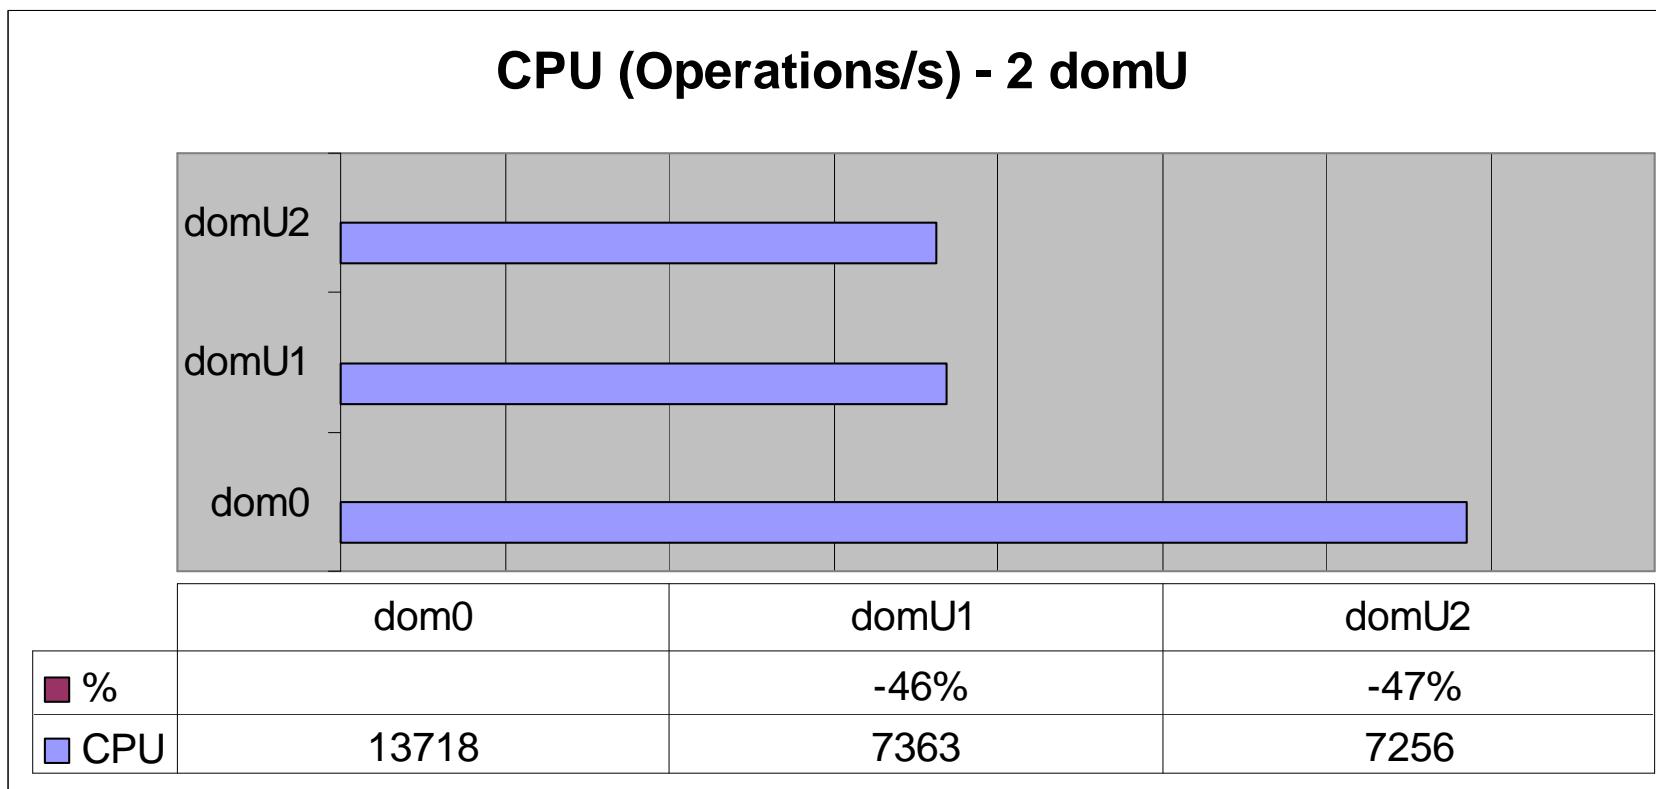
XEN - performances



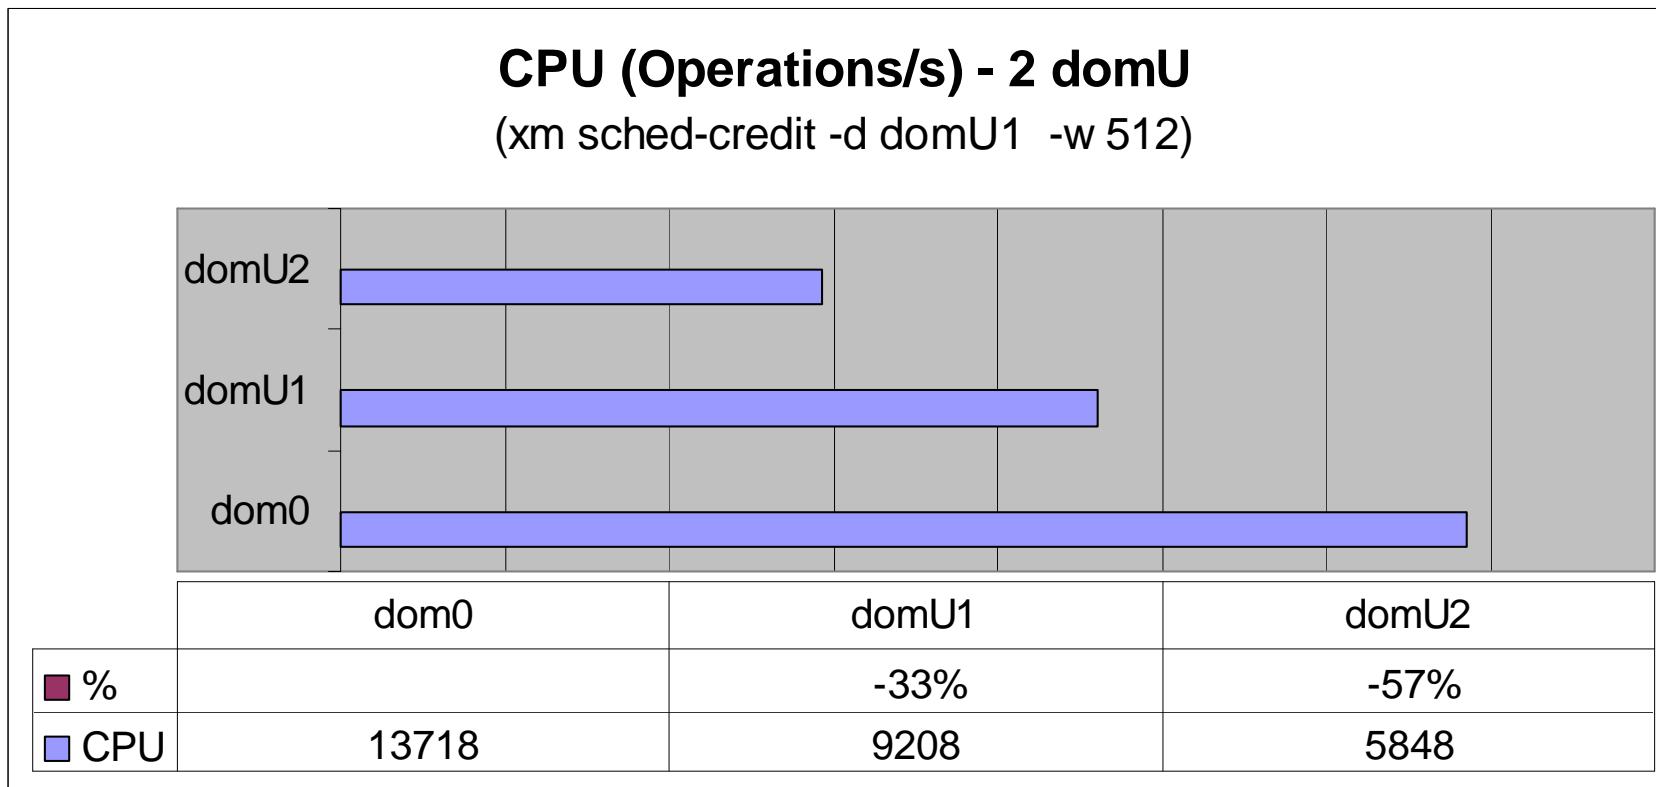
XEN - performances



XEN - performances

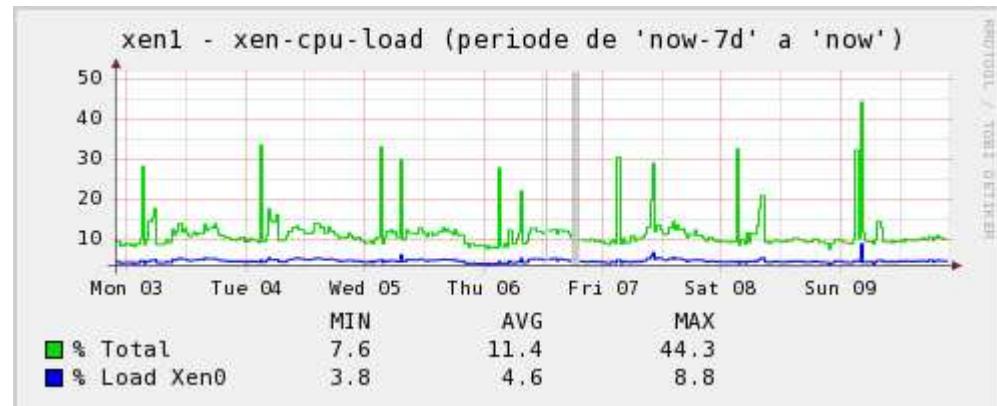


XEN - performances



XEN - performances

- 1 serveur « syslog »
- 1 serveur « DNS »
- 1 serveur « FlexLM »
- 1 serveur « Radius »

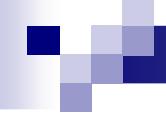


- 1 serveur physique non virtualisé utilise 15% de sa capacité

XEN – pour & contre

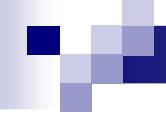
■ Limitations

- Berkeley DB est/était incompatible
- les librairies threadées sont à désactiver (fonctionnent, mais plus lentement)
- ne pas activer NTP dans les domU
(ce n'est pas un bug, mais une fonctionnalité : domU synchronisé avec dom0)
(ou modifier /proc/sys/xen/independent_wallclock)
- le plantage du dom0 (software ou hardware) entraîne le plantage de plusieurs domU (!)



XEN – pour & contre

- Outils d'administration basiques (OpenSource Xen)
 - xm (en mode texte)
 - quelques outils de monitoring en mode graphique
 - « assistant » de création d'images virtuelles et de fichiers de configuration ?
 - affichage de la configuration d'un domU ?
 - → Citrix XenServer ?



XEN – pour & contre

- « faiblesse » de l'ordonnanceur
 - Basé sur le « poids » des vCPU / domU
 - Pas de « QoS » I/O réseau
 - Pas de « QoS » I/O disque

XEN – pour & contre

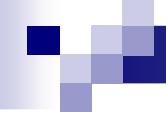
■ Erreurs de manipulation possible

□ 2 (ou plusieurs) dom0 avec les images domU partagées (SAN)

- [dom0A] # xm create domU1
[dom0B] # xm create domU1

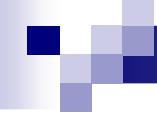
→ possible
→ pas longtemps ...

- → lvchange --available ey /dev/vgsan/domU
→ LiveMigration ?



XEN – pour ou contre ? pour !

- Fiabilité
→ Très peu (2 ou 3) de « xm destroy domU » en 1 an d'utilisation
- Perte de performances minime
- Facilité de déploiement
- Facilité d'augmentation de puissance de traitement
- Facilité de Reprise d'Activité
- Stress diminué !



Des questions ?