

# Introduction à ZFS

Matthieu Herrb



Capitoul, 26 février 2009

<http://www.laas.fr/~matthieu/talks/capitoul-zfs.pdf>

# Agenda

**1** Introduction

**2** Implémentation

**3** En pratique

**4** Conclusion

# Agenda

**1** Introduction

2 Implémentation

3 En pratique

4 Conclusion



version commerciale de l'OS de Sun.  
Actuellement version 10/08.  
Favorise la stabilité.



**opensolaris**

version Open-Source (CDDL).  
Développement de nouvelles fonctionnalités.  
Version courante 2008.11.  
OS orienté machines de bureau (Gnome)  
Live CD

# Présentation

Zetta ( $10^{21}$ ) byte file system.

- Développé par Sun Microsystems
- Introduit dans Solaris 10
- Licence CDDL
- Porté sur Mac OS X, Linux, FreeBSD, . . .
- Dernières versions dans OpenSolaris

# Principes de conception

Systeme de fichiers pour les 20 prochaines années:

- Pas de limites pratiques (taille des disques, fichiers, ...)
- Garantir la sécurité des données (intégrité, disponibilité)
- Administration simplifiée
- Gestionnaire de volume intégré
- Performances élevées
- Indépendant de l'architecture matérielle

# Fonctionnalités

- Snapshots
- Clones
- Quotas et réservation d'espace
- Compression
- Duplication
- Export/Import

# Agenda

1 Introduction


**2 Implémentation**

3 En pratique

4 Conclusion

# zpool

Un pool est un ensemble de périphériques qui fournissent de l'espace pour le stockage et la duplication des données.




- Construit à partir de périphériques virtuels (vdevs)

## Unité de base de stockage de données

- disques : entiers ou juste une partition
- fichiers dans un autre système de fichiers
- miroirs : 2 (ou plus) disques, partitions ou fichiers
- raid-z : plusieurs disques, variante de RAID-5

# Architecture interne



## Plus en détails

- ZPL: Posix Layer: interface classique du système de fichiers.
- DMU: Data management unit: coeur de la gestion des données dans les pools. Modèle transactionnel.
  - ZAP attribute processor
  - DSL Data snapshot layer
  - ZIL Intention Log
  - ARC Adaptative replacement Cache
  - ZIO Couche d'entrées sorties vers les vDevs.4

## Miroir classique

Utilise les mécanismes de checksum pour valider les lectures sur un composant,

Bascule sur le second composant si détection d'erreur,

Correction du composant défaillant (si possible).

- Similaire au RAID-5 (parité distribuée)
- Utilise les checksums (SHA-256 + fletcher)
- Rpose sur le copy on write : supprime le "write-hole".


Si beaucoup de disques : RaidZ2 (double la parité).

# Copy on Write (CoW)

## Modification d'un bloc de données


### Méthode traditionnelle

Read/Modify/Write



### Copy on write

Read/Write/update




Gain de performance, meilleure résistance aux coupures.

# Performances

[Nau 06]

Ontario T2000 utilizing 90GB stripe configuration



# Agenda

1 Introduction

2 Implémentation

**3 En pratique**

4 Conclusion

# Commande zpool

## Gestion des zpools

- Création
- Destruction
- Import/Export
- Ajout de stockage
- Visualisation état, performances

# Commande zfs

## Gestion des systèmes de fichiers

- Création/destruction
- Montage
- Gestion des attributs (export NFS, compression, etc.)
- Snapshots/Clones
- Sauvegardes

# Exemple: creation d'un pool

## Raidz

```
zpool create mypool raidz disk0 disk1 disk2 disk3  
disk4
```

## miroir

```
zpool create mypool mirror disk0 disk1
```

## concaténation

```
zpool create mypool disk0 disk1
```

# Exemple: création de systèmes de fichiers

## Création de home directories

```
zfs create mypool/home  
zfs create mypool/home/alice  
zfs create mypool/home/bob  
zfs create mypool/home/charlie
```

## Définition d'un point de montage

```
zfs set mountpoint=/home mypool/home
```

# Exemple: quotas et reservation

## Définition d'un quota

```
zfs set quota=10G mypool/home/alice  
zfs list
```

## Définition d'une réservation

```
zfs set reservation=5G mypool/home/alice  
zfs list
```

# Exemple: snapshots

## Création d'un snapshot

```
zfs snapshot -r mypool/home@jeudi_12h15  
zfs list -t snapshot  
ls -l .zfs/snapshot/
```

## Restauration d'un snapshot

```
zfs rollback mypool/home@jeudi_12h15
```

# Exemple: exportation

Utile pour la gestion des supports amovibles.

Exportation avant déconnexion

```
zpool export mykey
```

Importation d'un support après reconnexion

```
zpool import mykey
```

# Exemple: suivi de l'état

## Commandes d'inspection

```
zpool status  
zpool iostat 10  
zpool scrub mypool
```

# Agenda

1 Introduction

2 Implémentation

3 En pratique

**4 Conclusion**

# Un système de stockage pour l'avenir

- Prendre en compte la capacité croissante des supports et des données
- Simplification de l'administration.
- Meilleures performances: moins besoin de systèmes dédiés  
(ou meilleure utilisation de ces derniers)
- Techno mûre, en pleine expansion.
- Concurrents : ext4, btrfs, hammer...

# Intégration avec le système

## OpenSolaris:

- Gestion des “Environnements de boot”:  
création d'un clone avant une mise à jour: permet de revenir en arrière.  
Commande beadm: intégration avec grub pour sélectionner le clone à booter.
- Time Slider : “clone” de time machine,  
implémenté sous forme de service.  
Extension nautilus (file manager de gnome) pour explorer les snapshots.
- Utilisation de clones avec zones ou machines virtuelles:  
déduplication.

ZFS est ouvert à des extensions - nouvelles fonctionnalités.  
En cours:

- Retrait d'un device d'un pool
- Déduplication
- Chiffrement
- ...vDevs distants

# Bibliographie

- Nau06** Thomas Nau, *Peta, Exa, Zetta: looking at 18+ months of ZFS Experience*, SunHPC 2006, Singapour, mai 2006.
- Bonfils08** Bruno Bonfils, *OpenSolaris: fonctionnement des zones et ZFS*, Conférence Guses, Toulouse, octobre 2008.
- Banham07** J. Banham & J. Nash, *ZFS Under the Hood*, London Solaris User's Group, mai 2007.