

# Construindo seu próprio storage usando ZFS

27/11/2014

Fernando Frediani



GTER 38

GTS 24

# Disclaimer

- **Eu não tenho qualquer relação com qualquer um dos fabricantes mencionados e não recebo quaisquer benefícios deles.**
- **O conteúdo mencionado nesta apresentação é baseado na minha visão pessoal adquirida durante pesquisa, desenvolvimento e uso dessas tecnologias ao longo dos anos.**
- **Eu não garanto que as informações apresentadas aqui são livres de erros e não posso me responsabilizar por perdas e danos causados pelo seu uso. Portanto eu fortemente recomendo não utiliza-las em ambientes importantes para a empresa e/ou sem cópia de segurança dos dados.**



# Introdução

Por que construir seu próprio storage ?



# Introdução

- Storage hoje em dia, em muitos casos, por ser responsável por até 50% dos custos de uma plataforma.
- Nem todo dado precisa ser armazenado em um storage “Enterprise” Super-Rápido e de Altíssima Disponibilidade.
- Você pode construir seu próprio Storage compartilhado usando componentes de baixo custo, tecnologia livre e gratuita, ainda sim mantendo um ótimo nível de confiabilidade e performance.
- O objetivo desta apresentação **não é** desencorajar o uso de Storage Enterprise ou tradicionalmente usado, porém de mostrar uma alternativa para se balancear aonde cada tipo de dado pode ser armazenado.



# Resumo

## A receita

- Especificações do Servidor
- Hard Drives
- Solid State Drives (SSDs)
- Controladores RAID
- Placas de Rede
- Cabeamento
- Sistemas Operacionais
- Sistema de Arquivos (ZFS)
- Sistema de Gerenciamento
- Extras (JBOD para Expansão , High-Availbiliy, etc)



# Resumo

## ■ Possíveis casos de uso

- ISO / Repositório de Templates
- Datastore para Maquinas Virtuais em ambientes LAB / Testing.
- Storage para Sistemas de Backup.
- Armazenar grande quantidades de dados que não necessitam estar online 24/7.
- Para sistemas de alta performance (centenas de milhares de IOPS)

## ■ Pontos fracos

- “Single controlled” – Downtime é necessário para atualização do sistema.
- Downtime prolongado se o hardware falhar.
- Necessita de conhecimento mais especializado.
- Suporte de hardware mais restrito.
- Dificuldade em obter suporte se o problema for relacionado a storage (ex: VMware).

# Servidor

- Servidores 3U ou 4U with 16 ou 24 x 3.5” disk slots.
- Placa mãe (1-2 sockets)
- 1-2 Quad-core CPU dependendo da quantidade de “live data”.\*
- Mínimo de 24-32 GB de Memória um bom cache\*\*(quanto mais melhor).
- 2 x 2.5” discos internos para o Sistema Operacional.
- 2 x Fontes de Alimentação



\* Para funcionalidades como NFS e/ou compressão de grandes quantidades de dados é recomendado utilizar 2 CPUs.

\*\* Se utilizar deduplication, memória extra deve ser considerada.

# Hard drives

## ■ Enterprise class

- SAS or SATA
  - Seagate Constell ES.2, Hitachi Ultrastar, etc
- 7200 RPM, 10.000 RPM, 15.000 RPM
- **NÃO UTILIZAR** Green Drives.
- Single or Dual port
- Evite misturar SAS e SATA

## ■ SSDs

- MLC – Cache de Leitura (ZFS L2ARC)
- SLC e eMLC– Para Escrita (ZFS ZIL)
- DRAM based (STEC ZeusRAM, DDR Drive) (ZFS ZIL)





# Controladores RAID

- Os controladores RAID devem ser capazes de operar em modo JBOD e permitir ao ZFS o controle direto dos discos – IT-mode (Sem hardware RAID).
- Ser bem suportado pelo sistema operacional.
- Não é necessário utilizar controladores com bateria.



# Controladores RAID

## ■ LSI 9211-8i

- 2 conectores Mini-SAS (1 para os discos internos de 2.5", 1 para o backplane).
- Fusion MPT 2.0 IO Controller
- 600 MB/s bandwidth per lane
- Até 256 SAS/SATA hard drives
- Mais de 320,000 IOPS



# Controladores RAID

## ▪ LSI 9200-8e

- 2 conectores Mini-SAS (SFF8088) (Para expansão utilizando JBODs adicionais).
- Fusion MPT 2.0 IO Controller
- 600 MB/s bandwidth per lane
- Até 512 SAS/SATA hard drives
- Mais de 320,000 IOPS



# Placas de Rede

- Placas de rede adicionais são recomendadas para banda extra e separação de rede.
- Configuração típica (2 portas onboard para Gerenciamento + 2 portas adicionais para o tráfego de Storage)
- Placas Intel são conhecidas por terem ótimo suporte e estabilidade (82540EM, 82574L, 82575EB, 82576)
- Portas 10 Gigabit - Intel and Emulex funcionam bem.
- **Redundância de Switch**
  - Usar port-channel ou IPMP (Similar ao Bonding do Linux).

# Cabeamento

Discos Internos – 2.5” Sistema Operacional L2ARC ZIL



SFF-8087 to 4 x SFF-8482



\*\*\* Caso utilizar as portas SATA Onboard, configura-las em modo AHCI.



# Cabeamento

## Interno - Backplane



# Sistemas Operacionais

## ■ 3 escolhas de Sistemas Operacionais

- OpenIndiana (Open Source, CLI ou GUI com Time Slider) – Baseado em IllumOS.
- OmniOs (instalação mínima servidor) – Baseado em IllumOS.
- Oracle Solaris Express 11 (Sem uso comercial).



# Sistema de Arquivos - ZFS

- Built in RAID
- Ótima integridade dos dados
- Online scrub (“similar ao fsck”)
- Snapshots ilimitados
  - Send/Receive – Async remote replication
- ARC, L2ARC and ZIL
- Modelo Copy-on-write
- Deduplication
- Encryption
- Compressão
- Expansão Online
- Limite impossível de ser atingido (128 bit filesystem)
- Etc...





# Sistema de Arquivos - ZFS

- Uma pool ZFS (zpool) é constituída de um ou mais “vdev’s”.
- Um “vdev” tradicionalmente é constituído de vários hard drives em RAID ou em Mirrors (RAID 1).
- **Modos ZFS RAID**
  - Non-redundant (similar ao RAID 0)
  - Mirrors (Similar ao RAID1 – Vários vdevs juntos similar ao RAID 10)
  - RAIDZ – (Similar ao RAID 5) (Não recomendado para mais de 4 discos)
  - RAIDZ2 – (Similar ao RAID 6)
  - RAIDZ3 – (Similar ao RAID 6 porém com 3 discos usados para paridade)
- “zvols”(iSCSI, FibreChannel) e Shares (CIFS, NFS, WebDAV, Rsync) são criados em cima da pool ZFS.



# Sistema de Arquivos - ZFS

## ■ ZVOLs

- Um “block device” virtual que pode ser exportado via iSCSI ou Fibre Channel usando COMSTAR.
- Pode ser Thin-provisioned.
- Tamanho do bloco pode ser variável.
- Compressão (LZJB or LZ4) pode melhorar performance.
- Deduplicação (Usar com cuidado)

## ■ Shares

- Um diretório em cima da pool ZFS que pode ser exportado via NFS, CIFS, WebDAV, Rsync, etc
- Funcionalidades similares ao ZVOL



# Sistema de Gerenciamento

- **Napp-it - <http://www.napp-it.org>**

- Interface Web bastante funcional para gerenciar ZFS.
- Extensões Non-free disponíveis (Remote Replication, ACL e Gerenciamento Avançado de Usuários, Monitoramento) – Custo pequeno para o desenvolvimento do projeto.

The screenshot displays the napp-it web interface for managing ZFS pools. The top navigation bar includes links for napp-it, Help, Services, System, User, Disks, Pools, Snaps, Comstar, Jobs, Extensions, Add-Ons, and My menus. The main content area shows a breadcrumb trail: home > Pools > Help > Create Pool > Add Vdev > Smart > Export > Destroy > Poolinfo > Benchmarks. A table titled 'Pools and Volumes' lists three pools: rpool, titan, and zeus, with columns for VER, SIZE, ALLOC, RES, FRES, and FREE. Below this, the 'zpool status' section provides detailed information for two pools: rpool and titan. For rpool, it shows the state as ONLINE, no scan requested, and a configuration table with columns for NAME, STATE, READ, WRITE, CKSUM, CAP, and Product. The rpool configuration includes a raid1-0 vdev and three 1000.20 GB vdevs. For titan, it also shows ONLINE state, no scan requested, and a configuration table with columns for NAME, STATE, READ, WRITE, CKSUM, CAP, and Product. The titan configuration includes a raid1-0 vdev and four 2.00 TB vdevs. A context menu is open over the 'ZFS Folder' header, listing actions: Help, Create, Rename, Destroy, Snapshots, acl extension, zfsinfo, and reload.

Pool	VER	SIZE	ALLOC	RES	FRES	FREE
rpool	-	928G	11.1G	-	-	917G
titan	-	7.25T	2.32T	-	-	4.93T
zeus	-	1.81T	1.22T	-	-	605G

```
zpool status

pool: rpool
state: ONLINE
scan: none requested
config:

    NAME                STATE          READ WRITE CKSUM
    rpool                ONLINE         0   0   0
    c8t1d0a0              ONLINE         0   0   0
                                CAP             1000.20 GB
                                Product          WDC WD1002FRRS-0

errors: No known data errors

pool: titan
state: ONLINE
scan: none requested
config:

    NAME                STATE          READ WRITE CKSUM
    titan                ONLINE         0   0   0
    raid1-0              ONLINE         0   0   0
    e3t5000C500342F848A00 ONLINE         0   0   0
    e3t5000C5003EDC490140 ONLINE         0   0   0
    e3t5000C5003ED07774E60 ONLINE         0   0   0
    e3t5000C5003ED0F809840 ONLINE         0   0   0
                                CAP             2.00 TB
                                Product          ST32000641AS

errors: No known data errors
```

# Extras

- **JBOD para Expansao**

- Não necessita de CPU, Motherboard, Memória, etc.
- Mais barato do que um chassis convencional.
- Consumo menor de energia.
- Fácil de expandir (expansão online através de cascading ou stacking).

- **High availability**

- Não é fácil. Possível utilizando PaceMaker/Heartbeat.
- Necessita utilizar 'dual port' hard drives (sem SATA).
- Chassis 1U ou 2U podem ser utilizados como controladores.
- Sem discos para pool ZFS nos nodes controladores. Somente para o SO.



# Extras

- **Sistema All-in-one**

- ESXi + ZFS no mesmo servidor físico.
- Appliance virtual ZFS Storage em cima do ESXi
- Exporta via NFS or iSCSI

- **Pré-requisitos**

- Servidor capaz de VT-d.
- PCI-passthrough para o controlador RAID ao Appliance virtual.
- VMXNET3 para melhor performance interna.

- <http://www.napp-it.org/doc/downloads/all-in-one.pdf>



# Extras

- **Monitoramento**

- SNMP - Estatísticas
- Nagios - nrpe plugin
- IPMI – para monitoramento extra de hardware.
- S.M.A.R.T

- **Supporte**

- Opeindiana é suportado pela comunidade de usuários e desenvolvedores.
  - <http://openindiana.org/support/>
  - <http://wiki.openindiana.org/oi/OpenIndiana+Wiki+Home>
- OmniOS possui suporte comercial da OmniTI
  - <http://omniti.com/does/omnios>
- Solaris 11.1 possui suporte comercial da Oracle
  - Conferir se o hardware é compatível com a HCL

# Extras

- **ZFS on Linux** - <http://zfsonlinux.org/>
  - ZFS está sendo portado para Linux pelo Lawrence Livermore National Laboratory (LLNL)
  - Disponível na maioria das distribuições mais utilizadas.
  - Ainda não recomendado para produção.
  - Ainda não otimizado para performance
  - Vale a pena dar uma olhada e seguir.
- **ZFS no FreeBSD**
  - Disponível e estável
  - FreeNAS é o projeto mais popular relacionado - <http://www.freenas.org/>
    - Roda de um USB stick
  - Performance é boa o suficiente, porém não como nos Sistemas Operacionais derivados de Solaris.

# Exemplos de Configuração

- Configuração 1 - Pequeno

Chassis	Supermicro 3U
CPUs	1 Quad-core
Memory	24GB
Disks	16 x 1TB SATA
SSDs	2 x 40GB Intel SATA (OS), 1 x 240GB Intel MLC (L2ARC), 1 x SLC or eMLC (ZIL)
ZFS Pool	2 x RAIDZ2
Network	1 x Dual port NIC
RAID Controller	1 x LSI 9211-8i
Extras	None
Usable space	12TB
<b>Total cost</b>	<b>~£4100 - (R\$ 25.000)</b>



# Exemplos de Configuração

- Configuração 2 - Médio

Chassis	Supermicro 4U
CPUs	1 Hex-core
Memory	96GB
Disks	22 x 2TB SAS
SSDs	2 x 300GB SAS (OS), 1 x Samsung SM1625 400GB(L2ARC), 1 x 8GB STEC ZeusRAM (ZIL)
ZFS Pool	11 x Mirrors
Network	1 x Quad port NIC
RAID Controller	1 x LSI 9211-8i
Extras	1 x LSI 9200-8e (for future expansion)
Usable space	22TB
<b>Total cost</b>	<b>~£9000 – (R\$ 50.000)</b>

# Exemplos de Configuração

- Configuração 3 - Grande

Chassis	Supermicro 4U
CPUs	2 Hex-core
Memory	192GB
Disks	66 x 2TB SAS
SSDs	2 x 300GB SAS (OS), 1 x Intel 910 800GB PCI-e (L2ARC), 2 x 8GB STEC ZeusRAM (ZIL)
ZFS Pool	8 x RAIDZ2
Network	1 x Dual 10Gb Nic
RAID Controller	1 x LSI 9211-8i
Extras	1 x LSI 9200-8e, 2 x 4U Expansion JBOD, 2 Hot spare disks
Usable space	96TB
<b>Total cost</b>	<b>~£24750 – (R\$ 100.000)</b>

# Recomendações

- Checar Hardware Compatibility List para o SO escolhido.
  - <http://wiki.openindiana.org/display/oi/Community+HCL>
  - <http://illumos.org/hcl/>
  - <http://www.oracle.com/webfolder/technetwork/hcl/data/s11ga/index.html>
- Mantenha sempre componentes reservas no local – É mais barato do que suporte de hardware premium.
  - CPUs e Motherboard
  - Controlador RAID
  - Discos
  - Cabos
- Coloque o máximo possível de RAM.
- Utilize um número razoável de ‘vdevs’ para uma maior performance.
- Se a zpool chegar a perto de 80% da capacidade, aumente-a para evitar problemas de performance.



**Perguntas ?**



# Obrigado

Contato: [fhfrediani@gmail.com](mailto:fhfrediani@gmail.com)

