ZFS Grundlagen am Beispiel Proxmox VE(Stand Januar 2025)

Der Verfasser des Artikels, Christian-Peter Zengel, hat zum Zeitpunkt des Artikels ca **15 Jahre Erfahrung mit ZFS und Proxmox. Er betreibt aktuell ca 150 Systeme mit Proxmox und ZFS**

Das Einsatzgebiet geht von Standaloneinstallation bis zu ca 10 Hosts im Cluster. **Es ist keine Ceph Expertise vorhanden!**

> Dieser Dokumentation basiert auf diesem online Kurse von cloudistboese.de
>
> 21. + 23.01.2025 (13.00 Uhr bis 17.00 Uhr) - ZFS Grundlagen

ZFS ist die perfekte Grundlage für kleine und mittlere Systeme um gegen Ausfälle, Dummheit anderer und Erpressungstrojanern ideal aufgestellt zu sein.
In diesem Kurs erhalten sie Grundkenntnisse für Systeme wie Proxmox, TrueNAS oder ähnliche Systeme.

Der Fokus liegt auf der Technologie und der permanenten Sicherheit im Umgang mit Daten, Linux und dem Terminal.

Themen:

- Begrifflichkeiten und Überblick
- Basisfunktionen von Proxmox und TrueNAS per GUI
- Erklärung und Beispiele Snapshots und Rollbacks
- Praxisbeispiele Replikation
- Prüfung der Replikationen
- Weitere Features die das Leben massiv erleichtern

Nach diesem Kurs bist Du bei Ausfällen und Datenverlust vor dem Schlimmsten geschützt und in Minuten wieder produktiv!

> https://de.wikipedia.org/wiki/ZFS_(Dateisystem)
>
> https://www.proxmox.com/de/
>
> https://cloudistboese.de

So erstellt Proxmox VE seinen ZFS Raid

> zpool create -f -o cachefile=none -o ashift=12 rpool mirror disk1 disk2
>
> Destruktives Anlegen (-f), kein automatisches Importieren beim Start (-o cachefile=none)
> -o ashift=12 ist für 4k Festplatten, ashit=9 für 512e Disks, wobei man mit 12 nichts verkehrt macht
> rpool ist der Name vom künftigen Pool, mirror der Raidlevel und die Disks wurden zweifelsfrei über Ihre ID definiert
>
> Optionen für Raidlevel wären noch: ohne als Stripe, raidz, raidz2 oder raidz3, also Raid Level 5-7

Dokument 142
Bearbeitet

```
zpool create #erstellt raid
-f force #overwrite
-o cachefile=none #das teil merkt sich die letzte importsituation
-o ashift=12 #es gab früher 512e Disk, inzwischen ist 4k Standard
rpool mirror /dev/disk/by-id/ata-CT1000BX500SSD1_2348E88597D2-part3 /dev/disk/by-id/ata-
CT1000BX500SSD1_2348E885985B-part3


ashift=9  =  512b
ashift=12 = 4096b

RaidZ(5) 4+4+4+R
Raid(1)  4+R

Virtuelles Volume war Standardmässig 8k
Virtuelle Volumes mit mindestens 16k, genauso gilt das auch für Dateien (Standard 128k)
```

Buchstaben: 501 · Auswahl: 6 - 1 · Worte: 79

> Die ersten Zpool Manöver und die endlose Aktionsliste sieht man mit
>
> zpool history

```
       NAME                                    STATE     READ WRITE CKSUM
       rpool                                   ONLINE       0     0     0
         mirror-0                              ONLINE       0     0     0
           ata-CT1000BX500SSD1_2348E88597D2-part3  ONLINE       0     0     0
           ata-CT1000BX500SSD1_2348E885985B-part3  ONLINE       0     0     0

errors: No known data errors
root@pvews:~# zpool history
History for 'rpool':
2025-01-20.14:52:00 zpool create -f -o cachefile=none -o ashift=12 rpool mirror /dev/disk/by-id/ata-CT1000BX500SSD1_2348E88597D2-part3 /
dev/disk/by-id/ata-CT1000BX500SSD1_2348E885985B-part3
2025-01-20.14:52:00 zfs create rpool/ROOT
2025-01-20.14:52:00 zfs create rpool/data
2025-01-20.14:52:00 zfs create rpool/ROOT/pve-1
2025-01-20.14:52:00 zfs set atime=on relatime=on rpool
2025-01-20.14:52:00 zfs set compression=on rpool
2025-01-20.14:52:00 zfs set sync=disabled rpool
2025-01-20.14:55:27 zfs set sync=standard rpool
2025-01-20.14:55:27 zfs set mountpoint=/ rpool/ROOT/pve-1
2025-01-20.14:55:27 zpool set bootfs=rpool/ROOT/pve-1 rpool
2025-01-20.14:55:27 zpool export rpool
2025-01-20.15:00:36 zpool import -N rpool
2025-01-20.15:44:29 zpool import -N rpool
2025-01-20.16:49:35 zpool import -N rpool
2025-01-20.16:50:42 zpool clear rpool
2025-01-21.10:16:45 zpool import -N rpool
2025-01-21.13:19:38 zpool offline rpool ata-CT1000BX500SSD1_2348E885985B-part3
2025-01-21.13:21:48 zpool online rpool ata-CT1000BX500SSD1_2348E885985B-part3
2025-01-21.13:22:30 zpool clear rpool
2025-01-21.13:28:54 zpool set autotrim=on rpool

root@pvews:~#
```

> Manuelles Trimmen der SSDs um gelöscht Blöcke schner überschreiben zu können findet man unter /etc/cron.d
> Ebenso wird nach diesem Zeitplan der sog. **zpool scrub** durchgeführt, der die Konsistenz der Redundanz prüft und ggf. korrigiert. Gefundene Fehler findet man dann mit **zpool status**

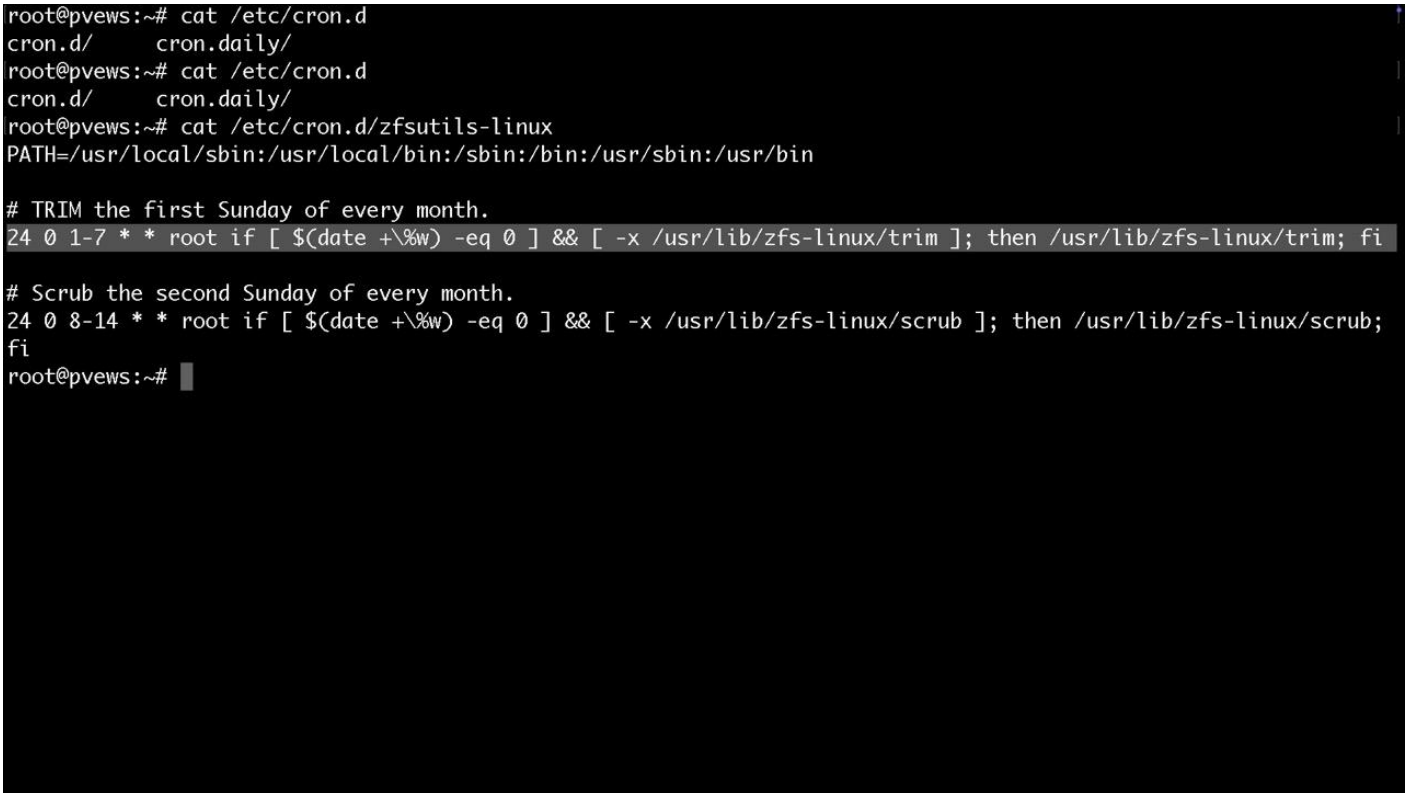

> Zum identifizieren der Platten bieten sich neben der PVE GUI noch folgende Befehle an. Es wird dringend empfohlen bereits genutzte Platten via PVE GUI zu wipen
>
> ```
> dmesg -Tw (live)
> lsblk
> ls -althr /dev/disk/by-id
> ```

```
root@pvews:~# lsblk
NAME                                                                                                  MAJ:MIN RM   SIZE RO TYPE MOUNTPOINT
sda                                                                                                     8:0    0   2.7T  0 disk
├─sda1                                                                                                  8:1    0   2.7T  0 part
└─sda9                                                                                                  8:9    0     8M  0 part
sdb                                                                                                     8:16   0   2.7T  0 disk
├─sdb1                                                                                                  8:17   0   2.7T  0 part
└─sdb9                                                                                                  8:25   0     8M  0 part
sdc                                                                                                     8:32   0   2.7T  0 disk
├─sdc1                                                                                                  8:33   0   2.7T  0 part
└─sdc9                                                                                                  8:41   0     8M  0 part
sdd                                                                                                     8:48   0   2.7T  0 disk
├─sdd1                                                                                                  8:49   0   2.7T  0 part
└─sdd9                                                                                                  8:57   0     8M  0 part
sde                                                                                                     8:64   0   2.7T  0 disk
├─sde1                                                                                                  8:65   0   2.7T  0 part
└─sde9                                                                                                  8:73   0     8M  0 part
sdf                                                                                                     8:80   0   2.7T  0 disk
├─sdf1                                                                                                  8:81   0   2.7T  0 part
└─sdf9                                                                                                  8:89   0     8M  0 part
sdg                                                                                                     8:96   0   2.7T  0 disk
├─sdg1                                                                                                  8:97   0   2.7T  0 part
└─sdg9                                                                                                  8:105  0     8M  0 part
sdh                                                                                                     8:112  0 931.5G  0 disk
├─sdh1                                                                                                  8:113  0  1007K  0 part
├─sdh2                                                                                                  8:114  0     1G  0 part
└─sdh3                                                                                                  8:115  0 930.5G  0 part
sdi                                                                                                     8:128  0 931.5G  0 disk
```

Erstellen verschiedener Raidlevel und Ihrer Vorzüge

> Mit ls -althr /dev/disk/by-id haben wir folgende Festplatten anhand ihrer aufgedruckten WWN Kennung identifiziert. Es ist dringend empfohlen bei HBAs sich die Slots und die Seriennummern beim Einbau zu notieren und in die Dokumentation aufzunehmen

wwn-0x5000cca01a72ded4 wwn-0x5000cca01a7b1e2c wwn-0x5000cca01a83a61c wwn-0x5000cca01a832d24 wwn-0x5000cca01a83331c wwn-0x5000cca01a7495b8 wwn-0x5000cca01a8417fc

Stripe, also Raid0

zpool create -f test wwn-0x5000cca01a72ded4 wwn-0x5000cca01a7b1e2c wwn-0x5000cca01a83a61c wwn-0x5000cca01a832d24 wwn-0x5000cca01a83331c wwn-0x5000cca01a7495b8

```
test                      ONLINE
 wwn-0x5000cca01a72ded4   ONLINE
 wwn-0x5000cca01a7b1e2c   ONLINE
 wwn-0x5000cca01a83a61c   ONLINE
 wwn-0x5000cca01a832d24   ONLINE
 wwn-0x5000cca01a83331c   ONLINE
```

```
 wwn-0x5000cca01a7495b8  ONLINE
 wwn-0x5000cca01a8417fc  ONLINE
```

Mirror, also Raid1

> zpool create -f test mirror wwn-0x5000cca01a72ded4 wwn-0x5000cca01a7b1e2c

```
test
 mirror
   wwn-0x5000cca01a72ded4
   wwn-0x5000cca01a7b1e2c
```

Striped Mirror, also Raid10

> zpool create -f test mirror wwn-0x5000cca01a72ded4 wwn-0x5000cca01a7b1e2c mirror
> wwn-0x5000cca01a83a61c wwn-0x5000cca01a832d24 mirror wwn-0x5000cca01a83331c
> wwn-0x5000cca01a7495b8

```
test
 mirror
   wwn-0x5000cca01a72ded4
   wwn-0x5000cca01a7b1e2c
 mirror
   wwn-0x5000cca01a83a61c
   wwn-0x5000cca01a832d24
 mirror
   wwn-0x5000cca01a83331c
   wwn-0x5000cca01a7495b8
```

RaidZ, also Raid 5, Nettoplatz x-1

> zpool create test raidz wwn-0x5000cca01a72ded4 wwn-0x5000cca01a7b1e2c wwn-
> 0x5000cca01a83a61c wwn-0x5000cca01a832d24 wwn-0x5000cca01a83331c wwn-
> 0x5000cca01a7495b8 wwn-0x5000cca01a8417fc

```
test                    ONLINE       0     0     0
 raidz1-0                 ONLINE       0     0     0
   wwn-0x5000cca01a72ded4  ONLINE       0     0     0
   wwn-0x5000cca01a7b1e2c  ONLINE       0     0     0
   wwn-0x5000cca01a83a61c  ONLINE       0     0     0
   wwn-0x5000cca01a832d24  ONLINE       0     0     0
   wwn-0x5000cca01a83331c  ONLINE       0     0     0
   wwn-0x5000cca01a7495b8  ONLINE       0     0     0
   wwn-0x5000cca01a8417fc  ONLINE       0     0     0
```

RaidZ2, also Raid 6, Nettoplatz x-2

> zpool create test raidz2 wwn-0x5000cca01a72ded4 wwn-0x5000cca01a7b1e2c wwn-0x5000cca01a83a61c wwn-0x5000cca01a832d24 wwn-0x5000cca01a83331c wwn-0x5000cca01a7495b8 wwn-0x5000cca01a8417fc

```
 raidz2-0                ONLINE       0     0     0
   wwn-0x5000cca01a72ded4  ONLINE       0     0     0
   wwn-0x5000cca01a7b1e2c  ONLINE       0     0     0
   wwn-0x5000cca01a83a61c  ONLINE       0     0     0
   wwn-0x5000cca01a832d24  ONLINE       0     0     0
   wwn-0x5000cca01a83331c  ONLINE       0     0     0
   wwn-0x5000cca01a7495b8  ONLINE       0     0     0
   wwn-0x5000cca01a8417fc  ONLINE       0     0     0
```

RaidZ-0, also Raid 5-0, Nettoplatz x-2, in diesem Beispiel

> zpool create test raidz wwn-0x5000cca01a72ded4 wwn-0x5000cca01a7b1e2c wwn-0x5000cca01a83a61c raidz wwn-0x5000cca01a832d24 wwn-0x5000cca01a83331c wwn-0x5000cca01a7495b8

```
test                    ONLINE       0     0     0
 raidz1-0               ONLINE       0     0     0
   wwn-0x5000cca01a72ded4  ONLINE       0     0     0
   wwn-0x5000cca01a7b1e2c  ONLINE       0     0     0
   wwn-0x5000cca01a83a61c  ONLINE       0     0     0
 raidz1-1               ONLINE       0     0     0
   wwn-0x5000cca01a832d24  ONLINE       0     0     0
   wwn-0x5000cca01a83331c  ONLINE       0     0     0
   wwn-0x5000cca01a7495b8  ONLINE       0     0     0
   wwn-0x5000cca01a8417fc  ONLINE       0     0     0
```

> “ oder mit Spare, wenn Du davon nicht booten musst

> zpool create test raidz wwn-0x5000cca01a72ded4 wwn-0x5000cca01a7b1e2c wwn-0x5000cca01a83a61c raidz wwn-0x5000cca01a832d24 wwn-0x5000cca01a83331c wwn-0x5000cca01a7495b8 **spare** wwn-0x5000cca01a8417fc

Erweiterung eines RaidZ zum RaidZ-0

```
test                    ONLINE       0     0     0
 raidz1-0               ONLINE       0     0     0
   wwn-0x5000cca01a72ded4  ONLINE       0     0     0
   wwn-0x5000cca01a7b1e2c  ONLINE       0     0     0
   wwn-0x5000cca01a83a61c  ONLINE       0     0     0
```

```
zpool add -n test raidz wwn-0x5000cca01a832d24  wwn-0x5000cca01a83331c  wwn-0x5000cca01a7495b8
```

```
test
 raidz1-0
   wwn-0x5000cca01a72ded4
   wwn-0x5000cca01a7b1e2c
   wwn-0x5000cca01a83a61c
 raidz1
   wwn-0x5000cca01a832d24
   wwn-0x5000cca01a83331c
   wwn-0x5000cca01a7495b8
```

Erweiterung eines Raid durch Ersetzen mit größeren Platten

> Die Platten müssen die Gleiche Geometrie hanben, also 4k zu 4k oder 512e zu 512e
>
> Bei Raid 1 und 10 reicht es zwei Disks zu tauschen, bei RaidZx müssen alle Disks getauscht werden
>
> Replace Vorgänge können auch laufen ohne die Redundanz zu brechen, wenn weitere Slots frei sind
>
> Bei Erweiterung durch Austausch von großen und vor allem älteren Raid 10 prüfen ob in einem Mirror ggf. neue Platten getauscht wurden, diese sollten weiter im Betrieb bleiben, während ältere Paare getauscht werden können

```
rpool-hdd
 mirror-0
   2024-8T (vorher Disk aus 2014)
   2024-8T (vorher Disk aus 2014)
 mirror-1
   2014-2T
   2021-2T
 mirror-2
   2022-2T
   2014-2T
```

Caches und Logdevices

> Vorsichtig formuloiert, Lese- und Schreibcache
>
> First Level Cache, sog. ARC kommt aus dem RAM und bekommt idealerweise ca. 1GB für 1TB Nettodaten
>
> Second Level Cache wird als Cachedevice als Partition auf einer schnelleren Disk als der Pool hat bereitgestellt, z. B. am idealsten mit NVMe

```
zpool add test -n cache sdl
```

```
test
 raidz2-0
   wwn-0x5000cca01a72ded4
   wwn-0x5000cca01a7b1e2c
   wwn-0x5000cca01a83a61c
   wwn-0x5000cca01a832d24
   wwn-0x5000cca01a83331c
   wwn-0x5000cca01a7495b8
   wwn-0x5000cca01a8417fc
cache
 sdl
```

> Logdevice (Writecache muss gespiegelt werden)
> Damit der Log auch genutzt wird muss man noch mit zfs set sync den cache aktivieren

```
zpool add test -n log mirror sdl
```

```
zfs set sync=always test
```

```
test
 raidz2-0
   wwn-0x5000cca01a72ded4
   wwn-0x5000cca01a7b1e2c
   wwn-0x5000cca01a83a61c
   wwn-0x5000cca01a832d24
   wwn-0x5000cca01a83331c
   wwn-0x5000cca01a7495b8
   wwn-0x5000cca01a8417fc
```

logs
mirror
sdl
sdk

> **Arc wird mit "arcstat 1" ausgelesen, er wird bei der Installation festgelegt oder später unter /etc/modprobe.d/zfs.conf geändert. update-initramfs -u macht das dann persistent und aktiviert die Änderungen beim nächsten reboot.**
> **Zur Laufzeit ändert man den Firstlevelcahce mit**
> **Cache- und Logdevices mit zpool iostat 1**

```
echo 2147483648 > /sys/module/zfs/parameters/zfs_arc_max
echo 1073741824 > /sys/module/zfs/parameters/zfs_arc_min
free -h && sync && echo 3 > /proc/sys/vm/drop_caches && free -h
```

```
arcstat 1
```

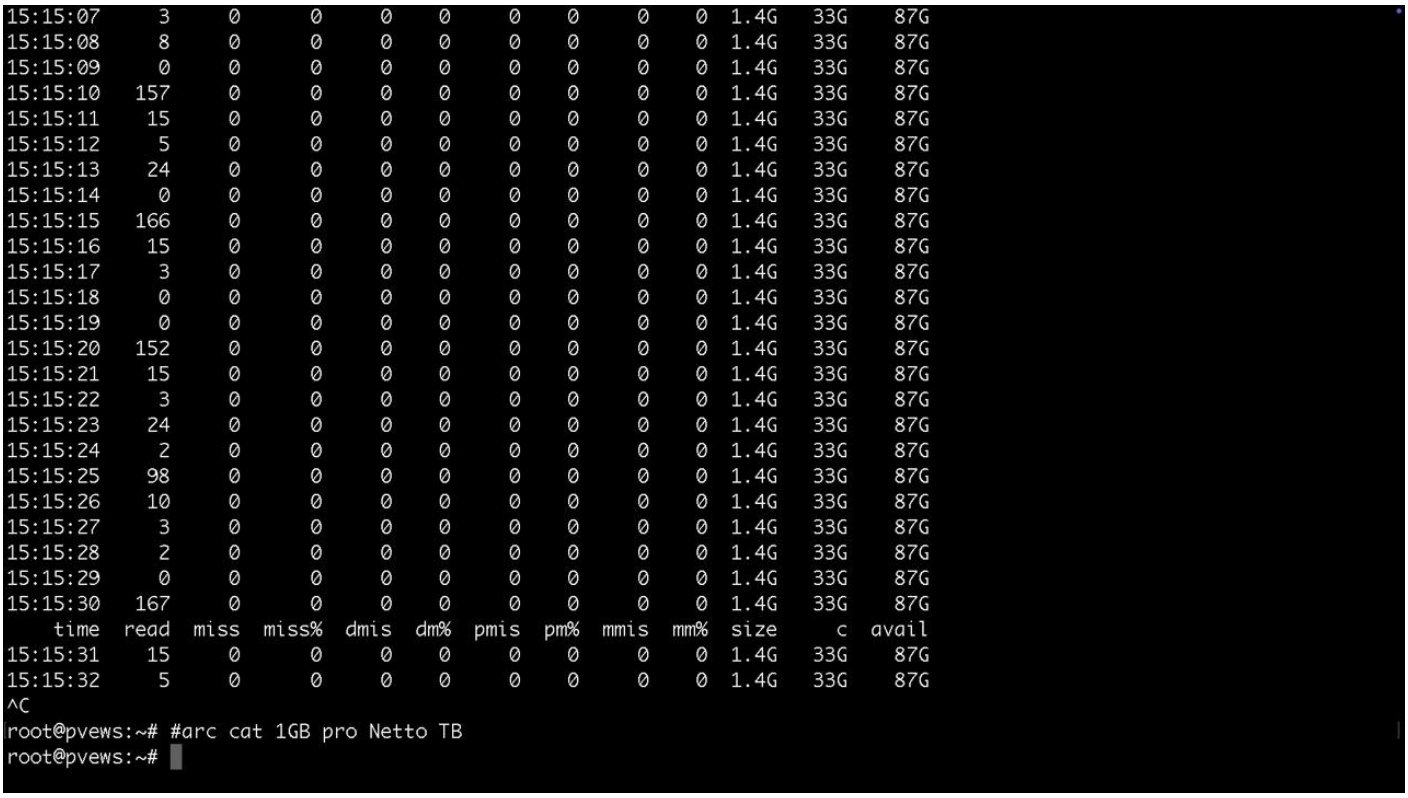

Test der Leistung eines Pools

```
zfs create -o compression=off test/speed
cd /test/speed
dd if=/dev/zero of=dd.tmp bs=256k count=16384 status=progress
dd if=/dev/zero of=dd.tmp bs=2M count=16384 status=progress
```

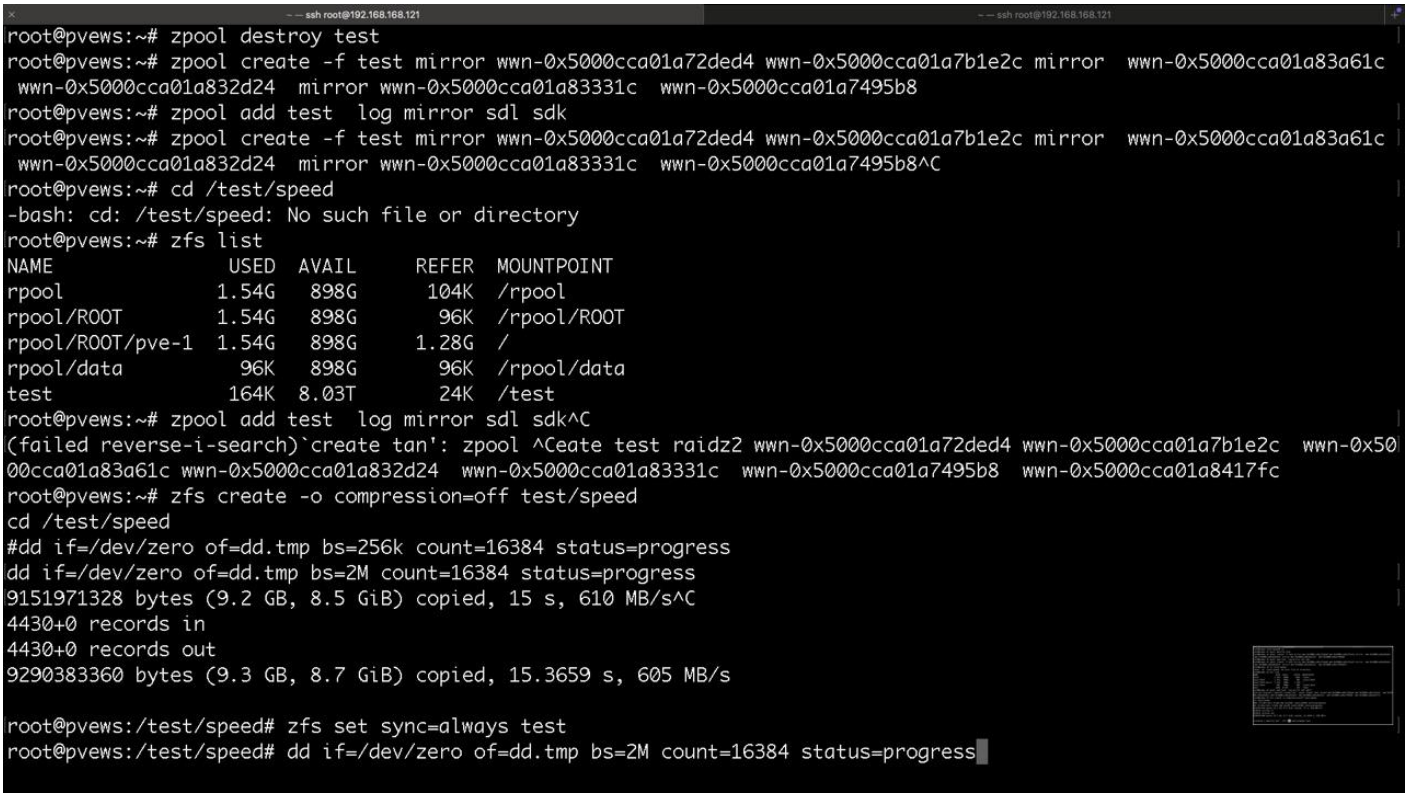

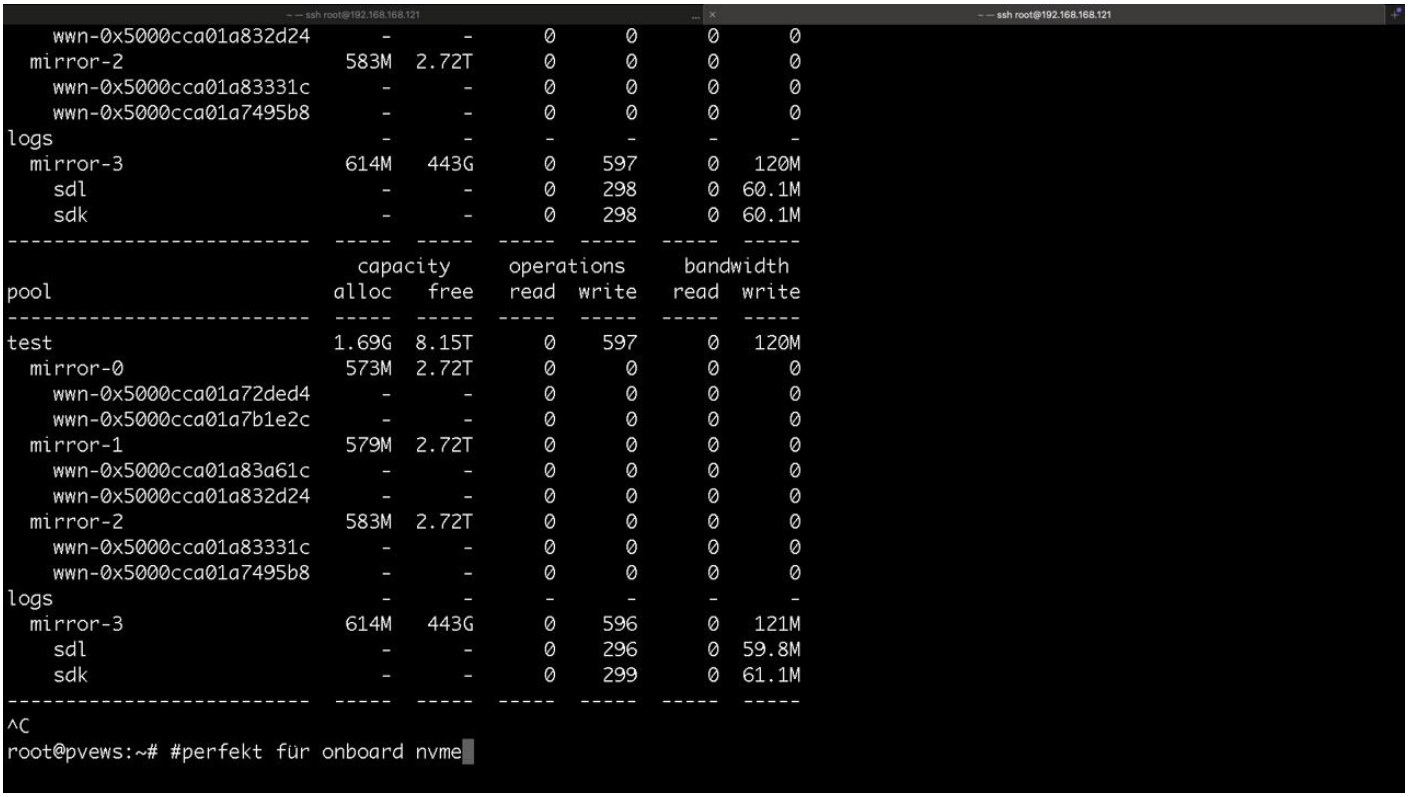

Erweiterung der Funktionen des Pools

```
```

> zpool status meldet neue Funktionen im ZFS und kann leicht und schnell mit
>
> > zpool upgrade -a
>
> erledigt werden
>
> Jedoch würde ich in jedem Fall empfehlen zu prüfen ob meine Notfall ISO diese Funktionen bereits unterstützt!

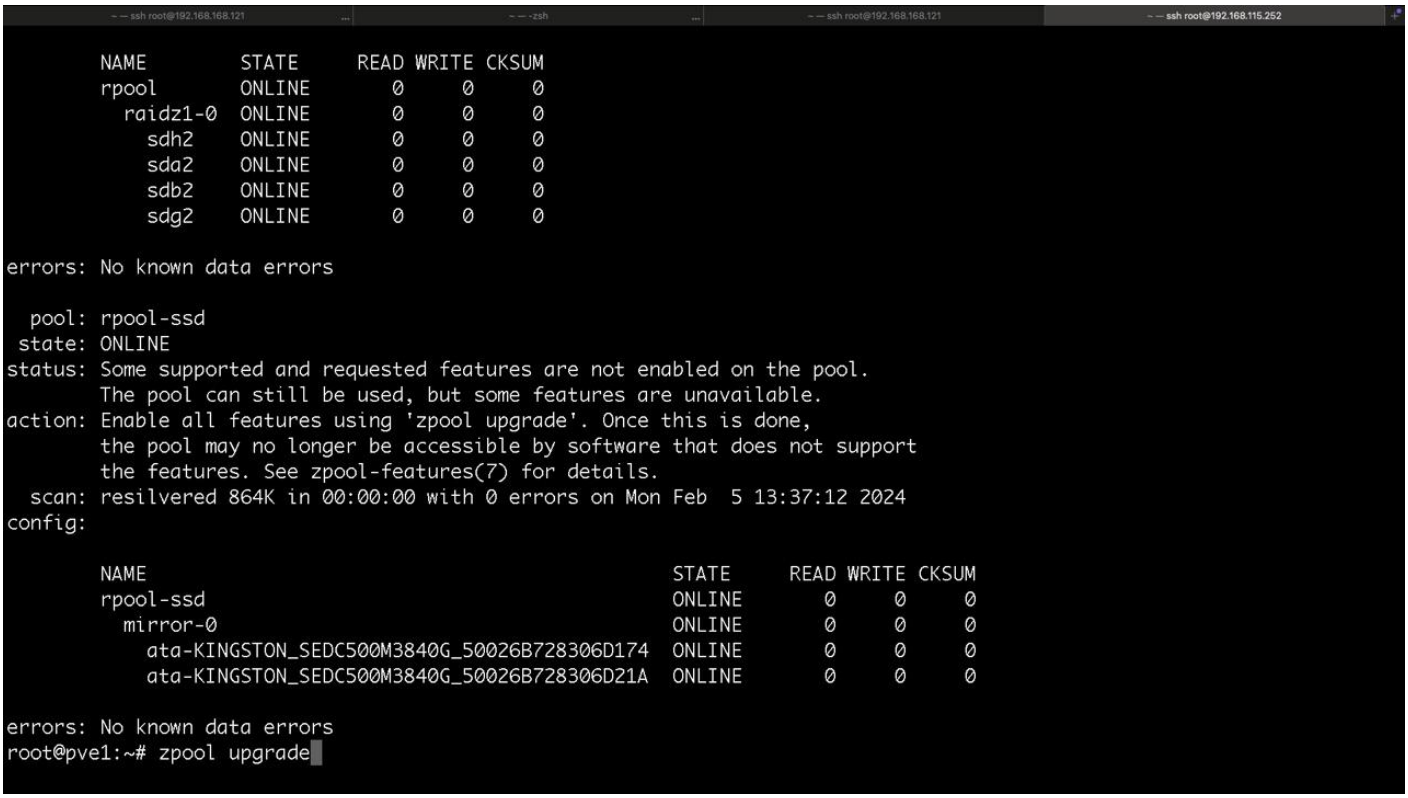

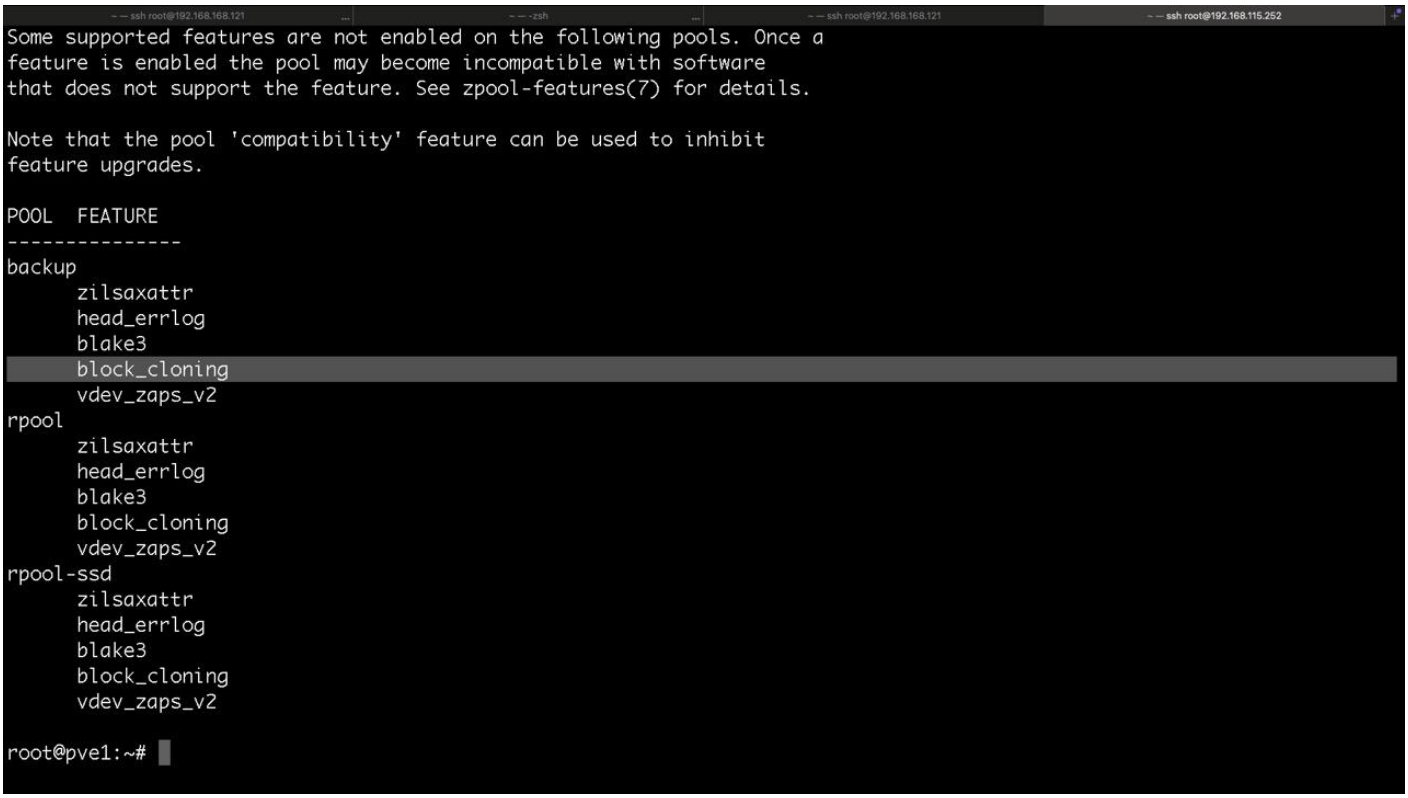

> Für das Auslesen der Parameter von Pools, Volumes, Datasets und Snapshots gibt es den Parameter **get**

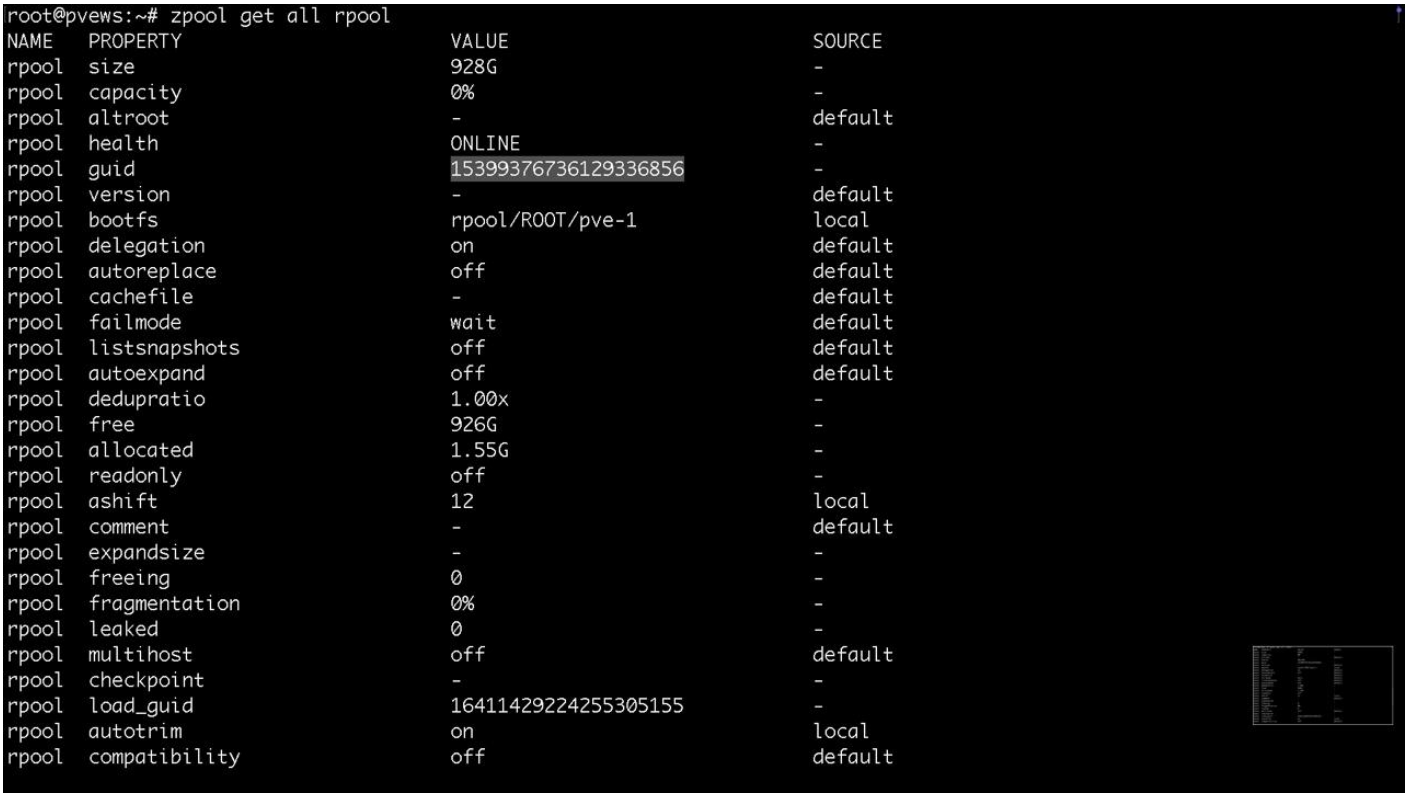

Bereitstellen und entfernen von Pools ohne löschen

> zpool import #zeigt was es zum importieren, also bereitstellen gibt
>
> zpool import poolname oder -a für alle importiert den Pool oder alle verfügbaren Pools
>
> Am elegantesten importiert man den Pool über
>
> **zpool import -d /dev/disk/by-id**
>
> damit man hinterher nicht sda, sdb, sondern die Bezeichner im Status sieht

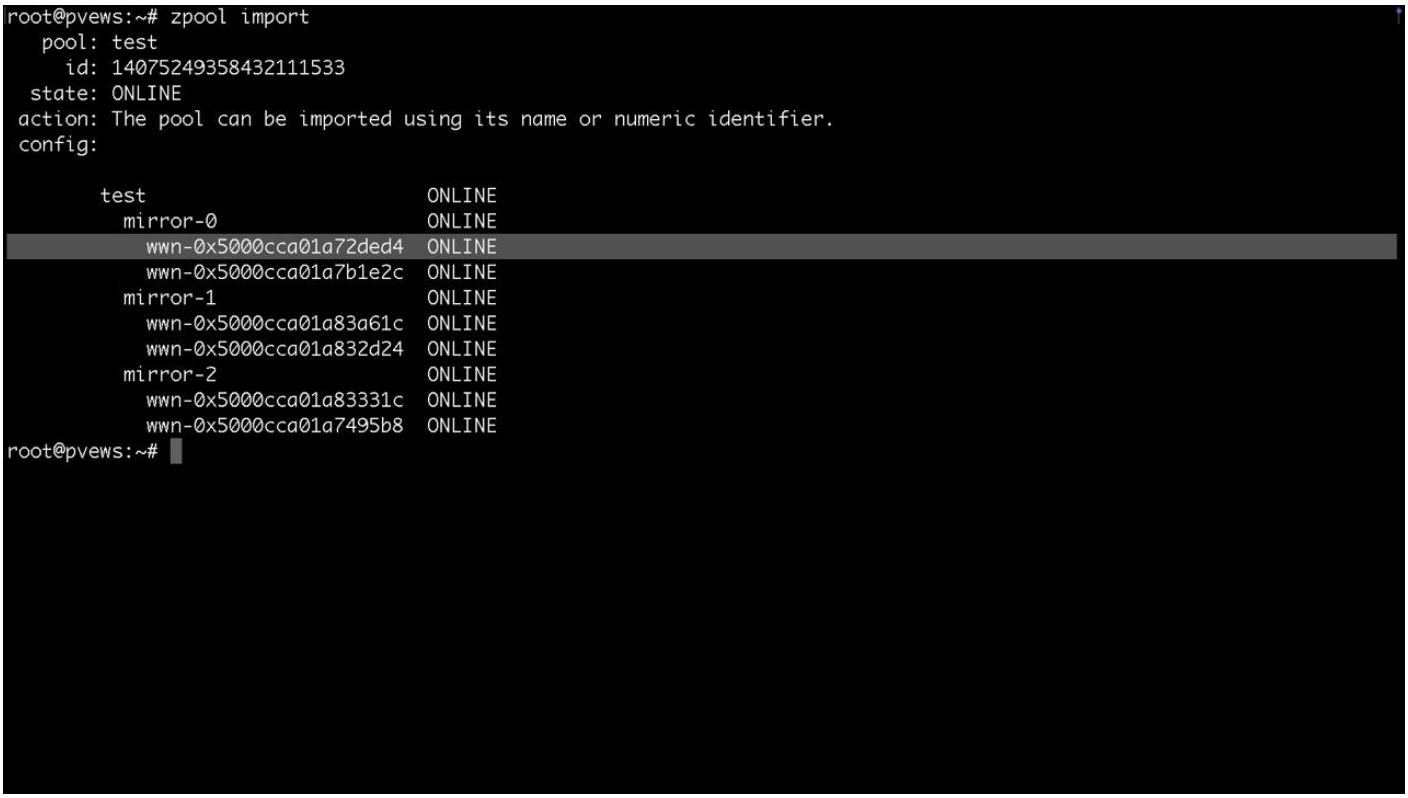

Nach der Bereitstellung würde man hier lediglich einen Mountpoint /test finden, bei TrueNAS /mnt/test. Dazu noch die Systemdatasets vom Proxmox selbst. Danach legen wir gleich mal ein Dataset namens dateisystem und ein Volume namens volume an.

```
root@pvews:~# zfs list
NAME               USED  AVAIL     REFER  MOUNTPOINT
rpool             1.55G   898G      104K  /rpool
rpool/ROOT        1.54G   898G       96K  /rpool/ROOT
rpool/ROOT/pve-1  1.54G   898G     1.28G  /
rpool/data          96K   898G       96K  /rpool/data
test               213K  16.1T     37.5K  /test
root@pvews:~# #zfs
root@pvews:~# zfs create test/dateisystem
root@pvews:~# zfs create -V 100G test/volume
root@pvews:~#
```

> Datasets werden als Ordner gemountet und / oder /mnt
>
> Volumes findet man unter /dev/zd... und zusätzlich mit vernünftigen Namen unter /dev/zvol/tankname/....

```
root@pvews:~# zfs list
NAME               USED  AVAIL     REFER  MOUNTPOINT
rpool             1.55G   898G      104K  /rpool
rpool/ROOT        1.54G   898G       96K  /rpool/ROOT
rpool/ROOT/pve-1  1.54G   898G     1.28G  /
rpool/data          96K   898G       96K  /rpool/data
test               213K  16.1T     37.5K  /test
root@pvews:~# #zfs
root@pvews:~# zfs create test/dateisystem
root@pvews:~# zfs create -V 100G test/volume
root@pvews:~# zfs list
NAME               USED  AVAIL     REFER  MOUNTPOINT
rpool             1.55G   898G      104K  /rpool
rpool/ROOT        1.54G   898G       96K  /rpool/ROOT
rpool/ROOT/pve-1  1.54G   898G     1.28G  /
rpool/data          96K   898G       96K  /rpool/data
test               110G  16.0T     25.4K  /test
test/dateisystem    24K  16.0T       24K  /test/dateisystem
test/volume        110G  16.1T       12K  -
root@pvews:~#
```

> Datasets werden mit Linuxcontainern, Backupfiles, Vorlagen oder Serverdateien bespielt
>
> Volumes verhalten sich wie eingebaute Datenträger, jedoch virtuell. Sie stehen nach dem Import des Pools bereit und können in einer VM genutzt werden. Manipulationen an Volumes zur Vorbereitung oder Datenrettung können jedoch ebenso auf dem PVE Host vorgenommen werden

> Diese Schritte übernimmt üblicherweise der Installer in der VM und sollen nur aufzeigen wie diese ZVOLs genutzt werden

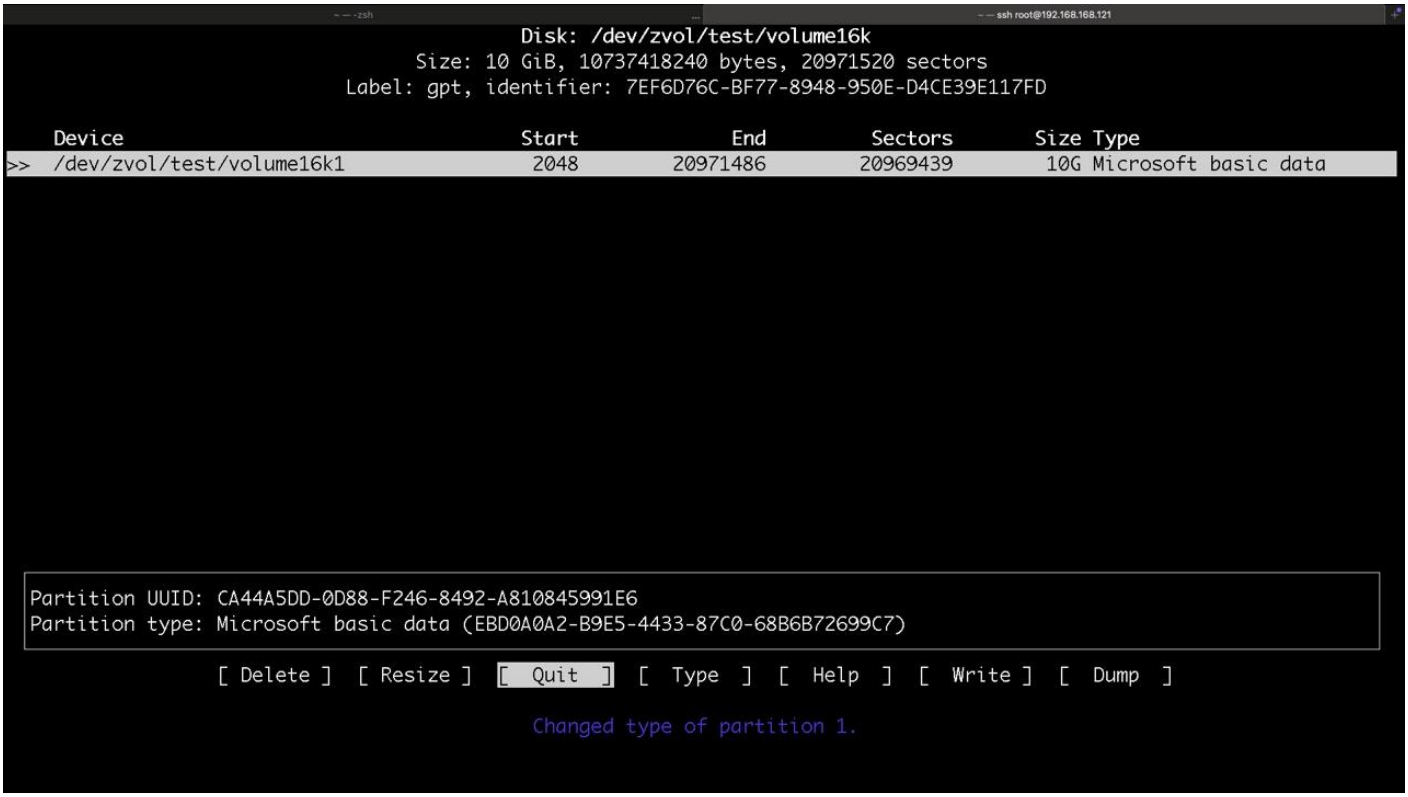

```
test/volume16k    10.3G  16.1T     1.01G  -
root@pvews:~# dd if=/dev/zero of=/dev/zvol/test/volume16k bs=1M count=1024 status=progress
1024+0 records in
1024+0 records out
1073741824 bytes (1.1 GB, 1.0 GiB) copied, 14.9745 s, 71.7 MB/s
root@pvews:~# zfs list
NAME               USED  AVAIL     REFER  MOUNTPOINT
rpool             1.55G   898G      104K  /rpool
rpool/ROOT        1.54G   898G       96K  /rpool/ROOT
rpool/ROOT/pve-1  1.54G   898G     1.28G  /
rpool/data         104K   898G      104K  /rpool/data
test              21.3G  16.1T     25.4K  /test
test/dateisystem    24K  16.1T       24K  /test/dateisystem
test/volume       11.0G  16.1T     1.07G  -
test/volume16k    10.3G  16.1T     1.01G  -
root@pvews:~# cfdisk /dev/zvol/test/volume16k

root@pvews:~# cfdisk /dev/zvol/test/volume16k

Syncing disks.
root@pvews:~# mkfs.
mkfs.bfs     mkfs.cramfs  mkfs.ext3    mkfs.fat     mkfs.msdos   mkfs.xfs
mkfs.btrfs   mkfs.ext2    mkfs.ext4    mkfs.minix   mkfs.vfat
root@pvews:~# mkfs.
mkfs.bfs     mkfs.cramfs  mkfs.ext3    mkfs.fat     mkfs.msdos   mkfs.xfs
mkfs.btrfs   mkfs.ext2    mkfs.ext4    mkfs.minix   mkfs.vfat
root@pvews:~# mkfs.vfat /dev/zvol/test/volume16k
volume16k        volume16k-part1
root@pvews:~# mkfs.vfat /dev/zvol/test/volume16k-part1
```

```
├─sdd1     8:49   0   2.7T  0 part
└─sdd9     8:57   0     8M  0 part
sde        8:64   0   2.7T  0 disk
├─sde1     8:65   0   2.7T  0 part
└─sde9     8:73   0     8M  0 part
sdf        8:80   0   2.7T  0 disk
├─sdf1     8:81   0   2.7T  0 part
└─sdf9     8:89   0     8M  0 part
sdg        8:96   0   2.7T  0 disk
├─sdg1     8:97   0   2.7T  0 part
└─sdg9     8:105  0     8M  0 part
sdh        8:112  0 931.5G  0 disk
├─sdh1     8:113  0  1007K  0 part
├─sdh2     8:114  0     1G  0 part
└─sdh3     8:115  0 930.5G  0 part
sdi        8:128  0 931.5G  0 disk
├─sdi1     8:129  0  1007K  0 part
├─sdi2     8:130  0     1G  0 part
└─sdi3     8:131  0 930.5G  0 part
sdk        8:160  0 447.1G  0 disk
├─sdk1     8:161  0 447.1G  0 part
└─sdk9     8:169  0     8M  0 part
sdl        8:176  0 447.1G  0 disk
├─sdl1     8:177  0 447.1G  0 part
└─sdl9     8:185  0     8M  0 part
zd16     230:16   0    10G  0 disk
└─zd16p1 230:17   0    10G  0 part
root@pvews:~# mkdir /mnt/restore
root@pvews:~# mount /dev/zd16p1 /mnt/restore/
```

```
devpts on /dev/pts type devpts (rw,nosuid,noexec,relatime,gid=5,mode=620,ptmxmode=000)
tmpfs on /run type tmpfs (rw,nosuid,nodev,noexec,relatime,size=9895684k,mode=755,inode64)
rpool/ROOT/pve-1 on / type zfs (rw,relatime,xattr,noacl)
securityfs on /sys/kernel/security type securityfs (rw,nosuid,nodev,noexec,relatime)
tmpfs on /dev/shm type tmpfs (rw,nosuid,nodev,inode64)
tmpfs on /run/lock type tmpfs (rw,nosuid,nodev,noexec,relatime,size=5120k,inode64)
cgroup2 on /sys/fs/cgroup type cgroup2 (rw,nosuid,nodev,noexec,relatime)
pstore on /sys/fs/pstore type pstore (rw,nosuid,nodev,noexec,relatime)
bpf on /sys/fs/bpf type bpf (rw,nosuid,nodev,noexec,relatime,mode=700)
systemd-1 on /proc/sys/fs/binfmt_misc type autofs (rw,relatime,fd=30,pgrp=1,timeout=0,minproto=5,maxproto=5,direct,pipe
_ino=24541)
mqueue on /dev/mqueue type mqueue (rw,nosuid,nodev,noexec,relatime)
hugetlbfs on /dev/hugepages type hugetlbfs (rw,relatime,pagesize=2M)
debugfs on /sys/kernel/debug type debugfs (rw,nosuid,nodev,noexec,relatime)
tracefs on /sys/kernel/tracing type tracefs (rw,nosuid,nodev,noexec,relatime)
fusectl on /sys/fs/fuse/connections type fusectl (rw,nosuid,nodev,noexec,relatime)
configfs on /sys/kernel/config type configfs (rw,nosuid,nodev,noexec,relatime)
sunrpc on /run/rpc_pipefs type rpc_pipefs (rw,relatime)
rpool on /rpool type zfs (rw,relatime,xattr,noacl)
rpool/ROOT on /rpool/ROOT type zfs (rw,relatime,xattr,noacl)
rpool/data on /rpool/data type zfs (rw,relatime,xattr,noacl)
lxcfs on /var/lib/lxcfs type fuse.lxcfs (rw,nosuid,nodev,relatime,user_id=0,group_id=0,allow_other)
/dev/fuse on /etc/pve type fuse (rw,nosuid,nodev,relatime,user_id=0,group_id=0,default_permissions,allow_other)
tmpfs on /run/user/0 type tmpfs (rw,nosuid,nodev,relatime,size=9895680k,nr_inodes=2473920,mode=700,inode64)
test on /test type zfs (rw,xattr,noacl)
test/dateisystem on /test/dateisystem type zfs (rw,xattr,noacl)
/dev/zd16p1 on /mnt/restore type vfat (rw,relatime,fmask=0022,dmask=0022,codepage=437,iocharset=iso8859-1,shortname=mix
ed,errors=remount-ro)
root@pvews:~#
```

Proxmox legt seine Datasets für LXC so ab

```
rpool/ROOT/klon                          744K   916G  33.8G  /rpool/ROOT/klon
rpool/ROOT/pve-1                        89.1G   916G  75.2G  /
rpool/azubi                               96K   916G    96K  /rpool/azubi
rpool/clone                               96K   916G    96K  /rpool/clone
rpool/data                               627G   916G   160K  /rpool/data
rpool/data/subvol-100-disk-0            26.0G  74.3G  25.7G  /rpool/data/subvol-100-disk-0
rpool/data/subvol-106-disk-0            1.36G  15.1G   900M  /rpool/data/subvol-106-disk-0
rpool/data/subvol-121-disk-0            1.76G  30.3G  1.68G  /rpool/data/subvol-121-disk-0
rpool/data/subvol-131-disk-0             958M  31.1G   958M  /rpool/data/subvol-131-disk-0
rpool/data/subvol-131-disk-1            3.19G  96.8G  3.19G  /rpool/data/subvol-131-disk-1
rpool/data/subvol-132-disk-0            1.21G  31.2G   866M  /rpool/data/subvol-132-disk-0
rpool/data/subvol-132-disk-1             220K   100G   220K  /rpool/data/subvol-132-disk-1
rpool/data/subvol-133-disk-0             707M  31.3G   707M  /rpool/data/subvol-133-disk-0
rpool/data/subvol-133-disk-1            18.4M   100G  18.4M  /rpool/data/subvol-133-disk-1
rpool/data/subvol-134-disk-0            1.05G  31.3G   687M  /rpool/data/subvol-134-disk-0
rpool/data/vm-101-disk-0                7.48G   916G  7.48G  -
rpool/data/vm-102-disk-0                  96K   916G    96K  -
rpool/data/vm-102-disk-1                22.5G   916G  22.5G  -
rpool/data/vm-102-disk-2                  64K   916G    64K  -
rpool/data/vm-103-disk-0                8.92G   916G  8.92G  -
rpool/data/vm-103-disk-1                3.06M   916G  3.06M  -
rpool/data/vm-103-disk-2                1.03G   917G   176K  -
rpool/data/vm-103-disk-3                1.65M   916G  1.65M  -
rpool/data/vm-104-disk-0                4.78G   916G  4.65G  -
rpool/data/vm-105-disk-0                 609M   916G   609M  -
rpool/data/vm-105-disk-1                8.49G   916G  8.49G  -
rpool/data/vm-107-disk-0                17.1G   916G  15.0G  -
rpool/data/vm-108-disk-0                5.22G   916G  5.22G  -
rpool/data/vm-113-disk-1                11.7G   916G  11.7G  -
```

und so die ZVOLs für VMs mit KVM, hier findet man die virtuellen Disk und /dev/zvol...

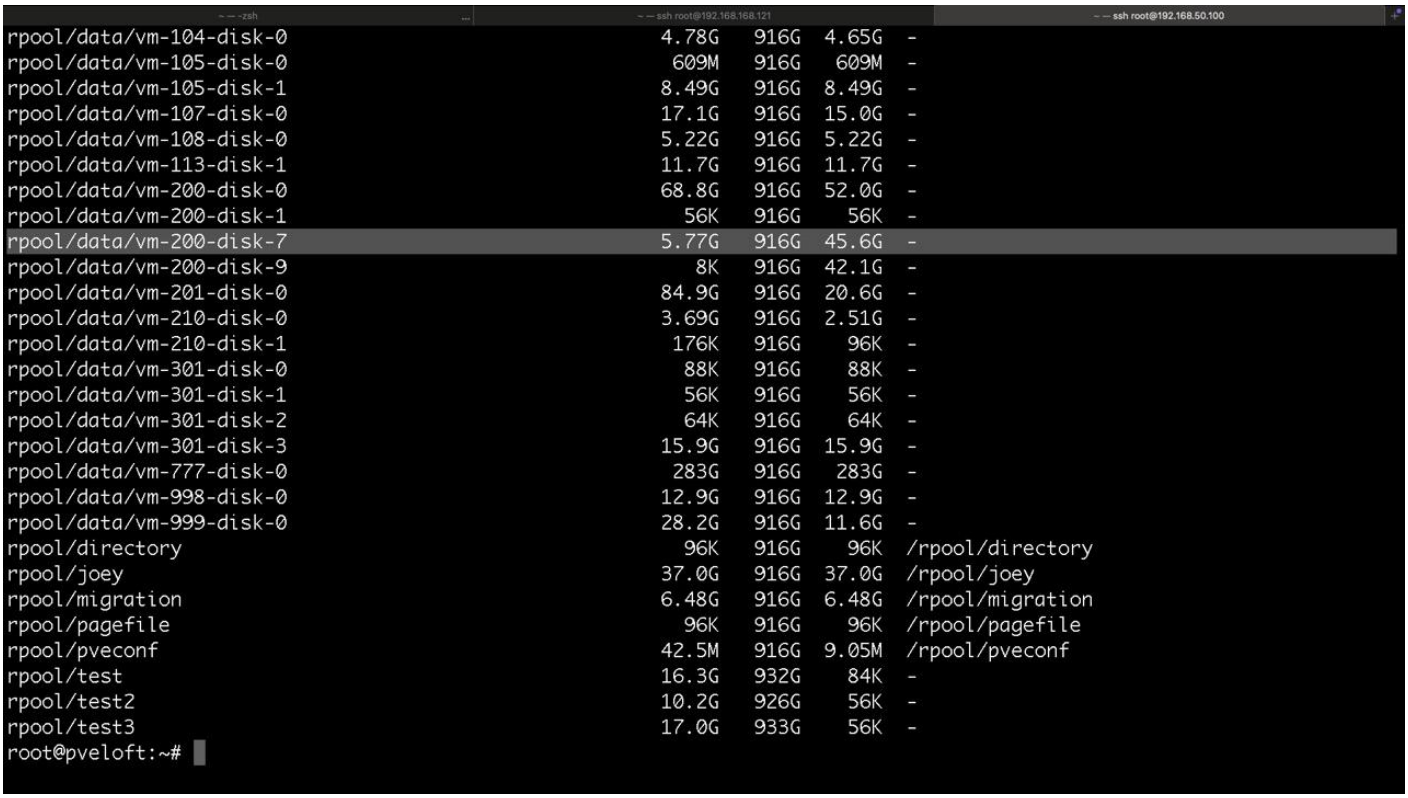

```
rpool/data/vm-104-disk-0                4.78G   916G  4.65G  -
rpool/data/vm-105-disk-0                 609M   916G   609M  -
rpool/data/vm-105-disk-1                8.49G   916G  8.49G  -
rpool/data/vm-107-disk-0                17.1G   916G  15.0G  -
rpool/data/vm-108-disk-0                5.22G   916G  5.22G  -
rpool/data/vm-113-disk-1                11.7G   916G  11.7G  -
rpool/data/vm-200-disk-0                68.8G   916G  52.0G  -
rpool/data/vm-200-disk-1                  56K   916G    56K  -
rpool/data/vm-200-disk-7                5.77G   916G  45.6G  -
rpool/data/vm-200-disk-9                   8K   916G  42.1G  -
rpool/data/vm-201-disk-0                84.9G   916G  20.6G  -
rpool/data/vm-210-disk-0                3.69G   916G  2.51G  -
rpool/data/vm-210-disk-1                 176K   916G    96K  -
rpool/data/vm-301-disk-0                  88K   916G    88K  -
rpool/data/vm-301-disk-1                  56K   916G    56K  -
rpool/data/vm-301-disk-2                  64K   916G    64K  -
rpool/data/vm-301-disk-3                15.9G   916G  15.9G  -
rpool/data/vm-777-disk-0                 283G   916G   283G  -
rpool/data/vm-998-disk-0                12.9G   916G  12.9G  -
rpool/data/vm-999-disk-0                28.2G   916G  11.6G  -
rpool/directory                           96K   916G    96K  /rpool/directory
rpool/joey                              37.0G   916G  37.0G  /rpool/joey
rpool/migration                         6.48G   916G  6.48G  /rpool/migration
rpool/pagefile                            96K   916G    96K  /rpool/pagefile
rpool/pveconf                           42.5M   916G  9.05M  /rpool/pveconf
rpool/test                              16.3G   932G    84K  -
rpool/test2                             10.2G   926G    56K  -
rpool/test3                             17.0G   933G    56K  -
root@pveloft:~#
```

Thin- und Thickprovisioning für Datasets und Volumes

> Am Beispiel von Proxmox VE via GUI wird hier eine Thinprovision Festplatte für VM 301 mit 32GB und einer Standardblockgröße von 16k erzeugt. 8k sind nur bei Raid1 und 10 möglich. Hakt man den Thinprovision Haken nicht an, wird beim Erzeugen noch die Option -o refreservation=32G ergänzt. Diese macht bei ZFS mit Autosnapshots aber keinen Sinn

```
zfs create -s -b 16k -V 33554432k rpool/data/vm-301-disk-4
```

```
rpool/data/vm-301-disk-4                 56K  1.17T    56K  - #hier kein Mount sonder unter /dev/zvol/...
```

> Bei LXC werden Datasets genutzt und der Platz via Reservierung genutzt, wobei bei der genutzten Refquota auch die Snapshotaufhebezeiten den Nettoplatz verkleinern, daher größer dimensionieren, gerne mal doppelt so groß

```
 zfs create -o acltype=posixacl -o xattr=sa -o refquota=33554432k rpool/data/subvol-106-disk-1
```

```

```

rpool/data/subvol-106-disk-1 96K 32.0G 96K **/rpool/data/subvol-106-disk-1 #hostzugriff möglich**

> Virtuelle Diskimages wie QCOW2, VMDK oder RAW-Dateien legt man üblicherweise nicht in Datasets, bestenfalls für NFS oder iSCSI Server

Snapshots

> Snapshots können jederzeit erstellt oder gelöscht werden. Die Datasets und Volumes befinden sich immer in einem Livezustand der sich durch die Vektorkette der eventuell vorhandenen Snapshots ergibt. Entfernt man einen Snapshot, so verändert sich der Weg der Vektoren. Das Ganze geschieht fast ohne Last!
>
> ZFS selbst bringt weder Workflows für Snapshotting, noch Replikationen mit. Es stellt nur die Werkzeuge bereit
>
> Snapshots generiert man bei Proxmox offiziell mit der GUI manuell oder für Replikationen, jedoch leistet dieser Workflow nicht genug.
>
> Daher nutzen wir...

apt install zfs-auto-snapshot -y

> ZFS-AUTO-SNAPSHOT legt seine Verknüpfungen in alle Cronordner. Proxmox VE weiß erst mal nichts davon. Zu berücksichtigen ist hier lediglich daß wir den Pool nicht über 80% befüllen wollen. Gehen wir darüber hinaus, müssen wir in den Cronordnern die Verknüpfungen anpassen um die Aufhebezeiten zu reduzieren.

nano /etc/crontab #kann angepasst werden, die viertelstündlichen finden sich unter cron.d!

```
# .---------------- minute (0 - 59)
# |  .------------- hour (0 - 23)
# |  |  .---------- day of month (1 - 31)
# |  |  |  .------- month (1 - 12) OR jan,feb,mar,apr ...
# |  |  |  |  .---- day of week (0 - 6) (Sunday=0 or 7) OR sun,mon,tue,wed,thu,fri,sat
# |  |  |  |  |
# *  *  *  *  * user-name command to be executed
```

17 * * * * root cd / && run-parts --report /etc/**cron.hourly**
25 6 * * * root test -x /usr/sbin/anacron || { cd / && run-parts --report /etc/**cron.daily**; }
47 6 * * 7 root test -x /usr/sbin/anacron || { cd / && run-parts --report /etc/**cron.weekly**; }
52 6 1 * * root test -x /usr/sbin/anacron || { cd / && run-parts --report /etc/**cron.monthly**; }

> cat /etc/cron.hourly/zfs-auto-snapshot

> exec zfs-auto-snapshot --quiet --syslog --label=hourly **--keep=96** // #also in dem Fall 96 Stunden

> Wir empfehlen für den Start folgende Settings: Drei Monate, sechs Wochen, zehn Tage, 96h und 12 Viertelstunden
>
> Damit kommt man auf ca. 2,5x- 3x so viele Daten wie belegt wären ohne Snapshots. Erfahrungswert.
>
> Das wären pro virtueller Disk oder LXC Mountpoint etwa 127 Snaphots, bei 20 Disks über 2540.
>
> Nicht davon abschrecken lassen, es geht auch easy fünfstellig, wenn die IO stimmt!
>
> Die in PVE eingebaute Snapshotfunktion sollte nicht mit den Autosnapshots kombiniert werden.
>
> Im Problemfall stoppen wir die VM, manipulieren was zu machen ist und starten sie wieder!
>
> Der eigentliche Vorteil der Snapshots in der GUI ist die Notierung der VM Definition zur Zeit der Erstellung, was wir über ein Backup im hauseigenen Postinstaller kompensieren. Dort findet man die Historie der PVE Config

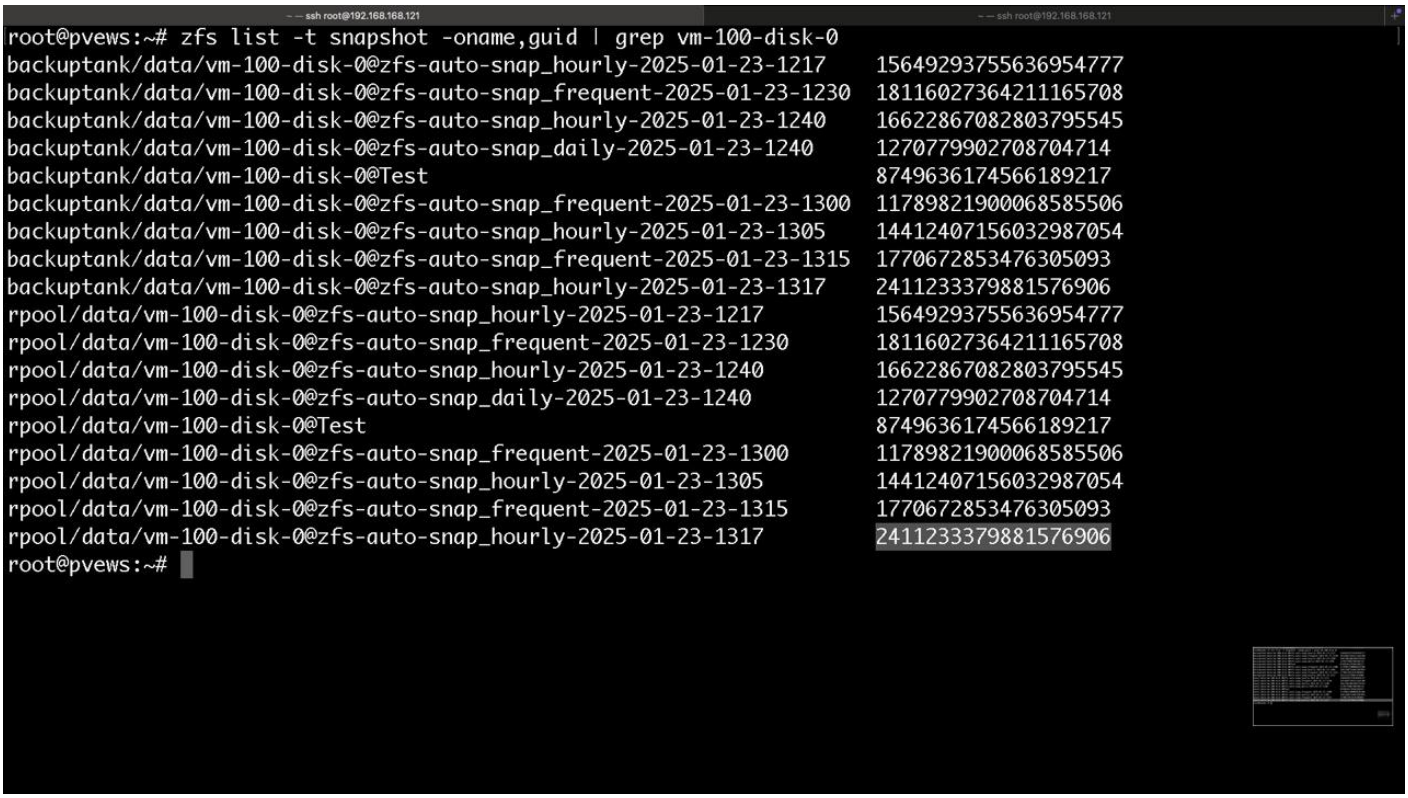

Kleines manuelles Beispiel, was für uns aber Z-A-S übernimmt

Snapshot

```
zfs snapshot tank/sub/datasetodervolume@snapshotname
```

Auflisten

```
zfs list -t snapshot tank/sub/datasetodervolume
```

VM oder LXC ausmachen

Rollback

```
zfs rollback -r rpool/data/vm-100-disk-0@Test #danach ist alles neuere weg!
```

VM oder LXC starten

Dynamik von Snapshots

Wir unterscheiden zwei Sorten von Datennutzung

- Zunehmende Datennutzung wie bei einem NAS
  - Es kommt nur was dazu und wird selten gelöscht
  - Viele Snapshots auf lange Zeit ändern nichts an der Gesamtnutzung des Pools
  - Replikation außer Haus kann in kleinen Schritten passieren, da die Gesamtübertragung gleich groß ist
- Rotierende Datennutzung wie bei einem Datenbankserver
  - Daten verändern sich permanent, wenig Zuwachs
  - Viele Snapshots auf lange Zeit ändern **brachial viel** an der Gesamtnutzung des Pools
  - Replikation außer Haus sollte in einem Schritt, ohne Zwischensnapshots passieren, da die Gesamtübertragung sonst ein vielfaches größer sein kann
  - Nur essenzielle Wiederherstellungspunkte sollten aufgehoben werden um das System nicht unnötig zu befüllen

Dynamik von Snapshots

> Dank ZFS kann man langfristig Replikationen inkrementell vornehmen, jedoch dauert die erste Replikation natürlich länger, wenn schon Datenbestand da war

Übliche Vorgehensweise einer Datenübertragung

PC NTFS>SMB> Datei > SAMBA Server BTRFS LVM > EXT4 Datei = Konsistent? Bitrod?

> Zu viele Köche verderben die Köchin

Funktion von Snapshotreplikation

Von ZFS zu Datei, was wenig Praxis findet

> zfs send tank/dataset@snapshot > datei.zfs

> zfs recv tank < datei.zfs

Von ZFS zu ZFS, was üblich ist

> zfs send | zfs recv #laufen immer gleichzeitig

>

zfs send rpool/data/vm-100-disk-0@Test | zfs recv -dvF backuptank
#überträgt den Zustand Test auf ein lokalen weiteren Pool, wobei das zfs Tool immer doppelt läuft

Pushreplikation

zfs send -pvwRI rpool/data/vm-100-disk-0@Test rpool/data/vm-100-disk-0@zfs-auto-snap_hourly-2025-01-23-1317 | zfs recv -dvF backuptank
#Fortschritt, Infos, Rohdaten plus Historie, ideal für verschlüsselte Volumes, erspart das De- und Komprimieren

Workflow

- Erzeugen eines Datasets oder Volumes
- Snapshot auf Dataset oder Volume ausführen
- Übertragung des Snapshotzustands auf Ziel, optional mit Zwischenständen

Trojanerproblem: Wer auf Quelle sitzt kann Pushziele löschen

Lösung: Pullreplikation, ähnlich Backupsoftware, Transport SSH, Daten ZFS
Quelle |> Pullserver

zfs **recv** | ssh root@quelle zfs **send** #Pull Replikation via SSH

Von PVE zu PVE, was uns zu wenig ist

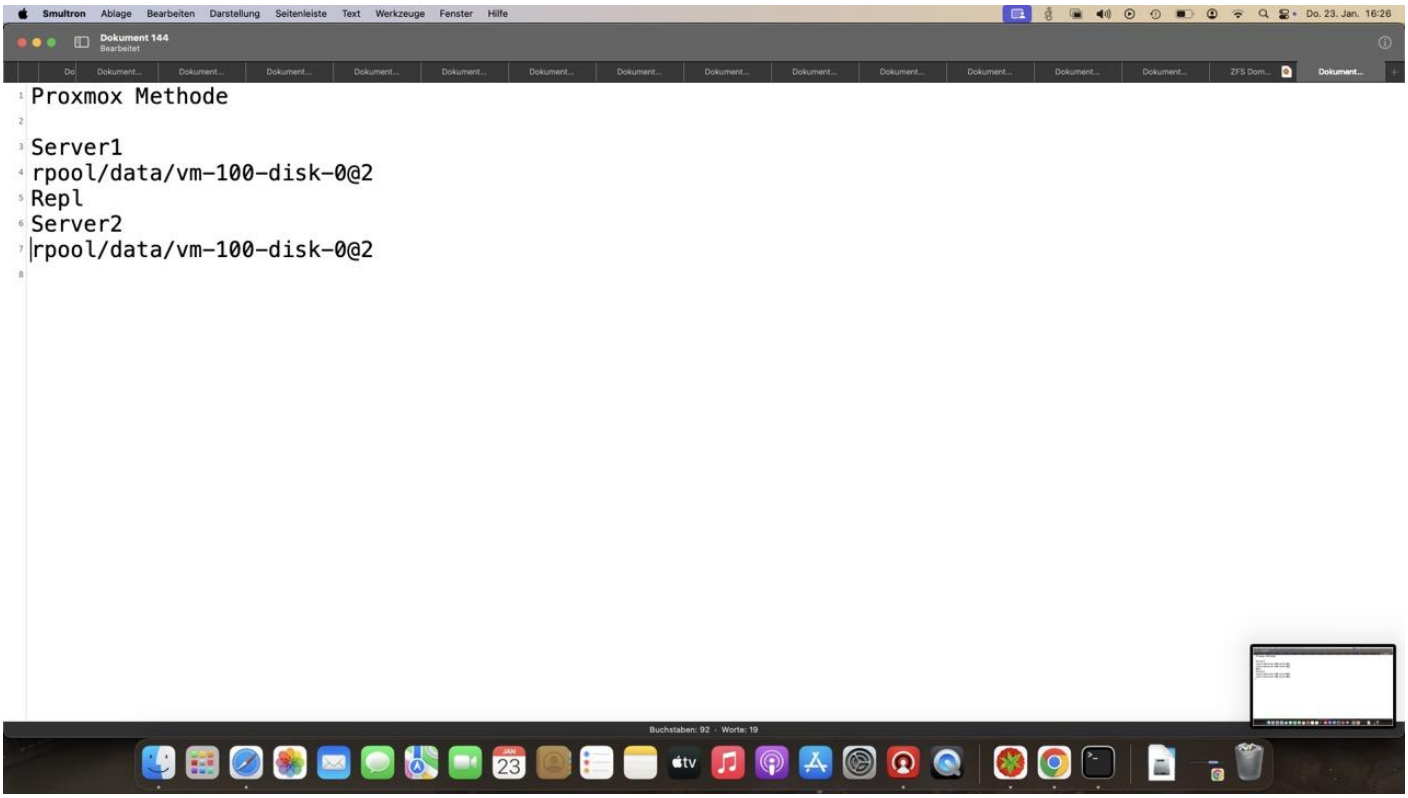
Smultron Ablage Bearbeiten Darstellung Seitenleiste Text Werkzeuge Fenster Hilfe
Do. 23. Jan. 16:26
Dokument 144
Bearbeitet
Proxmox Methode
Server1
rpool/data/vm-100-disk-0@2
Repl
Server2
rpool/data/vm-100-disk-0@2
Buchstaben: 92 · Worte: 19

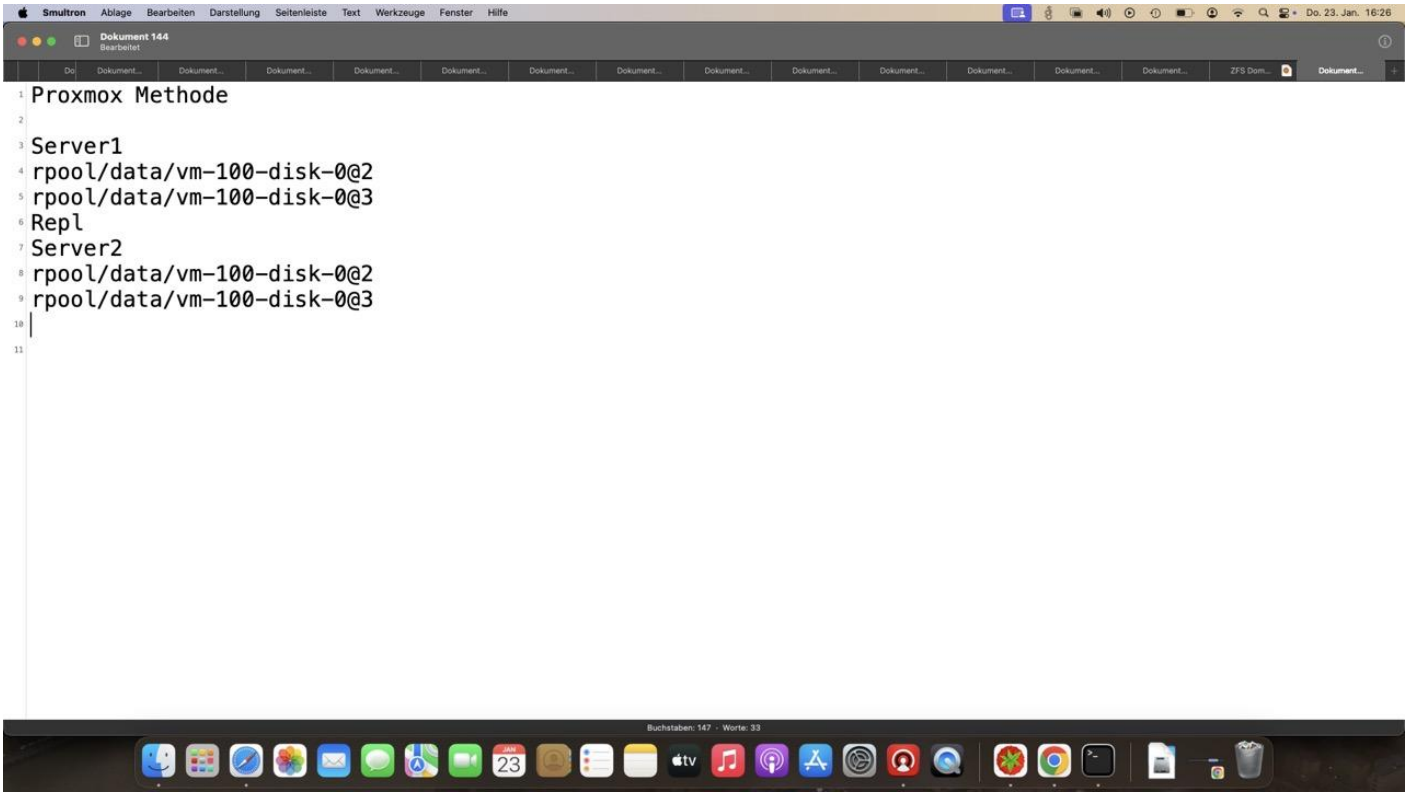
Smultron Ablage Bearbeiten Darstellung Seitenleiste Text Werkzeuge Fenster Hilfe
Do. 23. Jan. 16:26
Dokument 144
Bearbeitet
Proxmox Methode
Server1
rpool/data/vm-100-disk-0@2
rpool/data/vm-100-disk-0@3
Repl
Server2
rpool/data/vm-100-disk-0@2
rpool/data/vm-100-disk-0@3
Buchstaben: 147 · Worte: 33

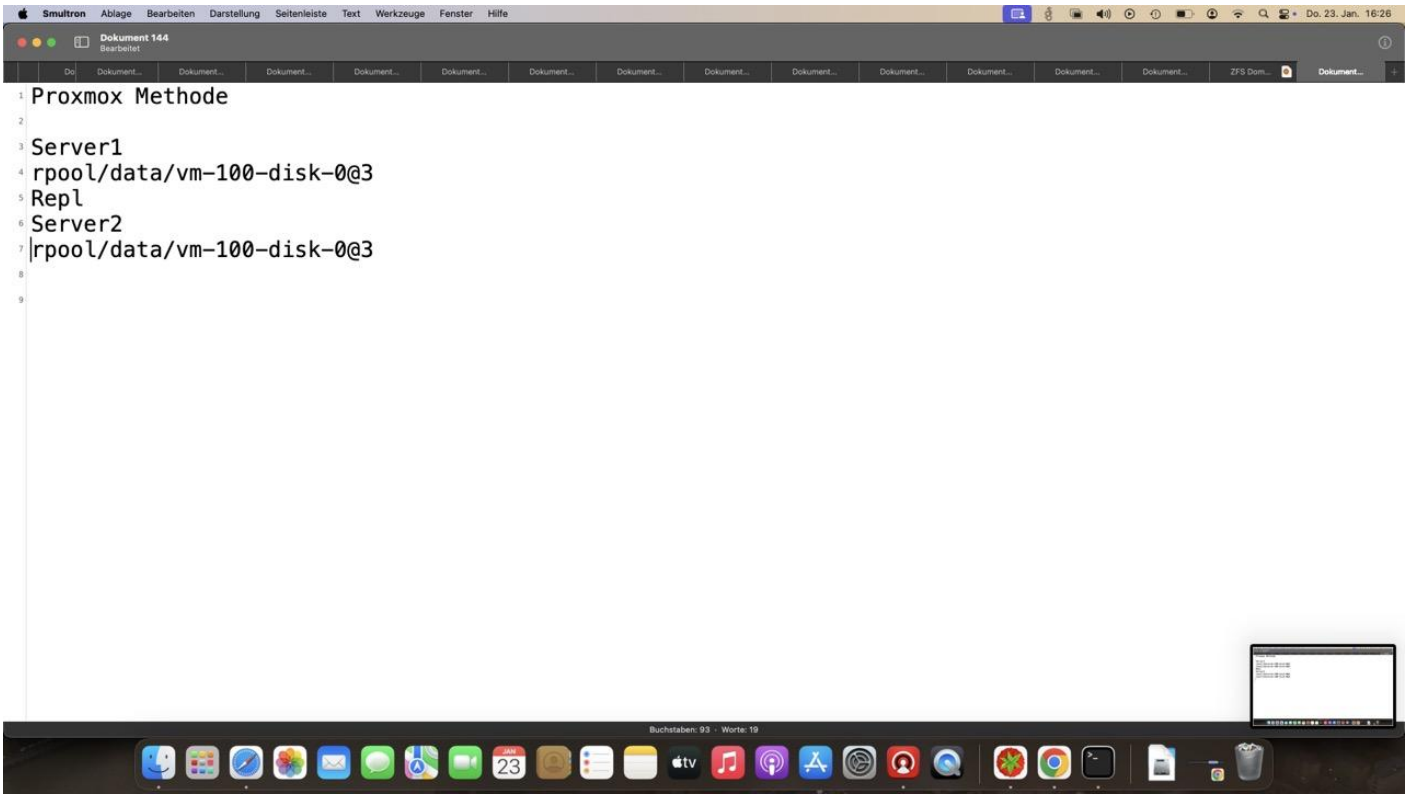

> Proxmox baut selbst keine Notfallpunkte auf und nutzt ZFS nur als Transport, nimmt jedoch manuelle und automatisierte Snapshots mit, auch von Z-A-S!

> Weitere Kopien per ZFS sind nur per Pushverfahren möglich, was ideal für Angreifer ist wenn sie alles löschen möchten. Ein Backupserver ist hier unverzichtbar, bei Pullreplikation gehts ggf. auch ohne. Außer Haus ist es nicht möglich ein ZFS Replikat zu senden, da sich der Partner im lokalen Cluster befinden muss!

Nondestruktiver Rollback nach Trojanerbefallt bei Forensikbedarf

Version #3
Erstellt: 31 Januar 2025 12:18:16 von Christian Zengel (sysops GmbH)
Zuletzt aktualisiert: 31 Januar 2025 15:20:12 von Christian Zengel (sysops GmbH)