

Warum sollten wir Btrfs verwenden?

CLT 2012

- Linux/Ubuntu im sicheren und virtuellen Netz
- Warum GNU/Linux/Ubuntu?

CLT 2016

- rsync, SSH, LUKS im Team
- Backup mit Linux Bordmitteln
-
-
-


CLT heute

- der Unterbau von allem
- Btrfs

Btrfs funktioniert nicht wie die gewohnten Dateisysteme.
Um BTRFS gut zu nutzen, muss man wissen, was man tut.
Die Dokumentation zu lesen ist der beste Weg das zu erreichen:

<https://btrfs.readthedocs.io/en/latest/>

Physiker in Halle
Fernstudium Theologie
seit 1988 in München
Physiker am Max-Planck-Institut
IT Berater und Entwickler
Linuxtage in
Augsburg, Graz, Dornbirn,
Wien, Kiel, Chemnitz, ...



- Btrfs ist Unterbau für Desktops und Server
- Links im Filesystem
- Copy-on-Write
- Subvolumes und Snapshots
- RAID und LUKS
- Tipps für neue Partitionen

einige Links

<https://wiki.archlinux.org/title/Btrfs>

<https://help.ubuntu.com/community/btrfs>

https://www.usenix.org/system/files/login/articles/bacik_0.pdf

- „The Swiss Army Knife of Storage“

Demos:

- Ext4 nach Btrfs umwandeln
- Datenintegrität online testen
- Softlink, Hardlink, Replink
- Arbeiten mit Snapshots
- RAID mit LUKS



Wie beginnen?

- *apt install btrfs-progs*
- formatieren und genau wie ein Ext4 verwenden
- Btrfs kann aber viel mehr

Eigenschaften

- Filesystem ist immer konsistent
- Checksummen pro File, Erkennen von Bitfehlern
- Copy-on-Write
- Subvolumes mit Snapshots
 - neue Arbeitsweise mit Mountpoints über Subvolumes
- Backup von Datenstrukturen, die gerade verwendet werden
- optimiert für SSD
- optimiert für SMR Disks
- RAID über Prüfsummen

Nachteile?

- RAID 5/6 nicht stabil



Online Neuformatierung eines Ext4 Filesystems mit Btrfs

convert from ext3/4 → Btrfs

btrfs-convert /dev/sdc1

oder

btrfs-convert /dev/disk/by-partlabel/mydisk

mount the resulting Btrfs filesystem

mount -t btrfs /dev/disk/by-partlabel/mydisk /mnt/mydisk

mount the ext3/4 snapshot

mount -t btrfs -o subvol=ext2_saved /dev/disk/by-partlabel/e1loop /mnt/ext4_saved

loopback mount the image file

mount -t ext4 -o loop,ro /mnt/ext4_saved/image /mnt/ext4

diff -r ext4/ mydisk/

<https://btrfs.readthedocs.io/en/latest/Convert.html>

Warnung:

- Umwandlung ist instabil bei Stromausfall

stabiler:

- Backup, Format mit Btrfs, Restore



Scrub – Kontrolle aller Prüfsummen

Scrub

- ca. alle 100 TB ein Bitfehler
- `btrfs scrub start /mnt/mydisk`
- `btrfs scrub status /mnt/mydisk`

Ergebnis wird gespeichert

- in `/var/lib/btrfs/scrub.status.UUID`
`cat /var/lib/btrfs/scrub.status.d5de08ef-45a5-4e5b-af6d-72b70528158b`

lange Laufzeit, wöchentlich empfohlen

Script

http://marc.merlins.org/perso/btrfs/post_2014-03-19_Btrfs-Tips_-Btrfs-Scrub-and-Btrfs-Filesystem-Repair.html



Softlink = Link zu einem File oder zu einem Verzeichnis

- `files -> /mnt/b1/btrfsstestfiles/files`
- über Partitionen hinweg
- kann auf nichts zeigen, dead link

Hardlink = nur für Files, weiterer Inode, der auf die gleichen Daten zeigt

```
ln hardlinkedfile.txt hardlinkedfile.txt1
```

- Referenzzähler zur Verwaltung
- mit `ls` anzeigbar

```
ls -ali,    8732422 -rw-r----- 2 root root 48 Sep 20 20:36 hardlinkedfile.txt
                        ^ hardlinkcount
```

- nur im gleichen Filesystem
- Ändern der Daten ändert alle Files im Hardlink

Reflink = Copy-on-Write = CoW

```
cp --reflink=always reflinkmaster.txt reflinkcopy.txt
```

- wird intern verwaltet, mit `ls` unsichtbar
- aus Sicht des Benutzers sind das 2 verschiedene Files
- „shallow copy“
- erst bei Änderung der Daten werden diese kopiert
- atomarer Vorgang
- nur im gleichen Filesystem



CoW = Copy-on-Write

Vorteile

- schnell, platzsparend, **transaktionssicher**
cp --reflink=always quelle ziel

Nachteile

- belegt Platz, wenn Daten geändert werden
- nicht mit herkömmlichen Tools darstellbar
filefrag -v kann verwendet werden
- man sollte wissen, was man auf der eigenen HD alles anlegt

Abschalten von Copy-on-Write

chattr +C new_empty_folder
chattr +C file

Snapshot

- schnelle „Kopie“
- Zusammenfassung von vielen CoW-Kommandos im Hintergrund
- transaktionssicher
- Basis ist Subvolume
- Snapshot ist wieder Subvolume

btrfs subvolume snapshot subvol/btrfstestfiles/ abc



CoW, Beispiel

1 File, 850.000.000 Zeichen, 800M, reflinkmaster.txt

kopiere File mit *cp*:

```
cp --reflink=always reflinkmaster.txt reflinkcopy.txt
```

ändere letztes Zeichen nach ‚0‘ mit *sed*

master

```
...  
thoquoo4ibiewai0Phiy  
iguu3Ieghe4gahcoog2e  
TaiTh7irah0geidibeev
```

```
-> sed -i '$ s/.$/0/' reflinkcopy.txt ->  
tail -f reflinkcopy.txt
```

copy

```
...  
thoquoo4ibiewai0Phiy  
iguu3Ieghe4gahcoog2e  
TaiTh7irah0geidibee0
```

filefrag -v (nach *cp*)

```
File size of reflinkmaster.txt is 850926120 (207746 blocks of 4096 bytes)  
ext:      logical_offset:      physical_offset: length:  expected: flags:  
0:         0.. 207745:  272645376.. 272853121: 207746:                last,eof  
reflinkmaster.txt: 1 extent found  
  
File size of reflinkcopy.txt is 850926120 (207746 blocks of 4096 bytes)  
ext:      logical_offset:      physical_offset: length:  expected: flags:  
0:         0.. 207745:  272645376.. 272853121: 207746:                last,shared,eof  
reflinkcopy.txt: 1 extent found
```

filefrag -v (nach *sed*)

```
File size of reflinkcopy.txt is 850926120 (207746 blocks of 4096 bytes)  
ext:      logical_offset:      physical_offset: length:  expected: flags:  
0:         0.. 163839:  174368941.. 174532780: 163840:  
1: 163840.. 207745:  174595328.. 174639233: 43906: 174532781: last,eof  
reflinkcopy.txt: 2 extents found
```



Doku

- „A subvolume looks like a normal directory, with some additional operations described below.“
<https://btrfs.readthedocs.io/en/latest/Subvolumes.html>

Subvolumes?

- funktionieren nicht wie normale Volumemanager
- „dynamische Partitionen“
- „Filesystem im Filesystem“
- keine Namensregeln, muss selbst gestaltet werden

mountable

- statt nur ROOT des Filesystems in Partition
- Mount ist nicht mehr fixe Zuordnung von Partitionen, sondern Zuordnung von Arbeitsbereichen
- Daten sind in tiefen Strukturen mit Subvolumes
- Mountpoints flach

rekursiv

- Mountpoints bilden Zugriffsgrenze
- wie eine Schicht von zusätzlichen Rechten

Subvolumes sind mit Btrfs-Tools sichtbar

btrfs subvolume list folder



Partitionen vs. Subvolumes

HD mit Partitionen




mount nach

/home/user/Arbeit

/home/user/Videos

HD mit Subvolumes



/mnt/disk/



Snapshot (=Subvolume)

Snapshot

- schnelle „Kopie“ eines Subvolume mit Reflinks
btrfs subvolume snapshot subvol/btrfstestfiles/ abc

nicht rekursiv

- Subvolumes downstream sind nicht enthalten
 - für selektive Backups nutzbar

Snapshots sind keine Backups

- nur durch Reflinks mit dem Subvolume verbundene Files
- wegen CoW wird Plattenplatz benötigt, wenn man einen Snapshot ändert
- Btrfs-Filesysteme nicht voll schreiben (ca. 70%)

Backups

- RO-Snapshots
- Backup von Subvolumes mit offenen Files möglich
- kein Zeitfenster für Backups nötig

Löschen

rm -r abc (langsam)
btrfs subvolume delete abc (sehr schnell)



Arbeiten mit Subvolumes und Snapshots

Arbeitsfolder: **workingfolder**

- „workingfolder“ bleibt gleich, *mount* zum *subvolume* mit den Daten wird angepasst

1. mount

```
mount -t btrfs -o subvol=daten/subvolume /dev/disk/by-partlabel/pl workingfolder/
```

2. jeden Tag einen Snapshot

```
btrfs subvolume snapshot subvolume/ snaps/montag
```

```
btrfs subvolume snapshot subvolume/ snaps/dienstag
```

```
btrfs subvolume snapshot subvolume/ snaps/mittwoch
```

3. Wechsel auf Mittwoch, weil die aktuellen Arbeitsdaten kaputt sind ...

```
umount workingfolder
```

```
mount -t btrfs -o subvol=snaps/mittwoch /dev/disk/by-partlabel/pl workingfolder/
```

4. Mittwoch zum Original machen, weil am Mittwoch noch alles ok war.

```
umount workingfolder
```

```
btrfs subvolume delete subvolume/
```

```
btrfs subvolume snapshot snaps/mittwoch subvolume
```



Wir bauen ein RAID, mit LUKS

RAID in Btrfs ist anders

- Redundanz über Prüfsummen an den Files
- nicht über das Blockdevice darunter
- einfach erweiterbar

```
dd if=/dev/zero of=crdisk0.img bs=1 count=0 seek=200G
dd if=/dev/zero of=crdisk1.img bs=1 count=0 seek=200G
```

```
parted crdisk0.img mklabel gpt
parted crdisk1.img mklabel gpt
parted -a optimal -- crdisk0.img mkpart "crdisk0" 0% 100%
parted -a optimal -- crdisk1.img mkpart "crdisk1" 0% 100%
losetup /dev/loop600 -P crdisk0.img
losetup /dev/loop601 -P crdisk1.img
```

```
cryptsetup -q luksFormat /dev/disk/by-partlabel/crdisk0 keyfile
cryptsetup -q luksFormat /dev/disk/by-partlabel/crdisk1 keyfile
cryptsetup luksOpen /dev/disk/by-partlabel/crdisk0 --key-file keyfile crdisk0
cryptsetup luksOpen /dev/disk/by-partlabel/crdisk1 --key-file keyfile crdisk1
```

```
mkfs.btrfs -L crloop -m raid1 -d raid1 /dev/mapper/crdisk0 /dev/mapper/crdisk1
mount -L crloop rr
btrfs filesystem show rr
```



Vorgehensweise bei neuer Festplatte

neue HD

- mit viel Platz
- nur eine Partition mit Btrfs anlegen

Präfix (Namespace) für Subvolumes festlegen

sv .. = Subvolumes

sn .. = Snapshots

@.. = Subvolumes

mounten, nach Bedarf

/mnt/work

/mnt/cpp

- Basissubvolume der Partition selbst wird nicht gemounted
 - nur nötig, wenn man Strukturen ändert

mit Daten füllen, *rsync*, *mv*, *cp -reflink=always*

- keine Daten ohne Subvolume verwenden

Scripte anlegen für

- Snapshots
- Backup
- Organisation



(K)eine gute Idee?

Subvolumes

- oberstes Subvolume mounten
- alle Subvolumes feststellen
- am Ziel neu anlegen
- mit *rsync* jedes Subvolume kopieren (?)
- oder mit *send* von Btrfs
- downstream Subvolumes berücksichtigen

Snapshots

- wie Subvolumes kopieren
- Reflinks zu Quellsubvolumes gehen verloren
- benötigter Plattenplatz am Ziel u.U. größer



Demos:

- Ext4 nach Btrfs umwandeln
- Datenintegrität mit Scrub testen
- Softlink, Hardlink, Reblink
- `cp` oder `cp --reflink` oder Snapshot
- Arbeiten mit Snapshots
- RAID und LUKS



Take Home Message

- ein sicheres Filesystem mit Linux Bordmitteln ist machbar
- mit Btrfs gibt es eine zuverlässige Lösung

Vielen Dank für Eure Aufmerksamkeit.

Richard Albrecht

LUG-Ottobrunn

LUG-Görlitz

LUG-Zittau

<https://www.görlinux.de>

