

So funktioniert der Linux Storage Stack

Werner Fischer (Thomas-Krenn.AG)
Chemnitzer Linux-Tage 2025 – 22. und 23. März



Ein paar Fragen zum Einstieg ...

Ein paar Fragen zum Einstieg ...

1. Hast du schon mal **tune2fs -l** ausgeführt?

Ein paar Fragen zum Einstieg ...

1. Hast du schon mal **tune2fs -l** ausgeführt?
2. Hast du **md-raid** konfiguriert?

Ein paar Fragen zum Einstieg ...

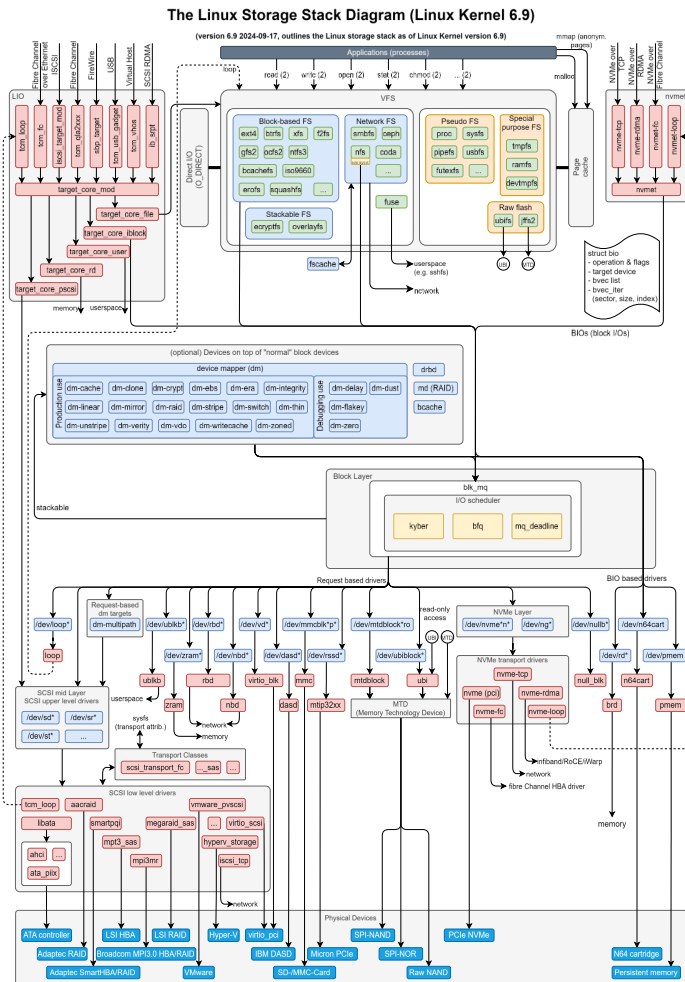
1. Hast du schon mal **tune2fs -l** ausgeführt?
2. Hast du **md-raid** konfiguriert?
3. Hast du **I/O-Scheduler** eingestellt?

Ein paar Fragen zum Einstieg ...


1. Hast du schon mal **tune2fs -l** ausgeführt?
2. Hast du **md-raid** konfiguriert?
3. Hast du **I/O-Scheduler** eingestellt?
4. Hast du schon einmal **nvme-cli** benutzt?

Agenda


- Wozu (secondary) Storage?
- Die Sicht des Nutzers
- VFS (Virtual FileSystem)
- Beispiel ext3/ext4
- Beispiel btrfs
- Block Layer: remapper
- Block Layer: Virtual Data Optimizer
- Block Layer: blk-mq & I/O scheduler
- Gerätetreiber
- The “big picture”




Wozu (secondary) Storage?



Pic: © Werner Fischer / CC-BY-SA-4.0



Pic: © OÖ Landesbibliothek / CC-BY-SA-3.0



Pic: © Burkhard Mücke / CC-BY-SA-4.0



Die Sicht des Nutzers

Daten speichern
(write)



Daten lesen
(read)

Was ist ein Block Device?


Reihe von
Blöcken

Jeder Block hat die
gleiche Größe

Befehle zum Lesen
und Schreiben

Synchroner versus asynchronem I/O

- Synchroner Kernel I/O
 - Thread startet I/O-Operation
 - Geht in den Wartezustand über, bis die E/A-Anforderung abgeschlossen ist
 - Beispiele: `read(2)`, `write(2)`, ...
- Asynchroner Kernel I/O
 - Thread sendet I/O-Anfrage an den Kernel
 - Fortlaufende Bearbeitung eines anderen Auftrags, bis der Kernel signalisiert, dass die E/A-Anforderung abgeschlossen ist
 - Beispiele: `aio_read`, `aio_write`, `aio`, `io_uring`
- Asynchronous User-space I/O
 - Storage Performance Development Kit (SPDK)
 - Tools und Bibliotheken zum Schreiben von Hochleistungsspeicheranwendungen im Benutzermodus
 - Die Grundlage von SPDK ist ein asynchroner, „lockless“, „polled-mode“ NVMe-Treiber.
- Weitere Details: Improved Storage Performance Using the New Linux Kernel I/O Interface (John Kariuki & Vishal Verma, SDC 2019)





VFS (Virtual FileSystem)

VFS

- Eingeführt mit System V ~Mitte der 80er Jahre
- Bietet eine generische Schnittstelle für Anwendungen
- Operationen wie
 - read(2)
 - write(2)
 - open(2)
 - statx(2)
 - chmod(2), ...

funktionieren immer auf die gleiche Weise, egal welches Dateisystem verwendet wird.






VFS Datenstrukturen / Objekte

- Inodes
- Directory entries
- File objects
- Superblocks

Inodes

- Index node
- Enthält Metadaten, welche die eigentlichen Daten _beschreiben_
- Enthält keine “echten” Daten

```
i_mode      = ...  
i_uid       = ...  
i_gid       = ...  
i_flags     = ...  
i_mapping   = ...  
i_nlink     = ...  
i_atime     = ...  
i_mtime     = ...  
i_ctime     = ...  
i_bytes     = ...  
i_blocks    = ...  
...
```



```
i_mode      = ...      <----- owner/group/others, eg 0777=rwxrwxrwx
i_uid       = ...      <----- user
i_gid       = ...      <---- group
i_flags     = ...      <-  flags
i_mapping   = ...      <----- mapping
i_nlink     = ...      <----- number of hard links to this file
i_atime     = ...      <----- last time file was open()-ed
i_mtime     = ...      <----- last time file was modified write()-d
i_ctime     = ...      <----- last time inode was changed (not creation!)
i_bytes     = ...      <----- file size, beginning to end
i_blocks    = ...      <----- number of used blocks
...
```

```
werner@x390:~/test$ echo "example line 1" > examplefile.txt
werner@x390:~/test$ stat examplefile.txt
  File: examplefile.txt
  Size: 15                Blocks: 8                IO Block: 4096   regular file
Device: 254,1    Inode: 97422132    Links: 1
Access: (0644/-rw-r--r--)  Uid: ( 1000/   werner)   Gid: ( 1000/   werner)
Access: 2024-09-10 16:46:31.220485190 +0200
Modify: 2024-09-10 16:46:31.220485190 +0200
Change: 2024-09-10 16:46:31.220485190 +0200
 Birth: 2024-09-10 16:46:31.220485190 +0200
```

```
werner@x390:~/test$ date && cat examplefile.txt
```

```
Di 10 Sep 2024 16:47:10 CEST
```

```
example line 1
```

```
werner@x390:~/test$ stat examplefile.txt
```

```
File: examplefile.txt
```

```
Size: 15          Blocks: 8          IO Block: 4096    regular file
```

```
Device: 254,1    Inode: 97422132    Links: 1
```

```
Access: (0644/-rw-r--r--)  Uid: ( 1000/   werner)   Gid: ( 1000/   werner)
```

```
Access: 2024-09-10 16:47:10.212575439 +0200
```

```
Modify: 2024-09-10 16:46:31.220485190 +0200
```

```
Change: 2024-09-10 16:46:31.220485190 +0200
```

```
Birth: 2024-09-10 16:46:31.220485190 +0200
```



```
werner@x390:~/test$ date && echo "example line 2" >> examplefile.txt
Di 10 Sep 2024 16:48:08 CEST
werner@x390:~/test$ stat examplefile.txt
  File: examplefile.txt
  Size: 30                Blocks: 8                IO Block: 4096   regular file
Device: 254,1    Inode: 97422132    Links: 1
Access: (0644/-rw-r--r--)  Uid: ( 1000/   werner)   Gid: ( 1000/   werner)
Access: 2024-09-10 16:47:10.212575439 +0200
Modify: 2024-09-10 16:48:08.600709043 +0200
Change: 2024-09-10 16:48:08.600709043 +0200
 Birth: 2024-09-10 16:46:31.220485190 +0200
```

```
werner@x390:~/test$ date && chmod g+w examplefile.txt
```

```
Di 10 Sep 2024 16:49:11 CEST
```

```
werner@x390:~/test$ stat examplefile.txt
```

```
File: examplefile.txt
```

```
Size: 30          Blocks: 8          IO Block: 4096    regular file
```

```
Device: 254,1    Inode: 97422132    Links: 1
```

```
Access: (0664/-rw-rw-r--)  Uid: ( 1000/   werner)   Gid: ( 1000/   werner)
```

```
Access: 2024-09-10 16:47:10.212575439 +0200
```

```
Modify: 2024-09-10 16:48:08.600709043 +0200
```


```
Change: 2024-09-10 16:49:11.904851911 +0200
```

```
Birth: 2024-09-10 16:46:31.220485190 +0200
```

Beispiel: Ext3 / Ext4

Ext3

- Block-basiert
 - 12 direkte Zeiger zu Datenblöcken
 - 1 einfach indirekter Zeiger (der auf einen Block von direkten Zeigern zeigt)
 - 1 zweifach indirekter Zeiger
 - 1 dreifach indirekter Zeiger
 - (Weitere Details: [Ext3 for large filesystems, lwn.net, 2006](#))
- Journal



Ext4

- Extent-basierend
 - Extents adressieren keine einzelnen Blöcke, sondern bilden einen (möglichst großen) Bereich einer Datei auf einen Bereich zusammenhängender Blöcke auf der Festplatte ab.
 - Statt vieler einzelner Blocknummern werden nur noch drei Werte benötigt:
 - Start und
 - die Größe des Bereichs in der Datei (jeweils in Dateisystemblöcken) und
 - die Nummer des ersten Datenblocks
- Preallocation
- Delayed allocation
- Journal
- (Weitere Details [Das Linux-Dateisystem Ext4, heise.de, 2009](#))

Beispiel: btrfs



btrfs

- Copy-On-Write
- Komprimierung
- Subvolumes
- Integriertes RAID
- Resize

Overwrite
Dateisystem



Copy-on-write
Dateisystem




Neuen Block auf
neue Position
schreiben

Aktualisierung
der Metadaten

The Linux Storage Stack Diagram (Linux Kernel 6.9)

(version 6.9 2024-05-12, outlines the Linux storage stack as of Linux Kernel version 6.9)




Block Layer: remapper

Stacked Block Devices (DM, MD, DRBD, ...)

- Device Mapper
 - Device Mapper wird am häufigsten via LVM verwendet
 - Device Mapper Targets für Produktivbetrieb: dm-cache, dm-clone, dm-crypt, ..., dm-vdo (virtual data optimizer), ..., dm-zoned
 - Targets für Debugging-Zwecke: dm-delay, dm-dust, dm-flakey, dm-zero
- MD (RAID)
- DRBD
- bcache

BIOs (block I/Os)



Stacked Block Devices (DM, MD, DRBD, ...)

- Bei gestapelten Blockgeräten („stacked block devices“) gibt es **kein BLK-MQ** und **kein I/O Scheduling** (Elevators)!

```
werner@x390:~$ lsblk -s /dev/dm-0
```

NAME	MAJ:MIN	RM	SIZE	RO	TYPE	MOUNTPOINTS
lvmlmde	254:0	0	1,9T	0	crypt	
└─nvme0n1p3	259:3	0	1,9T	0	part	
└─┬─nvme0n1	259:0	0	1,9T	0	disk	

verschlüsselte LVM
volume group

```
werner@x390:~$ ls /sys/block/dm-0/
```

alignment_offset	dm	holders	removable	trace
bdi	events	inflight	ro	uevent
capability	events_async	integrity	size	
dev	events_poll_msecs	power	slaves	
discard_alignment	ext_range	queue	stat	
diskseq	hidden	range	subsystem	

kein mq (multi queue)
Unterverzeichnis

```
werner@x390:~$ ls /sys/block/dm-0/mq/
```

```
ls: cannot access '/sys/block/dm-0/mq/': No such file or directory
```

```
werner@x390:~$ cat /sys/block/dm-0/queue/scheduler
```


none

kein I/O Scheduler zur Auswahl...

Block Layer: Virtual Data Optimizer (VDO)

Virtual Data Optimizer (VDO)

- VDO bietet auf Block-Ebene:
 - Deduplizierung
 - Komprimierung
 - Thin-Provisioning
- Ursprünglich proprietär von Permabit entwickelt, 2017 von Red Hat gekauft, seit Kernel 6.9 nun mainline
- Einsatz z.B. in KVM-Umgebungen (Bildquelle: Red Hat)
 - Weitere Infos: [VDO \(Thomas-Krenn Wiki\)](#)



275_RHEL_2022

```
tk@lmde:~$ sudo lvcreate --type vdo --name vdo-test --size 40G --virtualsize 100G vg-sata
```

The VDO volume can address 36.00 GB in 18 data slabs, each 2.00 GB.

It can grow to address at most 16.00 TB of physical storage in 8192 slabs.

If a larger maximum size might be needed, use bigger slabs.

Logical volume "vdo-test" created.

```
tk@lmde:~$ lsblk
```

NAME	MAJ:MIN	RM	SIZE	RO	TYPE	MOUNTPOINTS
sda	8:0	0	223,6G	0	disk	
└─sda1	8:1	0	223,6G	0	part	
└─┬vg--sata-vgpool0_vdata	254:0	0	40G	0	lvm	
└─┬vg--sata-vgpool0-vgpool	254:1	0	100G	0	lvm	
└─┬vg--sata-vdo--test	254:2	0	100G	0	lvm	
nvme0n1	259:0	0	111,8G	0	disk	
└─nvme0n1p1	259:1	0	286M	0	part	/boot/efi
└─nvme0n1p2	259:2	0	8,2G	0	part	[SWAP]
└─nvme0n1p3	259:3	0	103,3G	0	part	/

```
tk@lmde:~$ sudo mkfs.ext4 -E nodiscard /dev/vg-sata/vdo-test
[...]
```

tk@lmde:~\$ sudo mount /dev/mapper/vg--sata-vdo--test /mnt

tk@lmde:~\$ sudo dd if=/dev/urandom of=/mnt/testfile-1.bin bs=1M count=1024
1024+0 records in
1024+0 records out
1073741824 bytes (1,1 GB, 1,0 GiB) copied, 2,03686 s, 527 MB/s

tk@lmde:~\$ sudo cp /mnt/testfile-1.bin /mnt/testfile-2.bin
[...]

tk@lmde:~\$ sudo cp /mnt/testfile-1.bin /mnt/testfile-[...].bin

tk@lmde:~\$ sync


tk@lmde:~\$ sudo vdostats

Device	1k-blocks	Used	Available	Use%	Space saving%
vg--sata-vpool0-vpool	41943040	5279324	36663716	13%	85%

Block Layer: BLK-MQ & I/O Scheduler


BLK-MQ Architektur

- Per-CPU Software Queues
 - CPU-lokale Listen
 - Kein Locking
 - Keine Cache Lines von anderen CPUs
- Darunter: Hardware Queues
 - Optimum:
 $N(\text{hardware queues}) = N(\text{CPUs})$




BLK-MQ: SW Staging Queues

- Ein „Request“ besteht aus einem oder mehreren BIOs
- Jede Queue hat ihren **eigenen Lock**
- Anzahl der Warteschlangen wird pro CPU oder pro Knoten definiert
- Anforderungen können **zusammengeführt** werden („**plugging**“)
- Anforderungen können **neu geordnet** werden (**I/O-Scheduler**)



BLK-MQ: SW Queues – I/O Scheduler

- Mehrere Scheduler, von denen jeder einer Heuristik folgt, um die I/O-Leistung zu verbessern:
 - none (technisch kein Scheduler)
 - mq_deadline
 - bfq
 - kyber
- „pluggable“ - kann während der Laufzeit über sysfs ausgewählt werden
- Das Scheduling erfolgt nur zwischen Anfragen in derselben Warteschlange




BLK-MQ: HW Dispatch Queues

- Anzahl an HW Queues:

- hängt von der Anzahl der von der Hardware/dem Treiber unterstützten hw-Kontexte ab
- Treiber können zwischen 1 und 2.048 hw-Warteschlangen unterstützen (MSI-X-Limit)
- ist nicht größer als die Anzahl der Kerne
- SATA- und SAS-Geräte unterstützen eine einzige hw-Warteschlange

- Hardware-Warteschlangen sind unabhängig voneinander

- jede Software-Warteschlange kann in ihre Hardware-Warteschlange befüllen, ohne dass eine globale Reihenfolge eingehalten werden muss (innerhalb des Block Layers wird kein Ordering unterstützt)
- keine Locks zwischen Hardware-Warteschlangen -> höhere Performance
- HW kann eine oder mehrere Queues implementieren, die direkt auf NUMA-Knoten / CPU-Kerne abgebildet werden
 - Dies bietet einen schnellen IO-Pfad von Anwendungen zur Hardware ohne Zugriff auf den entfernten Speicher/Caches eines anderen NUMA-Knotens.






6 Cores, no HT



Completion Queues
Allocated (NCQA): 16

Submission Queues
Allocated (NSQA): 16



```
werner@pc:~$ lscpu
CPU(s): 6
  Model name: Intel(R) Core(TM) i5-8400 CPU @ 2.80GHz
werner@pc:~$ ls /sys/block/nvme0n1/mq/
0 1 2 3 4 5
werner@pc:~$ cat /sys/block/nvme0n1/mq/0/cpu_list
0
werner@pc:~$ cat /sys/block/nvme0n1/queue/scheduler
[none] mq-deadline
werner@pc:~$ sudo nvme get-feature /dev/nvme0n1 -f 7 -H
get-feature:0x07 (Number of Queues), Current value:0x000f000f
Number of IO Completion Queues Allocated (NCQA): 16
Number of IO Submission Queues Allocated (NSQA): 16
```



```
werner@pc:~$ lscpu
```

```
CPU(s):
```

6

```
Model name:
```

```
Intel(R) Core(TM) i5-8400 CPU @ 2.80GHz
```

```
werner@pc:~$ ls /sys/block/nvme0n1/mq/
```

```
0 1 2 3 4 5
```

```
werner@pc:~$ cat /sys/block/nvme0n1/mq/0/cpu_list
```

```
0
```

```
werner@pc:~$ cat /sys/block/nvme0n1/queue/scheduler
```

```
[none] mq-deadline
```

```
werner@pc:~$ sudo nvme get-feature /dev/nvme0n1 -f 7 -H
```

```
get-feature:0x07 (Number of Queues), Current value:0x000f000f
```

```
Number of IO Completion Queues Allocated (NCQA): 16
```

```
Number of IO Submission Queues Allocated (NSQA): 16
```

Obwohl die NVMe SSD 16 Queues unterstützt, richtet blk-mq nur 6 Queues ein (da die CPU nur 6 Cores hat)






6 Cores, no HT



SATA HDD
(Single Queue)



```
werner@pc:~$ lscpu
```

```
CPU(s):
```

6

```
Model name: Intel(R) Core(TM) i5-8400 CPU @ 2.80GHz
```

```
Thread(s) per core: 1
```

```
werner@pc:~$ uname -a
```

```
Linux pc 6.10.6+bpo-amd64 #1 SMP PREEMPT_DYNAMIC [...] x86_64
```

```
werner@pc:~$ ls /sys/block/sda/mq/
```

0

```
werner@pc:~$ cat /sys/block/sda/mq/0/cpu_list
```

0, 1, 2, 3, 4, 5

```
werner@pc:~$ cat /sys/block/sda/queue/scheduler
```

none [mq-deadline]



```
root@PMX5:~# nvme list -v
```

```
Device      SN                      MN
```

```
-----  
nvme0      9240A029TLW9          KIOXIA KCD81RUG960G
```

```
root@PMX5:~# nvme get-feature /dev/nvme0n1 -f 7 -H
```

```
get-feature:0x07 (Number of Queues), Current value:0x007f007f
```

```
Number of IO Completion Queues Allocated (NCQA): 128
```

```
Number of IO Submission Queues Allocated (NSQA): 128
```

```
root@PMX5:~# cat /sys/block/nvme0n1/queue/scheduler
```

```
[none] mq-deadline
```



```
root@PMX5:~# lscpu
```

```
CPU(s):
```

```
On-line CPU(s) list: 0-31
```

```
Model name: AMD EPYC 9124 16-Core Processor
```

```
Thread(s) per core: 2
```

```
Core(s) per socket: 16
```

```
Socket(s): 1
```

NVMe
device

32 Hardware Dispatch
Queues (die NVMe SSD
würde 128
unterstützen)

```
root@PMX5:~# ls /sys/block/nvme0n1/mq/
```

```
0 1 10 11 12 13 14 15 16 17 18 19 20 21 22 23 24 25  
26 27 28 29 30 31 4 5 6 7 8 9
```


```
root@PMX5:~# cat /sys/block/nvme0n1/mq/0/cpu_list
```

```
0  
root@PMX5:~# cat /sys/block/nvme0n1/mq/1/cpu_list
```


```
1  
[...]
```

Genau eine Software
Staging Queue ist
jeder HDQ zugeordnet






Gerätetreiber



The “big picture”

(version 6.9 2024-09-17, outlines the Linux storage stack as of Linux Kernel version 6.9)



The Linux Storage Stack Diagram
https://www.thomas-krenn.com/en/wiki/Linux_Storage_Stack_Diagram
 Design Werner Fischer, support by Christoph Hellwig, Richard Weinberger et al.
 License: CC-BY-SA 4.0, see <http://creativecommons.org/licenses/by-sa/4.0/>



**THOMAS
KRENN®**