

# SLAC 2024

06.-08. Mai 2024 | Berlin

[www.slac-2024.de](http://www.slac-2024.de)



# Einführung in Ceph



# Software defined Storage

# Abstraktion von Hardware



Hardware ist „egal“

Fing eigentlich schon mit LVM an

Beschränkt sich aber nicht nur auf eine Maschine

Redundanz nicht über RAID-Controller

Jede Hardware kann ausfallen

- Software natürlich auch

# Skalierbarkeit



Beliebig in die Breite skalieren

Keine „teure“ vertikale Skalierung notwendig  
günstigere Commodity Hardware einsetzbar

Trotzdem: Blick auf Performance wichtig



Ceph



# Es war einmal eine Open Source Speicherlösung namens Ceph

# Ceph ist ...



## gesetzt

- gibt es seit 2006
- Doktorarbeit von Sage Weil

## interessant

- verteilter Objektspeicher
- Redundanz
- Datensicherheit
- effiziente Skalierung
- lauffähig auf (fast) jeder Hardware

# Ceph bietet ...



## einen Storage-Cluster

- der sich selbst verwaltet
- der sich selbst heilt
- ohne Engpässe

## drei Schnittstellen

- Objektspeicher (kompatibel zu S3)
- Blockspeicher (für VMs, etc)
- verteiltes Dateisystem



Es war einmal eine Open Source Speicherlösung namens Ceph  
Mit verschiedenen Komponenten, die zu kennen sich lohnt

# Object Storage Daemon



OSD speichert Daten auf

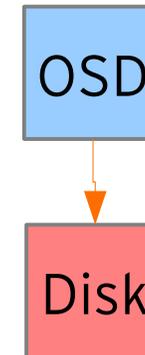
- HDD
- SSD
- NVMe
- oder was es noch geben wird

Ein Prozess pro Blockdevice

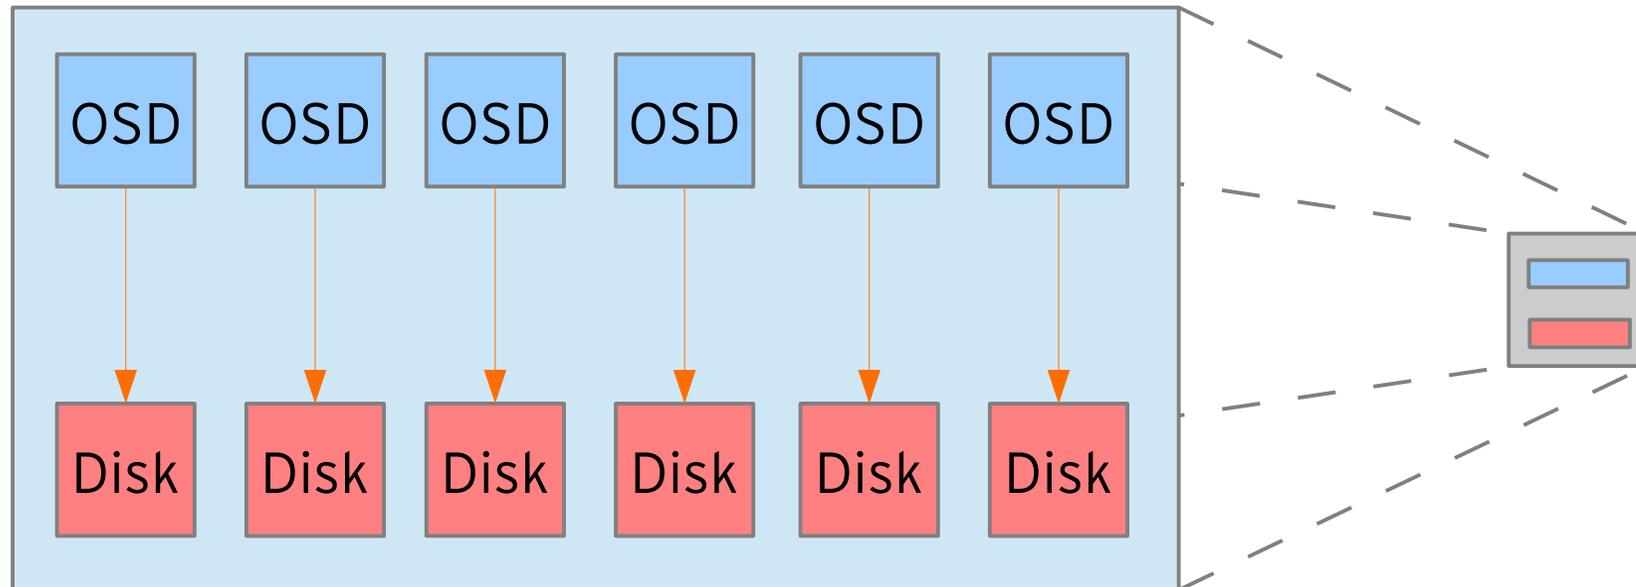
OSDs liefern Daten direkt an Clients

OSDs sprechen mit anderen OSDs

- Replikation
- Datenwiederherstellung



# Mehrere OSDs in einem Ceph-Knoten



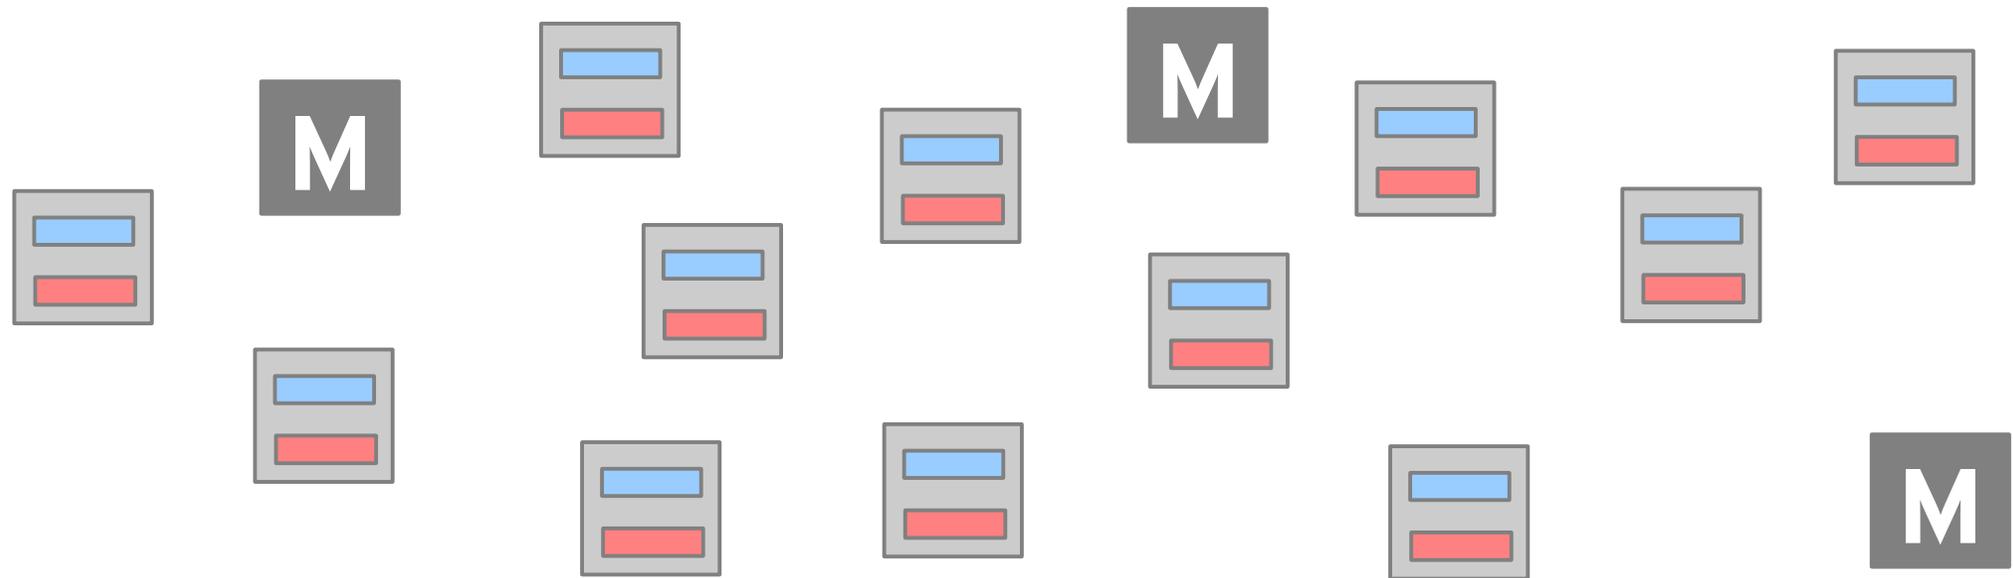
# Dazu kommen Monitore



MONs bilden das Gehirn des Clusters  
Quorum für Entscheidungen  
Nicht im Datenpfad



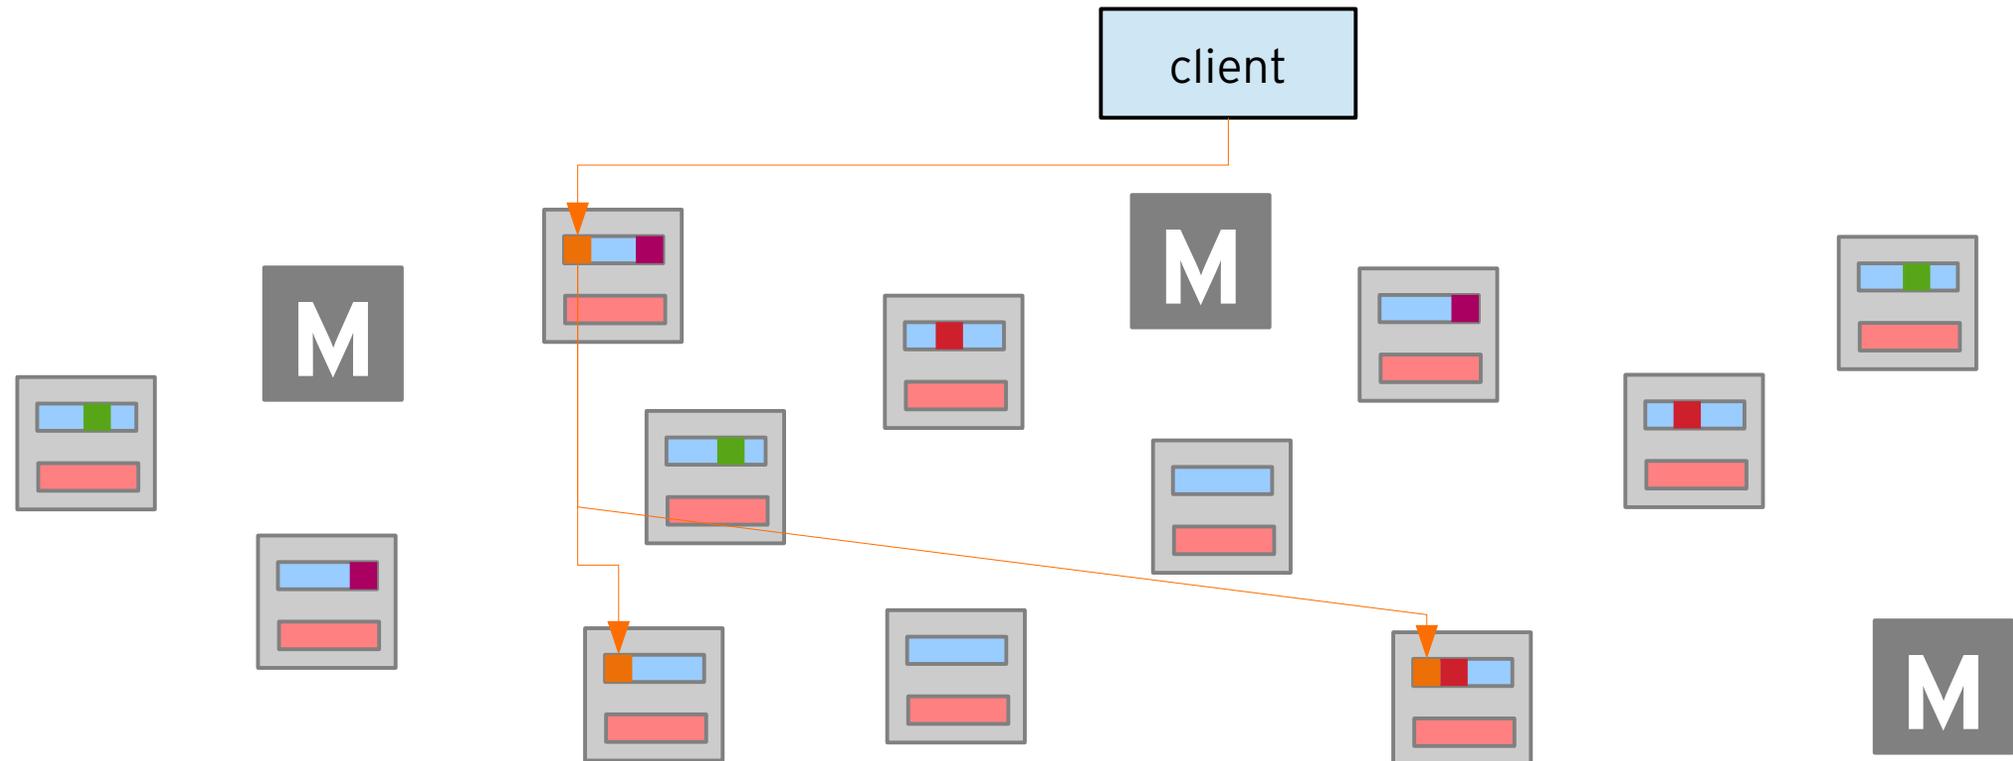
# Und schon ist der Ceph-Cluster fertig



# Schreiben ...



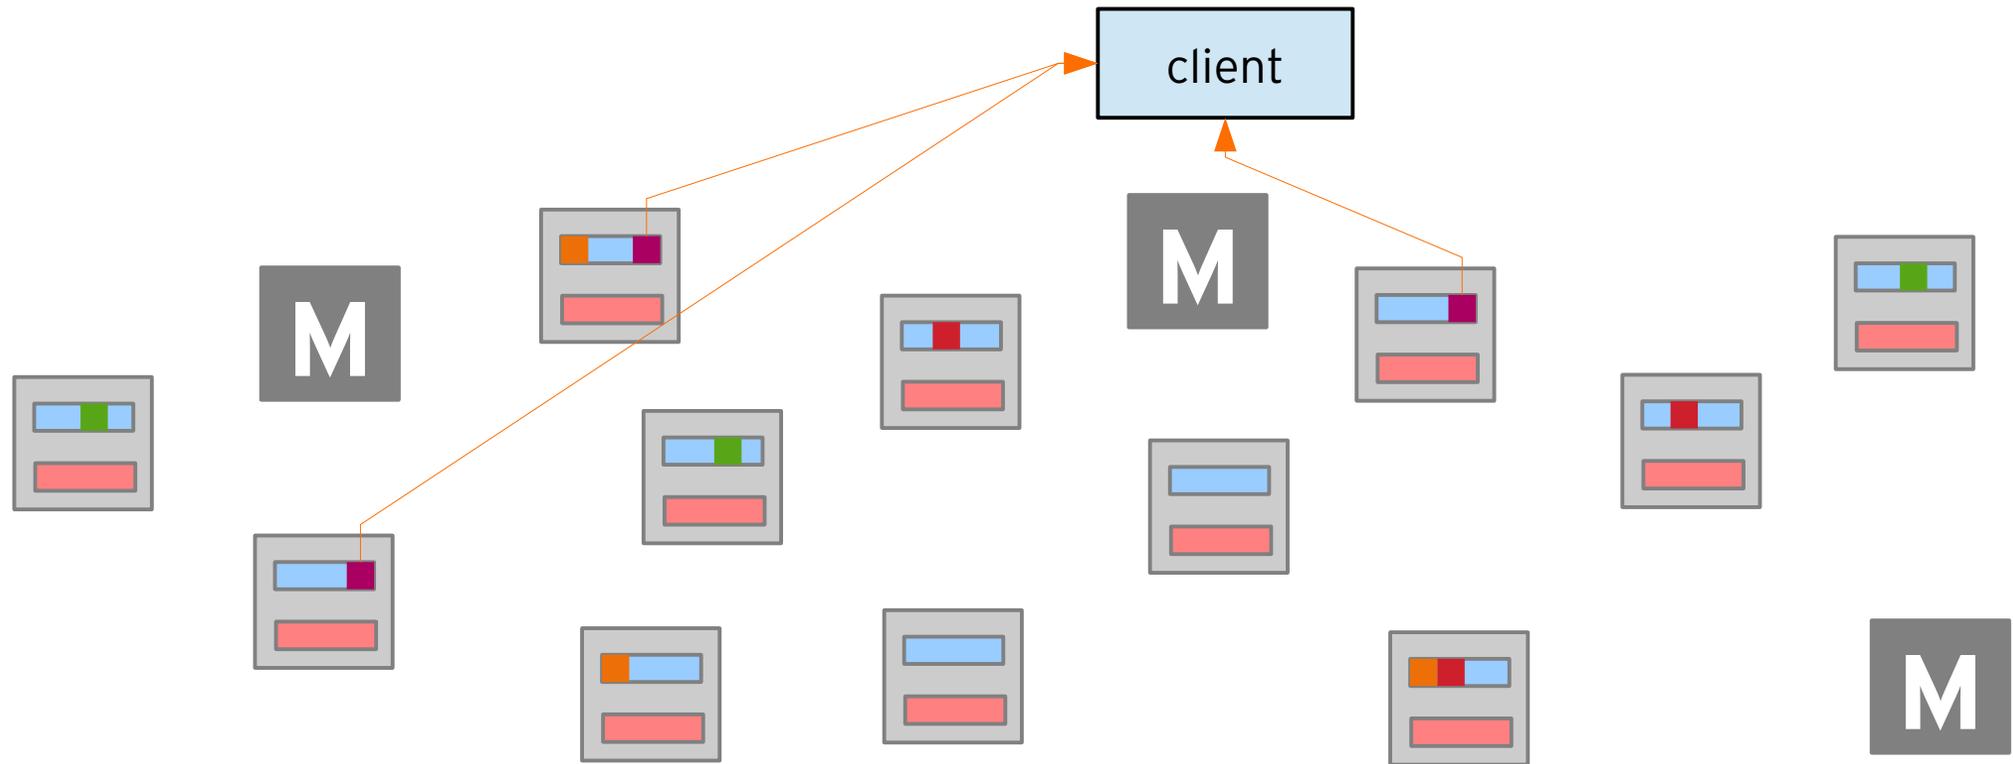
Ceph-Objekt wird auf ein OSD geschrieben und von dort repliziert



# .. und Lesen



gelesen werden kann von jeder Kopie



# Konzeptionelle Komponenten



## Pool

logischer Container für Ceph-Objekte

### Eigenschaften

- Name + ID
- Anzahl der Objektkopien
- Erasure Coding Einstellungen
- CRUSH Regel
- Besitzer
- Quota
- Snapshots

## CRUSH

Controlled Replication Under Scalable Hashing

- Algorithmus

MONs verwalten CRUSH Map

- Topologie des Clusters
- Ausfallzonen

Clients kalkulieren selber

- Platzierung der Daten
- keine Engpässe im Datenpfad



Es war einmal eine Open Source Speicherlösung namens Ceph  
Mit verschiedenen Komponenten, die zu kennen sich lohnt

**Alle wollen Software Defined Storage anstelle von „Legacy“ Storage-  
Arrays**

# Klassische (proprietäre) Speichersysteme



## Vorteile

- Einfach zu verstehen
- Vorhandene Erfahrung
- „Bauchgefühl“ besser
- Vorhersagbar in Verhalten und Kosten

## Nachteile

- Streng kontrollierte Umgebung
- Begrenztes Wachstum
- Weniger Optionen
  - bestimmte HDDs / SSDs
  - Anzahl der Blockdevices
  - Netzwerk-Varianten
  - Controller
  - CPU

# Software defined Storage



## **Vorteile**

Selbermachen

Unbegrenztes Wachstum

Anpassungsfähigkeit

Auswahlmöglichkeiten

## **Nachteile**

Selbermachen

Komplexität

Performance (Software CPU-bound)

# Software defined Storage



Durchsatz

Latenz

IOPS

Verfügbarkeit

Zuverlässigkeit

Kapazität

Packungsdichte

Kosten

# Konzipierung von SDS



## Zielkonflikte

Verfügbarkeit gegen Packungsdichte

IOPS gegen Packungsdichte

Alles gegen Kosten

Große Auswahl an Hardware → Unübersichtlich

Softwareauswahl (gibt ja nicht nur Ceph)

Es gibt kein Standardrezept, das allen passt



Es war einmal eine Open Source Speicherlösung namens Ceph  
Mit verschiedenen Komponenten, die zu kennen sich lohnt  
Alle wollen Software Defined Storage anstelle von „Legacy“ Storage-  
Arrays  
und hatten viele Fragen zu Konfigurationsmöglichkeiten

# Netzwerk



die schnellste Netzwerktechnologie, die das Budget hergibt

Client-Zugriffs- und Cluster-Replikations-Netzwerk trennen

Replikations-Netzwerk mit mindestens Faktor 2 in der Bandbreite

Ethernet 10G < 40G < 25G < 100G

wegen der Latenz

# Storage-Knoten



CPU, CPU, CPU

RAM, RAM, RAM

- 4GB pro OSD

guter Storage Controller

SSDs, SSDs, SSDs

HDDs

- günstiger
- eher für Archivdaten
- immer mit RocksDB+WAL auf SSD

# Redundanz

## Replikation

n genaue Kopien

hohe Leseraten

gute Schreibraten

- schnelles Cluster-Netzwerk

Wiederherstellung von mehreren Quellen

Netto-Kapazität nur  $1/n$

- $n = 3 \rightarrow 33\%$



## Erasure Coding

Daten aufgeteilt in  $k$  Teile und  $m$  Parity

Platzeffizient

hoher CPU-Verbrauch beim Schreiben

- Parity-Berechnung

Wiederherstellung braucht CPU

Netto-Kapazität:  $k / (k + m)$

- $k = 8, m = 2 \rightarrow 80\%$
- $k = 2, m = 2 \rightarrow 50\%$

$k + m + 2$  unabhängige Knoten notwendig

# Cluster ausbauen – Mehr Storage-Knoten



Gesamtkapazität steigt

Gesamtdurchsatz steigt

Gesamt-IOPS steigen

Verfügbarkeit erhöht sich

Latenz unverändert

Limit: Netzwerktopologie

Neuverteilung der Daten erzeugt temporär höhere Last



Es war einmal eine Open Source Speicherlösung namens Ceph  
Mit verschiedenen Komponenten, die zu kennen sich lohnt  
Alle wollen Software Defined Storage anstelle von „Legacy“ Storage-  
Arrays  
und hatten viele Fragen zu Konfigurationsmöglichkeiten  
und lernten, mit den richtigen Fragen Proof-of-Concepts zu bauen und  
auszubauen

# Wie setze ich einen Ceph-Cluster zusammen?



Was soll der Cluster tun?

Budget abschätzen

Pilotprojekt bauen in ~10% der Zielgröße

Stellschrauben verändern, bis die Performance passt

Skalieren durch Hinzufügen weiterer Komponenten

Nicht von Anfang an perfekt, kann aber über die Zeit wachsen



# Ceph-Clients

# librados



native Ceph-Objekte

wird praktisch nicht verwendet

rados als CLI-Tool praktisch für Debugging etc

# RADOS Block Device, RBD



virtuelle Festplatte

direkt per Kernel eingebunden

- /dev/rbd0

als (Boot-) Image für KVM-VMs mit qemu+rbd

- libvirt
- Proxmox
- OpenStack
- u.a.

teilt Gigabyte-großes Image in viele kleine 4MB Ceph-Objekt auf

Gateway für iSCSI möglich

# Rados-Gateway, S3, Swift



Object-Store mit HTTP-API

weitgehend kompatibel zu Amazon S3

Support für Object Locks

- WORM-ähnliches S3-Feature
- interessant für Archive / Backup

Nutzt mehrere Pools

- schneller SSD-Pool für Index
- platzsparender erasure coded HDD-Pool für Daten

# CephFS



POSIX-kompatibles verteiltes Dateisystem

Client-Implementierung nur für Linux

- FUSE
- Kernel

Daten auf mehrere Pools aufteilbar

- schnelle oder langsame Pools für verschiedene Teile des Dateisystems

Quota, Snapshots

Dateisystem-Zugriffsrechte bestimmt der Client (!)

- ähnlich wie NFSv3 oder lokales Dateisystem

Gateways für SMB (~~Samba VFS~~) und NFS (Ganesha FSAL) möglich

# FAQ



Kann ich mit Ceph meinen 300GB Fileserver ausfallsicher machen?

Nein.

Aber wenn Du Ceph brauchst, gibt es nichts anders.



Es war einmal eine Open Source Speicherlösung namens Ceph  
Mit verschiedenen Komponenten, die zu kennen sich lohnt  
Alle wollen Software Defined Storage anstelle von „Legacy“ Storage-  
Arrays  
und hatten viele Fragen zu Konfigurationsmöglichkeiten  
und lernten, mit den richtigen Fragen Proof-of-Concepts zu bauen und  
auszubauen  
**und lebten glücklich bis ans Ende ihrer Tage**



# Fragen und Diskussionen

# CompetenceCall



Das Backup für Ihre  
Server-Administration.

Nutzen Sie unsere  
SLA-Verträge und sichern  
Sie sich den 24/7-Support unserer  
Linux-Consultans.

- Kontinuierliche Absicherung mit garantierten Reaktionszeiten und festen SLAs
- Rückendeckung im Notfall: mindestens LPIC-2 zertifizierte Profis mit jahrelanger, täglicher Admin-Erfahrung
- Projektunterstützung: maßgeschneiderte Lösungen, die Flexibilität, Sicherheit, Administrierbarkeit und Hochverfügbarkeit vereinen
- Services: Performanceanalyse, Serverhärtung, Netzwerkanalyse, Konfigurationshilfe, Datenrestaurierung

# Werde Teil des Teams

- Du bist neugierig, voller Tatendrang und überzeugt von Linux, Open Source und sicherer, freier Kommunikation?
- Wir freuen uns über Unterstützung im Team:  
[www.heinlein-support.de/jobs](http://www.heinlein-support.de/jobs)





# Bleiben wir im Kontakt

## Robert Sander

Tel. +49 30 40 50 51-40  
[r.sander@heinlein-support.de](mailto:r.sander@heinlein-support.de)

Heinlein Support GmbH  
Schwedter Straße 8/9 | 10119 Berlin  
[www.heinlein-support.de](http://www.heinlein-support.de)