



# OSL RSIO

Remote Storage I/O

Storage-Networking der nächsten Generation

**Bert Miemietz**

OSL Gesellschaft für  
offene Systemlösungen mbH




# *Warum RSIO ?*

OSL Gesellschaft für offene Systemlösungen mbH  
[www.osl.eu](http://www.osl.eu)

# Speichernetzwerke

Heute Standard im Rechenzentrum - Warum?



- **Spezialisierung / Funktionsteilung**

- *Spezialsysteme für einfachere Handhabung, bessere Verfügbarkeit und Performance*

- **Flexibilität**

- *Trennung Compute Node – Storage erlaubt Anwendungsmobilität, HV, DR*
- *Trennung ermöglicht diverse Virtualisierungsansätze*

- **Heutige Massenspeichertechnologien sind langsam und fehleranfällig**

- *Netzwerke versprechen Skalierbarkeit und bessere Verfügbarkeit*

# Klassisch: Spezialisierte Netzwerke

## Verschiedene Netzwerke für verschiedene Anwendungen



*Aus Sicht des Anwenders sind sich beide Netzwerktechnologien heute im Verhalten oftmals ähnlicher als erwartet*

### **Fibre Channel**

- *Spezialprotokoll*
- *Block I/O*
- *Kanaleigenschaften*
- *Niedrige Latenz*
- *Hoher Durchsatz*
- *Niedrige CPU-  
Belastung*

- *NFS,  
SMB ...*
- *Backup*
- *IP over FC*
- *FC over IP*

### **Ethernet / IP**

- *Universalprotokoll*
- *Primär von Applikationen getrieben*
- *Zweck: Kommunikation*
- *Client/Server-Applikationen*
- *Implementierung wesentlich im OS  
-> höhere CPU-Belastung*
- *Seit langem auch für Storage  
genutzt (NFS, Backup ...)*

# Warum Storage über Ethernet?

## Anforderungen und Möglichkeiten



- **Anforderungen und Erwartungen**


- *Erfordernisse der Anwendungen und Protokolle (Kommunikation, Filesharing etc.)*
- *Preisliche Motivationen*
- *Einheitliche Infrastruktur, weniger Ports ?*
- *Einfachheit, Flexibilität ?*
- *Virtualisierungstechnologien, Verfügbarkeit von Treibern*
- *Zusatzfunktionen (Konvertierungen, Filesystemsnapshots ...)*

- **Möglichkeiten**

- *Gigabit-LAN heute vergleichsweise preiswert*
- *Gigabit-LAN heute in vernünftiger Relation zur Geschwindigkeit einer Festplatte bzw. eines RAID-Systems*
- *Gigabit-LAN heute in günstiger Relation zu Durchsatz-Anforderungen der Applikationen*
- *Mehrere Gigabit-Ports je Server*
- *Ethernet ist eigentlich (fast) kein Ethernet mehr -> Switching-Technologie*
- *RAID-Systeme / Filer sprechen direkt die erforderlichen Protokolle*
- *Neue Performance-Erwartungen an 10Gbit-Ethernet*

# Was ist mit den Kostenvorteilen?

## Ein Vergleich mit Fibre Channel (Stand 10/2009)




# Storage über Ethernet heute: NFS, SMB, CIFS

NA(F)S präsentiert sich mit handfesten Vorteilen



- *Spezialisierung auf Fileservices, dafür relativ einfache Handhabung*
- *kann komplexe RAID-Funktionen verbergen*
- *dateisystemtypische Funktionalitäten wie Snapshots und weitere Sonderfunktionen*
- *ermöglichen Filesharing*
- *weite Verbreitung und Unterstützung der wichtigsten Protokolle*
- *im Rahmen des heute Vorstellbaren Möglichkeiten nahezu ausgereizt*




OSL Gesellschaft für offene Systemlösungen mbH  
[www.osl.eu](http://www.osl.eu)

# Die Kehrseite des NAFS-Ansatzes

Es gibt auch prinzipbedingte Nachteile



- aufwendige Integration mit Server-OS (Zugriffskontrolle, User-Management)
- Cache- und Cohärenzproblematik, schwierige Nutzung der Client-Ressourcen
- nicht trivial: Skalierbarkeit, Hochverfügbarkeit, Multipathing
- feste Bindung an File-Access-Semantik
- mit zunehmender Funktionalität auch Zunahme von Komplexität und ggf. Inkompatibilitäten




# Starke Argumente für Block-I/O im RZ

*Jenseits von Filesharing überwiegen die Vorteile*



- *Volle Kontrolle des Client-OS über das Storage-Device*
- *Nutzbar für beliebige Filesysteme*
- *Keine Kopplung an Server-OS (Isolation, privates Identity Management)*
- *Nur Übertragung von I/O, nicht von Cache-Inhalten*
- *Cache liegt beim Client -> schnellster Zugriff, Client-Caches summieren sich auf*
- *Einfache Administration, schlankes Protokoll, hohe Geschwindigkeit*



# **Block-I/O über Ethernet/IP - Performance**



## *Performance hat viele Aspekte*



- **Latenz und Service Time**
  - *Relevant für einzelnen I/O und single threaded I/O*
  
- **Maximaler Durchsatz**
  - *Relevant für multithreaded I/O*
  
- **Skalierbarkeit / Parallelisierbarkeit**
  - *Thema für Multipathing*
  
- **IO-Größe**
  - *Relevant für Nutzdatenanteil am Gesamtdurchsatz*

# Bedeutung von Latenzen und IO-Größe

Heutige Paradigmen setzen Grenzen



**Zeitverteilung**

**großer IO**

Overhead  
6%



**kleiner IO**

Overhead  
20%



# Storage over Ethernet: Akzeptable Latenzen?

## Betrachtungen zur Performance



Zeit zur Übertragung von 32 Byte an 1 GBit-Lanboard


Zeit zur Übertragung von 512 Byte an 1 GBit-Lanboard

Zeit zur Übertragung von 8kByte an 1 GBit-Lanboard

memcpy 8k auf 600MHz-System

Threadwechsel per CV auf 600MHz-System

32Bit-Typkonvertierung auf 600MHz-System



OSL Gesellschaft für offene Systemlösungen mbH

[www.osl.eu](http://www.osl.eu)

# Storage over Ethernet: Akzeptable Latenzen?

## Betrachtungen zur Performance



Zeit zur Übertragung von 32 Byte an 1 GBit-Lanboard

Zeit zur Übertragung von 512 Byte an 1 GBit-Lanboard

**Es geht also:**

Zeit zur Übertragung von 8kByte an 1 GBit-Lanboard


**1. Weniger um die Hardware.**

**2. Entscheidend um das Protokoll.**

**3. Entscheidend um die Systemsoftware.**

**4. Nicht unerheblich um die Applikation.**

32Bit-Typkonvertierung auf 600MHz-System



OSL Gesellschaft für offene Systemlösungen mbH

[www.osl.eu](http://www.osl.eu)

# ***Block-I/O über Ethernet mit iSCSI***


## ***Bekanntes Protokoll über neues Medium***



- *Low-Level-Protokoll auf IP umgesetzt*
- *Plattformunabhängig auf Server-Seite (Target)*
- *Starke Bindung an TCP, Offload-Engines auf Initiatorseite dennoch selten*
- *Tiefer Stack – nicht unerheblicher CPU-Bedarf*
- *Zahlreiche SCSI-Funktionen, aus Sicht der Anwendungen aber dennoch Verlust an Funktionalität*  
*-> Storage-Management meist über andere Protokolle*
- *Vernetzte, geclusterte Speichersysteme ohne speziellen Support*
- *Weitere Schwierigkeiten*
  - *Multipathing*
  - *Clustering / Parallelisierung*
  - *Nomenklatur*
  - *Target Portal Groups*

# Block-I/O über Ethernet/IP – ohne SCSI

Ein anderer Ansatz mit OSL RSIO



# RSIO - Remote Storage IO

*Eckdaten der neuen Technologie für LAN-attached (shared) Block Devices*



- *eigenes, von OSL entwickeltes Protokoll*
- *natürliche Erweiterung des Speichervirtualisierung auf LAN (Ethernet)*
- *voller Clustersupport möglich (Client und Server), vorrangig natürlich:*
- *Einbindung in OSL-Clustertechnologie*
- *alle relevanten IO-Aufrufe (read, write, ioctl ...) abbildbar*
- *hochportable Implementierung*
- *internes Layout berücksichtigt moderne CPU- und Serverkonzeptionen*
- *guter Durchsatz / gute Verfügbarkeit mit heutiger preiswerter Standardtechnik*
- *integrierte und bequeme Administration vom Host aus*
- *Erweiterbarkeit, Raum für intelligente IO-Lösungen*



# *Überblick zur Technologie*

OSL Gesellschaft für offene Systemlösungen mbH  
[www.osl.eu](http://www.osl.eu)

# OSL Remote Storage IO (RSIO)


## *Etwas zu den Details der Implementierung*



- *Definition eigener Frames*
  - *Unabhängigkeit von TCP*
  - *Durchsatz-Optimierungen*
  - *ermöglicht Zusatzfunktionen wie Checksum / Encryption*
  - *Frames mit variabler Größe*
  - *Overhead per Frame nur 16 Byte*
- *Trennung von Treiber und Transport*
  - *größerer Funktionsumfang bei hoher Portabilität*
  - *besseres Error-Handling*
  - *Performance offensichtlich kein Problem*
  - *hochflexibler Multithreading-Support*
  - *bessere Abschirmung des Kerns*
- *Integriertes autonomes Multipathing und Trunking*
- *Selbstkonfiguration und Error Recovery*
- *Unterstützung geclusterter Server*
- *vollständige Abbildung relevanter Schnittstellen möglich (z. B. dkio, mtio)*

# RSIO - Architektur im RZ

Klar gegliedertes und flexibles administratives Konzept



OSL Gesellschaft für offene Systemlösungen mbH

[www.osl.eu](http://www.osl.eu)

# Parameter der RSIO-Architektur

## Flexible Client-Server-Implementierung



- *Ein Namespace definiert Server (und Clients) mit Zugriff auf dieselben Storage-Ressourcen*
- *Auf einem Serverhost können (nahezu) beliebig viele Server(prozesse) laufen*
- *Jeder Serverhost kann (nahezu) beliebig viele Clients bedienen*
- *jeder Client unterstützt den Zugriff auf bis zu 256 Server*
- *jede Maschine (Client und Server) unterstützt bis zu 8 Interfaces*
- *jeder Client hat simultan Zugriff auf verschiedene Namespaces*
- *Auto-Explorer*
  - *Ermitteln verfügbarer Verbindungen*
  - *Ermitteln der Schnittstelleneigenschaften*
  - *Test der Parameter auf der Übertragungsstrecke*



# *RSIO und Linux*

OSL Gesellschaft für offene Systemlösungen mbH  
[www.osl.eu](http://www.osl.eu)

# Und was ist mit Linux?


Was der technisch Interessierte zu diesem Thema wissen muß



- **GNU:**
  - **gcc** sehr leistungsfähiges Werkzeug, auf vielen Plattformen verfügbar
  - Unterstützung aller für C relevanten Programmier-Techniken und **Standards**
- **LINUX:**
  - leistungsfähiges OS, verfügbar auf vielen Hardware-Plattformen
  - positiv formuliert: große Vielfalt (ubuntu, fedora, openSUSE, **debian**, Mandriva, LinuxMint, PCLinuxOS, **slackware**, gentoo linux, CentOS, **Red Hat**, SLES, SLED)
  - **Gemeinsamkeit:** Kernel + gcc/libc + System Calls, oft auch verfügbare Applikationen
- **Kernel:**
  - unbestritten leistungsfähig und hoch optimiert
  - keine stabilen internen Schnittstellen -> aktuelle Dokumentation?  
-> Zukunftssicherheit für add-on-Driver?
  - Kernelprogrammierung sehr speziell bzw. proprietär (Kernel Build System, Macros etc.)
  - Konzepte unterscheiden sich z. T. deutlich von anderen Systemen (z. B. Multithreading)
  - Wartbarkeit des Kernels? (Strukturierung, Debugging ...)
  - Lizenzproblematik

# Wie umschiffen wir mögliche Probleme?

Die Entdeckung des Userspace...



# Wie umschiffen wir mögliche Probleme?

Die Entdeckung des Userspace...



## Vorteile:

### 1. Größter Teil läuft im Userspace

- > Portabilität
- > Systemstabilität
- > Fehlerbehandlung
- > Debugging
- > Handling (z. B. Clusterumgebungen)
- > Solaris kann vorrangige Entwicklungsplattform bleiben


### 2. Schlankes Kernelmodul und damit

### 3. Erleichterungen für die Portierbarkeit des Kernelmoduls

Filesystems

Applications

Others



# Und konkret ?

## Die Umsetzung auf Linux



- **Entwicklungsplattform: SUSE Linux Enterprise Server 11 (x86\_64)**
  - *Kernel: 2.6.27.19-5-default*
- **Ladbares Kernel-Modul (analog Solaris: “rs”)**
  - *Modul heißt analog zu Solaris “rs”*
  - *Vorabinform: modinfo*
  - *Laden: insmod (+ ggf. Optionen)*
  - *Anzeigen: lsmod*
  - *Entladen: rmmod*
- **Besonderheiten**
  - *Logging und Debug-System analog zu Solaris implementiert*
  - *sysfs-Integration, Management der Disk-Device-Nodes via rsconfig*
  - *Reservierung Major-Nummer für Block- und Char-Devices (Default: local 246)*
  - *Effektiv im Moment für Anwender nur Nutzung der Block-Devices (Disk)*
  - *modprobe-Konfiguration noch nicht enthalten*

# In's System geschaut

## Die Sicht des Client-Administrators auf den Server



```
[root@big-6] rsconfig -q
000 osl
    clt: big-6
    srv: 000 big-5
        0 tvoll1          disk          2097152 blocks of 512 bytes
        0 shadow         disk          2097152 blocks of 512 bytes
        0 z1_root         disk         10485760 blocks of 512 bytes
        0 sparse          disk         10485760 blocks of 512 bytes
        0 whole           disk         41943040 blocks of 512 bytes
        0 iscsit_cfg      disk           20480 blocks of 512 bytes
        0 target          disk          2097152 blocks of 512 bytes
        0 tconf           disk           20480 blocks of 512 bytes
        0 p07             disk        585920023 blocks of 512 bytes
        0 p08             disk        585920023 blocks of 512 bytes
        1 b07            disk        976545023 blocks of 512 bytes
        1 b08            disk        976545023 blocks of 512 bytes
        2 b09            disk        976545023 blocks of 512 bytes
        2 b10            disk        976545023 blocks of 512 bytes
        3 b11            disk        976545023 blocks of 512 bytes
        3 b12            disk        976545023 blocks of 512 bytes
```

```
[root@big-6] rsconfig -qv
000 osl (12345)
    clt: big-6 (0139dfX982)
    srv: 000 big-5 (id 1)
        0 tvoll1          disk          2097152 blocks of 512 bytes
            c: /dev/av0/rtvoll1
            b: /dev/av0/tvoll1
```

# In's System geschaut

## Wie sich die Volumes auf dem Client darstellen



```
[root@big-6] rsconfig -lvv
osl:tvoll1@0                               2097152 blocks,    1 server(s)
  c: /dev/av0/rtvoll1
  b: /dev/av0/tvoll1

osl:shadow@0                               2097152 blocks,    1 server(s)
  c: /dev/av0/rshadow
  b: /dev/av0/shadow

osl:z1_root@0                              10485760 blocks,   1 server(s)
  c: /dev/av0/rz1_root
  b: /dev/av0/z1_root

osl:sparse@0                              10485760 blocks,   1 server(s)
  c: /dev/av0/rsparse
  b: /dev/av0/sparse

osl:whole@0                                41943040 blocks,   1 server(s)
  c: /dev/av0/rwhole
  b: /dev/av0/whole
```



# *Leistungsparameter*


OSL Gesellschaft für offene Systemlösungen mbH  
[www.osl.eu](http://www.osl.eu)

# Und die Performance ?

## Nochmal kurz zur Theorie ...




- *wird zumeist schwächer sein als FC*
  - *schwächeres Universalprotokoll TCP/IP*
  - *bei IP werden erhebliche Kommunikationsteile im OS gerechnet*
  - *Ausnahmsweise stärker dort, wo der Server nicht über SAN/SCSI auf Storage zugreift*
- *Performance-Boost gegenüber NAFS durch IO-Vermeidung*
  - *virtueller IO-Cache bei exklusivem Zugriff*
  - *hier Vorteil gegenüber NFS/SMB*
  - *in manchen Situationen auch leichte Nachteile denkbar*
- *sollte bei vergleichbarer Last stärker sein als iSCSI*
  - *erheblich schlankeres Protokoll*
  - *moderneres Design*
- *Performance-Vorteile durch Multithreading*



# Performance in der Praxis

Wer viel mißt, mißt ... Vergleiche zu iSCSI / Filesysteme



OSL Gesellschaft für offene Systemlösungen mbH


[www.osl.eu](http://www.osl.eu)

# Performance in der Praxis

Wer viel mißt, mißt ... Vergleiche zu FC und iSCSI / Character Device (raw IO)



## WRITE (MB/s)



OSL Gesellschaft für offene Systemlösungen mbH

[www.osl.eu](http://www.osl.eu)

# Performance (nicht ganz) in der Praxis

## Performance bei Cache-Reads -> der Netzwerkprotokoll-Test



### Server-Performance bei Cache Read / 8k

<i>iSCSI</i>	<i>10 Clients</i>	<i>100 Threads</i>	<i>7,6 Cores</i>	<b><i>31.000 IOPS</i></b>
<i>iSCSI*</i>	<i>10 Clients</i>	<i>100 Threads</i>	<i>10,0 Cores</i>	<b><i>85.000 IOPS</i></b>
<i>RSIO</i>	<i>4 Clients</i>	<i>64 Threads</i>	<i>5,6 Cores</i>	<b><i>98.000 IOPS</i></b>
<i>RSIO</i>	<i>4 Clients</i>	<i>128 Threads</i>	<i>6,3 Cores</i>	<b><i>102.000 IOPS</i></b>

### Client-Performance Throughput

<i>RSIO</i>	<i>1 x 1 GBit</i>	<i>&lt; 0,5 Cores</i>	<b><i>&gt; 110 MByte/s</i></b>
<i>RSIO</i>	<i>2 x 1 GBit</i>	<i>&lt; 1,0 Cores</i>	<b><i>&gt; 220 MByte/s</i></b>
<i>RSIO</i>	<i>4 x 1 GBit</i>	<i>&lt; 2,0 Cores</i>	<b><i>&gt; 440 MByte/s</i></b>



- *exzellente Performance*
  - *keine Spezialsettings für TCP/IP -> Performance “out of the Box”*
  - *bis jetzt TCP, UDP möglich*
  - *prinzipielle Eignung für beliebige Medien*
  - *noch diverse Verbesserungsmöglichkeiten*
- *gewaltige Gestaltungs-, Entwicklungs- und Tuningmöglichkeiten*
- *extrem schlankes Kernelmodul*
- *komplett virtualisierter Speicher darstellbar, Handling wird vom Client aus möglich sein*
- *eingebaute Einfachheit (TCP/IP-Handling, Trunking ...)*
- *vielfältige Nutzungsmöglichkeiten / unglaublich viele Szenarien darstellbar*

***Wir hoffen auf Ihre Vorschläge und Ideen!***




# ***Einsatzszenarien***

OSL Gesellschaft für offene Systemlösungen mbH  
**[www.osl.eu](http://www.osl.eu)**


# Was kann ich prinzipiell damit tun?

## SAN-LAN-Konvergenz




# Was kann ich prinzipiell damit tun?

## SAN-LAN-Konvergenz





# Was wird mit der Hochverfügbarkeit ?

Auch hier: SAN-LAN-Konvergenz




# Was kann ich noch anstellen?

## SAN-LAN-Konvergenz




*Flexibilität bei Umrüstungen gewinnen*



Anwender


# Und auch das geht: Collapsed SAN = gar kein FC-SAN



*ganz auf FC-SAN  
verzichten,  
nicht aber auf  
Funktionalität  
und Performance*

# Passend zu Virtuellen Maschinen

Drastische Vereinfachung der Storage-Anbindung für virtuelle Maschinen




OSL Gesellschaft für offene Systemlösungen mbH

[www.osl.eu](http://www.osl.eu)

# Passend zu Virtuellen Maschinen

Drastische Vereinfachung der Storage-Anbindung für virtuelle Maschinen



OSL Gesellschaft für offene Systemlösungen mbH

[www.osl.eu](http://www.osl.eu)





# *Ausblick*

OSL Gesellschaft für offene Systemlösungen mbH  
[www.osl.eu](http://www.osl.eu)

# Wie wird es weitergehen?

Aufbruch in neue Welten ...



OSL Gesellschaft für offene Systemlösungen mbH

[www.osl.eu](http://www.osl.eu)

***RSIO ist noch immer in einer sehr frühen Phase  
Wenn wir uns etwas wünschen dürfen:***

- *Testanwender für Solaris + Linux*
- *Feedback und Anregungen*
- *die Möglichkeit, noch vor der Pilotierung Praxiserfahrungen im Design zu berücksichtigen*
- *Vorlauf in der Planung größerer Projekte*

***Bitte unterstützen Sie uns und gestalten Sie Ihre Lösung mit !***

# Zusammenfassung zu RSIO



- *Storage-Anbindung via LAN implementiert*
- *skalierbar und hochverfügbar*
- *respektable Performance*
- *einfach in der Handhabung*
- *unschlagbar niedrige Kosten*
- *enge Verknüpfung mit Clusterdiensten möglich*
- *ermöglicht virtuellen Storage, virtuelle Ablaufumgebungen und am Ende applikationsbezogenes Management vom Netzwerk-Client aus*
- *geeignet für Virtuelle Maschinen*
- *OSL Storage Cluster erschließt neue Systemplattformen*
- *noch riesiges Entwicklungspotential*



# OSL RSIO

Remote Storage I/O

Storage-Networking der nächsten Generation

## Besuchen Sie uns noch 2010:

Sun Breakfast	Berlin	25. Juni
OSL Technologietage	Berlin	15./16. September
SNW Europe	Frankfurt/M.	26./27. Oktober
iX Solaris Day	Stuttgart	30.9. - 1.10.