



Diskless Cluster und Lustre – Erfahrungsbericht zum CHiC

Frank Mietke, Torsten Hoefler, Torsten Mehlan
und Wolfgang Rehm

Fakultätsrechen- und Informationszentrum (FRIZ) /
Professur Rechnerarchitektur
Technische Universität Chemnitz

UNIX Stammtisch 24.04.2007



Inhaltsverzeichnis

CHiC-Bericht
US 20070424

Frank Mietke

HPC in Chemnitz

CHiC – Projekt

Clusterarchitektur

Software-
Umgebung

Und nun?

- 1 HPC in Chemnitz
- 2 CHiC – Projekt
- 3 Clusterarchitektur
- 4 Software-Umgebung
- 5 Und nun?



Hochleistungsrechnen

CHiC-Bericht
US 20070424

Frank Mietke

HPC in Chemnitz

CHiC – Projekt

Clusterarchitektur

Software-
Umgebung

Und nun?

- Zusammenlegen von:
 - Prozessorleistung
 - Hauptspeicherkapazität
- High Performance Computing (HPC)
- High Throughput Computing (HTC)
- Anwendungen: Simulation und Datenverarbeitung
- Top500 Liste (öffentlich)



- Chemnitzer **L**inux **C**luster – CLiC (2000)

- Chemnitzer **H**ochleistungs **L**inux **C**luster – CHiC (2007)

221,6 GFlop/s



8,21 TFlop/s





CHiC-Bericht
US 20070424

Frank Mietke

HPC in Chemnitz

CHiC – Projekt

Clusterarchitektur

Software-
Umgebung

Und nun?

- Mainstream Cluster
- Cutting-Edge Cluster
- Bleeding-Edge Cluster
- Vision

HPC ist Testfeld für neue Technologien



Projektstart

CHiC-Bericht
US 20070424

Frank Mietke

HPC in Chemnitz

CHiC – Projekt

Clusterarchitektur

Software-
Umgebung

Und nun?

- Erste Gespräche Mitte 2003
- CHiC-Konsortium (24 Professuren)
- HBFVG Antrag April 2004
- Antragssumme 2,64 Mio Euro
- Genehmigung, Ausschreibung und Aufbau 2006



Ziele des Projektes

CHiC-Bericht
US 20070424

Frank Mietke

HPC in Chemnitz

CHiC – Projekt

Clusterarchitektur

Software-
Umgebung

Und nun?

- Mindestens 1000 Prozessoren
- Hochgeschwindigkeitsnetzwerk
- Eigenbau/-design
- Open Source Software
- Verbesserung der Stabilität des Systems (Festplatte, Netzteil, Hauptspeicher)
- „Geringer“ Leistungsverbrauch (< 200KW)



Bauprojekt

CHiC-Bericht
US 20070424

Frank Mietke

HPC in Chemnitz

CHiC – Projekt

Clusterarchitektur

Software-
Umgebung

Und nun?

- Begrenzte Kühlleistung im Serverraum
(→ wassergekühlte Schränke)
- Tragkraftproblematik
- Raumrekonstruktion ca. 1,7 Mio Euro

Raumaufbau





Clusteraufbau

CHiC-Bericht
US 20070424

Frank Mietke

HPC in Chemnitz

CHiC – Projekt

Clusterarchitektur

Software-
Umgebung

Und nun?



- 1 Monat Aufbauzeit
- 21,6 Tonnen Material (Schränke + Inhalt)
- 4200 Muttern und 4600 Schrauben notwendig
- 4900 Kabel mit 9800 Steckverbindern (8km Länge)
- 300 Manntage Aufwand



Clusterarchitektur

CHiC-Bericht
US 20070424

Frank Mietke

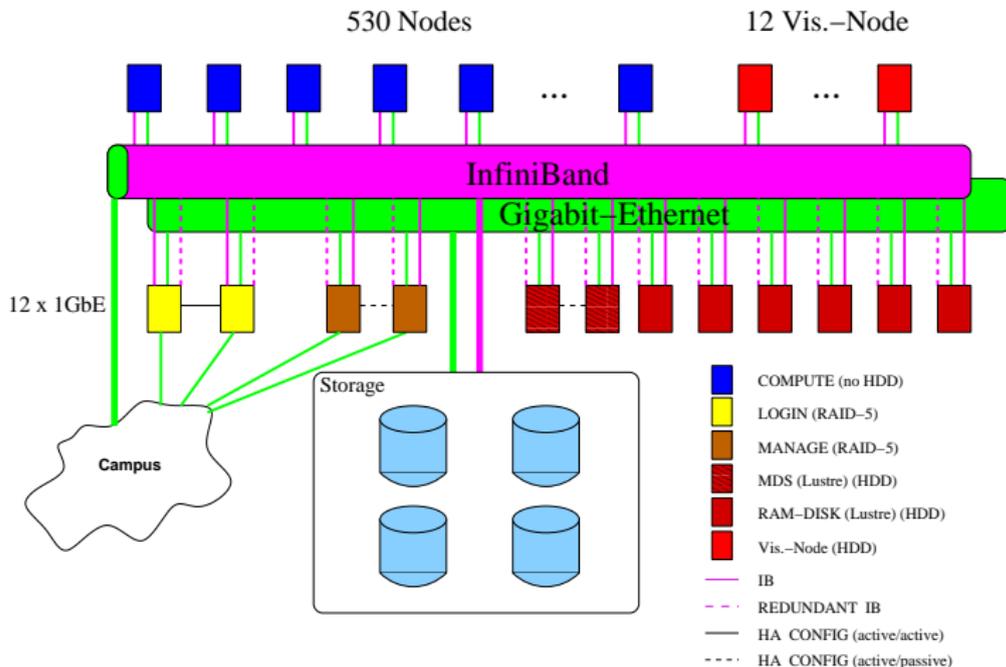
HPC in Chemnitz

CHiC – Projekt

Clusterarchitektur

Software-
Umgebung

Und nun?





Cluster Hardware

CHiC-Bericht
US 20070424

Frank Mietke

HPC in Chemnitz

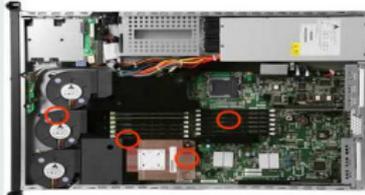
CHiC – Projekt

Clusterarchitektur

Software-
Umgebung

Und nun?

- IBM Server Technologie
- AMD Opteron Dual Core Rev. F
- Voltaire InfiniBand 10Gbit/s
- 288-Port IB-Switche
- NVIDIA Quadro FX 4500 X2





Cluster HW – Erfahrungen

CHiC-Bericht
US 20070424

Frank Mietke

HPC in Chemnitz

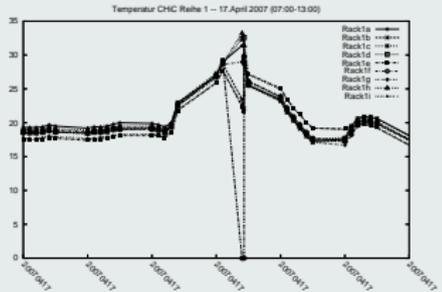
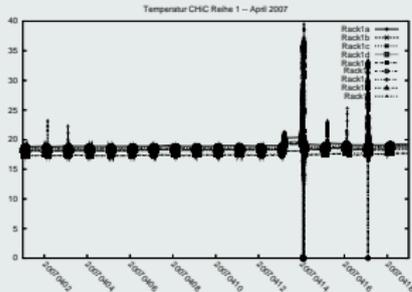
CHiC – Projekt

Clusterarchitektur

Software-
Umgebung

Und nun?

- 5 Netzwerke (IPMI und PXE, IPMI und APC)
- Sehr stabile Knoten- und Infrastrukturtechnik
- Probleme IPoIB HA (ARP)
- InfiniBand-Ethernet Gateway (HW-Probleme)
- **Aber:** kompetenter Support





Storagearchitektur

CHiC-Bericht
US 20070424

Frank Mietke

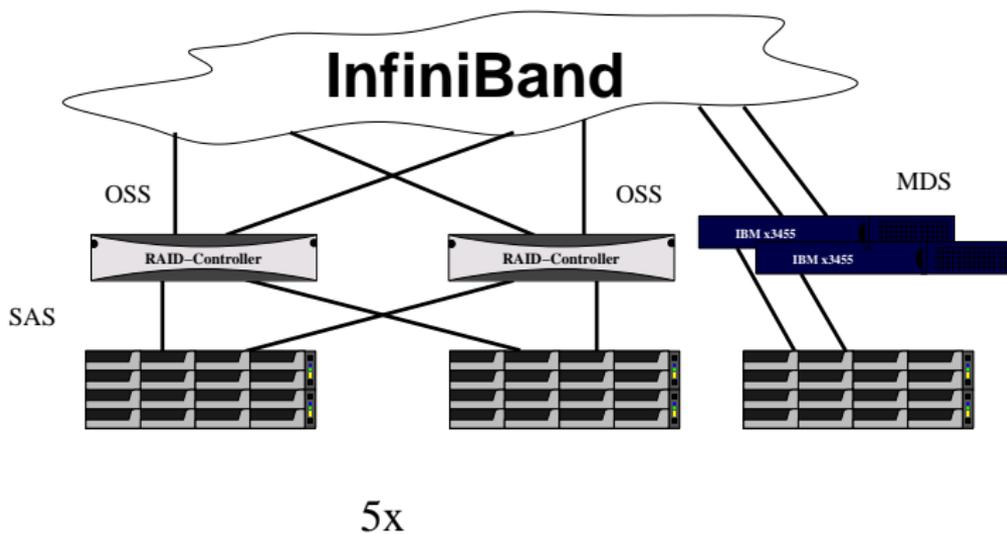
HPC in Chemnitz

CHiC – Projekt

Clusterarchitektur

Software-
Umgebung

Und nun?





Storage Hardware

CHiC-Bericht
US 20070424

Frank Mietke

HPC in Chemnitz

CHiC – Projekt

Clusterarchitektur

Software-
Umgebung

Und nun?



- 160x SATA (OSS)
- 16x SAS (MDS)
- 3,5GB/s (write)
- 1,7GB/s (read)
- RAID-5



Erfahrungen Storage Komplex

CHiC-Bericht
US 20070424

Frank Mietke

HPC in Chemnitz

CHiC – Projekt

Clusterarchitektur

Software-
Umgebung

Und nun?

- Leistungsfähige und stabile Hardware
- Lustre-Setup in 20 Minuten
- MDS/OSS HA funktioniert
- Fehlende RAID-6 Unterstützung
- Performancewerte Lesen moderat



- Scientific Linux 4.4
- Open Fabcris Enterprise Ed. 1.1
- Lustre 1.6 Beta 7
- Open MPI und MVAPICH
- GNU Compiler, EKOPath Compiler
- LoadLeveler Batchsystem



Modules Werkzeug

CHiC-Bericht
US 20070424

Frank Mietke

HPC in Chemnitz

CHiC – Projekt

Clusterarchitektur

Software-
Umgebung

Und nun?

- Besseres Handling mit Umgebungsvariablen
- Einfache Handhabung / Erstellung von Modulen

```
$ module avail
```

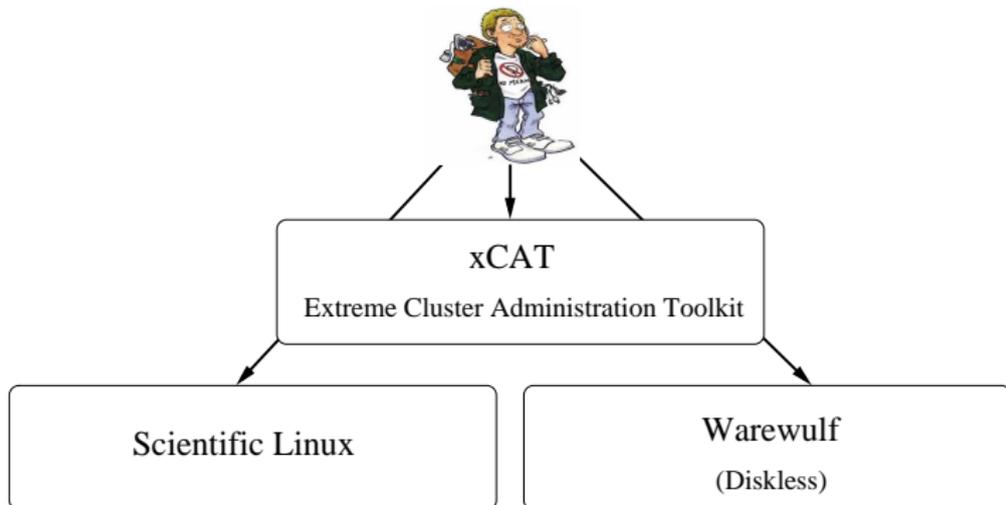
```
$ module show <modulename>
```

```
$ module load/unload <modulename>
```

```
$ module initadd/initrm <modulename>
```



- xCAT (www.xcat.org)
- Warewulf (www.warewulf-cluster.org)
- Scriptsammlungen/Konfigurationsdateien
- schlechte Dokumentation





Schritte zur Inbetriebnahme (xCAT) – 1/3

CHiC-Bericht
US 20070424

Frank Mietke

HPC in Chemnitz

CHiC – Projekt

Clusterarchitektur

Software-
Umgebung

Und nun?

- 1 Definition des Clusters:
 - Knotennamen, Netzwerke usw.
 - 20+ Konfigurationsdateien
 - XX angepasste Scripte
- 2 Konfiguration der Switchtechnik:
 - Ethernet
 - InfiniBand (Switch + Gateway)
 - Terminal Server
 - Global Console Server
- 3 Sammeln der MAC-Adressen (Ser.Cons. oder Switch):
 - `$getmacs <noderange>`
 - `$makedhcp -allmac`



Schritte zur Inbetriebnahme (xCAT) – 2/3

CHiC-Bericht
US 20070424

Frank Mietke

HPC in Chemnitz

CHiC – Projekt

Clusterarchitektur

Software-
Umgebung

Und nun?

- 1 Installations- und Imagetemplates:
 - SL-4.4
 - Warewulf
- 2 BIOS/FW Update 500+Knoten (IPMI)
- 3 Warewulf Knotenimage (Größe)
- 4 Serverskalierung (Dienste)
 - Offene TCP-Verbindungen
- 5 Synchronisierung der Knoten



Schritte zur Inbetriebnahme (xCAT) – 3/3

CHiC-Bericht
US 20070424

Frank Mietke

HPC in Chemnitz

CHiC – Projekt

Clusterarchitektur

Software-
Umgebung

Und nun?

- 1 Paralleles Dateisystem (Lustre)
 - Aufsetzen der RAIDs
 - Konfiguration des Metadatenserver (RAID-10 + Aktiv-Passiv HA)
 - Konfiguration der Object Storage Server (RAID-5 + Aktiv-Aktiv HA)

- 2 Software:
 - Compiler
 - MPis
 - Mathe-Bibliotheken
 - kommerzielle Nutzer-Software



Fehler sind die Regel!

- Nagios (Client/Server)
- Zugriff über SSH/IPMI/Ser.Console/APC
- Auftretende Lastspitzen im Managementknoten
- Kommunikationsaufkommen beachten



Debugging und Profiling

CHiC-Bericht
US 20070424

Frank Mietke

HPC in Chemnitz

CHiC – Projekt

Clusterarchitektur

Software-
Umgebung

Und nun?

- Spezielle Übersetzungen von MVAPICH1/2 und Open MPI
- mpirun mit Debugger (gdb,ddd)
- valgrind mit MPI Unterstützung
- Prozessor Performance Counter (PAPI)
- mpiP, gprof, Frysk usw.
- PathOpt2



Higher Performance Cluster

CHiC-Bericht
US 20070424

Frank Mietke

HPC in Chemnitz

CHiC – Projekt

Clusterarchitektur

Software-
Umgebung

Und nun?



- 12+ TFlops (einfache Genauigkeit)
- www.gpgpu.org



InfiniBand Projekte

CHiC-Bericht
US 20070424

Frank Mietke

HPC in Chemnitz

CHiC – Projekt

Clusterarchitektur

Software-
Umgebung

Und nun?

- MPICH2 InfiniBand Device (CH3)
- MySQL InfiniBand Transporter
- Switchfreie InfiniBand Topologien
- Opteron-Cell Hybride und InfiniBand
- HSM über InfiniBand (RAM -> SATA)



Danke für Ihre Aufmerksamkeit

??Clusterführung??