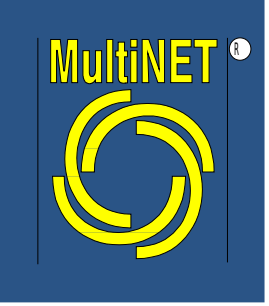


MultiNET Services GmbH

# Linux-HA Version 2

## GUUG München, 14.7.2008

Dr. Michael Schwartzkopff, MultiNET Services GmbH

# Inhalt

- Hochverfügbarkeit allgemein
- Grundlagen und Architektur von Clustern
- Ressourcen und Bedingungen
- Administration: GUI und Kommandozeile
- Betrieb

# Hardlink

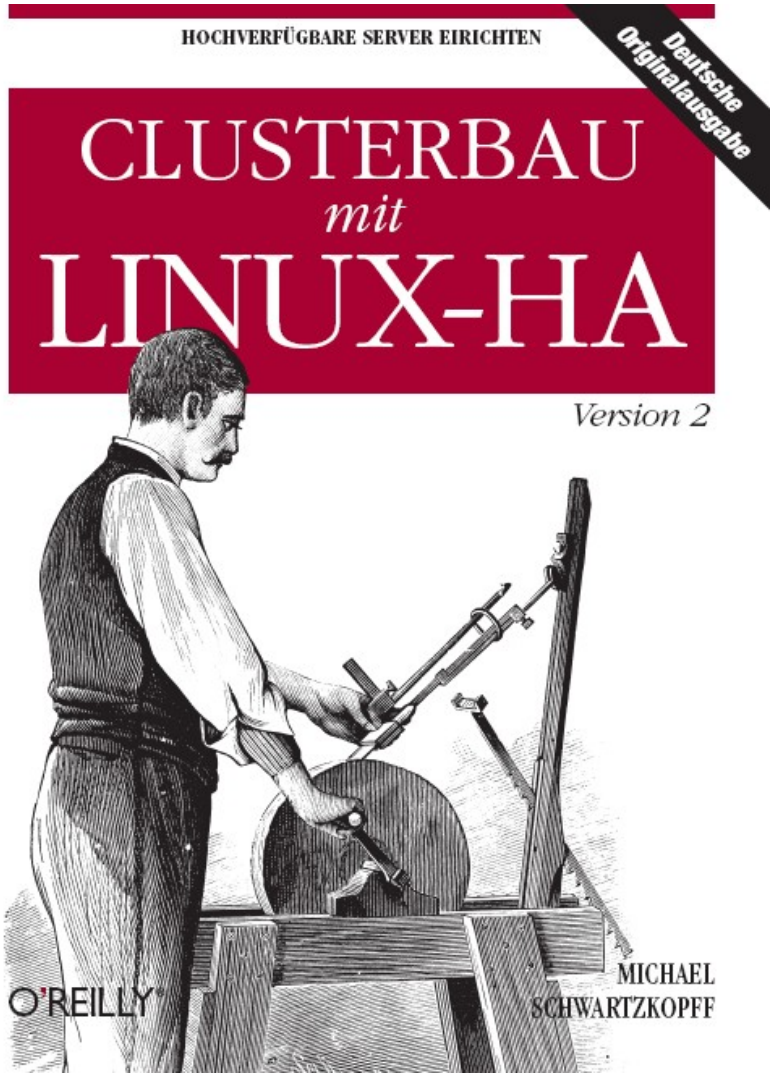


- misch@multinet.de
- Linux-HA Mailingliste

# Was ist Hochverfügbarkeit?

*„Die IT soll Dienste immer anbieten.“*

- Was sind „Dienste“?
- Was bedeutet „immer“?

# Was bedeutet „immer“?

- 7 x 24 ist Standard, also 365,2425 Tage/Jahr.
- Tatsächlich wird diese Verfügbarkeit nur annähernd erreicht. Der Grad wird in Prozent oder Anzahl „9“ angegeben.
- 100% Verfügbarkeit gibt es nicht.
- Beispiele
  - 99% ~ 7,2 h / Monat Ausfall
  - 99,999% ~ 5,26 Min / Jahr (!)

# Redundanz unter Linux

- Linux-HA (Heartbeat)
  - Ein Ersatzserver übernimmt im Fehlerfall die Aufgabe des primären Servers
  - Dies beinhaltet die Übername von IP Adressen, uvm.
  - Lastverteilung: Im Prinzip nein, aber ...
  - Aktiv / Passiv – System: Zwei Rechner.
  - Alternativen: Aktiv / Aktiv: Die Ressourcen sind auf zwei Rechnern verteilt.
  - oder „n to m“ Systeme: Die Ressourcen sind auf mehreren Rechnern verteilt.

# Was leistet Linux HA?

- Keine 100%ige Verfügbarkeit!
- Cluster schützen vor *einzelnen* Fehlern, nicht vor *mehreren gleichzeitigen* Fehlern.
- Auszeiten werden kurz: Sekunden bis Minuten
  - Wie beim Zaubern: „Wenn alles gut geht, war die Hand schneller als das Auge“
- Üblicherweise kann man eine „9“ an die Basisverfügbarkeit  anhängen.
- Achtung: Komplexität ist der Feind der Zuverlässigkeit!

# Linux – HA Prinzip I

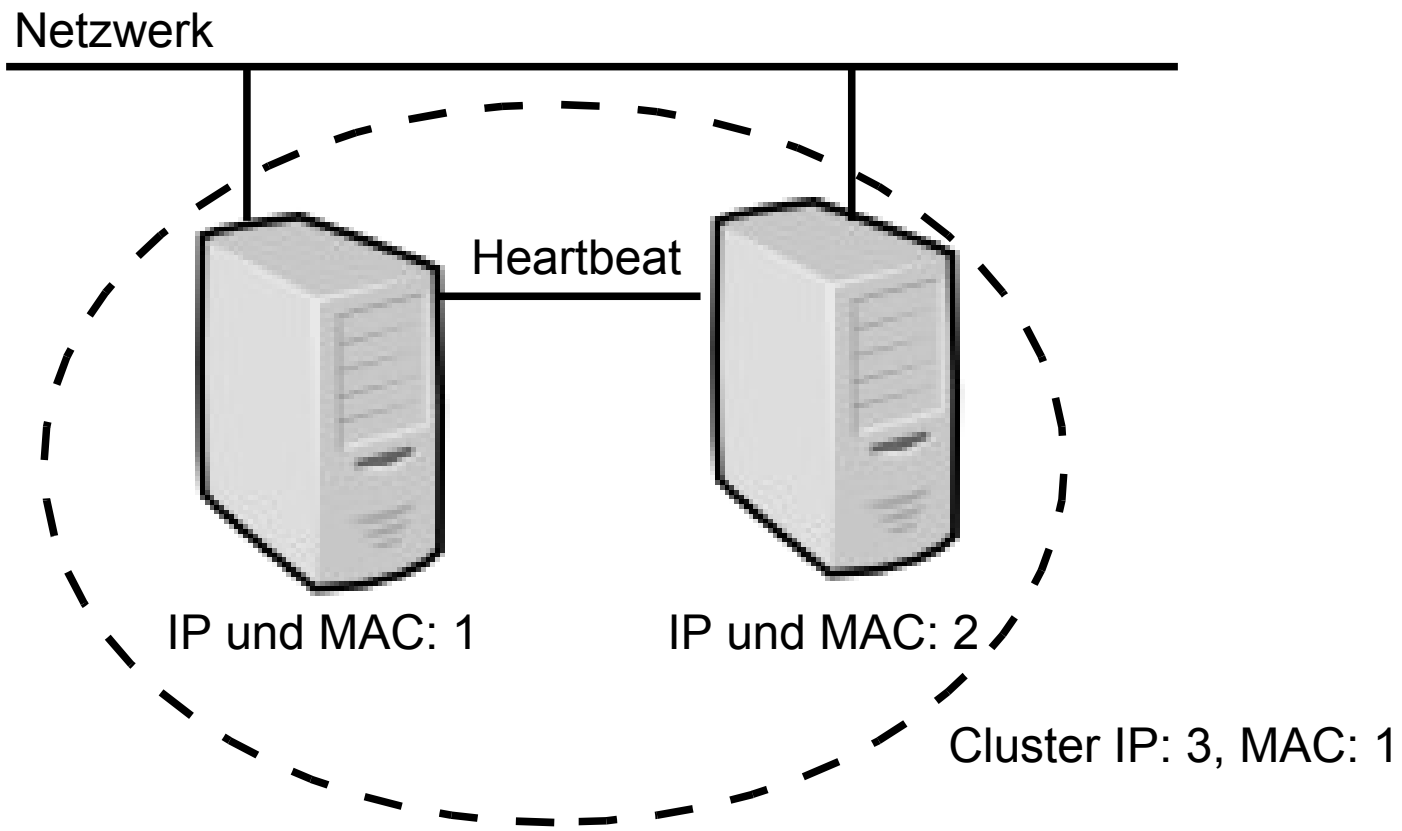

# Linux – HA Prinzip I

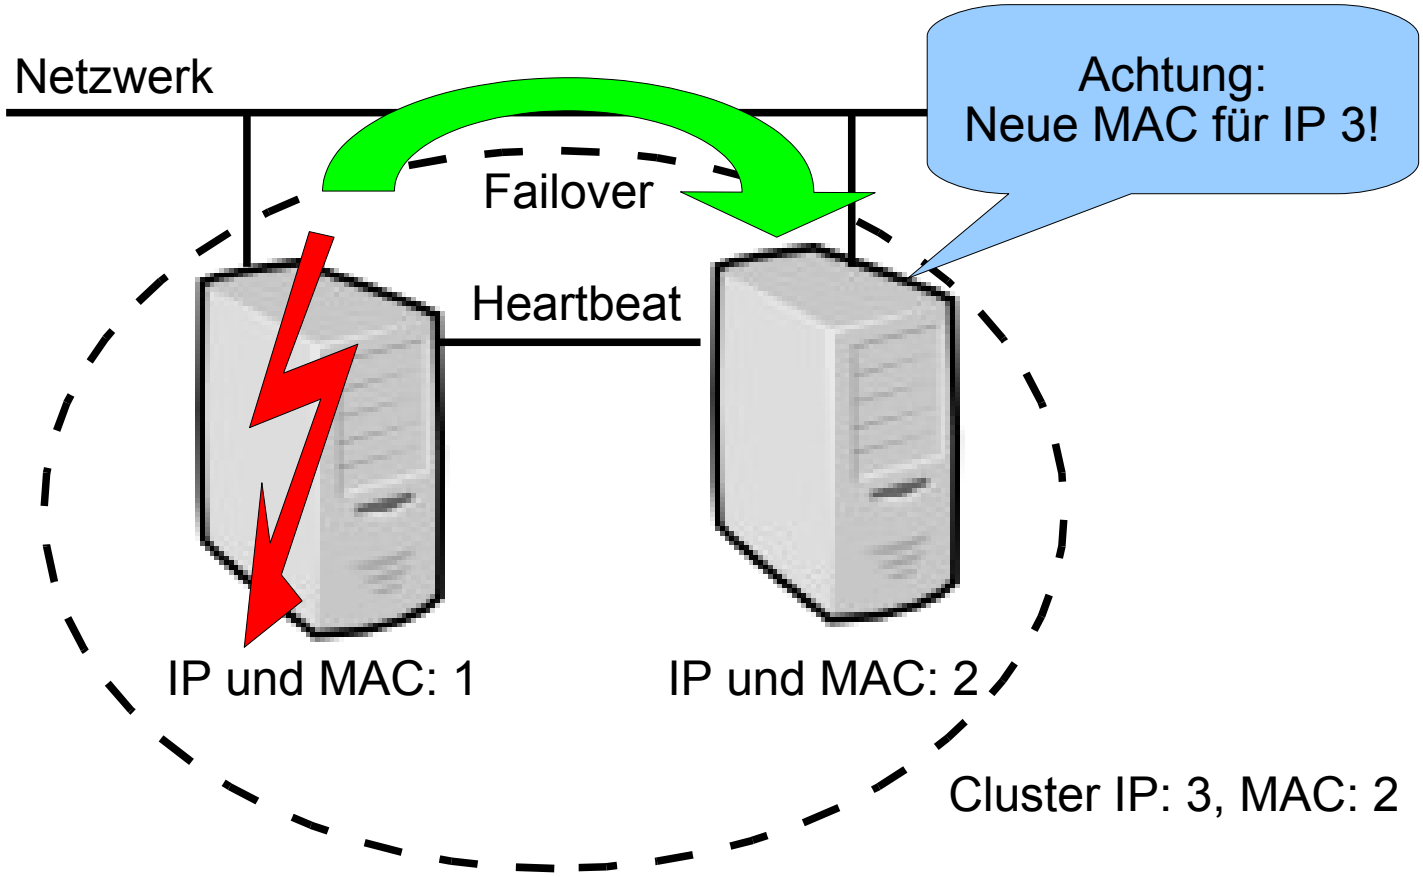

# Bekanntes ...

- Funktioniert so ähnlich wie die bekannten init startup Scripte
- Erweiterungen
  - Übergabe von Parametern an das Script (optional)
  - Läuft auf mehr als einem Computer
  - Regeln für
    - Reihenfolge für Start / Stop von Diensten
    - Beziehungen von Dienste untereinander
    - zeitliche Begrenzungen für Dienste
- HA Systeme sind ein bisschen wie „init on steroids”

# ... und Neues

- Clusterarchitekturen haben folgende Probleme zur Folge:
  - Split – Brain
  - Quorum
  - Fencing
- Gemeinsam genutzte Daten sind bei Einzelservern kein Problem, bei Clustern ist diese Funktion kritisch.

# Split - Brain

- Probleme in der Kommunikation zwischen den Knoten eines Clusters können zu separaten Teilen des Clusters führen.
- Wenn jeder dieser Teile versucht, die Kontrolle über den Cluster zu erhalten nennt man das eine „Split-Brain“ Situation.
- GAU im Cluster, bis hin zum totalen Datenverlust.

# Quorum

- Das „Quorum“ Konzept ist ein Versuch Split – Brain Situationen in die meisten Problemfällen zu verhindern.
- Üblicherweise wird versucht sicherzustellen, dass nur einen Teilcluster die Kontrolle übernimmt.
- Übliche Methode ist die Abstimmung: Nur eine Partition mit *mehr als* N/2 Knoten des ursprünglichen Clusters kann die Kontrolle übernehmen.
- Quorum funktioniert nicht mit 2 Knoten im Cluster

# Fencing (I)

- Fencing versucht fehlerhafte Knoten vom Zugriff auf Ressourcen abzuschneiden (Speicher, Netz, Strom).
- Auf die Annahme eines korrekten Verhaltens kann verzichtet werden.
- Linux HA nutzt STONITH
  - Shoot The Other Node In The Head
  - Self-Fencing, z.B. IBM ServeRAID
- Gute deutsche Übersetzung für „Fencing“ gesucht!

# Fencing (II)

- Garantiert die Integrität des Gesamtsystems „Cluster“ in problematischen Fällen
- Da ein Teilcluster nichts über den tatsächlichen Zustand andere Teilcluster wissen kann wird mit STONITH dafür gesorgt, dass der tatsächliche Zustand den anderen Teils der Vorstellung des ersten Teils entspricht.
- Einfachste Implementation: Strom abschalten.

# Gemeinsame Daten

- Keine: In vielen Szenarien werden keine Daten zwischen den Knoten eines Clusters gemeinsam genutzt.
- Replikation: In vielen Fällen reicht eine „langsame“ Replikation der Daten z.B. mit `rsync`.
- Volle Synchronisation: Distributed Redundant Block Devices (DRBD). Ein bisschen wie RAID, nur auf zwei Rechnern.
- Outsourcen des Problems: NAS, SAN

# Linux HA: Hintergrund

- Entwicklung seit 1998
- ca. 30.000 Syteme im Einsatz
- Aktive Entwicklung durch IBM und SuSE/Novell
- In den meisten Distributionen enthalten
- Keine zusätzliche Hardware notwendig, alles Userspace, d.h. kein Kernelmodul
- Alle Releases werden durch automatische Tests überprüft.

# Linux HAv2: Fähigkeiten (I)

- Bis zu 16 Knoten im Cluster
- Clusterkommunikation: Seriell, udp (bcast, mcast, ucast). Redundanz möglich.
- Failover bei Problem des Knoten oder des Dienstes
- Failover bei Problemen im Netzwerk oder bei anderen frei definierten Kriterien
- Aktiv / Passiv oder volles Aktiv / Aktiv
- Eingebaute Überwachung der Ressourcen

# Linux HAv2: Fähigkeiten (II)

- Unterstützung des Open Cluster Framework (OCF) Standards.
- Modell für Bedingungen und Abhängigkeiten
- Konfiguration basiert auf XML
- GUI zur Konfiguration und Überwachung
- Unterstützung für das OCFSv2
- Multi-State (Master/Slave) Ressourcen
- Split-Site Cluster mit Quorum

# Installation

- Bei vielen Distribution ist `heartbeart` enthalten
- SuSE Build Service:

  `http://download.opensuse.org/repositories/server:/ha-clustering/`

  – Pakete für debian, Fedora, Mandriva, SLES, openSUSE, Ubuntu
  – z. Zt. 2.1.3-18
- Aktuelle Version (>= 2.1.3) wichtig!
- SLES Dokumentation auf:

  `http://www.novell.com/documentation/sles10/heartbeat/data/heartbeat.html`

# Neu: Pacemaker

- Aufspaltung des Projekts im Dezember 2007
- Hintergründe dazu: Mailingliste und *http://www.clusterlabs.org/#Project_History*
- Installation siehe: *http://www.clusterlabs.org/mw/Install*
- Änderungen: Cluster Resource Manager (CRM) wird ersetzt durch `pacemaker`
- Es ist einfach ein zusätzliches Paket zu installieren.

# Erste Konfiguration

- Die Dateien `ha.cf` und `authkeys` werden benötigt.
- Beispiele aus `/usr/share/doc/heartbeat` nach `/etc/ha.d` kopieren.
- Knoten und Cluster – Kommunikation in `ha.cf` einrichten.
- Signatur (Passwort) in `authkeys` einrichten.

# Der Rest der Konfiguration ...

- ... steht in der CIB
- Datei: `/var/lib/heartbeat/crm/cib.xml`
- Niemals direkt editieren!
- Beim erstem Systemstart wird automatisch eine leere CIB angelegt.
- Ausgabe der CIB: `cibadmin -Q`

# Die CIB

- Die CIB enthält:
  - Information über die Konfiguration
    - Informationen über die Knoten
    - Informationen über die Ressourcen
    - Informationen über die Bedingungen
  - Informationen über den Status des Clusters
    - Welche Knoten sind up / down?
    - Alle Attribute der Knoten
    - Welche Ressourcen laufen auf welchem Knoten
- Der Administrator gibt nur die Konfiguration ein.

# Variablen in der CIB

- An vielen Stellen der CIB werden Namen Werte zugewiesen
- Linux HA nutzt <nvpair> Tags
- Die Syntax ist:

```
<nvpair id="uuid" name="Name" value="Wert"/>
```

- In anderen Programmiersprachen heißt das:

```
Name = Wert
```

# Ressourcen: Einfache Ressourcen

- *Ressourcen* sind alles, was von heartbeat verwaltet wird.
- *Agenten* sind Verbindung zwischen heartbeat und der tatsächlichen Ressource. Vergleichbar sind die Scripte, die von init beim Systemstart aufgerufen werden. Die Abkürzung ist RA.
- Einfache Ressourcen werden als „primitive Resources“ bezeichnet
- Im Gegensatz dazu existieren noch komplexere, zusammengesetzte Ressourcen.

# Ressource Objekte

- Version 2 unterstützt folgende “Ressource Objekte”:
  - Einfache (primitive) Ressources
    - OCF, heartbeat, oder LSB resource agent Scripte
  - Klone: *“n”* Ressource Objekte irgendwo im Cluster
  - Gruppen: Eine Gruppe von einfachen Ressourcen mit impliziten Bedingungen
  - Multi-state Ressourcen (master/slave)
    - Entwickelt, um Master/Slave Ressourcen abzubilden, die dies zur Replikation benötigen (DRBD, et al)

# OCF Ressource Agenten

- OCF: Open Cluster Framework
- OCF RAs sind erweiterte init Scripte
  - Sie können mittels Umgebungsvariablen gesteuert werden
  - Sie haben zusätzliche Aktionen:
    - monitor: Überwachung der Ressource
    - meta-data: Liefert Informationen über den RA. Wird in der GUI genutzt.
    - validate-all: Überprüfung der Parameter der Ressource
  - OCF RAs finden sich in **`/usr/lib/ocf/resource.d/`*`provider-name`*`/`**
- Siehe auch **`http://linux-ha.org/OCFResourceAgent`**

# Einfache Bedingungen

- Es gibt keine Vorgaben, wo welche Ressourcen laufen sollen.
- Falls der Administrator das nicht wünscht, können Bedingungen für Ressourcen definiert werden:
  - Anordnung: Eine Ressource wird nach einer anderen gestartet
  - Co-Lokation: Eine Ressourcen läuft auf dem selben Knoten, wie eine Andere.
  - Platzierung: Eine Ressource soll auf einem bestimmten Knoten laufen.

# Punktesystem

- Der Administrator vergibt Punkte für erfüllte Bedingungen. (Co-Lokation, ...(!))
- `heartbeat` wertet diese Bedingungen im Kontext jedes Knotens aus und die zählt entsprechenden Punkte pro Ressource und pro Knoten.
- Eine Ressource wird auf dem Knoten ausgeführt, wo sie am meisten Punkte sammeln kann
- Falls gleiche Punktezahl erreicht wird, verteilt `heartbeat` die Ressourcen gleichmäßig auf die Knoten.

# Bedingungen für Fortgeschrittene

- Beliebige Bedingungen können konfiguriert werden.
- Beispiele:
  - Bedingungen in Zusammenhang mit Multi-State Ressourcen.
  - Bedingungen, die sich auf Attribute von Knoten beziehen.
  - Zeitliche Begrenzungen für Bedingungen.
  - Erreichbarkeit im Netz
  - Beliebige Bedingungen
  - Failover erst nach „N“ Fehlern

# Bedienung: Die GUI

- Zur Bedienung / Konfiguration gibt es eine GUI.
- Ressourcen und Bedingungen können über die GUI konfiguriert werden.
- Die GUI hat ihre Grenzen! Diese Grenzen sind teilweise sehr schnell erreicht.
- Gut für die Überwachung. Aber: Es gibt *kein* Rollenkonzept!
- Für Firewalls: Die GUI nutzt Port tcp/5560.
- Ideal sind identische Versionen von GUI und heartbeat.
- Aufrufen mit `hb_gui`.

# Die GUI

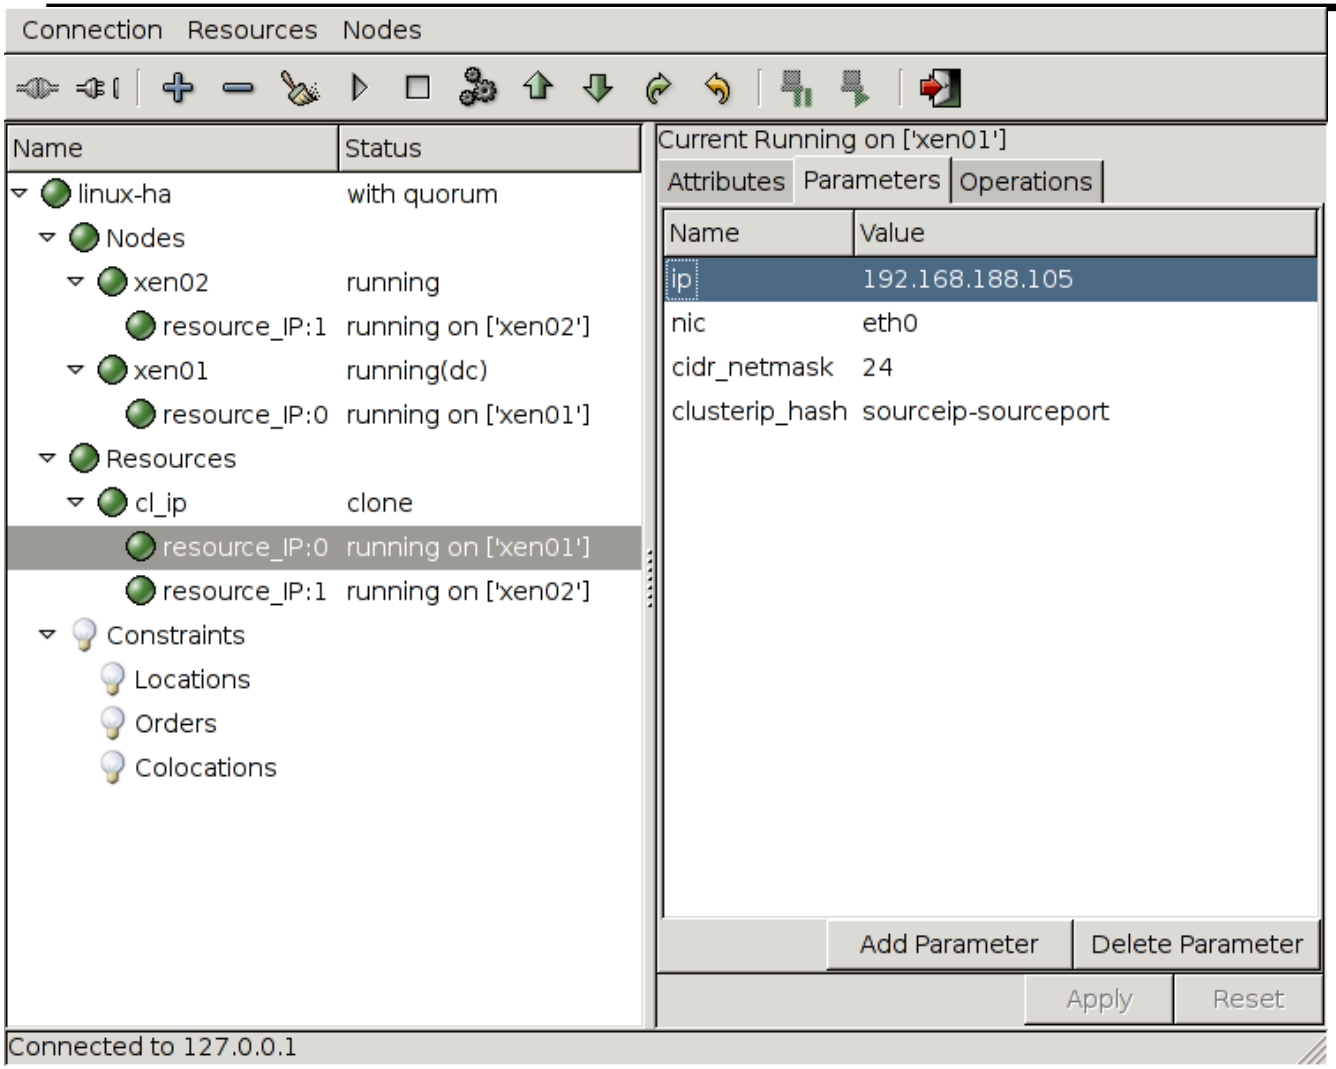
Connection Resources Nodes
Name Status
linux-ha with quorum
Nodes
xen02 running
resource_IP:1 running on ['xen02']
xen01 running(dc)
resource_IP:0 running on ['xen01']
Resources
cl_ip clone
resource_IP:0 running on ['xen01']
resource_IP:1 running on ['xen02']
Constraints
Locations
Orders
Colocations
Current Running on ['xen01']
Attributes Parameters Operations
Name Value
ip 192.168.188.105
nic eth0
cidr_netmask 24
clusterip_hash sourceip-sourceport
Add Parameter Delete Parameter
Apply Reset
Connected to 127.0.0.1

# Die Kommandozeile

- Die wichtigsten Kommandos:
  - `crm_mon`: Status des Clusters
  - `cibadmin`: Schnittstelle zur CIB
  - `crm_resource`: Schnittstelle zum CRM
  - `crm_failcount`: Schnittstelle zum Fehlerzähler
  - `ocf-tester`: Testet eine ocf Ressource
  - `crm_verify`: Überprüft die CIB auf Probleme
  - `stonith`: STONITH Kommando

# Warum Version 2?

- Einfache Konfigurationen, entsprechend Version 1, sind möglich.
- Schwierige Konfigurationen ebenfalls.
- Interne Überwachung der Ressourcen durch den Cluster.
- Dynamische Modifikation am Cluster während der Laufzeit.

# Überwachung eines Clusters

- Externe Überwachung notwendig.
- Netzwerk Management nutzen (oder aufbauen)!
- Simple Network Management Protocol (SNMP) ist der Klassiker.
- Linux HA bringt einen eigenen Subagenten mit.

# MIB von Linux-HA

```
LINUX-HA-MIB::LHATotalNodeCount.0 = Counter32: 2
LINUX-HA-MIB::LHALiveNodeCount.0 = Counter32: 2
(...)
LINUX-HA-MIB::LHANodeName.1 = STRING: xen02
LINUX-HA-MIB::LHANodeName.2 = STRING: xen01
LINUX-HA-MIB::LHANodeType.1 = INTEGER: normal(1)
LINUX-HA-MIB::LHANodeType.2 = INTEGER: normal(1)
LINUX-HA-MIB::LHANodeStatus.1 = INTEGER: active(3)
LINUX-HA-MIB::LHANodeStatus.2 = INTEGER: active(3)
(...)
LINUX-HA-MIB::LHANodeIFCount.1 = Counter32: 1
LINUX-HA-MIB::LHANodeIFCount.2 = Counter32: 1
LINUX-HA-MIB::LHAIFName.1.1 = STRING: eth0
LINUX-HA-MIB::LHAIFName.2.1 = STRING: eth0
LINUX-HA-MIB::LHAIFStatus.1.1 = INTEGER: up(1)
LINUX-HA-MIB::LHAIFStatus.2.1 = INTEGER: up(1)
(...)
```

# Traps von heartbeat

## Wichtige Traps von `hbagent`:

```
LHANodeStatusUpdate NOTIFICATION-TYPE
    OBJECTS { LHANodeName LHANodeStatus }
    DESCRIPTION "A node status change event just happened."

LHAIFStatusUpdate NOTIFICATION-TYPE
    OBJECTS { LHANodeName LHAIFName LHAIFStatus }
    DESCRIPTION "A link status just changed."

LHAMembershipChange NOTIFICATION-TYPE
    OBJECTS { LHANodeName LHAMemberLastChange }
    DESCRIPTION "A node just changed it membership. "
```

# Überwachung durch `nagios`

- Abfrage von `LHALiveNodeCount` und Vergleich mit der Anzahl der Knoten im Cluster
- Definition eines neuen Kommandos in *`checkcommands.conf`*:

```
define command {
    command_name check_snmp_cluster
    command_line $USER1$/check_snmp \
       -H $HOSTADDRESS$ \
       -o .1.3.6.1.4.1.4682.1.2.0 \
       -w 2: -c 2:
}
```

wenn der Cluster aus 2 Knoten besteht.

Vielen Dank für die Aufmerksamkeit!

Rückfragen jederzeit:

- *misch@multinet.de*
- Tipps und Tricks: *http://clusterbau.blogspot.com*
- Praxis – Seminar bei Heinlein-Support