Alternative zum ASCC auf GPL-Basis

-

UNIX-Stammtisch Dresden 01.11.2006

Josef Müller IT Dienstleistungen Stadtverwaltung Dresden JMueller@Dresden.de Tel: 0351 488 2112

Zustandsbeschreibung

- Anlass: Die Linux Internet Präsentation der Stadt Dresden ist unsicher bei Hardwareproblemen
- Ziel:
  - ausfallsicheres System durch Überwachung der Hardware und Software
  - standardisierte Software für alle Linux-Verfahren
  - Senkung des Administrations Aufwands für die Pflege
  - zentrale Steuerung aller Linux Systeme
- Lösung – Ausschreibung mit vier möglichen Lösungen als Ergebnis:
  - (1) Wir stellen Ihnen unsere Hardware zur Verfügung mit FC-HW. Unsere Stunde kostet: ...
  - (2) VMWARE-Lösung mit FC-HW
  - (3) FC-HW Lösung, bei sich
    - die SW selbst überwacht
    - auf jedem Server jeder Dienst mit läuft (auch bei DB)
  - (4) ASCC
- Entscheidung: ASCC
  - NFS als File Server – läuft immer und ist nicht zu teuer
  - zentrale Überwachung und Steuerung möglich; zentrale Systempflege
  - Load Balancing

Struktur

- Netz Filer (FAS 250)
  - NFS (nur am internen, privaten Netz)
    - Betriebssystem Images der Applikation Nodes
    - sonstige Daten Resourcen
  - Sicherung über FC (nach Austausch FAS250 durch FAS270)
- 2 Control Nodes
  - eigenes Betriebssystem
  - gegenseitiges Überwachen
  - Steuerung des Gesamtsystems
  - internes und externes Netz
  - steuern das Netz Boot der Applikation Nodes
- Applikation Nodes
  - internes und externes Netz
  - Netz Boot
  - Entwicklungsumgebung (manueller Modus) und Applikations Umgebung (online Modus)
- Struktur des ASCC
  - File-Server
  - Applikations-Knoten ohne eigens System
  - Steuer-Server (gegenseitige Überwachung)

Realitäten

- Eine-Person-Bedienoberfläche für ein Multi-User-System
  - nur Test einer Konfiguration auf einem Node zu einem Zeitpunkt möglich
  - Oberfläche reagiert stark Zeitversetzt auf Benutzerinteraktionen
- offensichtliche Schwächen und Startprobleme
  - keine doppelte Anbindung an das Hausnetz (wurde beseitigt)
  - Netz-Filer nur einfach eingebunden (wurde beseitigt)
  - Ausfall des Gesamtsystems noch möglich:
    - Ausfall des Rahmens, in dem die Knoten untergebracht sind
    - Ausfall des Netz Filers
      Daran wird gearbeitet; es sollte ein zweites ASCC daneben stehen können, auf das die Daten gespiegelt werden und das im Notfall die Arbeit übernimmt.
    - Die Sicherung des Netz Filers ist noch nicht realisiert! (Lösung ist auch mit TSM über FC möglich!; internes Problem)
- Clon-Technologie
  - Erzeugen eines Images dauert 6 bis 24 Minuten (auch mit NDMP-Copy)
  - Verlust der Protokolle
- Jede Änderung einer Applikation macht ein 'Take-Image' + 'Deploy Image' für alle Nodes nötig (weil die Konfiguration im Image gespeichert wird).
- es mangelt an Bedienkomfort: Kopieren von Teilen der Konfiguration oder Löschen (Beispielsweise NFS Ressource) geht nicht!

Wie würde ich das ASCC neu bauen?

- Die Lösung ist nicht akzeptable! Darum wird eine eigene Lösung angestrebt!
- File Server:
  - Linux – Shares auf LVM aufbauen
  - doppelt halten mit 'Heartbeat' und 'DRDB' (Siehe Linux-Magazin 2004/07)
  - sollte neben NFS auch tftp und pxelinux beinhalten
  - Bereitstellen der System Platten für alle Knoten: Knoppix Prinzip mit Union-FS (Siehe Linux-Magazin 2006/03)
- Steuer-Server:
  - ohne System Platten wie die restlichen Knoten (außer /tmp und swap)
  - Steuerung: Apache + Perl
  - Bedienoberfläche: einfacher Browser (ohne Java + Java Script)
  - doppelt halten: siehe File Server
- Applikation Nodes:
  - ohne eigene Platten (außer /tmp und swap)
  - Load Balancing: 'pound' oder 'LVS' einsetzbar
- Realitäten:
  - es gibt bereits einen NetApp Filer, der zu nutzen ist!
  - NetApp war nicht zu PXE-BOOT zu überreden, ebensowenig zum DHCP für PXE-Boot

hacc-

- Neuaufbau mit frei Software (außer NetApp) unter Beibehaltung der Grundstruktur:
  - Filer (zweiter Filer geplant - Ausfallsicherheit): NFS Services für:
    - Daten zum Boot der Arbeitsknoten (pxelinux,cfg, tftp-Kernel u. Initrd-Verweis)
    - Nagios Steuerdaten und Steuerscripte für die Arbeitsknoten
    - Root Partitionen
    - Union-FS Partitionen
    - Home Partition für die Arbeitsknoten und Daten-Partitionen für die Arbeitsknoten
  - Steuerknoten
    - eigenes Betriebssystem (Linux)
    - zwei Steuerknoten überwachen sich gegenseitig mit Heartbeat
    - Dienste für Boot: dhcp, tftp (atftpd) (PXE Boot Daten liegen auf NetApp Filer)
    - Überwachung und Gewährleistung der Ausfallsicherheit: Nagios
    - rinetd-Weiterleitung für Sicherung des NetApp Filers (keine Hausnetzanbindung)
    - Mail-Relais mit Postfix (Alarm des NetApp)
  - Arbeitsknoten
    - werden per PXE gebootet und per NFS und Union-FS mit Daten versorgt
    - sind austauschbar
  - Konfigurationsknoten (Einspielen von Patches in das Gesamtsystem)

hacc- Struktur

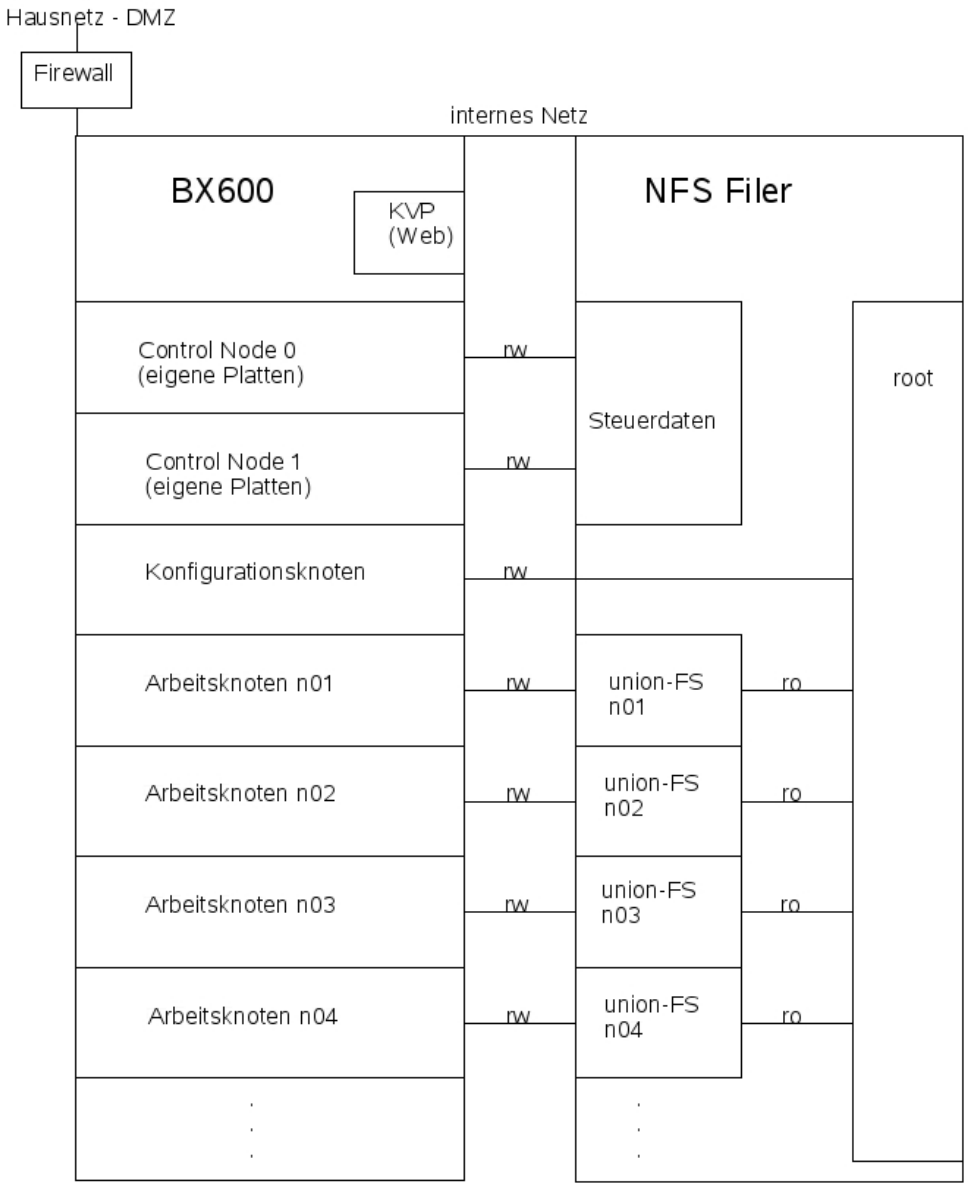

Management Blade

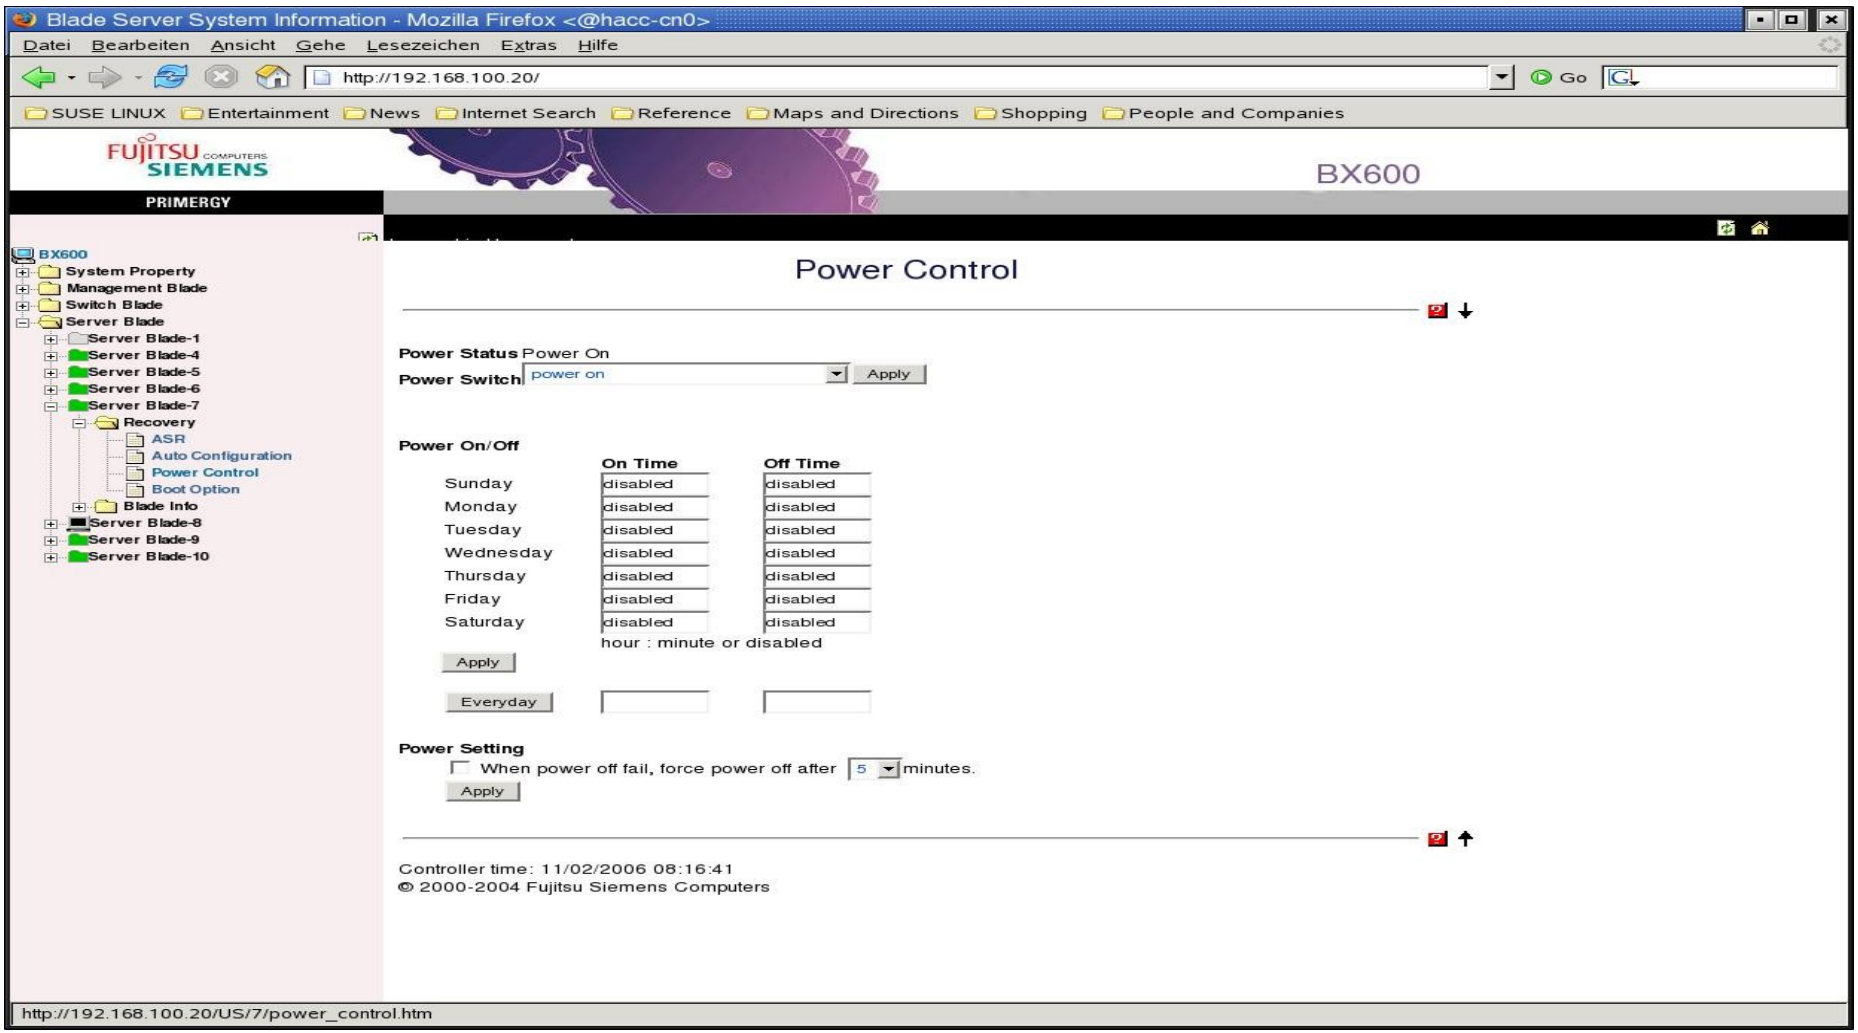

Netzanbindung - Sicherheit

- Das System arbeitet mit einem eigenen, abgeschotteten, inneren Netz (eth1)
  - Der NetApp Filer hat nur dort Zugriff
  - Die Resourcen des Filers werden nur im inneren Netz angeboten
  - Booten der Arbeitsknoten -> innere IP Adresse
  - Zugriff der Arbeitsknoten auf das Betriebssystem und auf das vorgeblendete Union-FS
  - Zugriff auf die Daten
  - Überwachung
- Über das externe Netz wird auf die Dienste und auf die Steuerrechner zugegriffen (bond0, bestehend aus eth0 und eth2):
  - IP Bonding (doppelt angebunden) -> Äußere IP Adresse
  - keine Routing zum inneren Netz
  - Überwachung der Zugriffe durch einen externen Firewall
- Ausbau:
  - Aufbau eines zweiten NetApp Filers (Aufbau NetApp Cluster)
  - Aufstellung einer zweiten BX600 und Verteilung der Steuerknoten
- Sicherheit:
  - Einzelsicherung der Steuerknoten über TSM
  - Sicherung NetApp Filer über TSM und FC

Boot

- dhcpd.conf:
  DHCPD_INTERFACE = "eth1";
  ... (PXE Optionen)
  filename "pxelinux.0";
  next-server 192.168.100.101;
  shared-network "Auto DHCP" {
  subnet 192.168.100.0 netmask 255.255.255.0 {
  group {# Server managed by NETboot
  host C0A86406 {
  hardware ethernet 00:C0:9F:99:EB:E7;
  fixed-address 192.168.100.6;
  }
  ...
- /etc/sysconfig/atftpd: ATFTPD_DIRECTORY="/data/vol_root/tftpdir" (NFS Resource)
  hacc-cn0:/data/vol_root/tftpdir # ls
  04-initrd (-> ../04/boot/initrd)
  04-vmlinuz (-> ../04/boot/vmlinuz)
  messages pxelinux.cfg pxelinux.0

PXE

- Je zu startenden Knoten gibt es in pxelinux.cfg ein File; z.B. C0A86407:
  default 04_SLES10
  label 04_SLES10
  KERNEL 04-vmlinuz
  APPEND initrd=04-initrd ip=192.168.100.7:192.168.100.100::255.255.255.0::hacc-n01P:eth1:off root=192.168.100.100:/vol/vol_root/04 acpi=off
- Der Knoten wird dadurch versorgt mit:
  - einem Root File-System: liegt in 192.168.100.100:/vol/vol_root/04
    - unter /vol/vol_root werden die verschiedenen Versionen des Betriebssystems aufbewahrt.
    - Mit jedem Patch wird eine neue Version erstellt. Hier wird der Stand 04 benutzt.
  - einer inneren IP Adresse; hier; 192.168.100.7
    - Netzwerkanbindung zum inneren Netz
    - die letzte Stelle (7) ist ein symbolischer Link auf das Stück Union-FS, das für diesen Arbeitsknoten vor das Root-System gekettet wird

Union-FS

- hacc-cn0:/data/vol_union # ls -l
  7 -> n01
  8 -> n02
  9 -> n03
  n01 (vor geschaltete Union-FS Systeme)
  n02
  n03
  n04
  n05
  XXX (Platzhalter für defekte Knoten)
- Union-FS: Knoppix:
  - Verketten mehrere Filesysteme so hintereinander, dass sie als ein Filesystem sichtbar sind
  - lesen in allen verketteten Systemen, schreiben im obersten
  - besondere Vorkehrungen für das Löschen
  - Voraussetzung: installieren der zum Linux Kernel passenden Treiber: runter laden, übersetzen (nur der speziellen Treiber), installieren im aktuellen Kernel, initrd Modulliste um 'unionfs' ergänzen und initrd neu erstellen mit 'mkinitrd -D eth1'

Arbeitsknoten

- speichert seine Daten in seinem individuellen Union-FS, das beim Boot vorgelagert wurde
  - Start der Kundendienste, die angeboten werden
  - besitzt eine primäre IP Adresse (und je Dienst eine Aliasadresse)
  - enthält alle Konfigurationsdateien des Servers
  - enthält alle Logs
  - erscheint wie ein normales Linux-System
- Initialisierung dieses Union-FS
  - Kopieren eines vorhandenen Union-FS und entfernen aller Dateien bis auf ein Grundgerüst
  - Anlegen eines Links für die innere IP Adresse, mit der die Initialisierung vorgenommen werden soll
  - Modifizieren einiger Dateien:
    - /etc/HOSTNAME
    - /etc/fstab
    - /etc/sysconfig/network/ifcfg-bond0 (neue Adressen eintragen)
  - Starten und weitere Konfigurationen, wie bei einem normalen Linux
- Jeder Knoten besitzt ein lokales Swap und ein lokales /tmp!

Nagios

- Nagios ist ein Überwachungssystem für das Netzwerk und für Systemkomponenten
- Steuerung: Konfigurationsfiles, Scripte und einer Web-Oberfläche
- Die Standard-Skripte der RPM Pakete von SuSE wurden stark verändert, da dieses Produkt so nicht einsetzbar war (evtl. hätte es sich gelohnt, die neueste Version herunter zu laden und einzusetzen)
- Je IP Adresse wurde ein Host definiert; alle externen IP Adressen eines Hosts wurden als 'parent' verbunden
- Für die Services wurden selbst programmierte Prüfroutinen zugefügt.
- Für die kritischen Services wurden event-Handler erstellt, die in Abstufung
  - den Dienst neu starten
  - den Server neu starten
  - für ssh-Probleme wurde ein Event-Handler erstellt, der ein Reset für den Knoten durchführt (über das Blade Control Center physisches RESET)
- für die Hosts wurde ein Event-Handler erstellt, der bei kritischen Hosts eingebunden werden kann und der in Abstufungen:
  - 15 Minuten warten
  - immer noch nicht erreichbar:
    - Auswahl eines neuen Knotens
    - Kennzeichnen des bisherigen Knotens als defekt

Konfigurationsknoten

- Beim Ersteinrichten wurden einige Anpassungen vorgenommen
  - /etc/sysconfig/network/config: 'FORCE_PERSISTENT_NAMES=no'
  - /etc/init.d/network: im Stop-Teil: Herunterfahren von eth1 durch Modifikation des Scripts verhindern (ifconfig bond0, eth0 und eth2 down und 'exit 0' wurde am Anfang des Stop-Teils eingebaut)
  - Einbau eines Scripts in den Bootprozeß, der das für die inneren IP Adresse ausgewählte Union-FS vorkettet (oder keines vorkettet beim Konfigurationsknoten)
    - /etc/init.d/boot wurde dafür entsprechend modifiziert (scriptaufruf eingebaut) (Siehe Quellen)
    - ein Script, von 48 Zeilen, welches dieses Einketten entsprechend vornimmt, wurde erstellt (Nur wenn ein Union-FS Filesystem für die IP Adresse existiert wird es vorgekettet)
- Über den Konfigurationsknoten werden Änderungen im Root Filesystem vorgenommen
  - Erstellen eines neuer Root Systems
  - Einspielen der Patches
  - Beim Einspielen von Kernel Updates (über neues Root System):
    - Neu Installieren Union-FS Treiber
    - Installieren der besonderen initrd mit unionfs Treiber: mkinitrd -D eth1

Script: /etc/init.d/union.sh

union.sh (/etc/init.d) - GVIM <@hacc-n00>

Datei Editieren Werkzeuge Syntax Puffer Ansicht Hilfe

```
#!/bin/bash

# union.sh
# Vorketten des union-fs Filer bereichs vor Root

# Boot Interface
IF='eth1'
# unionfs Resource Path
UNION='192.168.100.100:/vol/vol_union'

# IPT = <letzte Stelle der IP Adresse des Hostes auf Interface IF>
IPT=$(ifconfig $IF | head -2 | tail -1 | \
        awk '{ print $2 }' | awk -F. '{ print $4 }')

echo Resource: $UNION/$IPT/

set -x

# Anlegen der Resourcen zum Mounten
mkdir -p /ram
mount -n -t tmpfs tmpfs /ram -o rw
mkdir /ram/changes /ram/union

# Mounten des eigenen Bereichs des Servers
if (mount -n -t nfs $UNION/$IPT/ /ram/changes -o rw,nolock)
then
        # alte mtab-Files entfernen
        rm /ram/changes/etc/.wh.mtab*

        # neu mounten Root
        mount -n -o remount,ro,nolock /

        # zusammenfuehren der Resourcen
        mount -n -t unionfs -o dirs=/ram/changes=rw:/=ro unionfs /ram/union

        # einfuegen der Systembereiche
        mkdir -p /ram/union/changes
        cat /proc/mounts
        mount -n --move /proc /ram/union/proc
        mount -n --move /sys /ram/union/sys
        mount -n --move /dev /ram/union/dev
        mount
        pivot_root /ram/union /ram/union
        mount
        cat /proc/mounts
        echo Ende unionfs einbinden
        # sleep 60
fi
```

14,0-1 Alles

- Einbinden in /etc/init.d/boot:

boot (/etc/init.d) - GVIM <@hacc-n00>

Datei Editieren Werkzeuge Syntax Puffer Ansicht Hilfe

```
    *)      DO_CONFIRM=     ;;
    esac
    unset answer
    echo
fi
export DO_CONFIRM

#
# unionfs einfuegen
#
echo -n "Starten Dateisysteme"
/bin/sh /etc/init.d/union.sh

#
# Start blogd, requires /proc and /dev/pts.
# Export the real device in variable REDIRECT.
#
test -x /sbin/blogd -a -n "$REDIRECT" && /sbin/blogd $REDIRECT
if test -z "$REDIRECT" ; then
    if (echo -n > /dev/tty) 2>/dev/null ; then
        REDIRECT=/dev/tty
    else
```

147,28 44%

Ergebnis

- Alle Arbeitsknoten sind wie normale Linux-Rechner administrierbar
  - Keine Pfad-Verbiegungen
  - Keine zusätzlichem Modifikationen im System durch symbolische Links oder spezielle Mount-Bind-Operationen
  - SW-Patches dürfen nur auf dem Konfigurationsknoten eingespielt werden!
- Problem: neues Patch-Regime von Novell für SLES10
  - Jeder Knoten soll sich bei Novell melden (schlimmer als Microsoft)
  - dann holt er individuell die Patches und installiert sie
  - das kann so nicht gemacht werden, weil:
    - teilweise Softwarepakete geändert werden müssen nach der Installation, damit sie laufen (Nagios, Tomcat5)
    - die Server keine aktive Internetverbindung haben sollen
    - Software nicht auf den Arbeitsknoten sondern nur auf dem Konfigurationsknoten gespeichert werden soll
  - Lösung:
    - SLES10: Zur Zeit werden die Patches manuell runter geladen und irgendwann eingespielt
    - Langfristige Lösung: andere Distribution!

Weiterentwicklungsmöglichkeiten

- Nagios weiter einbinden:
  - Auslastung registrieren und grafisch darstellen
  - Standard Layout ändern
- Web Oberfläche für die Konfiguration des Systems
  - Installation neuer Blades
  - Einbinden neuer Applikationen in die Überwachung
  - Erstellen einer einheillichen Administrationsoberfläche (Web), für:
    - das Web Kontrol Center (KVP)
    - die Switches
    - Nagios
    - die zu entwickelnde Konfigurationsoberfläche
- Einbindung weiterer BX600 Systeme in ein System der Steuerung unter Beachtung eines Total Ausfalle (Strom Ausfall) eines BX600
- Aktives Betriebssystem Versions-Management, das die gezielte Einbindung mehrerer Betriebssystemversionen erlaubt

Quellen

- [1] http://www.am-utils.org/project-unionfs.html
- [2] http://www.gi-hill.de/fachtagung2005/linux-diskless.pdf
- [3] Linux-magazin 2006/03 Wurzelimport
- [4] http://www.kolbitsch.org/research/technical/Unattended_Linux.pdf
- [5] ftp://unionfs-mirror.linux-live.org/unionfs/
- [6] http://www.novell.com/de-de/documentation/suse10/pdfdoc/suse10_ref/suse10_ref.pdf