SmartOS

Zones + ZFS + KVM + DTrace = Awesome

Thomas Merkel <tm@core.io>
2014-04-20

SmartOS - Illumos basiertes Cloud OS mit KVM Support

whoami

- Frubar Network seit 2005
- Server Ninja / Partner bei SkyLime seit 2007
- Administration von ~450 Linux / Unix Server (Gentoo, Ubuntu, Debian, SmartOS)
- Fokus auf Monitoring, Webserver Cluster, Script Entwicklung

Frubar Network - Gruppe von vielen verrückten IT Fricklern / Freunden / etc.

SkyLime - IT Consulting und Hosting Firma

Agenda

- Was ist SmartOS?
  - Zones
  - Crossbow
  - ZFS
  - KVM
- Thinking SmartOS
  - Installation
  - Tipps
  - Konfiguration der Globalen Zone
  - Datasets
  - Verwaltung von Zones und KVM Images
  - Paketmanagement in Zones
  - Update SmartOS
- Project FiFo
- Links

Fragen am Ende

Feuerzangen Bowle: Aha, heute krieje mer de Dampfmaschin. Also, wat is en Dampfmaschin? Da stelle mehr uns janz dumm. Und da sage mer so: En Dampfmaschin, dat is ene jroße schwarze Raum, der hat hinten un vorn e Loch. Dat eine Loch, dat is de Feuerung. Und dat andere Loch, dat krieje mer später.

Was ist SmartOS?

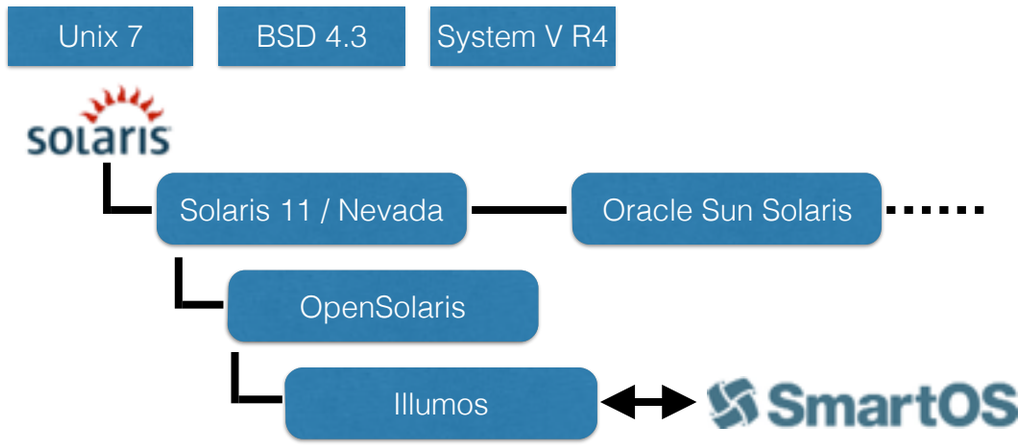

Unix Derivat

Illumos Distribution

Was ist SmartOS?

- Entwickelt von Joyent (Open Source)
- Solaris Features
  - Zones
  - Crossbow
  - ZFS
  - DTrace
- Fokus auf Virtualisierung
  - Boot via externer Medien (USB, Netboot)
  - Minimale Konfiguration
  - Verwaltungstools
- KVM Support

Zones: Virtualisierung auf OS Ebene

Crossbow: Virtuelles Netzwerk

ZFS: Dateisystem

DTrace: Kernel- und Anwendungsanalyse in Echtzeit

Zones - OS Virtualisierung

- Selbstverwalteter Container
  - Konfiguration eigener Benutzer, Festplatten, Netzwerk und Dienste
  - „Gefühlt“ wie ein OS
- Isoliert
  - Zone sieht nur sich selbst
  - Globale Zone überwacht lokale Zonen
  - Eigenes Netzwerk und isoliertes Dateisystem
- Ressourcen Verwaltung
  - Arbeitsspeicher, Festplatte und Netzwerk I/O
  - CPU Verteilung

Zones - OS Virtualisierung

- Minimaler Overhead
- Hardware muss nicht emuliert werden
- Dienste können aus der globalen Zone überwacht werden (z.B. via DTrace)

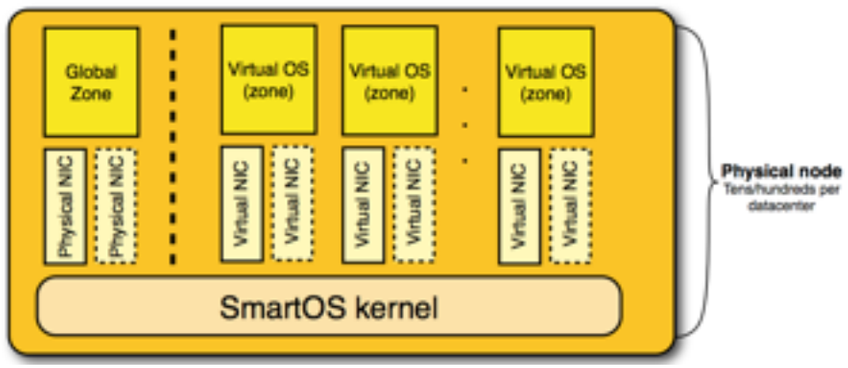

Crossbow - Virtual NICs

- Erstellung von virtuellen Netzwerkinterfaces oder Switches
- Verbindung von VNICs zu
  - Physikalischen NICs
  - Virtuellen Switches
- Antispoofing
  - MAC Adressen
  - IP Adressen
  - DHCP
- Kontrolle der Bandbreite

ZFS

- Copy on write Dateisystem
- Pool Storage
  - Partitionierung spielt keine Rolle
  - Verwaltung via Datasets
  - Live Änderungen an Quotas
- RAID
  - RAID 1 (Mirror)
  - RAIDZ, Z2, Z3, … (Single, Double oder Triple parity)
  - RAID 0 (Striping)

Geänderte Blöcke werden nicht überschrieben, sondern zunächst vollständig an einen freien Platz geschrieben. Verweise auf den Block in den Metadaten aktualisiert. Dadurch auch Snapshot Support

ZFS

- 128bit Checksum für alles
- Komprimierung
- Deduplizierung
- ZIL (Intent Log)
- L2ARC (Cache)
- Snapshot und Clone Support

ZIL: write cache - wird normalerweise nie gelesen ausser ggf. beim crash. Flush ZPOOL Data

L2ARC: read cache - Dedublikationstabelle z.B.

KVM

- Virtualisierung anderer Betriebssysteme
- Joyent unterstützt KVM nur bei Intel CPUs mit EPT
  - AMD Unterstützung durch Community
- Administrationsbefehle für KVM Image oder Zone sind gleich

Joyent portiere Linux KVM zu Illumos Kernel

EPT Erweiterung für VT-x


Thinking SmartOS
http://www.flickr.com/photos/sbisson/7377508532

Installation

- Download und `dd` des Images auf USB Stick
  - http://wiki.smartos.org/display/DOC/Download+SmartOS
- Server via USB Stick Booten und Installer folgen
  - Netzwerk Informationen, Zpool anlegen, Root Kennwort
- Zusätzliche Konfiguration falls nötig unter `/opt/custom` und `/usbkey/config`
  - Puppet, Bash Scripts, eigene SVCs
- Und los gehts :-)

Statt dessen kann natürlich auch ein TFTP Server verwendet werden

Tipps

- Globale Zone
  - RAM Disk nur zur Zonenadministration
  - Daten in **/etc** und **/root:** nicht dauerhaft
  - Daten in **/opt** und **/var:** dauerhaft
  - Basis Konfiguration in **/usbkey**
  - SMF Manifest Dateien in **/opt/custom/smf/** werden beim Booten geladen

SMF: Service Management Facility => XML Dateien „Start Scripte“

/usbkey liegt auf dem ZPool nicht auf dem USB Stick

Konfiguration Global Zone

- /usbkey/config

```
# admin_nic is the nic admin_ip will be connected to for headnode.
admin_nic=00:26:b9:87:47:6c
admin_ip=80.190.131.134
admin_netmask=255.255.255.128
admin_network=...
admin_gateway=80.190.131.134

headnode_default_gateway=80.190.131.129

# create a virtual switch for an internal NAT solution.
etherstub="switch0"

dns_resolvers=8.8.8.8,8.8.4.4
dns_domain=srv.skylime.net

ntp_hosts=pool.ntp.org
```

Konfiguration Global Zone

- /opt/custom/

```
├── cfg
│   ├── datacenter
│   ├── global
│   │   ├── crontab
│   │   │   ├── fmadm
│   │   │   └── zpool
│   │   ├── root
│   │   │   └── root
│   │   └── script
│   │       ├── 10-hostname.sh
│   │       ├── 15-ipv6.sh
│   │       └── 20-sendmail.sh
├── script
│   └── postboot.sh
└── smf
    └── postboot.xml
```

Konfiguration Global Zone

- /opt/custom/smf/postboot.xml

```
<?xml version="1.0"?>
<!DOCTYPE service_bundle SYSTEM […]>
<service_bundle type='manifest' name='site:postboot'>
<service name='site/postboot' type='service' version='1'>
    <create_default_instance enabled='true' />
    <single_instance />
    <dependency name="network" grouping="require_all"
        restart_on="error" type="service">
        <service_fmri value="svc:/milestone/network:default"/>
    </dependency>
    <exec_method type='method' name='start' timeout_seconds='0'
        exec='/opt/custom/script/postboot.sh'>
    </exec_method>
    […]
</service>
</service_bundle>
```


SMF Manifest

Verwaltung via „svc“-Befehle

Datasets

- Bestehende Images für Zones oder KVM
- Community Images bei http://datasets.at

```
# imgadm avail

UUID                                  NAME            VERSION  OS       PUBLISHED
7241e29a-a07b-11e3-9a5c-53df1db058c4  base            13.4.1   smartos  2014-02-28
c3321aac-a07c-11e3-9430-fbb1cc12d1df  base64          13.4.1   smartos  2014-02-28
835e27b2-a47e-11e3-9eb6-e78ef6d1ee8f  postgresql      13.3.1   smartos  2014-03-05
398deede-c025-11e3-8b24-f3ba141900bd  standard64      13.4.1   smartos  2014-04-09
0fbd0a74-c028-11e3-ac6a-bf348e9f760c  elasticsearch   13.4.1   smartos  2014-04-09
edd43ca8-c0ee-11e3-a027-c3a9f2cd2f6a  stm-developer   13.4.1   smartos  2014-04-10
19daa264-c4c4-11e3-bec3-c30e2c0d4ec0  centos-6        2.6.1    linux    2014-04-15

[…]
```

Zonenerstellung (1)

- Gewünschtes Dataset importieren

```
# imgadm import 398deede-c025-11e3-8b24-f3ba141900bd
Importing image 398deede-c02… (standard 13.4.1) from "https://images.joyent.com"
398deede-c025-11e3-8b24-f3ba141900bd     [       ]   0%    2.83MB 592.83KB/s 19m28s
```


Dataset wird heruntergeladen um später Zone daraus zu erstellen

Zonenerstellung (2)

- JSON Beschreibungsdatei erstellen
- Generator auf http://datasets.at

```
{
  "brand": "joyent",
  "image_uuid": "398deede-c025-11e3-8b24-f3ba141900bd",
  "autoboot": true,
  "alias": "nsa-box",
  "hostname": "mirror-customer-information",
  "dns_domain": "nsa.gov",
  "resolvers": [ "8.8.8.8" ],
  "max_physical_memory": 512,
  "max_swap": 512,
  "nics": [ { "nic_tag": "admin", "ip": "dhcp", "primary": true } ]
}
```


Zonen werden im JSON Format beschrieben. Können einfach automatisiert werden.

Zonenerstellung (3)

- Zone erstellen via **vmadm**

```
# vmadm create -f nsa-box.json
Successfully created 59aaecb6-467d-4116-92bd-f31842d44c90
```

- Zone anzeigen

```
# vmadm list
UUID                                  TYPE  RAM      STATE             ALIAS
59aaecb6-467d-4116-92bd-f31842d44c90  OS    512      running           nsa-box
```


Verwaltungstool „vmadm“ bietet auch die Möglichkeit bestehende Zonen zu Bearbeiten / Anzupassen.

KVM

- Das selbe wie bei Zones aber mit zusätzlichen Möglichkeiten
  - Erstellen einer leeren Instanz und booten von ISO
  - Verwendung bestehender Datasets

- QEMU läuft in einer minimalen Zone
  - Logdateien unter /zones/UUID/root/tmp

Paketmanagement

- Kein Paketmanagement in der Globalen Zone
- Paketverwaltung erfolgt durch **pkgsrc** von NetBSD
- Binary Pakete (32bit und 64bit)
- Releases jedes Quartal (2014Q1)

- Layout
  - PREFIX=/opt/local
  - PKG_SYSCONFDIR=/opt/local/etc
  - PKG_DBDIR=/opt/local/pkg

Paketmanagement

- Bootstrap **pkgsrc** falls nicht vorhanden

```
# cd /
# curl -k \
    http://pkgsrc.smartos.skylime.net/[...]/bootstrap-2014Q1-x86_64.tar.gz \
    | gzcat | tar -xf -
# echo http://pkgsrc.smartos.skylime.net/packages/SmartOS/2014Q1/x86_64/All/ \
    > /opt/local/etc/pkgin/repositories.conf
# pkg_admin rebuild
# pkgin -y update
```

Paketmanagement

- Datenbank update

```
# pkgin update
pkg_summary.bz2
processing remote summary (http://pkgsrc.smartos.skylime.net/[...]/x86_64/All)…
updating database: 100%
```

- Suche

```
# pkgin search bash
bash-doc-2.05.2      Documentation for the GNU Bourne Again Shell
bash-completion-2.1  Programmable completion specifications for bash
bash-4.2nb3 =        The GNU Bourne Again Shell

=: package is installed and up-to-date
<: package is installed but newer version is available
>: installed package has a greater version than available package
```

Paketmanagement

- Installation

```
# pkgin install nginx-1.5.0
calculating dependencies... done.

nothing to upgrade.
1 packages to be installed: nginx-1.5.0 (342K to download, 777K to install)

proceed ? [Y/n]
```

- Einige Pakete installieren SMF (Service Management Facility)
- Alternativ NetBSD rc.d-Scripte

Update SmartOS

- Ganz einfach :-)

- USB Stick
  - **smartos-platform-upgrade** Script https://github.com/calmh/smartos-platform-upgrade
  - Ersetzt den alten **platform** Ordner mit neuem **platform** Ordner

Update SmartOS

- TFTP Server
  - Platform Archiv herunterladen https://us-east.manta.joyent.com/Joyent_Dev/public/SmartOS/platform-latest.tgz
  - **IPXE Konfiguration** anpassen
- Server rebooten

Projekt FiFo

http://www.flickr.com/photos/orangeacid/204163841

Projekt FiFo

- http://project-fifo.net
- Open Source Cloud Management für SmartOS
- Entwicklung in Erlang
- Development Version
- mDNS Service Discovery
- VNC Support via noVNC

Aktuell sehr stark in der Entwicklung, zu finden auch auf GitHub

Bietet schon viele Möglichkeiten unter anderem ein Webinterface

Projekt FiFo - Architektur

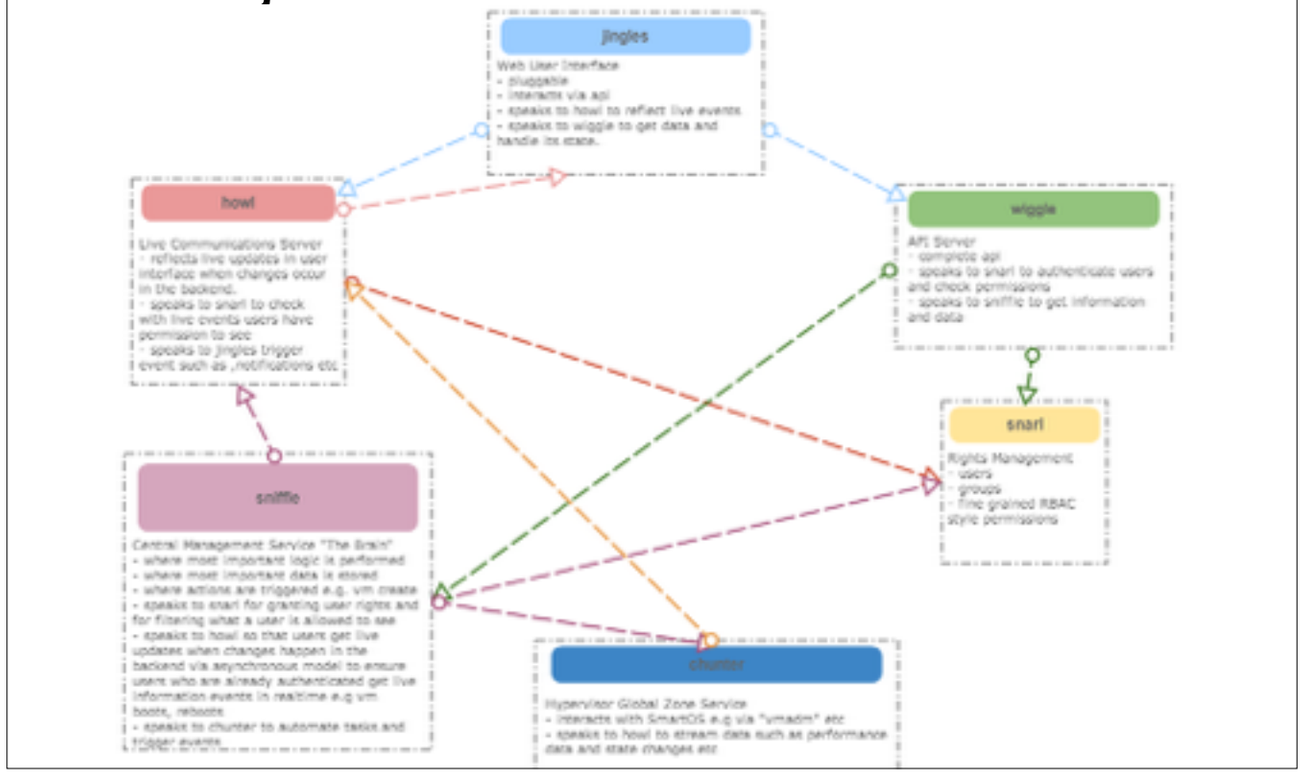

Service muss in der Globalen Zone installiert werden

Verschiedene Globale Zonen sollten über ein separates VLAN / Netz kommunizieren

Projekt FiFo - Status

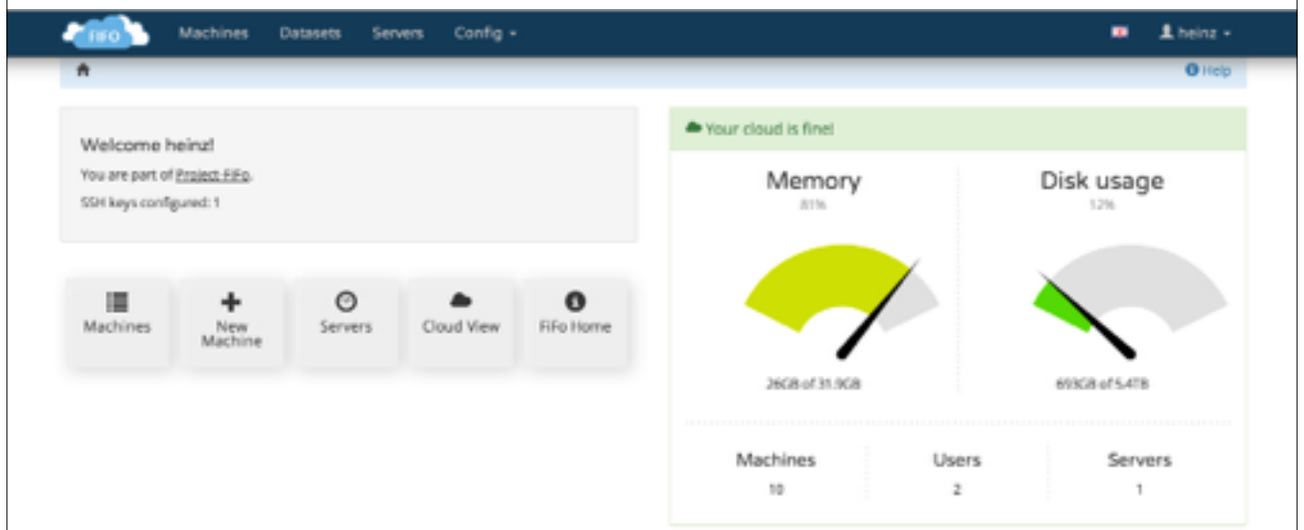

Einfaches Webinterface mit vielen Möglichkeiten

Web-API existiert auch

Projekt FiFo - VMs

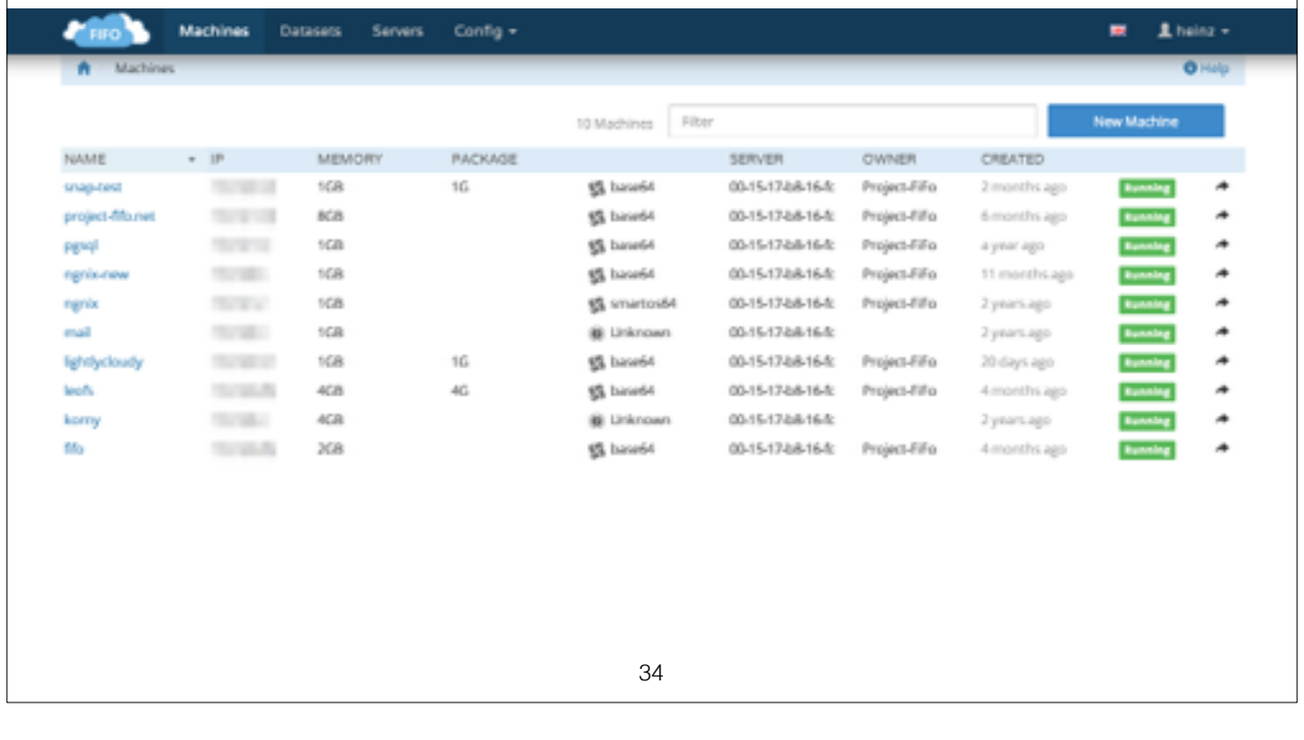

Verwaltung aller Virtuellen Maschinen auf verschiedenen Globalen Zonen

Projekt FiFo - VM details

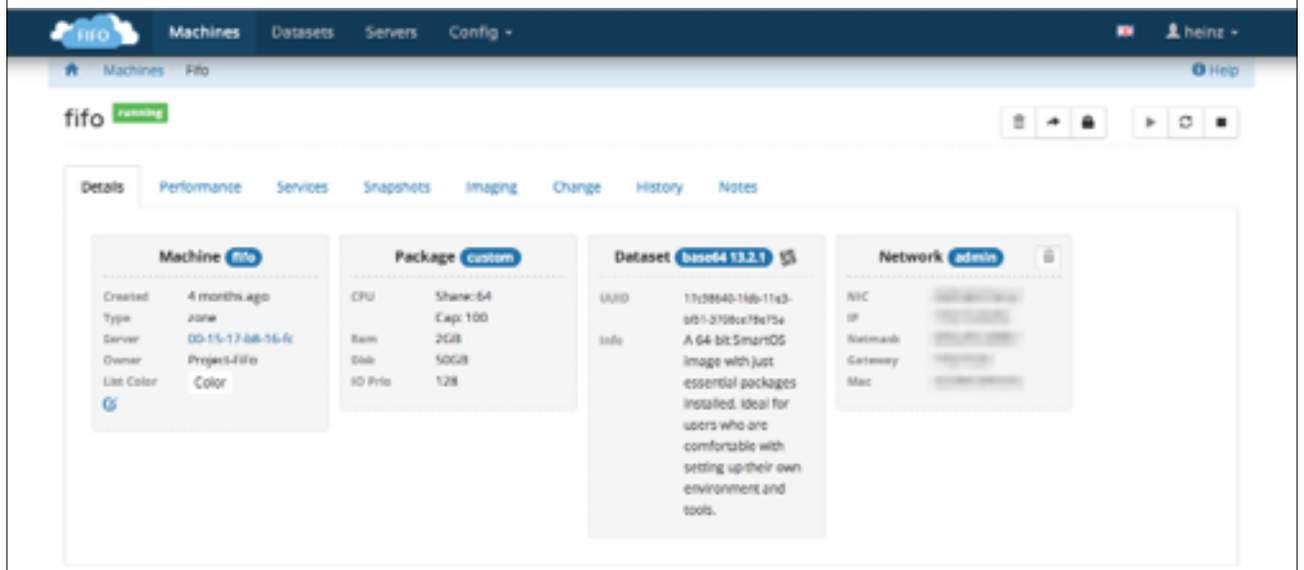

Verwaltung aller Virtuellen Maschinen auf verschiedenen Globalen Zonen


Global Zone build environment
http://www.flickr.com/photos/pultzpics/5864033917

Warum?

- Eigene Software-Pakete in der Globalen Zone
  - munin-node
  - postfix statt sendmail
- Anpassungen von SMF / Start-Scripte
- Eigene Erweiterungen

Build zone

- SmartOS multiarch Zone 13.3.0

```
# imgadm import a1d74530-4212-11e3-8a71-a7247697c8f2
```

- min. 32 GB RAM für die Zone
- ca. 20GB Speicherplatz

Build zone

- Zone über JSON Datei erstellen

```
{
  "brand": "joyent",
  "max_physical_memory": 32768,
  "tmpfs": 8192,
  "fs_allowed": "ufs,pcfs,tmpfs",
  "image_uuid": "a1d74530-4212-11e3-8a71-a7247697c8f2",
  "quota": 15,
}
```

The source

- Aktueller Quellcode aus dem Git Repository

```
build-zone # pkgin in scmgit
build-zone # git clone https://github.com/joyent/smartos-live
build-zone # cd smartos-live
```

```
build-zone # cp sample.configure.smartos configure.smartos
build-zone # ./configure
```

- Nicht genug Leistung (RAM, CPUs)?

```
gsed -e '/^PARALLEL/{s/-j[0-9]*/-j8/}' -i.bak projects/illumos-extra/Makefile.defs
```

The source

- Backe backe SmartOS

```
build-zone # gmake world && gmake live
```

- Packaging

```
build-zone # pkgin in cdrtools pbzip2

build-zone # export LC_ALL=C
build-zone # tools/build_iso
build-zone # tools/build_usb
```

Links

- SkyLime /opt/custom Scripts
  - https://github.com/skylime/smartos-config
- Joyent Wiki
  - http://wiki.smartos.org/
  - https://github.com/joyent/smartos-live
- Blog von Jonathan Perkin (Joyent Entwickler / pkgsrc)
  - http://www.perkin.org.uk/
- SmartOS mit IPv6 und AMD Support
  - http://imgapi.uqcloud.net/builds
- Community Datasets
  - http://datasets.at

Community

- IRC (irc.freenode.net)
  - #smartos
  - #illumos
  - #joyent
  - #project-fifo
- Mailinglist
  - http://smartos.org/smartos-mailing-list/
  - https://groups.google.com/forum/?fromgroups#!forum/project-fifo

Community trifft sich meist im IRC

Viel Hilfe im #smartos Channel durch Joyent Mitarbeiter und Community


Fragen?
http://www.flickr.com/photos/mandyxclear/3461234232