

FreeBSDで完全冗長化された Network Filesystemを 作れながら作った記録

2016/02/18

許 先明

お品書き

- Motivation
- Implement
- Problems

Motivation

なんで？

- Mail Serverなどに供給するFilesystemは安定性と冗長性が重要
 - 一般にFilesystemの冗長化は非常に難しい
 - Freeに利用できる良い実装はない。
 - MailServerを構築する場合
 - Lock問題への対応
 - Maildirを利用しHome Directoryに
 - ファイル単位で
 - 受信したメールを保存する
 - SMTP Serverは冗長性を確保したい
 - Mail spoolの冗長化を考えると Network Filesystemを利用したくなる
- 負荷分散を考える必要があるシステムで、コンテンツを共有する必要があるものには、常に存在する

どうやって？

- Linux系(CentOS/Ubuntu…)
 - DRBD : Disk単位(Block Device単位)での同期
 - Block DeviceとしてのHDDを同期
 - lsyncd/rsync : ファイル単位での同期
 - Linux kernelのinotifyを利用したファイルの書き換え検出(lsyncd)
 - 検出されたファイルの同期(rsync)
 - Symbolic Linkの取り扱いに難がある（というはなしをきいた）
- FreeBSD系
 - HAST : Disk単位(Block Device単位)での同期
- その他
 - 知らない。NetBSDとOpenBSDには、このような実装はないと思われ

FreeBSDでHAST?

- やっぱり運用するなら(慣れているし)*BSDだよね
- HASTしかないんだけど。しかもFreeBSD系だけなんだけど。
 - やっている人すくなそう。情報も少ないぞ
 - NAS4FreeとかFreeNASとか
 - どうせExperimentalだし
 - GUIから(全部は)設定できないし
 - 情報少ないし

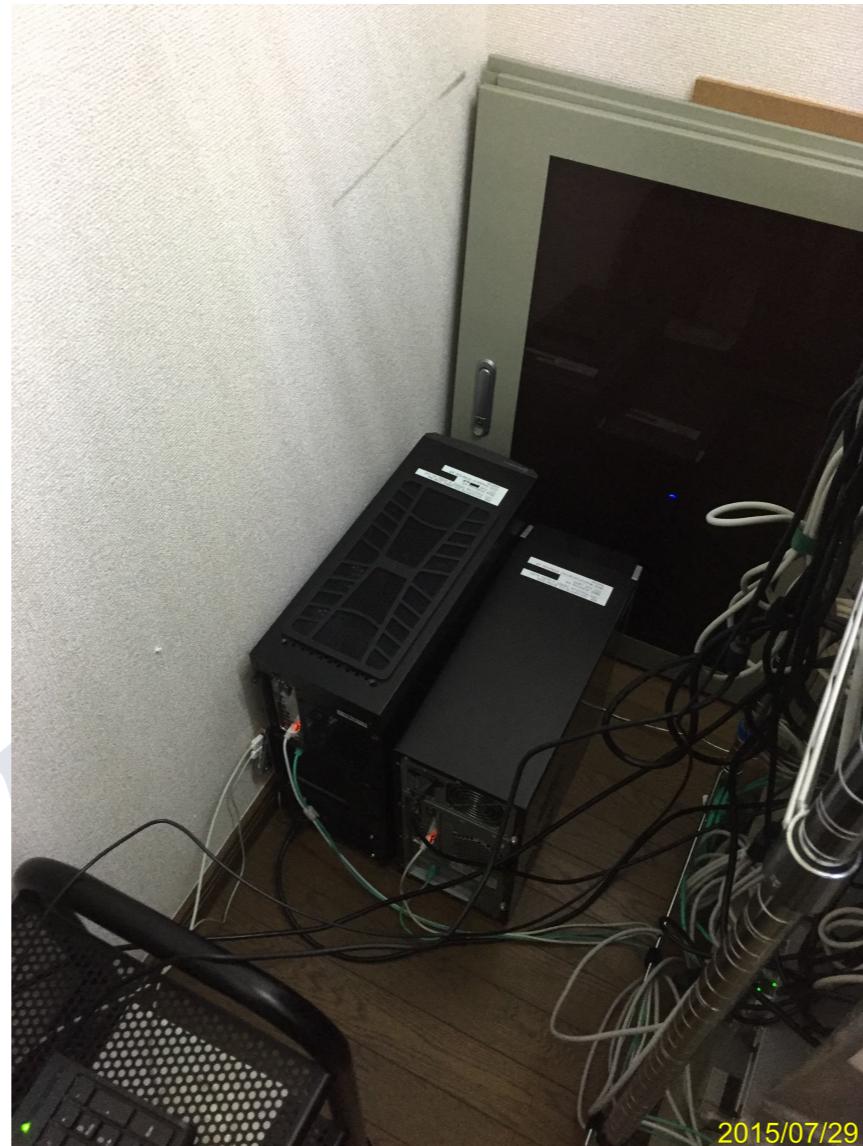
Implement

我が家の中の環境 -1-



Server
&
Switch

Storages



年間平均気温 25.3°C



Printer
&
Consoles

我が家の中の環境 -3-

◆ コンピュータルーム諸元

- ◆ 広さ：3畳

◆ 現在の消費電力

- ◆ コンピュータ系 定常状態で $12A+12A = 24A$: $24h/365days$

- ◆ エアコン(8畳用) $24h/365days$ 冷房：設定温度18°C、室温25.3°C (約 6.5A)

◆ 月額電気料金（家庭分含む）：**約60,000(4月)～約75,000(7月)**

◆ なにやってんの？

- ◆ 家庭内LAN環境

- ◆ 仮想システム試験環境

- ◆ Xen/XenServer、完全冗長構成NAS実稼働試験、完全冗長DB環境試験

- ◆ 個人及び知合の収容

- ◆ 個人のWeb Pageや、いくつかの公開サービス

- ◆ 個人で/28(IPv4)+/56(IPv6)、ドメイン4個+預かりドメイン3個

Install

- VMの諸元
 - CPU: 仮想CPU 1個
 - Memory: 1024MB (UFSを利用するのでこのくらいでいい)
 - HDD: 仮想HDD 20G + 仮想HDD 100G
 - NIC: 仮想NIC x2
- 詳しい記事は以下を参照
 - <http://www.seirios.org/seirios/dokuwiki/doku.php?id=os:freebsd:hast>
- 使った技術 ... W
 - HAST・CARP・devd・NFS
 - CARPのStateがMASTERになつたらHASTのroleをPrimaryにするためにdevd

memo

- FreeBSD 10系におけるdevd.conf(CARP部分だけ)の例

```
notify 100 {  
    match "system" "CARP";  
    match "subsystem" "[0-9]+@[0-9a-z]+";  
    match "type" "(MASTER|BACKUP|INIT)";  
    action "/usr/local/sbin/carp-hast-switch $subsystem $type";  
};
```

- 要するに、CARPのStateが変化したら、actionに記載されたコマンドを実行する。
 - その時、引数に、I/F名と状態を渡す

これで、Stateが変化した時に、hastの挙動を変化させるためのscriptを呼び出せる。

memo-2

carp-hast-switchを大幅に書き換えた(が、これ、使えない...)www

```

#!/bin/sh
#
# carp-hast-switch: shell script for change hast role when carp
#       status is changed.
#
# Original script by Freddie Cash <fjwcah@gmail.com>
# Modified by Michael Lucas <mwlucas@BlackHelicopters.org>
# and Viktor Peterson <vpetersson@ireload.net>
# and HEO SeonMeyong <seirios@seirios.org>
# Last modified 2015/11/10 HEO SeonMeyong <seirios@seirios.org>
#
# ***WARNINGS***
# Need net.inet.carp.preempt=1 and same of advskew on carp.
# Currently HAST device must be formatted by UFS
# ZFS code is implemented but not checked.
#   This script is assumed to match the ZFS pool name and HAST resource name
#####
# Setting Variables and parse Arguments.
#
#DEBUG=1
SYSLOG_FACILITY="user.notice"
SYSLOG_TAG="carp-hast"
IF=${!#}
VHID=${!#}
ACTION=${!#}
ACTION=${ACTION:-$VHID}

# Work around for boot time. devd execute this script before start hastd.
[ ! -e /bin/pgrep hastd ] && exit

case "${ACTION}" in
    MASTER|BACKUP|INIT)
        /usr/bin/logger -p ${SYSLOG_FACILITY} -t ${SYSLOG_TAG} \
            "State Changed. I/F: ${IF} VHID: ${VHID} state: ${ACTION}"
        ;;
    *)
        /usr/bin/logger -p ${SYSLOG_FACILITY} -t ${SYSLOG_TAG} \
            "FATAL: ${ACTION} is not yet implemented"
        exit 1
        ;;
esac

#####
# Get resources.

HASTDEV=/sbin/hastctl dump all | /usr/bin/grep resource | /usr/bin/sed -e 's/^.*:\ \*//'
[ "x$DEBUG != "x" ] && echo "HASTDEV = ${HASTDEV}"
[ -z "$HASTDEV" ] && exit 0 # no hast device.

# get all carp interfaces
if=${!#}
for i in ${!ifs}; do
    no_of_carp=/sbin/ifconfig $i | /usr/bin/grep -c carp
    [ "x$DEBUG != "x" ] && echo "Interface $i has ${no_of_carp} CARP configuration"
    [ ${no_of_carp} != "0" ] && carps="$carps $i"
done
[ "x$DEBUG != "x" ] && echo "CARP I/F = ${carps}"
[ -z "$carps" ] && exit 0 # no carp I/F.

PREEMPTION=/sbin/sysctl net.inet.carp.preempt | /usr/bin/awk '{print $2}'
[ "x$DEBUG != "x" ] && echo "CARP preempt = ${PREEMPTION}"
[ ${PREEMPTION} != "1" ] && exit 0 # No carp preempt. May cause failure.

#####
# Main.

case "${ACTION}" in
    "MASTER")
        # make sure all carp is master.
        if [ -n "$carps" ]; then
            for if in ${carps}; do
                vhid=/sbin/ifconfig ${if} | /usr/bin/grep carp | /usr/bin/awk '{print $3
" " $4}'
                /sbin/ifconfig ${if} ${vhid} state master
            done
        fi

        for disk in ${HASTDEV}; do
            # If there is secondary worker process, it means that remote primary process is
            # still running. We have to wait for it to terminate.
            for i in {1..30}; do
                /bin/pgrep -f "hastd: ${disk} \\\(secondary\\\)" >/dev/null 2>&1 || break
                sleep 1
            done
            if pgrep -f "hastd: ${disk} \\\(secondary\\\)" >/dev/null 2>&1; then
                /usr/bin/logger -p ${SYSLOG_FACILITY} -t ${SYSLOG_TAG} \
                    "FATAL: Secondary process for resource ${disk} is still
running after 30 seconds."
                exit 1
            fi
        done
    ;;
    "BACKUP"|"INIT")
        # make sure all carp is backup
        if [ -n "$carps" ]; then
            for if in ${carps}; do
                /usr/bin/logger -p ${SYSLOG_FACILITY} -t ${SYSLOG_TAG} \
                    "Role for HAST resources ${disk} switched to primary."
                /sbin/hastctl role primary ${disk}
                if [ $? -ne 0 ]; then
                    /usr/bin/logger -p ${SYSLOG_FACILITY} -t ${SYSLOG_TAG} \
                        "FATAL: Unable to change role to primary for
resource ${disk}."
                    exit 1
                fi
            done
        done
        # Wait for the /dev/hast/* devices to appear
        for disk in ${HASTDEV}; do
            for loop in $( { j=1..120 }; do
                [ -c "/dev/hast/${disk}" ] && break
                sleep 0.5
            done
            if [ ! -c "/dev/hast/${disk}" ]; then
                /usr/bin/logger -p ${SYSLOG_FACILITY} -t ${SYSLOG_TAG} \
                    "FATAL: GEOM provider /dev/hast/${disk} did not
appear."
                exit 1
            fi
            FSFM= file -bs /dev/hast/${disk}
            if [ $? -ne 0 ]; then
                /usr/bin/logger -p ${SYSLOG_FACILITY} -t ${SYSLOG_TAG} \
                    "FATAL: /dev/hast/${disk} cannot define FS format."
                exit 1
            fi
            FSFM= echo ${FSFM} | /usr/bin/awk '{print $1 " " $2}'
            case ${FSFM} in
                "Unix Fast")
                    /sbin/fsck -y -t ufs /dev/hast/${disk} >/dev/null 2>&1
                    if [ $? -ne 0 ]; then
                        /usr/bin/logger -p ${SYSLOG_FACILITY} -t ${SYSLOG_TAG} \
                            "FATAL: UFS fsck /dev/hast/${disk} failed."
                        exit 1
                    fi
                    /usr/bin/logger -p ${SYSLOG_FACILITY} -t ${SYSLOG_TAG} \
                        "fsck /dev/hast/${disk} finished."
                    e_code= /sbin/mount /dev/hast/${disk} /hast/${disk} 2>&1
                    if [ $? -ne 0 ]; then
                        /usr/bin/logger -p ${SYSLOG_FACILITY} -t ${SYSLOG_TAG} \
                            "FATAL: UFS mount for resource ${disk} failed: $(
e_code)."
                        exit 1
                    fi
                    /usr/bin/logger -p ${SYSLOG_FACILITY} -t ${SYSLOG_TAG} \
                        "UFS /dev/hast/${disk} is mounted."
                    ;;
                *) # If not UFS, Assume that filesystem is ZFS.
                    e_code= /sbin/zpool import -f ${disk} 2>&1
                    if [ $? -ne 0 ]; then
                        /usr/bin/logger -p ${SYSLOG_FACILITY} -t ${SYSLOG_TAG} \
                            "FATAL: ZFS import for resource ${disk} failed: ${e_code}."
                        exit 1
                    fi
                    /usr/bin/logger -p ${SYSLOG_FACILITY} -t ${SYSLOG_TAG} \
                        "ZFS ${disk} is imported."
                    ;;
            esac
        done
        # NFS Service ( run nfsd and mounted. )
        /usr/sbin/service rpcbind restart
        /usr/sbin/service statd restart
        /usr/sbin/service lockd restart
        /usr/sbin/service nfsd restart
        /usr/sbin/service mountd restart
        /usr/bin/logger -p ${SYSLOG_FACILITY} -t ${SYSLOG_TAG} \
            "NFS started."
        # iSCSI service
        # /etc/rc.d/iscsi_target start
        ;;

esac
fi

# Local Variables:
# coding: utf-8
# mode: sh
# sh-basic-offset: 4
# sh-indentation: 4
# End:

```

Problems

さて本題

- 問題点は
 - FreeBSDがBootする際の挙動
 - NFSが(この用途には)使えない

Boot時の挙動問題

起動時の挙動(必要部分だけ)

1.devdを起動

devdがNIC設定より前に起動される

→NIC設定(CARP設定)時にscriptが呼ばれる orz..

2.NICを設定

3.rpc関連を起動

4.NFS Client関連の起動

hastdが起動された時にはすでにNICは設定済み

→scriptは呼ばれない

→結果、hastd起動後にroleを設定できない

5.hastd起動

6.NFS Server関連の起動

hastdがprimaryになっていないのにExport

→されるはずがない

Boot時の挙動問題(解決策)

- システム起動に関しては手をつけない
 - rc.confとかrc.conf.localとかでFakeするのは、保守上ダメ
- 対応策(案)
 - carp-hast-switchをいじる
 - hastdの起動状態の確認を行う（起動してなければ何もしないようにする）
 - /etc/rc.localで、最後にcarp-hast-switchを呼び出す
 - CARP Stateの確認が必要

再起動問題さえなければ、現状でちゃんとHASTは動いてます。

しかも、かなり安定しています。

HASTを止めてmountすれば、ちゃんとFilesystemとして見えます。

でも、ここをちゃんとしないと、**SplitBrain**になります

NFSが使えない -1-

- 使えそうなNetwork File Systemはあるか？
 - FreeBSDで使えそうなものはほとんどない。
 - ClientにCentOS/Ubuntu/NetBSD/OpenBSDがあるので、そもそも制限がきつい
 - 実質NFSだけじゃね？、あえて言うならSAMBA???、(嫌～)
- NFS : Network File System
 - NFS: RFC1094 (1989/03)
 - NFS version 3: RFC 1813 (1995/06)
 - NFS version 4: RFC 3530 (2003/04)
 - RFC3010(Obsolete): (2000/12)
- つまるところ、古い…

NFSが使えない -2-

- いや、普通に使う分には使えます。
- NFS v4は認証関係でものすごく面倒そうだったので2035年問題があるのを承知で NFSv3にしました
- 別に普通にNFS鯖立てて、NFS暗蟻作れば普通にFilesystem共有できますよ。

駄菓子菓子

- 完全冗長にはできなかったのです。

NFSが使えない -3-

- NFS ServerはNFSでの接続ポイントをCARPで供給している
 - NFS ServerのIPアドレスをNs1/Ns2とし、NFSのアドレスをNsCとする
 - NFS ClientをNcとする
 - 初期状態では、Ns1がNsCを持っていて、NcがNFS mountしているとする
- 問題発生の流れ
 1. Ns1がshutdown
 2. NsCがNs2に移り、Ns2はHAST Primaryになり、NFS関連が起動する
 3. NcはNsCを通じてNs2のStorageにアクセスしようとする
 4. いつまでたってもアクセスできず、はまる

NFSが使えない -4-

- ▶ なにが起こっているのか？
 - ▶ NFSでFilesystemを公開しているのはmountd
 - ▶ mountdは、NFS Clientを記録している
 - ▶ /var/db/mountdtabにClientのIP Addressを記録している
 - ▶ NFS Server #1と#2は、当然、HASTのVolumeしか同期していない
 - ▶ したがって、当然mountdtabにはClientのIP Addressは記録されていない
 - ▶ 結論
 - ▶ NFS Server#2はNFS Clientからの接続を認めない！orz..

NFSが使えない -5-

- まず、そもそもArchitectureを考え直す
 - HASTは、Filesystemの完全な同期だから、NFS Client側のinode cacheに対して耐性があるはず
 - 耐性があるなら、NFSのCacheは忘れてもなんとかなるか..
- じゃあ、どうすりゃいいの？
 - まあ、取り急ぎで言うなら、/var/db/mountdtabを同期する手を考える
 - でもどうしよう？rsync?ないよなあ。
 - HAST???? 動く気がしないでもないが、えーと…
 - automountで凌ぐ？
 - 動く気がしない…。いや、動いてくれそうな気もするんだけど…
- 何らかの知恵求む