※ DRBDはLINBIT Information Technologies GmbHの登録商標です。

入門 PostgreSQL＋Pacemaker＋DRBDで 高可用性構成を構築してみよう

オープンソースカンファレンス2014 Tokyo/Spring
2014年2月28日

SRA OSS, Inc. 日本支社
佐藤 友章
sato@sraoss.co.jp

はじめに

- どのような人に聞いてほしいか
  - PostgreSQLを使っている人
  - PostgreSQLの可用性を上げたいと思っている人
  - 可用性構成は難しそうだと思っている人
- とりあえずPostgreSQLの高可用性構成を構築する手順について説明
  - とりあえず＝細かいことは置いておく
    - スプリットブレイン、STONITHなど
  - Pacemaker、HeartbeatについてはLinux-HA Japan Project、DRBDについてはサードウェアにも話を聞こう
    - PostgreSQLについてはSRA OSSも忘れないで

高可用性とは

- システムをいかに止めずに動かし続けられるかの度合い＝可用性が高いこと
  - HA＝High Availabilityとも言う
- 可用性は稼働率や停止時間で計られる

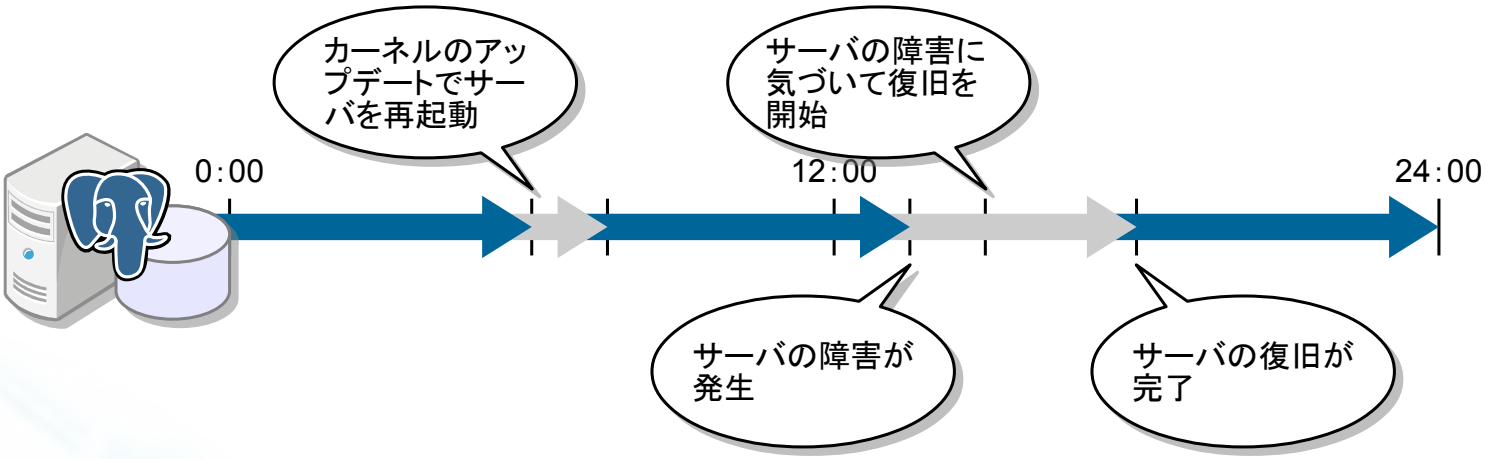

  - 稼働率は➡÷(➡＋➡)＝18÷(18＋6)＝75%
  - 停止時間は➡＝6時間／日≒91.25日／年
    - 日単位の停止時間を年単位に換算するのには無理があるが

SRA OSS, INC.

高可用性構成とは？（9）

- PostgreSQL高可用性の実現方法めやす

稼働率	年間停止時間	実現方法
90%	36.5 日	バックアップ～リストアだけで十分。オンラインバックアップ取得を実施。
99%	3.65 日	オンプレミスなら予備マシンが必要。大データならバックアップのリストア所要時間を把握しておく。
99.9%	8.7 時間	保守停電のないクラウド～ハウジングが必要。平日日中のみ障害検知だとむずかしい。
99.99%	52 分	バックアップのリストアがほぼ不可能。レプリケーション（データ同期）された待機サーバが必要。
99.999%	5 分	HAクラスタソフトウェア等が必要。5分は自動切り替え1～2回分。

PostgreSQL高可用性構成の選択肢とトレンド
http://www.sraoss.co.jp/event_seminar/2013/20130212_pgha_seminar_sraoss.pdf

Pacemakerとは

DRBDとは

SRA OSS, INC.

PostgreSQL高可用構成（3）

- HAクラスタ データレプリケーション型
  - ブロックデバイス～ファイルシステムレベルでのデータ同期機能を使う
  - HAクラスタソフトに機能統合されている
  - 書き込み性能劣化あり

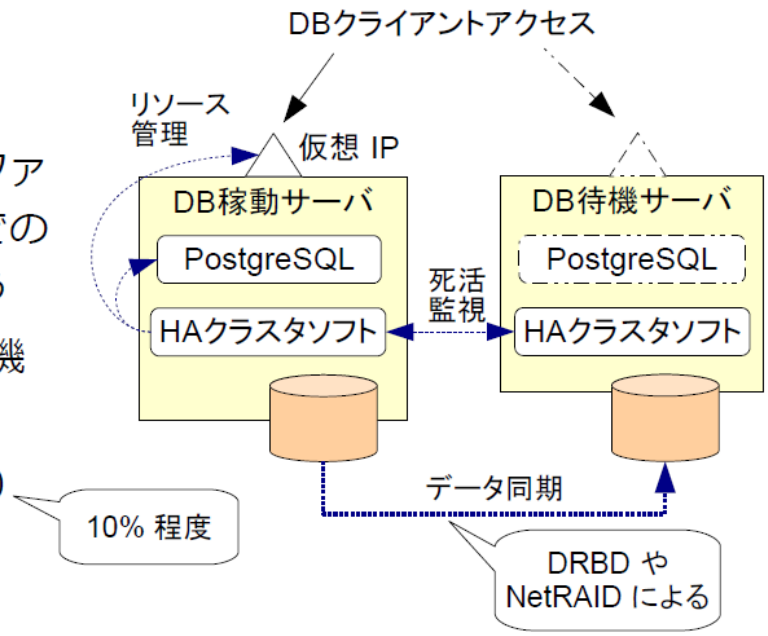

PowerGres on Linux + Lifekeeper でデータベースサーバの事業継続を実現
PowerGres on Linux HA

PostgreSQL高可用性構成の選択肢とトレンド
http://www.sraoss.co.jp/event_seminar/2013/20130212_pgha_seminar_sraoss.pdf

インストール

PostgreSQLのインストール

ACT
SBY
SRA OSS, INC.

- PGDGのリポジトリでPostgreSQLをインストール
  - PGDGとは
    - PostgreSQL Global Development Group
    - PostgreSQLの開発コミュニティ
    - http://www.postgresql.org/

1. リポジトリのパッケージをインストール

```
# yum -y install http://yum.postgresql.org/9.3/redhat/rhel-6-x86_64/pgdg-centos93-9.3-1.noarch.rpm
（省略）
Complete!
```

  - CentOS 6 x64以外については以下のURLを参照
    - http://yum.postgresql.org/repopackages.php

2. PostgreSQLのパッケージをインストール

```
# yum -y groupinstall "PostgreSQL Database Server 9.3 PGDG"
（省略）
Complete!
```

Linux-HA Japanリポジトリのダウンロード

ACT
SBY
SRA OSS, INC.

- Linux-HA Japanのローカルリポジトリでpacemakerをインストール
  - Linux-HA Japanとは
    - LinuxでHAクラスタを実現するソフトに関する日本のコミュニティ
    - http://linux-ha.sourceforge.jp/

1. ローカルリポジトリをダウンロード

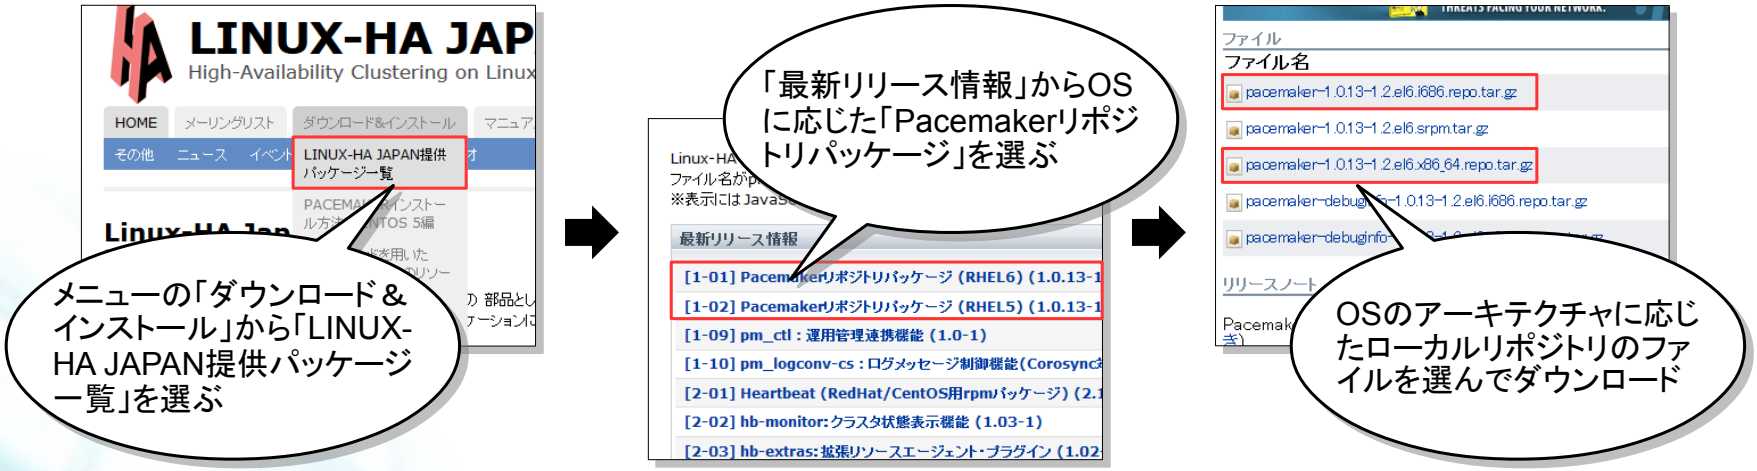

RHEL 6系 x64	pacemaker-1.0.13-1.2.el6.x86_64.repo.tar.gz
RHEL 6系 x86	pacemaker-1.0.13-1.2.el6.i686.repo.tar.gz
RHEL 5系 x64	pacemaker-1.0.13-1.2.el5.x86_64.repo.tar.gz
RHEL 5系 x86	pacemaker-1.0.13-1.2.el5.i386.repo.tar.gz

Linux-HA Japanリポジトリの設定

2. ローカルリポジトリを/tmpディレクトリに展開

```
# cd /tmp
# tar -xzf ~/Downloads/pacemaker-1.0.13-1.2.el6.x86_64.repo.tar.gz
```

- ほかのディレクトリに展開した場合には、展開先のディレクトリに合わせてリポジトリの設定を変更

```
# vim ./pacemaker-1.0.13-1.2.el6.x86_64.repo/pacemaker.repo
```

```
[pacemaker]
name=pacemaker
baseurl=file:///tmp/pacemaker-1.0.13-1.2.el6.x86_64.repo/
```

3. OS標準のリポジトリからPacemaker関連のパッケージがインストールされないようにリポジトリの設定を変更

```
# vim /etc/yum.repos.d/CentOS-Base.repo
```

```
[base]
(省略)
exclude=cluster-glue* corosync* pacemaker* resource-agents*

[updates]
(省略)
exclude=cluster-glue* corosync* pacemaker* resource-agents*
```

PacemakerとHeartbeatパッケージのインストール

4. PacemakerとHeartbeatのパッケージをインストール

```
# cd /tmp/pacemaker-1.0.13-1.2.el6.x86_64.repo
# yum -c pacemaker.repo -y install pacemaker heartbeat
（省略）
Complete!
```

- リポジトリに含まれるそのほかのパッケージ

パッケージ名	説明
pm_crmgen	Excelなどの表計算ソフトで編集したCSVファイルからPacemakerの設定ファイルを生成するツール
pm_diskd	ディスクにアクセスして読み取りを行うことでディスクの監視を行うリソースエージェント
pm_extras	NetVault Backupクライアント用のリソースエージェント（NVclient）、仮想IPアドレスの排他制御によるスプリットブレイン防止用のリソースエージェント（VIPcheck）、ハートビート通信用のネットワークインタフェースの状態を表示する機能（ifcheckd）、STONITH実行時に停止するノードを判断するSTONITHモジュール（stonith-helper）
pm_kvm_tools	KVM上のPacemakerと仮想マシン上のPacemakerを連携する機能
pm_logconv-hb	Pacemaker、Heartbeatのログメッセージを読みやすく変換する機能
vm-ctl	仮想マシンリソースを制御するツール

ELRepoリポジトリの設定

- ELRepoのリポジトリでDRBDをインストール
  - ELRepoとは
    - RHEL系のOS向けに標準でないパッケージを提供するプロジェクト
    - http://elrepo.org/

1. 公開キーをインポート

```
# rpm --import http://www.elrepo.org/RPM-GPG-KEY-elrepo.org
```

   - パッケージの署名をチェックするのに使う

2. リポジトリのパッケージをインストール

```
# rpm -ivh http://www.elrepo.org/elrepo-release-6-5.el6.elrepo.noarch.rpm
http://www.elrepo.org/elrepo-release-6-5.el6.elrepo.noarch.rpm を取得中
準備中...                ########################################### [100%]
   1:elrepo-release      ########################################### [100%]
```

RHEL 6系 `elrepo-release-6-6.el6.elrepo.noarch.rpm`

RHEL 5系 `elrepo-release-5-5.el5.elrepo.noarch.rpm`

DRBDパッケージのインストール

3. DRBDのパッケージをインストール

```
# yum -y kmod-drbd84 drbd84-utils
(省略)
Complete!
```

4. DRBDはPacemakerによって起動されるので、OSの起動時に自動的に起動されないように設定を変更

```
# chkconfig drbd off
$ chkconfig --list drbd
drbd            0:off   1:off   2:off   3:off   4:off   5:off   6:off
```

OSの設定

ファイアウォールの設定

ACT SBY SRA OSS,INC.

- PostgreSQL、Heartbeat、DRBDで使うポートを開く

サービス名	ポート	プロトコル
PostgreSQL	5432	TCP
Heartbeat	694	UDP
DRBD	7788	TCP

1. ファイアウォールの設定を行う

```
# vim /etc/sysconfig/iptables
```

```
-A INPUT -p icmp -j ACCEPT
-A INPUT -i lo -j ACCEPT
-A INPUT -m state --state NEW -m tcp -p tcp --dport 22 -j ACCEPT
-A INPUT -m state --state NEW -m tcp -p tcp --dport 5432 -j ACCEPT
-A INPUT -m state --state NEW -m udp -p udp --dport 694 -j ACCEPT
-A INPUT -m state --state NEW -m tcp -p tcp --dport 7788 -j ACCEPT
-A INPUT -j REJECT --reject-with icmp-host-prohibited
-A FORWARD -j REJECT --reject-with icmp-host-prohibited
COMMIT
```

直接ファイルを編集せずにsystem-config-firewallを使ってもOK

2. ファイアウォールを再起動

```
# service iptables restart
iptables: ファイアウォールルールを消去中:                  [  OK  ]
iptables: チェインをポリシー ACCEPT へ設定中filter         [  OK  ]
iptables: モジュールを取り外し中:                          [  OK  ]
iptables: ファイアウォールルールを適用中:                  [  OK  ]
```

SELinuxの設定

- SELinuxの設定は難しいので無効にする
  - 無効にしないと動かないわけではないが、ちゃんと設定してあげないと動かないこともある

1. SELinuxによるアクセス制御を一時的に無効にする

```
# setenforce 0
```

2. OSの起動時に完全に無効になるようにSELinuxの設定を変更

```
# vim /etc/selinux/config
```

```
# SELINUX= can take one of these three values:
#     enforcing - SELinux security policy is enforced.
#     permissive - SELinux prints warnings instead of enforcing.
#     disabled - No SELinux policy is loaded.
SELINUX=disabled
```

  - アクセス制御自体は無効になっているので、OSを再起動しなくてもOK

Syslogの設定

- PostgreSQL、Pacemaker、DRBDのログが専用のファイルに出力されるようにSyslog(rsyslog)の設定を行う
- Syslogの設定を行う

```
# vim /etc/rsyslog.conf
```

```
#### RULES ####

local0.*                                                /var/log/ha-log
& ~
:msg, contains, "drbd"                                  /var/log/ha-log
& ~
(省略)
*.info;mail.none;authpriv.none;cron.none                /var/log/messages
```

  - ファシリティがlocal0のログと「drbd」を含むログを取得

- Syslogを再起動

```
# service rsyslog restart
システムロガーを停止中:                                  [  OK  ]
システムロガーを起動中:                                  [  OK  ]
```

Heartbeatの設定

Heartbeatの設定

- テンプレートをコピーして設定ファイルを編集

```
# cp /usr/share/doc/heartbeat-3.0.5/ha.cf /etc/ha.d
# vim /etc/ha.d/ha.cf
```

```
pacemaker respawn
logfacility local0
#udpport 694
ucast eth0 192.168.137.101    # alice
ucast eth0 192.168.137.102    # bob
node alice
node bob
（抜粋）
```

「#（番号記号）」から行末まではコメント

- おもなパラメータ
  - pacemaker respawn
    - Pacemakerといっしょに動かすかどうか（動かすならrespawn）を指定
    - テンプレートに書かれていないのでパラメータ自体を追加
  - log_facility local0
    - Syslogファシリティを指定
  - udpport 694
    - ハートビート通信に使うポートを指定

Heartbeatのおもなパラメータ

- おもなパラメータ(続き)
  - `ucast eth0 192.168.137.101  # alice`
    `ucast eth0 192.168.137.102  # bob`
    - ユニキャストによるハートビート通信の設定としてデバイスと相手のIPアドレスを指定
    - 自分のIPアドレスを指定する必要はないが、ノード間で設定ファイルを同じにしておいたほうが管理しやすい
    - マルチキャスト(mcast)、ブロードキャスト(bcast)でも指定できる
  - `node alice`
    `node bob`
    - クラスタに加えるノードを指定
    - ノード名は「uname -n」で返ってくるホスト名と同じでなければならない
- そのほかのパラメータについてはテンプレートのコメントや「man ha.cf」でマニュアルを参照

認証用キーの設定

- ハートビート通信でノードの認証に使うキーの設定を行う

1. 認証用キーファイルのテンプレートをコピー

```
# cp /usr/share/doc/heartbeat-3.0.5/authkeys /etc/ha.d
```

2. rootユーザにしか読めないようにアクセス権を変更

```
# chmod 0600 /etc/ha.d/authkeys
```

3. 認証用キーファイルを編集

```
# vim /etc/ha.d/authkeys
```

```
auth 1
1 sha1 1d55b4aa7fe26469aee71baacd6f8e26e51b7d5c
```

- authの後にどの設定を使うかの番号を指定
- 設定には番号、ハッシュ化方式、認証用キーを指定
- 認証用キーは推測しにくいものであればOK

```
# head -c 8k /dev/urandom | sha1sum
d04675e6abdcb49913a0f94a08d760953cbd9430  -
```

Heartbeatの起動

- 設定ファイルを待機系ノードにコピーし、両方のノードでHeartbeatを起動

ACT

```
# scp /etc/ha.d/ha.cf /etc/ha.d/authkeys bob:/etc/ha.d
root@bob's password: （パスワードを入力）
ha.cf                                         100%   10KB  10.4KB/s   00:00
authkeys                                      100%  700     0.7KB/s   00:00
```

ACT
SBY

```
# service heartbeat start
Starting High-Availability services: Done.
```

- Heartbeatが起動していることを確認

ACT

```
# crm_mon
Version: 1.0.13-30bb
2 Nodes configured,
0 Resources configur
============

Online: [ alice bob ]

（Ctrl＋Cで終了）
```

しばらく待って「Online」の後にすべてのノードが表示されればOK

DRBDの設定

DRBD用パーティションの準備

- DRBD用のパーティションを準備
  - ディスクまたはパーティション（/dev/sdb1など）
  - とりあえず試してみたいだけなら、ループバックデバイス（/dev/loop0など）でもOK

```
# mkdir /srv/images
# dd if=/dev/zero of=/srv/images/pgsql-data.img bs=1M count=1024
1024+0 records in
1024+0 records out
1073741824 bytes (1.1 GB) copied, 5.30452 s, 202 MB/s
# losetup /dev/loop0 /srv/images/pgsql-data.img
# vim /etc/rc.local
```

```
touch /var/lock/subsys/local
losetup /dev/loop0 /srv/images/pgsql-data.img
```

DRBDリソースの設定

- DRBDリソースの設定ファイルを作成し、待機系ノードにコピー

```
# vim /etc/drbd.d/pgsql.res
```

```
resource pgsql {
  protocol C;
  meta-disk internal;
  disk {
    resync-rate 40M;
  }
  on alice {
    device /dev/drbd0;
    disk /dev/loop0;
    address 192.168.137.101:7788;
  }
  on bob {
    device /dev/drbd0;
    disk /dev/loop0;
    address 192.168.137.102:7788;
  }
}
```

```
# scp /etc/drbd.d/pgsql.res bob:/etc/drbd.d
root@bob's password: （パスワードを入力）
pgsql.res                                     100%  321     0.3KB/s   00:00
```

DRBDリソースの起動とデータの初期同期

- メタデータを作成し、DRBDリソースを起動

ACT
SBY

```
# drbdadm create-md pgsql
Writing meta data...
initializing activity log
NOT initializing bitmap
New drbd meta data block successfully created.
success
# drbdadm up pgsql
```

- データの初期同期を行う

ACT

```
# drbdadm disk-options --resync-rate=110M pgsql
# drbd-overview
  0:pgsql/0  Connected Secondary/Secondary Inconsistent/Inconsistent C
r-----
# drbdadm primary --force pgsql
# drbd-overview
  0:pgsql/0  SyncSource Primary/Secondary UpToDate/Inconsistent C r-----
        [=========>.........] sync'ed: 50.4% (524092/1048508)K
# drbd-overview
  0:pgsql/0  Connected Primary/Secondary UpToDate/UpToDate C r-----
# drbdadm adjust pgsql
```

ファイルシステムの作成とマウント

- DRBDデバイスにファイルシステムを作成し、マウント

```
# mkfs.ext4 /dev/drbd0
mke2fs 1.41.12 (17-May-2010)
Discarding device blocks: done
Filesystem label=
(省略)

This filesystem will be automatically checked every 21 mounts or
180 days, whichever comes first.  Use tune2fs -c or -i to override.
# mkdir /mnt/pgsql-data
# mount -t ext4 /dev/drbd0 /mnt/pgsql-data
# df
Filesystem           1K-ブロック     使用    使用可 使用% マウント位置
/dev/mapper/VolGroup-lv_root
                      14006192   5254108   8040612  40% /
tmpfs                   506208        72    506136   1% /dev/shm
/dev/sda1               495844     73912    396332  16% /boot
/dev/drbd0             1032020     17668    961928   2% /mnt/pgsql-data
```

PostgreSQLの設定

データベースクラスタの作成

- DRBDデバイス上のファイルシステムにデータベースクラスタを作成

```
# mkdir /mnt/pgsql-data/data
# chmod 0700 /mnt/pgsql-data/data
# chown postgres:postgres /mnt/pgsql-data/data
# su – postgres
$ /usr/pgsql-9.3/bin/initdb -A md5 -D /mnt/pgsql-data/data -E UTF8 \
>     --locale=C -W
（省略）
新しいスーパーユーザのパスワードを入力してください：（パスワードを入力）
再入力してください：（もう一度パスワードを入力）
（省略）
成功しました。以下を使用してデータベースサーバを起動することができます。

    /usr/pgsql-9.3/bin/postmaster -D /mnt/pgsql-data/data
または
    /usr/pgsql-9.3/bin/pg_ctl -D /mnt/pgsql-data/data -l logfile start

$ ls /mnt/pgsql-data/data
PG_VERSION  pg_hba.conf    pg_serial     pg_subtrans  postgresql.conf
base        pg_ident.conf  pg_snapshots  pg_tblspc
global      pg_multixact   pg_stat       pg_twophase
pg_clog     pg_notify      pg_stat_tmp   pg_xlog
```

PostgreSQLの設定

- リモートホストからの接続を監視し、Syslogでログを取得するようにPostgreSQLの設定を変更

```
$ vim /mnt/pgsql-data/data/postgresql.conf
```

```
listen_addresses = '*'                  # what IP address(es) to listen on;
#port = 5432                            # (change requires restart)
log_destination = 'syslog'              # Valid values are combinations of
logging_collector = off                 # Enable capturing of stderr and csvlog
#syslog_facility = 'LOCAL0'
log_line_prefix = ''                    # special values:
（抜粋）
```

- 同じネットワーク内から接続できるようにクライアント認証の設定を変更

```
$ vim /mnt/pgsql-data/data/pg_hba.conf
```

```
# TYPE  DATABASE        USER            ADDRESS                 METHOD
host    all             all             192.168.137.0/24        md5

# "local" is for Unix domain socket connections only
local   all             all                                     md5
```

PostgreSQLの起動と停止

- PostgreSQLを起動し、ネットワーク越しに接続できることを確認し、停止

```
$ /usr/pgsql-9.3/bin/pg_ctl start -w -D /mnt/pgsql-data/data
サーバの起動完了を待っています....LOG:  ending log output to stderr
HINT:  Future log output will go to log destination "syslog".
完了
サーバ起動完了
$ psql -h alice
パスワード:(パスワードを入力)
psql (9.3.3)
"help" でヘルプを表示します.

=# \q
$ /usr/pgsql-9.3/bin/pg_ctl stop -D /mnt/pgsql-data/data
サーバ停止処理の完了を待っています....完了
サーバは停止しました
$ exit
```

Pacemakerの設定

Pacemakerの設定

- Pacemakerとリソースのデフォルト値の設定を行う

```
# vim pgsql.crm
```

```
property \
    no-quorum-policy="ignore" \
    stonith-enabled="false" \
    startup-fencing="false"

rsc_defaults \
    resource-stickiness="INFINITY" \
    migration-threshold="2" \
    failure-timeout="60s"

（次のページに続く）
```

DRBDマスタスレーブリソースの設定

- DRBDマスタスレーブリソースを作成

```
primitive drbd ocf:linbit:drbd \
    params \
        drbd_resource="pgsql" \
    op start timeout="240s" \
    op stop timeout="100s" \
    op monitor interval="20s" timeout="20s" on_fail="restart" \
    op monitor interval="10s" timeout="20s" on_fail="restart" \
        role="Master" \
    op promote timeout="90s" \
    op demote timeout="90s"

ms ms_drbd drbd \
    meta \
        master-max="1" \
        master-node-max="1" \
        clone-max="2" \
        clone-node-max="1" \
        notify="true"

(次のページに続く)
```

ファイルシステムと仮想IPアドレスリソースの設定

- ファイルシステムと仮想IPアドレスリソースを作成

```
primitive filesystem ocf:heartbeat:Filesystem \
    params \
        device="/dev/drbd0" \
        directory="/mnt/pgsql-data" \
        fstype="ext4" \
    op start timeout="60s" \
    op stop timeout="60s" \
    op monitor interval="20s" timeout="40s" on_fail="restart"

primitive ipaddr ocf:heartbeat:IPaddr2 \
    params \
        ip="192.168.137.201" \
        nic="eth0" \
        cidr_netmask="24" \
    op start timeout="20s" \
    op stop timeout="20s" \
    op monitor interval="10s" timeout="20s" on_fail="restart"
```

(次のページに続く)

PostgreSQLグループリソースの設定

- PostgreSQLグループリソースを作成

```
primitive pgsql ocf:heartbeat:pgsql \
    params \
        pgctl="/usr/pgsql-9.3/bin/pg_ctl" \
        start_opt="-p 5432" \
        psql="/usr/bin/psql" \
        pgdba="postgres" \
        pgdata="/mnt/pgsql-data/data" \
        pgport="5432" \
        monitor_user="postgres" \
        monitor_password="password" \
    op start timeout="120s" \
    op stop timeout="120s" \
    op monitor interval="30s" timeout="30s" on_fail="restart"

group group_pgsql \
    filesystem ipaddr pgsql

colocation group_pgsql_and_ms_drbd_master \
    inf: group_pgsql ms_drbd:Master

order ms_drbd_promote_before_group_pgsql_start \
    inf: ms_drbd:promote group_pgsql:start
```

設定のロード

- ファイルから設定をロードしてリソースを作成

```
# crm configure load replace pgsql.crm
crm_verify[2199]: 2014/02/27_14:50:29 WARN: unpack_nodes: Blind faith:
not fencing unseen nodes
# crm_mon -r
```

```
============
Last updated: Thu Feb 27 14:51:25 2014
Stack: Heartbeat
Current DC: bob (e6cb12d9-acdc-45c7-ab3c-6f969e9d1665) - partition with
quorum
Version: 1.0.13-30bb726
2 Nodes configured, unknown expected votes
2 Resources configured.
============

Online: [ alice bob ]

 Resource Group: group_pgsql
     filesystem (ocf::heartbeat:Filesystem):    Started bob
     ipaddr     (ocf::heartbeat:IPaddr2):       Started bob
     pgsql      (ocf::heartbeat:pgsql): Started bob
 Master/Slave Set: ms_drbd
     Masters: [ bob ]
     Slaves: [ alice ]
```

動作確認

PowerGres HA Pacemaker版とは

- PowerGres＋Pacemaker for PowerGres
- オープンソースのHAクラスタソフトを採用し、PowerGres向けに機能を絞り、リーズナブルな価格で提供
- 24時間365日のサポートも提供

11/20プレスリリース：http://www.sraoss.co.jp/company/press/2013/1120.php

PowerGresでPostgreSQLの信頼性をより高めよう
http://www.sraoss.co.jp/event_seminar/2013/20131127_powergres-plus-and-ha.pdf

オープンソースとともに

SRA OSS, INC.