

OpenBGPD Illustrated

Masakazu Asama @ EBUG

OpenBGPD とは？

- OpenBGPD は Open Source(BSD License) な Border Gateway Protocol Version 4(BGP-4) の実装のひとつ
- OpenBSD Project の一部として Henning Brauer と Claudio Jeker を中心に開発されている
- FreeBSD では `ports/net/openbgpd` で利用可能
- 他の BSD にも簡単に移植可能と思われるがそれ以外の OS に移植する為には Routing Socket の操作に関する部分を書き直す必要があるため今のところは利用できない(と思われる)

BGP-4 とは？


- BGP-4 はインターネットの中核をなすルーティングプロトコル
- インターネットを自立システム(AS: おおよそ ISP のことを指していると考えて良い)の集合と考え AS 間におけるルーティング情報の交換をするためのプロトコル
- もともとは IPv4 ネットワークのこのみ考えたプロトコルだったが Multiprotocol Extensions for BGP-4(RFC4760) により他のプロトコルもサポート可能となり IPv6 も Use of BGP-4 Multiprotocol Extensions for IPv6 Inter-Domain Routing(RFC2545) によりサポートされている

BGP-4 の基本動作(0)


AS64512

片方の BGP-4 ルーターから
もう片方の BGP-4 ルーターに対して
TCP/179 コネクションを確立


AS64513




BGP-4 の基本動作(I)




BGP-4 の基本動作(2)




BGP-4 の基本動作(3)



BGP-4 の基本動作(4)



BGP-4 の基本動作(5)



UPDATE for IPv4


- Withdrawn Route Length 2
- Withdrawn Routes
 - 192.168.98.0/24
 - 192.168.99.0/24
- Total Path Attribute Length 3
- Path Attributes
 - ORIGIN IGP
 - AS_PATH 64513
 - NEXT_HOP 192.168.0.1
- Network Layer Reachability Info
 - 192.168.1.0/24
 - 192.168.2.0/24

UPDATE for IPv6

- Withdrawn Route Length 0
- Withdrawn Routes
- Total Path Attribute Length 4
- Path Attributes
 - ORIGIN IGP
 - AS_PATH 64513
 - MP_REACH_NLRI
 - Address family IPv6
 - Subsequent a.f. Unicast
 - Next hop 2001:db8::1
 - NLRI
 - 2001:db8:0:1::/64
 - 2001:db8:0:2::/64
 - MP_UNREACH_NLRI
 - Address family IPv6
 - Subsequent a.f. Unicast
 - Withdrawn routes
 - 2001:db8:0:98::/64
 - 2001:db8:0:99::/64
- Network Layer Reachability Info

OpenBGPD の特徴(1)

- 機能毎に 3 つのプロセスを稼働させる
 - ❖ Parent: 以下の 2 つのプロセスの親プロセス. 唯一 root 権限で chroot もされずに稼働するプロセス. 設定ファイルの再読み込みや Routing socket との通信等を行う.
 - ❖ Session Engine: 他の BGP ルーターとのセッションを管理するプロセス. bgpctl コマンドからの Unix socket 接続も受け付ける.
 - ❖ Route Decision Engine: 他のルーターから受け取った情報と自分自身の情報をもとにルーティングテーブルを計算する.
- Route Decision と Session を分離することでルーティング計算の最中でもあっても確実にセッションを保持することが可能となる



OpenBGPD の特徴(2)

- いわゆる CLI は用意されていない
 - かわりに設定ファイル `/etc/bgpd.conf` で設定を行う
 - 設定を変更したいときは `/etc/bgpd.conf` を書き換え後コマンドラインから `bgpctl reload` を実行する
 - 設定の読み込みと反映は `atomically` に行われる
 - 通常のコマンド `bgpctl` を用いて
 - ❖ 他のルーターとの接続状態を確認
 - ❖ 他のルーターとの接続を切断
 - ❖ 他のルーターから収集した情報を表示
- といった処理を行えるためシェルスクリプトによる自動化等を容易に実現することが可能となる

Example of bgpd.conf

```
AS 64512
router-id 192.168.0.1
network 192.168.0.1/24
network 2001:db8::/64
group "peering AS64513" {
    remote-as 64513
    neighbor 192.168.0.2 {
        descr    "AS64513 IPv4"
        local-address 192.168.0.1
        announce IPv4 unicast
        announce IPv6 none
    }
    neighbor 2001:db8::2 {
        descr    "AS64513 IPv6"
        local-address 2001:db8::1
        announce IPv4 none
        announce IPv6 unicast
    }
}
group "peering AS64514" {
    remote-as 64514
    neighbor 192.168.0.3 {
        descr    "AS64514 IPv4"
        local-address 192.168.0.1
        announce IPv4 unicast
        announce IPv6 none
    }
}
deny from any inet
allow from any inet prefixlen 8 - 24
deny from any prefix 0::/0 prefixlen <= 128
allow from any prefix 0::/0 prefixlen <= 48
```



Parent

- Configuration ファイルの parse 処理
 - ❖ pfctl と同じく yacc で構文解析を行う
 - ❖ 解析内容に基づき bgpd_config や peer, network, filter_rule といった構造体に内容を格納する
- Route Decision Engine からの要求による処理
 - ❖ ルーティング情報の変更/削除の要求があったとき
 - ❖ Next Hop/pftable の追加/削除依頼があったとき
- Session Engine からの要求による処理
 - ❖ Configuration の再読み込み要求があったとき
 - ❖ show nexthop/show interface 等の show 系コマンドがあったとき
 - ❖ 等々...

Session Engine

- bgpctl からの接続を待つ UNIX domain socket の準備
- bgpctl から接続があったときには Parent や Route Decision Engine から適宜情報を収集し結果を表示したり, Parent や Route Decision Engine に対して変更要求をだしたりする
- 各 peer(neighbor) 毎に FSM(Finite State Machine: 後述) を初期化
- 各 peer(neighbor) を Established 状態まで持っていく
- peer(neighbor) から受け取った UPDATE message を Route Decision Engine に渡したり, 逆に経路が増えたり減ったりした際には UPDATE message を peer(neighbor) に渡したりする

Finite State Machine



```

void
bgp_fsm(struct peer *peer, enum session_events event)
{
    switch (peer->state) {
    case STATE_NONE:
        /* nothing */
        break;
    case STATE_IDLE:
        switch (event) {
        case EVNT_START:
            ...
            break;
        default:
            /* ignore */
            break;
        }
        break;
    case STATE_CONNECT:
        switch (event) {
        case EVNT_START:
            /* ignore */
            break;
        case EVNT_CON_OPEN:
            session_tcp_established(peer);
            session_open(peer);
            ...
            change_state(peer, STATE_OPENSENT, event);
            break;
        ...
        }
        break;
    ...
    }
}

```



```

void
change_state(struct peer *peer, enum session_state state, enum session_events event)
{
    ...
    switch (state) {
    case STATE_IDLE:
        ...
        timer_stop(peer, Timer_IdleHoldReset);
        session_close_connection(peer);
        ...
        if (peer->state == STATE_ESTABLISHED)
            session_down(peer);
        ...
        break;
    case STATE_CONNECT:
        break;
    case STATE_ACTIVE:
        break;
    case STATE_OPENSENT:
        break;
    case STATE_OPENCONFIRM:
        break;
    case STATE_ESTABLISHED:
        timer_set(peer, Timer_IdleHoldReset, peer->IdleHoldTime);
        ...
        session_up(peer);
        break;
    default:      /* something seriously fucked */
        break;
    }
    ...
    peer->prev_state = peer->state;
    peer->state = state;
}

```

Route Decision Engine

- Session Engine から受け取った UPDATE message を蓄積し RIB(Routing Information Base) を構築する
- 構築した RIB からある prefix への最適な path を計算し Parent に対してルーティングテーブルを更新するよう依頼する

II

Route Decision Process

- Session Engine を通じて他の peer(neighbor) に UPDATE message を送る

Routing Information Base

- RFC4271 には以下の 3 つの RIB について記載されている
 - ❖ Adj-RIBs-In: peer(neighbor) から受信した経路がそのまま格納される.
 - ❖ Loc-RIB: Adj-RIBs-In に対してローカルポリシーを適用した結果が格納される.
 - ❖ Adj-RIBs-Out: peer(neighbor) へ送信する経路が格納される.
ただし上記の RIB を必ず実装しなければならないわけではない
- OpenBGPD では Adj-RIBs-In と Loc-RIB の 2 つと Configuration に応じた RIB が用意される

UPDATE 受信処理(I)

- `rde_update_dispatch(...)`
 - ❖ 受信した UPDATE message につき 1 回実行される.
`rde_attr_parse(...)` により attributes を parse し
`rde_aspath` 構造体を構築する. Withdraw なら
`rde_update_withdraw(...)` を, NLRI なら
`rde_update_update(...)` をそれぞれ実行する.
- `rde_update_update(...)`
 - ❖ UPDATE message 中に含まれる prefix 1 つにつき 1 回実行される.
RIB の数だけ `path_update(...)` を呼び出す.


UPDATE 受信処理(2)

- `path_update(...)`
 - ❖ すでに該当する `prefix` 構造体が存在し更新の必要がある場合は `prefix_move(...)` を実行する.`prefix` 構造体が存在しない場合は `prefix_add(...)` を実行する.`prefix` 構造体が存在し更新の必要がない場合は `lastchange` 変数を更新するだけ.
- `prefix_add(...)`
 - ❖ 該当する `prefix` 構造体が存在しない場合新しい `prefix` 構造体を用意し `prefix_link(...)` を実行する.存在し更新の必要がある場合は `prefix_move(...)` を実行する.ない場合は `lastchange` 変数を更新するだけ.

UPDATE 受信処理(3)

- `prefix_link(...)`
 - ❖ `prefix` 構造体と `rib_entry` 構造体, `rde_aspath` 構造体を接続し `prefix_evaluate(...)` を実行する.
- `prefix_evaluate(...)`
 - ❖ `rib_entry` の `prefix_h(prefix 構造体のリスト)` にベストな `prefix` 構造体为先頭にくるよう挿入し `active` がその `prefix` を向くようにする.
- `prefix_cmp(...)`
 - ❖ 2つの `prefix` のうちどちらがベストかを判定する. `NEXT_HOP` の到達性, `LOCAL_PREF` 属性値, `AS_PATH` 属性の長さ, `ORIGIN` 属性値, `MED` 属性値, ... 等々を比較し決定する.

Example Scenario



Step 0.

struct rib		Adj-RIB-In
name: char[PEER_DESCR_LEN]		
rib: RB_HEAD		
state: enum rib_state		
flags: u_int16_t		
id: u_int16_t		
struct rib		Loc-RIB
name: char[PEER_DESCR_LEN]		
rib: RB_HEAD		
state: enum rib_state		
flags: u_int16_t		
id: u_int16_t		


peer A

struct rde_peer	
hash_l: LIST_ENTRY	
peer_l: LIST_ENTRY	
path_h: LIST_HEAD	
:	


peer B

struct rde_peer	
hash_l: LIST_ENTRY	
peer_l: LIST_ENTRY	
path_h: LIST_HEAD	
:	


Step 1.




Step 2.




Step 3.



Best path lookup for 192.168.1.0/24



RDE memory statistics



The image shows a terminal window titled "ターミナル — ssh — 80x24" displaying the output of the command `# bgpctl show rib memory`. The output lists various memory statistics for the RDE. To the right of the terminal, there are seven white boxes with black text, each containing an annotation. Arrows point from these boxes to specific lines in the terminal output:

- `allocated struct pt_entry4` points to the line `308197 IPv4 network entries using 9.4M of memory`.
- `allocated struct pt_entry6` points to the line `2231 IPv6 network entries using 95.9K of memory`.
- `allocated struct prefix` points to the line `500756 prefix entries using 15.3M of memory`.
- `allocated struct rde_aspath` points to the line `88219 BGP path attribute entries using 6.7M of memory,`.
- `allocated struct aspath` points to the line `79072 BGP AS-PATH attribute entries using 3.1M of memory,`.
- `allocated struct attr` points to the line `5684 BGP attributes entries using 133K of memory`.
- `allocated struct attr's data` points to the line `5683 BGP attributes using 44.4K of memory`.

```
# bgpctl show rib memory
RDE memory statistics
308197 IPv4 network entries using 9.4M of memory
 2231 IPv6 network entries using 95.9K of memory
500756 prefix entries using 15.3M of memory
 88219 BGP path attribute entries using 6.7M of memory
 79072 BGP AS-PATH attribute entries using 3.1M of memory,
      and holding 88219 references
 5684 BGP attributes entries using 133K of memory
      and holding 17157 references
 5683 BGP attributes using 44.4K of memory
RIB using 34.8M of memory
#
```

参考情報

- OpenBGPD - bringing full views to OpenBSD since 2004 by Claudio Jeker
- <http://2009.asiabsdcon.org/papers/abc2009-P2A-paper.pdf>
❖ AsiaBSDCon 2009 Tokyo, 12-15 March, 2009 の発表資料
- The Design and Implementation of OpenBGPd by André Oppermann and Claudio Jeker
- <http://www.networx.ch/The%20Design%20and%20Implementation%20of%20OpenBGPd.pdf>
❖ SWINOG-9 Berne, 29. September 2004 の発表資料
- A secure BGP implementation by Henning Brauer
- http://2004.eurobsdcon.org/uploads/media/EBSD04_slides_44.pdf
❖ EuroBSDCon 2004 in Karlsruhe, 2004 の発表資料
- RFC4271: A Border Gateway Protocol 4 (BGP-4)
- <http://tools.ietf.org/html/4271>
- RFC4760 Multiprotocol Extensions for BGP-4
- <http://tools.ietf.org/html/4760>
- RFC2545 Use of BGP-4 Multiprotocol Extensions for IPv6 Inter-Domain Routing
- <http://tools.ietf.org/html/2545>