



OpenvSwitch で作る透過 L3DSR

Akira KAMIO

whoami

神尾 皓 (Akira KAMIO)

- 株式会社サイバーエージェント
 - CyberAgent group Infrastructure Unit (CIU)
 - Cyccloud Div, Compute Team
- 2020/06 中途入社
 - 入社以来、一貫してIaaS基盤の開発/運用業務に従事
 - Qemu/KVM や高集約コンピュータノードの最適化に興味がある

Contents

1.L3DSR とは

2.透過 L3DSR の設計

3.Open vSwitch 実装

4.まとめ



1

L3DSR とは




L3DSR について

- Inline 構成

- リクエストを LB で NAT して、レスポンスも LB を経由する


- L3DSR 構成

- リクエストを LB で NAT せず real server へ送信
- レスポンスは real server から直接返す
- L3 を跨いだ NW 構成が可能 -> 柔軟性が高い



L3DSR の実装方法

- DSCP (TOS)
 - リクエストパケットに DSCP bit を付与して real server へ転送
- IPIP
 - リクエストパケットを IPIP でカプセルして real server へ転送
- GRE
 - リクエストパケットを GRE でカプセルして real server へ転送



L3DSR の課題

- サーバ側に L3DSR の設定が必要
 - DSCP -> iptable で特定の DSCP bit が立っているときに曲げる
 - IPIP -> IPIP トンネル I/F を作成
 - GRE -> GRE トンネル I/F を作成

L3DSR の課題

- サーバ側に L3DSR の設定が必要
 - DSCP -> iptable で特定の DSCP bit が立っているときに曲げる
 - IPIP -> IPIP トンネル I/F を作成
 - GRE -> GRE トンネル I/F を作成

サーバに特別な設定を入れずに L3DSR できたら嬉しい！

2

透過 L3DSR の設計



透過 L3DSR の要件


- ・サーバに特別な設定を入れなくて良いようにする
=>ハイパーバイザ上で
 - ・リクエスト:VIP 宛の dsr IP を Server IP に変換
 - ・レスポンス:Client 宛のパケットの src IP を VIP に変換

透過 L3DSR の要件

- ・サーバに特別な設定を入れなくて良いようにする
=>ハイパーバイザ上で
 - ・リクエスト:VIP 宛の dsr IP を Server IP に変換
 - ・レスポンス:Client 宛のパケットの src IP を VIP に変換

透過 L3DSR の要件

- ・サーバに特別な設定を入れなくて良いようにする
=>ハイパーバイザ上で
 - ・リクエスト:VIP 宛の dsr IP を Server IP に変換
 - ・レスポンス:Client 宛のパケットの src IP を VIP に変換



L3DSR 宛の変換したパケットをすべて覚えている必要がある

3

Open vSwitch 実装



第1稿: DSCP パターン

・まずは DSCP パターンについて検討した

CLI -> LB
SRC IP: CLI IP
DST IP: VIP

- ・あくまで色付けとしての利用のため既存の NW に影響しないように設定する必要がある
 - ・IP Precedence 部をフルビットにしない
 - ・IP Precedence 部フルビットはネットワーク機器によっては制御パケットとして認識されてしまう
- ・そのため DSCP は 1-47 (48 から IP Precedence 部がフルビット) を色付け用として用いる

LB -> OVS
SRC IP: CLI IP
DST IP: VM IP
TOS: 32

例:

CLI IP: 124.0.124.100

VIP: 203.80.24.55

VM IP: 10.200.100.88

TOS: 32

OVS -> VM
SRC IP: CLI IP
DST IP: VM IP

TOS の値が 32 のときに VIP 宛の通信を reg0 に記録

```
ovs-ofctl add-flow br0 "table=0, priority=100, ip, nw_dst=10.200.100.88  
actions=load:NXM_NX_IP_TOS[]->NXM_NX_REG0[], goto_table:1"
```

VM -> OVS
SRC IP: VM IP
DST IP: CLI IP


reg0 が 32 (TOS の値) のときに SRC IP を VIP に書き換える

```
ovs-ofctl add-flow br0 "table=1, priority=110, ip, nw_src=10.200.100.88, reg0=0x20  
actions=mod_nw_src:203.80.24.55, normal"
```

OVS -> CLI
SRC IP: VIP
DST IP: CLI IP

第1稿: DSCP パターン

- ・まずは DSCP パターンについて検討した



第1稿: DSCP パターン

・まずは DSCP パターンについて検討した

CLI -> LB
SRC IP: CLI IP
DST IP: VIP

LB -> OVS
SRC IP: CLI IP
DST IP: VM IP
TOS: 32

OVS -> VM
SRC IP: CLI IP
DST IP: VM IP

VM -> OVS
SRC IP: VM IP
DST IP: CLI IP

OVS -> CLI
SRC IP: VIP
DST IP: CLI IP

- ・あくまで色付けとしての利用のため既存の NW に影響しないように設定する必要がある
 - ・IP Precedence 部をフルビットにしない
 - ・IP Precedence 部フルビットはネットワーク機器によっては制御パケットとして認識されてしまう
 - ・そのため DSCP は 1-47 (48 から IP Precedence 部がフルビット) を色付け用として用いる

例:

CLI IP: 124.0.124.100

VIP: 203.80.24.55

VM IP: 10.200.100.88

TOS: 32

TOS の値が 32 のときに VIP 宛の通信を reg0 に記録

```
ovs-ofctl add-flow br0 "table=0, priority=100, ip, nw_dst=10.200.100.88  
actions=load:NXM_NX_IP_TOS[]->NXM_NX_REG0[], goto_table:1"
```

reg0 が 32 (TOS の値) のときに SRC IP を VIP に書き換える

```
ovs-ofctl add-flow br0 "table=1, priority=110, ip, nw_src=10.200.100.88, reg0=0x20  
actions=mod_nw_src:203.80.24.55, normal"
```

第1稿: DSCP パターン

ボツ

・まずは DSCP パターンについて検討した

CLI -> LB
SRC IP: CLI IP
DST IP: VIP

LB -> OVS
SRC IP: CLI IP
DST IP: VM IP
TOS: 32

OVS -> VM
SRC IP: CLI IP
DST IP: VM IP

VM -> OVS
SRC IP: VM IP
DST IP: CLI IP

OVS -> CLI
SRC IP: VIP
DST IP: CLI IP

- ・あくまで色付けとしての利用のため既存の NW に影響しないように設定する必要がある
 - ・IP Precedence 部をフルビットにしない
 - ・IP Precedence 部フルビットはネットワーク機器によっては制御パケットとして認識されてしまう
 - ・そのため DSCP は 1-47 (48 から IP Precedence 部がフルビット) を色付け用として用いる

例:

CLI IP: 124.0.124.100

VIP: 203.80.24.55

VM IP: 10.200.100.88

TOS: 32

TOS の値が 32 のときに VIP 宛の通信を reg0 に記録

```
ovs-ofctl add-flow br0 "table=0, priority=100, ip, nw_dst=10.200.100.88  
actions=load:NXM_NX_IP_TOS[]->NXM_NX_REG0[], goto_table:1"
```

reg0 が 32 (TOS の値) のときに SRC IP を VIP に書き換える

```
ovs-ofctl add-flow br0 "table=1, priority=110, ip, nw_src=10.200.100.88, reg0=0x20  
actions=mod_nw_src:203.80.24.55, normal"
```

第1稿: DSCP パターン

ボツ

・まずは DSCP パターンについて検討した

CLI -> LB
SRC IP: CLI IP
DST IP: VIP

LB -> OVS
SRC IP: CLI IP
DST IP: VM IP
TOS: 32

OVS -> VM
SRC IP: CLI IP
DST IP: VM IP

- ・あくまで色付けとしての利用のため既存の NW に影響しないように設定する必要がある
 - ・IP Precedence 部をフルビットにしない
 - ・IP Precedence 部フルビットはネットワーク機器によっては制御パケットとして認識されてしまう
 - ・そのため DSCP は 1-47 (48 から IP Precedence 部がフルビット) を色付け用として用いる

例:

CLI IP: 124.0.124.100

VIP: 203.80.24.55

VM IP: 10.200.100.88

TOS: 32

**DSCP bit と VIP の紐づけを管理するエージェントが必要
OVS の flow rule だけで実現する方法があるはず ... !**

SRC IP: VIP
DST IP: CLI IP

```
ovs-vsctl add-flow table 1, priority 110, ip, nw_src 10.200.100.88, reg0 0x20  
actions=mod_nw_src:203.80.24.55, normal"
```

第2稿: IP/IP パターン

- ・IPIP であれば VIP の紐づけを管理しなくて良い... !


CLI -> LB
SRC IP: CLI IP
DST IP: VIP

LB -> OVS
SRC IP: VIP IP
DST IP: VM IP
inner SRC IP: CLI IP
inner DST IP: VIP IP

OVS -> VM
SRC IP: CLI IP
DST IP: VM IP

VM -> OVS
SRC IP: VM IP
DST IP: CLI IP

OVS -> CLI
SRC IP: VIP
DST IP: CLI IP



第2稿: IP/IP パターン

- ・IPIP であれば VIP の紐づけを管理しなくて良い... !


CLI -> LB
SRC IP: CLI IP
DST IP: VIP

LB -> OVS
SRC IP: VIP IP
DST IP: VM IP
inner SRC IP: CLI IP
inner DST IP: VIP IP

OVS -> VM
SRC IP: CLI IP
DST IP: VM IP

VM -> OVS
SRC IP: VM IP
DST IP: CLI IP

OVS -> CLI
SRC IP: VIP
DST IP: CLI IP



第2稿: IPIP パターン

- ・IPIP であれば VIP の紐づけを管理しなくて良い... !

OVS OVS に入ってくるパケット

SRC IP: LB_IP


DST IP: VM_IP

inner SRC IP: CLI_IP

inner DST IP: VIP_IP

(1) ip_proto=4, src=LB_IP

(2) eBPF で IPIP パケットを GRE パケットに変換、再送



(3) conntrack, ct_mark=0x04 を記録 tun_src->reg0 (CLI_IP), tun_dst->reg1 (VIP_IP)
SRC: CLI_IP, DST: VM_IP のパケットを action NORMAL に託す


(4) 返りのパケットは SRC: VM_IP, DST: CLI_IP
conntrack に載っている && ct_mark=0x04 のとき SRC IP を reg0 (VIP IP) に書き換え

第2稿: IPIP パターン

- ・IPIP であれば VIP の紐づけを管理しなくて良い... !

OVS OVS に入ってくるパケット
SRC IP: LB_IP
DST IP: VM_IP
inner SRC IP: CLI_IP
inner DST IP: VIP_IP

OVS の flow rule だけで完結して上手くいきそう ... !



(1) ip_proto=4, src=LB_IP
(2) eBPF で IPIP パケットを GRE パケットに変換、再送
(3) conntrack, ct_mark=0x04 を記録 tun_src->reg0 (CLI_IP), tun_dst->reg1 (VIP_IP)
SRC: CLI_IP, DST: VM_IP のパケットを action NORMAL に託す

(4) 返りのパケットは SRC: VM_IP, DST: CLI_IP
conntrack に載っている && ct_mark=0x04 のとき SRC IP を reg0 (VIP IP) に書き換え


第2稿: IPIP

ボツ

- ・IPIP であれば VM の紐づけを管理しなくて良い... !

OVS OVS に入ってくるパケット
SRC IP: LB_IP
DST IP: VM_IP
inner SRC IP: CLI_IP
inner DST IP: VIP_IP

OVS の flow rule だけで完結して上手くいきそう ... !



(1) ip_proto=4, src=LB_IP
(2) eBPF で IPIP パケットを GRE パケットに変換、再送
(3) conntrack, ct_mark=0x04 を記録 tun_src->reg0 (CLI_IP), tun_dst->reg1 (VIP_IP)
SRC: CLI_IP, DST: VM_IP のパケットを action NORMAL に託す

(4) 返りのパケットは SRC: VM_IP, DST: CLI_IP
conntrack に載っている && ct_mark=0x04 のとき SRC IP を reg0 (VIP IP) に書き換え

第2稿: IPIP

ボツ


- ・IPIP であれば VM の紐づけを管理しなくて良い... !

OVS OVS に入ってくるパケット
SRC IP: LB_IP
DST IP: VM_IP
inner SRC IP: CLI_IP
inner DST IP: VIP_IP

OVS の flow rule だけで完結して上手くいきそう ... !

(1) ip_proto=4, src=LB_IP

(2) eBPF で IPIP パケットを GRE パケットに変換、再送



GRE に変換するくらいなら最初から GRE 方式で送ればよい

conntrack に載っている && cli_mark=0x04 のところを SRC IP を reg0 (VIP IP) に書き換え

第3稿: GRE パターン

- パケットの流れは IPIP とほぼ変わらない (IPIP -> GRE になる)


CLI -> LB
SRC IP: CLI IP
DST IP: VIP

LB -> OVS
SRC IP: VIP IP
DST IP: VM IP
inner SRC IP: CLI IP
inner DST IP: VIP IP

OVS -> VM
SRC IP: CLI IP
DST IP: VM IP

VM -> OVS
SRC IP: VM IP
DST IP: CLI IP

OVS -> CLI
SRC IP: VIP
DST IP: CLI IP



第3稿: GRE パターン

- パケットの流れは IPIP とほぼ変わらない (IPIP -> GRE になる)


CLI -> LB
SRC IP: CLI IP
DST IP: VIP

LB -> OVS
SRC IP: VIP IP
DST IP: VM IP
inner SRC IP: CLI IP
inner DST IP: VIP IP

OVS -> VM
SRC IP: CLI IP
DST IP: VM IP


VM -> OVS
SRC IP: VM IP
DST IP: CLI IP

OVS -> CLI
SRC IP: VIP
DST IP: CLI IP



第3稿: GRE パターン

OVS




(1) GRE かつ LB IP の場合 decap アクションで GRE decap
ip_proto=47, src=LB_IP, actions=decap

(2) conntrack zone=47, VIP を CT_MARK に記録
move:NXM_OF_IP_DST[]->NXM_NX_CT_LABEL[0..31]

(3) conntrack zone=47 のものの IP SRC を CT_MARK に記録していた VIP に書き換え
move:NXM_NX_CT_LABEL[0..31]->NXM_OF_IP_SRC[]

第3稿: GRE パターン

OVS




机上では上手く行きそう ... !

- (1) GRE かつ LB IP の場合 decap アクションで GRE decap
ip_proto=47, src=LB_IP, actions=decap
- (2) conntrack zone=47, VIP を CT_MARK に記録
move:NXM_OF_IP_DST[]->NXM_NX_CT_LABEL[0..31]
- (3) conntrack zone=47 のものの IP SRC を CT_MARK に記録していた VIP に書き換え
move:NXM_NX_CT_LABEL[0..31]->NXM_OF_IP_SRC[]

第3稿: GRE トンネル

OVS



机上では上手く行きそう ... !

- (1) GRE かつ LB IP の場合 decap アクションで GRE decap
ip_proto=47, src=LB_IP, actions=decap
- (2) conntrack zone=47, VIP を CT_MARK に記録
move:NXM_OF_IP_DST[]->NXM_NX_CT_LABEL[0..31]
- (3) conntrack zone=47 のものの IP SRC を CT_MARK に記録していた VIP に書き換え
move:NXM_NX_CT_LABEL[0..31]->NXM_OF_IP_SRC[]

第3稿: GRE ーション

ボツ

OVS

bond

br-phy

机上では上手く行きそう ... !

(1) GRE かつ LB IP の場合 decap アクションで GRE decap
ip_proto=47, src=LB_IP, actions=decap

GRE のパケットがマッチしていない

cookie=0x0, duration=586.160s, table=0, **n_packets=0**, n_bytes=0,
priority=200, ip, in_port="dsr-dhcp", nw_src=10.255.4.0/22, nw_proto=47 actions=decap(), ct(table=1, zone=10)

(3) conntrack zone 47 の 0x00000000 IP SRC を CT_MARK に記録していた IP へ置換え
move:NXM_NX_CT_LABEL[0..31]->NXM_OF_IP_SRC[]

br-ext

第3稿: GRE ボン

OVS

bond

br-phy

机上では上手く行きそう ... !

(1) GRE かつ LB IP の場合 decap アクションで GRE decap
ip_proto=47, src=LB_IP, actions=decap

GRE のパケットがマッチしていない

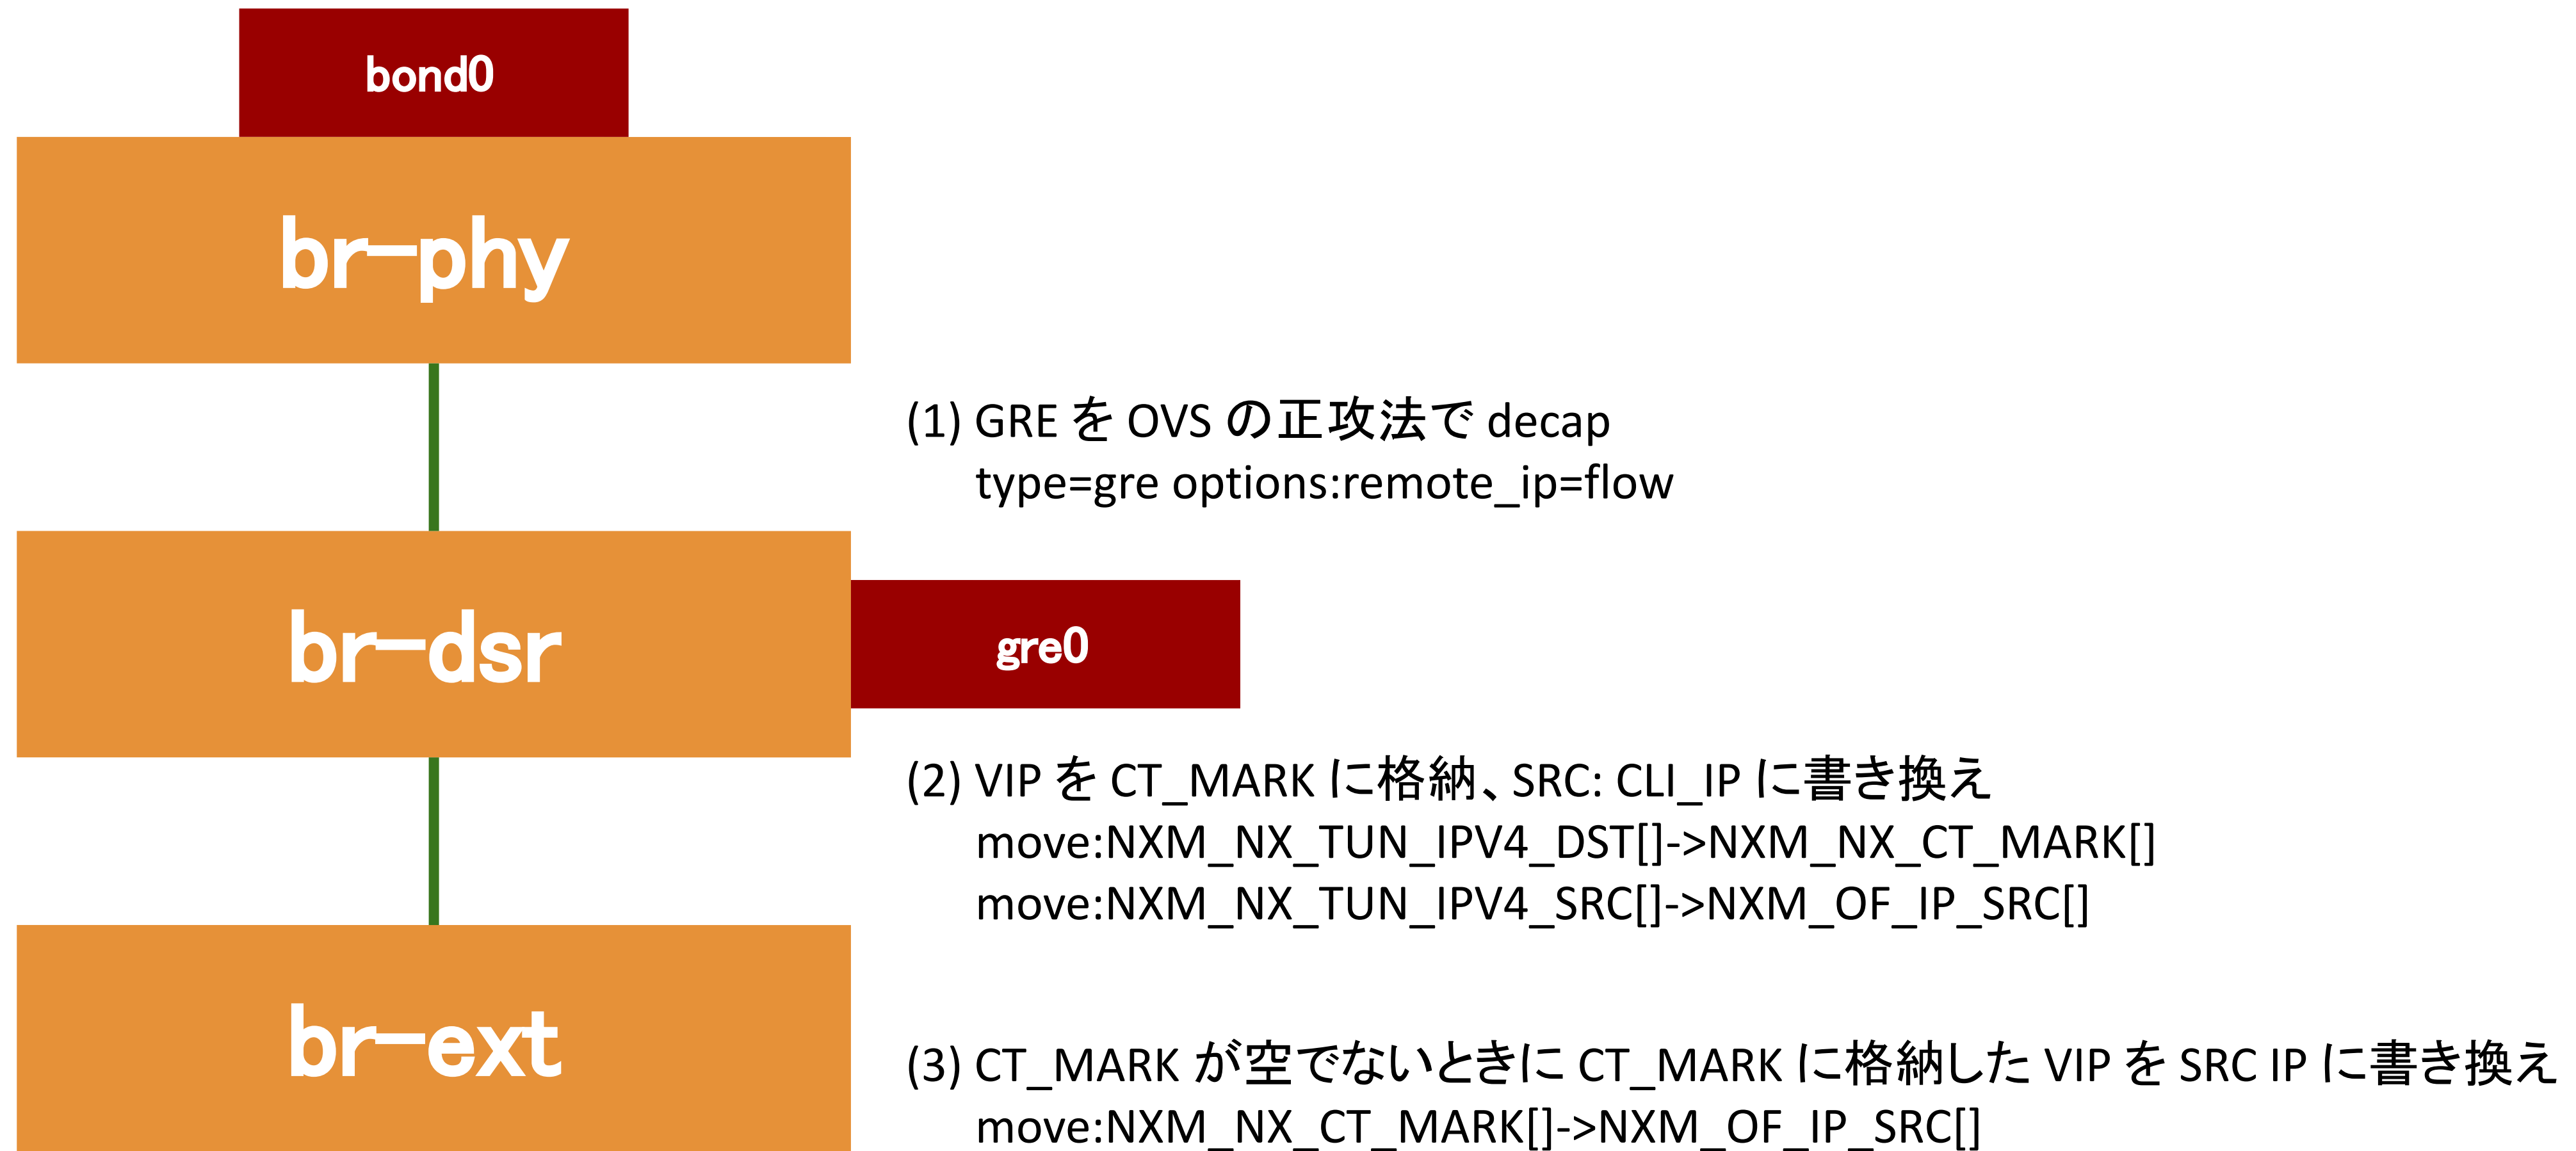
cookie=0x0, duration=586.160s, table=0, **n_packets=0**, n_bytes=0,
priority=200, ip, in_port="dss-dhcp", nw_src=10.255.4.0/22, nw_proto=47 actions=decap(), ct(table=1, zone=10)

(3) controller zone 47 の OVS の IP SRC と CT_MARK に記録された IP に一致し
NVM1_NX_CT_LABEL[0-31] = NVM1_OF_IP_SRC[0-31]

OpenvSwitch で GRE は decap アクションで decap できない


第N稿: GRE パターン

OVS



第N稿: GRE パターン

OVS



さすがに上手く行きそう ... !


(1) GRE を OVS の正攻法で decap
type=gre options:remote_ip=flow

(2) VIP を CT_MARK に格納、SRC: CLI_IP に書き換え
move:NXM_NX_TUN_IPV4_DST[]->NXM_NX_CT_MARK[]
move:NXM_NX_TUN_IPV4_SRC[]->NXM_OF_IP_SRC[]

(3) CT_MARK が空でないときに CT_MARK に格納した VIP を SRC IP に書き換え
move:NXM_NX_CT_MARK[]->NXM_OF_IP_SRC[]

第N稿: GRE トー

OVS



さすがに上手く行きそう ... !

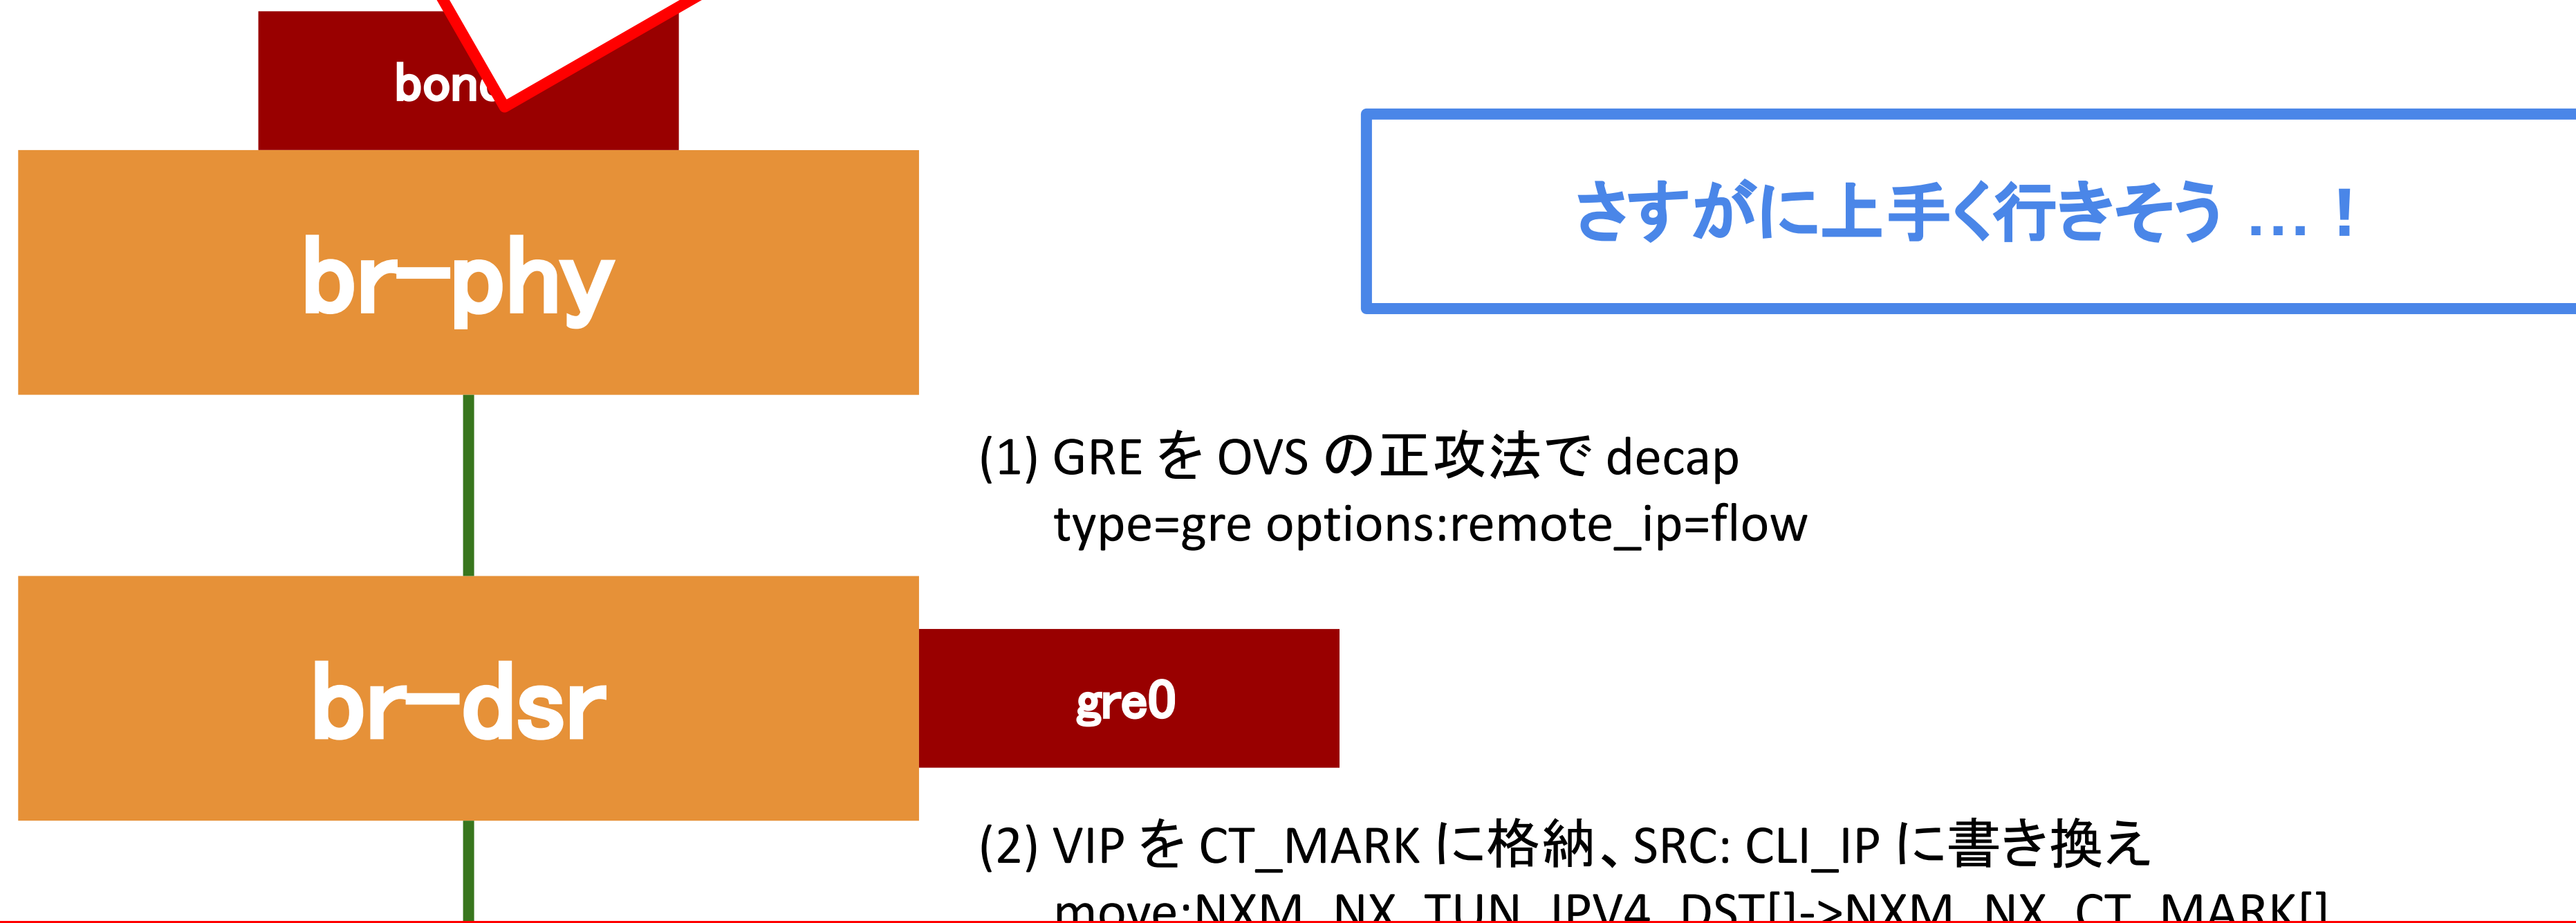
(1) GRE を OVS の正攻法で decap
type=gre options:remote_ip=flow

(2) VIP を CT_MARK に格納、SRC: CLI_IP に書き換え
move:NXM_NX_TUN_IPV4_DST[]->NXM_NX_CT_MARK[]
move:NXM_NX_TUN_IPV4_SRC[]->NXM_OF_IP_SRC[]

(3) CT_MARK が空でないときに CT_MARK に格納した VIP を SRC IP に書き換え
move:NXM_NX_CT_MARK[]->NXM_OF_IP_SRC[]

第N稿: GRE トンネー

OVS




**OpenvSwitch の GRE はトンネリング以外の用途では
上手く decap しないしログにも吐かない**

その後数十パターン試行錯誤...

決定稿: GRE パターン

OVS



本来は `pkt_mark` 領域に記録したかったが
veth から OVS に入ってくる途中でその情報が
落ちてしまっており、利用できなかった

性能評価

- Apache Bench で評価
 - 1127.08 req/sec
 - 平均 43 ms
 - 99%ile 157 ms

- OVS
 - w/ dpdk
 - bridge type: netdev

※この測定後、すぐに環境を壊すことになったので
負荷を上げた試験やさらに深い試験は実施できず...
負荷はかなり余裕があったので、10倍以上は食えるように見えた
(PMD thread や CPU usage)

大切な教訓

- OpenvSwitch の GRE 処理はクセが強い
 - 今回は制御しきれず eBPF に逃がした
- OpenvSwitch で複雑なパケット処理を行いたい場合は
flow rule だけで無理せず eBPF に逃がすことを検討すべき
- 複雑なパケット処理を行う場合、**TCP ヘッダまでであれば eBPF は高速に処理することができる**

4

まとめ



まとめ

- 透過 L3DSR を OpenvSwitch の flow rule + eBPF で実現
 - 設定を同期する agent などは不要
- パフォーマンスも 1Krps 程度までは問題ないことを確認
 - この10倍程度は少なくとも処理できそう
- 今後 L3DSR を使うことがあれば積極的に採用したい

EOP