

Next Data Center Networking with SRv6

- Data plane -

Toshiki Tsuchiya, LINE Corporation

2019/07/26 JANOG44 Meeting

Agenda

- LINEのサービスとネットワーク
- データプレーン
- コントロールプレーン

LINEのサービスとネットワーク



LINEのサービスとネットワーク


現状のネットワークと課題

Full L3 CLOS Network*

- シングルテナントネットワーク
- LINEのメッセージャーやファミリーサービスなどが稼動




...




特定サービス専用のネットワーク

- サービス固有の要件を持つサービスが稼動
- サービスごとにネットワークを構築



LINE Pay

その他 Fintech Business




アンダーレイネットワークの断片化
設計・構築にかかる時間の増加
運用コストの増加

* JANOG43 Meeting: LINEのネットワークをゼロから再設計した話
<https://www.janog.gr.jp/meeting/janog43/program/line>

解決策: マルチテナンシー

- アンダーレイネットワークを共通化し、運用負荷を軽減
- オーバーレイネットワークでサービス(テナント)ごとのポリシーを実現



柔軟にスケールするオーバーレイ
テナントで分離・独立したセキュリティ
将来的なサービスチェイニング

シンプルなL3のアンダーレイ

マルチテナンシー

VXLAN vs SRv6

VXLAN

Pros

- 運用実績や情報が多くある
- 多くのネットワーク機器で実装されている

Cons

- full-L3にした恩恵が損なわれるのでは...
- Service chainingを実現するために、追加のプロトコルが必要となる
→ プロトコルの多重化/複雑性が増す

IPv6 Segment Routing (SRv6)

Pros

- アンダーレイはIPv6 forwardingのみ
- Segment IDを駆使することで、SegregationやService chainingが実現できる
→ サービスの要件に合ったポリシーが実現できる

Cons

- データセンターネットワークでの導入事例・情報が無い
- ネットワーク機器での実装がほぼ無い


+ SRv6の将来性に期待

採用を決定

SRv6の概要

Segment ID (SID)

- 128bitのIPv6アドレス表記
- **Locator**: SRv6を処理するノード(ペアレントノード)へルーティングするための情報
- **Function**: ペアレントノードが実行する処理を示す情報



Segment Routing Header (SRH)

- IPv6の拡張ヘッダー
- 複数のSIDをまとめたSegment Listと、Segment Listの現在のポインタであるSegment Leftなどから構成

Well-known function (後述の説明で使うfunctionのみ)


- **T.Encaps(Encap)**: パケットにIPv6ヘッダー、SRHを付与してカプセル化する
- **End.DX4(Decap)**: SRv6のパケットからIPv6ヘッダーとSRHを外して、指定されたNexthopに転送
- **End.DT4(Decap)**: SRv6のパケットからIPv6ヘッダーとSRHを外して、指定されたRoutingTableをルックアップして転送 (Linux Kernelで実装されていないため今回の構成では使用していません。本来であればDX4よりDT4がしたい)

SRv6 Data Center Network

データプレーン


データプレーン

全体構成



データプレーン

SID、Routing




- NN, HVにはテナント単位でVRF (I3master device)を作成
- 各ノード(NN, HV)にはIPv6 アドレスを /96 単位で割り当て (**Locator**)
- テナントIDを**Function**としてSIDを設定
- 各ノードは Locatorとして割り当てられたIPv6の/96をBGPで経路広報

データプレーン

パケットフロー: テナント内通信


VM A1 (HV1 TennantA) → VM A2 (HV2 TennantA)



データプレーン

パケットフロー: テナント間通信

VM A1 (HV1 TennantA) → VM B2 (HV2 Tennant B)



データプレーン

実際の設定 (Network Node A)

Encap設定

```
[NetworkNode-A]# ip route show table 12
```

			Segment List		
10.122.12.113	encap seg6 mode encap segs 1	[	Locator(HVのアドレス)	Function (テナントID)	]
10.122.12.114	encap seg6 mode encap segs 1	[	Locator(HVのアドレス)	Function (テナントID)	]
10.122.12.115	encap seg6 mode encap segs 1	[	Locator(HVのアドレス)	Function (テナントID)	]

宛先VMのIPv4アドレス

Decap設定

```
[NetworkNode-A]# ip -6 route show table local
```

local	Locator(HVのアドレス)	:	4d87:	Function (テナントID)		encap seg6	local	action	End.DX4	nh4	169.254.1.2	dev	vrf01b1db9dd10f	metric	1024	pref	medium		
local	Locator(HVのアドレス)	:	4d87:	Function (テナントID)		encap seg6	local	action	End.DX4	nh4	169.254.1.4	dev	vrf01b1db7f5d2b	metric	1024	pref	medium		
local	Locator(HVのアドレス)	:	4d87:	Function (テナントID)		encap seg6	local	action	End.DX4	nh4	169.254.1.8	dev	vrf5c0594737b87	metric	1024	pref	medium		





... Locator(HVのアドレス) Function (テナントID)

VRFに設定したダミーのIPアドレス
(End.DX4でVRFのテーブルルックアップをするための小細工)

データプレーン

実際の挙動

IP: 10.122.12.36



IP: 10.122.12.35

```
[VM-A1]$ ping 10.122.12.35 -c 10
PING 10.122.12.35 (10.122.12.35) 56(84) bytes of data.
 64 bytes from 10.122.12.35: icmp_seq=1 ttl=63 time=0.356 ms
 64 bytes from 10.122.12.35: icmp_seq=2 ttl=63 time=0.461 ms
 ...
 64 bytes from 10.122.12.35: icmp_seq=10 ttl=63 time=0.415 ms
 --- 10.122.12.35 ping statistics ---
 10 packets transmitted, 10 received, 0% packet loss, time 9000ms
```

HV2: Decap

IPv6, SR headerが外れる

```
▶ Frame 5: 98 bytes on wire (784 bits), 98 bytes captured (784 bits)
▶ Ethernet II, Src: 7e:55:34:6d:37:3a (7e:55:34:6d:37:3a), Dst: fa:16:
▼ Internet Protocol Version 4, Src: 10.122.12.36, Dst: 10.122.12.35
  0100 .... = Version: 4
  .... 0101 = Header Length: 20 bytes (5)
  ▶ Differentiated Services Field: 0x00 (DSCP: CS0, ECN: Not-ECT)
    Total Length: 84
    Identification: 0x0000 (0)
  ▶ Flags: 0x4000, Don't fragment
    Time to live: 63
    Protocol: ICMP (1)
    Header checksum: 0x0e6f [validation disabled]
    [Header checksum status: Unverified]
    Source: 10.122.12.36
    Destination: 10.122.12.35
  ▶ Internet Control Message Protocol
```

HV1: Encap

IPv6, SR headerが挿入

```
▼ Internet Protocol Version 6, Src: :4d8e:a9fe:102, Dst: :4d8f:a9fe:102
  0110 .... = Version: 6
  ▶ .... 0000 0000 .... = Traffic Class: 0x00 (D
  .... 0000 0000 0000 0000 0000 0000 = Flow Label: 0x000000
  Payload Length: 108
  Next Header: Routing Header for IPv6 (43)
  Hop Limit: 63
  Source: :4d8e:a9fe:102
  Destination: :4d8f:a9fe:102
  ▼ Routing Header for IPv6 (Segment Routing)
    Next Header: IPIP (4)
    Length: 2
    [Length: 24 bytes]
    Type: Segment Routing (4)
    Segments Left: 0
    First segment: 0
    ▶ Flags: 0x00
    Reserved: 0000
    Address[0]: :4d8f:a9fe:102
    ▼ [Segments in Traversal Order]
      Address[0]: :4d8f:a9fe:102
  ▶ Internet Protocol Version 4, Src: 10.122.12.36, Dst: 10.122.12.35
  ▶ Internet Control Message Protocol
```

設計・構築で苦労した点

SRv6

- 情報が無い
- Best Practiceが無いのでどうやってSIDを設計すればいいのかわからない
- Linux KernelのSRv6を動かすのに一苦労

Linux networking

- VRF(l3mdev)の挙動
 - SRv6と組み合わせたときに必ずfragmentされる
 - バグ: Linux kernelへパッチ提出 (mainstreamに取り込まれています)
 - netfilterとの組み合わせが悪い
 - HV(Decap) → VMに通信した場合にFORWARDチェーンではなくOUTPUTチェーンで引っかかる
 - VMからHV外への通信に関してはtapデバイスをout interfaceに設定したルールに反応しない
- NICのoffloadが効かず、Decap時の性能がかなり落ちる
 - メーカーと協力して調査を実施。修正パッチによって、性能が大幅改善

データプレーン: まとめ

達成できたこと

- SRv6を利用したオーバーレイネットワークを設計
 - SIDやRoutingの設計などを1から設計
- 実環境で構築し、マルチテナンシーが実現できていることを確認 → まもなく実サービス投入予定

今後の課題

- 性能問題
 - 現時点ではNetworkNode, HypervisorともにLinux KernelのSRv6実装を使用
今後パフォーマンスが問題になることが目に見えている
→ 性能向上に向けて色々と検討中
(SRv6対応スイッチ/NOS、 P4スイッチ、 Smart NIC、 NIC HW offload、 DPDK、 XDP、 ...)
- ネットワーク構成
 - NFV(実際はFW)を通す部分はVRFとIP Routingで頑張っている状態のため、かなり複雑
→ SRv6でService chainingできる構成に作り変えていきたい