

データセンターでのルーティングプロトコル


Shishio Tsuchiya

shtsuchi@arista.com

アジェンダ

- **今のデータセンタールーティングが生まれてきた訳**
- EVPNデータセンター内デザイン
- ダイナミックディスカバリー
- IETF Dcrouting

2011年ごろのデータセンターネットワーク



- フラットなレイヤー2のネットワークデザイン
- データセンター内ではスパンニングツリーが使用
- ベンダー独自のリングプロトコル (またはG.8032)がデータセンター間で使用される
- VMライブマイグレーションは必要 (GARPによって移動を通知)
- VLANがユーザ毎にアサインされる

問題点

- データセンター間/データセンター内
 - VLANスケーラビリティ > 4K
 - MACアドレステーブルのスケーラビリティ
 - VMライブマイグレーションや簡単に使うためのブロードキャストドメインの拡張
 - East / Westトラフィック帯域の増加
 - 高速収束
 - 自動化/オーケストレーション
- データセンター間
 - 要求に応じた帯域増強
 - ベンダーロックイン技術からの解放
 - 柔軟性のあるトポロジーデザイン
 - トラフィックエンジニアリング
 - BUM(Broadcast/Unknown unicast/Multicast) トラフィックの最適化
- ゲートウェイ
 - ARP/NDPスケーラビリティ
 - IETF ARMD(Address Resolution for Massive numbers of hosts in the Data center) Groupは一つの informational RFCを発行 [RFC6820 Address Resolution Problems in Large Data Center Networks](#)

問題に関するソリューション

- 仮想オーバーレイプロトコル
 - [VXLAN: A Framework for Overlaying Virtualized Layer 2 Networks over Layer 3 Networks](#)
 - › draft-mahalingam-dutt-dcops-vxlanは2011年8月に experimental として発行
 - vmware/cisco/arista/broadcom/citrix/Redhat
 - › RFC7348は2014年8月に Informationalとして発行
 - [NVGRE: Network Virtualization using Generic Routing Encapsulation](#)
 - › draft-sridharan-virtualization-nvgreは2011年9月に発行
 - microsoft/arista/Intel/Dell/HPE/Broadcom/Emulux
 - › RFC7637は2015年にマイクロソフトによって informationalとして発行
 - [A Stateless Transport Tunneling Protocol for Network Virtualization\(STT\)](#)
 - › draft-davie-sttは2012年2月 nformationとして発行
 - › Nicira Networks
 - › 2016年にexpire
 - [Overlay Transport Virtualization\(OTV\)](#)
 - › draft-hasmit-otvは2010年4月にスタンダードとして発行
 - Cisco
 - › 2013年にexpire

問題に関するソリューション

- ネットワークデザイン

- Use of BGP for routing in large-scale data centers

- › Microsoft Petr Lapukhov がNANOG55 June 3-6, 2012でプレゼン

- › またdraft-lapukhov-bgp-routing-large-dcを2012年7月に発行 Ariff Premji(Arista)が共同著者

- › [RFC7938](#) は2012年8月にInformationalとして発行


- Transparent Interconnection of Lots of Links (trill)

- › draft-perlman-trill-rbridge-protocolは2006年に発行

- › Trill WG はRbridges([RFC6325](#))を次世代 IEEE802.1Dプロトコルとして定義 July 2011

- › RFCの著者は Intel/Huawei/Cisco/Brocade

Virtual eXtensible LAN (VXLAN)




- レイヤー2フレームをIPでカプセルプロトコルを定義
- レイヤー3インフラストラクチャー上でオーバーレイのネットワークを作成する為に使用
- レイヤー2の接続性をユーザに提供


Virtual eXtensible LAN (VXLAN)フレームフォーマット

- フラグ(8 bits):
 - 有効なVXLANのネットワークIDの場合、1フラグは1をセットしなければならない。他の7ビット(R)は予約フィールドで送信時に0をセットしなければならない、受信時に無視される
- VXLANセグメントID/VXLANネットワーク識別子 (VNI):
 - これは、通信するVMが配置されている個々のVXLANオーバーレイネットワークを指定するために使用される24ビットの値です。異なるVXLANオーバーレイネットワーク内のVMは互いに通信できません。
- 宛先ポート:
 - IANAはVXLANのポートとして4789をアサインした。このポートをデフォルトの宛先ポートとして使う
- 送信元ポート:
 - UDPソースポート番号は、ロードバランスの際のハッシュの計算に使用される。動的にプライベートポート範囲49152-65535である事が推奨される

Outer UDP Header:



VXLAN Header:




オーバーレイとアンダーレイ

- オーバーレイネットワーク (論理インフラ)


- 物理から切り離された論理トポロジー
- ルーティングされる物理インフラストラクチャーを通るトンネルにて構成される
- トンネルは物理と論理エンドポイントの接続性を提供

- アンダーレイ(物理インフラ)

- オーバーレイ技術に透過的
- レイヤー3インフラでの構築を許可
- 物理ネットワークは通信の為の帯域幅とトポロジーのスケールを提供
- 仮想化デバイスとノードのスケール要件は物理から抽象化される



大規模データセンタールーティングでのBGPの使用



- スケールアウトするClosデザイン
- 安定した標準的なBGPプロトコルをToR/Leafスイッチに使用
- 安定性にフォーカスし、VMモビリティはラック内に留める

このネットワークデザインにおける特別なBGPの要件

- AS_PATH Multipath Relax

- Allow AS In

- 重複したAS番号を使用する為の機能


- Fast eBGP Fall-over

- 高速コンバージェンスを可能にする


- Remove Private AS

- 2バイトのプライベートAS番号 (64512-65534)だけでなく、4バイトのプライベートAS番号 (4200000000 - 4294967294) もエッジで除去

- [RFC6996 Autonomous System \(AS\) Reservation for Private Use](#)




IP ECMPの利点




- ECMPで全てのLeaf-Spineリンクを使用する
- それぞれのフローはECMPハッシュにてバランスされる(既に実装されている)
- ルーティングパスはBGPパス属性により可視化される

BGPの利点



- ASパスを追加するもしくはBGPグレースフルシャットダウンコミュニティ([GSHUT \(0xFFFF0000\) community](#))を使って簡単にメンテナンス可能

VXLAN + IP Closデザイン



- データセンターデザインで完全なソリューション
- 標準で安定したBGPプロトコル/広く展開されたVXLANフォーマットを使用
- 特に特別な要求が中間ノードには存在しない

VXLANコントロールプレーンの選択

- VXLANコントロールプレーンはMAC学習とパケットフラッディングに使用される
 - リモートVTEPの背後にいるホストを発見するメカニズム
 - どのようにVTEPとVNIのメンバーを発見するのか?
 - レイヤー2セグメント(VNI)内でブロードキャスト/マルチキャストを転送する為のメカニズム

IPマルチキャストコントロールプレーン

- VTEPはVNIの所属するマルチキャストグループにjoin
- VNI内のUnknownユニキャストはVTEPにマルチキャストで転送
 - サードパーティVTEPをサポート
- 転送と学習はIPマルチキャストを要求-限られた展開例

HeadEnd Replication (HER)

- BUMトラフィックはVNIの中のリモートVTEPに複製される
 - ingress VTEPで複製される
- サードパーティのVTEPをサポート
- MAC学習は転送され学習されるしかし、マルチキャストは必要が無い


EVPN

- VTEP間のローカルに学習されたMACとIPの紐付けの為にBGPを使用
- ブロードキャストトラフィックはIPマルチキャストやHERによりハンドルのされる
- 設定されたBGPIによりMACアドレスとVNIはダイナミックに分配される
- サードパーティVTEPをサポート

アジェンダ

- 今のデータセンタールーティングが生まれてきた訳
- **EVPNデータセンター内デザイン**
- ダイナミックディスカバリー
- IETF Dcrouting


なぜEVPNが必要だったか？



- [RFC7209 Requirements for Ethernet VPN \(EVPN\)](#) は2つのVPLSモード([RFC4761](#) と [RFC4762](#)) 問題点を解決するために定義された
 - 冗長性の要求事項 Active/Activeリダンダンシーのサポート
 - マルチキャスト最適化要求: P2MPだけでは無く、MP2MPのサポート
 - データセンター間接続
 - プロビジョニングの簡素化
 - [RFC7432 BGP MPLS-Based Ethernet VPN](#) はスタンダードプロトコルとして発行された

A Network Virtualization Overlay Solution using EVPN


<https://tools.ietf.org/html/draft-ietf-bess-evpn-overlay>



- IETF NVO3(Network Virtualization over Layer 3) WGは現在のマルチテナントネットワークの問題点を定義した [RFC7364 Problem Statement: Overlays for Network Virtualization](#) .
- draft-ietf-bess-evpn-overlayはEVPNの技術を使って、どの様にNVO3の要件を提供するのかのソリューションドラフト
- 現在のIESGステータスは Publication Requested, proposal standardとして発行予定


Internet EXchange (IXP) Use case

<https://tools.ietf.org/html/draft-ietf-bess-evpn-proxy-arp-nd>



- IXPはBGPピアリングの為にレイヤー2の到達性を提供する
- レイヤー2技術と光スイッチを使用し、トポロジーは限られている
- BGPピアリングはIXPの顧客により行われる。もし片方のAS (AS64500)がIPアドレスを変えたり、そのサイトから切断された場合は他方のAS (AS64496)はBGPの為にARPやNDPを送り続ける。結果としてBUMトラフィックがネットワーク全体に波及する
- EVPNはActive-Activeマルチホーミングやダイナミックプロビジョニング/プロキシ-ARP/NDPによりこれらの問題を解決する
- draft-ietf-bess-evpn-proxy-arp-nd はIXPを含むProxy ARP/NDP使用例を記載している


Business L2VPN services




- 日本ではレイヤー2のイーサネットVPNサービスは2000年から続けている
- サービスプロバイダーはvlanヘッダーをスタックするExtreme vMAN(Ether type:0x9100) や Cisco QinQ(0x8100)を使用
- IEEEはその技術を 802.1ad Provider Bridges(0x88A8)として2006年に定義
- vMAN/QinQはvlan id(>4096)の制限を緩和させたが、安定はしていなかった
- 日立電線がEoE(Ether Over Ethernet)と呼ばれる新しいフレームフォーマットを開発した
- IEEEはその後2008年にこの技術を802.1ah Provider Backbone Bridgesとして定義する
- [RFC7623 Provider Backbone Bridging](#) はEthernet VPN (PBB-EVPN)でPBBフレームをMPLS上で転送する為の技術
- いくつかのサービスプロバイダーはここでVPLSを使っている

アンダーレイとオーバーレイのプロトコルの選択

- アンダーレイ:
 - 前述の通り、安定性とオープンなプロトコルを重視して、BGP
- オーバーレイ:
 - EVPNはコントロールプレーンとしてBGPを使用する
- BGP over BGP?




eBGP with Route Server(next hop unchange)



- eBGPセッションをVTEPとSpineの間でEVPNの為に設定
- それぞれのSpineはEVPNコミュニティやnext hopアトリビュートを透過しないといけない
- つまりルートサーバーの機能が必要

iBGP with Route Reflector



- iBGPセッションを VTEPとSpine のloopbackでEVPNの為に設定
- SpineをRRとして設定し、local-asを使う

アジェンダ


- 今のデータセンタールーティングが生まれてきた訳
- EVPNデータセンター内デザイン
- **ダイナミックディスカバリー**
- IETF Dcrouting

アンダーレイとしてのBGP

- コントロールのしやすさ・標準的なプロトコルでロックインされない
- 自動検出はZTPやSDNでカバー

- 最近は更にRFC5549機能拡張など

ZTP(Zero Touch Provisioning)



- 出荷状態において、全てのポートでDHCPクライアントとして動作
- LLDPの隣接情報などでそのまま正規設定をダウンロード
- インベントリシステムに登録後に正規設定をダウンロード

RFC5549 Capability Negotiation



Capability Code (1 octet:5)
Capability Length (1 octet)
Capability Value (variable)



NLRI AFI (2 octets) 1:IPv4
NLRI SAFI (2 octets) 1:Unicast 2:Multicast
4:Label 128:MPLS-VPN
Next Hop AFI (2 octets) 2:IPv6

- [RFC5492](#) の Capability Code 5 Extended Next Hop Encoding でネゴシエーション
- Value にてサポート可能な AFI/SFI および Next Hop AFI を通知 (IPv6:2)


RFC5549 UPDATE/WITHDRAWN



Address Family Identifier (2 octets)
Subsequent Address Family Identifier (1 octet)
Length of Next Hop Network Address (1 octet)
Network Address of Next Hop (variable)
Reserved (1 octet)
Network Layer Reachability Information (variable)

- [RFC4760](#) のMPBGPのMP_REACH_NLRIとMP_UNREACH_NLRIをそのまま使用可能


データセンターだと



- お？リンクローカル使いたくならない？？
- fe80::AS番号
- BGP4+ Peering Using IPv6 Link-local Address
 - <https://tools.ietf.org/html/draft-kato-bgp-ipv6-link-local>

更に拡張: BGP Link-Local Next Hop Capability

<https://tools.ietf.org/html/draft-kumar-idr-link-local-next-hop>



- [RFC5492](#) のCapability Code 5 Extended Next Hop Encodingでネゴシエーション
- +LINK-LOCAL-ONLY-NEXT-HOP (IANA未定義)でBGP OPENメッセージ
- 繋げただけで自動設定が目標

アジェンダ

- 今のデータセンタールーティングが生まれてきた訳
- EVPNデータセンター内デザイン
- ダイナミックディスカバリー
- **IETF Dcrouting**

IETF100 DCROUTING

<https://datatracker.ietf.org/meeting/100/session/dcrouting>

- IETF100シンガポールにてDCROUTING(データセンタールーティングに関する)BOFを開催
 - 要求事項と問題定義
 - 新しいルーティングテクノロジーでの対応
 - 既存のルーティングテクノロジーでの拡張


Requirements for the DataCenter Routing

<https://tools.ietf.org/html/draft-dt-rtgwg-dcrouting-requirements>

- 基本的な接続性と1つ以上のオーバーレイプロトコルを運ばなければならない
- Spine-Leafのトポロジーをサポートしなければならない
- 収束時間の仮のKPIは下記の通り
 - 5,000ノード/250Kルートで250msec以下
 - 7,500ノード/500Kルートで500msec以下
 - 10,000ノード/1Mルートで1秒以下
- ECMP/UCMPを使ったロードバランスをサポートしなければならない
- 様々なアドレスファミリーを運ばなければならない、また到達性以外のデータも運べる様に拡張可能でなければならない
- inbandのみでは無く、out band管理も出来なければならない
- ZTPをサポートしなければならない
- BFDをサポート出来なければいけない
- ステート情報をTelemetryで運べなければならない

Shortest Path Routing Extensions for BGP Protocol


<https://tools.ietf.org/html/draft-keyupate-idr-bgp-spf>



- SRLGやLFAなどを管理するにはトポロジー全体が必要(LSDB)
- リンクステート情報をBGPで伝播する仕組みは既にある=>BGP-LS
- これを使ってBGPとDijkstraアルゴリズムを組み合わせ、パス選択アルゴリズムを変更
 1. NLRIを発行したものかどうかを確認。発行元のNLRIを優先
 2. 次にBGP-LSのメトリック情報を元にSPFを実施
 3. Router IDの最も高い値


IS-IS Routing for Spine-Leaf Topology

<https://tools.ietf.org/html/draft-shen-isis-spine-leaf-ext>



- 既存のISISのメカニズムをそのまま使用
- Spine-Leaf TLVを持たせる
- Spine間ではフルデータベースを持ち、LeafではSpineでのデフォルトルートのみを持つ
- Leafでのスケーラビリティを持たし、障害時の影響範囲を狭める


今後のデータセンタールーティング標準化



- 既存のパスベクタープロトコルにDijkstraアルゴリズムを組み合わせたLSVR
- データセンタートポロジー用に新しいルーティングプロトコルを使うRIFT
- それぞれがWGとして標準化および議論を進めていく

おまけ BGP LLDP Peer Discovery

<https://tools.ietf.org/html/draft-acee-idr-lldp-peer-discovery>



- LLDPでBGP設定に必要な情報も追加
- データセンターの様な1ホップのBGPピアに対して活用

まとめ

- データセンターのスケールによって選択肢は色々
- BGPやISIS(OSPFも)データセンター用のものに少しずつ変わるかも
 - 要求を提案するなら今です。
- EVPNのデザインはインターデータセンターが中心で合ったため、データセンター内ではちょっと癖があるかも



Thank You

www.arista.com