



Сеть ЦОД на основе VXLAN/EVPN за 5 дней

День 1:

VXLAN/EVPN фабрика – основы

Александр Скороходов

Архитектор Cisco по технологиям

Апрель 2021

Программа спринта

День	Тема
5 апреля, понедельник	VXLAN/EVPN фабрика – основы
6 апреля вторник	VXLAN/EVPN фабрика – клиенты и внешние сегменты
7 апреля среда	VXLAN/EVPN фабрика – распределенные топологии
8 апреля четверг	VXLAN/EVPN фабрика – интеграция L4-L7 сервисов
9 апреля пятница	VXLAN/EVPN фабрика – эксплуатация и поддержка

Программа на сегодня

- Оверлеи, их преимущества и классификация
- VXLAN и его развитие
- Архитектура VXLAN фабрики с уровнем управления MP-BGP EVPN
- L2 и L3 сервисы в VXLAN/EVPN
- Целостное решение: физическая и логическая архитектура
- Дизайн MP-BGP
- Дизайн Underlay связности
- Управление VXLAN/EVPN фабрикой

Предмет обсуждения:

VXLAN фабрика с уровнем управления MP-BGP EVPN

Посмотрим подробнее:

VXLAN

фабрика

с уровнем управления

MP-BGP


EVPN

- оверлейная инкапсуляция
- сетевая архитектура
- способ сигнализации
- протокол сигнализации
- адресное семейство для представления управляющей информации


Оверлеи, их преимущества и классификация

Требования к современным сетям ЦОД



- Мобильность нагрузок
- Гибкость размещения нагрузок
- Сегментация – L2 и L3
- Масштабируемость – производительность и подключения
- Автоматизация и программируемость
- Связность на L2 и L3
- Физические и виртуальные подключения



Что такое оверлейная сеть?



Зачем нужны оверлейные сети?




Эффективный транспорт

- Универсальная опорная сеть
- Резервирование и производительность
- Эффективное управление трафиком
- Управление, диагностика, программируемость


Гибкая наложенная сеть

- Мобильность подключенных адресов
- Нужный тип связности
- Сегментация
- Масштабирование – снижение сложности в ядре
- Гибкость, программируемость
- Передача дополнительных метаданных

Типы наложенных сетей: вид сервиса




- **Layer 2**
- Эмуляция сегмента LAN
- Передача кадров Ethernet (IP и не-IP)
- Мобильность в подсети (L2 домене)
- Гибкость размещения нагрузок
- Поддержка (и риск!) L2 флэдинга



- **Layer 3**
- Абстракция связности на основе IP
- Передача IP пакетов
- Мобильность адреса без растягивания L2
- Ограничение доменов сбоем

Сигнализация

- Обнаружение сервисов
 - Пограничные устройства должны обнаружить друг друга
- Анонс адресов и построение отображения
 - Соотнесение подключений с пограничными устройствами
- Управление туннелями
 - Построение и управление соединениями между пограничными устройствами



Сигнализация


Data Plane Learning

- Используется сбор информации от уровня коммутации
 - Примеры: «выучивание» адресов на традиционных коммутаторах, VXLAN Flood&Learn, FabricPath
- Обеспечивается:
 - Обнаружение адресов и построение соответствия
 - Возможно – управление туннелями
 - Не обеспечивается обнаружение сервисов
- Требуется флдинга информации на уровне коммутации:
 - Multicast дерево
 - Репликация в unicast трафик на входе в оверлей

Сигнализация

Уровень управления

- Обеспечивает:
 - Обнаружение пограничных узлов
 - Анонс подключений
 - Управление туннелями
 - Могут обеспечиваться расширения для резервирования подключений и дополнительных сервисов



Протокол или контроллер:

- **Управляющий протокол** между пограничными узлами
 - BGP, IS-IS, LISP
- Центральная БД на **контроллере**
 - Распределённые виртуальные коммутаторы (OVS, N1Kv/VSM)

«Push» или «Pull»:

- **Распространение (Push)** информации до всех пограничных устройств
 - BGP, IS-IS, контроллеры
- **Запрос (Pull)** и кеширование на пограничном устройстве
 - LISP, DNS, контроллеры


VXLAN и его развитие

Почему VXLAN?

VXLAN обеспечивает сеть с сегментацией, мобильностью и масштабированием

- Используются «стандарты» (RFC)
- Используется IP сеть с Layer-3 ECMP – надёжная отработанная технология
- «Пространство имен» сегментов до 16 миллионов
- Развёртывание сегментов без изменений на промежуточных устройствах
- Поддержка физическими и виртуальными коммутаторами
- Поддержка разными производителями

Оверлейные сети с использованием VXLAN




Underlay:

- Маршрутизация IP – проверенная, надёжная, масштабируемая
- ECMP – использование всех путей


Overlay:

- Опора на стандарты
- Растягивание и мобильность на L2
- Расширенное пространство идентификаторов сегментов
- Масштабируемая сеть
- Multi-Tenancy


Формат пакета VXLAN MAC-in-UDP



Функционирование VXLAN



Функционирование VXLAN




VTEP – VXLAN Tunnel End-Point

VNI/VNID – VXLAN Network Identifier

VXLAN Flood&Learn на основе mulicast


Первоначальная реализация VXLAN

- Без уровня управления
- Flood-&-learn с использованием передаваемых данных
- Multicast транспорт для BUM трафика (Broadcast, Unknown Unicast и Multicast).




VTEP: выучивание адресов

VXLAN Flood&Learn




VTEP: выучивание адресов

VXLAN Flood&Learn



Передача данных

VXLAN Flood&Learn



VXLAN транспорт

И его развитие

Выучивание на уровне коммутации

- Flood & Learn в мультикастовой группе, в которой участвуют все устройства
- Уровень управления отсутствует



Выучивание на уровне протокола

- Оконечные узлы анонсируются управляющим протоколом между VTEP с помощью MP-BGP/EVPN

Варианты распространения BUM трафика

- Multicast или репликация на источнике через unicast

Использование для связи ЦОД

- VXLAN/EVPN Multi-Site

Развитие VXLAN

Независимость от multicast

- Репликация на входе (Ingress Replication) позволяет использовать unicast транспорт – если нужно!
- Уровень управления позволяет автоматически обнаруживать адреса VTEP

Внешние подключения

- Резервирование подключения к VTEP (VPC/MLAG)
- VXLAN шлюзы во внешние сети – MPLS VPN, Segment Routing (SR-MPLS, SRv6), ...
- «Сшивание» VXLAN туннелей для связи ЦОД: VXLAN Multi-Site

Уровень управления

- MAC и IP адреса нагрок выучиваются VTEP
- Анонс ассоциации L2 и L3 адресов с VTEP с использованием управляющего протокола
- Сокращение флдинга
- Оптимальное распространение ARP

IP сервисы

- Маршрутизация между VXLAN
- Распределённый шлюз по умолчанию
- Изоляция организаций (Multi-Tenancy) на L2 и L3

Архитектура VXLAN фабрики с уровнем управления MP- BGP EVPN

Архитектура VXLAN EVPN фабрики

Базовые составляющие решения

Оверлеи

- Layer-2
- Layer-3
- Layer-2 и Layer-3

VXLAN инкапсуляция

Underlay транспортная сеть

Плоскость управления на основе BGP

- Peer-Discovery
- Route Learning and Distribution
 - Local Learning
 - Remote Learning

Плоскость передачи данных

- Overlay Layer-2/Layer-3 Unicast Traffic
- Overlay Broadcast, Unknown Unicast, Multicast traffic (BUM traffic) forwarding
 - Ingress Replication (Unicast)
 - Multicast

Основные элементы

VXLAN

- Инкапсуляция на основе стандарта RFC 7348
- Инкапсуляция в UDP
- Независимость от транспортной сети
- Layer-3 транспорт (Underlay)
- Расширенное «пространство имён»
- 24-битное поле (VNID) - ~16M идентификаторов
- Allows Segmentations

EVPN

- Уровень управления на основе стандартов
- RFC 8365 (и RFC 7432)
- Использует Multiprotocol BGP
- Поддерживает разные виды транспорта
- VXLAN (EVPN-Overlay), MPLS, Provider Backbone (PBB)
- Много поддерживаемых сценариев
- Bridging, MAC Mobility, First-Hop & Prefix Routing, Multi-Tenancy (VPN)

EVPN (Ethernet VPN)

- Уровень управления на основе Multi-Protocol BGP (MP-BGP) с использованием EVPN NLRI (Network Layer Reachability Information)
- Выполнение коммутации на VTEPs для Layer-2 (MAC) и Layer-3 (IP)
- Обнаружение: BGP, используя механизмы MPLS VPN (RT)
- Сигнализация: BGP
- Выучивание хостов: Control plane (BGP)


BGP advertisement:

L2VPN/EVPN Addr = **CE1.MAC**


BGP Next-Hop = PE1

Route Target = 100:1

Label=42




EVPN – Ethernet VPN



- EVPN с использованием NVO туннелей (VXLAN, NVGRE, MPLSoGRE) для сетевых фабрик ЦОД
- Построение L2 и L3 оверлеев поверх IP сетей
- Поддержка различными производителями

Multiprotocol BGP (MP-BGP)

Универсальный транспорт для распространения информации хостах и сетях подключенных к фабрике



- Расширение для Border Gateway Protocol (BGP)
 - RFC 4760
- Multiprotocol BGP (MP-BGP)
- Адресные семейства
 - В рамках одной BGP сессии может переноситься информация различных Address-Families (например VPNv4/v6, MVPN, L2VPN, EVPN)

Важные элементы реализации MP-BGP

Параметры VRF

- **Route Distinguisher (RD):**

- 8-байтное поле, параметр VRF. Делает префиксы уникальными между клиентами/VRF
- **VPNv4 address:** RD + VPN IP префикс

- **Route Target (RT):**


- 8-байтное поле, параметр VRF. Уникальные значения для определения правил импорта/экспорта маршрутов VPNv4
- Анонсируется MP-BGP вместе с префиксами

Multiprotocol BGP (MP-BGP)

Автоматизация для RD, RT

```
vrf context A
rd auto
address-family ipv4 unicast
route-target import auto
route-target export auto
```


```
vrf context A
rd auto
address-family ipv4 unicast
route-target import auto
route-target export auto
```



- Автоматическое назначение Route Distinguisher
- Макрос использует следующий формат
 - 4-byte Router ID (RID)
 - 4-byte VRF ID (internal number)
 - Пример для RD:
 - 10.10.10.101:3


- Автоматическое назначение Route Target
- Макрос использует следующий формат
 - 4-byte Autonomous System
 - 4-byte VNI
 - Пример для RT:
 - Import, Export или Both
 - 65500:5000

VXLAN/EVPN – распространение информации о хостах и сетях при помощи MP-BGP EVPN



- Распространение информации о хостах подключенных к L2/L3 сегментам отделено от Underlay протокола
- Используется MultiProtocol-BGP (MP-BGP) на VTEP для распространения информации о достижимости Host/Subnet или внешних маршрутов
- Route-Reflectors (RR) для масштабирования


VXLAN/EVPN – распространение информации о хостах и сетях при помощи MP-BGP EVPN




- BGP EVPN NLRI*
- Host MAC (Route Type 2)
Только MAC, один VNI, один Route Target
- Host MAC+IP (Route Type 2)
MAC и IP, два VNI, два Route Target, Router MAC
- Internal and External Subnet Prefixes (Route Type 5)
IP префикс, один VNI, один Route Target

*NLRI: Network Layer Reachability Information (BGP Update Format)


АНОНС ХОСТОВ



АНОНС ХОСТОВ



АНОНС ХОСТОВ




Анонс хостов

Host MAC (Route Type 2)

- MAC
- MPLS Label1 (L2VNI*)
- Route Target for MAC-VRF

MAC атрибуты обязательны



Baremetal

Host A

MAC: 0000.3001.1101



Host B

MAC: 0000.3001.1102



Host C

MAC: 0000.3002.2101

```

V2# show bgp l2vpn evpn 0
BGP routing table for VRF default, VRF ID 0
Route Distinguisher: 10.10.10.101:32777
BGP routing table entry for [2]:[0]:[0]:[48]:[0000.3001.1101]:[0]:[0.0.0.0]/216,
version 4
Paths: (1 available, best #1)
Flags: (0x000202) on xmit-list, is not in l2rib/evpn, is locked

    path-id 1
    type: internal, is best path, no labeled nexthop
    AS-path: NONE, path length 0, origin IGP, MED not set,
    Received label 3001
    Extcommunity: RT:65500:3001 ENCAP:8
    Originator: 10.10.10.101 Cluster list: 10.10.10.201
  
```

Route Type:
MAC/IP

Ethernet Segment
Identifier (ESI)

Ethernet Tag
Identifier
(Ethtag)

MAC Address
Length

MAC
Address

Next-Hop
IP Address


L2VNI
(MPLS Label1)

L2VNI
Route Target

Encap:8 VXLAN

АНОНС ХОСТОВ


Type	MAC / Length	L2VNI / RT	IP / Length	L3VNI / RT	Next-Hop	Seq.
2	0000.3001.1101 / 48	30001, 65500:30001	192.168.10.101 / 32	50000, 65500:50000	10.200.200.101	2



Host A


MAC: 0000.3001.1101
IP: 192.168.10.101

АНОНС ХОСТОВ



АНОНС ХОСТОВ

Type	MAC / Length	L2VNI / RT	IP / Length	L3VNI / RT	Next-Hop	Seq.
2	0000.3001.1101 / 48	30001, 65500:30001	192.168.10.101 / 32	50000, 65500:50000	10.200.200.101	
2	0000.3001.1102 / 48	30001, 65500:30001	192.168.10.102 / 32	50000, 65500:50000	10.200.200.104	
2	0000.3002.2101 / 48	30002, 65500:30002	192.168.20.101 / 32	50000, 65500:50000	10.200.200.107	



Анонс хостов


Host MAC (Route Type 2)

- MAC and IP
- MPLS Label1 (L2VNI)
- Route Target for MAC-VRF
- MPLS Label2 (L3VNI*)
- Route Target for IP-VRF
- Router MAC

IP атрибуты не обязательны

Формируется на основе ARP/ND

Передаётся в дополнение к анонсу «только MAC»



V2# **show bgp l2vpn evpn 0000.3001.1101**

BGP routing table for VRF default, address family L2VPN EVPN

Route Distinguisher: 10.10.10.1:32777

BGP routing table entry for **[2]:[0]:[0]:[48]:[0000.3001.1101]:[32]:[192.168.10.101]/272**, version 4

Paths: (1 available, best #1)

Flags: (0x000202) on xmit-list, is not in l2rib/evpn, 1

Received path-id 1

Next-Hop IP Address: 10.200.200.101 (best path, no labeled nexthop)

AS-Path: NONE, from 10.10.10.201 (10.10.10.201) to AS

10.200.200.101 (metric 3) from 10.10.10.201 (10.10.10.201)

Origin IGP, MED not set, localpref 100, weight 0

Received label **3001 5000**

Extcommunity: **RT:65500:3001 RT:65500:5000 ENCAP:8 Router MAC:0200.0ade.de01**

Originator: 10.10.10.101 Cluster list 10.10.10.201

Ethernet Segment Identifier (ESI)

Ethernet Tag Identifier (Ethtag)

MAC Address Length

MAC Address

Route Type: MAC/IP

IP Address Length

IP Address

Next-Hop IP Address

L2VNI (MPLS Label1)

L3VNI (MPLS Label2)


Encap:8 VXLAN

L2VNI Route Target

L3VNI Route Target

Router MAC

Распространение информации о подсетях




Распространение информации о подсетях

Internal and External Subnet Prefixes (Route Type 5)

- IP Prefix
- MPLS Label (L3VNI)
- Route Target for IP-VRF
- Router MAC

Формируется на основе информации из протоколов маршрутизации (или static/connected маршрутов)

Subnet A
192.168.10.0/24



```

V2# show bgp l2vpn evpn 10.200.200.101
BGP routing table for VRF default, VRF ID 0
Route Distinguisher: 10.10.10.3
BGP routing table entry for [5]:[0]:[0]:[24]:[192.168.10.0]/224,
version 4
Paths: (1 available, best #1)
Flags: (0x000202) on xmit-list, is not in l2rib/evpn, is locked

    10.200.200.101 (metric 0)
        path-id 1
        type: internal
        AS-path: NONE, path length 0, is best path, no labeled nexthop
        Origin IGP, MED not set,
        Received label 5000
        Extcommunity: RT:65500:5000 ENCAP:8 Router MAC:0200.0ade.de01
        Originator: 10.10.10.101 Cluster list: 10.10.10.201

```

Route Type:
IP Prefix

Ethernet Segment
Identifier (ESI)

Ethernet Tag
Identifier
(Ethtag)

IP Address
Length

IP Address

Next-Hop
IP Address

L3VNI
(MPLS Label)

L3VNI
Route Target

Encap:8 VXLAN

Router MAC

VXLAN/EVPN и VXLAN Flood&Learn

Сравнение





	VXLAN/EVPN	VXLAN Flood&Learn
Инкапсуляция	VXLAN (MAC-in-UDP)	VXLAN (MAC-in-UDP)
Требования к транспорту	IP	IP
Распространение информации о подключенных узлах	MP-BGP EVPN	Flood&Learn
Доставка BUM* трафика	Multicast (PIM) или репликация через unicast	Multicast (PIM) или репликация через unicast
Уровень управления в транспортной сети	Любой протокол маршрутизации (OSPF, IS-IS, eBGP)	Любой протокол маршрутизации (OSPF, IS-IS, eBGP)
Тип сервиса	L2 и L3	L2
Идентификатор пограничного узла	VTEP IP	VTEP IP
Аутентификация	MP-BGP	Нет
Стандарт	RFC 7348 + RFC 8365	RFC 7348

*BUM: Broadcast, Unknown Unicast, Multicast

L2 и L3 сервисы в VXLAN/EVPN

Модель сервисов в VXLAN EVPN

Tenant A (VRF A)




- Один локальный VLAN отображается на VTEP в один L2 VNI => сегмент, относящийся к VRF
- К VRF может относиться несколько сегментов (L2 VNI)
- Внутри L2 VNI – L2 коммутация
- Между L2 VNI – маршрутизация

- Один L3 VNI на VRF для маршрутизации между VTEP
- Требуется назначения отдельного VLAN X

- Возможно также использование «чистых» L2 VNI без маршрутизации на фабрике (без SVI)
- Отображение локального VLAN на L2 VNI

Layer-2 Multi-Tenancy


- VNI обеспечивают изоляцию на L2 и L3 в VXLAN сети
- Принятые фреймы отображаются в конкретный VNI
- Соответствие VLAN-VNI возможно (в зависимости от версии ПО и платформы):
 - На уровне коммутатора
 - На уровне порта
- VLANы имеют локальное значение, VNI - глобальное



VXLAN и BGP EVPN – L2 взаимодействие

Control-Plane (BGP EVPN)


Type	MAC / Length	L2VNI / RT	IP / Length	L3VNI / RT	Next-Hop	Seq.
2	0000.3001.1102/48	30001 65500:30001	192.168.10.102/32	50000 65500:50000	10.200.200.103	



Data-Plane (VXLAN)

Bridging

Packet Walk – Bridging




VXLAN/EVPN $\neq$ Ingress Replication!

- VXLAN с уровнем управления BGP EVPN по-прежнему требует механизм репликации BUM (Broadcast/Unknown Unicast/Multicast) трафика
- Два возможных варианта
 - **Multicast** – эффективный способ отправки всем VTEP в данном L2 VNI (посылается одна копия)
 - **Unicast** (Ingress Replication) – отправка копии BUM пакета каждому из VTEP в данном L2 VNI

Layer-3 Multi-Tenancy


- VNI обеспечивают изоляцию на L2 и L3 в VXLAN сети
- Принятые фреймы отображаются в VNI, соответствующий данному VRF
- Весь маршрутизируемый между VTEP трафик использует L3 VNI, соответствующий данному VRF («симметричный режим»)



Распределённый шлюз по умолчанию (Anycast Gateway)

Требует EVPN control plane

- Распределённая маршрутизация с Distributed Anycast Gateway (интегрированная маршрутизация и коммутация IRB)
 - Маршрутизация между VNI
 - Бриджинг внутри VNI
- Функции шлюза по умолчанию в любой точке подключения хостов
 - На всех VTEP коммутаторах один и тот же Gateway IP и MAC адрес
 - Шлюз всегда активен на всех устройствах
 - Никаких специальных протоколов или обмена hello-пакетами
- Лучше масштабирование
 - Только локальные ARP записи




VXLAN и BGP EVPN – L3 взаимодействие

Control-Plane (BGP EVPN)

Type	MAC / Length	L2VNI / RT	IP / Length	L3VNI / RT	Next-Hop	Seq.
2	0000.3001.2101/48	30001 65500:30001	192.168.20.101/32	50000 65500:50000	10.200.200.104	

Extended Community
Router MAC
0200.0ade.de07




Data-Plane (VXLAN)

Routing

Packet Walk – Routing


EVPN Control-Plane	
Type	2
MAC / Length	0000.3002.2101 / 48
L2VNI / RT	30002 / 65500:30002
IP / Length	192.168.20.101 / 32
L3VNI / RT	50000 / 65500:50000
Next-Hop	10.200.200.104
Ext. Community	0200.0ade.de04



Что, если получатель –
«молчаливый» хост??


Packet Walk – Routing

Обнаружение «молчаливого» хоста



Packet Walk – Routing


Обнаружение «молчаливого» хоста



EVPN Control-Plane		
Type	5	
IP / Length	192.168.20.0 / 24	
L3VNI / RT	50000 / 65500:50000	
Next-Hop	10.200.200.102	10.200.200.104
Ext. Community	0200.0ade.de02	0200.0ade.de04


Packet Walk – Routing

Обнаружение «молчаливого» хоста




Packet Walk – Routing

Обнаружение «молчаливого» хоста




Packet Walk – Routing

«Молчаливый» хост обнаружен



Подавление ARP

Дополнительная функция




- 1. ARP запрос на адрес IP_B от хоста A
- 2. V1 знает про IP_B и может ответить локально, не распространяя ARP запрос по сети

Целостное решение:
физическая и логическая
архитектура

Типичная архитектура сетевой фабрики Spine-Leaf, она же «сеть Клоза» (folded Clos)


- Использование ECMP для передачи данных: для Unicast или Multicast трафика
- Фиксированный «радиус» сети
- Детерминированная задержка
- Высокая отказоустойчивость



Сетевая фабрика

Масштабирование


- Leaf
 - Минимальная операционная единица
- Spines
 - Горизонтальный рост полосы
- Аплинки
 - Симметричные подключения
- SAYG: Scale as You Grow



Сетевая фабрика

Внедрение VXLAN/EVPN


- **Spine**
 - Подключение всех Leafs and Border Leafs ко всем
- **Leaf (VTEP)**
 - Виртуальные машины
 - Физические сервера
 - FEX-ы
 - Другие коммутаторы
 - UCS FI
 - Блейд коммутаторы
- **Border Leaf (VTEP)**
 - Внешние подключения



Super-Spine


Модульная Spine-Leaf архитектура

- Масштабирование
 - Не ограничено плотностью портов на Spine
 - Упрощение планирования ресурсов
- Рост за пределы машзала
 - Обеспечение связи модулей
- Сохраняет топологию внутри модуля и гибкость в связности между модулями



Дизайн MP-BGP


Типичный дизайн VXLAN фабрики с MP-iBGP EVPN



- VTEP только на уровне leaf
- Spine коммутаторы являются iBGP RR
- Spine коммутаторы не требуют поддержки VTEP функций
- iBGP сессии между VTEP и RR
- IGP протокол для IP достижимости между loopback адресами

Варианты дизайна VXLAN фабрики с MP-iBGP EVPN


- Spine коммутаторы не требуют поддержки VTEP функций
- Не требуют и поддержки EVPN
- Чистый IP транспорт



Варианты дизайна VXLAN фабрики с MP-iBGP EVPN


- Spine коммутаторы не требуют поддержки VTEP функций
- Не требуют и поддержки EVPN
- Чистый IP транспорт

Пара выделенных iBGP route-reflector-ов для пиринга со всеми VTEP




All leaf VTEPs run iBGP sessions with the dedicated route reflectors.

Дизайн VXLAN фабрики с MP-eBGP EVPN Multi-AS



Дизайн VXLAN фабрики с MP-eBGP EVPN Dual-AS




Дизайн Underlay связности

Свойства underlay сети и требования к ней

- Минимальная сложность
 - Минимум маршрутов
 - Только достижимость VTEP и инфраструктурные маршруты
- ECMP
 - Equal Cost Multi-Path для масштабируемости и доступности
- Максимально быстрая сходимость
- Отделение настройки и эксплуатации underlay и overlay
- Не забудьте про MTU с учётом VXLAN заголовка!
- Проблемы в underlay => проблемы в overlay !!!

Интерфейсы и адресация

- Маршрутизируемые порты и интерфейсы
 - Интерфейсы Layer-3 между Leaf и Spine (no switchport)
 - Для каждого Point-2-Point (P2P) соединения требуется минимум /31 (IPv4)
 - Альтернатива, использовать IP Unnumbered (/32)
 - IPv6 поддерживает Link-Local и Global IP адресацию
- Используйте Loopback как Source-Interface для VTEP (NVE)
- Используйте *другие* Loopback для соседств control plane





Интерфейсы и адресация


p2p Agg: 10.1.1.0/24

- Подготовьте план IP адресации
 - Начиная с NX-OS 9.3(1) поддерживается и IPv6
- Разделите IP адреса интерфейсов по функциям в разные диапазоны (агрегаты)
 - Unicast Routing – Routing Protocol Peering (p2p)
 - Unicast Routing – Routing Identifier (RID)
 - VTEP и VPC
 - Multicast Rendezvous-Point (RP)

10.254.254.1/32



Пример IP адресации



Маршрутизация underlay – OSPF или IS-IS

- OSPF: обратите внимание на Network Type
- Network Type Point-2-Point
 - Предпочтительно (только LSA type-1)
 - Нет выборов DR/BDR
 - Хорошо подходит для маршрутизируемых интерфейсов/портов (оптимально с точки зрения LSA DB)
 - Полный пересчет SPF в случае изменений на линках

- IS-IS: что за CLNS такой?....
 - Не зависит от IP (CLNS)
 - Хорошо подходит для маршрутизируемых интерфейсов/портов
 - Нет пересчета SPF в случае изменений на линках
 - Быстрая сходимость
 - Аналог единственной зоны – использование Level-2
 - Не все хорошо с ним знакомы...

Для информации:

Работы по оптимизации IGP: Flood Optimization и Leaf/Spine Networks
`draft-ietf-lsr-isis-spine-leaf-ext & draft-li-lsr-dynamic-flooding`


Маршрутизация underlay – BGP???

- eBGP Underlay маршрутизация «в духе SP/MSDC»
 - Придумана для не-оверлейных L3 фабрик (RFC7938)
 - Значительный объем «подстройки» для VXLAN фабрики
 - Две модели внедрения
 - Two-AS
 - Multi-AS
- BGP - Distance Vector (Path Vector) протокол
 - Знает только про AS_Path, не про скорости или стоимость
 - Не забудьте включить ECMP
- Сохраняется ли «независимость» overlay/underlay??
- «Разный» пиринг
 - На физических интерфейсах для underlay
 - На Loopback-ах для EVPN (BFD не нужен)

*Подробнее о том, почему eBGP для underlay и уровня управления overlay не очень хорошая идея:


<https://learningnetwork.cisco.com/s/blogs/a0D3i000002eeaeAQ/the-magic-of-superspines-and-rfc7938-with-overlays-guest-post>

Unicast Routing – eBGP Two-AS Model



- eBGP Two-AS – да, так можно!
- eBGP пиринг для Underlay
 - Retain Route-Targets
 - Disable BGP AS-Path check
- Underlay отвечает за достижимость!
 - Анонсируйте Loopback-и
- Специальные требования для Overlay Control-Plane
 - Next-Hop Unchanged
 - Disable BGP AS-Path check


Unicast Routing – eBGP Multi-AS Model



- eBGP Multi-AS, воспроизводим Internet
- eBGP пиринг для Underlay
 - Retain Route-Targets
 - Disable BGP AS-Path check
 - Next-Hop Unchanged
- Underlay отвечает за достижимость!
 - Анонсируйте Loopback-и
- Специальные требования для Overlay Control-Plane
 - Next-Hop Unchanged

BUM репликация в Underlay с помощью multicast PIM ASM


- PIM Any-Source-Multicast (ASM)
- Поддержка оборудованием
 - Nexus 9000 / Nexus 7000 (F3/M3)
 - ASR 1000 / ASR 9000
- Резервирование RP
 - PIM Anycast-RP или MSDP
- Source-Trees (однонаправленные)
 - 1 Source Tree для каждого VTEP для каждой Multicast группы



Настройка метода распространения BUM трафика выполняется для VNI
Разные методы multicast и ingress replication могут комбинироваться на одном устройстве

BUM репликация на VTEP: Ingress Replication

- «Умножение» пакетов
- Поддержка платформами
 - Nexus 9000
- Ingress Replication
 - Хост отправляет 1 пакет на VTEP
 - VTEP на входе инкапсулирует пакет и размножает его по числу VTEP в данном L2VNI
- Не требуется отдельного control plane



Настройка метода распространения BUM трафика выполняется для VNI
Разные методы multicast и ingress replication могут комбинироваться на одном устройстве

Управление VXLAN/EVPN фабрикой

Data Center Network Manager (DCNM)

Единый продукт, три режима эксплуатации

- VXLAN EVPN фабрика (с поддержкой традиционных технологий)
- IP Media Network Controller (PMN)
- SAN (MDS & Nexus)

Инструмент эксплуатации

- Real-Time Topology
- Integrated Compute Visibility
- Performance Monitoring
- Fault Management
- Configuration Compliance
- Image Management, Upgrades and RMA

Сквозная настройка сетевых ресурсов

- GUI/API-based provisioning
- Multi-Fabric & Multi-Site
- Network Configuration Backup & Restore


Задачи «нулевого», «первого» и «второго» дня эксплуатации!

Режим LAN Fabric в DCNM 11

Deploy

Centralized config push

4



Define

Define Intent based on best practices

- Underlay
- Interfaces
- Overlay

1



Preview

Side-by-side diff

3



Save


Generates configuration based on intent

2



Фабрика готова за несколько минут!

Cisco DCNM: автоматическое развёртывание VXLAN фабрики С использованием шаблонов и POAP



Turn-Key VTEP
Deployment




Simplified
Deployment



Managed-Fabric
Operations

Управление оверлеями «сверху-вниз»


- Настройка Top-Down через GUI или REST APIs
- Создание сетей /VRF Creation на основе политик
- Настройка на коммутаторах и/или интерфейсах
- История настроек для коммутатора/сети
- Отслеживание ресурсов для VNIs, VLANs и т.д.
- Централизованное управление всеми настройками, включая оверлеи



Настройка внешней связности для внедрения на основе VXLAN-EVPN

- Настройка внешней связности от Border к WAN
 - VRF Lite с использованием субинтерфейсов
- Настройка Layer-2 и Layer-3 DCI связности с помощью EVPN Multi-Site
 - Настройка внешнего пиринга для Multi-Site Underlay и Overlay с использованием Multi-Site Domain (MSD)
 - MSD – «фабрика фабрик»
 - Определение сетей и VRF один раз
 - Поддержка TRM

Fabric Compliance – Underlay / Overlay / Access



Compliance



Fabric Reliability &
Visibility



Operations
Confidence

Эксплуатационные функции в DCNM

- Мониторинг
 - Отказы, предупреждения
 - Температура
 - Статистика
 - Интеграция с VMM и контейнерными доменами
 - Мониторинг endpoints в MP-BGP EVPN таблицах
 - ...
- Запуск дополнительных приложений для эксплуатации
 - Nexus Insights

