ACI Endpoint Learning Deep Dive

Cisco Systems Inc.

2020年 4月

Agenda

1. Endpoint Learning 要点 : 最適化パラメータ、Gen 2 Leaf 動作、ベストプラクティス
2. Endpoint 基礎 : Endpoint Table, Local / Remote Endpoint, Spine Proxy
3. Endpoint Table と COOP DB : COOP DB, Endpoint Table, Verified Scalability
4. Forwarding 基礎 : L2転送, L3転送, L3out転送
5. Endpoint 学習動作 : Local Endpoint学習, Remote Endpoint学習, L3out通信時 + **Issue Case #1-4**
6. Endpoint 移動への対応 : Bounce Entry, Retention Timer + **Issue Case #5-7**
7. Endpoint サイレントホスト対応 : Unknown MAC, Unknown IP, ARP Flooding
8. Endpoint Learning パラメータ詳細

参考資料

- ACI Fabric Endpoint Learning White Paper

  https://www.cisco.com/c/en/us/solutions/collateral/data-center-virtualization/application-centric-infrastructure/white-paper-c11-739989.html
- Cisco Live! BRKACI-2641 ACI Troubleshooting – Endpoints

  https://www.ciscolive.com/c/dam/r/ciscolive/emea/docs/2020/pdf/BRKACI-2641.pdf

ACI How To は移行しました!!

ACI How To は、learningnetwork から community に移行しました。
https://community.cisco.com/t5/%E3%83%87%E3%83%BC%E3%82%BF%E3%82%BB%E3%83%B3%E3%82%BF%E3%83%BC-%E3%83%89%E3%82%AD%E3%83%A5%E3%83%A1%E3%83%B3%E3%83%88/cisco-aci-how-to/ta-p/4039933

旧ページの資料は当面維持されますが、システム更新に伴い全ページのURLが変更されています。
また、新しい情報については community 側でのみ更新されますのでご注意下さい!!

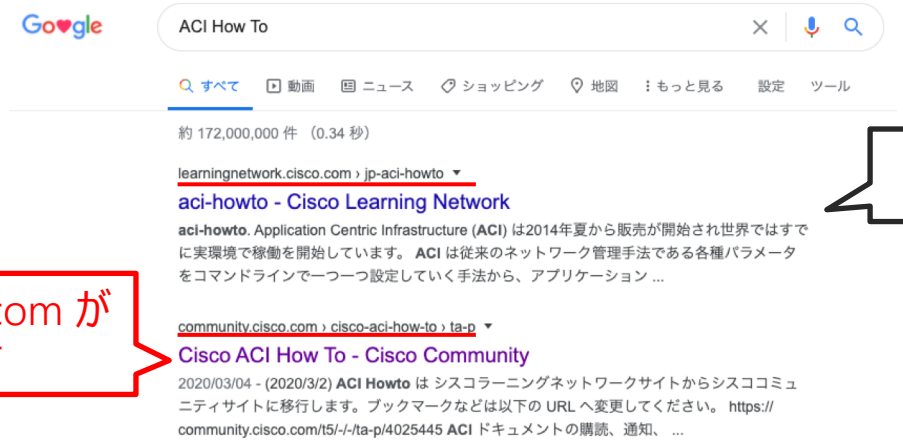

learningnetwork.cisco.com は古い方です

community.cisco.com が新しい方です

Endpoint Learning 要点

ACI Endpoint Learning 最適化パラメータ

	パラメータ [関連スライド番号]	設定箇所	実装 バージョン	用途	考慮点
EPG	**L4-L7 Virtual IPs** [74-74]	Tenant > Application Profiles > EPG / uSeg EPG	1.2(1m)	DSR動作のための仮想IPアドレスに対するData-Plane Learningを無効化する	用途としてDSR対応以外では正式にはサポートされない(開発側として未検証)
BD	**Unicast Routing** [27, 67, 77]	Tenant > Networking > Bridge Domains	1.0(1e)	当該BDでL3 Routing動作をするためにEndpointのIPアドレスを学習する	Disableにすると当該BD範囲でIPアドレスは学習しない
BD	**EP Move Detection Mode (GARP based detection)** [67, 78]		1.1(1j)	GARP情報からIPの移動を検出することで、同一Interface配下でのMACアドレス間での特定IPアドレスの移行に対応する	Unicast RoutingおよびARP Floodingを必ず有効化する必要がある (Gen 2 Leafでは対処不要)
BD	**Limit IP Learning To Subnet** [7, 36, 44-46, 79]		1.1(1j)	BDに構成したSubnet範囲外のIPアドレスはLocal Endpointとして学習しない	Remote Endpointとしての学習を防止することはできない
BD	**IP Data-plane Learning (BD)** [6, 51, 80]		2.0(1m)	当該BDでData-planeからのIPアドレスの学習を無効化する (PBR用のL4-7デバイス対応)	PBRを利用するService Graphのための機能
VRF	**IP Data-plane Learning (VRF)** [6, 49-50, 82, 91]	Tenant > Networking > VRFs	4.0(1h)	VRF範囲でData-planeからのIPアドレスの学習を無効化する	
Fabric	**Disable Remote EP Learning (on Border Leaf)** [6, 7, 36, 45, 63-64, 84]	System > System Settings > Fabric-Wide Settings	2.2(2e) 3.0(1k)	Ingress Policy Enforcementが構成されているVRFに紐づくL3outを持つBorder LeafでRemote EndpointのIPアドレス学習を無効化する	Gen 2 Leafの場合はL3 Multicastからは学習する (Gen 1 LeafはL3 Multicastをサポートしない)
Fabric	**Enforce Subnet Check** [7, 34, 36, 44, 47, 60, 85]		2.2(2q) 3.0(2h)	VRFに紐づくBDに構成されているSubnet範囲外のIPアドレスをLocal / Remote Endpointとして学習しない	Gen 2 Leaf に対してのみ有効 ※2.3および3.0(1)では利用できない
Fabric	**IP Aging** [7, 42, 49-50, 88-89]	System > System Settings > Endpoint Controls	2.1(1h)	Endpoint情報としてMACアドレスに紐付けて学習されているIPアドレスについて個別にAgingによりタイムアウト管理する	ACI 2.1(1h)以降ではデフォルト有効
Fabric	**Rouge EP Control** [39, 87]		3.2(1l)	一定以上のEndpointの頻繁な移動に対する負荷軽減	問題解決には直接はつながらない
Fabric	**EP Loop Protection** [40, 86]		1.0(1e)	一定以上のEndpointの頻繁な移動をLoopとみなす	対象以外にも影響を与える場合がある

ACI Endpoint Data-plane Learning 動作

構成			Data-plane 学習動作				
IP Data-plane Learning (VRF)	**IP Data-plane Learning (BD)**	**Disable Remote EP Learn (Global)**	**Local MAC**	**Local IP**	**Remote MAC**	**Remote IP (Unicast)**	**Remote IP (Multicast)**
Disabled	Enable/Disable どちらでも動作は変化しない	Enable/Disable どちらでも動作は変化しない	学習する	学習しない ARP/NDでは学習する	学習する ※Gen1は学習しない	学習しない	学習する ※Gen1はL3 Multicast非サポート
Enabled (Default)	**Disabled**	Enable/Disable どちらでも動作は変化しない	学習する	学習しない ARP/NDでは学習する	学習しない	学習しない	学習しない
Enabled (Default)	**Enabled (Default)**	**Disabled**	学習する	学習する	学習する	Border Leafのみ 学習しない	学習する
Enabled (Default)	**Enabled (Default)**	**Enabled (Default)**	学習する	学習する	学習する	学習する	学習する

Gen 2 モデルとは、型番の最後が –EX, -FX, -FX2, -GX などハイフンの後にXを含むものを指す。
-E はGen 1.5であり、広義にはGen 1 に含まれる。

ACI Endpoint Learning : ベストプラクティス

パラメータ	Gen 1 only	Gen 2 only	Gen 1 & Gen 2 mix
Limit IP Learning To Subnet	**Enabled** ※2.3(1e)および3.0(1k)以降でデフォルト有効	**構成しなくてもよい** ※ただし2.3(1e)および3.0(1k)以降でデフォルト有効	**Enabled** ※2.3(1e)および3.0(1k)以降でデフォルト有効
Disable Remote EP Learning (on Border Leaf)	ACI 3.2(2l)より前 かつ Policy Control Enforcement : Ingress の場合 **Enabled** ※必要に応じて手動での学習済Remote Endpointのクリアを実施 ACI 3.2(2l)以降の場合 **構成不要**(下記参照)	ACI 3.2(2l)より前 かつ Policy Control Enforcement : Ingress の場合 **Enabled** ※必要に応じて手動での学習済Remote Endpointのクリアを実施 ACI 3.2(2l)以降の場合 **構成不要**(下記参照)	ACI 3.2(2l)より前 かつ Policy Control Enforcement : Ingress の場合 **Enabled** ※必要に応じて手動での学習済Remote Endpointのクリアを実施 ACI 3.2(2l)以降の場合 **構成不要**(下記参照)
Enforce Subnet Check	**無効**	**Enabled**	**Enabled** ※効果があるのはGen 2のみ
IP Aging	**Enabled** ※2.1(1h)以降でデフォルト有効	**Enabled** ※2.1(1h)以降でデフォルト有効	**Enabled** ※2.1(1h)以降でデフォルト有効

ACI 3.2(2l)以降では[EP Announce on Bounce Delete]機能が自動的に利用可能となるため、意図しないRemote Endpoint情報がエントリされたままとなる問題を防止できる(CSCvj17665)。

Endpoint 基礎

Endpoint とは ACI 内部の接続端末情報

従来のネットワーク機器におけるMACアドレスとIPアドレスの学習動作とは異なり、ACIではホストルートとしてMACアドレステーブルとARPテーブルではなくEndpointテーブルを利用する(外部接続を除く)。ホストルート以外はRIBが合わせて参照される。

Table	含まれる情報	概要
RIB	Routing Table (内部ホストルートを除く)	ACIにおいてもVRF毎にRouting Tableが構成され、必要に応じてAPICからLeafに対してプログラムされる
Endpoint	MACアドレス・IPアドレス	1つのエントリーにMACアドレスは1つ、IPアドレスは なし or 1つ or 複数 IPアドレスはホストルート /32 (IPv4) or /128 (IPv6) でのみ学習する
ARP	L3out 隣接ノードについては、ARPに基づいて IPアドレスに紐づく対向ピアのMACアドレスを学習する	

ACI内部ではARP(= Control-plane)のみに依存せず、Leafスイッチに届いたパケットの送信元MACアドレス・IPアドレスから "も" Endpointを学習する(= Data-plane Learning)。

※DownlinkからのパケットではLocal Endpoint、UplinkからのパケットではRemote Endpointとして学習する

APIC における Endpoint = Object

MACアドレス Object と、それに紐づく IPアドレス Object

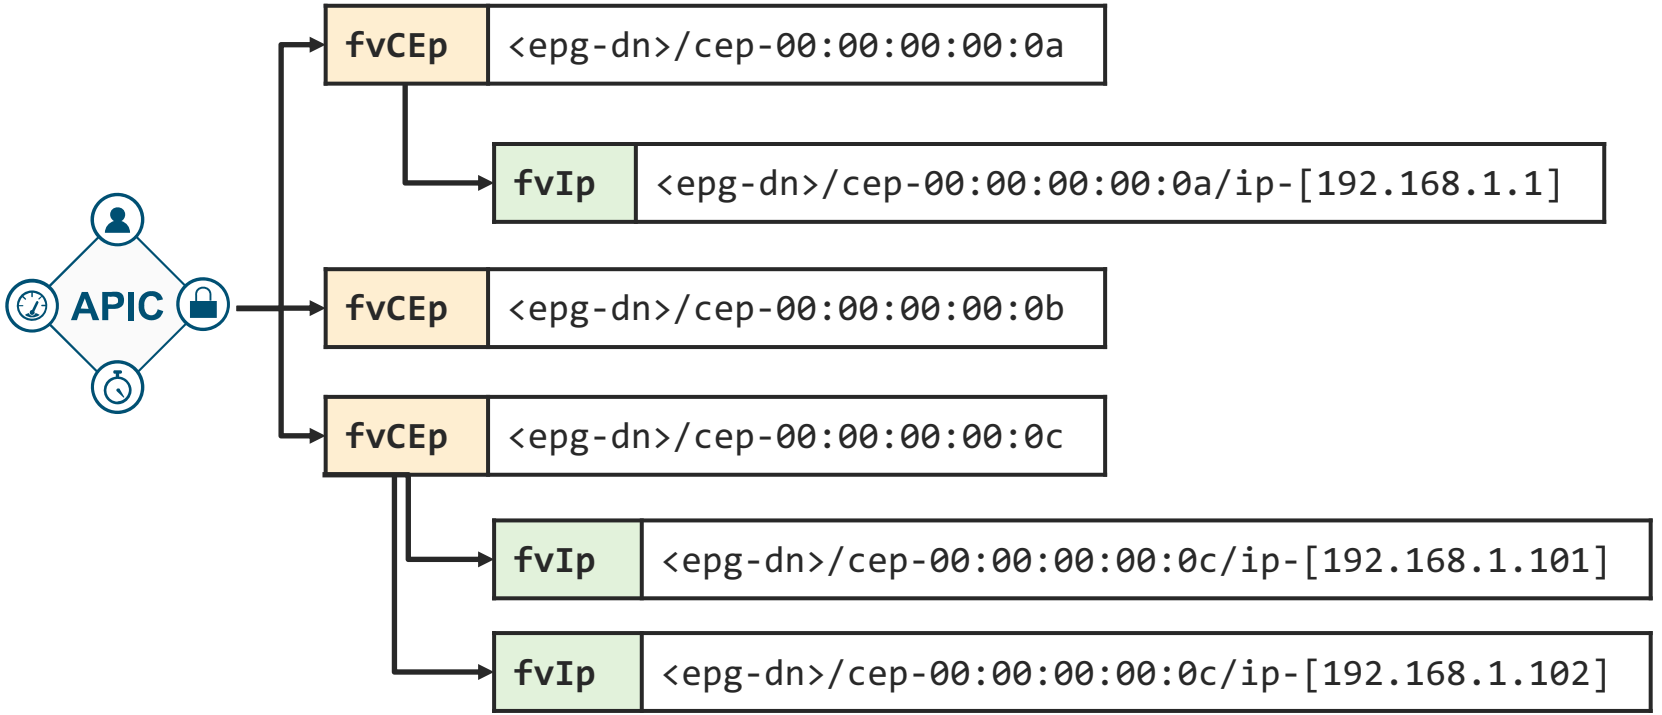

Local Endpoint と Remote Endpoint

各Leafスイッチは自身のDownlink側から学習したEndpoint情報をLocal Endpoint、Fabric Port側から学習したEndpoint情報をRemote Endpointとして区別して扱う。

Endpoint種別	学習対象	利用目的
Local Endpoint	1エントリに必ず1つのMACアドレスと、必要に応じて1つ以上のIPアドレスの組合せ	自身の配下に存在するEndpoint情報の把握と、COOPを通じたSpineへの通知
Remote Endpoint	VRFのVNIDに紐づく場合はIPアドレスのみ、BDのVNIDに紐づく場合はMACアドレスのみ	キャッシュとポリシー適用の最適化のために利用 ※COOPによる通知対象ではない

Local Endpoint、Remote Endpoint いずれについてもACIはデフォルトではData-planeでの学習も行う(送信元MAC/IPアドレスに基づく学習)。※ARP/ND学習も利用する

※VPC構成の場合はVPCノードはもちろん、Orphanノードについても VPCピア間で同期されるため、これらのノードはVPCペア同士でLocal Endpointとして扱われる。

Endpoint学習動作の違い

Local Endpointは学習したDownlinkポートとEncap VLANに紐付いて
Data-planeとControl-plane (ARP/ND)を通じて学習される。

Remote EndpointはVXLANの対向VNIDとTunnelインターフェイスに紐付いて
Data-planeを通じて学習される。

LeafスイッチはData-planeとControl-planeを通じてEndpointを学習する。
→ **Endpoint Table**

SpineスイッチはCOOPを通じてのみEndpointを学習する。
→ **COOP DB**

Endpoint Table と COOP DB

APIC : Capacity Dashboard

APIC [Operations] > [Capacity Dashboard] の数字はどう計算されている？

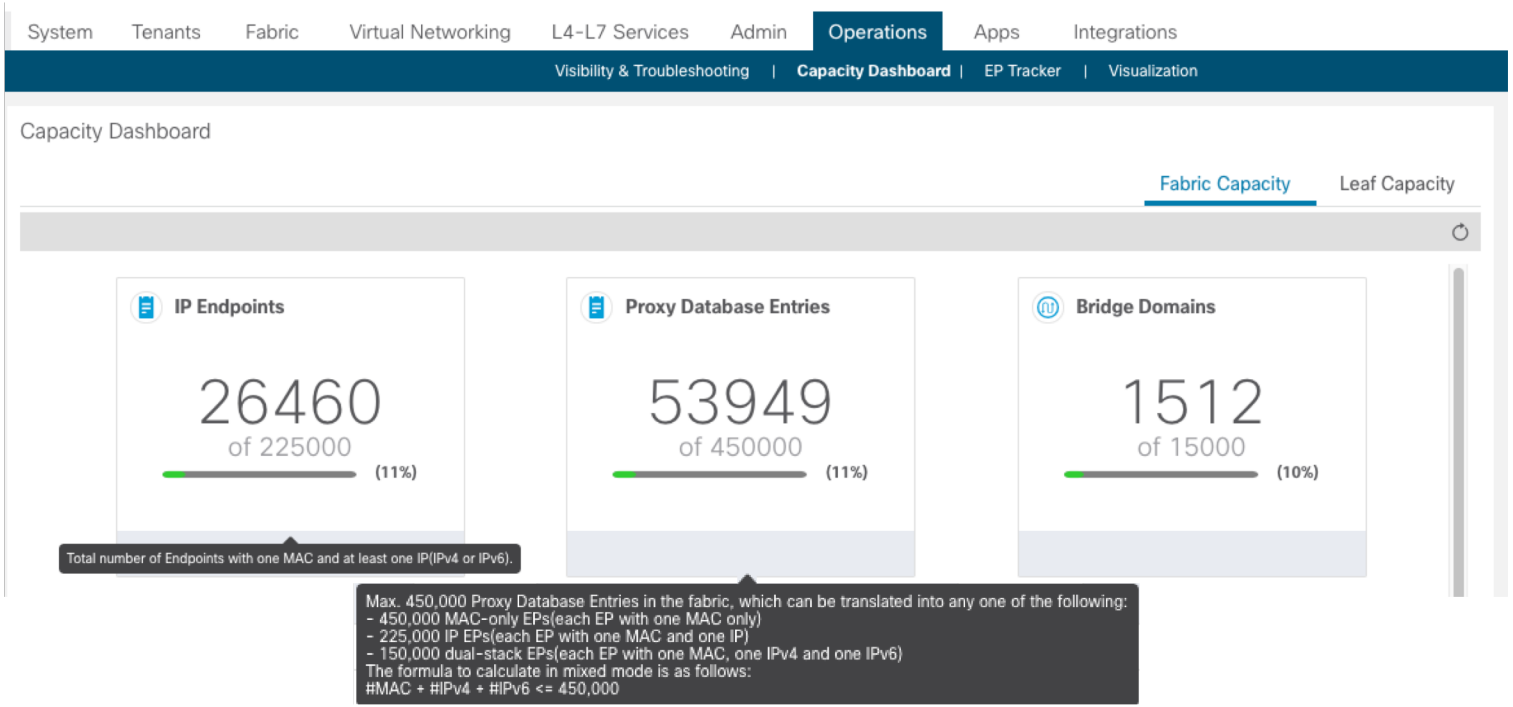

COOP (Council of Oracles Protocol) DB

ACI Fabric では Leaf スイッチと Spine スイッチは明確に役割が分けられている。

- COOP citizen である Leaf スイッチは、学習した Local Endpoint 情報を COOP を通じて Spine スイッチに通知する(Zero Message Queue : ZMQ)
- COOP oracle である Spine スイッチは、COOP 情報を相互に同期する

ただし、VPCを構成しているLeaf同士の間でのみ、Orphan port を含む Local Endpoint情報が同期される。

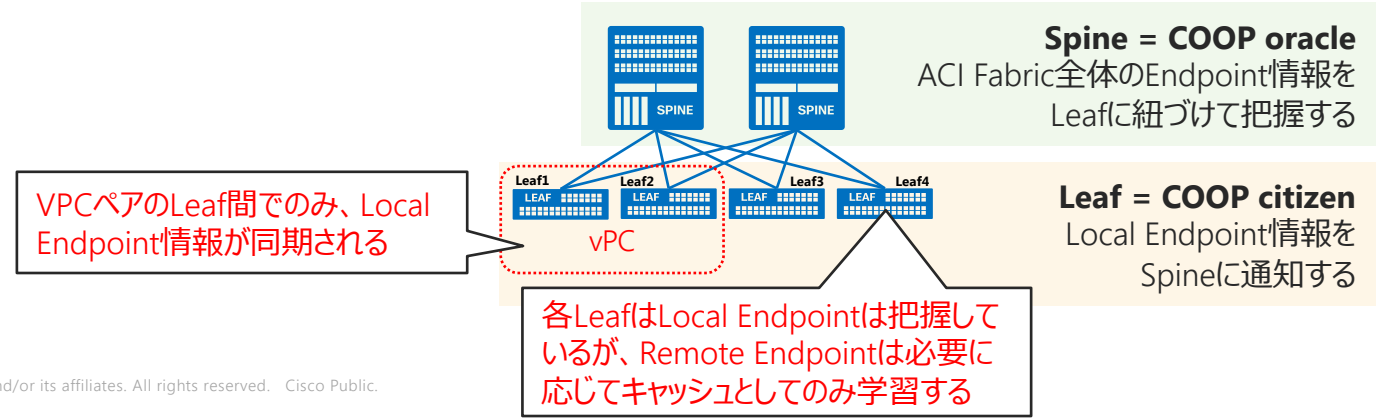

COOP DB エントリ

```
Pod1-Spine1# show coop internal info repo ep key 16220082 0050.5680.e818

EP bd vnid : 16220082
EP mac :  00:50:56:80:E8:18
flags : 0x80
repo flags : 0x122
Vrf vnid : 2326530
Epg vnid : 0
EVPN Seq no : 0
Remote publish timestamp: 01 01 1970 09:00:00 0
Snapshot timestamp: 03 23 2020 10:03:43 337833079
Tunnel nh : 10.0.120.64
MAC Tunnel  : 10.0.120.64
IPv4 Tunnel : 10.0.120.64
IPv6 Tunnel : 10.0.120.64
ETEP Tunnel : 0.0.0.0
num of active ipv4 addresses : 1
num of anycast ipv4 addresses : 0
num of ipv4 addresses : 1
Primary Path:
Current published TEP : 10.0.120.64
Current citizen (publisher_id): 10.0.120.64
Previous citizen : 10.0.120.64
Prev to Previous citizen : 10.0.120.64
Real IPv4 EP : 192.168.1.221
Current publisher_id: 10.0.120.64
MAC Tunnel  : 10.0.120.64
IPv4 Tunnel : 10.0.120.64
```

BD VNID

※出力を一部省略しています

```
Pod1-Spine1# show coop internal info ip-db key 2326530 192.168.1.221

IP address : 192.168.1.221
Vrf : 2326530
Flags : 0
EP bd vnid : 16220082
EP mac :  00:50:56:80:E8:18
Publisher Id : 10.0.120.64
Record timestamp : 03 23 2020 10:03:43 337833079
Publish timestamp : 03 23 2020 10:03:43 340608835
Seq No: 0
Remote publish timestamp: 01 01 1970 09:00:00 0
URIB Tunnel Info
Num tunnels : 1
        Tunnel address : 10.0.120.64
        Tunnel ref count : 1
```

VRF VNID

```
Pod1-Leaf1# show system internal epm endpoint ip 192.168.1.221

MAC : 0050.5680.e818 ::: Num IPs : 1
IP# 0 : 192.168.1.221 ::: IP# 0 flags : host-tracked| ::: l3-sw-hit:
Yes ::: flags2 :
Vlan id : 39 ::: Vlan vnid : 8703 ::: VRF name : tsetaka demo1:VRF1
BD vnid : 16220082 ::: VRF vnid : 2326530
Phy If : 0x1a021000 ::: Tunnel If : 0
Interface : Ethernet1/34
Flags : 0x80005c04 ::: sclass : 49155 ::: Ref count : 5
EP Create Timestamp : 03/09/2020 20:06:02.341638
EP Update Timestamp : 03/23/2020 10:22:26.121418
EP Flags : local|IP|MAC|host-tracked|sclass|timer|
```

Spine における Endpoint = COOP DB → HW

COOP DB のエントリは Spine ハードウェアエントリとなり ハードウェア処理される

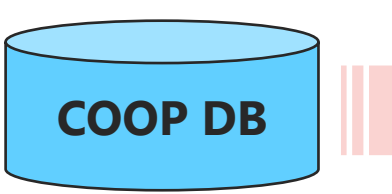


```
mac – 00:00:00:00:0a
      count – 1
      ip0 - 192.168.1.1
```

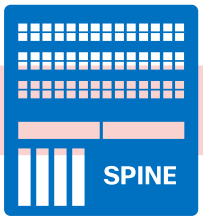

Hardware Entry

Endpoint	Synthetic IP
00:00:00:00:0a	xxx.xxx.xxx.xxx
192.168.1.1	yyy.yyy.yyy.yyy

Remote Endpoint 学習と Spine Proxy

各Leafスイッチは自身が送信先を把握していないEndpoint宛の通信をSpineに転送する Spine Proxy の機能を備えているが、Remote Endpoint の情報をキャッシュすることで、毎回Spineを経由することなく直接VXLAN Tunnel経由でのLeaf間転送が可能となる(Spineの負荷軽減と転送処理時間の最小化)。

また、送信元Leaf側でSource EPGとDestination EPGの組み合わせを把握できていれば、送信元Leaf側でPolicyの適用が可能となるため、無駄な通信をFabric内に流さずに済む(Ingress Policy Enforcement)。

ACI構成ノードにおける MAC/IP アドレスの扱い

Spineが持つCOOP DBでは、1つのEndpoint情報として1つのMACアドレスに加えて、必要に応じて1つもしくは複数のIPアドレスが紐付けて管理されるが、Endpoint Tableとしてはそれぞれの MACアドレスとIPアドレスは分けて構成される。そのため、Scalability はMACアドレス、IPv4アドレス、IPv6アドレスのそれぞれの最大値と合計した値の両方で決定される。

- Leaf の Scalability は、HWモデルと構成している Scale Profile 次第で決定される
- Spine の Scalability は、Modular・Fixedの選択で決定される

Leaf / Spine の Endpoint 最大エントリ数

Leaf側のScalability
(使用モデルとScale Profileの選択で異なる)

ALE/LSE Type	ACI-Supported ToR switches
ALE v1	• N9K-C9396PX + N9K-M12PQ • N9K-C93128TX + N9K-M12PQ • N9K-C9396TX + N9K-M12PQ
ALE v2	• N9K-C9396TX + N9K-M6PQ • N9K-C93128TX + N9K-M6PQ • N9K-C9396PX + N9K-M6PQ • N9K-C9372TX 64K • N9K-C9332PQ • N9K-C9372PX
LSE	N9K-C93108TC-EX N9K-C93180YC-EX N9K-C93180LC-EX N9K-C9336C-FX2 N9K-C93216TC-FX2 N9K-C93240YC-FX2 N9K-C93360YC-FX2
LSE2	N9K-C93108TC-FX N9K-C93180YC-FX N9K-C9348GC-FXP N9K-C93600CD-GX

Maximum number of endpoints (EPs)

Default (Dual Stack) profile:
- ALE v1 and v2:
  - MAC: 12,000
  - IPv4: 12,000 or
  - IPv6: 6,000 or
  - IPv4: 4,000
    IPv6: 4,000

Default profile or High LPM profile:
- LSE or LSE2:
  - MAC: 24,000
  - IPv4: 24,000
  - IPv6: 12,000

IPv4 scale profile:
- LSE and LSE2:
  - MAC: 48,000
  - IPv4: 48,000
  - IPv6: Not supported
- ALE v1 and v2: Not supported

High Dual Stack scale profile:
- LSE:
  - MAC: 64,000
  - IPv4: 64,000
  - IPv6: 24,000
- LSE2:
  - MAC: 64,000
  - IPv4: 64,000
  - IPv6: 48,000
- ALE v1 and v2: Not supported

High Policy profile:
- LSE2 (N9K-C93180YC-FX and N9K-C93600CD-GX with 32GB of RAM only):
  - MAC: 24,000
  - IPv4: 24,000
  - IPv6: 12,000

Modular spine switches:
Max. 450,000 Proxy Database Entries in the fabric, which can be translated into any one of the following:
- 450,000 MAC-only EPs (each EP with one MAC only)
- 225,000 IPv4 EPs (each EP with one MAC and one IPv4)
- 150,000 dual-stack EPs (each EP with one MAC, one IPv4, and one IPv6)

The formula to calculate in mixed mode is as follows:
#MAC + #IPv4 + #IPv6 <= 450,000
NOTE: Four fabric modules (N9K-C9508-FM-E) are required on all spines in the fabric to support above scale.

Spine側のScalability
(Modular / Fixed で異なる)

Fixed spine switches (N9K-C9364C and N9K-C9316D-GX):
Max. 180,000 Proxy Database Entries in the fabric, which can be translated into any one of the following:
- 180,000 MAC-only EPs (each EP with one MAC only)
- 90,000 IPv4 EPs (each EP with one MAC and one IPv4)
- 60,000 dual-stack EPs (each EP with one MAC, one IPv4, and one IPv6)

The formula to calculate in mixed mode is as follows:
#MAC + #IPv4 + #IPv6 <= 180,000

※Verified Scalability 4.2(3)

Forwarding 基礎

※詳細は “ACI Design : Forwarding Behavior Deep Dive” 参照

ACI Forwarding 概要

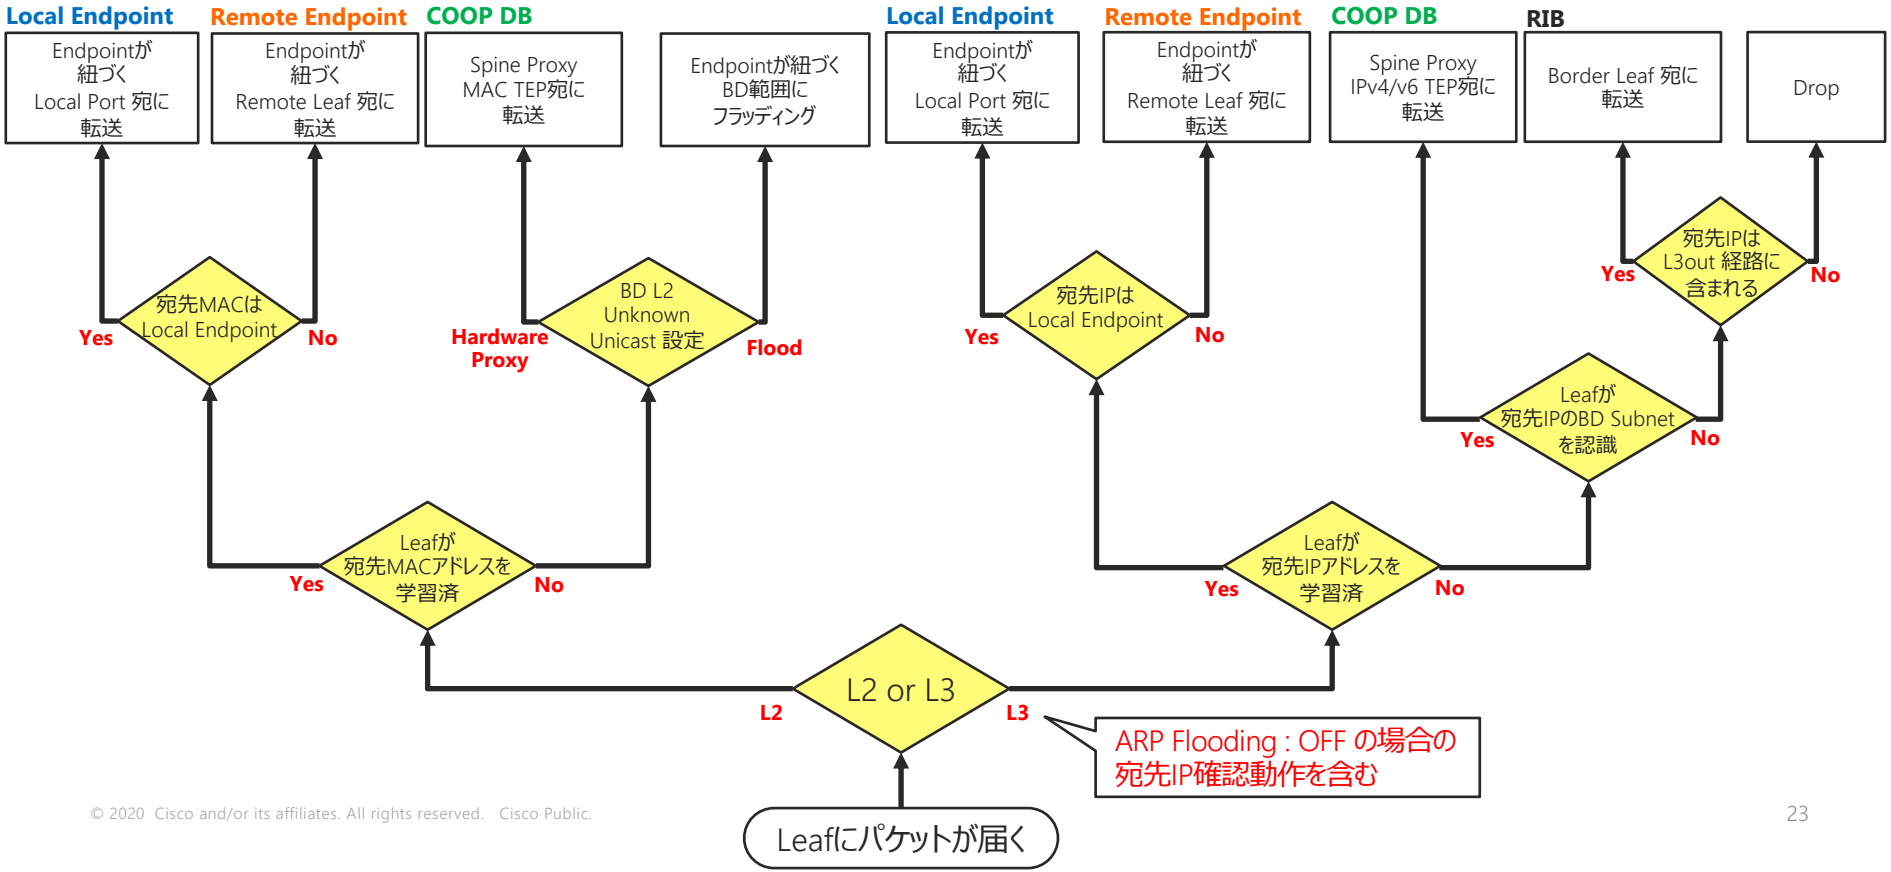

Endpoint 学習動作

参考：従来のスイッチにおける学習動作

IPアドレスに紐づくMACアドレスの解決にはARP/NDを利用する

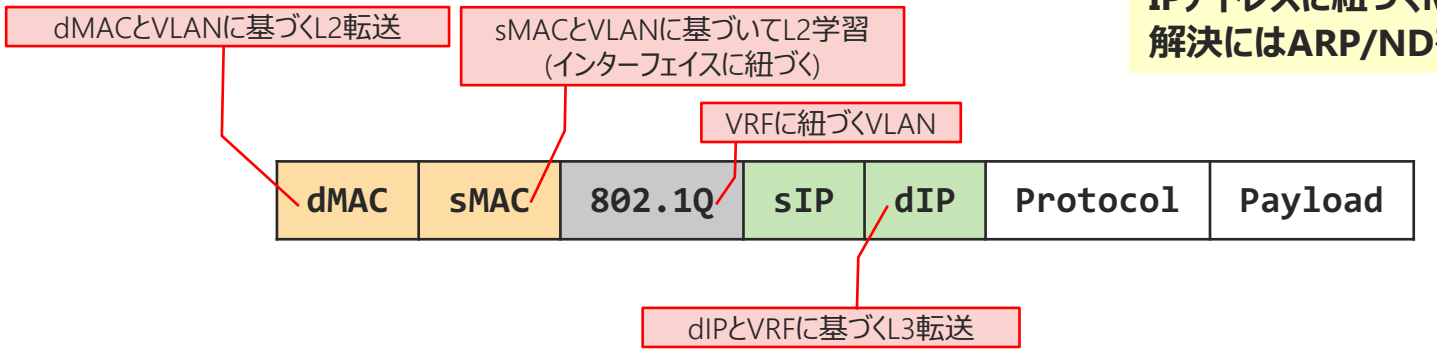

L2転送	
dMAC + VLAN → エントリにヒット	宛先ポートに転送
dMAC + VLAN → GW MAC	ルーティング処理
dMAC + VLAN → ミス	Flooding

L3転送 (LPM)	
VRF + dIP → エントリにヒット	Next Hop に転送
VRF + dIP → ミス	Drop

Local Endpoint の学習方法

Local Endpoint は 当該Leafのフロントパネルポート(非Fabricポート)から学習する

Local Endpoint	学習方法
MAC Address	フロントパネルポートから受信したパケット・フレームのSource MACアドレスを学習する
IP Address	フロントパネルポートから受信したACI BD Gateway宛パケットのSource IPアドレスを学習する (Data-plane Learning)
	フロントパネルポートから受信したARP/NDリクエストのSender IPアドレスを学習する (Control-plane Learning)

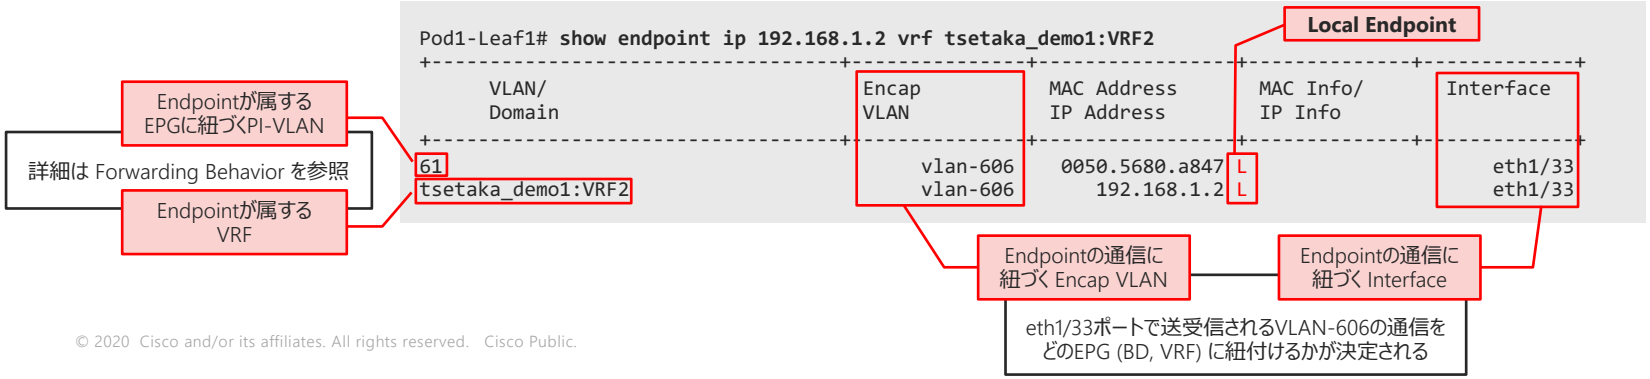

Local Endpoint 学習動作

IPアドレスに紐づくMACアドレスの解決にはFloodもしくはSpine Proxyを利用する

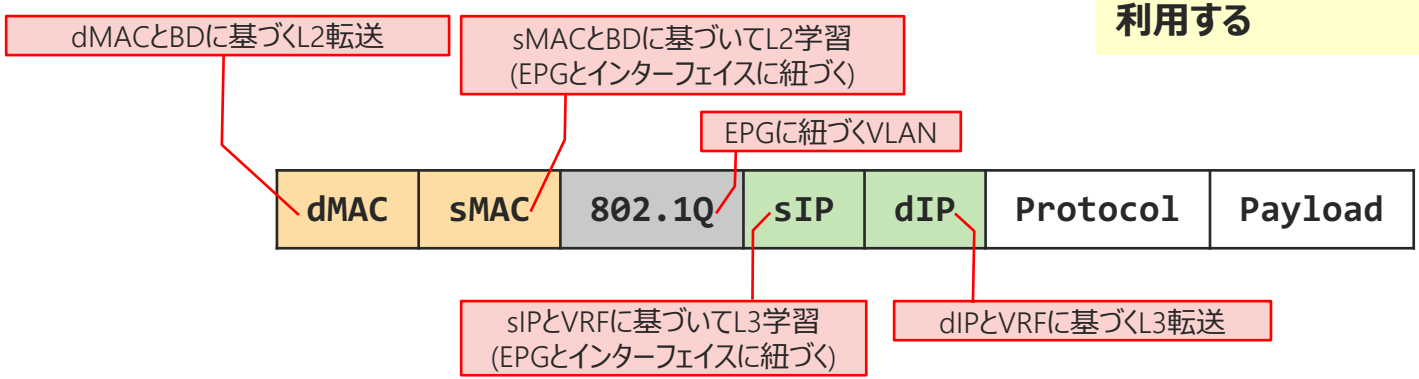

L2転送	
dMAC + BD → エントリにヒット	宛先ポート もしくは Next Hop に転送
dMAC + BD → GW MAC	ルーティング処理
dMAC + BD → ミス	Flooding もしくは Spine Proxy + Drop

L3転送 (LPM)	
VRF + dIP → エントリにヒット	宛先ポート もしくはNext Hop に転送
VRF + dIP → ミス	Drop + Spine Proxy (必要に応じてSpine側でARP Glean)

Unicast Routing 設定と Endpoint 学習

Local Endpointの学習動作は紐づくBDの設定によって学習対象が異なる。
COOPによる通知対象。デフォルトの Retention Timer は 900秒 (15分)。

BD設定	MACアドレス	IPアドレス
Unicast Routing 無効	Data-plane 学習	学習しない
Unicast Routing 有効	Data-plane 学習	ARP/ND および Data-plane学習 ※DP学習はRouting通信の場合のみ

※例外として、Infra VLANについてはIPアドレスの学習は行われない

Remote Endpoint の学習方法

Remote Endpoint は 当該LeafのFabricポート(Spine接続ポート)から学習する

Remote Endpoint	学習方法
MAC Address	FabricポートからEthernetフレーム(L2)のSource MACアドレスを学習する (iVXLANヘッダに含まれるVNIDはBDに紐づく) ※IPアドレスとは紐付けられない
IP Address	FabricポートからIPパケット(L3)のSource IPアドレスを学習する (iVXLANヘッダに含まれるVNIDはVRFに紐づく) ※MACアドレスとは紐付けられない

```
Pod1-Leaf1# show endpoint ip 192.168.1.1 vrf tsetaka_demo1:VRF2
+-----------------------------------+---------------+-----------------+--------------+-------------+
      VLAN/                         Encap           MAC Address       MAC Info/      Interface
      Domain                        VLAN            IP Address        IP Info
+-----------------------------------+---------------+-----------------+--------------+-------------+
tsetaka_demo1:VRF2                                        192.168.1.1                    tunnel5

Pod1-Leaf1# show endpoint mac 0050.5680.a836 vrf tsetaka_demo1:VRF2
+-----------------------------------+---------------+-----------------+--------------+-------------+
      VLAN/                         Encap           MAC Address       MAC Info/      Interface
      Domain                        VLAN            IP Address        IP Info
+-----------------------------------+---------------+-----------------+--------------+-------------+
58/tsetaka_demo1:VRF2               vxlan-16646017    0050.5680.a836                 tunnel5
```

Remote Endpointが紐づくVRF

Remote IPアドレスはVRF VNIDに紐づく

表示されるPI-VLANは自身が管理するBDに紐づくVLAN

Remote Endpointが紐づくPI-VLANとVRF

Remote Endpointが存在するノードとの間のVXLANトンネルInterface

詳細は Forwarding Behavior をあわせて参照

BDが紐づくVXLAN VNID

Remote Endpoint 学習動作

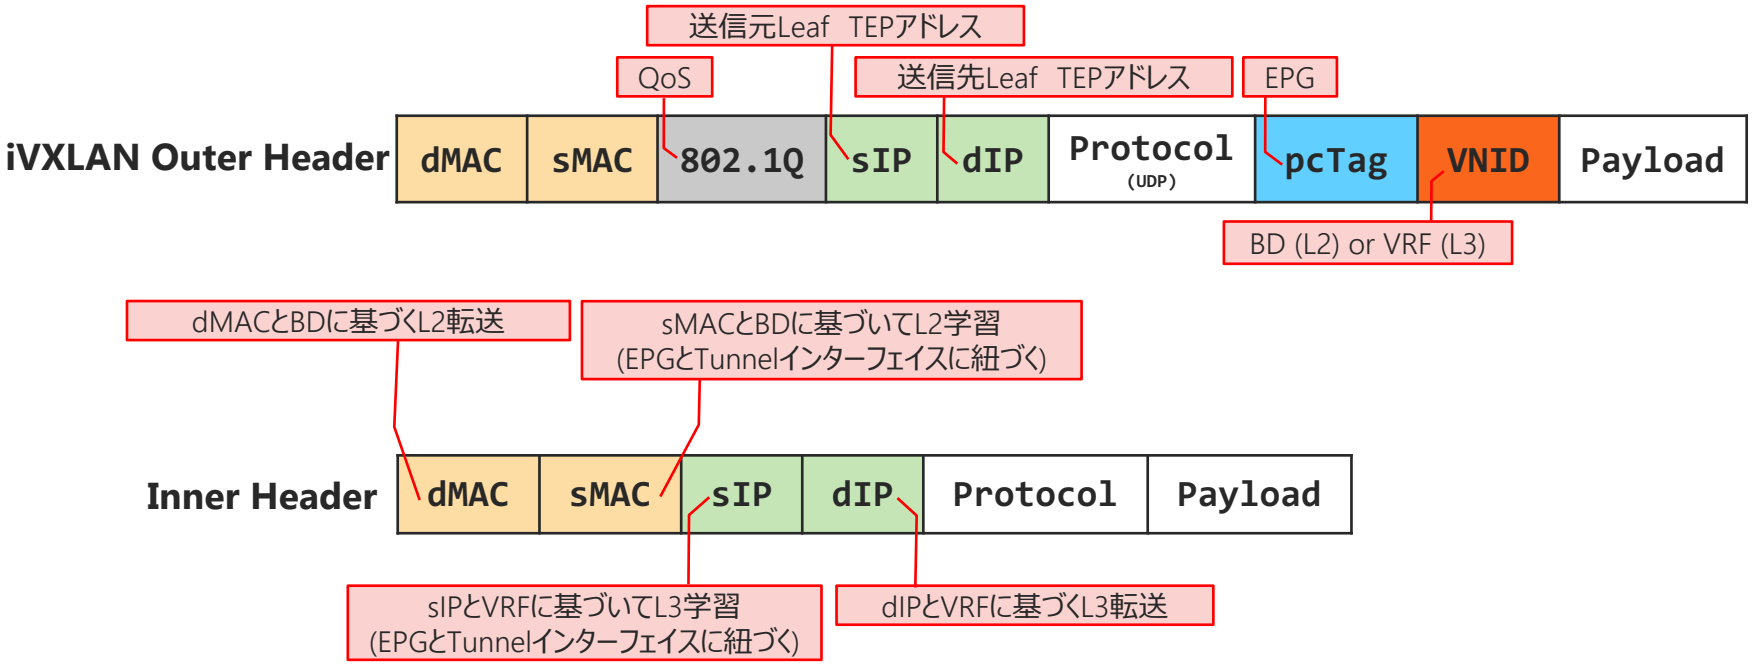

VNIDとRemote Endpoint学習

Remote Endpointの学習動作はVXLANヘッダに含まれるVNIDにより学習対象が異なる。COOPの通知対象ではない。デフォルトの Retention Timer は 300秒 (5分)。

VNID	MACアドレス	IPアドレス
BDに紐づくVNID	学習する	学習しない
VRFに紐づくVNID	学習しない	学習する

同じEndpointのMACアドレスとIPアドレスを対象としている場合であっても、Remote Endpointとしては別々に扱われる(Local EndpointのようにMACアドレスとIPアドレスの紐付けは管理されない)。

Endpoint 学習タイプの分類

Endpoint Tableには様々な学習タイプのEndpointがエントリされている

```
Pod1-Leaf1# show endpoint vrf tsetaka_demo1:VRF2
Legend:
 s - arp              H - vtep             V - vpc-attached     p - peer-aged
 R - peer-attached-rl B - bounce           S - static           M - span
 D - bounce-to-proxy  O - peer-attached    a - local-aged       m - svc-mgr
 L - local            E - shared-service
+------------------------------------+---------------+-----------------+--------------+-------------+
      VLAN/                           Encap           MAC Address       MAC Info/       Interface
      Domain                          VLAN            IP Address        IP Info
+------------------------------------+---------------+-----------------+--------------+-------------+
61                                        vlan-606     0050.5680.a847 L                  eth1/33
tsetaka_demo1:VRF2                        vlan-606        192.168.1.2 L                  eth1/33
58/tsetaka_demo1:VRF2                  vxlan-16646017     0050.5680.a836                 tunnel5
tsetaka_demo1:VRF2                                           192.168.1.1                 tunnel5
50                                        vlan-2004    0050.5680.a045 LV                 po1
tsetaka_demo1:VRF2                        vlan-2004       192.168.2.2 LV                 po1
48/tsetaka_demo1:VRF2                     vlan-2443    0050.5685.3a8a O                  tunnel4
63/tsetaka_demo1:VRF2                  vxlan-15269818     0050.5685.ce43 L               eth1/22
```

Local Endpoint (VLAN)

当該Leafに接続しているEndpoint

Local Endpoint (VXLAN)

VXLANで接続しているEndpoint
・AVE/AVS接続VM
・OpenStack (VXLAN)
・Kubernetes ACI CNI
等

当該Leafに接続しているEndpointが通信したためにキャッシュとして学習している他のノードに接続しているEndpoint

Remote Endpoint

VPC接続Endpoint

VPC接続Endpoint (Orphan Port)

VPCを構成しているため相互に学習ステータスを同期している対象のEndpoint

Endpoint Table における紐付け先の違い

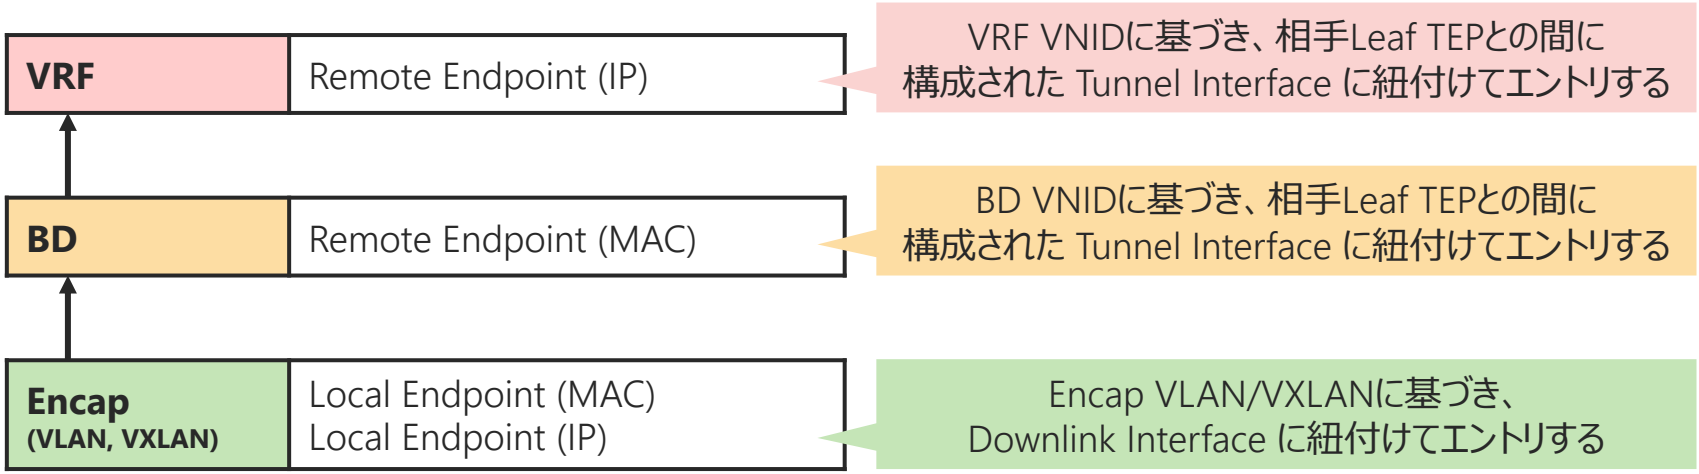

※ネットワークとしての識別にはVNIDが用いられるが、合わせてセキュリティの識別にはpcTagに基づくEPGへの紐付けによって識別される

ACI外部は Endpoint としては管理しない

Endpointテーブルでは1つのMACアドレスに対して紐付けることができるIPアドレスの数に制限がある(ACI3.2以降では4096,それ以前では1024)ため、ACIが外部として扱う範囲(L3out)に対してはLocal Endpointとしてではなく、従来同様にARPによって隣接ノードのIPアドレスに紐づくMACアドレスを学習する。

Table	含まれる情報	概要
RIB	Routing Table (内部ホストルートを除く)	ACIにおいてもVRF毎にRouting Tableが構成され、必要に応じてLeafに対してプログラムされる
ARP	L3out 隣接ノードについては、ARPに基づいて IPアドレスに紐づくMACアドレスを学習する	

ACI外部の経路情報については、Static Routeを利用した静的な定義と、OSPF, BGP, EIGRPを利用したDynamic Routingによる動的な経路情報を通じて設定される

L3out 通信時の Endpoint 学習動作

L3outとの間での通信では、通常のEndpoint同士の通信とは動作が異なる。

L3out通信	MACアドレス	IPアドレス
L3out → ACI	Local (Border Leaf) : 学習する Remote : 学習しない	Local (Border Leaf) : 学習しない Remote : 学習しない
ACI → L3out	Remote : Gen 1 Leaf からの送信である場合、送信元MAC/IPアドレスともに Remote Endpointとしては学習しない(DLビットが付加される)	

Gen2 Leafスイッチの場合、[Enforce Subnet Check]機能を有効化することで、L3out経路範囲に含まれる送信元IPアドレスはEndpointとして学習しない(0.0.0.0/0を除く)。

Issue Case #1

Teaming構成のミスによるIPアドレスのFrapping

スイッチ側のPort-channelをあわせて構成する必要があるTeaming方式を、サーバ側だけで構成してしまった場合、Teamingインターフェイスに構成したIPアドレスが複数の物理アダプタのMACアドレス間でフラッピングする事象が発生する。

ACIでこの様な事態が発生すると、LeafのCPU使用率の上昇や、COOP処理を通じたSpineのCPU使用率の上昇などが発生してしまうことがある。

ACI 3.2(1)～

Rogue EP Control : Enabled

指定した間隔の間に指定した回数以上のEndpointの移動が行われた場合、指定された間、対象のEndpoint情報を静的にエントリしてしまうことで新規Endpointとしての学習を防止するとともに、当該Endpointの通信に対してDLビットを付加してRemote Endpointとしての学習を防止する。

この対応は問題の解決にはつながらないが、ACI Fabric側の過負荷を抑制するとともに、管理者側が構成上の問題を認識するキッカケを提供する(Warning Fault扱い)。

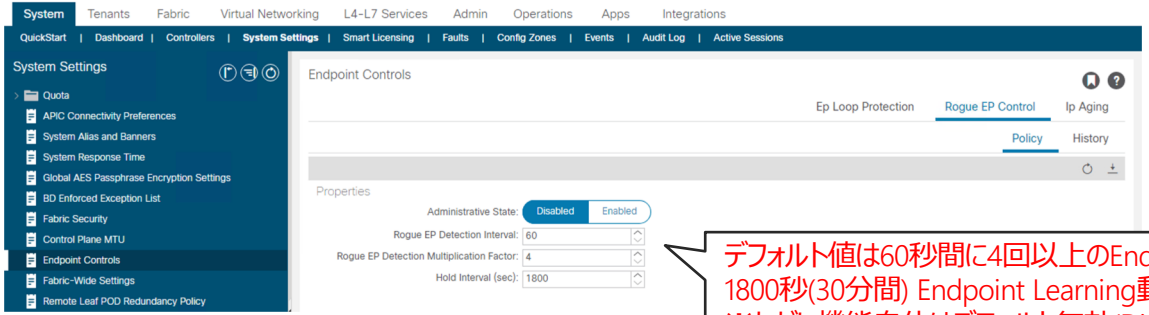

デフォルト値は60秒間に4回以上のEndpoint移動を検出した場合に、1800秒(30分間) Endpoint Learning動作を停止する
※ただし機能自体はデフォルト無効(Disabled)

非推奨

EP Loop Protection : Enabled

指定した間隔の間に指定した回数以上のEndpointの移動が行われた場合、以下の指定されたアクションを実行する。

- BDにおける新規学習の停止 (Action: BD Learn Disable)
- ポート停止 (Action: Port Disable)

どちらのアクションを選択した場合も、問題の対象となっているEndpoint以外に対しても与える影響が非常に大きくなるため、利用は可能な限り避ける(非推奨)。

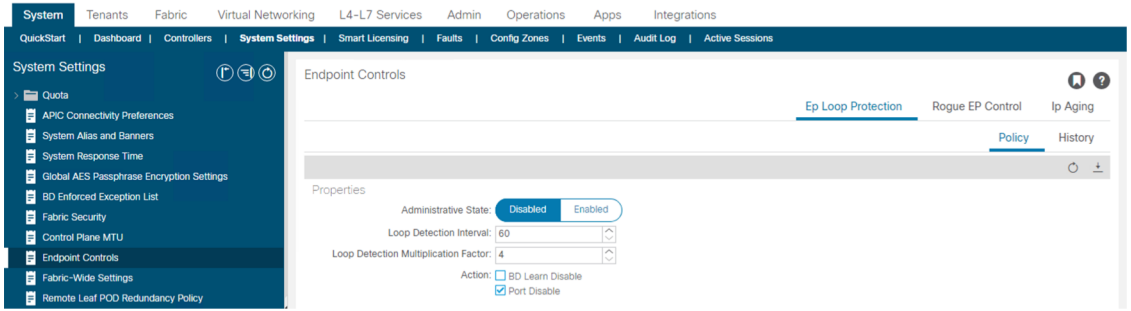

Issue Case #2

リンクローカルアドレスなどの情報が残り続ける

Endpoint に紐づくIPアドレスが個別にタイムアウトしない場合、一時的に構成されたリンクローカルアドレス(169.254.x.x/16)などが残り続けてしまう。

IP Agingを有効化することで、EndpointのMACアドレスに複数のIPアドレスが紐付けられている場合において個別のIPアドレス毎にAging Timerが構成される。

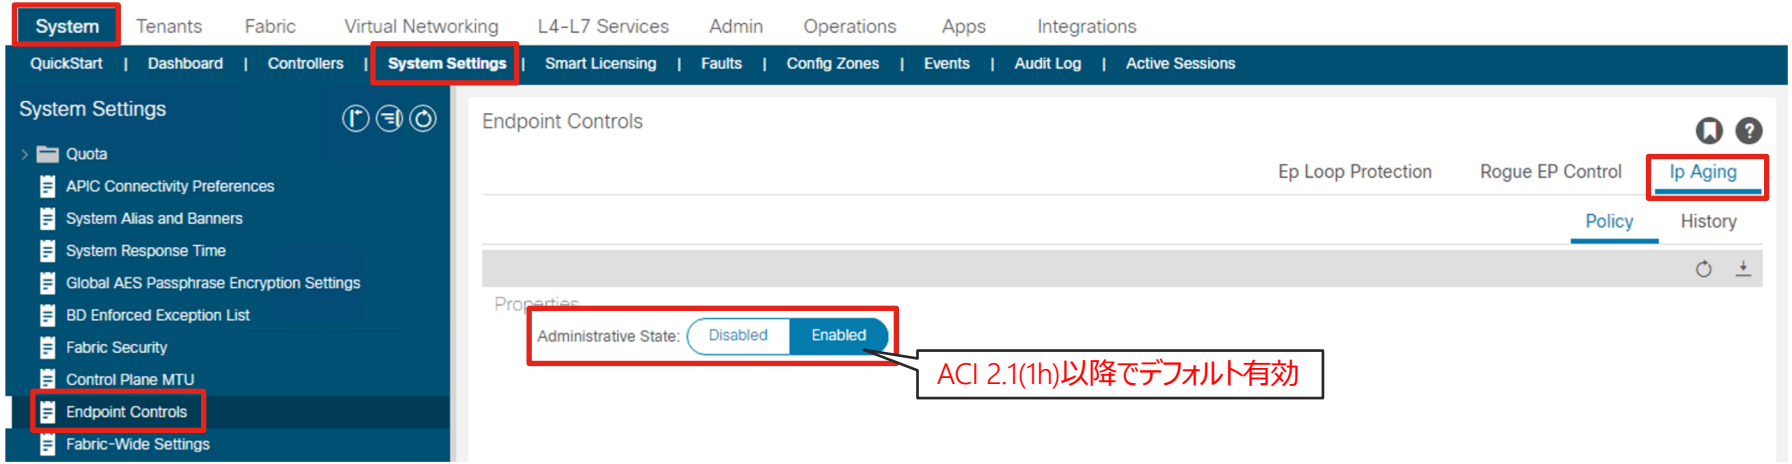

IP Aging Policy

- EndpointとしてエントリされたIPアドレスからのフレームを受信する度にセットされるHit-Bitに基づいてリセットされるAging Timer
- Aging Timerがタイムアウトすると、当該エントリはEndpoint Tableから削除される
- タイムアウト値は Endpoint Retention Policy 設定に基づく (VRF, BDで構成可)
- Local Endpointの場合、Aging Timer設定値の75%経過時にLeafスイッチからUnicast ARP/NDが3回送信され、存在確認が実行される
  ※LeafからのARP/NDに応答する限り、Endpoint Tableから削除されることはない
- Endpointに複数のIPアドレスがある場合、個別IP毎にAging Timerが設定される
- 2つのLeafがVPCドメインを構成している場合、VPCホストとOrphanホストの両方についてタイムアウト時には両ノードからエントリは削除される

Endpoint Retention Policy

無指定の場合は、以下の設定値がデフォルトとして使われる。
Tenants > common > Policies > Protocol > End Point Retention > default

Timer	Timeout デフォルト値	BD	VRF
Local Endpoint Aging Interval	900秒 (15分)	MAC/IP ※IP Aging Policyにより個別にAgingする	ー
Bounce Entry Aging Interval	630秒 (10分30秒)	MAC	IP
Remote Endpoint Aging Interval	300秒 (5分)	MAC	IP
Move Frequency	256回/秒	ー	ー
Hold Interval	300秒 (5分)	ー	ー

※各テナントで Endpoint Retention Policy を構成することが可能
※Endpoint Retention Policy は、VRF や BD の Policy パラメータとして紐付けることが可能

Issue Case #3

※"ACI Endpoint Learning : ベストプラクティス" を合わせて参照下さい

Endpointで誤ったIPアドレスを構成してしまった

Endpointで誤って意図しないIPアドレスを構成してしまった場合、そのIPアドレスがEndpointとしてエントリされてしまうとタイムアウトするまでの間、当該IPアドレスを持つ本来通信できるべき宛先との間で通信ができなくなってしまう。

この問題への対処方法は以下の通り(詳細後述)。

- **Limit IP Learning To Subnet : Enabled**
  ※ACI 1.1(1)以降で利用可能、ACI 2.3(1e)および3.0(1k)以降で新規に作成されたBDではデフォルトで有効
  ※以下の [Enforce Subnet Check]が利用できる かつ 全Leafスイッチ がGen 2であれば、構成不要
- **Enforce Subnet Check : Enabled** ←必要要件を満たすならば、こちらが推奨
  ※ACI 2.2(2q)および3.0(2)以降 かつ Gen 2 Leaf に対してのみ有効
  (ただし、ACI2.3および3.0(1)には実装されいないので注意)

Limit IP Learning To Subnet : Enabled

ACI 1.1(1)～

BD/EPGに構成されているSubnet範囲外のIPアドレスについて、Local Endpointとして学習しない。ただし、Border LeafがRemote Endpointとして学習することを防止することはできないため、完全な解決にはならない(VRFのVNIDのみで判断するため)。

Border Leaf において Remote Endpoint として学習してしまうことに対しては、合わせて[Disable Remote EP Learning]を有効化することで対処する。

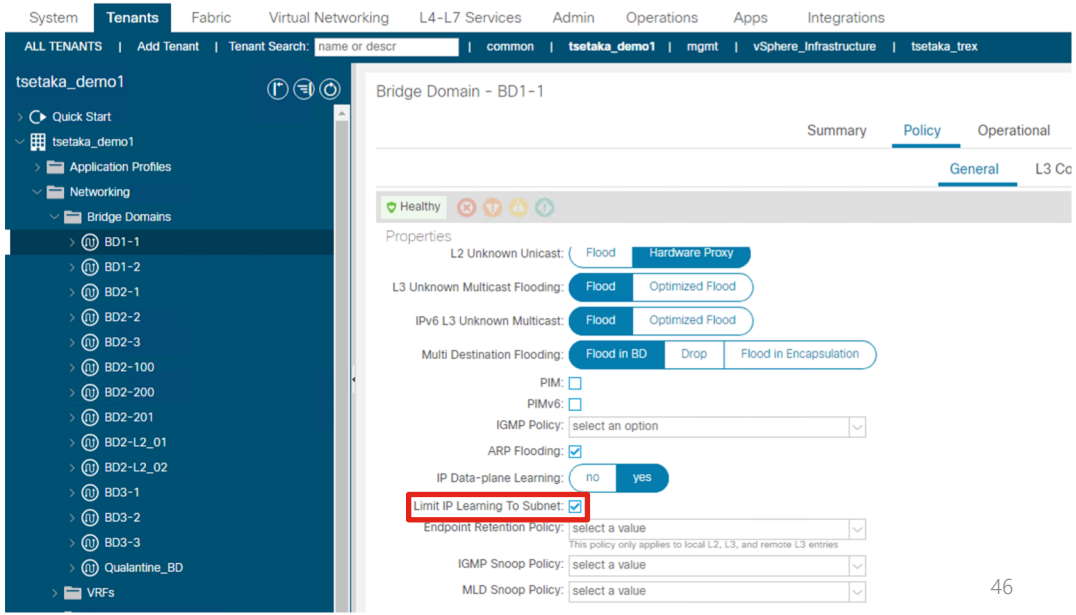

Limit IP Learning To Subnet 注意点

[Limit IP Learning To Subnet]オプションを、すでに利用中のBDに対してEnabled / Disabled の設定変更を実施した場合、ACI 3.0(1k)より前では以下の状態が発生する。

- 当該BD範囲において全ての学習済Endpointが一旦消去される
- 120秒間 MACアドレス および IPアドレス の学習が停止される

3.0(1k)以降では、上記に関して、以下の改善がされている(CSCve29663)。

- 有効化・無効化時において、学習済のEndpoint情報のフラッシュは行われない (ただし、BD Subnet範囲外のEndpoint IPアドレス情報についは消去される)
- 120秒間の Endpoint 学習の停止は発生しない

Enforce Subnet Check : Enabled

ACI 2.2(2q)～
ACI 3.0(2h)～

VRF範囲に構成されたBD/EPGのSubnet範囲外のIPアドレスはEndpointとして学習しない(Local Endpoint / Remote Endpoint いずれとしても)。

Gen 2 以降の Leaf スイッチに対してのみ有効。

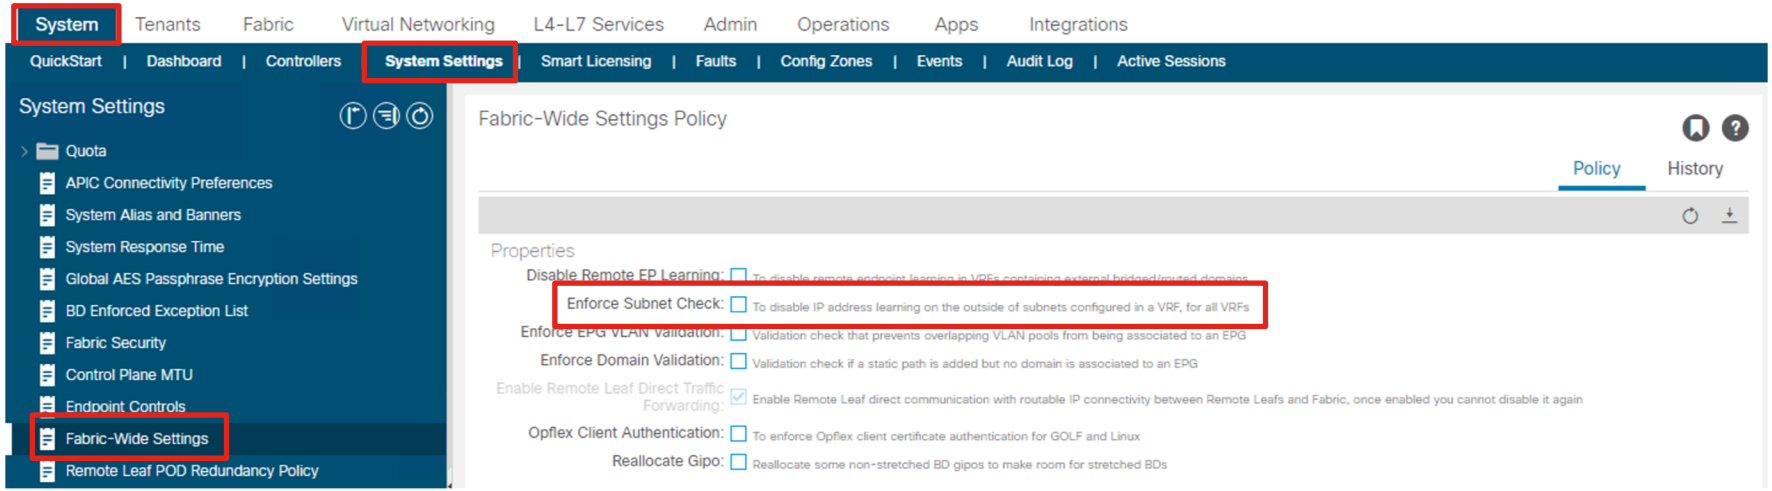

Issue Case #4

ACIに接続するデバイスを制御できないケース

ACIのData-planeにおけるEndpoint学習の仕組みは、ACIの様々な機能の基盤となっているため、基本的には利用することが強く推奨されますが、従来のスイッチと同じ様なARP/NDのみによるIP学習動作を求められるようなケースにおいては、Data-plane Learning を無効化することが可能。

例：ACI側での適切な構成を行うことなく(ネットワーク管理者が接続種別に合わせて必要な設定を定義することが出来ない)、EndpointとしてRouting動作をするデバイスやロードバランス動作、同一IPアドレスをARPベースでフェイルオーバー利用するサーバなどを接続して利用される可能性があるケース

※IP Data-plane Learning 無効化時には、IP Agingを有効化することを推奨 (Default 有効)

IP Data-plane Learning : Disabled (VRF)

ACI 4.0(1)～

IP Data-plane Learning を VRF で Disabled とした場合、以下の動作となる。

- Local Endpoint として MACアドレスは引き続きData-planeから学習する(Gen1/2)
- Remote Endpoint として MACアドレスは Data-planeから学習する (Gen2のみ)
  ※Gen 1がRemote Endpointを学習しないため、L2 Unknown Unicast 設定は Hardware Proxy を必ず利用する必要がある
- Local Endpoint の IPアドレスは Control-planeを通じたARP/NDでのみ学習する
  ※IP Aging は必ず Enable とする必要がある
- Remote Endpoint の IPアドレスは Unicast からは学習せず、Routed Multicast からのみ学習する

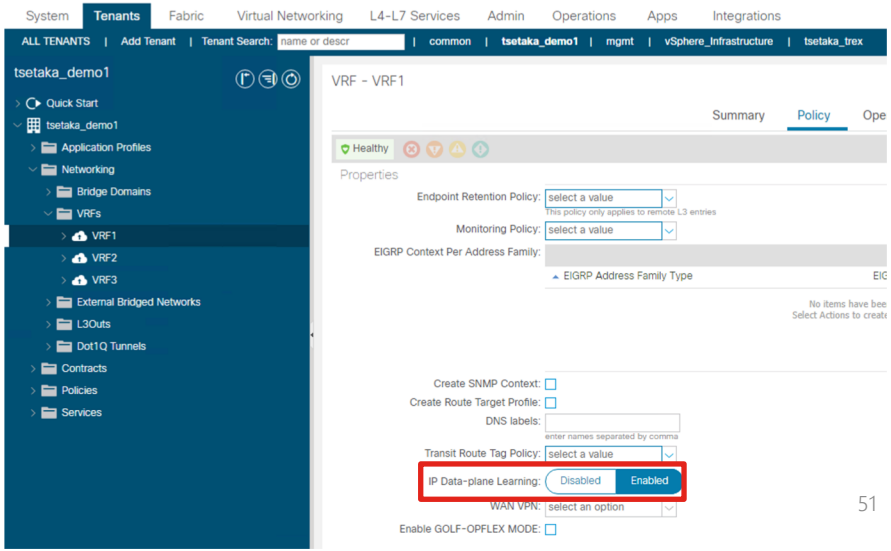

非推奨

IP Data-plane Learning : Disabled (BD)

IP Data-plane Learning を BD で Disabled とする使い方は、Service Graph で PBRを利用することのみが現在はサポートされている。
(要Gen 2 LeafスイッチへのService Node接続)

ACI 3.1以降では自動的にPBR利用されるService Node接続EPG単位で自動的にIP Data-plane LearningがDisabledとなるため、上記を手動で対応する必要はない。

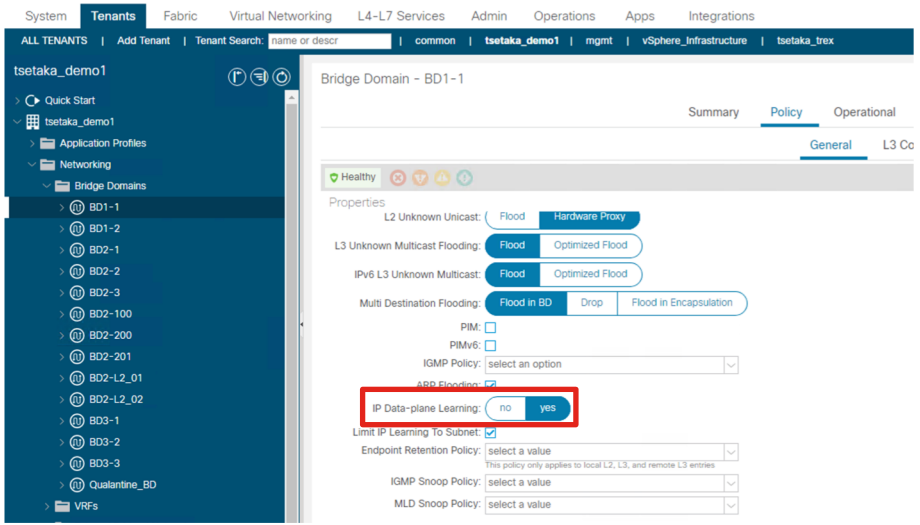

Endpoint 移動への対応

Bounce Entry (1/4)

EndpointがVMの場合などでは、Endpointは異なるLeaf配下へ動的に移動する可能性がある。しかし、ACIではRemote Endpoint情報をキャッシュとして保持する為、転送先Leafにはすでに当該Endpointが存在しない状態が発生しうる。

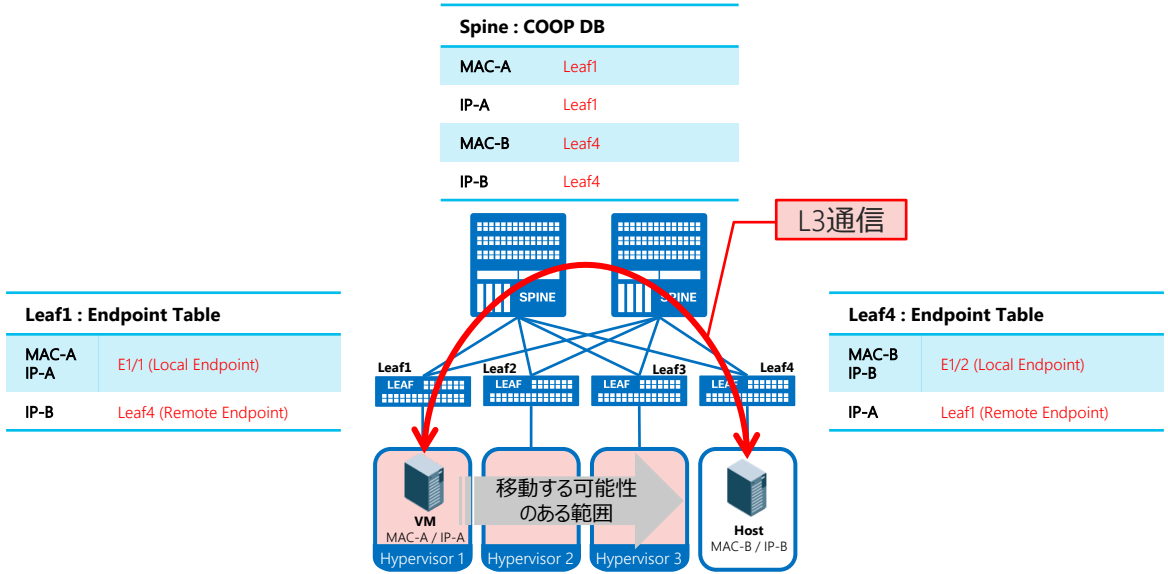

Bounce Entry (2/4)

別のLeafからCOOPを通じて登録済のEndpoint情報に対して異なるLeafからCOOPを通じて改めて登録依頼が来た場合、Spineは当該Endpointの紐付け先Leafの情報を更新すると同時に、元々当該Endpoint情報を登録していたLeafに対してのみ更新情報を通知する。

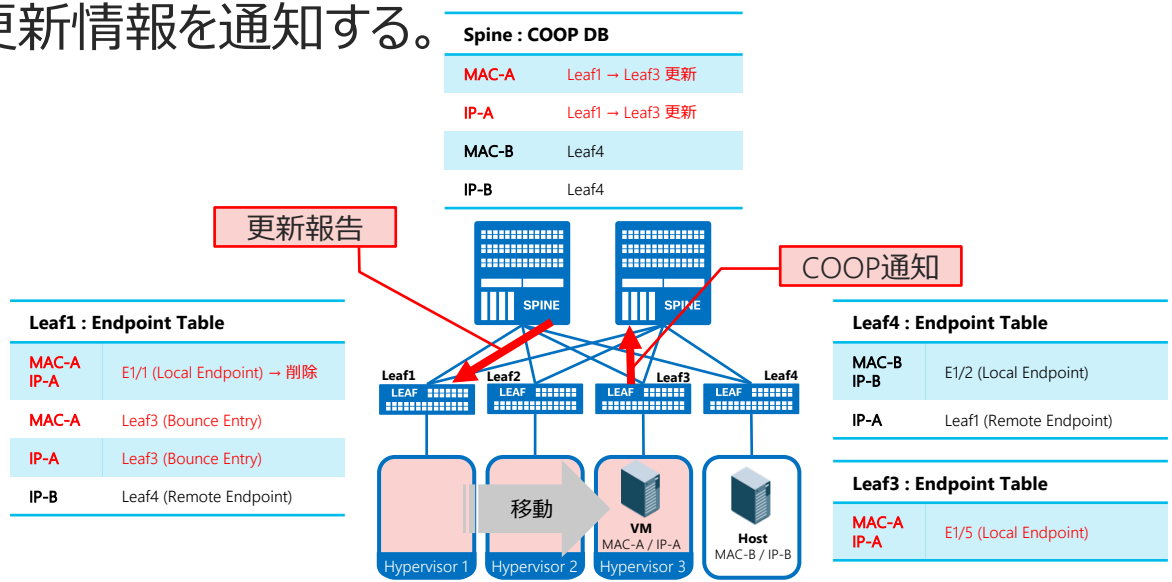

Bounce Entry (3/4)

Remote Endpoint情報を保持したままとなっているLeaf4は、この時点ではVMの移動を認識していないため、VM宛の通信をLeaf1に対して転送する。Leaf1は当該VMがLeaf3に移動していることを認識しているため、Leaf4からの転送をLeaf3に再転送する。この動作をBounceと呼ぶ。

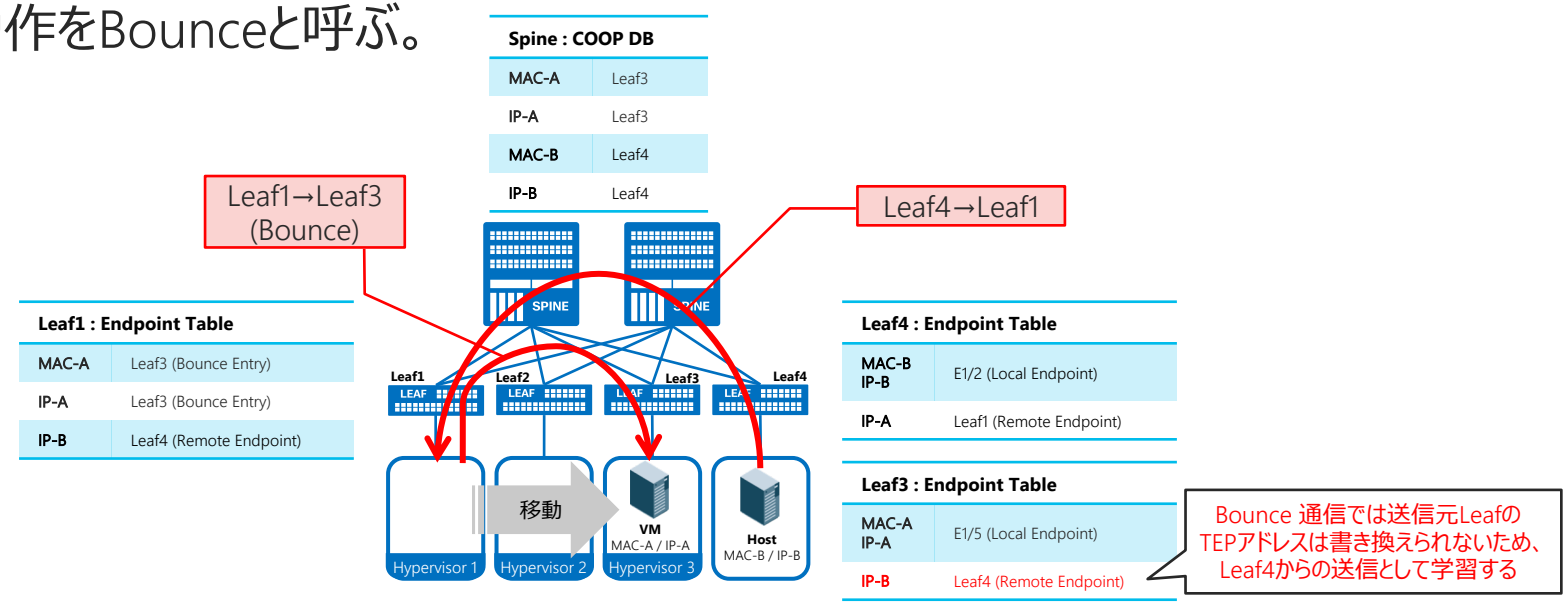

Bounce Entry (4/4)

Leaf3配下に移動したVMからの戻り通信は、Leaf3がBounceによりLeaf4を宛先TEPとして学習済のため、直接Leaf4に戻される。この時点で、Leaf4はVMの移動を認識し、自身のRemote Endpointエントリを更新する。

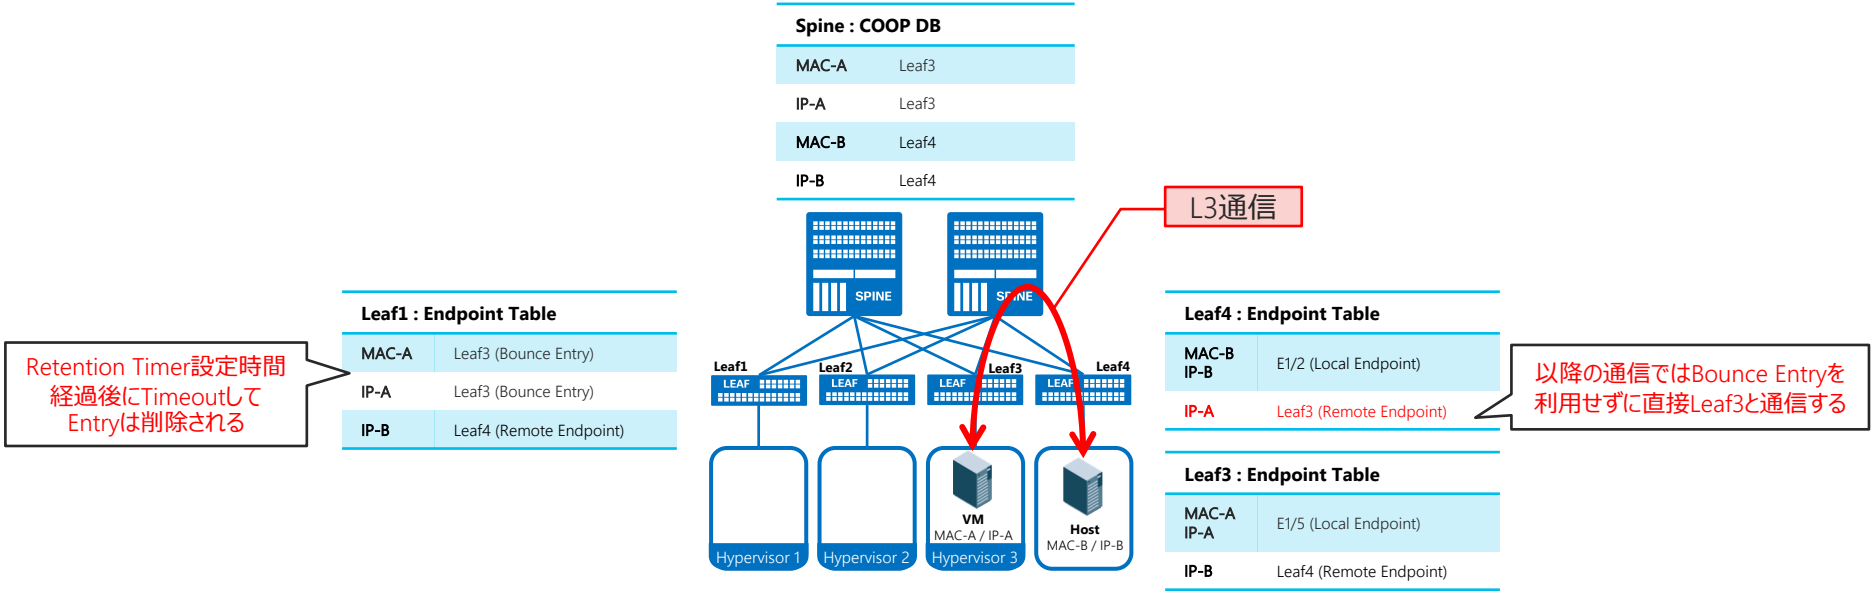

Bounce Entry と Endpoint Retention Timer

Bounce Entryは通常のRemote Endpointよりも長い(倍+30秒)Retention Timerが設定されるため、Bounce EntryがTimeoutする前にRemote Endpointのエントリがする。これにより、Bounce EntryがTimeoutしても問題は発生しない。

Timer	Timeout デフォルト値	BD	VRF
Local	900秒(15分)	MAC/IP	ー
Bounce	630秒 (10分30秒)	MAC	IP
Remote	300秒(5分)	MAC	IP
Move	256回/秒	ー	ー
Hold	300秒	ー	ー

Bounce Entryの仕組みにより、ACI Fabricの規模が拡大してもEndpoint移動時にSpineが更新を通知する対象は元々当該Endpointを紐付けていた移動元Leafのみのままとなるため、負荷が増大しない(通知対象が増加しない)。

Endpoint Retention Policy は、
BD単位やVRF単位でのカスタム構成が可能

Bounce Entry 削除時の通知 : 3.2(2l)～

ACI 3.2(2l)以降において、Bounce Entry削除時に全Leafに対して該当Remote Endpoint情報の削除を通知を行う機能が実装された(CSCvj17665)。これは極稀な例外的なケース(CSCva56754)としてBorder LeafにおいてRemote Endpoint情報が残ってしまう場合への対処のためである。この機能を利用する上で必要な構成はない(自動的に利用可能となる)。

Issue Case #5

ACI 内から ACI 外への Subnet の移行

ACI内からL3outの外にSubnetを移行した場合、Bounce Entryは構成されない。

L3out通信	IPアドレス
L3out → ACI	Remote : 学習しない

Remote Endpointエントリを持っているLeafからは、L3outの外に移行した宛先にはタイムアウトするまで疎通できない。
→ Leaf毎に Remote Endpoint 情報を手動でクリアすることが可能

特定Remote EndpointのIPアドレスエントリのみを削除する場合

```
LEAF1# clear system internal epm endpoint key vrf <vrf-name> ip <ip-address>
```

全Remote Endpointのエントリを削除する場合(MACアドレスを含む)

```
LEAF1# clear system internal epm endpoint vrf <vrf-name> remote
```

※Gen2 Leafの場合は[Enforce Subnet Check]を有効化することで、BD Subnetの削除によるEndpoint情報の削除が可能。

Issue Case #6

※"ACI Endpoint Learning : ベストプラクティス" を合わせて参照下さい

送信元LeafでGen1利用の場合の問題点(1/2)

以下の条件を満たしてしまった場合、Border LeafにおいてRemote Endpointのエントリが更新されない状況が発生しうる。

- Ingress Policy Enforcement (Default)を利用
- Border LeafにEndpoint-Aと通信を行ったEndpoint-Bが存在する
  (Border LeafはEndpoint-AをRemote Endpointとして学習している)
- 送信元Endpoint-Aが Leaf2 (Gen1)配下へと移動した後は、
  Endpoint-Bとは通信せずに当該Border Leafに構成されている
  L3outの先との間でのみ通信を行う
  (L3outとの通信によってRemote EndpointのRetention Timerは更新されるが、
  Leaf2への移動は学習しない = Leaf1に紐付いたままとなる)
- 移動前のLeafに構成されていたBounce Entryタイムアウト後
  Endpoint-AはL3outとの疎通ができなくなる

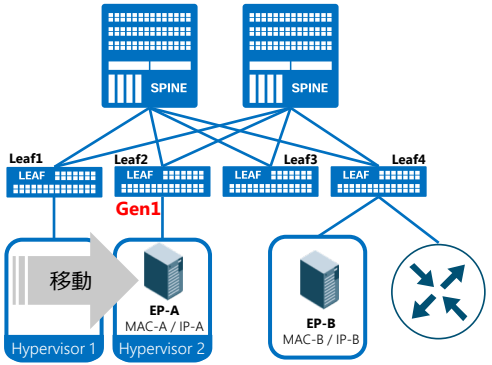

Leaf4 : Endpoint Table

MAC-B **IP-B**	E1/2 (Local Endpoint)
IP-A	Leaf1 (Remote Endpoint)

L3out通信	MACアドレス	IPアドレス
ACI → L3out	Remote : Gen 1 Leaf からの送信である場合、送信元MAC/IPアドレスともにRemote Endpointとしては学習しない(DLビットが付加される)	

送信元LeafでGen1利用の場合の問題点(2/2)

前項の問題への対処方法は以下の通り。
1.もしくは2.を満たす場合、3.および4.の対応は不要。
4.を満たす場合、3.の対応は不要。
→3.2(2l)以降へのアップグレードによる対応を推奨

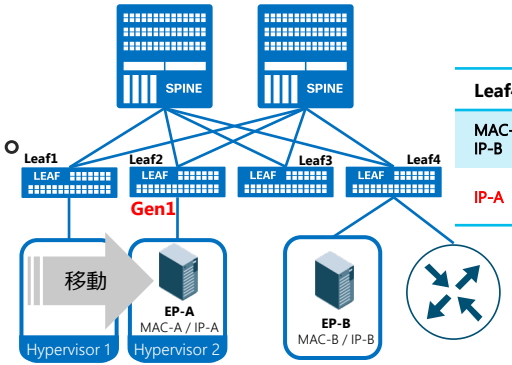

Leaf4 : Endpoint Table	
MAC-B IP-B	E1/2 (Local Endpoint)
IP-A	Leaf1 (Remote Endpoint)

1. Border Leaf (Leaf4) に Endpoint が同時に存在しない場合はこの問題は発生しない
2. 移動したEndpointの接続先Leaf (Leaf2) がGen2である場合はこの問題は発生しない
3. ACI 2.2(2)以降もしくはACI 3.0(1)以降の場合、[Disable Remote EP Learning]を有効にすることで、Border Leaf側でのRemote Endpointの学習をしないように構成することで問題の発生を防止できる
4. ACI 3.2(2)以降の場合、[EP Announce on Bounce Delete]が機能するため、Bounce Entryの削除時に合わせて、残ってしまっていたRemote Endpointエントリも削除される。これにより、問題の発生を防止できる (設定不要)

Disable Remote EP Learning : Enabled

2.2(2e)～
3.0(1k)～

VRFにL3outが紐付けられている場合に、Border LeafでのRemote Endpointの学習を無効化することで、問題の発生を予防する。

※ACI 3.2(2l)以降の場合は構成の必要なし

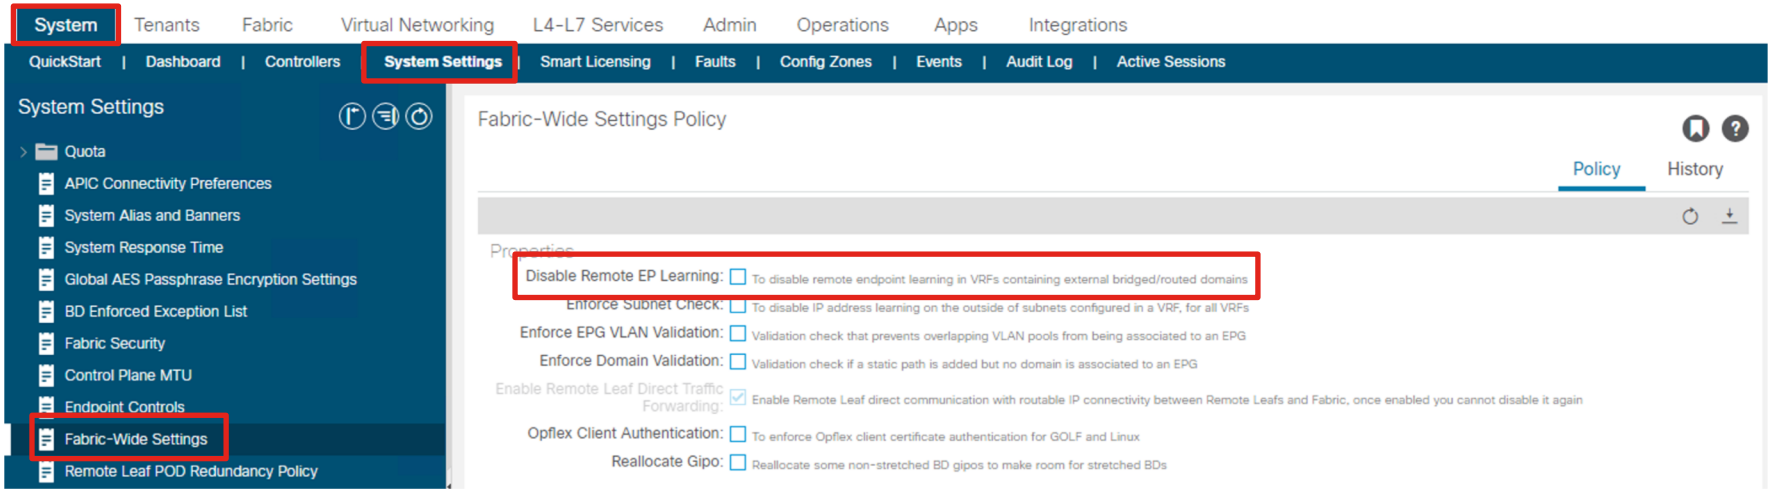

※VPCペアの片方のノードのみにL3outが構成されている場合、Disable Remote EP Learning を構成している場合でもVPCノード間での同期によってRemote Endpointを学習してしまうため、Border Leafの構成には注意が必要 (CSCvi50954)

Issue Case #7

同一ポート配下での別MACアドレスへのIP移行

MAC-Aに紐づくIP-Aを Endpoint として学習済の状態において、同一ポート配下でIP-AがMAC-Aを持つHost-Aから、MAC-Bを持つHost-Bに付け替えられた場合、Gen 1 Leafモデルはデフォルトでは Endpoint Tableを更新しない(CSCus77627)。

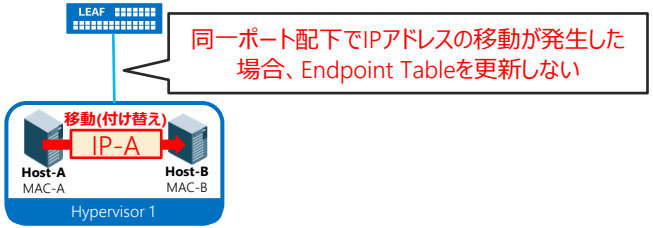

EP Move Detection Mode : Enabled

EP Move Detection Mode を有効化すると、Leaf スイッチは GARPパケットに基づいてEndpointの移動(別MACアドレスへのIPアドレスの付け替え)を認識しエントリを書き換える。

ただし、この機能を利用するためには、以下の条件を満たす必要がある。

- BD において Unicast Routing が有効となっている (ACI as Default G/W)
- ARP Flooding が有効となっている

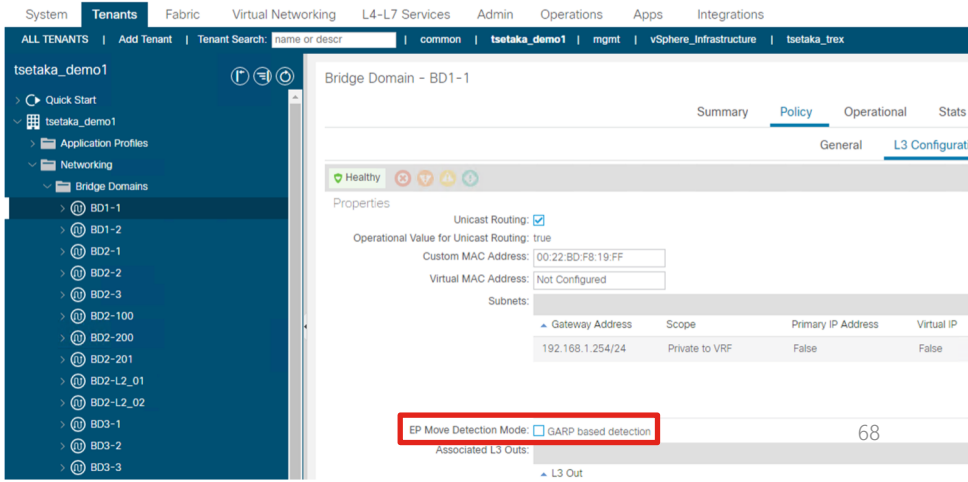

Endpoint
サイレントホスト対応

L2 : Unknown MAC Address

一切自発的にフレームを送信しないL2 Endpointが存在した場合、L2スイッチング通信を成立するためには宛先MACアドレスがEndpoint TableかCOOP DBにエントリされている必要がある。

BDでUnicast Routingが有効化されていない場合、ACIはMACアドレスのみを学習するため、Unicast ARPによる存在確認を行うことが出来ない。
そのため、L2 Unknown Unicast設定を[Flood]とすることで、BUMトラフィックをBD範囲でFloodingする様に構成する必要がある。

L2 Unknown Unicast	Endpoint Table	COOP DB
Hardware Proxy (Default)	送信元LeafのEndpoint Tableにエントリがない場合、Spine Proxyに転送する	COOP DBに当該MACアドレスのエントリがない場合、Dropする
Flood (ARP Floodingも有効化される)	Endpointが紐づくBD範囲でFloodingされる(宛先Endpointに到達する)	

L3 : Unknown IP Address

一切自発的にフレームを送信しないL3 Endpointが存在した場合、SpineのCOOP DBにエントリが存在しないとSpineはDropすると同時にLeafスイッチに対してARP Glean要求を出す。当該BDを持つLeafスイッチはPervasive Gatewayアドレスから当該IPアドレス宛のUnicast ARPを送信し存在確認を行う(ARP Glean動作)。

応答を受け取ったLeafは通常のEndpoint登録と同様にCOOPでSpineに通知するため、以降の通信に対してはSpine Proxyが成立する。

IPアドレスを登録されたEndpointはAging Timerによるタイムアウト前にUnicast ARPによる存在確認が行われるため、1度検出された後もサイレントホストだったとしても問題ない。

ARP Glean動作の詳細はForwarding Behavior資料にて解説

ARP Broadcast Flooding

Broadcast宛先のARPリクエストに対する動作は、BDにおける[ARP Flooding]設定次第で変化する。

ARP Flooding	
Disabled	ARP要求の宛先IPアドレス宛にUnicastで転送する(Fabric内の通信が最適化される)。 COOP DBにエントリがない場合は、ARP Gleanによる存在確認が実行される。
Enabled	BD範囲にARP要求はFloodingされる。GARPによる通知などを行わずに移動するEndpointが存在する場合にはARP FloodingをEnableにする必要がある。 ※明示的に構成しなくても、BDのUnicast Routing無効(ACIがGatewayではない)の場合はARP Floodingは有効となる

※ACI 4.2～ GUIでBDを単体で作成した場合において、[ARP Flooding]はデフォルトで有効となるように変更された。VRFとまとめてウィザード作成する場合や、API経由の場合のデフォルトは後方互換性維持のため従来どおり無効が規定値となるので注意

ARP Flooding動作の詳細はForwarding Behavior資料にて解説

Endpoint Learning
パラメータ詳細

EPG

L4-L7 Virtual IPs

- Tenants > Application Profiles > AP > Application EPGs > EPG

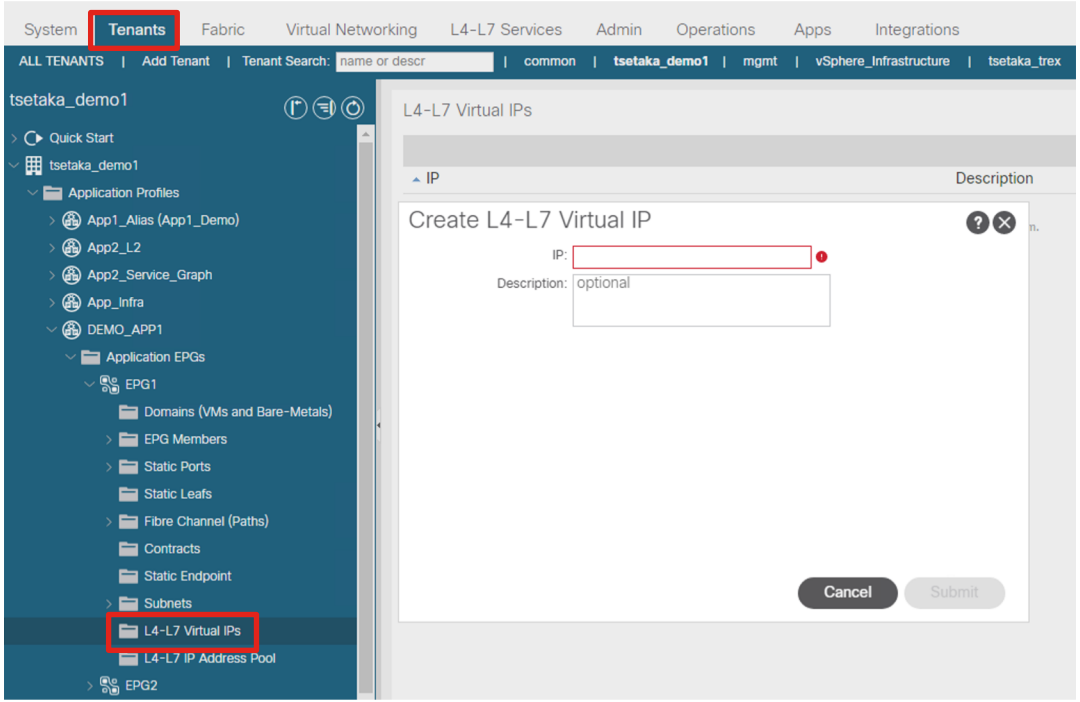

L4-L7 Virtual IPs ユースケース

L4-L7 Virtual IP として指定したIPアドレスは、Data-plane Learningの学習から除外されます。EPGにおけるこの設定は、L2 DSR (Direct Server Return) を利用する場合のみがテスト済のユースケースです。

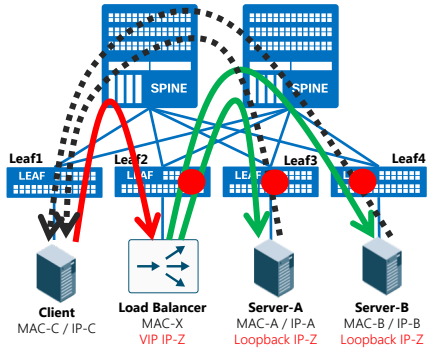

- ClientはLBのVIP IP-Z宛に通信(→)
- LBは宛先MACをMAC-AもしくはMAC-B宛にして転送(→)
  (送信元IPはClientのまま、宛先IPはVIPのまま)
- Server-A/Bは送信元IPアドレスであるClientに直接返信(→)

→ VIP-Z アドレスが LB, Server-A, Server-B でフラップしてしまう

VIP-Zアドレスを L4-L7 Virtual IP として設定することで、Data-plane学習を無効化することで、フラップすることなく正しく動作するようになる。

BD

Unicast Routing

- Tenants > Networking > Bridge Domains > BD > Policy > L3 Configurations

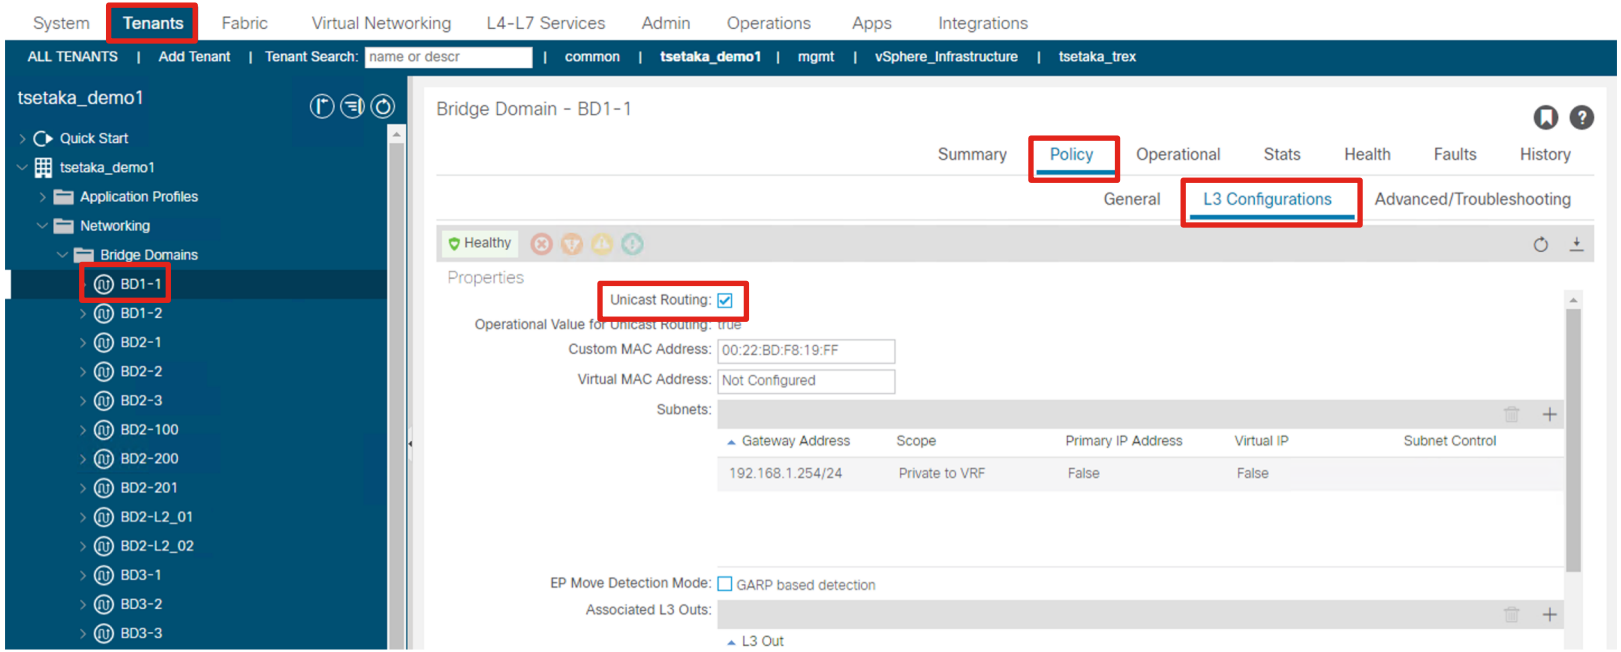

EP Move Detection Mode

- Tenants > Networking > Bridge Domains > BD > Policy > L3 Configurations

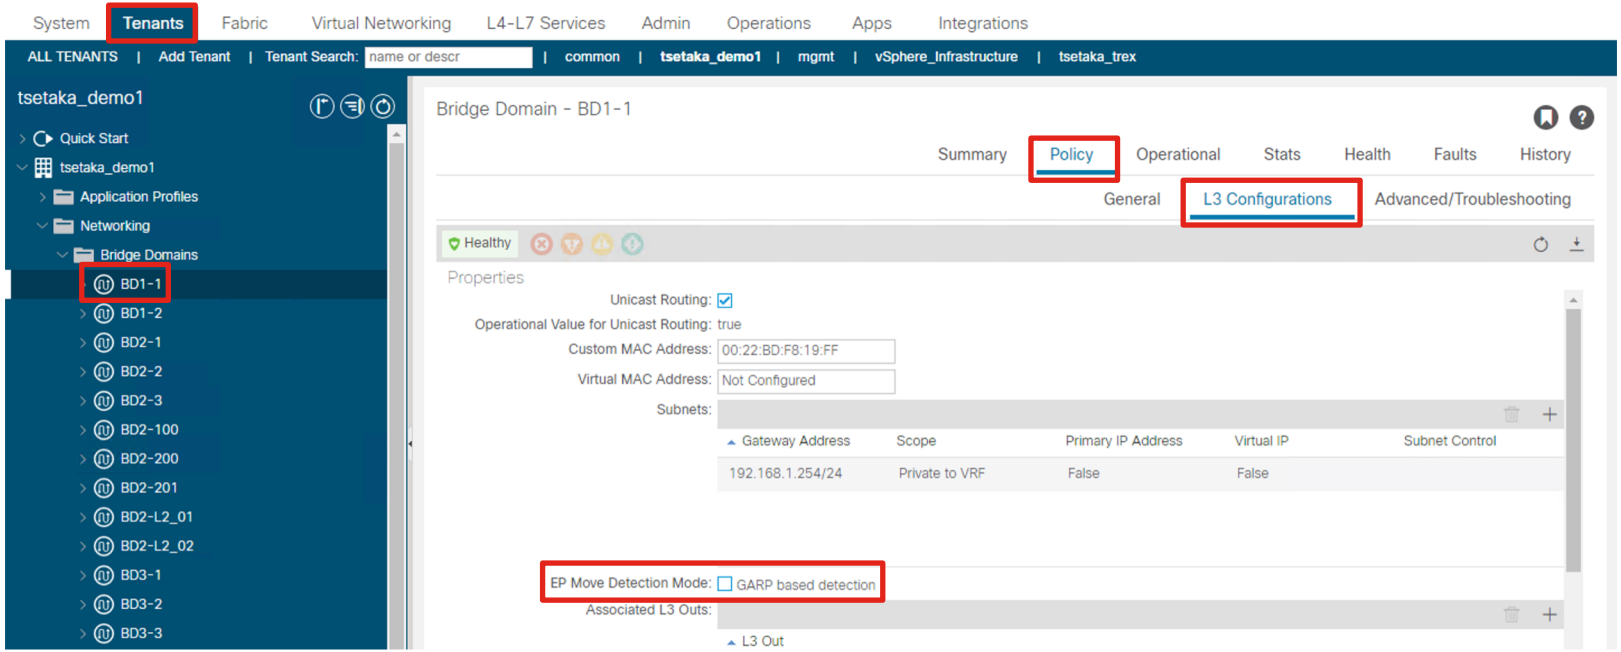

※要 Unicast Routing : 有効 + ARP Flooding : 有効

Limit IP Learning To Subnet

- Tenants > Networking > Bridge Domains > BD > Policy > General

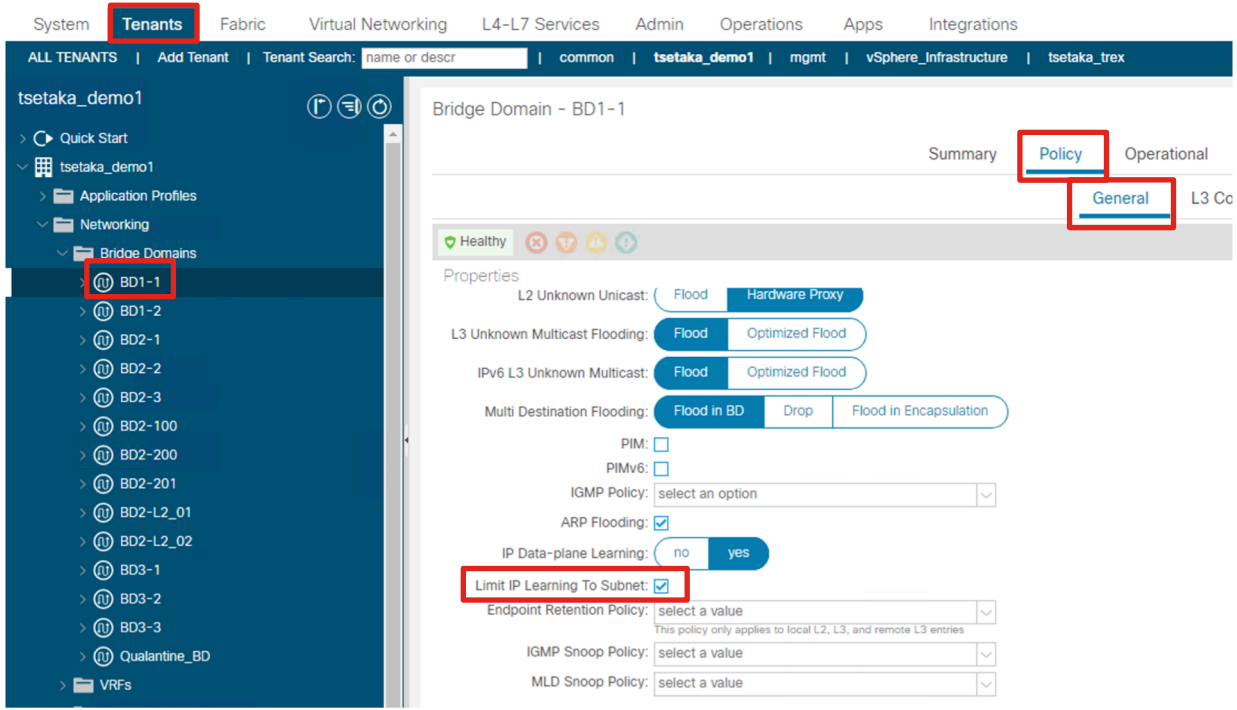

IP Data-plane Learning (BD)

- Tenants > Networking > Bridge Domains > BD > Policy > General

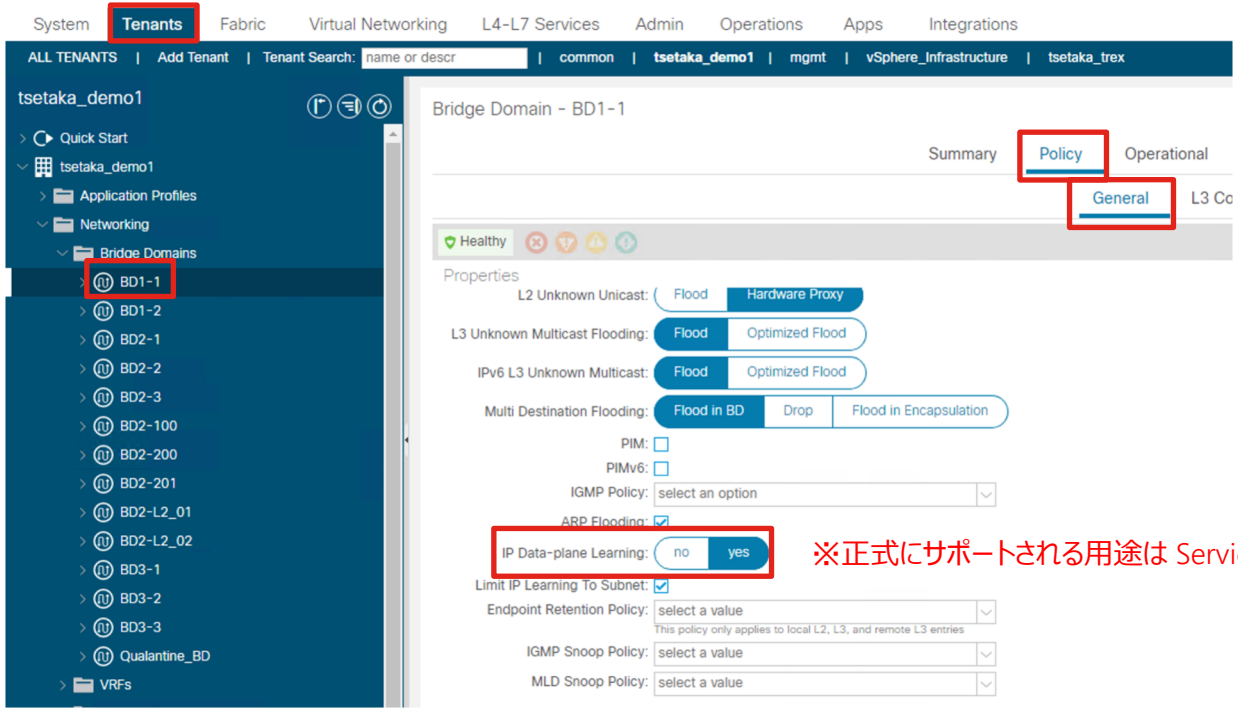

※正式にサポートされる用途は Service Graph + PBR 目的のみ

VRF

IP Data-plane Learning (VRF)

- Tenants > Networking > VRFs > VRF > Policy

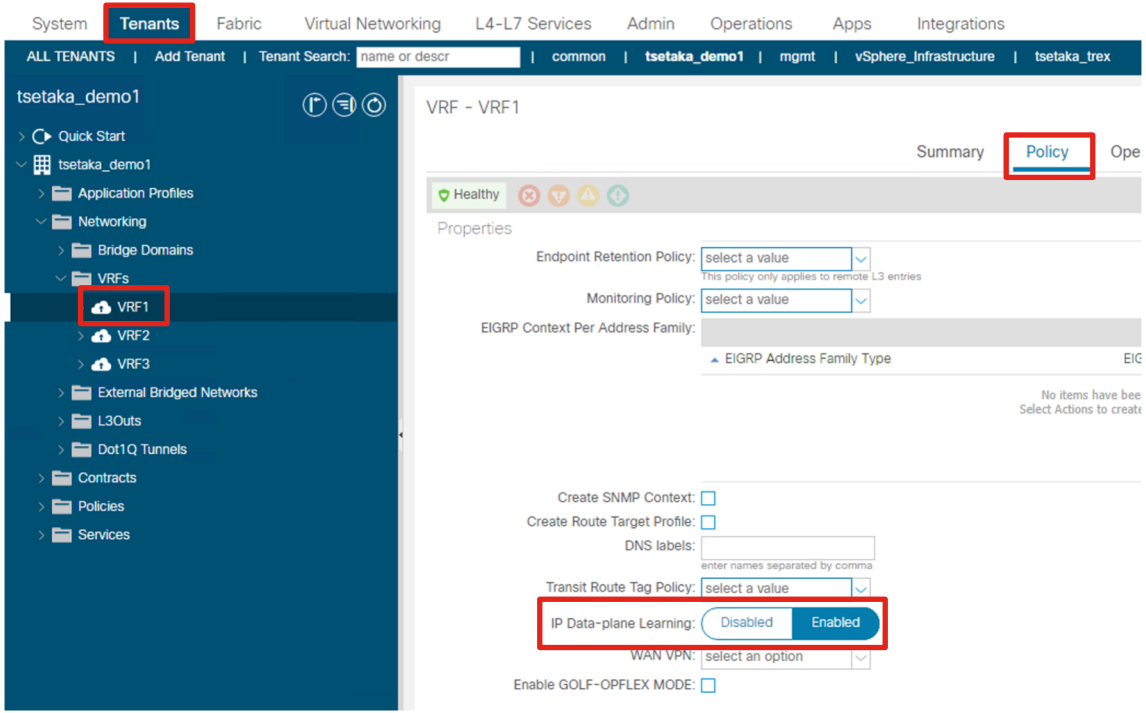

Fabric

Disable Remote EP Learning

- System > System Settings > Fabric-Wide Settings

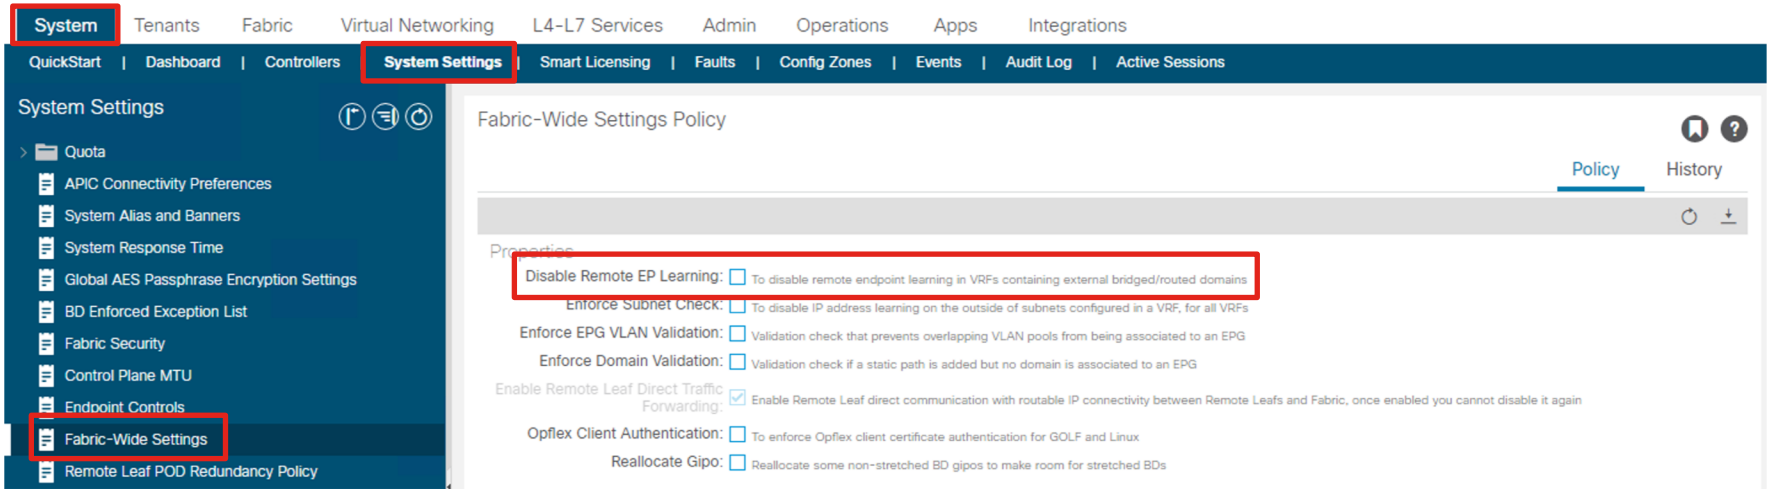

Enforce Subnet Check

- System > System Settings > Fabric-Wide Settings

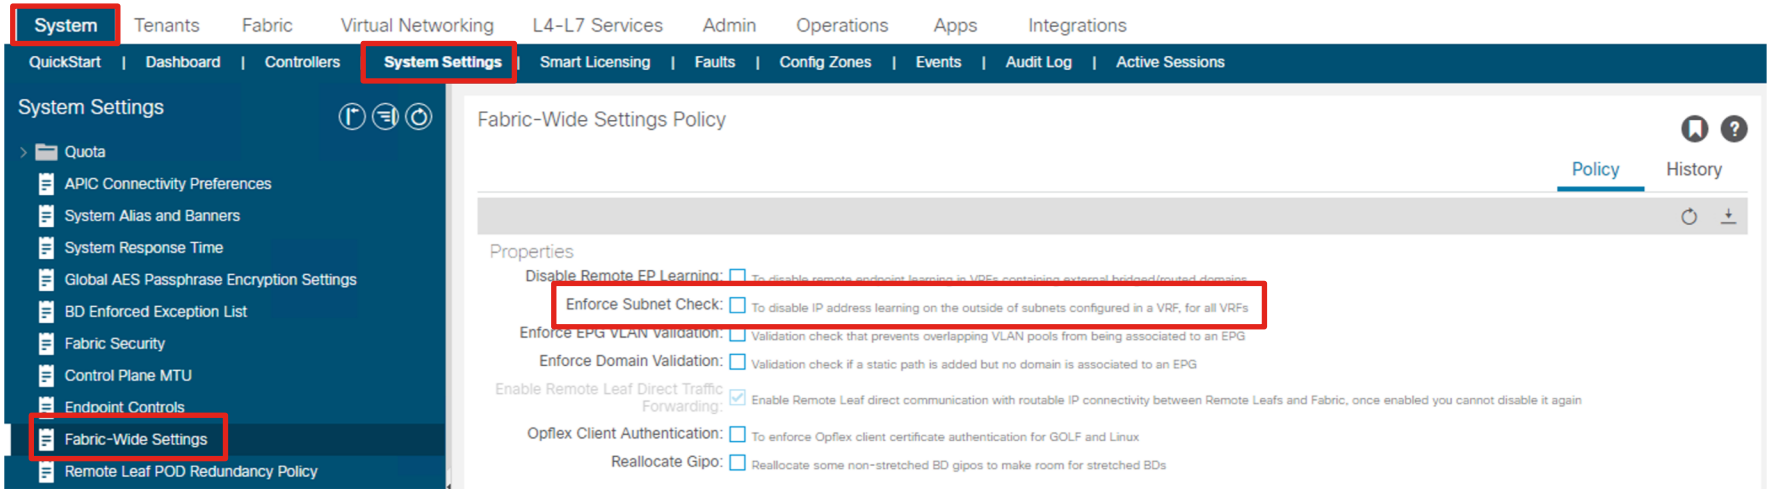

EP Loop Protection

- System > System Settings > Endpoint Controls > EP Loop Protection

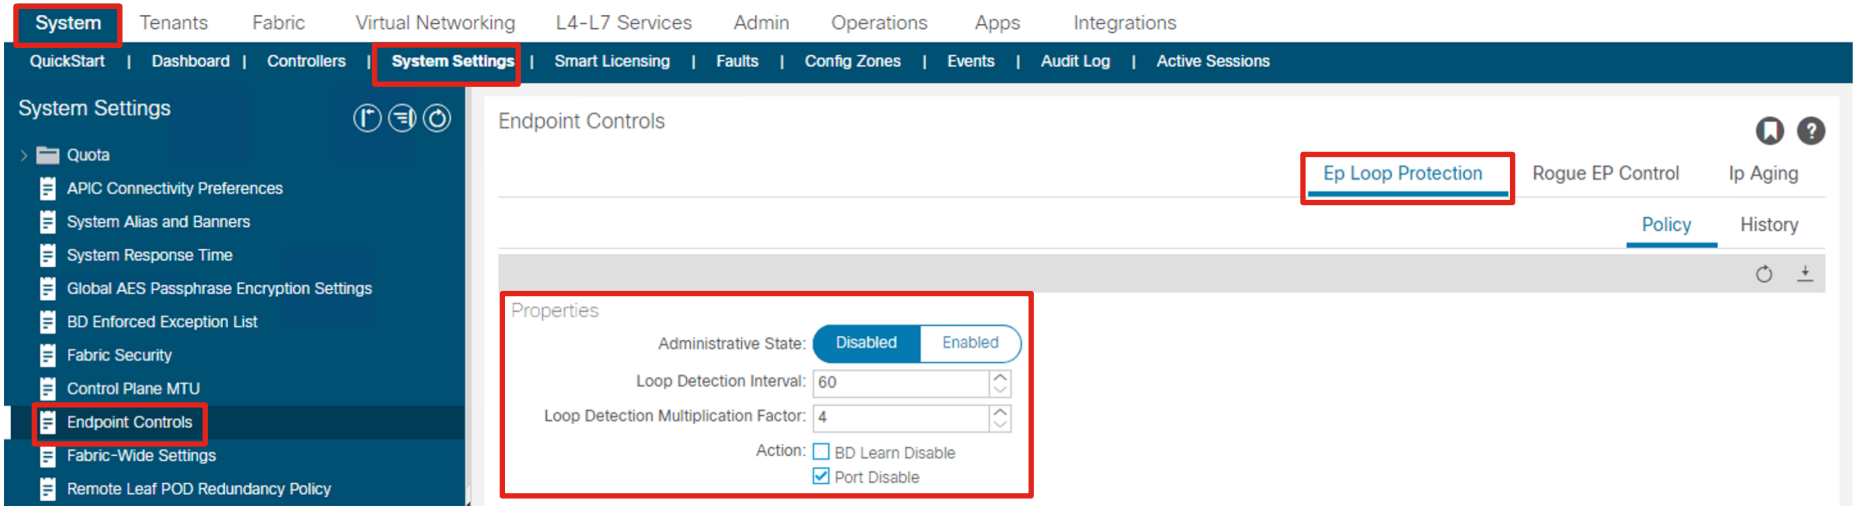

Rogue EP Control

- System > System Settings > Endpoint Controls > Rogue EP Control

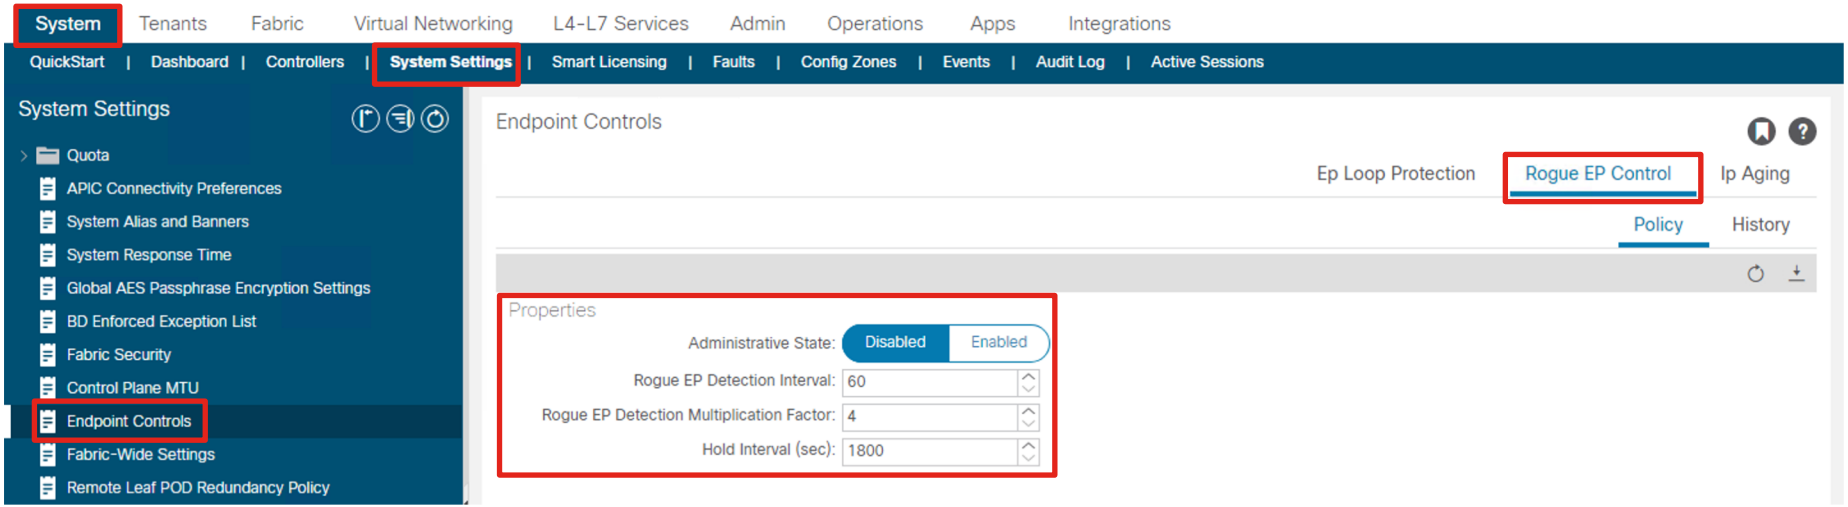

IP Aging Policy

- System > System Settings > Endpoint Controls > IP Aging

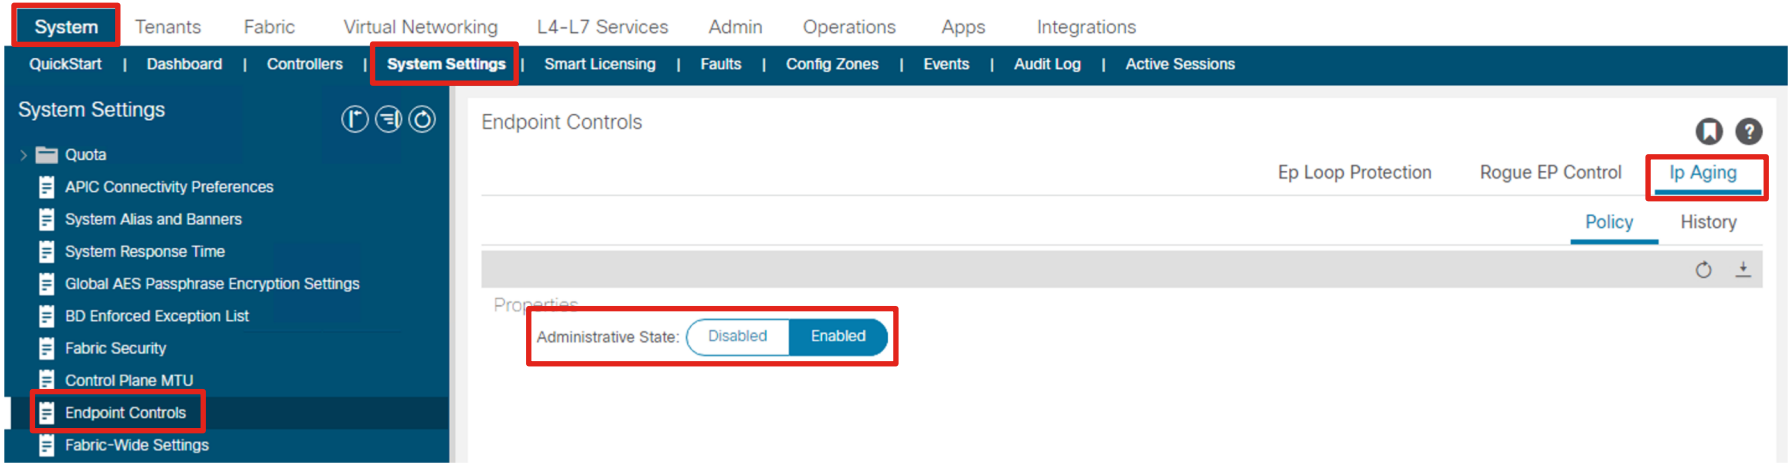

まとめ

Local Endpoint Learning

- デフォルトではData-planeでIPアドレス"も"学習する点が、ACIならではの動作

フレーム種別	転送動作種別	学習対象	
Non-IP	Bridged (L2)	MACアドレス (sMAC)	
ARP		MACアドレス (Sender MAC) IPアドレス (Sender IP)	※宛先がBD GW (BD-SVI)宛の場合
IPv4	Unicast Routed (L3)	MACアドレス (sMAC) **IPアドレス (sIP)**	**Data-plane IP Learning**
IPv6	Unicast Routed (L3)	MACアドレス (sMAC) **IPアドレス (sIP)**	
IPv6 / ND	Neighbor Discovery (ND)	MACアドレス (Source MAC) IPアドレス (Source IP)	※宛先がBD GW (BD-SVI)宛の場合

※L3out と Infra VLAN で受信したフレームからはIPアドレスの学習は行わない


CISCO