



Cisco ACI 転送

- ファブリック内の転送（1ページ）

ファブリック内の転送

ACI ファブリックは現代のデータセンター トラフィック フローを最適化する

[Cisco ACI] アーキテクチャは、従来のデータセンター設計から来る制限を解放して、最新のデータセンターで増大する East-West トラフィックの需要に対応します。

今日のアプリケーション設計は、データセンターのアクセスレイヤを通じて、サーバ間の East-West トラフィックを増大させています。このシフトを促進しているアプリケーションには、Hadoop のようなビッグデータの分散処理の設計、VMware vMotion のようなライブの仮想マシンまたはワークロードの移行、サーバのクラスタリング、および多層アプリケーションなどが含まれます。

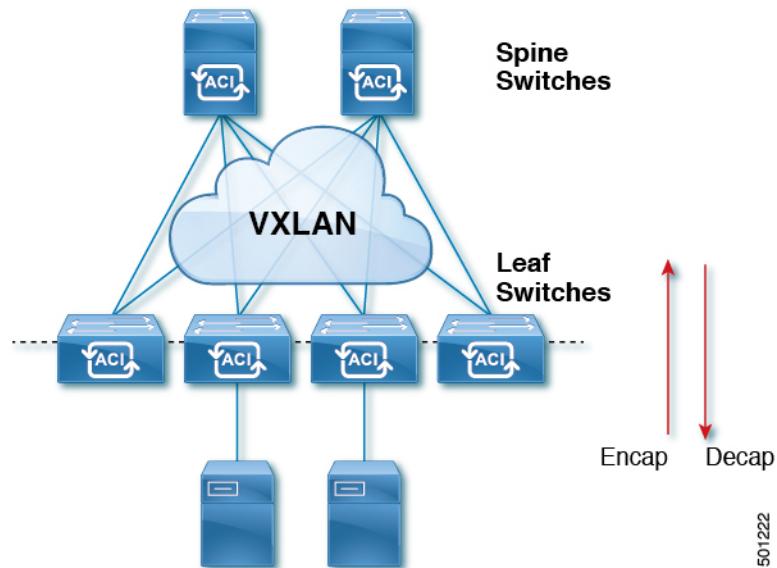
North-South トラフィックは、コア、集約、およびアクセス レイヤ、またはコラプスト コアとアクセス レイヤが重要となる、従来型のデータセンター設計を推進します。クライアントデータは WAN またはインターネットで受信され、サーバの処理を受けた後、データセンターを出ます。このような方式のため、WAN またはインターネットの帯域幅の制限により、データセンターのハードウェアは過剰設備になります。ただし、スパニングツリープロトコルが、ループをブロックするために要求されます。これは、ブロックされたリンクにより利用可能な帯域幅を制限し、トラフィックが準最適なパスを通るように強制する可能性があります。

従来のデータセンター設計においては、IEEE 802.1Q VLAN がレイヤ 2 境界の論理セグメンテーションまたはまたはブロードキャスト ドメインを提供します。ただし、ネットワークリンクの VLAN の使用は効率的ではありません。データセンター ネットワークでデバイスの配置要件は柔軟性に欠け、VLAN の最大値である 4094 の VLAN が制限となり得ます。IT 部門とクラウドプロバイダが大規模なマルチテナントデータセンターを構築するようになるにつれ、VLAN の制限は問題となりつつあります。

ACI で VXLAN

スパイン リーフ アーキテクチャは、これらの制限に対処します。[ACI] ファブリックは、外界からは、ブリッジングとルーティングが可能な単一のスイッチに見えます。レイヤ3のルーティングをアクセス レイヤに移動すると、最新のアプリケーションが必要としている、レイヤ2の到達可能性が制限されます。仮想マシン ワークロード モビリティや一部のクラスタリングのソフトウェアのようなアプリケーションは、送信元と宛先のサーバ間がレイヤ2で隣接していることを必要とします。アクセス レイヤでルーティングを行えば、トランク ダウンされた同じ VLAN の同じアクセス スイッチに接続したサーバだけが、レイヤ2で隣接します。入力 [ACI] では、VXLAN が、基盤となるレイヤ3 ネットワーク インフラストラクチャからレイヤ2 のドメインを切り離すことにより、このジレンマを解決します。

図 1: ACI ファブリック



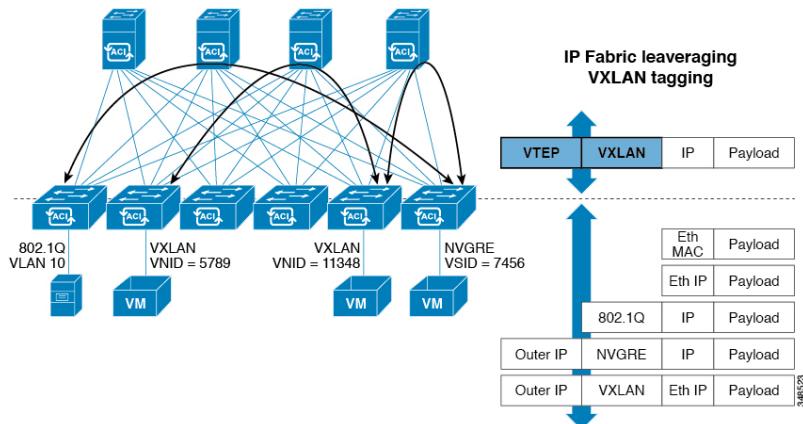
トラフィックがファブリックに入ると、[ACI] がカプセル化してポリシーを適用し、必要に応じてスパイン スイッチ(最大 2 ホップ)によってファブリックを通過させ、ファブリックを出るときにカプセル化を解除します。ファブリック内では、[ACI] はエンドポイント間通信でのすべての転送について、Intermediate System-to-Intermediate System プロトコル (IS-IS) および Council of Oracle Protocol (COOP) を使用します。これにより、すべての ACI リンクがアクティブで、ファブリック内の等コストマルチパス(ECMP)転送と高速再コンバージョンが可能になります。ファブリック内と、ファブリックの外部のルータ内でのソフトウェア定義ネットワーク間のルーティング情報を伝播するために、[ACI] はマルチプロトコル Border Gateway Protocol (MP-BGP) を使用します。

ACI で VXLAN

VXLAN は、レイヤ2 オーバーレイの論理ネットワークを構築するレイヤ3 のインフラストラクチャ上でレイヤ2 のセグメントを拡張する業界標準プロトコルです。[ACI] インフラストラクチャ レイヤ2 ドメインが隔離プロードキャストと障害ブリッジ ドメインをオーバーレイ内に存在します。このアプローチは大きすぎる、障害 ドメインの作成のリスクなしで大きくなるデータセンター ネットワークを使用できます。

すべてのトラフィック、[ACI] ファブリックは VXLAN パケットとして正規化されます。入力で [ACI] VXLAN パケットで外部 VLAN、VXLAN、および NVGRE パケットをカプセル化します。次の図は、[ACI] カプセル化の正規化を表示します。

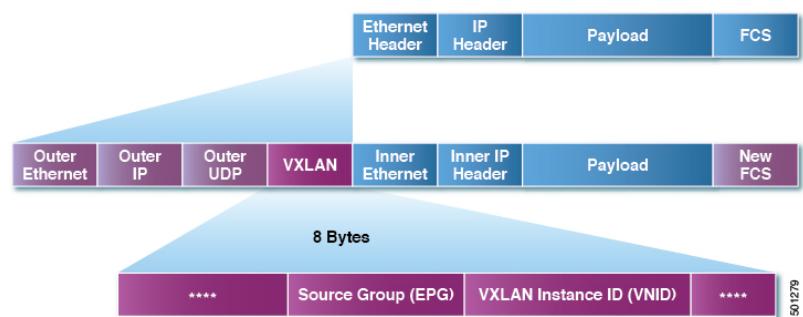
図 2:[ACI] カプセル化の正規化



[ACI] ファブリックでの転送は、カプセル化のタイプまたはカプセル化のオーバーレイ ネットワークによって制限または制約されません。[ACI] ブリッジ ドメインのフォワーディング ポリシーは、必要な場合に標準の VLAN 動作を提供するために定義できます。

ファブリック内のすべてのパケットが [ACI] ポリシー属性を持つので、[ACI] は、完全に分散された方法でポリシーを一貫して適用できます。[ACI] アプリケーション ポリシーの EPG ID を転送から分離します。次の図に示すように、[ACI] VXLAN ヘッダーは、ファブリック内のアプリケーション ポリシーを特定します。

図 3:[ACI] VXLAN のパケット形式



[ACI] VXLAN パケットには、レイヤ 2 の MAC アドレスとレイヤ 3 IP アドレスの送信元と宛先フィールド、ファブリック内の効率的など拡張性の転送を有効にします。[ACI] VXLAN パケットヘッダーの送信元グループフィールドは、パケットが属するアプリケーション ポリシー エンドポイント グループ (EPG) を特定します。VXLAN インスタンス ID (VNID) は、テナントの仮想ルーティングおよび転送 (VRF0) ドメイン ファブリック内で、パケットの転送を有効にします。VXLAN ヘッダーで 24 ビット VNID フィールドでは、同じネットワークで一意のレイヤ 2 のセグメントを最大 16 個の拡張アドレス空間を提供します。この拡張アドレス空間は、大規模なマルチ テナント データセンターを構築する柔軟性 IT 部門とクラウド プロバイダーを提供します。

■ サブネット間のテナント トラフィックの転送を促進するレイヤ3 VNID

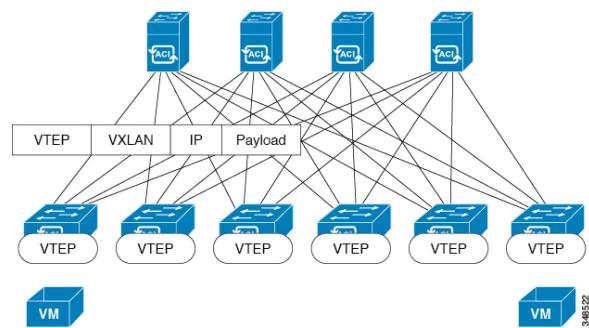
VXLAN の有効化に [ACI] ファブリック全体にわたってスケールでの仮想ネットワークインフラストラクチャのレイヤ3のアンダーレイレイヤ2を展開します。アプリケーションエンドポイントホスト柔軟に配置できます、アンダーレイインフラストラクチャのレイヤ3バウンダリのリスクなしでデータセンターネットワーク間をオーバーレイネットワーク、VXLANでレイヤ2の隣接関係を維持します。

サブネット間のテナント トラフィックの転送を促進するレイヤ3 VNID

[ACI] ファブリックは、[ACI] ファブリック VXLAN ネットワーク間のルーティングを実行するテナントのデフォルトゲートウェイ機能を備えています。各テナントに対して、ファブリックはテナントに割り当てられたすべてのリーフスイッチにまたがる仮想デフォルトゲートウェイを提供します。これは、エンドポイントに接続された最初のリーフスイッチの入力インターフェイスで提供されます。各入力インターフェイスはデフォルトゲートウェイインターフェイスをサポートします。ファブリック全体のすべての入力インターフェイスは、特定のテナントサブネットに対して同一のルータの IP アドレスと MAC アドレスを共有します。

[ACI] ファブリックは、エンドポイントのロケータまたは VXLAN トンネルエンドポイント(VTEP)アドレスで定義された場所から、テナントエンドポイントアドレスとその識別子を切り離します。ファブリック内の転送は VTEP 間で行われます。次の図は、[ACI]で切り離された ID と場所

図 4:[ACI]によって切り離された ID と場所



VXLAN は VTEP デバイスを使用してテナントのエンドデバイスを VXLAN セグメントにマッピングし、VXLAN のカプセル化およびカプセル化解除を実行します。各 VTEP 機能には、次の 2 つのインターフェイスがあります。

- ・ブリッジングを介したローカルエンドポイント通信をサポートするローカル LAN セグメントのスイッチインターフェイス
- ・転送 IP ネットワークへの IP インターフェイス

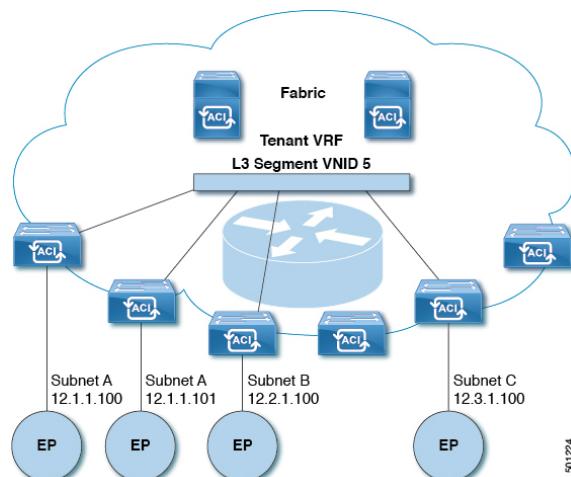
IP インターフェイスには一意の IP アドレスがあります。これは、インフラストラクチャ VLAN として知られる、転送 IP ネットワーク上の VTEP を識別します。VTEP デバイスはこの IP アドレスを使用してイーサネットフレームをカプセル化し、カプセル化されたパケットを、IP インターフェイスを介して転送ネットワークへ送信します。また、VTEP デバイスはリモート VTEP で VXLAN セグメントを検出し、IP インターフェイスを介してリモートの MAC Address-to-VTEP マッピングについて学習します。

[ACI] の VTEP は分散マッピングデータベースを使用して、内部テナントの MAC アドレスまたは IP アドレスを特定の場所にマッピングします。VTEP はルックアップの完了後に、宛先リーフスイッチ上の VTEP を宛先アドレスとして、VXLAN 内でカプセル化された元のデータパケットを送信します。宛先リーフスイッチはパケットをカプセル化解除して受信ホストに送信します。このモデルにより、ACI はスパニングツリープロトコルを使用することなく、フルメッシュでシングル ホップのループフリートポロジを使用してループを回避します。

VXLAN セグメントは基盤となるネットワーク トポロジに依存しません。逆に、VTEP 間の基盤となる IP ネットワークは、VXLAN オーバーレイに依存しません。これは送信元 IP アドレスとして開始 VTEP を持ち、宛先 IP アドレスとして終端 VTEP を持つており、外部 IP アドレス ヘッダーに基づいてパケットをカプセル化します。

次の図は、テナント内のルーティングがどのように行われるかを示します。

図 5: レイヤ 3 VNID トランスポート [ACI] サブネット間のテナント トラフィック



ファブリックの各テナント VRF について、[ACI] 単一の L3 VNID を割り当てます。ACI は、L3 VNID に従ってファブリック全体にトラフィックを転送します。出力リーフスイッチでは、ACI によって L3 VNID からのパケットが出力サブネットの VNID にルーティングされます。

ファブリック入力に到着し、[ACI] のファブリック デフォルト ゲートウェイに送信されるトラフィックは、レイヤ 3 VNID にルーティングされます。これにより、テナント内でルーティングされるトラフィックはファブリックで非常に効率的に転送されます。このモデルを使用すると、たとえば同じ物理ホスト上の同じテナントに属し、サブネットが異なる 2 つの VM 間では、トラフィックが(最小パス コストを使用して)正しい宛先にルーティングされる際に経由する必要があるは入力スイッチインターフェイスのみです。

ファブリック内で外部ルートを配布するために、[ACI] ルート リフレクタは、マルチプロトコル BGP (MP-BGP) を使用します。ファブリック管理者は自律システム (AS) 番号を提供し、ルート リフレクタにするスパインスイッチを指定します。

サブネット間のテナント トラフィックの転送を促進するレイヤ3 VNID



(注)

[Cisco ACI] は IP フラグメンテーションをサポートしていません。したがって、外部ルータへのレイヤ3 Outside (L3Out) 接続、または Inter-Pod Network (IPN) を介したマルチポッド接続を設定する場合は、インターフェイス MTU がリンクの両端で適切に設定することを推奨します。

IGP プロトコルパケット (EIGRP、OSPFv3) は、インターフェイス MTU サイズに基づいてコンポーネントによって構築されます。[Cisco ACI]では、CPU MTU サイズがインターフェイス MTU サイズよりも小さく、構築されたパケットサイズが CPU MTU より大きい場合、パケットはカーネルによってドロップされます (特に IPv6)。このような制御パケットのドロップを回避するには、コントロールプレーンとインターフェイスの両方で常に同じ MTU 値を設定します。

[Cisco ACI]、Cisco NX-OS、および Cisco IOS などの一部のプラットフォームでは、設定可能な MTU 値はイーサネットヘッダー (一致する IP MTU、14-18 イーサネットヘッダーサイズを除く) を考慮していません。また、IOS XR などの他のプラットフォームには、設定された MTU 値にイーサネットヘッダーが含まれています。構成された値が 9000 の場合、[Cisco ACI]、Cisco NX-OS および Cisco IOS の最大 IP パケットサイズは 9000 バイトになりますが、IOS-XR のタグなしインターフェイスの最大 IP パケットサイズは 8986 バイトになります。

各プラットフォームの適切な MTU 値については、それぞれの設定ガイドを参照してください。

CLIベースのコマンドを使用して MTU をテストすることを強く推奨します。たとえば、[Cisco NX-OS] CLI で ping 1.1.1.1 df-bit packet-size 9000 source-interface ethernet 1/1 などのコマンドを使用します。

翻訳について

このドキュメントは、米国シスコ発行ドキュメントの参考和訳です。リンク情報につきましては、日本語版掲載時点で、英語版にアップデートがあり、リンク先のページが移動/変更されている場合がありますことをご了承ください。あくまでも参考和訳となりますので、正式な内容については米国サイトのドキュメントを参照ください。