

# 「さくらのクラウド」を例に見る ネットワーク仮想化の設計と実装

さくらインターネット研究所

大久保修一 <ohkubo@sakura.ad.jp>

# Agenda

- クラウドとは？ IaaSとは？
- さくらのクラウドの目指すところ
- ネットワークの設計と実装
- 将来の構想
- 仮想アプライアンス
- まとめ

# 自己紹介

- 2003年4月 さくらインターネット入社
  - 以後、ネットワークの運用に携わる
- 2009年7月 さくらインターネット研究所
  - 発足と同時に異動
  - クラウド、IPv4アドレス枯渇について研究活動
- 2011年3月 クラウドサービスの開発に従事
  - 主にネットワーク部分を担当

# ところで、、

- 昨日(9/27)、PublickeyさんからPR記事を公開いただきました。
- PR:「さくらのクラウド」のアーキテクチャは、意外なほどシンプルだった
- [http://www.publickey1.jp/blog/11/pr\\_sakuracloud.html](http://www.publickey1.jp/blog/11/pr_sakuracloud.html)

# クラウドとは？

- NISTの定義がよく引用される
- 五つの特徴
  - On-demand self-service  
必要に応じてコンピュータリソースを利用可能
  - Resource pooling  
マルチテナントモデル、リソース配置場所の隠蔽
  - Rapid elasticity  
スケールアウト可能
  - Broad network access  
様々なプラットフォームから利用可能
  - Measured Service  
計測によるサービスの透明性

# IaaSとは？

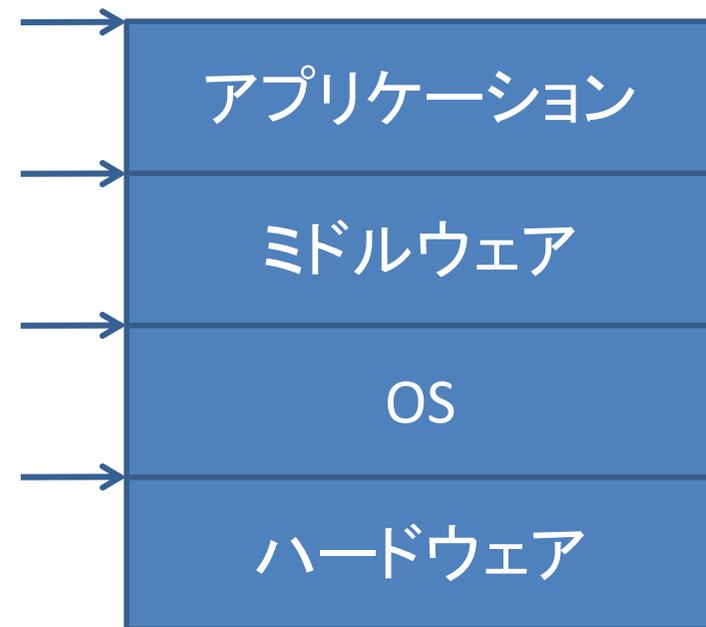
- 三つのサービスモデル

- SaaS (Software as a Service)

- PaaS (Platform as a Service)

- IaaS (Infrastructure as a Service)

- HaaS (Hardware as a Service)



現在の「さくらのクラウド」はIaaSです。

# IaaSに求められること

- 仮想マシンを自由に構成して作成できる  
(例)
  - CPUコア数: 2個
  - メモリ: 8GB
  - HDD: 1TB
  - NIC: 4枚
- 仮想ネットワークを自由に構成できる
- 様々な仮想アプリケーションを使える
  - 例: 仮想ルータ、仮想FW、仮想LB
- 利用実績に応じた支払い

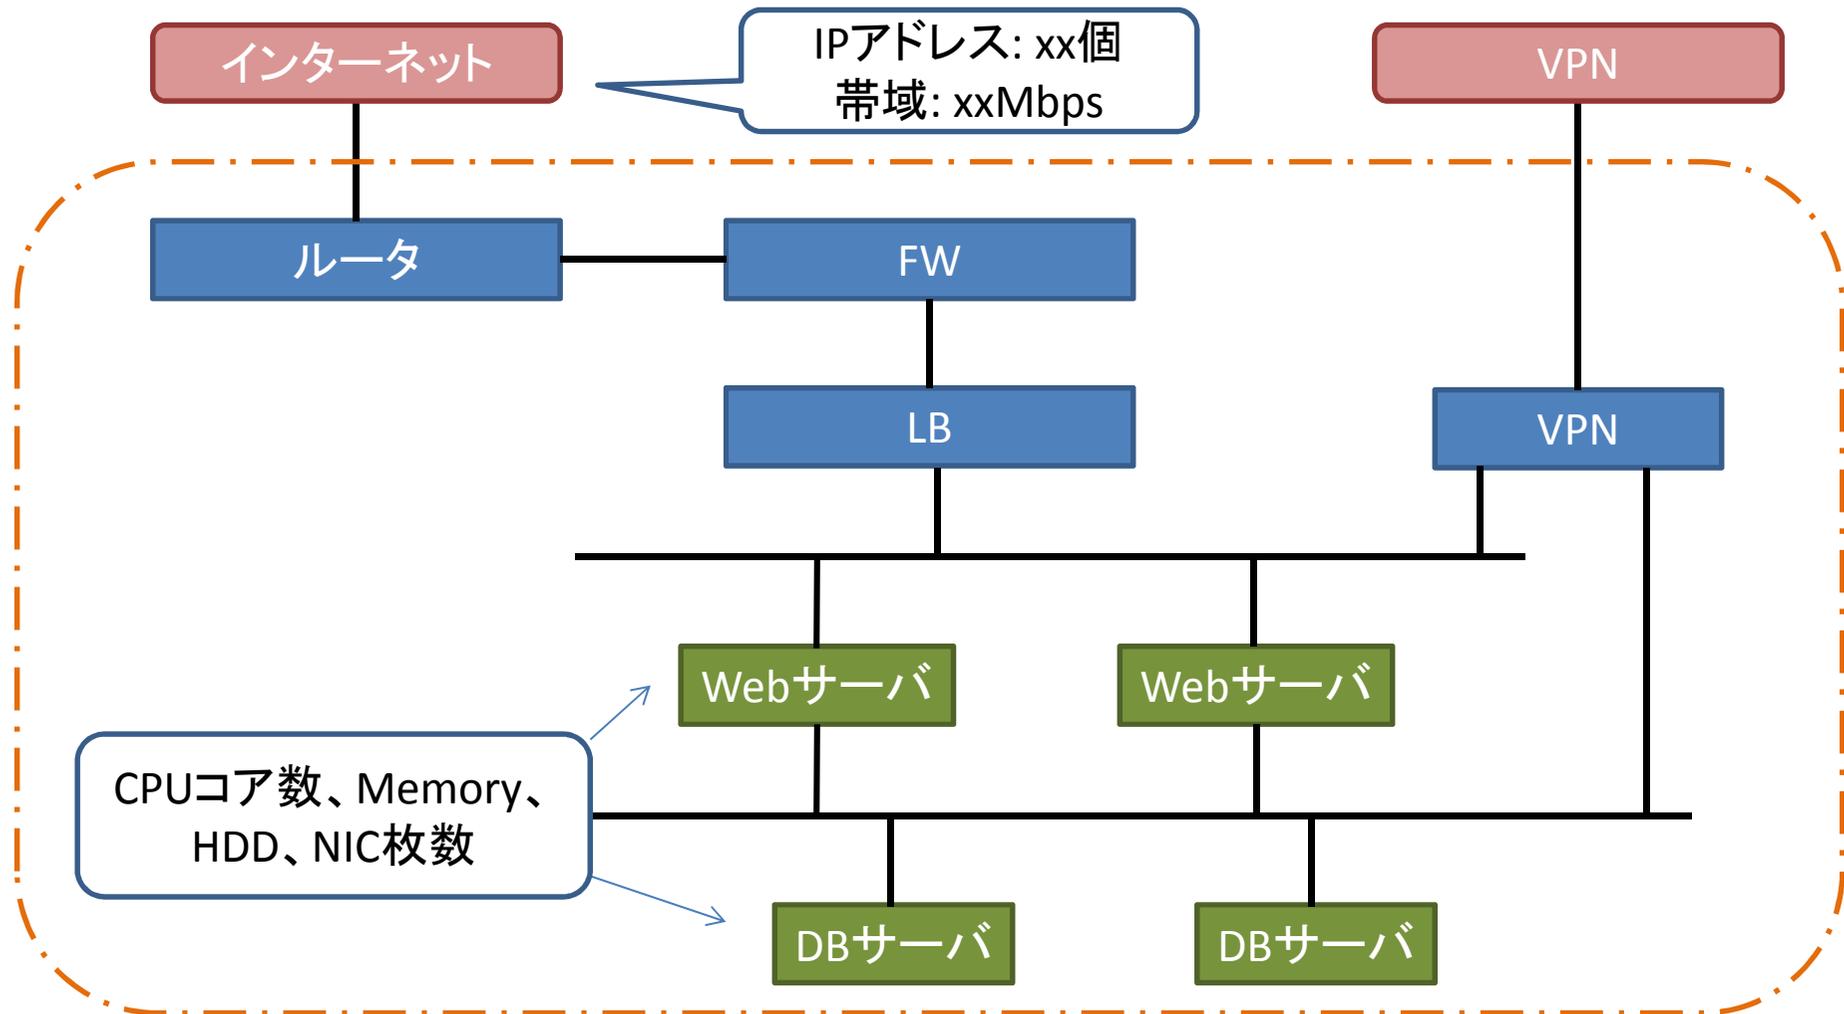
# そういえば……

ちょうど1年くらい前に社長がプロトタイプを作っていた

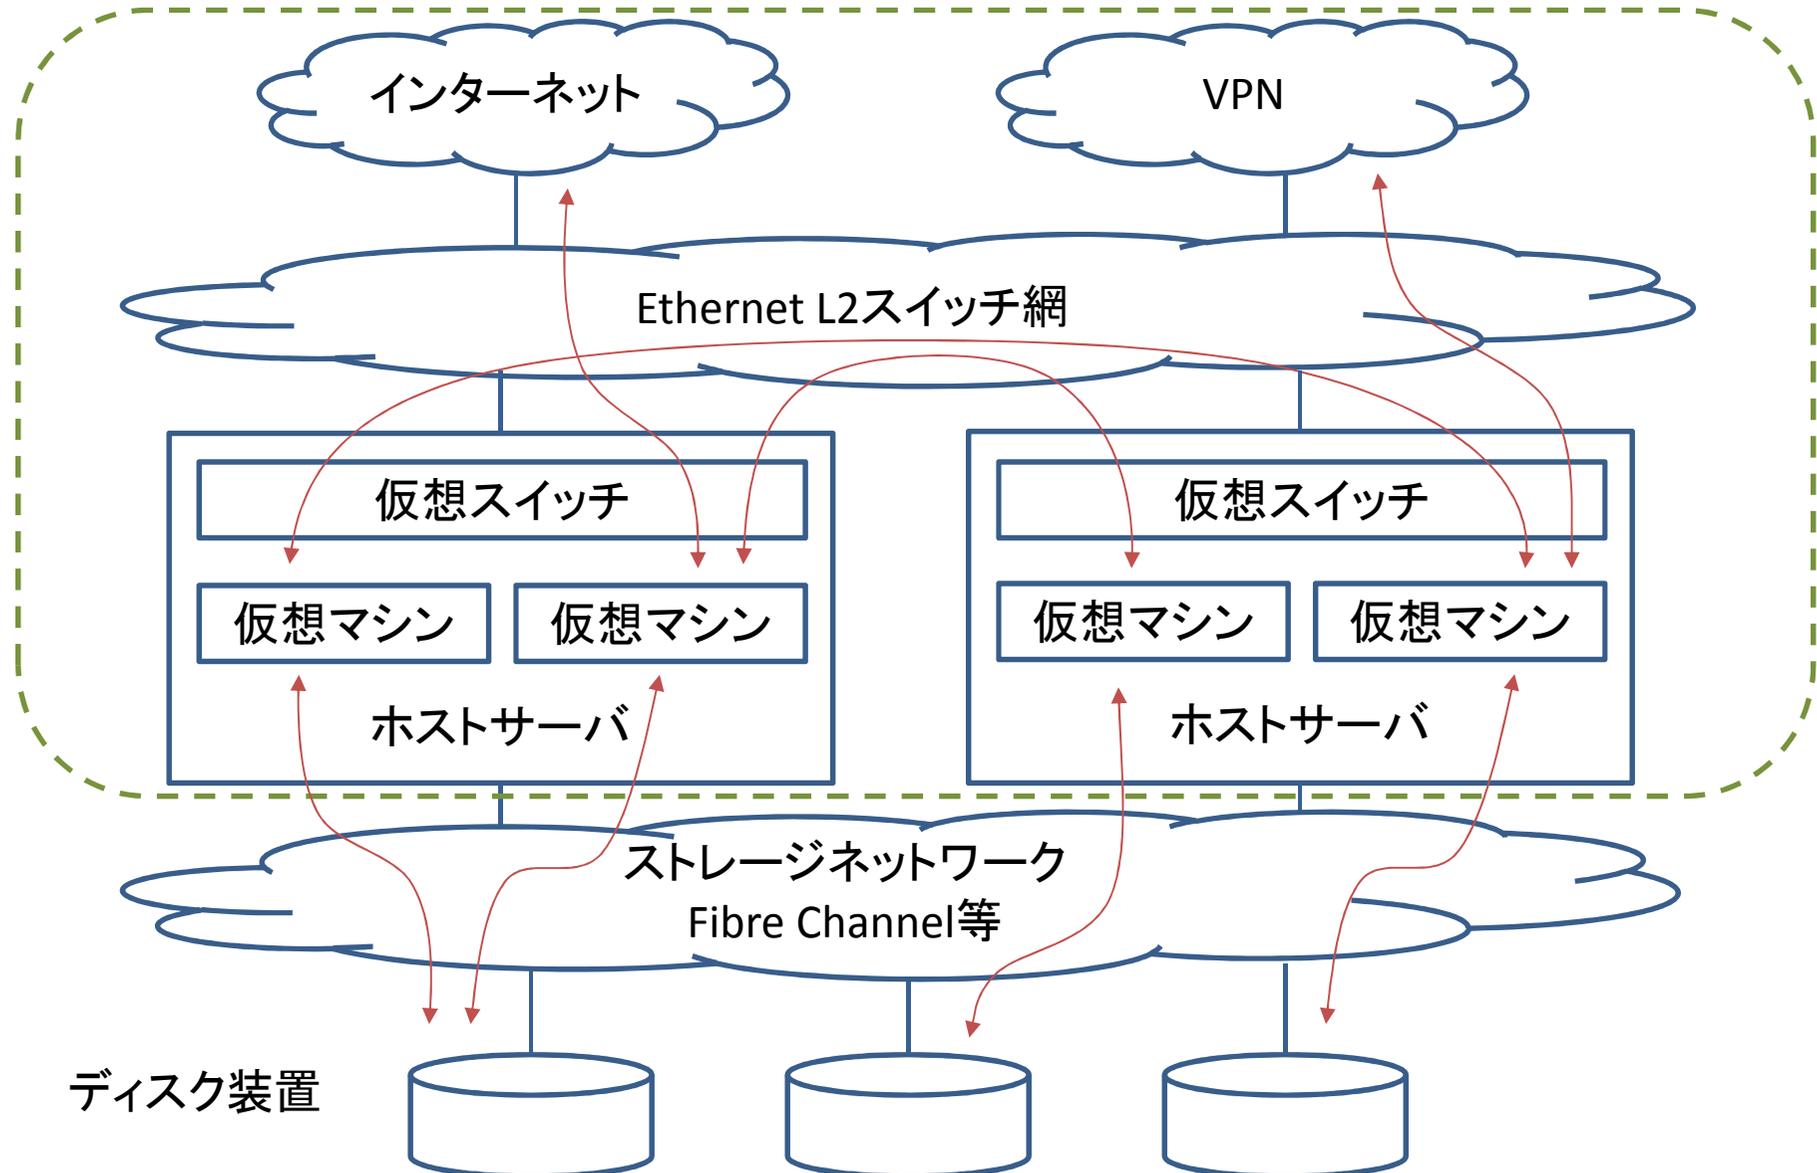


# IaaS上でのシステム構築例

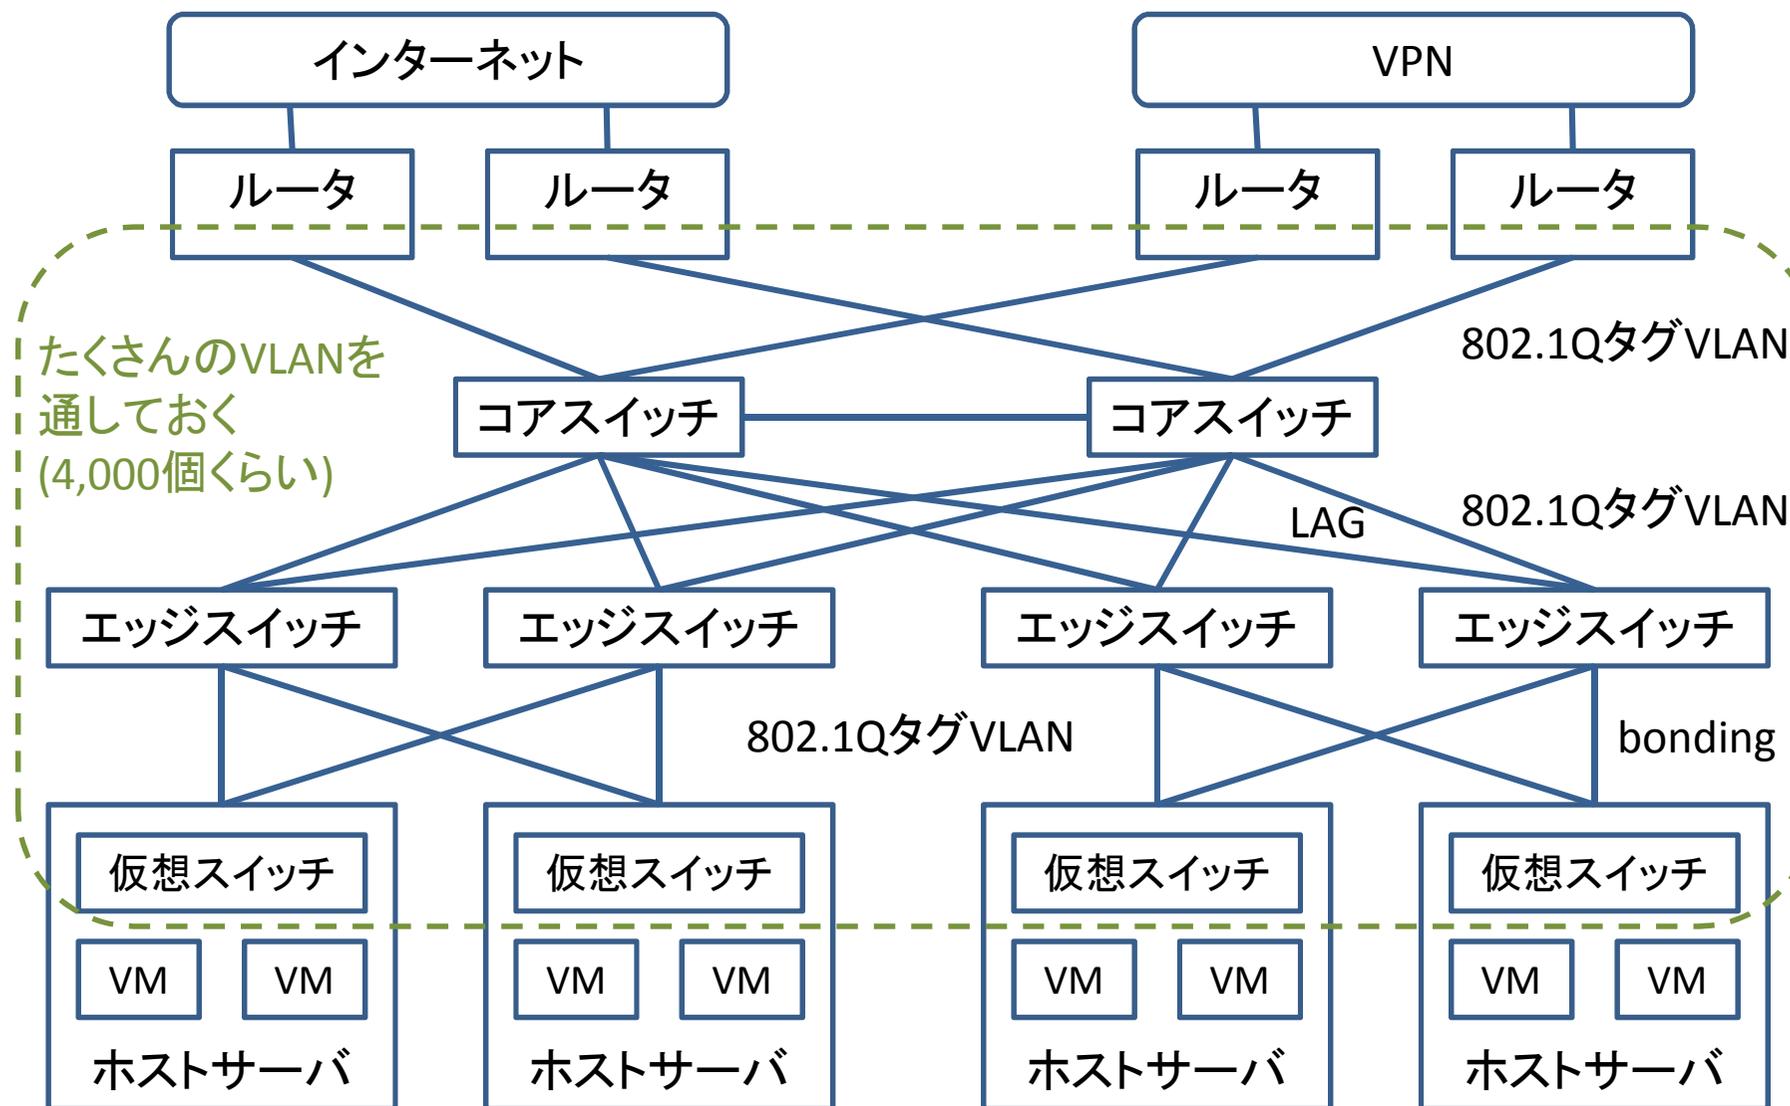
利用者がサーバ構成、ネットワーク構成を定義



# IaaSインフラの構成

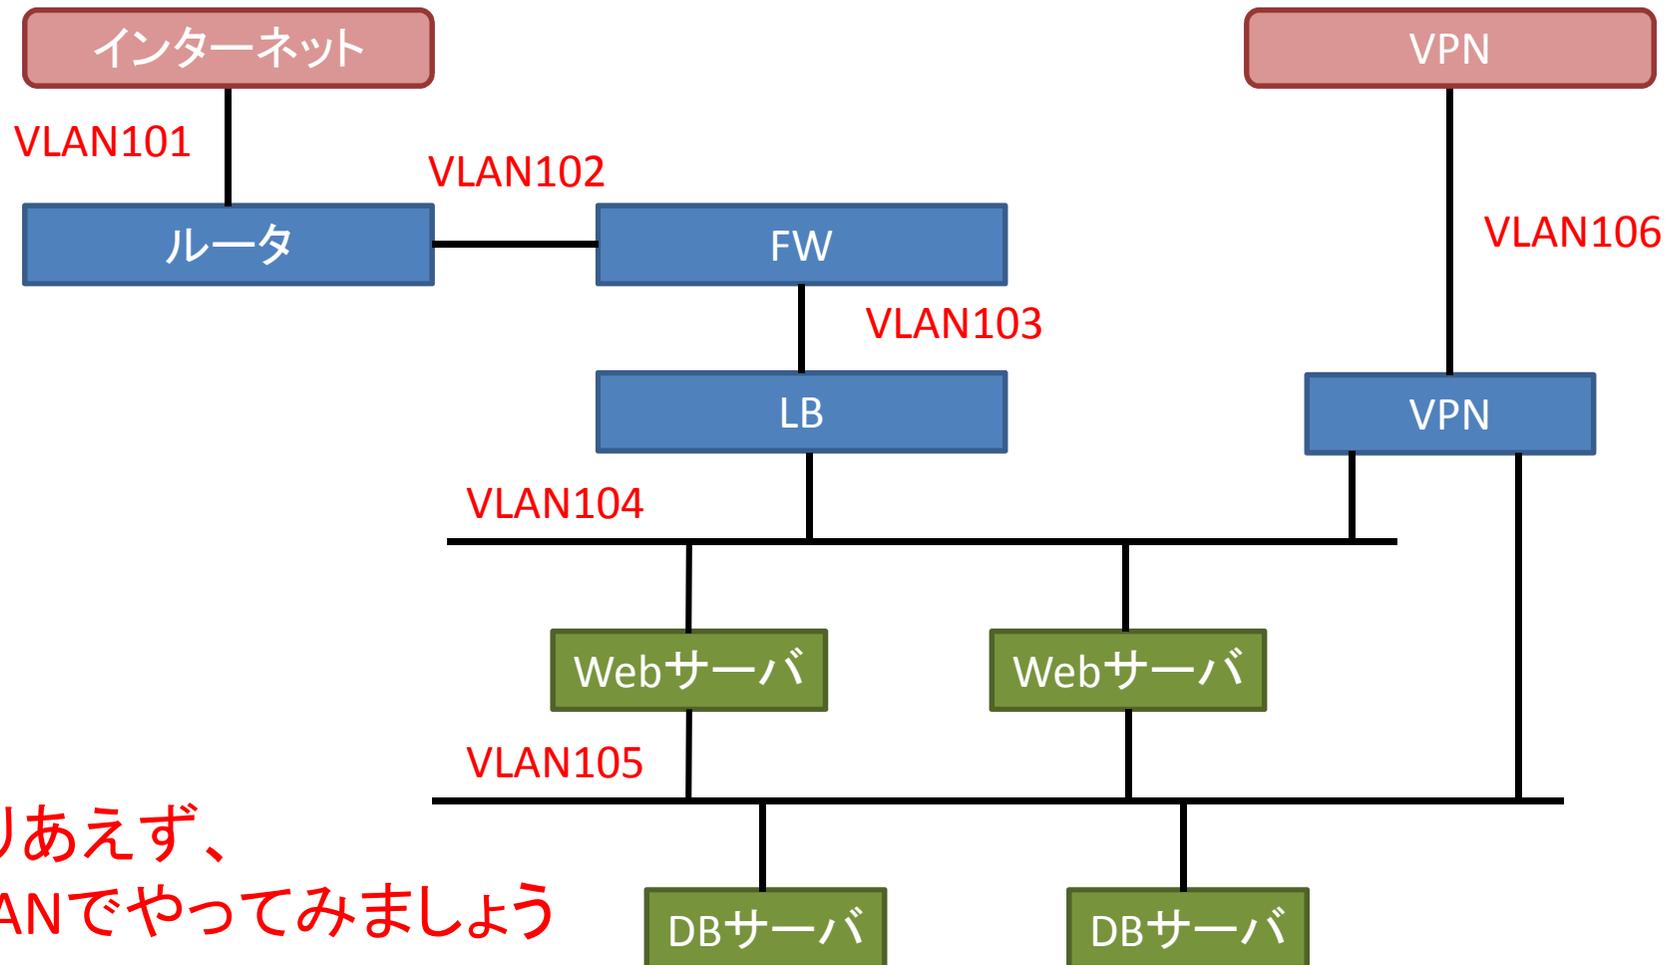


# IaaSネットワークの物理構成



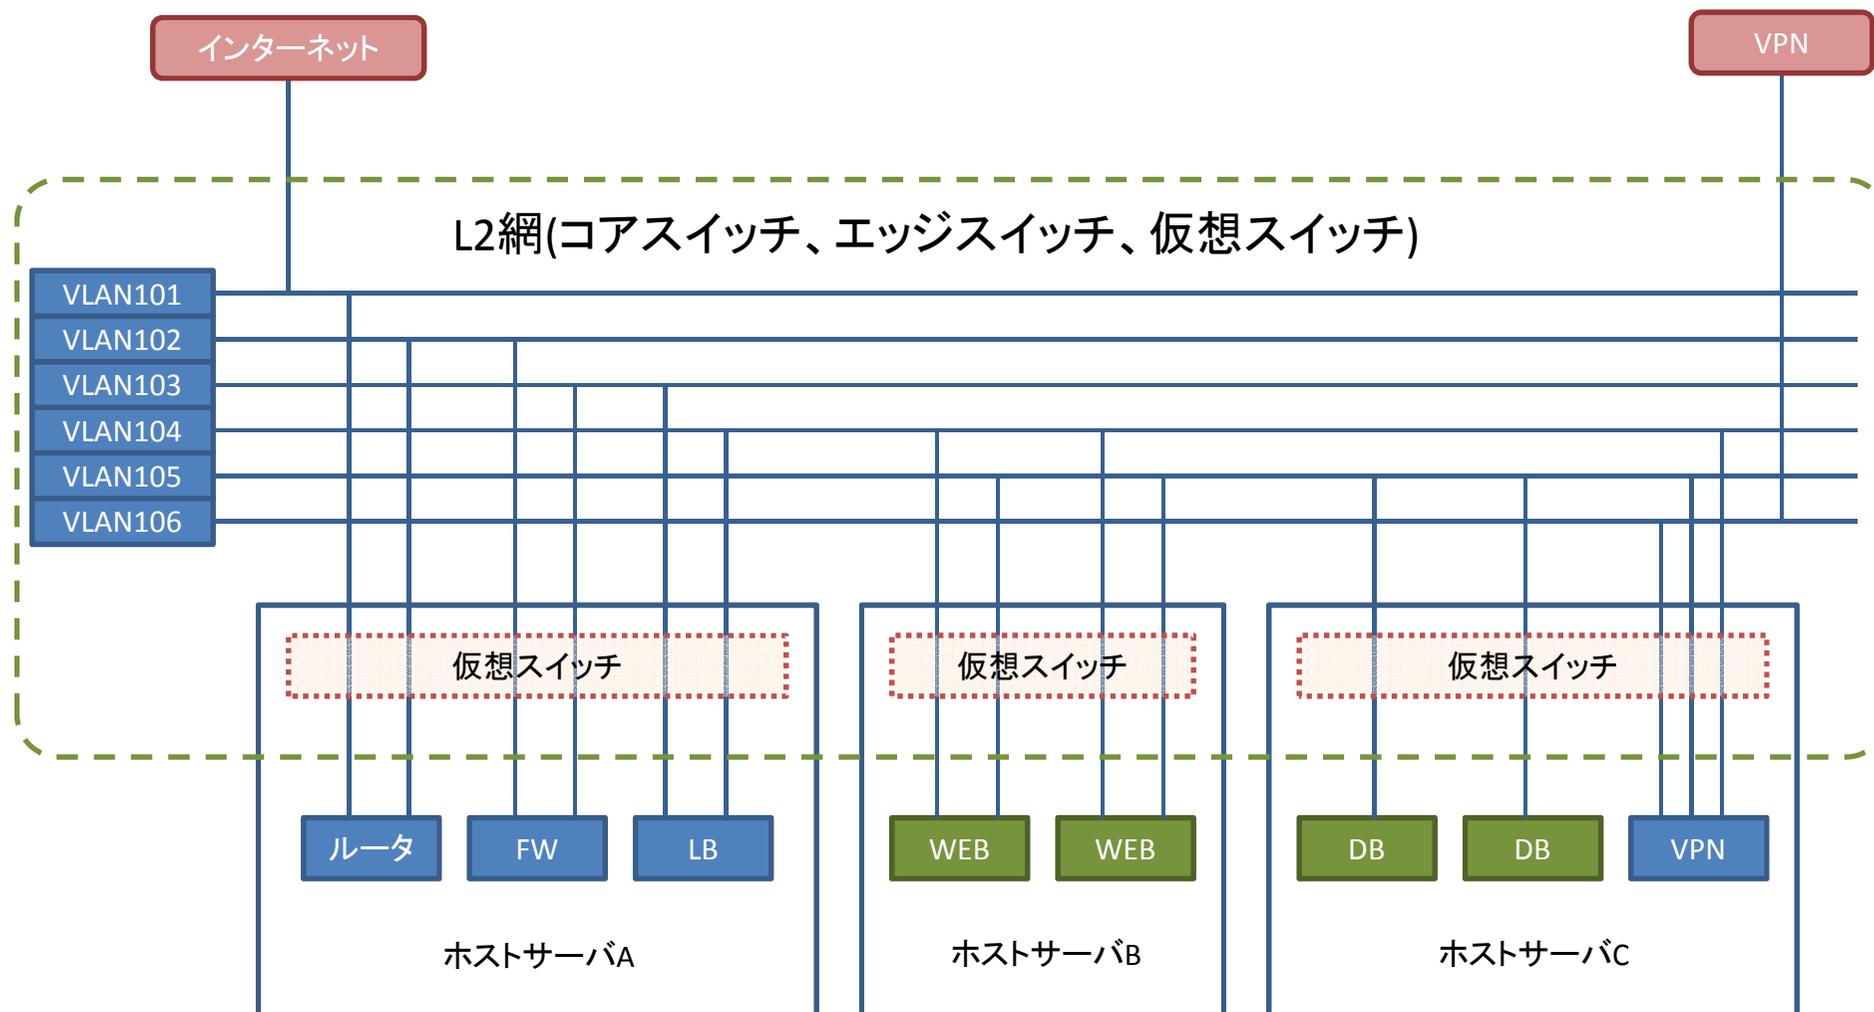
# 仮想システムプロビジョニング例

これを、IaaSインフラ上に展開してみる



とりあえず、  
VLANでやってみましょう

# クラウド上に配置したシステム



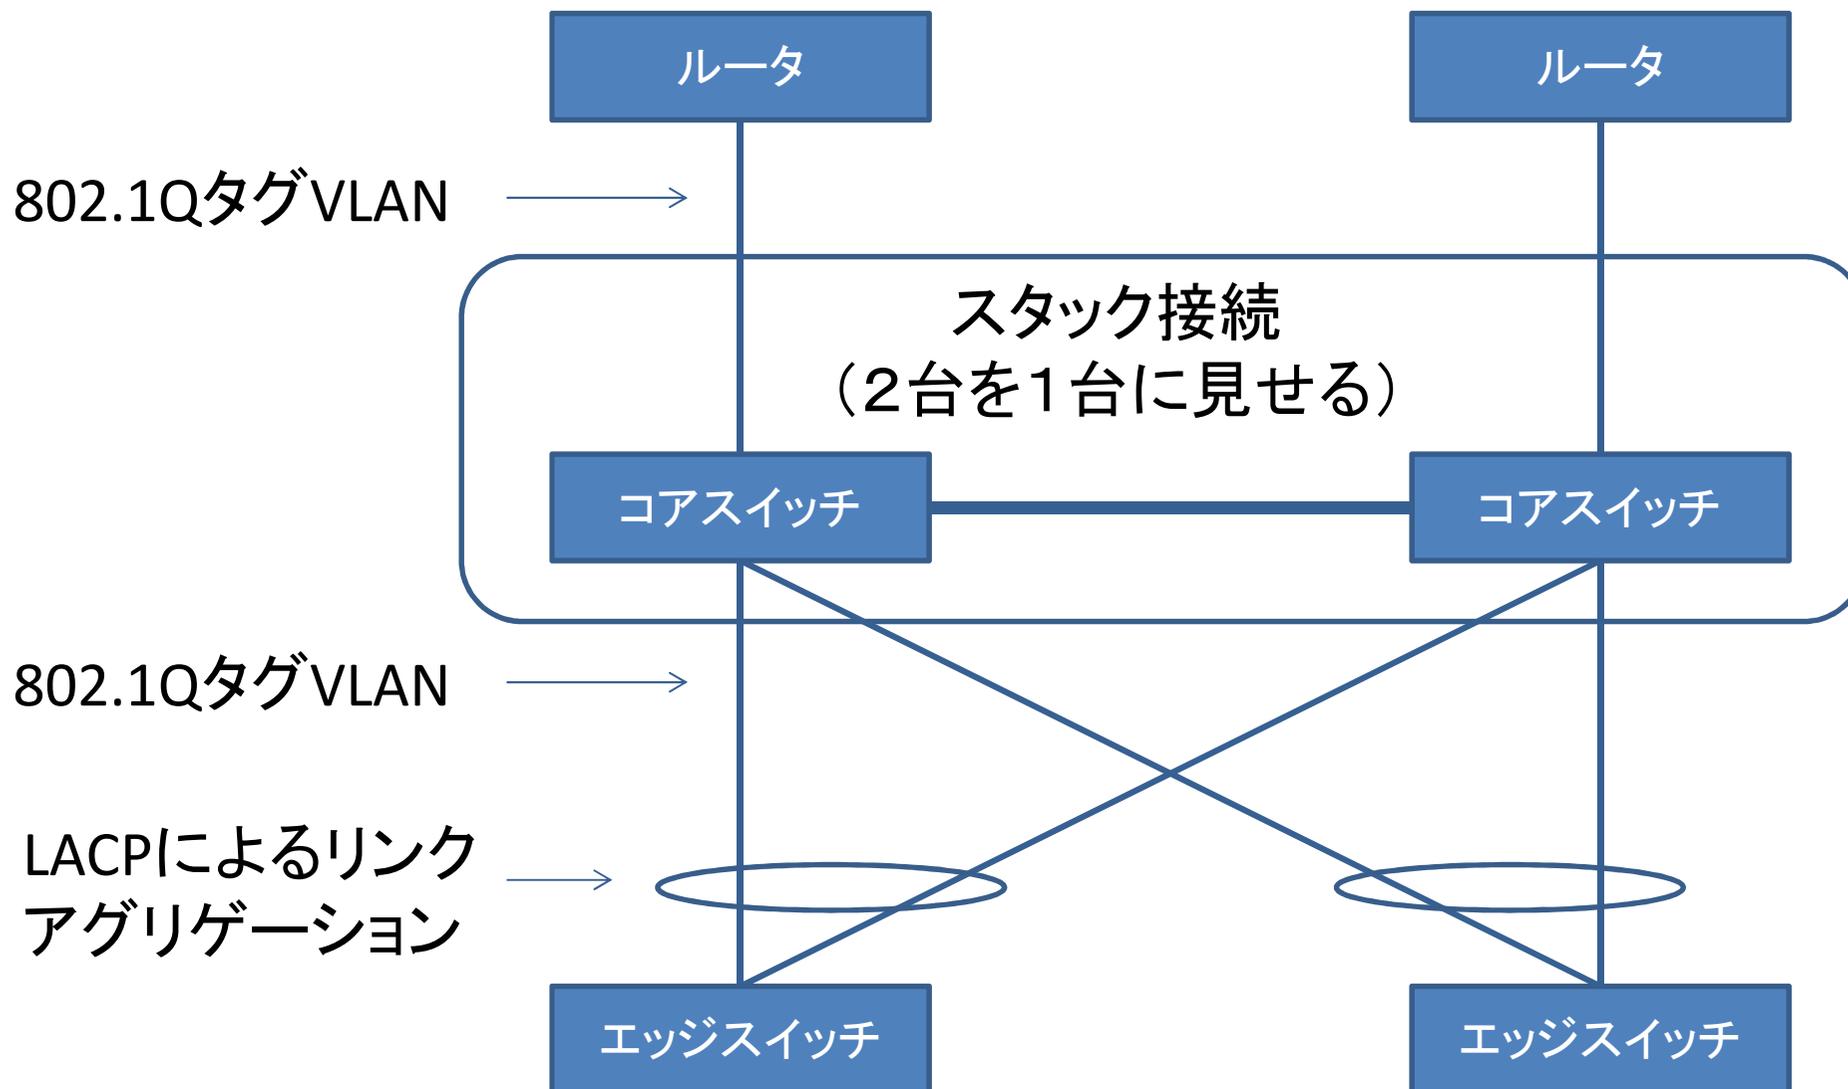
# 1ゾーンあたりの規模

- VLAN数: MAX4,096 (VLAN ID数の制限による)
- コアスイッチ数: 2台 (2台1セット)
- エッジスイッチ数: 数十台 (2台1セット)
- ホストサーバ数: 数百台
- VM数: MAX8,000
- VMあたり仮想NIC数: 平均2個
- MACアドレス数: 16,000 (8,000 × 2)

# 検討が必要な要素

- コアスイッチ
- エッジスイッチ
- 仮想スイッチ
- ルータ

# コア・エッジスイッチ間の接続



# コアスイッチの要件

- 2台でエッジスイッチやルータを集約する
- 冗長性: スタック機能
- VLAN数: 3,500以上
- MACアドレス数: 16,000以上
- ポート数: 40ポート以上

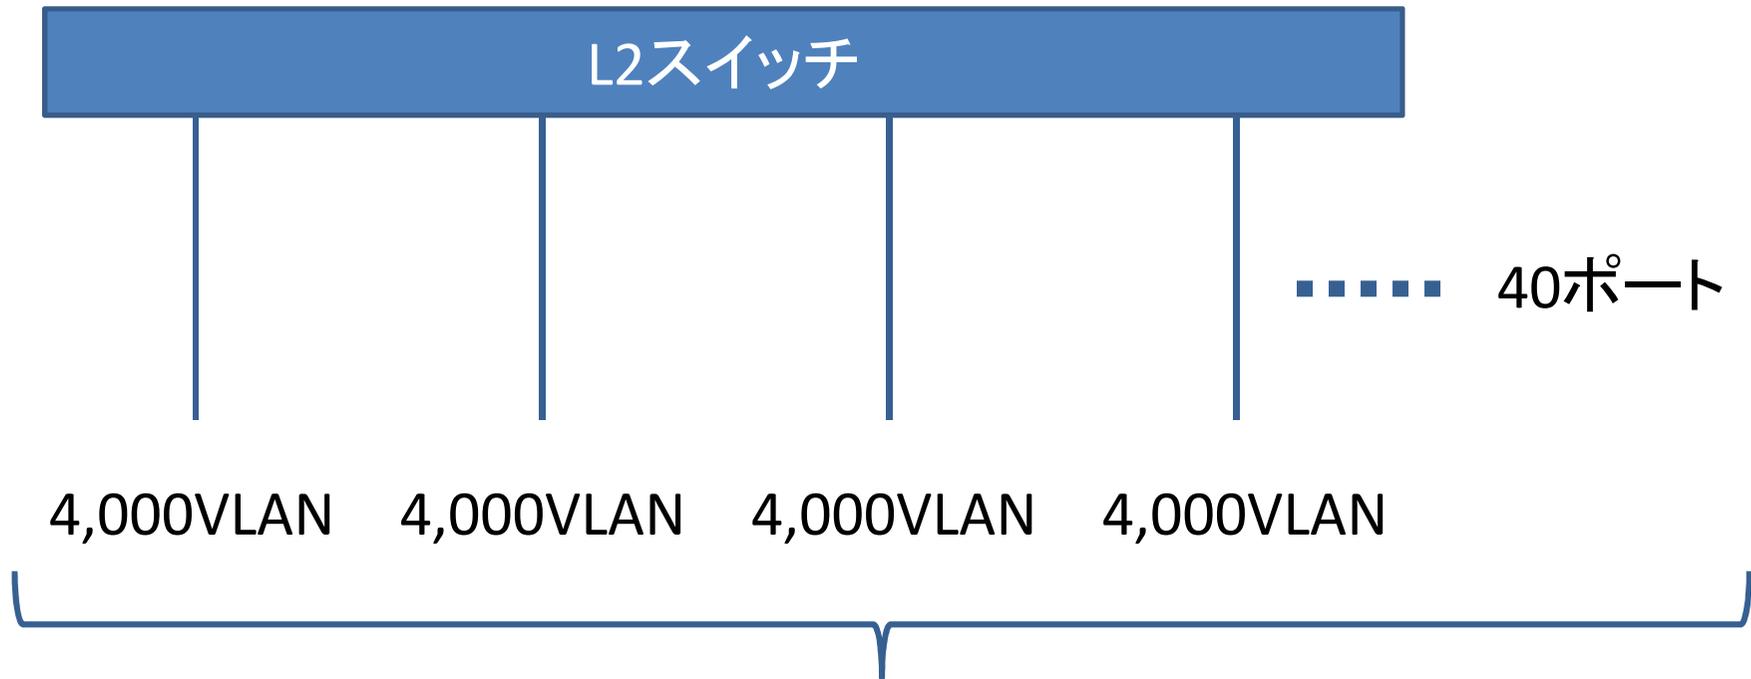
# エッジスイッチの要件

- 各ラックに2台ずつ(表、裏) 設置し、ラック内サーバを収容する
- 冗長性: Link Aggregation
- VLAN数: 3,500以上
- MACアドレス数: 16,000以上
- ポート数: 40ポート以上
- ループ検出機能

# 検証時に発生した問題

- ロジカルポート数の不足
- ショートパケットでワイヤレート出ない
- 使えないVLAN-IDが存在する
- configが長い
- 溢れてないのに学習できないMACアドレスがある
- VLANを設定すると、MACアドレステーブルを消費する
- LACPがダウンする

# ロジカルポート数の不足



約4,000 × 40ポート = 約160,000ロジカルポート必要

ロジカルポート数が12,000や24,000の制限があるスイッチ  
→採用せず

# ショートパケットでワイヤレートでない

## Etherのフレームフォーマット



最小 64Bytes

最小 84Bytes

最小フレーム長でワイヤレート出るには？

$$14.88\text{Mpps} = 10,000,000,000 / 8 / 84$$

ワイヤレートでないスイッチはよくある

→ 現実的に問題ない範囲ならOKとする。

# 使えないVLAN IDが存在する

- VLAN 1002番
  - 某箱では、FCoEのIDとして予約されている
- VLAN 1002～1005と1006以降いくつか
  - 某箱では、routed interfaceに割り当てられたり、予約されていたりする(show vlan internal usage)
- VLAN 3584～
  - 某箱では使用できない
- Configできても、正式サポート数が少ない(2000VLANとか。。)
- クラウドコントローラにて、お客様に割り当てないようにする必要あり

# Configが長くなる

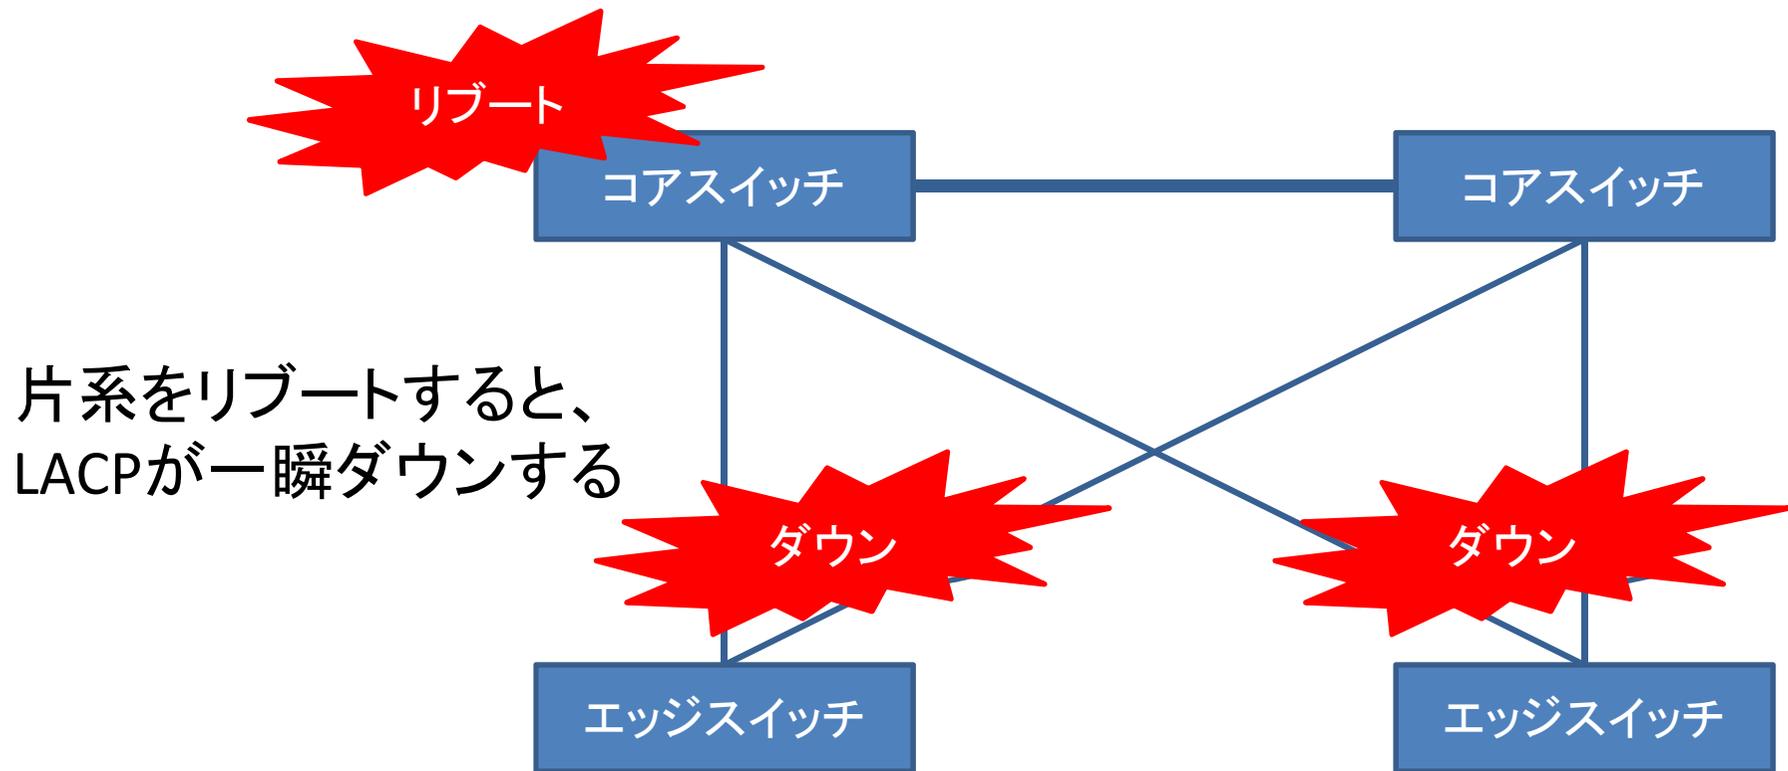
```
interface Vlan 1
  no shutdown
!
interface Vlan 2
  no shutdown
!
. . . 省略 . . .
interface Vlan 1998
  no shutdown
!
interface Vlan 1999
  no shutdown
!
interface Vlan 2000
  no shutdown
```

1VLAN毎に設定が必要

VLAN設定をまとめられるとうれしい

# LACPがダウンする

冗長性が確保できているはずだが...



スイッチのバグ → 修正してもらった

# MACアドレスハッシュコリジョン問題

- 多くのL2スイッチは、MACアドレスの学習にハッシュテーブルを使用している
- ハッシュ値のコリジョンが発生し、ハッシュテーブルの深さを超えると、学習できないMACアドレスが発生する
- 学習できないMACアドレスは、Unknown Unicast扱いとなりフラッディングする(設定によっては帯域制限がかかり、通信に影響)

# MACアドレスハッシュコリジョン問題

同じハッシュ値をとる5つ目のMACアドレスが来ると学習できない



4段の例

ハッシュ値1	gg:gg:gg:gg:gg:gg	hh:hh:hh:hh:hh:hh	ii:ii:ii:ii:ii:ii	jj:jj:jj:jj:jj:jj
ハッシュ値2	⋮	⋮	⋮	⋮
ハッシュ値3	⋮	⋮	⋮	⋮
ハッシュ値4	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮

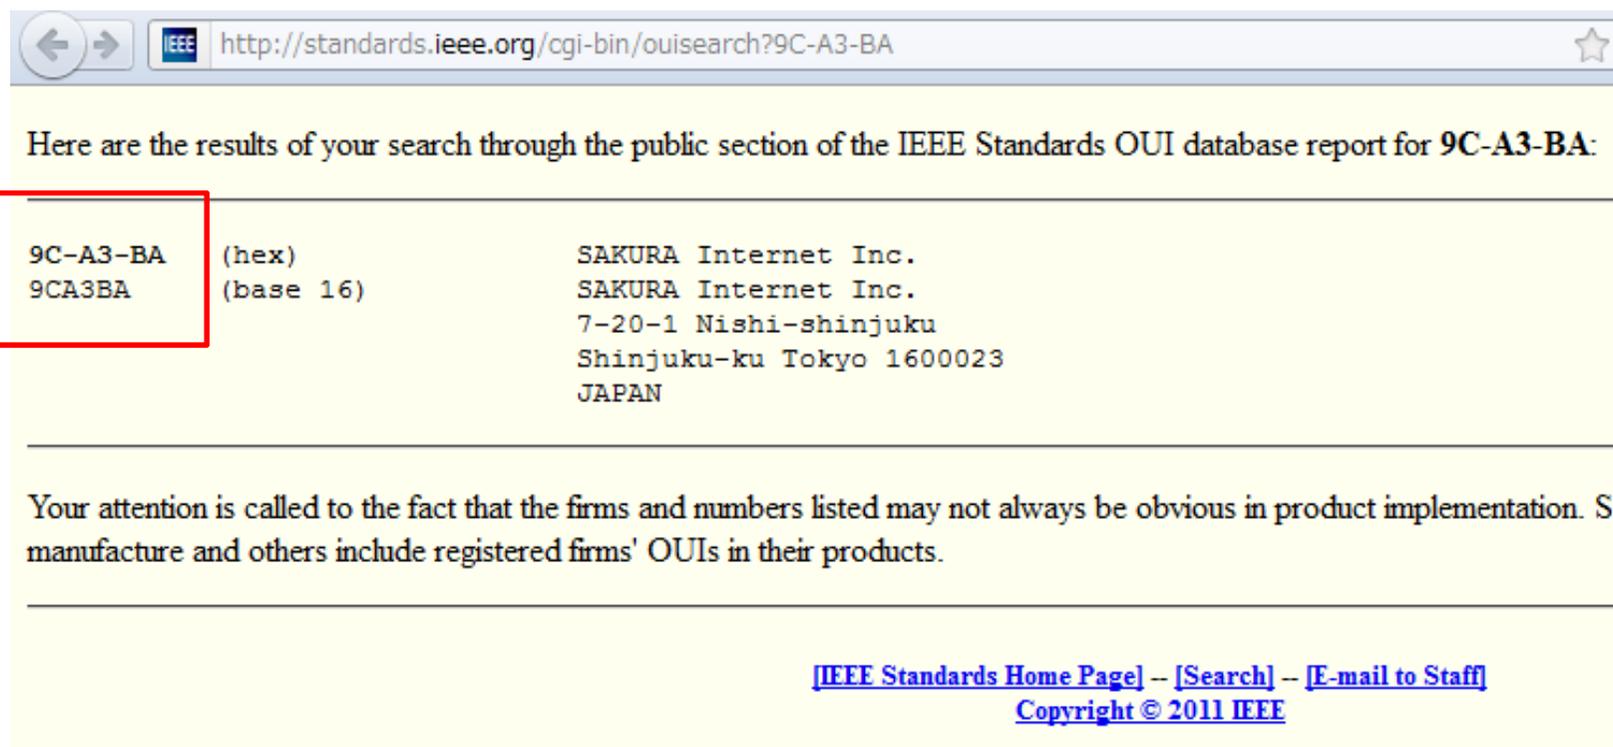
VMに割り当てるMACアドレスをランダムにすることで、コリジョンの可能性を減らすことができる

# VLANでMACエントリを消費

- 某B社のスイッチ
- スペックでは32,000のMACアドレステーブル
- ただ、1VLAN設定すると、3エントリ消費
- CPUに吸い上げる特殊なMACアドレスを自動で登録しているもよう
- 4,000VLAN設定すると、12,000エントリ消費
- 残り、20,000エントリしか使えない。。。

# 余談：OUI取得しました

<http://standards.ieee.org/cgi-bin/ouisearch?9C-A3-BA>



The screenshot shows a web browser window with the URL <http://standards.ieee.org/cgi-bin/ouisearch?9C-A3-BA>. The page content is as follows:

Here are the results of your search through the public section of the IEEE Standards OUI database report for 9C-A3-BA:

9C-A3-BA	(hex)	SAKURA Internet Inc.
9CA3BA	(base 16)	SAKURA Internet Inc. 7-20-1 Nishi-shinjuku Shinjuku-ku Tokyo 1600023 JAPAN

Your attention is called to the fact that the firms and numbers listed may not always be obvious in product implementation. Some manufacturers and others include registered firms' OUIs in their products.

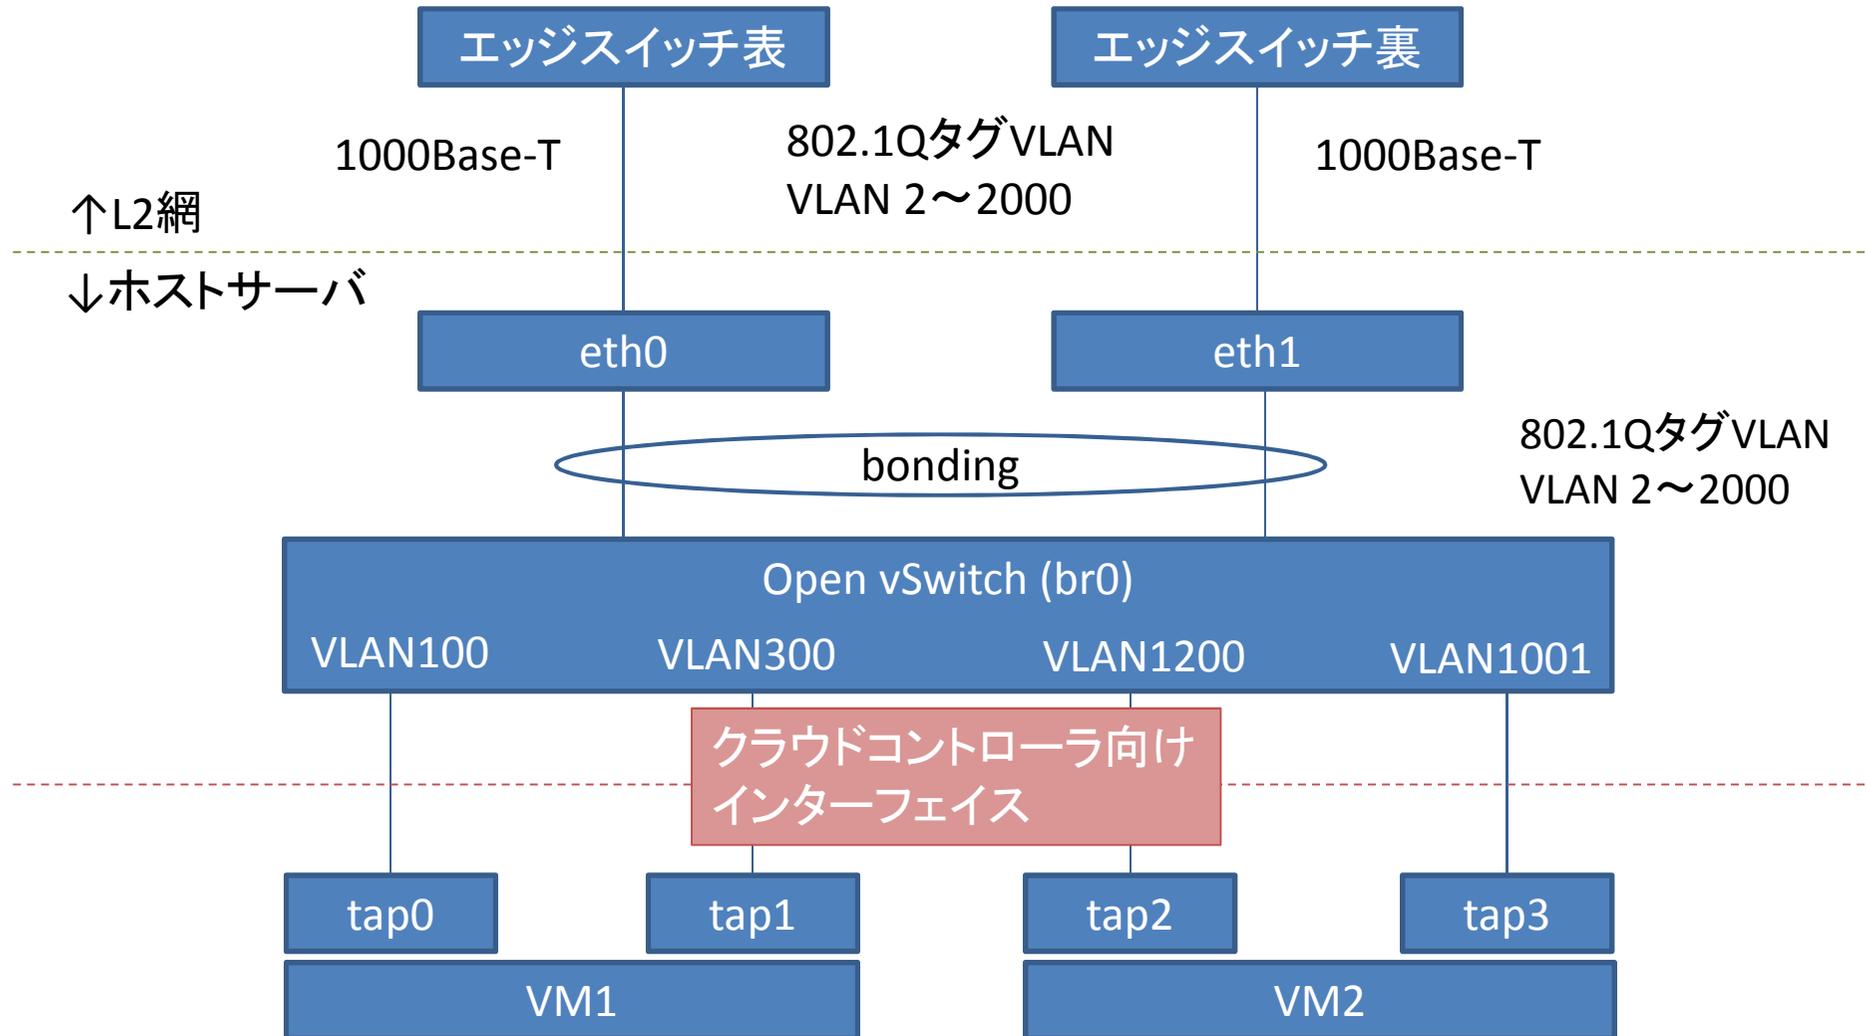
[\[IEEE Standards Home Page\]](#) -- [\[Search\]](#) -- [\[E-mail to Staff\]](#)  
Copyright © 2011 IEEE

他のクラウドや他の物理ネットワークとの  
L2レベルでの相互接続も問題なし！

# 仮想スイッチの要件

- ホストサーバ上で動作し、物理ネットワークとVM間の通信の橋渡しを行う。
- 冗長性: Bonding
- VLAN数: 3,500以上
- MACアドレス数: 16,000以上
- VM向けにフィルタ設定が必要
  - MACスプーフィング対策、ARPスプーフィング対策、
  - IPスプーフィング対策
  - その他
- 仮想ポートで帯域制限
- 弊社では、Open vSwitchを採用

# 弊社の実装例



# Open vSwitchのMAC学習数

- デフォルトで2,048になっていた  
全然足りない
- ソースコードを変更して32,768にして使用

```
% vi lib/mac-learning.h  
  
//#define MAC_MAX 2048  
#define MAC_MAX 32768
```

# 共有セグメントのスプーフィング対策

Open vSwitchでは、Open Flowのエントリとしてフィルタを設定する。

```
% ovs-ofctl add-flow br0 in_port=8, actions=drop
% ovs-ofctl add-flow br0 in_port=8, dl_src=52:54:00:f4:c7:47, ip,
  nw_src=10.0.140.1, actions=normal
% ovs-ofctl add-flow br0 in_port=8, dl_src=52:54:00:f4:c7:47, arp,
  nw_src=10.0.140.1, actions=normal
% ovs-ofctl add-flow br0 in_port=8, dl_src=52:54:00:f4:c7:47, udp,
  nw_src=0.0.0.0, tp_src=68, nw_dst=255.255.255.255,
  tp_dst=67, actions=normal
```

# 帯域制限

- とっても簡単
  - 10Mbpsの例

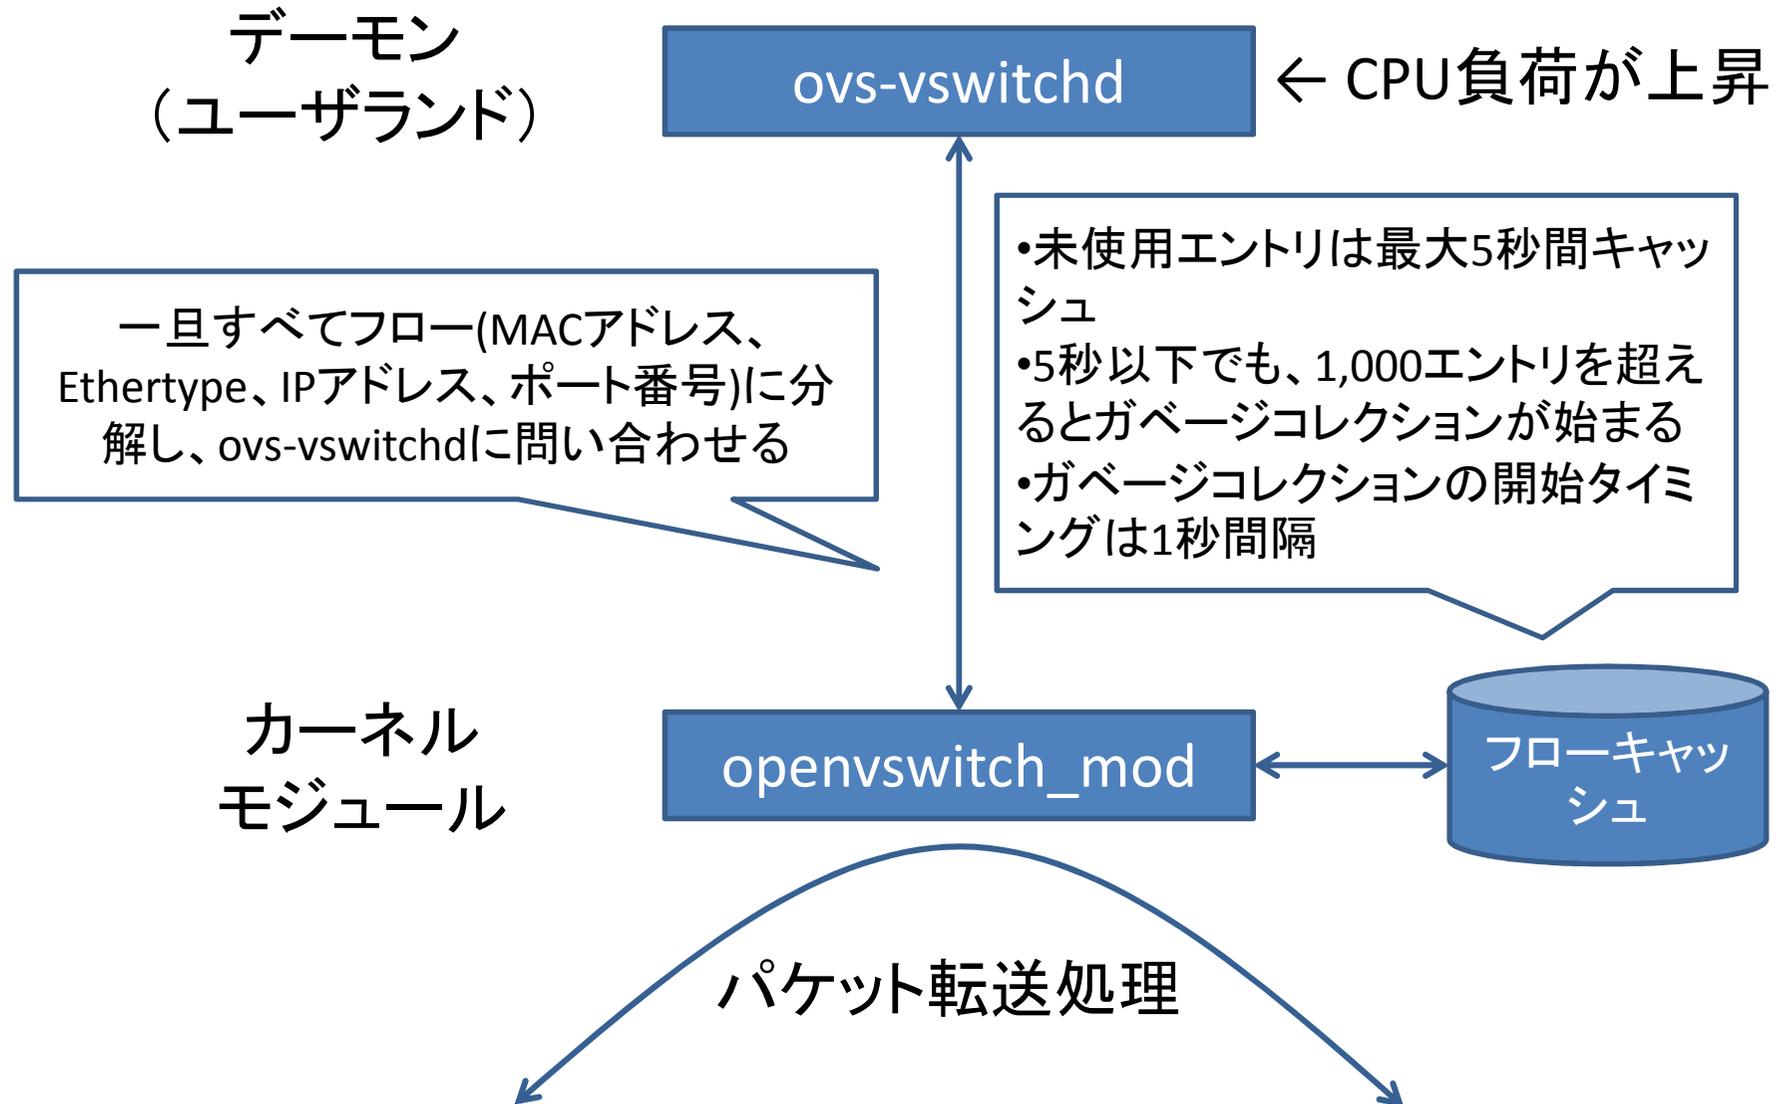
```
% ovs-vsctl set Interface tap2 ingress_policing_rate=10000
```

# 運用中に発生した問題

- Open vSwitchは、フローベース(Open Flow)のアーキテクチャ
- DoSアタックなど、大量のフローが発生すると、転送性能が極端に低下する
- 同一ホストの別のお客様のVMに影響が及ぶ
- フローキャッシュを見る方法

```
% ovs-dpctl dump-flows br0
in_port(2), eth(src=52:54:00:15:3e:a3, dst=52:54:00:b3:d4:57), eth_type(
0x0800), ipv4(src=220.205.27.17, dst=61.12.213.224, proto=17, tos=0), udp(
src=49766, dst=19968), packets:0, bytes:0, used:never, actions:1
in_port(2), eth(src=52:54:00:15:3e:a3, dst=52:54:00:b3:d4:57), eth_type(
0x0800), ipv4(src=200.254.249.181, dst=14.232.213.232, proto=17, tos=0), u
dp(src=54759, dst=10904), packets:0, bytes:0, used:never, actions:1
```

# Open vSwitchのアーキテクチャ



# とりあえずの対策

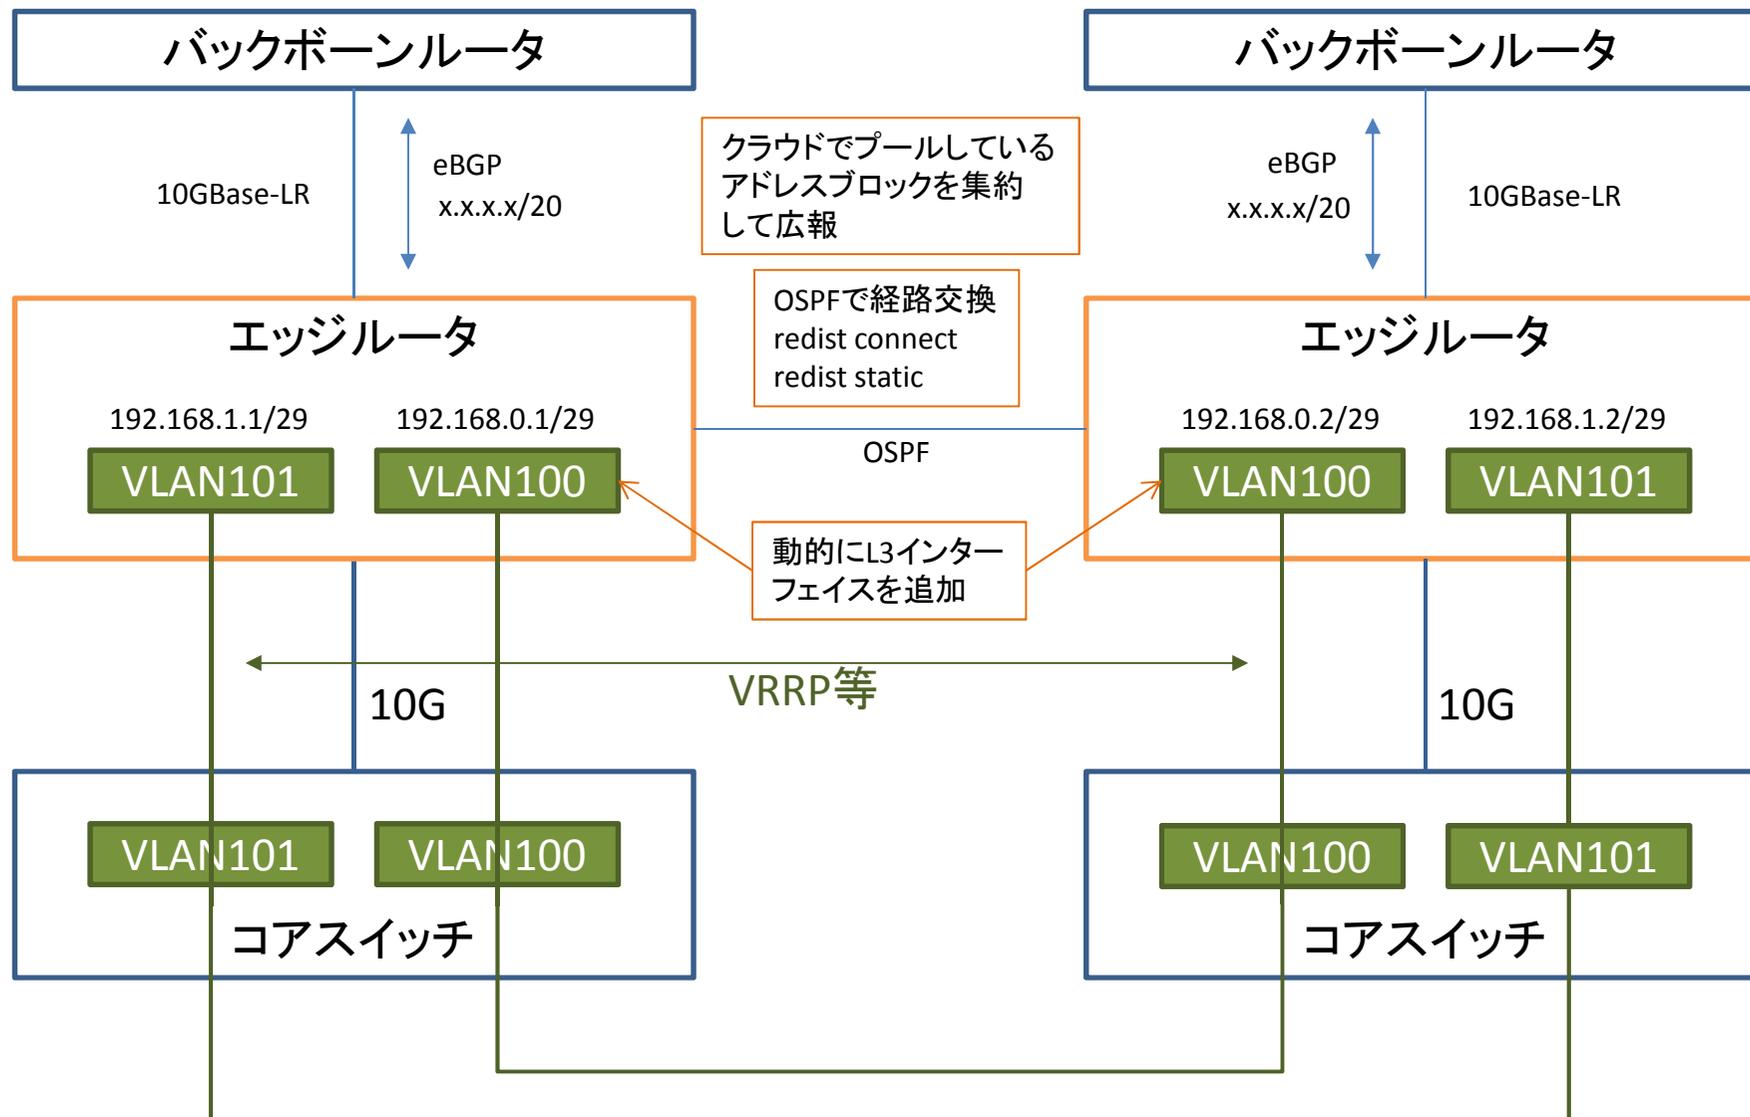
- Open vSwitch 1.1.0から1.2.1にバージョンアップ
- フローのセットアップ性能が50倍に  
(約800flows/sec → 約40,000flows/sec)
- バージョンアップに伴い、ガベージコレクション開始の閾値を変更可能に
- dp内フロー数の最大値が131,072なので、120,000に設定

```
% ovs-vsctl set bridge br0 other_config=flow-eviction-threshold=120000
```

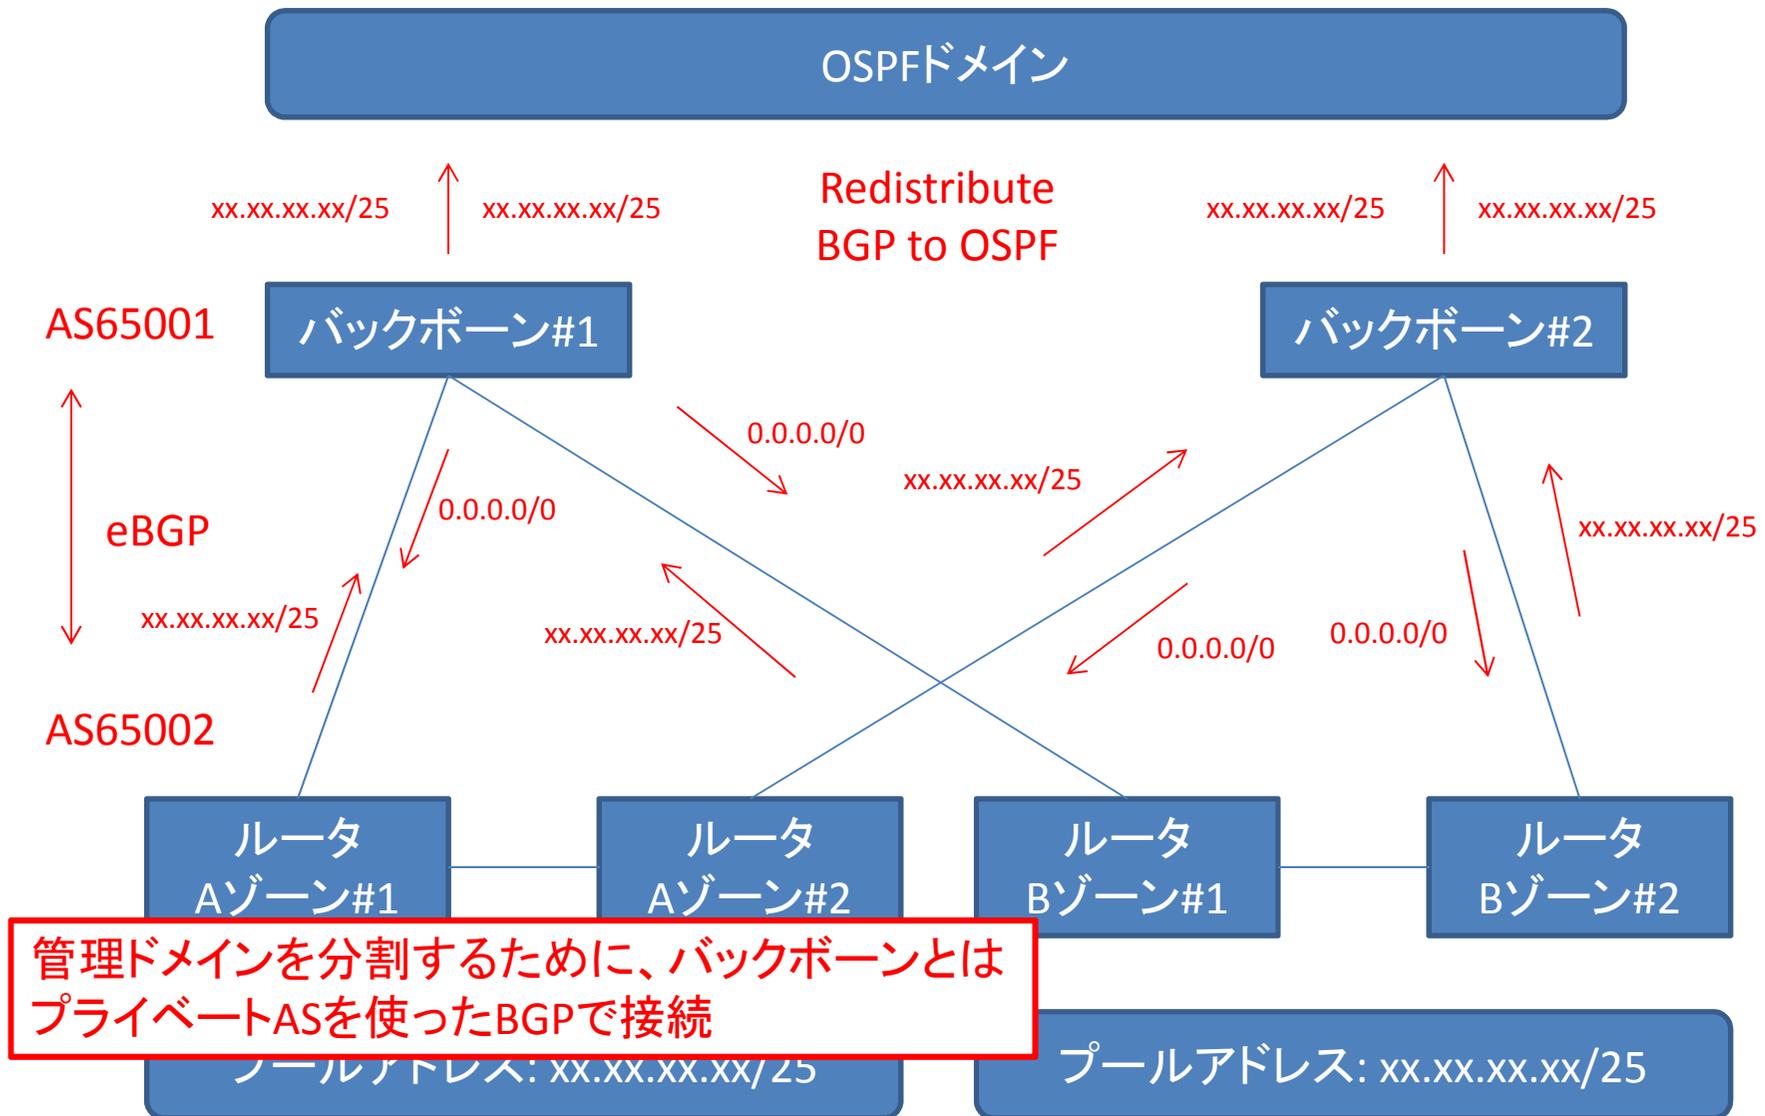
# 今後検討中の対策

- かなり緩和したが、根本的な解決策ではない。
- Open vSwitchがフローベースのアーキテクチャである以上、根本的な解決は難しそう。
- 定期的に仮想ポート毎のフロー数をモニタし、異常なフロー数が観測された場合、帯域制限を自動的に実施する機構の実装を検討。
- Open vSwitchにて、仮想ポート毎のフロー数制限を設定できるようになると吉か。

# インターネット接続構成



# ルーティング構成



# ルータの要件

- クラウドに配置した仮想サーバを、インターネットやVPN等の外部ネットワークと接続する。
- VLAN数: 500以上
- VRRPインスタンス数: 500以上
  - VRRP以外のプロトコルも可
- MACアドレス数: 8,000以上
- ARPエントリ数: 4,000以上
- プロトコル: OSPF、BGP

# 検証時に発生した問題

- VRRPインスタンスを大量に作成するとフラップ
- ルータ宛てDoSに弱い
- ARPのエントリを大量に持つと重くなる

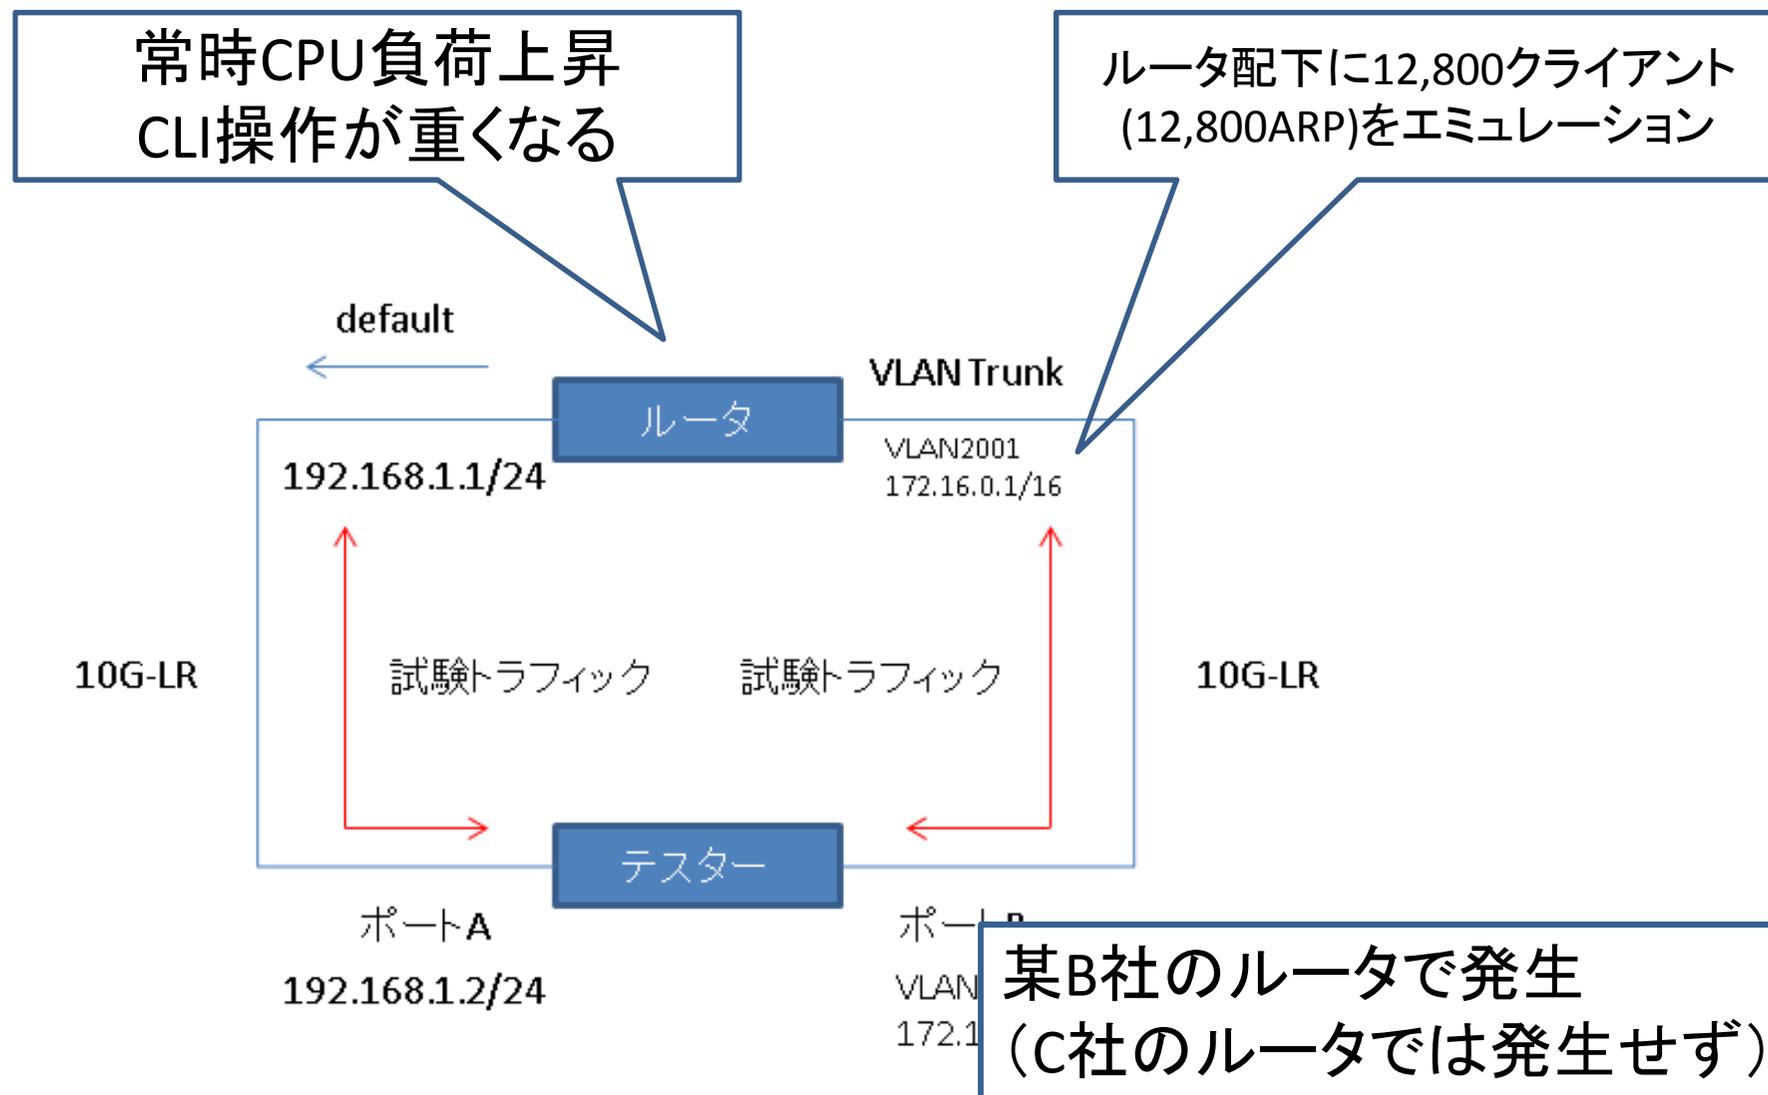
# VRRPインスタンスがフラップ

- 某B社のルータで発生（C社のルータでは発生せず）
- 2,000VLANにIPアドレスを設定し、VRRPを構成
- → 毎秒 2,000パケットのVRRP Hello（マルチキャスト）
- バックアップ側で受け取れずに、Masterに昇格するVLANが続出
- Helloのインターバルを伸ばすことで解決（5秒/15秒など）

# ルータ宛てDoS攻撃に弱い

- 某B社のルータで発生（C社のルータでは発生せず）
- TCP 23番ポート、ルータ宛てのパケットを10G  
ショートパケット、ワイヤレートで送出
- ルータの操作ができなくなった(CLIが固まる)。
- ACLの設定で回避可能

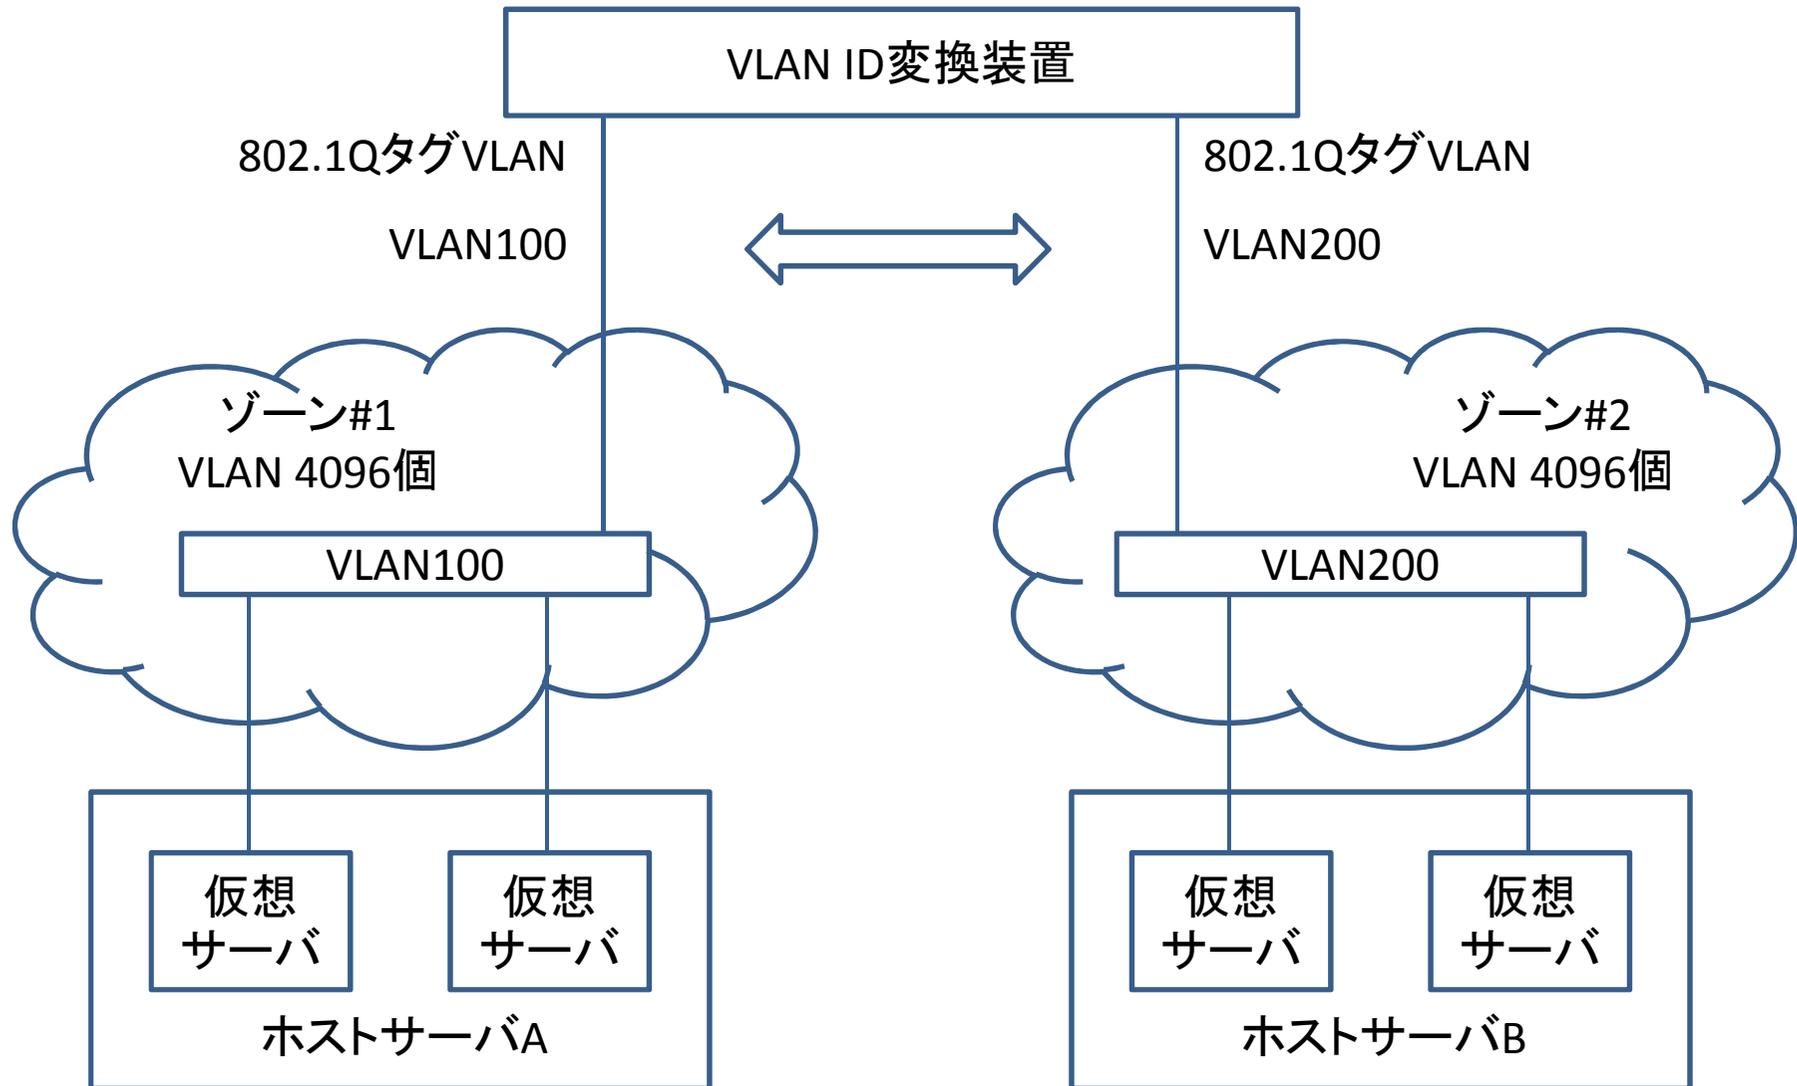
# 大量のARPエントリで重くなる



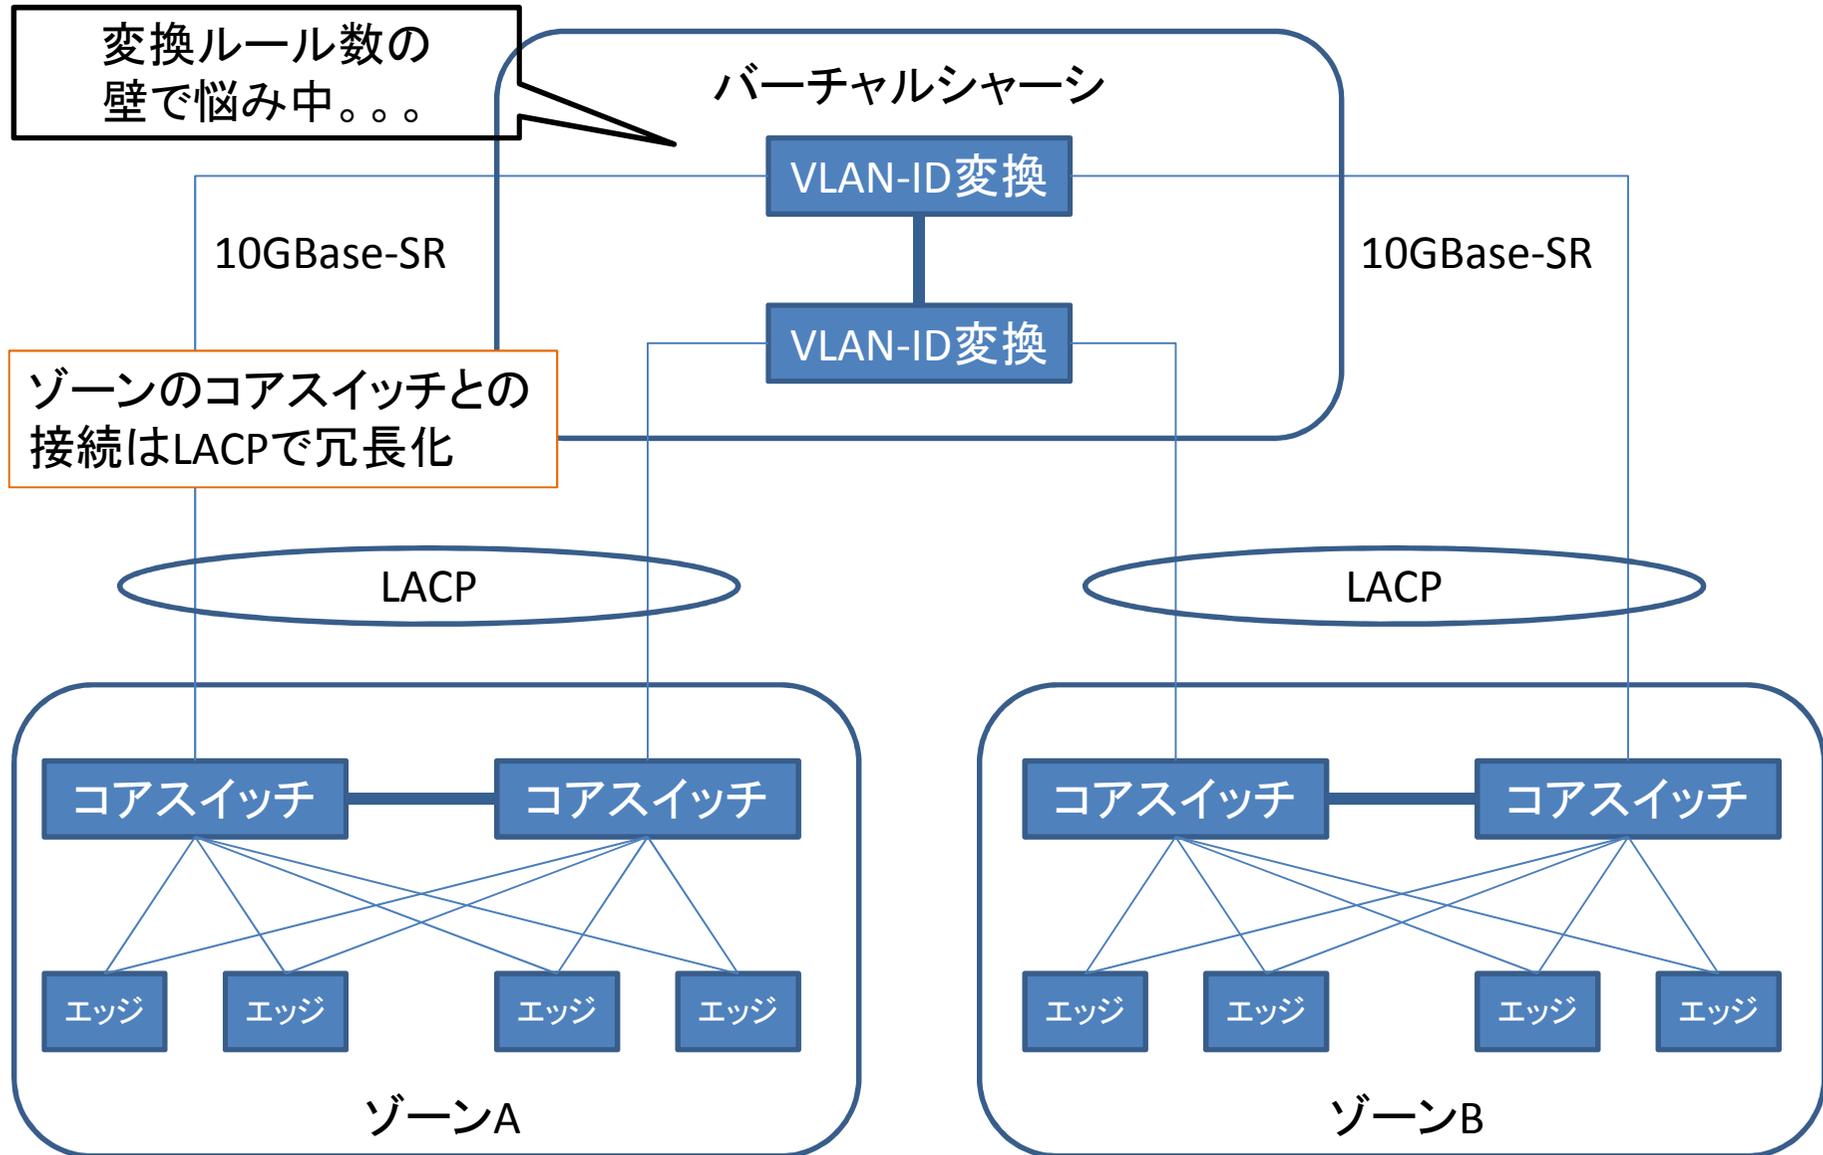
# VLAN ID数制限の克服

- 802.1QタグVLANのVLAN IDは12bit(4096)
- 1ゾーンあたり最大4,096VLANしか使用できない(実際はもっと少ない)。
- VLANが不足したら、別のゾーンを作成(ルータ、コアスイッチを新設)
- 別ゾーンに収容されたお客様が相互接続したい場合はどうするか？
- ゾーン間のL2接続を行う「ブリッジ」機能を実装

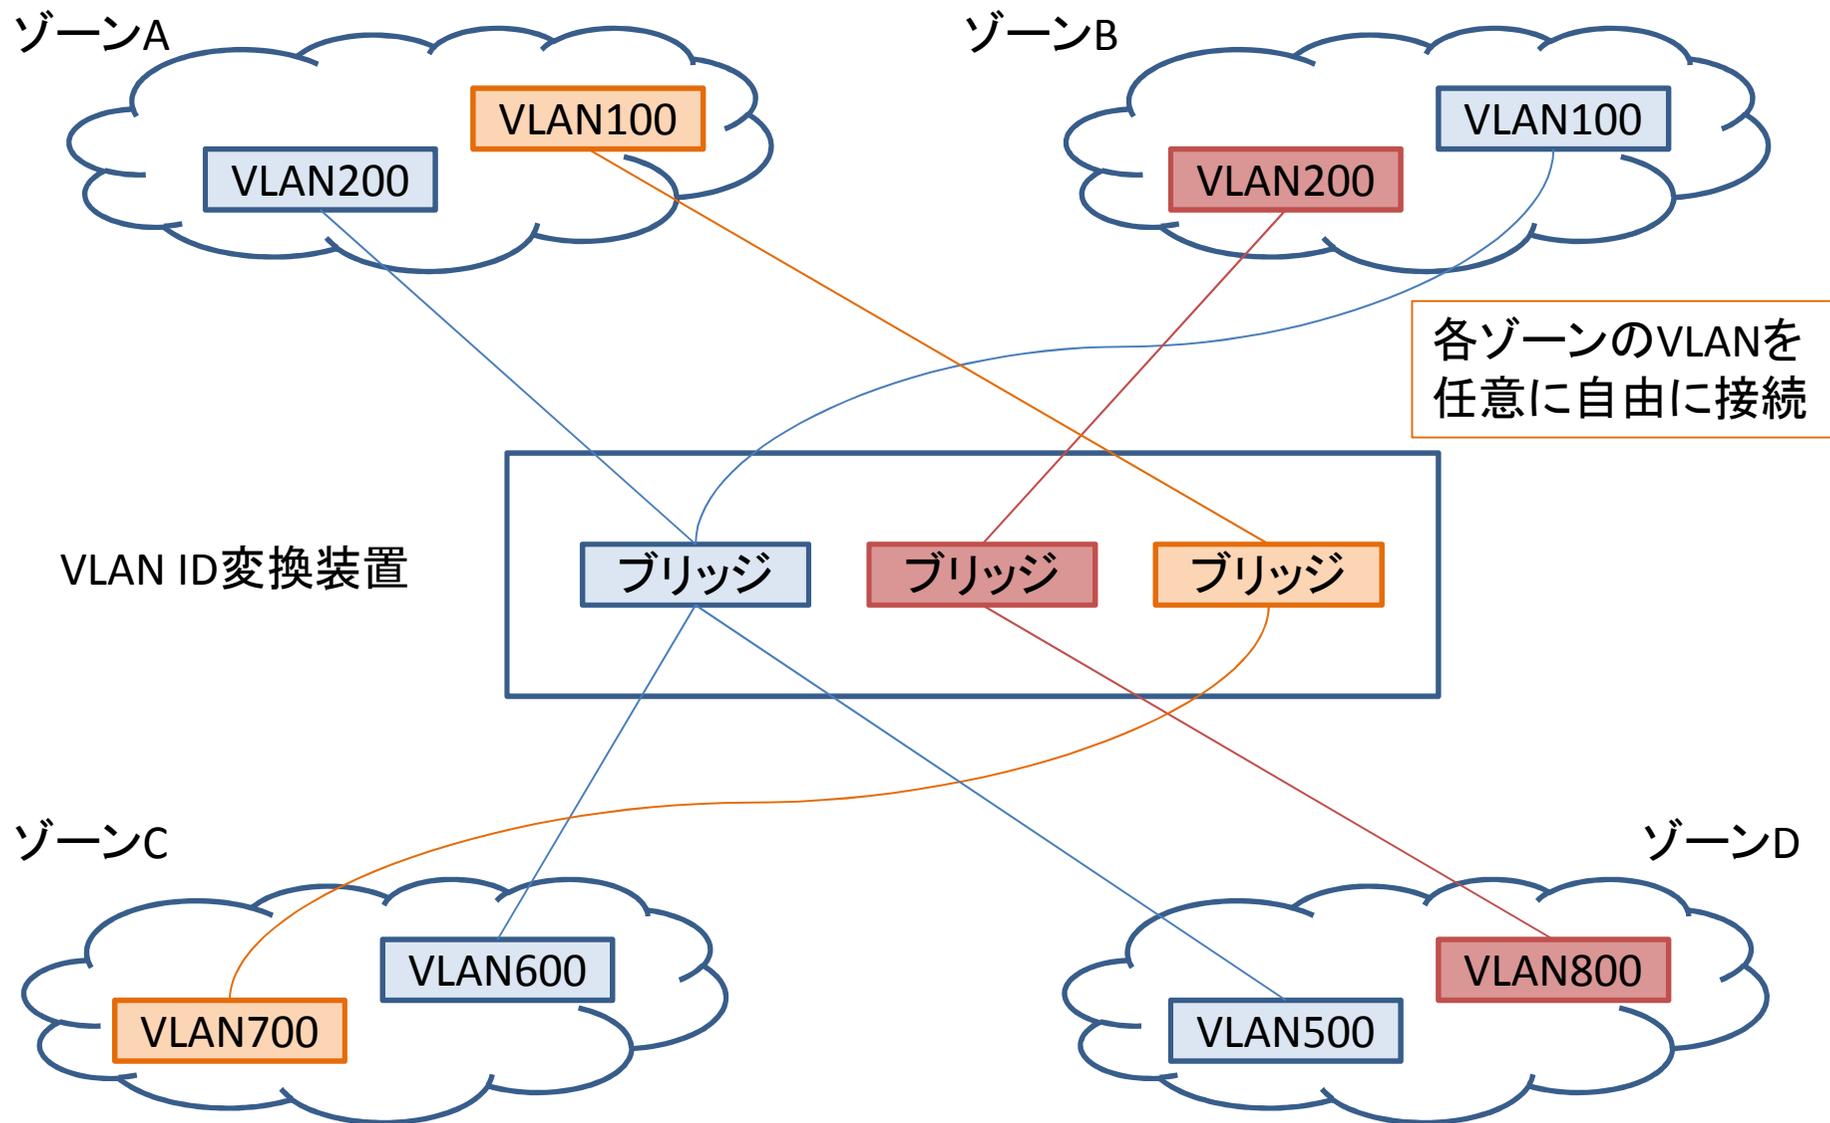
# ブリッジのイメージ



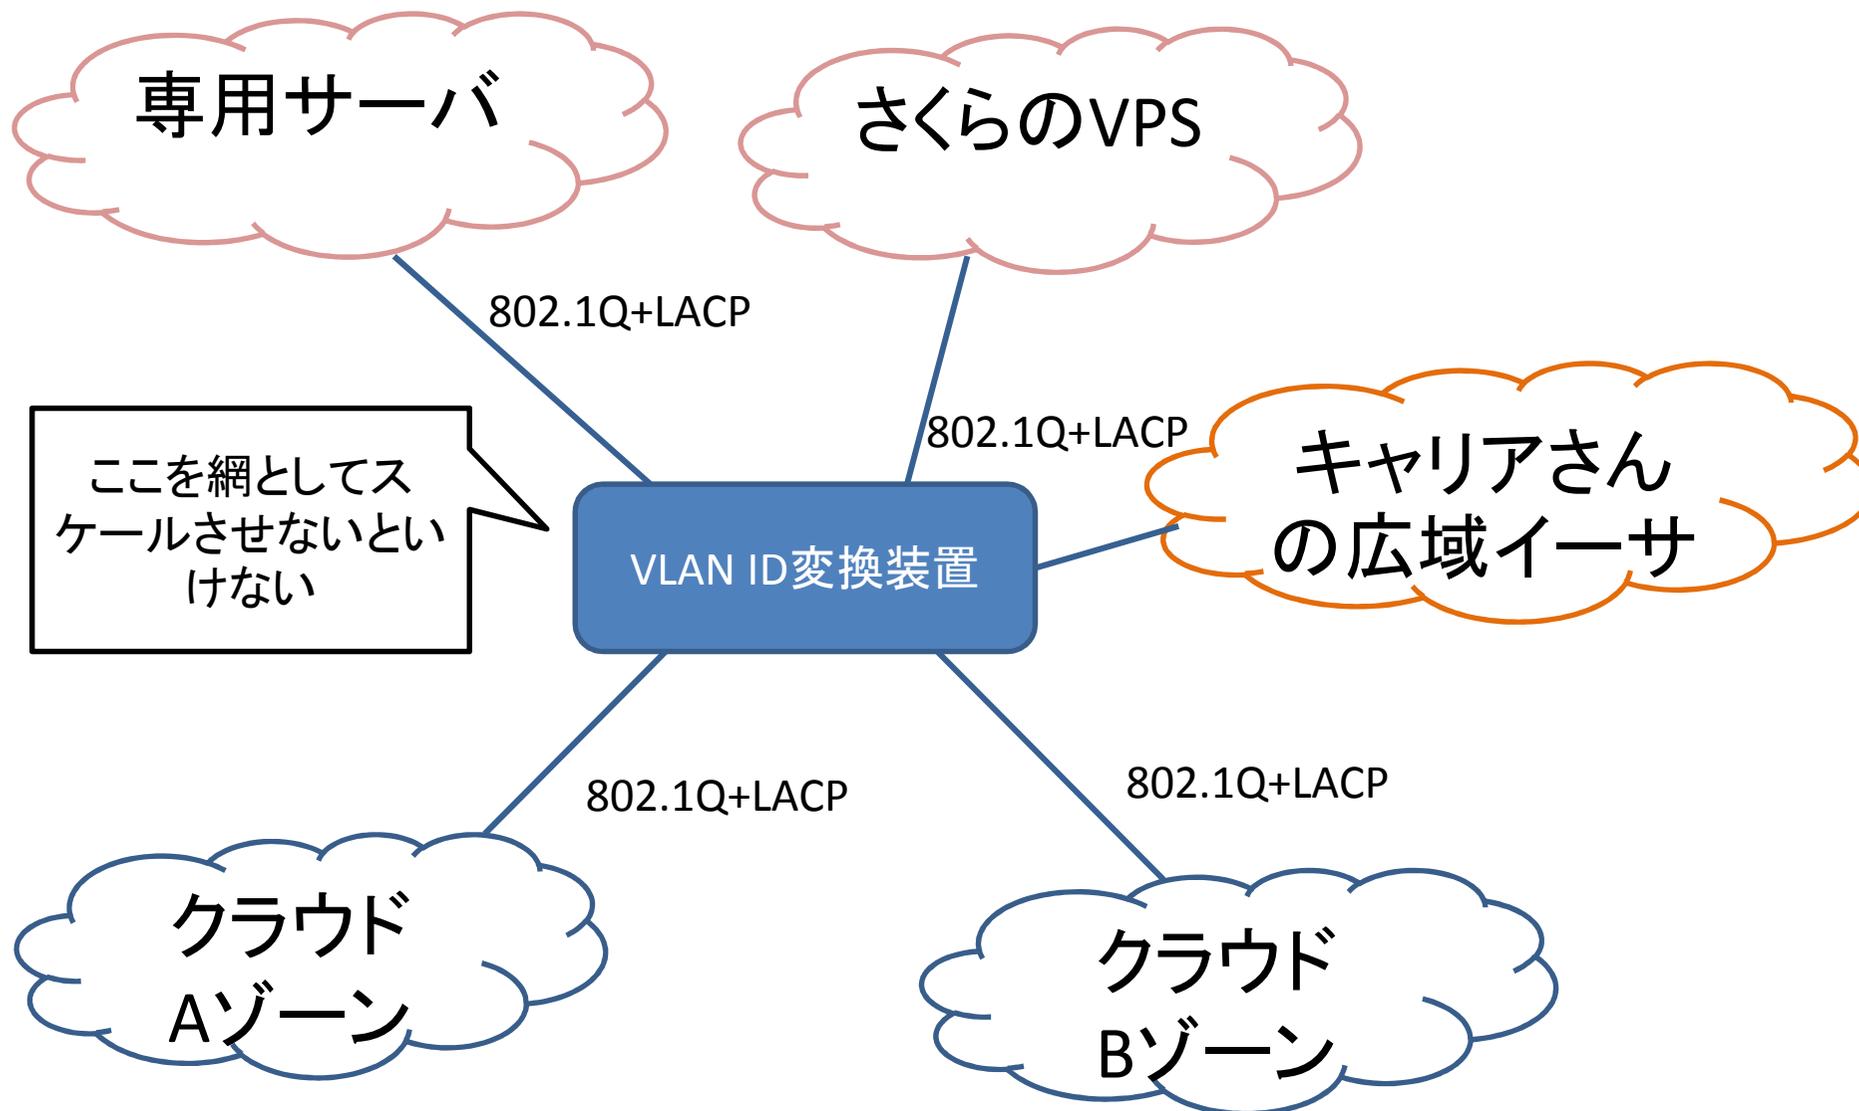
# 現在の構成



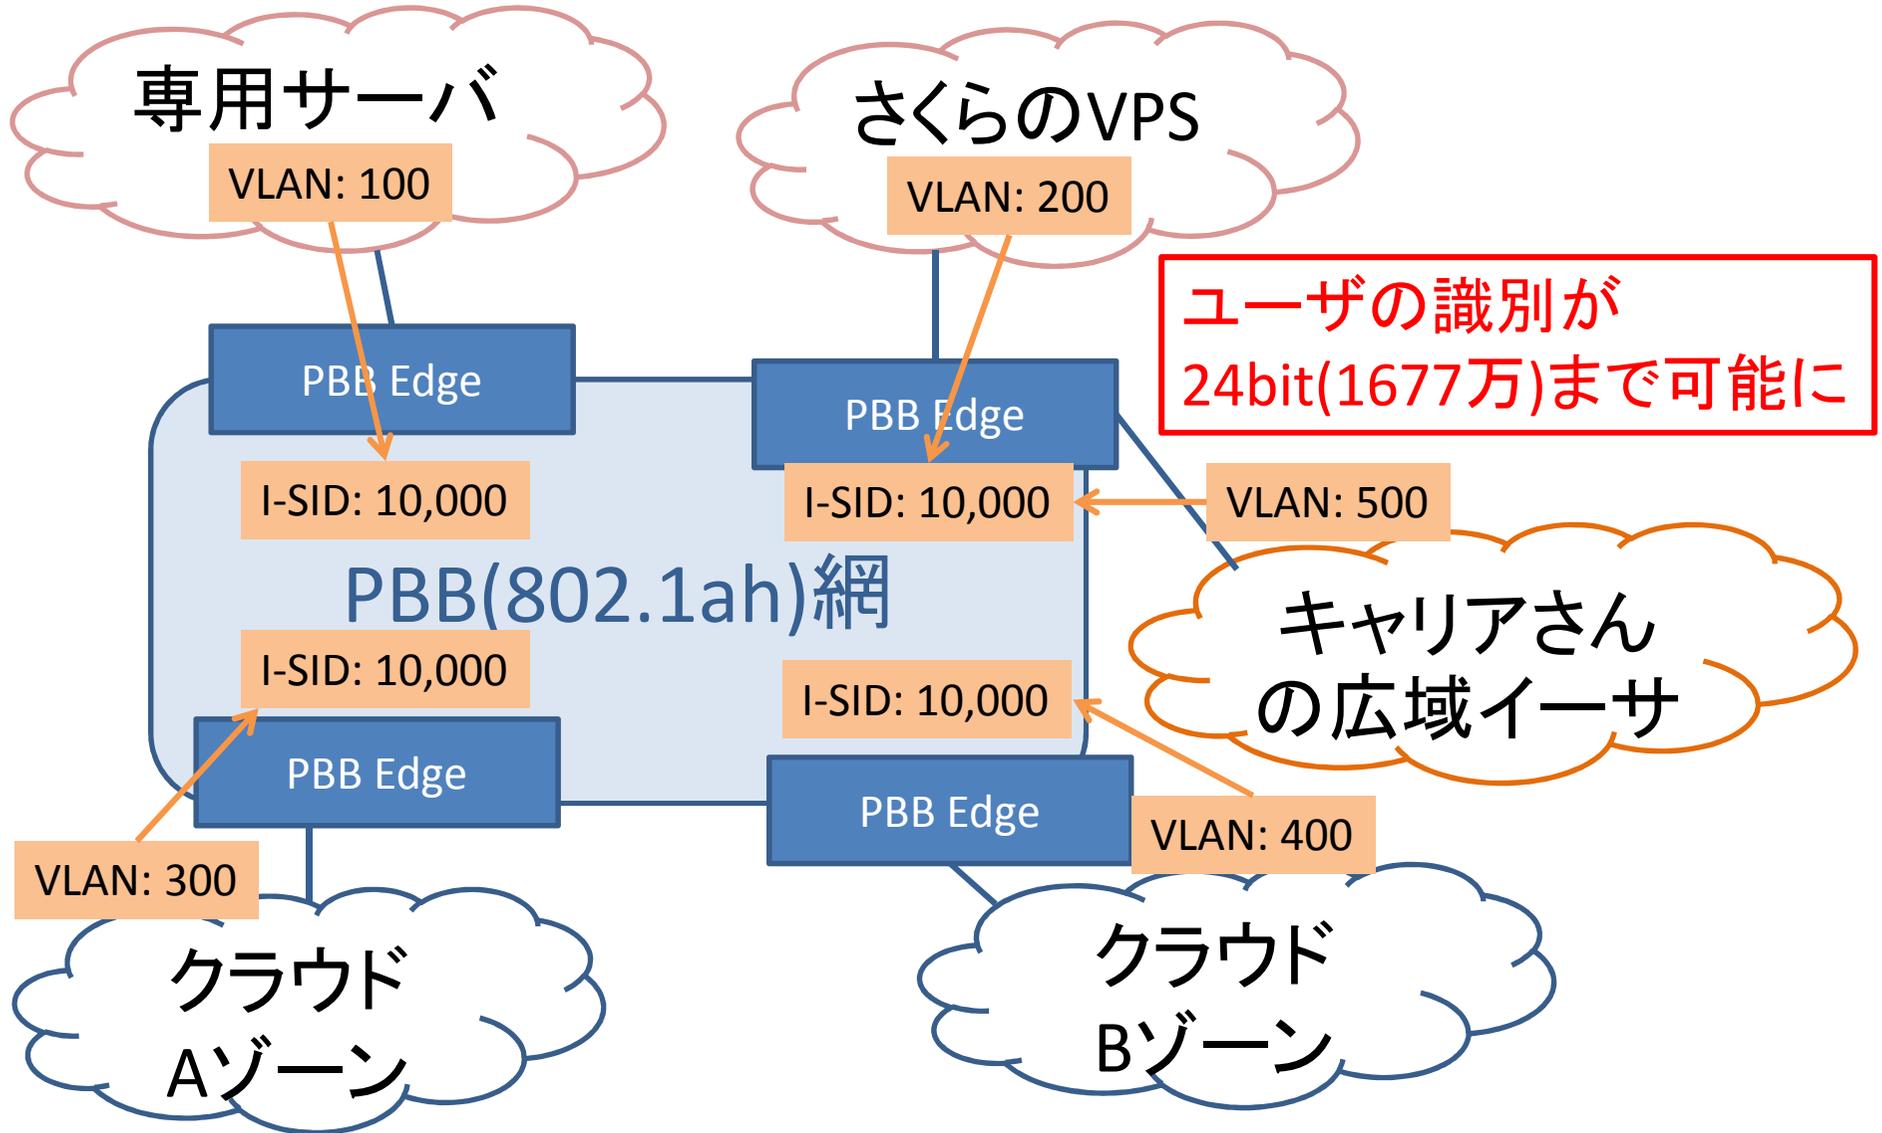
# マルチポイントでの相互接続



# 将来的には・・・



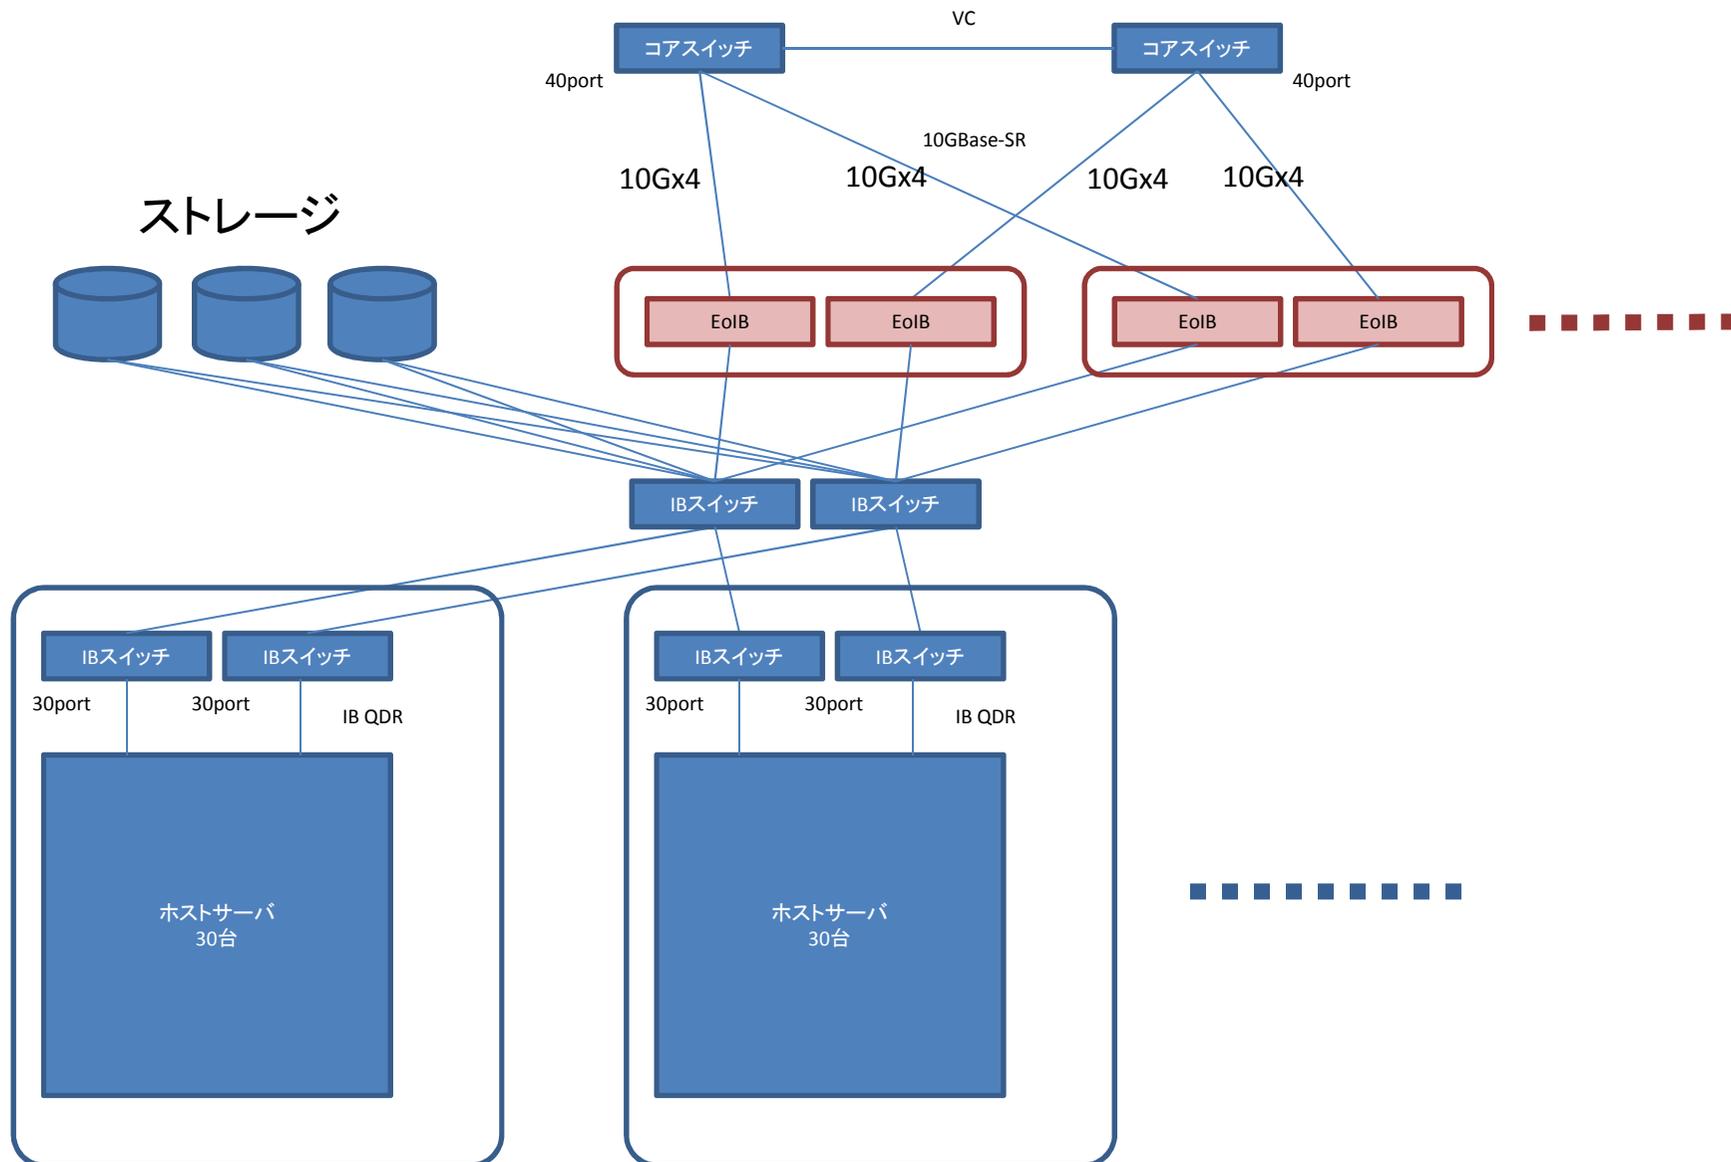
# PBBとか、EoEとか



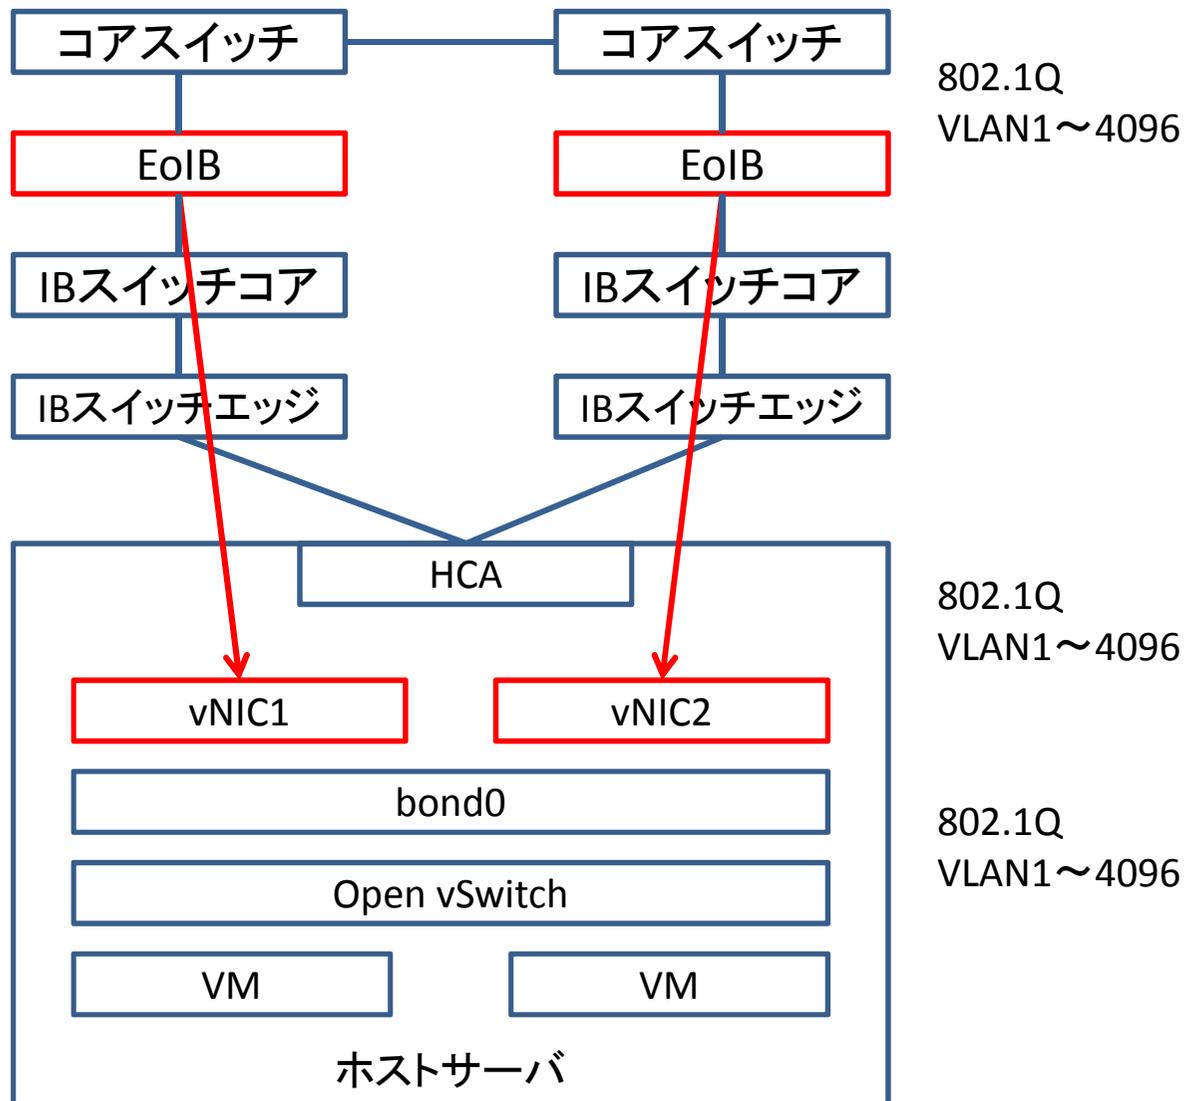
# 今後のネットワークプラン

- Ether over InfiniBand(石狩から導入)
  - 配線数の削減
  - コストそのまま、帯域増加
- 完全トンネル方式(2～3年後?)
  - VM間のL2通信を、ホストサーバにてIPTunnel
  - バックボーンをL3で組める
  - スケールする構成に

# Ether over InfiniBand



# ホスト内の構成



# 完全トンネル方式

- Open vSwitch
  - GREでEtherをIPで飛ばす機能が載っている
  - 某社が頑張っているらしい……
- 富士通研究所さんの事例
  - <http://www.ieice.org/ken/paper/20100805B000/>
  - Linux GRE-TAPを使った方式
- 新しいプロトコル仕様(IETFに提案されている)
  - <http://tools.ietf.org/html/draft-sridharan-virtualization-nvgre-00>
  - <http://tools.ietf.org/html/draft-mahalingam-dutt-dcops-vxlan-00>
  - どちらも、ユーザの識別は24bit、IP上にオーバレイする

Etherのスイッチを使わずに、Etherのネットワークが組めるようになる時代が来る！

# おまけ：仮想アプライアンス

- 単純なネットワーク到達性だけでは機能不足。
- 従来のハードウェアアプライアンスにかわるものを、クラウドで提供する。

種別	ソフトウェア
仮想ルータ	Vyatta SEIL/x86(実装中)
仮想ファイアウォール	pfSense その他実装中
仮想ロードバランサ	実装中
仮想ファイルサーバ	実装中

# まとめ

- クラウドのネットワークはL2との戦い
  - L2到達性が必要で、L3到達性ではダメだと認識
  - MACアドレス、VLAN数、スケーラビリティ
- 今後、どちらかの方向に進まないといけない
  - L2機器でがんばる
  - ホストサーバでトンネルする
- 他サービスとの相互接続も検討中
- さくらのクラウドでは、既存の全物理サービスの置き換えを目指したい
- 仮想アプライアンスの充実、QoSの強化を目指す