情報ネットワーク特論
ネットワークスイッチの構成と動作

名古屋大学 情報基盤センター
情報基盤ネットワーク研究部門
嶋田 創

L2における通信

- MACアドレスで宛先を決定
- IPアドレスからMACアドレスへの変換 →送信者がARPで解決
  - 宛先IPアドレス入りARP reqを送り、当該IPアドレスのホストがARP reply
- 宛先MACアドレスが当該L2スイッチの下に無い →ブロードキャスト

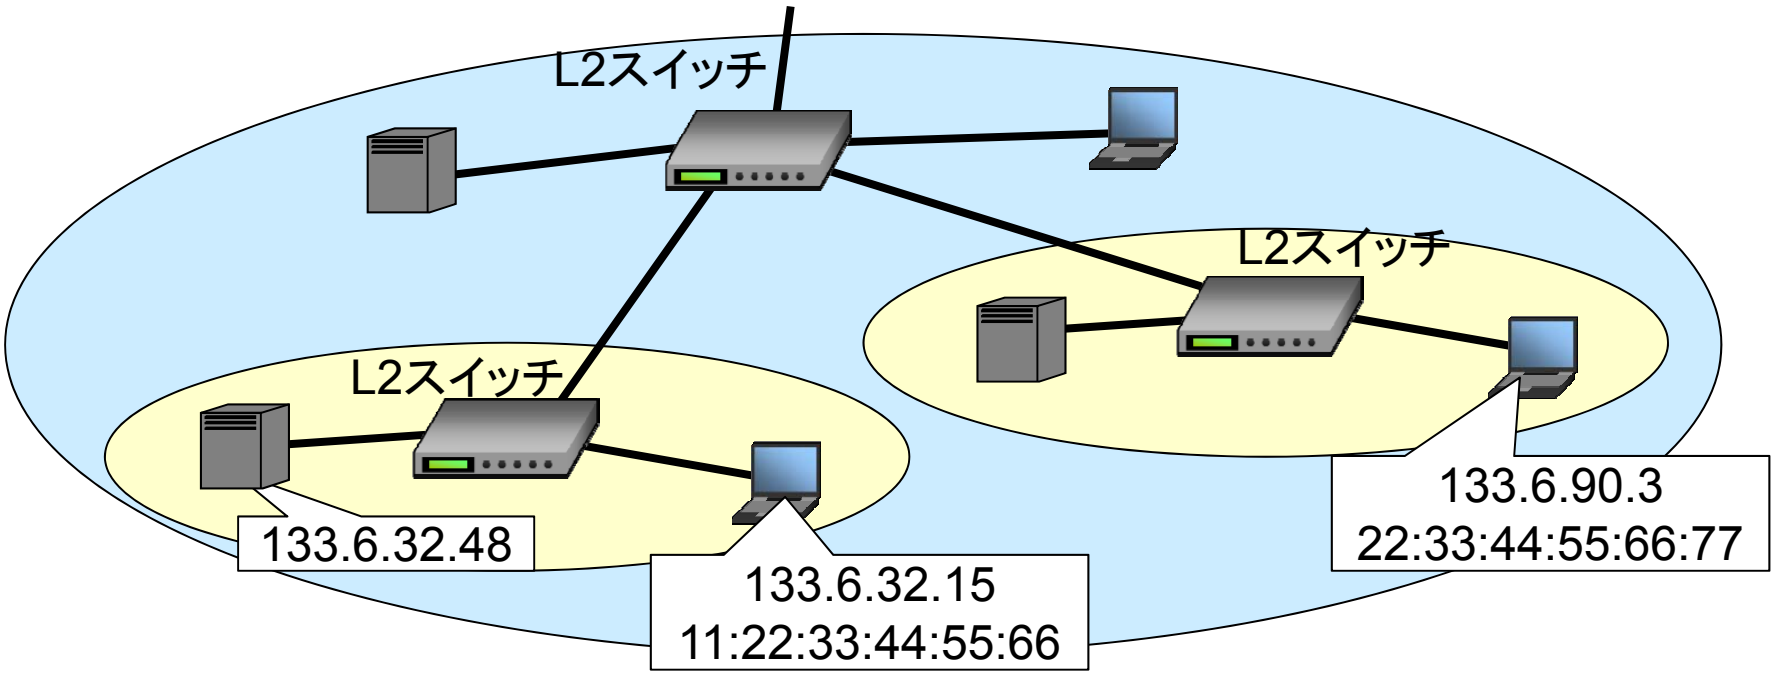

L3における通信

- 宛先IPアドレスを見て送信先を判別
  - L2のブロードキャストはL3スイッチで止まる
- 静的ルーティングや動的ルーティングで設定
  - 動的ルーティング: 各経路の距離や容量の情報をもとに経路選択

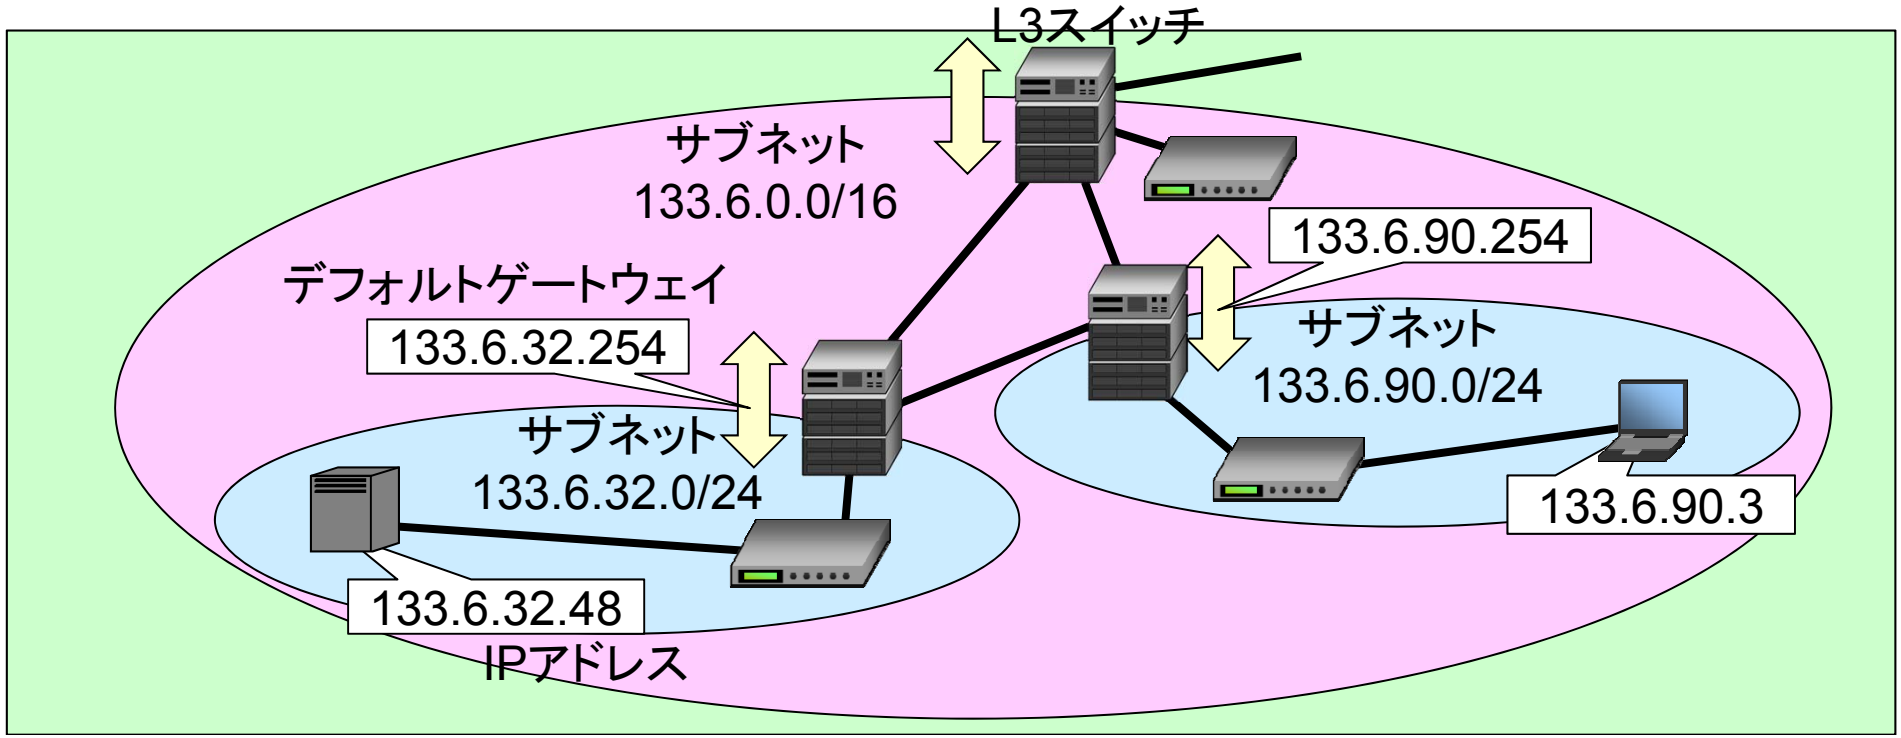

現実的なL3による通信

- L3スイッチは高価なので、各サブネット出口に1つは置けない

  →1つのL3スイッチが複数のサブネット(VLANなど)を管理
  - コアルータとか呼ばれたりする

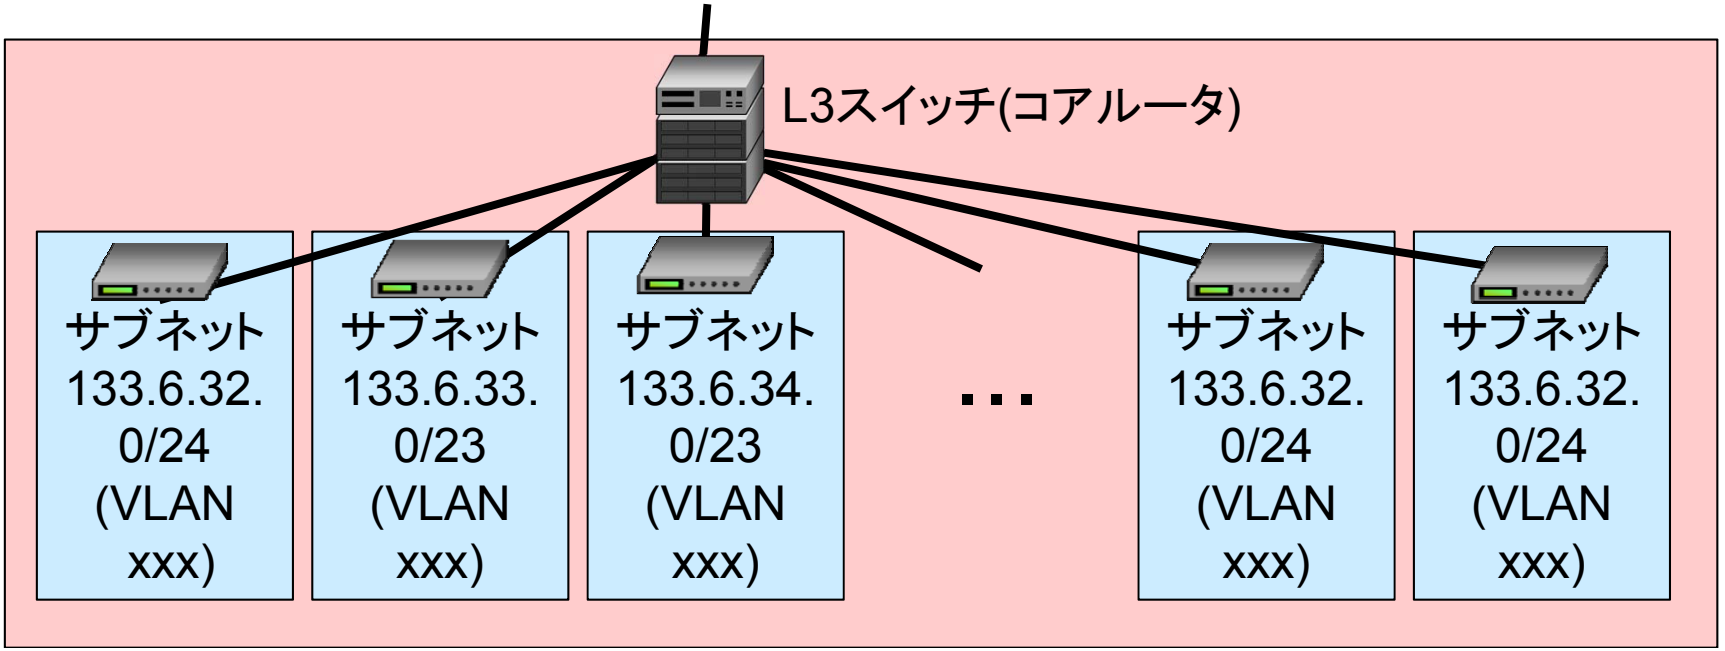

NICEにおけるルーティング

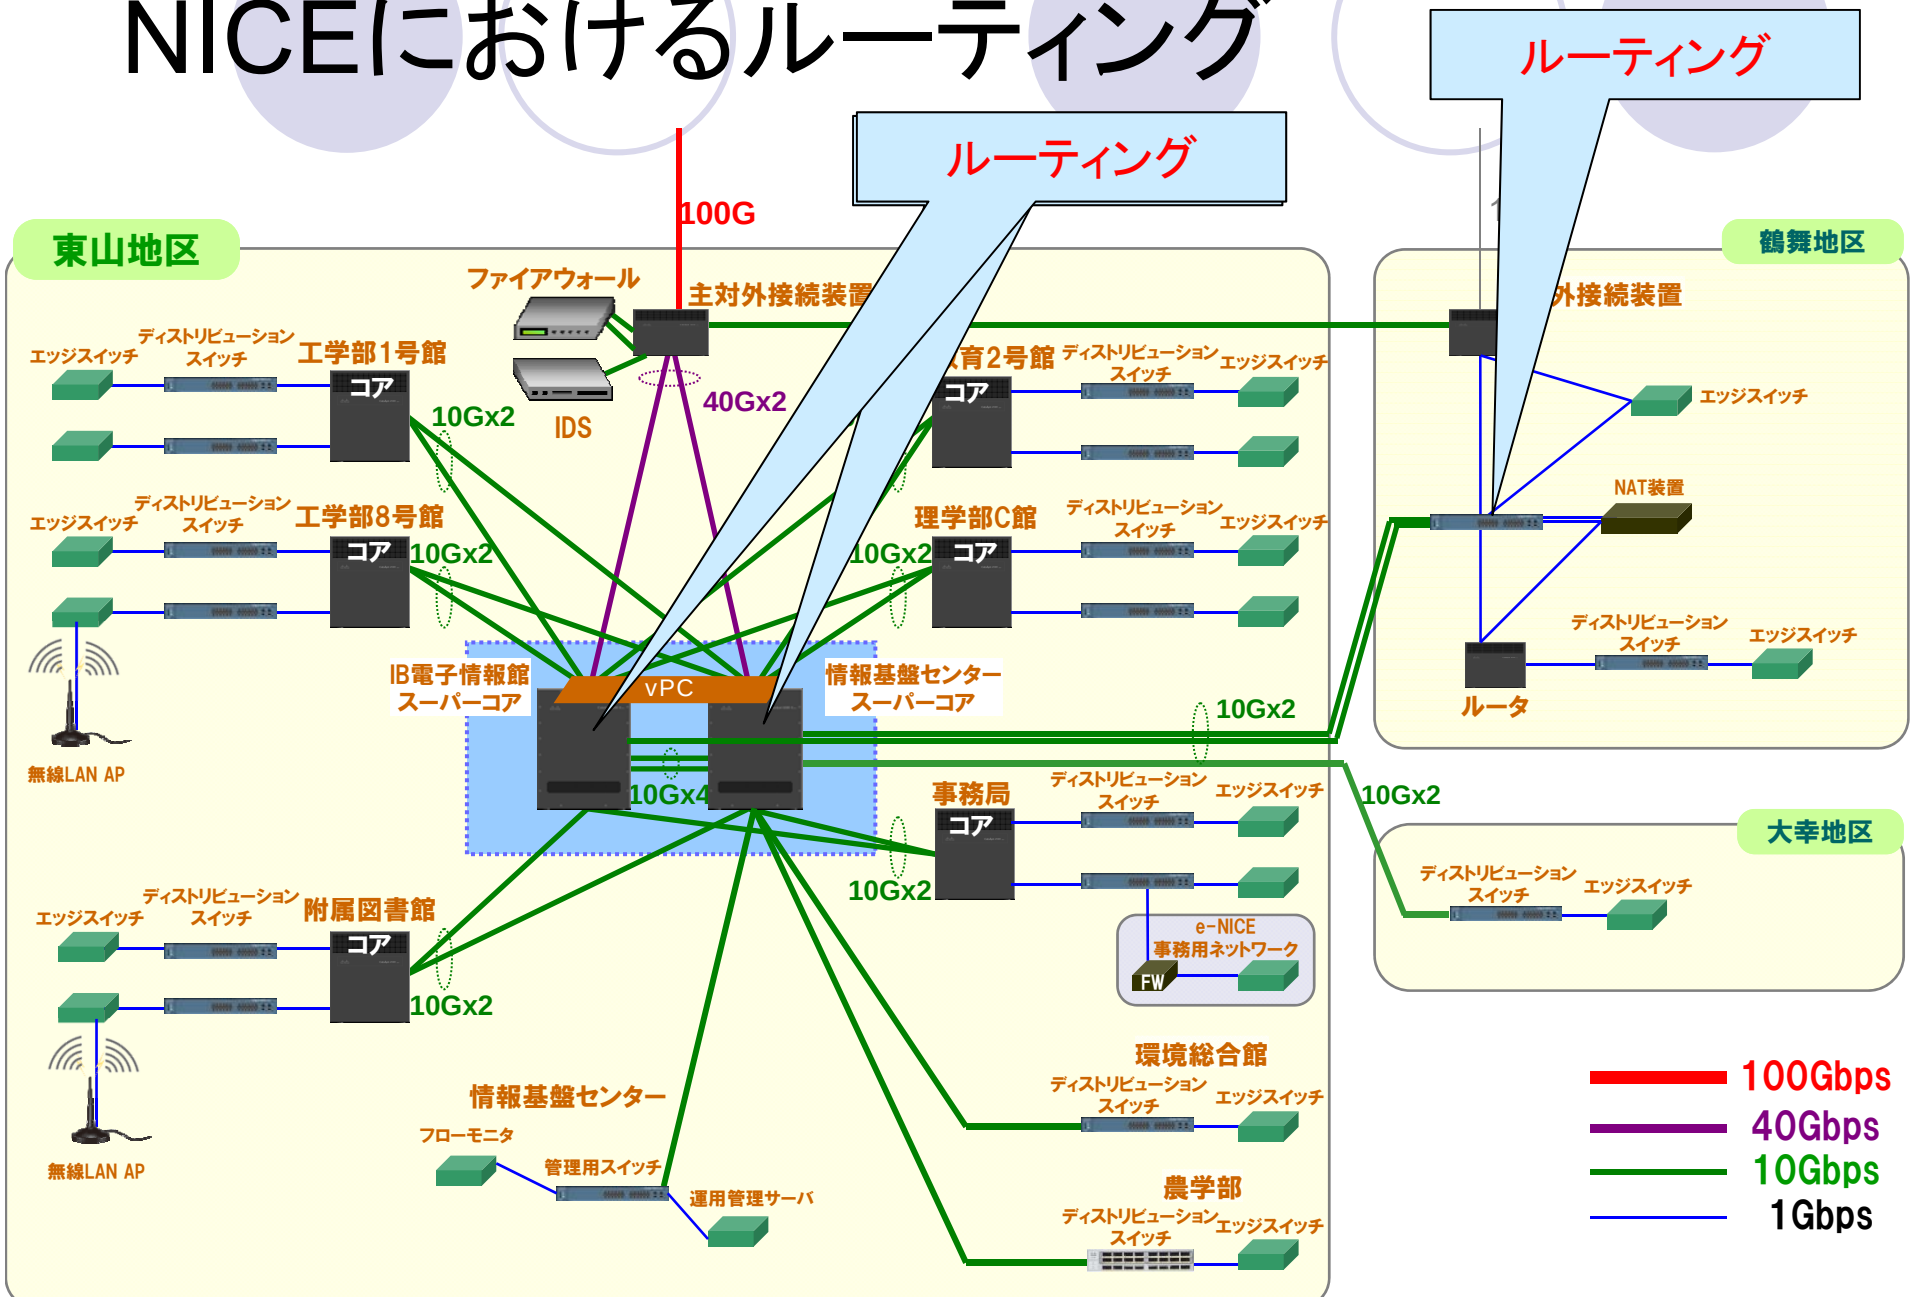

低価格L2スイッチの構成

- NICのMACの先がスイッチコントローラに変わったものと考えれば良い
- 注: スイッチングハブの構成です

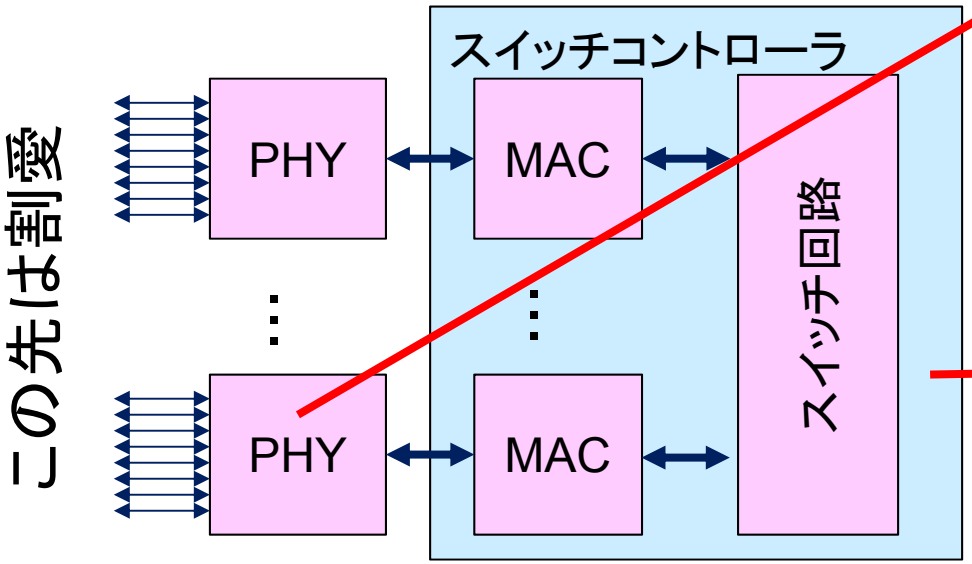

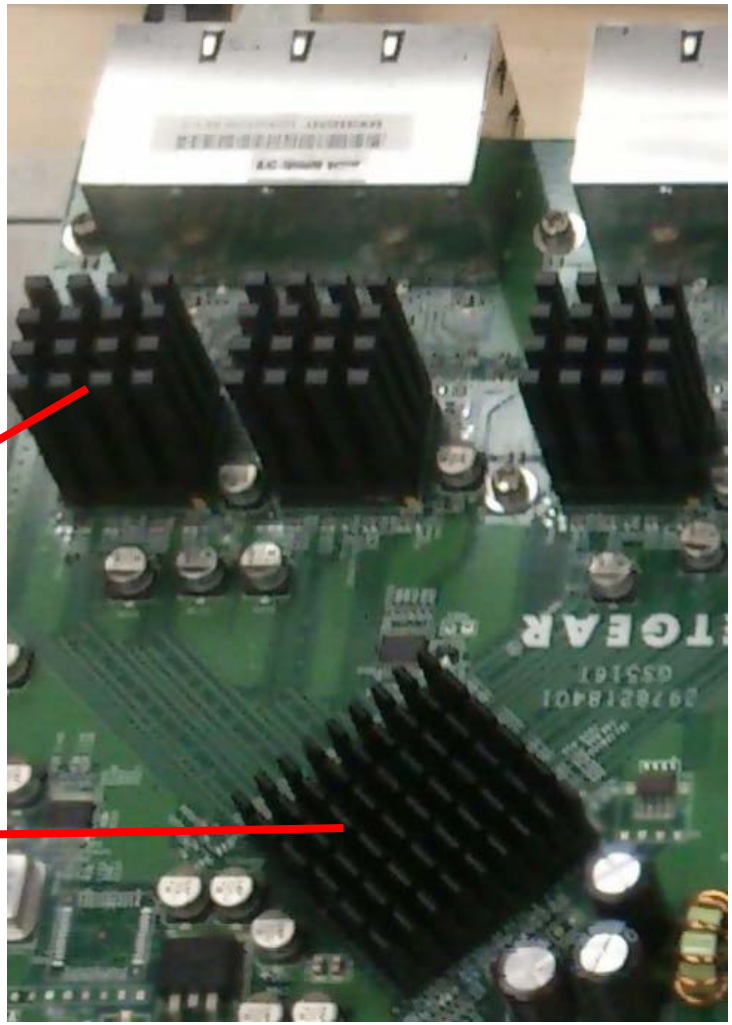

スイッチコントローラの動作(1/2)

1. MACがフレームを受信バッファに格納
2. 受信バッファ中のフレームのMACアドレスでMACアドレステーブルを検索
   - MACアドレステーブルは、どこのポートからどこのMACアドレスの通信がきたかどうかを保存
   - 一致があれば、そのポートのみに送信
   - 一致が無ければ、全ポートへ送信(ブロードキャスト)

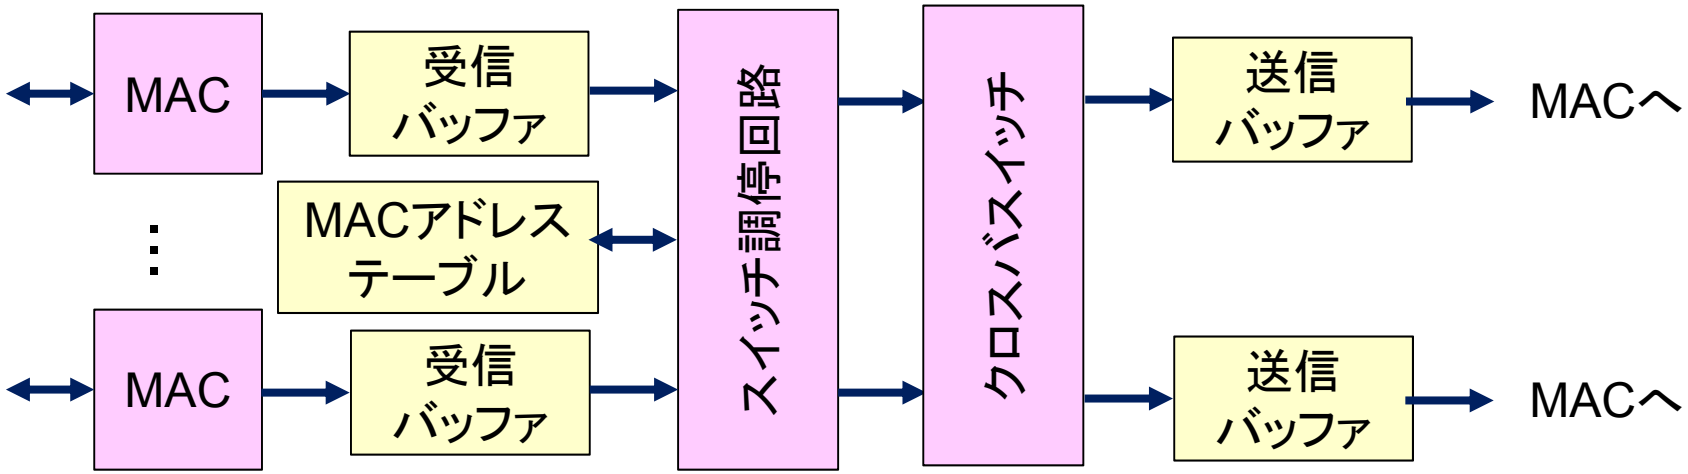

スイッチコントローラの動作(2/2)

3. 宛先ポートの送信バッファへのクロスバスイッチの調停ができたら送信
   - 宛先ポートの利用権はFIFOなどで制御
     - もちろん、ブロードキャストも

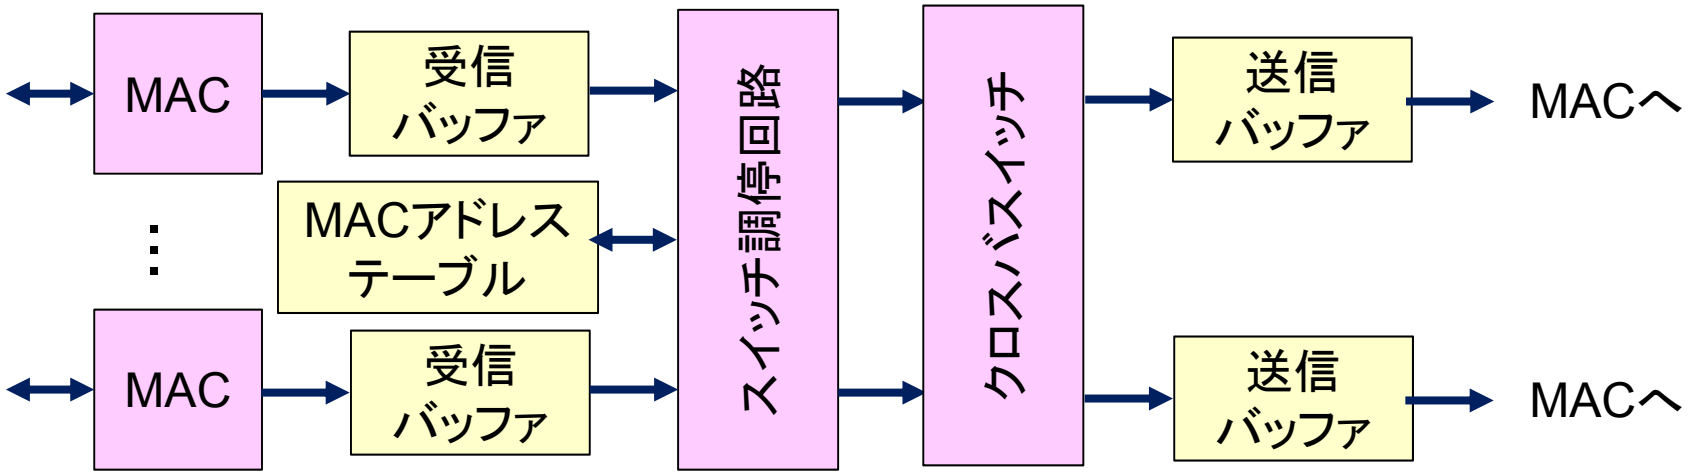

予定通りに行かない時のスイッチコントローラの動作

- MACアドレステーブルが溢れた
  - アップリンクポート側はそのうち溢れます
  - 古いものから削除
- 受信バッファが溢れた
  - パケットロスとして、パケットが再送信されて来るのを待ちます
    →効率が悪いのでフロー制御を
- フロー制御: パケットバッファが溢れるのを防ぐ制御
  - バッファが溢れそうになったら、フレームの送信を一時中止するように送信元に伝える
  - IEEE 802.3xによるフロー制御
    - 送信元に対してポーズフレームを送信し、受信側は送信を一旦停止
    - バッファが空いたらポーズ解除フレームを送信して通信を再開

スイッチコントローラに関する小ネタ

- いちいちパケットはバッファに保存する?
  →保存しないやり方(カットスルー)もある
  - フレームのMACアドレスを見て、クロスバスイッチの調停を先に済ませてしまう
  - ただし、フレームの途中でエラーが見つかると、調停は無駄になる

高機能なL2スイッチ

- スイッチの上でOSが入っていて色々と設定できる
- 基本的に設定できること
  - ポートごとの各種設定
  - L2でのアクセス制御(特定のMACアドレスを遮断、など)
  - 各種ログの読み出し/SNMPによる転送
- 最近ではもっと高機能なことができたりします
  - スイッチの各ポートに対して認証をかける
  - Power over Ethernetによる電力供給

Cisco Catalyst 2960X

一般的な大型スイッチの構成

- 小型L3スイッチもありますが、せっかくなので大きい物を
  - 小型L3スイッチ(ブロードバンドルーター)はL2スイッチ+組み込みプロセッサwith組み込みLinuxによるL3処理なので
- 通常はルーティングエンジンと複数のラインカードから構成される
  - ルーティングエンジンはテーブル生成部とクロスバスイッチから構成
  - ルーティングエンジンで生成した各種テーブルは各ラインカードにも送付
- L3ルーティングテーブルを持つ
  - CAMを用いるが、一部をマスク可能なTCAM(Ternary CAM)を利用
- もちろん、L2による通信機能も持つ
  - MACアドレステーブルなどのL2スイッチの機能もある

一般的な大型スイッチの構成

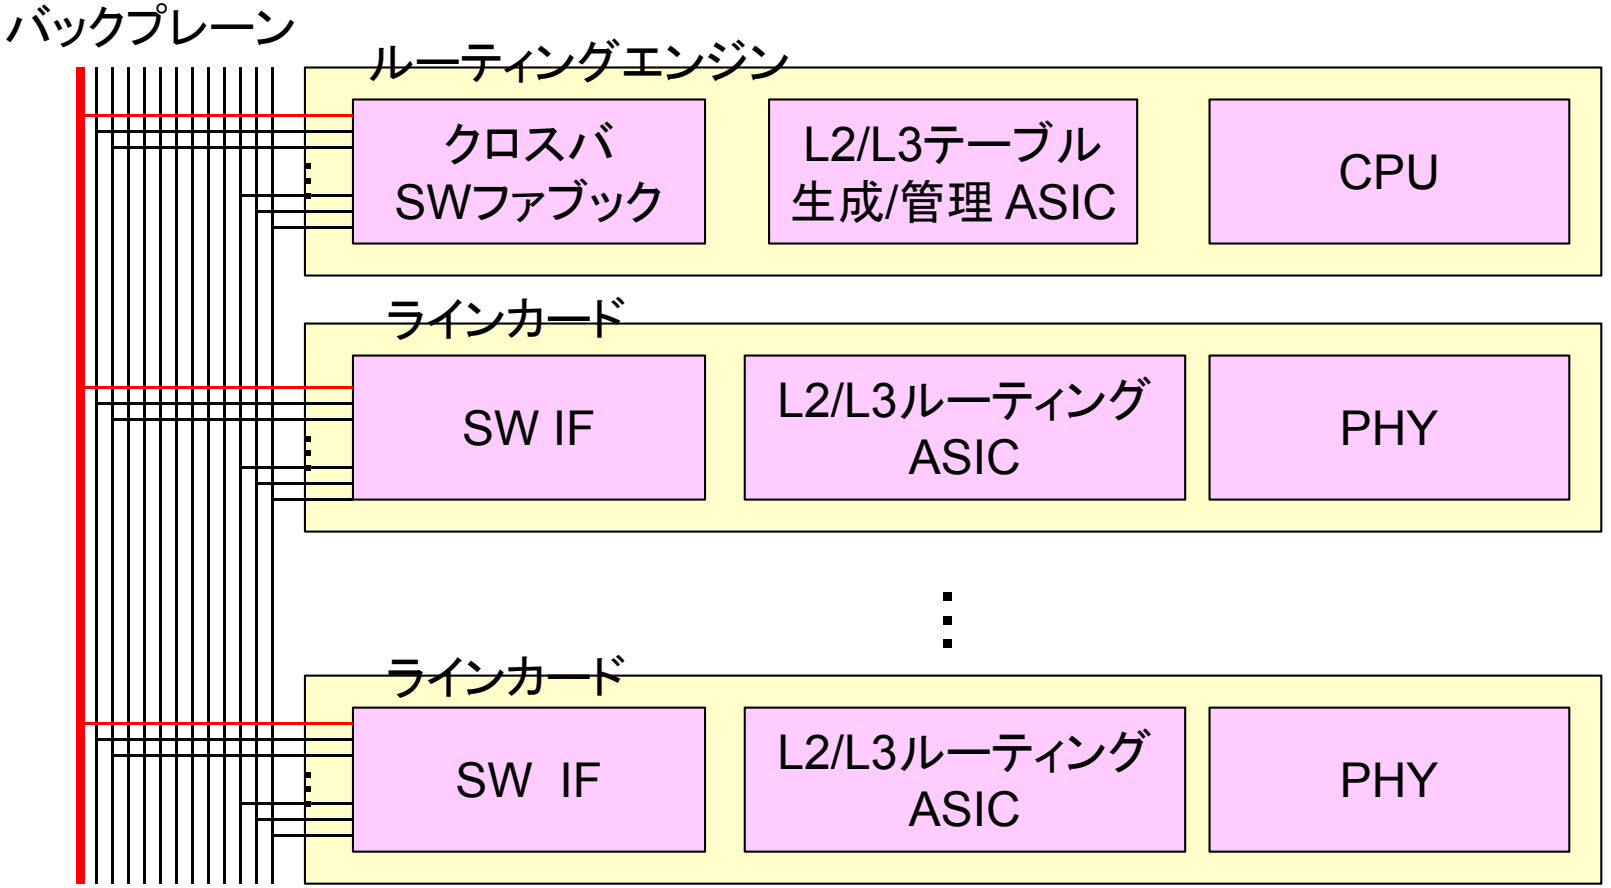

各部の処理(1/2)

- CPU
  - スイッチ全体の制御
  - ルーティングテーブル等の作成に必要な情報を管理
  - 管理用OSの実行
- L2/L3テーブル生成/管理ASIC
  - CPUからの指示を受けてL2/L3テーブル生成/管理
  - ルーティングエンジンで作成したテーブルのコピーを各ラインカードに保持
    - FIB(Forwarding Infomation Base)方式と呼ばれる
- バックプレーン
  - ルーティングエンジンやラインカード間を接続

各部の処理(2/2)

- ラインカード
  - 物理層から受け取ったフレームをバッファリング
  - テーブルにある宛先の送信制御
    - クロスバスイッチファブリックに調停要求→送信
  - テーブルにない宛先を持つフレームの送信をルーティングエンジンのCPUに依頼
  - マルチキャストフレームの複製

大型ネットワークスイッチの実例 (Cisco Catalyst 6500)

名大内ネットワークNICE4で利用中なので

- バックプレーン容量2Tbps
  - ルーティングエンジン(スーパバイザカード)も2Tbps対応
- 1G/10G/40Gイーサネット対応ラインカードを複数接続可能
- Virtual Switching Systemで複数のスイッチを束ねて制御可能

NICE4とCatalyst 6500

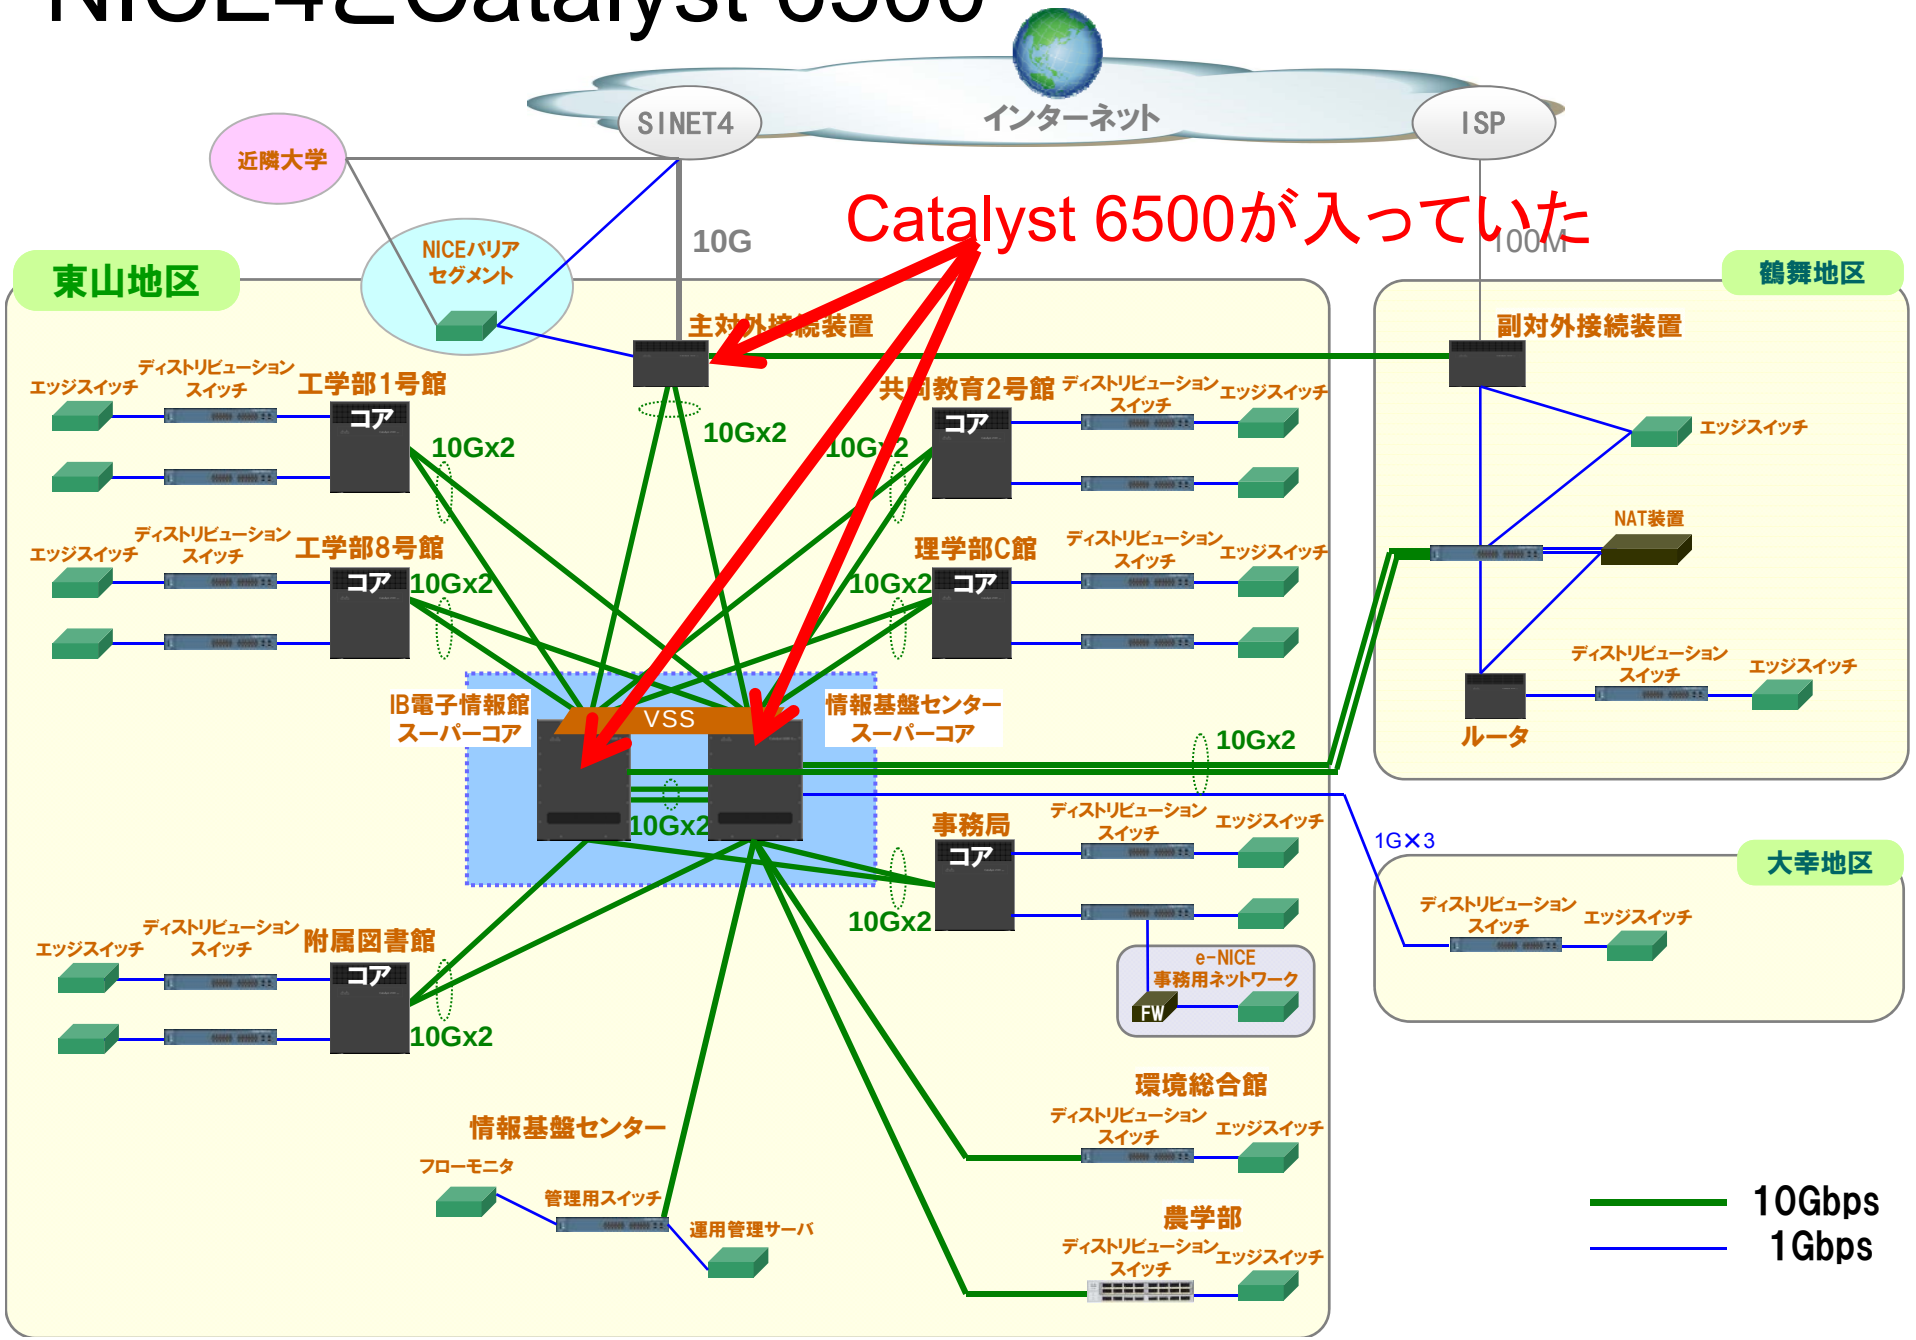

Catalyst 6500の構成

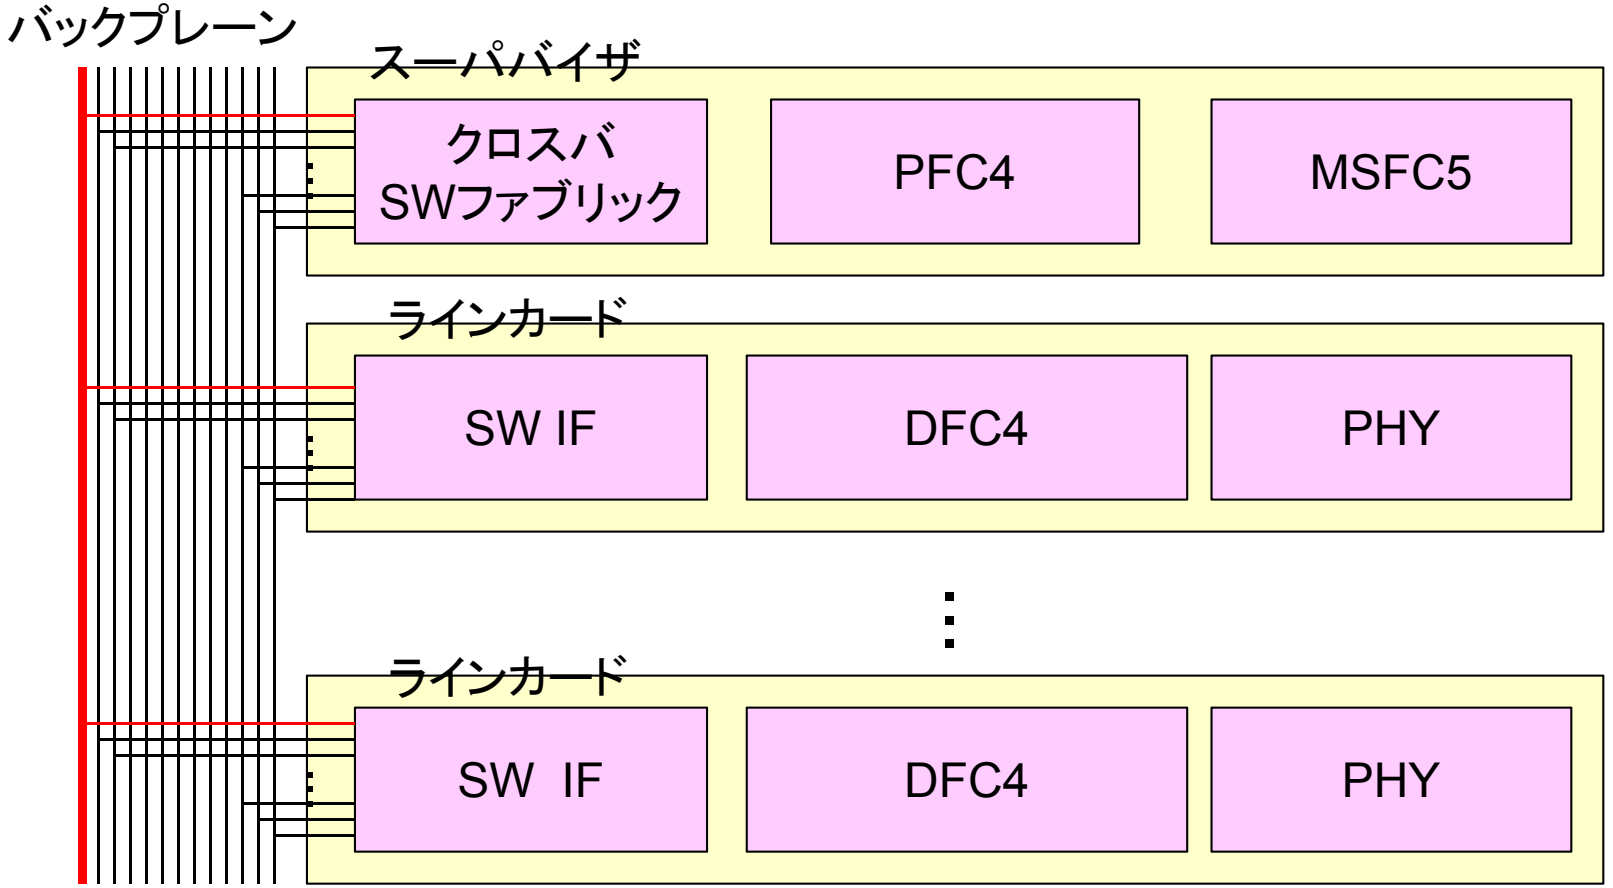

シャーシについているバックプレーン

- 共有バス接続部とクロスバスイッチ接続部に分かれている

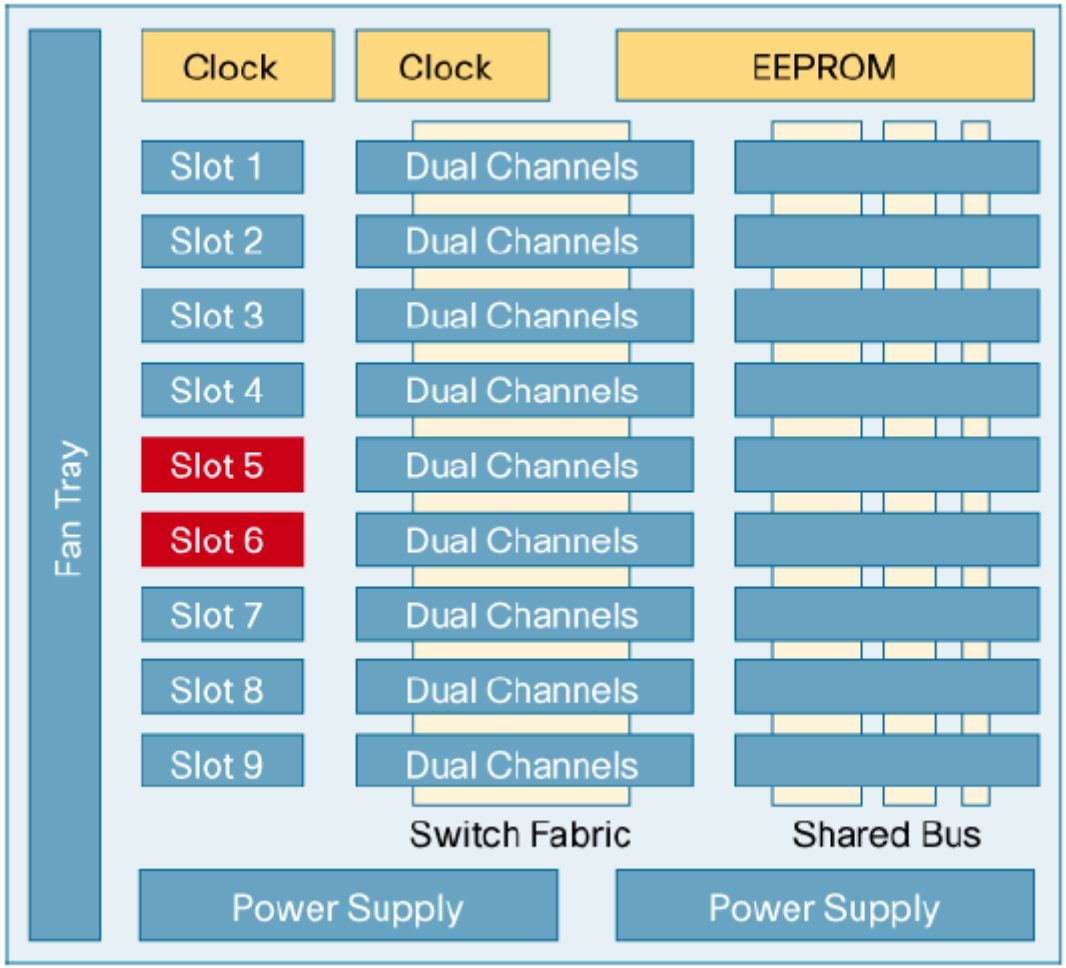

ラインカードによる接続形態の違い

- ラインカードによっては、共有バスのみの接続を取るものがある
  - ルーティングの依頼ができなくなるので、その逆はない

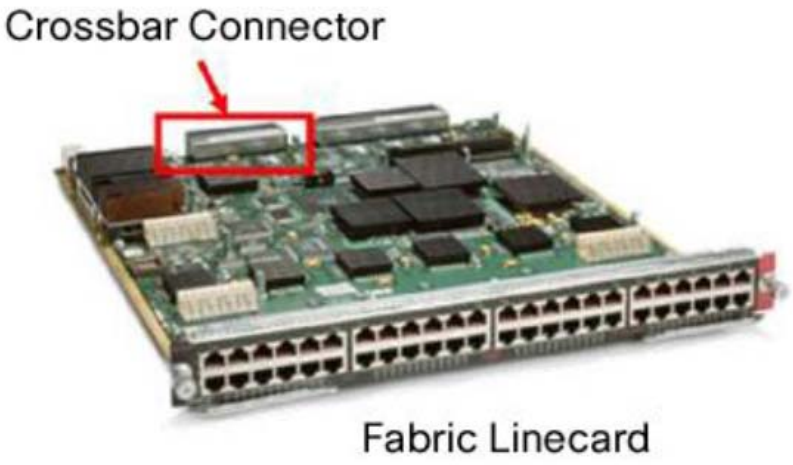

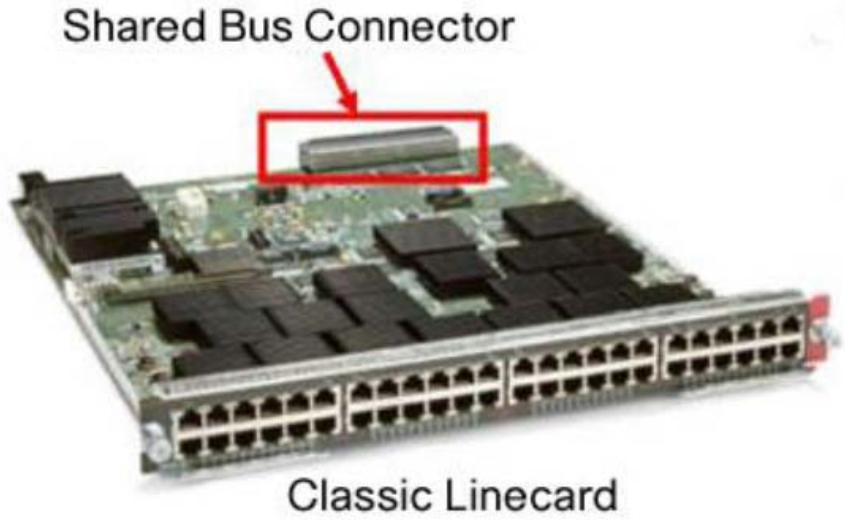

スーパバイザカード2T

以下より構成

- MSFC5: Multilayer Switch Feature Card 5
- PFC4: Policy Feature Card 4
- スイッチファブリック

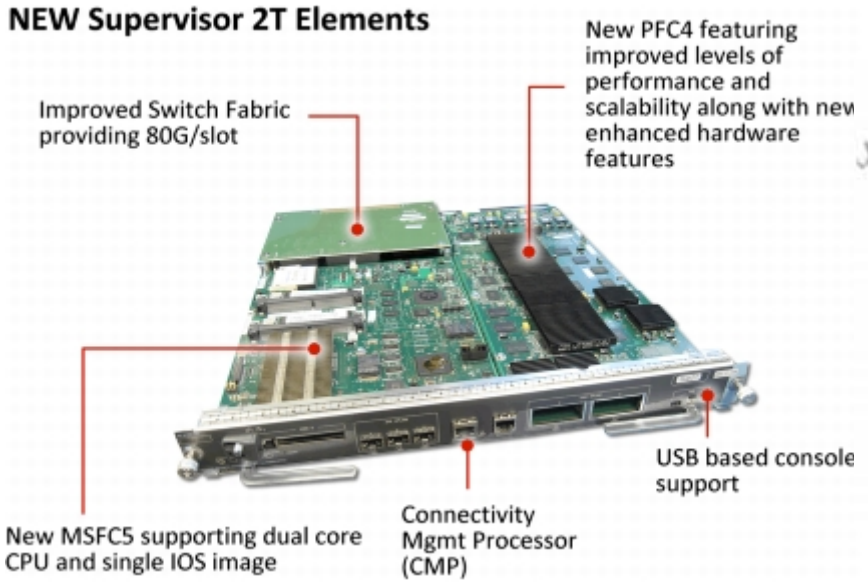

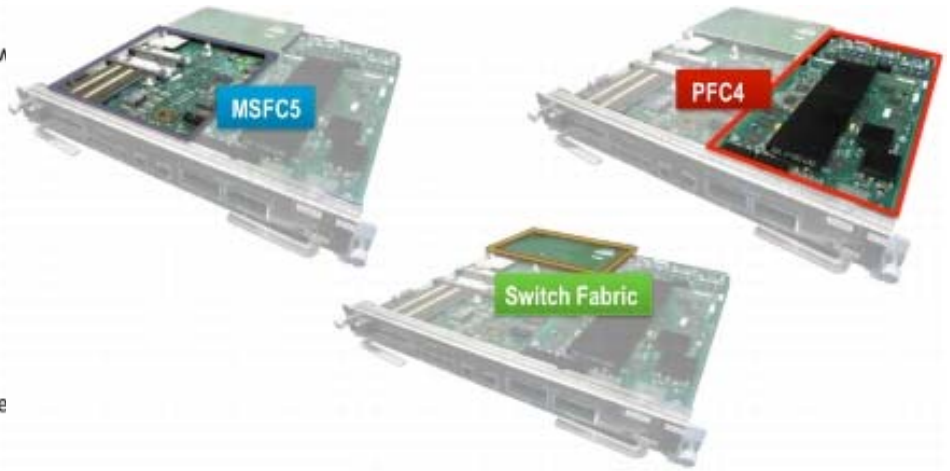

スーパバイザカードのブロック図

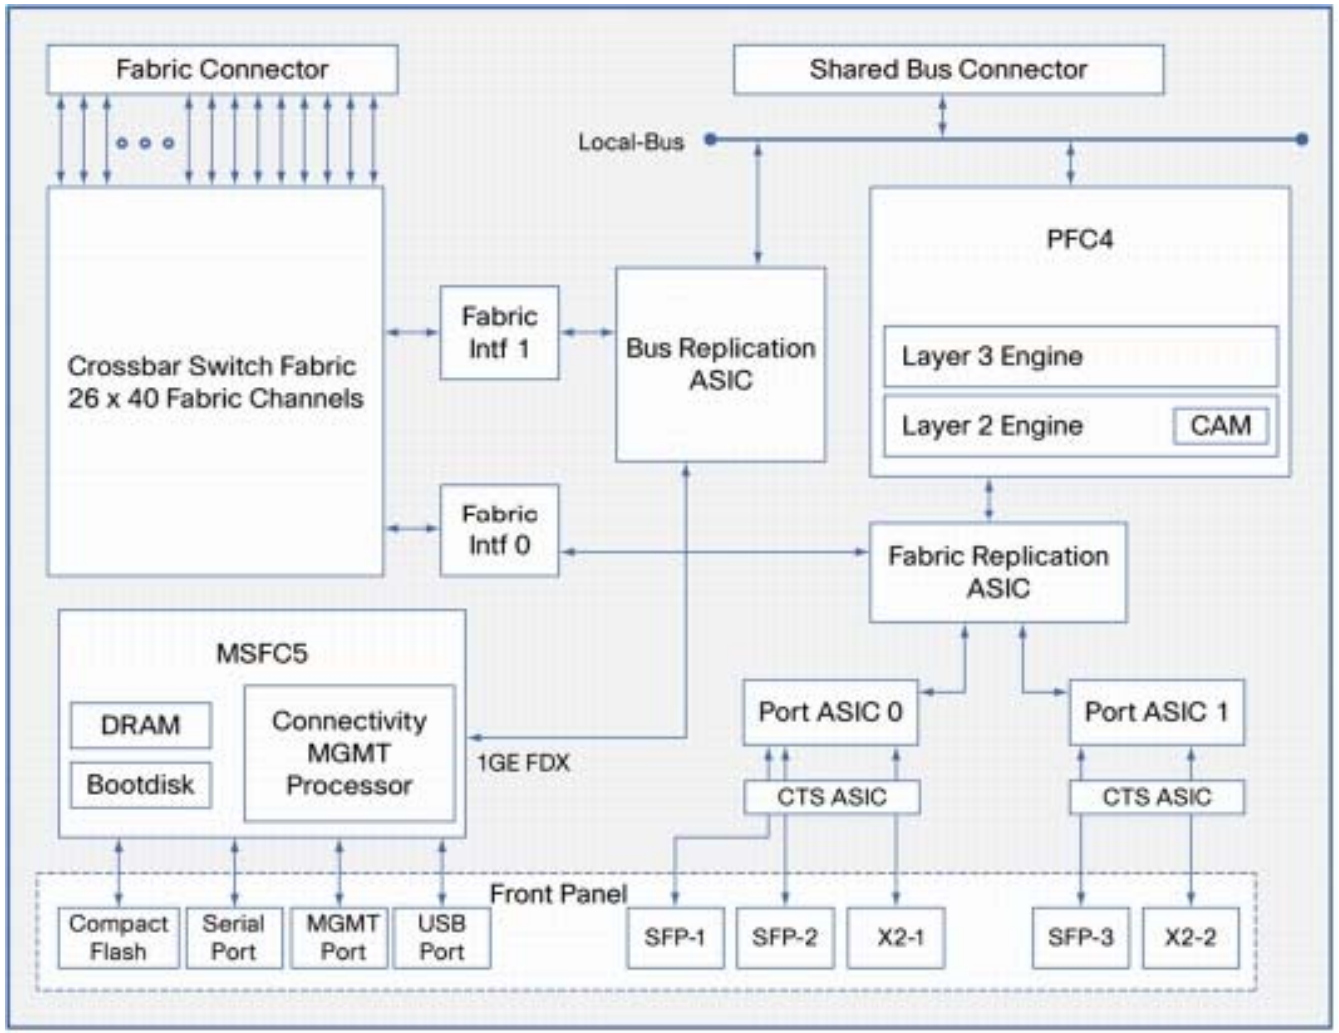

スイッチファブリック部

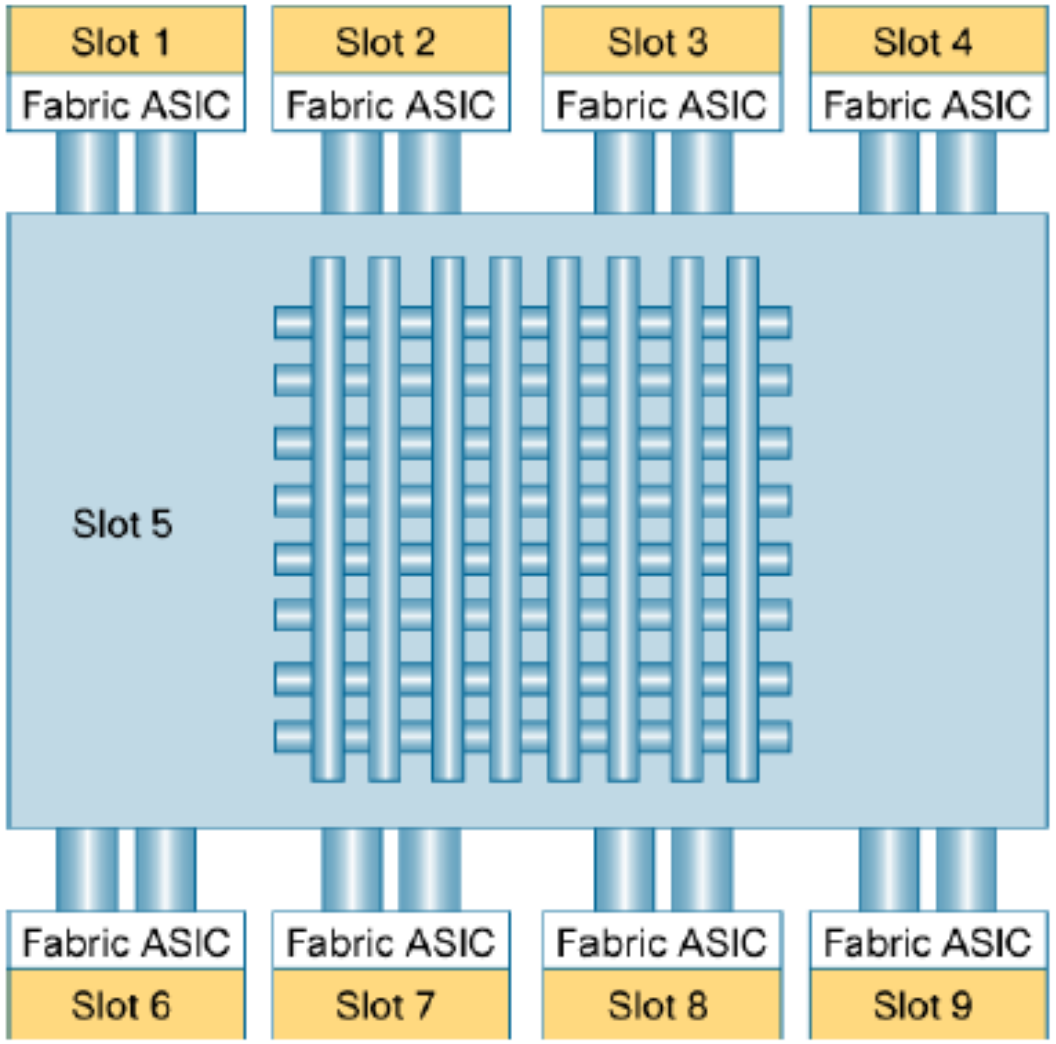

PFC4部

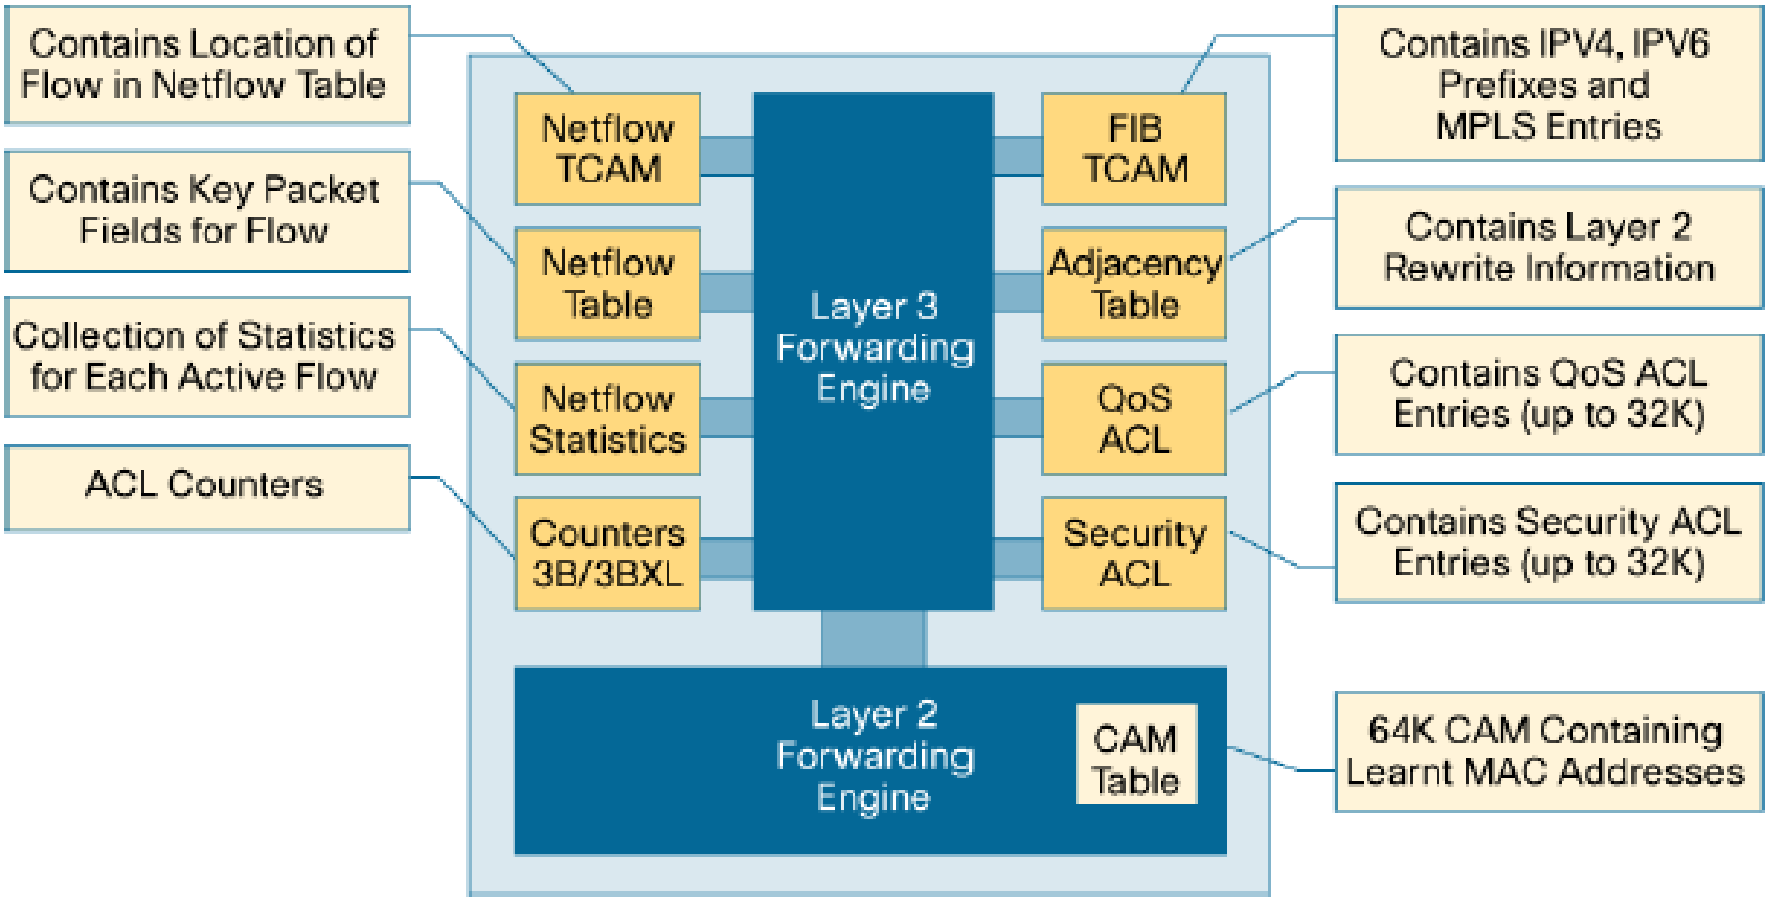
Contains Location of Flow in Netflow Table
Contains Key Packet Fields for Flow
Collection of Statistics for Each Active Flow
ACL Counters
Netflow TCAM
Netflow Table
Netflow Statistics
Counters 3B/3BXL
Layer 3 Forwarding Engine
FIB TCAM
Adjacency Table
QoS ACL
Security ACL
Layer 2 Forwarding Engine
CAM Table
Contains IPV4, IPV6 Prefixes and MPLS Entries
Contains Layer 2 Rewrite Information
Contains QoS ACL Entries (up to 32K)
Contains Security ACL Entries (up to 32K)
64K CAM Containing Learnt MAC Addresses

クロスバスイッチ部を1チャンネル使うラインカード

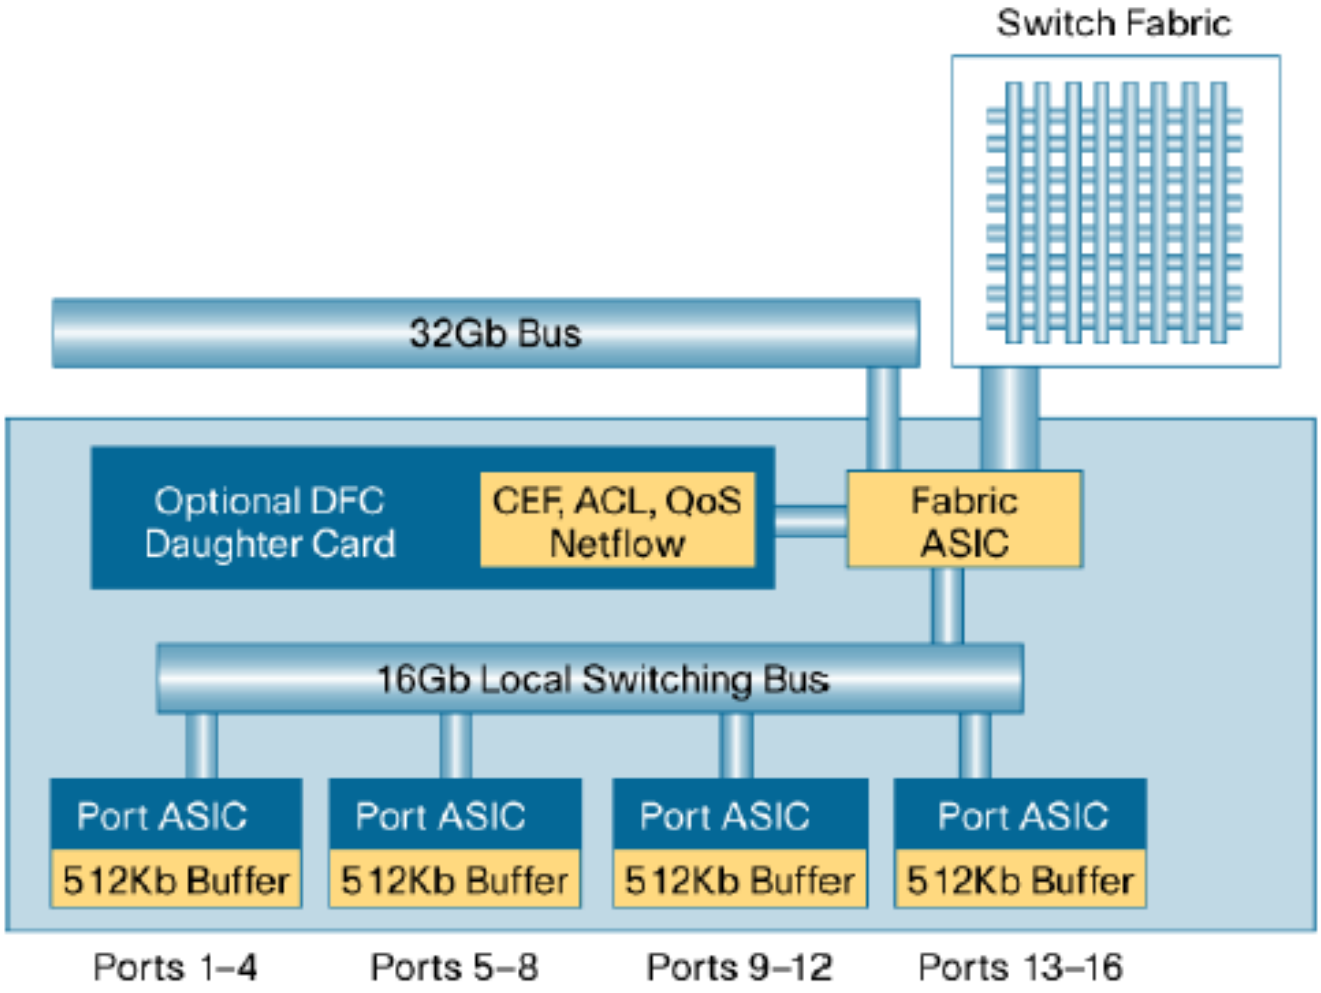

クロスバスイッチ部を2チャンネル使うラインカード

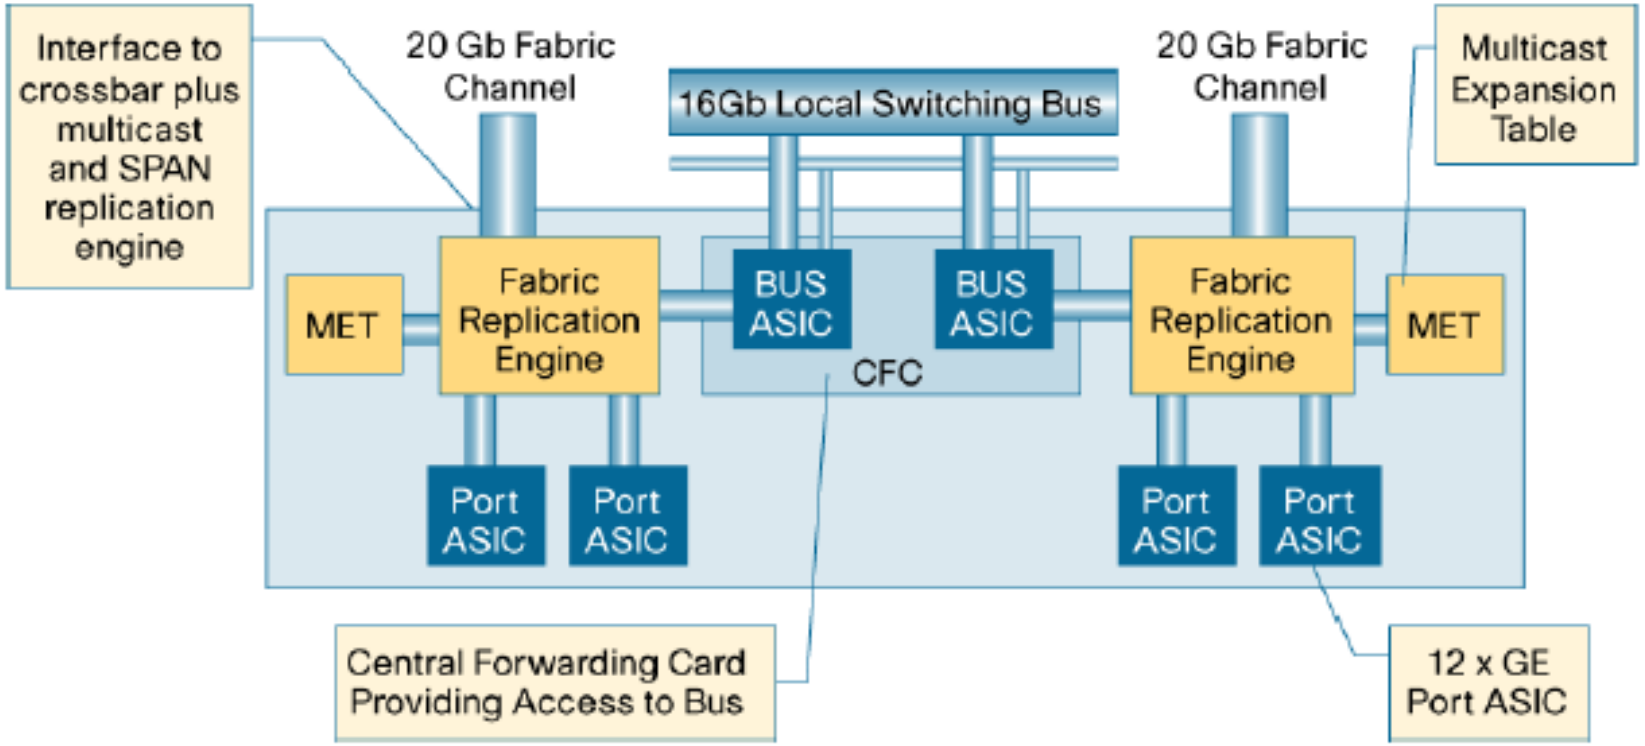

ルーティング情報が無い場合のスイッチング

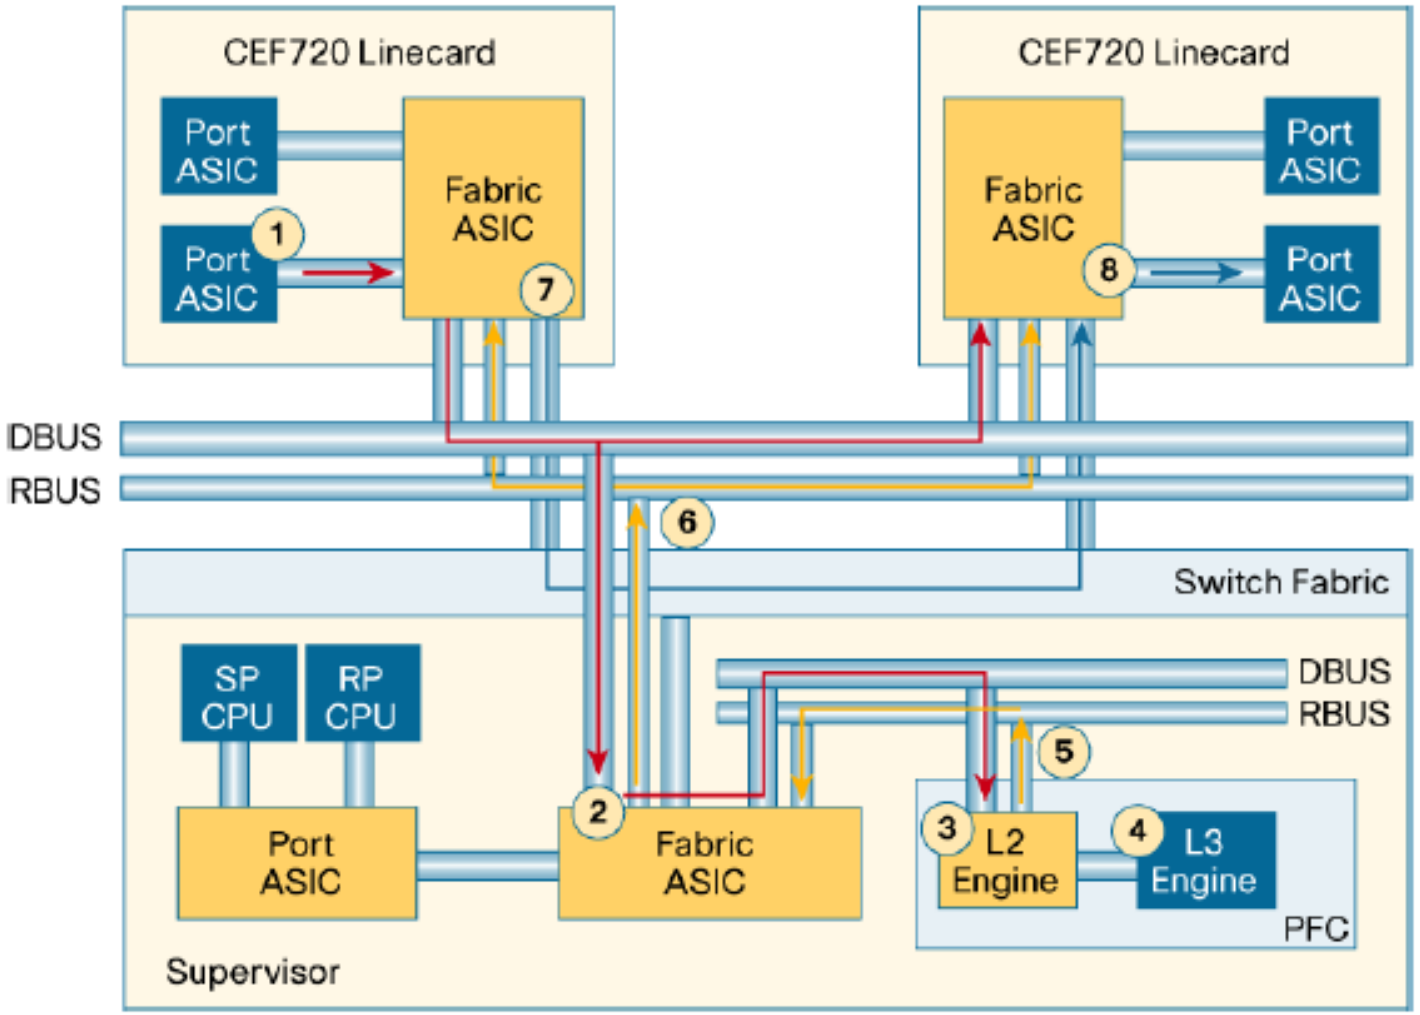

ルーティング情報がある場合のスイッチング

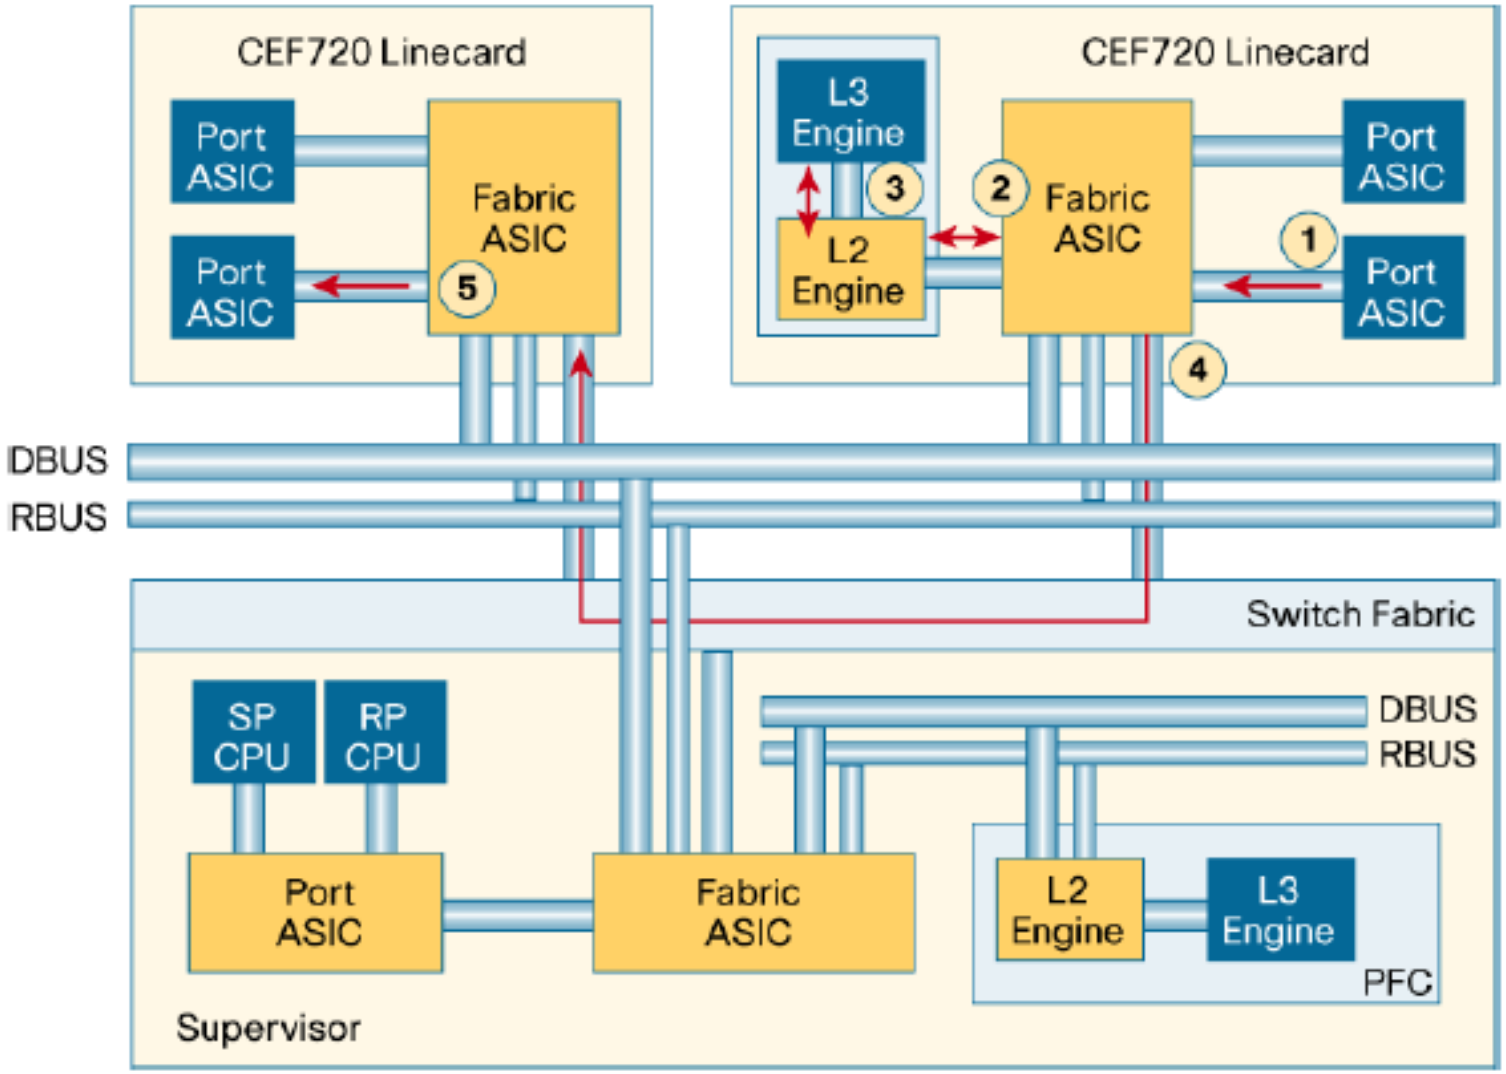

キャンパスLANの組み方の実例

- NICE(Nagoya university Integrated Communication Environment)を参考に
  - http://www.icts.nagoya-u.ac.jp/ja/services/nice/
- 現在は4世代目(NICE4)から5世代目(NICE5)への更新途中
  - 本来は一括で更新したかったのだが、お金が無い
  - SINET(Science Information NETwork: 学術情報ネットワーク)の方も2016/4にSINET5に更新された
    - http://www.sinet.ad.jp/

2016/4時点でのNICE

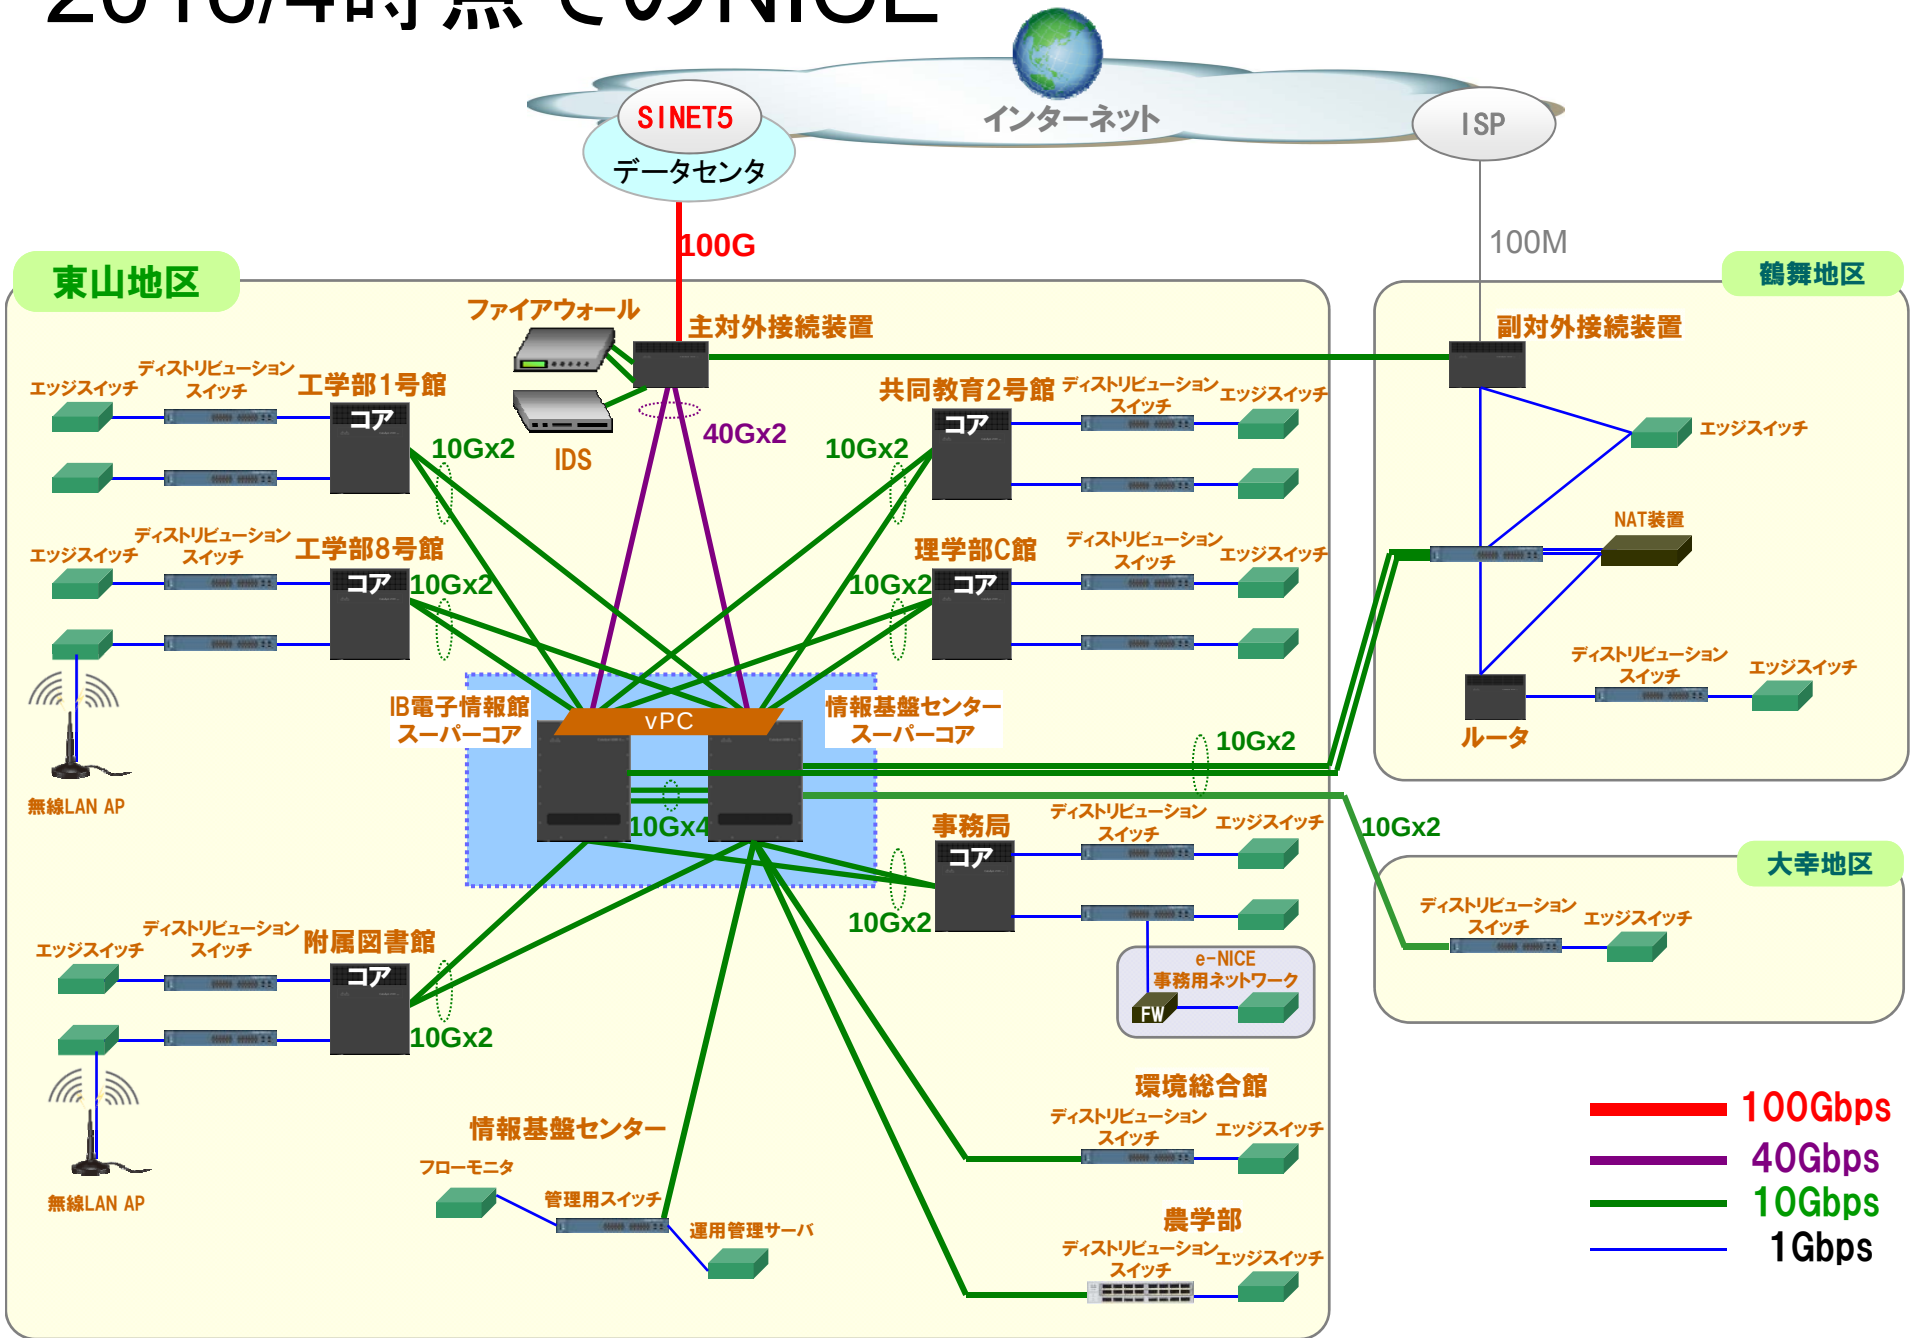

スイッチの階層の組み方(1/2)

- 対外接続スイッチ
  - 主対外外続は情報基盤センターからSINETへ100Gbpsで
  - 副対外接続は鶴舞のエネルギーセンターから某プロバイダ経由で100Mbpsで(ただし、業務用)
  - この周りにIDS、ファイアウォール、アンチウィルスゲートウェイ、フローモニタ、など
- (スーパ)コアスイッチ
  - スーパコアスイッチは情報基盤センターとIB北棟
    - vPCという方式で仮想的に1台のスイッチとして運用(冗長化)
    - 学内のVLAN(L2)をルーティングするL3スイッチ
  - コアスイッチは学内に7箇所
    - NICE4までは学内のルーティングも実施
    - 鶴舞のコアスイッチは引き続きルーティングを実施中

スイッチの階層の組み方(2/2)

- ディストリビューションスイッチ
  - 基本的に、各建物に1台存在
  - 複数のエッジスイッチの通信とコアスイッチの間をとりもつ
    - 基本的に、ディストリビューションスイッチまでは光、その先はUTP
- エッジスイッチ
  - 基本的に、各建物の各フロアに1台
  - 一部の小規模な建物は、エッジスイッチだけが存在
- 無線LANアクセスポイント
  - 認証系(ウェブ、802.1x)は情報基盤センターのサーバ室

キャンパスネットワーク設計の検討点

- 対外接続においてBGPフルルートを受けてルーティングするか?
  - BGPフルルートを受ける性能が対外接続スイッチに必要となる
    - 現状では50万経路ほどが必要になるが、将来のネットワーク細分化を考えると100万経路は欲しい
    - 全ルートをTCAM(3値連想検索メモリ)に入れることができるようなL3スイッチは高価
  - The Internetへの出口が1つならばBGPフルルートは不要
    - 複数の出口があって動的に経路選択をやらない限り不要
- 学内のルーティングはどこでやる?
  - 現状ではルーティングをスーパコアスイッチに集約中
    - メーカも集約する方向を売りにしている
    - L3機能を持ったスイッチ自体が高価(保守費用も含めて)
  - ただし、鶴舞のVLANを東山でルーティングするのは無駄が多いので、鶴舞のコアスイッチでルーティング

スイッチ調達時に主に気にする性能(1/

- スイッチング容量(単位: bit per second)
  - 例: 10Gbps 32ポート、40Gbps 4ポート
    10G x 32 x 2(双方向) + 40G x 4 x 2(双方向) = 960Gbps
  - 普通は全ポートが同時にフルに通信しても問題ない性能を持つ
- パケット転送性能(単位: packet per second)
  - こちらは全ポートが同時にフルにショートパケット(64byte)で通信しても耐えれるものはまず無い
  - ショートパケットが大量に来る用途では注意
- 各種プロトコル(ルーティング、管理、QoS、など)に対応しているか?

スイッチ調達時に主に気にする性能(2/

- 監視用の設定を色々とできるか?
  - フローモニタに出力できるか?
  - ミラーポートの切り方に自由度があるか?
  - アクセス・コントロール・リストをどれだけ設定できるか?
- メンテナンス性や冗長性は?
  - 複数のスイッチを1つとして動作させる機能は?
  - ソフトウェアアップデート時の停止時間は短いか?
- ラインカードあたりのポート数は?