JANOG routingチュートリアル

Matsuzaki ‘maz’ Yoshinobu
<maz@iij.ad.jp>

インターネット

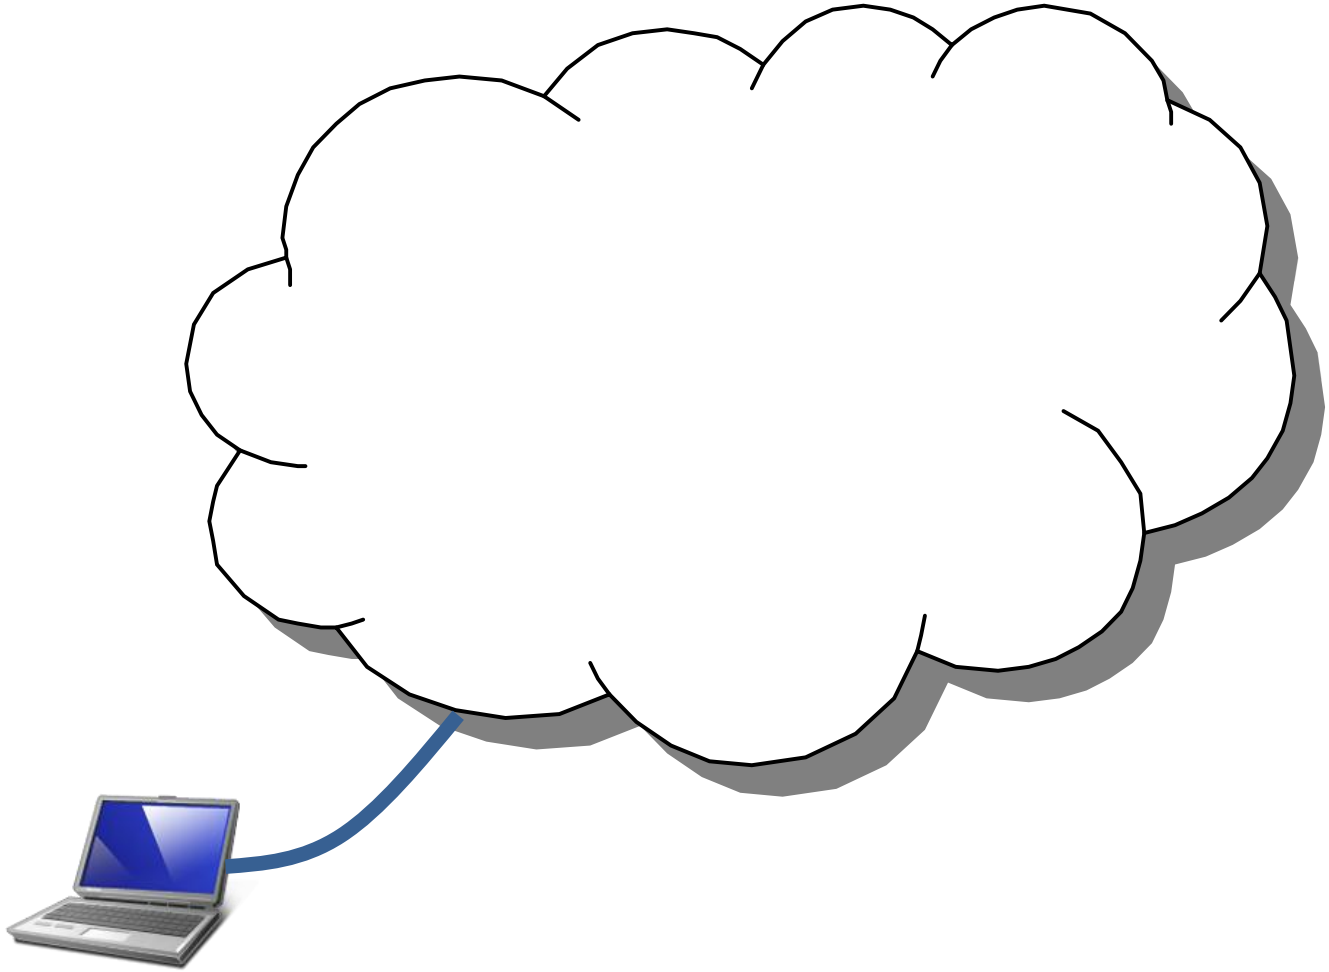

ネットワーク

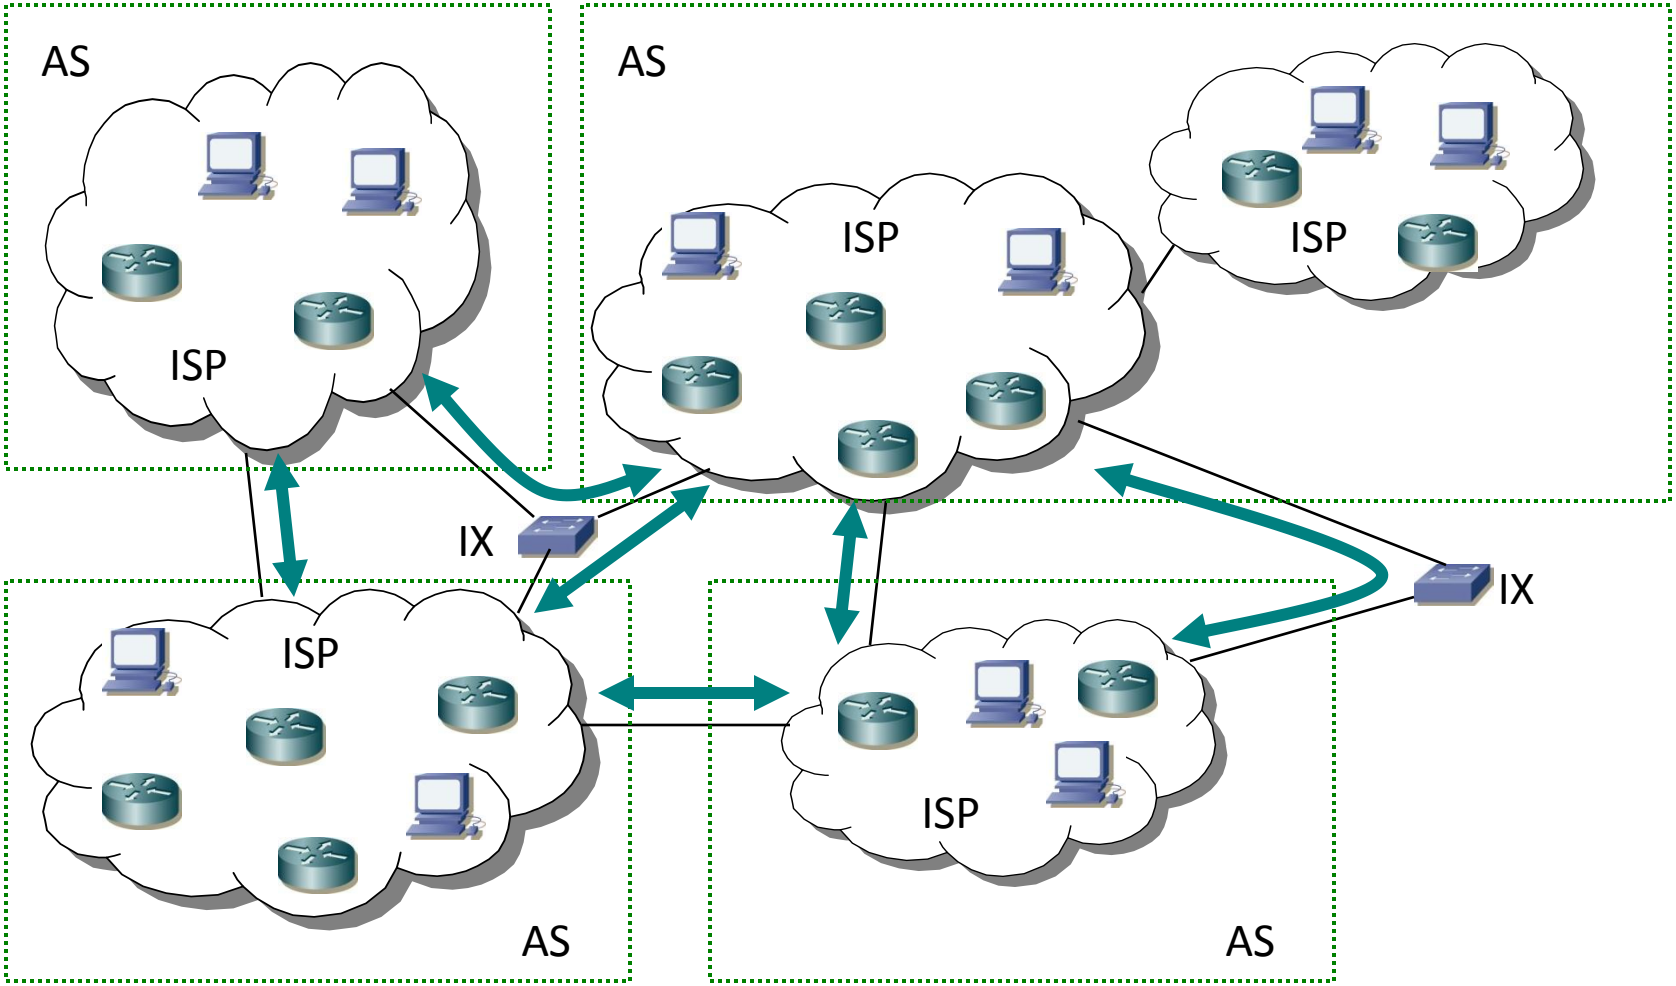

アクセス網とバックボーン網

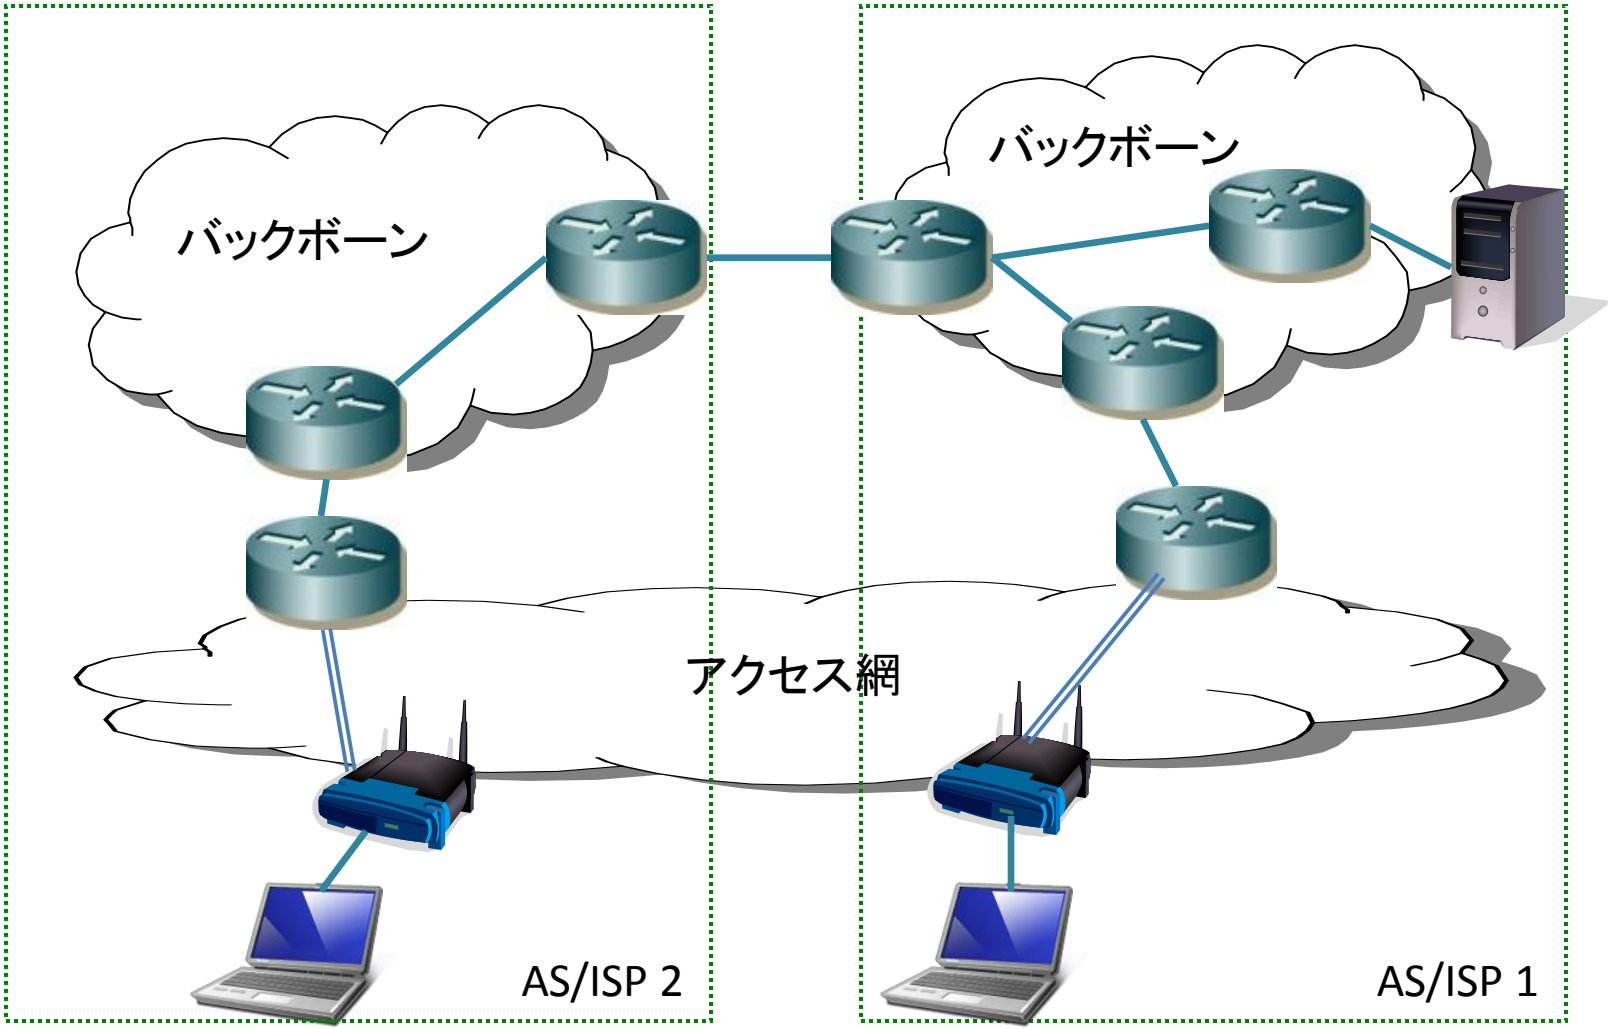

ホスト、回線、ルータ

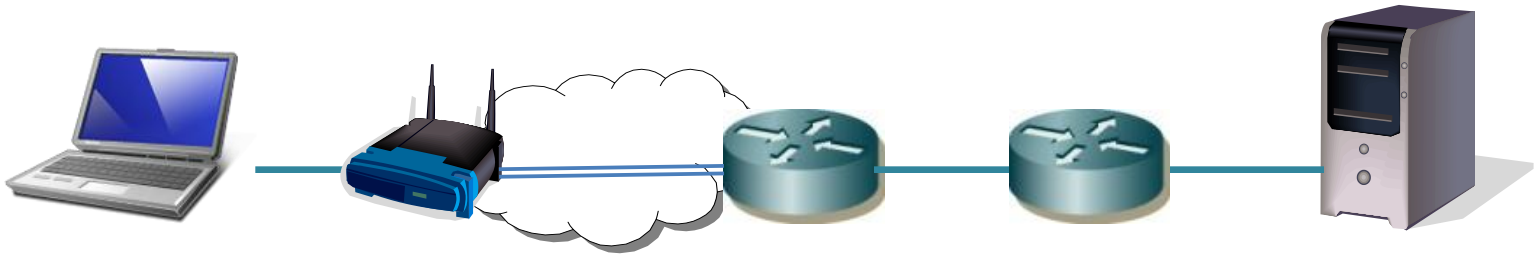

ホスト

- IPで通信したい人たち
  - PC、ゲーム、PDA、テレビ
- それぞれネットワークに接続するためのインターフェスを持つ
  - イーサネット
  - 無線LAN、無線WAN
  - シリアル、パラレル、USB

回線

- IPパケットを転送するための線
  - 専用線、ダークファイバ
  - アクセス網経由の回線(pppoe, ppp)
  - 光ファイバ、イーサケーブル
- 帯域の保証や到達距離、保守など、メディアやサービスに応じて違いがある
- 実のところ、回線は何が流れてても気にしない
  - IP以外でも良い
  - 独自プロトコルを利用するために利用する人も

2拠点間を結ぶ回線種別

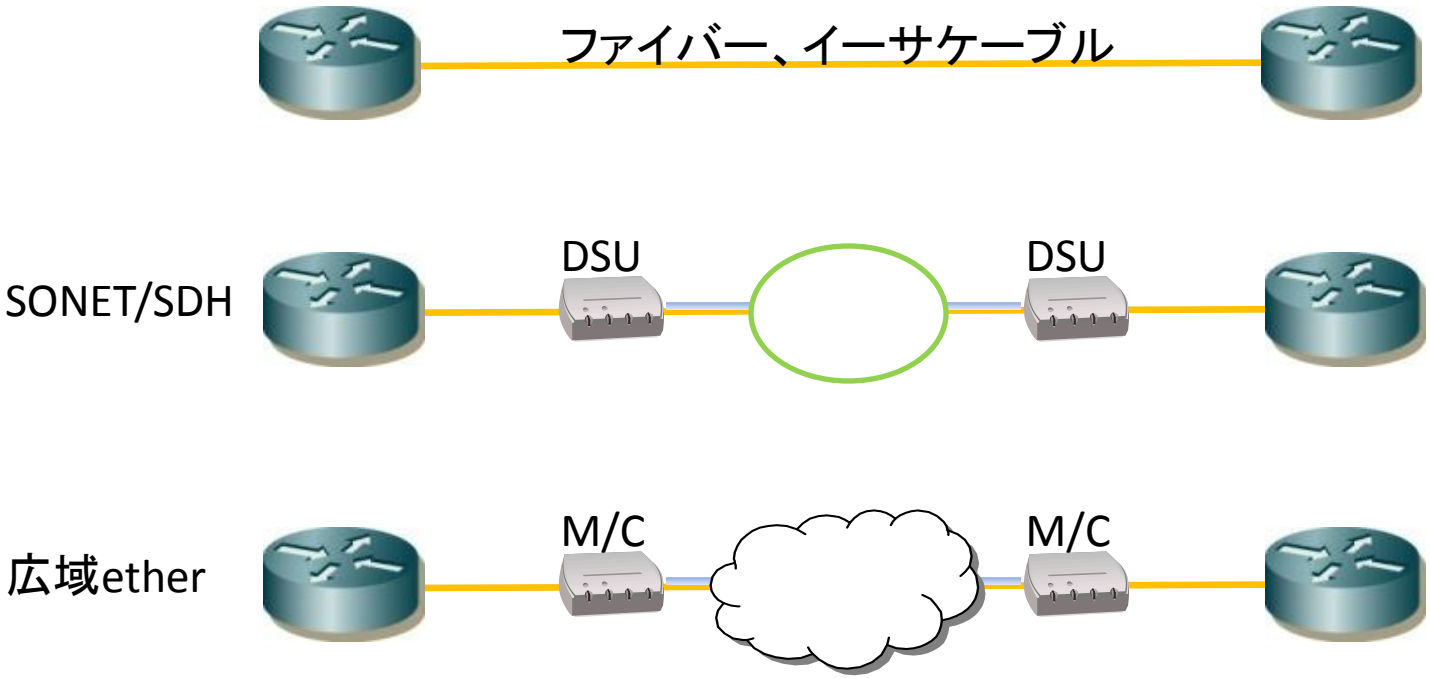

ルータ

- IPパケットを経路表に応じて転送する人たち
  - ブロードバンドルータ
  - エンタープライズ用ルータ
  - バックボーン用ルータ
- インタフェースや学習できる経路数などで違いがある

ルータの違い

- とあるブロードバンドルータ
  - 148,810pps (6micro sec/packet)
- とある大きなルータ
  - 770,000,000pps (1pico sec/packet)

- 専用ハードウェアによる高速化

ネットワーク設計

- 利用可能なネットワークが維持される様に
  - 冗長であること
  - 拡張しやすいこと
  - 運用しやすいこと
- 日々のトラヒックを運びつつも、様々な障害に耐え、増設も素直に行え、運用に過度の負荷をかけない

障害

- 回線は切れる
  - 異経路の確保
- ルータは落ちる
  - 通常時の負荷軽減
  - 迂回路の確保
- データセンタでも停電する
  - 一カ所に依存しない運用

拡張しやすさ、運用しやすさ

- 動くネットワークは誰でも設計できる
  - いろんなパターンが考えられる
- 維持できるネットワークを設計しないと駄目
  - 増強時にも素直に拡張できる
  - トラブル時に混乱しない
  - シンプルで一貫性のあるポリシ
  - 設定変更時に変更箇所が少なくて済むように

設計の制限事項

- 電源
  - 割り振られた電源容量
- 場所
  - 機器を設置するラック数
- 回線
  - 長距離区間を引ける本数、帯域
  - 引き込める回線種別
- ルータや機器
  - ポート数やインタフェース種別
  - サポートしているプロトコル、機能

RFCと実装

- 全ての実装が標準に忠実とは限らない
  - 実装ミス
  - 運用上や性能上の都合
  - 独自の拡張機能
    - 後にRFCとなる場合もある
- 異なる実装の相互接続で問題となりうる
  - OSPFのタイマーとか

標準技術と非標準技術

- 標準技術
  - みんなが使ってるのでメンテナンスされる
  - 他の機器で置き換えられる
- ベンダ特有の非標準技術
  - 痒いところを掻いてくれる(かも)
  - さっさと利用できる
- どれをどう採用するかはネットワークに寄る
  - IIJでは標準技術を重視

機器の評価と検証

- ベンダでも全てを検証しているわけではない
  - 機能の組み合わせによる場合分けが破綻した
- 求める機能、性能が利用できるか確かめる
  - カタログスペックなんて当てにならない
  - 自分たちが使うところを集中的に
    - 標準的な構成、機能を利用していると安心感

IPv4アドレス表記

- 32bit長を8bit毎に10進数表記、「.」で繋ぐ
- 192.168.0.1

IPv6アドレス表記

- 128bit長を16bit毎に16進数表記、「:」で繋ぐ
- 2001:0db8:0000:0000:0000:0000:0000:0001
  - 先頭の0を省略 2001:db8:0:0:0:0:0:1
  - 連続の0を圧縮 2001:db8::1
    - ただし、::は一か所だけ (ex: 2001:db8::1:0:1)

ネットワークのプレフィックス表記

- 192.168.0.0/24
  = 192.168.0.0～192.168.0.255
  = 192.168.0.0 mask 255.255.255.0
- 2001:db8::/64
  = 2001:db8:: ～ 2001:db8::ffff:ffff:ffff:ffff

- 連続ネットマスクが前提
  - 非連続ネットマスクは表現できない
    - 192.168.0.10 mask 255.255.0.255
  - 複数行での表記になる場合
    - 192.168.0.0～192.168.2.255
    - 192.168.0.0/23, 192.168.2.0/24

クラスレス(Classless)

- クラスの概念は過去の遺物なので忘れよう

- 昔はネットワークアドレスの認識に利用
  - IPv4アドレスを見れば、ネットマスクが分かった
  - RIPなどで利用
  - 最近はプロトコルでプレフィックス長を伝播する
  - 今やクラスレスが標準

クラスA　0.0.0.0 ~ 127.255.255.255 → /8
クラスB 128.0.0.0 ~ 191.255.255.255 → /16
クラスC 192.0.0.0 ~ 223.255.255.255 → /24

ルーティングとは

- どこを経由してパケットを宛先に届けるか
- ルータはパケットの宛先アドレスをみて次の送り先を判断する

IPv4パケット送信

- 同じネットワークに属していれば直接送信

inet 192.168.0.1 netmask 255.255.255.0
↓
192.168.0.0～192.168.0.255が同じセグメント上にある

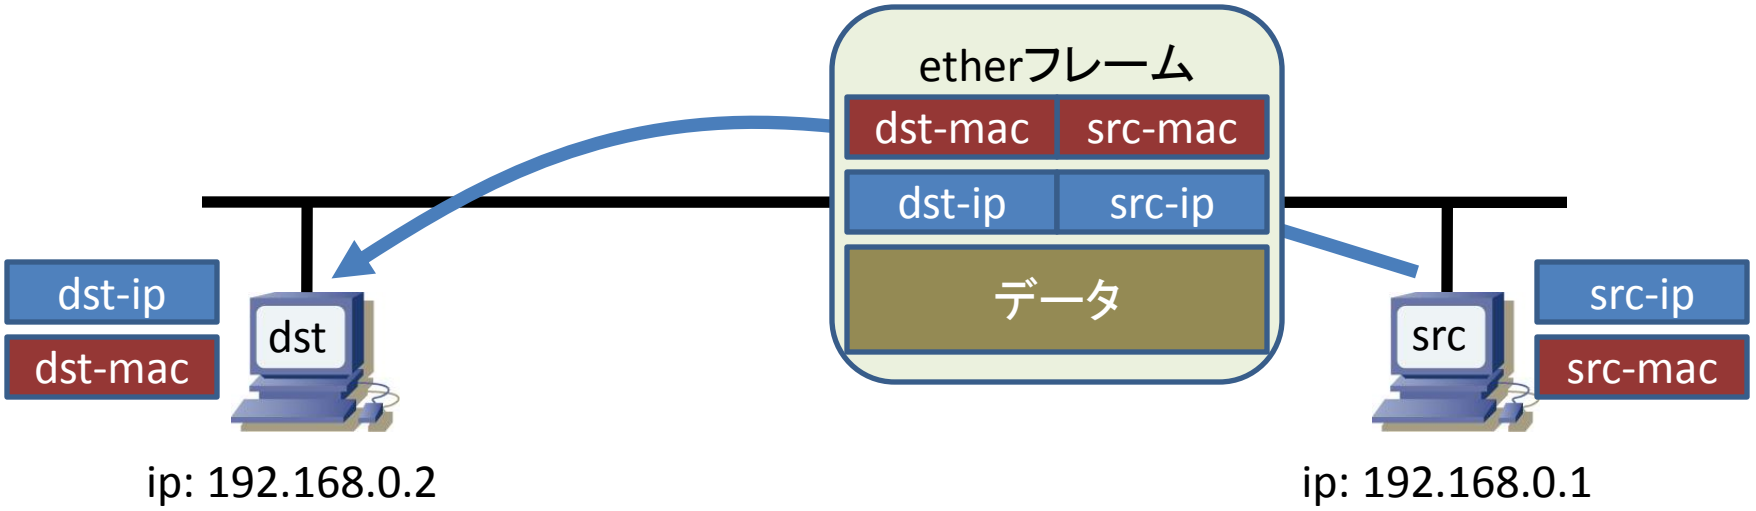

IPv4パケット送信 2

- 遠くには経路情報に従ってルータに投げる

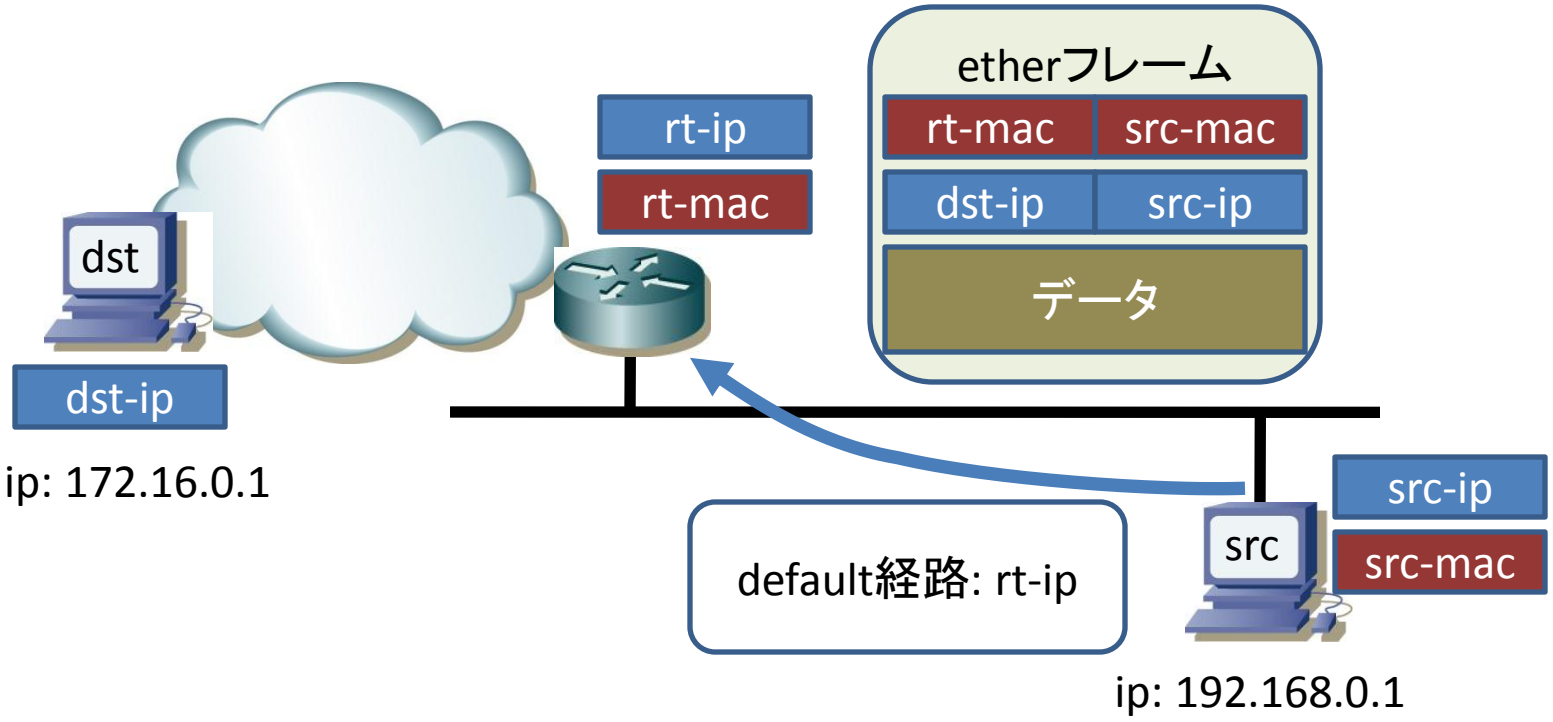

arp (Address Resolution Protocol)

- etherではパケット送信にMACアドレスが必要
  - IPv4アドレスは分かってる (ex. defaultの向け先)
  - 機器のIPv4アドレスからMACアドレスを知りたい
- arpで解決
  - RFC826

```
arp who-has 192.168.0.2 tell 192.168.0.1
 0x0000:  ffff ffff ffff 0019 bb27 37e0 0806 0001
 0x0010:  0800 0604 0001 0019 bb27 37e0 c0a8 0001
 0x0020:  0000 0000 0000 c0a8 0002
arp reply 192.168.0.2 is-at 00:16:17:61:64:86
 0x0000:  0019 bb27 37e0 0016 1761 6486 0806 0001
 0x0010:  0800 0604 0002 0016 1761 6486 c0a8 0002
 0x0020:  0019 bb27 37e0 c0a8 0001 0000 0000 0000
 0x0030:  0000 0000 0000 0000 0000 0000
```

IPv6パケット送信

- 同じネットワークに属していれば直接送信

inet6 2001:db8::1 prefixlen 64
↓
2001:db8::〜2001:db8::ffff:ffff:ffff:ffffが同じセグメント上にある

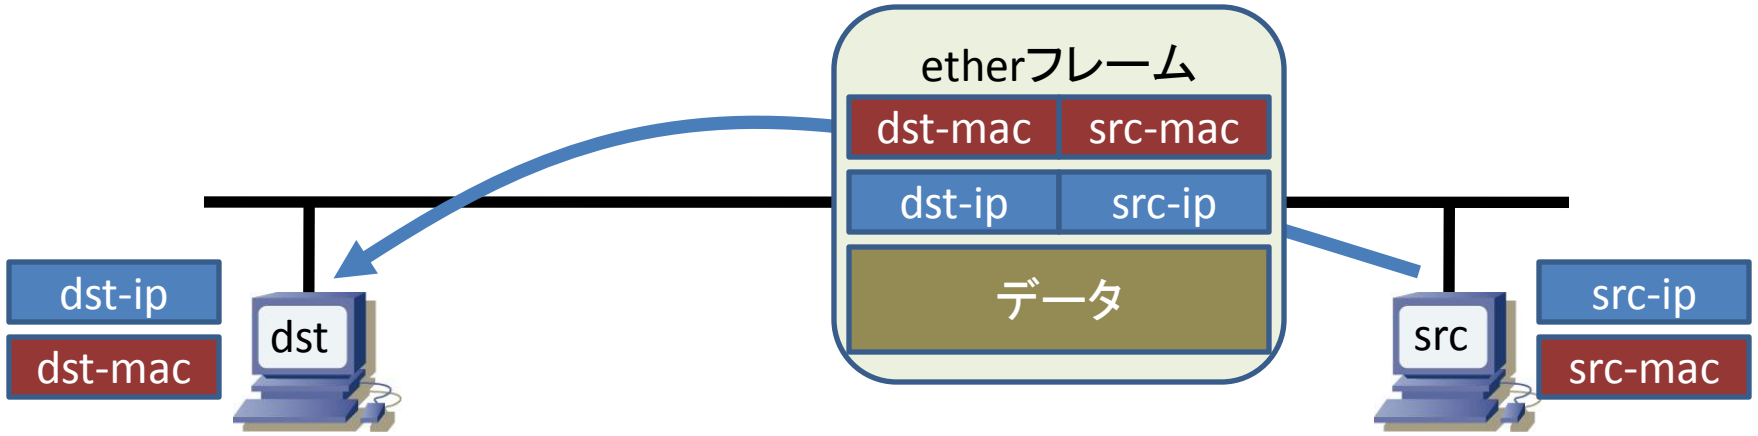

IPv6パケット送信 2

- 遠くには経路情報に従ってルータに投げる

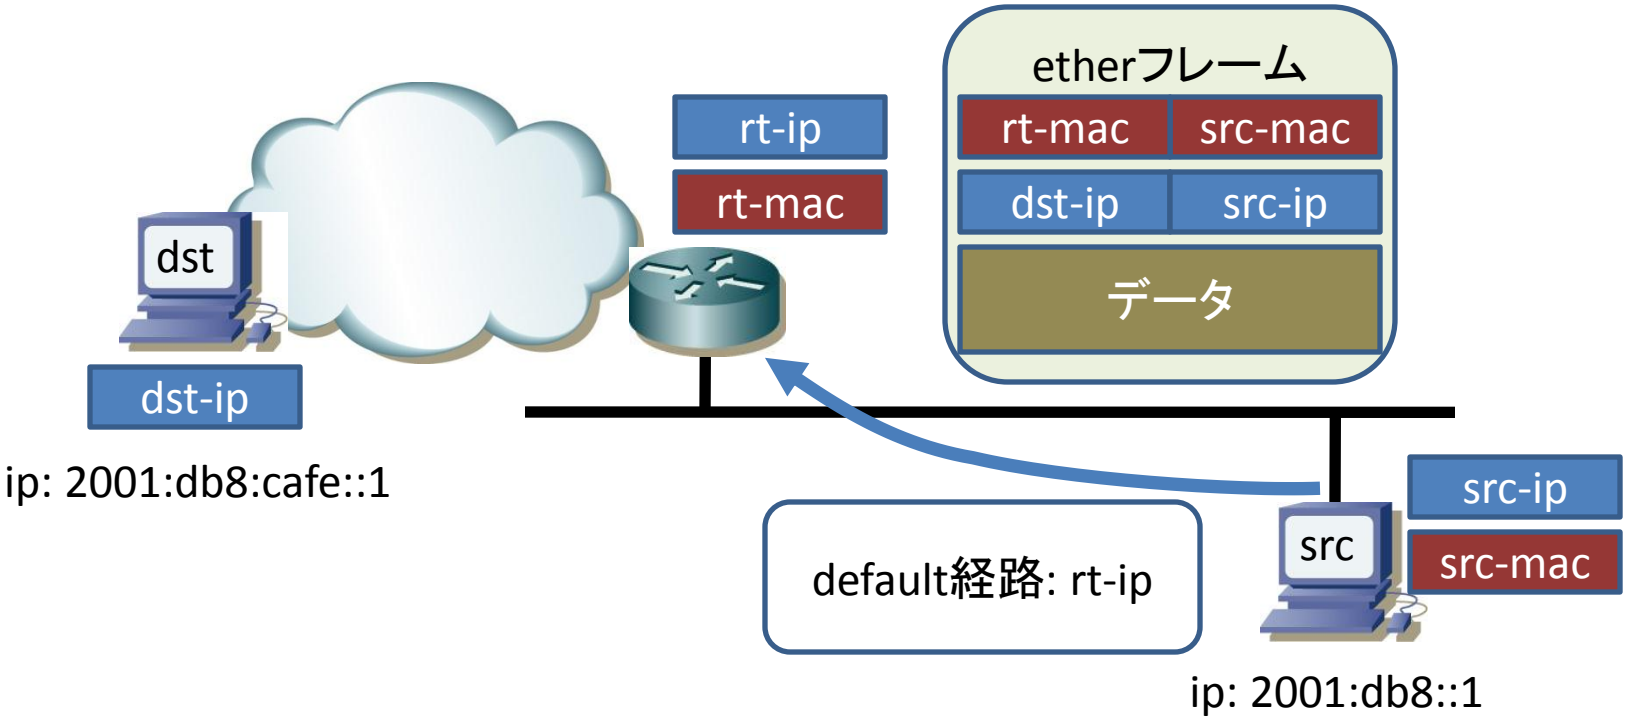

ndp (Neighbor Discovery Protocol)

- etherではパケット送信にMACアドレスが必要
  - 機器のIPv6アドレスからMACアドレスを知りたい
- ndpで解決
  - RFC4861
    - ICMPv6を利用してMACアドレスを問い合わせる
  - 送り先を未学習ならmulticastアドレス宛て
    - IP: ff02::1:ff00:0000 ～ ff02::1:ffff:ffff
      - 送信先IPアドレスの下位24bitを利用して生成
    - MAC: 33:33:00:00:00:00 ～ 33:33:ff:ff:ff:ff
      - 送信先IPアドレスの下位32bitを利用して生成

ndpでMACアドレス解決

```
IP6 2001:db8::1 > ff02::1:ffef:cafe
 ICMP6, neighbor solicitation, who has 2001:db8::beef:cafe
 source link-address option: 00:19:bb:27:37:e0
        0x0000:  3333 ffef cafe 0019 bb27 37e0 86dd 6000
        0x0010:  0000 0020 3aff 2001 0db8 0000 0000 0000
        0x0020:  0000 0000 0001 ff02 0000 0000 0000 0000
        0x0030:  0001 ffef cafe 8700 9a90 0000 0000 2001
        0x0040:  0db8 0000 0000 0000 0000 beef cafe 0101
        0x0050:  0019 bb27 37e0
IP6 2001:db8::beef:cafe > 2001:db8::1
 ICMP6, neighbor advertisement, tgt is 2001:db8::beef:cafe
 destination link-address option: 00:16:17:61:64:86
        0x0000:  0019 bb27 37e0 0016 1761 6486 86dd 6000
        0x0010:  0000 0020 3aff 2001 0db8 0000 0000 0000
        0x0020:  0000 beef cafe 2001 0db8 0000 0000 0000
        0x0030:  0000 0000 0001 8800 c1fd 6000 0000 2001
        0x0040:  0db8 0000 0000 0000 0000 beef cafe 0201
        0x0050:  0016 1761 6486
```

経路情報

- 宛先プレフィックス＋ネクストホップ　の集合

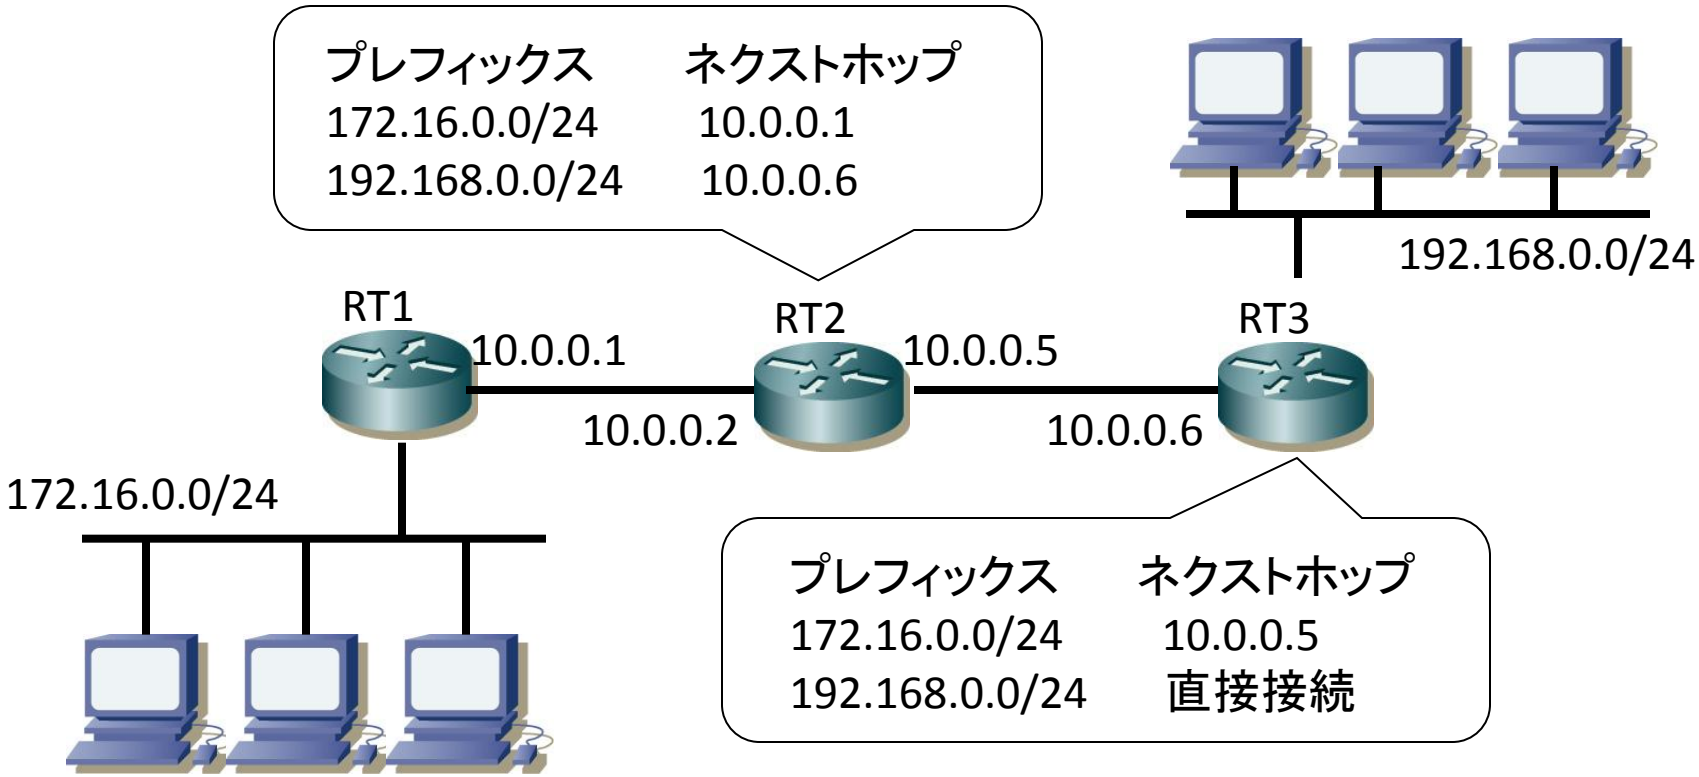

経路の優先順位

1. prefix長が長い(経路が細かい)ほど優先

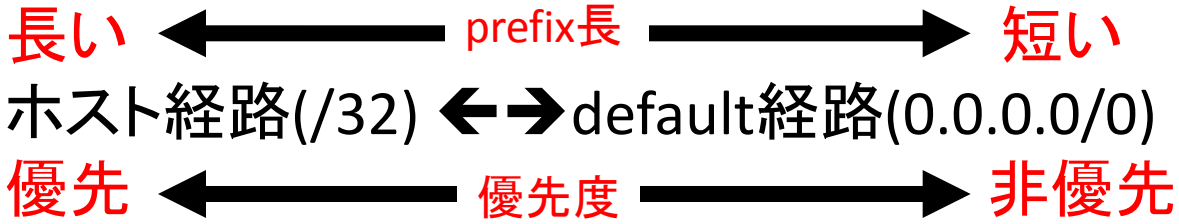

2. 経路種別で優先
   - ① connected経路
   - ② static経路
   - ③ 動的経路(ospf, bgp, etc...)
     - 内訳はベンダ依存

経路の種類

- 静的経路
  - connected経路
    - ルータが直接接続して知っている経路
  - static経路
    - ルータに静的に設定された経路
- 動的経路
  - ルーティングプロトコルで動的に学習した経路
    - OSPFやIS-IS、BGPなどで学習した経路

パケットと経路

- 送信元から宛先まで経路に矛盾が無ければ、パケットが届く
- 双方向で問題が無ければ、相互に通信できる
  - 行きと帰りの経路は違うかもしれない

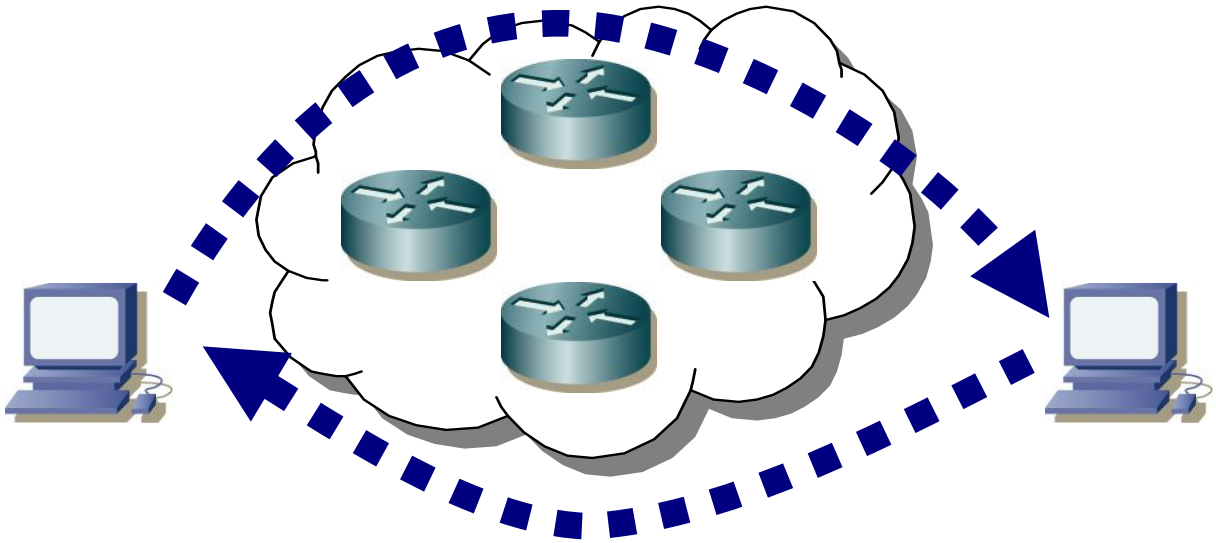

経路ループ

- 起こしちゃダメ
  - 簡単に回線帯域が埋まる
- 大抵設定/設計ミス
  - 矛盾のあるstatic route
  - 無茶な設定の動的経路制御

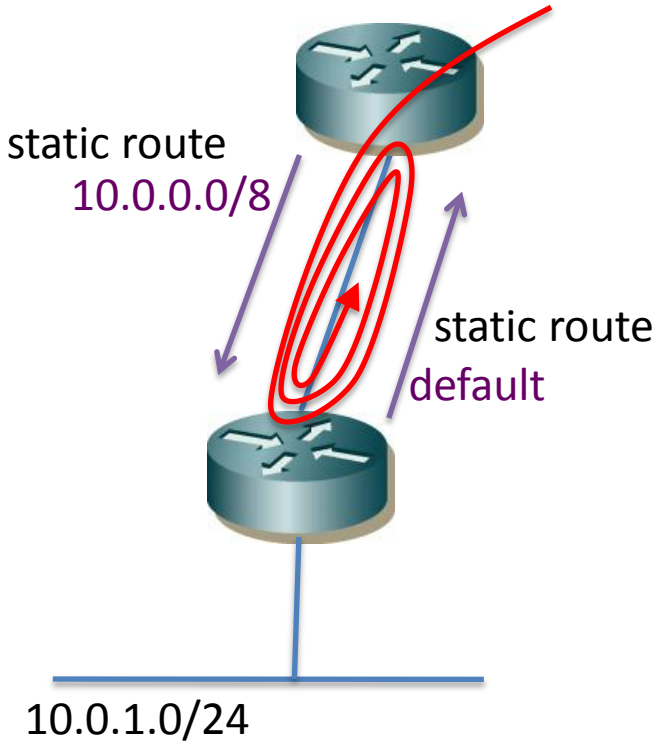

動的経路制御

インターネットと動的経路制御

動的経路制御の必要性

- ネットワーク変化を経路情報に反映
  - もちろん事前の設計は必要
- ISPのバックボーン運用では必須
  - インターネットは変化し続けてる
  - プロトコルごとの得手不得手を把握しておく
  - 何を設定しているのか理解しておく

動的経路制御の基本アイディア

- 検知 – ルータがネットワークの変化を検知
- 通知 – 情報を生成し他のルータに伝達
- 構成 – 最適経路で経路テーブルを構成

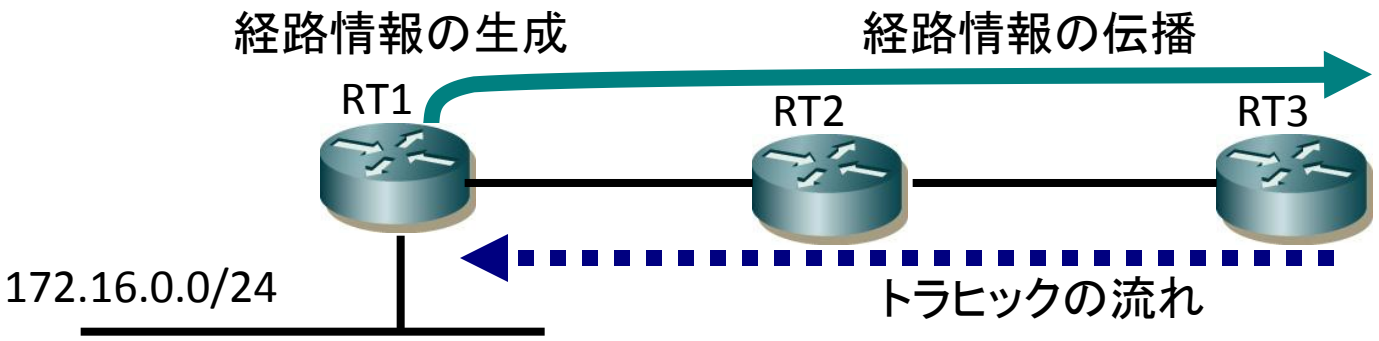

経路情報の伝搬の方向とトラヒックの流れは逆になる

動的経路制御の種類

- ディスタンスベクタ(distance vector)
  - RIPなど、距離と方向を扱うプロトコル
- リンクステート(link state)
  - OSPFやIS-ISなど、リンクの状態を収集して管理するプロトコル
- パスベクタ(path vector)
  - BGPなど、パス属性と方向を扱うプロトコル

インターネットの構成

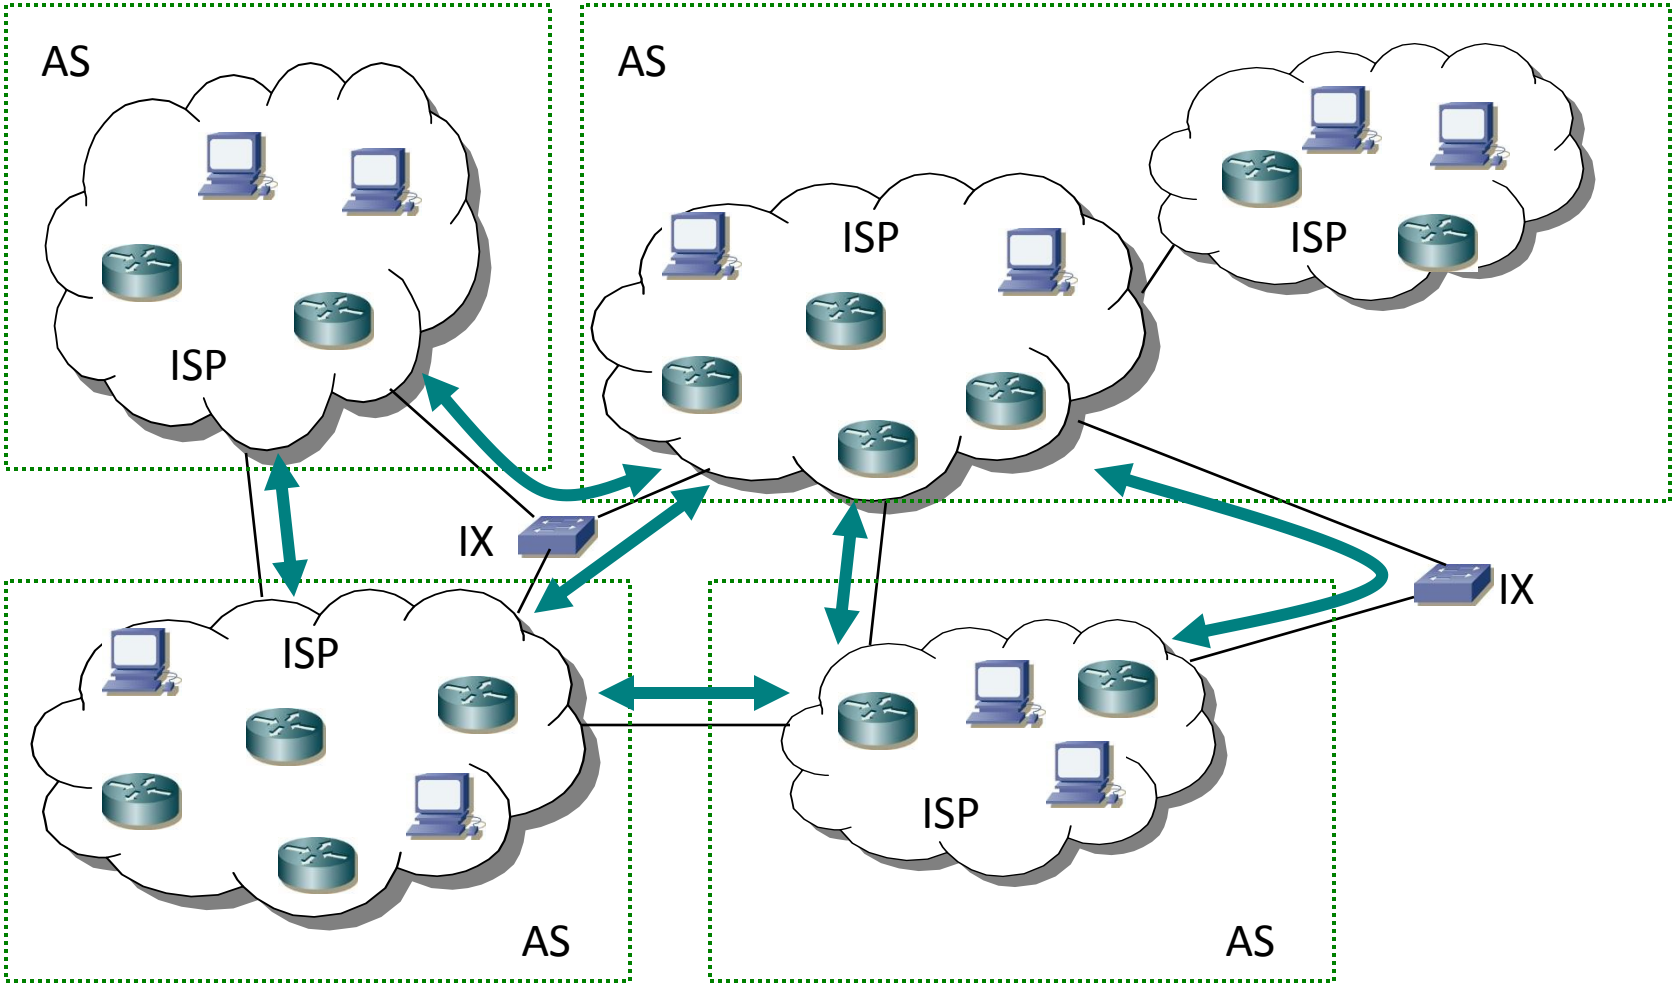

AS

- Autonomous System
- 統一のルーティングポリシのもとで運用されているIPプレフィックスの集まり
- インターネットではASの識別子として、IRから一意に割り当てられたAS番号を利用する

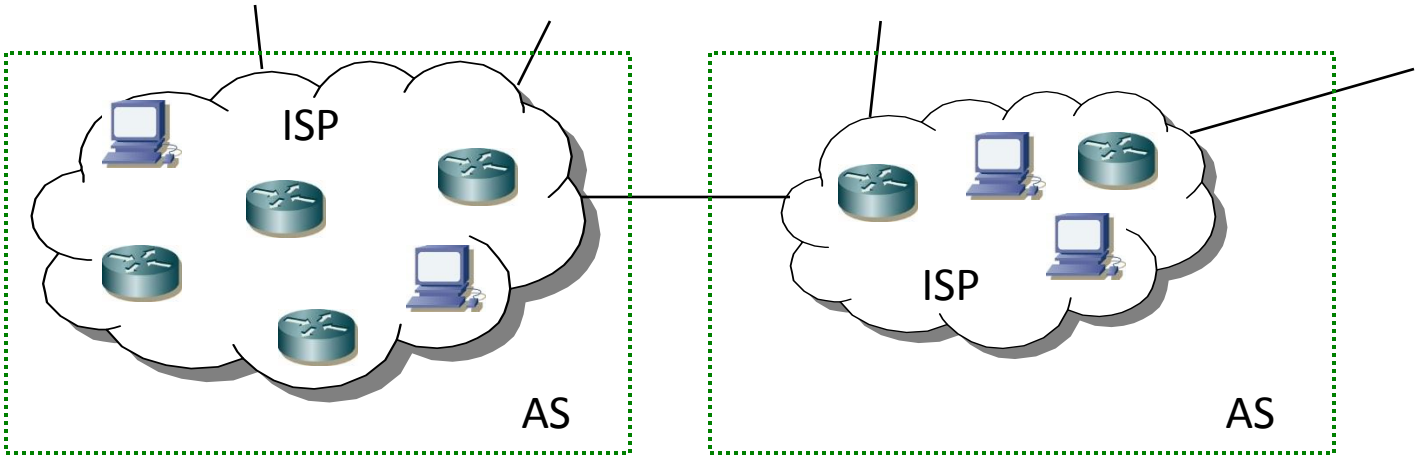

IGPとEGP

- IGP
  - OSPF、IS-IS、BGP等
  - AS内
- EGP
  - 事実上BGPのみ
  - AS間

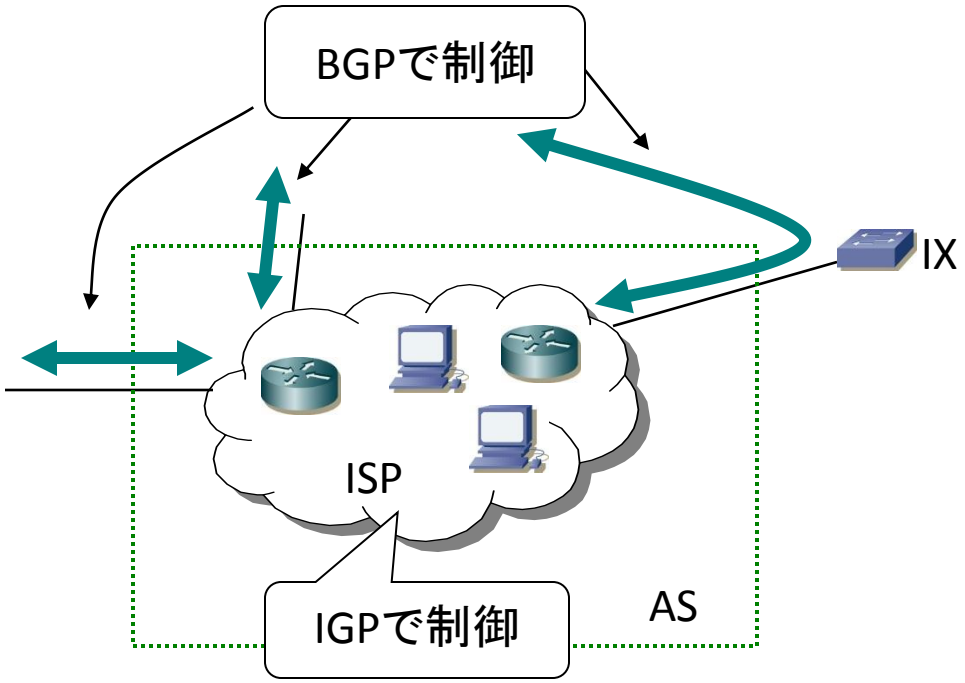

ISPでのプロトコルの利用法

- OSPF or IS-IS
  - ネットワークのトポロジ情報
  - 必要最小限の経路で動かす
  - 切断などの障害をいち早く通知、迂回
- BGP
  - その他全ての経路
    - 顧客の経路や他ASからの経路
  - 大規模になっても安心
  - ポリシに基づいて組織間の経路制御が可能

トラヒック増加への対応

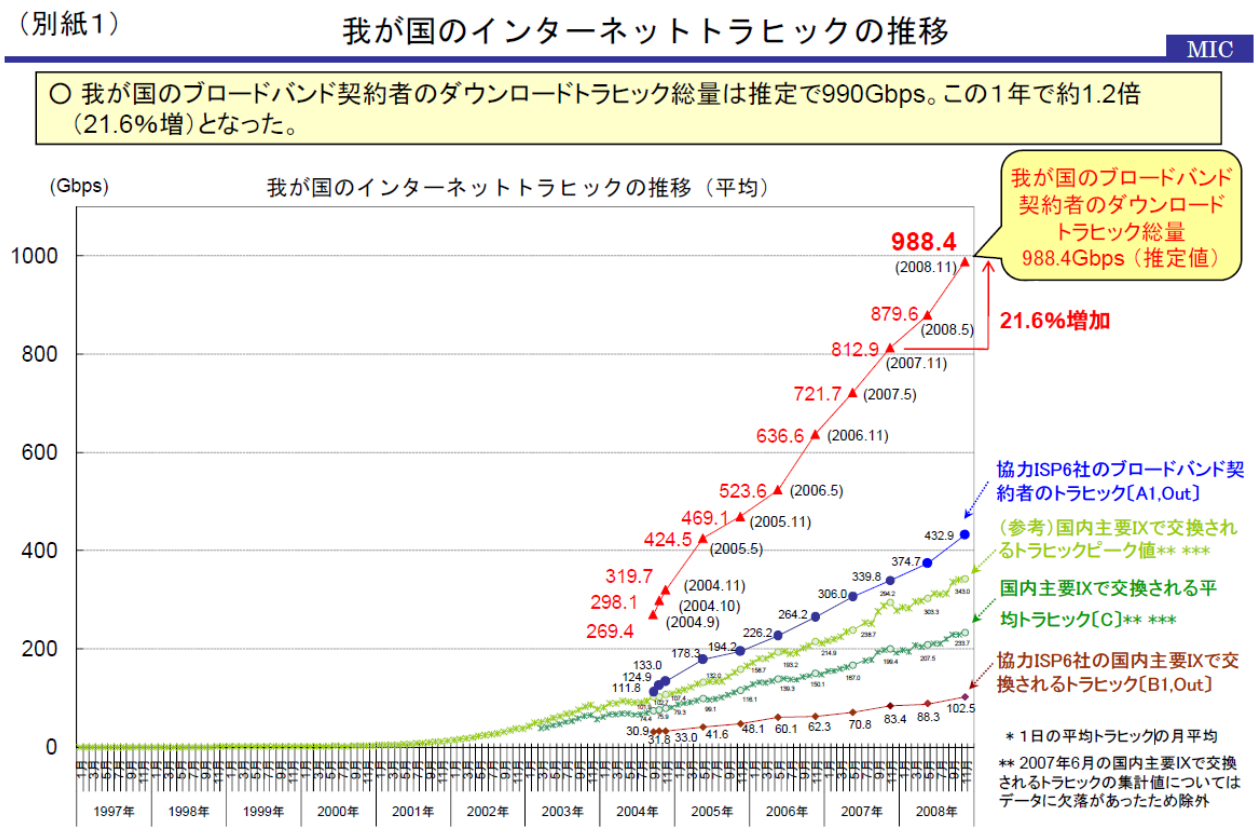

総務省：我が国のインターネットにおけるトラヒックの集計・試算(2008/11集計分)

トラヒック増加対応

- １インタフェースの上限速度がある
  - 今のところ、10GEが標準的
- ISP間、ルータ間はそれ以上のトラヒック
  - 実効帯域を何とかして増やしたい
  - しかも、冗長構成は必須

link aggregation

- 10Gbpsの回線を束ねて、ルータで論理的に一つの回線に見せる
  - 複数の回線を束ねられる
  - 束ねられる回線数には実装により、上限あり
- 回線が切れると迂回路に回る
  - 用意した帯域の半分程度しか利用できない

multipath

- OSPF Multipath
  - ISP(AS)内には有効
  - 標準技術
- BGP Multipath
  - 非標準技術だが、多くのベンダが採用
  - 構成をきちんと組めば、ISP(AS)間にも有効
- 帯域の利用効率が良い

より高速なインタフェース

- 100Gbpsインタフェースを備えたルータが市場に出て来たが・・・
  - お値段が高い
  - ポート密度が上がるまで時間がかかる

経路数増加への対応

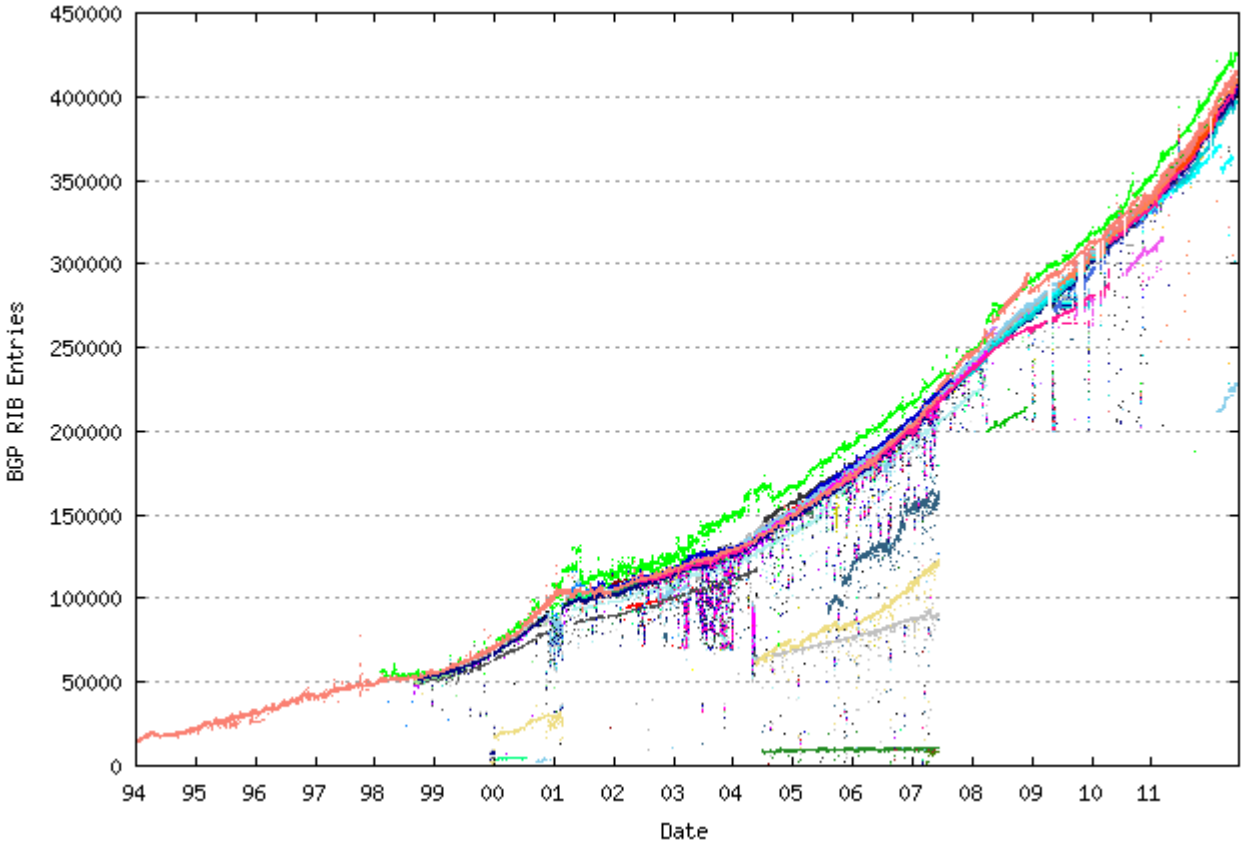

http://bgp.potaroo.net/bgprpts/rva-index.html

IPv6経路も増加中

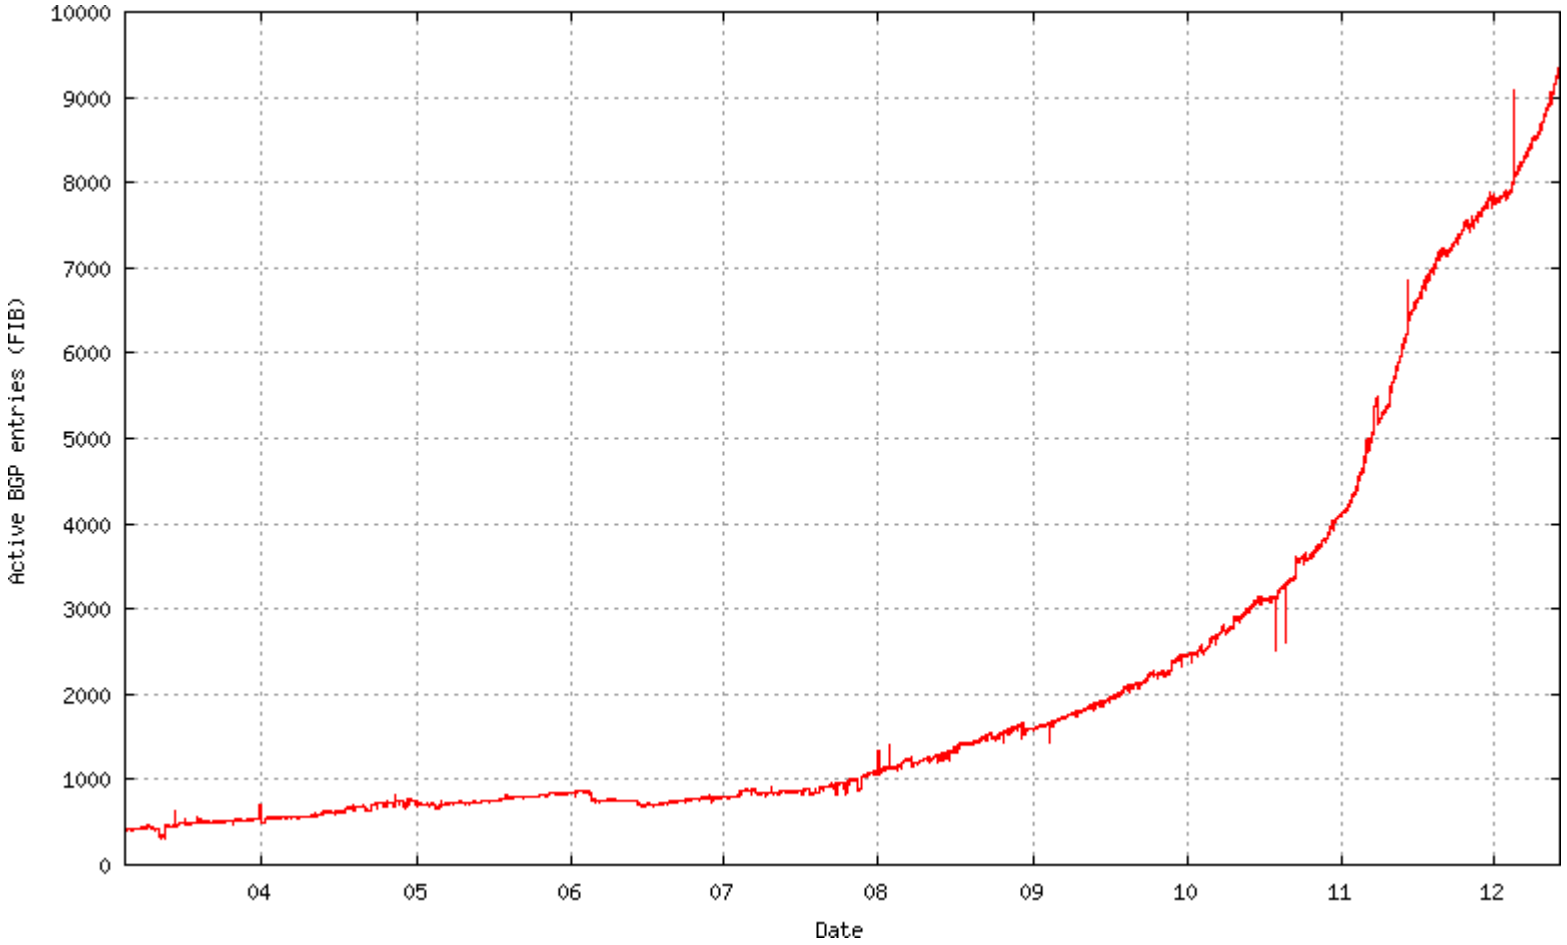

http://bgp.potaroo.net/index-v6.html

減りゆくメモリ

- IOS12.0S / 512MB メモリ

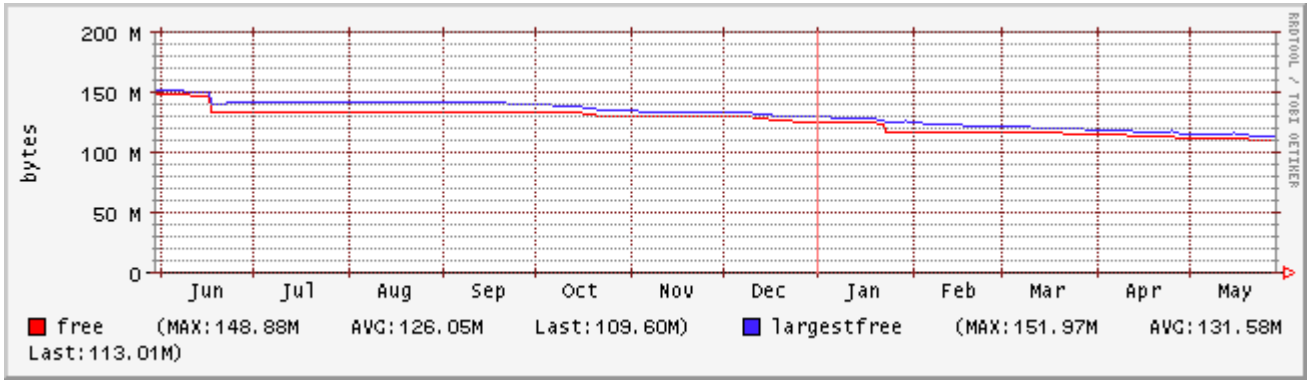

- IOS12.2 / 2GBメモリ

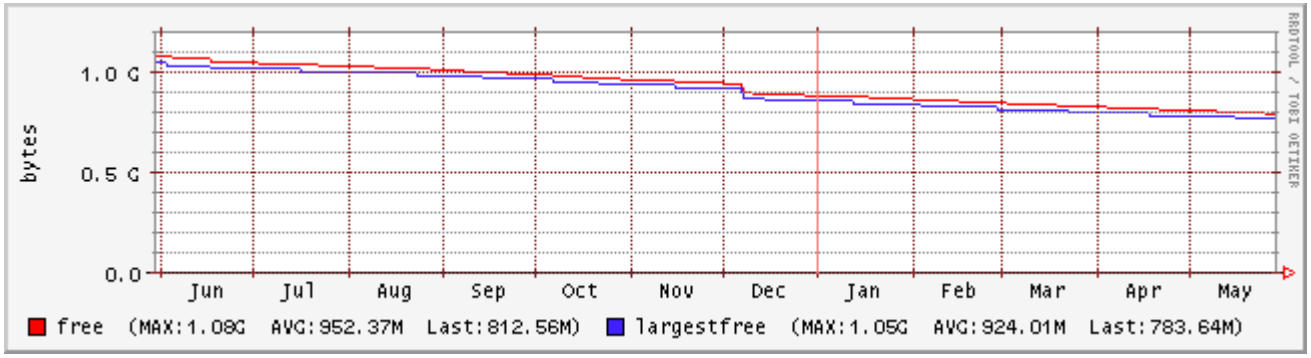

経路増加にはグッとくる解決無し

- default経路併用による運用
  - 小規模ルータで経路削り
- 泣きながら増強
  - BGPでトランジット提供している場合

OSPF

OSPF概要

- リンクステート型
  - 全ルータがネットワークのトポロジ情報を持つ
  - ネットワークに変更があれば通知
- SPFアルゴリズムによる最適経路の選択
  - リンクのコストによる優先付け
  - 同一コストの複数パスによる負荷分散
- エリアによる階層化
  - エリア境界はルータ
- 隣接のルータと情報を交換

OSPFの基本アイディア

- 準備
  - 隣接した他のOSPFルータと隣接関係を構築
- 通知
  - 各ルータが必要な情報をタイプ別にLSAとして生成
  - 隣接関係のルータにLSAを送信
  - 受信したLSAをさらに他のルータにfloodして網内に伝播
- 構成
  - 各ルータが全LSAを集め、LSDBとして保持
  - 各ルータでLSDBを元にSPF計算して最短パスを求め、経路情報を生成

OSPF RFCs

- 必読
  - [RFC2328] OSPF Version 2
- この他にもいっぱい
  - [RFC2370] The OSPF Opaque LSA Option
  - [RFC2740] OSPF for IPv6
  - [RFC3101] The OSPF NSSA Option
  - [RFC3137] OSPF Stub Router Advertisement
    :

OSPF用語

- ルータID
  - OSPFのAS内でルータを識別する32bitの数値
  - 特に指定が無い場合、ルータのインタフェースのIPアドレスから選ぶ場合が多い
  - ルータIDを変更する場合は、OSPFプロセスの再起動が必要なため、実運用では変更が発生しないようにloopbackインタフェースに付与したIPアドレスを利用する

OSPFの経路選択

OSPFとコスト

リンクコスト(link cost)

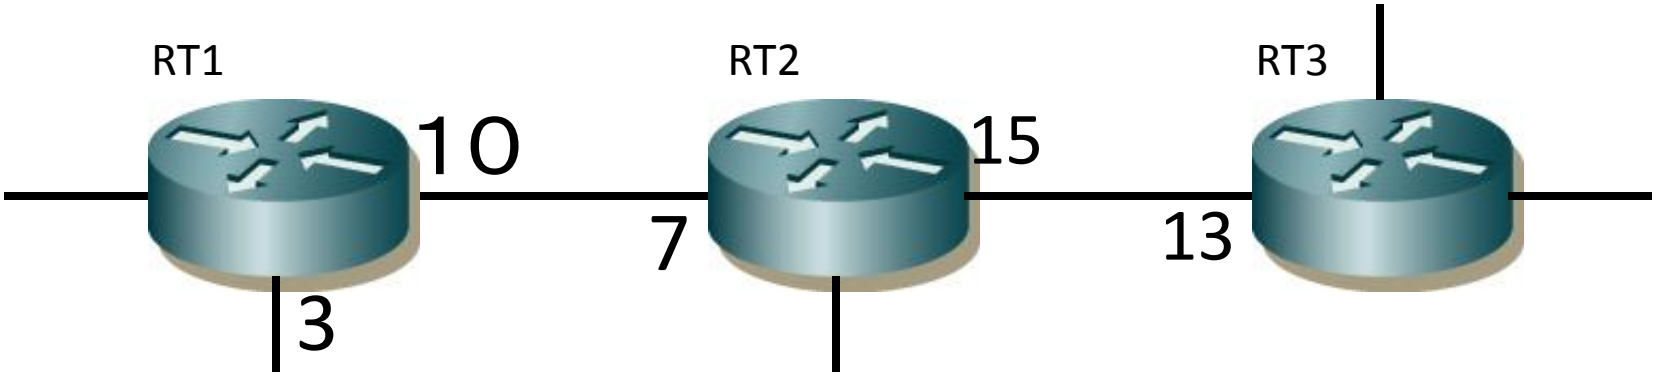

- ルータが、そのインタフェースからパケットを送出するときのコスト（負担）
- １～65535の整数を管理者が設定する

コスト(cost)

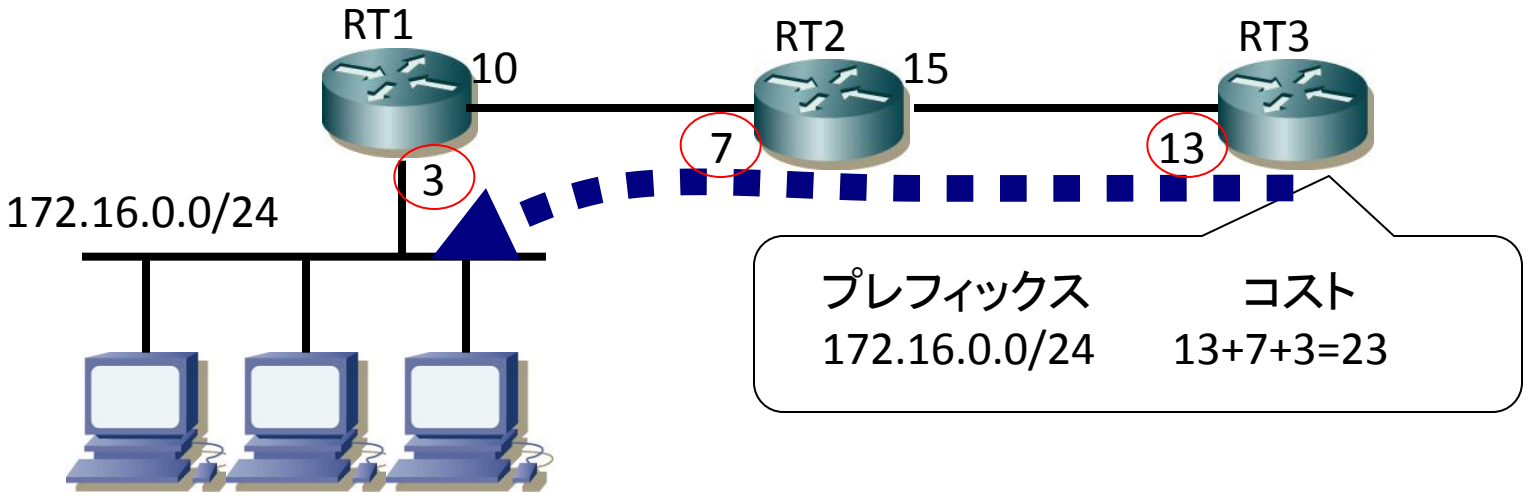

- 宛先までのパスで、パケットが出力されるインタフェースのリンクコストを合計した値

小さいコストのパスが優先

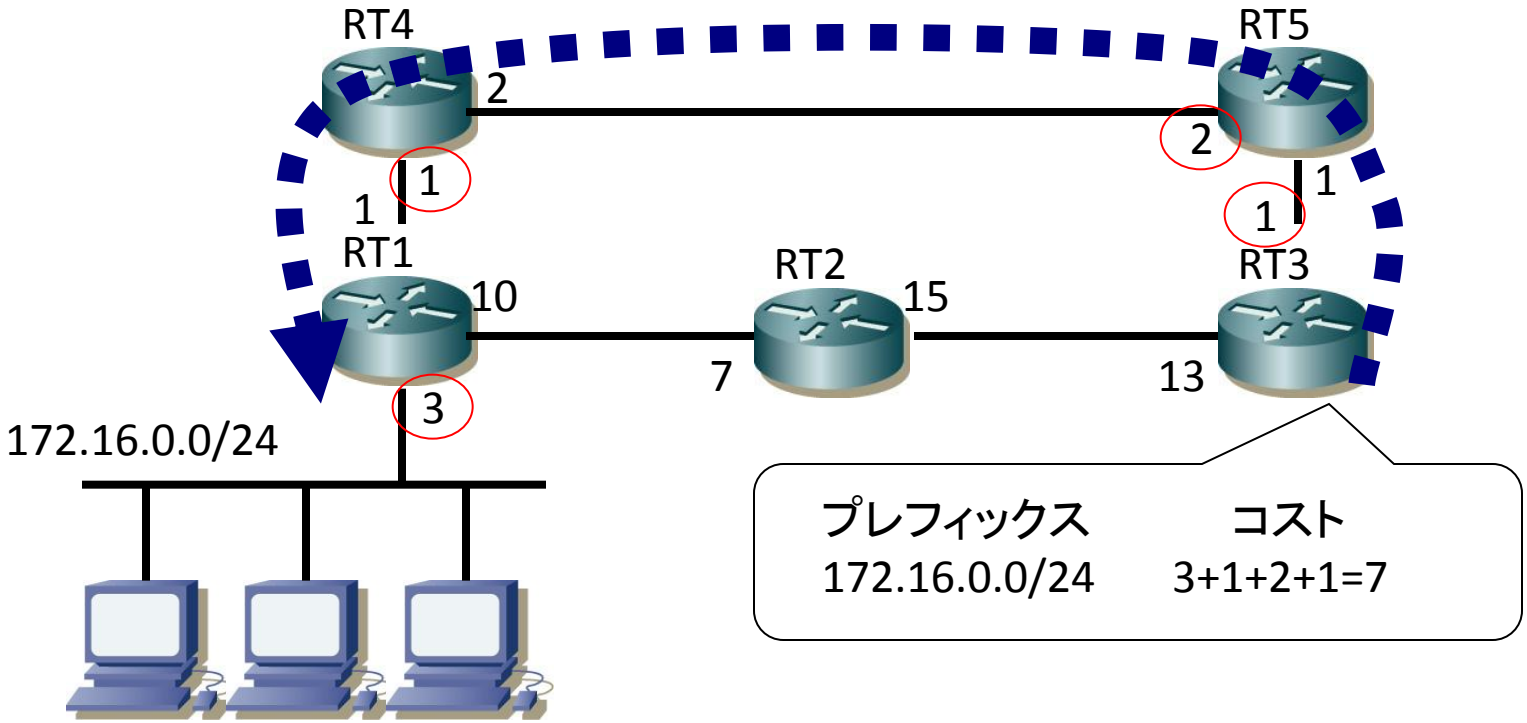

- 最も小さいコストの経路を探索するのが、SPFアルゴリズム

各ルータのSPF計算

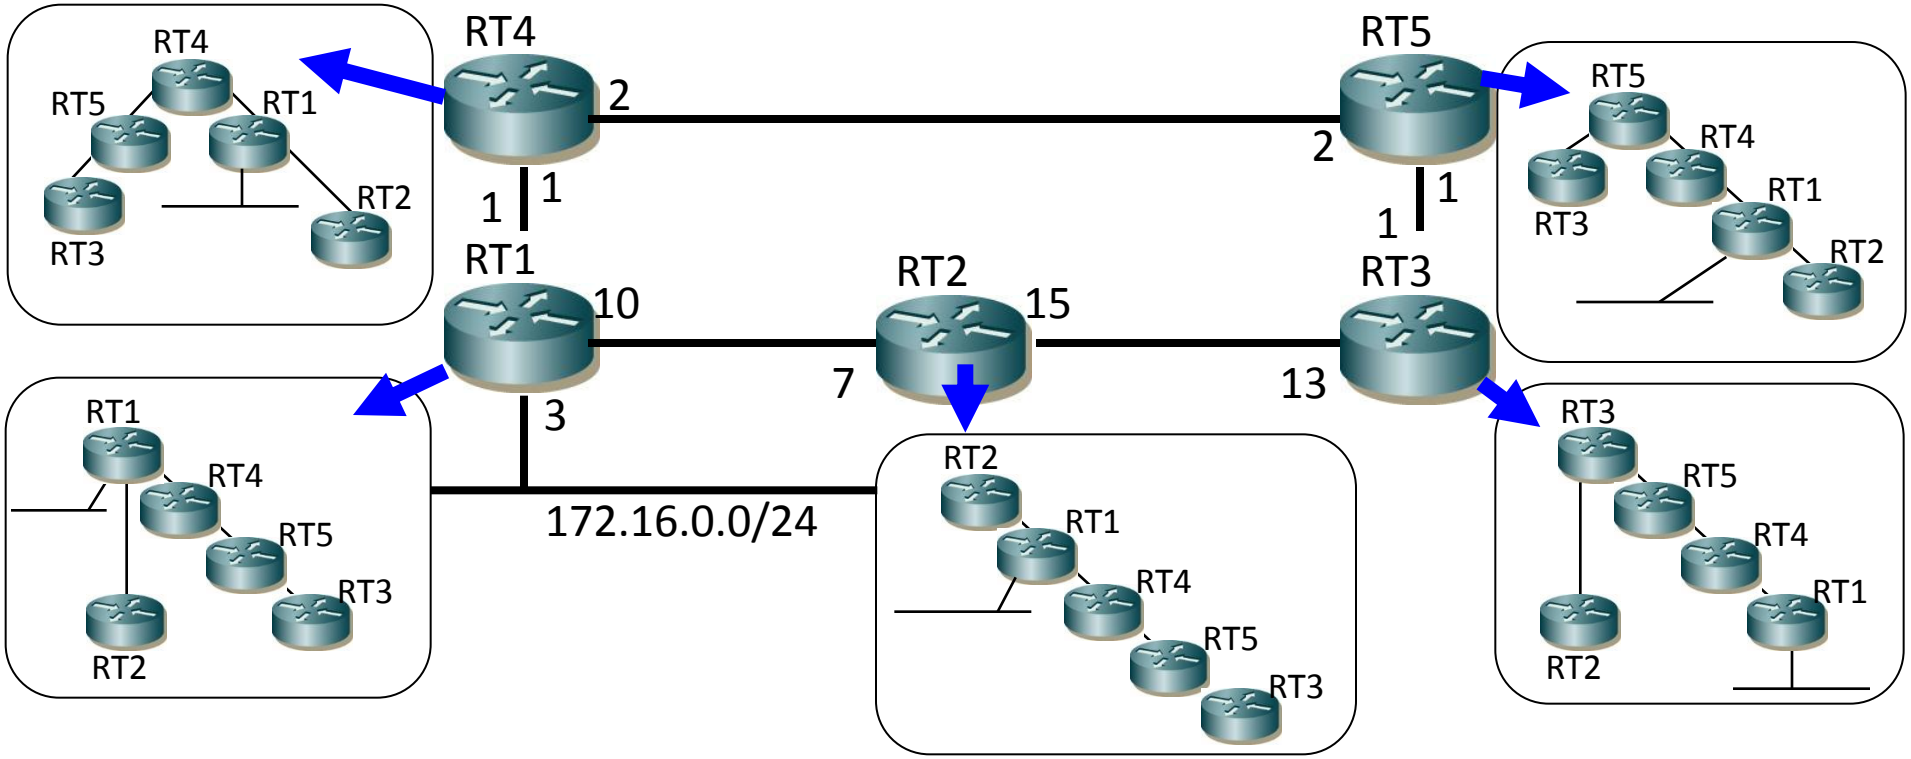

- 各ルータはSPFで自身を頂点とするツリーを計算する

同じコストのパスを複数利用できる

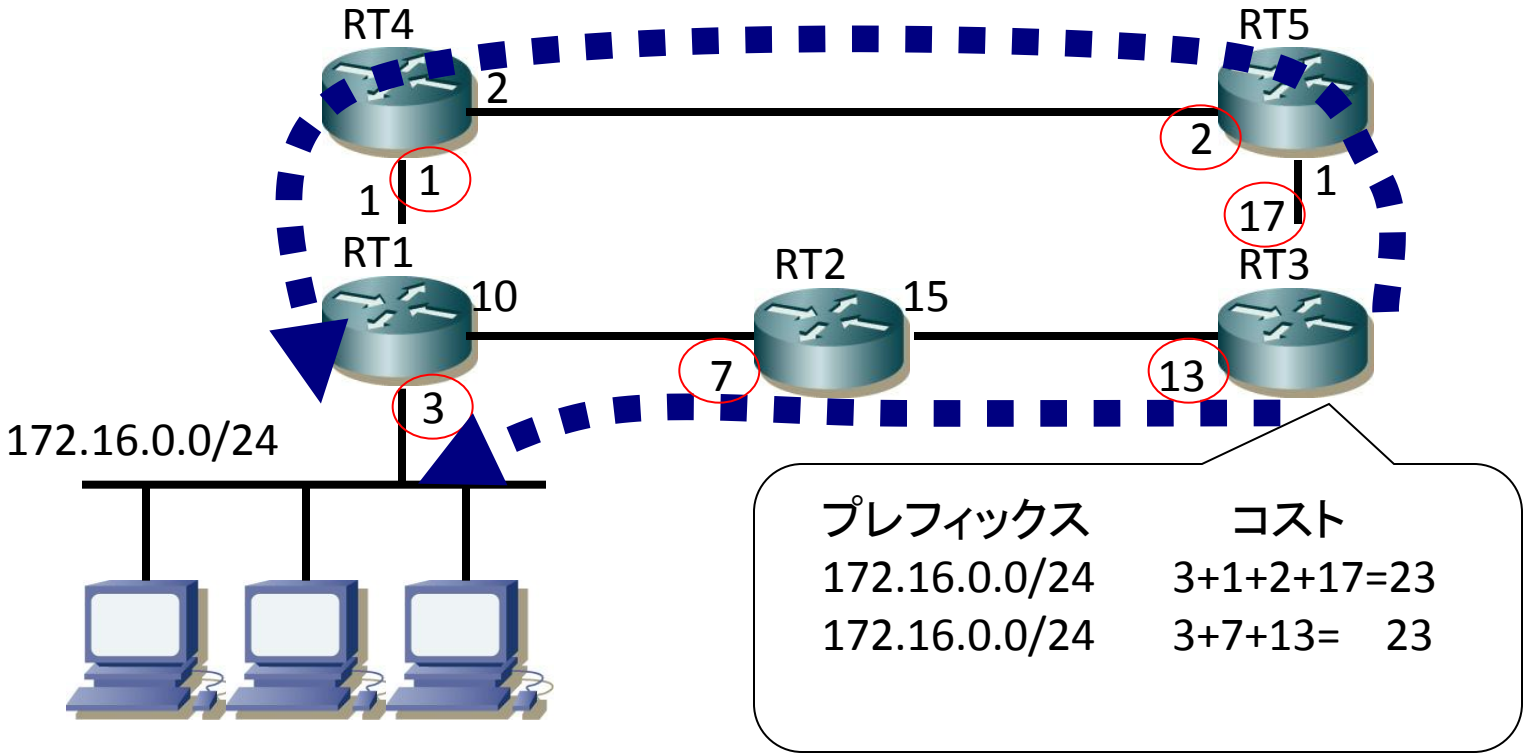

- 同じコストの経路を同時に利用できる
- Equal Cost Multi Path(ECMP)と呼ばれる

隣接関係

隣接関係の構築

ネイバとアジャセンシ

- ネイバ(neighbor)
  - 隣接する2台のルータで関係
  - 多くの場合、Helloで自動的に探索、維持される
- アジャセンシ(adjacency)
  - 経路情報を交換するネイバの関係
  - 全ネイバがアジャセンシになるわけではない

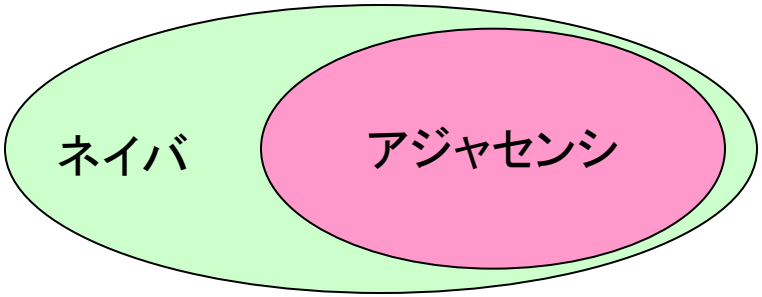

アジャセンシ

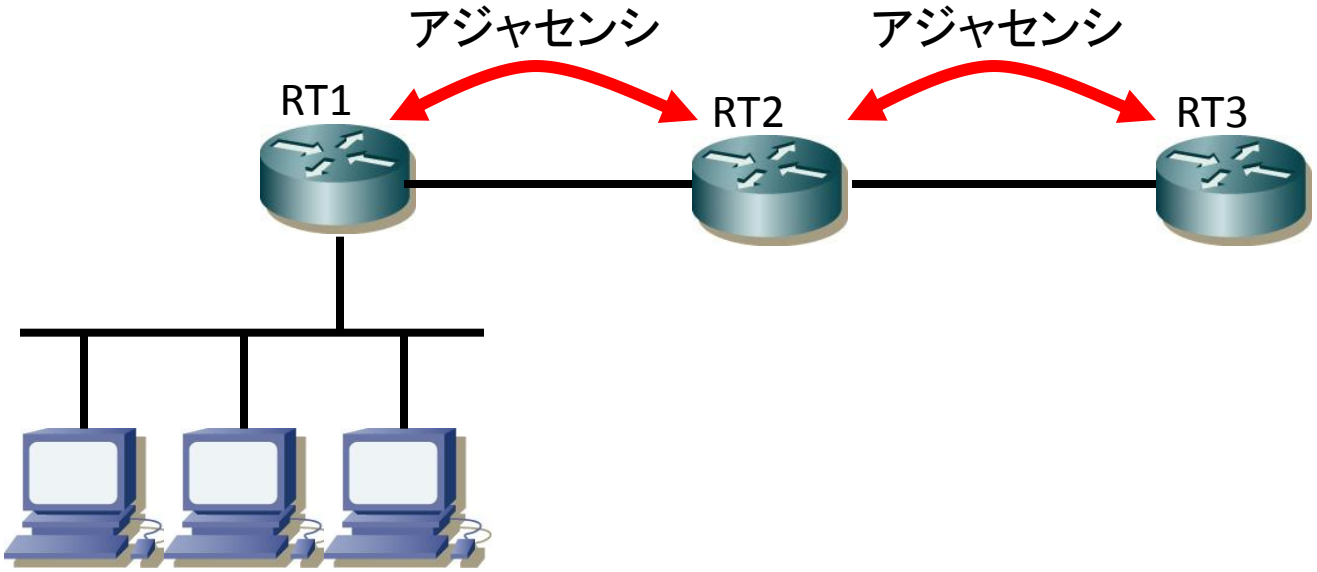

- OSPFで経路交換を行う隣接ルータのこと

代表ルータ(DR)

- Designated Routerのこと
  - ブロードキャストやNBMAネットワークで選ばれる
- アジャセンシ数を減らしたい
  - セグメントのルータ数が増えるとアジャセンシ数は猛烈に増加
  - アジャセンシ数が減れば負荷を軽減できる
  - 一つのセグメントでは、選出された代表ルータとだけアジャセンシを確立すればよい
    - 実際にはバックアップのBDRともアジャセンシを確立

DR、BDRとDR Other

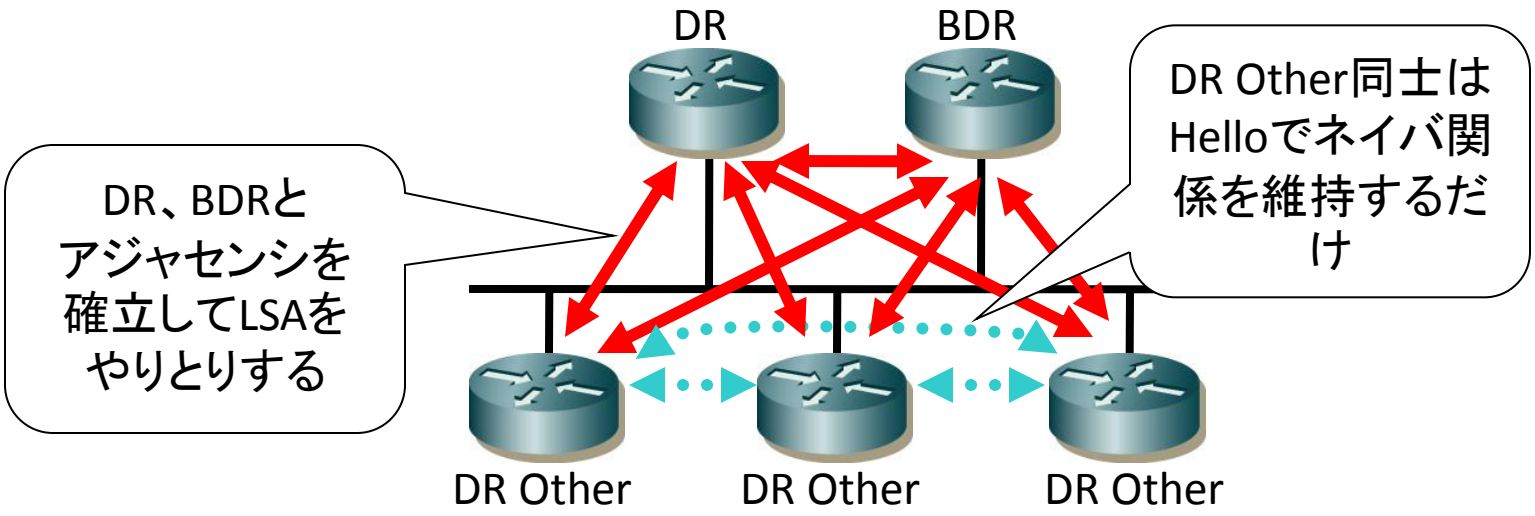

- DR Other(その他のルータ)は、DRとBDRとのみアジャセンシを確立する
- DR Other同士は、アジャセンシを確立せずにネイバ状態(2way)を維持する

DR、BDRの選出

- ルータ優先度の高いルータが選出される
  - ただし、既に選出済みの場合は置き換わらない
  - ルータ優先度はHelloで交換される
  - 優先度が同じ場合は、ルータIDの大きな方

- DRが故障したときはBDRがDRへと移行する
  - BDRがDRになるまで、新たなBDRは選ばれない
  - 不要な遷移をできるだけ防ぐため

隣接関係の状態遷移

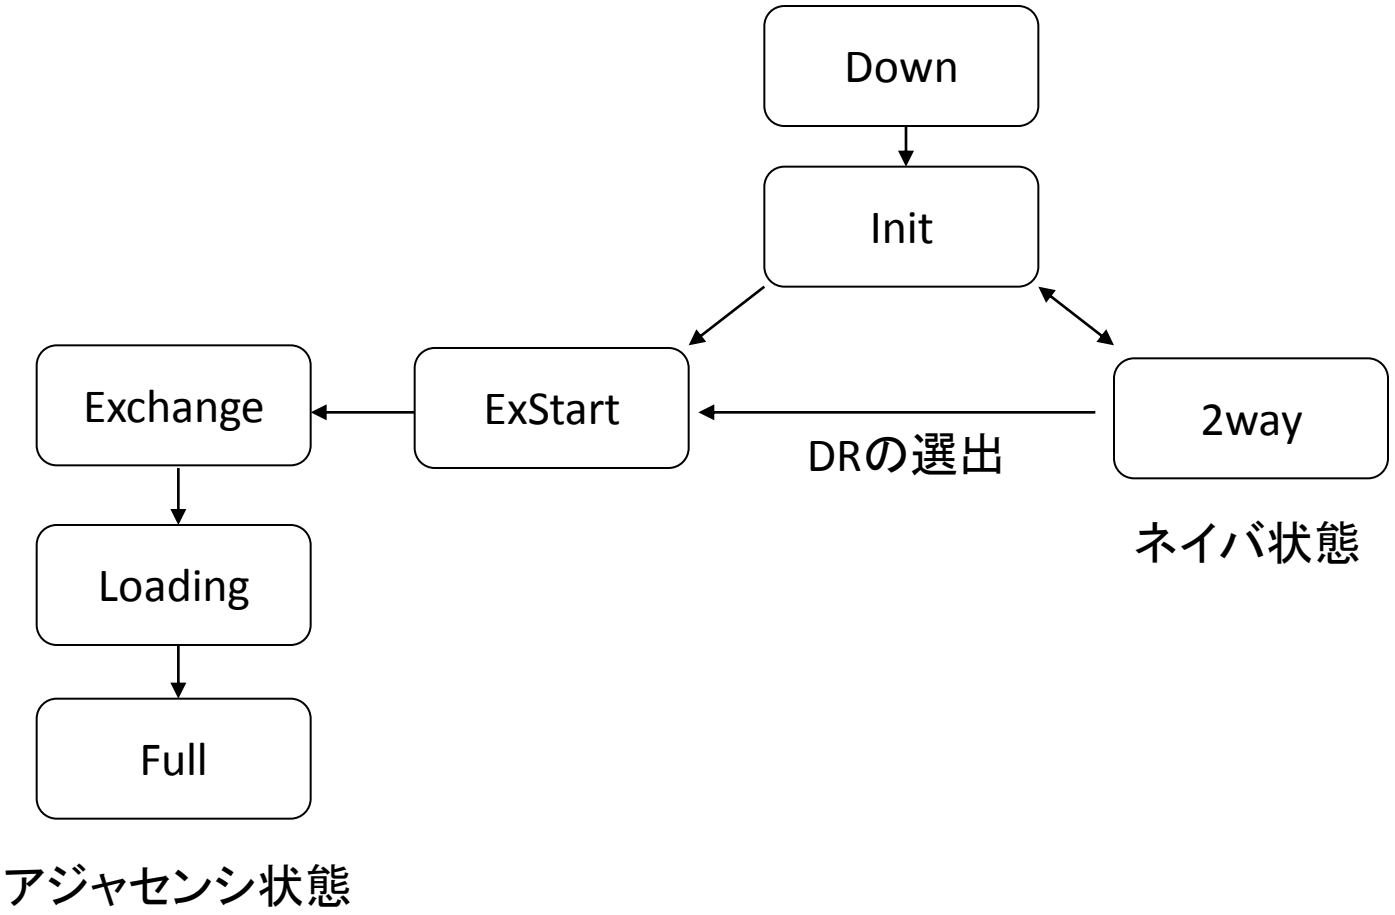
Down
Init
Exchange
ExStart
2way
DRの選出
ネイバ状態
Loading
Full
アジャセンシ状態

ネイバの確立まで

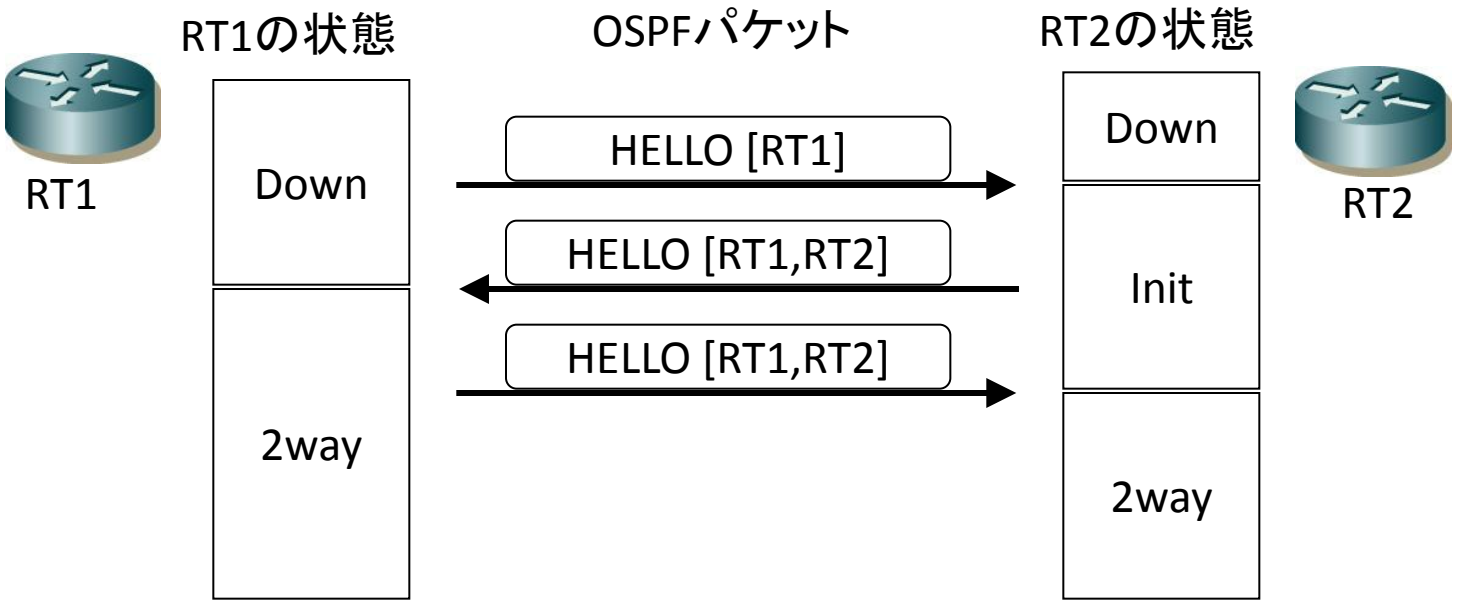

Down - Helloを受信していない状態
Init - Helloを受信した状態
2way - 受信したHelloに自ルータIDが有る状態

アジャセンシを確立する条件が整っていれば、2wayにならずにExStartに進む
point-to-pointリンクや、ルータのどちらかが既にDR、BDRの場合

ネイバ確立の条件

- Helloパケットに含まれる情報で判別
- 同一でなければならないもの
  - 認証情報
  - エリアID
  - 所属するネットワーク
    - p2pとvirtual接続を除く
  - OptionのE-bit(stubエリアかどうか)
  - hello送信間隔
  - ルータ死亡間隔秒数

データベースの同期

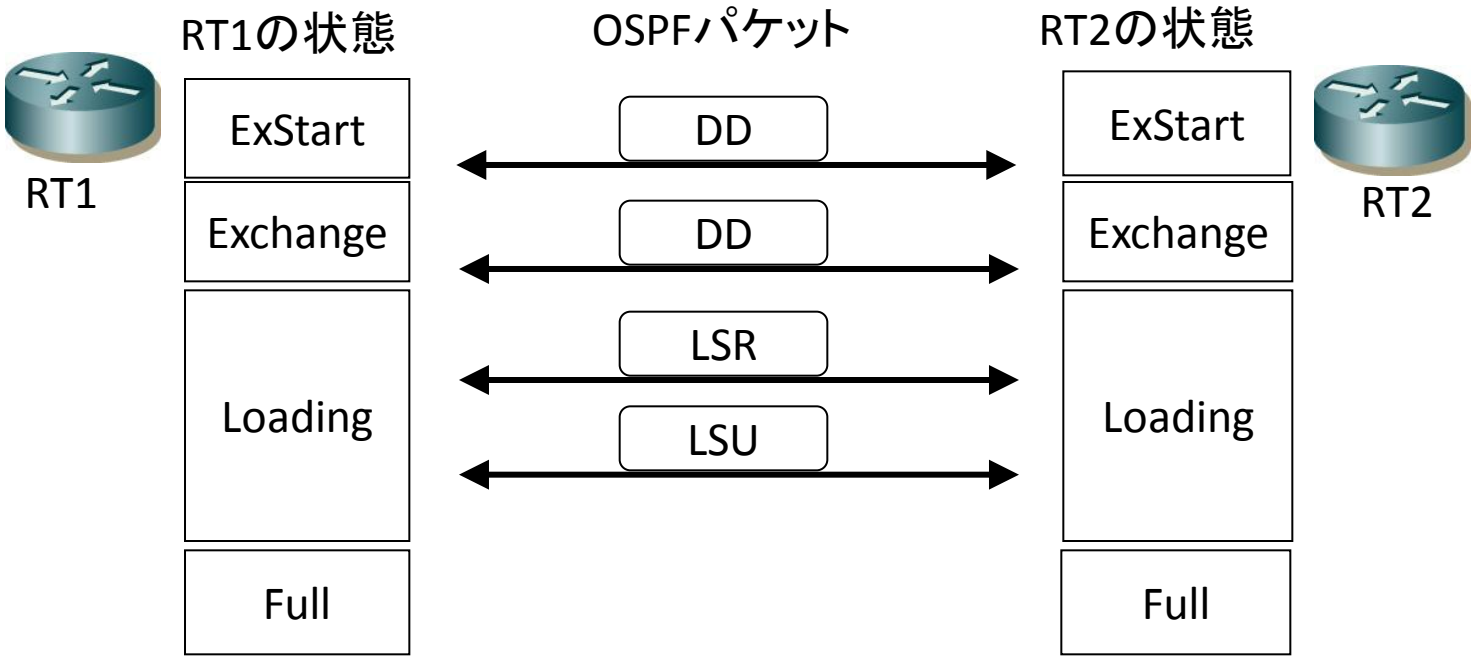

ExStart - 同期するマスターを選んでいる状態
Exchange - お互い保持するLSDBの情報を交換している状態
Loading - LSDBの差分を交換している状態
Full - LSDBが同期し、アジャセンシが確立した状態

データベースの同期条件

- Database Descriptionパケットに含まれる情報で判別
- 同一でなければならないもの
  - インタフェースのMTU
  - OptionのE-bit(stubエリアかどうか)

OSPFパケット

OSPFのパケットフォーマット

OSPFパケットの送信先

- ALLSPFRouter[224.0.0.5]
  - 全てのOSPFルータが受信する
- ALLDRouter[224.0.0.6]
  - DR, BDRのみが受信する

- p2p接続では [224.0.0.5]宛
- ブロードキャストネットワークで、
  - Hello及びDRとBDRからのLS update、LS Ackは[224.0.0.5]宛
  - DROtherからのLS update、LS Ackは[224.0.0.6]宛
- その他
  - ネイバへのunicast宛

OSPF packet header

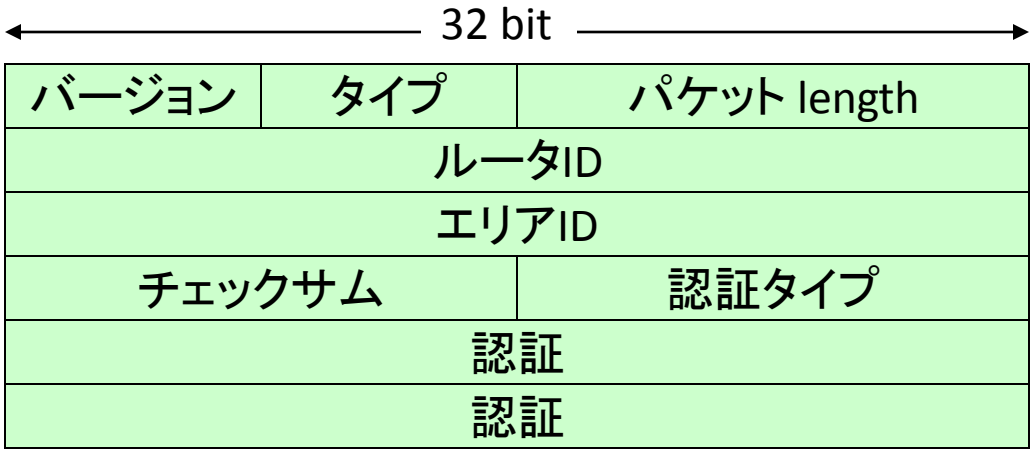

- 24-octetの固定長

タイプ:
1 Hello
2 Database Description
3 Link State Request
4 Link State Update
5 Link State Acknowledgment

認証タイプ:
1 認証なし
2 シンプルパスワード認証
3 暗号認証

タイプ1 - Hello

- ネイバの管理
  - ルータID、エリアIDの通知
  - ネイバの検出、維持、生死確認
- ルータ優先度の通知
  - DR、BDRの選出
- Optionフィールドでルータの機能の通知
  - E-bit: 外部経路が扱えるかどうか
    Stubエリアでは0、それ以外は1

タイプ1 - Hello

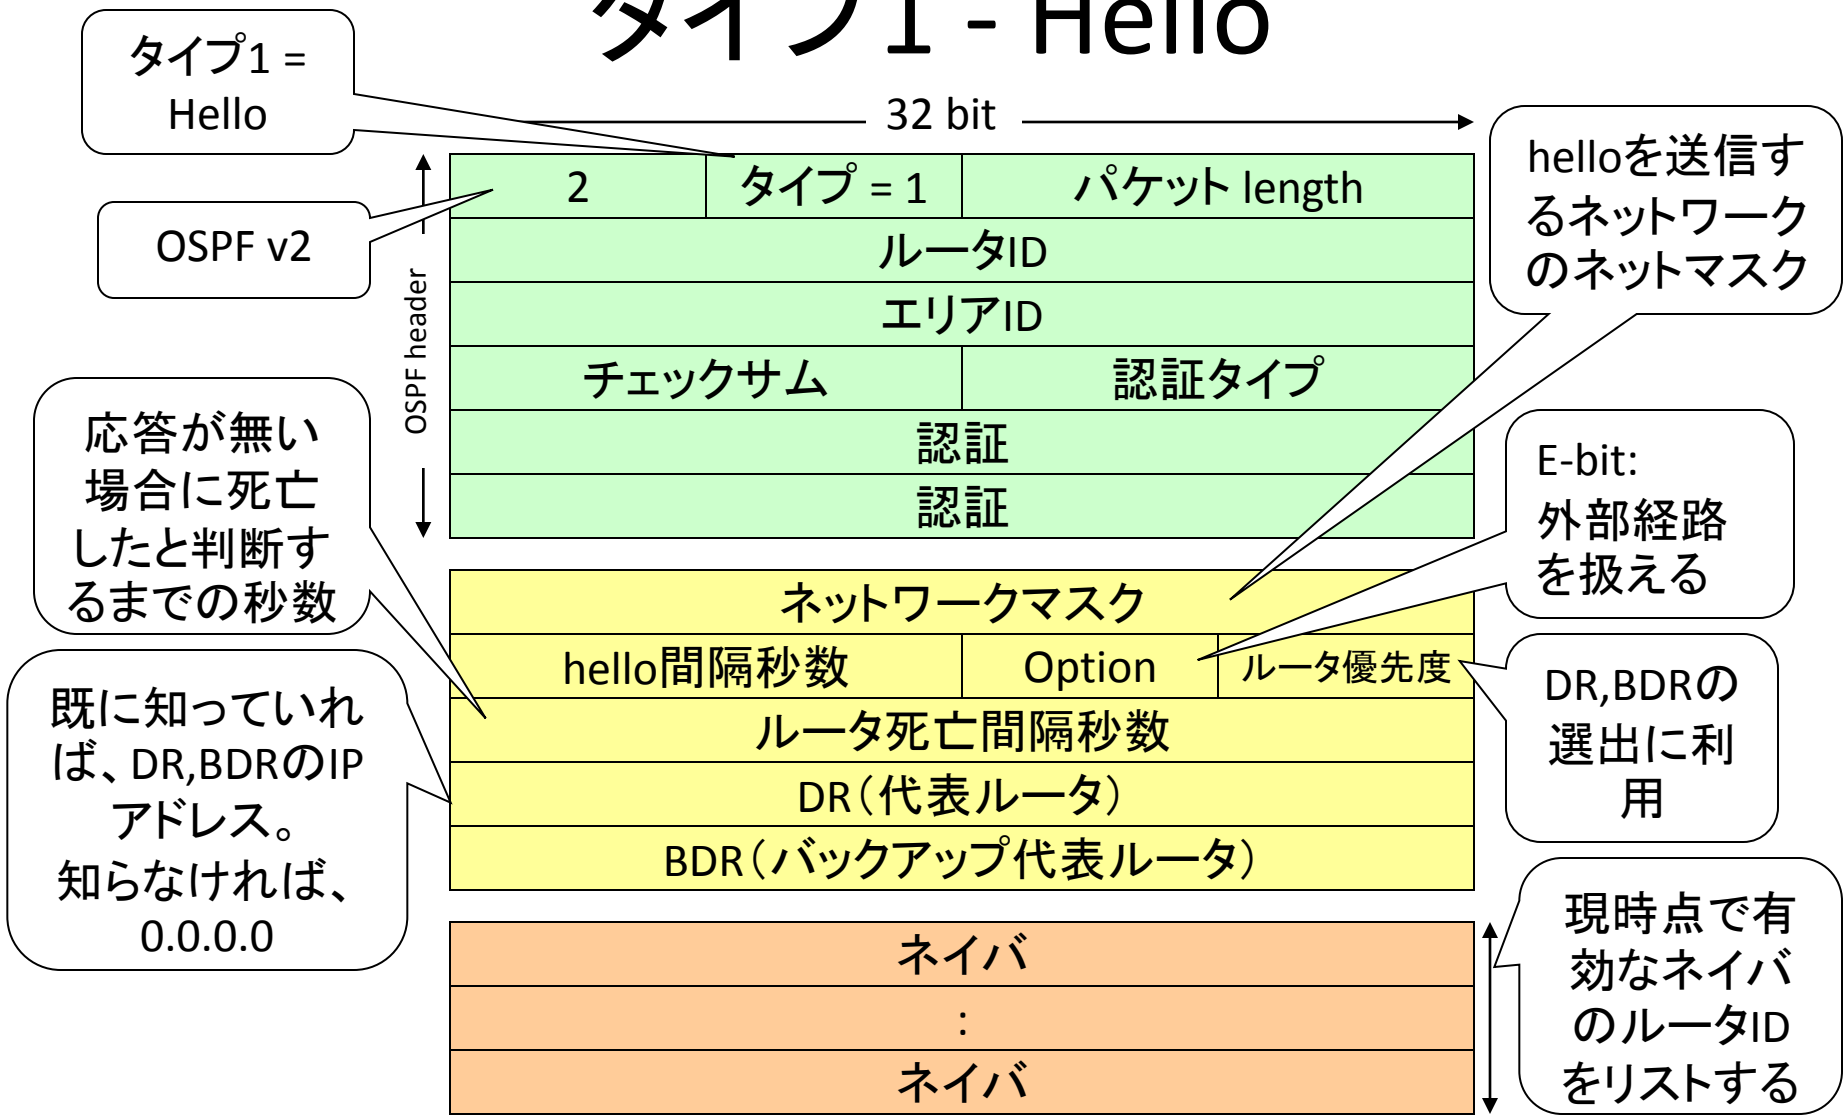
タイプ1 = Hello
32 bit
2
タイプ = 1
パケット length
OSPF v2
ルータID
エリアID
チェックサム
認証タイプ
認証
認証
OSPF header
helloを送信するネットワークのネットマスク
応答が無い場合に死亡したと判断するまでの秒数
E-bit:
外部経路を扱える
ネットワークマスク
hello間隔秒数
Option
ルータ優先度
既に知っていれば、DR,BDRのIPアドレス。
知らなければ、0.0.0.0
DR,BDRの選出に利用
ルータ死亡間隔秒数
DR（代表ルータ）
BDR（バックアップ代表ルータ）
ネイバ
:
ネイバ
現時点で有効なネイバのルータIDをリストする

タイプ2 - Database Description

- アジャセンシ確立時に、保持するLSAを通知
  - LSDBの同期をとる
  - 全LSAのヘッダのみを伝える
  - マスタとスレーブになって情報を交換
    - ルータIDの大きい方がマスタ
    - スレーブはマスタのDDシーケンス番号に同期する
- インタフェースのMTUを伝える
- Optionフィールドでルータの機能の通知
  - E-bit: 外部経路が扱えるかどうか(Stubエリアでは0)

タイプ2 - Database Description

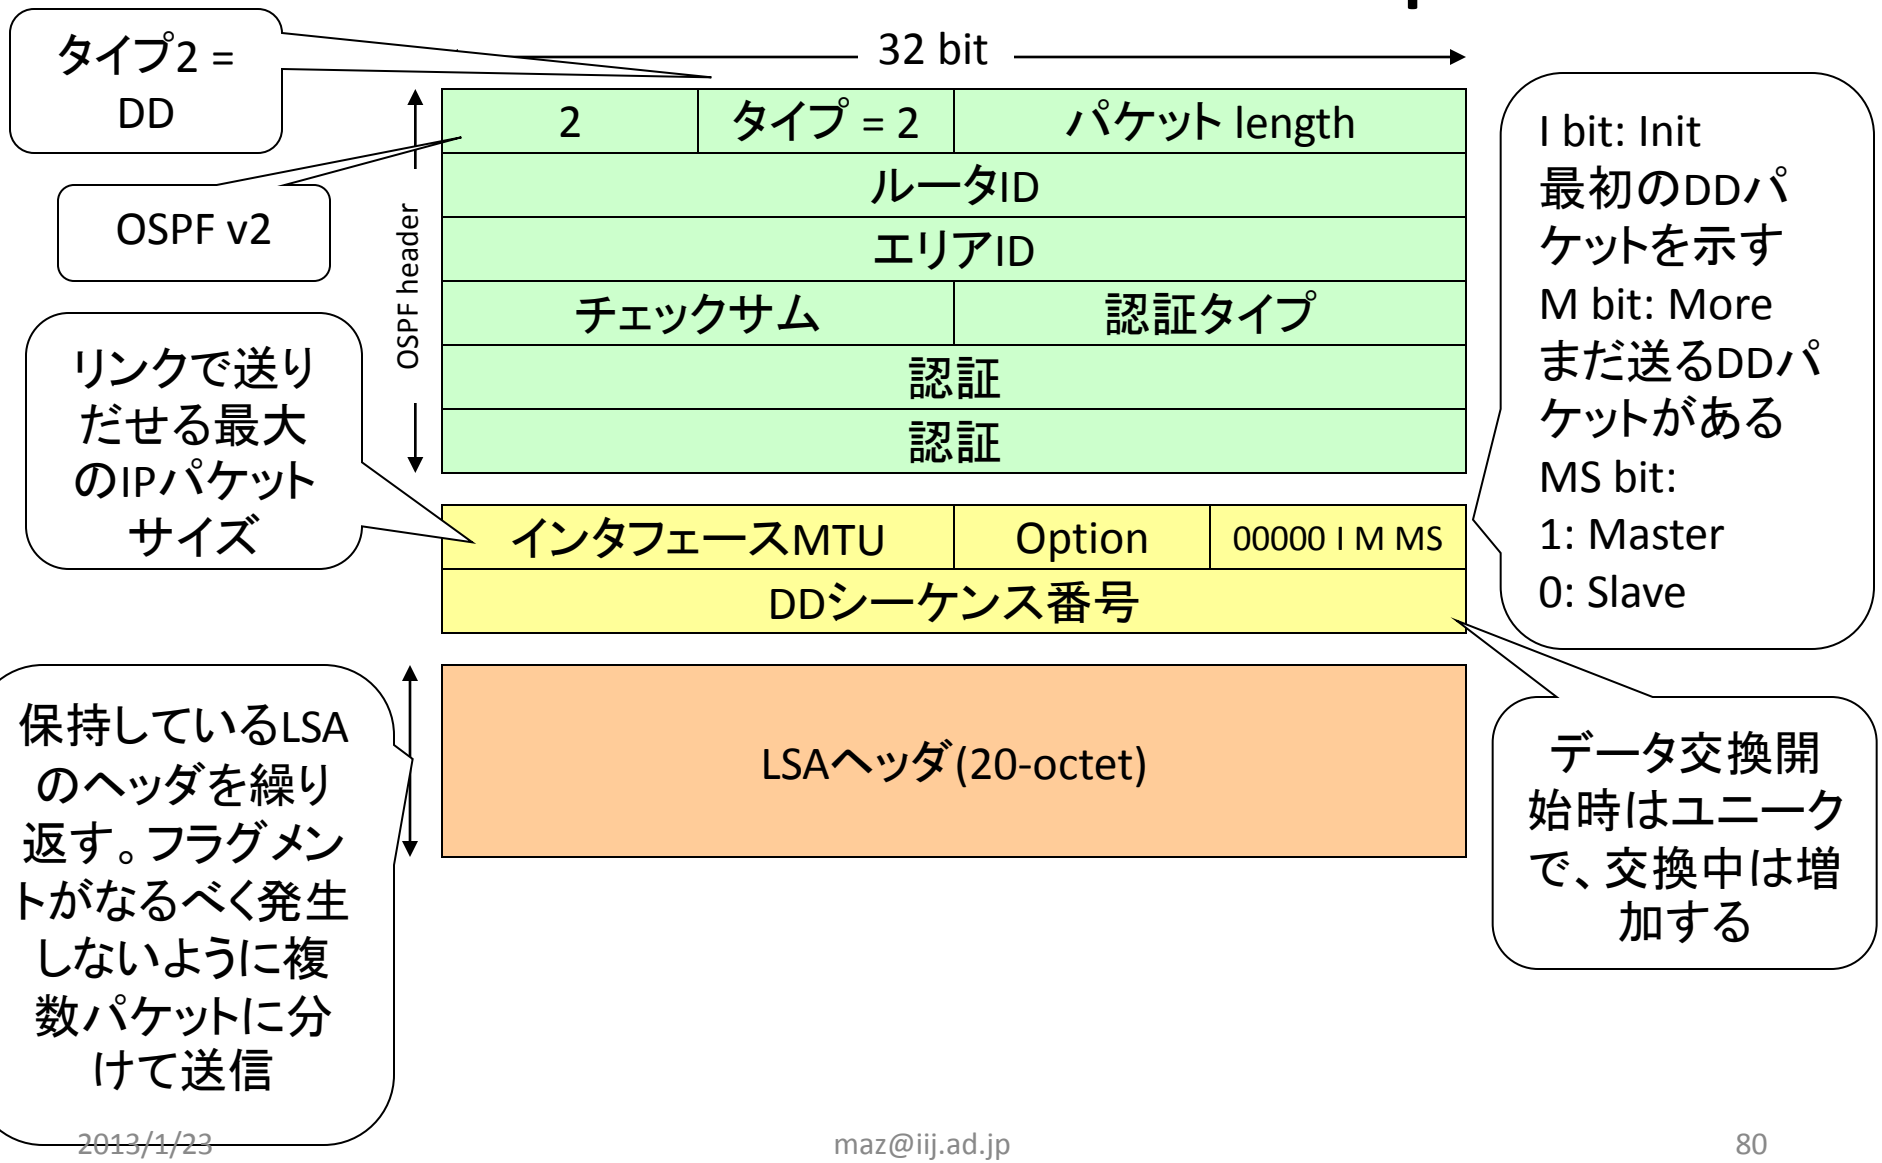

タイプ3 - Link State Request

- DDパケットでLSA情報を交換後、差分を埋めるためにLSAを要求する
  - 最新のLSAを要求
  - 保持していないLSAを要求
- LSAが識別できる情報をリストして送信する
  - LSタイプ、リンクステートID、広告元ID

タイプ3 - Link State Request

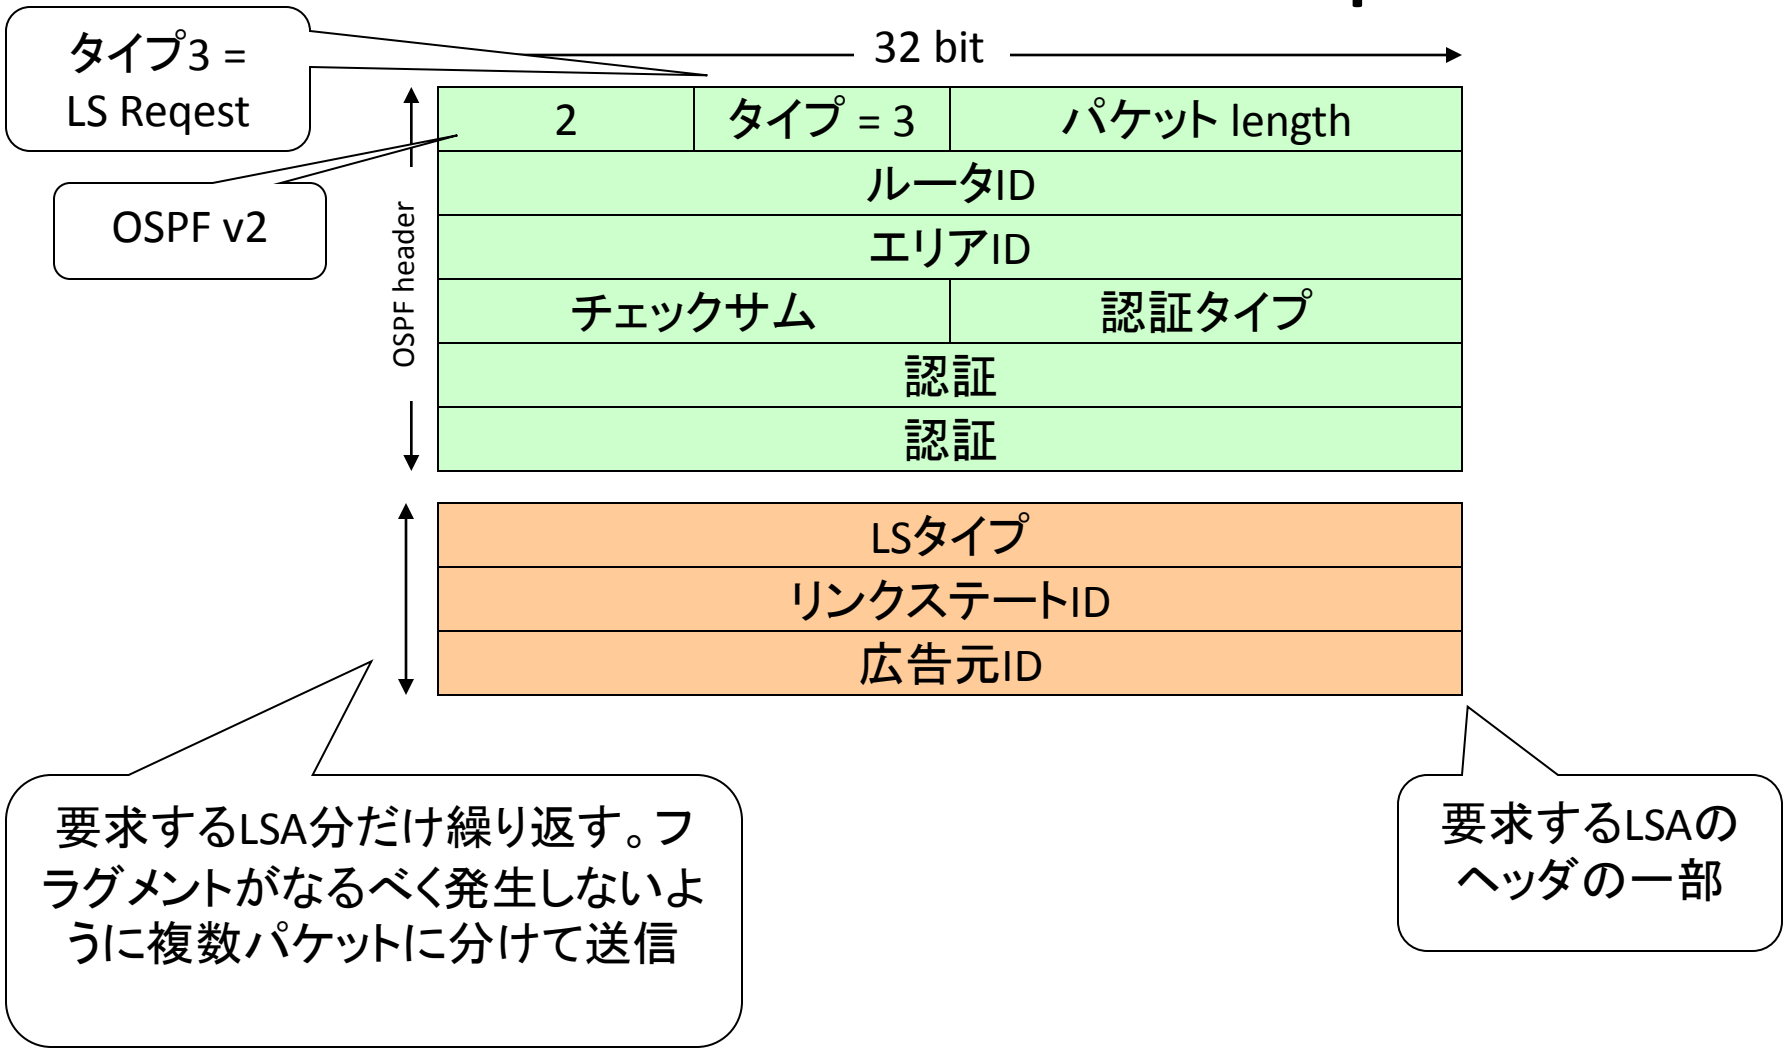

タイプ4 - Link State Update

- 一つ以上のLSAを運ぶ
- 隣接のOSPFルータまで伝播する
  - LSAの転送はHop by Hop
- 受信確認は状態によって異なる
  - Loading中の受信確認は無く、Link State Requestで必要なものが再要求される
  - アジャセンシ確立(Full)後はアジャセンシからLink State Acknowledgmentが返信される

タイプ4 - Link State Update

タイプ5 - Link State Acknowledgment

- 受信確認を通知する
  - LSAのヘッダを通知する
  - これで確実にLSAが伝わったことを保証する
- 一つ以上の受信確認を運ぶ
  - アジャセンシ確立(Full)後に利用

タイプ5 - Link State Acknowledgment

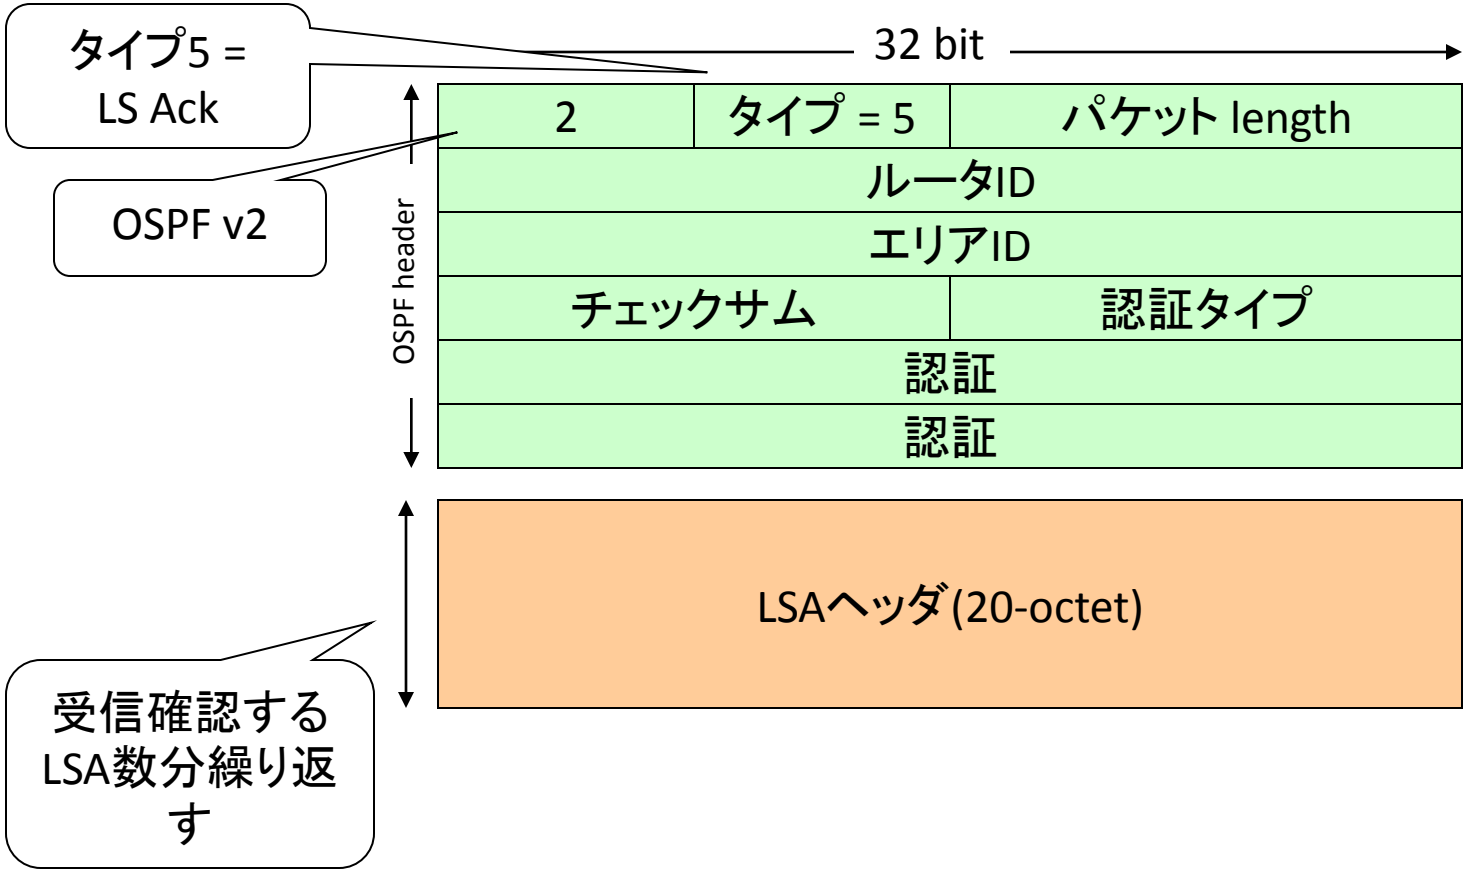

LSAの伝播と管理

LSAの管理を解説する

OSPFの再計算

- トポロジの変化等があれば、新規のLSA生成
  - 接続断や新規ネットワークの接続

- 検知
  - ルータがネットワークの変更を検知
- 通知
  - 新規LSAを生成して伝播
  - LSDBの更新
- 再構成
  - 各ルータでSPFを計算して経路情報を更新

LSAの伝播

- LSAはLSUパケットでアジャセンシに広報される
  - LSUパケットは複数のLSAを運べる
- 受信したLSAには受信証明としてLS ACKを返信
  - 伝播したことを明確にするため

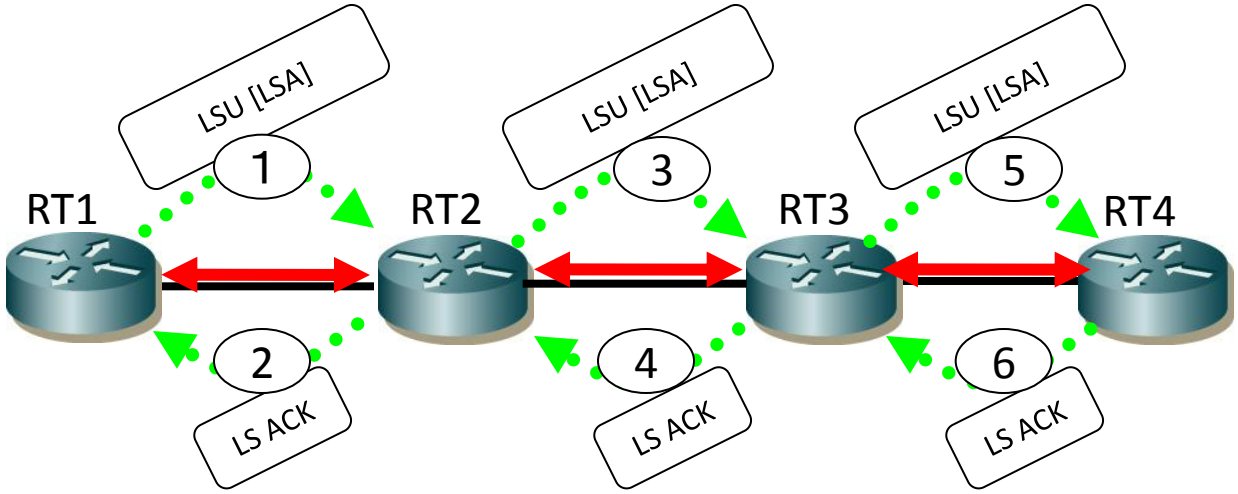

LSAのaging

- ルータは保持する全てのLSAに対して、生成されてからの経過秒数を管理する
- Max Age(60分)に達するとLSAが消される
  - LSAは生成元が定期的にリフレッシュする
  - 幽霊LSAを無くせる

LSAのリフレッシュ

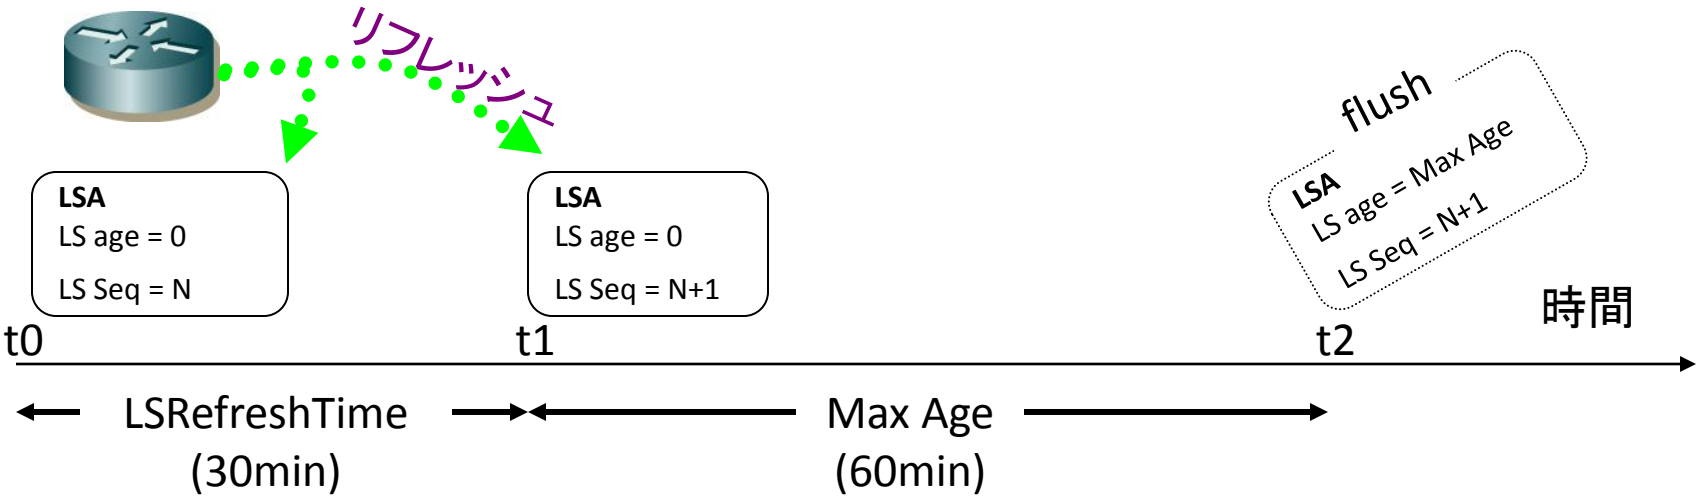

- LSAの生成元はリフレッシュ時間(30分)がくると新規にLSAを生成して広報
  - 変化が無くても生成される
- リフレッシュされないLSAはMaxAge後に利用されなくなる

OSPFと外部経路

外部経路の扱いを解説する

OSPFの中と外

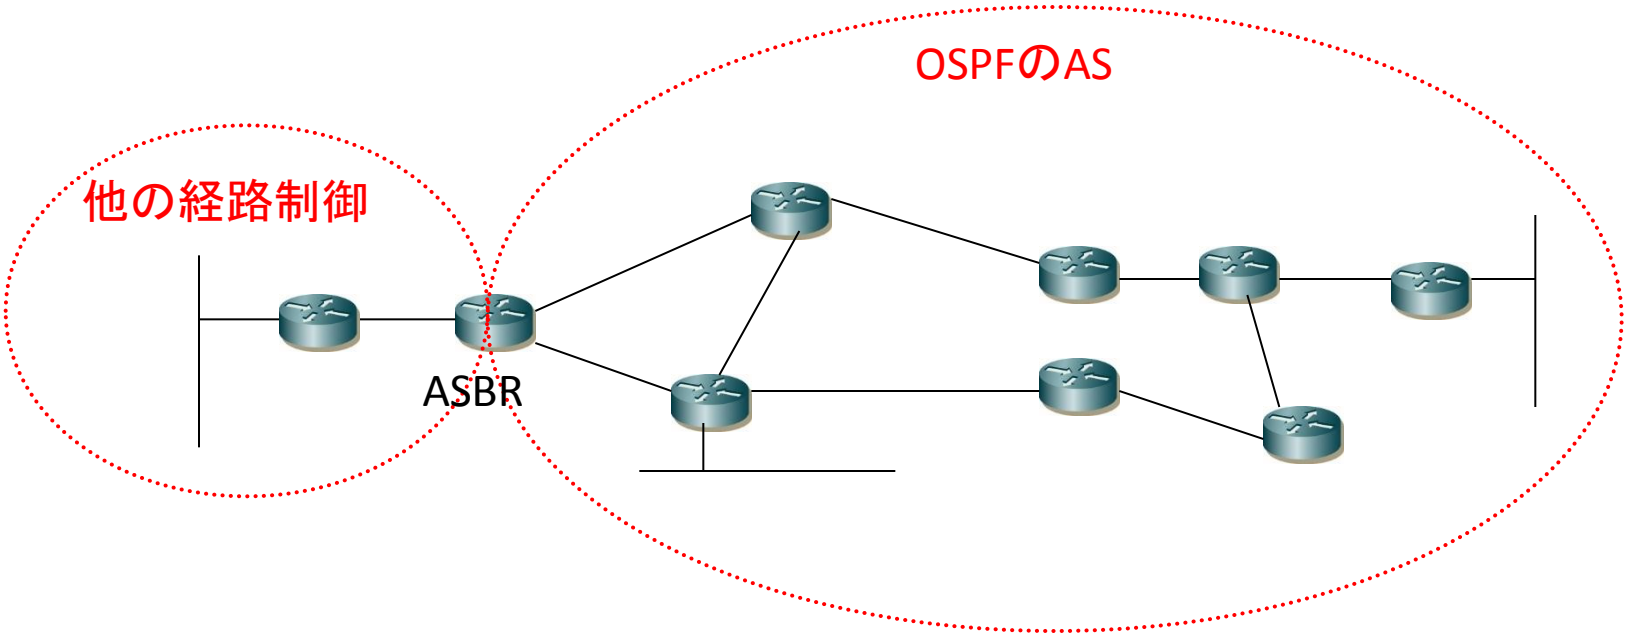

- OSPFで経路制御しているルータのグループがAS
- 他の経路制御との接点になっているルータがASBR

OSPFのASとASBR

- AS - Autonomous System
  - 共通のプロトコル（OSPF等）で経路情報を交換するルータのグループ
  - BGPなどでいうASとは概念が異なる
    - インターネットでのASはBGPのASを指す場合が多い
  - ここでは誤解を避けるためOSPFのASと明記する
- ASBR – AS boundary router
  - AS境界ルータ
  - 外部の経路（static等）をAS内に広報するルータ

外部経路(external route)

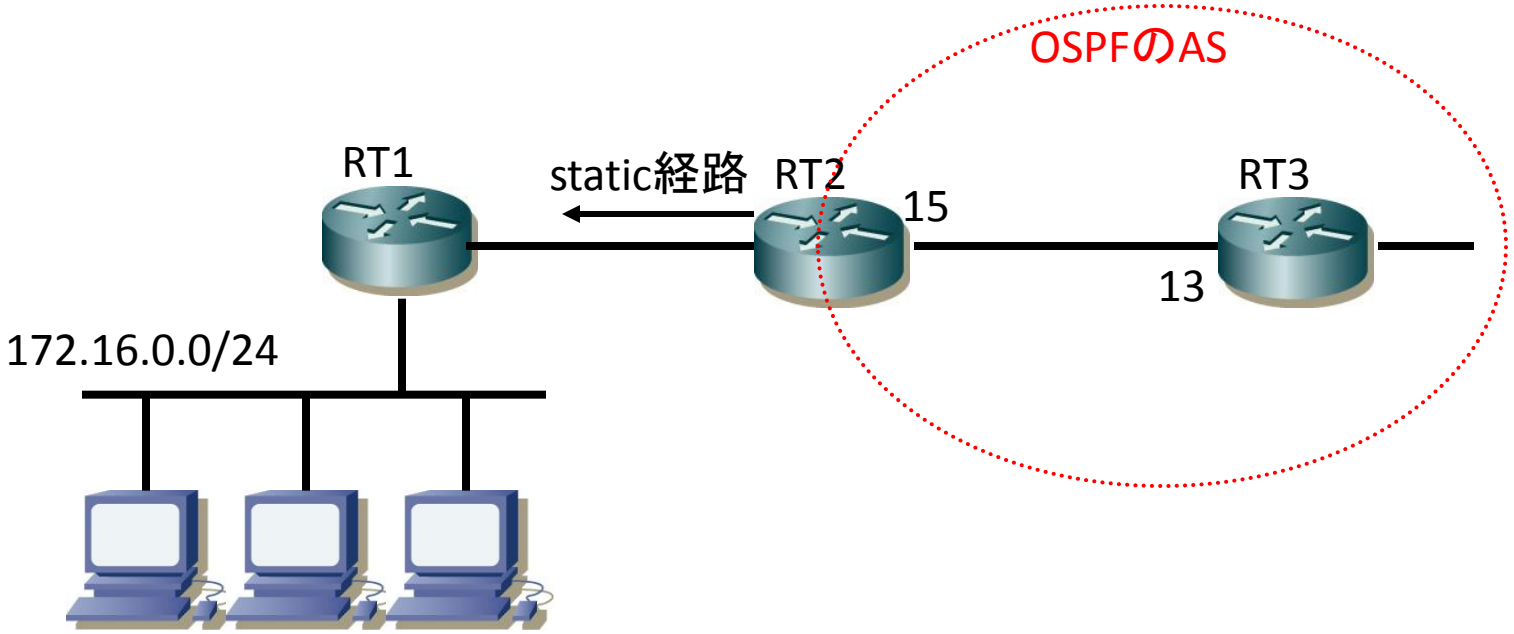

- RT2はstatic経路をOSPFのAS内に広報できる
- 外部経路を広報する際にメトリックを付加できる

外部経路メトリック

- Type 1　- リンクコストと同様に加算される
  - 同じ宛先のType 1外部経路があった場合、途中リンクのコストも加算して、もっとも小さなコストの経路が選ばれる
- Type 2　- とにかく小さな値が選ばれる
  - 同じ宛先のType 2外部経路があった場合、もっとも小さなType 2メトリックの経路が選ばれる
  - 同じType 2メトリックの場合、転送先アドレスまでのコストがもっとも小さな経路が選ばれる
- 同じ宛先のType 1とType 2の外部経路があった場合、Type 1の経路が選ばれる

Type 1 外部経路

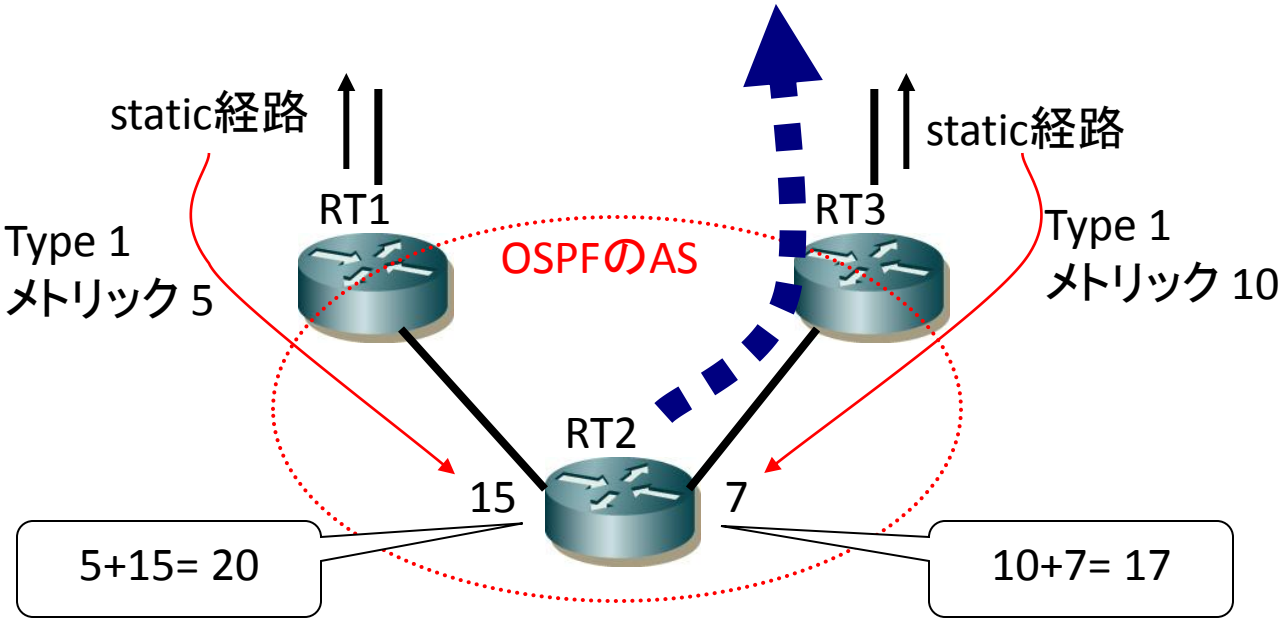

- リンクコストの加算の結果、RT3が広報する外部経路が優先される

Type 2 外部経路

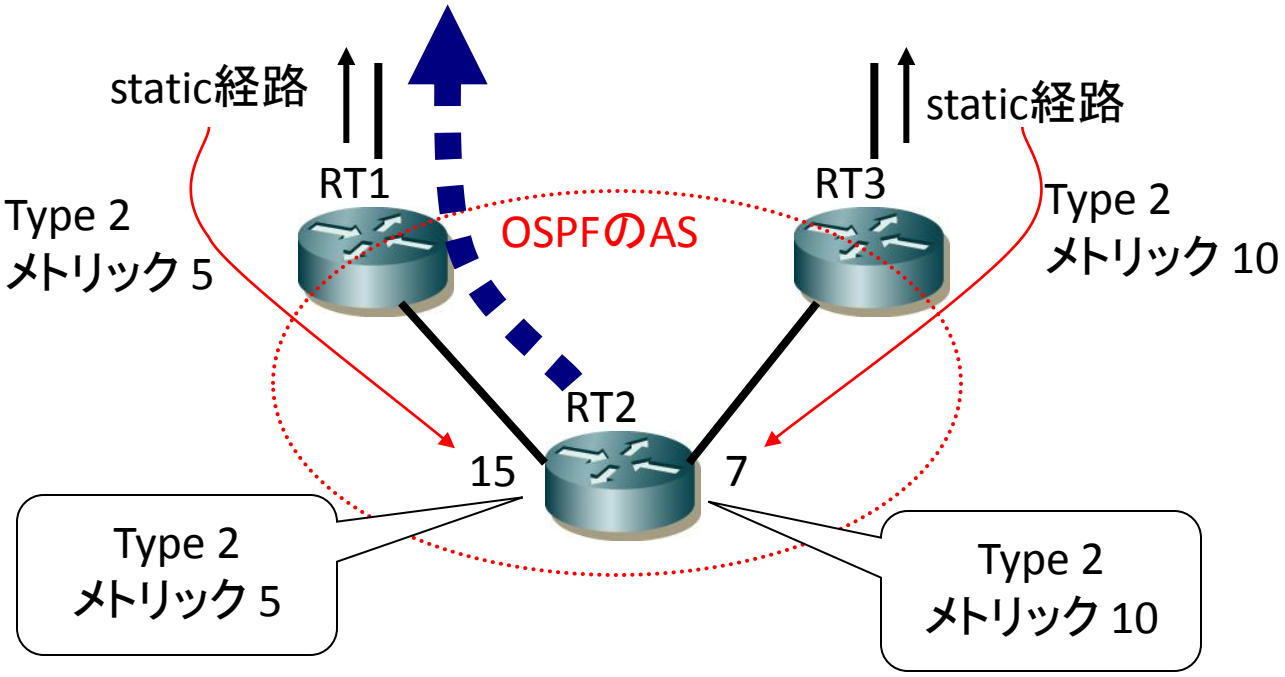

- 小さなType 2メトリックを持つRT1からの外部経路が優先される

外部経路の混在

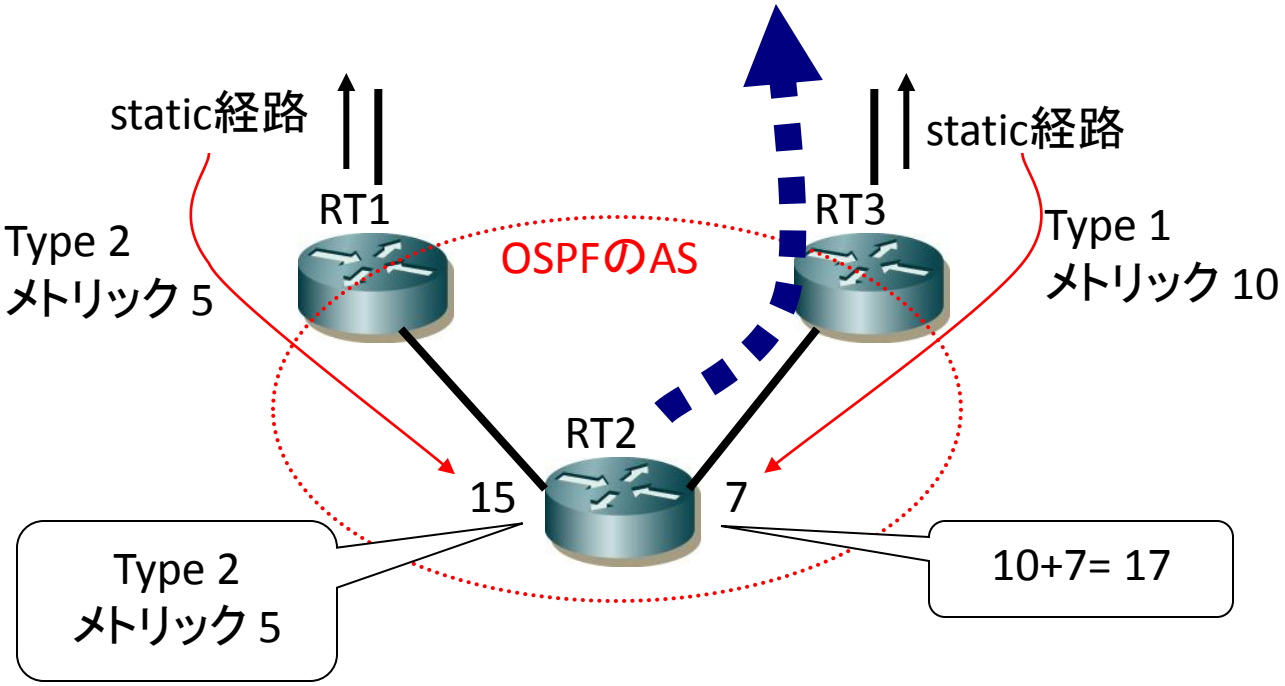

- 常にType 1経路が優先される
- BGPのネクストホップになるアドレスを運ぶならType 1経路
  - closest exitが維持できて便利

OSPFエリア

OSPFのエリアについて解説する

エリア(area)

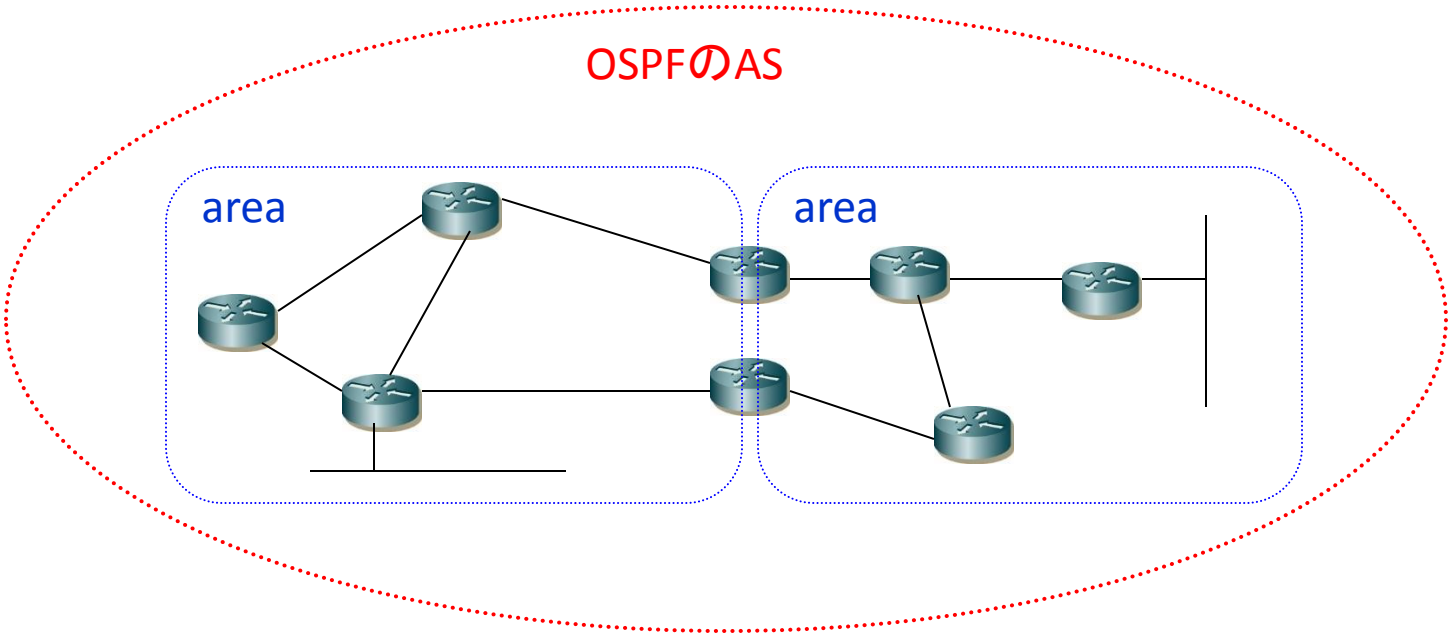

- OSPFでは連続したネットワークのグループを作成できる。これに接続するルータを含めて、エリアと呼ぶ。

エリアの概要

- ルータがエリアの境界になる
- それぞれのエリアで独立にLSDBが管理され、経路情報が計算される
- あるエリアのトポロジは、他のエリアからは見えない
  - 必要な経路情報のみが伝播する
  - 計算負荷の軽減

エリア間とエリア内

- 宛先が同じエリアか違うエリアか
  - エリア内経路(intra-area経路）
  - エリア間経路(inter-area経路)
- 同じ宛先については、エリア内経路が優先

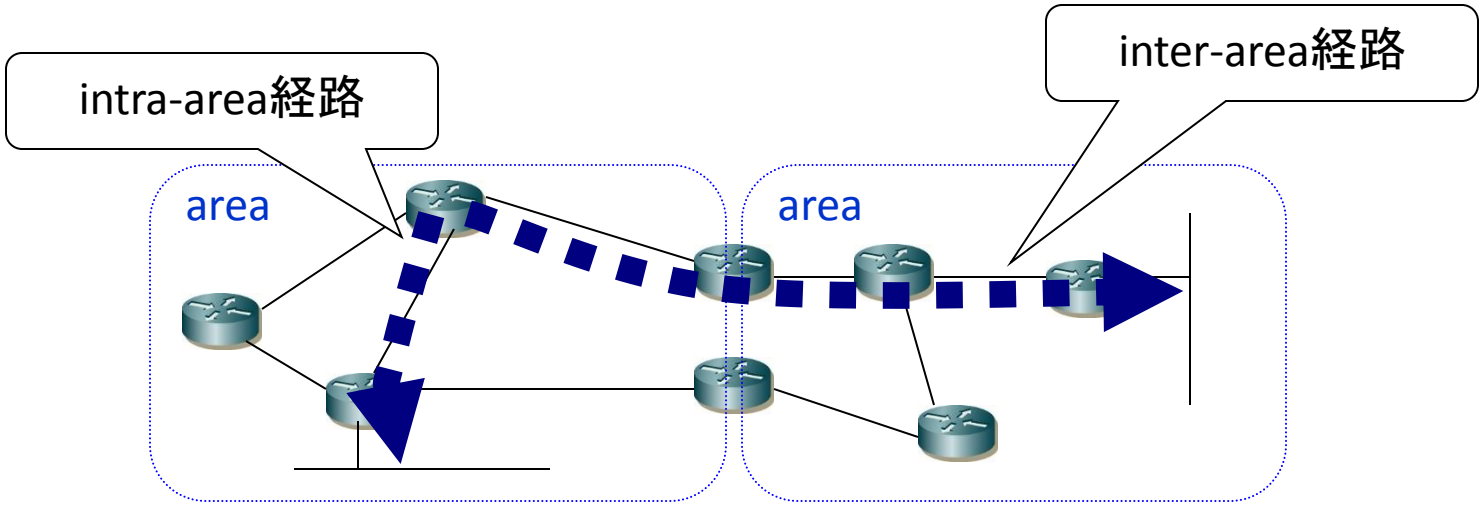

エリアID(area ID)

- 各エリアを識別する32bitの数値
  - 各エリアに管理者がIDを設定する
- そのまま数字で表記する書式
  - area 0
- IPアドレスの様に8bit毎に区切った書式
  - area 0.0.0.0

バックボーン エリア(area 0)

- エリアIDが0
- 各エリアの経路情報を交換できる特別なエリア
- OSPFのマルチエリア構成は、バックボーンエリアを中心としたスター型

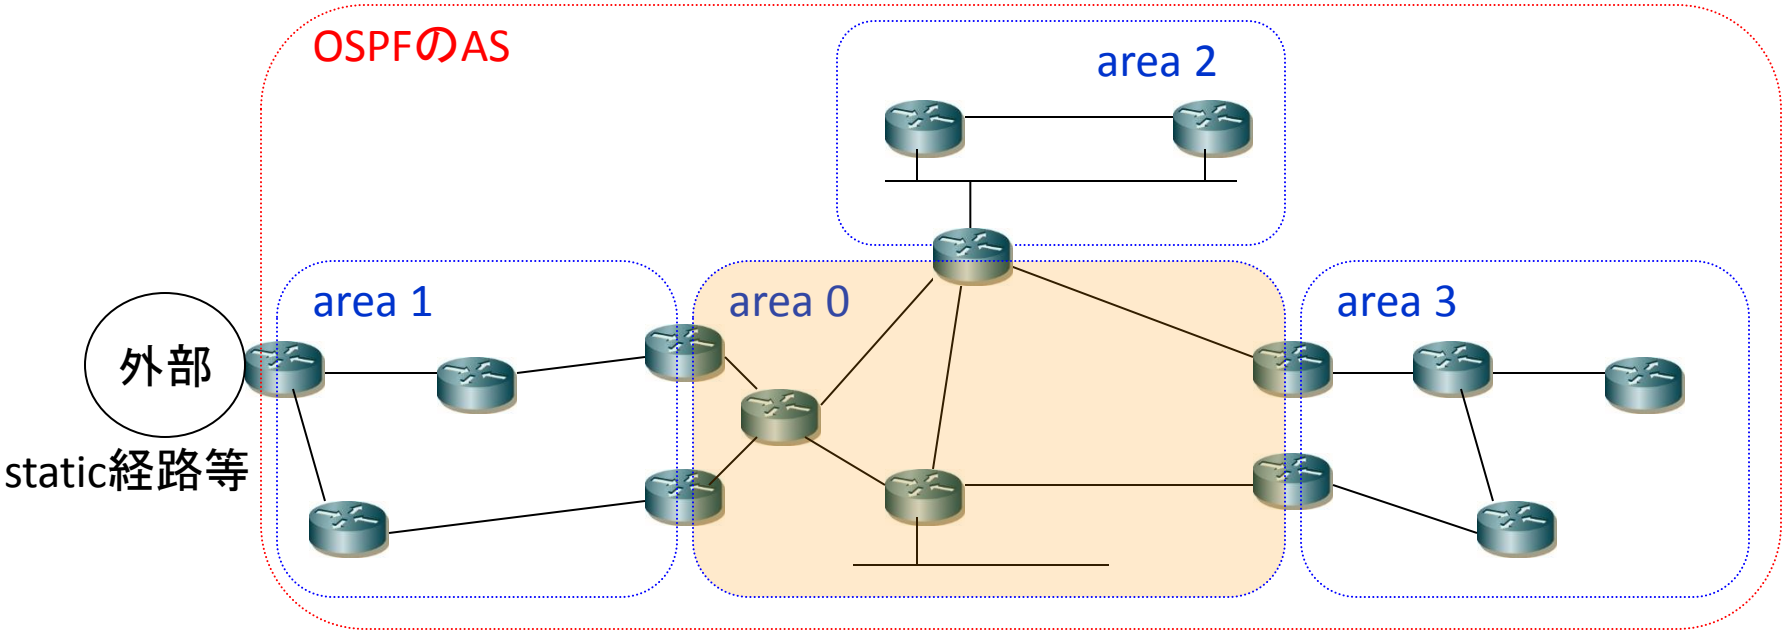

stubエリア

- 外部経路が増大した構成での対策を考えた
  - 外部経路は基本的に全エリアに広報される
  - これを軽減する仕組みがstubエリア
- 外部経路を伝播しない代わりに、default経路をエリア境界ルータが広報する
  - ASBRが無いエリアに適用できる
  - エリア内の全てのルータでstubエリアと設定する

area 2をstubエリアにしている例

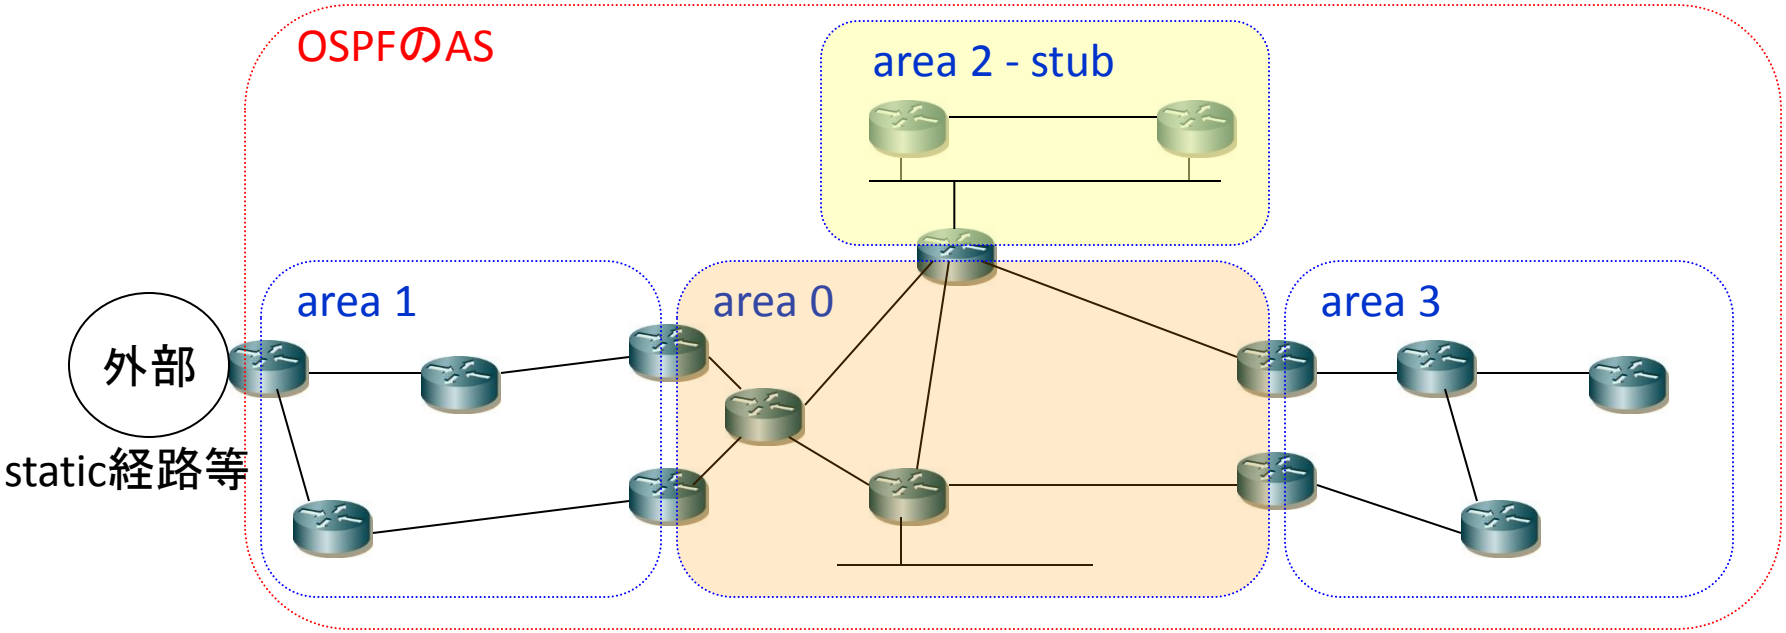

- area 2にはエリア間経路(inter area経路)とdefault経路のみが広報される
- この場合、area 3もstubエリアにすることができる

LSA

LSA(link state advertisement)の
パケットフォーマットを解説する

リンクステート広告（LSA)

- link state advertisement
- 各ルータが広告する情報のこと
- LSAの集合がLSDBになる
- 目的に応じた幾つかのタイプがある

LSAの種類（基本）

LSタイプ

1. **ルータLSA**
   ルータに接続するリンク、ネットワーク情報を運ぶ
   リンク種別に応じてp2p, transit, stub, virtualの4種類
2. **ネットワークLSA**
   ネットワークに接続するルータ情報を運ぶ
3. **サマリLSA（ネットワーク)**
   エリア外のネットワークへの経路を運ぶ
4. **サマリLSA（ASBR)**
   エリア外のASBRへの経路を運ぶ
5. **AS-external-LSA**
   外部経路を運ぶ
   Type 1とType 2のメトリックタイプが存在する

LSA header

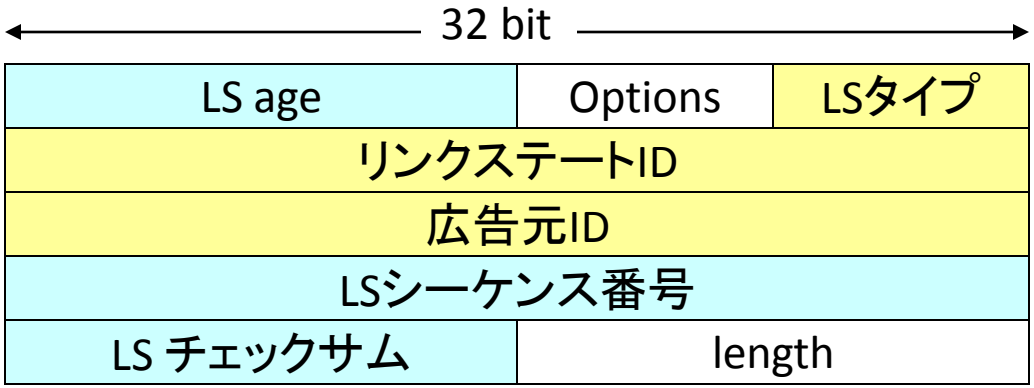

- 20-octetの固定長
- LSAを個別に識別できる
  - LSタイプ, リンクステートID, 広告元ID
- 新しいLSAを識別できる
  - LS age, LSシーケンス番号, LSチェックサム

LSタイプ1 - ルータLSA

- 全ルータが一つずつ広告する自己紹介
- 4種類のリンクタイプ

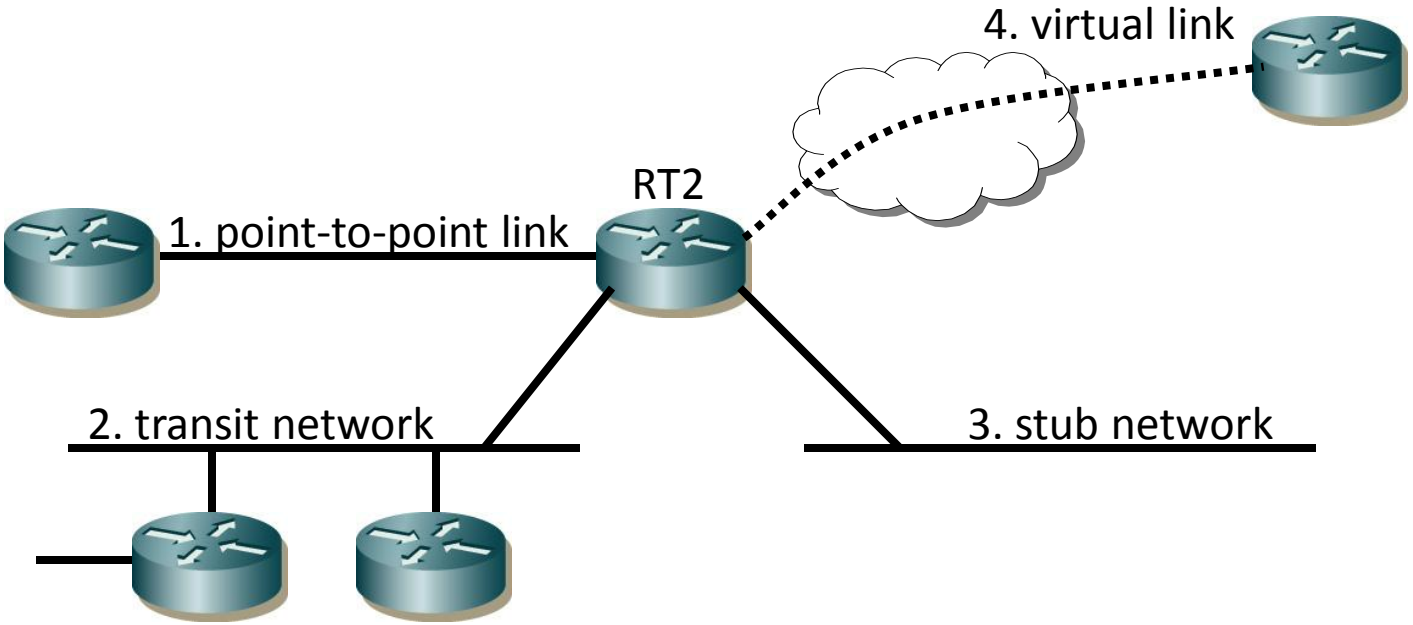

ルータLSA

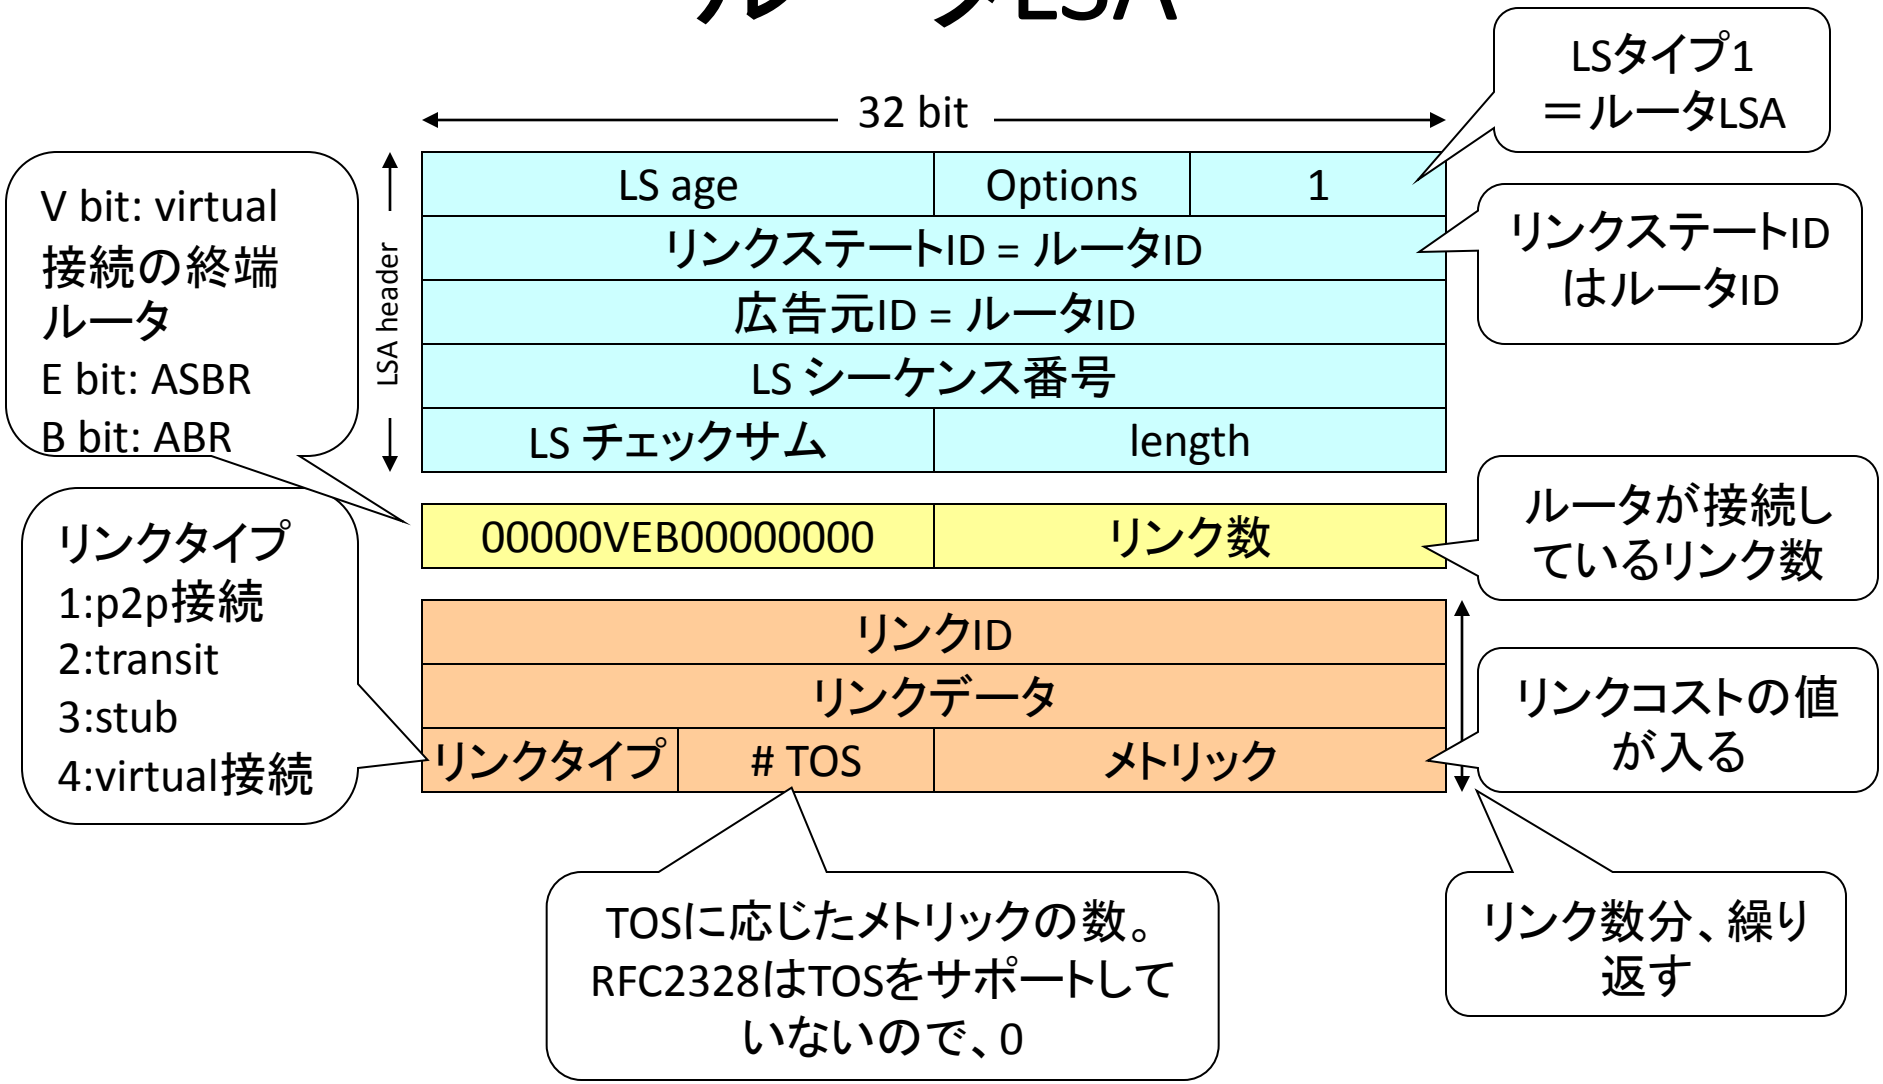
32 bit
LSタイプ1
＝ルータLSA
V bit: virtual
接続の終端
ルータ
E bit: ASBR
B bit: ABR
LSA header
LS age
Options
1
リンクステートID = ルータID
リンクステートID
はルータID
広告元ID = ルータID
LS シーケンス番号
LS チェックサム
length
00000VEB00000000
リンク数
ルータが接続し
ているリンク数
リンクタイプ
1:p2p接続
2:transit
3:stub
4:virtual接続
リンクID
リンクデータ
リンクタイプ
TOS
メトリック
リンクコストの値
が入る
TOSに応じたメトリックの数。
RFC2328はTOSをサポートして
いないので、0
リンク数分、繰り
返す

ルータLSAで運ぶ情報

- stubネットワークのみが経路情報を運び、その他はトポロジ情報を運ぶ

リンクタイプ	リンクID	リンクデータ	データ種類
1 p2p	ネイバのルータID	MIB-II ifindex値 (あれば、リンクのIPアドレス)	トポロジ
2 transit	DRのリンクのIPアドレス	リンクのIPアドレス	トポロジ
3 stub	リンクのIPネットワーク	ネットワークマスク	経路
4 virtual	ネイバのルータID	リンクのIPアドレス	トポロジ

LSタイプ2 - ネットワークLSA

- transitネットワークに接続するルータのリスト
- ネットワークにつき1台の代表ルータ（DR）のみが広告する

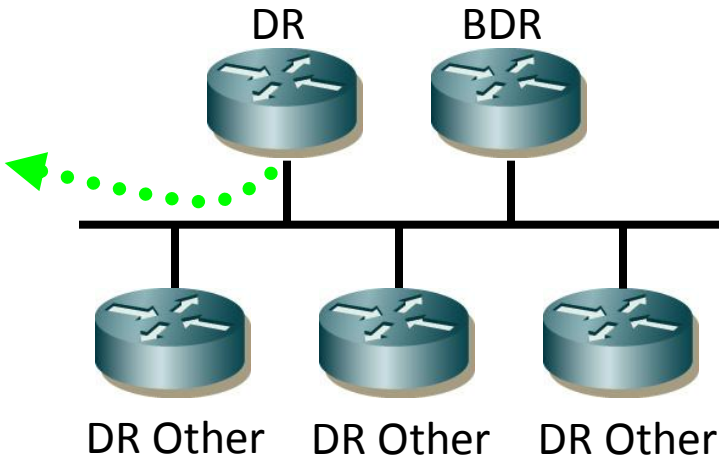

ネットワークLSA

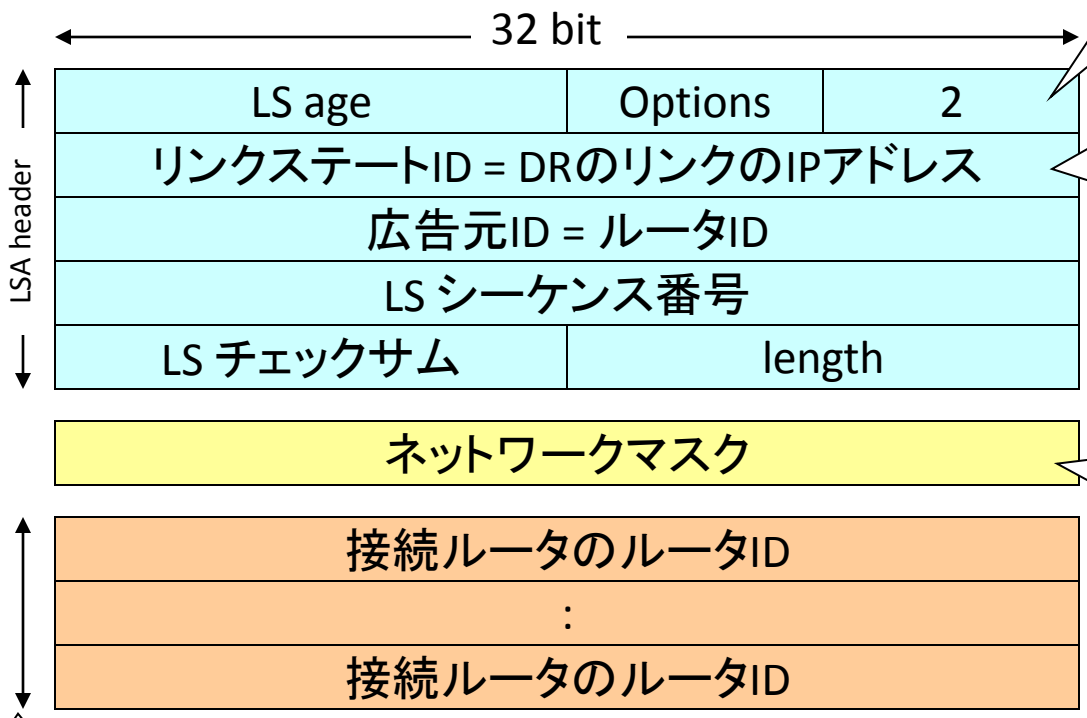

LSタイプ2＝ネットワークLSA

該当ネットワークのDRのリンクのIPアドレス

ネットワークのネットマスク

接続しているルータ数分、繰り返す

ネットワークLSAで運ぶ情報

- トポロジと経路を同時に運ぶ

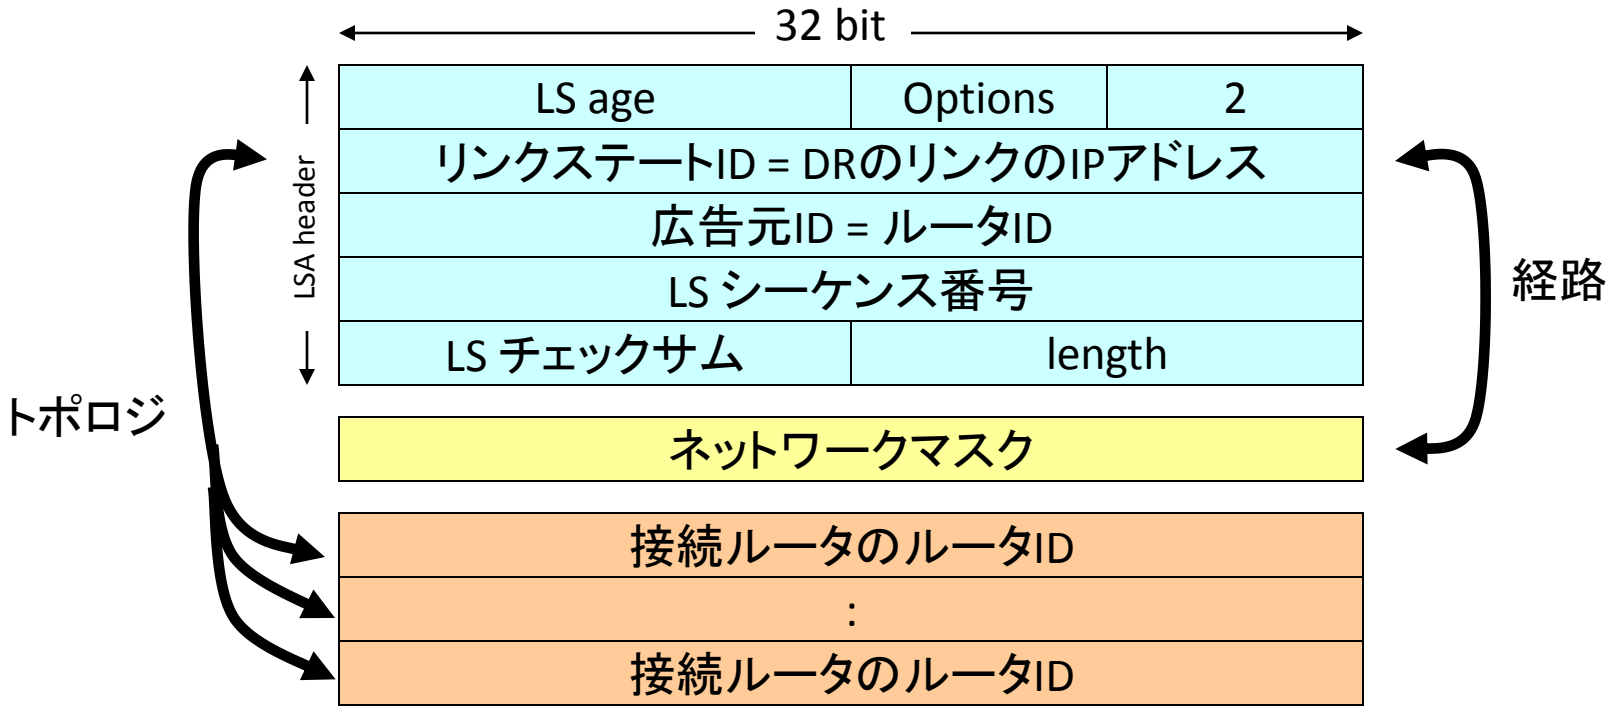

LSタイプ3 - サマリLSA

- エリア外のネットワークへの経路情報を運ぶ
- エリア境界で、エリア境界ルータが生成する

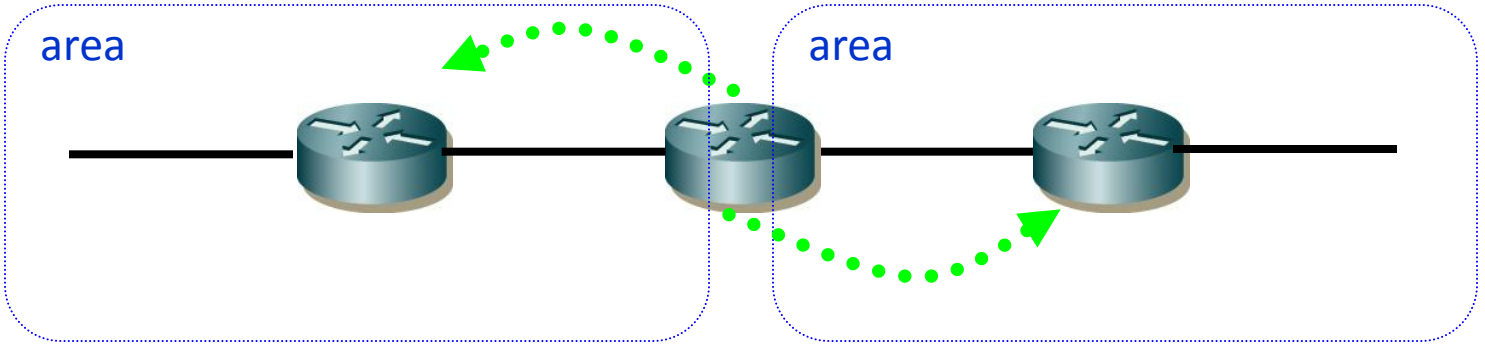

LSタイプ3 サマリLSA

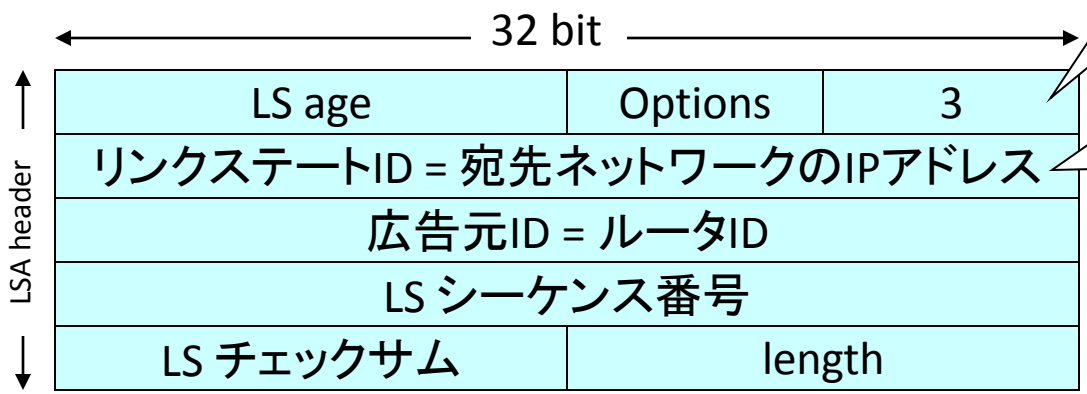

LSタイプ3＝サマリLSA (ネットワーク)

宛先ネットワークのIPアドレス

ネットワークのネットマスク

ネットワークへのコスト

LSタイプ4 - サマリLSA

- エリア外のASBRへの経路情報を運ぶ
- エリア境界で、エリア境界ルータが生成する
- LSタイプ3とほぼ一緒
  - リンクステートIDがルータID、ネットマスクが0

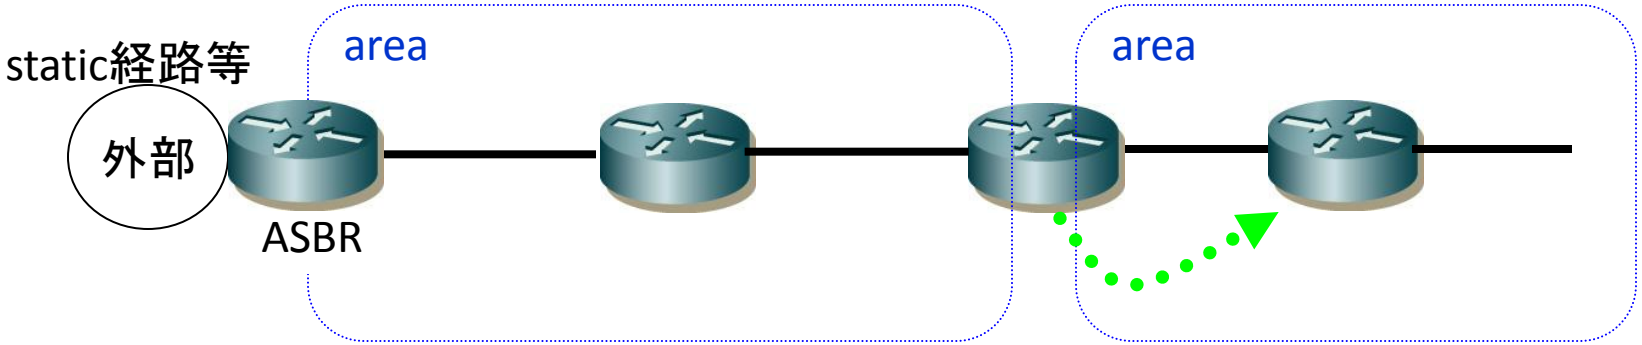

LSタイプ4 サマリLSA

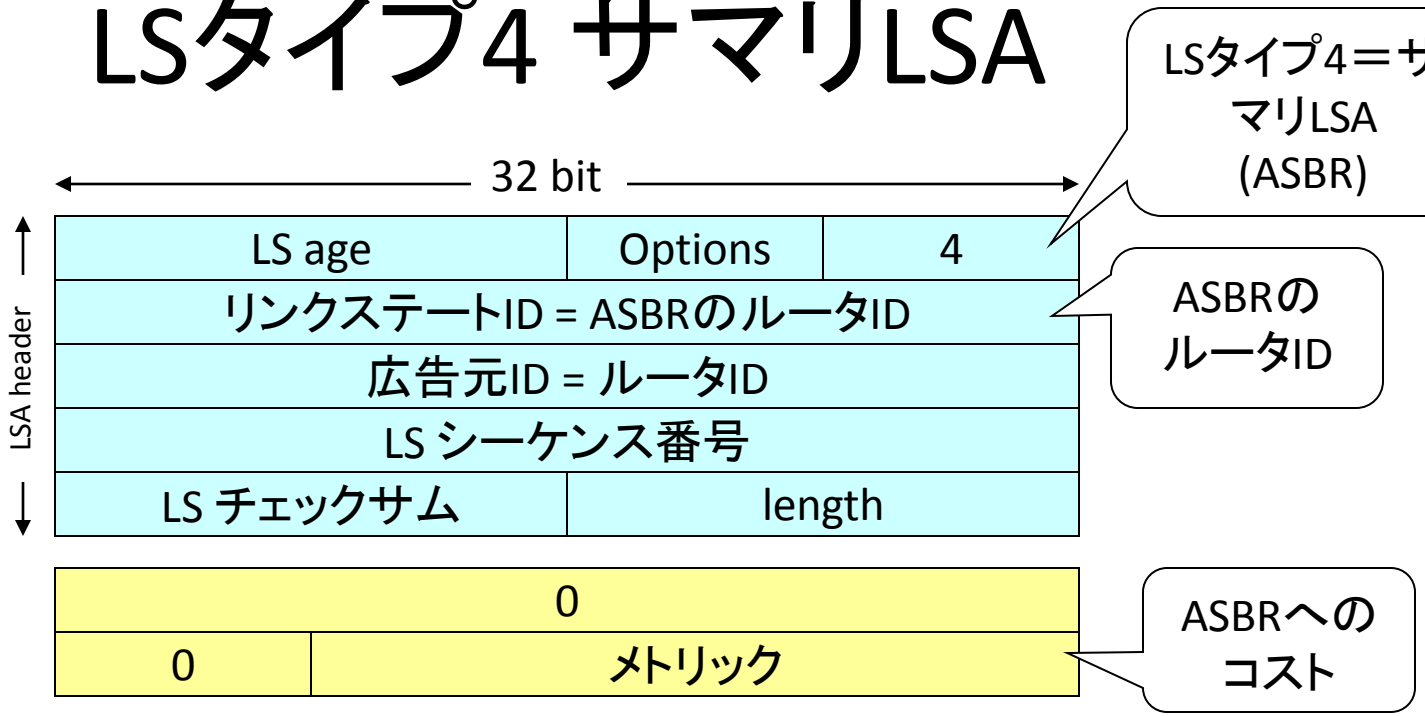

LSタイプ5 - AS-external-LSA

- staticや他のプロトコルで学習した経路情報を外部経路としてOSPF内で運ぶ
- AS境界ルータ(ASBR)が生成する
- Type1またはType2のメトリック

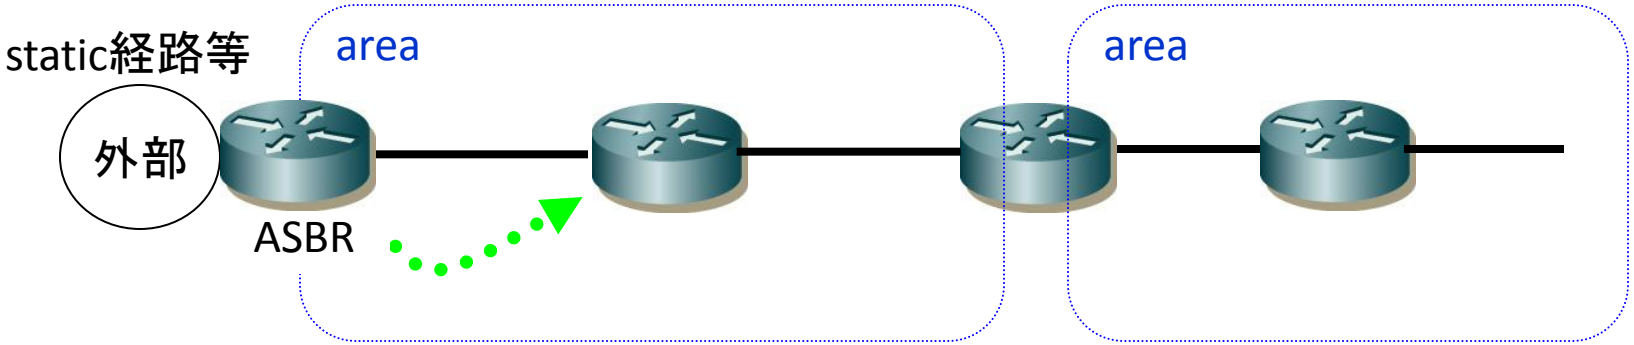

AS-external-LSA

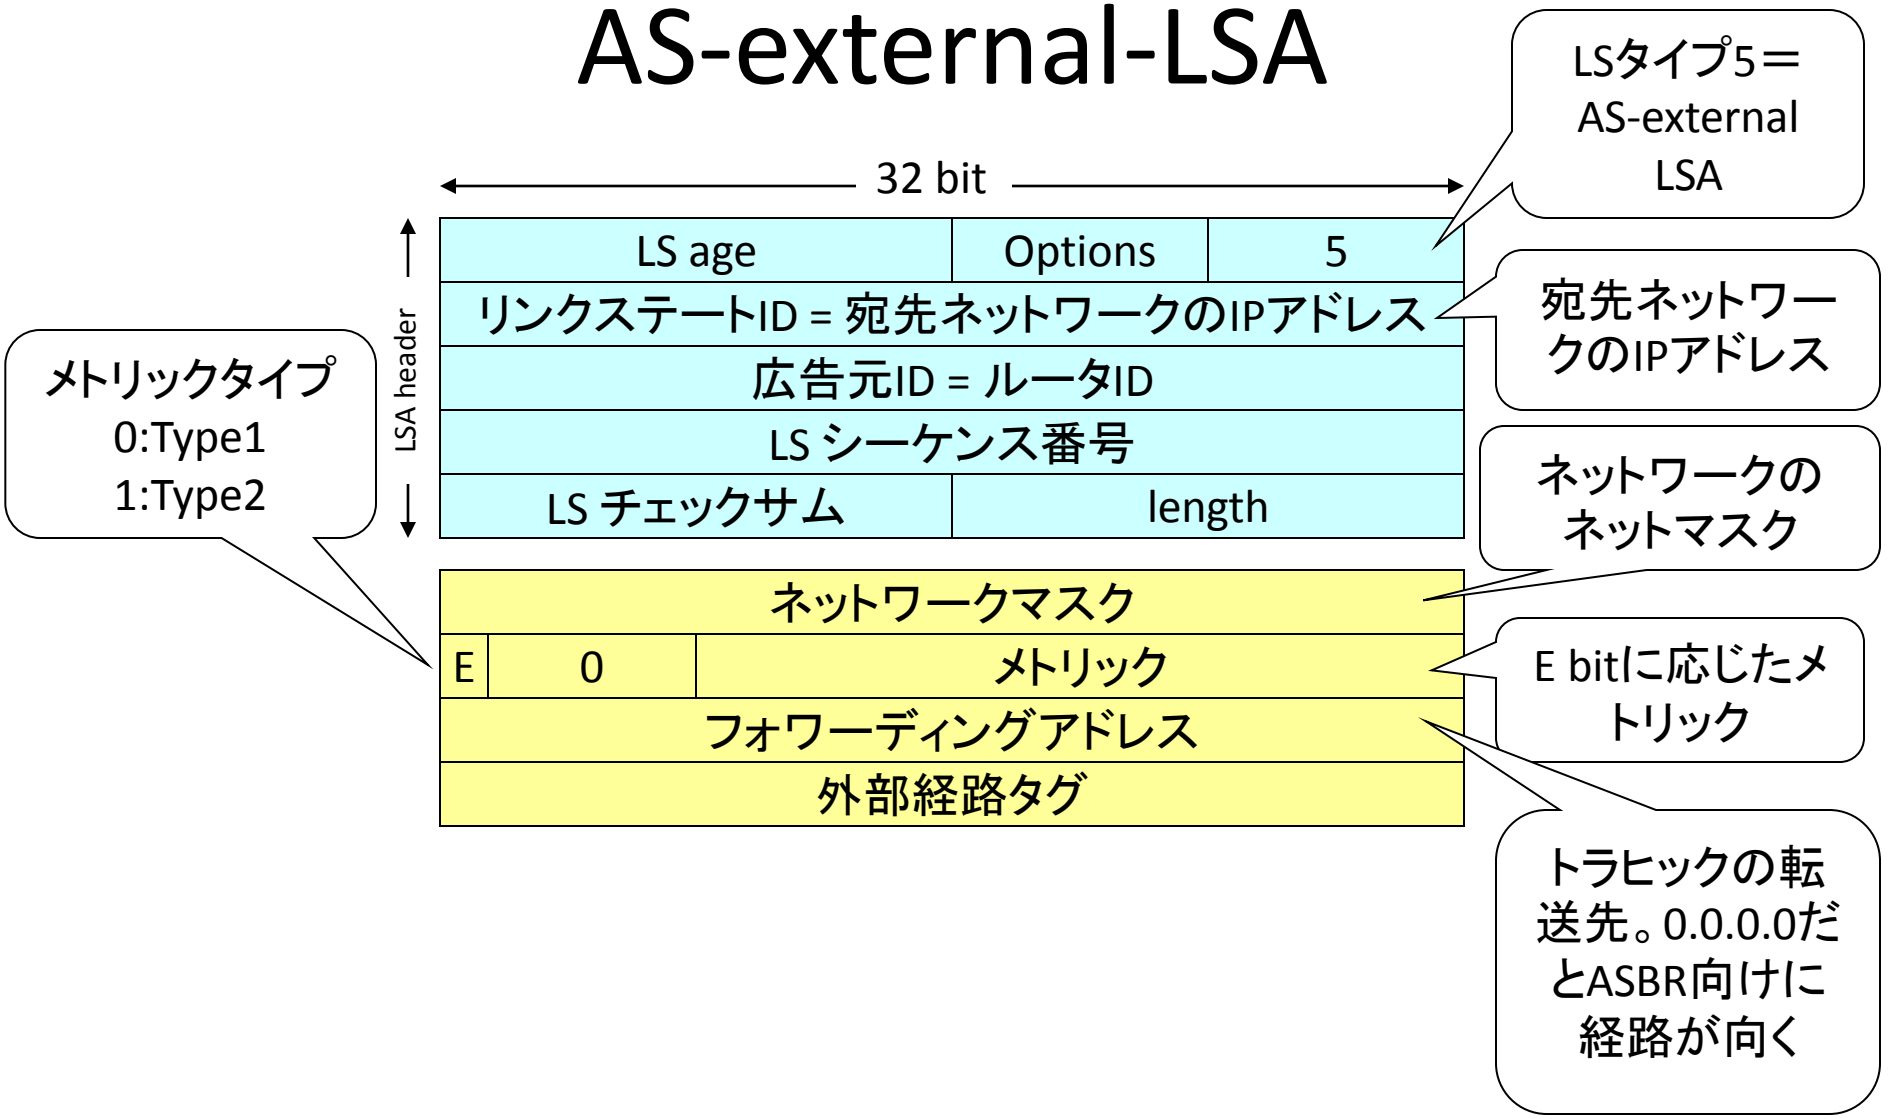

LSAとエリア

エリア間のLSAの伝播を整理する

バックボーンから他エリアへのLSA

- ルータLSA,ネットワークLSAの経路部分が伝播する
- その他のLSAはそのまま伝播する

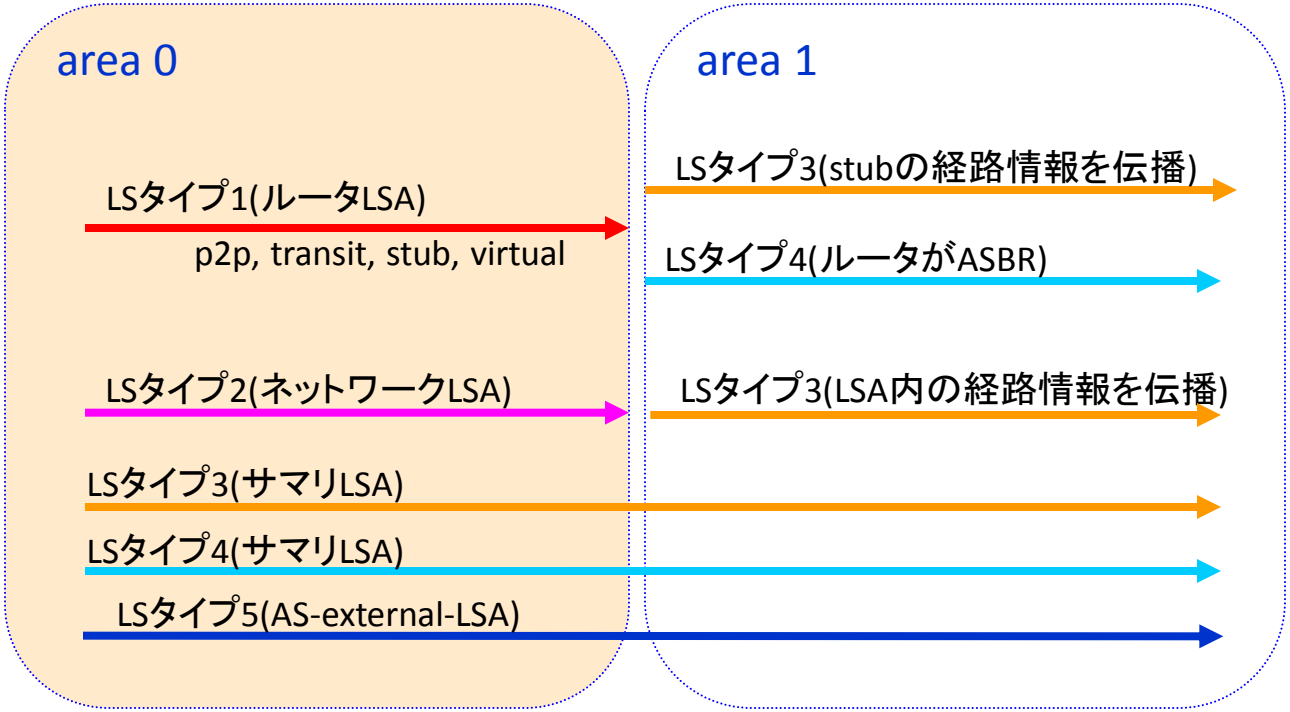

エリア間でのLSA

- バックボーンエリアのみがサマリLSAを他エリアに中継できる

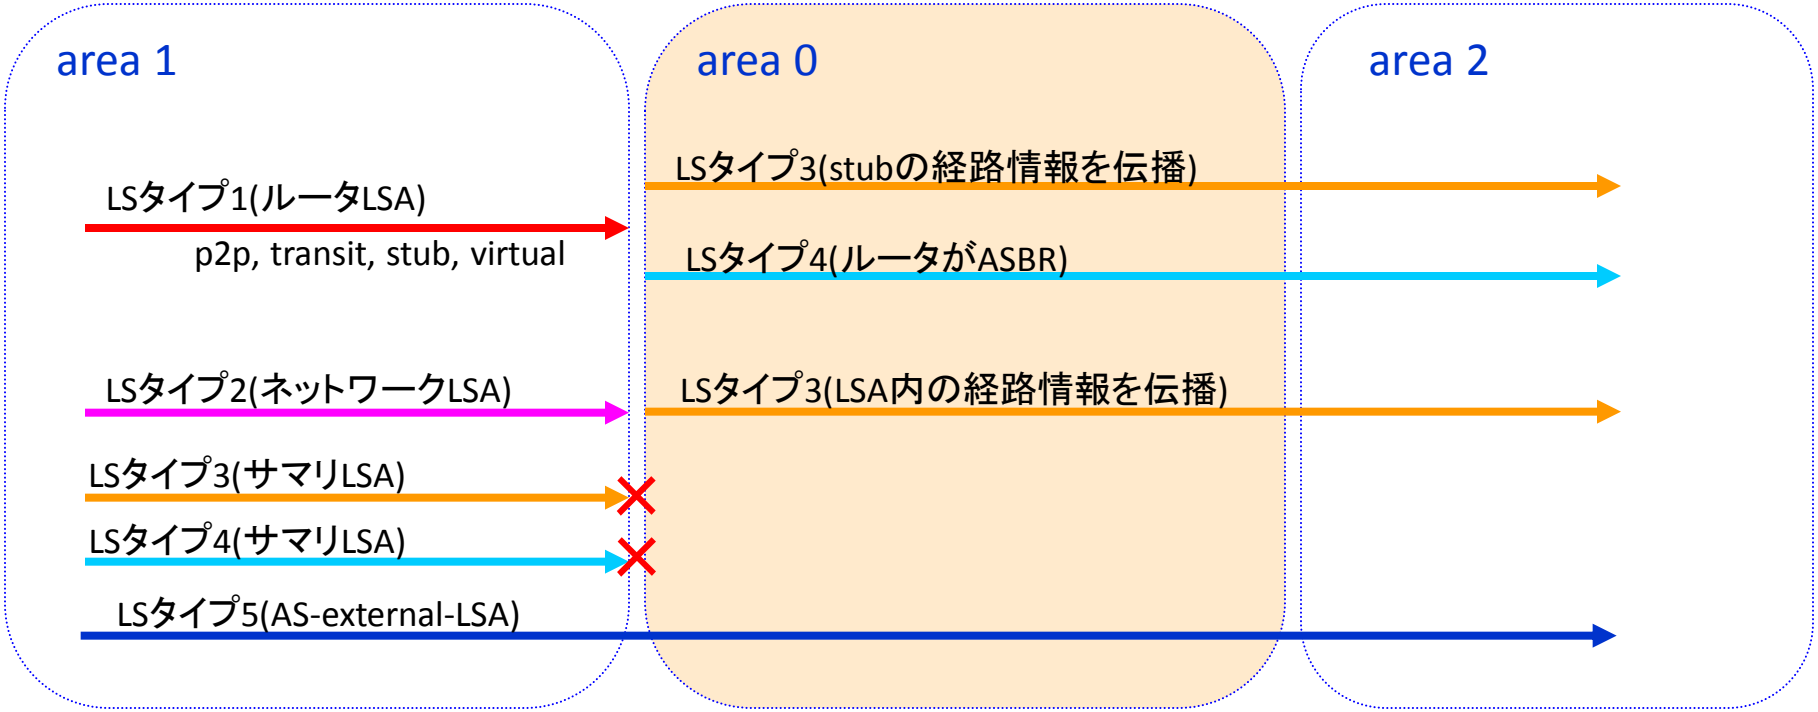

stubエリアへのLSA

- 外部経路が伝播せず、default経路が広告される
- ASBRへの経路も必要ないので、伝播しない

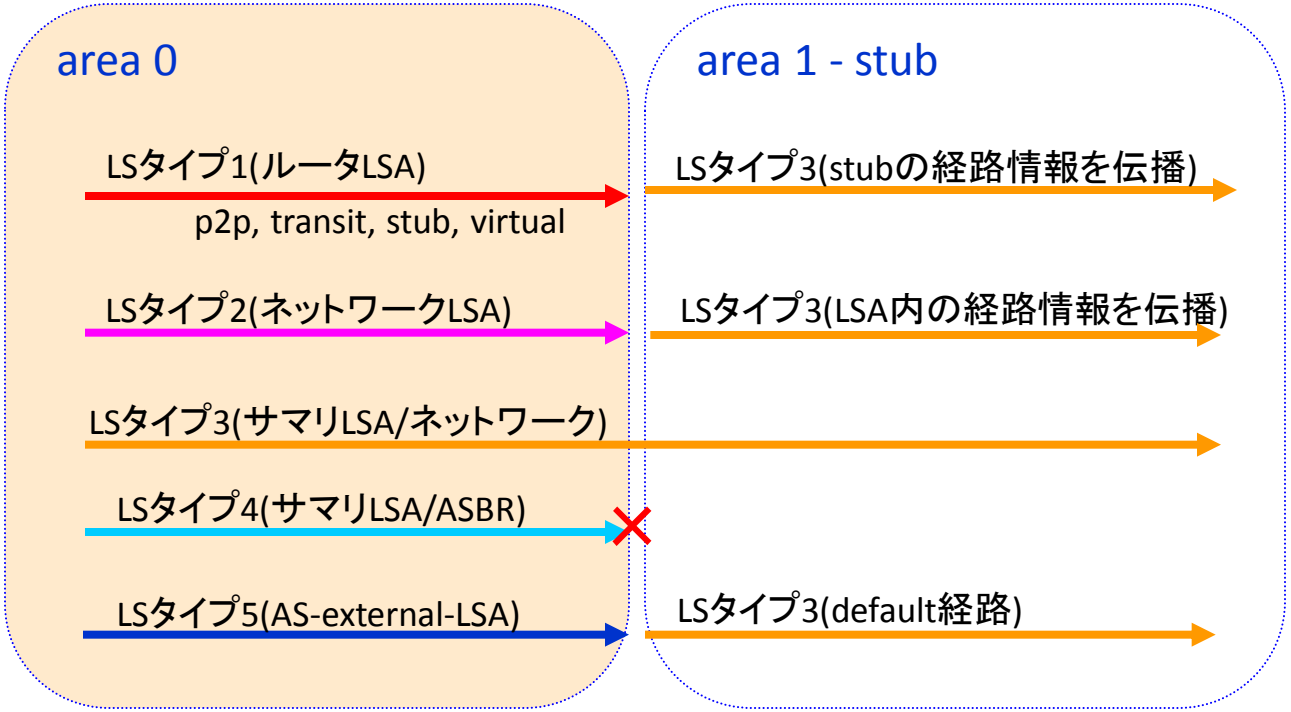

エリア構成を誤った場合

- area 1がバックボーンエリアに接していない
- ほとんどの経路がバックボーンに届かない
- 外部経路も転送先アドレスが到達できないと考えられるので、ほぼ全ての経路が利用できない

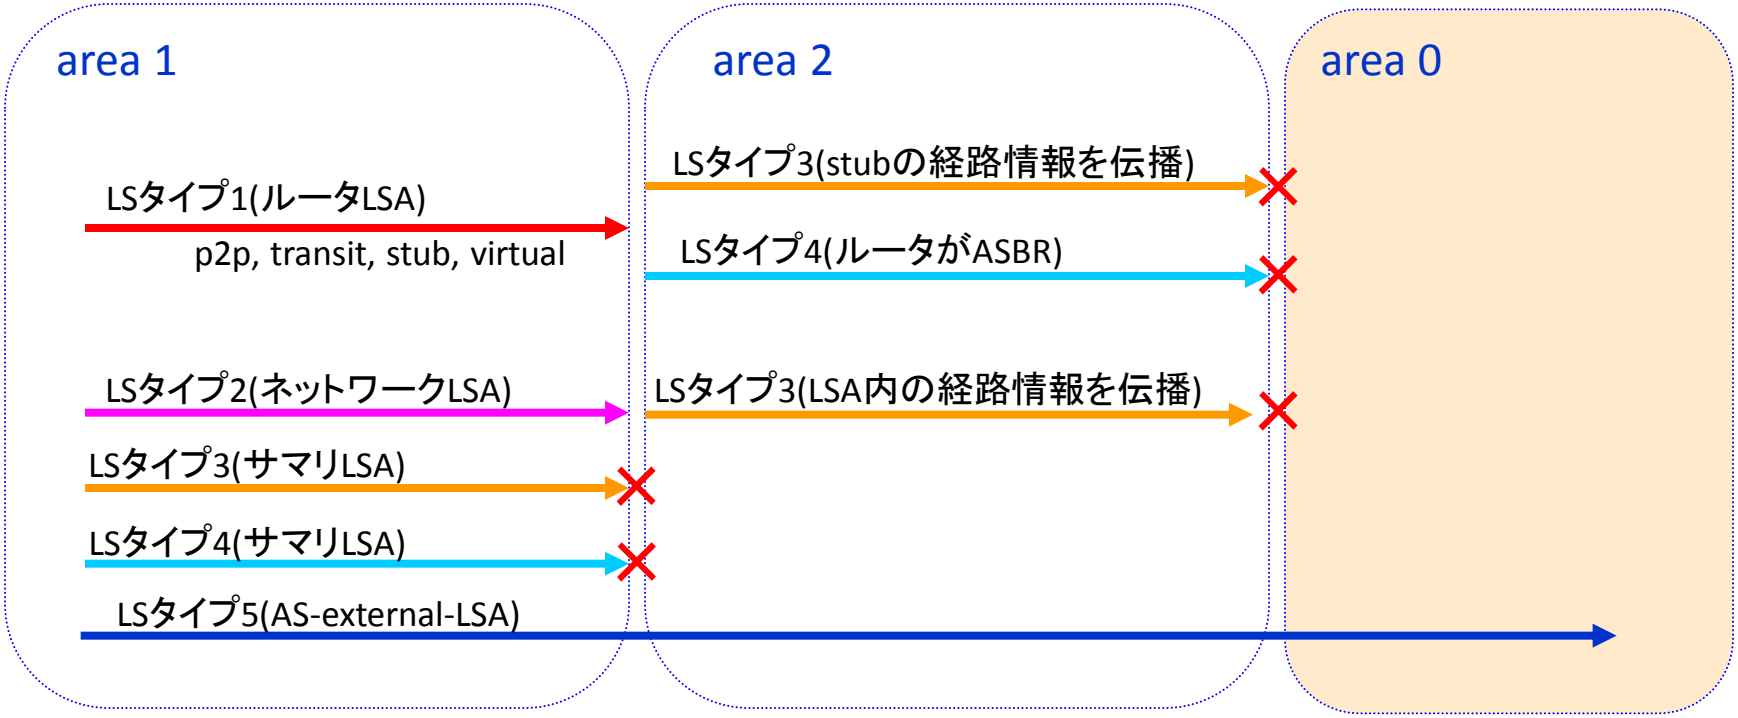

virtual linkの利用

- area 0が張り出している様にLSAのやり取りを行う
- 構成が複雑になるので、緊急時以外お勧めしない

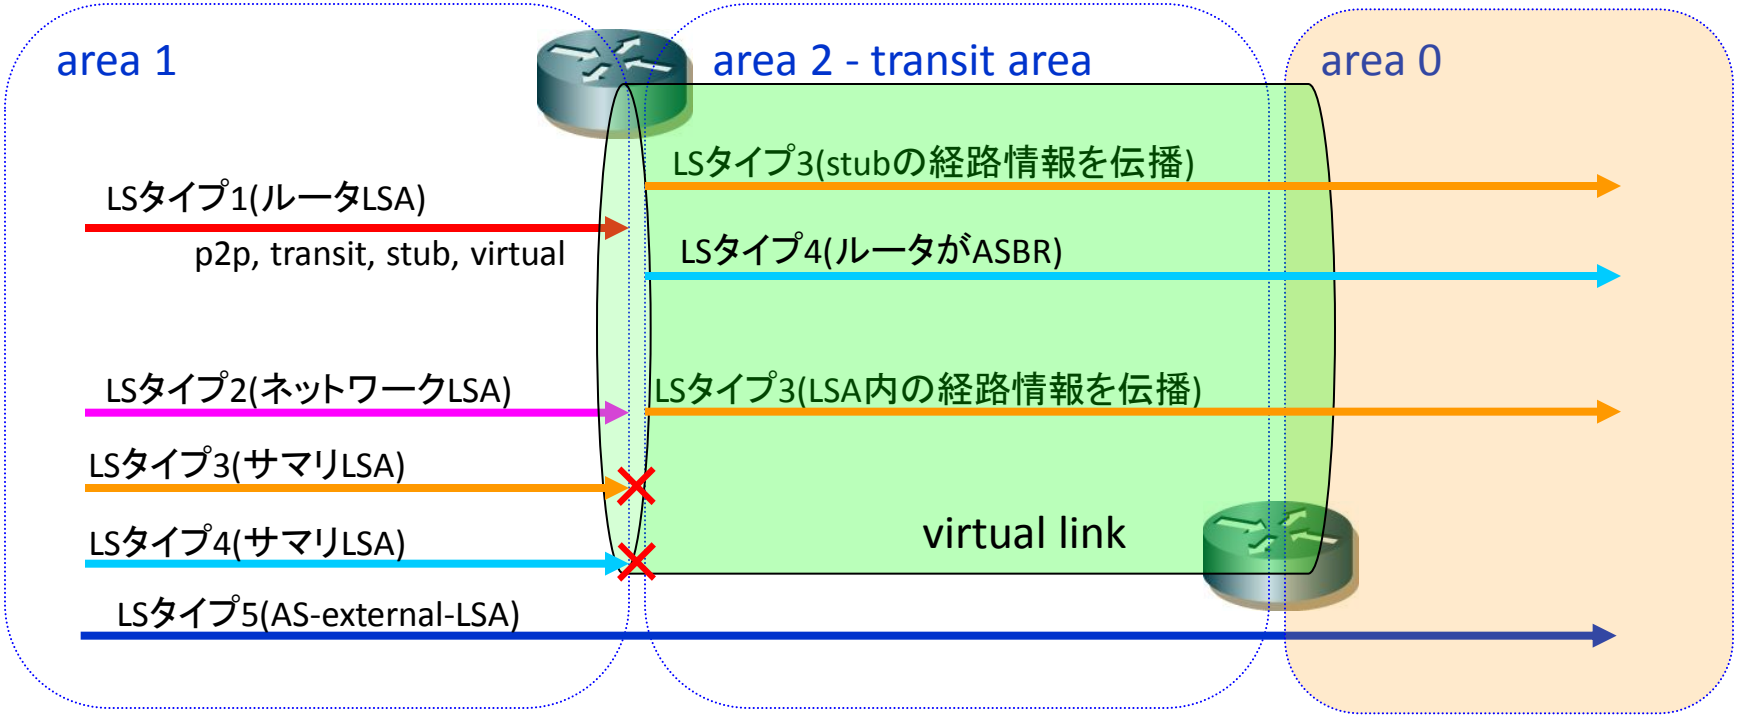

OSPF経路の優先順序

1. エリア内経路(intra area経路)
   ルータLSA(LSタイプ1)
   ネットワークLSA(LSタイプ2)
2. エリア間経路(inter area経路)
   サマリLSA(LSタイプ3, 4)
3. 外部経路タイプ1
   AS-external-LSA(LSタイプ5) メトリックタイプ1
4. 外部経路タイプ2
   AS-external-LSA(LSタイプ5) メトリックタイプ2

OSPFv3

- OSPF for IPv6のこと
  - 詳しくは[RFC2740]
  - IPv6に対応するために、変更が加えられた
- トポロジ情報と経路情報の分離
  - ルータLSA、ネットワークLSAから経路を削除
    - ルータLSAのstubネットワーク
    - ネットワークLSAのネットマスク
  - 代わりにIntra-Area-Prefix-LSAを用意
- LSAにFlooding Scopeの要素が追加

OSPFv3

- LSAを分かりやすく改名
  - サマリLSA(LSタイプ3)→Inter-Area-Prefix-LSA
  - サマリLSA(LSタイプ4)→Inter-Area-Router-LSA
- リンクの識別手法の変更
  - OSPFv2 – 3種類
    - リンクタイプ
    - リンクID、リンクデータ
  - OSPFv3 – 4種類
    - リンクタイプ、
    - インタフェースID、ネイバインタフェースID、ネイバルータID

他のプロトコルとの比較

- OSPFとIS-IS
  - １９８０年台の後半に開発が始まる
  - IS-ISのdraftが原型となり、OSPFが開発される
  - その後、各ベンダが実装
  - 現在もIETFのそれぞれのworking groupで議論が続く
  - どちらもSPFアルゴリズムを利用してリンクステートデータベースから経路情報を計算する

IS-ISとOSPFv2

- IS-ISでIPの経路制御を出来るように拡張したものが、Integrated IS-IS。または Dual IS-IS

	Integrated IS-IS	OSPFv2
プロトコルパケットの転送	CLNS	IPv4
扱う経路情報	CLNS and/or IPv4	IPv4
階層化	Level1(エリア内) Level2(エリア間)	中継を担うarea0と その他のエリア
エリア境界	リンク	ルータ

IS-IS

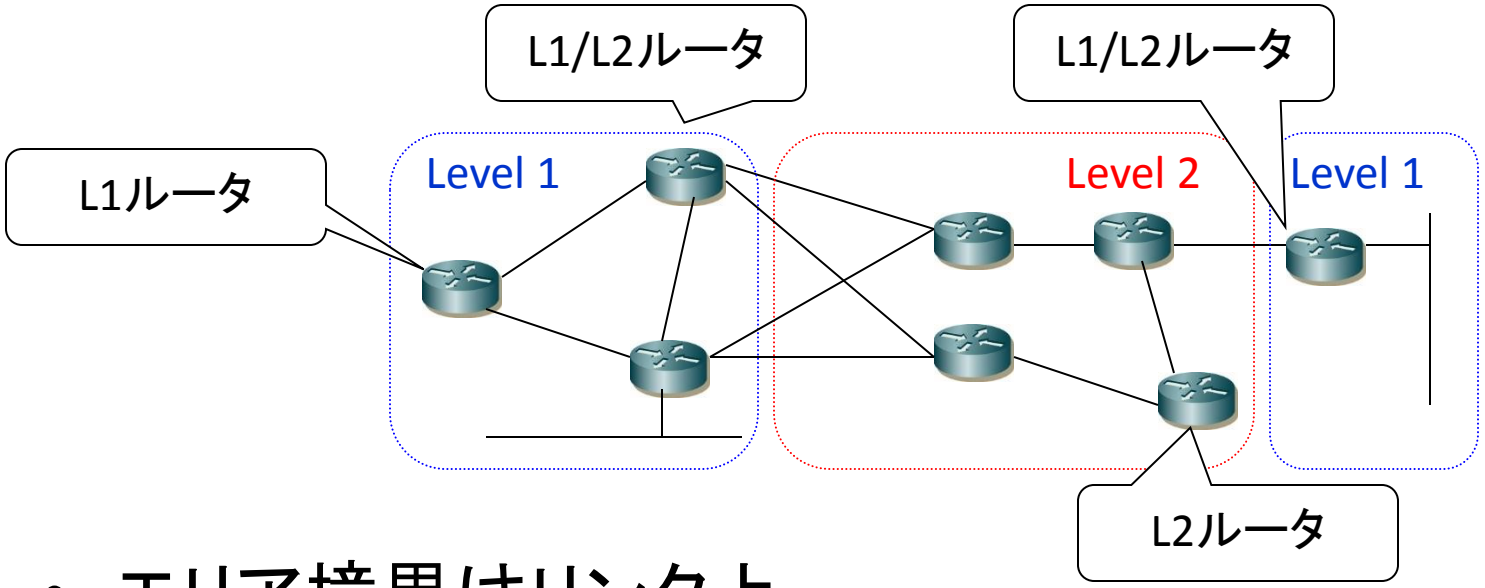

- エリア境界はリンク上
- Level2がエリア間の通信を担う
- Level1からエリア外への通信は近隣のL1/L2ルータに頼る
  - L2の経路をL1内に伝播させることもできる[RFC2966]

BGP

BGP概要

- パスベクタ型プロトコル
  - プレフィックスに付加されたパス属性で経路制御
- AS番号によって、組織間、組織内を認識する
- 経路交換にTCPを利用
  - データの到達や再転送はTCP任せ
- 変更があった場合にのみ通知
  - ベスト経路のみを通知する
- 現在のバージョンは4 (BGP4)

BGPの基本アイディア

- 準備
  - 経路交換したいBGPルータとTCPでネイバを構築
- 通知
  - ベスト経路に変更があればUPDATEとしてネイバに広報
  - 受信した経路は幾つかの条件を経て、他のネイバに広報
- 構成
  - 各ルータが受信経路にポリシを適用し、パス情報を元にベスト経路を計算

BGP RFCs

- 基本
  - [RFC4271] A Border Gateway Protocol 4 (BGP-4)
- この他にもいっぱい
  - [RFC1997] BGP Communities Attribute
  - [RFC3065] AS Confederations for BGP
  - [RFC4451] BGP MED Considerations
  - [RFC4456] BGP Route Reflection

BGP用語

- BGP ID
  - ルータを識別する32bitの数値
  - インタフェースのIPアドレスから選ばれる
  - 実運用では変更が発生しないようにloopbackインタフェースに付与したIPアドレスを利用する
- NLRI
  - Network Layer Reachability Information
  - ネットワーク層到達可能性情報
  - prefixで示される宛先のこと

BGPの世界

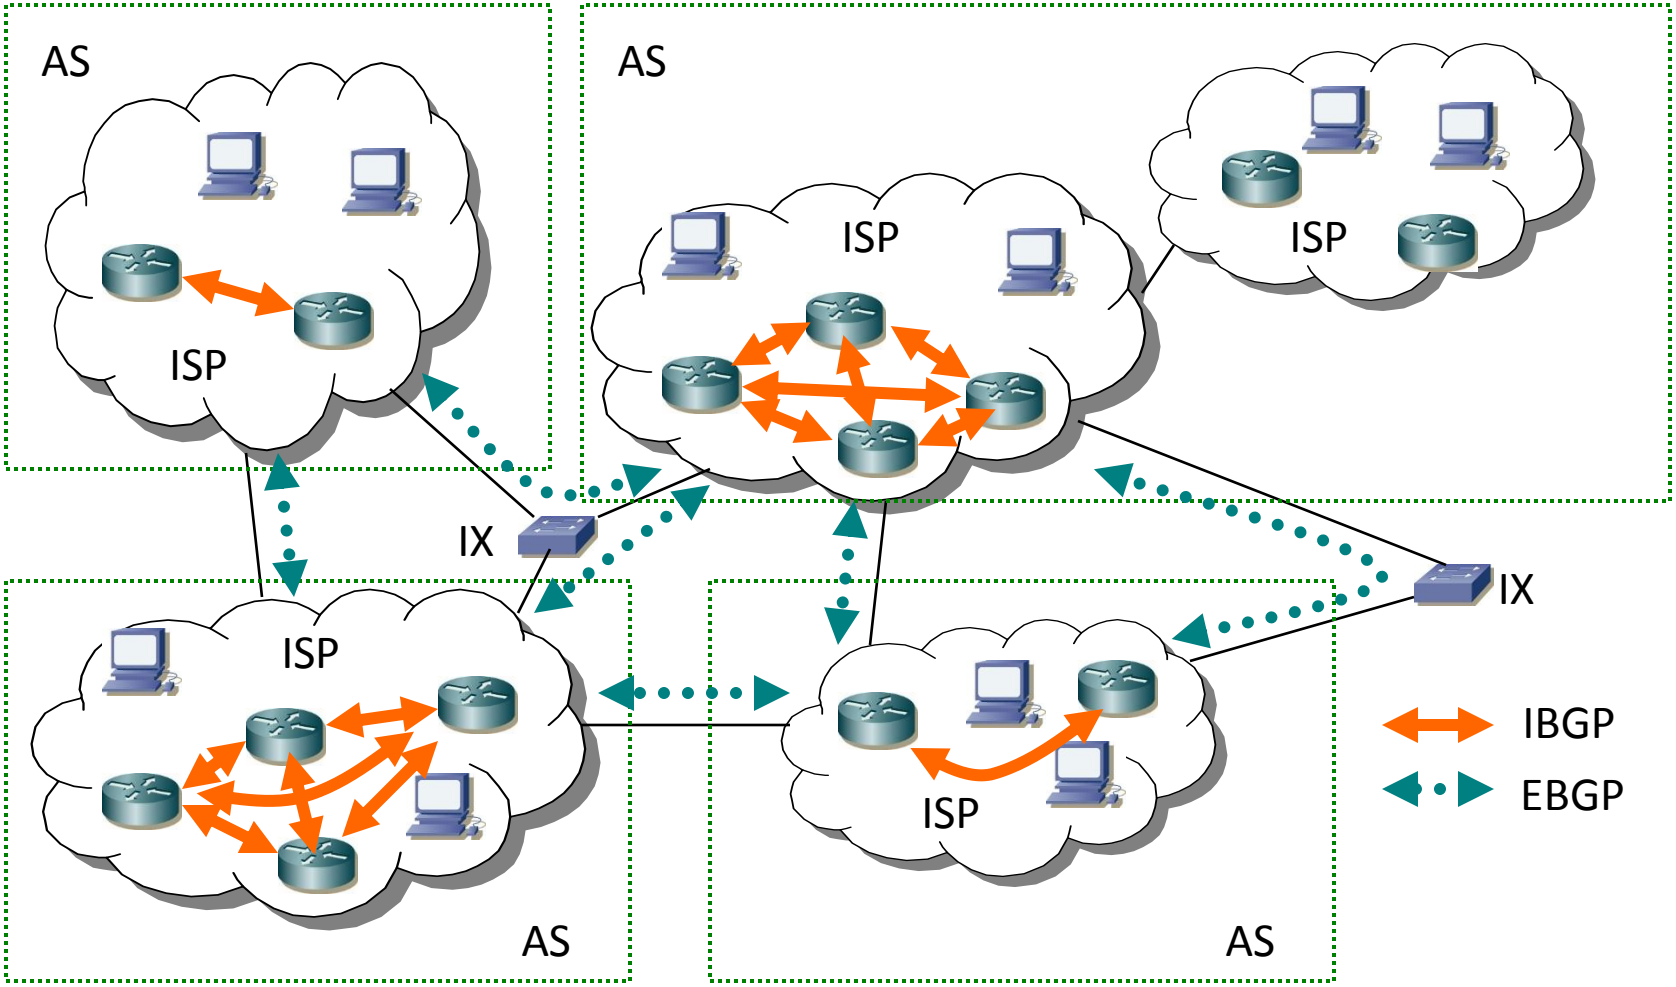

IBGP(Internal BGP)

- 同じAS内でのBGP接続
- IBGPで受信した経路は他のIBGPルータに広報されない
  - 全ての経路を伝えるには、AS内の全BGPルータがfull-meshでIBGPを張る必要がある

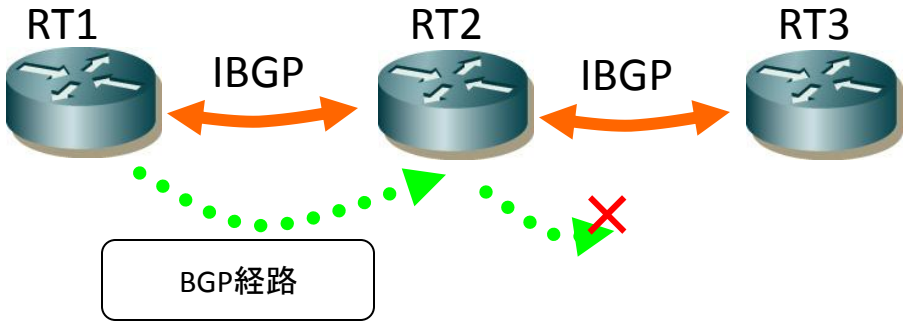

EBGP(External BGP)

- 異なるASとのBGP接続
- EBGPから受信した経路は、他のBGPルータに広報する
  - IBGPから受信した経路もEBGPには広報する

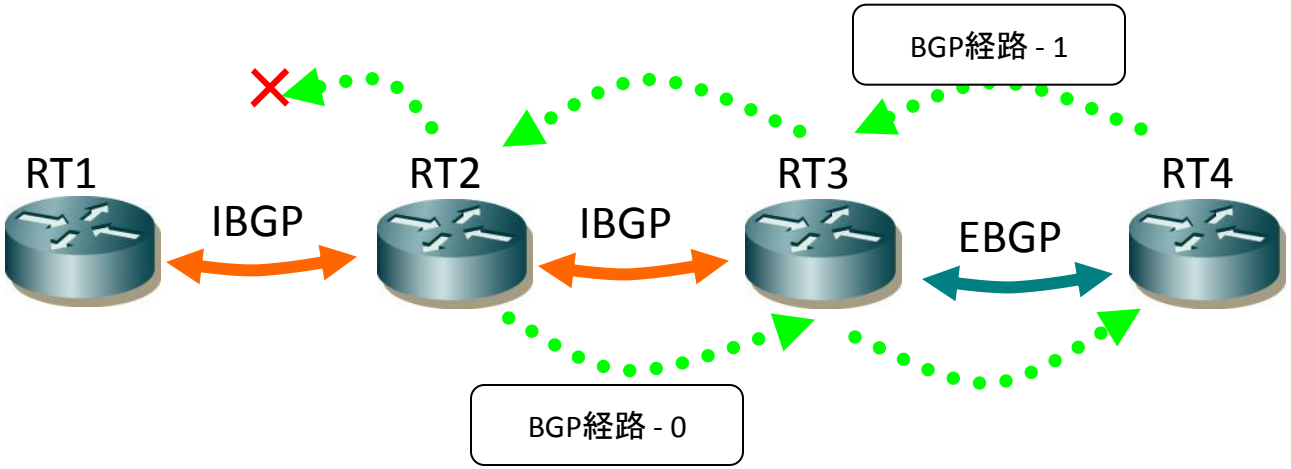

BGPのいにしえのモデル

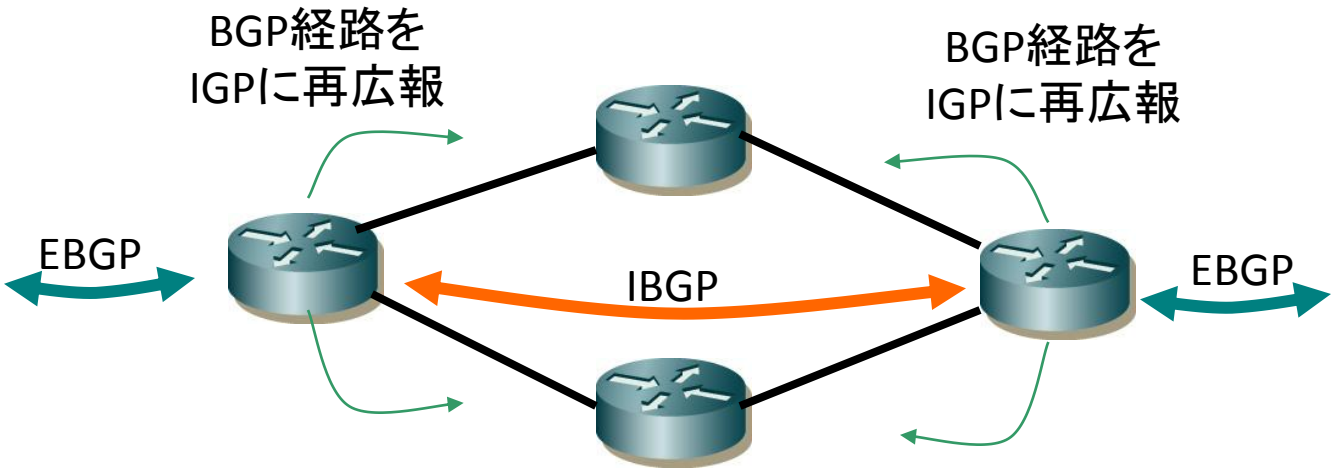

- EBGPを張るルータのみがBGPルータとなる
- BGP経路をIGP(OSPFやIS-IS)に再広報してAS内部はIGPで経路制御

・・・経路数が増大すると破綻

経路数の増大に対応したBGPモデル

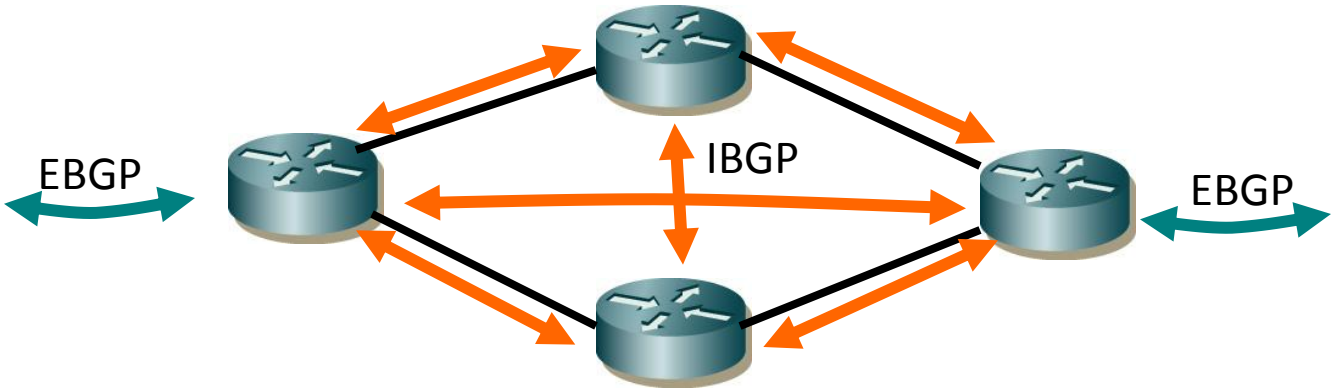

- 主要なルータは全てBGPルータ
- IGPはトポロジと最低限の経路を運び、BGPでその他の全ての経路を運ぶ

・・・IBGP接続の増大

IBGP full-mesh n*(n-1)/2

- AS内にBGPルータが増える毎にIBGP接続が増大していく
  - 20台目のBGPルータが接続すると19接続追加
  - ルータリソースの問題、設定負荷の問題
- 解決策の模索
  - [RFC4456] ルートリフレクタ
  - [RFC3065] コンフェデレーション
  - 気にせずリソースを強大にする
  - ルータを減らす

ルートリフレクタ

- IBGPで受信した経路の転送ルールを変更
- ルートリフレクタの機能
  - BGP接続ごとに設定される
  - クライアント以外のIBGPで受信した経路をクライアントに送信
  - クライアントから受信した経路を他のIBGPルータに送信
- ベスト経路のみを広報するルールは変わらない

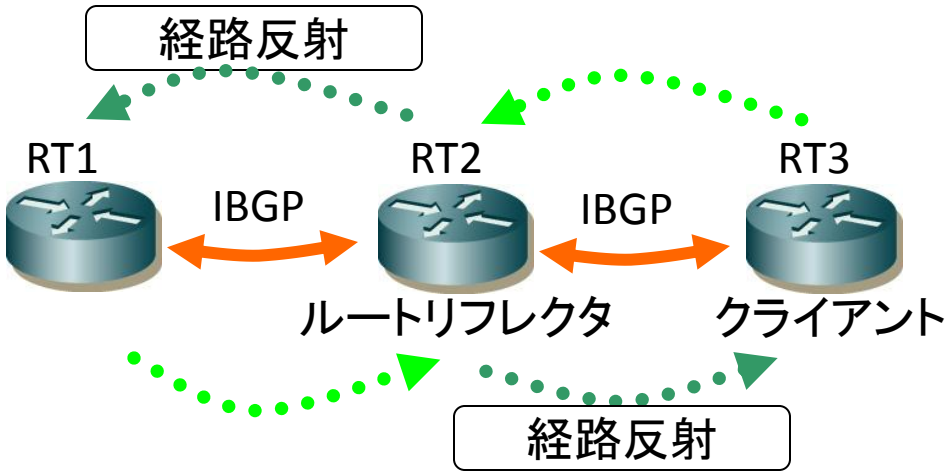

ルートリフレクタの利点と欠点

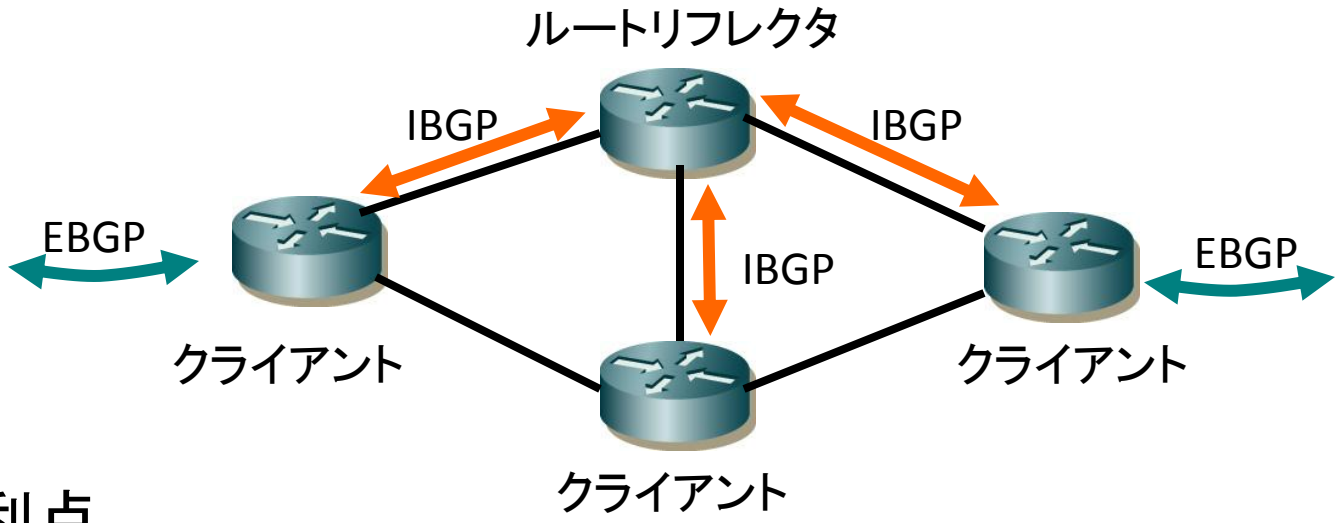

- 利点
  - IBGP接続数が削減できる
  - 比較的容易に導入できる
- 欠点
  - 経路削除時に、UPDATEが増える可能性がある
  - 経路情報が隠蔽されるため最適ではない経路を選ぶ可能性がある
    - リフレクタの階層はできるだけ物理トポロジに合わせるべし！

コンフェデレーション

- 外部からは一つのASのままだが、内部を複数のメンバASで構成する
- メンバAS間のBGP接続はEBGPに似た挙動をする
- メンバASにはプライベートASを使うのが一般的

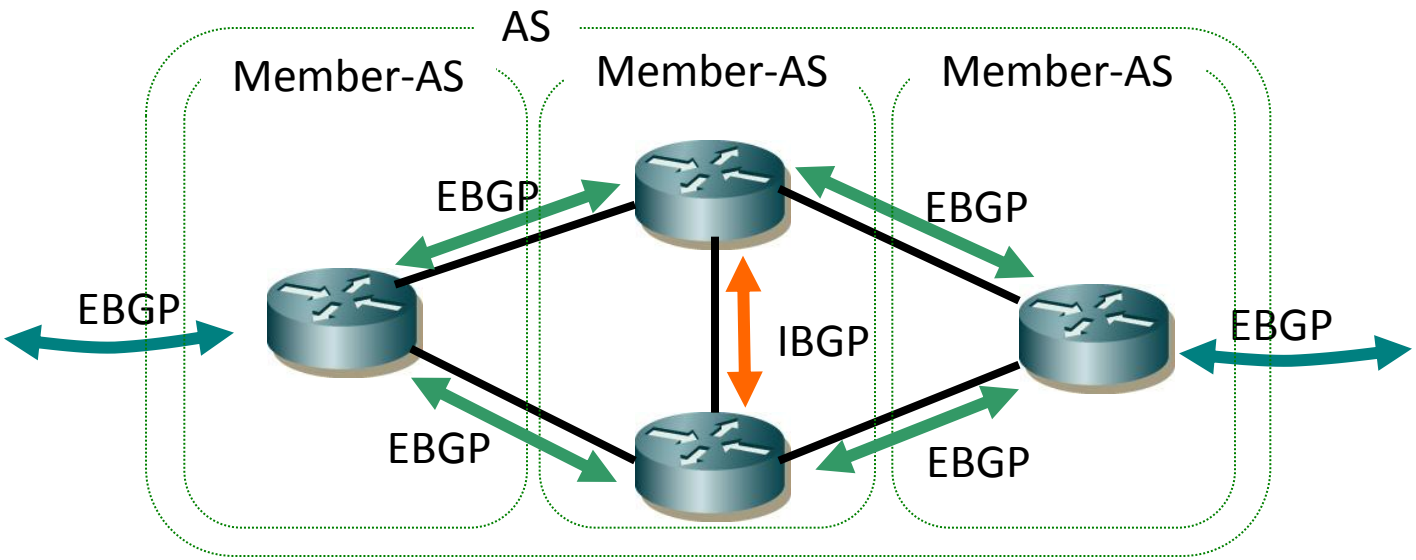

コンフェデレーションの利点と欠点

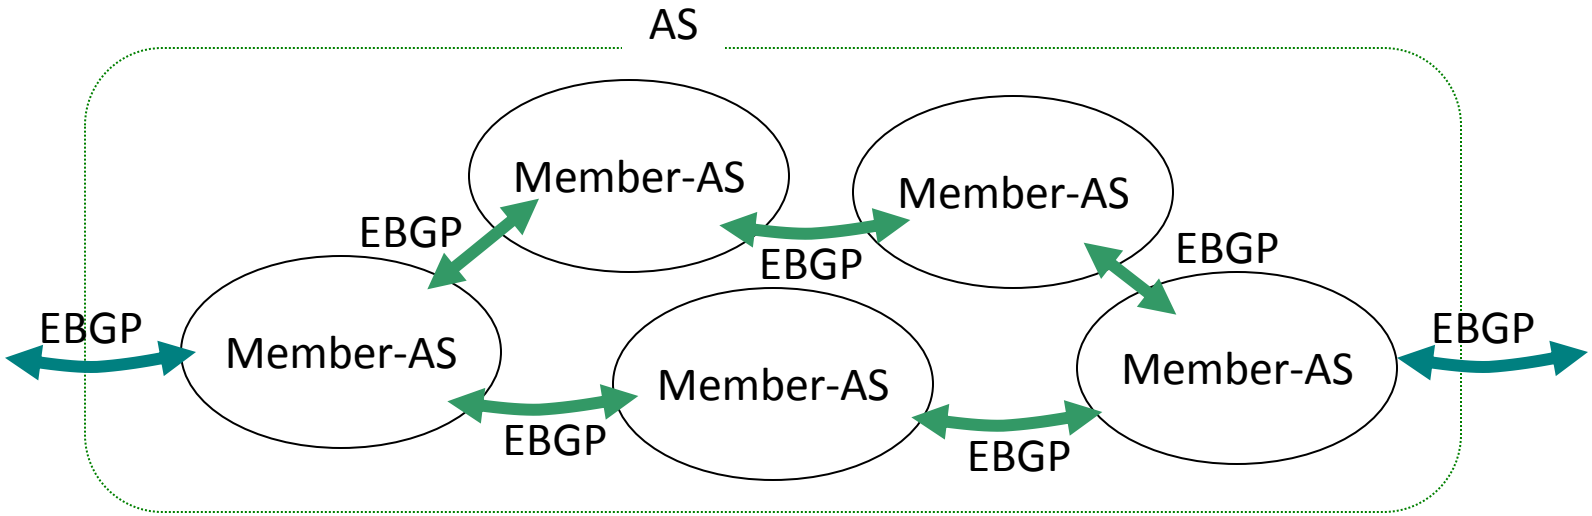

- 利点
  - IBGP接続数が削減できる
  - 管理区分を分けられる
- 欠点
  - 経路削除時にUPDATEが増える可能性がある
  - 経路情報が隠蔽されるため最適ではない経路を選ぶかもしれない

BGPパケット

BGPのプロトコルパケットの
フォーマットを解説する

BGP接続の確立

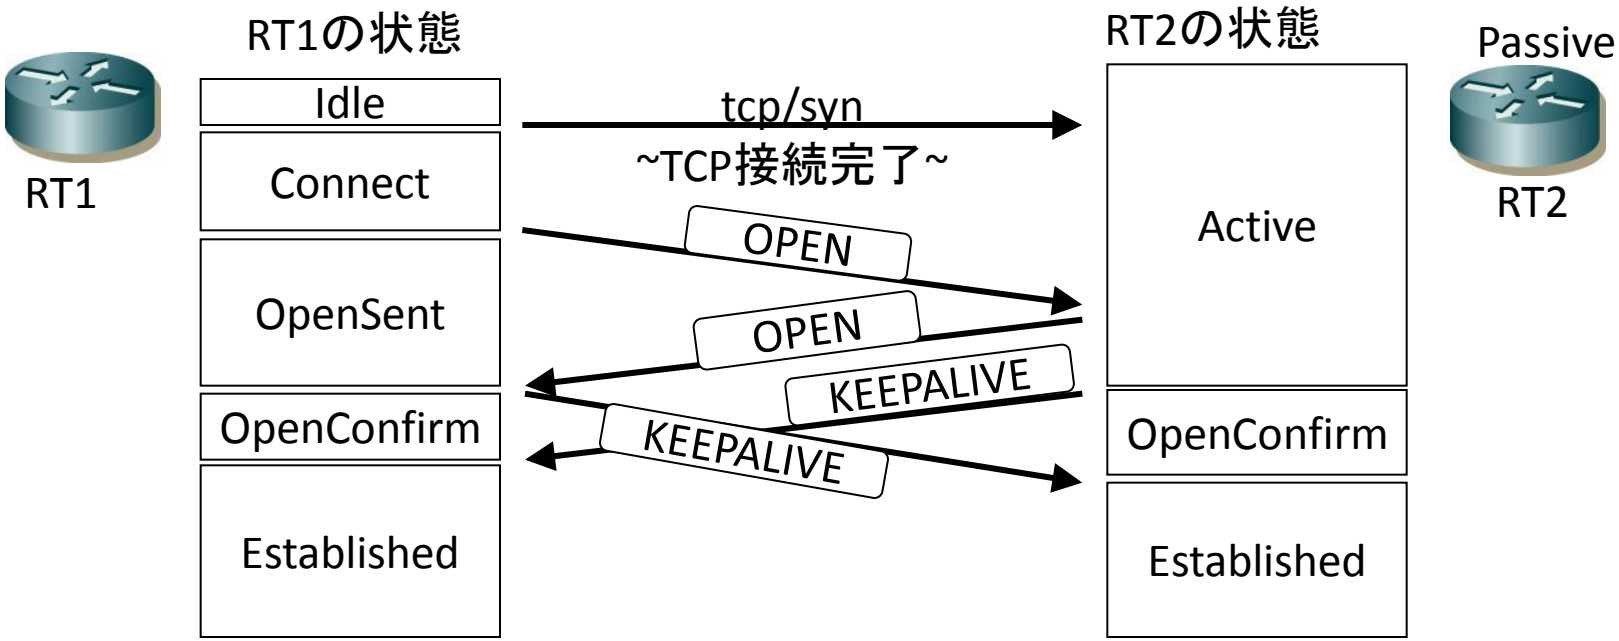

Idel – 初期状態
Connect – TCPの接続完了待ち
Active – 隣接からのTCP接続を待つ
OpenSent – OPEN送信後、隣接からのOPENを待つ
OpenConfirm – OPEN受信後、隣接からのKEEPALIVEを待つ
Established – BGP接続完了、経路交換の開始

BGP Message header

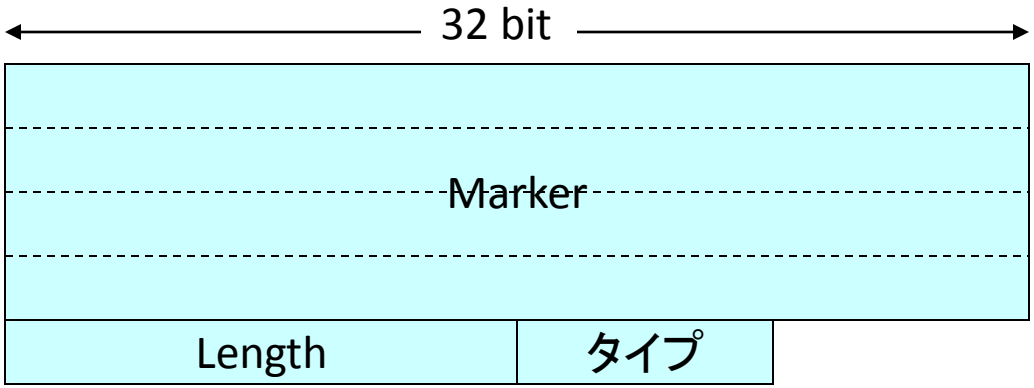

- Marker(マーカ)
  - 16-octetの全bitが1
  - 過去との互換性のため
- Length
  - 2-octetのメッセージ長
  - 19～4096

- タイプ（1-octet)
  1. OPEN
  2. UPDATE
  3. NOTIFICATION
  4. KEEPALIVE
  5. ROUTE_REFRESH

タイプ1 OPENメッセージ

- TCP接続が確立後、最初にやりとりされる
- パラメタの交換
  - バージョン、AS番号やBGP ID、ホールドタイム
  - オプションパラメータで各種機能を通知しあう

- タイプ4 KEEPALIVEで接続確立

タイプ1 OPENメッセージ

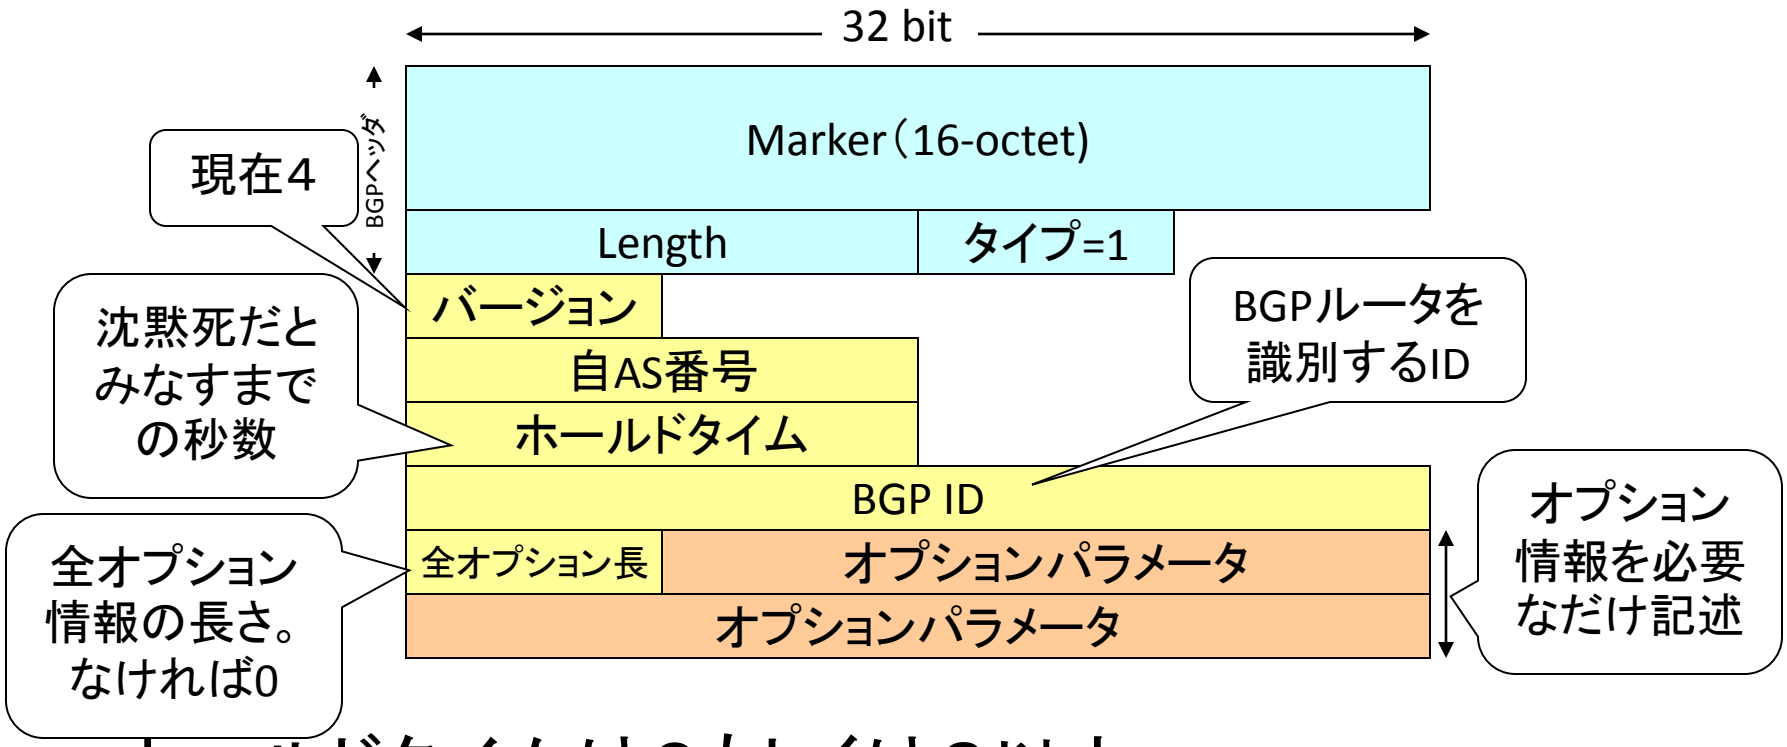

- ホールドタイムは0もしくは3以上
  - 小さな値が採用される
  - 0の場合、セッション維持にKEEPALIVEを利用しない

オプションパラメータフォーマット

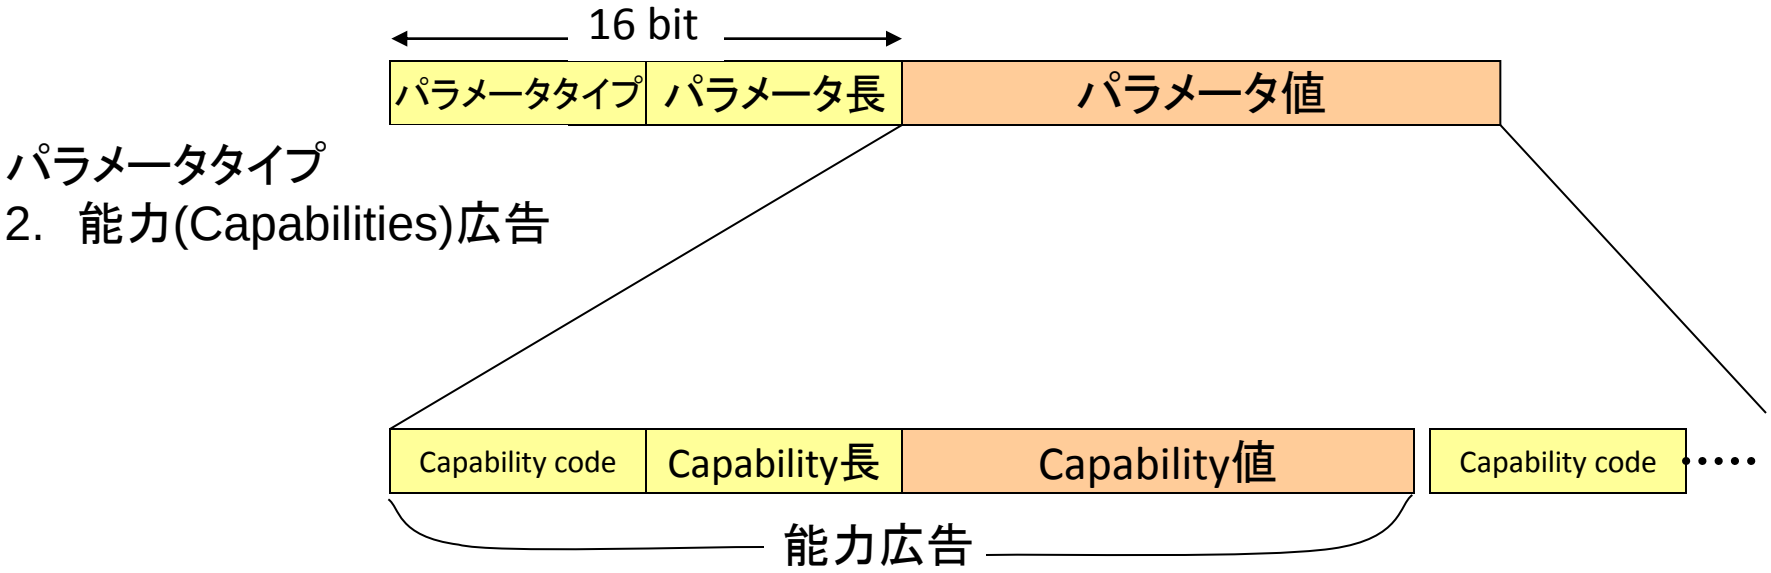

- 今のところ能力広告に利用
  - 利用可能な機能をピア先へ通知する

Capabilityコード

1	Multiprotocol Extension	サポートする<AFI, SAFI>の広告
2	Route Refresh	rfc版のRoute Refresh機能広告
3	Cooperative Route Filtering	
4	Multiple routes to a destination	
64	Graceful Restart	
65	Support for 4-octet AS number	
67	Support for Dynamic Capability	
128	Route Refresh(cisco)	Cisco独自のRoute Refresh機能広告

タイプ2 UPDATEメッセージ

- 経路情報を運ぶ
- 一つのメッセージで以下の情報を運べる
  - 複数のWithdrawn(取り消された)経路
  - 同じパス属性を持つ複数のNLRI
    - Withdrawn経路に含まれる経路は、同じメッセージ中でNLRIに含まれてはならない
- 情報の伝播保証はTCP任せ

タイプ2 UPDATEメッセージ

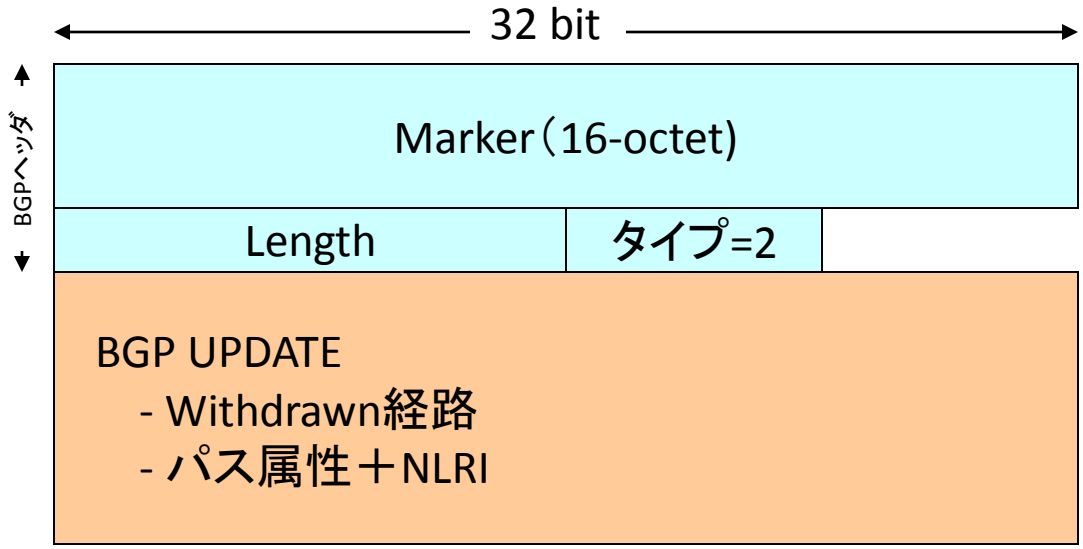

- パス属性が異なるNLRIは、異なるUPDATEメッセージで運ばれる

BGP UPDATEフォーマット

- Withdrawn経路
  - Withdrawnの長さ(2-octet)
  - Withdrawn経路の列挙
- 到達可能経路
  - 全パス属性の長さ(2-octet)
  - パス属性の列挙
  - NLRIの列挙

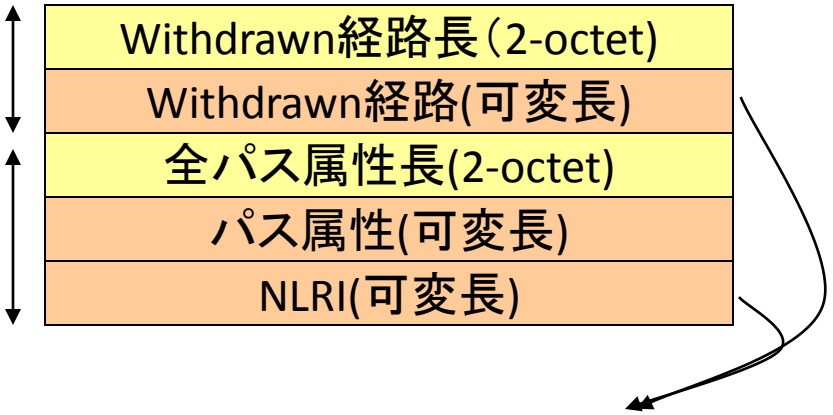

プレフィックスの格納形式

長さ(1-octet)	プレフィックス(可変長)

- 例：10.0.0.0/8

8(1-octet)	10(1-octet)

- 例：10.0.0.127/25

25(1-octet)	10.0.0.127(4-octet)

タイプ3 NOTIFICATIONメッセージ

- エラーを検出すると送信する
  - 送信後、すぐにBGP接続を切断する
- エラー内容がエラーコードとエラーサブコードで示される
  - 必要であれば、追加のデータも通知される

タイプ3 NOTIFICATIONメッセージ

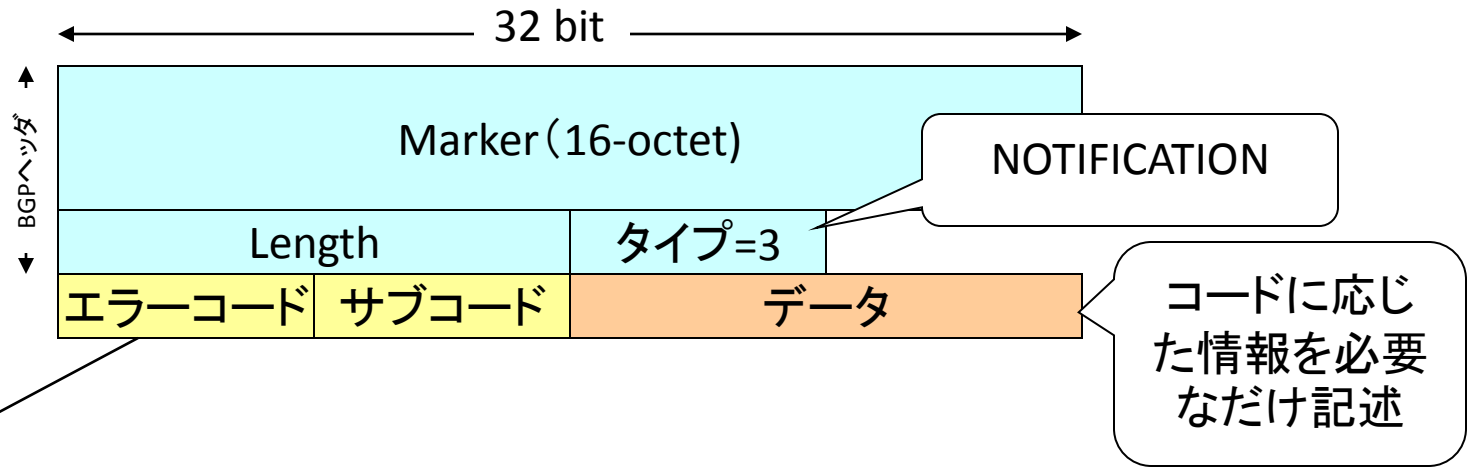

1. メッセージヘッダエラー
2. OPENメッセージエラー
3. UPDATEメッセージエラー
4. HoldTime超過
5. 状態遷移エラー
6. Cease

タイプ4 KEEPALIVEメッセージ

- BGP接続を確立させる
- BGP接続を維持する
  - 送信間隔内にUPDATEが無ければ送信
  - 送信間隔はホールドタイムの1/3程度
    - 最小で1秒
  - ホールドタイムが0の場合は送信してはならない

タイプ4 KEEPALIVEメッセージ

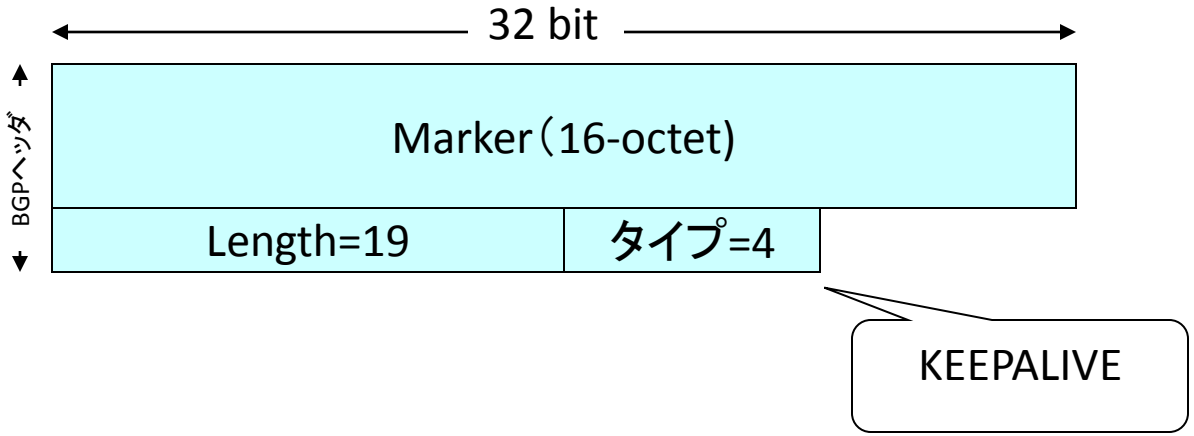

- KEEPALIVEであること以外、何も運ばない
- 最小のBGPメッセージ

タイプ5 ROUTE-REFRESHメッセージ

- 全経路の再広報を依頼する
  - <AFI, SAFI>を指定 (IPv4 unicastなど)
- 受信時、知らない<AFI, SAFI>であれば無視
- メッセージを送信するには、OPENメッセージのCapability広告でROUTE_REFRESH機能が通知されている必要がある

タイプ5 ROUTE-REFRESHメッセージ

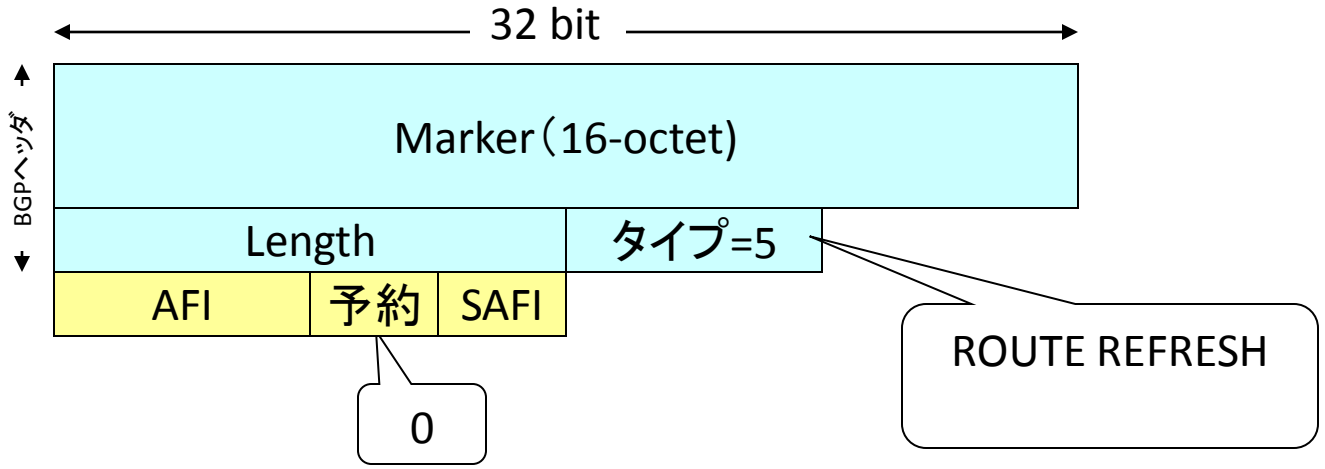

- AFI = Address Famiry Identifier
  - IPv4やIPv6など
- SAFI = Subsequent Address Famiry Identifier
  - UnicastやMulticastなど

パス属性

パス属性の構成と主要なパス属性
について解説する

パス属性フォーマット

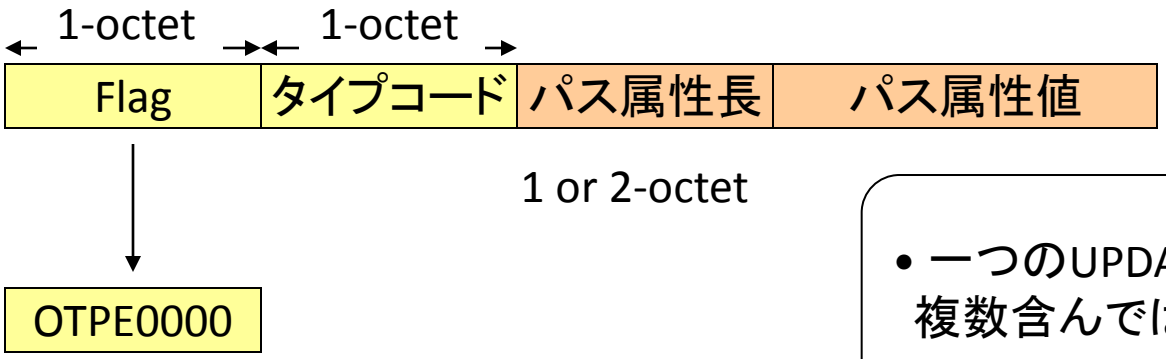

- 一つのUPDATEに同じパス属性を複数含んではいけない

O bit: Optional(パス属性の種別)
0=Wellknown, 1=optional
T bit: Transitive(パス属性の転送)
0=non-transitive, 1=transitive
P bit: Partial(パス属性の処理)
0=complete, 1=partial
E bit: Extended length
0=パス属性長は1-octet
1=パス属性長は2-octet

- Partial bit
  - オプション属性が、経路が広報されてから経由した全てのルータで解釈されたかどうかを示す
  - 0:全てのルータで解釈された
  - 1:解釈されなかったルータあり

パス属性の4つのカテゴリ

- 周知必須 - well-known mandatory [T]
  - 全てのBGPルータで解釈可能
  - NLRI情報があれば必ずパス属性に含まれる
- 周知任意 - well-known discretionary [T]
  - 全てのBGPルータで解釈可能
  - 必ずしも含まれない
- オプション通知 - Optional transitive [OT]
  - 一部のBGPルータでは解釈できないかもしれない
  - 解釈できなくても、そのまま他のルータに広報する
    - この際、Partial bitを1にセットする
- オプション非通知 - Optional non-transitive [O]
  - 一部のBGPルータでは解釈できないかもしれない
  - 解釈できない場合は、他のルータに広報するとき属性を削除する

ORIGIN属性値

- 周知必須
- NLRIの起源を示す3つのタイプ
- 経路生成元で付加され、その後変更されない

0 – IGP ・・・ AS内部で生成

1 – EGP ・・・ EGP[RFC904]から生成

2 – INCOMPLETE ・・・その他の方法で生成

AS_PATH属性

- 周知必須
- NLRIが通過してきたAS番号のリスト
  - 例えば“10 20 30”
  - 一番右は経路を生成したAS番号
  - 他のASに広報するときに先頭に自AS番号を付加
- 用途に応じてセグメントが用意されている
  - 通常はAS_SEQUENCEを利用する
  - 異なるAS_PATHを集約した場合はAS_SET
  - AS_SETは{}でくくられる表記が多い
    - 例えば”10 20 30 {40 41}”

AS_PATH属性フォーマット

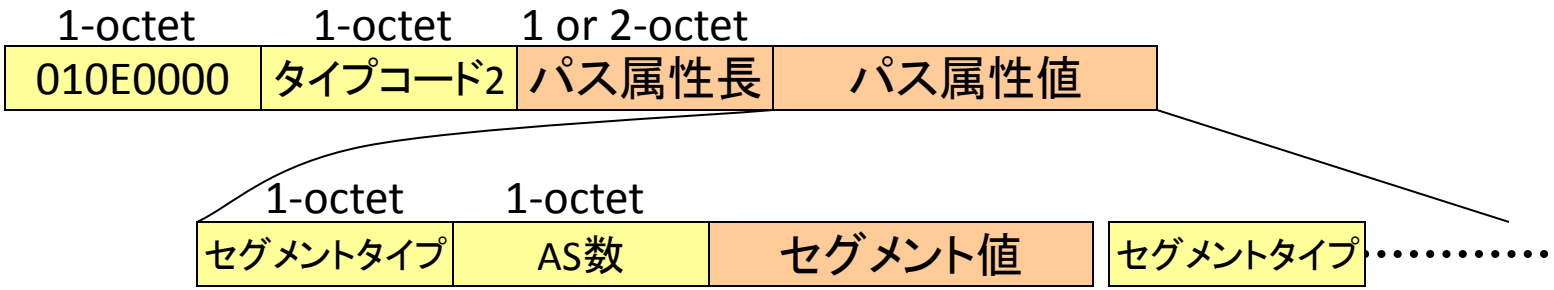

セグメントタイプ
1: AS_SET
UPDATEが経由したAS番号。順序は意味を持たない
異なるAS Pathの経路を集約したときに生成される
2: AS_SEQUENCE
UPDATEが経由したAS番号。順序に意味がある
経由した最新のAS番号はセグメント値の一番左

AS数
octet数ではなく、AS数
つまり、255個のASまで

セグメント値
2-octetのAS番号のリスト

- 新しい情報は先頭(左)に付加される

AS_PATH属性の処理

- 経路を転送する場合

広報先	
IBGP	変更しない
EBGP	自AS番号をAS_SEQUENCEタイプでAS_PATH属性の先頭に付加する

- 経路を生成する場合

広報先	
IBGP	空のAS_PATH属性を生成する
EBGP	AS_SEQUENCEタイプで自AS番号のみのAS_PATH属性を生成する

NEXT_HOP属性

- 周知必須
- NLRIへ到達するためのネクストホップIPアドレス

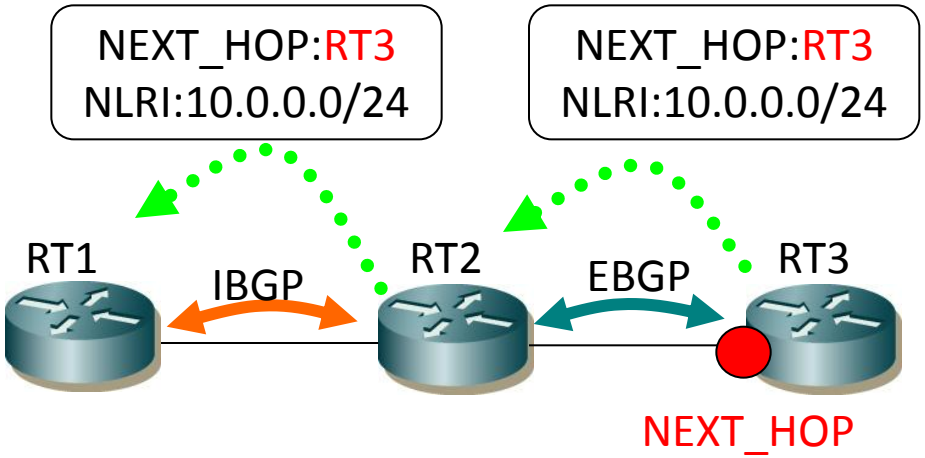

NEXT_HOP属性の処理

- IBGPに経路を転送するときは
  - 変更しない
  - ただし、設定で自身のIPアドレスに変更することも可能
- IBGPに生成した経路を広報するときは
  - その宛先に到達するためのネクストホップを設定する
  - ただし、自身のIPアドレスを設定することも可能
- EBGPに経路を広報するときは
  - BGP接続に利用している自身のIPアドレスを設定する
  - ただし、宛先のネクストホップがEBGPルータと共通のサブネットに属する場合は、他のルータのIPアドレスや自身の別なインタフェースのIPアドレスを設定することも可能

MULTI_EXIT_DISC(MED)属性

- 周知任意
- 隣接ASとの距離を表す4-octetの数値
  - 小さいほど優先される
  - 付加されていないと最小の0と見なす[RFC4271]
- EBGPで受信したMEDは他のEBGPでそのまま広報してはならない
- 幾つかの注意点
  - BGP MED Considerations [RFC4451]　など

LOCAL_PREF属性

- 周知
- AS内での優先度を示す4-octetの数値
  - 大きいほど優先される
- IBGPとEBGPで取り扱いが異なる
  - IBGPへの広報では付加されるべき
  - EBGPへの広報では付加してはならない
    - 付加されていた場合は無視
    - コンフェデレーションのSubAS間の場合は例外

COMMUNITIES属性

- オプション通知
- NLRIに32bitの数値で情報を付加する
  - この情報を元に予め実装したポリシ等を適用
- 上位16bitと下位16bitに分けた表記が一般的
  - 10進数で”上位:下位”の様に表記する
  - 自ASでの制御は上位に自AS番号を用い、下位で制御の情報を付加するのが一般的
  - つまり”asn:nn”

Well-Known-community

- (0xFFFFFF01) **NO_EXPORT**
  - 他ASに広報しない
  - コンフェデレーション内のメンバASには広報する
- (0xFFFFFF02) **NO_ADVERTISE**
  - 他BGPルータに広報しない
- (0xFFFFFF03) **NO_EXPORT_SUBCONFED**
  - 他ASに広報しない
  - コンフェデレーション内でメンバASにも広報しない
- (0xFFFFFF04) **NOPEER** [RFC3765]
  - 対等ピアには広報しない
  - まだ実装は無さそう

EBGP＆IBGPとパス属性

パス属性	EBGP	IBGP
ORIGIN	必須	必須
AS_PATH	必須	必須
NEXT_HOP	必須	必須
MULTI_EXIT_DISC	任意	任意
LOCAL_PREF	不許可	付加すべき
COMMUNITIES	任意	任意

BGPの経路選択

経路処理方法や、経路選択ルール
を解説する

BGPの経路処理

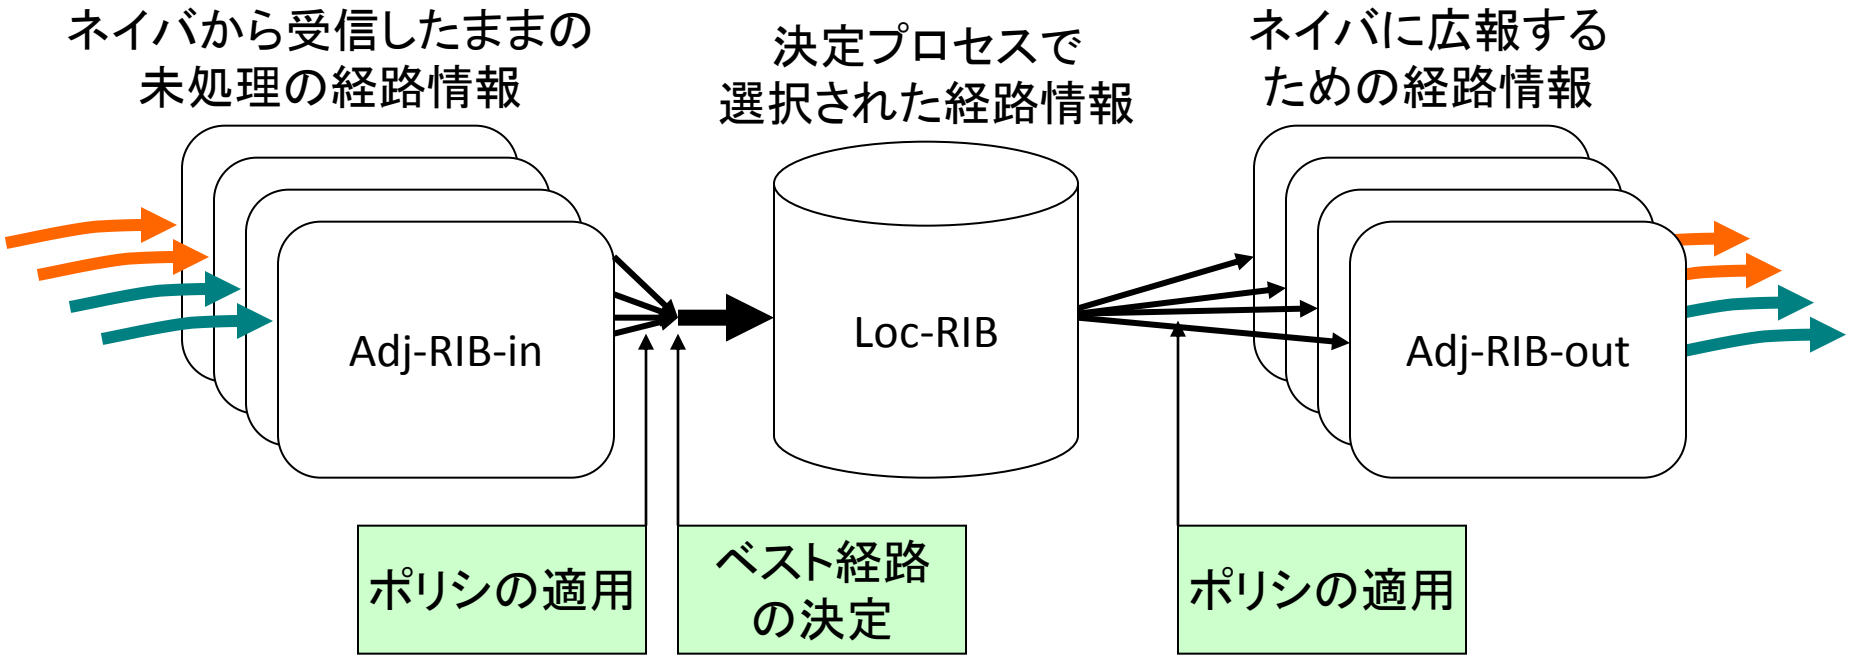

- ポリシは設定/実装依存
- 無理なポリシを適用すると、経路ループを引き起こす可能性があるので注意

ベスト経路のみを広報

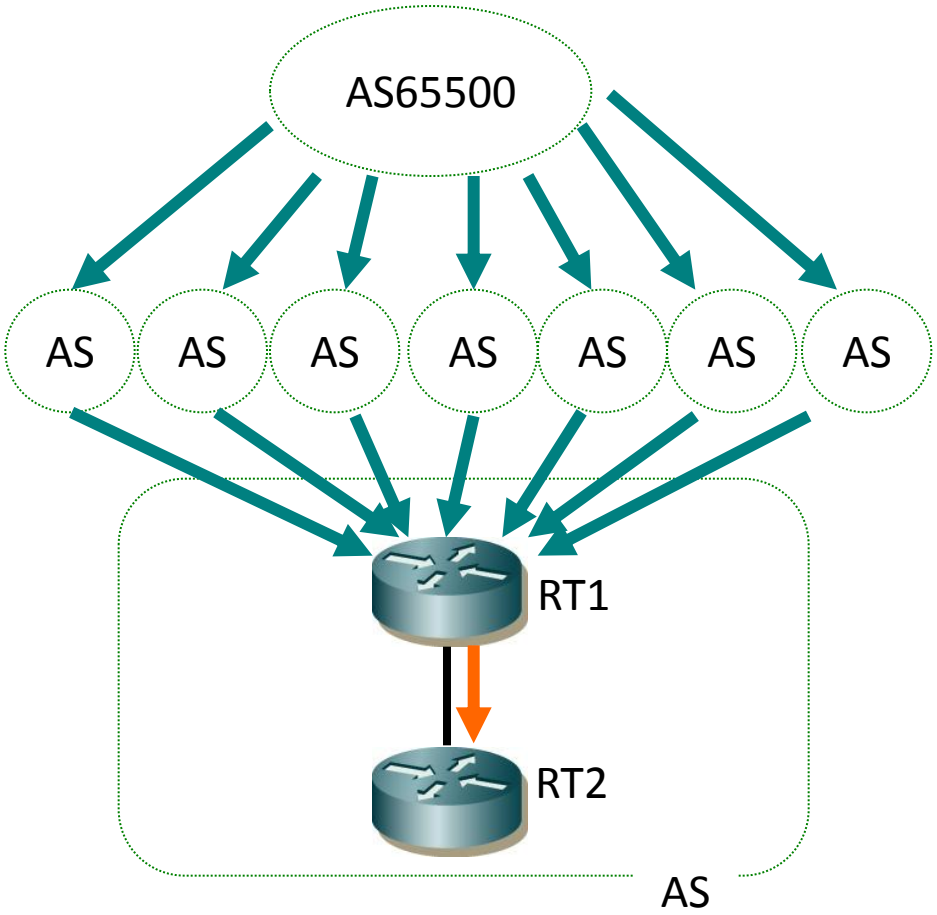

- RT1では7経路見える
  - ただし利用している経路はベストの1つだけ
- RT2へ広報されるのはRT1で選択されたベスト経路のみ

NEXT_HOP解決

- NEXT_HOP属性のIPアドレスまで到達可能であること
  - BGPも含めた経路で再帰解決して、最終的にBGPルータの隣接するネクストホップが得られる必要がある[RFC4271]

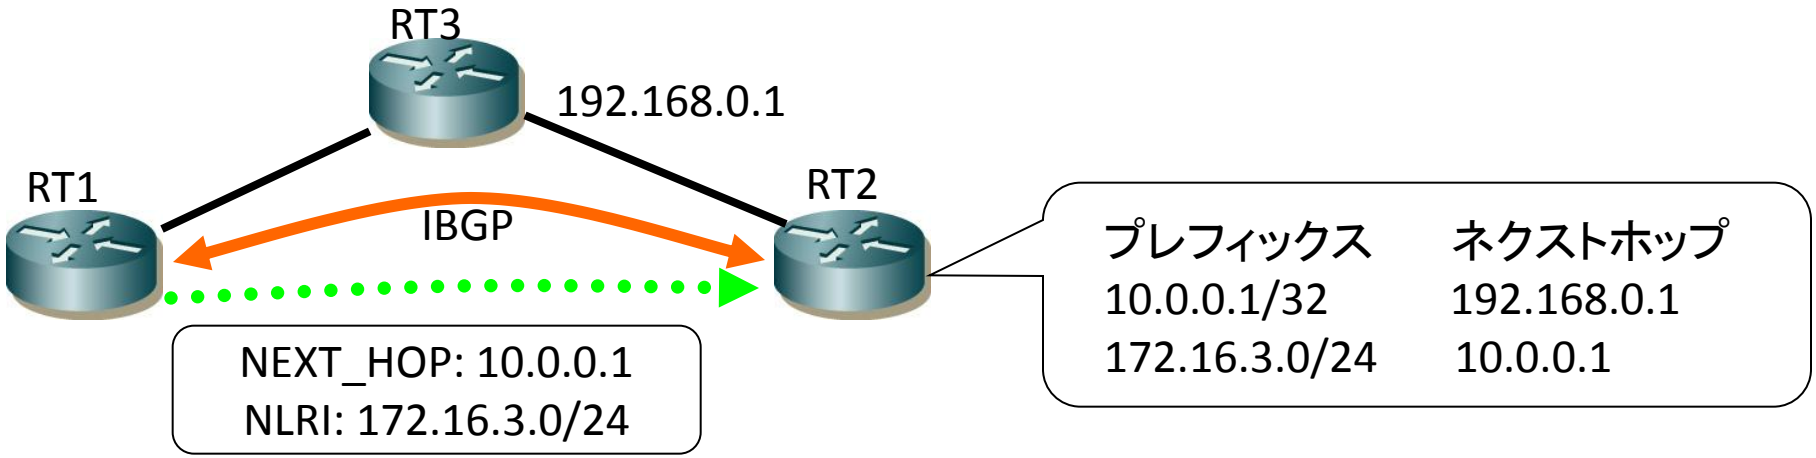

経路優先度

1	NEXT_HOP	NEXT_HOP属性のIPアドレスが到達不可能な経路は無効
2	AS loop	AS Path属性に自身のAS番号が含まれている経路は無効
3	LOCAL_PREF	LOCAL_PREF属性値が大きい経路を優先 (LOCAL_PREF属性が付加されていない場合は、ポリシに依存)
4	AS_PATH	AS_PATH属性に含まれるAS数が少ない経路を優先 (AS_SETタイプは幾つASを含んでも1として数える)
5	ORIGIN	ORIGIN属性の小さい経路を優先 (IGP < EGP < INCOMPLETE)
6	MULTI_EXIT_DISC	同じASからの経路はMED属性値が小さな経路を優先 (MED属性が付加されていない場合は、最小(=0)として扱う)
7	PEER_TYPE	IBGPよりもEBGPで受信した経路が優先
8	NEXT_HOP METRIC	NEXT_HOPへの内部経路コストが小さい経路が優先 (コストが算出できない経路がある場合は、この項目をスキップ)
9	BGP_ID	BGP IDの小さなBGPルータからの経路が優先 (ORIGINATOR_IDがある場合は、これをBGP IDとして扱う)
10	CLUSTER_LIST	CLUSTER_LISTの短い経路が優先
11	PEER_ADDRESS	ピアアドレスの小さなBGPルータからの経路を優先

属性値の評価

属性値がどう評価されるかを
解説する

受信経路で重要な属性値

- Local Preference
  - 受信時に設定する
- AS Path
  - 相手ASから広報される
- MED
  - 相手ASから設定されて広報される、もしくは受信時に上書き設定する
- NEXT_HOP Cost
  - AS内部のトポロジに依存する

Local Preference

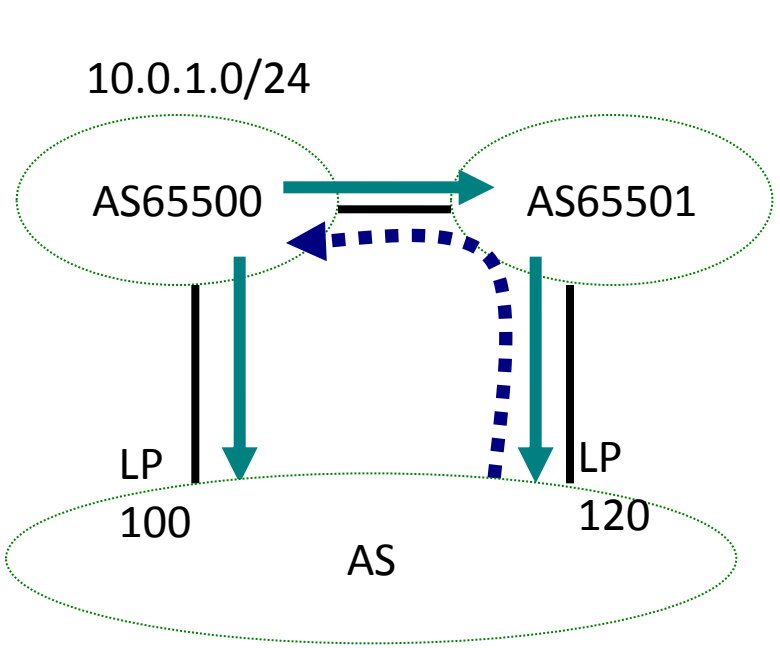

BGP UPDATE
trafficの流れ

AS's view:

prefix	LocPref	AS-PATH
10.0.1.0/24	100	65500
>10.0.1.0/24	120	65501 65500

- Local Preferenceの大きな値が優先
- あるAS経由の経路を優先したい場合に有効

AS Path

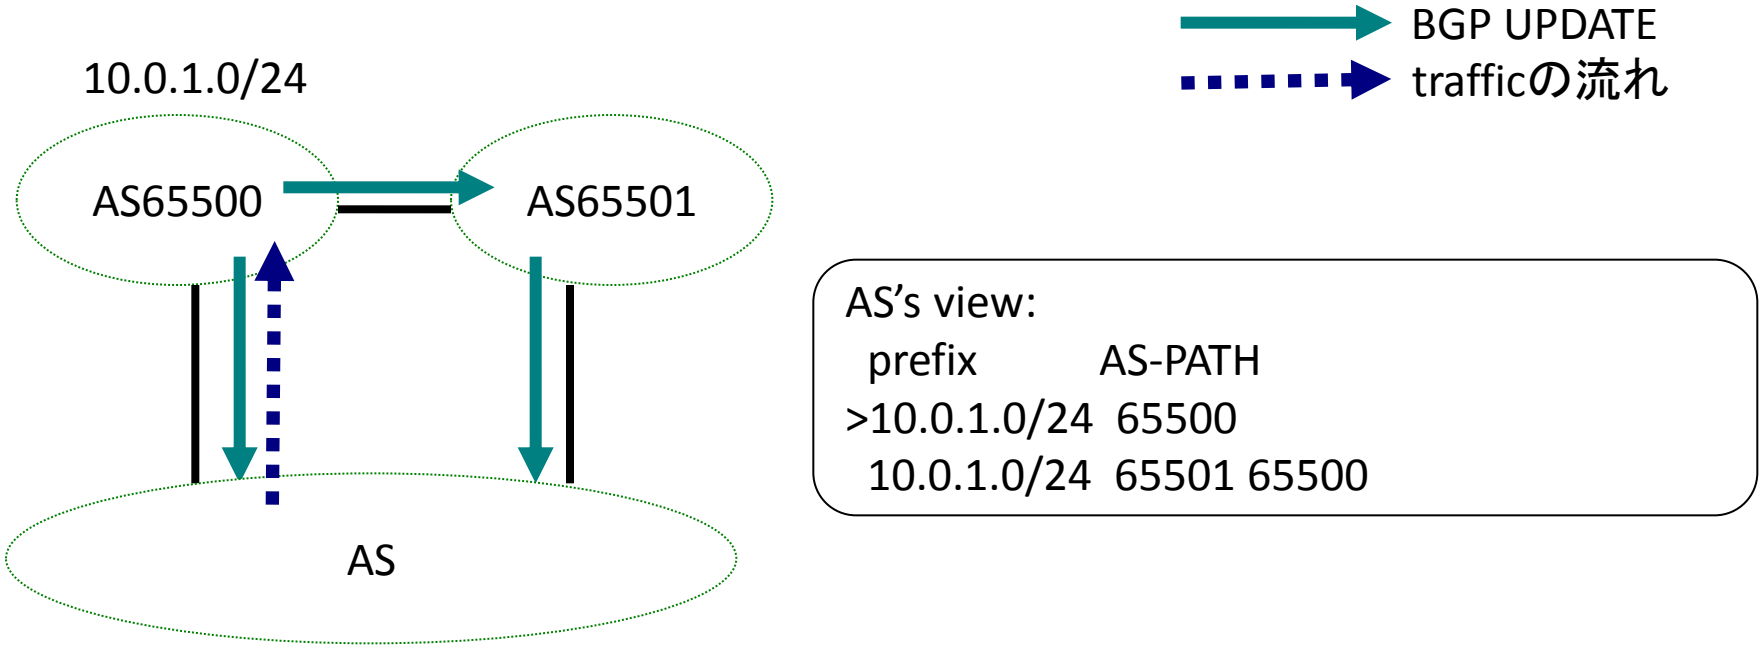

- AS Path長が短い経路が優先

MED(MULTI_EXIT_DISC)

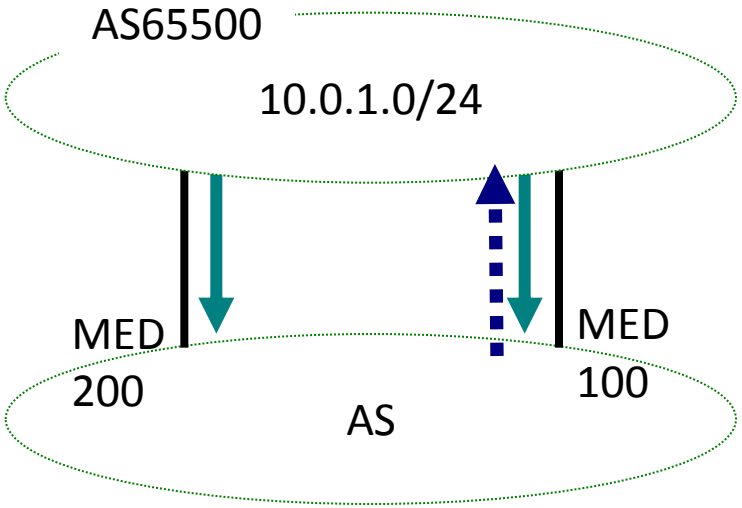

AS's view:

	prefix	MED
>	10.0.1.0/24	100
	10.0.1.0/24	200

- MEDの値が小さい経路が優先
- あるASとの複数接続に優先順位をつけたい場合に有効

NEXT_HOP COST

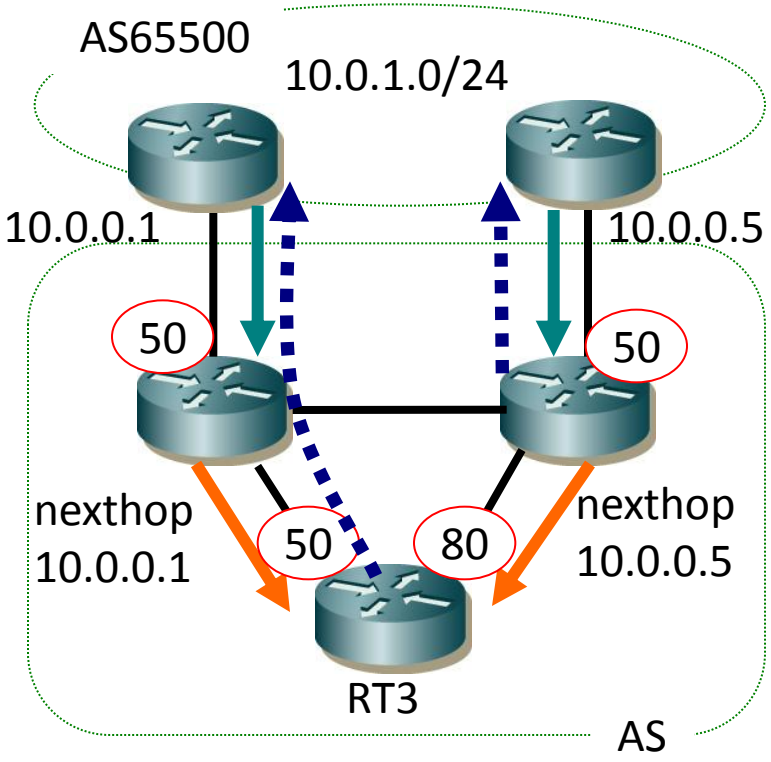

RT3's view:

prefix	nexthop [cost]
>10.0.1.0/24	10.0.0.1 [100]
10.0.1.0/24	10.0.0.5 [130]

- NEXT_HOPへのigpコストが小さい経路を優先
- これを利用したのがclosest exit

他ASへの広報で重要な属性値

- AS Path
  - prependでAS Path長を伸ばす
- MED
  - 複数接続に優先順位をつける
- Community
  - 広報先ASでの処理を期待する

- 相手とのポリシのすり合わせが重要

AS Path (広報時)

AS65500

prefix	AS-PATH
>10.3.0.0/16	65509
10.3.0.0/16	65501 65509

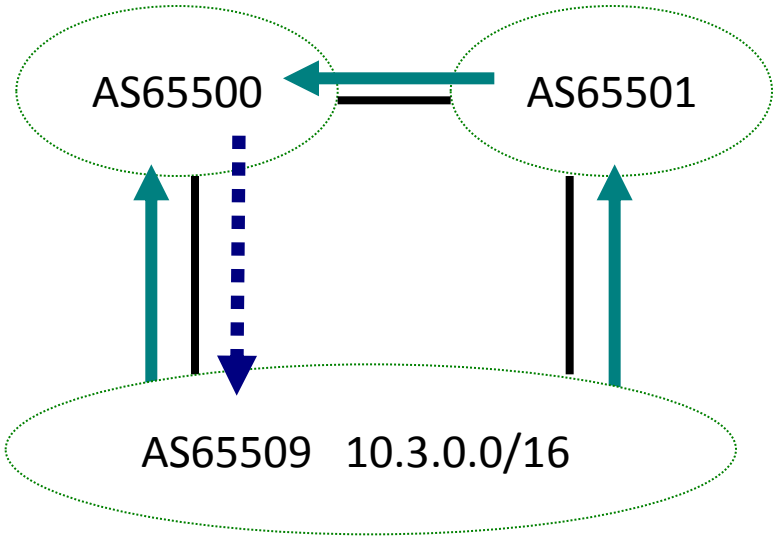

BGP UPDATE

trafficの流れ

- AS Path長が短い経路が優先

AS Path prepend

AS65500

prefix	AS-PATH
10.3.0.0/16	65509 65509 65509
>10.3.0.0/16	65501 65509

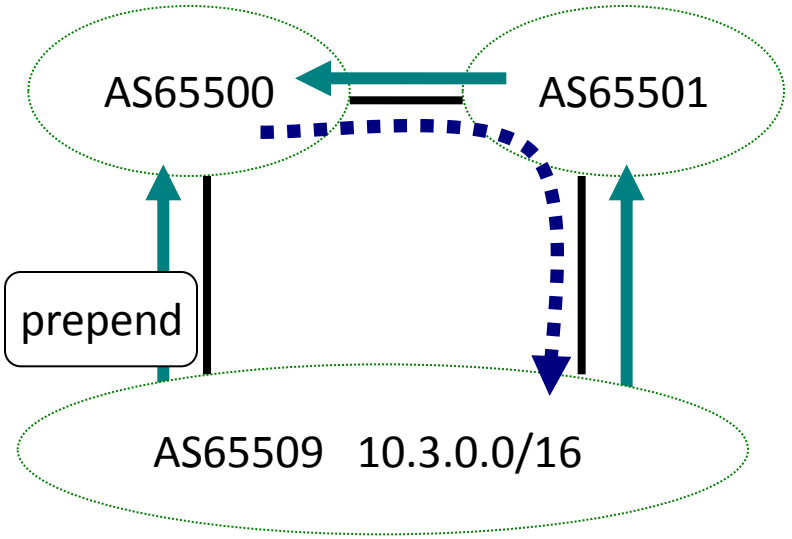

BGP UPDATE

trafficの流れ

- あるASとの接続リンクを利用したくない場合に、AS Pathを長くして優先度を下げることが出来る

広報通常時

AS65500

prefix	AS-PATH
10.3.0.0/16	65509
10.3.0.0/16	65509

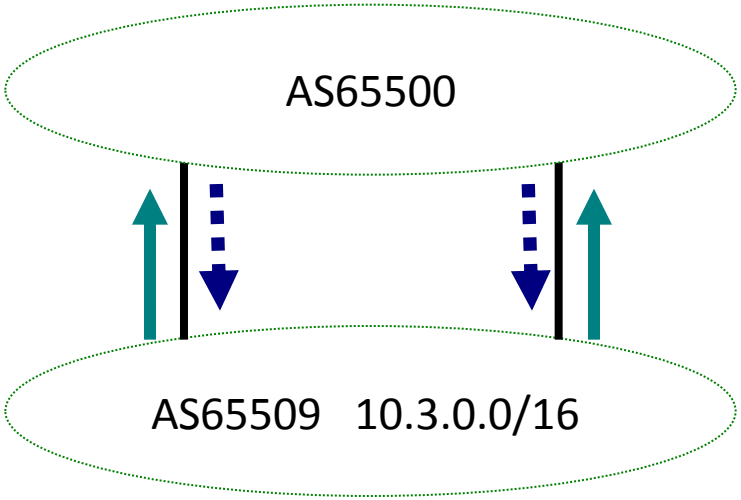

BGP UPDATE
trafficの流れ

- AS65500で特別な制御を行っていなければ、closest exitになるはず
  - トラヒックの分散は相手ASの構成に依存する

MED（広報時）

AS65500

prefix	MED	AS-PATH
>10.3.0.0/16	100	65509
10.3.0.0/16	200	65509

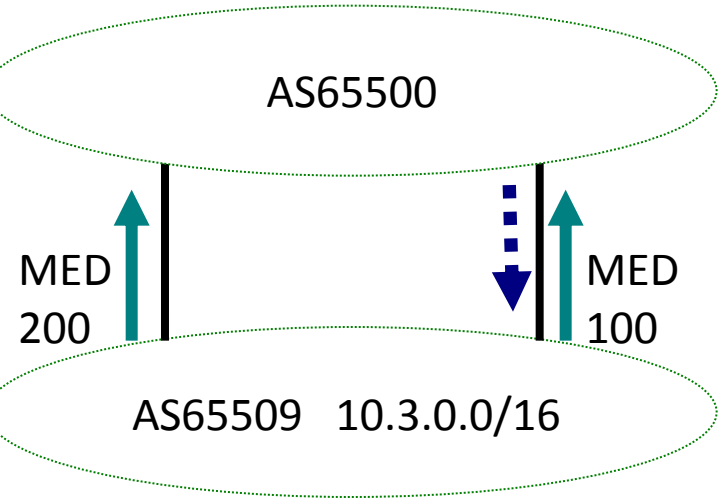

BGP UPDATE
trafficの流れ

- 複数接続に優先順位をつけたい場合
- AS65500でMEDを受け付ける設定になっていれば、小さなMED値の経路が優先される
- MEDを受け付けるかどうかは相手ASのポリシ依存

Community利用例

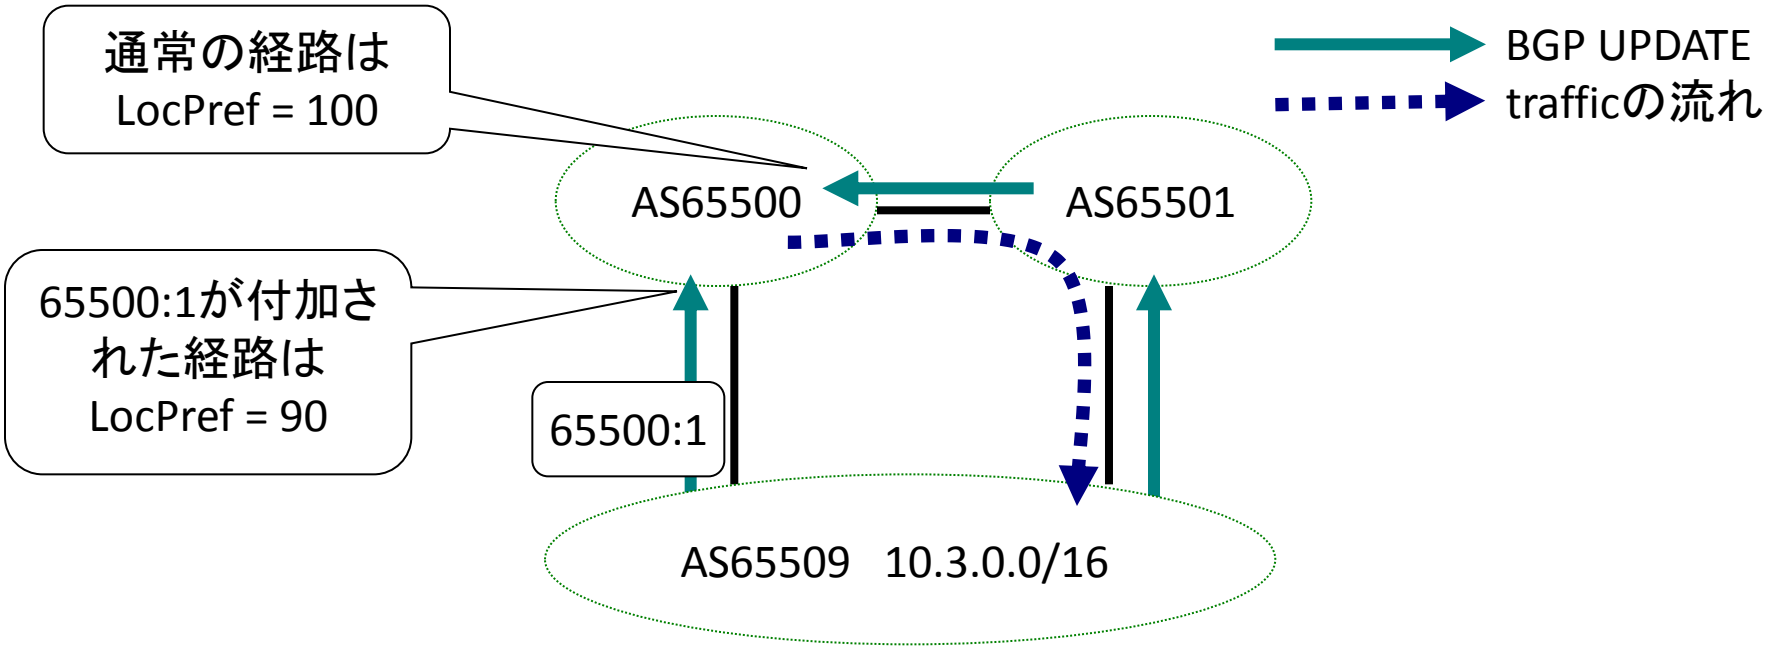

- AS65500がCommunity制御を実装していれば利用できる
- 経路にCommunity情報を付加して、その制御を利用する
- Communityを受け付けるかどうかはASのポリシ依存

BGPのパス選択

OSPFとBGPの関わりなどを
解説する

closest exitとBGP

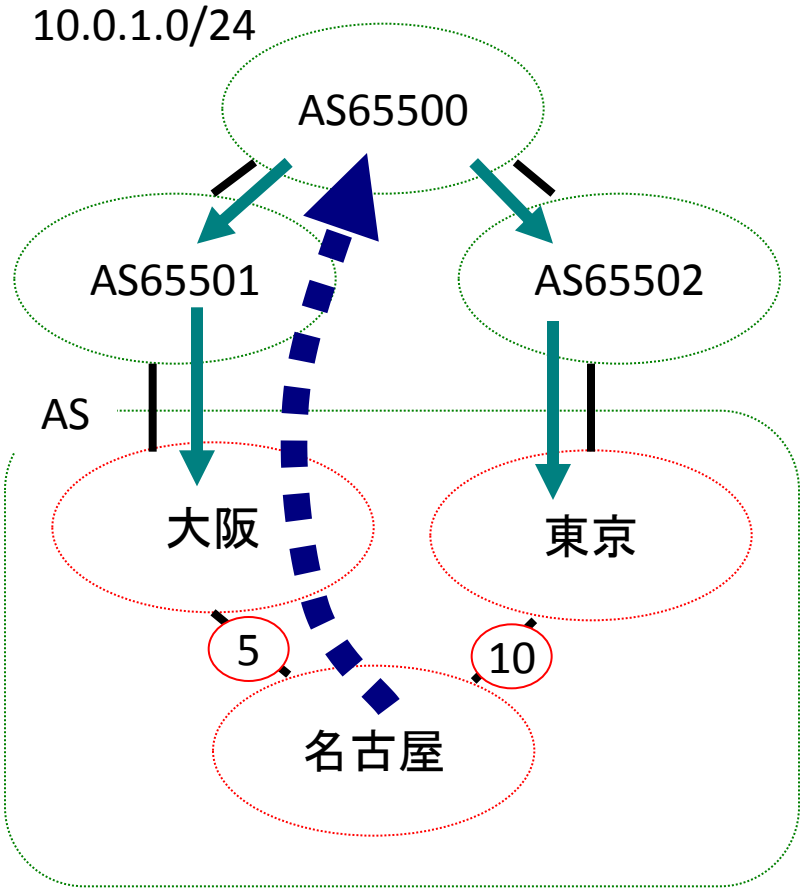

BGP UPDATE
trafficの流れ

名古屋

prefix	AS-PATH	
>10.0.1.0/24	65501 65500	5
10.0.1.0/24	65502 65500	10

- 名古屋では、65501(大阪)経由を選択中

OSPFのコスト変更

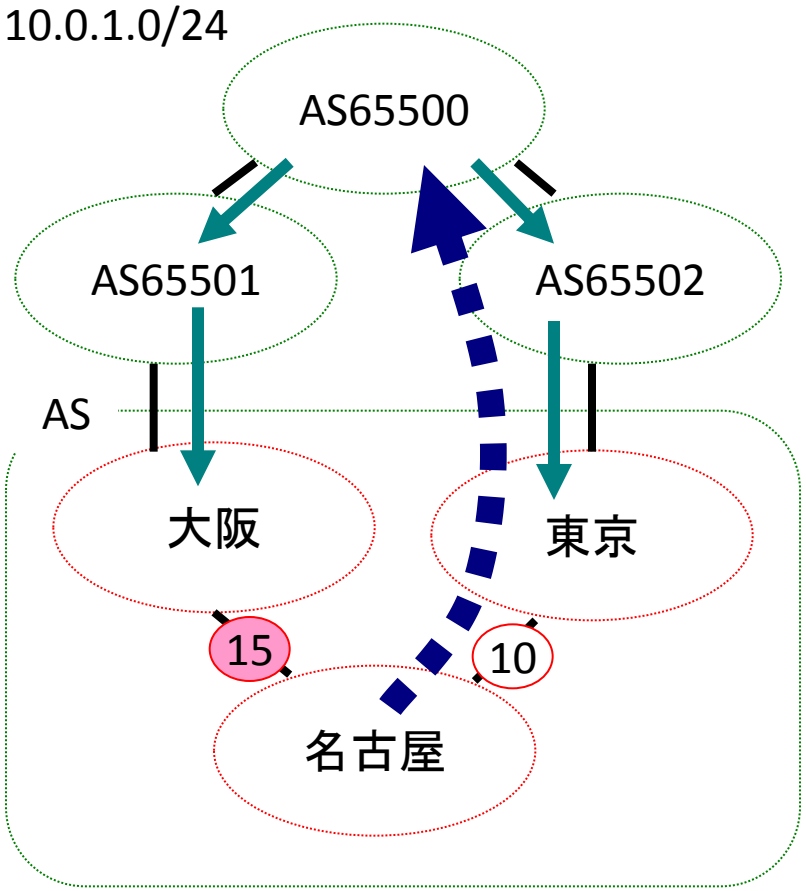

BGP UPDATE
trafficの流れ

名古屋

prefix	AS-PATH	
10.0.1.0/24	65501 65500	15
>10.0.1.0/24	65502 65500	10

- 名古屋からは65502(東京経由)に更新

OSPFコストとBGP

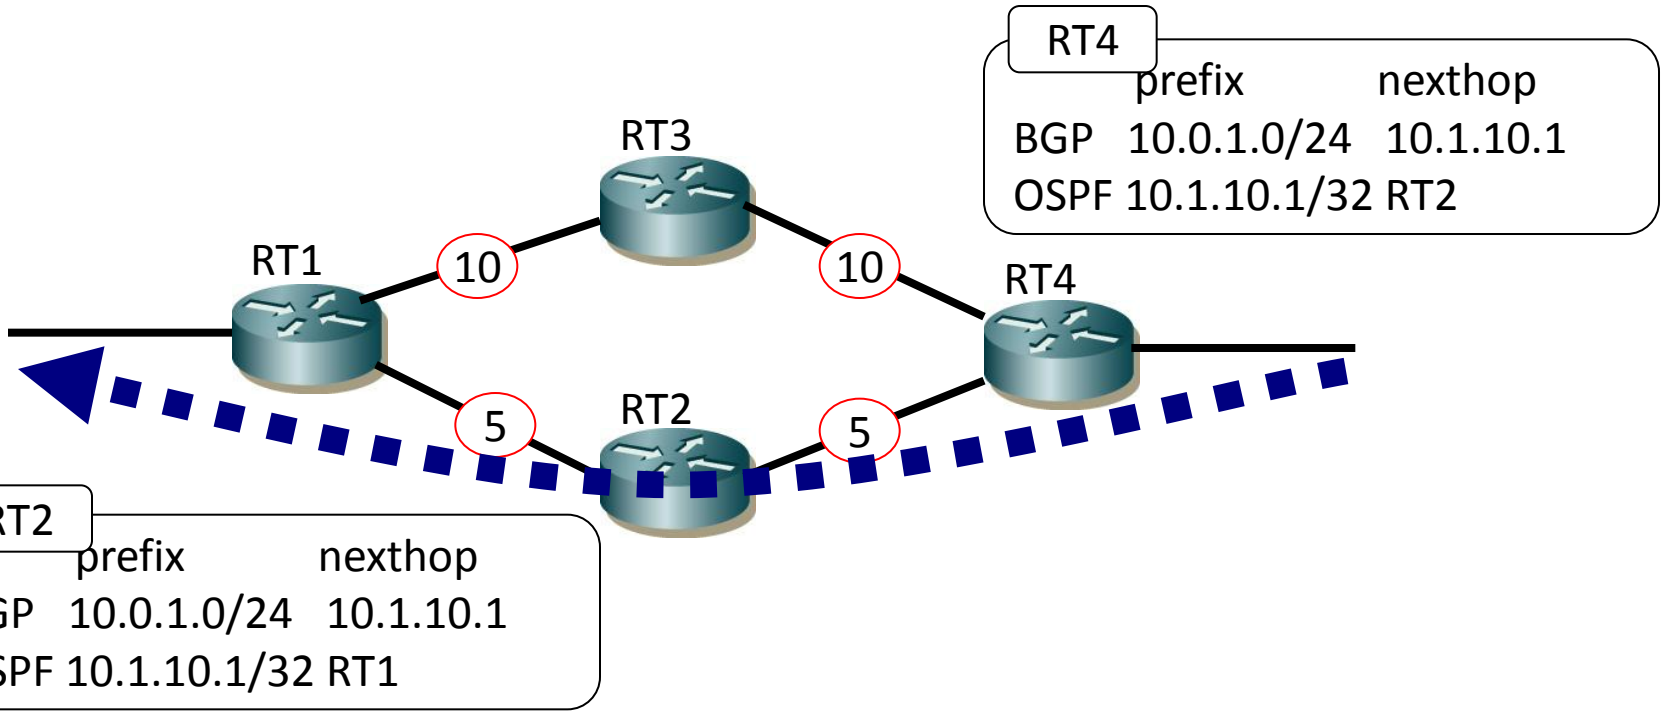

- BGPネクストホップへのOSPFコストが一番小さな経路が選択される

RT2が突然reload

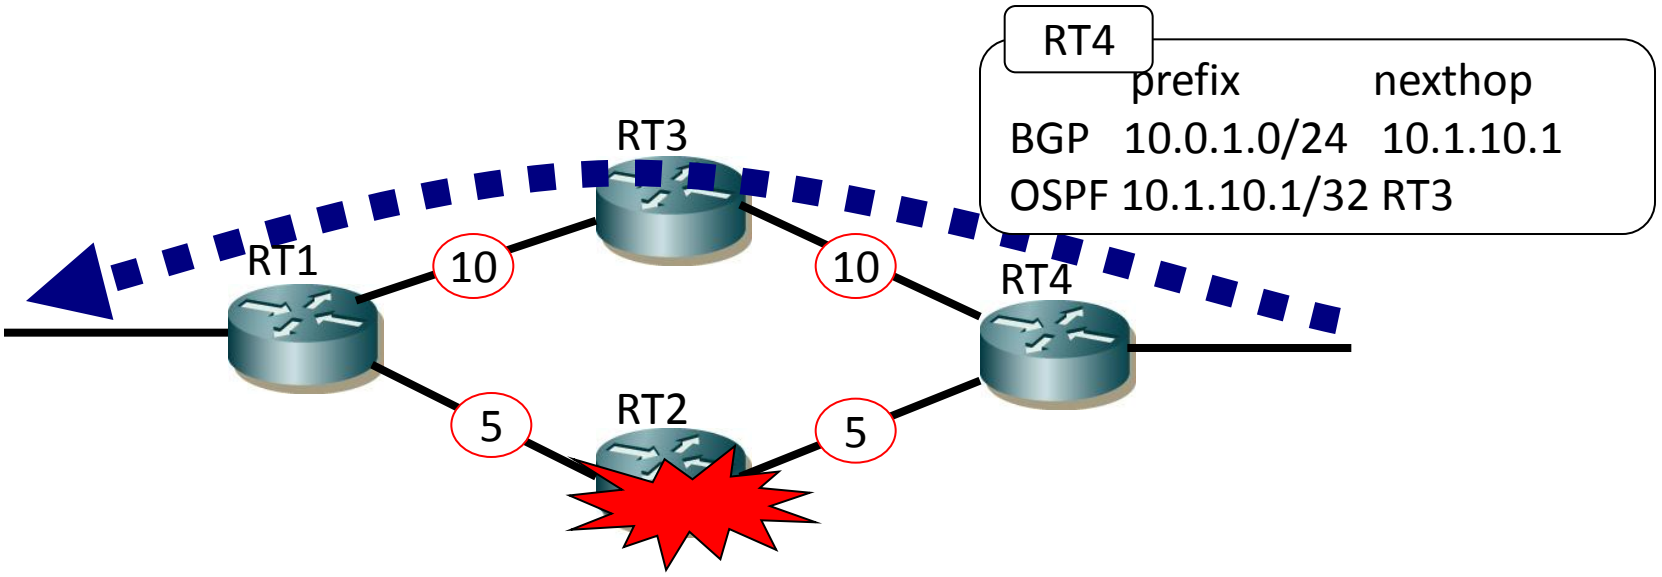

- RT2が再起動・・・
- 他のルータが障害を検出し、OSPF再計算
- トラヒックはRT3を迂回している

OSPFとBGPの収束時間が違う

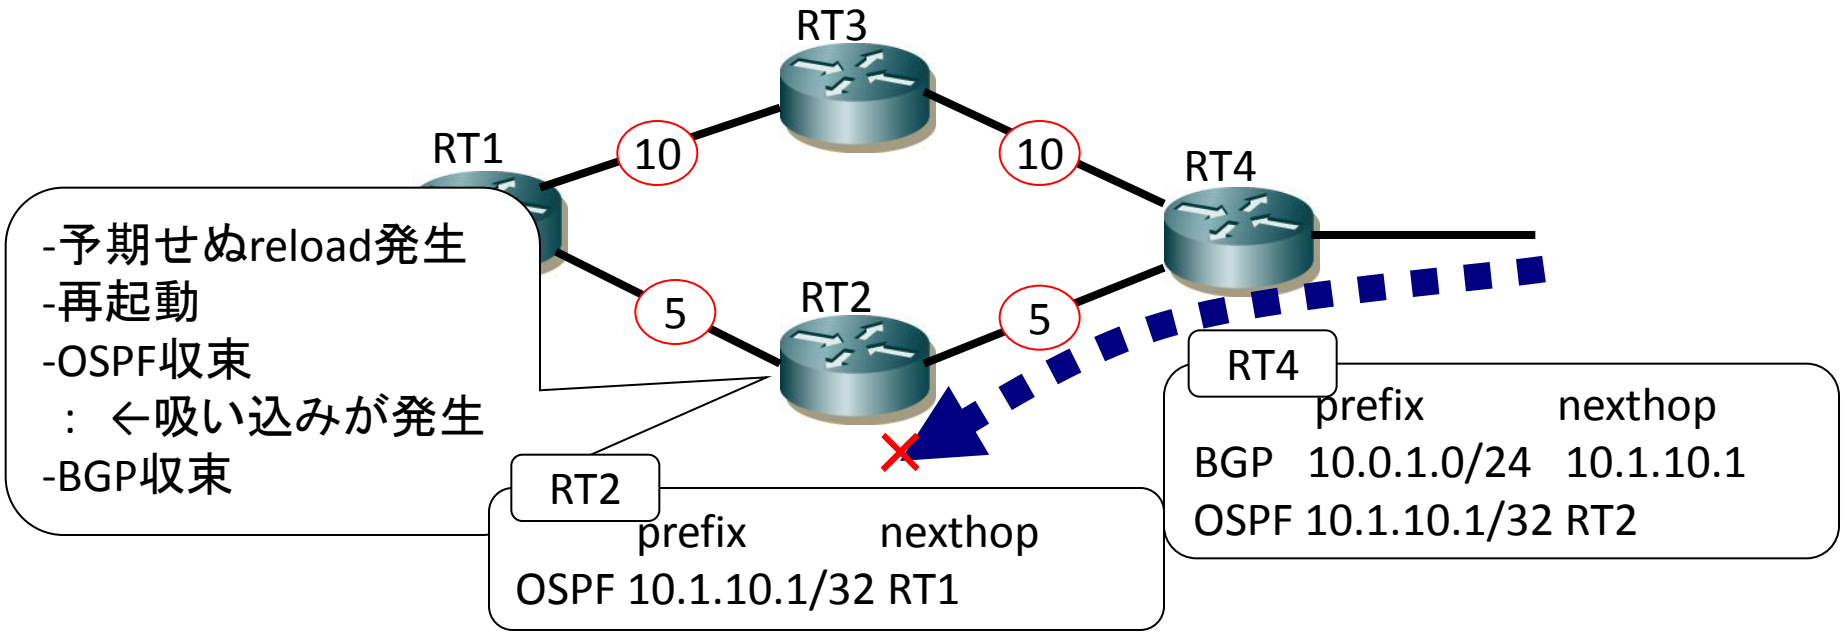

- OSPFは収束したので、RT4ではRT2側を選択
- RT2はまだBGP経路を受信しきっていない
- その間、RT2がトラヒックを破棄してしまう

OSPF StubRouterAdvertisement

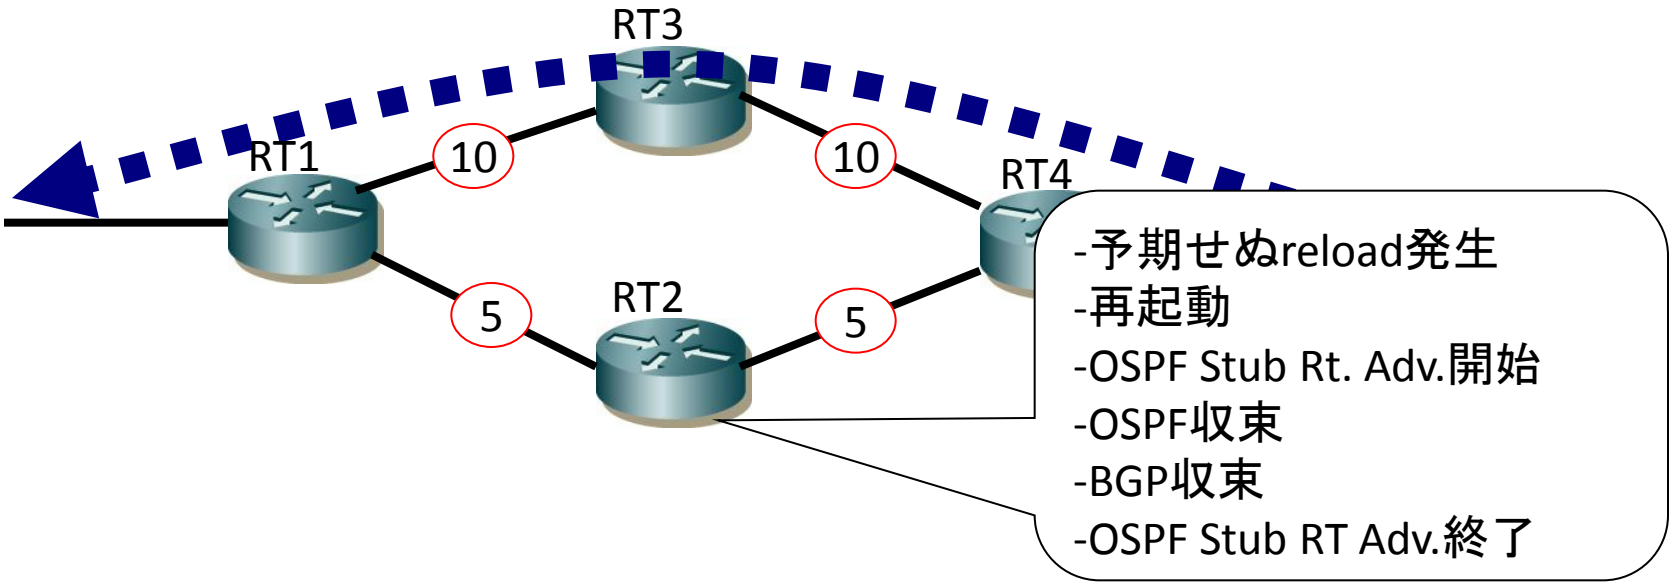

- ルータを経由するトラヒックを迂回させる機能
- OSPF起動後に実施して、BGP収束までトラヒックを迂回させる等の利用が考えられる
- 詳しくは[RFC3137]を参照

BGP Multipath

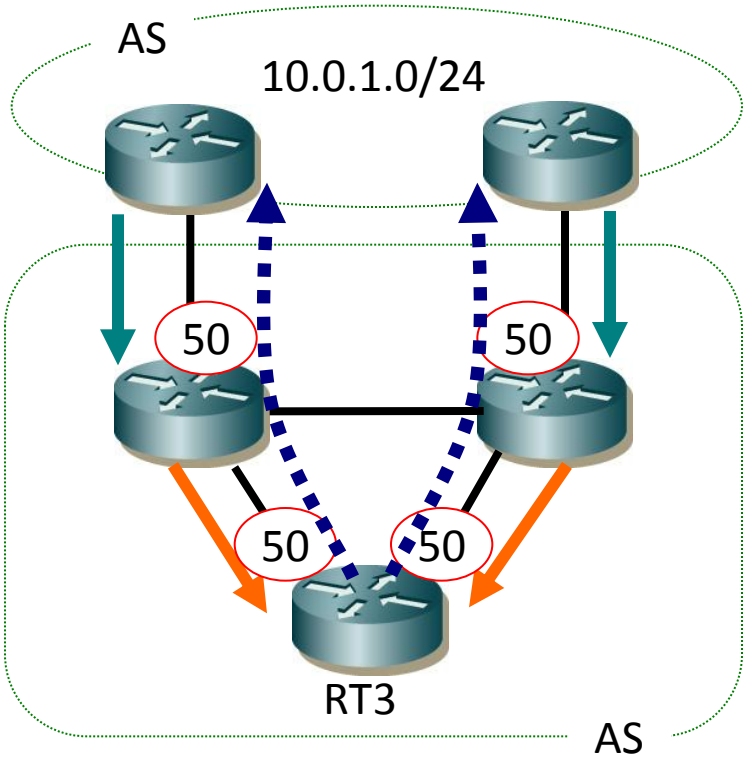

- 複数の経路を有効にできる手法
  - ベンダの実装依存
  - 経路選択で特定の段階まで優先度が一致すればMultipathとして扱う
- RT3でMultipathを使用
  - RT3が他のルータに広報する経路は通常選択される1つのベスト経路のみ

BGP4+

- BGP4のマルチプロトコル(IPv6)対応
  - [RFC2545] [RFC2858]
- OPENメッセージでマルチプロトコル対応を通知
- BGPセッションはIPv4 or IPv6どちらでも可
  - IPv6だと global unicast or link-localが選べる
  - IPv6の到達性を保証するには、IPv6でセッションを確立するのがお勧め
- NEXT_HOPは global unicast (+ link-local)
  - プレフィックスと共にMP_REACH_NLRIで運ばれる

BGPの転用

- BGPは、ルータにTCPで情報を通知できる
- パス属性で情報を運ぶ
  - IPv6経路等もパス属性で運ばれる

    ∴パス属性のみでNLRIが無いUPDATEも有効
- 経路を運ぶ以外の目的にも利用されるようになってきた

おわり

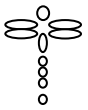

参考資料

- BGP NOTIFICATIONメッセージコード
- BGP パス属性コードタイプ

BGP NOTIFICATIONメッセージ

1. メッセージヘッダエラー
2. OPENメッセージエラー
3. UPDATEメッセージエラー
4. HoldTime超過
5. 状態遷移エラー
6. Cease

コード1 メッセージヘッダエラー

- メッセージヘッダの処理中にエラーを検出

サブコード	エラー内容	データに含まれる値
1.	Markerの値が不正	
2.	Lengthの値が不正	不正だと判断したLengthの値
3.	解釈できないタイプ	解釈できなかったタイプの値

コード2 OPENメッセージエラー

- OPENメッセージの処理中にエラーを検出

サブコード	エラー内容	データに含まれる値
0.	特定なし	
1.	バージョン不一致	サポートする最も近いバージョン
2.	AS番号でエラー	
3.	BGP IDが不正	
4.	解釈できないオプションパラメータがある	
5.	[Deprecated]	
6.	ホールドタイマ値が受け入れられない	
7.	未サポートのCapability	サポートしていないCapabilityコード

コード3 UPDATEメッセージエラー

- UPDATEメッセージの処理中にエラーを検出

3	サブコード	データ

サブコード	エラー内容	データに含まれる値
1.	アトリビュートが不正	
2.	周知必須属性が解釈できなかった	エラーを検出した属性(TLV)
3.	あるべき周知必須属性が無かった	無かった周知必須属性のタイプコード
4.	フラグが不正	エラーを検出した属性(TLV)
5.	パス属性長が不正	エラーを検出した属性(TLV)
6.	ORIGIN属性値が未規定の値	エラーを検出した属性(TLV)
7.	[Deprecated]	
8.	NEXT_HOP属性値の書式が不正	エラーを検出した属性(TLV)
9.	オプション属性値でエラー	エラーを検出した属性(TLV)
10.	NLRIの書式が不正	
11.	AS_PATH属性の書式が不正	

コード4 HoldTimer超過

- HoldTimer期間中に、UPDATEもKEEPALIVEも受信しなかった

コード5 状態遷移エラー

- 予期せぬイベントが発生

コード6 Cease

- その他のエラーを検出

サブコード	エラー内容	データに含まれる値
1.	最大受信経路数に到達	<AFI（2), SAFI(1), prefix上限値(4)>
2.	Administrative Shutdown	
3.	設定削除	
4.	Administrative Reset	
5.	接続拒否	
6.	その他の設定変更	
7.	接続競合の解決	
8.	リソース不足	

BGPパス属性値コードタイプ

1	ORIGIN	周知必須	経路の生成情報
2	AS_PATH	周知必須	経路が通過したASの情報
3	NEXT_HOP	周知必須	経路の宛先IPアドレス
4	MULTI_EXIT_DISC	オプション非通知	複数出口から経路選定する際の優先度
5	LOCAL_PREF	周知任意	経路の優先度
6	ATOMIC_AGGREGATE	周知任意	経路が途中で集約された情報
7	AGGREGATOR	オプション通知	経路集約を行ったルータ
8	COMMUNITIES	オプション通知	処理を行うための情報

BGPパス属性値コードタイプ 続き

9	ORIGINATOR	オプション非通知	クラスタ内での経路生成ルータ
10	CLUSTER_LIST	オプション非通知	経路を反射したクラスタIDのリスト
14	MP_REACH_NLRI	オプション非通知	マルチプロトコルの到達可能経路
15	MP_UNREACH_NLRI	オプション非通知	マルチプロトコルの到達不可能経路