D1

荒ぶるインターネットを乗りこなす!
ルーティング&ルーティングセキュリティ

BGPルーティング再入門

小島 慎太郎 / @codeout

小島 慎太郎

- **NTT Communications**
- @codeout
- **http://about.me/codeout**

本日のスライドは
https://speakerdeck.com/codeout/practical-bgp-routing
にあります

ルーティング & セキュリティ

http://www.flickr.com/photos/nesster/3168425434/

ルーティング & セキュリティ

http://www.flickr.com/photos/nesster/3168425434/

ルーティング & セキュリティ

BGP

http://www.flickr.com/photos/nesster/3168425434/

Agenda

- BGP とは?
- BGP の設計を考えよう
- BGP の運用を考えよう
- 道具を箱に詰めよう
- Communityの一員になろう

BGPとは？

BGP とは?

EGP の一種．**異なるAS間**でrouting情報を交換する

- AS接続グラフ(RIB)を構築し，packet forwardingに使う
- 1つのrouteには複数のpathが含まれている
  - route: あるprefixに到達するためのpath群
  - path: 様々な属性(Path Attribute)の組
- routing loopを解消する仕組みがある
- AS内での**routing policyを実装**できる

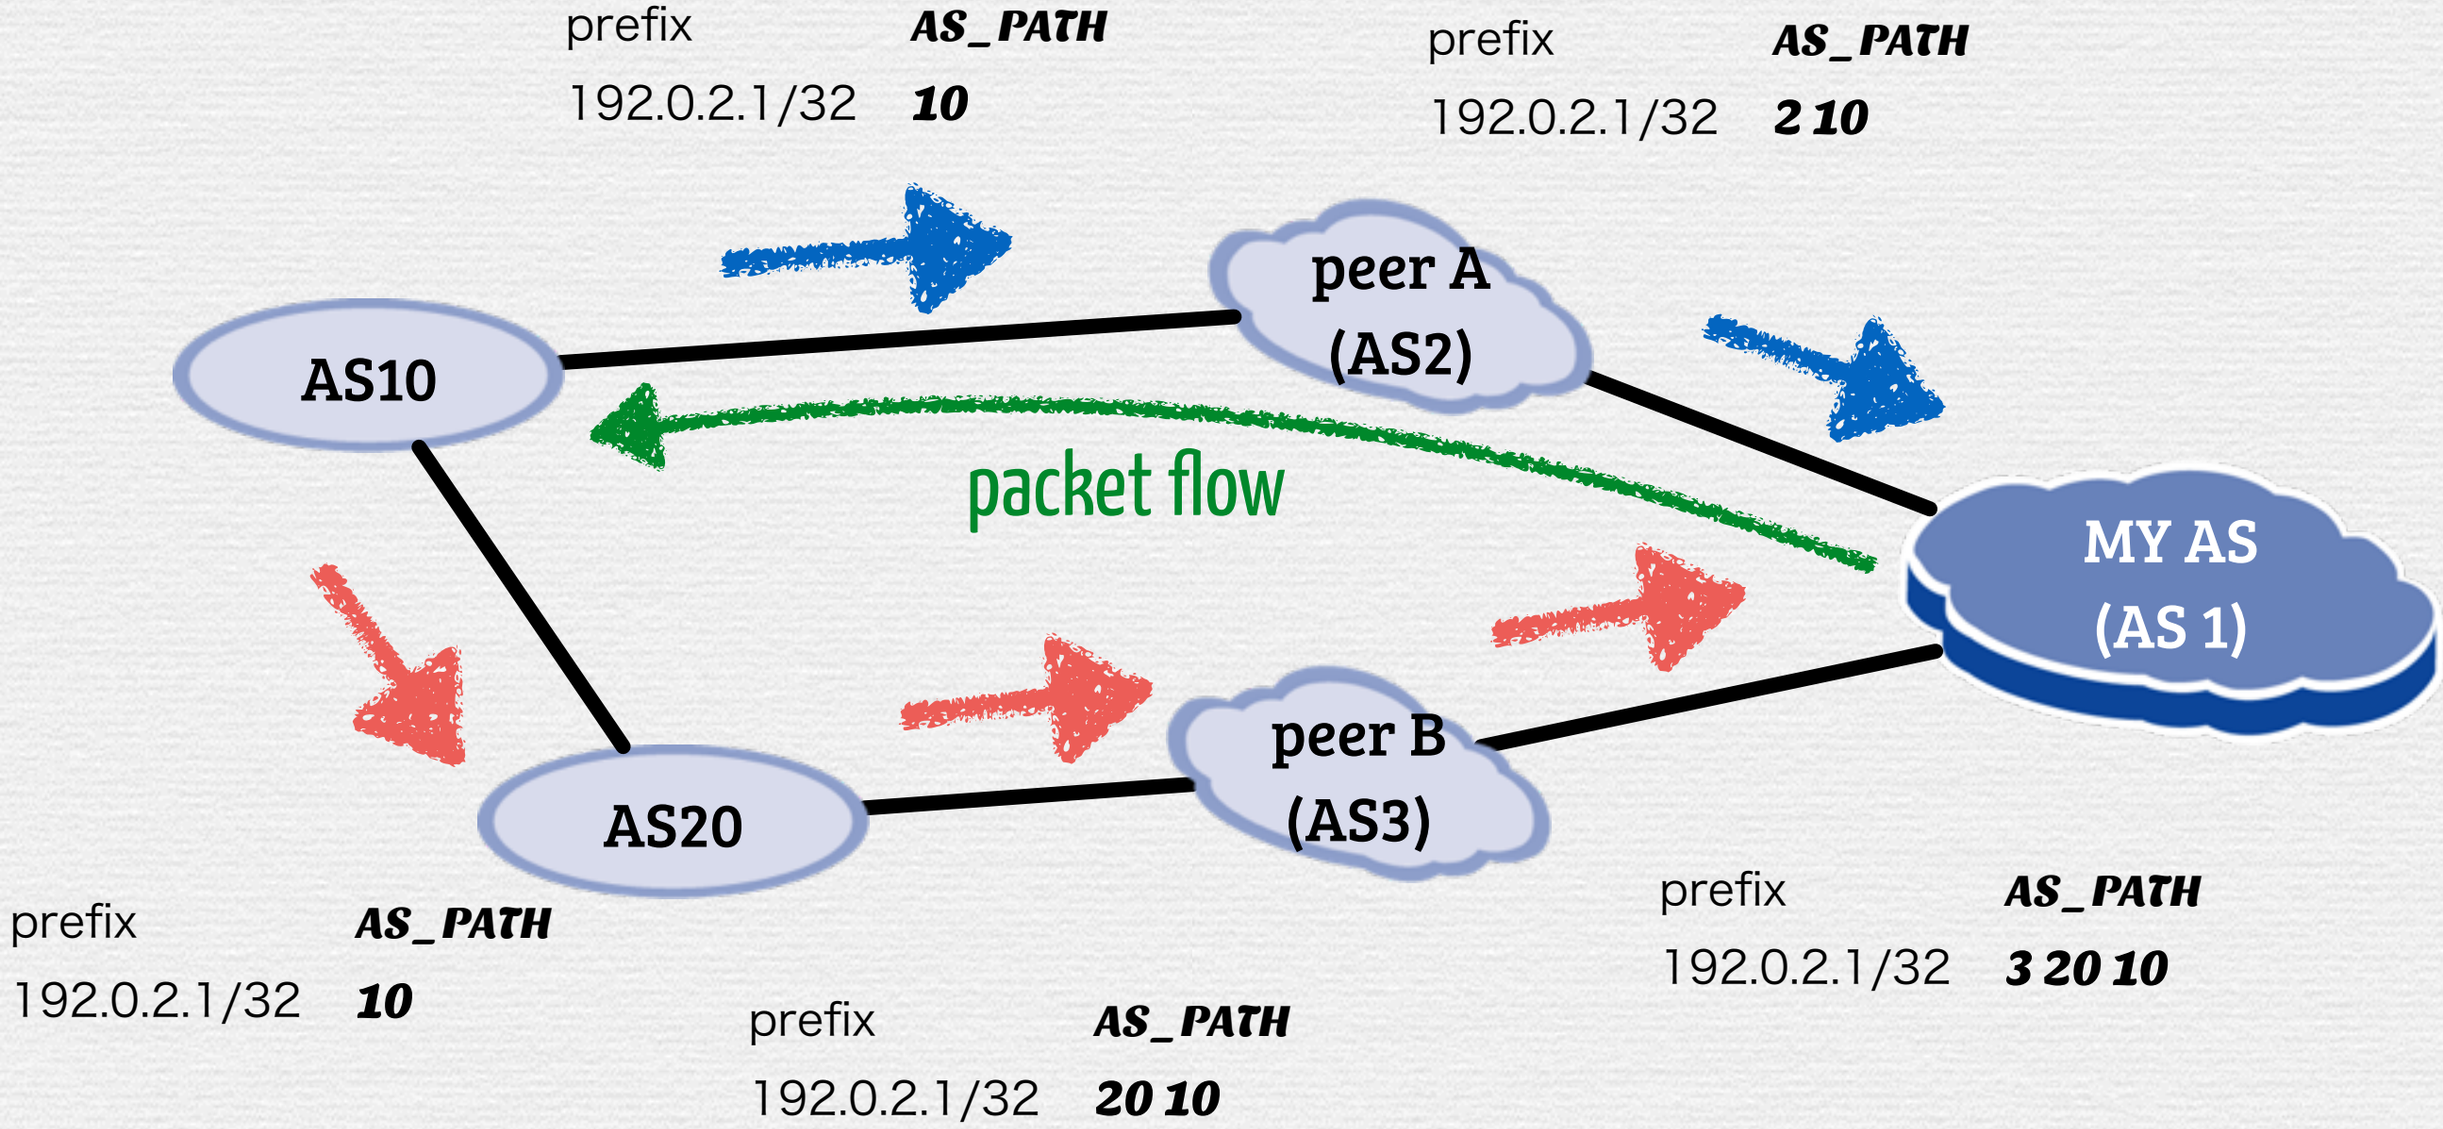

MY AS routerの動作:

packetを転送しようとするたびに，RIB内からdst ip addressを検索し，宛先(nexthop)を特定する

- 正確にはRIBを展開したFIB内を検索する

異なるASには
異なるrouting
policyがあり，それ
が反映されたrouting
情報を交換する点で
BGPは難しいし，おも
しろい

http://mrg.bz/WooRIg

もう少し
おさらいします

IGPとの関係

- BGPで解決できるのは，**Internet上のある目的地に達するために，自AS内のどの出口から出ればいいか?**のみ

- **その出口にはどうやったら到達できるか?**はIGP頼み

- IGPの主な用途は，BGPのprotocol nexthopを解決すること
  - むやみにBGP経路をIGPに注入しないほうがいい

A Border Gateway Protocol 4 (BGP-4)

- ***RFC1654*** (July 1994)
- ***RFC1771*** (March 1995)
- ***RFC4271*** (January 2006) 👍
- もちろん たくさん拡張されている
  - ***RFC1997*** BGP Communities Attribute
  - ***RFC2385*** Protection of BGP Sessions via the TCP MD5 Signature
  - ***RFC3065*** AS Confederations for BGP
  - ***RFC4451*** BGP MED Considerations
  - ***RFC4456*** BGP Route Reflection
  - ***RFC4360*** BGP Extended Communities Attribute
  - ***RFC5004*** Avoid BGP Best Path Transitions from One External to Another
  - ***RFC5668*** 4-Octet AS Specific BGP Extended Community
  - ...

BGP の経路選択

1. (最も高い **WEIGHT** を持つパスが優先されます．一部メーカーのみ)
2. **最も高い LOCAL_PREF を持つパスが優先されます**
3. network または aggregate BGP サブコマンドによって，あるいは IGP からの再配布を通じて，ローカルで発信されたパスが優先されます
4. **最短の AS_PATH を持つパスが優先されます**
5. 最小のオリジン タイプを持つパスが優先されます
6. **最小の Multi-Exit Discriminator (MED) を持つパスが優先されます**
   - ✎ **MED** は remote AS が同じ場合のみ評価される
7. iBGP パスよりも eBGP パスの方が優先されます
8. **BGP ネクストホップへの最小の IGP メトリックを持つパスが優先されます**
9. 両方のパスが外部のときは，先に受信したパス（最も古いパス）が優先されます
10. 最小のルータ ID を持つ BGP ルータから送られたルートが優先されます
11. 発信元 ID またはルータ ID が複数のパスで同じ場合は，最小のクラスタリスト長を持つパスが優先されます
12. 最小の隣接ルータ アドレスから送られたパスが優先されます

http://www.cisco.com/cisco/web/support/JP/100/1008/1008556_25-j.html

“本講演では、 教科書や一般的な演習では得ることが難しい、 講演者が経験した生の体験を共有します”

BGPルーティング

- **BGPの設計を決める際に考えないといけないこと** について話します

- “BGP sessionの先にいるAS (顧客 / peering partner / transit 提供者) にも個別のrouting policyがある” という環境で, **どうやって自分の思うようにtraffic controlするか?** を理解してもらうことを目的として

・ 私が使っている手法の紹介
・ その解説

もします


http://www.flickr.com/photos/21986855@N07/7607705630/
YouTube
Broadcast Yourself™

Internet

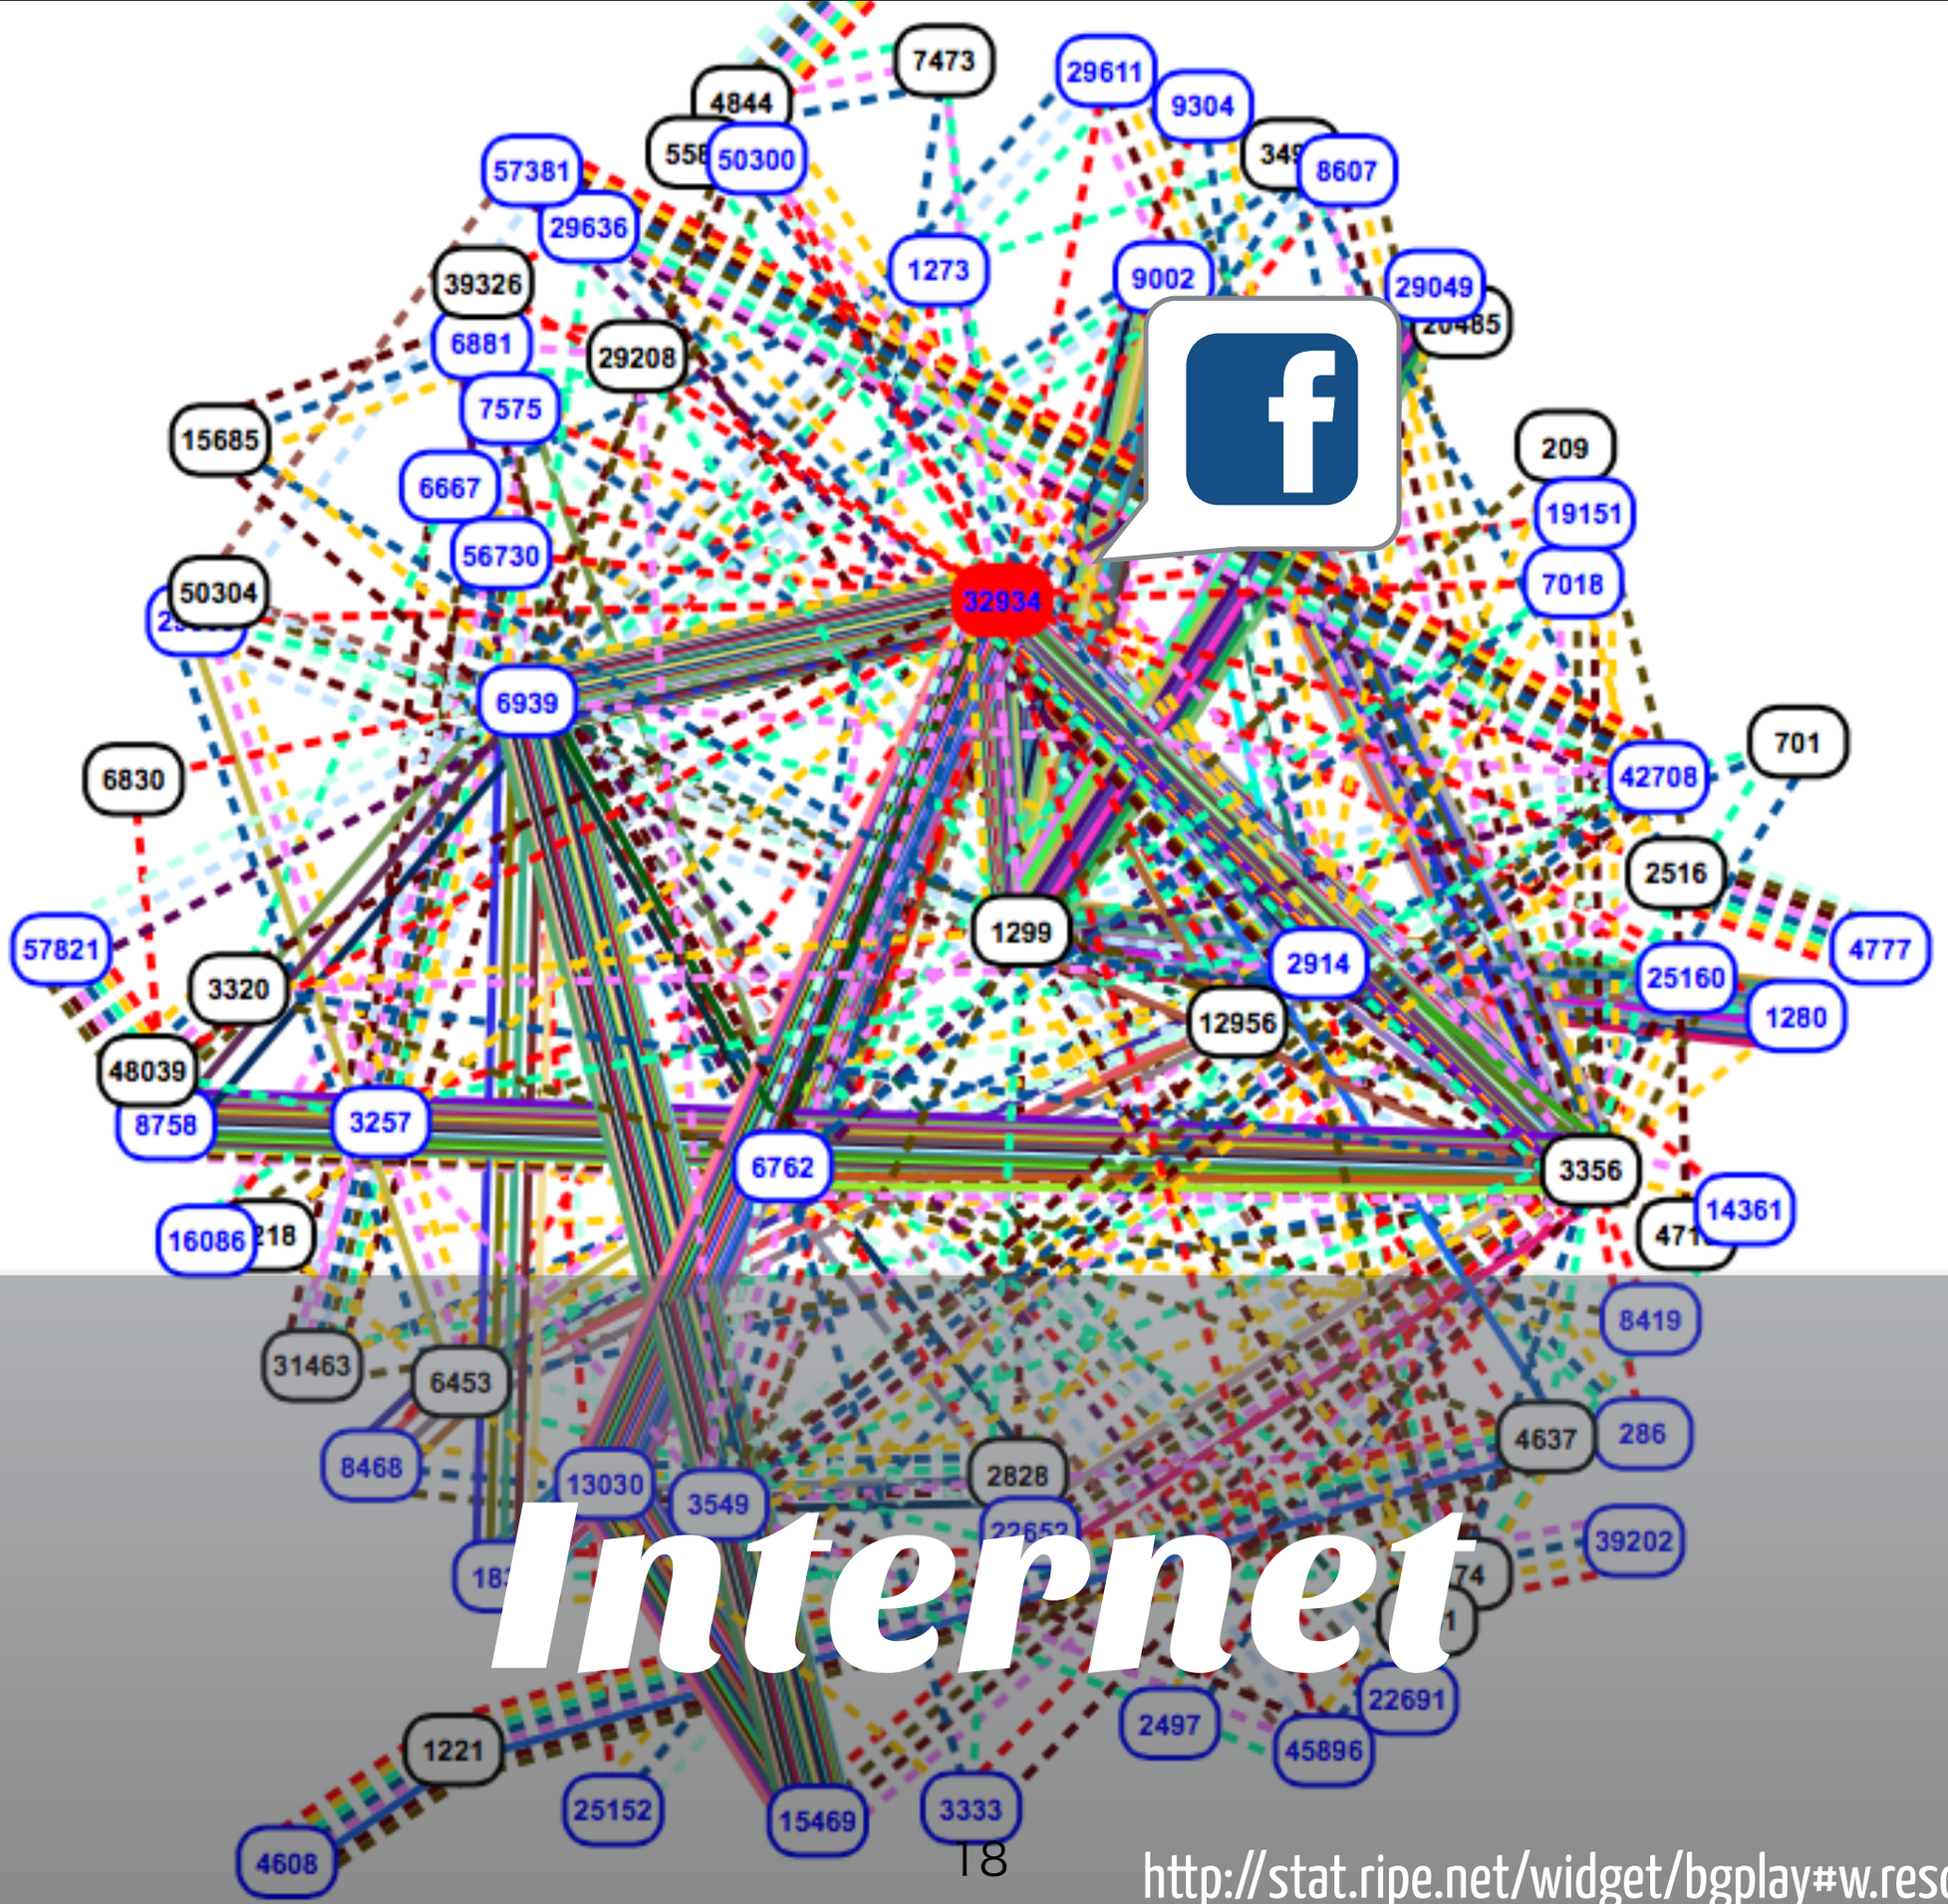

Internet

http://stat.ripe.net/widget/bgplay#w.resource=as32934

BGP の設計を考えよう

- addressing
- eBGP policy / 設計
  - 経路広告
  - 経路受信
- iBGP policy / 設計

BGP 設計

1. **network policyを決める**
    1. **可用性** (どのレベルの障害に耐えうるか? POP / router 筐体 / module / 回線 / 電源設備)
    2. **品質** (packet loss率 < 0.? % / jitter < 0.x? ms / latency @日本国内 < ??ms)
    3. **運用性**
    4. **拡張性**
    5. **security**
    6. cost (10G portあたり < ?百万円)

2. network policyを満たす実装のひとつとして，networkを設計する
    1. POP 配置 / DC 選定
    2. cable path
    3. 収容設計
    4. 機器選定

BGP 設計

3. 設計したnetworkにどうpacketを流すか?
   routing policyを決める（通常serviceごとにpolicyが変わる）
   1. どのような情報を流すか?
   2. 顧客にどのようなnetwork serviceを提供するか?

❗ 好ましいpolicyが作れない場合，networkを見直す必要があるかも

4. routing policyを満たすよう，routing(IGP/EGP) を設計する
   1. protocolは?
   2. route reflector(RR) or confederation?
   3. どの情報をどこに流す?

   うまく設計できない場合，routing policyを見直す必要があるかも

物理と論理は切り離せるかもしれない

教科書的な中規模Network

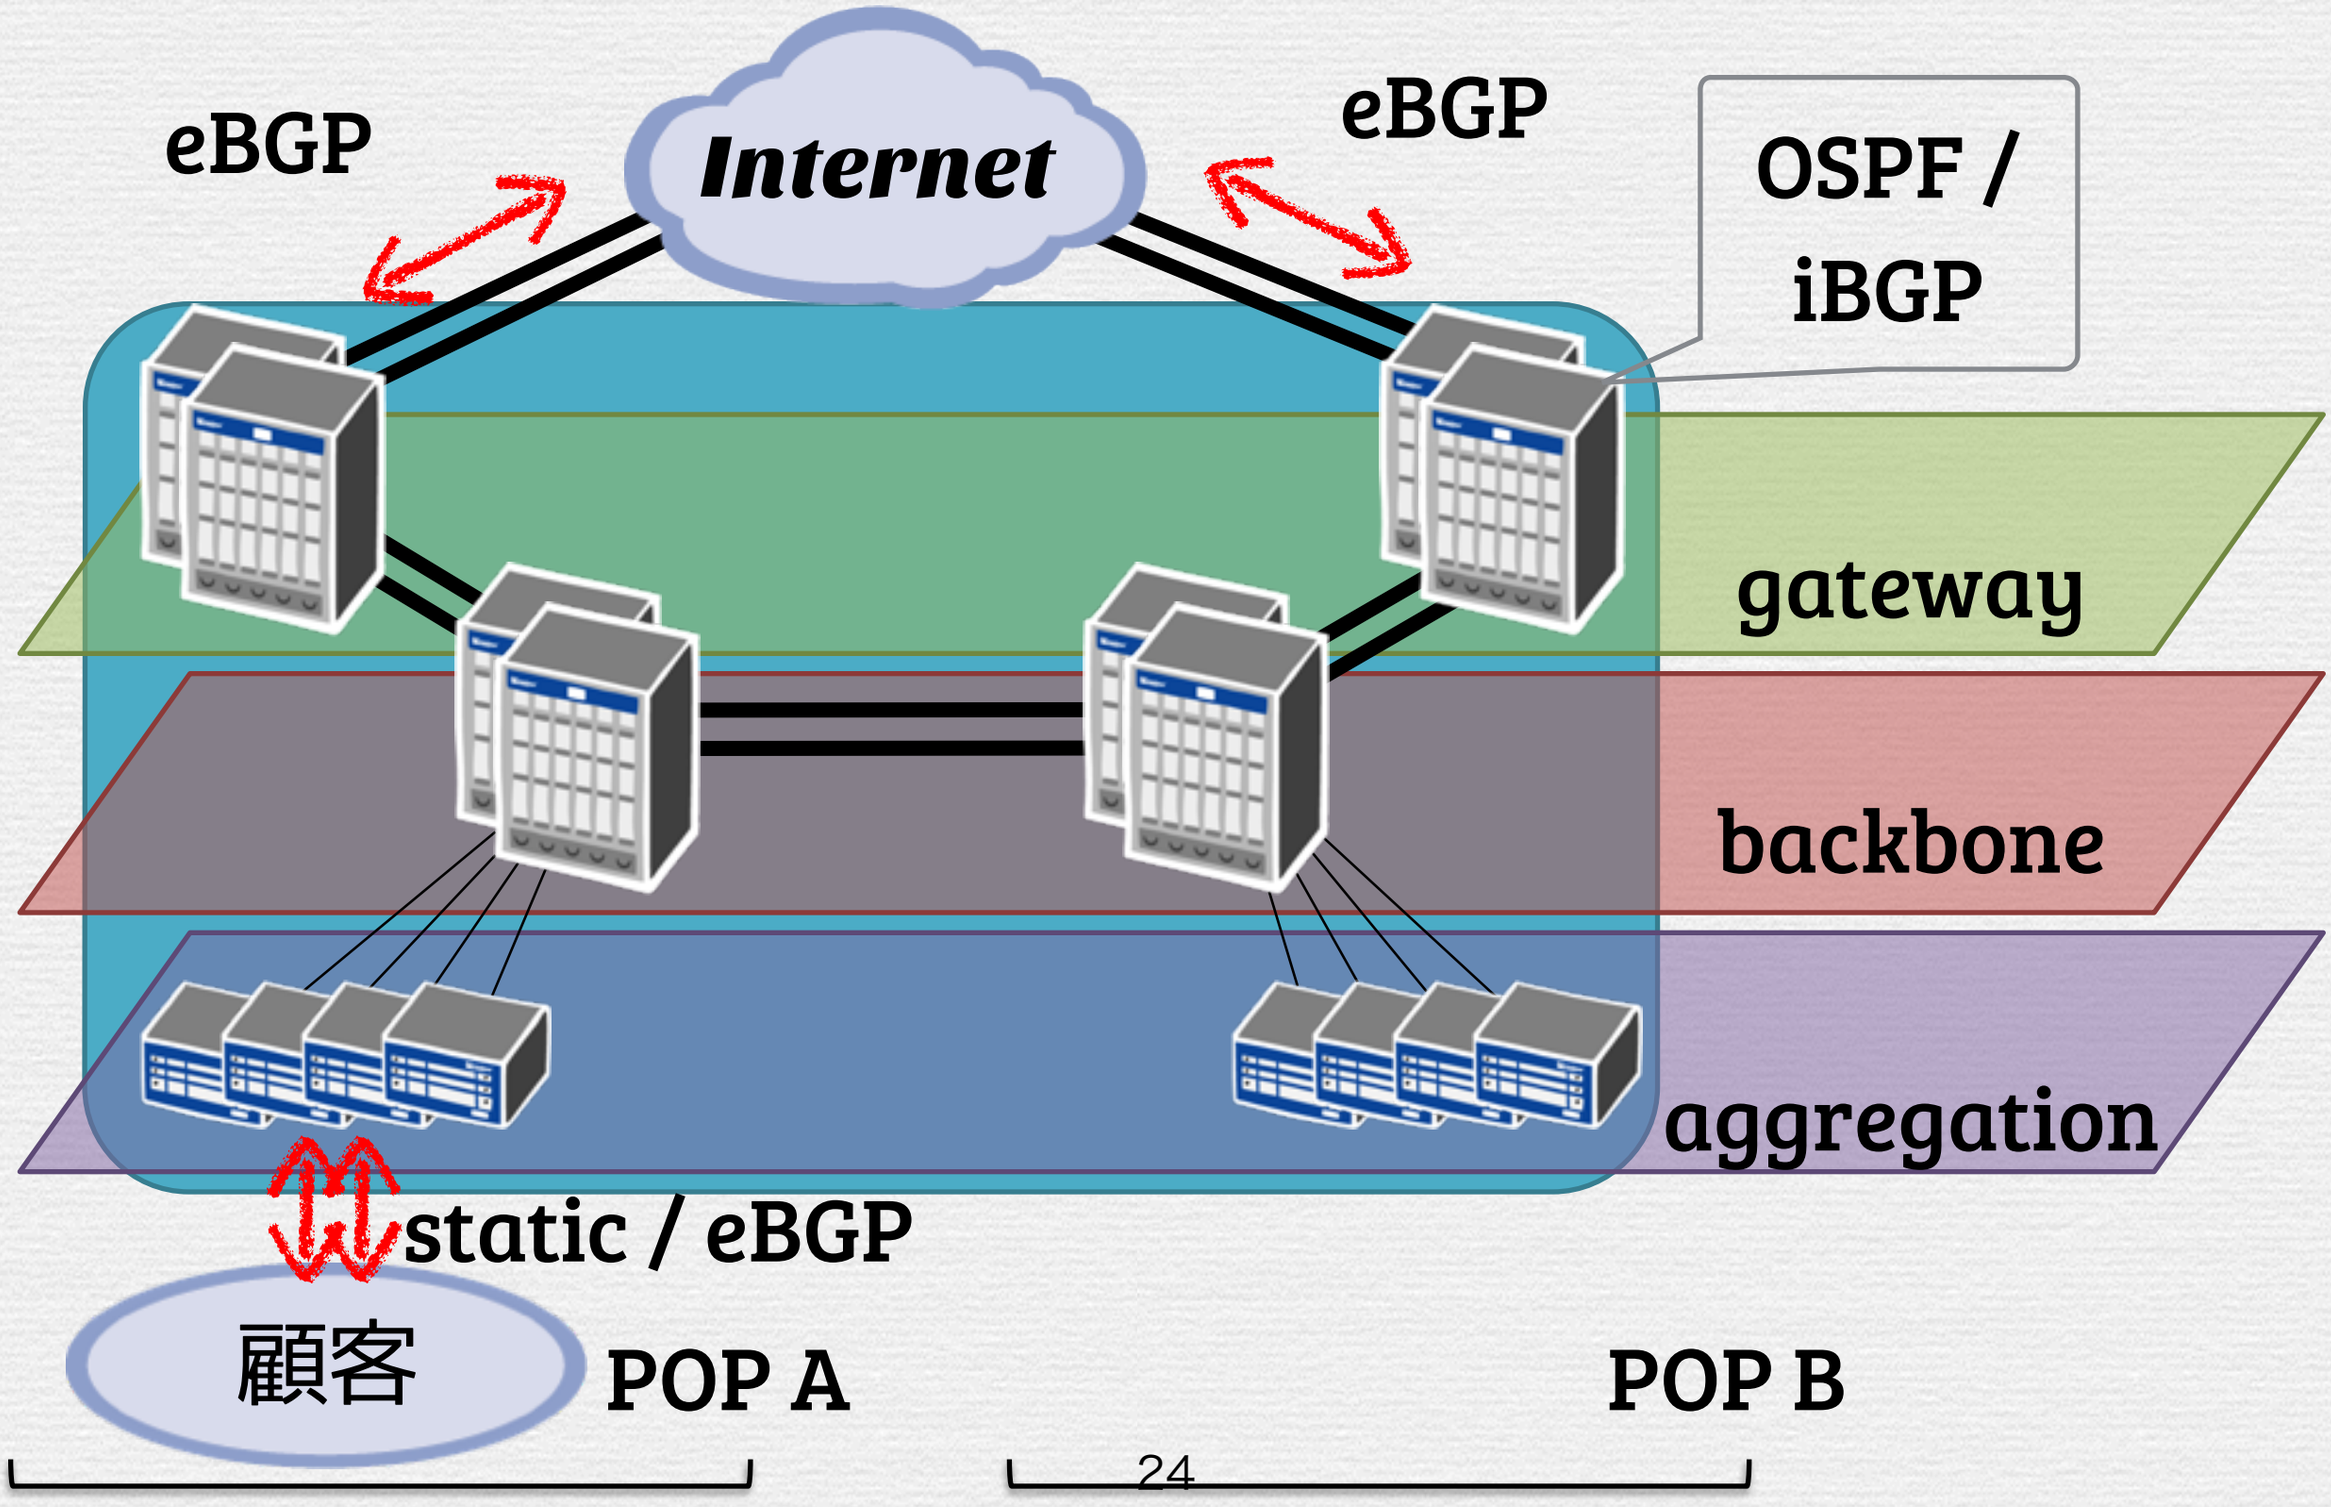

たぶん理想的にはこう

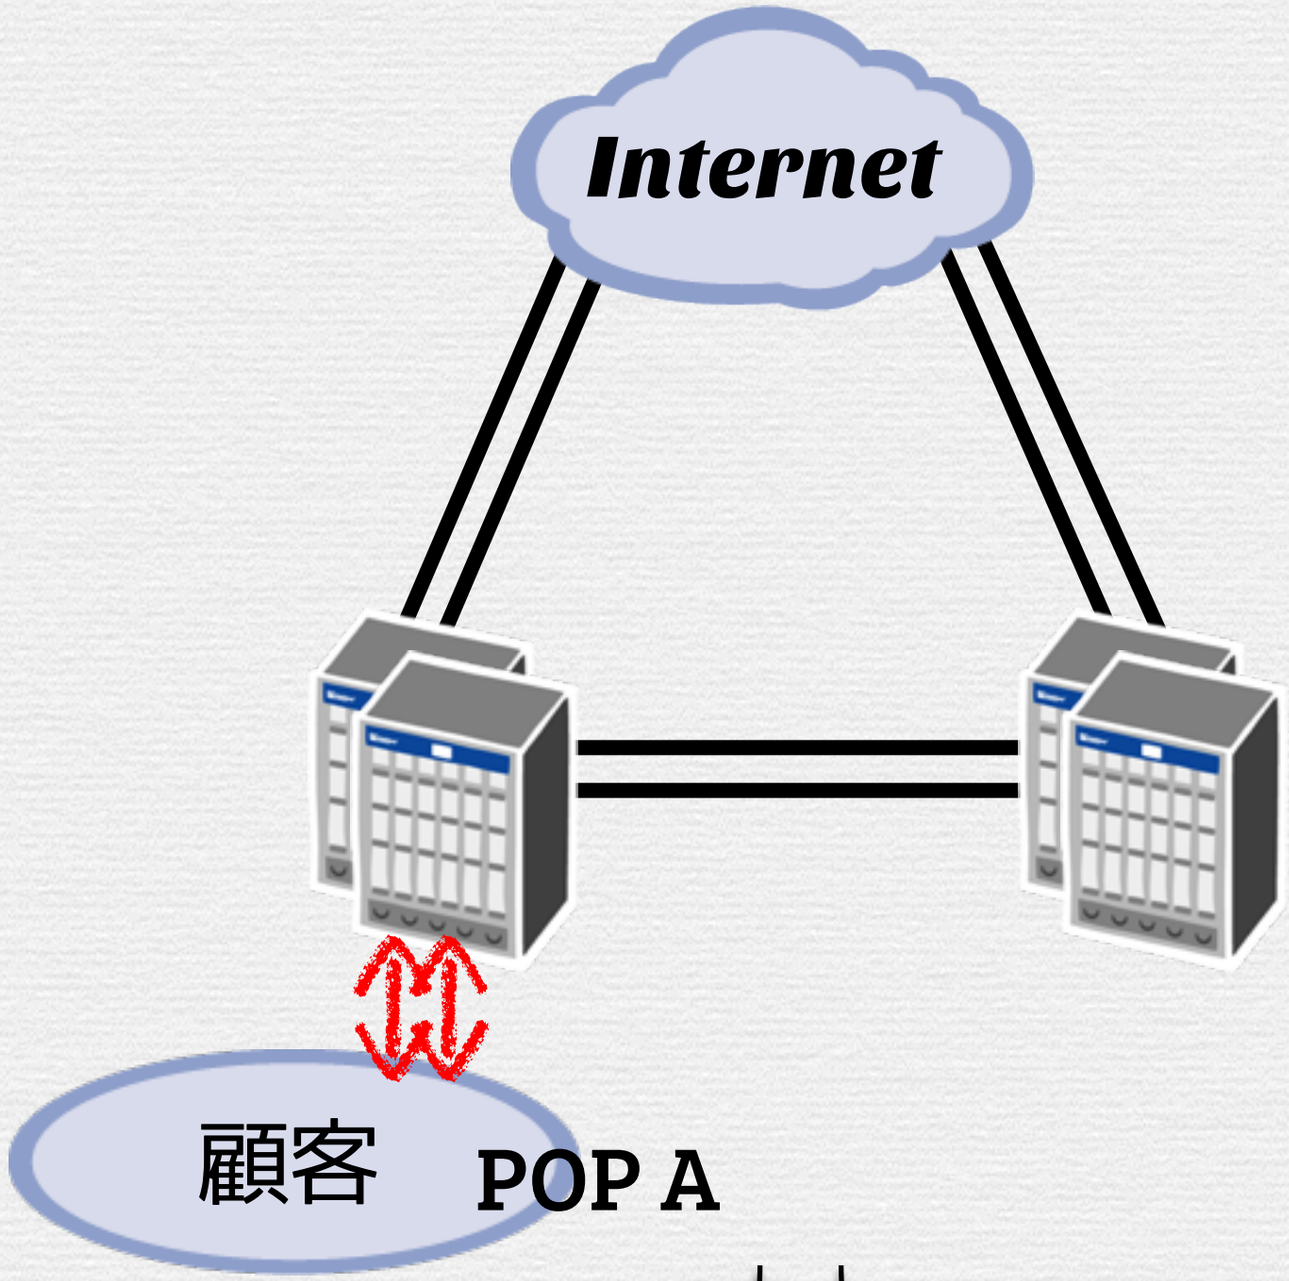

- routerの**集約**による統計多重効果
- virtual chassisなどによる**論理台数の削減**
- policyを分ける必要があれば，virtual routerなどによる**分離**
- シンプルな運用

Addressing

BGP 設計 / Addressing

- 目的に応じてblockを決める
  - loopback, p2p
  - 顧客割り当て
- できる限り集約可能に
  - security
  - シンプルに
- 大規模networkの場合
  - 拠点 / 地域ごとに address blockを分ける

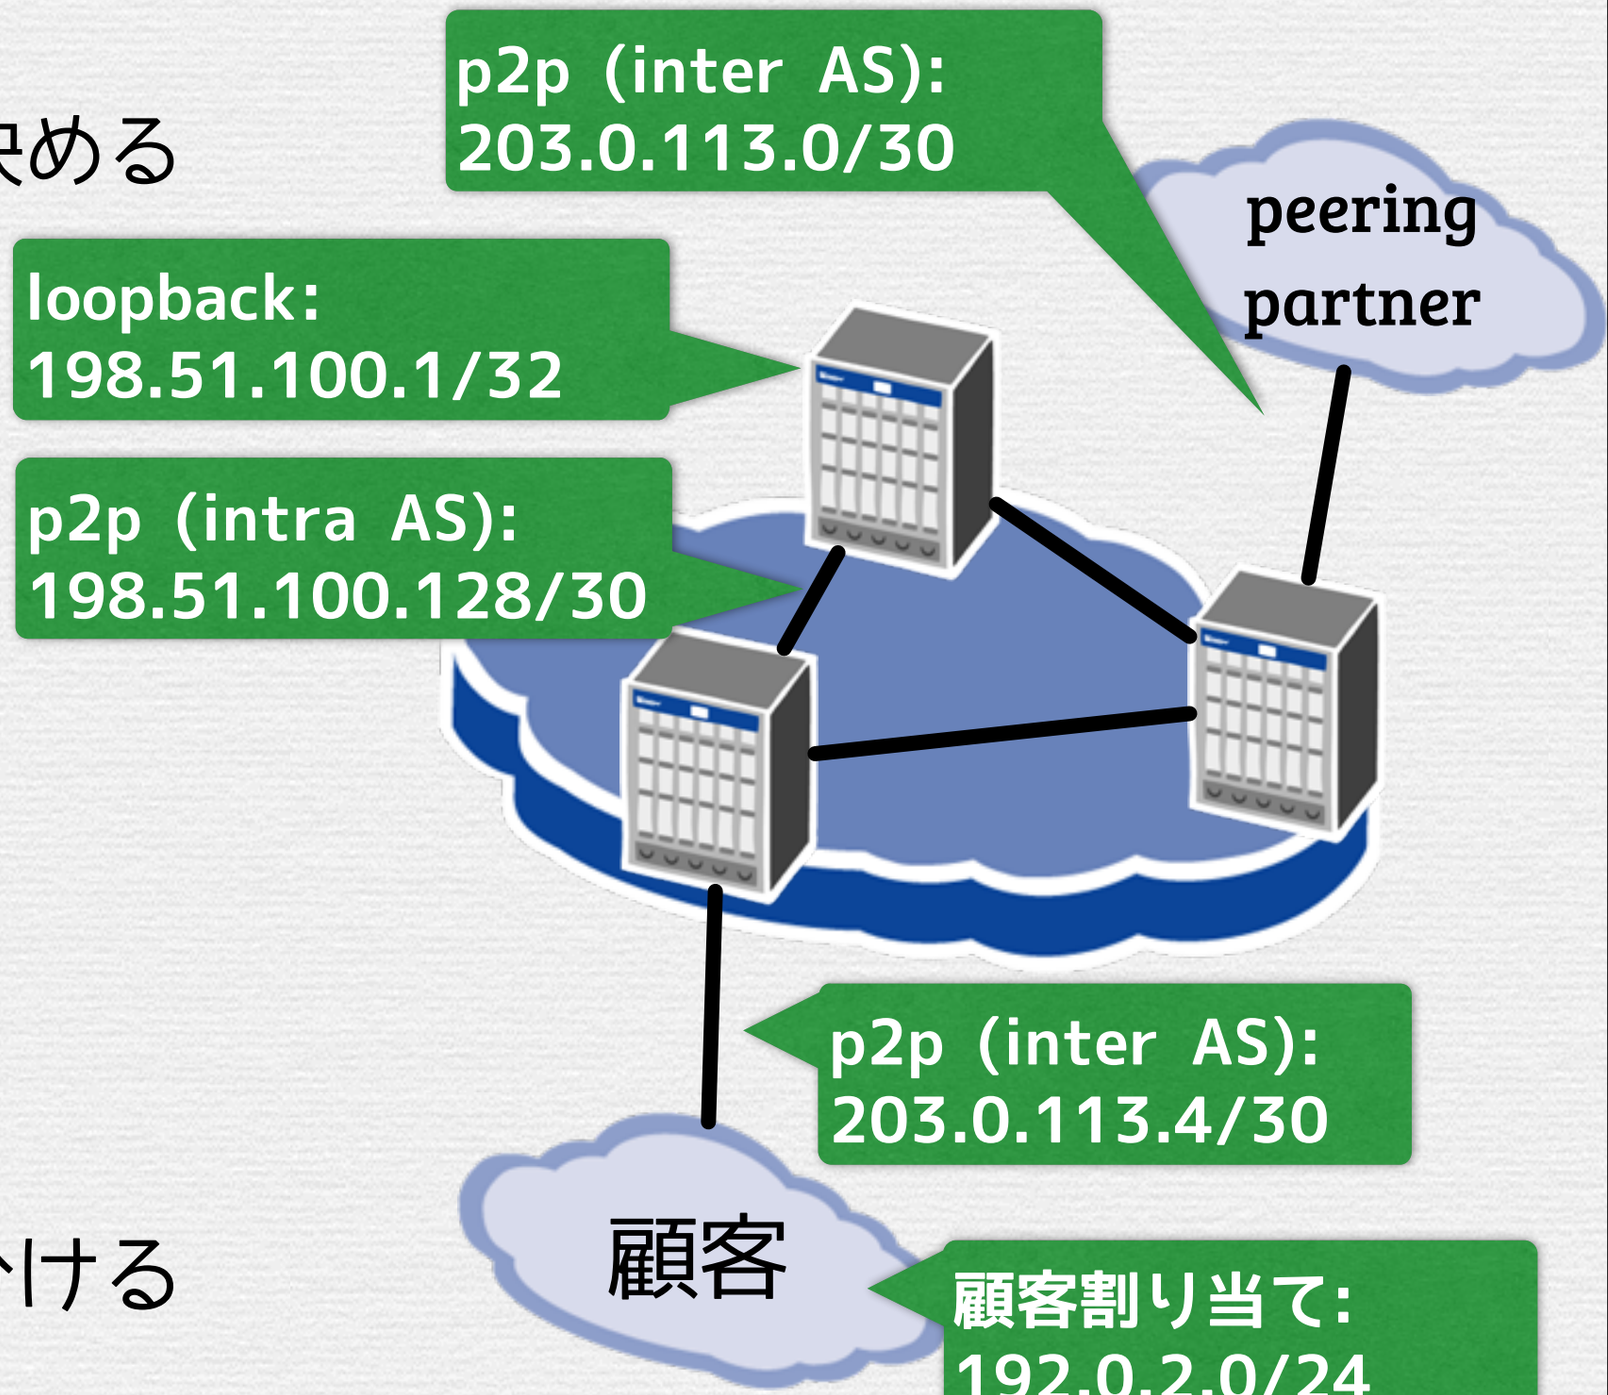

シンプルに
わかりやすく

http://www.flickr.com/photos/techsavvyed/5926978939/

例（最低限これだけ分けていれば十分）

type	用途	prefix 長	routing (外部へ...)
infra用	loopback	ipv4 /32, ipv6 /128	広告しない (*2)
infra / AS境界用	p2p	ipv4 /30, ipv6 /126 (*1)	広告しない (*2)
顧客用	割り当て Server SW	ipv4 /28~20, ipv6 /48 ipv4 /24, ipv6 /64	BGP 顧客のみ広告する (*3)

(*1) /31, /127 も使えるかも（実装依存）

[RFC3021] Using 31-Bit Prefixes on IPv4 Point-to-Point Links

[RFC6164] Using 127-Bit IPv6 Prefixes on Inter-Router Links

(*2) supernetとして広告する

security のため広告しないというアイデアもあるが,
外部からの到達性確認のため広告することを推奨

(*3) **static顧客，infra networkの経路はsupernetのみ広告**

```
interfaces {
    lo0 {
        unit 0 {
            family inet {
                filter {
                    input ssh_filter;
                }
            }
        }
    }
}

firewall {
    filter ssh_filter { ... }
}

# Juniper の例
```

- loopback addressへのsshはcpuの手前でpacket filterを通す
- **network edgeは多すぎて設定し忘れる**

```
policy-map ssh_filter
  class ...
  police ...


control-plane
 service-policy input ssh_filter


! Cisco 6500 の例
```

- loopback addressが増えすぎると，ACL のメンテナンスが困難になる

➔ **用途別にできる限り集約**

- p2p blockもなるべく集約可能に
  - 経路が増えるとrouterへの負荷が．．．
  - **シンプルな設計は，理解しやすい**
    - addressを見て，どのへんのloopback，p2p addressか推測できるだけで運用スピードが上がる

```
 1  210.173.162.117  0.466 ms  0.408 ms  0.358 ms
 2  210.173.162.110  0.480 ms  0.438 ms  0.448 ms
 3  202.232.13.73  0.501 ms  0.500 ms  0.498 ms
 4  58.138.98.217  1.265 ms  0.969 ms  1.106 ms
 5  58.138.82.233  1.057 ms 58.138.80.245  1.219 ms 58.138.80.241  25.255 ms
 6  206.132.169.121  102.497 ms 216.98.96.62  99.842 ms 206.132.169.109  101.315 ms
 7  206.132.169.82  114.063 ms 206.132.169.2  110.394 ms  100.695 ms
 8  198.172.90.101  116.817 ms  105.842 ms 128.241.219.17  106.500 ms
 9  129.250.4.9  115.313 ms 129.250.5.54  96.205 ms  107.022 ms
10  129.250.4.24  152.412 ms 129.250.2.169  148.279 ms  142.641 ms
11  129.250.2.154  142.619 ms 129.250.2.174  139.038 ms 129.250.3.67  145.834 ms
12  129.250.17.38  148.640 ms  147.068 ms 129.250.17.42  154.900 ms
```

・顧客割り当てblock もなるべく集約可能に
  ・traffic engineering（TE）しやすい

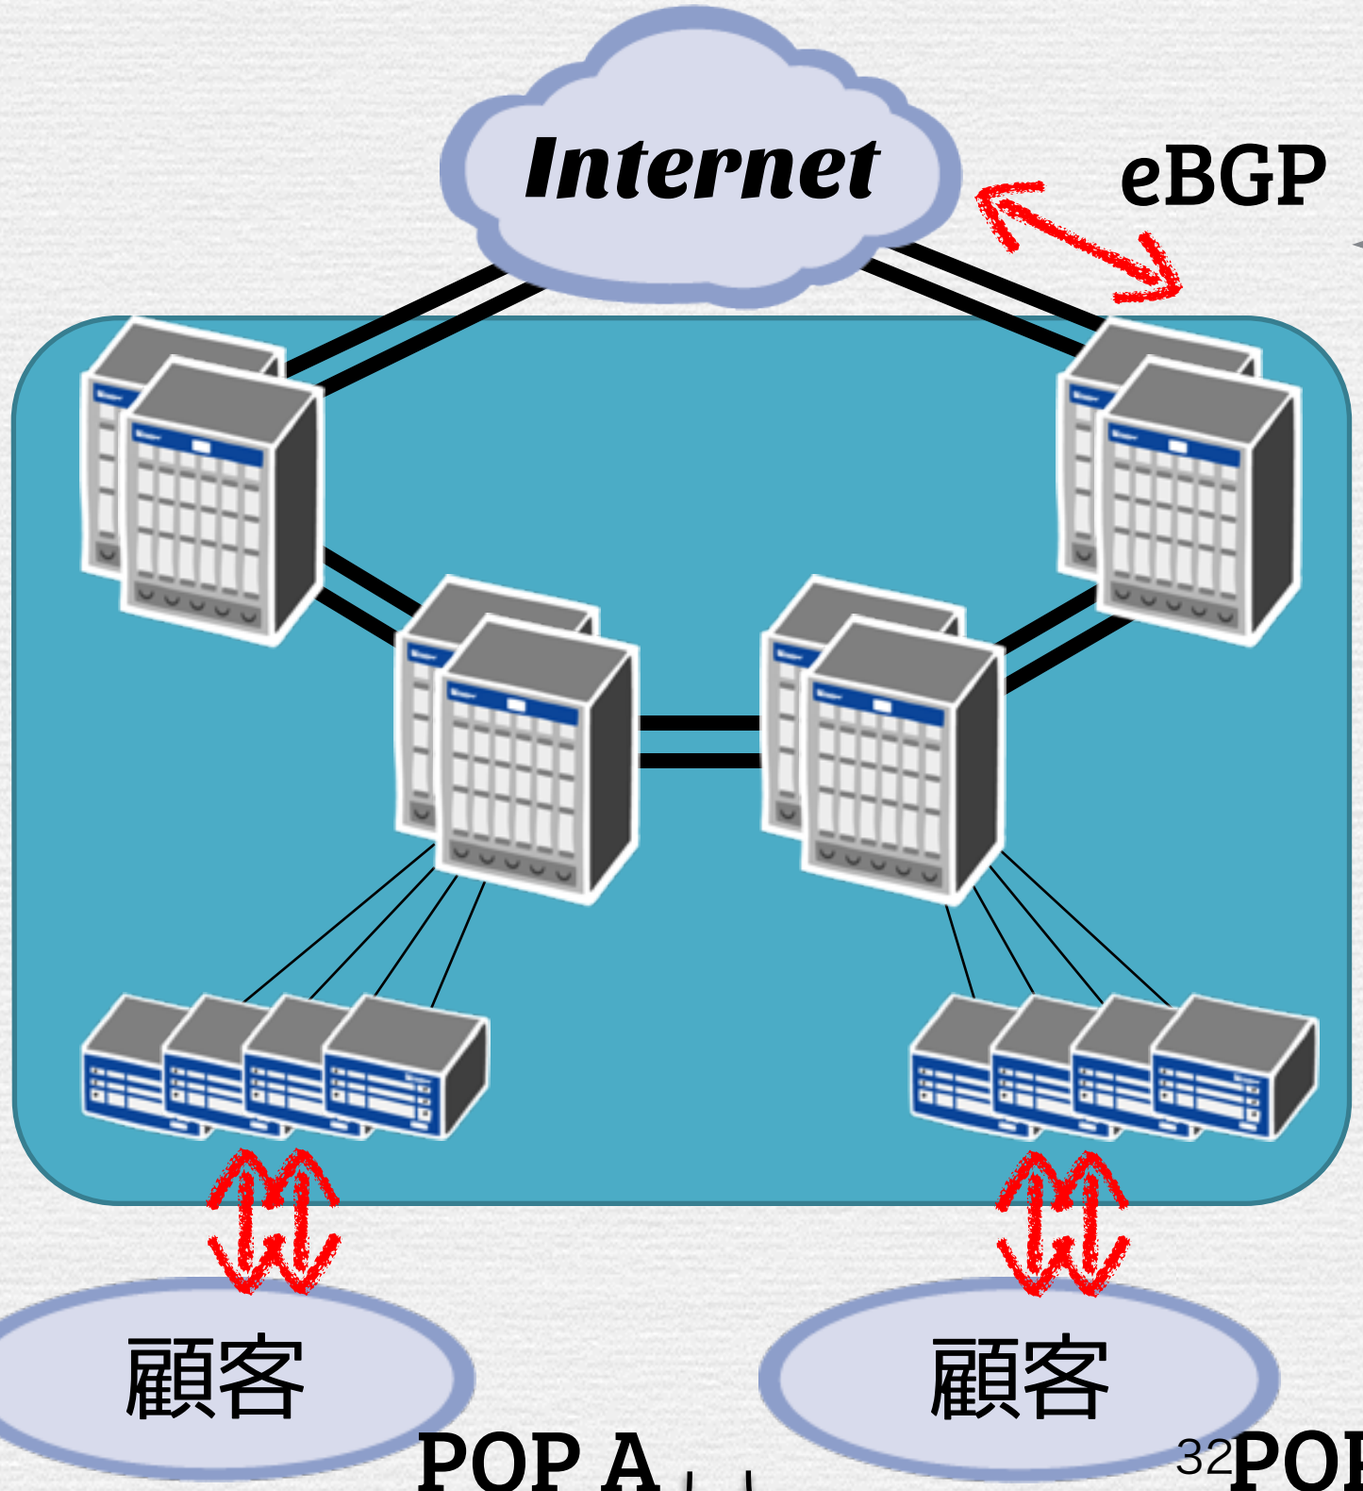

拠点Aの顧客prefixは
Internetに広告したくない !!

・POPごとにprefix を分けていないとコントロールできない

・実際はなかなか難しい．．．

eBGP policy / 設計

eBGP Policy を考えるポイント

- **どんな経路**を
  - **どんなeBGP session**からもらうか? (もらわないか?)
    - その際の優先度は?
  - **どんなeBGP session**へ広告するか? (広告しないか?)
    - その際の優先度は?
- 経路の各path attributeは誰のものか?

  - full routeを持てないrouterはある?
    - default routeを利用: よく考えないと危険
      簡単にrouting loopが起きる
  - BGPではなく，別のprotocol(OSPF など) にredistributeしないといけない，とかある?

経路の種別

- 顧客の経路
  - BGP 顧客
  - static 顧客 (実際はPAに集約)
- 自ASの経路
  - PA/PI経路
- peering partnerの経路
- transit providerの経路
- 不要な経路

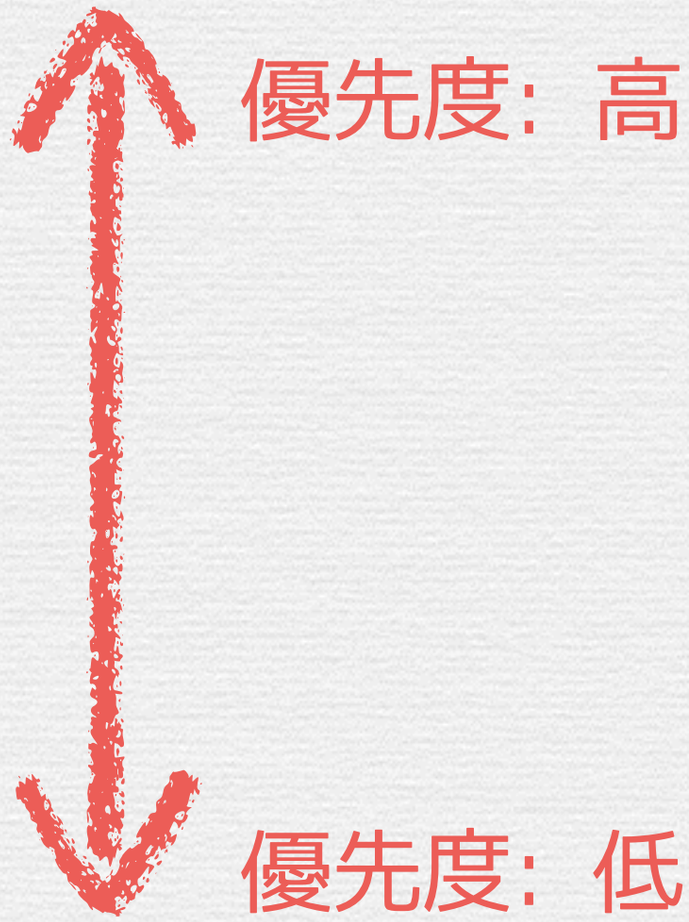

ビジネス上の観点から，基本的には上記の順に優先する
(優先 = なるべくその経路に従ってpacketを流したい / 流してほしい)

eBGPセッションの種別

- 顧客
- peer
  - paid peer（収益を得ている）
  - private peer
  - public peer (IX)
  - paid peer（費用を払っている）
- transit

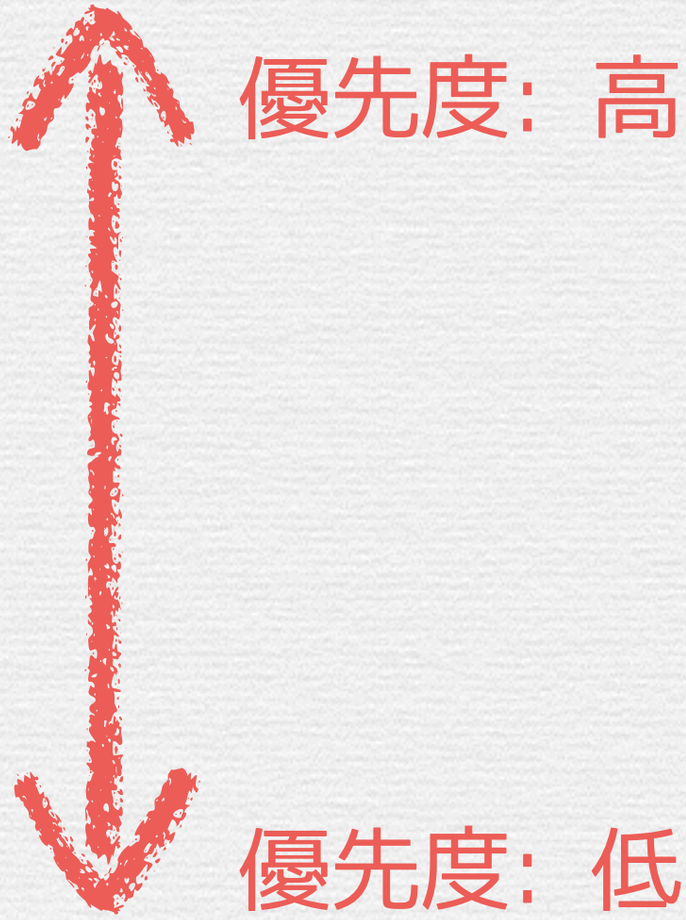

同様に，基本的には上記の順に優先する
(優先 = なるべくその接続/回線にpacketを流したい)

eBGP Policy の基本

受信 / 広告Policyは何に影響する？

受信Policy

自AS**網内**でどのように routing させる?

広告Policy

自AS**網外**でどのように routing させる?

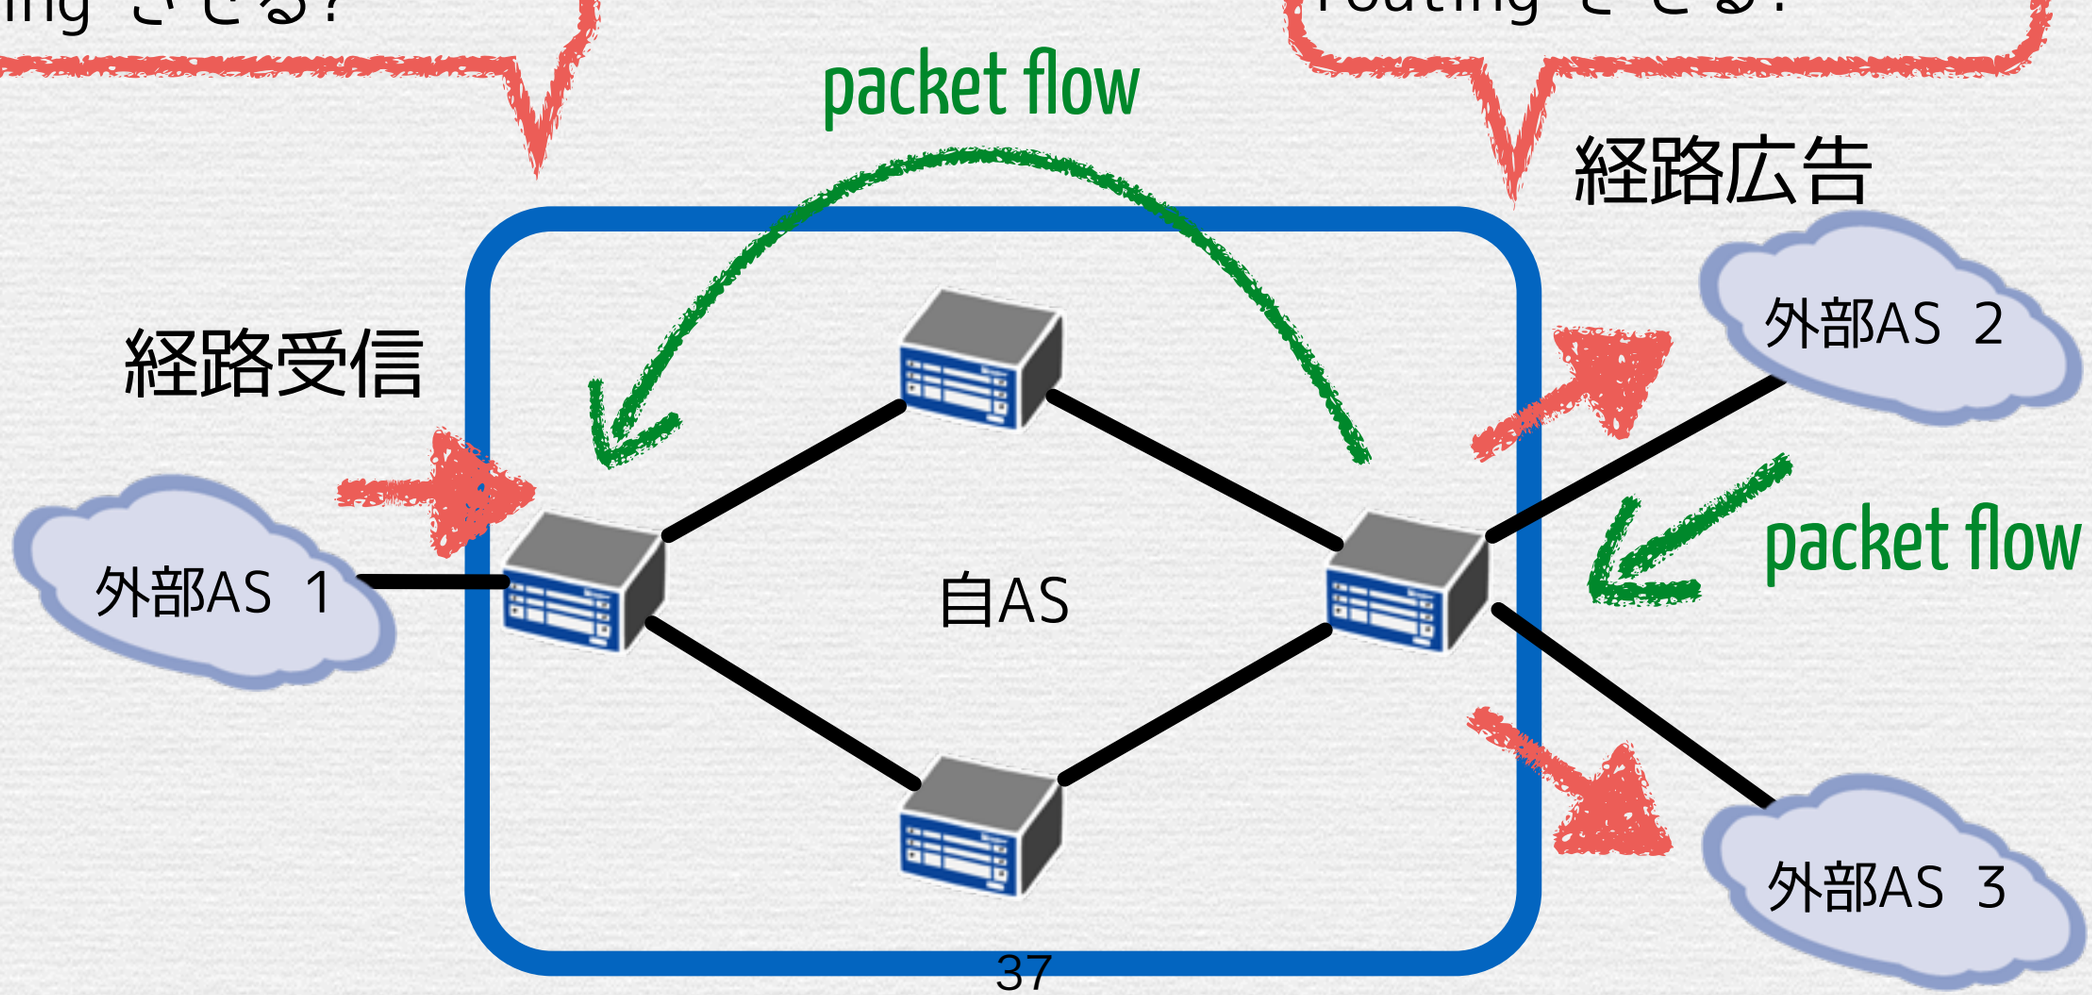

eBGP policy / 経路受信

eBGP Policy の基本（受信）

bogon filter はすべてに必要

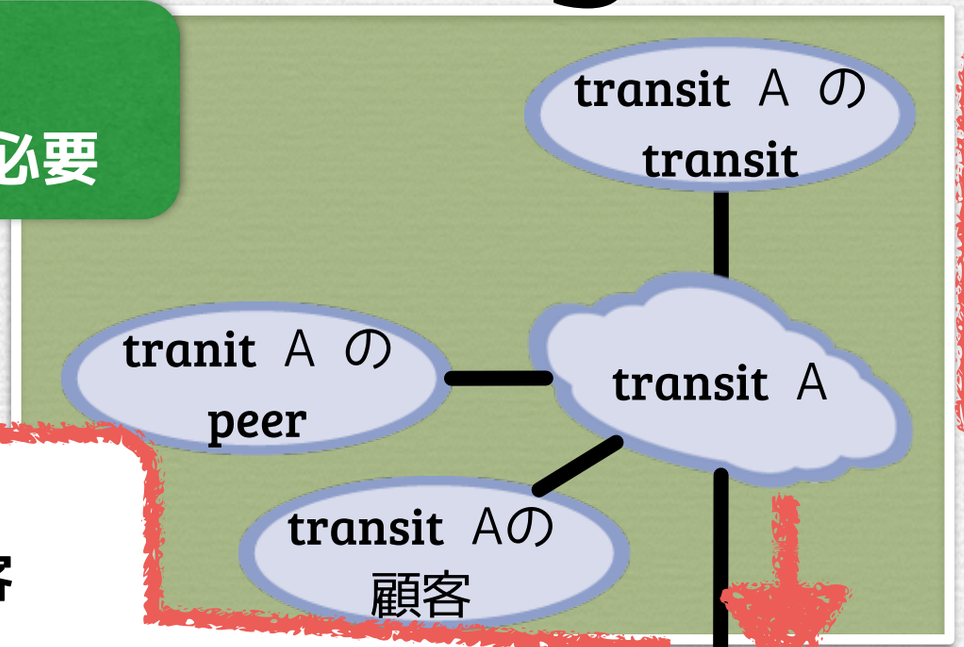

すべて受信
- transit A の顧客
- transit A 自身
- transit A のpeer
- transit A のtransit

すべて受信（経路filterあり）
- peer A の顧客
- peer A 自身
- peer A のpeer （通常流れてこない）
- peer A のtransit （通常流れてこない）

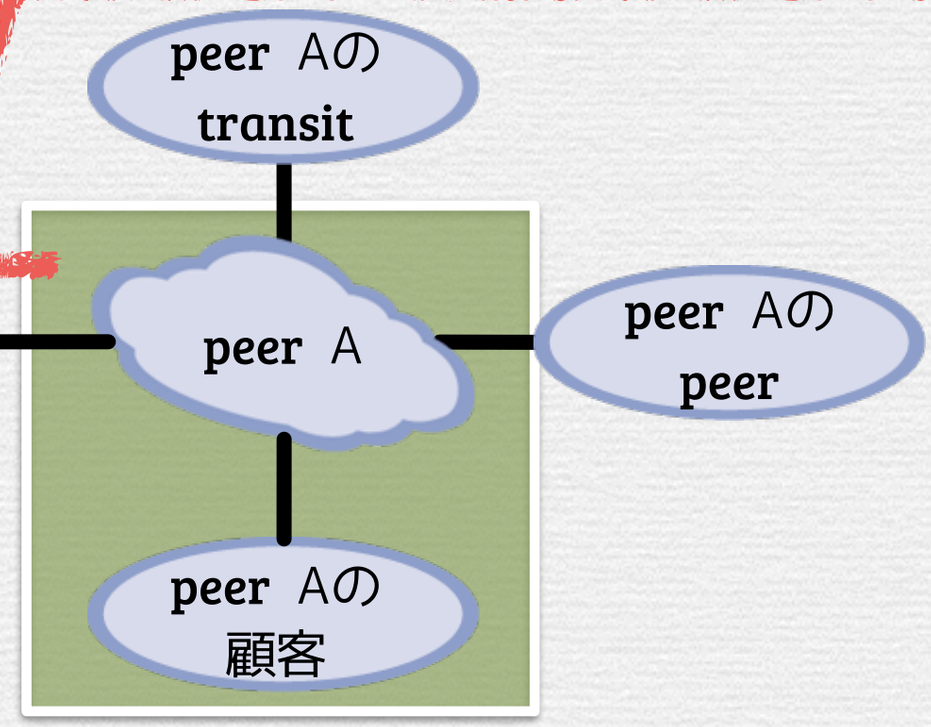

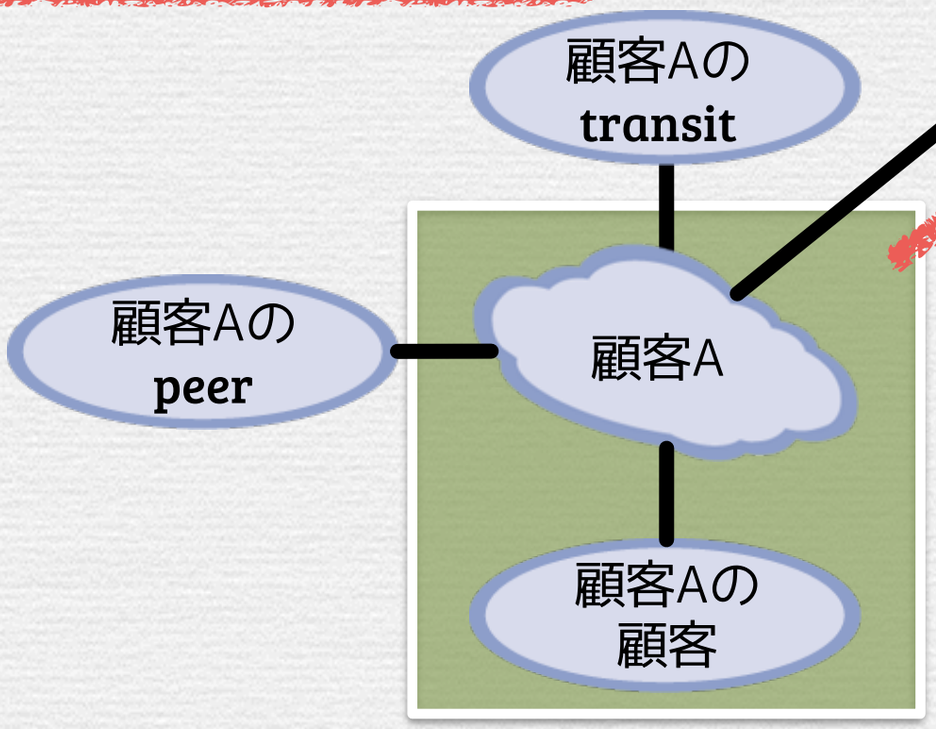

自身の経路を除き，すべて受信（経路filterあり）
- 顧客A の顧客
- 顧客A 自身
- 顧客A のpeer （通常流れてこない）
- 顧客A のtransit （通常流れてこない

eBGP Policy の基本（広告）

bogon filter はすべてに必要

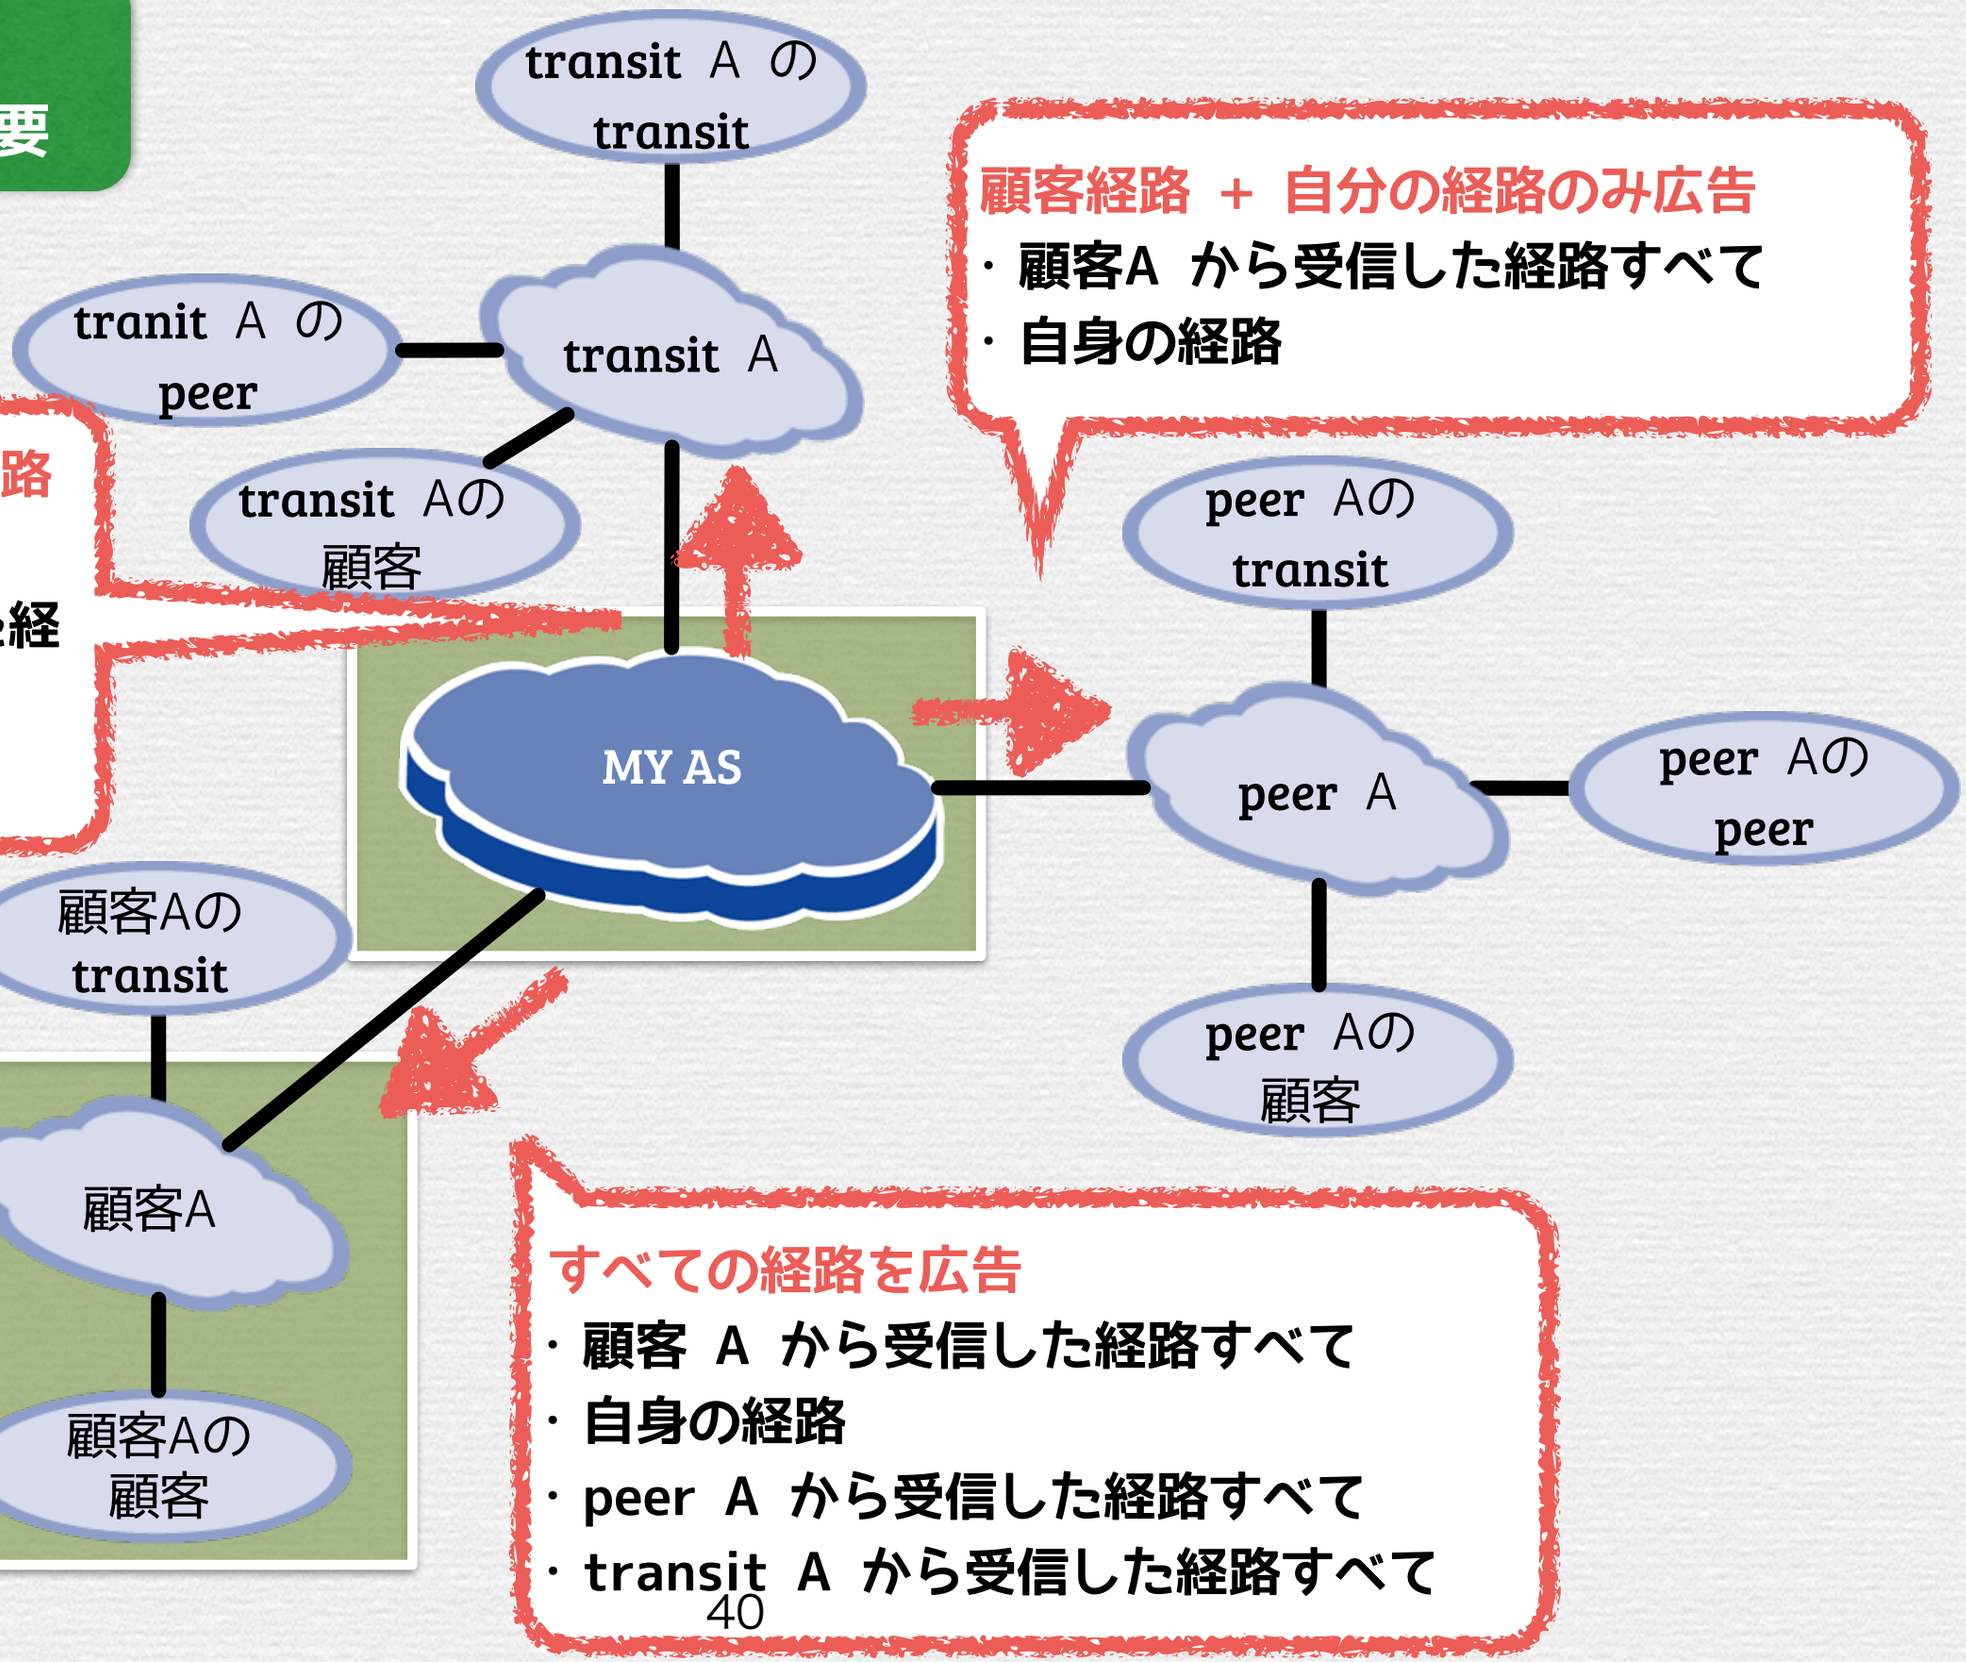

顧客経路 + 自分の経路のみ広告

- 顧客A から受信した経路すべて
- 自身の経路

顧客経路 + 自分の経路のみ広告

- 顧客A から受信した経路すべて
- 自身の経路

すべての経路を広告

- 顧客 A から受信した経路すべて
- 自身の経路
- peer A から受信した経路すべて
- transit A から受信した経路すべて

経路の各path attributeは誰のもの?

- 以下のような機能を提供しているISPも
  http://onesc.net/communities/
  - 顧客経路のMEDを上書きしない
  - 自AS内でのlocal preference(LP)を制御する
    BGP communityを顧客向けに提供する

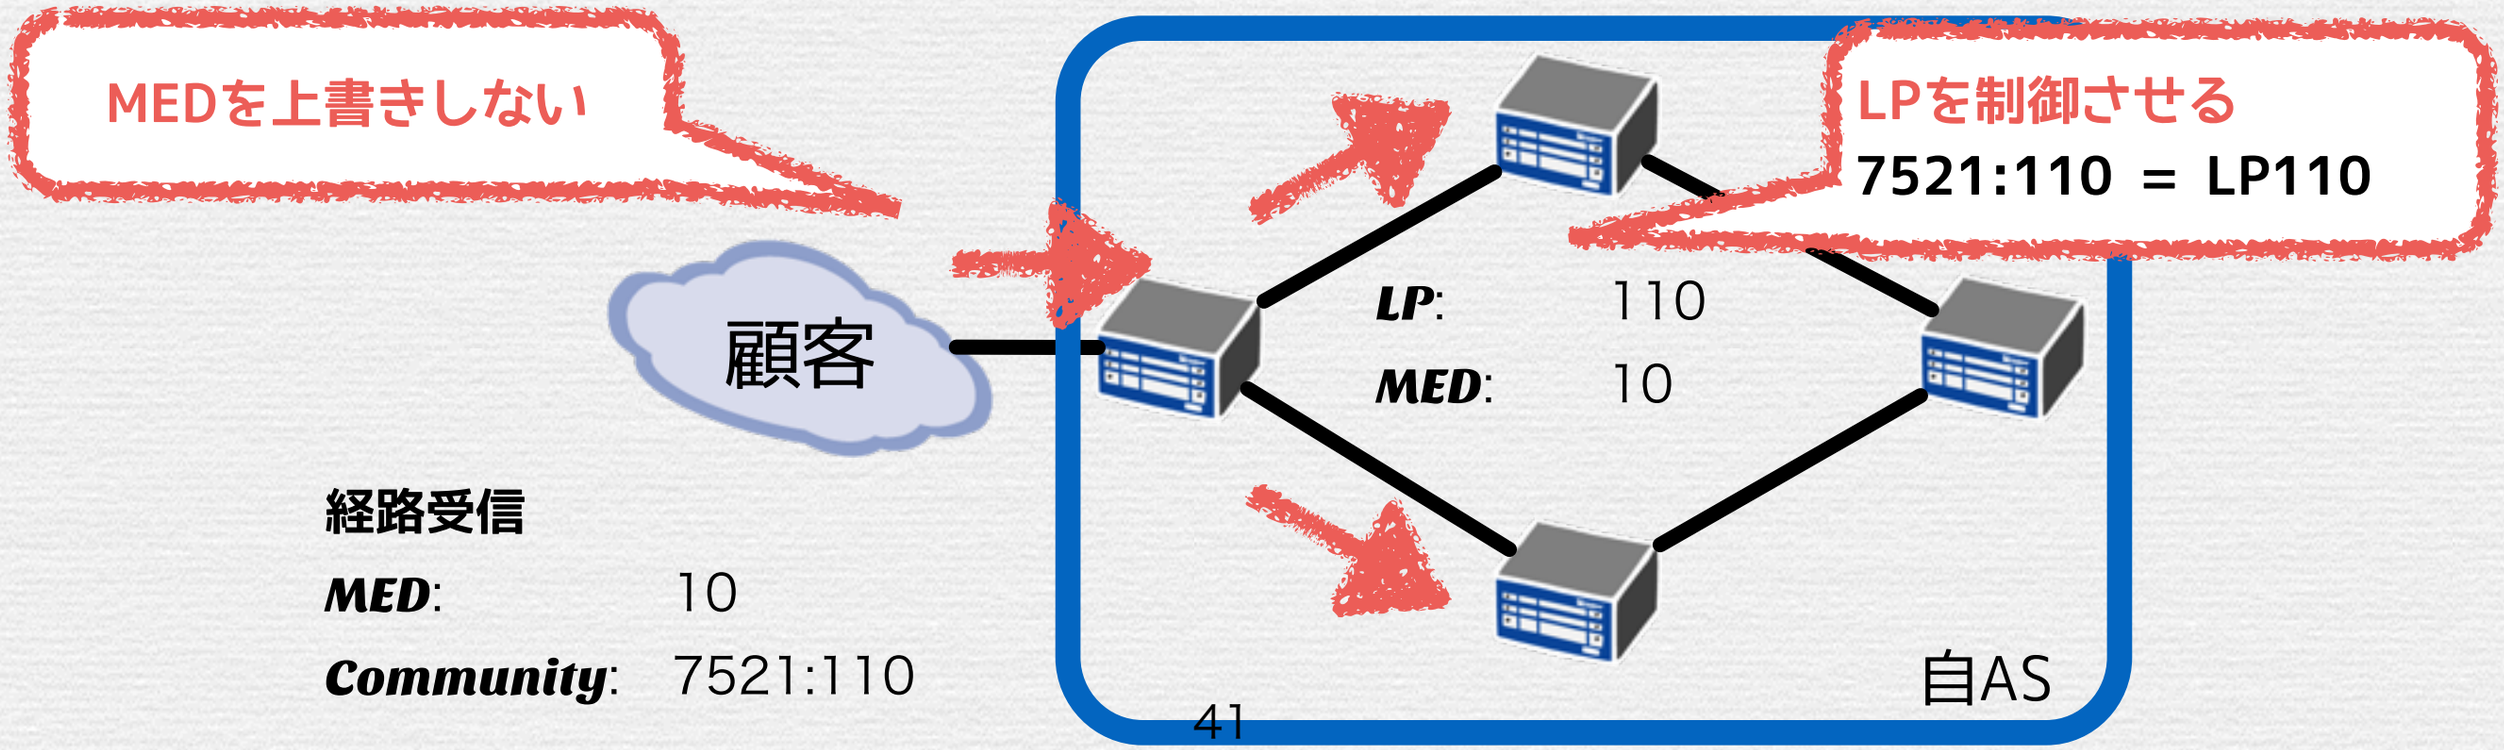

eBGP Policy 設計例（受信）

- **基本的に，受け取った経路は使う**
  - 例えば peer から“peerのpeer経路”を受信したとして，(相手の設定ミスの可能性大だが) 拒否する理由は特にない
  - 使いたくない理由があれば別（優先度を下げる or 拒否する）
    - 輻輳しそう，など

優先度	経路種別	LP	MED
1	顧客	150~300 (*)	上書きしない
2	自AS	200	なし
3	peer	200	上書き (十分大きな値)
4	transit	120	上書き

(*) 200をまたいで数段階（default: 300)

- 幅に余裕をもって数値を設定
- LPのdefault値が100の実装が多いので，
  安全を期すならLPの値は≥100

－ 解説 －

顧客の明確な意図がない限り最優先
常にRIBに保持

経路を指定して他の顧客やpeerに迂回させることができる

peerの200と比較して，必ず次のAS_PATHで優先度が決定

顧客のTE選択肢を増やす

優先度	経路種別	LP	MED
1	顧客	150~300 (*)	上書きしない
2	自AS	200	なし
3	peer	200	上書き (十分大きな値)
4	transit	120	上書き

- AS_PATHが同じならIGPベースのclosest exitを強制
- always-compare-med や peer&顧客AS対策でMEDを高めに
- 2^32 – 1 でもいいかも

private / public peer で2段階あるISPもある

一応>100

AS_PATHが同じならIGPベースのclosest exitを強制

(*) 200をまたいで数段階 (default:300)

eBGP Policy 設計例（受信）
– 経路Filter –

顧客経路の優先度が非常に高いため，細かくチェックする必要がある

- **IRRベース が理想的**
  - 頻繁にメンテナンスできるのであれば，手動でも問題ないかもしれない
- filter方法の候補
  - exact match な prefix filter
  - exact match な prefix filter & origin AS filter

- **bogon prefix，自ASのprefixは経路filterで除外**
- BGP communityは透過的に扱う

peer経路も手放しでは危ない

- **経路hijackの可能性**
- 細かいfilterを設定してしまうと**メンテナンスされなくなるかもしれない**
  - “AS_PATHをメールで伝え合う” 仕組みが動いていた
  - やはり限界があるので，できるのであれば顧客経路同様IRRベースがよい
- 一方，他の国では以下の組み合わせが多い
  - **maximum-prefix (prefix-limit) filter**
    - 実績ベース（昨日から20%増えたらアウト，など)
    - peering dbベース
  - **prefix lengthによるfilter**
    - ipv4: le /24
    - ipv6: le /48 など

Maximum-Prefix (Prefix-Limit) Filter

⚠ transitに設定すると危険な場合がある

- network上のeventにより急にprefix数が増えると，transitが全断するリスクがある
  - internetから遮断されることになる

経路Filterに関する参考情報

JANOG Comment JC1000~1003 に
大変丁寧にまとめられている
http://www.janog.gr.jp/doc/janog-comment/

eBGP Policy 設計例（受信）
– closest exit –

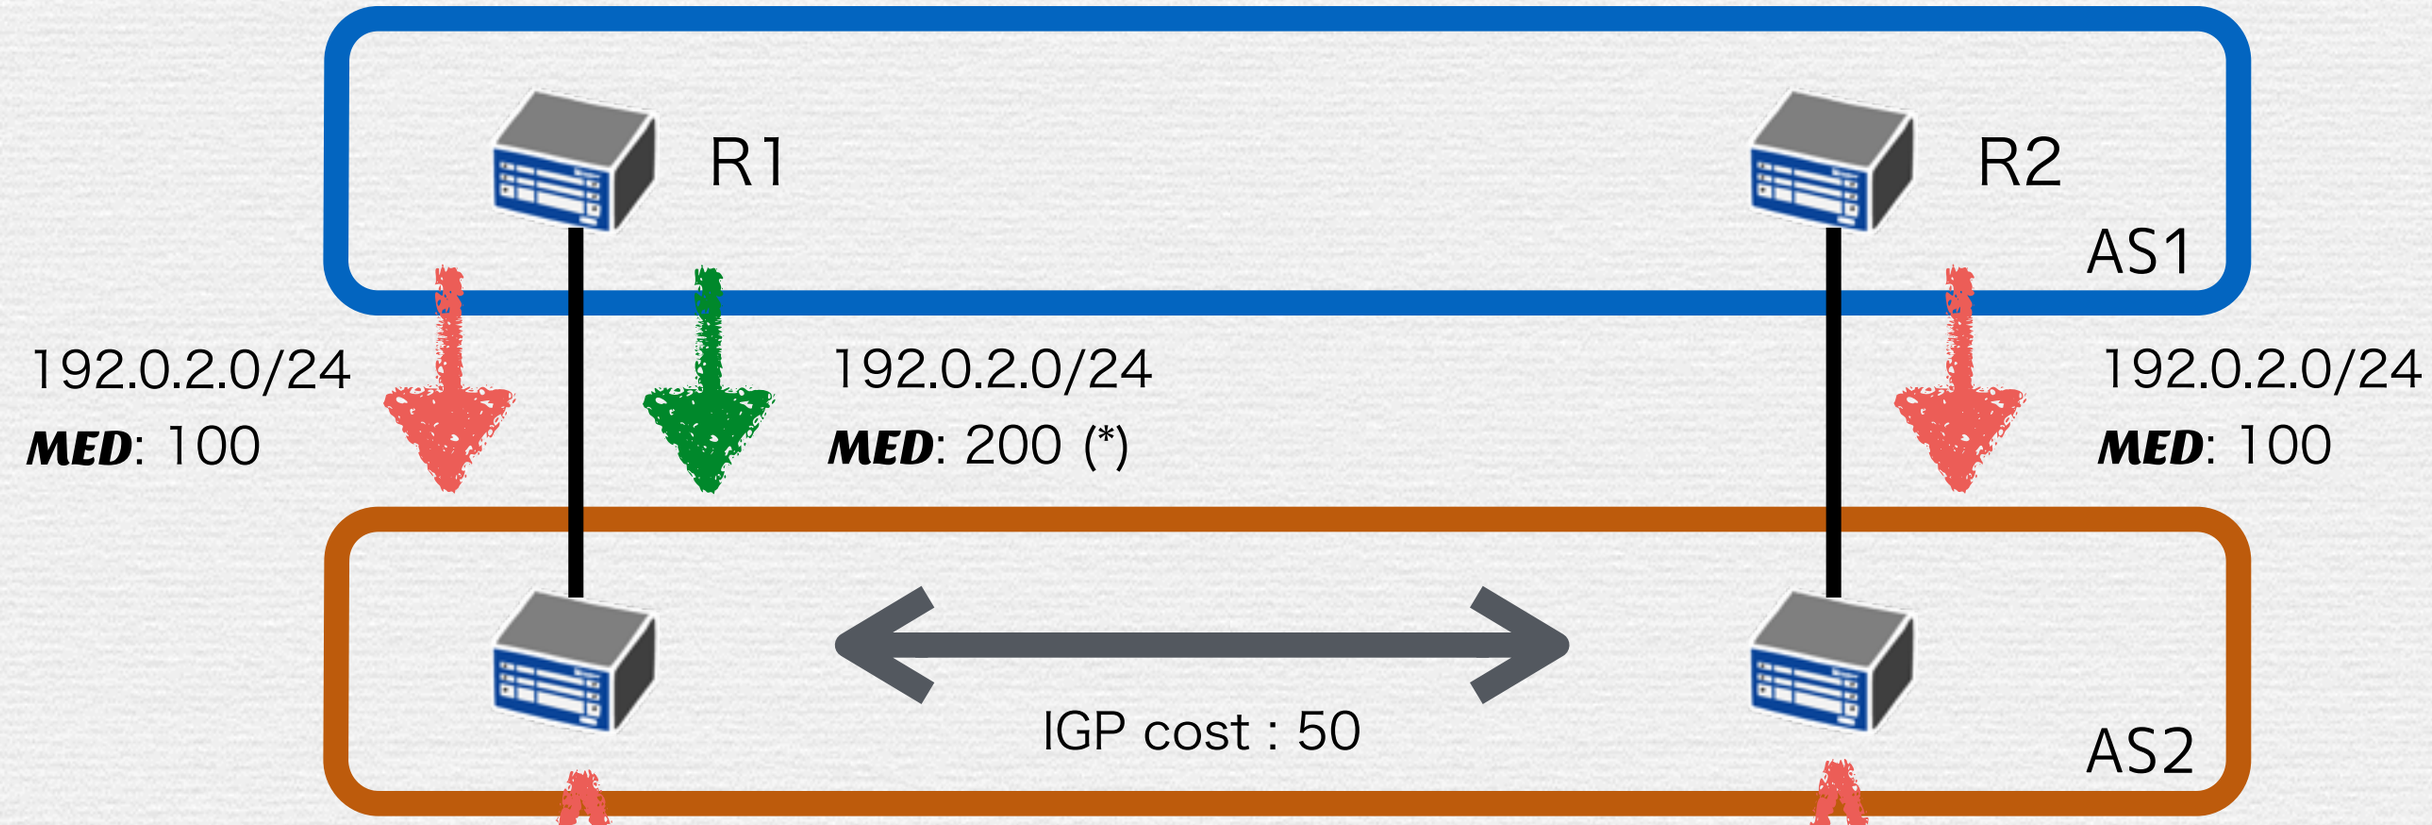


```
  prefix           Next Hop   MED     IGP
> 192.0.2.0/24     R1         100     0
  192.0.2.0/24     R2         100     50
```

```
  prefix           Next Hop   MED     IGP
  192.0.2.0/24     R1         100     50
> 192.0.2.0/24     R2         100     0
```

IGPによる制御

(*) MEDが異なる経路でもclosest exitしたい場合はMEDを上書きする必要がある

IGPを用いる代わりに，MEDを加算することでも一応実現できる

Juniper:	metric add 500
Cisco:	set metric +500

× router間でMED加算して回る必要がある

△ こちらもMEDの上書きが必要

(“壁”になっている 500 という数値が十分かどうかはpeer partnerの広告policy次第)

・ 本来のMEDの用途とは異なる

経路制御のオプション（受信）

どの経路を優先するかについて

- transit / peer 経路
  - LPの微調整
  - AS_PATH prepend
  - MED微調整
  - passive IGP
  - 経路を止める

- 顧客経路
  - 顧客からの依頼に基づく場合を除き，操作しない

- LP / MED などの数値はなるべく **弱くなる** 方に制御する
  - ヘンにtrafficを吸い込むのを防ぐ
  - MED: 増やす
    LP: 減らす (多くの実装でdefault: 100)
- AS_PATH prepend
  prepend された経路がRIBに残ってしまう可能性があるので，なるべく避ける
  - transitを売っている場合など，全体として経路が遠く見えてしまうのは良くない
- passive IGPは経路ごとの制御ができない

- LP / MED / AS_PATH 操作
  - **なるべくメンテナンス頻度を下げる**
    - peer AS
    - nexthop
    - origin AS
    - AS_PATH
    - prefix

  の順で操作

  (例えばprefixは時間が経つと変化する可能性が高い)

```
protocols {
    bgp {
        neighbor x.x.x.x {
            import [ regular irregular finalize ];
        }
    }
}

policy-options {
    policy-statement regular {
        from { ... }
        then {
            # 通常のpolicy
            next policy;
        }
    }

    #
    # remove me soon !!
    #
    policy-statement irregular {
        from { ... }
        then {
            # irregular なpolicy
            next policy;
        }
    }
    policy-statement finalize {
        then accept;
    }
}

# Juniperの例
```

```
no route-map route-filter
route-map route-filter permit 10
  ! 通常のpolicy
route-map route-filter permit 20
  ! 通常のpolicy
route-map route-filter permit 30
  ! 通常のpolicy

!
! remove me soon !!
!
route-map route-filter permit 25
  ! irregular なpolicy

! Cisco の例
```

irregularなことは目立つように / 消しやすく

経路制御のオプション（受信）

－ LP 制御 －

一部経路はpeerより
優先させたい

```
prefix          MED AS_PATH
192.0.2.1/32    100 1
192.0.2.2/32    100 1
```

```
   prefix          LP  MED  AS_PATH
>  192.0.2.1/32    120 1000 1
   192.0.2.1/32    110 1000 2
>  192.0.2.2/32    120 1000 1
```

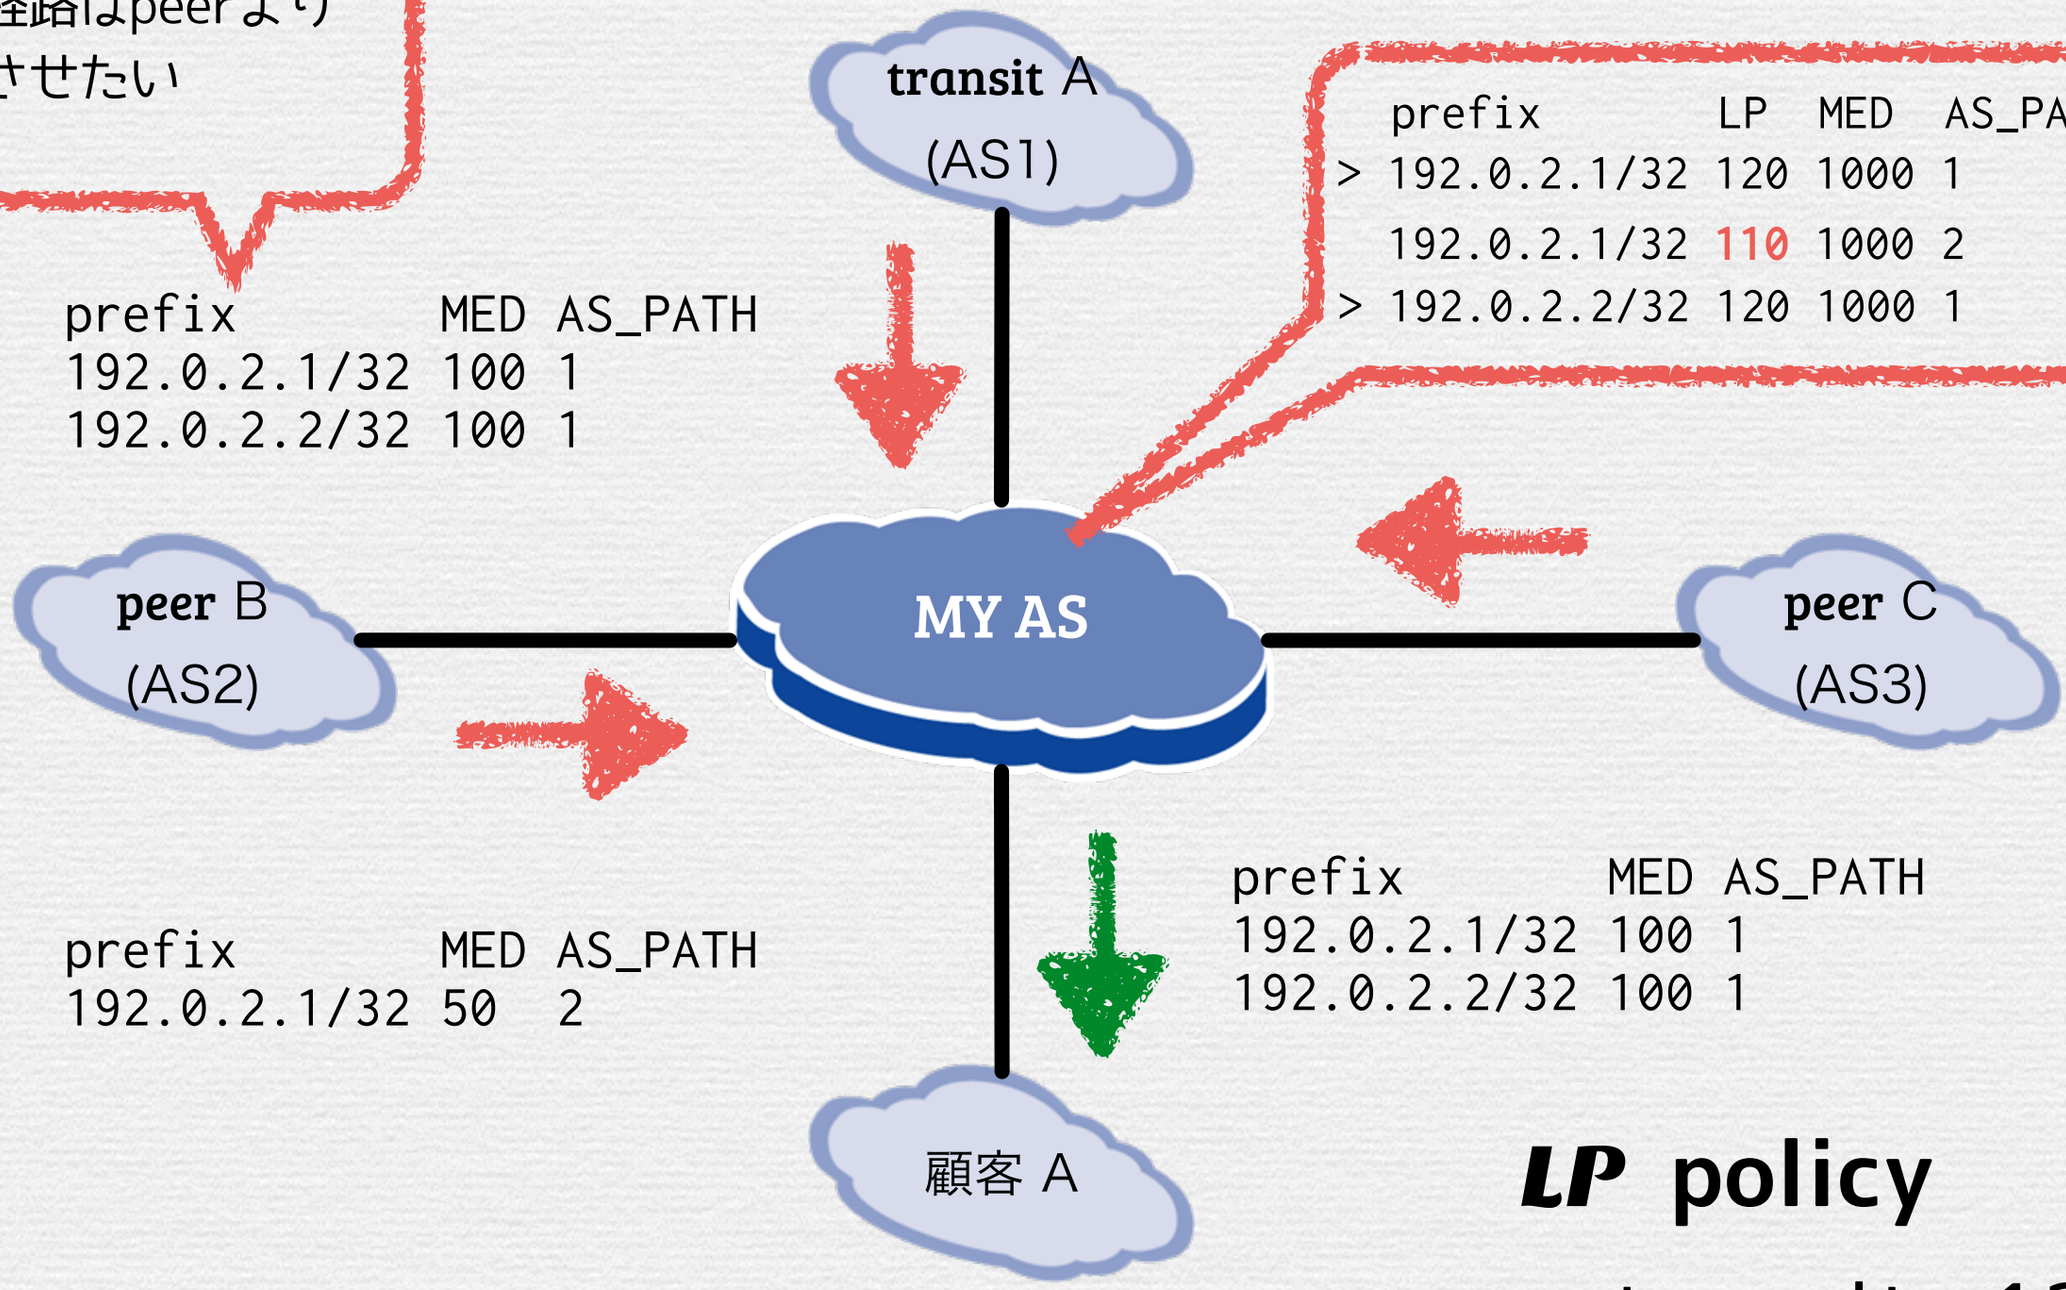


```
prefix          MED AS_PATH
192.0.2.1/32    50  2
```

```
prefix          MED AS_PATH
192.0.2.1/32    100 1
192.0.2.2/32    100 1
```

peer B からの経路について，LP を下げる

LP policy

- transit 120
- peer 200

経路制御のオプション（受信）

－ MED 制御 －

2 router から同じ経路を受信しているような場合で，優先度を操作したい

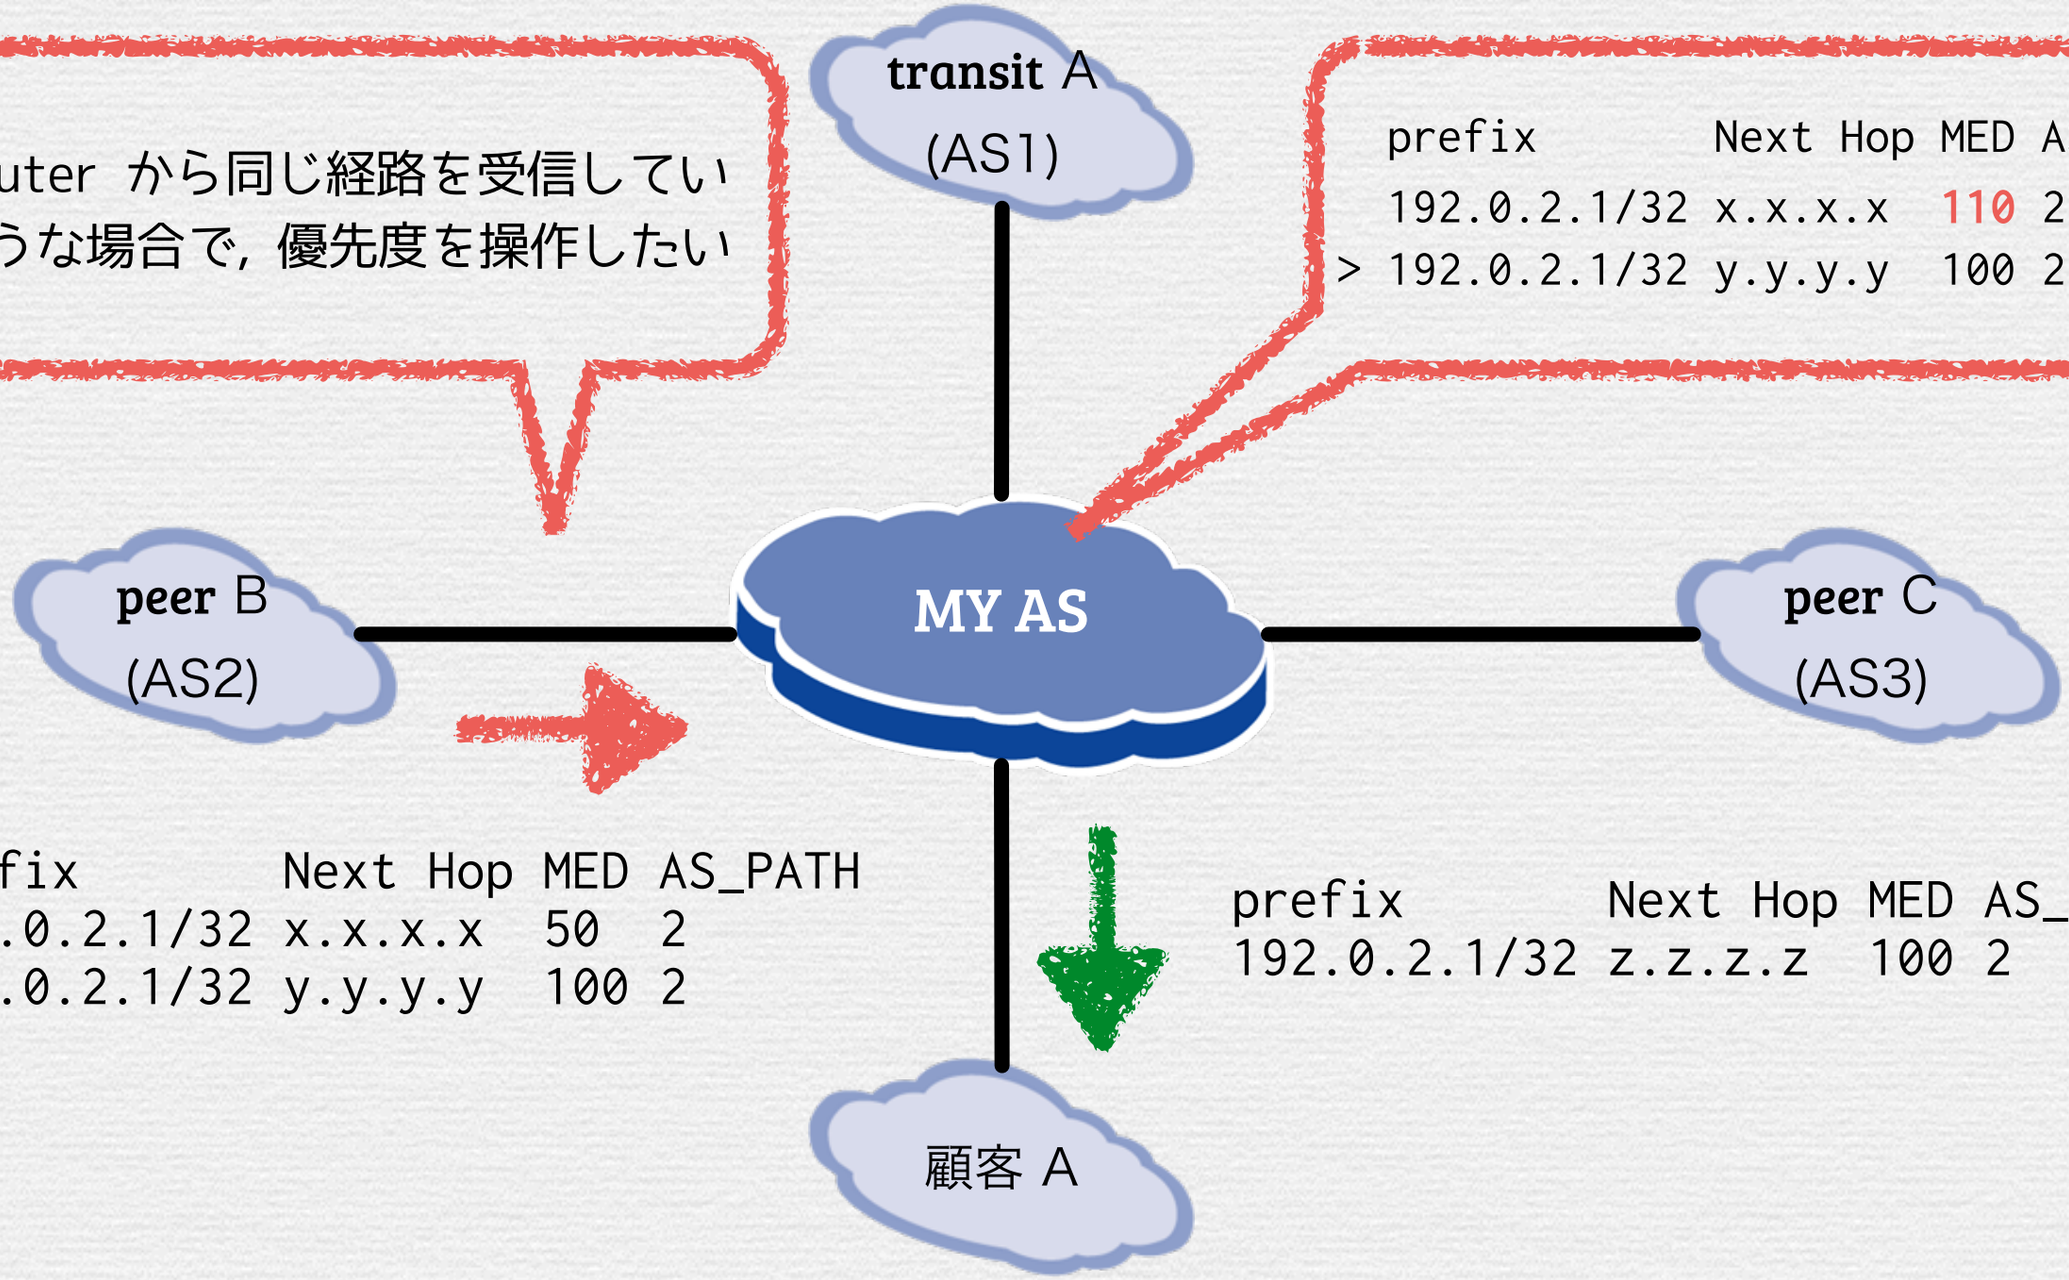


```
  prefix          Next Hop MED AS_PATH
  192.0.2.1/32    x.x.x.x  110 2
> 192.0.2.1/32    y.y.y.y  100 2
```

```
prefix          Next Hop MED AS_PATH
192.0.2.1/32    x.x.x.x  50  2
192.0.2.1/32    y.y.y.y  100 2
```

```
prefix          Next Hop MED AS_PATH
192.0.2.1/32    z.z.z.z  100 2
```

peer B からの経路について，一方のMEDを大きくする
(大きな値をセットする or **加算して大きくする**)

経路制御のオプション（受信）

－ IGP 制御 －

2 router から同じ経路を受信しているような場合で，neighbor単位で優先度を操作したい

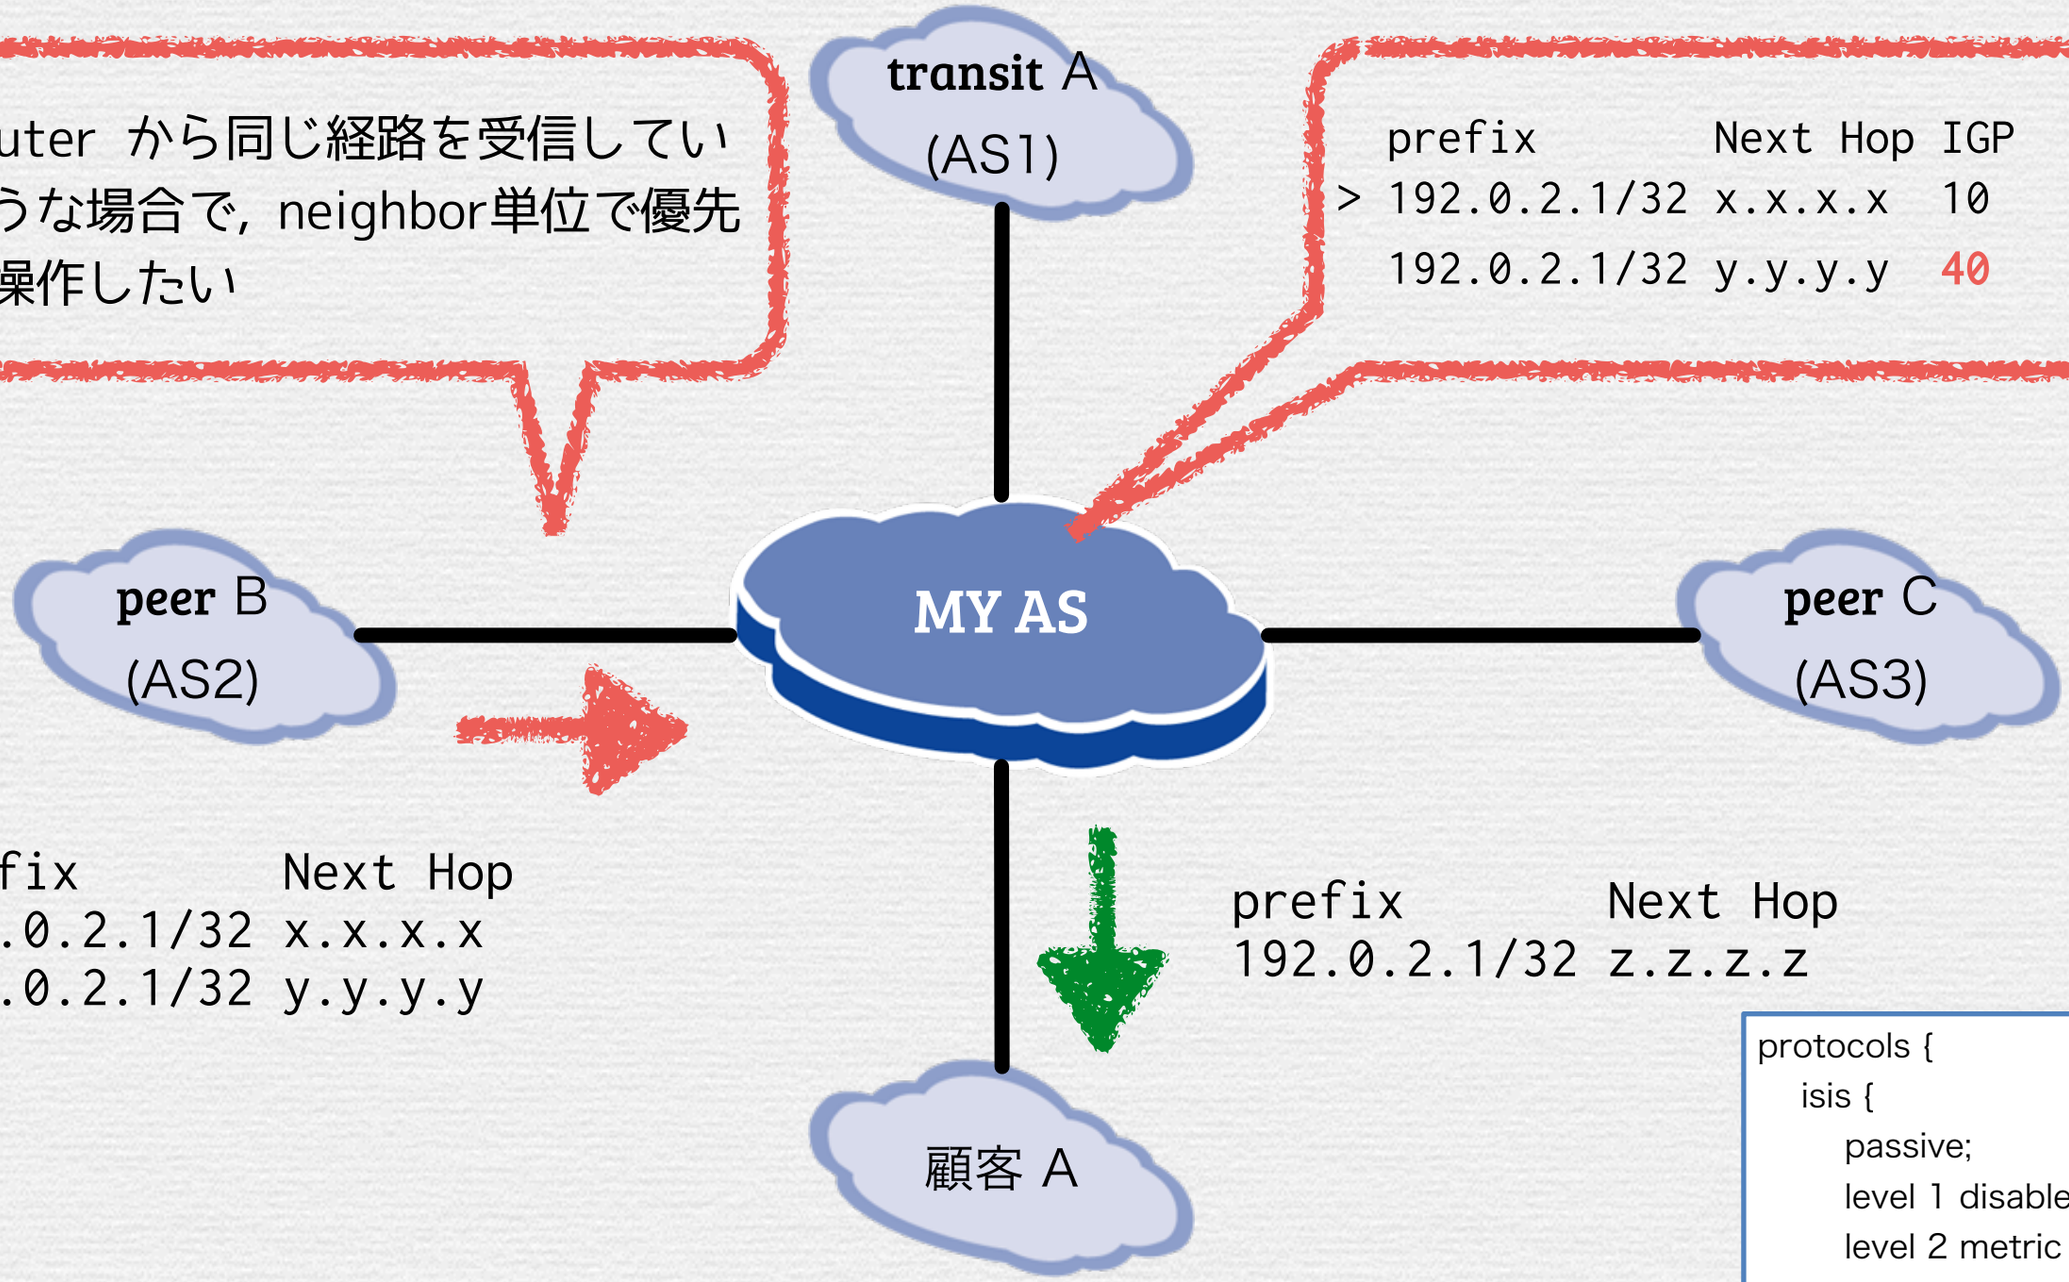


```
  prefix          Next Hop IGP
> 192.0.2.1/32    x.x.x.x  10
  192.0.2.1/32    y.y.y.y  40
```

```
prefix          Next Hop
192.0.2.1/32    x.x.x.x
192.0.2.1/32    y.y.y.y
```

```
prefix          Next Hop
192.0.2.1/32    z.z.z.z
```

```
protocols {
    isis {
        passive;
        level 1 disable;
        level 2 metric 30;
    }
}

# Juniper の例
```

通常だと，MY ASから見て x.x.x.x，y.y.y.y へのIGP costは両方 10 だが，一方だけ 40にする

eBGP policy / 経路広告

eBGP Policy 設計例（広告）

- 自ASが持つすべての経路(full route)を顧客に
- 顧客からのすべての経路 + 自ASの経路を
  - transitに
  - peerに

  広告
- 経路の種別による”マーク”をBGP communityとして

  付与すると顧客は便利に使える

  http://www.us.ntt.net/support/policy/routing.cfm
  - 外部ASから，**どの地域**で受け取ったか?
  - 外部ASとは，**transit**か? **peer**か? **顧客**か?

・ prepend community（例）

顧客に，自AS ➔ 外部ASへの広告時の
AS_PATHを制御させる

community: 7521:102
AS_PATH: 1

community: N/A
AS_PATH: 7521 7521 7521 1

- MED: 優先度をつけて広告する

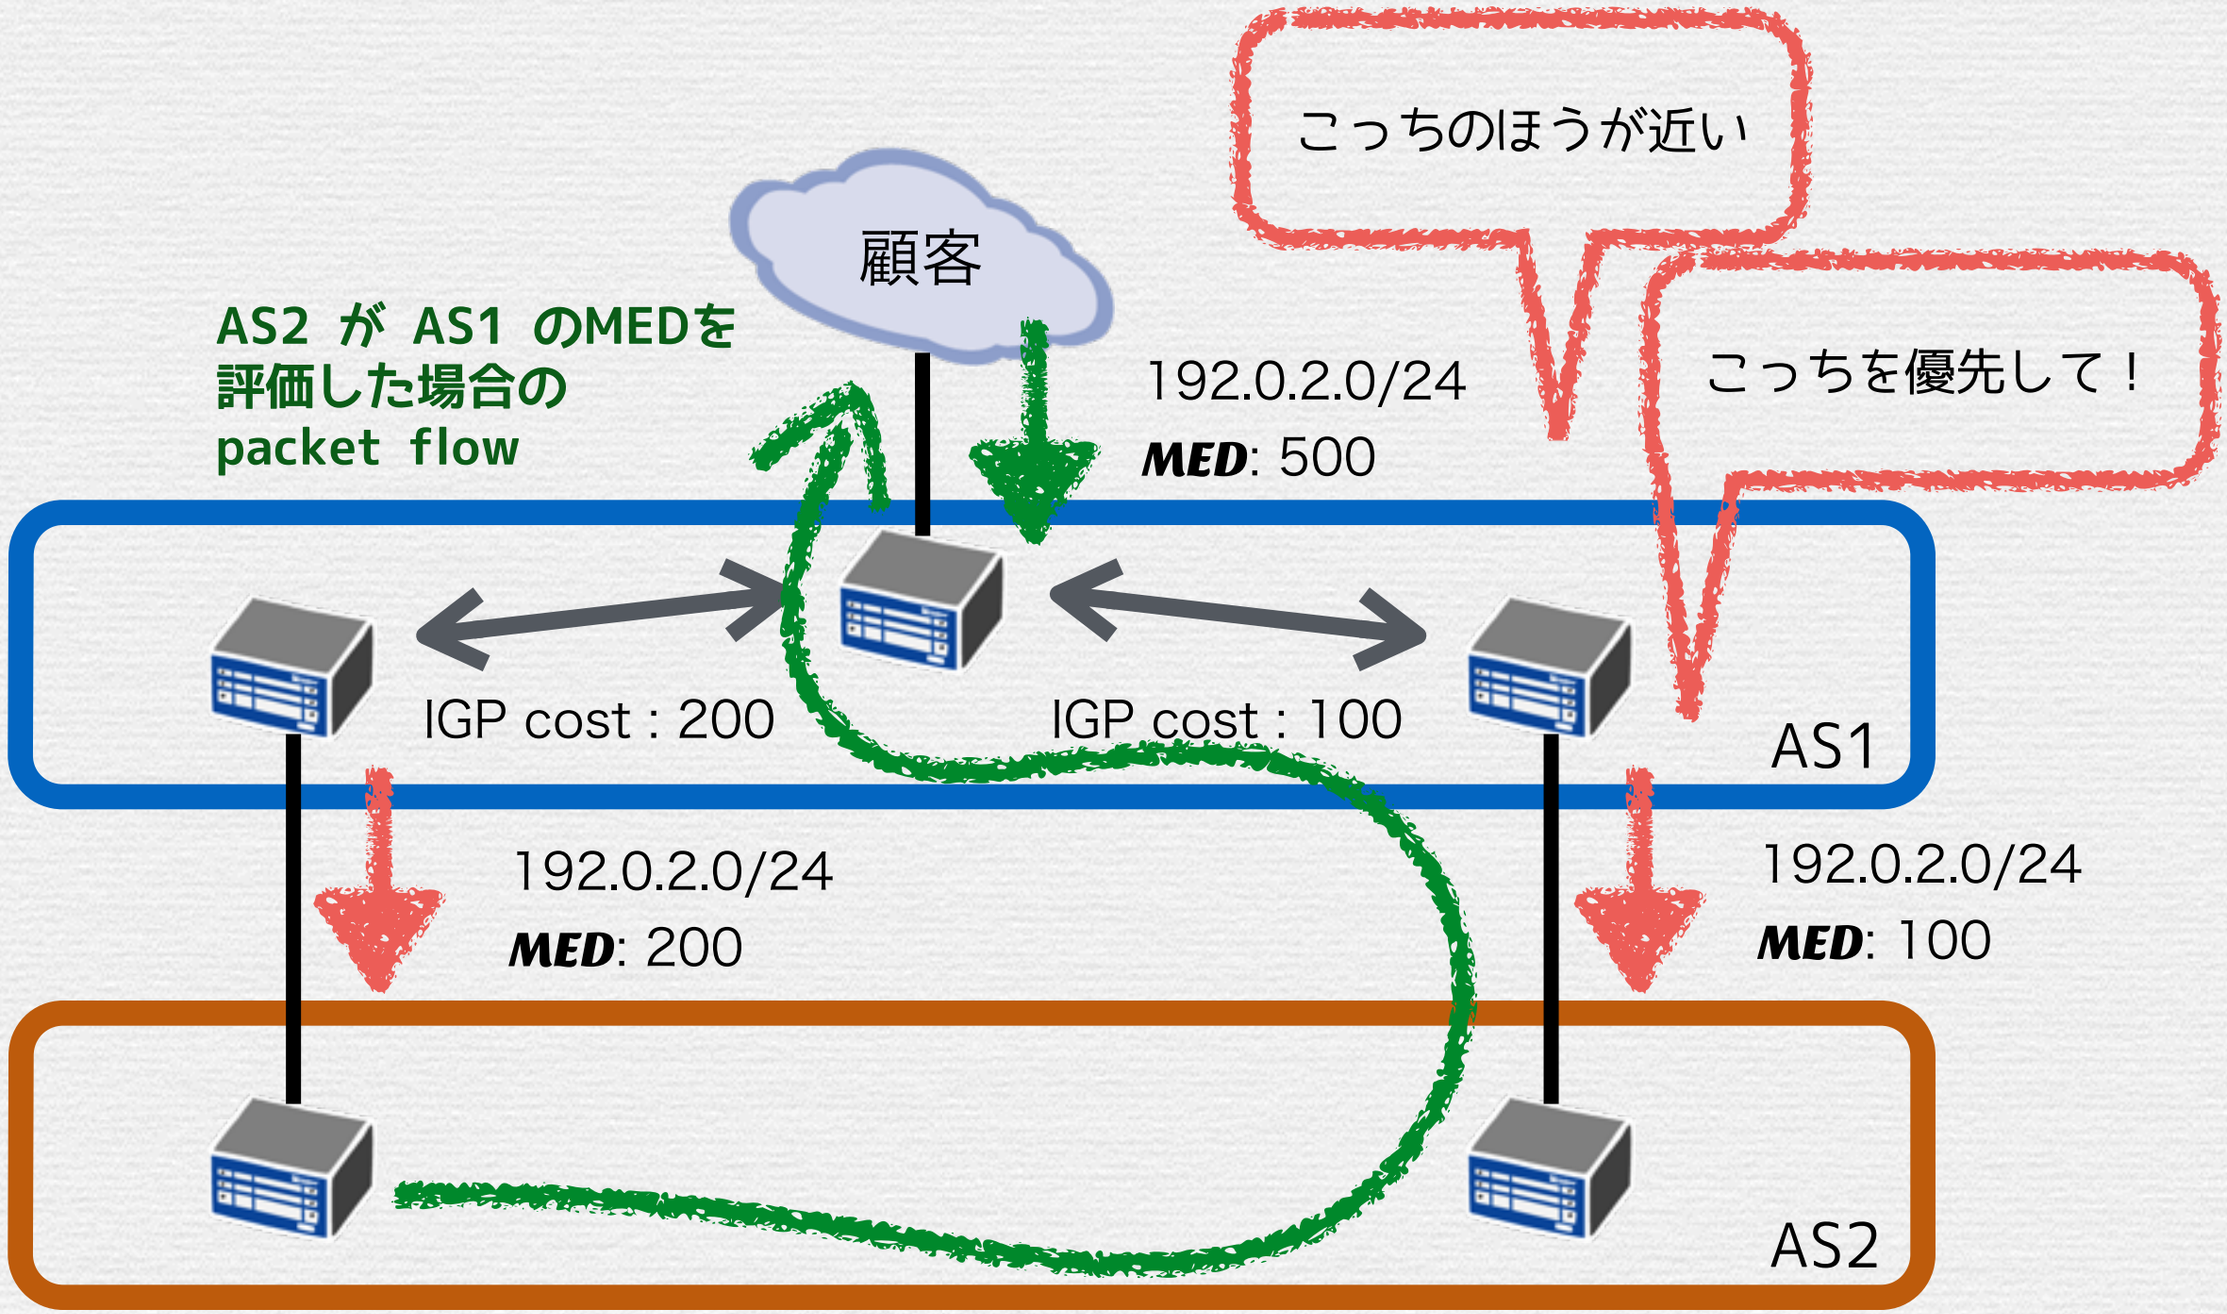

- metric-out igp が便利
  - IGP costを広告時のMEDとして利用

```
protocols {
    bgp {
        group ebgp {
            metric-out igp;
            neighbor x.x.x.x { ... }
        }
    }
}

# Juniper の例
```

```
router bgp xxxx
  ...
  neighbor y.y.y.y route-map ebgp
route-map ebgp
  ...
  set metric-type internal

! Cisco の例
```

⚠ 外部ASが常にMEDを評価してくれるとは限らない
- ダメもとでも広告しておく価値あり
- 評価してもらいたいなら，交渉

eBGP Policy 設計例（広告）
– 経路Filter –

- 内部の細かい経路は広告しない
  - connected(direct)経路はBGPにredistributeしないなど
    - するときにはno-export communityを付けておく
- bogonその他，internetに流すべきでない経路が含まれないかを再確認
- remove-privateしておく（private ASは削って広告）

- AS_PATH

  prependにより制御できるが，比較的制御が強い

- “設計”に含めるのは，やりすぎなイメージ
- どちらかというとtrouble shootなどの暫定対処用

経路制御のオプション（広告）

- 誰に対して制御するかについて
  - transit / peer
    - AS_PATH prepend
    - MED 微調整
  - BGP community（一部transitのみ）
    - transit AS 内のLP を制御
    - transit AS ➔ 他AS 経路広告を制御（広告しない / prepend）
  - 経路広告を止める

- 顧客
  - 顧客からの依頼に基づく場合を除き，操作しない

経路の各path attributeは誰のもの?

再掲

- 以下のような機能を提供しているISPも
  http://onesc.net/communities/
  - 顧客経路の**MEDを上書きしない**
  - 自AS内での**local preference(LP)を制御する**
    BGP communityを顧客向けに提供する

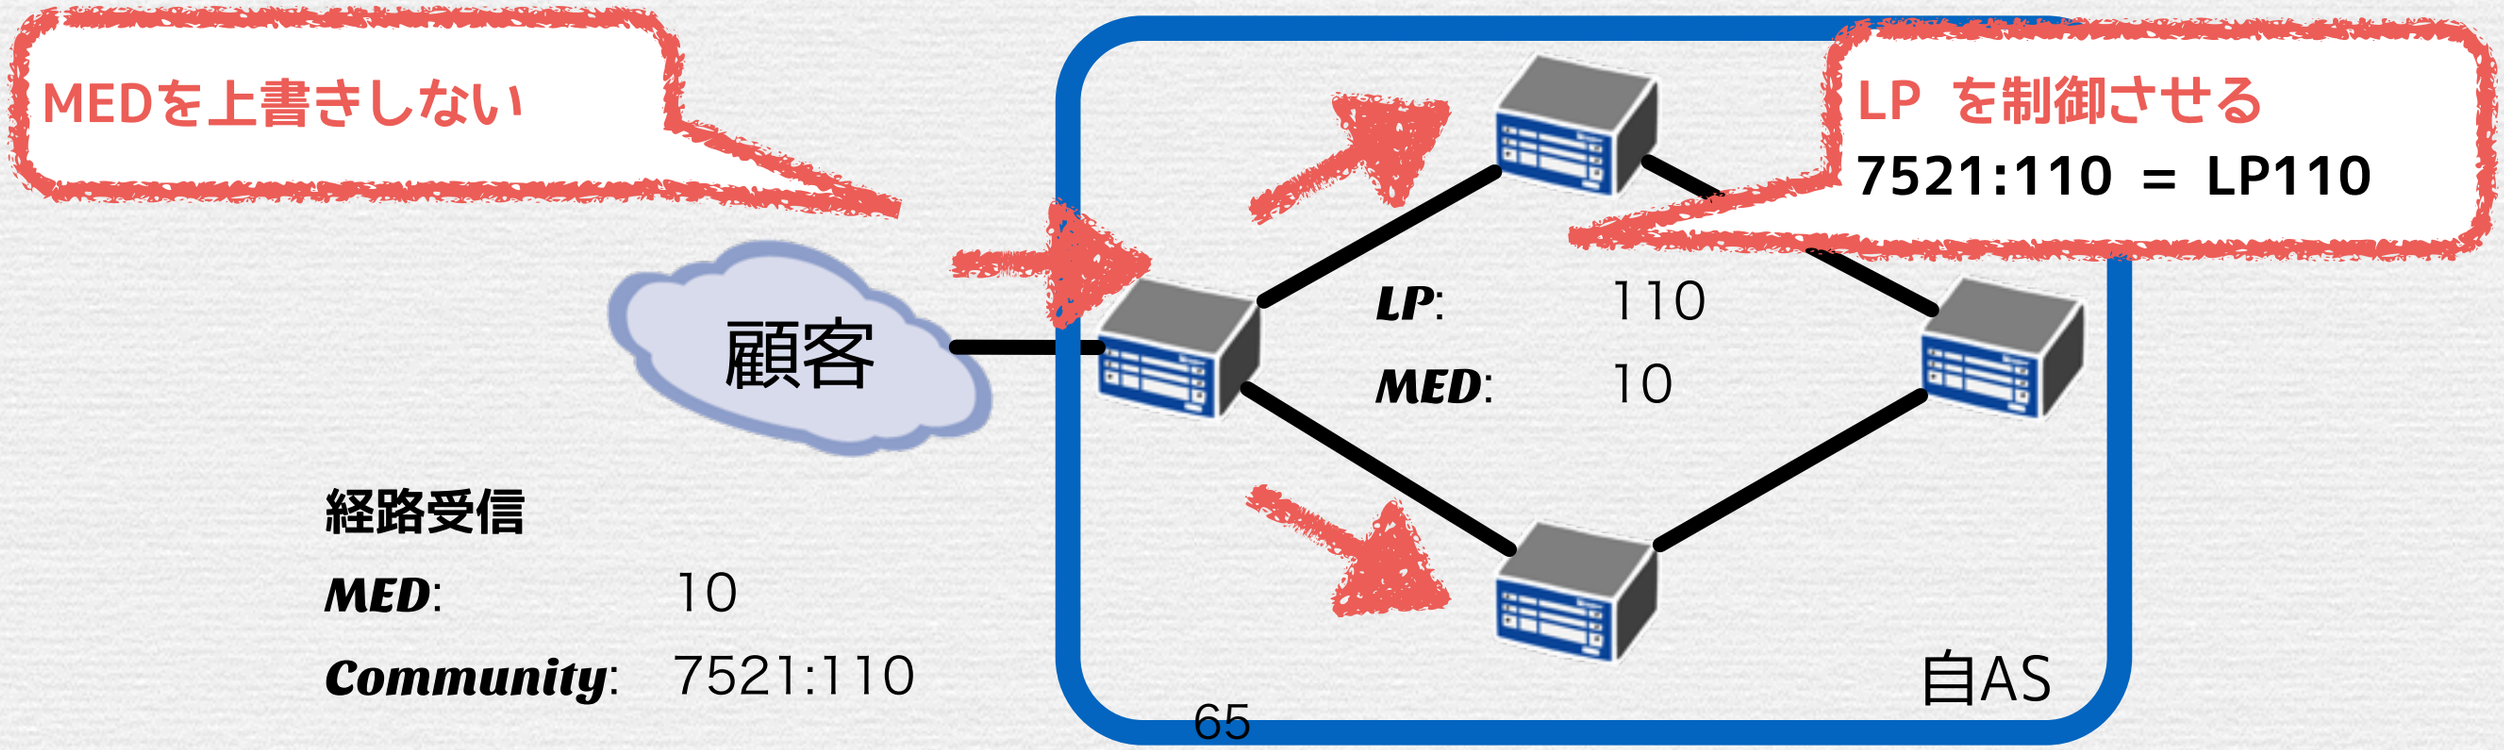

再掲

- prepend community（例）

顧客に，自AS ➔ 外部ASへの広告時の
AS_PATHを制御させる

community:	7521:102	community:	N/A
AS_PATH:	1	***AS_PATH***:	7521 7521 7521 1

経路制御のオプション（広告）
－ AS_PATH 制御 －

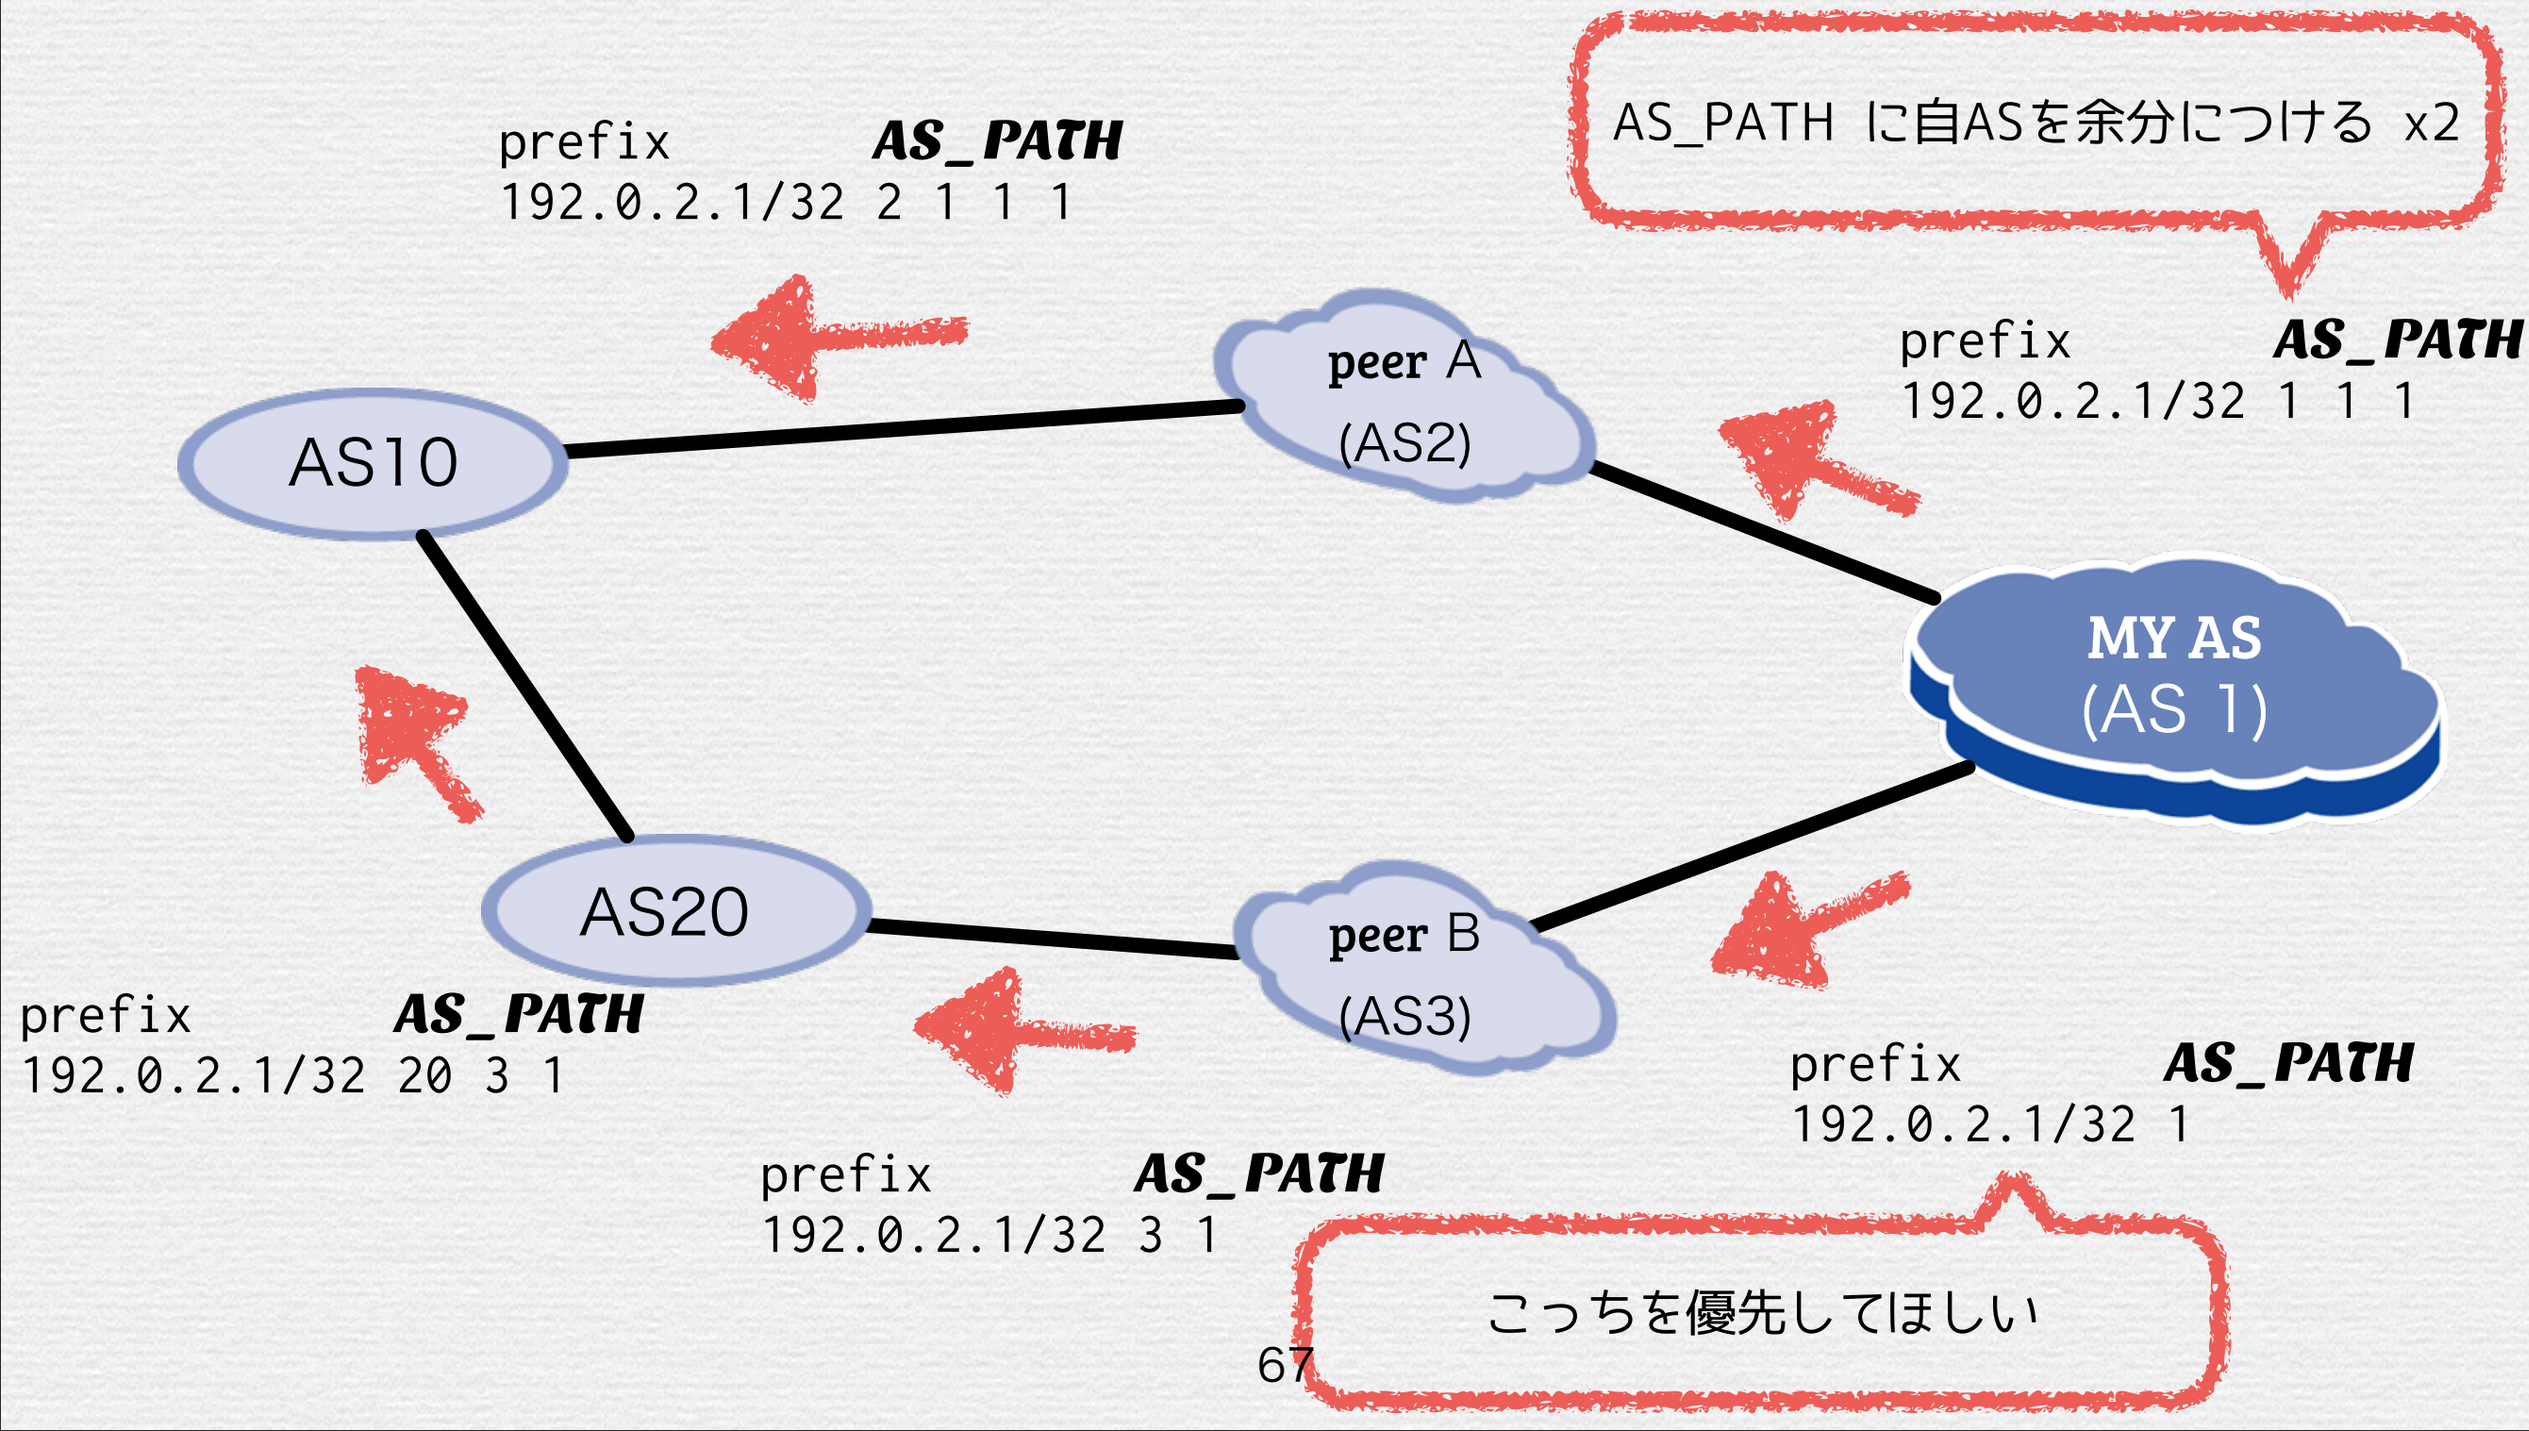

経路制御のオプション（広告）
－ MED 制御 －

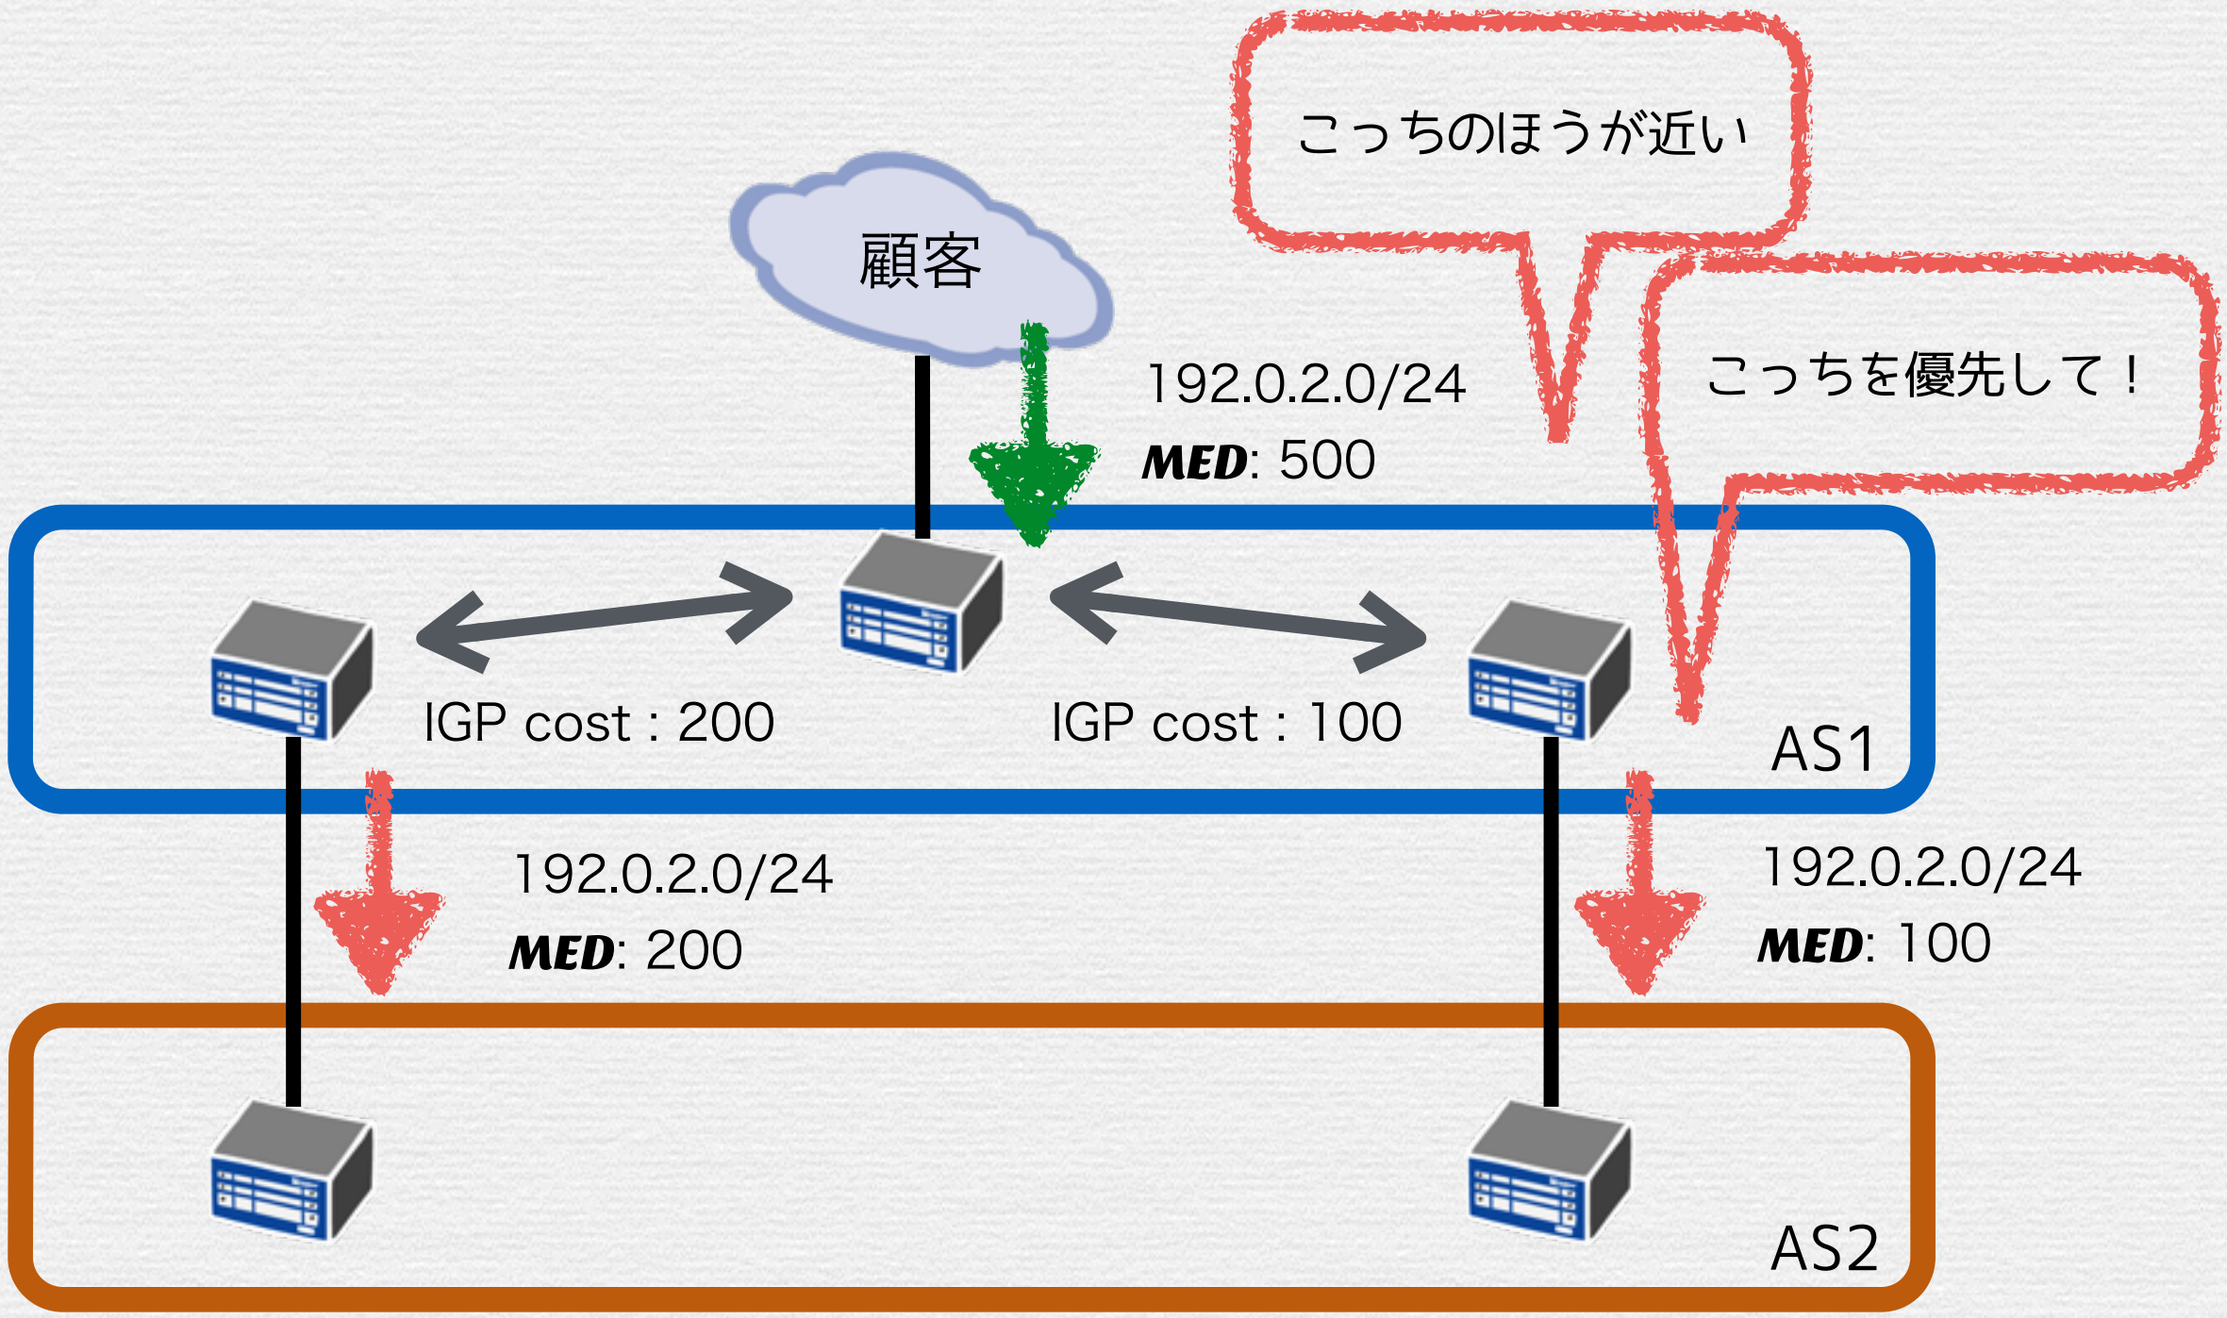

経路制御のオプション（広告）

- 広告経路の制御が効かない場合も多々ある
  - 顧客 / peering partner / transit提供者にも彼らなりのpolicyがあるので，やむを得ない
  - **接続しているtransit / peer のrouting設計を理解することがすごく重要**
    - MEDは効くか?
    - AS_PATH prepend可能か?
    - best pathはどのpath attributeで決まっているか?
    - 制御系BGP communityはあるか?
    - **そのような設計になっているのはなぜか?**

  - 直接答えてもらえればラッキー
  - 推測の蓄積でも十分役立つ

以下のオプションは高い確率で効果が期待できる

- BGP Community

奥の手！

- 経路広告を止める
  - 多くの場合，冗長性を損なう
  - more specificな経路にする(/20 = 2x /21)
    - 管理が煩雑になる

シンプルに
わかりやすく

http://www.flickr.com/photos/techsavvyed/5926978939/

それぞれのpolicyで違うので

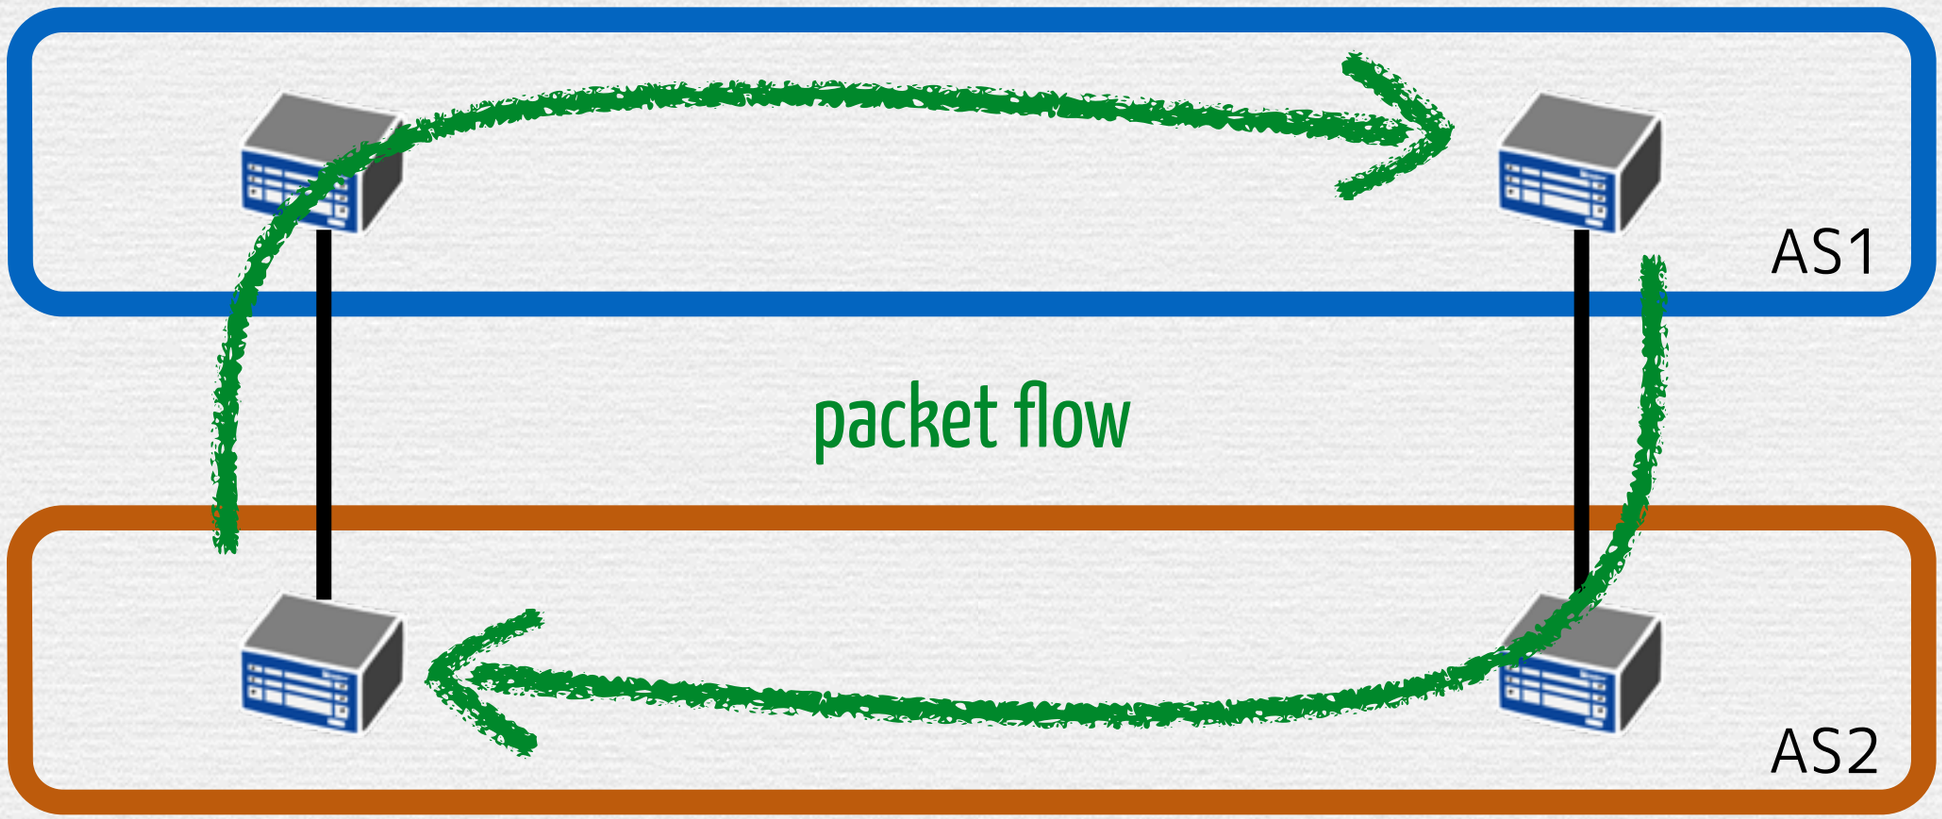

- 非対称なpacket flowになりがち
  - trouble shootしにくい
    例: pingの往復でpathが違う

お互い誠意を持って運用しよう

http://www.flickr.com/photos/waldec/2470541755/

Beer & Peer !

http://www.flickr.com/photos/mckln/3449304905/

iBGP policy / 設計

iBGP Policy を考えるポイント

- networkの中でどこまでBGPを動作させるか?
  - なるべくDFZ(Default Free Zone)が好ましい
- iBGP full-meshのスケールは?

- BGPを動作させないrouterやdefault routeが存在する場合はrouting loopに注意
- iBGP full-meshがスケールしなくなったら
  - Route Reflector or BGP Confederation

論理Topology 設計

- 物理 / 論理topologyを揃えておく
  - networkをシンプルに保つため

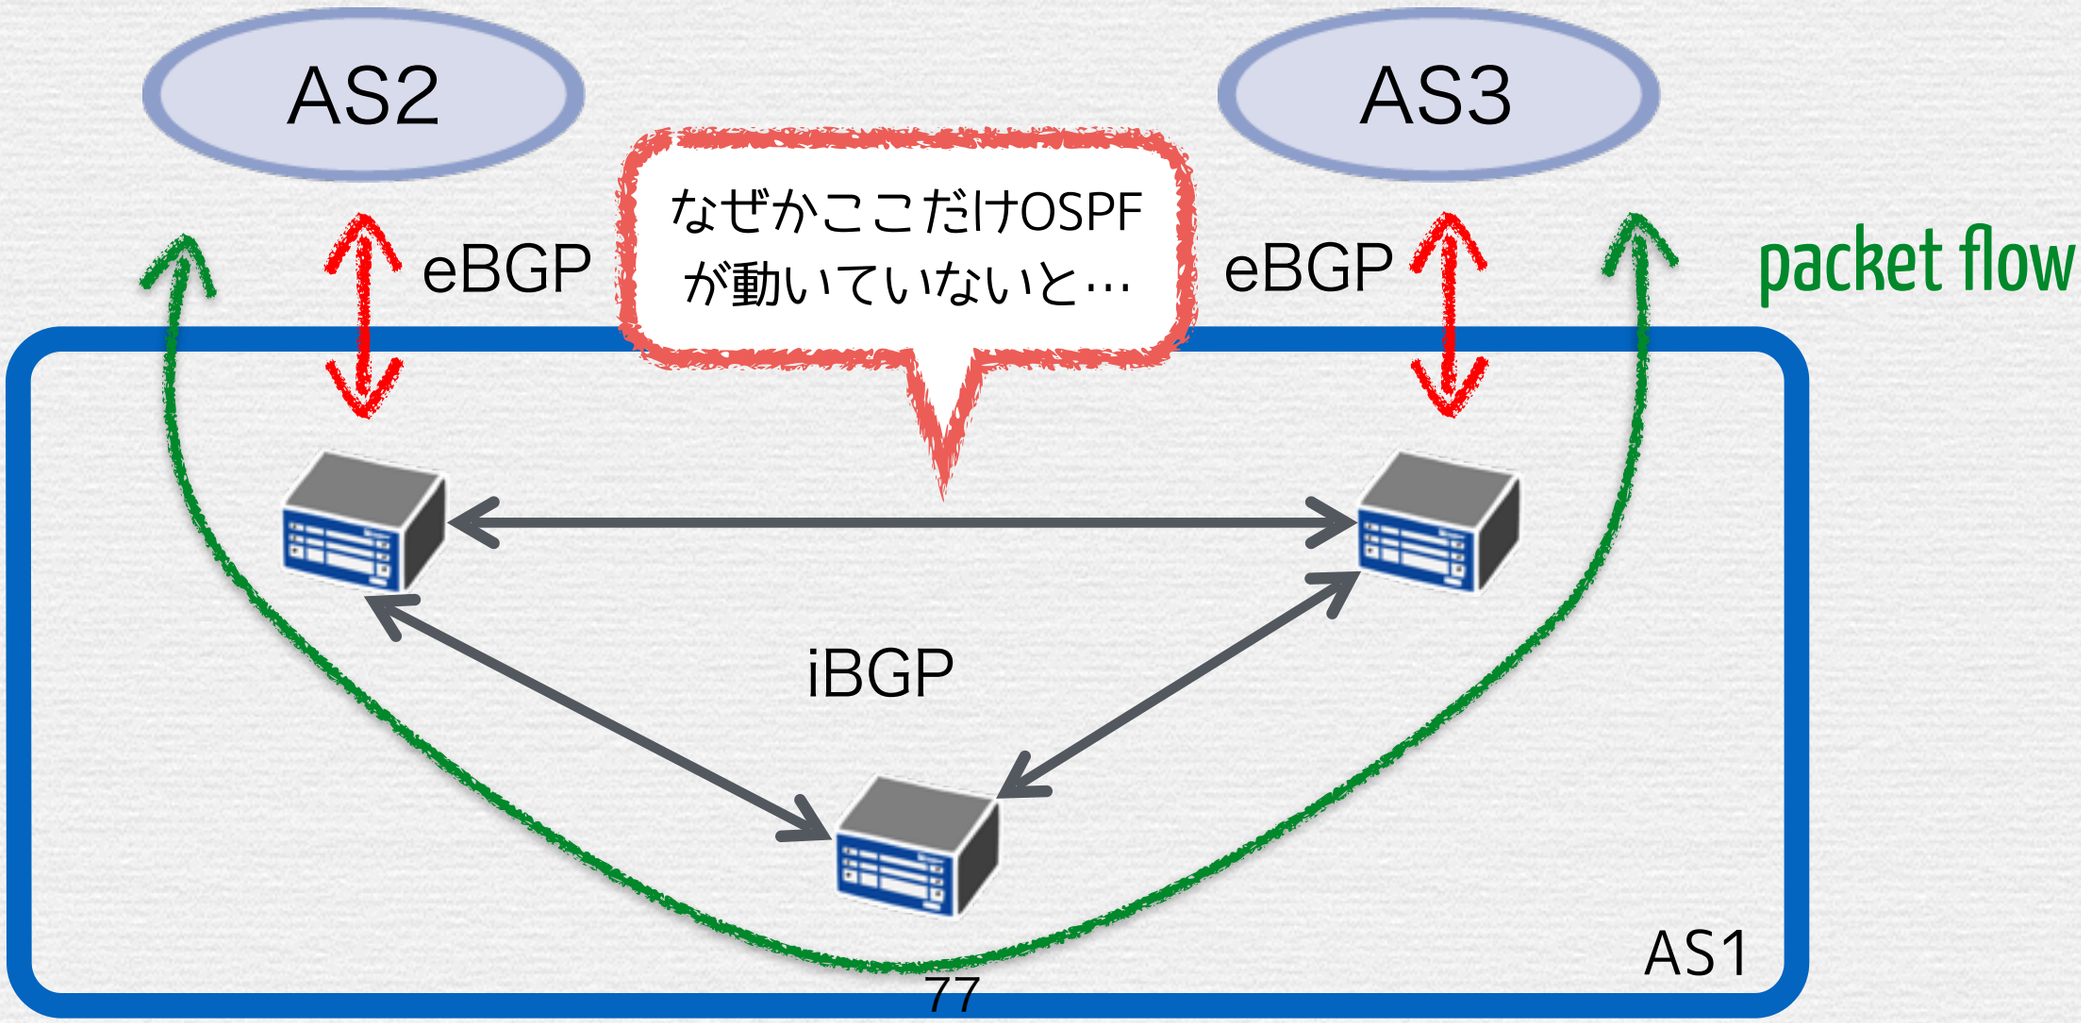

BGP Confederation

Route Reflector(RR)同様，BGPスケーラビリティを向上させる技術

- 複数のsub ASに分割し，sub AS間をeBGP接続
- hub & spokeが良いとされる

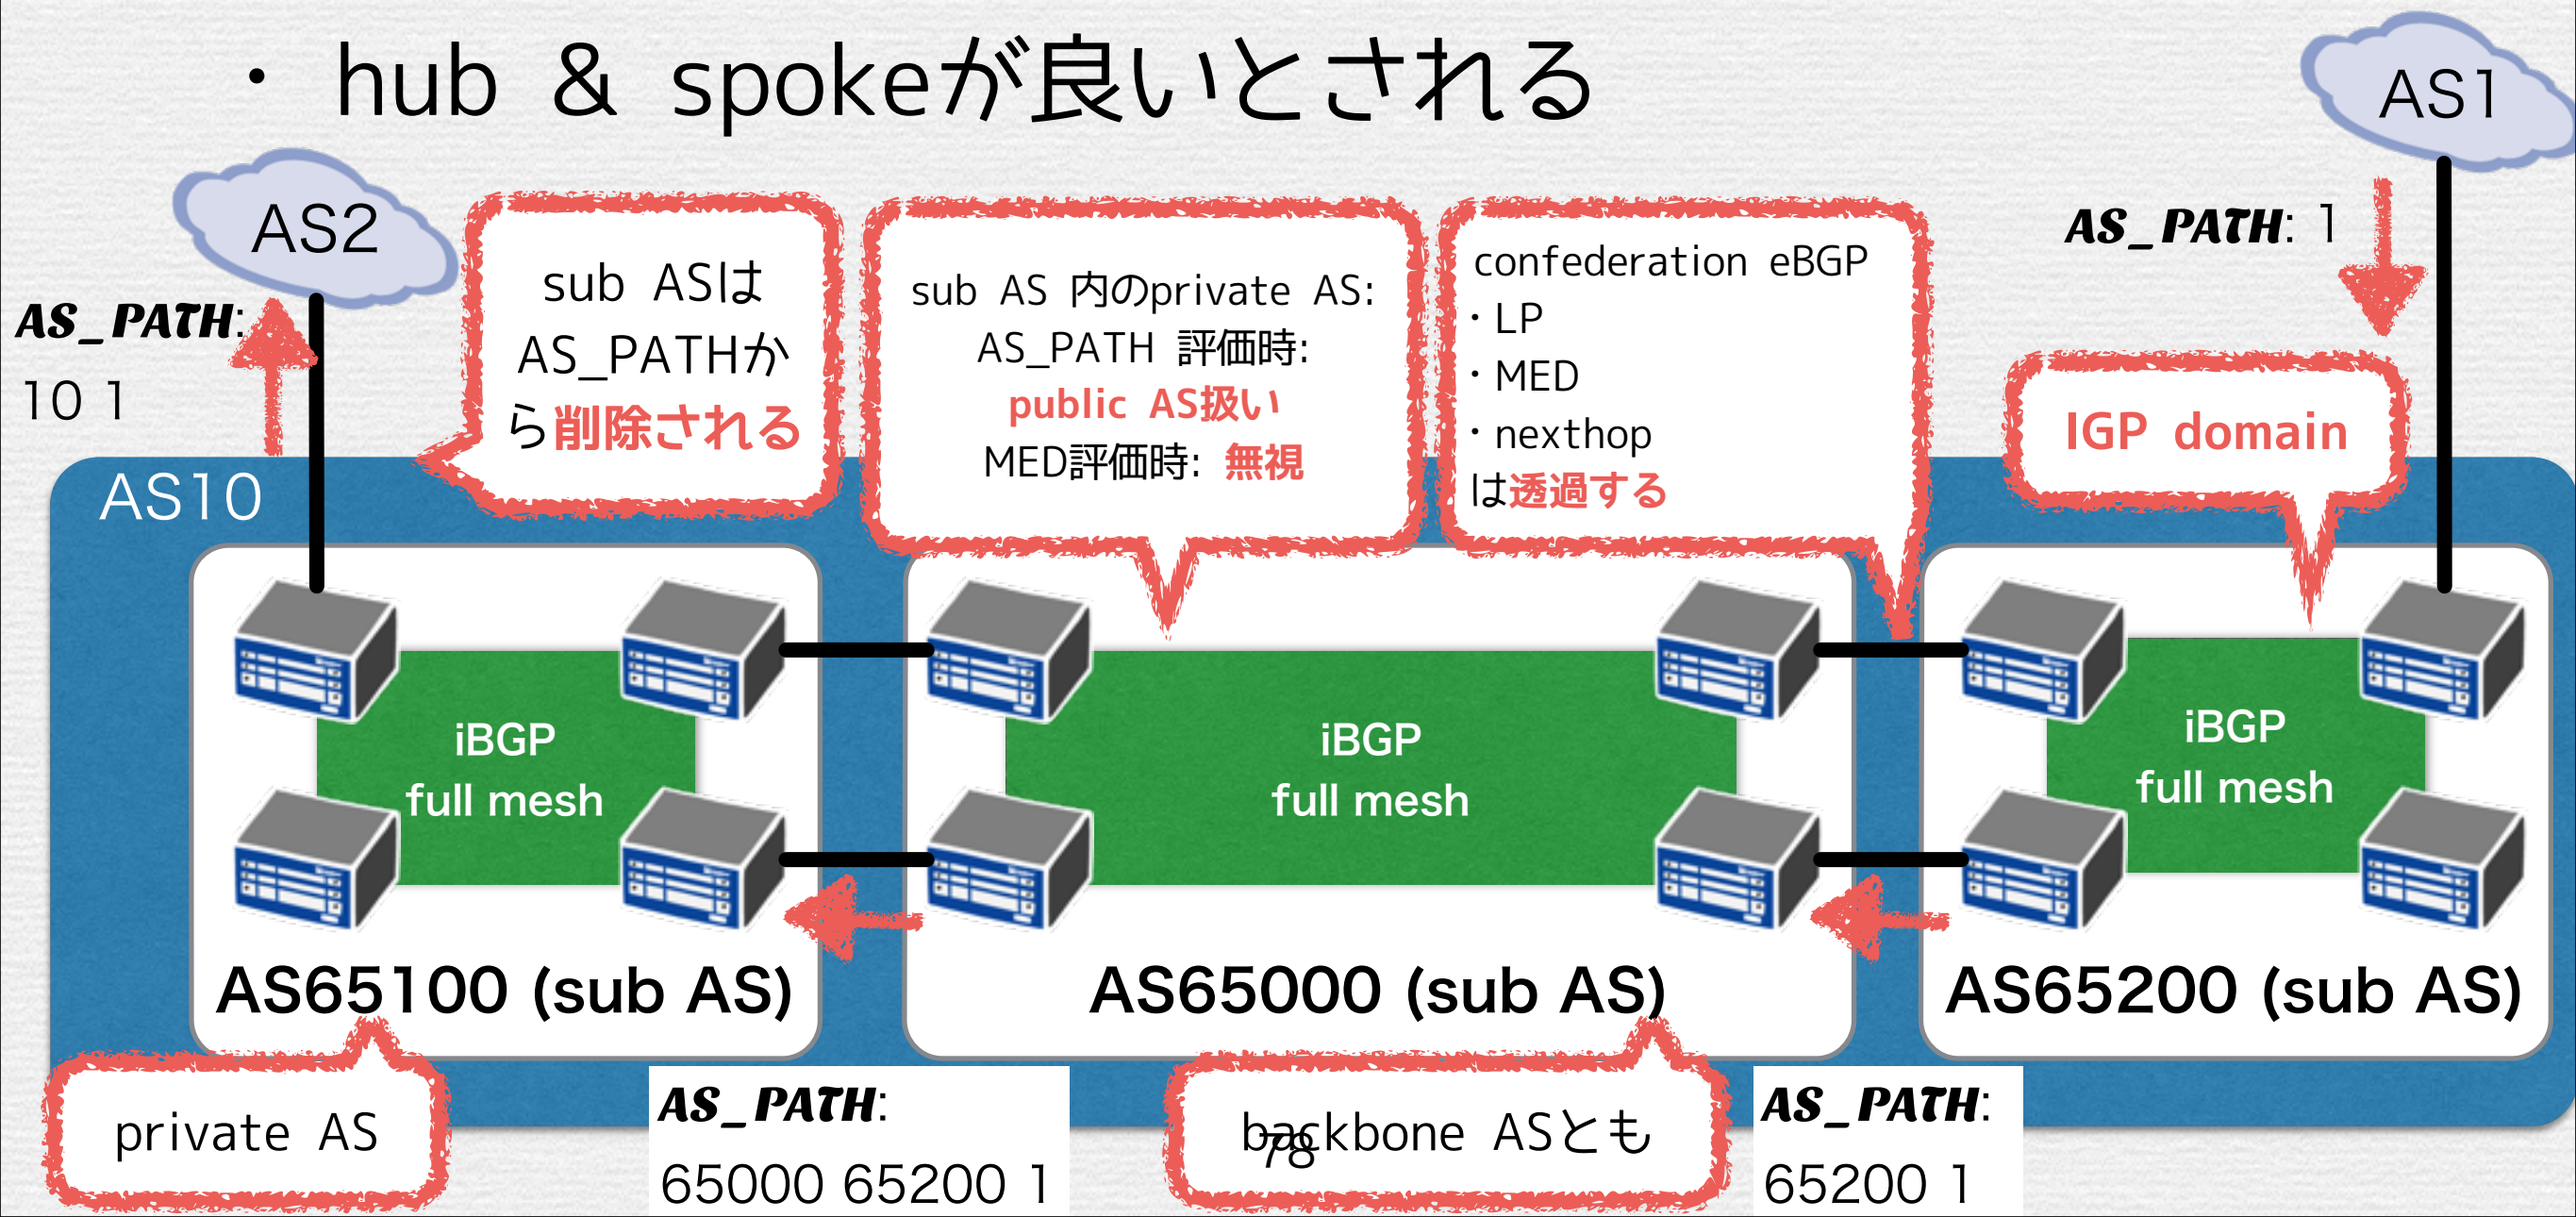

- 利点
  - IGP domainを分割できる
    - 大規模になると不安定になりがちなIGPへの対策
  - sub AS単位でBGP policyを分けられる
    - サービス別/国別/エリア別などで運営母体を分けるときにぴったりハマる
    - M&Aなどにより統合したnetworkを，1ASに移行するステップとして
- 欠点
  - sub ASの規模が大きくなるとiBGP session数 / それに伴う経路数が負荷になる
    - (bestではない)経路が多い ➔ route convergence timeが長い

sub ASが大きくなってきたら，sub AS内へのRR導入もOK
(BGP ConfederationとRRの併用)

BGP Confederation vs. RR

- BGP Confederation
  - BGP policyを分けたい
  - IGP domainを分けたい
  - iBGPによる細かい制御をしたい

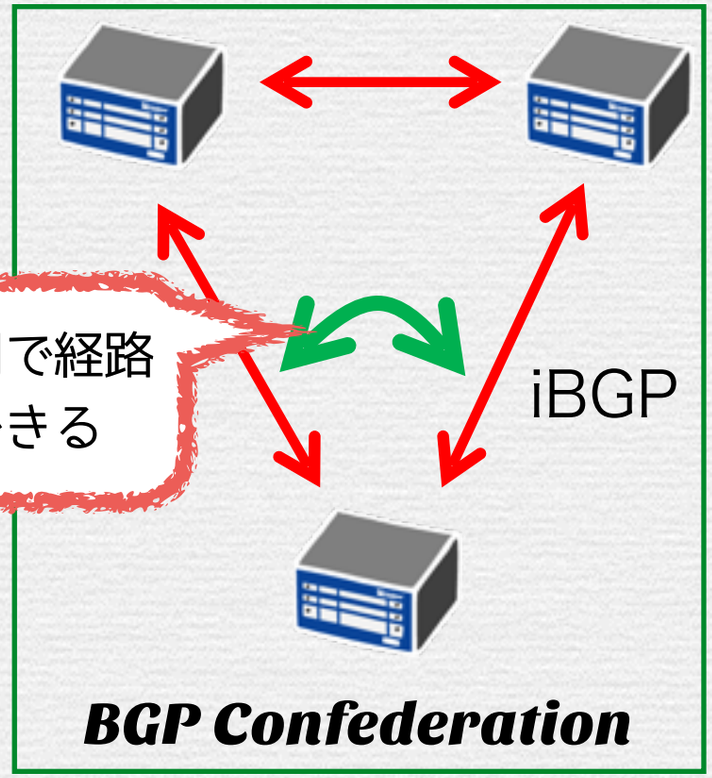

- RR
  - BGP policyを分けたくない
  - IGP domainを分けたくない
  - iBGPによる細かい制御をしたくない
    - iBGP sessionを減らしたい

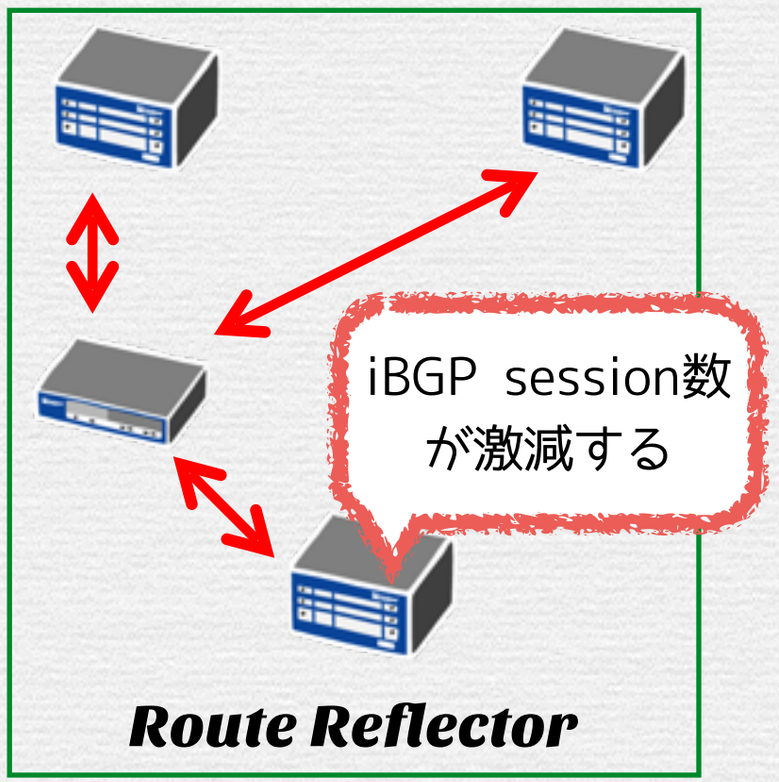

⚠ 意外と重要

next-hop self

- 自AS内のtrafficを細かく制御したい場合はnext-hop selfしないほうがいい
  - 経路制御のオプションを1つ失う
- したほうがいい場合もある（後述）

next-hopで区別して制御できない

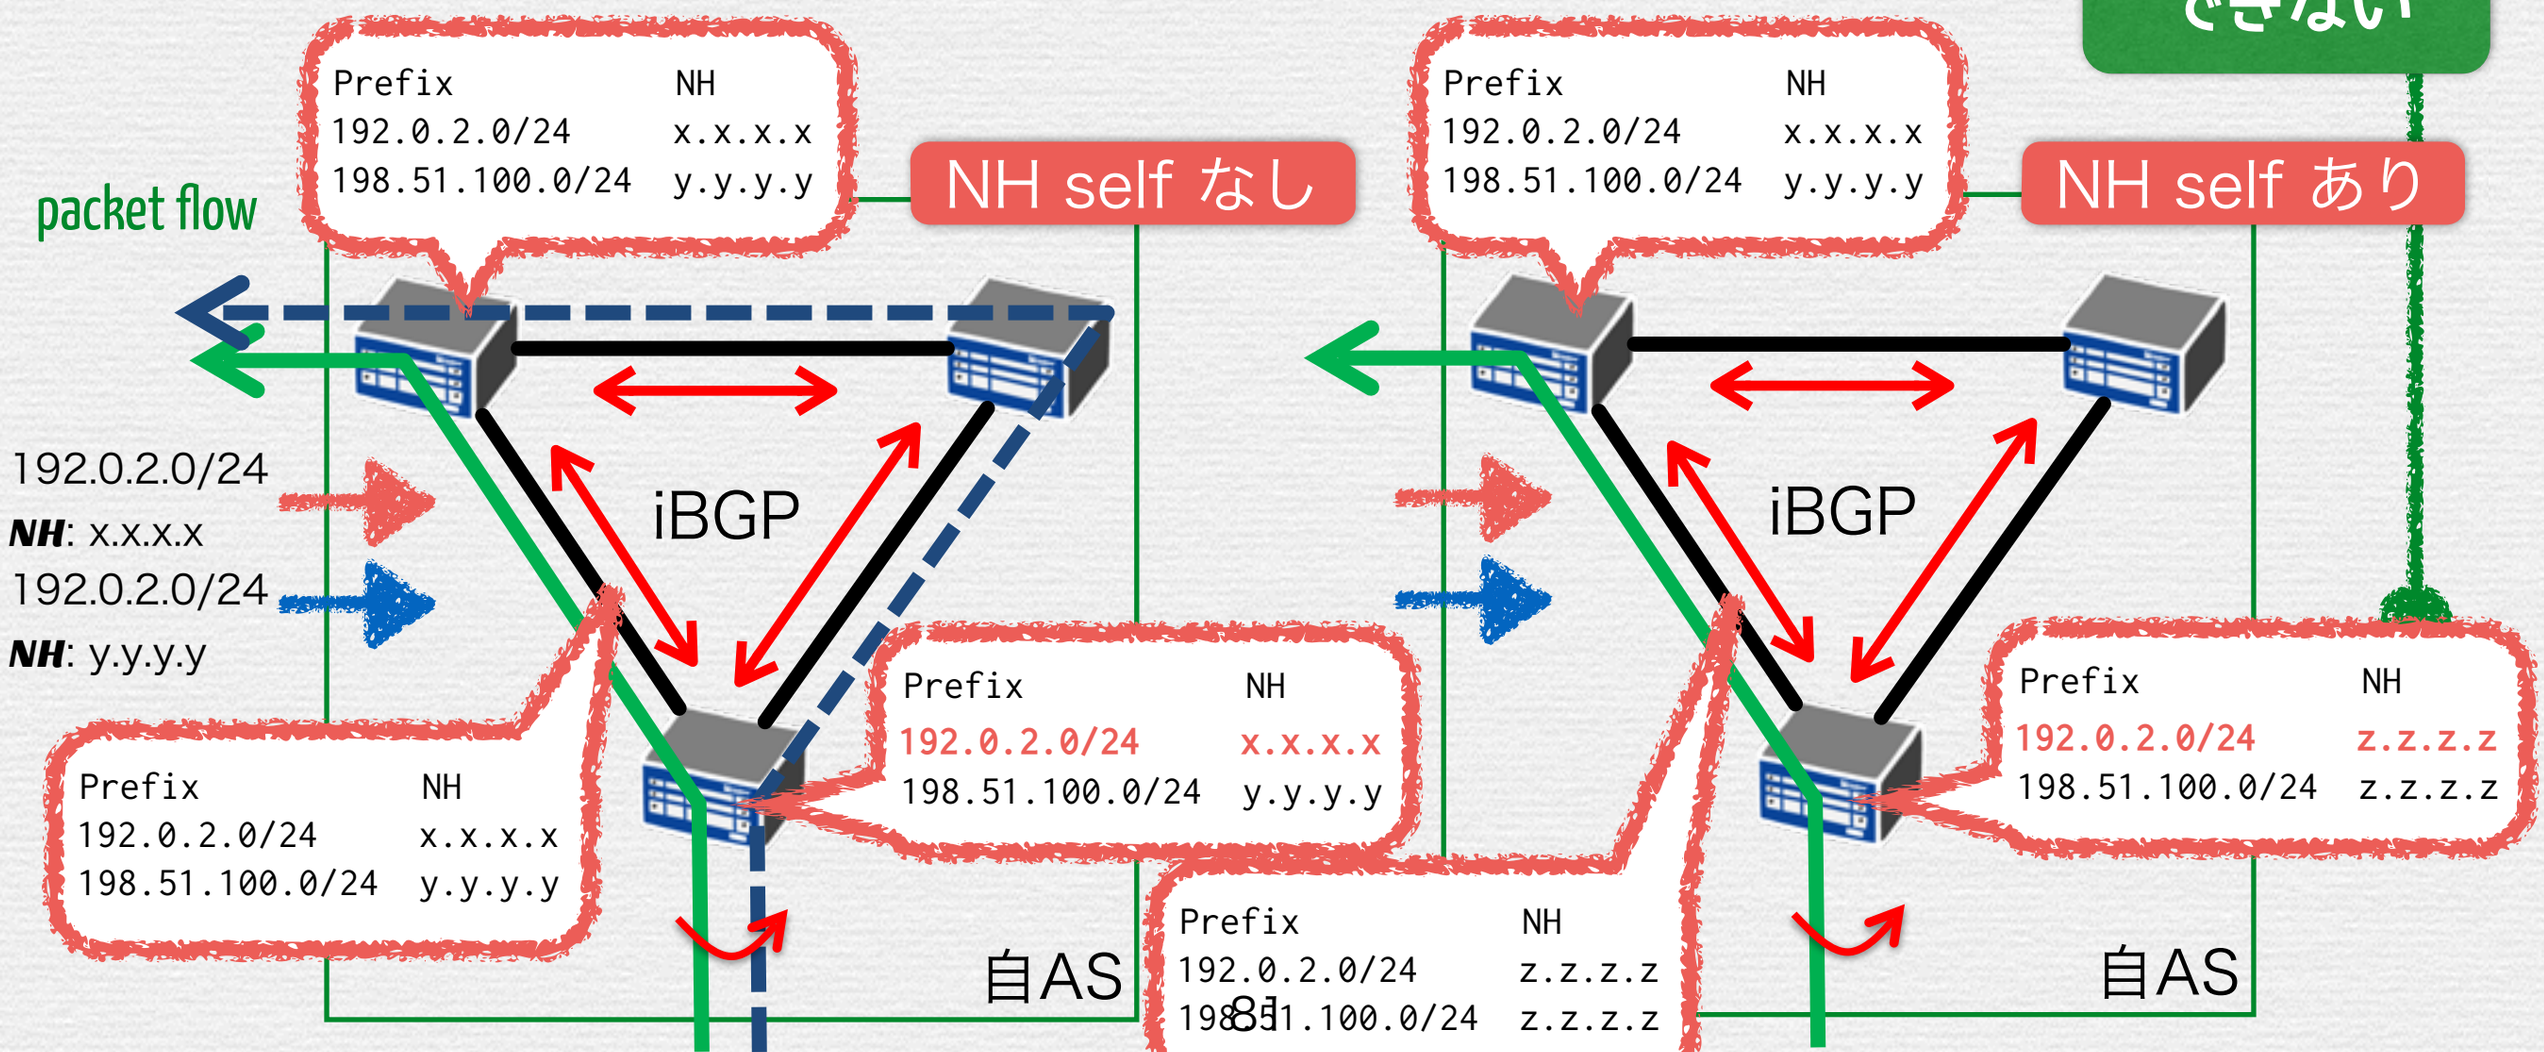

next-hop self したほうがいい場合

IX経由でもらった経路をiBGPに流すとき

http://www.janog.gr.jp/doc/janog-comment/jc1005.txt

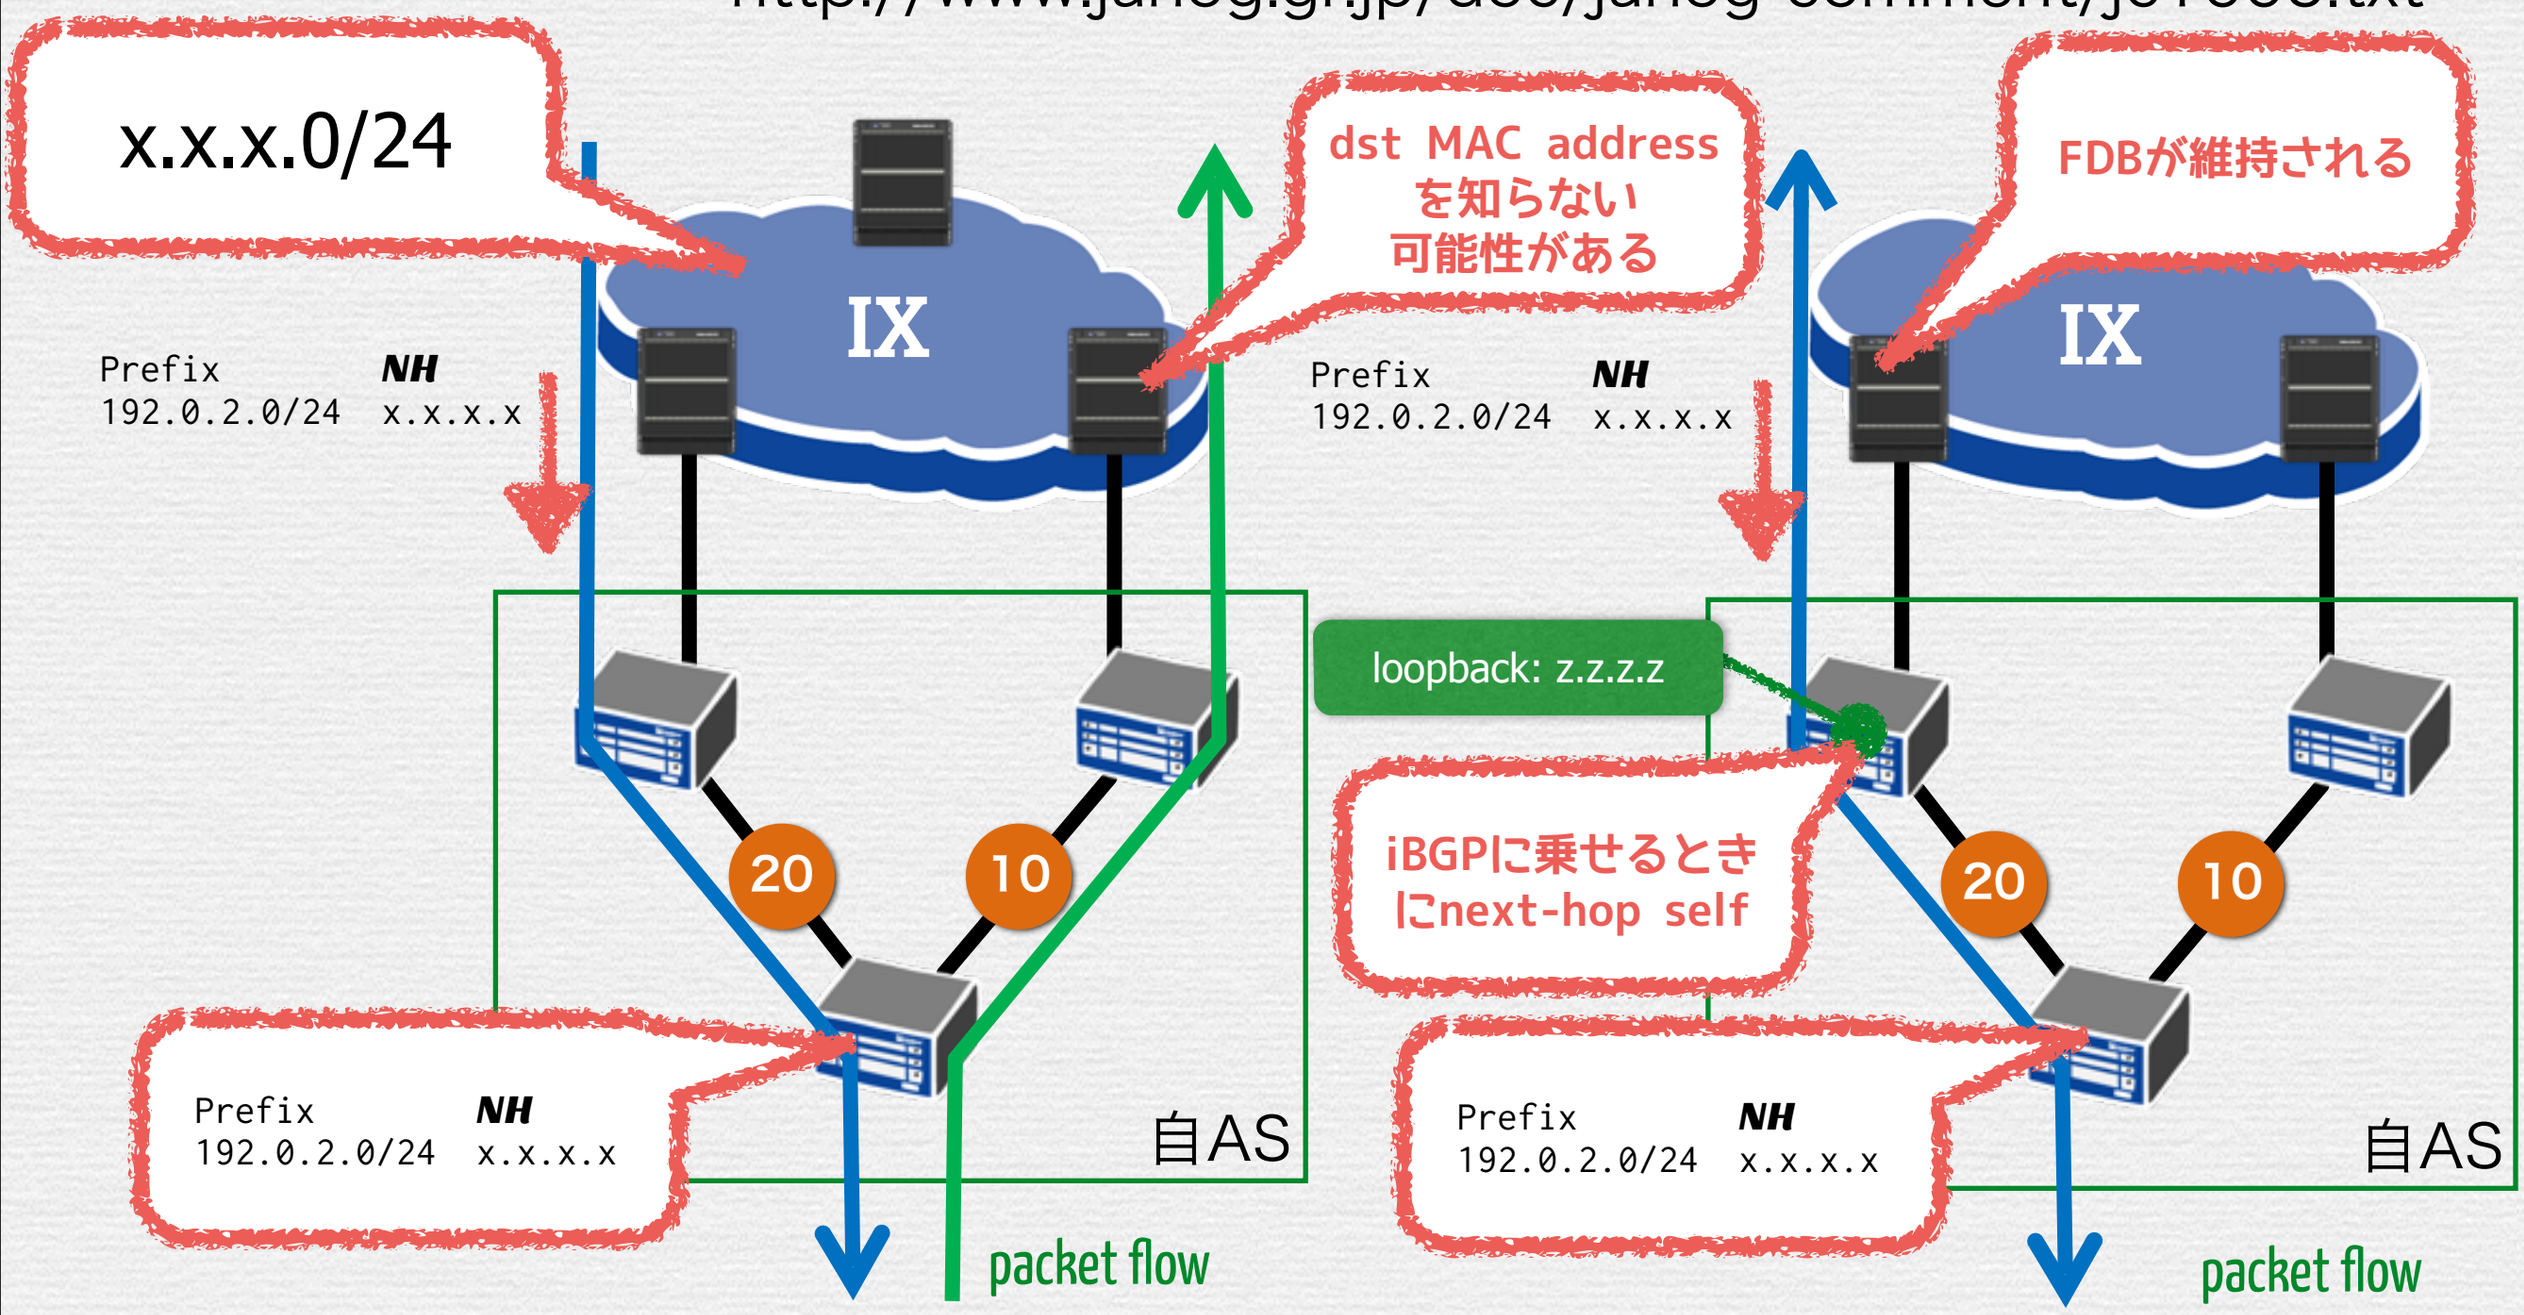

x.x.x.x(NH) に到達するのにIGP costが小さい方を選ぶ

next-hop self したほうがいい場合

IX経由でもらった経路を同じIX上の別のeBGPの流すとき

http://www.janog.gr.jp/doc/janog-comment/jc1005.txt

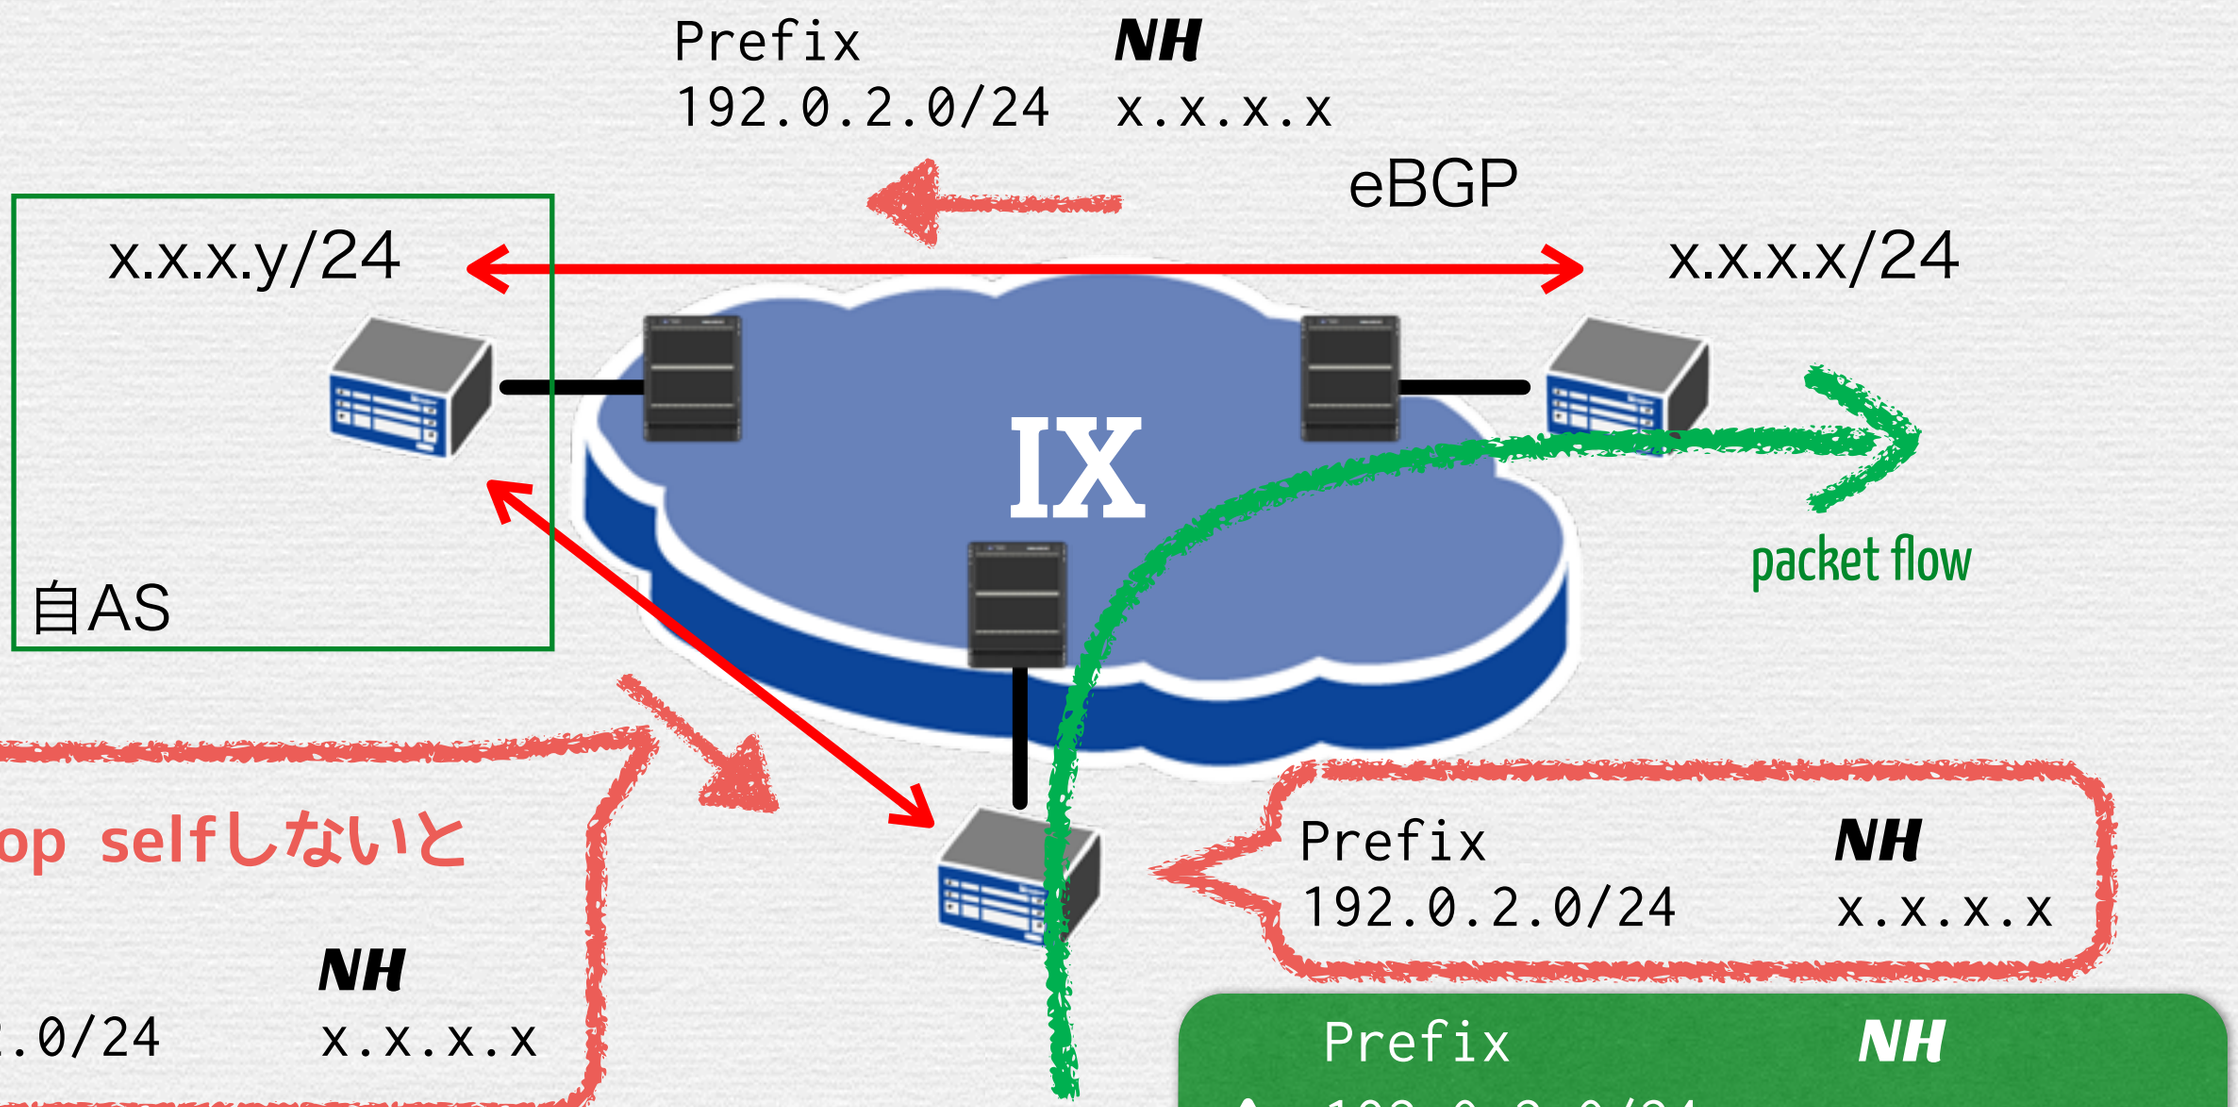

PA/PI AddressのOrigination

- 安定的にInternet上に**存在し続ける**必要がある
  - なくなると，自ASへの到達性が失われる恐れがある
- network上で最も安定している数台のrouterで
- Route Reflectorを使っている場合は，そこでoriginateするのがよさそう
  - 既存のcriticalなrouterで兼用する

BGPの運用を考えよう

- Traffic Engineering

- その他

Traffic Engineering

問題: 直接peerしているのに trafficが流れてこない

1. AS_PATH的には近いのに，別のpeerからtrafficが入ってくる
   - 図のようなケースで AS1内のroutingを変えることは困難
2. peerではなく，transitからtrafficが入ってくる
   - こちらはなんとかなるかも

(*) 理由として
- public peer(IX 経由)など
- このpeerが輻輳している

場合に, このようなことが起こり得る

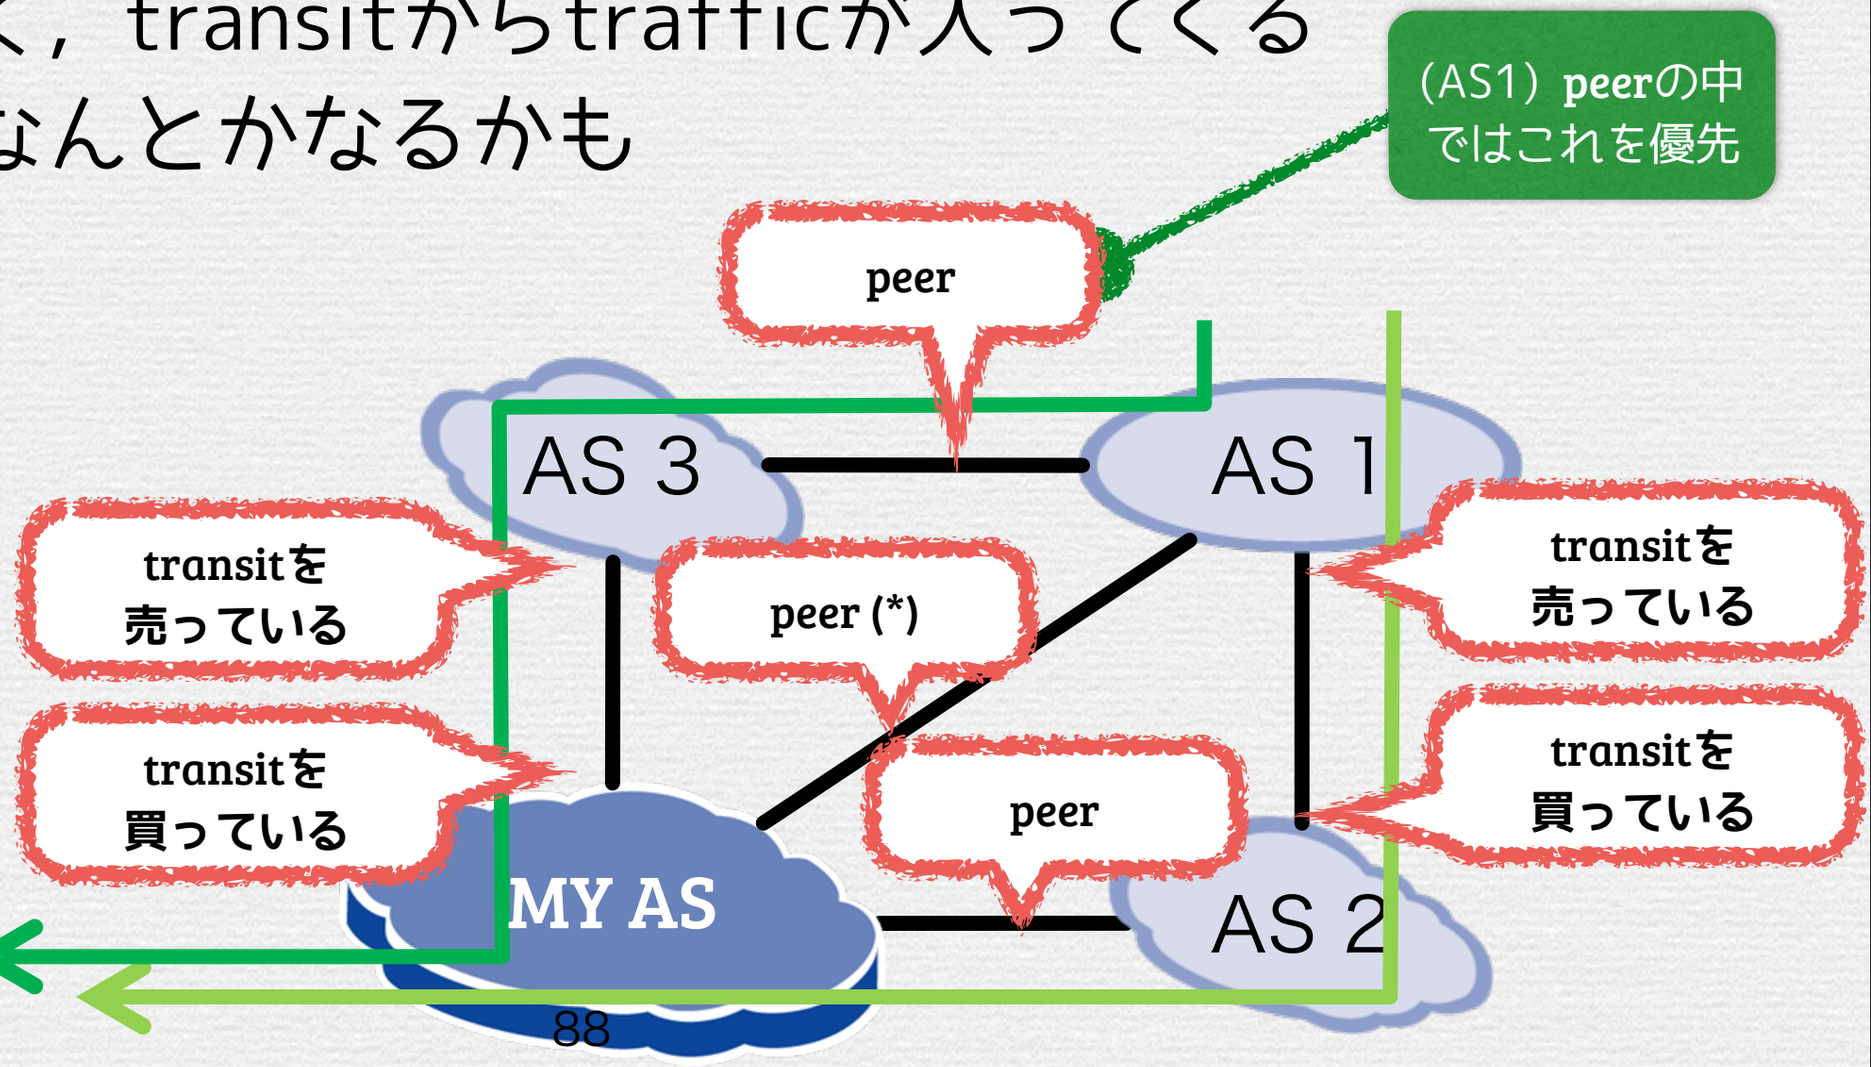

TE案：直接peerしているのに trafficが流れてこない

○ AS1にメールする（またはAS3にメールする）

✖ AS3への経路広告を操作する ➔ transit全体に影響するので，基本的には良くない

○(もし提供していれば）AS3のBGP communityを使い，AS1に対して経路を止める

△ AS1への経路広告をmore specificに

- AS3 ➔ MY AS へのtrafficなど，対象外のtrafficも引き込んでしまう
- no-exportをつければOK

(もしAS1 が提供していれば)ダメもとでAS1のBGP communityを付与してAS3に経路広告してみるのも一手

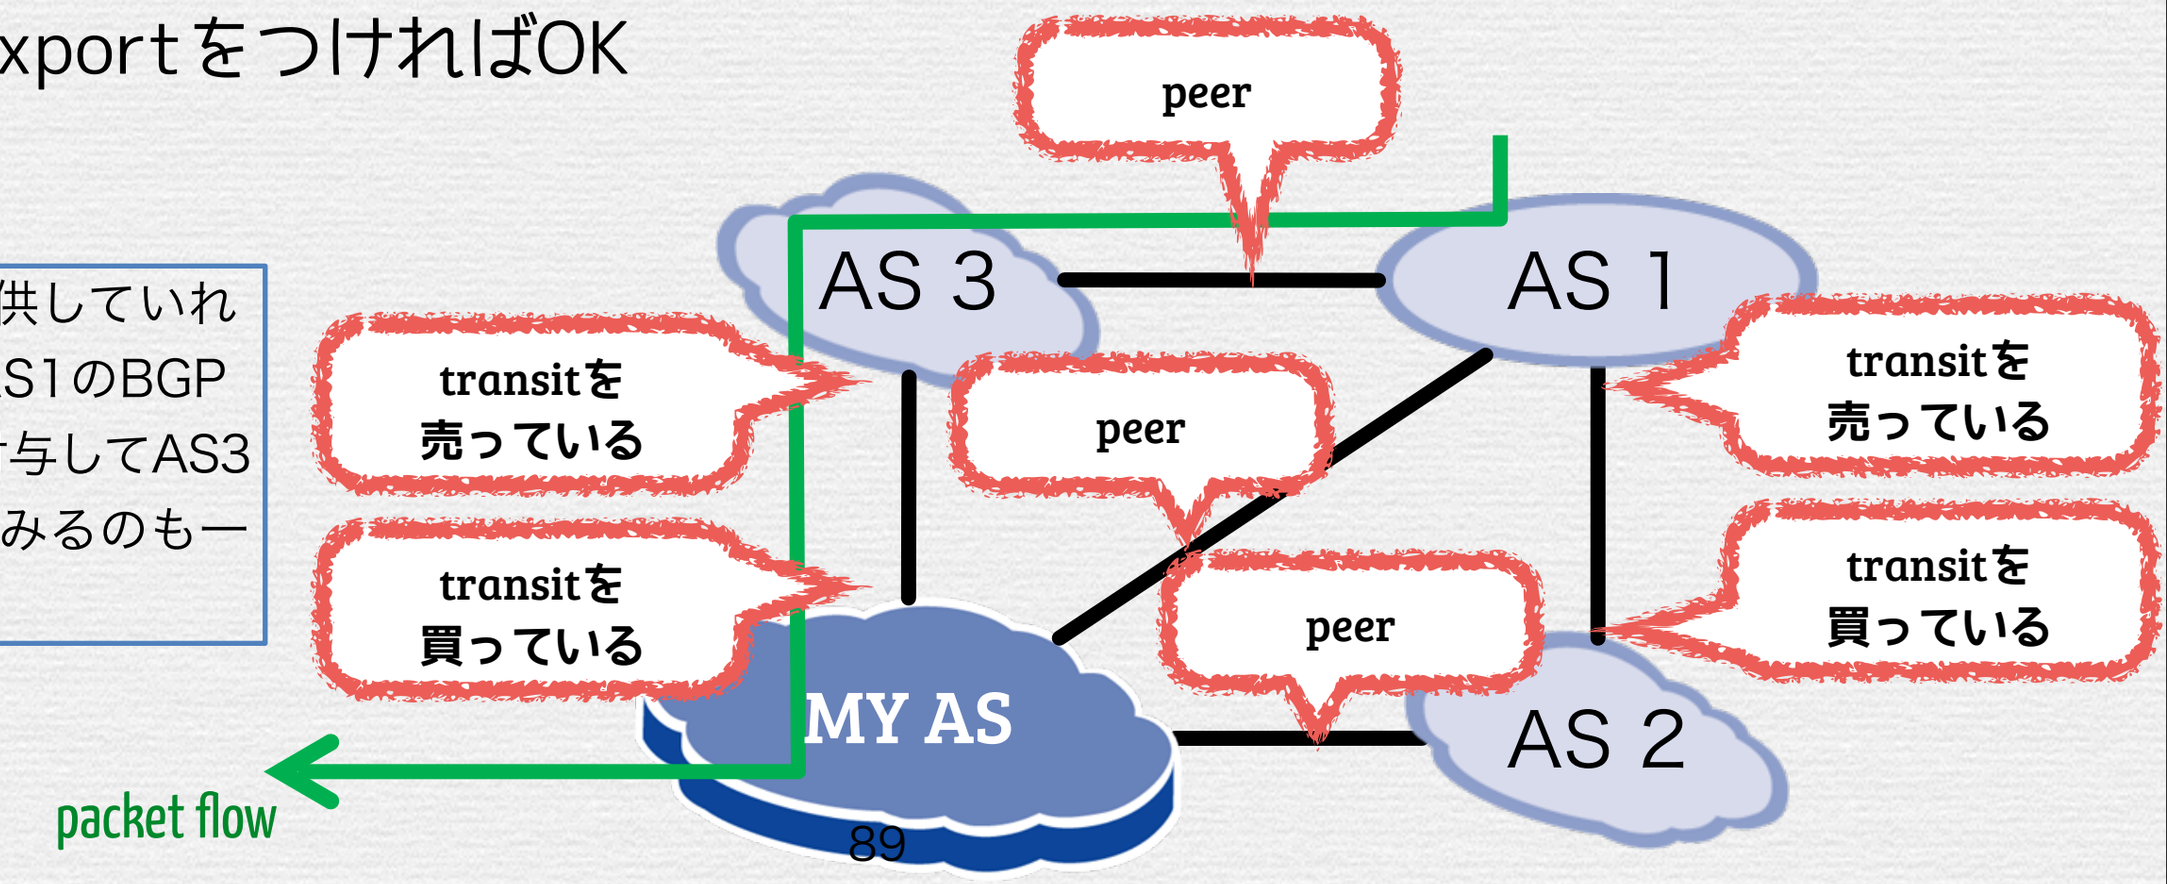

問題: transit間で trafficを動かしたい

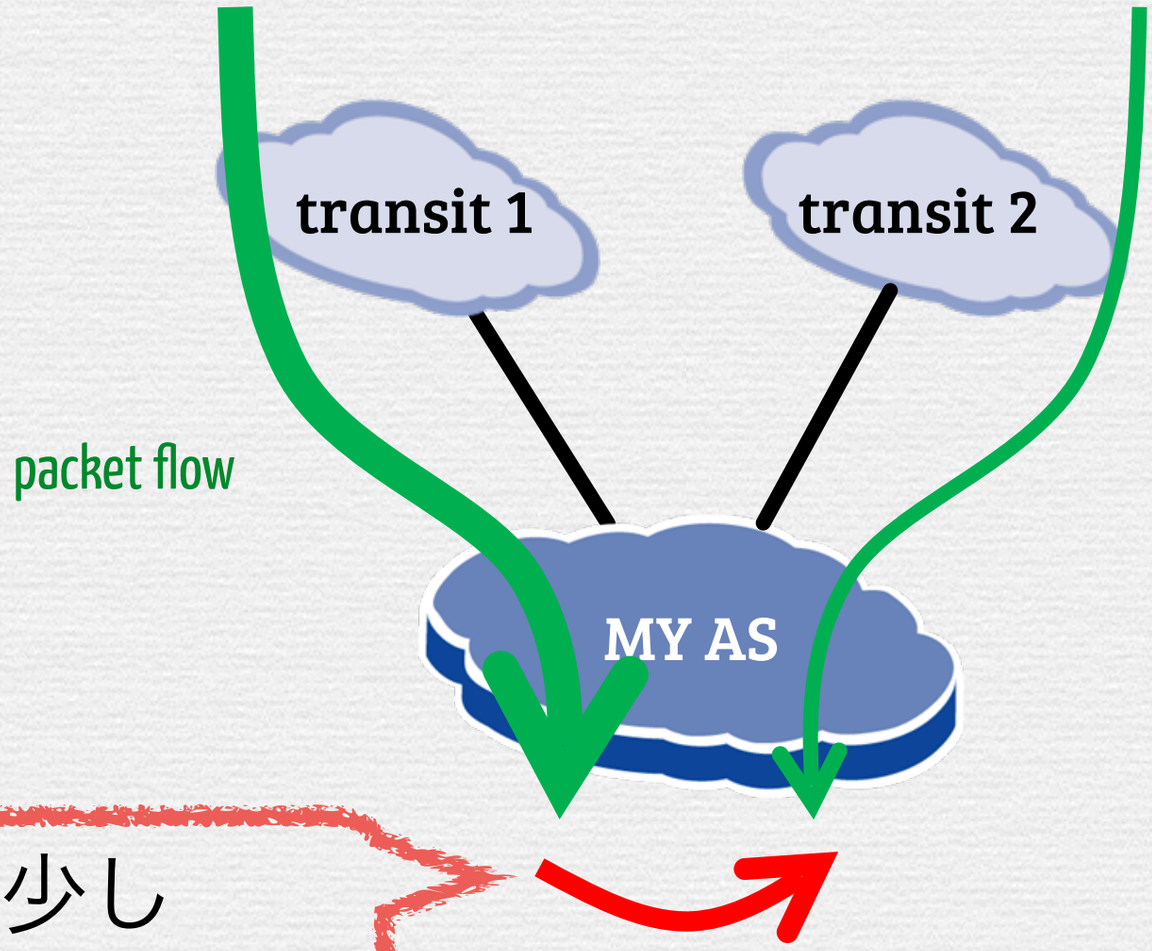

TE案：transit間で trafficを動かしたい

○ (特定ASからのtrafficが大きい場合) 直接peerする

○ transit 1への経路広告時にAS_PATH prepend

- 経験的にいくつもprependしても効果は薄い
  - 経験的には限界は+3程度．+3 prependして効果がなければ，増やしてもたぶん同じ

○ (もし提供していれば) transit 1のBGP communityを使い，transit 1内でのLPを下げる

△ 丁度いいvolumeの経路について，

- transit 2への広告をmore specificに
- transit 1への経路広告を止める

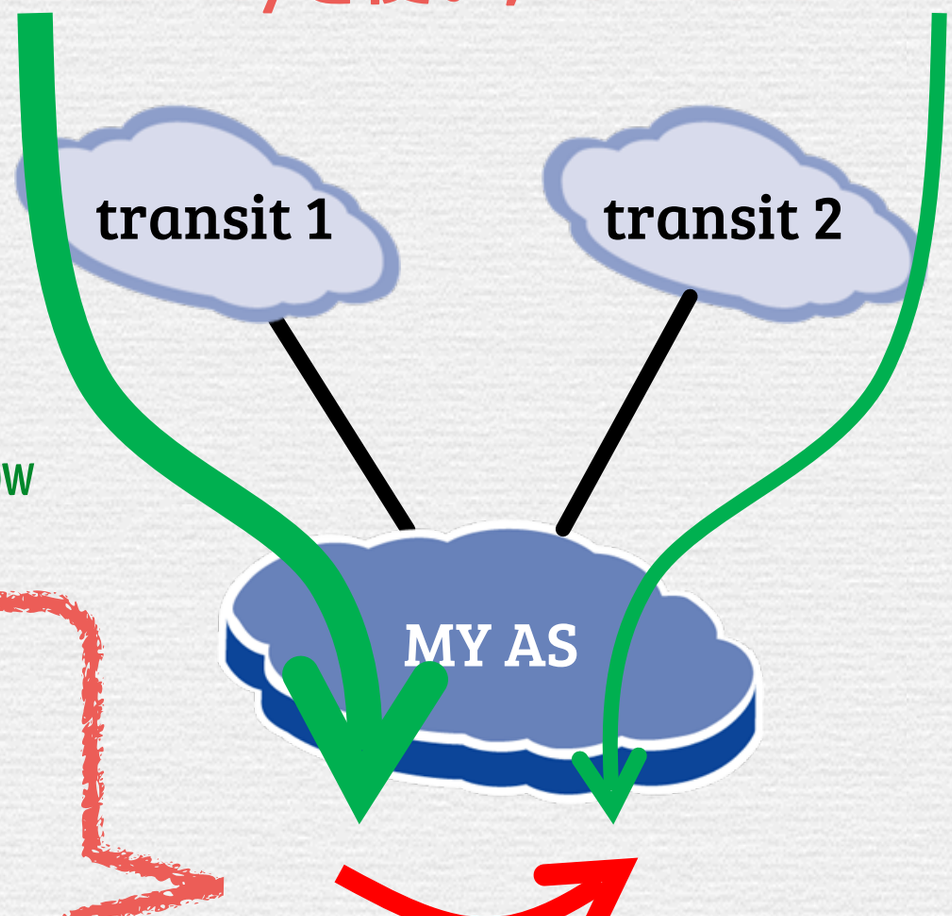

補足：transit間で trafficを動かしたい

- transit costを削減するため，ISPは日々制御している
  - 同じ量のtrafficを流すためのコストを最小化する
  - 例えば，まず **transit 1への経路広告時にAS_PATH prepend → transit 1のBGP communityを使い，transit 1内でのLPを下げる** など
- transitの選択は，コスト/品質以外にも決定要素がある
  - ビジネス上のバーター
  - 資本関係

問題: peer間でtrafficを動かしたい

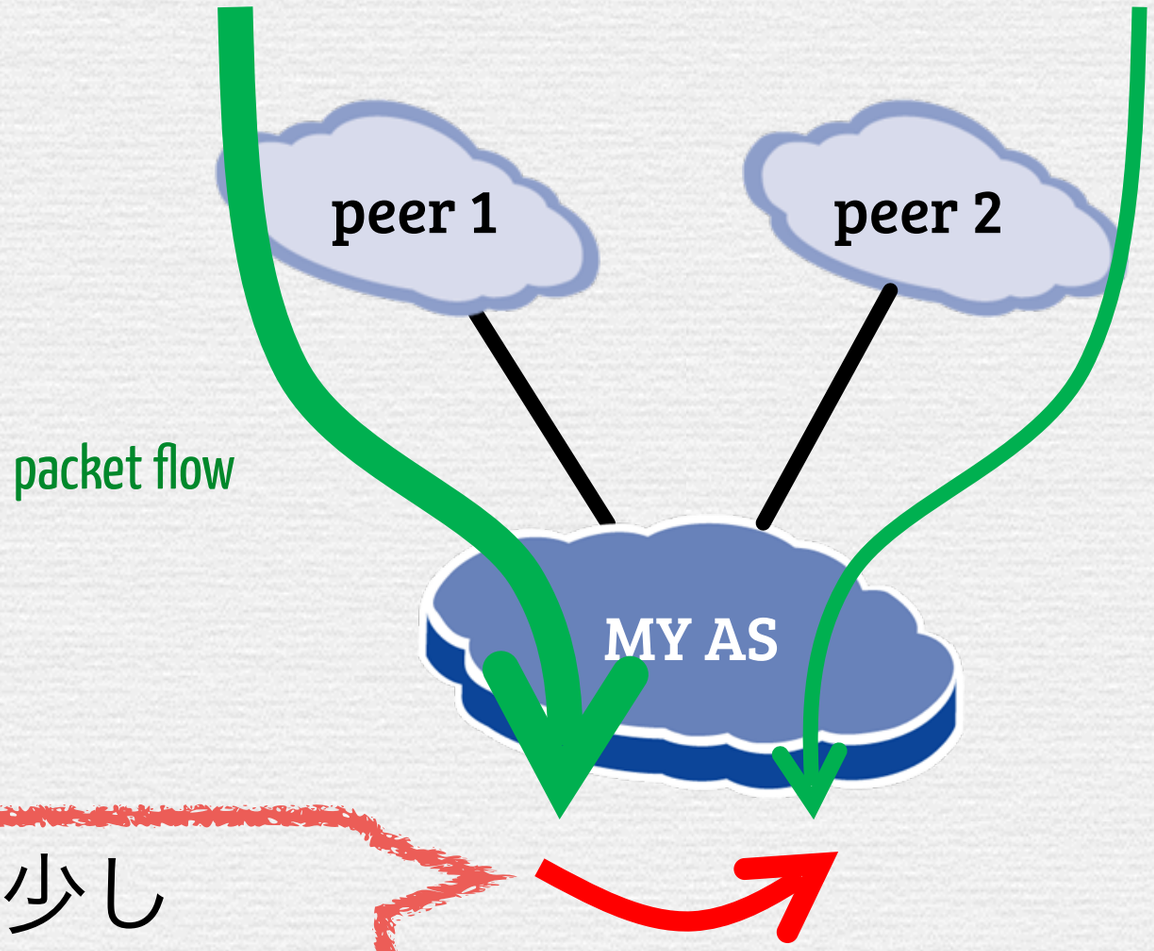

TE案：peer間でtrafficを動かしたい

○ peer 1への経路広告時にAS_PATH prepend

- 経験的にいくつもprependしても効果は薄い
  - 経験的には限界は+3程度．+3 prependして効果がなければ，増やしてもたぶん同じ

○（もしpeer1と複数peerしているなら）trafficをどけたいpeer 1とのeBGP sessionでのみ特定の経路広告を止める

△ 丁度いいvolume の経路について，
- peer 2への広告をmore specificに
- peer 1への経路広告を止める

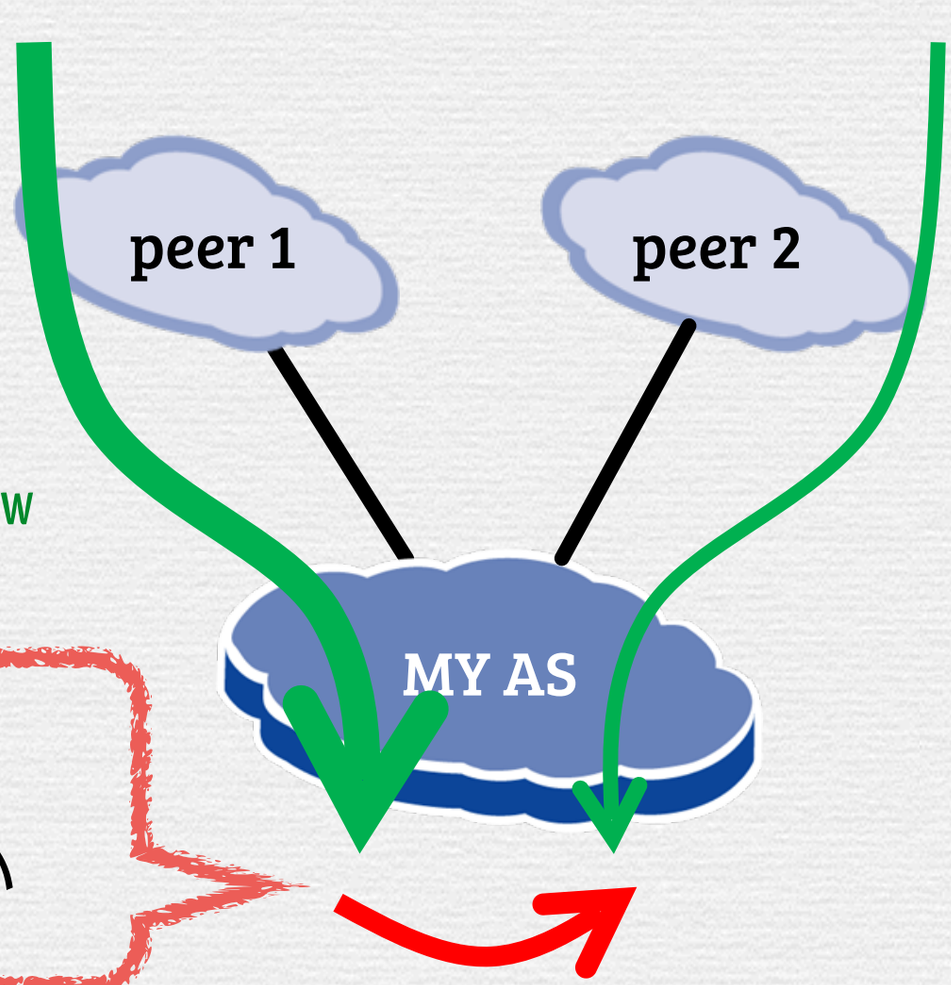

peer 1，peer 2 のASNが違うので，MED操作が効かない !!

補足：peer間でtrafficを動かしたい

- peer間でTEしたい理由
  - 品質が悪いから
  - 時間帯により輻輳する
  - latencyが大きい
- paid peerだから
- なぜかは分からないが顧客に依頼されたから

問題：自AS網内の traffic balanceを変えたい

- R1-R2 linkとR1-R3 linkのbalanceがよくないので，少しtrafficを移したい

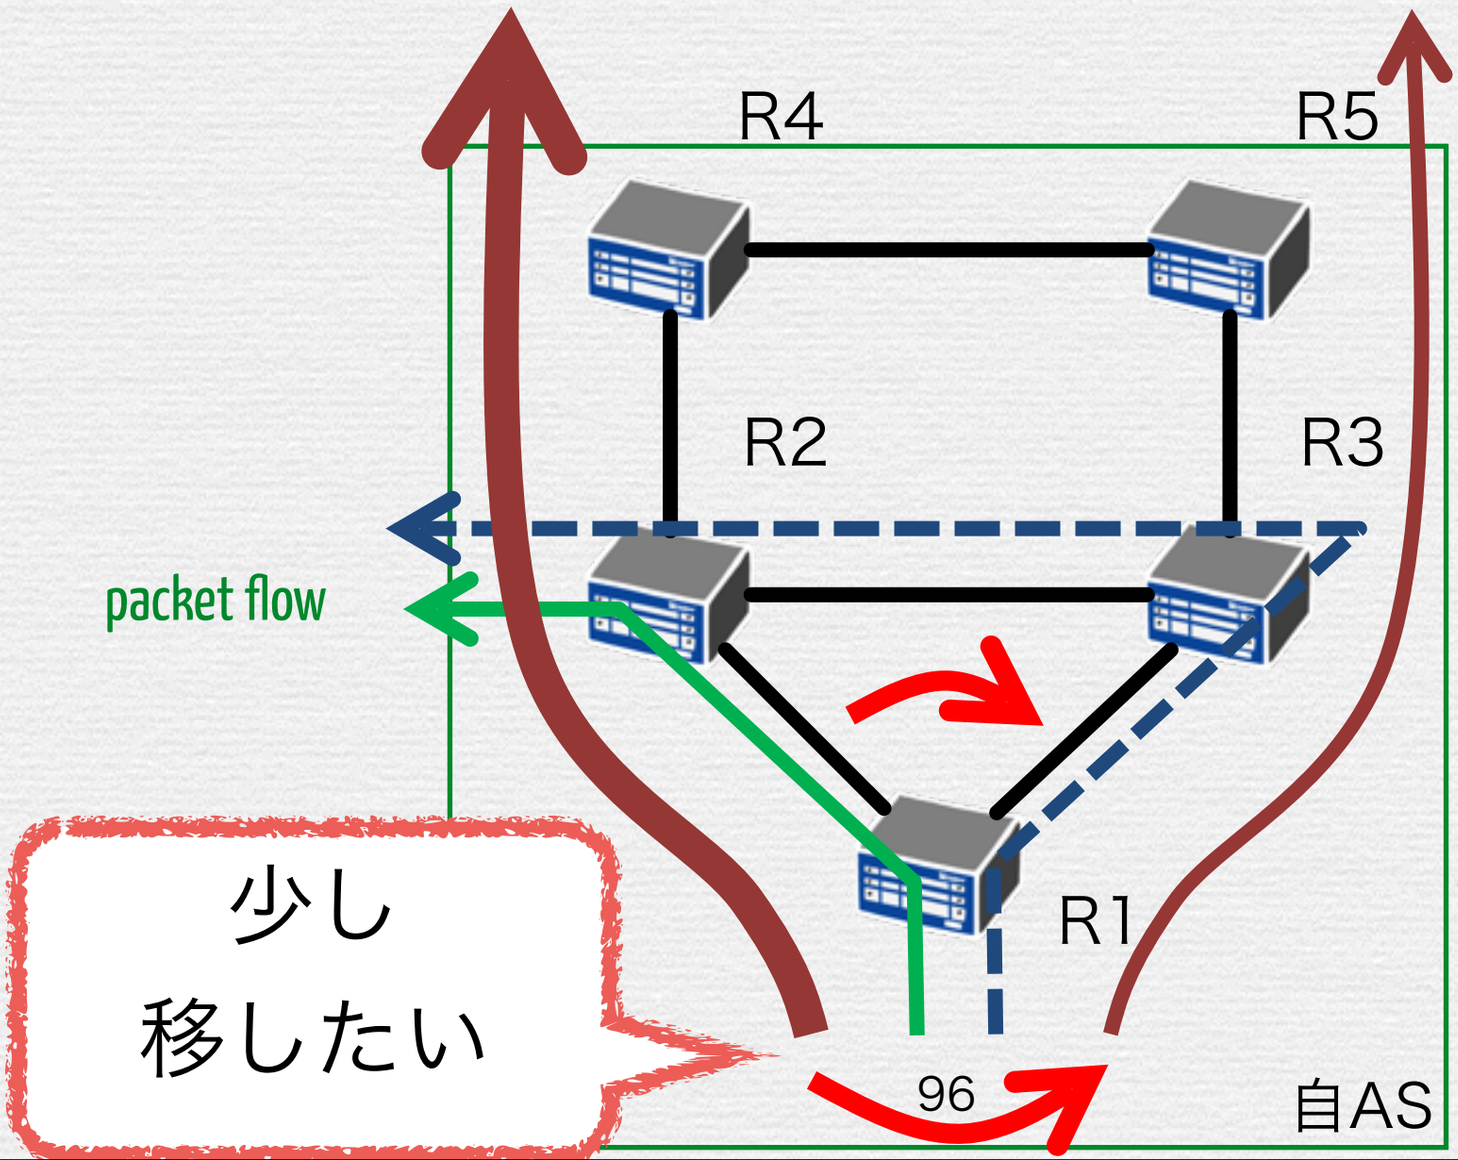

TE案: 自AS網内の traffic balanceを変えたい

- まず R4から出るtrafficの一部をR5に移せないか考える
  - R4，R5両方でpeerしていて，顧客ではないASがあれば，R4での経路受信時に特定経路について
    - ✖ LP を下げる（制御が強すぎる – AS_PATHが効かなくなる）
    - △ AS_PATH prepend（制御がまだ少々強い．自AS内全域に影響を与える *1)
    - **〇 MED を追加する（LP 操作は制御が強い *2)**
    - **〇(MED を制御に使えない場合 *3)**
      passive IGP costを付ける
      (そのBGP session全体に影響し，topologyによっては劇的に変化するので注意)

(*1) AS_PATHはtransitiveであり(MED はnon-transitive)，万が一prepend した経路がbestになると，外部には弱い経路が伝わってしまう．

(*2) MEDは，一般的にAS_PATHより頻繁に変更されることが多く，このような操作に使いやすい．また，別の箇所で追加したMEDを減らす(キャンセル) することも可能．

(*3) peer経路のMEDを2^32-1 で上書きしている場合など

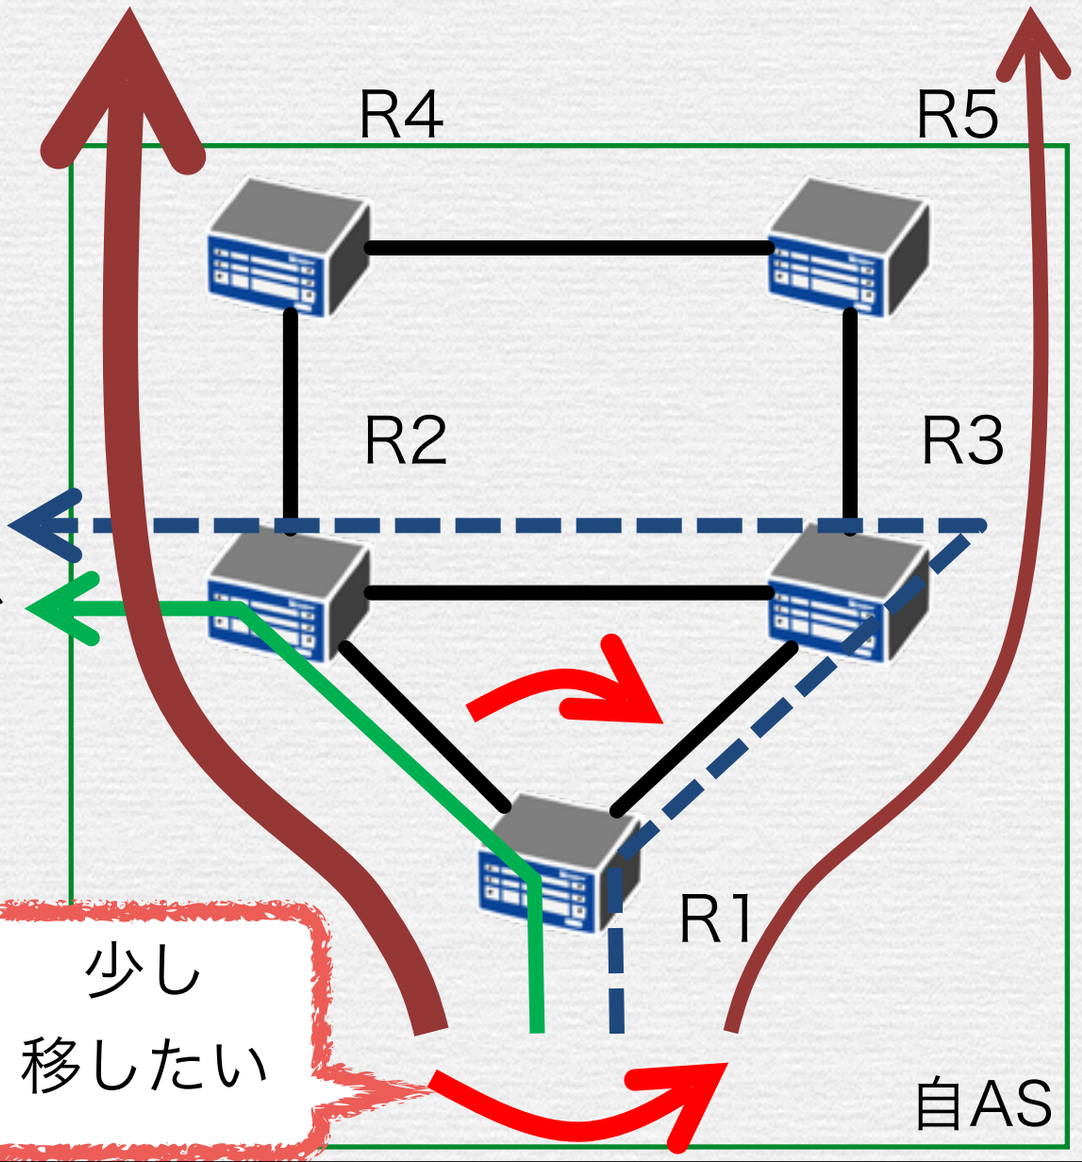

~~まず R4から出るtrafficの一部をR5に移せないか考える~~
ちょうどいい移動対象trafficがなかったら

○ R1 → R2 → R4 trafficをR1 → R3 → R5 → R4 にできないか考える

・ R2-R4のIGP costを上げる（影響範囲が大きいので注意）

○ R1 → R2 traffic をR1 → R3 → R2 にできないか考える

・ (R2が持っているeBGP sessionのうち，session単位のtraffic合計で丁度いいものがあれば)
next-hopになっているconnected prefix(ipv4なら/30など) へのstatic経路をR1でR3向けに設定する.

(iBGPでnext-hop selfしていない場合に限る.また構成によってはrouting loopが起きる可能性があるので注意)

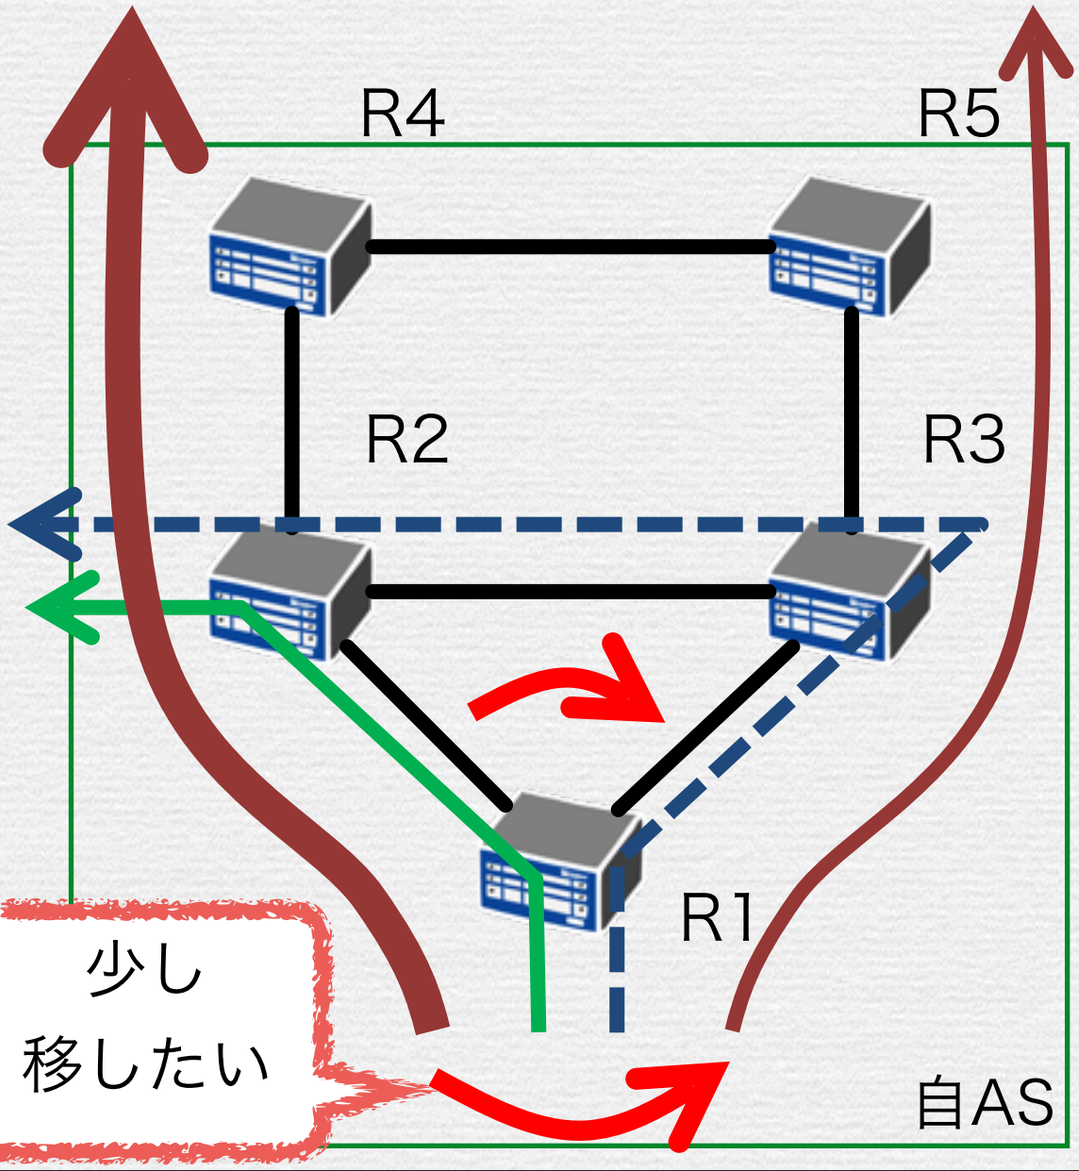

△ 物理的な変更を伴うアイデア

- R3-R4(R2-R5 も）にlinkを追加
  - R1-R3-R4 / R1-R2-R4 でECMPを効かす
    - R1➔R2➔R4 trafficの半分がR1➔R3➔R4 に移る
- 収容を変える（R4 ➔ R5）

△ その他

- R4，R5が同じIXに接続しているなら
- iBGP のnext-hop self をやめる
  - R1➔R2➔R4,
    R1➔R3➔R5がバランス

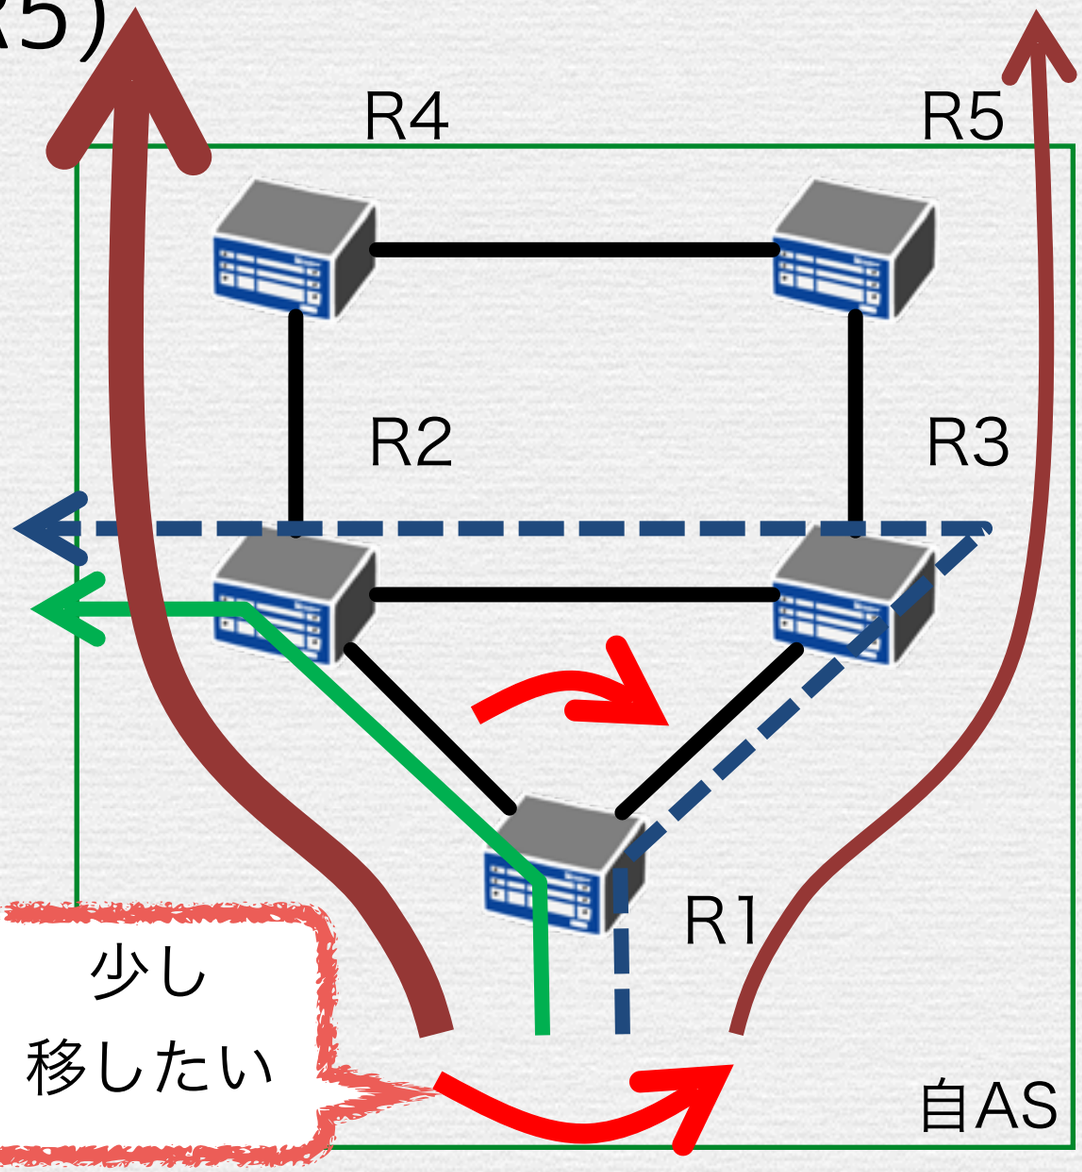

peer間などでよくある traffic移動

- 戻すのは困難

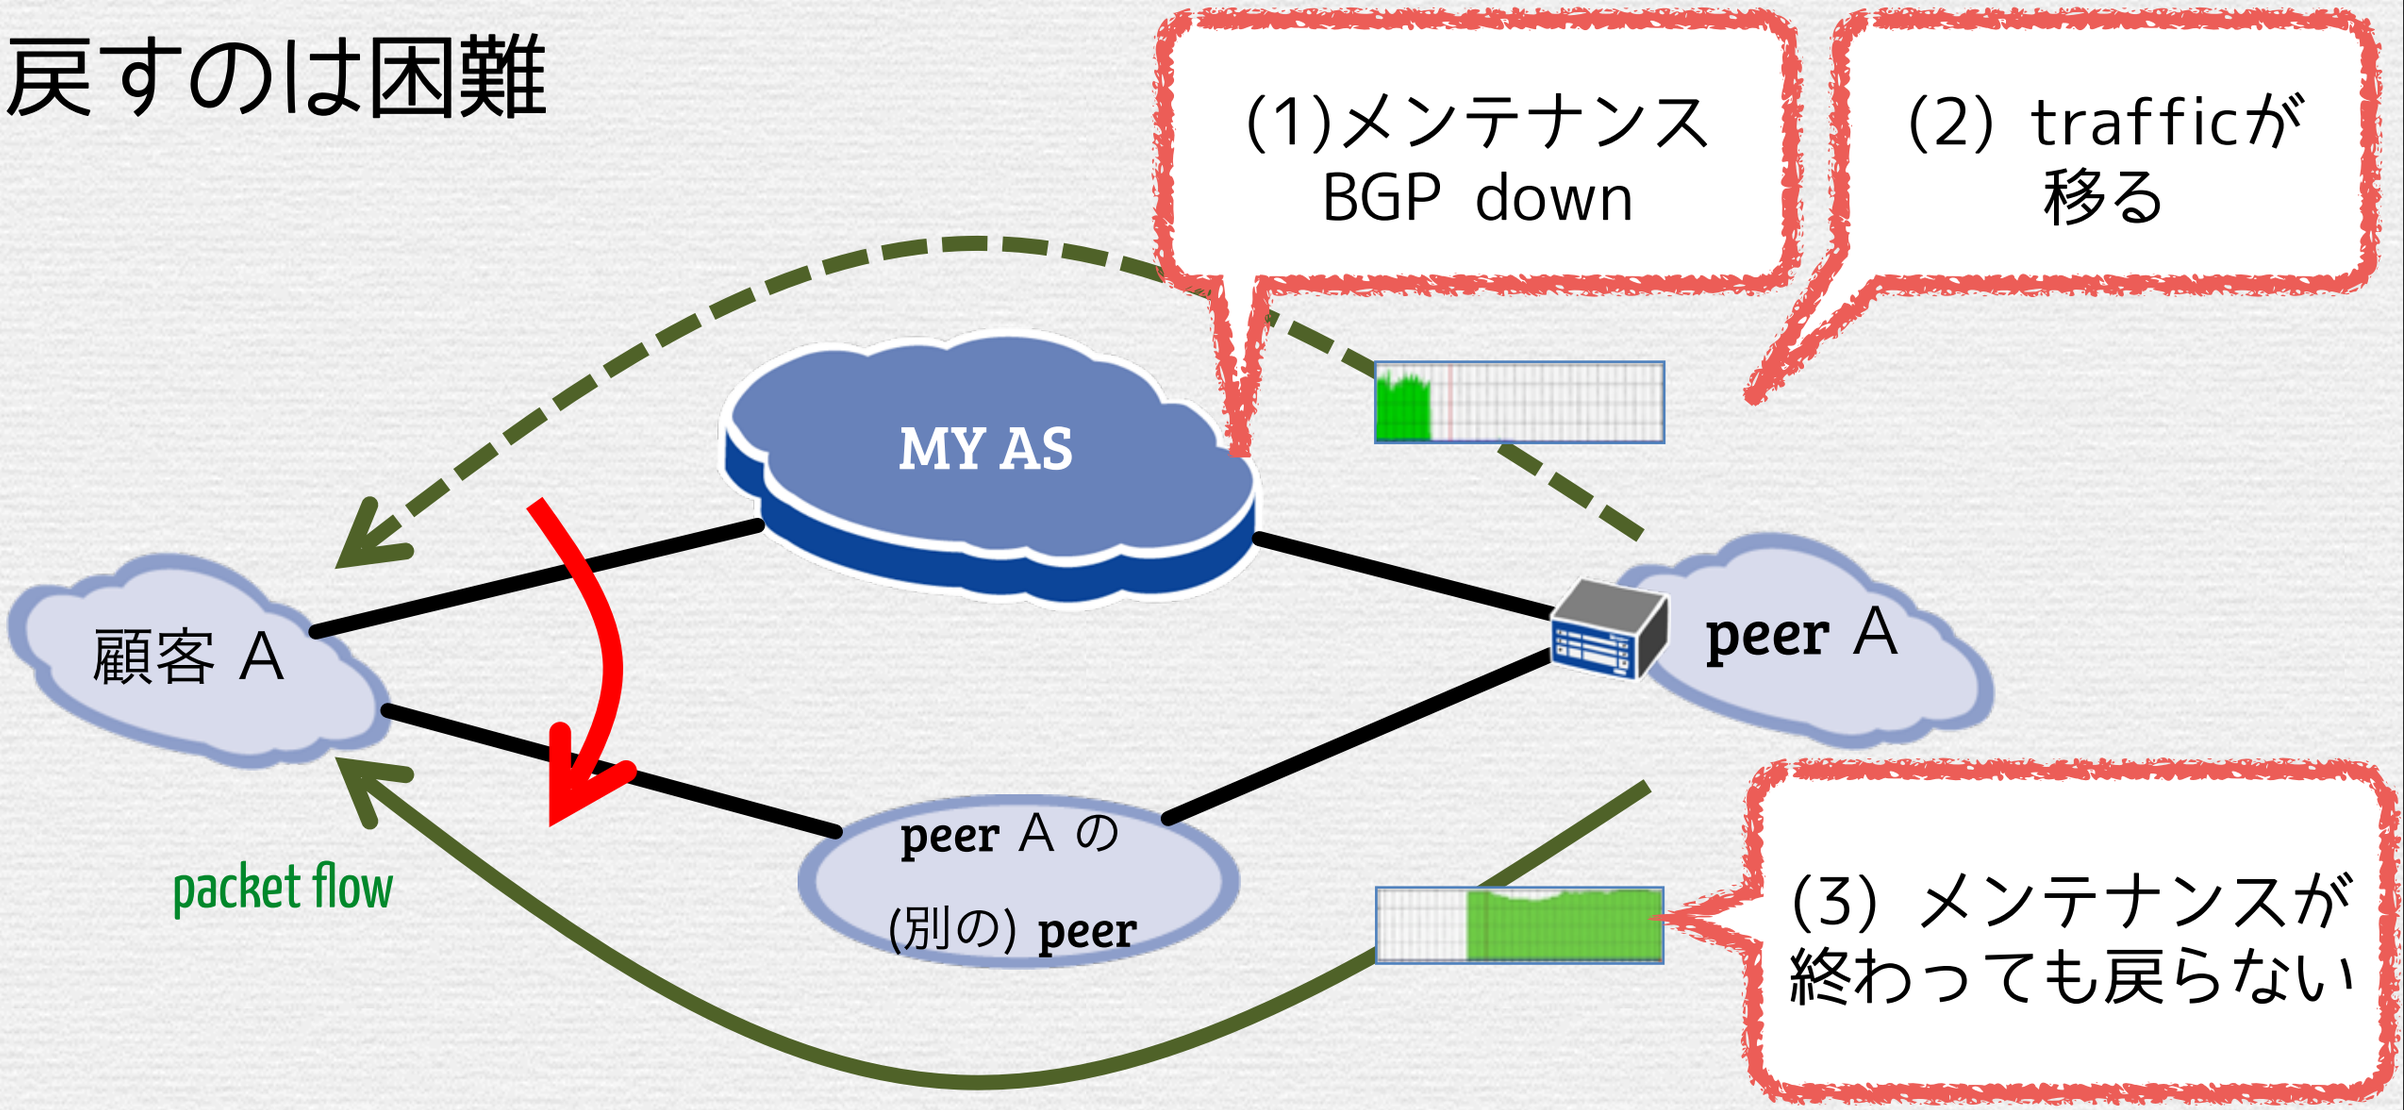

- eBGP間のbest path selectionはrouter IDではなく“経路の生存期間”で決定する場合が多い

MPLS-TE

- 自AS網内のtraffic balanceを自動で制御する技術
  - 空き帯域を自動で探し，そこへrouting
  - QoSも可能
- MPLS(Multi-Protocol Label Switching) + RSVP(ReSerVation Protocol)
- IP Packetにlabelをつけてカプセル化
  - 仮想的なトンネル(LSP: Label Switching Path)をつくる

trafficのend-pointは変わらず，rerouteする

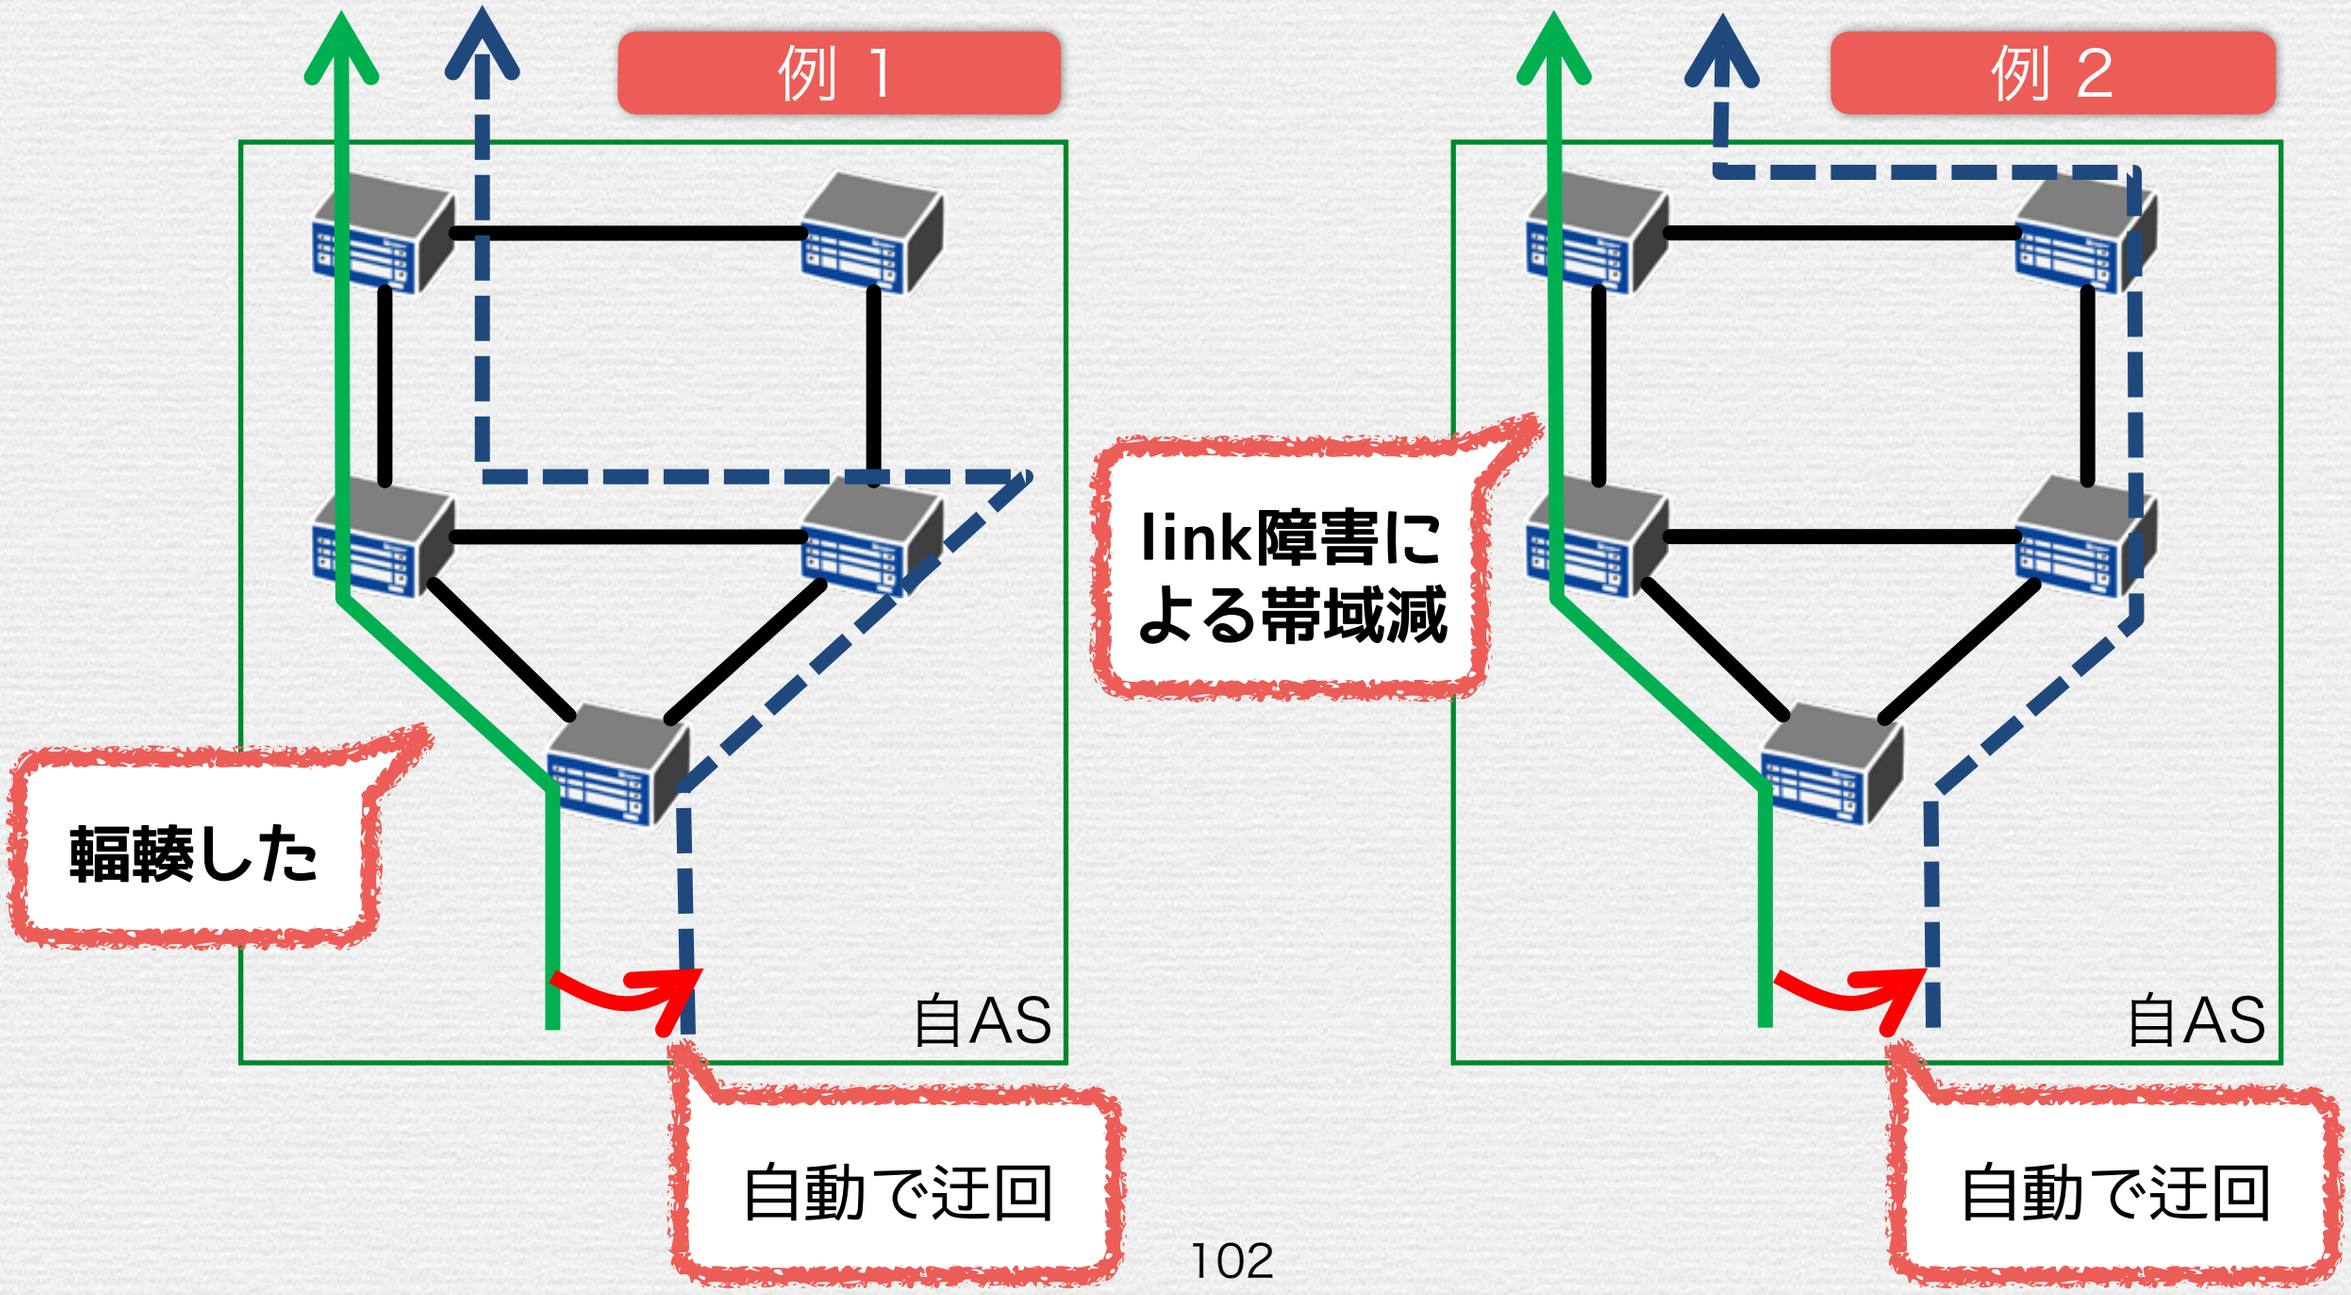

MPLS + RSVP のしくみ

- LSPはLSR(Label Switching Router: MPLSを設定するrouter)群で 2x full mesh分 張る
  - LSPは片方向通信のみ
    - 通信方向が異なると 別のLSPがpacket を運ぶ
      - R1 → R2 → R4
      - R4 → R2 → R1

      は別物
- LSPを張る前にRSVP signaling
  - CSPF(Constrainted Shortest Path First)
    - Link State型のIGPに依存する
      - OSPF
      - ISIS

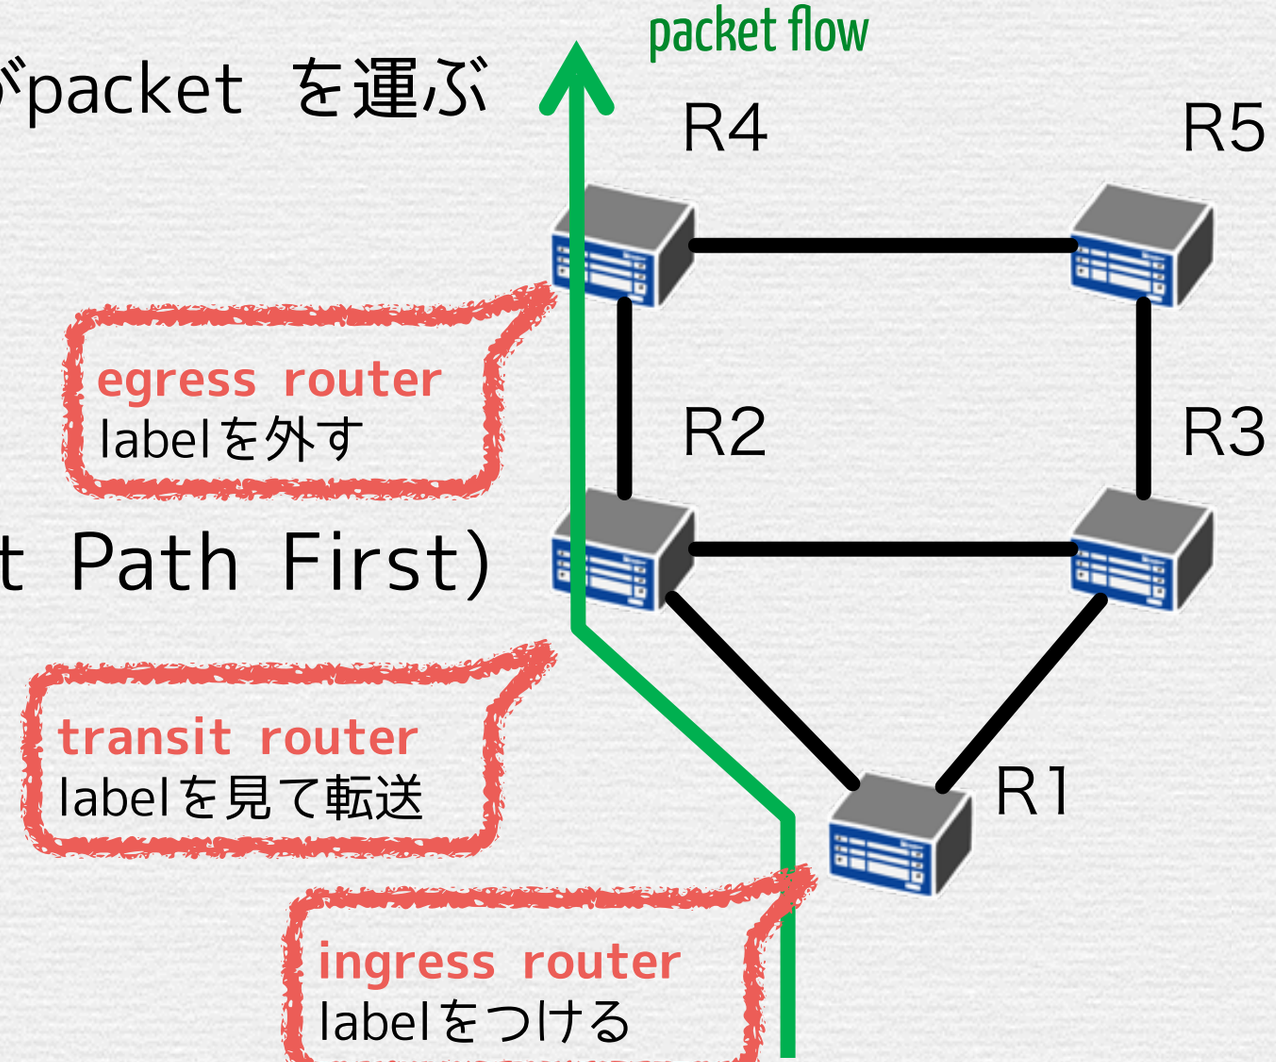

RSVP のしくみ

- LSPを張る前に，LSP毎にあらかじめ**設定された帯域**が確保できるかを調べる
  - ingress / egress router間でsignalを送り合う
  - IGP costの小さいpathから
  - 各LSRは接続されているRSVP linkの空き帯域を計算
  - R1-R4 LSPの例
    1. R1-R2-R4 で張れるか? → NG
    2. R1-R3-R4 は? → NG
    3. R1-R3-R5-R4 は? → OK
- LDPを使ったり(帯域計算なし)，LSPを特定pathに固定したりもできる

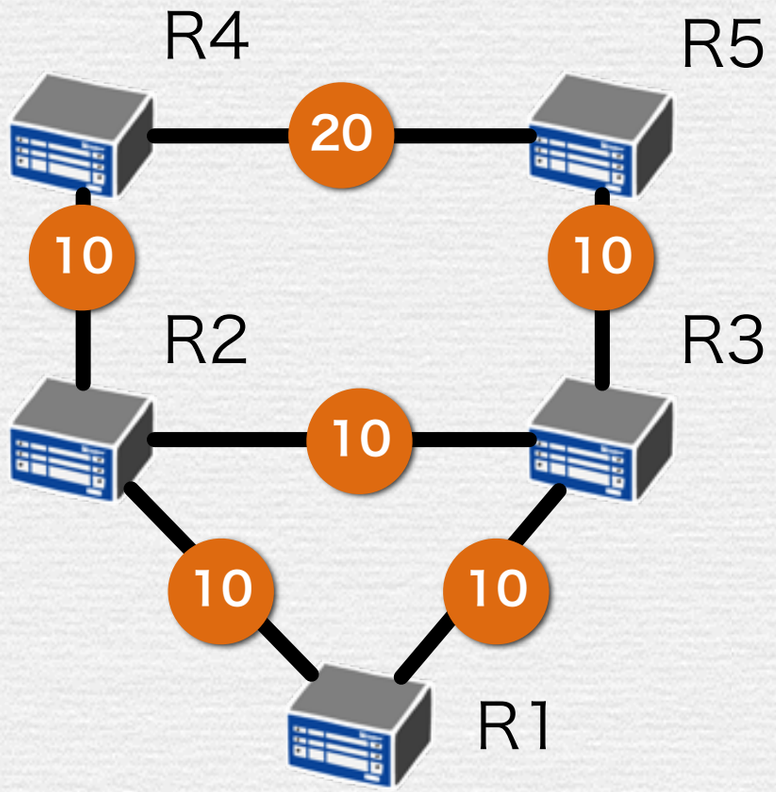

MPLS-TE

- network eventにより帯域が縮退
  1. RSVP signaling
  2. LSPが空き帯域に移る
- 自動で空き帯域を探索してくれるので，手動によるTE不要
- LSPが落ちても即packet lossではない
  - IGPにfallbackする(BGP のprotocol nexthopの解決のためにLSP + IGPを使う. 優先度が LSP > IGP)
- fast reroute
  - LSPが落ちたときのconvergenceを早くするために，あらかじめbackup LSPを張っておく

```
koji@test-router> show route 192.0.2.0/24

inet.0: 57 destinations, 57 routes (57 active, 0 holddown, 0 hidden)
+ = Active Route, - = Last Active, * = Both

192.0.2.0/24    *[BGP/170] 5d 07:12:01, localpref 100, from 192.0.2.1
                   AS path: I
                 > to 198.51.100.1 via ae1.0, label-switched-path r1-r5-00


koji@test-router> show route 192.0.2.1

inet.3: 1 destinations, 1 routes (1 active, 0 holddown, 0 hidden)
+ = Active Route, - = Last Active, * = Both

192.0.2.1/32    *[RSVP/7] 5d 06:47:49, metric 16
                 > to 198.51.100.1 via ae1.0, label-switched-path r1-r5-00
                 [IS-IS/18] 5d 06:47:48, metric 16
                 > to 198.51.100.1 via ae1.0, label-switched-path r1-r5-00
```

MPLS-TE

- LSPに優先度を付けてpreemptiveに動作させる → QoS
  - closed networkではよく使われている
- 10年以上前の枯れた技術
- Layer 2.5

MPLS-TE

- 利点
  - 手動TEからの開放
  - 帯域設計がラク
    - 最悪rerouteしてくれる
- 欠点
  - overlay model
  - label overhead
  - LSP sizeを設定するため，日々LSP毎のtraffic量をカウントする必要がある (MIB など)
  - 設定が煩雑
  - 理解しづらい

その他

peering 判断の基本

transitコストを抑えることが主な目的

- peerをするASホルダー同士の力関係にもよるが
  - peerすることでコストメリットがある
  - お互いのビジネスを侵害しないなど，両者のpeering policyを満たして初めてpeeringを行う

- “コストメリットがある” ことの目安として ”trafficが???Mbps 出ること” という条件がある場合や，(続く)

・“お互いのビジネスを侵害しない” 条件として複数リージョン / 複数POPでの接続を条件とするISPもいる

自分の経路を，自分のビジネス拠点の近くで渡したくない
(peering partnerはその経路でビジネスができる可能性がある)

“networkの規模が同じくらい” という目安にもなる

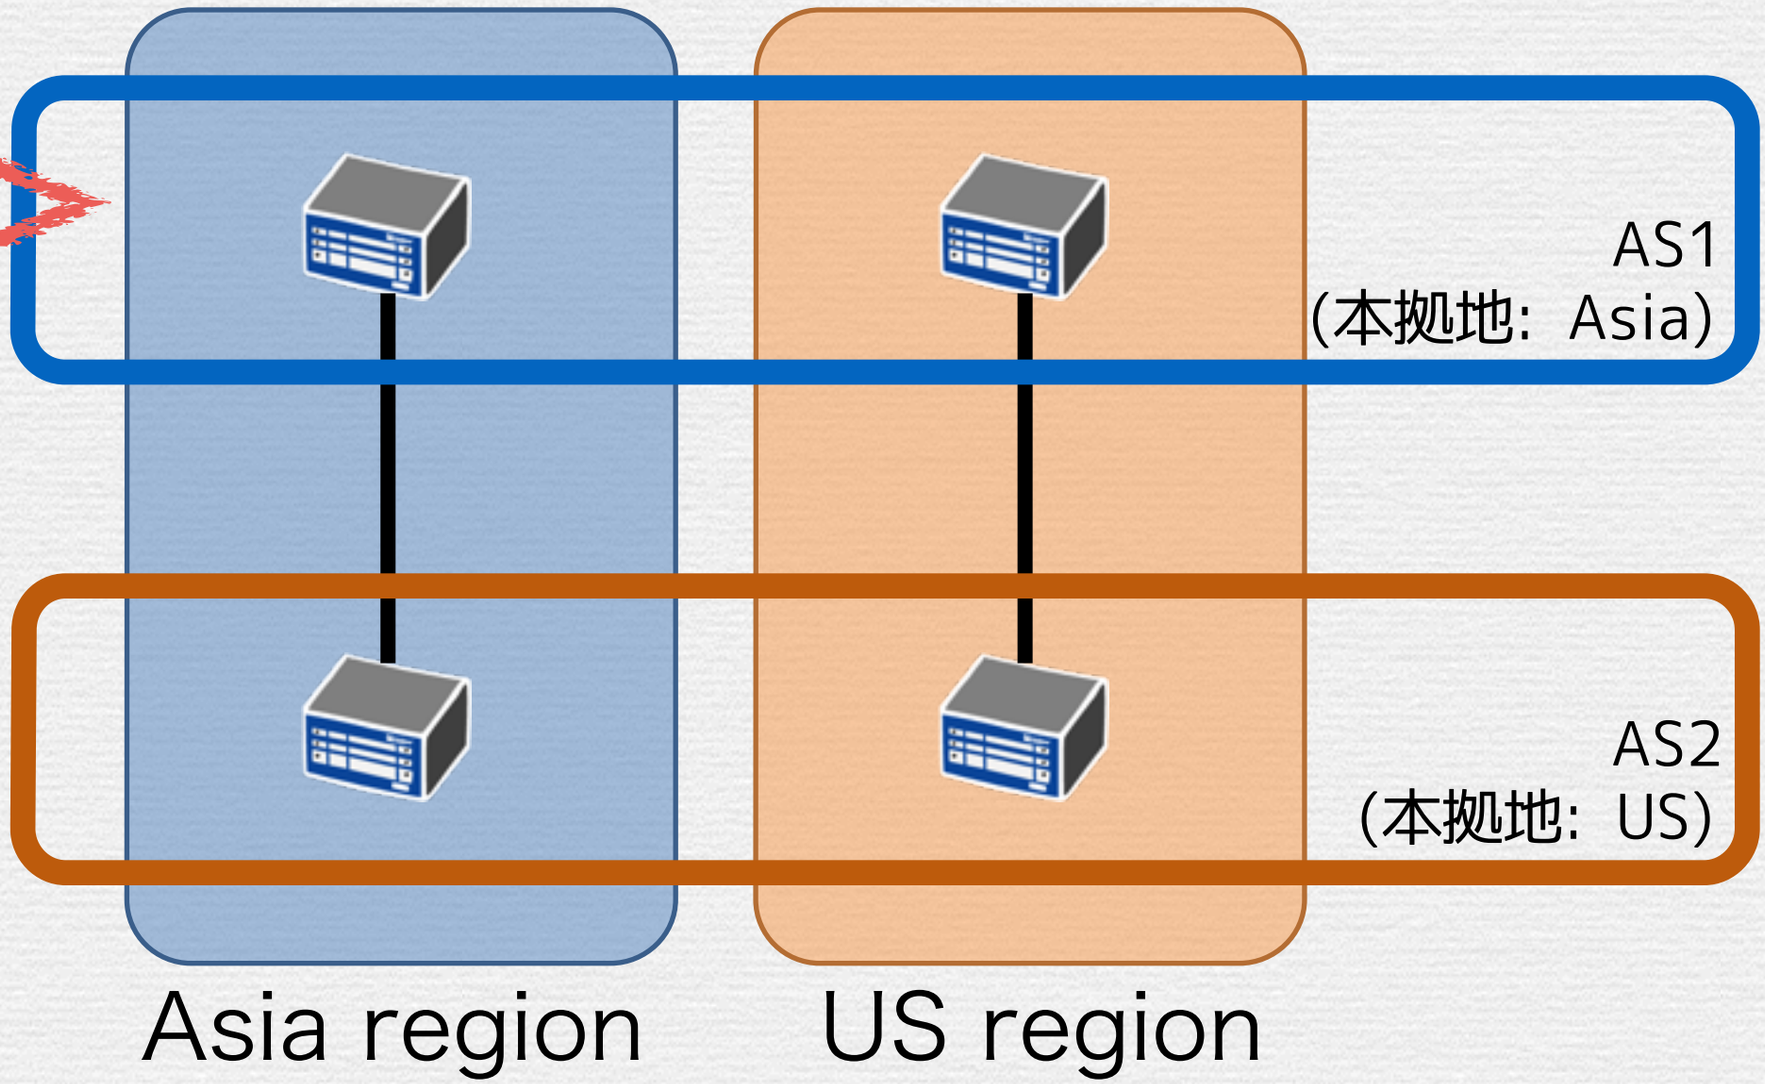

・AS ホルダー同士の力関係により
  ・paid peer
  ・“ある地域でtransitを買えば，別の地域でpeerできる”
    というバーター
のような形態もある

・www.peeringdb.com にある程度まとめられている．”General Policy” が “Open” なASホルダーはpeeringに応じてくれる可能性大
  ・web or mysqlで一覧が取得できる

```
$ mysql -r -hpeeringdb.com -upeeringdb -ppeeringdb Peering
mysql> SELECT asn, name, aka, policy_locations, policy_ratio FROM peerParticipants
WHERE policy_general IN ('Open') ORDER BY asn;
```

peering 判断の基本

- ICPにとって，ISPとのpeeringにより ”ビジネスが侵害” される可能性は低いため，単純に ”コストメリットがあるか?” がpeering判断の大きな評価軸になる場合が多い

- 一方，ICPは他のICPとpeeringするメリットはある?
  - 基本なさそうだが
    - ビジネスプラットフォームの連携 (ゲームなど)
    - 他社APIの利用

    などは増えてくる見込み

transit providerの filterを制御する

- どこかのInternet Routing Registry(IRR) に登録する必要がある
  - 日本でよく使われているもの
  - JPIRR (jpirr.nic.ad.jp)
    - JPNIC 会員のみ
  - RADB (whois.radb.net)
    - 有償 ($500/y)
  - NTTCOM (rr.ntt.net)
    - ntt.net ユーザーのみ

		このIRR の情報を持っているか?		
		JPIRR	RADB	NTTC
このIRRが	JPIRR	○	○	×
	RADB	○	○	○
	NTTCO	○	○	○

お互いにmirrorしているため，どこか1箇所に登録すればよい

IRR への登録

http://www.nic.ad.jp/doc/jpnic-01077.html
に丁寧な解説がある

- いくつかのobjectを登録する
  - Maintainer
  - Aut-num
  - Route
  - AS-Set

- 登録したAS-Set objectをtransit providerに伝える
- www.peeringdb.com にも登録しておく

peering db

“細かいことはpeering dbを見てください”

ですむので便利

- www.peeringdb.com
- 情報閲覧はguestアカウントでOK
- 自ASの情報を登録するには
  ユーザー登録 ➔データベース運営者の承認が必要
  - mail addressのdomainを見られるので，ASとの関連が明らかなmail addressを使う

peering dbには，いろいろ記載できる

- ASの基本情報
  - 名前
  - ASN
  - 種別(ISP / ICP など)
  - traffic level
  - looking glass / route server URL
  - ipv4 / multicast / ipv6
- peering policy
  - open / selective / restrictive / No
  - 複数拠点でのpeerを条件にするか?
  - in / outのtraffic比率を条件にするか?
- 連絡先
- 接続IX (public peer 用)
  - 名前
  - 帯域
- POP (private peer 用)
  - DC名
  - Interface 種別

経路奉行

- JPIRRに登録するといいことがある
  - BGP route hijackingを検知 / 通知してくれる
    - http://www.nic.ad.jp/ja/ip/irr/jpirr_exp.html
  - ISAlarm, BGPMON (*) みたいなもの

```
route:          202.12.30.0/24
descr:          JPNICNET
                Japan Network Information Center
                Kokusai Kogyo Kanda Bldg. 6F
                2-3-4 Uchi-Kanda
                Chiyoda-ku, Tokyo 101-0047
                JAPAN
                X-Keiro: okadams@nic.ad.jp      <--追加記述
                X-Keiro: okadams-noc@nic.ad.jp  <--複数あて先に通知する場合記述
origin:         AS2515
admin-c:        SN3603JP
tech-c:         YK11438JP
tech-c:         MO5920JP
notify:         system@nic.ad.jp
mnt-by:         MAINT-AS2515
changed:        apnic-ftp@nic.ad.jp 20080116
source:         JPIRR
```

(*) ISAlarm:
http://www.ripe.net/is/alarms
BGPMON:
http://www.bgpmon.net/

route server

- eBGP sessionをscaleさせる技術
  - 主にIXで利用されている

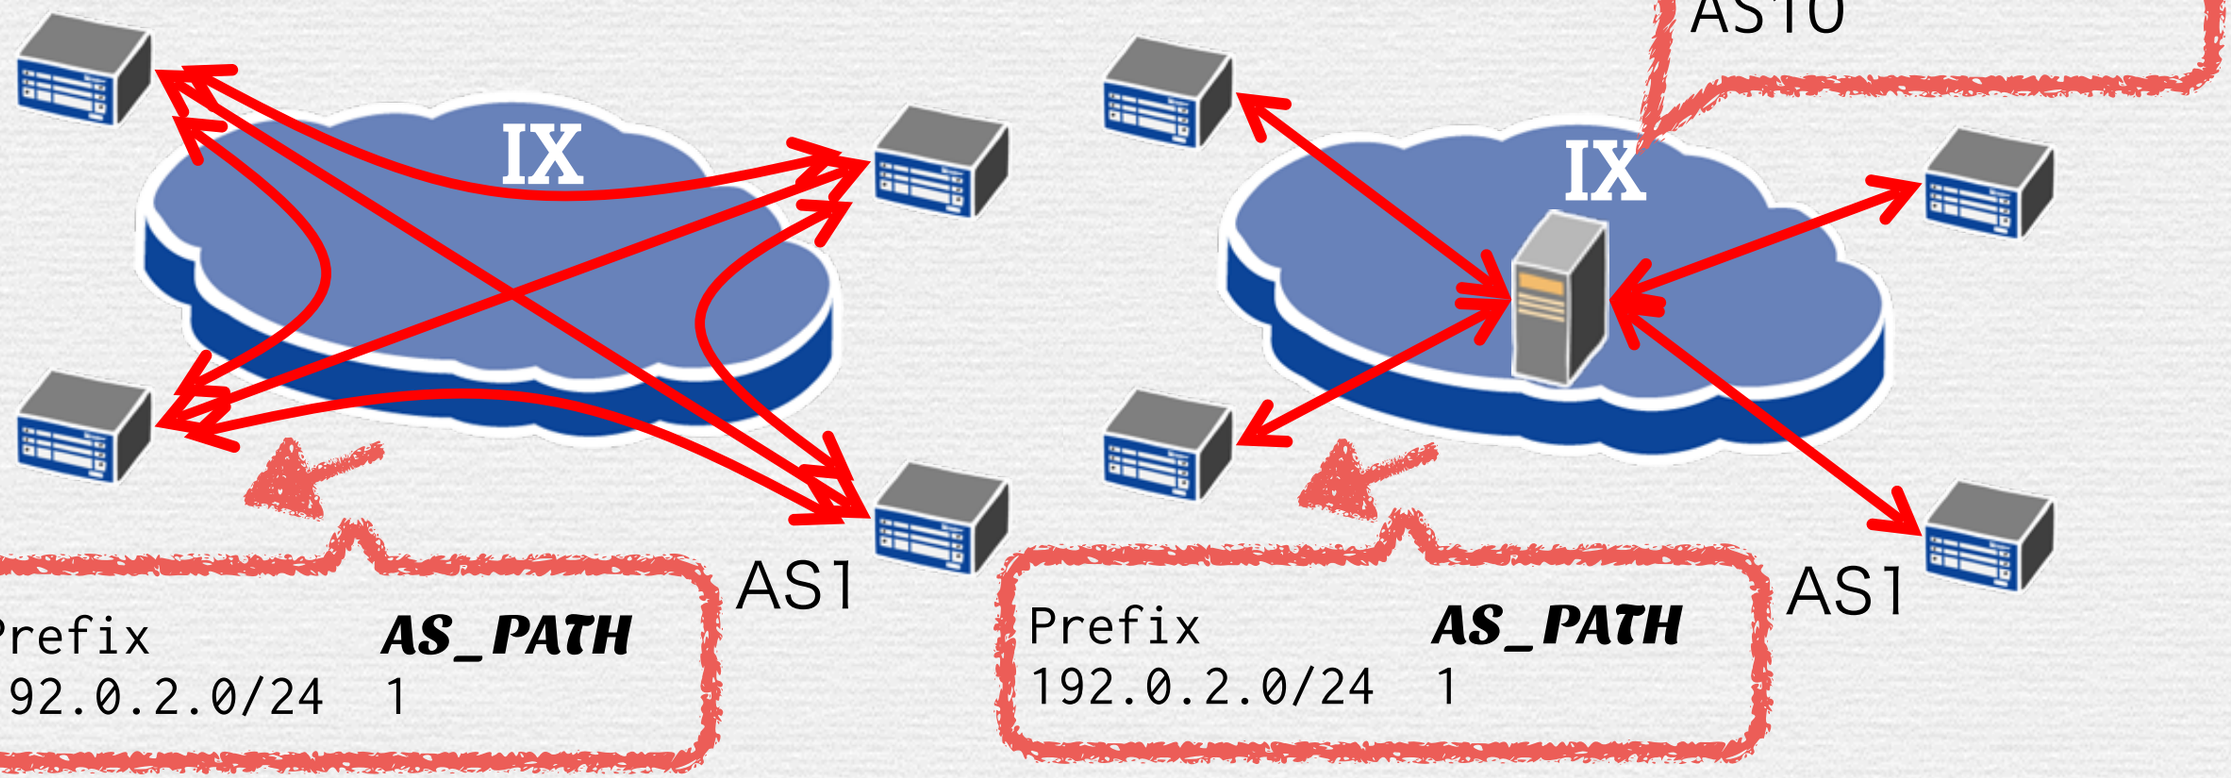

- 通常のpeeringの手法(bilateral)とroute server経由のpeeringの手法(multilateral)で，RIBの中身がほぼ同じ
  - remote AS(この例ではAS10)はAS_PATHに載らない
- eBGP session数を減らすことで運用をラクに
  - open policyのASホルダー向き

道具を箱に詰めよう

http://www.flickr.com/photos/cogdog/5516868634/

xflow

- Traffic Engineeringのため
  - どのAS, prefixが何bps持っているか?
  - あるlinkに乗っているtrafficのうち, ??% を移すためにどのAS, prefixを制御すればいいか?

  などを調べたい
- netflow v5 / v9
- sflow v5
- OSS collector(nfdump, flowtools)で十分
- sampling rate: 1/8192 ~ 1/10000

web services

- internetの構造を知るためのヒント
  - as-relationships:
    http://www.caida.org/data/active/as-relationships/
    - どのASがどのASからtransitを買っている(ように見える)か．．．という情報が掲載されている
    - リサーチの成果物なので事実との不一致もある

- bgplay
  https://stat.ripe.net/widget/bgplay
  - routeviews(official)よりRIPE版が使いやすい
  - 経路を解析することでAS間の接続性が確認できる
  - routeviews: route serverにも直接telnet可能
    http://www.routeviews.org/

- internetの構造を知るためのヒント
  - ripe stat
    https://stat.ripe.net
    - さまざまなinternet resourceの状態が閲覧できて便利
  - looking glass
    - http://www.bgp4.as/looking-glasses
    - http://www.traceroute.org
    - http://www.lookinglass.org/
    - http://www.bgp4.net/

rancid

- http://www.shrubbery.net/rancid/
- network deviceへのloginを簡略化できる
  指定のcommand群の実行を，複数deviceに対して実行できる
- expectでprogram可能
- config の自動backup / VCSへの投入
- 条件分岐したい時は**exscript**の方が便利
  https://github.com/knipknap/exscript/wiki
  - まだいくつかbugがあるらしい
    - ipv6がうまく読めない，など

ruby / python

- CLIをwrapしてprogram
- 豊富なlibrary

- rubyはwebと親和性が高い
- pythonはnetwork系libraryが充実
- “自動でrouterに設定を入れる” など

mrtdump / bgpdump

- bgp update / withdraw をdump, 解析
- bgp table自体をexportすることも可能

- QuaggaなどOSS route serverが一台手元にあると便利
  - VMでもOK
  - bird, openbgpdも

exabgp

BGP sessionを張り，任意のBGP updateを作れるsimulation 用tool

- shell scriptでシナリオを書ける
- 商用のBGP test toolと比べても，使い方によっては遜色ない
  - performanceの面で弱い可能性はある

- 最近よくメンテナンスされていて使いやすくなっている

経路Filter関係

- peval(IRR Toolset)
  - もはやメンテナンスが厳しいらしい
  - 代替品
    - Net::IRR
    - bgpq3
    - IRRPowerTools
    - Md4.7
    - p2BGPTool

  - capirca というのもある

自動化支援
(router メーカー製)

- event drivenでコマンド実行
  - Juniper: **Junoscript**
    - xml ベース
  - Cisco: **Embedded Event Manager (EEM)**
    - tcl ベース

- Cisco: **One Platform KIT(One PK)**
  - packet processingまでできるらしい

photo by Akinori Maemura

JANOG

- network運用にまつわる情報の共有 / 議論
- 問題の共有
- オペレーターcommunityで解決

- 例:
  1. open resolverを減らすには?
  2. あるIP address blockがGeoIPサービスに誤認識され，オンラインサービスに接続できなかった

各種 IX Meeting

- ユーザー会
  - JPNAP
  - JPIX
- Japan Peering Forum
  - Equinix

各種 Network Meeting

- Apricot (Asia)
- NANOG (North America)
- RIPE (Europe)

まとめ

今日の目的

- **BGPの設計を決める際に考えないといけないこと** をつかむ

- “BGP sessionの先にいるAS (顧客 / peering partner / transit 提供者) にも個別のrouting policyがある” という環境で, **どうやって自分の思うようにtraffic control するか?** を理解する

BGPのPolicyや設計を決めるために考えるべきこと

NetworkやRoutingを考える際には常にPolicyを意識

常に意識できるよう
Addressingや
Routing Policyは
なるべくシンプルに

とは言っても，
BGPはASをまたぐので
いつもPolicy/設計通りに
実装できるとは限らない

Policy/設計に反することは誰が見ても「反している」のが分かるように

技術的負債を返すため，目的を達成したら必ず戻す
その際に周囲に影響なく消せるよう，実装時から工夫することが大事

シンプルに
わかりやすく

http://www.flickr.com/photos/techsavvyed/5926978939/

ありがとうございました！