InternetWeek 2015 T7
IPv6ネットワーク運用とトラブルシューティング

株式会社ブロードバンドタワー
國武　功一

本プレゼンテーションに関して

IPv6ネットワークを構築・運用する際に
注意すべき観点について解説します
主にサーバセグメントについて解説します。

※基本的にはIPv6 onlyネットワークについては取り上げません

Agenda

BroadBand Tower, Inc.

- IPv6ネットワーク概要（基本）
  - 構成例について
  - DualStack
  - Fallbackについて
- IPv6トラブル事例および防止策
  - DNS関連
  - Path MTU Discovery Blackholeその原因
- 構築時の注意点

IPv6ネットワーク概要(1)

- IPv4とIPv6は別プロトコル
- サーバは、構成も経路も分けることが可能

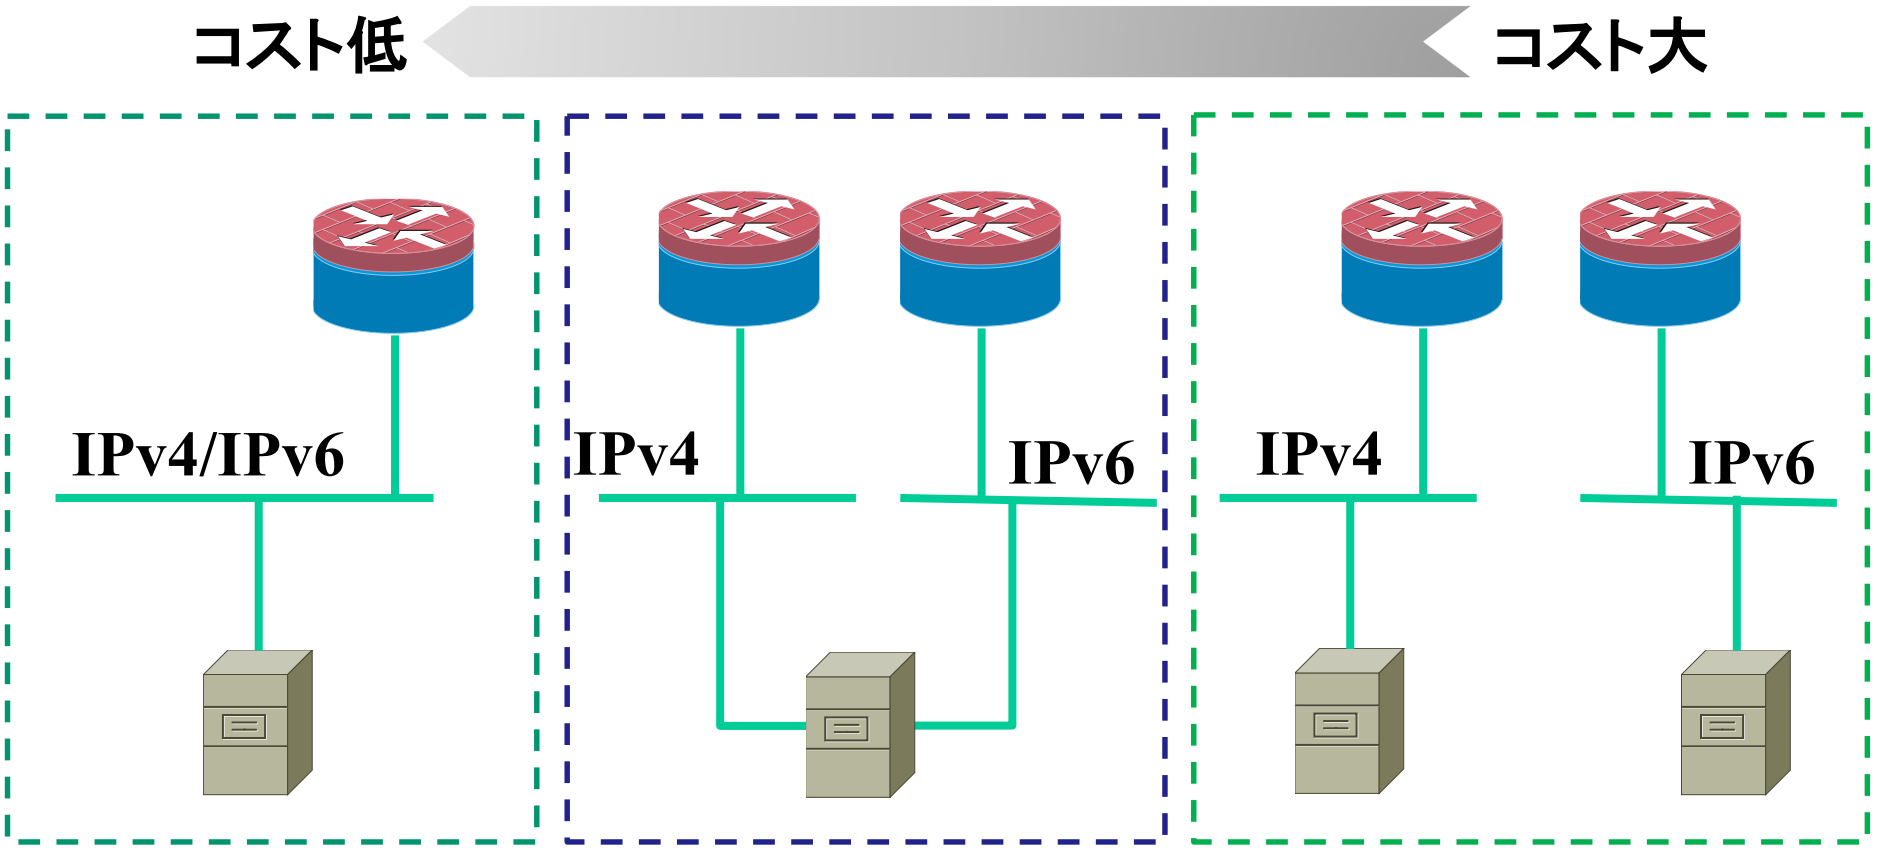

IPv6ネットワーク概要(2)

- クライアント側でのIPv6は、DualStackでの対応が多数。
- クライアントに割り当てられるIPv6アドレスはグローバルアドレスが割り当てられることが多い。

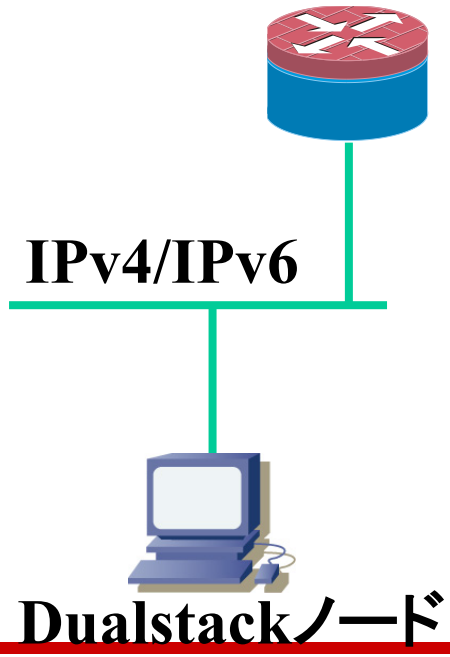

IPv6ネットワーク概要(3)

- IPv6 onlyでの運用も想定されつつある。
  - DNS64+NAT64での運用 (例：iOS9のアプリ要件 ※1)

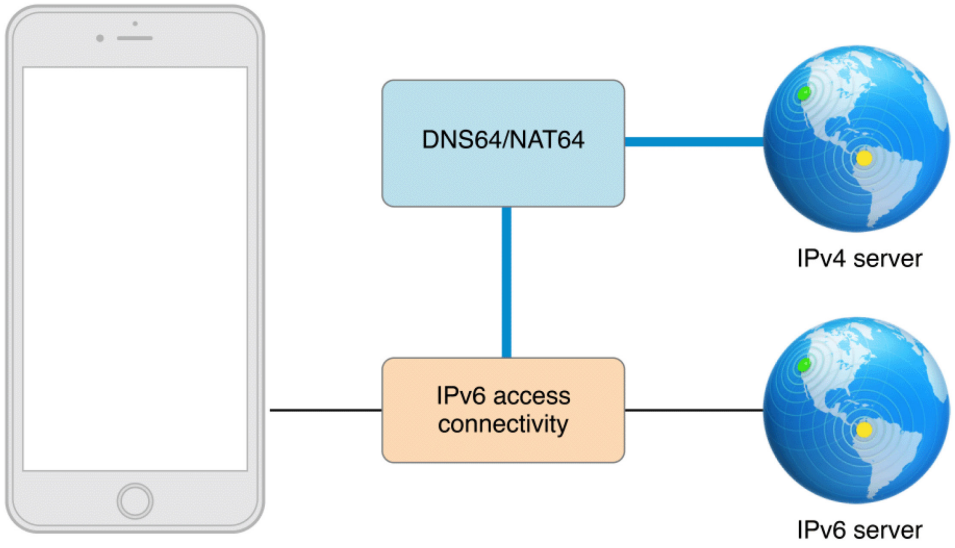

iOS Developer Library / Networkng Overview
Figure 10- 2 A cellular network that deploys an IPv6 network with DNS64 and NAT64
より引用

※1 http://goo.gl/0USFlz

IPv6ネットワーク概要(4)

- Privacy Extension

  クライアントに割り当てられるIPv6アドレスは、下位64bitが定期的にランダムに更新され、ユーザの特定が難しいように考慮されている（実装および利用されているかは、個別設定）

  ＝＞　DNSの逆引き設定が困難であり、期待できない。このため、クライアントに対する名前ベースのACLは利用できないことが多い。

俯瞰図

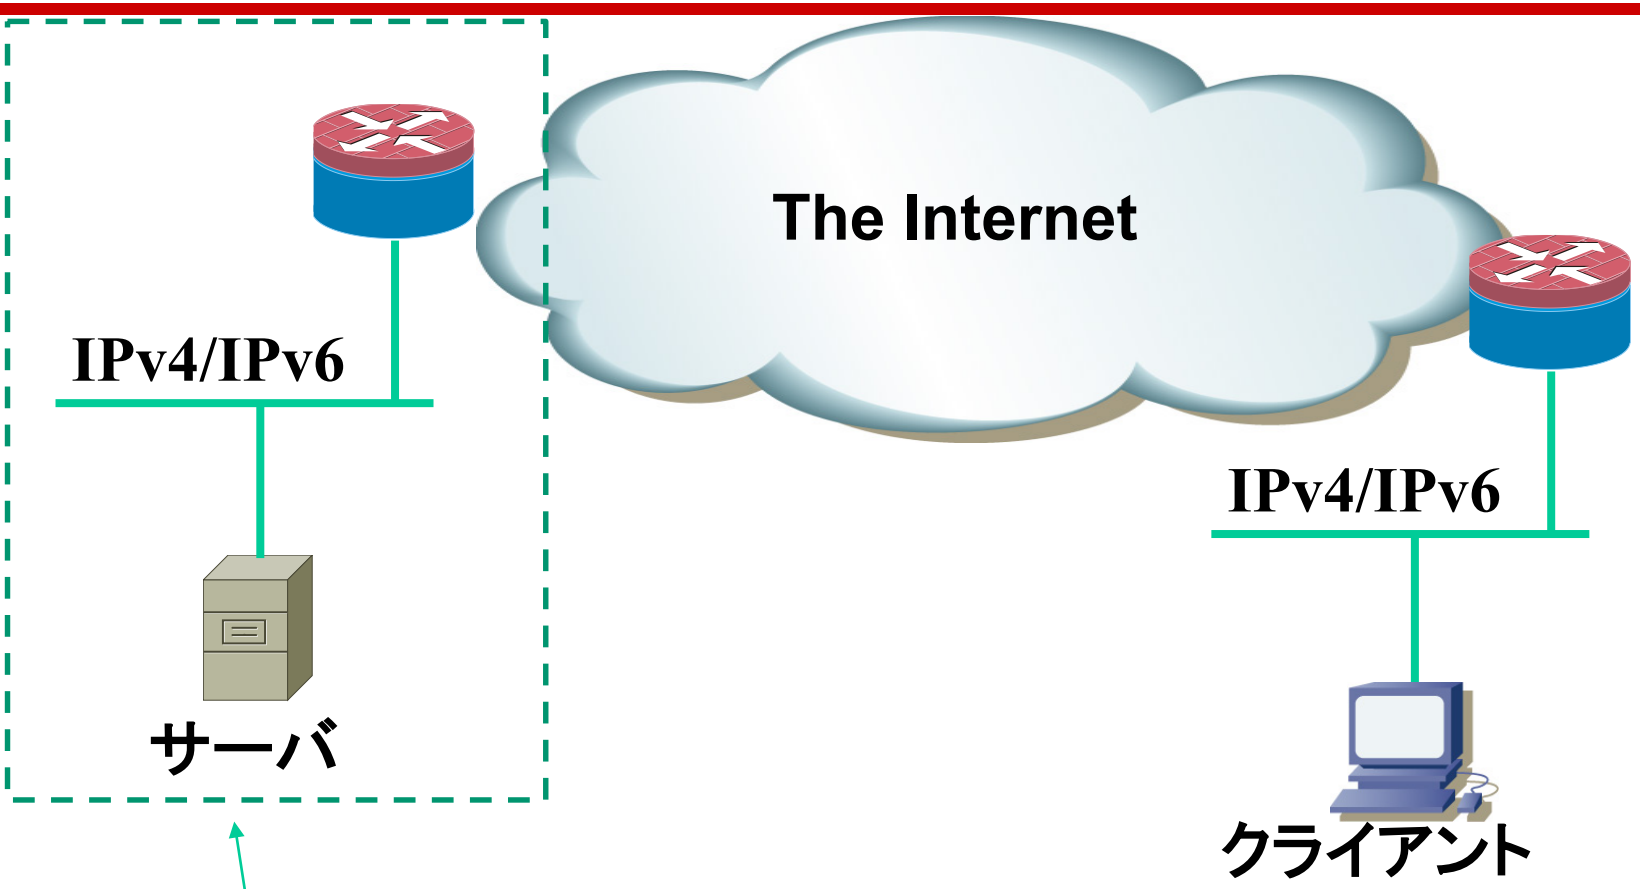

基本固定IPアドレス

下位64bitが固定であるケースと、時間経過とともにランダムに変更するものとが存在

DualStackについて

- IPv4 stackとIPv6 stackの両方を実装したノードをdualstack ノードと呼ぶ
- 単一のFQDNでIPv4/IPv6サービスを提供するケースで多い。
- FQDNを共有するケースでは、ユーザ側でのフォールバックについて気をつける必要がある。

DNS権威サーバへの登録

```
;; Server
www         IN    A          192.0.2.1
            IN    AAAA       2001:db8::80
```

IPv6 -> IPv4へのフォールバック

①FQDNの名前解決を行う
　IPv4 transport / IPv6 transportでもどちらでもよい）
②AAAA RR, A RRが返る
③IPv6で接続
④IPv6で接続できないと、IPv4へフォールバック

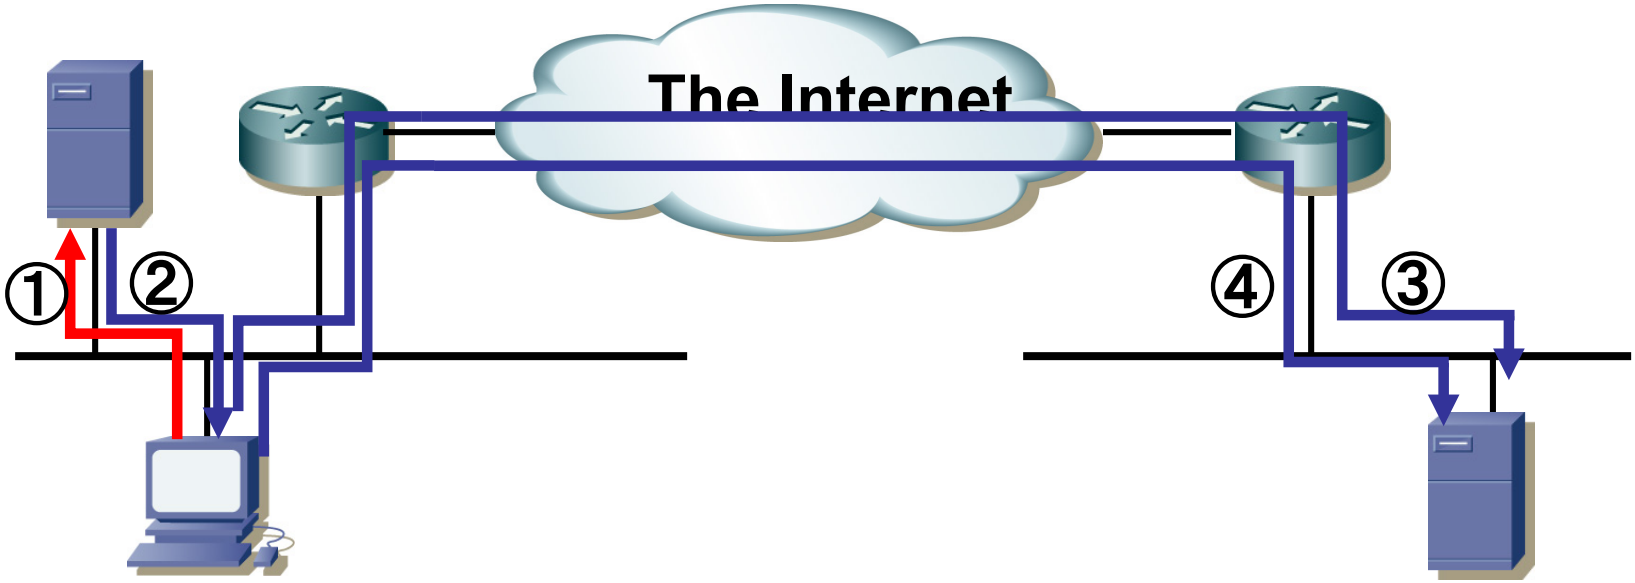

フォールバックの問題点について(1)

- IPv6閉域網フォールバック問題
  - IPv6グローバルアドレスを閉域網で利用した場合の問題点(いわゆるBフレッツ問題)
    TCP RSTを網側から返すことで、影響を極小化

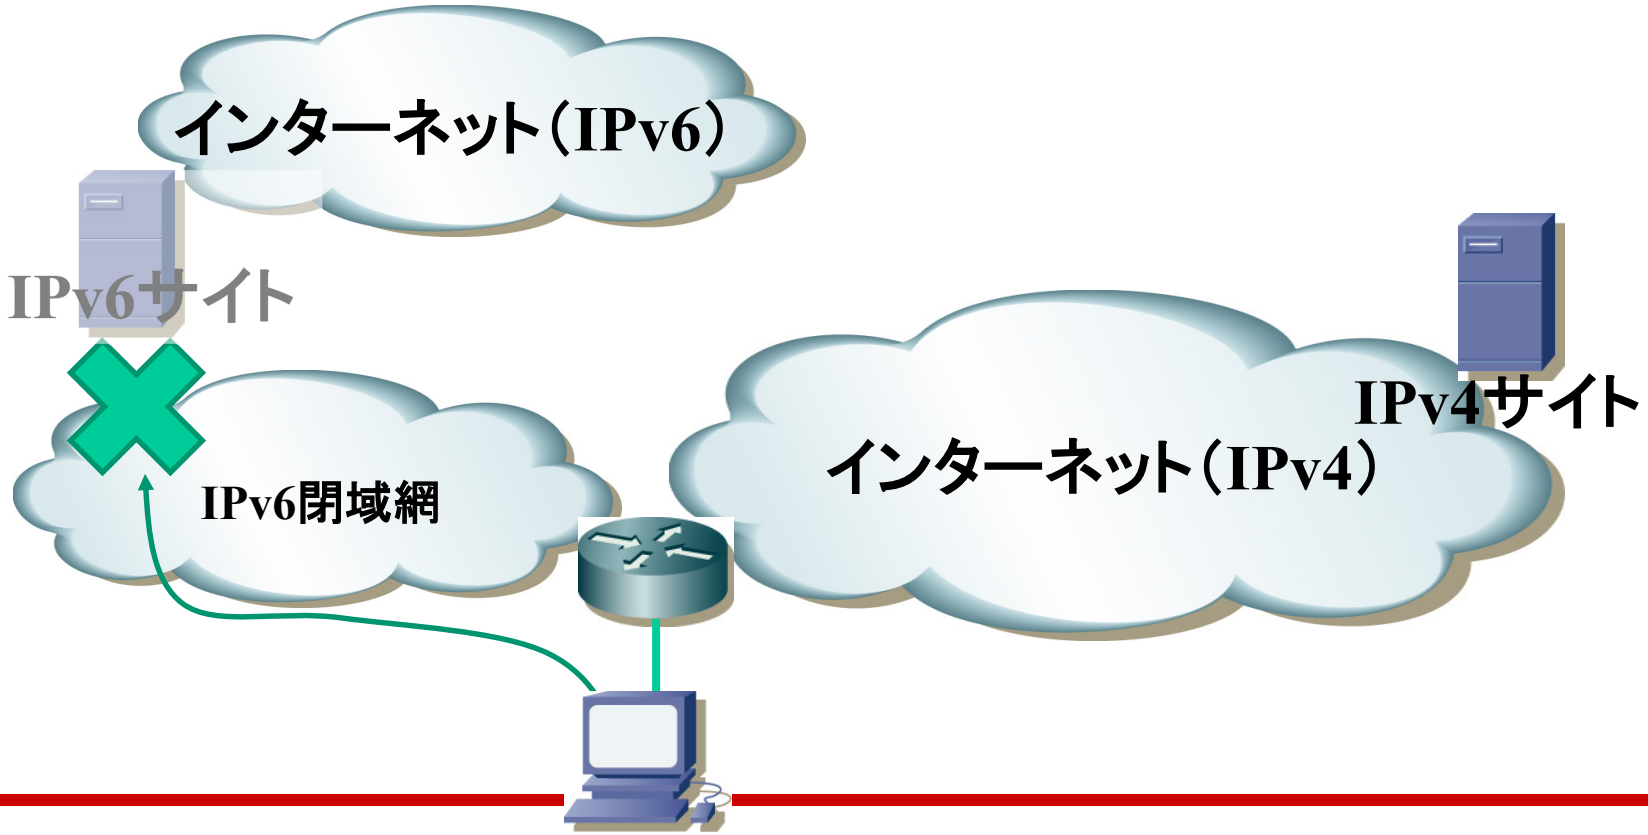

フォールバックの問題点について(2)

- TCPのタイムアウトが長く、ユーザへの影響が大きい

  Happy Eyeballsによるブラウザ側での対応が進む
- Happy Eyeballs

  最初から、IPv4/IPv6の両方で接続を開始し、先に接続が成功した方で通信を行う。これにより、TCPのタイムアウトを伴なうような事象での影響を極小化（＊1）

  かなり改善されてきたが、Happy Eyeballsはアプリによる対応のため、影響を受ける、受けないは実装依存

(*1)iOS9とEI Capitanでは、IPv4側に25msecの意図的なdelay

IPv6トラブル事例と防止策について

BroadBand Tower, Inc.

- **DNS関連**
- ネットワーク
- Path MTU Discovery Blackhole問題

DNS関連：ケース1

- 事象
  - 支店からウェブアクセスすると早い。本店からアクセスすると、妙に遅い。
- 原因
  - サーバの再構築後、IPv6アドレスの付与を忘れ、AAAAを残したままだった（フォールバック問題）
  - 支店にはIPv4環境しかなく、本店には、IPv4/IPv6の接続性があり、IPv6から、IPv4へのフォールバックが発生していた。

IPv6アドレスの付与漏れ

```
;; Server
www        IN     A          192.0.2.1
           IN     AAAA       2001:db8::80
```

移行前にはついていたアドレス

そもそもIPv6アドレスに対して、監視がなされていなかったのも問題
Happy Eyeballs対応のブラウザでは顕在化しづらい。

ケース1：対策

- サーバの構成変更、移行時には、そもそも既存でIPv6アドレスの利用がないかどうかをチェック
- チェックポイント
  - サーバにIPv6アドレスが付いていないか
    - 実際には付与の有無だけでは判断できない
  - FQDNにAAAA RRが登録されていないか

DNS関連：ケース2

BroadBand Tower, Inc.

- 事象
  - クラウドのAPI叩いている機能を使うと重い
  - sshでログインする時、妙なひっかかりがある
- 原因
  - Glibc2.6以降を使っている場合のLinuxのリゾルバの挙動と、Firewallとの総合作用

DNSクエリに関するOSの対応

BroadBand Tower, Inc.

- クエリ順序はOSで異なる
  - AAAAクエリを先に実施するOS
    - Windows XP、Linux
  - Aクエリを先に実施するOS
    - Windows Vista、Windows 7、FreeBSD、Mac OS X

InternetWeek 2010 北口氏資料より一部抜粋 (p.64)
http://www.nic.ad.jp/ja/materials/iw/2010/proceedings/s2/iw2010-s2-01.pdf

が、Glibcのバージョンによって…

- RHEL5/CentOS5

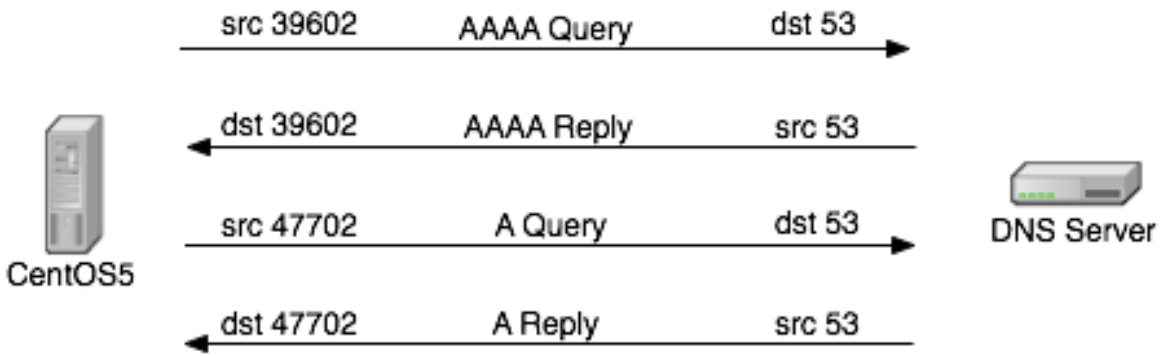

- RHEL6/CentOS6 and so on.

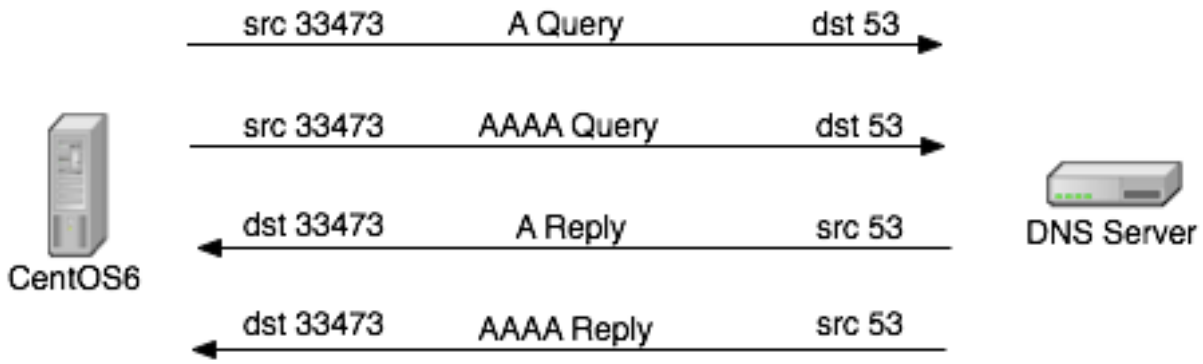

基本的にはよい方向だが…

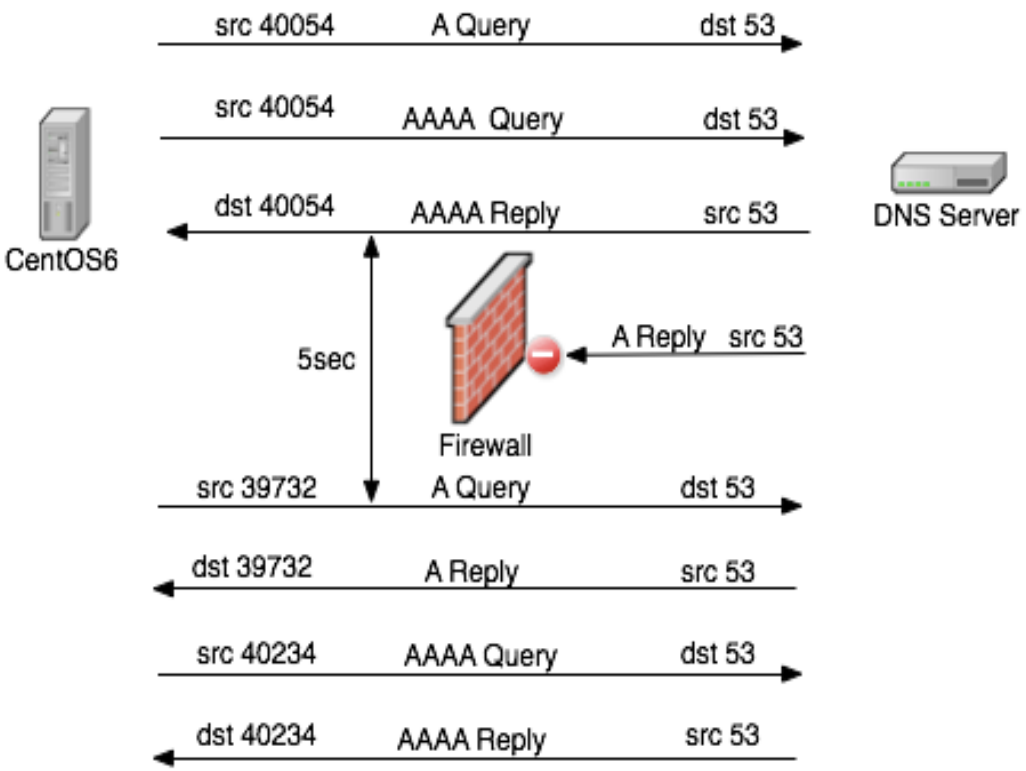

一部のファイアウォールの実装では、同一ポートからのクエリを再送（同一のセッション）とみなし、結果返信が落とされてしまうものがある

この問題の罪なところ

BroadBand Tower, Inc.

- 名前は最終的に引ける
- 若干遅いぐらい（標準設定で5秒でfallback)
  - options timeout:1 なら、もっと短い（そして発覚しづらい）
- 最近のサーバはAPI連携で、DNSを引くことも
  - 普通にクライアントとして使われる場合には、DNSの結果はキャッシュされないこともあり、ユーザの1リクエストに対して、複数回APIを叩くと……

single-request-reopenを設定する

- /etc/resolv.conf にオプションとして設定すると、クエリ毎にポートを変えるようになる(socketを作り直す)

```
search example.jp
nameserver 2001:db8:0001::53
nameserver 2001:db8:fffff::53
options single-request-reopen
```

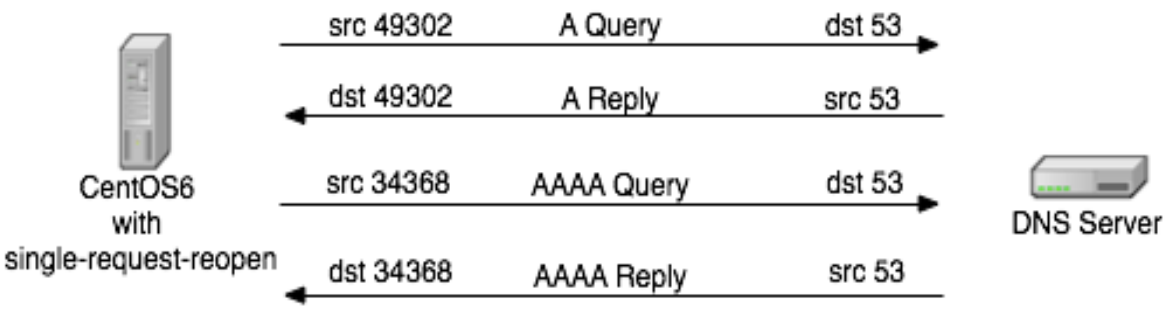

DNS関連：ケース3

- 事象
  - よくわかんないけど、重い
- 原因
  - ある事例では、GSLBなどが、AAAAに応答せず、タイムアウトすることで、AAAAのQueryを投げるクライアントからのアクセスが結果的に遅くなる。
  - 導入前に、Aレコードなどしか利用を想定していない、もしくはテストをしていない。

GSLBのざっくりとした仕組み

198.51.100.1

gslb1.example.jp

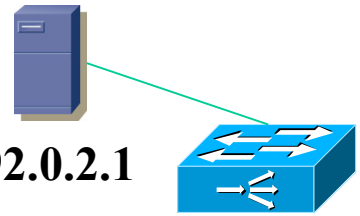

192.0.2.1

gslb2.example.jp

198.51.100.1だよ

DNS権威サーバ
ns.example.jp

www.example.jp の
IPアドレスは？

gslb{1|2}.example.jp
に聞いてね。

www.example.jpのAレコードは？

クライアント(というか、DNSキャッシュサーバ)

DNS関連：ケース４

- 事象
  - ある日、ULAを使っているネットワークで、突然タイムアウトの嵐。
- 原因
  - ULAに関する逆引きリクエストが Locally Serverd DNS Zonesの設定漏れで、IANA管理のサーバなどに聞きに行っていた。これが、IANA管理のDNS権威サーバの障害などで、タイムアウトを起こし障害へ発展。
  - Locally Served DNS Zones設定漏れに起因する障害（RFC6303)

DNS関連(Summary)

- 設定不備がほとんど
  - DNS権威サーバおよびDNSキャッシュサーバに対する知識の欠如
    - メーカー側、ユーザ側
  - IPv6サービスを提供していることが共有されない、またされ続けない。
  - IPv6でのサービスレベルが、IPv4のものと比べて、低くなってしまっている(積み重なっている運用経験が、活かされない)
  - 単純なテスト不足

IPv6トラブル事例と防止策について

BroadBand Tower, Inc.

- DNS関連
- **ネットワーク**
- Path MTU Discovery Blackhole問題

Proxy での問題点

- Happy Eyeballs Killer

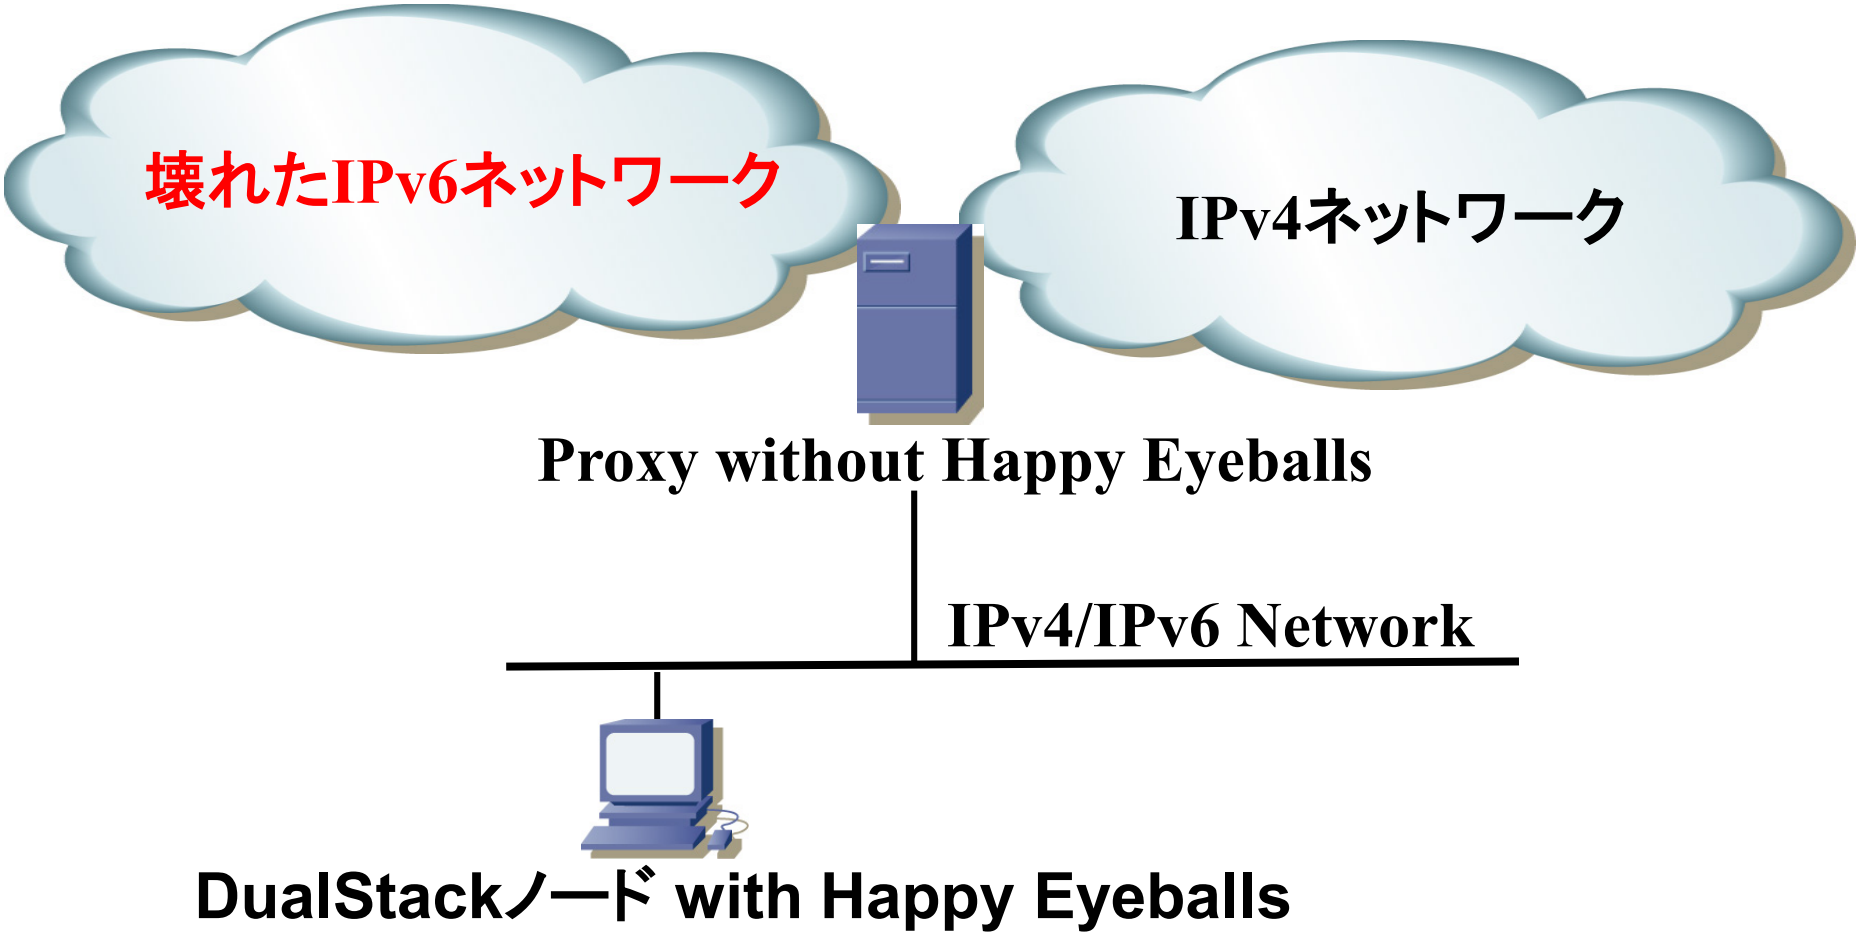

Proxy での問題点(2)

- Squidは現時点で、Happy Eyeballs をフル実装する予定はないと表明している。
- Anti-Virusソフトウェアで、Proxy ベースの実装があるため、該当してしまわないかに注意

Anti-Virus Software? as Firewall

BroadBand Tower, Inc.

- Firewall内蔵のAnti-Virus Softwareには注意！
  - 意図的に標準でIPv6トラフィックをすべて遮断しようとするものが存在（しかも実際は遮断できていなくて、問題を引き起こす）

ipv6 nd ra supressの盲点

Ciscoでは、default でRAを投げます

RAを完全に抑制するには

ipv6 nd ra supress

だけでは足りなくて

ipv6 nd ra supress all

と書く必要があります。

ipv6 nd ra supressの盲点（Cont)

BroadBand Tower, Inc.

“all” をつけないと、定期的なRA送出は抑制されるものの、RS(Router Solicitation)を受け取ると、RAを送出してしまう。

従来の実装では、RSは基本的にnodeが I/F を up した時にしか流れない(*1)ので、このRAでついたアドレスを利用すると、valid lifetimeが過ぎたあとに通信ができなくなる危険性がある（なにも設定変更していないと、３０日後）

http://www.cisco.com/c/en/us/td/docs/ios/ipv6/command/reference/ipv6_book/ipv6_07.html

***1 最近ではRFC7559ができた**

ipv6 nd ra supressの盲点（Cont)

- 古いIOSでは “all” がなく、下記のようなACLをI/Fに適用することで、フィルタリングする必要がある。

```
ipv6 access-list RS-Filter
deny icmp any any router-solicitation
permit ipv6 any any
```

下記より引用
シスコサポートコミュニティ
「IPv6 RAの Suppress動作について」
https://supportforums.cisco.com/ja/document/100306

IPv6トラブル事例と防止策について

BroadBand Tower, Inc.

- DNS関連
- ネットワーク
- **Path MTU Discovery Blackhole問題**

Path MTU Discovery Blackhole

BroadBand Tower, Inc.

- バグに起因しないネットワークトラブルのほとんどが、Path MTU Discovery Blackhole問題

Path MTU Discoveryおさらい

Path MTU Discoveryとは(1)

BroadBand Tower, Inc.

- IPv6 では中継ノードでフラグメントしない（始点ノードが実施）
  - IPv4 ではルータ等の中継ノードがフラグメントを実施
  - 送信パケットに対する ICMPv6 Error Message を受信時、MTU を変更
    - 最初のリンクのMTU が初期値
    - ICMPv6 Packet Too Big Message 受信時、始点ノードでフラグメントして再送
  - IPv6最小MTU は、1280byte
    - L2 SWのMTUにひっかかった場合は破棄される
    - Path MTU Discovery の実装が難しいノードは 1280byte 固定

Path MTU Discoveryとは(2)

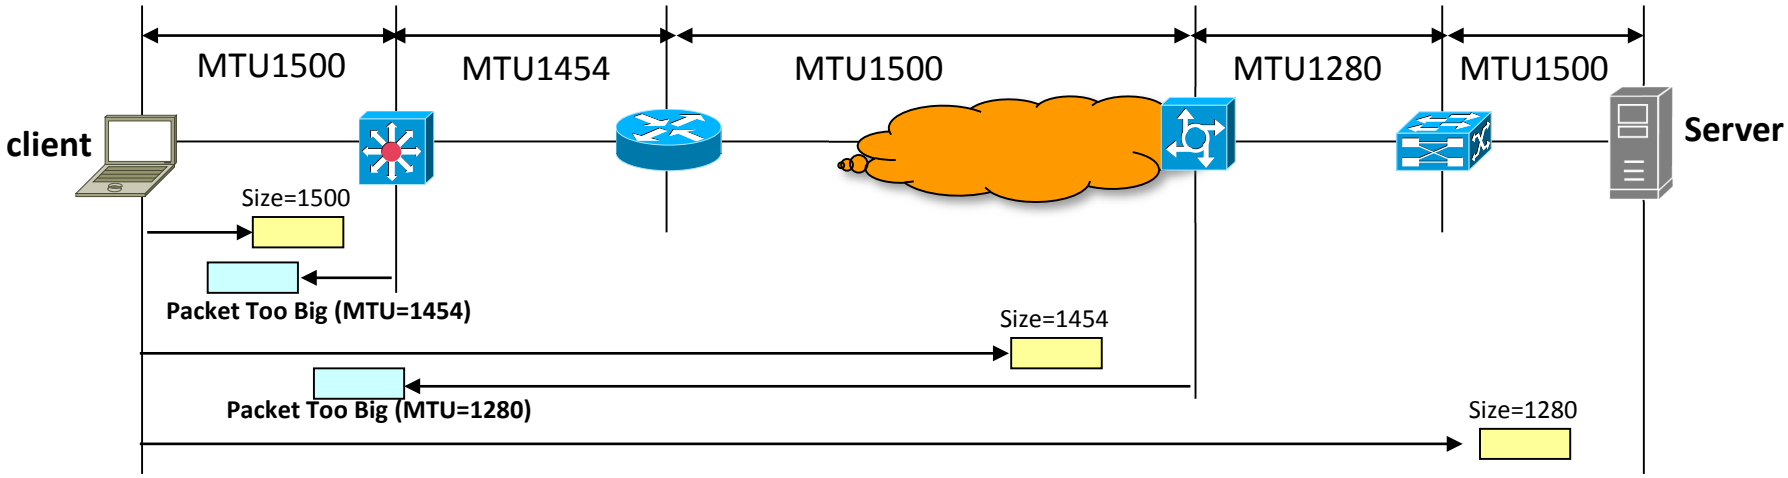

Path MTU Discoveryとは(3)

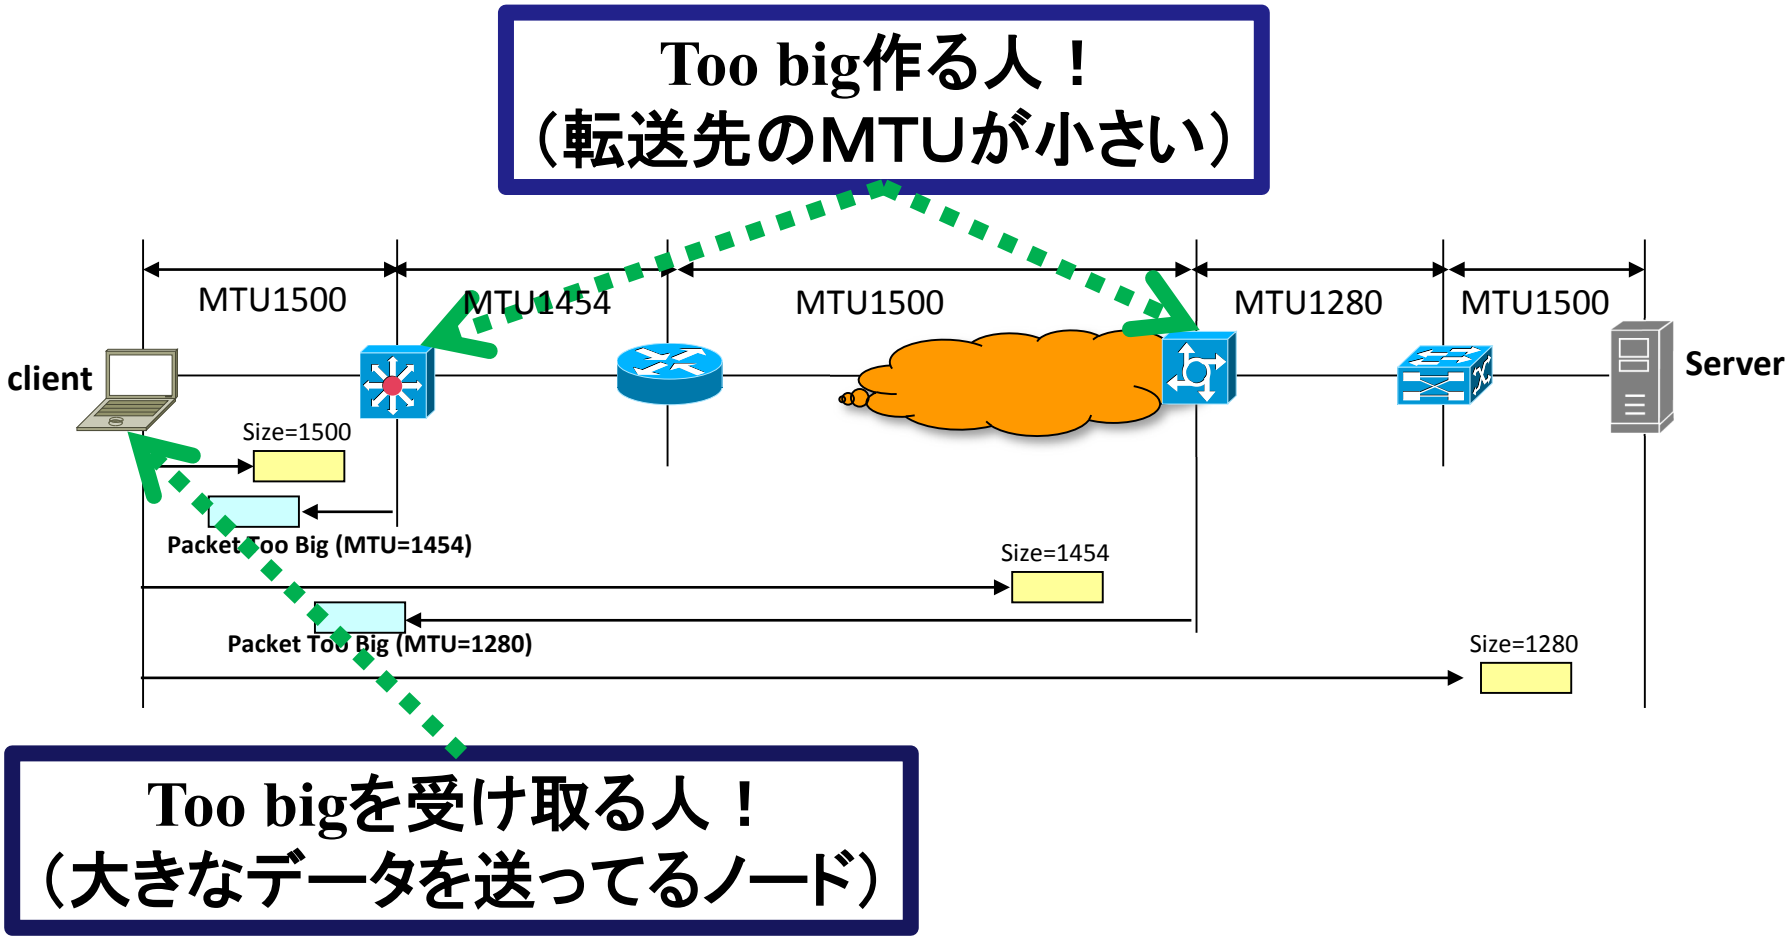

Blackholeの主な原因

1. Too big パケットが作れない
2. Too bigパケットが受信・転送できない

Too big 受け取るのはだれ？

BroadBand Tower, Inc.

- コンテンツを送信する側
  - ウェブサーバ
  - メール送信者(大きな添付ファイルとか）
  - Dropbox的ななにか

PMTUD Blackholeなぜ困る？

BroadBand Tower, Inc.

- IPv6のパケットは、IPv4で言えば、すべてDFビットが立っているパケット。つまり経路上のルータがパケットをフラグメントすることは禁止されており、PMTU Dicoveryが動作することによるパケットの再送を期待している。

  Too bigが届かないと、通信ができない！

※なおTCPのセッションは張れるため、前述した Happy Eyeballsでは対処できない

つまり…

Too bigを必ず届ける、受け取る！

or/and

Too bigを発生させない！

がIPv6通信には必須

PMTUD Blackhole demo

BroadBand Tower, Inc.

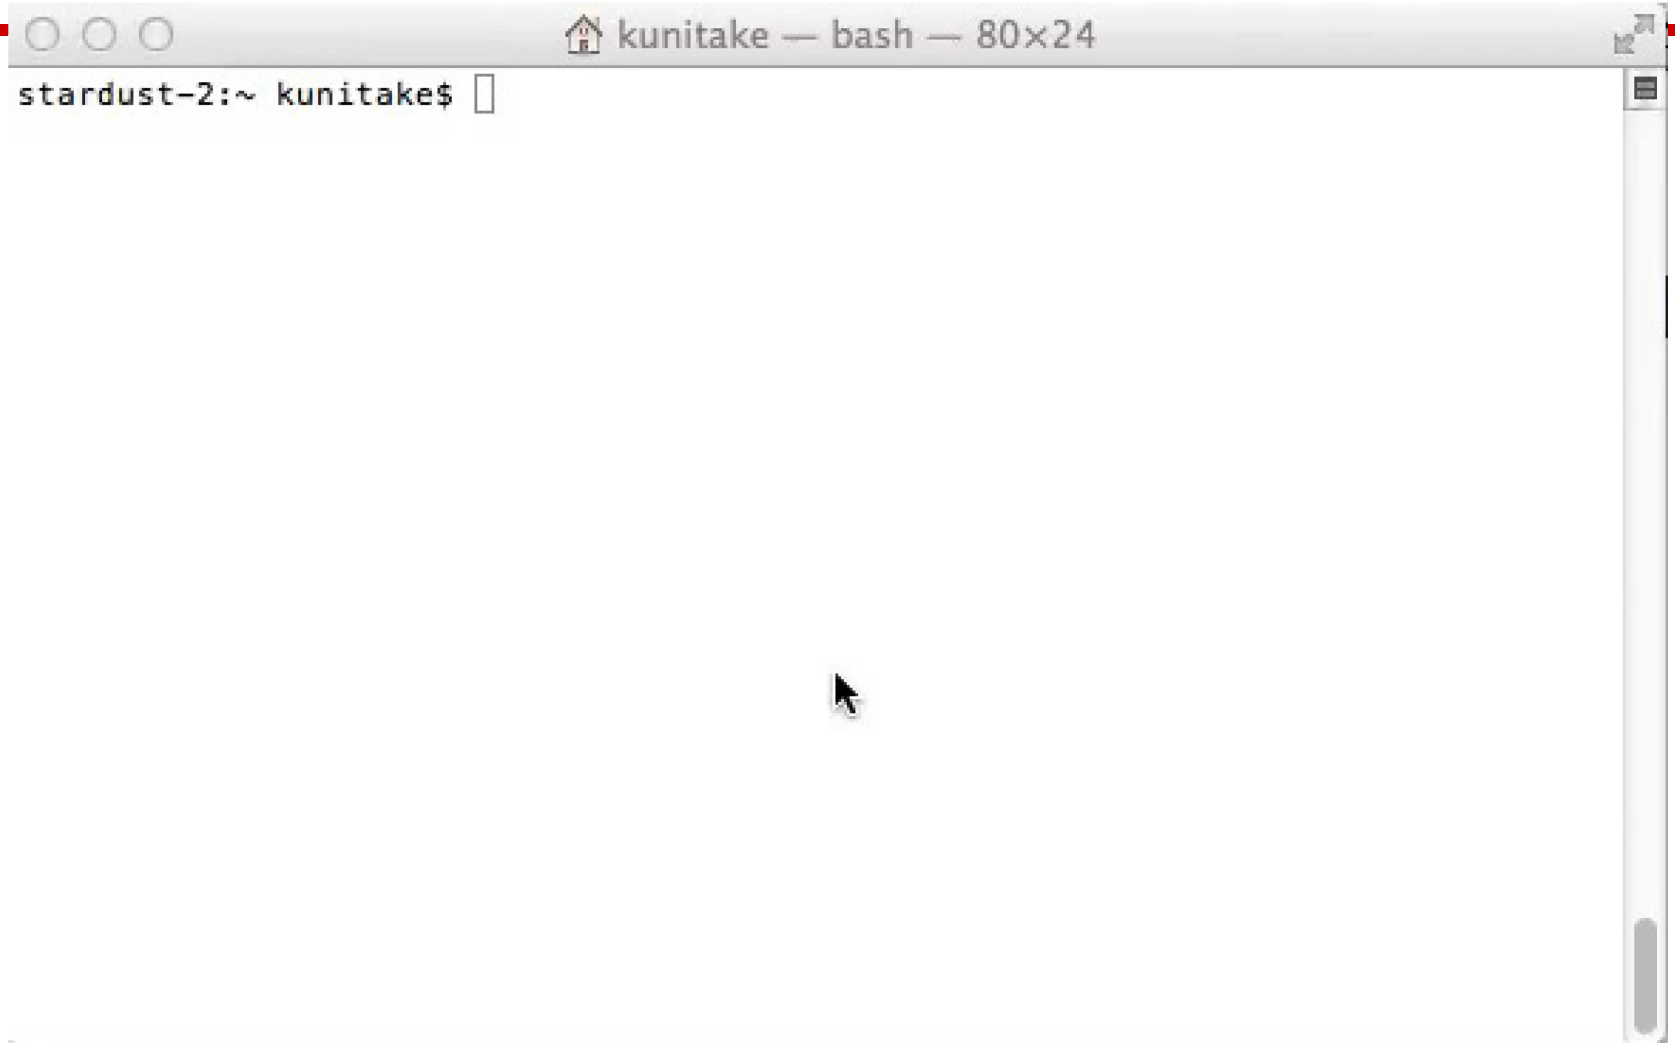

PMTUD Blackhole簡易切り分け

BroadBand Tower, Inc.

- MTUが小さくなる環境構築
  - クライアント環境で以下を実行しテスト

```
# ifconfig en0 mtu 1280
```

意図的にTCP MSSによる調整が発生させる。
これで問題解消する場合は、
Path MTU Discovery Blackholeが原因

TCP 3way handshake復習

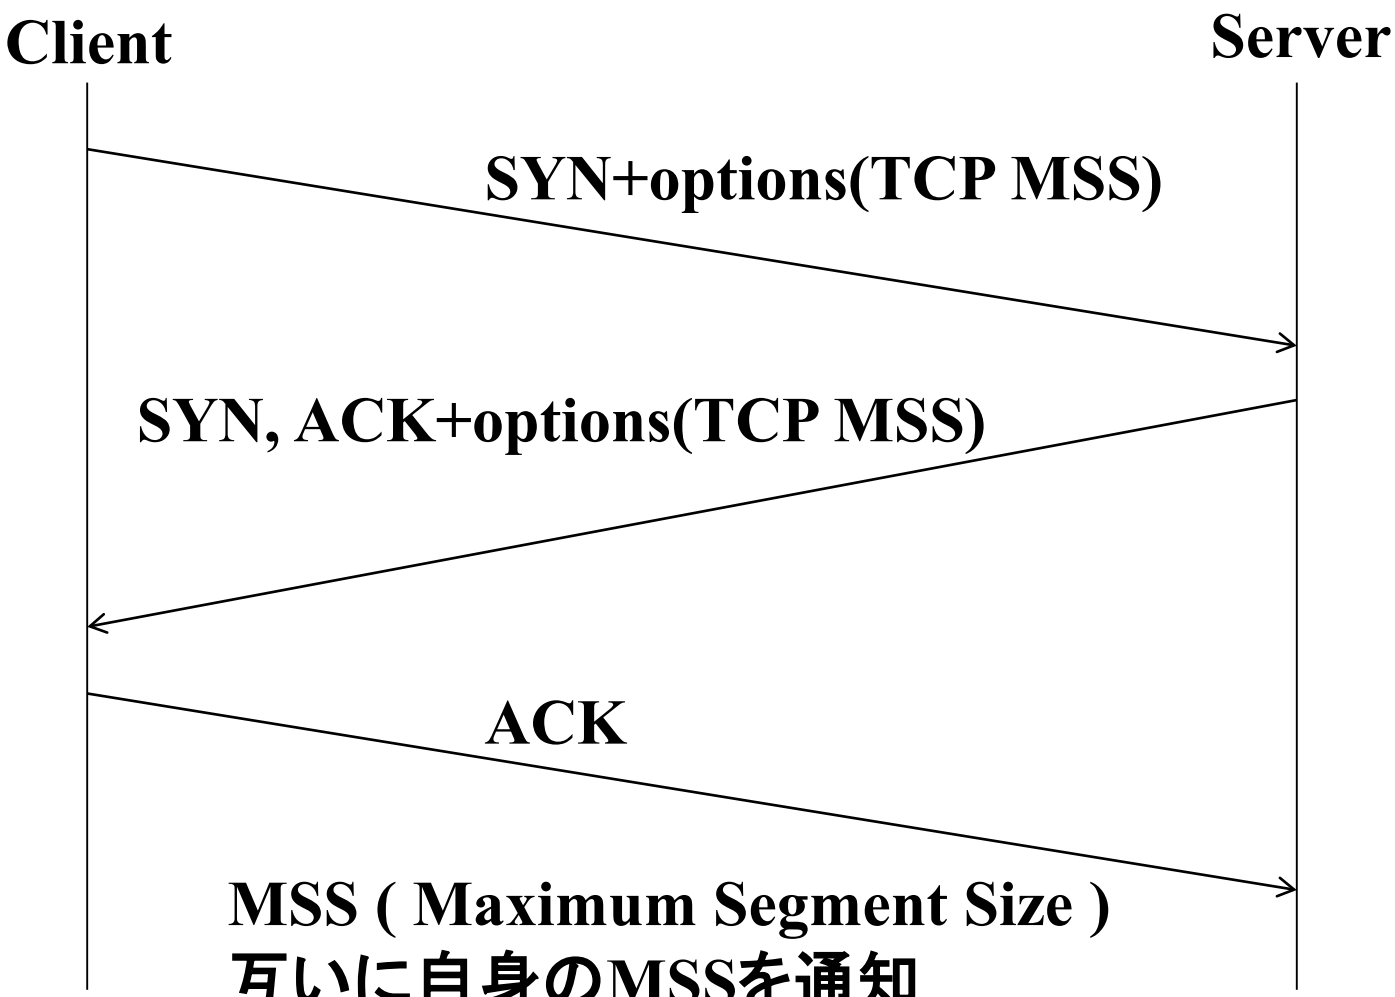

起きてしまったら、ここを疑え！

- L3’s icmp rate limit
  - L3装置では、ICMPに関してレートリミットがかかっているものがあり、リミットを超えるとTo bigを返せなくなる
- Firewall Policy
  - 本来通信に必要なICMPv6パケットまで落としてしまって、通信障害を発生させてしまっていないか
- LB構成でToo bigがちゃんとエンドに届くか
- ネットワーク構成
  - Anycastを利用していた場合、too bigが適切なサーバに転送されるか

ここを疑え！

- 頑張っちゃって link local addressのみでネットワーク作り、かつ異なるMTUサイズを混ぜていないか

  RFC4291: Routers must not forward any packets with link-local source or destination addresses to other link.

- IPS/UTMやステートを見ないパケットフィルタリング

補足：Firewallポリシーについて

- 実はFirewallのポリシーでは、事実上、Too big は落とせない（フロー上、自動的に許可される）

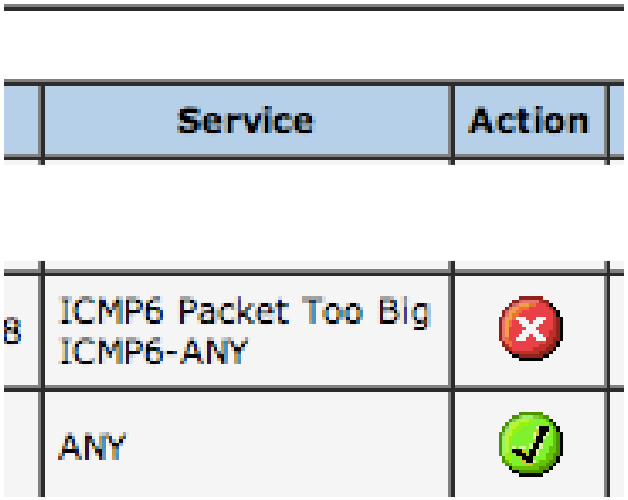

なんと、こんな設定書いてもToo bigは落とせない…

iptables/ip6tablesでも

BroadBand Tower, Inc.

-A INPUT -m state ¥

--state ESTABLISHED,RELATED ¥

-j ACCEPT

RELATED

meaning that the packet is starting a new connection, but is associated with an existing connection, such as an FTP data transfer, or an ICMP error.

UTMでのDrop例

[00001] 2014-10-17 21:00:00 [Root]system-critical-00436: Large ICMP packet! From 2001:db8:ffff::117 to 2001:db8::80, proto 58 (zone Untrust, int ethernet0/1). Occurred 6 times.

- [ScreenOS] Large Size ICMP Packet (size > 1024) in IPv6 environment.

  http://kb.juniper.net/InfoCenter/index?page=content&id=KB26473&actp=RSS
  （http://juni.pr/QJCruH）

  多くのICMPパケットは大きくないため、1024バイト以上のICMPパケットを攻撃パケットや Loki (ICMP Tunnel)の通信などとみなす。

なぜひっかかるのか？

3.2. Packet Too Big Message

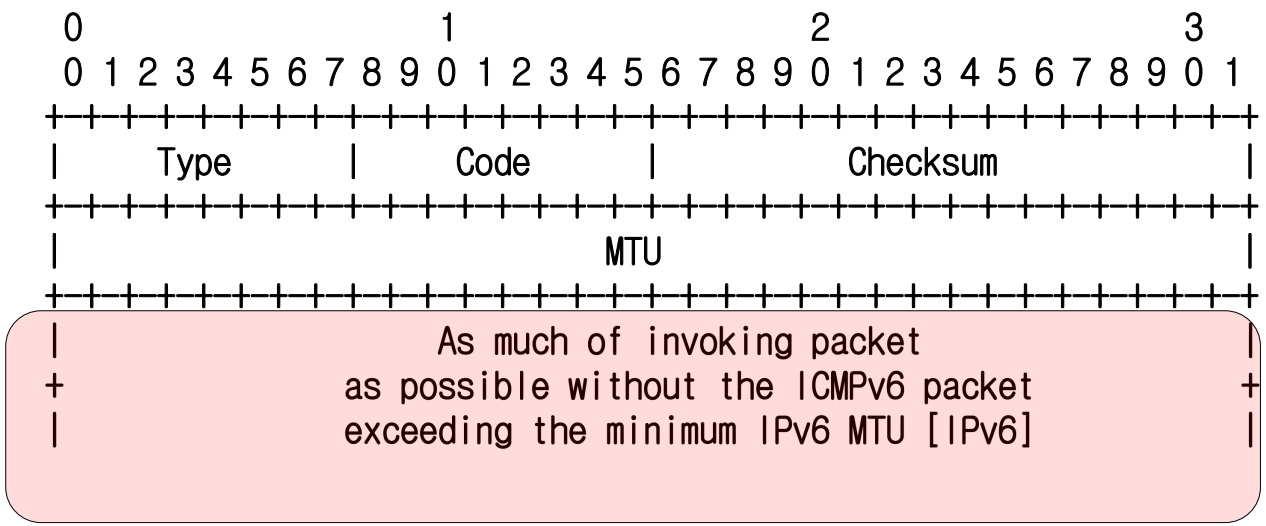

- 1280byte以下であることは仕様で決まっているが、どこまでパケットを頑張って詰め込むかは、実装依存

構築時の注意点

BroadBand Tower, Inc.

- Path MTU Blackhole問題対策
  - サーバセグメントのMTUよりもバックボーンのMTUを小さくしない
  - Too big を適切に転送できる構成であるかに注意する。できないなら、サーバのMTUは1280とするか(UDPを利用していないケース)、使っていないなら、適切にtoo bigを転送できるネットワーク構成に変更
  - ステートをみないパケットフィルタリングを利用しているのであれば、Too bigを通すように設定する。

サーバ環境に対する模擬テスト環境

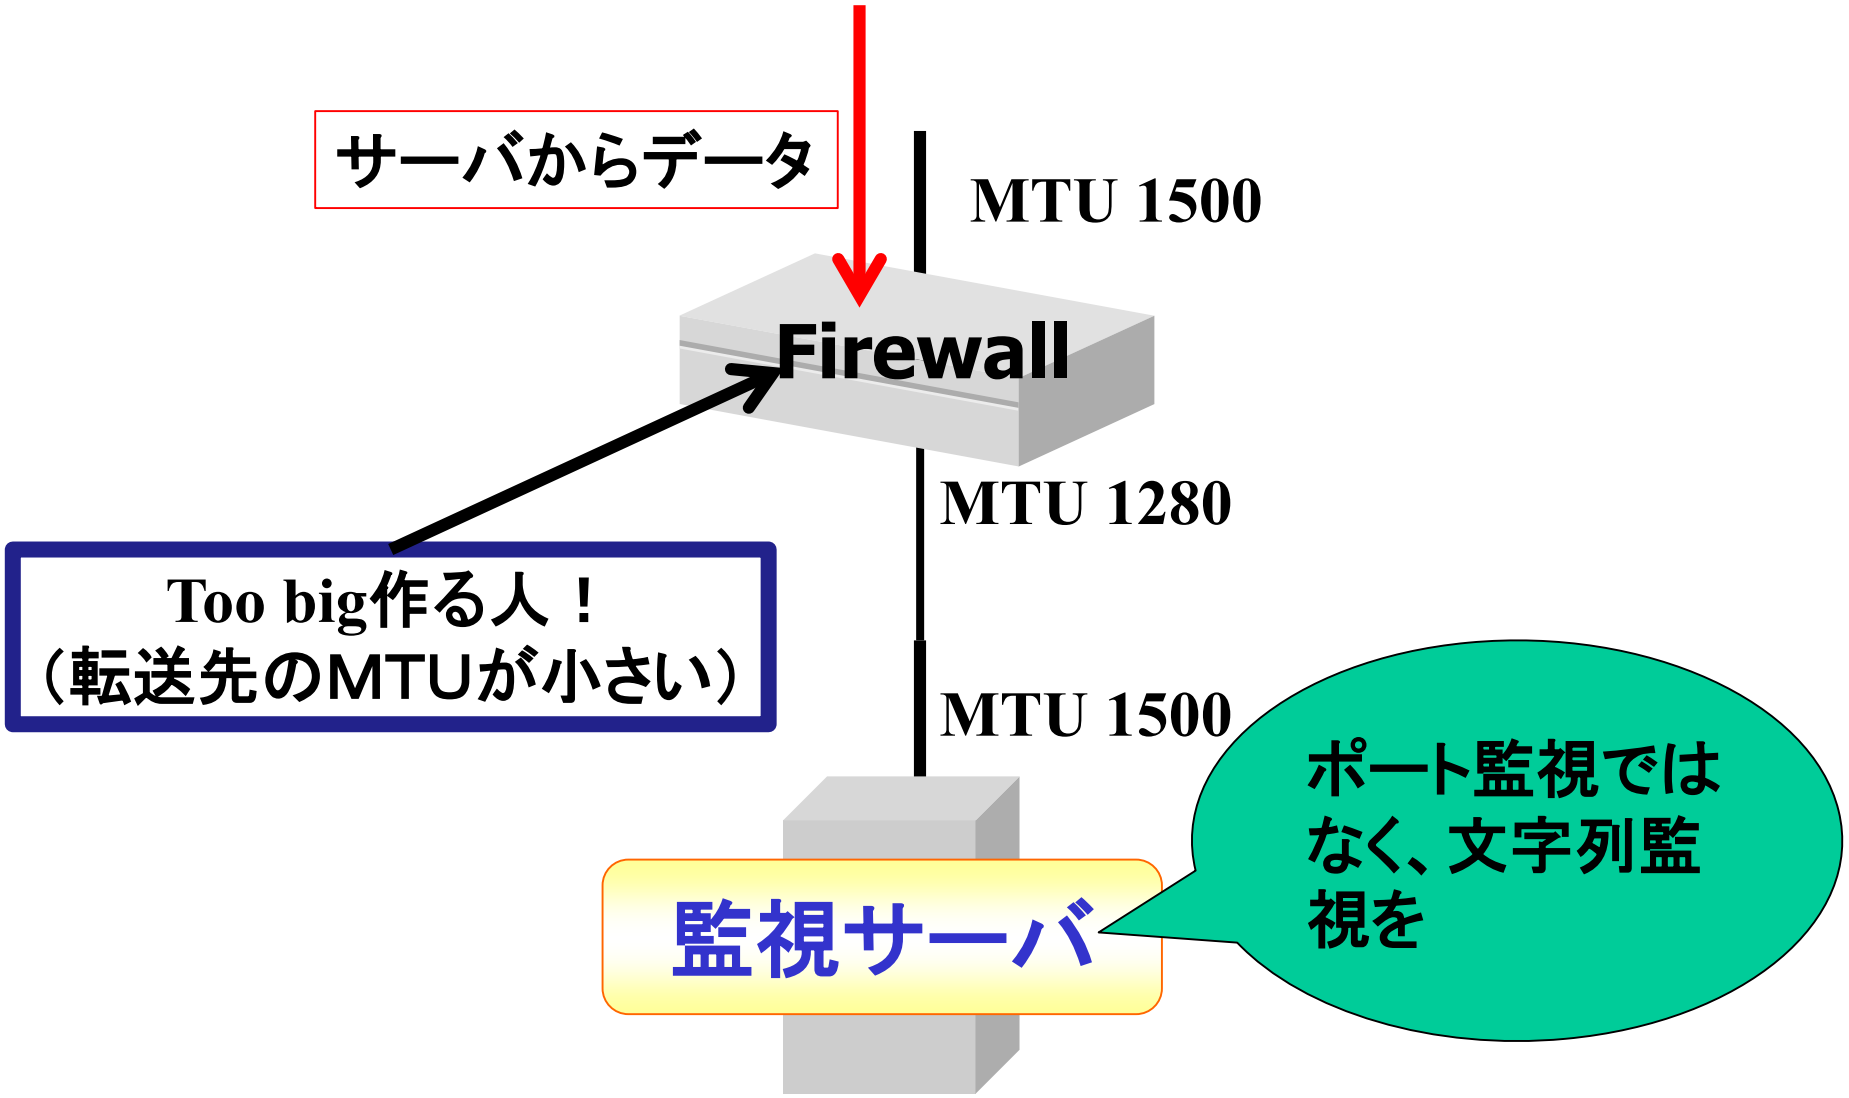

Q&A?

BroadBand Tower, Inc.