サーバ負荷分散

～仕組み、サイトの構築事例、技術動向～

泊 正和 http://www.netone.co.jp/
ネットワンシステムズ株式会社
2005年12月

Agenda

前半

- 負荷分散の概要
  - 必要性
  - 負荷分散装置とは
  - 導入によるメリット
- 負荷分散装置の基礎
  - 分散アルゴリズム
  - ヘルスチェック
  - セッション維持
  - 基本的な構成
- 分散技術の利用動向
- 負荷分散装置の進化

後半

- 構築のポイントと事例
  - 要件の整理
  - 構成の検討
  - 冗長化設計
  - HTTP 負荷分散例
  - 機器の参考設定例
  - HTTPS負荷分散例
  - その他の負荷分散
- 性能評価の考え方
- データセンタ構成例

負荷分散の概要

背景 #1

インターネットシステムに求められる性能

- 高速なレスポンス
  - アクセス集中によるレスポンスの低下を防ぐ
  - 8秒ルールを守る（合言葉と化しているが、実感としてはブロードバンド普及でユーザの要求はより厳しい）
- 高い耐障害性
  - サイトの長時間にわたるシステムダウンはビジネスの損失に直結する
  - 場合によっては損害賠償問題に発展することも？
  - SLA（サービス品質保証）の発想が浸透してきている

背景 #2

単一サーバによる運用環境の問題

- ユーザ数の増加
- 大容量コンテンツ
- 重要なサービス

→ アクセス、トラフィックの増大よるレスポンスの悪化
ダウン時の損害大

↓

・サーバ能力が限界に到達
・耐障害性の欠如

↓

単一サーバによる処理の限界

サーバ負荷分散の必要性

サーバ能力、耐障害性の限界に直面

対策: サーバの強化（メモリ、CPUのアップグレード）

問題点: 一時しのぎに過ぎず、頭打ちになる
増強時にダウンタイムが発生する
障害時間の問題は解決されない

より冗長性、拡張性、柔軟性に優れたソリューションの要求

↓

Server Load Balancing

負荷分散の実現手法

幾つかの実現手法がある。

- DNS によるラウンドロビン
- サーバのクラスタ化
- 負荷分散装置の導入 (本稿の対象)

DNSラウンドロビン #1

- 従来より使われている、一般的な手法
- クライアントからのホスト名の名前解決要求に対して、DNSサーバが IP アドレスのリストから一つを返す。
- BIND 等の、ゾーン定義ファイルの編集にて実現する。

```
www.example.com. IN A 192.168.100.1
www.example.com. IN A 192.168.100.2
www.example.com. IN A 192.168.100.3
www.example.com. IN A 192.168.100.4
```


DNSラウンドロビン #2

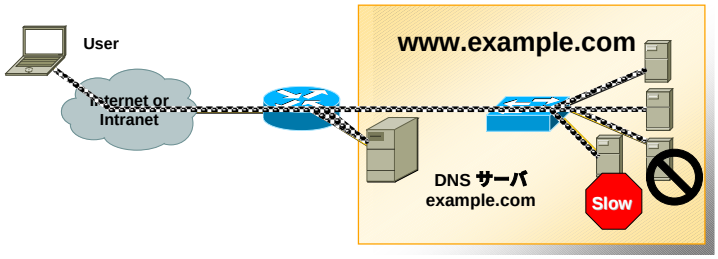

- ローテーションの結果、負荷の偏りが発生しやすい。
- サーバの障害検知は原則できない。
  - DNS も日々進歩しており、将来は現状よりも改善されるかもしれない。例えば RFC2782 では SRV レコードの定義があり重み付けなどが可能に。ただしクライアント側の追従も必要。

サーバのクラスタ化

- Microsoft Windows
  - Windows 2000 Advanced Server 等のサーバ製品にてネットワーク負荷分散 (NLB) 機能を提供。
- Linux
  - Linux Virtual Server(LVS)というオープンソースの仕組みが利用できる。
  - Ultra Monkey
- 専用装置を必要せず、導入時の低コストが一つの特徴。ただし導入時には分散可能サーバ台数や、細かなチューニングの可否など、（専用装置も同様ですが）サイトの要件と見合うか要検討。

サーバ負荷分散装置とは？

Server Load Balancing

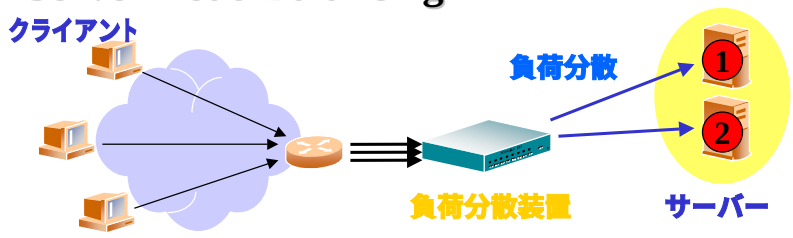

- SLB (Server Load Balancing) とも呼ばれる
- www などのアクセスを動的に複数のサーバへ配信する処理および技術
- 負荷分散装置は、ロードバランサ、L4/L7スイッチなどと呼ばれる (L4,L7の境界はあいまいな面も)

負荷分散装置の導入メリット

SLBによって得られる3つの優位性

- 柔軟性
- 高可用性
- 拡張性

インターネットシステムのニーズである
[高速なレスポンス] と、[高い耐障害性] を実現。

負荷分散装置の導入メリット①

柔軟性

- 随時サーバの追加と撤去が可能
- 多彩なアルゴリズムによる、柔軟な負荷の割り振り
- メンテナンスの容易性

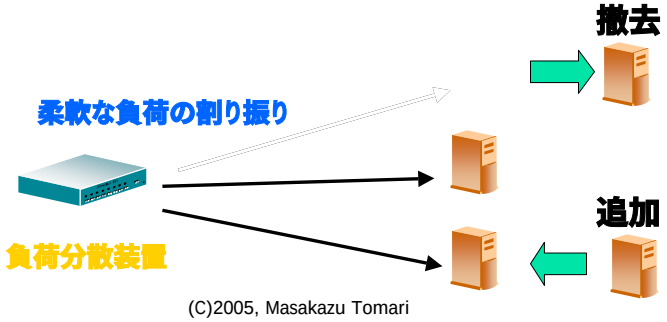

負荷分散装置の導入メリット②

高可用性

- サーバに対してヘルスチェックを行い、割り当てローテーションをダイナミックに変更する
- 自身の冗長構成により耐障害性を持つ

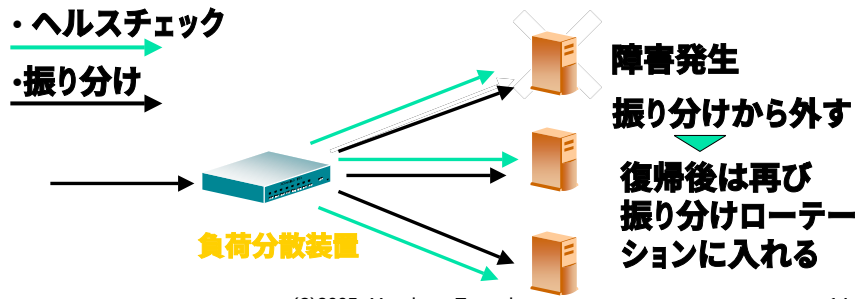

負荷分散装置の導入メリット③

拡張性

- サイトの処理能力増強は、サーバを追加するだけでよい。
- 一般的に、少数のハイエンドサーバの導入よりも、多数の小型から中型サーバの導入の方が、安価であり経済的効果も大きい。

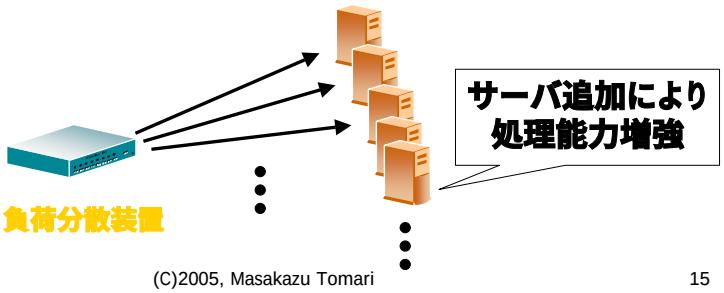

サーバ負荷分散のデメリット

- (当然ですが)サーバ台数の増加に従って、管理コストとメンテナンスの負荷も増大する。
- 昨今ではウィルス対策などで、パッチあて作業に追われることもしばしば。台数が多いと処理もたいへん
  - 負荷分散装置で、一台ずつサービス停止にしてパッチの適用可否を探りながら作業することは可能と思われる。
- 導入によるメリットとのトレードオフの面がある。サービス向上の観点からは、むしろメリット面が大きいのでは。

サーバ負荷分散概要まとめ

- インターネットシステムのニーズは高速なレスポンス と高い耐障害性である。
- サーバ負荷分散 (SLB) はこのニーズを柔軟性、高可用性、拡張性の三つの優位性によって実現する。
- サーバ負荷分散 (SLB) とは www などのアクセスを動的に複数のサーバへ配信する処理および技術である

負荷分散装置の基礎知識

負荷分散装置の機能 #1

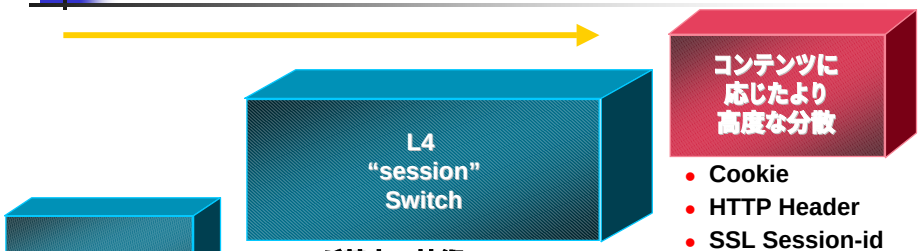

- Cookie
- HTTP Header
- SSL Session-id
- URL

- NAT が基本の技術
- IP アドレス、TCP/UDP ポート番号による分散
- コネクション情報の維持
- リアルサーバのヘルスチェック

- Switching on MAC address, VLANs
- IP Routing
- 802.1 P/Q

- 高速化を狙い、スイッチングハブ型のアーキテクチャを持つ負荷分散製品が増えてきた。
- L2/L3 の機能に加えコネクション管理を行い複合的な機能を提供する

(C)2005, Masakazu Tomari 19

負荷分散装置の機能 #2

- クライアント～サーバ間の個々のコネクションを管理する。NAT,MAC アドレスの変換が主な機能。
- より上位層(アプリケーション)に近い部分、HTTP では URL や cookie、HTTP ヘッダの内容に応じた分散機能を各製品とも実装している。基本機能の差は少ない。
- コネクションを管理する以上、L2-L3 Switch 等と同等の構築手法では不足がある。それらに加え、(例えるならば) ファイアウォールの導入に近い検討事項がある。
- 導入にあたって、通過プロトコルのフロー整理が必要。TCP/IPのポート番号やIPアドレスだけでは不足が多い。

(C)2005, Masakazu Tomari 20

SLBを構成する要素 #1

- Virtual IP (VIP)
  - 仮想IP (VIP) は、実在しない仮想的なサーバ (Virtual Server) の IP である
  - トラフィックの配信先として、最低でもひとつの本物のサーバ (Real Server) が各 VIP に割り当てられる
  - クライアントはサービスを利用するため VIP に対してアクセスする

SLBを構成する要素 #2

- Real Server
  - 実体として存在しているサーバのこと
  - Virtual Server（仮想サーバ）と対応して Real Server（実サーバ）と呼ぶ
- Real IP (RIP)
  - Real Server（実サーバ）のIPアドレス
  - Virtual IP (仮想 IP) に対応して Real IP (実IP) と呼ぶ

SLBを構成する要素 #3

- Group
  - グループという用語は、ベンダにより異なる概念で用いられる場合がある
  - 一般的には、負荷を分散させるサーバの集団を意味する。

SLB要素、関係図

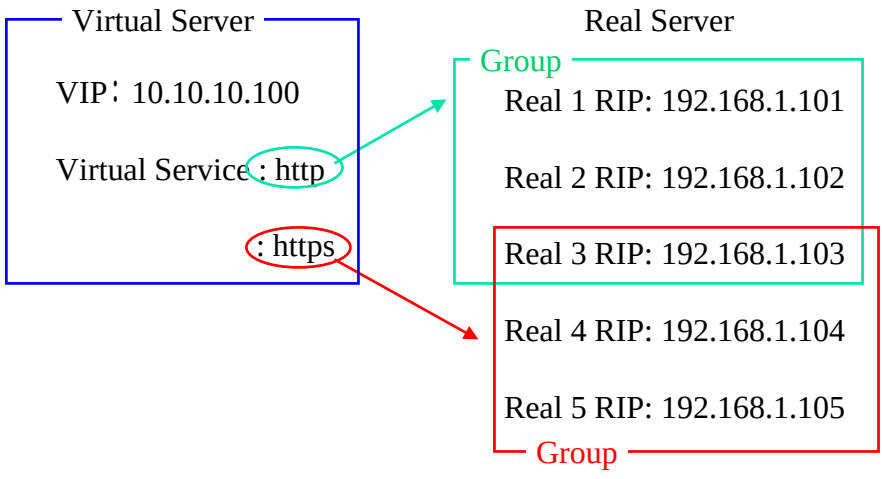

SLBを構成する要素#4

- 負荷分散アルゴリズム
  - それぞれの要求事項に応じて、特定の指標を使い、サーバグループにトラフィックを分散する方法
    - Least connection
    - Round Robin
    - Hash
    - HTTP ヘッダ (Contents)
    - 重み付け
  - 幾つかを複合的に組合わせることが可能な装置も。

負荷分散アルゴリズム①

Least Connection

- 各リアルサーバが保持しているオープン･コネクション数を計測し、コネクション数の少ないサーバへアクセスを割り振る
- この分散方式か、Roundrobin を default とする製品が多い

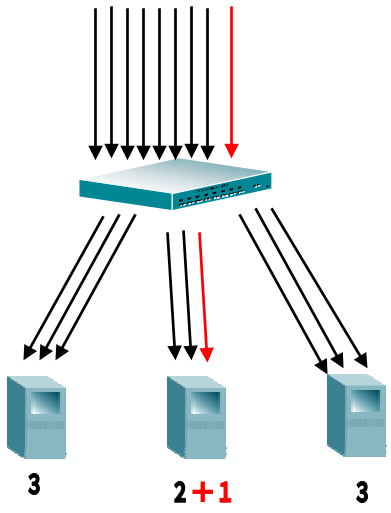

負荷分散アルゴリズム②

Round Robin

- クライアントからのアクセスを順番にサーバへ振り分ける
- 各サーバの性能差が無く、処理時間も比較的一定の場合に有効

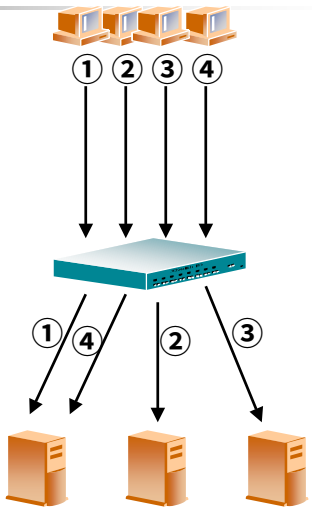

負荷分散アルゴリズム③

Hash(送信元IP)

- クライアントの送信元IPによって分散先を固定する方式。セッション維持などの目的で使われることが多い。
- 最適な分散のために、クライアントの IP やサーバの IP アドレスを材料として hash 計算を行い、分散先を決定する

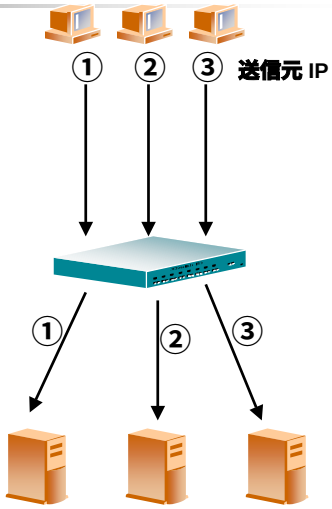

負荷分散アルゴリズム④

HTTPヘッダ(コンテンツ)

- L7レベルのアプリケーション層に近い分散アルゴリズム
- HTTP のヘッダ内容に応じて分散先のサーバを決定する
  - HTTPヘッダ：URI(URL)
  - HTTPヘッダ：user-agent
- 拡張子として*.cgi など簡易的ながら正規表現が可能
- 携帯電話、端末を識別する手段として用いられることがある。

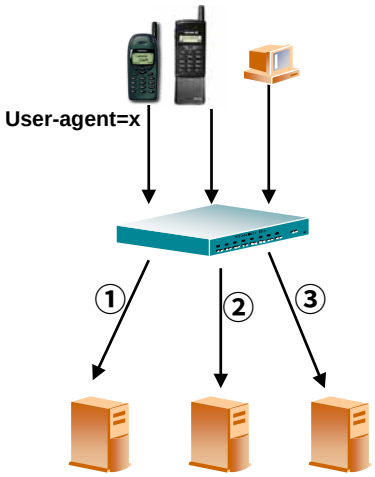

負荷分散アルゴリズム⑤

重み付け

- 各サーバへ重み付けを行い、アクセスを振り分ける
- 各サーバの性能差がある場合に有効
- 状況としてサーバを追加する時などの利用が考えられる。（あとから追加するハードの方が性能が高い、など）

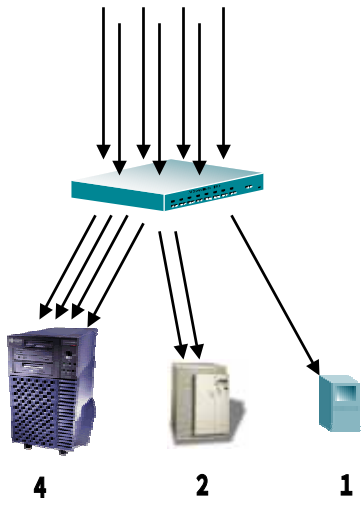

SLBを構成する要素 #5

- ヘルスチェック
  - サーバやサービスに障害が発生したことを検知して、そのサーバを割り振りローテーションから外すこと。
  - 単純なping によるものから、ポートチェック、特定の応答がサーバから返されることを調べるコンテンツチェックなど多数の方法がある。

ヘルスチェック①

Ping による障害検知

- LB より対象サーバに向けて Ping を発行する
- 応答無いサーバは、サービス対象グループから切り離す
- サーバのハードウェア障害の検知には有効だが、WWW デーモン(httpd)の停止などアプリケーション異常を知ることが出来ない。

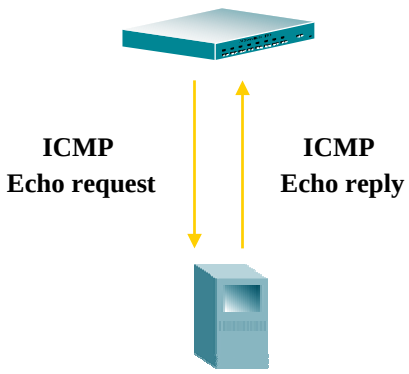

ヘルスチェック②

TCP による障害検知

- サービス対象の TCP ポート番号を使い、LB がクライアントとなってサーバとコネクション確立を試みる方式。
- Pingに比較すると精度が高まるが、アプリケーション層を意識した検査方式ではない。

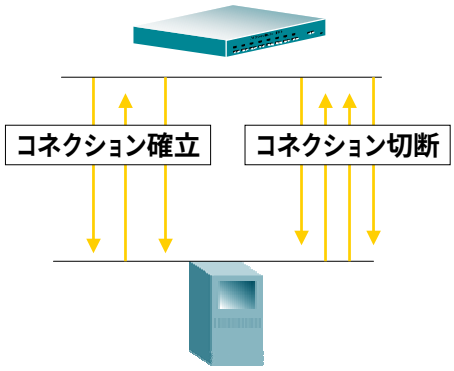

ヘルスチェック③

上位層を意識した検査

- LB が HTTP GET リクエストを発行し、サーバからの応答コードあるいは応答そのものの有無で生死を探る。
- これと似たアプローチが考えられるものはHTTP以外にもある。
  - FTP
  - SMTP
  - POP3
  - :

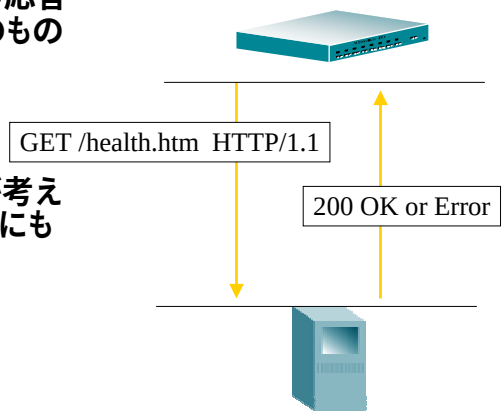

ヘルスチェック④

選択の基準、注意点

- Ping や TCP/IPのポート番号による検査方法が、装置の default となっており、管理者が気付かないケースも。アプリケーション・レベルの検査が必要なのかどうか、導入時に要検討。
- HTTP の GET リクエストを送る方法などでは、サーバ側のログが増大する可能性がある。また、ログ統計を取る時にもヘルスチェック系のログは除外するなどの注意事項もある。
- 各サービスを複合的に提供する装置では、コンテンツレベルのチェックが不可能になることも。

SLBを構成する要素#6

- セッション維持機能 (persistence)
  - スティッキー (Sticky) とも呼ばれる。
  - あるユーザのトラフィックをアクセス時に最初に接続したサーバと同じサーバに接続維持させる機能である。
  - 特にこれはWeb商店型のアプリケーションなどにおいて重要である。
  - 維持機能を実現するにはいくつか方法があるがそれぞれ一長一短がある。

セッション維持①

送信元のIP単位に分散

- クライアントの送信元IPが同一である場合に、分散先のサーバを毎回同じとする。
- Proxy やファイアウォールなどがクライアント側に存在すると、複数のユーザが NAT により1ユーザとみえてしまい、割り振りが偏る可能性が出てくる(実例あり)。
- クライアント側のネットワークが Proxy を複数使用していて送信元IPが変化する場合、セッション維持が不可能となる。
- 以上の注意点があるものの、状況が許すならセッション維持の実現は容易となる（ユーザが管理範囲内など）。

セッション維持②

cookie による分散

- サーバ側でCookieを挿入し、一度サーバへアクセスしたクライアントはブラウザを閉じるまで同一サーバへ割り振られるようにする。

Cookie Name = test

Cookie 値 = srv-000, srv-001 , srv-002

セッション維持③

SSL session ID

- SSL を分散する場合には、クライアント~サーバ間のデータが暗号化されているため、ダイレクトに負荷分散装置で処理すると制限事項がある。
- 送信元IP か、SSL プロトコルの Session-ID を識別子とする分散に限られてしまう。
- Microsoft 社のブラウザ(I.E)には、default 2分おきにSSLのセッションを再手続きしてしまうものがある。全てが該当せず、レジストリエディタにて振舞いを変更できる点はあるが、現実的には Session-ID分散の採用は難しいことが多い。
  - Internet Explorer Renegotiates Secure Sockets Layer Connection Every Two Minutes
  - http://support.microsoft.com/default.aspx?scid=kb;EN-US;265369

基本的な構成

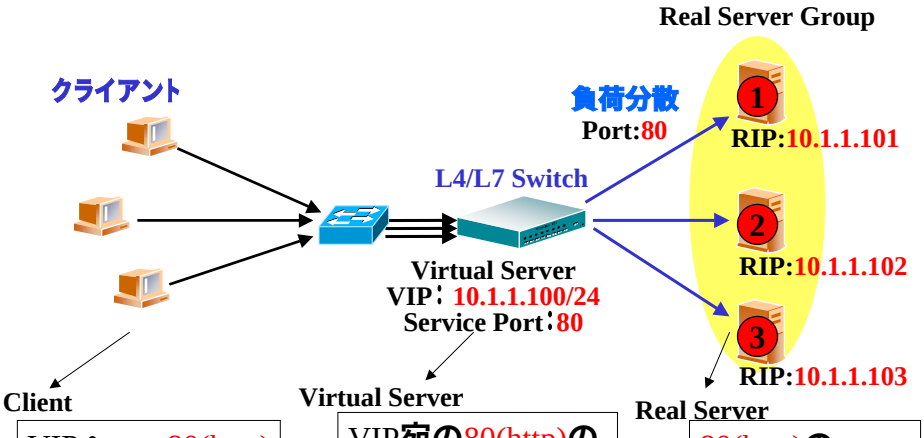

SLB の流れ

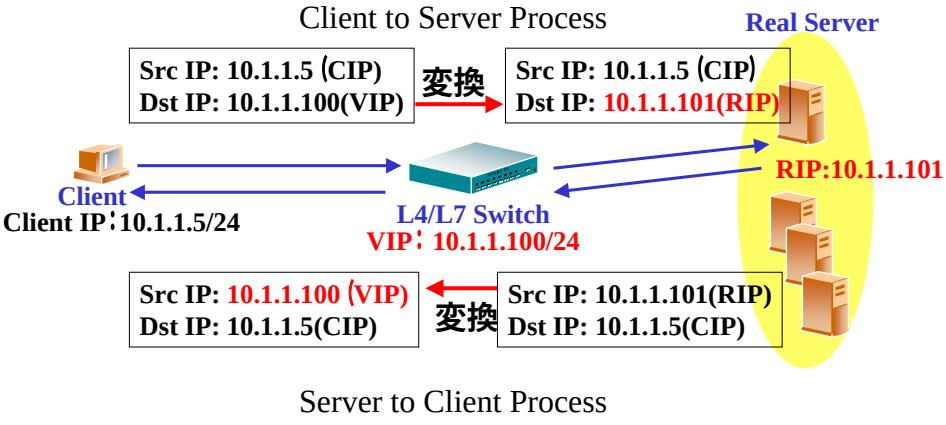

TCP/IP Connection と LB #1

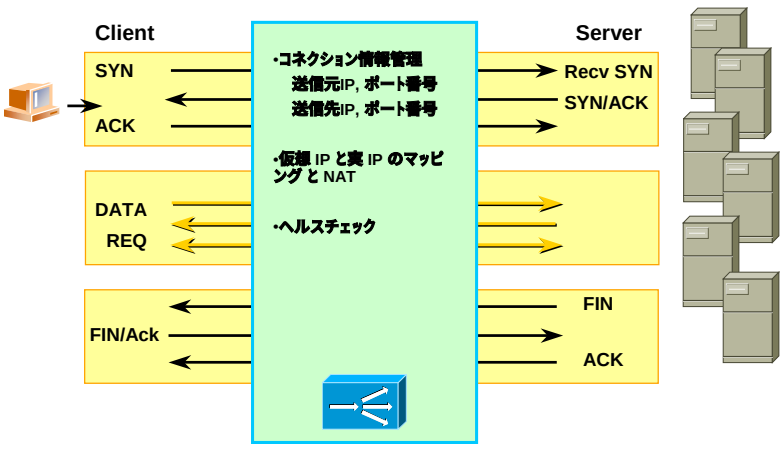

TCP/IP Connection と LB #2

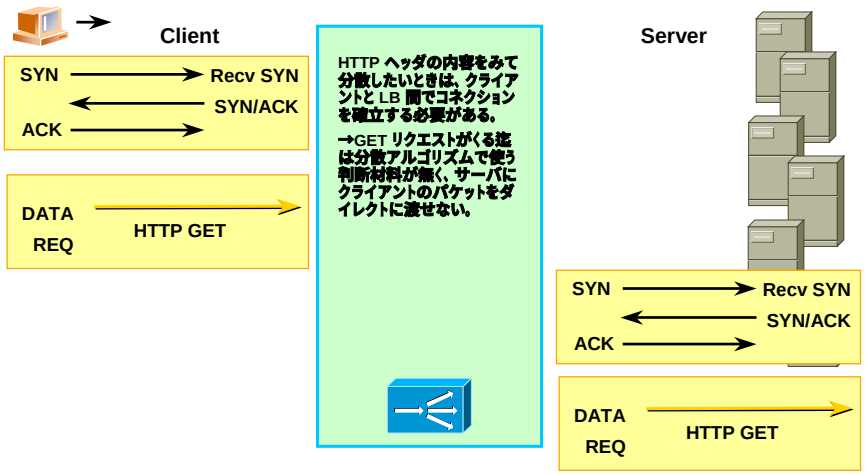

HTTP1.0

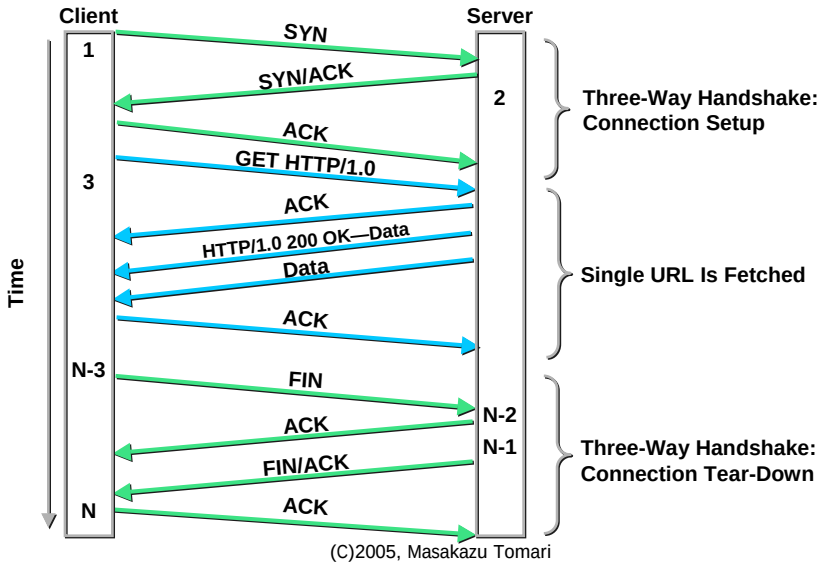

HTTP1.1

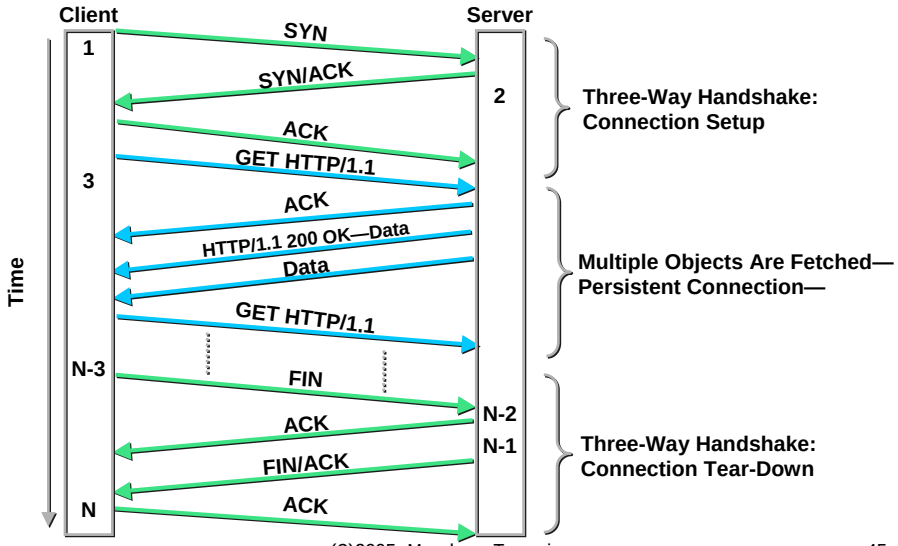

負荷分散装置の冗長化

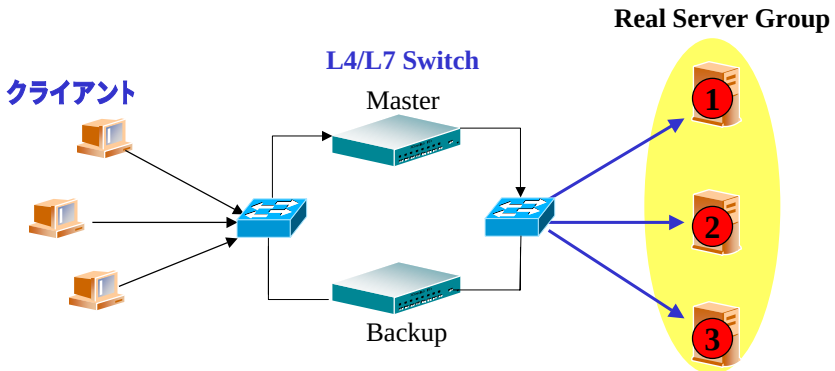

- VRRPを実装する機器のほか、メーカー独自方式を採用する機器も多い。主機と副機と副系をシリアルケーブルで接続してハード的な異常を検知する製品もある。

負荷分散技術の利用動向と負荷分散装置の進化

負荷分散技術の利用動向#1

- 「負荷分散」よりも「可用性」や「耐障害性」を重視
  - サービスを落とさない命題をクリアするための装置導入
- VoIP(IP電話)
  - SIP対応を実装する負荷分散製品が増えてきた。
  - 呼の識別に「CALL-ID」を利用する。
  - サーバの生死を上位レイヤ・レベルで検査できることも必要
  - HTTPと同じく、SIPの分散においても、ユーザの状態維持の考え方は重要なテーマ。
  - 呼制御のみならず、保留、転送といったメーカ独自の実装となる部分については、SIP製品と負荷分散製品の両方の仕様を照らしながら導入前に接続試験した方が安全。

負荷分散技術の利用動向#2

- GSLB(Global Server Load Balancing)
  - 複数サイト間でサーバロードバランスを行う。
  - BC(ビジネスコンティニュイ)。災害時等でサイト自体が運用停止しても、ビジネスプロセスを維持しようという目標の実現に、負荷分散技術を応用する。
  - DNSの動きと連動させて、ユーザのリクエストを最適なサイトへ誘導させる実装例が多い。
  - これに特化した専用の装置も存在する。
  - 日本のルーティング事情では、機能をフルに生かせない？

GSLBの例

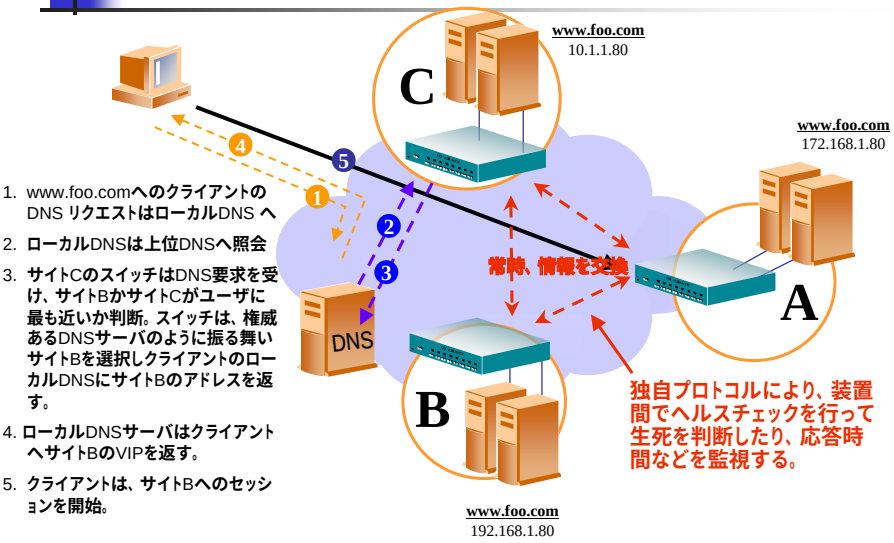

1. www.foo.comへのクライアントのDNS リクエストはローカルDNS へ
2. ローカルDNSは上位DNSへ照会
3. サイトCのスイッチはDNS要求を受け、サイトBかサイトCがユーザに最も近いか判断。スイッチは、権威あるDNSサーバのように振る舞いサイトBを選択しクライアントのローカルDNSにサイトBのアドレスを返す。
4. ローカルDNSサーバはクライアントへサイトBのVIPを返す。
5. クライアントは、サイトBへのセッションを開始。

負荷分散装置の進化

- 専用装置から統合装置への進化

Switching	Security
■LoadBalancing ■L7 Switcing ■GSLB	■SSL 暗号化･アクセラレータ ■SSL VPN ■DDoS
Optimization / Acceleation ■TCP最適化 ■HTTP圧縮	**What's Next ?**

TCP最適化 (TCP Multiplexing)

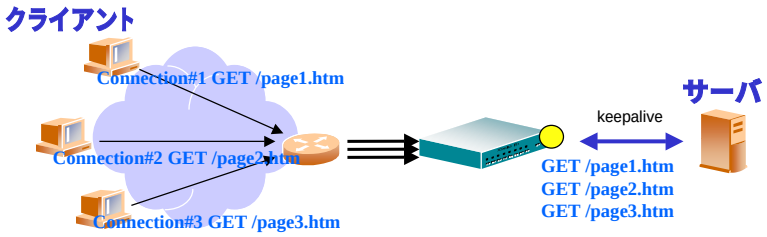

- クライアントのコネクションを負荷分散装置で束ねて、負荷分散装置がクライアントとなりサーバにリクエストを中継する。サーバの新規TCPコネクション確立、管理にかかる負担を軽減することで、全体的な性能向上を図ることが狙い。
- 負荷分散装置でコネクションが終端するため、サーバからみたクライアントのIPは負荷分散装置のIPにNATされる(分散装置とサーバ側の対応により、クライアントIPを伝達出来る場合もある)。

TCP最適化 (HTTP圧縮)

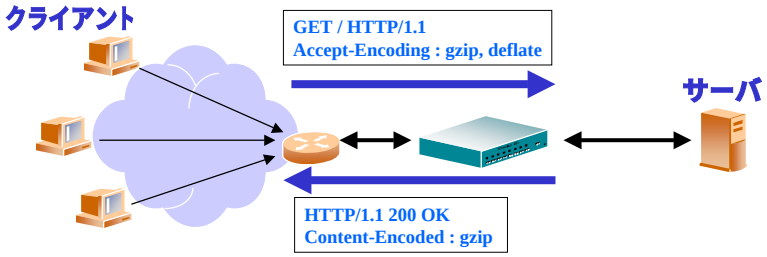

- サーバがクライアントにコンテンツを送信する前に、圧縮をおこなうことで帯域を節約する。
- Apache(mod_gzip), Microsoft IIS 等のWebサーバで利用可能だが、負荷分散装置でも機能実装される傾向が出てきた。
- クライアント側はブラウザが標準で対応していることが多い。

(C)2005, Masakazu Tomari 53

DDoSへの対策

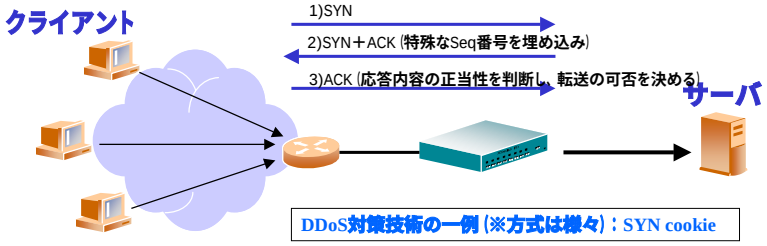

- 大量のデータや不正パケットを送りつけるDoS攻撃 (Denial of Service Attack)がさらに巧妙化したDDoS (Distributed DoS：攻撃元が分散化した DoS)攻撃が問題になっている。
- 負荷分散装置でも、サーバを保護する目的で対策機能が実装されていることが珍しくなくなってきた。(利用率はまだ低い？)
- ファイアウォールや、IDS/IDPなど専用装置との機能分担・負荷分担も一考に値する。※DDoS対策そのものが負荷となる時など。

(C)2005, Masakazu Tomari 54

構築のポイントと事例

要件の整理

- 要件の概要
  - サイトのサービス内容、クライアント(ユーザ)、サーバの情報
  - ネットワーク構成、冗長化の有無
- 通信に関する情報
  - 分散対象となるプロトコル、セッション維持の有無
  - 分散方式、コンテンツに含まれる情報
- 監視環境やアクセス制御に関する情報
  - telnet, snmp, syslog

要件の概要 #1

- 分散の対象となるものは何か
  - 機器 (WWW, Firewall, Proxy, …)
  - プロトコル(http、https、ftp、rtsp、etc...)
  - 通信フローの整理
- クライアント (ユーザ) 情報
  - 対象ユーザ (internet、社内、携帯端末、etc…)
  - ピーク時のセッション数、トラフィック量 →機器選定に影響
- サーバ情報
  - 分散対象サーバの構成(OSの種類、Versionなど)
  - 稼動しているサービス

要件の概要 #2

- ネットワーク構成
  - L4スイッチを含んだ物理ネットワーク構成
  - 各機器に割り振るアドレス
  - 他にL4switch を通過するプロトコルの有無
  - L4スイッチの Default Gateway
  - Routing プロトコルの有無
- 冗長構成
  - システム全体で何処までの冗長性を確保するか
  - L4スイッチの冗長化の有無
  - 障害復帰時の切り戻しの有無

通信に関する情報 #1

- 分散対象サービスの情報
  - 分散を行うサービス（プロトコル）の確認
  - 業務系の作りこみアプリケーション等の場合は特に、仮にHTTP/HTTPS のようなメジャーなプロトコルを使っていたとしても、通信フローの内容をよく整理した方が無難。
- セッション維持の有無
  - SourceIP による振り分けは可能か
  - cookie を用いる場合には Server側でcookieを付与できるか。

通信に関する情報 #2

- 分散方式
  - (leastconn, hash, roundrobin, ...)
  - コンテンツによる分散を用いる場合は、補足としてそれらの情報も必要(URL, cookie, etc..)
- ヘルスチェック
  - tcp, icmp, contents, script..

運用監視の指針

- 監視環境の情報
  - SNMP による監視のポリシー (取得するMIBの確認)
  - Syslog サーバの設置によるログの保存
- アクセス設定
  - 負荷分散装置への管理アクセス(telnet,web)の可否
    - よりセキュアなアクセス手段として SSH や SSLが利用可能な装置もある
  - リアルサーバへのアクセス制御の必要性
    - アクセスリストを設けることができる製品がある

構成の検討と冗長化設計

構成 #1

- 同一サブネット上に LB を含む機器群が置かれる構成
- Web Cache を置く場合はこの形態が多い
- 上位のファイアウォールなどで NAT せず、全てグローバルIPを割当てる場合はアドレスの消費数が増える

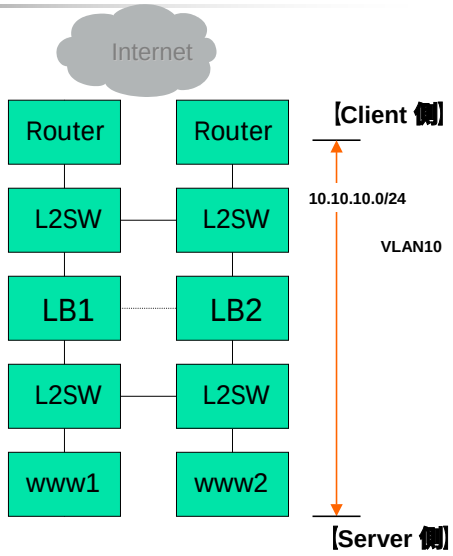

構成 #2

- LB でルーティングする構成
- サーバ群にプライベート IP アドレスを割り当て可能
- サーバ側から LB を超え外部に通信するときは、LB にて NAT の処理が必要。NAT が出来る装置が大半だが、プロトコル上の可否について都度確認した方がよい(例:FTP。逆に SMTP などはプロトコル特性から問題がおきにくい)

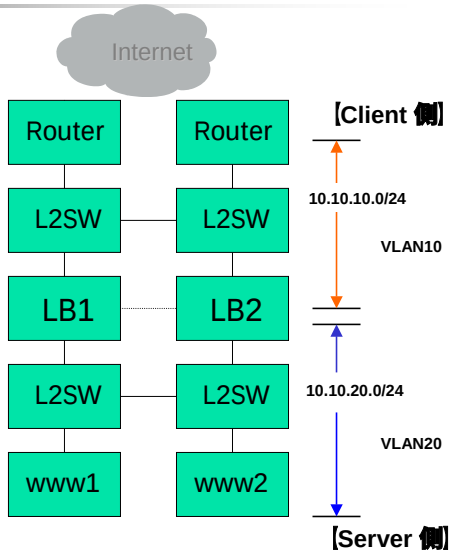

冗長化設計

- LB は VRRP をサポートしたり、独自方式を採用するものがあったり、実現方法は様々。
- VRRP を実装する機器の場合は、隣接する機器と VRID が重ならないようにする。
- ループ構成であってもSTP(スパニングツリー)を使わずに済む LB も存在する。障害時の収束を早く実現するためには、なるべく STP を使わない設計が望ましい
- Active/Standby をとるか、Active/Activeか、要件で判断。

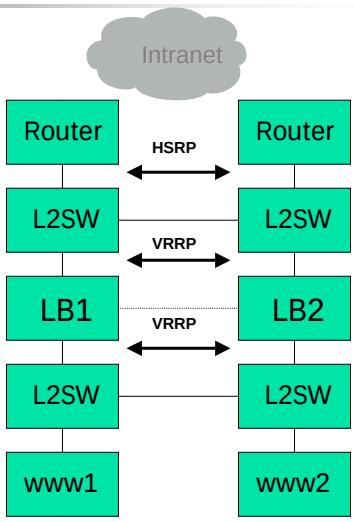

VRRP(Virtual Router Redundancy Protocol)

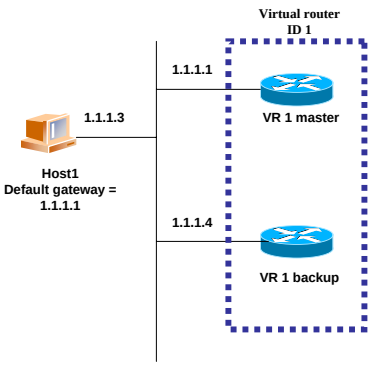

Virtual router ID 1
Virtual MAC address :
00:00:5E:00:01:**01**
Virtual IP address: 1.1.1.1

- 障害時に備えてルータのバックアップを行なうためのプロトコル。
- 仮想IPアドレスと仮想MACアドレスをもつ仮想ルータを設定する。
- ホストは、仮想ルータに割り当てた仮想IPアドレスをデフォルトゲートウェイとする。
- 障害時は、バックアップルータがマスタの仮想IP/MACを引き継ぎ、処理を継続する

VRRPによる負荷分散

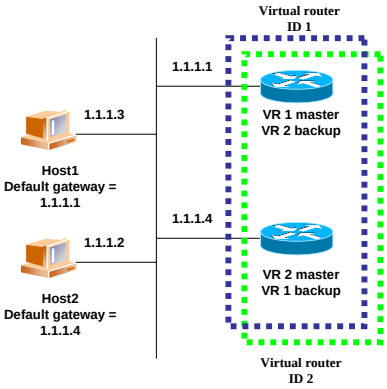

Virtual router ID 1
Virtual MAC address :
00:00:5E:00:01:**01**
Virtual IP address: 1.1.1.1

Virtual router ID 2
Virtual MAC address :
00:00:5E:00:01:**02**
Virtual IP address: 1.1.1.4

- VRRPのルータグループにはVRID という識別子がある。
- 1つのルータは複数のグループ(VRIDで区別)に所属することができるため、冗長化と同時に負荷分散を行なうことも可能。
- この動作を利用して、「Active/Active」を実現する負荷分散装置もある。

負荷分散機器の冗長化（参考例）

※Cisco社CSSシリーズの実装を元に説明します。※製品により、用語の使い方や振る舞いは異なります。

- 2つのモードがある。

1. Active-Standby(Box-to-Box Redundancy)
   - クライアント~サーバ間を1VLANにできる
   - CSS間のLinkDownは致命的な影響あり。→※注意事項

2. Active-Active(VIP Redundancy)
   - セッション同期が可能
   - LinkDownが致命的とならない。
   - さらに2つのモード。シェアドと非シェアド
   - 導入例としては、非シェアドのパターンが多い
     (後述の説明では、非シェアドを解説)

冗長化の例①

Active/Standby

バックアップ機では、すべてのサーキットがリダンダントとしてブロックされる。

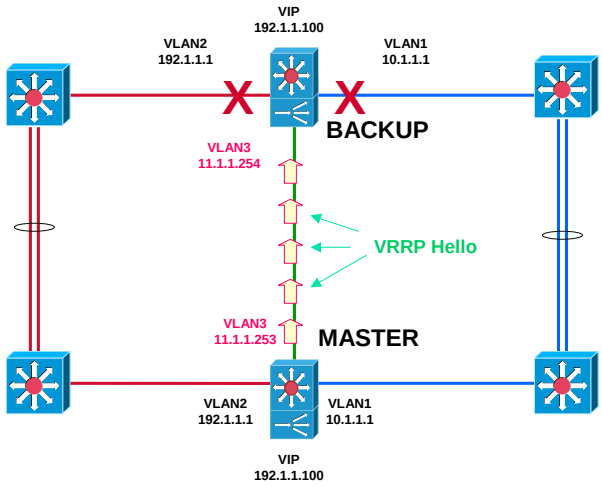

冗長化の例②

Active/Standby

Master はVRRP リンク上にヘルスチェックを送信する。

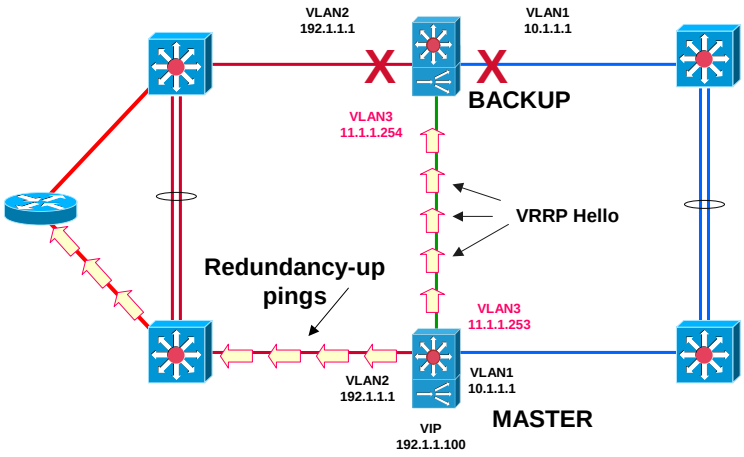

アップストリーム/ダウンストリームデバイスに向けてもヘルスチェックを行う。

冗長化の例③

Active/Active

各 CSS で Active になる方の VIP を Preempt を用いて指定する（VIP を使い分けている点に注目）。

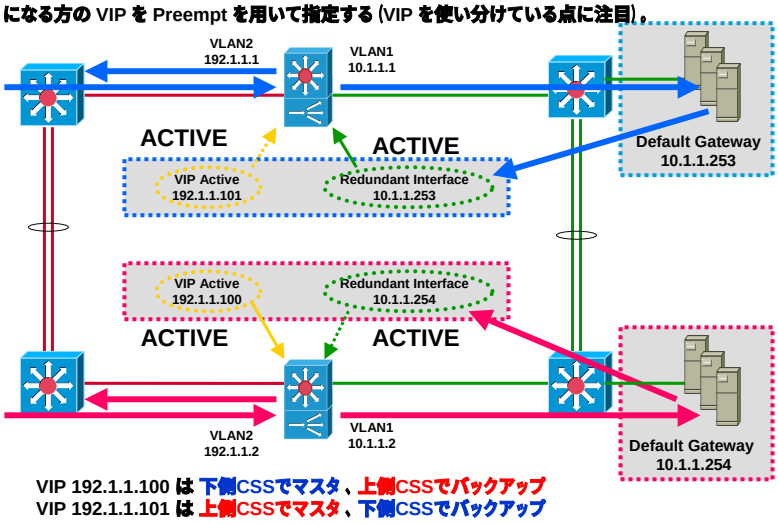

VIP 192.1.1.100 は 下側CSSでマスタ、上側CSSでバックアップ
VIP 192.1.1.101 は 上側CSSでマスタ、下側CSSでバックアップ

冗長化の例④

Active/Active

Top CSS

```
circuit VLAN1
  ip address 10.1.1.1 255.255.255.0
  ip virtual-router 1 priority 101 preempt
  ip virtual-router 2
  ip-redundant-interface 1 10.1.1.253
  ip-redundant-interface 2 10.1.1.254
  ip critical-service 1 VRRP-KAL
  ip critical-service 2 VRRP-KAL

Circuit VLAN2
ip address 192.1.1.1 255.255.255.0
  ip virtual-router 3 priority 101 preempt
  ip virtual-router 4
  ip redundant-vip 3 192.1.1.101
  ip redundant-vip 4 192.1.1.100
  ip critical-service 3 VRRP-KAL
  ip critical-service 4 VRRP-KAL
```

Bottom CSS

```
circuit VLAN1
  ip address 10.1.1.2 255.255.255.0
  ip virtual-router 1
  ip virtual-router 2 priority 101 preempt
  ip-redundant-interface 1 10.1.1.253
  ip-redundant-interface 2 10.1.1.254
  ip critical-service 1 VRRP-KAL
  ip critical-service 2 VRRP-KAL

Circuit VLAN2
ip address 192.1.1.2 255.255.255.0
  ip virtual-router 3
  ip virtual-router 4 priority 101 preempt
  ip redundant-vip 3 192.1.1.101
  ip redundant-vip 4 192.1.1.100
  ip critical-service 3 VRRP-KAL
  ip critical-service 4 VRRP-KAL
```

HTTP負荷分散

HTTP の分散 #1

- HTTP 分散はセッション管理の必要性を認識すること自体が最も重要。(HTTP 以外のプロトコルも同様!)
- 多くの場合、実現手段は用意されている(送信元 IP による分散、cookie, URL, HTTP ヘッダ等々)。
- クライアントとサーバ間の通信フローは？サーバとDB間のフローは？

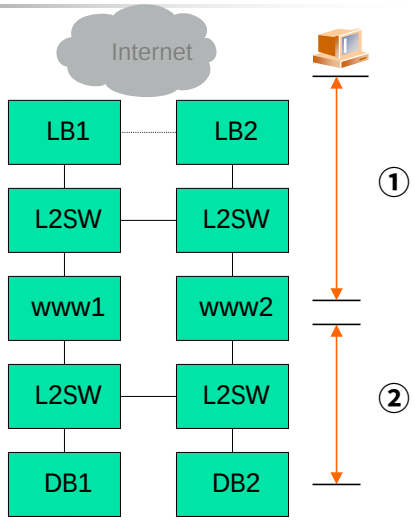

HTTP の分散 #2

- ヘルスチェックは分散対象のサーバのみ監視する方式が通例。このため、背後にDBが隠れている場合は、DBの障害検知を行なう仕組みとして別途考慮が必要になることも。
- 例えば右図にて①の範囲のみヘルスチェックの対象だと、背後の DB が障害に陥っても気付かない。
- これの回避方法として、例えば LB が www に “GET healthcheck.htm”とリクエストしたら、wwwは背後のDBにデータ照会し、その結果でLB へ応答を変える案が考えられる。何も工夫しない場合は、HTTP応答コード200を得てLBは正常とみなしてしまう。②のフローを実現すること。

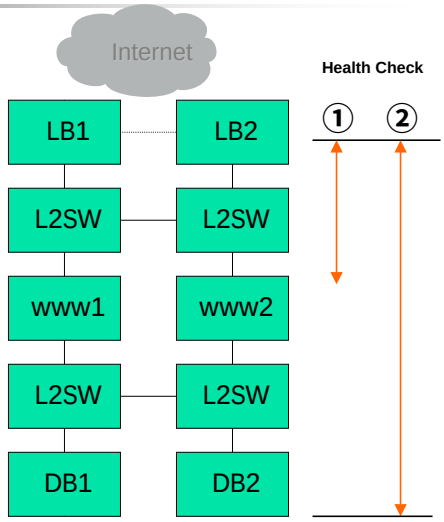

HTTP の分散 #3

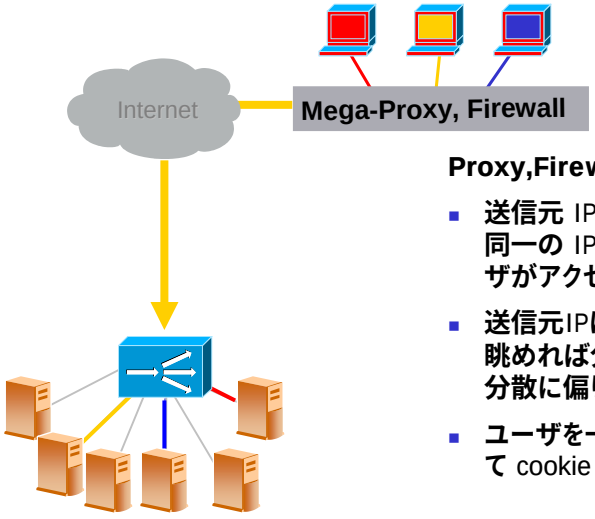

Proxy,Firewall 経由ユーザの管理

- 送信元 IP アドレスは不定であり、同一の IP でありながら、複数ユーザがアクセスしてくる状況。
- 送信元IPによる分散では、マクロに眺めれば分散できているとはいえ、、分散に偏りが生じる原因となり得る。
- ユーザを一意に識別する手段として cookie による分散を採用

設定イメージ

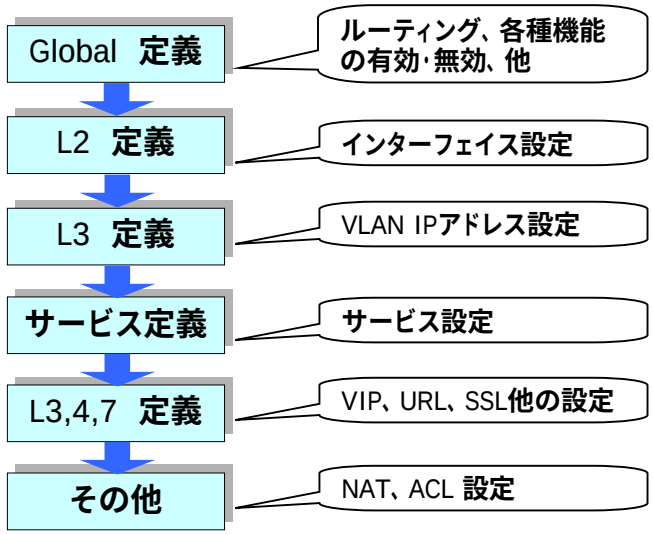

 77

設定例#1

※Cisco社CSSシリーズの実装を元に説明します。

```
configure
!************************** GLOBAL ***************************
  ip redundancy
  persistence reset remap
  acl enable
  snmp trap-source egress-port
  username root des-password ngpbdgtdfg6cacfcccngihtb1coawhxe superuser
  snmp trap-type enterprise
  snmp trap-host 10.0.0.30 netone
  snmp trap-type generic
  snmp trap-type enterprise service-transition
  snmp community netone read-only
  logging host 10.0.0.30 facility 7
  ip route 0.0.0.0 0.0.0.0 10.0.0.254 1
```

GLOBAL定義

ルーティング、各種機能の有効･無効、他

 78

設定例#2

```
!************************ INTERFACE ************************
interface e1
  bridge vlan 172
interface e2
  bridge vlan 10
interface e5
  bridge vlan 192
  phy 100Mbits-FD
  description "Server Seg"
```

L2(Interface)定義

Vlan アサイン、ポートスピード

設定例#3

```
!************************ CIRCUIT ************************
circuit VLAN172
  ip address 172.16.0.253 255.255.255.0
    redundancy-protocol

circuit VLAN10
  redundancy
  ip address 10.0.0.253 255.255.255.0

circuit VLAN192
  redundancy
  ip address 192.168.0.254 255.255.255.0
```

L3(Vlan)定義

IPアドレス、VRRP

設定例#4

```
!************************** SERVICE **************************
service S001
  ip address 192.168.0.1
  protocol tcp
  port 80
  keepalive type http
  keepalive port 80
  keepalive uri "/alive.html"
  active
!************************** OWNER ***************************
owner example.com
  content VIP001.http_rule
    vip address 10.0.0.1
    protocol tcp
    port 80
    url "/*"
    add service S001
    active
```

サービス定義
サーバIP、ヘルスチェック

L3,L4,L7定義
VIP、**分散ルール**

設定例#5

```
!************************** GROUP ***************************
group NAT
  vip address 10.0.0.1
  add service S001
  active
!************************** ACL ***************************
acl 10
  clause 10 permit tcp any destination 10.0.0.1 eq http
  clause 1 permit icmp 10.0.0.254 destination 10.0.0.253
  apply circuit-(VLAN10)
acl 72
  clause 254 permit any any destination any
  apply circuit-(VLAN172)
  apply circuit-(VLAN192)
```

その他定義
NAT

その他定義
アクセスリスト

HTTPS負荷分散

HTTPS の分散 #1

- SSL(https)分散での注意点は次の通り
  - データは暗号化される。
  - ショッピングサイトなどではセキュリティ向上の目的で SSLが導入されている。一方、ショッピングカートなどの作り込みがあるサイトが常であり、何らかセッション管理が必要。しない場合は誤ったサーバへ分散される危険性がある。
  - 逆に、静的なコンテンツを単に暗号化するページの参照には特に不都合は生じない。
  - Session-id による分散は多くの場合において使えない。

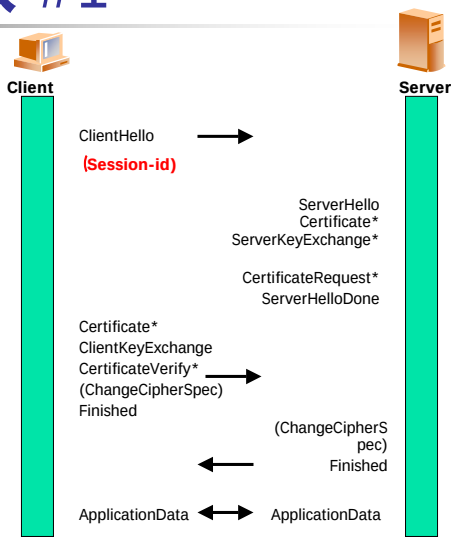

HTTPS の分散 #2

- LB にてセッション管理の幅を広げる為の方策として、SSLアクセラレータ(注)を導入する。
- この場合 SSL コネクションはクライアントと SSL アクセラレータ間でのみ発生する。SSL アクセラレータ配下は HTTP となるため、LB の持つセッション管理機能が生きてくる。
- 右の構成が典型例。構成1の場合は、ネットワークの全停止を避けるため SSL アクセラレータの耐障害性の確保がポイント。
- SSL の機能を内蔵した製品も存在するが、基本的には同様の仕組みと捉えると良い。

(注) SSLによる暗号通信で送受信されるデータの暗号･復号化を行う装置。サーバの負荷軽減が目的。

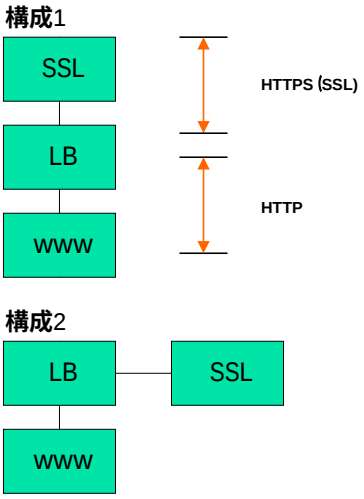

HTTPS の分散 #3

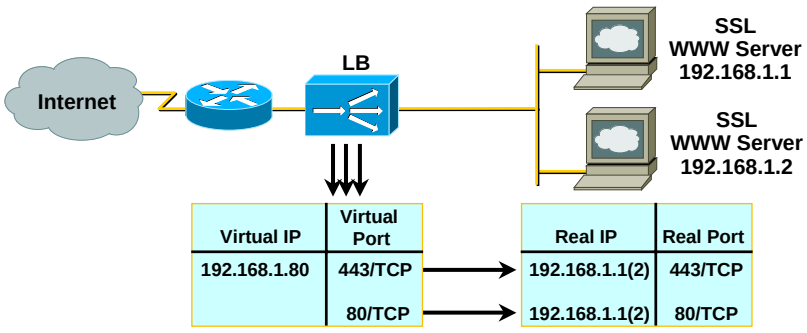

- HTTP と HTTPS のページが連動している場合には？
- HTTP であるサーバ X に誘導されたクライアントは、HTTPS の接続でもサーバ X に導く必要がある。
- LB は 80/tcp や 443/tcp を個々に管理するものが多い。グルーピングしながらの(広い意味での) セッション維持は出来ない装置がある。→代替策が必要。

HTTPS の分散 #4 (案1)

- HTTP と HTTPS のページが連動している場合は？　～ 案1 ～
- コンテンツの作りを工夫して、https の処理に入る時サーバ自身のホスト名を返す。
- LB で、ホスト毎に分散定義を行なう時は、VIP と RIP が 1対1 関係になる。通常は 1対n。
- 右図例では VIP2 は RIP1 にマップされる。同様に VIP3 を RIP2 にマップすればよい。
- 殆どの分散装置は、バックアップの定義が可能なので、RIP1 と RIP2 を相互バックアップ関係にしておく。

①→http://www.example.comに接続

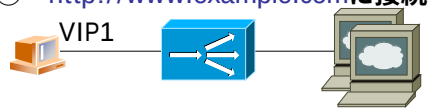

②←次は https://www1.example.com

あるいは。。

②←次は https://www2.example.com

③→https://www1.example.com

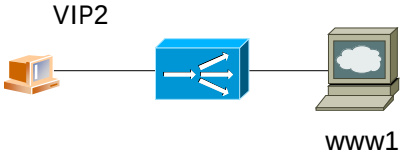

HTTPS の分散 #5 (案1)

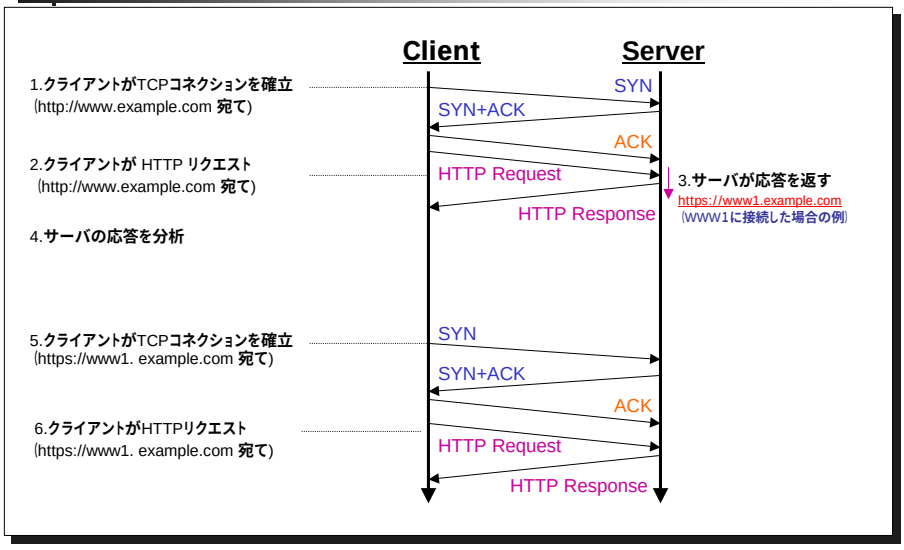

HTTPS の分散 #6 (案1)

Domain Name	VIP	Port	RIP
www.example.com	192.168.1.80	80(HTTP)	192.168.1.1(**www1**) 192.168.1.**2**(**www2**)

Domain Name	VIP	Port	RIP
www1.example.com	192.168.1.81	443(HTTPS)	192.168.1.1 192.168.1.**2**(**backup**)

Domain Name	VIP	Port	RIP
www2.example.com	192.168.1.82	443(HTTPS)	192.168.1.2 192.168.1.1(**backup**)

URL バーに www1や www2 が表示されないように、コンテンツ作成で工夫する (注) 場合もありうる。

注) 実現手段としてフレームを使う場合は、フレーム詐称のセキュリティ上の懸念など検討した上での実施が望ましい。

HTTPS の分散 #7 (案2)

- HTTP と HTTPS のページが連動している場合は？　～ 案2 ～
- 案1 と基本的な考えは同じ。
- “s1”や “s2”などサーバを特定する情報を URL に含ませる。
- SSLアクセラレータを導入し、LB にて URL による分散が行なえるようにする。LB は URL の “s1” や “s2” の文字列マッチングを行い、該当サーバに分散する。
- URL分散のほか、cookie による方法も考えられる。実現案は URL の場合と同じ手法となる。

①→http://www.example.comに接続

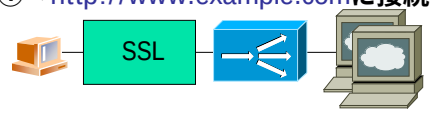

②←次はhttps://www.example.com/s1

あるいは。。

②←次は https://www.example.com/s2

③→ https://www.example.com/s1

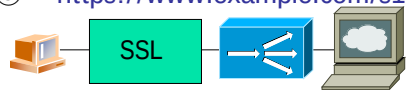

www1

その他の事例

- WebCache装置の分散
- ファイアウォール分散

Web Cache 装置の分散 #1

- WebCache 装置の分散
- クライアントの HTTP リクエスト (80/tcp)を LB がハンドリング。WebCacheへリダイレクションする。
- 宛先 MAC アドレスのみの変換が基本。NAT はしない。最適な分散(効率の良いキャッシュ)を実現するため、URLハッシュなどの分散手法が用いられる。
- 透過的な(トランスペアレント)な構成と呼ばれる

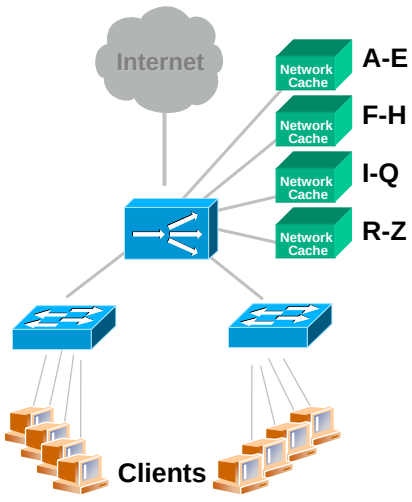

(C)2005, Masakazu Tomari 92

Web Cache 装置の分散 #2

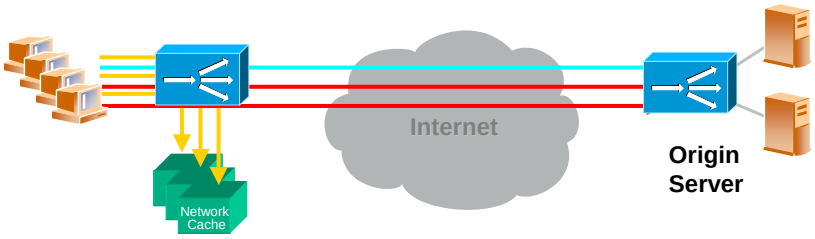

1. クライアントからインターネット上のサーバへ HTTP リクエスト
2. LB が Web Cache へパケットを転送。変換する情報は宛先MACのみ。
   (WebCache がそうしたリクエストに対応できる必要がある)
3. Web Cache にリクエストされたコンテンツがあればクライアントに返す。
4. Web Cache にコンテンツが無い場合、代理でサーバからコンテンツを取得

Web Proxy 装置の分散 #1

- WebProxy 装置の分散
- クライアントの HTTPリクエスト (例：8080/tcp) を LB がハンドリング。WebProxy へリダイレクションする。
- クライアントのリクエストは Proxy 宛ての HTTPヘッダとなっているので、宛先MACだけ変換する方式は適さない。。宛先 IP が LB の仮想 IP となるように設計する。

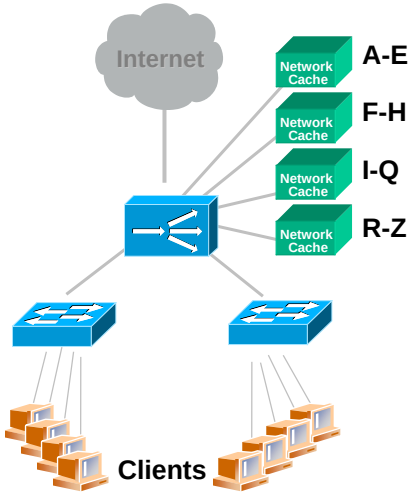

Web Proxy 装置の分散 #2

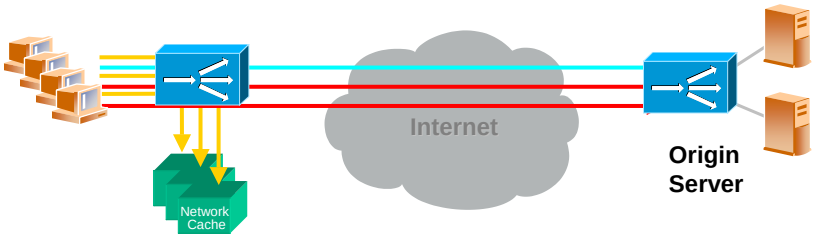

1. クライアントからインターネット上のサーバへ HTTP リクエスト
2. LB が Web Cache へパケットを転送。変換された情報は宛先MACと宛先IPとなる。クライアントのリクエスト形式が Proxy 宛てとなっているため。
   ※「GET /index.html HTTP/1.1」が通常とすると、、Proxy 宛ての HTTP リクエストは「GET http://www.example.com/index.html HTTP/1.1」となる。
3. Web Cache にリクエストされたコンテンツがあればクライアントに返す。
4. Web Cache にコンテンツが無い場合、代理でサーバからコンテンツを取得

ファイアウォール分散 #1

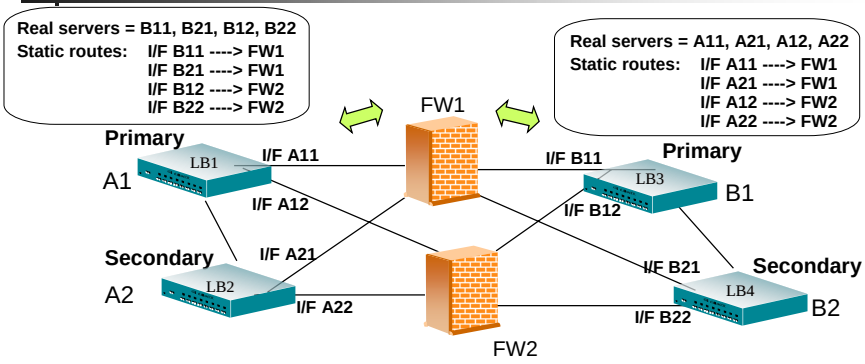

- LB にてファイアウォールを挟む(サンドイッチ)構成
- ファイアウォール側の要求事項としては、行きと戻りで同じ経路を保障する必要がある。→非対称ルーティング問題の回避。
- 実現手法は幾つかある。上図は経路確認でLB同士をping等で監視する方式。
- LBに到着したパケットのIPアドレスをハッシュ計算し、行き先FWを固定する→FWでのNATに注意

ファイアウォール分散 #2

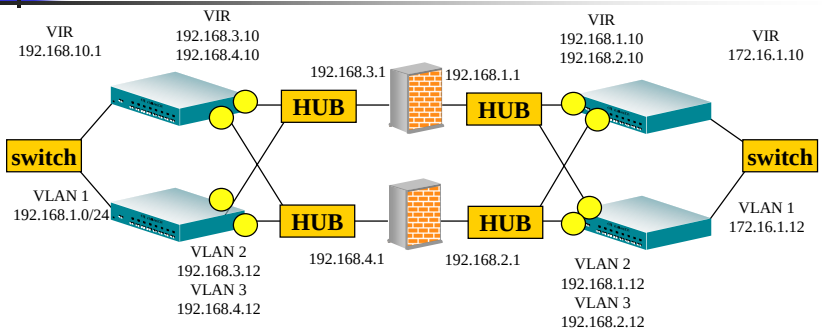

- ファイアウォールで NAT すると、LB での分散先FWの決定に狂いが生じてしまう。このため、別途アプローチが必要になる。実装例ではセッションをコントロールする情報として、 MAC アドレスを加える方式がある。例えばAlteon では これを RTS(Return-to-Sender)と呼び、ファイアウォール側の物理ポートに機能を持たせる設定を追加することで実現している。 この場合、ファイアウォールのMACアドレスが情報として使われることになる。
- Proxy 型のファイアウォールで WWW Proxy などが動いている場合は、pingによる経路チェックではアプリケーションの生死を判断できないことがある。この場合は、コンテンツレベルのヘルスチェック方法が可能か検討することになるが、ファイアウォールと LB の双方で実現の可否を探ることになる。→製品によって出来ないこともある。

(C)2005, Masakazu Tomari 97

負荷分散装置の性能評価 #1

- 従来よりあるネットワーク機器の性能測定の手法としては、IXIA, SmartBits等の計測機器を用いたものが多かった。
- RFC 2544 Throughput Test
  64,128, 256, 512,1024 1280,1518 の固定長データを送受信しパケットの転送率などを測定する。
- TCP/IPなどのコネクションを管理する装置には別な尺度での計測手法が(も)必要。
- より現実的なトラフィック生成の為、同じ計測機器を使うにしてもパラメータ調整としてIMIX(Internet MIX)という考え方も登場している。→ランダムなデータ長の生成と送受信

■RFC 2544 Throughput Test

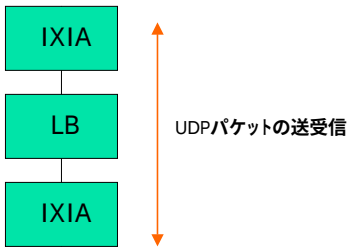

■IMIXの一例

Packet Size (Bytes)	Bandwidth (Load)
40	6.856%
576	56.415%
1500	36.729%

(C)2005, Masakazu Tomari 98

負荷分散装置の性能評価 #2

- LBでの性能評価の尺度
  - 秒間あたりの接続数
  - 同時に確立可能な接続数
- RFCxxx のような、LB 全般に通用する取り決めは現状では存在せず。また、案件ごとに評価テーマが異なることも珍しくない。
- TCP/IP レベルの要求と応答を、多数のコネクションを実現しながら測定できる装置が登場してきている。SPIRENT社の WebAvalancheや Antara.net の「FlameThrower」等が知られている。
- こうした計測機器はまだ高価。レンタルか所有する SI への依頼もありうる。→いずれにしても、何らかコストは発生。
- サイトの負荷測定をサービスする会社もある

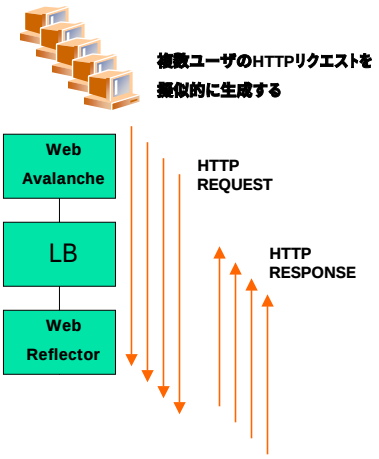

データセンタ構成例

※ Switch 間は全て GbE、Switch-PC間は FE

※ 機器によって LB 間の Linkは不要・使わない

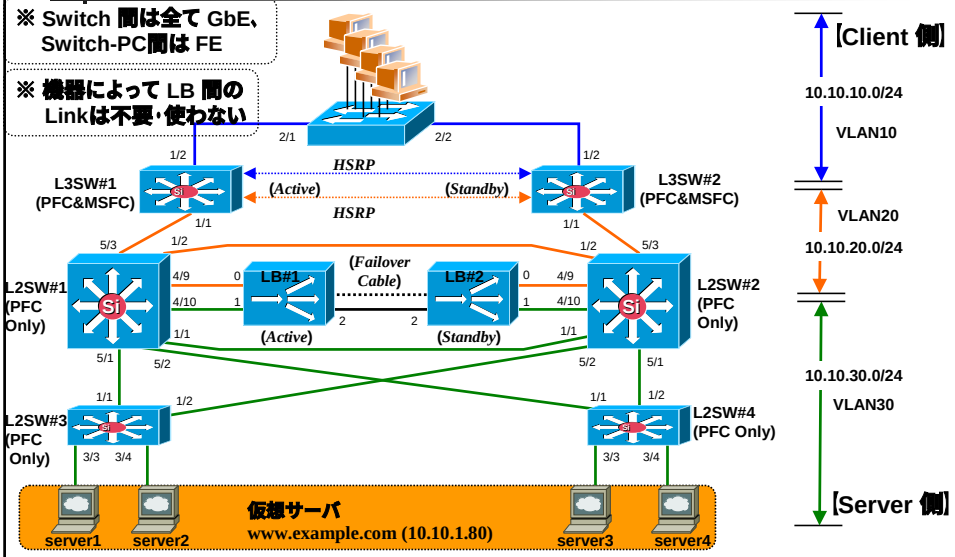

データセンタ構成例①

正常系の通信フロー

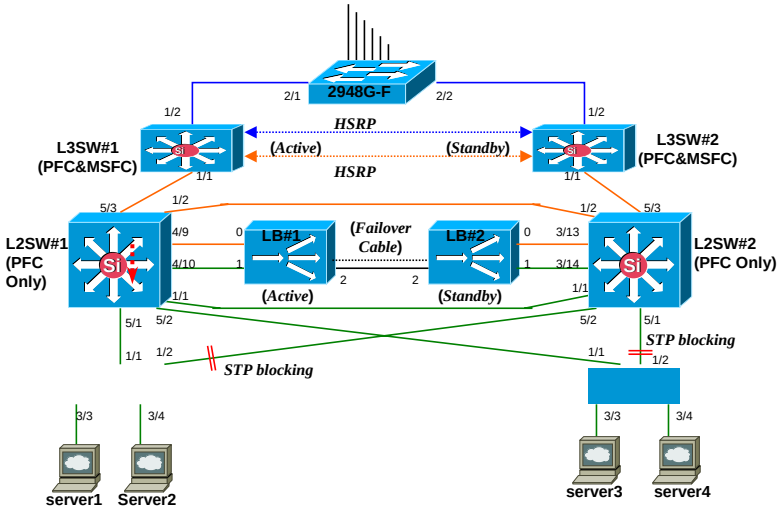

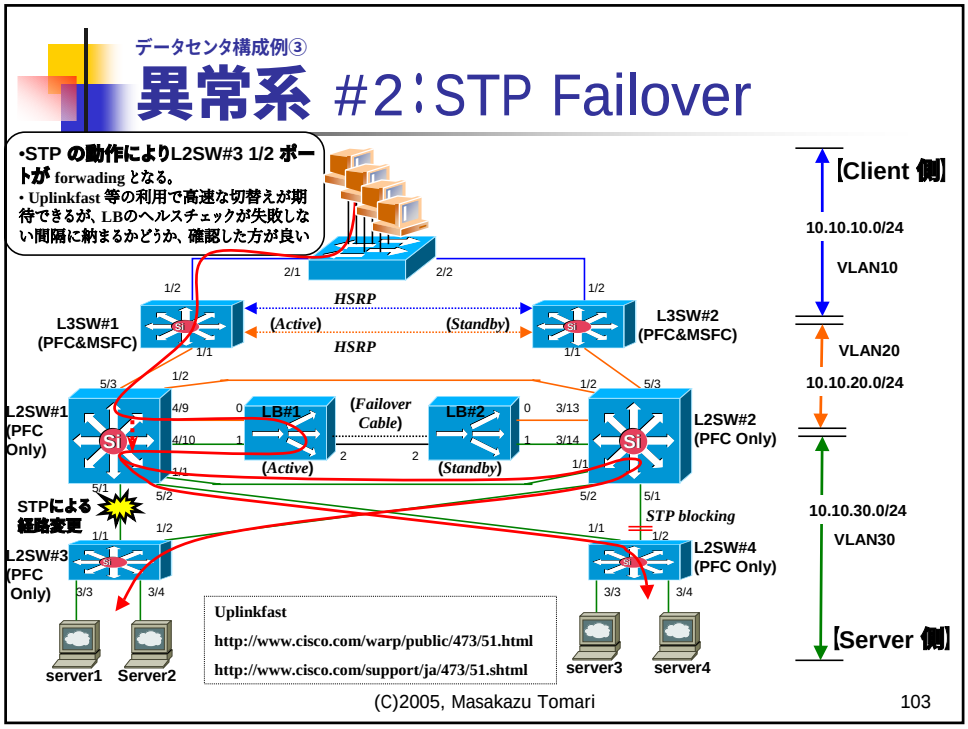
データセンタ構成例③
異常系 #2：STP Failover
•STP の動作によりL2SW#3 1/2 ポートが forwading となる。
• Uplinkfast 等の利用で高速な切替えが期待できるが、LBのヘルスチェックが失敗しない間隔に納まるかどうか、確認した方が良い
【Client 側】
10.10.10.0/24
VLAN10
VLAN20
10.10.20.0/24
10.10.30.0/24
VLAN30
【Server 側】
L3SW#1 (PFC&MSFC)
L3SW#2 (PFC&MSFC)
HSRP
(Active)
(Standby)
HSRP
L2SW#1 (PFC Only)
L2SW#2 (PFC Only)
L2SW#3 (PFC Only)
L2SW#4 (PFC Only)
LB#1
LB#2
(Failover Cable)
(Active)
(Standby)
STPによる経路変更
STP blocking
Uplinkfast
http://www.cisco.com/warp/public/473/51.html
http://www.cisco.com/support/ja/473/51.shtml
server1
Server2
server3
server4
(C)2005, Masakazu Tomari
103

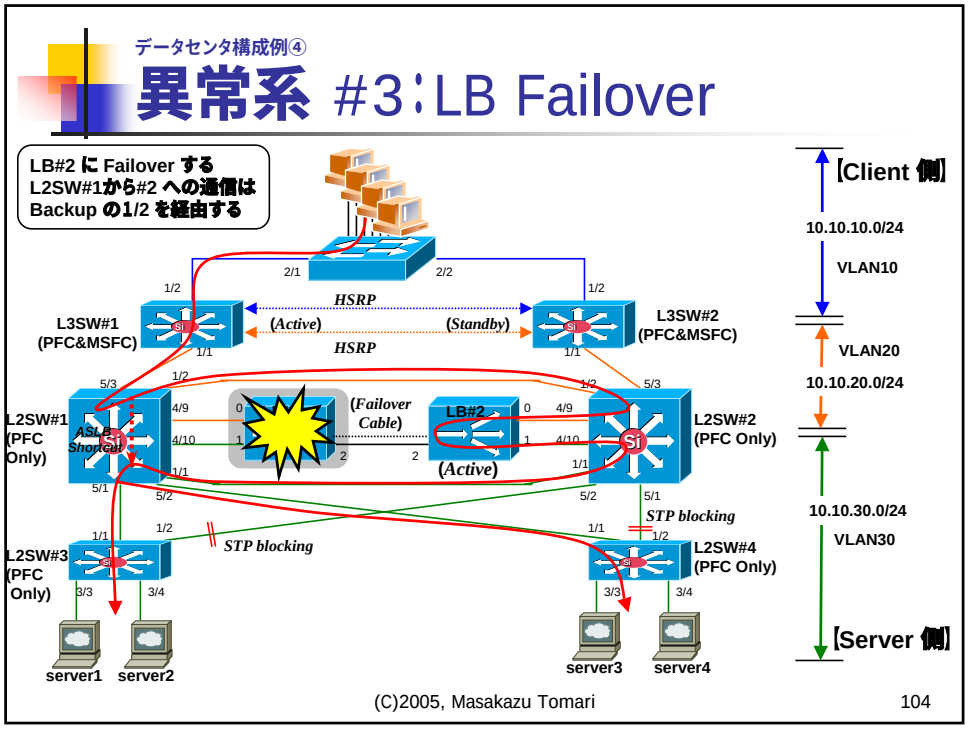
データセンタ構成例④
異常系 #3：LB Failover
LB#2 に Failover する
L2SW#1から#2 への通信は
Backup の1/2 を経由する
【Client 側】
10.10.10.0/24
VLAN10
VLAN20
10.10.20.0/24
10.10.30.0/24
VLAN30
【Server 側】
L3SW#1 (PFC&MSFC)
L3SW#2 (PFC&MSFC)
HSRP
(Active)
(Standby)
HSRP
L2SW#1 (PFC Only)
ASLB Shortcut
L2SW#2 (PFC Only)
L2SW#3 (PFC Only)
L2SW#4 (PFC Only)
LB#2
(Failover Cable)
(Active)
STP blocking
STP blocking
server1
server2
server3
server4
(C)2005, Masakazu Tomari
104

データセンタ構成例⑤

異常系 #4：HSRP + LB + STP

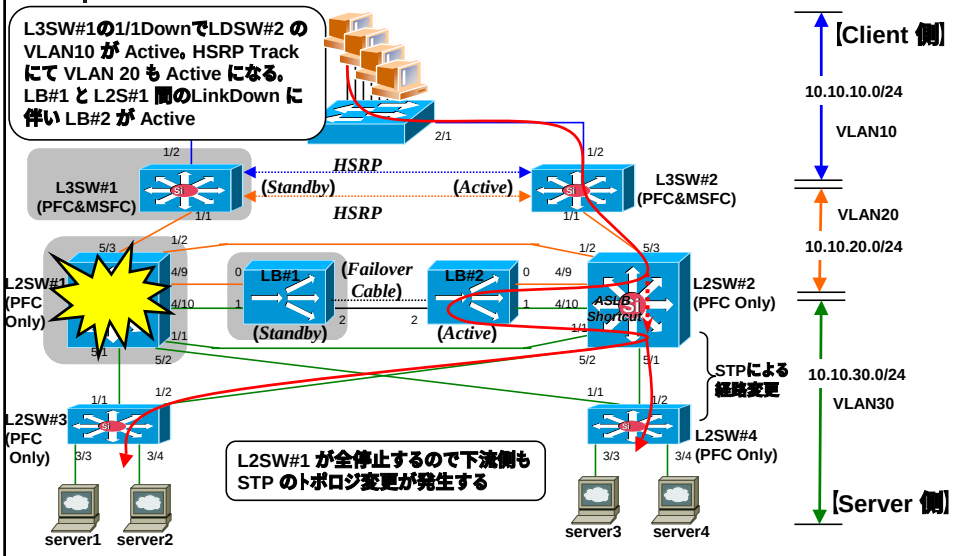

安全なサイトの運営のために

- 複雑な負荷分散のルールを追加する前には、事前の動作確認を推奨。→インストール作業に等しいコストが発生することもあるが止むを得ない。
- 障害が発生すると、復旧のために機器を再起動することが通例。再起動の前に、ログの収集を！→再起動後のログには解決のヒントが少なく原因追求が困難。
- HDDを持つ負荷分散装置も存在する。停電前の作業時にはシャットダウン処理が必要な場合も。

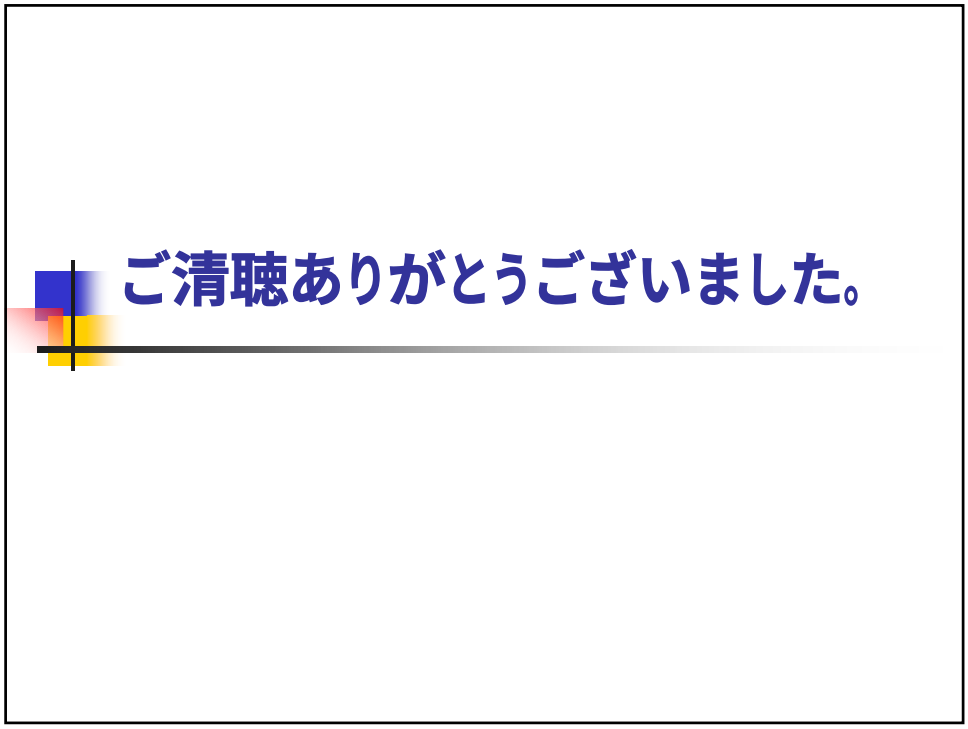
ご清聴ありがとうございました。