

# ファットツリー型データセンタネットワークにおける 障害箇所推定ルールを用いた自律的経路制御方式の検討 Autonomous Routing Algorithm using Fault Location Estimation for Fat-tree-based Data-center Networks

石川 さゆり†  
Sayuri Ishikawa

坂田 匡通†  
Masayuki Sakata

小川 祐紀雄†  
Yukio Ogawa

## 1. まえがき

近年、クラウドコンピューティング/クラウドサービスが社会に浸透し、データセンタ(DC)の大規模化が進んでいる<sup>[1]</sup>。また、MapReduce等の大規模分散処理アプリケーションの導入が進み、サーバ間通信が増加している<sup>[2]</sup>。このような中、DCでは大規模・高性能なネットワークが求められるとともに<sup>[3]</sup>、構成変更や拡張にスケラブルに追従し、通信状態の変化に対しても安定した性能を提供するネットワークが必要となる。

これに対し、我々のグループでは、多数の小型スイッチにて Fat-tree 型<sup>[4]</sup>のネットワークを構成し、スモールスタート/スケールアウトを可能とする DC 向けネットワークを検討している。小型スイッチを用いてスモールスタートすることにより、システム構築時の初期投資を大幅に抑えることができる。さらに、システムの構成変更や拡張に応じて、小型スイッチの並列化台数を増やすことで、システム規模をスケラブルに拡大することが可能となる。これにより、無駄のない投資が実現できる。

しかし、サーバ数百台規模の大規模システムに適用した場合、数十台規模の多数のスイッチにより構成されるため、障害時の経路制御が複雑になるという課題がある。

本報告では、Box 型スイッチを多数利用して構成した Fat-tree 型ネットワークにおいて、障害が発生した際の対策の検討結果を報告する。

## 2. Fat-tree 型データセンタネットワーク

我々は、価格性能比の高いボックス型スイッチを複数用いて Fat-tree 型のネットワークを構成し、スモールスタート/スケールアウトを実現させる方式を提案している。本章では、Fat-tree 型データセンタネットワークの構成と、障害時における課題を示す。

### 2.1 基本構成と経路制御方式

Fat-tree のネットワーク構成を図 1 に示す。図に示す上段スイッチと下段スイッチの間はメッシュで接続し(上段スイッチは、全ての下段スイッチと接続する)、上段スイッチ同士、下段スイッチ同士は接続しない。ここでは、上段スイッチをファブリックスイッチ(F-SW)、下段スイッチをポートスイッチ(P-SW)とし、F-SW 及び P-SW から構成するネットワークをスケラブルネットワーク(SCNW)と定義する。SCNW では、P-SW が負荷分散を担

い、F-SW が中継(フォワーディング)を担当する。従来、このような複数経路を持つ構成の経路制御には、STP(Spanning Tree Protocol)を利用することが一般的であったが、STPは、複数ある経路のうち、1経路以外の通信をブロックするという仕様であった(マルチパス接続ではない)。これに対し、SCNWでは、サーバ等のエンドノードと接続する P-SW から、F-SW へのフレーム転送を、MAC アドレスや IP アドレス等に基づく経路分散で構成し、マルチパスを実現している。

SCNW の、フレーム転送について説明する。全ての P-SW は、上記分散方法に従いフレームを転送し、全ての F-SW は、経路の学習に基づきフレームを転送する。例えば、図 1 に示すように、Server1 から Sever3 への通信において(往路)、Server1 が送信するフレームは、P-SW1 から F-SW1 へ転送される。このとき、F-SW1 では Server1 の接続経路を FDB(Filtering Database)に学習する。次に、F-SW1 は、自身の FDB を参照しフレームの転送を行う。宛先が FDB に未登録の場合、F-SW1 は、残りの全ての経路にフレームを送信する(フラッディング)。また、Server3 から Sever1 への通信において(復路)、Server3 が送信するフレームを受信した P-SW3 では、往路と同一の中継スイッチ(F-SW1)にフレームを転送する。この同一中継スイッチへの転送(シンメトリックルーティング)は全 P-SW が同一の分散ルールを持つ事により実現する。F-SW1 では、Server3 の接続経路を FDB に学習し、既に学習済みの FDB を参照し、P-SW1 にフレームを転送する。

以上に示すように、2階層の Fat-Tree 型のネットワークにおいて、多数のマルチパスにフレームを分散転送しつつ、シンメトリックルーティングにより効率的な転送を実現している。これにより、規模に依らず、SCNW 全体での負荷分散と低レイテンシが実現可能となる。




図 1 スケラブルネットワークの構成

†(株)日立製作所 横浜研究所  
Yokohama Research Laboratory, Hitachi, Ltd.




図2 シンメトリックルーティング崩壊時の問題

## 2.2 SCNWにおける障害発生時の問題


SCNWでは、構成と転送方法を限定していることで、ネットワーク内で障害が発生した場合、障害発生箇所へ接続する経路を通るフレームの転送を、他の経路に振り替えることにより、迅速な障害の回避を実現する。しかし、経路制御はシンメトリックルーティングを前提としているため、その前提が崩れた場合への対応が必要になる。例えば、図2に示すように、F-SW1とP-SW1の間のリンクにて障害が発生した場合、障害発生リンクと接続するP-SWにおいてのみ、経路変更が実施されると、シンメトリックルーティングが崩壊し、F-SWにおけるFDBの学習が完結しないため、フレームのロスが発生する。

## 2.3 課題

本節では、SCNWの構成に基づく課題と、性能に関する課題について説明する。

### 2.3.1 SCNWの構成に基づく課題

前節に示した問題を解決するためには、SCNW内のどの箇所でも障害が発生した場合においても、シンメトリックルーティングを成立させることが必要となる。従って、各スイッチが、シンメトリックルーティングを成立させることが1つ目の課題となる。課題を解決するためには、各スイッチは、以下(1)~(3)に示す場合において、それぞれの経路制御を実施する必要がある。



【凡例】--- : 障害発生後フレーム転送を停止する経路

図3 障害発生時の経路制御

### (1)F-SW1に障害が発生した場合

各P-SWは、障害のF-SW1への経路を、経路分散から除外し、全てのP-SWでの経路分散を統一させる。

### (2)F-SW1~P-SW1間のリンク障害が発生した場合

前節にて示したように、シンメトリックルーティングを成立させるため、障害発生リンクに接続するF-SW1を経由するフレームの転送を停止する。従って、各P-SWは、F-SW1への経路を、経路分散から除外し、全てのP-SWでの経路分散を統一させる。

### (3)P-SW1に障害が発生した場合

各F-SWは、障害のP-SW1への経路を、経路分散から除外する。P-SW側の経路変更はない。

### 2.3.2 性能に関する課題

DCの規模が拡大するにつれ、ネットワークにおける装置数の削減、ケーブルの簡素化、それに伴う装置コストや運用コストの軽減のニーズが高まり<sup>[5]</sup>、LAN/SAN統合の動きが活発化している<sup>[6]</sup>。SCNWにおいても、このような動きに対応するため、LAN/SAN統合の適用を考えると、SANでは、ファイバチャネル(FC)ノード(ex.ストレージ)の接続要件から、625msec以内での経路切り替えが必要となる<sup>[7]</sup>。そのため、SCNWにおける経路切り替えを、625msec以内で実現することを2つ目の課題とする。

## 3. 障害箇所推定ルールを用いた自律的経路制御方式

本章では、前章にて示した課題を解決するための、障害時箇所推定ルールを用いた自律的経路制御方式を提案する。以下、提案方式に関して説明する。

### 3.1 検知方法

障害が発生した際に経路制御を実施するためには、障害が発生したことを検知する必要がある。はじめに障害検知方法を説明する。

SCNWでは、F-SW同士又はP-SW同士は非接続であるため、経路分散の役割を担うP-SWのうち、障害が発生したリンクに直接接続していないP-SWは、障害が発生したことを知り得ない。従って、P-SWは、障害のリンクに接続するF-SWから通知を受け、障害の発生を認識する。

(1)F-SW障害や(3)P-SW障害の場合は、スイッチが、ポートのリンクダウン状態を監視することで検知を行う。

(2)リンク障害の場合は、障害が発生したリンクに接続するP-SW及びF-SWのみが障害を検知する。障害を検知したF-SWは、P-SWに対して障害の通知を実施することにより、全てのP-SWが障害を検知する。

また、(2)リンク障害は2種類考えられ、(2-1)リンクダウンと、(2-2)片断線とがある。(2-1)リンクダウンの検知は、ポートのリンクダウン状態を監視することにより実施する。一方、(2-2)片断線の検知は、各スイッチ間でKeep aliveを実施し、Keep Aliveを受け取らないことにより検知する。

### 3.2 障害箇所推定ルール

P-SWに対して障害を通知するF-SWは、(2)リンク障害であるか、(3)P-SW障害であるかを判別することができない。そのため、経路制御を実施する各P-SWは、障害発生箇所を推測し、障害箇所に応じた適切な経路制御を実施する必要がある。

前述の通り、P-SW が障害を検知する状況は、(1)F-SW 障害と(2)リンク障害である。このときの、P-SW における経路制御処理は、いずれも、障害の F-SW、もしくは障害のリンクに接続する F-SW を、分散経路から除外することである(図 3(1)(2))。F-SW が障害を検知する状況は、(2)リンク障害と(3)P-SW 障害である。このときの、P-SW における経路制御処理は、一方は、障害のリンクに接続する F-SW を、分散経路から除外することであり(図 3(2))、他方は、何もしないことである(図 3(3))。従って、P-SW は、リンク障害であるか、P-SW 障害であるのかを瞬時に推測し、適した経路制御を実施する必要がある。

ここで、両者の障害時における状況を比較すると、(2)リンク障害の場合には、障害を検知する装置は単一の F-SW であることに対し、(3)P-SW 障害の場合には、障害を検知する装置は複数の F-SW であるという違いがある。そこで、P-SW は、障害を検知した F-SW の数、つまり、F-SW から障害通知を受信したポートの数に従い、リンク障害であるのか、P-SW 障害であるのかを判別するルールを用いることで、迅速な障害回避処理が可能となる。

### 3.3 障害箇所推定ルールを用いた自律的経路制御アルゴリズム

前節までに示した障害箇所推定ルールを用いた経路制御の内容を、図 4 を用いて説明する。P-SW は、①障害通知を受信した場合、②一定時間の間に障害通知を受信したポート数をカウントする。その後、③カウント数を元にしきい値判断を実施する。障害通知を単一のポートで受信した場合、障害を検知した F-SW は 1 台であることがわかるため、リンク障害である。従って、障害通知を受信したポート数がしきい値よりも小さい場合、リンク障害であると判断する。そして、各 P-SW は、フレーム転送経路から、障害通知を受信したポートを、除外する。このとき、しきい値を設けた理由は、リンク障害の複数箇所同時発生に対応するためである。一方、障害通知を複数のポートで受信した場合、障害を検知した F-SW は複数であることがわかるため、P-SW 障害である可能性が高い。従って、この場合、P-SW が実施する処理はない。




図 4 自律的経路制御アルゴリズム

## 4. 評価実験

提案方式に基づく経路制御ソフトウェアをレイヤ 2 スイッチ(実機)に搭載し、障害を発生させた際の経路制御処理に関して、評価を行った。障害箇所に応じた処理を実施し、かつ、目標値以内に経路切り替え完了しているかを確認した。




図 5 評価構成

### 4.1 条件

評価構成を図 5 に示す。F-SW2 台、P-SW3 台構成とし、各 P-SW から、2 台の F-SW に対して 1 本ずつリンクを接続した。さらに、サーバ 1 から、P-SW1 へ接続し、サーバ 2 から、P-SW2 と P-SW3 へと接続した。このとき、提案方式におけるサーバ 1～サーバ 2 間の通信は、P-SW1、F-SW1、P-SW3 を経由するものとした。発生させる障害の種類は、(1)F-SW1 の装置障害、(2-1)F-SW1 と P-SW1 の間のリンク障害(リンクダウン)、(2-2)F-SW1 と P-SW1 の間のリンク障害(片断線)、(3)P-SW3 の装置障害の 4 種類とした。スイッチの装置障害はスイッチの電源を落とすことで実施し、リンク障害はケーブルを抜くことで実施し、片断線は途中経路にスイッチを挟み、片経路のみパケットをフィルタリングすることで実施した。

また、経路切り替え時間の測定は、サーバ 1 からサーバ 2 へ、2msec 間隔で UDP パケットを送信し、途中経路にて障害を発生させ、ロスパケット数をカウントすることにより算出した。このとき、従来技術との比較として、①提案方式と、②Rapid Per-VLAN Spanning-Tree(R-PVST)における、経路切り替え時間を比較した。

### 4.2 経路制御時間の試算と Keep Alive 間隔の決定

提案方式において、障害発生から、経路切り替えの処理が完了するまでに要する時間を試算した。試算結果を図 6 に示す。図に示す  $t$  は、提案方式の Keep Alive 間隔となる。提案方式は、一定時間毎に障害の検知処理を実施しているため、1 回のループ処理で障害検知までに要する時間は、最大  $t$  となる。

(1)F-SW 障害が発生した場合、障害を検知するスイッチは、P-SW となる。従って、P-SW が、(a)障害が発生してから障害を検知するまでの時間と、(b)障害を検知してから経路制御が完了するまでの時間、つまり(a)+(b)が、経路切り替えに要する時間となる。(3)P-SW 障害の場合は、障害を検知するスイッチは F-SW となるため、図の(c)+(d)+(h)が、経路切り替えに要する時間となる。(2-1)リンクダウンの場合は、F-SW が、リンクダウン箇所に接続していない P-SW に対して、障害発生の通知を実施し、P-SW が、経路切り替えの処理を実施するため、図の(c)+(d)+(e)+(f)+(g)が、経路切り替えまでに要する時間となる。(2-2)片断線の場合は、F-SW と P-SW 間で実施している Keep Alive の失敗を検知した後に、(2-1)リンクダウンと同様に、F-SW から P-SW への障害発生の通知を実施した後、P-SW において経路切り替えの処理を実施する。今回の実装では、片断線の検知タイミングを Keep Alive の 3 回失敗




図6 経路切り替え時間の試算(数値単位:msec)

時としたため、(c)+(d)+(e)+(f)+(g)が、経路切り替えまでに要する時間となる。

従って、前述した2つ目の課題である625msec以内での経路切り替えを達成するためには、経路切り替えに要する時間が最大となる(2-2)片断線時の時間(6t+21)<625msecとなればよい。そのため、t=100以下が、この要件を満たす値となる。しかし、実運用においては、他処理の割り込みやトラフィックの混雑等が原因で、Keep Alive間隔のずれが発生することを考慮し、今回は、Keep Alive間隔を50msecと設定した。

### 4.3 経路切り替え時間の評価結果

前述した4種類の障害における、経路切り替えの評価実験を行った。結果を以下に示す。

①提案方式(Keep Alive間隔は50msec)にて、4種類の障害を発生させた場合の、経路切り替えを評価した。その結果、全ての障害時において、適した経路制御を実施することを確認した。

表1には、①提案方式と、マルチパスではないが、従来技術による経路切り替えの参考として②R-PVSTとを用いて切り替えに要する時間と、障害からの復旧時に通信不能になる時間を計測した結果を示す。値は、それぞれ5回ずつ測定した平均値とし、単位はmsecとする。①提案方式では、全ての障害発生時の経路切り替えにおいて目標値以内を達成し、②R-PVSTと比較しても高速に経路切り替えを実施していることがわかり、提案方式の有効性が確認できた。また、障害からの復旧に関しては、①提案方式では、マルチパスを実現しているため、ロスが発生しないことを確認した。一方、②R-PVSTでは、経路が複数ある際、1経路以外の経路をブロックするという仕様であるため、障害復旧時において、通信経路が切り替わる際、フレームロスが発生していることがわかった。

②R-PVSTにおいて、復旧時に通信断が発生する原因は、R-PVSTの経路の変更において、ポートをブロックするタイミングと、FDBを更新するタイミングが合っていないためであると考えられる。また、片断線は想定外のためか、FDBが再更新されるまで復旧することはなかった。

表1 障害時の経路切り替え時間と障害復旧時の通信断時間

障害の種類	条件	障害時の経路切り替え時間		復旧時の通信断時間
		①提案方式	②R-PVST	②R-PVST
(1)	F-SW 障害	50	735	534
(2-1)	リンクダウン	100	460	316
(2-2)	片断線	289	526	-(復旧せず)
(3)	P-SW 障害	224	274	36

また、①提案方式において、表1に示した値は、図6で試算した値に適していることを確認した。

## 5. まとめ

本稿では、DC向け高スケール・低遅延なFat-tree型ラック間ネットワーク(SCNW)における、障害発生時の経路制御方式に関して検討を行い、以下を達成した。

- 各スイッチが障害箇所を推定し経路制御を実施
- マルチパス及びシンメトリックルーティングを保障
- Keep alive間隔50msecにて平均289msecでの経路切り替えを達成

今後の課題は、DCを想定した大規模構成にて検証を行い、本方式の有効性を確認することである。

### 参考文献

- [1] IDC Japan, “国内データセンター規模別分布 2009年の推定と2010年~2014年の予測”, J10280101 (2010).
- [2] T. Benson, A. Akella, and D.A. Maltz, “Network traffic characteristics of data centers in the wild”, in Proc. Internet Measurement Conference, 267-280 (2010).
- [3] David Bernstein, Erik Ludvigson, “Networking Challenges and Resultant Approaches for Large Scale Cloud Construction”, 4-8, 136-142 (2009).
- [4] Charles E. Leiserson, “Fat-trees - University networks for hardware-efficient supercomputing”, IEEE Transactions on Computers, Vol. C-34, 892-901 (1985).
- [5] Loukas Paraschis, Sudhir Modali, “Data Center Transport in the Zettabyte IP Network”, Photonics Society Summer Topical Meeting Series 2010 IEEE, 19-21, 227 - 228 (2010).
- [6] Reinemo. S., Skeie. T., Wadekar. M.K., “Ethernet For High-Performance Data Centers: on The New IEEE Datacenter Bridging Standards”, Micro, IEEE, 42-51 (2010).
- [7] INCITS, “FIBER CHANNEL BACKBONE-5(FC-BB-5) REV 2.00”, 122 (2009).