

Smart Scatter: インターネット / イントラネットの負荷分散機構

4 T-2

- パケット振りわけ部 - *

今井祐二 †岸本光弘 †高場浩一 †矢作毅彦 †

†† (株)富士通研究所 †§ (株)富士通

1 はじめに

我々は、大規模ネットワークサーバのためのフロントエンドミドルウェア「Smart Scatter」を開発している。Smart Scatterは、複数のサーバノードにTCP, UDPセッションを分配し、ノード故障時もリクエスト配達先を故障していないノードに切替えることで、大容量／高信頼でかつクライアントから1台に見えるネットワークサーバーをクラスタによって構築することを可能にする。Smart Scatterはカーネル内で実際にパケットの振りわけを行なう「パケット振り分け部」と、振り分け方法を指示する「制御部」からなる。本稿ではこのうちパケット振り分け部に関して述べる。

2 機能

Smart Scatterは、クラスタ全体を表す代表IPアドレス宛のTCP, UDP/IPパケットを、管理者が定義する割合でクラスタ内のノードに分配することができる。Smart Scatterでのパケット振り分け方法を、パターン＆ハッシュ方式と呼んでいる。（図1）振りわけ部は代表アドレス宛のパケットを指定されたパターンを用いて分類する。パターンはパケットのUDP, TCP, IPヘッダに含まれるIPアドレスとポート番号で表現されている。パターンに合致したパケットは同じくヘッダの情報をパラメータとするハッシュ関数を用いてハッシュ値を計算し、クラスタノードを要素とする宛




図1：パターン&ハッシュ

先ノード表から対応項目を参照し配達ノードを決定する。

单一のTCPセッションのデータグラムは宛先IPアドレス／ポート、送り元IPアドレス／ポートが同一なので、ハッシュ値も同一となり、同一ノードへの配達が保証される。配達されたノードでは、ノード固有のIPアドレスの他に代表アドレスを、Logical interface(例：Solaris 2.5.1におけるle0:1)等を用いて論理的に設定し、自ノード宛の通常パケットと同様に代表アドレス宛データグラムの処理を行なう。

ハッシュ関数へ渡すヘッダの情報はマスクによって選択が可能で、これにより配分手法を選択できる。例えばデータベース操作をCGIを経由して行なうWebアプリケーションの場合、同一クライアントからの連続したアクセスを常に同一ノードへ収容する事が望まれる。このような場合送り元IPアドレスのみをハッシュ関数引数として使用す

*Smart Scatter -scatter module-

†Yuji Imai

‡Mitsuhiko Kishimoto

§Kouichi Takaba

¶Takehiko Yahagi

||Fujitsu Laboratories, 4-1-1 Kamiodanaka, Nakahara, Kawasaki, Japan

ることで、連続した http セッションが他のノードへ配送される事を防げる。

宛先ノード表はパターン毎に設定が可能で、サービス毎に異なるノードグループを配送先に選んだり、特定クライアントからのリクエストを特別に用意したノードへ配送したりすることが可能である。

クラスタ内に性能に差があるノードを混在させたい場合、宛先ノード表でのノードの出現割合を性能に比例して配分することで調節可能である。また、宛先ノード表の大きさを大きくすることで、割り振りの粒度を所望の程度に調整可能である。

制御部がノードの故障を検出した場合、もしくはノードの予防保守などのために一時的にノードの切り離しを行ないたい場合には、宛先ノード表の切り離しノードの項目を、運転中のノードに書き換える。

予防保守時や振り分け割合変更時に宛先ノード表を書き換えた場合には、接続中の TCP セッションが切断されるおそれがある。これを防止するために、接続中の TCP セッション状態の監視を行うことができる。宛先ノード表切替時に接続されていた TCP セッションが存在する場合には、後続のパケットが既接続セッションのものかどうかを検査し、既接続セッションの場合には宛先ノード表が指すノードを無視し、切替え前のノードにパケットを配送する。同様に、前述の CGI によるデータベース連係時などの、連続 TCP セッションを同一ノードへ配送する必要がある場合のために、クライアント IP アドレス毎の最近の TCP セッション配送先を記録し、割り振り変更後も、以前のノードにパケットを配送することもできる。

3 構成

Scat module は UNIX SVR4 の STREAM module として IP module と DLPI driver の中に挿入される。(図 2) 外部ネットワークからのデータグラムはイーサーネットなどによって受信




図 2: Scat module

され、DLPI ドライバから上位モジュールである scat モジュールが呼び出される。scat モジュールは、データグラム中の IP ヘッダを見て、代表アドレス宛のデータグラムであるかどうかを判断する。代表アドレス宛である場合には上記パターン & ハッシュ手法により配送先ノードを決定し、物理層アドレスの解決と書き換えを行なった後、クラスタ内ネットにパケットを送出するため DLPI ドライバを起動する。サーバノードからクライアントへのリプライパケットなど、代表 IP アドレス宛でない場合には、上位の IP モジュールにパケットを転送する。IP モジュールではルーティング処理が行なわれ、下位の Scat モジュールに処理が依頼される。Scat module はこのパケットを、そのまま下位の DLPI ドライバに渡すので、全体として通常のフォーワーディングが行なわれることになる。

参考文献

- [1] 細井他,"Smart Scatter - 全体構成と制御部 - ", 第 55 回情報処理全国大会論文集 4T-01, 1997