

長距離超高速インターネット (4)

1 U-5

- ボトルネック -

村上 健一郎[†] 釘本 健司[‡] 天海 良治[†] 岡 敦子[‡]NTT 基礎研究所[†] NTT ソフトウェア研究所[‡]

1 はじめに

我々は、156Mbpsの同期デジタルハイアラキSDH (Synchronous Digital Hierarchy)を使用した長距離超高速インターネットの実験を進めている[1]。そこで使用しているプロトコルは、TCP/IP (Transmission Control Protocol / Internet Protocol)である。本論文では、実験結果[2][3][4]や理論上の検討をもとにしてボトルネックを整理し、実験で得られた知見について議論する。

2 さまざまなボトルネック

2.1 TCP/IP プロトコルの理論限界

TCP/IPのヘッダには、プロトコルの限界となり得る2つの領域、即ち、IPのデータグラム識別番号IP-IDとTCPの順序番号(Sequence Number)とがある。これらはそれぞれ16bitと32bit長である。前者は、IPデータグラムを送り出す際につけられるユニークな番号である。そして、それが途中のルータで細分化された場合に、転送先のノードが同じIP IDをもつデータグラムを集めて再組み立てできるようにしている。このため、データグラムがネットワーク内に生存する時間TTL (Time-To-Live)内には同じ番号を持つデータグラムを転送できない。TTLはTCPで指定される8bitの値である。そして、IPデータグラムの最大長は64Kbyteなので、その転送速度の上限は、 $64(K\text{byte}) \times 8 / TTL(\text{sec})$ で与えられる。つまり、TTLが15秒の場合には2.2Gbps、また、TTLが255秒の場合には129Mbpsが理論上の限界となる。

一方、順序番号は4Gbyteまで表現できるが、これも転送先のノードで重複した値を持つTCPセグメントが受信されないようにしなければならない。従って、転送速度の上限は、 $4096(M\text{byte}) / TTL(\text{sec})$ となり、TTLが15秒の場合には2.2Gbps、TTLが255秒の場合には129Mbpsである。

なお、データグラムのTTLはルータに中継されるごとに1だけ減らされ、0になった時点で破棄される。これは、ルータがデータグラムを中継するのに一秒を要すると想定しているからである。しかし、実際にはより短い時間で中継されるので生存時間はTTLで指定された値よりも短くなる。従って、限界スピードは計算値(129Mbpsから2.2Gbps)よりは大きいものとなる。

2.2 プロトコル実装のボトルネック

2.2.1 ヘッダ処理の速度

Jacobson[5]は、TCP/IPプロトコル処理の最適化を行い、IPを37命令と7回のメモリアクセス、TCPを最大60命令と22回のメモリアクセスで処理できることを確認した。この結果から1パケットの処理(1パケットの受信とそれに対する確認応答ACKの処理)に400命令の実行を仮定すると、10MIPSのプロセッサでは40 μ secで処理ができることになる。つまり、毎秒25,000パケットの処理ができる。ここでパケット長を4Kbyteとすると、転送速度は800Mbpsになる。これは十分な処理速度が達成可能であることを示している。

2.2.2 メモリアクセスによるボトルネック

上記の計算ではメモリアクセスのオーバーヘッドが考慮されていない。メモリアクセスは、インタフェースとシステム空間との間のコピー、チェックサム計算、システム空間からユーザ空間へのコピーで4回ものメモリサイクルが必要となる。しかも、オーバーヘッドはパケット長に比例する。ここではヘッダ処理に伴うメモリアクセスを無視し、1byte当りのアクセス時間を平均50nsec、そして、4回のメモリアクセスが必要な処理系を想定する。この場合、パケット長を4Kbyteとすると、1パケット当りの処理に1.6nsec程度を要することになる。これは毎秒600パケット、つまり、40Mbps程度の転送速度しか出ないことになり、ヘッダ処理よりもメモリアクセスがボトルネックになることを示している。なお、インタフェースのメモリをシステム空間に置いたり、コピーの代わりに仮想空間の切り替えを行うなどの最適化を行うことによって、メモリサイクルを減らすことも可能である。

2.3 アルゴリズムの不整合とボトルネック

長距離超高速インターネットの環境は、これまでのアルゴリズムの前提とは大きく異なっている。例えば、より大きな最大セグメント長MTU (Maximum Segment Size)が使用されたり、伝送遅延と帯域の積DBP (Delay Bandwidth Product)、つまり、ネットワーク内に蓄積されるパケットの量[2]が膨大なためにさまざまなアルゴリズムとの不整合が発生する。

2.3.1 大きなMTUによるアルゴリズムの不整合

SWS(Silly Window Syndrome)とは、TCPの極端に小さいウィンドーサイズによってほとんどヘッダだけしか含まない細分化されたTCPセグメントが発生する現象である。これによる有効帯域の減少やヘッ

[†] Ken-ichiro Murakami, Takeshi Kugimoto,

[‡] Yoshiji Amagai, and Atsuko Oka

NTT Basic Research Laboratories, NTT Software Laboratories

処理オーバーヘッドの増大などの問題に対し、転送ノードと受信ノードの両方でSWSを回避する以下のNagleのアルゴリズムが使用される。BSD UNIXの実装によると、受信側では、ACKを行っていないデータがMTUの2倍を超えてしかも受信バッファが空になった場合、または、受信バッファサイズの35%が満たされた場合、または、ACKが500ms以上遅延した場合に初めてACKを行う。また、送信側ではMTU分のウィンドウが開くか、すべての転送済にデータのACKを受信した場合に限って送信する。

ところがTCPバッファよりも大きなMTUを持つ高速回線では、送信バッファと受信バッファの組み合わせによっては、意図しない定期的な待ち状態が発生する可能性がある。即ち、送信側は受信側からACKが返ってくるのを待つ一方、受信側はACKの条件がそろえるための更なるデータが送信側から送られてくるのを待ってACKを遅延する。そして、このデッドロックは受信側の遅延タイム切れによって解けるが、これが極端なスループットの低下となって現われる。

2.3.2 帯域制御アルゴリズムの不整合

TCPでは、エンドノード間のフローコントロールにネットワーク側の輻輳制御を重ねている。まず、データを転送してからそれに対応するACKが受信されるまでの時間RTT(Round Trip Time)を常に計測し、それを再転送のタイマへ反映させる。また、通常のウィンドウの他に輻輳ウィンドウと呼ばれるネットワークの負荷を反映させたウィンドウも持っている。そして、利用可能な帯域を探るために次第に輻輳ウィンドウを大きくしてゆき(Slow-start)、最初のパケットのロスが発生した時を輻輳の発生と考え、輻輳ウィンドウを絞る(Congestion Avoidance)。ネットワークでは、利用できる帯域が常に変動しているため、この動作をくり返すことになる[3]。

しかし、長距離超高速インターネットでは、パケットのロスを用意的に利用するような帯域の調整は大きなオーバーヘッドを招く。それは、DBPが非常に大きいため、パケットのロス検出時にはすでに多くのパケットが先送りされており、TCPのGo-back-Nアルゴリズムではロスのあったパケット全部を再転送しなければならぬからである。また、パケットロスが検出されて再転送が開始される間まで、ウィンドウが尽きて長い間転送が停止したままとなる。

3 得られたいくつかの知見

3.1 DBPを考慮した帯域制御方式

現在の帯域制御アルゴリズムの最も大きな問題は、静的に設定されたウィンドウサイズがDBPを超える場合、回線の帯域以上に輻輳ウィンドウを拡大しようとして無駄なSlow-startとCongestion Avoidanceが繰り返されることである。これによるパケットのロスは大きなパフォーマンスの低下をもたらす[2][3][4]。

この問題を改善するため、回線自体の帯域を見積もり、それ以上の輻輳ウィンドウの拡大を行わないようにする方法や拡大を試る頻度を調整する方法などが考えられる。ここでは、(1)スループットの履歴を保持して回線の帯域を見積もる方法(2)ウィンドウベースではなく転送レートベースで制御する方法(3)ウィンドウベースとレートベースのハイブリッド方式(4)状況に応じて動的に適切なアルゴリズムの切り替えを行う方法などが検討課題である。これらの方法には、計

測が簡単で、しかも、正確な見積もりができることや従来との互換性が要求される。

3.2 同期制御とバックトラック

長距離のネットワークでは、伝送遅延によってネットワークをまたぐ同期に大きなコストを要する。すでに述べた帯域制御アルゴリズムの問題は、転送元ノードと転送先ノード間とのフローに関する同期の問題と考えることができる。しかし、この問題はアプリケーションを含めたあらゆるレイヤにもあてはまる。例えば、頻繁なリンクレイヤでのリンクの確立は遅延による待ち時間の増大を招き、スループット低下の要因となる。また、アプリケーションレイヤにおいても同様で、スループット低下を防止するためには、同期の頻度をできるだけ減らすような非決定的なパラダイムに基づくプログラミングが必要である。しかし、同期点の間隔が大きくなると、前の同期点までのバックトラック(トランスポートレイヤにおける再転送に相当する)が発生した場合に、そのオーバーヘッドが大きくなるため、そのトレードオフを考慮する必要がある。

3.3 光速と高速通信

高速ネットワークでは、その速度が上れば上るほど、パケットの物理的なデータ長が短くなる。そして、全部のデータを光ファイバに入れる時間とファイバ中をデータが伝播する時間が逆転する。そのため、いくら高速(広帯域)の伝送装置を持ってきても、遅延が光速にバウンドされ性能が向上しない。伝送装置のレベルで2.4Gbpsや10Gbpsを超える速度の伝送装置を使用できても、光速を超えるような伝送媒体を手に入れることは不可能であるので、エージェント同士が双方向の通信を行う高次の通信では、これまでとはまったく異なる伝送遅延に対応したプログラミングパラダイムが必要となる。

4 おわりに

本論文では、長距離超高速インターネットの実験や理論上の検討をもとにして、さまざまなボトルネックをいくつかのカテゴリに分類した。また、実験で得られたいくつかの知見について議論し、今後のエージェント間通信には非決定性を指向したプログラミングパラダイムが必要なることを明らかにした。

参考文献

- [1] 岡、釘本、天海、村上: 長距離超高速インターネット(1) 実験概要について、第50回情報処理全国大会、1995
- [2] 釘本、岡、村上、天海: 長距離超高速インターネット(2) スループット、第50回情報処理全国大会、1995
- [3] 天海、村上、釘本、岡: 長距離超高速インターネット(3) 特性解析、第50回情報処理全国大会、1995
- [4] 村上、天海、釘本、岡、伊藤正樹、後藤、伊藤光泰: 長距離超高速インターネット、NTT R&D, Vol. 43, No. 9, 1994. pp.973-pp.982
- [5] V.Jacobson: Some Design Issues for High-speed Networks, Networkshop '93, Nov. 1993.