

ATM ネットワークに適したストリーム転送プロトコル

綾田 和晶[†], 西村 浩二[‡], 相原 玲二[‡]

† 広島大学大学院 工学研究科 ‡ 広島大学 総合情報処理センター

ATM ネットワークにおいてデータ通信を行う場合、転送プロトコルとして主に AAL5 が用いられる。信頼性の要求されるデータ通信を行うために現時点では TCP (Transmission Control Protocol) などの既存のストリーム転送プロトコルを使用することになる。しかし、TCP のアルゴリズムは低速から高速まで様々な物理回線を想定しているため、ATM 通信を行う場合には必ずしも最適ではない。本稿では、ATM UBR サービスクラスにおいて高速なストリーム転送が行える、新しいデータ転送プロトコル (ATCP: ATM specific Transmission Control Protocol) を提案する。

A Transmission Control Protocol for ATM Networks

Kazuaki Ayada[†], Kouji Nishimura[‡], Reiji Aibara[‡]

† Graduate School of Engineering, Hiroshima University

‡ Information Processing Center, Hiroshima University

AAL5 is a popular adaptation layer protocol for data communication on ATM networks. To perform reliable transmission, connection based byte stream protocols, such as TCP (Transmission Control Protocol), must be used. Because TCP is designed for variety of physical lines, e.g., line speed, it is not the optimum protocol for ATM networks. We propose a new protocol (ATCP: ATM specific Transmission Control Protocol) which allows fast, reliable data communication on ATM UBR service class.

1 はじめに

TCP は、転送レートや遅延時間、またデータの損失や重複、到着順序狂いなどをアプリケーションが考慮しなくとも信頼性のあるデータ通信が行えるよう設計された通信プロトコルであり、現在、ストリーム転送プロトコルの標準的な存在として様々な環境で利用されている。

しかし、光ファイバー技術の導入により、TCP がもともと想定していた通信速度を越えたネットワークが登場するようになってくると、確認応答の到着までにネットワークに投入することのできるデータ量（帯域・遅延積）が大きくなるため、ウインドウサイズに制約があり、損失データに対する回復アルゴリズムも貧弱な現在の TCP では十分な速度性能が得られない。そこで近年、高帯域、高遅延のネットワーク上で TCP のこの性能ボトルネックを解消しようと様々な改良策が考案されている [1][2][3]。

このような高速なネットワークとしては現在、ATM (Asynchronous Transfer Mode) ネットワークが最も注目されている。ATM ネットワーク上でデータ通信を行う場合、通信ホスト間ではあらかじめ VC (Virtual Channel; 仮想チャネル) を設定する。また、ATM ネットワーク上のスイッチにおいてセルの送信順序替えは禁止されており、このため受信側ではデータの到着順序が狂うことはずないと考えられる。しかし、TCP は信頼性のない IP ネットワーク上でデータを順番通りに確実に届けるために構築されたものであり、ATM ネットワークでの使用を考えた場合、TCP のアルゴリズムには無駄な部分が存在する。

また、ATM を用いたデータ通信の方法として、近年、IP 層を介さず、ATM のフレーム (AAL5) に TCP のセグメントを直接埋め込む方法も検討されている。この方法では IP アドレスを使用できないため、利用は ATM 専用のネットワークに限定され

るが、ルーティング機能を元来持っている ATM にルーティングを任せることで IP 層のオーバーヘッドを取り除くことができる。実際、IP 層を介さず直接 ATM にアクセスする TCP を Solaris2.4 上に実装したもの (TCP-ONIP; TCP over Non Existant IP) も現在発表されている [4]。

そこで、本稿では、データの順序狂いに対して寛容な従来の TCP を改良し、廃棄セグメントの検知、再送をもっと効率良く行えるような、ATM に適したデータ転送プロトコルを提案する。

本稿では、以降、第 2 章において TCP の標準的な輻輳制御方法となりつつある 4 つのアルゴリズムについて述べ、第 3 章では最近 RFC2018 として発表された TCP SACK オプションのメカニズムおよびその問題点について触れる。また、第 4 章では本稿で提案する ATCP の概要、第 5 章で各 TCP のスループットの実測結果を報告し、終わりにまとめと今後の展望を述べる。

2 4.3BSD における TCP の実装

本章では、4.3BSDにおいて既に実装されており、また、TCP に一般的に導入されつつある 4 つの輻輳制御アルゴリズムについて簡単に説明する [5]。

2.1 スロースタート、輻輳回避

TCP は輻輳制御を行うためにスロースタートと輻輳回避という 2 つのモードを持つ (図 1)。

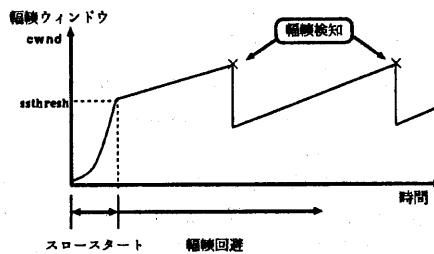


図 1: TCP における輻輳制御

送信側はまずスロースタート・モードでデータ転送を開始し、輻輳ウィンドウの大きさがある閾値 $ssthresh$ に達するまではウィンドウを指数関数的に増やし、閾値に達すると、ウィンドウを線形増加させる輻輳回避モードへと移行する。これは、輻輳ウィンドウがある程度の大きさになるまではデータ

投入量を素早く増加させ、閾値を越えると、利用可能な帯域の限界に近付いていると判断して、データ投入量の増加を抑えようとするためである。

2.2 Fast Retransmit/Fast Recovery

TCP では累積確認応答を用いているため、ACK には常に受信側が次に受け取るべきセグメントのシーケンス番号が記されて返って来る。すなわち、あるセグメントが廃棄された後に受信側に到着したセグメントによる ACK には廃棄されたセグメントのシーケンス番号と同じ値が記されている。従って、重複 ACK の到着はそのセグメントが廃棄されたことの強い裏付けとなる。そこで、3 つの重複 ACK が返ってきた場合、Fast Retransmit/Fast Recovery と呼ばれる次のアルゴリズムを実行する。

- (1) 3 つの重複 ACK が返ってきたら、 $ssthresh$ を現在の輻輳ウィンドウ $cwnd$ の半分に設定し、廃棄されたセグメントを再送する (Fast Retransmit)。そして、 $cwnd$ を $ssthresh + 3$ セグメント (重複 ACK の個数) にする。
- (2) 以降、重複 ACK が到着するごとに $cwnd$ を 1 セグメントずつ増加し、(増加した $cwnd$ によって許されるなら) 受信側の告知したウィンドウサイズを越えない範囲でまだ送信していないセグメントを送る。これにより、輻輳直前の $cwnd$ の半分の量のデータを常にネットワークに投入し続けようとする (Fast Recovery)。
- (3) ACK が更新されたら $cwnd$ を (1) で設定した $ssthresh$ の値にし、これ以降、通常の輻輳回避モードに入る。

しかし、このアルゴリズムは 1 ウィンドウ内の 1 セグメントが廃棄された場合に対して最適化されたものであり、複数のセグメントが一度に廃棄されると、それらのデータはタイムアウトするまで再送できないことがある。そこで最近、TCP のこの欠点を解決すべく新しい機構が発表された。次章ではその新しい機構について触れる。

3 TCP SACK オプション

本章では、RFC2018 にて提案されている TCP SACK オプションのメカニズムについて触れる [2]。

TCP SACK (Selective Acknowledgement) オプションとは、セグメントが順序通りに受信側に到着しなかった場合に、受信側が、確認応答はしていないが既に受信しているデータブロックの情報を ACK セグメントに付加して送信側に送り返すことで、送信側はその情報から、受信側に到着しなかったセグメントだけを選択再送できるようにするものである。これにより、1 ウィンドウ内に複数のセグメントが廃棄された場合にも、タイムアウトを待たずに複数の廃棄セグメントを検知、再送できる。

図 2 に受信側からの ACK セグメントに付加される SACK オプションのフォーマットを示す。図のように、受信したが確認応答していないデータブロックの先頭シーケンス番号および最終シーケンス番号（正確には最終番号の 1 つ後ろの値）の組を 1 単位として、最も最近変化したブロックから順に TCP のヘッダ長が許す限りできるだけ多く付加する。付加するブロック数を n とすると、SACK オプションのオプション長は $8 \times n + 2$ バイトとなるが、TCP ヘッダのオプション長の最大値は 40 バイトであるから $n \leq 4$ となる。しかし、SACK オプションは通常、10 バイト長のタイムスタンプオプション [1] とともに用いられることが多いと思われるため、実際には $n \leq 3$ となる。送信側では、到着した全ての確認応答セグメントの SACK ブロックを記録しておき、Fast Recovery の際には、まだ選択確認応答されていないセグメントのうち既に選択確認応答されているセグメントよりもシーケンス番号の小さなものを再送する。

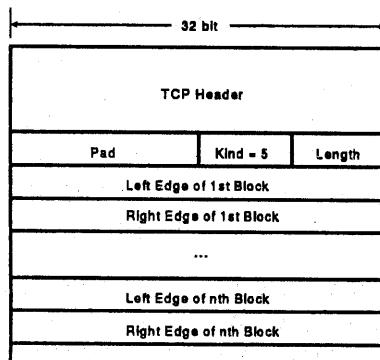


図 2: TCP SACK オプションのフォーマット

しかし、この実装では、選択確認応答されたセグメントより小さなシーケンス番号を持つセグメント

を廃棄されたものと見なしているため、再送セグメントが再び廃棄された場合にはそれを検知できず、タイムアウトを待たなければならないという欠点がある。その様子を図 3 に示す。ただし、セグメント長(MSS: Maximum Segment Size)、送信ウィンドウサイズはそれぞれ 1000byte、15000byte であり、また図中の●、□、△はそれぞれ、送信側の送信したデータセグメントのシーケンス番号、受信側から返ってきた確認応答の ACK 番号および SACK により選択確認応答されたセグメントのシーケンス番号を表すものとする。この図では、シーケンス番号 7000～9000 (○印) の 3 つのセグメントが連続して廃棄された後、シーケンス番号 7000 の再送セグメントが再び廃棄された場合の送信側の振舞いが示されている。3 個の重複 ACK を受け取り Fast Retransmit が行われるが、シーケンス番号 7000 の再送セグメントが再び廃棄されたために ACK が更新されないまま Fast Recovery を続けている（新たなセグメントを送信し続けている）。そして、受信側の告知したウィンドウサイズ分のセグメントを送信し終えた後、タイムアウトによりスロースタートモードでシーケンス番号 7000 のセグメントが再送されている。

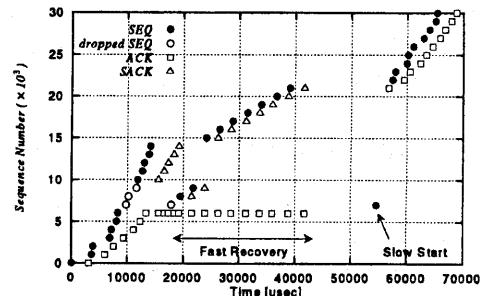


図 3: 再送されたセグメントが再び廃棄された場合の SACK TCP の振舞い

次章において、この欠点をも解消し、廃棄セグメントを受信されるまで何度も選択再送できる、新しいアルゴリズムを提案する。

4 ATCP プロトコル

4.1 ATCP の概要

ATCP は、ATM に直接アクセスしてデータ通信を行う、ATM ネットワーク用に最適化されたストリーム通信プロトコルである。前述のように、ATM

ネットワーク上ではデータの到着順序は入れ替わらないという特徴を活かして、ATCPではTCPに次のような変更を加えた。

まず、ATCPではセグメントヘッダに、従来のTCPで用いられるシーケンス番号(SEQ)および確認応答(ACK)のほかに、再送セグメントも含めて送信セグメントごとに1ずつ単調増加するセグメント番号(S_SEQ)を付加してデータを送信する。受信側では到着したセグメントごとにそのS_SEQの値をS_ACKフィールドに入れて確認応答を行う。送信側では、従来通り、確認応答セグメントのACKフィールドが更新されていればウインドウをスライドさせて新たなセグメントを送信するが、ACKフィールドは更新されなかつたがS_ACKフィールドであるセグメントが選択的に確認応答されていれば、S_ACKフィールドの示すセグメント番号よりも小さなセグメント番号を持つデータは全て廃棄されているとわかる。従って、Fast Recoveryの際には選択確認応答されなかつたものだけを再送できる。また、再送セグメントにも前回の送信時とは別のセグメント番号(S_SEQ)が付けられているため、再送セグメントが廃棄された場合でもそのセグメント番号より大きな値のセグメント番号を持つセグメントが選択確認応答されれば、再送セグメントの廃棄を再び検知でき、受信されるまで何度も再送可能である。

4.2 ATCPのセグメント・フォーマット

図4にATCPで用いるセグメントヘッダのフォーマットを示す。

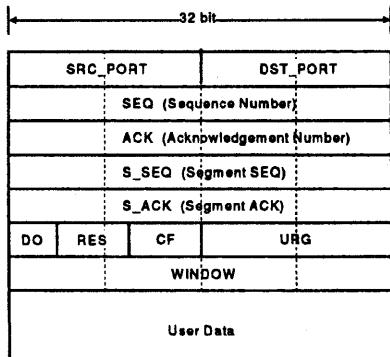


図4: ATCPのセグメントヘッダ・フォーマット

(1) SRC_PORT (16ビット): 送信ポート番号。

- (2) DST_PORT (16ビット):宛先ポート番号。
- (3) SEQ (32ビット):セグメント・データの最初の1バイトの順序番号が入れられる。
- (4) ACK (32ビット):シーケンス通りに受信した最終バイトの次の順序番号が入れられる。
- (5) S_SEQ (32ビット):送信セグメントごとに一意的に付けられるセグメント番号。
- (6) S_ACK (32ビット):受信したセグメント番号(S_SEQ)を確認応答するフィールド。
- (7) DO (4ビット):TCPのヘッダ長。32ビットを1単位として指定する。
- (8) RES (6ビット):将来使用する目的のフィールドで、現時点では未定義。0を代入しておく。
- (9) CF (6ビット):セグメントの種類を示すフィールドで、TCPと同様のフラグが定義される。
- (10) URG (16ビット):データの先頭から何バイトまでが緊急データであるかを示す。
- (11) WINDOW (32ビット):受信バッファの空き領域のバイト数を示す。

4.3 ATCPの輻輳制御・再送メカニズム

ATCPにおいても、TCPと同様にスロースタート、輻輳回避、Fast Retransmit/Fast Recoveryアルゴリズムを実装すべきである。ただし、輻輹時のACKに対する処理が従来のTCPとは少し異なり、送信側は”sndsseq”、“rcvsack”、“scount”、“maxscount”という新たな4つの内部変数を用いて次のような動作をする。ここで、”SEG.ACK”、“SEG.SACK”はそれぞれ確認応答セグメントのACK、S_ACKフィールドの値であり、送信側の保持する変数”sndsseq”には自分が最も最近送信したデータセグメントに付けられたセグメント番号(S_SEQ)が、また変数”rcvsack”には受信側から送られた確認応答のSEG.SACKの値がそれぞれ記録されるものとする。その他の変数は以下の文中で説明する。

- (1) 1つでも重複ACKが返ってきたら、直ちにssthreshを現在のcwndの半分の値に設定し、廃棄されたセグメントを再送する(Fast Retransmit)。そしてSEG.SACKで示されたセグメントを選択確認応答した後、現在ネットワーク中にあるセグメント数sndsseq - SEG.SACKおよび現在のウィンドウサイズ

の半分 ($sndseq - rcvsack$) / 2 の値をそれぞれ変数 *scount*、*maxscount* に記録する。

- (2) それ以降、ACK が到着するごとに、ネットワーク上から消えたセグメント数 (SEG.SACK - *rcvsack*) を求め、*scount* からその値を引く。(これにより、現在ネットワーク中に流れているセグメント数が正確に分かる。) *scount* が *maxscount* より小さくなれば、受信側の告知したウィンドウサイズを越えない範囲で選択確認応答されていないセグメントおよび新たなセグメントを最大 *maxscount - scount* 個まで送信し、輻輳直前にネットワーク中に流れているデータの半分の量を常に流し続ける。
- (3) SEG.ACK 番号が輻輳検知直前に送信していたシーケンス番号を越えたら、*cwnd* を(1)で設定した *ssthresh* の値にする。今、輻輹ウィンドウ *cwnd* は閾値 *ssthresh* に等しいので、これ以降、通常の輻輹回避モードに入る。

図 5 に、図 3 と同じ条件下での ATCP の振舞いを示す。この図より、再送セグメントが再び廃棄された場合でも、ATCP では ACK が返ってくる限りタイムアウトを待たずに廃棄セグメントの再送を何度も行えることが分かる。

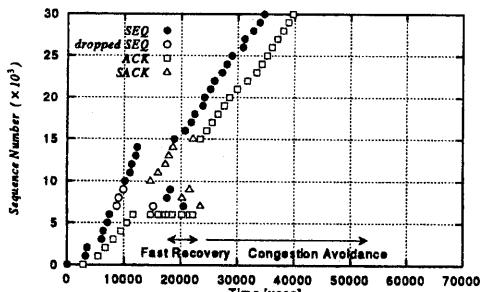


図 5: 再送されたセグメントが再び廃棄された場合の ATCP の振舞い

4.4 その他の特徴

ATCP では、受信されたデータセグメントが全て個別に選択確認応答されるため、これを利用すれば、タイムスタンプ機能を実現できる。すなわち、送信側がセグメントごとにその送信時刻を保持しておくことで、確認応答を受信する度に、現在時刻と選択確認応答されたセグメントの送信時刻からラウンドトリップ時間を計測することができる。

また、ATCP ではヘッダのチェックサムフィールドを削除している。ATCP は AAL5 フレームを利用しており、AAL5 のチェックサム機能によりデータの妥当性は保証されているため、TCP でのチェックサム計算は冗長であると思われる。

さらに、ウィンドウサイズを表示するフィールドを 32 ビット長に拡大した。これにより、従来の TCP でボトルネックになっていたウィンドウサイズの制約が取り除ける。

5 実験

5.1 実験に用いた環境

SunATM™-155 SBUS Card を搭載した 2 台の SPARC station 10 (CPU clock: 50MHz) を ATM スイッチに接続し、今回アプリケーションとして試作した ATCP のスループットを実測した。

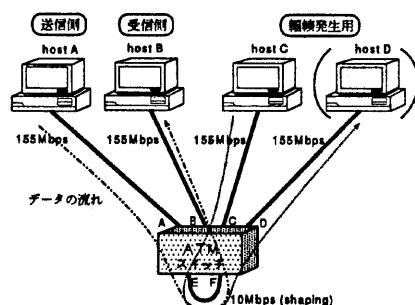


図 6: 実験ネットワーク構成

今回の実験では、遅延時間の小さな ATM-LAN でのデータ通信を想定して、図 6 に示すように通信ホスト間 (A-B 間) に ATM スイッチを 1 台接続し、A-E-F-B というポート経路で PVC を張って A から B にデータを送信した。また、ネットワークがある程度の輻輹状態にある環境を作るために、ポート E-F 間に 10Mbps のシェーピングを設定し、さらにスイッチにもう 1 台 ATM 端末 (C) を接続してポート C-E-F-D に別の PVC を張り、C から D に時々セルを送信することで、ポート E-F 間で輻輹を起こさせるようにした。

5.2 実験結果

実験ではまず、ネットワークに一切負荷をかけず、155Mbps のネットワーク帯域を全て使える状

態で、作成した各 TCP のスループットを計測した。ウィンドウサイズは 64Kbyte、最大セグメント長は 9Kbyte に設定した。結果を図 7 に示す。図には Solaris 2.4 用に実装された TCP-ONIP (TCP Over Non-existent IP) [4] および Solaris 2.4 において Classical IP over ATM を用いた従来の TCP のスループットも示してある。この図より、IP 層を除去して ATM に直接アクセスすると速度性能が向上することが分かる。

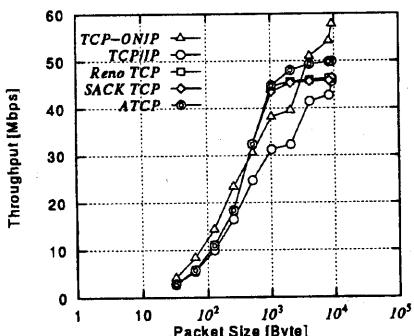


図 7: スループット測定結果

次に、ポート E-F 間に 10Mbps のシェーピングを設定し、さらにネットワークにあらかじめ負荷をかけた状態でスループットを測定した。送信データの最大セグメント長は 9Kbyte とし、また、負荷トラフィックは 64Kbyte の AAL5 フレームを連続して 3 回送信した後、一定時間休むというパターンを用いた。結果を図 8 に示す。

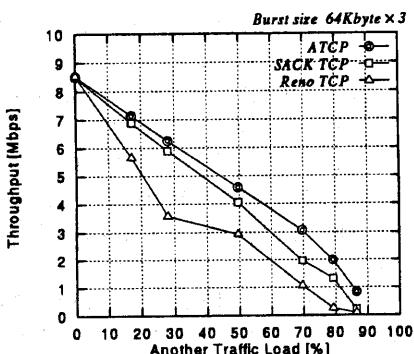


図 8: スループット測定結果（幅轍時）

図より、バースト性の高いトラフィックが他の存在する場合、Reno-TCP ではスループットがかなり低下することが分かる。これは、バーストトラフィックによって 1 ウィンドウ内の複数のセグメン

トが一度に破棄されたため、タイムアウトを頻繁に繰り返しているものと思われる。また、ATCP と SACK TCP において、ネットワーク負荷が大きくなればなるほど ATCP の方が良い結果が得られているが、これは頻繁に発生するバーストトラフィックにより再送セグメントが再び廃棄されてしまう確率が高くなっていること、確認応答が返ってくる限り廃棄セグメントを何度も再送できる ATCP が有利に働いているためだと思われる。

6 まとめ

本稿では、ATM ネットワーク用に最適化されたストリーム転送プロトコルを提案し、それを実装した。IP 層を取り除くことによりデータ転送効率は向上した。また、損失セグメントに対する回復アルゴリズムは従来の TCP よりも ATCP の方が優れていることが分かった。今後は、高帯域・高遅延の OLU ネットワーク上で実験を行い、高遅延環境で ATCP がどの程度スループットを維持できるか測定する予定である。

参考文献

- [1] D.Borman, R.Braden, and V.Jacobson. "TCP Extensions for High Performance", RFC1323, Internet Engineering Task Force, May 1992.
- [2] Matthew Mathis, Jamshid Mahdavi, Sally Floyd, and Allyn Romanow. "TCP Selective Acknowledgement Options", RFC2018, Internet Engineering Task Force, October 1996.
- [3] 釘本 健司、天海 良治、村上 健一郎. "絶対帯域見積りに基づく幅轍回避アルゴリズム", 情報処理学会 マルチメディア通信と分散処理ワークショップ, pp.245–pp.252, October 1996.
- [4] H. Afifi, D. Bonjour, O. Elloumi. "TCP over Non Existant IP for ATM Networks.", (Available via <ftp://ftp.rennes.enst-bretagne.fr/pub/reseau/afifi/tcp-onipv0.9.tar>)
- [5] W. Richard Stevens. "TCP Slow Start, Congestion Avoidance, Fast Retransmit, and Fast Recovery Algorithms", draft-stevens-tcpca-spec-01.txt, Internet-Draft. March 1996.