

3H-2 Ethernet上での全順序放送通信プロトコルの設計と実現

中村 章人、滝沢 誠
(東京電機大学理工学部)

1. はじめに

現在、複数の通信実体の協調動作が分散型データベースシステムで同時実行制御、コミットメント制御、分散型問合せ処理等を実現する上で必要とされており、このためには、複数の実体間での高信頼放送通信が求められている。本論文では、EthernetのMAC層で提供されている低信頼放送サービスを利用して複数の実体に対して全順序放送(TO)サービスを提供するプロトコルについて述べる。TOサービスを利用すると、全実体が同一のPDUを同一の順序で受信する。また、本プロトコル(TOプロトコル)の実現方法についても述べる。

2. 信頼性

従来のプロトコルでは、各実体はPDU p が正しく受信されたことを、 p が到着し、かつ p があるある条件を満たすこと、例えば通番のチェック等によって決定する。しかし、放送通信サービスに対する正しい受信の概念はこれより複雑である。正しい受信を決定するための方法として、ある1つの主制御実体がこれを行う集中型制御と、各実体が互いに通信し合うことによって自分自信で正しい受信の決定を行う分散型制御がある。TOプロトコルでは、後者を用いている。

[定義] 各実体 E_k は、以下の条件を満たすとき、PDU p を正しく受信したという。(1) E_k は p を受信する。(2) E_k は「 p の宛先内の全実体が p を受信した」ことを知る。(3) E_k は「 p の宛先の各実体は、全宛先実体が p を受信したことを知っている」ことを知る。□

(1)、(2)、(3)をそれぞれ p は E_k で受信された、前確認された、確認されたという。複数の実体がPDUを放送する状況で、各実体が同一のPDUを同一の順序で受信するような高信頼放送サービスを定義する。

[定義] 各PDU p と q が共通の宛先のSAPで同一の順序で受信されるとき、かつそのときに限りこの(N-1)高信頼放送サービスを全順序(TO)サービスという。□

従来の2つのSAP間のコネクションの概念を $n(\geq 2)$ 個に拡張したものが、群(cluster)である。

[定義] 1チャンネル(1C)サービスとは、PDUの紛失の可能性はあるが、受信されたPDUは全実体で同一の順序である低信頼放送サービスである。□

LANのMAC層と無線網は1Cサービスを提供している。

3. 1Cサービス上での全順序(TO)プロトコル

群は n 個の実体 E_1, \dots, E_n で構成される。各実体 E_k が送信したPDUを E_k は受信できるとする。各実体 E_k について、送信ログ $SL_k = (SP_k, \llcorner_k)$ を E_k が既に送信したPDUの系列、受信ログ $RL_k = (RP_k, \llcorner_k)$ を E_k が既に受信したPDUの系列とする。ここで SP_k と RP_k は各々、 E_k が送信したPDU

と受信したPDUの集合である。 E_k が q 以前に p を受信したとき RL_k 内で $p \llcorner_k q$ であり、 q 以前に p を送信したとき SL_k 内で $p \llcorner_k q$ である。 $p \llcorner_k q$ で $p \llcorner_k g$ かつ $g \llcorner_k q$ なる g が存在しないとき $p \rightarrow_k q$ である。

[定義] RL_k 内の全ての p と q に対して、もし p と q が E_j によって放送され、 SL_j 内で $p \rightarrow_j q$ で、 RL_k 内で $p \llcorner_k q$ ならば受信ログ RL_k は正しいという。□

RL_k^f を、 RL_k の先頭から f 番目までの部分系列とする。

[定義] 受信ログ RL_1, \dots, RL_n に対して、以下の条件が成り立つとき、かつそのときに限りPDU番号 f を障害点FPとする。(1)全ての j と k について、 $RL_j^{f+1} = RL_k^{f+1}$ で、これらの受信ログは正しい。(2)ある j について、 RL_j^f は正しくない。□

FPの存在は、ある実体があるPDUを受信できなかったことを意味する。 APL_k, PPL_k, RPL_k をそれぞれ確認されたPDU、前確認されたPDU、受信されたPDUからなる S_k の部分ログとする。 E_k が放送するPDU p は E_k が既に受信したPDUの確認通知を含んでいる。 E_k が放送する各PDU p は以下の情報を持っている。

$p.A_j = E_k$ が次に E_j から受信予定のPDUの通番
($j=1, \dots, n$)。

$p.SEQ = p$ の通番。

$p.SRC = p$ を放送する実体、つまり E_k 。

$p.BUF = E_k$ 内で利用可能なバッファ数。

各 E_k は、変数 SEQ_k とPDUの通番をチェックするためのマトリックス $AL_{pq}(p, q=1, \dots, n)$ を持っている。

$SEQ_k = E_k$ が次に放送する予定のPDUの通番。

$AL_{jj} = E_k$ が次に E_j から受信予定のPDUの通番。

$AL_{nj} = E_j$ が次に E_n から受信予定のPDUの通番。を、

AL_{j1}, \dots, AL_{jn} の中の最小値 $\min AL_j$ は、全実体が $g.SEQ < \min AL_j$ なるPDU g を E_j から既に受信していることを意味している。群内の各実体は、群開設手続き [TAK97a, b] によって各 E_j の初期通番 ISS_j と、空バッファ数 IBF_j を知っている。最初は $SEQ_k = ISS_k$ で $AL_{nj} = ISS_j$ ($h, j=1, \dots, n$)。

各実体は変数 F_1, \dots, F_n を持ち、 F_j は E_j 内の空バッファ数であり、最初 $F_j = IBF_j$ ($j=1, \dots, n$)である。 $\min F$ を F_1, \dots, F_n の中の最小値とする。

PDU p の送受信は、以下の条件を満たすとき行われる。

[受信条件] (1) $p.SEQ = AL_{jj}$. (2) $p.A_n < AL_{nn}$. ($h=1, \dots, n$). □

[受信動作] (1) $AL_{jj} = AL_{jj} + 1$, $AL_{nj} = p.A_n$ ($h=1, \dots, n$). (2) $F_j = p.BUF$. (3) p を RL_k の最後尾、つまり RPL_k の最後尾に追加する。□

[フロー条件] (1) $\min AL_k \leq SEQ_k < \min AL_k + \min(W, \min F/n)$. (2)各実体がPDUを受信可能である。□

[送信動作] (1) $p.BUF = F_k$, $p.A_j = AL_{jj}$ ($j=1, \dots, n$). (2) $p.SEQ = SEQ_k$, $p.SRC = E_k$, $SEQ_k = SEQ_k + 1$. (3) E_k は p を放送する。□

フロー条件が満たされなければ、 E_k は十分なバッファが利用できるようになるまで放送を待つ。

分散型制御において各実体 E_k が p の正しい受信をど

のように決定するかが問題となる。ここで、 p を E_j が放送したPDUとする。

[前確認(PACK)条件] $p.SEQ < \min AL_j$. □

[前確認動作] RPL_k 内の先頭から p までのPDUを RPL_k から取り出し、 PPL_k の最後尾に追加する。□

$$\begin{array}{ccc} PPL_k & & RPL_k \\ < \dots a > < b \dots p \dots > & == > \\ < \dots a & b \dots p & > < q \dots > \end{array}$$

[定義] 各 E_k と RL_k 内のPDU p と q に対して、 q が E_n で p を前確認し、 E_n で p を前確認する $g <_k q$ なるPDU g が存在しないとき q は E_n について p を最初前確認するPDUという。各 E_j について、 p を最初前確認するPDUの中で、最後に受信したものを p を最後前確認するPDUという。□

[確認(ACK)条件] PPL_k 内のPDU p を最後前確認するPDUが前確認される。□

[確認動作] PS_k 内の先頭から p までのPDUを PPL_k から取り出し、 APL_k の最後尾に追加する。□

$$\begin{array}{ccc} APL_k & & PPL_k & & RPL_k \\ < \dots a > < b \dots p \dots > < .g \dots > & == > \\ < \dots a & b \dots q & > < q \dots g & > < \dots & > \end{array}$$

PDUが紛失した点、つまり障害点FPは E_k がPDU p を受信する度に発見し、リセット手続きが適用される。

[紛失条件] (1) E_j から p を受信したとき、 $p.SEQ > AL_j$ ならば、 $AL_j \leq g.SEQ < p.SEQ$ なるPDU g を E_j から受信していない($j=1, \dots, n$)。 (2) E_n から q を受信したとき、ある j ($j \neq n$)について、 $q.A_j > AL_j$ ならば、 E_k は $AL_j \leq g.SEQ < q.A_j$ なるPDU g を E_j から受信していない($h=1, \dots, n$)。□

[リセット手続き] (1) E_k はPDUの受信を停止し、 $r.A_h = AL_{h_n}$ ($h=1, \dots, n$)なるRST(RESET) PDU r を放送し、 $SEQ_k = AL_{k_k}$ とする。 (2) E_j が E_k からRST r を受信したら、各 h について RL_k が $r.A_h \leq p.SEQ$ なる E_n からのPDU p を含むならば、 $p <_k g$ である全てのPDU g を RL_k から取り除く。同時に、ALリセット手続きを適用してALを更新する。 E_j はPDUの受信を停止し、 $ra.A_h = AL_{h_n}$ ($h=1, \dots, n$)なるRST_ACK PDU ra を放送し、 $SEQ_j = AL_j$ とする。 (3)全実体からRST_ACKを受信し、各 h について $r.A_h = AL_{h_n}$ であれば、 PPL_k と RPL_k 内のPDUを APL_k に移す。□

[ALリセット手続き] 各 E_j と $p = \text{last}(RL_{k_j})$ に対して、 $AL_{j_n} = p.SEQ$ とする($h=1, \dots, n$)。□

PDUの紛失は、タイムアウト処理によっても発見される。ある実体 E_k がPDU p を放送したにも関わらず、 E_k を含む全実体が p を受信していないとする。 E_k が $p \rightarrow_k g$ なるPDU g を放送しなければ、各実体は p の紛失を発見出来ない。 E_k は p を放送した後、タイムアウトが起きたら p の紛失を発見する。この場合、どの実体も p を受信していないので、 E_k は p を再放送できる。

4. 評価

本プロトコルの性能を、PDU数と必要時間で評価する。PDU数は、PDU p を確認するために送信されるPDU数とする。ラウンドとは、あるSAPから宛先までの最大遅延時間である。必要時間は、ラウンド数とする。 n を実体数としたとき、性能は以下ようになる。

PDU数 最良 $1+(n-1)+n = 2n$ 個
最悪 $1+(n-1)+(n-1)^2 = n^2-n+1$ 個

必要時間 最良 3 ラウンド

Ethernet MACサービスの様にPDUを並行放送できない場合 最良 $1+(n-1)+n = 2n$ ラウンド

最悪 $1+(n-1)+(n-1)^2 = n^2-n+1$ ラウンド

5. TOプロトコルの実現

データ転送手続きは、3つのキューPRQUE、ARQUE、PTQUEにより実現されている。各 E_k の部分ログPPL $_k$ 、RPL $_k$ は各々ARQUE、PRQUEに記憶される。

[送信] フロー条件が満たされるならば、PDU p をPTQUEに記憶し、 p を放送する。□

[受信] E_j から p を受信したら、(1)もし p が受信条件を満たせば、 p を受け入れPRQUEに記憶する。(2)PRQUEの先頭のPDU q が前確認条件を満たす間、 q をPTQUEから取り出しARQUEに記憶する。 $p.SRC = E_k$ ならば、 p をPTQUE、つまりPTQUEの先頭から取り出す。 $q.RPT=g$ であれば、ARQUEの先頭から g までのPDUをARQUEから取り出す。つまり、 E_k で確認される。もしPRQUEから最後に取り出したPDUが q であれば $p.RPT=q$ とする。(3)もし放送するデータがあれば送信動作を行い、そうでなければ確認通知を含むPDUを放送する。□

[障害] (1)もし紛失条件が成り立てば、リセット手続きを行う。□

6. まとめ

現在、TOプロトコルをEthernet MACサービスを用いて、Unix 4.2BSDとSystem V上でC言語で実現している。プロセス間の通信には、Unixのsocketインターフェイスを用いている。Ethernet上には、現在m380q、a400 (Facom)、Sun3ワークステーション3台が接続されている。現在、このシステムを使ってTOプロトコルの性能評価を行っている。問題はバッファサイズで、本プロトコルでは、従来の一対一通信に比べて最悪の場合、 n^2 倍以上のバッファが必要になる。しかし、今日のハードウェア技術により記憶装置のコストは非常に低くなっているため、この問題は数M byteの記憶装置を用いることで解決できると思われる。

参考文献

- [BRA] Bracha, G. and Toueg, S., "Asynchronous Consensus and Broadcast Protocols," JACM, Vol.32, No.4, 1985, pp.824-840.
[CHA] Chang, J.-M. and Maxemchuck, M.F., "Reliable Broadcast Protocols," ACM TOCS, Vol.2, No.3, 1984, pp.251-273.
[NAK] 中村 章人, 滝沢 誠, "多チャンネル上の全順序放送通信プロトコル", 情報処理学会MDP研究会39-1, 1988
[SCH] Schneider, F., Gries, D., and Schlichting, R.D., "Fault-Tolerant Broadcasts," Science of Computer Programming, Vol.4, 1984, pp.1-15.
[TAK87a] Takizawa, M., "Design of Highly Reliable Broadcast Communication Protocol," Proc. of IEEE COMPSAC87, 1987, pp.731-740.
[TAK87b] Takizawa, M., "Cluster Control Protocol for Highly Reliable Broadcast Communication," Proc. of the IFIP Conf. on Distributed Processing, Amsterdam, 1987.