

大規模網のための送信順序保存放送通信手順

4 P - 3

高村 昌興, 中村 章人, 滝沢 誠

東京電機大学

1はじめに

グループウェア等の新しい分散型応用で、OSIといった従来の1対1通信プロトコルに加えて、複数エンティティ間のグループ通信プロトコルが研究開発されてきている。これらは、通信エンティティ数が数十程度までの網を対象としており、数百以上のエンティティを含んだ大規模網では、負荷が大きくなり、実用的でない。例えば、放送通信プロトコル[1, 2, 3]では、エンティティ数nに対して、PDU数と処理負荷は、 $O(n)$ から $O(n^2)$ になる。本論文では、同一通信チャネルに接続された複数のエンティティを、論理的に分割することにより、処理負荷を減少させることを試みる。ここで、エンティティのグループを群とする。

2章では、群内で、受信の原子性と順序を保証する送信順序保存放送通信(OP)プロトコル[3]の概要を示す。3章では、群を論理的に分割した要素群とそれらの間を取り持つゲートウェイエンティティのモデルについて述べる。4章では、OPを拡張した大規模群送信順序保存放送通信(LOP)プロトコルについて述べる。

2 送信順序保存放送通信(OP)プロトコル

2.1 サービス

単一チャネル(1C)サービス[3]は、Ethernet MACや、無線システムで提供されるサービスを抽象化したものである。ここでは、各エンティティは、同順序で全PDUを受信するが、バッファ溢れ、オーバーランにより、PDUを受信し損ねる場合がある。OPプロトコルは、1Cサービスを利用し、まず、複数エンティティ E_1, \dots, E_n 間に群Cを確立する。群は、二つのエンティティ間のコネクション概念を、 $n(\geq 2)$ 個のエンティティ間に拡張した概念である。Cが確立された後、一意な群識別子が得られる。群識別子を持ったPDUが、C内のエンティティに送られる。OPプロトコルでは、各PDUは、C内の送信元の順序を保存しながら全エンティティに送られる。

2.2 三相による正しい受信概念

エンティティ E_1, \dots, E_n が提供する群Cで、 E_k が放送したPDU p は、受理、前確認、確認といった三相手続きにより正しい受信が行なわれる。

受信 p が E_j で受信される

前確認 E_j が、「 p の全宛先が p を受信した」ことを知る

確認 「 p の各宛先は、『全宛先が p を受信した』ことを知っている」ことを知る

2.3 データの転送と受信

p は PDU を示し、 $p.F$ により、 p の属性 F を示すとする。 $p.CID$ は、C の群識別子である。 $p.SRC$ は、 p の送信

元 E_k である。 $p.SEQ$ は、 E_k が送信したPDUの送信シーケンス番号である。 $p.ACK_j$ は、 E_k が E_j から次に受信予定のPDUの受信シーケンス番号である($j = 1, \dots, n$)。 $p.DATA$ は、データである。

E_k は、各 E_j に対して、送受信したPDUの履歴を示す受信ログ RL_{kj} と送信ログ SL_{kj} を持つ。これは、各々、受理、前確認、確認されたPDUが記録される副受信ログ RRL_{kj} 、 PRL_{kj} 、 ARL_{kj} から構成される。 E_k は、送信ログ SL_{kj} を持つ。 E_k は、PDUを放送するために変数 SEQ と REQ_j を持つ。 E_k が、 p を放送するとき、 $p.SEQ := SEQ$ 、 $p.ACK_j := REQ_j$ とし、 $SEQ := SEQ + 1$ とする。

E_k は、各 E_j に対して、受信用変数 REQ_j を持つ。 E_j からの p が、 E_k に届いたとき、 $REQ_j = p.SEQ_k$ ならば、 E_k は p を受理し、 REQ_j に1が加えられる。

E_k は、 $n \times n$ 行列 AL と PAL を持つ。 AL は、 E_k が「 E_i が、 SEQ が、 AL_{ij} 以下であるPDUを E_j から受信した」ことを知っていることを示す。 E_i からの p が、 E_k で受信されたとき、 $AL_{ij} := p.ACK_j$ となる。 $\min(AL_{1j}, \dots, AL_{nj})$ は、 SEQ がこれ以下のシーケンス番号を持つ E_j からのPDUが、全エンティティで受信されたことを、即ち、 E_k で前確認されたことを示す。

PAL は、 E_k が「 E_i が、 SEQ が、 PAL_{ij} 以下である E_j からのPDUを前確認した」とことを知っていることを示す。 E_i からの p が、 E_k で前確認されたとき、 $PAL_{ij} := p.ACK_j$ となる。 $\min(PAL_{1j}, \dots, PAL_{nj})$ 以下である E_j からのPDUが、全エンティティで前確認されたことを、即ち、 E_k で確認されたことを示す。

3 複合群とゲートウェイ

従来の群を、平群とする。平群のOPプロトコルでは、処理負荷が $O(n^2)$ であることから、大規模システムには適用できない。このために、一つの通信チャネルに接続されたエンティティを、論理的に分割し、それらの代表者が隣接している群に対して、受信状態を知らせることで、処理負荷の減少を試みる。ここで、分割された複数の群(要素群)から構成される群を、複合群とする。そして、要素群の代表者であり、かつ、それらの間の通信を行なうエンティティをゲートウェイGEとする[図1]。




図 1: 複合群CとゲートウェイGE

複合群Cは、要素群 C_1, \dots, C_h から構成される。 C_1, \dots, C_h は、ゲートウェイ GE_1, \dots, GE_g により接続される。従って、複合群 $C = \langle C_1, \dots, C_h, GE_1, \dots, GE_g \rangle$ とする。各 GE_i は、一般に $k(\geq 2)$ 個の要素群 C_{i1}, \dots, C_{ik} を相互接続す

る。この k を GE_i の結合度とする。図 1 の例では、 GE_1 の結合度 3、 GE_2 、 GE_3 、 GE_4 の結合度 2 である。ここで、複合群は、以下の性質を持つ。

[性質] 任意の二つの要素群 C_i と C_j 間には、必ず 1 つのゲートウェイエンティティが存在するとする。□

各 C_i 内で、PDU が、OP プロトコルに従って、 C 内に放送される。このとき、各要素群が、 C より少ないエンティティを含むので、各エンティティでの処理負荷を減少できる。更に、もし、各要素群が、一定数 m 以下の固定エンティティを含むならば、各エンティティのプロトコル処理の負荷を一定値 $O(m^2)$ に抑えられる。

4 複合群での OP プロトコル

4.1 PDU 形式

複合群 $C = \langle C_1, \dots, C_h, GE_1, \dots, GE_g \rangle$ を考える。各 C_i は、エンティティを E_{il} ($l = 1, \dots, m_i$) とゲートウェイ GE_{ij} ($j = 1, \dots, g_i$) を持つ。ここで、 GE_{ij} を E_{it} ($t = m_i + j$) とも書く。 E_{is} ($s = 1, \dots, c_i (= m_i + g_i)$) で放送される各 PDU p は、OP プロトコルの PDU 形式に加えて、 $LSRC$ を持つ。これは、 $p.SRC$ は、 C_i 内の送信元エンティティ (E_{il}) であるのにに対し、 $p.LSRC$ は、PDU を放送した送信元エンティティである。例えば、 E_{il} がゲートウェイでないときは、 $LSRC = SRC$ である。 E_{il} がゲートウェイのときは、 p を最初に送信したエンティティである。

4.2 手順

要素群 C_i を考える。 C_i 内で、ゲートウェイでないエンティティ E_{il} を通信エンティティとする。 C_i は、通信エンティティ E_{i1}, \dots, E_{im_i} から構成されるとする。更に C_i は、ゲートウェイ $GE_{i1}, \dots, GE_{ig_i}$ により接続されているとする。即ち、 $C_i = \langle E_{i1}, \dots, E_{im_i}, GE_{i1}, \dots, GE_{ig_i} \rangle$ である。通信エンティティ E_{il} は、平群の OP プロトコルと同一の動作を行なう。ゲートウェイ GE_{ij} の動作について考える。

C_i 内のある GE_{ij} が、 $C_{ij1}, \dots, C_{ijf_{ij}}$ を接続するとする ($j = 1, \dots, g_i$)。 GE_{ij} は、各要素群 C_r に対する処理を行なう副エンティティ SGE_{ijh} から構成される ($h = 1, \dots, f_{ij}$)。

SGE_{ijh} が、 E_{il} で放送された p を受信する。このとき、 $p.SRC = p.LSRC$ ならば、 SGE_{ijh} は SGE_{ijh} ($h \neq s$) に p を渡す。各 SGE_g は、 p を C_g 内で放送する。 $p.SRC \neq p.LSRC$ ならば、 SGE_{ijh} に渡さない。これは、 $p.SRC = p.LSRC$ ならば、 E_{il} が、実際の送信元エンティティであり、隣接している要素群内に放送しなければいけない。しかし、 $p.SRC \neq p.LSRC$ ならば、 E_{il} は別のゲートウェイであるので、これ以上、隣接している要素群に放送する必要がない。

GE_{ij} は、以下の受理と送信動作を行なう。

- (1) C_i の E_{il} が、 p を放送したとする。 $p.SEQ = REQ_j$ ならば、 SGE_{ijh} は、 p を受信する。そして、 $REQ_j = REQ_j + 1$ となる。 $p.SRC \neq p.LSRC$ ならば、 p を $SGE_{i1}, \dots, SGE_{ig_i}$ に送る。 $p.SRC = p.LSRC$ ならば、OP プロトコルに従って、 p の確認通知を含んだ PDU を C_i に放送する。
- (2) SGE_{ijh} が、 SGE_{ijr} から p を受信したとする。このとき、次の PDU q を作る。 $q.CID = C_i$ 、 $q.SEQ = SEQ$ 、 $SEQ = SEQ + 1$ 、 $q.SRC = p.SRC$ 、 $q.LSRC = GE_{ik}$ 、 $q.DATA = p.DATA$ 、 $q.ACK_j = REQ_j$ を行なう ($j = 1, \dots, i$)。この後、 q を放送する。 q を LSL に、 p を LRL_{ijr} に記憶する。 LSL の q に対して、 $q.ptr = p$ なるポインタ ptr を設ける。

次に、図 2 の例を用いて前確認と確認動作について考える。まず、 C_1 内の E_{11} が、 p を放送したとする。 GE 内

の SGE_1 は、 p を受信して SGE_2 に渡す。 SGE_2 は、 p から q を作り、 q を C_2 内に放送する。 C_1 内で受信したエンティティ E_{11} 、 E_{12} 、 E_{13} から、 p についての受理情報を含んだ PDU を受信したならば、 SGE_1 は、 SGE_2 にこれを放送する。 SGE_1 は、 GE 内の全副ゲートウェイから、この通知を受けたとき、 p の受理情報を含んだ PDU r を C_1 内に放送する。即ち、 $r.ACK_1 = p.SEQ + 1 (= REQ_1)$ であり、各エンティティがこれを受信したとき、 p が前確認される。同様に r について、前確認が行なわれたとき、 p の確認がされる。




図 2: PDU p についての三相手続き

5 結論

本論文で、大規模なシステムの複数エンティティ間での高信頼放送通信を有効に行なうための手順について述べた。本プロトコルでは、1C サービス網に接続されたエンティティを、要素群として論理的に分割することで、各エンティティの処理負荷を減少できる。

参考文献

- [1] Nakamura, A. and Takizawa, M.: *Reliable Broadcast Protocol for Selectively Ordering PDUs*, Proc. of the 11th IEEE International Conf. on Distributed Computing Systems (ICDCS-11), pp.239-246 (1991).
- [2] Nakamura, A. and Takizawa, M.: *Priority-Based Total and Semi-Total Ordering Broadcast Protocols*, Proc. of the 12th IEEE International Conf. on Distributed Computing Systems (ICDCS-12), pp.178-185 (1992).
- [3] Takizawa, M. and Nakamura, A.: *Partially Ordering Broadcast (PO) Protocol*, Proc. of the 9th IEEE Conf. on Computer Communications (INFOCOM), pp.357-364 (1990).