

分散型OSの構築に関する一考察

小島 一記、吉田 勇、山崎 晴明
(沖電気工業株式会社 総合システム研究所)

1.はじめに

近年、計算機の利用形態は従来の集中型の大型計算機を回線を介して端末から共同利用する形態から、各部所に中・小型の計算機を設置して分散処理をする形態へと移行しつつある。オフィスにおいても各部門にオフィスコンピュータやワークステーション、パーソナルコンピュータ等が多数導入されてきており、それらの資源を有効利用するために、それらをローカルエリアネットワーク(LAN)で結合するのが一般化している。

このようなオフィスの分散環境においては、真に分散資源の有効利用を実現するためには、ただ単に計算機間をLANで結合するだけではなく、利用者に対してはLANを意識させずに、あたかもひとつの計算機を利用しているのと同じ環境すなわち、ネットワーク・トランスペアレンシィを提供することが重要である。

このような環境をオペレーティング・システムのレベルで提供するのが分散型オペレーティング・システム(以下分散OSと略す)であり、現在国内外の大学・研究所を中心に研究が進められている。^{1), 2), 3), 4), 5), 6)}

分散OSが満たすべき機能としては以下のものが考えられる。^{7), 8)}

- (1) ロケーショントランスペアレンシィ機能
ユーザが、資源の物理的位置を意識せずにアクセスできる機能
- (2) 資源の共有制御機能
共有されるべき資源(周辺装置など)に対する排他制御、同時実行制御、デッドロック検出/回避機能
- (3) 異機種間通信機能
各サイトのOS、ハードウエアの差異を吸収しサイト間の通信を可能とする機能
- (4) プログラムのモビリティーを保証する機能
どのサイトにおいてもコードの変更なしにプログラムを実行可能とする機能
- (5) 統一的コマンドインターフェース機能
OSに対するコマンド言語をすべてのサイトで統一的にみせる機能
- (6) アクセス制御と機密保護機能
共有資源のアクセス権のチェックによる安全性保証と機密保護機能
- (7) 信頼性保証機能
障害部分の検出と隔離、復旧時の処理及びリモート診断等の保守機能
- (8) 負荷分散機能
各サイトの負荷状態の把握、スケジューリングと処理の割り当て機能
- (9) 高水準言語のサポート機能
並列実行の特色を活かせる高水準言語をサポートする機能
- (10) アカウント機能
システム内におけるアカウントを取得する機能
- (11) 既存ソフトウェアの実行機能
既存のソフトウェアをコードの変換することなしに実行可能とする機能

筆者等は、現在、上記の各機能を満足する分散OSの開発を目指して、そのための基本のアルゴリズムを研究中である。

特に LANをベースとしたシステムにおいてはネットワーク資源の共有制御機能が重

要である。ネットワーク上に分散された資源の共有制御を考察する場合、デッドロックの防止、検出あるいは回復といった問題が重要な技術的課題となる。

そこで、本稿では特にこの問題を取り上げ、筆者等が考察を行った新しい分散型デッドロック検出アルゴリズムについて報告する。

2. 分散型デッドロック検出アルゴリズム

分散システムにおける共有資源アクセスに伴うデッドロック検出法として、いくつかの方式が提案されている。^{9), 10), 11)}

検出を分散型で行う方法として IBM の OBERMARCK¹²⁾により提案された方法がある。ここではその概要を述べ、次に、本提案の方式について議論する。

2. 1 分散システムのモデル¹²⁾

対象とする分散システムを以下の定義および仮定によりモデル化する。

(1) トランザクションとは、1つのサイトで作られるが、このトランザクションは、別のサイトに代理としてエージェントを置くことができる。あるトランザクションのエージェントは、そのサイト上で他のトランザクションのエージェントと資源を競合し、その結果待ち状態となる場合がある。

(2) トランザクションが多数のサイトにエージェントを持つ場合、すべてのエージェントは、通信リンクによって直接または間接に結合される。ここで、もしトランザクション N 個のエージェントを持つとするとただ 1 個のエージェントのみがアクティブであり、メッセージの送信を期待されており、他の N - 1 個のエージェントは、メッセージの受信を待っている。

図 1 にグローバルな transaction wait for graph (TWFG) の例を示す。グラフのノードは、トランザクションを表し、エッジは、ノード（トランザクション）の待ち関係を示す。ノード 1 からノード 2 へのエッジは、ノード 2 のトランザクションをノード 1 のトランザクションが待っていることを意味する。

集中型デッドロック検出アルゴリズムは、図 1 のグラフ上で 3 個のデッドロックを検出する。集中デッドロック検出アルゴリズムは、資源待ち要求を持つ "VICTIM (いけにえ)" を選ぶことによりデッドロックサイクルを解除する。VICTIM はアポートし、その処理は UNDO され資源は解放される。

分散システム上においては図 1 のグラフは多くのサイト上のトランザクションの処理として分解される。前に述べた仮定の上で、図 1 のグラフの可能な分解を問題の一貫性を保ちつつ図 2 に示した。ここでは、トランザクション 2 はサイト B での仕事を終え、サイト A に移住する。そこではトランザクション 3 と 7 によって共有されている資源をトランザクション 2 は待っている。トランザクション 3 はサイト A で仕事をし、サイト C に移住する。サイト C ではトランザクション 3 は、トランザクション 4 を待っている。トランザクション 4 は、サイト B に移住する。そこではトランザクション 2 と 6 が共有している資源をトランザクション 4 は待っている。同様に、グラフのそれぞれの部分を説明することができる。

問題の定義により A ~ C のサイトそれは、各トランザクションのエージェントのペアを結合した通信リンクを持たねばならない。各トランザクションのエージェント間の最小リンクを図 3 に示す。受信を待っているトランザクションエージェントから送信を期待しているトランザクションのエージェントへと矢印は、向いている。




図 1 集中型システムとして見た TWF G




図 2 3 つのサイトに分割された TWF G




図 3 コミュニケーションリンクを伴った TWF G

2. 2 OBERMARCK のアルゴリズム^{12), 13)}

OBERMARCK のアルゴリズムは 'External' (EX) と呼ばれる TWF G 上の特別なノードを利用する。External (EX と略す) は、自サイトの外部にある分散 TWF G 部分を表している。例えば図 3 のサイト A では EX → 2 → 3 → EX および EX → 2 → 7 → EX というサイクルが作られる。

- (1) 各サイトはローカルに TWF G を作る。
- (2) 他のサイトから送られたグローバルエッジリスト (GEL) を現在の TWF G に追加する。GEL は、EX を含むサイクルの情報であり、例えば EX → 2 → 3 → EX のサイクルで考えると EX, 2, 3 のようなリストになる。
- (3) 新しい TWF G 上のサイクルをリストする。
- (4) EX を含まないサイクルがあればデッドロックであり、サイクルを破壊するため VICTIM を選択する。VICTIM を選ぶと、その VICTIM を含むすべてのサイクルを取り除く。VICTIM が分割されたトランザクションであれば、関連するサイトに VICTIM の通知を行う。
- (5) EX を含むサイクルを検査し、もし EX が待っているノードのトランザクション番号が EX を待っているトランザクション番号より大きいならば、そのサイクルの情報を GEL に入れ、関連するサイトに送信する。

2.3 本提案のアルゴリズム

ここでは、トランザクション、EXternalノードの定義、アルゴリズムの分散化された実行環境、アルゴリズム説明のために導入された仮定について、OBERMARCKの論文¹²⁾のものと同様とする。以下に、提案する検出アルゴリズムの記述に必要となる定義および検出アルゴリズムについて述べる。

2.3.1 用語の定義

(a) possible pathの定義

今、ネットワークにより接続されている分散システムの内の1つのローカルなサイトに注目する(図4参照)。このサイト内において、トランザクション*i*, *j*と*j*から*i*に到る待ち関係が存在し、かつトランザクション*i*がEXノードに対してSOURCEであり、トランザクション*j*がEXノードに対してSINKであるとき、*i*から*j*にはそのサイトにおいてpossible pathが存在するという。また、このようなpossible pathを(*i*, *j*)と記述する。これは、グローバルに*i*から*j*に到るpathが存在すれば、グローバルデッドロックが存在する可能性があるという意味である。




図4 possible pathの概念




図5 possible pathの例

前述(2.2節)したOBERMARCKの論文のサイトAの例においてpossible pathを考えると、(7, 2), (3, 2)となる(図5参照)。

(b) possible path間の演算

2つのpossible path(以後ppと省略する)、(*i*, *j*)と(*j*, *k*)の間の演算を式2-1, 2-2のように定義する。

$$(\text{i}, \text{j}) \cdot (\text{j}, \text{k}) = (\text{i}, \text{k}) \quad \dots \dots \text{式} 2-1$$

$$(\text{l}, \text{m}) \cdot (\text{n}, \text{l}) = (\text{n}, \text{m}) \quad \dots \dots \text{式} 2-2$$

演算の結果として得られた(*i*, *k*)をpp(*i*, *j*)とpp(*j*, *k*)の結合ppと呼ぶ。この演算子は、前者ppの右要素または、左要素と後者ppの左要素または右要素が一致した時のみ演算可能であり、常にpp間に結合演算が定義されるとは限らない。pp(*i*, *j*)に対し、左側に*j*または右側に*i*を含むppの集合Rを(*i*, *j*)と結合可能なpp集合と呼ぶ。

(c) 逆possible pathの定義

pp(*i*, *j*)に対し、pp(*j*, *i*)を逆ppとする。

(d) 関連possible path集合 R_i の定義

pp の集合 R が与えられたとき、要素 i を右側もしくは左側に含む pp の集合を i に関する possible path 集合として関連possible path集合 R_i と呼ぶ。ここでその集合 R_i の要素の数を $n(i)$ であらわす。

2.3.2 検出アルゴリズム

各サイトのデッドロック検出アルゴリズムは、possible path の導出と解析を行なう。以後のアルゴリズムで用いる「possible情報」とは、ローカルなサイトのデッドロック検出の結果として一つのサイトから一つ以上の各サイトへ送られるものである。具体的には、送出すべき条件を満たしたpossible path の集合またはVictimの番号である。

各サイトのデッドロック検出アルゴリズムは以下のように行なわれる。

(1) トランザクションの間の待ち関係の情報を用いてローカルな各サイト中で、 pp 集合 R を導出する。

(a) 同一サイト内の pp 集合 R の要素の間に逆 pp 関係 $[(i, j) \text{ と } (j, i)]$ のような pp の関係] が存在するものがあるか調べる。

(b) 存在する時は、Victimを選択してUNDO処理を行なう。

Victim選択の基準は以下のようである。possible path (i, j) と (j, i) の場合で考えると、同一サイト中の i または j の関連possible path集合 R_i の要素数 $n(i)$ と $n(j)$ を求め、

$n(i) > n(j)$ なら i を、

$n(i) < n(j)$ なら j を、

$n(i) = n(j)$ なら $\max(i, j)$

をVictimに選ぶ。

(2) 各サイトでローカルに導出された pp 集合 R の中に、左要素のトランザクション番号が右要素のトランザクション番号より大きい pp が存在する時、その pp の各要素のトランザクションのエージェントの存在するサイトに pp 情報として pp を伝送する。

(3) pp 情報を受信したサイトでは、サイトの中の pp の集合 R に、受信された pp を組み込む。次に新しい pp 集合 R の中に、逆 pp 関係を持つ pp の組が存在するかを調べる。

(a) もし存在すれば、(1)と同様のUNDO手順を実行する。

(b) もし存在しなければ、 pp 集合 R の中の pp 間で結合演算を実行し、結合 pp を求める。

(c) 結合 pp の演算結果を含む pp 集合 R の中に、逆 pp 関係が存在するかを調べる。もし存在すれば、Victimを選択し、UNDO手順を実行する。また結合 pp が(2)の条件を満たすならば(2)と同様の処理を行なう。

以下すべての、結合 pp を導出するか、逆 pp が導出されるまで処理を繰り返す。

UNDO手順

(a) Victimの通知要求をすべてのサイトにブロードカストし、通知する権利(VICTIM通知権)を取得する。

- (b) 選択したVictim番号をすべてのサイトにブロードカストする。(Victimの通知)この時、他のサイトのVictim通知は待たされる。(つまり、Victim通知は並列には実行しない。)
- (c) Victimを通知されたサイトでは、そのサイト中のVictimであるトランザクションを取り除く。ここで、Victimに選ばれたトランザクションのエージェントを持つサイトでは、今までに作成されたpp集合Rを消去し、再びローカルにppを導出する。またエージェントを持たないサイトでは、今までに受信したpp情報及びそれによって計算された結合ppを消去する。
- (d) Victimを通知したサイトが、すべてのサイトからUNDO処理実行終了の通知を受信したならば、このサイトは、すべてのサイトに、Victim通知権の放棄の通知をブロードカストする。
- (e) 別のVictim通知要求があれば、以上の手順を同様に実行する。

3. 分散型デッドロック検出の例

実際の分散型デッドロック検出アルゴリズムの動作を理解するために例を示す。例題としては、前述の図3を使用する。以下に検出の流れを説明する。

SITE	PP INF. (FROM)	PP (IN SITE)	UNION PP	PP INF. (TO)	SITE	PP INF. (FROM)	PP (IN SITE)	UNION PP	PP INF. (TO)
A	--	(3. 2) (7. 2)	--	(3. 2) B, C (7. 2) B, C	A	* (8. 7) * (4. 3)	* (3. 2) * (7. 2)	(4. 2) (8. 2)	(4. 2) B, C (8. 2) B, C
B	--	(7. 8) (2. 4)	--	--	B	* (3. 2) * (7. 2) * (8. 7) * (4. 3)	* (7. 8) (2. 4) * (3. 4) * (2. 3)	* (7. 4) * (2. 3)	VICTIM=7 VICTIM=3
C	--	(8. 7) (4. 3) (4. 7)	--	(8. 7) A, B (4. 3) A, B	C	* (3. 2) * (7. 2)	* (8. 7) * (4. 3) * (4. 7)	(8. 2) (4. 2) (4. 2)	(8. 2) A, B (4. 2) A, B (4. 2)

図6 検出アルゴリズムの反復 1

図7 検出アルゴリズムの反復 2

第一の検出アルゴリズムの反復(図6参照)は、各サイトにおけるデッドロック検出器のローカルな処理の結果として得られる。これは、各サイトにおけるデッドロック検出アルゴリズムの反復の結果である。ここでは、ローカルなpossible pathに結合させる他サイトからのpossible path情報はない。サイトAではEXTERNAL(EXであらわす)は、トランザクション2を持つことを示す。つまりトランザクション2は、EXノードに対するSINKとなっており、このサイトでトランザクション2を表現するエージェントを関係づけるコミュニケーションリンクの状態を表している。また、トランザクション3

と 7 は EX ノードを待っており、EX ノードに対する SOURCE になっている。ここでは、2 つ の possible path がこのサイトで導出される。そして pp (in site) の行に記入される。この pp は、左要素が右要素より大きいので各要素のエージェントの存在するサイトに pp 情報を送信する。つまり pp 情報 (3. 2), (7. 2) がサイト B と C に送られる。サイト B と C においても同様に pp 情報が導出される。サイト B では、降順の pp が導出されないので他のサイトへは pp 情報が送信されない。サイト C では、降順の pp (8. 7), (4. 3) が導出されるのでサイト A, B に pp 情報として送られる。

図 7 は、分散型デッドロック検出アルゴリズムの第 2 回目の反復を示している。第 1 回目の反復において送信され、受信サイトによって受け取られたすべての pp 情報が pp inf. の行に記入されている。そして、各サイトの pp 情報を組み込み、逆 pp 関係が存在するかを調べるとともに結合 pp の演算を行う。ここでは、(8. 7), (7. 8) という逆 pp 関係が発見される。VICTIM の選択基準に従って、7 又は 8 に関する関連 PP 集合の要素数 n (7) と n (8) を比較し、VICTIM-7 を選択する。サイト B の内に存在する VICTIM を含む pp を取り除く。次に (4. 3), (3. 4) という逆 pp 関係が発見される。これも、先と同様に n (3) = 4, n (4) = 3 を比較して VICTIM-3 を選択し、サイト内の VICTIM を含む PP を取り除く。発見された 2 つの VICTIM は、そのエージェントを持つ他のサイトに通知される。

VICTIM を通知されたサイト A と C には、トランザクション 3, 7 のエージェントが存在するので、アルゴリズムに従って今までに作成した pp 集合を廃棄して再びローカルに pp の導出を始める。最後の反復を図 8 に示す。サイト A, C には、1 つも pp が導出されない。また、サイト B では、送信する必要のある pp は導出されない。この反復においてすべてのデッドロックサイクルは、解消される。

4. 結論と今後の課題

本論文で提案した分散型デッドロック検出アルゴリズムを、OBERMARCK のアルゴリズム¹²⁾ と比較すると下記のようないくつかの利点がある。

- (1) グローバルなデッドロックサイクルを検出し、かつ解消するために各サイトは POSSIBLE PATH 情報と VICTIM のみを送受信するだけでよい。
- (2) 各サイトではローカルに導出した POSSIBLE PATH 集合 R と他のサイトから送られてきた POSSIBLE PATH 情報とを比較して、逆 POSSIBLE PATH の検出を行う。その後、結合 POSSIBLE PATH の作成が行われる。この操作は、代数的演算なので処理が容易である。
- (3) デッドロック検出の反復の回数を減らすことができる。

SITE	PP INF. (FROM)	PP (IN SITE)	UNION PP	PP INF. (TO)
A	--	--	--	--
B	--	(2. 4)	--	--
C	--	--	--	--

図 8 検出アルゴリズムの反復 3

今後、本アルゴリズムの性能評価を解析的側面と実験的側面の両面より行って行くとともに、1節で述べた分散OSの他の機能についても考察を進めてゆく予定である。

参考文献

- [1] Bruce Walker, Gerald Popek et al.: THE LOCUS DISTRIBUTED OPERATING SYSTEM. ACM Operating Systems REVIEW. 1983. 49-70
- [2] E. T. Mueller, J. D. Moore, and Gerald Popek: A NESTED TRANSACTION MECHANISM FOR LOCUS. ACM Operating Systems REVIEW. 1983. 71-89
- [3] Richard F. Rashid, George G. Robertson: Accent:A Communication Oriented Network Operating System Kernel. ACM operating systems REVIEW. 1981
- [4] E. D. Jensen, N. Pleszkoch: ArchOs:A Physically Dispersed Operating System. IEEE DISTRIBUTED PROCESSING TECHNICAL COMMITTEE NEWSLETTER. 1984
- [5] 谷口秀夫、鈴木達郎: リモートアクセスによるUNIXの分散処理OS化. 分散処理システム23-3. 1984. 1-8
- [6] 村井 純、斎藤信男: コンピュータネットワークを用いたソフトウェア開発環境、オペレーティングシステム研究会資料24. 1984. 15-20
- [7] 日本電子工業振興協会編: 分散システムに関する調査, 日本電子工業振興協会. 1982
- [8] 砂原秀樹、所 真理雄、中島達男: S & T net 上に構築された分散型オペレーティングシステムの基本機能、オペレーティングシステム研究会資料24. 1984. 21-26
- [9] Menasce, D., and Muntz, R: LOCKING AND DEADLOCK DETECTION IN DISTRIBUTED DATABASE. IEEE Trans. Softw. Eng. SE-5. 3. 1979. 195-202
- [10] Virgil D. and Susan H. SHATTUK: ON DEADLOCK DETECTION IN DISTRIBUTED SYSTEMS. IEEE Trans. Softw. Eng. SE-6. 5. 1980. 435-440
- [11] Goldman B.: DEADLOCK DETECTION IN COMPUTER NETWORKS. TECH. REP. M. I. T. - LCS TR-185. MASSACHUSETTS INSTITUTE OF TECHNOLOGY. CAMBRIDGE, MASS.. 1977
- [12] Obermack, R: DISTRIBUTED DEADLOCK DETECTION ALGORITHM. ACM Trans. DATABASE SYST. 7. 2. 1982. 187-208
- [13] Stefano Ceri: DISTRIBUTED DATABASE PRINCIPLES AND SYSTEMS. McGraw-Hill Book Company. 1984. 59-66