

データベース・マシンの同時処理制御

A Concurrency Control in a Database Machine

水摩正行 牧野武則 梅村 譲 曰吉茂樹
 Masayuki MIZUMA Takenori MAKINO Mamoru UMEMURA Shigeaki HIYOSHI
 日本電気(株) 中央研究所
 Central Research Lab. Nippon Electric Co., Ltd.

1.はじめに

データの共同利用を主目的とするデータベース管理システム(以下DBMSと略す)では、そのシステムが採用している同時処理制御方式が、システム性能、システムの使い易さに大きな影響を与える。

DBMSの制御方式に対して、種々の方式が提案され、実際に実現されてきた。同時処理制御の特徴は、制御の対象(ロック対象)と制御モードに現われる。システム設計において、これらをどのように決定するかは、ロック対象への競合度、システムオーバヘッド、使い易さ、実現の容易性などを十分考慮したうえで行うべきである。

現存するDBMSの中で同時処理制御機能が高いシステムはシステムRである[1]。システムRでは、tuple, データアイテム値など、非常に細かいレベルでの排他制御を行なっており、その制御モードも shared lock, exclusive lock などに選べる。しかしながら、実用システムとして、このような細かい制御機能を組み込むのは、それに伴ってもたらされる効果と制御の複雑さ、オーバヘッド等を考慮すると必ずしも最適でない。

一方、DMS1100[2], IDS[3]などでは、ロックの最小単位をページでおさえている。この方式は、システムRに比較して同時動作性、制御の柔軟性に劣るが制御が単純になる。しかししながら、ページに対するロックをソフトウェアにより実現しているのでオーバヘッドが

問題である。

本資料では、後置プロセッサタイプのデータベースマシン(Generalized Database Subsystem; 以下GDS^[4]と略す)の同時処理制御の設計思想、実現方式について報告する。

GDSの同時処理制御はDMS1100のアプローチに近いが、次のようは特徴をもっている。

- (1) ユーザインターフェースレベルでは、二段階別(エリア、レコードオカレンス)の排他制御を採用している。しかし、レコードレベルの排他制御はシステム内部でページに置換している。
- (2) ページの排他制御は、ロックオーバヘッドを減少させたため、ハードウェアによって実現せずアドレス変換機構を利用して行われる。
- (3) デッドロックフリー方式を採用している。デッドロック検出機構はハードウェア化される。

以下、データベースのロック対象の大きさとシステム性能との関係を解析する。そして、その解析結果を参考にして設計エントリGDSの同時処理制御方式について紹介する。

2. ロック単位の選択基準

DBMS の設計において、同時処理制御の最小単位をどの程度にするか、が重要な問題である。ロックの対象単位が大きくなればなりにトランザクション間の競合が発生し、多重処理の効果が減少する。一方、ロックの最小単位を細かくすると、競合率は減少するが、時間的空間的にはオーバヘッドが増大し、インプリメンテーションも困難になってくる。

ここで、ロック単位と競合性との関係を考察する。

はじめに、記号の定義を行う。

\bar{s} ; 平均実行トランザクション数

u_r ; トランザクション当たりの要求レコード数

d_r ; データベース(DB) の総レコード数

g ; DB ロック数(日あたり分割数)

s ; トランザクション当たりの要求ロック数
このとき、特定ロックに入り込むトランザクションが競合する確率 C_i は、次の二項分布で表現される。

$$C_i = \binom{s}{i} \left(\frac{\bar{s}}{g}\right)^i \left(1 - \frac{\bar{s}}{g}\right)^{s-i} \quad (1)$$

平均専有ロック数 B_c は、

$$B_c = \sum_{i=1}^s g \cdot C_i = g(1 - C_0) = g(1 - (1 - \frac{\bar{s}}{g})^s) \quad (2)$$

平均実行可能トランザクション数 \bar{x} は、

$$\bar{x} = (B_c / s) t = B_c / s \quad (3)$$

となる。

図1(実線)は \bar{x} , s , t の関係を示した。ここでは、 $t = 10$, $u_r = 50$ を仮定している。 u_r との関係は、一般にトランザクションのデータ参照特性(ローカリティ特性)に影響される。ここでは、次の3ケースについて示した。

$s = 5$; 完全離散

$s = g(1 - (\frac{s-1}{g})^{u_r})$; ランダム

$s = 10$; ローカリティがあら程度存在

また、Closed Queueing Network Model [5] を用いて、ロックによりシステム性能がどの程度低下するかを調べた。その結果を図1(破綻)に示している。なお、システムのモデルおよび値の設定は付録に示す。




図1. ロック単位と競合性の変化

図から、DB の分割数が 500 以上のオーダにはれば、ロック競合による実質的多度の低下はそれ程認められないことが判る。

一般に、DB のロックの対象候補として、DB 全体、エリア、レコードクラス、レコードオカレンス、データマイティ値、ページなど何か考えられるが、前記の解析結果より、大規模 DB を取り扱う DBMS では、ロックの最小単位はページで十分であると言えよう。

上記の背景をもとに、我々では、ロックの最小単位をページと定めシステム設計を行なった。以下、我々の同時処理制御について紹介する。

3. データベースの同時処理制御

我々の同時処理制御は、ユーザが開く要求を出すものと、システムが自動的に行うものがある。

前者は、ユーザのプログラムロックが他のユーザの更新によって乱されるのを防ぐために行われる。後者は、DB 上での矛盾を防ぐために行われる。矛盾が生じる主な原因は、複数ユーザが同時に出す更新要求の干渉、および更新処理の途中でのトランザクションの撤回である。

3.1 ユーザインターフェース レベルでの保護

ユーザインターフェース レベルでデータの一貫性(Consistency)を保障するため、我々では、エリアレベルの保護とレコードレベルでの保護機能を提供している。

(1) エリアの保護

エリアは COBASYL 案[6] のエリアの概念に相当する。一般的にエリアに含むデータ量は非常に多い。このレベルでは、トランザクション間の競合を緩和するために柔軟な排他制御モードが必要になる。

我々では、COBASYL 仕様に従った排他制御モードを全てサポートしている。

エリアに対する排他制御の宣言は、OPEN / CLOSE 命令によって行われる。ユーザは

この時、エリアの候用モード(RETrieve/UPDATE)と排他制御モード(EXCLUSIVE/PROTECTED/SHAREd)の宣言を行う。表 1 に同時処理の規則を示す。

表 1. エリアの排他制御規則

	S.R	S.U	P.R	P.U	EX
S.R	○	○	○	○	X
S.U	○	○	X	X	X
P.R	○	X	○	X	X
P.U	○	X	X	X	X
EX	X	X	X	X	X

○：実行可 X：不可

S(Shared)：エリアの共有使用

P(Protected)：検索処理ユーザに対しては許されるが更新処理ユーザは共有不可。

EX(Exclusive)：完全排他使用

R(Retrieve)：検索処理

U(Update)：更新処理

なお、我々では、エリアレベルでの排他制御によってシステムがデッドロック状態に陥らぬを防ぐため、トランザクションはエリアの候用と一緒に要求するようにしている。

(2) レコードオカレンスの保護

2 章の解析結果から判るように、レコードオカレンス単位ではトランザクション間の競合は余り生じない。そこで、我々では、このレベルでの排他制御は共有モード(Shared)と専有モード(Lock)に限定している。

ロック要求は次のようにして行われる。我々では、種々のアクセスパス(PRIMARYパス, IMAGEパス, LINKパス)に従って、DB 处理を行なうことができるが、ユーザはこの処理に先立ってアクセスパスの生成を要求する[4]。この時、必要があればロック要求を指定する。ロック要求が指定された場合、アクセスパスのカレントレコードは自動的にロックされる。カレントレコードが切り替わると旧カレントレコードは UNLOCK され、新カレントレコードが LOCK される。カレントレコードが切り替わった後にもう1回レコードをロックしようとすると、

LOCK 命令を使って陽に指定できる。

3.2 システムレベルでの保護

GDSだけ、1レコードアクセスを基本としているため、DBの更新は複数の命令を使って手続的に行われる。更新処理が完全に終了するまで同時に、他のトランザクションの更新が発生して場合のDBの論理的な矛盾が発生する。

また、更新の途中でトランザクションが戻されると可能性もある。このような状況からDBを守るために、DBレコードの更新されないページは更新トランザクションが終了するまで、GDSが自動的にロックをかける。

また、DBの更新に伴なって、インデックスやディスクリプタ等のシステム制御情報の修正が必要になってくる。これらも制御情報に対しては、GDSが必要に応じて該当ページを一時的にロックする。

4. システム構成

GDSの多層処理制御は、1つのトランザクションにつき、1つのGDIコマンド(Generalized




図2. システム構成

Database Interface)のみ実行する方式を採用している。

以下、多層処理制御機能に注目し、GDSのシステム構成を説明する。

GDSは処理の形態に応じて、いくつかの機能モジュール(FM)に分割されている。図2はその構成を示したものである。

(1) トランザクション コントロール

モジュール(TCM)

TCMはホストプロセッサとの通信、およびトランザクション処理のスケジューリングを行う。はじめに、START TRANS 命令を發せると、トランザクションエントリを作成する。トランザクションの動きは、トランザクションコントロールブロック(TCB)によって管理される。TCMは汎用計算機のそれに比べ單純化されており、少いオーバヘッドで制御できる。

多層処理制御は、3章で示したDBの同時処理制御イベント、エラ処理イベント、ホストからのCALL GDI命令を契機に行われる。図3は、GDS内部でのトランザクションの制御状態の動きを示している。

(2) エリア コントロール

モジュール

GDSに認識されたトランザクションは、最初にエリアの使用宣言を行ふ。ACMはトランザクションが要求した使用モードと排他制御モードを現在のエリアの使用状態と付き合わせて、トランザクションのキュー管理を行う。




図3. 制御状態の変動

(3) データ転送モジュール(DXM)

DXMは、各モジュール中に存在する。DBバッファと、他のFMのワームメモリ、ホスト端口セッサの主メモリと間でデータ転送を行う。データ転送はレコードバイメタで直接行われる。データ転送の機能パラメータは、論理レコードアドレス(エリア番号、ページ番号、ランク番号)、レコード内オフセットと長さで表現される。このデータ転送中にロックのチェックを行なう。他のトランザクションによってロックされている場合にはLCMに競合指令を発する。

(4) ロック コントロール

モジュール(LCM)

LCMは、DXMが確認したデータ競合に従って、トランザクションキュー管理を行う。また、キュー管理と同時にロック状態の検出を行なう。

(5) ページ リプレースメント

コントロール モジュール(PRM)

DBバッファ内のページ管理を行なう。即ち、DXMがデータ参照時にミッピングオルトを確認して場合、要求ページを二次記憶より転送するため、ページを置き換え制御を行う。置き換え制御では、ロックされたページは出来ら限り追い出さないようになっている。ロックされたページが追い出される場合は、ロック情報をマージするためLCMに制御を渡す。

(6) データ アクセス

モジュール(DAM)

各モジュールがサポートしている各種のアクセスパスに従って、レコードの検索、更新処理を実行する。

5. アドレス変換機構とロック

レコード、ページレベルの排他制御は従来ソフトウェアによって実現されていた。このため、ロック制御のためのオーバヘッドが多大である。また、そのオーバヘッドを無視することができないため、参照データに関係する制御情報

を更新する場合(たとえば、カレシードインジケータの修正時など)のみ、アクセス権チェックをする。というような方式で予め設計時に一定の規則を定めその規則に従ってチェックを行なっていた。しかしながら、このように方式では、正規の手続きで経ないデータ参照に対してアクセス違反で警告することができます。

今日では、このレベルの排他制御を行なうために、ハードウェアによって実現されるアドレス変換機構を効率的に利用している。DBデータを参照する場合には、常にこのアドレス変換機構を介するので、ロック機能を組み込めば、常時アクセス権のチェックを行なうことができる、より強力なロック制御機能を実現できる。また、ロックオーバヘッドも無視できる。なお、レコードに対する排他制御は、競合が少ないので、すべてページで代用している。

アドレス変換機構はDXMの1コンポーネントであり、論理アドレスをエロバッファ上の物理アドレスに変換する。図4にアドレス変換機構の構成を示す。




図4. アドレス変換機構(ATLB)

高性能なアドレス変換機能を実現する場合には、連想メモリ素子の使用が望ましいが、低価格で実現するためハッシュ機構と比較器を組み合わせた疑似連想記憶方式で実現される（DTLBと呼ぶ）。

DTLBの各エントリーには、アドレス変換情報の他に、ロック制御情報やバッファ管理情報が含まれている。

他のFMからデータベースデータの参照要求が発生した場合、このアドレス変換機構を通して、目的データページの物理アドレスを決定すると同時に、データに対するアクセス権のチェックを行う。

ロック制御情報はロックビット、トランザクションエイド、ロックカウントから成っている。

ロックビットは対応するページのロック状態を示す。もしロックビットが0Nであれば、他のトランザクションが対象ページをロックしていなければ表示。もしおトランザクション名はトランザクションIDフィールドに示されている。この場合データ参照はトランザクションエイドフィールドに一致するトランザクションのみ許可される。ロックビットが0F下の場合には、任意のトランザクションからのデータ参照が許可される。

ロックカウントはロック中のトランザクションが対象ページに要求を出したロックの回数とアノロックの回数の差を示す。対象ページをロックしている場合はその値は正である。ロックカウントが0になつた場合ロックビットが0FFになりページが解放される。このロックカウントは次の2つの目的で設けられた。

(1) 各DMAでは、レコードに対するロックをページで利用している。ページには一般に複数のレコードが存在し、ユーザはそのいくつかのレコードに対しロック要求を出す可能性がある。この時、ユーザが対象ページに含まれていらるロック中のすべてのレコードをアノロックするまでそのページを解放してはならない。

(2) 一般リストアを構成する場合 E.W. Diga-katha 等が提唱しているように階層設計が望ましい。これは他の階層に対する余分な知識を不要にするためである。このような

設計においては、各階層で同一オブジェクトに対し異なる目的でロックをかけられ場合が発生する。このように、目的に応じて自由にロック、アノロックをかけ得るようにすれば設計が楽になる。

上記の状況において、システムがページに対するロックの解放のタイミングをつかむためにロックカウントが設けられた。

6. デッドロック検出機構

デッドロックを防ぐ1つの方法として、資源を一括要求せらる方式がある。エリア単位の排他制御を行うため、専用では、この方式を採用している。しかしながら、レコードオカレインスレベルの排他制御でこの方式を採用した場合には、ユーザの負担が大きくなり問題である。

このため、専用では、レコードレベルでの排他制御はデッドロックフリー方式を採用している。




図5 デッドロック検出機構

システムのデッドロック状態を検出するためハードウェアにより実現されるデッドロック検出機構を備える。図5はその構成を示したものである。

デッドロック検出機構は、ロックマトリックス(LM)とウェイトマトリックス(WM)から成っている。LMの各要素は、ロック中のトランザクションとオブジェクトとの関係を表わしている。WMの各要素はオブジェクトを待つ

ているトランザクションの状態を示している。

5章で記述したアドレス変換機構により、あるトランザクションが目的ページのロック待ちイベントを確認すると本装置に通知される。

デッドロック検出機構は、ロック待ちトランザクション名とロックオブジェクト名を入力パラメータとして受け取り。最初に、LMより対応するオブジェクトをロックしてからトランザクション名を検出する。そして、次のトランザクション名をWMに入力することによって待ち状態にあるオブジェクト名が抽出される。そのオブジェクト名を再度LMに入力させ、その出力が選択トランザクション名(入力パラメータのトランザクション名)と一致した場合にデッドロック状態が発生したと言える。一致しなければ、同じ動作を続ける。そして、最後まで一致するトランザクションが検出できなければ、デッドロック状態が発生していいこととなる。

7. おわりに

DBMからの設計において、DBの保護の最小単位をどう程度に設定すればよいか、は興味深い問題であろう。

本資料では、この問題を解析的に求め、ページを最小単位とすれば十分であることを示した。

また、データベースマシンの同時処理制御方式について論じた。

本データベースマシンはメモリ共用型の後置アロセッサである。データベースの保護はページを基本単位としている。更に、核機能エハードウェア／ファームウェアにより実現するこことで、オーバヘッドの減少にはつながっている。

本方式の有効性を確かめるために、現在実験システムを開発中である。

最後に、本研究の機会を与えて下さった日本電気中央研究所コンピュータシステム研究部藤野部長、赤津課長、ならびに、日頃直特御指導頂いている箱崎主任、久株主任に感謝致します。

《参考文献》

- 1) M.M. Astrahan et al : System R: A relational approach to database management , ACM TODS, Vol.1, No.2 (1976).
- 2) UNIVAC 1100 Series, Data Management System (DMS1100) Data Manipulation Programmers Reference , UP-7908.
- 3) ACOS-6 データ管理 統合データベース (IDS) 説明書 .
- 4) K. Hakozaiki et al : A Conceptual Design of A Generalized Database Subsystem , 3rd International Conf. on VLDB, Oct.'77.
- 5) W.J. Gordon and G.F. Newell : Closed Queueing Systems with Exponential Servers , Operations Research, Vol.15, No.1-3, 1967.
- 6) CODASYL Data Description Language Journal of Development, Jun. '73, NBS Handbook (1974) .

[付録] システム評価モデル

Closed Queueing Network モデルでは、次のことを前提にしている。

- 各サーバのサービス時間：指數分布に従う。
- サーバ間の遷移：遷移確率に従う random walk

- システム内のトランザクションの数は一定である

上記の前提のもとに、システム構成、各サーバの平均サービス時間、サーバ間の遷移確率、システム内のトランザクションの数を入力パラメータとして、各サーバの平均使用率、平均待ち行列の長さ、システムレベルタイム(応答時間)を計算できる。

Closed Queueing Network モデルを使って、DBの分割数の変化によってシステム性能がどうよう影響されるかを近似的に示めるため、図A-1に示すようなシステム構成を仮定した。




図 A-1. システム構成モデル

図において、

μ_1 : ロックオーバヘッド時間。本来 CPU 处理であるが別サーバとした。

μ_2 : ロック競合によって待たされる時間

μ_3 : CPU による 1 回当たりのサービス時間

μ_4 : DBI/O 入出力時間。DBI/O は複数デバイスの指定可能

α, β : サーバ間の遷移確率

を表す。

入力パラメータは、次のようにして決めた。
 μ_3, β はトランザクションの DB 处理特性を反映させるもので、ある保険会社のオンラインデータベースシステムのデータを参考にして設定した。本システムでは、トランザクション当たりの CPU 处理量の平均は 3.20 msec であり、平均エントリ数は 2.5、5 回であった (I/O 時間: 4.0 msec)。この例では、CPU 处理 / 2 msec に 1 回の割合で I/O が発生するものとする。

これから

$$\mu_3 = 1.2 \text{ msec}$$

$$\beta = 25.5 / (25.5 + 1) = 0.96$$

が求まる。

システム内の全トランザクションの数は 10 に固定した。

α は 2 章の (3) 式とシステム内の全トランザクションの関係から求めた。 $(\alpha = \pi/10)$

μ_1 はロックオーバヘッドを表すもので、固定的に 2 msec とした。

Hold Time (μ_2) は、トランザクションの競合による待ち時間を近似的に表すため、マルチサーバ (待ち時間が長いほど) に 20 (> 10) 倍) を仮定した。

μ_2 の値を粗略くトランザクションの終了間隔と対応させたため、CPU と DBI/O みからなる別の Queuing Network Model を作り多量度のときの応答時間を計算した。そして、その応答時間を元で割り下限を M_2 として与えた。

表 A-1. 入力パラメータの設定値

入力パラメータ	値
多量度	10
μ_2	(多量度のときの CPU, DBI/O 系のみでの応答時間) / 定数 (サーバ 20)
μ_1	2 msec
μ_3	1.2 msec
μ_4	4.0 msec (サーバ 5)
α	$\pi/10$
β	0.96
s	5.0

なお、本モデルでは、各トランザクションは処理に関係するすべてのリソース (ロック) をトランザクション処理の開始時に確保し、終了時に解放することを仮定している。

結果は、図 1 の破線で示している。