データベース移動に基づく分散データベースシステム DB–MANα における同時実行制御機構の設計と実装

酒井 仁　秋山 豊和　海貝 明道　原 隆浩　塚本 昌彦　西尾 章治郎

大阪大学大学院工学研究科情報システム工学専攻

E-mail: {sakai, akiyama, umigai, hara, tuka, nishio}@ise.eng.osaka-u.ac.jp

概要

近年，ネットワークの帯域幅が拡大し，分散システムでは，データの転送遅延よりデータの伝播遅延が処理時間に大きな影響を与えるようになってきている．筆者らの研究グループでは，通信回数を削減し，伝播遅延の影響を小さくするため，データベースを移動してトランザクション処理を実行する分散データベースシステムを設計し，そのプロトタイプシステム DB–MANα を実装している．本稿では，データベース移動がある期間データベースを専有することを考慮し，データベース移動とデータベース操作の同時実行を制御する機構を提案する．さらに，提案した機構を DB–MANα システムに実装し，その性能を実測評価する．

Keywords: データベース移動，同時実行制御，分散データベースシステム，広帯域ネットワーク，トランザクション処理

1 はじめに

近年，ATM（Asynchronous Transfer Mode: 非同期転送モード）方式を中心としてネットワーク技術が急速に発展し，それに伴ってデータ通信に用いることのできるネットワークの帯域幅も急速に拡大している．従来の分散処理に関する研究では，一度に転送するデータの量を削減することで処理の高速化を図っていたが，ネットワークの帯域幅が急速に拡大されつつある今日では，広い帯域幅を有効に利用して一度に大量のデータを転送し，通信の回数を削減することで処理を高速化できる．

従来の分散データベースシステムでは，転送するデータ量の削減が性能向上の重要な要因であったため，データベースを特定のサイトに固定し，処理依頼と処理結果のメッセージ交換によって処理を行っていた．これに対して，広帯域ネットワークを利用すればデータベース全体の転送も短時間で行えるため，データベースを移動してそれに対する処理をローカルに行うことで通信の回数を減らすという手法が可能となる．筆者らの研究グループでは，このようなデータベース自体の移動（データベース移動）をトランザクション処理に用いる手法を提案した [6].

さらに，筆者らの研究グループは文献 [7] において，移動機能を有する分散データベースシステム DB–MAN を提案し，文献 [8] においてそのプロトタイプシステムとして DB–MANα を実装した．DB–MANα システムでは，データベース移動を用いた処理（移動処理）が従来のデータベース固定型の処理（固定処理）に比べて常に処理時間が短いとは限らないことを考慮して筆者らが提案した，固定処理と移動処理を適応的に選択する手法 [1] を用いてトランザクションを実行する．また，DB–MANα システムではデータベースアクセスを高速化し，データベース移動の効果を高めるため, 主記憶データベース [4, 5] を用いている．さらに，主記憶データベースを用いることで必要となるバックアップについても，移動を考慮した管理機構を実現した．

文献 [8] で実装したシステムでは，データベース操作間の同時実行制御は通常の 2 相施錠規約 [2, 3] を用いて実装しているが，データベース移動とデータベース操作の同時実行制御は行っていない．しかし，データベース移動がある期間データベースを専有する処理であることを考慮すると，移動中のデータベースに対するデータベース操作のサポートは処理スループット向上のために重要と考えられる．そこで本稿では，データベース移動に対する同時実行制御機構を設計し，DB–MANα システムに実装する．

同時実行制御機構は，通常の 2 相施錠規約で用いるデータベース単位の読出し施錠および書込み施錠に，データベース移動のための移動施錠の概念を新たに加えることで実現する．読出し施錠，書込み施錠と移動施錠の両立性について 3 方式を考案し，それらを DB–MANα システムに実装する．さらに，実測評価によって実装した 3

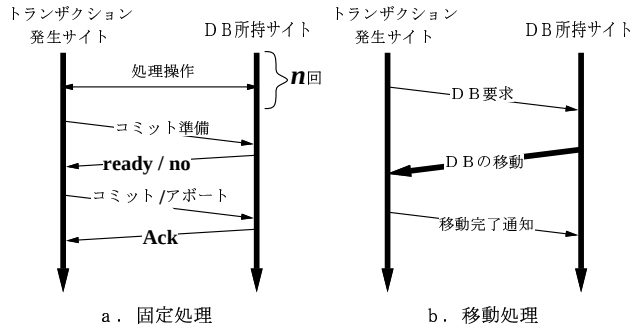

図 1: 各手法の通信手順

方式の性能を比較する．

以下では，2章でデータベース移動に基づく分散データベースシステム DB–MANα の概要を述べる．さらに3章で同時実行制御機構の設計と実装について述べ，4章で実装した機構の評価を行う．最後に 5章で本稿のまとめと今後の課題について述べる．

2 DB–MANα システムの概要

本章では，まず文献 [6] で提案したデータベース移動を用いたトランザクション処理について述べ，次に文献 [8] で実装した DB–MANα システムの概要について述べる．

2.1 データベース移動を用いたトランザクション処理

広帯域ネットワークでは転送遅延が小さいため，大量のデータ転送は短時間で行えるが，伝播遅延は従来のネットワークとほとんど差がないことから，通信の回数を削減することが処理速度向上のために重要である．データベース移動を用いたトランザクション処理（移動処理）では，処理を実行するサイトへデータベース自体を移動することで通信回数を削減し，処理を高速化する．

従来のデータベース固定型の処理（固定処理）では，図 1a に示すような通信手順でトランザクション処理が実行される．まず，トランザクション発生サイトからデータベースを所持するサイトへコネクションが設定される．その後，処理依頼と処理結果などのメッセージ交換が必要な回数だけ行われ，最後に 2 相コミットプロトコル（2PC）に必要なメッセージ交換が 2 往復行われる．これに対し移動処理は，図 1b に示すように，データベース要求，データベース移動，および移動完了通知の 3 回の通信で実現できる．なお，移動元サイトでは，移動の完了後に自サイトのデータベースを削除する．

このようなデータベース移動を用いた処理は，例えば次のような場合に有効であると考えられる．

- データベースを集中的にアクセスするサイトが時間と共に順次変移していくような場合:
  グローバルなデータ共有を考えた場合，各サイトでのアクセスパタンは一様であったとしても，サイト間の時差などによって順次，集中的にアクセスするサイトが変わっていくことになる．このような場合，集中的にアクセスするサイトの変化に合わせてデータベースを移動していけば通信コストを大幅に削減できる．
- 各サイトに分割して管理しているデータの統計処理を特定のサイトで実行するような場合:
  企業における各支社の顧客データおよび売り上げデータについて本社で統計処理を行い，次の戦略を立てる場合が考えられる．統計処理時は多くのデータがやり取りされることになるため，データベースを一旦処理サイトに移動し，処理終了後は元のサイトに戻すようにすれば，通信コストを削減できる．

2.2 DB–MANα システム

DB–MANα システムでは，文献 [1] の手法に基づいて，トランザクション開始時に直前までのアクセス情報からアクセスの偏りを検出し，固定処理と移動処理を適応的に選択して処理を行う．また，DB–MANα システムでは，データベース移動の高速化のために，主記憶データベースを用いているため，移動を考慮したバックアップ管理を行う．

図 2に DB–MANα システムのシステム構成を示す．以下では，図中のそれぞれのモジュールの機能について簡単に説明する．これらのモジュールのうち，手法選択部とバックアップ管理部以外は従来の分散データベースとほぼ同様のものである．

インタフェース部: クライアントからトランザクションを受け取り，トランザクション処理手法選択部に問合せを一つずつ渡す．一方，部分問合せや移動要求など，他サイトのシステムから受け取った処理要求は，直接トランザクション処理部に渡す．

トランザクション処理手法選択部: トランザクション処理手法選択部は，次の 3 つの各部からなる．

- **解析部:** クライアントから文字列で渡された問合せを解析し，問合せ木を構成して最適化部に渡す．
- **最適化部:** 問合せ木を，実際のデータベース操作を記述したプラン木に変換し，トランザクション処理部へ渡す．

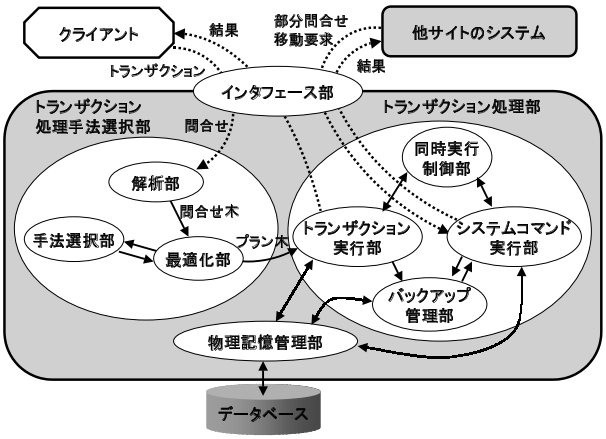

図 2: システム構成

手法選択部: 文献 [1] で提案した手法に基づいて，固定処理と移動処理のどちらで処理を行うかを決定する．

トランザクション処理部: トランザクション処理部は，次の 4 つの各部からなる．

トランザクション実行部: トランザクション処理手法選択部から，プラン木と処理手法の情報を受け取り，指定された処理手法でプラン木を実行する．

システムコマンド実行部: 自サイトおよび他サイトのトランザクション実行部およびシステムコマンド実行部から，データベース移動，部分問合せの実行，カタログ情報の更新などのシステムによる処理要求（システムコマンド）を受け取り，実行する．

同時実行制御部: データベース単位の 2 相施錠規約に基づいて，複数のトランザクションまたはシステムコマンドの同時実行を制御する．

バックアップ管理部: トランザクション実行部から更新操作の内容を受け取り，更新ログを作成して物理記憶に格納する．また，バックアップの送信要求を受けたときには，バックアップと更新ログの内容から最新のバックアップを作成して送信する．

物理記憶管理部: トランザクション処理部からの要求に応じて，物理記憶に対しデータの入出力を行う．

DB–MANα システムは，カリフォルニア大学バークレー校で開発されたアカデミックフリーのリレーショナルデータベースシステムである POSTGRES [10, 11] をベースに，C 言語で実装した．また，POSTGRES は分散データベースシステムでないため，Mariposa [9] のコードを一部流用してシステムを分散化した．

3 データベース移動を考慮した同時実行制御機構

DB–MANα システムでは，データベース単位の 2 相施錠規約に基づいて，データベース操作の同時実行制御を行う．しかし，文献 [8] の実装では，データベース移動とデータベース操作との同時実行制御を考慮しておらず，データベースの移動中に到着した問合せや，問合せ実行中に到着した移動要求に対応できなかった．

本章では，データベース移動とデータベース操作の同時実行制御機構を設計し，それを DB–MANα システムに実装する．

3.1 同時実行制御機構の設計

DB–MANα システムは，2 相施錠規約に従う読出し施錠と書込み施錠の 2 種類の施錠を用いてデータベース操作の同時実行を制御する．読出し施錠同士は両立が可能であり，読出し施錠と書込み施錠，および，書込み施錠同士はいずれも両立が不可能である．また，これらの施錠はデータベースを所持するサイトでローカルに管理する．

ここで，データベース移動とデータベース操作の同時実行制御を実現するために，これら 2 種類の施錠に，新たに**移動施錠**を導入する．移動元および移動先のサイトは，データベース移動を実行している間，移動中のデータベースに対して移動施錠を確保する．具体的には，移動施錠は，データベースの最初のページの送信を開始する直前に確保され，最後のページの送信を終了して，移動完了を示す確認応答が返された時点で解放される．したがって，移動施錠は 2 相施錠規約には従わない．

導入した移動施錠と，読出し施錠および書込み施錠との両立性には，データベース移動とデータベース操作の同時実行による並行処理性能の向上を重視するか，処理の簡素化によるオーバヘッドの低減を重視するかで，いくつかのケースが考えられる．そこで，移動施錠と読出し施錠，書込み施錠の両立性について，次の 3 方式を提案する．ただし，どの方式でも移動施錠同士は両立せず，後に到着した移動要求を発したトランザクションは，固定処理に切替えて実行される．

排他制御方式: 読出し施錠または書込み施錠と移動施錠は両立しない．

読出し施錠または書込み施錠が確保されているデータベースに対して，移動施錠要求が到着した場合は，先に確保されていた施錠が解放されるのを待って移動施錠が確保される．移動施錠が確保されているデータベースに対して，読出し施錠または書込み施錠の要求

が到着した場合は，その要求をデータベースの移動先へフォワードする．

並行処理方式: 読出し施錠または書込み施錠と移動施錠は，移動施錠が後に到着した場合に限り両立する．

読出し施錠または書込み施錠が確保されているデータベースに対して，移動施錠要求が到着した場合は，先に確保されていた施錠が解放されるのを待たずに移動施錠を確保できる．移動施錠が確保されているデータベースに対して，読出し施錠または書込み施錠の要求が到着した場合は，その要求をデータベースの移動先へフォワードする．

他のトランザクションが読出しまたは書込みを行っているデータベースを移動するときは，移動が完了しても移動元のデータベースをすぐには削除せず，読出しまたは書込みを行っていたトランザクションが施錠を解放した後に削除する．このとき，移動したデータベースに対して書込みが行われていたら，書込み操作のログを移動先へ送信して移動先のデータベースに反映する．移動先では，それまでデータベースに対する操作を禁止する．

移動中止方式: 読出し施錠または書込み施錠と移動施錠は両立しない．

読み出し施錠または書き込み施錠が確保されているデータベースに対して，移動施錠要求が到着した場合は，その要求を直ちに拒否し，移動施錠を要求したトランザクションを固定処理に切替えて実行する．移動施錠が確保されているデータベースに対して，読み出し施錠または書き込み施錠の要求が到着した場合は，データベース移動を中止し，移動を行っていたトランザクションを固定処理に切替えて実行する．

これらの方式の動作例を図 2 に示す．図では，サイト 1 において読出し操作を行うトランザクション 1 が発生し，続いてサイト 2 においてデータベース移動後に書込み操作を行うトランザクション 2 が発生した場合の，3 方式の動作を表している．排他制御方式では，トランザクション 1 が読出し施錠を解放するのを待ってデータベースを移動する（図 2a）．並行処理方式では，トランザクション 1 の読出しと並行してデータベースを移動し，トランザクション 1 が読出し施錠を解放するのを待って書込みを開始する（図 2b）．移動中止方式では，データベース移動は失敗し，その後の処理を固定処理に切替えて実行する（図 2c）．

これらの方式のうち，排他制御方式は最も単純な方式であり，制御用の処理のオーバヘッドが最も小さい．しかし，先に到着していたトランザクションが施錠を解放するまでデータベースの移動を開始できないため，移動を要求したトランザクションは，施錠の解放を待つ時間

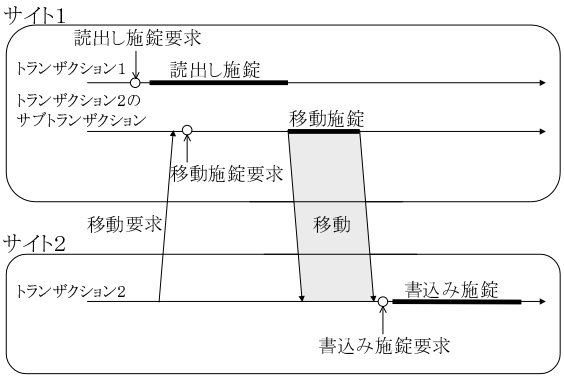

a. 排他制御方式

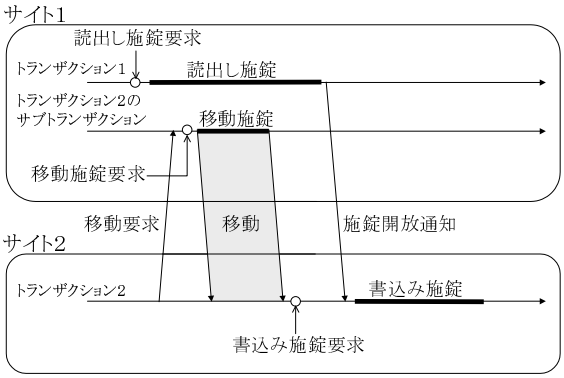

b. 並行処理方式

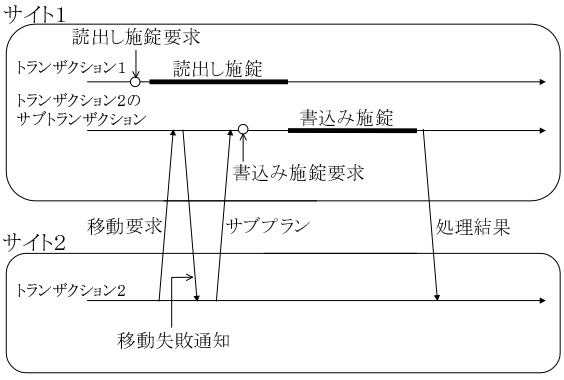

c. 移動中止方式

図 3: 同時実行制御 3 方式の動作例

と，データベース移動にかかる時間だけ処理遅延が大きくなる．

これに対し，並行処理方式はデータベース移動による遅延の影響を低減できる．この方式でも，先に到着していたトランザクションが施錠を解放するまで，データベース移動を要求したトランザクションはデータベース操作を開始できない．しかし，データベースの移動は処理中のデータベース操作と並行して実行できるため，移動が完了していれば先に到着していたトランザクションが施錠を解放した時点で移動先のデータベース操作を開始できる．したがって，排他制御方式と比べて，トランザクションの応答時間を短縮できるものと考えられる．しかし，先に到着していたトランザクションが書込みを行った場合，そのトランザクションの終了時に，更新ログを移動先に送信し，操作内容をデータベースに反映するオーバヘッドが発生する．

移動中止方式は，移動元サイトでのトランザクションの実行中は，データベースの移動要求を拒否するため，あるサイトに到着したトランザクションが，そのサイトで実行されることを保証する．また，先に到着していたトランザクションが施錠を確保していた場合，移動施錠の要求は直ちに拒否されるため，データベースを移動しようとしたトランザクションは，移動施錠が確保できるまで待つことなく処理を継続できる．この方式は，過剰なデータベース移動を防止できる反面，有効な移動を中止してしまう可能性もある．

3.2 同時実行制御機構の実装

3.1節の提案方式に基づいて，データベース移動とデータベース操作の同時実行制御機構を DB–MANα システムに実装した．本節では，その具体的な実装方法について説明する．

3.2.1 施錠の管理

DB–MANα システムは，1 トランザクションを 1 プロセスで実行し，トランザクション間の同時実行制御には，共有メモリを用いる．

プロセスが読出し施錠および書込み施錠を確保するときは，まず共有メモリ上の施錠情報テーブルを参照し，確保しようとする施錠が他のプロセスの施錠と競合しないかを確認する．競合しない場合は，自プロセスが施錠を確保したことを施錠情報テーブルに書込む．競合する場合は，共有メモリ上の施錠待ちプロセスキューに自プロセスの ID を書き込み，スリープする．施錠を解放するときは，施錠情報テーブルから自プロセスの施錠に関する情報を削除し，施錠待ちプロセスキューの先頭にあるプロセスにシグナルを送り，スリープから復帰させる．

移動施錠も，施錠情報テーブルと施錠待ちキューを用いて管理する．移動施錠を確保しようとするプロセスは，施錠情報テーブルを参照して他のプロセスによる施錠の状態を確認する．他のプロセスが施錠を確保しているときの動作は，3.1節で提案した同時実行制御の方式のうち，いずれを用いるかによって異なる．それぞれの方式での動作を次に示す．

排他制御方式: 施錠待ちプロセスキューに自プロセスの ID を書き込み，スリープする．

並行処理方式: 自プロセスが施錠を確保したことを施錠情報テーブルに書き込み，移動を開始する．

移動中止方式: 施錠情報テーブルおよび施錠待ちプロセスキューには変更を加えず，施錠確保に失敗したことを移動を要求してきたサイトへ通知する．

ただし，他のプロセスが移動施錠を先に確保しているときは，同時実行制御の方式に関わらず，移動施錠の確保に失敗したことを，移動を要求してきたサイトへ通知する．

読出し施錠または書込み施錠を確保するとき，他のプロセスが先に移動施錠を確保していた場合，移動中止方式では，3.2.3節で述べる方法でデータベース移動を中止させ，自プロセスは施錠を確保して処理を続行する．排他制御方式および並行処理方式では，読出し施錠または書込み施錠は確保できず，問合せを 3.2.4節で述べる方法でデータベースの移動先へフォワードする．

3.2.2 データベース移動とデータベース操作の並行処理

並行処理方式では，他のプロセスが読出しまたは書込みを行っているデータベースを移動するために，次のような処理を行う．

- 先にそのデータベースに対して操作を行っていたトランザクションが施錠を解放した後に，移動元のデータベースを削除する．
- 書込み操作を行っているデータベースが他のトランザクションによって移動されたときは，書込み操作のログを移動先のサイトへ送信する．

これらの処理は，共有メモリ上の位置情報テーブルを用いて，以下の方法で実現した．

- 移動施錠を確保したら，直ちに自サイトの位置情報テーブルを書き換え，データベースの現在位置を移動先のサイトとする．
- 読出し施錠，書込み施錠または移動施錠のいずれを解放するときも，施錠待ちキューが空であれば位置情報テーブルを参照し，データベースが移動していないかを確認する．データベースが他サイトに移動している

場合は，自サイトにあるデータベースを削除する．

3.2.3 データベース移動の中止

移動中止方式では，移動中のデータベースに対してデータベース操作の施錠を確保するとき，以下の方法で移動を中止する．

- 移動を中止するときは，移動開始時に書き換えられた位置情報テーブルを元に戻し，データベースの現在位置を自サイトとする．
- データベース移動を行っていたプロセスは，移動処理を終了する前に位置情報テーブルを確認する．データベースの位置が移動元サイトになっているときは，移動が中止されているので，移動に失敗したことを移動先のサイトへ通知する．

3.2.4 問合せのフォワード

排他制御方式および並行処理方式では，移動施錠が確保されているときに到着した読出し施錠または書込み施錠の要求を，以下の方法でデータベースの移動先へフォワードする．

- データベースの移動元サイトで発生したトランザクションは，他のトランザクションによって移動施錠が先に確保されていたなら，問合せプランを再作成し，サブトランザクションを移動先のサイトで実行する．
- データベースの移動元サイト以外で発生したトランザクションのサブトランザクションは，他のトランザクションによって移動施錠が先に確保されていたなら，問合せの結果を待っているトランザクション発生サイトのプロセスにデータベースの移動先サイトの ID を通知する．通知を受けたプロセスは，自サイトの位置情報テーブルを移動先サイトの ID に書き換え，問合せプランを再作成して実行する．

4 実測評価

本章では，DB-MANα システムに実装した同時実行制御機構の性能評価のために行った実験とその結果について述べる．

4.1 実験環境

実験では，DB-MANα システムにおいて，同時実行制御機構の各方式を用いたときのトランザクション処理にかかる平均応答時間を測定した．実験は，トランザクションを読出しのみとした実験 1 と，書込み操作を含むものとした 実験 2 の 2 通りを行った．それぞれの実験では，比較対象として，全てのトランザクションをデータベースを固定して処理した場合の平均応答時間も測定した．

表 1: 実験を行ったシステム環境

計算機	
機種	Sun Ultra 60 Model 2360
CPU	UltraSPARC-II (360MHz) × 2
メモリ	256MB
OS	Solaris 2.6
ネットワーク	
サイト数	3
実効帯域幅	約 80 Mbps
伝播遅延	200 ミリ秒

表 2: 実験で用いたパラメータ

データベース	
データベース数	1
データベースサイズ	3〜20 MB (10MB)
トランザクション	
問合せ/トランザクション	5
読出すデータの量	2 KB
書込むデータの量	2〜32KB
到着間隔変更周期	20 秒
集中時平均到着間隔	2 秒
散発時平均到着間隔	10 秒

実験を行ったシステム環境を表 1に示す．サイト数は 3 に，データベース数は 1 に固定した．ネットワークは，100Mbps のイーサネットを用いており，その実効帯域幅は約 80Mbps である．また，2.1節で述べたように，移動処理はネットワークの転送遅延より伝播遅延の影響が大きいときに有効となるが，実験を行った環境では想定しているような大きな伝播遅延が生じないため，伝播遅延はプログラム内で擬似的に発生させた．この伝播遅延は，図 1に示した通信手順に対応して，それぞれのメッセージに対して 200 ミリ秒の遅延を付加した．

実験で用いたパラメータを表 2に示す．実験 1 ではデータベースのサイズを 3MB から 20MB の範囲で変化させることでデータベース移動にかかる時間を変化させた．また，実験 2 ではデータベースのサイズは 10MB に固定した．データベースのサイズが小さいのは，本実験で使用できるネットワークの帯域幅が，本研究で想定して

いる将来の広帯域ネットワークの帯域幅（数 Gbps）より狭いためである．今後，使用できるネットワークの帯域幅が拡大すれば，より大きなサイズのデータベースを扱えるものと考えられる．

トランザクションは指数分布に基づいて発生させ，ある一つのサイトの平均到着間隔を，それ以外のサイトの平均到着間隔に比べて小さな値に設定することで，偏ったアクセスとなるようにした．このようなトランザクションの発生方法は，2.1節で述べたような，移動処理が有効となるアクセスパタンを想定している．集中してアクセスが発生するサイトの平均到着間隔を集中時平均到着間隔，それ以外のサイトの平均到着間隔を散発時平均到着間隔と呼ぶ．集中的にデータベースにアクセスするサイトは一様分布の乱数によって決定し，到着間隔変更周期ごとにそのサイトを変化させた．

DB–MANα システムでのトランザクション処理手法選択機構では，特定のサイトからアクセスが集中し，データベースを移動した方が平均処理時間を短縮できると判断したときに，データベースの移動を決定する．しかし，この機構では，過去の履歴に基づいてデータベースを移動するため，有効でない移動が生じる可能性がある．本実験では，このような有効でない移動によって同時実行制御の各方式間の違いが不明確になることを防ぐため，トランザクション処理手法選択機構を用いず，あらかじめ到着するトランザクション系列を調べることで最適なタイミングでデータベースを移動させた．

4.2 実験 1: 読出しのみのトランザクション

トランザクションを読出しのみとし，データベースのサイズを変化させたときの各方式の平均応答時間を図 4 に示す．

この実験では，トランザクションは書込み操作を行わないため，移動したデータベースに対する更新操作のログを送信する処理のオーバヘッドが生じないことから，並行処理方式が最も良い結果を示した．ただし，データベースサイズが大きくなると，移動処理の有効性が低くなるためにデータベース移動の回数が減少することから，平均応答時間は固定処理のみの場合と近くなった．

排他制御方式では，3.1節で述べたように，データベース移動にかかる時間だけ処理が遅れるため，データベースサイズの増加とともに並行処理方式との差が大きくなった．データベースサイズが 15MB のときに並行処理方式との差が小さくなっているのは，データベースサイズの増加とともにデータベース移動の回数が減少したためである．

実験では，平均応答時間が最も短くなるようにデータベースを移動するタイミングを指定してあるため，移動

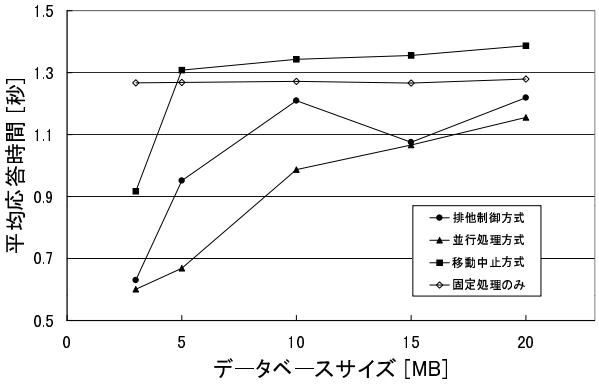

図 4: トランザクションが読出しのみのとき

中止方式では，有効なデータベース移動の中止によって，平均応答時間が長くなった．特に，データベースサイズが増加してデータベース移動にかかる時間が大きくなるほど，データベース移動の中止が発生しやすい．この実験では，データベースサイズが 5MB 以上のときはデータベース移動が全て中止され，固定処理のみを行った場合と近い結果を示した．しかし，データベースサイズが大きいと，データベース移動の中止処理にかかるオーバヘッドが大きくなるため，固定処理のみの場合より平均応答時間が長くなった．

4.3 実験 2: 書込みを含むトランザクション

トランザクションが書込み操作を含むとし，書込むデータの量を変化させたときの各方式の平均応答時間を図 5 に示す．

この実験では，書込むデータの量に関わらず，並行処理方式が最も短い応答時間を示した．これは，移動するデータベースに対して書込み操作が行われていて，移動先サイトへ書込み操作のログを送信する必要があるときでも，その処理のオーバヘッドは小さいことを示している．

移動中止方式では，書込むデータの量が増加して書込み操作を含むトランザクションの処理時間が長くなると，データベース移動を中止する確率が高くなり，固定処理のみの場合と近い結果を示した．特に，書込むデータの量が 16KB 以上のときは全てのデータベース移動が中止され，固定処理のみの場合とほぼ同じ応答時間を示した．

排他制御方式は，書込み操作を含むトランザクションが終了するまで待ってデータベースを移動するため，データベース移動にかかる時間が直接平均応答時間に影響する．この実験では，データベース移動による処理時間短縮の効果と，データベース移動にかかる時間の影響が打ち消し合い，固定処理のみの場合と近い結果を示した．

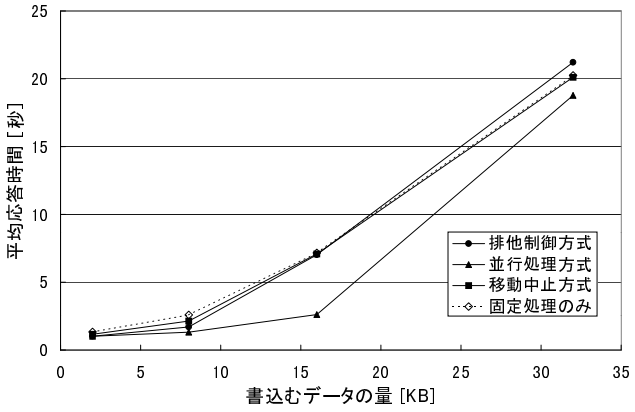

図 5: トランザクションが書込みを含むとき

5 おわりに

本稿では，DB–MANα システムにおいて，データベース移動とデータベース操作の同時実行を制御する機構を設計し実装した．同時実行制御機構は，通常のデータベース単位の施錠機構に，移動施錠を新たに導入することで実現した．

移動施錠と，従来の読出し施錠または書込み施錠との両立性の異なる 3 方式を提案し，DB–MANα システムに実装した．実測評価の結果，トランザクションが書込み操作を含んでも含まなくても，並行処理方式が最も良い性能を示すことが分かった．

今後の課題としては，データベースの複製を利用してトランザクションのスループットをさらに向上させることが考えられる．

謝辞

本研究は，日本学術振興会研究費奨励研究 (A)(10780260) および日本学術振興会未来開拓学術研究推進事業における研究プロジェクト「マルチメディア・コンテンツの高次処理の研究」(Project No. JSPS-RFTF97P00501) の研究助成によるものである．ここに記して謝意を表す．

参考文献

[1] 秋山豊和, 原隆浩, 春本要, 塚本昌彦, 西尾章治郎: アクセス情報に基づくデータベース移動を用いたデータベース再配置手法, 情報処理学会論文誌, Vol. 40, No. 6, pp. 2765–2775 (1999).

[2] Cellary, W., Gelenbe, E. and Morzy, T.: *Concurrency Control in Distributed Database Systems*, Studies in Computer Science and Artificial Intelligence, Elsevier Science Publishers B.V., Amsterdam (1988).

[3] Ceri, S. and Pelagatti, G.: *DISTRIBUTED DATABASES Principles and Systems*, McGraw-Hill Computer Science Series, McGraw-Hill Book Company, Singapore, international student edition (1985).

[4] DeWitt, D., Katz, R., Olken, F., Shapiro, L., Stonebraker, M. and Wood, D.: Implementation techniques for main memory database systems, *Proc. of ACM SIGMOD'84*, pp. 1–8 (1984).

[5] Garcia-Molina, H., Lipton, R. J. and Valdes, J.: A massive memory machine, *IEEE Trans. Comput.*, Vol. C-33, pp. 391–399 (1984).

[6] Hara, T., Harumoto, K., Tsukamoto, M. and Nishio, S.: Database migration: A new architecture for transaction processing in broadband networks, *IEEE Trans. Knowledge and Data Eng.*, Vol. 10, No. 5, pp. 839–854 (1998).

[7] Hara, T., Harumoto, K., Tsukamoto, M. and Nishio, S.: DB–MAN: A distributed database system based on database migration in ATM networks, *Proc. of IEEE Data Engineering*, pp. 522–531 (1998).

[8] 酒井仁, 秋山豊和, 海貝明道, 原隆浩, 春本要, 塚本昌彦, 西尾章治郎: 移動機能を有する分散データベースシステム DB–MANα の設計と実装, 電子情報通信学会第 10 回データ工学ワークショップ (DEWS'99) 論文集 (CD-ROM) (1999).

[9] Stonebraker, M., Aoki, P. M., Devine, R., Litwin, W. and Olson, M.: Mariposa: A new architecture for distributed data, *Proc. of IEEE Data Engineering*, pp. 54–65 (1994).

[10] Stonebraker, M. and Rowe, L. A.: The design of POSTGRES, *Proc. of ACM SIGMOD'86*, pp. 340–355 (1986).

[11] Stonebraker, M., Rowe, L. A. and Hirohama, M.: The implementation of POSTGRES, *IEEE Trans. Knowledge and Data Eng.*, Vol. 2, No. 1, pp. 125–142 (1990).