

分散処理向きデータベースマシンの考察

坂本 明史、川上 英、疋田 定幸
沖電気工業 (株)

データベースマシンはデータベース管理システムの性能向上に効果がある。したがって、データベースマシンを用いた性能価格比の高い分散処理システムの構築が可能である。しかし、そのためにはデータベースマシンとホスト計算機との通信オーバーヘッドを削減することが重要となる。筆者らは、この問題に対してデータベースマシンをプログラマブルな環境を持つ仮想データベース計算機とする方法でアプローチしている。仮想データベース計算機はデータベース管理命令、通信 I/O 命令などの仮想命令セットを持ち、応用システムに適したホストとのインタフェースを提供できる。

本稿では、今回インプリメントを行った仮想データベース計算機へのアプローチとそのアーキテクチャについて述べる。さらに、通信コストの改善について評価する。

A Distributed System Oriented Database Machine(in Japanese)

Akifumi SAKAMOTO, Suguru KAWAKAMI, Sadayuki HIKITA

OKI Electric Industry Co. Ltd,

4-11-22 Shibaaura, Minato-ku, Tokyo 108, Japan

Database machines work as good components to organize distributed systems. Database machines have shown their performance and cost-effectiveness in commercial markets. However, problems of communication overheads between host computers and database machines have not fully resolved yet. In order to resolve this problem, authors propose the virtual database machine which provides users with a programmable environment. This machine has a virtual instruction set such as query instruction, input/output instruction etc. to make the interface flexible to applications.

In this paper, the motivation of the virtual database machine is described. Then the architecture of it is explained. Finally, its performance is evaluated using an example.

1. はじめに

機能分散型の分散処理システムでは従来一つの計算機で行っていたことを複数の専用計算機で行うことにより性能/価格比を上げることができる。しかし、そのためには計算機間の通信オーバーヘッドを削減することが重要となる。

データベースマシンについても同じことが言える。たとえば、X D M S [CANA74]ではCODASYLのデータ操作命令がインタフェースの水準として低すぎたために、通信ボトルネックとなったと考えられる[植村80]。

関係データベースマシンでは、関係データベースのキュアリによる抽象度の高いインタフェースによって、通信ボトルネックを解決しようとしている[HIKI81][EPST80]。

ところが、実際の応用システムで応用プログラムがデータベースマシンにアクセスする場合には、検索、更新以外にもトランザクションの制御など多くのインタラクションが発生する。そこで応用システムにおいては、そのような通信コストをおさえることが要求される。

本稿では、通信コスト低減のため、データベースマシンのあるべきアーキテクチャを検討し、これを実際のデータベースマシンFRIEND [HIKI85a]へ適用した実例について述べる。

2. 通信コストの改善

データベースマシンがデータベース管理システム(DBMS)の性能改善に効果があることはベンチマークテスト[BITI83]により示されている。これは以下のような理由による[HIKI85a][STON81][STON83]。

- (1) 応用プログラムに影響されることなく、データベース処理に適した処理構成をとることができる。
- (2) バッファ管理をデータベース処理専用設計できる。
- (3) タスクスイッチなどのオーバーヘッドの少ない専用OSを用いることができる。

しかし、これらはあくまでDBMS自体の改善であり、通信オーバーヘッドの問題は解決されていない。特にデータベースマシンを共有サーバのように疎結合で用いる場合には、ホスト計算機との通信コストが高く問題が大きい。

通信オーバーヘッドには、通信量によるオーバ

ヘッドと通信回数によるオーバーヘッドがある。低速の通信回線では、通信量が問題となる。一方、高速の通信回線では、通信回数が問題となる。共有サーバ型のデータベースマシンは公衆回線のような低速の広域ネットワークからイーサネット[MET C76]などの高速のLANまで、種々の通信回線を通してアクセスされる。したがって、通信量と通信回数の両方のオーバーヘッドを削減する方法が必要となる。

大量のデータをデータベースマシンに送ったり、逆にデータベースマシンから取り出す場合には、高速の回線を用いる以外に通信コストを削減する方法はない。しかし、それ以外では幾つかの方法が考えられる。

通信量を減らす方法として、ANSI標準のSQL[ANSI85]に導入された手続きの機構が利用できる。これは手続き名と仮引数で手続きの仕様を記述し、本体を一つのSQL文で記述するものである。実行時には、手続きは手続き名と実引数によって呼び出され本体のSQL文が実行される。データベースマシンにSQLの手続きを置き、これをホストから呼び出すとすると、プログラム実行時にSQL文全体を送る必要がなくなり通信量を減らすことができる。

通信回数を減らす方法として、DELTA[SHIB84]のコマンド木がある。プリミティブなDELTAコマンドを個々に送るのではなく、複数のコマンドを含むキュアリ木として送るものである。この方法は、一回の転送で複数のコマンドを送ることができる。これにより、個々のプリミティブなコマンドとその応答が、ホストとデータベースマシン間で通信されるのをふせぐことができ、通信回数を減らすことができる。

しかし、SQLの手続きは、単一のSQL文を起動できるだけであり、DELTAのコマンド木も単一のキュアリを構成できるだけである。データベースマシンのインタフェースとしては、単一のキュアリの通信量、通信コストを下げることはできるが、それ以上の改善は望めない。

データベース検索言語の機能として集合関数の機能がある。この機能を拡張し、キュアリの記述能力を高めることによっても通信オーバーヘッドを減少させることが可能である。集合関数を用いれば、平均値、最大値、タプル数などを、一回の検索で求めることができる。2の巾乗、標準偏差などの関数をデータベースマシンのインタフェースに追加すれば、結果だけを転送することができ通

信コストを減少させることができる。しかし、実際には利用者の多様な要求をデータベースマシンが完全に満たすことはできない。

IDM [UBEL85] [EPST80]のstored commandは、トランザクション開始、トランザクション終了といった制御用のコマンドや、検索のプリミティブコマンドをあらかじめ格納しておくことにより、実行時の通信コストを減少させることができる。

しかし、この機能はデータベース処理のプリミティブを格納するためのものであり、手続きのな処理はホスト計算機側で行うことになる [TSUR84]。したがって、応用システムの処理全体を考えた場合、ホスト計算機とデータベースマシンの通信オーバーヘッドの問題は解決されない。

以上の分析より、データベースマシンにおける通信オーバーヘッドの問題は次の点の解決が必要であるといえる。

(1) インタフェースが単一キューリの記述能力では、トランザクションの制御や複雑な処理のためには複数の通信を必要とする。したがって、SQLの手続き、集合関数、コマンドのキューリ木としての一括送信により単一キューリの通信コストを下げただけでは処理全体の通信回数、通信量はそれほど減少しない。

(2) データベースマシンのコマンドセットは、データベース処理だけに基づいたもの（例えば関係代数演算やトランザクション制御）である。コマンド木やstored commandによってそれらのコマンドを組み合わせても、条件判断や計算などの手続きのな処理を作れない。したがって、手続きのな処理を必要とする処理においては、通信コストは減少しない。

筆者らは、これらの問題に対して、データベースマシンをプログラマブルにする方法でアプローチし、データベースマシンFRIEND上でインプリメントを行った。以下で、筆者らが開発したデータベース処理のための仮想計算機環境を提供するプログラマブルデータベースマシンの実現法について述べる。

3. 実現アーキテクチャ — 仮想データベースマシン

3.1 データベースマシンFRIENDの拡張

図1にFRIENDのシステム構成を示す。FRIENDは、パーソナルコンピュータやワークステーションをホスト計算機とするバックエンドマシンとして働く。FRIENDは関係DBMSを持ち、データベース管理を行う。応用プログラムはワークステーション上で実行される。

両者はFRIENDと通信ネットワークで接続される。キューリやトランザクション制御などのコマンドと検索結果などのデータが通信ネットワークを介してやりとりされる。この際の通信オーバーヘッドが2章で述べた問題点である。

この問題点の解決のために、リモートプロシジャコール [BIR84] を用いる方法が考えられる。利用者は、FRIENDの中にリモートプロシジャとしてプログラムを記述・格納する。ホスト側にある応用プログラムは、このプロシジャをリモートプロシジャコールにより起動し、パラメータを渡す。リモートプロシジャはFRIEND上で実行され、ホストはその処理結果を受け取る。しかし、この機構を実現するためには、FRIEND上で応用プログラムが実行できるようにFRIENDのCP




図1 FRIENDのシステム構成

Uを解放し、汎用のOSやプログラミング環境を提供する必要がある。これは、2章で述べたデータベースマシンFRIENDの性能を向上させる専用化の特長に反する。汎用計算機ではFRIENDは効率よく動かない。

そこで、筆者らは、FRIENDのCPUを利用者に解放せず、FRIENDをデータベース処理命令を持つ仮想計算機とする方式を用いた。以下この仮想計算機をFRIENDに対してV-FRIENDと呼ぶ。V-FRIENDは、トランザクション開始命令、検索命令、更新命令などデータベース処理に対応した命令（データベース管理命令）の他に、条件分岐命令や文字列操作命令、演算命令、ロードストア命令などを持つ。これにより、データベースマシンのコマンドセットの制約から、手続的な処理を実行する場合に生じる通信オーバーヘッドの問題を解決している。しかも、DBMSはデータベースマシンとして専用化された実行環境で動作できる。

利用者はV-FRIENDの命令を用いて、必要なプログラムを作成する。このプログラムはFRIENDの内部に格納される。このプログラムはワークステーション上のAPによって起動され、V-FRIEND上で実行され、結果がワークステーションに送り返される。以下では、V-FRIENDのアーキテクチャや実行手順の詳細について述べる。

3.2 仮想データベース計算機のアーキテクチャ

V-FRIENDは、以下のユニットにより構成される（図2）。

(1) 命令フェッチユニット (IFU)

次に実行するV-FRIEND命令を取り出す。

(2) 仮想命令ユニット (VIU)

・V-FRIENDの命令セットに対してデコードを行い実行ユニットを起動する。

(3) 実行ユニット (EXU)


・実行ユニットにはデータベース管理実行部 (DBEX)、通信実行部 (CMEX)、演算実行部 (AREX) がある。それぞれV-FRIENDのデータベース管理命令、通信I/O命令、演算命令の実行を行う。

(3-1) データベース管理命令実行部 (DBEX)

・内部のDBMSと対応する。DBMSの機能を使う命令、例えばトランザクション開始・終了、検索、更新などの命令を実行する。

(3-2) 通信実行ユニット (CMEX)

・ワークステーション等ホスト計算機との通信命令を実行する。検索結果の転送やホストからのパ



Virtual Database Machine

⇔ flow of data

↔ flow of control

EXU: Execution Unit

VIU: Virtual Instruction Unit

IFU: virtual Instruction Fetch Unit

CMEX: Communication Execution part

DBEX: DBMS Execution part

AREX: Arithmetic Execution part

reg: registers

PSU: Program Storage Unit

図2 仮想データベース計算機のアーキテクチャ

ラメタの受取りは、このユニットによって行われる。

(3-3) 演算ユニット (AREX)

・数の比較、演算、文字列操作等を行う。ループや条件分岐などの実行制御にも用いる。

(4) プログラム格納ユニット

・プログラムコードとデータを格納する。

実行ユニット内にはいくつかのレジスタがある。以下で主なものを説明する。

(1) 入出力レジスタ

入出力レジスタはホスト計算機との通信に用いる。ホスト計算機からのデータは入力命令 (INPUT命令) によって入力レジスタ (INPUT_REG) にセットされる。ホストへの転送データは出力レジスタ (OUTPUT_REG) にセットされた後、出力命令 (OUTPUT命令) によって送られる。

(2) データ操作レジスタ・タプルレジスタ

データベース管理命令のオペランドはデータ操作レジスタ (DM_REG) にセットされる。データベース管理命令の実行によりDBEXが起動される。検索されたタプルや更新するタプルはタプルレジスタ (TU_REG) にセットされる。

(3) プログラムカウンタ

プログラムカウンタは次に実行するV-FRENDの命令を指している。

(4) その他のレジスタ

利用人名レジスタ (UN_REG) がある。UN_REGは、V-FRENDを利用している利用人名を保持している。また、状態レジスタ (ST_REG) があり、V-FREND命令実行後の終了コードを保持している。

V-FRENDへは複数の利用者が同時にアクセスできる。したがって、レジスタなどの実行環境は利用者毎に割り当てられる。一方、プログラムコードは、全利用者で共有される。現在これらの実行環境は、すべてソフトウェアにより実現されている。

3.3 V-FREND命令の実行

ここでは簡単な例を挙げてV-FREND上でのプログラムの動作を説明する。

V-FRENDのPSUのデータ領域に、以下に示すデータが格納されている。これは検索条件の一部である。

```

NAME
from R
where CITY = 'NY'

```

ホスト計算機は、実行時に決るAGE = '25' という条件を引数としてプログラムを呼び出す。V-FRENDではこの引数とあらかじめ格納されていた検索条件から

```

NAME
from R
where CITY = 'NY'
AGE = '25'

```

という検索条件を生成する。次に、データベース検索命令 (SELECT命令) を実行し、検索結果をホスト計算機に送り返す。この例ではタプル 'SMITH' が検索され、正常終了コード '00' とともに送り返される。図3は、この例を示す。左側はプログラムで、右側はレジスタの内容




図3 仮想命令の実行

である。

- (1) INPUT命令によりCMEXから起動時の引数を受け取る。AGE='25'がINPUT_REGにセットされる。
- (2) SELECT命令のパラメタがPSUのデータ領域からDM_REGに転送される。
- (3) INPUT_REGの内容(AGE='25')とDM_REGの内容が、連結される。
- (4) SELECT命令が実行される。DM_REGの内容を命令のオペランドとしてDMEXが起動され、検索が行われる。タプル'SMITH'が検索されTU_REGに格納される。この例ではSELECT命令は正常終了しているため、正常終了コード'00'がST_REGに設定される。
- (5) ST_REGの内容がOUTPUT_REGに転送される。
- (6) SELECT命令の終了状態がチェックされる。プログラムのこれ以降の部分が実行されるかどうかを判断する。
- (7) TU_REGの内容(SMITH)がOUTPUT_REGに転送され、終了コードと連結される。
- (8) 出力命令が実行され、OUTPUT_REGの内容がホスト計算機へ転送される。

V-FRENDはあくまでデータベースマシンであり、目的はデータベース管理を高速化することにある。しかし、このように手続き的処理が記述できることで、応用システムへの対応を容易にすることができる。

3.4 プログラムの作成と実行

3.3節で述べたプログラムの作成と実行のためには、プログラムの作成、PSUへの格納、および起動が必要となる。この節では、それらについて述べる。

(1) プログラムの作成

プログラムの編纂、コンパイルといった作業は、ワークステーション等のホスト計算機で行う。ホスト計算機上のプログラミング環境として、コンパイラやアセンブラが必要となる。また、V-FREND開発時にはリモートにあるプログラムのデバッグツールが重要であった。このデバッグツールはプログラム開発時にも有効である

う。

ホスト計算機上で最終的にV-FREND命令列となったプログラムは、V-FRENDに格納する必要がある。プログラムは通常のデータを格納するのと同様に"insert"コマンドによりV-FRENDのリレーションにインサートされる。

(2) プログラムの準備 (OPEN)

リレーションに格納されたプログラムは、実行前にPSUにロードする必要がある。この処理はホストからのOPENコマンドによって行われる。まずコード領域、データ領域が確保される。次にコード領域にプログラムコードが読み込まれ、初期設定を必要とするデータが初期設定される。このプログラムはリエントラントであるため、既にロードされているプログラムがOPENされた場合はプログラムコード部分は共有されるだけで新たにロードはされない。もちろんこの場合でもデータ領域は確保され初期設定される。

(3) 実行 (RUN)

PSUにロードされたプログラムはホストからのRUNコマンドによって起動される。RUNコマンドには実行するプログラムの名前とプログラムに対する引数が含まれる。V-FRENDは起動されたプログラムの仮想命令の実行を開始する。

(4) 終了 (CLOSE)

OPENされたプログラムはCLOSEコマンドにより完了する。これによりプログラムのデータ領域が解放される。しかしこのプログラムが他の利用者に共有されている場合にはコード領域は解放されない。

以上のシーケンスを図4に示す。




図4 プログラム実行のシーケンス

4. 評価

簡単なトランザクション処理の例を用いてV-FRENDによる通信オーバーヘッドの改善を評価する。例として用いるトランザクションTは次の通りである。

例：トランザクションTは、リレーションAにタプルを、追加する。次にリレーションBのタプルを検索し、更新する。

トランザクションTを、プログラマブルでないFRENDで実行する場合のホストとFRENDのインタラクションを示す(図5)。まず、ホスト計算機は、FRENDに対して“start transaction”コマンドを出す。これによりリレーションAとリレーションBがオープンされ、ロックされる。次に“insert”コマンドにより、リレーションAにタプルを追加する。さらに、“update”コマンドにより、タプルを検索し更新する。最後に“end_transaction”コマンドによりこれらの変更がコミットされ、リレーションAとリレーションBのロックが解除される。

一方、V-FRENDでは、これらの処理は予めプログラムしてV-FREND内に格納しておくことになる。このプログラムは以下のようなる。

- (1) ホスト計算機から、追加するタプル、リレーションBの検索条件値、およびタプルBの更新後値をパラメータとして受け取り、リレーションA、Bをロックしてトランザクションを開始する。




図5 FRENDでのインタラクション

- (2) 受け取ったパラメータによりリレーションAにタプルを追加する。

- (3) リレーションBからタプルを検索し、これを更新する。

- (4) トランザクションを終了する。

- (5) 結果をホスト計算機に送り返す。

この例ではV-FRENDによってインタラクションの数が4回から1回に減っている。

図6に通信回線の速度と応答時間を示す。このグラフはFRENDの実際のレスポンスタイム、通信量、およびLANのオーバーヘッドにより求めたものである。これにより、実際の処理における通信オーバーヘッドの割合が示される。

回線速度が遅い(1200bps、2400bps)場合には、FRENDの応答時間はV-FRENDの応答時間より大きい。回線速度が速くなるにしたがって両者のギャップは小さくなる。これは通信速度の増加によって通信量のオーバーヘッドが減少するためである。

しかし、回線速度が無限大となっても、両者の間には全体の処理時間に対して無視できない差が残る。これは通信回数によって生じるLANのプロトコルオーバーヘッドである。

V-FRENDは、通信量と通信回数両方の削減を可能にする。したがって、このアプローチは低速の回線による広域ネットワークシステムにも、比較的高速のLANをベースにしたシステムにも有効であるといえる。




図6 応答時間の比較

5. 結論

プログラマブルデータベースマシンへのアプローチとデータベースマシンFRIENDでの実現例について述べた。仮想データベース計算機V-FRIENDは通信オーバーヘッドを改善するためにプログラム実行環境を持つ。これにより応用システムとしての利用に適したデータベースマシンとホスト計算機のインタフェースを提供できる。しかもFRIENDの持つ性能向上のための特長を保つことができる。

本稿では、クライアントサーバモデルだけについて述べた。複数のデータベースマシンによる分散データベースシステムでは”パイプラインジョイン”[HIKI85b]のようなデータベースマシンの協調動作が必要となる。仮想データベース計算機の考えは、このような分散データベースシステムにも適応できると思われる。

現在V-FRIENDはインプリメントが終わり、機能と性能の評価を行っている。分散環境への適応が今後の課題である。

〈参考文献〉

- [ANSI85] American National Standard Institute. "Draft Proposed American National Standard Database Language SQL". X3.135-198x project: 363-D. 1985
- [BIR84] A. D. Birrel, et al., "Implementing Remote Procedure Calls". ACM TOCS, Vol. 2, No. 1, 1984 pp39-59.
- [BIT83] D. Bitton, et al., "Benchmarking Database Systems A Systematic Approach". Proc. of VLDB, 1983, pp. 8-19.
- [CANA74] R. H. Canaday, et al., "A Back-end Computer for Data Base Management". CACM, Vol. 17, No. 10, 1974, pp. 575-582.
- [EPST80] R. Epstein, et al., "Design Decisions for the Intelligent Database Machine". Proc. AFIPS, Vol. 49, 1980, pp237-241.
- [HIKI81] S. Hikita, et al., "Optimization of the file access method in content addressable database access machine (CADAM)". Proc of AFIPS conference 1981, Vol 50, 1981, pp. 507-513.
- [HIKI85a] S. Hikita, et al., "Database Machine FRIEND". Database Machines Forth International Workshop, Springer-Verlag, 1985, pp. 190-207.
- [HIKI85b] S. Hikita, et al., "A Stepwise Approach to Distributed Database System by Database Machines". Proc. of 1985 ACM Symposium on Small Systems, 1985, pp. 18-24.
- [METC76] R. M. Metcalfe, et al., Bogges, D. R., "Ethernet: Distributed Packet Switching for local computer networks, CACM Vol. 19, No. 7, 1976, pp. 395-404.
- [SHIB84] S. Shibayama, et al., "A Relational Database Machine with Large Semiconductor Disk and Hardware Relational Algebra Processor" New Generation Computing 2, OHMSHA LTD. and Springer-Verlag, 1984, pp. 131-155
- [STON81] M. Stonebraker, "Operating System Support for Database Management" CACM, Vol. 24, No. 7, 1981, pp. 412-418.
- [STON83] M. Stonebraker, "Performance Enhancements to Relational Database System". ACM TODS, Vol. 8, No. 2, 1983, pp. 167-185.
- [TSUR84] S. Tsur, et al., "An Implementation of GEM - Supporting a Semantic Data". Proc. of SIGMOD '84, Vol. 14, No. 2, 1984, pp. 286-295.
- [UBEL85] M. Ubell, "The Intelligent Database Machine (IDM)". Query Processing in Database Systems, Springer-Verlag, 1985, pp. 237-247.
- [植村80] 植村、前川, "情報処理叢書1: データベースマシン", 1980, 情報処理学会, pp18-23.