

スーパーデータベースコンピュータ SDC に於ける単一モジュールの基本性能 5 H - 6

平野聰 原田昌信 楊維康 喜連川優 高木幹雄
東京大学 生産技術研究所

1 概要

本論文ではスーパー・データベース・コンピュータ SDC [1][2] の単一モジュールの性能評価について報告する。以下、SDC の特徴について簡単に述べた後、Wisconsin Benchmark[3] により試作版単一モジュールの性能評価を行ない、Teradata 社のデータベースマシン DCB/1012[6] 及び GAMMA[5] と比較する。

2 SDC の特徴

(1) ハイブリッド・アーキテクチャ: 図1に SDC の全体構成を示す。SDC ではプロセッサ 100 台規模の並列性を目指して、プロセッサ 4 台、磁気ディスク装置 2 台を密結合の処理モジュールとし、それらを高機能オメガ・ネットワークで疎に結合したハイブリッド・アーキテクチャをとる。この構成では、密結合の利点である軽い通信コストによる高速性と、クラスタ数の増減によるスケーラビリティが同時に得られる。並列性はモジュール内、モジュール間の二つのレベルで実現され、ダイナミック GRACE ハッシュアルゴリズム [7] を直接反映している。




図1: SDC の全体構成

(2) 高速 2 次記憶系と処理系の結合: 図2にデータベース処理モジュール内の構成を示す。SDC の大容量 2 次記憶は高速なディスクを複数台用い、リレーションをタブル単位で水平に分割して格納することにより、ストライピング・ディスクを構成して広いバンド幅を実現する。2 次記憶は高速データ転送専用バス H-Bus を介してプロセッサ Pn 群と密に結合されており、I/O とプロセッサ間のボトルネックが解消されている。また、ディスクに近いところで前処理を行なう為、モジュール外への不要なデータの転送を抑えネットワークの負荷を軽減している。

(3) ハードウェア・ソータ: 各モジュールは 19 個の LSI ソートチップからなるハードウェアソータを有し、512K レコードまでのソート処理を線形時間で高速に実行する。大容量ソータメモリはソータとしてもデータメモリ DM の拡張としても使用可能であり、ソート機能を有するバイモーダル・メモリとみなすことができる。

(4) 高機能オメガネットワーク: 高機能オメガネットワークは結合演算の際、データの分布が不均一でもパケットを各モジュールに均等に割り当てるパケット平坦化機能を持つ。ネットワー-




図2: モジュール構成

クのスイッチング。ユニットはパケットの分布に関する局所的な情報のみからネットワークの接続状態を決定する。

(5) ダイナミック・ハイブリッド GRACE ハッシュ・アルゴリズム DHGH: 従来結合演算で用いられてきたハイブリッド・ハッシュ・アルゴリズムでは、不均一なデータ分布を考慮していないかった。DHGH ではパケットの動的デステージングにより、パケットのデータ分布に因らず一定の処理時間で結合演算を実行できる。

3 ハードウェア諸元

評価した試作機及び比較対象のハードウェア仕様 [5] は以下の通りである。

- Teradata DCB/1012
 - プロセッサ i80286 20 台
 - 8 インチディスク 40 台
 - 各プロセッサにバッファメモリ 2 メガバイト、計 40 メガバイト
- GAMMA
 - プロセッサ VAX11/750 17 台
 - 8 インチディスク 8 台
 - 各プロセッサにバッファメモリ 2 メガバイト、計 34 メガバイト
- SDC (1 モジュール)
 - プロセッサ MC68020 20Mhz 5 台、うち 1 台はコントロール用
 - 8 インチディスク 2 台
 - バッファメモリ 8 メガバイト

4 性能評価

評価はウィスコンシンベンチマークを用い 3 種類のリレーションについて行なった。4 バイトのキーを持つ 208 バイト長のタブルをそれぞれ 1 万個、10 万個、100 万個含む。上記の 3 種のマシンいずれもデータを複数のディスクに水平に分割して格納している。

4.1 選択演算

選択演算では 1 % または 10 % の選択を行なった。Teradata では結果の格納時にリカバリーのための処理を行なっているが GAMMA と SDC では行なっていない。また今回はインデックスを使用していない。

^o SDC, The Super Database Computer, Basic performance of one module

S.Hirano, W.Yang, M.Harada, M.Kitsuregawa, M.Takagi
Institute of Industrial Science, University of Tokyo

```
insert into result
select * from relA where k1 < X;
```

選択演算	Teradata	GAMMA	SDC
1万タブル 1%	6.86	1.63	0.57
1万タブル 10%	15.97	2.11	0.61
10万タブル 1%	28.22	13.83	4.80
10万タブル 10%	111.0	17.44	5.23
100万タブル 1%	213.1	134.9	47.8
100万タブル 10%	1107	181.7	52.0

(単位秒)

図3はリレーションサイズの変化に対するSDCの実行時間の変化を表している。SDCはストリーム指向の処理方式をとるので、CPUの処理はディスクの読み出しとオーバーラップしている。入力リレーションだけでなく出力ファイルもディスクストライピングにより2つのディスクに分散して格納し、出入力時間の短縮を図っている。

図4は選択演算でのプロセッサの台数効果を示す。リレーションは100万タブルで、横軸は選択性率、縦軸は実行時間を表している。プロセッサ数が2台～4台の場合は全ての選択性率にわたってディスクの入力速度に追従しているが、プロセッサ数が1台の時には選択性50%以上になると、処理が追従不能になり急激に性能が低下していく。

4.2 選択演算

結合演算(join A and B)の結果を示す。入力リレーション relBは結合前に10%の選択演算を施される。

```
insert into result
select A.* , B.* from relA A, relB B
where A.k1 = B.k1 and B.k1 < X;
```

結合演算	Teradata	GAMMA	SDC
1万タブル	35.6	5.1	1.14
10万タブル	331.7	36.3	10.5
100万タブル	3535	703.0	127.0

(単位秒)

今回の評価では演算アルゴリズムとしてhybrid hash join[4]を用いた。TeradataではHash sort-merge join、GAMMAではSimple hash joinを用いている。図5はリレーションサイズの変化に対する実行時間の変化を表している。これからタブル数の増加に対して線形の時間で終了していることがわかる。TeradataとGAMMAではプロセッサ同士がネットワークを介してタブルを交換するのでオーバーヘッドが生ずるのに対して、SDCでは密結合の利点を生かしてディスクと各プロセッサがメモリを共有し、前処理の選択演算、ハッシュ、つき合わせ操作を行なうので、ディスクの入出力時間とオーバーラップして内で処理を行なっている。

5 結論

ベンチマークによりSDCではプロセッサ台数、ディスク台数共にTeradata、GAMMAと比べてわずかであるにもかかわらず、非常に高い性能を持つことが明らかになった。現在はこのモジュールを構成要素とする多モジュール版の実装を進めている。

参考文献

- [1] 楢、平野、喜連川、高木「スーパーデータベースコンピュータ SDC のアーキテクチャ」情報処理学会第39回全国大会、1989
- [2] 平野、楢、喜連川、高木「スーパーデータベースコンピュータ SDC のシステムソフトウェアの概要」情報処理学会第39回全国大会、1989
- [3] Bitton,D.,DeWitt,D.,C.Turbyfill "Benchmarking Database Systems - A Systematic Approach" Very Large Databases Conf., 1983
- [4] DeWitt,D.,R.Gerber, "Multiprocessor Hash-Based Join Algorithms" Very Large Databases Conf., 1983
- [5] DeWitt,D.,Ghandeharizadeh,S.,et al, "A SINGLE USER EVALUATION OF THE GAMMA DATABASE MACHINE" 5th International Workshop on Database Machines, 1985
- [6] Teradata Corp., "DBC/1012 Data Base Computer Concepts & Facilities" Teradata Corp, 1983
- [7] Kitsuregawa,M.,Nakayama,M.,Takagi,M. "The effect of bucket size tuning in the dynamic hybrid GRACE hash join method" Very Large Databases Conf., 1989




図3: 選択演算




図4: 選択演算の台数効果




図5: 結合演算