

3Q-1

データベースプロセッサ RINDA の 大容量ソート処理方式

佐藤 哲司、武田 英昭、中村 敏夫、速水 治夫

NTT情報通信処理研究所

1. はじめに

データベースプロセッサ RINDA の 1 つの構成要素である ROP (関係演算機構) は、専用ハードウェアを用いてソートや結合演算等を高速化している [1,2]。

本稿では、キー長やキー数に柔軟に対処できる大容量ソート処理方式について述べる。

2. ソータ構成法

ROP は、図 1 に示すようにチャンネルを介して本体装置に接続され、ホストから送られてくる表の各行からキーを抽出してソートする機能を有する。10万件を越えるキーを小型な装置で高速にソートするために、マルチウェイマージ処理を多段階に繰り返す多段マージソート法 [3] を採用している。

2-1. 基本動作

図 2 は ROP ソート部の構成であり、比較転送ユニットを 1 次元アレイ状に配置したソートアレイを用いて、最大 k 件のキーを並列に比較できる。以下に、本ソート回路を用いたソート処理の手順を示す。

①初期ソート段階：各行から抽出したキーを、ソートアレイを用いて k 件づつ連続的にソートし、結果を大きさ k のソート列として ROP メモリに格納する。キー抽出→ふるい落とし→ソート→行およびソート列の格納の各処理をパイプライン的に実行し、ホストからの表(行)の転送時間で初期ソート段階の処理を完了する。

②中間マージ段階：ROP メモリに格納されたソート列を最大 k 本づつマージして、結果を ROP メモリに格納する処理を、全ソート列の本数が k 以下になるまで繰り返す。 N 件のキーをソートするのに要する中間マージ段数 m は $m = \lceil \log_k N \rceil - 2$ である。ここで $\lceil x \rceil$ は、 x を超える最小の整数を示す。なお、 $m \leq 0$ の場合は中間マージ処理は行わずに、出力マージ段階に移行する。

③出力マージ段階：ROP メモリに格納されたソート列をマージし、キーの並び順に対応して行データを出力する。ソートした表は、ページ単位に編集して、本体装置に返送する。

本ソート法の特徴は、ROP メモリを繰り返し使用して大量のキーをソートできること、

ソートアレイで k 個のキーを並列に比較するため、一定のマージ処理速度を保ったままで、マージウェイ数 k を大きくできることである。

ROP では、チャンネル転送時間に重畳して、初期ソート段階と出力マージ段階の処理を行う。このため、本体装置からみてソートに必要な時間は、中間マージ段階の処理時間となる。この時間は、中間マージ段数に依存し、比較転送ユニット数を増やすことによって削減できる。

2-2. ユニット連結動作

データベースプロセッサは、整数(二進数)のような短いキーから、文字列等の比較的長いキーまで、幅広い範囲の長さのキーをソートできなければならない。ROP のソート部を構成するソートアレイは、1次元配置した比較転送ユニットの各メモリにキーを格納して比較を行うことから、各ユニットのメモリ容量でソートできるキー長の上限が規定される問題がある。




図1 ROPの構成

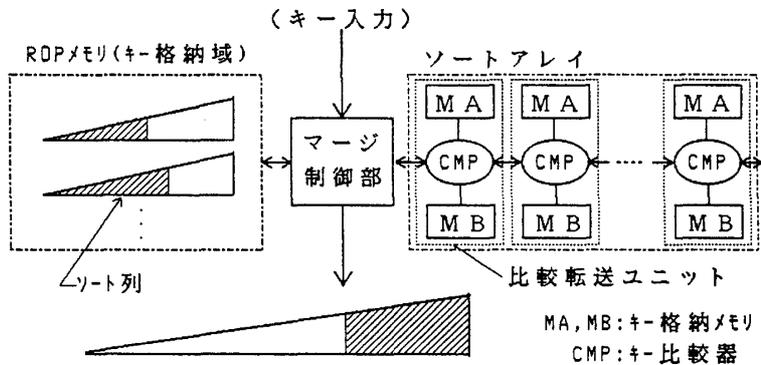


図2 ソート部の論理構成

キー長の上限を拡張する方式として以下の2案がある。

- ① キーの最大長に合わせて、各比較転送ユニットのメモリ容量を大きくする方式。
- ② 各ユニットのメモリ容量は一定として、キー長に応じて複数ユニットを連結して動作させる方式。この方式では、キーは複数の比較転送ユニットに分割格納される。

ROPでは以下の理由により、案②を採用した。

- ④ 総ハード量を一定とすると、キー長が短い範囲で案②の方が、より多くのユニットを実現できる。一般に、キー長が短い表に対するソートの使用頻度が高いと考えられるため、キー長が短い領域でより高い性能が実現できる案②が適する。
- ⑤ キーの最大長は、日本語文字列場合でも100文字程度と考えられる。キー長の上限を250バイト程度とした場合、数個のユニットを連結することで実現できる。本ソートアレイでは、数個のユニットの連結動作は容易であり、制御回路も比較的簡単に実現できる。
- ⑥ ユニット連結を行うと、実効の比較転送ユニット数が少なくなるためマージウェイク数が減少する。しかし、キー長(行の長さ)が長くなれば、ROPメモリに格納できるキー数が相対的に減少する。このため、通常2段の中間マージで、ROPメモリに格納できる件数のキーをソートできる。

3. 大容量ソート処理方式

多段マージを採用したROPソータでは、基本的にソート件数に上限はないが、実装されているROPメモリ容量によりソート容量が定まる。ROPのソート容量を超える表のソートは、ROPがオーバーフローするまでの範囲で分割ソートした後に本体装置においてマージする。ここでは、ROPにより分割ソートを行う場合に必要となる機能について述べる。

3-1. オーバフロー検出法

キー格納用と行格納用とに共用しているROPメモリは、可変長の長さを持つ行を扱うために、両者の境が動的に変化できる構成としている。この結果、ROPメモリが真に満杯になるまでソートできる件数を増大できるが、ソータのオーバーフローは行の長さに依存し、事前にソート可能件数を知ることはできない。更に、ソート前処理としてふるい落とし処理を行う場合もあることから[2]、ソート処理過程で常にオーバーフローの検出を行う必要がある。

キー格納域には、多段マージ処理を行うためのマージ作業域が含まれるが、その大きさはキーの件数から算出できる[3]。一方、行格納域の大きさは、格納する行毎にその長さが可変であるため、実際に行を格納するまでその長さを知ることはできない。このため、所定の件数のキー入力ごとに、ソート作業域を含めたキー格納域の大きさを算出し、行を格納する毎にオーバーフローの判定を行なう。

3-2. ROP入力の再開法

二つの表の結合は、ソートマージ結合法を基本として処理し、個々の表をROPでソートする段階で、ビットアレイを用いて結合する可能性のない行をふるい落としとして、結合処理の演算量を削減している[2]。

オーバーフローが発生しない通常の使用形態では、ROPの入出力処理は、表を単位として完結している。この特徴を利用して、通常、ROPからソート結果を出力する処理の裏でビットアレイを初期化して、初期化に要する時間をゼロにしている。

ビットアレイの設定、参照およびソート処理は、ROP入力操作と並行して処理することから、オーバーフローが発生した場合に、ビットアレイに対する処理が継続できるようにROP入力を再開しなければならない。

ビットアレイを操作中にオーバーフローが発生するのは、ソート処理と組み合わせて、ビットアレイの設定あるいは参照処理を行う場合である。いずれの場合も、ビットアレイの状態を保持したままで、一旦、ソート結果を出力してROPメモリのキー格納域と行格納域を空にしてから、ROP入力を再開する。

このため、ROPでは、ビットアレイの設定・参照処理を行っている際にオーバーフローが発生した場合、ビットアレイのクリア契機を最後の参照ソートの出力時まで遅らせることで、オーバーフロー時であっても処理を継続できる方式としている。

4. まとめ

ROPの主要な構成要素であるソート部の構成法に関して、キー長やキー数に柔軟に対処できる大容量ソート処理方式について述べた。ソートアレイを構成するユニットを連結することで、ソートできるキーの長さを約250バイトまで拡張した。ROPメモリの行格納域とキー格納域の境界を動的に変化させ、10万件以上の行からなる表を一度にソートできる方式とした。更に、ROPがオーバーフローするような大規模データベースをソートする場合であっても、ビットアレイの設定・参照処理を継続できる構成として、ROPを繰り返し使用して分割ソートが行える方式とした。

[参考文献]

- [1] 速水、井上他：リレーショナルデータベースプロセッサRINDAのアーキテクチャ、情報研報 88-CA-73-12、1988
- [2] 武田、佐藤他：データベースプロセッサRINDAの関係演算方式、情報研報 87-全大5Q-6、1988
- [3] 佐藤、武田他：大容量データベース処理に適したソート手法、信学技報 DE88-1、1988