

ソーティングにおける高速化の一手法（I）

1P-7

－ タグトーナメント技法 －

前島泰*，米城範正**，大熊和明**，小端則夫**

* 富士通静岡エンジニアリング

** 富士通株式会社

1. はじめに

近年、データ量は著しく増加しており、これを扱う外部ソートも一層の高速化が必要となっている。

外部ソートは、入力したレコードから複数の昇順（降順）に並んだレコード列を作るストリング生成部と、これら複数のストリングを一つにまとめるストリング併合部の、2段階を経る。本稿では、ストリング生成部を高速化する一手法について報告する。

2. トーナメント技法

従来、ストリング生成部では、総合処理性能が良いことから、トーナメントソート技法を用いている。トーナメントソート技法は、一連のレコード群について、トーナメント（勝ち抜き戦）方式で比較し、最も強いレコードの選出と、作業ファイルへの出力を、繰り返し行うソート技法である。“強いレコード”とは、昇順に並べる場合は小さいキーを持つレコードのことである。

図1にトーナメントソート技法の処理手順を示す。

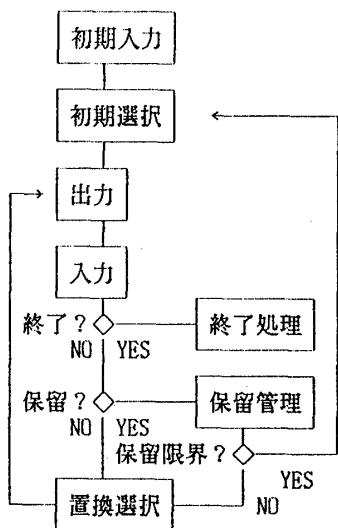


図1 トーナメントソート技法

初期入力で、トーナメントに参加させるレコードを読み込む。初期選択では、初回のトーナメントを行い、優勝レコードを選出し出力する。優勝レコード出力後、次のレコードを入力し優勝レコードと比較する。入力レコードのキーが優勝レコードのキーより弱い場合、入力レコードと残ったレコードでトーナメントを行い、新たに優勝レコードを選出する。入力レコードのキーが優勝レコードのキーと同値の場合、優勝レコードと同様に出力する。入力レコードのキーが優勝レコードのキーより強い場合、トーナメントに参加させずに保留しておく（保留レコード）。なぜなら、優勝レコードのキーより強いキーを持つレコードを、トーナメントに参加させると、ストリング内の並びが壊れるためである。

保留レコードが保留限界数（トーナメントするレコード数）になった場合、初期選択処理を含めたトーナメントを行う。

3. 問題点

従来のトーナメントソート技法では、保留レコードについて以下の問題点がある。

1) 保留レコードのトーナメントを行うごとに、初期選択が必要である。

2) 保留レコードの管理が必要である。

レコード数が増加するにつれて、保留レコード発生率が高くなり、ストリング生成部の処理時間に、大きな影響を及ぼしている。

4. タグトーナメント技法

これらの問題点を解決すべく、各レコード単位にタグ情報を付加することにより、非保留レコードと保留レコード

の識別を可能にし、保留レコードもトーナメントに参加できるように考案した。これをタグトーナメント技法と名付けた。タグトーナメントにおける対戦相手と勝敗は、次のように決定する。

- 非保留レコード対非保留レコード
→ キーの強弱により勝敗を決定する。
- 非保留レコード対保留レコード
→ 非保留レコードを勝ちとする。
- 保留レコード対保留レコード
→ キーの強弱により勝敗を決定する。

図2にタグトーナメント技法の処理フローを示す。従来と同様、初期入力、初期選択を行い、優勝レコードの選出と次のレコードの入力を行う。このとき、レコードに付加するタグ情報は、すべて非保留として初期化しておく。入力レコードのキーが、優勝レコードキーよりも強い場合には、“保留”を示すタグ情報を付加し、入力レコードをトーナメントに参加させて、再び優勝レコードを選出する。

非保留レコード同士、または保留レコード同士の対戦では、キーの値によって強弱が決定するため、出力するストリングは、通常の強弱順にレコードが並ぶことになる。これに対し、非保留レコードと保留レコードとの対戦では、必ず非保留レコードを勝たせ、保留レコードの値によってストリング内の、レコード順序が逆転することを防ぐ。

以上のように、保留レコードと非保留レコードを共にトーナメントに参加させることにより、保留レコード発生時の初期選択、および保留レコードの管理が不要になる。

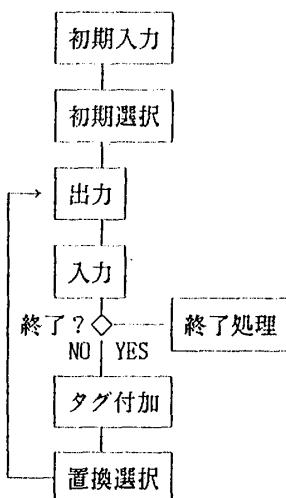


図2 タグトーナメント技法

5. 効果

従来の技法では、保留レコードが発生するたびに保留管理を行い、保留レコードが限界値に達した場合、初期選択処理を繰り返す必要があった。しかし、タグトーナメント技法では、ソート開始時点の1回だけである。また、保留レコードもトーナメントに参加できるため、保留レコードの管理が不要となる。さらに副次効果として、対戦相手を決定するとき、従来のトーナメントソート技法では、対戦相手がいるかどうかの、判定が必要であったが、タグトーナメント技法では、常に相手が存在するためその必要がない。図3に、タグトーナメント技法の効果を、CPU時間の差で表す。

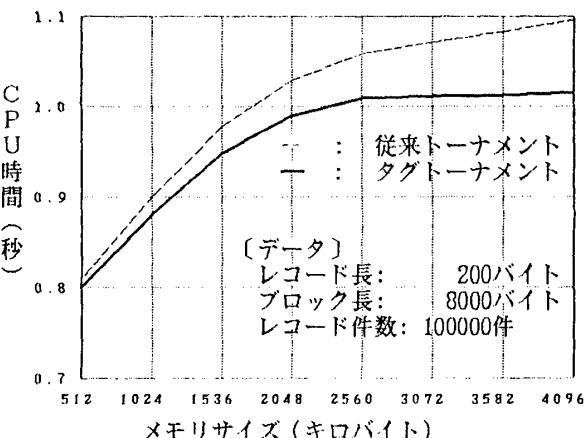


図3 トーナメントソート性能評価結果

タグトーナメントは従来のトーナメントソートに比べ、メモリサイズが多くなるほど性能差が開いている。これは、トーナメント規模が大きくなるにしたがって、一つの優勝レコードを決定するまでの比較回数が増加するため、保留処理時間や、対戦相手の存在を調べる処理時間の差が、より明確に現れてくるためである。

6. おわりに

以上ソート処理時間の性能を改善する手法について述べた。レコードにタグ情報を付加することによって、効率の良いトーナメントソートを行うことができる。