

省メモリ版相関ルール抽出エンジンの開発

1 T-3

三石 彰純, 小幡 康†

†三菱電機（株）情報技術総合研究所

1 はじめに

大量のデータから相関ルールを抽出するデータマイニングにおいて、ルールを高速に抽出するアルゴリズムが提案されてきた[1,2]。しかしこれらのアルゴリズムは主記憶上で処理を行っており、マイニング対象データによっては膨大なメモリ空間を必要とするため、マイニング処理が不可能となる場合がある。我々が現在開発を進めているデータマイニングシステム Knodias では、一時ファイルを併用することで少ないメモリ空間の中でマイニングを行うアルゴリズムを開発してきた[3]。本稿では、従来方式の問題点、省メモリ版マイニングエンジン開発の狙い、目標、アルゴリズム、性能向上に関して行った種々の試みについて述べる。

2 開発の狙いと目標

Knodias は主として医療データや品質管理データから相関係数に関して有用な相関ルールを抽出することを目的として開発している。これらのデータ(以下、DB)は1つのレコードに多数(平均 50~100)のアイテムが存在し、アイテムの組み合わせ(以下、I S)数が膨大となるため、巨大なメモリ空間を必要とし、マイニング処理が不可能な場合が多い。このような場合、マイニングを行う対象のアイテムをあらかじめ絞り込み、マイニングの負荷を下げざるを得ないが、人為的にアイテムの絞り込みを行った場合は有用な相関ルールを抽出できない危険性がある。

そこで我々は、一時ファイルを利用することでレコード長が 50~100 の“長いレコード”に対しても実用的な処理速度が得られることを目標としてマイニングアルゴリズムの開発を行った。なお、我々は結論部のアイテム数が1のルールを重視しており、効率上の理由もあって結論部の長さを1に限定している。

A Data Mining Engine using Small Memory Space.

Akitoshi MITSUISHI, Yasushi OBATA †

† Mitsubishi Electric Corporation

3 従来方式の問題点

従来のマイニングアルゴリズムではマイニング処理に必要な I S をすべて主記憶上に木構造として展開していることが最大の問題点であった。レコード長が高々十数アイテムの場合には大きな問題とならないが、50~100 あるいはそれ以上になると、仮想メモリ空間でも足りない状況が発生する。

ここでレコード長の増加に伴う I S 数の増加を考えるため、レコード長が 10、レコード数が $10 \times n$ の DB1 とレコード長が 100、レコード数が n の DB2 における I S 数を考える。簡単のため各 DB に含まれるアイテムはそれぞれ $100 \times n$ 種類、すなわち全てのアイテムが異なるとすると、DB1 に含まれる I S 数は約 $10^4 \times n$ であるのに対して、DB2 では約 $2 \times 10^{13} \times n$ に達し、両者の比は約 2×10^9 になる。すなわち、DB1 と DB2 では総アイテム数は同一であるにも係わらず、I S 数は9桁も違ってくる。現実にはこれほどの差は出ないが、レコード長の増加がアイテムセット数の増加に与える影響の大きさは容易に推測できる。

図1は apriori アルゴリズム[1]を元にしたマイニングアルゴリズムを示している。図において、 L_k は長さ k のラージアイテムセット(DB内の出現頻度が最小支持度以上のアイテムセット、以下 L I S)の集合、 C_k は長さ k の候補 I S の集合を意味する。ここで、ステップ4)~ステップ7)において、 C_k 、 L_k をメモリ上の木構造で表現することを前提としており、 C_k 、 L_k の数が膨大になった時に処理が不可能となる。

- 1) L_1 を作る
- 2) $k=2$
- 3) L_{k-1} が空なら終了
- 4) L_{k-1} から C_k を作る
- 5) DBを開いて、 C_k の各要素の出現度数を数える
- 6) C_k の中から最小支持度を満たさないものを削除し、残りを L_k とする
- 7) L_k 、 L_{k-1} 、 L_1 から長さ k のルールを抽出する
- 8) $k++$
- 9) 3)へ戻る

図1 従来方式

4 小ロット方式

図2に今回開発した省メモリ版マイニングアルゴリズム“小ロット方式”の基本アルゴリズムを示す。図において、 F_k は長さ k のLISについて、そのアイテム番号と出現頻度を記録した一時ファイルを意味している。小ロット方式では、 L_k をメモリではなく一時ファイル F_k に保持しておき、ユーザから指定されたメモリ領域に入る分だけLISをメモリに読み込んで木構造を作成する。すなわち、従来方式で展開される木構造の部分木のみを主記憶に展開し、その部分木に対してマイニング処理を行う。そのため従来方式と比較してDBと木構造の照合処理の回数は増加する。

上記の基本アルゴリズムに加えて、性能を向上させるために下記の工夫を行っている。

①兄弟LISの一括処理

長さ $k-1$ のLISから長さ k の候補ISを生成する時に、先頭から $k-2$ 個のアイテムが同じ“兄弟IS”を一括して処理することによって、不要な候補ISが生成されることを防いでいる。

②不要候補ISの削除

木構造を生成する過程において、中間的に作成し、最終的には不要であるノードが残る場合がある。この不要ノードを削除するステップを設けることで木構造とDBとの照合処理を高速化している。

③メモリ管理

木構造を作成するためのメモリ領域を処理の開始時に一括して確保し、その中をマイニングエンジンで管理することでメモリ管理を高速化している。

上記の他に、結果として採用しなかったが下記の改

良案も検討した。

④複数レコード一括処理方式

複数のレコードを一括して読み込んで木構造との照合を行う。DBの性質によって効果にばらつきが多い。

⑤木構造の逆引き方式

DBと木構造との照合処理において、木構造側からレコード内のIS有無を調べる。効果が大きくなく、逆効果の場合がある。

⑥ L_{k-1} 再照合方式

ルール生成に必要な L_{k-1} の出現度数をDBと木構造を照合した時に調べる。一時ファイルのファイルサイズを縮小することができるが、処理速度が低下するため不採用。ただし、一時ファイルが大きくなる場合には有効であり、再検討する余地がある。

5 まとめ

限られたメモリ空間の中で相関ルールを抽出するマイニングアルゴリズムを開発し、実用的な性能を得ることができた[5]。今後は、より大規模なデータを対象とした評価を行い、改良を加えていく予定である。

参考文献

- [1]Agrawal, R., Srikant, R. : "Fast Algorithm for Mining Association Rules", Proc. VLDB '94, 1994.
- [2]Park, J., and Chen M. : "Using a Hash-Based Method with Transaction Trimming for Mining Association Rules", IEEE Trans. Knowledge and Data Engineering 9(5), 1997.
- [3]小幡他:有限メモリ空間で相関ルールを抽出するマイニングアルゴリズム, 第56回情処全国大会2W-8, 1998!
- [4]三石他: Knodiasにおけるデータマイニング方式, 第56回情処全国大会2W-6, 1998.
- [5]小幡他:省メモリ版マイニングエンジンの評価, 第58回情処全国大会IT-4, 1999.

- 1) L_1 を作り、 F_1 にセーブする
- 2) $k=2$
- 3) 空の F_k を作成する
- 4) F_{k-1} が空なら19)へ
- 5) 使用メモリ量が割当てメモリ量に達していれば9)へ
- 6) F_{k-1} から1レコード読み出し、候補アイテムセットを作成して C_k に加える
 F_{k-1} にレコードが残っていなければ9)へ
- 7) 作成した候補アイテムセットからルールを抽出するのに必要な長さ $k-1$ のアイテムセットを作り木構造に加える
- 8) 5)に戻る
- 9) $pos=F_{k-1}$ のファイル読み出し位置
- 10) C_k の出現度数カウントに必要な枝を随分
- 11) DBを調べて、 C_k の各要素の出現度数をカウントする
- 12) C_k の中から最小支持度を満たすものを L_k とする
- 13) L_k のアイテム番号列とその出現度数を F_k に出力する
- 14) 10)で隠蔽した枝を復活する
- 15) F_{k-1} を最後まで読み込み、7)で追加したアイテムセットの出現度数を木構造に転記する
- 16) L_k, L_{k-1}, L_1 から長さ k のルールを抽出する
- 17) 木構造を消去する
- 18) L_{k-1} ファイルを pos の位置まで巻き戻し、4)へ戻る
- 19) F_{k-1} を削除、 F_k が空ならば終了
- 20) F_k をrewindして F_{k-1} とする、 $k++$ 、3)へ戻る

図2 小ロット方式