

6W-1

## 階層化されたシグネチャファイルを用いた集合値検索方式の検討

渡辺 悟康\*

北川 博之†

石川 佳治‡

\* 筑波大学工学研究科

† 筑波大学電子情報工学系

‡ 奈良先端科学技術大学院大学

### 1はじめに

集合データは、複雑なデータ構造を支援するデータベースにおいて、頻繁に現れる基本的なデータ構造である。そのため、集合データを用いるようなデータベースシステムでは、集合値を効率良く支援する索引機構が必要となる。我々は、従来テキスト検索に用いられてきたシグネチャファイルを集合値検索機構として取り上げ、比較的小規模のデータベース上での、様々なコスト評価を行なってきた[1, 2]。しかし、シグネチャファイルを用いた集合値検索には、検索コストがデータオブジェクトの数に比例して増加するという問題点がある。このためデータオブジェクト数が増加した時には、入れ子型索引より性能が劣ることがある[3]。

本稿では、シグネチャファイルによる検索の高速化の手段として知られている階層化の概念を用い、主に性能改善の必要性が大きい集合値問い合わせ条件を対象に階層化されたシグネチャファイルの有効性を検討する。

### 2シグネチャファイルを用いた集合値検索

シグネチャ(signature)とは、個々のデータオブジェクトから生成される固定長のビット列のことである。

#### シグネチャの作成法

1. 集合の各要素から、長さが  $F$  ビットで、その内  $m$  ビットが "1" にセットされている要素シグネチャ(element signature)を作成する。
2. すべての要素シグネチャのビットごとの論理和をとるスーパーインポーズドコーディング(superimposed coding)を行ない、集合シグネチャ(set signature)を作成する。

このようにして生成されたシグネチャと、各データオブジェクトの識別子(OID)の組を格納したのがシグネチャファイル(signature file)である。シグネチャファイルの構成法としては、シグネチャをビットごとに別々のファイルに格納するビットスライストシグネチャファイル(bit-sliced signature file, BSSF)を用いる。

問い合わせが与えられた際に、問い合わせ条件中に現れる集合を問い合わせ集合(query set,  $Q$ )、データベース中の集合をターゲット集合(target set,  $T$ )と呼ぶ。また、それぞれから作成される集合シグネチャを、問い合わせシグネチャ(query signature,  $S_Q$ )、ターゲットシグネチャ(target signature,  $S_T$ )と呼ぶ。

集合値検索の問い合わせ条件には様々なものがあるが、本稿では、 $Q$  が  $T$  に含まれる場合( $T \supseteq Q$ )を対象とする。この問い合わせ条件の場合、 $S_Q \wedge S_T \equiv S_Q$  を満たすターゲットシグネチャが、問い合わせ条件を満たす候

補となる。しかし、これらの候補の中には、実際に問い合わせ条件を満たすアクチュアルドロップ(actual drop)と、実際には条件を満たさないフルスドロップ(false drop)があるので、実際のデータからそれらを区別する必要がある。

### 3階層化されたBSSF

本稿では、2段階に階層化されたBSSFを考える。

#### 階層化されたBSSFの作成法

1. 前述のようにターゲットシグネチャを作成し、BSSFに格納する。このBSSFをレベル1BSSFと呼ぶ。
  2. レベル1の集合シグネチャ  $M$  個について、さらにスーパーインポーズドコーディングを行ない、1つのシグネチャを作成する。それらのシグネチャをまとめたものを、レベル2BSSFと呼ぶ。
- 階層化されたBSSFを作成した時のシグネチャファイルの概略は、図1のようになる。 $(F = 8, m = 2, M = 4)$




図1：階層化されたBSSFの構成

### 4コスト解析

表1に使用する記号の定義を示す。また、特に式を示さなかったものについては[3]の式を用いる。

#### 4.1フルスドロップ確率

レベル2BSSFのシグネチャ1つに対応した集合の平均要素数  $D_{t2}$  は、 $D_t \ll V$  の時、(1)式で与えられる。

$$D_{t2} = V \left\{ 1 - \left( 1 - \frac{(V-1)}{(D_t-1)} \right)^M \right\} \approx V \left( 1 - e^{-\frac{D_t}{V}M} \right) \quad (1)$$

よって、[1, 2]より、レベル2BSSFを検索する際のフルスドロップ確率  $Fd_2$  は、(2)式で与えられる。

$$Fd_2 \approx \left( 1 - e^{-\frac{mD_{t2}}{F}} \right)^{mD_q} \quad (2)$$

また、レベル1BSSFのみを用いた場合のフルスドロップ確率  $Fd_1$  は、(3)式で与えられる。

$$Fd_1 \approx \left( 1 - e^{-\frac{mD_t}{F}} \right)^{mD_q} \quad (3)$$

Evaluation of Two-level Signature Files as Set-valued Object Retrieval Facilities

Noriyasu Watanabe\*, Hiroyuki Kitagawa† and Yoshiharu Ishikawa‡

\*Doctoral Degree Program in Engineering, Univ. of Tsukuba

†Institute of Information Sciences and Electronics, Univ. of Tsukuba

‡Nara Institute of Science and Technology

記号	定義
$N$	オブジェクトの総数 (= 320,000)
$P$	1ページのバイト長 (= 4096)
$b$	1バイトのビット長 (= 8)
$M$	レベル2のシグネチャを1つ作るのに必要なレベル1のシグネチャの個数
$V$	ドメインの要素数 (= 10,000)
$D_t$	ターゲット集合の要素数
$D_q$	問い合わせ集合の要素数
$F$	シグネチャのビット長
$m$	要素シグネチャで"1"のセットされるビット数 (= 2)
$A$	アクチュアルドロップ数
$P_s$	成功検索時の1オブジェクト当たりのページアクセス数 (= 1)
$P_u$	不成功探索時の1オブジェクト当たりのページアクセス数 (= 1)

表 1: 変数の定義

## 4.2 検索コスト

総検索コストは、各レベルでのBSSFを検索するコスト、OIDファイルをアクセスするコスト( $LC_{OID}$ )、候補となったターゲットシグネチャがアクチュアルドロップかフルスドロップかを実際のデータから区別するコストの和になる。

レベル1,2 BSSFの検索コスト  $LC_1, LC_2$  は、以下のように与えられる。

$$LC_1 = \left\{ 1 - (1 - Fd_2)^{\frac{Pb}{M}} \right\} \left[ \frac{N}{Pb} \right] m_q \quad (4)$$

$$LC_2 = \left[ \frac{N}{PbM} \right] m_q \quad (5)$$

ここで、 $m_q$  は(6)式で与えられる問い合わせシグネチャのウェイト ("1"の立っているビット数) の期待値である。


$$m_q \approx F(1 - e^{-\frac{Pb}{M}D_q}) \quad (6)$$

以上より、総検索コスト  $RC$  は(7)式で与えられる。

$$RC = LC_2 + LC_1 + LC_{OID} + P_s A + P_u F d_1 (N - A) \quad (7)$$

階層化されたBSSF(BSSF2)、通常のBSSF(BSSF)、入れ子型索引(NIX)の3種類の検索機構の検索コストのグラフを図2に示す。

傾向として、 $D_q$  が一定の値より大きくなつた時、階層化されたBSSFは有効であることが分かる。これは、 $D_q$  が大きくなると、 $F d_2$  が減少するために、レベル2 BSSFでの絞り込みが効果的に行なわれるためである。しかし、 $D_q$  が小さい時は  $F d_2$  が大きいため、階層化されたBSSFの検索コストは通常のBSSFとほぼ同じになる。また、 $M$  が大きいと  $F d_2$  が悪化し、レベル2 BSSFでの絞り込みが効果的にできない。逆に  $M$  が小さいと  $LC_2$  が悪化してしまい、やはり検索コストは大きくなる。

図 2:  $F = 5000, D_t = 100$  の検索コスト

## 4.3 格納コスト

階層化されたBSSFの格納コスト  $SC$  は、各レベルのBSSFの格納コスト ( $SC_1, SC_2$ ) とOIDファイルの格納コスト ( $SC_{OID}$ ) との和になる。

$$\begin{aligned} SC &= SC_2 + SC_1 + SC_{OID} \\ &= \left[ \frac{N}{PbM} \right] F + \left[ \frac{N}{Pb} \right] F + SC_{OID} \end{aligned} \quad (8)$$

格納コストは、通常のBSSFに比べて、レベル2 BSSFを作るために増加する。しかし、検索コストがほぼ同等の入れ子型索引と比べると、低く抑えることができる。

## 5 まとめ

本稿では階層化されたBSSFの検索コストと、格納コストについて見積り式を示した。本稿で検討したパラメータ設定の下では、 $T \geq Q$  の問い合わせに対する検索コストは、通常のBSSFの1~2割程度となり、一定以上の  $D_q$  値に対しては、入れ子型索引以上の性能を示した。格納コストは通常のBSSFより若干大きくなるが、入れ子型索引と比べると、小さい格納コストで同等の検索コストを得られることが分かった。

今後の課題としては、[1]において提案されたスマート検索方式を用いた時の評価、 $N$  が増加した時の多段化などがあげられる。

## 参考文献

- [1] Y. Ishikawa, H. Kitagawa, and N. Ohbo. Evaluation of signature files as set access facilities in OODBs. In Proc. ACM SIGMOD, 1993.
- [2] H. Kitagawa, Y. Fukushima, Y. Ishikawa, and N. Ohbo. Estimation of false drops in set-valued object retrieval with signature files. In Proc. 4th International Conference on Foundations of Data Organization and Algorithms, 1993.
- [3] 石川、北川、大保. シグネチャファイルによる集合値検索のコスト評価. 情報処理学会研究会報告 93-DBS-94-27, 7 1993.