

拡張ハッシュ法を用いた類似キー検索ファイル

6W-6

田中栄一 川出慎二

神戸大学 工学部

1. はじめに

拡張ハッシュ法^[1]と類名表記^[2]を用いて、次の条件を満たすファイルを構成する方法を提案する。

- (1) 誤りが小さい場合は誤ったキーでも検索できる。
- (2) 入力キーと類似しているキーを全て列挙する。
- (3) キーの挿入が容易で、またキーの削除によっても記憶利用率が低下しない。類名表記を用いたファイル^[2]は条件(1)と(2)を満たすが(3)を満たさない。条件(1)~(3)を満たす方法には類名表記と B^+ 木を用いたもの^[3]がある。本文では、これより操作が単純で能力もほぼ等しいファイルを提案する。

2. 類名表記と拡張ハッシュ法

いまアルファベットを次のような2つの類に分類する。

$$A = \{a, b, c, d, e, f, g, h, i, j, k, l, m, n\},$$

$$B = \{o, p, q, r, s, t, u, v, w, x, y, z\}.$$

A, B を類名と呼び、キーを類名で表したものを類名表記という。“apple”を類名で書くとABBAとなり、これを“apple”の類名表記という。類名表記を用いるとキー集合を部分集合に分割できる。

類名表記をディレクトリに用い、拡張ハッシュ法によるファイルの例を図2に示す。ページ部の1つのブロックに5つのキーまで記憶できるものとする。ここではキーの長さは4であるが、ディレクトリ部の類名表記の長さは2である。

キーの数が増加してページが溢れると、ディレクトリ部の類名表記を長くして、ページ部のキーを分割する。またキーの削除が増え、ページ部の空き領域が多くなると、ディレクトリ部の類名表記の長

AAAA → cake, face
 AAAB → baby, lady
 ABAA → cold, home
 BBAB → star, stay

図1. 類名表記によるキー分類の例




図2. 拡張ハッシュ法によるファイルの例

さを短くし、ページを合併して、記憶利用率の低下を防ぐ。

3. 類似キーの検索法

入力キーを x とし、その類名表記を $E(x)$ とする。2つの文字列を α, β とすると、 $D(\alpha, \beta)$ を α から β へのレーベンシュタイン距離とする。ディレクトリにある類名表記の長さを m 、 $E(x)$ の最初の m 桁を $(E(x))_m$ 、距離のしきい値を d_t とし、 $S(x)$ を x との距離が d_t 以内のキーの集合とする。 $S(x)$ は最初空にしておく。 x と類似したキーの列挙は次のように行う。

- (1) $D(E(x), E') \leq d_t$ となる類名表記 E' を全て発生させ、(2)を行う。
- (2) $(E')_m$ をディレクトリで探し、あれば $(E')_m$ が指すブロック B を呼び、(3)を行う。
- (3) ブロック B にある全てのキー y に対して $D(x, y)$ を計算し、 $D(x, y) \leq d_t$ なら y を $S(x)$ に記憶する。
 x と最も類似したキーを出力したいときは、(3)

の代わりに (3)' を行う。

(3)' ブロック B にある全てのキー y に対して $D(x, y)$ を計算し、距離が d_t 以下のもののうち、 $D(x, y) \leq D(x, z)$ ($z \in B$) となる y を出力する。(このような y は複数あることもある)。

(1) で E' を発生させる代わりに、 E_k をディレクトリ部の類名表記とし、 $D(E(x), E_k)$ を計算して、その値が d_t 以下となる E_k を求めて、(2) の操作をすることも考えられるが、キーの数が数千以上で、 $d_t = 1$ あるいは $= 2$ の時は、(1) の方が速い。

4. 実験結果

約 23 万語の英語の辞書を用いて実験を行った。 $d_t = 1$ 、すなわち、1 つのキーの文字の置換誤り、挿入誤り、脱落誤りは高々 1 とした。正しいキー x' を誤らせて x とし、(1)~(3)' を用いて最も類似したキーを検索し、(3)' の出力 y が 1 つで、かつ $x' = y$ となるときの、すなわち、誤り訂正と見たときの長さ 8 の場合の正答率を図 3 に示す。これは誤ったキーによる検索の成功率でもある。このときのページの読み込み回数の平均値を図 4 に示す。図 5 に記憶利用率を示す。類数 4 のときは類数 2 のときに比べページの読み込み回数は約 2 倍であった。ランダムに選んだキーを挿入して記憶利用率を測定した。記憶利用率は約 0.675 で B 木のそれに近い。




図 3. 誤ったキーによる検索の成功率 R

5. あとがき

類似キーの検索結果は文字類の作り方には影響されない。記憶利用率を向上させることは今後の問題である。




図 4. 誤ったキーによる検索時のページの読み込み回数の平均値 I




図 5. 記憶利用率 U

参考文献

- [1] D. Fagin et al. : Extendible hashing - a fast access method for dynamic files, ACM Trans. Database Systems, vol.4, no.3, pp.315-344 (1979).
- [2] E. Tanaka et al. : A high speed string correction method using a hierarchical file, IEEE Trans. PAMI, vol.9, no.6, pp.806-815 (1987).
- [3] 平出基一, 田中栄一: 誤ったキーでも検索できるファイル構成法, 情報処理学会データベースシステム研究会研究報告, no.96, pp.65-74 (1993).