

## 誤ったキーでも検索できる情報検索システム†

沼倉 覚† 田中栄一†† 青木晴海†††  
 矢野目毅††††† 矢吹勉†††††

本論文は、誤りを持つキーでも検索できる階層的ファイルの構成法について述べている。B-木あるいはそれを改良した階層的ファイルはよく知られているが、これらは正しく記憶されたデータを正しいキーで速く検索するものである。データが大量になると、データが誤って記憶されることも避けられないし、検索者も常に正しいキーを使うとは限らない。このような事態にいかに対処するかはまだ手探りの状態であるが、最近、HL法が提案されている。本論文では、文字類の誤り傾向に基づいて文字をいくつかの類に分割し、その類名を用いてデータを分類し、階層的ファイルを作る。文字類が1つしかできないときは、適当に文字類を作る。このときは、他の類の文字に誤る(置換誤り)ことが起こりうる(類外置換)。ファイルの大部分あるいはすべてを補助記憶に記憶する。キーがファイルにあるかどうかを調べる。キーがファイルにないとき、レーベンシャタイン距離の意味で最も近いキーを探す。3つの方法を提案し、長さ4~8の1.66万語(辞書A)と10.4万語(辞書B)の上で、実験し、辞書Aの上で、HL法と比較した。キーの誤りは、類外置換、挿入、脱落は高々1つとし、実験では類外置換を含めて、誤り数は高々2としている。(a)すべての場合について、辞書の第1段を主記憶に置いた場合の方が、すべてを補助記憶に置いた場合より検索時間は短い。また、辞書Bの場合でも誤りのあるキーでの検索時間はそれほど低下しなかった。(b)誤りのないキーの検索時間は、HL法に比べて820~1800倍速く、誤りのあるキーでは、70~520倍速い。(c)挿入1、脱落1、脱落1+類内置換1の場合、HL法が検索率がよく、他の5つの場合は本論文の検索率が高い。HL法はすべての場合について誤検索率が高い。

### 1. まえがき

大型データを能率よく検索するためのファイルの構成法はよく研究されている<sup>1)</sup>。たとえば、B-木<sup>2)</sup>およびそれを改良した階層化ファイルはよく知られている。これらの方法は、正しく記憶されたデータを正しいキーで速く検索するものであるが、データが大量になると、データが誤って記憶されることも避けられないし、検索キーも常に正しいとは限らない。このような事態にいかに対処するかはまだ手探りの状態である<sup>3)</sup>。最近、伊藤・木沢<sup>4),5)</sup>は、この問題について1つの階層的ファイルの構成法を提案した。これは、筆者の知る限り、この問題に対するほとんど唯一の研究である。本論文は、綴りの編集法を大型ファイル構成に応用することについて述べる。綴りの編集法<sup>3),6)-8)</sup>は、

統計法と辞書法に大別される。統計法はn字組確率や文字・単語の発生確率などの統計的情報を用いるが辞書は用いない方法である。辞書法は辞書を用いる方法であるが、統計的情報を用いないことを意味しない。統計法は辞書法と比べて高速であるが訂正率が低いとされている。最近、栗田・相沢<sup>9)</sup>は大語彙環境下で高い訂正率を持つ統計法を提案している。一方、辞書法の高速化の研究もある<sup>10)-13)</sup>。綴りの編集法を大型ファイル構成に利用するとき、次のような問題がある。

- (1) データが大量になると、補助記憶に格納されるため、主記憶と補助記憶の間にデータの転送が頻繁に起こる。データのどの部分を主記憶に、どの部分を補助記憶に格納するか、また、補助記憶のデータをどのように主記憶に転送するか、が問題になる。主記憶上の操作で高速な綴りの編集法が、主記憶と補助記憶を含めた系で高速とは限らない。そこで、主記憶と補助記憶の間で、どのようにデータを分配するかが問題になる。
- (2) 情報検索では、通常、大部分のキーは正しい。綴りの編集法は誤った綴りを訂正するものであるが、誤った綴りの訂正に高速であっても、正しいキーの検索に高速であるとは限らない。一般に、キーが誤っていることは少ないと考えられるから、ファイルは正しいキーの検索でも十分高速で

† An Information Retrieval System Accessible by Keys with Errors by SATORU NUMAKURA (Information Science, Faculty of Engineering, Graduate School, Utsunomiya University), EIICHI TANAKA (Department of Information Science, Faculty of Engineering, Utsunomiya University), HARUMI AOKI (Fuji Heavy Industries, Ltd.), TAKESHI YANOME (Sharp Corporation) and TSUTOMU YABUKI (Fujitsu, Ltd.).

†† 宇都宮大学大学院工学研究科情報工学専攻

††† 宇都宮大学工学部情報工学科

†††† 富士重工(株)

††††† シャープ(株)

†††††† 富士通(株)

なければならない。

ここでは、綴りの編集法を誤りのあるキーでも検索できる大型ファイルの構成に応用する。第1の方法は、2種類の類名表記を用いた階層的ファイルで、第2の方法は、1種類の類名表記による階層的ファイルであり、いずれもハッシュ法で検索する。両方法は重みつきレーベンシュタイン距離を用いている。第3の方法は、第2の方法で重みつきレーベンシュタイン距離の代わりにハミング距離を用いるものである。

次章で本方法の基礎になる重みつきレーベンシュタイン距離と類名表記について述べる。第3章で検索法、第4章では実験のための大型データの発生法、第5章で実験結果について述べ、HL法<sup>5)</sup>と比較する。

## 2. 重みつきレーベンシュタイン距離<sup>15)</sup>と綴りの類名表記

系列  $X = x_1 x_2 \cdots x_m$  と  $Y = y_1 y_2 \cdots y_n$  の間に次の条件を満たす写像  $M$  が定義されているものとする。 $x_i$  が  $y_j$  に写像されているとき、 $(i, j)$  と書く。

- (i)  $(i, j) \in M$  のとき、 $1 \leq i \leq m, 1 \leq j \leq n$ .
- (ii)  $(i_1, j_1), (i_2, j_2) \in M$  のとき、
  - a)  $i_1 = i_2$  iff  $j_1 = j_2$ ,
  - b)  $i_1 < i_2$  iff  $j_1 < j_2$ .

条件(ii)は図1のような置換を禁止している。

$|M|$  で  $M$  の元の数を表すものとする。 $u_s$  は  $M$  の元  $(i, j)$  のうち、 $x_i \neq y_j$  であるものの数とし、 $v_s = n - |M|$ ,  $w_s = m - |M|$  とする。 $u_s, v_s, w_s$  はそれぞれ、置換の数、挿入の数、脱落の数である。このとき、 $X$  から  $Y$  への重みつきレーベンシュタイン距離(WLD)  $D(X, Y)$  は、次のように定義される。

$$D(X, Y) = \min_s \{ p*u_s + q*v_s + r*w_s \}.$$

ここで、 $p, q, r$  はそれぞれ、置換、挿入、脱落の重みである。通常、 $p < q+r$  と仮定する。 $D(X, Y)$  は、次の式で帰納的に計算できる。

$$\begin{aligned} d(i, j) &= \min \{ d(i-1, j) + r, d(i-1, j-1) + p(i, j), \\ &\quad d(i, j-1) + q \}. \end{aligned}$$

ここで、 $d(i, 0) = i * r$ ,  $d(0, j) = j * q$ ,

$$p(i, j) = \begin{cases} p, & x_i \neq y_j \text{ のとき.} \\ 0, & \text{そうでないとき.} \end{cases}$$

このとき、

$$D(X, Y) = d(m, n).$$

ここで、 $q=r$  のときは距離公理を満たすが、そうでないときは、必ずしも  $D(X, Y) = D(Y, X)$  が成り立た

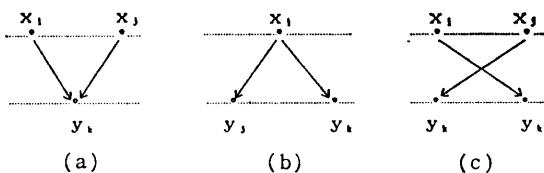


図 1  $X$  から  $Y$  への写像  
Fig. 1 Mapping from  $X$  to  $Y$ .

ない。

文字読み取り機(OCR)などには、読み取り誤りに、ある偏りがあるのが普通である。たとえば、荒川<sup>16)</sup>の英文字読み取りシステムでは、“アルファベットと記号” $\Sigma$  が次のように分類でき、同じ類の中では読み取り誤りがあることがあるが、他の類の文字に誤って読まれることはない。

### 分類 1

$$\begin{aligned} A &= \{a, h, k, m\}, B = \{n, p, u\}, C = \{b, e, f, g\}, \\ D &= \{l, q, y, z\}, E = \{i, j, o, r\}, F = \{s, t, v\}, \\ G &= \{c, d\}, H = \{w, x\}, I = \{\cdot, \}\}. \end{aligned}$$

ここで、 $A, \dots, I$  を類名という。次に類名表記を定義する<sup>10)</sup>。類名表記を用いて、キーの集合を分類し、キー集合全体を探索する代わりに、キー集合の1部分を探索することで、検索率と検索速度を上げることを目指す。いま単語 apple を類名で書くと、ABBDC となるが、これを apple の第1種の類名表記といい、E 1(apple) と書く。apple が誤って、apule になってしまっても、その類名表記は E 1(apule)=ABBDC で、E 1(apple) と等しい。分類1を使っていることを明示したいときは、E 1.1(apple) のように書く。このように、同じ類内で起こる文字置換を類内置換という。文字誤りの偏り情報が不明なときや、たとえ文字誤りの偏り情報がわかっていても、複数の類に分かれるのではなく、1つの類になってしまうことがある。このときには、適当に文字類を作らなければならない。このとき、文字の置換誤りは、その文字の属する類の文字だけでなく、他の類の文字に誤ることがある。このときの文字置換を類外置換という。

いま、単語 W の第1種の類名表記 E 1(W) の中に、 $A, \dots, I$  類の類名がそれぞれ、 $u_A, \dots, u_I$  個あるとき、 $(u_A, \dots, u_I)$  を W の第2種の類名表記といい、E 2(W) と書く。たとえば、E 2(apple)=(1, 2, 1, 1, 0, 0, 0, 0, 0) である。分類1を用いていることを明示するときは E 2.1(apple) と書く。第2種の類名表記でも、類内置換のときは、誤った綴りの類名表記は正しい綴りのそれと等しい。以後、分類1を統合した分類2を

用いる。

## 分類 2

$$J = \{a, h, k, m, n, p, u\},$$

$$K = \{b, e, f, g, l, q, y, z\},$$

$$L = \{i, j, o, r, s, t, v\}, M = \{c, d, w, x\},$$

$$N = \{-, '\}.$$

## 3. ファイル検索法

本章では3種のファイル検索法について述べる。

これらの検索法は、キーが誤って他のキーになってしまった場合は考慮していない。このような場合に対処するためには、キーの広い意味での文脈（周辺の情報）を用いないとできない。

### (1) 検索法 1

第1段に第2種の類名表記、第2段に第1種の類名表記を用いて、階層的ファイルを作ることができる<sup>13)</sup>が、ここでは、ハッシュ法でファイルにアクセスすることにする。主記憶に対する負荷を軽くするため、ファイルのアクセス法は文献13)とは異なった方法を用いる。いま、文字の分類を  $T = \{C_1, C_2, \dots, C_s\}$  とし、長さ  $\ell$  の単語に関するファイルの見出しになっている第2種の類名表記の1つを  $E2_i = (n_1, n_2, \dots, n_\ell)$  とする。ここで、 $n_i$  は  $n_{ci}$  の略記である。 $n_1 n_2 \dots n_\ell$  を  $E2_i$  の十進数と見て、これを  $E_{num}$  おく。また、ファイル中の長さ  $\ell$  の第2種の類名表記数を  $N1(\ell)$  とする。 $N1$  の1は第1段の見出しあることを示す。次のハッシュ関数を作る。

$$h(E2_i) = (E_{num} \bmod N1(\ell)) + 1.$$

衝突したキーのデータは空き領域に記憶し、無駄のないハッシュ表を作った。ファイルの一部を図2に示す。第2種の類名表記  $E2(W)$  の下にある第2段の第1種の類名表記の集合を、 $E2(W)$  を見出しどする部分辞書といい、 $d(E2(W))$  と書く。たとえば、 $d((5, 1, 0, 0, 0)) = \{JJJJJK, JJJJKJ, JJJKJJ\}$ 。

単語  $W$  が誤って  $W'$  になったとする。“類内置換の数には制限を設けないが、類外置換、挿入、脱落の数の和は高々1とする”(条件1)。いま、分類2を用いた類名表記を考え、 $E2.2(W') = (n_1, n_2, n_3, n_4, n_5)$  すると、 $E2.2(W)$  は次のいずれかである。

類内置換と仮定したとき

$$(n_1, n_2, n_3, n_4, n_5).$$

類外置換と仮定したとき

$$(n_1 - 1, n_2 + 1, \dots, n_5), (n_1 - 1, n_2, n_3 + 1, \dots, n_5), \dots,$$

$$(n_1 - 1, n_2, \dots, n_5 + 1),$$

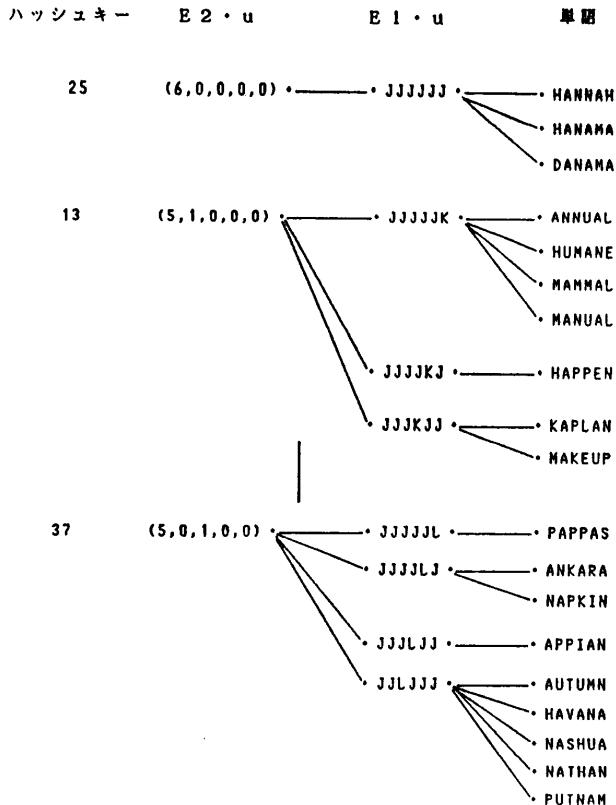


図2 階層化ファイルの一部  
Fig. 2 A part of a hierarchical file.

$$\begin{aligned} & (n_1 + 1, n_2 - 1, n_3, \dots, n_5), (n_1, n_2 - 1, n_3 + 1, \dots, n_5), \\ & \dots, (n_1, n_2 - 1, \dots, n_5 + 1), \\ & \vdots \\ & (n_1 + 1, n_2, \dots, n_5 - 1), (n_1, n_2 + 1, \dots, n_5 - 1), \dots, \\ & (n_1, n_2, \dots, n_4 + 1, n_5 - 1). \end{aligned}$$

(展開2)

挿入と仮定したとき

$$(n_1 - 1, n_2, \dots, n_5), (n_1, n_2 - 1, \dots, n_5), \dots, (n_1, n_2, \dots, n_5 - 1).$$

脱落と仮定したとき

$$(n_1 + 1, n_2, \dots, n_5), (n_1, n_2 + 1, \dots, n_5), \dots, (n_1, n_2, \dots, n_5 + 1).$$

ここで  $n_i - 1 < 0$  ( $i = 1, 2, \dots, 5$ ) のときは、その項がないものとする。たとえば、 $(n_1 - 1, n_2 + 1, \dots, n_5)$  で  $n_1 - 1 < 0$  のときは  $(n_1 - 1, n_2 + 1, \dots, n_5)$  は作らない。検索法1では、ある分類  $T$  を用いるものとし、特にそれを明記しない。

[検索法1]

0.  $E1(W')$  と  $E2(W')$  を作る。

1. ( $W'$  は誤りがないと仮定し, ファイルを検索する)
  - (a)  $E2(W')$  のハッシュ値を計算し, ファイルをアクセスする.  
 $E2(W')$  がファイルにあれば (b)へ.  
 なければ 2. へ.
  - (b)  $E1(W')$  が,  $E2(W')$  を見出しとする第2段の部分辞書  $d(E2(W'))$  にあれば (c)へ.  
 なければ 2. へ.
  - (c)  $W'$  が  $E1(W')$  を見出しとする第3段の部分辞書  $d(E1(W'))$  にあれば,  $W'$  が辞書にあることを表示し, なければ 2. へ.
2. ( $W'$  が辞書にないので,  $W'$  と最も近いものを探す)
  - (a)  $d_{\min} := |W'|$ ,  $S4 := \emptyset$ .  
 ここで,  $|W'|$  は  $W'$  の長さである.
  - (b)  $E2(W')$  から, (条件1)に合うすべての類名表記を発生させる.  
 発生させた類名表記の集合を  $S1$  とする.
  - (c)  $S1$  から類名表記を1つ(それを  $E2_k$  とする)取り出し,  
 $S1 := S1 - \{E2_k\}$   
 とおく.  $E2_k$  のハッシュ値を計算し, ファイルをアクセスする.  $E2_k$  がファイルにあれば, (d)へ. なければ,  $S1 \neq \emptyset$  のとき, (c)へ.  $S1 = \emptyset$  なら, (g)へ.
  - (d)  $E1(W')$  と  $E2_k$  を見出しとする第2段の部分辞書  $d(E2_k)$  にある類名表記  $E1_k$  との距離を計算し,  $D(E1_k, E1(W')) \leq 1$  となる類名表記の集合  $S2$  を作る. (e)へ.
  - (e)  $S2$  から類名表記1を(それを  $E1_k$  とする)を取り出し,  
 $S2 := S2 - \{E1_k\}$ ,  $S3 := d(E1_k)$ ,  
 とおく. (f)へ.
  - (f)  $S3$  から単語を1つ(それを  $W_z$  とする)取り出し,  
 $S3 := S3 - \{W_z\}$   
 として,  $W_z$  から  $W'$  への距離を計算し,  
 $D(W_z, W') < d_{\min}$  なら  
 $d_{\min} := D(W_z, W')$ ,  $S4 := \{W_z\}$ ,  
 とおく,  
 $D(W_z, W') = d_{\min}$  なら  
 $S4 := S4 \cup \{W_z\}$ ,  
 とおく.

$S3 \neq \emptyset$  なら (f)へ.  $S3 = \emptyset$  かつ  $S2 \neq \emptyset$  なら (e)へ.

$S3 = \emptyset$  かつ  $S2 = \emptyset$  かつ  $S1 \neq \emptyset$  なら (c)へ.

(g)  $|S4| = 1$  なら,  $W'$  を  $S4$  にある単語に訂正する.

$|S4| > 1$  なら,  $W'$  を棄却する.

類外置換がないことが明らかであるときは, 2. (b)で(展開2)の類名表記を発生させなくてもよい.

## (2) 検索法2

検索法2は第1種の類名表記を使った階層化ファイル<sup>12)</sup>をハッシュ法でアクセスする. 主記憶に対する負荷を軽くするため, ファイルへのアクセス法は文献13)の方法とは異なる. 操作の高速化を図るため, 第1段の類名表記を数値で表しているのは文献13)と異なる. 分類  $T = \{C_1, C_2, \dots, C_n\}$  とするとき,  $C_i$  を数値  $(i-1)$  で表すと, 類名表記を数値で表現できる. このようにすると, 類名表記を1つのu進法で表すことができ, ハッシュ表にその類名表記があるかどうかを調べるのが1回の比較ですむ. たとえば,  $J, K, L, M, N$  の類名を持つ分類2を用いた1つの類名表記  $KLJML$  を考える. いま, 類名に次のように数字を割り当てる.  $J \rightarrow 0, K \rightarrow 1, L \rightarrow 2, M \rightarrow 3, N \rightarrow 4$ . このとき,  $KLJML$  は12032なる数表現を得るが, これを5進数と見なす. 長さ5の第1種の類名表記の数  $N2(\ell)$  が525であったとすると, ハッシュ値  $h(KLJML)$  は

$$\begin{aligned} h(KLJML) &= ((12032)_5 \bmod 525) \\ &= 892 \bmod 525 \\ &= 369 \end{aligned}$$

となる. ここで  $(12032)_5$  は 12032 が5進数であることを示す. 記述を一般的にするために, 第1段, 第2段で使う分類をそれぞれ  $T_1, T_2$  と書く.  $T_2$  は  $T_1$  の細分類であれば,  $T_1, T_2$  はどのような分類でもよい. いま,  $E1. T_1(W') = A_1 A_2 \cdots A_\ell$  とする. これを数値で表したものを  $IE1. T_1(W')$  と書き,  $(F_1 F_2 \cdots F_\ell)_u$  とする. 添字の  $u$  は,  $F_1 F_2 \cdots F_\ell$  が u進法であることを示す. また,  $T_1$  の類数は u とし, (条件1)の下で考えるものとする.  $IE1. T_1(W')$  から  $IE1. T_1(W)$  を推定すると, 次のいずれかになる.

類内置換と仮定したとき,

$$(F_1 F_2 \cdots F_\ell)_u.$$

類外置換と仮定したとき,

$$(i F_2 \cdots F_\ell)_u (i \neq F_1), (F_1 i F_3 \cdots F_\ell)_u (i \neq F_2), \dots,$$

$$(F_1 F_2 \cdots F_{\ell-1} i)_*(i \neq F_\ell).$$

(条件 3)

(e)  $S_2$  から類名表記を 1 つ (それを  $E_1.T_{2k}$  とする) を取り出し,

$$S2 := S2 - \{E1.T_{2k}\},$$

$$S3 := d(E1. T_{2k}),$$

とおく。

(f), (g)は、検索法 1 と同じ。

類外置換がないことが明らかであるときは、2. (b)で  
(\*3) を発生させなくてもよい。

## [検索法 2]

1.  $E1. T_1(W')$  と  $E1. T_2(W')$  を作る.

1. ( $W'$  は誤りがないと仮定し, ファイルを検索する)

  - $E1. T_1(W')$  のハッシュ値を計算し, ファイルをアクセスする.  $E1. T_1(W')$  がファイルにあれば, (b)へ. なければ 2. へ.
  - $E1. T_2(W')$  が  $E1. T_1(W')$  を見出しつつると第 2 段の部分辞書  $d(E1. T_1(W'))$  にあれば, (c)へ. なければ 2. へ.
  - $W'$  が  $E1. T_2(W')$  を見出しつつする第 3 段の部分辞書  $d(E1. T_2(W'))$  にあれば,  $W'$  が辞書にあることを表示し, なければ 2. へ.

2. ( $W'$  が辞書ないので,  $W'$  と最も近いものを探す)

  - $d_{\min} := |W'|$ ,  $S4 := \emptyset$ .
  - $E1. T_1(W')$  から, (条件 1)に合うすべての類名表記を発生させる. 発生させた類名表記の集合を  $S1$  とする.
  - $S1$  から類名表記を 1 つ (それを  $E1. T_{1k}$  とする) 取り出し,  

$$S1 := S1 - \{E1. T_{1k}\}$$
 とおく.  $E1. T_{1k}$  のハッシュ値を計算し, ファイルをアクセスする.  $E1. T_{1k}$  がファイルにあれば, (d) へ. なければ,  $S1 \neq \emptyset$  のとき (c) へ.  $S1 = \emptyset$  なら (g) へ.
  - $E1. T_2(W')$  と  $E1. T_{1k}$  を見出しつつする第 2 段の部分辞書  $d(E1. T_{1k})$  にある類名表記  $E1. T_{2h}$  との距離を計算し,  $D(E1. T_{2h}, E1. T_2(W')) \leq 1$  となる類名表記の集合  $S2$  を作る. (e) へ.

検索法3は、検索法2でWLDを計算する部分をハミング距離(HD)で置き換えるものである。置換誤りを仮定したときは、WLDをそのままHDで置き換える。挿入誤りを仮定したとき、たとえば、 $E=F_1 \dots F_{i-1} F_i F_{i+1} \dots F_\ell$ がファイルにあったとする。このとき、 $d(E)$ にある1つの類名表記を  $B_1 B_2 \dots B_{\ell-1}$  とすると、 $HD(B_1 B_2 \dots B_{\ell-1}, \tilde{E}1. T_2(W'))$  を計算する。ここで、 $E1. T_2(W') = G_1 G_2 \dots G_\ell$  とするとき、 $\tilde{E}1. T_2(W') = G_1 \dots G_{i-1} G_{i+1} \dots G_\ell$  である。脱落誤りを仮定したとき、たとえば、 $E=F_1 \dots F_i F_j F_{i+1} \dots F_\ell$  がファイルにあつたとする。このとき、 $d(E)$ にある類名表記を  $D_1 D_2 \dots D_{\ell+1}$  とすると、 $HD(D_1 D_2 \dots D_{\ell+1}, \tilde{E}1. T_2(W'))$  を計算する。ここで、 $\tilde{E}1. T_2(W') = G_1 \dots G_i \$ G_{i+1} \dots G_\ell$  である。\$は $\Sigma$ に属さない文字である。

#### (4) 検索法の相違

検索法1と検索法2はファイルの構成法が異なっており、したがって検索の方法も異なっている。検索法3は検索法2と同じファイルを使うが、検索法2がWLDを使って検索するのに対して、検索法3はHDを使って、検索率を落とさずに検索速度を上げることを目指している。検索法は、ファイル構成・変更の容易さ、検索速度、検索率などで評価される。3方法と

表 1 2種類の辞書の語数と類名表記数の分布  
 Table 1 The distributions of words and class name expressions  
 of the two dictionaries.

単語長	辞書 A				辞書 B			
	単語数	第1種類名表記数		第2種類名表記数	単語数	第1種類名表記数		第2種類名表記数
		分類2	分類3	分類2		分類2	分類3	分類2
4	2135	215	23	37	4000	247	28	42
5	3091	668	41	59	10000	959	75	82
6	3782	1679	78	84	30000	3444	154	130
7	4025	2714	144	105	30000	8142	281	172
8	3567	3070	265	120	30000	14790	508	224
計	16600	8346	551	405	104000	27582	1046	650

も、ファイル構成・変更は同程度に容易である。検索速度、検索率などは、実験で比較する。

#### 4. 大型データの発生法

いま、長さ  $m$  の単語の集合（語数  $N_0$ ）から、第  $i$  文字が  $a$ 、第  $(i+1)$  文字が  $b$  であるものの数を調べ、それを  $d_i(a, b)$  とする。 $d_0(\$, a)$  は先頭の文字が  $a$  であるものの語数である。 $d_i(a, b)(i=0, 1, \dots, m)$  を“位置を決めた 2 文字組”(positional-digram) という。

$$\sum_{i=0}^m \sum_{j=1}^{28} \sum_{k=1}^{28} d_i(x_j, x_k) = (m+1) * N_0$$

ここで、 $x_j, x_k \in \Sigma$  である。 $N_0$  個の文字列の発生は、次のようにする。

##### (1) 先頭文字の発生

乱数を 28 個発生させ、それを  $q_1, \dots, q_{28}$  とする。

$$q_j * d_0(\$, x_j) (j=1, 2, \dots, 28)$$

のうち、最大の値をとるもの（それを、 $q_1 * d_0(\$, x_1)$  とする）を選び、 $x_1$  を第 1 文字とする。最大値をとる

表 2 辞書 A を用いた類外置換を認めない場合の検索結果  
Table 2 The results of retrieval for the dictionary A with no outer class substitution.

検索法	誤りの数			検索率 (%)	誤検索率 (%)	棄却率 (%)	検索時間 1 (秒)	検索時間 2 (秒)
	類内置換	挿入	脱落					
検索法 1	1			100.0	0.0	0.0	0.023	0.037
				86.4	0.0	13.6	1.124	1.312
				57.6	3.2	39.2	1.272	1.486
	2	1		97.6	0.0	2.4	1.471	1.697
				88.4	0.4	11.2	1.332	1.551
	1	1	1	49.2	0.0	50.8	0.611	0.700
検索法 2 3 段	1			100.0	0.0	0.0	0.021	0.025
				86.4	0.0	13.6	1.053	1.126
				57.6	3.2	39.2	1.159	1.237
	2	1		97.6	0.0	2.4	1.028	1.110
				88.4	0.4	11.2	1.016	1.105
	1	1	1	49.2	0.0	50.8	0.729	0.772
検索法 2 2 段	1			100.0	0.0	0.0	0.013	0.016
				86.4	0.0	13.6	0.196	0.314
				57.6	3.2	39.2	0.212	0.340
	2	1		97.6	0.0	2.4	0.124	0.332
				88.4	0.4	11.2	0.102	0.316
	1	1	1	49.2	0.0	50.8	0.252	0.311
検索法 3 3 段	1			100.0	0.0	0.0	0.021	0.025
				86.4	0.0	13.6	0.390	0.463
				58.4	3.2	38.4	0.427	0.509
	2	1		97.6	0.0	2.4	0.370	0.439
				90.0	0.4	9.6	0.364	0.438
	1	1	1	49.2	0.0	50.8	0.303	0.343
検索法 3 2 段	1			100.0	0.0	0.0	0.375	0.427
				86.4	0.0	13.6	0.095	0.212
				58.4	3.2	38.4	0.103	0.236
	2	1		97.6	0.0	2.4	0.069	0.277
				90.0	0.4	9.6	0.064	0.269
	1	1	1	49.2	0.0	50.8	0.112	0.182
	1	1	1	16.8	16.0	67.2	0.131	0.219



ものが2つ以上あるときは再試行する。

$$d_0(\$, x_i) := d_0(\$, x_i) - N_0/N_x \text{ とする。}$$

(2) 第  $k$  文字の発生

$\alpha_1\alpha_2\cdots\alpha_{k-1} (k < m)$  が作られたとする。新たに発生した 28 個の乱数を,  $q_1, q_2, \dots, q_{28}$  とする。

$$q_j * d_{k-1}(\alpha_{k-1}, x_i) (j = 1, 2, \dots, 28)$$

のうち、最大の値をとるもの（それを、 $q_i * d_{k-1}(\alpha_{k-1}, x_i)$  とする）を選び、 $x_i$  を第  $k$  文字とする。最大値をとるものが2つ以上あるときは再試行する。

$$d_{k-1}(\alpha_{k-1}, x_i) := d_{k-1}(\alpha_{k-1}, x_i) - N_0/N_x,$$

とする。

実際には、同じ文字列が発生することがあるので、上記の方法では、 $N_x$  個の文字列を作ることができない。そこで、 $N_0/N_x$  の代わりに  $\text{weight} * N_0/N_x$  ( $0 < \text{weight} < 1$ ) を用いた。

この系列の発生法を用いると、 $N_0$  と類似の性質を持つ  $N$  個の系列を発生させることができる。たとえば、1つの類名表記  $E_k$  の下にある単語（あるいは系

表 4 辞書 B を用いた類外置換を認めない場合の検索結果  
Table 4 The results of retrieval for the dictionary B with no outer class substitution.

検索法	誤りの数			検索率 (%)	誤検索率 (%)	棄却率 (%)	検索時間 1 (秒)	検索時間 2 (秒)
	類内置換	挿入	脱落					
検索法 1	1			100.0	0.0	0.0	0.028	0.042
				62.8	0.0	37.2	1.925	1.959
				31.2	8.0	60.8	3.081	3.109
	2	1		88.4	0.0	11.6	4.686	4.724
				63.2	2.4	34.4	4.968	4.985
				28.4	0.0	71.6	1.053	1.101
検索法 2 3段	1		1	4.8	20.0	75.2	1.683	1.744
				100.0	0.0	0.0	0.026	0.026
				62.8	0.0	37.2	1.823	1.845
	2	1		31.2	8.0	60.8	2.759	2.812
				88.4	0.0	11.6	3.136	3.186
				63.2	2.4	34.4	3.296	3.358
検索法 2 2段	1		1	28.4	0.0	71.6	1.125	1.127
				4.8	20.0	75.2	1.825	1.830
				100.0	0.0	0.0	0.015	0.019
	2	1		62.8	0.0	37.2	0.443	0.542
				31.2	8.0	60.8	0.665	0.817
				88.4	0.0	11.6	—	0.640
検索法 3 3段	1	1	1	63.2	2.4	34.4	—	0.663
				28.4	0.0	71.6	0.560	0.623
				4.8	20.0	75.2	0.836	0.923
	2	1		100.0	0.0	0.0	0.026	0.026
				62.8	0.0	37.2	0.572	0.612
				31.6	8.0	60.4	0.851	0.911
検索法 3 2段	1	1	1	88.4	0.0	11.6	0.896	0.980
				64.4	2.4	33.2	0.942	1.037
				28.4	0.0	71.6	0.374	0.385
	2	1		4.8	20.0	75.2	0.582	0.598
				100.0	0.0	0.0	0.015	0.019
				62.8	0.0	37.2	0.181	0.242
	1	1	1	31.6	8.0	60.4	0.265	0.358
				88.4	0.0	11.6	—	0.335
				64.4	2.4	33.2	—	0.359
	1	1	1	28.4	0.0	71.6	0.203	0.230
				4.8	20.0	75.2	0.296	0.336

表 5 辞書 B を用いた類外置換を認めた場合の検索結果  
Table 5 The results of retrieval for the dictionary B with an outer class substitution.

検索法	誤りの数			検索率 (%)	誤検索率 (%)	棄却率 (%)	検索時間 1 (秒)	検索時間 2 (秒)					
	置換		挿入										
	類外	類内											
検索法 1	1	1		100.0	0.0	0.0	0.028	0.042					
				47.2	0.0	52.8	3.242	3.354					
		2		14.4	10.8	74.8	5.696	5.815					
				52.8	0.0	47.2	3.410	3.522					
				18.4	10.0	71.6	5.425	5.618					
	1	1	1	82.8	0.0	17.2	9.468	9.564					
				54.8	2.8	42.4	10.041	10.075					
				17.2	0.0	82.8	1.489	1.549					
				3.6	18.4	78.0	2.384	2.453					
検索法 2 3段	1	1		100.0	0.0	0.0	0.026	0.026					
				47.2	0.0	52.8	2.546	2.582					
		2		14.4	10.8	74.8	4.454	4.506					
				52.8	0.0	47.2	2.668	2.709					
				18.4	10.0	71.6	4.038	4.108					
	1	1	1	82.8	0.0	17.2	5.130	5.224					
				54.8	2.8	42.4	5.478	5.580					
				17.2	0.0	82.8	1.401	1.411					
				3.6	18.4	78.0	2.380	2.390					
検索法 2 2段	1	1		100.0	0.0	0.0	0.014	0.019					
				47.2	0.0	52.8	0.862	0.999					
		2		14.4	10.8	74.8	1.380	1.589					
				52.8	0.0	47.2	0.745	1.038					
				18.4	10.0	71.6	1.266	1.462					
	1	1	1	82.8	0.0	17.2	—	1.064					
				54.8	2.8	42.4	—	1.462					
				17.2	0.0	82.8	0.774	0.854					
				3.6	18.4	78.0	1.171	1.286					
検索法 3 3段	1	1		100.0	0.0	0.0	0.026	0.026					
				47.2	0.0	52.8	0.729	0.769					
		2		14.4	10.8	74.8	1.256	1.328					
				52.8	0.0	47.2	0.756	0.804					
				18.8	10.0	71.2	1.148	1.225					
	1	1	1	82.8	0.0	17.2	1.346	1.474					
				55.2	2.8	42.0	1.447	1.591					
				17.2	0.0	82.8	0.442	0.457					
				3.6	18.4	78.0	0.740	0.764					
検索法 3 2段	1	1		100.0	0.0	0.0	0.014	0.019					
				47.2	0.0	52.8	0.284	0.372					
		2		14.4	10.8	74.8	0.453	0.598					
				52.8	0.0	47.2	0.295	0.396					
				18.8	10.0	71.2	0.411	0.556					
	1	1	1	82.8	0.0	17.2	—	0.538					
				55.2	2.8	42.0	—	0.585					
				17.2	0.0	82.8	0.254	0.293					
				3.6	18.4	78.0	0.391	0.454					

列) の個数を  $|E_s|$  とする。 $|E_s|=s$  となる類名表記の数を  $n(s)$  とする。原集合(元の数  $N_0$ ) の類名表記数分布を  $n(1), n(2), \dots$  と、新しく作った系列集合(元の数  $N$ ) の類名表記数  $n'(1), n'(2), \dots$  がほぼ等しい。

## 5. 実験

### (1) 実験条件

実験に使った辞書は UNIX の OS 下にある約 2.4 万語の辞書のうち長さ 4~8 の単語約 1.66 万語の辞書 A と第 4 章の方法で発生した長さ 4~8 の綴り 10.4 万語の辞書 B の 2 種類である。

両辞書の語数および類名表記分布を表

1 に示す。ここで、分類 3 は次のものである。

#### 分類 3

$$O=J \cup K, P=L \cup M, Q=N$$

実験は類外置換がないと仮定したときは、6 種の誤りパターンと誤りのない場合の 7 つの場合について、類外置換があると仮定したときは 9 つの場合について実験した。誤りのある場合には、各々の場合について、長さ 6 の単語から 250 の誤った綴りを発生させた。使用した計算機は ACOS-600 S で、プログラムは FORTRAN で書いた。

### (2) 実験結果

実験結果を表 2~表 5 に示す。2 段法では、分類 2 を、3 段法では分類 2 と分類 3 を用いた。表で、検索時間 1 は第 1 段を主記憶に置いた場合で、検索時間 2 はすべて補助記憶に記憶した場合である。なお、表 4 および表 5 で、検索法 2 (2 段) で挿入のある場合の検索時間 1 のデータは主記憶容量の制限からとれなかった。

- a) すべての場合について、ファイルを主記憶と補助記憶に分散して記憶した方が、補助記憶にだけ記憶する場合に比べて、検索に要する時間は短い。
- b) 辞書 B の類外置換を認める場合以外は、“類内置換 1 かつ脱落 1” の場合は誤検索率が 16~20 % と高いが、その他の場合は誤検索率が数 % 以下と低い。辞書 B の場合も、検索速度はそれほど落ちなかった。
- c) HL 法で、辞書 A を用いて実験した結果を表 6 に示す。HL 法の検索率は、本論文の方法の検

表 6 HL 法による検索率と検索時間  
Table 6 The correct retrieval rate and the retrieval time by the HL method.

検索法	誤りの数			検索率 (%)	誤検索率 (%)	棄却率 (%)	検索時間 (秒)				
	置換		挿入								
	類外	類内									
HL 法	1	1	1	100.0	0.0	0.0	30.438				
				65.2	19.6	15.2	197.639				
				14.0	48.4	37.6	190.810				
	1	1	1	64.8	16.8	18.4	194.122				
				14.0	57.2	28.8	186.169				
				97.6	2.4	0.0	207.887				
	1	1	1	55.6	23.2	21.2	254.983				
				68.0	20.0	12.0	127.916				
				8.8	53.2	38.0	131.732				

索率と比べて、挿入 1, 脱落 1, 脱落 1+類内置換 1 の場合には高く、他の場合には低い。また HL 法はすべての場合について誤検索率が高い。棄却されるときは、すべての訂正候補を表示して検索者に選ばせることができるが、誤検索ではそれができないので、誤検索率が高いのは好ましくない。検索時間は、誤りのないキーの場合、本論文の方法が 320~1800 倍近く、誤りのあるキーでは 70~520 倍速い。

## 6. むすび

誤ったキーでも検索できる階層的ファイルを用いた検索法を 3 つ提案し、実験してその有効性を確かめた。実験は、類外置換、挿入、脱落誤りが一語中高々 1 つであるとの制限の下に、長さ 4~8 の 1.66 万語の辞書を用いて行い、これまで知られていた唯一の方法 (HL 法) と比べ、はるかに高速である。8 つの誤りパターンのうち、5 つの場合で、提案した方法は HL 法より検索率が高く、すべての場合について、誤検索率が小さい。長さ 4~8 の 10.4 万語についての実験でも、検索速度はそれほど落ちなかった。

これらの方針に、統計的情報をファイルの構成に用いて高速化を図ったり、誤訂正率を上げないで検索率を高めること、また、単語検索では造語規則を用いて検索率を高めること等は、今後の問題である。さらに、文脈依存類似度<sup>17)</sup>が有用な問題に対するファイルの構成法も残された問題である。

## 参考文献

- 1) 伊藤：情報検索，昭晃堂（1986）。
- 2) Bayer, R. and McCreight, E.: Organization and Maintenance of Large Ordered Indexes, *Acta Inf.*, Vol. 1, pp. 173-189 (1972).
- 3) Hall, P. A. V. and Dowling, G. R.: Approximate String Matching, *Comput. Surv.*, Vol. 12, No. 4, pp. 381-402 (1980).
- 4) 伊藤, 木沢：階層化ファイルによるつづり誤りの訂正, 電子通信学会論文誌, Vol. J56-D, No. 8, pp. 1090-1091 (1982).
- 5) Ito, T. and Kizawa, M.: Hierarchical File Organization and Its Application to Similar-String Matching, *ACM Trans. Database Syst.*, Vol. 8, No. 3, pp. 410-433 (1983).
- 6) Peterson, J. L.: Computer Programs for Detecting and Correcting Spelling Errors, *CACM*, Vol. 23, No. 12, pp. 676-687 (1980).
- 7) 川合：英文綴り検査法, 情報処理, Vol. 24, No. 4, pp. 507-513 (1983).
- 8) 伊藤：英文つづり誤り訂正法, 情報処理, Vol. 25, No. 5, pp. 471-479 (1984).
- 9) 栗田, 相沢：日本語に適した単語の誤入力訂正法とその大語彙単語認識への応用, 情報処理学会論文誌, Vol. 25, No. 5, pp. 831-841 (1984).
- 10) 田中, 小橋口, 島村：綴りの置換誤りの高速訂正法, 情報処理学会論文誌, Vol. 27, No. 2, pp. 177-182 (1986).
- 11) Tanaka, E., Toyama, T. and Kawai, S.: High Speed Error Correction of Phoneme Sequence, *Pattern Recogn.*, Vol. 16, No. 5, pp. 407-412 (1986).
- 12) Tanaka, E. and Kojima, Y.: A High Speed String Correction Method Using a Hierarchical File, *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol. PAMI-9, No. 6, pp. 806-815 (1987).
- 13) 田中, 古河原：系列の高速訂正法, 情報処理学会文書処理とヒューマンインターフェース研究会, 15-1 (1987).
- 14) Tanaka, E. and Kogawara, A.: High Speed String Edit Methods Using Hierarchical Files and Hashing Techniques, *The 9th Int. Conf. Pattern Recogn.*, Rome, pp. 334-336 (1988).
- 15) Okuda, T., Tanaka, E. and Kasai, T.: A Method for the Correction of Garbled Words Based on the Levenshtein Metric, *IEEE Trans. Comput.*, Vol. C-25, No. 2, pp. 172-178 (1976).
- 16) 荒川：オンライン文字認識に関する研究, 北海道大学学位論文 (1981).

17) 田中：系列の文脈依存類似度, 電子通信学会論文誌, Vol. J67-A, No. 6, pp. 612-613 (1984).

(昭和 63 年 12 月 28 日受付)  
(平成元年 9 月 12 日採録)

## 沼倉 覚



昭和 38 年生。昭和 62 年 3 月宇都宮大学工学部情報工学科卒業。平成元年 3 月同大学院工学研究科情報工学専攻修了。同年 4 月リコー応用電子研究所(株)に入社。現在、情報システムに関する研究開発に従事。電子情報通信学会会員。

## 田中 栄一 (正会員)



昭和 37 年 3 月大阪府立大学工学部電気工学科卒業。昭和 43 年 1 月大阪大学大学院工学研究科博士課程通信工学専攻修了。工学博士。昭和 42 年 4 月大阪府立大学工学部電気工学科に勤務。昭和 52 年 4 月宇都宮大学工学部情報工学科教授。現在に至る。昭和 49~51 年パデュー大学客員研究員。言語認識およびパターン認識に関するアルゴリズムの研究に従事。

## 青木 晴海



昭和 40 年生。昭和 63 年 3 月宇都宮大学工学部情報工学科卒業。同年

3 月富士重工業(株)に入社。宇都宮製作所航空機工場電算機課に所属。

工場内システムの開発、ソフトウェアの調査、テスト等に従事。

## 矢野目 輪



昭和 41 年生。昭和 63 年 3 月宇都宮大学工学部情報工学科卒業。同年

4 月シャープ(株)入社。電子機器事業本部に勤務し、映像機器のファームウェア設計に従事。

## 矢吹 勉



昭和 39 年生。昭和 63 年 3 月宇都宮大学工学部情報工学科卒業。同年

4 月富士通(株)入社。以来、POS システムの開発に従事。