

キー概念に基づく情報検索システム方式の高度化(2) —キーワードの同表記異義の処理—

3 V - 5

藤崎 博也 大野 澄雄 阿部 賢司 片見 勝次 飯島 岐勇 鈴木 匡芳

東京理科大学

1. はじめに

キーワードによる従来の情報検索では、表記のみに着目して処理するため、異表記同義の存在による検索洩れや、同表記異義の存在による不要な検索が避けられない。これらを避けるには、キー概念のレベルにまで遡った検索が必要であるが[1]～[4]、異表記同義への対処の方法は既に提案した[5]。本報では、キーワードの同表記異義の例を収集・分析・分類し、その処理の方法について検討した結果を述べる。

2. 情報検索における異表記同義・同表記異義

本報では、1つの語は、1つの表記と1つの概念から構成されるものと考える。ここで語の表記とは、文字言語の場合には文字を、音声言語の場合には音声を意味するものとする。ただし、ここでは、文字言語の場合について議論する。

従来のキーワード検索では、語の表記のみに着目するため、キーワードに異表記同義が存在する場合には検索洩れが生じる(図1(a))。また、キーワードに同表記異義が存在する場合には不要な検索が生じる(図1(b))。




図1. 異表記同義・同表記異義が存在する場合の表記と概念との関係

3. 同表記異義の例の収集・分析・分類

キー概念に基づく検索方式を具体化するため、学術情報センター(<http://els.nacsis.ac.jp/nacsis-els-j.html>)

An advanced information retrieval system based on key concepts (2)
—Processing of polysemy in keywords—
Hiroya Fujisaki, Sumio Ohno, Kenji Abe, Kenji Katami, Michio Iijima
and Masayoshi Suzuki
Science University of Tokyo, 2641 Yamazaki, Noda, 278-8501

に公開されているデータベース5425件(1998年1月現在、以下データと記す)における同表記異義の例を収集し、以下のように分析・分類した。

3.1 収集

データ中の全論文のキーワードと、全論文のタイトルに使われている名詞を収集した。そのうち、概念が複数存在するものを同表記異義とし、その判断はEDRの概念辞書によって行った。

キーワードの中で同表記異義を持つものは168語、出現回数は延べ860回、タイトルの中の名詞では1364語、出現回数は延べ18445回存在した。

収集した同表記異義の概念を比較した結果、下記の例のように、概念は微妙に異なっているが、実際の検索においては問題にならないような同表記異義は省いた。

例. 電子メール

- ・電気通信的手段で送られる郵便
- ・郵便で送るような情報を電気通信的手段で送るサービス

3.2 分析・分類

検索の際に問題となる同表記異義は、表記上で4種類に分類できる。以下にそれぞれの例を示す。

(1) 略語・記号

例. SAR

- ・supervisor analysis router
- ・storage address register

(2) 英単語

例. permutation

- ・順列
- ・置換

(3) 外来語

例. グラフ

- ・関連する2つ又は2つ以上のものの数量や、関数関係をあらわした“図形”
- ・写真を中心とした“雑誌”

(4) 漢字・かな

例. 米

・植物の“コメ”

・“アメリカ”という国

・長さの国際単位系基本単位“メートル”

表1にキーワード中の同表記異義の語数と、タイトル中の同表記異義の語数を示す。また、括弧内の数字は出現回数を表す。

表1 同表記異義の分類結果

	キーワード中の 同表記異義の 語数(回数)	タイトル中の 同表記異義の 語数(回数)
(1) 略語・記号	21(79)	38(1662)
(2) 英単語	2(6)	4(14)
(3) 外来語	23(71)	203(2210)
(4) 漢字・かな	9(22)	523(7775)
合計	55(178)	588(11651)

4. 同表記異義の簡単な処理方法とその効果

4.1 処理方法

同表記異義の処理方法として、以下のように検討した。

(1) データ内の非省略形の言葉の利用

略語に関してデータ内に非省略形の表記がある場合には、それをを利用して特定できる。

例. … the specific absorption rate (SAR) …

(2) 英語表記の利用

日本語では同表記異義を持つ語でも、英語が併記されており、英語で異表記であれば特定できる。

例. 米→rice

(3) 前後の単語を繋げる

キーワードでは切られて短い単語になったことが原因で、同表記異義になっている場合がある。切られる前の長い単語に戻して、どの意味で使用されていたかを調べることにより特定できる。

例. グラフ→無向グラフ

4.2 処理結果

前節の方法で収集した、同表記異義を持つキーワードについて、上記の方法により特定可能となるもの

を表2に示す。ここで特定可能率は、キーワード中の同表記異義の出現回数に対する、特定可能な同表記異義の出現回数の割合である。

表2 処理結果

	キーワード中 の同表記異義 の出現回数	特定可能な 同表記異義 の出現回数	特定 可能率 [%]
(1) 略語・記号	79	48	60.8
(2) 英単語	6	3	50.0
(3) 外来語	71	29	40.8
(4) 漢字・かな	22	8	36.4
合計	178	88	49.4

簡単な処理を行うことにより、表2から、問題となる同表記異義をもつキーワードの約半分が特定可能である。なお、上記の方法で特定不可能なものに関しては、語の共起に関する情報の利用が考えられ、現在検討中である。

5. おわりに

本報では、キー概念検索方式を具体化することを目的とし、同表記異義の実例を収集・分析・分類し、それを処理するための方法を検討した。

参考文献

- [1] 藤崎博也, 龜田弘之, 河井恒: “新聞記事情報の階層構造に基づく記事分類・検索システム,” 情報処理学会「自然言語処理」研究会資料 44-4 (1984).
- [2] 藤崎博也, 龜田弘之, 田島研, 大野澄雄: “対話による高度情報検索システムの構築,” 言語処理学会第3回年次大会発表論文集, pp. 261-264 (1997).
- [3] 藤崎博也, 大野澄雄, 伊東卓哉, 阿部賢司, 佐久間聖二, 龜田弘之: “知的エージェントを用いるインターネット上の情報検索システム,” 電子情報通信学会総合大会講演論文集, p. 186 (1997).
- [4] H. Fujisaki, H. Kameda, S. Ohno, T. Ito, K. Tajima and K. Abe : “An intelligent system for information retrieval over the internet through spoken dialogue,” Proceeding of Eurospeech'97, vol. 3, pp. 1675-1678 (1997).
- [5] 藤崎博也, 龜田弘之, 大野澄雄, 阿部賢司, 劉軒, 戸井田和重, 八杉大輔: “キー概念に基づく情報検索システム方式の高度化(1) -キーワードの異表記同義の処理-,” 情報処理学会第56回全国大会講演論文集, vol.3, pp. 128-129 (1998).