

検索対象テキストDB自動決定法の検討

1C-10

田中智博 松尾比呂志 木本晴夫

NTT情報通信網研究所

1. はじめに

近年、様々な分野の文書が電子化され、様々なDBが利用できる環境になりつつあるが、どのDBを検索するかは、利用者が各々のDBの概要、あるいは、分野名を参考に決定しているのが現状である。しかし、対象とするDBの種類が多くなれば、DB選択に多大の労力が必要となる。そこで、我々は、各々のDBの内容を圧縮した情報を、DB決定用知識としてもたせ、これを用いて、検索要求文（「自動車を大量に輸出した年は？」などのような1文）から自動的にDBを決定する方法を検討した。

2. 基本的な考え方

・DB決定法

各テキストDBと、その内容を圧縮した情報（DB内容と呼ぶ）との対応関係を記述したDB決定用知識をあらかじめ作成しておき、検索要求文から抽出された情報と、DB内容との照合を行うことにより、テキストDBを決定する。

・DB決定用知識

新規DBの追加にも容易に対処できるように、各テキストDB内の文書群から、自動的にDB内容を抽出して作成する。

・照合用情報

文書および検索要求文から抽出する情報としては、自立語（名詞、用言）、KWとなる単語（從来より用いられているKWの自動抽出手法（例えば[1]など）による）の2つの場合について、DB決定用知識側、検索要求文側のそれぞれに適用し評価を行う。

・シソーラスの利用

シソーラスは、検索や分類において有効であるとの報告（例えば、[2], [3]など）がなされており、ここでもシソーラスを利用する。具体的には、文献[2]で用いられている意味属性体系（一種のシソーラス）を使用し、単語を意味属性に変換して使用することとする。この体系は、一般名詞に対して約2,800、固有名詞に対して約130の意味属性を設定している。なお、1単語に対して複数の意味が考えられる場合には、考えられる複数の意味属性を付与し、用言に対しても用言性名詞と同様な意味属性を付与してある。

3. DB決定手法

上記の考え方を基に検討を進めているテキストDB自動決定の処理構成を図1に示す。

3.1 DB決定用知識作成

各テキストDBごとに、文書群中の文書から、単語を抽出する。単語の抽出方法としては、文献[1]に述べられているKW抽出処理（並立表現語、連体修飾語、不要語

An Automatic Database Selection Method
for Information Retrieval

Tomohiro TANAKA, Hiroshi MATSUO,
Haruo KIMOTO

NTT Network Information Systems Laboratories

などの処理）と、単に形態素解析により、自立語のみを抽出する方法の2つを用意する。抽出された単語に対して意味属性を付与し、テキストDBごとに各意味属性の出現頻度をカウントする。なお、単語に複数の意味属性が付与される場合には、それら全てをカウントする。そして、全てのテキストDBに対して、意味属性の出現頻度がカウントされた時点での各意味属性ごとに、各テキストDBに対する出現頻度を得点に変換し、DB決定用知識とする。すなわち、ここでのDB決定用知識は、各テキストDBに対する得点が記述された意味属性の集合となる。DB決定用知識の一例を図1に示す。




図1 DB自動決定処理構成

頻度から得点への変換式としては、文献[2]で示されている次式を用いた。

$$Y_{jk} = (F_{jk} - M_{jk}) * F_{jk} - M_{jk} / M_{jk}$$

$$M_{jk} = (\sum_{j=1}^n F_{jk} / \sum_{j=1}^n \sum_{k=1}^m F_{jk}) * \sum_{k=1}^m F_{jk}$$

ここで、 Y_{jk} は、意味属性 j のテキストDB k における得点、 F_{jk} は、意味属性 j のテキストDB k における頻度、 M_{jk} は、意味属性 j がDB k に依存せずにランダムに出現した場合のテキストDB k における頻度（理論度数）、 m はテキストDB数、 n は意味属性の異なり数（約2,930）を表す。

この式により、得点が、 $F_{jk} - M_{jk} > 0$ （ランダムに出現する以上の頻度で出現している）場合には高く、 $F_{jk} - M_{jk} \leq 0$ （ランダムに出現する以上の頻度で出現していない）場合には低くなるように計算される。

例えば、図1の意味属性【乗物】の場合、DB4の得点が他のDBの得点に比べて高くなっていること、検索要求文中にこの意味属性が出現した場合、DBをDB4と特定すべき手掛かりとなることを示している。

3.2 検索要求文解析

DB決定用知識作成同様、KW抽出処理、自立語抽出処理の2つを行い、抽出された単語に対して意味属性を

付与する。

3.3 DB決定

検索要求文から得られた意味属性に対して、DB決定用知識から各DBに対する得点を付与し、検索要求文全体における全ての意味属性の得点を各テキストDBごとに合計する。1単語に対して複数の意味属性が付与されている場合は、その単語に付与された意味属性の得点の平均を求め、その単語の意味属性の得点とする。

検索要求文全体について得られた各テキストDBの正の値を持つ得点中もっとも大きいもので、各テキストDBの正の値を持つ得点を割り、その検索要求文に対する各テキストDBの正の値を持つ得点が0~1の範囲で分布するようにする。なお、負の得点を持つDBは、除外する。

結果出力においては、0~1の間で足切り値を設定し、その値以上の得点をもつ全てのテキストDBを、適合するテキストDBとして出力する。

例えば、図1に示すDB決定用知識を用いて計算すると、検索要求文から得られた意味属性が【住居】【乗物】【機械】（【乗物】と【機械】は1単語から得られた）であった場合、1単語から得られた【乗物】と【機械】の得点を平均化した得点(0.3 -0.2 -5.1 2.5)と、【住居】から得られた得点を合計して得点(2.8 1.1 -34.7 3.3)が得られ、各DBの正の値を持つ得点中最も大きな値で、各DBの値を割って、(0.85 0.29 --- 1.00)が得られる。ここで足切り値として0.8が設定されれば、適合するDBとしてDB4、DB1を出力する。

4. 評価・考察

4.1 評価実験

新聞の分野をそれぞれ独立したテキストDBと考え、新聞記事（1992年分）の7分野（科学、経済、社会、スポーツ、政治、文化、事件）からランダムに抽出した各200記事（1記事約200文程度）を対象テキストDBとし、約40名の男女（20~40歳）により作成した検索要求文（66文）を用いて実験を行った。検索要求文に対して、作成した人及び、作成した人以外の3名により適合すると思われるDBを決定してもらい（複数DBの決定を許す）、2名以上が決定したDBを正解DBとした。表2に示す条件に対して、足切り値を0.5~1.0まで0.05刻みで設定し、以下に示す再現率と適合率を求めた。

$$\text{再現率} = (\text{RETrel}/\text{rel}) * 100, \text{適合率} = (\text{RETrel}/\text{REL}) * 100$$

RETrel=システムが抽出した正解のDB数、

rel=正解のDB数、REL=システムが抽出したDB数。

実験結果を図2に示す。

4.2 考察

条件3（DB決定用知識側がKW抽出、検索要求文解析側が自立語抽出）のとき、精度が良くなっている。これは、文書群を対象としたKW抽出の場合、語の絞り込みにより、不要な語が削除され、比較的文書群に特異な語を抽出できているが、文を対象としたKW抽出の場合には、元の語数が少ないために、必要な情報まで削除しているためである。




図2 評価実験結果

条件3において、失敗している主な原因とその対策について以下に述べる。

・検索要求文から、自立語のみを抽出しているために、不要な（DB決定において負の作用を及ぼす）単語を抽出していることに起因する失敗。例えば、検索要求文「人工衛星の軍事以外の利用を知りたい。」（正解DBとしては、科学となるが、単語「軍事：意味属性【軍事】」の影響により、「政治」を出力している。）

検索要求文において単に自立語全てを抽出するのではなく、単語間の論理関係（上記の例では、NOTの関係）等を考慮して、抽出する単語を選定する必要がある。

・1単語に複数の意味属性が付与されている場合、得点計算において、単に平均をとっていることに起因する失敗。例えば検索要求文「自動車の輸出について知りたい。」（正解DB：経済）の場合、「自動車」の意味属性として【車】（得点の高いDBは経済、事件）、【スポーツ】（得点の高いDBはスポーツ）の2つが付与されており、平均をとると得点の高いDBがスポーツとなる。

意味属性を付与する際に、構文構造等の情報を基づいて、付与する意味属性の絞り込みを行う必要がある。

5. おわりに

本報告では、テキストDB自動決定手法の検討として、DBごとにDB決定用知識を作成し、意味属性の頻度情報に基づく手法の評価を試みた。その結果、DB決定用知識作成側では、DB中の文書群からKWを抽出し、検索要求文側では、自立語全てを抽出する方法が、有効であることが分かった。今後は、検索要求文から、DB決定に有効な単語の抽出を行う方法、意味属性を付与する際の絞り込みの方法を検討するとともに、DB側の汎用性を考慮しながら、頻度情報以外の情報によりDBを決定する手法についても検討を行う。

参考文献

- [1] 木本：「日本語新聞記事からのキーワード自動抽出と重要度評価」、信学会論文誌Vol.J74-D-I No.8 (1991)
- [2] 河合：「意味属性の学習結果にもとづく文書自動分類方式」、情処学会論文誌Vol.33 No.9 (1992)
- [3] 松尾、内野：「意味属性に基づくテキストベース検索方式」、情処学会論文誌Vol.32 No.9 (1991)