

1. はじめに

近年、日々増加する膨大な情報源の中から必要な情報をすばやく見つけることが困難になってきている。そのため多くの検索エンジンには、必要な情報をすばやく見つけるために多くの工夫がされている。それらは、キーワードを含む文を提示したり、2次キーワードを用いて検索結果を絞り込んだりするものである。確かに、キーワード情報は情報検索をする上でユーザに大変有益な情報を与える。しかし、低品質な情報があふれている web ページの検索ではあまり参考にならないことも多い。あるキーワードが含まれているからといって必ずしもそれに関連した内容のページであるとは限らない。そこで、web ページに書かれている内容をキーワードに関連のある情報とともに提示できれば、より効率のよい検索ができると考えられる。本稿では、web ページの内容を解析してページの主題を推定する手法について述べる。

2. 概要

web ページは、複数の話題について書かれていることが多いため、本手法ではページを表示上のまとまりに分割して¹、それぞれのまとまりに対して個別に内容の解析を行う。ページの分割には HTML タグを利用する。各まとまりに見出しが付いているものもあるが、文字サイズ拡大など別の目的のために使われていることがあるなど、必ずしもそれがそのまとまりを正しく表しているわけではないので、見出しを直接抜き出して主題とするのは不適切な場合がある。そこで、単語の出現頻度と助詞などの表層情報を用いて重要個所を求め^{2,5}、それを見出しのように表示上強調されている個所と比べ、内容的にふさわしい方をページ中の各まとまりの主題とする。最後にそれぞれのまとまりの主題を統合してページ全体の主題とする。

3. 提案手法

3.1 ページの分割

web ページは大きく分けるとテキスト、見出し、図、表、リンクの5種類を組み合わせると考えられる。

とができる。本手法では<table>、<map>等の HTML タグを用いてページをこの5種類の要素に分割する。この時、見出し要素は直後の要素に付けられたものと考えられるので直後の要素と統合して1つの要素と考え、その要素の主題を推定するのに利用する。

3.2 テキスト要素の主題推定

ここでは、テキスト要素の主題の推定方法について述べる。まず始めにテキスト中に現れる名詞の出現頻度を求める。次に各名詞の上位概念の出現頻度を各名詞の出現頻度と単語間の類似度³を考慮して求める。そして、各名詞の上位概念の出現頻度と助詞などの表層情報をもとにテキスト要素中の名詞句の評価値^{2,5}を求め、最も評価値の高い名詞句を抜き出す。最後に、テキスト要素に見出しが付いていればその見出しと抽出された名詞句との類似度を求め、類似していたら見出しを、類似していなかったら抽出した名詞句をテキスト要素の主題とする。

3.2.1 テキスト要素の名詞の出現頻度

形態素解析器「Chasen」⁴を用いてテキストを形態素解析して、テキストに含まれる名詞のうち接頭詞や接尾詞のようにそれ自体では意味をなさない名詞と「人」、「もの」のように抽象度が高い名詞を除く全ての名詞の出現頻度を求める。

3.2.2 テキスト要素の名詞の上概念の出現頻度

EDRのシソーラス辞書(tree 構造)を用いて3.2.1で求めた全ての名詞(葉)からのノードの距離が2以下の上位概念を求める。そして、次式を用いて、求めた全ての上位概念 j の出現頻度 c_j を計算する。

$$w_{ij} = \frac{d_j}{d_i + d_j} \quad (1)$$

$$c_j = \sum_{i=1}^N w_{ij} n_i \quad (2)$$

ここで、 d_i 、 d_j は、名詞 i の root からの距離、上位概念 j の root からの距離である。また、 N は、テキスト中の名詞の種類数、 n_i は名詞 i の出現頻度である。なお、(1)で各名詞

†名古屋大学大学院工学研究科

‡愛知県立大学情報科学部

