

可変スニペットとキーワード相関グラフを利用した検索補助インターフェースの提案

上條 朋彦[†] 小山 聰[†] 栗原 正仁[†]

北海道大学大学院 情報科学研究科[†]

1. はじめに

1.1 背景

近年、WEB ページ総数の爆発的増加が進んでいる。すでにその数は 80 億を超える。現在もなお増加し続けている。もはや人手による分類・利用は不可能であり、WWW からユーザーの目的に応じた情報抽出・情報検索を行う研究が数多くなされてきた。中でも現在、最も普及し利用されているサービスが、Google や Yahoo! に代表される検索エンジンである。これらは PageRank や HITS などのランクイングアルゴリズムを応用したもので、キーワードに関連するページを抽出する事に優れる。

しかし、現在の検索エンジンにも問題点が残されている。ランクイングアルゴリズムの特性もあり、ユーザーごとの微妙な目的の違いはさほど加味されず、一般的に著名なサイトを上位にランクインする傾向が強い。また、目的の情報に辿り着かない場合、ユーザーは検索ワードを修正して試行錯誤を行うが、使用経験の浅いユーザーにとっては試行錯誤する事自体が難しいといった問題がある。

1.2 検索エンジンのパーソナライズ

現状の検索エンジンの問題点を解決するため、検索エンジンのパーソナライズを目的とした研究が行われ始めた。検索結果の再ランクイング手法やスニペット（検索結果に表示される要約文）のクラスタリング[2]や最適化[3]、検索ワード操作支援[4]など様々なアプローチの研究が進められている。すでに稼動しているサービスもあり、Google パーソナライズ検索ツール各種や Google ウェブ履歴、Yahoo! Rerank などが存在する。

本研究では現状の検索エンジンの問題点に対して、特に以下の 2 点に着眼し、これを実現する検索補助インターフェースの提案を目指す。

A User Interface for Search Engines with Variable-Length Snippets and Keyword-Relation Graphs

[†]Tomohiko KAMIJO, Satoshi OYAMA, Masahito KURIHARA, Graduate School of Information Science and Technology, Hokkaido University

- ・リンク先を判断するための重要な要素であるスニペットは、検索毎・目的毎の興味の度合いに応じて、固定長ではなくユーザが操作可能な可変長である必要性
- ・検索エンジンとユーザの目的との間で齟齬が発生した場合、即座にそれを理解し検索ワードを修正できる視覚的情報掲示の必要性

2. 提案インターフェース

インターフェース構築の共通処理を説明する。

- (1) ユーザが入力するキーワードの検索結果上位 N 件を検索エンジンから取得する。
- (2) N 件のリンク先の文書の中身を取得し、HTML タグやスクリプトを除去した本文 d の集合 D を作成する。
- (3) 各本文を形態素解析し、重要語となりやすい名詞・形容詞・形容動詞を抽出して単語集合 W を作成する。
- (4) W の各単語の TF・IDF を算出する。文書 $d(\in D)$ 中の単語 $w(\in W)$ の TF・IDF は以下の式で表される。ただし $f_{w,d}$ は文書 d 中の単語 w の出現回数、 $n_{w,d}$ は文書 d 中の総単語数、 DF_w は単語 w の出現する文書数 ($\leq N$) である

$$TF \cdot IDF_{w,d} = \frac{f_{w,d}}{n_{w,d}} \cdot \log_2 \frac{N}{DF_w} \quad (1)$$

2.1 可変スニペットインターフェースの構築

- (1) 文書 $d(\in D)$ 内のテキストを 1 文ごとに分割し、文集合 S_d を作成する。
- (2) 文書 $d(\in D)$ 中の各文 $s(\in S_d)$ に対して、以下のスコアを与える

$$SCORE_{d,s} = \sum_{w \in s} f_{w,s} \cdot TF \cdot IDF_{w,d} \quad (2)$$

$f_{w,s}$ は、文 s 中の単語 w の出現回数である。

スコアの高い文 s から順にスニペットに追加していく事で可変スニペットを生成する。

2.2 キーワード相関グラフ部の構築

共通処理で算出済の文書 d 中の単語 w における TF・IDF 値を降順にソートしたものを特徴語集合とし、これを用いてキーワード相関グラフを生成する。

キーワード相関グラフの生成手順

- (1) グラフ G に N 個のノードを追加する。(これらを親ノードとする)
- (2) 各親ノードに、特徴語集合から m 個の単語ノードを追加する。 $(m$ はパラメータ)
- (3) 追加した m 個の単語ノードと親ノード間のエッジを作成する。単語ノードが他の親ノードに追加済であった場合、エッジのみを繋ぐ。
- (4) グラフ G を適切なグラフレイアウト手法で表示する

実装段階では $m = 20$ 、グラフレイアウトには KK 法[1]を使用している。

3. 実装実験

計算機上に提案インターフェースの実装を行った。実装には Java 言語を使用し、形態素解析器 sen、グラフ表示ライブラリ Jung を用いている。実際の動作画面は図 1, 2 のようになる。(検索ワード「北海道大学」, $N = 10$ の場合)




図 1. 可変スニペット部

可変スニペット部(図 1)では、ユーザがスクロールバーを調整することによりスニペットの長さを調節可能となっている。ユーザの興味の度合いに応じて情報を効率的に得る事が出来る。可変スニペットの表示内容も従来型とは異なる性質を持ち、リンク先全体を要約した内容を含んでいるため、ユーザはリンク先を開く前に目的情報と一致しているかを把握しやすい。図 1 の実装ではスニペット操作部にスクロールバーを採用したが、マウスホイールやマウスオーバーなどの様々な実装法が考えられ、場面に応じた表示が可能である。




図 2. キーワード相関グラフ部

キーワード相関グラフ部(図 2)は、検索結果 1 件 1 件を表す親ノード(赤)の周辺に、内容を端的に表す単語ノード(灰)が配置される形となる。KK 法によるグラフ配置により、関連語は距離的に近傍に配置され、多くの文書の共通重要単語(ピンク)ほど多くのエッジに繋がれ強調される。また、単語ノードをクリックする事で対応する単語を即座に AND 検索に追加でき、検索ワードの修正支援にも繋がる。その他、マウスホイールによる拡大縮小機能も備えており、検索結果の直観的理解と検索ワード修正を支援する。

4. まとめ

検索エンジンの検索結果に対するパーソナライズ手法として、可変スニペットとキーワード相関グラフを用いた検索補助インターフェースモデルを提案し、計算機上へ実装を行った。今後の課題としては、インターフェース全体の適切な性能評価がある。本研究の応用として、Web 検索エンジンだけでなくオフラインのドキュメント検索にも適用可能である。

参考文献

- [1] T. Kamada and S. Kawai. "An Algorithm for Drawing General Undirected Graphs", Information Processing Letters, 31, 7-15, 1989.
- [2] Ferragina, P. and Gulli, A. 2005. A personalized search engine based on web-snippet hierarchical clustering. In Special interest Tracks and Posters of the 14th international Conference on World Wide Web (Chiba, Japan, May 10 - 14, 2005). WWW '05. ACM, New York, NY, 801-810.
- [3] 高見真也・田中克己. 検索目的に基づくスニペットの動的再生成によるウェブ検索結果の個人適応化. 信学技報, vol. 107, no. 131, DE2007-69, pp. 283-288, 2007. 7.
- [4] 吉田 大我, 小山 聰, 中村 聰史, 田中 克己, Web 検索結果におけるキーワード出現相関の可視化と対話的な質問変換, DEWS2007, c7-2, 2007. 3.