

研究指導 中澤 真 助教授

ブックマーク情報を利用した 個人の嗜好に対応する検索システム

佐藤 来未

1. はじめに

豊富な情報量を誇るインターネットの浸透は、人々の情報検索・収集の手段を大きく変えつつある。その影響もあり、2004年のWebページ数は150億ページという膨大な数を記録し、2006年の時点で330億以上のWebページが存在していると推測されている[1]。このことは、情報を探し求めているユーザにとって手に入る情報量が増えるという利点があるが、同時に欲しい情報が見つかりにくくなるという欠点もある。この問題に対し、Google社はユーザによって異なる検索結果を出力する新サービス「Googleパーソナライズ¹検索」を開始した。これはユーザの閲覧履歴を利用してユーザプロフィールを生成し、その情報を基にユーザにとって有用であるだろうWebページを推薦するサービスである。しかし、閲覧履歴が蓄積されるまで検索結果に反映されず、ユーザにとって興味のないWebページが閲覧履歴として残り、ユーザプロフィールに組み込まれる可能性がある。そうすると、ユーザにとって興味のないWebページが検索結果に反映されてしまい、システムの意味を成さなくなってしまう。

よって本研究では、ユーザにとって興味のない嗜好情報を反映させないことで精度を高めたユーザプロフィール生成方法および、生成したユーザプロフィールを情報検索に対応させるモデルを提案する。なお、ユーザの強い嗜好を示している情報として、個人の記録するブックマークを利用する。

2. パーソナライズ検索システムの現状と問題点

今までの検索エンジンは、どのようなユーザが検索しても出力される検索結果は同一であるのが一般的であった。Web上の情報量が増えてきていることも背景とされるが、これに対しGoogle社は2005年11月に日本語の「Googleパーソナライズ検索²」の提供を開始した。こ

れは無料で提供されているサービスであり、Googleアカウントを取得すれば誰もが利用可能である。主な特徴は、過去の閲覧履歴からユーザの嗜好を学習し、そのユーザにとって重要なWebページを検索結果の上位に反映させるというものである。しかし、閲覧履歴が蓄積されて検索結果に反映されるまで時間がかかるということ、閲覧したWebページがユーザの興味のないものでも、それは閲覧履歴に記録され、検索結果に影響してしまうということが挙げられる。後者においての原因は次のような可能性が考えられる。

(i) ユーザが誤って興味のないWebページを閲覧してしまう。

(ii) 閲覧してみたが、さほど興味のない内容だった。

このことから、閲覧履歴を用いる手法では、少なからずユーザの嗜好に合わない情報が組み込まれ、検索結果に反映される。それには、ユーザプロフィールの生成方法が重要となってくる。

2.1 ユーザプロフィール技術

ユーザの嗜好に合った情報を提供するためには、対象となる情報に対してユーザがどの程度興味を持つか判断しなくてはならない。そのために、ユーザプロフィールを生成することが必要となる。このユーザプロフィールとは、ユーザの個人的な嗜好を表した情報のことを意味し、それを生成する技術をユーザプロフィール技術と呼ぶ [2][3]。

この技術には、明示的手法と暗黙的手法の2つが存在し、明示的手法は直接ユーザから興味に関する情報を入力してもらい、このデータに基づいてユーザの嗜好を抽出して、ユーザプロフィールを生成する。一方の暗黙的手法は、システムを利用するユーザの行為を用いて嗜好を判断し、それらの情報からユーザプロフィールを生成する。一般的に、明示的手法は暗黙的手法に比べてユーザにかかる負担が大きいという欠点がある。このためWebサービスなどにおけるユーザプロフィール技術では暗黙的手法がしばし

¹ 全員に同じサービスを提供するのではなく、ユーザ個人の嗜好に合わせて最適化したものを提供する手法を指す。

² <http://www.google.com/support/bin/answer.py?answer=26651&topic=9005>

ば用いられ、ユーザの行動履歴として Web サイトの閲覧履歴が利用される。次節では、閲覧履歴を用いたプロフィール生成手法について述べる。

2.2 閲覧履歴を用いたプロフィール生成手法

ユーザの行動履歴として、Web の閲覧履歴を用いたユーザプロフィールを生成する手法が研究されている[4][5]。これは「Googleパーソナライズ検索」にも使われている手法であり、ユーザの Web ページ閲覧行動に応じて、該当するページの特徴的なキーワードをシステムが自動的に抽出する。最終的に、抽出されたキーワードをユーザの特徴として、個々のユーザプロフィールが生成される。

2.3 閲覧履歴に基づく特徴抽出

ユーザの嗜好を抽出するためには閲覧したページの特徴となっているキーワードを抽出する必要があり、そのために $tf \cdot idf$ 法[6][7]が用いられている。これはキーワードの出現頻度から重み付けする手法で、 tf は対象となる Web ページにおける特定キーワードの出現頻度を、 idf は Web ページ集合の中で特定キーワードが含まれている Web ページの数を指す。もし、あるキーワードが一つの Web ページ内に頻出するものであり、そのキーワードが出現する Web ページ数がわずかな場合であれば、それは $tf \cdot idf$ 値が高く Web ページの特徴的なキーワードと言える。この手法を用いた特徴抽出について次式を定義とする。なお、ここでは Web ページ hp におけるキーワード k の $tf \cdot idf$ 値を $w^{hp}(k)$ として定義する。

$$w^{hp}(k) = tf(k) \cdot idf(k) \quad (1)$$

$tf(k)$ = 閲覧した Web ページ hp におけるキーワード k の出現回数

$$idf(k) = \frac{\text{全てのWebページ数}}{\text{キーワード}k\text{が出現するWebページ数}}$$

ここで、 $tf \cdot idf$ 値を求めて算出した Web ページの特徴となるキーワードを、ベクトル空間モデル³を用いて表す[8][9]。つまり特徴をベクトル化することで、その向きや長さで特徴の度合いを測ることができ、これを特徴ベクトルと呼ぶ。ある Web ページ hp の特徴ベクトル w^{hp} は次式のように定義される。

$$w^{hp} = (w^{hp}(k_1), w^{hp}(k_2), \dots, w^{hp}(k_m)) \quad (2)$$

k_i = 式 (1)より抽出された各キーワード ($i=1, 2, \dots, m$)

m = Web ページ hp におけるキーワードの総数

この特徴ベクトルをユーザプロフィールとして用いる。しかし、閲覧したページがユーザの嗜好に合っていない場合、ユーザの嗜好と異なる情報も共に抽出され、ユーザの嗜好が適切には反映されない。また、閲

読時間を設けてもユーザによって閲覧するスピードが異なるため、この手法は精度の高いユーザプロフィール生成手法とは言えない。そこで次章において、ブックマークを用いることで、ユーザの嗜好だけを抽出した精度の高いユーザプロフィール生成方法、並びに検索システムとの組み合わせを提案する。

3. ブックマークを用いた個人向け検索システム

情報検索に対応する本研究の提案モデルは、キーワード検索技術と情報フィルタリング技術⁴の両技術で構成されている。基本コンセプトは、検索結果である Web ページが、生成したユーザプロフィールに類似しているほどユーザが望む情報であると仮定して、その Web ページを上位に提示するというものである。例えば、ユーザがあるキーワードを入れて検索した時、Web 上に存在する大量の Web ページがヒットしたとする。そこで、情報フィルタリング技術と組み合わせることによって、ユーザの嗜好と似ている Web ページを抽出し、必要な情報だけに絞り込む。この結果、ユーザは全てのページをチェックすることなく、有益な Web ページを手早く得ることが出来る。

次の節で、閲覧履歴ではなくブックマーク情報を採用する利点を述べる。




図 1: 提案する個人向け検索システムのモデル

3.1 検索技術におけるブックマークの利点

ブックマークを作成するユーザの意志とは、「今後もこの Web ページを閲覧したい」という強い興味の表れである。したがって、ブックマークはユーザの嗜好が的確に反映されたものだといえる。ユーザの関心が薄れ、嗜好が変わった場合には、ブックマークを削除するこ

³ 情報検索分野で幅広く利用されている検索モデル。検索質問や Web ページをベクトルで表現し、ベクトルの向きによって内容を判断する。

⁴ ユーザの嗜好に基づいて、関心のあるものを提示したり、優先度を与えたりして情報を選別する技術。

とで常にユーザの嗜好を反映するユーザプロフィールを維持することが可能になる。以上の利点から、本研究ではユーザプロフィールの生成にブックマークを利用する。

3.2 ブックマークを用いたプロフィール生成方法

3.2.1 特徴抽出

ブックマークからユーザを特徴付けている特定キーワードを抽出するために、2.3 で述べた $tf \cdot idf$ 法を利用する。しかし、ブックマークは閲覧履歴と異なり、ユーザの嗜好が反映された結果として、偏ったページの集合となっている可能性が高い。そのため、ユーザの選別したブックマークの中には、内容の類似した Web ページが多数存在しても珍しくない。

このような場合、特定のジャンルに関わるキーワードの頻出度が上がり、 tf 値が上昇する。しかし、それらのページは似通っている内容のため、特定キーワードはほとんどの Web ページに出現することになり、逆に idf 値は減少する。これでは、そのキーワードに対して $tf \cdot idf$ 値が低く算出されてしまうため、ユーザの嗜好に合致しているはずのキーワードが抽出されないことになる。

そこで、ユーザのブックマークに存在するフォルダを利用し、フォルダ単位でブックマークの特徴抽出を行う。カテゴリ別に分類して似通ったページを一括りにすることで、 $tf \cdot idf$ 値が偏ることのない特徴抽出を可能にする。




図2:ブックマークフォルダを用いた特徴抽出手法

提案するシステムでは図2のようなモデルを想定し、 $tf \cdot idf$ 値によるブックマークからユーザの特徴を示す

キーワードを抽出する。まず、ブックマークフォルダ j におけるキーワード k の $tf \cdot idf$ 値 $bf_j(k)$ を次のように定義する。

$$bf_j(k) = tf_{bf}(k) \cdot idf(k) \tag{3}$$

$$tf_{bf}(k) = \frac{BF \text{ 内におけるキーワード } k \text{ の出現回数}}{BF}$$

$idf(k) = \frac{BF \text{ 内でキーワード } k \text{ が出現するWebページ数}}{BF}$
 $BF = \text{ブックマークフォルダ内の全 Web ページ数}$

$tf \cdot idf$ 値が高いキーワードほどそのブックマークフォルダの特徴となるキーワードと判断し、抽出したキーワードの集合をユーザプロフィールとする。しかし、この手法はフォルダ単位で計算しているため、どのフォルダにも属さない Web ページがある場合や、フォルダを一つしか作成していないユーザが存在する場合には特徴抽出をしても効果が見られない可能性がある。そこで、フォルダに分けられていないブックマークを一つのフォルダと仮定し、通常のフォルダと同様に $tf \cdot idf$ 値を算出する。つまり、これらのブックマークは Web ページ単体に対して $tf \cdot idf$ 値を求めていることになる。これにより、フォルダのカテゴリにとらわれない特徴抽出が可能となる。

このようにして、各カテゴリのブックマークフォルダに $tf \cdot idf$ 値が最大のキーワードをひとつずつ抽出する。次項において、この抽出したキーワードを用いた特徴ベクトル生成方法について述べる。

3.2.2 特徴ベクトル生成

検索結果における Web ページと類似度を測るため、ユーザのブックマークから抽出した特徴をベクトルで表す。前章で述べた特徴抽出方法を用いて、ブックマークフォルダの特徴となっているキーワードを抽出した。したがって、 $tf \cdot idf$ 値の高かったブックマークフォルダ $bf_j(k)$ を対象文書として特徴ベクトル f^{BF} を生成する。ブックマークフォルダの集合 BF における特徴ベクトル f^{BF} は次式のように示す。

$$f^{BF} = (bf_1(k_1^*), bf_2(k_2^*), \dots, bf_m(k_m^*)) \tag{4}$$

$k_i^* = \text{抽出されたキーワード}(i = 1, 2, \dots, m)$
 $m = \text{ブックマークフォルダの総数}$

このようにして生成した特徴ベクトルは、ユーザがキーワード検索をした際に出力された Web ページと、どれくらい似ているのか判断するのに利用される。そのためには比較対象である Web ページもベクトルで表現する必要があり、次にそれらのベクトル生成方法を述べる。

4. 文書ベクトル生成

文書ベクトルとは、キーワードの出現頻度に基づいて、検索結果である Web ページを一つずつベクトルで表現したものである。本システムでは、前述した特徴ベク

トルと文書ベクトル間の類似度を測り、検索結果を出力する。

次式で文書 doc_h ($1 \leq h \leq l$)の文書ベクトル d_h を次式で表す。

$$d_h = (w_{h1}, w_{h2}, w_{h3}, \dots, w_{hm}) \quad (5)$$

この文書ベクトルと先に述べた特徴ベクトル間の類似度を測り、ユーザの特徴ベクトルに対し類似度が高いと判定されたWebページを検索結果の上位に出力する。これは、検索対象であるWebページを表す文書ベクトルが、個々で生成された特徴ベクトルに近いほどユーザにとって興味のあるWebページであると判断した。類似度には、2つのベクトルのなす角度を用いたコサイン尺度を用いる[10]。ベクトル間の類似度を $\cos\theta$ とした場合、特徴ベクトル f^{BF} と文書ベクトル d_h の類似度は次のようにして求める。この値は1に近いほど類似度が高いことを意味する。

$$\cos \theta(f^{BF}, d_h) = \frac{f^{BF} \cdot d_h}{|f^{BF}| |d_h|} \quad (6)$$

このように、ベクトル空間モデルを利用してユーザの嗜好情報を表す特徴ベクトルと対象 Web ページを表す文書ベクトル間の類似度を算出させることで、類似度の高い Web ページから順に結果を表示する。

5. むすび

本研究では、ブックマーク情報を用いたユーザプロフィール生成手法を提案した。この手法はブックマークの機能を普段から利用しているユーザにとって、ユーザの負担は皆無であり、ブックマークに多数の登録をしているユーザは、より精度の高い検索結果を得ることが可能となる。例えば、個々のユーザが「アップル」と検索した場合、パソコン関係の Web ページをブックマークしていたユーザなら「アップル社」関連の Web ページが上位に表示され、料理関連の Web ページをブックマークしていたユーザなら「アップル(りんご)」関連の Web ページが上位に表示される。

さらに、ブックマークフォルダによってカテゴリが構成されているため、ユーザの嗜好を従来の方法より正確に抽出することを可能にした。

しかし、ブックマークに登録される Web ページの増加量は閲覧履歴のページ数よりもかなり緩やかである。そのため、個人の嗜好が反映されるまでに時間を要するという問題もある。よって、今後はブックマーク量が増加するような機能の追加など、本システムの改善に向けて検討していきたい。

Web 上の情報量が年々増加していく現代において、ユーザ個人の嗜好に対応する検索システムは不可欠

なものだと言える。今後、Google社が提供している「Googleパーソナライズ検索」のように、個人に対応するシステムが一般的なサービスとなるであろう。

参考文献

- [1] http://rblog-media.japan.cnet.com/0058/2006/11/googlemapagera_n_c27d.html CNET Japan, インターネットの理解, 2006. 11. 6.
- [2] 土方嘉徳, "情報推薦. 情報フィルタリングのためのユーザプロファイリング技術", 人工知能学会, 19 巻 3 号, pp.365-372, 2004. 5.
- [3] 堀 幸雄, 今井 慈郎, 中山 堯, "個別化する Web : 一検索キーワードの個別化", 情報知能学会誌, Vol. 16, No. 4, pp.4.33-4.40, 2006.
- [4] 杉山一成・波田野賢治・吉川正俊・植村俊亮, "ユーザからの負担なく構築したプロフィールに基づく適応性 Web 情報検索", 電子情報通信学会, No.11 ,pp.975-99, 2004. 4.
- [5] 中村雄一, 菊池浩明, "閲覧履歴に基づく情報検索の相互支援", 情報処理学会研究報告. DPS, マルチメディア通信と分散処理研究会報, 126, pp. 25-30, 20060316, (ISSN 09196072).
- [6] <http://www.ntts.co.jp/products/knowledgeocean/detail/qanda.html> NTT ソフトウェア.
- [7] <http://nlp.nagaokaut.ac.jp/~sekiguti/doc/pdf/tfidf/tfidf/> TFIDF.
- [8] 福島 俊一. "Web サーチエンジンの基本技術と最新動向(上)基本技術". 情報管理 Vol. 46, No. 6, (2003), 363-372.
- [9] 大谷紀子, "情報検索におけるベクトル空間モデルの応用", 武蔵野工業大学環境情報学部研究論文 3-6.
- [10] 小松香爾, "情報システムにおける言語処理技術の利用", 経営論集, pp.105-114, vol.13, No.1, 2003. 12.