

Web サイトのアクセスログに基づくユーザの目的ページ推定

安達 洋明[†] 倉本 到[†]
渋谷 雄[†] 辻野 嘉宏[†]

[†] 京都工芸繊維大学

E-mail: {adachih, kuramoto, shibuya, tsujino}@hit.dj.kit.ac.jp

ユーザの目的を知ることは、Web サイトのユーザビリティを自動評価する上で有効である。本研究では、Web サイトのアクセスログに基づき、ユーザがページ移動時に選択したリンクにおける字句出現頻度と、ユーザの移動経路の特徴とを解析することにより、ユーザの目的ページを推定する手法を提案し、評価した。その結果、情報の分類が整理されユーザに分かり易い階層構造を持つサイトのように、深い階層構造を横切る移動があまり生じないような Web サイトに適用した場合には、高い精度で目的ページを推定できることがわかった。

Finding Users' Target Pages Based on Web Access Logs

Hiroaki Adachi[†], Itaru Kuramoto[†], Yu Shibuya[†] and Yoshihiro Tsujino[†]

[†]Kyoto Institute of Technology

It is effective to know users' target web pages for checking the usability of the Web site automatically. In this paper, we proposed the method for finding target pages based on web access logs. The method uses word-frequency of anchor texts chosen by the user and the characteristics of his/her access path. From the experiments, we found that the method could find user's target pages by correctly in some particular kind of Web site.

1. はじめに

近年、Web サイトの制作工程において、ソフトウェアにより Web サイトを自動的に評価し、その結果をもとに Web サイトのユーザビリティを向上させるための修正を行っていくという手法を用いることが多くなってきている。このようなソフトウェアに用いられる自動評価手法では、コンテンツのみに基づく解析を行うのが一般的である。

その例として、W3C HTML Validation Service¹⁾ や LiFT²⁾ は、ページがアクセシビリティガイドラインやユーザビリティガイドラインに準拠しているかを調べることで評価を行っている。また、bloodhound³⁾ は、キーワードで表現した目的情報とリンクとの類似度を比較することで、ユーザが次に見るページを予測することができる行動モデル WU-FIS(Web User Flow by InfomationScent) を利用した自動評価システムである。これは、評価者が仮想

的なユーザの持つ目的をキーワードで表現し、ソフトウェアがその仮想的なユーザの行動をシミュレーションすることでアンカーテキスト等に関する問題の検出を支援している。

しかし、これらのコンテンツのみに基づく自動評価手法では、実際にサイトを利用するユーザがどのように振舞うかが考慮されていないため、検出できる問題のバリエーションは限られてしまう。そのため、これらソフトウェアによる自動評価はガイドラインの準拠等、基本的な事柄の確認のために使用されるに留まり、文章の分かり易さなどのそれ以外の内容は、人間により認知的ウォークスルー等の手法を用いて評価を行う必要があるのが現状である。この問題を解決するためには、ソフトウェアによる自動評価においてもユーザがどのように行動したのかを考慮する必要がある。そこで、アクセスログから得られるユーザの行動に着目する。

そもそもユーザの行動はユーザ自身が持つ目的に

左右される。例えば、ユーザが Web サイトを閲覧するときには、目的と関連する語句をページ中から探し、それがアンカーであればクリックして次のページへ移動する。また、ページの内容がユーザの期待にそぐわなければ、ブラウザの戻るボタンをクリックして、前に見ていたページに戻る。

従って、ユーザの目的が予め判っていれば、ユーザが「ここでなぜこのような行動をしたのか」を分析することができ、問題の検出、解決に役立てることができる。例えば、ユーザが目的の情報が記述されているページに到達する過程において、遠回りしてしまったり、迷ってしまった場合、ユーザの目的がわかっていればなぜ間違ったアンカーを選択してしまったかを分析することができる。

このことから、ユーザがどのように行動したかを解析するためには、ユーザの目的を知ることが重要であると言える。

そこで本研究では、Web サイトにおけるユーザビリティ自動評価に役立てることを目指し、ユーザの目的ページを推定する方法を提案する。

2. 推定手法における着眼点

2.1 ユーザの目的

ユーザの行動からユーザの目的を知ることは難しい。なぜなら、ユーザは多様で複数の目的を持って Web サイトを閲覧し、またその時々で変わることがあるからである。

そこで本研究では、ユーザは複数の目的を順番に1つずつ探して行き、ユーザの目的は「ユーザが欲しいと思った情報(目的情報)が記述されているページ(目的ページ)へ到達すること」であると仮定する。

2.2 特徴的なユーザの行動

ここであるユーザが目的の情報を Web サイトから見つけ出すために、サイト内のあるページを見ているとする。そのときユーザがとる行動の中で、ユーザの目的に関し、目的ページを推定するために役立つものとして次の2つが考えられる。

(1) ユーザの移動経路

ユーザは目的とする情報に近いと判断し、興味を持ったページは内容をじっくり読み、辿った先のページの内容がユーザの期待と大きく異なっていると、ユーザはブラウザの「戻る」ボタンにより一度見たページへ戻る。そのため、ユーザの移動経路における各ページには「このページに訪れた後で、一度見たページに戻った」「表示時間が長かった」といった特徴が生じる。

さらに、ユーザがそのような行動を起したページは、「サイトのトップページから近い」というような、Web サイトの構造による特徴を持つ場合もある。

このことから、これら特徴と目的ページとの関係を見つけ出し、目的ページを推定できることが期待できる。

(2) アンカーの選択

ユーザは目的とする情報に関連する単語をページから探し、そのような単語を含むアンカーを選択することでページを移動していく。そのため、ユーザが選んでいったアンカーテキスト上に出現する単語は、ユーザの目的情報に深い関連があり、これら単語を集めればユーザの目的情報を端的に表現することができる。こうして得た、ユーザの目的情報の断片は、ユーザの目的ページを推定するために非常に役立つことが期待できる。

そこで本研究では、アクセスログに基づいてユーザの移動経路から抽出した特徴と、ユーザが移動時に選択したリンクにおける字句出現頻度とを解析することにより、ユーザが実際に閲覧したページからユーザの目的ページを推定する手法を提案する。

2.3 目的変更ページ

ユーザが Web サイトにおいて情報を探索するとき、複数の目的を持って Web サイトを閲覧する。

従って、これらユーザの目的ページを推定するためには、ユーザが目的を変更したことを知る必要がある。さらに、ユーザが目的を変更したということは、その時点でユーザが目的情報を見つけたか、あきらめてしまったということである。

このことから、ユーザが目的を変更し、何らかの行動を起した直前のページを検出することで、目的ページの候補も得ることができる。

よって、ユーザが複数の目的を持っている場合を考慮するためには、まずユーザが目的を変更したページを検出し、さらにそれが本来の目的ページであるかどうかを判定するという手順を踏むことが必要である。

3. 移動経路における特徴抽出解析

ユーザの移動経路に対して各ページに生じた特徴と目的ページの関係から、目的ページを推定できることを2.2節で述べた。この考えに基づき、まずは推定に役立つページの特徴を抽出することを考えていく。

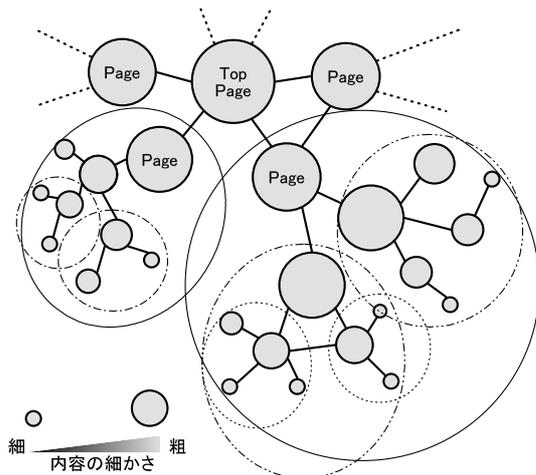


図 1 階層とグループ

3.1 移動経路の特徴

ユーザの目的ページや目的変更ページにおいて良く見られるであろう特徴として以下のものを考えた。

- ページ階層の深さ
- URL の変化
- 表示時間の長さ
- 移動経路上の特徴点

以下これらについて説明する。

3.1.1 ページ階層の深さ

多くの Web サイトにおいて、各ページは内容の分類によりグループ分けされており、その中にさらに細分化した分類のグループがあるというように、各ページは階層的に配置されている (図 1)。

そうすると、もしユーザが見ているページが細分化された情報が記述されている階層の深いページであった場合、ユーザは大きな情報の分類を決定した上でより限定された情報を探している段階にあるといえることができる。そして、ユーザが深い階層のページを閲覧しているときは、ユーザが見ている情報とユーザの目的の情報に近いとユーザが確信している状態にあると考えられる。

このことから、ユーザが見ているページにおける階層の深さから、ユーザの目的情報との近さを推し測ることが期待でき、階層が深いほどユーザの目的ページが存在する確率が高いと言える。

3.1.2 URL の変化

前述のような、内容によるグループの階層化はディレクトリ構造に反映されることも多い。そのような場合、ページの内容は URL に反映されるため、URL を見ることでページがどのグループのどの階層にあるかを知ることができる。

このことから、ユーザが見ていたページの URL を順に並べ、URL の文字列にある変化が生じた時点で、ユーザが見ている内容が大幅に変化し、目的を変更したと捉えることができる。

3.1.3 表示時間の長さ

ユーザがページを表示している時間が長いということは、ユーザが興味を持ってページの内容を読んでいる可能性が高い。また、表示時間が短いということはユーザの興味が薄いということになる。

3.1.4 移動経路上の特徴点

ユーザが Web サイトを移動するときにとった行動によって、移動経路が形成される。このような移動経路において特徴的な部分にあるページというのは、それ自体がページの特徴となりうる。そこで、そのような特徴のうち、ユーザの目的ページや目的変更ページにおいて良く見られるであろう特徴として以下のようなものを考えた。

(1) ユーザが最後に訪れたページ

ユーザが Web サイトの探索をやめる場合、目的の情報を見つけた、もしくはあきらめた可能性があると考えられる。

(2) ユーザがブラウザの「戻る」を選んだ直前のページ

ユーザがブラウザの「戻る」を選んだということは、見ていたページの内容がユーザの期待と違った可能性と、目的ページに到達し目的を変更した可能性があると考えられる。

(3) ユーザが同じ階層を見続けた後に、浅い階層へ移動した直前のページ

ユーザが同じ階層のページを移動し続けたということは、ユーザは内容の似通ったページを見続けている状態であると考えられる。その上でユーザが浅い階層へ移動したということは、その内容はユーザにとって必要ではなくなり、見る内容を変更しようとした可能性が大きい。従って、目的変更ページの候補とすることができる。

3.2 特徴の組合せによる推定

これらの特徴が目的ページにおいて良く見られるのであれば、特定の特徴の組み合わせを持つページが目的ページである確率が高くなる。つまり、ページがどの特徴の組み合わせを持つかによってそのページがユーザの目的ページである確率が定まる。

そして、これら特徴の組み合わせのうち確率の高いものから順にいくつかを選び、それらの組み合わせのうちどれかを満たすことが目的ページの条件で

あるとすれば、確率の高い状態で多くの目的ページを得ることができる。

これら特徴の組み合わせによる目的推定を、移動経路における特徴抽出によるユーザの目的推定法 (MPC) とする。

3.3 使用する特徴とその検出方法

3.1 節で述べた特徴を推定に使用するために具体化した特徴とその検出方法について述べる。

3.3.1 深さの検出

ページに記述された内容から Web サイトの階層構造を検出することは難しい。しかし、少なくともハイパーリンクの繋がりにおいては、このような内容による階層構造が反映されるため、これを利用することができる。従って、トップページから最低限経由する必要があるページの数 (最短経由ページ数) を階層の深さとし、最短経由ページ数の多いページを階層の深いページ、少ないページを階層の浅いページと呼ぶこととする。

3.3.2 使用する特徴

- 移動経路における特徴

A_1 ユーザが最後に訪れたページ

A_2 ユーザが戻るを選んだ直前のページ

ユーザが戻るを選んだということはアクセスログには記録されないため、これを100%検出することは難しい。そこで、ページ間のリンク構造を用いる。アクセスログ上で、ユーザがリンクの無いページ間を移動した場合、ユーザが戻るを選んだ上でアンカーにより移動したとみなすことにした。また、環境変数 HTTP_REFERER により、ユーザの移動元のページが分かる場合があるので、利用できる場合はそれも使用する。

A_3 ユーザが同じ階層を見続けた後に、浅い階層へ移動した直前のページ

Web サイトにおける階層は最短経由ページ数により概ね調べることが可能であると前述した。そこで、同じ階層を移動し続けるということを、最短経由ページ数が同じページを連続して移動することと考える。その上で最短経由ページ数が少ないページに移動したことを浅い階層に移動したとし、その直前のページを条件に合致するページとする。

しかしながら、連続して移動したページ数が2ページでは、移動し続けると言うには不十分なため、連続して移動したページ

が3ページ以上の場合に限ることとする。

A_2 と A_3 は同時に満たされることがあるが、 A_3 は A_2 のより特殊な場合と考えることができるため、その場合は A_3 を優先する。

- 表示時間の長さ

アクセスログから、ページの取得時刻の差分を計算することでページの表示時間を得る。そして、表示時間が長いページから順に並べて10%ごとにグループ分けし、上位4グループを表示時間の長いグループとする。

B_1 表示時間が上位0~9%に含まれるページ

B_2 表示時間が上位10~19%に含まれるページ

B_3 表示時間が上位20~29%に含まれるページ

B_4 表示時間が上位30~39%に含まれるページ

- URL の変化

C URL 中の先頭ディレクトリが変化する直前のページ

URL の変化を調べる方法として色々な手法が考えられるが、先頭ディレクトリの変化を調べることが、簡単で効果が大きいと考えられる。

- 階層の深さ

ユーザが閲覧したページの中で最短経由ページ数が一番多かったものから順に4つの最短経由ページ数を持つページを階層の深いページとした。

D_1 ユーザが閲覧した中で、ホームページからの最短経由ページ数が一番多いページ

D_2 D_1 の値より1少ない最短経由ページ数を持つページ

D_3 D_1 の値より2少ない最短経由ページ数を持つページ

D_4 D_1 の値より3少ない最短経由ページ数を持つページ

4. アンカーテキストにおける字句頻度解析

ユーザがページ移動時に選択したアンカーテキストの単語を集めることで、ユーザの目的情報を端的に表現でき、目的推定に役立てられることを2.2 節で述べた。

そこで、これら単語の出現頻度とページに含まれる単語の出現頻度を比べることで、ページがユーザ

の目的にどれだけ近いかを調べ、目的推定を行う。

以下、このアンカーテキストにおける字句頻度解析手法 (MWF) について述べる。

4.1 目的ベクトル

ユーザが目的情報を探索するとき、ユーザが選んでいったアンカーテキスト上に出現する単語は、ユーザの目的情報に関連があり、これらの単語を集めればユーザの目的情報を端的に表現することができると考えられる。そこで、これらの単語の出現頻度から単語の重みを算出し、ベクトルで表現したものを目的ベクトル T と呼ぶことにする。

なお、対象の Web サイト全体において頻出する単語は、そのサイト内での目的ページを特徴づけているとは言いがたいので単語の重みを下げる必要がある。そこで以後の方法では、TF・IDF 法を用いて出現する単語の重みを調整することとした。

また、「リンク」など WWW において一般的である単語はあらかじめ除外する。その上で、「ここをクリック」など、アンカーテキスト内に重みの高い単語が含まれない場合は、アンカーテキストの前後の文章がアンカーを説明する文章であると仮定し、この文章に含まれる単語も利用することとする。

4.2 目的ベクトルとページの内容との合致度

次に、ユーザの持つ目的情報と各ページの合致度を考える。合致度は、前述した目的ベクトルとあるページの単語出現頻度がどれだけ一致するか値である。これによりユーザの目的情報と対象のページの内容とどれだけ一致しているかを計ることができる。

ページ P 中に含まれる単語 t の出現頻度を $tf(P, t)$ 、単語 t を含むページ数を $df(t)$ 、全ページ数を N 、目的ベクトル T における単語 t の重みを $T(t)$ とし、 T と P との合致度 $m(P, T)$ を式で表すと以下ようになる。

$$m(P, T) = \sum_{t \in T} T(t) \cdot \frac{tf(P, t)}{\log(N/df(t))} \quad (1)$$

しかも、この合致度は実際にユーザが閲覧していないページに対しても求めることができるので、ユーザが達成することができなかった目的ページを推定する場合にも役立つことが期待できる。

4.3 合致度の変化と目的変更ページの検出

これまでに述べた考え方は、ユーザが複数の目的を持っている場合について考慮されていない。なぜなら、目的ベクトルにはユーザが探索した全ての目的に属する単語を含んでしまうため、ユーザの目的を個別に捉えることができないからである。

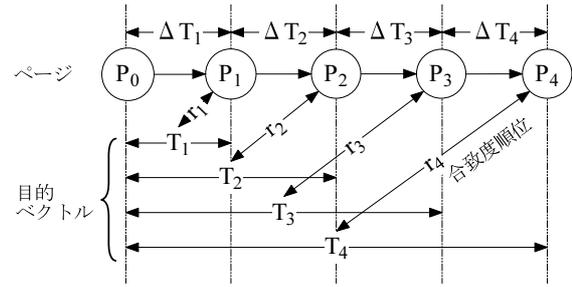


図 2 各値の関係

そこで、複数の目的を持っている場合にも対応するために、ユーザの目的変更を検出することを考える。ここで、あるページを表示した段階で、目的ベクトルとページとの合致度が大きく下がった場合を考える。このとき、ユーザは今までと違った内容のページを表示したことになり、すなわちユーザが目的とする情報を変更し、その違う目的ページにたどり着くためのリンクを選択したことを示すと考えられる。

従って、これら合致度の順位を求め、その差分と減少前の合致度の値により目的ページであるかの推定を行うこととする。これらは実際に以下のような手順で発見することができる。以下の手順における各値の関係を図 2 に示す。

- (1) ユーザが最初に見たページを起点と考え P_0 とする。そして、ユーザが P_0 から i 番目に移動したページを $P_i (1 \leq i \leq n)$ とする。
- (2) ユーザが見ているページ P_i と直前に見ていたページ P_{i-1} と間のアンカーテキストにより得られる目的ベクトル $\Delta T_i (1 \leq i \leq n)$ を求める。
- (3) ページ P_j を見た時点での目的ベクトル $T_j = \sum_{k=1}^j \Delta T_k$ とする。
- (4) T_j と、全てのページ $P_k (1 \leq k \leq n)$ との合致度 $m(P_k, T_j)$ を求める。
- (5) 求めた $m(P_k, T_j)$ の中で、ユーザが見ているページ P_i に対する合致度 $m(P_i, T_i)$ の順位を合致度順位 r_i とする。
- (6) 全ページ間における合致度順位の変化 $r_{j-1} - r_j$ を求め、合致度順位が差分の閾値を上まわって低下しており、かつ r_{j-1} が一定値を越えた最初の P_{j-1} を目的変更の候補ページとする。
- (7) (6) で決定した目的変更ページを P_0 、以後のページを P_1, P_2, \dots として (2) ~ (6) を繰り返す。

5. 解析手法の併用

これまで、ユーザの目的ページを推定するために、MPC と MWF の 2 つの異なる方法を考えた。次に、

この2つの手法の特性を考慮して併用することにより1つの推定手法とし、より良くできないかを考察する。

5.1 的中率と回収率

2つの手法の併用法を吟味するにあたり、目的ページ推定における精度の指標としての的中率と回収率を定義する。

的中率とは推定したページ中での目的ページの比率であり、回収率は実際の目的ページ全体のうちでの推定した目的ページの比率である。

なお、提案手法においては、パラメータとなる要素を変更することにより、これらの値が変化する。

MPCにおいては、条件式に取り入れる組み合わせの数がパラメータとなる。組み合わせの数が少ければ、的中率は高くなるが回収率は低くなってしまふ。逆に選択する組み合わせの数を多くすれば、組み合わせを満たすページは多くなるため回収率を上げることができるが、的中率の低い組み合わせも条件に含まれるための的中率は下がってしまう。

MWFにおいては、目的変更ページ検出に用いる合致度の差分における閾値と、目的ページの確度算出のために用いる合致度の閾値がパラメータとなる。

5.2 併用法

2つの手法の併用法として、以下のものを考えた。

- (A) それぞれの手法において的中率を優先してパラメータを調整し、少なくともどちらかによって目的ページとして推定されたページを目的ページとする。
- (B) それぞれの手法において回収率を優先してパラメータを調整し、双方によって目的ページとして推定されたページを目的ページとする。
- (C) MWFにおける合致度の変化をページの特徴の1つとして捉え、MPCで挙げた特徴にこれを加える。

(A)の手法は、2つの手法が異った目的ページを捉える傾向がある場合に効果が期待でき、2つの手法が不得意な部分を補うことができると考えられる。

(B)の手法は、2つの手法が同じような目的ページを捉える傾向がある場合に効果が期待でき、目的ページであるか判断がしづらい場合に確度を上げることができると考えられる。

(C)の手法は、ページが特にある特徴の組み合わせを持つときのみMWFが効果を発揮するような場合に有効だと考えられる。

6. 実験

6.1 実験の目的

ユーザの目的ページ推定法として、5.2節で提案した3手法の妥当性を評価する。

6.2 実験方法

Webブラウジングに慣れた理系大学生男女計12名に対し、指定したWebサイトから、用意した4つの質問の答えを探するというタスクを与えた。質問は1つのWebサイトにつき複数用意し、そのうち難易度の異なる4つの質問を1つのタスクとして使用した。そして、タスク達成のために到達すべきページを事前に決定し、これをユーザの目的ページとした。被験者はこれらを1つずつ順番に探す必要がある。ユーザがサイト中の単語と質問の内容を結びつけ易くするため、質問の文章を長めにした。

そして、被験者が実験時に行う行動が、日常において同様の探索を行う場合に近づくようにしつつ、推定手法が適用できるようにするため以下のような条件を与えた。

(1) サイト検索機能の使用を禁止

リンクを辿ることによって探索を行うことを前提としているため、サイトに設置されている検索機能の使用を禁止した

(2) 時間無制限

制限時間があれば、被験者はページをじっくり吟味しなくなる可能性があるため制限時間は設けなかった。

(3) 探索を諦めることを許可

諦めることを許さないと、ユーザが探索不可能と判断した場合、リンクを無作為に選択したりしてしまうため探索を諦めることを許可した。ただし、目的情報の探索を諦めた場合は次に指定されている目的情報を引き続き探索してもらい、一度諦めた目的情報をもう一度探索することは禁止した。これは、目的変更を頻繁に行うと推定が難しくなることが予想されるためである。

(4) 探索順序の指定

探索順序による影響を排除するように、探索する順番はこちらで指定した。

そして、実験により得られたユーザの行動から推定手法を用いて推定した目的ページが、設定した目的ページと一致した場合に正しく推定できたと判断した。

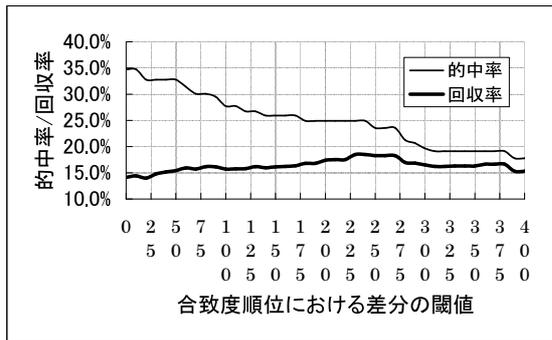


図3 MWFにおける閾値と的中率・回収率の関係

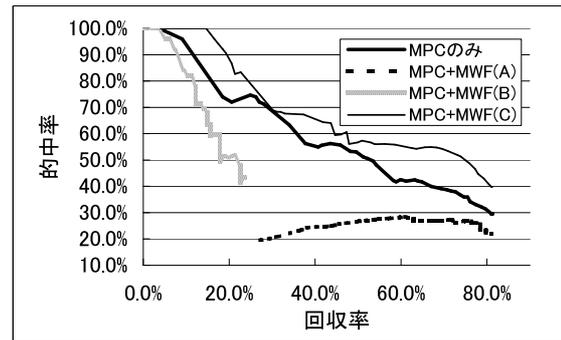


図4 併用結果

文章中心で構成され、両手法が適用し易いと考えられるサイトとして以下のサイトを利用した。

- 独立行政法人情報処理推進機構
<http://www.ipa.go.jp/>
- 特許庁
<http://www.jpo.go.jp/indexj.htm>
- 環境庁
<http://www.env.go.jp/>

なお今回の実験では、実在する外部の Web サイトを使用したため、Web サイト上のアクセスログを得ることが困難であった。そのため、クライアントに Proxy サーバを経由させ、そのログを取得することとした。

6.3 実験結果および考察

6.3.1 MWF の適用結果

MWF の単独使用において、合致度順位の高いページが目的ページであるという傾向はあまり得られず、この値の高さからページがユーザの目的ページであるかを確定することは困難であった。

そこで MPC との併用を考えるあたり、以後の分析では、合致度の値から目的ページの候補を絞り込むことはせず、合致度の変化から目的を変更したページを導き出すことのみにより目的ページを推定することとした。

しかしながら、質問の内容に固有名詞などのサイト内において特異な単語が含まれている場合においては、合致度の値が非常に高くなる傾向が見られた。これは TF・IDF による重みの算出時に、出現頻度の低い単語は重みが高くなるのが原因だと考えられる。よって、用語辞典のような、ページ間の単語分布の類似性が低い特殊なサイトにおいては、現状でも MWF 単体において高い効果を発揮する可能性があると考えられる。

6.3.2 併用結果

まず、5.2 節で述べたそれぞれの併用法を実際に

適用するにあたり、MWF 単独使用の結果 (図 3) から、MWF において、目的変更ページ検出に用いる合致度順位の変化の閾値を、的中率優先では 5、回収率優先では 270 と定めた。

次に、2 つの方法の併用法を決定するため、考えた 3 つの方法において MPC における特徴組合せ数を変化させ、回収率と的中率の変化を調べた (図 4)。

その結果、併用法 (A)(B) においては、2 つの手法を併せることで精度が低下してしまった。これは、併用法 (A)(B) は推定結果そのものを統合するため、単体での精度があまり良くない MWF と性能が平均化されてしまうことが原因であると考えられる。もし、MWF の精度が MPC と同程度あれば、これらの併用法においても精度が高まり、それぞれ違った特性を示すと考えられる。

また MPC と MWF において、双方が同じ目的ページを捉える傾向があったり、違う目的ページを捉える傾向があったりするということは見受けられなかった。

これら結果から、3 つの方法のうち性能を向上させるのに最も有効な方法は (C) の MWF における合致度の変動をページの特徴とした場合であり、MWF を併用することにより、目的ページをより高い精度で推定できることがわかった。

このことから、MWF を単体で用いるにはまだ不十分であるが、合致度の変動は目的ページの変更を検出し目的ページ推定に有効であると言える。

6.3.3 適用対象を変化させた結果

1 つのサイトの実験結果から、1 タスクの結果を取り出しこれを評価用データ、残りの結果をパラメータ調整データとした。そして、推定手法 MPC と MFC の併用法 (C) によりパラメータ調整データをもとにして特徴組み合わせ式を作成し、その式を用いて評価用データの目的ページを推定した。

その結果、あるタスクにおいては 75%以上の回収率と的中率を得られる場合から、目的ページが全く

推定されなかった場合まで様々な推定結果が得られた。それらタスクを分析した結果、推定精度を左右する要素として以下のようなものが関係していることが判った。

(i) サイトの階層構造

階層が深く、ユーザがそれらの深い階層まで探索している場合は、高い推定精度が得られる傾向があった。

これは MPC ではページの特徴として階層の深さを利用しており、MWF ではページに含まれる単語の意味の詳細さが階層の深さに関係していることが原因であると考えられる。

(ii) ユーザの移動パターン

階層が浅いサイトを対象とした場合や、ユーザがナビゲーションバーによる移動を積極的に利用することにより、見る内容を頻繁に変更している場合は推定精度が低くなる傾向があった。

また、このようなユーザはページの平均表示時間が短い傾向にあり、ユーザはページの内容をあまり吟味せずにページを移動していたことも理由の1つとして考えられる。

これは、ユーザがページをじっくり吟味した上でカテゴリ分けされた1つのグループを探索し、その後見る内容を大幅に変えるということをユーザモデルにおいて期待しているためと考えられる。

また、あるサイトにおいてパラメータを設定した上で、別のサイトの実験結果に推定手法を適用し、どのような特徴を持つサイト同士であれば推定精度が低下しないかを確かめようと試みたが、今回の実験結果からはその傾向を得ることはできなかった。

6.4 考 察

実験の結果、サイトの階層が深くて分類分けもユーザにとって分かりやすく、分類のグループ間の移動があまり生じないようなサイトにおいては高い精度で目的ページを推定が可能であることが判った。このことから、適用の対象とするサイトを選択することで、提案手法をユーザビリティ自動評価に応用し、役立てることができる。

ただ、実験においては期待した精度は得られなかった。その原因の1つとして、サイトの構造やユーザの行動が、提案手法で想定としていたものと必ずしも合致しなかったことが考えられる。そのため、ユーザビリティ自動評価において提案手法を効果的に適用するためには、サイト構造への依存を軽

減したり、ユーザモデルを拡張していく必要があると考えられる。

7. ま と め

本研究では、アクセスログに基づいてユーザの目的ページを推定する手法を提案し、その妥当性を評価した。

推定手段として、ユーザが移動時に選択したリンクにおける字句出現頻度と、ユーザの移動経路から抽出した特徴を用いることを提案し、それぞれとその併用について分析した。

また、評価基準としての的中率と回収率を定義し、提案手法の精度と特性を評価した。その結果、情報の分類が整理されユーザに分かり易い階層構造を持つサイトのように、深い階層構造を横切る移動があまり生じないようなサイトに対して、提案手法が有効であることがわかった。

参 考 文 献

- 1) W3C HTML Validation Service
<http://validator.w3.org/>
- 2) LiFT <http://www.usablenet.com/>
- 3) E. H. Chi, A. Rosien, G. Supattanasiri, A. Williams, C. Royer, C. Chow, E. Robles, B. Dalal, J. Chen, S. Cousins: "The Bloodhound Project: Automating Discovery of Web Usability Issues using the InfoScent. Simulator", CHI 2003, pp.505-512 (2003).
- 4) N. Eiron and K. McCurley: "Analysis of anchor text for web search", Proceedings of the 26th Annual International 673 Information Retrieval, pp.459-460 (2003).
- 5) Salton, G. and McGill, M.J.: Introduction to Modern Information Retrieval, McGraw-Hill Book Company, 1983.
- 6) 北島宗雄: ウェブ認知ウォークスルーによるウェブサイトユーザビリティの評価, 日本ファジィ学会誌 14, 5, pp.446-460 (2002).