

指定ドメインにおける Web ページ評価手法

2 X - 0 2

片山佳則, 古川淳子, 西野文人

(株)富士通研究所 ドキュメント処理研究部

E-mail: {katayama.yoshin, furukawa.junko, nishino}@jp.fujitsu.com

1. はじめに

企業や個人が、情報発信を行うために、インターネットやイントラネットの Web コンテンツ(ページ)が活用されている。しかし、そのページにあるべき情報が記述されていないために、情報伝達がスムーズに行えない事や、各種の検索エンジンによる検索結果から漏れてしまう事などが起きている。これらは、企業にとって、ビジネスの機会を逃してしまうという重大な問題につながる可能性がある。従って、Web ページをコンテンツの充実度の観点で評価でき、記述内容に関して示唆が行える方法が必要である。

本稿では、これらの目的に合う評価手法として、各業界やコミュニティなどのドメインで、既に情報発信されている発信内容に基づいて、ダイナミックに評価する Web ページ評価手法について述べる。次節以降では、評価手法の概要とその特徴を述べ、その評価の予備実験例、さらには、情報サービスへの活用可能性、応用技術としての発展性をまとめる。

2. Web ページ評価手法の概要

2.1 従来の Web ページ評価手法

既に、各種の Web ページ評価手法が提案されている¹⁾。それらは、一般的な出版物に対する評価項目を基に、(a)Web コンテンツの現状を考慮して新たな視点を付加した、チェックリストを用意して評価するものや、(b)表示スピードなどの利用者の利便性を重視したもの、(c)登録メンバに対するアンケートによる評価など、に発展させていている。これらの評価手法は、評価値判断の変化や利用者の状況に応じて評価値が変わり、ドメイン毎に柔軟に対応することは困難である。

2.2 発信内容による Web ページ評価手法

ディレクトリの充実や、キーワードを用いた検索技術も日々発展していることからも、Web ページもドメインに応じた発信内容の充実が重要である。Web ページの内容の充実には、対象ドメインごとの発信情報の内容に踏み込んだ評価が必要であり、それらの結果をフィードバックすることで、それぞれの Web ページの価値を高め、完成度が高められる。

発信内容による Web ページ評価手法の、基本的な流れを図 1 に示す。主な手順は、評価の対象ドメインを定め、そのドメインでの評価セットを作成し、評価セットにより Web ページを評価することである。評価セットは、情報発信のための基本となる共通項目と、ドメイン毎の特有項目などのメニュー表示項目、およびそのドメインの情報抽出技術により得られるテキスト情報内に埋め込まれている詳細情報項目からなる。これらにより、ドメイン毎の情報整理を実現する。

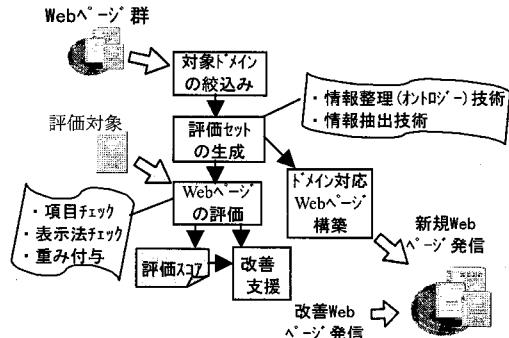


図 1 Web ページ評価手法の基本処理

- 本 Web ページ評価手法の特長は次の 4 点である。
 - 対象ドメインを、カテゴリや Web ページ指定などにより自由に規定できる。
 - メニュー表示等の情報表示項目から、テキスト情報に表現されている詳細情報項目まで、様々な粒度で内容情報の評価ができる。
 - 評価結果のスコア算出に各種の重みを選択付与できる。
 - 評価セットとなる各種の項目情報は、ドメイン毎の知識として蓄積される。

2.3 内容評価の効果

発信項目に基づくメニュー表示項目に加えて、情報抽出技術による詳細情報項目の内容情報による評価と、各内容情報の表示形式(深さ)による評価が行えることにより、主観的・表面的な判断でなく、客観的なスコアを用いて判断でき、改善点が明確に示される。また、対象ドメイン内での独自性の追及や、他ドメインにおける特徴の活用も、評価ドメインをダイナミックに変更することで容易に行える。

3. Web ページ評価手法の予備実験

本評価手法では、評価セットとなる各項目の抽出が重要になる。抽出の基本は以下とする。

ジャンルにまたがる共通項目:複数のジャンルに対して、共通度の高いメニュー項目を Pick-up する。

ドメイン依存の特有項目:対象ドメインに適当な Web ページを複数指定し、それらのドメインに共通度の高いメニュー項目を、共通項目以外で Pick-up する。

詳細情報項目:対象ドメインに適用可能な情報抽出ルールにおいて、情報抽出される項目を Pick-up する。

これらの項目の Pick-up は、自動化処理に向けたツール化を進めている。ここでの予備実験では、人手により Web ページをチェックして項目の Pick-up を行い、以下のような評価セットを用意して評価を行った。

4 種のジャンル(建築、自動車、化粧品、食品メーカー)から、ランキング上位を対象に、主に 7 割以上の出現頻度のある 10 項目を共通項目とした。

共通項目 = 10 項目(新着、リース、会社概要、採用、キャバーン、業績、商品、問合せ、サトニー、メルマガ)

ドメイン依存の特有項目としては、食品メーカーを対象ドメインとして、知的情報収集サービス²⁾で集められた優良トップページ 128 ページに対して、共通項目以外で 5 割以上の出現頻度のある 5 項目 + 全ページを参照して、食品メーカーに必要と判断した 2 項目の計 7 項目をドメイン依存の特有項目とした。

特有項目 = 7 項目(工場見学、トップメッセージ、ショッピング、イメージキャラクター、レシピ、健康、CM)

詳細情報項目としては、新聞記事情報からの企業情報抽出に用いた情報抽出ルールから、11 項目を取上げた。

詳細情報項目 = 11 項目(企業名、資本金、社長、従業員数、住所、郵便番号、Tel、Fax、地図、決算、株価)

これらを評価セットとして、先の優良トップページ 128 ページの評価を実施した。

<予備実験結果>

評価対象において、HTML 間のリンク解析技術を応用したページの人気度ランキング³⁾上位と下位での評価結果を比べたものを以下に示す。

○ 食品メーカーの優良トップページ人気度ランク上位 50 ページに対する各項目の出現率平均

共通項目出現率平均 = 77.8%、特有項目出現率平均 = 52.6%、詳細項目出現率平均 = 72.8%

○ 同人気度ランク下位 50 ページに対する各項目の出現率平均

共通項目出現率平均 = 57.3%、特有項目出現率平均 = 21.9%、詳細項目出現率平均 = 67.4%

予備実験である、今回の食品メーカーの Web ページ評

価では、詳細情報項目に関しては極端な違いは出でていないが、ジャンルにまたがる共通項目およびドメインに依存する特有項目に関しては、20 ポイント以上の明確な違いが出ている。この結果から、評価セットとして採用した今回の各項目は、そのドメインにおいて必要な項目であり、人気度下位のページに対しては、発信項目や内容の示唆が行えることが解る。

<蓄積された言語情報>

評価セット内の各情報項目の抽出において、今回は人手で、表現の揺れや同義語などの統一化処理を行った。この処理により、多種多様な言語情報が蓄積された。特に、共通項目の整理における言語情報に加えて、ドメイン依存の特有項目の整理において、蓄積された言語情報は、各ジャンルの重要な知識となる。

<評価における問題点>

- ◆ **項目名称の扱い:** 予備実験では、人手 Pick-up のため適当な項目名を代表としたが、同じ内容での表記の統計などによる判断が必要。
- ◆ **対象リンク範囲の指定:** 今回の評価に関しては、トップページから同じサイトと判断できる範囲で扱ったが、今後、処理の自動化に際して検討が必要。
- ◆ **pdf やイメージデータへの対応:** 今回の評価では全て対象外としたが、この形態での情報発信も行われているため今後検討が必要。

4. おわりに

ドメインに応じた評価によって Web ページの完成度を高めることは、情報発信者にとっても利用者にとってもメリットが大きい。

また、Web ページ評価によって蓄積される評価セットの情報は、ここで述べた評価だけでなく、ツール化によって、新規 Web ページを構築する際の内容項目支援に活用できる。さらには、評価セットとして、情報項目を整理する際に得られた言語情報は、これまで、専門的知識を必要としていた、ドメイン単位のオントロジーの構築に発展させられる。

謝辞 本手法に関して議論していただいた、富士通(株)ネットワーカサービス本部インターネット部、および富士通研究所ドキュメント処理研究部の方々のご協力に感謝いたします。

参考文献

- 1) J. Alexander, M. Tate: Evaluating Web Resources
<http://www.science.widener.edu/~withers/webeval.htm> 1996.8
- 2) 富士通㈱、ジー・サチ: 「ValueContents」
<http://pr.fujitsu.com/jp/news/2001/12/6-2.html> 2001.12
- 3) 津田、鶴飼、三末: Web ディレクトリのためのページメタデータの自動付与の試み、情報学シンposium 2002.1