

アンカー関連テキストを用いたWebページ分類

学籍番号：90173024 西田研究室 大坪 正典

1 はじめに

2005年現在、Googleが持つデータベースには80億ものWebページがある。膨大な情報の中からユーザが要求する情報を見つけるため、Yahoo!やExciteなどのようなWebページをカテゴリ分類しているポータルサイトの需要が高まっている。しかしこれらのポータルサイトのカテゴリ分類は人手でなされているため、80億ものページを分類することはできない。そこで、Webページを解析し自動で分類しようとする研究が行われてきた。

従来の方法では、分類対象のページ(以下、ターゲットページ)を分析してWebページを自動分類していた。しかしながらターゲットページ中にはそのページを説明するような情報は少ない。そこで、ターゲットページを用いるのではなく、そのページにリンクしているページ(以下、リンク元ページ)を用いて分類する方法が近年注目されてきた。Gloverらはリンク元ページのアンカー前後25単語を用いてWebページ分類を行っている。

しかしながら、リンク元ページを用いたこれまでの研究は、フォーマットに関わらず常に同じルールでアンカー周辺テキストを抽出している。これは、リンク元ページのフォーマットが均一であることを前提としている。そのため、BBSなど様々なスタイルで書かれたWebページ全体に適用するには無理がある。その改善方法として、WebページのDOM構造を見ることが挙げられる。そこで本研究では、DOMレベルの文書構造からアンカーに関連するテキスト部分(以下、アンカー関連テキスト)を推定することを提案する。本研究の目的は、アンカー関連テキストを分類に用いることで、より精度の高い自動分類を目指すことにある。

2 アンカー関連テキスト

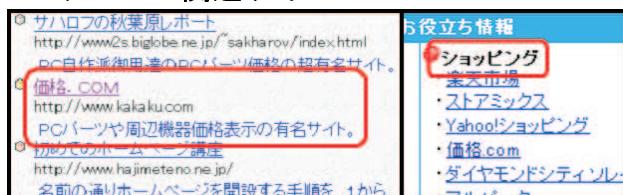


図1: LSPとUSPの例

アンカー関連テキストの抽出方法を決めるにあたり、Hungらの調査結果を用いた。彼らはアンカー関連テキストを大きく”Local Semantic Portion(以下、LSP)”と”Upper-level Semantic Portion(以下、USP)”の2種類に分けた。図1にLSP(左)とUSP(右)の例を示す。いずれもアンカーテキストは”価格.com”である。LSPはアンカーテキストを含むアンカー周辺テキスト部分であり、文書構造上アンカーノードと同レベルにあるものを指す。また、USPはアンカーに接していないテキスト部分で、文書構造上アンカーノードよりも上位レベルに位置するものを指す。Hungらの調査は、LSPについて333ページ、USPについて100ページの計433ページに対して行われ、この調査に基づいてアンカー関連テキストの抽出方法を決めた。以下に、アンカー関連テキストの抽出方法を挙げる。

Local Semantic Portionの抽出方法

- アンカーが段落内、ブロック内にあるとき
段落中に改行がなければ段落全体を抽出し、改行があれば形式に応じてアンカーを含むテキスト部分を抽出する。
- アンカーがリスト内にあるとき
アンカーを含む項目全体を抽出する。
- アンカーがテーブル内にあるとき
アンカーを含むセルの両隣を調べていき、他のアンカーを見つけるまで拡張していく。他のアンカーが見つかったら、その間のセルのテキストを抽出する。

Upper-level Semantic Portionの抽出方法

- タイトル、ヘッダーの抽出
ページタイトルと、アンカーよりも前にあるヘッダーを抽出する。ただし、同じヘッダーがある場合は最も近くにあるヘッダーを抽出する。
- テーブルヘッダーの抽出
アンカーがテーブル内にあるとき、テーブルヘッダーがあればテーブルヘッダーを抽出する。テーブルヘッダーがない場合は形式に応じてテーブルの1段目を抽出する。

3 評価用システム

アンカー関連テキストの有用性を確かめるため、Webページの分類精度を求めるシステムをJavaにより実装した。本システムの流れを図2に示す。

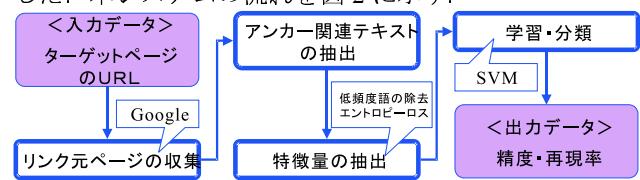


図2: システムの流れ

ターゲットページのURLをシステムに渡すと、Googleのリンク検索機能を用いてリンク元ページを収集する。次に、リンク元ページよりアンカー関連テキストを抽出し、低頻度語を除去して単語ベクトルを得る。各単語ベクトルのエントロピース¹を計算し、エントロピースの大きいものを特徴量として抽出する。最後に特徴量をSVMに学習させ、テスト用データを分類し、精度・再現率を算出する。

4 おわりに

本研究では、Webページの自動分類精度を上げることを目的とし、DOM構造を考慮して抽出したアンカー関連テキストを用いてWebページを分類する手法を提案した。アンカー関連テキストの抽出方法は、Hungらの調査結果に基づいている。また、アンカー関連テキストから特徴量を抽出し、SVMを用いてWebページ分類を行うシステムを実装した。今後は、実装したシステムを用いて評価実験を行い、本手法の有用性を検証する。

¹ (事前エントロピー) - (事後エントロピー) で求められる値。正データ・負データの両方に頻出する単語はエントロピースが小さくなる。つまり、エントロピースの大きいものを特徴量とすることでSVMの分類精度は上がる。