

Twitter における不快なつぶやきの検出

庄司 茜

ソーシャルネットワークサービスの代表格である、Twitter では短い文章のやりとりなどがなされており、他のユーザをフォローすることで、そのユーザの投稿を常に閲覧できる状態になる。従って、あえて特定の宛先に送らず、単なる投稿として質問文を投げかけた結果、多くのユーザの目に留まり、結果的に様々な回答が得られる場合がある。これは、広範囲に情報を発信するだけでなく、広範囲から情報が得られる有用なコミュニケーション手段と考えられるが、反面、ふとしたことで軋轢を生みやすいことも事実である。このようなトラブルを防ぐため、本研究では、不快なつぶやきのみをあらかじめ検出することで、Twitter 上でのコミュニケーションをより円滑にする基盤となる手法を提案した。提案にあたり、不快なつぶやきの傾向について、調査・分類を行った。調査に基づき、非難、自虐・自慢、わいせつの3グループに分類した。本研究では、3種の内、「非難」、「自虐・自慢」が明確な手がかり語が多く得られやすいと考え、これらを「不快なつぶやき」として扱った。予備調査の妥当性を検証するため、調べたカテゴリ定義に基づき、2名の被験者を用いて、双方が提供する「不快なつぶやき」の判定についてどれだけ一致するかを検証した。結果、不快さを感じる確率に関しては、それぞれの収集方法である程度の差が認められた。提案手法を実装するために、ユーザがタイムラインに反映しかねると判断したつぶやきとして、3種類のサービスからつぶやきを学習データとして収集した。分類には、SVM ライブラリ的一种である LIBSVM を用い、つぶやきデータの形態素解析には MeCab を用いた。実験では、SVM による2値分類において、正例データに Web 上で自動収集した愚痴や不満のつぶやき、負例データにパブリックタイムラインから自動収集した日本語のつぶやきデータを暫定的に採用した。素性には、学習データのつぶやき中に現れる全ての品詞(1)、名詞(2)、動詞(3)、形容詞(4)、名詞・動詞・形容詞の組み合わせ(5)をそれぞれ用い、5分割の交差検定を行い正解率を評価した。正解率の評価尺度としては、分類の正確さ(classification accuracy)を採用した。正例データには、関連サービス3種から3分の1ずつランダムに得たつぶやきデータ1,000件、負例データには、パブリックタイムラインから得た日本語のつぶやきデータのうちランダムに得た1,000件、合わせて2,000件を用いた。結果から、名詞・動詞・形容詞の内容語を素性とすることで、パブリックタイムラインから獲得したつぶやきと、3種類のつぶやき収集サービスから獲得したつぶやきが、7割程度の精度で分類できることが明らかとなった。この愚痴や毒舌のサービスを元に訓練データを収集した場合と、先行研究に用いられた誹謗中傷を元に収集した場合とを、比較したところ、正確さと再現率は低下したが、精度はわずかに向上した。今後の方針としては、アノテーションマニュアルの精緻化や、クラウドソーシングサービスを用いたアノテーションにより、人手によって判定したデータを用いた評価を行う予定である。また素性についても、特徴素選択により素性を絞り込む効果などを検証していく。

(指導教員 関 洋平)