

ソーシャルメディアの大規模なユーザインタラクションの分析に基づく

顔文字分類と予測に関する研究

A research of classifying emoticons and estimating sentiment of Japanese text based on the large-scale analysis of user interaction on the social media

河津 裕貴^{*1} 丸井 淳己^{*1} 榎 剛史^{*2*1} 森 純一郎^{*1} 坂田 一郎^{*1}
 Hirotaka KAWAZU Junki MARUI Takeshi SAKAKI Junichiro MORI Ichiro SAKATA

^{*1} 東京大学 Tokyo University ^{*2} 株式会社ホットリンク Hottolink Inc.

Recently, research about extracting opinion from social media has become increasingly important. Distant supervision is one of the approaches of sentiment analysis, using indirectly expressing sentiment, like emoticon, as labels for automatically classifying the sentiment of the messages. In this paper, we extend this approach for Japanese text in which there is a wide variety of emoticons unlike alphabet text.

1. はじめに

ソーシャルメディアではユーザ間のインタラクションが顕著であり、ユーザの率直な意見や反応が表出している。この特性に注目しソーシャルメディアから感情分析を用いた意見抽出等を試みる研究が多々なされている[1]。またソーシャルメディアで用いられる短文テキストにおいては、ユーザの感情や心境を表現する手段として「顔文字」が頻繁に用いられる。そこで顔文字をテキストに付加された感情ラベルと捉え感情推定を行う研究が近年行われている[2]。従来の研究は主に英語の文を対象としているが、アルファベットのテキストで用いられる顔文字は限定的であるのに対し、日本語テキストではユーザの感情や心境を表現する多種多様な顔文字が利用されている。本研究ではソーシャルメディアにおける日本語テキストの大量の顔文字を対象に、顔文字の自動分類による感情ラベルに資する情報の抽出、および顔文字を利用した短文テキストの感情推定の手法の確立を目的とする。

2. 提案手法

本研究は顔文字ラベルを利用した教師あり学習による感情推定を、大量の顔文字ラベルがある大量データに適用できるように拡張する事が目的である。Twitterのデータを利用し、まず大規模なユーザの書き込みデータを用いたクラスタリングによって分類を行い、次に本手法による顔文字分類を用いて NaiveBayes 分類器による感情推定を行う。提案手法の構成は 1)クラスタリング、2)顔文字のラベル表現の抽出、3)顔文字を含む書き込みから顔文字ラベルを基にした訓練データの作成、4)NaiveBayes 分類器による感情推定となる(図 1)。

1)では、まず分散表現モデルを用いて各顔文字に対応する単語ベクトルを作成する。分散表現モデルの実装は word2vec を用いる。次に作成したベクトル群を教師なし学習である K-Means クラスタリングを用いて分類する。クラスタの数はクラスタリングの評価関数である Davies Bouldin Index を計算し比較する事で決定する。

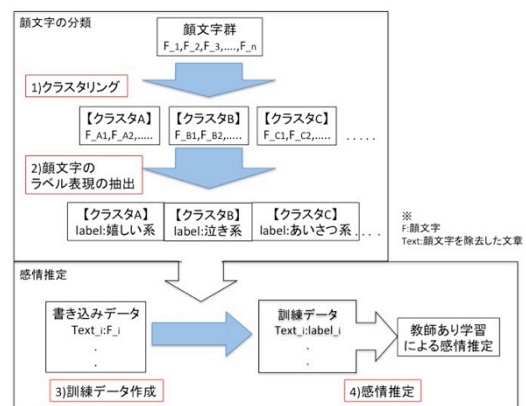


図. 1 提案手法の構成

2)では、分類された顔文字がどのような傾向を持つのか把握するためのデータとして、ユーザの書き込みデータにおいて顔文字と共に使用されている単語を抽出する。抽出する基準として、(方法 1). 出現回数の多い単語 (方法 2). TFIDF 値の高い単語 (方法 3). 総合出現回数に対する各クラスタでの出現割合の高い単語の 3 種類を比較する。

3)では、まず顔文字を含むユーザの書き込みデータの集合について、各データから顔文字と顔文字を除いたテキストのペアを抽出する。顔文字の分類結果を用いて、抽出した顔文字に対応するクラスタをテキスト感情推定の正解ラベルとし、残りのテキストから感情推定に用いる特徴量を生成する。特徴量はテキストを形態素解析により形態素に分割し、それらを Bag-of-Words モデルで表す。ユーザの書き込みデータの特徴量と顔文字ラベルで表し、これらを教師あり学習に用いる訓練データとする。

4)では訓練データを使って教師あり学習である NaiveBayes 分類器を作成する。本研究の NaiveBayes 分類器では特徴量を単語とし、入力された特徴量 F が各クラスに属する確率を式 (1),(2)の様に計算し、最も高い確率となるクラスを分類結果として出力する。ここで C_j はクラス j , F_i は各特徴量, n は単語の種類数, x_{ij} はクラス j における単語 i の出現回数を表し, $p(F_i|C_j)$ は特徴量 F_i がクラス j に属する確率を表す。

$$p(F_i|C_j) = \frac{x_{ij} + 1}{\sum_{i=1}^n (x_{ij} + 1)} \quad (1)$$

$$p(C_j|F_1, \dots, F_n) = p(C_j) \prod_{i=1}^n p(F_i|C_j) \quad (2)$$

3. 実験

3.1 分類

この章では顔文字の自動分類と感情ラベルに資する情報の抽出を行う。2個から29個の各クラス数でクラスタリングを行い、クラスタの評価関数である Davies Bouldin Index により評価したところ、5個と14個に分割する場合がそれぞれ良い結果となったため、この2つを分類結果とした。5クラス分類の結果を、クラス毎の顔文字の一覧と共に共起する単語の抽出結果、及び14クラス分類結果との比較から、喜びを表す「強い Positive」、あいさつを表す「弱い Positive」、泣く様子を表す「強い Negative」、悲しみや焦りを表す「弱い Negative」、及び「Neutral」とした。表1に顔文字の分類結果及び共起する単語の一部を載せた。

表1. クラスタ毎の顔文字と抽出された単語の例

クラスA	クラスB	クラスC	クラスD	クラスE
(´·´)	(´_´)	^(´o´)/	(^^)	(´·ω´)
(´Д´)	(T_T)	((o(*^▽^*)o))	(*^*)	(´▽´)
(´·ω´)	(:)	(*´ω`*)	(´▽`)/	(´·ω´)
(´·ω´)	\(:;▽;)/	(*´▽`*)	(^-)	(´ω´)
(´▽´)	(´·ω´)	(´q´)	(´o´)	(´▽´)
(´^´)	(´;ω;´)	(*´▽`*)	(^-)/	(≥▽≤)o
(´Д´)	(´;ω;´)	¥(/▽//¥)	(´O´)	☆*..
(´·ω´)	(´;ω;´)	^(´O´)/	♪(´▽´)	..*☆
(((((´Д´))))))	(T-T)	(´ω´)	o(´▽´)o	(´·ω´)
(*´*)	┌┐┌O	(´▽´)	(´^´)	^(´ω´)/
怖い	悲しい	たのしみ	こんにちは	眠い
不安	泣く	最高	はじめまして	がんばり
苦手	涙	楽し	おはよう	なるほど
きつい	寂しい	うれしい	こんばんは	全力
悪い	泣	大好き	お疲れさま	萌え

AとBは Negative を表す単語が、CとDは Positive を表す単語が共起している。Eは共起する単語に統一した傾向がなかった。

3.2 感情推定

この章では前章で得られた5クラス及び14クラスの顔文字分類を用いて、顔文字ラベルを利用した教師あり学習による感情推定を行う。まず顔文字クラスをそのまま用いて多クラス推定する分類器、及び Positive, Negative, Neutral の3クラス推定を行う分類器を作成した。まず多クラス推定について、5クラス分類を用いた場合正答率が約33%、14クラス分類を用いた場合正答率が約27%となった。ランダム・ゲッシングよりは高い精度が出ているものの、難しいタスクであると言え、その理由を調べる為に5クラス分類器における誤分類先も含めた分類結果をまとめたマトリクスを作成した。表2から Positive であるクラスAとB、及び Negative であるCとDがお互いに誤分類しやすい事が分かる。そこでクラスAとB、及びCとDを統合して、Positive, Negative, Neutral の3クラス推定を行う分類器を作成

表2. 5クラス分類器における分類結果

実際のクラス	A	B	C	D	E
Aと推定された割合	0.406	0.292	0.180	0.171	0.225
Bと推定された割合	0.241	0.353	0.114	0.103	0.126
Cと推定された割合	0.133	0.134	0.288	0.224	0.215
Dと推定された割合	0.118	0.14	0.295	0.388	0.225
Eと推定された割合	0.102	0.08	0.122	0.114	0.208

し精度を算出したところ約57%の正答率となった。

次に精度の改善のため、特徴量を変化させて精度を比較する。文末から一定の距離(単語数)にある単語のみを特徴量として訓練する学習器を作成し、考慮する最大距離毎に精度を算出し、図2にまとめた。表から考慮する単語の範囲が短すぎるとテキストの感情を推定出来ないが、逆に範囲が広すぎても推薦精度が落ちる事が分かり、感情推定を行う際は全単語を考慮するのではなく、単語の位置により足切りをした方が良い推定が出来る事を示唆している。




図2. 考慮する単語の最大距離に対する5クラス分類器の精度

4. まとめ

本研究は日本語テキストで利用されている多種多様な顔文字の分類をテキストの感情推定に利用するという着想から、ソーシャルメディアにおける日本語テキストの顔文字を対象に、顔文字の自動分類による感情ラベルに資する情報の抽出、および顔文字を利用した短文テキストの感情推定を行う事を目的とした。大規模なデータ上の膨大な顔文字の分類に対応できる手法を構築でき、また提案手法を用いた顔文字ラベルを利用した多クラス感情推定、及び Positive, Negative, Neutral の感情極性推定のベースラインを示した。提案する手法のベースラインの確認に焦点を当てたため、精度の向上には改善の余地があると思われる。今後の展開として、学習器のアルゴリズムの変更や特徴量設計の工夫による精度の改善等がなされれば、筆者の幸いとすることである。

参考文献

[Thelwall 2012] Thelwall, Mike, Kevan, and Georgios.: Sentiment strength detection for the social web, Journal of the American Society for Information Science and Technology, 63.1, 2012.
 [Go 2009] Go, Alec, Richa, and Lei: Twitter sentiment classification using distant supervision, CS224N Project Report, Stanford, 1-1, 2009.