

# Twitter ユーザの属性別感情推定の検討

岩朝 史展      松本 和幸      吉田 稔      北 研二

徳島大学 工学部 知能情報工学科

c501206003@tokushima-u.ac.jp

{matumoto, mino, kita}@is.tokushima-u.ac.jp

## 1 はじめに

インターネット上の掲示板、ブログ、SNSには様々な属性のユーザが記事を投稿しており、それらの記事には各自の仕事や嗜好などに関する内容が含まれている。属性別でそれらを見たとき、集団的傾向が存在しておりマーケティングなどの分野で応用されている [1].

また、人間とコンピュータの円滑なコミュニケーションを実現するためには高度な感情推定技術が必要となる。このため電子メールやブログ、Twitter[2]、Facebook[3]などの日常的に用いるテキストを対象に書き手の感情を推定する必要がある。

本研究では、感情推定の対象として Twitter 上の情報に焦点を当てる。Twitter は、140 文字以内という文字制限があり、短い文章を気軽に投稿することができるサービスである。また、スマートフォンの普及により、時間や場所を問わず投稿することができる。そのため、日常的な会話のように、言葉によって個人のリアルタイムな感情が反映されやすいという特徴がある。また、Twitter には「おすすめユーザ」というサービスがあり、フォローしているユーザに類似した属性のユーザが紹介されるようになっている。これはユーザ属性に存在する話題傾向を利用している。そのため属性別ユーザ集合で共通の話題が存在し、それに対する共感などの感情表現が属性別の特徴として表れると考えられる。

本研究では、ユーザ属性が文章や単語による感情表現に特徴として表れるという仮定から、属性別に感情推定モデルを作成する手法を提案する。作成した感情推定モデルを用いて評価実験とその考察をおこない、属性傾向が感情推定の成否に与える影響についての分析を検討する。

## 2 既存研究

既存の研究として、Twitter ユーザの利用度傾向ごとに感情表現を調査している研究 [4] がある。この研究においてユーザの利用度ごとに感情表現に特徴があることや、感情表現の時系列変動が示されている。

また、Twitter におけるリプライを用いて感情推定する研究 [5] がある。人の人に対する推測能力に着目し、ユーザに対する反応であるリプライを利用することで、単独のツイートのみでは推定が困難な場合の感情推定を実現している。

属性に関する研究として、個人の属性が人間観や対人感情に与える影響を調査した研究 [6] がある。この研究では、属性別に使われる特性語の傾向や、対人感情の好感度を数値化している。

さらに、Twitter の情報を用いユーザの職業を推定している研究 [7] がある。ユーザの投稿内容や自己紹介文を素性とし、職業判別を行っている。

これらの研究から、Twitter における感情推定やユーザ属性に対する傾向利用の有効性が示されている。本研究では、それらの観点から Twitter ユーザの属性別感情推定を検討する。

## 3 提案手法

本研究では、Twitter から収集したツイート本文を感情推定の対象とする。属性別感情推定モデルの作成の大まかな手順は以下ようになる。また、図 1 に提案手法の流れを示す。

- (1) Twitter から属性で分けた著名人ユーザごとにツイートを収集
- (2) 人手によるラベル付与
- (3) ツイートからの素性の抽出および機械学習手法を用いて属性別感情推定モデルを作成

以下、それぞれのフェーズについて詳細を述べる。

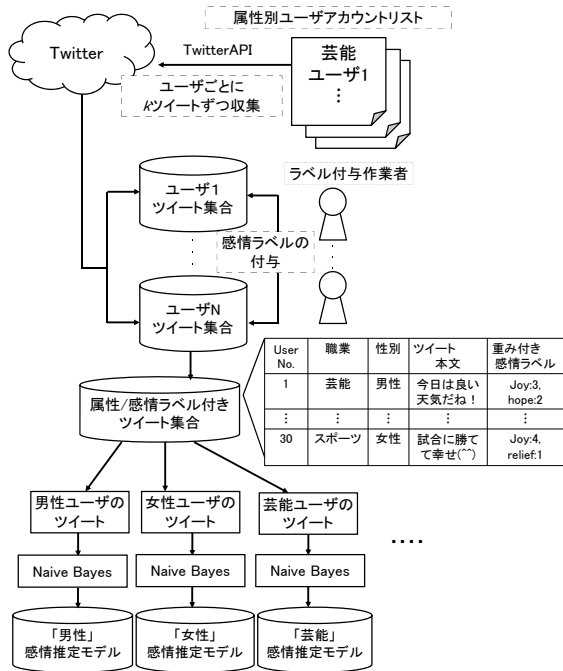


図 1: フローチャート

### 3.1 学習データ

表 1: ユーザ属性の分布

	スポーツ	アーティスト	芸能
男性	5	5	5
女性	5	5	5

表 2: ラベル付けの例

感情ラベル	ツイート	属性
嬉しい	あの時はナイスゲームでしたね!	男性スポーツ
希望	お疲れさまでした!ライブまで休んで万全な状態で会いましょう!	男性芸能
悲しみ	雨降ると服のコーディネートの予定狂いますよね。	女性アーティスト
不安	どこの道も大渋滞... サッカー間に合うかな...	女性スポーツ

表 3: 各感情のデータ数

嬉しい	希望	愛	安心	受容
6020	2135	487	67	15
怒り	憎しみ	悲しみ	恐れ	驚き
150	71	921	78	425
不安	感情無し	感情不明		
301	943	46		

本研究では、TwitterAPI[8]を用いて Tweet データを取得する。使用するデータとして、属性が判断できる著名人のユーザアカウント 30 人分を対象とし、それぞれ 300 ツイートずつ取得した。職業属性としてスポーツ、音楽アーティスト、芸能の 3 種類、性別属性として男女 (2 種類) の計 5 種類を対象とした。職業属性は、Twitter での感情表現が豊かであるという理由から選んだ。また、職業属性と性別属性は重複しており、それぞれのユーザは表 1 のように分布している。感情の種類として、ポジティブが、「嬉しい」、「希望」、「愛」、「安心」、「受容」の 6 種類、ネガティブが、「怒り」、「嫌悪」、「悲しみ」、「恐れ」、「驚き」、「不安」の 5 種類、その他に、「感情無し」、「感情不明」の 2 種類の計 13 種類とした。

本研究では、ラベル付けを 20 代の作業員 4 人による人手で行い、作業員の過半数が同じ感情ラベルを付与した場合のラベルをデータに付与した。そのため複数のラベルを有するデータが存在している。ラベル付けの例を表 2 に示す。表 3 に各感情ラベルごとの Tweet データ数を示す。

### 3.2 使用素性

Tweet 本文から抽出可能な機械学習により学習させる感情推定の素性として形態素や、単語 N-gram[9]などが考えられる。本研究では単語の意味的要素を考慮するため、名詞を素性として用いた。これにより、属性別の単語の傾向を考察する。感情の表現に有効と考えられる、形容詞や動詞の場合、活用のされ方や否定、打消しによる影響が大きいと考えられるため、本稿では扱わない。

### 3.3 Leave-one-out 交差検証

推定結果の評価方法としてデータに対して Leave-one-out 交差検証を使用する。1 つのユーザのみを評価データとし、残りすべてを学習データとする。すべ

てのユーザに対して検証を繰り返し、それぞれの評価結果の平均値を全体の推定値とする。

### 3.4 学習方法

機械学習の手法として、ナイーブベイズ法を使用する。文  $d$  に含まれる単語を  $(w_1, \dots, w_n)$  とする。文  $d$  に属するカテゴリを  $c$  とするとき、事後確率  $P(c|d)$  を最大化するカテゴリ  $\hat{c}$  を求めればよい。

$$\begin{aligned} \hat{c} &= \arg \max_c P(c|d) \\ &= \arg \max_c P(c|w_1, \dots, w_n) \\ &= \arg \max_c P(w_1, \dots, w_n|c)P(c) \end{aligned}$$

本稿において、 $c$  をそれぞれの感情ラベル、 $d$  を素性の集合に当てはめる。しかし、 $P(w_1, \dots, w_n|c)$  は、単語の種類とその組み合わせを考えると膨大な値になる。そこで、各カテゴリのもとで単語は独立に生起すると仮定する [10]。

## 4 実験

### 4.1 実験方法

表 4: 削減後のデータ数

嬉しい	希望	愛	悲しみ	驚き	不安
1037	816	217	816	322	278

提案手法の有効性を確かめるため、計算機実験を行った。ラベルの偏りにより受ける機械学習の影響を考慮しクラスの削減、データの削減を行った。感情無し、感情不明は判別が難しいため除外した。データ数が上位の 6 ラベル以外を削減し、特にデータ数の多い「嬉しい」、「希望」を各ユーザごとに 20 ツイートまでとした。複数のラベルが付与されたデータは対象外とする。6 クラスのラベル数は表 4 のようになった。データ取得におけるラベルの偏りは今後の課題とする。

Leave-one-out 交差検証を使い、全体で学習した結果と属性別で学習した結果を比較し評価する。全体データは、実験で使う属性別データを全て合わせたものである。ナイーブベイズ分類法には、Python の機械学習ライブラリ scikit-learn[11] を用いた。

### 4.2 実験結果

推定精度の評価指標は、

$$\text{推定精度} = \frac{\text{正答であったツイート数}}{\text{対象とするツイート数}}$$

とする。正答は付与ラベルと推定結果が一致していることを示す。と表 5 に実験で得られた全体、属性別の推定精度を示す。さらに、属性組み合わせの推定精度を表 6、属性組み合わせの全体モデルでの推定精度を表 7 に示す。

表 5: 全体、属性別での推定精度

	全体	属性別
スポーツ	54.59%	54.76%
アーティスト	50.09%	45.96%
芸能	48.13%	42.50%
男性	49.67%	45.42%
女性	52.20%	50.65%

表 6: 属性組み合わせの推定精度

	スポーツ	アーティスト	芸能
男性	51.80%	39.13%	37.28%
女性	45.35%	45.12%	41.12%

表 7: 属性組み合わせの全体モデルでの推定精度

	スポーツ	アーティスト	芸能
男性	57.84%	47.90%	41.68%
女性	49.75%	52.29%	54.58%

結果として、全体モデルを用いた推定精度の方が高い結果となったものが多かった。また、属性組み合わせのモデルでは、データ数が少なく傾向が出なかった。しかし、ユーザ別で見たとき、表 8 のように属性別で学習した結果の方が高くなったユーザが確認できた。

表 8: ユーザ別での推定精度

ユーザ No.	属性組み合わせ	全体	職業属性	性別
1	男性スポーツ	60.60%	65.65%	61.61%
2	女性スポーツ	40.90%	47.72%	44.31%
3	女性アーティスト	60.65%	57.37%	65.57%
4	女性芸能	57.47%	43.67%	63.21%

## 5 考察

表 9: ツイート例

属性	ツイート
男性スポーツ	チケットを早々にゲットしていたし、楽しみにしていたのですが、残念でした！
女性スポーツ	あまりに体調の変化が無く、本当に妊娠してるのか不思議な感じ (; - O -)

全体モデルで負例に判断されたが、属性別モデルでは正例になったデータが多く存在した。そのツイート例と属性組み合わせを表9に示す。それは、属性別の単語の傾向が一致していた場合に推定結果として表れるものがあるということが分かる。しかし、全体データを使い推定した方がよい結果が多数を占めたため、本手法の優位性はあまり示すことができなかった。

課題として2点挙げられる。1つ目に、詳細な属性別の傾向を抽出することである。そのためには、属性間の類似性や相違性を見つける必要があり、さらに多くの属性が必要になると考える。2つ目に、同属性においてより細かな属性を考慮することで、感情推定に関連が強い属性を見つけることが考えられる。

さらに、属性と、ツイート上で出現する話題(トピック)には、ある程度相関が有る。トピック抽出をおこなうことにより属性別に特徴語の重みを計算することが出来るのではないかと考える。

## 6 おわりに

本研究では、Twitter上の文章に対して、属性別に感情推定モデルを作成する手法を提案した。今後は、属性の傾向抽出や、属性の傾向により重み付けした感情推定モデルの検討を行う。

## 謝辞

本研究の一部は、科学研究費補助金(基盤研究(C)15K00425, 若手研究(B)15K16077)の補助を受けて行った。

## 参考文献

- [1] 石野正彦, 八巻直一, 市川照久, 水野忠則: “顧客の嗜好に合った商品推奨方法の提案” 情報処理学会, Vol.2005-IS-92, pp.37-42, 2005.
- [2] twitter, <http://twitter.com/>
- [3] Facebook, <https://ja-jp.facebook.com/>
- [4] 竹富厚美, 久野雅樹: “Twitterにおけるユーザーの特徴と感情表現” 研究報告自然言語処理, Vol.2014-NL-219, No.1, pp.1-4, 2014.
- [5] 堀宮ありさ, 坂野遼平, 佐藤晴彦, 小山聡, 栗原正仁, 沼澤政信: “Twitterにおける発話者へのリプライを用いたユーザー感情推定手法” DEIM Forum, F2-1, 2012.
- [6] 金順暎, 廣瀬慧, 今田美幸, 吉田学, 松尾真人, 藤井竜也: “個人属性が対人認知構造に及ぼす影響について” 電子情報通信学会技術研究報告.HCS, pp.97-102, 2012.
- [7] 榎剛史, 松尾豊: “ソーシャルメディアユーザーの職業推定手法の提案” 知能と情報(日本知能情報フェジ学会誌), Vol.26, No.4, pp.773-780, 2014.
- [8] TwitterAPI, <https://apps.twitter.com/>
- [9] 小川拓貴, 松本和幸, 任福継: “単語 1-gram を用いた感情推定”, 全国大会講演論文集 第72回(人工知能と認知科学), pp.365-366, 2010.
- [10] 北研二: “確率的言語モデル”, 東京大学出版会, 1999.
- [11] scikit-learn, <http://scikit-learn.org/stable/>