原著論文

Twitterを用いたニュース記事における 読み手の感情推定手法の提案と アクセス解析への応用

本間 幸徳, 萩原 将文

慶應義塾大学 理工学研究科

Estimation of Reader's Emotion to News Articles Using Twitter and its Application to Access Analysis

Yukinori HOMMA and Masafumi HAGIWARA

Keio University, 3-14-1 Hiyoshi, Kohoku-ku, Yokohama, Kanagawa 223-8522, Japan

Abstract : In this paper, we propose an estimation of reader's emotion towards news articles using Twitter, and apply this method to the access log analysis of a news website. The proposed estimation method is divided into 3 steps: 1) The system collects tweets about news articles from Twitter. 2) The system tags each tweet with an emotion. 3) The system estimates the reader's emotion towards the news articles using tweets obtained in the second step. The system can tag an article with one or more of 11 emotions (anger, dislike, excitement, fear, like, joy, relief, sadness, shame, surprise, nothing). The experimental result shows the effectiveness of this method using Twitter for estimating the reader's emotion. For access log analysis based on emotion, we collected the access log of a self-produced news website. The system tags each collected news article with emotions using the proposed method. We analyzed the access log by using Hidden Markov model (HMM). As the result of access log analysis, we obtained some interesting findings such as that the users tend to read the article which causes excitement or surprise at the start.

Keywords : Twitter, Emotion Tagging, Access Log Analysis

1. はじめに

感情は人間の意志決定に対して大きな影響を与えている [1]. これまで心理学や人間工学において、感情が人間の行動に対して与える役割についての研究がなされてきた [2, 3]. 近年では、感情が感性工学や自然言語処理分野で工学的に扱われるようになってきている [4-7]. ロボットやシステムと人間のインターフェースの観点において、感情を考慮することは相互のコミュニケーションに非常に重要と考えられる.

言語の中でも、特にニュース記事は読み手に感情的な反応を促し得る事実を含んでいる [4]. そのためニュース記事を利用した感情推定の研究は数多い. 例えば、熊本ら [5] はニュース記事から喜怒哀楽の感情を推定する手法を提案している. また Kozareva ら [6] は、感情語との相互情報量から記事の見出しの感情を推定する手法を提案している. Plaban ら [7] はニュース記事に対してアンサンブル手法を用いることで、複数の感情に分類させる手法を提案している.

以上の研究に共通する特徴として、記事情報のみから感情推定を行なっている点が挙げられる. しかし、より正確な感情推定のためには読者の意見を直接取得することが考えられる. 近年はインターネットの発達により、ニュース記事を読んだユーザの意見が容易に獲得できるサイトが公開されている. Twitter [8] などのソーシャルネットワークサービスも

その一つであり、投稿された意見は感情推定に有効であると考えられる.

感情推定手法の提案に留まらず、応用タスクに取り組む研究もされている. 高野ら [9] は感情推定手法を提案するだけでなく、ニュースサイトのアクセス解析に取り組んでいる.

アクセス解析とは、Web におけるユーザの閲覧履歴を解析し、ユーザの嗜好を抽出することで利便性の高いウェブサイトを構築しようとする試みである [10]. 高野らは、ユーザがニュースサイトを閲覧したログと、記事から推定される感情を利用してアクセス解析を行った. 感情がユーザの次に見る記事に影響を与えていることを示したものの、単純な N-gram モデルを用いた解析にとどまっている.

以上を踏まえて、本論文では以下2つの課題に取り組む.

(1) Twitter を用いた感情推定手法

(2) 隠れマルコフモデルを利用したアクセス解析

本論文では、Twitter から取得する意見を参考にする感情推定手法を提案する. 読者の意見のみを感情推定の対象とすることで、既存の研究に比べてより読者の感情を意識した感情推定を目指す. さらに提案した感情推定手法を用いて、隠れマルコフモデル (HMM) によるアクセス解析を試みる.

HMM は N-gram とは異なり、最尤推定により最適解が求められる. そのため、精度の高いアクセス解析が期待できる.

以下、第2章で提案する感情推定手法について、第3章でアクセス解析について述べる. 第4章で評価実験を説明する. 第5章の結論をまとめとする.

2. 感情推定手法

提案手法ではTwitterを利用した感情推定を行う。Twitterは、ツイートと呼ばれる140文字以内の短い文章を投稿して他者と共有するソーシャルネットワークサービスである。ツイートとしてニュース記事に対する意見は数多く投稿されている。そこでこれらのツイートを感情推定に利用することで、より精度の高い感情推定が考えられる。

図1に提案手法の大きな流れを示す。入力記事に対して、ツイート収集、ツイートの感情推定、記事全体の感情推定という処理により推定された感情を出力する。

ツイートの感情推定はさらに前処理、極性判定、感情推定の3ステップに分かれている。処理の詳細を図2に示す。極性判定、感情推定の各ステップでは後に説明する極性関連語辞書、感情関連語辞書を用いる。

2.1 記事入力

ニュース記事のタイトルを入力とする。

図1 提案手法の流れ

図2 ツイートの感情推定処理の詳細

2.2 ツイート収集

Twitterからニュース記事に関するツイートを収集する。入力記事のタイトルをTwitterAPIで検索し、ツイートを収集する。

2.3 ツイートの感情推定

感情の種類には様々な議論がされている[11, 12]。中でも中村[12]は言語表現の観点から「喜, 好, 安, 怒, 哀, 怖, 厭, 恥, 昂, 驚」に分類している。本研究では言語を扱うため、この分類法を採用し、さらに無感情を加え11種類の感情を扱うこととする。

ツイートは前処理、極性判定、感情推定の3ステップで処理され、11種類の感情のいずれかに分類される。

2.3.1 前処理部

ツイートはまずMecab[13]により形態素解析が行われ、単語単位に分割される。ここでツイート中の形容詞、名詞、感動詞を抽出する。さらにツイート発信者の意見をより正確に抽出するために、ニュース記事のタイトルに含まれる単語は除外される。

例えば「地球に似た惑星確認=生命存在の可能性-NASA」という記事に対する「凄い! 本当に生命が存在したら面白いな!」というツイートからは、単語列「凄い、本当、面白い」が処理の対象となる。

2.3.2 極性判定部

ツイートの感情推定部では、徳久ら[14]の手法を参考に、極性判定、感情推定の2段階の処理を行う。

まず極性判定のために、現代形容詞用法辞典[15]から極性関連語辞書を作成する。本辞典では1010語の形容詞がその用法やイメージ値と共に記述されている。イメージ値は「---」から「+++」までの7段階の値で示されている。この辞典から、使用頻度の高い200単語を選び、極性関連語辞書を作成する。ここではYahoo! [16] 検索でhit数が上位になる単語を使用頻度の高い単語と判断した。表1に極性関連語辞書の例を示す。現代形容詞辞典におけるイメージ値を直接利用するために、イメージ値を0から1の値域において7段階となる値に変換している。

極性判定は、一般回帰ニューラルネットワーク(GRNN)[17]を用いて行われる。GRNNは入力層、中間層、出力層の3層からなり、与データ間の関数近似を行うことができる。ここで作成した辞書を用いてGRNNの学習を行う。辞書の各単語は辞書内のすべての単語との類似度[18]が取られ、入力

表1 極性関連語辞書の例

イメージ値	極性関連語
1.0	まろやか, 好き, 良い, 楽しい, ...
0.84	乙, 気強い, すごい, 手早い, ...
0.50	同じ, 高い, 多い, 新しい, ...
0.00	気重, 悪い, 嫌, 口さがない, 怖い, ...

Twitterを用いたニュース記事における読み手の感情推定手法の提案とアクセス解析への応用

ベクトルに変換される。そしてイメージ値を教師信号としてGRNNの学習が行われる。結合荷重の学習には2乗誤差の勾配法を用いる。

構築されるネットワークを図3に示す。提案手法では、まずツイート*i*から得られた単語列の各単語*j*をベクトルに変換する。各単語は学習時と同様に、辞書内のすべての単語との類似度[18]が取られ、ベクトル $\mathbf{x}_j$ に変換される。このベクトルがGRNNへの入力となる。中間層の各ニューロンは1つの教師データセットに対応し、ニューロン*k*からの出力 $o_k(\mathbf{x}_j)$ は以下の式で算出される。

$$o_k(\mathbf{x}_j) = \phi(D_k) = \exp\left(-\frac{D_k^2}{2\sigma^2}\right) \quad (1)$$

ここで σ は関数の広がりを示す定数であり、 D_k はGRNNの入力ベクトルとニューロン*k*の教師データセットの入力ベクトルとのユークリッド距離を示している。

出力ニューロンは一つであり、中間層からの加重合計により、単語の極性スコア C_j を求める。

$$C_j = \frac{\sum_{k=1}^K w_k o_k(\mathbf{x}_j)}{\sum_{k=1}^K o_k(\mathbf{x}_j)} \quad (2)$$

ここで*K*は教師データセット数を示す。また w_k は出力ニューロンと中間ニューロン*k*との結合荷重である。

さらに、極性判定の精度を上げるために各単語の極性スコアには以下の2種類の修正が加えられる。

(1) 仮定文・否定文に対する修正

文の極性を考えるとき、仮定文・否定文を考慮する必要がある。例えば「本当にそれでいいの?」という文を考える。形態素解析の結果「いい」という形容詞が得られ、極性スコアは高い値となる。したがって文全体の極性としてはポジティブと判定されるが、これは正しくない場合が多い。

提案手法では、このような単語 N_{neg} を否定語または仮定語と扱うことで、この問題に対応している。具体的な処理としては、否定語前の単語の極性スコアを反転する。実際の修正式を以下に示す。

$$C_j^{new} = -1 \times (C_j^{old} - 0.5) + 0.5 \quad (3)$$

図3 構築されるGRNNネットワーク図

(2) 特定の単語に対する修正

特定の単語 N_{sp} について、処理の対象外とした。例えば「すごい悔しい」という文を考える。「すごい」という単語は、極性関連語辞書に含まれている単語であり、高いイメージ値を持つ。そのため例えば「すごい悔しい」のように、後に続く単語の絶対値が大きいくことを示す表現であっても、高い極性スコアを出力してしまう。このようなスコアは文全体の極性として正しくない場合が多い。

提案手法ではこのように直後の単語の程度を強調するような形容詞に対しては極性値を0.5にする処理を行なう。

$$C_j^{new} = 0.5 \quad (4)$$

Twitterから取得される文章は短文が多い。したがってこれら2つの処理による修正は比較的容易である。

以上の修正を踏まえ、ツイート*i*の極性スコア P_i は各単語*j*の極性スコア C_j から以下のように計算される。

$$P_i = \frac{\sum_{j=1}^W (C_j - 0.5)}{W} \quad (5)$$

ここで*W*はツイート*i*に含まれる単語数である。ツイートの極性スコアがしきい値 T_a 以上ならポジティブ、 $-T_a$ 以下ならネガティブと判定される。

2.3.3 感情推定部

次に、感情推定部について説明する。まず、感情推定のために、感情表現辞典[12]から感情関連語辞書を作成する。本辞典には前述のように10感情の感情に関する言葉が収録されている。ここで極性関連語辞書の場合と同様に使用頻度の高い単語を各感情ごとに20語ずつ、計200語取り出し感情関連語辞書を作成する。Yahoo!検索でhit数が上位の単語を使用頻度の高い単語と判断する。表2に感情関連語辞書の例を示す。

極性判定の場合と同様に、GRNNを用いて感情推定を行う。ただし出力は各感情ごとに計算し、教師データセットには感情関連語辞書を用いる。教師信号は各感情ごとに0か1の要素を持つ感情数10次元のベクトルとして表現される。例えば「幸福」の教師信号は「1,0,0,0,0,0,0,0,0,0」となる。

表2 感情関連語辞書の例

感情	感情関連語
喜	清々, 幸福, 大笑い, 感謝, 楽しい, …
好	好き, 情, 恋, 大好き, 友情, …
安	気軽, 平安, 安心, 楽, のんびり, …
怒	心外, 逆上, 激高, かつと, 怒り, …
哀	寂寞, 寒々, 涙, 傷, 寂しい, …
怖	物思い, 恐怖, 不安, 心配, 新刊, …
厭	後悔, 苦い, 痛手, 辛苦, 不味い, …
恥	てれ, 恥ずかしい, 真赤, 屈辱, …
昂	上気, 感動, 緊張, 興奮, 激情, …
驚	放心, びっくり, ショック, 驚き, …

ツイート*i*の各単語*j*は本辞書により、入力ベクトル $\mathbf{y}_j$ に変換される。GRNNは入力ベクトルより10次元の感情スコアベクトル $\mathbf{F}_j$ を出力する。

式(1)、(2)から単語の感情スコアベクトル $\mathbf{F}_j$ は以下の式で表わされる。

$$\mathbf{F}_j = \frac{\sum_{l=1}^L \mathbf{w}_{ml} o_l(\mathbf{y}_j)}{\sum_{l=1}^L o_l(\mathbf{y}_j)} \quad (6)$$

ここで L は教師データセット数を示す。 $\mathbf{w}_{ml}$ は各感情ごとの出力ニューロン m と中間ニューロン l との結合荷重である。

ツイート*i*の感情スコアベクトル $\mathbf{E}_i$ は各単語*j*の感情スコアベクトルから以下のように計算される。

$$\mathbf{E}_i = \max_w \mathbf{F}_j \quad (7)$$

感情スコアベクトル $\mathbf{E}_i$ で最大の値を取る感情をツイート*i*の感情とする。ただしその値が一定値 T_b 以下の場合は「無」感情と判定する。また、極性判定の結果により感情の修正を行う。具体的には、ツイートが既にポジティブと判定されている場合は「怒、哀、怖、厭、恥」を「無」感情として扱う。ネガティブと判定されている場合は「喜、好、安」を「無」感情として扱う。

2.4 記事の感情推定

以上のようにして、記事に対する各ツイートの感情が推定され、これを用いて記事の感情推定が行われる。

記事の感情推定では、一定数 T_c 以上のツイート数を持つ感情が出力される。記事には複数の感情が推定されうる。

ツイート数が少ない、または全てのツイートに感情が推定されない記事も存在する。提案手法ではこれらの記事に対して「無」感情と推定する。

表3に実際の感情推定例を示す。表から記事によって単一の感情や複数の感情が推定されていることが分かる。

表3 感情推定例

感情	記事タイトル
喜	飲み残しジュースで発電 ソニー携帯端末向け電池
好	伊達直人再び 図書カード10万円分、市役所に郵送
安	寒さも彩り、樹氷トンネル 三重・御在所岳
怒	国の借金：過去最高の945兆円
哀	国技館優勝額から日本人消える 史上初
怖	福島2号機で核分裂の可能性 ホウ酸水を注入
厭	ドコモ、富士通製スマホの販売一時停止 不具合
恥	オリンパス：財務、経理は社長直轄
昂	植物状態でも言葉に反応 カナダの大学が脳波調査
驚	フェラーリやランボルギーニ…13台が事故 中国道
無	日経平均小幅続落、午前終値8436円様子見続く
怒哀	わいせつ容疑：42歳歯科医を逮捕
好喜	地球に似た惑星確認＝生命存在の可能性－NASA

3. アクセス解析

アクセス解析は、ある記事を読んだユーザが次に見る記事の傾向等を調べる事が目的である。図4に解析までの流れを示す。アクセス解析では、まず作成したWebアプリ上でアクセスログの収集が行われる。次に保存されたニュース記事に対して提案した感情推定法が実行される。最後に感情が付与されたログに対してアクセス傾向の解析を行う。

3.1 ログの収集

アクセスログ収集は予め獲得したニュース記事とツイートをを用いたWebアプリ上で行われる。25名の学生の協力により、2011年10月7日から2012年4月4日の間ユーザのアクセスを記録した。

ユーザが連続して閲覧した全記事とその順番を、収集するログセットとして定義する。例えばあるユーザが「記事1を閲覧→記事2を閲覧→一定時間経過→記事3を閲覧→記事4を閲覧」というアクセスをすると、ログには「記事1→記事2」と「記事3→記事4」という2つのログセットが保存される。

すべてのユーザの閲覧した記事と順番はデータベースに記録される。収集したログデータの詳細を表4に示す。ここでPV数は全ユーザが記事を閲覧した回数を示している。

3.2 ログ記事の感情推定

ログに保存された記事に対して感情推定を行う。例えば「記事1→記事2→記事3→記事4→記事5」のようなログセットから「怒昂→厭→好→無→喜」のような感情ログセットが得られる。

3.3 N-gramによる解析

感情が推定されたログセットに対して、N-gramモデルを用いた解析を行う。N-gramモデルは確率・統計的自然言語処理の分野で最も広範に用いられている言語モデルである[19]。

図4 アクセス解析の流れ

表4 ログデータの詳細

記事数	3,463記事
PV数	5,269PV
ログセット数	1,114ログセット
ユーザ数	25名
収集期間	2011/10/7～2012/4/4

Twitterを用いたニュース記事における読み手の感情推定手法の提案とアクセス解析への応用

単語列 $w_1^n (= w_1 w_2 \cdots w_n)$ が学習データ中に出現する回数を $C(w_1^n)$ と表すこととすると、 N -gram の確率は次の式で示される。

$$P(w_n | w_{n-N+1}^{n-1}) = \frac{C(w_{n-N+1}^n)}{C(w_{n-N+1}^{n-1})} \quad (8)$$

上記の式よりユーザのアクセス傾向を調べる。今回の解析では、提案手法において最も推薦された感情のみを考慮する。また「無」感情のログはデータセットから除去する。これは、記事を見た時ユーザの感情に特に影響を与えなかったと考えたためである。 N -gram によって得られたデータの詳細は実験の章で詳述する。

3.4 隠れマルコフモデルによる解析

3.4.1 Baum-Welch アルゴリズム

HMM を利用したアルゴリズムにはいくつかあるが、今回は Baum-Welch アルゴリズム [20] を用いた解析を試みる。これは、与えられた観測系列 $O = O_1 O_2 \cdots O_T$ から、EM アルゴリズムを用いて HMM のパラメータ $\lambda = (A, B, \pi)$ を推定するアルゴリズムである。ここで A は状態 S_p から状態 S_q への遷移確率分布 a_{pq} 全体の集合、 B は状態 S_p における出力確率分布 $b_p(w)$ 全体の集合、 π は時刻 $t=1$ で状態 S_p にある初期状態確率分布 π_p 全体の集合を示す。

3.4.1 初期値の設定

隠れマルコフモデルでは、適切な初期値を設定すれば、与えるデータにノイズがあっても最尤解を出力可能である。そこで提案手法では、ログデータを用いてヒューリスティックに初期値を設定する。

まず、出力記号 $O \in (\text{喜, 好, 安, 怒, 哀, 怖, 厭, 恥, 昂, 驚})$ に対して状態 ($P(\text{positive}), N(\text{negative}), S(\text{surprise})$) を出力する関数を $s(O)$ とする。表5に出力値を示す。例えば、 $O = \text{喜}$ の場合は $s(\text{喜}) = P$ となる。

ここで3状態への分類はラッセル [21] の感情円環モデルを参考とする。ラッセルのモデルは覚醒-睡眠の軸と快-不快の軸からなり、すべての感情は2軸の数値として表されるとしている。軸名を状態として感情の分類を考えるが、記事という注目を集める題材において「睡眠」という感情状態は表出しづらいと判断し、特に「ポジティブ (快)」、「ネガティブ (不快)」、「サプライズ (覚醒)」を状態として選択した。

この対応表と学習用のテストデータ $O^1, O^2, \dots, O^N$ から初期パラメータ λ^0 を決定する。

初期状態確率分布 $\pi_{s(O)}$ は以下の式で計算される。

$$\pi_{s(O)} = \frac{\sum_{n=1}^N C(s(O_n^1))}{\sum_{n=1}^N \sum_{s(O_n^1)} C(s(O_n^1))} \quad (9)$$

同様に遷移確率分布 $a_{s(O)s(O')}$ は以下の式で計算される。

$$a_{s(O)s(O')} = \frac{\sum_{n=1}^N \sum_{t=1}^{T-1} C(s(O_t^n) s(O_{t+1}^n))}{\sum_{n=1}^N \sum_{t=1}^{T-1} \sum_{s(O_{t+1}^n)} C(s(O_t^n) s(O_{t+1}^n))} \quad (10)$$

表5 状態と出力状態の対応付け

状態 $s(O)$	出力記号 O
P (ポジティブ)	(喜, 好, 安)
N (ネガティブ)	(怒, 哀, 怖, 厭, 恥)
S (興奮・驚き)	(昂, 驚)

出力確率分布 $b_{s(O)}(O)$ は記事から複数感情が推定されることを利用して計算する。記事に複数の感情が付与されているとき、その感情を $O_{t_1}, O_{t_2}, \dots, O_{t_E}$ と表現する。

$$b_{s(O)}(O) = \frac{\sum_{n=1}^N \sum_{r=1}^E C(O_{t_r}^n) \cdot \delta}{\sum_{n=1}^N \sum_{s(O)} \sum_{r=1}^E C(O_{t_r}^n) \cdot \delta} \quad (11)$$

ただし

$$\delta = \begin{cases} 1 & (s(O_{t_i}) = s(O)) \\ 0 & (s(O_{t_i}) \neq s(O)) \end{cases} \quad (12)$$

である。

4. 実験

実験では感情推定精度の比較と、感情に基づいたアクセス解析によるユーザの傾向抽出を行った。

4.1 感情推定精度の比較実験

4.1.1 実験条件

提案した感情推定手法について、その推定精度評価を行った。比較対象として以下の手法を用いた。

(a) Baseline

Kozareva ら [6] が提案した感情推定手法をベースラインとした。彼らの手法では、入力記事に含まれる単語 cw_u と感情表現語 e との相互情報量 $PMI(e, cw_u)$ を求める。感情 E ことの相互情報量の和が感情スコアとなる。

$$\sum_u PMI(e, cw_u) = \sum_u \log \frac{hits(e, cw_u)}{hits(e) hits(cw_u)} \quad (13)$$

ここで $hits(x)$ は単語 x の検索エンジンでの検索ヒット数を表す。最大のスコアを取る感情 E を入力文の推定結果とする。今回は、10種類の感情について感情語を任意に選択した。選択した感情語を表6に示す。検索エンジンにはYahoo!

表6 Baseline感情語

感情	感情語
喜	楽しい
好	好き
安	安心
怒	怒り
哀	悲しい
怖	恐ろしい
厭	嫌い
恥	恥ずかしい
昂	興奮
驚	驚き

ニュース [22] を用いた。

(b) Baseline + Twitter (単感情)

ベースラインの手法において、ニュース記事ではなく記事についてのツイートを入力とした。ただし出力する感情数は(a)と同じく1つとする。

(c) Baseline + Twitter (複感情)

ベースラインの手法において、記事についてのツイートを入力とした。ただし複数の感情出力を許した。

(d) 提案手法

2章で述べたGRNNを用いた2段階の感情推定手法の評価を行った。使用したパラメータを表7に示す。

(e) 提案手法 (3クラス)

10感情ではなく、4.2.2節アクセス解析で用いる3クラスについて、提案手法を適用する。

評価データには抽出した120記事を用いた。これらの記事に15名の被験者が感情を付与する。ここで1つの記事に対して複数の感情を付与することは許されている。このデータを正解データとして、3つの手法の評価を行った。評価項目は適合率、再現率、F値、一致率である。一致率は比較手法が正解データのいずれかの感情を出力した割合を示す。

4.1.2 実験結果

[a] Baselineと[b] Baseline + Twitter (単感情) から、出力する感情が1つの場合の比較を行う。表8に比較手法の実験結果を示す。表より、適合率・再現率・F値・一致率すべての指標で[b]が[a]を上回っており、Twitter利用の有効性が示唆される。

さらに実験条件を揃えた[c] Baseline + Twitter (複感情) と[d] 提案手法との比較を行う。表より適合率・再現率・F値において提案手法が従来手法を上回るかまたは同等の推定精度を示しており、提案したGRNNを用いた2段階の感情推定手法の有効性が示唆されている。

全体的に適合率に比べ再現率が低いことは、正解感情について取りこぼしが多いという事を示している。これは正解データを複数人のアンケートで取得したため、多くの感情が正解とされているためである。この結果は人により記事に与える感情に差があることを示唆している。

表7 提案手法のパラメータ

σ of GRNN	0.5
N_{neg}	「ない」、「ば」、「たら」、「方が」 「いい加減」、「?」、「?」
N_{sp}	「すごい」、「もっと」
T_a	0.16
T_b	0.4
T_c	4

表8 推定精度の結果

手法	適合率	再現率	F値	一致率
[a] Baseline	0.38	0.10	0.16	0.38
[b] [a] + Twitter (単)	0.50	0.13	0.21	0.50
[c] [a] + Twitter (複)	0.45	0.22	0.29	0.71
[d] 提案法	0.57	0.22	0.32	0.69
[e] 提案法 (3クラス)	0.79	0.38	0.51	0.83

4.2 アクセス解析

3章で述べたアクセス解析について結果を示す。各解析において、得られたデータに対してカイ2乗検定を用いた検定を行った。ここでユーザがランダムに記事閲覧した場合の確率を、全記事内の割合から計算した。この閲覧確率との有意差を測り、5%の有意差が認められたものをユーザの行動に傾向があるものとして抽出した。なお簡略化のために、例えば恥感情と判定されている記事は「『恥』感情の記事」と記述する。

4.2.1 N-gramでの解析

10感情によるN-gramモデルを作成した。表9に10感情による2-gramモデルの結果を示す。ただし「恥」感情はデータ数が少なかったために「怒」感情に統合した。

表の数値はある時刻に左端列の感情状態であるとき、次の時刻で上端行の感情状態に移移する確率を示している。表10以降の表においても同様である。

有意差が見られたのは「昂」感情の記事から他の感情の記事への移移であった。ここでは「昂」感情の記事の次に「昂」・「驚」感情の記事は見られづらいこと、また「安」感情の記事が見られやすくなるという傾向が見られた。

表9 10感情の2-gramモデル（「恥」は「怒」に統合）

	喜	好	安	怒	哀	怖	嫌	昂	驚
閲覧確率	0.15	0.07	0.19	0.06	0.08	0.06	0.09	0.07	0.23
喜	0.16	0.08	0.26	0.05	0.06	0.05	0.09	0.07	0.24
好	0.16	0.09	0.20	0.05	0.12	0.05	0.09	0.06	0.19
安	0.15	0.07	0.19	0.06	0.09	0.05	0.10	0.07	0.22
怒	0.14	0.07	0.20	0.08	0.08	0.08	0.09	0.09	0.21
哀	0.11	0.08	0.22	0.05	0.09	0.07	0.12	0.09	0.17
怖	0.12	0.09	0.20	0.07	0.09	0.03	0.11	0.04	0.24
嫌	0.14	0.06	0.20	0.05	0.07	0.08	0.09	0.07	0.23
昂	0.16	0.10	0.26	0.09	0.06	0.07	0.08	0.05	0.16
驚	0.14	0.07	0.18	0.05	0.08	0.05	0.10	0.09	0.23

Twitterを用いたニュース記事における読み手の感情推定手法の提案とアクセス解析への応用

4.2.2 *N*-class gramでの解析

10感情ではデータのスパース性のため満足のいく解析が困難であった。そこで10感情を3クラスに分類する*N*-class gramモデルを用いた解析を試みた。分類は表5と同様に行った。3クラスによる分類は、表8に示す通り比較的高い精度であり、解析への利用は妥当であると考えられる。表10に3クラス2-gramモデルによる解析の結果を示す。

表より「ネガティブ」の記事を見たあとには「ネガティブ」の記事は見られやすいこと、「ポジティブ」の記事の後には「興奮・驚き」の記事は見られづらいこと等の偏りは見られたが、閲覧確率との有意差は見られなかった。

次に3クラスにおける3-gramモデルを作成した。結果を表11に示す。結果から「ポジティブ」の記事を連続で見た後は「興奮・驚き」の記事を見られづらいこと、「ネガティブ」の記事は連続で見られやすい等の偏りが見られたが、こちらも閲覧確率との有意差は見られなかった。そこでより精度の高い解析を目指して、隠れマルコフモデルを用いる解析を適用した。

4.2.3 隠れマルコフモデルでの解析

まず隠れ状態が「P,N,S」の単純マルコフモデルを想定したモデルにより解析を行った。結果を表12、表13に示す。

結果から、ユーザは始めに「興奮・驚き」の記事を見やすく「ネガティブ」の記事は見られづらいこと、「ネガティブ」の記事を見た後に「ネガティブ」の記事を見やすいことなどに5%の有意差が見られアクセス傾向として抽出された。

さらに隠れ状態を「PP,PN,PS,NP,NN,NS,SP,SN,SS」とした2重マルコフモデルを想定したモデルで解析を行った。遷移確率分布について結果を表14に示す。

結果から「ネガティブ」の記事と「ポジティブ」の記事を続けてみた後は「ネガティブ」の記事を見られやすいこと、「ネガティブ」の記事を連続で見た後は「興奮・驚き」の記事を見やすいこと等に閲覧確率との有意差が見られアクセス傾向として抽出された。

以上隠れマルコフモデルを用いた解析による傾向を示した。全体的に興奮・驚きと判定された記事に関する傾向が多く抽出された。これはアクセス解析の対象が新聞記事という興味を引くことに重点を置くものであり、ユーザにもその意識が表れたためと考えられる。

5. 結 論

本論文では、Twitterを用いてニュース記事の読者の感情を推定する手法を提案し、さらに同手法を用いてアクセス解析への応用を行った。提案した感情推定手法は、Twitterから記事に対するツイートを収集し、複数のツイートから記事の感情を推定する。ツイートの感情推定には、頑健性が強く学習が比較的高速であるGRNNを利用し、極性判定、感情推定の2段階の感情推定を行った。評価実験の結果、Twitterを用いた手法は用いない手法に比べ感情推定精度が上昇する

表10 3クラスの2-gramモデル

	P	N	S
閲覧確率	0.415	0.284	0.301
P	0.428	0.284	0.288
N	0.399	0.316	0.285
S	0.424	0.286	0.290

表11 3クラスの3-gramモデル

	P	N	S
閲覧確率	0.415	0.284	0.301
PP	0.435	0.306	0.258
PN	0.441	0.322	0.237
PS	0.468	0.289	0.243
NP	0.379	0.345	0.276
NN	0.329	0.316	0.355
NS	0.425	0.275	0.301
SP	0.445	0.262	0.293
SN	0.426	0.335	0.239
SS	0.433	0.310	0.257

表12 3状態HMMの初期状態確率

	P	N	S
閲覧確率	0.415	0.284	0.301
初期状態確率	0.389	0.248	0.363

表13 3状態HMMの状態遷移確率

	P	N	S
閲覧確率	0.415	0.284	0.301
P	0.428	0.256	0.286
N	0.387	0.333	0.280
S	0.428	0.281	0.291

表14 9状態HMMの状態遷移確率

	P	N	S
閲覧確率	0.411	0.288	0.301
PP	0.412	0.299	0.281
PN	0.479	0.337	0.184
PS	0.482	0.278	0.239
NP	0.327	0.388	0.285
NN	0.285	0.276	0.439
NS	0.464	0.213	0.324
SP	0.457	0.273	0.270
SN	0.406	0.369	0.225
SS	0.475	0.28	0.245

ことが示された。さらにGRNNと2段階感情推定を用いた手法の有効性が示された。

アクセス解析は*N*-gramモデルと隠れマルコフモデルを用いて行った。隠れマルコフモデルは、*N*-gramモデルと違い、初期状態を考慮し最尤推定により最適解を求めることができる。評価実験より隠れマルコフモデルを用いることで、既存のアクセス解析手法では抽出できなかったアクセス傾向について、有意差を見出すことができた。例えば、多くのユーザは初めに驚きや興味とシステムに判定された記事を見やす

い、ネガティブと判定された記事を見た後は再びネガティブと判定された記事を見る傾向が高い等である。

Twitterを用いた感情推定では、ツイートの感情と評価実験に用いた正解感情が大きくずれているために、ツイートの感情を正しく判定しているにもかかわらず推定精度を下けている記事も存在した。推定精度の向上のためには、更に読者の意見を集める必要があると考えられ、今後の課題となる。また、解析ではデータ数が限られていたため、ユーザごとの細かい解析までは行えなかった。今後はデータ数を増やすことでより詳細な検討を行っていく。

謝 辞

概念（単語）間の類似度計算システムをご提供下さった拓殖大学石川勉教授に深く感謝いたします。

参 考 文 献

- [1] 社会法人日本機械学会：感覚・感情とロボット，工業調査会，p.34，2008.
- [2] 水野邦夫：意に反した行動をした後の態度及び感情状態の変化：セルフ・モニタリングとの関連，性格心理学研究，2，1，pp.38-46，1994.
- [3] 尾崎由佳：接近・回避行動の反復による潜在的態度の変容，実験社会心理学研究，45，2，pp.98-110，2006.
- [4] Plaban Kumar Bhowmik, Anupam Basu, Pabitra Mitra: Classifying emotion in news sentences: When machine classification meets human classification, 2, 1, pp.98-108, 2010.
- [5] 熊本忠彦，田中克己：Webニュース記事からの喜怒哀楽抽出，自然言語処理研究会研究報告，2005-NL-165，pp.15-19，2005.
- [6] Z. Kozareva, B. Navarro, S. Vazquez, A. Nibtoyo: UA-ZBSA: A headline emotion classification through web information, Proc. 4th International Workshop on Semantic Evaluations, pp.334-337, 2007.
- [7] Plaban Kumar Bhowmik, Anupam Basu, Pabitra Mitra: Reader perspective emotion analysis in text through ensemble based multi-label classification framework, Computer and Information Science, 2, 4, pp.64-73, 2009.
- [8] Twitter: <https://twitter.com/>
- [9] 高野憲吾，萩原将文：感情関連語を用いた感情推定法の提案とニュースサイトのアクセス解析への応用，日本感性工学会論文誌，Vol.11，No.3，pp.495-502，2012.
- [10] David Nicholas, Paul Huntington, Nat Lievesley, Richard Withey: Cracking the code: web log analysis, Online Information Review, 23, 5, pp.263-269, 1999.
- [11] P. Ekman: An argument for basic emotions, Cognition and Emotion, 6, pp.169-200, 1992.
- [12] 中村明：感情表現辞典，東京堂出版，pp.5-20，1993.
- [13] 工藤拓：形態素解析器Mecab, <http://mecab.sourceforge.net>.
- [14] 徳久良子，乾健太郎，松本裕治：Webから獲得した感情生起要因コーパスに基づく感情推定，情報処理学会論文誌，50，4，pp.1365-1374，2009.
- [15] 飛田良文，浅田秀子：現代形容詞用法辞典，東京堂出版，1991.
- [16] Yahoo! : <http://www.yahoo.co.jp/>, Yahoo! JAPAN.
- [17] D. F. Specht: A general regression neural network, IEEE Trans. on Neural Networks, 2, 6, pp.567-576, 1991.
- [18] 石川研究室：概念（単語）間の類似度計算システム，<http://www.cs.takushoku-u.ac.jp/ai.ruiji/SimilaritySystem.cgi/>
- [19] 北研二：言語と計算-4 確率的言語モデル，東京大学出版会，p.57，2001.
- [20] L. E. Baum, T. Petrie, G. Soules, N. Weiss: A maximization technique occurring in the statistical analysis of probabilistic functions of Markov chains, Ann. Math. Statist., 41, 1, pp.164-171, 1970.
- [21] James A. Russell: A circumplex model of affect, Journal of Personality and Social Psychology, 39, 6, pp.1161-1178, 1980.
- [22] Yahoo! ニュース：
<http://headlines.yahoo.co.jp/hl/>, Yahoo! JAPAN.

本間 幸徳（非会員）

2012年3月 慶應義塾大学理工学部卒業。
現在，慶應義塾大学大学院開放環境科学専攻
修士課程に在学中。感性工学，ニューラル
ネットワークに関する研究に従事。

萩原 将文（正会員）

1982年 慶大・工・電気卒。1987年同大学院博士課程了。工博。同年同大助手。以来，ソフトコンピューティング，言語工学，感性工学の研究に従事。現在，同大教授。1991-92年度スタンフォード大学訪問研究員。1986年 丹羽記念賞，1987年 電子情報通信学会学術奨励賞，1990年 IEEE Consumer Electronics Society論文賞，1994年 安藤博記念学術奨励賞，1996年 日本ファジィ学会著述賞，2003年 日本感性工学会技術賞，2004年 日本感性工学会論文賞，2005年 日本知能情報ファジィ学会貢献賞受賞。電子情報通信学会，情報処理学会，日本知能情報ファジィ学会，人工知能学会，電気学会，日本神経回路学会，日本感性工学会，日本デザイン学会，言語処理学会各会員。IEEEシニアメンバ。