

単語極性反転モデルによる評価文分類

池田 大介[†] 高村 大也^{††} Lev-Arie Ratinov^{†††} 奥村 学^{††}

† 東京工業大学大学院 総合理工学研究科 〒226-8503 神奈川県横浜市緑区長津田町 4259

†† 東京工業大学 精密工学研究所 〒226-8503 神奈川県横浜市緑区長津田町 4259

††† Department of Computer Science, University of Illinois at Urbana-Champaign.
Urbana, IL 61801 USA.

E-mail: †ikeda@lr.pi.titech.ac.jp, ††{takamura,oku}@pi.titech.ac.jp, †††ratinov2@uiuc.edu

あらまし 本稿では単語に対して付与された極性を評価文分類に利用する手法について述べる。最も単純には、文中に出現する感情極性付きの単語の数を数える多数決による手法が考えられる。しかし、評価文中の単語の極性は否定や逆接等で反転することがあり、誤りの原因となる。そこで、本研究ではこういった極性の反転を捉えるため、単語極性反転モデルとこれを用いた評価文分類手法を提案する。このモデルを用いることで、単語の極性反転を捉えることができ、先述のような誤りは防ぐことができる。また、単語ごとではなく文単位にこのモデルを学習することで、文中の単語の極性に着目しつつも直接評価文分類問題を解くことができる。さらに、このモデルは既存の評価文分類モデルと容易に結合でき、単語の極性を利用しつつ、Bag-of-Words や依存構造といった、これまで提案してきた様々な情報を考慮したモデルが構築可能である。提案手法を用いることで、単語の極性を用いない評価文分類手法と比べ、最大 4.2 ポイント正解率が向上した。

キーワード 評価文分類 単語極性反転モデル 単語極性辞書

Sentiment Classification of Sentences by Modeling Word-Level Polarity-Shifters

Daisuke IKEDA[†], Hiroya TAKAMURA^{††}, Lev-Arie Ratinov^{†††}, and Manabu OKUMURA^{††}

† Interdisciplinary Graduate School of Science and Engineering, Tokyo Institute of Technology.

4259 Nagatsuta-cho, Midori-ku, Yokohama, 226-8503, Japan.

†† Precision and Intelligence Laboratory, Tokyo Institute of Technology.

4259 Nagatsuta-cho, Midori-ku, Yokohama, 226-8503, Japan.

††† Department of Computer Science, University of Illinois at Urbana-Champaign.
Urbana, IL 61801 USA.

E-mail: †ikeda@lr.pi.titech.ac.jp, ††{takamura,oku}@pi.titech.ac.jp, †††ratinov2@uiuc.edu

Abstract In this paper, we propose a machine learning method that uses word-level semantic orientations for sentiment classification of sentences. The simplest solution to this problem would be the majority voting by the number of positive words and the number of negative words in the given sentence. However, the semantic orientations of words in a sentence are not always the same as that of the sentence, because there can be polarity-shifters such as negation expressions. This inconsistency of word-level orientation and sentence-level orientation often causes errors in classification by the simple majority voting method. The machine learning method that we propose in this paper models the polarity-shifters. Our model can be trained in two different levels: word level and sentence level. While the word-level training focuses on the prediction of polarity shifts, the sentence-level training focuses more on the prediction of sentence orientations. The model can also be combined with features used in previous work such as bag-of-words and dependency trees. We report that the proposed method improves the accuracy of sentence classification by up to 4.2 points compared with other simpler methods.

Key words Sentiment Classification of Sentences, Polarity-Shifting Model, Sentiment Dictionary

1. はじめに

Web の普及に伴い、個人が手軽に情報を発信できるようになった。blog や掲示板などがその好例である。個人の発する情報には、事物に対する評価や感情が記述されることが多い。近年こういった情報に対する関心が高まっており、評価情報分析に関する研究が数多くなされている [12]。

中でも、文書や文をその著者の感情極性によってポジティブ（望ましい）、ネガティブ（望ましくない）の二つに分類するというタスクは盛んに研究されている [12]。このタスクは、Web 中の文書や文からある物に対する評判を検索する、といったアプリケーションに応用することが可能で、重要かつ実用的なタスクであると言える。

他方、文書や文の他に、単語に対する感情極性についての研究も行われている。例えば、“美味しい”という語はポジティブな極性を持っていると考えられ、“苦い”はネガティブな極性を持つ語であると言える。このような単語に対する感情極性を自動的に付与し、単語の極性辞書を構築する手法が提案されている [15]。単語の感情極性は、評価情報を考える上での基礎であり、様々な問題への利用が考えられる。データを辞書として用意することができ、他のタスクへの利用が容易であるというメリットもある。

評価文の分類というタスクに於いても、単語の極性は有用な情報であると考えられる。しかし、どのように単語の極性を利用すれば評価文分類の精度を向上させられるかは明らかになっていない。そこで、本稿では単語に付与された極性を文レベルの分類に利用する手法を提案する。単純には、多数決を用いることで、単語の感情極性を利用した評価文の分類は可能である。しかし、実際には単語の極性とそれを含む評価文の極性とは必ずしも一致しない。これは、逆接や否定など、様々な文脈により単語の極性が反転することがあるためである。こういった現象は、単純な多数決では致命的なエラーの原因となる。

逆に言えば、こういった極性の反転を捉えることは評価文分類に単語の極性を利用する上で重要な事象であると言える。そこで、我々はこの事象を捉える単語極性反転モデルを提案する。反転を捉えることで、単純な多数決であっても上記のようなエラーを回避する事ができる。さらに、このモデルは単語単位ではなく、文単位の学習が可能である。そうすることで、単語極性反転モデルを用いて直接評価文分類が可能となり、その精度を高める事ができる。また、このモデルは従来の機械学習による評価文分類モデルと自然に結合可能であり、文中の単語の極性を利用しつつ、これまで提案してきた様々な情報を考慮したモデルが構築可能である。

本稿では、提案手法の有効性を確認するため英語レビュー文に対し評価文分類の評価実験を行った。提案手法を用いることにより、単語極性を用いない評価文分類手法と比較し、最大 4.2 ポイント正解率が向上した。

本稿は以下のように構成される。まず 2 節で、関連研究について述べる。その後 3 節で、既存の単語極性の利用法について論じ、本研究のモチベーションを明らかにする。4 節で提案手法である単語極性反転モデルについて述べ、その学習法と評価文

分類法について説明する。評価実験の詳細とその考察について 5 節で述べ、6 節で結論と今後の課題を挙げる。

2. 関連研究

先にも述べた通り、評価文分類や評価文書分類に関する研究は近年広く行われている [12]。中でも、サポートベクターマシン (SVM) を始めとする教師有りの機械学習による手法は高い精度を残している [8] [5] [2] [13] [7]。この手法は様々な素性を柔軟に取り入れができるという点で優れており、依存構造木や語の系列など様々な情報を用いる手法が提案されている [5] [13]。本研究はこういった評価文そのものの持つ情報ではなく、文に含まれる単語の持つ極性という異なる階層の情報を取り込む手法を提案する。また、先行研究で提案されたような情報を自然に取り込むことも可能である。

本研究は、文と単語という自然言語における階層に着目し、ある階層の情報を別の階層の解析に利用しようという試みである。先行研究においても、こういった階層に着目した研究はいくつかなされている。Mao ら [4] や貞光ら [14] は、文書中の各文における感情極性の推移を捉える手法を提案しており、この手法を用いることで評価文書分類そのものの精度を高めることができることを報告している。ある対象の持つ感情極性と、そこに含まれる要素の感情極性は必ずしも一致しないという点に着目しており、本研究で考慮する感情極性の反転もこの一種であると言える。

他にも、階層に着目した評価情報に関する研究として Pang ら [9] や、McDonald ら [6] による手法が挙げられる。Pang らは、主観的な文こそが文書の感情極性の推定には有効という考え方の下、各文の主観性を推定した後に評価文書分類を行うという手法を提案している [9]。あらかじめ客観的な文を削除することで、評価文書分類の結果が良くなると報告している。McDonald らは、文単位での分類問題と文書単位での分類問題を同時に解くモデルを提案している [6]。彼らは文単位で主観性を、文書単位では感情極性を、同時に推定することで、通常の評価文書分類よりも高い精度が得られることを示した。また、文書-文間の 2 階層だけでなく、文書-段落-文といった 3 階層以上の構造に対しても適用可能であると論じている。

これらの研究の多くは、文書に対する感情極性と同時に、そこに含まれる文の主観性といった、考慮する全ての階層に対する教師データを必要としている。我々の研究も、これらの先行研究同様、階層に着目した評価情報分析であるが、単語の極性辞書があれば教師データとしては評価文とその感情極性のみしか必要としないという点で大きく異なる。

3. 既存の単語極性の利用法

単語の感情極性を利用した評価文分類手法のうち、もっとも単純な手法は多数決である。すなわち、分類対象の文に出現するポジティブ極性の付与された単語とネガティブ極性の付与された単語の数を数え、多く出現していた極性を文全体の極性と判定する、という手法である。

この手法はいくつかの致命的な欠点を持つ。一つ目は、文全体の極性とその文中に出現する単語の極性は必ずしも一致しな

いにも関わらず、その現象を一切考慮できないという点である。以下に具体的な例を挙げる。

照明が暗いなど一部不満もあるけど、全体としては良かった。

なお、下線の引かれた単語はネガティブな単語、二重下線の引かれた単語はポジティブな単語である。この文は局所的にはネガティブな表現も含まれるが、全体としてはポジティブ極性を持つ文であると言える。しかし、この文を上記の多数決によって極性を推定すると、ネガティブ極性を持つ単語が2語あることから、全体をネガティブと判定してしまう。こういった事例は頻繁に存在し、多数決による評価文分類の精度を大きく下げる原因となる。これは、単純な多数決では“けど”のような逆接表現や否定表現を考慮できることに起因する。つまり、逆接や否定と言った単語の極性反転を捉えることが、評価文分類に単語極性辞書を利用する上で重要であると言える。

また、既存の手法と組み合わせることが難しいという問題も存在する。多数決はあくまで単語の数を数えるだけであり、従来用いられてきた Bag-of-Words や木構造といった情報を取り込むことができない。本研究では、単語の感情極性を利用した評価文分類を提案するが、単語の感情極性だけから評価文の分類を行うのでは限界がある。提案手法である単語極性反転モデルを利用した評価文分類手法では、既存の評価文分類モデルとの結合も可能である。

4. 単語極性反転モデル

前節で述べた通り、文中に出現する単語は、様々な理由によりその極性が反転しており、文全体の極性と単語のそれとが一致するとは限らない。逆に言えば、文全体の極性と異なる極性を持つ単語が文中に出現する場合、その単語は文脈等によって極性が反転していると考えられる。単純な多数決による手法であっても、このような反転を捉えることにより、よりよい精度が得られると思われる。

本研究では、この現象を捉えるため単語極性反転モデルを提案する。このモデルは、感情極性を持つ単語の周辺の否定表現や逆接と言った文脈を利用し、その単語の極性が反転しているか否かを判定する2値分類モデルである。

単語極性反転モデルは、文 S 中の各極性付きの単語 x に対しスコア関数 $s_{shift}(x, S)$ を与える。この関数は、その単語の極性が文中で反転していれば $s_{shift}(x, S) > 0$ 、そうでなければ $s_{shift}(x, S) < 0$ を返す。なお、モデルのパラメータを w とし、スコア関数 $s_{shift}(x, S)$ は内積と素性関数 ϕ を用いて以下のように定義する：

$$s_{shift}(x, S) = w \cdot \phi(x, S). \quad (1)$$

このモデルは一般的な線形識別モデルであり、様々なパラメータ推定アルゴリズムが知られている。こういった場合、各単語を個々の事例として学習する方法が一般的である。しかし、このモデルでは極性付き単語を含む文に注目することにより効果的な学習が可能である。また、このモデルによって単語ごとの極性が文脈によって反転しているか否かを捉えることは可能だが、

それだけでは評価文分類を行うことはできない。本節の残りでは本モデルの学習法と、評価文分類への利用法について述べる。

4.1 単語単位学習

単純には、各単語を事例として単語極性反転モデルの学習は可能である。訓練事例は、極性の付与された評価文コープスより感情極性の付与された単語を抜き出し、文全体の感情極性と単語の極性が一致しているか否かを見ることで生成できる。なお、感情極性の付与された単語とは、単語感情極性辞書のエントリであり、その感情極性も辞書に準ずる。先に挙げた例では、ポジティブな感情極性で書かれた文中に、“暗い”，“不満”といったネガティブ極性を持つ単語と“良い”というポジティブ極性を持つ単語が出現していた。単語極性反転モデルの訓練事例としては、文全体の極性とそれが一致しない“暗い”，“不満”を反転の正例として、極性の一一致する“良い”を負例として学習する。

また、こうして学習されたモデルを評価文分類に利用するには、先にも述べた多数決による手法を用いればよい。モデルを分類対象である文に含まれる極性付きの単語に適用し、その結果を用いて多数決を行う。ポジティブ極性を持つ単語が反転していた場合には、その単語はネガティブ極性を持つ単語として扱えばよい。単語の極性をそのまま用いた多数決では良い結果が得られないということは先述した通りだが、各単語の極性の反転を考慮することで精度の向上が期待できる。

なお、多数決をする際にはポジティブ、ネガティブの数を数えるだけではなく、単語極性反転モデルの出力するスコアによる重み付き多数決を用いる。これは、モデルの出力するスコアが反転に対するある種の確信度として働くことを期待するためである。

この手法を定式化すると以下のように書ける。ここで、 N, P は辞書にそれぞれネガティブ、ポジティブとして登録されている単語の集合とする。すなわち $x \in N$ であれば、 x はネガティブ極性を持つ単語である。また、単語 x が文 S に含まれる事を $x \in S$ と表すことにする。まず、文 S に対する2つのスコア $score_p(S)$ と $score_n(S)$ を定義する。 $score_p(S)$ は重み付き多数決における“文 S がポジティブ極性を持つことを支持する票数”に、 $score_n(S)$ は“ネガティブ極性を持つことを支持する票数”にそれぞれ相当する。つまり、 $score_p(S) > score_n(S)$ であれば文 S はポジティブな極性を、そうでなければネガティブな極性を持つと判定する。 $score_p(S)$ は、文 S 中に出現するポジティブ極性を持つ単語 $x \in S \cap P$ が“反転しない”スコア $-s_{shift}(x, S)$ に、同じくネガティブ極性を持つ単語 $x \in S \cap N$ が“反転する”スコア $s_{shift}(x, S)$ を加えた物である。数式で表すと以下の通りである：

$$score_p(S) = \sum_{x \in S \cap N} s_{shift}(x, S) - \sum_{x \in S \cap P} s_{shift}(x, S). \quad (2)$$

同様に、以下の関係が成り立つ：

$$\begin{aligned} score_n(S) &= \sum_{x \in S \cap P} s_{shift}(x, S) - \sum_{x \in S \cap N} s_{shift}(x, S) \\ &= -score_p(S). \end{aligned} \quad (3)$$

よって、 $score_p(S) > 0$ であれば、ポジティブ、そうでなければネガティブと判定することができる。

4.2 文単位学習

式(2)は、単語極性反転モデルの定義を用いて以下のように変形できる:

$$\begin{aligned} score_p(S) &= \sum_{x \in S} s_{shift}(x, S) I(x) \\ &= \sum_{x \in S} w \cdot \phi(x, S) I(x) \\ &= w \cdot \left\{ \sum_{x \in S} \phi(x, S) I(x) \right\}. \end{aligned} \quad (4)$$

ただし、 $I(x)$ は以下で定義される関数である:

$$I(x) = \begin{cases} +1 & \text{if } x \in N, \\ -1 & \text{if } x \in P, \\ 0 & \text{otherwise.} \end{cases} \quad (5)$$

この $score_p(S)$ は再び w をパラメータとする線形識別モデルになっており、直接パラメータを推定することが可能である。

このモデルはいわば多数決された結果を直接出力するモデルであり、単語の極性の反転を元に評価文を分類するモデルとなっている。学習時には評価文とその極性を教師データとして直接用いることができる。すなわち、コーパス中のポジティブ極性を持つ文を正例、ネガティブ極性を持つ文を負例として学習する。先の例で言えば、文そのものを一つの正例として扱う。学習されるのはあくまで単語極性反転モデルのパラメータ w であることから、これは単語極性反転モデルを単語単位ではなく、文単位のモデルとして捉えて学習する手法であると言える。この手法では、各単語について反転を学習するのではなく、文全体での結果が最適になるように学習を行う。この結果、反転しているか否かの判定が難しい単語に対してはスコアの絶対値を小さくし、同じ文に出現する判定の容易な単語から文全体の極性を決定するという、言わばソフトな学習が可能である。

単語単位学習では、評価文中に出現する全ての極性付きの単語から反転したか否かを学習する。つまり、全ての単語が評価文全体の極性と何らかの関係があり、文全体と異なる極性を持つ単語が出現する際には必ず周囲にその要因が存在する事を仮定している。これは明らかに強引な仮定である。実際には評価文の極性に影響を与えない単語もしばしば存在する。単語単位で学習を行うと、文の極性に影響しないような単語であっても教師データとして扱われ、それをラベル通りに分離するような分離面が引かれてしまう。これは反転を捉えるという本来の目的にそぐわない。文単位学習を用いてソフトな学習を行うことで、この強引な仮定をある程度緩和することができる。評価文の極性に影響を与えないような単語に対しては強く学習せず、スコアの絶対値を低く抑えることで目的通りのモデルを学習することができる。

4.3 文単位学習と既存のモデルとの結合

これまで述べた評価文分類法は、共に評価文中の極性付きの単語のみから文全体での極性を推定する、という手法である。文全体の極性は、そこに含まれる単語の極性に大きく依存すると思われるため、これらの手法でも文の感情極性の推定は可能である。

他方、これまでの評価文分類や評価文書分類に関する研究では、文中の単語集合である Bag-of-Words を用いた手法 [8] や、係り受け解析による文の構造情報を用いる手法 [5] [13] が提案してきた。本研究の提案手法である単語極性反転モデルによる評価文分類は、これらの先行研究とは用いる情報や分類に対する観点が異なる。そのため提案手法と従来法を組み合わせる事でよりよい結果が期待できる。

従来の評価文分類や評価文書分類では、用いる情報は様々であるが、SVM をはじめとする識別モデルによる分類が広く用いられてきた [8]。この手法は、一般に以下の関数による分類であると考えることができる:

$$Y = \text{sign}(w' \cdot \phi'(X)). \quad (6)$$

X は分類対象、つまり評価文書分類では文書、評価文分類では文に相当し、 Y は極性ラベルを意味する。 $\phi'(X)$ は素性関数であり、Bag-of-Words を用いた手法であれば、文や文書 X を単語ベクトルへ射影する。依存構造木などの木構造を利用する場合、木カーネルを用いる手法 [13] が知られているが、この場合であっても $\phi'(X)$ は X に含まれる全ての部分木を列挙したベクトルを出力する関数と考えることができる。

このモデルは、 $w' \cdot \phi'(X)$ をスコア関数として用いているに他ならない。つまり、

$$score'_p(X) = w' \cdot \phi'(X) \quad (7)$$

とし、 $score'_p(X) > 0$ であればポジティブと判定するという手法である。文単位学習法によるスコア関数 $score_p(S)$ と、従来法によるスコア関数 $score_p(S)$ の線形和を、新たなモデルのスコア関数 $score_{comb}(S)$ として定義する。すると以下のように書ける:

$$\begin{aligned} score_{comb}(S) &= \lambda score_p(S) + (1 - \lambda) score'_p(S) \\ &= \lambda \sum_{x \in S} w \cdot \phi(x, S) I(x) + (1 - \lambda) w' \cdot \phi'(S) \\ &= w_{comb} \cdot \left\langle \sum_{x \in S} \phi(x, S) I(x), \phi'(S) \right\rangle. \end{aligned} \quad (8)$$

ただし、 $w_{comb} = \langle \lambda w, (1 - \lambda) w' \rangle$ であり、 λ は単語極性反転モデルの影響力を表すパラメータである。このモデルもまた一般的な識別モデルであり、SVM をはじめ様々なアルゴリズムを用いたパラメータの推定が可能である。また、素性関数 $\phi'(S)$ として、Bag-of-Words や依存構造木を利用することによって、これらの情報を取り込んだモデルとして学習が可能である。

文単位学習同様、このモデルにもソフトな学習をする効果がある。単語の極性だけからでは判断が難しい事例に対しては、その他の情報を用いて判定するように学習する。逆の場合も同様である。つまり、互いのモデルを補い合うようなモデルになっていると言える。

4.4 カーネル表現

本稿で提案した全てのモデルはカーネル関数としての表現が可能である。例えば結合モデルは以下のようないカーネルを用いたモデルであると解釈できる:

$$K_{comb}(S_1, S_2) = \lambda \sum_{x_i \in S_1} \sum_{x_j \in S_2} K((x_i, S_1), (x_j, S_2))$$

表 1 使用したコーパスの統計

	Customer Reviews	Moview Reviews
全事例数	1700 文	10662 文
適用可能事例数	1436 文	9492 文
極性付き単語	3276 単語	26493 単語
反転している単語	1076 単語	10674 単語

$$+ (1 - \lambda) K'(S_1, S_2). \quad (9)$$

ここで, K は文中に出現する極性付き単語同士のカーネル, K' は評価文同士に定義されるカーネルである. これらのカーネルを高次の多項式カーネルとすることで, 素性間の組み合わせを考慮した学習が可能である.

5. 評価実験

本節では, 提案手法の有効性を確認するために行った評価実験について報告する.

5.1 実験に用いたデータ

評価文分類実験の評価には Hu ら [3] による Customer Review^(注1) コーパスと Pang ら [10] による Movie Review^(注2) の 2 つのコーパスを用いた. これらは共に文単位に感情極性の付与された英文コーパスで, 評価情報分析で用いられることが多いデータセットである. 事例数などの統計を表 1 に示す.

提案手法では次に説明する単語評価極性辞書を元に文中の感情極性を持つ単語を抽出し, 分類に利用する. 感情極性を持つ単語が一つも抽出されない文に対しては提案手法を適用できなかったため, 実験に用いるデータセットから除外した. 表 1 中の適用可能事例数は, 手法の適応が可能で実際に実験に用いた事例数である. また, 極性付き単語数は, コーパスから抽出された極性付き単語の延べ数, 反転している単語は単語の極性と文全体の極性が異なり, 極性が反転していると考えられる単語の延べ数である.

なお, 実験の際にはこのデータを文単位で均等に 5 分割し, 交差検定による評価を行った. また, 評価尺度としては正解率を用いた.

単語に対する感情極性の辞書としては高村ら [15] による英語単語感情極性対応表^(注3) のうち, 確信度が 1.0 のエントリを用いた. これにはポジティブ極性の付与された単語 2084 語とネガティブ極性の付与された単語 2685 語が含まれている.

5.2 実験設定

本稿では各モデルのパラメータ推定アルゴリズムとして, オンライン最大マージン学習アルゴリズムを用いた [1] [6]. このアルゴリズムはシンプルで実装も容易でありながら, 予備実験において SVM と同程度かそれ以上の性能を示した.

単語極性反転モデルの素性表現 $\phi(x, S)$ としては, 単語 x 自身を含む周囲 n 単語と単語 x に付与された極性を用いた 2 値ベクトルを用いた. また, 予備実験より $n = 3$ とした.

また, 全てのモデルに対し 2 次の多項式カーネルを用いた. これは, Bag-of-Words のみを用いた評価文分類実験において最も

表 3 Customer Review コーパスにおける Bag-of-Words モデルと文単位学習による単語極性反転モデルの比較

	文単位学習 正解	文単位学習 不正解
BoW 正解	971(67.7%)	164(11.4%)
BoW 不正解	182(12.7%)	119(8.3%)

高い正解率を得たカーネルである.

5.3 評価文分類実験

提案手法の有効性を確認するため, 評価文分類による評価実験を行った. この実験では, 以下の 6 つの手法についてそれぞれ実験し比較した:

- **ベースライン:** すべての文をポジティブ極性を持つと判定.
- **Bag-of-Words :** Bag-of-Words を素性として利用したモデルによる分類. 単語の極性を利用しない.
- **Naive-Voting :** 極性付き単語の出現数による, 最も単純な多数決を用いた評価文分類.
- **単語単位学習:** 4.1 節で述べた, 単語単位学習を行った単語極性反転モデルによる評価文分類.
- **文単位学習:** 4.2 節で述べた, 文単位学習を行った単語極性反転モデルによる評価文分類.
- **結合モデル:** 4.3 節で述べた, 文単位学習と Bag-of-Words を結合したモデルによる評価文分類. $\lambda = 0.5$ とした.

実験結果を表 2 に示す. Customer Review, Moview Review の両データで, 提案手法である結合モデルが最も良い結果を得た. また, 単語極性反転モデルを用いることにより, 単純な多数決に比べ約 7 ポイント正解率が向上しており, 単語極性の反転が捉えられていることがわかる. さらに学習法を工夫した文単位学習についても, 単語単位学習を行った場合と比べ, 正解率を向上させられることが確認できた.

結合モデルが良い結果を得られた原因として, Bag-of-Words から得られる情報と単語の極性から得られる情報が独立なものであったためと考えられる. 表 3 は Customer Review コーパスにおける Bag-of-Words モデルと文単位学習による単語極性反転モデルにおける正解した事例数, 誤った事例数の比較である. 予想通り, 両方のモデルで誤った事例はわずかに 8.3% であり, 多くの事例はどちらかのモデルでは正解していることがある.

Customer Review コーパスでは提案手法を用いることで, 単語の極性を用いない Bag-of-Words モデルに比べ 3 ポイント以上の改善を見た. しかし, Movie Review コーパスにおいては, わずかに改善しているもののほぼ拮抗した結果となった. また, Movie Review コーパスでは Bag-of-Words モデルに比べ単語の極性のみを利用した手法の結果が著しく低い. つまり, 単語の極性から得られる情報が文全体の極性推定にはあまり役に立たなかつたと考えられる. これは, Movie Review コーパスには映画の内容に関する記述など, 文全体の極性に影響を与えない極性付き単語が数多く出現するためであると思われる. 提案手法では, ソフトな学習を行うことによりこういった誤りについてある程度緩和できるが, あくまで間接的に考慮するだけであり, 改善の余地がある.

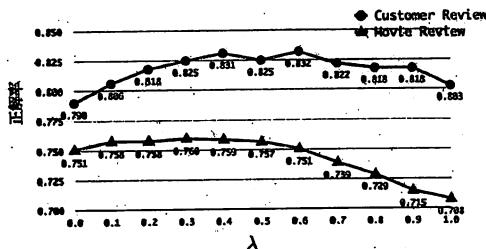
(注1) : <http://www.cs.uic.edu/~liub/FBS/FBS.html>

(注2) : <http://www.cs.cornell.edu/people/pabo/movie-review-data/>

(注3) : http://www.lri.fr/titech.ac.jp/~takamura/pndic_ja.html

表2 手法ごとの評価文分類の正解率の比較

	ベースライン	Bag-of-Words	Naive-Voting	単語単位学習	文単位学習	結合モデル
Customer Review	0.638	0.790	0.716	0.783	0.803	0.825
Movie Review	0.504	0.751	0.624	0.699	0.708	0.757

図1 パラメータ λ を変更した際の評価文分類における正解率の変動

5.4 結合パラメータの影響

最後に、結合モデルのパラメータである λ の影響を調べるための実験を行った。 λ は結合モデルにおける単語極性反転モデルの影響力をコントロールする、 $\lambda \in [0, 1]$ のパラメータである。 $\lambda = 0$ では単語極性反転モデルの影響が全くないモデル、つまり先の実験での Bag-of-Words に相当し、逆に $\lambda = 1$ では文単位学習による単語極性反転モデルと等しい。

図1に結果を示す。 λ に対しておよそ安定した挙動を示し、パラメータの調整を行うことでさらに正解率を高めることができた。 Customer Review では、単語の極性を用いないモデルに比べ最大 4.2 ポイント正解率が向上した。 Movie Review においても、最大で 0.9 ポイントほど正解率が向上しているが、先に述べた通り単語極性を利用したモデルの正解率が低く、結合モデルの正解率に影響していることが解る。

6. 結論と今後の課題

本稿では評価文中の単語の極性の反転を捉える、単語極性反転モデルを提案し、その評価文分類への応用法について述べた。さらに、このモデルに対しソフトな学習法の適用や既存のモデルとの結合といった拡張を行った。提案手法の有効性を確認するため、英文コーパスに対し評価文分類実験を行い、最大 4.2 ポイント正解率が向上した。

今後の課題として、単語極性反転モデルに適した素性の発見が挙げられる。今回実験で用いた素性は極めて単純な素性であり、反転を捉えるために十分であるとは言い難い。例えば単語の係先や接続詞といった情報は有用と思われる。また、要素の位置によって重要性が異なるという先行研究も存在する[11]。

文の極性に影響を及ぼさない単語についても考慮する必要があるだろう。提案手法では間接的にこれに対処したが、より効果的に単語の極性を他のタスクに応用していくためには、避けられない問題であると考える。

また、本論文では単語の極性を利用した評価文分類手法を提案したが、今後はこれをさらに文書レベルまで拡張したいと考えている。

文 献

- [1] Koby Crammer, Ofer Dekel, Joseph Keshet, Shai Shalev-

Shwartz, and Yoram Singer. Online Passive-Aggressive Algorithms. In *Journal of Machine Learning Research*, Vol.7, Mar, pp.551–585, 2006.

- [2] Michael Gamon. Sentiment classification on customer feedback data: noisy data, large feature vectors, and the role of linguistic analysis. In *Proceedings of the 20th International Conference on Computational Linguistics(COLING-2004)*, pp.841–847, 2004.
- [3] Mingqing Hu and Bing Liu. Mining Opinion Features in Customer Reviews. In *Proceedings of Nineteenth National Conference on Artificial Intelligence (AAAI-2004)*, pp.755–560, San Jose, USA, July 2004.
- [4] Yu Mao and Guy Lebanon. Isotonic Conditional Random Fields and Local Sentiment Flow. In *Proceedings of the Neural Information Processing Systems(NIPS-2006)*, pp.961–968, 2007.
- [5] Shotaro Matsumoto, Hiroya Takamura, and Manabu Okumura. Sentiment Classification using Word Sub-Sequences and Dependency Sub-Trees. In *Proceedings of the 9th Pacific-Asia International Conference on Knowledge Discovery and Data Mining(PAKDD-2005)*, pp.301–310, 2005.
- [6] Ryan McDonald, Kerry Hannan, Tyler Neylon, Mike Wells, and Jeff Reynar. Structured Models for Fine-to-Coarse Sentiment Analysis. In *Proceedings of the 45th Annual Meeting of the Association for Computational Linguistics (ACL-2007)*, pp.432–439, 2007.
- [7] Tony Mullen and Nigel Collier. Sentiment analysis using support vector machines with diverse information sources. In *Proceedings of the Conference on Empirical Methods in Natural Language Processing (EMNLP-2004)*, pp.412–418, 2004.
- [8] Bo Pang, Lillian Lee, and Shivakumar Vaithyanathan. Thumbs up? Sentiment Classification using Machine Learning Techniques. In *Proceedings of the Conference on Empirical Methods in Natural Language Processing(EMNLP-2002)*, pp.76–86, 2002.
- [9] Bo Pang and Lillian Lee. A Sentimental Education: Sentiment Analysis Using Subjectivity Summarization Based on Minimum Cuts. In *Proceedings of the 42th Annual Meeting of the Association for Computational Linguistics (ACL-2004)*, pp.271–278, 2004.
- [10] Bo Pang and Lillian Lee. Seeing stars: Exploiting class relationships for sentiment categorization with respect to rating scales. In *Proceedings of the 43rd Annual Meeting of the Association for Computational Linguistics (ACL-2005)*, pp.115–124, 2005.
- [11] Maite Taboada and Jack Grieve. Analyzing Appraisal Automatically. In *AAAI Spring Symposium on Exploring Attitude and Affect in Text: Theories and Applications(AAAI-EAAT2004)*, pp.158–161, 2004.
- [12] 乾 孝司, 奥村 学. テキストを対象とした評価情報の分析に関する研究動向. 自然言語処理, Vol.13, No. 3 pp.201–241, 2006.
- [13] 工藤 拓, 松本 裕治. 半構造化テキストの分類のためのブースティングアルゴリズム. 情報処理学会論文誌, Vol.45 No.9 pp.2146–2156 , 2004.
- [14] 貞光 九月, 山本 幹雄, 文を単位とする文書構造を利用した評価文書分類. 言語処理学会第 13 回年次大会予稿集, pp.230–233 , 2007.
- [15] 高村 大也, 乾 孝司, 奥村 学, スピンモデルによる単語の感情極性抽出. 情報処理学会論文誌, Vol.47 No.2 pp.627–637, 2006.