

# 分散表現を用いた単語の感情極性抽出

佐藤 貴俊<sup>†1</sup> 高村 大也<sup>†1</sup> 奥村 学<sup>†1</sup>

**概要**：単語の感情極性抽出における分散表現の有効な利用方法を検証する。提案手法では、単語の分散表現を使って分類器を学習することで、約 90%の正解率で単語の感情極性を判定することができた。学習した分類器は、分散表現を有するあらゆる単語に適用可能であり、Wikipedia 中のすべての単語に対して感情極性を付与することで、既存のものと比較して非常に大規模な単語の感情極性リストを構築した。

**キーワード**：分散表現，感情極性，文書分類

## 1. はじめに

各単語がポジティブであるかネガティブであるかを表す感情極性は、テキストの意見感情分析における最も基本的な言語リソースである。文や文書の感情分類手法として、非常に高性能な手法が提案されつつあるものの[1,2]、単語の感情極性は言語処理を含む様々な分野において現在でも盛んに利用されている[3,4,5]。また、単語の感情極性を利用し、より高性能な感情分類器を構築する手法も提案されている[6,7,8]。このような背景から、我々は単語の感情極性を獲得するための手法を改良することでより高品質な感情極性リソースを低コストで構築すること、また単語の感情極性を利用する手法を改良することを本研究の目的とする。

このような目的を達成するため、我々は単語の分散表現を利用する。単語の分散表現とは、単語を表す連続値のベクトル表現であり、似た意味の単語は似たベクトルで表現される。高品質な分散表現を容易に計算する手法が提案されたことにより[9,10]、自然言語処理における様々な分野で分散表現が活用されている[11,12,13]。我々は、既存の分散表現計算手法で得られた分散表現が、感情極性に関する情報も含んでいると仮定し、これを利用して感情極性を獲得する。より具体的には、分散表現を素性ベクトルとして活用し、教師付き分類手法を用いることで単語の分散表現を獲得する。二種類の分散表現計算手法 Skip-gram および GloVe を連結したものを素性ベクトルとして利用した場合、90%を超える正解率で単語の感情極性を判定することができた。更に、学習した分類器を使って Wikipedia 中のすべての単語に対して感情極性を付与することで、大規模な単語の感情極性リストを構築した。作成した感情極性リストは、池田らの提案した文の極性判断への転用により精度向上に繋がり、その有用性を示すことができた。

また、学習した感情極性分類器の、他の言語への適用可能性についても調査した。具体的には、英語以外の言語の分散表現を英語の分散表現の空間に写像することで、英単

語に対して学習された感情極性分類器を用いて他の言語の単語の感情極性を判定することができることを示した。

## 2. 関連研究

単語の感情極性分類手法としては、Hatzivassiloglou and McKeown [14]による教師無し手法が最初に提案された。2000年代に入り、少数の種単語を用いる手法が提案された。Turney and Littman [15]は、各単語と種単語との共起を検索エンジンのヒット数で見積もることにより極性を決定した。Kampsら[16]は、種単語から各単語へのシソーラス上の最短パスを用いて極性を決定した。Takamuraら[17]は語釈文に基づく語彙ネットワーク上で極性を伝搬させた。Esuli and Sebastiani [18]は分類器を用いて語釈文を分類することで極性を決定した。Rao and Ravichandran [19]、Speriosuら[20]、Brody and Diakopoulos [21]は、ラベル伝搬法[22]を用いて極性を決定した。これらの手法のほとんどは、辞書やシソーラスなどのリソースに依存しており、それらに記載されている単語のみ適用可能である。また、Turney and Littman [15]の手法は、辞書やシソーラスは使わないのであらゆる単語に適用可能であるが、その分類精度は他の手法より低い。

これに対し、我々の提案手法は、辞書やシソーラスを利用してなく、単語の分散表現さえ得られれば適用可能である。また、後の実験で示すように分類精度も高い。

## 3. 提案手法

本節では、最初に単語極性の抽出のために利用する既存手法と、単語極性を利用して文分類を行う既存手法について説明した後、本稿で提案する抽出手法について説明する。

### 3.1 基盤技術

提案手法では、以下に示す既存の技術を利用する。このうち、単語極性反転モデルは、獲得した単語極性が有用で

<sup>†1</sup> 東京工業大学 Tokyo Institute of Technology

あることを示すために用いる文分類手法である。

### 3.1.1 Skip-gram[9], GloVe[10]

分散表現を計算する2つの手法で、文書中の単語の共起関係を利用して、似た意味の単語は似たベクトルになるように学習するアルゴリズムである。Skip-gram [9]は、単語の出現を予測するモデルであり、GloVe [10]は単語の頻度を基にしたモデルである。これらの手法により獲得される分散表現は、単語間の類似度を計算するために使用される、様々な研究課題で素性ベクトルとして用いられる、あるいはニューラルネットワークの入力として用いられるなど、自然言語処理でも盛んに利用されている。

### 3.1.2 単語極性反転モデル

池田らの単語極性反転モデル[8]は、単語に付与された極性を文レベルの分類に利用したモデルである。単純に多数決による分類ではなく、逆説や否定など、文脈によって起こる極性の反転を捉えたモデルとなっている。単語の極性は文の極性と一致していることを前提とし、異なっている場合は、文脈によって反転が起こっていると考え、その反転を機械学習により捉える。

文  $S$  中における各極性付き単語  $x$  の反転は、以下の式で定式化される:

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

ただし、 $\phi$  は素性関数、 $\omega$  はその重みベクトルである。単語  $x$  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  $S_{shift}(x, S) \leq 0$  を返す。素性関数  $\phi$  として、文  $S$  において単語  $x$  の前後に出現する単語などを用いることにより、否定表現や逆説表現による極性反転を捉えている。

学習は、重みベクトル  $\omega$  を推定する。各文を事例にして、文全体での分類結果が最適になるように行う。

定式化すると以下ようになる:

$$\begin{aligned} Score_p(S) &= \omega \cdot \left\{ \sum_{x \in S} S_{shift}(x, S) I(x) \right\} \\ &= \sum_{x \in S} \omega \cdot \phi(x, S) I(x) \\ &= \omega \cdot \left\{ \sum_{x \in S} \phi(x, S) I(x) \right\}. \end{aligned} \quad (2)$$

ただし、 $I(x)$  は以下で定義される関数である:

$$I(x) = \begin{cases} +1, & x \in N \\ -1, & x \in P \\ 0, & \text{else} \end{cases} \quad (3)$$

### 3.1.3 言語横断単語分散表現

異なる言語の単語を同じ空間で表現する言語横断単語分散表現を求める手法は、いくつか提案されている [26,27,28]。その中で Mikolov らの提案した手法 [26] は、前もって計算されたある言語の分散表現を線形写像により別の言語に変換する手法である。計算コストの点で他の手法に対して優位性があるため、本稿ではこの手法を用いる。変換行列  $V$  は、一部の単語対をもとに推定する。次の最適化問題を解くことで、変換行列を得る:

$$\min_V \sum_{i=1}^n \|Vx_i - z_i\|^2. \quad (4)$$

ただし、 $x_i, z_i$  は原言語と目的言語の単語対の分散表現である。変換行列  $V$  で線形変換した  $x_i$  が  $z_i$  に近づくように、 $V$  を学習する。本稿の実験では  $x_i$  が日本語単語のベクトルであり、 $z_i$  が対応する英単語のベクトルになる。

## 3.2 分散表現による単語極性の抽出とその利用

本節では、3.1 節で説明した基盤技術を用いて単語極性を抽出する手法、及びその利用方法について説明する。

### 3.2.1 単語の感情極性抽出

まず、3.1.1 節で説明した Skip-gram および GloVe を用いて単語の分散表現を計算する。得られた分散表現を分類器の素性にして単語の感情極性分類器を学習する。この際、訓練事例としては、既存の極性辞書に含まれる極性単語を用いる。学習された分類器を、分散表現が得られた単語に適用し、その極性を決定する。その際、ポジティブ側の閾値  $\theta_{pos}$ 、ネガティブ側の閾値  $\theta_{neg}$  を用意し、単語  $x$  に関する分類器の出力スコア  $f(x)$  が、 $f(x) \geq \theta_{pos}$  であればポジティブ、 $f(x) \leq \theta_{neg}$  であればネガティブであると判定する。一般的に、非常に大規模な単語集合に対して効率的に分散表現を計算することができるので、大規模な単語極性辞書を構築することが可能である。また、分類器としてサポートベクトルマシンや対数線形モデルのようにスコアを算出できるものを用いることで、ポジティブもしくはネガティブの極性だけでなく、極性分類結果がどの程度信頼できるかを表す信頼度スコアを得ることができる。

### 3.2.2 文の感情極性分類

前節で作成した拡張辞書を極性辞書として、池田らの単語極性反転モデル [8] を用いて文の感情極性分類を行う。ただし、池田らのモデルをそのまま用いる手法と、その変種を考える。

まず、前節で説明したように、ポジティブ側の閾値  $\theta_{pos}$ 、ネガティブ側の閾値  $\theta_{neg}$  を設定することで、ポジティブ単

語集合  $P$  とネガティブ単語集合  $N$  を構成し、これを用いて池田らのモデルをそのまま用いることができる。

また、ポジティブ単語集合  $P$  とネガティブ単語集合  $N$  を明示的に構成せず、単語極性分類器の出力スコア  $f(x)$  を用いる方法も考える。この場合は、文全体の極性を

$$Score_p(S) = \omega \cdot \left\{ - \sum_{x \in S} \phi(x, S) f(x) \right\}. \quad (5)$$

によって決定する。式(2)との差異は、 $I(x)$ の代わりに出力スコア  $f(x)$  を用いている点である。このモデルの利点は、二つの閾値  $\theta_{pos}$  および  $\theta_{neg}$  を決定する必要がない点である。

### 3.2.3 他言語の単語への感情極性抽出

3.2.1 節で作成した感情極性分類器の、他言語への適用可能性を検討する。

英語以外のリソースから学習された分散表現を 3.1.3 節で述べた Mikolov らの手法を使って、少量の単語ペアから、英語のベクトル空間に射影する。得られた分散表現は英語空間における意味情報を有していると考えられるため、3.2.1 節で構築した分類器がそのまま適応可能である。

## 4. 実験

### 4.1 実験データ

単語の分散表現の学習用コーパスには English Wikipedia の全ページの本文を使用する。単語感情極性辞書としては General Inquirer[24]からポジティブ/ネガティブ極性の付与された、それぞれ 1636 語、1698 語を抽出して用いた。単語極性の推定実験では、General Inquirer から抽出したこのデータに対し 10 分割交差検定を行うことで評価をした。池田らの手法[8]による評価文分類実験の評価データには、Pang ら[25]による Movie Review のコーパスを用いた。これは文単位に感情極性の付与された英文コーパスで、評価情報分析で多く用いられている。事例数を表 1 に示す。池田らの手法とその変種は、極性辞書に含まれる単語が一つも含まれない文には適用できない。分散表現を用いて構築した極性辞書は General Inquirer より規模が大きいので、より多くの文を池田らの手法に適用することができる。しかし、ここでは評価データを揃えるために、General Inquirer に含まれる単語を一つも持たない文はデータセットから除外した。実験では、適用可能事例数 9,730 文を使用し、各単語は基本形に直した。実験の際には池田らの手順に従って、このデータに対し文単位の 5 分割交差検定による評価を行い、評価尺度には正解率を用いた。

3.2.3 節で説明した言語横断的な単語の感情極性分類においては、Mikolov らの手法[26]により、日本語の単語分散表現を英語の単語分散表現の空間に写像した。変換行列

の計算に使う単語対は、一般公開されている英和辞書である edict (<http://www.edrdg.org/jmdict/edict.html>) から、単語同士の対となるものを抽出し収集した。日本語の分散表現は日本語版 Wikipedia から Skip-gram で学習し、次元は 300 次元とした。英語の次元もここでは 300 とした。また、東北大学より公開されている日本語評価極性辞書[29,30] から、複数語から成る表現を削除して単語だけを抽出することで集めた極性単語集合を、日本語の単語の感情極性の評価データとした。

表 1 Movie Review コーパスの統計値。

\*ただし、この表の適用可能事例数は、General Inquirer を用いたときのものである。反転している単語とは、文の極性と極性辞書での極性が異なる単語のことである。

全事例数	10,662 文
適用可能事例数	9,730 文
極性付き単語トークン数	27,650 トークン
反転している単語トークン数	11,701 トークン

### 4.2 単語の感情極性分類

単語の分散表現を素性ベクトルにして単語の感情極性の識別モデルを構築する。分散表現の学習には Skip-gram と GloVe を使い、次元数を変えたものや、Skip-gram と GloVe を組み合わせたベクトルによる分類精度を比較する。Skip-gram については階層的ソフトマックスを用い、窓幅=5 とし、GloVe については、 $x-max=100$ 、窓幅=5 に設定した。また、分類器としてはサポートベクトルマシン(SVM)を用い、線形カーネルと RBF カーネルを試した。ハイパーパラメータとして、線形カーネルでは正則化パラメータ  $C \in \{1, 10, 100, 1000\}$ 、RBF カーネルでは  $C \in \{1, 10, 100, 1000\}$  に加え  $\gamma \in \{0.001, 0.0001\}$  ( $\gamma$  はカーネルパラメータで  $K(x_i, x_j) = \exp(-\gamma|x_i - x_j|^2)$  において使用される) で最適なパラメータを選択する。ハイパーパラメータは訓練データ中 5 分割交差検定をすることで最適パラメータを選択した。表 2 に Skip-gram、表 3 に GloVe、表 4 に Skip-gram+GloVe の各次元の正解率を示す。

Skip-gram も GloVe も次元数が増えるごとに分類精度が向上していく傾向があるが、Skip-gram では 900 次元あたり、GloVe では 400 次元あたりで分類精度は変わらなくなり、頭打ちとなっている。線形カーネルと RBF カーネルとはほとんどの場合で RBF カーネルの方が高い精度で分類することができた。文書分類を含む言語処理における分類課題では、線形カーネルで十分な精度が得られることが多い。これについての議論は、文献[23]の Appendix C を参照されたい。しかし、分散表現を用いた単語の極性分類においては、RBF の明らかな優位性が示された。このことは、分散表現を分類問題に用いる場合のカーネル関数の選択について考慮すべきであり、本稿の一つの知見である。表 4 では RBF カーネルの結果のみを表示している。

表4に示すように、Skip-gramとGloVeの組み合わせでは、異なる2つの分散表現がお互いを補い合うように高い分類精度を出している。特にSkip-gramの900-1200次元とGloVeの組み合わせは多くが単独の場合よりも高い正解率を出している。結果としてSkip-gram 1100次元とGloVe 400次元を組み合わせた分散表現が90.80%で最も高い分類精度を出した。以降Skip-gram 1100次元、GloVe 400次元の分散表現を使用する。この組み合わせを用いて、General-Inquirerから抽出した全単語を訓練データにして分類器を学習し、感情極性が付与されていない全単語を分類し、拡張極性辞書を作成した。

表2 次元ごとの分類正解率 (Skip-gram)

次元	線形	RBF
100	0.8592	0.8575
200	0.8723	0.8765
300	0.8765	0.8876
400	0.8809	0.8960
500	0.8717	0.8954
600	0.8734	0.8971
700	0.8681	0.9021
800	0.8703	0.9046
900	0.8687	0.9030
1000	0.8567	0.8965
1100	0.8620	0.9007
1200	0.8592	0.9030

表3 次元ごとの分類正解率 (GloVe)

次元	線形	RBF
100	0.8709	0.8773
200	0.8751	0.8862
300	0.8717	0.8871
400	0.8581	0.8924
500	0.8597	0.8885

表4 Skip-gram+GloVe の分類正解率

Skip-gram \ GloVe	次元				
	100	200	300	400	500
100	0.8826	0.8932	0.8938	0.8996	0.8949
200	0.8840	0.8932	0.9010	0.8971	0.9007
300	0.8929	0.8943	0.8977	0.8991	0.8993
400	0.8826	0.8840	0.8929	0.9018	0.8929
500	0.8949	0.9007	0.8993	0.9032	0.9018
600	0.8915	0.8991	0.9032	0.9010	0.8960
700	0.8974	0.8996	0.9046	0.8993	0.9013
800	0.8974	0.8999	0.9049	0.9055	0.9010
900	0.9018	0.9063	0.9052	0.9052	0.9024
1000	0.9013	0.9030	0.8991	0.9016	0.9004
1100	0.9074	0.9049	0.9066	<b>0.9080</b>	0.9041
1200	0.9002	0.9046	0.9044	0.9049	0.9024

#### 4.3 評価文分類

拡張極性辞書の有効性を示すために、評価文分類による評価実験を行う。この実験では、以下の3つ手法についてそれぞれ実験し比較する:

- **General Inquirer (ベースライン)**: General Inquire を利用した評価文分類。
- **General Inquirer + 拡張辞書, 閾値**: 3.2.1節で述べた、閾値 $\theta_{pos}$ ,  $\theta_{neg}$ を考慮した拡張極性辞書とGeneral Inquirerを利用した評価文分類  
なお、 $(\theta_{pos}, \theta_{neg}) = (0.2, -0.4)$ とする。
- **General Inquirer + 拡張辞書,  $f(x)$** : 3.2.2節で述べた、拡張極性辞書のスコア $f(x)$ とGeneral Inquirerを利用した評価文分類。General Inquirerのスコアは、ポジティブであれば1、ネガティブであれば-1とした。

なお、拡張極性辞書において、助詞や前置詞など感情極性に直接関わらないと考えられる単語は事前に取り除いた。

モデルの設定は、池田らの実験設定に準じて行ない、素性表現としては、極性単語 $x$ 自身を含む周囲3単語と単語 $x$ に付与されたスコアを用いた。学習器にはSVMを使い、カーネルは2次の多項式カーネルを使った。正則化パラメータ $C$ は各手法ごとに最適なパラメータを実験を通して選択した。

実験結果を表5に示す。拡張極性辞書の利用によってベースラインと比べて良い正解率を得た。

拡張極性辞書のスコア $f(x)$ を利用する変種モデルは最も良い結果を得ており、文の感情極性分類に効果的に作用していることがわかる。

表5 分類結果

	正解率
General Inquirer (ベースライン)	0.692
+ 拡張辞書, 閾値	0.703
+ 拡張辞書, $f(x)$	0.716

#### 4.4 言語横断的な単語の感情極性分類

Mikolovらのモデル[26]を使って、日本語の単語の分散表現を英語の分散表現の空間に写像した。英単語に対して学習された感情極性分類器を用いて他の言語の単語の感情極性を判定した。その結果、80.1%の正解率で分類することができた。ここでは、300次元から300次元へ写像した場合についての結果を報告したが、次元数を含む様々な設定次第により分類結果は変化する可能性があり、そのような影響の調査は今後の課題とする。



- [24] Philip J. Stone, Dexter C. Dunphy, Marshall S. Smith, and Daniel M. Ogilvie. 1966. *The General Inquirer: A Computer Approach to Content Analysis*. The MIT Press.
- [25] 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)*, pages 79-86, Association for Computational Linguistics, 2002.
- [26] Tomas Mikolov, Quoc V. Le, and Ilya Sutskever. Exploiting similarities among languages for machine translation. *arXiv preprint arXiv:1309.4168* (2013).
- [27] Stephan Gouws, Yoshua Bengio, and Greg Corrado. BilBOWA: Fast bilingual distributed representations without word alignments. In *Proceedings of the 32<sup>nd</sup> International Conference on Machine Learning*, pages 748-756, 2015.
- [28] Will Y. Zou, Richard Socher, Daniel Cer, and Christopher D. Manning. Bilingual word embeddings for phrase-based machine translation. In *Proceedings of the Conference on Empirical Methods in Natural Language Processing (EMNLP)*, pages 1393-1398, 2013.
- [29] 小林のぞみ, 乾健太郎, 松本裕治, 立石健二, 福島俊一. 意見抽出のための評価表現の収集. 自然言語処理, Vol.12, pages 203-222, 2005.
- [30] 東山昌彦, 乾健太郎, 松本裕治, 述語の選択選好性に着目した名詞評価極性の獲得, 言語処理学会第 14 回年次大会論文集, pages 584-587, 2008.