

評価文書分類における肯定・否定に特化したモデルの構築と精度の検証

1X15C007-1 石岡健伸
指導教員 大野高裕

1. 研究背景と目的

評判分析における評価文書分類は近年になって注目を集めているタスクである[1]。特に、評判が記述された文章を肯定・中立・否定の3つに分類する研究が盛んに行われている。中でも、肯定の文章を否定と判別してしまう、または、否定の文章を肯定と判別してしまうことは、結論が正反対になってしまうため間違っはならない分類である。(例えば、「私はあなたのことが好きです。」という文章を「嫌い」と判別してしまうことは回避する必要がある)

そこで本研究では、肯定の文章を否定と判別しない、または、否定の文章を肯定と判別しないモデルを構築し、精度の検証を行う。

ここで、評価文書分類ではルールベースのアプローチと自動アプローチが考えられる。ルールベースのアプローチは、テキスト中に出現する肯定の単語と否定の単語の出現比率の差から対象となるテキスト全体の極性を算出する手法である。この手法では、極性語(肯定と否定の単語)のほか、極性語の出現位置、反転子や強調子などの極性変化子などを考慮した研究が行われている[1]。なお、この手法では、事前に肯定の単語と否定の単語にそれぞれ極性のラベル付けを行い、辞書の構築を行う必要がある。一方、自動アプローチは、機械学習アルゴリズムによって、テキストの特徴量と極性ラベルとの関係性を学習し、未ラベルテキストに対して学習済みモデルを適用することで極性を付与する手法である。本研究では、辞書構築を必要とせず高い精度が得られる自動アプローチをベースとしてモデルの構築を考える。自動アプローチの手法の1つに、Kimの手法[2]がある。この手法は、Word2Vecで学習した単語ベクトルを使い、CNN(Convolutional Neural Network)を用いている。本研究では、Kimの手法の課題点を踏まえた上で、ルールベースのアプローチで挙げられている因子も考慮することで肯定・否定の分類に特化したモデルの構築を考える。

2. 準備

2.1. Word2Vec

自然言語処理の分野において、単語を低次元の意味空間上のベクトルで表現する手法として Word2Vec が知られている。この手法は CBOW 法と Skip-gram 法に分けられるが、Skip-gram 法では、ある単語を与えた時にその周辺語を予測するタスクを解く。この際、意味が近い単語は周辺語も似ているはずという考え方の元でタスクを解くが、このモデルは対義語に弱いという課題点が挙げられる。例えば、「好き」と「嫌い」を入力語として与えた場合、出力として、「私はあなたのことが○○です」が考えられる(○○は入力語)。つまり、「好き」と「嫌い」は同じベクトル表現になってしまう。

2.2. CNN

Kimの手法では畳み込み演算を行なった後、得られた特徴量マップに対して最大値を抜き出す(以下 max-

pooling と呼ぶ)。この手法では、複数単語の組み合わせから特徴量マップを生成し、特徴量マップの中から最大値を抽出するため、文章中の全単語を考慮した特徴量になっていない。そのため、文章全体を見る必要がある極性反転を十分考慮できていないと考えられる。

3. 提案手法

3.1. 概要

従来の Kim[2]の手法では、評価文書分類で重要な因子である対義語と極性反転を考慮できていない。

そこで本研究では、極性語同士が類似しないよう対義語を考慮したベクトル表現を取得した上、文章全体を考慮した特徴量を抽出するモデルを提案する。まず、対義語を考慮したベクトル表現を取得するため、Kim[3]らによって提案された dLCE 法を用いる。これは、Skip-gram 法の目的関数に、単語の類義性・対義性に関する制約項を加えたモデルで目的関数 o は式(1)で定義される。

$$o = \sum_{w \in V} \sum_{c \in V} \{ (\#(w, c) \log \sigma(\text{sim}(w, c)) + k \#(w) P_0(c) \log \sigma(-\text{sim}(w, c)) + \frac{1}{\#(w, u)} \sum_{u \in W(c) \cap S(w)} \text{sim}(w, u) - \frac{1}{\#(w, u)} \sum_{v \in W(c) \cap A(w)} \text{sim}(w, v)) \} \quad (1)$$

ここで、 V はコーパスに含まれる単語集合、 $\#(w, c)$ は単語 w とその周辺に出現する単語を表すコンテキスト c との共起回数、 $\sigma(\cdot)$ はシグモイド関数、 $\text{sim}(w_1, w_2)$ は単語 w_1 と w_2 のベクトル間のコサイン類似度、 k はネガティブサンプリングにおけるパラメータ値、 P_0 はユニグラム分布、 $W(c)$ はコンテキスト c に対する LMI 値が正の単語集合、 $S(w) \cdot A(w)$ は単語 w に対してシソーラスから抽出した類義語・対義語集合を表す。LMI は式(2)で表され、2 単語間の共起度合いを表す。

$$LMI = \log \frac{p(x|y)}{p(x)} \quad (2)$$

式(1)において、 $\sum_{w \in V} \sum_{c \in V} \{ (\#(w, c) \log \sigma(\text{sim}(w, c)) + k \#(w) P_0(c) \log \sigma(-\text{sim}(w, c)) \}$ の項は Skip-gram 法と同様の項、 $(\frac{1}{\#(w, u)} \sum_{u \in W(c) \cap S(w)} \text{sim}(w, u))$ の項は類義語同士の分散表現を近づける項、 $(\frac{1}{\#(w, u)} \sum_{v \in W(c) \cap A(w)} \text{sim}(w, v))$ の項は対義語同士の分散表現を遠ざける項である。

次に、文章全体を考慮した特徴量を抽出するモデルを構築するため、Yang らによって提案された Attention 機構[4]を導入する。これは文章の意味を捉えるのに重要な単語を抽出する手法で式(3)(4)(5)で表される。

$$u_{it} = \tan h(W_w h_{it} + b_w) \quad (3)$$

$$\alpha_{it} = \frac{\exp(u_{it}^T u_w)}{\sum_t \exp(u_{it}^T u_w)} \quad (4)$$

$$s_i = \sum_t \alpha_{it} h_{it} \quad (5)$$

ここで、 $W_w \in \mathbb{R}^{C \times H}$ 、 $b_w \in \mathbb{R}^C$ 、 $u_w \in \mathbb{R}^C$ はモデルパラメ

ータである。Cはコンテキストベクトル u_w の長さを表す。 α_{it} は0から1までの実数値で、 α_{it} が1に近いほど対応する h_{it} の重要度が高いことを表す。また、本研究において、 h_{it} は畳み込み層で得られた特徴量マップとする。式(5)より、1つの特徴量マップから1つのプーリング結果 s_i が出力される。(以下、この演算を attention-pooling と呼ぶ)

3.2. 提案手法のアルゴリズム

提案手法のアルゴリズムを以下に示す。

STEP1: 入力データの取得

肯定・否定・中立の Label とその理由となるテキスト(コーパス)を数万から数百万用意する。コーパスについて、形態素解析を行うことで、文章を単語ごとに分けた後、各単語に ID を割り当てる。

STEP2: 分散表現の取得

dLCE法を用いて、各単語を数百次元のベクトル表現に変換する。

STEP3: 分類モデルの構築

肯定・否定・中立の Label とベクトル表現に変換した文章を attention-pooling を用いた CNN モデルで学習させる。

STEP4: モデルの性能評価

得られたモデルについて、Accuracy(全体のうち、どれだけの割合で正解できたか)と F 値(適合率と再現率の調和平均)を用いることで性能評価する。

4. 実験

4.1. 実験条件

分析対象のデータとして、金融・経済分野の市場を記述している景気ウォッチャー調査を用いた。このデータは比喻や皮肉が含まれておらず、評価文書分類しやすいデータである。データ期間は2012年から2017年、データ数は80333センテンス、ラベルは肯定・否定・中立の3値分類問題となるよう変換を行なった。また、シソーラスとして類義語と対義語を用意した。類義語は Wordnet を用いて、類義語集合を約43000ペア取得した。対義語は Weblio の対義語辞典をクロージングした後、ある単語の対義語の類義語関係にある単語は、元の単語の対義語として定義することで、対義語ペアを約17000ペアに拡張した。

4.2. 実験結果と考察

実験結果を表1,2,3,4に示す。表1,2は実際の分類結果のうち、各予測結果の割合を示している。表1,2より、提案手法は先行研究による手法と比較し、否定の文章を肯定と予測する割合と、肯定の文章を否定と予測する割合が減少する結果となった。加えて、表3より全体の Accuracy も向上していることがわかる。また、表4より中立の F 値が増加しており、中立の分類について検知の性能が良くなったと言える。

表1,2より、提案手法は、否定の文章を中立と予測する、肯定の文章を否定と予測する傾向が増加したと考えられ

表1. 先行研究による手法における予測と実際の結果(%)

		予測結果		
		否定	肯定	中立
実際の分類結果	否定	63.1%	4.49%	32.5%
	肯定	3.59%	74.7%	21.7%
	中立	18.6%	9.66%	71.7%

表2. 提案手法における予測と実際の結果(%)

		予測結果		
		否定	肯定	中立
実際の分類結果	否定	56.8%	3.90%	39.3%
	肯定	2.41%	72.8%	24.8%
	中立	14.7%	8.46%	76.9%

表3. 先行研究による手法と提案手法の Accuracy の比較

先行研究による手法	提案手法
70.1%	70.4%

表4. 先行研究による手法と提案手法の F 値の比較

ラベル	先行研究による手法	提案手法
否定	0.633	0.614
肯定	0.748	0.748
中立	0.715	0.728

る。例えば、図1の否定の文章について、先行研究による手法では肯定と予測していた一方、提案手法では中立と予測する結果となった。(赤くなっている単語はモデルがその単語に着目していることを表す)

プレミアム付商品券の販売でにぎわいをみせているものの、プラスの買物というより必要に迫られて購入しているようである。

図1. 注目単語をハイライト化した出力結果

図1の文章では、「プラス」という極性語に最も注目している上、「ものの」という極性反転も注目していたことより、モデルは極性語と極性反転を考慮していると考えられる。

5. 結論と今後の課題

本研究では、肯定の文章を否定と判別しない、または、否定の文章を肯定と判別しないモデルを構築した。今回は景気に関する文章に関して、モデルの有用性を示した。一方、否定の文章と肯定の文章について、中立と誤判別する割合が増加した。

今後の課題として、否定の文章と肯定の文章の精度の向上、また、注目単語が肯定または否定のどちらなのか分類することが挙げられる。

参考文献

- [1]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 = Journal of natural language processing Vol.13, No.3, pp.201-241 (2006)
- [2]Yoon Kim: "Convolutional neural networks for sentence classification", Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP), pp.1746-1751 (2014)
- [3]Kim Anh Nguyen, Sabine Schulte im Walde, Ngoc Thang Vu: "Integrating Distributional Lexical Contrast into Word Embeddings for Antonym-Synonym Distinction", Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers), pp.454-459 (2016)
- [4]Zichao Yang, Diyi Yang, Chris Dyer, Xiaodong He, Alex Smola, Eduard Hovy: "Hierarchical Attention Networks for Document Classification", Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, pp.1480-1489 (2016)