

テキスト感情分析におけるマルチタスク学習の有効性

浅野 晴暉[†] 松原 雅文[‡]

岩手県立大学大学院ソフトウェア情報学研究科[†] 岩手県立大学ソフトウェア情報学部[‡]

1. はじめに

近年、テキストから感情を機械的に識別する感情分析と呼ばれる技術の研究が盛んに行われている。感情分析は、ネガティブ・ポジティブの二クラスと、喜・怒・哀・楽といった多クラスの感情を分析する手法に大別されるが、特に後者の手法では高精度な分析が困難である。その理由として、利用可能な既存のデータセットが非常に少ないことがあげられる。そこで、絵文字を用いることで上記の問題を緩和し、多クラスの感情分析を実現している手法が存在する¹⁾。しかし、絵文字と感情の関係性の解釈が主観的であったり、絵文字はあくまで疑似ラベルとして作用するためノイズが含まれてしまうといった問題点が存在する。

そこで、本稿では絵文字を用いて自動生成したコーパスをマルチタスク学習に適用し、その有効性を検証する。マルチタスク学習とは、関連する複数のタスクを共同で学習することで知識を共有し、特定、あるいは複数タスクの精度を向上させることを目的とした学習法である²⁾。モデルに内在する重みの一部をタスク間で共有させることで、絵文字予測から得られる知識を伝達させ、主タスクである感情分析の精度を向上させることを目指す。

2. 関連研究

近年、絵文字を活用した感情分析の研究が行われている¹⁾。絵文字には感情を表す性質があるため、絵文字が表すと考えられる感情を疑似ラベルとすることで、絵文字を含むテキストに感情ラベルを自動付与することが可能となる。しかし、絵文字と感情の関係性の解釈が主観的であり、絵文字はあくまで疑似ラベルとして作用するため、テキストと感情の関係が矛盾するノイズが含まれてしまう場合がある。絵文字の感情を同定するのではなく、絵文字を予測する過程で得られた重みを感情分析に伝達することで精度を向上させた研究が存在する³⁾。この研究では絵文字予測で得られた重みを転移学習し、感情分析のタスクを向上させている。

そこで、本手法では絵文字予測と感情予測を共同で行うマルチタスク学習モデルを提案する。マルチタスク学習とは、関連する複数のタスクを共同で学習することで知識を共有し、特定、あるいは複数タスクの精度を向上させることを目的とした学習法であり、言語処理においても、その有効性が示されている²⁾。本手法では、絵文字を予測する過程で得られた知識を活用し感情分析の精度の向上を図るとともに、絵文字予測のタスクも同時に行えるようにすることを目指している。

3. 提案手法

3.1. マルチタスク学習

本手法では絵文字予測と感情値予測を対象とした、深層学習ベースのマルチタスク学習を行う。今回は、すべての隠れ状態をタスク間で共有し、タスク固有の全結合層をつないだシンプルなモデルを構築する。

3.1.1 絵文字予測の学習

絵文字は多くの場合において感情を表す性質をもつため、あるテキストにどの絵文字が付与されているかを予測することで、テキストと感情の適切なマッピングが得られると考えられる。予測値は式(1)(2)により求められる。テキスト $T = \{w_1, w_2, \dots, w_n\}$ をエンコーダに入力し隠れ状態 h を得る。その後、隠れ状態を絵文字予測固有の重み W_e で全結合し softmax 関数にかけ、出力値を求める。

$$h = \text{encode}(T) \quad (1)$$

$$y = \text{softmax}(W_e h + b_e) \quad (2)$$

3.1.2 感情値予測の学習

感情値予測には、ラベル付けされた感情分析のデータセットを用いる。予測値は式(3)(4)により求められる。絵文字予測と同様にテキスト表現をエンコードし、隠れ状態を感情予測固有の重み W_s で全結合し、出力値を求める。

$$h = \text{encode}(T) \quad (3)$$

$$y = W_s h + b_s \quad (4)$$

3.1.3 損失の算出

マルチタスク学習では、各タスクごとの損失が算出される。そのため、最終的な損失 L は、これらを合算することで求める必要がある。本手法では式(5)で

Effectiveness of Multi-Task Learning in Text Sentiment Analysis

Haruki ASANO[†], Masafumi MATSUHARA[‡]

[†]Graduate School of Software and Information Science, Iwate Prefectural University Graduate School, [‡]Faculty of Software and Information Science, Iwate Prefectural University

最終損失を求める。

$$L = \lambda_1 L_e + \lambda_2 L_s \quad (5)$$

λ のパラメータによって絵文字予測の損失 L_e と、感情予測の損失 L_s の重みを調整し加算する。本手法ではパラメータが共有された層を設けることで、知識を共有し各タスクの精度を向上させる狙いがある。

4. 実験

4.1. データセット

絵文字予測の学習データには Twitter API を用いて収集した、32 種類の絵文字が付与されたテキストを用いる。1 種類の絵文字に対して 2,000 件ずつ無作為にサンプリングした、総数 64,000 件のデータセットとなっている。対象とした絵文字を図 1 に示す。




図 1: 対象とした絵文字

感情分析のデータセットには WRIME⁴⁾ を用いる。このデータセットはテキストに対して Plutchik の輪モデルに基づき、喜び、悲しみ、期待、驚き、怒り、恐れ、嫌悪、信頼、の 8 感情を主観と客観両方の視点から 4 段階 (0: 無・1: 弱・2: 中・3: 強) でラベル付けされている。

4.2. 学習条件

絵文字予測を補助タスクとしたマルチタスク学習の有効性を検証するために複数の学習条件で比較を行う。テキストのエンコードには事前学習済みモデルの BERT²⁾ を用い、以下のモデル間での感情分析精度を比較することで有効性を評価する。

- BERT-base: [CLS] の隠れ状態を全結合し感情分析タスクを行う
- BERT-MTL: 提案手法に基づき、[CLS] の隠れ状態にタスク固有の全結合層を 2 つ連結し、感情分析タスクと絵文字予測を行う

最適化アルゴリズムには Adam を用い、学習係数はそれぞれ 0.01 としている。学習損失に用いるパラメータ λ_1 , λ_2 は 0.6, 0.4 に設定している。評価は WRIME のテストデータ 2,000 件に対する平均絶対誤差 (MAE) で行う。

4.3. 実験結果

評価結果を表 1 に記す。なお、分析は 8 種類の感情を対象にしているが、ここでは喜び、悲しみを抜粋している。表 1 より、BERT-base と BERT-MTL 間で平

²⁾<https://huggingface.co/cl-tohoku/bert-base-japanese-whole-word-masking>

表 1: 各モデルの感情カテゴリに対する MAE

モデル	喜び	悲しみ	平均
BERT-base	0.61	0.68	0.53
BERT-MTL	0.69	0.64	0.53

均の MAE に差がなく、モデルの精度は同程度であることが確認できる。しかし、本手法では悲しみの MAE が減少し、逆に喜びの MAE が増加している。つまり、絵文字予測により得られた表現は悲しみの感情を予測するのに有益に作用したが、逆に喜びの感情予測には悪影響を及ぼしたと考えられる。

テストデータに含まれている”あーテスト勉強 ()”という悲しみの値が 2 のテキストに対しての出力を確認すると、BERT-base の予測値が 0.4, BERT-MTL では 1.2 となり、予測値を適切な値に補正できていることが確認できる。そのため、喜びの予測のみに強く寄与している絵文字を取り除くことで、絵文字で自動生成したコーパスを用いて精度の向上が図れると考えられる。

5. おわりに

本稿では絵文字を用いて自動生成したコーパスをマルチタスク学習に適用し、その有効性を検証した。実験結果から悲しみに対する分析精度が向上し、悲しみの感情予測に対しては本手法の有効性が示された。しかし、感情によっては精度が低下してしまうものもあった。そのため、今後は対象とする絵文字の適切な抽出方法の検討を行い、感情予測への影響を考察する予定である。

謝辞

本研究の一部は JSPS 科研費 15K00155 の助成を受けたものである。

参考文献

- 1) 林友超, 崔鴻翌, 宇津呂武仁. ツイート中の主観極性同定モデルの訓練事例収集における絵文字の利用. 知能と情報, Vol. 32, No. 5, pp. 923–933, 2020.
- 2) Joachim Bingel and Anders Søgaard. Identifying beneficial task relations for multi-task learning in deep neural networks. *CoRR*, Vol. abs/1702.08303, , 2017.
- 3) Bjarke Felbo, Alan Mislove, Anders Søgaard, Iyad Rahwan, and Sune Lehmann. Using millions of emoji occurrences to learn any-domain representations for detecting sentiment, emotion and sarcasm. In *Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing*, 2017.
- 4) Tomoyuki Kajiwara, Chenhui Chu, Noriko Takemura, Yuta Nakashima, and Hajime Nagahara. WRIME: A new dataset for emotional intensity estimation with subjective and objective annotations. In *Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, 2021.