

絵文字予測を感情分析の補助タスクとした マルチタスク学習手法

浅野 晴暉^{†1,a)} 松原 雅文^{†2,b)}

概要: テキスト感情分析には、喜・怒・哀・楽といった多種の感情を対象とする手法が存在するが、高精度な分析が困難である。その理由としては、ネガティブ・ポジティブの2値を対象とした場合と比較して、感情の粒度が細かく、データセットの作成コストが高いことが挙げられる。こうした背景から、感情分析におけるデータ拡張が重要視されており、絵文字を用いた手法が存在する。絵文字が表すと考えられる感情を定義することで、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、従来の手法では、感情の定義や重みづけが主観的であるといった問題点が存在する。そこで、本手法では絵文字を用いて教師データを自動生成し、それをマルチタスク学習に適用する。本手法は絵文字が表す感情を定義する際に生じる主観的な重みに影響されることなく、感情分析に有益な情報のみを伝達させることにより、感情分析の性能向上を目指している。

キーワード: 感情分析, 絵文字, マルチタスク学習

1. はじめに

テキスト感情分析はテキストから感情を機械的に識別する技術である。この技術には、喜・怒・哀・楽といった多種の感情を分析する手法が存在するが、ネガティブ・ポジティブの2値を対象とした分析と比較すると感情の粒度が細かいため、高精度な分析が困難となっている。日本語において、従来行われていた多種の感情分析の多くは、感情語辞書を用いたルールベースの手法である。しかし、ルールベースの手法では文法規則や多義語の影響により、文脈の識別が難しいといった問題が存在する。テキストには様々な感情が含まれているため、感情極性の分析だけでは不十分なケースが存在する [1]。そのため、多種の感情分析精度を向上させることには意義があり、その実現には多量のデータセットや深層学習の技術が必要であると考えられる。しかし、感情は機械学習の分類対象の中でも比較的曖昧な概念である。そのため、感情分析は解釈の曖昧性から、データセットの作成に、よりコストがかかるタスクであると考えられる。

上記の背景から、絵文字を用いた Distant supervision に

より、感情分析における教師データを自動構築する研究が存在する。Distant supervision は知識ベースから得られる手掛かりをもとに生データから関係を抽出し、教師データを自動生成する手法である [2]。絵文字が感情表現に用いられる性質を利用し、あらかじめ絵文字が表すと考えられる感情を定義する。そして、ある絵文字を含んだテキストは定義した感情を表すという仮定を置き、そのテキストに感情ラベルを付与するという手法である [3]。この手法は、低コストで多量の教師データを自動構築できる。しかし、データ内にノイズが含まれることや、絵文字と感情との関係性の解釈に主観的な要素や曖昧性を含んでしまうことが問題となる。

そこで、本稿では絵文字を用いて自動生成した教師データを適切に学習し、多種の感情分析精度を向上させる手法を提案する。本手法では、絵文字が表すと考えられる感情を客観的な指標を用いて定義することで、良質な教師データを生成する。さらに、そのデータを適切に学習するためにマルチタスク学習を行う。マルチタスク学習とは、複数のタスクを共同で学習する手法である。この学習法は関連するタスクを共同で学習した場合に、特定、あるいは複数タスクの精度を向上させることが知られている。

本手法では、Emotag1200 と呼ばれるデータセットをもとに絵文字の感情を定義する [4]。Emotag1200 は 150 個の絵文字と 8 種類の感情 (喜び, 悲しみ, 期待, 驚き, 怒り,

^{†1} 岩手県立大学大学院 ソフトウェア情報学研究所
Iwate Prefectural University

^{†2} 岩手県立大学大学 ソフトウェア情報学部
Iwate Prefectural University

a) g231t002@s.iwate-pu.ac.jp

b) masafumi@iwate-pu.ac.jp

恐れ、嫌悪、信頼)との連想性が、9人の評価者によってアノテーションされている。そして、テキストからその値を予測するタスクを絵文字予測タスクと定義し、これを感情分析タスクの補助タスクに用いる。この処理によって、定義した感情の主観性や曖昧性を含む重みに影響されることなく、感情分析に有益な情報のみを伝達させ、感情分析の性能を向上させることを目指している。

2. 関連研究

2.1 感情分析

日本語において、多種の感情を対象とした感情分析には感情語辞書を用いた手法が多い。主に、「感情表現辞典」によるパターンマッチングやそれを拡張した手法である ML-Ask が提案されている [5], [6], [7]。一方で、英語など他言語を対象とした多種の感情分析の研究では、Transformer をはじめとした深層学習を用いた研究が盛んである [1], [8], [9]。英語を対象とした感情分析では、プルチックの 8 感情などを分析対象にしている [10], [11]。

感情分析におけるリソース不足に言及し、絵文字を用いた Distant supervision により、ラベル付けのコストを削減しようとする研究が行われてきた。基本的には、絵文字が表す感情を定義し、絵文字を含むテキストに定義した感情ラベルを付与する手法である [3], [12], [13]。感情を定義せずに絵文字を予測する過程で得られた重みを転移学習する研究も存在する [14], [15]。また、絵文字の代わりにハッシュタグを用いる手法も存在する [16]。

2.2 マルチタスク学習

昨今における、深層学習の普及によりマルチタスク学習が盛んに活用されており、テキスト分類や感情分析においても適用事例が多数存在する [17], [18]。マルチタスク学習を行うモデルには、共有層とは別にタスク固有の層を設けることでタスク間で不変な空間と固有の空間に分離するモデルが存在する [19]。上記モデルに敵対的損失を加えることで、より正確に空間を分離することのできる、敵対的マルチタスク学習 (Adversarial Multi-Task Learning) という手法も存在する [20]。敵対的マルチタスク学習は、近年では、アスペクトベースの感情分析やユーモアの検出などに応用されている [21], [22]。

3. 提案手法

3.1 絵文字付きデータの収集

絵文字は Unicode 文字として定義されているため、絵文字をクエリとしてパターンマッチングすることができる。そのため、絵文字付きのテキストを多数収集することは、容易な処理である。多量のテキストリソースから、絵文字

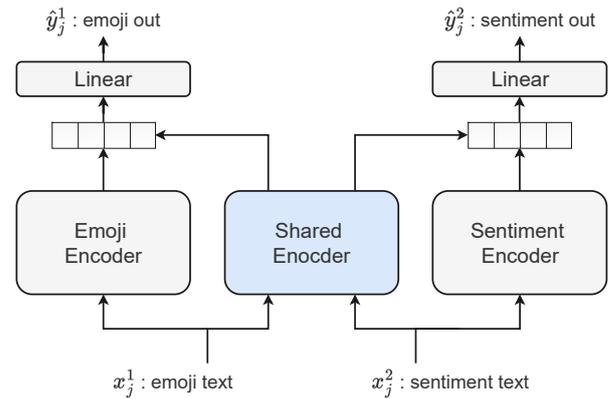


図 1 マルチタスク学習モデルのアーキテクチャ

付きテキストを抽出する手段として Twitter API^{*1}が利用可能である。本稿では Twitter API を用いて対象となる絵文字を含むツイートを集集し、それを絵文字予測の学習に用いる。

3.2 マルチタスク学習の設定

本手法では絵文字予測と感情値予測の 2 タスクを対象とした、深層学習ベースのマルチタスク学習を行う。モデルのアーキテクチャを図 1 に示す。各タスクはサンプル数 n_t のトレーニングデータからなるデータセット D_t を持つ。 t はタスクの id であり、絵文字予測を 1、感情値予測を 2 とする。すなわち、 $D_t = \{x_j^t, y_j^t\}_{j=1}^{n_t}$ であり、 x_j^t はタスク t の j 番目の入力テキストサンプル、 y_j^t はそのラベルである。テキストの入力形状は $x_j^t \in \mathbb{R}^l$ であり、 l はシーケンス長、ベクトルの各要素は単語の index である。なお、シーケンスは任意の定数によって padding され、固定長となる。

テキストはトークナイズされた後、Shared Encoder とタスク固有の Encoder に入力され、それぞれの特徴量が算出される。その後、二つの特徴量を結合し全結合することで各タスクの出力を求める。感情分析は同一の単語、文章表現であってもドメインの違いにより意味合いが大きく異なるケースがある [9]。そのため、仮に感情値予測と異なるドメインから収集した絵文字付きデータを用いる際、性能が低下してしまう恐れがある。そこで、本手法ではドメイン汚染による負の知識伝達を防ぐために、共有層とは別にタスク固有の層を設けている [20]。

3.3 BERT による Text Encoding

本手法では Encoder に BERT (Bidirectional Encoder Representations from Transformers) を用いる [23]。入力 x_j^t は、はじめに埋め込み次元 d_e に Word Embedding され $H \in \mathbb{R}^{l \times d_e}$ に変換される。位置エンコーディングと文種の判別が行われた後、Multi-Head Attention が計算される。式 (1) により query, key, value ベクトルを算出する。

^{*1} <https://developer.twitter.com/en/docs/twitter-api>

$$\begin{aligned} \mathbf{Q}_i &= \mathbf{H}\mathbf{W}_i^Q \\ \mathbf{K}_i &= \mathbf{H}\mathbf{W}_i^K \\ \mathbf{V}_i &= \mathbf{H}\mathbf{W}_i^V \end{aligned} \quad (1)$$

i は Attention head のインデックスを表し, $\mathbf{W}_i^Q \in \mathbb{R}^{d_e \times d_q}$, $\mathbf{W}_i^K \in \mathbb{R}^{d_e \times d_k}$, $\mathbf{W}_i^V \in \mathbb{R}^{d_e \times d_v}$ は特徴量の次元を変換する重み行列である. そして, 式 (2) により, Multi-Head Attention を計算する.

$$\begin{aligned} \text{Attention}(\mathbf{Q}_i, \mathbf{K}_i, \mathbf{V}_i) &= \text{softmax}\left(\frac{\mathbf{Q}_i^t \mathbf{K}_i}{\sqrt{d_k}}\right) \mathbf{V}_i \\ \text{MultiHead}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) &= \text{Concat}(\text{head}_1, \dots, \text{head}_h) \mathbf{W}^O \\ \text{where head}_i &= \text{Attention}(\mathbf{Q}_i, \mathbf{K}_i, \mathbf{V}_i) \end{aligned} \quad (2)$$

複数の head を Concat し, $\mathbf{W}^O \in \mathbb{R}^{hd_v \times d_e}$ により, もとの埋め込み次元に戻す. 複数の正則化を適用し, 最終的に GELU 関数にかけることで出力を得る.

なお, 以下では簡略化のために, 上記の操作を層数分繰り返して得られた BERT によるエンコードを式 (3) で表す.

$$\mathbf{H} = \text{BERT}(x_j^t) \quad (3)$$

3.4 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. そのため, テキストを入力とし, 付与されている絵文字を予測するタスクからは, テキストと感情との関係性を表す知識表現が得られると考えられる [14].

絵文字予測のアーキテクチャを図 2 に示す. Encoder に BERT を用いているため, 入力するテキストの文頭は [CLS], 文末は [SEP] トークンとなる. 予測するラベルは付与されていた絵文字の Emotag1200 の値である. そのため, 絵文字予測と定義しているが, 実際には絵文字から生成される感情値を予測するタスクである. 単に絵文字を予測するのではなく, 絵文字が表すと考えられる感情を予測することで絵文字と感情とのマッピングを明確にする狙いがある.

テキスト x_j^1 を絵文字予測固有の Encoder である $\text{BERT}_{\text{emoji}}$ と, 感情値予測タスクと共有された $\text{BERT}_{\text{shared}}$ にそれぞれ入力し, 隠れ状態 $\mathbf{H}_{\text{emoji}} \in \mathbb{R}^{l \times d_e}$ と $\mathbf{H}_{\text{shared}} \in \mathbb{R}^{l \times d_e}$ を算出する.

$$\mathbf{H}_{\text{emoji}} = \text{BERT}_{\text{emoji}}(x_j^1) \quad (4)$$

$$\mathbf{H}_{\text{shared}} = \text{BERT}_{\text{shared}}(x_j^1) \quad (5)$$

その後, それぞれの [CLS] に対応する隠れ状態を結合しテキスト特徴量 $C_{\text{emoji}} \in \mathbb{R}^{2d_e}$ を算出し, 全結合することで出力を求める.

$$C_{\text{emoji}} = \text{Concat}(\mathbf{H}_{\text{emoji},[\text{CLS}]}, \mathbf{H}_{\text{shared},[\text{CLS}]}) \quad (6)$$

$$\hat{y}_j^1 = C_{\text{emoji}} \mathbf{W}^1 + b^1 \quad (7)$$

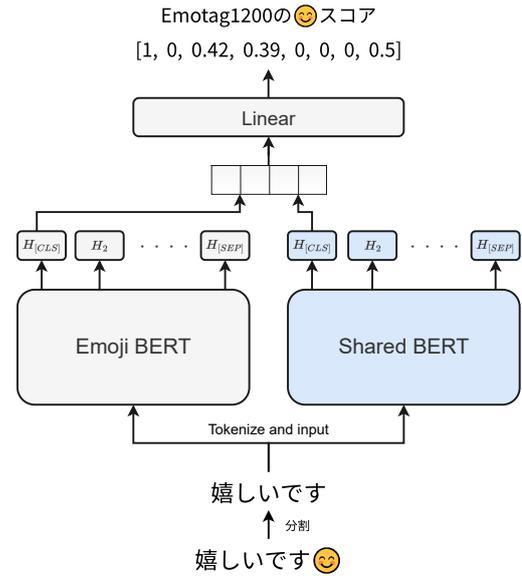


図 2 絵文字予測の学習

3.5 感情値予測の学習

感情値予測も絵文字予測と同様に行われる. テキスト x_j^2 を感情値予測のみに用いる $\text{BERT}_{\text{sent}}$ と絵文字予測タスクと共有された $\text{BERT}_{\text{shared}}$ にそれぞれ入力し, 隠れ状態 $\mathbf{H}_{\text{sent}} \in \mathbb{R}^{l \times d_e}$ と $\mathbf{H}_{\text{shared}} \in \mathbb{R}^{l \times d_e}$ を得る.

$$\mathbf{H}_{\text{sent}} = \text{BERT}_{\text{sent}}(x_j^2) \quad (8)$$

$$\mathbf{H}_{\text{shared}} = \text{BERT}_{\text{shared}}(x_j^2) \quad (9)$$

[CLS] に対応する隠れ状態 $\mathbf{H}_{\text{shared},[\text{CLS}]}$ と $\mathbf{H}_{\text{sent},[\text{CLS}]}$ を結合した $C_{\text{sent}} \in \mathbb{R}^{2d_e}$ を全結合し出力値を求める.

$$C_{\text{sent}} = \text{Concat}(\mathbf{H}_{\text{shared},[\text{CLS}]}, \mathbf{H}_{\text{sent},[\text{CLS}]}) \quad (10)$$

$$\hat{y}_j^2 = C_{\text{sent}} \mathbf{W}^2 + b^2 \quad (11)$$

3.6 損失の算出

マルチタスク学習では, 各タスクの損失が算出されるため, 最終的な損失 L は, これらを合算することで求める. 本手法では式 (12) で最終損失を求める.

$$L = \lambda_1 L_e + \lambda_2 L_s \quad (12)$$

λ_t の重みパラメータによって絵文字予測の損失 L_e と, 感情値予測の損失 L_s を調整する.

このように本手法においては, 上記損失を共同で最適化することで, 絵文字予測タスクで得られた知識表現を感情値予測に伝達する. 得られた知識が感情分析に有益に作用し, 感情分析の性能を向上させることが期待される.

4. 実験

4.1 データセット

感情値予測のデータセットには WRIME[24] を用いる. WRIME は主観と客観両方の視点から, テキストに喜び,

表 1 選定した絵文字とサンプル数

感情	絵文字	Name	総数
喜び	😊	smiling face	531
悲しみ	😭	crying face	2,389
驚き	❗	exclamation mark	2,517
怒り	😡	pouting face	10,252
恐れ	😨	fearful face	4,034
嫌悪	👎	thumbs down	5,361
信頼	😏	kissing face with smiling eyes	9,799

悲しみ, 期待, 驚き, 怒り, 恐れ, 嫌悪, 信頼の 8 感情が 4 段階 (0: 無・1: 弱・2: 中・3: 強) でラベル付けされている。今回の実験には客観で付与された 3 人のラベル値を平均したものをを用い, データは最小値 0, 最大値 1 に正規化する。また, 学習セット, 検証セット, テストセットは WRIME に割り当てられたものをを用い, 数はそれぞれ 30,000, 2,500, 2,500 となっている。

絵文字予測のデータセットは対象となる絵文字を含むツイートを抽出することで生成される。本実験では Emotag1200 の各感情カテゴリにおいて最も値が大きい絵文字を, その感情の代表絵文字とし対象にした。また, サンプルサイズに関しては, 感情カテゴリが不均衡なることを防ぐためオーバーサンプリングを行った。データセット内で値が 1 以上のラベルを確認したところ, 期待のラベルが最も多く 11,391 件であった。そこで, 11,391 とラベル数の差分だけ, 期待を除く各感情の代表絵文字を含むテキストを抽出した。対象とした絵文字, およびサンプル数を表 1 に示す。なお, ラベルの強弱は無視しており, 絵文字には代表となる感情以外のスコアも付与されているため, 各感情のラベル数や値は完全に均等になってはいない。

4.2 比較モデル

本実験では, 以下のモデルの性能を比較する。

- BERT_{BASE}: WRIME を用いて感情値予測の学習
- BERT_{AUG}: WRIME と絵文字予測データセットを用いて感情値予測の学習
- BERT_{MTL}: WRIME と絵文字予測データセットを用いて, 共有層のみでマルチタスク学習
- BERT_{SP-MTL}: WRIME と絵文字予測データセットを用いて, 共有層とタスク固有の層でマルチタスク学習 (提案手法)

BERT_{AUG} は WRIME と絵文字予測データセットを結合したものを感情値予測として学習したモデルである。絵文字予測データセットは Emotag1200 によって, WRIME と同カテゴリの感情値に変換されているため, 結合することができる。このモデルは, マルチタスク学習のモデルと異なり, 絵文字予測データセットのラベルが WRIME と同等

に学習される。WRIME は $[0, 3]$ のラベル y が $[0, 1]$ に正規化されており, Emotag1200 も同様に $[0, 1]$ である。そのため, Emotag1200 のラベル y' と y の対応関係は $y = 3y'$ になっている。

なお, いずれのモデルにおいても東北大学の乾研究室で公開されている日本語 BERT 訓練済みモデル*2 を用いる。

4.3 学習設定

Encoder に用いる BERT は, 層数: 12, 隠れ状態の次元: 768, Attention head の数: 12 となっており, シーケンス長は 64 としている。オプティマイザーには AdaBound[25] を用い, 学習率の初期値は 1×10^{-5} , 最終学習率は 1×10^{-2} である。BERT_{MTL} および BERT_{SP-MTL} の学習損失に用いる重みパラメータ λ_1, λ_2 は, 学習の収束が均一になるように調整し, それぞれ 0.4, 0.6 に設定している。出力は, 絵文字予測に恒等関数, 感情値予測にシグモイド関数を用いる。損失関数は, 絵文字予測に MSE (Mean squared error), 感情値予測に Binary cross entropy を用いる。

4.4 評価指標

評価は MAE (Mean absolute error), P@k, R@k, F@k を用いる。マルチラベル分類は, ラベルの次元数とは対照的に, 各インスタンスには少量のラベルしか付与されていない場合が多い。そのため, 上位何件かを対象にしたランク評価が用いられる [26]。

WRIME のデータにおいても, 重要な感情は上位 1~3 件ほどであると考えられる。そのため, 全体の予測値の誤差を把握するために MAE を算出し, 重要な感情の識別力を把握するためにランク指標を用いる。

4.5 性能評価

表 2 に各モデルの MAE を示す。表 2 より, BERT_{MTL} の MAE が平均的に低くなっていることが確認でき, 最も予測値の誤差が少ないモデルとなっている。また, 提案手法である BERT_{SP-MTL} は BERT_{MTL} には若干, 劣っているものの, BERT_{BASE} よりも誤差は小さくなっている。上記の結果から, マルチタスク学習において絵文字予測で得られた知識表現は感情分析に一定程度有益に寄与していると考えられる。

一方で, BERT_{AUG} は他のモデルと比較し, 誤差が著しく増加している。この結果は, WRIME と絵文字予測データセット間におけるラベルの対応関係が適切でなかったことが原因であると考えられる。また, 絵文字予測データ内に含まれるノイズに過剰に適合してしまったことも原因であると考えられる。ラベルの重みをチューニングすることで性能が改善される可能性もあるが, ノイズのフィルタリ

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

表 2 各モデルの各感情カテゴリに対する MAE

model	Joy	Sadness	Anticipation	Surprise	Anger	Fear	Disgust	Trust	Ave
BERT _{BASE}	.152	.109	.144	.135	.017	.098	.074	.041	.096
BERT _{AUG}	.162	.124	.150	.147	.058	.117	.099	.071	.116
BERT _{MTL}	.149	.098	.141	.129	.018	.095	.075	.040	.091
BERT _{SP-MTL}	.150	.100	.136	.130	.017	.098	.073	.038	.093

表 3 各モデルの P@k, R@k, F@k

model	P@1	P@2	P@3	R@1	R@2	R@3	F@1	F@2	F@3
BERT _{BASE}	.698	.572	.467	.443	.672	.790	.542	.618	.587
BERT _{AUG}	.678	.535	.446	.427	.627	.756	.524	.577	.561
BERT _{MTL}	.734	.585	.476	.465	.688	.807	.569	.633	.599
BERT _{SP-MTL}	.724	.581	.471	.458	.680	.799	.561	.626	.593

ングやスケージングを含め、感情分析に有益な知識だけを伝達することのできるマルチタスク学習の方が、有効な学習法であると考えられる。

表 3 に各モデルの P@k, R@k, F@k を示す。表 3 より、マルチタスク学習を行ったモデルのランク指標が、BERT_{BASE}, BERT_{AUG} と比較し、すべて向上していることが確認できる。よって、全体的な予測値の誤差だけでなく、重要な感情を識別する能力もマルチタスク学習によって向上したと考えられる。BERT_{AUG} はランク評価においても、性能が低下しているが、この結果も MAE が増加した理由と同様であると考えられる。

今回の実験では、タスク固有の層を設けた BERT_{SP-MTL} よりも、BERT_{MTL} の方が全体的に性能が高かった。この結果は、今回用いたデータセットが絵文字予測、感情予測ともにツイートより生成されたテキストであったことから、ハードにパラメータを共有したモデルが適していたためだと考えられる。しかし、Anticipation, Anger, Disgust, Trust は BERT_{MTL} よりも MAE が減少するなど、特定の感情においては、提案手法である BERT_{SP-MTL} の性能が向上していると考えられる。

また、同一ドメインの絵文字データを収集することができなかった場合には、他ドメインの絵文字データを用いるケースが想定される。そして、ドメインが異なるデータでマルチタスク学習を行う場合には、BERT_{SP-MTL} の方が適切な学習を行うことができ、性能が向上すると考えられる。そのため、今後はドメインが異なるデータセットでの評価を行い、他ドメインにおける絵文字データの適用可能性や、BERT_{SP-MTL} の有効性を再検証する必要がある。

4.6 予測値の分析

マルチタスク学習による特徴量の変化を考察するために、予測値の分析を行った。なお、特徴量を捉えやすくする意図から、BERT_{SP-MTL} ではなく BERT_{MTL} での結果を抜き BERT_{BASE} との比較を行う。表 4 にモデル

間で最も F@2 の値に差があったテキストを示す。表 4 は BERT_{BASE} と BERT_{MTL} の F@2 を比較したときに、BERT_{MTL} の F@2 が高くなり、かつその差が最も大きくなった WRIME テストデータ内のテキストである。正解集合が {anticipation, fear} であり、予測値上位 2 件の感情は BERT_{BASE} が {sadness, disgust}, BERT_{MTL} は {anticipation, fear} となっている。上記のように、マルチタスク学習を行うことで F 値を大きく向上させることができたサンプルが、テストデータ内に存在していることが確認できる。

図 3 にテキストを予測した時の各モデルの Self Attention を示す。上が BERT_{BASE}, 下が BERT_{MTL} のものであり、表 4 のテキストを予測した時に、[CLS] を query ベクトルとして算出される Self Attention を示している。[CLS] に対応する隠れ状態をテキスト特徴量に用いているため、上記の値は予測に対する単語の寄与率を表していると考えられる。図 3 より、BERT_{BASE} では“根”という単語の Attention が高いのに対して、BERT_{MTL} では減少していることがわかる。また、WRIME のトレーニングセット内からは、“結局昨日はジムで汗を流し、そのまま飲みに行き、カラオケで暴れ、精も根も尽き果てて眠りに落ちた。喉がいたい…”, “久々真面目にお稽古に行こうと思ったら、道具が根こそぎない。久々でそれはダメだろ〜と躍りになってさがしてみたが、ない。気づけばもう 30 分遅刻している。ほんっと、どーしょーもねーなあ。”という“根”を含むネガティブなサンプルが存在していることが分かった。この結果から、BERT_{BASE} はデータセットへの過学習により“根”をネガティブな感情が強い単語と解釈し、結果的に sadness, disgust の感情が強まってしまった可能性がある。一方で、マルチタスク学習を行うことで多様な感情表現を学習し、“根”という単語への解釈が広がった結果、BERT_{MTL} では anticipation といったポジティブな感情を出力できたと考えられる。上記より、マルチタスク学習による特徴量の変化の恩恵が確認でき、BERT_{SP-MTL} も同様

表 4 モデル間で最も F@2 の値に差があったテキスト

モデル	テキスト	正解集合	予測集合	F@2
BERT _{BASE}	いろいろ言っちゃう時あるけど根底にあるのは	{anticipation, fear}	{sadness, disgust}	0
BERT _{MTL}	えびの素晴らしさ知らないの勿体ないって		{anticipation, fear}	1.0

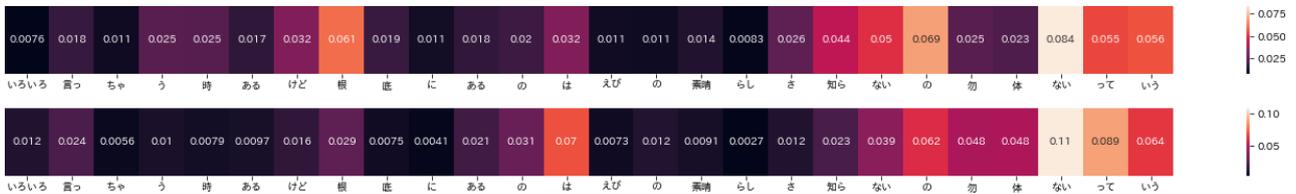


図 3 テキストを予測した時の各モデルの Self Attention

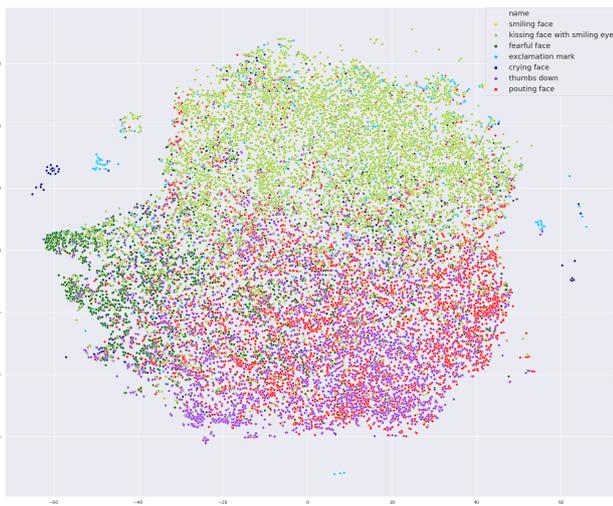


図 4 絵文字データの特徴空間

の恩恵を受けていると考えられる。しかし、BERT_{SP-MTL} はタスク固有の層を追加したことによる特徴量の変化があると考えられるため、今後はその考察も行う必要がある。

4.7 絵文字データの特徴空間

図 4 に絵文字データの特徴空間を示す。学習済みの BERT_{MTL} に絵文字データを入力し、出力された 768 次元のテキスト特徴量を t-SNE[27] で二次元に可視化したものである。図 4 より、絵文字ごとに一定のクラスターを形成していることが確認できる。この結果から、テキストを入力とし、絵文字疑似ラベルを予測するタスクは、適切な分離空間に射影され、感情カテゴリによってクラスターを形成していると考えられる。しかし、pouting face, thumbs down の特徴に関しては、散布図上で重なっている部分が多い。これは、それぞれの絵文字における変換後のラベルに“怒り”、“嫌悪”の感情が混在していることや、類似したテキスト表現に、これら二つの絵文字が付与されることが多いためだと考えられる。上記より“怒り”、“嫌悪”の識別は難しく、その代表絵文字である pouting face, thumbs down は類似する絵文字であるといえる。

5. おわりに

感情分析においては、解釈の曖昧性からデータセットの作成にコストがかかる。そこで、本稿では絵文字を用いて教師データを自動生成し、それをマルチタスク学習に適用させる手法の提案を行った。具体的には、タスク固有の BERT とタスク間で共有された BERT を設け、それぞれの Encoder から得られる特徴量を結合して、感情値と絵文字を予測するモデルを構築した。

実験では、本提案手法における MAE の減少や F@k の上昇が確認でき、絵文字予測が感情分析の性能を向上させるための補助タスクとして有効であることを示した。共有層のみを用いたシンプルなマルチタスク学習モデルと提案手法の性能はほとんど同程度であったが、Anticipation, Anger, Disgust, Trust の MAE が減少しているなど、特定の感情においては提案手法の性能が向上していることが確認された。また、仮に同一ドメインの絵文字データを収集することができなかった場合には、他ドメインの絵文字データを用いるケースが想定される。このように、ドメインが異なるデータでマルチタスク学習を行う場合には、特に本提案手法の利点が生かされると考えられる。

そのため、今後はドメインが異なるデータセットでの評価を行い、他ドメインにおける絵文字データの適用可能性や提案手法の有効性を再検証する予定である。

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] Nafis Irtiza Tripto and Mohammed Eunus Ali. Detecting multilabel sentiment and emotions from bangla youtube comments. In *2018 International Conference on Bangla Speech and Language Processing (ICBSLP)*, pp. 1–6, 2018.
- [2] Mike Mintz, Steven Bills, Rion Snow, and Daniel Jurafsky. Distant supervision for relation extraction without labeled data. In *Proceedings of the Joint Conference of*

- the 47th Annual Meeting of the ACL and the 4th International Joint Conference on Natural Language Processing of the AFNLP, pp. 1003–1011, Suntec, Singapore, August 2009.
- [3] 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.
- [4] Abu Awal Md Shoeb and Gerard de Melo. EmoTag1200: Understanding the association between emojis and emotions. In *Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, pp. 8957–8967, Online, November 2020.
- [5] Michal Ptaszynski, Pawel Dybala, Rafal Rzepka, Kenji Araki, and Fumito Masui. ML-ask: Open source affect analysis software for textual input in Japanese. *Journal of Open Research Software*, Vol. 5, No. 1, p. 16, 2017.
- [6] 鳥海不二夫, 榊剛史, 吉田光男. ソーシャルメディアを用いた新型コロナ禍における感情変化の分析. 人工知能学会論文誌, Vol. 35, No. 4, pp. F-K45–1–7, 2020.
- [7] 俊藤田, 孝典鷹野. コンテンツのユーザに与える感情を考慮したコンテンツ推薦手法の検討. 情報処理学会論文誌, Vol. 61, No. 6, pp. 1200–1209, Jun. 2020.
- [8] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N Gomez, Łukasz Kaiser, and Illia Polosukhin. Attention is all you need. In I. Guyon, U. Von Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, and R. Garnett, editors, *Advances in Neural Information Processing Systems*, Vol. 30. Curran Associates, Inc., 2017.
- [9] Wenhao Ying, Rong Xiang, and Qin Lu. Improving multi-label emotion classification by integrating both general and domain-specific knowledge. In *Proceedings of the 5th Workshop on Noisy User-generated Text (W-NUT 2019)*, pp. 316–321, Hong Kong, China, November 2019.
- [10] ROBERT PLUTCHIK. Chapter 1 - a general psycho-evolutionary theory of emotion. In Robert Plutchik and Henry Kellerman, editors, *Theories of Emotion*, pp. 3–33. Academic Press, 1980.
- [11] Neel Kant, Raul Puri, Nikolai Yakovenko, and Bryan Catanzaro. Practical text classification with large pre-trained language models, 2018.
- [12] Alec Go, Richa Bhayani, and Lei Huang. Twitter sentiment classification using distant supervision. *CS224N project report, Stanford*, Vol. 1, No. 12, 2009.
- [13] Jared Suttles and Nancy Ide. Distant supervision for emotion classification with discrete binary values. In *International Conference on Intelligent Text Processing and Computational Linguistics*, pp. 121–136. Springer, 2013.
- [14] 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*, pp. 1615–1625, Copenhagen, Denmark, September 2017.
- [15] Susann Boy, Dana Ruiters, and Dietrich Klakow. Emoji-based transfer learning for sentiment tasks. In *Proceedings of the 16th Conference of the European Chapter of the Association for Computational Linguistics: Student Research Workshop*, pp. 103–110, Online, April 2021.
- [16] Saif Mohammad. #emotional tweets. In **SEM 2012: The First Joint Conference on Lexical and Computational Semantics – Volume 1: Proceedings of the main conference and the shared task, and Volume 2: Proceedings of the Sixth International Workshop on Semantic Evaluation (SemEval 2012)*, pp. 246–255, Montréal, Canada, 7–8 June 2012.
- [17] Joachim Bingel and Anders Søgaard. Identifying beneficial task relations for multi-task learning in deep neural networks. In *Proceedings of the 15th Conference of the European Chapter of the Association for Computational Linguistics: Volume 2, Short Papers*, pp. 164–169, Valencia, Spain, April 2017.
- [18] Jian Zhang, Ke Yan, and Yuchang Mo. Multi-task learning for sentiment analysis with hard-sharing and task recognition mechanisms. *Information*, Vol. 12, No. 5, 2021.
- [19] Pengfei Liu, Xipeng Qiu, and Xuanjing Huang. Recurrent neural network for text classification with multi-task learning. In *Proceedings of the Twenty-Fifth International Joint Conference on Artificial Intelligence, IJCAI'16*, pp. 2873–2879. AAAI Press, 2016.
- [20] Pengfei Liu, Xipeng Qiu, and Xuanjing Huang. Adversarial multi-task learning for text classification. In *Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, pp. 1–10, Vancouver, Canada, July 2017.
- [21] Bin Liang, Rongdi Yin, Lin Gui, Jiachen Du, Yulan He, and Ruifeng Xu. Aspect-invariant sentiment features learning: Adversarial multi-task learning for aspect-based sentiment analysis. New York, NY, USA, 2020. Association for Computing Machinery.
- [22] Răzvan-Alexandru Smădu, Dumitru-Clementin Cercel, and Mihai Dascalu. UPB at SemEval-2021 task 7: Adversarial multi-task learning for detecting and rating humor and offense. In *Proceedings of the 15th International Workshop on Semantic Evaluation (SemEval-2021)*, pp. 1160–1168, Online, August 2021.
- [23] Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. BERT: Pre-training of deep bidirectional transformers for language understanding. In *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers)*, pp. 4171–4186, Minneapolis, Minnesota, June 2019.
- [24] 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*, pp. 2095–2104, Online, June 2021.
- [25] Liangchen Luo, Yuanhao Xiong, Yan Liu, and Xu Sun. Adaptive gradient methods with dynamic bound of learning rate. In *Proceedings of the 7th International Conference on Learning Representations*, New Orleans, Louisiana, May 2019.
- [26] Jingzhou Liu, Wei-Cheng Chang, Yuxin Wu, and Yiming Yang. Deep learning for extreme multi-label text classification. In *Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval, SIGIR '17*, New York, NY, USA, 2017.
- [27] Laurens van der Maaten and Geoffrey Hinton. Visualizing data using t-sne. *Journal of Machine Learning Research*, Vol. 9, No. 86, pp. 2579–2605, 2008.