

# 文表現の構成方法が感情価-覚醒度の推定に与える影響の分析

古 泳欣 小林 一郎

お茶の水女子大学大学院 人間文化創成科学研究科 理学専攻

{gu.yongxin,koba}@is.ocha.ac.jp

## 概要

本研究では、文表現の構成方法の違いが感情価-覚醒度 (Valence-Arousal: VA) 推定に与える影響を分析する。BERT に基づく文埋め込みに対して複数のプーリング手法を適用し、XANEW および EmoBank を用いて感情価と覚醒度の推定特性を比較した。その結果、感情価は文全体の意味情報に基づく表現で安定して推定される一方、覚醒度はトークンレベルの情報により強く依存する傾向が確認された。さらに、ライブ配信チャットへの適用を通じて、文表現の構成方法が VA 推定の時間的挙動に影響を与えることを示す。

## 1 はじめに

近年、ソーシャルメディアやライブ配信サービスの普及に伴い、テキストデータから人間の感情状態を推定する研究が注目されている。特に、感情を連続的な数値空間で表現できる感情価-覚醒度 (Valence-Arousal, 以下 VA) モデルは、感情の強度や変化を定量的に扱える枠組みとして広く用いられている [1]。

うな単語レベルの感情辞書 [2] や、EmoBank のような文レベルで注釈されたコーパス [3] が存在する。近年では、BERT をはじめとする文脈化言語モデルを用い、文埋め込みに基づいて感情価および覚醒度を回帰推定する手法が提案されている [4]。しかし、文ベクトルを構成する際のプーリング手法は、実装上の選択として固定されることが多く、その構成方法の違いが各感情次元の推定特性に与える影響は十分に検討されていない。

一方、感情価は文全体の意味的極性に強く関係するのに対し、覚醒度は語彙の強調表現や局所的な強度情報に影響されやすいと考えられる。このことから、感情価と覚醒度が同一の文表現の構成方法に基づいて同程度に推定できるとは限らず、各次元が依存する表現特性を分析する必要がある。

本研究では、文レベルの VA 推定における文表現の構成方法の違いに着目し、BERT に基づく複数のプーリング手法を用いて、感情価および覚醒度の推定性能と傾向を体系的に比較する。さらに、得られた知見を踏まえ、実際のライブ配信チャットデータに適用し、文表現の構成方法の違いが感情推定の時間的挙動に与える影響を分析する。

## 2 関連研究

感情を連続的な次元で表現する枠組みとして、Valence-Arousal (VA) モデルは心理学分野において提案され、感情の極性および活性度を定量的に扱うモデルとして広く用いられてきた [1]。この枠組みに基づき、ANEW [5] や XANEW [2] などの語彙資源が構築され、単語レベルの感情評価値は多くの感情分析研究の基盤となっている。

文脈を考慮した感情推定のため、文単位で VA 値が注釈されたコーパスとして EmoBank が提案されている [3]。EmoBank は文レベルの連続的感情推定を可能にする代表的なデータセットであり、機械学習モデルによる感情回帰の評価に広く用いられている [6]。

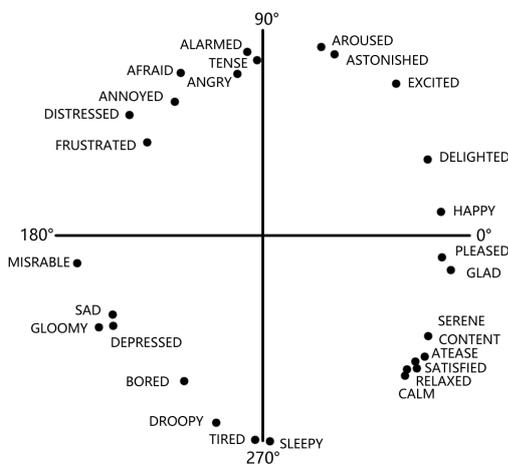


図1 Russell 円環モデルに基づく VA 空間の概念図

従来の VA データセットとしては、XANEW のよ

近年では、BERTをはじめとする文脈を捉えた言語モデルを用い、文埋め込みに基づいて感情価および覚醒度を回帰推定する手法が提案されている。Itoら [4] は Sentence-BERT と回帰モデルを組み合わせることで、文レベル感情推定の有効性を示した。同様の枠組みは、SNS やレビュー文書などの実データにも応用され、感情分布や時間的変動の分析に用いられている [7, 8].

一方、事前に構築された感情辞書を用い、単語レベルの感情スコアを文内で集約するアプローチも存在する。Mohammad ら [9] は、感情強度を連続値として扱う回帰課題を提案し、語彙レベルの感情情報の有効性を示している。さらに Horvat ら [10] は、語彙レベルの感情知識と文表現を組み合わせたハイブリッド型感情分析手法を提案している。しかし、感情知識の粒度と文表現の構成方法との関係については十分に整理されていない。

文脈化言語モデルから文ベクトルを構成する際には、[CLS] トークンや平均プーリングなど、複数のプーリング手法が用いられており、プーリングの選択が下流タスクの性能に影響を与えることが報告されている [11, 12, 13]. しかし、感情価と覚醒度を独立した次元として捉え、各次元がどのような文表現の構成方法に依存しているかを体系的に比較した研究は少ない。

本研究は、文レベル VA 推定におけるプーリング手法の違いに着目し、感情価および覚醒度の推定特性との関係を実証的に分析する点に特徴がある。

### 3 提案手法

本研究では、文レベルの感情価-覚醒度 (VA) 推定において、文表現の構成方法が各感情次元の推定特性に与える影響を分析する。モデル構造および学習設定を固定した上で、文ベクトルの構成に用いるプーリング手法のみを変更し、感情価および覚醒度の推定結果を比較する。本節では、文レベル VA 推定の基本的な枠組みを概説し、比較対象とするプーリング手法の整理を行う。

#### 3.1 文レベルの VA 推定モデル

文レベル VA 推定では、入力文を事前学習済み言語モデルに入力し、各トークンに対応する文脈化埋め込み表現を取得する。これらのトークン埋め込みを集約することで固定長の文ベクトルを構成し、回帰モデルを用いて感情価および覚醒度を連続値とし

て推定する。

本研究では、単語レベルの感情価-覚醒度評価値に基づいて事前に学習された回帰モデルを共通の推定器として用い、トークン埋め込みの集約方法 (プーリング手法) の違いが文レベル VA 推定結果に与える影響に着目する。

#### 3.2 プーリング手法

文ベクトルの構成方法は、トークン埋め込みをどの単位・粒度で集約するかという観点から整理できる。本研究では、(1) 特殊トークン ([CLS]) を直接用いる手法、(2) トークン埋め込みを平均・最大化などにより集約する手法、(3) トークンレベルでの予測結果を集約する手法、の三つに分類し、表現粒度の異なる代表的なプーリング手法を比較対象とする。

上記の分類に基づき、[CLS] トークンを直接用いる手法として m1、トークン埋め込みを文レベルに集約する手法として m2-m5、トークンレベルでの集約を行う手法として m6 および m7 の 7 つの手法を設定する。

**m1: CLS トークン** 入力文の先頭に付与される特殊トークン [CLS] の最終層における埋め込み表現を、文ベクトルとして直接用いる。実装が容易であり、BERT に基づく下流タスクにおいて広く利用されている手法である。

**m2: ナイーブ平均プーリング** [CLS], [SEP], およびパディングトークンを含むすべてのトークン埋め込みの平均を計算し、文ベクトルとする。マスキングを行わない単純な平均化手法として、ベースラインに用いる。

**m3: 平均プーリング ([CLS]/[SEP] 除外)** m2 と異なり、特殊トークンである [CLS] および [SEP] を除外し、残りのトークン埋め込みの平均を計算する。ただし、パディングトークンは含まれるため、文長の違いによる影響を受ける可能性がある。

**m4: 平均プーリング (Padding Mask あり)** 人工的に付与されたパディングトークン ([PAD]) を除外した上で、トークン埋め込みの平均を計算する。文長の違いによる影響を抑制することを目的とした手法である。

**m5: 最大プーリング** 各次元ごとにトークン埋め込みの最大値を取り、文ベクトルを構成する。顕著な特徴を強調できる一方で、文全体に分散

した情報を捉えにくい可能性がある。

**m6: アテンション加重平均** トークンごとの重要度に基づく加重平均により、文ベクトルを構成する。本研究では、アテンション情報を用いてトークン重要度を近似する。

**m7: トークンレベル平均** 各トークン埋め込みを回帰モデルに入力し、トークン単位で感情価および覚醒度を推定する。得られた VA 値を平均化することで、文全体の VA 値を算出する。

### 3.3 学習設定

回帰モデルの学習には、単語レベルの VA 値を含む XANEW データセットを用いる。各単語を入力として、対応する埋め込み表現から感情価および覚醒度を回帰予測するモデルを構築する。

学習済みモデルを用いて、文レベル VA 推定を行うことで、単語レベルの感情知識と文レベルの表現を対応付ける。

### 3.4 配信チャットへの適用

分析の第二段階として、実際のライブ配信を対象に収集した視聴者コメント（チャット）を分析対象とする。配信チャットは発話が非常に短く、同一・類似表現が高頻度で出現するという特徴を持つ。

これらの特性を踏まえ、本研究では SentenceBERT [4] による文埋め込みを用いてチャットの表現を構築し、推定された感情価および覚醒度の時間的変動を分析対象とする。

## 4 実験

### 4.1 実験設定

文レベル感情価-覚醒度 (VA) 推定におけるプーリング手法の違いが推定性能に与える影響を分析するため、BERT-base の最終層埋め込みに対し、第 3 章で述べた各プーリング手法 (m1-m7) を適用して文表現を構成し、同一構造の回帰モデルにより感情価および覚醒度を推定する。

比較においては、プーリング手法以外のモデル構造および学習設定を全て統一し、手法間の公平な評価を行う。これにより、文表現の構成方法そのものが推定特性に与える影響を明確に評価できる。

### 4.2 データセット

回帰モデルの学習には、単語レベルで感情価および覚醒度のアノテーションを含む XANEW データセットを用いる。各単語を入力とし、対応する VA 値を教師信号として学習を行うことで、単語レベルの感情知識を獲得する。

学習済みモデルの評価には、文レベルで連続的な VA 値が付与された EmoBank データセットを用いる。これにより、単語レベルで学習した回帰モデルが、文レベルの感情推定に対してどの程度一般化可能であるかを検証する。

### 4.3 評価指標

推定性能の評価には、感情価および覚醒度それぞれについて、平均二乗誤差 (MSE) とピアソン相関係数 (Corr) を用いる。平均二乗誤差は予測値と正解値の誤差の大きさを評価し、ピアソン相関係数は予測値が正解値の変動傾向をどの程度再現できているかを評価する。

### 4.4 結果

表 1 に、EmoBank における各プーリング手法の回帰性能を示す。

**表 1** EmoBank データセットにおける感情価および覚醒度の評価結果。各指標の最良値を太字で示す。

| Method                            | Valence      |              | Arousal      |              |
|-----------------------------------|--------------|--------------|--------------|--------------|
|                                   | MSE ↓        | Corr ↑       | MSE ↓        | Corr ↑       |
| m1 (CLS)                          | 0.917        | 0.464        | 0.345        | 0.180        |
| m2 (Naive mean)                   | 0.159        | <b>0.578</b> | 0.276        | 0.234        |
| m3 (Mean w/o CLS/SEP)             | 0.178        | 0.539        | 0.276        | 0.238        |
| m4 (Mean w/ padding mask)         | <b>0.141</b> | 0.563        | 0.308        | 0.248        |
| m5 (Max pooling)                  | 0.245        | 0.406        | 0.298        | 0.186        |
| m6 (Attention)                    | 0.259        | 0.568        | 0.148        | <b>0.255</b> |
| m7 (Token-level mean w/o CLS/SEP) | 0.393        | 0.558        | <b>0.131</b> | 0.254        |

感情価に関しては、平均化に基づくプーリング手法 (m2-m4) が比較的安定した性能を示した。特に、パディングトークンを除外した平均化手法 (m4) は、感情価において MSE が最小となり、相関係数も比較的高い値を示した。

一方、覚醒度に関しては、トークンレベルでの集約を行う手法 (m6, m7) が他の手法と比較して高い性能を示す傾向が確認された。特に、トークン単位で VA 値を推定し平均化する手法 (m7) は、覚醒度において MSE が最小となった。

## 4.5 考察

実験結果から、感情価と覚醒度は異なる文表現の構成方法に基づいて推定される傾向が示唆された。

感情価は、文全体の意味情報を集約した表現により比較的安定して推定される一方で、覚醒度は、個々のトークンに含まれる感情的手がかりにより強く依存する傾向が見られた。この結果は、感情の極性と活性度が、言語表現中において異なる情報源に基づいて現れる可能性を示している。

以上より、文レベル VA 推定においては、単一の文表現の構成方法を両次元に一律に適用するよりも、各次元の特性に応じた表現構成を検討することが有効であると考えられる。

## 5 配信チャットへの適用

本研究で得られたプーリング手法に関する知見を踏まえ、実際のライブ配信における視聴者チャットを対象に、文レベル感情価-覚醒度 (VA) 推定を適用した。本節では、学習に用いる感情知識の異なる二つの手法を用い、配信チャットにおける推定挙動を比較する。

一つ目の手法では、XANEW に基づいて学習した回帰モデルを用い、Sentence-BERT により得られた各チャット文の文埋め込みから感情価および覚醒度を推定する。二つ目の手法では、EmoBank に基づく文レベル回帰モデルを用い、同様に Sentence-BERT による文埋め込みから VA を直接推定する。両手法は入力表現を共有する一方で、学習に用いる感情知識の粒度が異なる点に特徴がある。

### 5.1 結果と考察

推定結果を可視化したところ、感情価および覚醒度の両次元において、推定手法間で異なる時間的挙動が観察された。両手法は変動方向自体は概ね一致しており、同一の発話イベントに対する感情変化を捉えていることが確認できる。

一方で、推定値の振幅や分布には手法間で明確な差異が見られた。感情価に関しては、EmoBank に基づく手法では推定値が比較的安定して推移するのに対し、XANEW に基づく手法では、語彙選択に起因する局所的な極性変化が逐条的に反映される傾向が観察された。一方、覚醒度に関しては、EmoBank に基づく手法において推定値の変動範囲が広く、局所的な尖峰が多く観察され、高覚醒状態への反応が顕

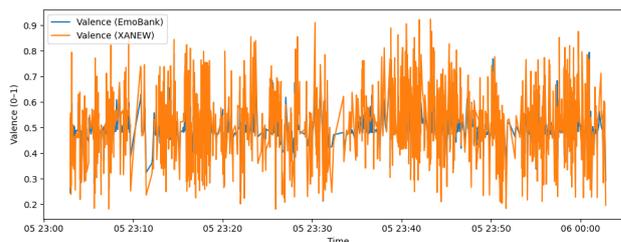


図2 配信チャットに対して推定された感情価の時間変化。

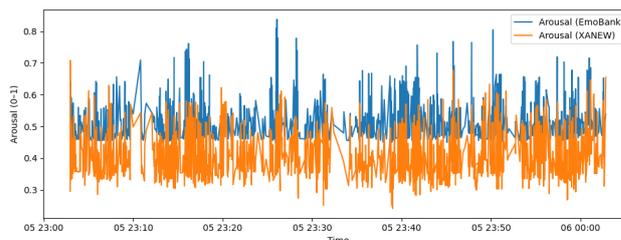


図3 配信チャットに対して推定された覚醒度の時間変化。

著であった。これに対し、XANEW に基づく手法では、推定値の変動範囲は比較的狭く、振幅が抑えられた緩やかな変動を示した。

以上の結果から、感情価と覚醒度は、学習に用いる感情知識および文表現の構成方法に対して異なる感度を示すことが示唆された。文レベル VA 推定においては、両次元に同一の表現構成を適用するのではなく、各次元の特性を考慮した表現設計が重要であると考えられる。

## 6 おわりに

本研究では、文表現の構成方法の違いが感情価-覚醒度 (VA) 推定に与える影響を分析した。複数のプーリング手法を比較した結果、感情価と覚醒度は学習に用いる感情知識および文表現の構成方法に対して異なる感度を示すことが確認された。

さらに、配信チャットへの適用を通じて、これらの差異が実データにおける推定挙動の違いとして現れることを示した。今後は、感情次元ごとに適した表現構成を選択する枠組みの検討や、多様なテキストデータへの応用が課題として挙げられる。

## 謝辞

本研究は、お茶の水女子大学ジェンダード・イノベーション研究所からご支援を頂きました。ここに深謝いたします。

## 参考文献

- [1] James A. Russell. A circumplex model of affect. **Journal of Personality and Social Psychology**, Vol. 39, No. 6, pp. 1161–1178, 1980.
- [2] Amy B. Warriner, Victor Kuperman, and Marc Brysbaert. Norms of valence, arousal, and dominance for 13,915 english lemmas. **Behavior Research Methods**, 2013.
- [3] Sven Buechel and Udo Hahn. Emobank: Studying the impact of annotation perspective and representation format on dimensional emotion analysis. In **EACL**, 2017.
- [4] Manabu Ito and Konstantin Markov. Sentence embedding based emotion recognition from text data. In **RACS**, 2022.
- [5] Margaret M. Bradley and Peter J. Lang. **Affective norms for English words (ANEW): Instruction manual and affective ratings**, 1999.
- [6] Sven Buechel and Udo Hahn. Learning continuous emotion representations from text. In **Proceedings of the 7th Joint Conference on Lexical and Computational Semantics**, pp. 123–134, 2018.
- [7] Daniel Beck, Víctor Soto, and Caroline Barriere. Emotion recognition in social media text using deep learning. **IEEE Transactions on Affective Computing**, 2021.
- [8] Taesung Kim and Piek Vossen. Predicting emotion intensities using bert. In **Proceedings of COLING**, 2020.
- [9] Saif M. Mohammad and Felipe Bravo-Marquez. Emotion intensity prediction. In **Proceedings of the 11th International Workshop on Semantic Evaluation (SemEval)**, 2017.
- [10] Martin Horvat, Senja Pollak, and Nikola Ljubešić. Sentence-level emotion analysis with affective lexicons. In **Proceedings of the 2024 Joint International Conference on Computational Linguistics, Language Resources and Evaluation (LREC-COLING)**, pp. 1–11, Torino, Italy, 2024. ELRA and ICCL.
- [11] Nils Reimers and Iryna Gurevych. Sentence-bert: Sentence embeddings using siamese bert-networks. In **EMNLP**, 2019.
- [12] Bohan Li, et al. Sentence embedding pooling strategies for downstream tasks. In **Proceedings of the Workshop on Representation Learning for NLP**, 2020.
- [13] Md Shad Akhtar, et al. A survey on emotion recognition methods for textual data. **ACM Computing Surveys**, 2020.