

大規模言語モデルによる書き手の情報を考慮した感情分析

花房 健太郎[†] 前川 大輔[†] 梶原 智之[‡]愛媛大学工学部工学科[†] 愛媛大学大学院理工学研究科[‡]

1 はじめに

感情分析は、対話システムやソーシャルメディアマイニングなど多くの応用を持つ主要な自然言語処理タスクのひとつである。感情分析の先行研究[1, 2]は、ポジティブまたはネガティブの感情極性分類と、喜びや悲しみなどの詳細な感情に対する感情強度推定の2つのサブタスクに取り組んでおり、読み手の客観的な感情と書き手の主観的な感情の間の乖離が指摘されてきた。

主観的な感情分析は、機械学習モデルを特定の書き手に個人特化させることが求められるため、より難しいタスクである。個人特化の感情分析では、書き手の性格情報を考慮する手法[3]や書き手の投稿履歴を考慮する手法[4]が提案され、高い性能を達成している。しかし、これらの既存手法は感情分析モデルに加えて特殊な特徴抽出機構を設計しており、構造が複雑である。

本研究では、大規模言語モデル (LLM: Large Language Model) に基づく個人特化の感情分析に取り組む。LLM のプロンプトとして書き手の性格情報や投稿履歴を入力することにより、複雑な特徴抽出なしで感情分析を個人特化する。日本語 LLM の Swallow を用いた評価実験の結果、8B モデルに対しては投稿履歴の考慮が有効であり、70B モデルに対しては性格と投稿履歴の両方が有効であることが明らかになった。70B モデルは工夫なしでも既存手法や人間よりも高性能であるが、提案手法による個人特化で更に性能を改善でき、最高性能を達成した。

2 提案手法

個人特化の感情分析に関する先行研究[3, 4]で有効性が示されている**書き手の性格情報**および**書き手の投稿履歴**を考慮し、本研究では新たに LLM ベースの感情分析を個人特化させる。先行研究では、事前訓練済みマスク言語モデルによる感情分析の際に性格情報や投稿履歴からの特徴抽出を行っているが、本研究では LLM に与えるプロンプトの中にこれらの情報を組み込むことで、個人特化のための特徴抽出を単純化する。

2.1 LLM ベース感情分析

LLM に対して「入力テキストを書いた人の感情強度を選択肢の中から1つずつ選んで出力してください。感情は、喜び・悲しみ・期待・驚き・怒り・恐れ・嫌悪・信頼の8種類です。小さい値は感情が弱いこと、大きい値は感情が強いことを表しています。」という指示および「0, 1, 2, 3」の選択肢を与え、8種類の感情に対して4段階の感情強度推定を行う。感情極性分類の場合は、選択肢を「-2, -1, 0, 1, 2」に置き換える。

2.2 性格情報を考慮した LLM ベース感情分析

日本語の感情分析コーパス WRIME[1, 2]には書き手の性格情報が付与されている。これは、BigFive 性格 5 因子モデル[5]に基づく60項目の性格診断(話し好き・悩みがち・反抗的など)の質問に対して、自身の該当度を7段階で回答させたものである。本研究では、これをプロンプトに含めることで、個人特化の感情分析を行う。

提案手法では、2.1 節の基本プロンプトに加えて「以下の書き手の性格を考慮して感情強度を出力してください。値が大きいほど、書き手がその性格によく当てはまることを表しています。」という指示および性格情報「{話し好き: 6, 悩みがち: 2, ...}」を与え、感情分析を実施する。

2.3 投稿履歴を考慮した LLM ベース感情分析

WRIME は、1人あたり少なくとも100件ずつの SNS 投稿テキストを60人分集めたコーパスである。本研究では、few-shot 文脈内学習の枠組みで、同じ書き手の複数投稿および各投稿に対応する感情ラベルをまとめて入力し、個人特化の感情分析を行う。

3 実験設定

日本語感情分析コーパス WRIME[1, 2]を用いて、個人特化した感情分析の性能を評価した。先行研究[4]と同様にコーパスを分割し、8感情の強度推定および感情極性分類を実験した。評価指標には、順序分類問題において一般的な Quadratic Weighted Kappa (QWK) を用いた。

比較手法には、BERT¹および RoBERTa²の事前

Emotion Analysis with Writer's Information Based on LLMs

[†] Kentaro Hanafusa (hanafusa@ai.cs.ehime-u.ac.jp)

[†] Daisuke Maekawa (maekawa@ai.cs.ehime-u.ac.jp)

[‡] Tomoyuki Kajiura (kajiura@cs.ehime-u.ac.jp)

Ehime University

¹ <https://huggingface.co/tohoku-nlp/bert-base-japanese>

² <https://huggingface.co/nlp-waseda/roberta-base-japanese-with-auto-jumanpp>

表 1：感情強度推定（8 感情）と感情極性分類（極性）の実験結果。QWK の改善が青色で悪化が赤色。

	喜び	悲しみ	期待	驚き	怒り	恐れ	嫌悪	信頼	8 感情	極性
BERT	0.524	0.417	0.298	0.286	0.399	0.282	0.412	0.143	0.410	0.524
+ 性格情報[3]	0.518	0.438	0.315	0.326	0.365	0.294	0.424	0.225	0.424	0.543
+ 投稿履歴[4]	0.551	0.420	0.331	0.320	0.351	0.296	0.411	0.189	0.433	0.548
RoBERTa	0.571	0.457	0.330	0.342	0.433	0.335	0.455	0.184	0.444	0.594
+ 性格情報[3]	0.576	0.474	0.393	0.349	0.440	0.347	0.476	0.224	0.474	0.605
+ 投稿履歴[4]	0.588	0.456	0.395	0.396	0.277	0.383	0.474	0.219	0.475	0.608
Swallow-8B (0-shot)	0.539	0.426	0.277	0.320	0.466	0.278	0.116	0.050	0.419	0.613
+ 性格情報	0.443	0.363	0.275	0.263	0.348	0.222	0.035	0.011	0.357	0.527
Swallow-8B (10-shot)	0.547	0.448	0.316	0.302	0.534	0.322	0.263	0.066	0.410	0.584
+ 投稿履歴	0.585	0.464	0.363	0.315	0.566	0.356	0.271	0.064	0.443	0.657
Swallow-70B (0-shot)	0.602	0.517	0.372	0.416	0.507	0.390	0.383	0.165	0.492	0.674
+ 性格情報	0.593	0.548	0.418	0.409	0.509	0.380	0.377	0.227	0.507	0.666
Swallow-70B (10-shot)	0.587	0.525	0.403	0.393	0.518	0.401	0.407	0.116	0.471	0.719
+ 投稿履歴	0.604	0.533	0.402	0.420	0.517	0.407	0.388	0.117	0.480	0.722
人手評価（被験者 A）	0.490	0.314	0.377	0.339	0.255	0.354	0.305	0.135	0.367	0.560
人手評価（被験者 B）	0.590	0.436	0.438	0.400	0.285	0.363	0.448	0.118	0.449	0.490
人手評価（被験者 C）	0.553	0.485	0.426	0.347	0.302	0.365	0.275	0.131	0.426	0.599

訓練済みマスク言語モデルに対して、性格情報 [3] および投稿履歴 [4] を考慮する既存手法を用いた。提案手法の日本語 LLM には、Swallow の 8B モデル³および 70B モデル⁴を用いた。LLM ベース感情分析は、プロンプト内に事例を含める few-shot 文脈内学習の設定と、事例を含めない 0-shot 設定の両方を評価する。性格情報を考慮する提案手法は、入力 of 投稿に対応する書き手の性格情報を提示するのみなので、0-shot 設定に相当する。一方で、投稿履歴を考慮する提案手法は、入力 of 投稿に対応する書き手の複数の投稿事例を提示するため、few-shot 設定に相当する。

4 実験結果

表 1 に実験結果を示す。まず、Swallow-70B は単純な 0-shot 設定でも人間の能力および全ての既存手法の性能を上回る。さらに、Swallow-70B に性格情報を与えることで感情強度推定の最高性能を達成し、投稿履歴を与えることで感情極性分類の最高性能を達成した。これらの実験結果から、提案手法の有効性が明らかになった。

Swallow-8B に対しては、性格情報を与えることで一貫して性能が低下した一方、投稿履歴を与えた際には 8 感情のうちの 7 感情において性能が改善した。比較的パラメータ数の少ない LLM に対しては、投稿履歴を用いる個人化が有効であることが示唆される。

³ <https://huggingface.co/tokyotech-llm/Llama-3.1-Swallow-8B-Instruct-v0.1>

⁴ <https://huggingface.co/tokyotech-llm/Llama-3.1-Swallow-70B-Instruct-v0.1>

表 2：few-shot 事例数 N ごとの感情分析の性能

事例数	Swallow-8B		Swallow-70B	
	8 感情	極性	8 感情	極性
N=5	0.391	0.563	0.467	0.692
N=10	0.422	0.646	0.480	0.722
N=15	0.410	0.584	0.471	0.719
N=20	0.413	0.567	0.478	0.706

表 2 に few-shot 文脈内学習の事例数を変えた際の性能の変化を示す。LLM のパラメータ数にも感情分析のタスクにも依存せず、一貫して 10 件の事例を見せる場合の性能が高いことがわかる。

5 おわりに

本研究では、LLM を用いて書き手に個人特化した感情分析に取り組んだ。LLM のプロンプトに性格情報や投稿履歴を組み込むことで、特徴抽出を単純化し、追加訓練なしで感情強度推定および感情極性分類の最高性能を達成した。

参考文献

- [1] Tomoyuki Kajiwar, Chenhui Chu, Noriko Takemura, Yuta Nakashima, Hajime Nagahara. WRIME: A New Dataset for Emotional Intensity Estimation with Subjective and Objective Annotations. NAACL, pp.2095-2104, 2021.
- [2] Haruya Suzuki, Yuto Miyauchi, Kazuki Akiyama, Tomoyuki Kajiwar, Takashi Ninomiya, Noriko Takemura, Yuta Nakashima, Hajime Nagahara. A Japanese Dataset for Subjective and Objective Sentiment Polarity Classification in Micro Blog Domain. LREC, pp.7022-7028, 2022.
- [3] Haruya Suzuki, Sora Tarumoto, Tomoyuki Kajiwar, Takashi Ninomiya, Yuta Nakashima, Hajime Nagahara. Emotional Intensity Estimation Based on Writer's Personality. AACL-SRW, pp.1-7, 2022.
- [4] 鈴木陽也, 山内洋輝, 梶原智之, 二宮崇, 早志英朗, 中島悠太, 長原一. 書き手の複数投稿を用いた感情分析. 人工知能学会全国大会第 38 回, 2024.
- [5] Lewis R. Goldberg. The Development of Markers for the Big-Five Factor Structure. Psychological Assessment, Vol.4, pp.26-42, 1992.