

## 流行要因分析のための投稿テキスト・リプライ・画像からの感性分析及び可視化 Affective analysis and visualization from posted text, replies, and images for analysis of buzz factors

網谷 嶺志<sup>†</sup>      松本 和幸<sup>‡</sup>      吉田 稔<sup>‡</sup>      北 研二<sup>‡</sup>  
Reishi Amitani   Kazuyuki Matsumoto   Minoru Yoshida   Kenji Kita

### 1. はじめに

近年、ソーシャル・ネットワーキング・サービス (Social Networking Service, SNS) の発展により、多くのユーザー間で様々なコンテンツの情報が共有・拡散されるようになってきている。これに伴い、インターネットを通じての流行が度々起こるようになった。とくに、情報が急激に広まり、人気急上昇することを「バズる」と呼ぶことがある。

企業のマーケティングは、拡散力の強い SNS との相性が良く、企業戦略の一つとして注目されている。戦略的に口コミ、レビューなどを発信してもらうことで商品の認知を拡大させることを「バズマーケティング」と呼ぶ。

バズマーケティングにより商品の販売促進や認知度の向上につながった成功例は多い。有名なものでは、江崎グリコの 11 月 11 日の「ポッキーの日」イベント、森永チョコレートの「ベイクを買わない理由を、Amazon ギフト券 100 円で買い取ります！」などがある。森永チョコレートのように販売促進には直接つながらないものの、認知度を向上させ、消費者の素直な意見を把握できるため、商品改良のきっかけとなるケースもいくつか存在する。このことから、バズマーケティングを上手く活用すれば、企業にとって有用であることがわかる。本研究では、バズツイートの分析をすることでどのようなツイートがバズを起こしやすいかを検討する。これにより、マーケティングに役立つバズ予測の手法の提案にもつなげられると考えている。

Twitter 上でバズ現象を起こした所謂「バズツイート」とよばれるツイートは、テキストだけで投稿されることも多いが、画像付きで投稿されているツイートも多い。これは、Twitter に投稿されるテキストの文字数には制限があり、テキストのみで表現することが難しい情報には画像を添付することで視覚的に伝えやすくなるためだと考えられる。

また、バズ現象を分析するという観点からも、画像付きのツイートはテキストのみのツイートよりも分析に使える情報量が増えるため、より詳細な分析が可能になると考えられる。加えてツイートの事後情報であるリプライテキストも分析に用いる。リプライは、ツイート投稿後に、そのツイートに対する反応として投稿されるものであるため、具体的なバズ現象の要因分析につながると考えた。本研究では、画像付きツイートについて、ツイートテキスト、画像、リプライテキストからそれぞれ抽出した感性情報を分析することで、バズ現象の要因分析を検討する。

## 2. 関連研究

### 2.1 リプライテキストを用いたバズツイートの分類

Matsumoto ら[1]は、リプライデータの特徴量に用いて、バズツイートとバズしていないツイートの 2 値分類を行う

手法を提案した。しかし、彼らの手法では、「話題のツイート・面白画像ツイート」などをまとめたキュレーションサイトからバズツイートを収集しており、バズったかどうかは収集者の主観的な判断によるところが大きく、「いいね」や「RT (リツイート)」の数などの客観的な指標を用いた検討は行われていなかった。本研究では、バズツイートであるか否かを判断する客観的な指標として「いいね」および「RT」を用いて分析する。また、本研究では、ツイートのテキストおよび画像の内容と、そのツイートに対するリプライの内容を用いてバズ現象の要因分析を検討するものであるため、研究方法が異なる。

### 2.2 Facebook データを用いたバズの予測

Deusser ら[2]は Facebook のデータを用いて SVM, AdaBoost, ランダムフォレストをそれぞれ用いてバズの予測を行い、結果の比較をしている。Facebook は Twitter と同様 SNS の一種であるが、そのアカウント登録が実名である性質から Twitter とは投稿される情報の性質が異なっている。Twitter の場合、評判の悪い口コミに対して正直な意見が投稿されやすい点で Facebook とは異なる。

### 2.3 SNS を用いた個人の興味推定

Masumoto ら[3]は、SNS において、個人のプロフィール (性別、年齢、趣味) や、位置情報など、利用できる情報が多いほど精度の高い興味推定が可能と考えている。また、ユーザの興味が、いいねや RT を増やす要因になっていると考えている。本研究では、ユーザの情報を利用しない点では Masumoto らの研究とは異なるが、ツイートの内容やリプライからいいねと RT の関係性を分析する点で、共通する部分がある。

### 2.4 ユーザの関心のあるトピック推測

Bhattacharya ら[4]は、ユーザの関心のあるトピックを推測するためのメカニズムを提案している。Twitter においてトピックの専門知識を推測し、それをフォローしているユーザの興味を推移的に推測する手法は、トピックモデルとして Labeled LDA (labeled latent Dirichlet allocation, L-LDA) を用いたときより、優れていることを明らかにしている。この研究ではユーザのトピックに関する情報やフォロワー数などをユーザの興味を推測する手がかりとして利用しているため、ツイート内容やリプライデータに基づいてバズ分析をする本研究とは本質的に異なっている。

<sup>†</sup> 徳島大学大学院創成科学研究科

Graduate School of Science and Technology for Innovation,  
Tokushima University

<sup>‡</sup> 徳島大学大学院社会産業理工学研究部

Graduate School of Technology, Industrial and Social  
Sciences, Tokushima University

## 2.5 Twitter のトレンド予測 (要因とモデル)

Zhang ら[5]は、ハッシュタグに着目し、そのトレンドや傾向を予測しようとした。語彙や感情などの内容と文脈を予測の要因として考慮している。この実験では、内容と文脈の要因が、大規模な Twitter データセットにおける流行予測に有用であることを示している。本研究では、ツイートのテキスト、画像、リプライからバズの分析を行うことを目的としているため、ツイートの内容が流行予測に有用であるとみなしている彼らの研究と類似している。

## 2.6 Twitter のハッシュタグの分析

Anusha ら[6]は、LDA (latent Dirichlet allocation) に基づくトピックモデリングや NLTK コーパスに基づく感情極性分析をツイートに対して用いて、内容が面白いかどうか判断する方法を提案している。この手法では、トピックの面白さを、トピックの空間的エントロピーの重み (そのトピックに対するツイートがどの程度注目されているのか) と、感情極性のスコア (良い意味で注目されているか否か) で判断している。本研究で目指す手法は、感性情報を用いた分析であり類似点はあるが、ハッシュタグは用いず、ツイート内容とリプライデータを用いたバズ現象の要因について分析を行うものであるため、目的が異なっている。

## 3. 提案手法

本研究で提案する手法について説明する。図 1 は、提案手法の概要を示したものである。以下、手順を述べる。

- Step-1 Twitter API を使用し、分析対象となるツイートに付与された「いいね」の数、「RT」の数、ツイートテキスト、ツイートに添付されている画像、対象ツイートに対して投稿されたリプライを収集する。
- Step-2 感性情報の分析を行うために、主観と客観の感情分析データセットの WRIME コーパスを用いて BERT ベクトルを入力として、感性情報を推定するモデル (感性推定モデル) を作成する。
- Step-3 画像に対しては、感性推定を直接行うことができないため、画像とそのキャプションテキストが対となっているデータセットをもとに画像特徴量からテキストの特徴量を推定するモデルを作成し、それを用いて画像からテキスト特徴量に変換する前処理を行う。
- Step-4 感性推定モデルを用いて、対象となるツイートのテキスト、画像、リプライについて、それぞれ感性情報を推定し、その感性情報といいねや RT の数との関係を可視化する。
- Step-5 可視化された結果などから、テキスト、画像、リプライの感性情報が、いいねや RT の数にどのように影響し、どの感性情報がいいねや RT が伸びる要因となっているかを分析する。

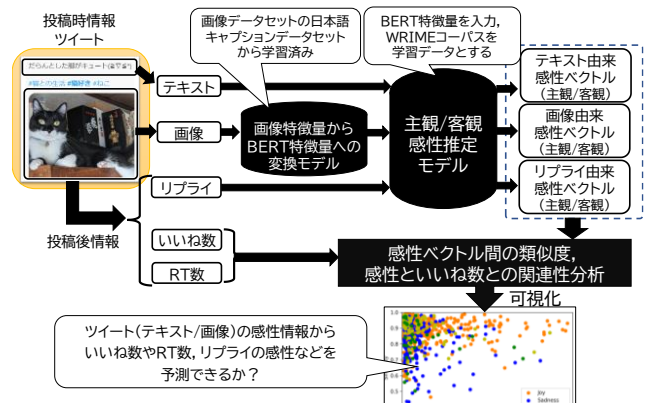


図 1: 提案手法の概要

### 3.1 ツイート収集

Twitter API[7]は、Twitter 社が開発者向けに提供している API である。Twitter API を利用することで、公式サイトを介さずに、Twitter 上のデータを取得することができる。Twitter API では、ツイート ID やユーザ ID を用いた検索、いいねや RT の数などの様々なデータが収集可能であり、分析に必要なツイートデータを効率的に収集することが可能となる。本研究では、いいねの数やツイート ID、ユーザ ID などの条件をもとに分析に必要なツイートとリプライのデータを収集した。

### 3.2 テキスト特徴量の抽出

本研究では、レトリバが公開している日本語話し言葉 BERT モデル[8]を用いて、ツイートからテキスト特徴の分散表現を取得した。日本語話し言葉 BERT モデルは日本語話し言葉コーパス (CSJ) [9]を対象に事前に学習されており、発話テキストに対し従来の BERT より高い表現能力を持つとされている。本研究では、話し言葉が多く含まれていると考えられる Twitter 上のツイートデータを使用するため、この日本語話し言葉 BERT を使用することにした。この BERT モデルから得られる分散表現のベクトルは、768 次元となっている。また、日本語話し言葉 BERT の学習済みモデルは、分野適応させる際のファインチューニングのデータの種類や追加学習の対象とする層の違いによって、“1-6 layer-wise”, “TAPT512 60k”, “DAPT128-TAPT512” の計 3 種類が公開されているが、本研究では、係り受け解析、文境界推定等のタスクで最も高い性能を示したとされる “TAPT512 60k”を用いた。

### 3.3 画像特徴量の抽出

画像の感性情報抽出方法として、100 万枚以上の画像が収録されている ImageNet データベースをもとに 1000 種類のオブジェクト・カテゴリに分類するように事前学習された InceptionV3 モデルを用いて画像特徴量の抽出を行う。この画像特徴量を、次で述べるモデルによって BERT の特徴量に変換し、BERT ベクトルから感性情報を抽出することにより画像の感性情報として扱うこととする。

### 3.4 画像特徴量からの BERT 特徴量への変換

大規模な画像データセットである COCO データセット [10] に対して付与された STAIRS 日本語キャプションデータセット [11] を用いて画像特徴量をテキスト特徴量 (BERT 特徴量) に変換するモデルをニューラルネットワークにより学習する。STAIRS 日本語キャプションデータセットは 82,783 件あり、COCO データセットの画像と 1:1 で対応している。作成したモデルから出力される次元数は 768 次元となる。作成したニューラルネットワークの構成図を図 2 に示す。画像特徴量には、InceptionV3 の事前学習済みモデルを用いて抽出した 2048 次元の特徴量ベクトルを用いる。

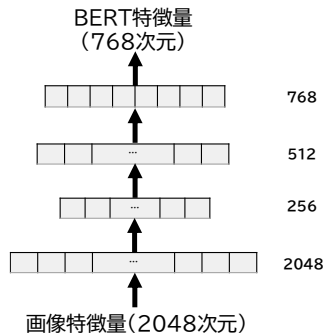


図 2: 画像特徴量から BERT 特徴量への変換モデル

### 3.5 感性情報の抽出

感性情報の抽出に WRIME コーパス [12] (主観と客観の感情極性分類のための日本語データセット) を用いる。WRIME コーパスはテキストに対して Plutchik の基本 8 感情 (喜び, 悲しみ, 期待, 驚き, 怒り, 恐れ, 嫌悪, 信頼) の感情ラベルがテキスト筆者 1 人の主観とクラウドワーカー 3 人の客観によりそれぞれ付与されている。このコーパスを用いて BERT ベクトルを入力とし、主観および客観感性情報を出力する感性推定モデルを作成し、テキスト、画像、リプライの感性情報をそれぞれ抽出する。図 3 に、感性推定モデルの構成図を示す。出力される感性情報は、喜び (Joy), 悲しみ (Sadness), 期待 (Anticipation), 驚き (Surprise), 怒り (Anger), 恐れ (Fear), 嫌悪 (Disgust), 信頼 (Trust) の 8 つの感情をそれぞれの次元とし、各確率値が格納されたベクトル形式で、主観感情と客観感情は区別して出力される。このベクトルにおいて、最大値をとる次元の感情が出力感性ラベルとなる。

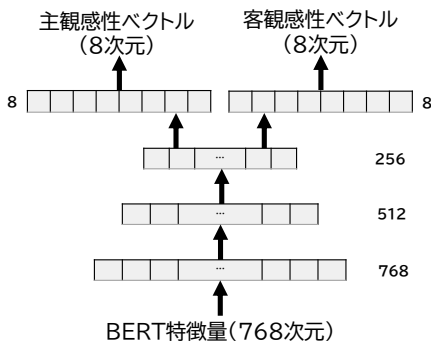


図 3: BERT 特徴量から感性情報を抽出する感性推定モデル

## 4. 実験

2021 年 1 月から 3 月の間で取得したツイート 2247 件の内、リプライが投稿されたツイート 811 件を対象に分析を行う。収集したツイートのいいね数の分布は、以下のヒストグラム (図 4, 5) のようになっている。




図 4: いいね (Like) 数 1000 以下の分布




図 5: いいね (Like) 数 1000 以上の分布

いいね数が少ないものが多いため、2つのヒストグラムに分けて示している。半分以上のツイートのいいね数が 0 から 100 であり、いいね数が増えるほどツイート数は少なくなっている。

ツイート 811 件に対して得られた感性情報はテキストと画像、主観と客観の合計 4 種類であり、それぞれの感性の内訳は以下の表 1, 2 のようになっている。感性ベクトルの最大値をとる次元の感性 (感性ラベル) をカウントした結果を示している。

表 1: テキストの感性情報内訳

| 感性           | 主観  | 客観  |
|--------------|-----|-----|
| Joy          | 509 | 372 |
| Sadness      | 184 | 181 |
| Anticipation | 79  | 143 |
| Surprise     | 39  | 54  |
| Anger        | 0   | 0   |
| Fear         | 0   | 46  |
| Disgust      | 0   | 15  |
| Trust        | 0   | 0   |

表 2: 画像の感性情報内訳

| 感性           | 主観  | 客観  |
|--------------|-----|-----|
| Joy          | 639 | 2   |
| Sadness      | 15  | 4   |
| Anticipation | 0   | 36  |
| Surprise     | 157 | 748 |
| Anger        | 0   | 0   |
| Fear         | 0   | 21  |
| Disgust      | 0   | 0   |
| Trust        | 0   | 0   |

ツイートテキストから推定した感性情報では Joy (喜び) が多くみられた。画像の主観の感性情報は Joy (喜び) が多くみられたのに対して、客観の感性情報では Surprise (驚き) が多くみられた。

テキストおよび画像から得られた主観の感性情報では Fear (恐れ), Disgust (嫌悪), Anger (怒り) といったネガティブな感性と、ポジティブな感性である Trust (信頼) はまったくみられず、客観の感性情報では、ネガティブな感性である Fear (恐れ), Disgust (嫌悪) が少しだけ見られ、感性情報の主観と客観の違いを確認できた。

ツイート 811 件に対して取得できたリプライの総数は 3266 件であった。リプライから推定した主観と客観のそれぞれの感性情報の内訳を表 3 に示す。

表 3: リプライの感性情報内訳

| 感性           | 主観   | 客観   |
|--------------|------|------|
| Joy          | 2278 | 1850 |
| Sadness      | 612  | 642  |
| Anticipation | 251  | 418  |
| Surprise     | 117  | 176  |
| Anger        | 0    | 0    |
| Fear         | 0    | 116  |
| Disgust      | 8    | 64   |
| Trust        | 0    | 0    |

リプライでは、主観において、ネガティブな感性である Disgust (嫌悪) が少し (8 件) ではあるが確認できた。客観では Fear (恐れ), Disgust (嫌悪) が少し確認できたが、ネガティブな感性である Anger (怒り) と、ポジティブな感性である Trust (信頼) は推定されなかった。

図 7~10 は収集したツイートのいいねと RT の数と感性情報の結果を図で表したものである。収集したツイートではいいねと RT にある程度の相関があることが確認できるが、いいねの数に比べて RT の数は少ないことが分かる。RT が少ないということは、拡散の規模があまり高くないということでもある。

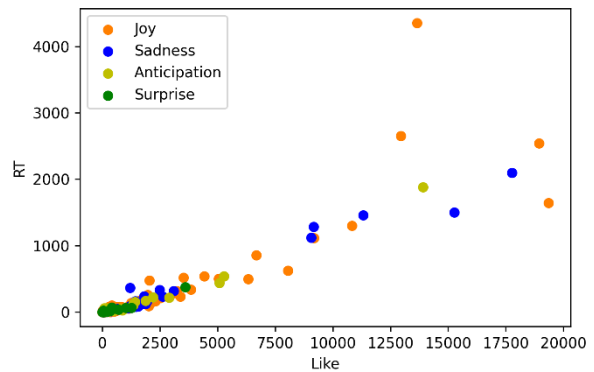


図 6: テキストの主観感性情報の分布

図 6 から、テキストの主観の感性情報では Joy (喜び), Sadness (悲しみ) が多くみられ、いいねが多いツイートも Joy (喜び), Sadness (悲しみ) が多くみられた。




図 7: テキストの主観感性情報の分布 (いいねが 1000 以下のツイート)

図 7 から、いいね数 1000 以下のツイートにおける感性の分布を確認すると Surprise (驚き) の感性と推定されたツイートは、いいね数が少ない傾向があることがわかる。

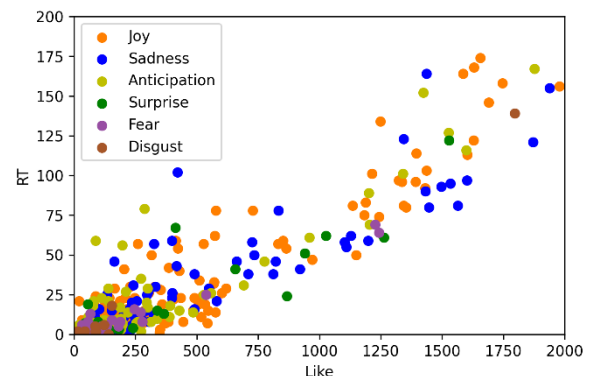


図 8: テキストの客観感性情報の分布 (いいねが 2000 以下のツイート)

図 8 より、客観の感性情報の分布は、2000 以下のツイートでは、Fear (恐れ), Disgust (嫌悪) の感性情報のツイートにおいて、いいね数が少ない傾向がみられた。




図 9: テキストと画像の感性ベクトル類似度 (主観)




図 12: テキストとリプライの感性ベクトル類似度 (客観)




図 10: テキストと画像の感性ベクトル類似度 (客観)

次に感性ベクトル間の類似度の可視化を行った。図 9, 10 に可視化結果を示す。テキストの感性情報と画像の感性情報とのベクトル間の類似度をコサイン類似度で算出した。主観の感性情報の結果では **Surprise** (驚き) はテキストと画像で類似度が高くなっている傾向が確認できた。

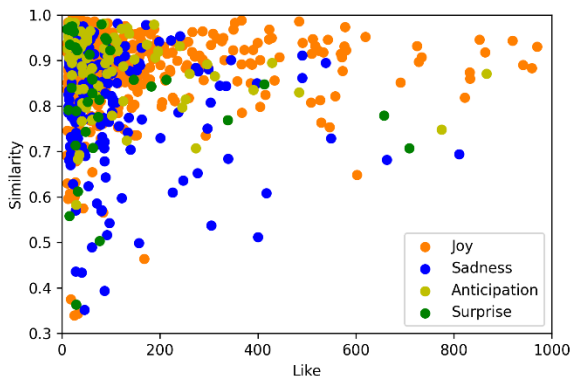


図 11: テキストとリプライの感性ベクトル類似度 (主観)

テキストの感性情報を元にテキストとリプライのコサイン類似度の可視化を行った。結果を図 11, 12 に示す。リプライ数はツイート毎に異なるため、コサイン類似度の平均の値を用いた。テキストとリプライのコサイン類似度は値にばらつきがある。Fear (恐れ), Disgust (嫌悪) は母数に対してコサイン類似度が広く分布しており、Joy (喜び) は全体的に類似度が高い傾向がある。

収集したツイートの中で、いいねが最も多かったツイートは、いいねが 19,348, RT が 1640 であり、リプライ数は 62 件であった。このツイートと添付画像を図 13 に示す。このツイートにおいて、推定された感性情報はテキストの主観、客観、画像の主観が Joy (喜び) であり、画像の客観は **Surprise** (驚き) となっていた。テキストには「かわいい」という表現が含まれ、Joy (喜び) は妥当な感性と考えられる。画像の感性情報の推定は、画像に対して感性を付与した大規模なデータセットが無かったため、画像キャプションデータセットを利用し、画像特徴量から BERT ベクトルに変換し、感性情報を抽出する方法をとった。しかし、用いたデータセットの性質を考えると、元々、ネガティブな感性を表現する画像やキャプションが含まれておらず、感性が偏っていた可能性もあるため、今後は画像特徴量から感性を直接推定できるような別の手法を検討する必要があると考えられる。

テキスト: 雪ともんた。足跡までがわいゝい。



図 13: ツイートと画像の例

## 5. 考察

本研究では、ツイートのテキスト、画像、リプライの感性情報を推定し、RT やいいね数との関係について分析を行った。感性情報は、Joy (喜び) が全体的に推定されやすく、Anger (怒り)、Fear (恐れ)、Disgust (嫌悪)、Trust (信頼) は推定されにくい傾向があった。Joy (喜び) はポジティブな感情であり、Anger (怒り)、Fear (恐れ)、Disgust (嫌悪) はネガティブな感性であることから、ツイートにはそういったポジティブ/ネガティブの感性の差が出ている可能性があるが、収集したツイートのデータに偏りがあったため、Joy (喜び) に偏って推定されてしまったとも考えられる。また、客観の感性情報の分布では Fear (恐れ)、Disgust (嫌悪) のツイートはいいね数が少なく、ネガティブな感性を含んだツイートは拡散されにくいことが推察できる。

ベクトル間の類似度を可視化した分析では、主観の感性情報でいいね数が高いものは、感性ベクトル間の類似度も高い傾向が見られた。テキストに画像が付与されることで意味を伝えやすくするため、テキストと画像の感性の類似度は高くなりやすいと考えられる。一方で、感性の類似度が低いものは、時には意外性があると判断されるが、全般的に意味が伝わりづらくなり、結果としてツイートも拡散されにくくなってしまおうと考えられる。

リプライとの感性類似度の分析において、リプライはツイートによって投稿されている数が異なり、今回はリプライそれぞれから得られた感性ベクトルの平均を用いたが、リプライ数が増えるほど感性情報も多種多様になり、平均ベクトルだと特徴が出にくくなると考えられる。このため、リプライ数も考慮して感性情報を分析する方法を検討する必要がある。テキストとリプライの感性の類似度では Joy (喜び) の類似度がある程度高い傾向が見られ、元ツイートがポジティブな内容であれば、リプライもポジティブ寄りの感性になりやすいことが考えられる。

## 6. おわりに

本研究では、Twitter でのバズ現象の要因を探るための分析手法を提案した。Twitter に投稿されたテキスト内容のみで、バズの要因を分析することは難しいと考え、画像が添付されたツイートに限定して、ツイートのテキストと添付された画像のそれぞれから推定した感性情報が、人気を示す指標「いいね」や拡散の規模を表す「RT」の数とどのような関係にあるのかを分析した。

提案手法では、テキスト、画像、リプライから抽出した特徴ベクトルを入力として感性情報を推定するモデルを学習し、推定された感性情報を用いて分析を行った。ツイートは、Joy (喜び)、Sadness (悲しみ)、Anticipation (期待)、Surprise (驚き) に分類されるものが多く、Fear (恐れ)、Disgust (嫌悪)、Anger (怒り)、Trust (信頼) にはほとんど分類されない結果となった。感性推定モデルの性能や学習データに問題があるとも考えられるが、拡散されやすいツイートには Fear (恐れ)、Disgust (嫌悪)、Anger (怒り)、Trust (信頼) などの感情はあまり含まれないことも要因の一つとして考えられる。また、画像からの感性推定の場合、画像特徴量から直接、感性を推定することができないため、画像と対応するキャプションのデータをもとに画像特徴量からテキスト特徴量に変換するモデ

ルを作成し、間接的に画像から感性を推定する手法を提案した。しかし、画像のキャプションは、画像に写っている物体や情景を端的に表現した文であり、感性が含まれにくく、WRIME コーパスにおける発話テキスト文とは本質的に性質が異なるため、用いるデータセットを再検討すべきである。

また、本研究ではユーザの属性にはとくに着目していないため、投稿者とフォロワーとの関係が拡散の速度や規模に強い関係があるバズ現象の性質から考えると、今後はユーザ情報 (属性、投稿履歴、フォロー・フォロワー関係) も含めた様々な角度から分析する必要がある。

また、実験対象としたデータセットの規模は小さく、収集期間も限られていたため、データに偏りがあった。今後は、Twitter API の学術研究向けトラックを用いることで、収集期間やリクエスト数の制限を緩和したうえで、収集条件などを再検討したい。また、投稿ユーザの属性やツイートの投稿時間など、分析対象を追加し、いいねや RT の数に影響を与える特徴量を明らかにしたい。

## 謝辞

本研究は令和 4 年度 SCAT 研究助成、JSPS 科研費 JP20K12027, JP 21K12141 の助成を受けたものです。

## 参考文献

- [1] Kazuyuki Matsumoto, Yuta Hada, Minoru Yoshida, and Kenji Kita, "Analysis of Reply-Tweets for Buzz Tweet Detection," Proceedings of the 33rd Pacific Asia Conference on Language, Information and Computation (PACLIC), pp. 138-146, (2019).
- [2] Clemens Deusser, Jansen Nora, Reubold Jan Schiller Benjamin, Hinz Oliver and Strufe Thorsten, "Buzz in social media: detection of short-lived viral 444 phenomena," Proceedings of the Web Conference, WWW'18, pp.1443-1449, (2018).
- [3] Chie Masumoto, Hiroki Yamaoka, Sho Ooi, Mutsuo Sano, "A Study on Personal Interests Estimation based on Machine Learning using SNS," Proceedings of the 6th International Conference on Communication and Information Processing, pp.74-78, November 27-29, (2020).
- [4] Parantapa Bhattacharya, Muhammad Zafar, Niloy Ganguly, Saptarshi Ghosh and Krishna Gummadi, "Inferring User Interests in the Twitter Social Network," Proceedings of the 8th ACM Conference on Recommender systems, pp.357-360, 2014.
- [5] Peng Zhang, Xufei Wang, Baoxin Li, "On Predicting Twitter Trend: Factors and Models," IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining, pp.1427-1429, 2013.
- [6] Anusha Ashok, Singh Sanjay, "Is That Twitter Hashtag Worth Reading," Proceedings of the Third International Symposium on Women in 440 Computing and Informatics, pp.272-277, 2015.
- [7] Twitter API, <https://developer.twitter.com/en/docs/twitter-api>
- [8] 勝又 智, 坂田 大直, "CSJ を用いた日本語話し言葉 BERT の作成", 言語処理学会 第 27 回年次大会発表論文集, 言語処理学会第 27 回年次大会発表論文集, pp.805-810, (2021).
- [9] 前川喜久雄. "『日本語話し言葉コーパス』の概要", 日本語科学, 15 巻, pp.111-133, 2004-04, 国立国語研究所 (2004).
- [10] Tsung-Yi Lin, Michael Maire, Serge Belongie, Lubomir Bourdev, Ross Girshick, James Hays, Pietro Perona, Deva Ramanan, C. Lawrence Zitnick, Piotr Dollár, "Microsoft COCO: Common Objects in Context," Computer Vision – ECCV 2014 pp 740–755, (2014)
- [11] 吉川 友也, 重藤 優太郎, 竹内 彰一, "STAIR Captions: 大規模日本語画像キャプションデータセット", 言語処理学会 第 23 回年次大会, pp537-540, (2017)
- [12] 宮内 裕人, 鈴木 陽也, 秋山 和輝, 梶原 智之, 二宮 崇, 武村 紀子, 中島 悠太, 長原 一, "主観と客観の感情極性分類のための日本語データセット", 言語処理学会第 28 回年次大会, (2022).