

複数の災害データを組み合わせた地域行動促進情報抽出手法の比較分析

山本 楓登[†] 鈴木 優^{††} 灘本 明代^{†††}

[†] 甲南大学大学院自然科学研究科 〒 658-8501 兵庫県神戸市東灘区岡本 8-9-1

^{††} 岐阜大学工学部 〒 501-1193 岐阜県岐阜市柳戸 1-1

^{†††} 甲南大学知能情報学部知能情報学科 〒 658-8501 兵庫県神戸市東灘区岡本 8-9-1

E-mail: [†]m2124007@s.konan-u.ac.jp, ^{††}ysuzuki@gifu-u.ac.jp, ^{†††}nadamoto@konan-u.ac.jp

あらまし 災害時の SNS 上には読み手に行動を促進する地域特有な情報（以下、地域行動促進情報）が存在する。これら地域行動促進情報は被災者へ様々な影響を与えると考えられる。これまで我々は Twitter を対象とし、1つの台風から地域行動促進情報抽出モデルを生成し分析してきた。しかしながら、台風には風台風や雨台風等様々な特徴があり、台風の特徴や規模によりこれまで提案してきた地域行動促進情報抽出モデルでは十分な抽出が行えないことがわかった。そこで、本研究では複数の台風の特徴を組み合わせたモデルを生成し、地域行動促進情報抽出手法の検討を行う。具体的には局地的かつ甚大な暴風をもたらした 2019 年台風 15 号と広範囲かつ甚大な暴風をもたらした 2022 年台風 14 号、局地的かつ大雨をもたらした 2022 年台風 15 号を対象として、各々を教師データとしたモデルと 3つの内 2つの教師データを組み合わせたモデルを生成する。そして、教師データと異なる台風を用いて各々のモデルの抽出精度を比較する。

キーワード Twitter, 災害, 行動促進, 地域情報

1 はじめに

台風や地震、豪雨といった災害発生時、SNS より災害時の情報を取得する人が増えている。実際に東日本大震災直後の平成 24 年の総務省「災害時における情報通信のあり方に関する調査結果」¹によると、被災者は即時性や地域性のある情報を SNS より取得している報告がある。しかしながら、災害発生時の SNS では様々な情報が発信されるため、SNS 上には膨大かつ様々な情報で溢れている。このような情報の中から有益な情報を迅速かつ的確に取得することは減災や被災者支援に繋がるため重要である。特に、読み手に行動の促進や抑制を促す情報は、読み手の行動に影響を与えるため、重要であると考えられる。

これまで我々は災害時の Twitter を対象とし、読み手に行動を促進するツイートを行動促進ツイートと呼び、行動促進ツイートの抽出手法を提案してきた [1]。行動促進ツイートとは、例えば、「豪雨により河川氾濫の恐れがあるため、早めに避難しましょう。」といったツイートが挙げられる。特に、「XXX 川の水位が上昇しているため、周辺地域にお住まいの方は早めに避難しましょう。」といったような、地域情報が含まれる行動促進ツイートは地域情報が含まれない行動促進ツイートと比べて、有益な情報が多いことがわかっている [2]。このような地域情報を含む行動促進ツイートを地域行動促進ツイートと呼ぶ。

また、この地域行動促進ツイートには様々な情報が混在しているため、災害時に必要な情報を迅速かつ的確に送ることが困難である。例えば、「中央公民館で避難所を開設しましたので、ご利用ください。」といった被災地から被災者に向けた情報や「XXX 町では断水の影響で水が不足しております。助けてくだ

さい。」といった被災地から非被災者に向けた情報がある。これらの情報は内容が異なるだけでなく、それを受け取った人の立場により有益な場合もあるが非有益な場合も考えられる。そこで我々は、地域行動促進ツイートを発信元地域（被災地、非被災地）と発信先（被災者、非被災者）に分類する手法を提案し、これら 4つの組み合わせによる特徴分析を行ってきた [3] [4]。

これまで我々は 2019 年の台風 15 号を対象とし、1つの台風時から地域行動促進ツイートの分類モデルを生成し分析してきた。分類した地域行動促進ツイートには、その台風特有の情報もあれば、行政が発信した情報や台風時に一般的に役立つような情報もあることがわかった。特に、あらゆる台風にとって一般的に役立つ情報は被災地に関わらず有益な情報であることがわかった。しかしながら、台風には風速のある風台風や降水量のある雨台風等様々な特徴を持った台風があり、台風の特徴や規模によって情報が異なり、特に重要な情報が異なることもわかった。そのため、これまで提案してきた 1つの台風時の地域行動促進情報分類モデルでは異なる特徴を持つ台風を十分な精度で抽出が行えないと考えられる。これでは、様々な特徴の台風が来た時に我々が提案したモデルの精度が十分ではなく対応できない。そこで、本研究では大規模台風、小規模台風、雨台風、風台風等様々な特徴を持つ台風がある中で、複数の台風を組み合わせたモデルを生成し、地域行動促進ツイートの抽出手法の検討を行う。具体的には、大規模ではあるが、局地的（千葉県を主とした関東地方）かつ風台風であった 2019 年台風 15 号と、列島横断型で風台風であった 2022 年台風 14 号、及び小規模であり静岡の局地的な台風ではあったが雨台風であった 2022 年台風 15 号の 3つの台風を対象とする。そして、3つの内 2つの台風データを教師データとして組み合わせた分類モデル、1つの台風データを教師データとした分類モデルを生成し、

1 : http://www.soumu.go.jp/menu_news/s-news/01tsushin02_02000036.html

それぞれの分類モデルの精度の比較実験を行い、考察する。そして、各々の台風の教師データと異なる台風を用いて各々のモデルの抽出精度を比較する。

本研究の手順は以下の通りである。

(1) 地域行動促進ツイートを抽出する。

(2) 3つの内2つの台風データを組み合わせた教師データと各々の台風データの教師データを用いて、地域行動促進ツイートの発信元地域と発信先の分類モデルを生成する。

(3) (2) で生成したモデルごとに教師データと異なる台風データで分類モデルの精度を比較する。

本研究により、今後新たに発生した台風に対して、必要としている人に必要な地域行動促進情報を迅速かつ的確に送ることができる考える。

以下、2章で関連研究について述べ、3章で地域行動促進ツイートの抽出手法について説明する。4章で複数の災害データを組み合わせた地域行動促進ツイートの抽出手法について説明する。5章で提案手法を用いた比較実験を行い、その考察について述べる。最後に、6章で本論文のまとめと今後の課題について述べる。

2 関連研究

Twitter上の災害情報を抽出する研究は数多く行われている。例えば、Paulら[5]は、2012年から2018年に発生した台風に関するツイートを分析し、機械学習を用いて停電や通信障害に関するツイートのカテゴリ分類を行っている。そして、BERTを用いることで短時間かつ高精度でカテゴリ分類できることを示している。Nguyenら[6]は、災害時のツイートを災害関連カテゴリに分類し、根拠を用いてツイートを要約するためのフレームワークを提案している。このフレームワークを用いることで、分類できるだけでなく、災害情報の要約をリアルタイムで生成できることを示している。Krishnaら[7]はリアルタイムのTwitterデータから災害に関連するツイートを識別し、「救助」と「寄付」に分類する災害対応システムとして「Disastro」を提案している。六瀬ら[8]は災害関連ツイートを機械学習を用いて「津波」「避難」「ライフライン」「交通機関」「道路」の災害カテゴリで分類している。これらの研究は、災害時のツイートを「救助」や「寄付」、「津波」といった災害情報や被害情報でカテゴリ毎に分類している。これらの研究に対し、本研究では読み手に行動の促進や抑制を促す情報を災害情報や被害情報ではなく、発信元地域と発信先で分類している点で異なる。

さらに、Twitter上の災害情報を分析する研究も数多く行われている。例えば、Yamadaら[9]は、2018年の西日本豪雨災害時のツイートを対象に、ツイート数の推移やハッシュタグ・絵文字の利用傾向、リツイート数、ニュース記事のURL付きツイート数に着目した分析を行っている。Nishikawaら[10]は、2018年西日本豪雨災害時に投稿された救助要請のハッシュタグが付いたツイートの内容や傾向を分析している。そして、救助要請のハッシュタグが付いたツイートは地域名やランドマーク、住所が含まれており、救助が必要な場所を特定する際に有用で

あることを示している。森野ら[11]は、2020年7月の豪雨時の「救援」もしくは「救助」を含む画像付きツイートを対象に、ツイート画像とそれに対応したツイートテキストの傾向を分析している。北田ら[12]は、東日本大震災前後のツイートから得られた議論話題のトピックをフィルタリングとランキングを用いて可視化し、分析を行っている。その結果、Twitterにおける議論話題の変遷が観測でき、トピックの時系列関係を幅広く観察できることを示している。これらの研究は、一つの大規模災害を対象として、ツイートの特徴分析を行っている。本論文では、複数の台風を対象として、台風データを組み合わせて地域行動促進ツイートの発信元地域と発信先の分類モデルの精度を比較分析している。

3 地域行動促進ツイートの抽出と分類

3.1 行動促進ツイートの抽出

これまで我々は、大規模災害時の行動促進ツイート自動抽出集手法を提案してきた[1][3]。本研究では行動促進ツイートの抽出にこれまでの比較実験で最も良い精度を出したRoBERTa[13]を用いる。RoBERTaの実装には機械学習ライブラリであるPyTorch²を採用する。pre-trainingモデルには、RoBERTa日本語Pretrainedモデル³を用いる。単語の特徴ベクトルは、URLとTwitterユーザ名を除いたツイートに対してJuman++⁴を用いて形態素解析を行い、RoBERTa日本語Pretrainedモデルに入力して、RoBERTaの最終層から取得した分散表現を用いる。取得した分散表現は全結合層への入力となり、fine-tuningを行い、行動促進ツイートか否かを判別する。このとき、RoBERTaの各種ハイパーパラメータはグリッドサーチにより決定し、隠れ層は12、ベクトルサイズは768、バッチサイズは32、エポック数は5、学習率は0.001、ドロップアウト率は0.1とした。また、RoBERTaの最終層の学習率は0.00005とし、オプティマイザーにはAdam[14]を採用した。

抽出モデルの作成には2019年に関東地方（特に千葉県房総半島）を襲った大型台風である台風15号⁵のデータ（2019年9月6日～9月18日）を用いる。使用するデータは行動促進ツイート、非行動促進ツイートともに12,215件で合計24,430件である。

3.2 地域行動促進ツイートの抽出

先行研究[3]と同様に、本研究でも地域行動促進ツイートは、行動促進ツイートの中で災害時の被災地域を判別できる単語が1つ以上含まれているツイートと定義する。この被災地域を判別できる単語を被災地特定単語と呼ぶ。被災地特定単語の地域特有な情報は細かい地名やその地域固有の施設名に含むため、以下の市区町村群名のみならず、町域名、施設名を用いる。この時、災害は局地的な場合もあるため、広い地域を示す県名は

2: <https://pytorch.org/>

3: <https://huggingface.co/nlp-waseda/roberta-base-japanese>

4: <https://nlp.ist.i.kyoto-u.ac.jp/?JUMAN>

5: <https://ja.wikipedia.org/wiki/令和元年房総半島台風>

表 1 取得した施設名

公民館	コミュニティセンター	センター	プラザ	ホール
アリーナ	小学校	中学校	高校	大学
市役所	区役所	消防署	警察署	保健所
病院	避難所	集会所	会館	館
保育園	学園	園	体育館	グラウンド
公園	川	駅		

被災地特定単語から外す。被災地特定単語の種類を以下に示す。

- 市区町村郡名

日本郵便の郵便データ⁶より取得し、被災地特定単語とする。この時ツイートの中には例えば「千葉県」と「千葉市」のように県名と市町村名が同じ名前がある。本研究では県名と市名が同じ場合、その名前だけが出ている場合は市名であると判断する。例えば「千葉」と含んでいるツイートは「千葉市」であるとみなす。千葉県で取得した場合の被災地特定単語の市区町村郡名は全部で 66 市区町村郡とある。

- 町域名

日本の住所では市区町村郡名の下に町域名がある。町域名とは、「千葉県館山市犬石」の場合の「犬石」である。この町域名も日本郵便の郵便データより取得する。この時、1 文字の地名は地名以外の単語にも含まれる可能性があると考え、削除する。例えば「千葉県館山市沼」の「沼」がそれである。また、町域名には県名や県庁所在地と同じ名称が含まれている場合があるため、これらも削除する。千葉県の場合は、町域名は千葉県内全部で 2,868 町域である。これを都道府県ごとに決定する。

- 施設名

「体育館」や「小学校」などの避難場所に関する施設名や、「警察署」「保健所」などの災害情報を発信する公共施設名は災害時に頻出する施設名である。これらの施設名は地域情報を特定することが可能である。そこで内閣官房国民ポータルサイトの避難施設の一覧表⁷より施設名を取得する。さらに、行動促進ツイートの中で、取得した施設名の前が名詞の場合のみ被災地特定単語とする。取得した施設名は全部で 28 施設である。表 1 に取得した施設名を示す。

被災地特定単語が 1 つ以上含まれている行動促進ツイートを地域行動促進ツイートとする。

3.3 地域行動促進ツイートの分類手法

災害時の地域行動促進ツイートには、様々な情報が混在している。例えば、被災者に向けて発信された避難所に関するツイートもあれば、非被災者に向けて発信されたボランティアに関するツイートもある。これら混在したツイートを発信元地域と発信先により分類することにより、必要な情報を必要な人に提示できると考えられる。そこで、先行研究の手法[3]を用いて、抽出した地域行動促進ツイートを発信元地域（被災地、非被災地）と発信先（被災者、非被災者）に分類する。ここで、発信元を人ではなく地域とした理由は、非被災者が被災地にボ

表 2 各台風の特徴

No	災害	被災地	台風の特徴
1	2019 年台風 15 号	局地的（千葉県）	暴風、停電、断水
2	2022 年台風 14 号	広範囲	暴風、停電
3	2022 年台風 15 号	局地的（静岡県）	大雨、停電、断水

ランティアに行ったりというように、非被災者が被災地から情報を発信する場合は考えられるためである。

発信元地域の分類

抽出した地域行動促進ツイートの発信元地域を被災地、非被災地に分類する。発信元地域の分類には RoBERTa を使用する。単語の特徴ベクトルは、URL と Twitter ユーザ名を除いたツイートに対して Juman++ で形態素解析を行い、RoBERTa 日本語 Pretrained モデルに入力して、RoBERTa の最終層から取得した分散表現を用いる。取得した分散表現は全結合層への入力となり、fine-tuning を行い、被災地か非被災地かを判別する。このとき、RoBERTa の各種パラメータはグリッドサーチにより決定する。隠れ層は 12、ベクトルサイズは 768、バッチサイズは 32 または 16、エポック数は 5、学習率は 0.00002 または 0.00003、ドロップアウト率は 0.1 とする。オプティマイザーには Adam を採用する。

発信先の分類

発信元の分類と同様に、地域行動促進ツイートの発信先を被災者、非被災者に分類する。この発信先の分類も RoBERTa を使用する。単語の特徴ベクトルは、URL と Twitter ユーザ名を除いたツイートに対して Juman++ で形態素解析を行い、RoBERTa 日本語 Pretrained モデルに入力して、RoBERTa の最終層から取得した分散表現を用いる。取得した分散表現は全結合層への入力となり、fine-tuning を行い、被災者か非被災者かを判別する。このとき、RoBERTa の各種パラメータはグリッドサーチにより決定し、オプティマイザーには Adam を採用する。

4 複数の災害データを組み合わせた地域行動促進ツイートの分類手法

これまで我々は、2019 年の台風 15 号を対象とし、提案手法である 3.3 節の地域行動促進ツイートの分類手法を用いて 1 つの台風時から発信元地域と発信先の地域行動促進ツイート分類モデルを生成し分析してきた。しかしながら、台風には風速のある風台風や降水量のある雨台風等様々な特徴を持つ台風があり、台風によって同じような被害もあれば、その台風特有の被害もある。また、台風の被害によって災害発生後の情報も異なる。そのため、台風の特徴によりこれまで提案してきた地域行動促進情報分類モデルでは、他の台風時に対して十分な精度で抽出が行えないことがわかった。そこで、本研究では複数の台風を組み合わせたモデルを生成し、発信元地域と発信先の地域行動促進ツイートの分類手法の検討を行う。具体的には、表 2 に示す 3 つの台風を対象とする。そして、3.3 節の地域行動促進ツイートの分類手法を用いて、3 つの内 2 つの台風データを

6 : <https://www.post.japanpost.jp/zipcode/dl/oogaki-zip.html>

7 : <http://www.kokuminhogo.go.jp/hinan/list.html>

表 3 災害ごとの地域行動促進ツイートのデータ数

No	災害	行動促進ツイート	地域行動促進ツイート
1	2019 年台風 15 号	12,215	4,025
2	2022 年台風 14 号	67,378	9,932
3	2022 年台風 15 号	51,599	6,994

表 4 災害ごとの収集データ数

No	災害	発信元地域			発信先		
		被災地	非被災地	合計	被災者	非被災者	合計
1	2019 年台風 15 号	1,942	1,240	3,182	2,032	986	3,018
2	2022 年台風 14 号	972	3,143	4,115	1,600	2,011	3,611
3	2022 年台風 15 号	3,436	1,743	5,179	2,994	1,829	4,823

表 5 災害ごとの実験データ数

No	災害	発信元地域			発信先		
		被災地	非被災地	合計	被災者	非被災者	合計
1	2019 年台風 15 号	1,240	1,240	2,480	985	985	1,970
2	2022 年台風 14 号	970	970	1,940	1,600	1,600	3,200
3	2022 年台風 15 号	1,740	1,740	3,480	1,825	1,825	3,650

組み合わせた分類モデルと 1 つの台風データを用いた分類モデルを生成し、それぞれの分類モデルの精度の比較実験を行う。台風データを組み合わせたモデルの発信元地域と発信先分類モデルの RoBERTa の各種パラメータはグリッドサーチにより決定する。

5 実 験

提案した 3 つの内 2 つの台風データを教師データとして組み合わせたモデルが発信元地域（被災地、非被災地）と発信先（被災者、非被災者）の分類に適しているかを評価するために、分類精度の比較実験を行う。実験で使用するデータは表 3 に示すツイートデータである。実験に使用するツイートデータは台風の上陸前から上陸後の期間を対象に、クエリとして「台風」を用いて無作為に収集したツイートを用いる。

5.1 実験データ

表 3 に示す 3 つの台風のデータから抽出した地域行動促進ツイートを用いる。

まず、3.1 節の我々の提案する行動促進ツイート抽出手法を用いて、行動促進ツイートを抽出する。次に、3.2 節の我々の提案する地域行動促進ツイートの抽出手法を用いて、被災地特定単語を含む地域行動促進ツイートを抽出する。ここで、各台風時の被災地特定単語は主な被災地を対象地域として決定した。その結果、2019 年台風 15 号は千葉県、2022 年台風 14 号は日本全国、2022 年台風 15 号は静岡県を対象地域として決定し抽出する。そして、これら抽出した地域行動促進ツイートに対してクラウドソーシングを用いて、発信元地域のラベル付けを被災地、非被災地、不明の 3 種類で行う。ここでは、1 ツイートあたり 5 人の被験者が判定し、3 人以上が被災地、非被災地とラベル付けしたツイートを正解データとする。次に発信先のラベル付けを被災者、非被災者、不明の 3 種類でクラウドソーシングを用いて行う。発信元地域のラベル付けと同様に決定した、被災者、非被災者のツイートを正解データとする。各々のデー

タのデータ数を表 4 に示す。そして、アンダーサンプリングを行い、実験に用いたデータ数を表 5 に示す。

5.2 実験方法

3.3 節の我々の提案する地域行動促進ツイートの分類手法を用いて、複数の台風データを組み合わせた地域行動促進ツイートを発信元地域と発信先の 2 つの分類を行う。具体的には RoBERTa の fine-tuning を各台風データのみで行ったモデルと、複数災害の台風データを用いて行ったモデルを比較する。手順を以下に示す。

(1) 2019 年台風 15 号と 2022 年台風 14 号、2022 年台風 15 号の 3 つの台風データ各々を教師データとして、発信元地域（被災地、非被災地）の fine-tuning を行い、発信元分類モデルを生成して、教師データと同じ台風のテストデータを用いて精度を算出する。

(2) 2019 年台風 15 号と 2022 年台風 14 号、2022 年台風 15 号の 3 つの内 2 つの台風データを教師データとして組み合わせ、発信元地域の fine-tuning を行い、発信元分類モデルを生成して、教師データと同じ 2 つの台風のテストデータを用いて精度を算出する。

(3) 発信先（被災者、非被災者）の分類に関しても (1) (2) と同様に、発信先分類モデルを生成して精度を算出する。

(4) 生成した発信元分類モデルと発信先モデルを用いて、fine-tuning 時に使用していない台風データを用いて精度を算出する。

表 6 に fine-tuning に用いたデータの一覧を示す。教師データとテストデータが同じ台風の実験データは地域行動促進ツイートからそれぞれ 20% のツイートを無作為に抽出し、テストデータとする。残りの 80% を教師データとし学習を行う。また、2 つの台風データを組み合わせた場合の実験データは各々の災害の地域行動促進ツイートからそれぞれ 20% のツイートをテストデータとし、残りの 80% を教師データとし学習を行う。そして、その精度を算出し、適合率、再現率、F 値、AUC を求める。

5.3 結果と考察

● 発信元地域の分類

教師データとテストデータが同じ台風の発信元地域の分類結果の適合率、再現率、F 値、AUC の結果を表 7 に示す。また、教師データとテストデータが別災害時の発信元地域で分類されたツイートの適合率、再現率、F 値、AUC の結果を表 8 に示す。表 7 より、1 つの台風データのみで学習したモデルと 2 つの台風データを組み合わせ学習したモデルを比較すると、どのモデルでも被災地、非被災地ともに適合率再現率が 0.8 を超えており、F 値も 0.8 を超えているため、発信元地域の分類ができていることがわかる。特に、No.1 と No.3 の結果より、2019 年台風 15 号 (A) と 2022 年台風 15 号 (C) は被災地が局地的である点、及び被害が停電や断水に集中した点より、教師データとテストデータの内容が近いこと全てのモデルで F 値が 0.8 以上になったと考えられる。また、各台風データの組み合わせごとの AUC の結果より、値が 0.9 前後であるため、モデルの判

表 6 災害ごとの教師データとテストデータ数

No	災害	発信元地域						発信先					
		教師データ			テストデータ			教師データ			テストデータ		
		被災地	非被災地	合計	被災者	非被災者	合計	被災地	非被災地	合計	被災者	非被災者	合計
1	2019 年台風 15 号	992	992	1,984	248	248	496	788	788	1,576	197	197	394
2	2022 年台風 14 号	776	776	1,552	194	194	388	1,280	1,280	2,560	320	320	640
3	2022 年台風 15 号	1,392	1,392	2,784	348	348	696	1,460	1,460	2,920	365	365	730

別ができてることがわかる。このことから、教師データとテストデータが同じ台風の発信元地域の分類結果から 2 つの台風データを組み合わせても発信元地域の学習ができてることがわかる。

次に 1 つの台風データのみで学習したモデルと 2 つの台風データを組み合わせて学習したモデルを別災害時に利用した際の分類結果の比較分析を行う。表 8 の No.1 と No.2 の結果より、教師データが 2019 年台風 15 号 (A) のみで学習したモデルでは、被災地の適合率が 0.891, 0.841 であり、再現率が 0.252, 0.290 であることがわかる。これは 2019 年台風 15 号 (A) の被災地が千葉県と局地的であったため、被災地の特徴を学習することができ、適合率が 0.8 以上になったと考えられる。その一方、2019 年台風 15 号 (A) のモデルでは別災害の大雨情報や断水情報をうまく判定できなかったため、再現率が 0.3 以下になったと考えられる。また、No.7 と No.9 の結果より、2019 年台風 15 号 (A) の台風データを組み合わせて学習したモデルと比較すると、どちらの組み合わせの場合も 1 つの台風データで学習したモデルより被災地の適合率再現率ともに高くなっている。これは、台風データを組み合わせることで新たな被災地の特徴を学習できたためと考えられる。

No.3 と No.4 の結果より、教師データが 2022 年台風 14 号 (B) のみで学習したモデルでは、被災地の再現率が 0.927, 0.957 であり、非被災地の再現率が 0.557, 0.547 であることがわかる。これは 2022 年台風 14 号 (B) の被災地が日本全国と広範囲であるため、どこが被災地でどこが非被災地かわからず、被災地、非被災地の特徴を学習することができなかったためと考えられる。また、No.7 と No.8 の結果より、2022 年台風 14 号 (B) の台風データを組み合わせて学習したモデルと比較すると、どちらの組み合わせも 1 つの台風データで学習したモデルより非被災地の再現率が高くなっている。そのため、台風データを組み合わせることで新たな非被災地の特徴を学習できたと考えられる。

No.5 と No.6 の結果より、教師データが 2022 年台風 15 号 (C) のみで学習したモデルでは、テストデータが 2019 年台風 15 号 (A) に対しては被災地、非被災地の適合率再現率がともに 0.8 前後であり、F 値も 0.8 以上であることがわかる。これは 2022 年台風 15 号 (A) の被災地が静岡県と局地的であるためと学習に用いる教師データが増えたため、様々な被災地の表現に対応できたと考えられる。テストデータが 2022 年台風 14 号 (B) に対しては被災地が広範囲であるため、被災地の F 値が 0.654 になったと考えられる。また、No.8 と No.9 の結果より、2022 年台風 15 号 (C) の台風データを組み合わせて学習

したモデルと比較すると、どちらの組み合わせも 1 つの台風データで学習したモデルより F 値が低くなっていることがわかる。No.8 より、2022 年台風 14 号 (B) は被災地が広範囲であり、非被災地の特徴を学習できていないためと考えられる。No.9 より、2019 年台風 15 号 (A) は 2022 年台風 15 号 (C) と同様に被災地が局地的であるため、台風データを増やしても被災地の F 値が上がらなかったと考えられる。

これらの結果から、発信元地域の分類は台風の被災地や台風データの組み合わせによって抽出精度が変わることがわかった。そのため、教師データとテストデータが同じような被災地の台風データを用いてモデルを生成する必要があると考えられる。

● 発信先の分類

教師データとテストデータが同じ台風の発信先の分類結果の適合率、再現率、F 値、AUC の結果を表 9 に示す。また、教師データとテストデータが別災害時の発信先で分類されたツイートの適合率、再現率、F 値、AUC の結果を表 10 に示す。表 9 より、1 つの台風データのみで学習したモデルと 2 つの台風データを組み合わせて学習したモデルを比較すると、2022 年台風 14 号 (B) のみで学習したモデル以外は被災者、非被災者ともに適合率再現率が 0.8 を超えており、F 値も 0.8 を超えているため、発信先の分類ができてることがわかる。特に、2019 年台風 15 号 (A) と 2022 年台風 15 号 (C) は被災地が局地的であり、被災者向けの情報に地域特有な情報が含まれているため、F 値が 0.8 以上になったと考えられる。また、2022 年台風 14 号 (B) は被災地が全国で発信先が広範囲であり、被災者、非被災者に向けた行動促進情報も様々であるため、F 値が 0.8 以下になったと考えられる。さらに、各台風データの組み合わせごとの AUC の結果より、値が 0.9 前後であるため、モデルの判別ができてることがわかる。このことから、教師データとテストデータが同じ台風の発信先の分類結果から 2 つの台風データを組み合わせることで発信先の学習ができてることがわかる。

次に 1 つの台風データのみで学習したモデルと 2 つの台風データを組み合わせて学習したモデルを別災害時に利用した際の分類結果の比較分析を行う。表 8 の No.1 と No.2 の結果より、教師データが 2019 年台風 15 号 (A) のみで学習したモデルでは、テストデータが 2022 年台風 14 号 (B) に対しては被災者の再現率が 0.483 であることがわかる。これは 2022 年台風 14 号 (B) の被災地が日本全国と広範囲であるため、その地域特有の情報を学習できず被災者向けの行動促進情報を網羅できなかったと考えられる。また、No.7 と No.9 の結果より、2019 年台風 15 号 (A) の台風データを組み合わせて学習した

表7 教師データとテストデータが同じ台風の発信元地域の分類結果

No	災害	被災地			非被災地			AUC
		適合率	再現率	F 値	適合率	再現率	F 値	
1	A	0.891	0.827	0.856	0.838	0.899	0.868	0.937
2	B	0.841	0.763	0.800	0.783	0.857	0.818	0.896
3	C	0.829	0.862	0.845	0.856	0.822	0.839	0.926
4	A & B	0.853	0.787	0.819	0.803	0.864	0.832	0.905
5	B & C	0.785	0.902	0.839	0.885	0.753	0.834	0.911
6	C & A	0.868	0.782	0.823	0.802	0.881	0.839	0.914

(注) A：2019年台風15号，B：2022年台風14号，C：2022年台風15号

表8 教師データとテストデータが別災害時の発信元地域の分類結果

No	災害		被災地			非被災地			AUC
	教師データ	テストデータ	適合率	再現率	F 値	適合率	再現率	F 値	
1	A	B	0.897	0.252	0.393	0.565	0.971	0.714	0.785
2	A	C	0.844	0.290	0.432	0.571	0.947	0.713	0.835
3	B	A	0.677	0.927	0.783	0.885	0.557	0.684	0.859
4	B	C	0.679	0.957	0.794	0.928	0.547	0.688	0.871
5	C	A	0.845	0.796	0.820	0.807	0.854	0.830	0.889
6	C	B	0.935	0.503	0.654	0.660	0.965	0.784	0.876
7	A & B	C	0.762	0.874	0.814	0.853	0.728	0.785	0.880
8	B & C	A	0.740	0.918	0.820	0.892	0.678	0.770	0.886
9	C & A	B	0.938	0.434	0.593	0.632	0.971	0.766	0.859

(注) A：2019年台風15号，B：2022年台風14号，C：2022年台風15号

モデルと比較すると、どちらの組み合わせも1つの台風データで学習したモデルより被災者、非被災者のF値が高くなっている。これは災害によって台風の被害が異なり、被災者、非被災者に向けた行動促進情報も台風によって異なるため、別台風のデータを学習させることで他の台風の行動促進情報を学習できたためと考えられる。

No.3とNo.4の結果より、教師データが2022年台風14号(B)のみで学習したモデルではテストデータがどちらの場合でも、F値が0.8前後であることがわかる。これは2022年台風14号(B)は日本全国を襲った台風であり、規模が広範囲かつ様々な被害が発生したため、様々な行動促進情報を学習できたためと考えられる。また、No.7とNo.8の結果より、2022年台風14号(B)の台風データを組み合わせ学習したモデルと比較すると、どちらの組み合わせも1つの台風データで学習したモデルより被災者、非被災者のF値が高くなっている。これは、2019年台風15号(A)と2022年台風15号(C)は被災地が局地的であるため、その地域特有な被災者向けの情報を学習できたためと考えられる。そのため、台風データを組み合わせることで行動促進情報の様々な特徴に対応できたと考えられる。

No.5とNo.6の結果より、教師データが2022年台風15号(C)のみで学習したモデルではテストデータがどちらの災害でも、F値が0.8前後であることがわかる。また、No.8とNo.9の結果より、2022年台風15号(C)の台風データを組み合わせ学習したモデルと比較すると、どちらの組み合わせも1つの台風データで学習したモデルより被災者、非被災者のF値が高いため、他の台風の行動促進情報を学習できたと考えられる。

これらの結果から発信先の分類は様々な台風データを増やす

ことで精度が向上することがわかった。そのため、複数の台風データを用いてモデルを生成する必要があると考えられる。

総評

発信元地域の分類は台風の被災地や台風データの組み合わせによって抽出精度が変わることがわかった。特に、教師データとテストデータの台風の特徴が違う場合は発信元地域を被災地、非被災地に分類することが困難である。そのため、新たに発生した台風に対して、同じような被災地の台風データや同じような被災地を組み合わせた台風データを用いて、学習した発信元地域の分類モデルを適用する必要があると考えられる。

発信先の分類は台風データを組み合わせ、学習データを増やすことで抽出精度が向上することがわかった。そのため、新たに発生した台風に対して、複数の台風データを学習した発信先の分類モデルを適用する必要があると考えられる。

6 まとめと今後の課題

本論文では、複数の台風を組み合わせた分類モデルを生成し、地域行動促進ツールの分類手法の検討を行った。具体的には、3つの台風を対象とし、2つの台風データを教師データとして組み合わせた分類モデル、1つの台風データを教師データとした分類モデルを生成し、発信元地域と発信先の分類モデルの精度の比較実験を行った。その結果、発信元地域の分類では台風の被災地や規模によって学習モデルを選択する必要があることがわかった。また、発信先の分類では台風データを組み合わせることで、1つの台風データを用いた分類モデルより抽出精度が向上することがわかった。

今後の課題として、災害データの追加や分類した地域行動促

表9 教師データとテストデータが同じ台風の発信先の分類結果

No	災害	被災者			非被災者			AUC
		適合率	再現率	F 値	適合率	再現率	F 値	
1	A	0.880	0.934	0.906	0.930	0.873	0.901	0.961
2	B	0.756	0.784	0.770	0.776	0.747	0.761	0.843
3	C	0.825	0.929	0.874	0.918	0.803	0.857	0.943
4	A & B	0.796	0.847	0.821	0.837	0.783	0.809	0.894
5	B & C	0.848	0.866	0.857	0.863	0.845	0.854	0.927
6	B & A	0.867	0.916	0.891	0.802	0.911	0.859	0.885

(注) A: 2019年台風15号, B: 2022年台風14号, C: 2022年台風15号

表10 教師データとテストデータが別災害時の発信先の分類結果

No	災害		被災者			非被災者			AUC
	教師データ	テストデータ	適合率	再現率	F 値	適合率	再現率	F 値	
1	A	B	0.681	0.374	0.483	0.568	0.825	0.673	0.700
2	A	C	0.900	0.576	0.702	0.688	0.936	0.793	0.896
3	B	A	0.730	0.847	0.784	0.818	0.687	0.747	0.863
4	B	C	0.797	0.816	0.807	0.812	0.792	0.802	0.874
5	C	A	0.820	0.864	0.842	0.857	0.810	0.833	0.925
6	C	B	0.812	0.657	0.726	0.712	0.848	0.774	0.842
7	A & B	C	0.889	0.858	0.873	0.862	0.893	0.878	0.944
8	B & C	A	0.846	0.890	0.867	0.884	0.838	0.860	0.942
9	C & A	B	0.821	0.674	0.741	0.723	0.853	0.783	0.850

(注) A: 2019年台風15号, B: 2022年台風14号, C: 2022年台風15号

進ツイートの推薦手法の提案が挙げられる。また、今回は台風を対象としたが、地震や豪雨などの他の災害での比較実験も挙げられる。

謝 辞

論文の一部はJSPS 科研費 19H04218, 20K12085, 及び私学助成金(大学間連携研究助成金)の助成によるものである。ここに記して謹んで感謝の意を表す。

文 献

- [1] 米田 吉希, 鈴木 優, 灘本 明代, “深層学習を用いた大規模災害の行動促進情報の分析,” 第12回データ工学と情報マネジメントに関するフォーラム (DEIM2020), C8-2, 7pages, 2020.
- [2] 山本 楓登, 鈴木 優, 灘本 明代, “SNS 上の大規模災害時における地域特有な行動促進情報の分析,” 第13回データ工学と情報マネジメントに関するフォーラム (DEIM2021), J11-2, 6pages, 2021.
- [3] 山本 楓登, 鈴木 優, 灘本 明代, “情報発信元地域と行動促進対象者に着目した災害時地域特有行動促進情報の分類,” 第12回ソーシャルコンピューティングシンポジウム (SoC2021), 信学技報, vol. 121, no. 125, DE2021-8, pp.40-45, 2021年7月.
- [4] Futo Yamamoto, Yu Suzuki and Akiyo Nadamoto, “Extraction and Analysis of Regionally Specific Behavioral Facilitation Information in the Event of a Large-scale Disaster”, The 20th IEEE/WIC/ACM International Conference on Web Intelligence and Intelligent Agent Technology (WI-IAT '21), pp.538-543, 2021.
- [5] U. Paul, and A. Ermakov, M. Nekrasov, V. Adarsh and E. Belding, “#Outage: Detecting power and communication outages from social networks,” Proc. of the Web Conference 2020, no.11, pp.1819-1829, 2020.
- [6] T. H. Nguyen and K. Rudra, “Towards an interpretable approach to classify and summarize crisis events from microblogs,” Proc. of the Web Conference 2022, pp.3641-3650, 2022.
- [7] A. Krishna Kanth, S. Abirami, P. Chitra and G. Gayathri Sowmya, “Real time twitter based disaster response system for indian scenarios,” 2019 26th International Conference on High Performance Computing, Data and Analytics Workshop (HiPCW), pp.82-86, 2019.
- [8] 六瀬 聡宏, 内田 理, 鳥海 不二夫, “大規模災害時の情報提供を目的としたツイート分類手法,” IEICE Conferences Archives. The Institute of Electronics, Information and Communication Engineers, 4pages, 2014.
- [9] S. Yamada, K. Utsu and O. Uchida, “An analysis of tweets posted during 2018 western japan heavy rain disaster,” 2019 IEEE International Conference on Big Data and Smart Computing (BigComp), pp.1-8, 2019.
- [10] S. Nishikawa, O. Uchida and K. Utsu, “Analysis of rescue request tweets in the 2018 japan floods,” Proc. of the 2019 International Conference on Information Technology and Computer Communications, pp.29-36, 2019.
- [11] 森野 穰, 安尾 萌, 松下 光範, 藤代 裕之, “Twitter に投稿された画像の分類に基づくツイート文の傾向分析-令和2年7月豪雨のツイートデータを対象に-,” 第13回データ工学と情報マネジメントに関するフォーラム (DEIM2021), I25-1, 5pages, 2021.
- [12] 北田 剛士, 風間 一洋, 榊 剛史, 鳥海 不二夫, 栗原 聡, 篠田 孝祐, 野田 五十樹, 斉藤 和巳, “東日本大震災時のツイートのトピック系列の可視化と分析,” 人工知能学会全国大会論文集, vol.JSAI2015, pp.2B3NFC02a1-2B3NFC02a1, 4pages, 2015.
- [13] Y. Liu, M. Ott, N. Goyal, J. Du, M. Joshi, D. Chen, O. Levy, M. Lewis, L. Zettlemoyer and V. Stoyanov, “RoBERTa: A robustly optimized bert pretraining approach,” arXiv preprint arXiv:1907.11692, 13pages, 2019.
- [14] D. P. Kingma and J. Ba, “Adam: A method for stochastic optimization,” 3rd International Conference on Learning Representations, 15pages, 2014.