

Twitter を用いた災害情報の早期発見

齋藤 翔太[†] 伊川 洋平^{††} 鈴木 秀幸[†] 村上 明子^{††}

[†] 東京大学大学院 情報理工学系研究科 〒113-8656 東京都文京区本郷 7-3-1

^{††} 日本アイ・ビー・エム株式会社 東京基礎研究所 〒135-8511 東京都江東区豊洲 5-6-52

E-mail: [†]ssaito@sat.t.u-tokyo.ac.jp, ^{††}{yikawa,akikom}@jp.ibm.com, ^{†††}hideyuki@mist.i.u-tokyo.ac.jp

あらまし 近年普及している Twitter において、ユーザーによって投稿されている即時的な情報により、実世界の出来事を即時に知ることができるようになり、特に災害対応などで注目されている。しかし、現在、災害対応においては、人手で検索し災害の情報を得ていることも多い。また、出来事の自動検出手法は数多く考案されているが、その災害のなすコンテキストの情報がわからないことが多い。本研究では、災害の情報を、その災害のなすコンテキストを示す情報とともに、早期に発見する方法を提案する。注目に値する災害は、複数の語によって表される話題になり、それらに言及するツイートは表現が異なるという仮説を立てた。この仮説に基づき、語の共起のなすグラフのコミュニティとして話題を検出し、その話題に言及しているツイート同士の表現の違いを指標化した独立ソース度という指標を考案し、それをもとに検出することを提案する。Twitter のデータを用いて 2014 年 1 月 17 日に発生した火災を対象に実験し、妥当な火災がメディアの報道より前に検出できたことを示した。

キーワード ソーシャルメディア, イベント検出, グラフ, 独立ソース度

Early Detection of Disasters with Contextual Information on Twitter

Shota SAITO[†], Yohei IKAWA^{††}, Hideyuki SUZUKI[†], and Akiko MURAKAMI^{††}

[†] Graduate School of Information Science and Technology, University of Tokyo 7-3-1 Hongo, Bunkyo-ku, Tokyo, 113-8656, Japan.

^{††} IBM Research – Tokyo 5-6-52 Toyosu, Koto-ku Tokyo, 135-8511, Japan.

E-mail: [†]ssaito@sat.t.u-tokyo.ac.jp, ^{††}{yikawa,akikom}@jp.ibm.com, ^{†††}hideyuki@mist.i.u-tokyo.ac.jp

Abstract Twitter, a recently growing micro-blogging service, offers opportunities to analyze real-time events by its real-time nature. Particularly, it is highly valuable if real-time disasters in a real world can be detected by Twitter. However, we have to search for the disaster on Twitter manually, or we cannot know the details or the contexts of the disaster if we use previous proposed event detection methods. Therefore we propose a method for an early detection of disasters with contextual information. In this study, we assume that huge disasters make a topic which is composed of several words, and that the expression of tweets mentioning that disaster diverge. Based on the assumptions, we propose to make a graph of cooccurrence of the words appearing in Twitter, and to detect real disasters by *independent source measure*, which measures how much the expressions between each tweet mentioning a same topic diverge. We demonstrate our technique on real data from Twitter and show that our method can detect reasonable disasters before media reports.

Key words Social Media, Event Detection, Graph, Independent Source Measure

1. はじめに

マイクロブログサービスの一つである Twitter は、広く世間に知られ、多くの利用者があるサービスである。Twitter においてユーザーは、自身の関心や、その時の気分や、今見ているものなど、様々なことを発信する。Twitter に発信された大量

のポストに対して、一定以上の人が言及する話題の検出や、話題の広がりなど、様々な角度から研究されている [2], [3], [5], [9].

特に近年、災害時において Twitter を活用する例が見られるようになってきている。例えば、2014 年 2 月に発生した大雪の災害においては、長野県佐久市の被害状況を市長が Twitter を

用いて把握するという事例がある^(注1)。このような災害対応は基本的には人の手を用いて行われている。また、実世界の出来事 [6], [14] や、ユーザーの言及する話題 [4], [18] を自動で検出する方法は考案されているが、どこでその災害が発生しているかや、その災害が誘引した二次災害など、災害のなすコンテキストの情報も同時に検出することは目的としていない。そこで、災害のなすコンテキストの情報に着目しコンテキスト情報と呼び、本研究では、災害の情報とともに、その災害のコンテキスト情報に価値があると考え、早期に検出することを考える。

本研究では、災害のコンテキスト情報を捉えるために、災害とそのコンテキスト情報は複数の語を含んだ話題となって Twitter 上に現れる、という仮説を立てた。既存の研究で行われてきた、ユーザーが言及する語の検出や、関連した単語を検索クエリとした出来事の検出のような、個々の語に着目したのではなく、その災害とそのコンテキスト情報を含んだ複数の語で話題として現れるという仮説を立て、この話題に着目した。

また、特に、災害を直接見て言及しているツイートは、その表現がそれぞれ異なるという仮説を立てた。具体的には、災害以外の話題は、ニュースソースの引用など、ツイートの表現が似ており、災害については、ユーザーが実際に見た物について言及するため、それぞれのツイートの表現が異なるであろうという仮説である。

この仮説に基づき、本研究では、災害とそのコンテキスト情報を検出する手法を以下のように提案する。まず、ツイートに含まれる語の共起のなすグラフに着目し、そのコミュニティを話題として検出する。その話題に言及しているツイート群の表現の違いを捉えるために、編集距離を応用した独立ソース度という指標を考案し、この指標に基づき検出することを試みた。

本研究では、以上の仮説に基づき、災害をコンテキスト情報とともに早期に発見する方法を提案する。また、実験によって手法の有効性を確かめた。

本節以降の本論文の構成は以下の通りである。第 2 節で本研究に関連した研究を紹介する。第 3 節で、Twitter からの複数の語でなされる話題の検出方法とその表現の違いを捉える独立ソース度を提案する。第 4 節で本手法の有効性を Twitter の実際のデータを用いて実験した結果を紹介し、第 5 節で本研究の結論を述べる。

2. 関連研究

本節では、本研究に関連した、Twitter からの話題の発見、及び、Twitter に現れる実世界の出来事についての研究について概観する。

話題を検出する研究に関しては、Topic Detection and Tracking と呼ばれる一つの研究分野が存在する [1]。特に Twitter から話題を発見するため、単語のバーストを捉える数理手法を構築した研究がある [18]。また、話題を共有したユーザーの友人

関係 [21] や、ユーザー間の普段作るリンクと話題引用時に作るリンクの違い [17] に基づいて検出する研究などがある。加えて、ある一定以上のユーザーがある話題について言及している状態を集団注意と呼び [19]、集団注意をハッシュタグや言語の頻度などから解析した研究も存在する [10], [16]。これらの研究は、本研究で扱う複数の語でなされる話題の発見、という点からは異なる。Cataldi ら [4] は、複数の語でなされる話題の発見を目標としている点で本研究と動機が近い。しかし、Cataldi らは、ユーザーの友人関係のなすグラフに着目し、他のユーザーに認められているユーザーによって言及された話題を検出することを目標としている点において、実世界の災害情報を対象とする本研究とは異なる。

Twitter に現れる実世界の出来事についての研究もさかに行われている。2009 年にフランスで発生した山火事 [7] や、2010 年に発生したチリ沖地震 [12] や、2011 年に発生した東日本大震災 [15] において、Twitter がどのように使われたかを分析した研究がある。これらの研究は、出来事を検出することを目的としていない点で本研究とは異なる。また、インフルエンザの流行を Twitter から予測する研究もある [6] が、予測を目的としており、インフルエンザの流行のコンテキスト情報を得ることや早期発見を目的としていない点で本研究と異なる。Sakaki ら [14] は、Twitter から地震を早期に発見することを目的としている点で本研究と動機が近い。Sakaki らの研究は、地震に関連した検索クエリを入力し、地震を早期発見し、また発見した地震の場所を推定する研究であるが、発見した出来事のコンテキスト情報を得ることを目的としていない点で、本研究と異なる。

3. 提案手法

本研究では、実世界における災害を直接見て言及するツイートは、Twitter 上において、

1. 災害と関連した複数の語を含む話題となる
2. 災害と関連したツイート群の表現が互いに異なる

という仮説を立てた。本仮説に基づき、

1. 対象とした災害に関連した語を検索クエリとして設定し、ツイートを収集
2. 各時刻ごとに語の共起をグラフ化し、そのコミュニティとして話題を検出。また、各時刻ごとに検出された話題を、時系列的に追跡
3. 各話題ごとに独立ソース度という、各ツイート同士の表現の違いを指標化したものを計算

という手法を提案する。以下では、上記の詳細を述べる。

3.1 データ集合の定義

本節では、手法を適用するデータ集合を定義する。

全ツイートを TW とおく。対象とする災害に関連した語を $Q = \{q_1, \dots, q_l\}$ と設定する。 TW に属するツイートのうち、 Q の要素である語を 1 つ以上含んでいるものの集合を TW_Q とおき、データセットとする。また、ツイートのサンプリング時刻を t_1, t_2, t_3, \dots とする。具体的には、実時間を一定間隔でサンプリングしたものである。 TW_Q のうち、時刻 t_k から τ 遡つ

(注1) : 雪害対応にツイッター活用 柳田清二・佐久市長に聞く / 東京 <http://mainichi.jp/area/tokyo/news/20140228dd1k13040029000c.html> 2014 年 5 月閲覧

時刻 $t_k - \tau$ までのツイートを、時刻 t_k の Q のツイートとして扱うことにし、 $TW_Q^{(t_k)}$ と表すことにし、このデータセットを対象に、以下の手法を適用する。

3.2 話題の検出

本節では、ツイートから、複数の語でなされる話題を検出する方法を述べる。ツイートに含まれる語と、その共起の相互情報量で語の共起を重み付きグラフで表現し、グラフから検出されたコミュニティを構成する語の集合を本研究で話題と呼ぶ。以下では、その詳細について述べる。

3.2.1 語の共起のグラフ

本小節では、語の共起から重み付きグラフを生成する方法について述べる。本研究において共起とは、同一ツイート内に2つの語が同時に出現することと定義する。

時刻 t_k における対象とするツイートの集合 $TW_Q^{(t_k)}$ 内の全ツイートを形態素解析し、検索クエリ Q に属する語を除いた一般名詞と固有名詞の集合を得る。ここで、他の語を除いたのは、一般名詞と固有名詞が、災害の情報を直接示しているであろうという理由による。さらに、得られた語のうち出現頻度の上位 d 個の語を選び、語の集合

$$W^{(t_k)} = \{w_1^{(t_k)}, w_2^{(t_k)}, \dots, w_d^{(t_k)}\} \quad (1)$$

を得る。また、各語の組 (w_i, w_j) の相互情報量

$$m_{i,j}^{(t_k)} = \log \frac{N^{(t_k)} \text{freq}(w_i, w_j)}{\text{freq}(w_i) \text{freq}(w_j)} \quad (2)$$

を求める。ただし、 $N^{(t_k)}$ は $TW_Q^{(t_k)}$ に現れる、形態素解析によって検出された語の総数を表し、 $\text{freq}(w_i)$ は語 w_i の出現頻度、 $\text{freq}(w_i, w_j)$ は w_i と w_j が同一ツイートに現れる頻度である。

このとき、語の集合 $W^{(t_k)}$ を頂点集合とし、各語間の相互情報量 $m_{i,j}^{(t_k)}$ を枝重みとする、重み付き無向グラフを考えることができる。これを語の共起グラフと呼び、 $G^{(t_k)}$ とおく

3.2.2 コミュニティ検出による話題検出

本小節では、3.2.1 節で定義した、語の共起グラフを用いて、話題を検出する方法について述べる。

一般にコミュニティ構造を持つグラフが数多く存在することが知られている [8]。そのようなグラフでは、グラフの頂点が複数の集団に分割され、同じ集団内では枝が密で、異なる集団間では枝が疎である。この1つの集団をコミュニティという。本研究では、時刻 t_k において、語の共起グラフ $G^{(t_k)}$ 内の各コミュニティを話題と呼び、 $T_i^{(t_k)} (i = 1, \dots, N^{(t_k)}_{com})$ と表す。ただし、 $N^{(t_k)}_{com}$ はコミュニティの数である。グラフからコミュニティを検出するアルゴリズムは多数提案されている [20] が、本研究では即時性を重視するため、計算量の点から有利である Fast Modularity [13] を利用する。

時刻 t_k におけるツイート $tw_j \in TW_Q^{(t_k)}$ が、 $T_i^{(t_k)}$ の語を a 種類以上含んでいた場合、 tw_j は話題 $T_i^{(t_k)}$ に言及しているツイートと定義し、そのツイートの集合を $S_i^{(t_k)}$ と表す。

3.2.3 話題の時系列追跡

次に、前小節で検出した各時刻における話題を、時系列とし

て追跡する手法ため、時刻 t_k の話題と時刻 t_{k-1} の話題が同じ話題かどうかを判定する方法を述べる。

時刻 t_k の話題 $T_i^{(t_k)}$ と、時刻 t_{k-1} の話題 $T_j^{(t_{k-1})}$ があるとき、2つの集合の類似度を測るジャックカード指数

$$d(T_i^{(t_k)}, T_j^{(t_{k-1})}) = \frac{|T_i^{(t_k)} \cap T_j^{(t_{k-1})}|}{|T_i^{(t_k)} \cup T_j^{(t_{k-1})}|} \quad (3)$$

を用い、

$$d(T_i^{(t_k)}, T_j^{(t_{k-1})}) > \kappa \quad (4)$$

であれば、 $T_i^{(t_k)}$ と $T_j^{(t_{k-1})}$ は同一の話題であると見なす。ここで、時刻 t_k の1つの話題 $T_i^{(t_k)}$ が時刻 t_{k-1} の複数の話題と同一と見なされることが起こることに注意する。また、時刻 t_k の話題 $T_i^{(t_k)}$ に対して、対応する時刻 t_{k-1} の話題が存在しないこともあることに注意する。

3.3 独立ソース度

本節では、ツイートの表現の違いを捉える指標である独立ソース度という指標を提案する。

ある話題に言及するツイートの表現の違いを指標とするために、話題に属するツイート同士の表現の違いを距離で評価し、それをそのツイートの長さで正規化する。それらを全ツイートの組み合わせ同士で足し合わせ、全ツイート数でまた正規化したものを独立ソース度として提案する。

すなわち、ツイートの集合 S に対して、

$$\text{ISM}(S) = \frac{1}{|S|} \sum_{tw_i, tw_j \in S} \frac{ld(tw_i, tw_j)}{l(tw_i) + l(tw_j)} \quad (5)$$

と定義する。ここで、 $ld(tw_i, tw_j)$ は、2つの文章 tw_i, tw_j 間の編集距離の一種である Levenshtein 距離 [11] である。また、 $l(tw_i)$ は、ツイート tw_i の文字数を表す。

4. 実データによる提案手法の評価実験

本節では、Twitter のデータを用いた評価実験について述べる。

4.1 実験 1: 独立ソース度の評価実験

本実験では、独立ソース度が、実際の災害を直接見て言及している話題と、それ以外の話題を弁別できるかを、2014年1月17日に発生した火災を対象に評価する。

4.1.1 目的

2014年1月17日に発生した火災のうち、メディアで取り上げられた火災に対して、メディアより報道される前に、これらを扱った話題の独立ソース度が、その他の話題と区別されるような特徴を示すかどうか試した。2014年1月17日のメディアに取り上げられた火災と、その発生時刻と、第一報が報道された時刻は表1の通りである。表1にある、通報時刻とは、消防署への第一通報時刻である。また、第一目撃時刻というのは、Twitter において、筆者らが確認した、その火災について言及している最初のツイートが投稿された時刻である。さらに、第一報時刻は、最初にメディアに報道された時刻のことを指す。

表 1 評価実験の対象とする災害

火災	通報時刻	第一目撃時刻	第一報時刻
味の素 川崎工場火災	10:19	10:21	11:29
新日鉄住金 名古屋製鉄所火災	12:00	12:07	13:00
北見工業大学火災	16:55	17:04	18:26




図 1 実験 1 の結果：提案手法によって検出された各話題とその独立ソース度

4.1.2 実データと実験の設定

2014 年 1 月 17 日 0 時 0 分から、24 時 0 分までに Twitter にポストされた公開されたツイートのうち、ツイートの中に「火事」あるいは「火災」が含まれている 20417 件を対象とした。このうち、スパムツイートや、関係のないニュース記事に関するツイートなどを排除するため、写真共有サービス 4 種 (<http://pic.twitter.com>, <http://twitpic.com>, <http://twipple.com>, <http://instagram.com>) と、初期情報拡散に効果のあるウェブサイト (<http://matome.naver.com>) 以外の URL を含んだツイートは除外した。また、ツイート中に固有名詞を含まないものは、情報が無いものとして除外した。

実験にあたって、時間のサンプリング間隔は 1 分とし、また $\tau = 20$ 分とした。また、語の共起グラフを作る際には、ツイートから、リツイートを示す 'RT'、ユーザー名を示す '@' とその後続くアルファベットと記号の列、URL を除いた。また、出現頻度順に抽出する語の数を示すパラメータ d は $d = 25$ としたが、出現頻度が 2 回以下の語は対象としなかった。加えて、式 (4) における κ は $\kappa = 0.3$ とした。これらのツイートと設定をもとに、第 3 章で提案した手法を試した。

4.1.3 実験 1 の結果と考察

実験 1 の結果を図 1 に示す。検出された 191 種類的话题に対して、横軸に時刻、縦軸に各話題の独立ソース度を取ってプロットしたものである。

図 1 より、本実験で対象としている、メディアに取り上げられた火事 3 件は、メディアで報道されるより前にピークを示していることが分かる。メディアで報道されるより前に 3 つの各火災について言及していると考えられる 4 つの話題について、独立ソース度が最も高かった時刻とその時の話題を表 2 に示す。

表 2 実験 1 の結果：各火災のメディア前の独立ソース度のピーク時刻とその話題

時刻	話題
10:40	沿線 列車 港町 鈴木町 遅れ 大師線
11:21	味の素 工場 スポンサー 事件 ヘリ
12:36	新日鉄 東海 愛知
17:36	消防車 北海道 まとめ 画像 北見工業大学 センター 工大 北見 大学

第一報時刻が 11:29 であった、味の素川崎工場の火災は、10:40 には、沿線であり火災の影響で遅延した大師線の遅れの話題として、11:21 には、味の素川崎工場を直接言及した話題として独立ソース度が最大値を示した。第一報時刻が 13:00 であった新日鉄住金名古屋製鉄所の火災は、12:36 に独立ソース度が最大値を示している。また、第一報時刻が 18:26 であった、北見工業大学における火災は、17:36 に独立ソース度が最大値として出ている。

しかし、図 1 を期間全体にわたって見ると、表 2 で示した話題より大きな独立ソース度を示している話題が多く、特に 13 時以降に集中している。これらは、主に味の素川崎工場の火災や、新日鉄住金名古屋製鉄所の火災のニュースを、テレビの映像などで見た人々によって発信されているものと考えられる。テレビでそのニュースを確認することによって、ユーザーが Twitter 上に多様な表現で感想をポストするため独立ソース度が高くなると考えられる。実際に起こっている火災を直接見て言及している話題と、メディアなどを見て言及している話題の間に弁別性があるとは言いがたい。

4.2 実験 2: 出来事の検出

本実験では、第 4.1 節で述べた実験 1 をふまえ、各火災を検出することを試みる。第 4.1.3 節で述べたように、メディアの感想を述べたツイート群が、実際の目撃情報を含んでいるツイート群より独立ソース度が高く出ることが観測されたため、一度検出した話題を扱わないことを本実験では考える。また、その上で、災害の検出の自動化を行う。

4.2.1 実験 2 の設定と目的

本実験では、実験 1 で用いた実データと、同じパラメータの設定で行った。加えて、メディアの感想の影響などを排除するために、次小節で述べる検出手法を用いて検出された話題 $T_i^{(t_k)}$ に含まれる語のうち、固有名詞だけを取り出し、この固有名詞を含むツイートを検出時刻以降に除外した。本実験では、第 4.1.1 節で述べたメディアに取り上げられた 3 件の火事が検出でき、それ以外の火事が検出されないかを試した。

4.2.2 検出手法

本実験で用いた検出手法について述べる。実験 1 で計算した各時刻、各話題の独立ソース度の平均

$$\delta_{AVE} = \frac{\sum_{t_k, i} ISM(S_i^{(t_k)})}{\sum_{t_k, i} |S_i^{(t_k)}|} \quad (6)$$

を求め、このとき、

$$ISM(S_i^{(t_k)}) > \rho \delta_{AVE} \quad (7)$$

表 3 実験 2 の結果: $\rho = 1$ で検出された話題とその時刻

時刻	話題
0:20	名城大学 消防車 画像 まとめ ツイート
9:26	東京 住宅 杉並 夫婦
10:40	沿線 大師線 列車 港町 遅れ 鈴木町
10:40	味の素 工場 川崎 近所 まとめ 画像
13:01	名古屋 工場 住金 東海 新日鉄
15:48	心斎橋 現場 商店 本町 学校 消防車
17:12	消防車 北見 方面 工大

表 4 実験 2 の結果: $\rho = 0.5$ で検出された話題とその時刻

時刻	話題
0:20	名城大学 消防車 画像 まとめ ツイート
6:12	大震災 阪神 テレビ 神戸 映像
9:26	東京 住宅 杉並 夫婦
10:33	沿線 大師 列車
10:51	味の素 工場 川崎 近所
12:33	新日鉄 工場 東海 画像 まとめ 愛知
13:02	名古屋 工場 住金 ニュース 事故
15:43	心斎橋 商店 学校
15:49	南船場 お気 ヘリ
17:09	消防車 方面 北見
19:37	萑崎 須玉 IC 中央 通行止め

であれば、話題 $T_i^{(t_k)}$ は災害として検出する。ただし ρ は 0 以上の実数である。本実験においては、係数のパラメータ ρ は $\rho = 1$ と $\rho = 0.5$ の 2 つを試した。

4.2.3 実験 2 の結果と考察

実験 2 において、検出された話題とその時刻を表 3 と表 4 に示す。まず、検出した話題の種類について述べる。目的としていたメディアに取り上げられた火災 3 件について、味の素川崎工場の火災はメディア第一報時刻 11:29 より前の 10:40 ($\rho = 1$) および、10:50 ($\rho = 0.5$) に検出され、新日鉄住金名古屋製鉄所の火災は $\rho = 0.5$ においてのみ、メディア第一報時刻 13:00 より前の 12:33 に検出され、北見工業大学の火災は、メディア第一報時刻 17:36 より前の 17:12 ($\rho = 1$) と 17:09 ($\rho = 0.5$) に検出され、 $\rho = 1$ における新日鉄住金名古屋製鉄所の火災以外はメディアによる報道より前に検出されたと考えられる。また、メディアに取り上げられた後のユーザーの感想なども、一度検出された後にまた検出されてないことから、一度話題として検出されたもののうちの固有名詞を含むツイートを排除することで、その影響を排除できたと考えられる。

また、メディアでは報道されていないが、注目を集めた火災が存在することがわかったと言える。例えば、 $\rho = 1$ では 15:48 に、 $\rho = 0.5$ では 15:43 に検出されている話題を見ると、心斎橋の付近で火災が起きていることが分かる。また $\rho = 0.5$ では、19:37 に火災の影響で中央自動車道の萑崎インターチェンジと須玉インターチェンジ間において通行止めあるいは渋滞が起っていたことがわかる。この結果により、本手法は、メディアに取り上げられる災害に限らず、ユーザーの関心を一定数集めるインパクトのある災害に対しても有効であると考えられる。

さらに、目撃情報の後に報道という順序の流れに従わないニュース報道の話題も検出された。 $\rho = 1$, $\rho = 0.5$ で同じく 9:26 に検出された話題は、ニュース報道のツイートであった。これは、この火災が深夜に発生したものであり、目撃情報が Twitter 上にポストされなかったことにより、本来検出したかった目撃情報ではなく、ニュース報道を検出してしまったと言える。

加えて、 $\rho = 0.5$ では、阪神淡路大震災関連の話題も検出されている。これは、1995 年 1 月 17 日に発生した阪神淡路大震災と同じ日付であるため表れた話題であり、これらは本手法が検出したいものではないが検出されてしまっている。

次に、違う話題として検出されているが、同じ災害について言及しているものがあることを指摘する。 $\rho = 0.5$ における、13:02 の話題は、新日鉄住金名古屋製鉄所の火災について示していると考えられるが、同様のものが 12:33 に検出されている。これは、表現が異なることによって起きたと考えられる。12:33 に検出された話題は、製鉄所の所在地である東海市で言及されていたが、13:02 では、新日鉄住金の製鉄所の名前である名古屋で言及されている。加えて、新日鉄という語を含むツイートはすでに、検出されているため除外されているが、住金という名称で言及しているユーザーが一定数おり、検出されたと考えられる。

また、 $\rho = 0.5$ で 15:49 に検出された話題に含まれる南船場は、心斎橋で起きた火災の詳細な地名である。表現の表層が異なるため、違う話題として扱われてしまっているが、同じ災害を指していると考えられる。

さらに、 $\rho = 1$ では 10:40 に、 $\rho = 0.5$ では 10:33 と 10:51 に検出されている話題は、片方は東武大師線が遅延していることに言及している話題であり、片方は味の素川崎工場における火災に言及した話題である。東武大師線の遅延は、沿線にある味の素川崎工場における火災が原因であったが、電車の遅延について言及する話題と、火災を目撃した話題は、別の話題として検出されて。これは、電車の遅延について言及するユーザーと、火災を目撃したユーザーは、現実世界において違う行動を取っていたためではないかと考えられる。

5. ま と め

本研究では、Twitter から災害を、その災害のなすコンテキストを示す情報とともに早期に検出するという問題を扱った。災害は、複数の語を含む話題として現れ、また、その災害に言及しているツイートの表現が異なるという仮説を立て、その仮説に基づき手法を提案した。2014 年 1 月 17 日のツイートを対象に実験に行い、本手法の効果を確認した。

本研究では、一度 1 日分独立ソース度を計算し、その平均 δ_{AVE} に係数 ρ をかけた $\rho\delta_{AVE}$ を閾値として採用したため、即時的な検出手法を提示することはかなわなかった。今後、対象とする時刻より前から閾値を学習することによって定めれば、即時的な検出が可能であると考えられる。災害について言及された話題を検出し、その話題に含まれる固有名詞を含むツイートを除くことは効果があったと考えられるが、即時的な検出手

法については検討課題である。

また、表現の表層が異なるがゆえに違う災害として検出されてしまっていることも今後の課題として挙げられる。これらは、本研究では、語間の関係を考慮していないことに起因すると考えられ、今後語にオントロジーのモデルをいれることなどが今後の方向性として考えられる。

最後に、今回は2014年1月17日を対象にして行ったが、他の日付に対しても実験することも今後の課題として挙げられる。また、本研究では、災害、特に火災を対象として実験を行ったが、ユーザーが独立に観測し、それについての感想を独立に述べるような性質の出来事である限り、他の出来事にも応用可能であると考えられる。例えば、災害の他にも実験2で検出された渋滞や、虹や、突発的に生じるゲリラライブなども検出できると考えられる。

文 献

- [1] J. Allan, J. Carbonell, G. Doddington, J. Yamron, and Y. Yang. Topic detection and tracking pilot study: Final report. *Evaluation*, Vol. 1998, pp. 194–218, 1998.
- [2] E. Bakshy, J. M. Hofman, W. A. Mason, and D. J. Watts. Everyone’s an influencer: quantifying influence on Twitter. In *Proc. WSDM*, pp. 65–74, 2011.
- [3] C. Castillo, M. Mendoza, and B. Poblete. Information credibility on Twitter. In *Proc. WWW*, pp. 675–684, 2011.
- [4] M. Cataldi, L. Di Caro, and C. Schifanella. Emerging topic detection on twitter based on temporal and social terms evaluation. In *Proc. MDMKDD*, pp. 4:1–4:10, 2010.
- [5] M. Cha, H. Haddadi, F. Benevenuto, and K.P. Gummadi. Measuring user influence in Twitter: The million follower fallacy. In *Proc. ICWSM*, pp. 10–17, 2010.
- [6] A. Culotta. Towards detecting influenza epidemics by analyzing Twitter messages. In *Proc. SOMA*, pp. 115–122, 2010.
- [7] B. De Longueville, R. S. Smith, and G. Luraschi. “OMG, from here, I can see the flames!”: A use case of mining location based social networks to acquire spatio-temporal data on forest fires. In *Proc. LBSN*, pp. 73–80, 2009.
- [8] S. Fortunato. Community detection in graphs. *Phys. Rep.*, Vol. 486, No. 3-5, pp. 75–174, 2010.
- [9] A. Java, X. Song, T. Finin, and B. Tseng. Why we twitter: Understanding microblogging usage and communities. In *Proc. WebKDD/SNA-KDD*, pp. 56–65, 2007.
- [10] J. Lehmann, B. Gonçalves, J. J. Ramasco, and C. Cattuto. Dynamical classes of collective attention in twitter. In *Proc. WWW*, pp. 251–260, 2012.
- [11] V. I. Levenshtein. Binary codes capable of correcting deletions, insertions and reversals. *Soviet Physics Doklady*, Vol. 10, No. 8, pp. 707–710, 1966. *Doklady Akademii Nauk SSSR*, V163 No4 845-848 1965.
- [12] M. Mendoza, B. Poblete, and C. Castillo. Twitter under crisis: Can we trust what we rt? In *Proc. SOMA*, pp. 71–79, 2010.
- [13] M.E.J. Newman. Fast algorithm for detecting community structure in networks. *Phys. Rev. E*, Vol. 69, p. 066133, Jun 2004.
- [14] T. Sakaki, M. Okazaki, and Y. Matsuo. Earthquake shakes twitter users: real-time event detection by social sensors. In *Proc. WWW*, pp. 851–860, 2010.
- [15] T. Sakaki, F. Toriumi, and Y. Matsuo. Tweet trend analysis in an emergency situation. In *Proc. SWID*, pp. 3:1–3:8, 2011.
- [16] K. Sasahara, Y. Hirata, M. Toyoda, M. Kitsuregawa, and K. Aihara. Quantifying collective attention from tweet stream. *PLoS ONE*, Vol. 8, No. 4, p. e61823, 2013.
- [17] T. Takahashi, R. Tomioka, and K. Yamanishi. Discovering emerging topics in social streams via link anomaly detection. In *Proc. ICDM*, pp. 1230–1235, 2011.
- [18] J. Weng and B.-S. Lee. Event detection in Twitter. In *ICWSM*, pp. 401–408, 2011.
- [19] F. Wu and B. A. Huberman. Novelty and collective attention. *Proc. Natl. Acad. Sci.*, Vol. 104, No. 45, pp. 17599–17601, 2007.
- [20] 増田直紀. 複雑ネットワーク: 基礎から応用まで. 近代科学社, 2010.
- [21] 斎藤翔太, 富岡亮太, 山西健司. ソーシャルネットワークにおける長期間流行する話題の早期検出. 電子情報通信学会技術研究報告. IBISML, 情報論的学習理論と機械学習, Vol. 111, No. 480, pp. 77–84, mar 2012.