

# 単語間の関係性の経時変化を考慮したマイクロブログからの実世界観測情報の抽出

## Real-world Observation Extraction from Microblog by Considering Temporal Change of Word Relationship

新田 直子<sup>△</sup> 角谷 直人<sup>△</sup> 馬場口登<sup>◆</sup>

Naoko NITTA Naoto SUMIYA

Noboru BABAGUCHI

マイクロブログにはユーザによるリアルタイムの実世界観測情報が多く投稿されるため、これらの自動抽出により実世界の状況が迅速に把握できる。ユーザから与えられるクエリにより観測対象が設定されるとき、クエリと関連性の高い単語を用いて、観測対象に関する観測情報が抽出可能と考えられる。提案手法では特に、単語間の関連性の経時変化に着目し、マイクロブログへの短期間の投稿から逐次的に学習した長期的・短期的という二つの側面の単語間関連性に基づき各投稿のクエリへの関連度を算出することにより、クエリで表される対象に加え、それに関連した対象に関する観測情報の抽出を目指す。

**The current situation of the real world can be observed from a large number of messages posted on a microblog by people all over the world. Given a text query which represents the target to observe, the messages describing the target's current situation can be extracted by using related words. Especially, aiming at extracting the messages describing the current situations of not only the target represented by the query but also other related targets, this paper proposes a sequential approach for learning both the long-term and short-term relationships among words and a method for scoring each message based on the two types of relationships among words.**

### 1. はじめに

近年、マイクロブログや画像共有サイトをはじめとするソーシャルメディアを通して、個々人が実世界を観測して得たさまざまな情報を、観測時間、場所と共に公開することに着目し、ソーシャルメディア上の情報から実世界観測情報を獲得する研究が注目されている。人間は実世界の多くの場所に存在し、五感を用いて感知したデータの意味を解釈する機能を持ったため、このように人間をセンサ (Citizen Sensor) [1] とみなして利用することは、センサ設置のコストを抑えた上で、多様な情報を取得できるという利点がある。中でも、全世界で 2 億人以上のアクティブユーザを抱

△ 正会員 大阪大学大学院工学研究科  
naoko@comm.eng.osaka-u.ac.jp

△ 非会員 大阪大学大学院工学研究科  
sumiya@nanase.comm.eng.osaka-u.ac.jp

◆ 非会員 大阪大学大学院工学研究科  
babaguchi@comm.eng.osaka-u.ac.jp

える Twitter[2] では、主な投稿形式がツイートと呼ばれる 140 文字以内の短いテキストであり、その手軽さから、テレビ番組やスポーツ観戦、災害情報、渋滞情報などさまざまな内容のリアルタイム性の高い実世界観測情報が大量に投稿されている。

Twitter を用いた実世界観測情報獲得に関する既存研究は、観測対象の関連語を用いて、観測情報を含むツイートを抽出する手法が主となっている。例えば、Sakaki ら [3] は、観測対象を地震に限定した上で、地震の観測時に用いられる単語を関連語として予め人手で設定し、関連語を含むツイートの追跡により震源地を推定した。また、土屋ら [4] は、観測対象を鉄道に限定した上で、予め準備した鉄道の運行トラブルの観測情報となるツイート集合から関連語を学習し、鉄道の運行トラブル情報を抽出した。これらの手法では、関連語や学習用データを人手で与える必要があるのに対し、ユーザが与えるクエリを観測対象と見なし、多様な観測対象の関連語を、現在までのツイートから自動的に学習する手法が提案されている。Massoudi ら [5] や藤木ら [6] は、観測対象に何か特徴的な事象が発生した場合、その事象を表す単語とクエリの同一ツイート内での共起頻度が短期的に高くなると考え、クエリと短期的に共起する単語を関連語とした。この手法により、例えば、渋滞という観測対象に対し、渋滞が発生した場所名が関連語となり、各地の渋滞の観測情報が抽出できると考えられる。

本研究では、これらの観測情報を加え、例えば渋滞の要因となる事故や工事、通行規制など、ユーザからのクエリにより定められた観測対象に関連する対象の観測情報を同時に抽出することを考える。この場合、各対象に関する観測情報は独立していることが多いため、例えば、クエリとなる渋滞という単語に対して、事故の観測情報に含まれる単語の共起頻度が短期的に高くなる可能性は低い。しかし、観測対象同士は関連しているため、渋滞と事故という単語のように、対象を表す単語同士は、時間によらず、頻度は低いものの同一ツイート内に共起する可能性が高いと考えられる。そこで、長期的、及び短期的という二つの側面での単語間の関連性に着目し、クエリに対する単語の長期的関連性に基づき観測対象を拡げ、クエリ、及びクエリと長期的関連性の高い単語に対する短期的関連性に基づき各観測対象に対する特徴的な事象を抽出する。この実現のため、本研究では、短時間のツイート集合から逐次的に単語間の長期的、短期的関連性を学習する方法、及び学習した単語間の関連性に基づき、各ツイートのクエリへの関連度を算出する方法を提案する。

### 2. 提案手法

提案手法では、ユーザから与えられるクエリ  $q$  で表される観測対象を  $Q$  とし、現在の直近の時区間において Twitter に投稿されたツイートから、 $Q$  及び  $Q$  に関連する対象  $Q'_n (n = 1, \dots)$  の観測情報を含むツイートを抽出することを目的とする。ただし観測対象  $Q, Q'_n$  はそれぞれ単語  $q, q'_n$  で表されるものとする。

ここでまず一つ目の問題として、 $Q'_n$  の観測情報の多くは、クエリとして与えられた単語  $q$  を含まないことが挙げられる。例として、クエリとして渋滞が与えられたとき、渋滞と関連する事故の観測情報の多くが渋滞という単語を含まない。ただし  $Q$  と  $Q'_n$  は関連しているため、単語  $q$  と  $q'_n$  は、頻度は高くないものの、時間によらず同一ツイート内に共起する可能性が高い。よって提案手法では、クエリ  $q$  に対して、長期的に同一ツイート内に共起する単語を  $q'_n$  として抽出することを考える。

次に、単語  $q$  及び  $q'_n$  を用いたツイート抽出を行う場合、単語  $q, q'_n$  を含むツイートは必ずしも  $Q, Q'_n$  の観測情報とは限らない、また、 $Q'_n$  の観測情報は必ずしも  $Q$  に関連しない、という二つの問題を考えられる。例として、渋滞、事故という単語を含むツイートは必ずしも渋滞、事故の観測情報とは限らず、また、事故の観測情報は、放送事故など、渋滞に関連しないものも多い。これらの問題に対しては、二つの解決策が考えられる。まず、これらのツイートは、事故に対する放送など、長期的関連性が  $q'_n$  とは高い

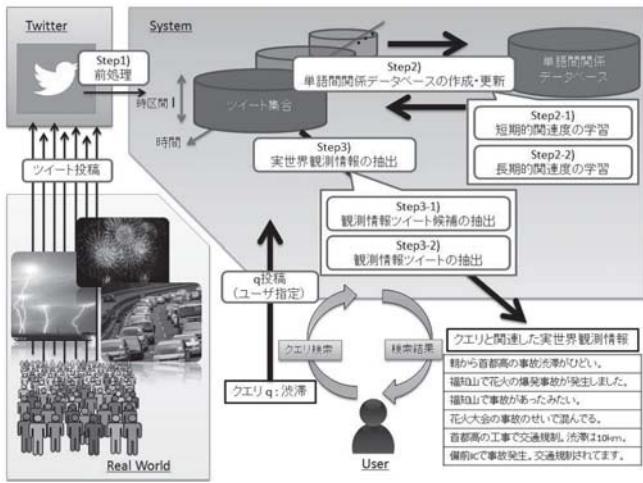


図 1: 提案手法の全体像

が、 $q$  とは低い単語を含む可能性が高いと考えられる。また、渋滞や事故の発生した場所名など、単語  $q$  や  $q'_n$  と共に頻度が短期的に高くなる単語を含むツイートは、 $Q$  や  $Q'_n$  との関連性が高く、逆に、 $q$  や  $q'_n$  と共に頻度の低い単語を含むツイートは、 $Q$  や  $Q'_n$  との関連性が低いと考えられる。

よって提案手法では、これら三つの問題に対応するため、単語間の長期的、短期的関連性を学習する。いずれの場合も、単語間の関係の経時変化を解析する必要があるため、短時間に投稿されたツイート集合から同一ツイート内の共起単語対を抽出し、現在までの学習結果を保持した単語間関係データベースの更新による逐次学習を行う。ユーザからクエリ  $q$  が与えられると、直近の時区間に投稿された各ツイートに対して、学習した単語間の長期的、短期的関連性に基づきクエリとの関連度を算出し、関連度の高いものをユーザに提示する。図 1 に手法の全体像を示し、各ステップの詳細を次節以降に述べる。

## 2.1 前処理

短い時区間長  $I$  ごとに Twitter に投稿された全ツイートを収集する。ただし、Twitter には、あるユーザが投稿したツイートを別のユーザがそのまま再投稿するリツイートや、同一のツイートを大量に投稿するスパムツイートが存在する。単語間の共起頻度はこれらのツイートによって大きく影響されるため、リツイートを表す「RT」が付与されたツイートや、重複するツイートを予め除去した上で、Twitter の Streaming API を用いて、ツイートを収集する。

また提案手法では、分析対象の単語を名詞のみに限定するため、収集したツイートに対して MeCab[7] による形態素解析を行い、名詞のみを抽出する。ただし、URL である「http://～」やユーザ名を表す「@～」をはじめとする英数字のみで構成される名詞は不要な単語として除去する。

## 2.2 単語間関係データベースの作成・更新

収集したツイートを用いて、共起単語対  $(w_i, w_j)$  とその短期的関連度  $B(w_i, w_j)$  及び長期的関連度  $S(w_i, w_j)$  からなる単語間関係を保持する単語間関係データベースを作成・更新する。ただし、時区間長  $I$  において、 $w_i$  と  $w_j$  の共起回数が 1 回の場合は、ノイズである可能性が高いため、共起回数 2 回以上の単語対のみを考慮する。

### 2.2.1 短期的関連度の学習

収集したツイート中の共起単語対  $(w_i, w_j)$  に対し、以下のように  $w_i$  と  $w_j$  の相互情報量を短期的関連度  $B(w_i, w_j)$  として算出する。相互情報量とは 2 つの確率変数の相互依存の尺度を表す量である。

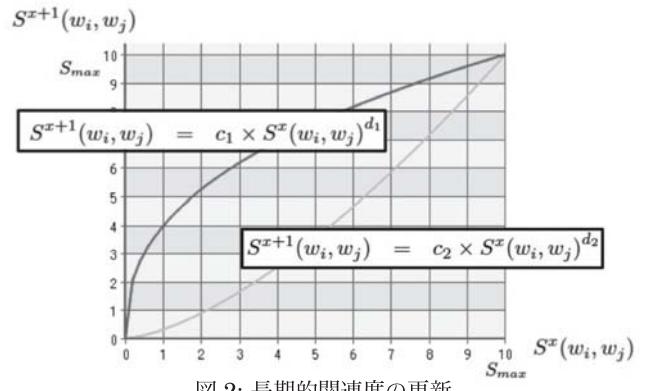


図 2: 長期的関連度の更新

あり、単語間の相互情報量が高いほど関連が高いことを示す。

$$B(w_i, w_j) = \log \frac{P(w_i, w_j)}{P(w_i) \times P(w_j)}$$

$$P(w_i) = \frac{|T_i|}{N}, \quad P(w_i, w_j) = \frac{|T_i \cap T_j|}{N}$$

ただし、単語  $w_i$  の出現確率を  $P(w_i)$ 、単語  $w_i, w_j$  の共起確率を  $P(w_i, w_j)$ 、単語  $w_i$  を含むツイート集合を  $T_i$ 、 $T_i$  のツイート数を  $|T_i|$ 、全ツイート数を  $N$  とする。

### 2.2.2 長期的関連度の学習

収集したツイート中の各共起単語対  $(w_i, w_j)$  に対し、単語間の連続的な関連性を表す指標として、以下のように長期的関連度  $S(w_i, w_j)$  を算出する。ただし、単語間の相互情報量として算出した短期的関連度  $B(w_i, w_j)$  が負の場合、 $w_i$  と  $w_j$  は関連がない。また、「フォロー」や「笑」のような出現確率が高い一般的な単語を含む単語対の相互情報量は低くなるため、以下では短期的関連度  $B(w_i, w_j) \geq \beta$  を満たす単語対のみを考慮する。

まず、 $(w_i, w_j)$  がデータベースに含まれていない場合、 $(w_i, w_j)$  を追加し、 $S(w_i, w_j)$  の初期値として、 $S(w_i, w_j) = 1$  と設定する。また、含まれている場合、現在の長期的関連度を  $S^x(w_i, w_j)$  とし、 $S^{x+1}(w_i, w_j)$  を以下のように更新する。ただし、 $d_1 < 1$  とする。

$$S^{x+1}(w_i, w_j) = c_1 \times S^x(w_i, w_j)^{d_1} \quad (1)$$

最後に、収集したツイート中に共起しなかったデータベース中の単語対  $(w_i, w_j)$  に対し、 $S^{x+1}(w_i, w_j)$  を以下のように更新する。ただし、 $d_2 > 1$  とする。

$$S^{x+1}(w_i, w_j) = c_2 \times S^x(w_i, w_j)^{d_2} \quad (2)$$

式(1)、(2)を図 2 に示す。 $d_1 < 1$  とすることにより、式(1)は連続して共起する単語対に対して、長期的関連度を上昇させる。特に、最初の数回で関連度が上昇し、連続する程に上昇の度合いが小さくなり  $S_{max}$  に収束する。また、 $d_2 > 1$  とすることにより、式(2)は共起しない期間が連続する単語対に対して、長期的関連度を下降させる。特に、スコアが大きい場合は下降の度合いが大きく、連続するほどに下降の度合いが小さくなり 0 に収束する。式(1)の傾きより小さく設定することにより、共起する時区間が散発する場合も、単語対の長期的関連度を上昇させることができる。また、 $c_1$  と  $c_2$  は、 $S(w_i, w_j)$  の最大値  $S_{max}$  により次式で決定される。

$$c_1 = S_{max}^{(1-d_1)}, \quad c_2 = S_{max}^{(1-d_2)}$$

最後に、長期的関連度が初期値を下回る、すなわち、 $S(w_i, w_j) < 1$  を満たす単語対  $(w_i, w_j)$  をデータベースから削除する。

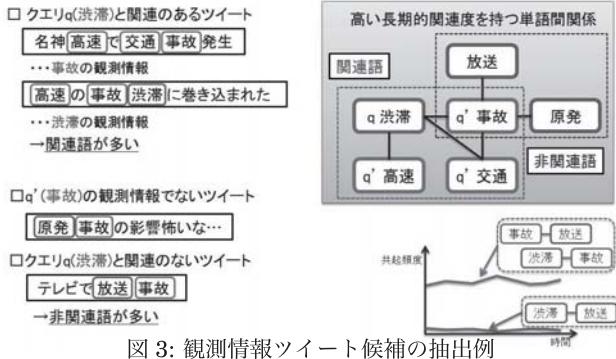


図 3: 観測情報ツイート候補の抽出例

### 2.3 実世界観測情報の抽出

ユーザからクエリ  $q$  が与えられたとき、 $q$  で表される観測対象  $Q$ 、及び  $Q$  と関連のある観測対象  $Q'_n (n=1, \dots)$  の観測情報であるツイート  $t$  を抽出する。まず、各ツイート  $t$  に対し、単語間の長期的関連度を用いて、観測対象  $Q$  及び  $Q'_n$  との関連度を算出し、関連度が高いものを観測情報ツイートの候補として抽出する。次に、各ツイート候補について、短期的関連度を用いて、観測対象  $Q$ 、 $Q'_n$  との関連度を算出し、関連度が高いものを観測情報ツイートとして抽出する。

#### 2.3.1 観測情報ツイート候補の抽出

観測対象  $Q$  と  $Q'_n$  は関連があるため、単語  $q'_n$  は、クエリ  $q$  と日常的に同一ツイートに共起し、 $q$  との長期的関連度が高いと考えられる。よって、クエリ  $q$  及び  $q$  と長期的関連度の高い単語  $q'_n$  を含むツイートを、 $Q$  と  $Q'_n$  の観測情報ツイート候補として抽出する。ただし、単語  $q'_n$  を含むツイートの中には、 $Q'_n$  の観測情報でないものや、 $Q$  と関連しない観測情報が含まれる。これらのツイートは、 $q'_n$  とは長期的関連度が高いが、 $q$  とは長期的関連度の低い単語を含む可能性が高い。

図 3 に例を示す。渋滞という単語は、事故や交通、高速などと長期間にわたって共起する。つまり、クエリ  $q$  を渋滞としたとき、 $q'_n$  となる事故や交通、高速などを含むツイートは、渋滞と関連度が高いと考え、これらを抽出する。しかし、例えば事故を含むツイートは必ずしも事故の観測情報とは限らず、また渋滞と関連しない観測情報である場合もある。このようなツイートは、図 3 に示すように、渋滞と長期的関連度が低く、事故と長期的関連度が高い放送や原発などの単語を含む可能性が高い。

そこで、ツイート  $t$  に含まれる単語  $w$  の長期的関連度を用いて、ツイート  $t$  の観測対象  $Q$  への関連度  $Score_Q(t)$  を以下のように算出する。

$$Score_Q(t) = \sum_{\substack{S(q,q') \geq \gamma \\ q' \in t}} S(q,q') - \sum_{\substack{S(q',w) \geq \gamma, \\ q' \in t, w \neq q'}} S(q',w) \quad (3)$$

第一項では、クエリ  $q$  に対する長期的関連度が高い単語  $q'$  を  $q$  の関連語とみなし、 $S(q,q')$  を加算する。第二項では、 $q'$  に対する长期的関連度が高く、かつクエリ  $q$  に対する长期的関連度が低い単語を  $q$  の非関連語  $w$  とみなし、 $S(q',w)$  を減算する。

以上の処理を行った結果、 $Score_Q(t) < \gamma$  となったツイートは、関連語より非関連語を多く含むため、クエリ  $q$  と関連が低いと考えられる。よって  $Score_Q(t) \geq \gamma$  を満たすツイート  $t$  を、観測対象ツイート候補とする。

#### 2.3.2 観測情報ツイートの抽出

観測対象  $Q$ 、 $Q'_n$  に関する特徴的な事象の観測情報となるツイートは、単語  $q$ 、 $q'_n$  と短期的に共起頻度が高くなる単語を含む可能性が高いと考えられる。図 4 に例を示す。渋滞が発生した際、その観測情報を複数のユーザが投稿することにより、発生地を表す名神や吹田という単語と渋滞の短期的関連度が高くなる。一方、携

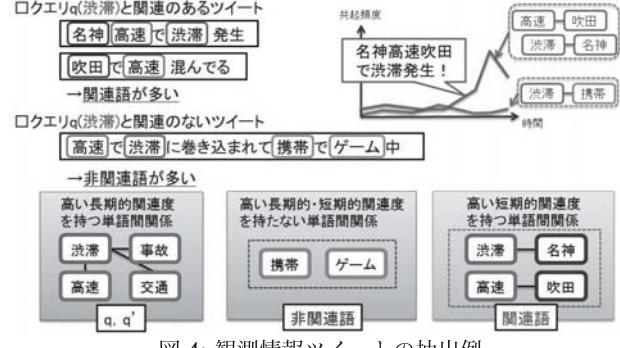


図 4: 観測情報ツイートの抽出例

帶やゲームといった単語は、偶然同一ツイート内で、渋滞と共に起したと考えられる。

そこで、ツイート  $t$  に含まれる長期的関連度が低い単語  $w$  の短期的関連度に基づき、ツイート  $t$  の観測対象  $Q$  及び  $Q'_n$  への関連度  $Score_{Q,Q'_n}(t)$  を以下のように設定する。

$$Score_{Q,Q'_n}(t) = Score_Q(t) + \sum_{\substack{w \in t, w \in R' \\ B(w, q_m) \geq \delta}} max_{q_m \in R} B(q_m, w) - \alpha S \quad (4)$$

ただし、 $R$  は  $q$  及び  $q'_n$  の集合、 $R'$  は  $Score_Q(t)$  算出時に用いなかった単語の集合であり、 $S$  は  $B(w, q_m) < \delta$  を満たすような観測対象と関連しない単語  $w$  と、共起回数が 1 回の単語  $w$  の数とする。つまり、2.3.1節で算出された関連語のいずれかに対し短期的関連度が高い単語が  $t$  に含まれる場合、該当する関連語が表す観測対象の特徴的な事象を表す単語とみなし、さらに関連度を加算する。一方で、短期的関連度が低い単語が  $t$  に含まれる場合、これを非関連語とみなし、関連度を減算する。

最後に、算出された  $Score_{Q,Q'_n}(t) \geq \gamma$  を満たすツイートをユーザに提示する。

### 3. 評価実験

提案手法の有効性を、長期的関連度と短期的関連度の有用性、及び単語間関係データベースの更新の必要性の二つの観点から検証する。Twitter の StreamingAPI を用いて、2013/10/25~11/27 に、日本語を用いて投稿されたツイートを収集し、そのうちのベ 32 日間のツイート 21,134,159 件を実験に用いた。また、 $I$  を 24 時間とし各パラメータは  $S_{max} = 10$ 、 $d_1 = 0.4$ 、 $d_2 = 1.5$ 、 $\gamma = 9.0$ 、 $\beta = 4.0$ 、 $\alpha = 4.0$ 、 $\delta = 1.0$  とした。

#### 3.1 長期的関連度と短期的関連度の有用性

まず、長期的関連度に基づく関連語がどのように変化するのかを確認するため、11/13, 20, 27 の一週間ごとの日付において、クエリ  $q$  との長期的関連度  $S(q, q'_n) \geq \gamma = 9.0$  を満たす、つまり長期的関連度に基づき  $q$  の関連語と判定された単語  $q'_n$  を表 1, 2, 3 にそれぞれ示す。下線を引いた単語は、3 日間で共通して抽出された単語  $q'_n$  である。各クエリ  $q$  に対して一般的に連想しうる単語が大きく変化することなく抽出されたことが分かる。 $q$  が清水寺のときを見ると、13 日は  $q'_n$  に該当する単語ではなく、20 日に京都、さらに 27 日に紅葉が追加されている。これは、紅葉の時期に近づくにつれて、紅葉の名所として知られる清水寺を訪れる観光客が増加し、紅葉に関する実世界観測情報が多く投稿されたことに起因すると考えられる。このように長期的関連度は比較的ゆるやかな単語間の経時変化を捉え、時節に応じた関連語も抽出できる。

また表 4 に、クエリ  $q$  を含むツイート数、 $q$  もしくは  $q'_n$  を含むツイート数、抽出した観測情報ツイート候補数を示す。各クエリ  $q$  を含むツイート数は、その日に収集された全ツイート数の 0.01 %程度であるが、 $q'_n$  を含むツイートも合わせると、大幅にツイート数が増加する。これは  $q'_n$  に一般的な単語が多く含まれるために

表 1:  $q$  を渋滞としたときの  $q'_n$  表 2:  $q$  を清水寺としたときの  $q'_n$ 

11/13				11/13			
事故	道路	交通	高速	-	-	-	-
11/20				11/20			
事故	道路	交通	高速	京都	-	-	-
11/27				11/27			
事故	道路	交通	高速	京都	紅葉	-	-

表 3:  $q$  を遅延としたときの  $q'_n$ 

11/13							
列車	本線	発生	電車	伝言板	点検	鉄道	提供
遅れ	人身	証明	事故	関東	影響	運行	提供
11/20							
列車	本線	発生	電車	伝言板	点検	鉄道	提供
遅れ	人身	証明	事故	関東	影響	運行	運休
11/27							
列車	本線	発生	電車	伝言板	点検	鉄道	提供
遅れ	人身	証明	京王	関東	運行	運休	-

表 4: 11/13～27 における各  $q$  に対する観測情報ツイート候補数

検索日時	$q$	$q$ を含むツイート数	$q, q'_n$ を含むツイート数	観測情報ツイート候補数
11/13	渋滞	37	725	198
11/20	渋滞	41	764	286
11/27	渋滞	38	789	214
11/13	遅延	54	3,211	1,095
11/20	遅延	66	3,299	967
11/27	遅延	84	3,460	1,197
11/13	清水寺	7	7	7
11/20	清水寺	14	530	140
11/27	清水寺	19	803	256

ある。例えば、クエリ  $q$  が遅延の場合、 $q'_n$  には電車や関東など、多くの人が日常的に使用する単語が含まれ、それらの単語を含むツイート数は膨大になる。これらのツイートには、クエリと関連する観測情報ツイートも含まれているが、9割以上はクエリと無関係なツイートである。

次に、クエリ  $q$  に応じた観測情報が抽出可能かを確認するため、同じ検索日時において、異なるクエリ  $q$  を与え、観測情報ツイートを抽出した。11/23において、クエリ  $q$  を渋滞、遅延としたとき、正しく抽出された観測情報ツイートと除外されたツイートの一部を表 5, 6 に示す。 $Score_Q(t)$ ,  $Score_{Q, Q'_n}(t)$  の算出時に関連語とされた単語を太字で、非関連語とされた単語を下線で示す。また、rank は各ツイートの順位である。

1-4, 1-5, 2-1, 2-4 のように、クエリ  $q$  を含む観測情報ツイートが多く関連語により正しく抽出された。例えば渋滞が発生した際には、1-4, 1-5 のように短期的関連度の高い東名や海老名などの関連語により、渋滞の観測情報が正しく抽出されている。

また、1-1～3, 2-2, 2-3 のように、クエリ  $q$  を含まないが、クエリ  $q$  に関連する観測情報も、長期的関連度の高い関連語に基づき正しく抽出された。例えばクエリ  $q$  が渋滞の場合の結果に注目すると、11/23において京葉道路でオートバイの追突事故が発生した影響で、渋滞と長期的関連度が高い事故という単語に対し、京葉道路という単語の短期的関連度が上昇し、1-1～3 のようなクエリ  $q$  を含まないツイートに対し  $Score_{Q, Q'_n}(t)$  が上昇した。

一方、1-6～10, 2-7～10 のように、クエリ  $q$  もしくは  $q'_n$  を含む観測情報ではないツイートは、非関連語により正しく除外された。1-6, 1-7, 2-7, 2-8 は短期的関連度に基づく非関連語、1-8～10, 2-9, 2-10 は長期的関連度に基づく非関連語を多く含む例

である。例えば 1-8～10 は、渋滞とは関連の低い電車の事故に関連するツイートであり、渋滞と長期的関連度の高い事故という単語を含む一方で、長期的関連度が事故とは高いが渋滞とは低い人身や遅延といった単語を含むため除外された。これらのツイートは、クエリ  $q$  が遅延の場合には、遅延と人身という単語の長期的関連度が高いため、2-1, 2-3, 2-4 のように正しく抽出されており、渋滞と遅延は、どちらも  $q'_n$  として事故を含むが、ツイートに含まれるそれ以外の長期的関連度、短期的関連度に基づき決定されるクエリ  $q$  の関連語、非関連語により、クエリ  $q$  に応じた観測情報ツイートが抽出されることが確認できた。

最後に、11/23において、クエリ  $q$  を渋滞としたときの誤抽出、未抽出例を表 7 に示す。3-1, 3-2 のように、長期的関連度に基づき学習された高速と道路という関連語  $q'$  が含まれていることに加え、 $q'$  である高速と縮小や料金という単語の短期的関連度が上昇したことにより、観測情報ではないツイートが抽出された。これは、クエリ  $q$  と長期的関連度が高い関連観測対象  $q'$  に特徴的な事象が発生した場合でも、その事象が必ずしもクエリ  $q$  と関連があるわけではないことが理由として考えられる。今後、このようなニュースなどと実際の観測情報を区別する方法を検討する必要がある。また、3-3, 3-4 はどちらも観測情報ツイートであるにも関わらず、誤って除外された。3-3 では、クエリ  $q$  である渋滞と長期的関連度が高い関連観測対象  $q'$  である事故に対しては長期的関連度が高いが、クエリ  $q$  との長期的関連度が低い発生と車線という単語が非関連語と判断され、長期的関連度に基づき  $Score_Q(t)$  が減算された。長期的関連度による非関連語を決定するパラメータについても今後検討が必要である。3-4 では、クエリ  $q$  や  $q'$  との共起回数が一回の単語を多く含むため短期的関連度に基づき  $Score_{Q, Q'_n}(t)$  が減算された。このことから、提案手法では、ツイートを収集する時区間において一度しか共起しない単語を多く含む観測情報を抽出できないことが分かる。

以上の結果より、いくつかの検討事項は残るもの、クエリ  $q$  に応じた実世界観測情報の抽出における、長期的関連度および短期的関連度の有用性が示された。

### 3.2 単語間関係データベースの更新の有用性

ユーザがクエリを与えたときの状況に応じた観測情報が抽出可能なかを確認するため、同じクエリ  $q$  に対し、異なる検索日時において観測情報ツイートを抽出した。11/18 と 11/23において、クエリ  $q$  を清水寺としたとき、正しく抽出された観測情報ツイートと除外されたツイートの一部を表 8, 9 に示す。

18 日には、4-5～8 のように、その日に発表された京都の高校サッカー選手権大会の組み合わせに関するツイートが多く抽出された。これらは清水寺の関連観測情報としては不適切と考えられるが、清水寺と長期的関連度の強い関連語として京都が抽出されたため、京都における特徴的な事象に関する観測情報として抽出された。しかし、23 日には、紅葉のシーズンを迎えた京都に関するツイートが増加したことに伴い、清水寺と紅葉の長期的関連度が高くなり、5-1～4, 5-6～8 のように、清水寺周辺の紅葉の観測情報ツイートが多く抽出された。このように、クエリを与えたときの状況に応じた関連語を抽出するためには、単語間関係データベースの更新が必要であることが分かる。

### 3.3 抽出ツイートの評価

提案手法により抽出したツイートが、クエリ  $q$  と関連する観測情報ツイートとして適切であるかを主観評価で確認した。異なる日付、異なるクエリ  $q$  を用いて観測情報の抽出を行った後、3人の被験者に、抽出したツイートのうち  $Score_{Q, Q'_n}(t)$  の上位 10, 30, 50 件のツイートに対して、クエリ  $q$  の観測情報ツイートとして適切であるかを判断させ、2人以上の被験者が適切と判断したツイートを正解ツイートとした。抽出結果は、上位  $N$  件中の正解ツイート数  $R$  の割合を示す適合率  $P@N = R/N$ 、及び、以下の式で定義される、正解ツイートが抽出したツイートの上位に存在する

表 5: 11/23 における  $q$  を渋滞としたときの観測情報ツイート

ID	rank	$Score_Q(t)$	$\hat{Score}_{Q,Q_n}(t)$	ツイート本文
1-1	1	29.99	36.28	京葉道路で事故か。オートバイの高速事故ってほぼ命にかかるから恐い
1-2	2	19.99	27.49	京葉道路で追突事故 5人死傷 <a href="http://t.co/M0kCgTUYto">http://t.co/M0kCgTUYto</a> ニュース
1-3	3	19.99	27.49	【N】京葉道路で追突事故 5人死傷 <a href="http://t.co/SqZhHTA9NO">http://t.co/SqZhHTA9NO</a>
1-4	7	20	27.19	うげー東名下りで海老名から 30km も事故渋滞してこれ解消されるまで待機
1-5	8	19.99	27.18	海老名 SA なう。ここまで東名高速は大渋滞ちう。
1-6	圈外	9.98	-18.01	交通費も全て会社持つの研修！研修内容は、地獄巡りと全国の支社の方との交流www バタバタになるかなあとは思ったけど、研修参加希望 しちゃった～楽しんできます
1-7	圈外	9.99	-14.00	道路に写し出された自分の影が、コートのせいもあってハンコックに見えるわ。わらわが美しいからじゃ！って遊びやつて仕事から帰ってる
1-8	圈外	-39.79		運行情報に関するお知らせです。16時43分現在 ■ 東京メトロ副都心線・一部列車 遅延 原因：人身事故 発生時刻：13時44分頃 発生場所：東急東横線反町駅
1-9	圈外	-49.76		unkokanto 東急東横線【平常運転】反町駅で発生した人身事故の影響で、列車に遅れが出ていますが、16:45 現在、ほぼ平常通り運転しています。(11/23 16:45) #駅の伝言板 #茨城県 運行速報
1-10	圈外	-49.86		unkokanto 東急東横線【列車遅延】13:44頃、反町駅で発生した人身事故の影響で、現在も列車に遅れが出ています。(11/23 15:45) #駅の伝言板 #東京都 運行速報

表 6: 11/23 における  $q$  を遅延としたときの観測情報ツイート

ID	rank	$Score_Q(t)$	$\hat{Score}_{Q,Q_n}(t)$	ツイート本文
2-1	1	89.93	97.35	unkokanto 東急東横線【列車遅延】13:44頃、反町駅で発生した人身事故の影響で、現在も列車に遅れが出ています。(11/23 15:45) #駅の伝言板 #東京都 運行速報
2-2	2	79.43	85.22	[関東]2013/11/23 10:00 #京王高尾線 05:45頃、京王線内で発生した人身事故の影響で、現在も一部列車に遅れや運休が出ています。
2-3	4	60.26	67.67	unkokanto 東急東横線【平常運転】反町駅で発生した人身事故の影響で、列車に遅れが出ましたが、16:45 現在、ほぼ平常通り運転しています。(11/23 16:45) #駅の伝言板 #茨城県 運行速報
2-4	12	49.94	51.33	運行情報に関するお知らせです。16時43分現在 ■ 東京メトロ副都心線・一部列車遅延原因：人身事故 発生時刻：13時44分頃 発生場所：東急東横線反町駅
2-5	89	19.94	25.67	京王線人身事故で各停しかこない。バイク間に合うかな(‘ω’) 小田急にすればよかったです(泣)
2-6	90	19.94	25.67	クソ京王線は朝の5時から人身事故なんですね
2-7	圈外	9.99	-10.00	マックのポテト。塩がまったくついてなくて味がしなかった3つとも。。まじないわー車の点検迫ってたでクレームも言い損ねたいらいら
2-8	圈外	9.99	-12.38	プラズマという物質は無い。個体や気体などと一緒に『状態』の名称だ。一般的にプラズマは気体で放電する事で生まれ、電磁波の交差でも発生する。
2-9	圈外	-9.97		まもなく上野駅から最終列車成田空港行が発車します
2-10	圈外	-68.69		京とれいん bot;阪急梅田駅 3号線から 13:52 発 快速特急・京都河原町行き(130列車)、まもなく発車いたします。停車駅は十三・淡路・桂・烏丸です。京都河原町終点には 14:35 に到着いたします。

表 7: 11/23 における  $q$  を渋滞としたときの誤抽出ツイートと未抽出ツイート

ID	rank	$Score_Q(t)$	$\hat{Score}_{Q,Q_n}(t)$	ツイート本文
3-1	12	19.99	26.15	高速道路、平日3割引き廃止検討 料金見直し <a href="http://t.co/cu5EH1eqYg">http://t.co/cu5EH1eqYg</a>
3-2	40	10	19.06	【最新ニュース】高速道路 各社 は来年春からの高速道路料金について、深夜の5割引きを3割引きに縮小するなど割引制度を見直す検討に入り、今後、国土交通省と調整を進めることにしています。
3-3	圈外	-9.97		ひやつはー！海老名で事故が発生して、25号渋滞中。さらには3車線の真ん中で救助中に1車線しか通れないとか！最悪、12時回るかもと言われてしまったよ！
3-4	圈外	10	-1.74	イオン近く南北通りは渋滞中、しかし東西、いなべから桑名方面はすいてますね。

かを表す指標である平均適合率  $AP@N$  により評価する。

$$AP@N = \frac{1}{N} \sum_{k=1}^N (P@k \times rel(k))$$

ただし、 $rel(k)$  は上位  $k$  件目のツイートが正解ツイートなら 1、正解ツイートでないなら 0 とする。

表 10 に結果を示す。クエリ  $q$  が遅延の場合、Twitter に投稿される観測情報が多いため、抽出するツイート数を増やすても適合率、平均適合率が共に高い結果が得られた。一方、クエリ  $q$  が渋滞の場合、主な観測者が運転手であるため、Twitter に投稿される観測情報が少なく、抽出するツイートの数を増やすごとに適合率が低下した。しかしこの場合でも、平均適合率は高く、少な

い観測情報ツイートが上位に抽出されていることが分かる。また、クエリ  $q$  が清水寺の場合、18日に比べ、23日では適合率、平均適合率が共に高い結果となった。これは、18日が月曜日なのにに対し、23日は紅葉のシーズンを迎えた土曜日であり、多くの観光客が、清水寺とその周辺において紅葉に関する観測情報を Twitter に投稿したためと考えられる。

このように、抽出精度はクエリ  $q$  に依存するものの、多くの観測情報が Twitter に投稿される観測対象がクエリ  $q$  である場合、高い適合率で観測情報の抽出が可能であり、投稿される観測情報が少ないクエリ  $q$  である場合でも、抽出したツイートの上位に多くの観測情報が抽出された。

表 8: 11/18 における  $q$  を清水寺としたときの観測情報ツイート

ID	rank	$Score_{Q(t)}$	$\hat{Score}_{Q,Q_n(t)}$	ツイート本文
4-1	1	19.37	28.44	京都行きたい? ライトアップされた清水寺見たい?。
4-2	2	10	19.06	清水寺行ってきやしたー?ライトアップ綺麗やた?http://t.co/9bfEYoeXO
4-3	3	10	19.06	清水寺のライトアップきてもーたがな(*j)めっちゃきれい!!!
4-4	6	10	15.98	あの清水寺でも今日はそんなに混んでなかった。やはり観光するなら平日がオススメ!
4-5	8	9.37	15.79	京都橘と藤枝東が2回戦で。全国高校サッカー選手権大会の組み合わせ抽選。
4-6	9	9.37	15.79	藤枝東 vs 京都橘って('ω')好カードすぎるだろ。一回戦で消えて欲しくないカード
4-7	10	9.37	15.79	藤枝東と京都橘楽しみすぎる
4-8	11	9.37	15.79	全国高校選手権組み合わせが決定!初戦から昨年準V京都橘 vs 藤枝東!!— ゲキサカ [講談社]http://t.co/JrZIMgggrgO@gekisaka さんから

表 9: 11/23 における  $q$  を清水寺としたときの観測情報ツイート

ID	rank	$Score_{Q(t)}$	$\hat{Score}_{Q,Q_n(t)}$	ツイート本文
5-1	1	19.31	26.26	昨日は紅葉狩りをしに京都へ行きました! 昼間の紅葉もライトアップされた紅葉も綺麗でした! http://t.co/uj7w6b64Ek
5-2	2	19.65	24.74	なにそのオシャレ RT@smokycatdeq: 清水寺から八坂神社まで、紅葉を見ながらツイートをしまくる。そういう仕事。
5-3	3	19.31	20.87	淨瑠璃寺の紅葉まっさかり@京都府木津川市 http://t.co/ECezQCXpwN
5-4	4	19.31	20.46	山科の毘沙門さん その4 #京都 #紅葉 http://t.co/Y5wJ9Lcv2V
5-5	5	19.65	19.65	@FutaH06 京都駅に売ってたよ清水寺と京都駅でほんどのお土産買えるからまとめて買うとよい
5-6	6	19.65	19.65	やっぱり清水寺の紅葉はきれい! http://t.co/DkJXWnclHT
5-7	11	19.31	19.31	@miwa0124 京都は紅葉真っ盛りです!!
5-8	21	9.65	16.79	銀閣寺! 紅葉綺麗!! http://t.co/blb07T6ozI

表 10: 評価実験結果

クエリ $q$	日時	P@10	P@30	P@50	AP@10	AP@30	AP@50
渋滞	11/16	0.60	0.45	0.40	0.67	0.59	0.51
渋滞	11/23	0.70	0.50	0.56	<b>0.93</b>	0.84	0.62
遅延	11/19	<b>0.90</b>	0.70	0.74	<b>0.99</b>	<b>0.95</b>	0.79
遅延	11/26	<b>1.00</b>	<b>1.00</b>	<b>0.98</b>	<b>1.00</b>	<b>1.00</b>	<b>0.99</b>
清水寺	11/18	0.30	0.17	0.16	0.56	0.41	0.34
清水寺	11/23	0.60	0.57	0.56	<b>0.90</b>	0.70	0.65

#### 4.まとめ

本研究では、Twitterに投稿されるツイートから、ユーザが与えたクエリと関連のある実世界観測情報を抽出するため、実世界の状況に応じて経時変化する長期的・短期的関連性という二つの側面を持つ単語間関係を、短期間に投稿されたツイート集合から逐次的に学習し、各ツイートに対し、現在の状況に応じたクエリとの関連度を算出する手法を提案した。2013年の32日間に投稿されたツイートに対し、異なるクエリを用いて提案手法を適用し、長期的関連性により、ユーザから与えられたクエリと関連する対象にまで観測対象が拡大され、クエリを含まない関連情報が抽出されること、および、短期的関連性により、観測対象に特徴的な事象が発生した際、それらの観測情報が抽出されることを確認した。加えて、異なる時間において同一のクエリを用いて提案手法を適用し、単語間関連性の更新により、現在の状況に応じた実世界観測情報が抽出されることを確認した。今後の課題として、関連度算出に用いるパラメータの適切な設定方法の検討や、より多くのクエリに対する評価実験が挙げられる。

#### [謝辞]

本研究の一部は、JSPS 科研費 26330137, 24240031 の助成を受けたものである。

#### [文献]

- [1] A. Sheth, "Citizen Sensing, Social Signals, and Enriching Human Experience," IEEE Internet Computing, Vol. 38, No. 4, pp 87-92, 2009.

[2] "Twitter," <http://twitter.com/>

[3] T. Sakaki, M. Okazaki, and Y. Matsuo, "Earthquake Shakes Twitter Users: Real-time Event Detection by Social Sensors," Proc. of Int'l Conf. on World Wide Web(WWW2010), pp. 851-860, 2010.

[4] 土屋圭, 豊田正史, 喜連川優, "マイクロブログを用いた鉄道の運行トラブル状況抽出に関する一検討", 情処学 DBS 研報, 2013-DBS-157(31), PP.1-6, 2013.

[5] K. Massoudi, M. Tsagkias, M. D. Dijke and W. Weerkamp, "Incorporating Query Expansion and Quality Indicators in Searching Microblog Posts," Advances in Information Retrieval, Springer Berlin Heidelberg, pp.362-367, 2011.

[6] 藤木紫乃, 上田高徳, 山名早人, "経時のな関連語句の変化を考慮したクエリ拡張による Twitter からの情報抽出手法", DEIM Forum, C9-5, 2013.

[7] "mecab Japanese morphological analyzer," <https://code.google.com/p/mecab/>

#### 新田直子 Naoko NITTA

1998年、大阪大学基礎工学部情報工学科卒業。2003年、同大学院博士後期課程修了。2002~2004年、日本学術振興会特別研究員。2003~2004年、コロンビア大客員研究員。現在、大阪大学大学院工学研究科講師。博(工)。メディア理解に関する研究に従事。

#### 角谷直人 Naoto SUMIYA

2012年、大阪大学工学部電子情報工学科卒業。2014年、同大学院博士前期課程修了。現在、双日(株)勤務。

#### 馬場口登 Noboru BABAGUCHI

1979年、大阪大学工学部通信工学科卒業。1981年、同大学院博士前期課程修了。1982年、愛媛大学工学部助手。大阪大学工学部助手、講師、産業科学研究所助教授を経て、現在、大学院工学研究科教授。1996~1997年、UCSD・文部省在学研究員。工博。メディア処理、プライバシー保護画像処理に関する研究に従事。電子情報通信学会フェロー。