

# 機械学習を用いたツイート解析と統計的異常検知による 通信障害検出システム

山田 尚志<sup>1,†1,a),b)</sup> 落合 桂一<sup>2,c)</sup> 横井 靖弘<sup>2,d)</sup> 神山 剛<sup>2,e)</sup> 鳥居 大祐<sup>2,†2,f)</sup>

受付日 2019年9月13日, 採録日 2020年2月14日

**概要:** 移動体通信網は生活インフラとして欠かせないものとなっており, 通信サービスの安定供給が求められている. 一方, Twitter などの SNS ではユーザが感知した実世界の状況がリアルタイムに共有されるため, SNS への投稿を解析することで実世界で発生する事象を把握できる. 本稿では, 機械学習による通信障害に関する投稿の分類と, 投稿数の時系列データに対する異常検知により通信障害を検出するシステムを提案し, 提案システムを実際の通信障害事例により評価した.

**キーワード:** 機械学習, SVM, 異常検知, 自然言語処理, テキスト解析

## Network Failure Detection System based on Tweet Analysis Using Machine Learning and Statistical Anomaly Detection

HISASHI YAMADA<sup>1,†1,a),b)</sup> KEIICHI OCHIAI<sup>2,c)</sup> YASUHIRO YOKOI<sup>2,d)</sup> TAKESHI KAMIYAMA<sup>2,e)</sup>  
DAISUKE TORII<sup>2,†2,f)</sup>

Received: September 13, 2019, Accepted: February 14, 2020

**Abstract:** Mobile communication networks are indispensable as a life infrastructure, and a stable supply of network services is required. On the other hand, in the SNS such as Twitter, the real-world situation sensed by the user is shared in real time. Therefore, it is possible to grasp the events that occur in the real world by analyzing posts to SNS. In this paper, we propose a system for detecting network failures by classifying posts related to network failures by machine learning and detecting anomalies in the time series of the number of posts. Furthermore, the proposed system was evaluated by actual network failure cases.

**Keywords:** machine learning, SVM, anomaly detection, natural language processing, text analysis

### 1. はじめに

総務省の通信利用動向調査によると 2017 年における日本のモバイル端末保有率は 84% [1] を超えており, 移動体通信網は生活インフラとして欠かせないものとなっている. そのため, 移動体通信事業者にとって通信状況を把握することは, 安定した通信サービスを提供するうえで重要なファクターである. 通常, 通信状態はトラフィックやシステムログを利用して常時監視されている. しかし, システムログやトラフィックは膨大であるため, 解析に時間を要し, 通信障害を即座に発見することは難しい [2]. 電気通信事業法 [3], [4] ではサービスの停止や品質の低下について, 「影響人数が 3 万人以上で, 継続時間が 2 時間以上」に及ん

<sup>1</sup> ドコモ・テクノロジー株式会社  
DOCOMO Technology, Inc., Minato, Tokyo 107-0052, Japan

<sup>2</sup> 株式会社 NTT ドコモ  
NTT DOCOMO, INC., Chiyoda, Tokyo 100-6150, Japan

<sup>†1</sup> 現在, ソフトバンク株式会社  
Presently with SoftBank, Corporation

<sup>†2</sup> 現在, 株式会社みらい翻訳  
Presently with Mirai Translate, Inc.

a) yamadahisa@nttdocomo.com

b) hisashi.yamada04@g.softbank.co.jp

c) ochiaike@nttdocomo.com

d) yokoiy@nttdocomo.com

e) kamiyamata@nttdocomo.com

f) toriid@nttdocomo.com

だ場合などを「重大な事故」と定義している。本稿では影響規模は電気通信事業法の重大な事故にのっとり、障害内容については音声通話、パケット通信、メール送受信などの通信サービスが利用できない状態を通信障害として定義する。通信障害の早期検出をロバストにするためには、既存の監視に加え、新たな情報源を増やすことが必要となる。

一方で、モバイルサービスを利用するユーザは、ユーザが感じるサービス状況や現状発生している問題について、リアルタイムにソーシャル・ネットワーキング・サービス(SNS)に書き込む傾向がある。そのため、SNSへの投稿を解析することで早期の通信障害検出ができるものと考えられる。

このような特性を活かしてネットワーク外部からの情報としてTwitterを利用して、ネットワークの制御や通信障害の検出手法が提案されているが、長期でのオンライン評価がなされていない[5], [6], [7], [8]。

本研究では、通信障害発生時にユーザから投稿されたツイートから特徴抽出を行い、機械学習モデルを用いて通信障害に関するツイートの分類と、投稿数の時系列データに対する異常検知により通信障害を検出するシステムを提案する。また、実際の障害事例中に投稿されたツイートを利用しオフライン・オンライン評価の実施、および、機械学習を利用したツイートの分類をシステムに適用した場合の精度について評価を実施する。

本稿における貢献は以下の3つである。

- (1) 通信障害に関するツイートならではの特微量から機械学習モデルを生成することで、通信障害に関するツイートを高精度で分類し、通信障害の検出適合度を向上できることを示した。
- (2) 提案システムの運用・評価を行い、システムによる平均障害検出時間を明らかにした。また、提案システムの活用フィールドについても検討した。
- (3) オフライン評価にて、影響ユーザ数や時間帯と検出可能性の評価を実施した。

本稿の構成は以下のとおりである。2章で関連研究について述べ、3章で提案システムについての概要を説明し、4章でツイート分類に関する評価、オフライン・オンライン評価結果を説明し、最後に、5章で本稿をまとめる。

## 2. 関連研究

Twitterなどマイクロブログを対象として急増している特定ワードから、現在話題となっている時事を発見する手法が確立され[9]、リアルタイム検索などの検索サービスとして提供がされている。また、自然言語処理を利用して、消費者の感情検出や地理情報の抽出といった研究もさかんである[10]。

応用としてTwitterを使ってネットワークの通信品質低下を検知する試みも行われており、池田らが投稿数の遷移

や、否定語に共起する語の一貫性を用いて、通信品質の低下傾向を早期に発見、サービス運用者にアラートをあげる手法を提案している[6]。しかし、単純なキーワードのみでのマッチングをしているため、ネットワーク障害に関するツイート以外(たとえば、「A社のコールセンターに繋がらない」、「B社の端末が遅い」など)も検索にて拾ってしまう可能性がある。

丸ら[7]は、SNSの解析結果を用いて通信障害を検知し、ネットワーク制御を自動的・自立的に行う手法を提案した。通信障害を検知するという点で本研究と類似しているが、ネットワークの制御という点に焦点を当てているため、Twitterを使った障害検知の評価という点に重点を置いている本研究とは異なる。丸らの研究[7]では、ツイート抽出を行う際に、「電話」といったキーワードと障害表現候補である「つながらない、通じない、使えない」といった単語間の文字列距離を元に抽出処理を行っている。しかし、この手法では、障害に関連しないツイートも取得してしまう可能性がある。たとえば、屋内など電波状況が悪い場所で電話がつながらないといったツイートが対象となりうる。そのため、本研究の手法では、障害に関するツイートを取得した後、機械学習によって障害に言及したツイートかどうかを判定を行い、障害に言及したツイートのみを通信障害の判定に利用することで非障害ツイートによる誤検知の防止を図った。また、丸らの障害判定は、通信障害のツイートの割合、震度、ツイート数の増加率を元に障害を判定していると記載しているが、どのようなツイート増加率、割合かを明記していない。本手法では、ポアソン分布を仮定した統計モデルを障害判定に用いるとともにその利用パラメータを明らかにしている点で違いがある。

Takeshitaら[8]は、ネットワークの故障状況を把握するために、Twitter上に投稿されたネットワーク問題に言及したツイートを利用している点で本研究と動機が似ている。しかし、システムが実用可能な性能かどうかの評価までは実施されていない。

同様にOkiら[11]も、複数のTwitterなどのSNSからモバイルネットワークサービスの障害検出を予測する手法を提案したが、検出時間が60分と長く、障害規模に準じた評価がなされていない。

そこで本研究では、通信障害について言及したツイート数の時系列データに対して確率的に異常を検出するシステムを運用・評価を行い、システムの実用可能性と活用フィールドについて検討を行った。また、SVMを通信障害に関するツイートの分類という新しい領域に適用し、精度評価とシステムへの組み込みも行った。

## 3. 提案システム

本章では、図1に通信障害に関するツイートを取得し、通信障害を検知する流れを示す。以降、通信障害に関する

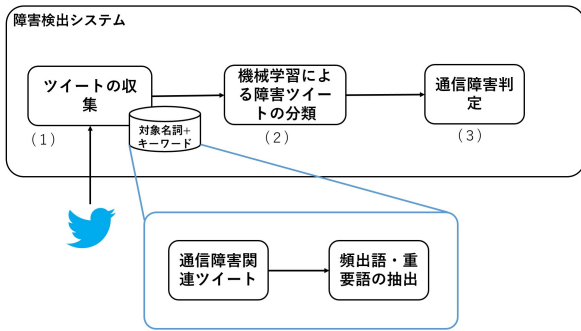


図 1 システム概要図  
Fig. 1 System overview.

ツイートを障害ツイート，通信障害を検知するシステムを障害検出システムと定義する。

図中の (1)~(3) は以下のとおりである。

- (1) 通信障害の話題に関して重要度が高い，もしくは頻出度が高い語を決定し，そのキーワードを含むツイートを取得する (3.1 節)。
- (2) (1) で取得したツイートに対して，通信障害とは無関係なツイートを分類するために，機械学習を利用してツイートの分類を行う (3.2 節)。
- (3) (2) で分類された通信障害に関係のあるツイートの投稿数の時系列データに対して統計的な処理を行い，定常時とは異なる状態にあるかどうかを確率値として算出する。得られた確率値を元に通信障害が発生しているかどうかを判定する (3.3 節)。

### 3.1 ツイートの収集

障害ツイートの抽出は，それを提供している通信事業者や提供されるサービスの内容に依存してツイート投稿時に使用される動詞や形容詞の特徴的表現が変わる。そのため，汎用的な辞書を用いての検索ではツイートの取得漏れや意図しないツイートが取得される可能性があり，検出したい通信事業者やサービス名に特化した否定表現や肯定表現辞書の作成が必要である。ここで，肯定・否定とは，一般的に良い印象を持つか(肯定) 悪い印象を持つか(否定)を表した属性である。たとえば，「良い」，「美しい」などを含む文は肯定的，「悪い」，「汚い」などは否定的な意味を持つ。

否定・肯定表現の辞書を構築する際，文献 [6] の手法では，通信会社や通信サービスの名称を使ってツイートを取得し，取得したツイートから否定的な表現を AIC [12] を用いて抽出している。また丸ら [7] はブートストラップ法を用いて障害表現を抽出している。しかし，従来の手法では通信障害に関連しない否定表現・障害表現を抽出してしまう可能性がある。そのため，本研究では実際に障害発生当日のツイートから否定的・肯定的な特徴的な表現を抽出し，TF-IDF を用いて重要度の高い表現を辞書として利

表 1 障害ツイート抽出単語例

Table 1 Examples of words for extract tweets about the network failure.

極性	ツイート抽出ワード
否定	つながら/つながりませ/送れな/送信できな/送信できん/通信障害
肯定	つながる/つながる/送れる/送れた/送れました/送信できる

- ・ A 社、通信障害かな？携帯回線側でのネット接続、つながらないや
- ・ A 社の 4G が繋がらない
- ・ A 社繋がらない！通信障害？
- ・ A 社全然繋がらなくなった。シャーなしに自宅の Wi-Fi 繋いだけど
- ・ A 社繋がらなくない？障害でてる？
- ・ おい A 社の 4g つながらないぞどうなってんだ
- ・ A 社の iPhone インターネット繋がらない

図 2 障害ツイート例

Fig. 2 An example of tweets about the network failure.

用した。

特定の通信・サービスに関する肯定・否定表現辞書の構築は，以下の流れで行っている。

- (1) 通信事業者やサービス名称で障害が発生した特定日時のツイートを検索，収集を行う。
- (2) 収集したツイートから肯定・否定の表現を含むツイートを抽出する。特に通信障害では，通信障害中，通信回復時にそれぞれ否定的，肯定的な特徴のある単語が抽出できる。たとえば，否定的であれば「つながらな(い)」，「通信障害」など。抽出にあたっては，TF 値や TF-IDF 値などが利用できる。

通信障害時と復旧時のそれぞれに分けて，取得した単語から構築した辞書の例を表 1 に示す。ツイートを取得する際は，ツイート抽出対象の名詞(通信事業者名)とツイート抽出ワードにて抽出を行う。抽出したツイートの例を図 2 に示す。以降，通信事業者名とツイート抽出ワードを合わせて検索キーワードと呼ぶ。

### 3.2 機械学習による障害ツイートの分類

本節では，検索キーワードで取得したツイートに対して，通信障害に関連のあるツイートかどうかを分類する手法について記載する。ここで，通信障害に関連のあるツイートとは，ユーザが通信事業者が提供している通信サービスそのものに関してコメントしたものと定義する。本処理は，検索キーワードで取得したツイートで，通信サービスについて言及していないツイートを解析対象から除外するためである。たとえば，「A 社のコールセンターに繋がらない」といったツイートが該当する。丸ら [7] は，ツイートが該当のロケーションを指したものかどうかの判定に機械学習を利用しているが，本研究では，障害ツイートかどうかの判定のために機械学習を利用している。

アプローチとしては，障害発生時に投稿されたツイート

を取得し、得られたツイートの集合を元にそれらが通信障害そのものを言及したツイートかを教師あり学習で構築した機械学習器を用いて判定する。学習にあたっては、通信障害発生時のツイートと平常時のツイートに人手で、教師ラベルを付け学習を行った。本方式では、ツイートに登場する言葉の多次元空間を構成し、障害ツイートかどうかを多次元空間上で線形分離する。線形分離とは、二次元平面上に2つの点の集合が存在する場合に、1つの直線で分離できることをいう。線形分離の機械学習としてSVM[13]が代表的である。本システムでは投稿ツイートをリアルタイムに障害に言及したツイートかどうかを判定したいため、計算コストが少なく、処理が速い線形モデルを採用した。

機械学習器は、機械学習ライブラリ LIBLINEAR [14] を用いた。LIBLINEAR は線形予測に特化した SVM ライブラリで、LIBSVM [15] などの同等の線形予測ツールと比較して処理にかかるコストが小さい。LIBLINEAR については、文献 [14] を参照されたい。なお、分類精度は、丸ら [7] の適合率 (86%)、再現率 (98%) を目標値とした。また、TwitterAPI では、秒間 1,000 件程度の日本語ツイートが取得できるため、秒間 1,000 件以上のツイートを分類することをサービス要件とした。

### 3.2.1 素性の作成

学習のための素性として、通信障害発生時のツイートならではの特徴を利用して作成する。素性作成において、形態素解析器で出力される形態素の unigram と bigram を利用しており、形態素解析器には JTAG [16] を利用した。

素性を作成する際、入力文章に対してまず形態素解析を行い、用言かどうかの判定を行う。用言かどうかは、JTAG の解析結果で表記の次の要素に値があるかどうかで判定する。また形態素解析で利用する辞書は形態素解析器標準の辞書とユーザが作成した辞書の2通りを利用する。これは、場所を特定するための地名や通信事業者名を意図した形で出力を行うためである。通信事業者名は揺らぎもあるため、揺らぎを含めて統一表記に置換を行う。同様に指定した体言や用言についても表記ゆれの正規化を行う。形態素解析した単語が用言である場合、単語の表記そのままではなく、語幹を利用し、それ以外については表記を利用する。これは、用言に特徴があり、その特徴を学習に利用したいためである。また指定した体言や用言の後ろに否定・過去・疑問の付属語が存在する場合、その情報を付加して素性とする。bigram 素性を作成する際は、名詞などの自立語のみの bigram とすべての品詞の bigram の2通りの素性を作成している。たとえば、「つながらない」を JTAG で形態素解析をすると『つながら-つながる-動詞語幹-ツナガラ-つながらない-動詞接尾辞:終止-ナイ-ない』と出力され、上記形態素解析結果の前から3つ目が語幹である。unigram 素性作成の際は、1文字の付属語(助詞など)は除外する。

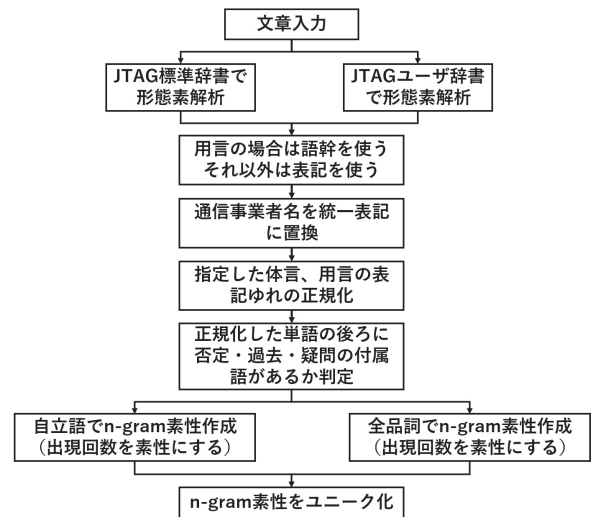


図 3 素性作成フロー

Fig. 3 A flow for creating features.

素性作成の流れを図 3 に示す。本システムでは、上記素性から作成したモデルをシステム内部にて保持している。入力されたツイートを分類するためには、入力ツイートを素性と同様の形式に変換することが必要である。そのため、入力ツイートを受け付けた際に、システム内で素性と同一のような形式に変換したうえで LIBLINEAR を動作させる。LIBLINEAR の出力は、障害ツイートにもっともらしいかを 0 から 1 のスコアで返却される。障害ツイートシステムは、返却された値に応じてツイートを障害判定に利用するかどうかを判定する。LIBLINEAR は、作成したモデルから 0 の群と 1 の群の判別を十分説明し得るような線形式を解き、スコアを算出する。

### 3.3 統計モデルによる異常検出

提案システムで障害検出を行うために、直前のツイート数遷移から急増を抽出する急増投稿検出手法 [6] を利用する。池田ら [6] は、急増投稿検出手法と前日、前々日の複数日の同一時間帯と比較して異常を検出する漸増投稿検出手法の二手法の組合せにより評価をしているが、本システムでは、ポアソン分布に従わない異常傾向のみを抽出する急増投稿検出手法のみをシステムで利用した。本システムにおける急増投稿検出手法では、現在時刻スロット  $t$  におけるツイート投稿数  $x$  と、 $t$  から過去  $L$  スロットの重み  $w$  を用いた重み付き平均ツイート数  $\lambda$  を用いて、ポアソン値  $p$  を式 (1) に定義する。算出したポアソン値  $p$  が閾値以下の場合、通信障害として判定する。ポアソン値計算の処理の流れは以下となる。

- (1) スロット幅ごとに障害ツイートを取得し、そのツイート総数を得る。
- (2) 現在の1つ前のスロットから過去  $L$  スロットに対して、重み付き平均ツイートを計算する。




図 4  $\tau$  値と重み付き平均の関係

Fig. 4 A relationship of weighted average and  $\tau$  value.

(3) 式 (1) を用いてポアソン値  $p$  を算出する.

$$w_i = e^{-\tau i}$$

$$\lambda = \frac{\sum_{i=1}^L w_i x_{t-i}}{\sum_{i=1}^L w_i}$$

$$p = 1 - \sum_{k=0}^{x-1} e^{-\lambda} \frac{\lambda^k}{k!} \quad (1)$$

ポアソン分布を利用した急増投稿検出手法は、ポアソン値算出の入力値であるツイート数に敏感になる傾向があるため、パラメータのチューニングが必要である。そのため、本システムでは、投稿ツイート数が1件または、重み付き平均  $\lambda$  が1以下であった場合は、ポアソン値は一律1と扱うようにした。

### 3.3.1 ポアソン値計算におけるパラメータ

本項では、システムにて通信障害を判定するための各種パラメータについて説明する。(1)で定義した式において、 $\tau$  値、ツイート取得のスロット幅、重み付き平均を算出するスロット数  $L$  により、検出の時間や精度は変わる。 $\tau$  値はポアソン値算出にあたっての重み付き平均算出時に利用しており、 $\tau$  値が大きいほど直近のスロットに重みが置かれる仕組みとなる。図4は、各  $\tau$  値におけるスロットと重み付き平均の関係をグラフ化したものである。 $x$  軸は単位時間に発生する事象の回数、 $y$  軸は生起確率である。

$\tau$  値が大きいほど直近のスロットに重みがかかるため、早く検知ができるが、意図しない急なツイート投稿数の増加があった場合、それにもなう誤検知が発生する可能性がある。本システムでは、通信障害を即座に把握することに重みを置いているため、 $\tau$  値は現在時間から直近30~40分ほど前に重みがかかる0.25とした。 $L$  はポアソン値を計算する際に現在時刻  $t$  から過去何時間分のスロットを用いるかを表した値である。時間帯によってツイート数が変化し検出精度に影響があるため、複数の設定で検証し本システムでは経験的に  $L$  は6時間分(36スロット)を利用した。

次にスロットの幅であるが、スロット幅を広くとること

でスロットあたりのツイート数が多くなるため、障害検出のリコール数を高めることに貢献すると思われるが、スロット幅を大きくすると障害検出時間が伸びてしまうため、本システムではスロット幅を10分とした。

## 4. 評価

### 4.1 障害ツイートの分類性能の評価

障害ツイートの分類精度をいくつかの観点で評価を行う。評価にあたって、通信障害のツイート分類については、学習データは3万件とした。

#### 4.1.1 分類性能

障害ツイートを分類する分類器として、LIBLINEAR と LIBSVM の性能評価を行った。LIBLINEAR では、線形カーネル、ロジスティック回帰を、LIBSVM では多項式カーネル、RBFカーネルを対象としている。また、特徴量は bigram, trigram, 4gram でそれぞれ比較をしている。図5に結果を示す。

LIBLINEAR では、線形カーネル、ロジスティック回帰とともに同程度の Accuracy が得られ、LIBSVM よりも良い結果となった。また、LIBSVM では多項式カーネル、RBFカーネルを用いても Accuracy の向上はみられなかった。障害ツイートを分類するうえで分類器は LIBLINEAR、モデルタイプとして線形 SVM を利用するのが最も良いと考えられる。

図6は、線形 SVM とロジスティック回帰の Precision, Recall について評価したグラフである。本評価では、障害ツイートと非障害ツイートを対象にしている。

線形 SVM, ロジスティック回帰ともに Precision : 86~87%, Recall : 85~86% とほぼ同程度であった。bigram から 4gram と  $n$  を上げるに連れ、Precision は若干向上する傾向が見られたが、Recall は低下した。

#### 4.1.2 処理速度

速度評価において利用したマシンスペックは、表2のとおりである。

計測方法として、テストデータ1万件を用意し、そのテストデータの障害ツイート分類にかかる時間の計測を行った。

計測の結果、テストデータ1万件すべての分類にかかる処理時間は4.7秒であり、秒間2,128件のツイートを分類することが可能である。この検証により、サービス要件としていた秒間1,000件以上のツイートの分類を満足できることを示した。

### 4.2 異常検出の評価

本節では、通信障害検出について、オフライン、オンラインで評価を行った結果について記載する。

#### 4.2.1 オフライン評価

システムを構築する前に机上での評価を実施した。表3

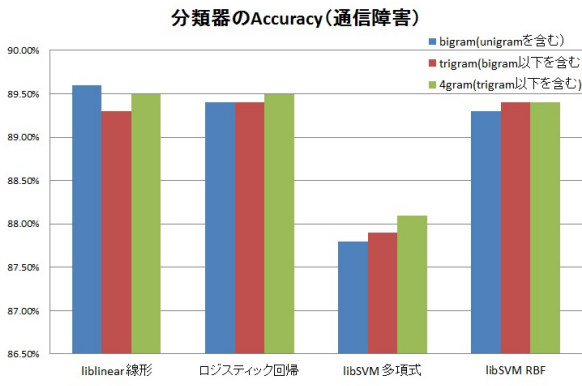


図 5 分類器の性能

Fig. 5 Performance of classifier.

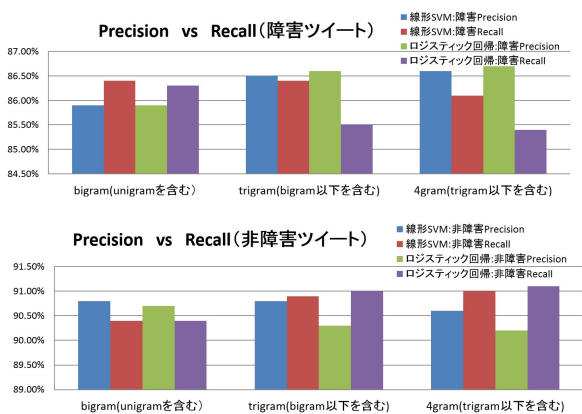


図 6 Precision, Recall (線形 SVM, ロジスティック回帰)

Fig. 6 Precision vs. Recall (Linier SVM, Logistic regression).

表 2 開発環境

Table 2 Development environment.

CPU タイプ	Intel Xeon
CPU 速度	1.60 GHz
メモリ	32 GB
OS	Windows7 Professional 64 bit

は、その結果である。

表中の障害検出時間は、3.3 節の急増投稿検出手法を用いて通信障害として判定された日時である。障害検出時間は通信事業者が公表している障害発生日時と急増投稿検出手法によって通信障害が検知された時間差を表している。

影響ユーザ数 10 万人以下では、平均検出時間 11,040 秒、10~100 万人では平均検出時間 2,172 秒、100 万人以上の場合だと平均検出時間は 305 秒という結果であった。また、検出率は 95.8%であった。影響ユーザ数が数十万人以上の大規模な通信障害（音声・データ通信）は、ユーザの反応も早くほぼリアルタイムに通信障害を検知できることが分かった。一方で、影響ユーザ数が数万人程度の中・小規模の障害では障害発生箇所が局所的であったり、利用ユーザ自体が少なく、ツイートへの投稿そのものが少ない状況で




図 7 ツイート数と影響ユーザ数の相関関係

Fig. 7 A correlation between tweet numbers and users influenced.

あったため、検知が遅れる、また検出できない状況であった。そのため、Twitter を使ったの障害検出は大規模な通信障害においてのみ効果があると考えられる。

一方で、障害検出時間が負の値になっている場合は、「通信障害と無関係な誤検知」の可能性と「通信障害の発生予兆として検知した」可能性が考えられる。

オフライン評価の中では、検知時のツイート内容を目視にて確認したので、通信事業者名と否定的な語を含む障害とは無関係なツイートによる誤検知は見受けられなかった。システムとしては、機械学習により通信障害と無関係なツイートを 80%以上の精度でフィルタリングできているため、「通信障害と無関係な誤検知」が発生する可能性は少ないと思われる。しかし、必ずしも発生しないとは言えないため、通信障害に関連するツイートのみを正確にフィルタリングできるように機械学習の精度を高めていくことが必要である。

電気通信事業法では「影響人数 3 万以上で継続 2 時間以上」を重大事故として定義しているため、表の負の値の場合は通信障害の予兆として通信システムの動作が不安定になり、一部のユーザに影響があったと考えられる。このように電気通信事業法で定められる重大事故前に障害予兆を把握できることは、通信事業者側における措置の迅速化・被害の拡大防止に貢献があると考えられる。

また、障害時間帯のツイート投稿総数から影響ユーザ数の推定ができるかの相関についても調査を行った。図 7 は、相関図である。ツイート総数と影響ユーザ数の相関係数は 0.63 と中程度の相関で、ツイート数は、影響ユーザ数だけでなく障害が発生した日の平日・休日、場所、時間にも依存すると思われる。事例の収集により今後詳細な分析が可能になるとと思われる。

#### 4.2.2 オンライン評価

本節では、2014 年 6 月から 2015 年 2 月の間で、構築し

表 3 オフライン評価結果  
Table 3 A result of offline evaluation.

通信事業者	発生日時	影響ユーザ数	影響サービス	影響地域	障害検知日時	障害検出時間 [秒]
A 社	2011/5/25 3:38~10:15	7 万 2700 人	音声&データ通信	関西	2011/5/25 7:40	14,520
	2013/5/6 13:01~14:59	非公開	データ通信	西日本	2013/5/6 13:01	1,740
	2013/7/26 13:33~15:31	非公開	音声	鹿児島県の一部	2013/7/26 18:30	18,000
	2013/9/4 13:41~17:57	非公開	音声	福井県の一部	2013/9/4 17:30	13,740
	2013/10/7 17:6~19:30	非公開	音声	鹿児島県の一部	2013/10/7 19:00	6,840
	2013/11/8 13:15~16:35	非公開	音声	沖縄県の一部	2013/11/8 17:30	15,300
	2014/1/9 14:00~15:37	非公開	音声	全国	2014/1/9 14:10	600
	2014/11/16 14:00~ 2014/11/17 5:56	非公開	メール送受信	非公開	2014/11/16 16:00	22,980
B 社	2011/8/16 11:29~18:29	110 万人	データ通信	全国	2011/8/16 11:40	660
	2011/12/20 12:22~14:25	12 万人	メール送受信	関西	2011/12/20 12:20	-120
	2012/1/1 21:30~22:35	260 万人	メール送受信	全国	2012/11/1 21:30	0
	2012/1/25 8:26~13:8	252 万人	音声&データ通信	東京	2012/1/25 8:50	1,440
	2012/2/7 14:01~14:40	83 万人	音声&データ通信	関西	2012/2/7 14:10	540
	2012/8/2 18:15~19:42	145 万人	音声&データ通信	関東甲信越 ・東海・関西	2012/8/2 18:30	900
	2012/8/13 18:24~ 2012/8/14 2:13	8 万人	国際ローミング	220 の国と地域	2012/8/13 20:30	7,560
	2012/11/14 18:01~19:43	191 万人	データ通信	全国	2014/11/14 18:10	540
C 社	2011/4/30 6:36~14:57	91 万人	データ通信	全国	2011/4/30 7:40	3,840
	2011/2/11 02:10~09:44	110 万人	メール送受信	埼玉・東京・岩手	検知出来ず	-
	2012/2/9 16:11~17:17	130 万人	データ通信	全国	2012/2/9 16:20	540
	2012/2/11 20:35~23:59	615 万人	メール送受信	全国	2012/2/11 20:20	-900
	2012/12/31 00:35~04:23	180 万人	データ通信	全国	2012/12/31 00:00	0
	2013/1/2 00:17~02:10	175 万人	データ通信	全国	2013/1/2 00:10	-420
	2013/4/16 08:08~13:29	288 万人	メール送受信	全国	2013/4/16 08:00	-480
	2013/5/30 13:04~23:50	64 万人	音声	東京都, 神奈川県, 山梨県の一部	2013/5/30 12:40	-14,400

た障害検出システムにて検出した事例について分析を行う。構築した障害検出システムは以下の機能を具備しており、システムのユーザ表示画面を図 8 に示す。

- (1) 通信障害をポアソン値の閾値により自動抽出
- (2) 抽出した通信障害をメールにて通知
- (3) 地図表示, グラフ表示, ツイート閲覧
- (4) ツイートを抽出する任意キーワードの追加

運用期間中に障害検出システムで検知できた障害は、9 件中 5 件でオフライン評価結果のとおり、いずれも比較的大きな通信障害であり、平均検出時間は 7,848 秒であった。また、検出キーワードによる障害ツイートの検出度合いは、43%程度で、残り 57%はユーザ独特の造語であったり、「おかしい」など意味が一律でないワードが多かった。図 9 は、2014 年 10 月 20 日に発生した通信障害に関するツイート数の推移である。

本事例では障害発生の検出はできたが、公式発表よりも遅い検出であった。しかし、障害発生時に障害発生と分かる数少ない有益なツイートと障害発生初期に障害状況が分かる数少ない有益なツイートも存在していた。図 10 に障

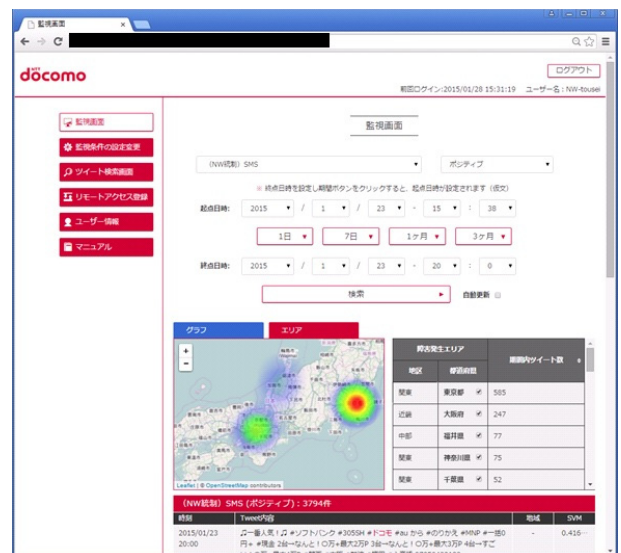


図 8 障害検知システムユーザ表示画面  
Fig. 8 A screen of the network failure detection system.

害発生初期に障害が分かるツイートの例を、図 11 に障害状況が分かるツイートの例を示す。

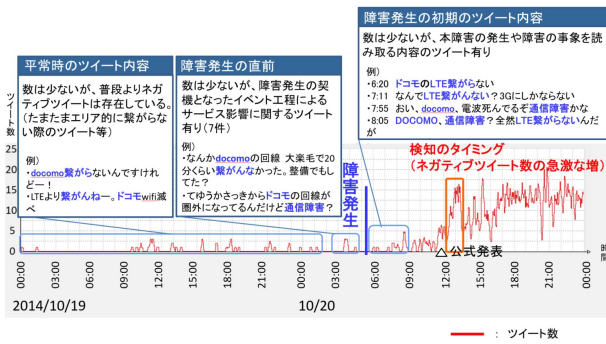


図 9 ツイートの推移

Fig. 9 Changes in tweet numbers.

- ・ 6:00: B 社通信障害だったのかよ… (省略)
- ・ 6:20: B 社の LTE 繋がらない

図 10 障害発生初期のツイート例

Fig. 10 Examples of tweets of early in the network failure.

- ・ 7:11: なんで LTE 繋がらないの？ 3G にしかならない、(省略)
- ・ 7:30: iPad mini の電波、今朝から圏外と 3G を行ったり来たり。

図 11 障害状況が分かるツイート例

Fig. 11 Examples of tweets representing the status of the network failure.

このようなツイートを的確に抽出し、システムで通信障害と判定できれば、よりリアルタイムに障害発生を検知できるとともに、ツイート内容から措置の迅速化・的確化につながれると考えられる。

#### 4.2.3 SVM 適用に関する評価

池田らの既存手法は図 1 の機能では (1) と (3) に該当し、提案手法では (2) で SVM による判定を入れているところが違いである。SVM の閾値 0.0 が池田らの手法に該当するため、閾値 0.0 (既存手法) と閾値を上げた場合で精度比較を行う。精度比較では通信事業者が公表している 8 件の通信障害が発生した日時的前後 1 週間分のツイートを対象とした。

SVM の適用による適合率と再現率は表 4 となる。通信障害の検出成功数については、ベースライン手法、SVM を適用した手法ともに 6 件の通信障害を検出したため、再現率は 75% であった。ベースライン手法では、誤検出数が 37 件 (適合率 14%) と多数の誤検出が発生する傾向が見られた。SVM を適用した手法では、閾値の値によるが閾値 0.3 では適合率 30% とベースライン手法よりも 16% 高い性能であった。SVM 閾値を高くすれば非障害ツイートによる検出誤り数を減らすことができるが、これまで障害ツイートとして検出できていたツイートも非障害ツイートとして判定され検出成功数が低下する可能性があるため、本システムでは SVM 閾値を 0.3 に留めた。

SVM を利用して障害ツイートかどうかを分類することで誤検出の起因となるツイートを除去でき、検出成功数を

表 4 SVM の適用による適合率/再現率

Table 4 Precision/Recall when SVM is applied.

SVM 閾値	0.0	0.1	0.2	0.3
通信障害数	8 件	8 件	8 件	8 件
検出成功数	6 件	6 件	6 件	6 件
検出誤り数	37 件	31 件	19 件	14 件
適合率 [%]	14 (6/43)	16 (6/37)	24 (6/25)	30 (6/20)
再現率 [%]	75 (6/8)	75 (6/8)	75 (6/8)	75 (6/8)

下げることなく適合率を高めることに効果があることが分かった。より障害ツイートシステムの検知精度を上げるためには、SVM を利用することは効果的である。

一方で、障害に関する内容のツイートが除外されていることも散見されたため、事例を集めモデルを更新することで機械学習の精度向上を行い、有用なツイートを的確に検出することが今後の課題となる。

#### 4.3 考察

これまでの Twitter の投稿内容を解析し、統計的な異常検知を用いた手法は、通信障害を高い確率で検出できることが確認できた。しかし、一方で既存手法では誤検出も多く見られた。

本研究では、電気通信事業者が定める重大事故に対して、提案した手法のシステムを適用した場合、検出成功数の改善は見られなかったが、誤検出数の低下に効果があり、16% の改善効果があった。

#### 5. おわりに

本稿では、障害検出システムにおいて、SVM による機械学習により通信障害に関連するツイートかどうかを自動で分類し、そのツイートを利用して通信障害を検出するシステムについて述べた。

また、障害検出システムを運用し、評価を実施した。その結果、当初の狙いと異なり、ツイート数の増加傾向からの障害検出はサイレント故障などの通信障害での早期検知はあまり効果が見込めないことが分かった。ただし、音声が使えないがデータ通信は使える、といったサービス影響のパターンによっては、お客様申告よりも早期に通信障害を検出できる可能性もある。また数は少ないが「通信障害発生に早期に気づくことができる」、「通信障害発生初期に、通信障害状況を把握できる」ツイートが存在するため、これらのツイートをリアルタイムに把握できれば、ツイートによる通信障害検出の有効性は上がると思われる。

今後は、通信障害発生当初に発生する数少ない通信障害発生を読みとれるツイートをリアルタイムに把握し、通信障害発生に早期に気づく手法の確立を目指す。この実現により、ツイート数の増加傾向によらず、通信障害を検出できるだけでなく、サイレント故障時の詳細な発生状況を



リアルタイムに把握することができると考えられる。また、今回は通信事業者の立場で通信障害を検出することを前提とした評価を行ったが、通信事業者以外の第3者が本システムを介して通信状況を一般に公開されることで、通信障害時に発生する輻輳の軽減とユーザの不満足低下につながると思われる。このような観点での評価も今後検討したい。

参考文献

[1] 総務省：通信利用動向調査 (2018), 総務省 (オンライン), 入手先 [http://www.soumu.go.jp/johotsusintokei/statistics/data/180525\\_1.pdf](http://www.soumu.go.jp/johotsusintokei/statistics/data/180525_1.pdf) (参照 2019-04-18).

[2] 大和田英成, Sandeep, K., Ahmed, A., Glenn, M., 白鳥則郎：高速ネットワークの監視, 電子情報通信学会技術研究報告, IN, 情報ネットワーク, Vol.100, No.299, pp.61-66 (オンライン) (2000), 入手先 <https://ci.nii.ac.jp/naid/110003196573/>.

[3] 総務省：電気通信事業法, 総務省 (オンライン), 入手先 [https://elaws.e-gov.go.jp/search/elawsSearch/elaws\\_search/lsg0500/detail?lawId=359AC0000000086](https://elaws.e-gov.go.jp/search/elawsSearch/elaws_search/lsg0500/detail?lawId=359AC0000000086) (参照 2019-12-17).

[4] 総務省：電気通信事業法施行規則, 総務省 (オンライン), 入手先 [https://elaws.e-gov.go.jp/search/elawsSearch/elaws\\_search/lsg0500/detail?lawId=360M50001000025](https://elaws.e-gov.go.jp/search/elawsSearch/elaws_search/lsg0500/detail?lawId=360M50001000025) (参照 2019-12-17).

[5] 神野裕宣, 寒河江佑太, ベンジャブールアナス, 古谷雅典, 萩原淳一郎：トラヒック情報を用いた無線基地局装置のサイレント故障検出に関する一考察, 電子情報通信学会技術研究報告, ICM, 情報通信マネジメント：IEICE Technical Report, Vol.110, No.466, pp.1-6 (オンライン) (2011), 入手先 <https://ci.nii.ac.jp/naid/110008688651/>.

[6] 池田和史, 服部 元, 小野智弘, 麻生英樹：D-012 Twitter 解析による通信品質低下傾向の早期検出手法の提案 (マイクロブログ, D分野：データベース), 情報科学技術フォーラム講演論文集, Vol.11, No.2, pp.101-102 (オンライン) (2012), 入手先 <https://ci.nii.ac.jp/naid/110009622514/>.

[7] 丸 千尋, 榎 美紀, 中尾彰宏, 山本 周, 山口実靖, 小口正人：大規模災害時における SNS による集合知に基づいたネットワークの QoE 制御, マルチメディア, 分散協調とモバイルシンポジウム 2016 論文集, No.2016, pp.1418-1426 (オンライン) (2016), 入手先 <https://ci.nii.ac.jp/naid/170000174181/>.

[8] Takeshita, K., Yokota, M. and Nishimatsu, K.: Early Network Failure Detection System by Analyzing Twitter Data, *2015 IFIP/IEEE International Symposium on Integrated Network Management (IM)*, pp.279-286, IEEE (2015).

[9] Kleinberg, J.: Bursty and Hierarchical Structure in Streams, *Data Min. Knowl. Discov.*, Vol.7, No.4, pp.373-397 (online), DOI: 10.1023/A:1024940629314 (2003).

[10] Qi, W., Guo, W., Procter, R. and Zhang, J.: Geo-Tagging Quality-of-Experience Self-Reporting on Twitter to Mobile Network Outage Events, *IEEE International Smart Cities Conference*, IEEE (2019).

[11] Oki, M., Takeuchi, K. and Uematsu, Y.: Mobile Network Failure Event Detection and Forecasting with Multiple User Activity Data Sets, *30th Annual Conference on Innovative Applications of Artificial Intelligence (IAAI-18)* (2017).

[12] Akaike, H.: *A New Look at the Statistical Model Identification*, pp.215-222 (online), DOI: 10.1007/978-1-4612-

1694-0.16 (1998).

[13] Vapnik, V.N.: *Statistical Learning Theory*, Wiley-Interscience (1998).

[14] Fan, R.-E., Chang, K.-W, Hsieh, C.-J., Wang, X.-R. and Lin, C.-J.: LIBLINEAR: A library for large linear classification, *Journal of Machine Learning Research*, Vol.9, pp.1871-1874 (2008).


[15] Chang, C.-C. and Lin, C.-J.: LIBSVM: A library for support vector machines, *ACM Trans. Intelligent Systems and Technology*, Vol.2, No.3 (2011).

[16] 今村賢治, 斎藤邦子, 浅野久子：テキストからの知識抽出の基盤となる日本語基本解析技術, NTT 技術ジャーナル 2008.06, pp.20-23 (2008).



山田 尚志 (正会員)

2006年公立はこだて未来大学システム情報科学部卒業。2008年同大学システム情報科学研究科博士前期課程修了。同年ドコモ・テクノロジー株式会社に入社し、検索システム、位置情報解析の研究開発に従事。2019年より、ソフトバンク株式会社に所属。



落合 桂一 (正会員)

2006年千葉大学工学部情報画像工学科卒業。2008年同大学院自然科学研究科知能情報工学専攻博士前期課程修了。同年株式会社NTTドコモ入社。2017年東京大学大学院工学系研究科技術経営戦略学専攻博士後期課程修了。博士(工学)。SNS, 位置情報, ヘルスケアデータやスマートフォンログ解析の研究開発に従事。ACM, 日本データベース学会, 人工知能学会各会員。




横井 靖弘

2003年名古屋大学工学部電気電子・情報工学科卒業。2005年同大学大学院工学研究科電子情報学専攻博士前期課程修了。同年株式会社NTTドコモに入社し、検索システム、位置情報解析の研究開発に従事。



神山 剛 (正会員)

NTT ドコモ IoT ビジネス部勤務.  
2003 年 (株) イーゼス代表取締役,  
2006 年同社退社, 東京大学新領域創  
成科学研究科修士課程修了を経て, 同  
年 (株) NTT ドコモ入社. 先進技術研  
究所 (~2016 年), サービスイノベー  
ション部 (~2017 年), IoT ビジネス部 (~現在) にて,  
モバイルコンピューティング, ソフトウェア省電力化, 分  
散システム, ユーザ行動センシング, 次世代交通需要予測  
に関する研究開発に従事. 博士 (工学), 九州大学客員准  
教授.



鳥居 大祐 (正会員)

2001 年京都大学工学部情報学科卒業.  
2006 年同大学院社会情報学専攻にて  
博士 (情報学) を取得. 同年より株式  
会社 NTT ドコモに所属し, 検索シス  
テムや位置情報解析に取り組む. 2014  
年 2 月より株式会社みらい翻訳にて機  
械翻訳を中心とした自然言語処理の技術開発に従事. 2018  
年 11 月より同 COO&CTO. 言語処理学会会員.