

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^{1,a)} 落合 桂一^{2,b)} 横井 靖弘^{2,c)} 神山 剛^{2,d)} 鳥居 大祐^{2,†1,e)}

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

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]を越えており、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上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]。また、特定条件下で発生するサイレント障害は従来のネットワーク管理機能では検知できないため、長期的な計測等による原因特定が必要となる[3]。

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やサイ

レント障害の把握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[4], [5], [6]。

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。

本論文における貢献は以下の2つである。

- (1) 通信障害に関するツイートならではの特徴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。

本論文の構成は以下の通りである。第2章で関連研究について述べ、第3章で提案システムについての概要を説明し、第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

¹ ドコモ・テクノロジー株式会社
Akasaka-intercity, 1-8-1 Akasaka, Minato Ku, Tokyo 107-0052, Japan
² 株式会社NTTドコモ
Sanno Park Tower, 2-11-1 Nagata-cho, Chiyoda Ku, Tokyo 100-6150, Japan
^{†1} 現在、株式会社みらい翻訳
Presently with Mirai Translate, Inc.
a) yamadahisa@nttdocomo.com
b) ochiaike@nttdocomo.com
c) yokoiy@nttdocomo.com
d) kamiyamata@nttdocomo.com
e) toriid@nttdocomo.com

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 [7], 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、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。[4] 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（例えば、「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 [5] は、SNS を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。

Takeshita ら [6] 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。

そこで本研究では、通信障害に関するツイートならではの特徴量から機械学習モデルを生成し、通信障害に関するツイートを高精度で分類し、ツイートからの通信障害の検出適合度を向上を目指すと共に、提案システムの運用・評価からシステムの実用可能性について検討する。

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。

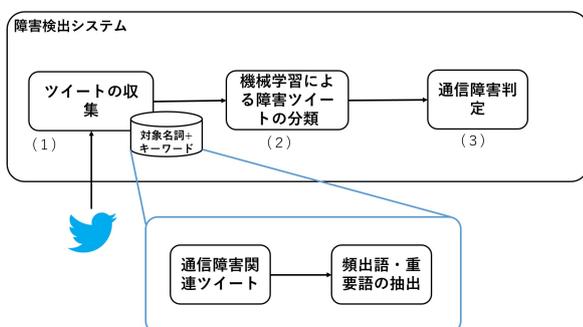


図 1 システム概要図

図中の (1)~(4) は以下の通りである。

(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。

(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) 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。

(4) (3) で得られた確率値を元に通信異常が発生しているかどうかを判定する。

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多々あり、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。例えば、「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。

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。例えば、否定的であれば「繋がらない」、「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表 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。

表 1 障害ツイート抽出単語例

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

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、

表 2 障害ツイート例

<ul style="list-style-type: none"> ・ 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。しゃーなしに自宅の 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
--

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の、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。例えば、「A 社のコールセンターに繋がらない」と言ったツイートが該当する。

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、ツイートの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、二次元平面上に二つの点の集合が存在する場合に、一つの直線で分離できることを言う。線形分離の機械学習として、SVM[8]が代表的である。

機械学習器は、機械学習ライブラリ LIBLINEAR[9] を用いた。LIBLINEAR は線形予測に特化した SVM ライブラリで、LIBSVM[11] 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、参考文献 [9] を参照されたい。

なお、分類精度は、丸ら [5] の適合率 (86%)、再現率 (98%) を目標値とした。また、TwitterAPI では、秒間 1000 件程度の日本語ツイートが取得できるため、秒間 1000 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[10] 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いたためである。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 と全ての品詞の bigram の 2 通りの素性を作成している。例えば、「繋がらない」を JTAG で形態素解析すると『繋がら-繋がる-動詞語幹-ツナガラ-繋がら-ない-動詞接尾辞:終始-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（助詞等）は除外する。

素性作成の流れを図 2 に示す。

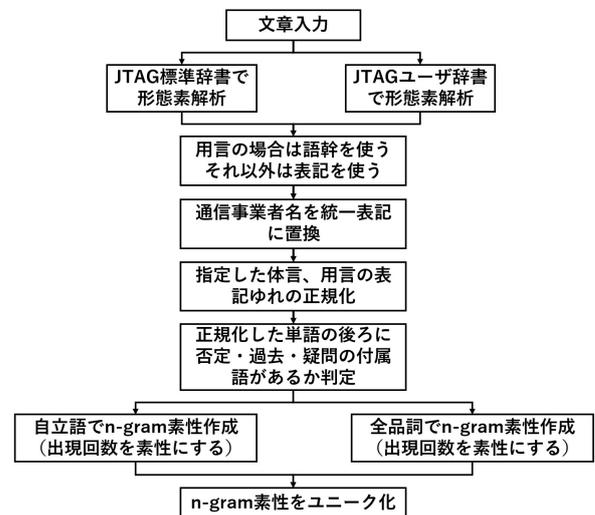


図 2 素性作成フロー

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じような形式に変換した上で LIBLINEAR を動作させる。LIBLINEAR の出力は、障害ツイートに最もらしいかを 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

文献 [4] では、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と前日、前々日のなど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み合わせにより実装されているが、本稿では、ポアソ

ン分布に従わない異常傾向を抽出する急増投稿検出手法のみを採用した。急増投稿検出手法では、現在時刻スロット t (10 分間) 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 λ 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。

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

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

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

ポアソン分布を利用した急増投稿検出手法は、ツイート数の変動が少なくても障害発生の確率が大きく変わりやすいため、障害を早期に発見できる可能性が高いためである。ただし、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になるため、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 λ 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定義

本小節では、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値を定義する。(1) で定義した式において、 τ 値、ツイート取得のスロット幅により、検出の時間や精度は変わる。

τ 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、 τ 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 3 は、各 τ 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。

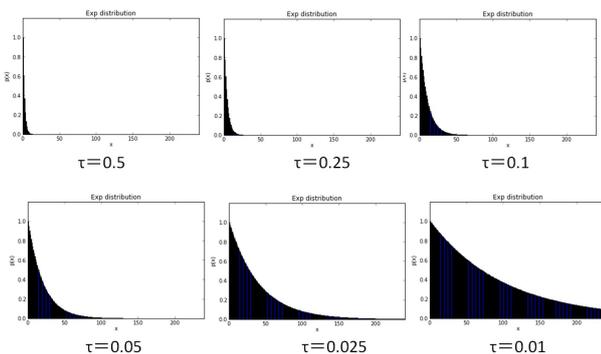


図 3 τ 値と重み付き平均の関係

τ 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、それに伴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、 τ 値は現在時間から直近 30~40 分ほ

ど前に重みが置かれる 0.25 とした。

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、障害検知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取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。評価に当たって、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 4 に結果を示す。

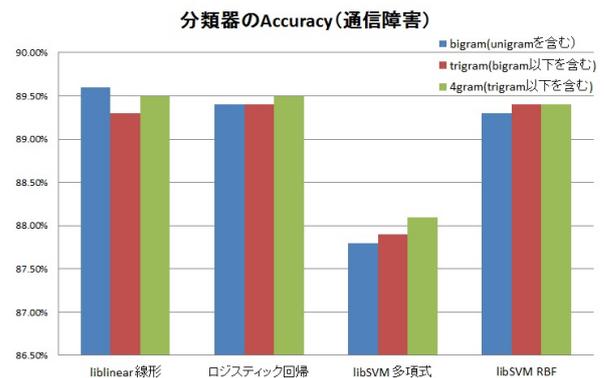


図 4 分類器の性能

LIBLINEAR では、線形カーネル、ロジスティック回帰ともに同程度の 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上で分類器は 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 5 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。

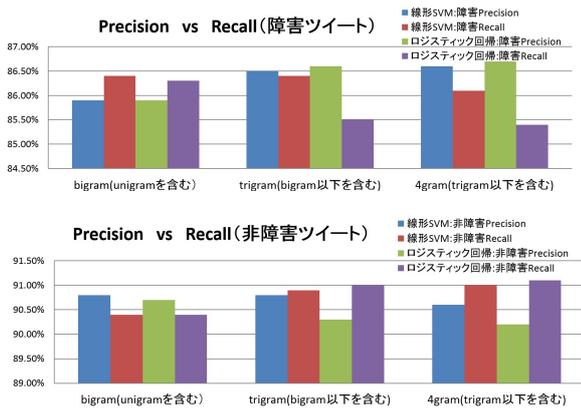


図 5 Precision, Recall(線形 SVM, ロジスティック回帰)

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 3 の通りである。

表 3 開発環境

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

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 万件全ての分類にかかる処理時間は 4.7 秒であり、秒間 2128 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 1000 件以上のツイートの分類を満足出来ることを示した。

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 4 は、その結果である。

影響ユーザ数 10 万人以下では、平均検出時間 11040 秒、10~100 万人では平均検出時間 2172 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いため、ツイートへの投稿そのものが少ない状況であったため、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。

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なった。図 6 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思われる。

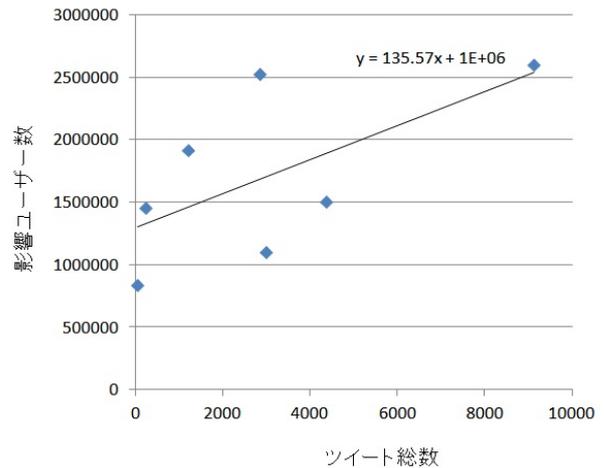


図 6 ツイート数と影響ユーザ数の相関関係

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 7 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通り、いずれも比較的大きな通信障害であり、平均検出時間は 7848 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、市場の 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 8 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時の検出は出来たが、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。表 5 に障害発生初期に障害が分かるツイートの例を、表 6 に障害状況がわかるツイートの例を示す。

このようなツイートを的確に抽出し、システムで通信障

表 4 オフライン評価結果

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	2011/7/25 7:40	14520
	2013/5/6 13:01~14:59	非公開	データ通信	西日本	2013/5/6 13:01	1740
	2013/7/26 13:33~15:31	非公開	音声	鹿児島県の一部	2013/7/26 18:30	18000
	2013/9/4 13:41~17:57	非公開	音声	福井県の一部	2013/9/4 17:30	13740
	2013/10/7 17:6~19:30	非公開	音声	鹿児島県の一部	2013/10/7 19:00	6840
	2013/11/8 13:15~16:35	非公開	音声	沖縄県の一部	2013/11/8 17:30	15300
	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	22980
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	1440
	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	7560
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	3840
	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 29:20	-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	-14400

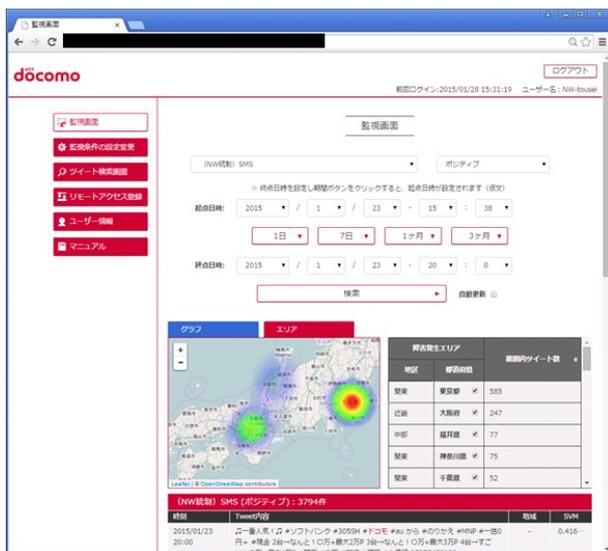


図 7 障害検知システムユーザ表示画面

表 5 障害発生初期のツイート例

- ・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

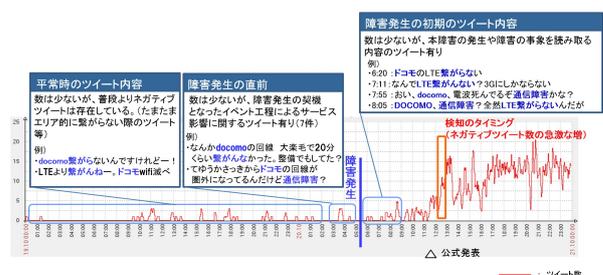


図 8 ツイートの推移

表 6 障害状況が分かるツイート例

- ・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。

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・的確化に繋がれると考えられる。

また、過去に発生した障害事例、誤検出事例に SVM を適用しその効果についても確認を行った。障害事例については、2014 年 12 月から 2015 年 1 月にかけて発生した各通信事業者が報告している通信障害を対象とした。

SVM の適用による適合率と再現率は表 7 となる。表中の SVM 閾値は、分類器から出力されるスコアから障害ツイートとして利用するかどうかを判断するための閾値で、閾値以上のツイートを障害ツイートとして採用する。

表 7 SVM の適用による適合率/再現率

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 [%]	16(6/37)	19(6/31)	32(6/19)	43(6/14)
再現率 [%]	75(6/8)	75(6/8)	75(6/8)	75(6/8)

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、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を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精度の精度向上を行い、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

本評価より、Twitter の投稿内容を解析し、統計的な異常検知を用いての手法は、大規模な通信障害においては早期に障害を検知できる場合もあったが、小中規模の通信障害では、障害を検知出来ないことが多く、サイレント故障に対する検知への期待は少ないと考えられる。

ただし、障害発生当初に発生する障害発生を読み取れるツイートには、障害状況を把握できる内容が含まれていたため、これらのツイートをリアルタイムに把握することが出来れば、通信障害に対する初動対応の迅速化に期待が出来る。

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等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取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依らず、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。

参考文献

- [1] 総務省, "通信利用動向調査", http://www.soumu.go.jp/johotsusintokei/statistics/data/180525_1.pdf
- [2] 大和田英成, "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: 信学技報 100(301) 2000.9.21 p61-66
- [3] 神野裕宣, 寒河江佑太, ベンジャールアナス, 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, vol.110, no.466, pp.1-6, 2011.
- [4] 池田和史, 服部元, 小野智弘, 麻生英樹, "Twitter 解析による通信品質低下傾向の早期検出手法の提案", FIT2012(2012).
- [5] 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 (DICOMO2016) シンポジウム (2016).
- [6] Kei Takeshita, Masahiro Yokota, Ken Nishimatsu, "Early Network Failure Detection System by Analyzing Twitter Data,"
- [7] J. Kleinberg, "bursty and hierarchical structure in streams," Proc. of SIGKDD, pp.1-25, 2002.
- [8] V.N.Vapnik, "Statistical Learning Theory", Wiley, New York, 1998.
- [9] R.-E.Fan, K.-W.Chang, C.-J.Hsieh, X.-R.Wang, and C.-J.Lin, "LIBLINEAR: A library for large linear classification," Journal of Machine Learning Research 9, 1871-1874, 2008.
- [10] 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, 2008
- [11] Chih-Chung Chang and Chih-Jen Lin, "LIBSVM: a library for support vector machines," ACM Transactions on Intelligent Systems and Technology, 2:27:1-27:27, 2011