

# 気象とプローブデータを活用した 統計的時系列モデルによる災害発生時の 道路異常事象検知手法の構築

梅田 祥吾<sup>1</sup>・桑原 雅夫<sup>2</sup>

<sup>1</sup>正会員 東北大学大学院 情報科学研究科 (〒980-8579 仙台市青葉区荒巻字青葉6-6-06)

E-mail: umeda@plan.civil.tohoku.ac.jp

<sup>2</sup>正会員 東北大学大学院 情報科学研究科 教授 (〒980-8579 仙台市青葉区荒巻字青葉6-6-06)

E-mail: kuwahara@plan.civil.tohoku.ac.jp

本研究では、プローブデータと気象データを活用し、大雨や豪雪等の自然災害に起因する道路ネットワーク上の道路交通異常事象(スタックや立ち往生等)の検知手法を提案した。災害発生時の道路交通異常事象を早期に発見することが出来れば、管理者の適切な判断、対応を促すことができ、災害発生後の迅速な復旧及び安全、円滑な道路管理に繋がる。具体的には、実災害発生時のデータの時系列分析の結果から、状態空間モデルを構築し、予測と状態推定を行い、算出した2つの値の乖離から道路交通異常事象の発生時点を検知する手法を構築した。また、本研究での提案手法と従来の統計的時系列モデル(ARIMA, ARIMAX, VAR)との比較検証を行い、提案手法が従来の手法よりも予測精度が高いことを示した。

**Key Words :** *anomaly detection, time series data, natural disasters, probe data, state space model*

## 1. はじめに

我が国では、多くの自然災害が発生し、その都度、道路損傷や冠水、スタック、立ち往生といった多数の道路交通異常事象(以下、異常事象)が発生している。近年でも、平成30年の2月に発生した北陸での豪雪による立ち往生、7月に発生した西日本豪雨による冠水、道路損傷等の被害が記憶に新しいところである。これらの自然災害の影響を受けて、国土交通省は、高速道路や国道を早めに通行規制する「予防的通行止め」<sup>1)</sup>の導入、検討を進めており、災害時の異常事象発生の予測、早期発見の重要性が一層高まっている。こういった自然災害に起因する異常事象を早期に予測、発見することが出来れば、管理者の適切な判断、対応をサポートすることができ、災害時の安全で迅速な避難支援、通行規制や情報提供、道路復旧、救助活動等に貢献すると考えられる。

一方で、従来の異常事象の発見は、CCTVや車両感知器等の固定センサー、管理者のパトロール、道路利用者からの通報等に頼っている。これらの方法は監視範囲や監視時間に制限があるため、異常事象の発見が遅れ、その影響が拡大することもある。そのため、広範囲かつ自

動で異常事象の検知が可能な手法の構築が求められている。特に一般道は高速道路と比較して、監視する道路延長が長く、車両の行動が複雑であることや固定センサー設置、維持コストが膨大になる等、課題が多い。

そこで、本研究は、近年データ数が増加し、広範囲かつ常時データの収集が可能なプローブデータ及び災害時の気象データに着目し、一般道を含む道路ネットワーク全体を対象にした自然災害発生時の異常事象を自動で検知可能な手法の構築を目的として研究を行う。

本論文の構成は以下のとおりである、まず第2章では、災害時の交通実態把握に関する研究、異常事象の検知手法に関する研究のレビュー結果から本研究の位置づけ及び新規性を整理する。第3章では、本研究での異常事象検知問題の設定及び本研究で提案する異常事象検知手法の詳細を述べる。第4章では、提案する異常事象検知手法を実災害時のデータに適用し、異常事象の検知可能性及び従来手法との比較検証を行う。最後に本研究のまとめと今後の課題について整理する。

## 2. 本研究の位置づけと既往研究について

### (1) 災害時の交通実態把握に関する研究

災害時の交通実態を把握する研究としては、Zhuら<sup>2)</sup>により車両感知器、バス利用者統計及びアンケート調査結果を用いたミネアポリス高速道路崩壊後の交通パターンの変化を把握した研究がある。

プローブデータを用いた研究には、Bengtssonら<sup>3)</sup>によってハイチ地震後の人口推移を携帯プローブから把握した事例があり、東日本大震災発生後の状況はHaraら<sup>4)</sup>、熊本地震発生後の状況はKawasakiら<sup>5)</sup>によって明らかにされている。これらの研究実績からもわかるとおり、プローブデータは災害時においても、データを収集・分析可能であり、災害時の交通実態把握に有用であることがわかる。ただし、災害発生自体が日本でも年に数回と稀で、プローブ機器（カーナビ、スマホ等）によるデータ収集・活用の仕組みが近年になって整ってきたことから災害時のプローブデータを活用した研究は多くない。

### (2) 道路交通異常事象検知に関する研究

道路交通異常事象検知に関する研究は、数多く実施されている。プローブデータの集計量を用いた例としては、Horiguchiら<sup>6)</sup>のエリア内の存在台数とフローとの関係を推定し、観測値との乖離により非日常的な混雑状況を持つメッシュを検出する手法、または牛木ら<sup>7)</sup>、Li and McDonal<sup>8)</sup>の旅行時間の空間的変化と突発的BN直下流のプローブ通過台数の時間的変化により検出を行う手法等がある。

プローブ車両の個々のデータを使う例としては、Pettyら<sup>9)</sup>の異常事象発生箇所を低速走行した車両はボトルネック通過後、自由流速度まで加速する特性を利用した手法や関塚ら<sup>10)</sup>の事故発生時のタイムスペース図から渋滞延伸状況を解析し、旅行時間を予測する手法、Asakuraら<sup>11)</sup>は、車両軌跡の変曲点間をつないだ衝撃波面に着目し、交通障害発生時の時間と場所を推定する手法、Caiら<sup>12)</sup>の一般道の交通障害発生時に交差点の進入区間で生じるふらつきや車線逸脱を異常と定義し、プローブの異常挙動を検出する手法等、さまざまな手法の提案がなされている。

車両感知器データを使用した例としては、Salamanisら<sup>13)</sup>の高速道路車両感知器データを活用し、機械学習(k-近傍法およびサポートベクトル回帰アルゴリズム)と時系列モデルの両方を用いて交通予測モデルを構築した例や野村ら<sup>14)</sup>によってベイジアンネットワークを用いた突発事象検知モデルを構築、首都高の5路線に適用した例がある。交通量やオキュパンシー、車線別の速度差等の統計量について、平常時と交通障害発生時の差異を分析した例としてはCullipら<sup>15)</sup>、Kawasakiら<sup>16)</sup>がある。

その他道路交通異常事象以外の異常検知の例としては、神谷ら<sup>17)</sup>によってメッシュ人口時系列データの潜在状態数を推定可能な隠れマルコフモデルを援用した異常検知手法が提案されている。

上記の例に挙げたとおり、センシングデータを活用した異常事象検知に関する研究は多く実施されているが、その多くが高速道路を対象にしており、検知異常事象は事故、渋滞がメインとなっている。本研究で対象とする災害時の一般道を含む道路ネットワーク全体を対象とした異常事象の検知とは手法の適用範囲、検知事象が異なっている。また、交通状態に関する変数(速度や交通量)のみを扱っているものが多く、本研究のように複数のセンシングデータ(交通、気象)を取り扱う研究は少ない。

## 3. 道路交通異常事象検知手法の提案

### (1) 道路交通異常事象検知問題の設定

Chandolaら<sup>18)</sup>は、異常検知問題を分類する要因として、対象とするデータの性質、異常検知の出力方法、学習時のラベル、異常の種類を提案している。本研究でも、この枠組みに基づき、異常検知問題の設定を行う。

本研究で取り扱うデータの性質、異常検知の出力方法、学習時のラベル、異常の種類は以下のとおりである。

データの性質：時系列データ(プローブと気象の状態)  
異常検知の出力方法：「異常」「正常」のラベルと異常度

学習時のラベル：「正常」ラベルのみを持つデータ(半教師データ)災害時のデータを大量に収集するのは容易ではないため、日常のデータを収集

異常の種類：文脈型異常

上記より、本研究で取り扱う問題は半教師付き学習による統計的時系列異常検知問題として設定した。統計的異常検知とは、大概のデータが従うパターンを統計モデルによって学習し、モデルからの予測値からある程度の尺度を以って外れたデータを検出する問題である。

### (2) 状態空間モデルによる統計的異常事象検知手法

本研究での具体的な異常事象検知手法について、以下に述べる。

本研究では、状態空間モデルの枠組みを活用して異常検知を行う。状態空間モデルでは潜在状態ベクトル  $x$  と観測ベクトル  $y$  から構成される。潜在状態ベクトル  $x$  がシステムモデルに従って時間変化すると共に、各々の潜在状態ベクトル  $x$  から観測モデルに従って観測ベクトル  $y$  が出力される。図1に状態空間モデルのグラフィカルモデルを示す。この表現により、複雑に時系列変化する




図-1 状態空間モデルのグラフィカル表現

データのモデリングが可能となるため、時系列データの異常検知に状態空間モデルが用いられることが多い。

状態空間モデルを利用した異常検知手法の1つに、異常は観測値と予測値との乖離度であると仮定するものがあり、カルマンフィルタやパーティクルフィルタにより尤度や出力確率を計算することで異常を検出することが出来る。本研究ではこの手法を援用し、異常事象の検知を行う。

### (3) 異常検知フロー

本研究で提案する異常検知手法のフローを以下に整理する。分析対象データを学習データと検証データに分割する(ステップ1)。学習データの時系列分析を行い、データの特徴からモデル構築を行う(ステップ2)。最尤推定によりモデルパラメータを推定する(ステップ3)。学習データにより同定したモデルを用いて予測を実施する(ステップ4)。検証データを用いてカルマンフィルタにより時刻  $t$  のデータが得られた時の事後確率が最大となる状態量を推定(ステップ5)。ステップ4の予測値とステップ5の状態量の2つの値の乖離が大きい場合に異常を検知(ステップ6)

上記のとおり、予測値と観測値との比較ではなく、予測値と状態量との比較により異常を検知することにより、観測誤差を考慮した、確率的な異常検知が可能となる。

## 4. 実災害時データへの適用検証

### (1) 平成30年福井豪雪の概要

本研究での提案手法を実災害事例に適用し、異常事象の検知可否及びその適用可能性について検証する。適用事象は、平成30年2月に発生した福井豪雪時の立ち往生事例とする。適用対象事例の概要について以下に述べる。2018年2月6日、日本列島は上空の強い寒気の影響により日本海側で大雪となった。日本海側に位置する福井県では、平年の6倍を超える積雪の深さ147センチを記録し、37年ぶりに130cmを超えた。

この大雪の影響を受けて、福井県北部の国道8号線では午前6時頃に坂井市丸岡町からあわら市熊坂の10キロの区間に渡って約1,500台の車が立ち往生した。

### (2) 使用データ

#### (a) プローブデータ

交通状況を把握し、交通障害を検出するためのデータとして、本田技研工業株式会社のインターナビ会員車両のプローブデータを使用した。このプローブデータは会員車両の位置情報(緯度、経度)、走行速度、移動方向を記録した情報である。

本研究では、立ち往生が発生した国道8号線の坂井市丸岡町からあわら市熊坂間を含む約20km×50km(北緯35.98度~36.30度,東経136.15度~136.32度)のエリア内で記録されているプローブデータを抽出した。また、各プローブデータの位置情報(緯度・経度)から、1km四方メッシュにデータを振り分け、メッシュ単位で15分毎の平均速度の集計を行った。学習データとして、平成30年1月22日~2月5日の13日間(1月27日、28日は欠測)、検証データとして、災害当日の2月6日を設定した。

#### (b) 気象データ

気象データは国土交通省気象庁が観測・発表する気象統計データを使用した。具体的には、福井気象観測所で観測した1時間毎の積雪深の記録値を用いた。

### (2) 災害発生時の状況分析

前項で整理したデータを用いて、災害発生時の交通状況及び気象状況について分析を行った。

#### (a) 気象状況

図2は、福井市内の分析期間の積雪深さの時間変動を示したものである。1月24日から雪が降り始め、2月4日から急激に積雪深さの値が大きくなっている。立ち往生が発生した2月6日がピークとなり積雪深さは130cmを超過している。

#### (b) 交通状況

図3は立ち往生が発生した2018年2月6日6時台の1kmメッシュ内のプローブ車両の平均速度を示した図である。ほとんどのメッシュが赤色で示されており、エリア全域が30km/h以下であり、一部のメッシュでは10km/h以下の低い速度であったことが分かる。立ち往生発生区間はプローブが計測できないため、メッシュに色が付かず、データが欠測していることが分かる。



図-2 積雪深さの時間変動




図-3 立ち往生発生区間とメッシュ別平均速度(2月6日6:00)




図-6 学習データ(平均速度)の水準+トレンド成分



図-4 立ち往生発生区間の平均速度の変動




図-7 学習データ(平均速度)の周期成分




図-5 立ち往生発生区間プローブ存在台数の変動

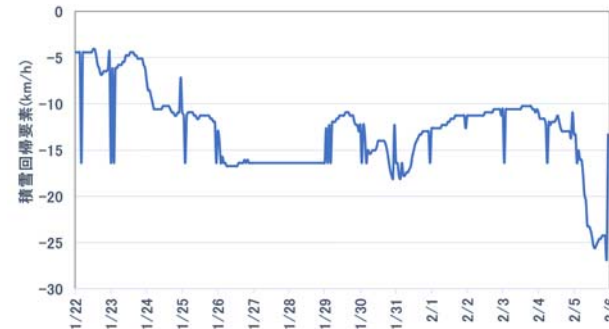


図-8 学習データ(平均速度)の積雪深さの回帰要素

図4は立ち往生が発生した区間を含む1km四方のプローブの15分間のメッシュ平均速度及び1時間プローブ台数の変動を示したものである。平均速度変動を見ると、時折、高い速度が観測されるが、おおむね1日単位の周期性を持ってデータが変動していることが見て取れる。災害発生当日は、急激な速度の低下が見られ、何らかの異常が発生した事が定性的に見て取れる。同様にプローブの存在台数の時間変動を見てみると、速度と同様に概ね1日単位の周期性をもっており、最大でも30台程度の存在台数であることが分かる(図5)。この平均速度の原系列データを周期成分と水準値とトレンド成分、自己回帰成分、外生変数(積雪深さ)による回帰成分、観測ノイズの和によって表現できると仮定して、以降のモデル構築を行う。現系列の水準値とトレンド成分、周期成分と外生変数(積雪深さ)の回帰成分を図示すると図6~8となる。

### (3) モデルの構築

学習データの分析結果から状態空間モデルのモデル構築を行う。自己回帰成分を含めた各成分の和がある交通状態を表し、それが観測誤差を伴って、平均速度として観測されたとすることで、よりフレキシブルな構造を持つ状態空間モデルの枠組みで示すことが出来る。上記を踏まえると潜在的な平均速度  $x$  を表す状態方程式と観測値  $y$  を表す観測方程式は式(1)と式(2)で表現できる。

#### システム方程式

$$\begin{aligned}
 x_t &= x_{t-1} + \delta_t + S_t + R_{at} + w_t, & w_t &\sim N(0, \sigma_w^2) \\
 \delta_t &= \delta_{t-1} + \xi_t, & \xi_t &\sim N(0, \sigma_\xi^2) \\
 S_t &= -\sum_{i=1}^{n-1} S_{t-i} + v_t & v_t &\sim N(0, \sigma_v^2) \\
 R_{at} &= \alpha_t R_t
 \end{aligned} \quad (1)$$

観測方程式

$$y_t = x_t + v_t, \quad v_t \sim N(0, \sigma_v^2) \quad (2)$$

$x_t$  : 時刻  $t$  の状態量(平均速度)  
 $\delta_t$  : 時刻  $t$  のトレンド成分  
 $S_t$  : 時刻  $t$  の周期成分  
 $R_t$  : 時刻  $t$  の積雪深さ  
 $\alpha_t$  : 時刻  $t$  の回帰係数  
 $w_t$  : 時刻  $t$  のシステムノイズ  
 $\xi_t$  : 時刻  $t$  のトレンドのノイズ  
 $y_t$  : 時刻  $t$  の観測値(平均速度)  
 $v_t$  : 時刻  $t$  の観測のノイズ  
 $n$  : 日当たりのデータ数

フィルタリング

$$K_t = \frac{P_t}{P_t + \sigma_v^2} = \frac{P_t}{F_t}$$

$$y_{resid,t} = y_t - \hat{y}_t \quad (4)$$

$$y_{t|t} = x_t + K_t \cdot y_{resid,t}$$

$$P_{t|t} = (1 - K_t)P_t$$

$x_{t|t}$  : 時刻  $t$  のフィルタ化推定量  
 $y_t$  : 時刻  $t$  の観測値  
 $Y_t$  : 時刻  $t$  までのすべての観測値  $\{y_1 \dots y_t\}$   
 $\hat{y}_t$  : 時刻  $t$  の観測値の予測値  
 $y_{resid,t}$  : 時刻  $t$  の予測残差  
 $x_t$  : 時刻  $t$  の予測値  
 $P_t$  : 時刻  $t$  の状態の予測誤差の分散  
 $K_t$  : 時刻  $t$  のカルマンゲイン  
 $F_t$  : 時刻  $t$  の観測値の予測誤差の分散

(4) 計算アルゴリズム

前述した状態空間モデルは式(1), 式(2)で示すように時系列の関係を線形で表現し, 各種ノイズに正規分布を仮定することでカルマンフィルタのアルゴリズムが適用出来る. 簡単のためローカルレベルモデルでのカルマンフィルタの1期先予測の式を式(3)に, フィルタリングの式を式(4)に示す. 1期先予測とフィルタリングを繰り返すことで先の交通状態の推定を行うことが出来る.

一期先予測

$$x_t = x_{t-1|t-1}$$

$$P_t = P_{t-1|t-1} + \sigma_w^2 \quad (3)$$

$$\hat{y}_t = x_t$$

$$F_t = P_t + \sigma_v^2$$

(5) 異常事象検知の実施

構築したモデルを用いて, 検証データによる異常事象検知を行う. 図8に提案モデルによる予測値と観測値の比較を示す. また, 図9に提案モデルにより推定した状態量と観測値の比較を示す. 図10は, 図8と図9の予測推定区間を拡大図である. 上段には, 予測値と状態推定量, 観測値の比較結果を示し, 中段には, 予測の下限值と観測値の残差, 下段には, 予測の下限值と状態推定量の残差を示す. 予測値と状態量との残差が下方方向に大きくなった地点が異常に速度低下が発生した時点と見るこ




図-9 提案モデルによる予測値と観測値の比較




図-10 提案モデルによる推定状態量と観測値との比較

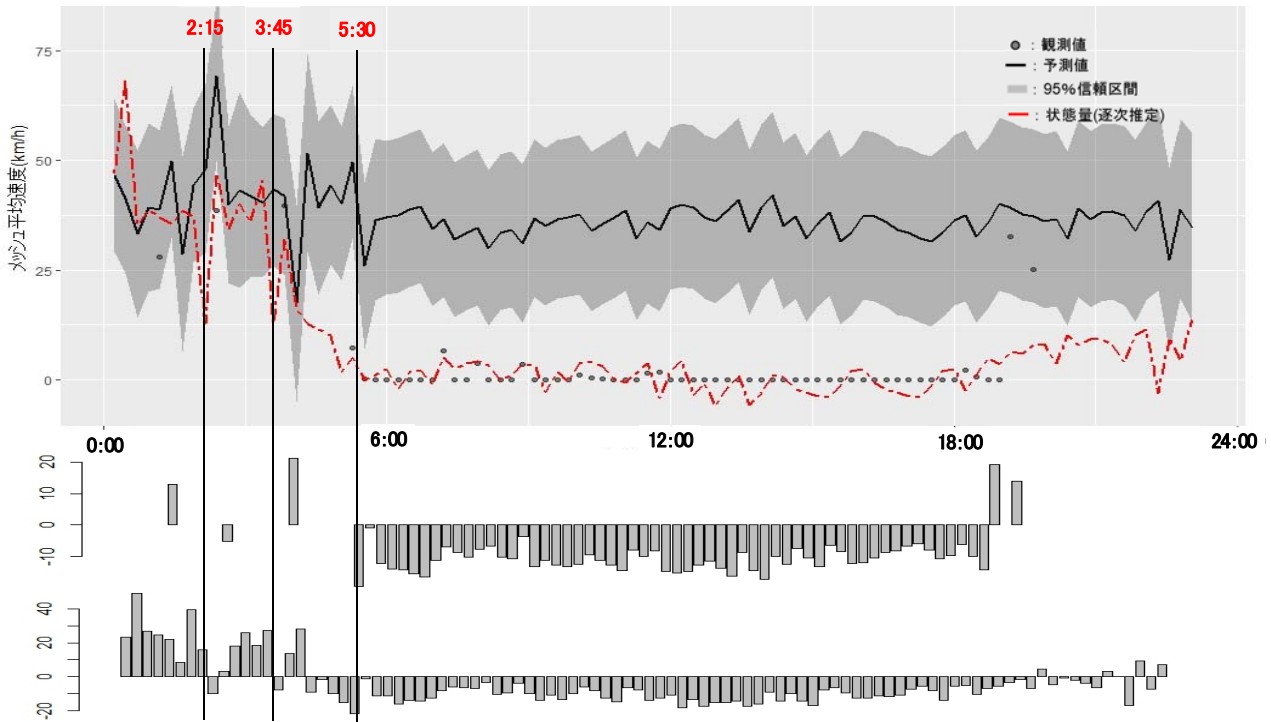


図-11 提案モデルによる異常事象検知結果(2月6日)  
 (上段：予測値と状態推定量の比較 中段：予測値(下限値)と観測値の残差 下段：予測値(下限値)と状態量との残差)

とが出来る。同図より、災害発生当日の2:15には、予測値と状態量との乖離が大きくなり、異常を検知していることが分かる。また、3:45には再度予測値と状態量との乖離が大きくなっている。4:30以降は連続して予測値と状態量との乖離が大きくなっている。これらより提案手法では、実際に立ち往生が発生したとされている5:30頃よりも早い段階で複数回の異常を検知した。また観測値よりも状態空間モデルによる状態量との比較を行ったことにより、観測誤差を考慮できていること、欠測値の補正を行っていることにより異常検知の精度が高まっていると推定される。

(6) 従来手法との比較検証

提案モデルによる予測値と古典的な統計モデルであるARIMAモデル(自己回帰和分移動平均モデル)、ARIMAの拡張版であり、多変量時系列データを取り扱うことが出来るARIMAXモデル(外生変数付きARIMAモデル)とVARモデル(ベクトル自己回帰モデル)による予測、ナীবな予測(学習データの平均値を予測値とする)の4種類の予測結果を用いてモデル精度の比較検証を実施した。モデルの次数はAICが最小となる次数とした。また、比較検証のための学習データは平成30年1月22日~2月4日の12日間(1月27日、28日は欠測)、検証データは2月5日と設定した。モデルのによる12期先までの予測値と観測値との乖離をRMSEによって評価した。図12~図16は、各モデルによる予測値と観測値をプロットしたものである。評価結果は表1に示したとおりである。表1を見ると提案

モデルが最も値が小さくなり、予測値と観測値との乖離が小さいことが分かる。ARIMAモデルやその拡張版のモデルは、モデル構築の際に、原系列をそのまま扱わずに差分を取るなどの処理の過程で情報を一部失っていること等から予測の精度に差が発生していると考えられる。




図-12 ナীব予測と観測値との比較

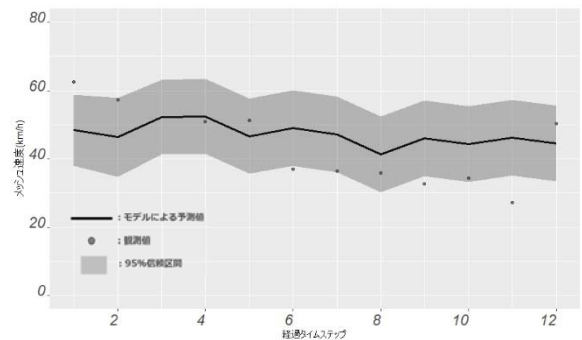


図-13 ARIMAモデルによる予測と観測値との比較




図-14 ARIMAX モデルによる予測と観測値との比較




図-15 VAR モデルによる予測と観測値との比較




図-16 提案モデルによる予測と観測値との比較

表-1 予測手法別のRMSE.

予測手法	使用変数	RMSE
ナイーブ予測(学習データの平均値)	平均速度	11.007
ARIMA モデル	平均速度	10.865
ARIMAX モデル	平均速度+積雪深さ	9.639
VAR モデル	平均速度+積雪深さ	9.833
提案モデル	平均速度+積雪深さ	9.375

## 5. 終わりに

本研究では、自然災害発生時の道路交通異常事象の検知問題を半教師付き学習による統計的時系列異常検知問題として設定した。具体的には、メッシュ別のプローブ平均速度とメッシュ別の積雪深さを状態空間モデルにより表現し、モデルから推定される予測値と状態量との乖

離によって異常事象を検知する手法を提案した。また、提案手法を災害時(平成30年福井豪雪時の立ち往生)に適用し、立ち往生事象が発生する前に異常を検知することが出来た。また、古典的な統計的モデルであるARIMAモデルやARIMAモデルの拡張版であるARIMAXモデル、VARモデル等と提案手法の予測精度の比較検証を行い、提案手法の方が予測精度が高いことを示した。

今後は、モデルの精度向上や適用範囲の検証が必要と考えられる。具体的には、他の災害事例や他の異常事象(事故、冠水、道路損傷等)への適用やメッシュ間の空間の相関関係、相互依存関係を考慮したモデルの拡張が考えられる。また、民間プローブデータではスパースな時間帯や地域が存在するため、商用車プローブや車両感知器による補間によっても異常検知精度の向上が図られると考えられる。

**謝辞：**本研究はJSPS科研費26220906の助成を受けたものである。また、本研究で使用したプローブデータは本田技研工業株式会社より提供していただいたものである。ここに感謝の意を表す。

## 参考文献

- 1) 国土交通省HP, <http://www.mlit.go.jp/road/ir/ir-council/toukidourokanri/pdf01/07.pdf>
- 2) Zhu, S., Levinson, D., Liu, H, X. : Kathleen Harder: The traffic and behavioral effects of the I-35W Mississippi River bridge collapse, Transportation Research Part A: Policy and Practice, Vol.44, Issue 10, pp. 771-784, 2010.
- 3) Bengtsson, L., Lu, X., Thorson, A., Garfield, R., von Schreeb, J., Improved response to disasters and outbreaks by tracking population movements with mobile phone network data: a post-earthquake geospatial study in Haiti, PLoS Med., Vol.8, No.8, p. e1001083, 2011.
- 4) Hara, Y., Kuwahara, M. : Traffic Monitoring immediately after a major natural disaster as revealed by probe data - A case in Ishinomaki after the Great East Japan Earthquake, Transportation Research Part A : Policy and Practice, Vol. 75, pp. 1-15, 2015.
- 5) Kawasaki, Y., Kuwahara, M., Hara, Y., Mitani, T., Takenouchi, A., Iryo, T. and Urata, J. : Investigation of Traffic and Evacuation Aspects at Kumamoto Earthquake and the Future Issues, Journal of Disaster Research, Vol.12, No.2, 2017.
- 6) Horiguchi, R., Iijima, M., Kobayashi, M. and Hanabusa, H.: Traffic anomaly detection for surface street networks with the mesh-wised traffic indices on macroscopic fundamental diagram, OPTIMUM 2013 International Symposium on Recent Advances in Transport Modelling, pp. 1-7, 2013.
- 7) 牛木 隆匡, 日下部 貴彦, NGUYEN Xuan Long, 朝倉 康夫, 交通容量低下を考慮したプローブカーデータによる突発事象検出手法, 土木計画学論文集D 3 (土木計画学), Vol.70.No5, 2014

- 8) Li, Y. and McDonald, M. : Motorway incident detection using probe vehicles, Proceedings of the Institution of Civil Engineers-Transport, Vol. 158, pp. 11-15, February 2005.
- 9) Petty, K. F., Skabardonis, A. and Varaiya, P. P. : Incident detection with probe vehicles: performance, infrastructure requirements and feasibility, Transportation Systems 1997, A Proceedings Volume from the 8th IFAC/ IFIP/ IFORS Symposium, Chania, Greece, June 16-18, 1997, Vol. 1, pp.125-130, 1997.
- 10) 関塚貴一, 三谷卓摩, 川崎洋輔, 益田卓朗, 永井慎一, 桑原雅夫, 車両軌跡のみを用いた突発事象発生時の旅行時間予測, 土木計画学研究・講演集, Vol.53, CD-ROM, 2016
- 11) Asakura, Y., Kusakabe, T., Nguyen, L., X., and Ushiki, T.; Incident Detection Methods using Probe Vehicles with on-board GPS Equipment, Transportation Research Part C: Emerging Technologies, In press, 2016.
- 12) Cai, Y., Wang, H., Chen, X., Jiang, H. : Trajectory-based anomalous behaviour detection for intelligent traffic surveillance, IET Intelligent Transport Systems, Vol.9, pp. 810-816, 2015.
- 13) Athanasios Salamanis, Giorgos Margaritis, Dionysios D. Kehagias, Georgios Matzoulas, Dimitrios Tzovaras, Identifying patterns under both normal and abnormal traffic conditions for short-term traffic prediction, Transportation Research Procedia, Volume 22, 2017, Pages 665-674
- 14) 野村 大智, 西内 裕晶, 轟 朝幸, 川 智也, 割田 博, ベイジアンネットワークを用いた都市内高速道路における突発事象検知モデルの構築, 土木学会論文集 F3 (土木情報学) 70(2), I\_303-I\_309, 2014
- 15) Cullip, M. and Hall, F. : Incident Detection on an Arterial Roadway, Transportation Research Record: Journal of the Transportation Research Board, Vol.1603, pp.112-118, 1997.
- 16) Kawasaki, Y., Tanaka, A., Goto, H., Takada, J., Warita, H., Hong, S., Tanaka, S. and Kuwahara, M. : Research on Mechanisms to Provide Attention-attracting Information Effective in Preventing Rear-end Collisions, 18th ITS World Congress, 2011.
- 17) 神谷 啓太, 布施 孝志, メッシュ人口データに対するノンパラメトリックベイズに基づく統計的異常検知手法の適用可能性の検証, 土木学会論文集 D3 (土木計画学), Vol.72, No.5 (土木計画学研究・論文集第 33 巻), I\_759-I\_769, 2016.
- 18) Chandola, V., Banerjee, A. and Kumar, V.: Anomaly detection: a survey, ACM Computing Surveys, Vol. 41, No. 3, pp. 15:1-15:58, 2009.
- 19) Pimentel, M. A., Clifton, D. A., Clifton, L. and Tarassenko, L.: A review of novelty detection, Signal Processing, Vol. 99, pp. 215-249, 2014.

(2018. 7. 31 受付)