

# ETC 2.0 プローブ通過情報を活用した 道路交通状態のリアルタイム異常検知

柳沼 秀樹<sup>1</sup>・日下部 貴彦<sup>2</sup>・福田 大輔<sup>3</sup>・鯉淵 正裕<sup>4</sup>・高橋 香織<sup>5</sup>・  
平 哲治<sup>6</sup>・井上 崇<sup>7</sup>

<sup>1</sup>正会員 東京理科大学 講師 理工学部土木工学科 (〒 278-8510 千葉県野田市山崎 2641)  
E-mail: yaginuma@rs.tus.ac.jp

<sup>2</sup>正会員 東京大学 講師 空間情報科学センター (〒 277-8568 千葉県柏市柏の葉 5-1-5)  
E-mail: t.kusakabe@ccsis.u-tokyo.ac.jp

<sup>3</sup>正会員 東京工業大学 准教授 環境・社会理工学院 (〒 152-8552 東京都目黒区大岡山 2-12-1)  
E-mail: fukuda@plan.cv.titech.ac.jp

<sup>4</sup>正会員 株式会社三菱総合研究所 次世代インフラ事業本部 (〒 100-8141 東京都千代田区永田町 2-10-3)  
E-mail: koibuchi@mri.co.jp

<sup>5</sup>非会員 株式会社三菱総合研究所 次世代インフラ事業本部 (〒 100-8141 東京都千代田区永田町 2-10-3)  
E-mail: ta-kaori@mri.co.jp

<sup>6</sup>非会員 国土交通省 関東地方整備局 交通対策課 (〒 330-9724 埼玉県さいたま市中央区新都心 2-1)  
E-mail: taira-t2dd@mlit.go.jp

<sup>7</sup>非会員 国土交通省 関東地方整備局 交通対策課 (〒 330-9724 埼玉県さいたま市中央区新都心 2-1)  
E-mail: inoue-t8311@mlit.go.jp

災害やイベントなどの非平常時において、時々刻々と変化する交通状況をモニタリングし、かつ平時には観測されない異常な状態を早期に検知することは、道路啓開や交通誘導などを効果的に実施する上で極めて有益な情報となりうる。本研究では、リアルタイムに収集される ETC2.0 プローブ通過情報から異常と思われる交通状態を検知するプロトタイプシステムを構築する。具体的には、過去に蓄積された通過情報と 5 分周期で取得される最新の通過情報を用いて、異常検知アルゴリズムの一種である特異値スペクトル変換法を適用し、自動的かつ早期に異常を検知することを目指した。その結果、機器の計測異常や交通量の急激な変化等を捉えることが可能となり、計算コストや操作性の面からも提案手法が実利用の観点から有益であることが確認された。

**Key Words:** ETC2.0 probe data, traffic state, time series analysis, anomaly detection, singular spectrum analysis

## 1. はじめに

近年、我が国では全国各地で大規模な自然災害が頻発しており、社会基盤施設や地域経済に深刻なダメージを与えている。内閣府<sup>1)</sup>が激甚災害として法的支援が必要と判断した災害は、地震と豪雨を中心にこの 5 年間で 28 件にものぼり、それらは未だに被害の爪痕を残している。激甚災害に指定されない災害であっても見過ごすことはできず、被害規模の大小に関わらず、地域の防災性を高めながら安全・安心な国土を築いていく必要がある。しかしながら、近年では、大規模かつ広範囲での災害が頻発しており、社会基盤施設が被災することで本来の機能を維持できない状況が散見される。道路ネットワークでは、被災により線的もしくは面的な遮断や容量低下などにより交通障害が発生し、ネットワーク全体が機能不全に陥る状況が発生している。国や地方自治体は、このような中で避難誘導や道路啓開、支援物資の運搬などを行う必要があり、これらを支援する仕組みを整備することが喫緊の課題と言えよう。

一方、マラソンなどの大規模なイベントや工事等による通行規制なども災害と同様に交通ネットワーク上に様々な問題を引き起こしている。これらは事前の検知と対策が十分に行われたとしても事故などの突発的な事象により、想定した運用が困難な状況に陥っている。このように、平常時から災害やイベント時などの非平常時、すなわち、異常な交通状態をすばやく把握することが可能となれば、適切かつ迅速な道路運用を行う上で有効と考える。そのためには、交通状態を常時モニタリングし、異常を検知する仕組みが必須となる。

道路ネットワーク上の交通モニタリングは、車両感知器や CCTV 画像等の固定計測データや GPS を活用したプローブ等の移動計測データなど様々なデータを活用して実施されている。そのような中、国土交通省では、2010 年より ETC2.0 プローブデータとして、車載器を搭載している車両の移動軌跡や運転挙動データを全国的に収集している。ETC2.0 の普及率は、2018 年時点で約 20% に達しており、地域や属性に偏りが存在するものの、時空間的に高い解像度で大量のデータが取得さ

れつつある。非平常時の交通状態を検出するためには、時々刻々と変化する交通状況をモニタリングできることが前提となる。しかしながら、これらのデータは、オンラインで即時利用可能な状況には現時点でなっていない。国土交通省関東地方整備局では、ETC2.0 プローブデータの車両通過情報のみをほぼリアルタイムで収集する仕組みを試行的に構築<sup>2),3)</sup>しているが、収集・蓄積したデータから異常を検知するようなシステムは実装されておらず、観測値と CCTV の双方を確認しながらマニュアルで運用されている。

以上を踏まえて、本研究では、ETC2.0 プローブ通過情報を活用して異常な交通状態を検出することを目的として、手法の検討ならびに実データへの適用を行う。具体的には、情報工学分野を中心に発展している異常検知の考え方を援用して、ETC2.0 プローブ通過情報の特徴に合致した手法を検討する。その上で、実データに試行的適用し、実務的な観点から有効性を検証する。これにより、災害時やイベント時の適切かつ効率的な交通運用の一助になる事が期待される。

## 2. 既往研究の整理およびデータの概要

はじめに、異常検知に関する整理と ETC2.0 プローブ通過情報の概要を示す。その上で、本研究で適用可能と思われる異常検知手法を選定する。

### (1) 統計的異常検知手法の整理<sup>4),5),6)</sup>

工学分野における異常検知とは、観測データに対して変化や異常を察知する方法論であり、ある閾値を超えた場合にアラートを鳴らすといったルールベースの方法から統計ベースの方法まで様々な既往研究が存在する。ここでは、大規模なデータへの適用を念頭に統計的異常検知に関する整理を行う。統計的異常検知とは、データ生成プロセスが確率モデル(確率分布)で表現可能であると仮定したアプローチであり、以下の2つのステップからモデリングが行われる。

**Step:1** 観測値からデータ生成過程の確率モデルを学習

**Step:2** 学習した確率モデルから異常度をスコアリング

以降では、上記の2つのステップに着目して既往手法の整理を行う。

はじめに、**Step:1** について、山西<sup>5)</sup> は観測値やデータ生成仮定、確率モデルの違いから異常検知を「外れ値検出」、「変化点検出」、「異常行動検出」の3つに分類している。外れ値検出は、多次元ベクトルを入力値として、正規分布などのパラメトリックな確率分布を学習し、観測値とモデルとの相対的な差異から特異なデータを検出する方法である。変化点検出は、多次元時系列データを入力値として、Auto-Regression (AR) モデ

ルなどの時系列モデルを学習し、時系列上に現れる変化を検出する方法である。最後に異常行動検出は、ユーザーの行動履歴を入力値として、マルコフモデルやベイジアンネットワークなどの行動モデルを学習して、なりすましや不審挙動などを検出する方法である。なお、これらを組み合わせた手法は集合型異常検知手法と呼ばれている。

次に、**Step:2** について、異常度の定義から「教師あり学習」と「教師なし学習」の2つに分類できる。異常検知の基本的な考え方は、「観測データには異常点もしくは区間が含まれていない、もしくは含まれていても圧倒的に少ない」という前提の下で異常度を以下のように定義する。

- 正常時に出現確率が高い観測値は異常度が低い
- 正常時に出現確率が低い観測値は異常度が高い

この考え方は、観測データが事前に正常か異常かに分類可能であり、両者の確率分布の違いから異常度が定義されることを意味している。すなわち、事前にラベルを貼った上で学習を行う教師あり学習に該当し、分布間の尤度比や密度比によって異常度を定量化している。一方、異常度をラベリングできない場合には、教師なし学習となり、異常度を以下のように再解釈する。

- 異常度が高い場合は得られる情報量が高い
- 異常度が低い場合は得られる情報量が低い

これは、情報量の観点から異常度を定義しており、Kullback-Leibler divergence などの情報量と距離から異常度を定量化する。なお、ラベルの有無に依らない密度比推定<sup>6)</sup>に基づく一般的な方法も近年提案されている。

### (2) ETC2.0 プローブデータの概要

ETC2.0 プローブデータは、国土交通省が2010年から整備を進めている大規模交通データであり、車両の移動軌跡や運転挙動データが取得可能である。しかしながら、データが収集されてからサーバー上でマップマッチング処理や経路情報等の付加情報の構築、個人情報の秘匿化処理が行われるため、利用するためには収集されてから数週間程度の時間を要する。これは、災害時やイベント時等による交通状況の変化を即時的に捉えることが困難であることを意味している。このような問題意識の下、国土交通省関東地方整備局では、時々刻々と変化する交通状況をリアルタイムで収集・活用することを目的として、ETC2.0 プローブ通過情報システムを構築している。具体的には、車載器が持つ固有 ID のみを収集・蓄積するシステムであり、検知器 (ITS スポットもしくは経路情報収集装置) が持つ RUS-ID 毎に、そこを通過した車両が持つ ASL-ID と通過時刻のみを収集し、5分単位で通過交通量を集計したデータである。これにより、既存の ETC2.0 プローブデータより

は情報量が劣るものの、計算コストの高い中間処理を必要としないため、概ね 5 分周期でデータを利用することが可能である。

ETC2.0 プローブ通過情報は「地点毎に通過交通量をほぼリアルタイムで利用可能」であることが最大の特徴であり、時系列での通過交通量データに分類される。ここから異常な交通状態を判定することが本研究の目的であるが、当該データを適用する上で留意すべき点が存在する。まず、機器トラブルによる異常値、具体的には、電源や改修等により観測が行われない状況や機器の何らかの問題により通過交通量を過大・過少に記録される状況が稀に見られる。本研究の関心である遮断による通過不能状態や通過交通量の異変と機器の問題による異変を完全には識別できないことに注意したい。なお、以降の分析では、過大な通過交通量については、普段の需要や交通容量から見て明らかに通過不可能な値（例えば 5 分間に 1000 台など）を削除し、機器改修等の実施情報などを踏まえて、可能な限りのデータクリーニングを実施して分析用データセットを作成した。

### (3) ETC2.0 プロブ通過情報の異常検知手法

これまでの整理を踏まえて、ETC2.0 プロブ通過情報に適用可能な異常検知手法を整理する。当該データは時系列データあり、異常を事前にラベリングすることが難しいことから「教師なし学習による変化点検出」に分類される。なお、異常ラベリングは不可能ではないが、異常ラベルの定義が難しく、定義できたとしてもラベルを貼るコストが非常に高いため、教師なし学習によるアプローチを前提とする。

既往研究では、回帰モデルや状態空間モデルを利用して時系列データを点列としてモデリングする方法、特異値スペクトル変換法のような時系列データを集約した部分時系列データに基づいてモデリングする部分空間法の 2 つに大別できる。本研究では、効率性（オンラインでの処理が実時間で可能）と適応性（データの性質が時間変化しても適応可能）の視点から、後者の特異値スペクトル変換法を ETC2.0 プロブ通過情報の異常検知アルゴリズムとして採用する。その理由として、前者のアプローチは、時系列モデルの予測値と観測値の差から異常度を導くものであるが、予測精度の高い時系列モデルを RUS-ID 毎に構築する必要があり、モデリングのコストが高い。くわえて、記述力の高いパーティクルフィルタなどのモデルを適用した場合には、計算量が膨大となりリアルタイム処理に適しているとは言いがたい。一方、後者のアプローチは、事前のモデル推定を必要とせず、処理速度も比較的高速であり、効率性と適応性にくわえて実務的にも適した手法であると判断した。

## 3. 特異値スペクトル変換法による異常検知

本章では、部分空間法の特徴である部分時系列データや特異値スペクトル変換法の定式化を示す。なお、定式化は、井出ら<sup>5)</sup>に準拠しており、より詳細は参考文献を参照されたい。

### (1) 部分時系列

時系列データに対する異常検知では、観測値  $x$  を個々に比較することをせずに部分時系列データに変換して扱うことが多い。ここでは、簡単のために 1 次元の時系列データについて部分時系列データの変換方法を示すが、多次元の場合でも本質的には同じである。以下に示すような長さ  $T$  の時系列データ  $\mathcal{D}$  について考える。

$$\mathcal{D} = [x^{(1)}, x^{(2)}, \dots, x^{(T-1)}, x^{(T)}] \quad (1)$$

ここで、 $x$  の添字は時刻を表している。この時系列データを  $M$  個の隣接した観測値にまとめたベクトルを新たに定義する。

$$\mathbf{x}^{(1)} \equiv \begin{pmatrix} x^{(1)} \\ x^{(2)} \\ \vdots \\ x^{(M)} \end{pmatrix}, \quad \mathbf{x}^{(2)} \equiv \begin{pmatrix} x^{(2)} \\ x^{(3)} \\ \vdots \\ x^{(M+1)} \end{pmatrix}, \quad \dots \quad (2)$$

$M$  はスライド窓と呼ばれる外生パラメータである。この操作は、時系列データを左から右に 1 つずつ移動させながら長さ  $M$  の時系列片を作ることを意味しており、最終的に時系列データ  $\mathcal{D}$  は  $N (= T - M + 1)$  本の  $M$  次元ベクトルに変換される。これらを並べたものが部分時系列データ  $\mathcal{D}'$  である。

$$\mathcal{D}' = [\mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \dots, \mathbf{x}^{(N-1)}, \mathbf{x}^{(N)}] \quad (3)$$

部分空間法では、部分時系列データを用いて、これらの特徴量を定義し、その差異から異常度を定義する。本論では、固有値に基づく特異スペクトルを利用した異常検知手法を適用する。

### (2) 特異値スペクトル変換法

時刻  $t$  周辺に対して、部分時系列データを過去側と現在側の 2 つの領域を設定する。過去側は  $t$  より以前の直近のデータで構成される履歴行列  $\mathcal{X}^{(t)}$ 、現在側は  $t$  以降のデータも含めたテスト行列  $\mathcal{Z}^{(t)}$  とそれぞれ呼ばれており、具体的には以下のように表される。

$$\mathcal{X}^{(t)} = [\mathbf{x}^{(t-n-M+1)}, \dots, \mathbf{x}^{(t-M-1)}, \mathbf{x}^{(t-M)}] \quad (4)$$

$$\mathcal{Z}^{(t)} = [\mathbf{x}^{(t-K+L-M+1)}, \dots, \mathbf{x}^{(t-M+L-1)}, \mathbf{x}^{(t-M+L)}] \quad (5)$$

ここで、 $L$  は履歴行列とテスト行列の相互位置、すなわちデータの重複を表しており、ラグと呼ばれる外生パラメータである。なお、履歴行列は  $n$  本、テスト行列




図-1 地点 A における 2ヶ月間の通過台数

は  $k$  本の部分時系列から定義されており、 $n$  と  $k$  も外生パラメータである。

設定した 2 つの領域について定量的な比較を行うために、これらの部分時系列データに何らかの特徴量を定義する必要がある。特異値スペクトル変換法では、その名前から分かるとおり、ここでは固有値分解（スペクトル分解）の概念に基づく特異値分解 (singular value decomposition: SVD) を適用する。両行列について特異値分解を行い、左特異ベクトルを求めて、履歴行列  $\mathcal{X}^{(t)}$  から上位  $r$  本、テスト行列  $\mathcal{Z}^{(t)}$  から上位  $m$  本を選ぶ。

$$\mathbf{U}_r^{(t)} = [\mathbf{u}^{(t,1)}, \mathbf{u}^{(t,2)}, \dots, \mathbf{u}^{(t,r)}] \quad (6)$$

$$\mathbf{Q}_m^{(t)} = [\mathbf{q}^{(t,1)}, \mathbf{q}^{(t,2)}, \dots, \mathbf{q}^{(t,m)}] \quad (7)$$

上記の式 (6) と式 (7) に示す履歴行列とテスト行列の上位の特異値を用いて、時刻  $t$  における変化度は以下のように定義される。

$$a^{(t)} = 1 - \|\mathbf{U}_r^{(t)T} \mathbf{Q}_m^{(t)}\|_p \quad (8)$$

ここで、 $\|\cdot\|_p$  はベクトルに対する  $p$  次ノルムであり、既往研究では  $p = 2$  のユークリッドノルムを仮定した値を変化度する場合が多い。なお、別のノルム (KL のように距離の性質を厳密には満たさない場合もある) や 2 乗ノルムを用いる文献もあり、データの特性などを踏まえて分析者が設計することが可能である。変化度は、0 から 1 の間で定義されるスカラーであり、直感的にもわかりやすい指標となっている。実際のシステムでは、変化度がある閾値  $\epsilon$  を超えた場合を時刻  $t$  で異常が生じたと仮定してアラート処理を行うことが多い。

## 4. 実データを用いた手法の適用と検証

### (1) データ概要

本研究では、2017 年 4 月 1 日から 5 月 31 日の 2 ヶ月間に関東地方整備局管内の高速道路および国道上に設置された全センサーで収集された ETC2.0 プローブ通過情報を用いた。このデータには、5 分毎で集計した通過台数が記録されており、データ件数は 2 ヶ月の 17568 件であった。以降では、高速道路上に設置された地点 A(仮称) について試算を行った。

地点 A で観測された通過台数を時系列プロットしたものを図-1 に示す。図上段は、2 ヶ月間のデータをプロットしたものであるが、週と日で周期性が存在していることが確認できる。また、GW 期間 (4 月 29 日から 5 月 7 日) では、通過台数が平日の半分程度に減少していること、平日であった 5 月 1 日と 2 日は普段と同程度の通過があったことが分かる。4 月 13 日 (金) 5:05~6:50 と 5 月 5 日 16:40~17:40 では、通過台数が連続してゼロを記録しているが、これは機器に関する問題が発生していたことを確認している。図下段には、上段の図からある週と日の通過台数を抽出してプロットしたものを示している。週 (4 月 1 日 (土) から 4 月 8 日 (日)) の図より、土日に交通量が減少し、平日は曜日での違いはさほど見られないことが確認できる。また、日 (4 月 13 日 (金)) の図より、朝から通過台数が増加して、夕方 17 時頃から深夜にかけて通過台数が減少する傾向が見られる。なお、ここには、機器異常により通過交通量がゼロを記録している様子が確認できる。




図-2 特異値スペクトル変換の適用結果 ( $M = 36, m = r = 2$ )

**(2) 異常検知の適用**

同じく地点 A に対して、特異値スペクトル変換法を適用した結果を図-2 に示す。外生パラメータとして、スライド窓サイズ  $M$  を 36 (3 時間)、履歴行列とテスト行列の本数  $n$  と  $k$  を同じ  $M/2$ 、ラグ  $L$  を  $n/2$ 、特異ベクトルの本数  $r$  と  $m$  を同じ 2 とした結果である。赤色で示した変化度の動きを見ると、全体的には前後で何らかの変化が生じている時点を検出していることが確認できる。変化度が最も高いところは、5 月 5 日の機器の問題により複数回のゼロを記録した時点であった。なお、同様の事例が 4 月 13 日にも発生しているが、こちらについては、5 月 5 日ほど大きく異常度が上昇しておらず、この異常を十分に捉えられていないと思われる。また、週末と GW で高い変化度が見られ、この傾向から週と日の周期的な変化や休日の変化を捉えられていると思われる。

**(3) パラメータの感度分析**

ここでは、スライド窓サイズ  $M$  と特異ベクトル数  $r$  と  $m$  に着目して感度分析を行う。なお、履歴行列とテスト行列の本数とラグは上記の結果と同じ値を設定した。

まず、スライド窓に関する感度分析の結果を図-3 に示す。ここでは、特異ベクトルの本数は  $r = m = 1$  として最大特異値のみを利用している。図は上から  $M = 12$ (1 時間),  $M = 72$ (6 時間),  $M = 288$ (24 時間) の結果を示している。 $M = 2$  では、機器異常でゼロを記録した日時のみで変化度が高い。 $M = 72$  では、図-2 の  $M = 36$  と同様な傾向が見られるが、日変動が卓越しているように思われる。 $M = 288$  では、週変動を捉えているが、変化度は全体的に高く、相対的な差が小さくなっている。

次に、特異ベクトルの本数に関する感度分析の結果を図-3 に示す。スライド窓は  $M = 36$  に固定している。図は上から  $r = m = 1, 2, 3$  の結果を示している。全体として、 $M = 288$  のような異常度が全体的に高くなる傾向は見られない。1 の時は  $M = 12$  と同様に機器異常を検出しており、2 の時では GW の影響、3 の時では 2 の結果に週変動が加わっているような様相が確認できる。

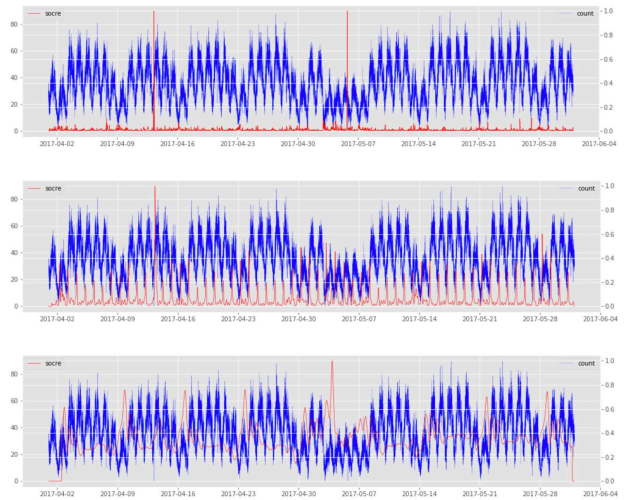


図-3 スライド窓  $M$  の感度分析




図-4 特異ベクトル数  $r = m$  の感度分析

**(4) 結果の考察**

特異値スペクトル変換法を適用した結果、時系列上での変化点を検出することには成功していると思われる。しかしながら、感度分析の結果を踏まえると、外生パラメータの値で捉えられる変化が異なると考えら

れる。スライド窓のサイズは、 $M$  が小さいほど急激な変化、大きいほど周期的な変化を捉えているように思われる。これは、 $M$  が大きいほど部分時系列データが増加するため、特徴量である最大特異ベクトルが相対的に小さくなるためと考えられる。また、特異ベクトルの数は、増えるほど様々な変化が捉えられるようになると思われる。特異ベクトルは、直交する特異値を大きい順に並べたものであり、多様な特徴が反映されると考えられる。今回はこの 2 つのパラメータについて感度分析を行ったが、他のパラメータについても検証が必要である。例えば、 $M$  を小さくした際には、履歴行列とテスト行列の本数  $n$  と  $k$  を増やすことにより、周期的な変化が特異ベクトルに反映されやすくなると考えられる。

特異値スペクトル変換法の性能について、簡単であるが幾つかの考察を示す。適応性については、モデル構築やパラメータ推定が必要なく、データから特徴を抽出して検知を行うため、導入コストが低く、柔軟と言える。しかしながら、外生パラメータが性能にダイレクトに影響するため、現象を踏まえて慎重に設定する必要がある。また、手法の効率性については、詳細は割愛するが、特異値分解が素朴な実装ではスライド窓サイズ  $M$  について 3 乗オーダーの計算量となるため、 $M$  が全体の計算時間に大きく寄与する。しかしながら、1 回あたりの計算時間を計測した結果、数秒程度に留まるため、数百箇所のある RUS-ID 毎にオンラインで計算を実施しても ETC2.0 プローブ通過情報の更新周期より早いと運用上は問題ないと考えられる。なお、地点数の増加に対して計算時間はたかだか線形でしか増加しないスケラビリティを有しているため、地点毎にデータ並列処理を実装することで高速化が期待できる。

## 5. おわりに

### (1) 本研究の成果

災害やイベントなどの非平常時のリアルタイム異常検知を目的として、ETC2.0 プローブ通過情報から異常な交通状態を検知するシステムを構築した。既往研究およびデータの特徴を整理から、特異値スペクトル変換法が有効な手法であると考えて、関東圏における 2 ヶ月分の実データに適用した。その結果、検討手法は当該データの変化点検知に対して適用可能であることが示された。これにより、リアルタイムモニタリングによる交通状況の変化が自動的に捉えられる可能性を確認でき、道路運用の一助となることが期待される。しかしながら、感度分析から、外生パラメータの設定によって結果が変化することが確認されたため、引き続きの検討が必要である。

### (2) 今後の課題

本研究は、ETC2.0 プローブ通過情報によるリアルタイム異常検知の可能性を示すことに成功したが、実適用に向けてさらなる検討が必要である。以下に今後の課題を幾つか示す。

- 外生パラメータについて、引き続きの検証が必要であり、特に未検証である履歴行列とテスト行列の本数とラグについて感度分析して傾向の把握を行いたい。くわえて、検証したパラメータについても範囲を拡張して深度化を図る。
- 本研究が狙いとしている非平常時の検出をより精度高く行うために、実際の災害時や突発事象の発生時との比較・検証を行いたい。そのためにも改めて捉えるべき異常を明確にする必要がある。
- 教師なし学習である特異値スペクトル変換法を適用したが、他の手法との比較から、より適切な方法を選択できるようにしたい。
- 今回は 1 地点での適用であるため、異なる地点での適用と性能を把握したい。また、地点毎に前後のデータとの相関性が存在するため、センサ間のグラフ構造を仮定し、その変化を記述するような方法を検討したい。

謝辞：本研究は国土交通省関東地方整備局および道路経済戦略会議関東地方研究会の協力のもと実施したものである。また、本検討の一部は、国土交通省・新道路技術会議（特定課題：ETC 2.0 を含む多様なビッグデータ活用）「ETC 2.0 プローブ情報等を活用した“データ駆動型”交通需要・空間マネジメントに関する研究開発」（平成 28 年採択）のもと実施したものである。ここに謝意を表します。

### 参考文献

- 1) 内閣府: 過去 5 年の激甚災害の指定状況一覧, <http://www.bousai.go.jp/taisaku/gekijinhukko/list.html> (2019 年 3 月 7 日閲覧)。
- 2) 間宮義満, 外川和彦, 菅原宣治, 鯉淵正裕, 柳沼秀樹: ETC 2.0 ITS スポット通過情報を活用したリアルタイム道路交通状況把握手法の確立, 土木計画学研究・講演集, Vol.55, 2017。
- 3) 松崎暁, 松山隆雄, 吉田幸男, 関口広喜, 山本伸之, 日下部貴彦: ETC 2.0 を活用した高速バスロケーションサービスのプロトタイプの開発, 土木計画学研究・講演集, Vol.55, 2017。
- 4) 井出剛, 杉山将: 異常検知と変化検知, 講談社, 2015。
- 5) 山西健司: データマイニングによる異常検知, 共立出版, 2009。
- 6) Sugiyama, M., Suzuki, T. and Kanamori, T.: Density Ratio Estimation in Machine Learning, Cambridge University Press, 2012。

(2019. 03. 10 受付)

TRAFFIC ANOMALY STATE DETECTION USING REAL TIME ETC 2.0 PROBE  
PASSEGE INFOMATION DATA

Hideki YAGINUMA, Takahiko KUSAKABE, Daisuke FUKUDA, Masahiro  
KOIBUCHI, Kaori TAKAHASHI, Tetsuji TAIRA and Takashi INOUE