

状態空間モデルによる事故発生時の 交通流率の推定手法の構築

川崎 洋輔¹・梅田 祥吾²・桑原 雅夫³・熊倉 大起⁴・大畑 長⁵・
田中 淳⁶・南 航太⁷・鈴木 裕介⁸

¹正会員 東北大学助教 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: kawasaki-y@plan.civil.tohoku.ac.jp

²正会員 東北大学研究員 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

³正会員 東北大学教授 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: kuwahara@plan.civil.tohoku.ac.jp

⁴正会員 (株)オリエンタルコンサルタンツ (〒151-0071 東京都渋谷区本町3-12-1)
E-mail: kumakura-di@oriconsul.com

⁵正会員 (株)オリエンタルコンサルタンツ (〒151-0071 東京都渋谷区本町3-12-1)
E-mail: ohhata@oriconsul.com

⁶正会員 (株)オリエンタルコンサルタンツ (〒450-0003 名古屋市中村区名駅2-14-19)
E-mail: tanaka-at@oriconsul.com

⁷非会員 首都高速道路(株) (〒221-0013 神奈川県横浜市神奈川区新子安1-2-4 (オルトヨコハマ・ビジネス
センター 3F))
E-mail: k.minami613@shutoko.jp

⁸正会員 首都高速道路(株) (〒100-8930 東京都千代田区霞が関1-4-1 (日土地ビル))
E-mail: y.suzuki1472@shutoko.jp

本研究では、状態空間モデルによる事故発生時の交通流率の推定手法を提案する。交通管制では、事故発生時の交通流率を把握することが重要である。首都高速道路では、車両感知器を密に配置しているため、事故発生時の交通流率が把握できる。しかし、全ての車両感知器を維持管理するには、コスト面で課題がある。一方、大量のプローブデータが、取得されており、活用法が模索されている。今後は、プローブデータを活用することで、現状の車両感知器を減らし、合理化を図ることが望ましい。しかし、プローブデータは、交通量の把握ができない。よって、本研究では、車両感知器、プローブデータおよびvariational theoryを用いた状態空間モデルを構築し、交通流率の推定を試みる。検証の結果、交通流率を精度よく推定することが出来た。

Key Words : traffic flow, variational theory, state-space model, traffic accident, probe data

1. はじめに

本研究では、状態空間モデルを用いた事故時の交通流率の推定手法を提案する。

首都高速道路には、車両感知器が密に配置されており、緻密な交通モニタリングが行われている。しかし、車両感知器は、メンテナンスの手間や費用がかかるといった維持管理のコスト面で課題がある。一方、ETC2.0等のプローブデータが、日々、取得されており、交通管制への活用法が模索されている。よって、今後は、プローブデータと車両感知器を活用し、現状の車両感知器数を減ら

し、合理化を図ることが望ましいと考える。

これまで、交通流モデルの解法の一つであるvariational theory (VT)¹⁾を活用して車両感知器とプローブデータの融合による交通状態推定手法が研究されている²⁾³⁾。しかし、既往研究では、平常時の交通流を対象にしており、事故時は対象としていない。既往のVTをそのまま事故発生時の交通流に適用してもよい推定精度は得られない。その理由を以下に述べる。VTでは、時空間上のFD (Fundamental diagram)が一定という仮定の下、交通状態を推定している。一方、事故時は、車線閉塞等により、事故地点の交通流率が低下するため、FDの形状が変化する。

VTでは、こうしたFDの時系列変化を考慮できないため、FD形状がモデルと実際の交通流で乖離し、推定精度が低下する。

本研究では、上記の課題解決のために、VTを状態空間モデルに拡張し、FDの時系列変化を捉えることで、事故発生時の交通流率の推定を試みる。




図-1 時空間ネットワーク

2. 既往研究

本章では、既往研究として、Variational theoryによる交通状態推定と状態空間モデルによる交通状態推定およびセンシングデータを用いた事故時の交通解析に関する研究を整理する。最後に既往研究を踏まえた本研究の意義を述べる。

(1) Variational theory による交通状態推定

まず、Daganzo¹⁾により提案されたVTの概要を以下に述べる。VTで用いる区分線形FDを定義する。区分線形FDを ϕ と表記する。 $\phi = (q_{\max}, v, w)$ は、以下に示すパラメータを持っている。

- v = forward wave スピード
- w = backward wave スピード
- q_{\max} = 最大交通流率

次に、時空間ネットワークを定義する。VTでは、図-1に示すようにタイムスペース上に $\Delta t \times \Delta x$ の大きさの区分線形FDを敷き詰めた時空間ネットワークを用いる。以降、時空間ネットワーク上のFDの交点をノード、辺をリンクと呼ぶ。リンクは、図-1の矢印に示すような有方向リンクでありforward waveに沿ったリンク l_f (図中青色)、backward waveに沿ったリンク l_b (図中赤色)の2種類で構成される。VTによる交通状態推定法を以下に述べる。VTは、最短経路探索により、時空間ネットワークの境界条件とリンクコストを用いて、任意のノードの累積交通量を推定する手法である。 l_f のコストを C_f 、 l_b のコストを C_b と表記すると、 C_f, C_b は、

$$C_f = 0 \quad (1a)$$

$$C_b = k_{jam} \cdot \Delta x = q_{\max} \cdot \Delta t \quad (1b)$$

とかける。式(1)より、リンクコストは、 q_{\max} と Δt がパラメータである。時空間上で累積交通量が既知のノードを境界ノードと定義する。時空間上の累積交通量が不明な任意のノード i に到達可能な境界ノード m のインデックス集合を Ω_i と定義する。 N_i と $N_m, m \in \Omega_i$ をノード i と m の累積交通量と定義する。ノード i とノード m 間の累積交通量の変化量を Z_{mi} とする。variational theoryによると、累

積交通量 N_i は、以下のように示される。

$$N_i = \inf\{N_m + Z_{mi}\}, \forall i, m \in \Omega_i \quad (2)$$

ここで、 Z_{mi} はノード m からノード i 間の最短経路コストで与えられる。累積交通量が不明な全てのノードに対して、式(2)を実行すれば累積交通量が推定できる。

次にVTの拡張に関する研究を整理する。VTは、信号やセンシングデータ(e.g.車両感知器データ、プローブデータ)を境界条件に組み込むことが可能であり、その条件下で時空間上の累積交通量を解析的に推定できる。しかしながら、VTでは、区間途中の流出入交通を考慮できない。VTを拡張して区間途中の流出入を考慮した研究にMehran et al.²⁾やMehran and Kuwahara³⁾が存在する。これらの研究では、流出入が既知(観測可能)の場合に時空間上の累積台数を修正する手法を提案している。その他、Takayasu and Kuwahara⁴⁾は、VTの境界条件の変動が、累積交通量の推定結果に与える感度を分析した。これらの研究は、VTを決定論的なモデルとして扱っており、本研究のように変数を確率的に扱う状態空間モデルには拡張していない。

(2) 状態空間モデルによる交通状態推定

本節では、VT等の交通流モデルを状態空間モデルに拡張し、交通状態推定を行っている既往研究を整理する。ここで、状態空間モデルとは、観測データによりシミュレーションモデルの状態量を改善するモデルである²⁾。システムモデルと観測モデルで構成される。システムモデルとは、決定論的なシミュレーションモデルを確率的に拡張したモデルである。観測モデルは、システムモデルの状態量と観測データの関係性を記述したモデルである。以降に状態空間モデルによる交通状態推定に関する研究を整理する。

Work et al.⁵⁾は、高速道路を対象にCTM-vとプローブデータ(GPS)を使用して状態空間モデルを構築することにより、区間速度を推定した。Herrera and Bayen⁶⁾は、ナッジングとカルマンフィルタリングという2つのデータ同化

方法を提案した。その後、カリフォルニア州の高速道路で携帯電話のデータと次世代シミュレーション(NGSIM)データを使用して、両方の手法を検証した。Allströma et al.⁷⁾は、BluetoothデータとCTM-vモデルを使用したアンサンブル・カルマンフィルタに基づく同化手法を提案した。提案された手法は、いくつかのオンランプとオフランプがある高速道路で検証された。Yuan et al.⁸⁾は、カルマンフィルタの枠組みを採用し、交通流の変形式のシステムモデルとプローブ車両データおよび車両感知器データを使用したモデルを提案した。このモデルは、1kmの単路部区間に適用され、Newellの追従モデルとの良好な一致を示しつつ、より高い操作性を実現した。Nate et al.⁹⁾は、車両感知器とBluetoothデータを使用して、拡張カルマンフィルタにより信号交差点を備えた一般道をリアルタイムに交通状態推定するモデルを提案した。Jiang et al.¹⁰⁾は、拡張したTreiber-Helbingフィルタを用いて、プローブデータと車両感知器データを融合することにより、都市高速道路の交通状態と排気ガスの排出量を推定した。Canepa and Claudel¹¹⁾は、センシングデータを使用したLWRモデルに基づくデータ同化方法を提案した。データ同化を混合整数計画問題として定式化し、高速道路の交通密度を推定した。Xie et al.¹²⁾は、信号のある都市内の一般道の車両軌跡を推定するためのデータ同化フレームワークを提案した。そのフレームワークは、粒子フィルタ¹³⁾を使用して、様々なセンシングデータ(e.g. 車両感知器データ、交通信号の現示および旅行時間の測定値)をマイクロな交通シミュレーションモデルに同化した。Kawasaki et al.¹⁴⁾は、VTを状態空間モデルに拡張し、粒子フィルタによりFDの揺らぎを解析しました。また、VTベースの状態空間モデルで区間途中の流入入台数を試みた研究(川崎ら¹⁵⁾)もある。これら状態空間モデルによる交通状態推定に関する研究の中には、交通状態に加えて、モデルパラメータを推定することを試みた研究がある(e.g. Wang et al.¹⁶⁾, Sun et al.¹⁷⁾, Kawasaki et al.¹⁸⁾)。Kawasaki et al.は、CTMと経路選択モデルおよびプローブデータを用いて、2次元ネットワークの交通状態を推定する状態空間モデルを提案している。また、自己組織化状態空間モデル¹⁹⁾の枠組で、モデルを拡張し、交通状態とパラメータ(FD, 経路選択モデル, OD需要)の推定を試みている。このように状態空間モデルの研究は多数、存在する。しかし、上記の研究は、全て平常時の交通流を対象にしており、事故等の突発事象時の交通流は対象にしている。

(3) センシングデータを用いた突発事象時の交通分析

本節では、センシングデータを用いた事故等の突発事象時の交通解析に関する研究を整理する。

車両感知器データを用いた交通異常検出を試みた研究はいくつかある(e.g. Cullip et al.²⁰⁾, Kawasaki et al.²¹⁾)。Kawasa-

ki et al.は、平常時と事故時の交通量、オキュパンシーおよび車線別速度等を分析した。その結果、事故時は、臨海流(自由流と渋滞流の狭間)で発生していることを明らかにした。また、事故時の交通流の特徴量から事故発生直前の交通流(事故の予兆)を検出するための閾値を提案している。このように事故地点に車両感知器が設置されていれば、事故発生前後の交通流の解析が可能である。本研究では、車両感知器がない地点において、プローブデータによる交通流率の推定を試みる。

次に、プローブデータを用いた突発事象時の交通分析に関する研究を述べる。プローブ軌跡データを用いた事故発生地点の検出に関する研究に関塚ら²²⁾やAsakura et al.²³⁾がある。どちらも、交通障害発生時の時空間上の車両軌跡の変曲点間をつないだ衝撃波面に着目し、事故発生地点(時間と場所)を推定している点が共通している。プローブデータをクラスタリングするアプローチで異常検出を行っている研究にCai et al.²⁴⁾や日下部²⁵⁾がある。Cai et al.は、予め交差点付近で観測された平常時と異常挙動の車両軌跡が属するクラスタを構築し、新たに得られた軌跡が異常挙動のクラスタに分類された時、その軌跡を異常挙動軌跡として検出している。日下部は、第3次メッシュ(1km四方)を最小単位とし、メッシュごとの平均旅行時間を各日・時間帯ごとのベクトルとして作成している。そのベクトルに対して、メッシュごとにk-means++法を用いたクラスタリングを行い、異常が生じたメッシュや日時を特定している。これらの研究の目的は、事故地点の検出や異常軌跡の検出であり、事故発生地点の交通流率の推定は行っていない。

(4) 本研究の意義

既往研究を踏まえ、本研究の意義を述べる。

- 1) プローブデータは、移動体データであり、かつ、サンプルのため、事故地点の交通流率の把握が出来ない。本研究は、VTを拡張し、プローブデータを用いて、事故地点の交通流率を推定する状態空間モデルを提案した。交通管制では、情報提供や交通制御の前に、まず、交通状態を把握することが重要である。したがって、本研究は、交通管制技術の発展への貢献が期待される。
- 2) モデル検証の結果、提案モデルは、車両感知器と同程度の精度で事故時の交通流率を推定できた。提案したモデルを用いれば、事故地点に車両感知器がなくても交通流率を把握できる可能性がある。したがって、本研究は、今後の車両感知器の合理化(現状の車両感知器を間引くこと)への貢献が期待される。

3. 事故発生時の交通流率推定の問題設定と手順

本章では、問題設定の定義と事故発生時の交通流率を推定する手順を述べる。

(1) 問題設定

まず、本研究で取り組む問題を以下に定義する。本研究では、前提条件として、以下の状況を仮定する。

- ・ 高速道路の単路部区間を対象とする。
- ・ 対象区間は、FIFO(First-In-First-Out)を仮定する。すなわち、区間途中の流出入 (e.g. IC) および追い越しはないと仮定する。
- ・ 区間上下端に車両感知器が設置されており、欠損なくリアルタイムに交通量が観測される。
- ・ プローブ車両軌跡データがリアルタイムに観測される。

上記の下、本研究では、区間途中で発生した事故発生地点の交通流率を推定する問題を定義する。

(2) 交通流率の推定手順

図-2に示すような事故発生時のタイムスペース図を考える。タイムスペース図の下段は、 a - a' 断面の交通流率の変化を示している。図中の $a(t_0, x_0)$ は、事故発生地点(車線閉塞開始点)、 $a'(t_1, x_0)$ は、車線閉塞終了地点を示している。同図に示すように事故発生地点 a - a' の断面で車線閉塞により交通流率が低下し、渋滞が発生する。渋滞発生に伴い、図-2下段のように交通流率 q_{max} が、平常時の交通流率 q_{max}^n から事故時の交通流率 q_{max}^a に低下する。本研究では、この事故地点の交通流率 q_{max} の時系列変化を推定することを目的とする。以上を踏まえ、本研究では、事故地点の交通流率推定は、以下の2ステップで推定することを提案する。

- 1) 事故発生点 $a(t_0, x_0)$ の推定
- 2) 事故発生断面(a - a')の交通流率の推定

なお、本稿では、ステップ1)で推定する事故発生地点 $a(t_0, x_0)$ を所与とし、ステップ2)の事故時の交通流率の推定法の構築に焦点をあてる。

4. 状態空間モデル

本章では、VT を状態空間モデルに拡張し、事故時の交通流率を推定する手法を定式化する。

(1) 状態ベクトル

最初に、状態ベクトルのタイムステップを定義する。タイムステップを $1, 2, \dots, t-1, t, t+1, \dots$ で表記する。タイ




図-2 事故発生時のタイム・スペース図




図-3 タイムステップの設定例

ムステップ t におけるシステムモデルの推定対象時間の区間を $[T-1, T]$ 、タイムステップの時間幅を ΔT と定義する。タイムステップ t の状態ベクトルは、 $[T-1, T]$ の時空間に存在するノードの累積交通量の集合ベクトル $\mathbf{N}(t)$ と定義する。 $\mathbf{N}(t)$ の詳細を以下に述べる。 $[T-1, T]$ の時空間に存在するノードのインデックスを $i = \{1, 2, \dots, I\}, i \in A$ と表記する。以上より、タイムステップ t の状態ベクトルを下式で定義する。

$$\mathbf{N}(t) = (N_1(t), N_2(t), \dots, N_i(t), \dots, N_I(t))^T, i \in A, \forall t \quad (3)$$

ここで、状態ベクトルは、全てのタイムステップで要素数を同数 ($|\mathbf{N}(t)| = |\mathbf{N}(t-1)|, \forall t$) とし、各要素の時間進展を記述できるようにする必要がある。なお、本稿では、 $|\cdot|$ は、ベクトル “ \cdot ” の要素数を意味する。要素数が異なる場合 ($|\mathbf{N}(t)| \neq |\mathbf{N}(t-1)|$)、タイムステップ毎の状態ベクトルの要素の対応が出来ないため、マルコフ性を満たせない。したがって、タイムステップ幅 ΔT は、タイムステップ毎のノード構成(位置、ノード数)が等しくなるように設定する必要がある。この条件を満たすには、時空間ネットワークの FD の時間幅 Δt に整合する

ように $\Delta T = n\Delta t$ と設定すればよい。ここで、 n は自然数である。 n は、 v, w の比率に応じて、 y 軸方向に整数個の FD が収まるように設定すればよい。例えば、図-3 のように $v:w=2:1$ ネットワークの場合を考えよう。図では、 $n=1(\Delta T = \Delta t)$ としている。縦軸方向には、3つの FD が積みあがった状況である。図中のノード内の番号は、時刻に対応する。この場合、縦軸方向に3つの FD を積み上げれば、底辺の FD と4段目の FD の密度0の x 座標が一致するので、 ΔT ごとに同じパターンが繰り返される。なお、 $v:w$ の比率の値が整数の場合、 $n \geq 1$ であれば $|\mathbf{N}(t)| = |\mathbf{N}(t-1)|, \forall t$ を満たす。その他、 $v:w=3.5:1$ のように比率が整数値でない場合は、縦軸方向に FD が整数個($v:w=3.5:1$ の場合 9 個)収まるように1セットを定義し、 $\Delta T = 2 \cdot \Delta t$ と設定すればよい。

(2) 観測ベクトル

タイムステップ t の観測ベクトルは、 $[T-1, T]$ に観測されるノードの累積交通量の集合ベクトル $\hat{\mathbf{N}}(t)$ および交通流率 $\hat{q}_{\max}(t)$ の集合と定義する。観測ベクトルの詳細を以下に述べる。まず、ノードの累積交通量 $\hat{\mathbf{N}}(t)$ の観測方法を述べる。図-4 に示す区間上流端に車両感知器が設置されたネットワークを例に累積交通量の観測方法を述べる。図に示すように $[T-1, T]$ では、ノード $i, i+1$ の2つのノードを通過するプローブ車両 j が観測されている。あわせて、車両感知器によって、プローブ車両 j に最も近いノードの累積交通量 \hat{N}_j が観測されている。前述したように本研究は、FIFO を仮定しているため、プローブ軌跡上の累積交通量は変化しない。よって、 $[T-1, T]$ では、車両感知器とプローブ軌跡により、ノード $i, i+1$ の累積台数 $\hat{N}_i(t) = \hat{N}_{i+1}(t) = \hat{N}_j$ が観測される。 $[T-1, T]$ において観測されるプローブ軌跡上のノードのインデックス集合を $\hat{\Lambda}(t) \in \Lambda$ と定義する。以上より、タイムステップ t に観測される累積交通量の集合ベクトルを下式で定義する。

$$\hat{\mathbf{N}}(t) = (\dots, \hat{N}_i(t), \dots)^T, i \in \hat{\Lambda}(t) \in \Lambda, \forall t \quad (4)$$

次に、交通流率 $\hat{q}_{\max}(t)$ の観測方法を述べる。交通流率は直接観測されるのではなく、プローブデータとFDを用いて推定される。対象区間でプローブデータが観測され、Edie²⁶⁾が提案した空間平均速度 $\hat{v}_A(t)$ が得られたことを考えよう。観測交通流率は、図-5に示すように空間平均速度 $\hat{v}_A(t)$ の傾きの直線とFDの交点から得られる。なお、 $\hat{v}_A(t) > v$ の場合は、FD上では、解が一意に決定




図-4 累積交通量の観測方法




図-5 交通流率の観測方法

されない。事故によるボトルネックの容量を観測することが目的のため、ボトルネック以外(自由流)は、便宜上、ボトルネック容量よりも大きな値を設定したほうがよい。よって、 $\hat{v}_A(t) > v$ の場合は、最大交通流率 q_{\max} が観測されると仮定する。以上より、 $\hat{q}_{\max}(t)$ は、

$$\hat{q}_{\max}(t) = \begin{cases} \text{if } \hat{v}_A(t) > v, & q_{\max} \\ \text{else,} & \{k_{jam} / (1 + \hat{v}_A(t) / w)\} \cdot \hat{v}_A(t) \end{cases} \quad (5)$$

と定義する。ここで、 k_{jam} はジャム密度であり、 ϕ のパラメータで算定可能($k_{jam} = q_{\max} / v + q_{\max} / w$)である。式(4),(5)より、観測ベクトル $\mathbf{Y}(t)$ を下式で定義する。

$$\mathbf{Y}(t) = (\hat{\mathbf{N}}(t), \hat{q}_{\max}(t))^T, \forall t \quad (6)$$

(3) グラフィカルモデル

本研究が仮定する状態空間モデルのグラフィカルモデルを図-6に示す。同図に示すようにFD ϕ のパラメータである v, w を所与、 q_{\max} を時系列変化する確率変数と仮定する。よって、FD ϕ も確率変数となる。 $\mathbf{N}_B(t)$ は、タイムステップ t におけるVTに入力する境界条件(e.g. 上下端の車両感知器による交通量)である。状態空間モデルでは、観測される交通流率 $\hat{q}_{\max}(t)$ および観測累積交通量 $\hat{\mathbf{N}}(t)$ によりVTによる状態ベクトル $\mathbf{N}(t)$ およびパラメータ q_{\max} のフィルタリングを行い、推定結果の改善を図る。フィルタリングとは、観測ベクトルが与えら

れた下で状態ベクトルの事後分布を推定することである。**図-7**を例にタイムステップ t における累積交通量の推定値 $\mathbf{N}(t)$ と観測値 $\hat{\mathbf{N}}(t)$ の関係を説明する。図に示すノード i の累積交通量の推定値と観測値の関係を考えよう。タイムステップ t では、 $t-1$ に実行されたシステムモデルにより区間 $[T-2, T-1]$ の累積交通量 $\mathbf{N}(t-1)$ が推定されている状況である。タイムステップ t において、ノード i に到達可能な境界ノード m のインデックス集合を $\Omega_i(t)$ と定義する。式(2)より VT によるノード i の累積交通量は、

$$N_i(t) = \inf\{N_m(t) + Z_{mi}(t)\}, \forall i, m \in \Omega_i(t), \quad (7)$$

$$N_m(t) \in \{N(t-1), N_B(t)\}$$

とかける。ここで、 $N_i(t), N_m(t)$ はタイムステップ t におけるノード m, i の累積交通量である。 $Z_{mi}(t)$ は、ノード m と i 間の累積交通量の変化量である。システムノイズと観測ノイズがない (ノイズ=0) と仮定すると、推定値 $N_i(t)$ と観測値 $\hat{N}_i(t)$ は一致する。しかし、事故発生時は、車線閉塞による q_{\max} の時系列変化やノイズにより、推定値と観測値に乖離が生じる。状態空間モデルでは、観測値を用いてフィルタリングすることで、推定結果と観測値の乖離を減少させる。

(4) システムモデル

本節では、システムモデルを定義する。まず、確率変数である FD をモデル化する。**図-6** のグラフィカルモデルの仮定より、FD は、

$$q_{\max}(t) = q_{\max}(t-1) + \omega(t), \forall t \quad (8a)$$

$$\phi(t) = (q_{\max}(t), v, w), \forall t \quad (8b)$$

とかける。 $\omega(t)$ はシステムノイズである。境界条件、FD を引数とし、累積交通量が不明な全てのノード i に対して、式(7)の処理を行い、累積交通量を推定する関数を $f_{iT}(\cdot)$ と定義する。**図-6** のグラフィカルモデルの仮定および式(8)より、システムモデルは、

$$\mathbf{N}(t) = f_{iT}(\mathbf{N}(t-1), \mathbf{N}_B(t), \phi(t)) + \boldsymbol{\tau}(t), \forall t \quad (9a)$$

$$\boldsymbol{\tau}(t) = (\tau_1(t), \tau_2(t), \dots, \tau_i(t), \dots, \tau_l(t))^T, i \in \Lambda, \forall t \quad (9b)$$

とかける。ここで、 $\mathbf{N}_B(t)$ は、タイムステップ t における境界条件であり、 $\boldsymbol{\tau}(t)$ はシステムノイズである。

(5) 観測モデル

本節では、観測モデルを定義する。観測ベクトルは、(3)節で定義したプローブ軌跡上のノードの累積交通量

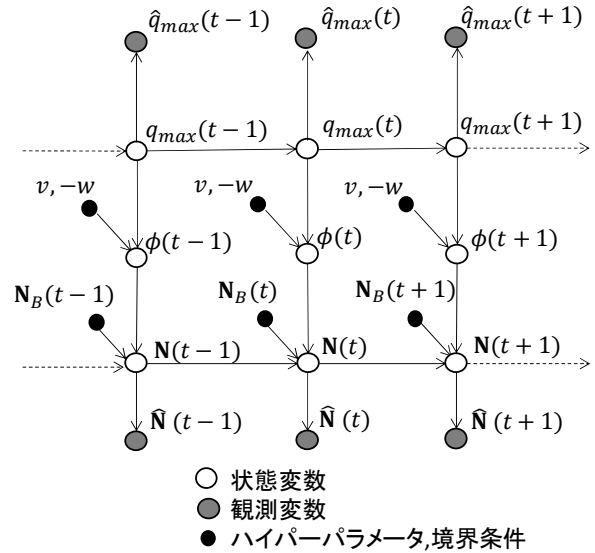


図-6 グラフィカルモデル




図-7 累積交通量の推定

と交通流率である。**図-6** のグラフィカルモデルの仮定より、観測モデルを、

$$\hat{\mathbf{N}}(t) = \mathbf{H}(t)\mathbf{N}(t) + \boldsymbol{\xi}(t), \forall t \quad (10a)$$

$$\boldsymbol{\xi}(t) = (\dots, \xi_j(t), \dots), j \in \hat{\Lambda}(t), \forall t \quad (10b)$$

$$\hat{q}_{\max}(t) = q_{\max} + \gamma(t), \forall t \quad (10c)$$

と定義する。ここで、 $\mathbf{H}(t)$ は状態ベクトルと観測ベクトルを対応付ける $J \times I$ の観測行列である。ここで、 $I = |\Lambda|, J = |\hat{\Lambda}(t)|$ である。 $\mathbf{H}(t)$ は、タイムステップ t に観測値が得られた要素は 1, その他は、0 をとる。したがって、 $\mathbf{H}(t)\mathbf{N}(t)$ は、 J 次元のベクトルとなる。

(6) パラメータ推定

本節では、自己組織化状態空間モデル(Kitagawa,1998)¹⁹ の枠組で状態ベクトルと FD パラメータである交通流率 $q_{\max}(t)$ を推定する方法を定式化する。状態ベクトル $\mathbf{N}(t)$ と $q_{\max}(t)$ で構成される拡張状態ベクトルを $\mathbf{X}(t)$ と定義する。 $\mathbf{X}(t)$ と観測ベクトル $\mathbf{Y}(t)$ を用いると、システムモデルと観測モデルは、

$$\mathbf{X}(t) = \begin{pmatrix} \mathbf{N}(t) \\ q_{\max}(t) \end{pmatrix} = \begin{pmatrix} f_{\text{IT}}(\mathbf{N}(t-1), \mathbf{N}_B(t), \phi(t)) + \boldsymbol{\tau}(t) \\ q_{\max}(t-1) + \omega(t) \end{pmatrix} \quad (11a)$$

$$= f_s(\mathbf{X}(t-1), \mathbf{E}(t))$$

$$\mathbf{Y}(t) = \begin{pmatrix} \hat{\mathbf{N}}(t) \\ \hat{q}_{\max} \end{pmatrix} = \begin{pmatrix} \mathbf{H}(t) & 0 \\ 0 & 1 \end{pmatrix} \begin{pmatrix} \mathbf{N}(t) \\ q_{\max}(t) \end{pmatrix} + \begin{pmatrix} \boldsymbol{\xi}(t) \\ \gamma(t) \end{pmatrix} \quad (11b)$$

$$= \hat{\mathbf{H}}(t)\mathbf{X}(t) + \mathbf{Z}(t)$$

とかける。フィルタリングにより拡張状態ベクトル $\mathbf{X}(t)$ の事後分布 $p(\mathbf{X}(t) | \mathbf{Y}(t))$ を推定すれば、状態ベクトル $\mathbf{N}(t)$ と交通流率 $q_{\max}(t)$ を推定できる。

(7) フィルタリング

システムモデルの関数は非線形、観測モデルの関数は線形である。観測ノイズが正規分布であれば、非線形・ガウス型のフィルタ (e.g. アンサンブル・カルマンフィルタ) が適用できる。しかし、観測ノイズが必ずしも正規分布とならない場合が考えられるため、本研究では、非線形・非ガウス型フィルタの適用を提案する。筆者らが以前に構築した VT ベースの状態空間モデル(Kawasaki et al.2017⁴⁾)では、非線形・非ガウス型フィルタの 1 種である粒子フィルタを用いた。しかし、粒子フィルタは、以下に述べる縮退の問題が指摘されている。粒子フィルタは、時間進展に伴い、少数の粒子の重みだけ大きくなり、その他の多数の粒子の重みはほとんどゼロになってしまう。こうなると、少数の粒子だけで確率分布(予測分布・フィルタ分布)を近似することとなり、分布の近似精度が極端に悪化する。この問題を縮退という。よって、本研究では、縮退を抑制する目的で提案された融合粒子フィルタ(Nakano et al.2007²⁷⁾)を用いる。なお、融合粒子フィルタは、既往手法であるため、本節での内容説明は割愛し、付録に記載する。

5. モデル検証

本章では、首都高速道路の事故を対象としたモデル検証の結果を述べる。

(1) モデル検証の設定

まず、検証の概要を述べる。ここでは、首都高速道路の事故を対象にモデルを適用し、事故時の交通流率の推定を行う。なお、事故発生地点は所与とする。事故発生地点直近の車両感知器の交通量を真値とし、モデルの推定精度を評価する。

事故の概要を述べる。表-1に対象とする事故統計データ、図-8にETC2.0プローブによる事故時のタイム・スペ

表-1 事故統計データ

項目	内容
事故発生時刻 (通報時刻)	2018年10月17日(水) 8:20
事故発生地点	首都高速道路3号渋谷線上り、 7.1kp地点、2車線区間
交通規制	事故により1車線規制
事故形態	車両接触事故

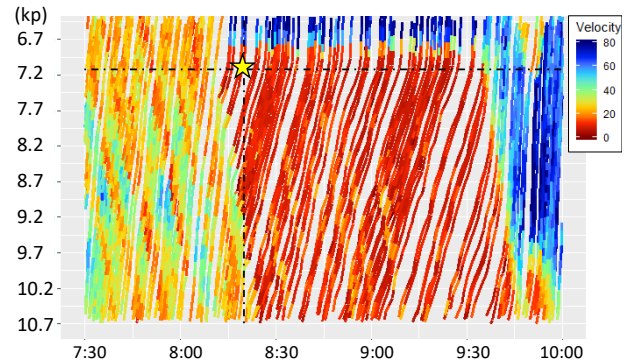


図-8 タイム・スペース図

表-2 状態空間モデルの設定

項目	設定内容
対象時間	7:30 ~ 10:00 (2時間半)
対象区間	10.7 ~ 6.4kp (4.3[km])
タイムステップ	$\Delta t = 3.0[\text{sec}]$ $\Delta T = 300[\text{sec}]$
FDパラメータ	$v = 67[\text{km/h}]$ $w = 20[\text{km/h}]$ $q_{\max}(0) \sim \text{Uniform}(1300 \leq x \leq 4400)$
システムノイズ	$\omega(t) \sim N(0, \sigma_\omega^2), \sigma_\omega = 0.10, \forall t$ $\tau_i(t) \sim N(0, \sigma_\tau^2), \sigma_\tau = 0.15, \forall i, t$
観測ノイズ	$\xi_i(t) \sim N(0, \sigma_\xi^2), \sigma_\xi = 0.08, \forall i, t$
観測データ	1) 上下流端の車両感知器の交通量 (番号: 03-01-47, 03-01-32) 2) ETC2.0プローブ軌跡データ
検証用データ	事故地点付近の車両感知器の交通量 (番号: 03-01-35 (7.12 kpに設置))

ース図を示す。なお、表中の事故発生時刻は、通報時刻を示し、発生地点は、事故統計データの記録地点である。図中の星マークは事故発生地点、プローブ軌跡の色は速度を示している。タイム・スペース図を見ると、事故発生後、7.1kp付近をボトルネックとした渋滞が発生し、9:30過ぎまで渋滞が続いている。10時には、渋滞が解消している状況が見られる。なお、プローブ車両の速度低下状況を見ると、渋滞開始時刻は、通報のあった8:20よりも早い時刻であると推察される。

次に状態空間モデルの設定を述べる。表-2に状態空間モデルの設定を示す。表に示すように対象時刻は、事故発生から渋滞終了時刻を含む2時間半とした。FDパラメ

一タの v, w は平常時の車両感知器から推定した値を設定した。交通流率 q_{max} は、事故発生地点付近の区間(7.1~7.2kp)のみフィルタリングした。 q_{max} の初期分布は、表に示す一様分布を仮定し、500パターン生成した。上記より生成した事故発生地点のFDの初期分布を図-9に示す。図中の赤線は、車両感知器より推定した平常時のFDである。なお、フィルタリング区間以外の最大交通流率は、平常時のFDの最大交通流率 $q_{max}(t) = 3750, \forall t$ を設定した。システムノイズおよび観測ノイズは、正規分布を仮定し、表のようにパラメータを設定した。観測データは、上下端の車両感知器の交通量およびETC2.0プローブ軌跡データを用いた。また、交通流率の精度検証には、表に示す事故発生地点付近の車両感知器の交通量データを用いた。

(2) モデル検証結果

検証結果を述べる。図-10に交通流率の推定結果を示す。上段の図は、交通流率の時間推移を示している。黒線は、推定値であり、アンサンブル平均を出力している。灰色のバンド幅は、推定値からの標準偏差分の乖離を示す。下段の図は、推定値と車両感知器の差分を示す。赤線は車両感知器の交通量である。同図を見ると、事故後の交通流率の低下および事故渋滞解消時の交通流率の回復の過程をモデルが追隨している様子が確認される。推定値と車両感知器個交通流率の差分は、概ね、±200~350台/hrとなっている。車両感知器交通量は、概ね推定値±標準偏差の幅(灰色バンド)に収まっている。一方、事故発生前の7:45や事故渋滞の終了時の9:30過ぎに比較的、推定値と観測値に乖離が生じている。図-11に交通流率の推定値と観測値の関係を示す。同時刻の推定値と観測値を散布図としてプロットしている。青線は、回帰直線であり、灰色バンドは、95%信頼区間を示す。同図を見ると、相関係数は0.86となっており、また、回帰直線の傾きは1.0に近い値となっている。MAPE(平均誤差)は、0.09(10%未満)となっている。以上より、本事例では、車両感知器と同程度まで、精度よく交通流率が推定されしていると判断される。しかし、前述したように時間によっては、推定値と観測値の乖離が大きくなるため、今後は、モデル改良による精度向上が課題と考える。

6. おわりに

本研究では、VTを拡張し、上下端の車両感知器とプローブデータを用いて、事故発生地点の交通流率を推定する状態空間モデルを提案した。首都高速道路の事故を対象にモデル検証した結果、車両感知器と同程度に精度よく交通流率を推定することが出来た。また、事故後の

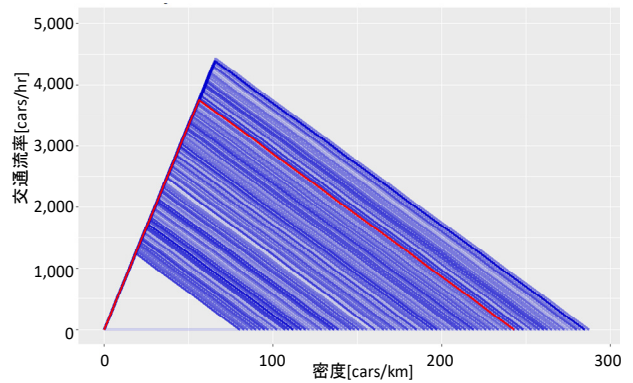


図-9 事故発生地点のFDの初期分布

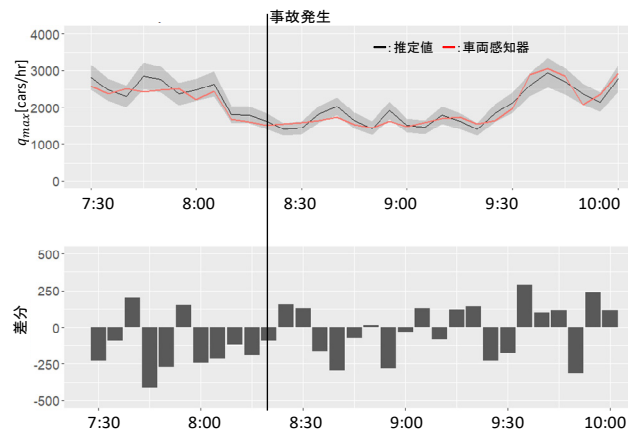


図-10 交通流率の推定結果および車両感知器との差分

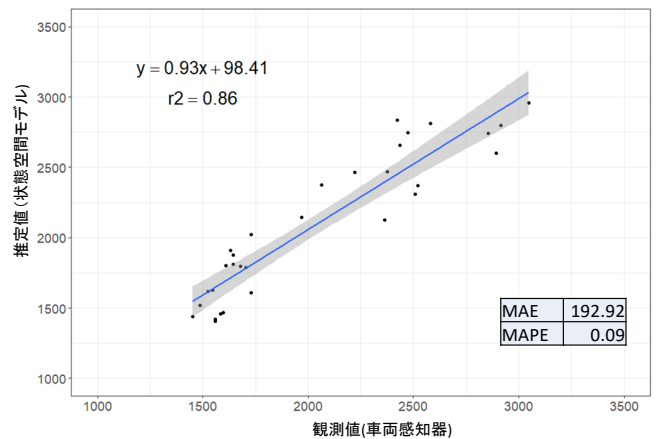


図-11 交通流率の推定値と観測値の関係

交通流率の低下および事故渋滞解消時の交通流率の回復の過程をモデルが追隨している様子が確認された。今後の検討課題を以下に示す。

- 1) モデル改良；検証の結果、MAPEの観点では、精度よく交通流率を推定したことが確認された。しかし、一部の時間帯において、推定精度の低下が見られるといった問題も浮き彫りとなった。よって、今後は、精度低下の要因を分析し、モデルを改良する必要がある。

- 2) FDのパラメータ設定；本研究のFDは、簡単のため、 q_{\max} のみを確率変数とし、その他のパラメータ (v, w) は所与という強い仮定をおいた。この仮定は、実際の事故時の交通流とは異なることが懸念される。例えば、事故発生時は、車線閉塞により、通常よりもbackward waveスピード w が速くなる可能性が考えられる。今後は、事故時の交通流を解析し、FDのパラメータの設定を再検討する必要がある。
- 3) ノイズの設定；本検証では、システムノイズ、観測ノイズの分布形状を正規分布と仮定し、分散等のパラメータは、所与(ハイパーパラメータ)とした。今後は、こうした確率分布形状やパラメータの適切な設定方法についても検討が必要である。
- 4) 検証の拡充；本検証では、車両感知器の交通流率と推定値の比較結果のみ評価したが、他の視点(e.g. 事故渋滞の再現性)も追加し、多面的に評価することが必要である。また、モデルのロバスト性を検証するためには、事例を追加し、更に分析を深堀することが必要と考える。
- 5) 事故発生地点の推定；本稿では、事故発生地点を所与とし、事故発生地点の交通流率の推定を試みた。実際の交通流への適用にあたっては、まず、事故発生地点を推定することが必要である。したがって、既往研究^{22), 23)}を踏まえ、事故発生地点の推定手法の開発が必要と考える。

謝辞：本研究は、JSPS科研費 JP19K15107および独立行政法人情報通信研究機構(NICT)の委託研究「異分野データ連携によるスマートモビリティ基盤の研究開発」の助成を受けたものである。また、研究で使用した車両感知器データおよびETC2.0プローブデータは、首都高速道路(株)より提供いただいた。ここに深く感謝の意を表す。

付録 I 融合粒子フィルタ

ここでは、参考に融合粒子フィルタの概要を整理する。なお、詳細は、参考文献^{27), 28), 29)}を参照されたい。

まず、粒子フィルタ¹⁴⁾のアルゴリズムを述べる。なお、状態ベクトル、観測ベクトル、ノイズの表記法は、本編の式(11)を踏襲する。

上記の変数を用いて、粒子フィルタの計算ステップを以下に示す。

- 1) 初期分布の生成： $t=0$ とし、 N 個の初期パーティクル $\{\mathbf{X}^{(i)}(0)\}_{i=1}^N, i=1, 2, \dots, N$ を生成する。
- 2) 予測： $t=t+1$ とし、ノイズ分布 $\mathbf{E}(t)$ に従って、 N 個のシ

ステムノイズ $\{\mathbf{E}^{(i)}(t)\}_{i=1}^N$ を生成する。システムノイズとシステムモデルにより一期先の状態 $\{\mathbf{X}^{(i)}(t|t-1)\}_{i=1}^N$ を予測する。

- 3) 尤度：観測ベクトル $\mathbf{Y}(t)$ と観測ノイズ $\mathbf{Z}(t)$ により、尤度 $\lambda^{(i)}(t) = p(\mathbf{Y}(t) | \mathbf{X}^{(i)}(t))$ を算定する。次に、正規化した尤度 $\beta^{(i)}(t) = \lambda^{(i)}(t) / \sum_{k=1}^N \lambda^{(k)}(t)$ を算定する。
- 4) リサンプリング： $\beta^{(i)}(t)$ の確率で、 N 個のパーティクルを復元抽出し、 $\{\mathbf{X}^{(i)}(t|t)\}_{i=1}^N$ を生成する。
- 5) 時間更新： $t=t+1$ とし、計算終了まで2)~4)を繰り返す。

融合粒子フィルタは粒子フィルタの“3)尤度”のステップまでは、同様である。異なるのは、“4)リサンプリング”に代わり、Mergingと呼ばれる処理を行う点である。Mergingの処理内容を以下に示す。

$\{\mathbf{X}^{(1)}(t|t-1), \dots, \mathbf{X}^{(N)}(t|t-1)\}$ から各粒子 $\mathbf{X}^{(i)}(t|t-1)$ が $\beta^{(i)}(t)$ の確率で抽出されるように $n \times N$ の粒子を復元抽出し、 $\{\tilde{\mathbf{X}}^{(1,1)}(t|t), \dots, \tilde{\mathbf{X}}^{(n,1)}(t|t), \dots, \tilde{\mathbf{X}}^{(1,N)}(t|t), \dots, \tilde{\mathbf{X}}^{(n,N)}(t|t)\}$ を生成する。次に、 $n \times N$ の粒子 $\{\tilde{\mathbf{X}}^{(j,i)}(t|t)\}$ から n 個の粒子 $\{\tilde{\mathbf{X}}^{(1,i)}(t|t), \dots, \tilde{\mathbf{X}}^{(n,i)}(t|t)\}$ を取り出したうえで、各粒子の重み付き和

$$\mathbf{X}^{(i)}(t|t) = \sum_{j=1}^n \alpha_j \tilde{\mathbf{X}}^{(j,i)}(t|t) \quad (I.1)$$

を計算し、新たな粒子 $\mathbf{X}^{(i)}(t|t)$ を生成する。これを全ての粒子 $i=1, 2, \dots, N$ で実行し、 $\{\mathbf{X}^{(i)}(t|t)\}_{i=1}^N$ を生成する。ここで、重み付き和をとる際の重み α_j は、

$$\sum_{j=1}^n \alpha_j = 1, \sum_{j=1}^n \alpha_j^2 = 1 \quad (I.2)$$

を満たす必要がある。重み付き和をとるサンプル数 $n \geq 3$ であれば、式(I.1)で生成したフィルタアンサンブル $\{\mathbf{X}^{(i)}(t|t)\}_{i=1}^N$ がフィルタ分布 $p(\mathbf{X}(t) | \mathbf{Y}(t))$ と近似的に等しい平均値と分散共分散(1次モーメント、2次モーメント)を得ることができる。なお、 $n=1$ の場合は、通常の粒子フィルタと同じである。 $n=2$ の場合は、式(I.2)の制約により、重み α_j のいずれかを0にする必要があるため、通常の粒子フィルタと同じとなる。

本稿の検証では既往文献^{28), 29)}より $n=3$ とし、重み α_j は、

$$\alpha_1 = 3/4, \alpha_2 = (\sqrt{13}+1)/8, \alpha_3 = (\sqrt{13}-1)/8$$

を設定した。

参考文献

- 1) Daganzo, C. F.: On the Variational Theory of Traffic Flow: well-posedness, duality and applications, Networks

- and Heterogeneous Media, Vol.1(4), pp.601-619, 2006.
- 2) Mehran, B., Kuwahara, M. and Naznin, F.: Implementing kinematic wave theory to reconstruct vehicle trajectories from fixed and probe sensor data, *Transp. Res. Part C*, Vol.20(1), pp.144-163, 2012.
 - 3) Mehran, B. and Kuwahara, M.: Fusion of probe and fixed sensor data for short-term traffic prediction in urban signalized arterials, *International Journal of Urban Sciences*, Vol.17(2), pp.163-183, 2013.
 - 4) Takayasu, A., Kuwahara, M. : Traffic state estimation considering stochasticity of input data based on variational theory, *The 21st International Conference of Hong Kong Society for Transportation Studies*, 2016.
 - 5) Work, D.B., Tossavainen, O.P., Blandin, S., Bayen, A.M., Iwuchukwu, T., Tracton, K. : An Ensemble Kalman Filtering approach to highway traffic estimation using GPS enabled mobile devices, *Proceedings of the IEEE Conference on Decision and Control*, 2008.
 - 6) Herrera, J.C., Bayen, A.M. : Incorporation of Lagrangian measurements in freeway traffic state estimation. *Transp. Res. Part B*, Vol.44, pp.460-481, 2010.
 - 7) Allströma, A., Bayen, A.M., Fransson, Magnus, Gundlegårda, David, Patirec, Anthony D., Rydergren, Clas, Sandina, Mats. : Calibration framework based on bluetooth sensors for traffic state estimation using a velocity based cell transmission model. *Transp. Res. Procedia*, Vol.3, pp.972-981, 2014.
 - 8) Yuan, Y., Duret, A., van Lint, H. : Mesoscopic traffic state estimation based on a variational formulation of the LWR model in Lagrangian-space coordinates and Kalman filter, *18th Euro Working Group on Transportation, EWGT 2015*, 14-16 July 2015, Delft, The Netherlands, *Transp. Res. Procedia*, Vol.10, 82-92, 2015.
 - 9) Nantes, A., Ngoduy, D., Bhaskar, A., Miska, M., Chung, E. : Real-time traffic state estimation in urban corridors from heterogeneous data. *Transp. Res. Part C*, Vol.66, pp.99-118, 2016.
 - 10) Jiang, Z., Chen, M., Ouyang, Y. : Traffic state and emission estimation for urban expressways based on heterogeneous data. *Transp. Res. Part D*, Vol.53, pp.440-453, 2017.
 - 11) Canepa, E.S., Claudel, C.G. : Networked traffic state estimation involving mixed fixed-mobile sensor data using Hamilton-Jacobi equations. *Transp. Res. Part B*, Vol.104, pp.686-709, 2017.
 - 12) Xie, X., van Lint, H., Verbraeck, A. : A generic data assimilation framework for vehicle trajectory reconstruction on signalized urban arterials using particle filters. *Transp. Res. Part C*, Vol.92, pp.364-391, 2018.
 - 13) Kitagawa, G.: Monte Carlo filter and smoother for non-Gaussian nonlinear state space models, *Journal of Computational and Graphical Statistics*, Vol. 5, No. 1, pp. 1-25, 1996.
 - 14) Kawasaki, Y., Hara, Y., Kuwahara, M. : Real-time monitoring of dynamic traffic states by state space model. *Transp. Res. Proc*, Vol.21, pp.42-55, 2017.
 - 15) 川崎洋輔, 原祐輔, 桑原雅夫 : 状態空間モデルとプローブ軌跡データを用いた区間途中の流出入台数の推定手法の構築, *土木学会論文集 D3*, Vol.72, 2016.
 - 16) Wang, Y., Papageorgiou, M., Messmer, A. : Investigation of the adaptive features of a real-time nonlinear freeway traffic state estimator. *Nonlin. Dyn.*, Vol.49 (4), pp.511-524, 2007.
 - 17) Sun, Z., Jin, W., Ritchie, S.G. : Simultaneous estimation of states and parameters in Newell's simplified kinematic wave model with Eulerian and Lagrangian traffic data. *Transp. Res. Part B*, Vol.104, pp.106-122, 2017.
 - 18) Kawasaki, Y., Hara, Y., Kuwahara, M. : Real-Time Traffic State Estimation on a Two-dimensional Network by State Space Model, *Transp. Res. Part C*, in press, 2019.
 - 19) Kitagawa, G. : A self-organizing state-space model. *J. Am. Stat. Assoc.*, Vol.93, pp.1203-1215, 1998.
 - 20) 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.
 - 21) 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.
 - 22) 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.
 - 23) Asakura, Y., Kusakabe, T., Nguyen, L., X., and Ushiki, T.; Incident Detection Methods using Probe Vehicles with on-board GPS Equipment, *Transp. Res. Part C*, Vol.81, pp.330-341, 2016.
 - 24) 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.
 - 25) 日下部貴彦 : 全国規模のプローブカーデータを用いた広域的異常事象の検出手法の構築, *土木計画学研究・講演集*, Vol. 55, CD-ROM, 2017.
 - 26) Edie, L.C. : Discussion of traffic stream measurements and definitions, *Proceedings of the 2nd International Symposium on the Theory of Traffic Flow*, pp.139-154, 1963.
 - 27) Nakano, S., Ueno, G. and Higuchi, T. : Merging particle filter for sequential data assimilation, *Nonlinear Processes in Geophysics*, 14, pp.395-408, 2007.
 - 28) 中野慎也, 上野玄太, 中村和幸, 樋口知之 : Merging Particle Filter とその特性, *統計数理*, Vol.56, No.2, pp.225-234, 2008.
 - 29) 樋口知之, 上野玄太, 中野慎也, 中村和幸, 吉田 亮 : データ同化入門 - 次世代のシミュレーション技術 -, pp.47-77, 朝倉書店, 2011.

(2020.3.8 受付)

CONSTRUCTION OF ESTIMATION METHOD OF TRAFFIC FLOW RATE AT TRAFFIC ACCIDENT BY STATE SPACE MODEL

Yosuke KAWASAKI, Shogo UMEDA, Masao KUWAHARA, Daiki KUMAKURA,
Takeshi OHATA, Kota MINAMI and Yusuke SUZUKI

In this study, we propose a method for estimating the traffic flow rate at an accident location using a state space model. In traffic control, it is important to understand the traffic flow rate at the accident location. On the Metropolitan Expressway, vehicle detectors are densely arranged, and the traffic flow rate at the accident location can be measured. However, there is a problem in terms of cost for maintain all vehicle detectors. On the other hand, a large amount of probe data has been measured, and a method of using it has been sought. In the future, it is desirable to reduce the number of current vehicle detectors using probe data and rationalize them. However, the probe data cannot measure the traffic volume. Therefore, in this study, we construct a state space model using vehicle detectors, probe data and variational theory, and try to estimate the traffic flow rate. As a result of the verification, the traffic flow rate at an accident location was accurately estimated.