センシングデータと交通流モデルによる交通状態の長期モニタリング方法の提案

川崎洋輔[1]・桑原雅夫[2]・伊藤 裕貴[3]・川松祐太[4]・大畑長[5]・熊倉大起[6]・吉川真央[7]・江森唯[8]

[1]正会員　日本大学准教授　工学部土木工学科（〒 963-8642 福島県郡山市田村町徳定字中河原 1 番地）
E-mail: kawasaki.yosuke@nihon-u.ac.jp(Corresponding author)
[2]正会員　東北大学名誉教授　タフサイバーフィジカル AI 研究センター（〒 980-8579 仙台市青葉区荒巻字青葉 6-6-10）
E-mail: kuwahara@plan.civil.tohoku.ac.jp
[3]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.ito153@shutoko.jp
[4]非会員　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.kawamatsu3852@shutoko.jp
[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（〒 151-0071 東京都渋谷区本町 3-12-1）
E-mail: kumakura-di@oriconsul.com
[7]非会員　首都高技術 (株)（〒 105‐0001　東京都港区虎ノ門三丁目 10 番 11 号虎ノ門 PF ビル）
E-mail: m.yoshikawa@shutoko-eng.jp
[8]非会員　首都高技術 (株)（〒 105‐0001　東京都港区虎ノ門三丁目 10 番 11 号虎ノ門 PF ビル）
E-mail: y.emori@shutoko-eng.jp

本研究では，センシングデータと交通流モデルを用いた交通状態の長期モニタリング手法を提案する．交通管制では，交通流をモニタリングした上で，情報提供することが重要である. 交通状態を把握するためのセンサー（e.g. 車両感知器，プローブデータ）はスパースなため，交通流モデルによる未観測箇所の補完推定が必要である．交通流モデルは，事前にパラメータを設定する必要があるが，交通流は時事刻々と変化するため，事前にモデルパラメータをキャリブレーションすることは困難である．本研究では，前述のような交通状態の長期モニタリングに関する交通流モデルの技術課題を抽出するとともに，課題解決のためのモデルの改良方針を述べる．また，首都高速道路の実際の交通流を対象としたケーススタディを通じてモデル検証を行う．

Key Words: *traffic flow, variational theory, probe data, traffic detector, long-term monitoring*

1. はじめに

本研究では，センシングデータと交通流モデルを用いた交通状態の長期モニタリング手法を提案する．

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, 筆者らは，現状の車両感知器を減らした状況[1]を想定し，交通流モデルの解法の一つである variational theory (VT)[4] 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を研究してきた[1)]．しかし，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．筆者らは，この課題解決のために，VT を状態空間モデルを構築し，逐次観測されるプローブデータを用いて，交通流率を推定するモデルを提案した[2)3)]．これらの研究では，数時間程度の自然渋滞や事故渋滞のみを対象に精度検証を行ってきた．一方，提案する交通状態推定のモデルを実社会に実装するためには，長期間交通モニタリングに耐えうる性能が必要となる．

以上を踏まえ，本研究では，実装を見据えて，長期モニタリングを見据えた技術課題の整理及び課題解決のためのモデル改良方法を提案する．あわせて，首都高速

[1] 感知器を減らした状況とは，IC や JCT 部等の流出入箇所の感知器のみを残し，単路部の感知器を間引いた状況を想定している．詳細は既往研究[1)2)3)] を参照されたい．

道路の実際の交通流にモデルを適用するケースタディを実施し，実証的に精度検証を行う．

2. 既往研究

本章では，既往研究として，Variational theory（VT）による交通状態推定と FD の推定およびセンシングデータを用いた事故発生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，Daganzo[4] により提案された VT の概要を以下に述べる．VT は，kimematic wave theory に基づく交通流モデルの解法の一つである．VT は，時空間の累積台数を推定することができる．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．そのため，信号や区間途中の流出入台数のデータを境界条件に組み込んだ研究（Mehran et al.[5]) や対応車線のプローブデータを境界条件とした研究（Takenouchi et al.[6]) などが存在する．川崎ら[1] は，VT を首都高速道路の交通流に適用し，精度検証を行っている．しかし，この研究では，数時間の渋滞流や非渋滞状況のみを対象としており，長期的なモニタリングは行われていない．

(2) fundamental diagram パラメータの推定

FD のパラメータは，古くから車両感知器の観測データを用いて推定される．しかし，車両感知器の設置位置は限定的なため，最近は，プローブデータによる FD 推定を試みた研究がいくつかある． Seo et al.[7] は，ジャム密度を所与として，プローブ軌跡データのみから FD パラメータを推定する手法を提案している．また，交通流モデルを状態空間モデルに拡張し，交通状態と FD パラメータの同時推定を試みている研究もある (Sun et al.[8], Kawasaki et al. [9])．Sun et al. [8] は，車両感知器データとプローブデータを用いて，単路を対象に交通状態と Newell の simplified kinematic wave model とパラメータ (FD と初期車両数) を同時に推定する最適化問題を定式化した．Kawasaki et al. [9] は，二次元ネットワークの交通状態を推定する交通流モデルを状態空間モデルに拡張し，交通状態と FD の同時推定を試みている．川崎ら[1] は，あらかじめ F のパラメータ候補を複数用意し，VT 入力時の推定軌跡と実測値との乖離を評価することで，適切なパラメータ候補の探索を試みている．これらの研究は，全て平常時の交通状態下での FD パラメータ推定を試みている．

(3) センシングデータを用いた事故発生時の交通解析

本節では，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．古くより，オイラー型の観測装置である車両感知器を用いた突発事象検知に関する研究はいくつかある[10),11)]．最近では，プローブデータ等のラグランジェ型の観測データを使った研究が行われている．例えば，プローブ軌跡データを用いて事故地点の検出を試みた研究 (Asakura et al.[12)]) やクラスタリングにより異常検出を試みた研究 (Cai et al.[13)]) ならびに時空間の相関関係を用いた異常検出を試みた研究 (Kusakabe et al.[14)]) がある．また，Kuwahara et al.[15)] は，対向車線のプローブデータを用いて，事故発生時の交通流率の推定を試みている．本研究の事故時の交通流率推定は，観測値のノイズを時間に依存した確率変数としていること，スムージング処理を行い，推定している点が異なる．

(4) 本研究の貢献

既往研究を踏まえて，以下に本研級の貢献を述べる．

1) 交通流モデルの解法の一つである VT をベースにセンシングデータと交通流モデルを用いて，交通流を長期モニタリングできる手法を提案した．

2) 実際の長期間の交通流にモデルを適用し，実証的に精度検証を行った．

3. モデル

本章では，提案するモデルを定式化する．本研究では，交通状態推定のモデルに VT を用いる．よって，まず，VT を概説した上で，事故等の突発事象発生時の状態推定方法を述べる．

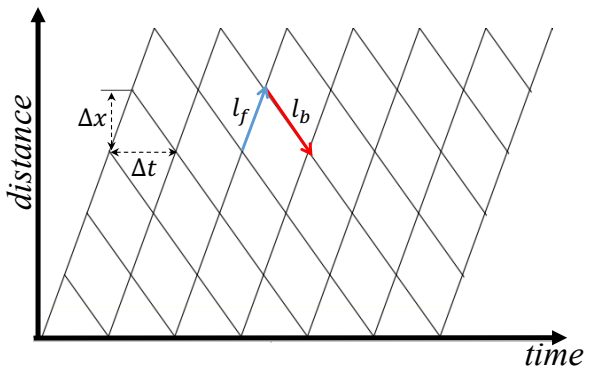
(1) Variational theory

まず，Daganzo[4] 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．$\varphi = (q_{max}, v, w)$ は，以下に示すパラメータを持っている．

$$v = forward\ wave\ speed$$
$$w = backward\ wave\ speed$$
$$q_{max} = \text{最大交通流率}$$

ここで，本研究では，FD における交通流率の最大値を「最大交通流率」，最大交通流率以下 (容量低下時) の時の交通流率を単に「交通流率」と表記する．

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



図–1 時空間ネットワーク

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，

$$C_f = 0 \tag{1a}$$

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

とかける．式 (1) より，リンクコストは，FD パラメータと q_{max},Δt で決定される．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．

$$N_i = inf\{N_m + Z_{mi} \mid m \in \Omega_i\},\ \forall i \tag{2}$$

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．

(2) 事故時の交通流の推定

ここでは，事故時の交通流の推定手法を述べる. 事故や落下物といった突発事象の発生時には，交通規制に伴う車線閉塞により，突発的に交通流率が低下する. そのため，VT のパラメータである FD の最大交通流率 (q_{max}) が現実の交通流と乖離し，推定精度が低下する. よって，筆者らは，これまで，VT を状態空間モデルに拡張し，事故地点の交通流率の推定手法を研究してきた[2)3)]．本研究では，これらの手法をベースに事故地点の交通流率を推定する．そして，推定した交通流率を VT の FD パラメータである最大交通流率 (q_{max}) 設定し，VT により交通状態推定を試みる．なお，FD パラメータを変えた場合，FD 形状が変化するため，図 1 に示した時空間ネットワークの形状 (敷き詰められる FD の数) も変化する．しかし，ここでは，簡単のため，FD 形状を変化させずに，q_{max} の値のみ変更する．

以降で，交通流率を推定するための状態空間モデルについて述べる．提案する手法は，既往研究[3)] の手法をベースとし，観測値のみ異なる．したがって，ここでは，観測値の取り扱いを主に整理し，モデルの全体像は概要のみ述べる．詳細は参考文献を参照されたい[3)]．

a) 状態ベクトル

最初に，状態空間モデルのタイムステップを定義する．前述した VT の時空間ネットワーク (図 1) に対応させて，時刻を $n \cdot \Delta t$ 単位に離散化する．ここで，n は自然数である．離散化された時刻を $t = 0, 1, 2 \cdots, T$ と表記する．離散化した時間幅 $n \cdot \Delta t$ を状態空間モデルのタイムステップと定義する．$n = 1$ の場合は，VT のタイムステップと状態空間モデルのタイムステップは Δt となり，一致する． $n > 2$ の場合，状態空間モデルのタイムステップは，VT の n 倍となる．いずれの場合においても，VT と状態空間モデルのタイムステップは整合する (状態空間モデルのタイムステップに VT のタイムステップが整数個含まれる)．なお，以降では，簡略化のため，時刻 $t - n \cdot \Delta t$ は，$t - 1$ と表記する．

状態ベクトルを以下に定義する．状態ベクトルの定義のために，まず，離散時刻 t を以下に定義する．

$$t \equiv [t, t + n \cdot \Delta t),\ t = 0, 1, 2, \cdots, T. \tag{3}$$

式 (3) より，今後，時刻 t は，連続時間 $[t, t + n \cdot \Delta t)$ を意味する．時刻 t の時空間に存在するノードのインデックスを $i = 1, 2, \cdots, I, i \in \Lambda$ と表す．時刻 t の状態ベクトルは，累積交通量の集合ベクトル $\mathbf{N}(t)$ と FD パラメータである q_{max} で構成されると定義する．よって，時刻 t の状態ベクトル $\mathbf{X}(t)$ は，下式で定義される．

$$\mathbf{N}(t) = (N_1(t), N_2(t), \cdots, N_i(t), \cdots, N_I(t))^T,\ i \in \Lambda,\ \forall t \tag{4a}$$

$$q(t) = q(t-1) + \omega(t), \tag{4b}$$

$$\varphi(t) = (q(t), v, w),\ \forall t \tag{4c}$$

$$\mathbf{X}(t) = \begin{pmatrix} \mathbf{N}(t) \\ q(t) \end{pmatrix} \tag{4d}$$

式 4 のように交通流率 $q(t)$ は確率変数である. なお，状態ベクトルは，全タイムステップで要素を同数とし，各

要素の時間進展を記述できるように，過去の研究[2] を踏襲し，タイムステップを $n \cdot \Delta t$ で設定する．

b) 観測ベクトル

ここでは，観測ベクトルを定義する．本研究で取り扱う観測値は，１）車両感知器による累積交通量及び２）プローブ車両もしくは車両感知器から得られる交通流率である．筆者らは，これまで，プローブ車両の速度を観測し，状態空間モデルにより車両感知器がない場所の交通流率を推定する手法を研究してきた[3]．しかし，観測に関して問題があることがわかった．以下に問題及びその対応内容を述べる．首都高速道路での実装に向けて，プローブ軌跡データの解析を進めたところ，渋滞時等に欠損（プローブが未観測）となる場合があることがわかった．プローブ欠損の例を図 10 に示す．図に示すように渋滞中にプローブが一定時間未観測となる場合が確認される．そこで，本研究では，プローブが未観測の場合に，事故地点下流側の車両感知器の交通流率を代替利用することを提案する．交通流率の観測イメージを図 2 に示す．同図に示すように，本研究では，事故地点の交通流率を１）プローブ速度と所与の FD から推定される交通流率, $\hat{q}_1(t)$ と，2) 区間下流端の車両感知器から観測される交通流率, $\hat{q}_2(t)$ の２タイプの方法で観測する．観測値の取り扱いルールは，以下の通り：

$$\hat{q}(t) = \begin{cases} \hat{q}_1(t) & (\text{プローブデータ観測}) \\ \hat{q}_2(t) & (\text{プローブデータ未観測}) \end{cases} \tag{5}$$

式 5 のように, プローブデータが観測できるか否かで，観測に用いるリソースを切り替える. なお，プローブ車両による交通流率 $\hat{q}_1(t)$ は，下式で定義される．

$$\hat{q}_1(t) = \begin{cases} if\ \hat{v}(t) > \hat{v},\ \hat{q}_{max} \\ else\ \{\hat{k}_{jam}/(1 + \hat{v}(t)/\hat{w})\} \end{cases} \tag{6}$$

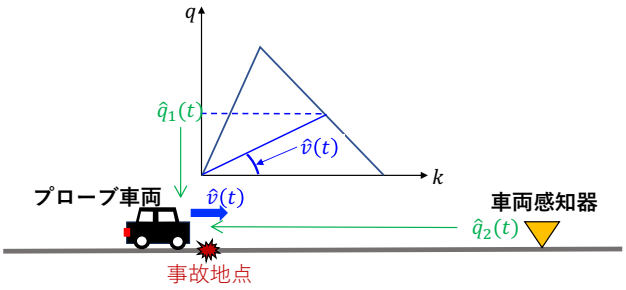
ここで，$\hat{v}(t)$ はプローブ車両速度，$\hat{v}(t), \hat{q}_{max}, \hat{k}_{jam}, \hat{w}$ は，交通流率観測用の FD パラメータであり，それぞれ，forward wave speed, 最大交通流率，ジャム密度，backward wave speed である. この FD パラメータは所与（given）と仮定する．

また，車両感知器から得られる時刻 t の累積交通量は，下式で定義される．

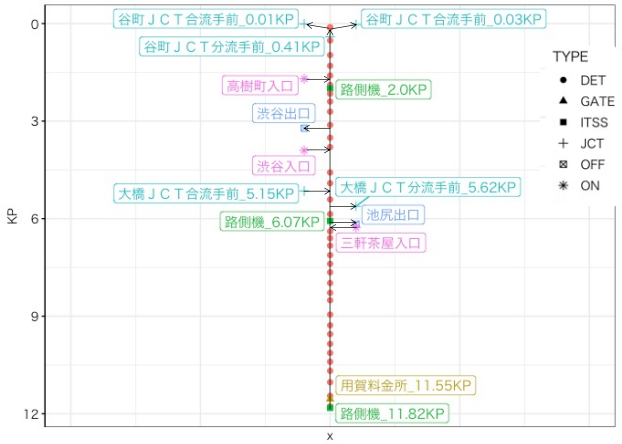
$$\hat{\mathbf{N}}(t) = \begin{pmatrix} \vdots \\ \hat{N}_i(t) \\ \vdots \end{pmatrix} + \begin{pmatrix} \vdots \\ \eta(t) \\ \vdots \end{pmatrix},\ i \in \hat{\Lambda}(t),\ \forall t. \tag{7}$$

以上より，観測ベクトルを下式に定義する．

$$\mathbf{Y}(t) = (\hat{N}_i(t), \hat{q}(t))^T,\ \forall t. \tag{8}$$



図–2 交通流率の観測方法のイメージ図



図–3 3 号渋谷線上りにおける流出入箇所およびセンサー配置図中の凡例の説明） ITSS：ITS スポット，DET：車両感知器，JCT：ジャンクション，ON/OFF：出入口 IC, GATE：料金所

c) 状態空間モデル

ここでは，状態空間モデルの概要を述べる．既往研究[3] より，状態空間モデルは，下式で定義する．

$$\mathbf{X}(t) = f_s(\mathbf{X}(t-1), \mathbf{E}(t)) \tag{9a}$$

$$\mathbf{Y}(t) = \tilde{\mathbf{H}}(t) \cdot \mathbf{X}(t) + \mathbf{Z}(t),\ \forall t. \tag{9b}$$

ここで，$f_s(\ldots)$ はシステムモデルの関数，$\mathbf{E}(t))$ はシステムノイズ，$\mathbf{Z}(t)$ は観測ノイズ，$\mathbf{H}(t)$ は状態ベクトルと観測ベクトルを対応づける $|\Lambda| \times |\hat{\Lambda}(t)|$ の観測行列である．ここで，$|\cdot|$ はベクトルの要素数を表す．ベイズの定理により状態ベクトル $\mathbf{X}(t)$ の事後分布 $p(\mathbf{X}(t)|\mathbf{Y}(t))$ を推定すれば，観測値により補正された状態ベクトルが求められる．このパラメータと状態ベクトルを推定する枠組は，自己組織化状態空間モデル[16] とよばれる．

4. モデル検証

本章では，VT による長期モニタリングの検証結果を述べる．

表–1 交通状態推定の区間割り

No	区間	距離 (km)
1	用賀-三軒茶屋入口	4.29
2	池尻出口-大橋 JCT 分流	0.45
3	大橋 JCT 分流-合流手前	0.26
4	大橋 JCT 合流-渋谷入口	0.33
5	渋谷入口-渋谷出口	0.29
6	渋谷出口-高樹町入口	1.23
7	高樹町入口-谷町分流	1.19

表–2 状態推定に使用する感知器一覧

No	感知器_上流	感知器_下流
1	03-01-47_10.68KP	03-01-32_6.39KP
2	03-01-28_6.07KP	03-01-26_5.62KP
3	03-01-25_5.41KP	03-01-24_5.15KP
4	03-01-23_4.91KP	03-01-22_4.58KP
5	03-01-19_3.80KP	03-01-18_3.51KP
6	03-01-15_3.12KP	03-01-11_1.89KP
7	03-01-09_1.60KP	03-01-05_0.41KP

(1) 検証条件

本節では，モデルの検証条件を整理する．

まず，検証対象の区間を述べる. 対象区間は，3 号渋谷線上り方向全線である. 対照区間の流出入区間およびセンサー配置を図 3 に示す.3 号渋谷線上りのセンサーは，感知器（地点）が 37 箇所，ITS スポットが 3 箇所設置されている．また，分合流部は，JCT 部が 5 箇所，出入口ランプが 5 箇所（入口 ; 2，出口 ; 3）配置されている．図 3 を見ると，ITS スポットは，1) 上流端（用賀）と 2) 三軒茶屋入口下流， 3) 渋谷入口下流の 3 箇所に設置されている. 対象区間には，区間途中で出入口があるため，区間途中で累積台数の整合性が取れない. Mehran et al.[5] のように VT を拡張し，流出入台数を組み込み整合性を図ることは可能である．しかしながら，モデルが複雑になること，出入口の台数が逐次観測される必要があるといった課題がある. よって，本研究の VT は，実装の簡易性や出入口の感知器雨が不要となることから，流出入箇所で区間を分割して実行（区間途中で流出入なしの単路部ごとに実行）することとした. 以上を踏まえ，対象区間の区間割を表 1 に示す．VT は，表に示すように流出入箇所で推定区間を分割した 7 区間で実行し，精度検証を行う．なお，三軒茶屋入口-池尻出口間は，距離が 0.32km と短くかつ，感知器が 1 つしかないため，VT 計算対象外とし，感知器のデータを用いることとした.

次に使用するセンサーを述べる．センサーは，“車両感知器”と”ETC2. 0 プローブ軌跡データ”である．使用する感知器の番号一覧を表 2 に示す．表に示すように，各区間の上流端と下流端の 2 箇所の感知器を用いる．その他の感知器は，状態推定には用いず，VT との精度比較にのみ使用する．

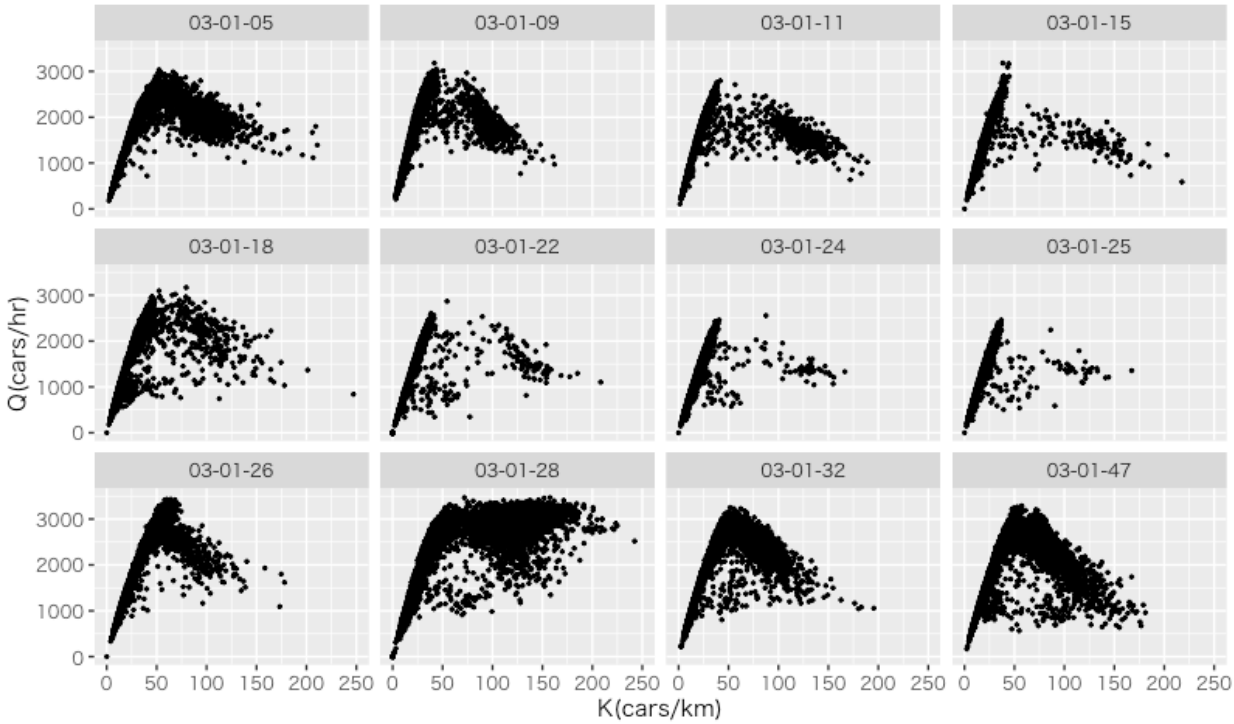
次に，検証期間を述べる．検証期間は，2022 年 7 月 (1 ヶ月間) の平日とした. 表 3 に対象日を示す．表に示すように 2022 年 7 月の平常時（事故なしの日）は，10 日間，事故発生日は，10 日間となっている. 平常時（事故発生なし）の日は，通常の VT を用いて精度検証する．

表–3 交通モニタリング対象日

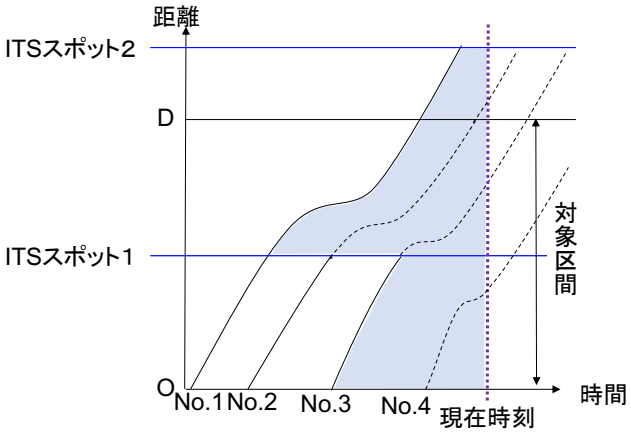
年月日	事故なし
2022 年 7 月 1 日 (金)	○
2022 年 7 月 4 日 (月)	
2022 年 7 月 5 日 (火)	○
2022 年 7 月 6 日 (水)	○
2022 年 7 月 7 日 (木)	
2022 年 7 月 8 日 (金)	○
2022 年 7 月 11 日 (月)	○
2022 年 7 月 12 日 (火)	○
2022 年 7 月 13 日 (水)	
2022 年 7 月 14 日 (木)	
2022 年 7 月 15 日 (金)	
2022 年 7 月 19 日 (火)	○
2022 年 7 月 20 日 (水)	○
2022 年 7 月 21 日 (木)	○
2022 年 7 月 22 日 (金)	
2022 年 7 月 25 日 (月)	
2022 年 7 月 26 日 (火)	
2022 年 7 月 27 日 (水)	
2022 年 7 月 28 日 (木)	
2022 年 7 月 29 日 (金)	○
事故なし日数	10

事故発生日は，前述した状態空間モデル（SSM：State-Space Model）により，事故地点の交通流率推定手法を VT と組み合わせて状態推定することとする．また，VT の実行期間は 24 時間とし，日別に状態推定することとする．

FD(fundamental diagram) パラメータを設定する．表 1 の区間上流端・下流端の Q-K(フローレート [台/hr]-密度 [台/km]) プロットを図 4 に示す.Q は，感知器の 5 分間交通量を時間交通量に換算（12 倍）して算定している. この図をみると，渋滞領域のデータが十分に得られな



図–4 fundamental diagram : 2022 年 07 月 (車両感知器地点 5 分間データ)



図–5 ETC2.0 プローブ軌跡の例

い車両感知器 (03-01-22,03-01-24,03-01-25) やエラー値が多いと思われるもの（03-01-28）が確認される．本検証では，簡単のため，地点番号「03-01-47」の車両感知器による Q-K プロットから推定した FD パラメータを全区間で用いることとした．本検証の VT で設定した FD パラメータは以下の通りである：

$$v = forward\ wave\ speed\ =\ 67[km/h]$$
$$w = backward\ wave\ speed\ =\ 20[km/h]$$
$$q_{max} = \text{最大交通流率}\ =\ 3750[cars/hr]$$

なお，今後の精度検証において，上記の FD パラメータでは精度が低下すると判断される場合，一定時間や区間ごとにキャリブレーションすることを検討することとする．

(2) 評価指標

本節では，VT の精度の評価指標を定義する．

評価指標の説明のために，まず，ETC2.0 プローブ車両軌跡の性質を図 5 の例を用いて, 説明する．図 5 は横軸が時刻，縦軸が距離のタイムスペース図である．図の例では, 地点 O〜D 間が交通状態推定の対象区間，現在時刻は, 状態推定を実施する時刻を示す．また，対象区間を挟んで 2ヶ所の ITS スポットが存在する．現在時刻において，車両 No1 は ITS1, 2 をともに通過しているため,O〜ITS スポット 2 間の車両軌跡が観測される．車両 No2, 3 は，ITS スポット 1 のみ通過しているため，現在時刻には，O〜ITS スポット 1 間の車両軌跡のみ観測される．また，車両 No4 は，ITS スポット未通過のため，車両軌跡は観測されない．このように ETC2.0 プローブは，ITS スポット未通過車両により，時空間に空白領域（図中の点線の軌跡）が存在してしまう．また，実際は，プローブ車両が ITS スポットに到着しても，データの処理時間がかかるため，処理時間分だけ空白領域は拡大する．したがって，センシングデータのみでは，空白領域の交通状態は不明である． VT を活用すると，空白領域の交通状態を補完推定できるといった利点がある．

本検証では，“空白領域の空間平均速度の RMSE(Root Mean Squared Error)”及び“メッシュ速度を用いた同時

刻総和法による旅行時間 ” を評価指標とする．RMSE を以下に定義する. 空白領域の時空間を大きさ t(時間) $\times l$(空間) のメッシュで分割する．メッシュのインデックスを $i = 1, 2, ..., I$ と表記する．メッシュ i の空間平均速度の真値を v_i^{true},VT による推定値を v_i^{VT} と表記する．RMSE は,

$$RMSE = \sqrt{\frac{1}{I}\Sigma_{i=1}^{I}\left(v_i^{true} - v_i^{VT}\right)^2} \tag{10}$$

と定義される．なお，ETC2.0 プローブ軌跡および VT の推定軌跡による空間速度は，Edie[17] による手法で算定する．

次に同時刻総和法による旅行時間の算定方法を定義する．同時刻総和法は，時刻 t において，対象区間を構成する全てのセグメントの所要時間の総和を求める方法である．なお，首都高速道路の情報提供に用いている旅行時間は，1 分毎に更新している．旅行時間算定区間が，N 個のセグメントで構成されているとすると，時刻 t における同時刻総和法によるの旅行時間 $T_{st}(t)$ は下式で定義される．

$$T_{st}(t) = \Sigma_{i=1}^{N}\frac{l_i}{v_i(t)} \tag{11}$$

ここに，

l_i = セグメント i の距離

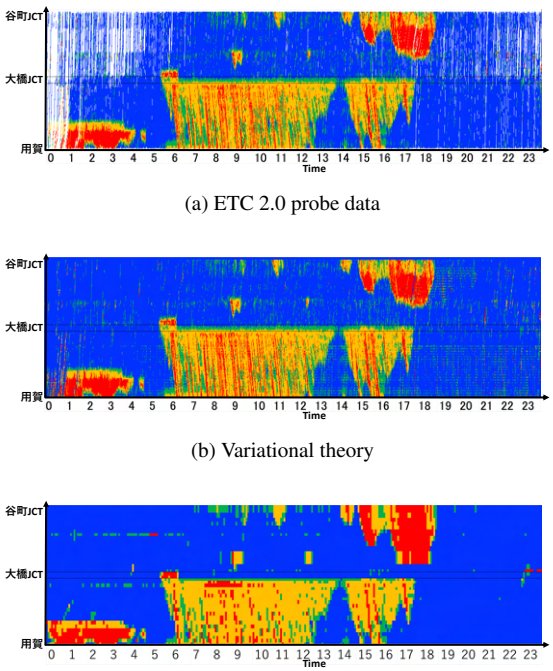
$v_i(t)$ = 時刻 t におけるセグメント i の空間平均速度

(3) 平常時の検証結果

本節では平常時の 2022 年 7 月平日（表 3 の 10 日間）の VT の精度検証結果を述べる．

まず，空間平均速度によるタイムスペース図を評価する. 一例として，2022 年 7 月 1 日（金）の 24 時間のタイムスペース図を図 6 に示す. 上段 (図 6a) が ETC2. 0 プローブ軌跡によるタイムスペース図である. 色は，メッシュ（100m×1 分）の空間平均速度 (赤 [低速] →青 [高速]) を示す．白色箇所はデータ欠損箇所である．図の中段 (図 6b) は，VT による推定値，下段 (図 6c) は車両感知器速度（地点 5 分）によるタイムスペース図である. 同図を見ると，VT は概ね，真値である ETC2.0 と類似していることから，渋滞状況を再現できていると判断される．

次に前述したタイムスペース図の空間平均速度の類似性を式 10 で定義した RMSE で評価する．図 7 に日別の RMSE を示す. 横軸は，2022 年 7 月の日付，縦軸は RMSE を表している．同図を見ると，全ての日で，車両感知器よりも VT の RMSE が小さい状況が確認される．日別・時間帯別の RMSE を図 8 に示す．これを見ると，夜間（0-7 時,19-24 時）は車両感知器と VT の RMSE は

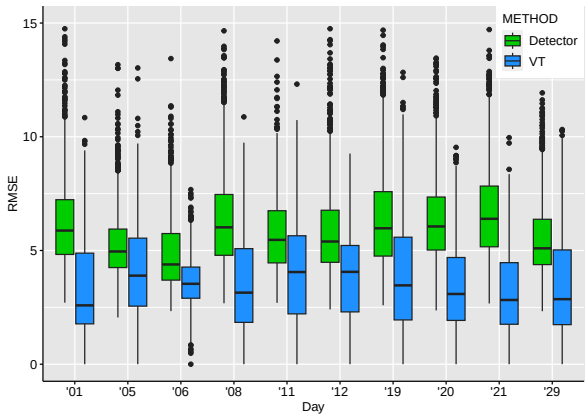


(a) ETC 2.0 probe data

(b) Variational theory

(c) Detector

図–6 タイムスペース図：平常時（2022/ 7 / 1 （金））
注）色は，メッシュ（100m × 1 分）の空間平均速度 (赤 [低速] →青 [高速])，白色メッシュはデータ欠損



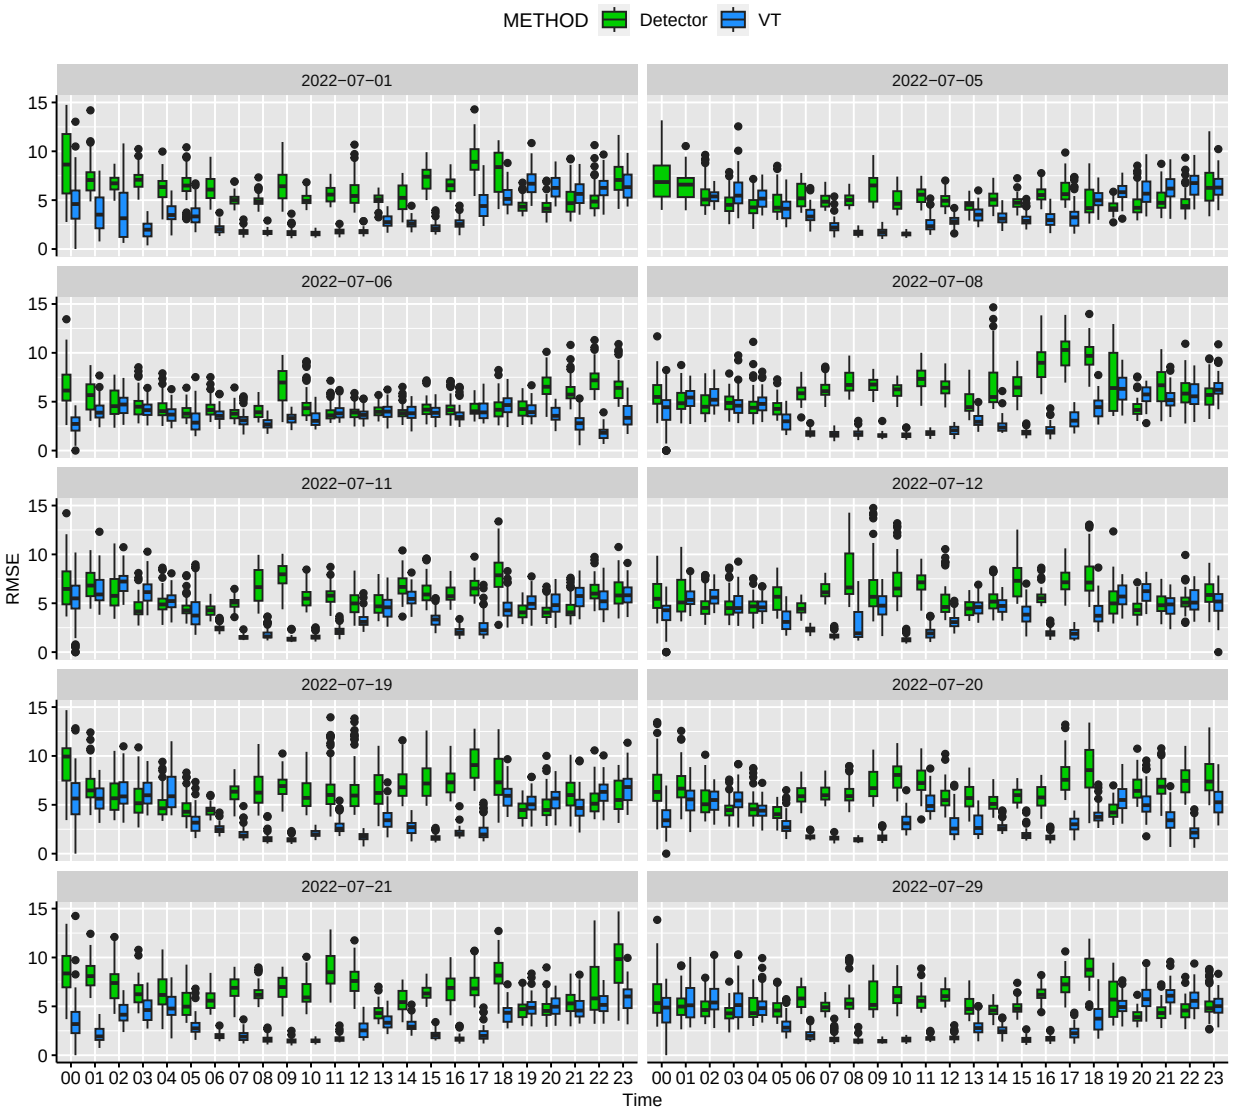
図–7 日別の空間平均速度の RMSE：平常時（2022 年 7 月）

大きな差はないが，比較的，渋滞している昼間（7-19 時）は VT の方が RMSE が小さい傾向が確認される．

最後に，旅行時間の検証結果を述べる. 図 9 に所要時間の時系列変化を示す．この図をみると，VT は，ETC2.0 プローブと大きな誤差を生じさせることなく旅行時間が推定できている. 一方で，車両感知器は，1 日，8 日等の夕方の渋滞発生時に旅行時間を過剰に推定している状況が確認される．

(4) 事故発生時の検証結果

本節では，収集した事故関連のデータを整理し，事故時の交通流をケーススタディとした交通状態推定結



図–8 時間帯別の空間平均速度の RMSE 時系列変化：平常時（2022 年 7 月）

果について述べる．

まず，2022 年 7 月の事故発生状況を整理する．表 4 に 2022 年 7 月の事故発生状況を整理する．事故は，14 件発生しており，追突事故が 6 件と最も多く，次いで，車両接触事故 4 件，施設接触 3 件となっている．ここでは，“（1）2022 年 7 月 13 日（水），池尻出口”および“（2）2022 年 7 月 28 日 (木)12:55,7.70KP ”の事故をケーススタディとしてモデル検証する．

次に，事故時の交通流率の推定方法を述べる．事故時の交通流率，$\hat{q}_1(t)$ の推定方法は，状態空間モデルによるスムージング処理[3] を用いた．モデルのパラメータは，既往研究の値を踏襲し，設定した. パラメータの詳細は，参考文献[3] を参照されたい. 表に示すように，事故地点は所与とし，事故による交通影響の見られる 2 時間 (7 月 13 日 11:30-13:30，7 月 28 日　12:30-14:30) を推定対象とした．

プローブ軌跡データによる事故発生時の渋滞の発生状況を整理する. 図 10 に ETC2.0 プローブ軌跡による事故発生時のタイムスペース図を示す. 図中の黒線は，事故統計データベース[2]による事故発生位置（kp, 時刻）を示している．このデータには，通報もしくは，パトロールにより事故の通報があった時刻が記録されている．図 10a を見ると，この事故は渋滞内で発生していることがわかる. 事故発生後に渋滞は用賀まで延伸しており，13:30 ごろに渋滞が解消している. 一方，図 10bd では，事故後に事故地点を先頭とした渋滞が発生している．なお，事故統計データベースによる事故発生位置（黒線）と渋滞先頭位置がズレている．これは，事故発生から通報までの時間ロスが影響しているものと推察される. また，2 事例とも事故発生後の渋滞中に ETC2.0

[2] 事故統計データベースとは，交通管制システムに記録された事故データである．データベースには，事故発生日時，場所（kp），事故形態，警察到着時刻等が記録されている．



図–9 用賀-谷町 JCT 間の所要時間の時系列変化：平常時（2022 年 7 月）

プローブが未観測なっている状況が共通している．

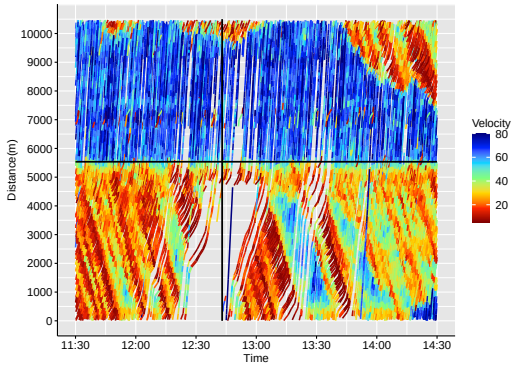
次に，事故発生時の渋滞状況と状態空間モデルによる交通流率の推定結果を述べる．図 10a および図 10b の ETC2.0 プローブデータと区間上流端 (03-01-47)・下流端 (03-01-32) の車両感知器を用いて推定した交通流率を図 11a および，図 11b に示す．上段の，丸印が真値，三角が下流端の車両感知器のフローレート，赤線が SSM による推定値，リボンは推定値±標準偏差，ならびに青線は，平常時の FD に設定した最大フローレート (q_{max}) を示している．バツ印は，ETC2. 0 プローブデータが観測されなかった時間帯である．下段の図は，時間帯別の誤差を示しており，ロリポップは，誤差値，折れ線は，誤差の絶対値の変化を示している．

図 11a を見ると，状態空間モデルは，事故前後の交通流率の変化を概ね捉えられている．しかし，プローブデータ未観測の時間帯（バツ印）に着目すると，状態空間モデルは，観測値による事後分布の推定ができない状態であるため，標準偏差（システムノイズ）が拡大している状況が確認される．一方，同時間帯の下流端の車両感知器データをみると，状態空間モデルよりも精度良く，事故地点の交通流率を追随している時間もある．一方，図 11b を見ると，事故後に状態空間モデルは，真値の交通流率を精度よく追随している．プローブ未観測時間帯に着目すると，下流側感知器の方が誤差が小さい傾向が見られる．上記より，交通流率の推定は，“ プローブ観測時には，状態空間モデルを使用するに対して，プローブ未観測時には，下流側の車両感知器を使用という方針が妥当 ” と考える．

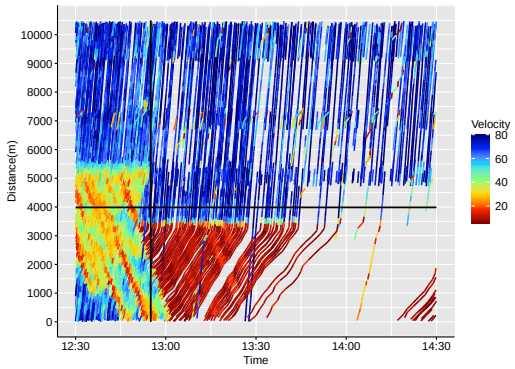
渋滞発生状況の精度検証結果を述べる．図 12, 図 13 にタイムスペース図を示す．図 12a-図 12c は，図 6 と同じ構成である．図 12d は，11:30-13:30 において，状態空間モデルにより推定した交通流率を VT に入力している．

表–4 事故発生状況 (2022 年 7 月)

No	年月日	時刻	KP	事故形態
1	4 日 (月)	09:38	11.30	車両接触
2	7 日 (木)	07:14	11.60	車両接触
3	13 日 (水)	12:43	6.1(池尻出口)	事故
4	13 日 (水)	21:49	4.20	施設接触
5	14 日 (木)	17:28	11.20	追突
6	15 日 (金)	02:50	11.50	施設接触
7	15 日 (金)	17:14	0.60	追突
8	15 日 (金)	20:11	0.90	追突
9	22 日 (金)	13:04	11.30	車両接触
10	25 日 (月)	08:45	4.80	追突
11	26 日 (火)	13:40	11.20	追突
12	27 日 (水)	07:11	4.00	施設接触
13	28 日 (木)	10:25	11.60	車両接触
14	28 日 (木)	12:55	7.70	追突

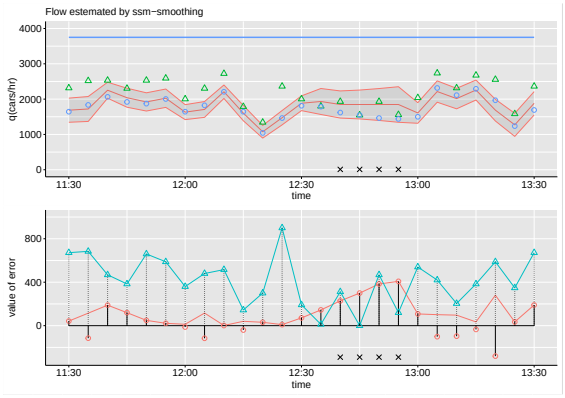


(a) 2022/7/13(水)12:43, 池尻出口事故

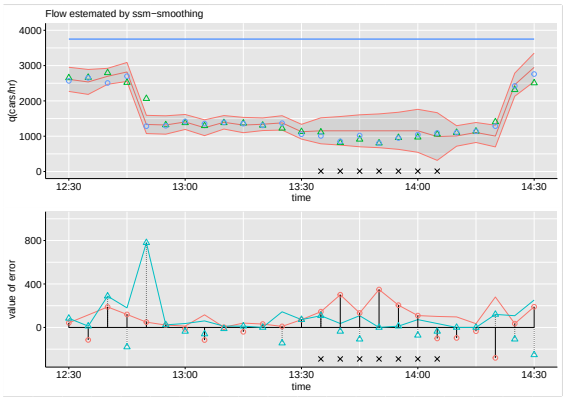


(b) 2022/7/28(木)，追突事故，7.7KP

図–10 事故前後の渋滞発生状況
注）黒線は事故発生時間・位置の断面を示す.



(a) 2022/ 7 /13(水)12:43, 池尻出口



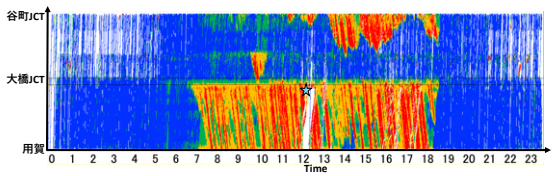
(b) 2022 年 7 月 28 日 (木)，追突事故，7.7KP

図–11 事故前後の交通流率
注）図の凡例は以下の通り：
上段; 丸 (青) ＝真値 (車両感知器 (03-01-32)), 線 (赤)= 状態空間モデルによる交通流率の期待値，リボン=期待値±標準偏差, 三角（緑）=下流の車両感知器 (03-01-28,6.07KP), バツ＝プローブデータ未観測の時間帯
下段; 折れ線＝誤差の絶対値（青：下流側の車両感知器，赤：状態空間モデル）, ロリポップ＝真値との誤差（青：下流側の車両感知器，赤：状態空間モデル）

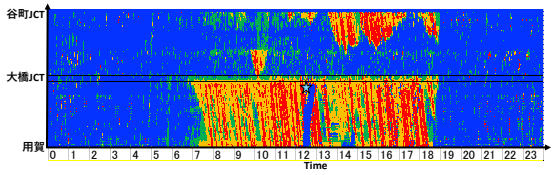
図中の青い星マークは事故地点である. この図をみると，VT は概ね，精度良く渋滞を推定しているが，プローブ未観測箇所（図 12a の 12 時ごろの白色のメッシュ）では，非渋滞と推定している. 車両感知器（図 13c）をみると，プローブ未観測の時間帯は，事故渋滞が発生している. このことから，おそらく実際は，事故渋滞が発生しているものの，VT では誤った推定を行なってしまっていると推察される．図 12d を見ると，プローブ未観測箇所での渋滞が再現されている. よって，事故時は，状態空間モデルにより交通流率を推定することは有効と考えられる. 図 13 を見ると，13 日の事例と同様に状態空間モデルを用いた場合の方が，精度よく渋滞を再現している.

図 14 に空間平均速度の RMSE 誤差を示す. 図を見ると，VT は，車両感知器よりも精度良く渋滞を再現している状況が確認される. 一方，プローブ未観測の時間帯は，VT の RMSE 誤差が拡大している状況が確認される. 状態空間モデルを用いた場合は，RMSE 誤差が低減している状況が見られる.

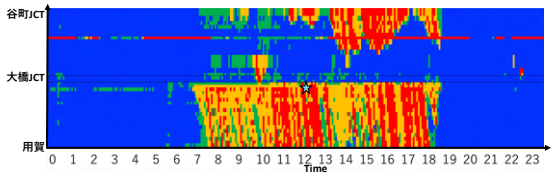
図 15 に旅行時間の時系列変化を示す．どの手法も概ね真値（ETC2. 0 プローブ）と乖離はない．しかし，



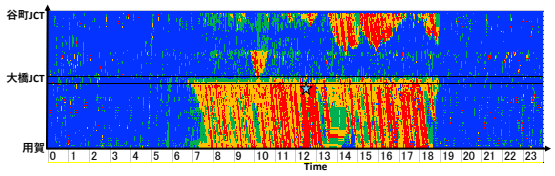
(a) ETC 2.0 probe data



(b) Variational theory

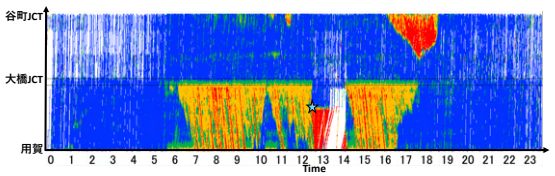


(c) Detector

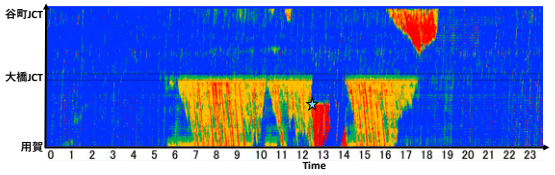


(d) VT+State-space model

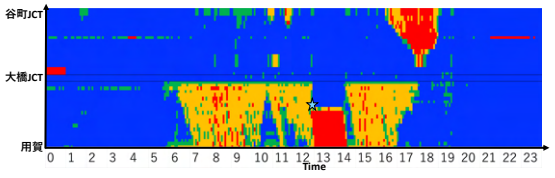
図–12 タイムスペース図：(2022/7/13(水)12:43, 池尻出口事故)
注 1）色は，メッシュ（100m × 1 分）の空間平均速度 (赤 [低速] →青 [高速])，白色メッシュはデータ欠損
注 2）星は，事故統計データによる事故地点



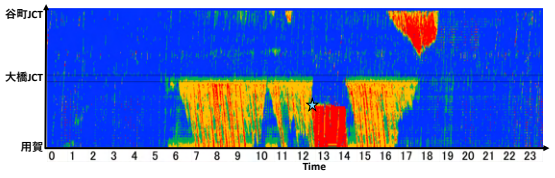
(a) ETC 2.0 probe data



(b) Variational theory



(c) Detector



(d) VT+State-space model

図–13 タイムスペース図（2022/7/28(木)10:25,11.60KP, 車両接触事故）
注 1）色は，メッシュ（100m × 1 分）の空間平均速度 (赤 [低速] →青 [高速])，白色メッシュはデータ欠損
注 2）星は，事故統計データによる事故地点

プローブ未観測の時間帯は，感知器データが ETC2.0 プローブと大きく乖離している状況が見られる. 状態空間モデルは，感知器の状況に近い．便宜上，ETC2.0 プローブの旅行時間は，プローブが未観測の場合は，*forwardwave speed* で走行できるものとして処理しており，この処理が所要時間精度に影響しているものと思われる. プローブ未観測の場合に真値をどのように設定するかは今後の課題と考える.

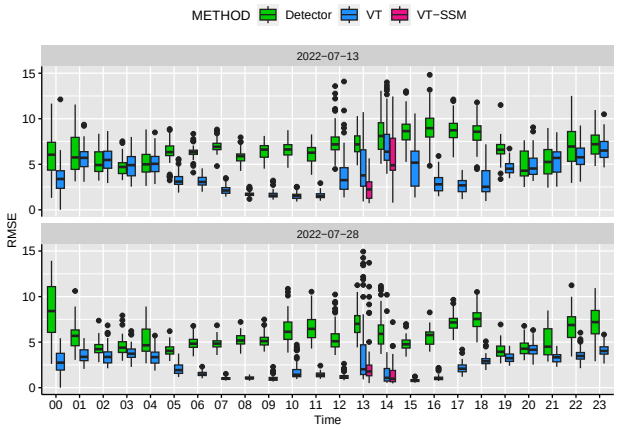
5. おわりに

本研究では，センシングデータと交通流モデルを用いた交通状態の長期モニタリング手法を提案した．具体的には，交通流モデルの解法の一つである VT 及び VT を拡張した状態空間モデルにより，交通状態を推定するモデルを構築した．首都高速道路の 3 号渋谷線上りの交通流に適用し，検証した結果，平常時，事故時ともに良好な精度が得られた.

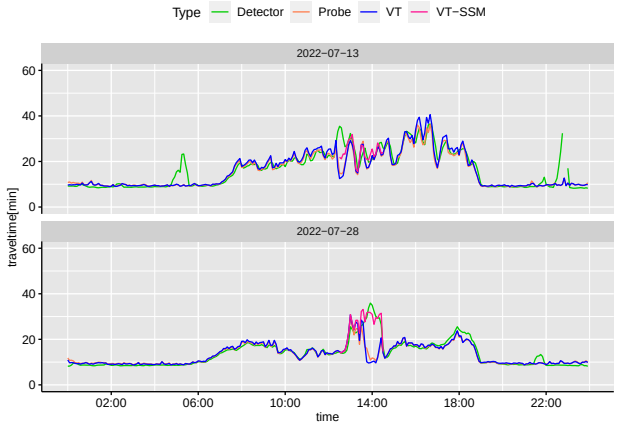
今後の課題を以下に整理する.

1) モデル検証事例の拡充：ここでは，3 号渋谷線をケーススタディとしたモデル検証を行った．モデルの妥当性を検証するためには，更に検証事例を拡充し，実装に向けた課題を抽出する必要がある.

2) 常時モニタリングに向けたシステム開発：交通管制システムに提案モデルを実装するためには，常時（24 時間,365 日) 交通モニタリングする必要がある．そのためには，“ 交通状態推定の各処理のモジュール化 ”，“ 観測データの前処理（e.g. データ収集，マップマッチング，異常値除外）のリアルタイム化 ” や “ プロトタイプによるシステムの常時稼働 ” など，開発する必要がある．そのため，本研究では，今後，モデルの実装テストを行うためのエミュレータ開発に着手する予定である.



図–14 RMSE の時系列変化：事故時
1)2022/ 7 /28(木)10:25,11.60KP,
2) 車両接触,2022/ 7 /13(水)12:43, 池尻出口



図–15 用賀-谷町 JCT 間の所要時間の時系列変化：事故時
1)2022 年 7 月 28 日 (木)10:25,11.60KP,
2) 車両接触,2022/ 7 /13(水)12:43, 池尻出口

謝辞: 本研究成果は，JSPS 科研費 22K04356，首都高速道路株式会社との共同研究「リアルタイムデータ収集の高度化・合理化に向けたデータ融合手法に関する研究」により得られたものです．ここに感謝の意を表す．

参考文献

1) 川崎洋輔, 梅田祥吾, 桑原雅夫, 熊倉大起, 大畑長, 田中淳, 吉川真央, and 鈴木裕介: 首都高速道路におけるプローブ軌跡データと車両感知器の融合による交通状態の推定および精度検証, **土木学会論文集** *D3*（**土木計画学**）, Vol.77, No.5, pp.I_521–I_534, 2022.
2) 川崎洋輔, 梅田祥吾, 桑原雅夫, 熊倉大起, 大畑長, 田中淳, 南航太, and 鈴木裕介: 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, **土木学会論文集** *D3*（**土木計画学**）, Vol.76, No.5, pp.I_1297–I_1309, 2021.
3) 川崎洋輔, 桑原雅夫, 梅田祥吾, 熊倉大起, 大畑長, 田中淳, 吉川真央, and 川松祐太: センシングデータと交通流モデルの融合による事故発生時の交通状態推定手法の提案, **土木学会論文集** *D3*（**土木計画学**）*[**投稿中**]*, Vol.79, No.20, pp.I_**–I_**, 2024.
4) Daganzo, C. F.: A variational formulation of kinematic waves: Solution methods, *Transportation Research Part B: Methodological*, Vol.39, No.10, pp.934–950, 2005.
5) Mehran, B., Kuwahara, M., and Naznin, F.: Implementing kinematic wave theory to reconstruct vehicle trajectories from fixed and probe sensor data, *Transportation Research Part C: Emerging Technologies*, Vol.20, No.1, pp.144–163, 2012, Special issue on Optimization in Public Transport+ISTT2011.
6) Takenouchi, A., Kawai, K., and Kuwahara, M.: Traffic state estimation and its sensitivity utilizing measurements from the opposite lane, *Transportation Research Part C: Emerging Technologies*, Vol.104, pp.95–109, 2019.
7) Seo, T., Kawasaki, Y., Kusakabe, T., and Asakura, Y.: Fundamental diagram estimation by using trajectories of probe vehicles, *Transportation Research Part B: Methodological*, Vol.122, pp.40–56, 2019.
8) Sun, Z., Jin, W.-L., and Ritchie, S. G.: Simultaneous estimation of states and parameters in newell's simplified kinematic wave model with eulerian and lagrangian traffic data, *Transportation Research Part B: Methodological*, Vol.104, pp.106–122, 2017.
9) Kawasaki, Y., Hara, Y., and Kuwahara, M.: Traffic state estimation on a two-dimensional network by a state-space model, *Transportation Research Part C: Emerging Technologies*, Vol.113, pp.176–192, 2020, ISTTT 23 TR_C-23rd International Symposium on Transportation and Traffic Theory (ISTTT 23).
10) Culli, M. J. and Hall, F. L.: Incident detection on an arterial roadway, *Transportation Research Record*, Vol.1603, No.1, pp.112–118, 1997.
11) 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, Proceedings of 18th ITS World Congress, 2011.
12) 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*, Vol.81, pp.330–341, 2017.
13) Cai, Y., Wang, H., Chen, X., and bin Jiang, H.: Trajectory-based anomalous behaviour detection for intelligent traffic surveillance, *Iet Intelligent Transport Systems*, Vol.9, pp.810–816, 2015.
14) Kusakabe, T.: Detection method of wide-area incident with massive probe vehicle data, 2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC), pp. 1–6, 2017.
15) Kuwahara, M., Takenouchi, A., and Kawai, K.: Traffic state estimation by backward moving observers: An application and validation under an incident, *Transportation Research Part C: Emerging Technologies*, Vol.127, pp.103158, 2021.
16) Kitagawa, G.: A self-organizing state-space model, *Journal of the American Statistical Association*, Vol.93, No.43, pp.1203–1215, 1998.
17) Edie, L. C.: Discussion of traffic stream measurements and definitions, *Proceedings of the Second Interna-tional Symposium on the Theory of Traffic Flow*, pp. pp.139–154, 1963.

(Received October 13, 2023)
(Accepted ,)

PROPOSAL FOR A LONG-TERM MONITORING METHOD OF TRAFFIC STATES USING SENSING DATA AND TRAFFIC FLOW MODEL

Yosuke KAWASAKI, Masao KUWAHARA, Yuki ITO, Yuta KAWAMATSU,
Takeshi OHATA, Daiki KUMAKURA, Mao YOSHIKAWA, Yui EMORI

This study proposes a long-term monitoring method of traffic conditions using sensing data and traffic flow models. In traffic control, it is important to monitor traffic flow and provide information. Since sensors (e.g., vehicle detectors, probe data) used to monitor traffic conditions are sparse, a traffic flow model is required to estimate unobserved areas. Although the parameters of the traffic flow model need to be set in advance, it is difficult to calibrate the model parameters in advance because of the ever-changing nature of traffic flow. In this study, we identify technical issues of traffic flow models for long-term monitoring of traffic conditions as described above, and describe a policy for improving models to solve these issues. The model is validated through a case study of actual traffic flow on the Metropolitan Expressway.