

自動運転車両の車間距離データに基づく 混合交通流の車線別状態推定

酒井 健吾¹・瀬尾 亨²・布施 孝志³

¹ 非会員 東京大学大学院 社会基盤学専攻 (〒113-8656 東京都文京区本郷七丁目三番地一号)

E-mail: sakai@trip.t.u-tokyo.ac.jp

² 正会員 東京大学大学院助教 社会基盤学専攻 (〒113-8656 東京都文京区本郷七丁目三番地一号)

E-mail: seo@civil.t.u-tokyo.ac.jp

³ 正会員 東京大学大学院教授 社会基盤学専攻 (〒113-8656 東京都文京区本郷七丁目三番地一号) .

自動運転車の普及段階には手動運転車との混合流が生じ、その高精細で効率的な制御のため車線別交通状態推定の重要性の高まりが予想される。また、自動運転車の軌跡や車間距離情報はコストや観測範囲の制約が大きい路側観測機器に代わる新たな交通状態の観測手段として期待される。しかし、多車線道路において車線別交通状態を自動運転車の観測情報のみに基づき推定する手法は提案されていない。本研究では、多車線道路の混合交通流に対し、自動運転車の観測する車間距離情報により車線別交通状態を推定する手法を構築した。具体的には、まず多車線道路において軌跡に着目したラグランジュ座標型の多車線交通流モデルを保存則に基づき構築した。その上で、データ同化を用いて本モデルを観測情報と統合し、交通状態を推定する手法を開発した。

Key Words: *autonomous car, traffic stream model, multi lane, data assimilation*

1. はじめに

近年、自動運転の技術開発・検証がさかんに取り組まれているが、実用化に際して自動運転車を高精細かつ効率的に制御していくためには交通状態の推定がこれまで以上に重要となる。交通状態推定では道路上の車両の速度や密度といった変量の時間・空間横断的な把握を目指す。短期的には混雑情報の提供や信号制御に活用されるほか、長期的には道路の新設等の判断材料としても、重要な役割を果たす。自動運転車は経路や車線を自ら判断して走る。この際、車載カメラなどで確認できる範囲の情報だけでなく、車両からは直接見えないような少し先の交通状況についても認識して走行するのが望ましい。例えば道路合流部においては、合流先道路の車両の位置や速度の情報を得られれば、自動運転車が予め速度を調整して最小限の減速で円滑な合流を実現できる。

自動運転車は交通状態推定の需要を高めると同時に、新たな観測手法としても期待される。現在我が国では路上に設置された感知器を用いる手法が主流となっている。しかし、機器の設置や維持には多額の費用を要するため、すべての道路に十分な数の感知器を設置するのは現実的とは言えない。また、感知器の測定は空間について離散

的であり、連続的に交通状態を把握することはできない。そこで、限られた地点の観測情報から他の部分の連続的な交通状態を推定しなければならない。これは線形などにより地点ごとに特性の異なる交通流を正確に把握するには大きな欠点であった。近年ではコネクティッドカーなどプローブとして使える車両が増加しており、道路を走行している車両の位置や速度といった情報をリアルタイムに取得できるようになりつつある。とはいえ、道路上を走行するすべての車両がこのような機能を備えるには長い時間を要すると予想される。この間は、自動運転車と既存の車両とが共存する混合流となる。

混合流においても、自動運転車から得られる情報をプローブとして活用すると、地上機器に頼らずに交通状態を推定できる可能性がある。Nanthawichit¹⁾らは、このようなプローブデータを従来型の感知器による情報と組み合わせた推定手法を提案している。さらに Bekiaris-Liberis²⁾は、感知器とプローブの観測情報を用いて車線別の交通状態をモデルベースで推定する手法を提案している。これらはプローブ軌跡からの推定が困難な量的情報を路側感知器から取得しており、依然として観測コストの問題が残る。Seo and Kusakabe³⁾は、自動運転のために観測される車間距離の情報を利用して、路側感知器に頼らな

い推定手法を提案している。車間距離が均等であるとの仮定の下で、プローブ間に存在する車両台数を推定する。単車線道路であれば、交差点間において車両の前後関係や台数は保存するため、この手法が有効といえる。しかし主要な道路に多い多車線道路においては十分な検討がなされているとは言い難い。

多車線道路では各車線における走行車両台数が保存せず、観測情報と交通流モデルとの統合が必要となる。車線変更や追い越しなどにより、多車線道路では任意の地点で車線間に車両の流動が生じる。現状の観測機器ではすべての車線変更に対する直接の観測は困難であり、部分的な観測情報を多車線交通流モデルと統合していく必要がある。しかしこれまでの多車線交通流モデルでは、プローブによる観測を前提としたものは見当たらない。

Laval and Daganzo⁴⁾は車線ごとに Kinematic Wave (KW) モデル⁵⁾⁶⁾を適用し、多車線の交通流をモデル化している。車線間の速度差に応じて車線変更需要を推定し、IT (Incremental-Transfer) principle⁷⁾に基づいてブロック間の車両の移動量を調整する。車線変更が及ぼす交通流への影響を考慮したモデルである。さらに、この研究では車線変更車両がそれぞれ確率的に生じるものとされているのに対して、車線変更による効用に着目したのが Shioni ら⁸⁾である。こちらは交通需要量に対する各車線の利用率が均衡に向かう過程として車線変更をモデル化している。しかしこれらの手法は車線変更にまつわるパラメータの調整が不可欠であり、すべての道路において実装していくのは困難である。また、いずれもオイラー型の観測を前提としており、プローブのような移動体観測にそのまま対応できるものではない。van Wageningen-Kessel ら⁹⁾は、ラグランジュ型座標系における離散 KW モデルを開発しているが、ネットワークにおける各リンクを対象としており、個別の車線レベルの検討には至っていない。

本研究では、多車線道路の混合交通流に対し、自動運転車の観測する車間距離情報により車線別交通状態を推定する手法を構築する。具体的には、まず多車線道路において車両軌跡に着目したラグランジュ座標型の多車線交通流モデルを保存則に基づき構築した。その上で、データ同化を用いてモデルを Seo and Kusakabe の手法に基づく観測情報と統合し、交通状態を推定する手法を開発した。

2. 手法

本章では、まず本研究で提案する交通流モデルについて説明する。その後、Seo and Kusakabe の提案手法とその交通流モデルとの統合について述べる。

(1) 多車線交通流モデルの構築

本研究で提案する交通流モデルでは、道路を一定の長さのセグメントに分割し、セグメント内の各車線において2台の自動運転車に挟まれる領域を単位として各領域内の車両台数の遷移を定式化する。分岐合流を含まない道路区間を、数百メートル程度の長さのセグメントに分割する。車両はセグメントの境界部分 x_j でのみ車線変更するものと近似的にみなす。すなわち、車両は必ずセグメントの上流端から下流端まで同じ車線を走る。なお、実際の車線変更は地点が限定されたものではないが、車両が前に進みながら行う動作であり、車線変更箇所は空間的な幅を持つ。セグメントの長さある程度小さく設定すれば、車線変更の多くがセグメント境界をまたぎ、この境界を車線変更地点とすればよい。図-1のように、ある車線において区間 $x_j \leq x < x_{j+1}$ のセグメント内で2つの自動運転車の軌跡で挟まれる時空間領域を1単位として \mathbf{D}_m^j とする。ここで、 m は領域の後ろ側の縁を走るプローブを表す。ただし、領域の前側の縁を走る自動運転車は領域に含まない。領域内ではどの地点でも通過車両の台数は一定とみなせる。この領域内の車両の集合を $\mathbf{N}(\mathbf{D}_m^j)$ で表し、その台数を $|\mathbf{N}(\mathbf{D}_m^j)|$ と表記する。車線変更がなければ、セグメント境界において車両は \mathbf{D}_m^j から \mathbf{D}_m^{j+1} に進む。多車線道路では一部の車両は車線を変更し、 $\mathbf{D}_{m_1}^j$ から $\mathbf{D}_{m_2}^{j+1}$ へ進む。ここで、 m_1, m_2 は相異なる自動運転車である。車線を変更する台数を $\phi(\mathbf{D}_{m_1}^j \rightarrow \mathbf{D}_{m_2}^{j+1})$ で表すと、変更しない車両の台数について式(1)が成り立つ。

$$|\mathbf{N}(\mathbf{D}_{m_i}^{j+1})| = |\mathbf{N}(\mathbf{D}_{m_i}^j)| + \sum_{m \neq m_i} \phi(\mathbf{D}_m^j \rightarrow \mathbf{D}_{m_i}^j) - \sum_{m \neq m_i} \phi(\mathbf{D}_{m_i}^j \rightarrow \mathbf{D}_m^j) \quad (1)$$

自動運転車が車線変更した場合には、その前後の車線において領域の数が増減する。変更前の車線では、図-2のように、下流側セグメントにおいて領域の数が1つ減




図-1 領域の定義




図-2 車線変更前の車線の領域 (自動運転車のみ記載)




図-3 車線変更後の車線の領域 (自動運転車のみ記載)

少するため、1つの領域に2つの領域から車両が流入する。ゆえにこの場合の遷移は、

$$\begin{aligned}
 |\mathbf{N}(\mathbf{D}_{m_{i+1}}^{j+1})| &= |\mathbf{N}(\mathbf{D}_{m_i}^j)| + \sum_{m \neq m_i} \phi(\mathbf{D}_m^j \rightarrow \mathbf{D}_{m_i}^j) \\
 &\quad - \sum_{m \neq m_i} \phi(\mathbf{D}_{m_i}^j \rightarrow \mathbf{D}_m^j) \\
 &\quad + |\mathbf{N}(\mathbf{D}_{m_{i+1}}^j)| + \sum_{m \neq m_{i+1}} \phi(\mathbf{D}_m^j \rightarrow \mathbf{D}_{m_{i+1}}^j) \\
 &\quad - \sum_{m \neq m_{i+1}} \phi(\mathbf{D}_{m_{i+1}}^j \rightarrow \mathbf{D}_m^j) - 1 \quad (2)
 \end{aligned}$$

となる。ここで、車線変更をした自動運転車を m_i とし、その後ろの自動運転車を $m_i + 1$ と表記している。第1項から3項が m_i より前の車両にあたり、次いで第4項から6項が後ろの車両にあたる。最終項の1はこの自動運転車 m_i 自身を示す。逆に、車線変更後の車線では図-3のように下流側セグメントにおいて領域の数が1つ増加する。すなわち、2つの領域に1つの領域から車両が流入する。車両が等間隔に走行していると仮定すれば、流入台数は各領域の上流端の時間幅の比に応じて按分され、次のように表現できる。

$$\begin{aligned}
 |\mathbf{N}(\mathbf{D}_{m_i}^{j+1})| &= \frac{t_{m_i}^{j+1} - t_{m_i-1}^{j+1}}{t_{m_{i+1}}^{j+1} - t_{m_i-1}^{j+1}} \left\{ |\mathbf{N}(\mathbf{D}_{m_{i+1}}^j)| \right. \\
 &\quad + \sum_{m \neq m_{i+1}} \phi(\mathbf{D}_m^j \rightarrow \mathbf{D}_{m_{i+1}}^j) \\
 &\quad \left. - \sum_{m \neq m_{i+1}} \phi(\mathbf{D}_{m_{i+1}}^j \rightarrow \mathbf{D}_m^j) + 1 \right\} \quad (3a)
 \end{aligned}$$

$$\begin{aligned}
 |\mathbf{N}(\mathbf{D}_{m_{i+1}}^{j+1})| &= \frac{t_{m_{i+1}}^{j+1} - t_{m_i}^{j+1}}{t_{m_{i+1}}^{j+1} - t_{m_i-1}^{j+1}} \left\{ |\mathbf{N}(\mathbf{D}_{m_{i+1}}^j)| \right. \\
 &\quad + \sum_{m \neq m_{i+1}} \phi(\mathbf{D}_m^j \rightarrow \mathbf{D}_{m_{i+1}}^j) \\
 &\quad \left. - \sum_{m \neq m_{i+1}} \phi(\mathbf{D}_{m_{i+1}}^j \rightarrow \mathbf{D}_m^j) + 1 \right\} \quad (3b)
 \end{aligned}$$

なお、 t_m^j でプローブ m が地点 x_j に到達した時刻を表す。車線変更台数は変更前の車線の車両台数、プローブにより得られる車線変更率と車線変更の機会をもとに式(4)のように予測する。

$$\phi(\mathbf{D}_{m_1}^j \rightarrow \mathbf{D}_{m_2}^j) = |\mathbf{N}(\mathbf{D}_{m_1}^j)| \Phi(j, l_1 \rightarrow l_2) \frac{|\mathbf{D}_{m_1}^j \cap \mathbf{D}_{m_2}^j|}{|\mathbf{D}_{m_1}^j|} \quad (4)$$

ここで、 m_1, m_2 はそれぞれ $j < x < j + 1, j + 1 < x < j + 2$ において車線 l_1, l_2 を走る自動運転車である。

$|\mathbf{N}(\mathbf{D}_{m_1}^j)|$ は変更元領域の車両台数であり、車線変更する可能性のある車両の台数に対応する。 $\Phi(j, l_1 \rightarrow l_2)$ は区間 $j < x < j + 1$ における車線 l_1 から l_2 への車線変更率であり、事前に得た自動運転車の軌跡情報をもとに算出する。なお、ここで自動運転車の車線変更に関する挙動はその他の車両の挙動と同様と仮定している。

$\frac{|\mathbf{D}_{m_1}^j \cap \mathbf{D}_{m_2}^j|}{|\mathbf{D}_{m_1}^j|}$ は時空間領域を共有する割合である。時空間領域内において車線変更が均等に発生すると仮定し、この2車線間の車線変更で遷移する先の領域をその重なり大きさに応じて割り振っている。式(4)で用いるのは軌跡情報のみであり、単純ではあるが車線変更の主体と実現可能性を移動体観測を前提として評価したものといえる。対象区間における自動運転車の走行実績があればどの道路であっても計算でき、事前のパラメータ調整等

を必要としない利点がある。

(2) 観測情報との統合

Seo and Kusakabe による単車線道路での交通状態推定手法を本研究で定める領域のそれぞれで適用し、この交通流モデルと統合して多車線道路の交通状態を推定する。

同手法では、領域内に存在する車両台数を推定し、各地点の累積台数をもとに速度や交通量を算出する。台数の推定は以下の式に従う。

$$|\hat{N}(A_m^j)| = \frac{|A_m^j|}{(|a_{m-1}(A_m^j)| + |a_m(A_m^j)|)/2} \quad (5)$$

ただし、図-4のように、領域 D_m^j に対して領域前方の自動運転車の 1 台前の車両と領域後方の自動運転車両に挟まれる領域を A_m^j とし、 $|\hat{N}(A_m^j)|$ はその領域に含まれる車両の数の推定値としている。領域の前方の自動運転車とその前の車両とに挟まれる時空間領域を $a_{m-1}(A_m^j)$ 、後方の自動運転車とその前の車両とに挟まれる領域を $a_m(A_m^j)$ とする。分母は自動運転車に観測された、車間距離の時間積分値の平均といえる。なお、この $|\hat{N}(A_m^j)|$ と提案モデルにおける $|\hat{N}(D_m^j)|$ には次の関係が成り立つ。

$$|\hat{N}(A_m^j)| = |\hat{N}(D_m^j)| + 2 \quad (6)$$

この領域ごとの推定台数から、累積台数は次のように算出できる。

$$\hat{N}(t_0^x, x) = 0 \quad (7)$$

$$\hat{N}(t_m^x, x) = \hat{N}(t_{m-1}^x, x) + |\hat{N}(D_m^j)|$$

$\hat{N}(t_m^x, x)$ は地点 x において自動運転車 m が通過する時刻 t_m^x の推定累積通過台数を指す。自動運転車のうち $m = 0$ は推定対象とする時空間領域を最初に通過する自動運転車であり、この時点の累積台数を 0 として扱う。流量は累積台数を時間で偏微分したものであるから、推定流量 \hat{q} は

$$\hat{q}(t, x) = \frac{\hat{N}(t_m^x, x) - \hat{N}(t_{m-1}^x, x)}{t_m^x - t_{m-1}^x} \quad (8)$$

で計算できる。ただし、 $t_{m-1}^x < t < t_m^x$ を満たす。詳細は Makigami ら¹⁰⁾ に詳しい。また、密度は領域内の総所要時間を時空間領域の大きさで除したものであるから、

$$\hat{k}(t, x) = \frac{(t_{m-1}^{x_{j+1}} - t_{m-1}^{x_j} + t_m^{x_{j+1}} - t_m^{x_j})}{2} \times \frac{|\hat{N}(D_m^j)|}{|D_m^j|} \quad (9)$$

で得られる。ここで、 (t, x) は領域 D_m^j の内部とする。この式の分子は、領域内において車両がセグメントを通過するのに要する時間を自動運転車の所要時間の平均とみなし、これに推定した車両台数を乗じて総所要時間としている。

本手法では各領域の車両台数に着目し、構築した交通流モデルと Seo and Kusakabe の手法による観測情報とをカ




図-4 車間距離情報による観測

ルマンフィルタ¹¹⁾の手法を用いて統合する。各セグメントにおける車両台数

$$x^j = (|\hat{N}(D_1^j)|, \dots, |\hat{N}(D_m^j)|) \quad (10)$$

を状態ベクトルとし、これを式(1-4)の交通流モデルに従い上流から下流へと遷移させる。カルマンフィルタにおいて、状態空間モデルは

$$x^{j+1} = F^j x^j \quad (11)$$

$$y^j = H^j x^j + v^j$$

となる。ただし、 F^j は前節で述べた交通流モデルを表す行列、 y^j は車間距離情報に基づき観測される車両台数からなる観測ベクトルで

$$y^j = (|\hat{N}(D_1^j)|, \dots, |\hat{N}(D_m^j)|) \quad (12)$$

であり、 H^j は観測行列である。 v^j は観測ノイズベクトルで、 Q^j を分散共分散行列とする正規分布に従う。また、境界条件として x^0 を与える。 x^0 は対象区間の上流端におけるプローブ間の車両台数に当たり、この地点に路側感知器があればその観測情報の組み込みも可能である。この枠組みに従い、 F^j, H^j, y^j, Q^j をもとに最も確からしい状態 x^j を決定する。詳細は樋口・上野¹¹⁾ を参照されたい。

3. 提案手法の適用

(1) 適用条件

本研究で想定しているような自動運転車に取得された車間距離情報は、現在のところ広く流通はしていない。そこで、阪神高速道路の全車両軌跡データ Zen Traffic Data¹²⁾ をもとに、一部車両を自動運転車とみなして車間距離情報を生成し、提案手法を適用して推定精度を検証した。使用したデータは阪神高速道路の 11 号池田線、塚本付近の大阪方面に向かう全車両軌跡である。このうち、分岐・合流のない 1100 m の区間を対象とした。同区間は 2 つの車線からなり、第一走行帯、第二走行帯を

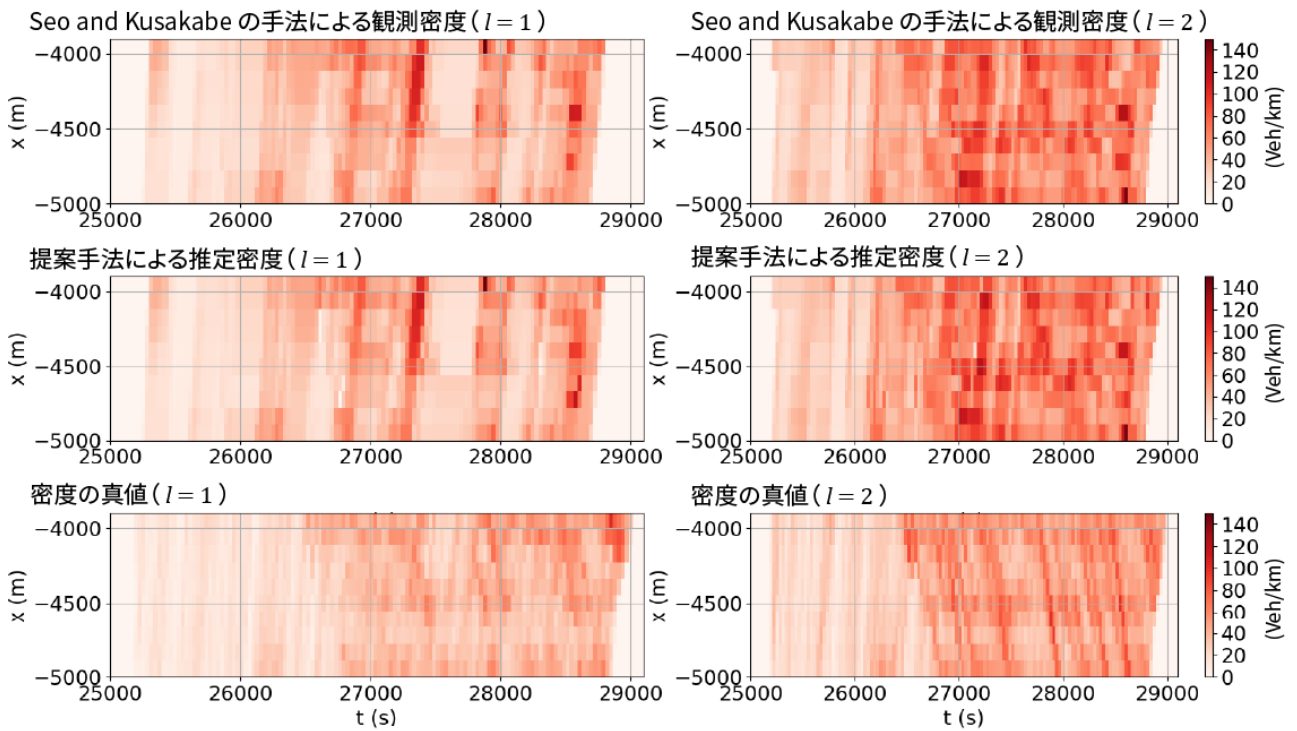


図- 5 推定密度の時空間図

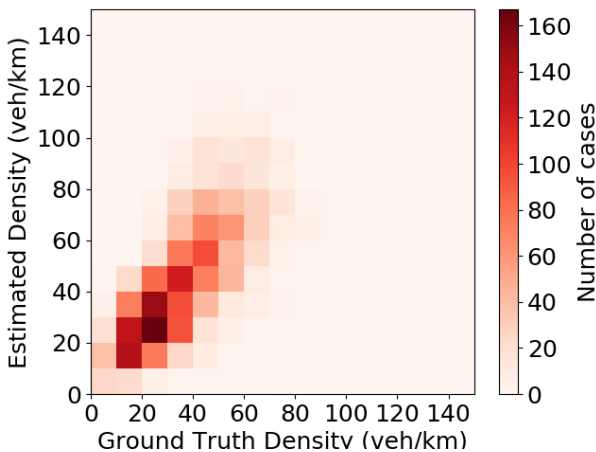


図- 6 推定密度と真値の分布




図- 7 推定密度と観測値の分布

それぞれ $l = 1, l = 2$ とする。下流側 300 m ほどの区間は車線変更が禁止されている。対象区間を走行する車両を無作為に抽出して自動運転車とみなし、前を走る車両との車間距離を取得する。抽出する自動運転車の割合は混入率 p で定める。真値として全車両軌跡に基づき 30 秒 \times 110 m の時空間領域ごとに算出した密度と、推定値として同じ時空間領域における提案手法による密度を比較して精度を求める。評価指標は RMSPE (Root Mean Square Percentage Error) を採用し、次の式で計算する。

$$RMSPE(\hat{\theta}) = \sqrt{E \left[\left(\frac{\hat{\theta} - \theta}{\theta} \right)^2 \right]} \quad (13)$$

なお、この値はそれぞれの条件で自動運転車として抽出する車両を変えながら推定を 5 回繰り返して計算し、平

均を採用した。提案手法におけるカルマンフィルタのパラメータは、観測ノイズの分散を 1.0 台、システムノイズの分散を 2.0 台とそれぞれ適当に値を設定した。

(2) 適用結果

提案手法を用いた密度の推定結果を示す。まず混入率 $p = 0.05$ の結果を示す。図-5 は、左側 3 つのグラフが車線 $l = 1$ 、右側が $l = 2$ であり、上から Seo and Kusakabe の手法による推定結果、提案手法による推定結果、全車両軌跡に基づく真値である。また、図-6 は提案手法による推定密度と密度の真値の散布図であり、図-7 は同じく提案手法による推定密度と Seo and Kusakabe の手法による観測密度の散布図である。さらに、混入率ごとの推定精度は表-1 の通りであった。「ML」は提案手法、「SK」は多車線モデルと統合しない Seo and Kusakabe の手法によ

表-1 混入率と密度の推定精度

p	手法	全体の RMSPE (%)	下流側 RMSPE (%)	上流側 RMSPE (%)
0.01	ML	88.5	82.6	88.7
0.01	SK	89.2	85.8	88.5
0.05	ML	80.5	77.3	80.2
0.05	SK	81.5	78.4	81.0
0.20	ML	77.1	74.7	77.4
0.20	SK	78.9	76.7	79.2

る推定を指す。「下流側」は車線変更禁止区間の 220 m における値であり、「上流側」は残りの部分からさらに境界部分を除いた 770m を対象として算出している。

提案手法は交通状態の傾向を概ねとらえているといえ、またほぼすべての条件において Seo and Kusakabe の手法と同等かそれよりわずかに良い精度を実現している。図-5 では、 $l = 2$ の後半部分に渋滞の伝播を読み取れる。また、図-6からも、密度の全体の傾向は把握できているといえる。しかし、提案手法において交通流モデルを用いたカルマンフィルタの導入による精度改善の効果は小さい。図-5 の上 2 行の推定密度分布図には大きな差はみられない。ただし、図-7 では提案手法の推定値が Seo, Kusakabe の手法に比べわずかに小さくなる傾向がみられる。同手法は構造上推定値に正のバイアスがかかる。提案手法はこれを補正する方向に推定している可能性が示唆される。なお、今回はシステムノイズおよび観測ノイズをそれぞれ一律の値で設定している。この値によってカルマンフィルタの効果は変わるため、推定誤差を踏まえたより適切なノイズの設定は今後の検討課題といえる。

混入率や車線変更の可否も推定精度に影響を与えている。表-1 によれば推定精度は混入率の増加に伴い緩やかに高くなる傾向があり、得られる観測データの増加による精度の改善がみられる。車線変更が可能な上流側は、禁止されている下流側に比べいずれの場合も推定精度が低い。しかし、上流部と下流部との間で両手法の推定精度の違いに明確な差異は確認できない。今回の推定で用いたデータは全体での車線変更回数が必ずしも多くない。区間ごとの車線変更率は大きいものでも 0.1 に満たなかった。今後、車線変更の発生頻度が高い道路においても提案手法を適用し、検証を進める必要がある。

4. まとめ

本研究では、多車線道路における混合流を想定し、自動運転車の観測情報に基づき交通状態を推定する手法を開発した。移動体観測を前提とした多車線交通流モデルを考案し、これと車間距離情報に基づく交通状態推定手法とをカルマンフィルタを用いて統合した。さらに、実際の軌跡データに提案手法を適用し、精度を検証した。

一層の精度向上のためにいくつかの改良が考えられる。

提案手法では交通流モデルを導入しても推定結果に正のバイアスがみられた。これを考慮した交通流モデルとの統合が必要といえる。また、提案手法では自動運転車による周辺観測を前方のみとしている。しかし実際の観測可能範囲は側方にも及ぶ。van Erp¹³⁾や Takenouchi¹⁴⁾が提案しているように、これを活用して隣接車線からの観測情報を統合していけば、精度の改善が期待できる。他にも、分岐・合流部への本手法の適用も今後の課題である。

謝辞：本研究は JSPS 科研費 19H02268, 20H02267 の助成を受けた。

参考文献

- 1) Nanthawichit, C., Nakatsuji, T., & Suzuki, H. (2003) Application of probe-vehicle data for real-time traffic-state estimation and short-term travel-time prediction on a freeway. *Transportation research record*, 1855(1), 49-59.
- 2) Bekiaris-Liberis, N., Roncoli, C., & Papageorgiou, M. (2016). Highway traffic state estimation with mixed connected and conventional vehicles. *IEEE Transactions on Intelligent Transportation Systems*, 17(12), 3484-3497.
- 3) Seo, T., & Kusakabe, T. (2015). Probe vehicle-based traffic state estimation method with spacing information and conservation law. *Transportation Research Part C: Emerging Technologies*, 59, 391-403.
- 4) Laval, J. A., & Daganzo, C. F. (2006). Lane-changing in traffic streams. *Transportation Research Part B: Methodological*, 40(3), 251-264.
- 5) Lighthill, M. J., & Whitham, G. B. (1955). On kinematic waves II. A theory of traffic flow on long crowded roads. *Proceedings of the Royal Society of London. Series A. Mathematical and Physical Sciences*, 229(1178), 317-345.
- 6) Richards, P. I. (1956). Shock waves on the highway. *Operations research*, 4(1), 42-51.
- 7) Daganzo, C. F., Lin, W. H., & Del Castillo, J. M. (1997). A simple physical principle for the simulation of freeways with special lanes and priority vehicles. *Transportation Research Part B: Methodological*, 31(2), 103-125.
- 8) Shioni, Y., Taniguchi, T., Uno, N., Shimamoto, H., & Nakamura, T. (2015). Multilane first-order traffic flow model with endogenous representation of lane-flow equilibrium. *Transportation Research Part C: Emerging Technologies*, 59, 198-215.
- 9) van Wageningen-Kessels, F., Yuan, Y., Hoogendoorn, S. P., Van Lint, H., & Vuik, K. (2013). Discontinuities in the Lagrangian formulation of the kinematic wave model. *Transportation Research Part C: Emerging Technologies*, 34, 148-161.
- 10) Makigami, Y., Newell, G. F., & Rothery, R. (1971). Three-dimensional representation of traffic flow. *Transportation Science*, 5(3), 302-313.
- 11) 樋口知之, & 上野玄太. (2011). データ同化入門: 次世代のシミュレーション技術. 朝倉書店.
- 12) 阪神高速道路: Zen Traffic Data, 2018, Accessed 2018-09-03 from <https://zen-traffic-data.net/>
- 13) van Erp, P. B., Knoop, V. L., & Hoogendoorn, S. P. (2019). On the value of relative flow data. *Transportation Research Part C: Emerging Technologies*
- 14) Takenouchi, A., Kawai, K., & Kuwahara, M. (2019). Traffic state estimation and its sensitivity utilizing measurements from the oppo-site lane.

Transportation research part C: emerging technologies, 104, 95-109.

(?)

(?)

TRAFFIC STATE ESTIMATION ON MIXED FLOW BY LANE
WITH SPACING INFORMATION OF AUTONOMOUS CAR

Kengo SAKAI, Toru SEO, Takashi FUSE