

# 周辺移動体を観測する移動体観測に基づく 交通状態推定理論の整理

瀬尾 亨<sup>1</sup>

<sup>1</sup>学生会員 東京工業大学 大学院理工学研究科 土木工学専攻 (〒 152-8552 目黒区大岡山 2-12-1-M1-20)  
E-mail: t.seo@plan.cv.titech.ac.jp

本稿では、「周辺移動体を観測する移動体観測」という、交通データ収集とそれによる交通システム分析のための方法論の可能性について、交通状態推定の例を通して考察する。ここでは、車間距離測定プローブカーが「周辺移動体を観測する移動体観測」の一つと位置づけられる。そして、本プローブカーがその特徴を活かし、交通状態推定に資すると明らかにした。例えば、本プローブカーに基づく手法は、既存手法と比較し、交通流理論に関する強い外生的仮定を緩和した上で交通状態を推定できると示した。これは、事前知識・理論的矛盾なしに様々な状況の交通状態を推定できることにつながり、土木計画学な観点から有用であるといえる。

**Key Words:** data collection, state estimation, model estimation, traffic flow, traffic state estimation

## 1. はじめに

### (1) 背景

#### a) 交通流

自動車交通流（以下、交通流と呼称）は旅行者が一次的に移動する交通システムであり、最も単純な交通システムであるといえる。交通流は現代社会を代表する交通システムであり、経済・安全・環境の観点からその効率を高く維持する必要がある。交通流の効率が低下する問題の例としては、渋滞（ある地点にその容量を上回る交通が流入し待ち行列を生じる現象）が知られている。その基本的な対策には、渋滞が発生する地点（ボトルネック）とその容量などを特定し、かつ現在の交通状況を把握し、それらの情報に基づく最適な施策（例：制御、情報提供、設備改善）の実行がある。

このような理由により、様々な手法（例：路側車両感知器、GPS プローブカー）により交通流データが収集されている。また、部分的なデータに基づいて全体の交通状況を推定する手法も提案されている（交通状態推定）。しかし、広範囲に対する恒常的なデータ収集はいまだ実現していない<sup>1)</sup>。そして、渋滞検出とその詳細なメカニズムの解明や、交通流の集合であるネットワーク交通流の分析に関し課題が残っている<sup>2)</sup>原因の一端は、今日のデータ収集の限界にあると考えられる。例えば、量的な交通データの恒常的収集は限られた離散地点でのみ可能なため、ボトルネックの厳密な位置やその動的な容量は不明な場合が多い。

上述した問題に対応すべく、著者ら<sup>3)-6)</sup>は新たな交通

流データ収集手法として「車間距離測定プローブカー」を提案し、それに基づく交通状態推定手法を構築・検証し、一定の成果を得ている。これは、周辺移動体を観測する移動体観測手法であり、位置に加えて車間距離を連続的に測定すると想定されたプローブカーである。位置と車間距離は局所的な交通状態と等価である。そのため、本情報が多数の車両の軌跡全体に沿って得られれば、既存データ収集手法では実現できない広範囲からの恒常的なデータ収集が可能と期待される。

#### b) 一般的な交通データ収集

前節の議論は、一般的な交通データ収集に関しても同様に成り立つと考えられる。今日実用されている代表的な手法には、

- 断面観測：ある時刻のデータを収集
- 定点観測：ある地点のデータを収集
- 移動体観測：ある旅行者のデータを収集

がある。しかし、いずれも一長一短であり、ほとんどの交通システムについて、広範囲に対する恒常的なデータ収集には至っていない<sup>1)</sup>。

「車間距離測定プローブカー」を一般的に表現すると、「周辺移動体を観測する移動体観測」という交通データ収集の方法論といえる。本方法論は

- 交通システム内の広大な時空間のデータ
- 旅行者個人の大域的な挙動のデータ
- 旅行者同士の局所的な相互作用のデータ

を同時に収集できると表現でき、これは広範囲に対する恒常的なデータ収集につながる。そのため、本方法

論は、その実際の性能次第では、一般的な交通システム分析に際し有用な可能性がある。例えば、歩行者行動分析では、定点観測（例：ビデオカメラ）を用いた施設内規模のミクロな挙動の詳細な分析<sup>7),8)</sup>、移動体観測（例：GPS）を用いた都市規模のマクロな挙動の詳細な分析<sup>9),10)</sup>はなされている。一方、回遊行動などといった歩行圏規模の行動分析は蓄積が少なく、マクロな挙動とミクロな相互作用の挙動が共に影響する規模の行動についてはほとんど明らかにされていない点が指摘されており<sup>11)</sup>、本方法論はこのような問題の解決に資する可能性がある。

## (2) 目的

本稿の目的は、「周辺移動体を観測する移動体観測」という、交通データ収集とそれによる交通システム分析のための新たな方法論の可能性の考察である。具体的には、車間距離測定プローブカーによる交通状態推定について、既存の交通流理論とデータ収集手法と比較した位置付けを整理・考察する。

本稿の構成は以下の通りである。第2.章では、交通流理論、交通流データ収集、交通状態推定に関する既往研究を概観する。次に、第3.章では、車間距離測定プローブカーによる交通状態およびモデルパラメータの推定手法について述べる。最後に、第4.章にて結論を述べる。

## 2. 交通状態推定に関する既往研究整理

本章にて、既往研究について整理する。

### (1) 交通流理論

既往研究により構築されたマクロ交通流理論について、その概要を述べる。

累積台数  $N(t, x)$  とは「地点  $x$  を時刻  $t$  までに通過した車両台数を、ある原点から累積した数」と定義される。交通流は、 $N-t-x$  空間中の累積台数平面として図-1のように表せる<sup>12),13)</sup>。そのため、累積台数は交通流を表す最も基礎的な量であるといえる<sup>14)</sup>。

交通状態とはある時空間領域での流率  $q$ 、密度  $k$ 、速度  $v$  を意味するとする。時刻  $t$ 、地点  $x$  の交通状態は累積台数  $N$  を用いて

$$q(t, x) = \frac{\partial N(t, x)}{\partial t} \quad (1)$$

$$k(t, x) = \frac{\partial N(t, x)}{\partial x} \quad (2)$$

$$v(t, x) = \frac{q(t, x)}{k(t, x)} \quad (3)$$

と定義できる。これは、 $N-t-x$  空間上で、流率は累積台数の時間方向の傾き、密度は累積台数の空間方向の傾




図-1: 累積台数を用いた交通流の三次元的表現

きであるともいえる。

Edie<sup>15)</sup> は、ある時空間領域での交通状態の一般的な定義を以下と与えた：

$$q(\mathbf{A}) = \frac{d(\mathbf{A})}{|\mathbf{A}|} \quad (4)$$

$$k(\mathbf{A}) = \frac{t(\mathbf{A})}{|\mathbf{A}|} \quad (5)$$

$$v(\mathbf{A}) = \frac{d(\mathbf{A})}{t(\mathbf{A})} \quad (6)$$

ここに、 $\mathbf{A}$  は任意の時空間領域、 $d(\mathbf{A})$  は領域  $\mathbf{A}$  内の全車両の総移動距離（台×距離）、 $t(\mathbf{A})$  は領域  $\mathbf{A}$  内の全車両の総移動時間（台×時間）、 $|\mathbf{A}|$  は領域  $\mathbf{A}$  の時空間面積（時間×距離）である。本定義は、極限を取ると式(1)–(3)と一致する。また、実務で広く用いられている交通状態の定義である地点交通量や空間平均速度などを包含している。また、リンク上の次元交通（交通流）に限らない多様な交通に対しても適用可能である。

交通流モデルは、累積台数の動的な変化を表現する枠組みである。Lighthill and Whitham<sup>16)</sup> と Richards<sup>17)</sup> は、交通状態の時空間遷移を流率密度関係（Fundamental Diagram, FD）と保存則に基づき以下のように表現した（LWR モデル、衝撃波理論）：

$$q(t, x) = Q(k(t, x), t, x) \quad (7)$$

$$\frac{\partial q(t, x)}{\partial x} + \frac{\partial k(t, x)}{\partial t} = 0 \quad (8)$$

ここに、 $Q(k, t, x)$  は点  $(t, x)$  にて密度  $k$  のときの流率を示す関数であり、FD を意味する。本モデルは、交通流を連続流体とみなし、分合流地点のない交通流では保存則と first-in first-out 則が成り立ち、また交通流は常に均衡状態（全車両が車間距離と速度を変える動機を持たない交通流の状態）にあると仮定している。

FD とは、ある時刻・地点の均衡流の流率と密度の間に成り立つとされる関係である。その実際の形態は、運

転者の属性や車両・道路の性能など多様な要素が複雑に関係している<sup>2)</sup>ため、そもそも実在するか否かを含め、完全な記述は難しいといえる。広く受け入れられている近似として、三角形近似FD(式(9))がある。

$$q = Q(k) = \begin{cases} uk, & 0 \leq k < k_c \\ -\frac{uk_c}{\kappa - k_c}k + \frac{u}{1/k_c - 1/\kappa}, & k_c \leq k \leq \kappa \end{cases} \quad (9)$$

ここに、 $u$ は自由流速度、 $k_c$ は臨界密度、 $\kappa$ は渋滞密度である。式(9)では $n, t, x$ についての依存は無視している(均質車両・道路仮定)。異質性がある場合には、時点 $t$ に周辺地点と比較し容量 $uk_c$ が小さい地点 $x$ が時点 $t$ のボトルネックと呼ばれる。また、他車両と比較し遅い車両 $n$ がボトルネックとなる場合もある。

三角形FDに基づくLWRモデルは、扱い易さと高い表現力を両立しているため、現在も広く用いられている。その計算法としては、時空間を離散化する方法<sup>18)-20)</sup>や車両軌跡(すなわち累積台数)を明示的に扱う方法<sup>14), 21)-24)</sup>などが知られている。

LWRモデルで記述される交通流では、式(1)-(3)で求められる交通状態(点交通状態)は常にFDで記述される流率-密度関係を満たす。一方、式(4)-(6)の交通状態(エリア交通状態)はFDに従うとは限らない。領域 $A$ 内が定常状態(全車両が等間隔で等速度である状態)の場合、エリア交通状態は点交通状態に一致しFDに従う。

実際の交通流では、理論と実際の乖離により、点交通状態はFDに従うとは限らない。そもそも、点交通状態の流率と密度は厳密には求められない。一方、エリア交通状態は厳密に求められる。領域 $A$ 内が定常状態であれば、そのエリア交通状態はFDに概ね従うと報告されている<sup>25)</sup>。<sup>1</sup>

## (2) 交通流データ収集

本稿では、交通流データを「ある単一または複数の時空間領域で既知である累積台数」と定義する<sup>2)</sup>。測定誤差を無視すると、交通流データは以下のように数式で表現できる：

$$\mathcal{D}(\mathcal{A}) = \{ \{ N(t, x) - N(t_0(\mathbf{A}), x_0(\mathbf{A})) \mid (t, x) \in \mathbf{A} \} \mid \mathbf{A} \in \mathcal{A} \} \quad (10)$$

ここに、 $\mathcal{D}(\mathcal{A})$ は交通流データ、 $\mathcal{A}$ は時空間領域の集合、 $\mathbf{A}$ は時空間領域、 $(t_0(\mathbf{A}), x_0(\mathbf{A}))$ は $\mathbf{A}$ の原点の時空間座標( $\mathbf{A}$ 内での相対累積台数の原点)である。図-2に代表的な交通流データ収集手法を図示する(それぞれの

<sup>1</sup> ちなみに、領域 $A$ を空間方向に十分に大きく(例:複数リンクに跨る規模)設定したとき、その空間が一定の条件を満たす場合には、そのエリア交通状態がFDに類似した関係に概ね従うとする説が提唱されている。その関係は Macroscopic Fundamental Diagram と呼ばれる<sup>26)</sup>。

<sup>2</sup> これは、交通流データとその収集手法を交通流理論の観点から統一的に概観するための便宜的な定義であり、一般の交通流データの全要素を捨象せずに取り扱うものではない。

詳細は後述)。図中、赤線・赤点は収集された車両軌跡情報、薄赤領域・点は領域 $A$ 、破線は車両軌跡、赤線はある $A$ 内に複数の離れた領域・点が含まれる場合の関連付けを意味する。

完全な交通流データは、全車両が自車の位置を正確に連続的に報告すれば得られる(図-2a)。航空機などで上空から撮影した画像から車両挙動を抽出できれば、空間的には完全に近いデータ収集が可能な場合がある<sup>27)-29)</sup>。また、十分に高い密度で路側カメラを設置すれば、同様の効果を得られる<sup>3)</sup>。しかし、技術的・費用的問題などから、上記の手法の恒常的な運用はされておらず、試験的な断面観測に留まっているのが現状である。

定点観測は交通流データ収集の代表的な実用アプローチである。例えば、調査員の人手による測定、路側に設置した磁気・超音波センサで車両通過台数・速度を測定する車両感知器や、路側カメラの撮影画像の解析により短区間の全車両挙動を得る手法(図-2b)がある。ただし、車長の値やごく短時間の定常状態などの仮定を要する場合がある。これらの手法で得られる情報は本来は非集計データであるが、実務上、データ転送・保存のために一定時間単位で集計される場合が多い(図-2c)。信号現示情報は、赤信号時には車両通過がないはずであるため、交通流データの種類と位置づけられる(図-2d)。一般に、定点観測ではセンサ設置位置での交通流データを量的情報を含めて得られる(信号現示は除く)。すなわち、ある $A$ 内には複数の累積台数の値が含まれている。一方、センサの設置・維持に費用が掛かるため、広範囲からの恒常的なデータ収集は難しい。

移動体観測は交通流データ収集の新たなアプローチとして注目されている。例えば、GPSなどにより自車位置を特定し、通信により伝達するGPSプローブカー(図-2e)が盛んに用いられている。ただし、本情報は個人の移動軌跡とほぼ同一であり、個人情報保護の観点から問題となる場合がある。そのため、匿名化のための一定の処理を施し、平均速度へと集計する場合も多い(図-2f)。一般に、移動体観測者は旅行者全体からサンプリングされる。また、センサは旅行者が自身の目的で装備している場合(例:経路案内)が多く、定点観測と比較しデータ収集のための追加コストが低い。そのため、移動体観測は非常に広範囲から恒常的にデータを収集できる可能性がある。GPSプローブカーによって得られる情報は、車両軌跡そのもの(速度)である。一方、量的情報は含まれていない。すなわち、ある $A$ 内には単一の累積台数の値のみが含まれている。

複数地点間での同一車両の特定(マッチング, Automatic vehicle (re-)identification, AVI)もなされる(図-

<sup>3</sup> このようなオープンデータとしてNGSIMデータセット<sup>30)</sup>が有名。

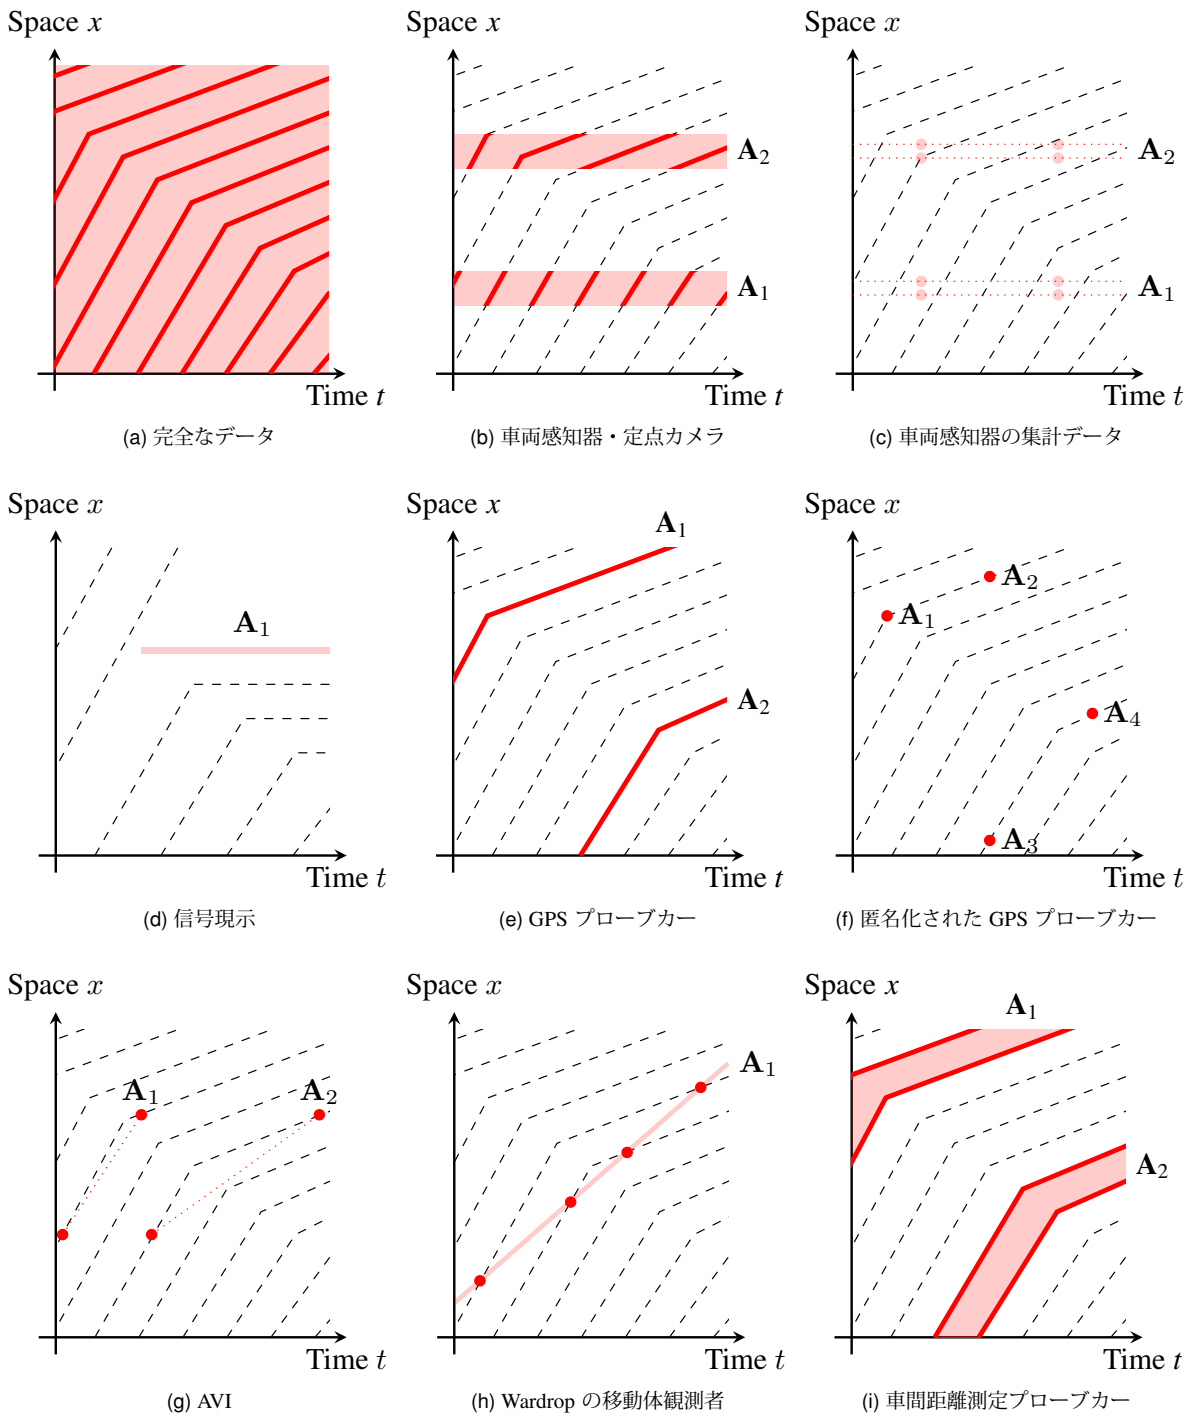


図-2: 車両軌跡・累積台数と交通流データの例

2g). 本手法は、車両に固有の特徴（例：外見的特徴、車載機器 ID）などにに基づき、一部の車両を同定し、地点間旅行時間を算出する。そのため、センサ自体は定点に固定されているものの、得られる情報の質は移動体観測に近い。すなわち、平均移動速度を得られるが、対応する量的情報は常には得られない。

Wardrop and Charlesworth<sup>31)</sup>の移動体観測者は、周辺車両を感知する移動体観測を活用する手法である（図-

2h). 本手法はあるプローブカーが追い越した車両、そのプローブカーを追い越した車両、そのプローブカーと対向車線ですれ違った車両の数を測定し、自車の速度と合わせて交通状態を推定する。ただし、実際の交通流データ収集手法として使われた例は見当たらない。これは、比較的長期間に渡り定常流を仮定する必要があり、さらに対向車線の車両数の測定が技術的に困難

であるためと考えられる<sup>4</sup>。

著者ら<sup>3)-6)</sup>は、新たな移動体観測として「車間距離測定プローブカー」を提案している。これは、車載機器により車間距離を連続的に測定すると想定されたプローブカーである。車頭距離(=車間距離+車体長)は局所的な密度の逆数であり、累積台数が1台減る距離を意味しており、交通流データといえる(図-2i)。さらに、車頭距離と速度の関係はFDと等価であるため、交通流モデルの最も基本的な要素に関する情報も得られるといえる。本手法は、近年発展の著しい先進運転支援システムを応用すれば実現可能と考えられる<sup>33)</sup>。すなわち、本手法は旅行者の機器を活用するため、GPSプローブカーと同様にデータ収集の追加コストが低い。よって、本手段が普及した場合、恒常的に広範囲の交通状態とモデルの同時推定が可能と期待できる。なお、同様の目的に着目したより包括的な測定技術も開発されており、「画像プローブ<sup>34)</sup>」や「拡張フローティングカーデータ、xFCD<sup>35)</sup>」などとも呼ばれている。

### (3) 交通状態推定

交通状態推定とは、「ある領域で収集(観測)された交通流データとその他の仮定に基づき、その領域またはそれ以外の領域の交通状態を推定すること」と定義できる。これは、以下のように数式で表現できる：

$$\hat{D}(B) = F(D'(A), \theta) \quad (11)$$

ここに、 $B$ は交通状態を推定する時空間領域、 $\hat{D}$ は推定された交通状態(に対応する交通流データ)、 $F$ は交通状態推定手法を意味する関数、 $\theta$ は推定手法のパラメータベクトル、 $A$ は交通流データを収集した領域(観測領域)、 $D'$ は収集された交通流データを意味する。多くの場合、未観測領域の交通状態を推定するため $A \subset B$ である。

#### a) 既存の交通状態推定手法

交通状態推定手法はこれまでも無数に提案されている。本稿では方法論と入力データ種別の2つの観点から整理した概略を述べる<sup>5</sup>。方法論は、交通流モデルに基づく手法と、統計的・機械学習的手法に大別できる。入力データの種別は第2.2)節に述べた通りである。

交通流モデルに基づく手法は、観測領域での収集データを境界条件とし、LWRモデルなどの交通流モデルに基づき、未観測領域の交通状態を計算する。そのため、交通流モデルの計算法自体も交通状態推定手法の特殊な例として位置づけられる。より実際的な手法では、理

論と実際との乖離や測定誤差を扱うため、残差最小化や最尤法を適用できる問題に帰着させる例が多い。このとき、 $A$ は境界を、 $B$ は境界内部を、 $F$ は交通流モデルの計算法と関連する推定法を、 $\theta$ は交通流モデル・その計算法・推定法のパラメータを意味する。当手法では、FDに何らかの仮定を置く場合が多い(例：FD変数を $\theta$ として外生的に与える)。

統計的・機械学習的手法では、過去に実現した観測データ間の関係性を統計的あるいは機械学習的手法により得て、それが常に成り立つと仮定し、観測領域の情報から未観測領域の交通状態を推定する。よって、 $F$ は関係性を得る手法あるいは得られた関係性に基づく計算法を意味し、 $\theta$ は関係性を得る手法のパラメータあるいは得られた関係性を意味する。この特性から、当手法は現在の定点観測データから近未来の交通状態を推定する手法(特に旅行時間予測)によく用いられる<sup>39), 40)</sup>。このとき、 $A$ は過去、 $B$ は未来を意味し、同一空間である。また、移動体観測データに基づく未観測空間の補間推定にも用いられる<sup>41)</sup>。このとき、 $A$ は観測空間、 $B$ は未観測空間を意味する。統計的・機械学習的手法の弱点は、関係性を得るための大量の蓄積データが必要な点と、関係性が成り立たなくなる突発事象に弱い点である<sup>6</sup>。

入力データに関して、多様な既存交通流データの組み合わせが研究されている。例えば、車両感知器<sup>43)-45)</sup>、車両感知器とGPSプローブカーの集計情報<sup>46), 47)</sup>、車両感知器とGPSプローブカーとAVI<sup>48)</sup>、車両感知器とGPSプローブカーと信号現示<sup>49)</sup>、車両感知器とGPSプローブカー<sup>50), 51)</sup>、GPSプローブカーと信号現示<sup>52)</sup>などを用いる手法が提案されている。

#### b) FD推定

参考までに、FD推定について簡潔に述べる。前述のとおり、FDとは均衡流での流率と密度の関係である。そのため、FDがある領域で一定で存在する事実と、その領域の均衡流での流率と密度の値がわかればFDは容易に推定できる。例えば、感知器の集計データに基づく推定<sup>53)</sup>、詳細な全車両軌跡データに基づく推定<sup>54)</sup>、感知器に基づくデータ同化による交通状態との同時推定<sup>55), 56)</sup>、FDの一部要素が既知と仮定したもとのGPSプローブカーデータに基づく推定<sup>57), 58)</sup>などがなされている。しかし、交通状態推定と同様、広範囲に渡り恒常的にFDを推定する手法は提案されていない。

#### c) 考察

既存の交通状態推定手法の問題点は、交通状態推定に際し強い外生的仮定を置いている点といえる。ここに、強い外生的仮定とは、本来は交通状態推定が推定

<sup>4</sup> 全ての車両数を測定する必要のない車種別構成比の推定に用いる研究例はある<sup>32)</sup>。また、交通流モデルやその計算法の導出のためのアナロジーとしての応用が有名である。

<sup>5</sup> 交通流モデルとデータ同化の観点からは中辻<sup>36)</sup>と福田<sup>37)</sup>が、統計・機械学習の観点からはKarlaftis and Vlahogianni<sup>38)</sup>がそれぞれ詳細にレビューしている。

<sup>6</sup> この性質を逆手に取ると、統計的・機械学習的手法により大量の蓄積データのみに基づき突発事象を検出できる<sup>42)</sup>。

対象としている情報自体から導かれる要素を意味する。例えば、多くの手法ではFDを所与として交通状態を推定している。しかし、本来は、FDは時間、空間（そして車両）に依存する関係であり、交通状態を把握せずには把握できないといえる。これに起因する実用上の問題の例としては、推定手法がもともとデータ収集が十分な地点に対してのみ適用可能である点や、交通事故などの突発事象に対応できない点が挙げられる。

このような背景のもと、FDなどの強い外生的仮定に基づかずに、車間距離測定プローブカーを活用した交通状態推定手法が提案されている<sup>3)-6)</sup>。次章にてこれらの手法を詳述する。

### 3. 車間距離測定プローブカーの活用例

本章で、車間距離測定プローブカーによる交通状態推定について述べる。

車間距離測定プローブカーの収集データのみに基づく交通流の推定手法として、モデルパラメータ推定手法<sup>5)</sup>、交通状態推定手法<sup>4), 5)</sup>、交通状態とモデルパラメータの同時推定手法<sup>6)</sup>が提案されている。また、定点観測データとxFCDの間の相関関係に基づく交通状態推定手法<sup>6)</sup>も提案されている。いずれの手法も、「交通システム内の広大な時空間のデータ」と「旅行者個人の大域的な挙動のデータ」を収集できる点を活用した手法といえる。

Seo et al.<sup>4)</sup>の手法は、前述した特性を活用し、ランダムサンプリング以外の外生的仮定に頼らずに交通状態を推定する。当手法は外生的仮定に最も頼らない手法といえるため、第3.(1)節にて詳細を述べる。Seo et al.<sup>6)</sup>の手法は、「局所的な相互作用」の法則が大域的にも成り立つと仮定し、交通状態を推定する。当手法は動的な交通流理論（LWRモデル）を考慮しており、「旅行者同士の局所的な相互作用のデータ」をより積極的に活用した手法といえるため、第3.(2)節にて詳細を述べる。

#### (1) 交通状態推定

Seo et al.<sup>4)</sup>による交通状態推定について述べる。本手法は、車間距離測定プローブカーの収集データから直接交通状態を推定する手法であり、外生的仮定を最も緩和した手法といえる。

##### a) コンセプト

車間距離測定プローブカーは、全車両中にランダムに混入しており、自車の位置と先行車両との車頭距離を連続的に正確に測定するとする。そのプローブデータから交通状態を推定したい。

##### b) 推定手法

Edieの定義（式(4)-(6)）は、車両一台一台に着目すると、

$$q(\mathbf{A}) = \frac{\sum_{n \in \mathbf{N}(\mathbf{A})} d_n(\mathbf{A})}{\sum_{n \in \mathbf{N}(\mathbf{A})} |\mathbf{a}_n(\mathbf{A})|} \quad (12)$$

$$k(\mathbf{A}) = \frac{\sum_{n \in \mathbf{N}(\mathbf{A})} t_n(\mathbf{A})}{\sum_{n \in \mathbf{N}(\mathbf{A})} |\mathbf{a}_n(\mathbf{A})|} \quad (13)$$

$$v(\mathbf{A}) = \frac{\sum_{n \in \mathbf{N}(\mathbf{A})} d_n(\mathbf{A})}{\sum_{n \in \mathbf{N}(\mathbf{A})} t_n(\mathbf{A})} \quad (14)$$

と変形できる。ここに、 $\mathbf{A}$ は任意の時空間領域、 $d_n(\mathbf{A})$ は領域 $\mathbf{A}$ 内での車両 $n$ の走行距離、 $t_n(\mathbf{A})$ は領域 $\mathbf{A}$ 内での車両 $n$ の走行時間、 $\mathbf{a}_n(\mathbf{A})$ は領域 $\mathbf{A}$ 内での車両 $n$ とその先行車との間の時空間領域、 $\mathbf{N}(\mathbf{A})$ は領域 $\mathbf{A}$ 内の全車両の集合である。ここで、 $\mathbf{N}(\mathbf{A})$ を領域 $\mathbf{A}$ 内の全プローブカーの集合 $\mathbf{P}(\mathbf{A})$ に置き換え、以下の推定量を定義する：

$$\hat{q}(\mathbf{A}) = \frac{\sum_{n \in \mathbf{P}(\mathbf{A})} d_n(\mathbf{A})}{\sum_{n \in \mathbf{P}(\mathbf{A})} |\mathbf{a}_n(\mathbf{A})|} \quad (15)$$

$$\hat{k}(\mathbf{A}) = \frac{\sum_{n \in \mathbf{P}(\mathbf{A})} t_n(\mathbf{A})}{\sum_{n \in \mathbf{P}(\mathbf{A})} |\mathbf{a}_n(\mathbf{A})|} \quad (16)$$

$$\hat{v}(\mathbf{A}) = \frac{\sum_{n \in \mathbf{P}(\mathbf{A})} d_n(\mathbf{A})}{\sum_{n \in \mathbf{P}(\mathbf{A})} t_n(\mathbf{A})} \quad (17)$$

なお、 $\sum_{n \in \mathbf{P}(\mathbf{A})} |\mathbf{a}_n(\mathbf{A})| > 0$ が前提条件である。図-3にプローブカー（赤太線）と領域 $\mathbf{A}$ （青矩形）の例を示す。

推定量 $\hat{q}(\mathbf{A})$ の精度と偏りは以下のように近似できる：

$$\begin{aligned} \text{RMSE}(\hat{q}(\mathbf{A})) &= \sqrt{(\hat{q}(\mathbf{A}) - q(\mathbf{A}))^2} \\ &\approx \frac{1}{\mu(\bar{h}_n(\mathbf{A}))^2} \sqrt{\frac{\sigma(\bar{h}_n(\mathbf{A}))^2}{|\mathbf{P}(\mathbf{A})|}} \quad (18) \end{aligned}$$

$$\begin{aligned} \text{Bias}(\hat{q}(\mathbf{A})) &= E[\hat{q}(\mathbf{A})] - q(\mathbf{A}) \\ &\approx \frac{\sigma(\bar{h}_n(\mathbf{A}))^2}{|\mathbf{P}(\mathbf{A})|\mu(\bar{h}_n(\mathbf{A}))^3} \quad (19) \end{aligned}$$

ここに、RMSEは二乗平均平方根誤差、 $\mu(\cdot)$ は平均、 $\sigma(\cdot)$ は分散、 $\bar{h}_n(\mathbf{A})$ は領域 $\mathbf{A}$ 内部での車両 $n$ の平均車頭時間である。式(18)、(19)によると、流率の推定誤差は、平均車頭時間の分散が同平均と比較し大きいほど大きく、利用可能なプローブカーの数が多いほど小さいと示唆される。なお、密度についても同様の推定誤差が近似できる。

本手法の特徴は以下とまとめられる：

- 移動体観測のみに基づき量的情報を推定可能
- 任意の時空間分解能での交通状態が推定可能
- 仮定している要素が少ない

1点目の特徴の利点は前述したとおりである。2点目の特徴から、目的に応じて様々な状態量（例：5分間交通量、1時間交通量）の推定が可能である。なお、以降、




図-3: 車間距離測定プローブカーと領域 A





図-4: 車間距離測定プローブカーの収集データの実例


本稿では簡単のため領域 A を時間長さ  $\Delta t$ , 空間長さ  $\Delta x$  の矩形とする (図-3). 3 点目に関して, 例えば, 本手法は FD や保存則に一切の仮定を置いていない. そのため, 本手法は様々な性質の交通流に対して適用できる頑健な手法であると考えられる. なお, 比較的弱い仮定と考えられる保存則を導入した交通状態推定手法は Seo and Kusakabe<sup>5)</sup> にて定式化・検証されている. さらに, FD の概念の導入も可能であり, その定式化・検証は第 3.(2) 節にて後述する.

### c) 検証結果

高速都心環状線にて, 2013 年 9 月 24 日 (火) の 15:00 ~ 16:00 に実道実験を実施した. 観測区間は内回り方向の霞が関トンネル出口付近 (谷町 JCT 上流部) から千代田トンネル入口付近 (竹橋 JCT 付近) の走行車線, 計 11 km である. 本路線は路側超音波感知器を用いた定点観測網が整備されており (時間分解能: 1 分, 空間分解能: 車線毎に平均 250 m), この観測結果を真値とみなす. 実際の平均交通状態は 1255 veh/h/lane, 40.7



(a) 感知器データ



(b) プローブデータに基づく推定結果

図-5: 高速都心環状線の密度の time-space diagram

表-1: 交通状態推定の誤差指標

$P$	$\Delta t$ (min)	$\Delta x$ (m)	RMSPE( $\hat{q}$ )	Bias( $\hat{q}$ ) (veh/h)
0.2%	5	500	42.8%	44.3
0.2%	60	11000	16.4%	-159.0
1.0%	5	500	43.1%	21.1
1.0%	60	11000	11.6%	-134.5
3.5%	5	500	26.3%	-82.4
3.5%	60	11000	12.9%	-161.4

veh/km/lane, 30.8 km/h であった.

車間距離測定プローブカーとして, 単眼カメラと GPS ロガーを装備した普通車 20 台を使用し, 各車両が平均 3 周の周回走行を行った. プローブは 15 秒毎に自車両の位置と先行車両との車頭距離を測定する. 位置は GPS ロガーにより測定した. 車頭距離は, 画像上に写った先行車両の見かけ上の大きさとそれに対する実距離の関係から推定した. 図-4 に収集データの一部を示す. 点はプローブの測位点, 赤線はプローブの軌跡, 赤領域はプローブとその先行車との間の領域を示す.

全てのプローブデータを用い, (5 min, 500 m) 分解能で密度を推定した結果を図-5b に示す. 感知器の観測値 (図-5a) と比較し, 交通現象を良く再現できている (例: 8km 付近を先頭とした渋滞の延伸) といえる.

様々なプローブ混入率  $P$  と時空間分解能 ( $\Delta t, \Delta x$ ) の設定のもとでの流率の推定誤差を表-1 に示す. ここで,

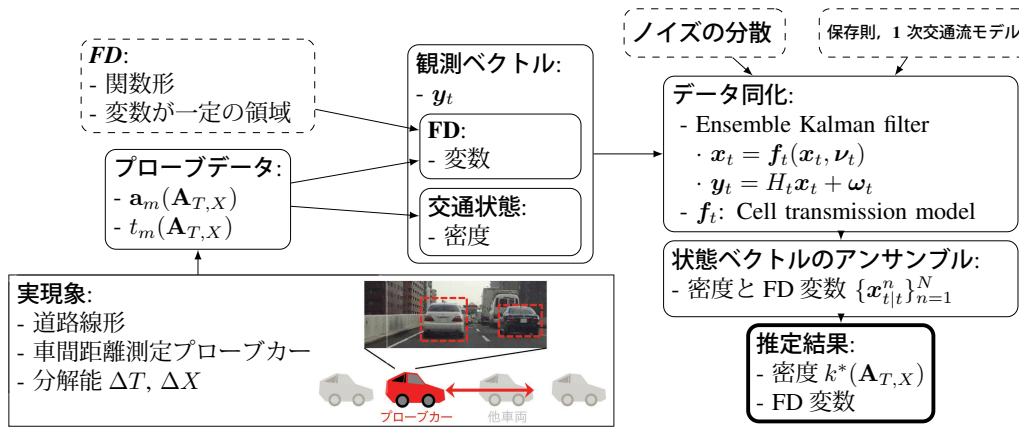


図-6: 交通状態・モデルパラメータ同時推定手法のコンセプト

RMSPE (二乗平均平方誤差率) は精度, Bias は偏りを意味する. 表-1 からは, プローブ率が高いほど, 分解能が粗いほど推定精度が良い傾向があるとわかる. 例えば, プローブ混入率 3.5% あれば, 都市内高速のような密な車両感知器に相当する (5 min, 500 m) 分解能での推定がある程度の精度で可能であった. 一方, プローブ混入率 0.2% (プローブカーが 1 時間 1 車線当たり 2 台走行) のときは, 1 時間交通量が高精度で推定可能であった. 若干の過小推定がみられるが, これはプローブカーの運転挙動が他車両と比較し低速側に偏っていたためと推測される. それ以外の定性的傾向や定量的値は式 (18), (19) で示した解析近似とある程度合致している.

## (2) 交通状態とモデルパラメータの同時推定

Seo et al.<sup>6)</sup> による交通状態・モデルパラメータ同時推定の概要<sup>7)</sup> について述べる. 本手法は, FD という概念が存在すると仮定する. その上で, 車間距離測定プローブカーの収集データから FD のパラメータを推定する. そして, 推定した FD パラメータと第 3.(1) 節の手法 (以下, 基本手法と呼称) の交通状態推定結果をデータ同化<sup>37)</sup> により統合し, より良い推定結果を得る手法である.

### a) コンセプト

基本手法は, ランダムサンプリングのみを仮定し, 車間距離測定プローブカーの収集データから交通状態を推定する手法であった. この特徴は, 様々な性質の交通流に対し事前知識・理論的矛盾なしで本手法を適用可能とする一方, その推定精度 (特に高分解能時) は必ずしも高くないという欠点にもつながっている. 基本手法で高分解能の交通状態を推定する際には, 小さな領域  $A$  を設定し  $A$  内部の情報のみにより  $A$  の状態を

推定している. そして, 小領域ではマイクロ交通流の乱雑さ (例: 車群の発生・解消, 車線変更, 加減速の安定性) の影響が大きい. これが前述した欠点の要因の一つといえる. ところで, 第 2.(1) 節で述べたとおり, 交通流は時空間上の遷移現象である. そのため, ある領域  $A$  の交通状態は, その前の時間の周辺空間の影響を強く受けている. この影響を適切に考慮すれば, 交通状態推定の合理性と精度を向上できると考えられる.

交通流の時空間上の遷移を表現する代表的なモデルは LWR モデルである. そこで, LWR モデルの基本要素である保存則と FD の成立を仮定する. FD について, 具体的には, FD の存在, 三角形の関数形 (式 (9)), FD 変数がある所与の領域で一定であることを仮定する. FD 変数の値は, プローブデータ内の定常状態の車頭距離と速度から推定するとする. そして, LWR モデルをシステムモデル, 基本手法による交通状態推定と FD 変数推定を観測モデルとする状態空間モデルを構築し, データ同化手法により交通状態を推定する. このとき, データ同化の枠組みとしてアンサンブルカルマンフィルタ (EnKF)<sup>61)</sup> を採用した. その長所は, 交通流の非線形性を十分に表現できる点と, 観測モデルの線形性によりモンテカルロ法の計算コストを大幅に抑えられる点である.

本手法の問題点について述べる. 第 2. 章で述べたとおり, FD は本来は時刻・地点・車両依存する関係である. 本手法は FD が一定である時空間を所与としており, その依存関係を適切には考慮していない. しかし, FD 変数の値を所与とする場合と比較すれば, 外生的仮定を緩和できているといえる. いずれにせよ, 今後の課題として, 車間距離測定プローブカーのデータから FD の依存関係を内生的に推定する手法を構築する必要がある.

<sup>7)</sup> 紙面の都合上, 手法の詳細は記述できないため, それらについては原著を参照されたい.



## b) 推定手法

EnKF の状態空間モデルは以下と記述できる：

$$\mathbf{x}_t = \mathbf{f}_t(\mathbf{x}_t, \boldsymbol{\nu}_t), \quad (20)$$

$$\mathbf{y}_t = \mathbf{H}_t \mathbf{x}_t + \boldsymbol{\omega}_t, \quad (21)$$

ここに、式 (20) はシステム方程式、式 (21) は観測方程式、 $\mathbf{x}_t$  は状態ベクトル、 $\mathbf{f}_t$  はシステムモデル、 $\boldsymbol{\nu}_t$  はシステムノイズ、 $\mathbf{y}_t$  は観測ベクトル、 $\mathbf{H}_t$  は観測行列、 $\boldsymbol{\omega}_t$  は  $\boldsymbol{\omega}_t \sim \mathcal{N}(0, R_t)$  なる観測ノイズ、 $R_t$  は観測ノイズの分散共分散行列である（全て時刻  $t$  について）。

状態ベクトル  $\mathbf{x}_t$  はそれぞれの時空間領域の密度、FD 変数（自由流速度、臨界密度、渋滞密度）からなる。システムモデル  $\mathbf{f}_t$  は Cell transmission model<sup>18)</sup> にノイズを付加したものとし、時空間領域間の交通流の移流を表現する。観測ベクトル  $\mathbf{y}_t$  は、 $\mathbf{x}_t$  と同質の要素からなる。その値は、密度は基本手法によって推定（式 (16)）した値とする。FD 変数はプローブカーが定常状態にあるときの車頭距離と速度の集合を回帰して得る。観測行列  $\mathbf{H}_t$  は、プローブカーが存在する時空間領域に対応する要素の値は 1、それ以外は 0 とする。観測ノイズの分散共分散行列  $R_t$  は、式 (18) を参考にして、それぞれの時空間領域内のプローブカーの逆数に比例するとする。

EnKF による状態推定では、初期状態  $\{\mathbf{x}_{0|0}^n\}_{n=1}^N$  を生成したのち、 $\{\mathbf{x}_{t|t}^n\}_{n=1}^N$  を  $\mathbf{y}_t$ ,  $\mathbf{H}_t$ ,  $R_t$ ,  $\mathbf{x}_{t-1|t-1}^n = \mathbf{f}_t(\mathbf{x}_{t-1|t-1}^n, \boldsymbol{\nu}_t^n)$ ,  $\{\boldsymbol{\omega}_t^n\}_{n=1}^N$  に基づき逐次的に計算する。その結果、全ての  $t$  に関して  $\{\mathbf{x}_{t|t}^n\}_{n=1}^N$  が得られる。そのうち、密度に関する時刻  $T$ 、地点  $X$  周辺 (=時空間領域  $\mathbf{A}_{T,X}$ ) での要素の平均値を  $k^*(\mathbf{A}_{T,X})$  と表記し、本手法の交通状態推定結果とする。

## c) 検証結果

マイクロ交通流シミュレータ Aimsun<sup>62)</sup> により、検証用の交通流を生成した。このとき、第 3.(1)c) 節で述べた実道実験の環境に類似するよう設定した。すなわち、道路は終端部にボトルネックを有する延長 3km の 2 車線道路とし、1 時間に渡り需要と供給を調整して渋滞の延伸と解消を伴う交通流を生成した。その結果、平均交通状態は 1081.4 veh/h/lane, 64.3 veh/km/lane, 32.6 km/h であった。FD 変数の推定について、今回は全領域で FD 変数が同一であると仮定し、本手法により推定した。

プローブ混入率 5.0%、時間分解能 1 min、空間分解能 300 m の推定結果を図-7 に示す。図-7a は真の交通状態、b は観測ベクトルの値すなわち基本手法の推定結果、c は本手法の推定結果である。図-7b と c を比較すると、特に密度の小さい自由流領域にて誤差が大きく解消されている点が見える。

図-8 に、同シナリオでプローブカーによって観測された FD（赤線）、プローブカー毎の非集計の車頭距離-

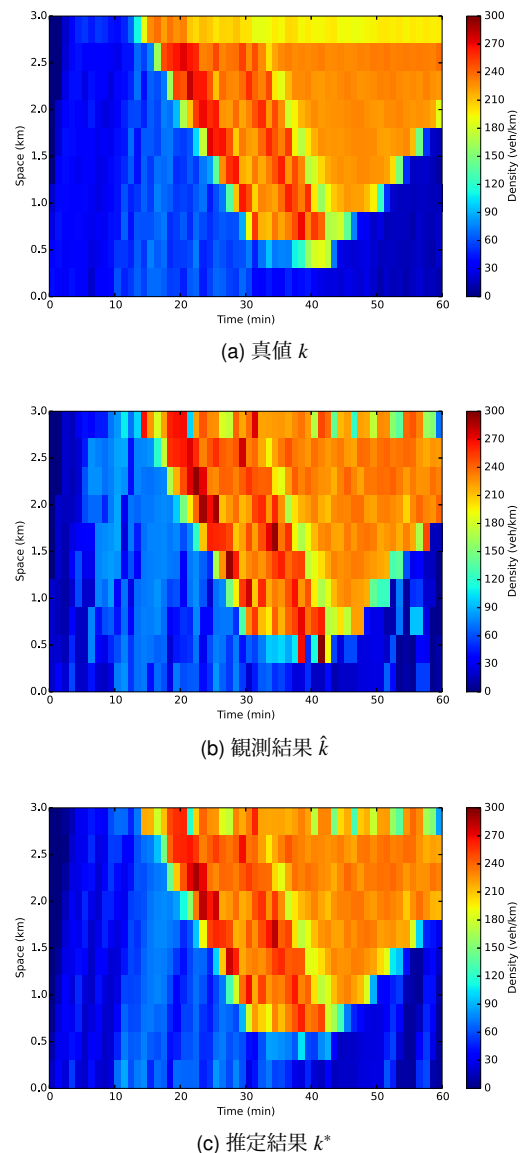


図-7: シミュレーション実験結果の time-space diagram

車頭時間関係（灰点）、時空間毎に集計された流率-密度関係（青クロス）を示す。非集計関係はマイクロ交通流の乱雑さや車両毎の異質性により広く散らばった関係となっているが、そのデータから推定された観測 FD は集計された流率-密度関係に近い 2 値関係を描いている。

表-2 に推定シナリオごとの誤差指標をまとめた。ここに、 $\text{PoI}(k^*, \hat{k})$  は  $(\text{RMSPE}(\hat{k}) - \text{RMSPE}(k^*)) / \text{RMSPE}(\hat{k})$  で定義され、推定量  $k^*$  が推定量  $\hat{k}$  に比べて改善した割合を示している。RMSPE の傾向は基本手法と同一であり、 $P$ ,  $\Delta t$ ,  $\Delta x$  が大きいほど精度が良いという結果であった。また、PoI によると、FD の内生的考慮により精度が向上したといえ、本手法の長所が想定通り働いたといえる。ただし、これは本実験では FD が大きく変わらないようなシミュレーション設定を用いた点も一因である。




図-8: 観測FD, 非集計車頭距離-車頭時間関係, 集計流量-密度関係

表-2: 交通状態・パラメータ同時推定の誤差指標

Scenario parameters			Error Indices	
$P$	$\Delta t$ (min)	$\Delta x$ (m)	RMSPE( $k^*$ )	Pol( $k^*, k$ )
0.5%	1	300	207.2%	11.4%
0.5%	5	500	105.3%	4.8%
0.5%	10	1000	21.5%	6.8%
1.0%	1	300	153.3%	14.9%
1.0%	5	500	79.3%	18.7%
1.0%	10	1000	14.9%	14.8%
5.0%	1	300	57.0%	24.3%
5.0%	5	500	17.8%	23.8%
5.0%	10	1000	7.2%	21.1%

#### 4. おわりに

本稿では、「周辺移動体を観測する移動体観測」という、交通データ収集のための方法論の可能性について、交通状態推定の例を通して考察した。交通状態推定は、自動車交通流に関して、その一部領域で収集（観測）したデータに基づき未観測領域のマクロな状態を推定する。ここでは、車間距離測定プローブカーが「周辺移動体を観測する移動体観測」の一つと位置づけられる。そして、「周辺移動体を観測する移動体観測」が、その「大域的な挙動のデータ」と「局所的な相互作用のデータ」を「交通システム内の広大な時空間」から収集可能であるという特徴を活かし、交通状態推定に資すると明らかにした。例えば、本プローブカーは、既存の移動体観測手法と同様に利用者側機器を用いてデータを収集するため追加コストが小さく、一方で既存の定点観測手法と同様に量的情報を収集できる。そして、本プローブカーによる交通状態推定手法は、既存手法と比較し、交通流理論に関する強い外生的仮定を緩和した上で交通状態を推定できると示した。これは、理論的な矛盾なしに広大な道路時空間を対象として交通状態を推定できることにつながり、土木計画学・交通工学的な観点から有用であるといえる。

第2章では、交通流理論とデータに関する既往研究

を整理した。すなわち、(1) マクロ交通流理論の基礎を概説し、(2) 交通流データ収集手法について交通流理論と統合的な定義を導入してその性質を概観し、(3) 交通状態推定手法についてその方法論と用いるデータの観点からその長所と短所を明らかにした。具体的には、まず、多くの既往研究では、交通状態推定に際し強い外生的仮定を置いている問題を示した。ここに、強い外生的仮定とは、本来は交通状態推定が推定対象としている情報自体から導かれる要素を意味する。そして、車間距離測定プローブカーはそのような仮定を緩和する可能性を示した。

第3章では、車間距離測定プローブカーによる交通状態の推定手法について述べた。すなわち、(1) 同プローブカーを用いた交通状態推定手法の理論と実道実験による検証を述べ、(2) 同プローブカーを用いた交通状態とモデルパラメータの同時推定手法の理論とシミュレーション実験による検証について述べ、両手法の関係を議論した。具体的には、前述した強い外生的仮定を緩和しても、同プローブカーにより実際に交通状態を推定できると示した。ただし、高分解能状態の推定に際しては、ミクロ現象の乱雑さが支配的となり、推定精度が低くなる。この精度低下現象は、交通流モデルパラメータを同プローブカーデータから内生的に推定できると仮定すれば、それに基づく交通状態推定量の更新により改善できると示した。

今後の課題としては、本交通状態推定手法そのものの改善と、本方法論の他分野への拡張が考えられる。本交通状態推定手法の限界には、移動体観測者がランダムサンプリングされると仮定している点がある。すなわち、FDとは、本来は時刻 $t$ 、地点 $x$ 、車両 $n$ の全てに依存する関係である<sup>21), 24), 63)</sup>と考えられる( $q = Q(k, x, t, n)$ )。交通状態推定に関する多くの既往研究はその依存関係を無視していた。一方、本稿で紹介した車間距離測定プローブカーによる交通状態推定の基本手法は、そのうち $t, x$ についての依存関係を適切に考慮している。また、第3(2)章の手法も、さらなる改良を加えれば $t, x$ についての依存関係をより適切に考慮できる可能性がある。しかし、ランダムサンプリングの仮定は、 $n$ についての依存関係は未だ考慮できていないことを意味する。この点に関する改善に資する可能性のあるアプローチとして、認識された周辺旅行者情報に基づき自らの偏りを推定する手法が考えられる。

他分野への拡張の例としては、ネットワーク交通流推定が本手法の直接的な拡張として考えられる。そのための状態推定手法は提案されている<sup>64)</sup>。モデルを同時推定するためには、プローブデータに基づく交通需要の発生・集中モデル、経路選択モデル、分合流モデルの推定法を構築する必要がある。本交通状態推定手

法は、リンクでの低分解能情報を比較的小さいプローブ混入率で精度良く推定可能であるため、道路ネットワーク全域に渡りそのような情報を推定できれば、土木計画の実用的な観点から有益と期待できる。歩行者行動分析などといったより異なる分野への拡張については、原理的には、状態推定は可能と考えられる。モデルの推定に関しては、マクロモデルとミクロモデルを統合した枠組みを構築できれば、本方法論固有の性質を活かせるといえる。そのうえで、既存手法と比較して実用上十分な性能を期待できるか否か・実用上十分な性能とは何かという議論が必要となるだろう。

**謝辞:** 本稿の内容は、東京工業大学の朝倉康夫教授・日下部貴彦助教の指導のもと進められた研究に基づいている。第3.(1)節の分析で用いた車両感知器データは首都高速道路(株)に提供頂いた。本研究の一部は、(独)日本学術振興会の助成を受けている。

## 参考文献

- 1) 日下部貴彦: データオリエンテッド交通研究, 土木計画学研究・講演集, Vol. 50, 2014.
- 2) 大口敬, 中村英樹: 日本における交通容量・サービスの質に関する研究の概観と展望, 土木学会論文集 D3, Vol. 67, No. 3, pp. 217–229, 2011.
- 3) 瀬尾亨, 日下部貴彦, 朝倉康夫: 車間距離を計測するプローブカーを前提とした交通状態の推定手法, 土木学会論文集 D3 (土木計画学), Vol. 69, No. 5, pp. I.809–I.818, 2013.
- 4) Seo, T., Kusakabe, T., and Asakura, Y.: Estimation of flow and density using probe vehicles with spacing measurement equipment, *Transportation Research Part C: Emerging Technologies*, Vol. 53, pp. 134–150, 2015.
- 5) Seo, T. and Kusakabe, T.: Probe vehicle-based traffic state estimation method with spacing information and conservation law, *Transportation Research Part C: Emerging Technologies*, 2015, in press. doi:10.1016/j.trc.2015.05.019.
- 6) Seo, T., Kusakabe, T., and Asakura, Y.: Traffic state estimation with the advanced probe vehicles using data assimilation, in *Intelligent Transportation Systems (ITSC), 2015 18th International IEEE Conference on*, 2015, accepted.
- 7) 浅野美帆, 井料隆雅, 桑原雅夫: 交錯交通の容量評価のためのミクロ歩行者行動モデル, 交通工学, Vol. 43, No. 4, pp. 80–89, 2008.
- 8) 瀬尾亨, 柳沼秀樹, 福田大輔: Plan-Action 構造を考慮した歩行者挙動モデリングとその適用—駅改札付近を対象として, 土木学会論文集 D3 (土木計画学), Vol. 68, No. 5, pp. I.679–I.690, 2012.
- 9) 大森宣暁, 室町泰徳, 原田昇, 太田勝敏: 交通行動調査への GPS の適用可能性に関する調査, 第 18 回交通工学研究発表会報告, 1998.
- 10) 朝倉康夫, 羽藤英二, 大藤武彦, 田名部淳: PHS による位置情報を用いた交通行動調査手法, 土木学会論文集, No. 653, pp. 95–104, 2000.
- 11) 福山祥代, 羽藤英二: ネットワーク上の空間計画に向けた観測と行動モデルの展開, 土木計画学研究・講演集, Vol. 50, 2014.
- 12) Moskowitz, K.: Discussion of ‘freeway level of service as influenced by volume and capacity characteristics’ by D. R. Drew and C. J. Keese, *Highway Research Record*, Vol. 99, pp. 43–44, 1965.
- 13) Makigami, Y., Newell, G. F., and Rothery, R.: Three-dimensional representation of traffic flow, *Transportation Science*, Vol. 5, No. 3, pp. 302–313, 1971.
- 14) Newell, G. F.: A simplified theory of kinematic waves in highway traffic, part I, II and III, *Transportation Research Part B: Methodological*, Vol. 27, No. 4, pp. 281–313, 1993.
- 15) Edie, L. C.: Discussion of traffic stream measurements and definitions, in Almond, J. ed. *Proceedings of the 2nd International Symposium on the Theory of Traffic Flow*, pp. 139–154, 1963.
- 16) Lighthill, M. J. and Whitham, G. B.: 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*, Vol. 229, No. 1178, pp. 317–345, 1955.
- 17) Richards, P. I.: Shock waves on the highway, *Operations Research*, Vol. 4, No. 1, pp. 42–51, 1956.
- 18) Daganzo, C. F.: The cell transmission model: A dynamic representation of highway traffic consistent with the hydrodynamic theory, *Transportation Research Part B: Methodological*, Vol. 28, No. 4, pp. 269–287, 1994.
- 19) Lebacque, J. P.: The Godunov scheme and what it means for first order traffic flow models, in Lesort, J. B. ed. *Transportation and Traffic Theory. Proceedings of the 13th International Symposium on Transportation and Traffic Theory*, pp. 647–677, 1996.
- 20) 桑原雅夫, 吉井稔雄, 堀口良太: ブロック密度法を用いた交通流の表現方法について, 交通工学, Vol. 32, No. 4, pp. 39–43, 1997.
- 21) Newell, G. F.: A simplified car-following theory: a lower order model, *Transportation Research Part B: Methodological*, Vol. 36, No. 3, pp. 195–205, 2002.
- 22) Daganzo, C. F.: A variational formulation of kinematic waves: basic theory and complex boundary conditions, *Transportation Research Part B: Methodological*, Vol. 39, No. 2, pp. 187–196, 2005a.
- 23) Daganzo, C. F.: A variational formulation of kinematic waves: Solution methods, *Transportation Research Part B: Methodological*, Vol. 39, No. 10, pp. 934–950, 2005b.
- 24) Laval, J. A. and Leclercq, L.: The Hamilton–Jacobi partial differential equation and the three representations of traffic flow, *Transportation Research Part B: Methodological*, Vol. 52, pp. 17–30, 2013.
- 25) Cassidy, M. J.: Bivariate relations in nearly stationary highway traffic, *Transportation Research Part B: Methodological*, Vol. 32, No. 1, pp. 49–59, 1998.
- 26) Geroliminis, N. and Daganzo, C. F.: Existence of urban-scale macroscopic fundamental diagrams: Some experimental findings, *Transportation Research Part B: Methodological*, Vol. 42, No. 9, pp. 759–770, 2008.
- 27) 清水英範, 四童子隆, 布施孝志: 成層圏プラットフォームを想定した車両の動体追跡手法に関する研究, 写真測量とリモートセンシング, Vol. 38, No. 4, pp. 53–58, 1999.
- 28) 布施孝志, 清水英範, 前田亮: 高度撮影時系列画像を用いた車両動態認識手法の構築, 土木学会論文集, No. 737, pp. 159–173, 2003.
- 29) Coifman, B., McCord, M., Mishalani, R. G., Iswalt, M., and Ji, Y.: Roadway traffic monitoring from an unmanned aerial vehicle, *Intelligent Transport Systems, IEE Proceedings*, Vol. 153, No. 1, pp. 11–20, 2006.
- 30) US Department of Transportation: NGSIM—Next Generation Simulation, 2006. <http://ngsim-community.org/>.
- 31) Wardrop, J. G. and Charlesworth, G.: A method of

- estimating speed and flow of traffic from a moving vehicle, in *ICE Proceedings: Engineering Divisions*, Vol. 3, pp. 158–171, Thomas Telford, 1954.
- 32) Redmill, K. A., Coifman, B., McCord, M., and Mishalani, R. G.: Using transit or municipal vehicles as moving observer platforms for large scale collection of traffic and transportation system information, in *Intelligent Transportation Systems (ITSC), 2011 14th International IEEE Conference on*, pp. 1089–1095, 2011.
- 33) 国土交通省: オートパイロットシステムの実現に向けて, 審議会・委員会中間とりまとめ, 2013.
- 34) Yokoi, K., Suzuki, Y., Sato, T., Abe, T., Toda, H., and Ozaki, N.: A camera-based probe car system for traffic condition estimation, in *Proceedings of 20th ITS World Congress*, 2013.
- 35) Messelodi, S., Modena, C. M., Zanin, M., Natale, F. G. D., Granelli, F., Betterle, E., and Guarise, A.: Intelligent extended floating car data collection, *Expert Systems with Applications*, Vol. 36, No. 3, Part 1, pp. 4213–4227, 2009.
- 36) 中辻隆: 交通流におけるフィードバック原理に基づく推定技術の現状と展望, *IATSS Review*, Vol. 31, No. 1, pp. 15–23, 2006.
- 37) 福田大輔: データ同化アプローチによる交通状態の推定に関する研究動向, *交通工学*, Vol. 47, No. 2, pp. 33–38, 2012.
- 38) Karlaftis, M. G. and Vlahogianni, E. I.: Statistical methods versus neural networks in transportation research: Differences, similarities and some insights, *Transportation Research Part C: Emerging Technologies*, Vol. 19, No. 3, pp. 387–399, 2011.
- 39) 坂井勝哉, 日下部貴彦, Chong, Wei, 朝倉康夫: 旅行時間の区間推定に関する統計分析, *土木学会論文集 D3 (土木計画学)*, Vol. 68, No. 5, pp. I.1297–I.1307, 2012.
- 40) Vlahogianni, E. I., Karlaftis, M. G., and Golias, J. C.: Short-term traffic forecasting: Where we are and where we're going, *Transportation Research Part C: Emerging Technologies*, Vol. 43, Part 1, pp. 3–19, 2014.
- 41) 花岡洋平, 原祐輔, 片岡駿, 桑原雅夫: Graphical Lasso を用いた長期観測プローブデータによるリンク交通状態補間, *土木計画学研究・講演集*, Vol. 51, 2015.
- 42) 成岡尚哉, 瀬尾亨, 日下部貴彦, 朝倉康夫: ノンパラメトリック手法による車両感知器データからの突発的ボトルネック検出法, *交通工学論文集*, Vol. 1, No. 1, pp. 11–20, 2015.
- 43) Gazis, D. C. and Knapp, C. H.: On-line estimation of traffic densities from time-series of flow and speed data, *Transportation Science*, Vol. 5, No. 3, pp. 283–301, 1971.
- 44) Muñoz, L., Sun, X., Horowitz, R., and Alvarez, L.: Traffic density estimation with the cell transmission model, in *American Control Conference*, Vol. 5, pp. 3750–3755, 2003.
- 45) Wang, Y. and Papageorgiou, M.: Real-time freeway traffic state estimation based on extended Kalman filter: a general approach, *Transportation Research Part B: Methodological*, Vol. 39, No. 2, pp. 141–167, 2005.
- 46) Nanthawichit, Chumchoke, 中辻隆, 鈴木宏典: プローブカーデータを用いた高速道路における動的な交通状態推定について, *土木学会論文集*, No. 730, pp. 43–54, 2003.
- 47) Herrera, J. C. and Bayen, A. M.: Incorporation of Lagrangian measurements in freeway traffic state estimation, *Transportation Research Part B: Methodological*, Vol. 44, No. 4, pp. 460–481, 2010.
- 48) Deng, W., Lei, H., and Zhou, X.: Traffic state estimation and uncertainty quantification based on heterogeneous data sources: A three detector approach, *Transportation Research Part B: Methodological*, Vol. 57, pp. 132–157, 2013.
- 49) Mehran, B. and Kuwahara, M.: プローブ, 車両通過時刻, 信号制御データの融合による一般街路上の車両軌跡推定, *交通工学*, Vol. 46, No. 1, pp. 77–89, 2011.
- 50) Yuan, Y., van Lint, J. W. C., Wilson, R. E., van Wageningen-Kessels, F., and Hoogendoorn, S. P.: Real-time Lagrangian traffic state estimator for freeways, *Intelligent Transportation Systems, IEEE Transactions on*, Vol. 13, No. 1, pp. 59–70, 2012.
- 51) 桑原雅夫, 大畑長, 瀧川翼, 阿部公一, 今井武: プローブデータと車両感知器データを融合活用した都市間高速道路における交通状態の推定, *土木計画学研究・講演集*, Vol. 47, 2013.
- 52) 和田健太郎, 小林桂子, 桑原雅夫: プローブ車両軌跡データのみを用いた交通の量的把握, *生産研究*, Vol. 67, No. 2, pp. 143–147, 2015.
- 53) Qu, X., Wang, S., and Zhang, J.: On the fundamental diagram for freeway traffic: A novel calibration approach for single-regime models, *Transportation Research Part B: Methodological*, Vol. 73, pp. 91–102, 2015.
- 54) Chiabaut, N., Buisson, C., and Leclercq, L.: Fundamental diagram estimation through passing rate measurements in congestion, *Intelligent Transportation Systems, IEEE Transactions on*, Vol. 10, No. 2, pp. 355–359, 2009.
- 55) Hegyi, A., Girimonte, D., Babuska, R., and De Schutter, B.: A comparison of filter configurations for freeway traffic state estimation, in *Intelligent Transportation Systems Conference, IEEE*, pp. 1029–1034, 2006.
- 56) Wang, Y., Papageorgiou, M., Messmer, A., Coppola, P., Tzimitsis, A., and Nuzzolo, A.: An adaptive freeway traffic state estimator, *Automatica*, Vol. 45, No. 1, pp. 10–24, 2009.
- 57) Herrera, J. C., Work, D. B., Herring, R., Ban, X. J., Jacobson, Q., and Bayen, A. M.: Evaluation of traffic data obtained via GPS-enabled mobile phones: The Mobile Century field experiment, *Transportation Research Part C: Emerging Technologies*, Vol. 18, No. 4, pp. 568–583, 2010.
- 58) 瀬尾亨, 日下部貴彦, 朝倉康夫: 車両軌跡に基づく流率密度関係の推定法—基本的な枠組みと数値実験, 第35回交通工学研究発表会論文集, 2015, 受理.
- 59) 小谷益男, 古市朋輝, 児島正之, 岩崎征人: 高速道路単路部における連続的な交通容量推定手法とその有効性, *土木学会論文集*, No. 737/IV-60, pp. 125–131, 2003.
- 60) Wilby, M. R., Diaz, J. J. V., Gonzalez, A. B. R., and Sotelo, M. A.: Lightweight occupancy estimation on freeways using extended floating car data, *Journal of Intelligent Transportation Systems*, Vol. 18, No. 2, pp. 149–163, 2014.
- 61) Evensen, G.: Sequential data assimilation with a nonlinear quasi-geostrophic model using Monte Carlo methods to forecast error statistics, *Journal of Geophysical Research: Oceans*, Vol. 99, No. C5, pp. 10143–10162, 1994.
- 62) TSS-Transport Simulation Systems: Aimsun. <http://www.aimsun.com>.
- 63) Coifman, B.: Empirical flow-density and speed-spacing relationships: Evidence of vehicle length dependency, *Transportation Research Part B: Methodological*, Vol. 78, pp. 54–65, 2015.
- 64) Seo, T.: Traffic estimation with vehicles observing other vehicles, Ph.D. dissertation, Tokyo Institute of Technology, 2015, preparing.

REVIEW OF METHODOLOGY OF ESTIMATING TRAFFIC STATE BASED ON  
LAGRANGIAN SENSING WHICH OBSERVES OTHER NEARBY VEHICLES

Toru SEO