

# 速度データに基づく交通流の状態と モデルパラメータの同時推定

成岡 尚哉<sup>1</sup>・瀬尾 亨<sup>2</sup>・日下部 貴彦<sup>3</sup>・朝倉 康夫<sup>4</sup>

<sup>1</sup>正会員 東日本高速道路株式会社（〒100-6080 東京都千代田区霞が関三丁目3-2）

<sup>2</sup>学生会員 東京工業大学（〒152-8552 東京都目黒区大岡山2-12-1-M1-20）  
E-mail: t.seo@plan.cv.titech.ac.jp

<sup>3</sup>正会員 東京工業大学助教（〒152-8552 東京都目黒区大岡山2-12-1-M1-20）  
E-mail: t.kusakabe@plan.cv.titech.ac.jp

<sup>4</sup>正会員 東京工業大学教授（〒152-8552 東京都目黒区大岡山2-12-1-M1-20）  
E-mail: asakura@plan.cv.titech.ac.jp

道路ネットワーク上において時々刻々と変化する交通状態や交通容量などの交通流パラメータを把握することは、動的な交通施策を行う上で重要である。このため道路上では車両感知器など様々な観測機器が設置されているが、例えば、定点に設置されている観測機器では、設置地点間の非観測領域の交通状態を直接的には得ることはできない。そこで本研究では、このような非観測領域の交通状態と交通流パラメータを推定することを目的としたデータ同化手法を構築する。速度を状態変数とするCell Transmission Model for velocityを用い、パラメータと交通状態を交互に推定していくDual法を適用する。また、交通流には非線形特性があるためParticle Filteringによる計算を行う。検証により、特定の条件下ではパラメータの推定が可能であることが示された。

**Key Words :** *traffic state estimation, parameter estimation, data assimilation*

## 1. はじめに

道路ネットワーク上で時々刻々と変化する交通量や速度などの交通流の状態変数（交通状態）を把握することは、動的な交通施策を行ううえで重要である。このような状態変数は、交通流の現況把握に必要なだけでなく、旅行時間の予測や交通流制御には欠かせない交通流シミュレータ等の基本的な入力値となるためである。

高速道路での交通状態の把握は、車両感知器（あるいは車両検知器）などの定点観測装置による観測が主流である。定点観測では、観測装置が設置されている地点では交通量や速度を観測することができるが、設置されていない地点での交通状態を一切把握することができない。このため、都市間高速道路のように設置間隔が大きい道路区間では、空間的に高解像度な交通状態の把握はできない。近年では、GPSを搭載したプローブカー（GPSプローブカー）などの移動体観測が普及しつつあり、定点観測装置が設置されていない地点での交通状態を部分的に把握できつつある。しかし、GPSプローブカーでは、

速度のみが観測可能であることから、交通量や交通密度といった車両台数に関わる状態変数を観測することはできない。また、道路上に存在する一部の車両のみが観測を行うことから、必ずしも、全ての時間・空間が網羅的に観測されているわけではない。交通状態は、ショックウェーブの延伸などの動的な現象の影響を受けることから、定点観測によっても移動体観測によっても直接観測されていない領域の交通状態は、線形回帰モデルなどの単純な統計モデルでは推定することはできない。しかし、逆に、基本図（QK図とも）等の交通流の性質が明らかの場合には、そのような既知の性質を活かして、限られたデータから補間推定することが可能と考えられ、交通状態をより広い範囲かつ高解像度で把握できると期待される。

交通流の性質を活かし交通流理論に整合的な交通状態を推定する方法として、データ同化手法がある（例えば、中辻<sup>1)2)</sup>）。これは、交通流理論に従った演繹的なシミュレーションモデルと、多量の観測されたデータを統合する。一般に、演繹的なシミュレーションモデルはモデ

ルの構造や初期条件, 境界条件の設定に依存し, 推定結果と実際の交通状態の間に誤差が生じる. 一方で, 観測データの統計値は観測値自体に誤差を含んでいることがある. そのため, 統計値を用いる際に, それが交通流理論と整合性があるかを判別することは難しい. データ同化手法による交通状態推定では, 両者をベイズ統計学の手法により統合することで, 初期条件の設定や境界条件の設定, 交通流理論との整合性の問題点を緩和する.

シミュレーションモデルのパラメータは常に一定とは限らず, 例えば, 気象条件により変化することもある. 特に車線閉塞を伴う事故等により突発的なボトルネックが発生した時は急激な交通容量の低下がみられる. そのためシミュレーションを行う際のパラメータ設定は極めて重要である. しかし, 既存の交通状態推定手法の多くが, 事前にモデルパラメータをするなど所与として取り扱っている<sup>3)4)</sup>. 突発的なボトルネックが発生などによるモデルパラメータの変動をいち早く検知するには, モデルパラメータも速度や密度などの交通状態とともに推定することが必要と考えられる. このような手法を用いれば, 交通状態の把握がより重要となる突発事象発生時や悪天候時の交通状態を精緻に把握できると期待される.

本研究の目的は観測装置から得られる交通状態から, 非観測地点の交通状態とシミュレーションに用いるマクロ交通流モデルのパラメータをデータ同化手法を用いて同時に推定する手法を構築することである.

## 2. 既往研究

データ同化手法を用いた交通状態推定に関する研究は, シミュレーションのモデルパラメータの与え方の観点から以下の2つに大別できる.

- ① モデルパラメータを所与とするもの (既知もしくは事前推定)
- ② モデルパラメータを交通状態とともに同時に推定するもの

本来, シミュレーション (例: マクロ交通流モデル) のモデルパラメータ (例: 臨界速度や交通容量) は時点・地点に依存する値であり, シミュレーション中の交通状態の動的的变化を決定するための値である. これらの値は必ずしも動的に変化するとは限らないが, 背景で述べたように一定であるとも限らない.

モデルパラメータを事前に与える①のモデルは, モデルパラメータは, 所与とするものであり, 既往研究で多く採用されている. ②はモデルパラメータを同時推定するものであるが, 同時推定法を適用している交通分野の研究は少ない.

### (1) データ同化手法による交通状態推定に関する研究

これまでの交通流に関するデータ同化手法は, Kalman Filtering (以下, KF) を基本として, 発展系である Unscented Kalman Filter (以下, UKF), Extended Kalman Filtering (以下, EKF), Ensemble Kalman Filtering (以下, EnKF) を用いた研究がある. 観測値には, 車両感知器等で取得される地点交通量・速度を用いた研究が多いが, プローブカー等で得られる速度データも用いているものもある. シミュレーションモデルには, マクロ交通流モデル (例: Cell Transmission Model<sup>6)</sup> (以下CTM) とその発展系や, 高次項モデル<sup>7)8)</sup> が用いられる.

Workら<sup>9)</sup>は, CTMの状態変数を速度を用いた式に変換したCell Transmission Model for velocity (以下CTM-v) を用い, EnKFにより交通状態を推定している. CTM-vを用いて状態変数を速度にすることで, 移動体観測装置で得られる速度を直接的に状態変数として用いている. また, Workら<sup>10)</sup>, Allstromら<sup>11)</sup>では, 実際の道路区間で取得されたデータに適用している. 福田ら<sup>5)</sup>は, CTM-vを用いたEnKFによる交通状態推定手法を構築し, データ同化手法を用いることで, 非観測地点の交通状態の推定が可能であることを示している.

### (2) 同時推定に関する研究

データ同化手法によりモデルパラメータと状態変数を同時推定する方法は大きく2つに分かれる. 一つはJoint法であり, もう一つはDual法である. 前者は, モデルパラメータと状態変数を一つのベクトルとして扱い, 通常のデータ同化手法で推定する. この手法は, モデルパラメータと状態変数の相関関係も推定できる. 一方で, 推定すべき変数のベクトルの次元は大きくなるため, パーティクルフィルタのようにモンテカルロシミュレーションでサンプルを発生させて近似計算を行う推定手法の場合, 変数が多くなるにつれて必要なサンプル数が膨大になる. 後者は, モデルパラメータと状態変数それぞれ交互に推定する手法である. モデルパラメータと状態変数は条件付独立の仮定が必要であるが, パーティクルフィルタのようにサンプルによる近似計算をする推定手法の場合, Joint法に比べて必要なサンプル数が少なくすむという利点がある.

Wangら<sup>12)</sup>は, Papageorgiouら<sup>8)</sup>による高次項モデルを用い, EKFによるJoint法によりモデルパラメータを推定した. 中西・布施<sup>13)</sup>はネットワーク上の歩行者の移動を対象とし, Joint法を用いて観測誤差に関する分散の値を逐次的に推定した. 一方, Dual法を交通流に適用した研究は少ない. Wan・Nelson<sup>14)</sup>は音声の状態推定を対象として, Dual法によりパラメータを推定した. Olivier<sup>15)</sup>らは, 鉱石の粉碎機の状態推定を対象として, Joint法とDual法をそれぞれPFに適用し, 状態変数とモデルパラメータを推定した. その結果, モデルパラメータに変動がある

場合、Joint法と比べDual法の方が推定精度が高いことを示している。これは、Dual法を用いた場合、観測値に対するモデルの感度がJoint法よりも高いためである。

### 3. モデル

本研究では、Dual法とPFを用いた交通流のデータ同化手法を提案する。交通状態推定では、モデルパラメータの突発的变化に素早く、正確に追従する必要があることから、Joint法に比べパラメータの変動に対する追従性に優れているDual法を採用した。PFは、モンテカルロ法により分布を近似することから状態変数やモデルパラメータの分布は正規分布に限らず任意の形状をとることができる。また、状態変数と観測値の次元が線形の関係でなくとも状態推定が可能であるため、定点観測や移動体観測など様々な観測装置が混在する場合にも適用が可能である。このことから、PFは今後の研究で応用がしやすく発展性があると考えられるため採用した。

交通流のシミュレーションモデルには、プローブカーから取得可能な速度データの適用が容易なCTM-vを用いる。本研究では移動体観測装置であるGPSプローブカーによる地点ごとの速度データと、定点観測装置である車両感知器の速度データを扱う。したがって、状態変数を速度としているシミュレーションモデルを採用することで、状態変数と観測値が同じ次元に乗り、観測モデルを容易に定めることができる。

#### (1) Dual Particle Filtering (DPF)

本研究では交通流理論に従ったシミュレーションモデルと観測値から、状態変数とモデルパラメータを推定する手法を提案する。そのためのDual法によるPFに属する手法として、Dual Particle Filtering (DPF)を定式化する。図-1にDPFの概念図を示す。DPFは状態変数とモデルパラメータを交互に推定する手法である。それぞれの推定では、予測段階とフィルタリング段階の二つの段階を交互

に行う。なお、本章で用いる記号は、

- $t$  :時刻
- $x_t$  :時刻 $t$ における状態変数ベクトル
- $\theta_t$  :時刻 $t$ におけるモデルパラメータベクトル
- $y_t$  :時刻 $t$ における観測値ベクトル
- $Y_{1:t}$  :時刻1から $t$ までのにおける観測値ベクトル集合
- $\tilde{x}_t$  :パラメータ推定に用いる時刻 $t$ における補助状態変数ベクトル

である。DPFでは、状態変数の発展を記述する交通シミュレーションモデル、モデルパラメータの発展を記述するモデル、状態変数と観測値の関係を記述する観測モデルを用いて、時刻 $t$ までに観測された観測値から状態変数とパラメータの分布である $p(x_t|Y_{1:t})$ と $p(\theta_t|Y_{1:t})$ を求めるところを目的としている。

状態変数の発展を記述する交通シミュレーションモデルは、時刻 $t-1$ までの状態変数ベクトル $x_{t-1}$ とパラメータ $\theta$ から時刻 $t$ の状態変数ベクトルの分布 $p(x_t|x_{t-1}, \theta)$ を推定するものである。モデルパラメータの発展を記述するモデルは、時刻 $t-1$ までのモデルパラメータ $\theta_{t-1}$ から時刻 $t$ のパラメータベクトルの分布 $p(\theta_t|\theta_{t-1})$ を求めるものである。観測モデルは、状態変数及びパラメータベクトルと観測値との関係を記述した分布であり、 $p(y_t|x_t, \theta_t)$ のように表す。それぞれのモデルの具体的な設定については、(2)から(4)で述べる。

予測段階は、状態変数とモデルパラメータの時間的推移がマルコフ性を持つという仮定のもとで、時刻 $t-1$ までの観測ベクトルを用いて状態変数を推定する。

$$p(x_t|Y_{1:t-1}) = \int p(x_t|x_{t-1}, \bar{\theta}_{t-1}) p(x_{t-1}|Y_{1:t-1}) dx_{t-1} \quad (1)$$

この式で、 $t-1$ でのパラメータベクトルには、 $\theta_{t-1}$ の分布 $p(\theta_{t-1}|Y_{1:t-1})$ を直接用いる代わりに、

$$\bar{\theta}_{t-1} = \arg \max_{\theta_{t-1}} p(\theta_{t-1}|Y_{1:t-1}) \quad (2)$$

とした代表点を用いる。なお、 $\bar{\theta}_{t-1}$ は、 $p(\theta_{t-1}|Y_{1:t-1})$ が単峰かつ歪度が0の分布である場合は、その期待値と一致することから、式(1)は $p(\theta_{t-1}|Y_{1:t-1})$ を直接用いる場合と一致する。つまり、時刻 $t-1$ までの観測モデルによって得られた状態変数ベクトルの分布とその時点でのパ

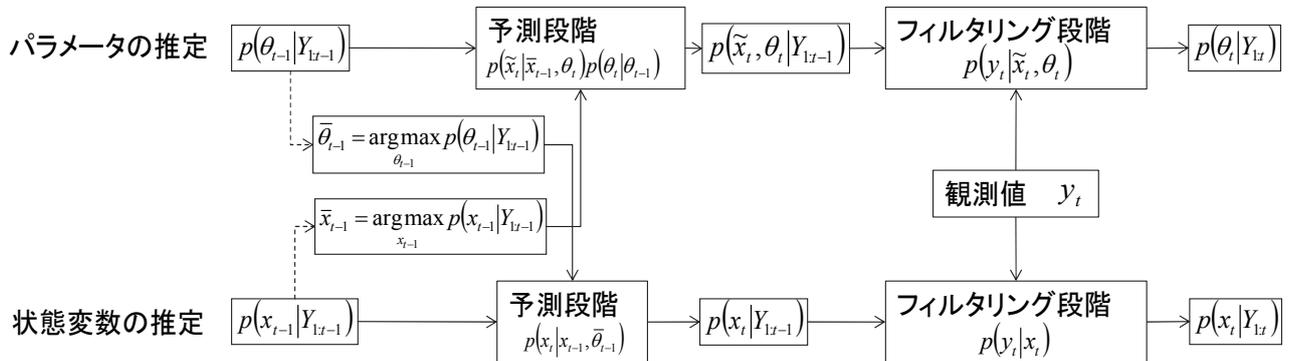


図-1 Dual Particle Filtering (DPF)の概念図

ラメータベクトルの代表値を用いて交通シミュレーションモデルによって、時刻 $t$ の状態変数ベクトルを求めていると解釈できる。パラメータベクトルと補助状態ベクトルを推定する式は、

$$p(\tilde{x}_t, \theta_t | Y_{t-1}) = \int p(\tilde{x}_t | \tilde{x}_{t-1}, \theta_t) p(\theta_t | \theta_{t-1}) p(\theta_{t-1} | Y_{t-1}) d\tilde{x}_{t-1} \quad (3)$$

$$\tilde{x}_{t-1} = \arg \max_{\tilde{x}_{t-1}} p(\tilde{x}_{t-1} | Y_{t-1}) \quad (4)$$

を表す。この式では、時刻 $t-1$ までの観測モデルによって得られたパラメータベクトルと、モデルパラメータの発展を記述するモデルと交通シミュレーションモデルから、時刻 $t$ での補助状態変数ベクトルとパラメータベクトルを得る。

フィルタリング段階では、予測段階で得られた状態変数ベクトル、補助状態変数ベクトル、パラメータベクトルのそれぞれの分布を時刻 $t$ の観測値とベイズの定理を用いて更新する。状態変数ベクトルの更新式は、

$$p(x_t | Y_t) = \frac{p(y_t | x_t) p(x_t | Y_{t-1})}{\int p(y_t | x_t) p(x_t | Y_{t-1}) dx_t} \quad (5)$$

と表すことができ、

$$p(\theta_t | Y_t) = \int \frac{p(y_t | \tilde{x}_t, \theta_t) p(\tilde{x}_t, \theta_t | Y_{t-1})}{\iint p(y_t | \tilde{x}_t, \theta_t) p(\tilde{x}_t, \theta_t | Y_{t-1}) d\theta_t d\tilde{x}_t} d\tilde{x}_t \quad (6)$$

と表すことができる。なお、DPFを用いた推定では、非線形性の強い交通シミュレーションモデルによる分布 $p(x_t | x_{t-1}, \theta)$ をモンテカルロ法によって求める。また、パラメータモデルである $p(\theta_t | \theta_{t-1})$ についても、状態変数モデルと整合的な取り扱いをするために、モンテカルロ法を用いる。

## (2) 交通シミュレーションモデルの定式化

DPFの $p(x_t | x_{t-1}, \theta)$ の分布を求めるための交通シミュレーションモデルとして、付録1で定義されるCTM-v<sup>20</sup>を用いる。このモデルは、道路上での速度変化の伝播を表現するモデルとして用いる。CTM-vは、道路区間を一定の長さを持ったセルに離散化し、離散化された時間ステップ毎にセル毎の速度を求める。

道路区間がセル $i=1,2,\dots,n$ で定義されている際に、時刻 $t$ の各セルの速度を $v_i^t$ とし、時刻 $t$ の速度ベクトル $\hat{v}_t = (\hat{v}_1^t, \hat{v}_2^t, \dots, \hat{v}_n^t)^T$ を定義する。 $\theta$ をパラメータとするCTM-vによる速度の時間的変化は、

$$\hat{v}_t = f(\hat{v}_{t-1}, \theta) \quad (7)$$

として表現できる。このとき、時刻 $t$ と時刻 $t-1$ の状態変数ベクトルの関係

$$x_t = f(x_{t-1}, \theta) + \varepsilon_{v,t} \quad (8)$$

と定義し、この分布関数を $p(x_t | x_{t-1}, \theta)$ とする。

$\varepsilon_{v,t} = (\varepsilon_{v,t}^1, \varepsilon_{v,t}^2, \dots, \varepsilon_{v,t}^n)$ は、シミュレーションモデルの不確実性を示す確率変数ベクトルである。ただし、 $\varepsilon_{v,t}^i \sim G_{v_i}$ で $G_{v_i}$ は分布関数とし、具体的な分布関数は第4章(2)で定義する。

## (3) 交通流モデルのパラメータに関する定式化

本節では、式(3)の確率変数によるベクトル $\theta_t$ の分布 $p(\theta_t | \theta_{t-1})$ を定義する。CTM-vは、交通流の基本関係であるQK関係に関わるパラメータをもとに交通流の速度伝播を表現するマクロシミュレーションモデルである。このモデルのパラメータベクトルには、それぞれのセルのQK関係を決定するパラメータである臨界密度、最大密度、最大速度を用いる。これらのパラメータは、各セルについて時刻毎に定義されることから、臨界密度ベクトル $\hat{k}_{c,t} = (\hat{k}_{c,t}^1, \hat{k}_{c,t}^2, \dots, \hat{k}_{c,t}^n)$ 、最大密度ベクトル $\hat{k}_{\max,t} = (\hat{k}_{\max,t}^1, \hat{k}_{\max,t}^2, \dots, \hat{k}_{\max,t}^n)$ 、最大速度ベクトル $\hat{v}_{\max,t} = (\hat{v}_{\max,t}^1, \hat{v}_{\max,t}^2, \dots, \hat{v}_{\max,t}^n)$ として定義する。したがって、パラメータベクトルは、 $\theta_t = (\hat{k}_{c,t}, \hat{k}_{\max,t}, \hat{v}_{\max,t})^T$ と定義できる。

本研究では、パラメータベクトルの時間変化に単純な確率モデルであるランダムウォークを仮定する。このとき、それぞれのパラメータの時間変化は、

$$\hat{k}_{\max,t} = \hat{k}_{\max,t-1} + \varepsilon_{k_{\max},t} \quad (9)$$

$$\hat{k}_{c,t} = \hat{k}_{c,t-1} + \varepsilon_{k_c,t} \quad (10)$$

$$\hat{v}_{\max,t} = \hat{v}_{\max,t-1} + \varepsilon_{v_{\max},t} \quad (11)$$

と表せる。ただし、 $\varepsilon_{k_{\max},t}$   $\varepsilon_{k_c,t}$   $\varepsilon_{v_{\max},t}$ は、それぞれ、分布関数 $G_{k_{\max}}$   $G_{k_c}$   $G_{v_{\max}}$ に従う確率変数ベクトルである。なお、本研究で用いる具体的な分布関数は、第4章(2)で定義する。

## (4) 観測モデルの定式化

観測モデル $p(y_t | x_t)$ 及び $p(y_t | x_t, \theta_t)$ は、時刻 $t$ の状態変数及びパラメータと観測値の関係を表すモデルである。本研究では、プローブカーの通過地点や車両感知器の設置地点での速度が得られると想定し、各セルでの速度を観測変数とする。時刻 $t$ に $\kappa_t$ 個のセルで観測値が得られているときに、観測値が得られているセル番号を $C(t) = \{C(t,1), C(t,2), \dots, C(t,\kappa_t)\}$ とすると、観測ベクトルは、 $y_t = (v_{obs,t}^{C(t,1)}, v_{obs,t}^{C(t,2)}, \dots, v_{obs,t}^{C(t,\kappa_t)})^T$ と表現できる。観測ベクトルと状態ベクトルの次元が異なることから、これらを変換するための行列として、

$$H_t = \begin{bmatrix} h_{0,0}^t & \dots & h_{0,N}^t \\ \vdots & \ddots & \vdots \\ h_{\kappa_t,0}^t & \dots & h_{\kappa_t,N}^t \end{bmatrix} \quad (12)$$

$$h_{i,j}^t = \begin{cases} 1 & \text{if } j = C(t,i) \\ 0 & \text{otherwise} \end{cases} \quad (13)$$

を定義する。観測誤差が共分散行列 $R$ が与えられたときの多次元正規分布 $N(0, R)$ に従うとすると、 $p(y_t | x_t)$

は,

$$p(y_i|x_i) = p(y_i|x_i, \theta_i) = \frac{1}{(2\pi)^k \sqrt{|R|}} \exp\left(-\frac{(y-Hx)R^{-1}(y-Hx)^T}{2}\right) \quad (14)$$

となる.

#### 4. シミュレーションを用いた検証

本章では、DPFによる交通状態とパラメータの同時推定手法を検証する。まず、推定の対象となるモデルパラメータを持つシミュレーションモデルCTM-vを用いて検証用シミュレーションを実施し、真値となる速度データを生成する。生成された速度データを用いて、DPFにより状態変数とモデルパラメータを推定する。推定されたモデルパラメータと、速度データを生成する際に与えたパラメータを比較することで、DPFによるパラメータ推定の精度を検証する。また、推定された交通状態と、速度データを比較し、DPFの交通状態推定の精度を検証する。本研究では、車両感知器およびプローブカーからデータが収集されることを想定し、速度データのみから1種類のパラメータ臨界密度  $k_c^i$  又は最大速度  $v_{\max}^k$  を推定することで、モデルの特徴を分析する。

##### (1) 検証用シミュレーションの設定

シミュレーション全体に必要なパラメータであるセルの長さ  $l$  とタイムステップをそれぞれ  $l = 0.1$  [km],  $\Delta t = 3$  [秒]とし、図-2に示すセル数が7の単路部で1時間分のシミュレーションを行い、真値となる速度データを生成する。セル1への流入速度は図-3に示した値を中心に  $-2.5 \sim 2.5$  [km/h]の一様分布として与えた。

シミュレーションでは、4種類のシナリオを実施した。各シナリオの各セルの設定は、表-1に示す通りである。いずれのシナリオでもセル6以外のパラメータは共通である。シナリオ1と2では、セル6の臨界密度を30 [Veh/km]とすることでボトルネックを設定している。一方で、シナリオ3と4では、セル6の最大速度を85 [km/h]と設定することでボトルネックとしている。シナリオ1, 3では、全てのセルで速度が観測されている一方で、シナリオ2と4では、観測機器が設置されていないセルがあることを想定してセル4で観測値が得られない設定としている。なお、観測値は、各時間ステップでシミュレーションから得られる値そのものを用いる。シナリオ1, 2のシミュレーションから得られる速度は図-4となっており、シナリオ3, 4から得られる速度は図-5である。いずれのシナリオでも、ボトルネックを起点とした渋滞がセル1まで延伸した後、一度、渋滞が全て解消した後再び同様の渋滞の延伸が発生する設定とした。これは、渋滞領域、自由流時、渋滞の延伸時、渋滞の後退時の推定値の性質を分析することを意図したものである。

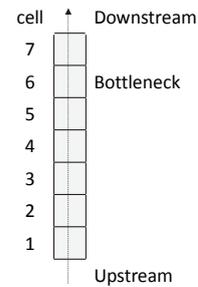


図-2 シミュレーション区間の模式図

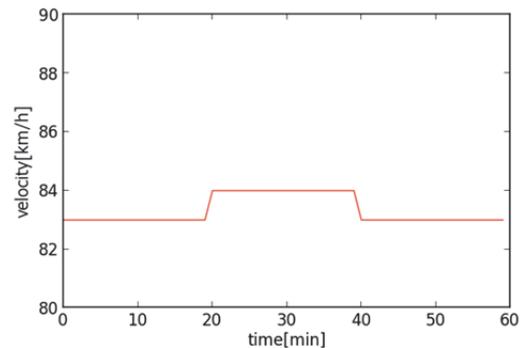


図-3 セル1への流入速度の時間分布

表-1 分析シナリオと各セルの設定値.

セル $i$	$k_c^i$		$k_{\max}^i$		$v_{\max}^i$		観測セル
	[Veh/km]		[Veh/km]		[km/h]		
セル $i$	1-5,7	6	1-7	1-5,7	6		
シナリオ1	40	30	180	100			全て
シナリオ2	40	30	180	100			4以外
シナリオ3	40		180	100	85		全て
シナリオ4	40		180	100	85		4以外

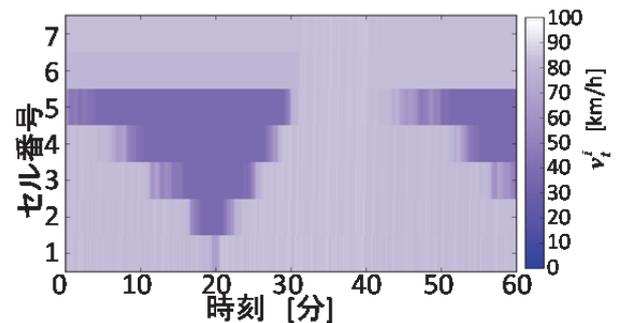


図-4 シナリオ1と2の速度の時空間分布

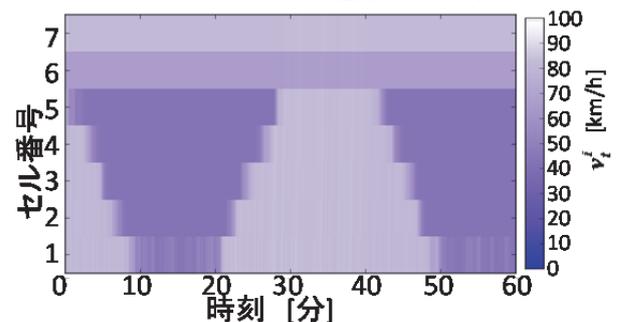


図-5 シナリオ3と4の速度の時空間分布

表-2 分析シナリオ毎のDPFの設定と初期値.

	初期値			$s_{k_c}$ [Veh/km]	$s_{v_{\max}}$ [km/h]
	$\hat{k}_{c,0}^i$	$\hat{k}_{\max,0}^i$	$\hat{v}_{\max,0}^i$		
	[Veh/km]	[Veh/km]	[km/h]		
シナリオ1	30±15	180	100	0.55	0
シナリオ2	30±15	180	100	0.55	0
シナリオ3	40	180	90±20	0	0.55
シナリオ4	40	180	90±20	0	0.55

## (2) 検証時のDPFの設定

シミュレーションの不確実性を示すランダム項に与える分布ベクトル  $G_v$  及びパラメータモデルのランダム項の分布ベクトル  $G_{k_{\max}}$ ,  $G_{k_c}$ ,  $G_{v_{\max}}$  には、それぞれ独立なロジスティック分布を仮定し、ロジスティック分布の確率密度関数は、

$$g(\varepsilon; \mu, s) = \frac{\exp(-(\varepsilon - \mu)/s)}{s(1 + \exp(-(\varepsilon - \mu)/s))^2} \quad (15)$$

とした。なお、 $s = 0$  のときは、

$$g(\varepsilon; \mu, s) = \begin{cases} \infty & \text{if } \varepsilon = \mu \\ 0 & \text{otherwise} \end{cases} \quad (16)$$

として取り扱う。各ベクトルの要素の分布関数は、

$$G_v^i = g(\varepsilon_{v,t}^i; 0, 0.55) \quad (17)$$

$$G_{k_{\max}}^i = g(\varepsilon_{k_{\max},t}^i; 0, 0) \quad (18)$$

$$G_{k_c}^i = g(\varepsilon_{k_c,t}^i; 0, s_{k_c}) \quad (19)$$

$$G_{v_{\max}}^i = g(\varepsilon_{v_{\max},t}^i; 0, s_{v_{\max}}) \quad (20)$$

とし、シナリオによって、異なる  $s_{k_c}$ ,  $s_{v_{\max}}$  を採用した。なお、最大密度に関しては、 $s = 0$  として初期値をそのまま用い、推定の対象とはしない。観測誤差には、観測ベクトルの要素のそれぞれに独立な正規分布  $N(0,1)$  を仮定した。また、DPFのパーティクル数は、シナリオ1と3で7000、シナリオ2と4で10000と設定した。表-2に各シナリオの推定対象と初期値をまとめた。

セル6の臨界密度  $k_c^6$  が他のセルに比べて小さいことを起因としたボトルネックがあるシナリオ1と2では、臨界密度  $k_{c,t}^i$  を推定の対象とする。最大速度については、 $s_{v_{\max}} = 0$  とすることで、初期値をそのまま用いる。セル6の最大速度  $v_{\max}^6$  が小さいことでボトルネックが生じるシナリオ3と4は、最大速度  $v_{\max}^k$  を推定の対象とする。また、これらのシナリオでは、 $s_{k_c} = 0$  として臨界密度は初期値を用いる。シナリオ1と2では、推定対象となる臨界密度  $k_{c,0}^i$  に初期値の設定が必要である。この  $k_{c,0}^i$  の初期値には、 $-15 \sim 15$  [Veh/km] の一様分布から得られた値に30 [Veh/km] を加えたものを用いる。シナリオ3と4では、推定対象となる臨界密度  $v_{\max,0}^i$  に初期値を設定する必要があるが、これは  $-20 \sim 20$  [Veh/km] の一様分布から得ら

れた値に90 [km/h] を加えたものとする。

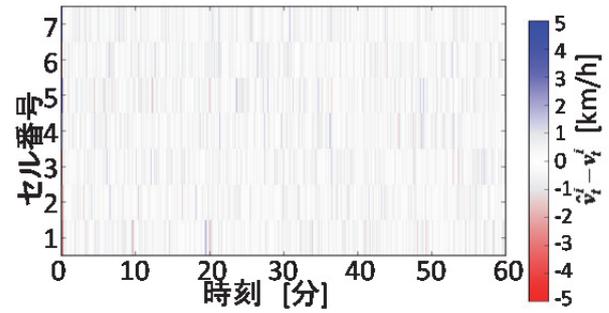
## (3) 結果

### a) シナリオ1

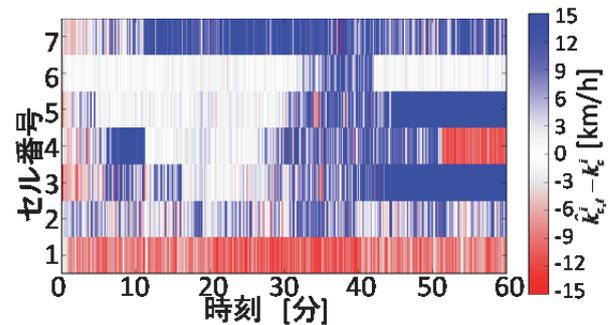
図-6は、シナリオ1の「推定された速度と観測された速度の差分」と「臨界密度と設定した臨界密度の差分」を示したものである。差分が正であるとき、過大に推定しており、一方で差分が負であるときは過小に推定していることを示している。図の(a)より速度は、大きくとも  $\pm 5$  [km/h] 以内の差であり、概ね正確な推定ができていることが分かる。一方で、(b)より、臨界密度の推定は、渋滞流領域では比較的精度よく推定できている部分があるが、自由流領域では、臨界密度の推定は過大推定となる傾向がある。また、境界領域（セル1及び7）では、臨界密度の推定が過大または過小となっていることが読み取れる。

自由流領域での臨界密度のパラメータの推定誤差が大きくなる原因として、本研究で採用した交通流モデルの性質として自由流領域では臨界密度の大きさが速度と密度の関係に影響を与えないことが挙げられる。観測値が自由流領域に収まる範囲の臨界密度であれば、臨界密度の値によらず速度と密度の関係は一定である。すなわち、臨界密度は、

$$\hat{k}_{c,t}^i \leq \hat{k}_{\max,t}^i \left( 1 - \frac{\hat{v}_t^i}{\hat{v}_{\max}^i} \right) \quad (21)$$



(a) 推定された速度と真値との差分



(b) 推定された臨界密度と真値との差分

図-6 シナリオ1の推定結果

の条件を満たせば、どの値であっても速度の推定精度に

は影響がでないため、臨界密度は過小に推定されることは少なく、過大に推定されることが多い。

渋滞領域での臨界密度のパラメータは、30分までに発生している渋滞では、比較的精度良く推定できているにもかかわらず、後半の40分以降に発生する渋滞では、推定精度が大きく低下している。

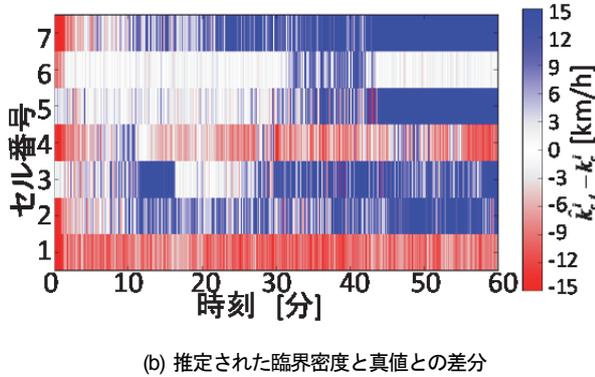
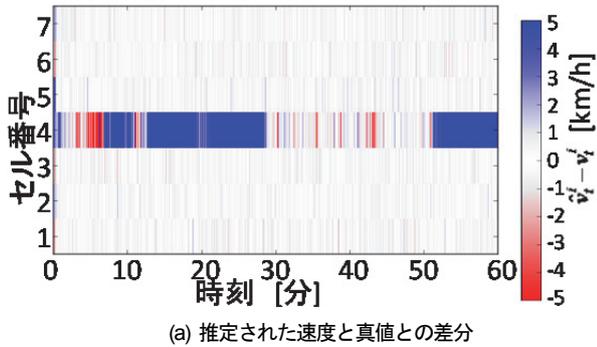


図-7 シナリオ2の推定結果

図-7は、シナリオ2の推定結果である。観測されているセルの推定結果は、シナリオ1と同様の傾向がある。非観測地点での速度の推定は、観測地点に比べてばらつきが大きい。また、自由流時は渋滞時に比べ精度がよい傾向にある。一方、臨界密度の推定結果の誤差は大きい。

非観測地点の速度の誤差が渋滞時に特に大きくなる原因は、本来、QK関係の渋滞領域として推定されるべき状態変数が、同じ交通量が実現される自由流領域として推定されていることが原因である。

c) シナリオ3

図-8は、シナリオ3の推定結果である。最大速度の推定は、渋滞の延伸時・縮小時に誤差が大きくなる傾向がある。また、過大推定となることが多く、特に速度の速い領域では顕著である。

d) シナリオ4

図-9は、シナリオ4の推定結果である。非観測地点の速度の推定は、ほとんどの場合過小推定となっている。観測地点の最大速度の推定は、渋滞の延伸時・縮小時に誤差が大きくなる。非観測地点の最大速度の推定は、渋滞流時には過大推定、自由流時には過小推定となる。

これまで考察してきた自由流領域・渋滞流領域の誤推定はセル4(非観測地点)での観測値が得られた場合の考察であった。そのため、セル4において速度が観測されない場合、推定する変数の自由度が高くなってしまふ。したがって、速度と最大速度は、特定の一つの値に推定されるのではなく、ある制約条件の上で任意の値をとることができるため、推定誤差が大きくなると考えられる。

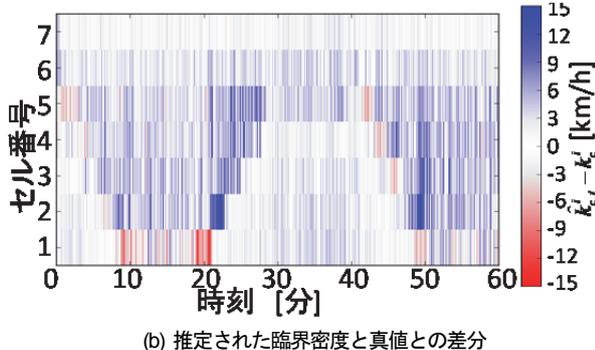
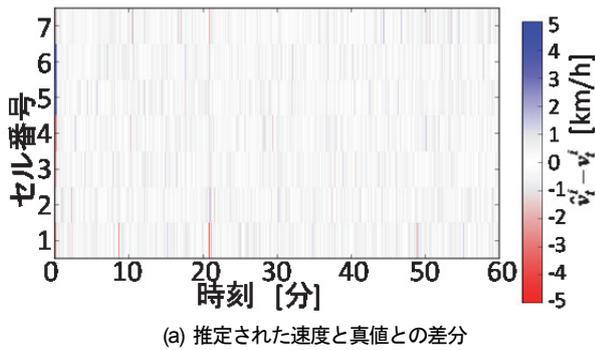


図-8 シナリオ3の推定結果

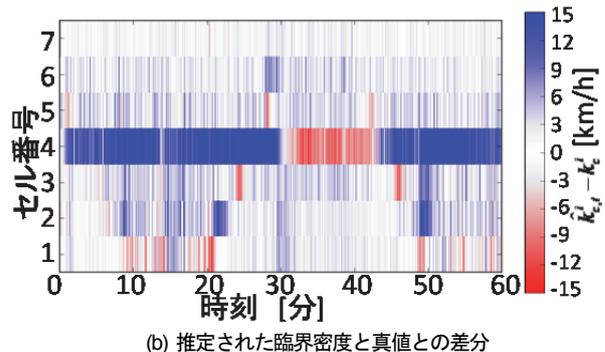
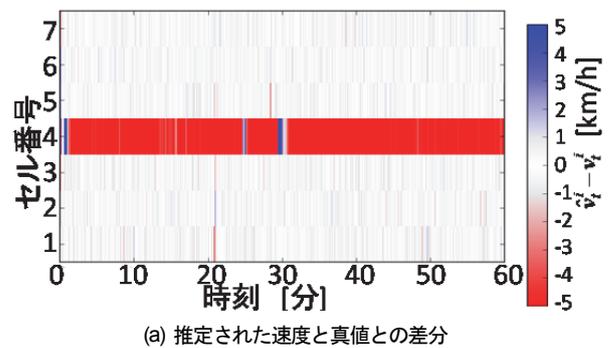


図-9 シナリオ4の推定結果

b) シナリオ2

## 5. おわりに

本研究はデータ同化手法の一つであるパーティクルフィルタをDual法に適用して用いて交通状態と交通流モデルパラメータを同時に推定するモデルを構築した。3章では、交通状態推定のためのシミュレーションモデル及びモデルパラメータの時系列変化モデル、観測モデルを示した。4章では、シミュレーションにより生成されたデータを用いて交通状態推定及びモデルパラメータ推定を行った。これにより、本手法の検証を行い、特徴を確認した。

4章の分析により、本手法の特徴が明らかになった。まず、非観測地点におけるモデルパラメータの推定は精度が悪いということである。これは、非観測地点において推定する変数の自由度が高いことが原因である。また、観測地点であってもモデルパラメータが推定できない場合がある。例えば、臨界密度を推定する際、自由流領域であると臨界密度の値が一意に決まらないことがわかった。この問題は、観測セルと非観測セルの従属関係を仮定し、観測変数に交通量を含めることで緩和できると考えられる。

謝辞：本研究はJSPS科研費挑戦的萌芽研究25630214「データ同化とシミュレーションによる交通状態のリアルタイム推定」の助成を受けたものです。

## 付録 CTM-vの定式化

付録では、CTM-v<sup>3)</sup>の定式化を示す。CTM-vは道路区間をセルに離散化し、時間ステップごとに隣り合うセル間を移動する車両台数を求め、交通状態を算出するマクロシミュレーションモデルである。CTM-vに用いる記号を示すと、シミュレーション全体で共通して用いる記号は、

$i$  : セルのID, セル $i$ に対して $i-1$ を上流,  $i+1$ を下流とする。

$l$  : セルの長さ[km]

$\Delta t$  : シミュレーションのタイムステップ

であり、セル毎のパラメータとして設定される記号は、

$k_c^i$  : 臨界密度[Veh/km]

$k_{\max}^i$  : 最大密度[Veh/km]

$v_{\max}^i$  : 最大速度[km/h]

$\omega_f^i$  : ショックウェーブ速度[km/h]  $\omega_f^i = \frac{v_{\max}^i k_c^i}{k_{\max}^i}$

$v_c^i$  : 臨界速度[km/h],  $v_c^i = v_{\max}^i \left(1 - \frac{k_c^i}{k_{\max}^i}\right)$

である。これらのパラメータを元に、シミュレーションによって決まる変数は、

$Q_{in,t-1}^i$  : 時刻 $t-1$ から $t$ のセル $i$ への流入量[Veh/h]

$Q_{out,t-1}^i$  : 時刻 $t-1$ から $t$ のセル $i+1$ への流出量[Veh/h]

$Q_{up,t-1}^{i-1}$  : 時刻 $t-1$ から $t$ のセル $i$ への最大流出量[Veh/h]

$Q_{dn,t-1}^i$  : 時刻 $t-1$ から $t$ のセル $i$ の可能流入量[Veh/h]

$v_t^i$  : 時刻 $t$ のセル $i$ の速度[km/h]

である。

上記の定義に示したように、CTM-vでは交通流の基本的関係であるVK関係、QK関係を規定するパラメータである $\omega_f^i$ と $v_c^i$ は、 $k_c^i$ 、 $v_{\max}^i$ 、 $k_{\max}^i$ に従属して決まる。このため、QK関係は三角形形状の関数とはならず、自由流速度は一定ではない。このことから、CTM-vは、速度を状態変数としたときに、密度を一意に決定することができる。一方で、自由流時に複数回のタイムステップでも次のセルに進めない車両による残留交通量（流入交通量が小さい場合に見かけ上セル内を後ろに進む車両）が生じるという問題を生じ、交通流の速度伝播の性質を必ずしも正確に表現できていないことに留意されたい。ただし、Workら<sup>4)</sup>に示されているように、流入交通量が十分に大きい場合には、この影響は相対的に小さい<sup>4)</sup>ため実用上の問題は小さい。

各時間ステップのセル $i$ の流入量は、

$$Q_{in,t-1}^i = \min(Q_{up,t-1}^{i-1}, Q_{dn,t-1}^i) \quad (a1)$$

$$Q_{up,t-1}^i = \begin{cases} v_c^{i-1} k_{\max}^{i-1} \left( \frac{1}{1 + v_c^{i-1} / \omega_f^{i-1}} \right) & \text{if } v_{t-1}^{i-1} \leq v_c^{i-1} \\ v_{t-1}^{i-1} k_{\max}^{i-1} \left( 1 - v_{t-1}^{i-1} / v_{\max}^{i-1} \right) & \text{otherwise} \end{cases} \quad (a2)$$

$$Q_{dn,t-1}^i = \begin{cases} v_{t-1}^i k_{\max}^i \left( \frac{1}{1 + v_{t-1}^i / \omega_f^i} \right) & \text{if } v_{t-1}^i \leq v_c^i \\ v_c^i k_{\max}^i \left( 1 - v_{t-1}^i / v_{\max}^i \right) & \text{otherwise} \end{cases} \quad (a3)$$

となる。流出量は、

$$Q_{out,t-1}^i = \min(Q_{up,t-1}^i, Q_{dn,t-1}^{i+1}) \quad (a4)$$

となる。これらの流入出力から、速度は、

$$v_t^i = V_i \left( V_i^{-1}(v_{t-1}^i) + \frac{\Delta t}{l} (Q_{in,t-1}^i, Q_{out,t-1}^i) \right) \quad (a5)$$

として求めることができる。ただし、 $V_i(k)$ と $V_i^{-1}(v)$ は、密度と速度の変換式であり、

$$V_i(k) = \begin{cases} v_{\max}^i + \frac{v_c^i - v_{\max}^i}{k_c^i} k & \text{if } k \leq k_c^i \\ \frac{v_c^i k_c^i (k - k_{\max}^i)}{k (k_c^i - k_{\max}^i)} & \text{otherwise} \end{cases} \quad (a6)$$

$$V_i^{-1}(v) = \begin{cases} \frac{k_c^i(v - v_{\max}^i)}{v_c^i - v_{\max}^i} & \text{if } v \geq v_c^i \\ \frac{k_c^i}{1 - v(k_c^i - k_{\max}^i)/v_c^i k_c^i} & \text{otherwise} \end{cases} \quad (\text{a7})$$

である。

## 参考文献

- 1) 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:国際交通安全学会誌, Vol. 31, pp. 15-23, 2006.
- 2) 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, 交通工学研究会, Vol. 47, No. 2, pp. 33-38, 2012.
- 3) Mihaylova, L., Boel, R. and Hegyi, A. : Freeway traffic estimation within particle filtering framework, Automatica, Vol. 43, No. 2, pp. 290–300, 2007.
- 4) Work, D. B., Blandin, S., Tossavainen, O. -P., Piccoli, B. and Bayen, A. : A traffic model for velocity data assimilation, Applied Mathematics Research eXpress, Vol. 1, No. 1, pp. 1-35, 2010.
- 5) 福田大輔, HONG Zihan, 石田東生：都市高速道路における交通状態推定問題ならびにセンサー配置問題に対するデータ同化アプローチ, 土木計画学研究・講演集, Vol.48, pp. 176, 2013.
- 6) Daganzo, C. F. : The cell transmission model: A dynamic representation of high way traffic consistent with the hydrodynamic theory, Transportation Research Part B: Methodological, Vol. 28, No. 4, pp. 269–287, 1994.
- 7) Papageorgiou, M., Blosseville, J.-M. and Hadj-Salem, H. : Macroscopic modelling of traffic flow on the Boulevard Peripherique in Paris, Transportation Research Part B: Methodological, Vol. 23, No. 1, pp. 29–47, 1989.
- 8) Papageorgiou, M., Blosseville, J.-M. and Hadj-Salem, H. : Modelling and real-time control of traffic flow on the southern part of Boulevard Peripherique in Paris: Part I: Modelling, Transportation Research Part A: General, Vol. 24, No. 5, pp.345–359, 1990.
- 9) Work, D.B., Tossavainen, O.-P., Blandin, S., Bayen, A.M., Iwuchukwu, T. and Tracton, K. : An ensemble Kalman filtering approach to highway traffic estimation using GPS enabled mobile devices, 47th IEEE Conference on Decision and Control, pp. 5062-5068, 2008.
- 10) Work, D.B., Tossavainen, O.-P., Jacobson, Q. and Bayen AM : Lagrangian sensing: traffic estimation with mobile devices, American Control Conference, pp. 1536–1543, 2009.
- 11) Allstrom, A., Gundlegard D., and Rydergren C. : Evaluation of travel time estimation based on LWR-v and CTM-v. A case study in Stockholm, in Intelligent Transportation Systems (ITSC), 2012 15th International IEEE Conference on, pp. 1644-1649, 2012.
- 12) Wang, Y., Papageorgiou, M., Messmer, A., Coppola, P., Tzimitsi, A. and Nuzzolo A. : An adaptive freeway traffic state estimator, Automatica, Vol. 45, No. 1, pp. 10–24, 2009.
- 13) 中西航, 布施孝志: ネットワーク上の人物移動推定のための観測モデルパラメータの適応的推定, 土木計画学研究・講演集, Vol. 50, CD-ROM, 2014.
- 14) Wan, E.A. and Nelson A.T. : Neural dual extended Kalman filtering: applications in speech enhancement and monaural blind signal separation, in Neural Networks for Signal Processing VII. Proceedings of the 1997 IEEE Workshop, pp. 466-475, 1997.
- 15) Olivier, L.E., Huang, B., and Craig, I.K. : Dual particle filters for state and parameter estimation with application to a run-of-mine ore mill, Journal of Process Control, Vol. 22, No. 4, pp. 710–717, 2012.

(2015. 4. 24 受付)

## JOINT ESTIMATION OF STATE AND MODEL PARAMETERS OF TRAFFIC BASED ON SPEED DATA

Naoya NARIOKA, Toru SEO, Takahiko KUSAKABE and Yasuo ASAKURA