

Link Transmission Model と移動体観測を 組み合わせた交通状態推定手法の開発と検証

文山 草¹・瀬尾 亨²・布施 孝志³

¹非会員 東京大学大学院修士課程 工学系研究科 社会基盤学専攻 (〒 113-8656 東京都文京区本郷 7-3-1)

E-mail: fumiymas-ut@g.ecc.u-tokyo.ac.jp

²正会員 東京工業大学環境・社会理工学院准教授 土木・環境工学系 (〒 152-8552 東京都目黒区大岡山 2-12-1)

E-mail: seo.t.aa@m.titech.ac.jp

³正会員 東京大学大学院教授 工学系研究科 社会基盤学専攻 (〒 113-8656 東京都文京区本郷 7-3-1)

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

交通状態推定とは、観測データから交通流の流率、密度、速度を推定する手法である。広域道路網の交通状態推定はデータの制約と推定の際の計算効率の 2 点で課題がある。移動体観測や、道路の端点での累積台数のみで交通状態を表す交通流モデルの Link Transmission Model (LTM) は、先述の課題に対する有望な手法である。しかし、移動体観測と LTM の状態変数である累積台数の対応関係は非自明であり、両者を組み合わせた交通状態推定は実現されていない。本研究では、プローブ軌跡データ及び少数の感知器データを入力とし、LTM に基づくデータ同化により道路網の交通状態を推定する手法を開発した。提案手法は数値実験でその有効性を検証したのち、実際の高速道路で得られたデータに対してもその挙動の合理性を確認した。

Key Words: traffic state estimation, data assimilation, probe vehicle, link transmission model

1. はじめに

交通状態 (交通流率、交通密度、速度) の高分解能での把握は交通の制御や計画のために有用である。現状では交通状態は主に車両感知器などの地上に設置された観測機器を用いて把握されている。しかし、こうした機器は設置箇所が限られており、それらのみに基づいた道路ネットワーク全体の交通状態の把握は難しい。一方、近年普及している ETC2.0 等を搭載したプローブカーからは広範囲に渡ってプローブデータを取得できるため、ネットワーク全体の交通状態の把握への活用が期待されている。

プローブカーを交通状態推定に用いる既往研究では、プローブデータの観測と交通流モデルの Cell Transmission Model (CTM)¹⁾²⁾ およびその亜種による予測とをデータ同化によって組み合わせ、観測データが不十分な箇所の交通状態推定を試みるアプローチが盛んに採用されている。³⁾⁴⁾⁵⁾⁶⁾⁷⁾しかし、CTM は標準的な交通流モデルである Kinematic Wave モデル⁸⁾⁹⁾¹⁰⁾を差分法によって離散化して近似計算する手法であり、リンクを多数の均一なセルに分割する必要があるため、大規模ネットワークの交通状態推定のためには計算効率や精度に難点がある。

近年提案された交通流モデルの Link Transmission

Model (LTM)¹¹⁾ は同じく Kinematic Wave モデルを計算する手法であるが、リンクを分割せず、リンク境界における累積台数のみを用いて正確に交通状態を計算できるため、大規模ネットワークの交通状態推定の際にも状態量の次元を小さく抑えられ、計算効率と精度に優れた手法である。しかし、プローブデータと LTM に基づく交通状態推定手法は著者らの知る限り提案されていない。その理由はいくつか考えられる。まず、LTM の状態変数である定点の累積台数と、広範囲に渡って車両毎に取得されるプローブデータの対応関係が自明ではない。プローブデータは交通流中の一部の車両から個別に得られるデータであり、プローブデータのみに基づいて定点における累積台数データを得られないためである。次に、交通状態推定の標準的な枠組みである逐次データ同化は、交通流モデルが 1 次のマルコフモデルであることを前提とするが、LTM はそれに該当しない。そのため、状態空間の次元を過度に大きくすることなしに LTM を逐次データ同化に組み込むためには工夫を要する。これらの課題を解決し、LTM とプローブデータの対応関係を定式化し、両者を適切に結びつけた交通状態推定手法を開発できれば、ネットワークを対象にした推定が精度良く、かつ効率的に可能になると期待される。

本研究は LTM と移動体観測を組み合わせた交通状態

推定手法の開発と検証を目的とする。2. では、LTM をシステムモデルとし、プローブカー軌跡と少数の感知器を観測データとする交通状態推定手法を、前述した課題を解決する形で定式化する。3. では、提案手法をシミュレーションデータに適用する双子実験により、その性質を検証する。4. では、提案手法を実際の高速道路で収集された実データに適用し、その現実的な状況下での性質を検証する。

2. 方法

提案手法は状態空間モデルの枠組みに即し、システムモデルを LTM に基づき定式化する。また、観測モデルは少量の感知器データとプローブデータをもとに、累積台数の推定を行うモデルを定式化する。データ同化の手法には Ensemble Kalman Filter (EnKF)¹²⁾ を用いる。

(1) データ同化手法

データ同化の手法には EnKF を用いる。EnKF を用いる理由は、システムモデルに非線形のモデルを用いることができ、加えて類似手法であるパーティクルフィルタに比べて大きな次元の状態ベクトルに対しても、計算の精度と安定性が良く、かつ計算量が小さいためである。EnKF では、状態空間モデルは以下のように定義される。

$$\mathbf{x}_t = f_t(\mathbf{x}_{t-1}, \mathbf{v}_t) \quad (1)$$

$$\mathbf{y}_t = H_t \mathbf{x}_t + \mathbf{w}_t \quad (2)$$

ここに、 f_t はシステムモデル、 \mathbf{x}_t はタイムステップ t におけるシステムの状態を表す状態ベクトル、 \mathbf{v}_t は任意の分布に従うシステムノイズであり、 \mathbf{y}_t はタイムステップ t における観測データを列挙した観測ベクトル、 H_t は観測行列、 \mathbf{w}_t は平均が 0、分散共分散行列が R_t の正規分布に従う観測ノイズである。

EnKF では、状態ベクトルの確率分布を N 個のサンプルの集合であるアンサンブルを用いて近似する。そして、このアンサンブルを状態空間モデルに沿って更新し、最も確からしいフィルタ分布を得る。以下に、樋口ら¹³⁾ を参考に、EnKF の計算の手続きをまとめる。

1. 初期状態を表す N 個のサンプルからなるアンサンブル $\{\mathbf{x}_{0|0}^{(i)}\}_{i=1}^N$ を生成し、タイムステップ $t = 1$ とする。ここに、 $\{\mathbf{x}_{0|0}^{(i)}\}$ はシステムモデルの状態ベクトルを表す i 番目のサンプルである。
2. $t = T$ に達するまで以下のステップを繰り返す。
 - (a) システムノイズのアンサンブル $\{\mathbf{v}_t^{(i)}\}_{i=1}^N$ を発生させる。
 - (b) 各 i について、 $\mathbf{x}_{t|t-1}^{(i)} = f_t(\mathbf{x}_{t-1|t-1}^{(i)}, \mathbf{v}_t^{(i)})$ を計算する。

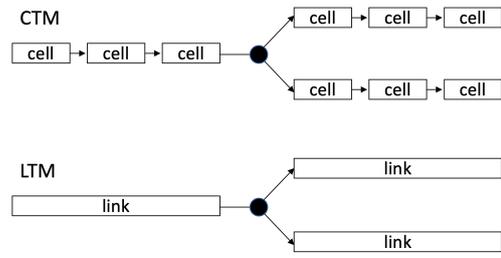


図-1: CTM と LTM の計算手法の模式図

- (c) 観測ノイズのアンサンブル $\{\mathbf{w}_t^{(i)}\}_{i=1}^N$ を発生させる。
- (d) 分散共分散行列 $\hat{V}_{t|t-1}, \hat{R}_t$ 及びカルマンゲイン \hat{K}_t を以下のように計算する。

$$\tilde{\mathbf{x}}_{t|t-1}^{(i)} = \mathbf{x}_{t|t-1}^{(i)} - \frac{1}{N} \sum_{j=1}^N \mathbf{x}_{t|t-1}^{(j)}$$

$$\hat{V}_{t|t-1} = \frac{1}{N-1} \sum_{j=1}^N \tilde{\mathbf{x}}_{t|t-1}^{(j)} \tilde{\mathbf{x}}_{t|t-1}^{(j) \prime}$$

$$\tilde{\mathbf{w}}_t^{(i)} = \mathbf{w}_t^{(i)} - \frac{1}{N} \sum_{j=1}^N \mathbf{w}_t^{(j)}$$

$$\hat{R}_t = \frac{1}{N-1} \sum_{j=1}^N \tilde{\mathbf{w}}_t^{(j)} \tilde{\mathbf{w}}_t^{(j) \prime}$$

$$\hat{K}_t = \hat{V}_{t|t-1} H_t' (H_t \hat{V}_{t|t-1} H_t' + \hat{R}_t)^{-1}$$

- (e) 各 i について $\mathbf{x}_{t|t}^{(i)} = \mathbf{x}_{t|t-1}^{(i)} + \hat{K}_t (\mathbf{y}_t + \tilde{\mathbf{w}}_t^{(i)} - H_t \mathbf{x}_{t|t-1}^{(i)})$ を計算しフィルタアンサンブル $\{\mathbf{x}_{t|t}^{(i)}\}_{i=1}^N$ を得る。
- (f) タイムステップ t を $t+1$ に更新する。
ここに、下付き文字の $t|t-1$ は時刻 t における事前分布を、 $t|t$ は時刻 t における事後分布を表す。

(2) システムモデル

本手法では交通流を LTM によって表現し、交通状態推定を行う。LTM は CTM と同じく LWR モデル⁸⁾⁹⁾ の数値解法の一つである。しかし、LTM では交通流保存則が成立し、Fundamental Diagram (FD) 変数が一定とみなせる区間を一つのリンクとして扱い、リンクの境界地点の累積台数を交通流を表す指標として用いる。リンクの境界地点の値のみを扱うため、リンクをセルに分割する必要がなく、計算量がリンク長に依存しない。このため、計算量が CTM に比べ小さいという特徴がある。図-1 は CTM と LTM の計算手法の違いを模式的に示したものである。LTM では交通流をリンク境界の累積台数で表現するので、これが本手法の主な状態変数となる。

また、本手法ではノードモデルに Daganzo²⁾ のモデルを用いる。このモデルでは、ネットワークを道路が 1 本から 2 本に分岐する Diverge ノードと、2 本から 1 本に合流する Merge ノードの 2 種類の組み合わせで表現する。

このモデルに基づくと、Diverge ノードでの分岐先の比率を表現する分岐率 $\beta_d(t)$ も時間変化する変数とみなせる。したがって、本手法での状態ベクトルは以下のように定義できる。

$$\mathbf{x}_t = (\dots N(x_a^0, t) \dots N(x_a^L, t) \dots \beta_d(t) \dots) \quad (3)$$

ここに、 $N(x, t)$ は位置 x の時刻 t における車両の累積台数、 x_a^0 はリンク a の上流境界の位置、 x_a^L はリンク a の下流境界の位置、 $\beta_d(t)$ は時刻 t における Diverge ノード d での分岐率である。

以下に、状態ベクトルの要素である累積台数と分岐率それぞれにシステムモデルを構築し、統合する。

a) 累積台数のシステムモデル

累積台数のシステムモデルは、LTM における更新式にいくつかの修正を加えたものとする。LTM における累積台数の更新式は以下で与えられる。

$$N(x_i^L, t) = N(x_i^L, t - \Delta t) + \sum_{j \in J_n} G_{ij} \quad (4)$$

$$N(x_j^0, t) = N(x_j^0, t - \Delta t) + \sum_{i \in I_n} G_{ij} \quad (5)$$

ここに、 Δt はタイムステップ (計算時間) 幅、 G_{ij} は時刻 $t - \Delta t$ のリンク i の sending flow $S_i(t - \Delta t)$ とリンク j の receiving flow $R_j(t - \Delta t)$ 、及び需要交通量 D によって定まる、実際にリンク間を移動する交通量である。

また、LTM では sending flow と receiving flow は以下のように与えられる。

$$S_i(t - \Delta t) = \min\left(\left(N(x_i^0, t - \frac{L_i}{u_i}) - N(x_i^L, t - \Delta t)\right), q_{\max, i} \Delta t\right) \quad (6)$$

$$R_j(t - \Delta t) = \min\left(\left(N(x_j^L, t - \frac{L_j}{w_j}) + \kappa L_j - N(x_j^0, t - \Delta t)\right), q_{\max, j} \Delta t\right) \quad (7)$$

ここに、 L_a はリンク a の長さ、 u_a はリンク a の自由流速度、 w_a はリンク a の渋滞波速度、 $q_{\max, a}$ はリンク a の最大流率、 κ_a はリンク a の渋滞密度である。

ここで、一般に $N(x_i^0, t - \frac{L_i}{u_i})$ と $N(x_j^L, t - \frac{L_j}{w_j})$ の少なくともいずれかは時刻 $t - \Delta t$ より前の時刻の状態変数であり、この式は EnKF の満たすべき条件であるマルコフ性を満たさない。

本手法では、 $N(x_i^0, t - \frac{L_i}{u_i})$ と $N(x_j^L, t - \frac{L_j}{w_j})$ は状態ベクトル中の状態変数ではなく、システムモデルを構成す

るパラメータベクトル θ_t の要素であるとみなす。このモデルでは、他に FD 変数や優先率もこのパラメータベクトル θ_t の要素に含まれる。ところで、システムモデルの計算の際に、時刻 $t - \Delta t$ より前の時刻 $t - k\Delta t$ までの状態ベクトルが必要な場合は、その時刻までの状態ベクトルをすべて含んだ新たな状態ベクトル $\mathbf{x}_{T-1} = (x_{t-1}, x_{t-2}, \dots, x_{t-k})$ を構成し、マルコフ性を満たす手法が用いられることがある¹³⁾。しかし、こうした手法は新たな状態ベクトル \mathbf{x}_{T-1} の次元が増加し、計算コストが増大するという欠点がある。提案手法はネットワーク上の過去の時点の累積台数を状態ベクトルに加えず計算を行う。この方法では過去の時点の累積台数を更新できないため、その精度を向上できないという短所がある一方で、状態ベクトルの次元を小さくし、計算コストを抑えられるという長所もある。提案手法では効率の観点から、この方法を用いた。

さらに、需要交通量 D は時刻 $t - \Delta t$ から時刻 t までの間にネットワークに流入しようとする車両の台数である。一般に時刻 $t - \Delta t$ における情報から、時刻 t までの需要交通量は正確に与えられないため、本手法では需要交通量 D はシステムノイズ \mathbf{v}_t により定まる確率分布 $q(\mathbf{v}_t)$ により与えられるとする。このとき、確率分布は推定する交通流の性質に基づいて、任意に定められる。以上により、状態ベクトル \mathbf{x}_{t-1} に含まれる状態変数とシステムノイズ、及びシステムパラメータのみで時刻 t における累積台数の計算が可能となる。この性質は EnKF が満たすべき条件のマルコフ性を満たす。

このようにして求めた sending flow $S_i(t - \Delta t)$ とリンク j の receiving flow $R_j(t - \Delta t)$ をもとに、ノードモデルで実際に移動する交通量 G_{ij} を求める。

Diverge ノードでは、リンク i からリンク j 、 j' へと移動する交通量、 G_{ij} 、 $G_{ij'}$ は分岐率 β_d を用いて、それぞれ以下のように与えられる。

$$G_{ij} = \beta_{d_{ij}} \min\left(S_i, R_j / \beta_{d_{ij}}, R_{j'} / \beta_{d_{ij'}}\right) \quad (8)$$

$$G_{ij'} = \beta_{d_{ij'}} \min\left(S_i, R_j / \beta_{d_{ij}}, R_{j'} / \beta_{d_{ij'}}\right) \quad (9)$$

ただし、 $\beta_{d_{ij}} + \beta_{d_{ij'}} = 1$ である。

なお、本論文では注釈のない限り $\beta_d = \beta_{d_{ij}}$ とする。 $\beta_{d_{ij'}} = 1 - \beta_d$ の関係から、 β_d のみでも以上の関係を表現できる。

Merge ノードでは、リンク i 、 i' からリンク j へと移動する交通量、 G_{ij} 、 $G_{i'j}$ は優先率 p_m を用いて、それぞれ以下のように与えられる。

$$G_{ij} = \text{median}(S_i, R_j - S_{i'}, p_{m_{ij}} R_j) \quad (10)$$

$$G_{i'j} = \text{median}(S_{i'}, R_j - S_i, p_{m_{i'j}} R_j) \quad (11)$$

ただし、 $p_{m_{ij}} + p_{m_{i'j}} = 1$ である。なお、本論文では注釈のない限り $p_m = p_{m_{ij}}$ とする。 $p_{m_{i'j}} = 1 - p_m$ の関

係から, p_m のみでも以上の関係を表現できる.

b) 分岐率のシステムモデル

分岐率は LTM の更新式に含まれていないため, 新たにシステムモデルを構築する. 分岐率も本研究で用いる観測データからは, 時刻 $t - \Delta t$ における情報から時刻 t における値を求めることは難しい. しかしながら, 分岐率は時間経過に伴い緩やかに変化することが予想されるため, システムモデルはランダムウォークであるとし, 以下のように定式化する.

$$\beta_d(t) = \beta_d(t - \Delta t) + v_{\text{div}}(t) \quad (12)$$

ここに, $v_{\text{div}}(t)$ は分岐率のシステムノイズである. 以上の累積台数と分岐率の更新式をまとめたものが, 本手法のシステムモデルである.

(3) 観測モデルの構築

本手法での観測ベクトルは以下のように定義する.

$$\mathbf{y}_t = \begin{pmatrix} \vdots \\ \tilde{N}(x_a^0, t) \\ \vdots \\ \tilde{N}(x_a^L, t) \\ \vdots \\ \hat{N}(x_a^0, T(x_a^0, I(x_a^L, t))) \\ \vdots \\ \beta_d^{\text{all}}(t) \\ \vdots \end{pmatrix} \quad (13)$$

ここに, $\tilde{N}(x, t)$ は感知器による位置 x の時刻 t における累積台数の推定値であり, $\hat{N}(x_a^0, T(x_a^0, I(x_a^L, t)))$ は位置 x_a^L を時刻 t に通過した車両 $I(x_a^L, t)$ が, 過去に位置 x_a^0 を通過した時刻 $T(x_a^0, I(x_a^L, t))$ における累積台数の推定値である. また, $\beta_d^{\text{all}}(t)$ はプローブデータによる全車両の分岐率の推定値である.

観測モデルは観測データの取得方法や推定する状態量ごとに部分的なモデルを構築し, それらを統合して構築する. 部分的なモデルには, 感知器による累積台数の推定モデル, プローブデータによる累積台数の推定モデル, プローブデータによる分岐率の推定モデルがある. 以下に各部分モデルについて述べ, 最後にそれらの統合方法を述べる.

a) 感知器による累積台数の推定モデル

このモデルでは感知器を用いて時刻 t におけるリンク境界の累積台数を推定する. 累積台数の推定には感知器が観測した時刻 $t - \Delta t$ から時刻 t における交通量 Δn を用いる. モデルの構築に際し, 推定を行うネットワークに, 「感知器が存在するならば, その感知器は必ず

リンクの境界上に位置する.」という仮定をおく. LTM では, リンクは任意に分割可能なため, この仮定をおいても一般性を損なわない. この仮定により, 感知器が観測を行う位置, 時刻の累積台数を表す状態変数が必ず状態ベクトル中に存在することが保証される. したがって, 交通量 Δn と累積台数の関係は以下のように定式化できる.

$$\Delta n = N(x_a^l, t) - N(x_a^l, t - \Delta t) + \omega_{\text{veh}}(x_a^l, t) \quad (l = 0, L) \quad (14)$$

ここに, $\omega_{\text{veh}}(x_a^l, t)$ は感知器による交通量の観測に伴う誤差であり, その分散は σ_{veh}^2 である. 時刻 $t - \Delta t$ は時刻 t より前の時刻であるから, この時刻の位置 x_a^l における累積台数の推定は既知である. この推定値 $\hat{N}(x_a^l, t - \Delta t)$ と Δn の和を感知器による累積台数の推定値 $\tilde{N}(x_a^l, t)$ とすれば, 感知器の観測モデルは以下のように定式化できる.

$$\Delta n = N(x_a^l, t) - N(x_a^l, t - \Delta t) + \omega_{\text{veh}}(x_a^l, t)$$

$$N(x_a^l, t - \Delta t) + \Delta n = N(x_a^l, t) + \omega_{\text{veh}}(x_a^l, t)$$

$$\tilde{N}(x_a^l, t - \Delta t) + \Delta n = N(x_a^l, t) + \omega_{\text{veh}}(x_a^l, t) + \omega_{\text{sen}}(x_a^l, t)$$

$$\tilde{N}(x_a^l, t) = N(x_a^l, t) + \omega_{\text{veh}}(x_a^l, t) + \omega_{\text{sen}}(x_a^l, t) \quad (15)$$

ここに, $\omega_{\text{sen}}(x_a^l, t)$ は $\tilde{N}(x_a^l, t - \Delta t)$ の推定に基づく誤差であり, この定義からその分散 σ_{sen}^2 は推定値の分散である.

b) プローブデータによる累積台数の推定モデル

このモデルは, プローブデータによって下流境界における累積台数を推定する. 累積台数の推定には, 同一車両軌跡上では累積台数は変化しないという性質を用いる. LTM ではリンク内で車両の前後関係が変化しないという First In First Out (FIFO) の仮定をおいている. そのため, リンク a の下流境界位置 x_a^L を累積台数 n 台目に通過した車両番号 i の車両は, リンク a の上流境界位置 x_a^0 も累積台数 n 台目に通過したと考えられる.

本研究で想定するプローブデータは車両ごとの位置情報と時刻を記録したデータであり, このデータからあるプローブカーがリンクの境界位置を通過した時刻が得られる. したがって, FIFO が厳密に成立しプローブデータに誤差がないと仮定すれば, FIFO の条件とプローブデータを用いて, プローブカーが位置 x_a^L を通過した時刻の位置 x_a^L における累積台数と, 位置 x_a^0 を通過した時刻の位置 x_a^0 における累積台数が等しいという条件が得られる. この条件は以下のように定式化できる.

$$\begin{aligned} N(x_a^L, t) &= N(x_a^L, T(x_a^L, i)) \\ &= N(x_a^0, T(x_a^0, i)) \\ &= N(x_a^0, T(x_a^0, I(x_a^L, t))) \end{aligned} \quad (16)$$

$T(x, i)$ は位置 x を車両番号 i の車両が通過する時刻を表す関数であり、 $I(x, t)$ は位置 x を時刻 t に通過する車両の車両番号を表す関数である。

ここで、時刻 $T(x_a^0, I(x_a^L, t))$ は時刻 t より前の時刻であるから、この時刻の位置 x_a^0 における累積台数の推定値は既知である。その推定値と状態変数との関係は以下のように定式化できる。

$$\hat{N}(x_a^0, T(x_a^0, I(x_a^L, t))) = N(x_a^0, T(x_a^0, I(x_a^L, t))) + \omega_{\text{probe}}(x_a^L, t) \quad (17)$$

ここに、 $\omega_{\text{probe}}(x_a^L, t)$ は推定値 $\hat{N}(x_a^0, T(x_a^0, I(x_a^L, t)))$ の推定に基づく誤差であり、この定義からその分散 σ_{probe}^2 は推定値の分散である。式 (16)、式 (17) より上流境界と下流境界の累積台数の間には以下の関係が成り立つ。

$$\begin{aligned} \hat{N}(x_a^0, T(x_a^0, I(x_a^L, t))) \\ = N(x_a^0, T(x_a^0, I(x_a^L, t))) + \omega_{\text{probe}}(x_a^L, t) \quad (18) \\ = N(x_a^L, t) + \omega_{\text{probe}}(x_a^L, t) \end{aligned}$$

ただし、実際の交通流は FIFO の条件を満たさないために、この関係には誤差が生じると考えられる。この誤差を観測ノイズとして考慮すると、観測モデルは以下のように定式化できる。

$$\begin{aligned} \hat{N}(x_a^0, T(x_a^0, I(x_a^L, t))) \\ = N(x_a^L, t) + \omega_{\text{probe}}(x_a^L, t) + \omega_{\text{fifo}}(x_a^L, t) \quad (19) \end{aligned}$$

ここに、 $\omega_{\text{fifo}}(x_a^L, t)$ は実際の交通流が FIFO の条件に従わないことで生じる観測ノイズであり、その分散は σ_{fifo}^2 である。

c) プローブデータによる分岐率の推定モデル

このモデルでは Diverge ノードにおける分岐率を推定する。推定にはプローブ軌跡データに基づいて求めた時刻 t までの一定時間帯における、ある Diverge ノード d でのプローブカーのみの分岐率 $\beta_d^{\text{probe}}(t)$ を用いる。瀬尾・日下部⁷⁾ はプローブカーが全車両からランダムに抽出されている場合、全車両の分岐率 $\beta_d^{\text{all}}(t)$ は以下のように近似できると定式化している。

$$\beta_d^{\text{all}}(t) \sim \mathcal{N}(\beta_d^{\text{probe}}(t), \beta_d^{\text{probe}}(t) (1 - \beta_d^{\text{probe}}(t)) / \gamma_d(t)) \quad (20)$$

ここに、 $\gamma_d(t)$ は分岐率を計算する時間帯にそのノードを通過したプローブカーの台数であり、 $\mathcal{N}(\mu, \sigma^2)$ は平均 μ 、分散 σ^2 の正規分布を表す。以上の式を用いて観測データから推定できる全車両の分岐率 β_d^{all} を、状態ベクトル中の対応するノードの分岐率を表す状態変数と対応させると考えると、分岐率の観測モデルは以下のように定式化できる。

$$\beta_d(t) = \beta_d^{\text{all}}(t) + \omega_\beta(t) \quad (21)$$

ここに、 $\omega_\beta(t)$ は分岐率の推定誤差であり、定義からその分散 σ_β^2 は $\beta_d^{\text{probe}}(t) (1 - \beta_d^{\text{probe}}(t)) / \gamma_d(t)$ である。

d) 観測モデルの統合

以上の部分モデルを統合し、一つの観測モデルを構築する。部分モデルはいずれも、

$$(\text{観測に基づく状態量}) = (\text{状態変数}) + (\text{観測ノイズ}) \quad (22)$$

の形をしているので、部分モデルの対応する項をベクトルとして統合すると、以下のように一つの観測モデルを構築できる。

$$\mathbf{y}_t = \mathbf{H}_t \mathbf{x}_t + \mathbf{w}_t \quad (23)$$

ここに、 \mathbf{H}_t は観測行列であり、 \mathbf{H}_t の (i, j) 成分 h_{ij} は、状態ベクトル \mathbf{x}_t の j 番目の状態に対応する値が観測ベクトル \mathbf{y}_t の i 番目に存在するときのみ 1 を、そうでない場合は 0 を取る変数である。また、観測ノイズ \mathbf{w}_t の分散共分散行列 \mathbf{R}_t は、各観測状態量の観測ノイズの相関は無視できるとし、各観測状態量に対応する対角成分に観測ノイズの分散を配置したものとする。

(4) 提案手法の考察

本節では提案手法について、その定義から予想される定性的な特徴について考察する。

まず、前述した通り、LTM のリンク毎の状態変数はリンク上流端と下流端の累積台数のみであり、CTM と比較し圧倒的に少数である。そのため、本手法の EnKF のモンテカルロ近似の計算効率性は CTM に基づく交通状態推定手法と比べて非常に良いと期待される。また、LTM は Kinematic Wave モデルの厳密解を計算するため、CTM よりも高精度であり、この点も交通状態推定手法として優れていると考えられる。

さらに、CTM に基づく交通状態推定手法は一般に離散的なプローブカー軌跡は扱えず、集計的な平均速度等に変換して用いるため、情報の損失が避けられない。提案手法は離散的なプローブカー軌跡を直接扱うため、リンク端レベルでは精度の高い推定が期待できる。一方、提案手法はリンク内部のプローブカー軌跡は無視する。そのため、リンク内部で実際の FD が変化する場合や、リアルタイム推定の場合（すなわち、リンク端に到達しないプローブデータを扱う必要がある場合）には問題が生じうる。

次に、個別の観測モデルについて述べる。感知器による累積台数の推定を行うモデルは、交通量の観測を介して、設置箇所の累積台数を他の地点の累積台数の情報に頼ることなく、直接推定できる。したがって、感知器が設置された地点では常に精度良く累積台数が推定可能であると考えられる。また、リンクの上流境界、下流境界のどちらか一方にしか感知器がない場合でも、片方の累積台数を精度良く推定できれば、LTM の仮定する交通量保存則に従って、もう片方の境界の累積台

数の推定精度もある程度は向上することが予想される。

また、プローブデータによる累積台数の推定を行うモデルは、プローブデータに含まれる通過時間の関係を介して、上流境界の累積台数を用いて、下流境界の累積台数を間接的に推定する。プローブカーがあるリンクの通過に要する時間はそのリンクの FD 変数を反映した値である。したがって、プローブカーの観測によって、実際の交通流の FD 変数に基づいて上流境界と下流境界の累積台数の関係を補正できるため、実際の交通流の FD 変数とシステムモデルの FD 変数との差によって生じる推定の誤差を補正できると考えられる。観測可能なプローブカーの台数が増えるほど、多くの時刻で累積台数の関係を補正できるため、精度が良くなると予想できる。加えて、上流境界に感知器がある場合は、感知器の観測モデルにより精度良く推定された累積台数の値を、下流境界に反映できるため、特に精度が良くなるとも予想できる。

最後に、分岐率の観測モデルは、直近の一定時間帯におけるプローブ軌跡データから分岐率を推定する。そのため、交通流中のプローブカーの割合が極端に低い、もしくはプローブカーの混入状況に偏りがある場合、プローブカーがほとんど通過しない時間帯の分岐率を正しく推定できないという限界があると考えられる。

3. シミュレーションによる検証

本章では、提案手法のシミュレーション実験による検証を行う。検証の目的は、本手法の推定精度がプローブ率や感知器の設置数に応じてどのように変化するかや、その推定精度を定量的に明らかにするためである。

検証には双子実験と呼ばれる手法を用いる。双子実験とはデータ同化の有効性を判断するための実験手法であり、その手順は次の通りである¹⁴⁾。まず、最初にモデルにある条件を与えて計算を行い、その結果を真値と仮定する。次に、モデルに与える条件の一部、または全部を変更して計算を行い、その結果をシミュレーション値とする。このシミュレーション値に、真値に誤差を加えて生成した観測値を同化させ、同化の結果が真値に近づいているかによって、手法の有効性を判断する。以下に、提案手法の双子実験の具体的な設定を述べる。

(1) シミュレーション設定

実験では図-2 に示すネットワークのうち、link0 から link3 の 4 つのリンクを対象に推定を行う。4 つのリンクはいずれも長さ 1km で、同じ平均交通容量を持つとする。link3 の下流には他のリンクの半分の平均交通容量を持つ仮想リンクを接続し、link3 とこのリンクをつ

なぐノードをボトルネックとする。また、各リンクの境界地点を point と名付ける。

実験に用いる真値はシステムモデルに確定的な初期条件と需要交通量を与えて生成する。初期条件はすべての point における累積台数を 0 台、Diverge ノードにおける分岐率を 0.5 とし、需要交通量は 2 段階の適当なピークを持つとする。

システムモデルのタイムステップ幅 Δt は 50 秒、システムパラメータは FD 変数が $u = 60\text{km}$, $w = 20\text{km}$, $\kappa = 200\text{veh/km}$ を平均とし、タイムステップ毎に平均から $\pm 10\%$ の値の範囲内で一様分布に従って変化するとする。分岐率は 0 から 1 の範囲でランダムウォークするとし、システムノイズ $v_{\text{div}}(t)$ は平均 0、標準偏差 0.01 の正規分布に従うとする。また、優先率は 0.5 で一定とする。

こうして生成した各 point の累積台数の真値をもとに、シミュレーションで使用する感知器データとプローブデータを生成する。

感知器データは真値の累積台数の 1 タイムステップ間の差分から求めた交通量 Δn_{true} に誤差を加えて生成する。具体的には、感知器が観測する交通量には平均 0、標準偏差 $\Delta n_{\text{true}} \times 10\%$ の正規分布に従う誤差が加わるとする。

プローブデータはリンクの上流境界と下流境界の累積台数を用いて生成する。リンク内の交通流が FIFO の条件に従う場合は、そのリンクの上流境界を N 番目に通過した車両 i は下流境界も N 番目に通過する。しかし、現実の交通流には追い抜きや追い越しが含まれ、FIFO の条件には厳密に従わないために、この関係には誤差が生じる。プローブデータの生成の際はその誤差を考慮し、リンクの上流境界を $N + \Delta N$ 番目に通過した車両 i が下流境界を N 番目に通過するとして、それぞれの境界の通過時間をプローブデータとして記録する。 ΔN は追い抜き、追い越しに伴う車両の通過順の変化を表し、リンク内の交通量に伴って変化する量である。具体的には、 ΔN は車両 i がリンクの上流境界 x を通過したタイムステップの交通量 Δn_{fifo} をもとに、平均 0、標準偏差 $\Delta n_{\text{fifo}} \times 10\%$ の正規分布に従うとする。なお、Diverge ノードにおけるプローブカーの経路選択は、プローブカーが Diverge ノードに到達した時刻の分岐率に従うとする。こうして生成したデータは厳密にネットワーク内での単一車両の軌跡を表現したものではないが、本手法の観測モデルでは同一リンクの上流境界と下流境界におけるプローブカーの通過時刻の関係が重要であり、検証にはこのデータで問題はない。

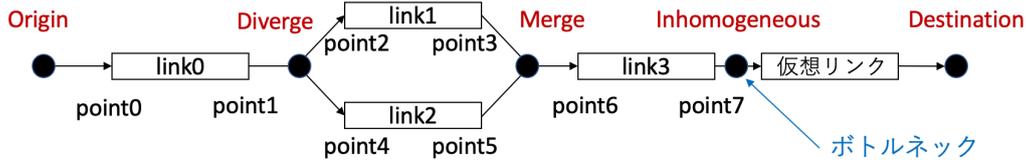


図-2: 推定を行うネットワーク

(2) 検証項目

シミュレーションのシステムモデルには、真値の生成に用いたシステムモデルのうち、システムノイズで与えられる需要交通量を確率的に変化させたモデルを用いる。具体的には、需要交通量は0とlink0の最大流率との間で一様に变化する流率に従うとする。

また、観測モデルの観測ノイズは次のように与える。 σ_{veh} は感知器が観測した台数の10%とする。 σ_{fifo} は、プローブカーが上流境界を通過したタイムステップの推定交通量の10%とする。 σ_{sen} , σ_{probe} 及び σ_{β} については2.の定義通りとする。なお、分岐率は直近20分間のプローブデータから推定する。

EnKFのアンサンブルメンバ数は100とし、初期条件は、累積台数は平均5、標準偏差1の正規分布に、分岐率は平均0.5、標準偏差0.1の正規分布に従って生成する。累積台数の平均値が真値より大きいのは、累積台数の初期条件が負にならないようにするためである。

また、EnKFにおけるフィルタの後の値が不合理な値をとった場合は、推定を安定に続けるため、補正を加える。フィルタ後の累積台数に基づく流率が負になった場合はフィルタ後の流率が0に、最大流率を超えた場合は最大流率になるように累積台数を補正し、フィルタ後の分岐率が1を超えた場合は分岐率を1に、分岐率が0を下回った場合は分岐率を0に補正する。

この実験では以上の条件のもと、表-1のシナリオでネットワーク上のプローブ率と感知器の設置箇所数を変化させ、提案手法を用いた推定結果を検証する。まず、シナリオ1からシナリオ4では、提案手法の考察で予想された、感知器の観測モデルによる感知器設置箇所の推定精度の向上が、ネットワークの上流と下流にどのように波及するかを検証するために、point2のみに感知器を設置する。そして、ネットワーク全体の推定精度が、プローブ率の向上によりどの程度改善されるかを検証するために、プローブ率を1%から20%まで変化させる。

次に、シナリオ5とシナリオ6では感知器の設置箇所数の変化がどの程度推定精度の向上に寄与するかを検証するために、プローブ率を一定にしたまま、感知

表-1: 各シナリオとその設定

シナリオ	プローブ率	感知器の設置箇所
1	1%	point 2
2	5%	point 2
3	10%	point 2
4	20%	point 2
5	10%	point 0, 2
6	10%	point 0, 2, 4, 6

器の設置箇所を増やす。この2つのシナリオとシナリオ3とを合わせて比較を行い、ネットワーク上の感知器の数と、ネットワークの各pointにおける精度向上の程度を検証する。

なお、プローブ率の定義は全車両中に占めるプローブカーの割合であり、本実験ではネットワークに流入した車両がプローブ率と同じ確率でプローブカーと判断されるとする。

検証の指標には各pointにおける流率 q を用いる。位置 x 、時刻 t における流率 $q(x, t)$ は以下のように求められる。

$$q(x, t) = \frac{N(x, t) - N(x, t - \Delta t)}{\Delta t} \quad (24)$$

本手法の状態変数である累積台数を直接指標として用いないのは、累積台数は交通量を積分した量であり、初期状態やわずかな外れ値による誤差を蓄積してしまうことから、精度評価に不相当と考えられるためである。

精度評価の指標は Mean Absolute Percentage Error (MAPE) と Root Mean Square Error (RMSE) を用いる。これらの指標はそれぞれ以下のように定義される。

$$\text{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{q_i - \hat{q}_i}{q_i} \right| \quad (25)$$

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (q_i - \hat{q}_i)^2} \quad (26)$$

ここに、 q_i は流率の真値、 \hat{q}_i は流率の推定値、 N は推定値の総数である。

推定は 240 分間に渡って行うとし、推定の際の初期状態の影響を除くために、精度評価は推定開始から 60 分後以降の値を用いて行う。このように初期の推定結果を用いずに精度評価を行うことは、交通状態推定では一般的であり¹⁵⁾、実際の交通状態推定でも、推定は長時間に渡っての実施が想定され、初期状態の影響は無視できると考えられるため、交通状態推定手法の評価方法としては妥当であるといえる。

実験は乱数のシード値を変化させ、各シナリオについて 11 回ずつ行う。

(3) 結果と考察

表-2、表-3 は各シナリオにおける精度評価指標の中央値の一覧である。シナリオ間の比較に中央値を用いた理由は、MAPE の外れ値の影響を抑えるためである。MAPE の定義上、渋滞時に流率の真値が 0 に近い値を取る場合の誤差が極端に大きく見積もられ、外れ値を取ることがある。

結果を比較すると、2. での考察通り、プローブ率が大きいほど推定精度が高く、同様に推定に使用する感知器が多くなるほど推定精度が高くなっている。

プローブ率の変化と精度評価指標との関係を表した表-2 をみると、シナリオ 1 の精度評価指標が他のシナリオに比べ顕著に大きい。これも考察でも述べたとおり、分岐率の推定に使用可能なプローブカーが少なく、分岐率を正しく推定できていないためだと考えられる。また、シナリオ 2 からシナリオ 4 を比較すると、プローブ率が上がるにつれ、推定精度の改善幅が小さくなる様子が読み取れる。特に、シナリオ 3 とシナリオ 4 を比較すると、シナリオ 4 のほうが MAPE の値はわずかに改善しているものの、RMSE の値はわずかに悪化しており、実質的にこの 2 つのシナリオにおける推定精度にはほとんど差がないと考えられる。

表-2 と表-3 を総合すると、本手法ではプローブ率が 10% ほどあれば、ネットワークを構成するリンクの半数ほどにしか感知器がなくとも、比較的良好な推定精度を得られるといえる。

次に、具体的な推定の様子について、シナリオ 3 を例に、流率の散布図と密度の時空間図を用いて比較する。

流率の散布図 (図-3) は横軸が真値、縦軸が推定値であり、よく観測された結果ほど濃くプロットされる。推定結果は過大推定であれば対角線の上側に、真値と等しい値であれば対角線上に、過小推定であれば対角線の下側にプロットされる。まず、散布図では、同じ link1 上に位置する point 2 と 3 に注目すると、感知器の下流地点でも推定結果が対角線上に分布し、感知器設置箇所に近い精度で推定できていることがわかる。また、同じ link2 上に位置する point 4 と 5 に注目すると、

表-2: プローブ率を変化させた際の精度評価指標

シナリオ	プローブ率	MAPE	RMSE (veh/h)
1	1%	0.655	666.7
2	5%	0.389	390.3
3	10%	0.324	357.7
4	20%	0.322	371.0

表-3: 感知器の設置箇所を変化させた際の精度評価指標

シナリオ	感知器の設置箇所	MAPE	RMSE (veh/h)
3	point 2	0.324	357.7
5	point 0, 2	0.235	299.0
6	point 0, 2, 4, 6	0.144	198.8

推定に用いた条件は真値と異なるにも関わらず、上流に比べ下流で散布図が大きく散らばらず、観測モデルによる補正が有効に機能しているといえる。

次に、密度の時空間図 (図-4) からは、感知器が少ない場合に link3 における渋滞の発生と解消が、真値に比べて遅れて推定されている様子が読み取れる。この理由は散布図の場合と同様に、プローブデータの観測モデルをもとに解釈できる。LTM では渋滞の発生及び解消は、同一時間帯における上流と下流の累積台数の差の増加及び減少として現れる。渋滞の発生が始まると渋滞波がリンクの下流境界から上流境界へと伝播していくが、その間も車両は下流へと進んでいる。渋滞波が上流境界に到達すると、上流境界からのリンクに流入する車両の数が減少し、上流境界における累積台数の増加は鈍くなる。一方で、その間に下流境界に到着した車両は渋滞波が上流境界に到達する前に上流境界を出発したので、この車両がプローブカーだった場合は、渋滞流でない場合の累積台数の変化が渋滞が発生している下流境界に伝わる。よって、渋滞状態になる前の上流境界を出発したプローブカーがリンク内を走行している間は下流境界の累積台数が大きく推定され、上流境界と下流境界の累積台数の差が小さくなるために、渋滞の発生が遅れて推定されることが考えられる。また、渋滞の解消時にはこの現象と逆の現象が生じていると考えられる。

4. 実データによる検証

本章では提案手法を実データに適用し、その結果を検証する。検証の目的は、本手法が実データに対する推定でも有効であるかや、双子実験で確認された提案手法の特性が、実データに対する推定でも確認される

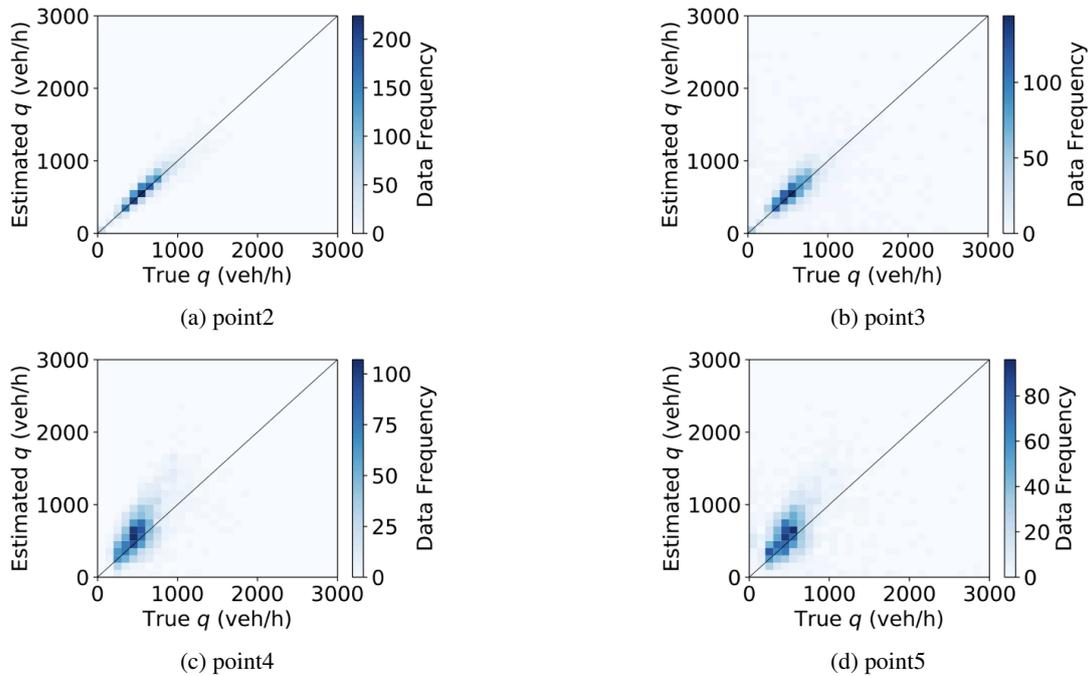


図-3: シナリオ 3 の代表 point における流率の真値と推定値の散布図

かを明らかにするためである。

a) 実データの概要

検証には 2018 年 6 月 1 日午前 8 時 00 分から午前 12 時 00 分にかけての阪神高速の一部区間における感知器データと ETC2.0 プローブデータを使用した。使用したプローブデータ及びネットワークデータは Yasuda et al. の手法¹⁶⁾に基づき、効率的な計算が可能となるよう処理されたものである。

感知器データには 5 分ごとに感知器が設置された車線における 5 分間交通量、平均速度が記録されており、プローブデータには予め分割されたリンクの境界地点の通過時刻が秒単位で記録されているほか、車両を識別するトリップ ID が記録されている。検証は図-5 中に赤線で示す阪神高速 3 号神戸線と 16 号大阪港線の一部の区間を対象に行なった。なお、この区間における 1 日の平均プローブ率はおよそ 3.4% である。平均プローブ率は感知器による全車両交通量の観測値とプローブデータに記録されたトリップ数との比から求めた。

b) シミュレーション設定

シミュレーションは図-5 の道路網を図-6 のようにモデル化したネットワークを対象に行う。モデル化の際には複数車線の道路はその区間の車線ごとの感知器データを集計し、擬似的に 1 車線の道路として扱った。また、感知器の設置位置とプローブデータにおけるリンク境界の位置は必ずしも厳密に一致しないが、両者の不一致による車両の通過時間の差の影響は、この実験におけるタイムステップ幅に対して無視できるとし、図

-6 中に赤色で示した、シミュレーションに使用する感知器の detector0 から detector2 についてはリンク境界位置に設置されているとした。加えて実際の交通状態推定では、交通状態の把握が重要であるのは高速道路の本線部分であることから、モデル化の際は出入り口部分を簡略化した。具体的には、プローブデータに基づき分岐率が 10% に満たない出口からの流出は無視できるとし、分岐率が 10% 以上の出口はダミーリンクとしてモデル化した。ダミーリンクとは交通容量が十分に大きく、そのリンクへの車両の流入に制限のないリンクである。仮に、実際はダミーリンクとした部分が渋滞しており、車両の流入に制限があったとしても、その場合はプローブカーに基づく分岐率が 0 に近づくため、このような設定としても渋滞状況を本線部分の推定に加味できる。

システムパラメータとして与えるこの区間の FD 変数は、感知器の交通量データと平均速度データに基づいてこの区間の密度 k を算出したのち、図-7 のように FD を作図して求めた。このように求めた対象区間の各リンクの長さ、及び FD 変数は表-4 の通りである。区間内にシミュレーションに用いる赤色の感知器が存在しない link4 については欠測とし、シミュレーションの際には link3 と同じ FD 変数を用いた。また、link1 はダミーリンクであるため、FD 変数は CFL 条件を満たし、かつ、車両の流入を制限しないよう十分な交通容量を与える適当な値とした。link4 の渋滞密度 k が他のリンクと比べ極端な値となっているのはこのためである。優

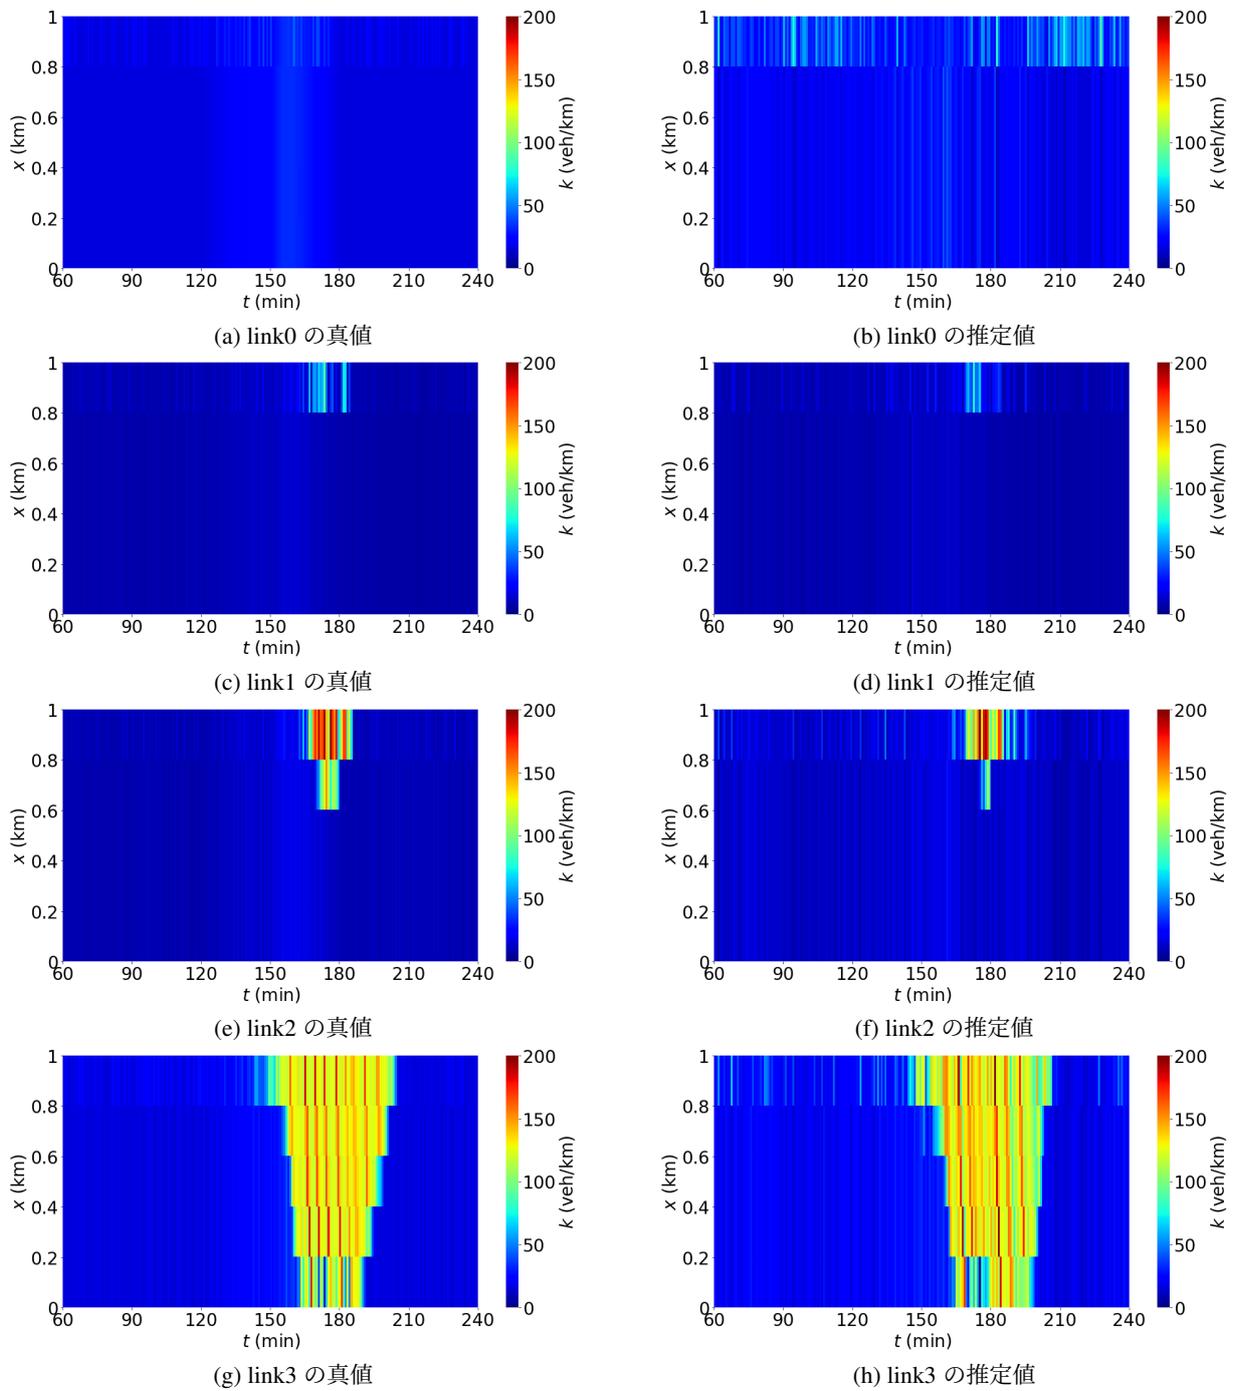


図-4: シナリオ 3 における各リンクの密度の時空間図

先率は、実際の道路における合流部の車線数の比をもとに、link2 と link3 の優先率の比率が 1 : 2 となるよう定め、タイムステップ幅は 50 秒とした。ここで、観測された感知器データが 5 分毎のデータであり、タイムステップ毎の交通量が観測されるとした 3. の双子実験と条件を揃えるために、この間に車両は一様に到着するとし、データを補間した。その他のシステムノイズや観測ノイズ、及び EnKF の設定は双子実験の場合と同様とした。

c) 検証項目

双子実験の場合とは異なり、実際の交通流の真値の把握は不可能である。そこで、手法の検証は図-6 のうち、赤色の感知器のデータを観測データとして使用し、青色の感知器のデータを真値とみなして比較する。真値と推定値を比較する項目は流率の時間変化と密度の時空間変化とする。なお、感知器が密度を観測できる範囲はその直下に限られるため、密度の時空間変化の比較においては、各リンクを 200m 程度のブロックに分割

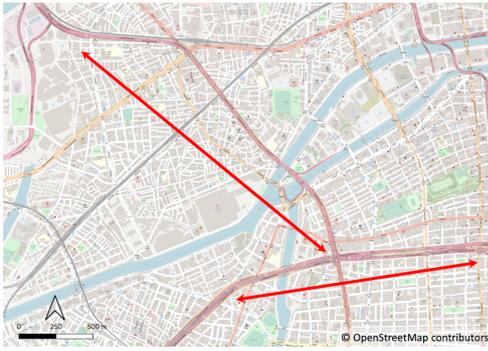


図-5: 検証の対象区間

表-4: 対象区間の各リンクの長さ及び FD 変数

リンク名	長さ (km)	u (km/h)	w (km/h)	κ (veh/km)
link0	2.11	75	15	250
link1	0.457	25	5	2500
link2	0.940	45	17.5	130
link3	1.05	60	15	225
link4	1.02	60	15	225

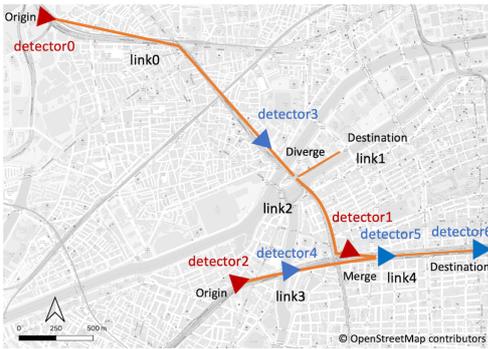


図-6: モデル化した対象区間

表-5: 実データに対する推定の精度評価指標

シナリオ	使用感知器	MAPE	RMSE (veh/h)
シナリオ A	detector 0,1,2	0.221	448.9
シナリオ B	detector 0	0.311	680.6

感知器を detector0 のみとしたシナリオ B でも検証を行う。感知器の個数以外は 2 つのシナリオの条件は等しい。実験は乱数シードを変更して 11 回ずつ行い、精度評価指標 MAPE が 11 回のうちの中央値を示した場合を比較する。なお、精度評価指標の値は、図-6 で青色で示された 4 箇所の感知器のある地点の平均である。

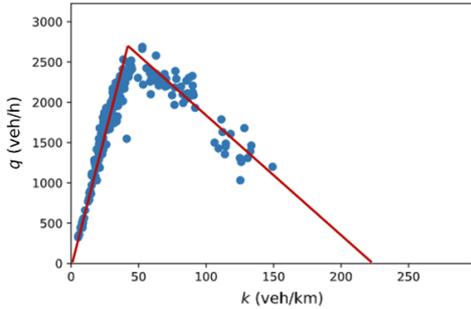


図-7: detector4 の観測に基づく FD

(1) 結果と考察

表-5 が示すように、シナリオ A では良好な精度で各地点の流率を推定できた。シナリオ A ではネットワークに存在する 2 つの Origin ノードに感知器が位置しており、ネットワークの上流地点の感知器による観測によって、下流地点の推定精度向上が見られる点で、3. の考察や双子実験とも整合する結果である。流率の時間変化図 (図-8) や密度の時空間図 (図-9) においては、シナリオ A ではネットワーク全体に渡って、真値の流率変化を追従し、渋滞の発生や解消を推定できており、感知器の間隔が約 1.7km あたり 1 個ほどであっても、ネットワーク上流で需要交通量を観測できる場合は、本手法はネットワーク全体に渡って良好な精度で交通状態を推定可能だといえる。

の上、感知器が含まれるブロックには感知器データをプロットし、その他のブロックでは欠測とした。流率の時間変化については、双子実験と同様に図及び精度評価指標 MAPE と RMSE に基づき比較する。なお、真値として用いる感知器データの観測間隔が 5 分であることから、推定値も 5 分ごとに集計したのちに比較する。比較には推定を行う午前 8 時 00 分から午前 12 時 00 分の時間帯のうち、初期状態の影響を除くために、午前 9 時 00 分から午前 12 時 00 分の推定結果を用いる。また、双子実験と同様に、使用する感知器の個数や位置がネットワークの推定に及ぼす影響を比較するために、上記の設定による検証シナリオ A に加えて、使用する

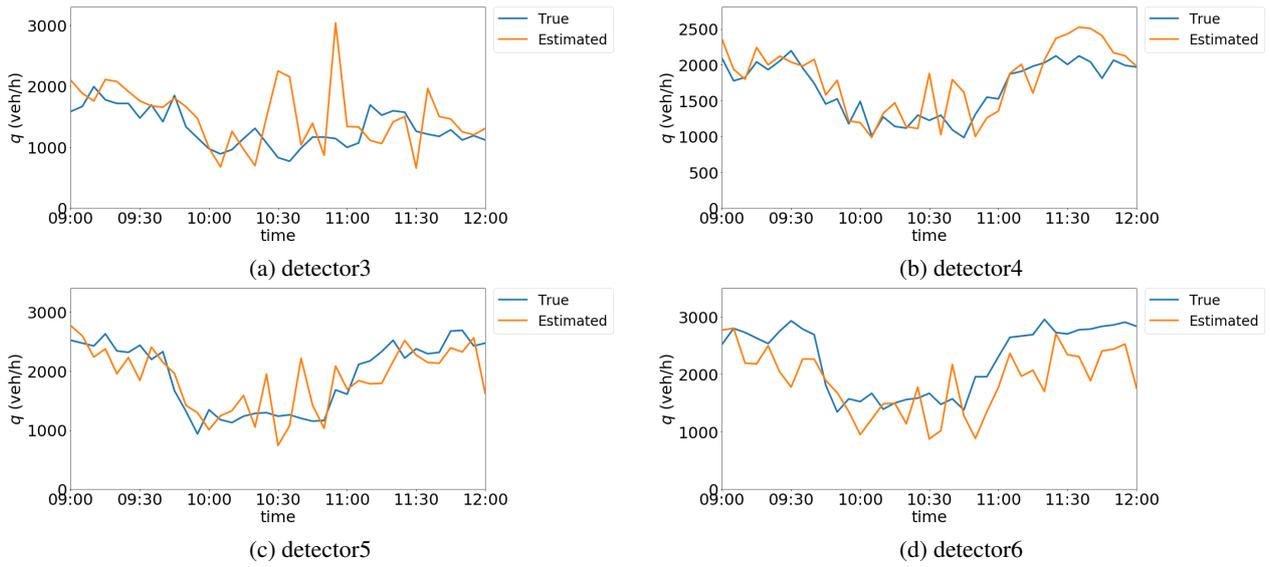


図-8: シナリオ A における各感知器位置での流率の時間変化図

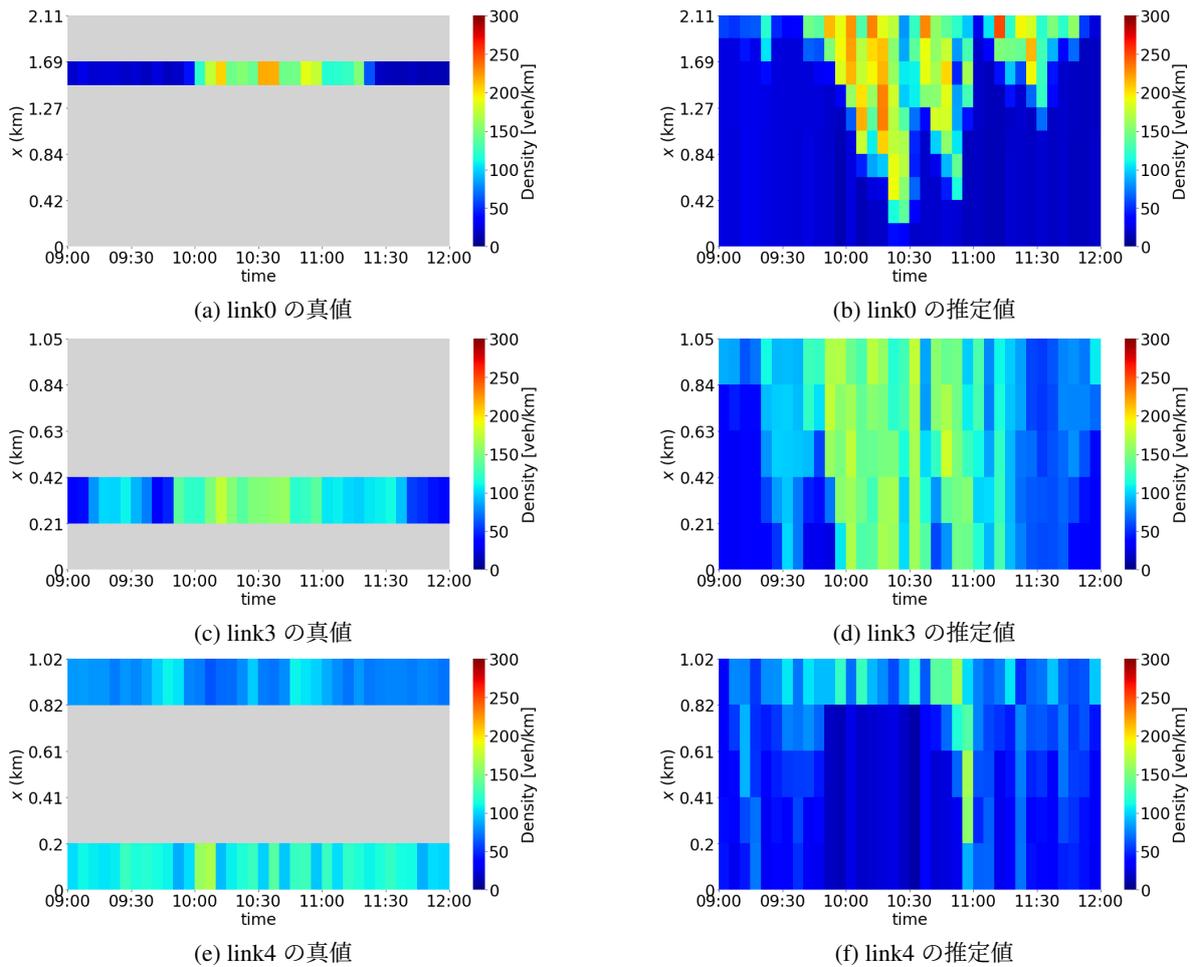


図-9: シナリオ A における各リンクの密度の時空間図

5. おわりに

本研究では、プローブデータと感知器データの併用を想定し、LTM と移動体観測を組み合わせた道路ネットワークの交通状態推定手法を開発した。開発した手法はシミュレーションを用いた双子実験によりその有効性を検証したのち、実データに対しても適用と検証を行った。結果として、利用可能な感知器データとプローブデータの増加に伴って、流率と密度の推定精度の向上が確認された。加えて、推定結果からはプローブ率が 10% ほどあれば、ネットワーク上に少量の感知器しかない場合でも、提案手法を用いて良好な精度でネットワークの交通状態推定が可能であることが示唆された。一方で、感知器が極端に少ない場合では、感知器から離れた箇所における推定が需要交通量の偏りの影響を受けることや、渋滞の発生・解消を遅れて推定するといった、構築したモデルの持つ誤差傾向も確認された。

今後の展望としては、主に 2 点が挙げられる。

1 点目は感知器に依存しない FD 変数の推定である。本研究で行った交通状態推定では、FD 変数を感知器データに基づいて事前に計算し、所与であるとした。しかし、現実には感知器は設置数が不十分な場合も多く、感知器のみに基づくネットワーク全体にわたる FD 変数の推定は難しい。FD 変数の推定精度は交通状態推定の精度に大きく影響を及ぼすために、高精度の交通状態推定には本手法と、ネットワーク全体にわたって FD 変数を精度よく推定する手法との統合が必要といえる。具体的には FD 変数も状態ベクトルの要素とし、状態空間モデルによって内生的に推定する手法や、Seo et al. の手法¹⁷⁾のように、FD 変数もプローブデータから推定する手法の利用が考えられる。

2 点目はより広域で複雑なネットワークへの拡張である。本研究の実データを用いた推定の検証は、実際の高速道路を分岐と合流が一箇所ずつ含まれる、5 リンクからなるネットワークにモデル化した上で行った。しかし、実際のネットワークには一度に複数の道路が分合流するジャンクションや環状構造を持った箇所が存在する。こうした箇所の LTM によるモデル化方法にはノードモデルの選定¹⁰⁾など検討の余地がある。効率のよい手法を開発し、さらに広域のネットワークでの検証が望まれる。

謝辞: 本研究で使用した阪神高速道路のネットワークデータ、検知器データ、及び ETC2.0 データは阪神高速道路(株)に提供いただいた。また、同データの利用にあたっては阪神高速道路(株)の石原雅晃氏と、東京大学大学院の安田昌平助教の両名に技術的協力をいただいた。本研究の一部は JSPS 科研費 20H02267 およ

び国土交通省新道路技術会議の研究課題「カメラ画像および複数の観測データを融合した次世代交通計測手法に関する研究開発」の助成を受けた。ここに謝意を表する。

参考文献

- 1) 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.
- 2) Daganzo, C. F.: The cell transmission model, part ii: network traffic, *Transportation Research Part B: Methodological*, Vol.29, No.2, pp.79–93, 1995.
- 3) Seo, T., Bayen, A. M., Kusakabe, T., and Asakura, Y.: Traffic state estimation on highway: A comprehensive survey, *Annual reviews in control*, Vol.43, pp.128–151, 2017.
- 4) ナンタウィットチュムチョーク, 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*, Vol.2003, No.730, pp.43–54, 2003.
- 5) 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, *2008 47th IEEE Conference on Decision and Control*, pp. 5062–5068, IEEE, 2008.
- 6) 川崎洋輔, 原祐輔, 桑原雅夫: 状態空間モデルによる経路選択を考慮した二次元ネットワークの交通状態推定手法の構築, *土木学会論文集 D3 (土木計画学)*, Vol.73, No.5, pp.I.949–I.959, 2017.
- 7) 瀬尾亨, 日下部貴彦: 衛星画像とプローブカー軌跡を用いたネットワーク交通状態推定のシミュレーション分析, *交通工学論文集*, Vol.5, No.2, pp.A.1–A.10, 2019.
- 8) 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.
- 9) Richards, P. I.: Shock waves on the highway, *Operations research*, Vol.4, No.1, pp.42–51, 1956.
- 10) 和田健太郎, 瀬尾亨, 中西航, 佐津川功季, 柳原正実: Kinematic wave 理論の近年の発展: 変分理論とネットワーク拡張, *土木学会論文集 D3 (土木計画学)*, Vol.73, No.5, pp.I.1139–I.1158, 2017.
- 11) Yperman, I., Logghe, S., Tampere, C. M., and Immers, B.: Multicommodity link transmission model for dynamic network loading, 2006.
- 12) Evensen, G.: The ensemble kalman filter: Theoretical formulation and practical implementation, *Ocean dynamics*, Vol.53, No.4, pp.343–367, 2003.
- 13) 樋口知之, 上野玄太, 中野慎也, 中村和幸, 吉田亮: データ同化入門 -次世代のシミュレーション技術-, シリーズ予測と発見の科学 6, 朝倉書店, 2011.
- 14) 淡路敏之, 蒲地政文, 池田元美, 石川洋一: データ同化: 観測・実験とモデルを融合するイノベーション, 京都大学学術出版会, 2009.
- 15) 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.
- 16) Yasuda, S., Iryo, T., Sakai, K., and Fukushima, K.: Data-oriented network aggregation for large-scale network analysis using probe-vehicle trajectories, *2019 IEEE Intelligent Transportation Systems Conference (ITSC)*, pp. 1677–1682, IEEE, 2019.

- 17) 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.

Development and Validation of a Traffic State Estimation Method Combining Link Transmission Model and Mobile Observation

So FUMIYAMA, Toru SEO and Takashi FUSE

Traffic state estimation is a method of estimating the flow rate, density, and speed of traffic flows from observed data. Estimating the traffic state of a wide area road network has two problems: the limitation of data and the computational efficiency of the estimation. Mobile observations and the Link Transmission Model (LTM), which is a traffic flow model that represents traffic conditions based only on the accumulated number of vehicles at the end points of a road, are promising methods to address the aforementioned issues.

However, the correspondence between mobile observations and the accumulated number of vehicles, which is the state variable of LTM, is non-trivial, and the traffic state estimation combining the two has not been realized. In this study, we developed a method for estimating the traffic condition of a road network by data assimilation based on LTM, using probe trajectory data and fractional detector data as inputs. The effectiveness of the proposed method was validated by numerical experiments, and the reasonableness of its behavior was also confirmed for data obtained on actual highways.