

博士論文

プローブ軌跡データと交通流モデルの同化による
二次元ネットワークの交通状態推定手法の構築

東北大学大学院情報科学研究科
人間社会情報科学専攻 空間計画科学分野

川崎 洋輔

2018年3月

Copyright © 2018 by 川崎 洋輔

桑原 雅夫

桑原 雅夫 教授

(主査)

赤松 隆

赤松 隆 教授

河野 達仁

河野 達仁 教授

布施 孝志

布施 孝志 教授

要　旨

プローブ軌跡データと交通流モデルの同化による
二次元ネットワークの交通状態推定手法の構築

川崎 洋輔

本研究は、プローブデータと交通流モデルの同化による二次元ネットワークのリアルタイムな交通モニタリング手法を提案する。

交通管理では、主要路線や代替路線、その他あらゆる路線の情報を収集し、二次元ネットワーク全体の交通状態をモニタリングした上で、交通制御・情報提供することが重要である。しかし、交通状態モニタリングのためのセンサーデータは、未観測箇所が存在し、かつ観測誤差が含まれる。そこで本研究では、状態空間モデルを構築し、上記課題解決を図った。二次元ネットワークの交通状態推定では、単路部(一次元)と異なり、利用者の経路選択行動のモデル化が必要である。そのため、交通流モデルと経路選択モデルを組み合わせて二次元ネットワークの交通流を表現するモデルを定式化した。そして、そのモデルにプローブ車両から得られる車両密度と分岐率のデータを同化し、モデルの推定結果を改善する状態空間モデルを構築した。構築した状態空間モデルはプローブデータの観測誤差を考慮して、二次元ネットワークの交通状態を推定する。双子実験により、モデル検証を行い、OD交通量の更新過程や事後分布を分析し、提案モデルの限界と改良方針に関する考察を行った。

謝 辞

本論文を遂行する上でご指導とご援助を頂いた全ての方々に感謝の意を表します。

東北大学大学院情報科学研究科 桑原雅夫教授には、日々、激励とご指導、ご教鞭を頂きました。本論文執筆にあたって、先生と研究に関する議論を続けて日々は、私にとつて、とても幸せな時間でした。本研究のみならず、自らが様々な研究を行い、交通の知見を活かし社会に貢献していく先生のお姿は、私にとって、研究者としての在り方の見本となりました。今後、先生のご指導の下で培ったものを、さらに研鑽を重ね、社会に貢献していきたいと考えます。

学位論文審査において拙論の副査を務めて頂き、貴重なご指摘とご助言を頂いた東北大学大学院情報科学研究科赤松隆教授、河野達仁教授、東京大学布施孝志教授に心より感謝申し上げます。

東北大学大学院情報科学研究科人間社会情報科学専攻空間計画科学分野桑原研究室スタッフの三谷卓磨元助教、原祐輔元助教、竹之内篤元研究員には、ゼミでの議論を通じて非常に多くの貴重なご意見を頂き、支えて頂きました。特に、原祐輔元助教は、忙しいにも関わらず、日々、ベイズ推論や状態空間モデルの定式化について、議論・指導していただき、誠に感謝しております。本論文は、桑原雅夫教授と原祐輔元助教なくしては完成できなかつたといつても過言ではないと考えています。佐々木恵秘書には、日々の研究生活の中の事務手続き等、支援いただきました。研究室の学生の皆様には、研究や飲み会等、多々ご協力を賜り支えて頂きました。特に、大学院生の吉田幸司君、宮下明久君、高安安奈さんには、学会の度に論文やプレゼン資料への貴重な意見をいただきました。3年間、共に楽しい研究生活を過ごさせていただいた研究室スタッフ、学生の皆様への感謝の意をここに記します。

オリエンタルコンサルタンツの皆様にも多くのご協力を賜りました。特に格段のご配慮とご支援を賜りました江藤和昭氏、辻光弘氏、田中淳氏、松戸努氏、河野芳徳氏、小野ひかり氏に心より感謝申し上げます。また、私の研究生活、コンサルタント業務およびその他日常生活を支え続けてくれた妻の幸世と長女の汐璃、次女の碧唯に感謝の意を表します。

最後に、ここに記しきれない多くの方々のご支援によって本研究が遂行されましたこと、心より感謝致します。

目 次

	頁
第 1 章 序論	1-1
1.1 研究の背景と目的	1-1
1.2 論文の構成	1-5
1.3 変数の表記	1-5
第 2 章 既往研究	2-1
2.1 Kinematic wave 理論に基づく交通流モデル	2-1
2.2 状態空間モデルによる交通状態推定	2-3
2.3 本研究の貢献	2-6
第 3 章 二次元ネットワークの交通状態推定モデルの定式化	3-1
3.1 一次元モデルを二次元ネットワークに拡張する場合の技術課題と解決方針	3-1
3.2 二次元ネットワーク交通流の表現	3-3
3.3 状態空間モデルの構築	3-12
3.4 事後分布の推定方法	3-17
第 4 章 双子実験によるモデルの検証	4-1
4.1 双子実験の概要	4-1
4.2 モデル検証条件	4-2
4.2 モデルの検証結果	4-7

第 5 章 結論 **5-1**

5.1 まとめ	5-1
5.2 今後の課題	5-3

Appendix 1 二次元モデルにおける経路選択モデルの設定例

Appendix 2 状態空間モデルの計算アルゴリズム

Appendix 3 Variational Theory(VT)の概要

Appendix 4 一次元モデル(FD の揺らぎの考慮)の定式化

Appendix 5 一次元モデル(区間途中の流入出台数の推定)の定式化

Appendix 6 一次元モデルの検証

表 目 次

	頁
1－ 1 本研究で扱う主な変数の表記	1－6
4－ 1 真値と状態空間モデルの設定条件の比較	4－4
4－ 2 シミュレーション条件[真値, 状態空間モデル共通]	4－5
4－ 3 シミュレーション条件[状態空間モデル]	4－5
4－ 4 OD 需要の設定条件(真値)	4－6
4－ 5 プローブ車両台数	4－6
4－ 6 OD 需要の設定条件(状態空間モデル)	4－6
4－ 7 実際の渋滞状況とモデルの推定結果の関係	4－9

図 目 次

	頁
2- 1 Fundamental diagram (FD)	2-2
2- 2 3次元の交通流の表現	2-3
2- 3 システムモデルと観測モデルの関係	2-4
3- 1 一次元ネットワークにおける状態変数と観測変数	3-3
3- 2 二次元ネットワークにおける状態変数と観測変数	3-3
3- 3 CTM ネットワークの例	3-4
3- 4 区分線形 Fundamental Diagram (FD)	3-5
3- 5 観測車両密度	3-13
3- 6 観測分岐台数	3-13
3- 7 状態空間モデルのグラフィカル表現	3-14
3- 8 フィルタリングの概念図	3-17
3- 9 パーティクルフィルタ	3-19
3-10 状態空間モデルの計算アルゴリズム	3-19
4- 1 双子実験の概要	4-2
4- 2 シミュレーションネットワーク	4-5
4- 3 平均対数尤度の比較[ケース 1]	4-8
4- 4 平均対数尤度の比較[ケース 2]	4-8
4- 5 Precision, Recall, F 値の比較[ケース 1]	4-11
4- 6 Precision, Recall, F 値の比較[ケース 2]	4-12
4- 7 タイムスペース図[ケース 1]	4-13
4- 8 タイムスペース図[ケース 2]	4-14
4- 9 OD 需要の確率分布 [ケース 1]	4-15

4-10 起点ノード 1 の OD 需要の確率分布 [ケース 2] 4-16

4-11 起点ノード 4 の OD 需要の確率分布 [ケース 2] 4-17

第1章 序論

1.1 研究の背景と目的

本研究では、状態空間モデルによるリアルタイムな二次元ネットワークの交通状態推定手法を提案する。交通管理において、交通制御と情報提供を併せたものを交通管制¹⁾という。

交通管制では、主要路線やその代替路線、その他あらゆる路線の情報を収集し、二次元ネットワーク全体の交通状態を把握した上で、交通制御・情報提供する必要がある。交通管理の目的の一つに渋滞状況の把握・改善があげられる。わが国では、渋滞損失は移動時間の約4割を占めており、年間約50億人時間と試算されている。これは、約280万人分の労働力に匹敵するといわれている²⁾。こうした日常的な渋滞の改善を図るには、まず、渋滞状況をモニタリングした上で、要因分析・対策立案することが必要と考えられる。

渋滞対策の一環として、ETC2.0対応カーナビを活用したダイナミックルートガイドンス³⁾が行われている。ダイナミックルートガイドンスとは、県境を越える広域な道路交通情報がITSスポットでリアルタイムに配信され、カーナビが最速のルートを提供するサービスである。こうした情報提供を行うためには、渋滞状況を“面的”，かつ“リアルタイム”にモニタリングする必要がある。日常的な渋滞モニタリングの他、非日常的な場面でもリアルタイムな交通モニタリングは重要と考えられる。例えば、自然災害(地震、豪雪、豪雨、洪水等)および交通事故発生直後における道路損傷や渋発生時の迅速な交通誘導、通行規制および情報提供、道路復旧を行うためには、時々刻々と変化する交通状態をリアルタイムにモニタリングする必要がある。

現状、道路管理者の災害時の被災や交通状態の把握手段は、道路に設置された車両感知器、CCTVカメラやパトロールカーによる巡回ならびに地域住民からの通報であ

る。しかしながら、車両感知器や CCTV カメラ等のセンサーはカバー範囲が限定されるため、センサーのない場所は、巡回員による現地での目視確認が必須である。災害時に避難車両の集中による渋滞や被災による道路の寸断が発生した場合、通行不能箇所以遠の施設巡視が困難になる。そのため、被災や交通状態の把握遅れによる道路の通行規制のタイミングへの影響が懸念される。桑原ら⁴⁾は、プローブデータにより、熊本地震時の交通を解析し、「災害時にネットワーク全体を活用するには、情報提供が有効であるが、車両感知器が設置されていない細街路を含む路線や感知器が損傷した路線の交通状況を効率的に収集することが必要である」と提言している。

以上の観点から日常時および非日常時のリアルタイムな二次元ネットワークの交通モニタリングに対する道路管理者のニーズは高いと考えられる。こうした背景を踏まえ、交通モニタリングのための既往のセンサーについて、以下に整理する。

交通モニタリングのセンサーとして、古くから車両感知器が使われている。車両感知器は、路側に設置され、車両の通過や存在を検出する。車両感知器により、高速道路および一般道路において、地点速度、交通量(車両通過台数)、道路占有率等を計測することができる。高速道路では300mから500m(平均的な設置間隔は首都高速道路が300m、阪神高速道路が500m、都市間高速道路は2km)の密な間隔で設置⁵⁾され、24時間365日にわたりデータを収集している。一方で、一般道路では、一部の主要道路にしか設置されておらず車両感知器のみで交通状態を把握することは困難である。例えば、平成22年道路交通センサス調査では、高速道路の調査地点の9割以上を車両感知器がカバーしているのに対して、一般道では、直轄国道の調査地点の4割程度、その他国道や地方道では1割に満たないカバー率⁶⁾となっている。車両感知器は高価であることから、交通状態を把握すべき箇所全てに設置することは現実的ではない。

最近は、車両感知器の他、GPS等の移動体のセンサーから大量の観測データが得られており、交通管制への活用が期待されている。こうした移動体データは、

- ・ 個々のプローブ車両の軌跡（位置、速度）が把握可能
- ・ 車両感知器等の設置型センサーに比べて広範なデータの収集が可能

・ 交通モニタリングのための専用デバイスの設置が不要であり、ユーザーが有する多様なデバイス(スマートフォン、カーナビゲーション等)からデータ収集が可能といった特徴を持つ。しかし、こうしたプローブデータは、

- ・ スパース（あくまでサンプルデータ）なため、未観測箇所が存在する。
- ・ 観測されるデータにノイズ(観測誤差)が含まれる。

といった問題が存在する。一般的には、前者の問題解決のアプローチは、観測データを入力値とした交通シミュレーションモデルを活用して交通状態を推定する。後者の場合は、観測データとシステムモデル（シミュレーションモデル）により状態空間モデルを構築し、モデルの精度改善を図るデータ同化というアプローチ⁷⁾がある。本研究では、上記2つのアプローチにより課題解決を図る。以降に研究方針を述べる。

まず、未観測箇所の補完・推定のためのモデルの構築方針について述べる。単路部（一次元）を対象にした交通流モデルは、リンク内の交通流をモデル化すればよい。一方で、二次元ネットワークでは、利用者の経路選択行動により渋滞状況が変化する。こうした二次元ネットワークでの交通状態推定のアプローチとしては、

- ・ 二次元ネットワークを複数の単路部に分割し、一次元モデルを全ての単路部に適用する。
- ・ 一次元モデルを拡張し、経路選択を考慮したモデリング(新たな二次元モデルの構築)を行う。

が考えられる。前者の場合、一次元のモデルを拡張する必要がない。そのため、比較的、適用が容易であるが、下記のような問題が生じる。

- 1) 未観測箇所の交通状態は不明：観測データが未観測の単路部では、一次元モデルの入力値が得られない。したがって、一次元モデルが実行できないため、単路部の交通状態は不明である。
- 2) リンク間の交通流の不整合：交差点の複雑な交通現象(直進、右左折等)は、一次元モデルのみでは表現できない。すなわち、一次元モデルのみでは、リンク間の交通流の受け渡しに不整合が生じる。

一方で、後者の場合は、新たなモデル構築の必要はあるが、“経路選択により未観測箇所にも交通が流れる”，かつ“モデルによりリンク間の交通流の整合を図っている”ため、上記の問題は生じない。そのため、本研究では、後者のアプローチにより、二次元ネットワークの交通流を表現した交通流モデルを構築し、課題解決を試みる。交通流モデルとは、Kinematic Wave 理論⁸⁾⁹⁾に基づき、Fundamental Diagram (FD)に従って、車両を移動させるものである。交通流モデルの詳細は2章で述べる。本研究では、交通流モデルの解法の一つであるCell Transmission Model (CTM)¹⁰⁾を用いて二次元ネットワークの交通流を表現する。

次に状態空間モデルの構築方針を述べる。前述したように状態空間モデルでは、観測データが必要である。観測データは、前述した車両感知器の他、プローブデータが考えられる。車両感知器は、センサー設置箇所が限定的であるため、本研究では、モデル適用の汎用性を高めるためにプローブデータのみを用いることとする。本研究では、プローブ軌跡データに着目し、2種類の観測変数を設定した。一つは、プローブ車両速度を用いて推定した“セルの車両密度”，2つ目は，“プローブ車両分岐率”である。各々の観測変数の詳細は後述する。

データ同化による交通状態推定の既往研究は、全て一次元ネットワーク(单路部)を対象にしたものである。一次元ネットワークのリンクの状態量は、リンク内の車両の密度や平均速度のみであるが、二次元ネットワークの道路の場合は、リンク内に異なる目的地の情報を持った車両が混在する。そのため、既往研究のモデルをそのまま二次元ネットワークに適用することは出来ない。

上記を踏まえ、本研究では、交通流モデルにプローブ軌跡データ同化させた二次元ネットワークの交通状態推定のための状態空間モデルの構築を目的とする。提案するモデルは、プローブ軌跡データと交通流モデルのみで二次元ネットワーク全体の交通状態推定が可能であるため、交通管制技術の高度化への貢献が期待される。

1.2 論文の構成

論文の構成は以下の通りである。第1章では本研究の背景と目的を述べる。第2章では、本研究に関連する Kinematic Wave 理論に基づく交通流モデル、一般状態空間モデルの概要について述べるとともに、状態空間モデルを用いた交通状態推定手法に関する既往研究を整理する。2章の最後に、既往研究の課題を踏まえて、本研究の貢献（本研究の位置づけ）を述べる。第3章では、まず、一次元モデルを二次元ネットワークに拡張する場合の技術課題を整理する。その上で、二次元ネットワークの交通状態を推定するモデルの定式化を行う。本章では、車両密度と分岐率の2種類の観測値を評価する状態空間モデルの定式化を行う。第4章は、第3章で定式化した状態空間モデルを双子実験と呼ばれる手法で検証する。第5章は、本論文の結論であり、得られた結論を整理し、総括するとともに、今後の展望も議論する。

1.3 変数の表記

状態空間モデルの構築にあたって、下表に本研究で使用する主な変数の表記を示す。

表 1-1 本研究で扱う主な変数の表記

記号	定義
i	セルのインデックス . $i = 1, 2, \dots, I$
Ω_I	全てのセルのインデックス集合, $i \in \Omega_I$
Ω_{ij}	隣接セルのインデックス集合
$C_u(i)$	セル <i>i</i> の上流のセル <i>m</i> の集合
$C_d(i)$	セル <i>i</i> の下流のセル <i>j</i> の集合
Ω_D	車両の目的地 <i>d</i> の集合. $d = 1, 2, \dots, D \in \Omega_D$
t	システムモデルのタイムステップ. $t = 0, 1, 2, \dots, T$
潜在変数	
$k_i^d(t)$	状態量. 時刻 <i>t</i> におけるセル <i>i</i> の目的地 <i>d</i> を持つ車両密度
$\mathbf{K}_i^D(t)$	時刻 <i>t</i> におけるセル <i>i</i> の全ての $k_i^d(t), d \in \Omega_D$ の集合
$\mathbf{K}_I^D(t)$	状態ベクトル. 時刻 <i>t</i> における全てのセルの $K_i^D(t), i \in \Omega_I$ の集合
$k_i(t)$	時刻 <i>t</i> におけるセル <i>i</i> の車両密度
$\mathbf{K}_I(t)$	時刻 <i>t</i> における全てのセルの $k_i(t), i \in \Omega_I$ の集合
$\pi_{ij}^d(t)$	時刻 <i>t</i> における目的地 <i>d</i> を持つ車両のセル <i>i</i> からセル <i>j</i> への分岐率
$\Pi^D(t)$	時刻 <i>t</i> における全ての $\pi_{ij}^d(t), d \in \Omega_D, ij \in \Omega_{ij}$ の集合
$\pi_{ij}(t)$	時刻 <i>t</i> におけるセル <i>i</i> からセル <i>j</i> への分岐率
$\Pi(t)$	時刻 <i>t</i> における全ての $\pi_{ij}(t), ij \in \Omega_{ij}$ の集合
観測変数	
$\hat{k}_i(t)$	時刻 <i>t</i> におけるセル <i>i</i> の観測車両密度
$\hat{\mathbf{R}}_i(t)$	観測ベクトル. 時刻 <i>t</i> における全ての $\hat{k}_i(t), i \in \Omega_I$ の集合
$\hat{\pi}_{ij}(t)$	時刻 <i>t</i> におけるセル <i>i</i> からセル <i>j</i> への観測分岐率
$\hat{\Pi}(t)$	観測ベクトル. 時刻 <i>t</i> における全ての隣接セルの $\hat{\pi}_{ij}(t), ij \in \Omega_{ij}$ の集合
ハイパーパラメータ	
\mathbf{F}	Fundamental diagramの諸量

1章の参考文献

- 1) 飯田恭敬, 佐佐木綱 : 交通工学, 国民科学社, 1995.
- 2) 平成 27 年度国土交通白書, 国土交通省.
- 3) 国土交通省ホームページ, ITS スポットサービスの内容,
http://www.mlit.go.jp/road/ITS/j-html/spot_dsrc/naiyou.html (2017 年 12 月 30 アクセス)
- 4) 桑原雅夫, 原祐輔, 三谷卓摩, 川崎洋輔, 竹之内篤, 井料隆雅, 浦田淳司 : 熊本地震における都市内交通, 避難の実態と課題, 土木計画学研究・講演集, Vol.54, CD-ROM, 2016.
- 5) 土坂克己ほか : 国土総合技術研究所資料 道路交通における所要時間信頼性の調査、分析および評価方法に関する実用的研究, 国総研資料 第 660 号, 2013.
- 6) 村下剛, 笹岡和幸, 焼田聰, 荒木悠 : これからの中の交通状況の把握方法について, 国土交通省北陸地方整備局 研究発表会, 2013.
- 7) 横口知之, 上野玄太, 中野慎也, 中村和幸, 吉田 亮: データ同化入門一次世代のシミュレーション技術一, 朝倉書店, 2011.
- 8) Lighthill, M.J. and G.B.Whitham: On kinematic waves II. A theory of traffic flow on long crowded roads, The Proceedings of the Royal Society, LONDON, series A 229(1178), pp313-345, 1955.
- 9) Richards, P.I. : Shock waves on the highway, Operation Research Vol.4, pp.42-51, 1956.
- 10) Daganzo, C.F. : The cell transmission model, part II : network traffic, Transportation Research Part B : Methodological, Vol. 29(2), pp. 79-93, 1995.

第2章 既往研究

本章では、本研究に関連する Kinematic Wave 理論に基づく交通流モデル、一般状態空間モデルの概要について述べるとともに、状態空間モデルを用いた交通状態推定手法に関する既往研究を整理する。最後に、既往研究の課題を踏まえて、本研究の貢献（本研究の位置づけ）を述べる。

2.1 Kinematic wave 理論に基づく交通流モデル

Kinematic wave 理論は、Lighthill and Whitham¹⁾、及び Richards²⁾によって提案された。Kinematic wave 理論の概要を以下に整理する。Lighthill and Whitam は単路部交通流を対象に、単位距離あたりの存在台数を表す指標として、「交通密度」を定義した。また、

- ・道路上の各断面において交通量は密度の関数として表される。
- ・臨界密度で交通量は最大値を取り、ジャム密度で交通量は0となる。

と仮定し、時空間的な交通量－密度状態の変遷を記述する Kinematic wave 理論を構築した。具体的には、交通密度の不連続面がショックウェーブとして移動する速度 S を、

$$S = \Delta q / \Delta k \quad (2-1)$$

と表した。ただし、 Δq 、 Δk は、密度の不連続面における交通量、及び密度の変化量を表す。一方、それと同時期に、Richards は交通流に関して、

- ・車両挙動に関する分布はすべて連続な確率密度関数で記述可能である。
- ・平均走行速度は交通密度に対して単調減少する関数として表される。

との仮定の下、交通密度の不連続面が伝播する速度 s を

$$d_1(V_1 - s) = d_2(V_2 - s). \quad (2-2)$$

と表現するモデルをした。提案ただし、 d_1, V_1 は密度の不連続面上流の交通密度と速度、 d_2, V_2 は密度の不連続面下流の交通密度と速度である。

両モデルは、交通量 Q [veh/h]、交通密度 K [veh/km]、区間平均速度 V [km/h] の間に、

$$Q = KV. \quad (2-3)$$

の関係を導入することで一致する。したがって、一般に Lighthill- Whitam- Richards の頭文字を取って LWR モデルと言われる。LWR モデルの重要な仮定は、交通量と車両密度との間に関係が存在することである。図 2-1 に示す Fundamental diagram (FD) と呼ばれるこの関係は、場所によって変化するが、時間変化しない。本研究では、FD に従つて車両を動かすモデルを LWR モデル含め、総称して交通流モデルと呼ぶ。FD と境界条件が与えられれば、交通流モデルは、交通量保存則に基づき、交通状態として、図 2-2 に示す時空間上の累積交通量を推定する。Kinematic wave 理論では、各道路断面は単位時間あたりに通過可能な最大の交通量である交通容量を有する。この場合、ある道路区間内で最も交通容量の低い道路断面をボトルネックとし、その交通容量を超過する流入需要が生じた場合にのみ渋滞が発生するとされる。

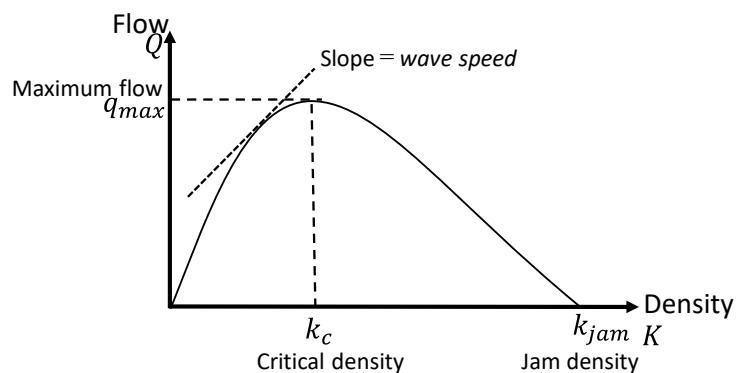


図 2-1 Fundamental diagram (FD)

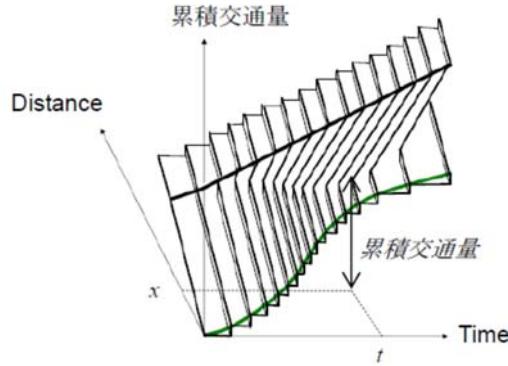


図 2-2 3 次元の交通流の表現

2.2 状態空間モデルによる交通状態推定

本研究では、前節で述べた交通流モデルを状態空間モデルに拡張し、交通状態を推定する手法を構築する。そのため、まず、2.2.1節で一般的な状態空間モデルについて述べる。2.2.2節では、状態空間モデルによる交通状態推定に関する既往研究を整理する。

2.2.1 一般状態空間モデル

一般状態空間モデル(以降、状態空間モデルという)とは、時系列モデルの枠組のモデルである³⁾⁴⁾。状態ベクトルと観測ベクトルで構成される。“状態”とは、シミュレーションモデルの計算結果の状態である。時刻 t のシミュレーションモデルの状態のベクトル量を状態ベクトル \mathbf{x}_t と定義する。一般的なシミュレーションモデルは決定論的である。状態空間モデルでは、シミュレーションモデルに確率的な誤差を考慮した確率論的なモデルを用いる。この確率論的なシミュレーションモデルをシステムモデル、システムモデルの確率的な誤差をシステムノイズと呼ぶ。

次に観測された時系列データを考える。時刻 t に得られた観測値のベクトル量を観測ベクトル \mathbf{y}_t と定義する。状態ベクトルと観測ベクトルとの関係を表したもの観測モデルと呼ぶ。モデルから推定される状態ベクトルと観測モデルは一般的には一致せず、

近い値が得られると考えられる。この両者の誤差を観測ノイズと呼ぶ。なお、観測ノイズは、確率変数である。

状態空間モデルでは、時刻 t までの観測ベクトルが得られた時に、事後分布を算出し、事後分布を最大化するような状態ベクトルを推定する。観測モデル、システムモデルの関係のグラフィカル表現を図 2-3 に示す。事後分布 $p(\mathbf{x}_t | \mathbf{y}_{1:t})$ は、図 2-3 のモデルの仮定とベイズの定理より下式のように示される。

$$p(\mathbf{x}_t | \mathbf{y}_t) \propto p(\mathbf{y}_t | \mathbf{x}_t) p(\mathbf{x}_t | \mathbf{y}_{1:t-1}) = p(\mathbf{y}_t | \mathbf{x}_t) \int p(\mathbf{x}_t | \mathbf{x}_{t-1}) p(\mathbf{x}_{t-1} | \mathbf{y}_{1:t-1}) d\mathbf{x}_{t-1}. \quad (2-4)$$

右辺の中で、 $p(\mathbf{y}_t | \mathbf{x}_t)$ は観測モデル、 $p(\mathbf{x}_t | \mathbf{x}_{t-1})$ はシステムモデル、 $p(\mathbf{x}_{t-1} | \mathbf{y}_{1:t-1})$ は、 $t-1$ 時(1期前)における推定結果を示す。以上より、状態空間モデルでは、観測モデル、システムモデルの構築と事後分布の計算が必要である。

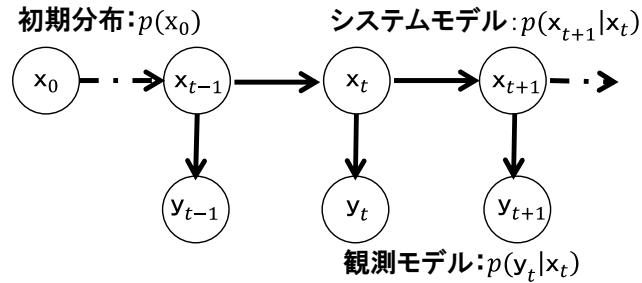


図 2-3 システムモデルと観測モデルの関係

2.2.2 状態空間モデルによる交通状態推定に関する既往研究

既往研究でのデータ同化による交通状態推定は、データ同化により交通シミュレーションモデルのパラメータを推定するものと観測データによりシステムモデルの推定結果を改善するという 2 つのアプローチに分けられる。

前者は、Sopasakis et al.⁵⁾、本山ら⁶⁾、藤井ら⁷⁾などにより、観測データを用いた交通シミュレーションモデルのパラメータ推定手法が提案されている。本研究は、後者に位置づけられるため、以下に関連研究を整理する。

高速道路の交通状態推定を対象とした状態空間モデルは, Claudel and Bayen⁸⁾, Deng et al.⁹⁾, Work et al.¹⁰⁾, Yuan et al.¹¹⁾がある. 各々, 道路の区間をセルに分割し, Kinematic wave 理論に基づいた交通流モデルベースのシステムモデルを用いている点が共通している. 観測データは, 車両感知器といった設置型のセンサーの他, Bluetooth やプローブデータ等, 研究によって様々なセンサーデータが活用されている. 成岡ら¹²⁾のようにパラメータと交通状態を同時推定している例もある. Seo et.al.¹³⁾は, 車間距離測定プローブ車両から得られる車間距離とプローブ車両の位置情報により逐次 Fundamental Diagram(FD)と車両密度を推定するモデルを提案している. このように, 既往のセンサーに加えて車間距離等の新たな観測データの活用が模索されている. この他のアプローチとしては, フィルタリング手法の違いによる交通状態推定精度の比較検証を行った研究として, 高嶋ら¹⁴⁾, Seo et.al.¹⁵⁾がある.

一般道を対象としたものには, Nates et al.¹⁶⁾がある. 一般道路を対象に CTM(Cell Transmission Model)¹⁷⁾と類似したセルベースのモデルとプローブデータ, Bluetooth データを用いて拡張カルマンフィルタにより交通状態を推定する手法を提案している. 竹ノ内ら¹⁸⁾は, CTM とプローブ軌跡データのみで, 一般道の信号交差点含む単路部の交通状態推定を試みている. Kawasaki et al.¹⁹⁾は, 交通流モデルの解法の一つである Variational Theory にプローブ軌跡データを同化させて FD の時系列変化をモデル化している.

以上の研究は, 全て一次元ネットワーク(単路部)を対象にしたものである. 一次元ネットワークの道路を分割したセルの状態量は, セル内の車両の密度や平均速度のみであるが, 二次元ネットワークの道路のセルの場合は, セル内に異なる目的地の情報を持った車両が混在する. そのため, 既往研究のモデルをそのまま二次元ネットワークに適用することは出来ない.

2.3 本研究の貢献

前節の既往研究を踏まえ、本研究の貢献は以下のように考える。

(1) 新たなプローブ車両の観測値として、プローブ車両分岐率を提案

これまでの研究は、プローブ車両からの観測値として、車両速度や旅行時間を使ってきた。本研究では、モデル内の車両の目的地構成比率の改善に資する新たな観測値として、プローブ車両分岐率を提案した。

(2) 状態空間モデルを一次元から二次元ネットワークに拡張

前節で述べたように既往の状態空間モデルは、一次元ネットワークを対象にしたものである。この理由は、

- ・二次元ネットワークの場合、ドライバーの経路選択を考慮する必要があること
- ・一般道の交差点の交通流は複雑でありモデル化が難しいこと

といった点が推察される。本研究では、これらの課題解決のために、交通流モデルと経路選択モデルを用いて二次元ネットワークの交通流を表現するシステムモデルを構築した。そして、システムモデルの推定結果をプローブ軌跡データから得られる車両密度と分岐率を用いて推定結果を改善する状態空間モデルを構築した。

交通流モデルは、OD交通”量”が境界条件のため、一般的には、車両感知器等の車両の全数が観測可能な設置型のセンシングデータを活用する必要がある。しかし、車両感知器は、設置箇所が限定的(主要道にのみ設置)されているため、観測範囲が限定される。一方、プローブデータは、広範なデータを得られるが、量的な把握不可といった問題がある。本研究では、これらの問題解決のために、観測値とモデル構造を工夫して、対応している。

2章の参考文献

- 1) Lighthill, M.J. and G.B.Whitham: On kinematic waves II. A theory of traffic flow on long crowded roads, *The Proceedings of the Royal Society, LONDON, series A* 229(1178), pp313-345, 1955.
- 2) Richards, P.I. : Shock waves on the highway, *Operation Research Vol.4*, pp.42-51, 1956.
- 3) 北川源四郎：時系列解析入門，岩波書店，2005。
- 4) 樋口知之, 上野玄太, 中野慎也, 中村和幸, 吉田 亮:データ同化入門一次世代のシミュレーション技術一, 朝倉書店, 2011.
- 5) Sopasakis, A. and Katsoulakis, M.,A. : Information metrics for improved traffic model fidelity through sensitivity analysis and data assimilation, *Transportation Research Part B: Methodological*,Vol.86 ,pp.1–18,2016.
- 6) 本山 拓樹,佐々木 邦明:高速道路のミクロシミュレーションへの交通状態観測のフィードバック, 土木計画学研究・講演集, Vol.51, 2015.
- 7) 藤井涼,大園涉,奥野潤,中辻隆 : Particle Filter を用いた Micro simulation の動的パラメータ推定の実ネットワークへの適応,土木計画学研究・講演集, Vol.44, 2011.
- 8) Claudel, C. G. and Bayen, A. M.: Convex formulations of data assimilation problems for a class of Hamilton-Jacobi equations, *SIAM Journal on Control and Optimization*, Vol. 49, No. 2, pp. 383-402, 2011.
- 9) 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.
- 10) Work, D., Blandin, S., Tossavainen, O. P., Piccoli, B. and Bayen, A.: A traffic model for velocity data assimilation, *Appl. Math. Res. Exp.*, Vol. 2010, No. 1, pp. 1-35, 2010.
- 11) Yuan, Y., Duret, A., and van Lint, H., "Mesoscopic Traffic State Estimation based on a Variational Formulation of the LWR Model in Lagrangian-space Coordinates and Kalman Filter," *Transportation Research Procedia*, Vol.10, pp.82–92,2015.

- 12) 成岡尚哉, 瀬尾亨, 日下部貴彦, 朝倉康夫 : 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, 土木計画学研究・講演集, Vol. 51, 2015.
- 13) Seo T., Kusakabe, T. and Asakura, Y. : Traffic state estimation with the advanced probe vehicles using data assimilation, in IEEE 18th International Conference on Intelligent Transportation Systems, pp. 824–830, 2015.
- 14) 高嶋 望都, 塩見 康博 : データ同化を用いた高速道路サグ部における渋滞現象の分析, 土木計画学研究・講演集, Vol.54, CD-ROM, 2016.
- 15) Seo T., Tchrakian, T., Zhuk, S. and Bayen, A. : Filter comparison for estimation on discretized PDEs modeling traffic: Ensemble Kalman filter and Minimax filter, 2016 IEEE 55th Conference on Decision and Control (CDC), pp. 3979–3984, 2016.
- 16) Nantes, A., Ngoduy, D., Bhaskar, A., Miska, M. and Chung, E.: Real-time traffic state estimation in urban corridors from heterogeneous data, *Transportation Research Part C: Emerging Technologies*, 2015.
- 17) Daganzo, C.F. : The cell transmission model, part II : network traffic, *Transportation Research Part B : Methodological*, Vol. 29(2), pp. 79-93, 1995.
- 18) 竹之内篤, 桑原雅夫, 移動体データのみを用いた交通状態推定手法の研究, 土木計画学研究・講演集, Vol.53, CD-ROM, 2016.
- 19) Kawasaki,Y., Hara,Y., Mitani, T.and Kuwahara,M.,:Real-time Simulation of Dynamic Traffic Flow with Traffic Data Assimilation Approach, *Journal of Disaster Research*, Vol.11, No.2, 2016.

第3章 二次元ネットワークの交通状態推定モデルの定式化

本章では、交通流モデルとプローブ軌跡データを用いた二次元ネットワークの交通状態推定モデルの定式化を行う。二次元ネットワークの交通流の表現は、交通流モデルの解法の一つである Cell Transmission Model(CTM)¹⁾を用いる。

本章の構成を述べる。3.1 節では、一次元モデルを二次元ネットワークに拡張する場合の技術課題を整理する。3.2 節では、二次元ネットワークの交通流の表現について述べる。3.3 節では、3.1 節および 3.2 節を踏まえ、二次元ネットワークの交通状態推定のための状態空間モデルの定式化を行う。

3.1 一次元モデルを二次元ネットワークに拡張する場合の技術課題と解決方針

本節では、まず、一次元モデルを二次元ネットワークに拡張する場合の技術課題を整理し、課題の解決方針を述べる。2章で述べたように一次元（单路部）を対象にしたモデル(以降、一次元モデル)は多数存在する。一次元モデルを二次元に拡張する際の技術課題および解決方針を述べる。

CTM は、リンク(道路)をセルと呼ばれる小さな区間に分割する。まず、図 3-1 に示すような一次元のネットワークを考えよう。セルのインデックスを、 $i = \{1, 2, \dots, I\}$ と定義する。状態変数は、セル i の車両密度(時刻 t にセル i にいる車両台数)とし、 $k_i(t)$ と表記する。観測変数は、プローブデータから推定される車両密度とし、 $\hat{k}_i(t)$ と表記する。一次元ネットワークの場合、セル i の車両は、必ず下流セル j に流出する。この場合、状態変数 $k_i(t)$ を観測車両密度 $\hat{k}_i(t)$ で改善すればよい。

次に、図 3-2 に示す二次元ネットワークを考えよう。こうした二次元ネットワークでは、下記のような技術課題がある。

課題 1：分岐セルにおいて、下流セルへの流出量は、ドライバーの目的地およびネットワークの交通状態に応じて刻々と変化する。すなわちドライバーの経路選択行動を考慮する必要がある。

課題 2：プローブデータからリアルタイムにドライバーの目的地を直接観測することは出来ない。観測できるのは、タイムステップごとの車両軌跡のみである。ドライバーの目的地の推定が必要である。

上記技術課題の解決方針を以下に述べる。

1) 課題 1 の解決方針

経路選択行動をモデルで考慮するには、分岐セルの車両の目的地構成比率(目的地 d を持つ車両の割合)を状態変数に組み込むことが必要と考える。したがって、状態変数は、目的地 d をもつセル i の車両密度とし、 $k_i^d(t)$ と表記する。状態変数にあわせて、経路選択モデルと信号制御を内包した交通流モデル(CTM)を構築する。

2) 課題 2 の解決方針

前述したように、プローブデータからは、ドライバーの目的地を観測できない。そこで、以下の方針で分岐セルの目的地構成率を改善する。本節のモデルでは、OD 需要の先驗的な確率分布は所与とする。OD 需要在ネットワークに流入した際、図 3-2 に示すようにプローブ車両観測分岐率 $\hat{\pi}_{ij}(t)$ を活用し、モデルの分岐率 $\pi_{ij}(t)$ を更新することで、分岐セルの車両密度の目的地構成比率の改善を図る。

次節では、上記、課題解決方針を踏まえ、二次元ネットワークの交通流の表現につ

いて述べる。

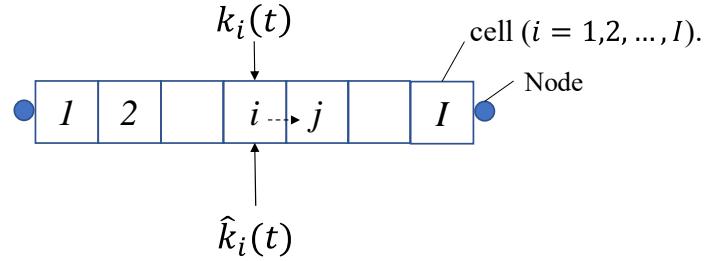


図 3-1 一次元ネットワークにおける状態変数と観測変数

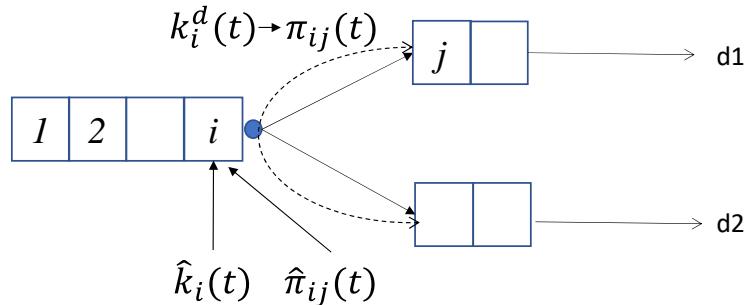


図 3-2 二次元ネットワークにおける状態変数と観測変数

3.2 二次元ネットワーク交通流の表現

本節では、ネットワーク交通流の表現について述べる。本研究のネットワーク交通流は、Kinematic wave 理論に基づく交通流モデルと経路選択モデルで表現する。本研究では、交通流モデルの解法の一つである CTM を用いる。ネットワーク交通流の表現には、交通流モデルの他に、利用者の経路選択行動をモデル化した経路選択モデルが必要である。本節では、まず、ネットワーク条件とモデルの前提条件を述べる。次に、二次元ネットワークの交通流を表現するための交通流モデルと経路選択モデルを定式化する。

3.2.1 ネットワーク条件

本研究で用いるCTMネットワークを定義する。CTMのネットワークの例を図 3-3に示す。同図の上段のようにネットワークは有向リンクとノード $n = 1, 2, \dots, N$ で構成されている。CTMネットワークでは、同図の下段のように各リンクは、微小距離 Δx のセルで分割されていると仮定する。リンクは、道路を示し、ノードはリンクの端点である。以降、ノード*i*、ノード*j*で構成されるリンクは「リンク(*i,j*)」と表記する。リンクの距離 X は $X = n\Delta x$ とする。ここで*n*は自然数である。ネットワークに存在するセルのインデックス集合を $\Omega_I = \{1, 2, \dots, i, \dots, I\}$ と定義する。セル*i*は、図 3-4に示す区分線形FDを持ち、諸量を下記のように表す。

$$v_i = \text{セル } i \text{ の Forward wave speed}$$

$$w_i = \text{セル } i \text{ の Backward wave speed}$$

$$k_i^c = \text{セル } i \text{ の臨界密度}$$

$$k_i^{jam} = \text{セル } i \text{ のジャム密度}$$

なお、FDの諸量は時間変化しないと仮定し、所与とする。

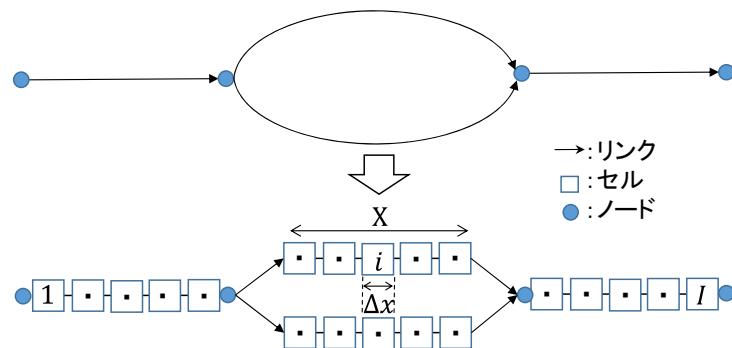


図 3-3 CTM ネットワークの例

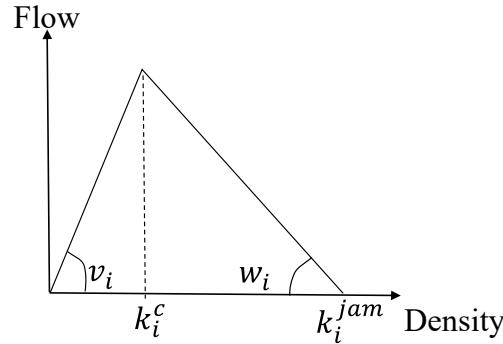


図 3-4 区分線形 Fundamental Diagram (FD)

3.2.2 モデルの前提条件

本研究のモデルの前提条件を以下に整理する。

- (1) 利用者は、CTMのネットワークを走行している。
- (2) 利用者は、利用可能な経路についての完全な情報を得ている。
- (3) 利用者は、逐次経路選択を行っている。(分岐部に到着する度に逐次経路選択を行っている)
- (4) 利用者は、時刻 t において、時刻 t に実現している(瞬間的な)所要時間のみを基に経路選択を行っている。すなわち、経路選択行動はマルコフ性を仮定する。
- (5) 経路選択モデルが、利用者の経路選択行動を完全に再現できていると仮定する。
- (6) 以下の1)~4)は所与とする。
 - 1) ネットワーク条件(リンクの接続関係、リンク長等)
 - 2) 信号現示条件
 - 3) FDの諸量
 - 4) 時刻 t におけるセル i を出発し目的地ノード d に向かうOD交通密度、 $q_i^d(t)$

3.2.3 交通流モデル

本節では、二次元ネットワークの交通流を表現する交通流モデルを定式化する。本研究では、交通流モデルの解法であるCTMを用いる。前述したように二次元ネットワ

一クでは、一つのセル内に異なる目的地の情報を持った車両が混在する。そこで、本研究では、CTMにおいてセルの密度を目的地別に保持し、逐次更新することを考える。CTMのタイムステップを $t = 1, 2, \dots, T$ と表記し、タイムステップの時間幅を Δt とする。車両の目的地ノードのインデックス集合を $\Omega_D = \{1, 2, \dots, d, \dots, D\}$ とし、時刻 t のセル i におけるセルの車両密度を $k_i(t)$ 、そのうち目的地 d を持つ車両の密度を $k_i^d(t)$ と表記する。CTMのセルは、タイムステップごとに以下の交通密度を持つ。

$$k_i(t) = \sum_{d \in \Omega_D} k_i^d(t), \forall i \in \Omega_I. \quad (3-1)$$

$$\mathbf{K}_I(t) = (k_1(t), k_2(t), \dots, k_i(t), \dots, k_I(t))^T. \quad (3-2)$$

$$\mathbf{K}_i^D(t) = (k_i^1(t), k_i^2(t), \dots, k_i^d(t), \dots, k_i^D(t))^T, \forall i \in \Omega_I. \quad (3-3)$$

$$\mathbf{K}_I^D(t) = (\mathbf{K}_1^D(t), \mathbf{K}_2^D(t), \dots, \mathbf{K}_i^D(t), \dots, \mathbf{K}_I^D(t))^T. \quad (3-4)$$

$\mathbf{K}_I(t)$ は、すべてのセルの車両密度 $k_i(t)$ の集合である。 $\mathbf{K}_I^D(t)$ は、目的地 d を持つ車両の密度 $k_i^d(t)$ の集合と定義する。

次にCTMにおける交通量保存則について、述べる。まず、隣接するセル m, i, j 間の車両密度の時間進展を定式化する。セル i の上流のセルの集合を $C_u(i) = \{\dots m \dots\}$ 、下流セルの集合を $C_d(i) = \{\dots j \dots\}$ と定義すると、時刻 t におけるセル m, i, j の交通流率は、交通量保存則より、

$$k_i^d(t) = k_i^d(t-1) + (\sum_{m \in C_u} x_{mi}^d(t-1) - \sum_{j \in C_d} x_{ij}^d(t-1) + q_i^d(t-1)) \Delta t / \Delta x, \\ s.t. \Delta x / \Delta t \geq v_i, \forall d \in \Omega_D, \forall i \neq d, m \in C_u(i), j \in C_d(i). \quad (3-5)$$

と書ける。ここに、

$x_{ij}^d(t)$ = 時刻 t の目的地 d をもつ車両のセル i から j 間の流率

$q_i^d(t)$ = 時刻 t におけるセル i を出発し、目的地 d に向かう OD 交通密度(所与)

である。上式では、 Δt の間にセルを飛び越えないように $\Delta x / \Delta t \geq v_i$ の制約を設けている。

右第 1 項は、1 期前 ($t-1$) 時の車両密度、第二項は、上流セル m からセル i への交通流率、第 3 項は、セル i から下流セル j への交通流率である。

次に、セル ij 間の交通流率 $x_{ij}^d(t)$ の算定法を整理する。交通流率 $x_{ij}^d(t)$ を求めるにあたっては、以下の交通流率を考える必要がある。

1) セル i からセル $j \in C_d(i)$ に流出したい交通流率、 $u_{ij}(t)$

2) セル i からセル $j \in C_d(i)$ に流出できる交通流率、 $r_{ij}(t)$

3) セル $j \in C_d(i)$ がセル i から受け入れることができる交通流率、 $s_{ij}(t)$

1) の $u_{ij}(t)$ とは、セル i に存在する交通のうち終点セルに向かうためにセル $j \in C_d(i)$ に流出したい交通需要のことを言う。したがって、この交通流率は、終点までの経路に依存した関数として、

$$u_{ij}^d(t) = v_i \cdot k_i^d(t) \cdot \pi_{ij}^d(t), \forall d \in \Omega_D. \quad (3-6)$$

$$\sum_{j \in C_d(i)} \pi_{ij}^d(t) = 1, \forall d \in \Omega_D. \quad (3-7)$$

$$u_{ij}(t) = \sum_d u_{ij}^d(t) = \sum_d v_i \cdot k_i^d(t) \cdot \pi_{ij}^d(t). \quad (3-8)$$

$$u_j(t) = \sum_i u_{ij}(t) = \sum_{i,d} u_{ij}^d(t) = \sum_{i,d} v_i \cdot k_i^d(t) \cdot \pi_{ij}^d(t). \quad (3-9)$$

と定義する。ここに、

$u_{ij}^d(t)$ = 時刻 t に目的地 d を持つ車両がセル i から $j \in C_d(i)$ に流出したい交通需要

$\pi_{ij}^d(t)$ = 時刻 t にセル i の目的地 d を持つ交通が、セル $j \in C_d(i)$ を選択する割合

= 目的地別の分岐率

$\pi_{ij}^d(t)$ の算定法は、次節で述べる。

以下に 2) の $r_{ij}(t)$ を定義する。 $r_{ij}(t)$ を考えなければいけない理由は、セル間の幾何構造によっては、1) の交通需要 $u_{ij}(t)$ がセル $j \in C_d(i)$ に流出できない場合があるからである。例えば、セル $j \in C_d(i)$ のひとつ上流に複数のセルが存在してセル j で合流が起こる場合には、上流セルの交通状態とセル間の幾何構造によって、実際に合流できる交通流率

が制限される場合がある。セル j の上流セルの集合を $C_u(j) = \{ \dots m \dots \}$ とすると、 $r_{ij}(t)$ は、 $u_{ij}(t)$ と上流セル m の幾何構造に依存する関数として、一般的に

$$r_{ij}(t) = f_{r_{ij}}(u_{mj}(t), m \in C_u(j)). \quad (3-10)$$

と書ける。本来であれば、実際の合流状況を加味して適切な $f_{r_{ij}}(u_{mj}(t), m \in C_u(j))$ を設定すべきであるが、本研究では簡単のため、最も単純な関数として、

$$r_{ij}(t) = u_{ij}(t). \quad (3-11)$$

を採用する。セル $j \in C_d(i)$ に流出できる総交通流率 $r_j(t)$ は、

$$r_j(t) = \sum_i r_{ij}(t) = \sum_i u_{ij}(t). \quad (3-12)$$

で表される。

次に 3)の $s_{ij}(t)$ の算定法を整理する。セル $j \in C_d(i)$ がセル i から受け入れができる交通流率 $s_{ij}(t)$ を求めるためには、まずセル $j \in C_d(i)$ が受け入れができるセル全体の交通流率 $S_j(t)$ を求める必要がある。この交通流率は、セル $j \in C_d(i)$ の交通状態に依存し、

$$S_j(t) = w_j(k_j^{jam} - k_j(t)) \quad (3-13)$$

と表される。セル $j \in C_d(i)$ に流入できる交通流率 $x_j(t)$ は、 $r_j(t)$ のうち受け入れ可能な $S_j(t)$ だけであるため、

$$x_j(t) = \min\{r_j(t), S_j(t)\}. \quad (3-14)$$

と書ける。 $x_j(t)$ を上流セル*i*別に分解すると、

$$x_{ij}(t) = x_j(t) \cdot r_{ij}(t) / r_j(t). \quad (3-15)$$

が得られる。なお、セル下流側に信号が設置されており、かつ時刻*t*の時に信号が赤現示の場合は、 $x_{ij}(t) = 0$ とする。 $x_{ij}(t)$ を目的地別に分解すると、

$$\begin{aligned} x_{ij}^d(t) &= x_{ij}(t) \cdot u_{ij}^d(t) / \sum_{d \in \Omega_D} u_{ij}^d(t) \\ &= x_j(t) \cdot (u_{ij}(t) / u_j(t)) \cdot (u_{ij}^d(t) / u_{ij}(t)) = x_j(t) \cdot u_{ij}^d(t) / u_j(t). \end{aligned} \quad (3-16)$$

が得られる。以上のように、 $k_i^d(t)$ から $x_{ij}^d(t), \forall d, i, j$ を決めることができ、これを交通量保存則の式(3-5)に代入すれば、時刻 $t+1$ におけるすべてのセルの交通密度 $k_i^d(t), \forall d, i$ を計算することができる。なお、式(3-6)から式(3-9)の計算過程において、全ての分岐セルでの目的地別の分岐率 $\pi_{ij}^d(t)$ が必要である。 $\pi_{ij}^d(t)$ の算定法は次節で述べる。時刻 t における $\pi_{ij}^d(t)$ の集合を、

$$\boldsymbol{\Pi}^D(t) = (\dots, \pi_{ij}^d(t), \dots)^T, \forall ij \in \Omega_{ij}. \quad (3-17)$$

と定義する。ネットワーク上の FD の諸量を \mathbf{F} と定義する。便宜上、 $\mathbf{K}_l^D(t)$, $\boldsymbol{\Pi}^D(t)$, \mathbf{F} を引数とした本節の交通流モデルの関数を $k_l^*(\cdot)$ と表記する。以上より、交通流モデルは、

$$k_i^d(t) = k_l^*(\mathbf{K}_l^D(t-1), \boldsymbol{\Pi}^D(t-1), \mathbf{F}). \quad (3-18)$$

と書ける。次節では、 $\pi_{ij}^d(t)$ を算定するための経路選択モデルを定式化する。

3.2.4 経路選択モデル

ネットワークの交通流では、前節で述べた交通流モデルの他に、利用者の経路選択行動を考慮する必要がある。すなわち、目的地別の分岐率 $\pi_{ij}^d(t)$ をネットワークの交通状態と関連付けてモデル化する必要がある。まず、 $\pi_{ij}^d(t)$ を定義する。 $\pi_{ij}^d(t)$ は時刻 t における交通状態 $\mathbf{K}_I^D(t)$ のみに依存すると仮定する。現在時刻の交通状態に基づいた経路選択モデルの1例を、Appendixに示すが、このほかにも様々なモデルが考えられる。分岐率 $\pi_{ij}^d(t)$ を算定する関数を $\pi_{ij}^{d*}(\cdot)$ と表記する。以上より、分岐率は、 $\pi_{ij}^{d*}(\cdot)$ を用いて、

$$\pi_{ij}^d(t) = \pi_{ij}^{d*}\left(\mathbf{K}_I^D(t)\right). \quad (3-19)$$

と書ける。分岐セルに隣接するセルの集合を Ω_{ij} と表記する。便宜上、 $\mathbf{K}_I^D(t)$ を引数とし、上式の操作を隣接セル $ij \in \Omega_{ij}$ に行い、 $\boldsymbol{\Pi}^D(t)$ を算定する関数を $\Pi^{D*}(\cdot)$ と表記する。以上より $\boldsymbol{\Pi}^D(t)$ は、

$$\boldsymbol{\Pi}^D(t) = \Pi^{D*}\left(\mathbf{K}_I^D(t)\right). \quad (3-20)$$

と書ける。プローブ車両からは、上記、目的地別の分岐率は、観測できず、セル間の分岐率のみ観測可能である。そのため、観測分岐率でモデルを評価するためには、モデル変数として、分岐率を定義する必要がある。したがって、セル i から下流セル j への分岐率 $\pi_{ij}(t)$ を定式化する。まず、時刻 t における $\pi_{ij}(t)$ の集合を、

$$\boldsymbol{\Pi}(t) = (\dots, \pi_{ij}(t), \dots)^T, \forall ij \in \Omega_{ij}. \quad (3-21)$$

と定義する。目的地別車両の分岐率 $\pi_{ij}^d(t)$ と前節で定義した交通流モデルの式(3-16)を組み合わせると、分岐率 $\pi_{ij}(t)$ は、

$$\begin{aligned}
\pi_{ij}(t) &= x_{ij}(t)/\sum_{j \in C_d(i)} x_{ij}(t) \\
&= [x_j(t) \cdot \{\sum_d u_{ij}^d(t)/\sum_{i,d} u_{ij}^d(t)\}] / [\sum_{j \in C_d(i)} x_j(t) \cdot \{\sum_d u_{ij}^d(t)/\sum_{i,d} u_{ij}^d(t)\}] \\
&= \frac{\min\{\sum_{i,d} (v_i \cdot k_i^d(t) \cdot \pi_{ij}^d(t)), w_j(k_j^{jam} - k_j(t))\} \cdot \{\sum_d (v_i \cdot k_i^d(t) \cdot \pi_{ij}^d(t)) / \sum_{i,d} (v_i \cdot k_i^d(t) \cdot \pi_{ij}^d(t))\}}{\sum_j [\min\{\sum_{i,d} (v_i \cdot k_i^d(t) \cdot \pi_{ij}^d(t)), w_j(k_j^{jam} - k_j(t))\} \cdot \{\sum_d (v_i \cdot k_i^d(t) \cdot \pi_{ij}^d(t)) / \sum_{i,d} (v_i \cdot k_i^d(t) \cdot \pi_{ij}^d(t))\}]}.
\end{aligned} \tag{3-22}$$

で表される。右辺中の $\pi_{ij}^d(t)$ は、式(3-19)より $\mathbf{K}_l^D(t)$ を引数とした関数から得られるので、分岐率 $\pi_{ij}(t)$ も $\mathbf{K}_l^D(t)$ を引数とした関数で書くことができる。したがって、 $\Pi(t)$ は、

$$\Pi(t) = \Pi^*(\mathbf{K}_l^D(t)). \tag{3-23}$$

と書ける。ここで、 $\Pi^*(\cdot)$ は、式(3-22)の操作を隣接セル $ij \in \Omega_{ij}$ に行い、 $\Pi(t)$ を算定する関数である。これまでに定式化した交通流モデル、経路選択モデルは確定的なモデルである。次節では、これを状態空間モデルに拡張する。

3.3 状態空間モデルの構築

本節では、3.2節で述べた交通流モデル、経路選択モデルを用いて状態空間モデルを定式化する。また、最後に状態空間モデルの計算アルゴリズムを整理し、モデルの計算量について議論する。

3.3.1 モデルの前提条件

(1) 状態ベクトル

本研究では、状態ベクトルとして、式(3-4)で示した目的地別の車両密度の集合ベクトル $\mathbf{K}_l^D(t)$ を定義する。

(2) 観測ベクトル

プローブ車両による観測変数として、時刻 t のセル i の観測車両密度 $\hat{k}_i(t)$ よびセル i から下流セル $j \in C_d(i)$ への観測分岐率 $\hat{\pi}_{ij}(t)$ を用いる。まず、 $\hat{k}_i(t)$ を定義する。時刻 t において、セル i を走行するプローブ車両速度 $\hat{v}_i(t)$ が観測されたことを考えよう。観測車両密度は、図 3-5 のようにプローブ速度 $\hat{v}_i(t)$ の傾きを持った直線とセル i の FD の接点から求める。なお、プローブ速度 $\hat{v}_i(t)$ が、 v_i 以上の自由流の場合は、FD 上では、密度が一意に決まらないため、便宜的に $k_i^c/2$ が観測される設定とした。以上よりプローブ速度をセルの車両密度に変換する式は、

$$\hat{k}_i(t) = \begin{cases} k_i^c/2 & , \text{if } \hat{v}_i(t) \geq v_i \\ w_i/(v_i^{ob} + w_i) \cdot k_i^{jam} & , \text{else} \end{cases} . \quad (3-24)$$

と書ける。時刻 t において車両密度が観測されたセルのインデックス集合を $\Omega_{i,o}(t) = \{ \dots, i, \dots \} \in \Omega_I$ と表記する。時刻 t ごとにプローブが観測されるセル数は異なるため、集合 $\Omega_{i,o}(t)$ のサイズは異なる。また、全てのセルで観測値が得られない場合もあるため、 $|\Omega_{i,o}(t)| \leq |\Omega_I|$ となる。以上より観測車両密度ベクトル $\hat{\mathbf{K}}_I(t)$ は、次元数 $|\Omega_{i,o}(t)|$ の

$$\hat{\mathbf{K}}_I(t) = (\dots, \hat{k}_i(t), \dots)^T, i \in \Omega_{i,o}(t). \quad (3-25)$$

と定義する。

次に観測分岐率を定義する。まず、時刻 t においてセル i から下流セル $j \in C_d(i)$ へ分岐したプローブ車両台数を観測分岐台数 $Z_{ij}(t)$ と定義する。図 3-6 のように時刻 t において、セル i から下流セルに分岐するプローブ車両が観測分岐車両である。この観測分岐台数を用いて、セル i から下流セル j への観測分岐率を、

$$\hat{\pi}_{ij}(t) = Z_{ij}(t) / \sum_{j \in C_d(i)} Z_{ij}(t). \quad (3-26)$$

と定義する。時刻 t において分岐台数が観測された隣接セルのインデックス集合を $\Omega_{ij,o}(t) = \{\dots, ij, \dots\}$ と表記する。時刻 t ごとに分岐台数が観測されるセル数は異なるため、集合 $\Omega_{ij,o}(t)$ のサイズは異なる。観測分岐率ベクトル $\hat{\Pi}(t)$ は、次元数 $|\Omega_{ij,o}(t)|$ の

$$\hat{\Pi}(t) = \{\dots, \hat{\pi}_{ij}(t), \dots\}^T, ij \in \Omega_{ij,o}(t). \quad (3-27)$$

と定義する。

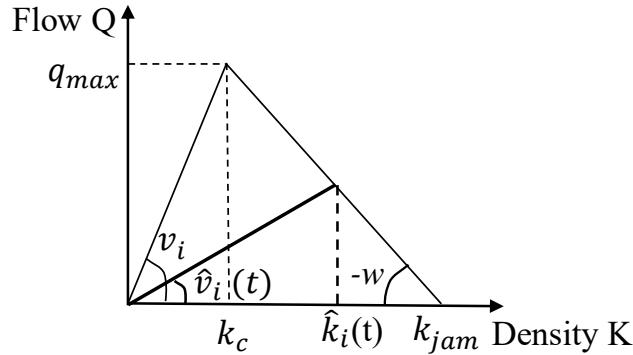


図 3-5 観測車両密度

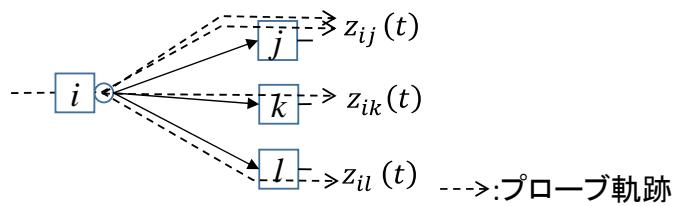


図 3-6 観測分岐台数

(3) 状態空間モデルの仮定

本節では、状態空間モデルの仮定を述べる。まず、本研究が仮定する状態空間モデルのグラフィカル表現を図 3-7に示す。同図に示す \mathbf{F} は FD の諸量であり、前述の通り所与とする。状態ベクトル $\mathbf{K}_I^D(t)$ は、マルコフ性を仮定する。図中の $\mathbf{K}_I^D(0)$ は、初期分布(確

率分布)である。同図に示すように、提案モデルでは、観測ベクトル、 $\hat{\mathbf{R}}_I(t)$ 、 $\hat{\mathbf{n}}(t)$ により $\mathbf{K}_I^D(t)$ の事後分布を求ることで、モデルの推定精度の改善を図る。

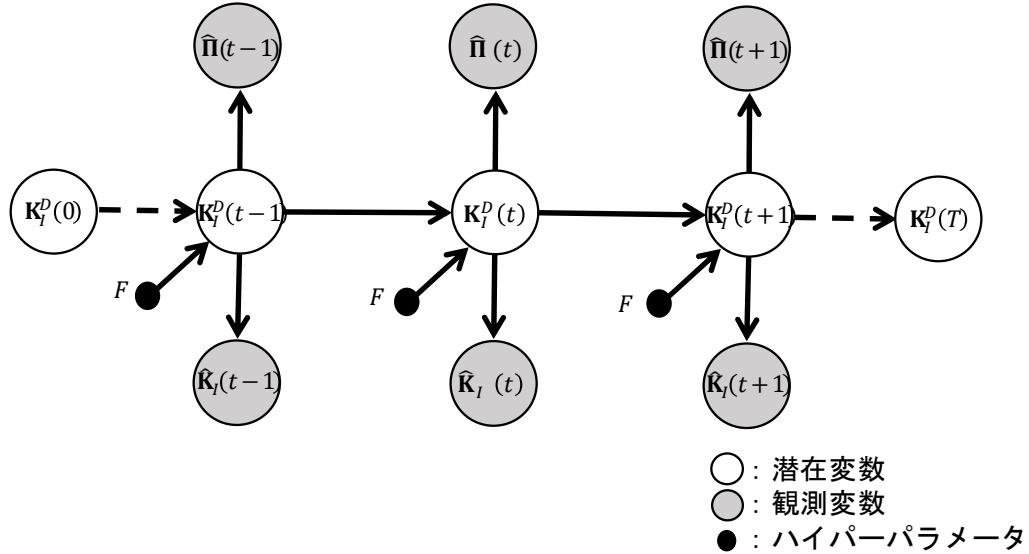


図 3-7 状態空間モデルのグラフィカル表現

3.3.2 システムモデルおよび観測モデル

本節では、前節の状態空間モデルの仮定に従い、システムモデル、観測モデルを定式化する。前述の状態空間モデルの仮定より、システムモデルを、

$$k_i^d(t) = k_i^*(\mathbf{K}_I^D(t-1), \Pi^D(t-1), \mathbf{F}) + \varepsilon_i^d(t), \quad \varepsilon_i^d(t) \sim p(\varepsilon_i^d(t)). \quad (3-28)$$

と定義する。ここで、

$\varepsilon_i^d(t)$ = 時刻 t のセル i における目的地 d を持つ交通密度のシステムノイズ

観測モデルは、前節で定義した観測密度、観測分岐率および状態空間モデルの仮定から、

$$\hat{k}_i(t) = \sum_d k_i^d(t) + \omega_i(t), \quad \omega_i(t) \sim p(\omega_i(t)). \quad (3-29)$$

$$\hat{\pi}_{ij}(t) = \pi_{ij}(t) + \eta_{ij}(t) = \pi_{ij}^*(\mathbf{K}_I^D(t)) + \eta_{ij}(t), \quad \eta_{ij}(t) \sim p(\eta_{ij}(t)). \quad (3-30)$$

と書ける。ここで、

$\omega_i(t)$ = 時刻 t , セル i の交通密度の観測ノイズ

$\eta_{ij}(t)$ = 時刻 t , セル i の分岐率の観測ノイズ

$\varepsilon_i^d(t)$ は、システムモデルのノイズであるが、システムモデルは交通流モデルと経路選択モデルから構成されており、その両者のノイズを合わせたものと考える。システムモデルは、交通流モデルと経路選択モデルを分離して次のように書くこともできる。

$$k_i^d(t) = k_i^{d*}(\mathbf{K}_I^D(t-1), \mathbf{\Pi}^D(t-1), \mathbf{F}) + \varepsilon_i^d(t). \quad (3-31)$$

$$\pi_{ij}^d(t) = \pi_{ij}^{d*}(\mathbf{K}_I^D(t)) + \gamma_{ij}^d(t). \quad (3-32)$$

上記、 $\varepsilon_i^d(t)$ は交通流モデルのシステムノイズ、 $\gamma_{ij}^d(t)$ は経路選択モデルのシステムノイズである。このように、それぞれのモデルのシステムノイズを個別に考慮することもできる。ただし、前述のように両モデルはともに $K_I^D(t)$ の関数なので、 $\varepsilon_i^d(t)$ と $\gamma_{ij}^d(t)$ は独立ではなく、相関のあるノイズの同時確率分布を考える必要がある。この場合、確率分布が複雑になるので、簡単のため、本定式化では、経路選択モデルにシステムノイズはないと仮定する。したがって、式(3-33)のようなシステムモデルとし、交通流モデルと経路選択モデルの両者を合わせたノイズ $\varepsilon_i^d(t)$ を扱うこととする。一方、 $\omega_i(t)$ と $\eta_{ij}(t)$ は、それぞれセル密度と分岐率の観測ノイズであるが、セル密度はプローブの速度から推定する観測値、分流部における分岐率はプローブの台数から推定する観測値であり、観測リソースが異なるため、独立と仮定する。システムノイズおよび観測ノイズの詳細は後述する。次節では、予測分布、事後分布の算定法を述べる。

3.3.3 予測分布および事後分布

(1) 予測分布

本節では、予測分布の算定法について述べる。時刻 $t-1$ の事後分布 $p(\mathbf{K}_I^D(t-1) | \hat{\mathbf{R}}_I(t-1), \hat{\boldsymbol{\Pi}}(t-1))$ が得られているとき、時刻 t の予測分布は、下記の式に従って算定すればよい。

$$\begin{aligned} & p(\mathbf{K}_I^D(t) | \hat{\mathbf{R}}_I(t-1), \hat{\boldsymbol{\Pi}}(t-1)) \\ &= \int \left\{ p(\mathbf{K}_I^D(t) | \mathbf{K}_I^D(t-1)) \times p(\mathbf{K}_I^D(t-1) | \hat{\mathbf{R}}_I(t-1), \hat{\boldsymbol{\Pi}}(t-1)) \right\} d\mathbf{K}_I^D(t-1) . \quad (3-33) \end{aligned}$$

上式の右辺の $p(\mathbf{K}_I^D(t) | \mathbf{K}_I^D(t-1))$ は、システムモデルの出力結果である。

(2) 事後分布

本節では、事後分布を定義する。事後分布は、観測値 $\hat{\mathbf{R}}_I(t), \hat{\boldsymbol{\Pi}}(t)$ が得られた場合の目的地別車両密度の確率分布 $p(\mathbf{K}_I^D(t) | \hat{\mathbf{R}}_I(t), \hat{\boldsymbol{\Pi}}(t))$ と定義する。セルの車両密度に関するフィルタリングの概念を図 3-8 に示す。同図と 3.3.1 節の状態空間モデルの仮定から、事後分布は、

$$\begin{aligned} & p(\mathbf{K}_I^D(t) | \hat{\mathbf{R}}_I(t), \hat{\boldsymbol{\Pi}}(t)) \\ &= p(\hat{\mathbf{R}}_I(t), \hat{\boldsymbol{\Pi}}(t) | \mathbf{K}_I^D(t)) \cdot p(\mathbf{K}_I^D(t)) / \sum_{I', D'} p(\hat{\mathbf{R}}_{I'}(t), \hat{\boldsymbol{\Pi}}(t) | \mathbf{K}_{I'}^{D'}(t)) \cdot p(\mathbf{K}_{I'}^{D'}(t)) . \quad (3-34) \end{aligned}$$

と書ける。観測ノイズ $\omega_i(t), \eta_{ij}(t)$ は独立と仮定しているため、上式は、

$$\begin{aligned} & p(\mathbf{K}_I^D(t) | \hat{\mathbf{R}}_I(t), \hat{\boldsymbol{\Pi}}(t)) \\ &= p(\hat{\mathbf{R}}_I(t), \hat{\boldsymbol{\Pi}}(t) | \mathbf{K}_I^D(t)) \cdot p(\mathbf{K}_I^D(t)) / \sum_{I', D'} p(\hat{\mathbf{R}}_{I'}(t), \hat{\boldsymbol{\Pi}}(t) | \mathbf{K}_{I'}^{D'}(t)) \cdot p(\mathbf{K}_{I'}^{D'}(t)) \\ &\propto p(\hat{\mathbf{R}}_I(t), \hat{\boldsymbol{\Pi}}(t) | \mathbf{K}_I^D(t)) \cdot p(\mathbf{K}_I^D(t)) \end{aligned}$$

$$\begin{aligned}
&= p(\hat{\mathbf{K}}_I(t) \mid \mathbf{K}_I^D(t)) \cdot p(\hat{\Pi}(t) \mid \mathbf{K}_I^D(t)) \cdot p(\mathbf{K}_I^D(t)) \\
&= p(\hat{\mathbf{K}}_I(t) \mid \mathbf{K}_I^D(t)) \cdot p(\hat{\Pi}(t) \mid \Pi^*(\mathbf{K}_I^D(t))) \cdot p(\mathbf{K}_I^D(t)). \tag{3-35}
\end{aligned}$$

と表せる。上式を使って、 $\mathbf{K}_I^D(t)$ の要素に対して、事前分布 $p(\mathbf{K}_I^D(t))$ が、事後確率 $p(\mathbf{K}_I^D(t) \mid \hat{\mathbf{K}}_I(t), \hat{\Pi}(t))$ にフィルタリングされる。上式より、本モデルでは、一括して全体のセルの事後分布を求めているため、交通流モデルの交通量保存則は満たされる。

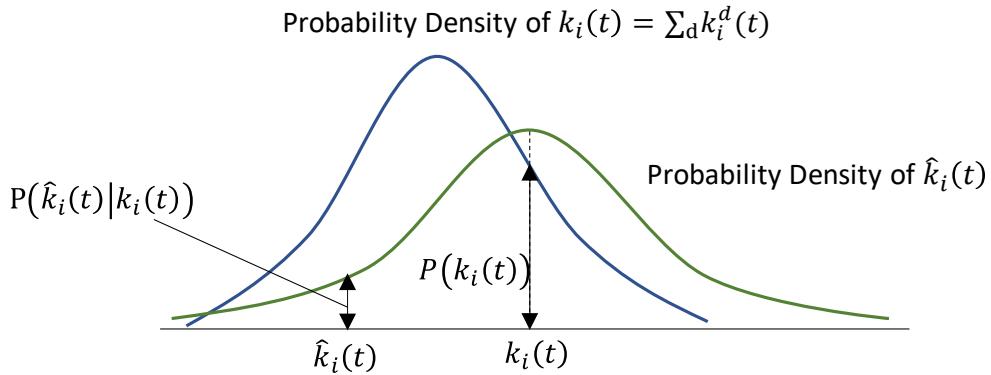


図 3-8 フィルタリングの概念図

3.4 事後分布の推定方法

提案モデルでは、パーティクルフィルタ³⁾により $\mathbf{K}_I^D(t)$ の事後分布を求める。パーティクルフィルタとは、時系列フィルタの一つで、事前分布や事後分布(条件付き分布)を多数のパーティクル(サンプル)でモンテカルロ近似表現するものである。パーティクルフィルタは、システムモデルや観測モデルが非線形な場合やノイズが非ガウスの場合であっても事後分布を算定可能といった特徴を持つ。パーティクルフィルタの概要を図 3-9 に示す。同図に示すように、パーティクルフィルタは、「初期分布」、「予測」、「尤度計算」、「リサンプリング」の 4 ステップに分けられる。各ステップの処理概要

を以下に述べる。「初期分布」では、シミュレーション時の初期分布として、N個のパーティクルを生成する。「予測」では、システムモデルにより、一期先の状態を予測する。「尤度計算」では、観測モデルに対応する尤度関数により、各パーティクルの重み（尤度）を算定する。「リサンプリング」では、パーティクルの重みに応じて、パーティクルをN個復元抽出（リサンプリング）し、事後分布を近似する。

パーティクルフィルタによる提案モデルの計算アルゴリズムを述べる。提案モデルでは、最初に、初期分布として、N個のOD交通密度を生成する。このOD交通密度の集合を $\{\langle \mathbf{K}_I^D(0) \rangle^{(n)}\}_{n=1}^N = (\langle \mathbf{K}_I^D(0) \rangle^{(1)}, \langle \mathbf{K}_I^D(0) \rangle^{(2)}, \dots, \langle \mathbf{K}_I^D(0) \rangle^{(N)})$ と表記する。 $\langle \mathbf{K}_I^D(0) \rangle^{(n)}$ は、n番目の状態ベクトルを示す。このOD交通密度がネットワークを進むうちに観測密度 $\hat{R}_I(t)$ と観測分岐率 $\hat{\Pi}(t)$ を用いたフィルタリングにより、Nパターンそれぞれの重み（数）が変化し、 $\{\langle \mathbf{K}_I^D(0) \rangle^{(n)}\}_{n=1}^N$ の更新を図る（経路選択モデル自体を同定するものではない）。状態空間モデルのアルゴリズムを図3-10に示す。アルゴリズムを元に、状態空間モデルの計算量について議論する。以下では、計算量は、基本命令回数に等しいとして議論を進める。図3-10に示すように、状態空間モデルでは、一度だけstep 0の処理を行い、その後、step 1～step 3の処理を各々N回実行する。計算量の負荷に大きく関与するのは繰り返し処理のため、1タイムステップあたりの基本命令回数を、step 1～step 3の命令回数3N回と定義する。この処理が総タイムステップ数、T回だけ繰り返し処理されるため、基本命令数の総数は $T \times 3N$ 回となる。これを、O記法（ビッグオー）で整理すると、計算量は、 $T \times 3N \rightarrow n \times 3n \approx O(n^2)$ となる。したがって、タイムステップもしくは、パーティクル数増加に伴い、指数関数的に計算量が増加する。この他、step 2の経路選択モデル、経路選択モデルは、ネットワーク規模（ノード数、リンク数）により、処理負荷が増大する。そのため、計算実行可否の観点では、対象のネットワーク規模に留意しつつ、マシン性能を見据えて、パーティクル数Nや総タイムステップ数Tを設定する必要がある。

なお、上記アルゴリズムを疑似コードで整理したものを Appendix 2 に整理する。

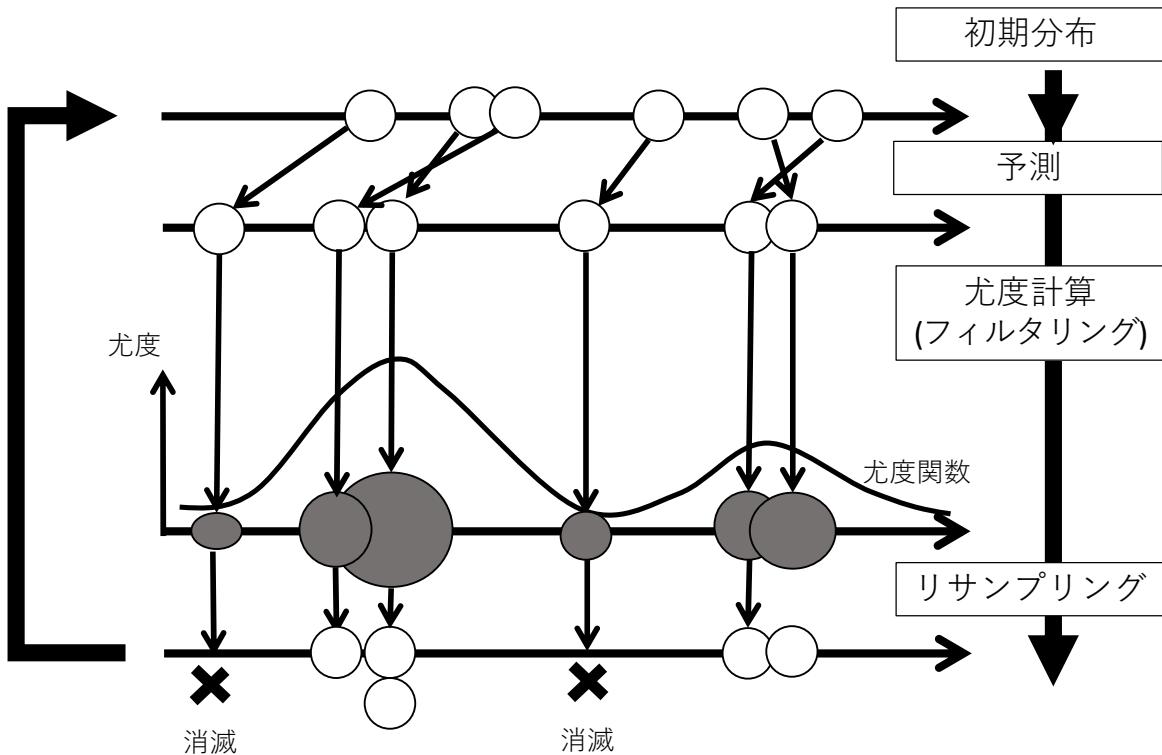


図 3-9 パーティクルフィルタ

Algorithm パーティクルフィルタによる状態空間モデルの計算

Input ネットワーク情報（リンク，ノード），セル長，システムノイズおよび観測ノイズパラメータ，Fundamental diagram の諸量，パーティクル数 N

step 1 初期分布 (t=0)

- セルネットワークの生成，およびシステムノイズ，観測ノイズの確率分布設定
- システムノイズの確率分布に従い，N 個の交通需要 $\{\langle \mathbf{K}_I^D(0) \rangle^{(n)}\}_{n=1}^N$ を生成

step 2 予測

- 経路選択モデル（式(3-19)）と交通流モデル（式(3-18)）を N 回実行し，一期先の $\{\langle \mathbf{K}_I^D(t) \rangle^{(n)}\}_{n=1}^N$ を予測

step 3 尤度算定

- パーティクルごとに尤度を算定(N回処理を実行)し，各パーティクルの重みを設定

step 4 リサンプリング

- 各パーティクルの重みに応じて，パーティクルを N 個復元抽出 (N 回処理を実行)

Step 5 タイムステップの更新

- $t=t+1$ とし，シミュレーション終了まで，**step 1～step 4** を繰り返す。

図 3-10 状態空間モデルの計算アルゴリズム

3章の参考文献

- 1) Daganzo, C.F. : The cell transmission model, part II : network traffic, Transportation Research Part B : Methodological, Vol. 29(2), pp. 79-93, 1995.
- 2) 土木学会 土木計画学研究委員会：交通ネットワークの均衡分析—最新の理論と解法，丸善，1998。
- 3) Kitagawa, G.: Monte Carlo Filter and Smoother for Non-Gaussian Nonlinear State Space Models, Journal of Computational and Graphical Statistics, Vol. 5, No. 1, pp. 1-25, 1996.

◆本章は、下記の論文を基に加筆・修正し、執筆したものである。

- (1) Kawasaki, Y., Hara, Y., Kuwahara, M. : Real-Time Traffic State Estimation on a Two-dimensional Network by State Space Model, The 23nd International Symposium on Transportation and Traffic Theory, Lausanne, Switzerland, Jul, 2019. [投稿中]
- (2) Kawasaki, Y., Hara, Y., Kuwahara, M. : A study of traffic state estimation by data assimilation in two-dimensional networks, 7th International Conference on Transport Network Reliability, Sydney, Australia, Jan, 2018. [accepted]
- (3) 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, Vol.73, 2017.
- (4) 川崎洋輔, 原祐輔, 桑原雅夫：二次元ネットワークにおけるデータ同化による交通状態推定に関する研究, 土木計画学研究・講演集, Vol.55, CD-ROM, 2017.
- (5) Kawasaki, Y., Hara, Y., Kuwahara, M. : Real-Time Traffic State Estimation on A Two-Dimensional Network by The State-Space Model, 21st HKSTS International Conference, Hong Kong, China, December 2016.
- (6) Kawasaki, Y., Hara, Y., Kuwahara, M. : Construction of real-time traffic state estimation method of a two-dimensional network by data assimilation, ASIA-PACIFIC ECONOPHYSICS CONFERENCE 2016 - Big Data Analysis and Modeling toward Super

Smart Society - (APEC-SSS 2016), Tokyo, Japan, August,2016.

- (7) 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, 土木計画学研究・講演集, Vol.54, CD-ROM, 2016.
- (8) 川崎洋輔, 原祐輔, 桑原雅夫: 状態空間モデルによる交通状態推定手法の二次元ネットワークへの拡張, 土木計画学研究・講演集, Vol.53, CD-ROM, 2016.

第4章 双子実験によるモデル検証

本章では、第3章で定式化した交通状態推定モデルの性能検証を行う。モデル検証は、双子実験¹⁾の枠組みで実施する。双子実験の詳細は、後述する。

4.1 双子実験の概要

本節では、モデル性能の検証方法を述べる。モデルの妥当性検証には、モデルの推定精度を比較検証するための状態ベクトルの真の状態が必要である。しかしながら、状態ベクトルを直接観測することが出来ない。そこで、状態空間モデルでは、この問題に対して、双子実験¹⁾と呼ばれる手法を用いた検証が行われている。

双子実験の内容を図4-1に示す。まず始めに、初期条件、境界条件、モデルパラメータなどを設定してシミュレーションモデルで計算を行い、その結果を“真値”と仮定する。時刻 t の“真値”を \mathbf{x}_t^{true} と表記する。次に、初期条件、境界条件、モデルパラメータなどを全てまたは一部を真値から変更してモデル計算を行い、その結果を“シミュレーション値”とする。時刻 t の“シミュレーション値”を \mathbf{x}_t と表記する。観測値は“真値”的一部から観測に相当する物理量を抽出し、作成する。時刻 t の観測値を \mathbf{y}_t と表記する。そして、この観測値 \mathbf{y}_t を“シミュレーション値” \mathbf{x}_t に同化して、結果を“真値” \mathbf{x}_t^{true} と比較して精度検証を行う。

本研究では、上記の双子実験の手法を踏襲してモデル検証を行う。具体的には、交通シミュレーションにより生成したベンチマークデータを真値として用いて状態空間モデルの推定値と比較検証を行う。

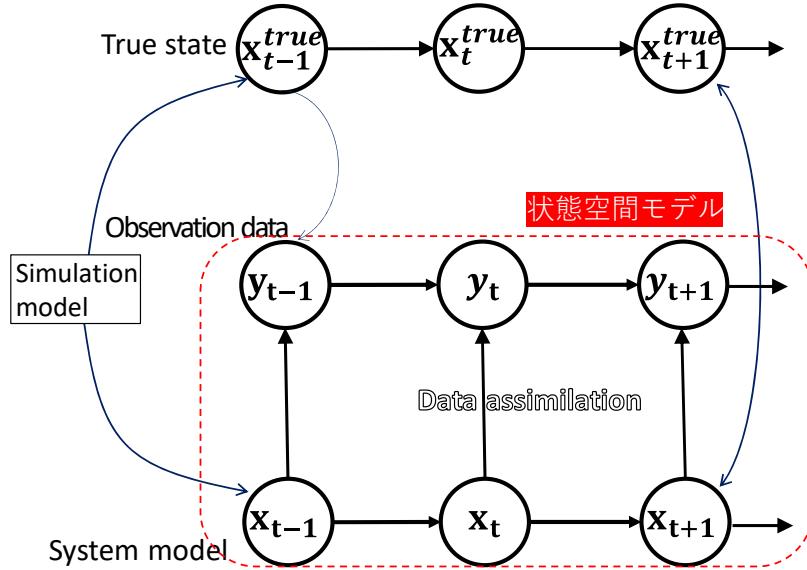


図 4-1 双子実験の概要

4.2 モデル検証条件

4.2.1 交通シミュレーション概要

本節では、双子実験で用いる真値生成のための交通シミュレーションモデルの内容を述べる。シミュレーションモデルは、状態空間モデルと同様のCTM²⁾および経路選択モデルを用いた。モデルの詳細は、3.2節を参照されたい。シミュレーションに、タイムステップごとのOD交通量を入力し、真値とする交通状況を生成した。真値生成に用いたなお、シミュレーション中に個々の車両がどのセルにいるか判別するため、入力するOD需要の個々の車両には、固有のIDを付与して逐次、車両位置を管理した。シミュレーションの経路選択モデルは、ロジットモデル³⁾を用いた。ロジットモデルによる起終点*i,d*間の経路*r*の選択確率 $p^r(t)$ は、3章で定義した*i,d*間の経路集合 $\Omega_R(i,d)$ 、時刻*t*における経路*r*の所要時間 $T^r(t)$ を用いて、

$$p^r(t) = \exp\{-\theta \cdot T^r(t-1)\} / \sum_{r \in \Omega_R(i,d)} \exp\{-\theta \cdot T^r(t-1)\}. \quad (4-1)$$

と定義される。上式の θ は、ロジットモデルのパラメータであり、本検証では、所与（ θ

=0.1) とする.

4.2.2 システムノイズおよび観測ノイズの仮定

本研究で仮定するシステムノイズおよび観測ノイズを以下に示す.

$$\rho = \frac{\text{Uniform}(x)}{v_i}, \quad (4-2)$$

$$\varepsilon_i^d(t) = \rho/T, a \leq x \leq b, \forall i \in \Omega_o. \quad (4-3)$$

s.t. x, a, b : 自然数

$$\omega_i(t) \sim N(0, \sigma_\omega^2), \forall i \in \Omega_{i,o}(t). \quad (4-4)$$

$$\eta_{ij}(t) \sim N(0, \sigma_\eta^2), \forall ij \in \Omega_{ij,o}(t). \quad (4-5)$$

式(4-2)の $\text{Uniform}(x)$ は、区間 $[a, b]$ 上の一様分布を返す関数を示す. a, b はパラメータである. $\omega_i(t), \eta_{ij}(t)$ は、上式のとおり独立な正規分布ノイズを仮定する. 正規分布の分散 $\sigma_\omega^2, \sigma_\eta^2$ は、パラメータである. Ω_o は需要が発生するセルのインデックス集合である.

4.2.3 シミュレーション条件

本節では、シミュレーション条件を述べる. 本検証では、OD 需要の異なる 2 ケースの数値実験を行った. 表 4-1 に検証に用いる真値と状態空間モデルの設定の一覧を示す. 同表に示すように真値と状態空間モデルの設定の違いは、入力する OD 需要と観測値を用いているか否かである.

シミュレーションの設定条件を以下に整理する. まず、シミュレーションネットワークを図 4-2 に示す. 同図に示すようにネットワークはダイヤモンド型の左右対称の形状とし、各ノード(交差点)には信号が設置されている. ノードの傍にある数字は、ノード番号である. 以降、ノード番号 n のものはノード n と表記する. 真値および状態空間モデルに共通するシミュレーション条件を表 4-2 に示す. シミュレーション時間は 1 時間とし、同表に示す条件でシミュレーションを実施した. 状態空間モデルのみの条件を表 4-3 に示す. 同表に示すように、モデルで用いる観測密度と分岐率の観測

間隔(=フィルタリングのタイムステップ)は異なる。次に、OD 需要の設定について述べる。真値生成に用いた OD 需要是、表 4-2 に示すように、起点をノード 1, ノード 4, 終点をノード 5, ノード 8 とした 2 ケース設定した。タイムステップごとの OD 需要是、一様分布で発生させた。対して、状態空間モデルの OD 需要是、表 4-3 に示すように、真の OD 需要が含まれる区間において、一様分布に従って、ランダム発生させた。プローブデータは、真値（全車両）の中から予め設定した抽出率に従って、ランダム抽出して生成した。生成したケース別のプローブ車両台数を表 4-6 に示す。同表に示すように、プローブ車両の抽出率は、各ケースとも約 3%とした。初期 $t=0$ には、式(4-2)により、N パターンの OD 交通密度を生成し、それを初期分布とした。N はパーティクル数であり、本検証では、N=2,000 とした。提案モデルの性能検証のために、以下に示す観測変数の異なる 3 種類の状態空間モデルを比較・評価した。

- ① 提案モデル : 観測車両密度および観測分岐率を使用
- ② 車両密度評価 : 観測車両密度のみ使用(分岐率は観測されないと仮定)
- ③ 分岐率評価 : 観測分岐率のみ使用(車両密度は観測されないと仮定)

上記、②、③は、過去に筆者らが提案したモデルである。詳細は参考文献⁵⁾を参照されたい。次節より、双子実験によるモデルの検証結果を述べる。

表 4-1 真値と状態空間モデルの設定条件の比較

設定項目	真値	状態空間モデル
ネットワーク条件	ダイヤモンド型（図 4-2）	同左
シミュレーションモデル	交通流モデル(CTM), 経路選択モデル	同左
モデルパラメータ	真のパラメータ（表 4-2）	同左
OD 需要	真の OD 需要（表 4-4）	偽の OD 需要（表 4-6）
観測値	使用しない	プローブ車両を使用

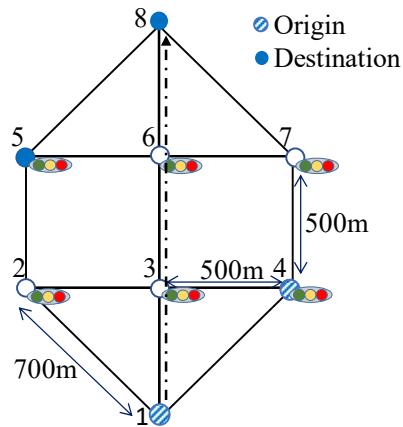


図 4-2 シミュレーションネットワーク

表 4-2 シミュレーション条件[真値, 状態空間モデル共通]

項目	設定値
シミュレーション時間	1時間
信号機	6基, 2現示 ノード 2-4 …青 : 100秒, 赤 : 20秒 ノード 5-7 …青 : 70秒, 赤 : 50秒
セル長 Δx	50m
タイムステップ Δt	4.0秒
FDパラメータ(全セル共通)	$v_i: 40\text{km/h}, w_i: 10\text{km/h}, q_i^{max}: 1,500\text{veh/h}$
ロジットモデルのパラメータ θ	0.1

表 4-3 シミュレーション条件[状態空間モデル]

項目	設定値	
車両密度観測間隔	4.0秒	
分岐率観測間隔	1分	
システムノイズパラメータ	a, b	別表参照
	σ_ε^2	0.5
観測ノイズパラメータ	σ_ω^2	2.0
	σ_η^2	0.2
パーティクル数	2,000	

表 4-4 OD 需要の設定条件[真値]

ケース	起点ノード	終点ノード	OD需要(veh/h)
ケース 1	1	8	1,500
	4	5	1,500
		計	3,000
ケース 2	1	5	1,500
	1	8	1,500
	4	5	1,500
	4	8	1,500
		計	6,000

表 4-5 プローブ車両台数

	プローブ車両台数	抽出率
ケース 1	100 veh/h	約 3% ($\approx 100/3,000$)
ケース 2	200 veh/h	約 3% ($\approx 200/6,000$)

表 4-6 OD 需要の設定条件(状態空間モデル)

ケース	起点ノード	終点ノード	OD需要(veh/h)
ケース 1	1	8	800~2,200台/時でランダム発生 (a= 800, b=2,200)
	4	5	800~2,200台/時でランダム発生 (a= 800, b=2,200)
ケース 2	1	5	800~2,200台/時でランダム発生 (a= 800, b=2,200)
	1	8	800~2,200台/時でランダム発生 (a= 800, b=2,200)
	4	5	800~2,200台/時でランダム発生 (a= 800, b=2,200)
	4	8	800~2,200台/時でランダム発生 (a= 800, b=2,200)

4.3 モデル検証結果

4.3.1 経路選択の推定精度検証

本節では、提案モデルの経路選択の推定精度検証の指標および検証結果について述べる。

(1) 評価指標の定義

経路選択の評価は、分岐セルから下流セルへの選択確率を用いた平均対数尤度で評価することとした。セル i とその下流セル j を考える。本モデル検証では、シミュレーション後、時刻 t のモデルによる推定分岐率 $\pi_{ij}(t)$ と交通シミュレーションにより生成された真の分岐率 $\pi_{ij}^{true}(t)$ が得られている。上記と参考文献⁵⁾より、時刻 t のセル i におけるモデルの推定分岐率を評価する対数尤度 $l_i(t)$ を

$$l_i(t) = \sum_j \left\{ \pi_{ij}^{true}(t) \times \log(\pi_{ij}(t)) \right\}, \forall i \in C_I, j \in C_d(i). \quad (4-6)$$

と定義する。この対数尤度の値が 0 に近いほどモデルは、真のモデルに近い(モデル精度が良い)とみなされる。上式より、時刻 $t_1 \sim t_2$ 間の平均対数尤度 $\bar{l}_I(t)$ は、

$$\bar{l}_I(t) = \sum_{t=t_1}^{t_2} (\sum_i l_i(t) / |C_I|) / (t_2 - t_1), \forall i \in C_I. \quad (4-7)$$

と書ける。以降の検証では、この平均対数尤度を用いる。

(2) 検証結果

図 4-3 および図 4-4 に時刻 1 ~ T(シミュレーション時間)における起点から下流セルのケース別の平均対数尤度を示す。同図の縦軸は、平均対数尤度、横軸はモデル名を示す。同図を見ると、ケース 1, 2 ともに①提案モデルの対数尤度が最も 0 に近く、次いで③分岐率評価となっている。以上より、観測分岐台率は、モデルの経路選択(分岐率)の改善に寄与すること、ならびに分岐率に車両密度もあわせて評価した方がより経路選択が改善されると推察される。ケース間を比較すると、ケース 1 の方が対数尤度が小さい傾向にある。これは、ケース 2 の方が、OD 需要のパターン数が多いため、と推察される。経路選択の改善率は、OD 需要の設定やプローブデータの設定(ランダ

ムに抽出するか、プローブの台数を何台に設定するか等)に影響を受けるため、モデル間の比較・評価結果の妥当性を評価するためには、今後、プローブデータの設定を変えた様々なパターンでの検証が必要と考える。

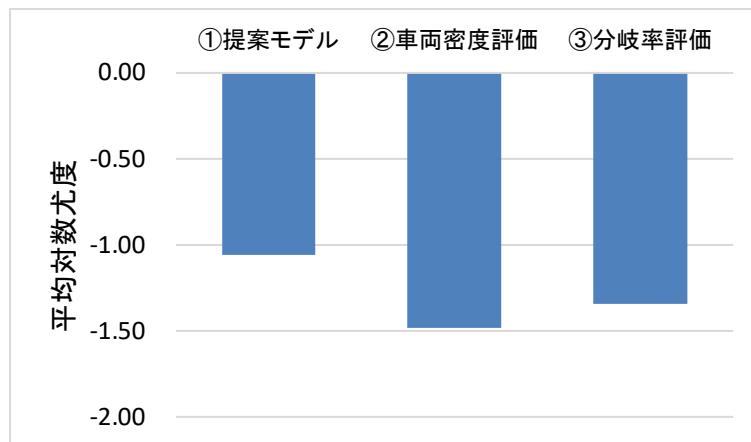


図 4-3 平均対数尤度の比較[ケース 1]

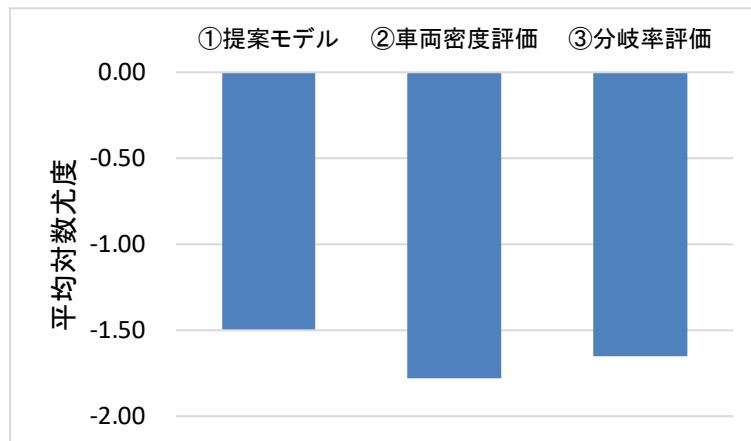


図 4-4 平均対数尤度の比較[ケース 2]

4.3.2 渋滞推定精度の評価

本節では、提案モデルの渋滞推定精度検証の評価指標および評価結果について述べる。

(1) 評価指標の定義

渋滞推定精度の評価は、

- Precision(適合率)と Recall(再現率)および F 値(F-measure)
- 渋滞発生状況図

を用いる。Precision と Recall は情報検索の有効性を示す評価指標として使われている。Precision は検索結果(モデルによる推定結果)に適合データ(正解)がどれだけ含まれるかを示す適合率である。Recall は、適合データ全体のどれだけが検索結果(推定結果)に含まれているかを示すものである。そして Precision と Recall の調和平均が、F 値である。一般に、Precision と Recall は、トレードオフの関係にある。そして F 値が高ければ、モデルの性能が良いことを意味する⁶⁾。

本研究での Precision とは、モデルが渋滞と推定した中で、実際も渋滞となっているものの割合とする。Recall とは、実際に渋滞が発生している場所の中で、モデルが渋滞と推定しているものの割合と定義する。ここでは、メッシュ速度を対象に速度 20km/h 未満を渋滞として評価を行った。Precision, Recall 算定にあたって、実際の渋滞状況とモデルで推定された渋滞の関係を表 4-7 のように定義する。表 4-7 の内容を踏まえ、Precision と Recall および F 値の算定方法を以下に示す。

$$Precision = TP / (TP + FP), \quad (4-8)$$

$$Recall = TP / (TP + FN), \quad (4-9)$$

$$F\text{値} = (2 \times Precision \times Recall) / (Precision + Recall). \quad (4-10)$$

ここで、 TP, FP, FN は表 4-7 の関係に該当するメッシュ数である。なお、上記定義より $0 \leq$ 適合率 ≤ 1 と $0 \leq$ 再現率 ≤ 1 であることから、 $0 \leq F\text{値} \leq 1$ となる。

表 4-7 実際の渋滞状況とモデルの推定結果の関係

		真値(実際の渋滞状況)	
		渋滞	非渋滞
推定値 (モデル)	渋滞	TP (True Positive)	FP(False Positive)
	非渋滞	FN (False Negative)	TN(True Negative)

※セルの平均速度 20km/h 未満を渋滞と定義

(2) 検証結果

図 4-5および図 4-6にケース別のPrecision, Recall, F値の算定結果を示す。同図を見ると、ケース1,2とともに全ての指標で、①提案モデルが最も高く、次いで、②車両密度評価となっている。これは、車両密度は、渋滞推定精度改善に有効であること、および車両密度と分岐率をあわせて評価した方がより渋滞推定精度が改善されると考えられる。提案モデルの精度が高い理由は、観測分岐率による経路選択と観測車両密度によりセルの車両密度(状態量)の両方が改善されるためと推察される。ケース1とケース2を比較すると、ケース1の方が、いずれのモデルもF値が高い。次に、渋滞推定状況の一例として、図 4-2に示す特定経路のタイムスペース図を分析した。ケース1の他0無スペース図を図 4-7およびケース2のタイムスペース図を図 4-8に示す。同図の色は、セルの平均速度を示す。ケース1(図 4-7)を見ると、プローブデータのみ(最下段)では、未観測箇所の交通状態が不明であるが、状態空間モデルでは、全箇所の交通状態が補完推定されている。また、提案モデルの渋滞状況が最も真値と類似しており、渋滞推定精度が高い状況が確認される。これは、前述したF値と同傾向である。ケース2(図 4-8)を見ると、提案モデルの渋滞状況が最も真値と類似しており、ケース1と同傾向である。しかしながら、ケース1に比べて、真値と提案モデルの渋滞状況が乖離している状況が見受けられる。この要因を分析するために、OD需要分布の事後分布を分析した。ケース1のOD需要の確率分布を図 4-9、ケース2のOD需要の確率分布を図 4-10に示す。図4-9のケース1のOD需要の確率分布のグラフの横軸は、OD需要量、縦軸は発生確率となっている。なお、発生確率は、全パーティクルに占めるOD需要量別のパーティクル数により算定した。同図には、t=0の初期分布および事後分布(t=3,600sec)の2ODペアのOD需要分布を可視化している。同図を見ると、初期のt=0では、OD需要はランダムに一様発生させているため、確率分布は平坦となっている。事後分布は、顕著に真値(1,500台/時)付近の確率が高い。以上より、観測されるプローブデータ(車両密度、分岐率)によりOD需要パターンが更新され、真値に近づいていると考えられる。次に、ケース2のOD需要の確率分布を図 4-10、図 4-11に示す。同図は、起点別にOD需要の確

率をヒートマップで可視化しており、灰色が濃いほうが、発生確率が高い状況を示している。ヒートマップの横軸は、終点ノード8へのOD需要量、縦軸は、終点ノード8へのOD需要量となっており、図中にある赤枠は、真値（真のOD需要）を示している。図の最上段は、初期分布($t=0$)、中段は中間時($t=1800$)、下段は、事後分布($t=3600$)を示している。起点ノード1(図 4-10)を見ると、時間進展に伴い真値近傍の発生確率が高くなっている。一方、起点ノード4(図 4-11)を見ると、事後分布において真値と発生確率の高い箇所が乖離している。よって、ケース2の渋滞推定精度が低い理由は、OD需要分布が真値と乖離しているためと思われる。この乖離の理由は、現状、モデルで評価している分岐率では、真のOD需要が特定できない（OD需要パターンによっては、同じ分岐率のパターンが複数存在する）場合があるためと推察される。したがって、OD需要をモデル化し、制約を付与して答えを絞り込むことが課題と考える。また、本モデルの精度は、OD需要の初期分布の精度に依存するため、初期分布の設計方法も課題と考える。その理由は、真値と乖離した初期分布を設定しても真の交通状態に近いものは得られないためである。

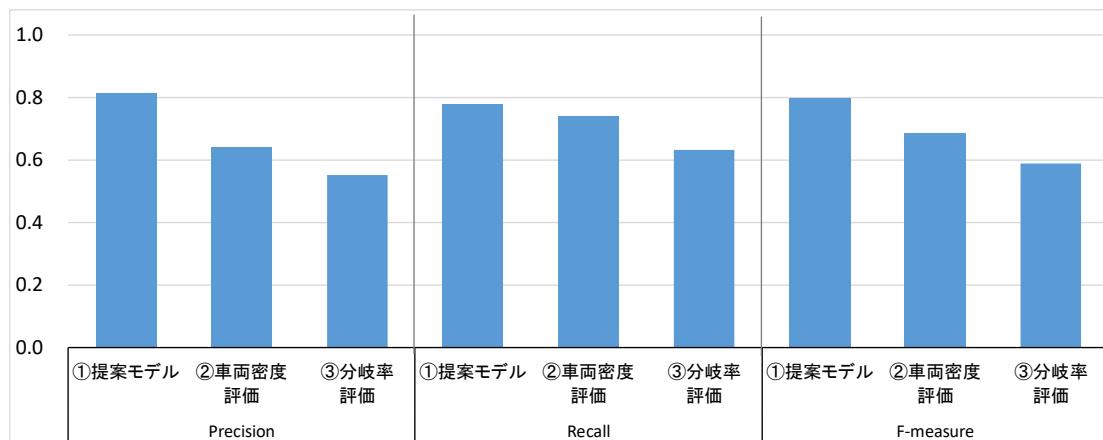


図 4-5 Precision, Recall, F値の比較[ケース1]

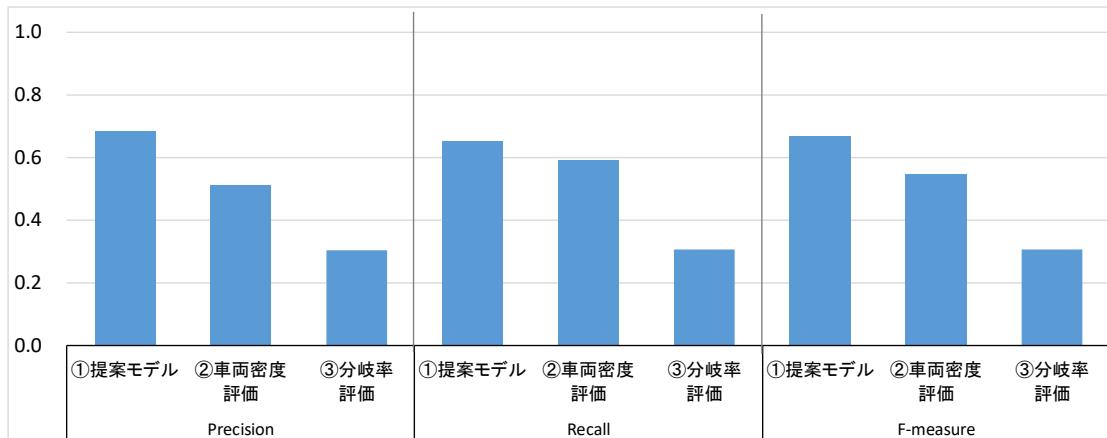


図 4-6 Precision, Recall, F値の比較[ケース2]

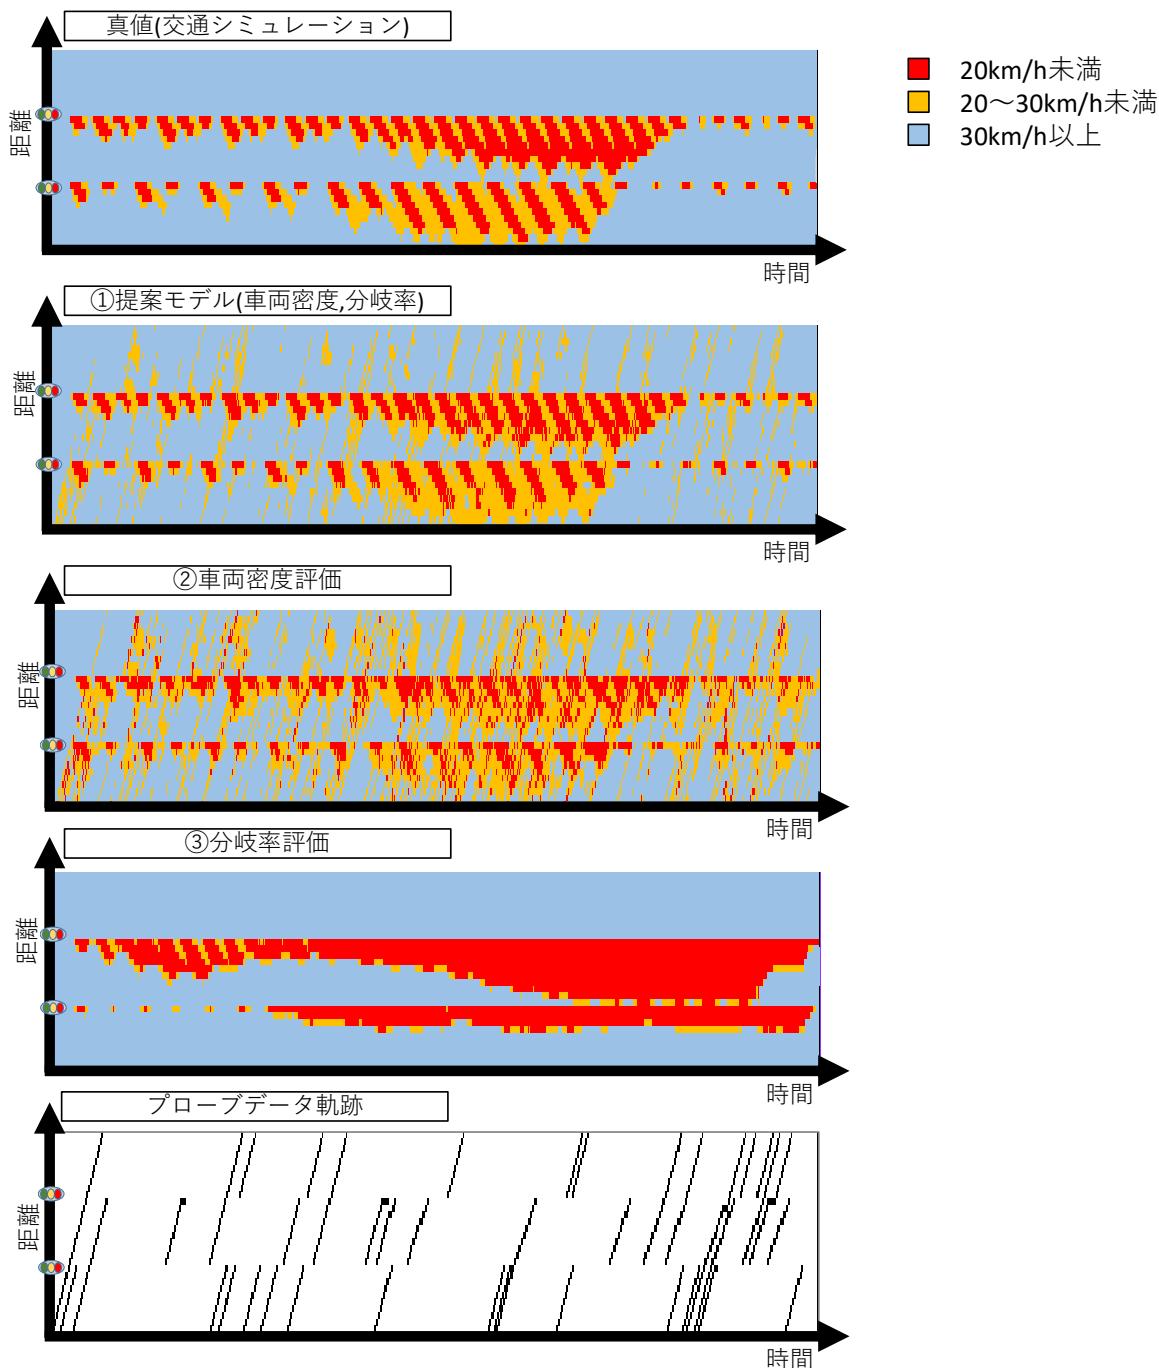


図 4-7 タイムスペース図[ケース 1]

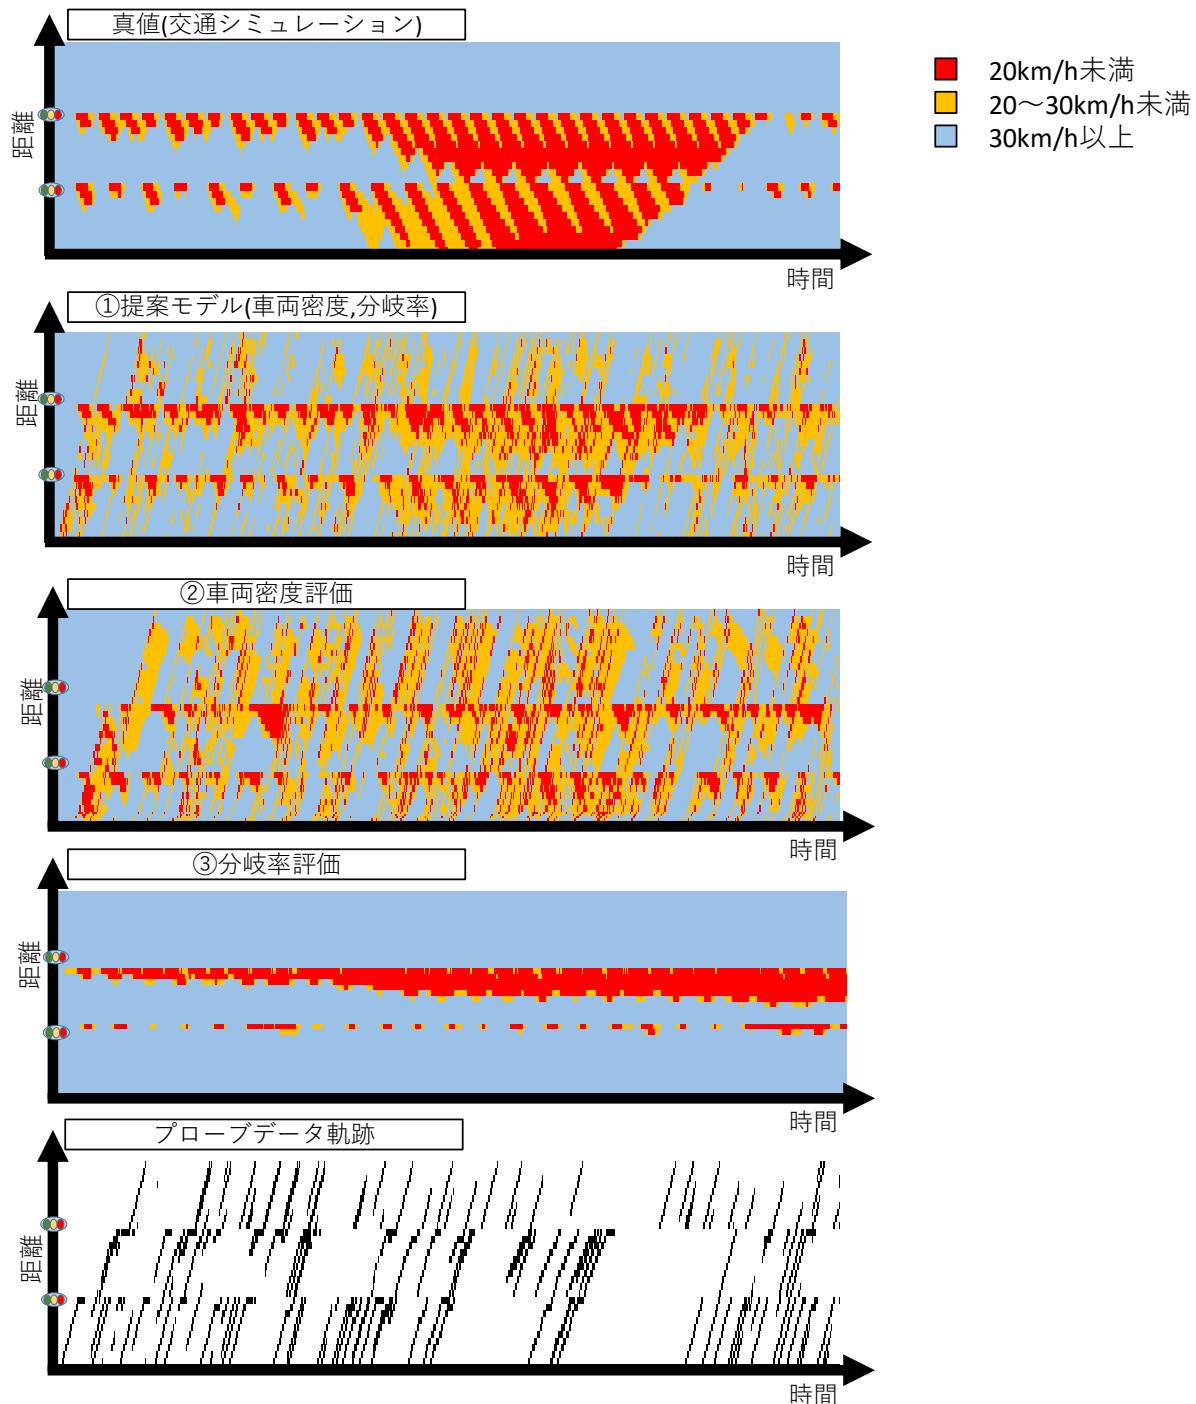


図 4-8 タイムスペース図[ケース 2]

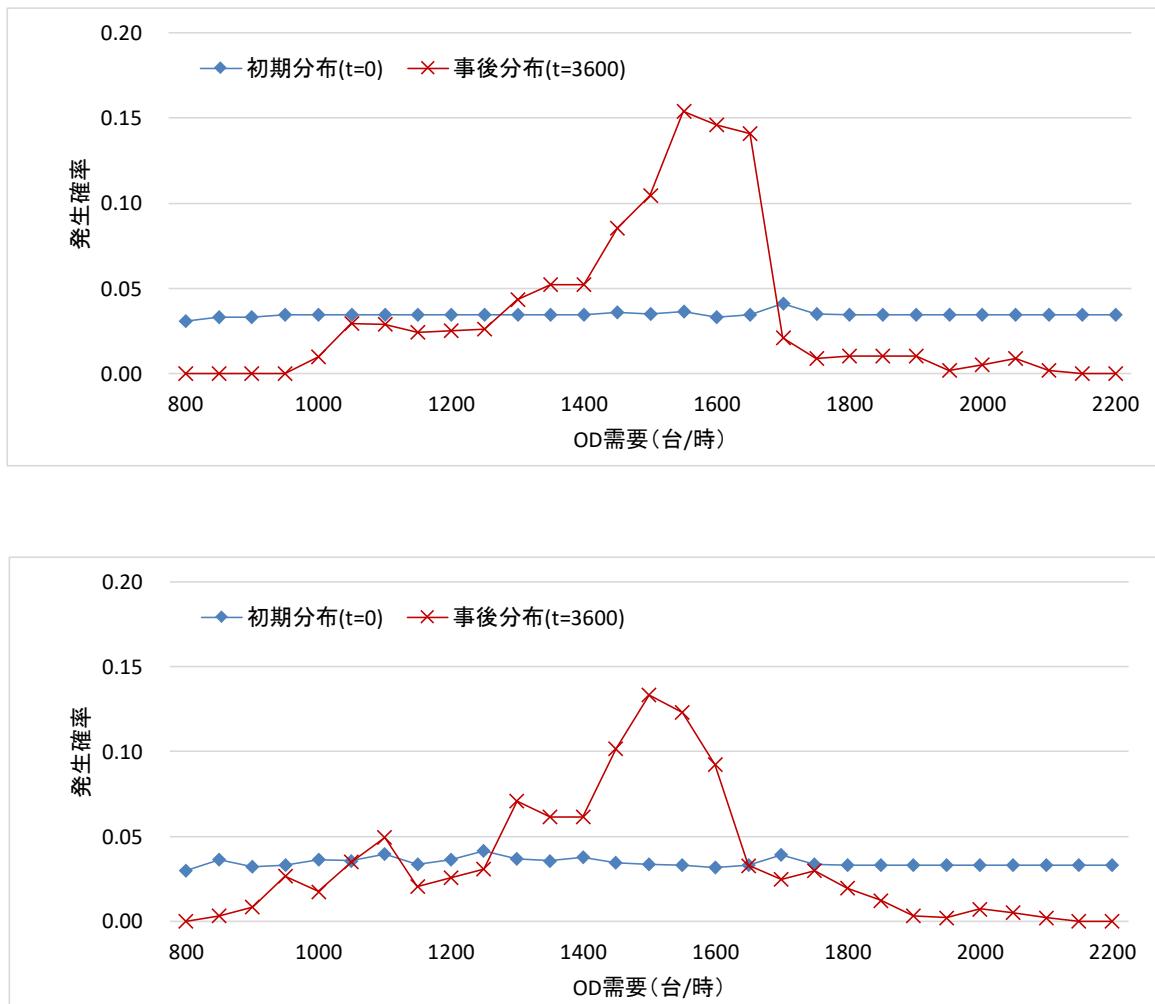
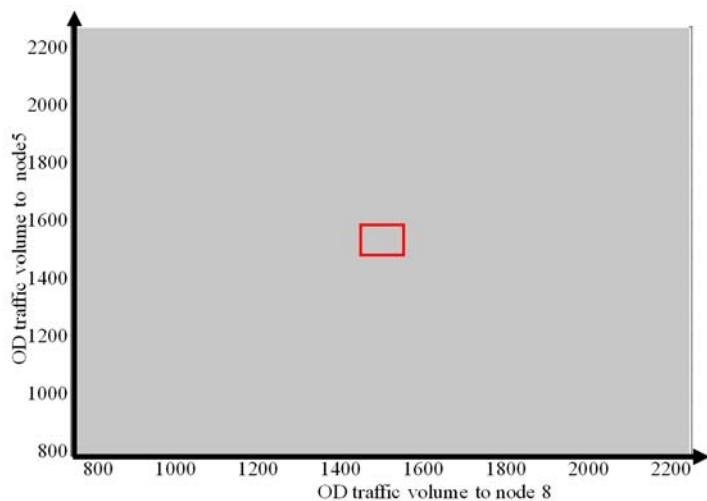
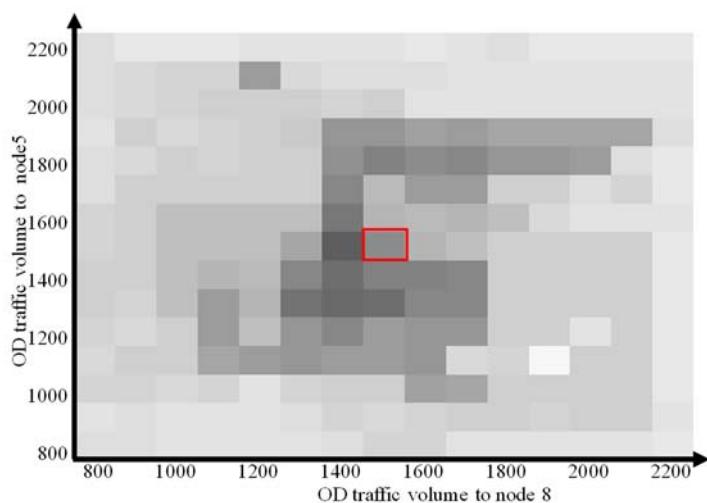
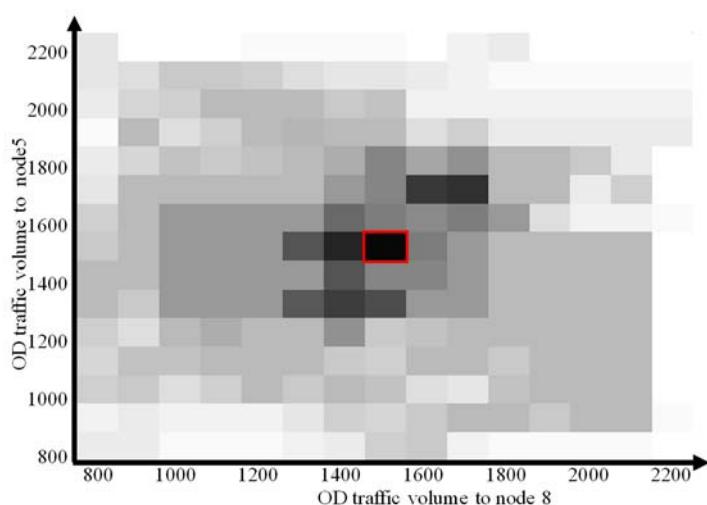
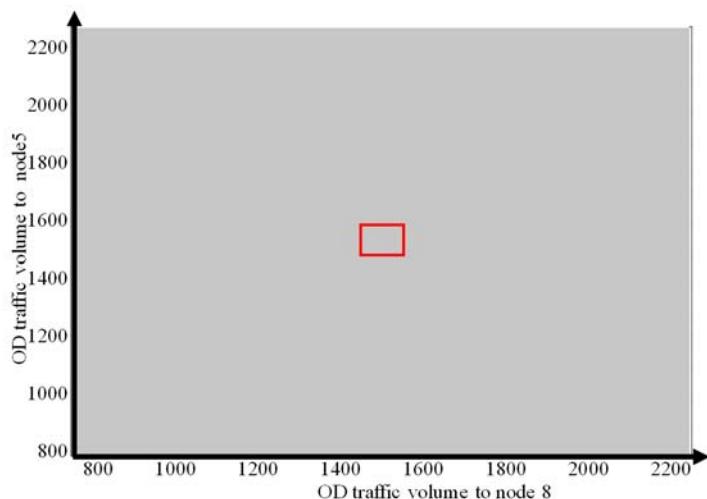
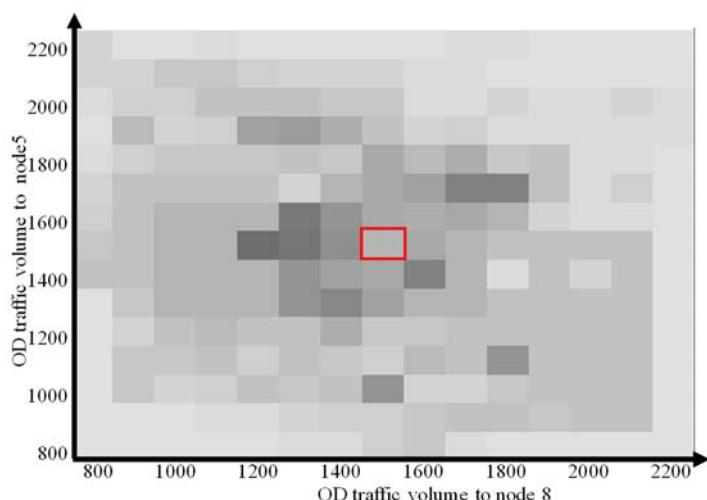
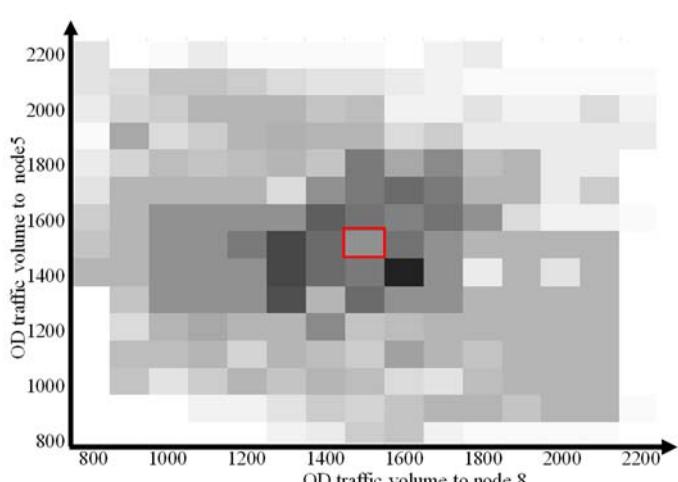


図 4-9 OD 需要の確率分布 [ケース 1]
(上段; ノード 1→ノード 8, 下段; ノード 4→ノード 5)

(a) 初期分布($t=0$) Origin node 1(b) 中間($t=1800$) Origin node 1(c) 事後分布($t=3600$) Origin node 1

□ : 真値

図 4-10 起点ノード 1 の OD 需要の確率分布[ケース 2]

(a) 初期分布($t=0$) Origin node 4(b) 中間($t=1800$) Origin node 4(c) 事後分布($t=3600$) Origin node 4

□ : 真値

図 4-11 起点ノード 4 の OD 需要の確率分布[ケース 2]

4.3.3 モデル検証結果の考察

本節では、これまでのモデル検証結果の考察を行い、モデル改善に向けた課題を述べる。これまでのモデル検証により、複数のODを設定したケース2において、渋滞状況が乖離していること、その原因是、OD需要分布が真値の値に収束されていないことがわかった。本節では、上記OD需要分布が収束しない理由の考察を行うとともに、今後の検討課題を述べる。

まず、提案モデルにおけるOD交通量と分岐率との関係を整理する。セル*i*から目的地*d*に向かうOD交通量を q_i^d と示す（簡単のため、ここでは、時間*t*を除いた表記とする）。OD交通量の集合を、 $\mathbf{Q}_i^d = (\dots, q_i^d, \dots)^T$ と表記する。以降、 \mathbf{Q}_i^d をODパターンと呼ぶ。式(3-22)より、分岐率は、 $\pi_{ij}(t) = \pi_{ij}^*(K_l^D(t))$ とあらわせる。目的地別車両密度は、 \mathbf{Q}_i^d の値により一意に決まるので、ここでは、分岐率を \mathbf{Q}_i^d を引数とした関数 $g(\cdot)$ を用いて、

$$\pi_{ij}(t) = g(\mathbf{Q}_i^d) = g(\dots, q_i^d, \dots). \quad (4-11)$$

とあらわす。提案モデルでは、観測分岐率 $\hat{\pi}_{ij}(t)$ が与えられたもとでODパターン \mathbf{Q}_i^d を未知変数として推定している。式(4-11)を用いて、この \mathbf{Q}_i^d を、

$$\mathbf{Q}_i^d = (\dots, q_i^d, \dots)^T = g^{-1}(\hat{\pi}_{ij}(t)). \quad (4-12)$$

と定義する。 $g^{-1}(\cdot)$ は、 $g(\cdot)$ の逆関数である。提案モデルでは、 $g^{-1}(\cdot)$ は、観測モデルによるフィルタリング処理を行う関数に該当する。上式に示すように提案モデルでは、 $g^{-1}(\cdot)$ で、起終点の組み合わせ数 $|\mathbf{Q}_i^d|$ と q_i^d の発集量を推定している。上式をもとに提案モデルにおける分岐率とOD交通の関係を以下に整理する。提案モデルでは、考えうるODパターンの中から観測分岐率を頼りに \mathbf{Q}_i^d を一意に特定しなければなら

ない。本研究では、 \mathbf{Q}_i^d に制約がないため、モデルが考える OD パターン(=[起終点の組み合わせ数] $|\mathbf{Q}_i^d|$)×[OD 交通量 q_i^d の発集量パターン])の数だけ存在する。したがって、OD パターン数が少ない場合は、考慮すべき OD パターン数が限られるため、観測分岐率で \mathbf{Q}_i^d を特定可能であるが、OD パターン数増加に伴い、観測分岐率を実現可能な OD パターン数が急増するため、分岐率のみで OD パターンが特定できない。すなわち提案モデルでは、未知変数に対して、与えている情報量や制約条件となる関数が不足しているため、解が一意に決定できない状況となっていると考えられる。本検証で、OD パターン数が少ないケース 1 では、OD 交通が精度よく推定できているものの、OD パターン数の多い(many-to-many)のケース 2において OD 需要が真値と乖離したのは、上記の理由と考えらえる。

上記を踏まえ、今後の課題を以下に述べる。OD パターンを特定するためには、

- 1) 先見的なOD 交通量（事前知識）を用いる。
- 2) OD 需要在モデル化(OD 交通の制約を付与)し、考える OD パターンを絞り込む。
- 3) 新たな観測値を追加し、OD に関わる情報を直接観測する。

といった解決方針が考えられる。解決方針 1)～3)の詳細を以下に述べる。解決方針 1)は、先見的なOD 交通量を用いる方法である。事前に OD 交通量が観測されていれば、それを用いて、高精度の OD パターンの初期分布を生成することで、モデル精度向上が期待できる。解決方針 2)は、起終点ノードの発生・集中交通量と起終点間の距離を関数化し、OD 交通“量”に制約を付与することが考えられる。この関数のイメージを以下に整理する。起点 i での発生量 G_i 、終点 d での集中量 A_d 、起終点間の距離を D_{id} と表記する。 q_i^d を、OD 需要在算定する関数 $f_q(\cdot)$ を用いて、

$$q_i^d = f_q(G_i, A_d, D_{id}). \quad (4-13)$$

と定義する。上式では、発集量や起終点間距離の大小に応じて、 q_i^d を一意に決定する関数である。式(4-9)を式(4-8)の制約として用いて、OD パターンの絞り込みを行

うイメージである。例えば、このような関数を導入すれば、ODパターンの未知変数をである発集量のパターン数を減少させることができる。今後は、重力モデル⁷⁾等、OD推定に関する既往研究での知見を踏まえ、適切な $f_q(\cdot)$ の関数形や引数を決定する必要がある。解決方針3)は、例えば、車両感知器、AVI、携帯電話等のデバイスにより，“特定のODペアの交通量は観測可能”，もしくは，“発生集中量の総量は観測可能”といった設定が考えられる。

4.3.4 検証結果のまとめ

本節の検証結果を以下に整理する。本検証では、OD需要のパターンが異なる2ケースの検証を行った。検証の結果、モデルの経路選択(分岐率)の改善に寄与すること、ならびに分岐率に車両密度もあわせて評価した方がより経路選択が改善されたことがわかった。渋滞推定の観点では、F値の評価の結果、①提案モデルが最も高く、次いで、②車両密度評価となっている。これは、車両密度は、渋滞推定精度改善に有効であること、および車両密度と分岐率をあわせて評価した方がより渋滞推定精度が改善されると考えられる。提案モデルの精度が高い理由は、観測分岐率による経路選択と観測車両密度によりセルの車両密度(状態量)の両方が改善されるためと推察される。検証の結果明らかとなった課題を以下に整理する。提案モデルのOD需要を分析した結果、比較的ODパターン数の多いケース2でOD需要の事後分布と真値に乖離が見られた。この理由は、ODパターン増加に伴い、観測分岐率を実現可能なODパターンが急増し、観測分岐率のみでは、ODパターンが特定できないためと推察される。したがって、今後は、ODパターンを絞りこむために、未知変数(ODパターン)と与える情報量や関数のバランスを整えることがモデル改善の課題と考える。この課題の解決方針は、例えば、先見ODの活用(初期分布の精度向上)、OD需要のモデル化や観測値の追加が考えられる。最後に、モデル検証に関する課題を以下に述べる。

- 1) OD交通量という変数の数と分岐率という制約条件の数との関係の分析：前述したように、提案モデルでは、ODパターン増加に伴い、観測分岐率のみでのODパタ

ーン推定が困難になることが考えられる。したがって、より大きなサイズのネットワークかつ複数パターンのOD需要を設定した数値実験を行い、ODパターン数と分岐率数との関係を定量的に分析し、今後のモデル化の知見とする必要と考える。

- 2) 想定外の経路選択行動下での分析：本モデルは、経路選択モデルが完全に利用者の経路選択行動を説明できるものとして構築されている。したがって、モデルで仮定した経路選択行動とは異なる経路選択が行われているケースにおいても、提案モデルがどの程度交通状態を再現できるのかを検証すべきである。

4章の参考文献

- 1) 淡路敏之, 蒲地政文, 池田元美, 石川洋一 編著 : 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.
- 2) Daganzo, C.F. : The cell transmission model, partII: network traffic, Transportation Research Part B : Methodological, Vol. 29(2), pp. 79-93, 1995.
- 3) 土木学会 土木計画学研究委員会 : 交通ネットワークの均衡分析—最新の理論と解法, 丸善, 1998.
- 4) 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, Vol.73, 2017.
- 5) 赤池弘次, 甘利俊一, 北川源四郎, 権島祥介, 下平英寿 : 赤池情報量基準 AIC—モデリング・予測・知識発見—, 共立出版, 2009.
- 6) Han,J., Kamber,M. and Pei,J.:DATA MINING Concepts and Techniques Third Edition, Morgan Kaufmann, 2011.
- 7) 土木学会 : 道路交通需要予測の理論と適用 第 I 編 利用者均衡配分の適用に向けて, 丸善, 2009.

◆本章は、下記の論文を基に加筆・修正し、執筆したものである。

- (1) Kawasaki, Y., Hara, Y., Kuwahara, M. : Real-Time Traffic State Estimation on a Two-dimensional Network by State Space Model, The 23nd International Symposium on Transportation and Traffic Theory, Lausanne, Switzerland, Jul, 2019. [投稿中]
- (2) Kawasaki, Y., Hara, Y., Kuwahara, M. : A study of traffic state estimation by data assimilation in two-dimensional networks, 7th International Conference on Transport Network Reliability, Sydney, Australia, Jan, 2018. [accepted]
- (3) 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, Vol.73, 2017.
- (4) 川崎洋輔, 原祐輔, 桑原雅夫 : 二次元ネットワークにおけるデータ同化による交通状態推

定に関する研究, 土木計画学研究・講演集, Vol.55, CD-ROM, 2017.

- (5) Kawasaki, Y., Hara, Y., Kuwahara, M. : Real-Time Traffic State Estimation on A Two-Dimensional Network by The State-Space Model, 21st HKSTS International Conference, Hong Kong, China, December 2016.
- (6) Kawasaki, Y., Hara, Y., Kuwahara, M. : Construction of real-time traffic state estimation method of a two-dimensional network by data assimilation, ASIA-PACIFIC ECONOPHYSICS CONFERENCE 2016 - Big Data Analysis and Modeling toward Super Smart Society - (APEC-SSS 2016), Tokyo, Japan, August, 2016.
- (7) 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, 土木計画学研究・講演集, Vol.54, CD-ROM, 2016.
- (8) 川崎洋輔, 原祐輔, 桑原雅夫 : 状態空間モデルによる交通状態推定手法の二次元ネットワークへの拡張, 土木計画学研究・講演集, Vol.53, CD-ROM, 2016.

第5章 結論

5.1 本研究のまとめ

本研究では、状態空間モデルによる二次元ネットワークの交通状態推定手法を提案した。以下に本研究で得られた知見を述べる。

2章では、既往研究について整理した。本研究に関連する Kinematic Wave 理論¹⁾²⁾に基づく交通流モデル、一般状態空間モデル³⁾⁴⁾の概要について述べるとともに、状態空間モデルを用いた交通状態推定手法に関する既往研究を整理した。最後に、既往研究の課題を踏まえて、本研究の貢献（本研究の位置づけ）を述べた。

3章では、状態空間モデルによる二次元ネットワークの交通状態推定手法を提案した。交通管制においては、二次元ネットワーク全体の交通状態をモニタリングすることが重要である。本研究では、観測されるプローブ車両の車両密度データ、分岐率と交通流モデルの解法の一つである CTM (Cell Transmission Model)⁵⁾ を用いて二次元ネットワークの交通状態を推定する状態空間モデルを構築した。二次元ネットワークでは、

- ・ ドライバーの経路選択行動を考慮する必要がある。
 - ・ プローブデータからドライバーの目的地を直接観測することは出来ない。
- といった課題がある。この課題解決のために本研究では、
- ・ 経路選択行動の考慮；分岐セルの車両の目的地構成比率(目的地 d を持つ車両の割合)を状態変数に組み込むことが必要と考える。したがって、状態変数は、目的地 d をもつセル i の車両密度 $k_i^d(t)$ とした。

- ・ 分岐セルの目的地構成比率の改善；プローブ車両分岐率 $\hat{\pi}_{ij}(t)$ を活用し、モデルの $\pi_{ij}(t)$ を更新することで、分岐セルの目的地構成比率の改善を図った。

の解決方針を検討し、二次元モデルの定式化を行った。

既往の状態空間モデルは、一次元ネットワークを対象にしたものである。この理由は、「二次元ネットワークの場合、ドライバーの経路選択を考慮する必要があること」、「一般道の交差点の交通流は複雑でありモデル化が難しいこと」が考えられる。こうした背景の下、本研究の貢献は、状態空間モデルを一次元から二次元ネットワークに拡張した点と考える。

4章では、双子実験⁶⁾により、第4章で構築した二次元ネットワークの状態空間モデルの性能検証を行った。モデル検証の結果、得られた知見は以下のとおりである。

1) プローブ車両分岐率による経路選択の改善

これまでの研究は、プローブ車両からの観測値として、車両速度や旅行時間を使ってきた。本研究では、モデル内の車両の目的地構成比率の改善に資する新たな観測値として、プローブ車両分岐率を提案した。検証の結果、プローブ車両の分岐率は、モデルの経路選択改善に寄与することが確認された。

2) 車両密度および分岐率の同時評価による渋滞推定精度の向上

モデル検証の結果、車両密度のみ、分岐率のみの評価に比べて、車両密度および分岐率を同時に評価した提案モデルが最も渋滞推定精度が良い結果となった。提案モデルの精度が高い理由は、観測分岐率による経路選択と観測車両密度によりセルの車両密度(状態量)の両方が改善されるためと推察される。

3) モデルとプローブ軌跡データのみによる二次元ネットワークの交通状態の推定可能性の示唆

交通流モデルは、OD交通”量”が境界条件のため、一般的には、車両感知器等の車両の全数が観測可能な設置型のセンシングデータを活用する必要がある。しかし、車両感知器は、設置箇所が限定的(主要道にのみ設置)されているため、観測範囲が限定される。一方、プローブデータは、広範なデータを得られるが、量的な把握不可といった問題

がある。本研究では、3章で示したモデルで、これらの課題解決を図った。OD需要の異なる2ケースでモデル検証した結果、渋滞推定精度の高いケースと低いケースが見られた。渋滞推定精度が低くなった理由は、OD需要パターンによっては、同じ分岐率のパターンが複数存在するためと推察される。

5.2 今後の課題

今後の研究課題を以下に述べる。以下、1)～4)はモデル改善の課題、5)はモデル検証に関する課題、6)はモデルの位置づけに関する課題である。

- 1) ODパターンの推定精度向上：モデル検証の結果、複数のOD需要を設定したケースにおいて、OD需要分布が真値とモデルで乖離しているため、渋滞推定精度が低い状況が見られた。この乖離の理由は、観測分岐率のみでは、与えている情報量や関数が足りないため、真のOD需要が特定できない（OD需要パターンによっては、同じ分岐率のパターンが複数存在する）と推察される。この問題解決のためには、ODパターンの推定精度向上が課題と考える。本モデルの精度は、OD需要の初期分布の精度に依存する。その理由は、真値と乖離した初期分布を設定しても真の交通状態に近いものは得られないためである。したがって、課題解決のアプローチの一つに精度のよい初期分布の設定が考えられる。初期分布の設定方法としては、例えば、先見的な（過去調査結果等）のOD需要を設定し、真値との乖離を抑止することや、初期分布で生成するOD需要パターン数（パーティクル数）を増やすことが考えられる。ただし、後者の場合、OD需要のパターン数が多くなると、生成するパーティクルの数（OD需要の組み合わせパターン）が膨大になるといった新たな問題が生じるため、その解決策も検討が必要と考える。この他、OD需要をモデル化し、ODの制約を増やすことが考えられる。OD需要のモデル化については、4章で述べたように、起終点ノードの発生・集中交通量の大小と起終点間の距離など

の関数としてODを表すようなモデルを本モデルに組み込むことが考えられる。また、OD推定のヒントとなる観測値を追加するといったアプローチも考えられる。

- 2) フィルタリング（事後分布の推定）手法の検討：本研究では、事後分布の算定法として、パーティクルフィルタ⁷⁾を用いている。パーティクルフィルタは、システムモデルや観測モデルが非線形な場合やノイズが非ガウスの場合であっても事後分布を算定可能といった特徴を持つ。しかし、パーティクルフィルタは、少數の粒子の重みだけ大きく、その他の多数の粒子の重みはほとんどゼロになってしまい、所謂、縮退の問題が指摘されている⁸⁾。そのため、今後は、アンサンブルカルマンフィルタ等、縮退を抑止するようなフィルタリング手法の検討が必要である。
- 3) ドライバーの交通状態の学習過程の定式化：提案したモデルでは、経路選択行動にマルコフ性（一期前のみ経路選択行動に影響を与える）を仮定して、定式化した。しかしながら、実際の経路選択行動では、一期前よりもさらに前の状態をドライバーが学習し、経路選択を行うことも考えられる。今後は、こうしたドライバーの過去の交通状態の学習過程を定式化することが課題と考える。
- 4) 運転者の経路選択行動のモデル化：提案モデルは経路選択モデルに完全に依存しているため、経路選択モデルが実際の経路選択行動と異なれば、交通状態の推定精度が悪化する。したがって、運転者の経路選択行動のモデル化も課題と考える。あわせて、柔軟な経路選択モデルを仮定して、自己組織化状態空間モデル⁹⁾を構築し、交通状態と経路選択モデルのパラメータを同時に推定することも考えられる。
- 5) 双子実験によるモデル検証の深堀：本研究で提案したモデル検証結果に一般性を持たせるには、ネットワーク形状やOD需要、観測プローブデータ（台数、抽出率）、

様々な経路選択行動下でのケースを追加検証することが必要と考える。例えば、追加検証の内容は、下記が考えられる。

- ・ 大規模ネットワークにおけるOD数と分岐率数との関係の検証
- ・ モデルで仮定した経路選択行動とは異なる経路選択が行われているケースにおいて、提案モデルがどの程度交通状態を再現できるのかを検証

また、上記の次のステップとしては、実測データを用いて、適用上の課題抽出および解決策の検討、ならびに実地でのモデルの妥当性検証が必要と考える。実地での検証は、プローブデータが多く得られること、経路選択が発生するネットワークでの適用が望ましい。そのため、実地検証は、首都圏のネットワークでの検証を想定している。

- 6) 従来の動的な交通配分モデルとの関係の議論：ネットワーク交通配分モデルの視点で見ると、提案モデルは、従来の動的な交通配分モデルを状態空間モデルに（確率的に）拡張したものと考えられる。今後は、従来の動的な交通配分モデルと、提案モデルの関係を議論し、提案モデルの位置づけを明確にすべきと考える。

5 章の参考文献

- 1) Lighthill, M.J. and G.B.Whitham: On kinematic waves II. A theory of traffic flow on long crowded roads, The Proceedings of the Royal Society, LONDON, series A 229(1178), pp313-345, 1955.
- 2) Richards, P.I. : Shock waves on the highway, Operation Research Vol.4, pp.42-51, 1956.
- 3) 北川源四郎：時系列解析入門，岩波書店，2005。
- 4) 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－，朝倉書店，2011。
- 5) Daganzo, C.F. : The cell transmission model, partII: network traffic, Transportation Research Part B : Methodological, Vol. 29(2), pp. 79-93, 1995.
- 6) 淡路敏之，蒲地政文，池田元美，石川洋一 編著：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。
- 7) Kitagawa, G.: Monte Carlo Filter and Smoother for Non-Gaussian Nonlinear State Space Models, Journal of Computational and Graphical Statistics, Vol. 5, No. 1 , pp. 1-25, 1996.
- 8) 矢野浩一：粒子フィルタの基礎と応用：フィルタ・平滑化・パラメータ推定，日本統計学会誌，第44巻，第1号， pp.189-216, 2014.
- 9) Kitagawa, G.: A self-organizing state-space model, Journal of the American Statistical Association, Vol. 93, pp. 1203-1215, 1998.

Appendix 1 二次元モデルにおける経路選択モデルの設定例

ここでは、3章で定式化した二次元モデルの経路選択モデルの設定例を示す。まず、図1-1のようなセル*i*から終点*d*までに複数の経路があるネットワークを考えよう。ここで、

$$\Omega_R(i, d) = \text{セル } i \text{ と目的地 } d \text{ 間の経路集合}$$

$$r = \Omega_R(i, d) \text{ に含まれる経路}$$

$$T^r(t) = \text{時刻 } t \text{ における経路 } r \in \Omega_R(i, d) \text{ の所要時間}$$

を定義する。 $\Omega_R(i, d)$ に属する全ての経路の所要時間の集合を

$$T(t) = (\dots, T^r(t), \dots)^T. \quad (1-1)$$

と定義する。本研究では、 $T^r(t)$ は、時刻*t*における経路*r*に属するセルの通過時間の同時刻和と仮定する。時刻*t*におけるセル*i*の所要時間は、FDと車両密度 $k_i(t) = \sum_d k_i^d(t)$ より推定された速度とセル長 Δx から算定できる。便宜上、 $\Omega_R(i, d)$ に属する全ての経路（経路に属するセル）の所要時間を算定する関数を $T^*(\cdot)$ と表記すると、 $T(t)$ は、

$$T(t) = T^*(K_I^D(t)). \quad (1-2)$$

と書ける。経路*r*の選択確率は経路旅行時間のみに依存すると仮定する。経路選択確率を算定する関数を $p^*(\cdot)$ と表記すると、経路選択確率 $p^r(t)$ は一般に、

$$p^r(t) = p^*(T(t)) = p^*(T^*(K_I^D(t))), \forall r \in \Omega_R(i, d). \quad (1-3)$$

と書ける。後述する状態空間モデルは、経路選択モデルに完全に依存する。したがって、関数 $p^*(\cdot)$ は、ロジットモデル²⁾など経路選択行動のマルコフ性の表現および経路選択確率を解析的に明示できるモデルを用いる必要がある。次に $\pi_{ij}^d(t)$ を定式化する。 $\pi_{ij}^d(t)$ は、セル i から下流セル $j \in C_d(i)$ への分岐率である。 $\pi_{ij}^d(t)$ は $p^r(t)$ を用いて次のように表すことができる。

$$\pi_{ij}^d(t) = \sum_{r \in \Omega_R(i, d)} p^r(t) \cdot \delta_{ij}^r. \quad (1-4)$$

ここで、

$$\delta_{ij}^r = \begin{cases} 1, & \text{if リンク } (i, j) \text{ が経路 } r \text{ に含まれる} \\ 0, & \text{if リンク } (i, j) \text{ が経路 } r \text{ に含まれない} \end{cases}$$

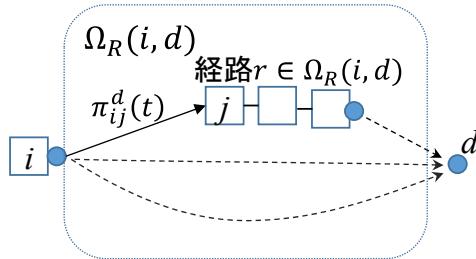


図 1-1 セル i から目的地 d 間のネットワーク

Appendix 2 状態空間モデルの計算アルゴリズム

状態空間モデルのアルゴリズムを整理する。アルゴリズムの整理に当たって、ネットワークのリンク、ノードの集合を有向グラフ $\mathbf{G} := (\mathbf{V}, \mathbf{E})$ として定義する。ここで、 \mathbf{V} は、ノード集合、 \mathbf{E} はリンク集合 $\mathbf{E} \subseteq \mathbf{V} \times \mathbf{V}$ である。提案モデルでは、最初に、初期分布として、 N パターンの OD 交通密度を生成する。この OD 交通密度の集合を $\{\langle \mathbf{K}_I^D(0) \rangle^{(n)}\}_{n=1}^N = (\langle \mathbf{K}_I^D(0) \rangle^{(1)}, \langle \mathbf{K}_I^D(0) \rangle^{(2)}, \dots, \langle \mathbf{K}_I^D(0) \rangle^{(N)})$ と表記する。 $\langle \mathbf{K}_I^D(0) \rangle^{(n)}$ は、 n 番目の状態ベクトルを示す。この OD 交通密度がネットワークを進むうちに観測密度 $\hat{\mathbf{K}}_I(t)$ と観測分岐率 $\hat{\Pi}(t)$ を用いた

フィルタリングにより、 N パターンそれぞれの重み（数）が変化し、 $\{\langle \mathbf{K}_I^D(0) \rangle^{(n)}\}_{n=1}^N$ の更新を図る（経路選択モデル自体を同定するものではない）。

状態空間モデルのアルゴリズムを疑似コードで整理したものを **Algorithm 1**, **Algorithm 2**, **Algorithm 3** に示す。アルゴリズム中の左の数値は処理の行数を示す。以降の文章の、行数とは、この数値を示す。と表記する。**Algorithm 1** は、状態空間モデルの全体フレームを表現したものである。5 行目までは、最初に一度だけ呼ばれる初期設定の処理である。6 行目以降がシミュレーション実行部分である。シミュレーション実行部分を見ると、「システムモデル (7, 8 行)」「尤度の算定 (9, 10 行)」「リサンプリング (11, 12 行)」の 3 つの処理がタイムステップのループ (T 回) 内で独立に N 回ループ処理されることがわかる。
Algorithm 2 は、初期分布の生成を行うアルゴリズムである。シミュレーション開始時に一度呼ばれるのみである。**Algorithm 3** は、システムモデルの関数の処理内容を示している。同図の 2, 3 行目を見ると、セルの総数 $I \times$ 目的地の数 D 回ループ処理を行い、セルの車両密度を更新していることがわかる。

Algorithm 1 状態空間モデルの全体の流れを実装した関数

Function $f_{ss}(a, b, F, G, N,)$.

Input

G ; 有向グラフ(ネットワークのノード集合V, リンク集合Eの集合)

Δx ; セル長

T ; シミュレーション時間 ($t=0, 1, 2, \dots, T$)

a, b ; 初期分布生成パラメータ

F ; Fundamental diagram の諸量

N ; パーティクルの数

Function definition

$f_1(\cdot)$;セルの総数を算定する関数(ネットワークの総リンク長÷セル長)

$f_C(\cdot)$;セルを生成する関数

$f_{ini}(\cdot)$; 車両密度の初期分布を生成する関数

Algorithm 2

$f_{sys}(\cdot)$; システムモデル(交通流モデル, 経路選択モデル)関数

Algorithm 3

$f_{like}(\cdot)$; 式(3-36)により各粒子の尤度を算定

$f_{rs}(\cdot)$;各パーティクルの尤度に応じて、粒子を復元抽出（リサンプリング）

Latent variable definition;

$$\left\{\langle \mathbf{K}_I^D(0) \rangle^{(n)}\right\}_{n=1}^N = (\langle \mathbf{K}_I^D(0) \rangle^{(1)}, \langle \mathbf{K}_I^D(0) \rangle^{(2)}, \dots, \langle \mathbf{K}_I^D(0) \rangle^{(N)}).$$

$$\{\langle w(t) \rangle^{(n)}\}_{n=1}^N = (\langle w(t) \rangle^{(1)}, \langle w(t) \rangle^{(2)}, \dots, \langle w(t) \rangle^{(N)}).$$

- ```

1. I = $f_l(\mathbf{G}, \Delta x)$
2. for I=1 to I
3. $C_i = f_c(\mathbf{G})$
4. for n = 1 to N #N パターンの車両密度(OD 需要)生成
5. $\langle \mathbf{K}_I^D(0) \rangle^{(n)} \leftarrow f_{ini}(\mathbf{a}, \mathbf{b}, I)$
6. for t = 1 to T
7. for n = 1 to N
8. $\langle \mathbf{K}_I^D(t) \rangle^{(n)} \leftarrow f_{sys}(\langle \mathbf{K}_I^D(t-1) \rangle^{(n)}, \mathbf{F}, \theta, I)$ #システムモデル(車両密度更新)
9. for n = 1 to N
10. $\langle w(t) \rangle^{(n)} \leftarrow f_{like}(\langle \mathbf{K}_I^D(t) \rangle^{(n)})$ #パーセイクル n の尤度 $\langle w(t) \rangle^{(n)}$ を算定
11. for n = 1 to N
12. $\langle \mathbf{K}_I^D(t) \rangle^{(n)} \leftarrow f_{rs}\left(\left\{\langle \mathbf{K}_I^D(0) \rangle^{(n)}\right\}_{n=1}^N, \left\{\langle w(t) \rangle^{(n)}\right\}_{n=1}^N\right)$ #リサンプリング

```

注) アルゴリズム内の#以降はコメント文

---

**Algorithm 2** 車両密度の初期分布を生成する関数

---

Function  $f_{ini}(a, b, I)$ 

Input

 $a, b$  ; 初期の車両密度生成パラメータ     $I$  ; セルの総数

Function definition

 $Uniform(x)$  ; 区間 $[a, b]$ 上の一様分布の乱数を返す関数

1. for  $n = 1$  to  $N$
  2.     for  $i = 1$  to  $I$
  3.         for  $d = 1$  to  $D$
  4.             if セル*i*から目的地 *d* 間のODが発生する場合 then
  5.                  $\rho = Uniform(x)/v_i$                           #以降, 式(3-37), 式(3-38)
  6.                 for  $t = 0$  to  $T-1$
  7.                      $\varepsilon_i^d(t) \leftarrow \rho/T$                           #  $t=0 \sim T-1$  のシステムノイズ(初期)生成
  8.                      $k_i^d(0) \leftarrow \varepsilon_i^d(0)$                           # 初期の車両密度を生成
  9.     return  $\mathbf{K}_I^D(0)$
- 

---

**Algorithm 3** システムモデル(交通流モデル, 経路選択モデル)関数

---

Function  $f_{sys}(\langle \mathbf{K}_I^D(t-1) \rangle^{(n)}, \mathbf{F})$ 

Input

 $\mathbf{K}_I^D(t-1)$  ; 時刻  $t-1$  の目的地別車両密度集合     $\mathbf{F}$  ; Fundamental diagram の諸量     $I$  ; セルの総数

1.  $\Pi^D(t-1) = \Pi^{D*}(\mathbf{K}_I^D(t-1))$ . #式(3-20). 経路選択モデルの関数
  2. for  $i = 1$  to  $I$
  3.     for  $d = 1$  to  $D$
  4.         if セル*i*から目的地*d*間のODが発生する場合 then
  5.              $k_i^d(t) = k_i^*(\mathbf{K}_I^D(t-1), \Pi^D(t-1), \mathbf{F}) + \varepsilon_i^d(t)$  #式(3-29)
  6.         else
  7.              $k_i^d(t) = k_i^*(\mathbf{K}_I^D(t-1), \Pi^D(t-1), \mathbf{F})$ . #式(3-17)
  8.     return  $\langle \mathbf{K}_I^D(t) \rangle^{(n)}$
- 

注) アルゴリズム内の#以降はコメント文

## Appendix 3 Variational Theory(VT)の概要

Variational Theory(VT)<sup>1)</sup>の概要について説明する。 VTは、 Daganzoにより提案された交通流モデルの解法の一つである。 VTの対象区間では、 区間途中の流入出がないFIFO(First In First Out)条件を満たすと仮定する。 forward wave speed  $v_f$  と backward wave speed  $-w$  が与えられた時、 図 3-1のような区分線形FDが時空間上に敷き詰められたFDネットワーク（図 3-2）を構築する。 FDの最大フローレートを  $q_{max}$ 、 最大密度を  $k_{jam}$  とする。 青矢印は、 forward wave speed  $v_f$  に付随したコスト0のリンク(以降fwリンクという)を示す。 赤矢印のリンクは、 backward wave speed  $-w$  に付随したリンク(以降bwリンクという)である。 赤リンクのコストは、  $k_{jam}dx = q_{max}dt$  で示され、  $dx$  と  $dt$  は、 図 3-2に示すように時空間を区切る微小区間である。 時空間上で累積交通量が既知のノードを境界ノードと定義する。 時空間上の累積交通量が不明な任意のノード  $j$  に到達可能な境界ノード  $i$  のインデックス集合を  $\Omega_j$  と定義する。  $N_i$  と  $N_j$  をノード  $i$  と  $j$  の累積交通量とする。 なお、  $N_i$  は境界ノードの累積交通量で既知である。 ノード  $i$  とノード  $j$  間の累積交通量の変化量を  $Z_{ij}$  とする。 Variational Theoryによると、 ノード  $j$  の累積交通量は、

$$N_j = \inf_i \{N_i + Z_{ij}\}, i \in \Omega_j. \quad (3-1)$$

で示される。 ここで、  $Z_{ij}$  は、 FDネットワーク上のノード  $i$  からノード  $j$  間の最短経路コストで与えられる。 全ての  $Z_{ij}$  を計算した場合、 ノード  $j$  の累積交通量は、  $N_i$  と  $Z_{ij}$  の和の最小値となる。 上式の操作をすべてのノード  $j$  に対して繰り返せば、 FDネットワークの全てのノードの累積交通量を求めることができる。 実際の道路交通に VTを適用する時の上流側(下流側)の境界ノードの交通量は、 車両感知器により観測される個々の車両の到着時刻から与えればよい。 FDネットワーク内のプローブ軌跡データの取り扱いについて説明する。 VTでは、 プローブ軌跡上のノードの累積交通量は変化しないという制約を付与(=プローブ軌跡に沿って、 FDネットワークにリンクコストをゼロにするリンク

クを追加)する。その制約の下で累積交通量を算定すれば、プローブ車両軌跡と整合するように累積交通量を求めることができる。そして、全てのノードの累積交通量が求められた下で、図 3-3に示すように累積交通量の等しいノードをつなぐと、車両軌跡を推定できる。車両軌跡の傾きは車両速度である。本研究では、ノード $j$ を起点とした車両軌跡の傾き $v$ をノード $j$ の地点速度と定義する。時空間上の全てのノードの累積交通量から車両軌跡を推定し、地点速度を算定する関数を

$$\mathbf{v} = g_v(\mathbf{N}) \quad (3-2)$$

と定義する。ここで、 $\mathbf{N}$ は時空間上の累積交通量の集合ベクトル、 $\mathbf{v}$ は地点速度ベクトル、 $g_v(\cdot)$ は、累積交通量を引数として速度を算定する関数である。以上より、VTは、境界条件とFDを与えることによって、全てのノードの累積交通量と地点速度を算定することが出来る。

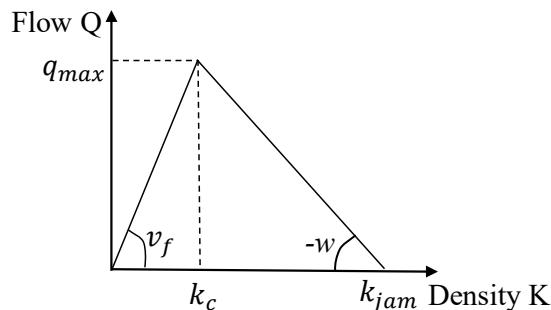


図 3-1 区分線形 FD

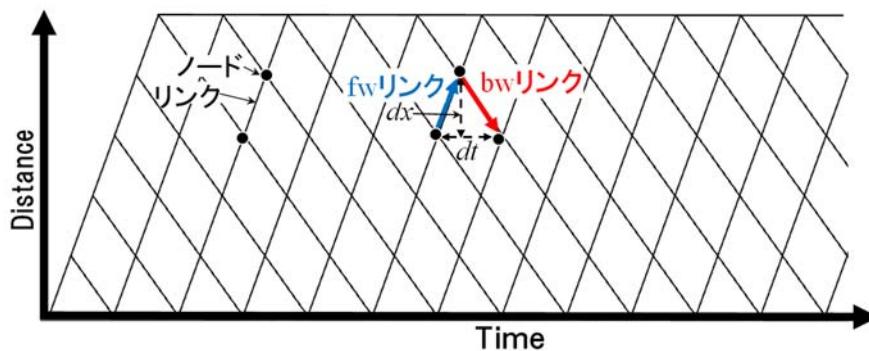


図 3-2 FD ネットワーク

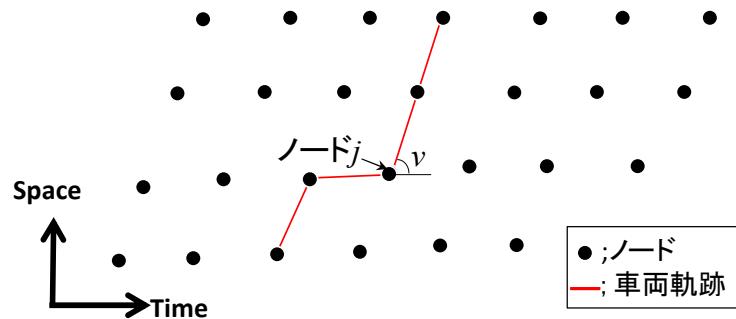


図 3-3 車両軌跡の推定イメージ

## Appendix 4 一次元モデル(FD の揺らぎの考慮)の定式化

本節では、Fundamental diagram (FD) の揺らぎを考慮した状態空間モデルを提案する。本節の概要を以下に述べる。自由流の状況では、運転者の特性によって、個々の車両の挙動が異なるため、結果として同じ区間であっても FD が時々刻々と変化する。さらに、FD は歩行者や路上駐車などの外部要因にも影響を受ける。そこで、本研究では、交通流モデルの解法の一つである Variation theory (VT)<sup>1)</sup>とセンシングデータ(車両感知器、プローブ軌跡データ)を用いたモデル構築を試みた。VT は、確定的な手法であり、FD のばらつきをリアルタイムに考慮することはできない。そのため、VT を状態空間モデル<sup>2)</sup>に拡張し、FD を確率的に取り扱えるようにした。交通シミュレーションによるモデル検証の結果、提案モデルは、既往の確定的な VT よりも渋滞の推定精度が高いことがわかった。最後に、実データの検証(Validation)として提案モデルを東京の駒沢通りに適用した。

### 4.1.1 研究の目的

本章では、交通流モデルとセンシングデータを用いてリアルタイムに交通状態をモニタリングするためのモデルを提案する。センシングデータとして、古くから使われている車両感知器は、全数把握が可能であるが、設置個所が限定される。一方、プロ

ープデータ (GPS) は、車両のデータを広域に把握可能であるが、サンプルデータであるため、全数把握はできないこと、観測誤差が存在するといった問題がある。したがって、センシングデータは、

- ・スペースであり、未観測領域が存在
- ・観測誤差が存在

といった問題がある。こうした問題解決のアプローチの一つにデータ同化<sup>2)</sup>がある。データ同化はシミュレーションモデルに観測データを入力（同化）し、シミュレーション結果の改善を図る。本研究では、センシングデータを VT に同化する状態空間モデル構築を試みる。

前節で述べたようにDaganzoにより提案されたVariational theory (VT)は、Kinematic wave 理論に基づく交通流モデルの解法の一つであり、境界条件として、観測データを入力し、モデル推定精度の改善を図る。したがって、VTはデータ同化とアプローチが同類である。FDと境界条件が与えられれば、交通流モデルは、交通量保存則に基づき、交通状態として、時空間上の累積交通量を推定する。VTはこの問題を、FDで構成されたネットワーク上の最短経路問題に変換する。Mehran et al.<sup>3)</sup>およびMehran and Kuwahara<sup>4)</sup>は、VTを拡張し、プローブ車両軌跡と車両感知器のデータを用いて、信号制御下の一般道の全車両軌跡を推定する手法を提案した。VTは、確定的に交通状態を推定する。しかし、実際は、確率的な要素が交通状態推定に影響を及ぼす。

一つは、FD の変動である。自由流の状況では、運転者の特性によって、個々の車両の挙動が異なるため、結果として同じ区間であっても FD が時々刻々と変化する。さらに、FD は歩行者や路上駐車などの外部要因にも影響を受ける。もう一つの確率的要因は、境界条件の状況であり、センシングデータに起因する。Mehran らは、対象区間の出入り口に設置された車両感知器とプローブ車両軌跡から VT の境界条件を設定している。こうしたセンサーから取得される車両軌跡や交通量には、確率的な観測誤差が含まれる。本節では、上記の FD、変動と観測誤差を考慮した状態空間モデルを提案する。本研究は、一般道路を対象とし、推定する交通状態を

時空間上の累積交通量としている点が本編 2 章で述べた既往研究と異なる。

#### 4.1.2 状態空間モデルの仮定

本節では、状態空間モデルの仮定を述べる。本研究の状態空間を図 4-1 に示す。

図 4-1 に示す本線区間の時空間を、空間と時間でそれぞれ離散化する。対象とする 1 つの離散時空間は距離  $L$ 、時間  $\Delta T$  であり、これが離散時刻  $T$  の対象時空間である。さらに、時刻  $T$  の対象時空間を微小区間  $\Delta t$ ,  $\Delta I$  ごとに分割した単位メッシュを作成し、これらを時刻  $T$  の時空間メッシュと呼ぶ。時空間メッシュ内の単位メッシュのインデックス集合を  $\Omega_K = \{1, 2, \dots, k, \dots, K\}$  とする。時刻  $T$  の持つ時間幅  $\Delta T$  は  $\Delta T = n \Delta t$  とする。ここで、 $n$  は自然数である。各単位メッシュは状態量として一つの累積交通量を持つ。時間軸を  $\Delta T$  からさらに  $\Delta t$  で分割している理由は、システムモデルである VT の計算時間ステップ  $dt$  が  $\Delta T$  よりも小さい場合に VT と状態空間の時間ステップに整合を持たせて状態量と VT の出力結果を対応させるためである。

時刻  $T$  の時空間メッシュにおける単位メッシュ  $k$  の累積交通量を  $n_k(T)$ ,  $k = 1, 2, \dots, K$  と表記する。状態ベクトル  $N(T)$  は、 $n_k(T)$  の集合、

$$N(T) = (n_1(T), \dots, n_k(T), \dots, n_K(T))^T, k \in \Omega_K.$$

(4-1)

と定義する。時刻  $T$  の時空間メッシュの観測ベクトル  $\hat{N}(T)$  を以下に定義する。観測値は、対象区間上下端の車両感知器とプローブ軌跡データから得られる累積交通量である。図 4-2 に観測値と状態ベクトルの対応を示す。同図の左は、観測値、右側は状態ベクトルに対応した時空間メッシュである。ハッシュがかけられた単位メッシュは、状態量が得られたメッシュである。同図に示すように時刻  $T$  にプローブ車両軌跡が通過した単位メッシュを考えよう。時刻  $T$  にプローブ車両軌跡が観測さ

れたメッシュのインデックス集合を  $M(T) = \{\dots, m, \dots\}$  と表記する。時刻  $T$  に単位メッシュ  $m \in M_T$  に観測される累積交通量を  $y_T^m$  と表記する。観測ベクトル  $\hat{\mathbf{N}}(T)$  は、 $\hat{n}_m(T)$  の集合、

$$\hat{\mathbf{N}}(T) = (\dots, \hat{n}_m(T), \dots)^T, m \in M_T \in \Omega_K, |M_T| \leq K.$$

(4-2)

と定義する。本研究では、非線形のシステムモデル、線形の観測モデルで構成される状態空間モデル、

$$\mathbf{N}(T) = f_{VT}(\mathbf{N}(T-1), \mathbf{v}(T)), \mathbf{v}(T) \sim prob(\mathbf{v}(T)), \quad (4-3)$$

$$\hat{\mathbf{N}}(T) = \mathbf{H}(T)\mathbf{N}(T) + \mathbf{w}(T), \mathbf{w}(T) \sim prob(\mathbf{w}(T)). \quad (4-4)$$

を定義する。ここで、上式の  $f_{VT}(\cdot)$  は、3.1 節で述べた VT の関数、 $\mathbf{v}(T)$  はシステムノイズである。式(3-5)の  $\mathbf{H}(T)$  は次元数  $K \times |M(T)|$  の観測行列、 $\mathbf{w}(T)$  は観測ノイズである。 $f_{VT}(\cdot)$  や観測ノイズ、システムノイズの詳細は後述する。

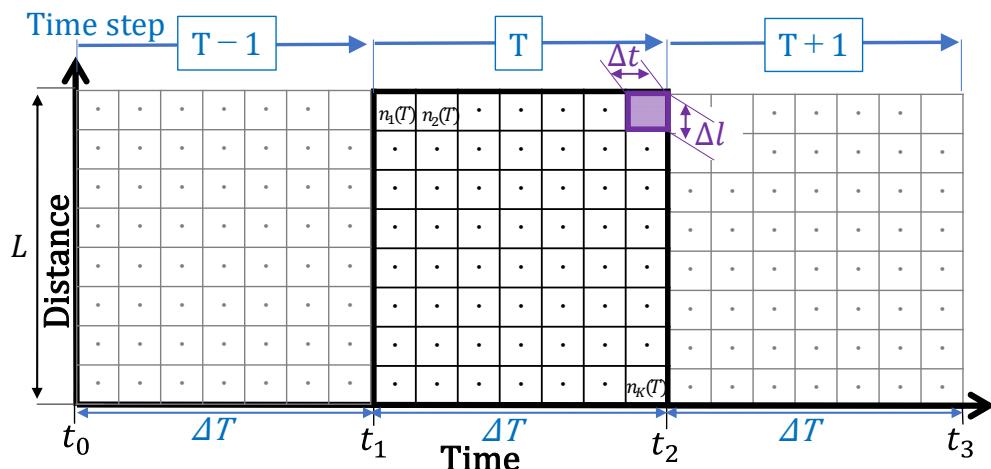


図 4-1 時空間メッシュ

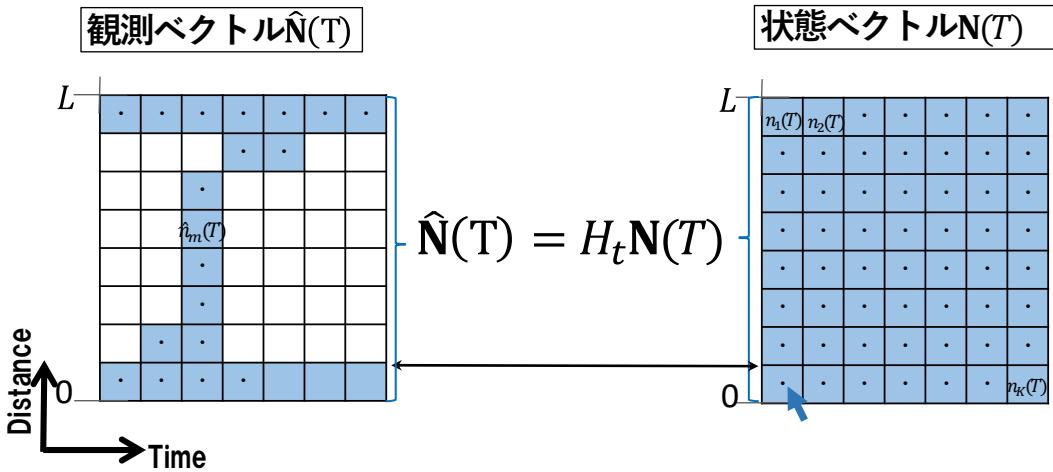


図 4-2 観測値と状態ベクトルの関係

#### 4.1.3 状態空間モデルの構築

##### 1) システムモデル

システムモデルを以下に定義する。システムモデルでは、FD の変動だけを考え、Boundary node は変動しないと仮定する。3.1 節で述べた VT について、境界条件と FD を引数とした VT の関数を便宜上、 $f_{VT}(\cdot)$  と表記する。システムモデルは、時刻  $T$  の境界ノードの累積交通量  $N_i^B$  の集合  $\mathbf{N}_B(T)$ 、区分線系 FD の形状  $\mathbf{S}_{FD}$  および VT の関数  $f_{VT}(\cdot)$  を用いて、

$$\mathbf{N}(T) = f_{VT} (\mathbf{N}(T-1), \mathbf{N}_B(T), \mathbf{S}_{FD}(T)) . \quad (4-5)$$

と定義する。 $\mathbf{S}_{FD}(T)$  の詳細は後述する。初期時刻  $T=0$  の時、 $\mathbf{N}_B(T)$  は、区間上流下流端の車両感知器とプローブ車両軌跡から与えられる。VT で求められた時刻  $T$  の時空間メッシュの状態ベクトル  $\mathbf{N}(T)$  は、次の時刻  $T+1$  の境界条件となる。FD ネットワークが単位メッシュに比べて密な場合、単位メッシュ内の平均累積交通量を算定する。

区分線系 FD の形状は、最大フローレート  $q_{max}$ 、臨海密度  $k_c$  および ジャム密度  $k_{jam}$  の 3 つのパラメータによって決定される。FD の変動は、 $q_{max}, k_c$  により確率的に変動す

ると仮定する。以上より、 $\mathbf{S}_{FD}(\mathbf{T})$ を、

$$\mathbf{S}_{FD}(\mathbf{T}) = \mathbf{f}_{FD}(q_{max} + \varepsilon, k_c + \gamma, k_{jam}). \quad (4-6)$$

と定義する。ここで、 $\varepsilon, \gamma$ はシステムノイズであり、正規分布を仮定する。 $k_{jam}$ は、定数と仮定する。

## 2) 観測モデル

観測モデルを以下に定義する。本モデルは、上流端の車両感知器とプローブ軌跡を組み合わせて、時空間上の累積交通量を観測する。観測モデルは、以下(a～f)を仮定する。

- a. 観測値取得のセンサーは、プローブ機器(GPS)と区間上流端・下流端の車両感知器とする。
  - b. 観測値は、システムモデルの1スキャンインターバルの間に走行するプローブ車両軌跡上の累積交通量とする。
  - c. 観測対象とするプローブ車両は対象区間の上流端から流入してきたもののみとする。(区間途中で流入してきたプローブ車両は対象外)
  - d. プローブ車両軌跡に対応した単位メッシュごとの累積交通量 $\hat{n}_m(T)$ が観測されると仮定する。観測値 $\hat{n}_m(T)$ の集合が、式(3-4)で定義した観測ベクトル $\hat{\mathbf{N}}(T)$ である。
  - e. 区間途中での出入り交通はないと仮定する。そのため、プローブ車両軌跡上の累積交通量は、図 4-3に示すように上流の車両感知器の累積交通量に等しい。
  - f. 式(3-5)で定義した観測誤差 $\mathbf{w}_T$ は、独立な正規分布 $N(0, \sigma_N^2)$ に従うと仮定する。
- 上記仮定と式(3-6)より尤度関数を以下のように定義する。

$$p(\mathbf{N}(T) | \hat{\mathbf{N}}(T)) = \prod_{m \in M(T)} \left( 1 / \sqrt{2\pi\sigma_N^2} \right) \exp \left\{ -1/2 \sigma_N^2 (\hat{n}_m(T) - (\mathbf{H}(T)\mathbf{N}(T))^{(m)})^2 \right\}. \quad (4-7)$$

ここで、 $\sigma_N^2$ は正規分布の分散、 $m$ は観測値のインデックス、 $M(T)$ は、時刻  $T$  の観測値が得られた単位メッシュのインデックス集合を示す。また、 $H(T)$ は観測マトリクス、 $(H(T)N(T))^{(m)}$ は $H(T)N(T)$ の  $m$  番目の要素を示す。

以降、提案したシステムモデル、観測モデルで構成される状態空間モデルを PFVT(Particle Filter on Variational Theory)と呼ぶ。以上のグラフィカルモデルを図 4-4 に示す。

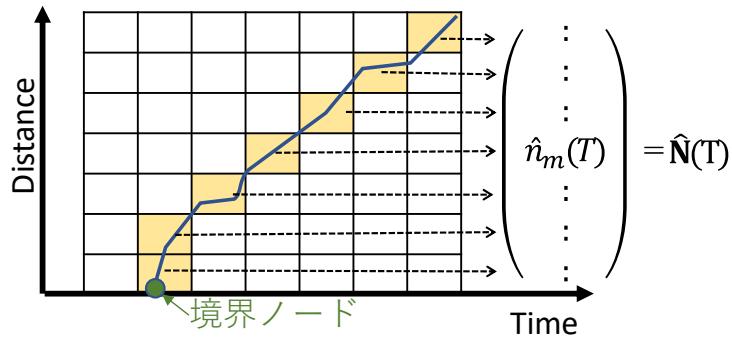


図 4-3 累積交通量の観測イメージ

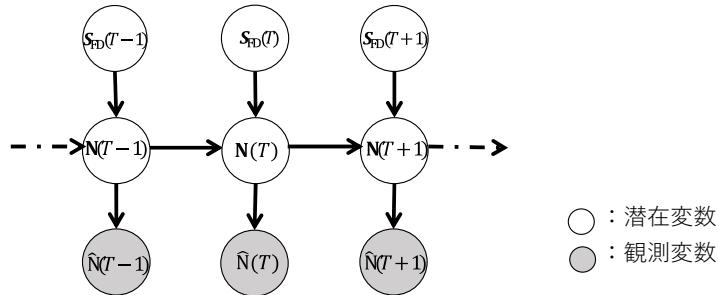


図 4-4 グラフィカルモデル

### 3) パーティクルフィルタ

事後分布は、北川<sup>5)</sup>に提案されたパーティクルフィルタを用いて推定する。パーティクルフィルタは、システムモデルや観測モデルが非線形な場合やノイズが非ガウスの場合であっても事後分布を算定可能といった特徴を持つ。パーティクルフィルタとは、時系列フィルタの一つで、事前分布や事後分布(条件付き分布)を多数のパーティクル(サンプル)でモンテカルロ近似表現するものである。カルマンフィルタの強い制約

を無くし、非線形モデルや非正規分布のノイズであっても適用可能といった特徴がある。パーティクルフィルタでは、以下の手順および図 4-5 のイメージで対象の状態推定を行う。

- 1) 初期分布  $p(x_0)$  に従い、初期状態  $x_{0|0}^{(i)}$  ( $i=1,2,\dots,N$ ) のパーティクルを生成
- 2) システムモデルにより各パーティクルの一期先の状態  $x_{t|t-1}^{(i)}$  を予測
- 3) 観測モデルに対応する尤度関数  $p(y_t | x_t^{(i)})$  より、各パーティクルの重み  $\omega_t^{(i)}$  を算出
- 4) 重み  $\omega_t^{(i)}$  に応じて、パーティクルを復元抽出し、パーティクル  $x_{t|t}^{(i)}$  をリサンプリング
- 5)  $t=t+1$  とし、計算終了まで 2)~4) を繰り返す。

ここで、 $i$  はパーティクルのインデックスを示す。本モデルでは、 $\mathbf{x}(T-1)$  の事後分布  $p(\mathbf{x}(T-1)|\mathbf{y}(T-1))$  と境界条件  $\mathbf{N}_B(T)$  により状態ベクトル  $\mathbf{x}(T-1)$  が推定される。具体的には、システムモデルにより、1,000 個のパーティクルを生成（1,000 回 VT を実行）し、モンテカルロ近似により予測分布を生成する。観測モデルにより、タイムステップごとに、尤度  $p(\mathbf{y}(T)|\mathbf{x}(T))$  を推定し、その後、式 (3-1) により事後分布  $p(\mathbf{x}(T)|\mathbf{y}(T))$  を推定する。上記モデルの検証結果は、Appendix 4 に示す。

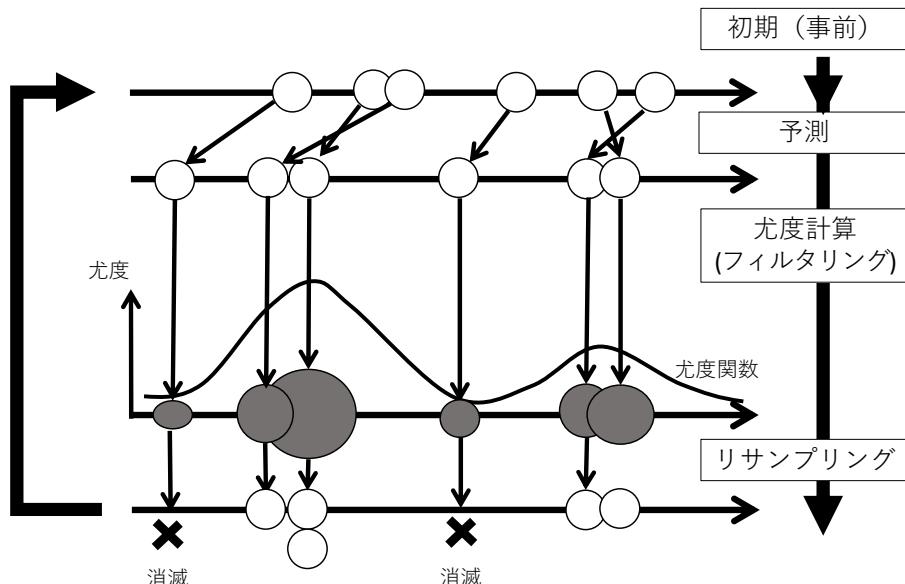


図 4-5 パーティクルフィルタ

## Appendix 5 一次元モデル(区間途中の流入出台数の推定)の定式化

### 5.1.1 はじめに

本節では、状態空間モデルとプローブ軌跡データを用いて区間途中の流入出台数を推定する手法を提案する。

高速道路では、オンランプ・オフランプ・ジャンクションでの流入出交通は本線交通に影響を及ぼす。しかしながら、一般道のほうが交差点(流入出箇所)の間隔が短いため、流入出交通が交通に与える影響が大きいと考えられる。

ネットワークの交通状態をモニタリングするためのセンサーとして車両感知器やプローブ機器(GPS)がある。車両感知器は、設置箇所の交通量や平均速度が把握可能であるが、設置箇所が限定的である。プローブ機器は、車両の状態が詳細に把握可能であるが、プローブ機器のみでは、交通の量的な把握はできない。本節では、区間途中の流入出台数が把握できない状況下において、流入出台数を推定する手法を提案する。流入出台数が推定できれば、Mehran et al.<sup>3)</sup>やMehran and Kuwahara<sup>4)</sup>の手法で渋滞状況を推定することができる。流入出台数の推定は、状態空間モデルを構築して、システムモデル(交通シミュレーションモデル)の推定結果の改善を図るデータ同化<sup>2)</sup>のアプローチをとる。前節では、VTを状態空間モデルに拡張し、区間途中の流入出がない条件下でFDの時系列変化を考慮し、一般道の渋滞状況をリアルタイムに推定するモデルを提案した。本モデルは、FDが時間変化する状況において既往のVTよりも高い精度で渋滞状況を推定することが可能である。しかし前述の区間途中の流入出の状況を考慮できていない。よって、区間途中での流入出がある場合の本線の渋滞を推定するためには、流入出を明示的にモデルに考慮する必要があると考える。

そこで、本節では、区間途中の流入出台数が把握できない状況下において、流入出台数を推定する手法を提案する。具体的には、Merhnan et al.<sup>3)</sup>の手法とプローブ軌跡デ

ータを用いて状態空間モデルを構築し、本線区間途中の流入出台数を推定する手法を提案する。本研究は、状態変数として、区間途中の流入出台数を取り扱っている点が2章で述べた既往研究と異なる。

### 5.1.2 状態空間モデルのコンセプト

#### 1) ネットワークおよび交通条件の仮定

まず、図 5-1に本研究が仮定するネットワークおよび流入出箇所を示す。同図に示すように対象区間は、信号交差点が含まれる一般道の単路部区間(以降、本線区間と表記する)とする。本線区間内での追い越しはないと仮定する。

次に区間途中の流入出箇所の設定を整理する。流入出可能な箇所の空間と時間を以下のように定義する。流入出可能な空間は信号交差点のみとする。流入出可能な時間(タイミング)は、本線区間の信号が青と黄色現示の時に本線区間からの流出が発生し、赤現示の時には本線区間への流入が発生すると仮定する。例えば、図 5-1の場合は、流入出可能な空間(信号交差点数)は1箇所、流入出可能な時間は、流入2箇所、流出2箇所である。この流入出可能な箇所の流入出台数を本研究では、箇所別の流入出台数と呼ぶこととする。本線区間の流入端と流出端の交通量(車両の到着分布)は車両感知器によって観測可能である。そして、区間途中の信号交差点で箇所別に実際に何台流入出したことかは不明であるが、信号現示と平均流入出台数は既知という状況を考える。

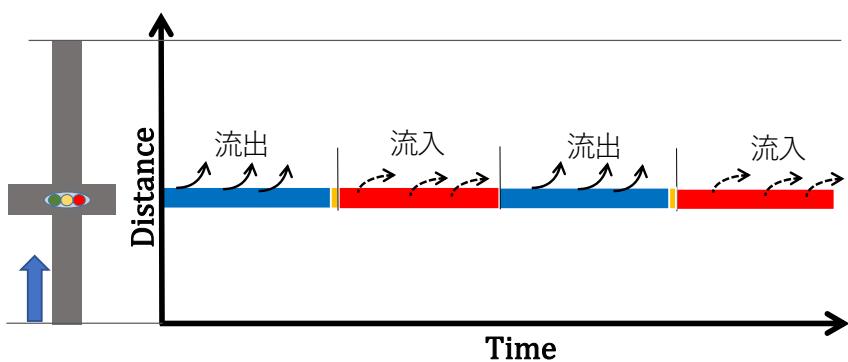


図 5-1 仮定するネットワークおよび流入出箇所

## 2) 状態空間の定義

本研究における状態空間を定義する。図 5-1 と同様の本線区間を考えよう。本線区間の区間長は  $L$  とする。図 5-2 に示すように本節のモデルの状態空間は、3-2 節と同様の時空間メッシュを考える。状態量は、各単位メッシュの累積交通量  $n_k(T)$  である。

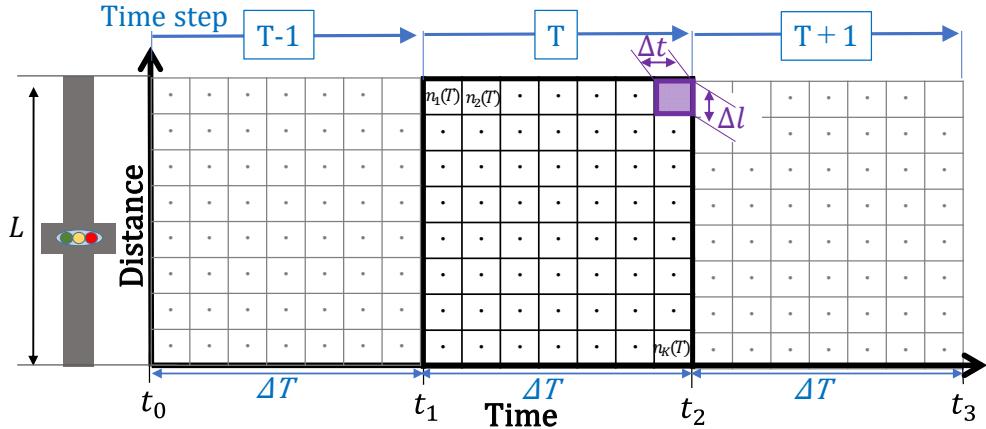


図 5-2 時空間メッシュ

## 3) 状態ベクトルの定義

状態ベクトルは前節と同様に  $n_k(T)$  の集合、 $\mathbf{N}(T)$  と定義する。 $\mathbf{N}(T)$  の詳細は、前節を参照されたい。

## 4) 観測ベクトルの定義

時刻  $T$  の時空間メッシュ内の観測ベクトル  $\hat{\mathbf{v}}(T)$  を定義する。観測量は、プローブ軌跡データから得られる速度である。図 5-3 に示すようにプローブ車両が、時刻  $T$  の時空間メッシュ内を走行した場合を考える。プローブ車両が走行した単位メッシュのインデックスの集合を  $\Omega_{k_o,T}$  と定義する。これは時刻  $T$  ごとに観測されるメッシュ数が異なるため、集合のサイズは異なる。 $k_{o,T}$  番目の単位メッシュの観測量を  $\hat{v}_{k_o}(T)$  と表記する。観測ベクトル  $\hat{\mathbf{v}}(T)$  を  $\hat{v}_{k_o,T}$  の集合ベクトルとして、

$$\hat{\mathbf{v}}(T) = (\dots \hat{v}_{k_o}(T) \dots)^T, \forall k_{o,T} \in \Omega_{k_o,T} \in \Omega_K, \quad (5-1)$$

$$|\Omega_{k_o,T}| \leq |\Omega_k| \quad (5-2)$$

と定義する。

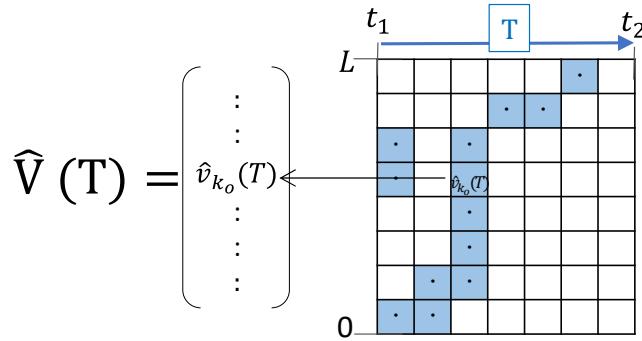


図 5-3 観測ベクトルと時空間メッシュの関係

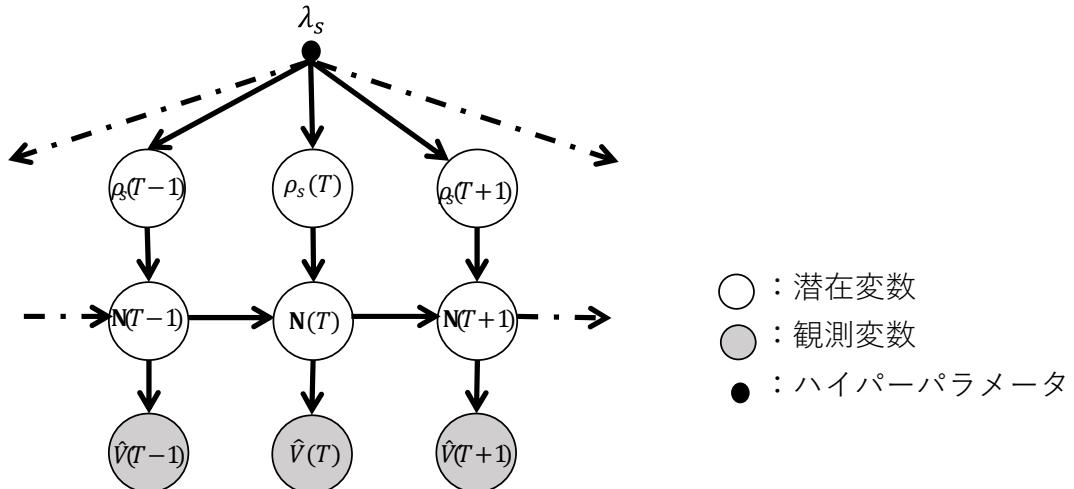
### 5.1.3 状態空間モデルの構築

#### 1) 状態空間モデルの仮定

図 5-4に本研究が仮定する状態空間モデルのグラフィカル表現を示す。ここで、 $\rho_s(T)$ は交差点ノード $s$ の時刻 $t$ における出入台数であり、確率変数である。 $\lambda_s$ は交差点ノード $s$ の平均出入台数である。出入台数 $\rho_s(T)$ は $\lambda_s$ を母数とする確率分布に従うものとする。 $\rho_s(T)$ の詳細は、後述する。状態ベクトル $\mathbf{N}(T)$ は出入台数 $\rho_s(T)$ と状態ベクトル $\mathbf{N}(T-1)$ に依存する。この関係より、状態ベクトル $\mathbf{N}(T)$ のシステムモデルを、

$$p(\mathbf{N}(T)|\mathbf{N}(T-1)) = \int_{\rho_s(T)} p(\mathbf{N}(T)|\mathbf{N}(1:T-1), \delta_{s,t}) p(\rho_s(T)) d\rho_s(T), \forall s \quad (5-3)$$

と定義する。なお、 $\mathbf{N}(T)$ は、後述する決定論的なモデルであるVTによって計算されるが、入力データである $\rho_s(T)$ が確率変数のため、VTのアウトプットは確率変数となる。観測ベクトル $\hat{\mathbf{V}}(T)$ は状態ベクトル $\mathbf{N}(T)$ に依存する。観測ベクトルと状態ベクトルの関係は観測モデルにより定式化する。本研究では、システムモデルと観測モデルにより、出入台数の事後分布 $p(\rho_s(T)|\hat{\mathbf{V}}(T))$ を推定する。なお、観測モデルの内容および事後分布の推定方法は、後述する。



## 2) 流出入台数が既知の場合の VT の拡張

本節では Mehran et al. による流入出台数が既知な場合の VT の拡張の概要について述べる。図 5-5 のように時空間上有る流入出点 A を中心に、forward wave speed  $v_f$  と backward wave speed  $-w$  の波面で区切った領域 I ~ IV を考える。Mehran et al. によると wave speed は、 $v_f, -w$  に限定されているので、A に流入/流出した場合の累積交通量は、領域 I の累積交通量にのみに影響する。例えば、A に 1 台の車両が流入した場合、領域 I の累積交通量を算定する初期条件である A-D 波面に接続する fw リンクのコストと D-E 断面の境界ノードのコストを図 5-5 のように 1 台増加させればよい。もしも A から車両が 1 台流出した場合は、同様の箇所のコストを 1 台減少させればよい。

以上の操作を以下の数式で整理する。点 A の流入出台数を  $\rho_A$  と表記する。A-D 波面に接続する fw リンクのインデックス集合を  $\Omega_{AD}$ 、リンク  $m$  のリンクコストを  $c_m$  と定義する。このとき、A-D 波面に接続する fw リンクコストは、

$$c_m = c_m + \rho_A, \forall m \in \Omega_{AD}. \quad (5-4)$$

として更新される。

同様に、D-E 断面における境界ノードのコスト更新を説明する。D-E 波面上の境界ノ

ードのインデックス集合を  $\Omega_{DE}$ , 境界ノード  $i$  の累積交通量を  $N_i$  と定義する.

このとき, D-E波面上の境界ノードの累積交通量は,

$$N_i = N_i + \rho_A, \forall i \in \Omega_{DE}. \quad (5-5)$$

として更新される.

流入出がある場合に, 上式の更新を繰り返すことで, 流出入量に整合したVTによる累積交通量の算定ができる. なお, 累積交通量算定後に領域 I を跨いだ車両軌跡を推定する際は, 初期条件の更新を加味する必要がある. 本手法の車両軌跡更新の詳細は Mehran et al.<sup>3)</sup>を参照されたい.

以上の流入出台数を考慮したVTによる累積交通量算定の関数を定義する. 上記のVTの拡張手法により時空間上の全てのノードの累積交通量を推定する関数を  $f_{VT}(\cdot)$  と表記する. 推定対象である時空間上の全てのノードの累積交通量の集合ベクトルを  $\mathbf{N}_{all}$  とする. そして,  $\mathbf{N}_{all}$  を求める関数を

$$\mathbf{N}_{all} = f_{VT}(\mathbf{N}_{B,all}, \mathbf{S}_{FD}, \rho_i) \quad (5-6)$$

と定義する. ここで,  $f_{VT}(\cdot)$  の引数である  $\mathbf{N}_{B,all}$  は境界ノードの集合ベクトル (境界条件),  $\mathbf{S}_{FD}$  は, Fundamental diagram の形状,  $\rho_i$  は点  $i$  の流入出台数である.

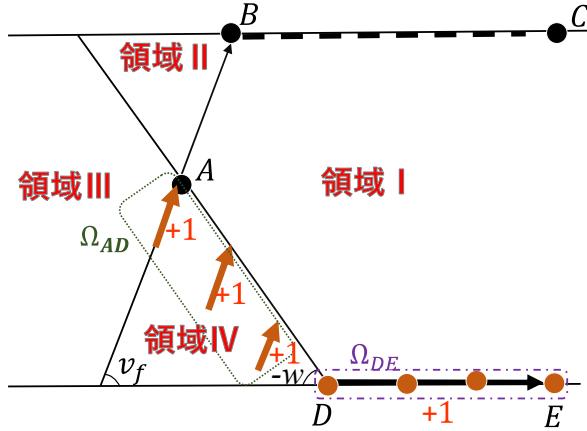


図 5-5 車両が流入/流出する場合のネットワークコストの調整

### 3) システムモデルの構築

本研究では、確率的に流入入台数が発生する場合のシステムモデルをMehran et al.を参考にモデル化する。

3.1節で述べたVTについて、境界条件とFDを引数としたVTの関数を便宜上、 $f_{VT}(\cdot)$ と表記する。時刻 $T$ の交差点ノード $s$ の流入出台数を $\rho_s(T)$ として表記する。流入出台数は、一般的に車両の到着分布で用いられるポアソン分布に従うと仮定する。この仮定と式(3-15)および $f_{VT}(\cdot)$ よりシステムモデルの関数を、

$$\mathbf{N}(T) = f_{VT}(\mathbf{N}(T-1), \mathbf{N}_B(T), \mathbf{S}_{FD}, \rho_s(T)), \quad (5-7)$$

$$\rho_s(T) \sim Poisson(\lambda_s), \forall s. \quad (5-8)$$

と定義する。ここで、前述した、境界条件、FD形状および流入出台数を引数としたVTの関数である。 $\mathbf{N}(T-1)$ は時刻T-1の状態ベクトル（時刻T-1の累積交通量）である。 $\mathbf{N}_B(T)$ は時刻Tにおける境界ノードの集合ベクトルならびに、 $\mathbf{S}_{FD}$ は、FDの形状である。式(3-17)の $\lambda_s$ はポアソン分布のパラメータであり、交差点ノードsの平均流入出台数である。 $\lambda_s$ は、前述した通り、本研究では既知とする。ただし、各交差点ノードで実際に何台の車両が流入出したかは不明とする。

システムモデルによる時間ステップごとの累積交通量の算定手順について述べる。

図 5-6にシステムモデルの時間更新イメージを示す。同図に示すように初期時刻 $t=0$ の時、境界ノードの累積交通量は、上流/下流端の車両感知器とプローブ軌跡によって計測された累積交通量によって初期の $\mathbf{N}(T)$ が決定される。その初期条件により算定された累積交通量 $\mathbf{N}(T)$ と $\mathbf{N}_B(T+1)$ を新たな境界条件として次の時間 $T+1$ 時の累積交通量 $\mathbf{N}(T+1)$ を算定する。

なお、単位メッシュのサイズによっては、VTのFDネットワークのノードと単位メッシュが一対一対応しない。そのため、単位メッシュ内に一つ以上のノードが含まれる( $dt < \Delta t$ を満たす)ように $dt, \Delta t$ を設定する必要がある。単位メッシュ内に複数のノードが含まれる場合は、単位メッシュ内のノードの累積交通量の平均値を状態量とした。

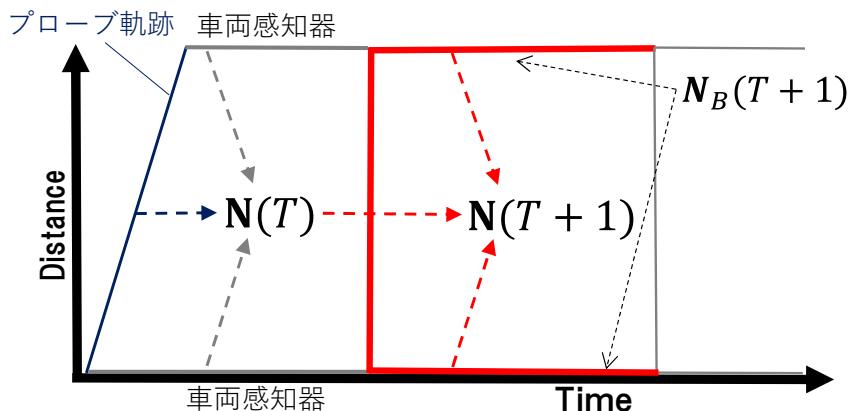


図 5-6 システムモデルの時間更新イメージ

#### 4) 観測モデルの構築

観測値は、図 5-7のようにプローブ車両軌跡により観測される単位メッシュごとの速度である。観測モデルは、状態ベクトルに観測ノイズが加えられたものが観測されると仮定し、

$$\hat{\mathbf{v}}(T) = \mathbf{H}(T)g_v(\mathbf{N}(T)) + \mathbf{w}(T), \quad (5-9)$$

$$\mathbf{w}(T) = (\dots w_{k_o}(T) \dots), \forall k_{o,T} \in \Omega_{k_o,T} \in \Omega_k, w_{k_o}(T) \sim N(0, \sigma^2). \quad (5-10)$$

と定義する。ここで、 $\mathbf{H}(T)$ は、全状態量から観測される状態量を取り出す次元数

$|\Omega_k| \times |\Omega_{k_o,T}|$  の観測行列である。 $g_v(\cdot)$  は、Appendix 1 の式(1-2)で定義した累積交通量から速度を算定する関数である。 $\mathbf{w}(T)$  は観測ノイズベクトルである。観測ノイズは、独立な正規分布を仮定する。 $\sigma^2$  は正規分布の分散である。

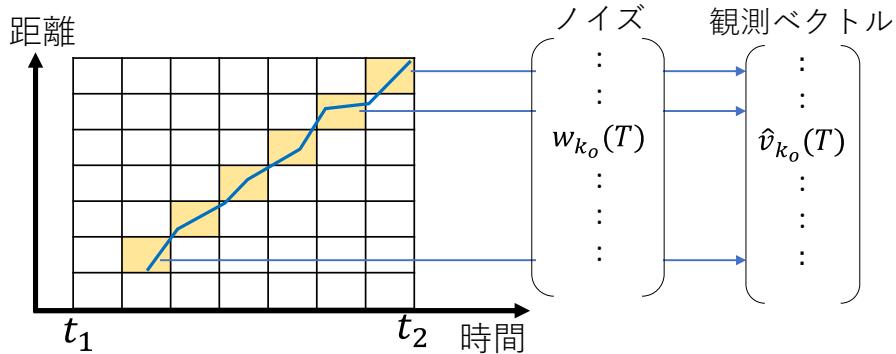


図 5-7 観測値取得イメージ

##### 5) 流出入台数の事後分布の推定

事後分布について以下に定義する。本研究では、観測値が得られた下での流入出台数の生成確率  $p(\rho_s(T)|\hat{V}(1:T))$  を事後分布として定義する。事後分布は、3.1.3(1)節の状態空間モデルの仮定から、

$$\begin{aligned}
 p(\rho_s(T)|\hat{V}(1:T)) &\propto \\
 p(\hat{V}(T)|\mathbf{N}(T)) \int_{\mathbf{N}(T)} \int_{\rho_s(T)} p(\mathbf{N}(T)|\mathbf{N}(T-1), \rho_s(T)) p(\rho_s(T)) p(\mathbf{N}(T-1)|\hat{N}(1:T-1)) d\mathbf{N}(T) d\rho_s(T), \forall s.
 \end{aligned} \tag{5-11}$$

と書ける。 $p(\mathbf{x}_{t-1}|\mathbf{y}_{1:t-1})$  は、T-1時の予測結果である。また、尤度関数は、

$$p(\hat{V}(T)|\mathbf{N}(T)) = \prod_{k_{o,T}} \left( 1/\sqrt{2\sigma^2} \right) \exp \left\{ \left( \hat{v}_{k_o}(T) - (\mathbf{H}(T) g_v(\mathbf{N}(T)))_{k_{o,T}} \right)^2 \right\}, k_{o,T} \in \Omega_{k_{o,T}}$$

(5-12)

と書ける。ここで、 $\sigma^2$ は式(3-10)で定義した正規分布の分散、 $k_{o,T}$ は時刻Tにおいてプローブ車両が走行した単位メッシュのインデックスを示す。また、 $(\mathbf{H}(T)g_v(\mathbf{N}(T)))_{k_{o,T}}$ は $\mathbf{H}(T)g_v(\mathbf{N}(T))$ の $k_{o,T}$ 番目の要素を示す。

$p(\rho_s(T)|\hat{\mathbf{V}}(1:T))$ の具体的な計算方法を以下に整理する。3.1.3(1)節の状態空間モデルの仮定により、本研究の状態空間モデルでは、 $\rho_s(T)$ と $\mathbf{N}(T-1)$ の値が決定すれば $\mathbf{N}(T)$ が計算できる。本研究では、 $\rho_s(T)$ は、交差点ノードsの流入出台数であることから、

- a)  $\rho_s(T)$ は、自然数である（負の数、小数値はとらない）。
- b)  $\rho_s(T)$ の実現可能な上限値は、交差点ノードsの信号現示時間の長さより決定される。

と考えた。したがって、実現可能な $\rho_s(T)$ は列挙可能であり、 $\rho_s(T)$ に対応する全ての $\mathbf{N}(T)$ が算定できれば、積分計算なしで、式(3-11)の結果が $\mathbf{N}(T)$ の和で近似的に求められると考えた。以上より、本研究では以下の計算ステップで $p(\rho_s(T)|\hat{\mathbf{V}}(1:T))$ を計算した。

- ① 信号現示時間より $\rho_s(T)$ の上限値を求め、実現可能な $\rho_s(T)$ を列挙
- ② ①で列挙した $\rho_s(T)$ を用いて、 $\mathbf{N}(T)$ を算定
- ③ ②で算定した $\mathbf{N}(T)$ と式(3-21)より尤度を計算
- ④ ②、③の結果と式(3-20)より $p(\rho_s(T)|\hat{\mathbf{V}}(1:T))$ を計算

本節の最後に実現可能な流入出台数の列挙方法(上記ステップ①)を整理する。例えば、時刻tにおいて、交差点ノードsで流入台数 $\delta_{s,t}$ が発生している状況を考える。実現可能な流入台数 $\rho_s(T)$ の最大値 $\rho_s^{max}(T)$ を

$$\rho_s^{max}(T) = t_{s,red}/t_{min} \quad (5-13)$$

として求める。ここで、 $t_{s,red}$ は交差点ノードsの信号の赤現示時間、 $t_{min}$ は最低車頭時

間である。流入出台数は、自然数であるため、実現可能な流入台数を、 $\rho_s(T) = \{1, 2, \dots, \rho_s^{max}(T)\}$  のように列挙する。 $\rho_s(T)$  の生成確率は、式(3-17)より求めることが出来る。なお、ノード  $s$  で流出台数  $\rho_s(T)$  が発生している場合は、式(3-22)の  $t_{s,red}$  を流出箇所の信号の青(+黄)現示時間  $t_{s,blue}$  に置き換えて最大流出量を求めて上記の手順で計算すればよい。モデルの検証結果は、後述する。

## Appendix 6 一次元モデルの検証

モデル検証は、モデル検証は、双子実験<sup>6)</sup>の枠組みで実施する。双子実験の詳細は、本編 4.1 節を参照されたい。

### 6.1.1 一次元モデル(FD の揺らぎの考慮)の検証

本節では、前述した Variational theory(VT)<sup>2)</sup>をベースとした一次元モデル(FD の揺らぎの考慮)の検証を行う。なお、本節では、状態空間モデルのことを PFVT と呼ぶ。

#### (1) 双子実験によるモデル検証

##### 1) 交通シミュレーションの概要

モデル検証の概要を述べる。まず、交通シミュレーションにより、ベンチマークデータ(真値)を生成した。交通シミュレーション条件を表 6-1、表 6-2 に示す。シミュレーションにより生成した全車両軌跡を図 6-1 に示す。プローブデータは、ベンチマークデータからランダム抽出した。ベンチマークデータ生成に用いた FD の設定を下記に示す。図 6-2 に FD と S-V 条件の設定法を示す。同図に示すようにベース FD を設定し、ベース FD を基にノイズ  $\varepsilon$ 、 $\gamma$  を用いて 300 パターンの FD を生成した。ノイズ  $\varepsilon$ 、 $\gamma$  は、ベース FD の  $q_{max}$ 、 $k_c$  を  $\pm 20\%$  の範囲で変動させる一様分布を仮定する。生成した 300 パターンの FD を交通シミュレーションに入力し、3 ベンチマークデータ(300 台の車両軌跡)を生成した。

VT は、ベース FD を用いて事項する。図 6-2 と同様の手法で、ノイズ  $\varepsilon$ 、 $\gamma$  を用

いて 1,000 パターンの FD を生成し, PFVT に入力した. この 1,000 パターンの FD を用いて, VT が 1,000 回繰り返し計算し, 予測分布を生成した.

表 6-1 シミュレーション条件

| 項目                           | 設定値                  |
|------------------------------|----------------------|
| 区間長                          | 1.0 km               |
| 信号                           | 200m ピッチで 4 基設置      |
| シミュレーション時間                   | 30 [分]               |
| 交通量                          | 300 [台]              |
| プローブ車両台数                     | 30 [台]               |
| 車両の発生分布                      | 一様分布                 |
| S-V 条件*                      | 個々の車両で異なる S-V* 条件を設定 |
| $dt$ : FD ネットワークにおける FD の時間幅 | 1.0 [秒]              |
| $\Delta t$ : 単位メッシュの時間幅      | 1.0 [秒]              |
| $\Delta T$ : 状態空間モデルのタイムステップ | 300 [秒] (= 5 [分])    |

\*S-V: Space clearance–Velocity の略

表 6-2 信号現示

|          | 青   | 黄 | 赤  | サイクル長 | オフセット |
|----------|-----|---|----|-------|-------|
| Signal 1 | 117 | 3 | 30 | 150   | 0     |
| Signal 2 | 117 | 3 | 30 | 150   | 5     |
| Signal 3 | 117 | 3 | 30 | 150   | 10    |
| Signal 4 | 57  | 3 | 30 | 90    | 15    |

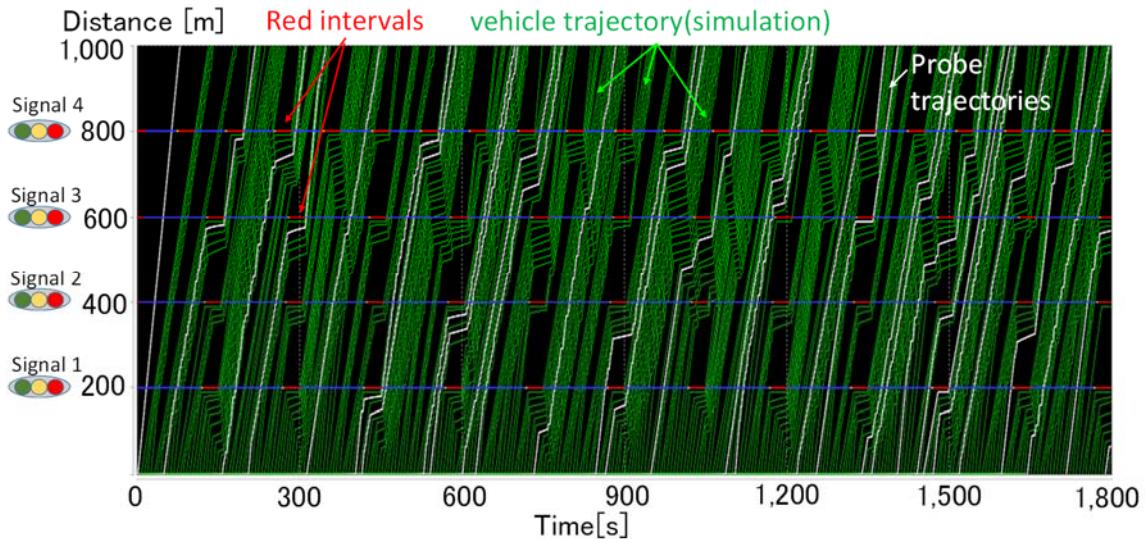


図 6-1 ベンチマークデータ（全車両軌跡）

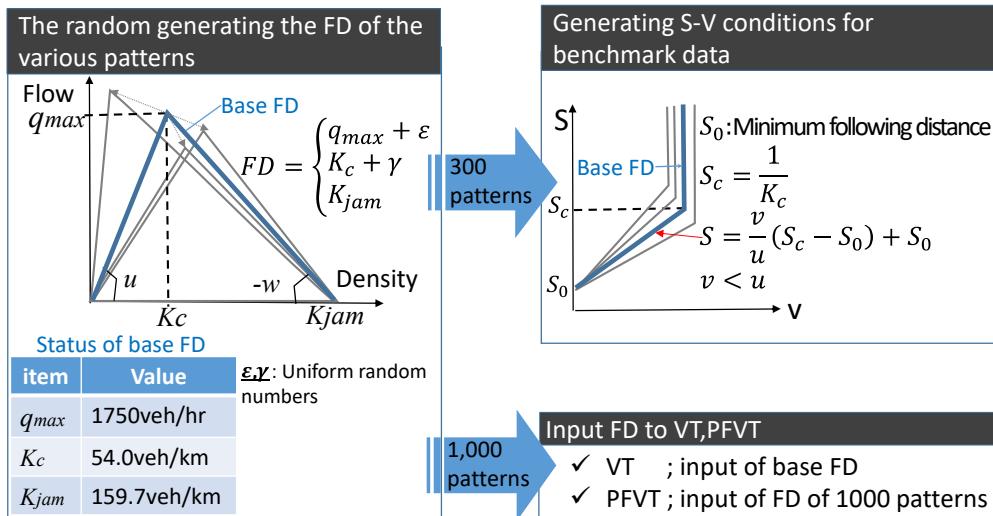


図 6-2 FD と S-V 条件の設定

## 2) 交通状態推定方法とモデル精度検証方法

時空間上の累積交通量は、区間上下端の車両感知器、プローブ軌跡データを用いて、VT、PFVTにより推定される。PFVTの計算タイムステップは、300秒とした。モデル精度は、累積交通量と渋滞の推定結果をVT、PFVTで比較した。最後に、プローブデータの抽出精度と累積交通量の推定精度との関係を分析した。VTとPFVTの時空間ノードの位置は異なるため、単位メッシュ(10秒×20m)の平均値を比較検証した。

### 3) 累積交通量の検証結果

モデルによる累積交通量の推定誤差は、MAE(平均絶対誤差), MAPE(平均絶対誤差率)と誤差の3D図により評価した。MAEは、真値と推定値の誤差の絶対値の平均値である。MAPEは、真値と推定値の平均誤差率の平均値である。MAEとMAPEは下式のように定義する。

$$\text{MAE} = \frac{1}{K} \sum_{k=1}^K |n_k^{true} - n_k|. \quad (6-1)$$

$$\text{MAPE} = \frac{100}{K} \sum_{k=1}^K \left| \frac{n_k^{true} - n_k}{n_k} \right|. \quad (6-2)$$

ここで、 $K$ はデータ数、 $n_k^{true}$ は、真の累積交通量(ここではシミュレーション結果)、左下の添え字の $k$ は $n$ のインデックスを示す。 $n_k$ はモデルによる累積交通量の推定値である。なお、累積交通量は、タイムスペース上の10秒×20mのメッシュ平均値を用いた。

図6-3に累積交通量の推定誤差のヒートマップを示す。同図を見ると、既往VTに比べてPFVTは、累積交通量の誤差が小さい傾向であることがわかる。最大誤差は、21.2台から10.5台と9.7台減少している。また、プローブ軌跡周辺や区間上流端(始点)の周辺は誤差が比較的小さいことが推察される。

MAEとMAPEの評価結果を図6-4に示す。これを見ると、PFVTの方が既往VTよりもMAE, MAPEが約4割減少していることがわかる。

次に、累積交通量の誤差とプローブデータの軌跡の関係を定量的に把握するために、タイムスペース上の誤差分布とプローブ取得からの経過時間の関係を分析した。具体的には、図6-5に示すように、信号設置断面、プローブ取得からの経過時間別に誤差値を集計し分析を行った。図6-6にプローブ取得からの経過時間と誤差の関係を示す。既往VTは、プローブ取得後60秒を超えたあたりから誤差値のばらつきが大きいのにに対し、PFVTは誤差の値が小さく、値のばらつきも小さいことがわかる。誤差値を集計

し、バブルチャートにより可視化したものを図 6-7 に示す。既往 VT では、区間の始点から距離が離れると誤差が大きくなる傾向が読み取れる。また、800m断面においてプローブ取得後 150 秒後の誤差が最大となっている。一方、PFVT は、距離やプローブ取得からの経過時間が離れても誤差の発生が抑えられていることがわかる。

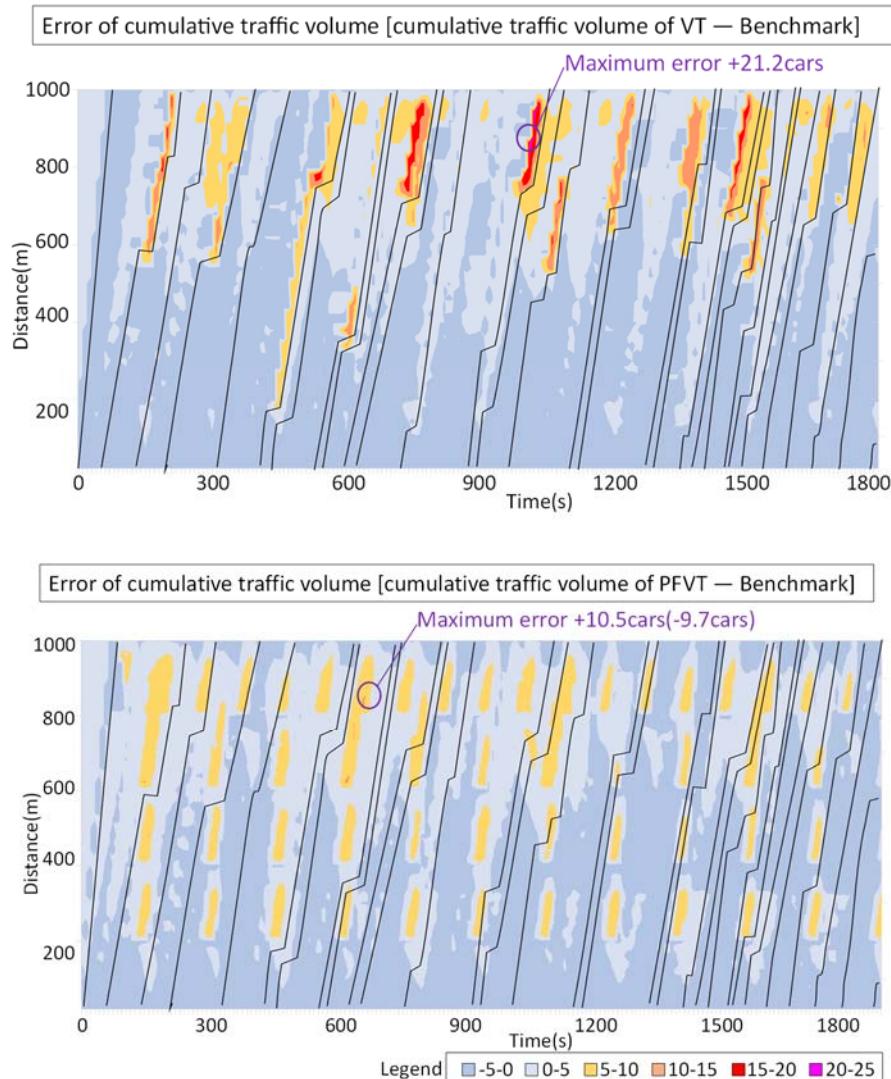


図 6-3 累積交通量の誤差のヒートマップ(上段 ; VT, 下段 ; PFVT)

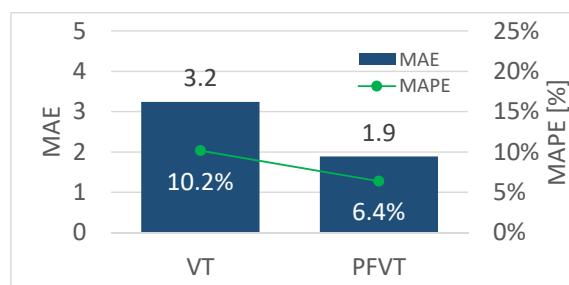


図 6-4 MAE, MAPE の比較

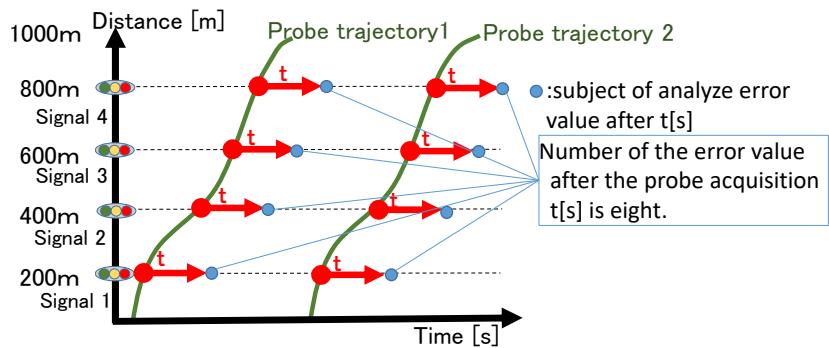


図 6-5 時空間上のプローブ軌跡取得後の誤差のイメージ

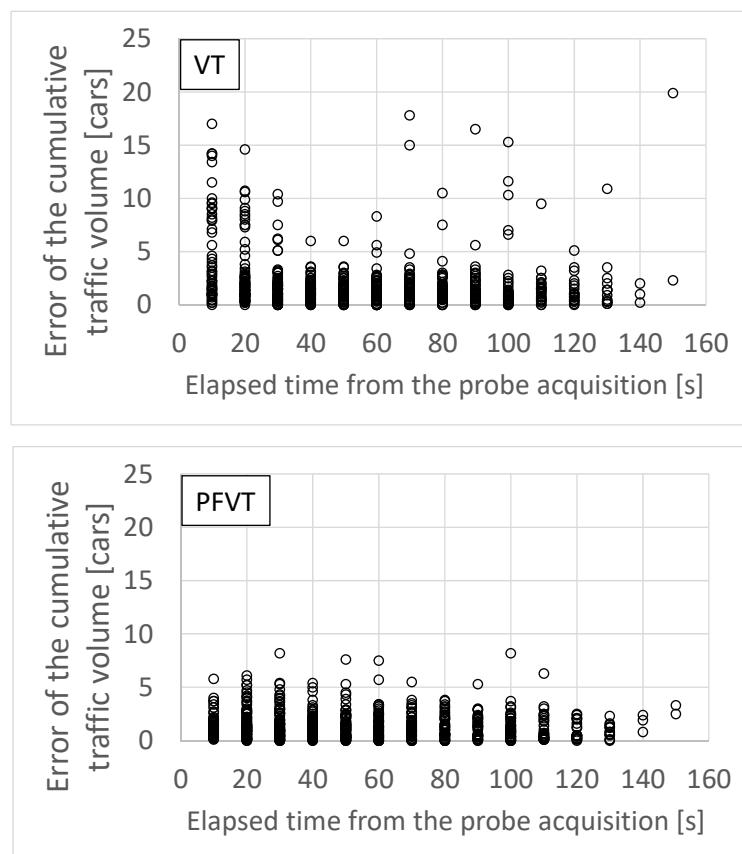
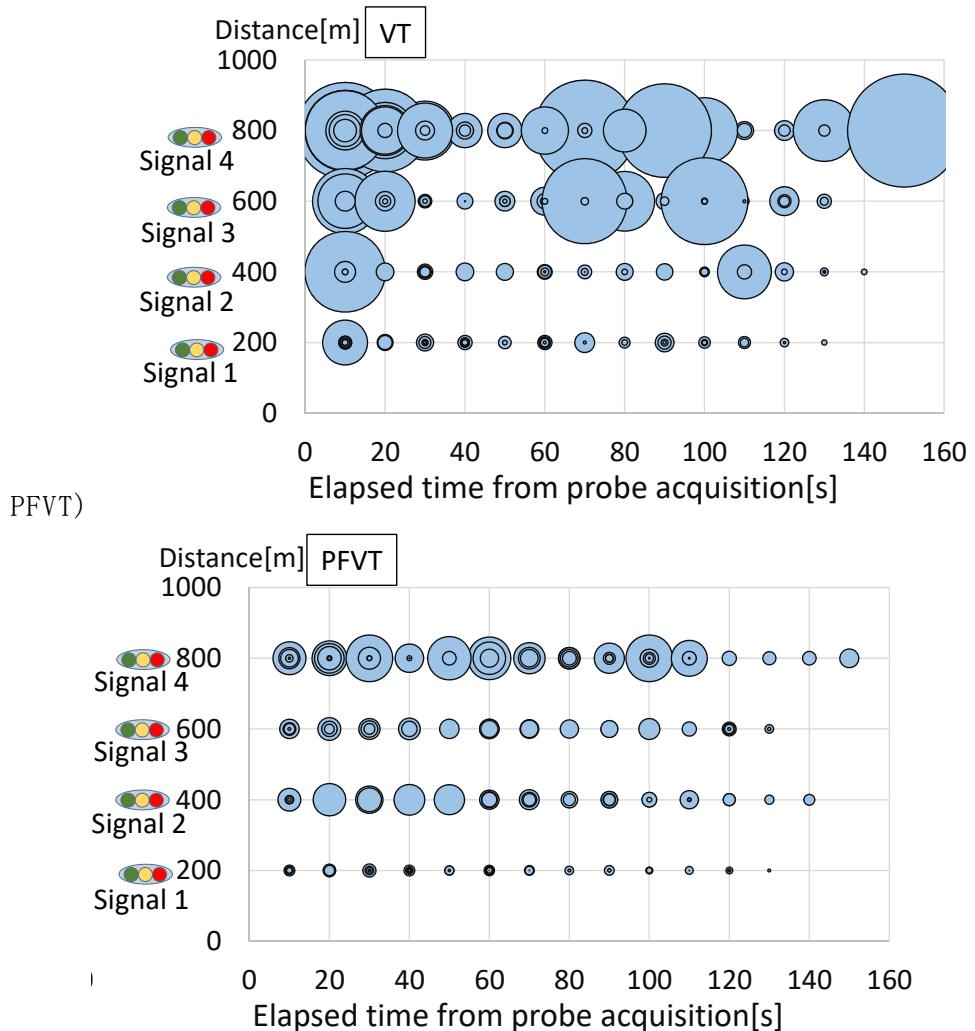


図 6-6 プローブ軌跡取得経後の過時間と累積交通量の誤差の関係(上段 ; VT, 下段 ; PFVT)



\*円の大きさは誤差の大きさを示す.

図 6-7 プローブ取得からの経過時間と信号断面の誤差分布との関係  
(上段 ; VT, 下段 ; PFVT)

#### 4) 渋滞推定精度の検証結果

渋滞発生状況図を図 6-8 に示す。同図を見ると、シミュレーション結果(真値)では、信号 3 や 4 をボトルネックとした渋滞が発生しているが、既往 VT では、信号 4 の先の区間を渋滞箇所なわち先詰まりと推定している。一方、PFVT では、シミュレーションと同様に信号 3 や 4 の箇所を渋滞と推定しており、比較的精度が良いと考えられる。

以下に、Precision(適合率)と Recall(再現率)および F 値の分析結果について述べる。Precision と Recall は情報検索の有効性を示す評価指標として使われている。Precision は検索結果(モデルによる推定結果)に適合データ(正解)がどれだけ含まれるかを示す

適合率である。Recall は、適合データ全体のどれだけが検索結果(推定結果)に含まれているかを示すものである。そして Precision と Recall の調和平均が、F 値(F-measure)である。一般に、Precision と Recall は、トレードオフの関係にある。そして F 値が高ければ、モデルの性能が良いことを意味する<sup>7)</sup>。

本研究での Precision とは、モデルが渋滞と推定した中で、実際も渋滞となっているものの割合とする。Recall とは、実際に渋滞が発生している場所の中で、モデルが渋滞と推定しているものの割合と定義する。ここでは、メッシュ速度を対象に速度 20km/h 未満を渋滞として評価を行った。Precision, Recall 算定にあたって、実際の渋滞状況とモデルで推定された渋滞の関係を表 6-3 のように定義する。表 6-3 の内容を踏まえ、Precision と Recall および F 値の算定方法を以下に示す。

$$Precision = \frac{TP}{TP + FP}, \quad (6-3)$$

$$Recall = \frac{TP}{TP + FN}, \quad (6-4)$$

$$F = \frac{2 \times Precision \times Recall}{Precision + Recall}. \quad (6-5)$$

ここで、 $TP, FP, FN$  は表 6-3 の関係に該当するメッシュ数である。なお、上記定義より  $0 \leq$  適合率  $\leq 1$  と  $0 \leq$  再現率  $\leq 1$  であることから、 $0 \leq F$  値  $\leq 1$  となる。

図 6-9 に各々の指標の算定結果を示す。同図を見ると、既往 VT の Precision は 0.41 に対して、PFVT は 0.85 と非常に高い値となっている。Recall についても同様に PFVT の値が高い結果となった。そして、F 値は、既往 VT が 0.25 に対して PFVT は 0.72 と約 3 倍の値となった。

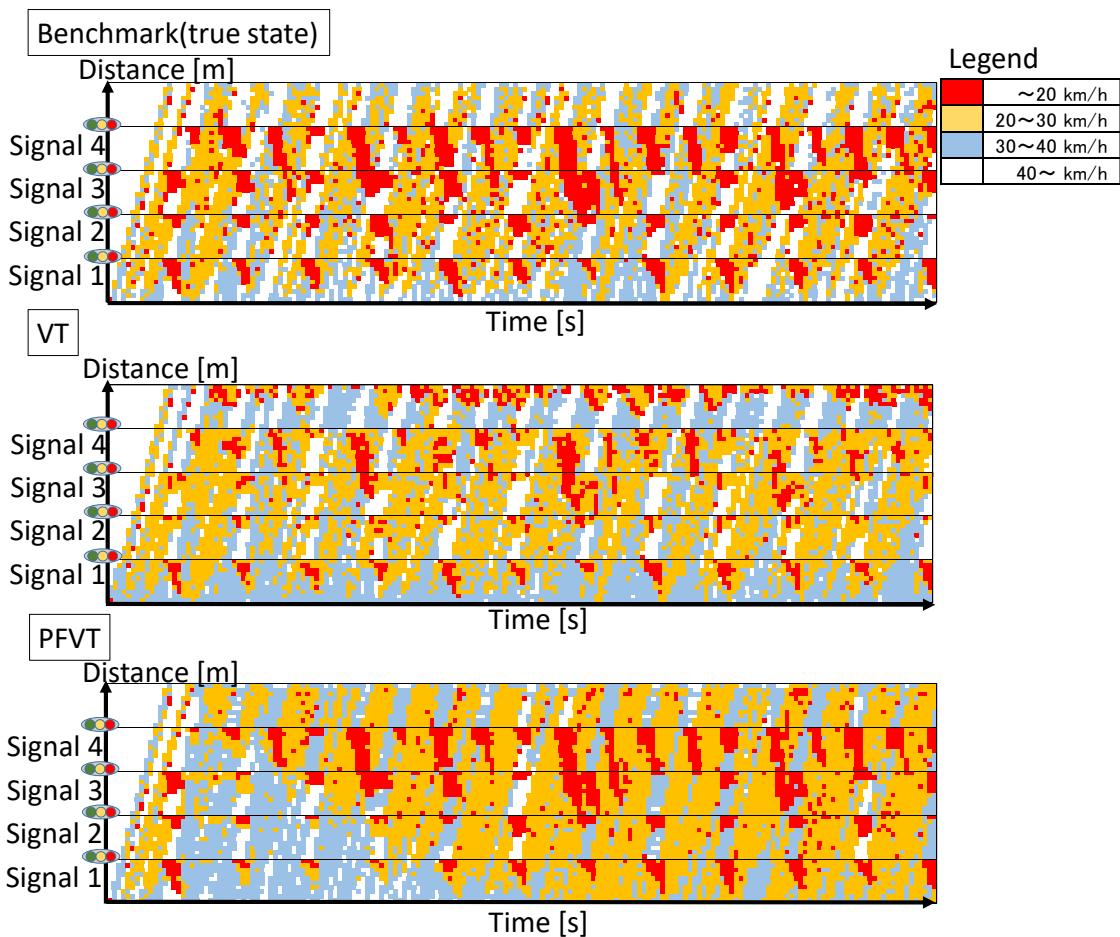


図 6-8 滞滞推定状況

表 6-3 実際の滯滞状況とモデルの推定結果の関係

|              |     | 真値(実際の滯滞状況)            |                        |
|--------------|-----|------------------------|------------------------|
|              |     | 滯滞                     | 非滯滞                    |
| 推定値<br>(モデル) | 滯滞  | TP<br>(True Positive)  | FP<br>(False Positive) |
|              | 非滯滞 | FN<br>(False Negative) | TN<br>(True Negative)  |

※セルの平均速度 20km/h 未満を滯滞と定義

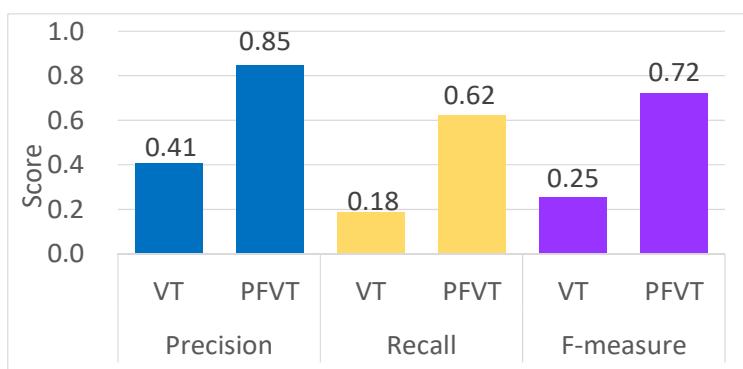


図 6-9 Precision, recall および F-measure

### 5) プローブデータの抽出率とモデル精度の関係

ここでは、プローブデータの抽出率とモデル精度の関係を分析する。プローブ抽出率を10~50%まで変更した場合の累積交通量のMAEの変化を図 6-10に示す。同図を見ると、プローブ抽出率が低い場合は、VTとPFVTのMAEに差が生じているが、プローブ抽出率が高くなるにつれ、VTとPFVTが近づき、抽出率50%の場合、概ね差はない。すなわち、プローブ抽出率が高くなっても、VTほど精度向上しない。

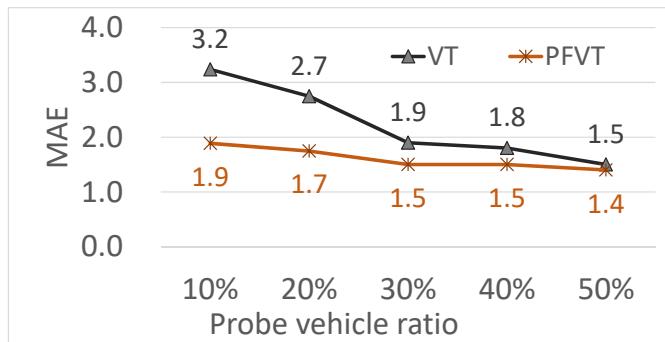


図 6-10 プローブ抽出率とモデル精度の関係

### (2) 実測データによるモデル検証

#### 1) 概要

モデル検証は、図 6-11 に示すように、東京都駒沢通りの 1,600m 区間(仲町～駒沢公園)を対象とした。対象区間は、1 車線区間、信号交差点 8 と信号交差点のない交差点が含まれる。分析時間は、2006 年の 9 月 1 日の朝ピークの 8:45～9:30 とした。プローブデータは、GPS を搭載したタクシーにより取得した。AVI データは、車両感知器のように個々の車両の通過タイミングを観測する。AVI カメラ 2 は、モデルに入力せずにモデル検証に用いた。状態空間モデルのパラメータは表 6-4 に示す。

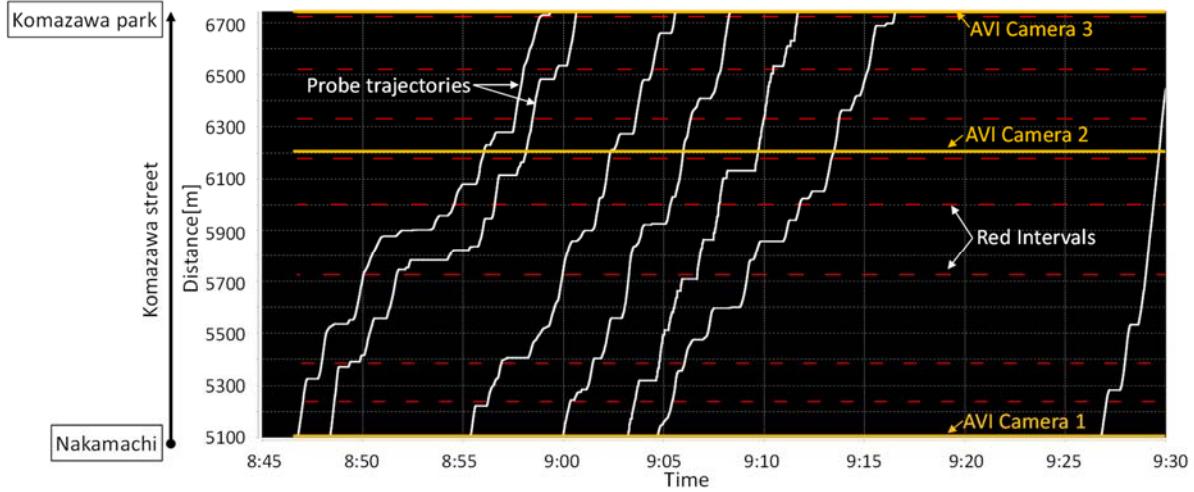


図 6-11 分析対象区間（信号赤現示，プローブ車両軌跡，AVI 設置個所）

表 6-4 モデルパラメータ

| 項目                           | 設定値              |
|------------------------------|------------------|
| $dt$ : FD ネットワークにおける FD の時間幅 | 2.0 [秒]          |
| $\Delta t$ : 単位メッシュの時間幅      | 2.0 [秒]          |
| $\Delta T$ : 状態空間モデルのタイムステップ | 300 [秒] (=5 [分]) |
| パーティクルの数                     | 2,000            |
| FD パラメータ                     |                  |
| $v_f$                        | 32.4[km/h]       |
| $-w$                         | 17 [km/h]        |
| $q_{max}$                    | 1800 [veh/hr]    |
| $k_c$                        | 55 [veh/km]      |
| $k_{jam}$                    | 154[veh/km]      |

## 2) 検証結果

AVI カメラ 2 のフローレートの MAE, MAPE の検証結果を図 6-12 に示す。MAE, MAPE ともに VT に比べて PFVT のほうが小さく、MAPE は 15% 低い。渋滞推定状況を図 6-13 に示す。VT と PFVT では、推定しているボトルネックが異なる。これは、図 6-12 で示したフローレートが渋滞推定精度に影響していると推察される。各々の FD の尤度の時系列変化グラフを図 6-14 に示す。このグラフの x 軸は時刻、y 軸は FD の ID、z 軸は尤度である。同図を見ると、時々刻々と FD の尤度が変化していることがわかる。VT は、FD が実際の交通流と異なる場合、推定精度が低下する。したがって、PFVT では、尤度の高い FD を逐次選択しているため、VT よりも推定精度が高いと推察される。

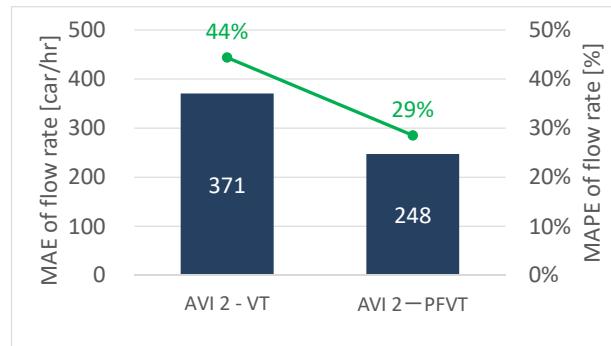


図 6-12 AVI カメラ 2 のフローレート (MAE,MAPE)

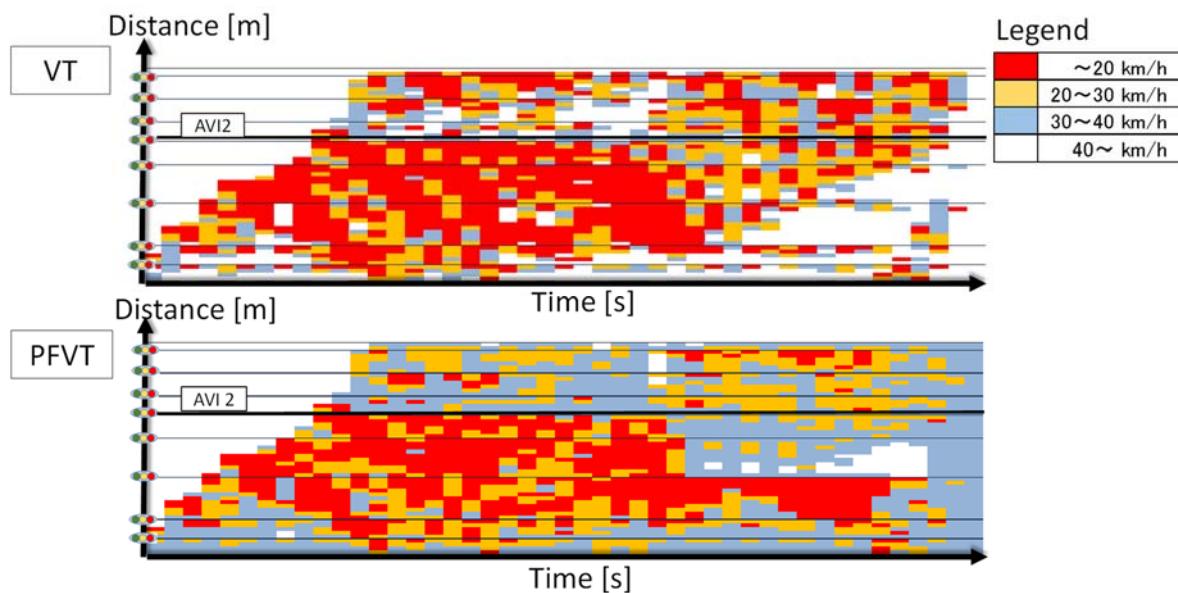


図 6-13 渋滞推定状況

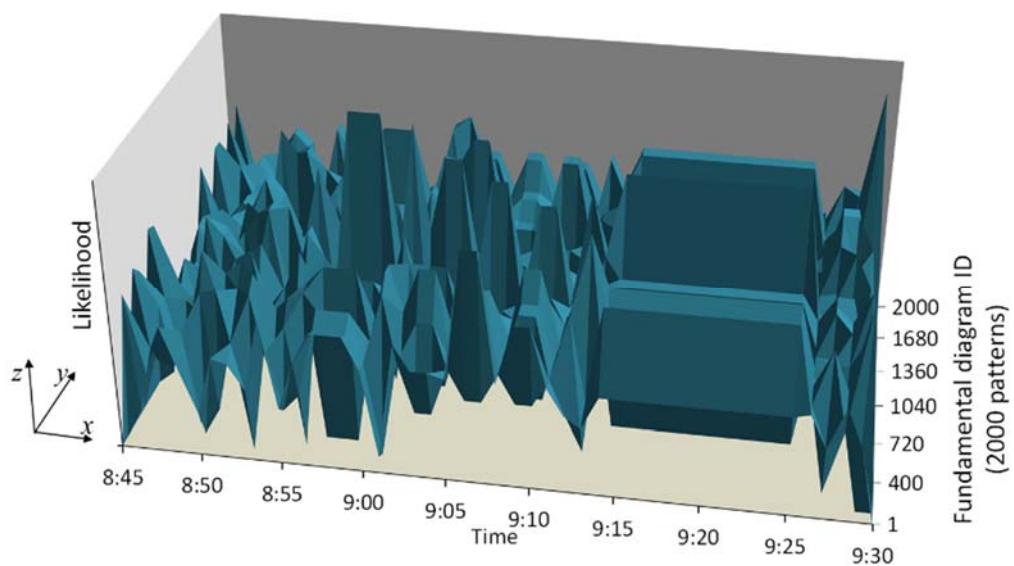


図 6-14 FD の時系列変化

### (3) まとめと今後の課題

モデル検証は、交通シミュレーションによって生成したベンチマークデータを用いた。交通シミュレーションによるモデル検証の結果、提案モデルは、既往の確定的な VT よりも渋滞の推定精度が高いことがわかった。最後に、実データの検証(Validation)として提案モデルを東京の駒沢通りに適用した。車両感知器のフローレートとモデルの乖離を評価した結果、既往の VT よりも PFVT の方が乖離が小さいことがわかった。その理由は、VT は、FD が実際の交通流と異なる場合、推定精度が低下する。したがって、PFVT では、尤度の高い FD を逐次選択しているため、VT よりも推定精度が高いと推察される。

今後の課題は以下のとおりである。

#### 1) 他の地域への適用

他の地域に本モデルを適用し、モデルの性能を検証する必要がある。

#### 2) 二次元ネットワークの交通状態推定手法の構築

本節では、一次元単路部かつ区間途中流入出交通なしの仮定の下でモデル化を行った。しかしながら、実際は、二次元ネットワークを交通が流れるため、区間途中や交差点での流入出やドライバーの経路選択が発生する。そのため、区間途中の流入出等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が必要と考える。

### 6.1.2 一次元モデル(区間途中の流入出台数の推定)の検証

本節では、3.3 節で述べた VT を拡張した一次元モデル(区間途中の流入出台数の推定)の検証を行う。

#### (1) 交通シミュレーションの概要

双子実験で用いる交通シミュレーションは、個々の車両の車間距離の時間進展を記述した追従モデルを用いた。追従モデルは、図 6-15 に示すようにシステムモデルの FD に対応した S-V 条件を用いる。図 6-15 の  $S_0$  は最小車頭距離、 $S_c$  は、臨界車頭距離であり、

$S_0 = 1 / k_{jam}$ ,  $S_c = 1 / k_c$  の関係が成り立つ。したがって、車両  $i$  の S-V 条件は、

$$S_{i,t} = \frac{v_{i,t}}{u} (S_c - S_0) + S_0, \text{s.t. } v_{i,t} \leq u \quad (6-6)$$

と書ける。ここで、 $v_{i,t}$  は  $t$  時の車両  $i$  の速度、 $S_{i,t}$  は、 $t$  時の車両  $i$  と車両  $i$  の前方車両との車頭距離である。交通シミュレーションでは、式(3-28)により、逐次全車両の車両速度を算定し、車両位置を更新する。このようにベンチマークデータと状態空間モデルの推定結果は同じ FD に従って交通流が生成（同じシステムモデルで交通流が生成）されており、このベンチマークデータを用いれば双子実験と同様の枠組で評価可能と考えた。

交通シミュレーションと状態空間モデルの設定条件を表 6-5～表 6-7 に示す。表 6-5 に示すように、シミュレーションのネットワークは、信号交差点を含む区間長 1km の単路部とした。まず、交通シミュレーションでベンチマークデータ（全車両の軌跡）とプローブデータを生成する。交通シミュレーションでは、全車両共通の S-V 条件を設定した。プローブデータは、ベンチマークデータの全車両の中から、ランダム抽出して生成した。生成したベンチマークデータを図 6-16 に示す。状態空間モデルは、表 6-6 の信号現示データ、表 6-7、図 6-15 のパラメータならびにプローブデータ、区間上流/下流端の交通量を用いた。

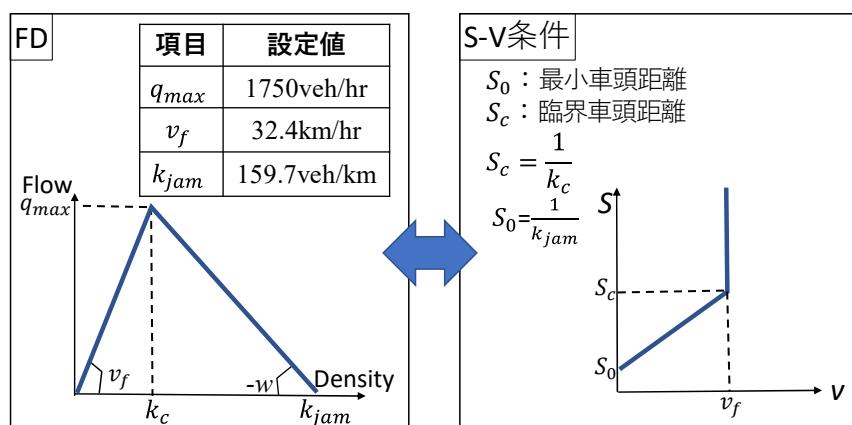


図 6-15 FD および S-V 条件の設定

表 6-5 交通シミュレーション条件

| 項目              | 設定値                                                                                                                                                                                                                                                     |
|-----------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| 区間長／車線数         | ・ 1.0 km                                                                                                                                                                                                                                                |
| 車線数             | ・ 1車線                                                                                                                                                                                                                                                   |
| 信号機数, 設置間隔      | ・ 2基{信号1, 信号2}, 400m間隔で設置                                                                                                                                                                                                                               |
| シミュレーション時間      | ・ 30 分                                                                                                                                                                                                                                                  |
| 全交通量(本線+流入)     | ・ 377台 (300台 + 77台)                                                                                                                                                                                                                                     |
| 流入車両台数 $\delta$ | <ul style="list-style-type: none"> <li>・ 流入箇所 : 11箇所</li> <li>※信号1の赤現示を流入箇所として設定</li> <li>・ ポアソン分布(<math>\lambda=7</math>)に従って発生させた<math>\delta</math>をシミュレーションに入力</li> <li><math>\delta = \{6, 7, 6, 7, 3, 9, 10, 7, 8, 9, 5\}</math>, 計77台</li> </ul> |
| プローブ車両生成方法      | ・ 全車両の中からランダム抽出                                                                                                                                                                                                                                         |
| 車両発生方法          | ・ 一様分布                                                                                                                                                                                                                                                  |
| S-V条件           | <ul style="list-style-type: none"> <li>・ 全車両同じ S-V 条件を設定</li> <li>・ 図 6-15のFDに対応したS-V条件を生成</li> </ul>                                                                                                                                                   |

表 6-6 信号現示(秒)

|      | 青   | 黄 | 赤  | サイクル長 | オフセット |
|------|-----|---|----|-------|-------|
| 信号 1 | 117 | 3 | 30 | 150   | 10    |
| 信号 2 | 57  | 3 | 40 | 100   | 15    |

表 6-7 状態空間モデルの計算条件

| 項目                    | 設定値                                                         |
|-----------------------|-------------------------------------------------------------|
| FD                    | ・図 6-15に示すFD                                                |
| Dt (FDの時間幅)           | ・3.0秒                                                       |
| 単位メッシュサイズ             | ・ $\Delta t \times \Delta l$ : 10秒×20m                      |
| $\Delta T$ (計算時間ステップ) | ・150秒：信号1のサイクル長と同じ                                          |
| 流入車両台数 $\rho$         | ・ポアソン分布( $\lambda=7$ )に従って発生<br>・ $\lambda$ の値は、シミュレーションと同値 |

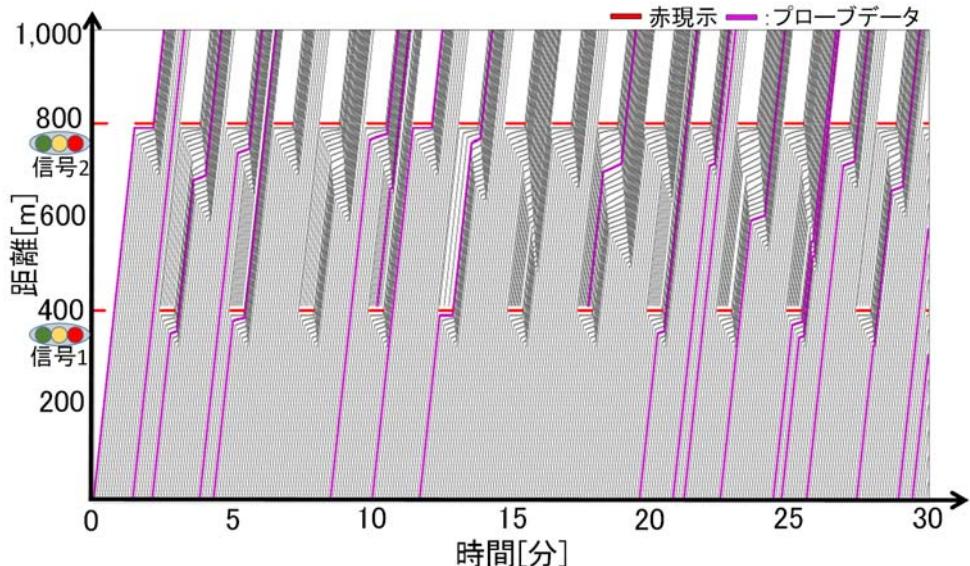


図 6-16 ベンチマークデータ(プローブ車両 20 台の例)

## (2) 本手法による流入台数検証結果

本節では、モデル性能の検証結果を述べる。提案した状態空間モデルでは、プローブデータの取得状況が精度に影響を与えると考えられる。そこで、本研究では、本線交通量と流入車両台数を固定した上で、プローブ取得状況のみを変化させてプローブ取得状況とモデルの推定精度関係の分析を試みた。次節より“プローブ台数別の精度検証”と“プローブ抽出パターンの違いによる精度検証”との2つの視点でモデル検証した結果を整理する。

### (3) プローブ台数別の流入台数の精度検証

ここでは、プローブ台数別の精度検証を行う。本線区間の交通量、流入台数を固定した上で、プローブ台数を、20~280台まで20台ピッチで変化させた計14ケースを設定した。そして、ケース別にプローブの抽出パターンをランダムに50パターン生成し、精度検証を行った。精度検証の評価指標として、各ケースのRMSEを

$$C_{RMSE} = \sqrt{\frac{1}{M} \sum_{m=1}^M (\rho_{all}^{true} - \rho_{m,all})^2}, \quad (6-7)$$

$$\rho_{m,all} = \sum_{i=1}^N \rho_{m,i}, \rho_{all}^{true} = \sum_{i=1}^N \rho_i^{true}. \quad (6-8)$$

と定義する。 $\rho_{all}^{true}$ は推定時間内の総流入台数の真値、 $\rho_{m,all}$ はプローブ抽出パターン $m$ における推定時間内の総流入台数の推定値である。図6-17にケース別の $C_{RMSE}$ を示す。同図を見ると、プローブ台数が100台を超えると、 $C_{RMSE}$ の低減が鈍化している。この鈍化が開始するプローブ台数100台の地点を変化点(以降、単に変化点と表記する)と呼ぶこととする。変化点が発生する理由について考察する。流入台数の発生状況によつては、本線区間の渋滞に影響を与えない場合がある。状態空間モデルでは、本線区間の渋滞状況を評価して、流入台数を推定しているため、流入車両が本線に影響を与えない場合には、うまく流入台数を推定できない。そのため、観測プローブ台数が増加しても流入台数の推定精度が上がらない変化点が発生すると推察される。この変化点は、プローブ車両の増加に伴い、効果的に本モデルの流入台数の推定精度向上が見込めるプローブ台数の目安であると解釈できる。

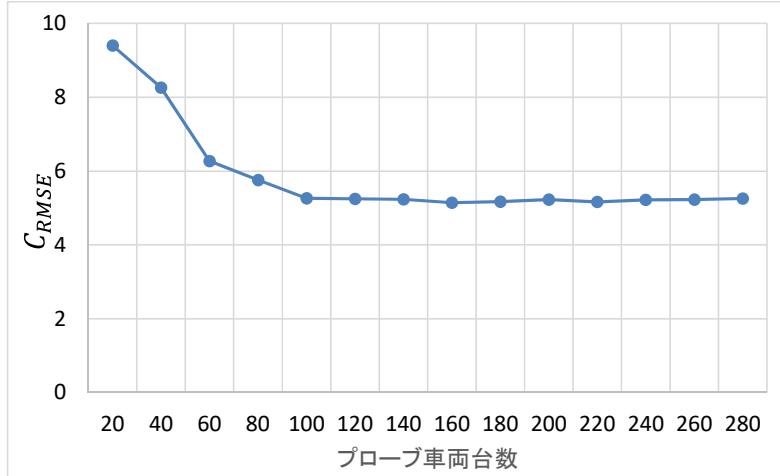


図 6-17 プローブ台数別の流入台数(推定値)の RMSE

#### (4) プローブ抽出パターンの違いによる流入台数の精度検証

ここでは、プローブの抽出パターンの違いによる精度検証を行う。本研究では、どの車両がプローブ車両として観測されるかというパターンを“プローブ抽出パターン”と定義する。例えば、区間途中で流入車両が発生し、その影響で後方に渋滞が発生した状況を考える。その時、プローブ車両として、流入車両の前方の車両が観測されるよりも、流入車両の後続の車両が観測される方が、流入車両による渋滞の発生状況を把握できると思われる。以下にプローブ抽出パターンの違いによるモデルの検証結果を整理する。本線区間の交通量、流入台数およびプローブ車両の抽出台数を20台(全車両の約5%)に固定し、ランダムに50パターン抽出したプローブデータセットを用いて精度検証を行った。精度評価の指標として、流入台数のRMSEを、

$$I_{RMSE} = \sqrt{\frac{1}{MN} \sum_{i=1}^N \sum_{m=1}^M (\rho_i^{true} - \rho_{m,i})^2}. \quad (6-9)$$

として定義する。ここで、 $i$ は流入箇所のインデックス、 $N$ は推定時間内の流入箇所の総数、 $m$ はプローブ抽出パターンのインデックス、 $M$ はプローブ抽出パターンの総数である。今回の検証では、 $N=11, M=50$  である。 $\rho_i^{true}$ は箇所*i*の流入台数の真値、 $\rho_{m,i}$

はプローブ抽出パターン $m$ における箇所 $i$ の流入台数の推定値である。

流入箇所別の流入台数の真値と推定値を図 6-18に示す。同図の平均値に着目すると精度よく流入台数を推定していることがわかる。 $I_{RMSE}$ は、3.1であり、±3台程度の精度で流入車両を推定していると解釈できる。

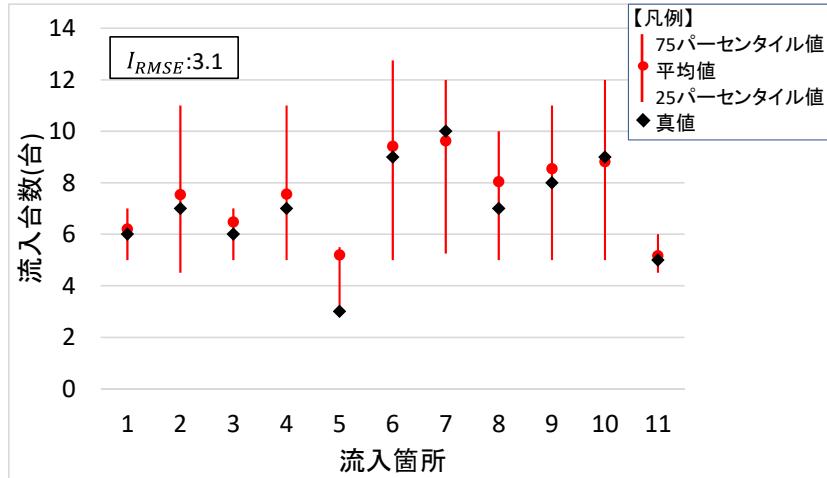


図 6-18 流入箇所別の流入台数の推定結果

### (5) 流入台数の推定値を用いた渋滞状況の推定精度検証

推定した流入台数を用いてMehran et al.の手法で推定した渋滞状況を分析した。流入台数の推定値は、前節で推定したプローブ抽出パターン別流入台数の推定値の期待値を用いた。渋滞状況の分析には、対象とする本線区間の渋滞状況(RYG)を用いる。推定した渋滞発生状況を図 6-19に示す。ベンチマークと状態空間モデルの渋滞状況を比較すると、プローブが全車両の約5% (20台) であっても状態空間モデルはベンチマークデータと渋滞状況(ボトルネック、渋滞長)が概ね整合していることがわかる。プローブデータのみで渋滞状況を可視化した結果を見ると、プローブデータ未観測箇所が時空間上に多数存在するため、渋滞の延伸状況が把握できない。以上のことから、状態空間モデルで推定した流入台数は、渋滞状況を推定するという視点において、良好な精度を得られていることがわかった。

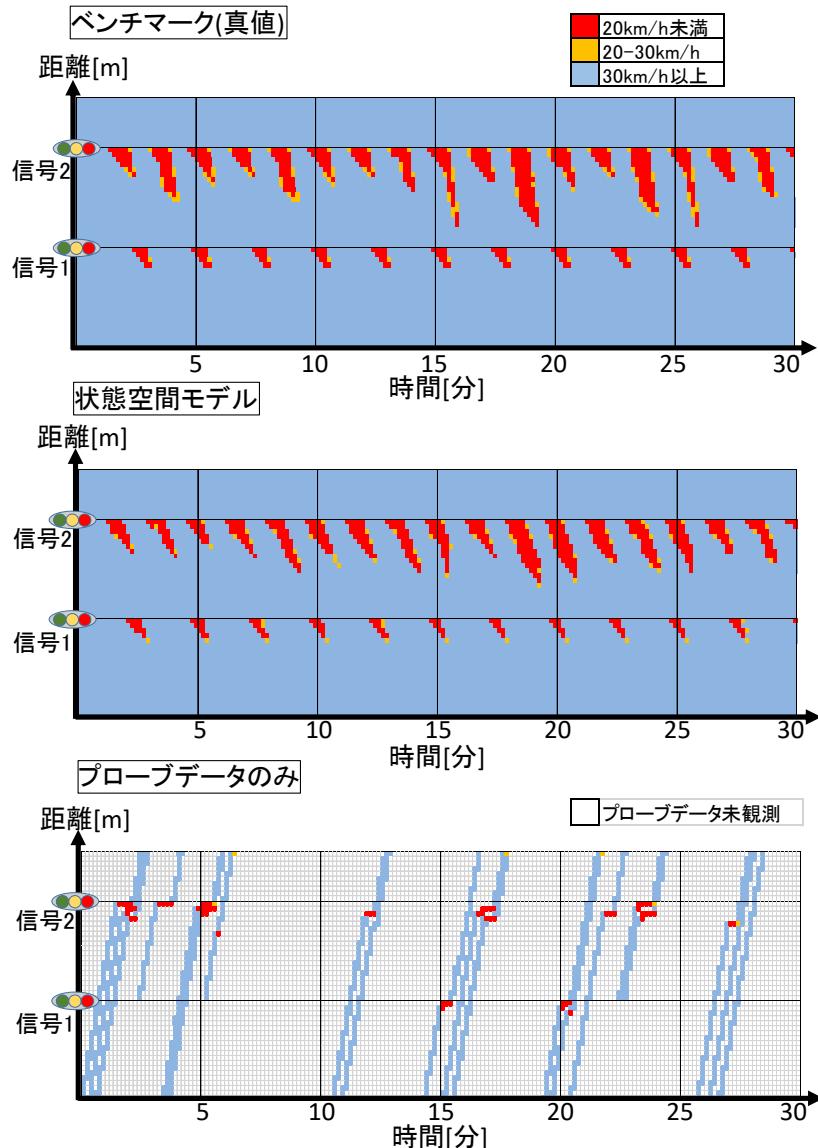


図 6-19 渋滞発生状況の比較(プローブ台数 20 台)

## (6) まとめと今後の課題

本節では、状態空間モデルとプローブデータを用いて区間途中の流入出台数を推定する手法を検証した。区間途中の流入により交通状況を再現したベンチマークデータを用いて本モデルの性能を検証した。プローブ台数別の推定流入台数のRMSEを分析した結果、一定のプローブ台数を超えると、RMSEの低減が鈍化する変化点が存在することがわかった。この変化点は、プローブ車両の増加に伴い、効果的に本モデルの流入台数の推定精度向上が見込めるプローブ台数の目安であると解釈できる。またプローブ抽出パターン別の流入台数の精度を検証した結果、状態空間モデルで推定した流入

台数は、良好な精度を得られているという結果を得た。最後に推定した流入台数を用いて本線区間の渋滞を推定した結果、プローブデータのみに比べてベンチマークデータに近い状態の渋滞状況が推定できた。本モデルの今後の課題は、以下の通りである。

### 1) 時空間メッシュのサイズの違いによるモデル検証

モデル検証では、時空間メッシュのサイズを固定し、分析を行った。しかしながら、時空間メッシュのサイズは、プローブ台数の量によって望ましいサイズがあると推察される。そのため、プローブ台数ごとに時空間メッシュサイズを変更し、時空間メッシュのサイズの違いによるモデル精度の検証が必要と考える。

### 2) 状態空間モデルの高度化

今回、流入出台数を確率的に発生させるポアソン分布パラメータ $\lambda$ は既知という仮定としたが、 $\lambda$ が未知な場合においても流入出台数を推定できるように拡張することが望ましい。その対応方針としては、パーティクルフィルタによってシステムモデルの予測分布をモンテカルロ近似し、 $\lambda$ の値を探索することが考えられる。

### 3) 二次元ネットワークへの拡張

本モデルでは、区間途中の流入出台数、すなわちリンク間の交通流の推定を行った。今後は、本モデルを拡張し、二次元ネットワーク（ネットワーク全体）の交通流の推定手法の構築が必要と考える。

## Appendixの参考文献

- 1) Daganzo, C. F., 2006. On the Variational Theory of Traffic Flow: Well-posedness, Duality and Applications, Networks and Heterogeneous Media 1(4), 601-619.
- 2) 樋口知之, 上野玄太, 中野慎也, 中村和幸, 吉田 亮:データ同化入門一次世代のシミュレーション技術一, 朝倉書店, 2011.
- 3) Mehran, B., Kuwahara, M. and Naznin, F.: Implementing Kinematic Wave Theory to Estimate Vehicle Trajectories from Fixed and Probe Sensor Data, Transportation Research Part C, Vol.20, pp144–163, 2012.
- 4) Mehran, B. and Kuwahara, M.: Fusion of probe and fixed sensor data for short-term traffic prediction in urban signalized arterials, Special Issue for the International Journal of Urban Sciences on Urban Transportation, Vol.17, pp. 163-183, 2013.
- 5) Kitagawa, G.: Monte Carlo Filter and Smoother for Non-Gaussian Nonlinear State Space Models,Journal of Computational and Graphical Statistics,Vol. 5, No. 1 , pp. 1-25, 1996.
- 6) 淡路敏之, 蒲地政文, 池田元美, 石川洋一 編著: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.
- 7) Han,J., Kamber,M. and Pei,J.:DATA MINING Concepts and Techniques Third Edition, Morgan Kaufmann, 2011.

◆ Appendixは、下記の論文を基に加筆・修正し、執筆したものである。

- (1) Kawasaki, Y., Hara, Y., Kuwahara, M. : Real-time Monitoring of Dynamic Traffic States by State-Space Model, *Transportation Research Procedia*, Vol.21, pp.42-51, 2017.
- (2) Kawasaki, Y., Hara, Y., Mitani, T., Kuwahara, M. : Real-time Simulation of Dynamic Traffic Flow with Traffic Data Assimilation Approach, *Journal of Disaster Research*, Vol.11, No.2, 2016.
- (3) Kawasaki, Y., Hara, Y. and Kuwahara, M. : Real-time Monitoring of Dynamic Traffic States by State-Space Model, *International Symposium of Transport Simulation International Workshop on Traffic Data Collection and its Standardisation (ISTS and IWTDCS'16)*, Jeju, Korea, July, 2016.
- (4) Kawasaki, Y., Hara, Y., Kuwahara, M. : Construction of traffic state estimation method based on data assimilation, *22nd ITS World Congress*, Bordeaux, France, October 2015.
- (5) 川崎洋輔, 原祐輔, 桑原雅夫: 交通流理論の状態空間モデルへの拡張, Vol.51, CD-ROM, 2015.
- (6) 川崎洋輔, 原祐輔, 桑原雅夫: 状態空間モデルとプローブ軌跡データを用いた区間途中の流入出台数の推定手法の構築, 土木学会論文集 D3, Vol.72, 2016.
- (7) 川崎洋輔, 原祐輔, 桑原雅夫: 状態空間モデルによる区間途中の流入出を考慮したリアルタイムな渋滞状況の推定手法の構築, 土木計画学研究・講演集, Vol.52, CD-ROM, 2015.