



車両走行軌跡データを用いた大規模ネットワークの 交通状態推定手法

安田, 昌平

(Degree)

博士 (工学)

(Date of Degree)

2020-09-25

(Date of Publication)

2021-09-01

(Resource Type)

doctoral thesis

(Report Number)

甲第7874号

(URL)

<https://hdl.handle.net/20.500.14094/D1007874>

※ 当コンテンツは神戸大学の学術成果です。無断複製・不正使用等を禁じます。著作権法で認められている範囲内で、適切にご利用ください。



博士論文
車両走行軌跡データを用いた
大規模ネットワークの交通状態推定手法

令和2年7月16日

神戸大学大学院工学研究科市民工学専攻

氏名：安田昌平

学籍番号：159T757T

Traffic state estimation method for large scale network using vehicle trajectory data

Shohei Yasuda

159T757T

Department of Civil Engineering
Graduate School of Engineering
Kobe University

July 16, 2020

ABSTRACT

Due to the rapid development of information and communication technology, it has become possible for various devices around us to collect and provide information to each other. The Internet of things (IoT) is a concept that utilizes information communication between devices to connect all the things used in our daily lives as sensors in an Internet-like manner. Further development of the IoT is expected in the future, such as the practical application of the 5th generation mobile communication system (5G), which can communicate large amounts of information to many terminals at high speed. Therefore, methodologies to analyze the huge amount of data collected from devices and to optimize human behavior and systems by controlling information and communication are actively studied.

Connected vehicle (CV) technology, in which a moving vehicle exchanges information with other vehicles or infrastructure, is attracting attention as an IoT-related technology in the field of road transport systems. For example, the Electronic Toll Collection System 2.0 (ETC2.0) is a CV technology that stores information on the trajectory of a vehicle in a toll collection device and collects and provides this information via antennas installed on the roadside units. Compared with conventional observations, the CV technology is promising as a next-

generation road traffic observation system because of its advantages such as the ability to observe a wide area of vehicles and the low cost of introduction and maintenance.

It is not possible to fully cover the traffic states of a large network by observed data since the number of vehicles that can acquire trajectory data is still limited. Therefore, traffic state estimation methods have been actively studied as a methodology to understand the traffic state in the network using limited observation information. However, existing studies are specialized in estimating local traffic states such as single-roads and signalized intersections, and there are few methodologies that provide comprehensive estimates of traffic states in large networks. One of the reasons for this is that traffic state estimation methods using trajectory data often use detailed network data that is excellent for drawing linear structures, and the computational load using the network represented by numerous nodes and links is very large.

The purpose of this research is to develop a comprehensive framework for estimating traffic states for large-scale networks by developing a network representation of spatial resolutions determined according to the acquisition status of vehicle trajectory data. The spatial resolution of the network is determined according to the spatial information of the actual trajectory, thus resolving the subjectivity of the conventional network representation. Since the network is constructed directly from the vehicle trajectory, the dependence on the given detailed network data can be relaxed and the network data with a high affinity to the observed data can be constructed efficiently. We develop a methodology to estimate various traffic states for links only from the corresponding trajectory data. By using a time-space diagram of traffic states generated from trajectory data and a methodology combining image recognition methods and macro-traffic flow theory, it is possible to estimate quantitative variables such as traffic volume and density, which have been difficult to estimate from trajectory data alone. We develop a methodology for estimating the traffic state of zones from the corresponding trajectory data. In order to improve the accuracy of the estimated values, we use a device that can observe the traffic volume in the zone as well as the trajectory data.

論文要旨

情報通信技術の急速な発展により、身の回りの様々なデバイスが相互に情報収集・提供を行うことが可能となった。デバイス間の情報通信を活用し、日常生活で用いられるあらゆるモノをセンサーとしてインターネットのように接続する概念は Internet of things (IoT) と呼ばれる。大容量の情報を多数端末に高速で通信可能な第 5 世代移動通信システム (5G) の実用化など、IoT には今後更なる発展が見込まれており、デバイスから収集された膨大なデータの解析や、情報通信を活用した制御により人々の行動やシステムを最適化する方法論が活発に研究されている。

道路交通システム分野の IoT 関連技術として、例えば走行する車両が他の車両やインフラと情報交換を行う Connected vehicle (CV) 技術が注目を浴びている。既に実用化されている CV 技術として、例えば国内では料金収受に関わる車両搭載機器に車両の走行軌跡情報を蓄積し、路側に設置されたアンテナを介して情報の収集・提供を行う Electronic Toll Collection System 2.0 (ETC2.0) がある。CV 技術は、従来のアンケート調査や定点観測と比較して広域な範囲の車両を追跡的に観測できること、車両搭載機器やドライバーのスマートフォン等を活用することで導入・メンテナンスが低コストで行えるなどの利点があり、次世代の道路交通観測システムとして有望視されている。

走行する全ての車両の走行軌跡を取得できない限りネットワークの交通状態をくまなく把握することはできないため、限られた観測情報から交通状態を推定する方法論が求められる。実際、混入率の低い走行軌跡データを用いた交通状態推定手法が近年活発に研究されている。しかしながら、既存の研究は単路や信号交差点付近などの局所的な区間を対象としたものが多く、大規模なネットワークの交通状態を包括的に推定するような方法論は未だ乏しい。その原因として、位置情報に基づく車両走行軌跡データは一般に線形構造が詳細に表現されたネットワークデータに紐付けて用いられることが多く、分析対象範囲を広げることにより計算や前処理のコストが膨大になることが挙げられる。また計算負荷削減のため、ネットワークデータおよび対応する観測情報を分析に適した空間分解能に変換することは膨大な労力を要する上、その変換には分析者の主観性が伴うという課題がある。

本研究の目的は、車両走行軌跡データの取得状況に応じて決定された空間分解能のネットワーク表現を行い、その空間分解能に応じて交通状態を推定する包括的なフ

レームワークを構築することである。これにより、大規模ネットワークを対象とした交通状態推定の効率化および精度向上を目指す。ネットワークの空間分解能は実走行軌跡の空間情報に応じて決定されるため、従来のネットワーク表現の主観性の問題を解決する。車両走行軌跡から直接ネットワークを構築するため、所与の詳細なネットワークデータへの依存を緩和し、観測データと親和性の高いネットワークデータを効率的に構築できる。また、観測データをネットワークデータに紐付ける膨大な処理を必要としない。

構築されたネットワークのうちリンクで表現された部分について、対応する走行軌跡データのみから各種交通状態量を推定する方法論を開発した。走行軌跡データから生成した交通状態の時空間図と、画像認識手法およびマクロ交通流理論を組み合わせた方法論により、走行軌跡データのみから推定することが困難であった交通量や密度などの量的変数についてその信頼区間を含めて推定することを可能とした。構築されたネットワークのうち、ゾーンで表現された部分について、対応する走行軌跡データから交通状態を推定する方法論を開発した。マクロな交通状態変数の推定に用いる既存の方法論について、観測データの統計誤差を考慮した新たな指標を開発し、その実用性を評価した。

目次

1	序論	1
1.1	背景	1
1.2	研究の目的	3
1.3	本論文の構成	6
2	既存研究の整理	7
2.1	ネットワーク表現	7
2.2	ネットワークフリーデータの活用	12
2.3	走行軌跡データを用いた交通状態推定・予測手法	13
2.4	本研究の位置付け	14
3	走行軌跡データ指向なネットワーク表現	16
3.1	はじめに	16
3.2	マップマッチング処理が施された走行軌跡情報を用いた方法論	20
3.3	ネットワークフリーな走行軌跡情報を用いた方法論	33
3.4	各点列の走行方向情報を用いた主要ノード領域の特定	48
3.5	本章のまとめ	52
4	リンク部に対応する交通状態の推定	53
4.1	はじめに	53
4.2	走行軌跡データを用いた量的変数の推定	54
4.3	時空間状態の将来予測	74
4.4	本章のまとめ	86
5	ゾーン部に対応する交通状態の推定	87
5.1	はじめに	87
5.2	実観測データを用いた MFD の推定と well-definedness の評価	89
5.3	本章のまとめ	104
6	結論	105
6.1	本研究の成果と貢献	105

6.2	今後の展望	106
	参考文献	108
	謝辞	115

1 序論

1.1 背景

情報通信技術の急速な発展により、身の回りの様々なデバイスが相互に情報收拾・提供を行うことが可能となった。デバイス間の情報通信を活用し、日常生活で用いられるあらゆるモノをセンサーとしてインターネットのように接続する概念は Internet of things (IoT) と呼ばれる。大容量の情報を多数端末に高速で通信可能な第 5 世代移動通信システム (5G) の実用化など、IoT には今後更なる発展が見込まれており、デバイスから収集された膨大なデータの解析や、情報通信を活用した制御により人々の行動やシステムを最適化する方法論が活発に研究されている。

道路交通システム分野の IoT 関連技術として、例えば走行する車両が他の車両やインフラと情報交換を行う Connected vehicle (CV) 技術が注目を浴びている。CV 技術のうち、車両間の情報交換を行うシステムは vehicle-to-vehicle (V2V)、車両とインフラ間で情報交換を行うシステムは vehicle-to-infrastructure (V2I) と呼ばれ、将来的には自動運転技術等と組み合わせた統合的な道路交通システムの開発が期待されている。既に実用化されている CV (V2I) 技術として、例えば国内では料金収受に関わる車両搭載機器に車両の走行軌跡情報を蓄積し、路側に設置されたアンテナを介して情報の收拾・提供を行う Electronic Toll Collection System 2.0 (ETC2.0) がある。このようにして收拾された一般車両の走行軌跡情報は CV データと呼ばれる。CV 技術は、従来のアンケート調査や定点観測と比較して広域な範囲の車両を追跡的に観測できること、車両搭載機器やドライバーのスマートフォン等を活用することで導入・メンテナンスが低コストで行えるなどの利点があり、次世代の道路交通観測システムとして有望視されている。

道路交通に関わる観測データを収集する目的の一つとして、現状の交通状態を把握することが挙げられる。交通状態を適切に把握することは、交通マネジメントや道路計画の策定にとって不可欠である。交通量や密度、速度などの交通状態変数の値を把握することで、道路ネットワーク上の渋滞や事故などのインシデントの発見や、その原因の分析が行えるようになる。また各種交通状態変数の定量的な値が得られなければ、料金施策や新設道路の計画は非効率的なものとなろう。観測範囲が限定的で誤差を含む観測データを用いて交通状態を把握することは非常に困難なタスクであるた

め、現実の観測データから交通状態を適切に推定する方法論の開発が必要となる。近年、走行軌跡データなどの新たな観測データが普及してきていることから、その特性を活かした効率的かつ合理的な交通状態推定手法の開発が求められている。

走行軌跡データを用いた交通状態推定手法として、交通工学に基づく数理モデルや機械学習などのデータ駆動型モデルを活用した多様な方法論が日々提案されているが、それらは主に単路や狭域な道路群を対象としたものである。走行軌跡データにより広範囲の観測情報が得られるようになった現在においても大規模なネットワークを対象とした方法論が未だ少ない。この原因として、走行軌跡データと大規模ネットワークデータを用いた計算負荷および前処理の負荷の高さが挙げられる。

走行軌跡データを分析に用いる場合、その特性から様々な前処理が必要である。一般に走行軌跡データは位置座標と時刻の情報が一定間隔で収拾された点列データであるため、設置箇所が事前に特定されている車両検知器データ等とは異なり、収拾された時点でネットワークの情報を持たないネットワークフリーデータとして知られる。そのため走行軌跡データを分析に用いるためには、観測された点列をネットワークデータに紐づけるマップマッチング処理や、一連の走行軌跡を分析目的に応じた移動単位に分解する移動滞在判別処理、未観測区間の補完処理などの前処理が必要である。中でもマップマッチング処理は、並走路や立体交差を多く含む複雑なネットワークを対象とした場合、その処理負荷が膨大になる上、様々な誤差の原因となることが指摘されている。

膨大な工程を経て複雑な道路ネットワークに走行軌跡情報を正確に付与できたとしても、大量のリンクとノードによって構成される大規模ネットワークを対象とした計算は実現不可能なほど大きくなる。このような問題を解決するため、ネットワークの簡略化手法が提案されているが、既存の方法論は、所与の詳細なネットワークデータに対して CV データのようなネットワークフリーデータを紐付け、リンク特性を考慮した集約により簡略化するという流れが一般的である。このような手順で生成されたネットワークの空間分解能は、インプットとなるネットワークデータの空間分解能に強く依存する。また、詳細なネットワークデータの各リンクに紐付けた高次元の観測情報を用いてクラスタリング等を行う必要があるため、その処理自体が高負荷なものとなる。このように、大規模ネットワークを対象とした包括的な交通状態推定が活発に研究されていない原因は、所与の詳細なネットワークデータの利用にある可能性がある。

ネットワークの交通状態をどのような空間分解能で表現するかは、その目的や制約（使用できるデータや計算コストなど）によって様々であり、一意に定まっているものではない。ネットワークをどのように表現するかという問題は、推定結果の活用やデータとの親和性にとって核となる重要な要件であるが、現代においても詳細に議論

されることは少ないテーマである．大規模ネットワークの交通状態推定を効率的に行うためには，所与のネットワークデータに依存したネットワーク表現を再構築することが必要だが，新たに構築するネットワークデータの空間分解能を客観的かつ合理的に決定する方法論は今のところ存在しない．

近年，豊富に取得されるようになった走行軌跡データを空間上にプロットした図は，まるで道路ネットワークの形状を描画しているようにその空間情報を特定できている．このような走行軌跡データを所与のネットワークデータに紐付けるのではなく，新たなネットワークデータを直接生成することができれば，マップマッチングなどの高負荷な処理を行わず観測情報の対応が取れる上，分析の目的やデータの取得状況に応じた空間分解能の設定が行える可能性がある．実際，測量学の分野では車両の位置座標から道路の構造を推定する方法論が提案されている．一方，既存の方法論は道路の線形構造を推定することが主な目的であり，各リンクの平均速度等の走行情報の取得や，交通工学的なモデルを実装するための計算負荷削減を考慮した空間分解能の設定等は行われていない．

1.2 研究の目的

本研究では，車両走行軌跡データの取得状況に応じて決定された空間分解能のネットワーク表現およびネットワークの空間分解能に応じた交通状態推定を行う包括的なフレームワークを提案する．ネットワークの空間分解能は実走行軌跡の疎密に応じて決定されるため，従来のネットワーク表現の主観性を解決する．また車両走行軌跡からネットワークを直接構築するため，観測情報との対応が取れた状態でネットワークデータを生成することが可能となる．

このような観測データ指向なネットワーク表現を活用して，大規模ネットワークの交通状態を効率的に推定するフレームワークを構築する．はじめに，走行軌跡データの空間情報に応じた空間分解能の設定，およびリンクとゾーンで構成されるネットワークデータの生成手法を開発する．これにより，所与の詳細なネットワークデータへの依存を緩和し，観測データと親和性の高いネットワークデータを効率的に構築する．構築されたネットワークのうち，リンクで表現された部分について，対応する走行軌跡データのみから各種交通状態量を推定する方法論を開発する．走行軌跡データから生成した交通状態の時空間図と，画像認識手法およびマクロ交通流理論を組み合わせた方法論を用いて，走行軌跡データのみから推定することが困難であった交通量や密度などの量的変数について推定することを可能とする．構築されたネットワークのうち，ゾーンで表現された部分について，対応する走行軌跡データから交通状態を推定する方法論を開発する．精度向上のため，本研究では走行軌跡データだけでなく

ゾーン内の交通量を観測できるデバイスを用いた補正を行う。ただし、交通量観測デバイスはゾーン内の交通量レベルを補正するために用いられるため、設置されている道路を特定する必要はなく、ネットワークフリーな情報として扱われる。従来の研究で用いられている様に、所与のネットワークデータへ走行軌跡データを紐付け、交通状態を管理するイメージを図 1.1 に、本研究で提案する方法論のイメージを図 1.2 に示す。




図 1.1 従来のネットワークへの観測データの紐付け




図 1.2 本研究のフレームワーク

1.3 本論文の構成

本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について述べた．第 2 章では，本研究と関連する既存研究を整理し，本研究の位置付けを示す．第 3 章では，利用目的やデータ取得状況に応じた空間分解能のネットワークデータ生成手法について述べる．第 4 章では，第 3 章で生成したネットワークのリンク部に対応する交通状態の推定手法について，第 5 章では，ゾーン部に対応する交通状態の推定手法について述べる．第 6 章では，本論文の結論をとりまとめ，今後の展望を示す．

2 既存研究の整理

本章では、関連する既存研究を整理し、本研究の位置付けを明らかにする。2.1 節では、様々な目的に応じたネットワーク表現について、2.2 節では、走行軌跡データの扱いについて、2.3 節では、交通状態推定・予測手法についてそれぞれ整理する。

2.1 ネットワーク表現

本節では、ネットワーク表現に関する研究について整理する。具体的には、大規模ネットワークを対象とした交通量配分や脆弱性評価等の分析において用いられるネットワーク表現や、観測データ指向なネットワークの簡略化手法について、またネットワークの構造を完全に捨象する巨視的な交通状態の表現について説明する。

2.1.1 ネットワークの簡略化表現

道路ネットワークの性能評価や規範的な交通状態を示すための代表的な方法論として交通量配分が挙げられる。交通量配分とは、ネットワークに流入する交通需要に対して実現されるリンクフローパターンを計算するものであり、例えば Wardrop が提示した確定的な利用者均衡配分モデル¹⁾は直感的に理解しやすく Beckmann により凸計画問題に置き換えられた²⁾ことで解析的に扱いやすいものとなったため瞬く間に普及し、現在も政策評価等に用いられている。更に、全ての利用者が最小コストの経路を選択しようとする確定的なモデルに対して確率的な配分モデル³⁾や、交通流が定常的であることを仮定したこれらのモデル（静的均衡配分）に対して交通流の時間軸方向の変動を考慮した動的均衡配分モデルに拡張されるなど、交通工学分野において活発に研究されている最も重要なテーマの一つである。

2.1.1.1 セントロイドによる細街路の表現

現実の道路ネットワークを対象とした交通量配分において用いられるネットワークデータは、一般にノードとリンクで構成されたグラフ構造と、交通量の発生集中を表現する複数の点（セントロイド）、およびそれらを結ぶダミーリンクによって表現される。計算負荷削減のため、ネットワークは主要な道路のみで構成され、それ以外の道路（細街路など）はいずれかのセントロイドに集約されることになる（図 2.1）。し




図 2.1 細街路のセントロイド表現

かしながら，この表現は集約された細街路内の交通流を完全に捨象するため，様々な誤差の要因となる．この問題の解決策として，例えばセントロイドの数を増やすことで，集約されるそれぞれの細街路の領域を小さくする方法が考えられる．しかし，多数のセントロイドを扱うことによる交通量の発生・集中パターン数の急激な増加や，各セントロイドに対応する細街路の設定コストの増加を考慮すると，効果的な解決策とは言えない．

このように，交通量配分問題においてネットワーク表現は結果の信頼性や計算コストに大きく関わる重要な要素である．Daganzo⁴⁾ は，交通量配分を行うにあたって，研究者は現実の交通行動を考慮したネットワークへのセントロイドの紐付けからはじめなければならないこと，またネットワークを表現する上で下記の 4 項目に対する明確なルール設定がないため，それが適切に行われていないことを問題視している．

- 対象地域をどのようにしてゾーンに分けるか
- ゾーン内のセントロイドをどこに配置するか
- どのようにしてセントロイドをネットワークに接続するか
- 道路ネットワークの各要素をどのように表現するか

Daganzo は，事前に設定されたセントロイドの内部に多数のセントロイド（サブセントロイド）を定義し，それにより増大するであろう Frank-wolfe 法⁵⁾ の計算負荷を軽減するアルゴリズムを開発した⁴⁾．また，セントロイドによる細街路の代替表現に関する Newell⁶⁾ の提言に基づいて，細街路を連続空間で近似することによりセントロ

イドの集約表現を緩和した方法論⁷⁾を開発した。この研究では、連続空間として近似された細街路上を各車両が等速度で移動できるという仮定を用いて、ゾーンおよびセントロイドの設定を完全に排除している。ただし、これらの研究はセントロイドの設定に関する課題の解決策のみを提示しており、ネットワークを表現する上で考慮すべき項目の最後に示された「道路ネットワークの各要素をどのように表現するか」という問題については触れられていない。これは、道路ネットワークのうち細街路としてセントロイドにより表現される部分だけでなく、ノードとリンクで表現されるネットワークについても考慮すべき項目である。

2.1.1.2 ノードとリンクによるネットワークの表現

交通量配分や交通シミュレーションなどのアプリケーションの実装において、主要な対象となる道路ネットワークはノードと有向リンクで表現される。しかしながら、単純な4差路の交差点を例に取ってもその表現方法は一意に決まらない（例えば図2.2）。そのため、主な分析対象であるネットワークについても目的等に応じて表現方法を設定する必要がある。しかしながら、ネットワーク表現の違いが交通量配分等の結果に対してどのような影響を及ぼすか過去にはほとんど議論されていなかった⁴⁾。

前項で示した研究が行われていた時代には、計算能力の限界からノードとリンク




図 2.2 ノードと有向リンクを用いた交差点の表現

による表現は最小限に留められたため、細街路の集約・近似表現が注目を浴びていたが、細街路の交通状態が経路選択に与える影響を考慮するため、可能な限りその形状をリンクによって表現する必要性が認知された。しかしながら、細街路を多数のリンクで表現することは計算負荷の観点から有用ではないため、細街路に対応する一部の道路網（サブネットワーク）を少数のリンクとして扱う表現が開発された。例えば Boyles⁸⁾ は、細街路の走行コストを経路選択に反映させるため、電気回路の解析に用いられる方法論のアナロジーを用いて集約前のサブネットワークのコスト関数から集約後のリンクのコスト関数を定義する方法論を提案した。

細街路に対応するサブネットワークの分析は、主要ネットワークが適切に表現されていることを前提としているが、先述の通りその表現は一意的なものではない。そのため、交通量配分などの分析を繰り返し実行する必要がある場合、主要ネットワークを含めた道路網全体の簡略化表現が必要となる。例えば、交通量配分を用いてネットワークの脆弱性評価を行う場合、需要の変動が及ぼすネットワークの影響を分析するため、様々な需要設定に対する配分結果を繰り返し計算しなければならない。ネットワークが複雑な場合、配分の繰り返し計算は非常に負荷の大きいものとなる。

ネットワーク全体の簡略化を行う方法論として、例えばネットワーク内の重要でないリンクやノードを抽出し削除する方法⁹⁾¹⁰⁾が挙げられる。また、ネットワークのリンク/ノード集合を抽象化されたリンク/ノード集合で置き換える方法論として連続リンクや並列リンクを一つのリンクで置き換える方法¹¹⁾が開発されている。また Wada et al.¹²⁾ は、非渋滞リンクをノードとして集約した reduced network を用いてネットワークの特性を効率的に解析した。Connors¹³⁾ は、簡略化後のネットワークの各リンクの走行コストを設定する方法について、いくつかの研究では簡略化前のネットワークを対象とした分析（配分やシミュレーション）結果が用いられていることに着目し、その分析に用いた仮定やシナリオに依存することを課題としている。

2.1.2 観測データ指向なネットワークの簡略化表現

ここまでで整理してきたネットワーク表現手法に共通する課題として、入力データである簡略化前のネットワーク構造自体が事前に構築された主観的なネットワークであること、また観測データとの対応を考慮していないことが挙げられる。近年、CV技術により普及した走行軌跡データを活用するため、ナビゲーションシステムなどに用いられる詳細なネットワークデータに観測情報を紐付けて分析に用いるようになった。しかしながら、このような詳細なネットワークデータを入力として、これまで開発されてきたネットワークの集約手法を適用することはそれ自体が非常に高負荷であ

り、大規模ネットワークを対象とした場合計算が不可能となる。また、集約されるリンク群の観測情報をどのように効率的に集約するかという方法論もこれまでの研究では提案されていないため、観測データを適切に活用することができない。Casadei et al.¹⁴⁾ は、詳細なネットワークデータとマップマッチング処理により紐付けられた走行軌跡情報を用いて、速度値の類似性に基づいたクラスタリングにより、ネットワークを集約する方法論を開発した。観測データ指向にネットワークを集約・表現する方法論は、今後のビッグデータ時代に適合したものとして期待されるが、マップマッチング処理を施した詳細なネットワークデータを用いたクラスタリング自体が高負荷であること、ネットワークの接続構造が捨象されることなどが課題として挙げられる。

2.1.3 エリアワイドなネットワークの集約表現

Daganzo¹⁵⁾ は、複雑な道路ネットワークの交通状態はインプットのわずかな変化に敏感であり、そのミクロな予測は不可能に近いと指摘し、リンク単位ではなく集計的な記述・制御をすべきであると示唆した。近年、このような観点からネットワークの構造を完全に捨象し、その内部の集計的な変数間の関係を記述する Macroscopic fundamental diagram (MFD) を用いて交通状態の推定・制御を行う方法論が研究されている。このようなエリアワイドな集約表現もネットワーク表現の一つであると捉えられる。

MFD の存在が実観測データを用いて確認されたことにより¹⁶⁾、その研究が活発に行われるようになった。近年、対象ネットワークの MFD を推定するためのデータソースとして、従来から用いられている検知器データだけでなく、走行軌跡データを用いた方法論が開発されている。走行軌跡データを用いた MFD の推定方法は以下の2つに大別される。

- 混入率を用いた方法¹⁷⁾¹⁸⁾
- 検知器データと組み合わせた方法¹⁹⁾²⁰⁾

混入率を用いた方法は、ネットワークを走行する CV 車両の台数を混入率で割り戻すことでエリア内の交通量を計算するものである。一方で、検知器データと走行軌跡データを組み合わせた方法は、交通量を検知器データから、速度を走行軌跡データから取得し、これらの情報からネットワーク内の交通密度を算出し、変数間の関係（例えば交通量と密度の関係）を記述するものである。

2.2 ネットワークフリーデータの活用

本節では、ネットワークフリーな走行軌跡データを活用するための方法論について整理する。

2.2.1 マップマッチング技術

ネットワークフリーデータを活用するための方法として、マップマッチング処理があげられる。マップマッチング技術はオンラインマップマッチングとオフライン(batch)マップマッチングに大別される。オンラインマップマッチングは主にナビゲーションシステム等に用いられるもので、位置情報の取得後、即座に走行中のネットワークリンクを特定することを目的としている。一方で、オフラインマップマッチングは、過去の位置情報シーケンスを処理し、単一の車両や人の移動軌跡を連続するネットワークリンクの軌跡として抽出することを目的としている。

Quddus ら²¹⁾は、既存のマップマッチング技術を

1. Geometric analysis
2. Topological analysis
3. Probabilistic map-matching algorithms
4. Advanced map-matching algorithms

に分類し、それぞれの特徴を取りまとめている。1) Geometric analysis を用いた方法は、ネットワークの形状のみを考慮したもので、例えば各測位点を最も近いノードに紐付ける point to point 法や、最も近いリンクに紐付ける point to curve 法などが含まれる。容易に実装でき、高速で処理が可能だが、誤ったリンクへの紐付けや経路の連続性を担保できない可能性があるなど様々な課題がある。2) Topological analysis を用いた方法は、ネットワークの幾何的な情報に加え、リンクと軌跡データの交差角度や相対角度距離などを用いて、リンクの接続性や連続性を考慮したマッチングを行うものである。3) Probabilistic map-matching algorithms は、ナビゲーションシステムから取得した位置情報の周囲に、取得精度の誤差分散等を考慮した楕円または長方形の信頼領域を定義し、リンクとの位相幾何情報を元にマップマッチングを行うものである。4) Advanced map-matching algorithms は、カルマンフィルターやパーティクルフィルターなどの状態空間モデルを組み合わせた方法論や、ファジー理論を組み合わせた方法論などが提案されている。

地図データや測定機器の精度の限界から、マップマッチング処理はしばしば誤った

経路を推定することがある。このような誤差を軽減するため、これまでの研究ではドライバーが制限速度を遵守し、最短経路を走行するなどの仮定を置く方法論が開発されてきた。Knapen ら²²⁾は、これらの仮定が分析内容に制約されることを課題とし、時空間情報のみを用いてマップマッチング処理を行う方法論を開発した。

2.2.2 ネットワークフリーデータとネットワークベースドモデルの調和

Bierlaire et al.²³⁾は、ネットワークフリーデータを所与のネットワークに紐付ける確定的なマップマッチング処理が様々な誤差やバイアスの原因となっていることに着目し、ネットワークフリーデータとネットワークベースドモデル（e.g. 経路選択モデル）を調和させる Domain of Data Relevance (DDR) という概念を開発した。DDR とは、観測された軌跡の各点列に一定の幅を持った領域を定義したものであり、その領域とネットワークデータの位置関係を元にモデルを構築することで、従来のネットワークフリーデータを扱うことによる誤差を緩和させたものである。例えば複数の経路に対して同一の観測を対応させることを許容することで、曖昧な観測データを1つの経路に対応付けなければならない状況を緩和した。

Bierlaire et al.²⁴⁾は、この DDR の概念を用いて、スパースなスマートフォンの GPS データを対象に確率的なマップマッチング処理を施す方法論を提案している。スパースな位置情報データから潜在的な経路集合を生成し、軌跡の空間的な情報および速度などの情報を用いて各経路に尤度を関連づける手法を開発した。

これらの研究は走行軌跡データのようなネットワークフリーデータの活用法として画期的かつ有用なものであるが、所与の適切なネットワークデータの存在を前提としており、分析結果がその構造や空間分解能に依存することが課題である。

2.3 走行軌跡データを用いた交通状態推定・予測手法

ネットワークに紐付けられた走行軌跡情報を用いて現在の交通状態を把握するため、または将来の交通状態を予測するための方法論として、マクロ交通流理論を用いた交通状態変数の推定、および蓄積された過去の観測データに基づく統計学的・機械学習的な手法が数多く提案されている。本節では、走行軌跡データを用いた既存の交通状態推定・予測手法について、交通流理論に基づく方法論と、観測データ駆動な方法論に分けて整理する。

2.3.1 交通流理論を用いた方法論

交通状態を表す代表的な変数である交通量，密度，および速度の正確な推定において，交通流理論を活用することが望ましい．交通状態推定に用いられる代表的な交通流理論として，車両の流体近似により渋滞の延伸や解消などの交通状態のダイナミクスをマクロに記述した Kinematic Wave (KW) 理論²⁵⁾²⁶⁾が挙げられる．KW 理論は，Newell²⁷⁾による最小化原理や Daganzo²⁸⁾²⁹⁾による変分理論などの理論解析法，Cell Transmission Model (CTM)³⁰⁾などの数値解法が新たに開発されたことにより，その実用性が大幅に向上し，広く用いられるようになった．

対象を広域なネットワークとした場合，単路を対象とした交通流理論を単に組み合わせて用いることは計算資源の問題から困難である．エリアの交通状態を交通流理論に基づいて推定する方法論として，MFD を用いた方法論が提案されている．例えば推定された MFD と少数の走行速度情報を用いて，エリア内の密度を推定する方法論が提案されている³¹⁾．現実の限られた走行軌跡データを用いたケーススタディでは，自由流領域の推定は困難であったが，渋滞流領域の推定は精度よく行えたと主張されている．

2.3.2 観測データ駆動な方法論

近年の観測データの充実により，交通流理論に基づく方法論に対して，過去の観測情報に基づいて交通状態の推定・予測を行う観測データ駆動な方法論が注目されている³²⁾．一般に，観測データ駆動な方法論は繰り返し実現される交通状態のパターンや変数間の関係を学習することにより現在の状態を推定，または将来の状態を予測する．

走行軌跡データを用いた交通状態推定において，混入率の低いスパースな観測データを用いた場合にも精度よく推定できることが望ましい．実際，スパースな走行軌跡データを用いたデータ駆動な方法論が開発されているが³³⁾³⁴⁾，その推定対象である指標は主に速度またはその逆数である旅行時間である．特に走行軌跡データのみを用いた推定手法の場合，交通量や密度などの量的な変数を推定することは非常に困難であり，今後の課題とされている．

2.4 本研究の位置付け

以上の既存研究のレビューを踏まえ，本研究の位置付けについてまとめる．ネットワーク表現は計算負荷や結果の信頼性にも関わる重要なテーマであるが，未だその研究は少ない．これまで提案されている研究は，主な興味の対象であるネットワークに

対して、重要性が低く構造が複雑になりやすい細街路 (Local street network) に注目し、その構造を簡略化したネットワーク表現を適用する研究がほとんどである。しかしながら、近年用いられる詳細な道路地図データの特性から、主要なリンクも詳細な構造表現や細街路との接続構造の表現のため複雑な構造をしている場合が多く、細街路のみを簡略化する方法論では簡略化が不十分である可能性がある。近年、観測データが紐付けられたネットワークデータに対して、主要道路を含めたネットワークを対象に簡略化を行う方法論が提案されているが、接続パターンの増加に伴い簡略化処理の定義が困難となること、マップマッチング処理により割り当てられた指標を用いて所与のネットワークの全リンクをインプットとして用いるため計算負荷が膨大となることが問題である。また、これらの研究では道路の接続構造が捨象されているものもあり、その場合その用途は可視化や MFD を用いた分析へ活用に限られ、その他のネットワーク解析に用いられる代表的なアプリケーションがほとんど実装できない。交通量配分や交通シミュレーションを行う上で、重要な道路はグラフ構造で表現されていることが望ましく、またその接続構造は現実の主要道路網の構造を客観的に担保していることが重要である。これらの課題を踏まえ、本研究では主要道路網をグラフ構造で、細街路をゾーンで表現したネットワークの生成手法を提案する。

ネットワークフリーな走行軌跡データを活用する上で、主に用いられているマップマッチング処理は、高負荷かつ様々な誤差を含む。軌跡の各点列に領域を定義して所与のネットワークデータに明示的な紐付けを行わず、ネットワークフリーな状態のまま軌跡情報を用いるアイデアが提案されているが、この概念は所与のネットワークデータとの位置関係を元に定義されるため、ネットワークデータの構造に強く依存する。本研究では、走行軌跡の空間情報からリンクおよびゾーンを生成することで、所与のネットワークデータの構造への依存を緩和する方法論を提案する。

交通流理論に基づく既存の交通状態推定手法として、単路を対象とした交通状態の時間進展を記述する方法論や、エリアの交通状態を推定するための方法論が豊富に蓄積されている。これらはそれぞれ非常に合理的かつ有用なものであるが、大規模ネットワークを対象とした交通状態推定には未だ十分には活かされていない。本研究は、主に KW 理論および MFD に基づく交通状態推定手法を活用し、本研究で開発するネットワーク表現と組み合わせることにより大規模ネットワークの交通状態推定フレームワークとして提案するものである。

3 走行軌跡データ指向なネットワーク表現

3.1 はじめに

本章では、車両の走行軌跡情報を用いて、利用目的や観測データの特性に応じた空間分解能のネットワークデータを生成する方法論を説明する。本方法論の基本的なアイデアは、「車両が通過した空間には道路が存在し、より多くの走行軌跡が得られる空間ほど主要な道路であるはずだ」という仮定に基づいている。図 3.1 は、首都圏における日本デジタル道路地図（DRM）と ETC2.0 によって取得されたある 1 日の 8 時台の車両走行軌跡を比較したものである。ETC2.0 搭載車両が走行した空間は、1 時間という短時間でも首都圏の道路網の概形を一定の精度で捉えられていることが確認できる。高速道路や主要国道に対応する空間とその他の街路に対応する空間を比較すると、取得されている走行軌跡の疎密や速度情報に明らかな差異がある。所与のネットワークデータを分析に用いる場合、その空間分解能や道路種別等の属性は予め定義されているが、車両の走行軌跡データからネットワークを構築する場合、走行軌跡の疎密や速度情報等を活用することで、現実の道路ネットワークの利用特性に応じたネットワークデータを生成できる可能性がある。ネットワークをノードとリンクのみで表現する場合、その空間分解能はノードの設定に強く依存する。具体的には、交差点の表現や単路の分割箇所によってネットワークの表現に必要となるリンク数が増減する。例えば DRM を交通シミュレーションなどの分析に用いる際、主な研究対象となる道路のみ抽出したものがネットワークデータとして用いられる。図 3.2 は DRM から高速道路と主要国道のみを抽出したネットワークの一部を示したものであり、実践は抽出されたリンク（main link）、点線は抽出されなかったリンク（sub link）、赤い円は main link に対応するノードである。DRM はナビゲーションシステムにも用いられることから、道路の線型構造を詳細に描画するために設定されたノードが多く存在し、それに応じてリンク数が非常に多くなっていることがわかる。また単純な抽出処理では main link と sub link の接続箇所がノードとして残るため、細街路付近を通過する主要道路では、図 3.2 のようにノード間の距離が数十メートルと比較的短くなる傾向にある。分析対象のスケールや利用する観測データによるが、単純に抽出されたネットワークデータの空間分解能が分析に適している可能性は低いであろう。




図 3.1 日本デジタル道路地図と ETC2.0 データのプロット

2 章で述べたように，抽出されたネットワークをベースに簡略化処理を行うことで空間分解能を調整する方法論が提案されているが，簡略化を行う前にマップマッチング処理による観測情報の紐付けが必要となることや，リンクの接続パターンが増えるほど必要な処理の種類が増えて複雑になることを考えると，効率的な方法論とは言えない．これらの問題点を解決するため，車両走行軌跡の空間情報を活用して新たにネットワークデータを構築する効率的な方法論の開発が求められる．




図 3.2 抽出した主要リンク（実線）とノード

新たなネットワークデータを構築する方法論を開発する上で、ネットワークデータが担保しなければならない条件や機能について整理する。交通分析で用いられるネットワークデータは、一般にノードと有向リンクによって構成されるグラフ構造、または一部の道路網をゾーンにより表現した構造で構成される。現実の道路網の分析に用いる場合、主な対象となる道路の主要な交差点（高速道路のランプを含む）をノードで表現し、それらがどのように接続されるか方向別の到達可能性を加味した有向リンクにより表現されることが望ましい。交通状態の可視化や動学化のため、ネットワークの要素は観測データから取得した情報を保持する。本章では、これらの条件を満たすネットワークデータの生成手法を提案する。

本研究で提案するネットワークの構築手順は

1. ノードの設定
2. 有向リンクおよびゾーンの設定

に整理される。構築するネットワークのノードを適切に設定することで、その空間分解能を観測データの特性や分析の目的に応じて調整する。設定されたノードを基準として実際に観測された車両走行軌跡を束ねて有向リンクまたはゾーンを設定し、ネットワーク構造を定義する。設定されたノード間で実際に走行が確認された方向のリン




図 3.3 マップマッチング処理と本研究で提案する方法論の比較

クのみ設定することで、現実の接続構造を担保する。空間的に観測が疎であり、リンク表現では十分な情報量を持たない走行軌跡についてはゾーンにより表現することで、情報量の集約およびネットワークの空間分解能の調整を行う。マップマッチング処理により所与のネットワークデータに情報を紐付ける工程と、本研究で提案する方法論のイメージを図 3.3 に示す。

本章では上記の構築手順に則った、2つの異なる状況に対応した方法論を提案する。3.2 節では、マップマッチング処理が施された車両走行軌跡データを用いる場合の方法論を、3.3 節では、ネットワークフリーな車両走行軌跡データを用いる場合の方法論を開発する。3.4 節では、3.3 節で開発したネットワークフリーデータを用いたネットワーク表現の拡張として、軌跡の空間情報に基づくノード設定手法の開発を行う。

3.2 マップマッチング処理が施された走行軌跡情報を用いた方法論

本節では，すでにマップマッチング処理が施された走行軌跡データを用いて，新たにネットワークデータを生成する方法論を開発する．本方法論は，対象とするネットワークの主要な交差点の特定，主要な交差点を通過した走行軌跡の特定，そしてリンクとして表現すべき走行軌跡の特定において，所与のネットワークの情報を用いる．具体的には，所与のネットワークデータに簡易的な階層化・簡略化処理を施し，主要交差点を基準とする空間分解能の無向グラフおよびゾーンで構成されたネットワークを構築する．これは走行軌跡データを用いて新たに構築するネットワークの下書きのような役割を果たすため，ドラフトネットワークと名付ける．マップマッチング処理が施された走行軌跡データをドラフトネットワークの空間分解能に対応して変換し，主要な交差点単位で集約を行うことで，走行軌跡データ指向のネットワークデータを構築する．本節の方法論で用いるドラフトネットワークのイメージを図 3.4 に示す．

3.2.1 方法論

本節で用いるデータは，対象地域のネットワークデータ $G = (V, E)$ と，マップマッチング処理が施された車両軌跡データ $P = \{p_{ci}\}$ である． V と E はそれぞれネットワーク G を構成するノードとリンクの集合である．各リンクは，起終点ノードと重み $w(e \in E)$ の情報を持つ．は分析目的に応じて各リンクに設定される値であり，重要なリンクほど高い値を持つ指標とする．車両軌跡 P は，車両 c のトリップ i における




図 3.4 ドラフトネットワークを用いた走行軌跡の集約

起点から終点までの軌跡 p_{ci} の集合である。 p_{ci} は車両 c のトリップ i で観測されたリンク単位の観測情報 $s_{cij} = (e_{cij}, t_{cij}^{IN}, t_{cij}^{OUT}, l_{cij})$ の集合であり、 j は各軌跡 p_{ci} で走行したリンクの順番を連番で振ったものである。ここで、 e_{cij} は走行したリンク、 t_{cij}^{IN} はリンクへの流入時刻、 t_{cij}^{OUT} はリンクからの流出時刻、 l_{cij} は走行距離である。

本節で提案する方法論は、リンク単位でネットワークを表現する主要ネットワークと、ゾーン単位でネットワークを表現するサブネットワークを、それぞれ観測された車両軌跡から構築するものである。主要ネットワークの構築手順は

1. ネットワークデータ G から主要部の抽出・無向化・簡略化処理により概略的なネットワーク構造を作成する。以降、このネットワークをドラフトネットワークとし、各ノードを代表交差点とする。
2. 車両軌跡 P の主要部を抽出し、ドラフトネットワークにマッチングすることで代表交差点単位の移動軌跡として再構成する。
3. 再構成した軌跡を用いて、各代表交差点間について移動が観測された方向にリンクを定義し、対応する軌跡から当該リンクの特性を推定する。

というものである。本方法論の特色は、ドラフトネットワークを無向グラフとして構築し、対応する走行軌跡情報から方向などの情報や属性を振り直すことで、ネットワークを再構築する点である。これにより、複雑な接続構造を持つ道路ネットワークを対象とした簡略化、および観測情報に基づく客観的な属性付与が可能となる。具体的には、既存研究で行われているようなネットワークの接続構造のみに基づく簡略化は、有向リンクの膨大な接続パターンを考慮した複雑な集約規則の定義を必要とし、多様なネットワークを対象に体系化することが困難である。本節では、ネットワークを無向グラフとみなすことで、シンプルな二つの集約規則のみを用いて簡略化することができ、図 3.2 に示したような一般的なネットワークデータに見られる過剰な数のノードを効率的に削減することが可能となる。ドラフトネットワークの生成過程で削除されなかったノードをネットワークの形状を表現する重要な交差点であるとみなし、これを代表交差点と定義する。車両軌跡情報を用いて代表交差点間を結ぶリンクを定義することで、実際に到達が観測された方向にのみリンクを設定することができ、軌跡の情報から直接その属性を付与することが可能となる。

サブネットワークについては主要ネットワークの構築に用いられなかった軌跡を分類し、同一クラスの軌跡を集約することで構築する。以下、それぞれの手順の詳細を述べる。

3.2.1.1 ドラフトネットワークの作成

ドラフトネットワークを作成するため、ネットワーク G から重み w が閾値 τ_1 以上のリンク

$$E^{MAIN} = \{e | w(e) \geq \tau_1\} \quad (3.1)$$

を抽出する．前述の通り，重み $w(e)$ はリンクの重要度が高い時ほど大きくなる指標であり，例えば当該リンクの交通量や道路種別などによって決められる指標である．リンク E^{MAIN} に対応する端点ノードの集合を V^{MAIN} とし，抽出されたネットワークを $G^{MAIN} = (V^{MAIN}, E^{MAIN})$ とする．ドラフトネットワーク作成のため，抽出したネットワーク G^{MAIN} を無向化し，以下の二種類の処理により簡略化を行う．一つ目は連続リンクの処理であり，任意のノードから伸びるリンクが二本のみの場合，当該ノードの除去により二本のリンクを連続化する処理である．もう一つは平行リンクの処理であり，同一ノードペア間を結ぶリンクが複数ある場合，それらを一本のリンクにまとめる．これらの簡略化処理のイメージを図 3.5 に示す．ネットワーク G^{MAIN} に対してこれらの処理を再帰的に行うことによりドラフトネットワーク $G^{DRAFT} = (V^{DRAFT}, E^{DRAFT})$ を生成し，ここに含まれる全ノード $v^{DRAFT} \in V^{DRAFT}$ を代表交差点に指定する．後の処理のため，ネットワーク G^{MAIN} の各リンク $e^{MAIN} \in E^{MAIN}$ が本処理によりドラフトネットワークのいずれの無向リンク $e^{DRAFT} \in E^{DRAFT}$ に簡略化されたかという情報を保存する．ここでドラフトネットワーク G^{DRAFT} は方向や重み等の情報を失っているが，本節で構築するネットワークの方向については観測された走行軌跡に基づいて，そのリンクの情報は対応する軌跡の集合から計算された集計量に基づいて設定されることに注意されたい．

3.2.1.2 車両軌跡の再構成

主要ネットワークの構築要素として，車両軌跡 P から走行したリンクの重み $w(e)$ が閾値 $\tau_2 (\geq \tau_1)$ 以上の部分

$$p_{ci}^{MAIN} = \{s_{cij} | w(e_{cij}) \geq \tau_2\} \quad (3.2)$$

を抽出する．ここで $\tau_2 (\geq \tau_1)$ より， p_{ci}^{MAIN} はネットワーク G^{MAIN} 上で観測された軌跡のみ抽出されることに注意されたい．抽出された車両軌跡 $P^{MAIN} = \{p_{ci}^{MAIN}\}$ をドラフトネットワーク G^{DRAFT} 上にマッチングすることで代表交差点単位の軌跡として再構築する．具体的には，前述の簡略化処理で保存した e^{MAIN} と e^{DRAFT} の対応情報を用いて， $p_{ci}^{MAIN} \in P^{MAIN}$ に含まれる観測情報 s_{cij} の走行リンク情報を対応する e^{DRAFT} に置き換える．この操作により連続して観測された s_{cij} (つまり j




図 3.5 ドラフトネットワーク作成のための簡略化処理

が連続する部分)のうち, 走行したリンクの情報 e^{DRAFT} が同一である部分について, 該当する複数の観測情報を一つの s_{cij} で取りまとめ, $t_{cij}^{IN}, t_{cij}^{OUT}, l_{cij}$ にはそれぞれ当該部分で最初の観測された時刻, 当該部分で最後に観測された時刻, 当該部分で観測された走行距離の総和を代入する. ここで再構成された観測情報を s_{cij}^{DRAFT} とし, その集合を車両軌跡 p_{ci}^{DRAFT} とする.

3.2.1.3 主要ネットワークの構築

代表交差点単位の車両軌跡 p_{ci}^{DRAFT} を用いて, 主要ネットワークを構築する. 各代表交差点ペアについて, 車両の移動が一度も確認できなかった方向にリンクを設定しないため, 移動軌跡が少なくとも一回以上観測された方向にリンク (以降, 車両軌跡リンクとする) を定義し, 対応する観測情報からそのリンク特性を推定する. 設定可能なリンク特性として, 例えばプローブカーの混入率 r が既知の場合, 各車両軌跡リンクを構成する軌跡の本数 m を用いて交通量

$$q = \frac{m}{r} \quad (3.3)$$

が推定可能である. また, Edie の定義³⁵⁾を用いることで各車両軌跡リンクの平均速度

$$v = \frac{TTD}{TTT} \quad (3.4)$$

が推定可能である. ここで TTD は対応する車両軌跡の総走行距離, TTT は対応する車両軌跡の総走行時間である. 本節では車両軌跡が1本でも確認できた場合に車両軌跡リンクを定義したが, 主要ネットワークの利用用途によっては各車両軌跡リンクが一定以上の軌跡から構成されている方が望ましい場合がある (例えば交通量の多い

道路を対象として分析したい場合等). また, リンク特性の設定の観点から, 対応する軌跡数が多いほど豊富な情報を持つことは明らかである. 今後, 車両軌跡リンクを定義する際の軌跡本数についても, ネットワークを利用する目的や使用する車両軌跡データの取得期間・混入率等に応じて設定するパラメータとすることが望ましいであろう.

3.2.1.4 サブネットワークの構築

車両軌跡データ P のうち, 主要ネットワークの構築で用いられなかった部分の軌跡

$$\mathbf{p}_{ci}^{SUB} = \{s_{cij} | w(e_{cij}) < \tau_2\} \quad (3.5)$$

を用いてサブネットワークを構築する. サブネットワークは主要ネットワークに比べて補助的な役割を果たすものであり, 利用目的に応じて必要となる情報が大きく異なる. 本節では, 交通状態の可視化とネットワークモデルへの活用という二つの目的に分けて, サブネットワーク構築の方法論を提案する.

(1) 交通状態の可視化を目的とした手法

車両軌跡 $\mathbf{p}_{ci}^{SUB}$ の観測情報に応じた重み $w^{SUB}(e)$ をネットワークデータ G の各リンクに追加し, 重み付きグラフカット理論を用いて適切なサイズになるまで G を分割する. 分割された各ネットワーク (以降, セグメントとする) をそれぞれサブネットワークの構成単位とし, 各セグメントについて対応する車両軌跡から可視化したい指標を算出する. これにより所与のネットワークデータ G に準拠した空間的な交通状態の可視化が可能となり, 取り扱う指標の次元も本来の膨大なリンク数から分割後のセグメント数まで削減される.

(2) ネットワークモデルへの活用を目的とした手法

主要ネットワークとの接続関係に基づいて車両軌跡 $\mathbf{p}_{ci}^{SUB}$ を分割・分類する. 具体的には, $\mathbf{p}_{ci}^{SUB}$ の観測情報 s_{cij}^{SUB} について, 主要ネットワーク構築に用いた軌跡の観測情報 s_{cij}^{DRAFT} と観測された順番 j を考慮し, 代表交差点間を結ぶ s_{cij}^{SUB} の部分集合, 代表交差点から開始し代表交差点以外の領域でトリップを終える s_{cij}^{SUB} の部分集合, 代表交差点以外の領域からトリップを開始し代表交差点までを結ぶ s_{cij}^{SUB} の部分集合をそれぞれ代表交差点ペア毎, 及び代表交差点毎に抽出する. これらを代表交差点間のサブネットワーク, または代表交差点を端点とするサブネットワークとしてそれぞれ定義し, 対応する観測情報から属性を推定することで, 主要ネットワークとの接続構造を保持したサブネットワークを構築する. ここで, (2) の方法論では車両軌跡 $\mathbf{p}_{ci}^{SUB}$ のうち代表交差点を一度も通過しなかった軌跡についてはネットワーク構築

に用いられないことに注意されたい。

3.2.2 validation

3.2.2.1 概要

3.2.1 で説明した方法論について、実データを用いたケーススタディの結果を示す。ネットワークデータには DRM の基本地図情報（3003 版）を、車両軌跡データには、Electronic Toll Collection System 2.0 (ETC 2.0) により取得された軌跡情報を用いた。車両軌跡データには別途 DRM へのマップマッチング処理³⁶⁾を施している。対象範囲は日本全国とし、観測データの対象期間は 2018 年 3 月の 1 ヶ月間とした。対象範囲における DRM のリンク数は 1,550,305 本、マップマッチング処理を施した ETC2.0 データは、DRM リンク 1 本分の移動を 1 単位としたとき、対象期間中に 1,244,407,348 単位の移動が計測されていた。DRM は日本全国を約 10km 四方のメッシュ単位で分割した「第 2 次地域区画」と呼ばれるエリア毎に管理されている。日本は 4,748 個の第 2 次地域区画で構成されており、これらを並列的に処理することで計算時間を軽減した。

本ケーススタディで用いた設定について述べる。各リンクが持つ重み $w(e)$ には、DRM の各リンクが保持する道路種別情報を用いた。DRM の各リンクには道路種別として「高速自動車国道、都高速道路、一般国道、主要地方道 (都道府県道)、主要地方道 (指定市道)、一般都道府県道、指定市の一般市道、その他の道路」の 8 種別のどれかが割り当てられており、高速自動車国道から順に 8~1 の値を割り当て、重み $w(e)$ として設定した。本ケーススタディでは閾値に $\tau_1 = 2, \tau_2 = 7$ を用いたケース (ケース 1) と、 $\tau_1 = 3, \tau_2 = 7$ を用いたケース (ケース 2) の 2 ケースを実施した。なお、DRM には信号交差点や U ターン路を短小リンクの組み合わせにより詳細に表現している箇所が多数ある。本ケーススタディでは、このような過剰な詳細表現を簡略化する前処理として、20m 以下のリンクが連続している部分を一つのノードに変換する前処理を施している。

3.2.2.2 ネットワークの構築

ネットワークの構築結果を示す。前処理の施された DRM ネットワークについて、2 章で説明した方法論によりドラフトネットワークを作成し、代表交差点ペア毎に車両の移動が確認された方向にのみ車両軌跡リンクを定義することで主要ネットワークを構築した。特定した代表交差点と構築した主要ネットワークの例 (ケース 2) を図 3.6 に示す。ただし図 3.6 では見やすさのため日本全国ではなく関東圏の 2 次メッシュ 4 個分の範囲のみ表示している。以降、図で結果のイメージを示す際は、同様に




図 3.6 代表交差点と主要ネットワーク（関東圏）

日本全国ではなく関東圏のみを表示する。

3.2.1 で説明した方法論に基づいて、残る処理を行った結果を示す。本ケーススタディにおけるサブネットワークの構築には交通状態の可視化を目的とした方法論を採用しており、各リンクの重み $w^{SUB}(e)$ には車両軌跡データから取得した重み付き交通量を用いた。また重みつきグラフカット手法には spectral partitioning の発展である normalized-cut³⁷⁾ を用いた。spectral partitioning はカットされるリンクの本数になるべく小さくし、分割されたネットワークのリンク数になるべく等しくなるような分割面を探索する最適化問題であり、その内 normalized-cut は重み付きネットワークを対象とした手法である。本ケーススタディで構築したサブネットワークの例（ケース 2）を図 3.7 に示す。図では各セグメントを異なる色で塗り分けており、それぞれ対応する軌跡情報を用いて式 3.4 から平均速度を計算することができる。主要ネットワークの各車両軌跡リンクと、サブネットワークの各セグメントについて、代表日（2018 年 3 月 13 日）の平均速度を算出し、色分けした例を図 3.8 に示す。集約前との比較のため、オリジナルの DRM ネットワークデータの各リンクに対応する軌跡から、同様に平均速度を計算し、色分けした例を同時に示している。二つの結果を比較すると、広範囲を対象とした概略的なモニタリングにおいては、重大な差異は確認できないことがわかる。特に、主要ネットワークについてはリンク単位で速度の




図 3.7 サブネットワークを構成するセグメント（関東圏）

切り替わりを表現できており，サブネットワークについてはセグメント単位で扱うことによりネットワークの要素数を削減しつつ適切な空間単位で速度情報を表現できている．

ネットワークの集約状況と，推定されたリンク特性を確認するため，代表日（2018年3月13日）における午前8時台の平均速度で可視化を行ったネットワークについて，一部を拡大したものを図3.9に示す．オリジナルネットワークの可視化結果を見ると，約300m程度の区間を3つのリンクで表現している箇所（オリジナルリンク1～3）が存在する．特にそのうちの1本（オリジナルリンク2）の延長は20m程度であり，このような短リンクを詳細に表現する有用性は低い．本節で構築したネットワークは，代表交差点単位でリンクを表現することから，適切な設定を行うことで交通工学的なモデル等にとって有用な集計単位でリンクを構築し，情報を活用できる可能性を示唆している．また，図3.9を比較すると，オリジナルリンクでは速度情報を持っていない（色が着いていない）リンクについて，集約ネットワークでは速度情報を保持している箇所があることが確認できる．これは，本節で構築したネットワークでサブネットワークの部分にあたり，その観測情報は同一セグメント内の観測情報の集計値により与えているためである．車両軌跡が観測される頻度が少ないサブネットワーク部において，1本1本のリンクに僅かな情報を付与するのではなく，セグメン




図 3.8 平均速度を可視化した例（上：オリジナルネットワーク 下：本節で構築したネットワーク）

ト単位で集計値を保持する方が、統計的な観点からも有用であると考えている。

主要ネットワークのリンク特性を確認するため、図 3.9 のオリジナルリンク 1 ～ 3 および車両軌跡リンクのそれぞれに付与された 1 時間毎の平均速度情報を図 3.10 および図 3.11 に示す。同じ観測データを元に集計された情報のため、その精度を比較することは難しい。特に GPS 軌跡等から推定した速度情報などは、より短い区間で集計した方が正しい（有用な）値であるとは限らないからである。図 3.10 と図 3.11 の比較より、これらが同様の速度変化傾向を捉えられているものとみなし、過剰に短いリンクの存在や観測が疎なエリアの情報を適当な空間単位で表現できることを考慮すると、本方法論は車両軌跡データから適切な解像度のネットワークを再構築できる可能性を示していると言えよう。

3.2.3 集約結果および計算時間

本方法論のリンク数削減効果について考察する。本方法論で構築したネットワークの構成単位数（つまり車両軌跡リンク数とセグメント数の合計）は、ケース 1 で 22,434、ケース 2 では 90,606 であった。これは集約前の DRM リンク数 1,550,305 本と比較して、ケース 1 では約 98.5% の削減、ケース 2 では約 94.1% の削減となっている。前節で考察した通り、本方法論は適切な単位での情報を集約し、ネットワークの大幅な次元の削減に成功していると言えよう。更に、ETC2.0 車両軌跡データを DRM ネットワーク上に紐付けて管理する場合、そのデータ数は 1,244,407,348 単位であったのと比較して、ケース 1 で構築した集約ネットワーク上に紐づけた車両軌跡データ数は 160,852,479 単位、ケース 2 で構築した集約ネットワーク上に紐づけた車両軌跡データ数は 353,269,928 単位であり、それぞれ約 87.1% と約 72.3% のデータ数削減になっている。オリジナルネットワーク上で管理・表現することが高負荷であった移動軌跡についても、本手法で構築した車両軌跡ネットワークを用いることでその負荷を大幅に軽減できる可能性を示唆している。本ケーススタディを行なった計算環境および計算時間について記載する。ネットワークの構築に用いた計算機の Operating system は Ubuntu(Version 16.04.5 LTS(Xenial Xerus)), CPU は Intel(R) Xeon(R) Gold 6148 CPU@2.40GHz, メモリは 388GB であった。計算時間については、ケース 1 では 1 メッシュあたり約 5.03 秒、ケース 2 では 1 メッシュあたり約 2.34 秒であった。車両軌跡データのマップマッチング処理については、オリジナルネットワークへの情報の付与においても必要となるため、計算時間には含めていない。




図 3.9 平均速度を可視化したした例（拡大） （上：オリジナルネットワーク
下：本節で構築した集約ネットワーク）




図 3.10 平均速度の変動（オリジナルリンク）（上：リンク 1，中：リンク 2，下：リンク 3）




図 3.11 平均速度の変動（車両軌跡リンク）

3.2.4 本節のまとめ

本節では，車両軌跡データを用いたネットワーク表現を行うことによる，ネットワーク集約手法を開発した．提案手法は，大規模ネットワーク上で観測された移動軌跡に基づき，ネットワーク構造の定義及び特性の計算を自動的に行うことができる．ネットワークの接続構造のみを考慮した簡略化や，サブネットワークのみを対象とした既存研究と比較して，客観的かつ汎用性に優れた方法論となっている．日本全国を対象としたケーススタディでは，オリジナルネットワークのリンク数を 90% 以上削減することができた．更に関東圏を対象とした広域的な可視化においては，削減効果に対して十分な精度を保っていることが確認できた．車両軌跡データのマップマッチング処理は，経路の特定において有用である一方，それ自体が多大な労力を要する上，誤差の原因となり得る．本方法論の拡張として，マップマッチング処理を用いることなく，ネットワークフリーな軌跡情報から直接ネットワークを表現する方法論の開発が挙げられる．

3.3 ネットワークフリーな走行軌跡情報を用いた方法論

本節では、ネットワークフリーな走行軌跡情報を用いたネットワークデータの生成手法について述べる。前節では、設定されたノードに対して各軌跡を関連付けるためマップマッチング処理の結果を活用したが、本節では一定の大きさを持つノード領域を定義し、その内部を走行した軌跡を紐づけることによりノード領域と軌跡を関連付ける。ノード領域は中心の位置座標と半径によって定義される円形の領域とする。ネットワークの代表的な交差点に対応するノード領域を主要ノード領域と名付け、観測された軌跡の量や空間情報に基づいてこの領域を適切に設定することで、ネットワークフリーな走行軌跡データからネットワークデータを構築する。

主要ノード領域の探索には、軌跡が観測された範囲内を全くの無情報からくまなく探索する方法と、交差点が存在する位置座標を所与のネットワークデータから事前情報として取得し、その中から主要ノード領域を探索する方法が考えられる。前者は、正確なネットワークデータが存在せず、走行軌跡情報のみ得られるような地域を対象とした場合に必要となる手法である。後者は、交差点の位置座標の情報が容易に得られる場合に活用できる手法である。本研究では、所与のネットワークデータから交差点の位置座標が事前取得できるものとし、その位置座標を中心とした一定サイズの領域から主要ノードを探索するものとする。事前情報として得られるこの領域を主要ノード領域候補と名付ける。以降、主要ノード領域候補から主要ノード領域を特定し、設定された主要ノード領域に基づく空間分解能で走行軌跡データからネットワークデータを生成する方法論を開発する。本方法論のイメージを図 3.12 に示す。




図 3.12 本節の方法論のイメージ

3.3.1 方法論

本方法論は、「主要ノード領域の特定および走行軌跡の断片化」、「主要リンクとゾーンの特定」、「交通状態量の計算」の3ステップで構成される。本節で用いる軌跡データは位置座標と時刻の情報を持つ点列データであり、また各点は車両 id と前回観測された点からの走行距離の情報を持つ。本項では、軌跡データの空間取得バイアスは小さく、各軌跡が通過した主要ノード領域候補は正確に特定できているものと仮定する。

3.3.1.1 代表交差点の特定および走行軌跡の断片化

全ての主要ノード領域候補から主要ノード領域を特定するため、セクション交通量を定義する。任意の主要ノード領域候補間を連続して通過した車両 id の数をカウントし、これをセクション交通量 q_{ij} と定義する。 $i, j \in I$ は通過された主要ノード領域候補、 I は全ての主要ノード領域候補である。主要ノード領域の集合を M とし、この特定のため閾値 τ_1 を定義する。主要ノード領域候補 i はセクション交通量が τ_1 以上の対応する主要ノード領域が3つ以上存在するとき、主要ノード領域となる。数式で記述すると、以下の通りである。

$$\begin{aligned} i \in M \\ \text{if } |S_i| \geq 3 \\ \text{where } S_i = \{ j \mid (j \in I, q_{ij} \geq \tau_1) \} \end{aligned} \quad (3.6)$$

全ての車両走行軌跡は、主要ノード領域を境界に断片化され、fragmental trajectories と定義される。 $g(t)$ は、車両軌跡 t が通過した全ての主要ノード領域候補を抽出する関数とする。例えば、 $g(t) = s_1, s_2, s_3, \dots, s_n$ の時、 s_i は軌跡 t が通過した i 番目の主要ノード領域候補である。 $d_1(t, s), d_2(t, s)$ は、主要ノード領域候補 s で軌跡 t を分割し、2つの軌跡を取得する関数とする。元の軌跡 t のうち、 $d_1(t, s)$ は分割された軌跡の前半を、 $d_2(t, s)$ は後半を取得する。例えば、軌跡 $g(t) = s_1, s_2, s_3, s_4, s_5$ に対して、 $g(d_1(t, s_3)) = s_1, s_2, s_3$ 、 $g(d_2(t, s_3)) = s_3, s_4, s_5$ となる。これらの関数を用いて、車両軌跡 t から fragmental trajectories を抽出する過程は以下のように記述される：

1. $i=1$ とする。
2. 軌跡 t が通過した主要ノード領域候補の中で最も上流側の主要ノード領域を特定し、これを s とする。
3. $t_i = d_1(t, s)$ とし、 t を $d_2(t, s)$ に置き換える。
4. t が空の場合プロセスを終了する。それ以外の場合 i を1増やし、2.に戻る。

全ての fragmental trajectories は主要ノード領域ペアを基準として束ねられる。

上流端と下流端が主要ノード領域 (それぞれ r, s と表される) である fragmental trajectories は, 集合 L_{rs} に属す. L_{rs} に属さない fragmental trajectories (i.e. 上流端または下流端, あるいはその両方が主要ノード領域でない軌跡) は集合 Z に属す.

3.3.1.2 主要リンクとゾーンの特定

Fragmental trajectories の集合 L_{rs} は主要リンクを定義するために用いられる. 主要リンクは二つの主要ノード領域間を結ぶ有向リンクである. リンク (r, s) は以下の条件を満たす時に主要リンクと呼ばれる:

$$|L_{rs}| \geq \tau_2 \quad (3.7)$$

Z に属するすべての fragmental trajectories のうち, 主要ノード領域を端点とするものを抽出し, 同一の主要ノード領域を端点とする fragmental trajectories の集合が一つのゾーンとして定義される. このため, 本節におけるゾーンは主要ノード領域との接続を担保したものとなる.

3.3.1.3 交通状態量の計算

上記で特定された各主要リンクとゾーンの交通状態量は, 対応する fragmental trajectories から計算される. 各主要リンクとゾーンに対応する fragmental trajectories の集合はすでに特定されているため, 交通量や平均速度などの交通状態量は, 軌跡データから直接計算される. 例えば, Edie の定義³⁵⁾ の平均速度 v_A は次のように計算される.

$$v_A = TTD_A / TTT_A, \quad (3.8)$$

ここで A は主要リンクまたはゾーンの一つであり, TTD_A は A で観測された軌跡の総旅行時間, TTT_A は A で観測された軌跡の総走行距離である. このようにして計算された値を用いて, 各主要リンクおよびゾーンに対応する交通状態量を計算する.

3.3.2 Validation

3.3.2.1 対象区間および使用データ

実際に観測された走行軌跡データを用いて提案手法の validation を行う. 対象区間は兵庫県神戸市付近を中心とした 10km 四方 (第二次地域区画番号: 523502), ネットワークデータの生成に用いたデータは, ETC 2.0 により 1 か月間 (2018 年 6 月) 取得された走行軌跡情報と, DRM 基本地図情報のノード位置座標情報である. 各走行軌跡は, 匿名化された車両 id, 位置座標, 時刻, 速度, 走行距離, 旅行 ID などの情報を保持している. また, 構築したネットワークデータの空間分解能を比較するた

め、DRM 基本地図情報のリンク情報を用いた。図 3.13 は、2018 年 6 月 6 日に取得した軌跡の点列を速度で色分けしたもの（上）と、事前情報として用いた主要ノード領域候補の位置、およびネットワークデータの空間分解能の比較に用いたリンク情報（下）を示したものである。

3.3.2.2 ネットワークデータの構築

二つのパラメータ τ_1 および τ_2 を変化させて構築した複数のネットワークデータの結果として、特定した主要ノード領域、対応する走行軌跡のプロット（1 日分）、定義した主要リンクをパラメータ毎に図 3.14 から 3.19 に示す。所与のネットワークデータとの比較のため、背景に DRM リンクデータを表示している。各結果について、比較対象となる DRM ネットワークデータのリンク数と比較して、構築したネットワークデータの要素数（リンク数とゾーン数の合計）で表現することにより集約された割合を計算し、これを Aggregation rate（AR）とする。結果より、AR が 70% 程度までのネットワークについては主要な生活道路を含めたネットワーク全域の主要道路がリンクとして構築されていることがわかる。AR が 90% 程度までのネットワークは、東西に伸びる高速道路と主要国道・県道と、それらを南北につなぐいくつかの主要道路がリンクとして構築されている。AR が 95% を越えると、高速道路のみ、または国道のみとなっている。

構築されたゾーンの例として、 $\tau_1 = 100$, $\tau_2 = 20$ の結果を図 3.20 に示す。上図は対応する設定の主要ノード領域および主要リンクを、下図は主要リンクおよびゾーンに対応する 1 日分の軌跡をそれぞれ色分けして表示している。本節の方法論ではゾーンは主要ノード領域へ流入した、または主要ノード領域から流出した軌跡の集合により定義されるため、異なるゾーンまたはリンクの軌跡と空間的に混在する可能性がある。対応する走行軌跡情報を用いて分析を行う上では問題とならないが、新たに位置座標に基づく処理を行う必要がある場合には注意が必要である。

3.3.2.3 構築したリンクおよびゾーンの観測情報

構築したネットワークデータに対応する観測情報の算出結果を示す。主要リンクに対応する観測情報の一例として、図 3.21 は高速道路部に対応するある主要リンクの速度を示したものである。本節では、マップマッチング処理を行わず観測情報を直接取得しているが、方向別の平均速度の時間変動を適切に捉えることができていることが分かる。ゾーンに対応する観測情報の一例として、図 3.22 はゾーンの trip length の分布を示したものである。ゾーン部を構成する軌跡は観測頻度が低く、軌跡単体から交通状態に関する情報を取得することが困難であるものだが、主要ノード領域を基準として集約することで、trip-length の平均や分散に関する情報を取得できているこ

とが分かる.







図 3.13 2018 年 6 月 6 日に神戸で観測された車両走行軌跡の点列（上）と 主要ノード領域候補および所与のネットワークの概形（下）



(a) 特定した主要ノード領域




(b) 主要リンクを構成する fragmental trajectories (1日分)




$\tau_1 = 10, \tau_2 = 10$
 Aggregation Rate : **59.21%**
 The number of Major links: 1,201
 The number of Zones: 505

(c) 構築結果とパラメータ


図 3.14 構築したネットワーク (主要ノード領域と主要リンク)



(a) 特定した主要ノード領域




(b) 主要リンクを構成する fragmental trajectories (1日分)




$\tau_1 = 20, \tau_2 = 20$
 Aggregation Rate : **70.97%**
 The number of Major links: 824
 The number of Zones: 390

(c) 構築結果とパラメータ


図 3.15 構築したネットワーク (主要ノード領域と主要リンク)



(a) 特定した主要ノード領域




(b) 主要リンクを構成する fragmental trajectories (1日分)




$\tau_1 = 50, \tau_2 = 20$
 Aggregation Rate : **83.31%**
 The number of Major links: 472
 The number of Zones: 226

(c) 構築結果とパラメータ


図 3.16 構築したネットワーク (主要ノード領域と主要リンク)



(a) 特定した主要ノード領域




(b) 主要リンクを構成する fragmental trajectories (1日分)




$\tau_1 = 100, \tau_2 = 20$
 Aggregation Rate : **89.29%**
 The number of Major links: 301
 The number of Zones: 147

(c) 構築結果とパラメータ


図 3.17 構築したネットワーク (主要ノード領域と主要リンク)



(a) 特定した主要ノード領域




(b) 主要リンクを構成する fragmental trajectories (1日分)



$\tau_1 = 200, \tau_2 = 20$
 Aggregation Rate : **95.17%**
 The number of Major links: 136
 The number of Zones: 66

(c) 構築結果とパラメータ


図 3.18 構築したネットワーク (主要ノード領域と主要リンク)



(a) 特定した主要ノード領域




(b) 主要リンクを構成する fragmental trajectories (1日分)



$\tau_1 = 400, \tau_2 = 20$
 Aggregation Rate : **98.73%**
 The number of Major links: 33
 The number of Zones: 20

(c) 構築結果とパラメータ

図 3.19 構築したネットワーク (主要ノード領域と主要リンク)



Aggregation Rate : **89.29%**
($\tau_1 = 100$, $\tau_2 = 20$)
Number of Major links: 301
Number of Zones: 147

図 3.20 主要リンクとゾーンの一例




図 3.21 主要リンクの方向別の速度情報





図 3.22 ゾーンの trip length (上の図が地図中央付近のゾーンに, 下の図が地図左下端付近のゾーンに対応する結果である.)

3.4 各点列の走行方向情報を用いた主要ノード領域の特定

前節では、各軌跡が通過した主要ノード領域候補をその位置関係のみから特定することを想定していたが、走行軌跡データの測位誤差や道路ネットワークの複雑さを考慮すると主要ノード領域の特定に重大な誤差を生じさせる可能性がある。本節では、走行軌跡の位置情報だけでなく、進行方向などの情報を用いて主要ノード領域を特定する方法論を開発する。

本節では前処理として、走行軌跡の各観測点から次の観測点へ進行する方向の角度情報の付与を行う。次に主要ノード領域の探索に用いる一定サイズの円領域を定義し、その内部に含まれる点列について角度情報の分布を取得可能とする。図 3.23 は各点の角度情報（上）と、3つの円領域に対応する角度分布（下）のイメージを示したものである。また図 3.24 は、実際に観測された走行軌跡データを用いて、半径 20m の領域を交差点上、道路上、ランプ上などに定義した場合に取得できる角度分布の例を示したものである。これらのうち、主要な交差点上に定義した円領域の角度分布は 4 峰となっていることが確認できる。本節では、このような角度分布の情報を用いて、進行角度を付与した走行軌跡データと、所与のネットワークデータから取得した交差点位置情報のみから主要ノード領域を特定する方法論を開発するものである。本研究では簡単のため、主要ノード領域のサイズは半径 20m で固定とする。

3.4.1 方法論および validation

主要ノード領域が 4 方向の道路に接続されており、各道路の交通量が一定以上であると仮定し、その特定を行う。主要ノード領域内の角度分布が 4 つの正規分布の混合分布であると仮定し、以下の数式で表す。

$$p(x) \sim \pi_1 N(\mu_1, \sigma^2) + \pi_2 N(\mu_2, \sigma^2) + \pi_3 N(\mu_3, \sigma^2) + \pi_4 N(\mu_4, \sigma^2) \quad (3.9)$$

μ_1 から μ_4 は、各正規分布の平均、 σ^2 は分散、 π_1 から π_4 は各正規分布の重みを表している。任意の主要ノード領域候補について得られた角度分布の情報を用いて、これらのパラメータを Expectation–Maximization (EM) アルゴリズムにより推定する。各方向の交通量が全て閾値 τ_a 以上の時、その領域を主要ノード領域とする。

角度情報を付与した走行軌跡データと所与のネットワークデータから取得した交差点位置情報を用いて、主要ノード領域の特定を行う。対象区間および用いたデータは前節と同様である。事前に取得した全ての交差点位置情報を中心点とした半径 20m の円領域を定義し、上記方法論で特定した主要ノード領域の結果を閾値 τ_a 別に図 3.25 に示す。






図 3.23 各点列への角度情報の付与

1) 主要な交差点



2) 双方向道路



3) その他 (ランプの一部)





図 3.24 現実の走行軌跡データを用いた角度分布の例


$\tau_a=5$




$\tau_a=10$




$\tau_a=15$



$\tau_a=20$



$\tau_a=25$



$\tau_a=30$




図 3.25 本節で特定した主要ノード領域

3.5 本章のまとめ

本章では、走行軌跡データ指向なネットワーク表現を行う方法論を開発した。3.2では、所与のネットワークに紐づいた走行軌跡データについて、単純な2種類の処理で生成可能なドラフトネットワークに基づいて主要ノードの特定およびリンクとゾーンの分割を行い、走行軌跡指向なネットワークを構築する方法論を示した。日本全国を対象とした実観測データによる validation では、所与のネットワークデータと比較して大幅に次元削減されたネットワークデータを実行可能な計算時間で構築できることを示した。ネットワークに紐づいている交通状態を可視化した結果では、主要路線の情報を高い空間分解能で表現し、それ以外をゾーンとして表現することで、対応する観測データ量の集約という観点からも合理的な結果を示していた。

走行軌跡データと所与のネットワークの交差点位置の情報のみを用いて、3.3では走行軌跡の量的な情報からネットワークを構築する方法を、3.4では観測誤差に関する仮定を緩和し、走行軌跡の進行方向情報から主要ノード領域を特定する方法論への拡張を行った。実観測データを用いた validation では、マップマッチング処理を伴わず、任意の空間分解能のネットワークデータを生成し、観測情報の紐付けが適切に行えることを示した。

今後の発展として、走行軌跡情報を用いた各リンクの道路種別の特定、経路情報を活用した並走路や立体交差の特定などが想定される。またマップマッチング処理を排除した方法論では、交差点の位置情報が容易に取得できることを想定して事前情報として用いた。道路地図データが生成されておらず、走行軌跡データのみからネットワークデータを生成したい場面等を想定して、全くの無情報から主要ノード領域を特定する方法論への拡張も想定される。

4 リンク部に対応する交通状態の推定

4.1 はじめに

本章では，3章で構築されたネットワークデータのうち，リンクとして表現された部分の交通状態を推定する方法論を提案する．リンク部に対応する各走行軌跡については，起点側の主要ノード領域を基準とした1次元的な走行距離を計算することが可能である．この情報を用いて，基準点からの走行距離を縦軸に，対応する時刻を横軸に取った時空間図によりリンク部を走行した軌跡の状態を表現することができる．本章では，この時空間図を活用してリンク部の交通状態を表現し，状態量を推定する方法論を開発する．本章で用いるリンク部の軌跡と，構築される時空間図のイメージを図4.1に示す．




図 4.1 リンク部に対応する走行軌跡と時空間図のイメージ

4.2 走行軌跡データを用いた量的変数の推定

本節では、走行軌跡データを用いた量的変数の推定手法について述べる。走行軌跡データは特に速度や旅行時間を取得することに適しており、これらの値は混入率の低い状況においても高い精度で推定できる一方、量的な値（e.g. 交通流率、交通密度）を走行軌跡データのみを用いて推定することは困難であると指摘されている³⁸⁾。その一例として、Fundamental diagram (FD) と呼ばれる経験的な変数間の関係を用いた推定に関する課題が挙げられる。FD の形状を三角形と仮定すること²⁷⁾は、実証的にその妥当性が認められ³⁹⁾⁴⁰⁾、理論的にも好ましい性質を持つことから多くの研究で用いられているが、自由流領域では速度を流率や密度に変換することができない。走行軌跡データから取得された自由流領域の速度と流率・密度を関連づけるため、変数間の関係として狭義凸 FD⁴¹⁾を仮定した研究⁴²⁾⁴³⁾があるが、自由流領域では速度の僅かな差に対する密度の差が大きいため、混入率の低い走行軌跡データから密度を推定する適切な手段とは言えない。量的な値の取得を目的として他のデータや機器と走行軌跡データを融合させた方法論として、検知器データと組み合わせた方法論⁴⁴⁾⁴⁵⁾や、headway camera の存在を仮定した方法論⁴⁶⁾が提案されている。これらの研究では、マクロ交通流理論の枠組みを用いた融合を行うことにより、合理的かつ高い精度の結果が示されている。しかしながら、観測データの取得可能性や運用にかかるコストを考慮すると、位置のみを計測する走行軌跡データのみを用いた方法論の開発が望ましいといえる。

走行軌跡データのみを用いて量的な値を推定する方法論として、CV の混入率の推定を元にした手法が提案されている⁴⁷⁾。CV の混入率は一般に未知であるが、その推定を介すことで走行軌跡データと量的変数を関連づけることは有用なアイデアである。時空間的な速度低下から推定されるショックウェーブ速度もまた、CV 軌跡のみから取得できる重要な情報の一つである。ショックウェーブ速度を活用した研究として、ショックウェーブ速度のフィルタリングによる交通状態推定手法⁴⁸⁾⁴⁹⁾が提案されているが、これらの方法論は交通流理論との整合がなく、交通流理論を用いた結果に比べて精度が低い。近年、ショックウェーブ速度とマクロ交通流理論²⁵⁾²⁶⁾を組み合わせることで流率または密度を推定する方法論が提案されている⁵⁰⁾⁵¹⁾。これまで、走行軌跡データとマクロ交通流理論を組み合わせた方法論では、その核となる FD が走行軌跡データから得ることが難しいという課題があった。近年、走行軌跡データのみを用いて FD を推定する方法⁵²⁾が開発されたことから、これらの方法論を組み合わせることで、走行軌跡データのみから量的な値を推定する方法論を開発できる可能性がある。

ショックウェーブ速度とマクロ交通流理論を組み合わせた研究はまだ数が少なく、様々な課題が残されている。混入率が低いまたは安定しない走行軌跡データを用いて密度を推定する際、その推定値の統計的なバラつきについて定量的に評価することが重要だが、推定値の信頼区間の推定を同時に行う研究は存在しない。既存研究が対象としているショックウェーブは、単一ボトルネックのシミュレーションや信号交差点の待ち行列によるものなど非常に単純なものであり現実で観測されるように様々な要因による複数のショックウェーブが組み合わさった状況は想定されていない。

本節の目的は、走行軌跡データのみを用いて、交通流率または密度およびその信頼区間を推定する方法論を開発することである。交通流理論に基づく交通状態推定では推定の時空間分解能に制約が課される場合が多い。特に、Cell Transmission Model³⁰⁾ や標準的な Variational Theory⁵³⁾⁵⁴⁾ に基づく推定では Courant-Friedrichs-Lewy Condition やそれに相当する条件を満たす必要があり、(一部に例外はあるものの)空間的に高精細な推定が困難であった。本節は、交通流理論に基づきながら推定の時空間分解能を任意に設定できる手法の構築を目指す。提案手法の独自性は以下の通りである。

- CV 軌跡データのみに基づく推定法である。
- 走行軌跡データに含まれる様々な情報 (FD, 混入率, ショックウェーブ) をベイズ的に統合する。
- 自由流領域の交通密度も推定できる。すなわち、ショックウェーブの付近の時空間だけでなく、渋滞が発生していない時間帯を含めた全ての時空間について量的な値を推定する。
- 交通流理論に基づいていながら推定の時空間分解能を任意に設定できる。
- ショックウェーブが複雑に組み合わさった一般の交通流に適用できる。

提案手法の validation のため、日本の都市高速道路で収集された低混入率の走行軌跡データに対してアルゴリズムを適用する。

4.2.1 方法論

本章では、CV から取得されたデータのみを用いて、交通密度の推定およびその信頼区間の推定を行う方法論を説明する。

4.2.1.1 Assumptions and definitions

交通流ダイナミクスが Lighthill–Whitham–Richards(LWR) モデル²⁵⁾²⁶⁾によって記述される時空間領域 $\mathcal{A}$ を考える．時空間領域 $\mathcal{A}$ を時間方向・空間方向にそれぞれ離散幅 Δt と Δx の等間隔で分割した離散的な時空間領域 $\mathbf{A}_{ij}$ が、それぞれ交通状態である交通流率 $q(\mathbf{A}_{ij})$ 、密度 $k(\mathbf{A}_{ij})$ 、速度 $v(\mathbf{A}_{ij})$ を持つものとする． i と j はそれぞれ時間と位置を示す非負の indices であり、 i が小さいほど早い時間帯を、 j が小さいほど上流側の位置を示す．以降これらの indices による区別が必要ない場合、その表示を省略し単に $\mathbf{A}$ と、更に $q(\mathbf{A}_{ij})$ 、 $k(\mathbf{A}_{ij})$ 、 $v(\mathbf{A}_{ij})$ は単に q 、 k 、 v と表現する．

ある時空間領域 $\mathbf{A}$ における速度 v と密度 k を車両軌跡から取得する場合、Edie の定義³⁵⁾ より以下のように計算できる：

$$v = \frac{\sum_{n \in \mathbf{N}(\mathbf{A})} d_n(\mathbf{A})}{\sum_{n \in \mathbf{N}(\mathbf{A})} t_n(\mathbf{A})} \quad (4.1a)$$

$$k = \frac{\sum_{n \in \mathbf{N}(\mathbf{A})} d_n(\mathbf{A})}{|\mathbf{A}|}. \quad (4.1b)$$

$\mathbf{N}(\mathbf{A})$ は時空間領域 $\mathbf{A}$ を走行した全車両の集合、 $d_n(\mathbf{A})$ と $t_n(\mathbf{A})$ はそれぞれ車両 n が領域 $\mathbf{A}$ 内を走行した距離と時間、 $|\mathbf{A}|$ は $\mathbf{A}$ の面積である．現実には、全車両の走行軌跡を取得することは困難なため、 $\mathbf{A}$ を走行した CV の集合 $\mathbf{P}(\mathbf{A})$ で $\mathbf{N}(\mathbf{A})$ を置き換えた指標を考える．時空間領域 $\mathbf{A}$ を走行した CV の速度 v^P と密度 k^P はそれぞれ

$$v^P = \frac{\sum_{n \in \mathbf{P}(\mathbf{A})} d_n(\mathbf{A})}{\sum_{n \in \mathbf{P}(\mathbf{A})} t_n(\mathbf{A})} \quad (4.2a)$$

$$k^P = \frac{\sum_{n \in \mathbf{P}(\mathbf{A})} d_n(\mathbf{A})}{|\mathbf{A}|}. \quad (4.2b)$$

となる．様々な既存研究で用いられているように、 v^P は v の推定値として用いることが可能である．以降、時空間領域 $\mathbf{A}$ の速度 v は、CV 軌跡より計算された速度 v^P により推定されているものとする．

任意の時空間領域 $\mathbf{A}$ について、交通状態が定常状態であり、交通流率と交通密度の関係が常に FD によって記述されると仮定する．FD の形状を三角形であると仮定すると²⁷⁾、時空間領域 $\mathbf{A}$ における交通流率 q と交通密度 k の関係は以下のように記述できる：

$$q = \begin{cases} uk & \text{if } k \leq \frac{w\kappa}{u+w} \\ w(\kappa - k) & \text{if } \frac{w\kappa}{u+w} \leq k \leq \kappa \end{cases} \quad (4.3a)$$

$$(4.3b)$$

u は自由流速度, w は backward wave 速度, κ は渋滞密度であり, 式 (4.3a) は自由流領域の関係を, 式 (4.3b) は渋滞流領域の関係を表している. FD のパラメータは走行軌跡データのみから推定可能であり⁵²⁾, 本節ではこれらのパラメータは事前に推定されているものとする. 全ての時空間 $\mathbf{A}$ について, 速度 v が u 以上である時空間領域を $\mathbf{A}^F \in F$, それ以外の時空間領域を $\mathbf{A}^J \in J$ とする. 実際には, 時空間 $\mathbf{A}^F$ の速度 $v(\mathbf{A}^F)$ は u 以上の様々な値が観測されうるが, 三角形 FD の仮定と整合させるため, $v(\mathbf{A}^F) = u$ とする.

4.2.1.2 Outline of methodology

これらの仮定を踏まえて, 各時空間 $\mathbf{A}$ の密度とその信頼区間を推定する方法論のアウトラインを以下に示す.

Step 0 FD の推定 (既往研究 Seo et al. による)

Step 1 渋滞領域の密度推定 (Step 0 の結果を用いる)

Step 2 混入率を用いた自由流領域の密度推定 (Step 1 の結果を用いる)

Step 3 ショックウェーブ理論を用いた自由流領域の密度推定 (Step 1 の結果を用いる)

Step 4 2つの推定結果の混合 (Step 2 と Step 3 の結果を用いる)

Step 0 では, Seo et al.⁵²⁾ による走行軌跡データのみを用いた FD 推定法により, FD を推定する. Step 1 では, CV から推定された速度と FD を用いて渋滞流領域の時空間の交通密度を推定する. Step 2 と Step 3 では, それぞれ独立に自由流領域を含む時空間の密度の推定を行う. Step 2 では, Step 1 の結果を用いて推定された混入率により, 自由流領域を含む全時空間の交通密度を推定する. Step 3 では, ショックウェーブの検知およびショックウェーブ速度の推定を行い, マクロ交通流理論を用いて自由流領域の密度推定を行う. Step 4 では, 混入率を用いて推定された密度の期待値および信頼区間と, 交通流理論を用いて推定された密度の期待値および信頼区間について, それぞれ確率分布を仮定し, バイズ推定の枠組みでそれらを掛け合わせることで各時空間の密度の事後分布を推定する. 本論文では, Step 2 までで推定された結果, すなわち混入率のみを用いて推定する方法”method with penetration rate”と, Step 4 までで推定された結果, すなわち shockwave 理論を用いてその結果を更新する方法”method with shockwaves”を比較することにより shockwave 理論を用いた方法論による精度を定量的に評価する.

Fig. 4.2 は, 本方法論の対象となる時空間のうち, step 1 から step 3 が対象とする箇所を示したものである. 渋滞領域であるオレンジ色の領域の密度は Step 1 によって, 緑色の領域の密度は Step 2 によって, 青色の領域の密度は Step 3 によってそれ




図 4.2 各 Step によって推定される時空間領域箇所を示した概略図

ぞれ推定される。Step 2 の推定では、緑色の領域だけでなく、全ての時空間領域について密度が推定されることに注意されたい。

4.2.1.3 Density estimation of congested regime (Step 1)

走行軌跡データから推定した速度情報と FD を用いて、渋滞流の時空間領域 $\mathbf{A}^J$ の密度を推定する。交通状態量間の基本的な関係式³⁵⁾

$$q = kv, \quad (4.4)$$

と式 (4.3b) より、 $\mathbf{A}^J$ の密度は

$$k(\mathbf{A}^J) = \frac{w\kappa}{v(\mathbf{A}^J) + w}, \quad (4.5)$$

と推定される。

4.2.1.4 Traffic density estimation using penetration rate (Step 2)

時空間領域 $\mathbf{A}$ を走行する全ての車両から、確率 r のベルヌーイ試行で CV が選定されると仮定し、時空間領域 $\mathbf{A}$ の密度 k を推定する。この時、時空間領域 $\mathbf{A}$ を走行し




図 4.3 時空間領域内の車両走行台数

た全車両の台数 $|\mathbf{N}(\mathbf{A})|$ は，成功回数を表すパラメータが時空間領域 $\mathbf{A}$ における CV の走行台数 $|\mathbf{P}(\mathbf{A})|$ ，各試行で成功する確率を表すパラメータが全車両に対する CV の混入率 r である負の二項分布に従う．各時空間領域の全車両の走行台数 $|\mathbf{N}(\mathbf{A})|$ の期待値は

$$E[|\mathbf{N}(\mathbf{A})|] = \frac{|\mathbf{P}(\mathbf{A})|}{r}, \quad (4.6)$$

分散は

$$Var[|\mathbf{N}(\mathbf{A})|] = \frac{|\mathbf{P}(\mathbf{A})|(1-r)}{r^2}, \quad (4.7)$$

となる．時空間領域 $\mathbf{A}$ の交通状態は定常状態と仮定されているため， $\mathbf{A}$ における全車両の走行台数は，時空間領域の時間幅 Δt ，距離幅 Δx ，そして密度 k を用いて

$$|\mathbf{N}(\mathbf{A})| = \Delta x k + \Delta t q \quad (4.8)$$

$$= (\Delta x + \Delta t v) k \quad (4.9)$$

と計算できる (Fig. 4.3 参照)．同様に，CV の存在台数は，

$$|\mathbf{P}(\mathbf{A})| = (\Delta x + \Delta t v) k^P \quad (4.10)$$

である．よって各時空間領域の密度 k の期待値は

$$E[k] = \frac{k^p}{r}, \quad (4.11)$$

分散は

$$Var[k] = \frac{k^p(1-r)}{r^2(\Delta x + \Delta tv)}, \quad (4.12)$$

となる．

混入率 r は，渋滞領域における交通密度の推定値 $k(\mathbf{A}^J)$ と，対応する CV の密度 $k^p(\mathbf{A}^J)$ を用いて推定される．時空間 $\mathcal{A}$ の期間内で混入率が一定であると仮定すると，混入率 r は

$$r = \frac{\sum_{\mathbf{A}^J \in J} k^p(\mathbf{A}^J)}{\sum_{\mathbf{A}^J \in J} k(\mathbf{A}^J)}, \quad (4.13)$$

である． J は当該期間中に混雑領域であった全時空間領域の集合である．

4.2.1.5 Traffic density estimation using shockwave theory

本節では，ショックウェーブ理論を用いた自由流領域の密度推定と，それに伴うショックウェーブ検知およびショックウェーブ速度の推定について説明する．

4.2.1.6 ショックウェーブ速度を用いた自由流領域の密度推定のアウトライン

ショックウェーブ理論²⁵⁾²⁶⁾を用いた自由流領域の交通密度推定は Fig.4.4 を用いて説明できる．Fig. 4.4 は，三角形 FD のパラメータが所与である場合における，ショックウェーブの延伸速度と，ショックウェーブによって分断された各領域の交通状態量との関係を示したものである．例えば，ショックウェーブ x によって区切られている状態 a と状態 b があり，状態 a が自由流領域，状態 b が渋滞領域であるとす．状態 a の交通流率および密度を q_a および k_a ，状態 b の交通流率および密度を q_b および k_b とすると，ショックウェーブ x の速度 s_x を用いて，これらの関係は

$$s_x = \frac{q_b - q_a}{k_b - k_a}, \quad (4.14)$$

と書ける．渋滞領域である状態 b の密度 k_b と交通流率 q_b が既に推定されており，ショックウェーブ速度 s_x が得られている場合，自由流領域である状態 a の交通流率 q_a および密度 k_a は式 (4.3a) と式 (4.14) より推定可能である．自由流領域の交通密度 $k(\mathbf{A}^F)$ の推定について一般化すると， $k(\mathbf{A}^F)$ は隣接する渋滞領域の密度 k^J ，境界となるショックウェーブの速度 s ，および FD パラメータを用いて

$$k(\mathbf{A}^F) = \frac{w\kappa - (w + s)k_j}{u - s}, \quad (4.15)$$

で計算できる．





図 4.4 ショックウェーブ速度を用いた自由流領域の交通密度推定

4.2.1.7 Shockwave speed estimation and free flow density estimation

ショックウェーブが通過した時空間を検出し、検出された各時空間についてそれぞれ対応するショックウェーブ速度を推定する．ショックウェーブ検知のため、各時空間 $\mathbf{A}_{ij}$ の速度 v_{ij} を用いて、時空間 $\mathcal{A}$ において速度が大きく変化した時空間の検出を行う．具体的には、画像処理の境界線識別手法 Sobel フィルター⁵⁵⁾を用いる．本手法は、各時空間 $\mathbf{A}_{ij}$ における空間方向の変化量”magnitude”を

$$m(\mathbf{A}_{ij}) = \sum_{i'=i-1,i,i+1} \sum_{j'=j-1,j,j+1} G_{i'j'} v(\mathbf{A}_{i'j'}), \quad (4.16)$$

ただしカーネル G は

$$G = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix}, \quad (4.17)$$

と定義する．ただし $\mathcal{A}$ の端にあたる時空間の変化量は 0 とする． m が正の場合は上流側が、負の場合は下流側が渋滞流領域であり、その絶対値が大きいほどその前後で大きな速度の変化が起きたことを示す．本節では、 m の絶対値が閾値 τ 以上の時空間を shockwave regime $\mathbf{A}^S$ と定義し、ショックウェーブが存在する時空間とみなす．

特定した各 shockwave regime について、以下の手順でショックウェーブ速度の推定および対応する自由流側の密度推定を行う．

1. 時間方向および空間方向に $\mathbf{A}^S$ より大きい適当な時間幅 Δt_B と距離幅 Δx_B を持つフィルター B を定義する．
2. $\mathbf{A}_{ij}^S$ が中心となるようにフィルター B を配置し、 B の内側で $m(\mathbf{A}_{ij}^S)$ と同じ符号の変化量を持つ shockwave regime $\mathbf{A}^B$ を全て特定する．ただし $\mathbf{A}_{ij}^S$ 自身も $\mathbf{A}^B$ の集合に含まれる．
3. 各 $\mathbf{A}^B$ の indicate を座標、対応する変化量 $m(\mathbf{A}^B)$ の絶対値を重みとした重み付き線形回帰を行い、推定した直線の傾きを速度の単位 (km/h) に合わせたものを、各 $\mathbf{A}_{ij}^S$ におけるショックウェーブ速度 $s(\mathbf{A}_{ij}^S)$ とする．
4. 変化量 $m(\mathbf{A}_{ij}^S)$ の符号を参考に、渋滞流領域側の隣接時空間 $\mathbf{A}^{SJ}$ を特定し、 $k(\mathbf{A}^{SJ})$, $s(\mathbf{A}_{ij}^S)$ および式 (4.15) を用いて隣接する自由流領域側の密度 k^{SF} を推定する．
5. $\mathbf{A}_{ij}^S$ の中心から自由流領域側に向けて、渋滞流領域の時空間または時空間 $\mathcal{A}$ の端に当たるまで自由流速度 u で進む（または後退する）直線を伸ばし、直線が通過した時空間の密度を k^{SF} とする．ただし、他の $\mathbf{A}^S$ を元に同様の手順で自由流領域の密度が既に推定されている時空間については、対応する変化量 $m(\mathbf{A}^S)$ の絶対値が大きい方の推定値を採用する．

4.2.1.8 信頼区間範囲推定におけるバラつきの伝播

FD とショックウェーブ理論を用いた密度推定過程において考慮すべきバラつきとして、FD のバラつき、プローブ軌跡から推定された速度のバラつき、ショックウェーブ速度のバラつきが挙げられる。これらのバラつきがそれぞれ期待値 0 の独立な正規分布に従うと仮定し、密度の推定過程で伝播するバラつきの大きさを計算する。推定密度のバラつきについても正規分布に従うと仮定する。

FD のバラつきは、自由流側と渋滞流側でそれぞれ推定された直線の切片のばらつきで表現する。式 (4.3a) および式 (4.3b) をそれぞれ切片 b_f および b_j を含む式に書き換えると

$$q = \begin{cases} uk + b_f & \text{if } k \leq \frac{w\kappa}{u+w} \\ -kw + b_j & \text{otherwise,} \end{cases} \quad (4.18a)$$

$$(4.18b)$$

となる。 b_f の期待値は 0、標準偏差は e_{b_f} 、 b_j の期待値は $w\kappa$ 、標準偏差は e_{b_j} である。これらの標準偏差は FD パラメータと同様事前に推定されているものとする。プローブ軌跡から推定された各時空間 $\mathbf{A}$ の速度の標準偏差 e_v は、

$$e_v = \sqrt{\frac{1}{|\mathbf{P}(\mathbf{A})| - 1} \sum_{n \in \mathbf{P}(\mathbf{A})} \left(\frac{d_n(\mathbf{A})}{t_n(\mathbf{A})} - v(\mathbf{A}) \right)^2}, \quad (4.19)$$

と計算される。 $|\mathbf{P}(\mathbf{A})|$ は $\mathbf{A}$ を走行した CV の台数であり、 $|\mathbf{P}(\mathbf{A})| \leq 1$ の場合 e_v は無限大とする。ショックウェーブ速度の標準偏差 e_s は、重み付き線形回帰における傾きの標準誤差とする。

密度の推定過程において、これらのバラつきが線形に伝播すると仮定し、推定密度のバラつきを計算する。渋滞領域の密度の推定を以下の関数

$$f(v, b_j) = \frac{b_j}{v + w}, \quad (4.20)$$

で定義すると、誤差伝播の公式より、推定密度の標準偏差 e_{k_j} は

$$e_{k_j} = \sqrt{\left(\frac{\partial f}{\partial v} \right)^2 e_v^2 + \left(\frac{\partial f}{\partial b_j} \right)^2 e_{b_j}^2}, \quad (4.21)$$

と計算できる。同様に、自由流領域の密度の推定を関数

$$g(v^J, s, b_j, b_f) = \frac{(v^J - s)b_j - (v^J + w)b_f}{(u - s)(v^J + w)}, \quad (4.22)$$

で定義する。 v^J は自由流領域の密度推定に用いられた、対応する渋滞領域の速度である。推定密度の標準偏差 e_{k_f} は

$$e_{k_f} = \sqrt{\left(\frac{\partial g}{\partial v^J} \right)^2 e_{v^J}^2 + \left(\frac{\partial g}{\partial s} \right)^2 e_s^2 + \left(\frac{\partial g}{\partial b_j} \right)^2 e_{b_j}^2 + \left(\frac{\partial g}{\partial b_f} \right)^2 e_{b_f}^2}, \quad (4.23)$$

となる．

4.2.1.9 Posterior distribution of estimated density

混入率を用いた推定と交通流理論を用いた推定の両方で密度の分布が推定された時空間について，2つの推定結果の分布を掛け合わせることで密度の事後分布を計算する．事後分布の計算においては，混入率を用いて推定された負の二項分布を，平均と標準偏差が等しい独立な正規分布で近似する．

混入率を用いて推定された密度の期待値を μ_p ，標準偏差を e_p と，交通流理論を用いて推定された密度の期待値を μ_s ，標準偏差を e_s とすると，これらの正規分布をかけた分布は，期待値

$$\mu_m = \frac{\frac{\mu_p}{e_p^2} + \frac{\mu_s}{e_s^2}}{\frac{1}{e_p^2} + \frac{1}{e_s^2}}, \quad (4.24)$$

標準偏差

$$e_m = \sqrt{\frac{1}{\frac{1}{e_p^2} + \frac{1}{e_s^2}}}, \quad (4.25)$$

の正規分布となる．

4.2.2 validation

提案手法の精度を検証するため，実観測走行軌跡データを用いた validation を行う．

4.2.2.1 Data and target road

対象路線は阪神高速道路3号神戸線，京橋ランプから深江ランプまでの約9.5kmの区間である．図4.5に対象路線付近の地図を示す．使用するデータは，2018年6月に取得された Electronic Toll Collection system(ETC)2.0 走行軌跡データと精度検証用の検知器データである．ただし，大規模な地震発生に起因する対象路線の通行止めがあった6月18日のデータは用いていない．本節で用いる ETC2.0 走行軌跡データの混入率は3%に満たない．ETC2.0CV から取得された軌跡の一例を図4.6に示す．

本方法論の仮定を考慮し，対象区間を出入りのない区間ごとに区切り，各区間各日毎に時空間 ω を定義してそれぞれ密度の推定を行う．ただし，ショックウェーブ速度推定のための変化量計算のみ全区間を通して行った．対象区間内には出入口が3つ（生田川・摩耶・魚崎）存在する．これらのランプにより区切られた各区間を上流側から順に section1 から4と名付ける．検知器は各区間に一つずつ設置されており，これ

表 4.1 対象区間および検知器設置位置

	range of a section(m)	location of a detector(m)
section 1	0 – 1000	200
section 2	1000 – 3000	2200
section 3	3000 – 8000	6100
section 4	8000 – 9500	8600

らによって 5 分毎に観測された交通流率や密度を推定精度検証用の ground truth とする．各区間の範囲および検知器の位置を表 4.1 に示す．

推定のために設定した各パラメータの値は以下の通りである．各区間の時空間の離散化に用いる時間幅 Δt は 15 分，距離幅 Δx は 500m，ショックウェーブ検知のパラメータ $\tau = 15$ ，フィルター B の時間幅 Δt_B は 75 分，距離幅 Δx_B は 1500m




図 4.5 Map of the target road




図 4.6 ETC2.0 probe vehicle trajectories (June 15, 2018)

表 4.2 FD parameters of each section

	FD parameters		standard deviations	
	u (km/h)	w (km/h)	e_{bf} (veh/h)	e_{bj} (veh/h)
section1	62.6	10.6	85.8	185.5
section2	62.1	10.9	150.9	112.8
section3	67.4	10.3	131.3	109.8
section4	69.0	11.5	113.7	133.2


とした．前章で述べた通り，各区間の FD パラメータは事前に推定されているものとする．各区間の FD パラメータを表 4.2 に示す．ただし渋滞密度は全ての区間で 160(veh/km/lane) を仮定した．推定した FD の一例として，各区間の FD と，対応する検知器データのプロットを Fig.4.7 に示す．

4.2.2.2 Estimation results


本方法論で推定された速度と密度の期待値，および速度の変化量を値によって色分けされた時空間図として示す．結果の時空間図は対象区間全域を結合した形で表示する．スペースの都合から，本論文には 6 月 15 日（金）の結果のみ掲載する．Fig.4.8 は走行軌跡データから推定した速度の時空間図を，Fig.4.9 は method with penetration rate で推定した密度の期待値を示している．4.16 を用いて計算した速度の距離方向の変化量を Fig.4.10 に，method with shockwaves で推定した密度の期待値を Fig.4.11 に示す．

検知器が設置された地点において，method with penetration rate および method with shockwaves の推定結果と ground truth の比較を行う．各区間の推定結果と ground truth について，6 時から 21 時までの変動を比較した結果を Fig. 4.12 に示す．時間幅は推定結果に合わせて 15 分単位としている．図の左側は method with penetration rate の結果と ground truth の比較を，図の右側は method with shockwaves の結果と ground truth の比較を示している．図より，method with penetration rate および method with shockwaves の推定結果はどちらも ground truth の日内変動を概ね捉えられていると言える．method with shockwaves では method with penetration rate に比べて信頼区間が小さくなっており，更に推定値がより ground truth に近い値を取っていることが分かる．


全対象期間において，method with shockwaves で推定した密度の期待値と感知器による密度の ground truth を散布図で比較した結果を Fig. 4.13 に示す．全ての区




(a) 京橋ー生田川



(b) 生田川ー摩耶



(c) 摩耶ー魚崎



(d) 魚崎ー深江

図 4.7 推定した FD と対応する検知器データのプロット




図 4.8 CV 軌跡から推定された平均速度により色分けした time-space diagram




図 4.9 method with penetration rate によって推定された密度により色分けされた time-space diagram

間において、推定結果は ground truth の傾向を捉えられているように見える。しかしながら、区間 4 の比較的交通密度が小さい領域については、ground truth に比べて推定密度が過大となっている。このバイアスの原因として、区間 4 の検知器設置がサグ付近に設置されていることが考えられる。サグの上り坂に設置されている検知器により、区間の自由流速度が過小に推定され、そこから推定される密度が過大に偏っている可能性がある。これらの結果より、本方法論によって計算した交通密度の期待値の精度は良いと言える。

method with penetration rate と method with shockwaves の推定結果を定量的に比較するため、Root mean square error(RMSE) による評価を行う。Fig. 4.3 は各区間における method with penetration rate と method with shockwaves の RMSE




図 4.10 Edge detection によって計算された magnitude により色分けされた time-space diagram






図 4.11 method with shockwaves によって推定された密度により色分けされた time-space diagram

を示したものである。全ての区間で、method with shockwaves の RMSE は method with penetration rate の RMSE より 10.5% から 21.1% 減少している。この結果は、混入率のみに基づく推定手法と比較して、FD と交通流理論により更新を行う本手法が合理的であることを示している。


各区間の 15 分毎の推定結果において、ground truth が推定値の信頼区間範囲内に含まれる割合を表 4.6 に、各推定において算出された信頼区間の 1s.d. 幅の大きさを表 4.4 示す。結果より、信頼区間に入る ground truth の量は概ね等しい一方で、信頼区間幅の大きさを比較すると、with shockwave の方が without shockwave よりも 8.2% から 17.5% 小さいことから、提案手法の信頼性が高いことが示されている。信




(a) method with penetration rate (section1)




(b) method with shockwaves (section1)




(c) method with penetration rate (section2)




(d) method with shockwaves (section2)




(e) method with penetration rate (section3)



(f) method with shockwaves (section3)



(g) method with penetration rate (section4)



(h) method with shockwaves (section4)

図 4.12 method with penetration rate と method with shockwaves により推定された信頼区間付きの推定密度と ground truths の比較 (June 15, 2018)




図 4.13 method with shockwaves により推定された密度の期待値と ground truth の比較

頼区間内に存在する ground truth の量について、どちらの結果も正規分布の 1s.d. 範囲内に存在すべき理論的な割合に近いが、やや小さい値を取っていることがわかる。この原因の一つとして、本方法論で仮定した正規分布と比較して、実際の ground truth の分布形が異なる可能性が考えられる。もう一つの原因として、混入率に基づく推定において、理想的な状態として混入率一定の仮定を置いたが、実際には混入率は時間帯等によって変動する値である可能性があり、これにより実際の分散は推定値よりも大きくなることが考えられる。実際の ground truth のばらつきも正規分布に従うとするならば、本方法論で推定された標準偏差の約 1.25 倍が理論的に正しい値である。このような過分散についても適切に推定できる方法論の開発は望ましいが、その違いは約 1.25 倍と小さく、3s.d. 範囲内に 92.5% から 97.9% の ground truth が存在することや、混入率の推定を介した推定のみの結果に比べて提案手法の信頼区間範囲が小さく信頼性が高いことを考慮すると、本方法論について実用上の問題はない

表 4.3 RMSE の比較

	RMSE (veh/km/lane)	
	without SW	with SW
section 1	11.5	10.3
section 2	9.4	8.0
section 3	8.8	7.3
section 4	11.4	9.0

表 4.4 1s.d. 幅の比較

	Standard deviation (veh/km/lane)	
	without SW	with SW
section 1	6.1	5.6
section 2	6.5	5.7
section 3	5.6	4.7
section 4	6.3	5.2

表 4.5 信頼区間に含まれる ground truth の割合 (method with penetration rate)

	Rate of ground truth in the confidence interval(%)		
	mean $\pm$ s.d.	mean $\pm$ 2s.d.	mean $\pm$ 3s.d.
section 1	49.4	79.7	92.4
section 2	58.0	89.1	97.6
section 3	54.8	88.4	97.9
section 4	36.0	76.3	96.3

と考えられる.

4.2.3 本節のまとめ

本節では, マクロ交通流理論を用いて, 走行軌跡データのみから交通密度を推定する方法論を開発した. 本方法論は, 実データの観測誤差を考慮して, 推定値の誤差の

表 4.6 信頼区間に含まれる ground truth の割合 (method with shockwaves)

	Rate of ground truth in the confidence interval(%)		
	mean±s.d.	mean±2s.d.	mean±3s.d.
section 1	49.4	79.7	92.5
section 2	57.3	89.2	97.5
section 3	54.8	88.4	97.9
section 4	41.3	78.6	96.4

範囲も同時に推定する．現実の交通マネジメントへの活用を想定し，提案手法は画像処理アルゴリズムを用いてショックウェーブの複雑な形状にも適用可能であり，更に渋滞の発生していない時間帯についてもナイーブな方法で密度を推定可能である．提案手法は，対象となる時空間の分割において，マクロ交通流理論を用いたシミュレーションで満たさなければならない条件（e.g. Courant-Friedrichs-Lewy Condition）を考慮する必要がなく，観測データの疎密に応じて柔軟に時空間を設定することができる．この特徴により，例えば validation で用いたように混入率の低い走行軌跡データを用いる際，距離方向の幅を必要以上に広く取ることなく時間方向の幅を広く設定することが可能となる．日本の都市高速道路で取得されたデータを用いた精度検証では，平均混入率が 3% に満たない走行軌跡データを用いた推定結果が，検知器データによって取得された観測密度の傾向を良好に捉えられていることを示した．また，混入率を用いたナイーブな推定手法に比べて，ショックウェーブ理論等を組み合わせた手法がほぼ全てのケースにおいて推定精度が向上していた．

交通流理論の活用にあたり，一般に密度情報は速度情報よりも有益な指標である．しかしながら，走行軌跡データを用いた方法論では，密度情報を推定することが困難であったことから，代わりに速度情報が用いられてきた．本節の貢献は，走行軌跡データのみから密度情報を推定する方法論の開発により，走行軌跡データを用いる多くの研究の精度を向上させる可能性があることである．例えば走行軌跡データの速度情報を用いたデータ同化手法⁴²⁾⁴³⁾において，観測値である速度を密度に関連付ける手段に課題があった．走行軌跡データから密度情報を適切に取得することができれば，より精度の高いデータ同化が行える可能性がある．速度の時空間図を画像としてパターン認識を行うことで旅行時間の予測を行う方法論⁵⁶⁾⁵⁷⁾が開発されているが，自由流領域の交通状態の違いについて速度から判定することが困難であるという課題がある．速度の時空間図の代わりに密度の時空間図を用いることで，自由流領域についても適切に評価できるパターン認識を行える可能性がある．

4.3 時空間状態の将来予測

本節では、時空間図を用いた将来の交通状態予測手法として画像認識を用いた方法論⁵⁶⁾⁵⁷⁾を応用し、低混入率の CV データを用いた場合の検証を行う。近年、豊富に蓄積された観測データを活用して、現在の交通状態と類似する過去の交通状態を特定し、将来の予測を行う機械学習・パターン認識手法が研究されている。しかしながら、高時空間分解能の交通状態を用いる場合、各時空間の交通状態およびその時間・空間方向の変動のパターンは膨大になるため、観測データの次元数が非常に大きくなる。機械学習等のデータ駆動型モデルを用いる上で、データの次元数が増加することにより、その処理速度や予測精度が急速に悪化することは”次元の呪い”と呼ばれ広く認知されている。そのため、予測を行うモデルに入力するまでに、観測データの次元を適切に削減することが重要な過程である。

データの次元削減を目的として、例えば画像認識分野では Gray-level Co-occurrence Matrix (GLCM) という指標⁵⁸⁾が開発され、現在もテクスチャ解析などで用いられている。GLCM とは、画像データの各セルの値や隣接セルとの差分を直接観測データとして用いるのではなく、隣接セルへの変動パターンをより小さいサイズの行列で表現したものである。具体的には、各セルの値を gray level と呼ばれる階級に分類し、隣接セル間の階級値の変動パターンのみをその頻度で表現する。図 4.14 は、GLCM の生成過程を図で示したものである。




図 4.14 GLCM の作成

Zhang et al.⁵⁷⁾ は、交通状態の時空間図を GLCM として表現することで、現在の交通状態と類似する過去の交通状態パターンを抽出し、旅行時間の予測に活用した。しかしながら、この研究では調査用に走行させた車両の軌跡情報を用いることで、比較的密な観測データを用いている。そのため、CV のような一般車両から取得される疎な観測データを用いた場合の精度を定量的に評価する必要がある。また既存研究では、自由流領域と渋滞流領域の速度情報の特性を考慮していないという課題もある。自由流領域では、渋滞領域と比較して周囲の車両による物理的な制限が少なくなることから、個々の車両の速度のばらつきは混入率の影響を受けやすい。しかしながら、交通状態の特定における主な興味の対象は渋滞領域であるため、自由流領域の速度変化よりも渋滞領域の速度変化を特徴量として優先的に採用すべきである。本研究では、疎な観測データを用いたパターン認識手法の実装を想定し、渋滞流領域の速度変化を認識することに特化した改良を加え、実観測データを用いて検証を行った。

本節では、過去の類似する交通状態を抽出した後、それぞれの状態の直後（将来）に観測された交通状態量を用いて、現在の交通状態に対する将来予測を行う。本節で構築する旅行時間予測のイメージを図 4.15 に示す。




図 4.15 時空間図を用いた将来予測

4.3.1 方法論

4.3.1.1 定義

走行軌跡データから生成した時空間図を入力として、交通状態パターンの類似度を定義する．時空間図の全ての値に対して 1 から n_g まで順に増加する連番の整数を割り当てた gray level を定義する．時空間図の各セルの値を gray level に置き換えたものをスケールマトリクスとする．スケールマトリクスを用いて、 n_g 行 n_g 列の行列 GLCM を作成する．GLCM の i 行 j 列目の値は

$$p(i, j) = |\{(x_1, y_1), (x_2, y_2) \in M \times N | f(x_1, y_1) = i, f(x_2, y_2) = j\}|, \quad (4.26)$$

と定義される． $f(x, y)$ はスケールマトリクスの y 行 x 列目の値、 M は時空間図の高さ、 N は時空間図の幅である．本研究では、渋滞領域の速度変化に特化したパターン認識を行うため、自由流速度の速度変化はただ一つの gray-level を用いて表現する．

現在の交通状態を表す時空間図と同サイズの時空間図を用いて同様に GLCM を作成し、その比較により交通状態の類似度を定義する．GLCM の類似度の計算には Normalized Sum of Squared Differences (NSSD) を用いる．NSSD は、

$$NSSD = \frac{\sum_{i=1}^{n_g} \sum_{j=1}^{n_g} (b_{ij} - \tilde{b}_{ij})^2}{\sqrt{\sum_{i=1}^{n_g} \sum_{j=1}^{n_g} (b_{ij})^2} \sqrt{\sum_{i=1}^{n_g} \sum_{j=1}^{n_g} (\tilde{b}_{ij})^2}}, \quad (4.27)$$

で計算される． b_{ij} は現在の交通状態から作成された GLCM における要素、 $\tilde{b}_{ij}$ は過去の交通状態から作成された GLCM における要素であり、NSSD が小さいほど現在と過去の交通状態が類似することを表す．

過去の交通状態の時空間図から GLCM が類似する候補を特定し、各候補に対する将来の観測情報を、類似度に基づいて重み付き平均することにより現在の交通状態の将来予測を行う．過去の GLCM のうち NSSD の小さい順に K 個選択する．負の指数分布を用いて類似度 k 番目の $NSSD_k$ を、

$$s_k = \lambda e^{-\lambda d_k}, \quad (4.28)$$

と変換する． λ は指数分布のパラメータ、 e はネイピア数である． s_k を用いて、加重平均を

$$w_k = \frac{s_k}{\sum_{\tilde{k}=1}^K s_{\tilde{k}}}, \quad (4.29)$$

と計算する．これより、現在のタイムステップ u から Δu 後の交通状態 $\hat{T}_{u+\Delta u}$ は、

$$\hat{T}_{u+\Delta u} = \sum_{k=1}^K w_k T_{k, \tilde{u}+\Delta u}^P, \quad (4.30)$$

で計算される． $T_{k,\tilde{u}+\Delta u}^P$ は類似度が k 番目の交通状態， $\tilde{u}$ は対応するタイムステップである．

4.3.1.2 モデルの学習とハイパーパラメータの推定

本モデルの予測精度を向上させるため，テストデータを用いてハイパーパラメータの学習を行う．本方法論の予測精度に関わるハイパーパラメータとして，GLCM 生成に用いる時空間図のタイムステップサイズ L ，過去の類似する時空間図の探索におけるタイムステップの探索範囲 R ，類似する GLCM の候補数 K ，重みづけに用いる指数分布のパラメータ λ が挙げられる． L は GLCM の生成に用いる時空間図の時間幅であり，現在の交通状態の時刻からどれだけ過去に遡って類似度を計算するかを示す． R は，類似する交通状態を探索する上での時間的な制約であり，現在の時刻とかけ離れた時間帯の交通状態を探索から除外する目的を持つ． K および λ は，重み付き平均による予測結果に影響を及ぼすものである．

活用可能な観測データをホールドアウト法 (Hold-out Validation) ⁵⁹⁾ により訓練データ，検証データ，テストデータの 3 つに分割する．予測精度を Mean Absolute Percentage Error (以下 MAPE とする) により評価し，訓練データと検証データを用いたグリッド探索法により最適なパラメータを求める．評価式は，

$$MAPE(L, R, K, \lambda) = \frac{100}{\hat{n}} \sum_{t=1}^{\hat{n}} \left| \frac{T(t) - \hat{T}(t)}{T(t)} \right| \%, \quad (4.31)$$

で表される． $T(t)$ ， $\hat{T}(t)$ はそれぞれ交通状態量の真値と予測値， $\hat{n}$ は精度評価を行う予測数である．式 (4.31) が最も小さくなるパラメータの組み合わせを採用する．これにより学習されたパラメータを用いて，テストデータを対象とした予測精度の評価を行う．

4.3.1.3 予測手法の精度評価

本節では，将来の交通状態予測における代表的な指標である旅行時間の予測によりその精度評価を行う．予測精度の比較のため，実際に都市高速道路において旅行時間予測手法として採用されている直近の同時刻和旅行時間が引き続き実現されることを仮定した Previous Instantaneous を用いて本方法論の精度評価を行う．また，ナイーブな推定法として過去の同一タイムステップの平均値を用いた Historical average も合わせて比較する．

4.3.2 validation


本節では、実データを用いた検証を行う。観測データには、2018 年 1 月 1 日から 6 月 30 日までの 6 ヶ月間に阪神高速道路神戸線（東行き）の京橋ランプから西宮ランプ間で収集された ETC2.0 走行軌跡データを用いる。各月 18 日までのデータを訓練データ、各月 19 日から 25 日までのデータを検証データ、各月 26 日以降のデータをテストデータとした。前節と同様に、各セルの距離幅と時間幅を定義して時空間図を構築する。本節で用いる距離幅は 500m、時間幅は 5 分である。図 4.16 は、作成した時空間図の一例を示したものである。

訓練データと検証データを用いてハイパーパラメータの学習を行い、テストデータの 6 時から 22 時までの時間帯を対象に旅行時間予測を行った結果を、本手法 (Pattern matching), Historical average, Previous instantaneous についてそれぞれ示す。 Δu は、既存の予測手法と合わせるため 1 単位 10 分とし、 $\Delta u = 1$ から $\Delta u = 6$ までの予測を行った。


$\Delta u = 1$ の結果の一例と $\Delta u = 2$ の結果の一例をそれぞれ図 4.17 と図 4.19 に示す。 $\Delta u = 1$ の結果については Previous Instantaneous がもっとも良い精度となっており、次いで Pattern matching が、そして Historical average が大きく予測を外していることがわかる。一方で、 $\Delta u = 2$ の結果については Pattern matching の MAPE が最も小さく、精度の良い結果を示している。この結果の考察として、将来の交通状態は直近の交通状態に強く依存するため、直前の同時刻和旅行時間を用いることは単純ながら精度の高い予測結果をもたらしていると考えられる。10 分後 ($\Delta u = 1$) などの近い将来の旅行時間を予測するためには、Previous Instantaneous は簡単かつ有効な手法であり、これが実務において採用されている理由だと考えられる。一方で、本研究で採用した Pattern matching は、直近の旅行時間情報を用いず、過去の情報のみから予測を行っているにも関わらず 10 分後 ($\Delta u = 1$) の予測結果では Previous Instantaneous と近い精度を示しており、更に 20 分後 ($\Delta u = 2$) の予測結果ではその精度を上回っている。同様に過去の情報のみを用いる Historical average と比較すると、その精度の差は歴然である。短期的な予測を効率的に行う同時刻和に対して、Pattern matching による予測は中期的な予測に活かせる可能性があるとし唆された。

図 4.18 と図 4.20 は、Pattern matching および Previous instantaneous の予測結果の精度が一部大きく外れていた時間帯がある日付の結果を示したものである。これらの日付において、対象区間における日々の交通状態で観測されない突発事象が起きていたことが確認されており、その場合直近の情報の活用や過去のデータとのパターン認識手法は適切な効果を持たないことを示している。


図 4.21 は、 Δu 別・日別の MAPE の結果を表したものである。より将来の予測を行うにつれて、同時刻和旅行時間による精度が悪くなり、パターンマッチングによる予測の精度のほうが同時刻和旅行時間による精度が良くなっていることが確認できる。




(a) 2018 年 6 月 24 日 (日)




(b) 2018 年 6 月 25 日 (月)




(c) 2018 年 6 月 26 日 (火)




(d) 2018 年 6 月 27 日 (水)



(e) 2018 年 6 月 28 日 (木)




(f) 2018 年 6 月 29 日 (金)




(g) 2018 年 6 月 30 日 (土)


図 4.16 本節で構築した時空間図



(a) 2018 年 3 月 29 日 (木)




(b) 2018 年 6 月 26 日 (火)




(c) 2018 年 6 月 30 日 (土)


図 4.17 1 期先 ($\Delta u = 1$) 旅行時間予測の比較図 1



(a) 2018 年 3 月 30 日 (金)




(b) 2018 年 3 月 31 日 (土)




(c) 2018 年 4 月 27 日 (金)


図 4.18 1 期先 ($\Delta u = 1$) 旅行時間予測の比較図 2



(a) 2018 年 3 月 29 日 (木)



(b) 2018 年 6 月 26 日 (火)



(c) 2018 年 6 月 30 日 (土)

図 4.19 2 期先 ($\Delta u = 2$) 旅行時間予測の比較図 1









図 4.20 2 期先 ($\Delta u = 2$) 旅行時間予測の比較図 2




(a) $\Delta u = 1$




(b) $\Delta u = 2$




(c) $\Delta u = 3$



(d) $\Delta u = 4$



(e) $\Delta u = 5$



(f) $\Delta u = 6$

図 4.21 $\Delta u \cdot$ 日別の MAPE 比較図

4.4 本章のまとめ

本章では、走行軌跡情報がリンク単位で集計されている区間について、走行軌跡データのみから推定することが困難であった交通量や密度などの量的変数を信頼区間込みで推定する方法論を開発した。結果は、車両検知器データから得られた真値を適切に推定できており、更にその信頼区間範囲も合理的な値で推定できていた。

速度の時空間情報を用いて、画像認識手法を活用したデータ指向な将来予測手法を構築した。旅行時間を対象に実観測データを用いて行った validation では、10 分以上先の将来予測を行う際、実務で実際に採用されている方法論と比較してその精度が優れていたことを示した。交通状態に関する変数としてより詳細な情報を持つ交通密度の時空間図を用いて同様の予測を行うことや、マクロ交通流理論を組み合わせた動学化などが今後の発展として求められる。

5 ゾーン部に対応する交通状態の推定

5.1 はじめに

本章では、3章で構築したネットワークデータのゾーン部分に対応する交通状態を推定する方法論について述べる。ゾーン内部のマクロな交通状態量を推定する方法論として、MFDを用いた推定手法が挙げられる³¹⁾。各ゾーンについて集計的な交通状態量を定義し、これらの変数間の関係式であるMFDが推定できれば、以降はゾーン内の平均速度情報のみから平均交通流率や平均密度などの量的な交通状態変数を推定することが可能となろう。このような推定にMFDを用いるためには、その形状がwell-definedであることが必要である。MFDがwell-definedであるということは、同一の平均密度に対して複数の平均交通量に対応することがなく、変数間の関係を明確に定義できるような状態のことを指す。しかしながら、現実の道路網を対象とした分析ではヒステリシスループなどのwell-definedでないMFD（以降 ill-defined MFD と呼ぶ）が推定された例が多数報告されている⁶⁰⁾⁶¹⁾⁶²⁾。

Well-defined な MFD を推定するための条件として、交通流理論的な側面から、対象とするネットワークや需要の特性に言及した研究はあるが⁶³⁾、実データを用いて検証を行った研究は未だ乏しい。例えば、推定に用いる車両検知器の設置箇所や対象ネットワークのサイズが well-definedness に与える影響について考察した研究⁶⁴⁾があるが、これらの研究において well-defined であるかどうかはプロットのばらつきを見ただけで判断したものである。

走行軌跡データのように未だサンプル数が少なく、混入率が安定しないデータを用いる際、統計誤差を考慮することは重要な要件である。本章では、実観測データを用いて推定した MFD が well-defined であるかどうか、観測データの統計誤差を考慮して判定できる指標を開発する。MFD の well-definedness に関する統計的な評価が行えるようになることで、ゾーンとして定義されたネットワークの交通状態を車両軌跡データから適切に推定できるかどうか定量的に判断することができるであろう。

実観測データを用いた MFD の推定を行う上で、その推定手法には走行軌跡データのみを用いたものと、検知器データの情報を組み合わせたものが存在する。前者の方法論の精度は混入率の安定性に強く依存するため、本章では一般に普及している走行軌跡データの混入率の不安定性を考慮し、軌跡情報と併せてゾーン内に設置された車

両感知器から取得された情報を用いた方法論を採用する。ただし，図 5.1 のイメージで示すように，走行軌跡情報および車両感知器情報は共にネットワークフリーな状態で用いられるため，ネットワークデータとの紐付けなどの処理は必要ないことに注意されたい。




図 5.1 ゾーン部の交通状態推定に用いる情報のイメージ

5.2 実観測データを用いた MFD の推定と well-definedness の評価

5.2.1 方法論

5.2.1.1 交通状態量および MFD の定義

任意の空間領域 $\mathbf{A}$ における交通状態変数を定義する．交通流率は領域内に設置されている車両感知器から，平均速度は領域内を走行した車両の軌跡データから推定し，これらの変数から交通状態量間の基本的な関係式³⁵⁾

$$q = kv \quad (5.1)$$

を用いて交通密度を計算する． $\mathbf{A}$ のエリア交通量 $q(\mathbf{A})$ は $\mathbf{A}$ 内に存在する検知器を用いて

$$q(\mathbf{A}) = \sum_{i \in \mathbf{D}(\mathbf{A})} q_i \quad (5.2)$$

と計算される． $\mathbf{D}(\mathbf{A})$ は領域 $\mathbf{A}$ 内に存在する検知器の集合， q_i は検知器 i の交通量である． $\mathbf{A}$ の平均速度 $v(\mathbf{A})$ は $\mathbf{A}$ 内を走行したプローブ車両の情報を用いて，Eddie の定義³⁵⁾ より以下のように計算できる：

$$v(\mathbf{A}) = \frac{\sum_{n \in \mathbf{P}(\mathbf{A})} d_n(\mathbf{A})}{\sum_{n \in \mathbf{P}(\mathbf{A})} t_n(\mathbf{A})} \quad (5.3)$$

$\mathbf{P}(\mathbf{A})$ は時空間領域 $\mathbf{A}$ を走行したプローブカーの集合の集合， $d_n(\mathbf{A})$ と $t_n(\mathbf{A})$ はそれぞれ車両 n が領域 $\mathbf{A}$ 内を走行した距離と時間， $|\mathbf{A}|$ は $\mathbf{A}$ の面積である．これらの指標を用いて，領域内の密度は

$$k(\mathbf{A}) = \frac{q(\mathbf{A})}{v(\mathbf{A})} \quad (5.4)$$

と計算される．これらの交通状態量を一定期間毎に取得し，プロットしたものの best-fit 曲線を対象エリアの MFD とする．

5.2.1.2 MFD の well-definedness の評価

MFD の well-definedness を統計的な検証に用いる指標を計算するため，各交通状態量の信頼区間を定義する．交通流率 $q(\mathbf{A})$ の標準偏差 e_q はポアソン分布に比例すると仮定し，

$$e_q = \sqrt{q(\mathbf{A})} \quad (5.5)$$

と計算される．プローブ軌跡から推定された領域 $\mathbf{A}$ の速度の標準誤差 e_v は，

$$e_v = \frac{1}{\sqrt{|\mathbf{P}(\mathbf{A})|}} \sqrt{\frac{1}{|\mathbf{P}(\mathbf{A})| - 1} \sum_{n \in \mathbf{P}(\mathbf{A})} \left(\frac{d_n(\mathbf{A})}{t_n(\mathbf{A})} - v(\mathbf{A}) \right)^2} \quad (5.6)$$

と計算される． $|\mathbf{P}(\mathbf{A})|$ は $\mathbf{A}$ を走行したプローブカーの台数である．ただし $|\mathbf{P}(\mathbf{A})| \leq 1$ の場合 e_v は計算しない．交通密度の推定過程において，誤差が線形に伝播すると仮定する．密度を算出する式 (5.4) を関数 $f(q, v)$ とすると，誤差伝播の公式より，密度の標準偏差 e_k は

$$e_k = \sqrt{\left(\frac{\partial f}{\partial q} \right)^2 e_q^2 + \left(\frac{\partial f}{\partial v} \right)^2 e_v^2} \quad (5.7)$$

と計算できる．

以上で計算された各交通状態量の標準偏差を踏まえて，推定された MFD が well-defined であるか定量的に検証する．任意の期間のデータを用いて推定された MFD 曲線と，異なる期間の検証用データを用いて well-definedness の指標を計算する．検証用データのプロット群について，各プロットから平均交通流率方向または平均密度方向の 3 標準偏差範囲内に MFD 曲線が収まっていた場合，そのプロットを well-defined plot と，それ以外の場合そのプロットを ill-defined plot と名付ける．全プロットのうち well-defined plot の割合を $r_w(\%)$ と定義し， r_w が高いほどそのエリアの MFD が well-defined であるとみなす．図 5.2 に，各プロットとその信頼区間を用いて well-definedness の検証を行うイメージを示す．

本方法論と比較を行うため，RMSE による well-definedness の評価を定義する．本章では，推定された MFD 曲線と，各検証用プロットの縦軸（交通量）方向の残差を用いて RMSE を計算した．

5.2.2 validation

5.2.2.1 対象エリアと使用する観測データ

本節で行う validation の対象エリアは，大阪府中心部を含む約 10km 四方の領域（第 2 次地域区画番号：523504）である．対象期間は 2018 年 6 月 4 日～8 日および 11 日～15 日の平日 10 日間とし，ETC2.0 から取得した軌跡のうち高速道路を走行していない軌跡データと，対象エリアにおいて一般道路の交通量を取得している jartic 車両感知器データを観測データとして用いた．図 5.3 は，対象エリアにおいて車両感知器が設置されている箇所を示したものである．




図 5.2 信頼区間を用いた well-definedness の検証




図 5.3 対象範囲と車両検知器の設置箇所


5.2.2.2 対象エリアからゾーンをランダムに抽出した結果

対象エリア内部からランダムなサイズの矩形ゾーンを 100 個抽出し、2018 年 6 月 4 日～8 日の観測データから MFD を推定、11 日～15 日のデータを用いて well-definedness 指標 r_w の計算を行った。図 5.4 は、推定用のデータをプロットしたグラフの一例である。見やすさのため、各軸の値は mesh 内の検知器設置位置における 1 車線単位に合わせているが、誤差の計算には事前に mesh 内の交通量の総和を用いていることに注意されたい。図の左半分は比較的大きいサイズのゾーンのプロットを、図の右半分は比較的小さいサイズのゾーンのプロットを示しており、その見た目のみから判断するならば、MFD はサイズが大きいほど well-defined であると言える。一方で、対応する検証用のデータを用いて本研究で定義した信頼区間範囲を計算し、各プロットに 1 標準偏差範囲を示したものを図 5.5 に示す。ゾーン内で観測された走行軌跡数および設置されている検知器数に応じて、信頼区間の幅が大きく異なることがわかる。ここから、MFD の well-definedness にネットワークのサイズは直接影響せず、用いる観測データの統計誤差により MFD がバラついて見えていた可能性が示唆される。


図 5.6 および図 5.7 は、ランダムに抽出した 100 個のゾーンに対してそれぞれ MFD の推定および well-definedness 指標の計算と RMSE の計算を行い、ゾーン内部の特性との関係を示したものである。ゾーン内部の特性として、図 5.6 は、ゾーン内のネットワークの総延長を、図 5.7 は、ゾーン内の検知器数をそれぞれ採用し、横軸にとっている。RMSE に対する結果を見ると、ネットワークの総延長および検知器数が増えるほど RMSE が小さくなり、MFD が well-defined に近づく傾向が見て取れる。しかしながら、本研究で定義した well-defined 指標に対する結果を見ると、そのような強い傾向はなく、むしろネットワークの総延長および検知器数の増加に対して well-defined plot の割合が小さくなっており、MFD が ill-defined に近づいていることを示している。この原因として、ネットワーク内に存在する検知器間の相関が関係している可能性がある。MFD の推定において、交通量の計算に用いられる各検知器はそれぞれ独立であると仮定されているが、もしこれらが相関を持つ場合、過分散の原因となり、理論的な統計誤差よりも大きくばらつく。このような過分散の影響により、ネットワーク内に多くの車両検知器が存在している場合に well-definedness 指標が小さくなった可能性がある。一方で、本評価手法を用いた場合どのようなサイズのゾーンに対しても r_w が概ね 80% 以上となっており、走行軌跡データとゾーン内の交通量データを組み合わせて推定した MFD の well-definedness が十分実用に足るものである可能性を示唆している。




(a)



(b)




(c)




(d)


図 5.4 MFD 推定に用いたプロット




(a)



(b)




(c)




(d)

図 5.5 推定された MFD と検証用のプロット




(a) Well-definedness 指標




(b) RMSE

図 5.6 ネットワークの総延長に対する well-definedness の評価



(a) Well-definedness 指標



(b) RMSE

図 5.7 検知器数に対する well-definedness の評価


5.2.2.3 対象エリアを等間隔に区切ってゾーンを作成した結果

対象エリアを約 2km 四方の比較的小さなゾーン（第 3 次地域区画 4 個分に相当）に分割した各エリアの MFD の推定および r_w の計算を行い、ヒートマップによる可視化を行う。25 個に分割されたゾーンのうち南西端のものを mesh1 とし、東隣の mesh が 1 つ、北隣の mesh が 5 つ数が増えるよう mesh 番号をつけた。5.2.2.2 と同様に、2018 年 6 月 4 日～8 日のデータから MFD を推定し、11 日～15 日のデータを用いて r_w を計算した。


結果として、各 mesh の MFD 推定に用いたプロットおよび r_w の計算に用いた誤差付きのプロットを図 5.8～5.12 に示す。ゾーンのサイズは均一であるが、ゾーン内で観測された走行軌跡の量およびゾーン内に設置されている検知器数の影響等により、それぞれプロットのばらつきに差異が確認できる。同様に、各検証用データのプロットの信頼区間範囲にも差異があることから、5.2.2.2 で考察したように、プロットのばらつきが MFD の well-definedness を表しているとは一概には言えない。

対象エリアの各メッシュについて、計算した r_w と RMSE のヒートマップをそれぞれ図 5.13 に示す。Well-defined plot の割合は大きいほど、RMSE は値が小さいほど well-defined な MFD を推定できていることを意味するため、それぞれ well-defined であるほど色が黄色に近くようカラーバーを調整している。図より、RMSE を用いた評価と本研究で開発した指標の評価は大きく異なる結果を示していることが視覚的に確認できる。例えば、大阪市内中心部（mesh1,6 付近に相当）において、RMSE は比較的小さく well-definedness の高さを示しているが、 r_w による評価では周辺と比較して well-definedness が低くなっていることがわかる。また郊外部（mesh8,21 等）では反対に、RMSE による評価は低く、 r_w による評価は高くなっている。


本章で開発した評価指標を用いる場合、対象エリアにおける MFD の well-definedness は概ね実用に足るものであると確認できる。例えば、各メッシュの r_w は平均 91.6%、最小で 76.3% であった。また 25 個のメッシュの内、 r_w が 80% 以上の mesh が 23 個、90% 以上の mesh が 16 個であった。これより、ETC2.0 走行軌跡データと jartic 検知器データを用いて推定した MFD は、統計誤差範囲を考慮すると概ね well-defined であったと言える。




(a) mesh1(2018/6/4-8)




(b) mesh1(2018/6/11-15)




(c) mesh2(2018/6/4-8)




(d) mesh2(2018/6/11-15)




(e) mesh3(2018/6/4-8)




(f) mesh3(2018/6/11-15)




(g) mesh4(2018/6/4-8)



(h) mesh4(2018/6/11-15)




(i) mesh5(2018/6/4-8)




(j) mesh5(2018/6/11-15)


図 5.8 MFD の推定に用いたデータのプロット (左) と well-definedness の検証用に用いたデータの信頼区間範囲付きプロット (右)




(a) mesh6(2018/6/4-8)




(b) mesh6(2018/6/11-15)




(c) mesh7(2018/6/4-8)




(d) mesh7(2018/6/11-15)




(e) mesh8(2018/6/4-8)




(f) mesh8(2018/6/11-15)




(g) mesh9(2018/6/4-8)



(h) mesh9(2018/6/11-15)




(i) mesh10(2018/6/4-8)




(j) mesh10(2018/6/11-15)


図 5.9 MFD の推定に用いたデータのプロット (左) と well-definedness の検証に用いたデータの信頼区間範囲付きプロット (右)




(a) mesh11(2018/6/4-8)




(b) mesh11(2018/6/11-15)




(c) mesh12(2018/6/4-8)




(d) mesh12(2018/6/11-15)




(e) mesh13(2018/6/4-8)




(f) mesh13(2018/6/11-15)




(g) mesh14(2018/6/4-8)



(h) mesh14(2018/6/11-15)




(i) mesh15(2018/6/4-8)




(j) mesh15(2018/6/11-15)


図 5.10 MFD の推定に用いたデータのプロット (左) と well-definedness の検証に用いたデータの信頼区間範囲付きプロット (右)




(a) mesh16(2018/6/4-8)




(b) mesh16(2018/6/11-15)




(c) mesh17(2018/6/4-8)




(d) mesh17(2018/6/11-15)




(e) mesh18(2018/6/4-8)




(f) mesh18(2018/6/11-15)




(g) mesh19(2018/6/4-8)



(h) mesh19(2018/6/11-15)




(i) mesh20(2018/6/4-8)




(j) mesh20(2018/6/11-15)


図 5.11 MFD の推定に用いたデータのプロット (左) と well-definedness の検証に用いたデータの信頼区間範囲付きプロット (右)




(a) mesh21(2018/6/4-8)




(b) mesh21(2018/6/11-15)




(c) mesh22(2018/6/4-8)




(d) mesh22(2018/6/11-15)




(e) mesh23(2018/6/4-8)




(f) mesh23(2018/6/11-15)




(g) mesh24(2018/6/4-8)



(h) mesh24(2018/6/11-15)




(i) mesh25(2018/6/4-8)




(j) mesh25(2018/6/11-15)

図 5.12 MFD の推定に用いたデータのプロット (左) と well-definedness の検証に用いたデータの信頼区間範囲付きプロット (右)



(a) Well-definedness のヒートマップ



(b) RMSE のヒートマップ

図 5.13 全対象メッシュのヒートマップ

5.3 本章のまとめ

本章では、ネットワークフリーデータからゾーン内部の交通状態推定に用いることができる MFD の推定手法およびその well-definedness を統計的に評価する方法論を開発した。実観測データを用いた validation では、MFD の well-definedness に影響するネットワークの特性について分析を行った。ネットワークのサイズが大きいほど、見た目や RMSE を用いた評価では MFD の well-definedness は向上しているように見えるが、観測データの統計誤差を考慮した確率論的な評価ではネットワークを広く取ることはむしろ僅かながら MFD を ill-defined に近づける結果となった。この要因として、ネットワークを広く取ることで用いる検知器数が増え、検知器間の相関が強くなることが考えられる。

MFD の見た目や RMSE による評価を用いる場合、比較的小さいサイズのゾーンや観測が疎なゾーンについては MFD が大きくばらつき、well-definedness が低いと判断される可能性があるが、本評価手法を用いた場合、2km 四方のゾーンを対象に推定した MFD についてもその well-definedness は実用性に足るものであることが示唆された。しかしながら、本研究では MFD の実用性に関して well-defined plot の割合にのみ注目しており、信頼区間の大きさについては言及していない。各プロットの信頼区間の幅が大きすぎると、対応する MFD を用いた交通状態の推定の信頼性が下がるため、信頼区間範囲の大きさも考慮した well-definedness の評価手法が求められる。

6 結論

6.1 本研究の成果と貢献

本研究は、走行軌跡データの空間情報に基づくネットワークデータの生成手法を開発し、生成されたネットワークの要素であるリンクおよびゾーンの交通状態を推定する方法論を開発した。以下、それぞれで得られた成果について整理する。

(1) 観測データ指向なネットワーク表現

従来のネットワーク表現手法が所与の詳細なネットワークデータの構造に依存していることに着眼し、その課題を緩和する方法論として、主要なノード領域の特定およびこれにより決定される空間分解能での走行軌跡データの集約を行うことで、任意の分解能のネットワークデータを生成できる方法論を示した。大規模なネットワークを対象に実観測データを用いて行った検証の結果、所与の詳細なネットワークデータに情報を紐付けたものと比較して、大幅な次元の削減に成功し、更に観測情報の適切な集約に成功していた。

(2) 走行軌跡データを用いた単路の交通状態推定

走行軌跡情報が得られたリンクの交通状態を推定する方法論として、画像処理手法とマクロ交通流理論を組み合わせた手法を開発した。これまで、走行軌跡データのみからは交通量や密度などの量的な変数を推定することが困難であったという問題点に対して、画像処理によるショックウェーブの検知、およびベイズ統計学とショックウェーブ理論を用いた推定手法により時空間的な交通状態を量的変数込みで推定する方法論を開発した。結果は、検知器により観測された真値を適切に推定できており、更に推定値の信頼区間も同時に推定した。

走行軌跡情報から作成した時空間図を用いて、画像処理技術で用いられているパターン認識手法により将来の交通状態を予測する方法論を構築した。混入率が少なく、安定しない実観測データを用いた validation では、10 分以上先の将来予測を行う場合、実務で採用されている方法論と比較してその精度が優れていたことを示した。

(3) MFD の well-definedness に関する知見

走行軌跡情報が得られたゾーンの交通状態を推定する方法論として、MFD を用いた推定手法を開発した。これまで、MFD が推定に用いることができるかどうか、つまり well-defined であるかどうかは、その形状から判断されていたが、本研究では、観測データの統計誤差に着目し、確率論的に well-definedness を判定する指標を定義した。様々なネットワークを対象に MFD を推定し、その well-definedness を評価した結果、MFD の形状のみから判断できない well-definedness に影響する要因について示唆する結果が得られた。

6.2 今後の展望

本研究の結果を踏まえ、今後の展望について整理する。

(1) 観測データ指向なネットワーク表現

走行軌跡に基づくネットワーク表現に関する課題として、本研究で構築したネットワークデータは並走路や立体交差の特定を直接的に行うことができない。しかしながら、リンク部に対応する軌跡の経路情報や走行特性を用いて判別できる可能性があるため、その拡張が考えられる、

本研究では、主要ノード領域の探索に用いた円領域のサイズは固定値を用いていたが、巨大な交差点やインターチェンジを単一のノードとして判定するためには可変型の探索領域を定義できることが望ましい。サイズの変更を含めた探索による組み合わせの急激な増加や、領域内の指標の正規化、複数の異なる交差点を含む領域を定義した場合のルール設計などが必要となることを想定した拡張が望まれる。また、本研究では交差点の位置座標を前情報として所与のネットワークデータから取得したが、走行軌跡データのみを用いた方法論への拡張が考えられる。この場合、主要ノード領域の探索に関する情報がなくなるため、空間スキャン統計等を活用した、効率的な方法論の開発が求められる。

(2) 走行軌跡データを用いた単路の交通状態推定

リンクを対象とした交通状態推定について、時空間的な交通状態の変動を記述するモデルへの拡張が考えられる。具体的には、本研究で開発した時空間的な密度の推定手法と、時空間図を用いた将来予測手法を組み合わせ、より合理的な将来予測が行える可能性がある。また、交通状態のダイナミクスを記述するマクロ交通流理論の活用により、将来予測の精度を向上させる方法論が考えられる。具体的には、交通状態

の変動を CTM などのシミュレーションモデルにより記述し，本研究で開発した観測データ指向な密度推定と組み合わせて，既存の方法論よりも精度の高いデータ同化手法を開発できる可能性がある．

(3) MFD の well-definedness に関する知見

本研究では，MFD の well-definedness へ影響を与える要因について統計誤差を考慮した評価を行なったが，これによりネットワーク表現に与える影響については考察できていない．具体的には，本研究で開発したネットワーク表現において，ゾーン部は観測が疎な軌跡を集約したものである．しかしながら，ゾーンの交通状態推定を行うためには well-defined な MFD が得られる必要があるため，ネットワーク表現におけるゾーンの構築過程において MFD の well-definedness へ影響を与える要因を考慮した条件設定を行うことが望ましい．

参考文献

- [1] Wardrop, J. G.: Road paper. some theoretical aspects of road traffic research., *Proceedings of the institution of civil engineers*, Vol.1, No.3, pp.325–362, 1952.
- [2] Beckmann, M., McGuire, C. B., and Winsten, C. B.: Studies in the economics of transportation, *New Haven: Yale University Press*, 1956.
- [3] Daganzo, C. F. and Sheffi, Y.: On stochastic models of traffic assignment, *Transportation science*, Vol.11, No.3, pp.253–274, 1977.
- [4] Daganzo, C. F.: An equilibrium algorithm for the spatial aggregation problem of traffic assignment, *Transportation Research Part B: Methodological*, Vol.14, No.3, pp.221–228, 1980.
- [5] Frank, M. and Wolfe, P.: An algorithm for quadratic programming, *Naval research logistics quarterly*, Vol.3, No.1-2, pp.95–110, 1956.
- [6] Newell, G. F.: *Traffic flow on transportation networks*, MIT Press, Cambridge, MA.
- [7] Daganzo, C. F.: Network representation, continuum approximations and a solution to the spatial aggregation problem of traffic assignment, *Transportation Research Part B: Methodological*, Vol.14, No.3, pp.229–239, 1980.
- [8] Boyles, S. D.: Bush-based sensitivity analysis for approximating subnetwork diversion, *Transportation Research Part B: Methodological*, Vol.46, No.1, pp.139–155, 2012.
- [9] Chan, Y.: A method to simplify network representation in transportation planning, *Transportation Research*, Vol.10, No.3, pp.179–191, 1976.
- [10] Hearn, D.: Practical and theoretical aspects of aggregation problems in transportation planning models, *Publication of: Elsevier Science Publishers BV*, 1984.

- [11] Wright, I., Xiang, Y., Waller, L., Cross, J., Norton, E., and Van Vliet, D.: The practical benefits of the saturn origin-based assignment algorithm and network aggregation techniques, *European Transport Conference, 2010 Association for European Transport (AET)*, Citeseer, 2010.
- [12] Wada, K., Satsukawa, K., Smith, M., and Akamatsu, T.: Network throughput under dynamic user equilibrium: Queue spillback, paradox and traffic control, *Transportation Research Part B: Methodological*, Vol.126, pp.391–413, 2019.
- [13] Connors, R. D. and Watling, D. P.: Assessing the demand vulnerability of equilibrium traffic networks via network aggregation, *Networks and Spatial Economics*, Vol.15, No.2, pp.367–395, 2015.
- [14] Casadei, G., Bertrand, V., Gouin, B., and Canudas-de Wit, C.: Aggregation and travel time calculation over large scale traffic networks: An empiric study on the grenoble city, *Transportation Research Part C: Emerging Technologies*, Vol.95, pp.713–730, 2018.
- [15] Daganzo, C. F.: Queue spillovers in transportation networks with a route choice, *Transportation Science*, Vol.32, No.1, pp.3–11, 1998.
- [16] Geroliminis, N. and Daganzo, C. F.: Existence of urban-scale macroscopic fundamental diagrams: Some experimental findings, *Transportation Research Part B: Methodological*, Vol.42, No.9, pp.759–770, 2008.
- [17] Nagle, A. S. and Gayah, V. V.: Accuracy of networkwide traffic states estimated from mobile probe data, *Transportation Research Record*, Vol.2421, No.1, pp.1–11, 2014.
- [18] Du, J., Rakha, H., and Gayah, V. V.: Deriving macroscopic fundamental diagrams from probe data: Issues and proposed solutions, *Transportation Research Part C: Emerging Technologies*, Vol.66, pp.136–149, 2016.
- [19] Leclercq, L., Chiabaut, N., and Trinquier, B.: Macroscopic fundamental diagrams: A cross-comparison of estimation methods, *Transportation Research Part B: Methodological*, Vol.62, pp.1–12, 2014.
- [20] Ambühl, L., Loder, A., Menendez, M., and Axhausen, K. W.: Empirical macroscopic fundamental diagrams: New insights from loop detector and floating car data, *TRB 96th Annual Meeting Compendium of Papers*, pp.

17-03331, Transportation Research Board, 2017.

- [21] Quddus, M. A., Ochieng, W. Y., and Noland, R. B.: Current map-matching algorithms for transport applications: State-of-the art and future research directions, *Transportation research part c: Emerging technologies*, Vol.15, No.5, pp.312–328, 2007.
- [22] Knapen, L., Bellemans, T., Janssens, D., and Wets, G.: Likelihood-based offline map matching of gps recordings using global trace information, *Transportation Research Part C: Emerging Technologies*, Vol.93, pp.13–35, 2018.
- [23] Bierlaire, M. and Frejinger, E.: Route choice modeling with network-free data, *Transportation Research Part C: Emerging Technologies*, Vol.16, No.2, pp.187–198, 2008.
- [24] Bierlaire, M., Chen, J., and Newman, J.: A probabilistic map matching method for smartphone gps data, *Transportation Research Part C: Emerging Technologies*, Vol.26, pp.78–98, 2013.
- [25] Lighthill, M. J. and Whitham, G. B.: On kinematic waves ii. a theory of traffic flow on long crowded roads, *Proceedings of the Royal Society of London. Series A. Mathematical and Physical Sciences*, Vol.229, No.1178, pp.317–345, 1955.
- [26] Richards, P. I.: Shock waves on the highway, *Operations research*, Vol.4, No.1, pp.42–51, 1956.
- [27] Newell, G. F.: A simplified theory of kinematic waves in highway traffic, part i: General theory, *Transportation Research Part B: Methodological*, Vol.27, No.4, pp.281–287, 1993.
- [28] Daganzo, C. F.: A variational formulation of kinematic waves: basic theory and complex boundary conditions, *Transportation Research Part B: Methodological*, Vol.39, No.2, pp.187–196, 2005.
- [29] Daganzo, C. F.: A variational formulation of kinematic waves: Solution methods, *Transportation Research Part B: Methodological*, Vol.39, No.10, pp.934–950, 2005.
- [30] Daganzo, C. F.: The cell transmission model: A dynamic representation of highway traffic consistent with the hydrodynamic theory. transpn. res,

Transportation Research Part B: Methodological, Vol.28, No.4, pp.269–287, 1994.

- [31] Gayah, V. V. and Dixit, V. V.: Using mobile probe data and the macroscopic fundamental diagram to estimate network densities: Tests using microsimulation, *Transportation research record*, Vol.2390, No.1, pp.76–86, 2013.
- [32] Oh, S., Byon, Y.-J., Jang, K., and Yeo, H.: Short-term travel-time prediction on highway: a review of the data-driven approach, *Transport Reviews*, Vol.35, No.1, pp.4–32, 2015.
- [33] Hunter, T., Herring, R., Abbeel, P., and Bayen, A.: Path and travel time inference from gps probe vehicle data, *NIPS Analyzing Networks and Learning with Graphs*, Vol.12, No.1, pp.2, 2009.
- [34] Hara, Y., Suzuki, J., and Kuwahara, M.: Network-wide traffic state estimation using a mixture gaussian graphical model and graphical lasso, *Transportation Research Part C: Emerging Technologies*, Vol.86, pp.622–638, 2018.
- [35] Edie, L. C.: *Discussion of traffic stream measurements and definitions*, Port of New York Authority, 1963.
- [36] Asakura, Y., Hato, E., Daito, T., and Tanabe, J.: Monitoring travel behaviour using pbs based location data, *Journal of JSCE*, Vol.2000, No.653, pp.95–104, 2000.
- [37] Von Luxburg, U.: A tutorial on spectral clustering, *Statistics and computing*, Vol.17, No.4, pp.395–416, 2007.
- [38] Herrera, J. C. and Bayen, A. M.: Incorporation of lagrangian measurements in freeway traffic state estimation, *Transportation Research Part B: Methodological*, Vol.44, No.4, pp.460–481, 2010.
- [39] Cassidy, M. J.: Bivariate relations in nearly stationary highway traffic, *Transportation Research Part B: Methodological*, Vol.32, No.1, pp.49–59, 1998.
- [40] Coifman, B.: Revisiting the empirical fundamental relationship, *Transportation Research Part B: Methodological*, Vol.68, pp.173–184, 2014.
- [41] Greenshields, B., Channing, W., Miller, H., et al.: A study of traffic capacity,

Highway research board proceedings, Vol. 1935, National Research Council (USA), Highway Research Board, 1935.

- [42] Work, D. B., Tossavainen, O.-P., Blandin, S., Bayen, A. M., Iwuchukwu, T., and Tracton, K.: An ensemble kalman filtering approach to highway traffic estimation using gps enabled mobile devices, *2008 47th IEEE Conference on Decision and Control*, pp. 5062–5068, IEEE, 2008.
- [43] Work, D. B., Blandin, S., Tossavainen, O.-P., Piccoli, B., and Bayen, A. M.: A traffic model for velocity data assimilation, *Applied Mathematics Research eXpress*, Vol.2010, No.1, pp.1–35, 2010.
- [44] Mehran, B., Kuwahara, M., and Naznin, F.: Implementing kinematic wave theory to reconstruct vehicle trajectories from fixed and probe sensor data, *Procedia-Social and Behavioral Sciences*, Vol.17, pp.247–268, 2011.
- [45] Kawasaki, Y., Hara, Y., and Kuwahara, M.: Traffic state estimation on a two-dimensional network by a state-space model, *Transportation Research Part C: Emerging Technologies*, 2019.
- [46] Seo, T., Kusakabe, T., and Asakura, Y.: Estimation of flow and density using probe vehicles with spacing measurement equipment, *Transportation Research Part C: Emerging Technologies*, Vol.53, pp.134–150, 2015.
- [47] Wong, W., Shen, S., Zhao, Y., and Liu, H. X.: On the estimation of connected vehicle penetration rate based on single-source connected vehicle data, *Transportation Research Part B: Methodological*, Vol.126, pp.169–191, 2019.
- [48] Van Lint, J. and Hoogendoorn, S. P.: A robust and efficient method for fusing heterogeneous data from traffic sensors on freeways, *Computer-Aided Civil and Infrastructure Engineering*, Vol.25, No.8, pp.596–612, 2010.
- [49] Treiber, M., Kesting, A., and Wilson, R. E.: Reconstructing the traffic state by fusion of heterogeneous data, *Computer-Aided Civil and Infrastructure Engineering*, Vol.26, No.6, pp.408–419, 2011.
- [50] Anuar, K. and Cetin, M.: Estimating freeway traffic volume using shock-waves and probe vehicle trajectory data, *Transportation research proceedings*, Vol.22, pp.183–192, 2017.
- [51] Wang, S., Huang, W., and Lo, H. K.: Traffic parameters estimation for

signalized intersections based on combined shockwave analysis and bayesian network, *Transportation research part C: emerging technologies*, Vol.104, pp.22–37, 2019.

- [52] Seo, T., Kawasaki, Y., Kusakabe, T., and Asakura, Y.: Fundamental diagram estimation by using trajectories of probe vehicles, *Transportation Research Part B: Methodological*, Vol.122, pp.40–56, 2019.
- [53] Daganzo, C. F.: A variational formulation of kinematic waves: basic theory and complex boundary conditions, *Transportation Research Part B: Methodological*, Vol.39, No.2, pp.187–196, 2005.
- [54] Daganzo, C. F.: A variational formulation of kinematic waves: Solution methods, *Transportation Research Part B: Methodological*, Vol.39, No.10, pp.934–950, 2005.
- [55] Vincent, O. R., Folorunso, O., et al.: A descriptive algorithm for sobel image edge detection, *Proceedings of Informing Science & IT Education Conference (InSITE)*, Vol. 40, pp. 97–107, Informing Science Institute California, 2009.
- [56] Ma, X., Dai, Z., He, Z., Ma, J., Wang, Y., and Wang, Y.: Learning traffic as images: a deep convolutional neural network for large-scale transportation network speed prediction, *Sensors*, Vol.17, No.4, pp.818, 2017.
- [57] Zhang, Z., Wang, Y., Chen, P., He, Z., and Yu, G.: Probe data-driven travel time forecasting for urban expressways by matching similar spatiotemporal traffic patterns, *Transportation Research Part C: Emerging Technologies*, Vol.85, pp.476–493, 2017.
- [58] Haralick, R. M., Shanmugam, K., and Dinstein, I. H.: Textural features for image classification, *IEEE Transactions on systems, man, and cybernetics*, No.6, pp.610–621, 1973.
- [59] Refaeilzadeh P., Tang L., Liu H.: *Cross-Validation*, pp. 532–538, Springer US, Boston, MA, 2009.
- [60] Buisson, C. and Ladier, C.: Exploring the impact of homogeneity of traffic measurements on the existence of macroscopic fundamental diagrams, *Transportation Research Record*, Vol.2124, No.1, pp.127–136, 2009.
- [61] Geroliminis, N. and Sun, J.: Hysteresis phenomena of a macroscopic fun-

damental diagram in freeway networks, *Procedia-Social and Behavioral Sciences*, Vol.17, pp.213–228, 2011.

- [62] Saberi, M. and Mahmassani, H. S.: Exploring properties of networkwide flow–density relations in a freeway network, *Transportation research record*, Vol.2315, No.1, pp.153–163, 2012.
- [63] Daganzo, C. F. and Geroliminis, N.: An analytical approximation for the macroscopic fundamental diagram of urban traffic, *Transportation Research Part B: Methodological*, Vol.42, No.9, pp.771–781, 2008.
- [64] Wand, P. F., Wada, K., Akamatsu, T., and Hara, Y.: An empirical analysis of macroscopic fundamental diagrams for sendai road networks, *Interdisciplinary Information Sciences*, Vol.21, No.1, pp.49–61, 2015.

謝辞

本研究の遂行にあたり、多くの方々からご指導、ご協力を頂きました。ここに感謝の意を表します。

東北大学の井料隆雅教授には、専門分野に関わる学術的な知識だけでなく、研究に取り組む姿勢や遵守すべき倫理観、そして教育者としての心構え等について幅広くご指導をいただきました。井料先生が幾つもの魅力的な研究を絶えず実施されていたことは、私の博士後期課程進学の強い後押しとなりました。改めて御礼申し上げます。

神戸大学の小池淳司教授には、突発的な事態に関わらず本研究の主査を快くお引き受けいただきました。研究内容について発表させていただく機会では、研究の目的に対する方法論の曖昧な箇所や考えを深めるべきポイントについて適切にご助言いただきました。また本研究について、空間情報の活用の観点から交通のみならず多様な分野への発展可能性を示唆いただきました。芥川真一教授には、博士後期課程入学時の試験官および本論文の副査として、私の研究課題に対する重要な問いかけをいただきました。特に、防災の観点から捉えた現状の観測データの活用可能性や、今後の交通系観測データに関わる研究に期待する点についてのご意見は、私の今後のリサーチクエスチョンを整理する上で貴重なものとなりました。瀬谷創准教授には、空間情報および統計学的な観点から様々なご指導をいただきました。また研究だけでなく、私の能力に見合ったデータ分析大会の幹旋や、将来のキャリアプランに資するご助言をいただくなど、普段から気にかけていただきました。

東京工業大学の朝倉康夫教授には、交通工学的な観点から既存の方法論と比較した本研究のアピールポイントについて、私の発想になかったものを数多く示していただきました。特に本研究の核となるネットワーク表現に関しては、朝倉先生の研究室へ長期滞在させていただき、中西航助教を含めて多面的な観点から議論させていただきました。

本研究のうち交通状態推定に関わる一部の方法論の開発は、東京大学への滞在時に行われたものです。その際、研究室への滞在を快く受け入れてくださった清水英範教授、布施孝志教授、瀬尾亨助教に深く感謝申し上げます。特に瀬尾先生には、交通流理論に基づく推定手法の開発において多様なアイデアをご提供いただいただけでなく、論文執筆において必要となる技術等について、一つ一つ丁寧にご指導いただきました。本滞在において、羽藤英二教授がこまめにコミュニケーションを取ってくだ

さったことは、私にとって非常に有益なことでした。どのような場所でも、いついかなる時も好んで研究の話をされる羽藤先生と一緒に時間を過ごせたことで、私自身これからも楽しんで研究を続けていけるように感じました。また些細な話から本研究を進展させるヒントをいただくこともできました。

博士後期課程に進んだ当初、研究者を目指す上で右も左もわからない状態だった私にとって、東京大学の浦田淳司助教が身近にいたことは非常に幸運でした。浦田先生からいただいたご助言が的中し、従って良かった（または従っていれば良かった）と感じたことは数えきれません。National Taiwan University の坂井勝哉助教には、その親しみやすさから、研究や業界に関する素朴な疑問を気軽に聞き出すことができました。また国際学会や海外での滞在の度同行してくださり、私が積極的に質問するようノルマを設定されるなど色々と面倒を見ていただきました。学会発表や勉強会等でお世話になった全ての方のお名前や内容をここで挙げることはできませんが、愛媛大学の吉井稔雄教授、金沢大学の中山晶一郎教授、高山雄貴准教授、山口裕通助教、岐阜大学の倉内文孝教授、高知工科大学の西内裕晶准教授、神戸大学の織田澤利守准教授、筑波大学の和田健太郎准教授、東京大学の福田大輔教授、日下部貴彦講師、原祐輔氏、東京都立大学の柳原正実助教、東京理科大学の柳沼秀樹講師、東北大学の桑原雅夫教授、長江剛志准教授、水谷大二郎助教、佐津川功季助教、鳥取大学の桑野将司教授、広島大学の力石真准教授、立命館大学の塩見康博准教授には、それぞれ勉強の機会を設けてくださったこと、難しい内容の講義を非常にわかりやすく解説してくださったこと、私の研究について有用なご指摘・ご意見をくださったこと等、感謝しなければならないことばかりです。この場をお借りして改めて御礼申し上げます。また、日々の事務処理や学生生活を送る上で、吉川昭子氏には数えきれないほどお世話になりました。

本研究を進める上で使用した観測データは、主に国土交通省 国土技術政策総合研究所および阪神高速道路株式会社から貸与いただきました。第3章と第5章の研究内容は、国土交通省「道路政策の質の向上に資する技術研究開発」における研究「蓄積車両軌跡データの効率的活用のための階層型データベースの構築」（代表：井料隆雅）の一部として実施されたものです。また、第4章で用いた車両走行軌跡データおよび車両検知器データは、阪神高速道路株式会社より貸与いただいたものです。本研究は観測データなくしては実施不可能であるため、みなさまに心から御礼申し上げます。

最後に、本研究に携わった全ての方々に感謝の意を表し、本論文の締めくくりとさせていただきます。

令和2年7月16日
安田昌平

神戸大学博士論文

「車両走行軌跡データを用いた大規模ネットワークの交通状態推定手法」

全 123 頁

提出日 2020 年 7 月 16 日

© 安田 昌平

本論文の内容の一部あるいは全部を

無断で複製・転載・翻訳することを禁じます。