



道路政策の質の向上に資する技術研究開発
成果報告レポート
No. 30-3

研究テーマ

学習型モニタリング・交通流動予測に基づく
観光渋滞マネジメントについての研究開発

研究代表者：東京大学教授	布施 孝志
共同研究者：東京大学教授	福田 大輔
熊本大学准教授	円山 琢也
東京大学教授	市村 強
統計数理研究所助教	村上 大輔
東京工業大学准教授	瀬尾 亨
地域未来研究所	田名部 淳

令和3年6月

新道路技術会議

目次

研究概要（様式3）	1
第1章 はじめに	3
第2章 学習型モニタリング手法の開発	4
2.1 学習型モニタリングに関するレビュー	4
2.2 車・人の認識・追跡の学習型モデルの開発	7
2.3 車・人の認識・追跡の学習型モデルの検証	12
第3章 学習型交通状態予測手法の開発	17
3.1 AIを活用した車・人の交通流動予測に関するレビュー	17
3.2 短期交通量予測モデル	18
3.3 予測性能の検証	20
3.4 予測の時間解像度と予測範囲の検討	22
第4章 交通流動マネジメント手法の開発	24
4.1 交通流動マネジメントに関するレビュー	24
4.2 ベース課金の設定方法の構築と鎌倉市内での試算	27
4.3 リアルタイム観測情報に基づく課金の調整方法の検討	30
4.4 強化学習による動的混雑課金手法の実験経済学的検証	32
第5章 解析基盤の開発	35
5.1 異種情報を融合した交通状態補間手法の検討	35
5.2 解析基盤へのデータ同化の導入と深層学習による大規模解析に基づく 最適化手法の開発	38
第6章 まとめ	41
参考文献	43

「道路政策の質の向上に資する技術研究開発」（平成30年度採択）
研究概要

番号	研究課題名	研究代表者
No.30-3	学習型モニタリング・交通流動予測に基づく観光渋滞マネジメントについての研究開発	東京大学 教授 布施 孝志

観光渋滞エリア内の交通流動の改善を実現するため、学習型の交通状態モニタリング・予測手法、および適応型交通需要マネジメントに関する開発を研究目的として、観光交通イノベーション地域等でのデータに適用し実効性の確認実施する研究開発。

1. 研究の背景・目的

道路を賢く使うためには、適切なモニタリング、交通流動予測に基づくエリア内の交通流動マネジメントが重要である。特に、交通の非定常性、季節、イベント等に応じた大きな変動特性を考慮しなければならない観光渋滞については、モニタリング、交通流動予測に基づく交通流動マネジメントが効果的である。

近年、カメラ等を用いた定点型観測データ、GPS等を用いた移動型観測データ等のビッグデータが取得されている。また、AIに代表される学習手法が開発されつつあり、ビッグデータや学習型手法を活用した高精度なモニタリング手法や交通状態予測を用いた道路交通マネジメントが期待される。さらに、モニタリング・交通状態予測から道路交通マネジメントへの一貫した方法論やそれに基づいた社会実装の確立が求められている。

本研究は、観光渋滞対策を目的とした効率的、かつ効果的な交通渋滞対策の検討に資する学習型モニタリングシステムの構築、交通状態予測システムの構築、およびモニタリング・予測に基づくエリア内の交通流動マネジメントスキームの構築を行うものである。

2. 研究内容

まず、研究の全体像を図1に示す。テーマ1において各種データから車・人の動きを認識する学習型モニタリングシステムを構築する。これにより交通状態の現状値の推定が可能になる。この結果から、テーマ2で学習型の交通状態予測システムを構築する。特に短期予測を行うものである。テーマ1, 2を受け、テーマ3では、エリア内の交通流動マネジメントスキームを構築する。これらのテーマ間を連携させるため、テーマ4において連携のための基盤技術を開発する。




図1 研究の全体像

3. 研究成果

テーマ1：学習型モニタリングシステムの構築

定点カメラ、GNSS、Wi-fi、衛星を対象として、データ同化に基づく統一のアプローチによるモデル開発を行った。定点カメラによる車・人の認識・追跡に対して、深層学習を導入したモデルを開発し、物体数・追跡の同時推定手法への拡張を行った。また、GNSSとWi-fiデータを統合し、保存則に基づくメッシュ単位での滞在人数・移動人数の同時推定モデルを開発した(図2)。さらに、超小型衛星を見据え、深層学習による車両密度推定手法、高分解能・高画質化手法の開発を行った。

テーマ2：交通状態予測システムの構築

車両の時間的な集中度合いを短期(30~90分後)で予測するための深層学習による分析枠組みを構築した。交通量等のデータは、時間方向に強




図2 鎌倉での推定

い依存性を持つ時系列データであるため、深層学習において時系列データの予測に適しているモデルである LSTM をベースとした。実データに対して、季節ごとに設定したモデルの予測精度、降水量や社会イベントの影響、混雑時期の予測精度に関して検証を行い、車両流入が多い時間帯において、誤差率が低くなることを確認した。

テーマ3：モニタリング・予測に基づくエリア内交通流動マネジメントスキームの構築

テーマ1, 2を考慮した動的課金の枠組みを整理し、基本トレンド（季節、平休日、時間帯等）に基づくベース課金と、リアルタイム観測情報に基づく課金調整の手法を開発した。トレンド・ベース課金においては、時間帯別需要変動型利用者均衡配分によるモデルを開発した。鎌倉市内へのコードン課金施策を対象とした試算結果から有用な知見を得た。また、リアルタイム観測情報による課金調整においては、トライ&エラーによる課金調整に対して強化学習を導入した手法を開発した。実験経済学の枠組みによる実験を実施し、個人の行動変容を分析した。

テーマ4：テーマ間連携のための基盤技術の開発

テーマ間の連携を強化するため、特性が異なる、あるいは、観測データが得られない部分に対して、任意リンクにおける補間をするための動的時空間モデルを開発した。さらに、モニタリング、予測、補間において得られるリンク上での交通状態から、リアルタイムに個別車両の行動等を推定する手法を開発した。ここでは、データ同化の導入を進め、観測データとシミュレーションの差異を効率的に解消するための深層学習を用いた大規模解析に基づく最適化手法を開発した。開発手法を、OD逆推定問題に対して適用し、手法の有効性を確認した。

4. 主な発表論文

- (1) Sakai, K., Seo, T., Fuse, T.: Traffic density estimation method from small satellite imagery: Towards frequent remote sensing of car traffic. IEEE 22nd International Conference on Intelligent Transportation Systems, pp.1776-1781, Auckland, New Zealand, 2019.
- (2) Qian, Q., Fukuda, D., Han, K. and Song, W.: Reservoir-based surrogate modeling of dynamic user equilibrium. The 23rd International Symposium on Transportation and Traffic Theory (ISTTT23), Lausanne, 2019.
- (3) Murakami, D. and Griffith, D.A.: A precompression approach for fast spatial mixed effects modeling. Spatial Statistics 2019, Sitges, Spain, 2019.
- (4) Ichimura, T., Fujita, K., Yamaguchi, T., Hori, M., Wijerathne, L., Ueda, N.: Fast multi-step optimization with deep learning for data-centric supercomputing, 4th International Conference on High Performance Compilation, Computing and Communications, 2020.
- (5) Sato, K., Seo, T., Fuse, T.: A reinforcement learning-based dynamic congestion pricing method for the morning commute problems, Transportation Research Procedia, Vol.52, pp.347-355, 2021.

5. 今後の展望

各テーマにおいて、学習型手法として開発を行ってきた。いずれも、学習データを確保することが必要になるため、その方法論を検討することも重要になる。また、深層学習一般の問題として、解釈困難性が存在する。この問題に対して、説明可能な AI 手法を導入することにより、モデルと結果の解釈を可能にすることが期待される。また、説明変数の自動選択の仕組みを導入し、解釈と推定精度の両者を向上するための拡張が考えられる。また、他都市への展開も考えられる。

6. 道路政策の質の向上への寄与

本研究の成果は汎用性を有するものである。さらなる精度向上・安定化・高速化により、その利用可能性が益々高まることが期待される。観測機器のスペック等を特定するための知見も有用となる。また、短期予測の困難さも指摘されているところであるが、より現実に即した予測手法として活用が期待できる。トレンド・ベース課金では政策に資する知見が得られている。また、トライ&エラー課金により混雑解消が確認でき、こちらも実務に資する内容と考えられる。

7. ホームページ等

なし

第1章 はじめに

道路を賢く使うためには、適切なモニタリング、交通状態予測に基づくエリア内の交通流動マネジメントが重要である。特に、交通の非定常性、季節、イベント等に応じた大きな変動特性を考慮しなければならない観光渋滞については、モニタリング、交通流動予測に基づく交通流動マネジメントが効果的である。

近年、カメラ等を用いた定点型観測データ、GPS等を用いた移動型観測データ等のビッグデータが取得されている。また、AIに代表される学習手法が開発されつつあり、ビッグデータや学習型手法を活用した高精度なモニタリング手法や交通状態予測を用いた道路交通マネジメントが期待される。さらに、モニタリング・交通状態予測から道路交通マネジメントへの一貫した方法論やそれに基づいた社会実装の確立が求められている。

本研究は、観光渋滞対策を目的とした効率的、かつ効果的な交通渋滞対策の検討に資する学習型モニタリングシステムの構築、交通状態予測システムの構築、およびモニタリング・予測に基づくエリア内の交通流動マネジメントスキームの構築を行うものである。また、提案手

法を観光交通イノベーション地域等でのデータに適用し実効性を確認する。

研究の全体像を図-1に示す。

- ・テーマ1: 学習型モニタリングシステムの構築
 定点型・移動型観測データによる車・人の認識や交通状態モニタリングの手法を開発し、それらを統合したモニタリングシステムを構築する。さらに予測システムとの連携を図る。
- ・テーマ2: 交通状態予測システムの構築
 モニタリングシステムで得られたデータを活用して、エリア内における車・人の交通状態・渋滞発生を予測する機械学習ベースの交通行動モデルを構築する。
- ・テーマ3: モニタリング・予測に基づくエリア内の交通流動マネジメントスキームの構築
 前2テーマを踏まえつつ、旅行時間や交通量等のモニタリング情報と予測を考慮し、課金制度等の適応型エリア内交通流動マネジメントのためのスキームを検討する。
- ・テーマ4: テーマ間連携のための基盤技術開発
 各テーマで得られる異種情報を融合し交通状態補間手法を開発するとともに、全テーマを包括的に検討するための解析基盤を開発する。

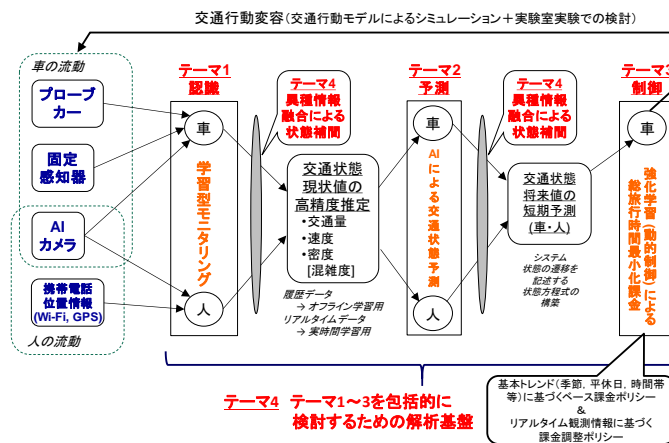


図-1 研究の全体像

第2章 学習型モニタリング手法の開発

2.1 学習型モニタリングに関するレビュー

速度や混雑状況といった交通状態の把握は、交通マネジメントや道路政策上重要な問題として取り組まれてきており、様々な手法が研究されてきた。例えば、Seoら¹⁾は高速道路上の交通状態推定手法について学術的研究の調査結果がまとめられている。広域での道路交通を知る手段として、道路交通センサがある。道路交通センサは地点ごとの交通流の把握、あるいは道路交通の発着地の把握によりなされる。この調査は人の手による抽出調査であり、対象となる日・時間帯・場所のいずれも網羅できていない。速度や混雑状況といった交通状態の把握は、交通マネジメントや道路政策上重要な問題として取り組まれてきており、様々な手法が研究されてきた。現在主流となっている交通状態モニタリングでは感知器が使われる。トラフィックカウンター（以下、トラカンとする。）は超音波などにより通過する車両の台数や車種を観測できる機器である。トラカンは24時間365日の観測が可能であり、時間の面では網羅的である。しかし感知器による観測は、設置地点以外の情報を得ることができない。トラカンは非常に高価であり、設置できる数には限りがあるため、空間的にも網羅的なモニタリングを行うには十分でない。

一方、近年は、モニタリング技術の発展により、新たな観測手法が登場してきている。これらは、特に、定点観測、移動体観測、リモートセンシングに大別される。定点観測においては、従来からのトラカンに対して、固定カメラによる観測により、軌跡等の詳細な情報取得が期待されている。移動体観測では、近年発展・普及の目覚ましいGNSS（Global Navigation Satellite System, GPS等の衛星測位システムの総称）や

Wi-Fi等の利用が挙げられる。これは、サンプリングデータであるものの、広域な観測を可能にしている。また、リモートセンシングに関しては、今後の超小型衛星の打ち上げに対して、交通モニタリングへの応用が期待され始めたところである。これらのデータ収集手法の模式図を図-2に示す。本研究では、特に着目に値する上記観測手法についてレビューを行った。

(1) 定点カメラによるモニタリング

定点カメラによる観測は、動画像からの物体追跡手法に行われる。物体追跡手法は大きく2種類に分けることができる。1つ目は各時刻において物体抽出を行った結果を対応付けることで軌跡を取得する方法である。2つ目はある時刻における物体抽出結果をもとに、次の時刻におけるその物体の位置を探索する方法である。この両方に共通する点は、同一物体であることを判断するマッチング手法を必要とすることである。これらは、画素値の分布・勾配やエッジ等に代表される画像特徴量の類似度に基づくものである²⁾。その代表的な手法の一つとして、空間整合性を用いたLucas-Kanadeアルゴリズム³⁾が基礎手法として知られている。しかしながら、この手法や派生手法は単位時刻間

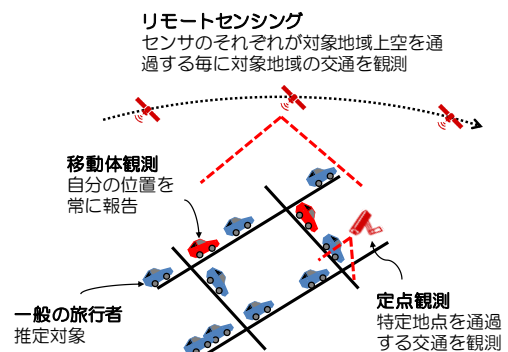


図-2 交通データ収集に用いられる様々な手法

における対象の輝度の不変性を仮定していることなどから、オクルージョン（物体同士の重なりによる隠れ）への対応が難しいという課題を持つ。また、対象物体が剛体ではない人物の追跡では、色や距離を用いて人物を3次元楕円体ととらえる方法⁴⁾や2次元において色情報のみから頭部・胴部・足部をそれぞれモデルする方法が存在する^{5), 6)}。

上記の方法に対して、物体の挙動モデルをデータ同化により組み合わせた手法が、大きく注目を集めている。データ同化はシミュレーションによる予測と観測で得られるデータを統合するものであり、物体追跡手法においても高い適用可能性が示されている。歩行者に適用した例としては、布施・中西⁷⁾の研究が挙げられる。この研究では、離散選択モデルによる歩行者挙動モデルをシステムモデルとし、色情報を用いたBhattacharyya係数（色のヒストグラムの相関）と距離情報を併用した観測モデルを提案している。また、小林ら⁸⁾は視野を共有していないカメラを用いて、カメラ間の視野外エリアまでも含めた軌跡を推定する手法を提案している。

これらのデータ同化手法は状態ベクトルを追跡物体の位置とし、単物体を追跡する枠組みとして用いられることが多い。複数物体の追跡に適用する場合、対象を検出できない場合や偽の検出をしてしまう場合等を考慮するため、ランダム有限集合の枠組みを用いたPHD (Probability Hypothesis Density : 確率仮説密度) に基づく手法が考案された⁹⁾。PHDとは推定すべき事後分布の1次モーメントで近似した分布であり、ある領域でPHDを積分した結果がその領域内に存在する対象数の期待値となる分布である。また、Voら¹⁰⁾はPHDフィルタを逐次モンテカルロ法の枠組みで実装する手法を提案している。その後、Risticら¹¹⁾はそのアルゴリズムを改善し、新規出現と残存を区別可能にしている。

一方、近年では、物体認識手法の中でも高い精度を誇る深層学習とそれを用いた物体認識・追跡手法が多数開発されている。深層学習は機械学習手法の1つである。基本構造として多層のニューラルネットワークを有するため、非線形性をもつ問題に柔軟に対応可能である。また、大量の教師データに基づく学習を通して、タスクのための特徴量を自動抽出することを可能にした。主にこの2点により、認識問題等でも高い精度を実現することができる。このような手法が近年になって幅広い分野で注目されるようになった要因としては大きく3つが挙げられる。1つ目はGPUやメモリなどハードウェアの

進歩である。2つ目は学習を行うために必要である大量のデータが手に入りやすくなったことである。3つ目には過学習を抑制するドロップアウトなどの方法や、学習をうまく収束させるような活性化関数、転移学習¹²⁾といった事前学習法など、深層学習を構成する各要素の工夫が充実してきたことが挙げられる。特に画像解析においては、CNN (Convolutional Neural Network : 畳み込みニューラルネットワーク) が、現在でもトップレベルの認識性能を誇っている。CNNは入力層、畳み込み層、プーリング層、全結合層の4種の層から構成されているものである。CNNでは、入力層に近い特徴量ほど位置情報を保持し、出力層に近い層ほど物体全体の特徴を有すると考えられ、これらを組み合わせた物体追跡手法も提案されている¹³⁾。また、時刻間の相関フィルタに着目し、オンライン学習により逐次更新して追跡を行う手法も提案されている¹⁴⁾。

(2) 移動体観測によるモニタリング

近年では走行中の車両の一部をプローブカーとして軌跡や通過時刻などの情報を得られるようになってきた。プローブカーは、道路ネットワーク上を走っている車の中に混入し、自車位置等の情報を定期的に報告する。プローブの情報収集はこれまでは一部の車載GPSやスマートフォンの情報を特定目的で収集してなされていたが、一般の目的のためにネットワーク接続がされたコネクティッドカーでは、よりリアルタイムかつ大量、広範囲にわたる観測も期待される。特にコネクティッドカーは今後自動運転が普及に近づく中で増加が予想され、2025年には日本国内において950万台を超えるとの予測もある。このようなプローブカーによる移動体観測は、感知器による観測と異なり、プローブカーが走行すればどの区間でも情報を得られる。プローブデータのさらなる利用可能性向上を見越した手法も提案されている。しかし、ここで想定されているのは自動運転の普及を加味したより発展的なプローブ情報である。このようなプローブデータの収集は現在のところ難しく、軌跡情報のような収集しやすい情報単独では交通状態を推定するに至っていない。他に提案されている手法でも、プローブ軌跡以外の観測手段に依存している。プローブデータと地点感知器データを合わせて用いることで、高速道路上の動的な交通状態を推定している手法も提案されている。同手法においては感知器が既に存在していることを前提としており、

やはりその設置・維持コストの負担は免れない。

一方、スマートフォン等の携帯端末の普及により、モードの推定には難があるものの、人物の移動を把握することが可能になってきた。携帯端末を用いたプローブパーソン調査も行われてきている。携帯電話の基地局は、携帯端末の接続のため、定期的に携帯端末と基地局の間で交信をしている。この交信の履歴情報をもとに人の移動を把握するものが携帯電話基地局データである。従来のGPSとの併用により、その有効性が高まっている。携帯端末に搭載されているGPS受信機の精度は、数mから百mほどといわれており、比較的高分解能な軌跡情報が取得できる。しかし、GPSデータはデータ取得可能の割合が低いことが問題点である。位置情報の利用に対する意識調査¹⁵⁾によれば、携帯端末の位置情報をONにしている人は端末所持者の22.1%となっている。また、GPS位置情報はアプリケーションの利用時に個別に情報提供を承認しているため、実際に取得できるGPSデータ数は上述の割合よりもさらに少ないとされる。

無線LANによるインターネット接続のためのWi-Fiも交通データ取得の可能性のある技術と考えられる。例えば、流動人口データの取得に使用されるWi-Fiは、携帯端末が公共施設や商業施設を中心に設置されているWi-Fiアクセスポイントと交信した記録を利用したものである。

上記の技術を用いた滞在人口や移動人口について整理する。携帯電話基地局データを用いたモバイル空間統計（NTTドコモ）は、国内で用いられている商用データとして代表的なものである。携帯電話利用者のデータから全人口の値に拡大する際には、携帯電話の端末に記録されている利用者の属性データを用い、それを国勢調査のデータを参考にして、層別に拡大処理している¹⁶⁾。この情報を用いると、複数の基地局で同一端末が時系列的に観測されることによって、移動軌跡と移動速度の概略も把握できる。しかし、基地局単位よりも小さな空間内の移動を推定することはできないという特徴がある¹⁷⁾。

GPSデータを用いた推計は数多く行われており、すでに実用化されているものもある。例えば、株式会社ゼンリンデータコム「混雑統計」や、Agoop社が手掛けるスマートフォン向けアプリケーション「混雑マップ」などが存在する。非集計データとして移動軌跡がわかるため、PTデータと組み合わせることで移動人口分布を推定している研究も存在する。このようにGPS

データは容易に取得できることや移動の軌跡情報がわかることから広く利用されているデータだが、GPSデータは全人口に対して観測される割合が少ない。したがって、GPSデータのみを用いた流動人口分布推定は現実の人口分布を必ずしも表したものであるとは限らない。

Wi-Fiデータの特徴は、アクセスポイントがあれば屋内や地下でも人物位置を観測できる点である。Schauerら¹⁸⁾や森本ら¹⁹⁾は、建物内に置いた複数のアクセスポイント（パケットセンサ）で入手した人物位置情報から人物分布を推定している。また、複数地点にWi-Fiパケットセンサを設置することによって、同一携帯端末の情報を複数個所で取得でき、この時系列データを用いて人物の移動を推定した研究もある²⁰⁾。

また、プライバシー保護の観点から、滞在人数分布の集計データを用いて、移動人数を推定した研究例も存在する。Iwataら²¹⁾は、メッシュごとに集計した滞在人数データを用いて移動人数を推計している。本論文では、1日の中で時間帯をその時間による活動のパターンからクラスターに分ける。各時刻のクラスター内の各セルから隣接セルへの移動確率を表すパラメータを与え、集計データである人数からその移動人口を推定する。Akagiら²²⁾は、同様の考え方に基づき、隣接セル以外への拡張を行った。

(3) リモートセンシングによるモニタリング

前項で見た通り、プローブ軌跡情報は速度情報を得ることはできるが、密度を得ることができない。速度と密度の間には流率密度関係が存在するが、この関係は線形などの条件によって場所により異なる。軌跡から流率密度関係を推定するには、渋滞密度や流率密度関係の関数形の仮定が必要となるため、単純に速度から密度を推定することは難しい。プローブ情報単独での推定が困難なのはこのためであり、別に車両密度の情報を得る必要がある。衛星画像を用いると、広範囲の分布を把握できる。これを用いた車両密度は十分実現可能であるといえる。

交通流推定における車両密度は流率密度関係と密接な関係を持つ。越らの研究²³⁾をみると、流率密度関係は概ね40台/kmで臨界密度となり、渋滞密度は120台/km程度となる。これは高速道路上の値であるため、一般道ではやや異なる値を取ると考えられるが、それでも一般的な車両の長さを考慮すると渋滞密度は200台/kmに満たないと思われる。この範囲で意義ある推定をするのであれば、混雑の大まかな程度を把握するには20台/km、交通量や流速等のさらに詳し

い情報を得るには5台/km程度の精度が求められる。

瀬尾らの研究²⁴⁾によれば、プローブ軌跡に加え、小型衛星画像により道路上の車両密度を推定することができれば、交通状態の推定が可能である。具体的には、プローブ軌跡から平均速度および分岐率を、これに車両密度情報を組み合わせることでプローブの混入率と渋滞密度を、それぞれ推定できる。これらの値から流率密度関係を得て、データ同化により交通流モニタリングが可能となる。

初期の地球観測衛星の重量は数百kg程度であったが、時代が進み、高機能化が求められた結果、人工衛星は大型化していった。大型衛星は安定した姿勢制御や高精度の観測ができ、質の高い衛星画像を得られる。ところが、衛星は大きくなると製造・打ち上げ費用が高額になり、開発にかかる期間も長期化してしまう。その結果、運用数の増加が難しい。数少ない衛星で観測を行う場合、観測周期が大きくなってしまふ。質が高い反面、入手できるタイミングが限られてしまうのが大型衛星の衛星画像の問題点であった。小型衛星は、人工衛星が技術の発達に伴い高機能化・大型化していくのに対して、機能を追求せずに小さく、軽く、安くの三点を求め開発されるようになってきた。国内でも企業や大学の研究室といった単位で超小型衛星の開発・運用が取り組まれており、いわゆる「ほどよしプロジェクト」や「UNIFORM プロジェクト」がその例である。小型衛星は開発費用自体も安価であり、小型・軽量であるために打ち上げの際の複数相乗りが可能で、同時に複数を宇宙空間に送り届けられる。この利点を活かしてコンステレーション運用を実施すれば、衛星画像をこれまでより高い頻度で入手できると期待される。しかし、地上分解能を高くするには、望遠鏡の口径を大きく取ったうえで、焦点距離を確保しなければならないが、小型衛星では大きさの制約からこれらを十分にとれない。地上分解能と衛星の重量はトレードオフの関係にある。

従来から、大型衛星を想定した高分解能衛星画像を対象とした物体検出の研究はなされている。それらの手法の多くは、車両一台一台を検出するものである。そのため、小型衛星の低解像度画像に対しては適用困難である。しかし、交通マネジメント上は必ずしも個々の車両一台一台を検出する必要は無く、巨視的な交通状態量（例：車両密度）を推定すれば十分といえる。こうした条件を加味すると、小型衛星画像

を用いた交通状態推定の実現可能性は高いといえる。前述の通り、衛星画像に基づく画像解析に用いられる手法としては、CNNが非常に有力である。Zhangら²⁵⁾は、リモートセンシングについて画像処理、画素分類、物体認識、シーン理解の四つの観点を挙げて、物体認識とシーン理解で深層学習が強みを発揮していると述べている。

2.2 車・人の認識・追跡の学習型モデルの開発

前節でのレビューに基づき、観測手法別にみたデータ特性の整理を行った。整理結果に基づき、活用するモニタリングデータ（機器）を、定点カメラ画像（一般的なビデオカメラ）、GNSS・Wi-Fiデータ（携帯端末搭載のGNSS・Wi-Fi）、衛星画像（小型衛星搭載の静止カメラ）に特定した。定点カメラ画像は、画像解析により車・人の詳細な移動軌跡を取得できることが特徴である。GPS・Wi-Fiは、スマートフォンの普及により大量データを収集できる特徴を有する。また、衛星画像は、今後多数の超小型衛星の打ち上げが計画されており、将来高頻度観測が可能になることが期待される。いずれの観測手法も、センサの測定データからの交通状態量の抽出が必要になる。このためには、確率統計・機械学習と交通工学の理論を活かす方法論が有望と考えられる。また、単一の観測手法のみによる常時・広範囲の交通状態観測は困難であることから、異なる観測手法を組み合わせるデータ融合が有望である。以上から、すべての観測手法に対してデータ同化に基づく統一的アプローチによるモデル開発を行った。

データ同化においては、状態が時々刻々変化し、観測データが時系列で得られることを前提としており、それらの関係をモデル化し、時系列解析手法に基づき、状態を推定する。状態や観測データの関係は、一般状態空間モデル²⁶⁾により表現することができる。一般状態空間モデルは状態ベクトルと観測ベクトルとから構成される。状態ベクトルは、直接観測できない、あるいは推定したい変数のベクトルであり、観測ベクトルは、センサにより観測した変数のベクトルである。状態ベクトルを隠れ変数として導入することにより、一般状態空間モデルとしての表現力が向上している。また、観測ベクトルは異種データごとに分割して利用することも可能である。ベクトル間の関係性は、条件付き分布としてモデル化できる。状態ベクトルと

観測ベクトルとの関係を表したモデルを観測モデルと呼び、状態ベクトルの時間推移を表したモデルをシステムモデルと呼ぶ。時刻1から t までの観測ベクトルが得られたときに、時刻 t における状態ベクトルを事後確率最大化基準（あるいは期待値）により推定する。事後確率は、ベイズの法則より計算することができる。一般状態空間モデルの典型例は、逐次ベイズフィルタであり²⁷⁾、システムモデルに基づき予測を行い、観測モデルに基づきフィルタリングを行うものである。これらの変数やモデルを、対象とする状態や観測データに応じて定義やモデル化すれば、一般状態空間モデルの枠組みは変更することなく利用できる。

一般状態空間モデルの構成要素である、状態ベクトルと観測ベクトルを定義、システムモデルと観測モデルを定式化すれば、状態推定が可能になる。本章では、その一般的手法について触れる。システムモデル、観測モデルがともに線形であり、両ノイズもガウス分布で表現できる場合には、カルマンフィルタにより、解析的に状態推定を行うことができる。カルマンフィルタにおいては、予測を行った後、観測データを用いた予測誤差に基づき修正し（フィルタリング）、状態を推定する。予測により不確実性（分散共分散行列）が増加するものの、フィルタリングにおいて、予測誤差の分散共分散行列を用いた推定精度の改善がなされる。カルマンフィルタは、線形・ガウス性のシステムを前提としており、安定性はある一方で、適用範囲は限定される。非線形・非ガウス性に対応するため、様々な手法が提案されてきた²⁸⁾。ガウス性ノイズを仮定するが、非線形関数への適用拡張を行った手法として、拡張カルマンフィルタ、モーメントマッチング、アンセンティッドカルマンフィルタがある。非ガウス型ノイズにまで拡張した手法としては、ヒストグラムフィルタやガウス分布和フィルタ（複数仮説カルマンフィルタ）、アンサンブルカルマンフィルタ（Ensemble Kalman Filter: EnKF）²⁹⁾、パーティクルフィルタ（Particle Filter: PF）³⁰⁾が存在する。これらの手法は、確率分布をヒストグラム、ガウス分布和、アンサンブル等で近似したものである。この中でも、アンサンブルベースの手法として、EnKFとPFが、その自由度から、様々な分野で適用されている。

(1) 定点カメラ画像を用いたモデルの開発

前述の通り、動画像処理分野のレビューの結果、既存の自動追跡手法には、オクルージョン

や見えの変化に脆弱であるという課題が存在することを確認した。また、これまでも観測データとシミュレーションを統合するデータ同化による手法が開発されているが、データ同化を用いた追跡手法の多くは、特徴量を手動で決定した観測モデルを用いているため、その適用可能性が限定的であった。一方で、近年の物体認識精度の向上に大きな貢献をなしているのが、深層学習である。特に、CNN(Convolutional Neural Network: 畳み込みニューラルネットワーク)の登場により、画像認識コンペティションにおいて人による分類精度を超えるモデルが開発されるまでに至っている。そこで、データ同化の枠組みの中でCNNを観測モデルとして導入した車・人の追跡の基礎モデルを構築した。

この基礎モデルでは、状態ベクトルとして物体位置と速度、観測ベクトルとして固定カメラ画像の各画素のRGB値と定義した。なお、撮影領域内における数点において画像座標と現地座標を計測し、射影変換により、画像を実座標と対応付けている。システムモデルでは、車・人ともに等速直線運動を設定した。観測モデルは、観測ベクトルから該当位置における車・人らしさを評価するモデルであり、本研究で新たにCNNを導入した。特に、転移モデルを用いて観測モデルを構築する。転移学習とは、あるデータセットを用いて事前にモデルを学習させた後、入力に近い層のパラメータを固定し、出力に近い層のみを目的に合わせて学習させる手法である。これにより事前に学習したデータセットから汎用的な特徴量を抽出可能なパラメータを得ることができる。ここでは、事前に学習された学習済みモデルであるInception v3³¹⁾を用いた。

Inception-v3はILSVRCと呼ばれる大規模画像認識チャレンジのために、2012年からImageNetと呼ばれるデータセットを用いて訓練されてきたモデルである。ImageNetは1,400万枚を超える画像を収録したデータセットであり、その画像に写っている物体名（クラス名）が付与されている。その物体名は2万種類以上存在する。ILSVRCは、このImageNetの中から物体名1,000個、学習用データ120万枚、検証用データ5万枚、評価用データ10万枚を抽出したデータセットを用いている。このモデルにおいて、最後のFully connected層とSoftmax層を転移学習により再学習する。再学習のデータセットとしては人認識モデルにはINIRIA Person Dataset³²⁾ (2,700枚)、車認識モデルにはVehicle Make and Model Recognition Dataset (VMMRdb)³³⁾ (10,000枚)を

利用した。その結果、両者とも97~99%の認識率を達成した。

以上の通り作成した認識モデルを一般状態空間モデルの枠組みの中で、観測モデルとして組み込む。矩形ウィンドウのサイズを観測モデルで設定し、状態ベクトルの予測値が示唆する動画像内での座標からあらかじめ定めた矩形ウィンドウサイズの範囲内に存在する画素をCNNの入力とする。本研究で適用する動画像において、歩行者のデータは比較的高いところから角度を大きく撮影されたデータを用いるため、動画像内での歩行者の大きさは比較的变化しない。そのためウィンドウサイズは常に一定と設定した。車両のデータは角度が小さく撮影されたものであること、また進行方向と平行に撮影されていることから、車両の大きさが変化するため、状態ベクトルの位置に比例する形でウィンドウサイズを変化させるように設定した。

データ同化の計算には、観測モデルが非線形であることから、パーティクルフィルタを適用した。パーティクルフィルタは、データ同化の計算手法の一つであり、非線形・非ガウス性のモデルにも適用可能な最も自由度の高いものである。基礎モデルは、複雑な非線形性を有するため、パーティクルフィルタによる計算以外は困難であるといえる。ここでは、初期値（初期分布）が必要になる。対象とする問題の場合、画像内において、車・人が出現した時に、それらを認識する問題に相当する。車両の抽出には、出現位置が明確であることから、探索範囲をあらかじめ限定し、観測モデルを構築する際に作成したCNNを用いた。一方の人物の抽出には、出現位置の自由度が高いため、今回はマニュアルで与えることにした。

上記のモデルにおいては、個人ごとにモデルを適用していたため、人の複雑性（相互作用等）から追跡が困難になるという課題が確認された。そこで、人数および複数人物を同時に認識・追跡する手法への拡張を行った。基礎モデルに対して、PHD（Probability Hypothesis Density：確率仮説密度）フィルタを導入する。

PHDフィルタはランダム有限集合の状態推定手法である。ランダム有限集合とは、推定したい状態量（本研究では、人物位置と速度）に、対象の個数も確率変数として加えた状態ベクトルのことである。

ランダム有限集合を用いる場合、推定する標本空間が複雑なものとなってしまう、パーティクルフィルタを用いた推定には限界が生じる。

このため、計算量を少なくするための工夫が必要である。この点を考慮して考案された手法がPHDフィルタである。これは推定すべき事後分布の1次のモーメントを逐次的に推定する手法である。すなわち、単一の追跡対象の状態空間において、その地点に存在する対象数の期待値を強度としてもつ分布を推定していく手法であり、この推定対象をPHDと呼ぶ。そのためPHDは非負値関数であり、その積分値は積分領域中の追跡対象数の期待値となる。

PHDフィルタにおいても、他のデータ同化手法などと同様にシステムモデルと観測モデルの2つのステップで構成される。システムモデルにおいては、予測分布は、追跡対象の残存・消失の確率分布および新規追跡対象の出現を表す確率分布から構成される。新規追跡対象の出現を表す確率分布は、ポアソン分布に従うものとする。観測モデルにおけるフィルタ分布は、検出・未検出の確率分布の和から構成される。検出部分の確率分布は、基礎モデルにおいて開発した、深層学習の1種である畳み込みニューラルネットワークを用いる。このシステムモデルと観測モデルから、逐次モンテカルロフィルタを用いて、状態ベクトルを逐次推定していく。逐次モンテカルロフィルタにおいては、状態ベクトルの事後分布を、解の候補となる粒子とその重みで表現する。重みは、観測モデルにより計算される尤度に対応する。逐次モンテカルロフィルタの流れは、以下の通りである：初期分布の生成、残存粒子の次時刻への伝搬、新規出現粒子の発生、重みの更新、ラベルの付与・削除（後述）、リサンプリングである。

上記で述べたPHDフィルタの逐次モンテカルロ実装では、対象が存在する位置とその数を推定することができる。しかしながら各対象を明示的に区別しないため、同一対象の軌跡を推定するために粒子に対象を識別するためのラベル情報を加える必要がある。ここでは、重み付き粒子の集合において、各粒子に整数値をとるラベル変数を追加する。残存物体に対しては、その位置関係から同じラベルを付加する。新規出現の粒子に対しては、クラスタリングに基づき仮ラベルを与え、それが一定期間存続する場合に、新規ラベルを付与する。

ここで、拡張手法の流れを下図に基づいて整理する。まず、存在人数の期待値を分布としてあらわしたPHDを、モンテカルロ近似を用いて粒子の集合とする。次に各対象におけるシステムモデルを用いて粒子を伝播させた後、新規粒子をポアソン分布に従って生成する。残存粒子

に関しては既存のラベルを、新規粒子に関しては、クラスタリングにより仮のラベルを付与する。このラベルに従って、各粒子の重みを更新する。更新後、各ラベルに所属する粒子の尤度の平均と位置・速度からラベル削除の判定を行う。これらの操作によるラベルの増減を踏まえたうえで、ポアソン分布によって提示された新規出現対象数で最大付与数新規ラベル付与を行う。新規ラベルの付与は、ラベルがすでに付与されているものには行わない。先ほど仮ラベルを与えた粒子、またはラベル削除された粒子に対して行う。状態空間をメッシュで区切り、そのメッシュ内に存在する該当粒子の尤度の平均が閾値を上回った場合に、その該当粒子群に新規ラベルを付与する。最後に各粒子の重みに従ってリサンプリングを行う。これを繰り返すことで、複数物体の位置の逐次推定と、観測エリア内の対象数の期待値算出を行う。

(2) GNSS・Wi-Fiを用いたモデルの開発

流動人口分布を推定するために、広範囲に、かつ時空間分解能が高いデータの活用可能性が高まってきているが、中でも高い時空間分解能を持ち、取得が容易であるGPS・Wi-Fiデータの2種類のサンプリングデータに着目する。GPSデータは、人の移動軌跡情報が取得可能である反面、サンプルは少ないという特徴を有する。一方のWi-Fiデータは、人の密度が観測可能であり、移動軌跡までは取得困難であるものの、サンプルは多い。これらのデータを組み合わせることにより、両データの長所を合わせた滞在人口分布と移動人口を同時に推定できると考えられる。そこで、GPS・Wi-Fiのデータ統合による滞在人口分布と移動人口の同時推定の基礎モデルを構築した。ここでは、GPS・Wi-Fiデータから、滞在人数・隣接セル間の移動人数をメッシュ集計データの形に変換したのに対して、状態空間モデルの枠組みを用いた。

この基礎モデルでは、状態ベクトルには各時刻・メッシュにおける滞在人数、前時刻からの隣接メッシュ間での流入・流出人数、前時刻からの対象範囲内での出現・消失人数を用いる(図-3)。全メッシュのこれらの状態を並べたも




図-3 滞在人口・移動人口のモデル化イメージ

のを状態ベクトル定義した。観測ベクトルとしては、GPS・Wi-Fiデータをタイムステップごとの各メッシュについて集計した人数を、抽出率で割った値を用いた。抽出率とは、GPS・Wi-Fiの各センサで観測された人数を対象範囲の全人口で割った値であり、すなわち、拡大率の逆数に相当する。観測ベクトルとしては、状態ベクトルと同様に、各時刻・メッシュにおける滞在人数、前時刻からの隣接メッシュ間での流入・流出人数、前時刻からの対象範囲内での出現・消失人数とした。ただし、流入・流出人数や出現・消失人数は、GPSでのみ観測可能なため、GPS観測ベクトルにのみ定義する。全メッシュの以上の観測量を並べたものを観測ベクトルと定義した。

システムモデルとしては、人の滞在・移動を表現するため、保存則を適用した。保存則は、滞在人数の変化、隣接メッシュからの流入人数、隣接メッシュへの流出人数、および出現・消失人数の線形和で表現した。また、流入・流出人数、出現・消失人数も時間変移することとし、時間遷移割合を乗じたものに、システムノイズを加えてモデル化を行った。時間遷移行列としてトレンド項を導入したが、トレンドは観測データから推定し、時間不変とした。なお、保存則モデルに基づけば、負の推定値が得られる可能性があるが、これは現実的ではない。そのため、推定値が負になった場合には、次の観測モデルによる更新を行わないモデルとした。

観測モデルについては、GPS・Wi-Fiデータのそれぞれについて定式化する。観測ベクトルは、状態ベクトルに観測ノイズが加えられた上で観測されるものとして定式化が可能である。観測ノイズには、抽出率誤差と観測人数誤差が考えられる。これらの誤差は、負の二項分布³⁴⁾に従うと考えられる。負の二項分布とは、統計的に独立なベルヌーイ試行を行った時、ある回数の成功を得るのに必要な試行回数の分である。これは、人数などのカウントデータの統計に用いられることがあり、分布が負の値をとらないことが特徴である。今回は、観測人数が成功回数に、抽出率が成功確率に対応することになる。ただし、本基礎モデルでは、状態ベクトルが高次元になるため、カルマンフィルタの適用を考えるため、線形・正規性モデルである必要がある。そのため、誤差項には、負の二項分布から得られた平均と分散を用いて正規分布として定義した。

上記モデルの大きな課題の一つは、システムモデルにおける移動人数等の時間遷移モデル

の単純さであった。具体的には、基礎モデルではある時刻の移動人数、発生人数、消失人数のそれぞれを前時刻の同状態量にある係数（トレンド項と呼ぶ）を乗じたものとしていたが、このトレンド項が全ての地点で同一であるという仮定を置いていた。一般に、移動人数の時間遷移は地点毎に異なるはずであるので、その効果をモデルに適切に組み込めれば、推定精度の向上が期待できる。

そこで、地点毎に異なる移動人数の時間遷移をデータから学習するようなモデルを構築し、流動人口分布の推定精度の向上を図る。そのために、トレンド項に地点依存性を組み込んだモデルを開発した。すなわち、ある地点の移動人口のトレンド項は、その地点の移動人口データのみから求めるモデルである。基礎モデルはある地点の移動人口のトレンド項を全地点の平均移動人口データから求めるモデルであったため、新モデルは地点特有の現象をより適切に考慮できる一方、サンプル数の不足による推定の不安定化が懸念される。ただし、データを十分な長期間にわたって取得すれば、サンプル数の不足は解決可能と期待される。

(3) 衛星画像を用いたモデルの開発

人工衛星によるリモートセンシングは広い範囲の地表面を周期的に観測できるという特徴を持つ。衛星においても機器の小型化・軽量化が進んできた。これにより、衛星自体の大きさや重量も小さく、軽くできるようになり、超小型衛星（2009年内閣府「宇宙基本計画」内では、小型衛星を100kg～1t程度、超小型衛星を100kg以下のものとしている）の開発につながっている。このような超小型衛星は、一度の打ち上げに複数が相乗りできるため、同等のコスト内でもより多くの衛星の打ち上げが期待できる。使用できる衛星の増加を見込んで、ひとつの衛星を単独で用いるのではなくいくつか組み合わせて利用する衛星コンステレーションも多数計画されている。複数の衛星を用い、それらを適切な軌道に配置すれば、数時間オーダーの間隔での地表面の観測も可能と考えられる。例えば、コネクティッドカーのプローブ軌跡情報に、この衛星画像による車両密度情報を組み合わせての交通状態推定が考えられる。

しかしながら超小型衛星は光学機器等の性能が大型衛星に対して劣るといった問題がある。超小型衛星の撮影画像における分解能は1～3m程度のものが多く、個別車両を検出するのは容易ではない。従来は、エッジの検出やNG(normed

gradient)特徴量の利用により車両の検出を行っているが、上記の分解能画像に対して単純に適用できる手法とは言い難い。ところで、交通状態の推定を目的とする場合、個別車両の座標の特定は必ずしも必要なく、対象とする道路・車線上の車両密度が分かれば、そこでの混雑状況の把握は可能である。こうした中でCNNに代表される深層学習は、近年画像分類をはじめとした多くの分野において目覚ましい発展を遂げており、物体認識においても例外ではない。そこで、深層学習を用いて超小型衛星画像の道路領域から車両密度を推定する基礎モデルを開発した。現状では、超小型衛星画像が流通していないことから、今回は、分解能31cmの大型衛星WorldView-3により撮影された画像を低解像度化したものを使用する。本モデルは、プローブ軌跡情報とのデータ同化による融合のための前処理の位置付けにあたる。

衛星画像から車両密度を推定するためには、
1. 衛星画像の道路領域と対応する道路との紐づけ、
2. 学習・解析のための衛星画像の整形、
3. CNNの学習、
4. 学習モデルによる推定の4段階を踏む必要がある。まず、衛星画像からの道路領域の抽出および地図との紐づけを行う。衛星画像は画像撮影時の衛星座標の誤差や傾き、また地表面の起伏によって、ずれや歪みが生じているため、単純に地形図に重ね合わせるだけでは正しく抽出・紐づけができない。これらに対し補正を行ったものとしてオルソ画像があるが、撮影から処理を行って利用可能となるまでには時間を要するため、交通状態推定に用いるにはより簡便で迅速な方法を用いることが望ましい。道路領域の抽出については、土地被覆分類を用いる方法あるいは地物抽出による方法³⁵⁾などが考案されてきた。抽出された領域を地図上のネットワークに紐づける際にも、マップマッチングの技術が応用できると考えられる。本研究では、これらの技術を用いて地図情報と紐づけされた、衛星画像の道路領域について扱うものとする。その上で、CNNに入力できる形式に整える手順も必要となる。衛星画像における道路領域は網状になっており、CNNによる学習には適していない。そのため、一定の長さの道路部分を切り出して同一の形状にそろえることが望ましい。準備ができた画像を用いて学習を行う。これには多数のトレーニングデータが必要であり、また真の値が既知である必要がある。新設道路等への適用やデータ量の充実のため、学習する道路領域の場所は推定を行う場所と同一箇所に限定せず、道路一般に適

用可能なモデルを作成する。実際に推定をする際にはここまでで学習したモデルを用いる。推定する際のデータも学習データと同様の整形が必要となる。なお、推定の結果は車両密度であるため、非負実数の範囲で連続である。さらに、本研究では、画像の前処理やネットワーク構成について、いくつかの条件を比較し検討を行った。

前処理については、本手法の適用を想定した場合、対象となる道路は前節で述べたようにネットワーク状であり、曲がり角や交差点を多数含んでいる。ここではCNNに入力する便宜上、対象部分を一定長さ・単一車線で切り出して使用する。なお、一車線の幅は道路により多少の差異があるため、単一車線を切り出したからといって画像の幅は同一にならない。そこで、画像の幅を一定値に定め、それより広いものについては切り落とし、狭いものについては欠落部分を単一の画素値をもって穴埋めする。穴埋めする値としてはゼロ（黒）、当該画像の画素値の平均値、同じく最頻値の3通りが考えられる。この画素値は、道路の舗装面と同じであることが望ましいと考えられる。そこで今回は、画像全体の画素を最も多く占めるものが路面であるとの仮定を置き、画素値の最頻値を代表値として採用した。

前処理を行った画像をCNNに入力し、車両密度を推定する。密度の推定自体は車両を認識して道路領域上で積算する方法でも実現可能と考えられるが、車両の認識が座標のずれや誤検出・検出漏れ等複数の指標を持つのに比べ、車両密度の推定では、密度の値をただ一つの指標として持つ。すなわち密度については推定すべき値が明確であり、この最適化は車両の認識とは異なる枠組みである。そのため、車両認識を利用するよりも直接密度を推定する方がより適切なCNNモデルを構成できる可能性が高い。

入力する画像は、前述の通りすべて同一サイズの画像である。これを畳み込み層とプーリング層のユニットに複数回通し、全結合層を経て出力する。出力値は実数値一出力であり、連続とみなせる。クラス分類に用いられるCNNは、各クラスに対応する出力を設定してそれぞれに尤度を求める場合が多い。これを参考にすれば今回のような場合も、台数別に尤度を出力するようにして同様のモデルに帰着できる。しかし今回は、求める値が密度であり連続であること、また台数の誤差について定量的な評価と最小化が求められることの2点を考慮し、このような回帰型の一出力としている。学習時は正解

のラベルとこの出力値との差の二乗を誤差として、誤差逆伝播法によりパラメータを修正する。ここでは、参考文献³⁶⁾に基づき、検討すべきハイパーパラメータを隠れ層の数、フィルタ数、バッチサイズ、活性化関数の種類に絞り込んだ。

2.3 車・人の認識・追跡の学習型モデルの検証

(1) 定点カメラ画像を用いたモデルの検証

車両追跡の適用データとして、「鎌倉エリア観光渋滞対策実験」のために設置された路側カメラのうち、鶴岡八幡宮前交差点の東側を撮影した解像度640pixel×480pixel、10fpsの画像を用いた（図-4）。適用対象の映像は2018年6月14日11時～12時に撮影されたものである。これは2018年6月11日～17日に開催されたあじさい祭りの期間内であり、問題視されている混雑時の状況を撮影したものである。歩行者追跡の適用データとしては、2010年11月29日の朝のラッシュ時間帯に、東急田園都市線たまプラーザ駅改札の撮影画像を用いた。フレームレートは10fpsである。それぞれの撮影画像例を図-5に示す。



図-4 カメラ設置位置および適用対象



図-5 撮影画像例

まず、基礎手法内におけるパラメータを試行錯誤により設定した。車両追跡手法においては、パーティクルフィルタのパーティクル数を100、システムノイズの分散を10pixelと設定した。一方の人物追跡手法においては、パーティクル数を70、システムノイズの分散を速度の0.2倍に設定した。

提案手法を、車両および人物それぞれに適用した。車両追跡手法においては、実通行台数211台に対し、197台(約93%)の認識結果が得られた。認識されなかった例としては、バス等の大型車両により、抽出部分において後続の車両が完全に隠れてしまい、途中から出現したものである。これに関しては、車両抽出部分の拡張により対処可能であると考えられる。追跡精度の評価はRMSE (Root Mean Square Error) により行った(表-1)。認識率、および位置の追跡精度については、十分な精度に達していることを確認した。なお、速度精度に関しては、やや悪くみえるが、モデル推定のために用いたものであり、推定結果としては問題なく、参考までに記載している。

人物追跡手法における追跡精度の評価は、同様にRMSEにより行った(表-2)。多くの場合で、十分な追跡精度に達していることを確認した。また、PHDフィルタによる改良により、軌跡位置の二乗平均平方根誤差(RMSE)は、改良前後で、1.04mから0.47mに向上した。

(2) GNSS・Wi-Fiを用いたモデルの検証

株式会社Agoopが取得しているGPSデータ、およびSoftbank株式会社の取得しているWi-Fiデータに対して、基礎モデルの適用を行った。本研究における集計データ作成対象範囲は図-6に示す約1km×1kmの範囲とし、125mメッシュ(図中水色)をあわせて示す。主に鎌倉駅から鶴岡八幡宮にかけて交通が集中し、混雑が発生する箇所である。2018年6月を対象にした1か月分のGPSデータとWi-Fiデータを用い、2018年6月17日(日)を対象にして推定を行う。

GPSデータにはデイリーID・観測時刻・観測座標が記録されている。観測時刻は分単位で記録されており、観測座標は緯度・経度の形でそれぞれ小数点第6位まで記録されている。座標データの取得時間間隔は携帯端末のOS等によって異なっているため、人物位置データを単位時間ごとの人物位置座標の形式に成型する必要がある。ここでは、単位時間として、取得可能な観測時刻の最小単位である1分と設定した。データ成型では、変換は同一人物の座標を時系

列に並べた際、観測時刻が1分ごとになるように、2つの操作を行っている。1つは同デイリーIDの観測座標が単位時間である1分のうちに複数回存在した場合は同時間に観測された複数座標の平均座標をその時間の人物位置とする処理(平均処理)である。この処理は、同時刻においては複数観測された座標の観測の順番が判別できないため行う。2つめは、同デイリーIDを時系列に並べた際、連続する2点の観測時刻の差が単位時間より大きくなっていった場合(今回の場合は2分以上)には2点間を線分で結び、1分ごとの座標になるように線分上を内分して座標を補間する処理(補間処理)である。ここまでの処理を当該範囲・期間のデータに適用したときの観測座標数は、取得データ座標数3,904、平均処理後座標数2,519、補間処理後座標数43,274となった。

補間後のポイントデータについて、タイムステップごとにメッシュに区切って集計する。今回は、集計タイムステップを、5・10・30分の3種類、メッシュの区切り方を125・250mと設定し、各時空間単位で集計した。それぞれのタイムステップに対し、滞在人数・それぞれの隣接セルとの間の移動人数・発生人数・消失人数を集計する。移動人数については、成型後のGPS

表-1 車両適用時における位置・速度精度のRMSE

	画素単位	空間単位
位置 (横断方向)	12.4 pixels	0.27 m
位置 (進行方向)	86.5 pixels	1.88 m
速度	111.4 pixels/s	8.72 km/h

表-2 人物適用時における位置・速度精度のRMSE

	画素単位	空間単位
位置	49.4 pixels	1.04 m
速度	4.27 pixels/s	0.32 km/h



図-6 適用対象範囲

データの座標を直線で結んだ形の軌跡として扱い、軌跡がまたぐセルを移動としてすべて隣接セル間の移動となるように集計をしている。


Wi-Fiデータは、アクセスポイントと呼ばれる無線LAN局に携帯端末が接続した時刻を集計したものである。アクセスポイントの座標は既知であるため、携帯端末がどのアクセスポイントに接続したのかがわかると携帯端末のおおよその位置が判断できる。一つのアクセスポイントから電波が届く範囲は、障害物がない状態で約100mとなっている。観測された携帯端末の位置は、プライバシー保護の観点上、そのままの形で公開することはできないものとなっている。したがって、集計データに変換されたものが人物位置の観測データとして利用可能となる。集計の際に用いられる空間単位は、今回は標準地域メッシュ4次(約500m四方)、5次(約250m四方)、6次(約125m四方)である。同様に時間単位は、5分・10分・30分となる。また集計の際に、メッシュ内の人数が10人以下であった場合は通信端末利用者のプライバシーを守るための処理として該当セルの人数を欠損値(0人)にする操作が行われている。ここまでの処理を施したものがWi-Fiデータとして入手可能であり、今回はこのデータを使用する。入手したWi-Fi集計データにはそれぞれ集計単位時間とそのときのセル内の滞在人数が記されている。また、今回の推定に適した時空間分解能を検討した。集計データを可視化したものを比較することにより、時空間分解能として125m・10分単位を採用することにした。

今回の流動人口分布・流入人数の推定を行うにあたり、推定の精度を検証する必要がある。しかし、現実には数100m四方単位で時系列の流動人口分布の全数調査のデータは存在しない。したがって、同対象範囲に対して1日分の人物移動データを作成する。作成したデータの流動人口分布、及び隣接セル間の移動人数を真値とし、ここからデータを抽出することによって、仮想的にGPSデータ・Wi-Fiデータを作成して検証に用いる。シミュレーションデータ作成においては、実データを参考に、人物の発生分布を作成し、その分布にランダム誤差を付加して、個人データを作成する。この各人に座標を与えるが、空間的に人数が集中する場所を再現するため、緯度、経度それぞれに対しガウス分布を仮定し、ある座標を中心とした二次元ガウス分布に従うような発生座標分布とした。次に発生させた座標に対して、タイムステップごとに一つ前の時刻にいた座標からランダムウォーク


をさせることによって、移動を表す。この座標データを拡大することにより、最終的に50,000人のシミュレーションデータを得た。さらに、ここから、GPSデータ(観測率0.6%)とWi-Fiデータ(観測率6%)としてサンプリングを行った。なお、このデータではWi-Fiデータの欠損処理も再現している。

上記の通り作成したシミュレーションデータに対する適用結果を、図-7に示す。この結果から、概ね全体の傾向が捉えられていることが確認された。推定精度として、平均絶対誤差(MAE)と平均絶対誤差率(MAPE)により評価を行った(表-3)。結果から、GPSのみ、Wi-Fiのみと比較して、高い精度での推定が実現できたことを確認した。また、真値と推定値の関係を示す散布図から、両者に高い相関が確認されたことと、Wi-Fiの欠損データによる外れ値の存在を確認した。なお、Wi-Fiでは移動人口が観測できないため、滞在人口の結果のみを示す。

提案手法を鎌倉の実データに対しても適用した。若宮大路が存在するセルに関しての移動人数と比べて、小町通りの移動人数が少なく推定された。若宮大路は広い通りであるが、小町通りは道沿いに土産物店などがあり、歩行者中心の通りとなっている。滞在人数と移動人数を



(a) 滞在人数



(b) 1方向移動人数

図-7 1メッシュにおける精度評価例

表-3 推定人数の精度評価

	滞在人口		移動人口	
	MAE (人)	MAPE (%)	MAE (人)	MAPE (%)
提案手法	54.98	42.74	36.73	60.26
GPS	160.83	90.54	96.59	170.60
Wi-Fi	59.59	49.35	-	-

同時にみることにより、人々が鎌倉駅から小町通りに流入して鶴岡八幡宮方面に向かうこと、鶴岡八幡宮方面から駅に向かう方向では小町通りのみならず、若宮大路を通る人が多いことが示唆された。

改良後の精度検証では、同様に正解データが既知であるシミュレーションデータを用いることとする。これは、実際に人の旅行行動を再現したうえで、その行動からGPS、Wi-Fiデータを実際のデータの特徴（例：サンプル数が少ない時の秘匿化処理）を考慮しつつ生成するものである。まず、滞在人数推定精度を検証する。全地点・全時刻の推定値についての平均絶対誤差率を求めると、25.7%となった。同一のシミュレーションデータを対象としたときの基礎モデルの平均絶対誤差率は42.7%であった。大幅に精度が向上したといえる。以上より、改良モデルは滞在人数推定の精度を向上させたといえる。

(3) 衛星画像を用いたモデルの検証

衛星画像を用いて提案手法を適用し、その精度を確認した。本研究で想定する画像は超小型衛星で撮影されたものである。しかし前述のように、超小型衛星の画像はまだ一般に流通している段階にない。そのため今回は大型衛星WorldView-3による衛星画像を利用する。同衛星はDigitalGlobe社が運用する太陽同期準回帰軌道衛星であり、高度617km、軌道周回時間は97分である（同一地点を観測できる間隔（回帰日数）はこれより大きい）。同衛星により撮影された衛星画像を4地域それぞれ約25km²、計100km²用意した。場所はそれぞれ神奈川県鎌倉付近、東京都新宿付近、同練馬付近、兵庫県尼崎付近である。選定にあたっては、ある程度の道路率および交通量が期待でき、かつ高層建築密集地、住宅地、山林、沿岸部といった多様な場所が含まれることを意図した。また、撮影時期は、雲が少なく空気の澄んでいる秋から冬にかけてで、太陽高度が偏りすぎないことを考慮し決定した。1画素あたりのビット深度は11bit/pixel、観測波長帯は青(B:450-510nm)、緑(G:510-580nm)、赤(R:630-690nm)、近赤外1(N:770-895nm)の4チャンネルである。神谷らの研究³⁷⁾では、チャンネルをBGRの3つに絞っても検出率に大きな影響はないという結果が出ている。また、ビット深度8bit/pixelの場合は、ノイズの影響が抑えられたため検出率が向上したとしている。今回は、今後の超小型衛星の仕様を想定し、3チャンネル・8bit/pixelの形で切り出し利用

する。なおこの画像はいずれもカラー画像であり、分解能は31cmである。分解能の変更は作業の便宜上、教師データの作成後に行った。

CNNに入力する画像の準備と、教師データとなるラベルの作成を行った。準備した衛星画像は、そのままでは巨大なため、一枚が数百メートル四方となるよう格子状に分割した。分割した衛星画像から道路領域を切り出す作業については、Pythonによるツールを作成し、計算機上で行った。なお直線部の道路領域は基本的に長方形であると考えられるため、切り出し時にはその形状を長方形に制限している。また、直線部分であっても極端に短い場所(100m未満)については切り出しの対象外とした。切り出した長方形領域はそのままでは四辺が画像領域の各辺に対して水平・垂直でないため、長辺が横方向となるよう回転させた。

教師データを作成するためには車両台数の情報が必要となる。そこで、作成したPythonのツールで道路領域の画像を読み込み、マウスで車両をクリックしていくことで座標を取得した。車両は面的な対象物であるが、今回必要となるのは台数情報のみであり、車両の領域を指定するのは大幅に作業の負担が増加するため、車両の中心付近を一か所代表点として指定することとした。なおこの時点での分解能は31cmである。目視での車両の特定にはこの程度の分解能が必要であり、実際に超小型衛星の画像を使う場合も教師データの作成には高分解能衛星の画像を使う必要が生じる。この点は本研究の課題の一つである。

ここまでの段階では各画像の大きさは一定でないため、あらためて整形し分解能を低くする。整形は道路の長さ方向と幅方向にそれぞれ必要となる。長さ方向は約50m(165pixel)を1単位として切り分けた。幅方向は約7m(24pixel)を基準とし、それより大きいものについては切り捨て、不足する場合は画素値の最頻値で埋めた。なお、分割や切り捨てにより画像の範囲外となる車両が存在するため、この段階で先ほど作成した車両の座標データから改めて車両台数の教師データを生成した。ここまでで準備できたデータがおおよそ2,500枚であった。しかし、深層学習では非常に多くの教師データを必要とする。また、このうち大部分が車両台数0台や1台の画像であり、混雑している道路の学習データが不足してしまう。そこで、Data Augmentationを行う。まず画像の左右・上下の反転により、データ数を4倍にすることができる。また、双三次補間において分解能を下げる場合、ある画

素がリサンプリング後の画素の中心に位置するか端に位置するかによって、リサンプリング後の画素の色が異なってくる。そこで、画像をわずかにずらすことで、サンプリングの位置がずれ、異なる画素配列を作ることができる。分最終的に用意したデータの数は分解能93cmで121,188枚であった。画像中の最大車両数は10台で、台数が少ないほどデータ数も多かった。このうち入力するデータセットは、0台から6台の車両を含む画像各856枚の計5,992枚とした。

上記の通り準備した画像と、これよりさらに空間分解能の低い画像を用いて比較する。空間分解能が低い画像ほど、データ量が小さくなり、車両1台を表現する画素の数も減少する。よって、車両密度の推定精度は低くなると予想される。空間分解能93cm(基本状態)と124cm, 155cmのデータセットに、それぞれ提案手法を適用した。使用したデータセットはいずれも同じ衛星画像から生成した道路領域5,992枚であり、台数ごとのデータ数も同一である。またその他のネットワーク構成等もすべて同一である。ハイパーパラメータを試行錯誤により調整したのち、最も精度の良かった結果を表-4に示す。車両密

度の取りうる値は0~200台/kmであることを考えると、10~17台/kmの精度は比較的良好といえる。特に、自由流状態と渋滞状態の区別や、渋滞の激しさを把握可能な精度であるため、交通マネジメント上有用な性能を発揮しているといえる。分解能ごとの精度をみると、テストデータ、トレーニングデータとも、分解能93cmの画像に比べて分解能124cm, 155cmでは大幅に精度が低下した。一方、分解能が低い2つの場合では学習している間を通して精度の差がほとんど出なかった。道路横断方向における車両の幅は2, 3mであることが多い。分解能が1mを超えると、2pixelしか幅を持たない車両が多くなり、トレーニングデータにおける車両の画素パターンも少なくなる。そのため、画素パターンのうち車両に特有のものが抽出できず、検出が難しかったものと思われる。

表-4 密度推定のRMSE

分解能 (cm)	RMSE (台/km)
93	11.2
124	16.0
155	16.3

第3章 学習型交通状態予測手法の開発

蓄積されたビッグデータを使用して将来予測を実施することはAIの典型的な活用事例であり、交通状態の短期予測に関する研究が進展している。しかし、観光交通が卓越した地域を対象とした短期交通量予測の適用事例は未だ少なく、オーバーツーリズムの評価等への適用にも至っていない。通学や通勤による日常的な交通混雑は、発生する時間帯がある程度特定されているのに対し、観光交通による交通混雑はその限りではない。また、曜日や季節、天気、社会イベントの開催などによって観光交通は一般に大きく変動する。そのため、このような特徴を持つ観光交通を高い精度で短期予測する手法の確立が求められている。

観光交通の場合、特にOD表等の交通インプット情報は曜日や季節の移り変わりと共に大きく変化する。鎌倉市の場合、市内に多く存在するあじさいの名所には開花時期の6月から7月上旬に例年多くの観光客が訪れる。先述の通り観光交通需要には大きな季節変動が存在するため、厳密に交通量を予測するためには曜日や季節毎のOD表を多数構築する必要があるが、それは容易な作業ではない。

そこで本研究では、分析手法として深層学習に着目し、鎌倉市中心部における車両の時間的な集中度合いを短期予測する分析枠組の構築を行う。したがって、交通シミュレーションで得られるような経路・リンク交通量、エリア内の車両総旅行時間などを短期予測するものではない。むしろ、観光交通需要の季節性、社会イベントの有無、降水量の影響等を考慮することで、短期の交通量予測の精度がどこまで向上しうるのかを明らかにすることを主な目的とする。深層学習は、入力されたデータを学習することでその特徴を包括的に考慮し、極めて詳細な予測を行うことができ、上述の分析目的に

適した手法であると共に、各種のリアルタイム交通需要マネジメント施策への活用も期待される。

交通量などのデータは時間方向に強い依存性を持っている時系列データである。深層学習において時系列データの予測に適しているモデルの代表例はLong short-term memory (LSTM)³⁸⁾である。後述するように、LSTMを活用した既往研究はこれまでも幾つか見られるが、その多くは通勤交通等が支配的な都市内道路等における短期の交通量や旅行速度の予測を主眼としている。また、そのほとんどは一変量型のLSTMに基づく短期予測である。これに対し本研究では、鎌倉市中心部に位置する下馬の過去交通量、下馬に繋がる周辺部複数地点の交通量、降水量、市内で開催される社会イベントの有無などの多様な属性を入力データとして、下馬の60分先の交通量予測値を出力する枠組みを多変量LSTMに基づいて構築する。

特に、学習型モニタリングの結果から得られるデータの活用を念頭に置いた交通流動予測について検討や精度確認を行い、必要な場合はモデルの改良を行う。また、実際の交通流動マネジメントにおいて利用される場合を想定し、予測の時間解像度と予測範囲について検討を行う。

3.1 AIを活用した車・人の交通流動予測に関するレビュー

AIを活用した機械学習ベースの交通流動予測を考えるにあたり、本研究で主に検討する鎌倉市のような観光地の交通状況の特性として考慮すべき点は主として以下の点であると考えられる。1つ目は変動特性（季節特性、平休日特性、時間変動特性）の適切な考慮の

必要性である。観光交通は一般にそのような交通量変動が非常に大きいと言われており、適切な予測手法の確率が必須である。次に、突発的事象の考慮の必要性である。観光交通は天候等にも大きく左右されると言われている。また、一旦観光地内の道路で大きな事故が発生したらその影響は甚大になる。同様に、大規模な観光イベントの考慮も重要となる。観光地で大規模なイベント等が催される場合、需要が通常の観光交通の流動と劇的に異なりうる。AI型モデルの構築にあたっては、観光交通流動のそのような側面を適切に考慮できることが重要と思われる。以上のような問題意識から、本研究に密接に関連すると思われる複数の研究のレビューを行った。

(1) オンデマンド乗車サービスの予測事例

Ke et al. (2017)³⁹⁾は、FCL-Netという新たな深層学習の手法を提案している。これは、複数のLSTM (Long-Short Term Memory) 層、通常のLSTM層、および畳み込み層が積み重なった構造を持ち、時空間特性と説明変数の相関を捉えることに適していると考えられる。この研究では、中国の杭州市でのオンデマンドライドサービスにて今回のモデルを提案している。

オンデマンド乗車サービスにおける短期予測は、観光交通の予測と類似しており、依存関係に関する課題が存在すると考えられる。一つ目は、時間依存性であり、乗客需要は強い周期性（朝と夕方にピークに達するなど）を有している。二つ目は、空間依存性であり、ある特定のゾーンにおける旅客需要はネットワーク内全てのゾーン変数に大きく影響を受ける。最後に、外生的依存性であるが、これは、気象条件などの外生変数は短期旅行客需要に強い影響を及ぼす。Ke et al. (2017)で提案する Fusion Convolutional Long short-term memory Network (FCL-Net) では、これらを適切に考慮することが可能とされている。

(2) 予測モデルにおける交通需要の空間的特徴の明示的な考慮

Liu and Chen (2017)⁴⁰⁾は、LSTMの予測精度の向上や同ネットワークが使用するデータの空間的特徴を抽出するために、時空間行列と畳み込みニューラルネットワーク (CNN) の統合を行っている。旅行速度を予測するために用いているのはCNNだが、分析では、交通量、速度、および占有率によって構築された3次元データ

行列を扱っている。15分間隔での交通データを用いた実験を通じて、提案したアルゴリズムが他の一般的に使用されているアルゴリズムと比較してタスクを予測する際に精度向上をもたらすことが示されている。同時に、オートエンコーダー（入出力に同データを用いるモデル）の注意モデルによって生成された重みを視覚化することにより、予測タスクに対する様々な時空間データの影響を見られることが示されている。

(3) サイクルシェアシステムの需要予測事例

Xe et al. (2018)⁴¹⁾は、ディープラーニングアプローチを使用して、ステーションフリーの自転車共有のための動的需要予測モデルの開発を行っている。ステーションフリーの自転車共有の移動パターンを調査するために、空間的および時間的分析を行った結果、自転車共有旅行の空間的および時間的な需要がインバランスであることが分かった。そうした背景を踏まえて、Xe et al. (2018)では短期需要予測のためのLSTMニューラルネットワーク (LSTM-NN) モデルを開発し、10分、15分、20分、および30分間隔を含むさまざまな時間間隔でのTAZでの自転車共有旅行に関する予測を行い、高い精度を実現していることを確認している。

(4) 高速道路における短期交通量予測の事例

Polson and Sokokov (2017)⁴²⁾は、スパースアプローチによる機械学習ベースの短期交通量予測モデルを構築している。L1正則化とtanh層をNeural Networkの最終層に適用したモデルを構築しており、自由流、インシデントの発生、渋滞状況からの回復等の非線形現象の記述を行っている。特に、大きなイベント（フットボールゲーム、降雪）を対象としたケーススタディを行い、提案手法の有効性を確認している。

3.2 短期交通量予測モデル

交通混雑の緩和には道路規制や混雑課金に代表される流入交通量抑制政策を効率的に実施することが必要となる。そこで本研究では、その前段階の交通状況分析として、市内中心部の交通量の60分先の予測値を出力する。予測対象は「下馬（横浜鎌倉線下り）」、「下馬（横浜鎌倉線上り）」、「下馬（横浜鎌倉線上下合計）」の3種類の交通量である。東京方面から流入する車両が下り交通、海岸方面から流入する車両が

上り交通である．ここで予測先の時間を60分と設定したのは，都心から鎌倉市中心部までの車での所要時間が約60分～70分であることを踏まえ，60分先の交通量を出力することで，早い段階でドライバーのトリップ選択行動を補助できると判断したためである．

(1) 入力データの検討

日本道路交通情報センター (JARTIC)から図-8に示す7地点の交通量データを取得した．このエリアでは，路上カメラによる道路状況の撮影が常時別途行われており，将来的には映像解析によるリアルタイム交通データが入手可能になると考えられるが，今回の分析では固定感知器による交通量データを使用する．データ期間は2017年1月1日から2018年12月31日までの2年分である．元データの交通量は5分単位で集計されているが，60分先を予測するには時間分解能が高すぎると考えられる．そこで，本研究では15分単位で再集計してデータセットを構築した．また，本研究は観光交通を主な対象としているため，1日の中で比較的交通量が少ない深夜及び早朝の時間帯は除外し，午前8時から午後8時までの交通量を使用した12時間周期のデータを学習に使用する．

気象庁より1時間単位の降水量データを取得した．データ期間は交通量データと同じく2017年1月1日から2018年12月31日までの2年分である．しかし，データ取得可能地点に鎌倉市が含まれていなかったことから，隣接する三浦市観測所の降水量データを採用し，学習モデルに取り入れることとした．

鎌倉市観光課に問い合わせたところ，鎌倉まつり，大船祭り，鎌倉花火大会，あじさい祭りの行事が来訪者が特に多い社会イベントであるとの回答を得た．そこで，交通量に影響を及ぼすと判断し学習モデルに取り入れることとした．

(2) 多変量LSTMのアーキテクチャ

LSTMは，その前身のモデルであるRecurrent Neural Network (RNN) が抱える勾配消失問題を解消した高次モデルである．本研究で構築する多変量LSTMの全体構造は図-9のようになる．隠れ層にはループ構造が備わっており，過去の情報を適切なタイミングまで保持して次の層へ伝播する仕組みとなっている．このとき，ある時点 t の隠れ層 $h(t)$ は同時刻の入力層 $x(t)$ と一時刻前の隠れ層 $h(t-1)$ から信号を受け取ることとなる．ここで，隠れ層の値 $h(t)$ はメモリーセル

の値 $c(t)$ と出力ゲートの値 $o(t)$ を用いて定義される．隠れ層内には図-10に示すLSTMブロックが設置されており，このブロックはメモリーセル，入力ゲート，出力ゲート，忘却ゲートで構成されている．

(3) モデル構造の検討

先に述べたデータを入力項目として，4期先すなわち60分後の下馬の交通量を出力する学習モデルを構築する．入力層には出力対象である下馬を含む各地点の交通量，降水量が15分刻



図-8 交通量データ取得地点および入出力項目

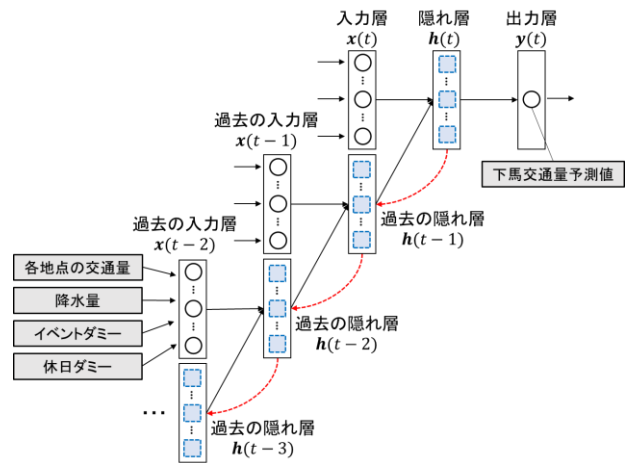


図-9 多変量LSTMモデルの概略




図-10 LSTMブロック

みで入力される。また、社会イベント開催日ダミーは、それに該当する場合には1、そうでない場合は0が入るようにした。休日ダミーも同様に、土曜日、日曜日、祝日の際には1、平日には0で変数コーディングがなされている。すなわち本モデルは、入力層に複数のデータが挿入される多変量LSTMの構造を有している。

ハイパーパラメータとは、モデル学習に先立ち、分析者があらかじめ調整する必要のあるパラメータのことであり、具体的には、隠れ層の数、LSTMブロック数、ルックバック（モデル内に保持される情報量）などが該当する。本研究では、隠れ層の数を1層から6層までの6種類、隠れ層内に設置するLSTMブロックを4個、8個、16個、32個、64個、128個の6種類を用意した。また、ルックバックに関しては、交通量は日単位あるいは週単位で規則的に変化することが予想されるため、保持する情報量をそれらの周期に合わせることで交通量の変動を適切に学習できると考えられる。そこで本研究では1日単位、1週間単位の2種類のルックバックを用意した。本研究では、これらの設定の中から予測精度が最良となる組み合わせを探索し、ハイパーパラメータを決定することとした。

標準的な予測モデルの目的は、真値に近い値を出力することと言えるが、鎌倉市のようにオーバーツーリズムに悩む観光地の混雑緩和を想定した予測を実施する場合には、観測値よりも小さな予測値の出力（過小推計）を避けることが望ましい場合が往々にして起こり得る。これは、予測した交通量よりも多くの交通量が通過する状態が継続すると、混雑の発生を検知するタイミングが遅れてしまう恐れがあるためである。この問題に対処すべく、本研究では学習で最適化する損失関数に着目する。

回帰問題において一般的に用いられる損失関数は、平均二乗誤差 (Mean Squared Error: MSE) である。他方で平均二乗対数誤差 (Mean Square Logarithmic Error: MSLE) は、予測値が観測値を超過しやすいためという特徴を持っている。すなわちMSLEは予測値の過小推計問題の回避に寄与すると期待されるため、本研究ではMSLEを使用することとした。

回帰型の深層学習の目的は、データを学習することでその特徴を把握し予測を実施することであるが、データから適切な予測がなされているかを判断するためには与えられたデータ以外の未知のデータに対する予測性能を確認する必要がある。現実には、真に未知のデータを入手することは困難であり、与えられた全デ

ータを訓練データとテストデータに分割して疑似的に未知のデータを作成することが一般的である。

観光交通予測モデルとしての有用性を正確に評価するためには、テストデータの期間を各季節や特に混雑が予想されるあじさいの開花時期に設定し、予測性能を確認することが必要である。本研究における訓練データとテストデータの設定については、後述するそれぞれの学習モデルに応じて異なるため、詳細については次章で個別に明示する。

なお、予測性能は、テストデータの学習により出力された予測値に対して、二乗平均平方根誤差 (Root Mean Squared Error: RMSE) と平均絶対誤差率 (MAPE) を算出して評価する。

3.3 予測性能の検証

(1) 分析手順

本研究では、大別して9つのモデルを構築した。まず最適なハイパーパラメータを特定するための基礎モデルとしてモデル①を構築し、そこで決定されたハイパーパラメータを以降のモデルでも使用することとする。

次に、観光交通予測モデルには、四季を通して安定した予測性能が求められるため、テストデータを季節ごとに設定したモデルを構築した。具体的には、冬季（1月～3月）交通量検証モデルをモデル②、春季（4月～6月）交通量検証モデルをモデル③、夏季（7月～9月）交通量検証モデルをモデル④、秋季（10月～12月）交通量検証モデルをモデル⑤とそれぞれ称する。

また、降雨や鎌倉市内で開催される社会イベントが交通量に与える影響をモデルが捕捉しているかを評価することも重要であり、降水量データを入力から除去したモデル⑥を構築してモデル④と比較することとする。また、社会イベント開催日ダミーを入力から除去したモデル⑦を構築してモデル③と比較することとする。

最後に、交通混雑がより激しいとされるあじさい開花時期の交通量に対する予測性能を確認するためにモデル⑧を構築することとする。さらに、路上カメラの映像から混雑発生が確認された日の予測性能を確認するためにモデル⑨を構築することとする。

(2) 分析結果（モデル①）

基礎モデル（モデル①）では、2017年1月1日から2018年9月30日までを訓練データ、2018年

10月1日から12月31日までをテストデータとして、予測性能が最良となる隠れ層数とLSTMブロック数、ルックバックを調査した。まず、ルックバックを1日単位とした場合、隠れ層1層、LSTMブロック4個ではMAPEは9.46%と算出された。ここから層数とブロック数をそれぞれ増加させていくと、6層・128個の場合ではMAPEは9.96%となった。層数とブロック数を徐々に増加させていくとMAPEが低下するが、ある状況を境にMAPEが上昇することが確認された。今回の検討の範囲内においてMAPEが最小となったのは、隠れ層2層、LSTMブロック数32個の場合であった。

次に、ルックバックを1週間単位に変更すると、MAPEは9.70%と算出された。すなわち、1日単位の設定の方がMAPEが小さいため、本モデルにおけるハイパーパラメータとして、隠れ層2層、LSTMブロック32個、ルックバック1日単位という設定を採用し、以降の分析に適用することとした。なお、ハイパーパラメータは入力するデータ量にも依存していると考えられている。そこで、下り交通量推定とデータ数が同じである上り交通量、上下合計交通量の学習においても同一のハイパーパラメータを設定することとした。

本研究では、大別して9つのモデルを構築した。まず最適なハイパーパラメータを特定するための基礎モデルとしてモデル①を構築し、そこで決定されたハイパーパラメータを以降のモデルでも使用することとする。

(3) 分析結果 (モデル②～⑤)

各季節における予測性能を把握するために、各季節の期間をテストデータとしたモデル(モデル②～⑤)を構築した。この際、データ数を同条件として予測性能を比較するため、訓練データの量を統一した。2018年の1月から3月をテストデータとした学習における訓練データは2017年の1月から12月であり、2018年の4月から6月をテストデータとした学習の訓練データは2017年4月から2018年の3月となっている。すなわち、どの学習も12か月間の訓練データと3か月間のテストデータというデータ分割で統一されている。

下馬下り交通量に対する予測性能は四季を通じて安定していることが各ケースのMAPEより確認された。これより本モデルは、観光交通需要の季節変動を十分に捕捉していると考えられる。一方下馬上り交通量に対する予測性能は、冬季(1月～3月)におけるMAPEが20.12%

と他の季節と比較して大きくなっている。各学習におけるモデル設定は同一であるため、この結果はモデルの不備ではなく、使用したデータに原因があるものと推察される。本研究ではJARTICより取得した断面交通量データを用いているが、2018年1月の下馬上り交通量データはデータベースから欠落しており入手することができなかった。そのため本研究では、2017年1月の下馬上り交通量データを2018年1月の交通量として代用したが、これにより2年分の交通量データ内に本来存在する変動の特徴が乱れてしまった可能性がある。なお、2018年2月から3月にかけてのMAPEを算出したところ、下馬上りは13.71%、下馬上下合計は9.40%であり、他の季節に対する予測性能と遜色ない結果が確認された。これより、代用した2017年1月の交通量データが学習に悪影響を及ぼしている可能性が高いものと思われる。

(4) 分析結果 (モデル⑥, ⑦)

これまでの分析では、降雨や社会イベントの開催が交通量の変動に影響を与えるという仮定のもと、入力変数として設定していたが、その真偽は不明であった。ゆえに、降水量や社会イベントの開催が予測性能に与える影響を把握する必要があり、両変数を入力に加えたモデル、降水量データを入力から除外したモデル(モデル⑥)、社会イベント開催日ダミーを入力から除外したモデル(モデル⑦)を構築し、交通量予測値の比較を行った。

まず、降雨が連続した2018年9月2日から4日までの下馬上下合計の交通量予測値を比較した。降雨を考慮することにより、1日あたりの交通量予測値が約43台減少(9,318台/日→9,275台/日)していることがわかった。一般に、雨天時は晴天時よりも道路容量が低下し、また観光を目的とした外出機会が減少すると考えられるため、交通量は減少すると考えられる。推計された交通量の減少量は大きなものとは言えないが、注目すべきは降雨が観光交通に与える影響であり、出力された交通量予測値は想定される変化を適切に表していると考えられる。

次に、鎌倉まつりが開催された4月8日から15日までの8日間の交通量予測値を比較した。社会イベントの開催を考慮することで、1日あたりの交通量予測値が約336台増加(8,246台/日→8,582台/日)することが確認された。社会イベントが開催される日は通常日より多くの観光客が来訪し、交通量も増加すると考えられる。構築した学習モデルはこの傾向を保持してお

り、イベントの影響を適切に捉えている可能性が示唆される。

(5) 分析結果 (モデル⑧, ⑨)

これまでの分析から、各学習モデルが観光交通が持つ季節性を捕捉し、降雨や社会イベントの影響を予測に反映していることが確認された。しかし、観光交通予測モデルとしての実適用可能性を評価するためには、混雑発生時期におけるモデルの予測性能を確認することも必要である。そこで、あじさいの開花時期である6月中旬の1週間(6月11日~17日)をテストデータとして学習を実施した。その結果を表-5に示すが、モデル①の結果よりもMAPEが低下していることが分かる。Zhao et al.3)では、5分単位のデータから60分先の交通量予測値を出力しており、そのMAPEは16~17%であった。予測対象とする地点やモデルの学習設定が同一でないため、単純に比較することは難しいが、本研究で構築したモデルが示すMAPEは7~10%であるため、既存モデルに劣らない性能を確保できたと考える。

また、推定された予測値に対して、時間帯別の適合度を確認するため、予測値と誤差率をプロットした結果を図-11に示す。左側の軸が下馬下り車線の断面交通量[台/15分]を右側の軸が誤差率[%]を表す。また、図中の黒破線は下馬下り車線の交通量の観測値、青実線はその予測値である。赤線の棒グラフで示される誤差率を見ると、8時や20時付近よりも日中の方が予測値の当てはまりが良いことが分かる。車両の流入量

表-5 あじさい開花時期の交通量に対する予測性能 (モデル⑧)

	平均交通量 (台/15分)	RMSE (台/15分)	MAPE (%)
下馬下り	96.62	10.82	8.89
下馬上り	102.57	12.37	9.94
下馬上下 合計	199.19	17.71	7.03




図-11 下馬下り交通量の予測値と誤差率 (2018年6月11日~17日) (モデル⑧)

が大きい時間帯に対して、精度の高い予測値が算出されたことは、混雑緩和を目的とした交通政策の立案に対する本モデルの適用可能性を示唆する結果であると考えられる。

3.4 予測の時間解像度と予測範囲の検討

本節では、予測の時間解像度の検討が予測精度に及ぼす影響を検討するため、交通量の集計単位を5分、15分、30分単位にそれぞれ設定した上で予測性能を比較する。併せて、予測範囲の検討を行うため、LSTMによる予測先時間に関しても、30分、60分、90分先変化させた上でそれぞれの予測性能を比較する。予測先を3通り、集計単位を3通りとして計9通りのモデルを構築し、予測性能を比較する。

(1) 予測先の違いによる予測性能の比較

集計単位毎に、予測先の違いによる予測性能の違いを比較した。表-6はRMSEによる比較、表-7はMAPEによる比較をそれぞれ表す。表内の赤字は各集計単位で最も誤差の小さいものを示している。なお、平均交通量は92[台/15分]であった。5分毎60分先の場合を除いて、予測先が将来になるほど予測性能が悪くなっていることが確認された。また、いずれの集計単位においても、予測先の違いによるRMSEの変化が15分あたり0.4台未満という結果となった。

(2) 集計単位毎の予測性能の比較

各集計単位、各予測先の予測結果を5分間交通量、15分間交通量、30分間交通量に再集計し、予測性能を比較したものが表-8~表-13である。表内の赤字は各予測先で最も誤差の小さいものを示している。全体通して、集計単位が小さいほど誤差が大きくなっていることや、5分毎60分先の5分間交通量に対する予測を除き、集計単位と再集計単位が等しいモデルが各予測

表-6 予測先毎のRMSE (台/15分)

集計単位	30分先	60分先	90分先
5分毎	18.40	18.62	18.58
15分毎	10.60	10.62	10.78
30分毎	7.57	7.76	7.87

表-7 予測先毎のMAPE (%)

集計単位	30分先	60分先	90分先
5分毎	16.48	16.73	16.71
15分毎	9.15	9.19	9.27
30分毎	6.54	6.67	6.75

先に対して最も性能が良くなっていることが確認される。

今回のモデルは逐次的に次の時刻のデータを予測していないことから、予測先の違いによる性能の差が小さい結果が得られたと考えられる。また、予測の時間解像度については、集計単位と再集計単位が等しいモデルの予測性能が高いという、深層学習手法に相応しい結果が得られた。これは、集計単位が小さいほど交通量のばらつきの影響を受けやすくなるので、予測の精度が悪くなったと考えられる。したがって、必要とする時間解像度と予測精度のトレードオフを考慮して集計単位を設定する必要性が示唆される。

表-8 集計単位毎のRMSE (台/5分) (再集計単位：5分)

予測先	5分毎	15分毎	30分毎
30分先	6.12	6.38	6.27
60分先	6.44	6.45	6.34
90分先	6.29	6.41	6.35

表-9 集計単位毎のMAPE (%) (再集計単位：5分)

予測先	5分毎	15分毎	30分毎
30分先	16.48	17.50	17.01
60分先	16.73	18.22	17.47
90分先	16.71	17.61	17.63

表-10 集計単位毎のRMSE (台/15分)
(再集計単位：15分)

予測先	5分毎	15分毎	30分毎
30分先	10.89	10.60	10.71
60分先	12.13	10.62	11.05
90分先	11.50	10.78	11.10

表-11 集計単位毎のMAPE (%) (再集計単位：15分)

予測先	5分毎	15分毎	30分毎
30分先	9.57	9.15	9.33
60分先	10.70	9.19	9.70
90分先	10.33	9.27	9.83

表-12 集計単位毎のRMSE (台/30分)
(再集計単位：30分)

予測先	5分毎	15分毎	30分毎
30分先	17.69	18.48	16.96
60分先	20.30	19.22	17.75
90分先	19.04	18.66	17.90

表-13 集計単位毎のMAPE (%) (再集計単位：30分)

予測先	5分毎	15分毎	30分毎
30分先	7.65	8.04	7.21
60分先	8.78	8.50	7.67
90分先	8.39	7.98	7.82

第4章 交通流動マネジメント手法の開発

観光渋滞の緩和を目的とした道路課金政策を念頭において、学習型モニタリング・交通流動予測に基づくエリア内の交通流動マネジメントを検討する。まず、課金設定において基本となる考え方を示す。道路混雑のレベルに応じて課金額を変化させることが望まれるが、混雑は365日24時間で曜日、季節、イベントの実施、時間帯、天気等によって変化する。これらの変化の基本傾向は事前に予測可能な部分があり、それに基づく課金レベルを本研究ではベース課金と呼ぶ(図-12)。また、予測不可能な要素にともない交通量は変動しうるため、各種モニタリング機器による情報でベース課金のレベルを調整することも望まれる。この仕組みを本研究では、リアルタイム観測情報による課金調整と呼ぶ(図-12)。

時間帯別に異なるベース課金の設定に関しては、既存の時間帯別均衡配分が有効と考えられ、課金による需要の変化を考慮できるモデルへの展開が重要となる。そこで、ベース課金の設定の試算例として、時間帯別需要変動型利用者均衡配分を利用した分析フレームを構築し、鎌倉市内を対象とした試算結果を示す。

ただし、時間帯別配分モデルは、時間帯内で交通の定常状態を仮定した静的モデルであり、

交通渋滞の表現は十分ではない。そこで、動的な混雑現象を表現するボトルネックモデルによる分析も有効となる。リアルタイム観測情報による課金調整を念頭において、ボトルネックモデルによる動的混雑課金について、旅行者の反応を見ながら適切な課金額を設定する問題を分析する。より具体的には、強化学習手法を利用した手法について、実験経済学の方法論を利用してその性能を検証する。

一方、ボトルネックモデルには課題も指摘されており、その課題に対応したバスタブモデルを検討する。代替交通手段を考慮していないという課題もあるため、複数交通手段を対象としたバスタブモデルを構築し、それを利用した理論分析を示す。

4.1 交通流動マネジメントに関するレビュー

交通の非定常性、季節、イベント等に応じた大きな変動特性を考慮しなければならない観光渋滞については、モニタリング、交通流動予測に基づく交通流動マネジメントが効果的と考えられる。交通流動マネジメントには、流入制御、信号制御など多様な施策がありうるが、本節では、道路課金による流動制御に関する国内外の研究をレビューする。

特定の地域を対象とした道路課金施策の導入事例としては、シンガポール、ロンドン、ストックホルムなどの海外の都市が有名である。課金の種類は、流入時に課金がされるコードン課金、一日単位で課金がされるエリア課金に大別される。さらに、流出時の課金の有無、走行距離に応じた課金額の設定などで細部に違いが生じる。そこで、最近の研究を踏まえて、課金の導入方式とそれらの特性を整理する。また、地域内の平均的な交通流と交通密度の関係式

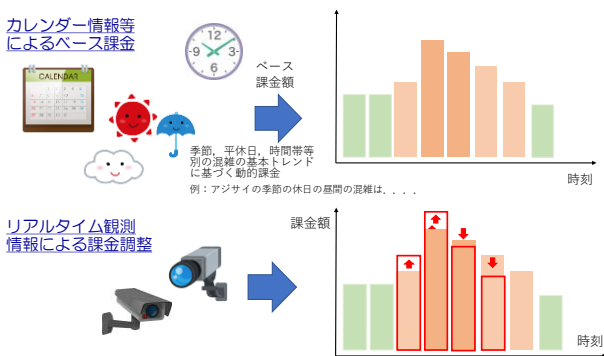


図-12 ベース課金と課金調整の概念

であるMFD (Macroscopic Fundamental Diagram) を利用した課金の検討事例も整理する。

(1) MFDの計測と分析事例に関する既存研究

都市内の交通状態の把握方法として、Daganzo⁴³は対象エリア内における交通流動量と交通密度の関係を集計的にとらえる指標として、Macroscopic Fundamental Diagram (MFD) を提案している。MFDでは、エリア内の流動量を最大とする交通密度が存在することが示されており、Geroliminis and Daganzo⁴⁴は横浜の実都市ネットワークにおいてMFDが存在することを明らかにした。MFDの実測事例はそれを用いた分析方法の拡張が盛んになされている。

日本におけるMFDの実証研究としては、首都高速における流入制御手法に関する割田ら⁴⁵、前原ら⁴⁶の研究がある。阪神高速では、交通シミュレーションとMFDを利用したエリア流入制御が早期から検討されていた(米澤ら⁴⁷)。さらに、王ら⁴⁸は一般道の渋滞を対象に車両感知器により観測されたデータを用いて、MFDの特徴を明らかにするとともに、渋滞領域が現れるメカニズムを分析している。また、尾高ら⁴⁹、尾高ら⁵⁰は、松山市、新潟市、新宿区の各都心部を対象にETC2.0データによるMFDの特性を折れ線回帰分析によって示している。さらに、稲富ら⁵¹は、要人の来日などのイベント時に首都高の車線規制を実施した場合の影響をMFDで分析している。

また、水口・福田⁵²は、観測データの散らばり (scatter) が非常に小さい交通量-密度関係 (Well-defined MFD) が求められるとは限らない状況下でもエリア流入施策を検討せざるを得ない点を指摘している。そして、MFDの形状の不確実性を考慮した交通制御方法について検討している。また、平林ら⁵³は、well-definedなMFDを構成するための適切なエリア分割について、東京都心部の路上感知器データを利用して分析している。また、酒井・赤松⁵⁴は、首都圏高速道路網の長期間観測データの渋滞パターンを年間で8タイプ、日内状態推移を4タイプに分類し、パターンごとにMFDの形状が異なる点を指摘している。

複数交通手段への展開例として、Geroliminisら⁵⁵は、MFDの対象に公共交通も含めた3D-MFDを提案している。壇辻ら⁵⁶は、Zhengら⁵⁷が提案した3D-MFDを利用したバス専用レーンの最適配置の手法を東京都心部への実施している。また、Zheng and Geroliminis⁵⁸は、MFDを利用した動的な駐車料金の設定について分析し

ている。さらにZhong et al.⁵⁹は、MFDの不確実性と需要の変動を考慮した、混雑課金等を想定した制御手法を提案している。

以上で簡単にレビューしたようにMFDの実測と、それを交通流動マネジメントに活用した事例が多数発表されている。

(2) バスタブモデル

経済学者は、MFDを利用した分析をバスタブモデルと呼んでいる。バスタブモデルの名前の由来はVickrey⁶⁰の未公開資料によるとされる。Arnott and Buli⁶¹によると、完全なバスタブモデルの最初は、Small and Chu⁶²であるとされている。Small and Chuは、通勤者の速度が、街路網の交通システムの交通密度に依存する状況をバスタブモデルの近似として解いている。Geroliminis and Levinson⁶³は、通勤者の速度が、街路網の交通システムを流出する際の密度のみに依存するという単純なモデルを提案している。Arnott⁶⁴のモデルは、Vickrey⁶⁰による動的モデルの均衡と最適を求めている。しかし、Arnott and Buli⁶¹によると、以上で紹介したVickrey⁶⁰、Small and Chu⁶²、Geroliminis and Levinson⁶³、Arnott⁶⁴のモデルは、交通流の表現において、improper “不適切”なバスタブモデルであるとしている。

適切なバスタブモデルの例として、Arnott and Buli⁶¹は、Arnott et al.⁶⁵、Fosgerau⁶⁶、Lamotte and Geroliminis⁶⁷の3論文を挙げている。Arnott et al.⁶⁵は、適切なバスタブモデルの特殊例であり、 $\alpha-\beta-\gamma$ 型のトリップは費用関数に基づく出発時刻選択問題が扱われている。Fosgerau⁶⁶、Lamotte and Geroliminis⁶⁷では、異質な通勤者の連続体の常微分方程式モデルが示されている。さらに、Arnott and Buli⁶¹は、適切なバスタブモデルの均衡解を導く計算法を提示している。

Geroliminis and Levinson⁶³やFosgerau and Small⁶⁸は、MFDによる混雑課金の制御で道路網の交通流率を高いものに保つことができれば、Vickreyのボトルネックモデルで考察する場合よりも、ピーク時間が短くなりうるため、課金の効果はより高くなりうることを指摘している。また、Daganzo and Lehe⁶⁹は、トリップ長の異質性の影響を考慮した分析を提示し、トリップ距離と利用時刻依存した混雑課金の効果を分析している。MFDを利用した動的課金の分析例は、Amirgholy and Gao⁷⁰にも見られる。

Zheng et al.⁷¹は、エージェントベーストシミュレーターMATSimとMFDを組み合わせた、動的課金の分析例を示している。そして、チュー

リッヒの都心部への動的コーン課金を検討している。Zheng et al.⁷²⁾は、時間価値の異質性と公共交通を考慮した同様な分析を提示している。また、Simoni et al.⁷³⁾は、MFDと限界費用理論を利用した最適課金を導出している。

以上で紹介したようにMFDは、交通流動制御の経済学的分析にも活用されつつあることが確認できる。

(3) 特定地域を対象とした混雑課金の特性整理

シンガポールで実施されている流入時コーン課金、ストックホルムで実施されている流入流出時コーン課金は、課金領域を通過するたびに課金がなされる。一方、ロンドンのエリア課金は、一日単位で課金がなされ、一旦支払いが済んだのちは、自由に課金区域内を走行できる違いがある。コーン課金とエリア内課金を比較した研究に古くはMaruyama and Harata⁷⁴⁾、Maruyama and Sumalee⁷⁵⁾があり、最適コーン課金額は、最適エリア課金額よりも低いこと、最適料金下での社会的厚生に、コーン課金、エリア課金に大差はないことなどが示されている。さらに高木ら⁷⁶⁾は、エリア課金の最適領域の決定アルゴリズムを提案し、高木ら⁷⁷⁾は、課金領域の形状制約を考慮したアルゴリズムを提案している。円山⁷⁸⁾は、これらの既存研究の知見を以下のように整理している。

(1) 所与の課金領域への最適課金レベルは、エリア課金の値がコーン課金よりも高い。

(2) エリア課金とコーン課金の最適課金領域の形状は大幅に異なる。

(3) 領域を最適化すると、コーン課金による余剰改善は、エリア課金の余剰改善よりも大きい。

(4) 複数領域を最適化することで、単独の課金領域よりも社会的余剰の増加が見込める

(1)の主な理由は、コーン課金は一日単位で複数回課金されるため、一日で一度の課金であるエリア課金がコーン課金と日単位で同程度の総課金額になるためには、エリア課金の額を高く設定する必要があるためである。(2)については、コーン課金は、課金領域内で完結する移動に課金がされないことが一因である。(3)については、コーン課金は、課金領域をまたぐたびに課金されるため、課金領域の設定に敏感に反応し、領域を最適化する効果がエリア課金よりも発現しやすいためである。(4)については、単一の課金領域で単独の課金額を設定するよりも、混雑している地域に多様な課金額を設

定したほうが効果があるためである。以上について、詳しくは円山⁷⁸⁾を参照されたい。このほか、混雑課金研究のレビューとして、例えば、de Palma and Lindsey⁷⁹⁾があり、この他、円山⁸⁰⁾は、和文も含めた2000年から2010年までの混雑課金の研究レビューを示している。ここでは、それら以降の混雑課金の関連論文を簡単にレビューする。Liu et al.⁸¹⁾は、速度に依存したコーン課金の最適化を示している。Liu et al.⁸²⁾は、距離と時間に依存したコーン型課金の最適化問題をロジット型確率均衡モデルを利用しながら分析している。Gu et al.⁸³⁾は、距離と時間に依存したエリア課金をMFDを用いて分析している。Zhang and Sun⁸⁴⁾は、コーン領域の数理表現に基づく最適課金の設計を示している。Gu et al.⁸⁵⁾は、課金の受容に関して研究と事例をレビューしている。Liu et al.⁸⁶⁾は、距離単位課金のロバスト最適化を示している。Liu et al.⁸⁷⁾は付加制約付き確率均衡のもとでの、コーン課金に最適化を変分不等式で導いている。Zhong et al.⁸⁸⁾は、土地利用交通モデルを利用して、混雑課金の土地利用への影響を分析している。

Liu et al.⁸²⁾による分析を紹介する。まず、通常のコードン課金は、課金区域内の走行距離に関係なく一定額であり不公平という指摘から、課金区域内の距離比例課金が提案された。さらに、この方式は、距離完全比例に限らず折れ線型距離依存などもありうる。ただし、単純に距離依存だと、最短距離経路に交通が集中し、混雑しうる問題がある。そこで、距離依存かつ走行時間に依存した課金が提案された。これはタクシー料金に類似したアイデアである。

Liu et al.⁸²⁾は、社会的余剰の最大化を目的関数として、この折れ線関数と課金額について組み合わせ最適化問題を、下位問題をロジット型確率均衡とおいて解いている。その過程で、仮想リンク法、経路エントロピー分解、双対性定理など、交通配分に関連する技術が多様に活用されている。Maruyama and Harata⁷⁴⁾、Maruyama and Sumalee⁷⁵⁾、高木ら⁷⁷⁾、⁷⁸⁾のモデルは、Liu et al.⁸²⁾のモデルと親和性が高く、今後、それらの統合なども検討可能と考えられる。

土木学会⁸⁹⁾には、本章で紹介しているエリア課金、距離依存課金等が整理されている。これらは、非線形課金⁹⁰⁾としてまとめられることもある。これらに対応した交通モデルは基本的に開発されていると理解してよい。

これら多様な課金施策が交通流動のマネジメント施策の候補となりうる。どの施策を導入すべきかは、対象となる地域・都市の特性の

勘案が必要であり、住民の受容性も検討材料となる。

4.2 ベース課金の設定方法の構築と鎌倉市内での試算

本節では、ベースとなる課金方法の検討を行う。利用する方法は、需要変動型利用者均衡配分とする。この配分方法は古典的な分析手法であるが、以下の2点を工夫している。第一に、1時間単位で計算することで、時間帯内での交通流の定常状態を仮定しながらも時間帯別の混雑の変化を考慮したベース課金を設定している。第二に、社会的余剰を最大化する最適なベース課金の料金レベルを時間帯別に計算しつつ、最適な社会的余剰にほぼ近い状況も実現する、許容課金レベルも算出している点である。第三に需要弾力性のパラメータや交通需要量の感度分析を行い、その影響を考察している点である。

(1) 最適料金設定モデルと評価指標の概念整理

最適料金問題を考えるにあたり、標準的な以下の社会的余剰 (SW: Social Welfare) を最大化する問題を考える。この問題は、二段階最適化問題と呼ばれる。上位問題で定まる料金レベルによって、下位問題の需要変動型利用者均衡配分のリンク交通量やOD交通量、所要時間等が変化する。社会的余剰は、それらリンク交通量やOD交通量、所要時間で定まるため、社会的余剰を最大化するような料金を探索することになる。課金領域の最適化等も含めた場合、この問題を解くためには、アルゴリズムの工夫が必要となる。ただし、課金区域を所与として、料金レベルだけを最適化する場合は、料金を少しずつ変化させて、下位問題の均衡配分を繰り返し、社会的余剰が最大化される料金を探索する方法で十分となる。課金区域の候補が複数に限定される場合も、課金区域と料金レベルのすべての組み合わせを計算する解法が理解しやすい。

社会全体の望ましさの効率性指標である社会的余剰は、一般に消費者余剰と生産者余剰の和で表現される。今回の場合の生産者余剰は単純に料金収入である。さて社会的余剰の絶対量そのものを解釈することあまり意味はない。既存研究で利用される式として、無課金時と比較して、どの程度社会的余剰が改善したかの差分である社会的余剰の改善 (Welfare Gain, WG)

が利用される場合がある。さらに、相対的改善指標 (Relative Gain, RG)が利用される場合もある。

これまでの延長として限界費用課金を説明するために、OD間に一本のリンクがあると想定し、そのリンクの所要時間関数を $t(q)$ としよう。限界費用課金とは所要時間関数の微分値に交通量かけたものを料金とするものである。無課金時では、逆需要関数と所要時間関数の交点の交通量が均衡値になる。限界費用課金時には、社会的限界曲線と逆需要関数の交点の交通量が実現値となる。

さて、限界費用課金の例で考えると、無課金時と比べて、このリンクの通行を取りやめている人がいる。具体的にはトリップを取りやめたか、別の交通手段で移動するなどであるが、いずれにせよ、何らかの不利益を受け、その分は消費者余剰の減少として表現される。一方、料金の負荷により交通量は少なくなるため、所要時間は短時間化する。本分析では、時間価値の異質性は考慮していないが、高い時間価値の人は、料金の支払いで、移動の速達性が実現できるので、課金後のほうが望ましい状態になりうる。また、行政等が得た料金収入で、代替交通手段の整備などを行うことができる。これが社会的余剰最大化による課金設定の考え方となる。OD間に複数のリンクがある場合も同様な議論が展開でき、全リンクに限界費用課金が課されることで社会的余剰は最大値をとる。どのような課金を設定してもこれ以上の余剰値は実現しないため、参照点として、その課金時の余剰値を利用している。今回、検討する課金政策は、一部の地域のみを課金対象としており、改善道路課金政策と呼ばれることがある。

(2) データ・設定

鎌倉市内の休日観光渋滞の緩和を目的とした道路課金政策の評価を念頭に、ネットワークデータ等を準備した。データは、国土交通省関東地方整備局から貸与されたものである。元のネットワークデータは、関東地方全域を含み、リンク数が膨大となるため、鎌倉周辺部を中心にリンクを抽出した (図-13)。ネットワークデータには、時間帯別の交通容量と自由旅行速度のデータが含まれており、それらを利用して、BPR型のリンク所要時間関数を設定した。

時間帯別OD交通量についても、貸与された時間帯別OD表を参考に、今回の分析ネットワークに対応したOD表を作成した。元のOD表は全域を対象としたものであり、このうち、図-13の対




図-13 ベース課金と課金調整の概念

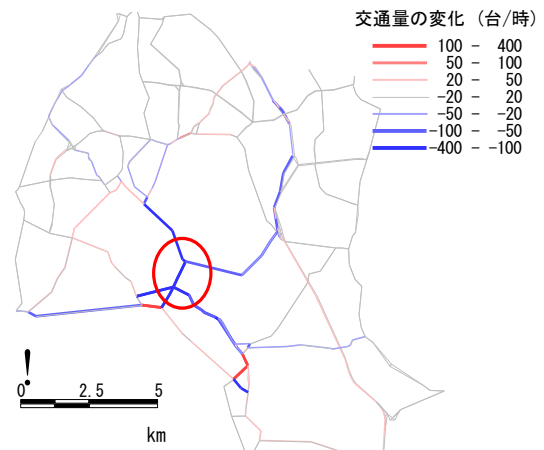


図-14 コードン課金による交通量の変化

象地域に影響を与えるOD交通量を含むように設定している。また、分析対象の時間帯別OD交通量の時間変動パターンが、全域のOD交通量の変動パターンに等しいと仮定して設定している。これは、小さなゾーンでは時間帯別OD交通の十分なサンプルが得られていないことを留意しての設定である。このOD表は、休日の交通量を意図して設定されたものであるが、平日の時間帯別分布にも類似した傾向が見受けられる点には留意が必要である。

今回の研究は、分析フレームの提示と試算に主目的があるため、モデルの現況再現性は確認していない。現実施策の評価を正確に行うことを目的とするのであれば、ネットワークデータ、パラメータの設定、自由旅行時間の設定、交通容量、時間帯別OD交通量の設定を精査する必要がある。以降で、提示する結果も鎌倉での施策評価を念頭においているが、あくまで試算であることに注意が必要である。

(3) 分析結果と考察

図-14に300円の流入時コードン課金を実施したときの7時における交通量変化の試算例を示す。若宮大路や、それに流入する道路の交通量が削減されていることが確認できる。国道134号などの周辺部の道路の交通量が迂回交通などで増加していることも確認できる。図-15には、平均速度の変化を示す。利用しているリンク所要時間関数の性質から当然ながら、交通量が減少しているリンクでは平均速度が向上している。交通容量の大きい高速道路などの道路では交通量変化に対する平均速度の変化は小さいが、鎌倉市中心部の渋滞が緩和していることが読み取れる。

図-16に、コードン課金額を変化させて、時間帯別の計算を多数繰り返し、社会的余剰の改善を算出した結果を示す。図の見方として、7時、

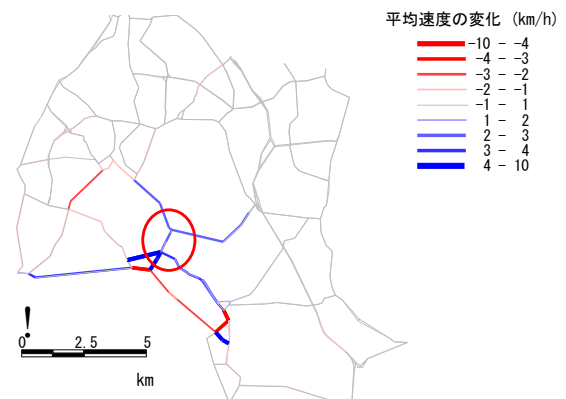


図-15 コードン課金による平均速度の変化

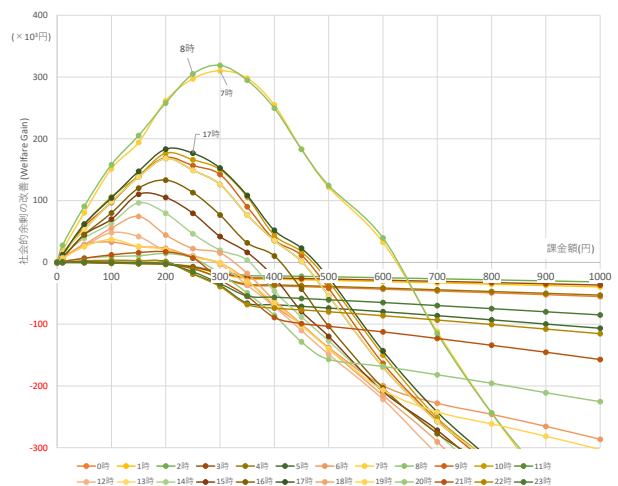


図-16 コードン課金による時間帯別社会的余剰の改善 (WG指標)

8時がほぼ同様な形状となっているが、課金額0円では、現状と変化しないため、余剰改善はゼロである。課金額を増加させると余剰が改善していき、課金額300円程度で最大の余剰改善が実現しているため、これらの時間帯の最適コードン課金額は300円程度となる。これ以上の料金を設定すると、余剰改善は低下する。これは、課金額が高すぎるため、トリップを取りやめる

人が多くなるためと解釈できる。課金額が約650円を超えると余剰改善はマイナスとなり、現状よりも改悪されることになる。次に大きな山型は、17時、9時、10時、13時に観察され、最適コードン課金額は200円となる。夜中の時間帯の余剰改善はわずかであり、最適課金額も0~100円程度になる。このような料金にともなう社会的余剰の改善が山型に算出されるのは既存研究と同様であるが、今回は、時間帯別に計算している点が新規性である。これらは、時間帯の交通量パターンを想定すれば、納得できる結果である。もっとも交通量の多い時間帯は、高い課金を賦課することで、高い余剰改善が期待できる。一方、交通量の少ない時間帯は、課金の必要性は低い。表-14には図-16を表で可視化したものを示す。この表を利用すれば、例えば、時間帯のベース課金を赤い着色部を参考に設定すれば良いという考え方ができる。

図-17には、上記から計算される時間帯別の最適課金額を示す。さらに、30×103円以上の社会的余剰改善が実現する上限と下限の時間帯別課金額も示す。この上下限の課金額は、例えば、図-16で、y軸が30(×103円)以上に社会的余剰が改善する課金額の範囲ということになる。もしくは表-14の値が、30(×103円)以上の値をとる範囲とも言える。既存研究で、このような形式で最適課金の範囲を提示した例は少ない。ピーク時の7-8時では、最適課金の2倍の600円を賦課しても余剰の改善は期待できる。一方、21-22時では、最適課金は200円と算出されるが、これによる余剰改善は、30(×103円)以下であり、現実にはこの時間には課金しないことが望まれる。

以上を踏まえると、本結果をもとにした時間

帯別のコードン課金額としては、深夜から5時までは0円、6時台 100円、7-8時台300円、9-17時台200円、18-19時台100円、20時以降0円という値が提案できる。なお、繰り返しになるが、本計算結果は、試算に過ぎず、現実政策への反映には、モデルの完全による再計算に基づいた考察が不可欠である。

次に社会的余剰の相対的改善指標 (Relative Gain, RG)指標による結果をみたい。前述したように、この値はゼロ課金時を0%、全リンクへ限界費用課金による最適時の社会的余剰を100%と基準化したものである。時間帯別に限界費用課金による社会的余剰の最適値を計算している。このRG指標が最大値となる課金額が、最適コードン課金であり、その課金レベルは表-14と同一である。ただし、余剰値が時間帯別に基準化されることになり、値の解釈がしにくいところがある。例えば、6時~20時台のRG指標の最大値は5-6%程度であるのに対して、5時、21時、22時では、15%を超えることもある。これは、5時、21時、22時台の現時点の交通量は、現在の交通容量に対して適正レベルに近く、課金による効果が発現しやすいとみなせないこともな




図-17 時間帯別の最適コードン課金額と一定の余剰改善を実現するための課金額の上下限

表-14 コードン課金による時間帯別社会的余剰の改善(WG指標) (×103円)

		時間帯																							
		0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23
課金額 (円)	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	10	0	0	0	0	0	0	6	20	28	12	11	16	9	16	10	7	8	13	8	6	1	1	0	0
	50	0	0	0	0	0	2	29	80	91	58	61	53	27	53	39	45	45	62	29	25	7	7	3	1
	100	-1	-1	-1	-1	-1	3	33	152	158	97	106	98	48	98	64	70	80	104	55	37	10	12	3	0
	150	-2	-2	-2	-2	-2	3	26	194	205	140	140	138	42	138	96	110	120	147	74	26	11	16	3	-1
	200	-3	-3	-3	-3	-3	1	23	262	258	170	177	168	19	168	79	105	133	183	44	21	15	17	1	-2
	250	-10	-8	-7	-7	-10	-18	9	297	305	157	166	149	11	149	46	80	113	177	22	8	7	7	-19	-15
	300	-25	-18	-15	-17	-24	-37	-1	310	319	142	150	126	-4	126	20	42	77	153	15	-1	-18	-27	-39	-34
	350	-37	-26	-21	-25	-35	-66	-29	298	295	90	106	77	-37	77	4	16	32	108	-18	-31	-49	-55	-68	-55
	400	-38	-27	-22	-25	-36	-69	-70	255	250	37	44	35	-72	35	-47	-24	10	52	-61	-66	-85	-89	-74	-56
	450	-39	-28	-23	-26	-38	-71	-101	183	183	12	17	2	-110	2	-88	-79	-43	23	-100	-102	-129	-99	-77	-58
	500	-41	-29	-23	-27	-39	-74	-138	122	125	-42	-31	-54	-149	-54	-127	-120	-103	-24	-140	-140	-157	-103	-80	-61
	600	-43	-31	-25	-29	-41	-80	-200	33	40	-163	-150	-170	-222	-170	-207	-209	-203	-143	-215	-207	-168	-112	-86	-65
	700	-46	-33	-27	-31	-44	-86	-228	-112	-115	-256	-252	-258	-310	-258	-277	-272	-277	-242	-290	-242	-182	-123	-93	-70
800	-49	-35	-28	-33	-47	-93	-246	-244	-331	-324	-325	-377	-325	-361	-350	-337	-321	-385	-261	-196	-134	-100	-75		
900	-52	-37	-30	-35	-50	-100	-265	-357	-349	-411	-407	-415	-396	-415	-462	-454	-438	-408	-448	-281	-211	-145	-108	-80	
1000	-55	-40	-32	-37	-53	-107	-286	-429	-431	-525	-519	-534	-420	-534	-517	-535	-559	-520	-471	-303	-225	-157	-115	-85	

い。また、夜間の交通量が少ない時間帯では、利用者均衡がシステム最適にすでに近い状態が実現しており、それに過剰な課金を賦課すると、RG指標が大幅に低下することが示されているとも解釈できる。

なお、RG指標については、ネットワークを明示した分析では、RG=10%~30%程度の範囲が報告されている。本分析のRGは、それらよりも低めであるが、対象地域において課金区域への迂回経路が少ないことなどが影響している可能性はある。また、RG指標では時間帯別の効果の比較がしにくいいため、なく、社会的余剰の改善(WG指標)が、時間帯別のモデルの効果に適していると判断され、以降では、WG指標のみの結果を提示する。

上記に対しては、感度分析も行っているが、ここでは割愛する。

4.3 リアルタイム観測情報に基づく課金の調整方法の検討

リアルタイム観測情報に基づく課金の調整方法を検討するためには、時間軸を考慮した動的な交通モデルを考慮する必要がある。そこで、本節および次節ではday-to-day dynamicsによって1日の中での出発時刻選択が決定され、within-day dynamicsにより経路選択確率が時々刻々と変化する複数ボトルネックモデルを考える。これは、単一ボトルネックにおける出発時刻選択問題を単一もしくは複数ボトルネックを扱えるよう一般化したものである。そして、このような状況に対し、時々刻々変化する交通観測情報(リアルタイム観測情報)に基づく混雑課金の調整を行うことを考える。

この交通システムにおいて、旅行者は各自の一般化旅行費用(目的地への到着時刻と希望到着時刻のズレと総旅行時間を費用換算したもの)を最小化するように出発時刻と経路を選択する。その結果、需要の時間的・空間的集中により待ち行列が生じうる。例えば、旅行者が類似した希望到着時刻を持っている場合、希望到着時刻前後をピークとした待ち行列、すなわち渋滞が発生する。通常の場合、待ち行列が発生せず、ピーク時間帯に全ボトルネックが飽和流率で流れている状態が社会最適状態である。混雑課金の文脈では、交通システム管理者は、流率といった交通状態を観測しながら社会最適状態を達成するように課金額を調整することとなる。

近年、機械学習の分野で強化学習が大きな成果を挙げている。これは、ある環境内において、エージェントが観測した状態を基に行動を決定する際に行動選択の中で報酬を獲得し、その報酬に基づき最適な行動を学習するというものであり、機械学習の一種である。詳細が未知の環境においても学習可能である点から、交通分野への適用が盛んに研究されている。強化学習を採用することにより、各種パラメータの変化に対応可能かつ交通モデルによらず、大量の観測データを活かしたデータ駆動型の動的混雑課金手法が構築できると期待される。

そこで、本節では強化学習を用いた観測データのみに基づくTrial-and-error型の動的混雑課金手法の開発を行う(図-18)。より具体的には、旅行者の意思決定過程と要因の詳細(例:時間価値、早着コスト、遅着コスト等)の各種パラメータの詳細が不明でかつ変化するような現実即した状況のもとで、交通モデルに依存せずに課金額を速やかに最適に近づける学習モデルを構築し、シミュレーションによりその性質を検証する。そして、その枠組みへのリアルタイム情報の組み込みについて検討する。

強化学習の枠組みとしてQ学習を採用する。Q学習は、時刻毎に逐次行動価値を学習する「TD学習(Temporal Difference Learning)」の1つに分類される。Q学習では、行動価値(Q値)の更新に用いる目標値として、「変化後の状態における最大の行動価値」を常に用いる。そのため、方策(行動の決定方式)とは独立に最適行動価値の近似を行うものであり、「方策オフ型TD制御」と言われる。また、Q値の更新には行動価値関数を近似した ϵ -greedy法を用いる。Q学習のアルゴリズムは以下のように記述される。

- (1) 全ての状態、行動に対応するQ値の初期値を設定する。
- (2) あるステップにおけるある状態において、Q値に基づきある行動が選択され、その行動により、次のステップにおいて状態がある状態に遷移する。
- (3) 遷移先の状態に基づきある報酬を獲得する。
- (4) 報酬に基づいて、Q値を更新し、(2)に戻る。




図-18 Trial-and-error型の動的混雑課金のイメージ

ここで、Q値はシステムがある状態にあるときにある行動をとることの価値を表すものである。強化学習は、初期状態ではQ値は真の行動価値とは乖離しているが、行動選択と報酬獲得を繰り返し、Q値を更新していくことで、よりよい行動を隔週する枠組みである。

Q学習を混雑課金による交通システム制御に用いることを考える。このとき、状態は交通データ、行動は課金額の変更、報酬はある適切に定義された関数に対応すると考えられる。このように、状態などの定義は柔軟に行えるため、リアルタイム交通データの取り込みが可能である。

本研究では、Q学習の実装として「中央制御型手法」と「分散制御型手法」の2種類を考える。中央制御型手法は交通需要のピーク時間帯全体の課金額を同時に最適化するもので、状態を「ピーク時間帯内での交通流率ヒストグラム」、行動を「区分線形近似された課金額分布の変更度」、報酬関数を「ピーク時間帯内での待ち時間総和を少なくする行動に良い報酬を与える」ように定義した。一方、分散制御型手法はピーク時間帯を複数の時間帯に分割し、それぞれの時間帯の課金額を個別に最適化するもので、状態を「ある時刻での交通流率、待ち時間」、行動を「ある時刻での課金額の変更度」、報酬関数を「交通流率とボトルネック容量の差を小さくする行動に良い報酬を与える」ように定義した。中央制御型手法と分散制御型手法のイメージを図-19に示す。中央制御型手法と分散制御型手法を比較すると以下のような違いが想定される。十分な学習を経たのちでは、中央制御型手法は全ての時間帯の課金額を同時に最適化するため、分散制御型よりも性能が良いと考えられる。しかし、中央制御型手法では探索すべき行動価値空間が膨大になる（状態・行動の数に応じて指数的に増大する）ため、学習が遅いと考えられる。特に、大きな交通システムへの適用は実際上不可能な恐れがある。中央制御型手法はアルゴリズムを一つだけ適用し、分散型制御手法はアルゴリズムを時間帯数分だけ適用する形となる。




図-19 中央制御型手法と分散制御型手法のイメージ

提案手法を様々な状況に対してシミュレーションとして適用し、交通制御手法の効率性を検証した。具体的には、以下の要件を確認した：

- (1) 単一ボトルネックモデルの場合
 - (a) 学習時のパラメータ値の設定が制御効率に及ぼす影響の検証
 - (b) 学習サイクル数が制御効率に及ぼす影響の検証
 - (c) 交通モデルパラメータの差異が制御効率に及ぼす影響の検証
- (2) 複数ボトルネックモデルの場合
 - (a) 学習時のパラメータの値の設定が制御効率に及ぼす影響の検証

「学習時のパラメータの値の設定が制御効率に及ぼす影響の検証」の結果を述べる。 ϵ は学習過程でどれだけ積極的に新たな方策を試すかを示すパラメータで、 e はday-to-day dynamicsの収束判定に用いるパラメータである。これらのパラメータ値を様々に変えて感度分析を行った。中央制御型、分散制御型ともに適するパラメータ値が異なること、パラメータ値によっては待ち時間を減らせないことがわかった。以降の分析では、この分析で判明した最適な ϵ と e の値を用いるとする。

「学習サイクル数が制御効率に及ぼす影響の検証」では、Q学習のサイクル数についての感度分析を行う。本手法を所定のサイクル数学習させ、交通システムに適用した場合の総待ち時間の分布を確認することで、最適なサイクル数を検証する。なお、総待ち時間が分布する理由は、本学習手法は確率的要素を含むため、同一の初期状態から学習を開始しても乱数シードに応じて異なる学習をするためである。中央制御型の場合はサイクル数を増やすと平均総待ち時間が減少する傾向にあること、分散制御型の場合はサイクル数10以上であればあまり変化がないこと、中央制御型と分散制御型を比較すると中央制御型は総待ち時間が非常に大きくなる場合が多く学習が不安定であること、などがわかった。よって、今回のシミュレーションにおいては、分散制御型手法が優れていると判断し、以降の分析では分散制御型のみ用いる。

「交通モデルパラメータの差異が制御効率に及ぼす影響の検証」では、既往研究の手法と比較する形で、時間価値や総需要などの交通モデルパラメータの差異が制御効率に及ぼす影響を検証する。時間価値の想定が異なる場合には既存手法は課金額をうまく調整できない一方、提案手法はすみやかに待ち時間を減らすことに成功した。総需要の想定が異なる場合にも、提

案手法は比較的すみやかに待ち時間を減らすことに成功した。これらの結果より、提案手法の既存手法に対する優位性が確認できた。この特性は、交通モデルパラメータの事前の特定が困難な観光混雑に対して特に有用といえるだろう。

「複数ボトルネックモデルの場合の学習時のパラメータの値の設定が制御効率に及ぼす影響の検証」について述べる。複数ボトルネックの場合、交通モデルの複雑度が増すため、この分析に限って行うこととした。また、ボトルネックの数は2とした。全体的に各ボトルネックにおける待ち時間は減少傾向にあるものの、パラメータ設定によっては片方のボトルネックのみ待ち時間が減少しないなどの現象がみられた。パラメータ間の差異は小さいものの、最適なパラメータ値はいずれにせよ存在することがわかる。

最後に、提案手法の適用結果を図-20に示す。総待ち時間の推移をみると、待ち時間がおおむね単調に減少している。また、時間帯別総待ち時間の推移では、待ち時間がすべての時間帯でおおむねに単調に減少している。さらに、時間帯別課金額の推移では、ピーク時に課金額が増え、三角形型の最適課金に近づいていることがわかる。


4.4 強化学習による動的混雑課金手法の実験 経済学的検証

前節では、当該手法をシミュレーションにより検証した。すなわち、交通システムや被験者の選択行動をコンピュータシミュレーションにより再現し、当該手法が渋滞を解消できるか実験的に検証した。その結果、日数が経過するとともに渋滞待ち時間が減少することが確認できた。しかし、シミュレーションを用い旅行者が単純で合理的な行動をおこなうと仮定されているため、その現実性は明らかではないという限界があった。


そこで、開発した強化学習による動的混雑課金手法を実際の人間に適用し、その性能を検証する。すなわち、実験経済学の方法論を用い、多数の被験者に交通シミュレータ上で交通行動を行わせ、それに対して混雑課金による制御を行い、制御の性質を検証する。

実験の全体的な流れは以下の通りである。

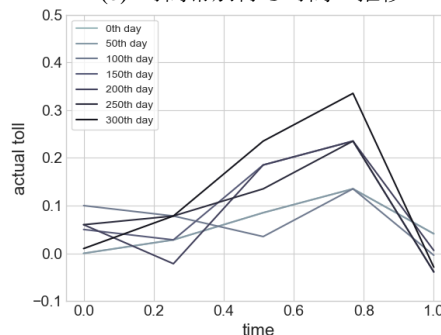
- (1) 被験者を集める
- (2) 被験者に実験の概要や実験システムの



(a) 総待ち時間の推移



(b) 時間帯別待ち時間の推移



(c) 時間帯別課金額の推移

図-20 強化学習による最適課金額の推定

操作方法を説明する

- (3) 実験システムを初期化し、 $i:=0$ とする。
- (4) 被験者が実験システムにログインする
- (5) 被験者が実験システム上で*i*日目の行動を選択する。
- (6) 実験システムが交通シミュレーションにより*i*日目の交通状況を計算する。
- (7) 実験システムが*i+1*日目の課金額を決定する。
- (8) *i*が最終日でない場合、 $i:=i+1$ としてステップ5に戻る。
- (9) 各被験者の総効用を計算し、報酬として配布する。
- (10) 実験終了

実験は計3回行った。実施日は2020年11月21日であり、時刻は1回目が11:00～、2回目が14:00～、3回目が16:00～であった。実験は東京大学対面授業基準に則ったCOVID-19対策のもと実施した。被験者が密集するのを避けるため、会

場は東京と大阪に分けて設置し、Zoom (<https://zoom.us/>) と Amazon Web Service (<https://aws.amazon.com/>) を使って接続した。被験者はweb調査会社のモニターから募集した。被験者数は1回目が34名、2回目が32名、3回目が40名であった。それぞれの実験で100日分の交通行動を再現した。

被験者属性は、男女はほぼ同数、年齢層は20代~70代まで幅広い。職業は多くが一般会社員、自動車や高速道路の運転頻度は高めである。また、オリンピック混雑課金への賛否を訪ねたところ賛成の方が多かった。混雑課金という概念を認識している被験者が多かったと考えられる。

実験システムについて述べる。本システムは全体を統括する「Webサーバ」、交通シミュレーションと課金額決定を行う「交通学習シミュ」、被験者に情報を示し行動を入力させる「Webブラウザ上アプリ」からなる。その構造を図-21に示す。「Webサーバ」と「交通学習シミュ」はAmazon Web Serviceのクラウドサーバ上に構築した。「交通学習シミュ」は前年度開発した強化学習による動的混雑課金手法に基づく。「Webブラウザ上アプリ」は通常のWebブラウザで閲覧できるように設計し、スマートフォンからでも容易に操作ができるようにした。

「Webブラウザ上アプリ」では、各被験者が前日の交通状況と当日の課金額を見ながら出発時刻を選択し、全員の行動が終わったら行動結果と獲得効用が表示されるものである。その画面表示を図-22に示す。

前述の通り、実験は計3回行った。しかし、1回目の実験は被験者が想定外の行動をとり、課金手法が不適切な挙動を示したため分析の対象外とする。これは、被験者の出発時刻が余りに集中した場合、元の課金手法の挙動を微調整するための項の値が巨大になってしまい、手法の挙動を支配してしまうためである。2,3回目の実験ではそのようなことが生じないように手法を改良したため問題は生じなかった。以下では2,3回目の実験結果について述べる。

結果評価のため、以下の指標を用いる：

- ・個人の効用：待ち時間、早着時間、遅着時間、課金額の加重和。効用を計算する式は被験者に提示し、獲得した総効用に比例して報酬が支払われる。被験者は効用を増加させるように行動することが期待される。

- ・社会的余剰：個人の効用から課金額分を引いたものの総計。課金手法は社会的余剰を増加させるように働くことが期待される。

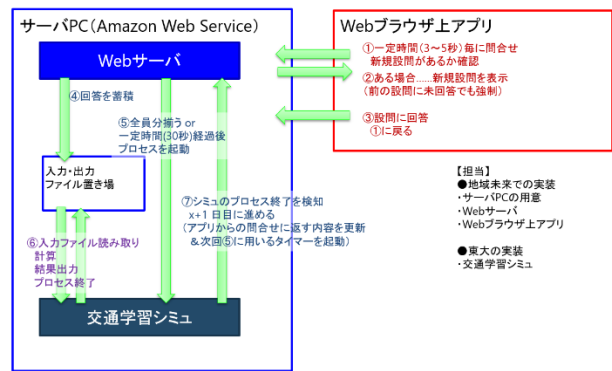


図-21 実験システムの構造



図-22 「Webブラウザ上アプリ」の画面遷移

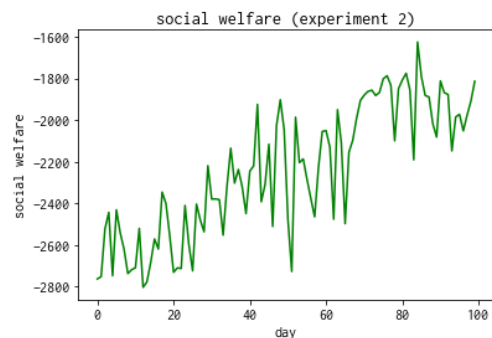


図-23 社会的余剰の推移




図-24 「Webブラウザ上アプリ」の画面遷移

2回目の実験の社会的余剰の推移を図-23に示す。日数が経過するにつれて社会的余剰が増加していることがわかる。出発時刻分布の標準偏差の推移を図-24に示す。日数が経過するにつれて出発時刻が分散していくことがわかる。以上のことから、課金手法は全体としては混雑を解

消し、効率的な交通システムの実現に向かって
いることがわかる。それぞれの個人が獲得した
効用の分布を確認したところ、実験を通して個
人ごとの効用が広く分布していることがわか
る。個人ごとの実験前半と後半の平均効用の推
移からは、前半から後半にかけてうまく効用を
増加できた人とできなかった人がいることが
わかる。

以上の結果を踏まえ、本手法の性質について
考察する。まず、本手法は日数の経過とともに
渋滞を低減させ社会的余剰を増加させる傾向
にあると言える。これは、2回目、3回目の実験
ともに同様の結果を示したことからわかる。こ

の点はシミュレーション実験での性質とも同
様である。一方、渋滞を低減させる速度は比較
的遅い。この点はシミュレーション実験の結果
と異なる。個人ごとの獲得する効用には大きな
差がある。また、混雑課金により旅行者全体の
効用が増加すること(2回目)もあれば減少する
こと(3回目)もあることがわかった。このこと
は、提案手法は平等性の観点から課題を抱えて
いることを示唆する。このことはシミュレーシ
ョン実験では全く見られなかった現象であり、
本実験の大きな成果である。今後は、この効用
の差の原因を分析することが研究課題となる
だろう。

第5章 解析基盤の開発

5.1 異種情報を融合した交通状態補間手法の検討

(1) 交通量補完モデル

時点 t に観測された断面交通量（上り線）をまとめたベクトルと断面交通量（下り線）をまとめたベクトルを準備する。また、空間相関パターン（近接する道路リンクとは値が類似するという性質）を有するベクトルを導入し、回帰係数と残差の空間相関パターンを捉えるために使用される。断面交通量（方向別）を(i)回帰項（回帰係数に空間相関を仮定）、(ii)空間相関する残差、(iii)ノイズで説明しようというモデルを構築した。精度良くモデル化するためには(i)と(ii)を柔軟にモデル化することが特に重要である。

回帰計数のシステムモデルでは、回帰係数の空間相関と時間変化をモデル化した。また、残差のシステムモデルでは、交通量の急激な時間変化を捉えるために、Generalized Hyperbolic (GH) 分布に従うと仮定する。同分布は正規分布、 t 分布、コーシー分布等の幅広い分布を包含する柔軟な分布として知られている。GH分布の交通流推計への応用はみられないものの、GH分布を用いることで交通量の急激な変化が精度よくモデル化できることを確認済みである。上下線に共通のGH分布を仮定することで、交通量の時間変化パターンを推定することとした。また、Generalized Inverse Gaussian (GIG) 分布に従う潜在変数も導入し、上下線共通と仮定した。分布の尖度を定めるパラメータがあり、値が大きいほど分布の裾が厚くなる（交通量の急増・急減が起りやすくなる）。一方で、分布の歪度を定めるパラメータは、値が正に大きい場合は分布の裾が正に伸び（交通量の極端な増加が起りやすくなる）、値が負に大きい場合は分布の裾

が負に伸びる（交通量の極端な減少が起りやすくなる）ことを表す。

これらのモデルを元に、交通量の観測されていない道路リンク（以下、未観測リンク）における交通量を推計する方法を説明する。なお、以下では上り線を対象に説明を行うが、下り線の場合も同様である。

いま未観測リンク(上り)の交通量を推定するために、同リンクにおける交通量（未知）に回帰モデルを仮定し、期待二乗誤差最小化により交通量を推定する。

(2) 実データでの検証

鎌倉市内のトラフィックカウンター（以下、トラカン）で2018年6月に観測された断面交通量（5分間隔；上り26箇所、下り23箇所）に開発モデルをあてはめることで、市内の主要道路リンク（237リンク）の交通量（5分間隔；上下線別）を推計する。各パラメータを逐次的にMonte Carloサンプリング（サンプル数：200）によって生成することで、期待二乗誤差を最小化する交通量を近似的に求める。

年間の断面交通量の平均値のプロットから、鎌倉市内では特に南部海沿いの国道134号線での交通量が多いことや、上下線の交通量が比較的類似したパターンを持つことなどを確認し、推計される交通量もまた同様の傾向を持つことが期待される。

交通量推計精度の向上の第一歩として説明変数の検討を行なった。まずは平均気温やイベント期間ダミーのような時点毎（全リンクで共通の値）の説明変数についての予備的検討を行った。その結果、時点毎の効果は定数項に吸収されるため、時点毎の説明変数の投入は推計精度の改善につながらないことが明らかとなった。この結果を踏まえ、今回は時点毎（全リン

クで共通の値)の説明変数は用いない。

今回用いる説明変数は以下の通りである：

[A] 携帯GPS密度：特定のスマートフォンアプリケーションの利用者の5分おきの位置座標を収集したデータ（出典：ポイント型流動人口データ；株式会社Agoop提供）。2018年6月の1日あたりの平均標本数は53,784。

- ・各道路リンクから半径50m圏内の5分おきのGPS点数（以後、携帯GPS密度）を説明変数として用いる
- ・高時間解像度：5分おきに集計
- ・低精度：捕捉率（0.01%程度）が低く標本に偏りがある可能性がある。

[B] 滞留人口密度（月）：NTTドコモが提供するアプリケーションのユーザーから推計される250mメッシュ毎の滞留人口密度（出典：混雑統計；株式会社ゼンリデータコム提供）。時間帯別・日別の人口密度だと欠損値が多くなるため（滞留人口が一定未満の場合は秘匿化される）。

- ・各道路リンクの重心点を含む250mメッシュの滞留人口密度（月平均）を説明変数として用いる
- ・中時間解像度：月平均

- ・中精度：月平均のため標本の偏りの影響は比較的小さいが、集計元の日別データに欠損が高いため、ある程度の偏りは存在する可能性がある。

[C] 滞留人口密度（年）：

- ・各道路リンクの重心点を含む250mメッシュの滞留人口密度（年平均）
- ・低時間解像度：年平均
- ・高精度：年平均であり、標本の偏りは小さいと考えられる。

上でまとめた通り、[A]は高時間解像度・低頻度、[B]は中時間解像度・中精度、[C]は低時間解像度・高精度である。

(3) パラメータ推定結果

交通量推計モデルを観測交通量にあてはめることで推定された道路リンク毎・時点毎の回帰係数の推定値を図-25にプロットした。ここでは6/2(土)～6/5(火)の12時（下り）の推定値をプロットした。図中の赤い道路リンクは、回帰係数が特に正に大きく強い説明力が示唆されたリンクを表す。

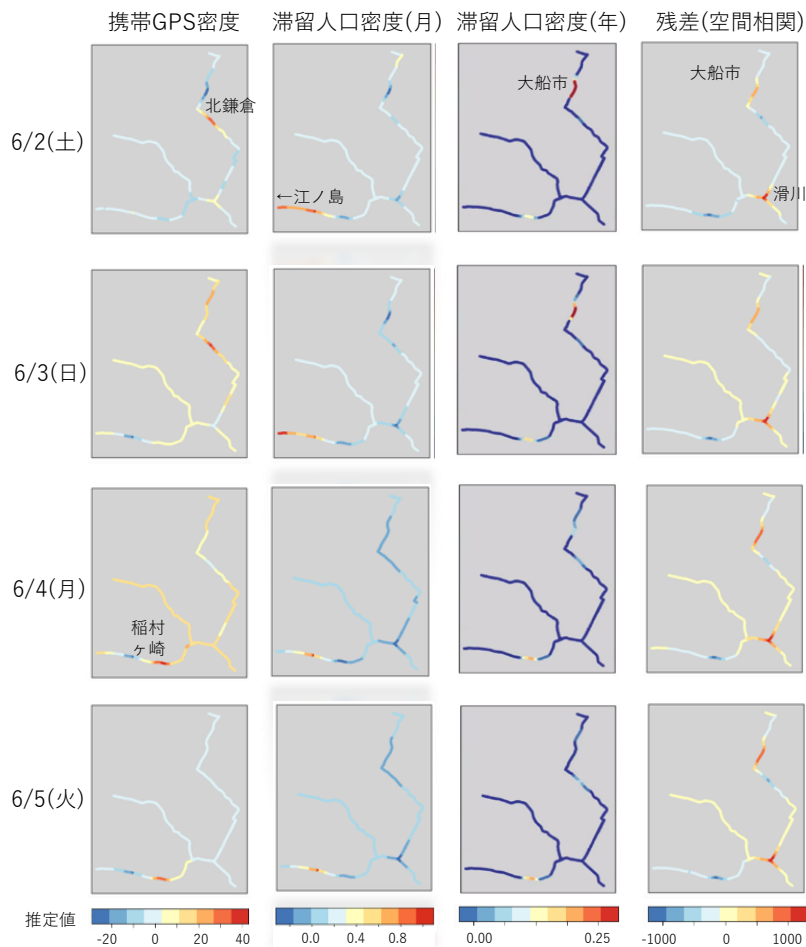


図-25 道路リンク毎の回帰係数の推定結果

携帯GPS密度の回帰係数は北鎌倉と稲村ヶ崎で大きな値を示す傾向が見られた。両地域は両側を山または海で挟まれた道路網が疎な地域であり、GPS点の道路への割り付けが比較的うまくいった地域である可能性がある。この結果から、携帯GPS密度は道路網が疎な地域の交通量推定精度を改善するうえで特に有用との示唆を得た。

滞留人口密度（月平均）の回帰係数は江の島方面に向かう道路で土日に大きな値となった。6月の江の島は観光客でにぎわう。滞留人口密度（月平均）は江の島方面への自動車交通量の増加を捉える上で有用であった可能性がある。

滞留人口密度（年平均）の係数は大船市街地の入り口にあたるエリア並びに稲村ヶ崎付近で高い値となった。両地域が交通量の特に多い地域であることを踏まえると、本結果は直感に整合する。

最後に、残差の空間相関パターンは、滑川交差点付近や大船市市街地に向かう道路において局所的に高い値となった。このことから、残差の空間相関を考慮することで局所的な混雑が捉えられることを確認した。

以上より、提案モデルを用いることで交通量を説明すると考えられる各変数からの影響を、解釈しやすい形でモデルに組み込むことができるとの示唆を得た。

次に、交通量の急増・急減の起こりやすさのパラメータの推定値から、夜間に交通量が急増・急減しにくく、昼間は一様に急増・急減が起こりやすい点、各日が平日・休日を問わず類似した時間変化パターンを持つことなどが確認された。

(4) 交通量の補間結果

2018年6月1～31日の道路リンク別の交通量を推計した。まずは、観測値と推定値の類似性を評価するために2日（火）と5日（水）について、観測値の存在する道路リンク（北鎌倉～鎌倉駅前の中間にある1観測点、鎌倉駅前の1観測点）における観測値と推計値を比較した。上り下りともに観測交通量のパターンを精度良く推計できていることが確認できた。また上りと下りで交通量に差のある鎌倉駅前の一点においては上下線の差が適切に推定されていることもまた確認できる。以上より、上下線別の推定を行う交通量推計モデルを用いることで、より実態と整合した交通量推計が行えることを確認した。

最後に、2018年6月2日（土）の全道路リンクの交通量推計結果を図-26に、6月5日（火）の推計結果を図-27にそれぞれプロットした。6月2日の結果からは、上下線で交通量のパターンに違いがみられることや、上りは長谷交差点付近で

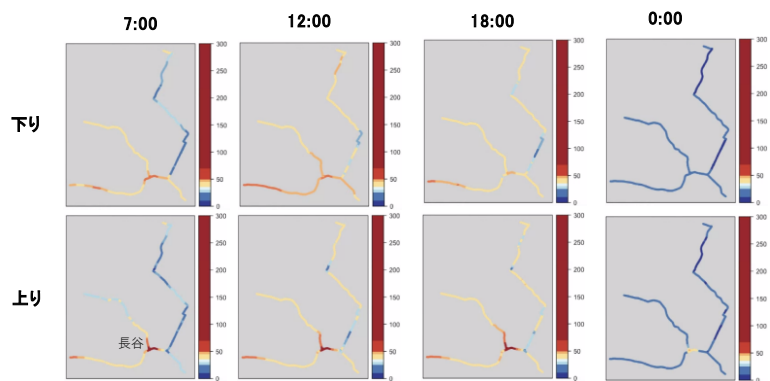


図-26 休日（2018/6/2土）の交通量推定結果

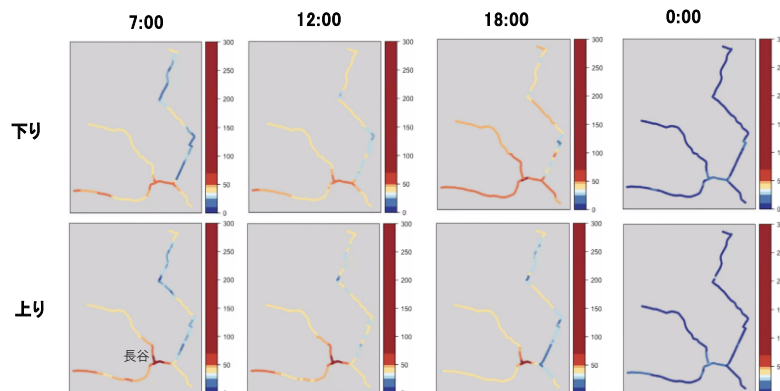


図-27 平日（2018/6/5火）の交通量推定結果

常時混雑している傾向がみられ同エリアがボトルネックであることが推定された。主要道路が交わる同ゾーンで交通量が増加するという本結果は直感に整合する。また、上下線とも江の島に向かう道路が混雑する傾向があるが特に下りにその傾向が顕著であった。

6月5日結果からは上りの長谷交差点付近が混雑するという推定結果が得られた。一方、休日とは異なり18時台の下り線の交通量が増加している傾向が確認できる。これは帰宅ラッシュの影響を受けたものと考えられる。以上の各結果は直感に整合する。

最後に、補完モデルの補完精度を検証した。ここでは、観測地点の中の1つをデータセットから除外したデータセットで同地点の観測値を推計（補完）するという操作を繰り返すことで全地点の交通量を推計して、同推計値と観測値を比較した。この結果から概ね良好な予測精度となっていることが確認できた。地点毎の決定係数の中央値は0.72（最大値0.93，最小値0.22）であり、概ね良好な精度で交通量が補完されたことを確認した。

5.2 解析基盤へのデータ同化の導入と深層学習による大規模解析に基づく最適化手法の開発

解析基盤プラットフォーム対して、学習型モニタリング・交通流動予測を考慮し、観測データとシミュレーションを同化するための枠組みとして大規模解析に基づくAIを介した最適化手法を、異種データ統合や異なる順解析の組み込みなど拡張性に留意しつつ開発し、その有効性を確認した。具体的には、順解析と、観測データと数値シミュレーション結果を同化するためのBig Data & Extreme Computing (BDEC)環境に適したデータセントリックなAIを介した最適化手法を組み合わせ、OD逆推定問題で有効性を確認した。本節では、BDEC環境に適したデータセントリックなAIを介した最適化手法を概説し、これを用いたOD逆推定の例を示すことで本手法の有効性を示す。本節で用いている順解析には精度向上の余地があるのでその検討を行うか、異種データ統合や異なる順解析の組み込みなど拡張が容易である点を活用して他の順解析を導入することで、本手法の信頼性を高めることが可能と考えられる。

IoTや5Gの進展や解析能力の向上に伴い、大量の観測データが高速にsupercomputing環境に

流し込まれ、その高速処理が期待される、大量データの利活用を前提としたData-Centric SupercomputingであるBig Data and Extreme-Scale Computing (BDEC)が増加してきている (ex, BDEC2: Big Data and Extreme-Scale Computing 2, <https://www.exascale.org/bdec/>など)。分散配置されたIoT機器から5Gにより大量データを遍在する計算機資源を動的に割り振り、蓄積されたデータを活用しつつ、新たな観測データへの評価を行い、付加価値をつける。

(1) BDEC環境に適したAIを介した最適化によるOD逆推定手法

ネットワーク最適化問題として、上述の手法によりOD逆推定問題を解くことを考える。各Originから車が道路ネットワークに流入し各Destinationから道路ネットワークの域外に流出する際に、道路ネットワーク上で観測されている交通流の時刻歴にそぐうようにODを逆推定することとなる。具体的には、観測しているネットワーク内でのリンクの観測交通量との誤差を表す関数Errを定義し、最小化する。

ここでは、順解析と深層学習を連成して、BDEC環境下で高速で最適化を行う。BDEC環境では、大量のデータを計算機に一気に入力して処理することが可能である。複数パターンへの入力による順解析を並列計算により処理し、高速に「入力データ-観測量」のデータセットを得るとともに、この得られたデータをDeep Neural Network (DNN)により学習し、入力データ-観測量を与えるAI (サロゲートモデル) を構築する。このようにすることで、シミュレーションの逐次的な処理や複雑な計算を減らして、最適化に必要な実時間の短縮を図ることが基本的なアプローチである。

本アプローチでは、まず n_0 の解候補（サンプル）を生成し、これを用いた順解析を行う。この順解析により、「入力データ-観測量」のデータセットを得る。次に、このデータセットを用いて、順解析の代替となるサロゲートモデルをDNNにより構築する。この際、Errの回帰モデルではなくErrの値に基づいた階級分けのサロゲートモデルをDNNによって構築する。このサロゲートモデルは入力から誤差そのものではなく、誤差の大きさに応じた階級を推定するモデルであり、回帰モデルよりも頑健な評価を進めることができ、高速に解近傍の解候補が得られることが期待される。このように構築したDNNによって、 $n_1 (>> n_0)$ の入力パラメータからErrの値が小さい n_0 個のサンプルを選択し、

これに対して、順解析を行って Err を計算し、 Err が最小になった入力パラメータが観測データにそぐう解 x_{best} として選択することとする。これらの過程を繰り返すことで、徐々に x_{best} が最適解に近づいていくことが期待され、適切な性能の解が得られた時点で最適化を打ち切ることとなる（今回は、この繰り返しはせずに x_{best} が得られた時点で最適化を打ち切っている）。このように、サロゲートモデルとして構築した DNN によって膨大な数のデータの候補の中から解候補を選択するため、必要とされる順解析の回数を大幅に減らし、計算コストを抑えながら大量のデータの評価を高速に行い、より良い解候補の探索が行えることとなる。

(2) BDEC環境に適したデータセントリックなAIを介した最適化によるOD逆推定適用

OD 逆推定に本手法を適用することでその有効性を検証する。上述のように、ここでは、OD 逆推定は、ネットワーク内で観測される時刻歴の交通量により各 $origin$ からネットワークに流入してくる時刻歴交通量の $destination$ 別の内訳を推定する問題を考えている。OD 逆推定をリアルタイムで行うことで、交通シミュレーションとの併用により将来のネットワーク内の交通量予測ができるため、ロードプライシングなどの交通渋滞に対する方策に関するリアルタイム意思決定などへの応用が期待される。従来から、OD 逆推定に関する研究が行われており、カルマンフィルタや粒子フィルタとシミュレーションを組み合わせた解法など数多くの手法が提案されている。本手法は、多数の計算ノードを並列使用可能な BDEC 環境を前提とし、観測データとシミュレーションの差のネットワーク誤差最小化のプロセスを、DNN も組み込みつつ並列処理に適したように新たに開発することで超高速なネットワーク最適化実現を目指したものであり、従来の研究とは一線を画すものとなっている。

本検討で対象とする道路ネットワークを図-28に示す。この道路ネットワークは鎌倉の主要幹線を模しており、59 のノードと 240 リンクで構成され、また、各リンクは上下線に分かれており、有向グラフネットワークとなっている。この道路ネットワーク外からの来訪車両が交通量の多くを占めるため、来訪車両に関する OD 交通量を推定する（来訪車両の推定と問題の単純化のため、車両がネットワーク内部を OD としたり、ネットワーク内に入る車両が $origin$ と同じ場所を $destination$ としたりする

ような状況は想定しない）。 $origin/destination$ は 6 つとし、車両がこれらの 6 つのノードのいずれかを $origin$ としてネットワーク域内に流入し、 $origin$ となった点以外の 5 つのノードを $destination$ としてネットワーク域外に流出する交通流を発生させ、14 箇所の観測リンクにおいて時刻歴交通量が観測される問題を考え、観測データにそぐう OD ペア別の時刻歴交通量をネットワーク最適化により推定することを目的とする。

今回は実観測交通量を参考に、時刻 it 、OD ペア (i,j) における参照 OD 交通量を設定し (OD 逆推定で推定する正解に相当)、これを用いた順解析により $nobs$ 個の各観測リンクにおける参照時刻歴交通流を生成した (正解の OD により生成される交通流に相当)。なお、ここで用いる順解析は各有向リンクを構造グリッドに離散化しそのグリッド内を追い越し挙動なども可能とした車両エージェントが移動し、各エージェントが、現在自身が存在している位置と、 $destination$ の情報から最適な経路を選択して隣接するノードやリンクへの移動を行い、 $destination$ へ向かっていくモデルを用いており、複雑な離散非線形動的ネットワーク挙動を考慮することが出来ているが、交通実挙動の再現性を高めるためには信号や交差点の精緻な組み込みなどの追加検討が必要と考えられる。上記の参照 OD 交通量に対する参照観測時刻歴交通流、および解候補 OD 交通量に対する観測時刻歴交通流のいずれも、一時間毎に設定された OD 交通量を順解析の 1 ステップ (=10 秒) 単位に変換し、本道路ネットワーク上で順解析を行うことにより求めている。

誤差を最小化するように前述のアルゴリズムの流れにより最適化を行う。まず、 $n0=1,000$ 個の OD 交通量を過去の実績値に一樣分布の乱数を足しこんで生成した。その際、各流入点においてネットワークに流入するエージェン




図-28 本検討で対象とする道路ネットワーク

トの総交通量が過去の実績値と整合するように各時刻で変化しないように調整を行った。これを以降 datasetA と呼ぶ。datasetA の各交通量を用いて順解析を行い、各観測点において交通流を求めた。パラメータ数が 90 と多めであり、また、各パラメータの可動範囲も広いことから、1,000 程度のサンプルでは良い解が拾えていない。


次に、この順解析結果を用いて深層学習により DNN を構築する。各観測点で計算した Err の最大値と最小値の間に 10 個の区間に分割し、Err の値が小さい順に、各区間に含まれるサンプルに階級 $L_i (i=0-9)$ を与え、学習に用いるデータセットを $n_0=1,000$ 個作成した。これを用いて OD 交通量から階級を推定する DNN ($l=1-nobs$) を観測リンクごとに構築した。各 DNN の入力 は 3 次元のデータであり、1 時間ごとの OD 交通量を 1 次元のデータ x に変換している。この x と L の関係を学習させる形で、一般的な階級推定に用いられる全結合の DNN (活性化関数は Relu(中間層) と cross-entropy(出力層)、ユニット数、層数はそれぞれ 60, 4) を構築する。構築には PyTorch を用いた。optimizer は Adam(学習率 0.001) を用い、空間的に観測リンクの誤差との相関のないパラメータを棄却するために L1 正則化を行い(係数は $\lambda=10^{-4}$)、エポック数は 1,000、バッチサイズを 200 として学習を進めた(1000 個のサンプルのうち、800 を学習、200 を検証に用いて正答率を検証した)。階級は、実際に計算された誤差を分割している値であるため、正確に値を推定するのではなく、おおよその値が分かればよい、そのため、推定値が正解の前後 1 階級であっても許容した場合の正答率が高水準であれば利用できると考えられる。前後 1 階級を許容した場合の正答率が高い状態となっていたので、これらの DNN で最適化を進める。

datasetA と同様に過去の実績値と整合するように生成した $n_1=109$ の OD 交通量を DNN に入力し、各交通量に対する L_i を求める。この総和を評価することで、リンク毎にも全体として誤差の小さい交通量が選択されることを期待し、総和が小さく、かつ、 $L_i < 3$ となる交通量を 1000 選択する。これを以降 datasetB と呼ぶ。datasetB の各交通量に対して順解析を行い得られた交通流により、ネットワーク全体での誤差 Err を評価した。初期のランダムサンプリングによる datasetA により得られた Err の分布と比較して、DNN を介した解空間の拘束により観測データとの誤差が小さく交通量が


datasetB として選択された。datasetB における Err の最小は 1.42 となっており、この場合の OD 交通量の例を図-29 に示す。参照解と比較して良好に一致していることが分かる。

一方、従来手法のひとつである焼きなまし法により 1,000 回反復(順解析 1,000 回分の実時間)で最適化を試みた。焼きなまし法で対応の工夫をしない場合には、ランダムサンプリングにおける最良の解よりも精度の低い解が得られることが分かった。これに対し、本手法ではランダムサンプリングよりも精度の良い、ヒューリスティックな解を高速で得られることが確認できた。

なお、観測リンクの数だけ DNN を構築する必要が生じるが、BDEC 環境下では、DNN の構築やこれを用いた評価が並列して行うことができるため、DNN の数の増加が最適化の実行時間への影響を及ぼさない。このため、実質順解析回数分の計算時間と DNN での計算時間のみの時間の実質数分以内で最適化を行うことができる。



(a) 正解



(b) 提案手法による推定

図-29 本検討で対象とする道路ネットワーク

第6章 まとめ

6.1 研究の総括

本研究の成果は以下の通りである。

- ・テーマ1: 学習型モニタリングシステムの構築
定点カメラ, GNSS, Wi-fi, 衛星を対象として, データ同化に基づく統一的アプローチによるモデル開発を行った。定点カメラによる車・人の認識・追跡に対して, 深層学習を導入したモデルを開発し, 物体数・追跡の同時推定手法への拡張を行った。また, GNSSとWi-fiデータを統合し, 保存則に基づくメッシュ単位での滞在人数・移動人数の同時推定モデルを開発した。さらに, 超小型衛星を見据え, 深層学習による車両密度推定手法, 高分解能・高画質化手法の開発を行った。
- ・テーマ2: 交通状態予測システムの構築
車両の時間的な集中度合いを短期(30~90分後)で予測するための深層学習による分析枠組みを構築した。交通量等のデータは, 時間方向に強い依存性を持つ時系列データであるため, 深層学習において時系列データの予測に適しているモデルであるLSTMをベースとした。実データに対して, 季節ごとに設定したモデルの予測精度, 降水量や社会イベントの影響, 混雑時期の予測精度に関して検証を行い, 車両流入が多い時間帯において, 誤差率が低くなることを確認した。
- ・テーマ3: モニタリング・予測に基づくエリア内交通流動マネジメントスキームの構築
動的課金の枠組みを整理し, 基本トレンド(季節, 平休日, 時間帯等)に基づくベース課金と, リアルタイム観測情報に基づく課金調整の手法を開発した。トレンド・ベース課金においては, 時間帯別需要変動型利用者均衡配分に

よるモデルを開発した。鎌倉市内へのコードン課金施策を対象とした試算結果から有用な知見を得た。また, リアルタイム観測情報による課金調整においては, トライ&エラーによる課金調整に対して強化学習を導入した手法を開発した。実験経済学の枠組みによる実験を実施し, 個人の行動変容を分析した。

- ・テーマ4: 基盤技術の開発

テーマ間の連携を強化するため, 特性が異なる, あるいは, 観測データが得られない部分に対して, 任意リンクにおける補間をするための動的時空間モデルを開発した。さらに, モニタリング, 予測, 補間において得られるリンク上での交通状態から, リアルタイムに個別車両の行動等を推定する手法を開発した。ここでは, データ同化の導入を進め, 観測データとシミュレーションの差異を効率的に解消するための深層学習を用いた大規模解析に基づく最適化手法を開発した。開発手法を, OD逆推定問題に対して適用し, 手法の有効性を確認した。

6.2 今後の展望

各テーマにおいて, 学習型手法として開発を行ってきた。いずれも, 学習データを確保することが必要になるため, その方法論を検討することも重要になる。また, 深層学習一般の問題として, 解釈困難性が存在する。この問題に対して, 説明可能なAI手法を導入することにより, モデルと結果の解釈を可能にすることが期待される。また, 説明変数の自動選択の仕組みを導入し, 解釈と推定精度の両者を向上するための拡張が考えられる。また, 他都市への展開も考えられる。

本研究の成果は汎用性を有するものである。さらなる精度向上・安定化・高速化により、その利用可能性が益々高まることが期待される。観測機器のスペック等を特定するための知見も有用となる。また、短期予測の困難さも指摘されているところであるが、より現実に即した予測手法として活用が期待できる。トレンド・ベース課金では政策に資する知見が得られている。また、トライ&エラー課金により混雑解消が確認でき、こちらも実務に資する内容と考えられる。

参考文献

- 1) Seo, T., Bayen, A. M., Kusakabe, T. and Asakura, Y.: Traffic state estimation on highway: A comprehensive survey, *Annual Reviews in Control*, Vol.43, pp.128-151, 2017.
- 2) 加藤文和, 深尾隆則, 羽下哲司: 対象追跡フレーム間の類似度に着目した手法から動きのモデルに着目した手法まで, 情報処理学会研究報告コンピュータビジョンとイメージメディア, Vol.2005, No.88 (2005-CVIM-150), pp.185-198, 2005.
- 3) Lucas, B.D and Kanade, T.: An iterative image registration technique with an application to stereo vision, *Proceedings DARPA Image Understanding Workshop*, pp.121-130, 1981.
- 4) 布施孝志, 母里明陽: ステレオビデオカメラによる複数人物追跡の可能性, 応用測量論文集, Vol.20, pp.15-22, 2009.
- 5) Zhao, T. and Nevatia, R.: Tracking multiple humans in complex situations, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.26, No.9, pp.1208-1221, 2004.
- 6) Wu, B. and Nevatia, R.: Detection and tracking of multiple, partially occluded humans by Bayesian combination of edgelet based part detectors, *International Journal of Computer Vision*, Vol.75, No.2, pp.247-266, 2007.
- 7) 布施孝志, 中西航: 歩行者挙動モデルを統合した人物自動追跡手法の構築, 土木学会論文集 D3, Vol.68, No.2, pp.92-104, 2012.
- 8) 小林貴訓, 佐藤洋一: 分散センサ情報の統合によるエリア内人物追跡と動線推定, 情報処理学会研究報告コンピュータビジョンとイメージメディア, Vol.2008, No.36 (2008-CVIM-163), pp.231-246, 2008.
- 9) Mahler, R.: Multitarget Bayes filtering via first-order multitarget moments, *IEEE Transactions on Aerospace and Electronic Systems*, Vol.39, No.4, pp.1152-1178, 2003.
- 10) Vo, B.-N., Singh, S. and Doucet, S.: Sequential monte carlo implementation of the phd filter for multi-target tracking, *Proc. Int'l Conf. on Information Fusion*, pp.792-799, 2003.
- 11) Ristic, B., Clark, D. and Vo, B.-N.: Improved smc implementation of the phd filter, *Proc. 13th IEEE Conference on Information Fusion*, pp.1-8, 2010.
- 12) Pan, S.J., Yang, Q., et al.: A survey on transfer learning, *IEEE Transactions on knowledge and data engineering*, Vol.22, No.10, pp.1345-1359, 2010.
- 13) Ma, C., Huang, J.-B., Yang, X. and Yang, M.-H.: Hierarchical convolutional features for visual tracking, *Proceedings of the IEEE international conference on computer vision*, pp.3074-3082, 2015.
- 14) Cui, Z., Xiao, S., Feng, J. and Yan, S.: Recurrently target-attending tracking, *Proceeding of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016.
- 15) 総務省情報通信政策研究所: 位置情報の利用に対する意識調査, 2014.
- 16) 寺田雅之, 永田智大, 小林基成: モバイル空間統計における人口推計技術, *NTT DOCOMO テクニカル・ジャーナル*, Vol.20, No.3, pp.11-16, 2012.
- 17) 布施孝志, 原田遼: 詳細な交通行動推定のためのアクティビティシミュレーションと観測データの統合に関する研究, 土木計画学研究・講演集, Vol.57, 2018.
- 18) Schauer, L., Werner, M. and Marcus, P.: Estimating crowd densities and pedestrian flows using wi-fi and Bluetooth, *Proceedings of the 11th International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services*, pp.171-177, 2014.
- 19) 森本哲郎, 辻本悠佑, 白浜勝太, 上善恒雄: Wi-fi パケットセンサを用いた人流解析と可視化, データ工学と情報マネジメントに関するフォーラム(DEIM2015)論文集, 2015.
- 20) 中西航, 小林巴奈, 都留崇弘, 松本拓朗, 田中謙大, 菅芳樹, 神谷大介, 福田大輔: Wi-fi パケットセンサーによる観光周遊パターンの把握可能性, 第 55 回土木計画学研究発表会・講演集, 2017.
- 21) Iwata, T., Shimizu, H., Naya, F. and Ueda, N.: Estimating people flow from spatiotemporal population data via collective graphical mixture models, *ACM Transactions on Spatial Algorithms and Systems*, Vol.3, pp.1-18, 2017.
- 22) Akagi, Y., Nishimura, T., Kurashima, T. and Toda, H.: A fast and accurate method for estimating people flow from spatiotemporal population data, *Proceedings of the 27th International Joint Conference on Artificial Intelligence*, pp.3293-3300, 2018.
- 23) Koshi, M., Iwasaki, M., Ohkura, I. and Nishimiya, R.: A study on the phenomena of congested traffic flows, *Proceedings of the Japan Society of Civil Engineers*, Vol.1981, No.306, pp.59-70, 1981.
- 24) 瀬尾亨, 日下部貴彦: 衛星画像とプローブカー軌跡を用いたネットワーク交通状態推定のシミュレーション分析, *交通工学論文集*, Vol.5, No.2, pp.A_1-A_10, 2019.
- 25) Zhang, L., Zhang, L. and Du, B.: Deep learning for remote sensing data, A technical tutorial on the state of the art, *IEEE Geoscience and Remote Sensing Magazine*, Vol.4, No.2, pp.22-40, 2016.
- 26) 樋口知之: 粒子フィルタ, *電子情報通信学会誌*, Vol.88, No.12, pp.989-994, 2005.
- 27) Kitagawa, G.: Monte carlo filter and smoother for non-Gaussian nonlinear state space models, *Journal of Computational and Graphical Statistics*, Vol.5, No.1, pp.1-25, 1996.
- 28) Thrun, S., Burgard, W. and Fox, D.: *Probabilistic Robotics*, MIT Press, 2005.
- 29) Evensen, G.: Sequential data assimilation with a nonlinear quasi-geostrophic model using Monte Carlo methods to forecast error statistics, *J. Geophys. Res.*, Vol.99, No.C5, pp.10143-10162, 1994.
- 30) Gordon, N. J., Salmond, D. J. and Smith, A. F. M.: Novel approach to nonlinear / non-Gaussian Bayesian state estimation, *Radar and Signal Processing, IEE Proceedings F*, Vol.140, No.2, pp.107-113, 1993.
- 31) Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. and Wojna, Z.: Rethinking the inception architecture for computer vision. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.2818-2826, 2016.
- 32) Dalal, N.: Inria person dataset, <http://pascal.inrialpes.fr/data/human/>.
- 33) Faezetta: Vehicle make and model recognition dataset (vmmrdb), <https://github.com/faezetta/VMMRdb>.
- 34) 岩崎学: カウントデータの統計解析, 朝倉書店, 2010.
- 35) 藤田藍斗, 今泉友之, 彦坂修平: CNN を用いた高空間解像度衛星画像からの地物抽出, *人工知能学会全国大会論文集*, Vol. JSAI2016, 2016.
- 36) 山下隆義: イラストで学ぶディープラーニング, 講談

- 社, 2016.
- 37) 神谷啓太, 布施孝志, 泉裕一朗: 空中写真を用いた市街地における車両認識手法の適用可能性の検証, 応用測量論文集, Vol.28, pp.99-107, 2017.
- 38) Hochreiter, S. and Schmidhuber, J.: Long short-term memory, *Neural Computation*, vol. 9, no. 8, p. 1735-1780, 1997.
- 39) Ke, J. Zheng, H., Yang, H. and Chen, X.: Short-term forecasting of passenger demand under on-demand ride services: A spatio-temporal deep learning approach, *Transportation Research Part C: Emerging Technologies*, Vol. 85, pp. 591-608, 2017.
- 40) Liu, L. and Chen, R.-C.: A novel passenger flow prediction model using deep learning methods, *Transportation Research Part C: Emerging Technologies*, Vol. 84, pp. 74-91, 2017.
- 41) Xu, C. Ji, J. and Liu, P.: The station-free sharing bike demand forecasting with a deep T learning approach and large-scale datasets, *Transportation Research Part C: Emerging Technologies*, Vol. 95, pp. 47-60, 2018.
- 42) Polson, N. G. and Sokolov, V. O.: Deep learning for short-term traffic flow prediction, *Transportation Research Part C: Emerging Technologies*, Vol. 79, pp. 1-17, 2017.
- 43) Daganzo, C. F.: Urban gridlock: Macroscopic modeling and mitigation approaches, *Transportation Research Part B: Methodological*, Vol. 41, No. 1, pp. 49-62, 2007.
- 44) 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.
- 45) 割田博, 桑原雅夫, 吉井稔雄, 稲富貴久: 首都高速道路における集計 QK を用いたエリア流入制御の適用に関する研究, 土木計画学研究・講演集, Vol. 49, 2014.
- 46) 前原慎也, 吉井稔雄, 高山雄貴: MFD を用いた流入制御手法に関する研究, 土木計画学研究・講演集, Vol. 49, 2014.
- 47) 米澤悠二, 吉井稔雄, 北村隆一: 集計 QK を用いたエリア流入制御の実施効果検証, 土木計画学研究・論文集, Vol. 26, No. 3, pp. 561-568, 2009.
- 48) 王鵬飛, 和田健太郎, 赤松隆, 杉田正俊, 名古屋利一, 鷺見浩: 長期間観測データを用いた Macroscopic Fundamental Diagram の特徴づけ: 仙台市および京都市におけるケース・スタディ, 交通工学論文集, Vol. 2, No. 5, pp. 11-20, 2016.
- 49) 尾高慎二, 吉井稔雄, 神戸信人: ETC2.0 データを活用した都心部における Macroscopic Fundamental Diagram に関する研究, 土木計画学研究・講演集, Vol. 56, 2017.
- 50) 尾高慎二, 吉井稔雄, 藤井浩史, 神戸信人: プローブデータを活用した MFD の特性及び要因に関する基礎的研究, 土木計画学研究発表会・講演集, Vol. 57, 2018.
- 51) 稲富貴久, 割田博, 桑原雅夫, 吉井稔雄: 首都高速道路における大規模イベント開催時を対象とした集計 QK を用いた流入制御に関する研究, 土木計画学研究・講演集, Vol.53, pp. 1572-1575, 2016.
- 52) 水口正教, 福田大輔: MFD 形状の不確実性を考慮した最適なエリア流入制御に関する基礎的検討, 土木計画学研究発表会・講演集, Vol. 56, No. P38, pp. 1-9, 2017.
- 53) 平林新, 壇辻貴生, 福田大輔, 葛乾: 都市内道路網の空間分割手法の実証比較分析, 土木計画学研究発表会・講演集, Vol. 57, 2018.
- 54) 酒井高良, 赤松隆: 首都圏高速道路網における渋滞パターンと MFD の関係性, 回土木計画学研究発表会・講演集, Vol. 58, 2018.
- 55) Geroliminis, N., Zheng, N., Ampountolas, K.: A three-dimensional macroscopic fundamental diagram for mixed bimodal urban networks, *Transportation Research Part C: Emerging Technologies*, Vol. 42, pp. 168-181, 2014.
- 56) 壇辻貴生, 鄭楠, 福田大輔: Multimodal Macroscopic Fundamental Diagram に基づくバス専用レーンの都市空間内最適配置に関する研究-東京都心部への適用-, 土木計画学研究発表会・講演集, Vol. 55, 2017.
- 57) Zheng, N., Dantsuji, T., Wang, P., Geroliminis, N.: Macroscopic Approach for Optimizing Road Space Allocation of Bus Lanes in Multimodal Urban Networks Through Simulation Analysis, *Transportation Research Record: Journal of the Transportation Research Board*, Vol. 2651, No. 1, pp. 42-51, 2017.
- 58) Zheng, N. and Geroliminis, N.: Modeling and optimization of multimodal urban networks with limited parking and dynamic pricing, *Transportation Research Part B: Methodological*, Vol. 83, pp. 36-58, 2016.
- 59) Zhong, R. X., Chen, C., Huang, Y. P., Sumalee, A., Lam, W. H. K., & Xu, D. B.: Robust perimeter control for two urban regions with macroscopic fundamental diagrams: A control-Lyapunov function approach, *Transportation Research Part B: Methodological*, Vol. 117, pp. 687-707, 2018.
- 60) Vickrey, W. S.: Congestion in Manhattan in relation to marginal cost pricing, Memo, Columbia University. Notational Glossary, 1991.
- 61) Arnott, R. and Buli, J.: Solving for equilibrium in the basic bathtub model, *Transportation Research Part B: Methodological*, Vol. 109, pp. 150-175, 2018.
- 62) Small, K. A. & Chu, X.: Hypercongestion, *Journal of Transport Economics and Policy*, Vol. 37, No. 3, pp. 319-352, 2003.
- 63) Geroliminis, N. and Levinson, D. M.: Cordon Pricing Consistent with the Physics of Overcrowding, *Transportation and Traffic Theory 2009: Golden Jubilee*, No. 1995, pp. 219-240, 2009.
- 64) Arnott, R.: A bathtub model of downtown traffic congestion, *Journal of Urban Economics*, Vol. 76, pp. 110-121, 2013.
- 65) Arnott, R., Kokoza, A., Naji, M.: Equilibrium traffic dynamics in a bathtub model: A special case, *Economics of Transportation*, Vol. 7-8, pp. 38-52, 2016.
- 66) Fosgerau, M.: Congestion in the bathtub, *Economics of Transportation*, Vol. 4, No. 4, pp. 241-255, 2015.
- 67) Lamotte, R. and Geroliminis, N.: The morning commute in urban areas with heterogeneous trip lengths, *Transportation Research Part B: Methodological*, Vol. 117, pp. 794-810, 2018.
- 68) Fosgerau, M. and Small, K. A.: Hypercongestion in downtown metropolis, *Journal of Urban Economics*, Vol. 76, No. 1, pp. 122-134, 2013.
- 69) Daganzo, C. F. and Lehe, L. J.: Distance-dependent congestion pricing for downtown zones, *Transportation Research Part B: Methodological*, Vol. 75, pp. 89-99, 2015.
- 70) Amirgholy, M. and Gao, H. O.: Modeling the dynamics of congestion in large urban networks using the macroscopic fundamental diagram: User equilibrium, system optimum, and pricing strategies, *Transportation Research Part B:*

- Methodological, Vol. 104, pp. 215–237, 2017.
- 71) Zheng, N., Waraich, R. A., Axhausen, K. W., Geroliminis, N.: A dynamic cordon pricing scheme combining the Macroscopic Fundamental Diagram and an agent-based traffic model, *Transportation Research Part A: Policy and Practice*, Vol. 46, No. 8, pp. 1291–1303, 2012.
- 72) Zheng, N., R erat, G., Geroliminis, N.: Time-dependent area-based pricing for multimodal systems with heterogeneous users in an agent-based environment, *Transportation Research Part C: Emerging Technologies*, Vol. 62, pp. 133–148, 2016.
- 73) Simoni, M. D. D., Pel, A. J. J., Waraich, R. A. A., Hoogendoorn, S. P. P.: Marginal cost congestion pricing based on the network fundamental diagram, *Transportation Research Part C: Emerging Technologies*, Vol. 56, pp. 221–238, 2015.
- 74) Maruyama, T. and Harata, N.: Difference Between Area-Based and Cordon-Based Congestion Pricing: Investigation by Trip-Chain-Based Network Equilibrium Model with Nonadditive Path Costs, *Transportation Research Record: Journal of the Transportation Research Board*, Vol. 1964, pp. 1–8, 2006.
- 75) Maruyama, T. and Sumalee, A.: Efficiency and equity comparison of cordon- and area-based road pricing schemes using a trip-chain equilibrium model, *Transportation Research Part A: Policy and Practice*, Vol. 41, No. 7, pp. 655–671, 2007.
- 76) 高木良太, 円山琢也, 溝上章志: エリア課金の最適設計問題: 課金領域・レベルの決定アルゴリズムの構築と適用, *土木学会論文集 D3 (土木計画学)*, Vol. 67, No. 5, pp. 67_I_1233-67_I_1242, 2011.
- 77) 高木良太, 円山琢也, 溝上章志: 混雑課金領域の形状制約を考慮した最適設計手法の構築と適用, *土木学会論文集 D3 (土木計画学)*, Vol. 70, No. 1, pp. 88-101, 2014.
- 78) 円山琢也: 領域形状に着目した次善混雑課金の政策分析, *応用地域学研究*, Vol. 20, No. 20, pp. 13-22, 2016.
- 79) de Palma, A. and Lindsey, R.: Traffic congestion pricing methodologies and technologies, *Transportation Research Part C: Emerging Technologies*, Vol. 19, No. 6, pp. 1377–1399, 2011.
- 80) 円山琢也: 都市域における混雑課金の政策分析: レビューと展望, *土木計画学研究・論文集*, Vol. 26, No. 1, pp. 15-32, 2009.
- 81) Liu, Z., Meng, Q., Wang, S.: Speed-based toll design for cordon-based congestion pricing scheme, *Transportation Research Part C: Emerging Technologies*, Vol. 31, pp. 83–98, 2013.
- 82) Liu, Z., Wang, S., Meng, Q.: Optimal joint distance and time toll for cordon-based congestion pricing, *Transportation Research Part B: Methodological*, Vol. 69, pp. 81–97, 2014.
- 83) Gu, Z., Shafiei, S., Liu, Z., Saberi, M.: Optimal distance- and time-dependent area-based pricing with the Network Fundamental Diagram, *Transportation Research Part C: Emerging Technologies*, Vol. 95, pp. 1–28, 2018.
- 84) Zhang, L. and Sun, J.: Dual-based heuristic for optimal cordon pricing design, *Journal of Transportation Engineering*, Vol. 139, No. 11, pp. 1105–1116, 2013.
- 85) Gu, Z., Liu, Z., Cheng, Q., Saberi, M.: Congestion pricing practices and public acceptance: A review of evidence, *Case Studies on Transport Policy*, Vol. 6, No. 1, pp. 94–101, 2018.
- 86) Liu, Z., Wang, S., Zhou, B., Cheng, Q.: Robust optimization of distance-based tolls in a network considering stochastic day to day dynamics, *Transportation Research Part C: Emerging Technologies*, Vol. 79, pp. 58–72, 2017.
- 87) Liu, Z., Meng, Q., Wang, S.: Variational inequality model for cordon-based congestion pricing under side constrained stochastic user equilibrium conditions, *Transportmetrica A: Transport Science*, Vol. 10, No. 8, pp. 693–704, 2014.
- 88) Zhong, S., Wang, S., Jiang, Y., Yu, B., Zhang, W.: Distinguishing the land use effects of road pricing based on the urban form attributes, *Transportation Research Part A: Policy and Practice*, Vol. 74, pp. 44–58, 2015.
- 89) 土木学会: 道路交通需要予測の理論と適用 第II編 利用者均衡配分モデルの展開.
- 90) Lawphongpanich, S. and Yin, Y.: Nonlinear pricing on transportation networks, *Transportation Research Part C: Emerging Technologies*, Vol. 20, No. 1, pp. 218–235, 2012.

(2021年??月??日受理)

道路政策の質の向上に資する技術研究開発 成果報告レポート No.30-3
学習型モニタリング・交通流動予測に基づく観光渋滞マネジメントについての研究開発

2021.6