

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. 29-4

研究テーマ

観光流動把握を目的とした
交通流動推定システムの研究開発

研究代表者：京都大学教授	宇野 伸宏
共同研究者：京都大学特命教授	西田 純二
東京都立大学教授	清水 哲夫
岐阜大学教授	倉内 文孝
京都大学准教授	シュマッカー・ヤンディヤク
宮崎大学准教授	嶋本 寛
名古屋大学特任准教授	中村 俊之
北海道大学准教授	杉浦 聡志
京都大学助教	木村 優介

令和 2 年 〇 月

新道路技術会議

目次

研究概要	1
第1章 はじめに	3
1.1 研究目的・背景	3
1.2 研究体制	3
1.3 本報告書の構成	4
第2章 移動体データによる交通流動の観測	6
2.1 はじめに	6
2.2 データの収集状況	6
2.3 Wi-Fi パケットセンサによる分析	8
2.4 おわりに	12
第3章 自動車トリップパターン推定モデルの構築	13
3.1 はじめに	13
3.2 トリップパターン推定モデルの構築	13
3.3 仮想ネットワークを用いた精度検証	15
3.4 先験 OD 確率作成方法の検討	16
3.5 ETC2.0 データによる経路選択傾向の考察	16
3.6 MFD を用いた交通状況評価	18
3.7 推定結果を用いたトリップパターン評価	18
3.8 おわりに	20
第4章 乗客トリップパターン推定モデルの構築	21
4.1 はじめに	21
4.2 乗客トリップパターン推定モデル	21
4.3 実規模ネットワークにおける推定精度検証	22
4.4 2018 年秋におけるトリップパターン推定	25
4.5 おわりに	27
第5章 トリップチェーン推定手法の構築	29
5.1 はじめに	29
5.2 トリップチェーン推定手法の構築	29
5.3 仮想ネットワークにおけるモデルの適用	30
5.4 GNSS データを用いたトリップチェーン推定手法の試行	30
5.5 2018 年秋季の京都におけるデータへのトリップチェーン推定手法の適用	33
5.6 おわりに	36

第6章 交通マネジメント方策の影響分析に関する基礎分析	37
6.1 はじめに	37
6.2 トリップパターンから見た観光地交通対策の影響分析	37
6.3 時間消費を考慮した観光流動分析	41
6.4 おわりに	44
第7章 まとめ	45
7.1 研究成果	45
7.2 今後の課題	46

**「道路政策の質の向上に資する技術研究開発」(平成29年度採択)
研究概要**

番号	研究課題名	研究代表者
No.29-4	観光流動把握を目的とした交通流動推定システムの研究開発	京都大学 教授 宇野 伸宏

都市内での実効性の高い、観光・交通需要マネジメントを実現するため、OD 交通量推定モデルを核とし、各種移動体データを活用しつつ、観光流動をはじめとする都市内のトリップベースの交通流動（トリップパターン）およびトリップチェーンを把握可能な交通流動推定システムの構築を実施する研究開発。

1. 研究の背景・目的

観光立国をめざす我が国にとって円滑な観光流動の実現のためには、自動車とともに人流を推定し、その変化を評価することが不可欠である。需要の平準化等の交通マネジメント施策の評価には、交通流動変化を捉える必要がある。一方道路交通センサ等の交通調査は秋季の平均的な状況を対象とし、観光等季節変動の激しい交通需要やインバウンド観光を把握できない等の課題がある。各種ビッグデータが蓄積されつつある今、それらを活用した交通流動推定手法を確立できれば、道路交通施策の継続的な改善に寄与すると考えられる。以上を踏まえ、様々なビッグデータを利活用し、観光行動を主とした都市内の移動を対象に時空間上の変動を分析し、トリップパターンおよびトリップチェーン流動を推定するシステムを開発するとともに、観光・交通マネジメント方策の効果検証を目指した。

2. 研究内容

研究目的を達成するために、次の4点の研究・開発を行った。1)移動体通信データによる繁忙期または交通マネジメント方策実施時の交通流動観測。モバイル空間統計データ、ETC2.0 データ、交通量感知器データ、経路探索履歴データを収集するとともに、Wi-Fi パケットセンサを京都市内の主要観光スポット等に設置し、人の流動の観測を実施した。2)自動車トリップパターン推定モデルの構築。最小二乗推定量をベースとし、自動車トリップベースのOD交通量推定モデルを構築した。空間的な交通移動を主モデルで、交通量の時間的な伝播を副モデルで表現した。3)乗客トリップパターン推定モデルの構築・検証。路線バスの利用者を主対象として、公共交通ネットワーク上の乗客のトリップパターンを推定するモデルを構築した。バス系統単位の乗降を表すレグODを推定した上で、乗り換えを考慮した真のODであるジャーニーODを推定する方法とした。4)トリップチェーン推定モデルの構築・検証。2), 3)にて得られる自動車・乗客のトリップパターンを所与とし、GNSS データを用いてトリップチェーンを推定する方法を開発した。加えて1), 2), 3)の成果を活用し、京都市を対象に観光・交通マネジメント方策の効果検証も試みた。

3. 研究成果

本研究により得られた代表的な研究成果を列挙する。1)移動体データ、特に Wi-Fi パケットセンサデータを活用した分析の結果、系列パターンマイニング手法の適用により、観光客の代表的流動パターンを明らかにした(図-1)。2)自動車トリップパターン推定モデルにより、動的トリップパターンを推定した結果、入力データに応じて日生成交通量や時間パターンは変化しており、観測交通量に整合した動的トリップパターンを推定することを確認した(図-2)。3)京都市バスネットワークを対象に乗客トリップパターン推定モデルを構築し、仮想的な入力データを作成して、推定精度の検証を行った。加えて繁忙期の2018年11月休日のトリップパターンの推定を行った。4)上記2), 3)の推定結果を所与として、属性別・時間帯別のトリップチェーンを推定するモデルを構築した。推定結果より個人属性によって選好が異なること、季節変動による影響等を提案したモデルにより表現可能であることを確認した。5)一連の




図-1 頻出代表的観光パターン




図-2 時間帯別生成交通量(土曜日)

研究成果を活用し、京都市を対象に観光・交通マネジメント方策の効果検証も試みた。知見の例としては、MFD(Macroscopic Fundamental Diagram)分析から、交通対策と関係して東山地区において、若干の交通流動性の改善が、そして嵐山地区では交通需要の抑制が確認できた。また、観光客の集中する清水エリアにおいては、Wi-Fi パケットセンサデータを用いて時間軸上の行動特性に基づき分類し、ピーク時間帯の来訪者の時間分散の可能性について考察した。

4. 主な発表論文

平井一成, 嶋本寛: 大規模ネットワークにおける2段階乗客トリップパターン推定モデルの精度検証, 第60回土木計画学研究・講演集, CD-ROM, 2019.

東川晃久, 木村優介: Wi-Fi パケットセンサを用いた観光街路空間における歩行者流動の解析手法の検討, 第60回土木計画学研究・講演集, CD-ROM, 2019.

明光就平, 倉内文孝, 伊藤伸: Wi-Fi パケットセンサを用いた代表的観光パターン抽出, 第60回土木計画学研究・講演集, CD-ROM, 2019.

佐竹克仁, 宇野伸宏, 中村俊之: Wi-Fi パケットセンサを用いた観測間隔を考慮した代表的観光周遊パターン分析, 第60回土木計画学研究・講演集, CD-ROM, 2019.

浅尾啓明, 宇野伸宏, 木村優介, 西田純二: ビッグデータの横断的活用の可能性, 第60回土木計画学研究・講演集, CD-ROM, 2019.

Yuhan GAO, Jan-Dirk Schmoecker: Tourist route choices and short-term flow predictions in tourist areas based on Wi-Fi packet data (Wi-Fi センサーを用いた観光地における旅行者の経路選択と短期流動予測), 第60回土木計画学研究・講演集, CD-ROM, 2019.

浅井拓登, 杉浦聡志, 倉内文孝: OD 交通量・移動滞留データを用いた属性・モード別トリップチェーン推定手法の研究, 第60回土木計画学研究・講演集, CD-ROM, 2019.

宇野伸宏, 西田純一, 倉内文孝, Schmoecker, Jan-Dirk, 中村俊之, 嶋本寛, 杉浦聡志, 木村優介: 様々なビッグデータを活用した京都市における観光流動把握の取り組み, 交通工学, 第55巻4号, 2020.

5. 今後の展望 (研究成果の活用や発展性、今後の課題等)

ICT 及び ITS の進展により、交通研究に利用可能なデータについては、質・量ともに飛躍的に進歩したといえる。一方、データ蓄積の速度が非常に速いこともあり、交通工学・計画分野においてもデータの活用は、その途上にあるといえる。本研究で構築した自動車・乗客のトリップパターン推定モデル、ならびに、トリップチェーン推定モデルは、交通ビッグデータを有効活用しつつ、道路・公共交通ネットワークにおける交通状態の動態を定量的に把握できるものである。いわば交通状態のモニタリングシステムとして、各種混雑緩和施策の効果を単に断面交通量の変化にとどまらず、OD やトリップチェーンの変化に基づき検証できるポテンシャルを有していると考えられる。

今後の主な課題として2点あげておく。1) 自動車のトリップパターン推定モデル、乗客のトリップパターン推定モデルおよびトリップチェーン推定手法に共通する課題として、計算効率性の向上を挙げることが必要である。1つのケーススタディを実施するのに数十時間を要するものもあり、今後、並列計算などの可能性も含め計算効率性の改善が望まれる。2) 観光都市における混雑緩和施策と効果の関係を常時モニタリングすることを通じて、その結果を体系的に蓄積整理し、観光都市における交通マネジメントの促進の観点で有効な施策を明らかにすることも必要と考えている。

6. 道路政策の質の向上への寄与

本研究の目指すところと、京都エリア観光渋滞対策実験協議会(国土交通省近畿地方整備局京都国道事務所)の目的は共通の内容を多く含んでいる。本研究の研究代表者が、上記実験協議会の座長を務めていることもあり、既に協働体制を築いた部分もある。特にWi-Fi パケットセンサを用いた人の流動調査では、本研究、上記実験協議会にJR西日本を加え、共同で機器設置、データ取得およびデータの共同利用を図ることで、広域での調査を実現できた。今後、実験協議会で実施される混雑緩和施策の効果を、本研究の成果を用いて定量的にモニタリング、評価を行うことが可能と考えられる。また、研究者のみならず、実務者も多く集う「交通工学研究会」の機関誌に、本研究の成果の概要を紹介する記事を掲載予定であり、さらなる実務的課題とのタイアップも検討する予定である。

7. ホームページ等

• Wi-Fi パケットセンサを用いた観光流動調査 http://www.gi.ce.t.kyoto-u.ac.jp/wifi/cart_wifi.html

第1章 はじめに

1.1 研究目的・背景

道路ネットワーク上の状況は、交通量感知器、画像センサなどで把握可能であり、それに基づき様々な交通課題の解決につながる施策が展開されている。また、トリップベースの OD 交通量、経路交通量といった交通流動については従来道路交通センサ調査、パーソントリップ調査などにより把握していたが、近年回答精度の低下などから現状を十分反映できていない可能性があること、秋の平均的な状況を分析対象としており観光都市などに見られる季節変動に対して適用が困難であること、インバウンド観光に対応できないことなどの課題が指摘されている。観光立国をめざす我が国にとって円滑な観光流動を実現するためには、自動車だけでなくヒトの流動を推定しその変化を評価することが不可欠といえる。さらに、交通ピークの平準化のような交通マネジメント施策を評価するためには動的な交通流動変化を捉える必要がある。

観測された断面交通量からネットワーク全体の交通流動を把握する OD 交通量推定法は様々なモデルが提案されているものの、入力データが十分に整備されていなかったことから実務適用は進んでいない。道路交通について考えれば、近年では ETC2.0 の普及とともに ITS スポットが一般街路にも設置されつつあるほか、経路探索履歴など様々なビッグデータが蓄積されており、旅行時間など限られた情報であれば精度よく、かつ常時観測された情報が入手可能である。また、ヒトの流動に関しても経路探索データや交通系 IC カードデータ、携帯電話の位置情報に基づくデータなどが蓄積されている。さらに、比較的安価に位置情報を取得できる Wi-Fi パケットセンサの開発も進んでおり、分析目的に応じて補完的に流動をとらえることも可能である。このように各種のビッグデータの蓄積が始まりつつある今、交通流動推定的手法論を確立させることができれば、交通流動推定の実務導入が実現でき、道路施策の継続的な改善に寄与することができるといえる。

道路交通における基本となる調査である、道路交通センサ等の交通調査は秋季の平均的な状況に対

象に実施されることが多く、観光都市などで見られる大きな季節変動に対する適用が困難であり、インバウンド観光に対応できないことなどの課題が生じている。観光立国を目指す我が国にとって、円滑な観光流動を実現するためには、自動車だけでなく人の流動を把握ならびに推定し、その変化・変動を評価することが不可欠といえよう。各種のビッグデータの蓄積が始まりつつある今、交通流動推定的手法論を確立させることができれば、交通流動推定の実務面での本格導入が実現でき、道路・交通施策の継続的な改善に寄与すると考えられる。特に、季節変動ならびに時間変動の大きな観光交通を対象として、その OD やトリップチェーン構成などの移動特性を把握できれば、道路・交通マネジメント方策の改善に寄与すると考えられる。

本研究は、観光流動の把握を主たる目的とし、ETC2.0 プローブ情報、携帯電話系データ、Wi-Fi パケットセンサデータなど様々なビッグデータを利活用し、観光トリップを主とした都市内の移動に関して、そのトリップパターンおよびトリップチェーン流動を推定するシステムを開発するものである。本研究にて開発される方法論は、情報提供、イベント実施を始めとする観光需要マネジメント施策の効果について、OD ならびにトリップチェーンの変化を通じて、量的、質的に把握するとともに、交通混雑の緩和との関係性を明らかにするため活用することを目指している。

1.2 研究体制

本研究は、研究代表者宇野を含む以下の9名の学識経験者により実施する。

宇野 伸宏	京都大学 教授
西田 純二	京都大学 特命教授
清水 哲夫	首都大学東京 教授
倉内 文孝	岐阜大学 教授
シュマッカー・ヤンディヤク	京都大学 准教授
嶋本 寛	宮崎大学 准教授

中村 俊之 名古屋大学 特任准教授
杉浦 聡志 北海道大学 准教授
木村 優介 京都大学 助教

研究代表者（宇野）は、経路選択をはじめとし、特に ITS 技術を活用した交通管理制御に造詣が深く^{1),4),6)}、本研究では全体の統括を行う。西田は Wi-Fi パケットセンサを活用した移動体観測について様々な地域でデータ観測を実施しており^{2),14)}、センサ開発の第一人者である。その適用は国内にとどまらず、途上国においても実績を有する。清水は観光行動および観光政策に関する研究を進めており^{10),11),12)}、本研究においては観光行動のモデル化を中心に進める。倉内は OD 交通量推定モデルの動学化やそれを用いた情報提供効果検証などに従事しており、この研究分野に造詣が深い^{3),4),5),13)}。本研究では道路交通流の OD 推定を主体的に進める。シュマッカー、嶋本、中村、木村は、ビッグデータに位置づけられる交通 IC カードデータを用いた交通流動分析を中心に研究成果^{7),8),9),15)}を有しており、乗客流の OD 交通量推定を中心に従事する。トリップチェーンの推定モデリングについては、マルコフ連鎖分析に造詣が深い杉浦が担当した。

外部協力機関としては、京都未来交通イノベーション研究機構関係機関に加え、京都市、国土交通省京都国道事務所におブザーバ参加いただいた。また、ETC2.0 データや民間プローブデータの処理及び基礎的な集計については一般社団法人システム科学研究所、(株)福山コンサルタント（平成 29 年度のみ）の協力も得た上で実施した。Wi-Fi パケットセンサによる観測調査実施の点では、(株)ナレッジアーク研究所、トリップパターン推定モデルの精度検証のための交通シミュレーション実施の点では、(株)ニュージェットの協力の下で実施した。加えて、Wi-Fi パケットセンサデータの収集、利活用の面では、JR 西日本とも相互協力を行った。また、交通ネットワーク分析の第一人者である飯田恭敬京都大学名誉教授からも助言を得た。

1.3 本報告書の構成

本報告書は、7 章から構成される。第 1 章では、研究の背景、目的、研究体制などについて述べた。第 2 章では、本研究課題を遂行するにあたり、収集したデータ概要を整理し、その上で、得られた移動体通信データによる交通流動解析の分析結果を示す。具体的なデータ活用の事例として、観光客の流動として代表パターン経路を Wi-Fi パケットセンサデータならびに歩くまち京都 GPS データにより分析した結果を示す。次に東山地区を対象に、EM アルゴリズムを用いて歩行者の移動速度を分析した結果、歩行者経路選択行動を分析した結果も示す。

第 3 章では、自動車を対象とした動的トリップパターン推定モデルについて、その定式化を示すとともに、実際のデータを用いて推定した結果を報告す

る。まずは経路選択行動について ETC2.0 データを用いて分析を行い、新たな経路選択モデルの構築を試み、この推定結果を用いて動的リンク利用率を算定し改良の効果を確認する。その上で、京都府警の所有する車両感知器で得られた実際の交通量データを用いトリップパターン推定を行うとともに、2018 年秋季を中心に京都市内にて観光地交通対策が実施されている時期をターゲットにトリップパターンの推定を行い、日ごと、天候による推定結果の違いを考察する。

第 4 章では、乗客のトリップパターン推定モデルの定式化を示した上で、30 年 11 月の繁忙期における京都市バスの乗客トリップパターンの推定を行う。京都市交通局収集のバス OD データを活用して、レグ OD 推定モデルを京都市バスネットワークに適用し、再現性検証を行うと共に、特に 30 年秋季を中心に京都市内にて観光地交通対策が実施されている時期をターゲットとして、外的要因が与える影響を検証する。

第 5 章では、時間帯別、モード別、属性別の目的地選択確率を基礎としたトリップチェーン推定方法について、時間帯を跨ぐ状況を考慮できるよう拡張することにより、トリップチェーン推定精度の向上を図る。また、上記の手法のほかに、直接的に観測された観光客のトリップチェーンの情報を活用した新たな手法構築を試みる。この手法に基づいて 2018 年秋季を中心に京都市内にて観光地交通対策が実施されている時期をターゲットに、影響分析を試みる。

第 6 章では上で記述した研究成果を踏まえ、道路および観光地の混雑緩和に資するマネジメント施策について検討する。自動車ならびにバスの乗客のトリップパターンを推定する方法を活用し、秋季の観光地交通対策の影響について分析する。加えて、自動車交通については、MFD を用いて道路ネットワーク上の流動特性を評価する。さらに、観光客の諸活動の時空間的分散の可能性について考察するため、訪問者の代表的周遊・観光エリアでの時間消費パターンを Wi-Fi パケットセンサデータより推定する。これらの分析結果に基づき、観光需要のマネジメント施策について影響評価を実施し、有効なマネジメント施策に関する示唆を示す。

第 7 章では、本年度の研究成果をとりまとめ、今後の課題について論じている。

参考文献

- 1) Uno, N., Kurauchi, F., Tamura, H. and Iida, Y.: Using Bus Probe Data for Analysis of Travel Time Variability, *Journal of Intelligent Transportation Systems Technology, Planning, and Operations*, Vol. 13, Issue 1, 2-15, 2009.
- 2) 西田純二：ラオスにおけるバスロケと Wi-Fi パケットセンサによる低コスト都市交通観測システム、*交通工学*（交通工学研究会）、2016 年 10 月号（Vol.51, No.4）pp.20
- 3) Kim, J., Kurauchi, F. and Iida, Y.: Analysis of Path Flow Changes Caused by Traffic Information Provision Using Dynamic Path Flow Estimation, *Journal of the EASTS*, 6, 2515-2529, 2005

- 4) Kim, J.Y., Kurauchi, F., Uno, N., Hagihara, T. and Daito T., "Using Electronic Toll Collection Data to Understand Traffic Demand", *Journal of Intelligent Transportation Systems: Technology, Planning, and Operations*, 18(2), 190-203, 2014.
- 5) 上坂克巳, 倉内文孝ら : OD 交通量逆推定手法の道路交通センサへの適用に関するケーススタディ, 土木計画学研究・講演集, Vol. 40, CD-ROM, 2009.
- 6) Sumalee, A., Pan, T., Zhong, R., Uno, N. and Indrapayoong, N.: Dynamic Stochastic Journey Time Estimation and Reliability Analysis Using Stochastic Cell Transmission Model: Algorithm and Case Studies, *Transportation Research Part C: Emerging Technologies*, 35, 263-285, 2013.
- 7) Kurauchi, F., Schmöcker, J.-D., Shimamoto, H., and Hassan, S. M.: Variability of Commuters' Bus Line Choice: An Analysis of Oystercard Data, *Public Transport*, 6, 1, 21-34, 2014.
- 8) 嶋本寛, 飯田恭敬, 倉内文孝, 國府恒彰 : モバイル移動データを活用した交通流動推定手法の提案, 土木計画学研究・講演集, Vol. 52, CD-ROM, 2015.
- 9) 嶋本寛, 北脇徹, 宇野伸宏, 中村俊之 : IC カード利用履歴データを用いた公共交通需要変動分析, 土木学会論文集 D3 (土木計画学), Vol. 70, No. 5, p.I_605-I_610, 2014
- 10) Shimizu, T., Yamaguchi, T., Ai, H., Kawase, J. and Katagiri, Y.: Travel path and transport mode identification method using "less-frequently-detected" position data, *Earth and Environmental Science*, Vol.18, 012058, 2014.
- 11) 片桐由希子, 清水哲夫, 河東宗平 : 東京都区部における訪日外国人旅行者の観光行動と広域避難場所の対応に関する一考察, 社会技術研究論文集, Vol.12, pp.61-70, 2015.
- 12) 竹本佳文, 清水哲夫, 片桐由希子, 太田恒平, 野津直樹 : 景勝地における眺望対象物の可視条件が観光周遊行動に及ぼす影響の分析 -富士五湖エリアを対象とした大規模位置情報データを利用して-, 土木計画学研究・講演集, No.54(CD-ROM), 2016.
- 13) 加藤雅仁, 倉内文孝 : ETC2.0 データを活用した Dial 型経路配分アルゴリズムの検証, 土木学会中部支部平成 29 年度研究発表会講演概要, 2018
- 14) 市川拓哉, 倉内文孝, 安東直紀, 西田純二 : Wi-Fi パケットセンサを用いた観光流動パターンの抽出に関する研究, 土木学会中部支部平成 29 年度研究発表会講演概要, 2018
- 15) 平井一成, 嶋本寛 : ボトムアップ的アプローチによる乗客のトリップパターン推定モデルの構築, 土木学会西部支部平成 29 年度研究発表会講演概要, 2018

第2章 移動体データによる交通流動の観測

2.1 はじめに

本章では、本研究課題の遂行にあたり表2.1に示すような定点観測型、移動体観測型、集計・非集計型の多様なデータを収集した。その一部データの概要を2.2節にて説明する。2.3節では得られた移動体通信データのうち、Wi-Fiパケットセンサデータによる交通流動解析の例を取りあげる。2.3 (1)項では市内広域の観測データを用いた観光流動抽出について、2.3 (2)項では東山地区を対象とした狭域の観測データによる歩行者経路選択行動分析について述べる。

2.2 データの収集状況

(1) Wi-Fiパケットセンサデータ

近年の急速なスマートフォンの普及により、人や車などの多くの移動体がWi-Fi機能を持つ通信端末を備えるようになった。スマートフォンの多くはスタンバイ状態でも機種固有のアドレスを含む探索パケット (Probe Request Packet) と呼ばれる管理パケットを送出しており、このパケットを受信し解析する

ことで、移動体の交通流動を計測することができる。さらに複数個所での受信データを突合することで、車両や人の移動速度や滞留時間、トリップパターンの計測が可能となる。

パケットに含まれる機器固有の情報は、それ単独では個人の特特定を行うことはできないが、例えば狙った個人を追跡してMACアドレスを取得する等、悪意を持って個人情報との紐付けが行われた場合には、個人の行動追跡が行われる可能性がある。そこで本システムでは、取得したMACアドレスをセンサ内で一方向ハッシュ関数により変換し、匿名化を行うこととした。

このように匿名化したMACアドレスを用いたProbe Requestを受信するセンサを以下ではAMPセンサ (Anonymous MAC address Probe Sensor) と呼ぶ。AMPセンサ・システムでは、Wi-Fiパケットを取得した後すぐに匿名化処理を行い、取得ログを内部メモリに保存した後、一定時間ごとにセンササーバにアップロードする。

2017年度は京都市東山地区に20基のWi-Fiパケットセンサを設置し、清水寺を中心とする東山地区の観光流動を観測した。2018年度は、他事業者との協

表2.1 本研究での収集データと各種データの基本特性

種類	名称	長所	課題
	交通量感知器データ	<ul style="list-style-type: none"> ・ 定点データ ・ 常時観測 ・ 自動車の混雑把握 	<ul style="list-style-type: none"> ・ 低速域でのバイアス ・ メンテナンスが不十分なことによる計測誤差の増大
	ETC2.0プローブ情報	<ul style="list-style-type: none"> ・ 面的な交通状況把握 ・ 常時観測 ・ 大まかなOD把握 	<ul style="list-style-type: none"> ・ 搭載車両の偏り (大型車、高級車が多い) ・ 普及率が低い ・ データ収集位置によるバイアス
携帯電話データ	人口分布統計 (NTTドコモ)	<ul style="list-style-type: none"> ・ 性別、年齢の把握 ・ 居住地、ローミング元の国などの情報把握 	<ul style="list-style-type: none"> ・ 位置情報は基地局あるいはメッシュ単位 ・ 1時間単位 ・ キャリアが限定される。
	人口流動統計 (NTTドコモ)	<ul style="list-style-type: none"> ・ サンプルが多い 	
アプリデータ	歩くまち京都検索データ	<ul style="list-style-type: none"> ・ 出発地、目的地 ・ 検索日時 	<ul style="list-style-type: none"> ・ 実際に移動したかどうかはわからない。
GNSSデータ	バスGPSデータ	<ul style="list-style-type: none"> ・ 固定ルートの所要時間評価 ・ 団子運転発生の有無などの評価 	<ul style="list-style-type: none"> ・ 停車によるバイアス
	特定アプリ利用者データ	<ul style="list-style-type: none"> ・ 居住地、ローミング元の国などの情報が把握可能 	<ul style="list-style-type: none"> ・ サンプルが少ない ・ 機種 (iPhone / Android) によりデータ収集頻度が異なる
	Wi-Fiパケットセンサデータ	<ul style="list-style-type: none"> ・ キャリアフリー ・ 屋内、屋外ともに対応可能 ・ 安価で設置可能 	<ul style="list-style-type: none"> ・ 性別、年齢の取得不可 ・ 移動履歴はAP単位 ・ 機種により異なる収集頻度 ・ 設置条件により取得率が変化

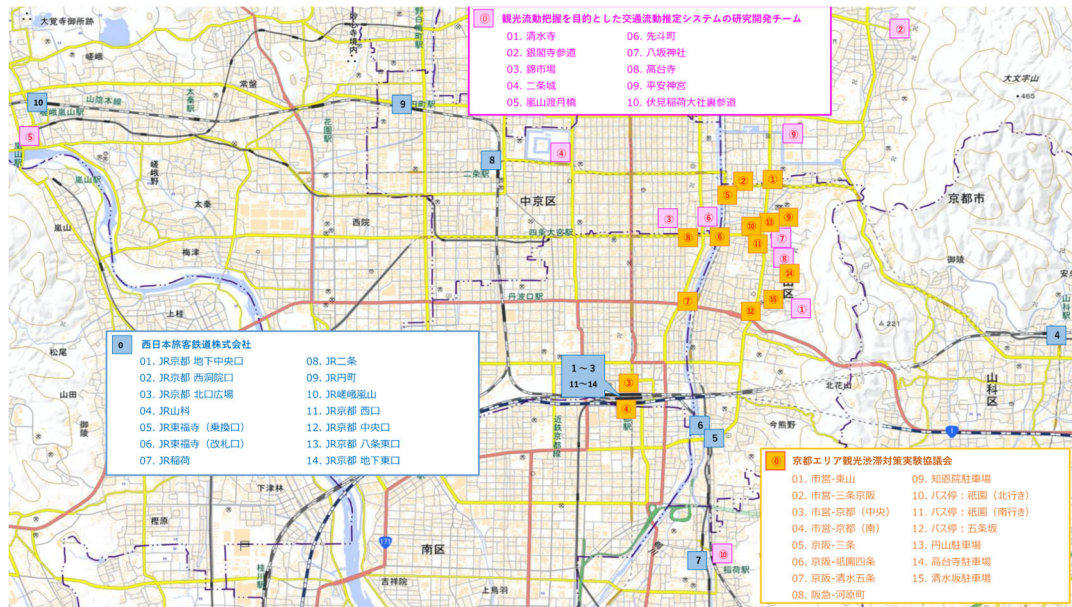


図2.1 2018年度調査におけるセンサ設置箇所



図2.2 2019年度調査におけるセンサ設置箇所

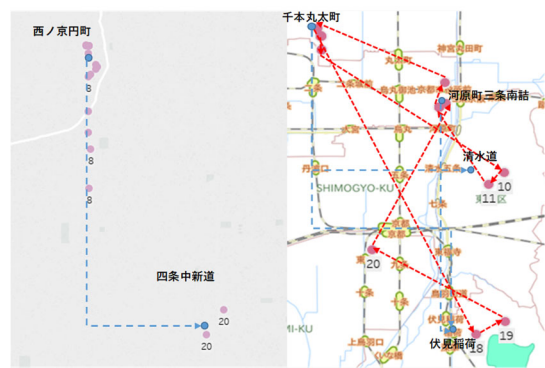


図2.3 歩くまち京都アプリでのデータ収集状況 (左: iOS, 右: Android)

力のもと、京都市内の主要観光施設へセンサを設置し、京都市全域での観光流動の計測を行った。具体的には、国土交通省近畿地方整備局による「京都エリア観光渋滞対策実験協議会」が東山地区を中心としたエリアに15台のセンサを設置し、西日本旅客鉄道株式会社が京都駅及び市内の同社主要駅に14台のセンサを設置した。この29台に本研究において設置した10台を加えて、合計39台のセンサで京都市全域における観光流動を計測した(図2.1)。このとき、異なる3つの調査主体が取得したデータを集約して相互解析を行うために、各主体が連携して統一のプライバシーポリシーを設定し、それぞれが管理するホームページで調査告知を図った。2019年度は2018年度から継続し、11箇所14台のWi-Fiパケットセンサの運用を行い、データ収集を行った(図2.2)。

(2) 歩くまち京都GPSデータ

歩くまち京都GPSデータは、「バス・鉄道の達人」アプリより収集されたものである。このアプリでは、京都市内のバス、鉄道を対象とし、出発地と目的地を入力するだけで簡単に最適な経路や運賃、所要時間を調べることができる無料の経路検索システムを

内包しており、アプリをインストール、起動により、以後自動的に位置情報が収集される仕組みである。

スマートフォンのiOSとAndroidといったOSにより、データ収集の様子が異なっている。iOSでは位置情報取得の許諾をユーザーがアプリごとに行うことができるため、多くのユーザーがアプリ起動時のみで、位置情報取得を許可している。その結果、iOSユーザーのデータは断片的になる。一方で、Androidではバックグラウンド処理でデータを収集しており、原則1時間に1度、アプリ内に蓄積されたデータをサーバーに送る仕様であるが、送信時の電波状況が悪いと送られず、データは消去される(図2.3)。

収集されるデータ項目は、データID、ユーザーID、機種固有番号、時間、位置(緯度・経度)、OS、国籍、アプリバージョンの8項目であり、主にユーザーID、時間、位置のデータを用いて分析を行った。対象期間は2018年9月から2019年3月までの半年間とした。

(3) モバイル空間統計データ

モバイル空間統計とは、ドコモ・インサイトマーケティングにより提供される、日本全国の人口の統計情報である。携帯電話ネットワークの運用データから継続的に生成されるものであり、寺田らによる

と、モバイル空間統計は非識別化処理、集計処理、秘匿処理の3段階のプロセスを経て作成される。ここでの集計処理とは、非識別化された運用データをメッシュ等の集計エリアに推計することを意味する。

携帯電話ネットワークから作成されるデータであるため、データのカバレッジ、空間解像度、時間解像度などの特性も携帯電話ネットワークに依存する。今回対象とする京都のような都市では、その規模からも携帯電話ネットワークは十分に整備されている。そのため、モバイル空間統計の統計的的代表性は十分に確保されていると考えられる。注意点として、携帯電話普及率の観点から、分析対象年齢層が15歳から79歳に限られることである。児童や80歳以上の高齢者についての分析を行うことはできないが、全体のサンプルから見れば少量である。

提供サービスはデータの内容から4種類(人口分布統計・人口流動統計・訪日外国人分布統計・訪日外国人動態統計)にわけられ、本研究課題では人口分布統計と人口流動統計を利用した。人口分布統計は、日本全国における人口分布の時間変動に加え、その属性(性別・年代・居住地)を把握するものである。調査期間とエリアの解像度はそれぞれ自由に設定できるが、解像度を上げるほど、個人情報観点から秘匿処理されるデータは多くなる。人口流動統計は、ある1日の中で出発エリアから到着エリアへ何人移動したかを推計するものである。ここで、出発エリアと到着エリアとは、最小1 kmメッシュ相当の単位をシェープファイルで指定したものであり、分析目的に応じて自由に形状を決定することができる。

本研究課題では、2018年11月の観光繁忙期、特に京都市東山地区や嵐山地区で交通対策の実施される時期と、比較対象となる通常期を中心にデータを利用した。人口分布統計については、性別×年齢10歳階別、居住地(市区町村)別、居住地(都道府県)別に、1時間ごとに京都市全域のメッシュ単位で集計したデータを、人口流動統計については、居住地(都道府県)別に、指定したゾーンを基に集計したOD量と移動・滞留人口を用いた

(4) バスGPSデータ

京都では観光客の増加によりバスへの乗降時間の増加から、バスの遅延が発生している。特に繁忙期における自動車交通の増加と相まって、バスの遅延は極めて酷い状況である。バスGPSデータは、バス車両に搭載された車載器を通じて、バスの走行に基づく位置情報や系統情報等が収集される。本研究では、観光客の移動の足となるバスの走行実態を把握すべくバスGPSデータを利用した。データの特徴として、京都市バスと京阪バスの運行実績に基づく、位置情報のGPSデータであり、収集間隔は概ね8秒単位で収集されている点、運行実績データの形式は1レコード40バイトのバイナリ形式である点が挙げられる。

データ項目としては、測位時刻、バス系統ID、バス車両ID、緯度経度、進行方向、速度、停留所停車状態がある。データ収集期間は、京都市営バスと京

阪バスにおいて収集された2016年4-6月、および10-12月である。

2.3 Wi-Fiパケットセンサによる分析

(1) 系列パターンマイニングによる観光流動抽出

a) Community Detection法によるセンサ集約

本節では、2018年11月より京都市内に設置した39基のWi-Fiパケットセンサによるデータを用いた。期間は2018年11月～12月としている。なお、分析目的ごとに対象日時が異なるため、詳細については各分析において記載する。

ここで用いるセンサデータは、本研究の目的に沿って設置されたものだけではなく、その他の団体がそれぞれの目的に応じて設置したものも含まれている。そのため、センサの設置位置は、京都駅周辺や東山地区周辺のように近接して集中的に配置されているものから、嵐山方面やJR山科駅のように非常に離れて設置されているものまで様々であり、設置密度も一様ではない。近接し合うセンサ間ほど双方で捕捉される確率は高くなるため、それらを個々に扱うと広域な観光流動よりも狭域での移動が相対的に多く見えてしまい、広域観光行動に着目することができなくなる恐れがある。そのため、近接するセンサ間をグルーピングしエリアを設定したうえで、エリア間のトリップチェーンを抽出することを試みる。

ここでは、社会ネットワーク分析等の分野で提案されている手法で、ネットワークをコミュニティ(集団内での繋がりが多く、周りとの繋がりが少ないところ)に分割する手法である、Community Detection²⁾法を用いる。分類指標については多くの研究がなされており、ネットワークの分割方法を定めるルールがさまざま提案されている。本研究では、焼きなまし法(spin glass法)³⁾という手法を採用する。この手法は、統計力学のスピングラスに関する考えを念頭に、ネットワーク内のエネルギー最小化を考えるものである。ネットワークのエネルギーは、隣接点と同じ状態であるとき、分割数が多いときに小さくなるよう式(2.1)のように定義される。 a_{ij} から d_{ij} に該当する各項の重みは1として扱っている。結果として出力されるノード群は物理的距離を考慮せず、コミュニティ内の移動が多くなるように形成される。

$$H(\{\sigma\}) = -\sum_{i \neq j} a_{ij} A_{ij} \delta(\sigma_i, \sigma_j) + \sum_{i \neq j} b_{ij} (1 - A_{ij}) \delta(\sigma_i, \sigma_j) + \sum_{i \neq j} c_{ij} A_{ij} [1 - \delta(\sigma_i, \sigma_j)] - \sum_{i \neq j} d_{ij} (1 - A_{ij}) [1 - \delta(\sigma_i, \sigma_j)] \dots \dots \dots (2.1)$$

ここで、 A_{ij} : ノード*i, j*の間のリンクの有無(ある際には重みを入れる)

$\delta(\sigma_i, \sigma_j)$: ノード*i, j*の所属コミュニティ σ_i, σ_j が一致しているか(0か1)

$a_{ij}, b_{ij}, c_{ij}, d_{ij}$: ノード*i, j*が同じコミュニティに所属し、かつエッジでつながっている場合の報酬の重み

Community Detection 法はネットワークを分割する

手法であり、センサをノード、各センサ間をリンク、センサ間の移動量を重みとして計算した。ここでは、すべてのセンサが稼働している 2018 年 12 月 3 日（月）～9 日（日）に観測されたデータを用いた。観測データのうち各日 7 時～24 時の移動を対象とし、1 日ずつのデータについて Community Detection 法を適用した。7 日間の平均的な分割結果に多少の物理的距離を加味した結果、16 のエリアに分類された。

b) クラスタ分析による観光移動層の抽出

Wi-Fiパケットセンサデータは匿名であることから、観光流動分析のような目的別の交通流動を把握するためには、分類に工夫が必要である。移動傾向から調査対象者の属性を推定する手法として、データの特性を踏まえた上で非階層クラスタリングを実施した。データは11月19日（月）～25日（日）及び12月3日（月）～9日（日）の1週間分をそれぞれ使用する。前者の1週間は金曜日から3連休を含み、祝日を含まない1週間とは移動傾向が異なることが考えられることから1週間単位で分析して比較した。

事前処理として、移動データとして取り扱うことができない「1時点のみしか観測されていないアドレス」および「ランダムイズされたアドレス」を除去した。そしてAMACアドレスごとに観測された時間、地点（捕捉されたセンサ）などの情報を元に、表2.2で示した項目を集計してアドレスごとの特性値とし、K-Means法による非階層クラスタリングを実施した。クラスタ数は、エルボー法により5を採用した。

データの集計項目毎に分類結果をまとめ、平均観測時間が短かったクラスタから順にクラスタ番号を決定した。11月19日～25日の結果を表2.3に例として示す。どちらの週もクラスタ1に全体の6割ほどのアドレスが含まれていたが、他のクラスタもアドレス数が極端に少ないクラスタは存在しなかった。

クラスタ1はどちらの週も平日に比べて土日の観測が多く、日中の観測割合が高かった。また観測時間が3時間弱であることから、このクラスタに日帰り観光客の所持するWi-Fi機器が多く含まれていると推測でき、このクラスタを「日帰り層」と定義した。次に、クラスタ2について、どちらの週も日中に観測が多く1日強の観測時間であったことから、宿泊観光客の所持するWi-Fi通信機器が多く含まれていると推測でき、このクラスタを「宿泊層」と定義した。

c) 系列パターンマイニングによる観光流動の抽出

本項では、観光客と推定される「日帰り層」と「宿泊層」のグループでどのような移動の連なりが代表的であるのかを、系列パターンマイニング手法を用いて分析する。系列パターンマイニングとは、時間順に並べられたアイテムの順列の中から頻出する順列を抽出する手法である。ここでは、捕捉されたエリアの番号の順列を対象として頻出パターンを求める。あるアドレス r のデータ列を $T_r = \{t_{1r}, t_{2r}, \dots, t_{nr}\}$ という集合とする。またデータベース全体を $D = \{T_1, T_2, \dots, T_m\}$ と定義する。ある訪問列の順列を示す前提部 X 、その後を訪れた訪問先を示す帰結部 Y という部分集合パターンが含まれているとする。このよ

表2.2 クラスタリングのためのアドレス特性値

分類要因	概要
観測時間	同一アドレスについて最後に観測された時刻と最初に観測された時刻の差
総観測数	同一アドレスが捕捉された回数
捕捉センサ数	捕捉されたセンサの数
捕捉エリア数	捕捉されたエリアの数
第一観測時間	最初に観測された時刻
最終観測時間	最後に観測された時刻
時間帯別観測時間	ある時間帯の観測回数を総観測数で除したものの、3時間ごとに8要因
曜日別観測時間	ある曜日の観測回数を総観測数で除したものの、平日と土日の2要因
センサ別観測時間	あるセンサにおける観測回数を総観測数で除したものの、センサ設置点毎の39要因

表2.3 クラスタリング結果（11月19日から25日）

クラスタ	1 日帰り層	2 宿泊層	3	4	5
アドレス数	434,796	98,613	74,745	73,946	54,211
平均観測時間 (h)	2.6	25.8	51.7	85.6	134.0
曜日別割合	金土日に多い	金土に多い	平日に多い	水木に多い	日月に多い
時間帯別割合	日中に多い	日中に多い	朝タピーク	朝タピーク	朝タピーク
平均観測回数	5.7	10	11.8	13	30.4
平均捕捉センサ数	2.2	3.6	3.9	3.5	3.7
平均捕捉エリア数	1.6	2.6	2.7	2.3	2.5

うに定義した場合、相関ルールとして3つの指標が利用されている⁴⁾。

支持度：パターンの発生する全確率を示す指標である。1に近いほどそのパターンの発生割合が大きいことを示している。パターン X, Y を含む支持度は以下のように表現される。

$$\text{Support}(X, Y) = \frac{X \text{かつ} Y \text{を満たす訪問パターン数}}{\text{全体訪問パターン数}} \dots\dots\dots (2.2)$$

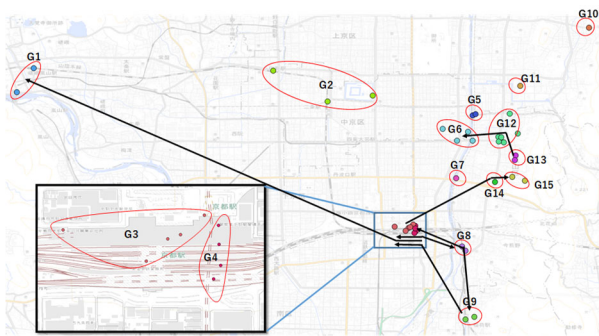
確信度：前提部 X が観測された際に帰結部 Y が発生する条件付き確率を示す。1に近いほど X と Y が同時に発生、つまり X を満たすパターンは、 Y に向かう可能性が高いということを示しており、パターン X, Y を含む確信度は次のように表現される。

$$\text{Confidence}(X, Y) = \frac{X \text{かつ} Y \text{を満たす訪問パターン数}}{X \text{を満たす訪問パターン数}} \dots\dots\dots (2.3)$$

リフト値：確信度を帰結部 Y の発生確率で除した値である。前提部の影響により帰結部の発生率がどの程度増加するのかという相関を示しており、1以上であれば X の影響により Y が発生しやすくなったといえる。パターン X, Y を含むリフト値は次のように表現される。

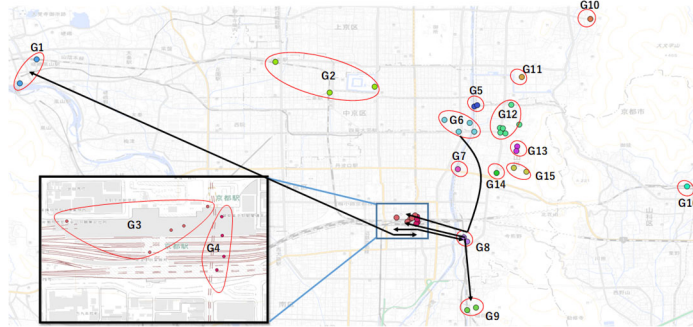
$$\text{Lift}(X, Y) = \frac{\text{Confidence}(X, Y)}{Y \text{の発生確率}} \quad (2.4)$$

系列パターンマイニングの実装には様々なアルゴリズムが提案されているが、今回はcSPADE⁵⁾というアルゴリズムを用いた。



X	Y	支持度	確信度	リフト値	該当アドレス
G8→G4	G3	0.004671	0.223298	0.471635	853
G3→G4	G8	0.003039	0.037339	0.225384	555
G3→G14	G15	0.003012	0.396254	2.422955	550
G9→G8	G4	0.002902	0.172414	0.462056	530
G9→G8	G3	0.002798	0.166233	0.351105	511
G13→G12	G6	0.002705	0.170816	0.932087	494
G4→G3	G1	0.002629	0.028924	0.228791	480
G9→G4	G3	0.002601	0.219806	0.464258	475
G4→G8	G9	0.00259	0.132753	1.038871	473
G3→G8	G9	0.002229	0.111476	0.872366	407

(a) 日帰り層 支持度上位パターン



X	Y	支持度	確信度	リフト値	該当アドレス
G8→G4	G3	0.003303	0.242424	0.609807	472
G4→G3	G1	0.002596	0.051025	0.429871	371
G9→G8	G3	0.002197	0.182558	0.459216	314
G9→G8	G4	0.002078	0.172674	0.560921	297
G3→G4	G8	0.001987	0.041956	0.38149	284
G4→G8	G9	0.001833	0.156605	1.564276	262
G1→G3	G4	0.001658	0.104359	0.339004	237
G3→G8	G9	0.001637	0.131166	1.310174	234
G8→G3	G4	0.001371	0.092235	0.29962	196
G6→G8	G4	0.001343	0.163823	0.532166	192

(b) 宿泊層 支持度上位パターン

図2.4 11月19日～11月25日の系列パターンマイニング結果

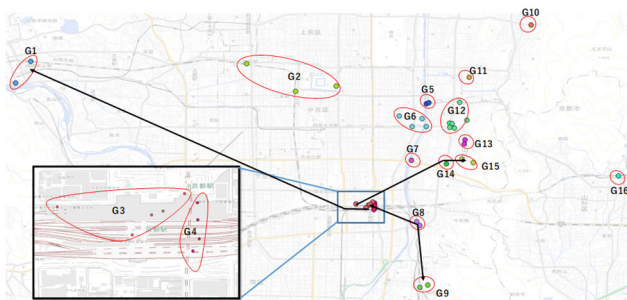


図2.5 頻出する代表的観光パターン

11月19日～25日の日帰り層に系列パターンマイニングを適用した結果、3地点間以上の支持度が高い上位10パターンを図2.4(a)に示す。抽出されたパターンはいずれも3地点間のみの移動のみではあるが、このクラスターに日帰り観光客のデータが含まれていることを考えると、京都駅から嵐山方面、清水寺、伏見稲荷を観光する人が多いことがわかる。同じく11月19日～25日の宿泊層に系列パターンマイニングを適用した結果、3地点間以上の支持度が高い上位10パターンを図2.4(b)に示す。抽出されたパターンはいずれも3地点間のみの移動のみではあるが、京都駅から嵐山方面、伏見稲荷を観光する人が多いことがわかる。また、これらの移動は先述した日帰り層の結果にも抽出されており、滞在期間によらず観光パターンに含まれる割合が高いといえる。

以上の11月の結果と12月の結果から、支持度が上位であるパターン抽出によって頻出する移動パターンを特定できることが明らかになった。4クラスターのうち3クラスター以上で抽出された移動パターン（図2.5）から、“京都駅から嵐山”、“京都駅から東福寺駅を経由して伏見稲荷”、“京都駅から五条坂を経由して清水寺”の3パターンは代表的観光行動であるとい

える。一方、多くのアドレスにおいて確認できるのは3地点間までの移動であり、同時に訪れる可能性が高い観光地の組み合わせ等は明確ではない。3地点間以上の移動では支持度が低くなり、多くのアドレスに共通する移動パターンを見つけることが困難であることも明らかとなった。

(2) 東山地区における歩行者経路選択行動

a) 分析の枠組み

本節では、Wi-Fiパケットセンサデータを使用して、観光客の流動を非集計レベルで把握し予測する手法を提案する。観光客は、移動の際に最短経路を選択するのではなく、移動自体を目的にしていると考えられる。したがって、観光地を移動する旅客の経路選択は、一般的なものよりも目的地指向性が弱いと推測される。ここでは、逐次経路選択モデル (sequential route choice model) を仮定し、中でも再帰型ロジット (Recursive Logit. 以下RLという) モデルにより観光客の経路選択を定式化する。

Fosgerauら⁶⁾は、経路列挙のない経路選択モデルとしてRLを提案した。個人の経路選択は多くのリンクに分解され、即時効用だけでなく、下流効用も考慮される。旅行者 n は、即時効用 $u(a|k)$ と下流効用 $V_n^d(k)$ の和を最大化するようにリンクを選択していく。即時効用 $u(a|k)$ および下流効用 $V_n^d(k)$ は次の式(2.5)、(2.6)で表される。

$$u(a|k) = v(a|k) + \mu \varepsilon_n(a) \dots \dots \dots (2.5)$$

$$V_n^d(k) = E \left[\max_{a \in A(k)} (v(a|k) + V_n^d(a) + \mu \varepsilon_n(a)) \right] \quad \forall k \in A \dots \dots \dots (2.6)$$

式(2.6)は、ベルマン方程式⁷⁾として知られている。旅行者の逐次経路選択のマルコフ特性を仮定し、この動的選択モデルは、無限の選択肢を持つ基本的

MNLモデルと同等であることが証明されている。

b) 対象地域と収集データ

データ収集は、2017年11月から2018年3月まで京都市東山区で実施された(2.2(1)参照)。対象地域は、東西に約700 m、南北に約800 mの範囲にわたり、清水寺や八坂神社など京都のよく知られた観光地を含む。センサは全部で20個あり、図2.6に示すように設置されている。

センサNo.1は八坂神社の入り口から南に50 mの位置に設置され、センサNo.15と16は清水寺の入り口付近にある。山岳地帯の西麓に位置する東山区はアクセスの利便性に乏しく、ほとんどの観光客はセンサNo.6, 10, 19, 20に沿う南北の幹線道路(東大路通)から入る。センサにより複数回記録されるMACアドレスは、1日あたり平均90,000もある。これらの記録は歩行者または運転者によるものと考えられ、経路選択を考えるのに有効な経路として採用する。

c) ネットワークの構築

RLモデルは、リンクベースモデルより、個々人の逐次経路選択とその入力先としての非巡回グラフが必要となる。位置情報を継続的に記録するGPSデータとは異なり、Wi-Fiパケットセンサデータは、センサに十分近い状態でのみデータが収集される。すなわち、Wi-Fiパケットデータからは個人の詳細な経路は把握ができず、センサ間の移動情報のみが把握できる。したがって、実際の地図にGPSデータを使用してRLを実装するほかの研究とは異なり、本研究では、特定のネットワークを構築する必要がある。この簡略化されたネットワーク(以下簡略ネットワークという)は、各センサに対応するノード、およびダミーノードのみを含む。

本節では、OpenStreetMap(OSM)が提供する歩行者マップのデータに基づいて簡略ネットワークを構築する。このマップデータは900を超えるノードと

2,500を超えるリンクを備えた多方向グラフ(Multi-directed graph)である。この多方向グラフから、21のノードと119のリンクのみを持つ有向グラフを構築する。本研究では、清水寺に到着する(センサNo.15またはNo.16に観測される)ことを吸収状態と定義し、21ノードと119リンクの内、1つのダミーノードとこれに対応する2つのダミーリンクを決める。これより今後は、このモデルをさらに多くの目的地に合わせて拡張できる。

簡略ネットワーク内の各ノード間の接続性は、実ネットワーク上において、両センサノードが第三のセンサを経由しなくても連結しているかどうかで決まる。吸収ノードを除いた全てのノードは双方向に接続されている。簡略ネットワークのリンク属性は、実ネットワーク上の関連するノードとリンクの属性によって決定される。

モデル化において、RLの「リンクの魅力度」の決定方法が重要になる。本研究で扱う簡略ネットワークでは、「距離」、「リターンペナルティ」、「POIの数」の3つのリンク属性がある。「距離」は各センサノード間の最短経路距離として定義する。「リターンペナルティ」はリンク k の後にまた同じリンク k を選択する場合を1とするダミー変数である。これらに加えて、観光地では重要な評価基準となる、お店や観光名所などの“Points Of Interest”(以下POIという)の数をリンク属性とする。センサノード間にあるPOIの数は以下の手順にて得られる。

1. OSMのデータベースから、お土産屋、飲食店、寺社仏閣などの商業施設および観光名所を表示するPOIの座標を読み込む。
2. 各POIを最も近いセンサノードに関連付ける。このセンサノードが無向リンクのみを持つ場合は、隣接するPOIに合併する。
3. 簡略ネットワークの各リンクについて、関連付けられたノードが k 最短パス上にある場合は、POIの数に1を追加する(Yen's k -shortest path algorithmより計算)。

ノードペアを介したPOI数の分布を図2.7に示す。

POIの数が多い1, 2, 3の領域は八坂神社であり、8, 13, 14は清水寺へ繋がる、観光地としても有名な二寧坂および産寧坂である。

d) POIの数を考慮したRLモデル

観光客は、簡略ネットワーク上の非吸収リンクを通過するとき、次に訪れるリンクについて決定を下すことが想定される。この行動をRLモデルにより再現するため、データ、効用関数、結果について説明する。

インプットデータについて、最初の試行では、調査を行った最初の週のデータのみを扱う。モデルへのデータ入力は、八坂神社から清水寺の歩行者(センサNo.1からNo.15, No.16の観測データ)のみとする。なお、前の検出に物理的に連結されていない場合や検出期間が妥当でない(短すぎる、あるいは長すぎる)場合は、続いて起こる検出を無視する。その結果、計793個の経路および6349個のリンク選択と



図2.6 東山区におけるセンサ設置位置




図2.7 ノードペアを介したPOI数の分布

表2.4 POI数の有無別のモデル推定結果

	Without NP_a	With NP_a
β_L	-1.49 (-61.47)	-1.55 (-61.56)
β_{UT}	-0.77 (-9.31)	-0.97 (-11.33)
β_{NP}	—	0.04 (10.40)
$LL(\beta)$	-4186.96	-4134.95

なった。

効用関数について、リンク k が与えられている中、後続のリンクとしてリンク a を選ぶ即時効用は次の式で表される。

$$v(a|k) = \beta_L L_a + \beta_{UT} UT_{a|k} + \beta_{NP} NP_a \dots \dots \dots (2.9)$$

L_a : リンク a の長さ (m/100)

$UT_{a|k}$: リンク k と a に関連するリターンダミー, NP_a : リンク a に付属するPOIの数

NP_a がある場合とない場合の2つに分けて推定したRLモデルの推定結果を表2.4に示す。推定した全ての変数は有意水準0.1%で有意であり、推定に用いた変数同士には有意な相関関係は確認されていない。

NP_a (POIの数) については、想定通り、リンクの効用と正の相関を示し、モデルを改善する結果が得られた。両モデルで、 $UT_{a|k}$ のパラメータ β_L の結果は類似しており、リンクの長さおよびリンクの効用と負の相関が示された。リターンペナルティのパラメータ結果に関しては、一度 NP_a (POIの数) が制御されると $UT_{a|k}$ のパラメータである β_{UT} はリンクに負の効用を与えることが示された。さまざまなお店や観光名所 (POI) を含むリンク上では、一度立ち寄ったのちに、再度その場所に戻ってくる可能性は比較的少なく、観光客にとってこの結果は合理的であると考えられる。

今回は八坂神社から清水寺への流動のみをモデリングしたが、今後は全ODペアに対して行う。また経路の抽出に関しては、歩行者の種別を考慮するために、クラスタリング手法を選択モデルに組み合わせる。モデルの結果を比較することにより、観光客と通勤者の間で異なる選択行動が見られることが期待される。

2.4 おわりに

本章では、移動体通信データによる繁忙期または交通マネジメント方策実施時の交通流動観測として、本研究課題において収集したデータの概要を示すとともに、繁忙期において収集されたWi-Fiパケットセンサデータを例に、観光流動に関する分析、東山地区における歩行者の経路選択に関する分析を行った。成果としては、以下の点をあげることができる。

- 本研究課題ではWi-Fiパケットセンサを京都の主要観光地に設置することで、リアルタイムでの設置地点の観光客の捕捉が可能となった。それにより、繁忙期の観光客の流動把握や交通マネジメント方策実施に伴う効果検証のためのデータを整理した。
- Wi-Fiパケットセンサのデータに系列パターンマイニング手法を適用することで、観光客の代表的流動パターンを明らかにした。この手法ではデータ別にクレンジングや観光客特定のためのクラスタリングを行う必要はあるものの、利用するデータによらず、代表的流動パターンの抽出適用が可能である。
- 混雑する観光地として、東山地区における観光客の経路選択に関して、収集したWi-Fiパケットデータに基づき、実際の地理データを使用して簡略ネットワークを構築し、観光地の魅力度を反映する変数を加味したRecursive Logitモデルを構築した。

参考文献

- 1) 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, 2012.
- 2) Girvan Michélie, Newman M.E.J, “Community structure in social and biological networks”, Proceedings of the National Academy of science of the United States of America, Vol 99, pp7821-7826, 2002.
- 3) Joerg Reichardt, Stefan Bornholdt, “Statistical Mechanics of Community Detection”, Physical Review E Vol. 74, 016110, 2006.
- 4) 篠原透, 沼尾雅之, シーケンシャルパターンマイニング拡張による特徴的なコード進行の抽出手法, DEIM Forum, 2015.
- 5) Mohammed J. Zaki, “Sequence mining in categorical domains: incorporating constraints”, Proceedings of the ninth international conference on Information and knowledge.
- 6) Fosgerau, M., Frejinger, E. and Karlstrom, A. : A link based network route choice model with unrestricted choice set. Transportation Research Part B: Methodological, 56, pp.70-80, 2013.
- 7) Bellman, R. : Dynamic programming. Science, 153(3731), pp.34-37, 1966.

第3章 自動車トリップパターン推定モデルの構築

3.1 はじめに

本章では、前章で特性整理を行い、活用方法を検討したインプットデータを用いて、自動車のトリップベースの OD パターン（トリップパターン）を把握する推定モデルを開発する。一般に、OD 交通量推定の計算可能性は未知変数の数に左右され、そしてその数は、空間解像度、時間解像度、未知変数の解像度によって決まる。本研究では、空間的パターンと時間的パターンを分割して推定する近似的モデルを適用することで、時間的パターンの解像度は計算実行可能性に依存しない構造とした。また、空間的パターンについては、現実的な計算時間で実行可能な変数サイズの検討を行った。さらに、全体の自動車交通状況を把握するため、インプットデータとして用いた交通量感知器データにより MFD (Macroscopic Fundamental Diagram) を描き考察を加えた。最後に、トリップパターン推定を実施し、対象日ごと時間帯ごとに推定トリップパターンが変化することを確認する。

3.2 トリップパターン推定モデルの構築

(1) モデルの定式化

本研究で用いる動的トリップパターン推定モデルは、推定量に最小自乗法を採用し、さらにはトリップ分布の平面パターンと時間遅れに代表される時間パターンを分離して推定することで計算性を高めたものである。空間パターンを推定する主モデルは以下の(3.1)式で示されている当該時間帯 t にネットワーク上に存在する OD 交通量 x_{ijt} を推定する。

目的関数

$$Z = \sum_a (\sum_i \sum_j x_{ijt} \cdot p_{aijt} - v_{at}^*)^2 + \mu \sum_i \sum_j (\sum_i \sum_j x_{ij} \cdot f_{ijt} - x_{ijt})^2 \rightarrow \min \dots\dots\dots (3.1)$$

ただし、

x_{ij} : 時間帯 t にネットワーク上に存在している OD ペア (i, j) の交通量

p_{aijt} : OD (i, j) の車両のうち、時間帯 t にリンク a で観測される比率（動的リンク利用

率)

v_{at}^* : 時間帯 t にリンク a で観測された交通量
 μ : リンク交通量の誤差と先験 OD 確率との変化量の相対的な重み

f_{ijt} : OD (i, j) の交通量が時間帯 t においてネットワーク上で観測されている比率（先験 OD 確率）

また、計算安定性のために、OD 交通量の変化量には一定の制限を加えることも可能としているが、今回の計算にはこの機能は使用せず、OD 交通量は自由に変動可能である。

制約条件

$$x_{ijt} \leq x_{ijt} \leq \bar{x}_{ijt} \quad \forall i, j, t \dots\dots\dots (3.2)$$

ただし、

x_{ijt}, \bar{x}_{ijt} : x_{ijt} の上下限值

ここでは、出発時間帯を考慮せず、あくまで時間帯 t における交通についてのみ推定を行う。すなわち、当該時間帯においてネットワーク上を走行する車両のうち各リンクに影響を及ぼしている OD ペア交通量をまず主モデルで求め、その後、副モデルで出発時間帯別に割り振ることとする。そのため、推定は時間帯ごとに分離して推定すればよい。

交通の時間遅れパターンを推定する副モデルは、**図 3.1**によって示されている時間帯寄与率の概念を用い、時間帯 t にて観測されている OD 交通量を出発時間帯 s に戻す作業を行うものである。 t 時台に観測されたある OD ペアの交通量は、 t 時以前に出発地を出発したものである。ここでは、OD ペア間の移動に関する所要時間は各時間帯における最短経路所要時間で代表されるものとする。つまり、**図 3.1**のそれぞれの斜線の傾きが最短経路所要時間で示されるとする。主モデルで得られるのは各時間帯でネットワーク上の交通量 x_{ijt} であり、求めたいのはある時間帯 s に出発した交通量 y_{ijs} である。このとき、傾きが最短経路所要時間によりわかっているならば、 y_{ijs} が各時間帯 t においてどの程度影響を及ぼしているかを表す時間帯寄与率（**図中**の q_{ijst} ）は、簡単に求めることができる。時間帯寄与率は、「ある時間帯 s に出発した車両が時間帯 t における交通量のうちの割合」と定義でき、 $\sum_t q_{ijst} = 1 (\forall s, i, j)$ の関係を持つ。




図 3.1 時間帯寄与率の概念

上記の時間帯寄与率の概念を用いると、主モデルで推定された x_{ijt} と出発時間帯ごとの OD ペア交通量 y_{ijs} には(3.3)式の関係が成立する。

$$x_{ijt} = \sum_s q_{ijst} y_{ijs} \quad \dots\dots\dots (3.3)$$

これは、OD ペア (i, j) を省略して考えれば、時間帯 s, t ともに大きさが時間帯数に等しい列ベクトル \mathbf{x} 、 \mathbf{y} およびその関係を表す行列 \mathbf{Q} を用い、 $\mathbf{x} = \mathbf{Q}\mathbf{y}$ と記述できることになる。従って、 \mathbf{y} は $\mathbf{y} = \mathbf{Q}^{-1}\mathbf{x}$ で得られる。ただし、ここでは OD ペアの所要時間を最短経路所要時間で代表させているため、 \mathbf{Q} の値に誤差が含まれる。そのため、(3.4)式に未知変数 y_{ijt} を求める最適化問題を定義する。

$$Z_{ij} = \sum_t \sum_s (x_{ijt} - \sum_s q_{ijst} y_{ijs})^2 \rightarrow \min \dots\dots (3.4)$$

制約条件

$$y_{ijs} \geq 0 \quad \forall i, j, s \dots\dots\dots (3.5)$$

本モデルは、上下制限のある典型的な最小二乗推定法による交通量推定となっているため、汎用の最適化ソフトウェアを活用できる。本研究では数値演算ソフトウェアである MATLAB を活用し、推定計算を行う。

(2) 必要なインプットデータ

提案したモデルを推定するにあたっては、観測リンク交通量、動的リンク利用率、先験 OD 確率が必要となる。ここではそれらの入手方法や考え方を示し、先験 OD 確率および動的リンク利用率の推定方法については 3.4, 3.5 において詳述する。

観測リンク交通量

観測リンク交通量としては、例えば国土交通省が設置している常時観測交通量感知器を用いることなどが考えられる。その他、近年では各県警が収集しているデータが（公財）道路交通情報センターを通じて公表されている。これらのデータを活用することで、時々刻々変化する観測リンク交通量を作成できる。

先験 OD 確率

先験 OD 確率とは、OD (i, j) がネットワーク上で観測されている比率を示しており、従来はパーソントリップ調査や道路交通センサス時の起終点調査を用いて設定することが一般的であった。しかしながら、それらの調査の頻度は決して高くないため、その他のデータ、特に自動収集されるリアルタイムに近いデータの活用が期待されることである。

動的リンク利用率

動的リンク利用率は、それぞれの未知変数が観測されているリンク交通量とどのように関係性を持っているかを定義するものである。本研究で開発するモデルでは、未知変数の基本は時間帯別 OD 交通量であるため、それぞれの未知変数とリンク交通量との関係性を表現すればよい。このような問題は DNL

(Dynamic Network Loading) と呼ばれるものであり、最も基本的なのは AoN (All or Nothing) 配分であり、最短経路にすべて割り付けるというものである。AoN 配分は、簡便性は高いものの、実際の利用者の経路は所要時間の同じ経路に集中しているとはいえない。所要時間の大きさに応じて分散するような経路配分も存在しており、その中ではハンドリングも容易なロジット型の経路配分が一般的である。本研究でもロジット型の経路配分を前提とする。ロジット型経路配分とは、経路の一般化費用を用い、分散パラメータを介して以下の式で経路選択を行う。

$$Pr(k) = \frac{\exp(\theta c_k)}{\sum_k \exp(\theta c'_k)} \dots\dots\dots (3.6)$$

ただし、

- θ : 経路の一般化費用に対する分散パラメータ
- c_k : 経路 k の一般化費用

(3) ネットワークサイズと計算規模の検討

ここで提案した OD 交通量推定は最小二乗法による解法を採用している。最小二乗法の計算量は未知変数の量に依存する。未知変数の数が膨大になれば、求解が困難となるため、実務適用を検討する際には、分析対象とするネットワークの大きさや時空間の単位時間の大きさを踏まえ、無理のない時間で計算可能な未知変数となるよう適当なモデルを採用する必要があるといえる。ここでは、未知変数の量を変更し、汎用プログラミングソフトによる最小二乗法に要する時間を計測する。無理なく多種の求解が可能となる時間の目安として 2 時間と制限したときに求解可能な未知変数の量を明らかにすることをめざす。そのうえで、分析対象となりうる道路ネットワークの大きさを整理し、求解可能な未知変数の量となるようなモデルについて考察する。

a) 疑似データの作成

ここでは、求解精度を問うわけではなく、純粋に変数サイズの影響のみをみればよい。そのため、OD 交通量推定と同等の目的関数、制約条件を持つ以下に疑似データを作成した。

- ・ 複数の未知変数の線形和によって表現される目的関数項の数は 1,000 個とする。これは、式(3.1)における第 1 項を表現するものであり、リンク集合に含まれるリンク数を 1,000 とすることと同等である。
- ・ それぞれの未知変数の誤差量を表現する目的関数項の数は未知変数の数と等しくする。これは、式(3.1)における第 2 項を表現するものであり、先験 OD 交通量と推定 OD 交通量の差を求

める項である。

- v_{at}^* , $x_{wt}' \cdot g_{wt}$ にあたる定数に乱数を, p_{wat} にあたる定数に1を与える。この設定により計算の解は現実的な意味を持たなくなるが, 計算時間の計測には影響しない。
- 各未知変数には, $x_{wt}' \cdot g_{wt}$ に該当する定数に与えた乱数の±20%の上下制限約を与える。これが, 式(3.6)に相当する。

b) 計算時間

最小二乗法の求解には Matlab の Optimization Toolbox を用いた。計算機は岐阜大学所有のワークステーション (CPU : Core i7-4960X 3.60GHz x 2, メモリ : 32GB RAM) を使用した。以上の条件により計算した結果を図 3.2 に示す。図中赤線が 7,200 秒 (2 時間) を示す。なお, 未知変数の数が 50,000 のケースは計算が不可能であった。検証の結果, 未知変数が増大すると計算時間は指数的に増大する関係であることが確認できる。未知変数の数が 10,000 の場合では 3,700 秒 (1 時間程度) となり, 2 時間以内で計算が完了しているが, 25,000 では 26,700 秒 (7 時間以上) を要する。したがって, 最小二乗法が現実的に無理なく計算できる未知変数の限度は概ね 10,000 程度といえる。

c) ネットワークサイズと計算規模

以上の結果より, 様々な分析サイズに対し, OD 交通量推定に用いることが適正な変数を表 3.1 のように整理した。観光流動について考えた場合, 主要な観光地間の移動を詳細に分析する必要がある。ただし, 自動車での移動については, やはりセンサス B




図 3.2 未知変数の数と計算時間の関係

表 3.1 ネットワークサイズと適正な未知変数

サイズ	ノード数	無向リンク数	セントロイド数	適正変数
全国	-	-	約 6,800	発生交通量
地方整備局管内 (中部, Bゾーン)	12,287	18,051	1,049	発生交通量
県 (岐阜県, Bゾーン)	1,852	2,895	163	間引いて OD 交通量
市町村 (岐阜市, Bゾーン)	228	417	22	OD 交通量
岐阜市内 (DR Mリンク)	27,820	43,137	65 (PT 小ゾーン)	分析目的に依存
【参考】モバイル空間統計 (京都市)	-	-	約 200 (メッシュ数)	半分程度までメッシュを減少

ゾーン程度での分析が適当であろう。道路交通センサスにおける交通量調査地点は 12 時間観測を含め 200 カ所程度であった。また, (公財) 日本道路交通情報センターに掲載された京都市内の交通量観測地点を確認したところ, 500 カ所程度であった。

3.3 仮想ネットワークを用いた精度検証

開発したモデルの推定精度に対するインプットデータの影響について事前に把握しておくことは, 今後のインプットデータの推定方法や入手方法などを検討する際に重要な情報となる。そのため, ここではあらかじめ OD 交通量を設定し, それを特定の経路選択ルールおよび車両移動ルールに基づき観測リンク交通量を設定した。その後, 観測誤差を適宜追加してインプットデータを作成し, 推定精度の確認を行った。9 ノード, 12 リンク, 4 セントロイド, 5 時間帯の小さな仮想ネットワークと, 京都市全域を模した 1,035 ノード, 2,747 リンク, 204 のセントロイド, 24 時間帯のネットワーク (図 3.3) において検証を加えたが, ここでは後者について報告する。

本研究では, (株) NewJEC が VICS 情報提供効果の検証のために構築した交通流シミュレーションモデル²⁾を改良し用いた。このシミュレーションの挙動モデルはブロック密度法を用いたメソスコピックモデルであり, 車線数による容量の違いは考慮しているものの, 車線ごとの交通は再現しない。信号はプログラム上では容量設定値により反映することとなっており, 明示的には考慮できない。さらに, 経路選択モデルは, 東京都市圏ネットワークシミュレーションにおける経路選択モデル³⁾を参考に設定し, Dial のアルゴリズムにより配分している。

設定値として用いる OD 交通量は平成 22 年度道路交通センサスにおける現況 OD をベースとした。ただし, 図 3.3 に示したゾーン代表ノード (セントロイド) 数は, ゾーンより多いため, 重力モデルの概念を用いて各代表ノードに割り振った。さらに, 時間帯別の OD 交通量の変化については, センサス交通量に記録されているリンク観測交通量の時間帯別の比率を用い, それに平均 0, 分散 0.1 の正規乱数を加えて時間帯別 OD 交通量を作成した。このように作成された時間帯別 OD 交通量設定値を用いてシミュレーション計算を実施し, その結果から, 誤差のない場合の観測リンク交通量, 先験 OD 確率, および動的リンク利用率を算定した。また, ここでは, 全てに誤差がないケース (ケース 0), 既存 OD 確率に日平均値を用いるケース (ケース 1), 観測交通量に平均ゼロ, 分散が 0.1 の正規乱数を加えたケース (ケース 2), リンク数を道路交通センサスで観測されている 550 リンクに限定したケース (ケース 3), そしてセンサスリンク交通量に警察観測リンクを追加したケース (ケース 4) の 5 ケースについて計算を実施した。その結果得られたリンク交通量および推定 OD 交通量の相関係数を表 3.2 に示す。この推

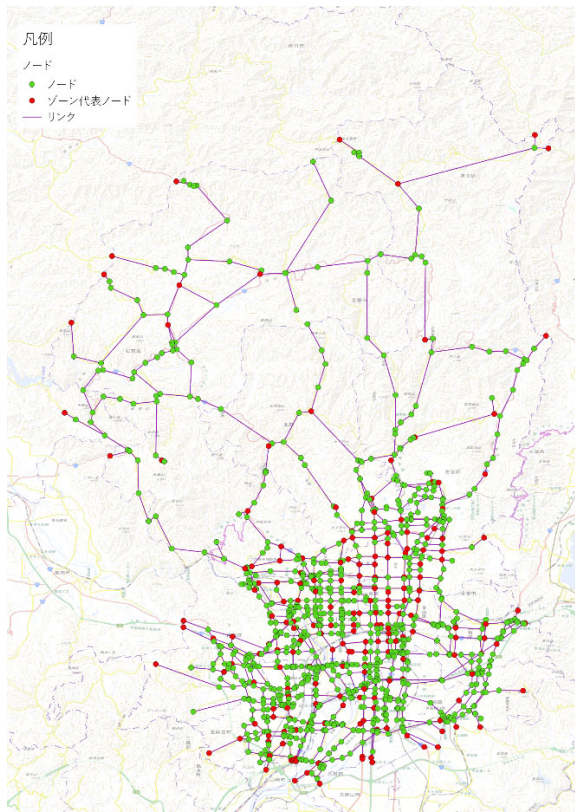


図 3.3 未知変数の数と計算時間の関係

表 3.2 リンク交通量および OD 交通量の相関係数

ケース	概要	リンク交通量	OD 交通量
0	ベースケース	0.998	0.990
1	既存 OD 確率に日平均値	0.998	0.978
2	観測交通量に誤差	0.998	0.981
3	観測リンクをセンサスに合わせる	0.962	0.826
4	3に警察リンクを追加	0.913	0.869

定結果より、(1)既存 OD 確率に日平均値を用いても大きな影響はない、(2)リンク交通量の観測が限定的である場合、精度低下の可能性はあるが、常観データを活用することで誤算の低下を緩和する可能性がある、ことがわかった。

3.4 先験OD確率作成方法の検討

ここでは、ETC2.0 データを活用した先験 OD 確率の推定方法を検討した。まず、検討するにあたっての前提条件を以下のように設定する。

- OD ペア w (出発地 o_w , 目的地 d_w) の交通は、出発地あるいは目的地のいずれかで ETC2.0 をセットアップしたものとし、それ以外のは無視可能であるとする。つまり、OD ペア w の車両の装着率は、その起終点における装着率に依存するものとする。
- 装着率は、(ETC2.0 セットアップ件数 / 当該セントロイドの発生交通量) で求められるものとする。
- 上記の仮定に従えば、OD ペア w の ETC 装着率

g_w は、各地域の装着率 f_{o_w} , f_{d_w} と、それぞれのセントロイドにおける発生交通量比率 e_i ($\sum_{i \in 0} e_i = 1$) を用いて次のように記述できる。

$$g_w = \frac{e_{o_w} f_{o_w} + e_{d_w} f_{d_w}}{e_{o_w} + e_{d_w}} \dots \dots \dots (3.7)$$

- 捕捉率は OD パターンごとに一定とする。つまり捕捉率に地域的な偏りはないとする。

以上の情報を元に、ベイズ更新を検討することとする。ここで、事象 A を観測の有無とし、 $A_0 \equiv$ 非観測、 $A_1 \equiv$ 観測と定義する。このとき、以下を考える。

$P(w|A_1)$: 観測された交通のうち、OD ペアが w である確率 ($P(w|A_1) = X_w / X = h_w$; X : ETC2.0 により観測された総交通量, X_w : ETC2.0 により観測された OD ペア w の交通量)

$P(A_1)$: 交通量が捕捉される確率

$P(w)$: OD ペアが w である確率 (真の OD 確率 \rightarrow 未知変量)

また、ベイズの定理により以下が成り立つ。

$$P(w) = \frac{P(w|A_1) \cdot P(A_1)}{P(A_1|w)} \dots \dots \dots (3.8)$$

ここで、

$$P(A_1|w) = g_w = \frac{e_{o_w} f_{o_w} + e_{d_w} f_{d_w}}{e_{o_w} + e_{d_w}} \dots \dots \dots (3.9)$$

$$P(A_1) = \frac{X}{Y} \dots \dots \dots (3.10)$$

である。ただし、 Y : 道路交通センサスから得られる総発生交通量とする。このとき、以下のように記述できる。

$$P(w) = \frac{P(w|A_1) \cdot P(A_1)}{P(A_1|w)} = \frac{h_w}{g_w} \cdot \frac{X}{Y} \dots \dots \dots (3.11)$$

なお、ETC2.0 による観測が行われた時点での総発生交通量がセンサスから得られる総発生交通量 Y と一般には一致しないため、上式で得られる $P(w)$ の総和は一般的には 1.0 とならない。ただし、全体の交通量については、後段階の OD 推定において観測リンク交通量に整合するように補正されるため、ここで必要なのは OD 確率 p_w である。そのため、以下のように $P(w)$ を正規化し、 p_w を求める。

$$p_w = \frac{P(w)}{\sum_w P(w)} \dots \dots \dots (3.12)$$

上記の考え方の妥当性をみるために、例題にて計算をしてみる。ここでは、例としてまず先験情報として平成 22 年センサス OD 交通量を、一様乱数を用いて 0.5~1.5 倍に変化させたものを用い、提案した手法により元の値を再現できるかを確認した。その結果、捕捉率が精度よく推定されていれば、正確に先験 OD 確率を推定可能であることが確認できている。

3.5 ETC2.0データによる経路選択傾向の考察

次に、動的リンク利用率を算定するために、経路選択行動についての考察を行う。

(1) 所要時間を説明変数にした経路選択

ここでは、2016 年 10 月の 1 ヶ月間の ETC2.0 デー


タのうち、京都市内の北大路通、西大路通、東大路通、十条通に囲まれたエリアから出発した車両を対象として分析を進めた。また、京都市内から東西および南方向に延びる高速道路上の ITS スポット 5 箇所を仮の目的地とし、そこまでの経路選択状況の分析を進めた。これらのデータを用い、観測データから代表経路を設定した上で経路選択をロジットモデルにより推定した。その結果、所要時間(分)に関する分散パラメータは、 -0.170 という値を得た。これを用い、Dial の効率的経路の考え方に基づき循環経路を排除した上で経路選択の再現性を確認した。茨木 IC までの経路の選択状況を示したのが図 3.4 であるが、図 3.4(a)より、効率的経路に含まれるリンクが非常に限定的であることがわかる。その一方で、図 3.4(b)の実測をみると、阪神高速京都線を利用したものや、市内の他の通りの利用など、多様な経路が利用されている。四条烏丸交差点を便宜上の出発地としていることも当然考えられるが、それに加えて所要時間のみによる経路選択の過程が現実を表していない可能性が示唆される。

(2) 右左折数および信号交差点数を考慮した経路選択

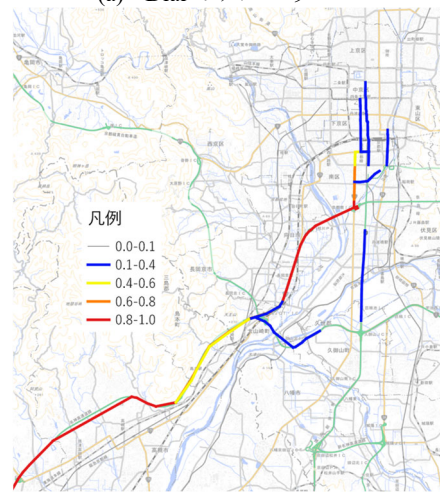
上記の考察結果を受け、所要時間以外の経路選択要因として、右左折数および信号交差点を用いた推定を試みる。なお、(1)で用いたデータは高速道路を目的地として設定したため一般街路の経路選択を必ずしも表現しているとは限らないこと、ETC2.0 データを単純に集計したものであるため、移動途中でリンクが途切れていることなどから、(一社)システム科学研究所の協力の下、データの分割処理と、全リンクを対象として軌跡接続処理をしたものを用いた。2018 年 10 月の 1 ヶ月間のデータを用いる。京都市内中心部の 3 カ所および京都市端部の 16 カ所を起終点とし分析を加えた。それぞれの起終点ペアに対し、代表経路を定義した上でそれぞれの経路の右左折数および信号交差点数を求めた。

所要時間のみを説明変数としたケース(パターン 1)、経路選択と右左折数を説明変数としたケース(パターン 2)、そしてパターン 2 に信号交差点数を加えたケース(パターン 3)について、ロジットモデルによる推定結果を表 3.3 に示す。推定結果を見ると、右左折数及び信号交差点数を考慮することで修正尤度比が大幅に改善しており、右左折数及び信号交差点数の影響は無視できないことがわかる。また、これらの推定結果を用いいくつかの OD ペアについてリンク利用率を算定した結果、右左折数および交差点数を考慮することで経路選択に多様性が生まれることが確認できている。なお、所要時間に関するパラメータは、(1)で示したものと比較して若干小さい(-0.170 (分)に対してパターン 1 で -0.140 (分))。都市内の足の短いデータを用いて分析を行ったため、分散パラメータの値が相対的に小さくなったと考えられる。

さらに、3.3 で示した仮想ネットワークにおける



(a) Dial のアルゴリズム



(b) 実際のデータによるリンク利用率

図 3.4 リンク利用率の比較(茨木 IC)

表 3.3 経路選択推定結果(括弧内は t 値)

説明変数	パターン 1	パターン 2	パターン 3
所要時間(秒)	-0.00233* (-23.39)	-0.00167* (-17.10)	-0.00189* (-16.27)
左折数	-	-3.10 (-1.34)	-1.02* (-3.24)
右折数	-	-0.850* (-3.61)	-0.425 (-1.35)
信号交差点数	-	-	-0.363* (-27.55)
修正尤度比	0.079	0.144	0.215

*: 1%有意

表 3.4 推定結果の RMSE 値の比較

RMSE	パターン 1	パターン 3	改善率 (%)
リンク交通量	301.68	263.61	12.6%
OD 交通量	14.22	14.25	-0.19%

ベースケース(ケース 0)を対象に、経路選択モデルをパターン 1 およびパターン 3 に入れ替えた場合について比較検討した。ここでは、リンク交通量及び OD 交通量の RMSE (Root Mean Squared Error) により評価した。その結果を表 3.4 に示すが、リンク交通量で 12.6%程度の改善が確認された。なお、OD 交通量については若干悪化しているが、先に設定した先験情報とのずれを示しており、これが大きいことは、OD 交通量が観測リンク交通量の情報によって

より先験情報と異なるものになったことを表しているに過ぎない。したがって、今回の動的リンク利用率算定方法の改良によって13%程度の改善効果が得られたといえる。

3.6 MFDを用いた交通状況評価

マクロ交通量基本図 (Macroscopic Fundamental Diagram, MFD) は、都市レベルの複雑な道路網 (エリア) の交通状態・性能を巨視的にとらえる手法として Daganzo⁴⁾によって提案されたものである。MFD は、エリアの時間ごとの平均密度 (車両存在台数) と平均交通量 (スループット) をプロットした時にあらわれる関係関数であり、再現性の高い定義された MFD の存在が実証的に確認されている。また、MFD の形によって、どのような交通状態を示すかが判断でき、ネットワーク全体の混雑状況が把握可能である。そして、MFD は平均密度のみでエリアの交通状態をリアルタイムに観測できるため、多くの都市が抱える渋滞問題の瞬時把握に繋がる指標となる。

a) MFD の計算方法

本節では、京都市に設置された車両感知器のデータを用い、11/10 (土)、17 (土)、18 (日)、24 (土)、12/15 (土)、16 (日) の MFD 分析を実施した。なお、12/16 は雨天日であり、降雨の影響をみるために設定した。この検討では、京都府警により設置された1,548 個の交通量感知器データを用いる。車両感知器からは感知地点、地点交通量 (台)、地点占有率 (%), 地点平均速度 (km/h) のデータが24 時間5 分ごとに得られる。その車両感知器のデータから、各時間帯に観測された交通量のネットワーク全体での総和であるスループット \bar{Q} (台/5min) と、各時間帯に対象ネットワークで観測された交通密度のネットワーク全体での総和である車両存在台数 \bar{K} (台/km) を(3.13), (3.14)式によって算定し、横軸に車両存在台数、縦軸にスループットをとり、MFD を作成した。

$$\bar{Q} = \sum_{n=1}^N Q_n \quad \dots\dots\dots(3.13)$$

$$\bar{K} = \sum_{n=1}^N (Q_n \times 12 / V_n) \quad \dots\dots\dots(3.14)$$

ただし、

- N : 車両感知器数
- Q_n : 交通量 (台/5 分)
- V_n : 平均速度 (km/時)

b) MFD 計算結果

計算結果の例として、11/17, 24, 12/15 の結果を図 3.5(a)~(c)に示す。まず、最大スループットは、11/17, 24 でほぼ同様に 82,000 (台/5 分) あり、これがこのネットワークにおける晴天時の容量といえる。また、11/24 は三連休の中日であり、最も混雑が激しかった。それは、最大存在台数がかなり大きいこと、および渋滞延伸時と渋滞解消時の軌跡のずれ (ヒステリシス) の大きさから確認できる。また、午前 8~10 時には最大スループットが発現していることから、朝一番から混雑が発生していたといえる。さらに、

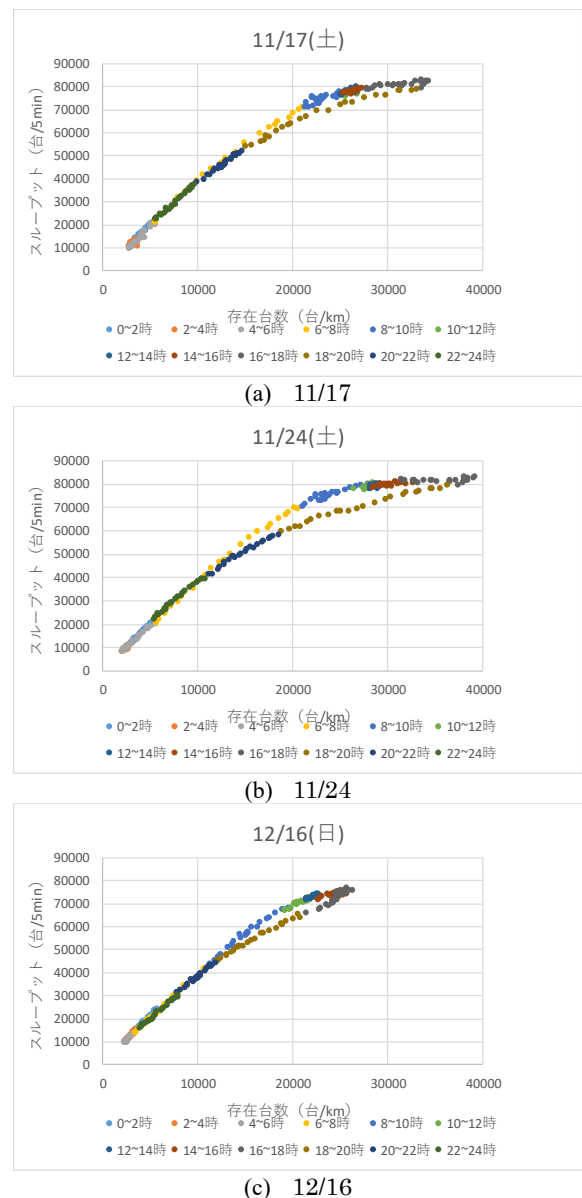


図 3.5 MFD 算定結果

12/16 と他の日を比較すると、最大スループットが 76,000 (台/5 分) とかなり減少しているにもかかわらずヒステリシスも確認されている。雨天となったこと、秋の観光シーズンも一段落となったことにより、交通需要は15%程度減少したものの、捌け可能交通量の方も3.5%減少し、結果として混雑が生じていたといえる。

3.7 推定結果を用いたトリップパターン評価

(1) 計算条件

最後に、実際のデータを用いて京都市内の自動車トリップパターン推定を行う。観測リンク交通量は、計算対象日において交通量感知器により得られた5 分間交通量を1 時間交通量に集計し使用する。動的リンク利用率は、所要時間、右左折数および信号交差点数を考慮する。各対象日の1 時間ごとのリンク所要時間平均値を ETC2.0 データから求め、それを

用いて表 3.3 のパラメータを用いてリンク利用率を求めた。また、先験 OD 確率は、道路交通センサ調査により得られた日平均のものを活用した。副モデルにおける時間帯寄与率も ETC2.0 データからのリンク所要時間平均値を用いる。

(2) 推定結果の考察

図 3.6 は、推定対象日の生成交通量の推移である。図中水色が土曜日、緑が日祝日である。図より、土曜日の生成交通量が 180 万台を超えているのに対して、日祝日は 170 万台前後であることがわかる。また、特に観光需要が高まり、混雑が激しいと考えられる 11/17、18 および 23~25 の交通量は、同一曜日のそれ以外の日と顕著に異なるわけではないことも確認できる。

次に、時間帯別にみた生成交通量の変化について、土曜日の生成交通量の推移を図 3.7 に示す。それぞれの日の変動はかなり類似しており、深夜の生成交通量は 11/10 から時間が経つにしたがって減少傾向にあるが、日中の生成交通量に大きな変化はない。17 時から 22 時ごろの交通量は 11/24、12/1 の方が他

の日程よりも大きくなっており、比較的遅くまで滞在していたと考えられる。また、1 時間あたりの生成交通量が最大となるのが 17 時台であり、土曜日で 12 万台、日祝日で 11.5 万台程度であった。

次に、トリップパターンの推移からの考察を行う。ここで示しているグラフは、弦グラフと呼ばれるものであり、それぞれの弦および帯の幅が OD 間の交通流動を示す。また、帯は、 i と j の間の移動とすると、 $x_{ij} < x_{ji}$ のとき、 i の色が塗られる。紙面の都合上割愛するが、トリップパターンについて、計算対象日間でそれほど大きな変動はないことが確認できた。次に、同じ 1 日のうちで、時間帯による変化について考察を加える。右京区を対象として考察を加える。図 3.8 に、最も混雑の激しかった 11/24 の 6~18 時について、2 つの時間帯に分割してトリップパターンを示す。外部との移動について帯の色を見てみると、6~11 時台については赤色ということで外部から右京区への流動が多く、逆に 12~23 時台では右京区から外部への流動が多いという結果となった。つまり、午前中に京都市内に流入し、午後に流出していく傾向にあるといえる。




図 3.6 生成交通量の推移


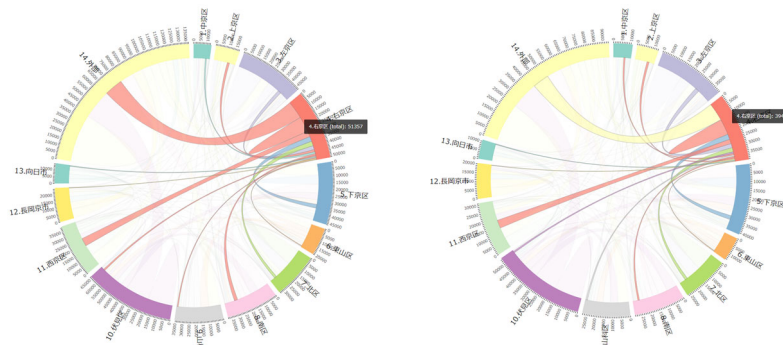


図 3.7 時間帯ごとの生成交通量（土曜日）



(a) 6~11 時台

(b) 12~17 時台

図 3.8 トリップパターンの日内変動（11/24、右京区）

3.8 おわりに

本章では、トリップパターン推定モデルの開発を行った。以下に主たる知見をまとめる。

- ・ 右左折数および交差点数を説明要因に加えた経路選択モデルにより経路選択の多様性が表現可能であることを確認した。また、リンク交通量の再現率も15%程度改善する。
- ・ 交通量感知器データを用いて MFD 分析を実施したところ、混雑を適切に表現しており、簡易に交通状態を評価する手段として MFD 分析が有効であることを示した。
- ・ 10日間を分析対象として動的トリップパターン推定を行った結果、インプットデータに応じて日生成交通量やその時間パターンは変化しており、観測交通量に整合した動的トリップパターンを推定していた。また、雨天時では最大存在台数が15%程度減少し、かつ最大スループットが2%程度低下していることが確認できた。

参考文献

- 1) (公財)日本道路交通情報センター：各種情報の提供 (<http://public-data.jartic-raws.durasite.net/opendata.html>), 2020/06/27 アクセス
- 2) Uno, N., Oda, T., Koga, M. and Kurauchi, F., “Evaluating Social and Economic Benefits of VICS WIDE and Its Future Prospects”, 23rd ITS World Congress, Melbourne, Australia, 11-14, Oct, 2016.
- 3) 大口敬：東京都市圏三環状道路の交通マネジメントに関する試論～ネットワークシミュレーションモデルとその適用～, 国際シンポジウム メガシティにおける道路ネットワーク交通マネジメント スライド資料, 2016.12
- 4) Daganzo, CF: “Urban gridlock: Macroscopic modeling and mitigation approaches”, Transportation Research, B41(1), 49-62, 2007.

第4章 乗客トリップパターン推定モデルの構築

4.1 はじめに

本章では、乗客トリップパターン推定モデルを構築し、京都市の繁忙期における乗客トリップパターンの推定を行う。まず、4.2で乗客トリップパターン推定モデルの定式化を示す。4.3で仮想的なデータを生成し、入力データの精度と推定精度の関係を明らかにする。最後に、4.4で2018年11月における乗客トリップパターンの推定を試みる。

4.2 乗客トリップパターン推定モデル

(1) 推定手法の概要

本研究で構築した推定手法は、乗り込み調査により得られた系統単位のトリップパターン（レグOD）を、ICカードデータや直接計測により得られる乗降人数データにより更新する第1段階と、第1段階で更新したレグODに加えてパーソントリップ調査データ等のデータから推計されるすべてのバス停の乗降人数データとバス停間サービスレベルデータを用いて乗り換えを考慮したトリップパターンであるジャーニーODを推定する第2段階からなる、ボトムアップ的な推定するものである。以下に、それぞれのモデルの定式化を示す。

(2) レグODパターン推定モデル

第1段階においては、佐佐木のエン트로ピーモデル¹⁾を援用し、一部のバス停において観測される系統・車両別の乗降人数と、乗り込み調査等により得られる先験OD情報からレグODパターンを推定する。レグOD推定モデルは以下のように定式化できる。

$$\min_{x_{ij}^{r_l(\tau)}; i < j \leq N} \sum_{n=1}^N \sum_{m=1}^{n-1} \left(x_{mn}^{r_l(\tau)} \ln \frac{x_{mn}^{r_l(\tau)}}{q_{mn}^{r_l(\tau)}} - x_{mn}^{r_l(\tau)} \right) \quad (4.1)$$

$$, \forall l \in L, r \in R_l, \tau \in T$$

such that

$$\sum_{i \geq n} \sum_{j \geq n+1} x_{ij}^{r_l(\tau)} \leq C_{r_l}, \quad (4.2)$$

$$n = 1, 2, \dots, N_l - 1, r \in R_l, l \in L, \tau \in T$$

$$\sum_{n < j \leq N} x_{nj}^{r_l(\tau)} = X_n^{r_l(\tau)}, n \in B_l, r \in R_l, l \in L, \tau \in T \quad (4.3)$$

$$\sum_{n < j \leq N} x_{nj}^{r_l(\tau)} = X_n^{r_l(\tau)}, n \in B_l, r \in R_l, l \in L, \tau \in T \quad (4.4)$$

ただし、

- L : 路線集合
- R_l : 路線 $l \in L$ におけるバス走行の集合
- T : 時間帯の集合
- N_l : 路線 $l \in L$ におけるバス停の集合（起点から順に番号を振るものとする）
- B_l : 路線 $l \in L$ において乗車人数を計測するバス停の集合
- C_{r_l} : バス $r \in R_l, l \in L$ の車内容量
- $X_n^{r_l(\tau)}$: バス $r \in R_l, l \in L$ の時間帯 $\tau \in T$ におけるバス停 $n \in B_l$ における乗車人数
- $Y_n^{r_l(\tau)}$: バス $r \in R_l, l \in L$ の時間帯 $\tau \in T$ におけるバス停 n における降車人数
- $x_{mn}^{r_l(\tau)}$: バス $r \in R_l, l \in L$ 、時間帯 $\tau \in T$ における mn 間の乗客需要（未知変数）
- $q_{mn}^{r_l(\tau)}$: バス $r \in R_l, l \in L$ 、時間帯 $\tau \in T$ における mn 間の乗客需要の先験情報データ

式(4.2)は、バス $r \in R_l, l \in L$ のバス停 $n, (n+1)$ 間の乗車人数が車両容量を超過しないという容量制約を表している。また、式(4.3)および(4.4)は、バス $r \in R_l, l \in L$ のバス停 n における降車および乗車人数が、および一部のバス停で直接観測する乗車人数と一致するということを表している。

(3) ジャーニーODパターン推定モデル

第2段階においては、ジャーニーODから推定されるレグODパターンが第1段階で推定されたレグODパターンを時間帯、路線別に集約したものと整合するように、ジャーニーODを推定する。

いま、ジャーニーODは以下に示すような重力モデルにより記述できるものとしよう。

$$\hat{T}_{OD}^\tau = (NB_0^\tau)^\alpha (NA_0^\tau)^\beta (d_{OD})^\gamma (LOS_{OD}^\tau)^\delta, \quad (4.5)$$

$$\forall O, D \in N$$

ただし、

- NB_0^τ : 時間帯 $\tau \in T$ におけるバス停 $O \in N$ における乗車人数
 NA_D^τ : 時間帯 $\tau \in T$ におけるバス停 $D \in N$ における降車人数
 d_{OD} : OD間の直線距離
 LOS_{OD}^τ : 時間帯 $\tau \in T$ におけるOD間の一般化費用
 N : バス停の集合
 $\alpha, \beta, \gamma, \rho$: 推定対象パラメータ

さらに、ジャーニーODの路線利用確率が与件のとき、栞元ら²⁾を参考にジャーニーODとレグODには以下の関係式が成り立つ。

$$\hat{y}_{mn}^{l(\tau)} = \sum_{OD \in \Omega} \hat{\mu}_{rs,l}^{OD}(\tau) \hat{T}_{OD}^\tau, \quad (4.6)$$

$$\forall mn \in \omega, r \in R_l, l \in L, \tau \in T$$

ただし、

- Ω : ジャーニーのODペアの集合
 ω : レグのODペアの集合
 T_{OD}^τ : 時間帯 $\tau \in T$ におけるジャーニーOD需要
 $\mu_{rs,l}^{OD}(\tau)$: T_{OD}^τ の路線 l, rs 間の利用率
 \hat{A} : A の推定値

ここで、式(4.6)によりジャーニーODから求められるレグODと、第1段階で推定したレグODの誤差率が平均0の正規分布に従うと仮定すると、全レグペアにおける同時確率密度は以下のように表せる。

$$L_\tau = \prod_{\substack{mn \in \omega \\ l \in L}} \left[\frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{1}{2} \frac{\{\ln(\hat{y}_{mn}^{l(\tau)}) - \ln(\hat{y}_{mn}^{l(\tau)})\}^2}{\sigma^2}\right) \right]^{\delta_{mn}^l} \quad (4.7)$$

ここに、 σ^2 は推定対象の分散パラメータであり、 δ_{mn}^l は路線 $l \in L$ にレグODペア mn が含まれていれば1をとるダミー変数である。また、 \hat{y}_{mn} は第1段階で推定したレグODパターン $\hat{x}_{mn}^{r_l(\tau)}$ を式(4.8)により時間帯、路線別に集約したレグODパターンであり、 \hat{y}_{mn} は式(4.5)により第2段階で推定するジャーニーODパターンを式(4.6)によりレグODパターンに変換されるものである。

$$\hat{y}_{mn}^{l(\tau)} = \sum_{r \in R_l(\tau)} \hat{x}_{mn}^{r_l(\tau)}, \quad \forall mn \in \omega \quad (4.8)$$

式(4.5)に示したパラメータは、式(4.7)に示した L を尤度関数とする最尤推定法により求める。

なお、本研究の対象である京都市においては複雑な路線網が形成され、また高頻度のバスサービスが提供されている都市部への適用を念頭に置いているため、ジャーニーODの路線利用確率 $\mu_{rs,l}^{OD}(\tau)$ および重力モデルの説明変数であるジャーニーODペア間の一般化費用は最小費用Hyperpath探索アルゴリズム³⁾により求める。

4.3 実規模ネットワークにおける推定精度検証

(1) 推定精度検証方法

本章では、実規模ネットワークを用いて提案したモデルの推定精度の検証を行う。レグOD推定精度検

証を行うにあたり、設定したジャーニーODの真値を公共交通ネットワーク上に配分することにより系統・バス停別乗降人数と、ジャーニーODのレグ利用率 $\mu_{rs,l}^{OD}$ の真値を算出する。ついで、ジャーニーODの真値とレグ利用率 $\mu_{rs,l}^{OD}$ からレグODデータの真値を作成し、これに誤差を付与した「レグODの先験情報データ」を作成する。このデータと、誤差を付与した「系統・バス停別乗降人数データ」を用いて、レグODの推定精度を検証する。ジャーニーOD推定精度は、ゼロフロー配分を行うことにより、公共交通ネットワークにおける混雑を考慮しない条件下におけるODペア間一般化費用とレグ利用率 $\mu_{rs,l}^{OD}$ を算出し、これらのデータと前段階において推定した「レグODデータ」およびジャーニーODの真値データの集計値に誤差を付与した「バス停別乗降客数」データを用いて検証する。

なお、混雑が発生する場合は車両に乗車できない可能性が発生するため、乗客の経路選択に影響を及ぼす。したがって、本来はレグ利用率 $\mu_{rs,l}^{OD}$ 算出する際には均衡配分により混雑の影響を加味する必要がある。その場合はジャーニーOD推定と均衡配分を収束するまで繰り返すことが必要となるが、後述するように均衡配分の計算負荷が非常に大きく現実的な時間内で計算できない。そこで、ゼロフロー配分により算出したレグ利用率を用いた推定結果と、均衡配分⁴⁾により算出したレグ利用率を用いた推定結果の比較を行い、レグ利用率算出にあたり混雑の影響の有無が推定精度に及ぼす影響についても考察を加える。

(2) 分析対象ネットワークと真値の設定

本研究では、京都市バスネットワークにおける概ね京都駅以北の均一料金区間のエリアを分析対象ネットワークとして設定する。分析対象ネットワークにおけるそれぞれのバス系統の経路と運行頻度は2018年10月時点の平日の時刻表を参考に作成した。バス停数、系統数はそれぞれ403、135となった。図4.1に検証用ネットワークの範囲を示す。

ジャーニーODの真値の設定にあたり、各バス停における乗降人数を設定し、これを式(4.5)のパラメータを設定した上で以下に示す式により変換した。

$$\hat{T}_{OD}^\tau = (NB_0^\tau)^{0.9} (NA_D^\tau)^{0.9} (d_{OD})^{-0.4} (LOS_{OD}^\tau)^{-0.5} \quad (4.9)$$



図4.1 分析対象ネットワーク

表 4.1 推定モデルの入力データ

モデル	入力データ	想定されるデータソース
レグOD 推定モデル	系統別・バス停別乗降人数 (一部バス停)	直接計測
	レグODの先験情報	乗り込み調査
ジャーニーOD 推定モデル	バス停別の全系統の乗降人数	パーソントリップ調査
	ジャーニーODのレグ利用率	バスネットワーク

なお、ODペア間の一般化費用 LOS_{OD} はゼロフロー配分により求めた値を用いる。その上で、京都市バスの1日あたりの利用者数⁵⁾を参考に、ジャーニーODの総量が30万人になるように拡大し、これを「有効頻度」⁶⁾により混雑の影響を考慮して配分した。繰返し回数が50回で概ね収束に近づいたことを確認している。なお、汎用WS (Intel Xeon (R) CPU E-5-1603 2.80GHz, 64GB RMM) を用いて計算に14日程度の時間を要した。

本研究で構築するモデルの入力データは表4.1の通りであり、それぞれのデータに誤差を付与する。

(3) レグOD推定精度検証

本節では、前述したレグOD推定モデルにおける2つの誤差要因に加え、乗降人数を観測するバス停数が推定精度に及ぼす影響を評価する。系統別・バス停別乗降人数の観測誤差の平均を0, 0.05, 0.1の3水準に、レグODの先験情報誤差の平均を0, 0.1, 0.2, 0.3の4水準に、乗車人数の観測箇所数を全バス停の0%から10%刻みに100%までの11水準とし、これらの全要因を組み合わせて推定を行った。なお、乗降人数を計測するバス停は乗降人数が多いバス停から順に設定した。また、乱数の影響を考慮するため、系統別・バス停別乗降人数とレグODの先験情報はそれ

ぞれの平均に対して20回乱数を発生させ、合計1871回の推定を行った。

図4.2に先験情報誤差、乗降人数観測誤差、乗降人数観測比率と推定精度の関係を示す。図中における棒グラフはRMSE誤差の平均値を、線グラフはその最大値と最小値を表している。図4.2(a)を見ると、先験情報誤差が大きくなるにつれRMSE誤差の平均値およびその最大値が大きくなっており、先験情報誤差が大きくなるにつれてレグODの推定精度が悪化することが読み取れる。しかし、図4.2(b)および図4.2(c)を見ると、乗降人数の観測誤差および観測箇所数はレグODの推定精度に大きな影響を及ぼさないといえる。

次に、RMSE誤差が最小値、中央値、最大値におけるレグODの真値と推定値の比較を図4.3に示す。図中に、それぞれのケースにおける先験情報誤差、乗降人数観測誤差および観測比率の水準も示している。RMSE誤差最小値ケースでは相関係数も0.999と非常に高く、レグODをほぼ正確に推定できているといえる。RMSE誤差中央値、最大値ケースの相関係数も0.9を超えており、さらに真値と推定結果の関係が45度線上に分布していることから、本研究におけるレグOD推定モデルは観測誤差に対して頑強であるといえる。なお、RMSE誤差最大値ケースは、誤差なく90%ものバス停で乗降人数を観測するケースに相当する。本研究で用いたレグOD推定モデルは両側制約つきエントロピーモデルの1種であり、先験情報誤差が0.3と大きい中で制約条件数が多くなったためであると考えられる。

(4) ジャーニーOD推定精度検証

次に、ジャーニーODの推定精度の検証を行う。前




図 4.2 観測誤差要因とレグ OD の推定精度の関係

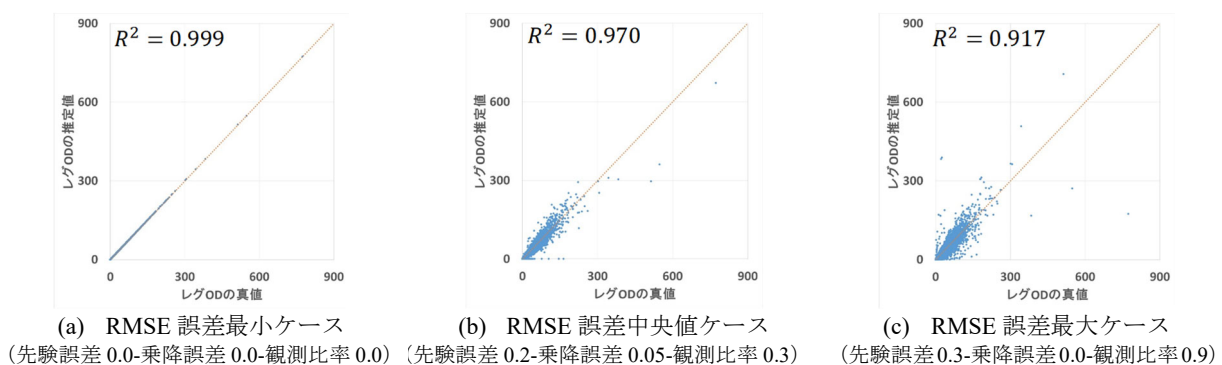


図 4.3 レグ OD の真値と推定値の比較




図 4.4 観測誤差要因とジャーニーOD の推定精度の関係

表 4.2 ジャーニーOD 推定モデルのパラメータ推定結果

		RMSE誤差最小値ケース		RMSE誤差中央値ケース		RMSE誤差最大値ケース	
		推定値	P値	推定値	P値	推定値	P値
推定結果	乗車人数	0.781	0.000	0.744	0.000	0.539	0.000
	降車人数	0.755	0.000	0.686	0.000	0.553	0.000
	直線距離	0.008	0.017	-0.246	0.000	-0.221	0.000
	一般化費用	-1.517	0.000	-1.375	0.000	-0.966	0.000
	ρ^2	0.121	0.000	1.134	0.000	0.467	0.000
	初期尤度	-7.50E+06		-6.01E+06		-7.39E+06	
	最終尤度	-1.34E+04		-4.46E+04		-3.82E+04	
入力データ	レグOD推定精度	Best		Medium		Best	
	乗降人数観測誤差	0.1		0.15		0.3	
	車内混雑の考慮	有		無		有	

述したように、ジャーニーOD推定モデルにおける誤差要因は、バス停別の全系統の乗降客数とレグ利用率算出の際の車内混雑の考慮の有無である。バス停別の全系統の乗降客数の観測誤差を0, 0.05, 0.1, 0.15, 0.2, 0.25, 0.3の7水準、レグ利用率算出の際の車内混雑の有無を2水準として設定した。これらの誤差要因に加えて、入力データであるレグODの推定精度の影響を評価するため、前節で述べたレグODの推定結果のうち、前節で述べたRMSE誤差が最小値、中央値、最大値のときの3種類のレグOD推定値を入力データとして用いる。また、乱数の影響を考慮するため、乗降客数の観測誤差のそれぞれの平均に対して20回乱数を発生させ、合計726回の推定を行った。

図4.4に観測誤差要因とジャーニーODの推定精度の関係を示す。棒グラフはRMSE誤差の平均値を、線グラフはその最大値と最小値を表している。また、図中における'Best', 'Medium', 'Worst'はそれぞれRMSE誤差が最小値、中央値、最大値のときのレグOD推定値を表しており、'W/O', 'With'はそれぞれレグ利用率算出の際に混雑を考慮していないケース、考慮しているケースを表している。図4.4(a)を見ると、推定精度が中程度のレグODを入力データとして用いたときにRMSE誤差の平均が最大となり、推定精度が最良と最悪のレグODを入力データとして用いたときのRMSE誤差の平均は同程度である。しかし、RMSE誤差の最大値に着目すると、レグODの推定精度が最良の場合が最大となっており、レグODの推定精度とジャーニーODの推定精度の間に一定の

関係は見られない。図4.4(b)を見ると、乗降人数観測誤差が0.1程度までのRMSE誤差の平均値および最大値はほぼ横ばいであり、構築したモデルは乗降人数観測誤差に関してある程度頑強であるといえる。しかし、乗降観測誤差が0.15より大きくなると、RMSE誤差は増加する傾向にあるといえる。図4.4(c)を見ると、ジャーニーODのレグ利用率を算出する際に混雑を考慮することによりRMSE誤差の最小値と平均値は減少していることが読み取れる。

最後に、RMSE誤差が最小値、中央値、最大値ケースにおけるパラメータの推定結果とジャーニーODの推定精度について考察する。表4.2にジャーニーOD推定モデルのRMSE誤差が最小値、中央値、最大値ケースにおけるパラメータの推定結果と入力データを示す。すべてのケースにおいてパラメータは統計的に有意となり、またRMSE誤差最小値ケースの直線距離以外のパラメータは符号条件を満たしていることがわかる。図4.5にRMSE誤差が最小値、中央値、最大値ケースにおけるジャーニーODの真値と推定値の比較を示す。RMSE誤差最小値ケース、中央値においては相関係数がそれぞれ0.948, 0.930と非常に高く、ジャーニーODの真値が大きいODペアにおいてやや過小推定の傾向が見られるが概ね正確に推定できているといえる。しかし、RMSE誤差最大値ケースにおいては、相関係数も0.826とやや低く、さらには全体的に過小推定の傾向が見られる。




図 4.5 ジャーニーOD の真値と推定値の比較

4.4 2018年秋におけるトリップパターン推定

本節では、図4.1に示したネットワークを対象範囲として、2018年11月の繁忙期における京都市バスの乗客トリップパターンの推定を行う。

(1) 使用したデータ

レグODの先験情報として、京都市交通局より提供を受けた平成24年5月の平日に行われた旅客流動調査データを用いる。データの概要を表4.3に示す。なお、旅客流動調査の実施年月（2012年5月）が分析対象年月（2018年11月）とずれているため、京都市交通局から公表されている京都市交通事業白書に記載されている月別旅客数（1日平均）データから算出される、平成24年5月と平成30年11月の1日平均旅客数の比率を用いて補正を行った。

ジャーニーOD推定モデルの入力データである、バス停ごとの乗降客数を推定するために、歩くまち京都アプリ「バス・鉄道の達人」の検索位置情報データ（GNSSデータ）を用いる。データ概要を表4.4に示す。なお、Android利用者およびiOS利用者の両方のデータが取得されているが、システムの仕様上

表 4.3 旅客流動調査の概要

調査実施日	平日調査 （全系統、全ダイヤで実施） 平成24年5月22日（火）、5月24日（木）、5月29日（火） 休日調査 （全系統、1時間に1運行程度の抽出調査） 平成24年5月27日（日）、6月3日（日） 土曜調査 （7系統、1時間に1運行程度の抽出調査） 平成24年6月2日（土）
調査項目	<ul style="list-style-type: none"> 乗車・降車停留所 利用券種 乗車目的 乗車前後の乗継状況
調査方法	各車両に2名の調査員が添乗し調査カードの配布、回収した

表 4.4 歩くまち京都アプリ「バス・鉄道の達人」の取得データ概要

期間	2018年9月1日～2019年2月27日
対象者	GNSSデータ取得を承諾したアプリユーザー
取得項目	<ul style="list-style-type: none"> ユーザーID 取得日、取得時刻 緯度、経度 OS（iOSまたはAndroid） 言語、国コード スクリーンタッチの有無に関する情報

Android利用者の位置情報は概ね1時間に1回程度取得されているのに対し、iOS利用者のうち位置情報のプライバシー設定を「常に許可」と設定している一定距離移動した利用者の位置情報はより詳細に記録されているため、本章ではiOS利用者のデータのみを分析に用いた。

(2) GNSSデータを用いた乗降客数の推定


前述したGNSSデータは、移動中における連続する位置情報が記録されている。本章では付録に示す手順に従って乗降客数の推定を行った。分析対象の5日間で全データのうち0.2%に相当する34,000件程度の乗車場所、時刻および降車場所、時刻のデータを取得できた。分析時間帯幅を決定するために、GNSSデータにより抽出された日別・時間帯別の乗降サンプル数を図4.6に示す。これを見ると、乗降とも24日の午後のサンプル数はやや多い傾向が見受けられるが、日によるサンプル数の大きな差はないといえる。また、時間帯に着目すれば各日とも夕方サンプル数のピークがあることが見受けられるが、ピーク時間帯におけるサンプル数も300件程度にとどまっており、時間帯幅を1時間とした場合には乗降サンプルが0となるメッシュが存在することが危惧される。そこで、本章では時間帯ごとのサンプル数を勘案して、1) 6:00～8:59, 2) 9:00～11:59, 3) 12:00～16:59, 4) 17:00～の4時間帯にわけて分析することにした。

図4.7に時間帯ごとの乗車場所の分布を示す。6:00～8:59の時間帯は京都駅を含むメッシュのデータ件数が占める割合が高く、その後京都駅を含むメッシュ以外の乗降人数が占める割合も増加していることがわかる。また、サンプル数が少ない6:00～8:59の時間帯においても、ほぼすべてのメッシュで1件以上の乗車データが算出されていることがわかる。また、降車場所の分布も同様に図示したところ、すべての時間帯でほぼすべてのメッシュで1件以上のデータが算出されていることを確認している。


(3) ジャーニーODの推定における留意点

(1)および(2)で述べたデータを用いてジャーニーODを推定するが、データ制約のための以下に述べる点に留意が必要である。

まず、分析対象期間において系統別の乗降人数を調査していないため、レグODの推定値は、京都市交通局より提供を受けた旅客流動調査データを補正し




(a) 乗車データ




(b) 降車データ


図 4.6 GNSS により抽出された時間帯別サンプル数




(a) 6:00~8:59 ($N = 1,922$)



(b) 9:00~11:59 ($N = 3,416$)



(c) 12:00~16:59 ($N = 6,309$)



(d) 17:00~ ($N = 5,188$)

図 4.7 推定された乗車場所の分布 (5 日間の合計)

たものを用いた。なお、4.2で確認したように、レグ OD の推定精度がジャーニー OD の推定精度に及ぼす影響は小さいため、レグ OD を観測値により更新しないことの影響は大きくないと思われる。

次に、計算時間の都合上、乗客配分モデルにおいて混雑の影響を加味していない。今回は観測していないが、経験的に乗客が集中するバス停において乗客の到着および乗車時刻を観測することにより、混雑の影響を加味した推定が行えると思われる。

最後に、GNSS データ数の制約のために、(2) で述べたように 4 時間帯の推定にとどまっている。さらに、分析対象期間中における日ごとの総需要データが入手できなかったため、推定された乗車人数および降

車人数の総数の日変動は考慮されておらず、ジャーニー OD の日変動は比較できない。

(4) ジャーニー OD の推定結果

表 4.5 に、ジャーニー OD 推定モデルパラメータの推定結果を示す。これを見ると、GNSS のサンプル数の多い 12:00~16:59 の時間帯では、5 日間ともすべてのパラメータの符号条件を満たしており、また有意に推定されていることがわかる。しかし、その他の時間帯では、有意に推定されていない、あるいは符号条件を満たしていないパラメータも見受けられる結果となった。なお、6 章において、推定されたジャ

表 4.5 ジャーニーOD 推定モデルのパラメータの推定結果

			乗車人数	降車人数	直線距離	一般化費用	ρ^2	初期尤度	最終尤度
11月17日	6:00~8:59	推定値	0.00	-0.04	-0.99	0.45	2.63	-3,038,500	-44,617
		P値	0.500	0.001	0.000	0.000	0.000		
	9:00~11:59	推定値	0.49	0.46	-0.58	-0.52	3.05	-3,810,600	-53,935
		P値	0.000	0.000	0.000	0.000	0.000		
	12:00~16:59	推定値	0.50	0.48	-0.54	-0.65	3.51	-4,374,400	-55,848
		P値	0.000	0.000	0.000	0.000	0.000		
	17:00~	推定値	0.46	0.47	-0.55	-0.58	3.20	-4,260,500	-54,595
		P値	0.000	0.000	0.000	0.050	0.000		
11月18日	6:00~8:59	推定値	0.00	-0.18	0.74	0.15	5.17	-2,944,600	-52,781
		P値	0.500	0.067	0.000	0.133	0.000		
	9:00~11:59	推定値	-0.05	0.00	-1.09	0.45	2.37	-3,813,800	-46,522
		P値	0.475	0.500	0.014	0.046	0.032		
	12:00~16:59	推定値	0.50	0.48	-0.53	-0.65	3.31	-4,425,900	-55,039
		P値	0.000	0.000	0.000	0.000	0.000		
	17:00~	推定値	0.00	-0.03	-0.77	0.38	4.08	-4,102,600	-49,570
		P値	0.500	0.138	0.005	0.000	0.004		
11月23日	6:00~8:59	推定値	0.00	-0.24	-1.21	0.59	7.47	-2,937,400	-55,099
		P値	0.500	0.000	0.000	0.000	0.000		
	9:00~11:59	推定値	0.00	-0.02	-0.94	0.40	2.48	-3,709,000	-46,210
		P値	0.500	0.003	0.000	0.000	0.000		
	12:00~16:59	推定値	0.52	0.46	-0.56	-0.63	3.15	-4,359,600	-54,348
		P値	0.000	0.000	0.000	0.000	0.000		
	17:00~	推定値	0.42	0.45	-0.57	-0.53	3.80	-4,249,800	-56,921
		P値	0.000	0.000	0.000	0.000	0.000		
11月24日	6:00~8:59	推定値	0.43	0.40	-0.64	-0.30	8.06	-3,052,200	-67,189
		P値	0.000	0.000	0.000	0.000	0.000		
	9:00~11:59	推定値	0.46	0.47	-0.61	-0.48	3.75	-3,728,200	-56,756
		P値	0.164	0.225	0.221	0.000	0.000		
	12:00~16:59	推定値	0.50	0.48	-0.55	-0.64	3.26	-4,335,700	-54,852
		P値	0.000	0.000	0.000	0.000	0.000		
	17:00~	推定値	0.00	0.00	0.70	-0.18	2.31	-4,264,300	-59,530
		P値	0.500	0.500	0.149	0.306	0.000		
11月25日	6:00~8:59	推定値	-0.15	0.00	-1.07	0.51	2.64	-3,049,800	-46,017
		P値	0.000	0.500	0.000	0.000	0.000		
	9:00~11:59	推定値	0.51	0.47	-0.59	-0.54	2.98	-3,834,800	-53,622
		P値	0.000	0.000	0.000	0.000	0.000		
	12:00~16:59	推定値	0.46	0.48	-0.55	-0.62	3.18	-4,422,300	-54,501
		P値	0.000	0.000	0.000	0.000	0.000		
	17:00~	推定値	0.42	0.47	-0.58	-0.52	3.90	-4,126,300	-57,284
		P値	0.000	0.000	0.000	0.000	0.000		

ジャーニーODを用いて交通マネジメント対策がバス利用者の流動に及ぼす影響を考察する。

(5) ジャーニーODの推定結果と滞留人口相関分析

最後に、推定されたジャーニーODの推定精度を検証するため、推定されたジャーニーODからバス停ごとの乗降人数の合計値を算出し、これを3次メッシュ単位に集計したものとモバイル空間統計の滞留人口データの相関係数を比較する。なお、モバイル空間統計データには、1)バス利用者以外の滞留人数も含まれている、2)データ仕様上短時間の立ち寄り客数は計上されないため、例えば京都駅等のターミナル駅に短時間滞留した人数が乖離する可能性がある、という限界がある点に注意が必要である。

表4.6に結果を示す。これを見ると、データ数の多い12:00~16:59の時間帯における相関係数は他の時間帯よりも大きいことがわかる。図4.8に相関係数が最小ケースと最大ケースにおけるジャーニーODから算出した滞留人数と滞留人口データの比較を示す。相関係数最小ケースはジャーニーODから算出した


表 4.6 ジャーニーOD から算出したメッシュ 滞在人数と滞留人口データ間の相関係数

時間帯 \ 日にち	11月17日	11月18日	11月23日	11月24日	11月25日
6:00~8:59	-0.284	-0.304	-0.382	-0.326	-0.404
9:00~11:59	0.086	-0.051	0.060	0.167	0.056
12:00~16:59	0.249	0.294	0.427	0.428	0.310
17:00~	-0.227	-0.339	-0.166	-0.145	-0.314


滞留人数は0であるにもかかわらず、滞留人口データの値が大きい点が少なからず見られるため、グラフは右肩下がりとなった。相関係数最大ケースでは、概ね右肩上がりの関係となり、両者の間に正の相関があることがわかる。

4.5 おわりに

本章では、京都市バスネットワークにおける乗客のトリップパターン推定モデルを構築した。京都市を模した仮想的な入力データを作成し、入力データ



(a) 相関係数最小ケース (23日 6:00~8:59)



(b) 相関係数最大ケース (24日 12:00~16:59)

図 4.8 滞留人数の比較

の精度と推定精度の関係を明らかにした。その上で、2018年11月休日のトリップパターンの推定を行った。GNSSデータ数の多い12:00~16:59の時間帯における推定モデルのパラメータは符号条件を満たしており、統計的に有意であることを確認した。さらに、モバイル空間統計の滞留人数とも一定の相関があることを確認した。

参考文献

- 1) 佐佐木綱：トリップの OD 分布を求める確率的方法，交通工学，2(6)，12-21，1967
- 2) 柘元淳平，奥村誠，塚井誠人：純流動データによる都道府県間純流動の逆推定，土木計画学・論文集 21(1)，83-89，2004
- 3) 倉内文孝，嶋本寛，王萍，飯田恭敬：最小費用 Hyperpath 探索アルゴリズムを用いたバスサービス評価に関する研究，土木計画学研究・論文集，23(3)，755-761，2006
- 4) 嶋本寛，倉内文孝，飯田恭敬：乗客配分モデルを用いた公共交通の混雑緩和施策評価，土木計画学研究・論文集，22(1)，239-246，2005
- 5) 平成 30 年度京都市交通事業白書，<https://www.city.kyoto.lg.jp/kotsu/page/0000073257.html> (2020年6月最終アクセス)
- 6) De Cea, D. and Fernandez, E. Transit assignment for congested public transport systems, Transportation Science, 35, 250-267, 1993

付録 GNSS データからバス停別乗降人数の推定

Step 1 GNSSデータから乗降データの抽出

GNSSデータからiOSデータのみを抽出し、これを日ごと、IDごとに並び替えたのちに以下のルールに従って乗降データを抽出する。

乗車データ

$\Delta t_{i-1}^i = t_i - t_{i-1} \geq 30$ and $\Delta t_i^{i+1} = t_{i+1} - t_i < 30$ ならば i 番目のデータを乗車データとして抽出

降車データ

$\Delta t_{i-1}^i = t_i - t_{i-1} < 30$ and $\Delta t_i^{i+1} = t_{i+1} - t_i \geq 30$ ならば i 番目のデータを降車データとして抽出

ただし、 t_i は i 番目のデータが観測された時刻を表している。

Step 2 3次メッシュ単位の乗降人数(標本値)の算出

Step1で推定した乗降データを3次メッシュ単位で集計し、時間帯ごとの乗車人数および降車人数 B_m^τ および A_m^τ (m および τ はそれぞれ3次メッシュ，時間帯を表す添え字) を算出する。

Step 3 バス停ごとの乗降人数(標本値)の算出

Step2で算出した3次メッシュ単位の乗車人数，降車人数を，メッシュに含まれる個々のバス停の乗車人数，降車人数に振り分ける。ここでは，各バス停の乗降人数は旅客流動調査データを集計して得られる乗降人数に比例すると仮定し，以下の式により振り分けを行う。

$$GB_O^\tau = \frac{b_O}{\sum_{O' \in N_m} b_{O'}} B_m^\tau, \forall O \in N_m, m \in M \quad (4.10)$$

$$GA_D^\tau = \frac{a_D}{\sum_{D' \in N_m} a_{D'}} A_m^\tau, \forall D \in N_m, m \in M \quad (4.11)$$

ここに、 b_O 、 a_D は旅客流動データから得られる系統別 OD 需要を集計して得られるバス停 O および D の乗車，降車需要を表しており、 N_m はメッシュ m に含まれるバス停の集合である。

Step 3 バス停ごとの乗降人数の推定

Step2 および Step3 で推定された乗降人数は GNSS データから得られた標本データである。ここでは、ベイズ更新の考え方を援用して旅客流動データと GNSS データから以下の式により乗車人数および降車人数の推定値を算出する。

$$\widehat{NB}_O^\tau = \frac{GB_O^\tau SB_O}{\sum_{O' \in N} GB_{O'}^\tau SB_{O'}} NB^\tau, \forall O \in N \quad (4.12)$$

$$\widehat{NA}_D^\tau = \frac{GA_D^\tau SA_D}{\sum_{D' \in N} GA_{D'}^\tau SA_{D'}} NA^\tau, \forall D \in N \quad (4.13)$$

ここに、 SB_O および SA_D は旅客流動データを集計して得られるバス停ごとの乗車，降車人数を表している。さらに、 NB^τ および NA^τ は時間帯 τ における全バス停の乗車人数および降車人数の合計であり，本研究では旅客流動調査データから補正される2018年11月における系統別 OD 需要の合計を，GNSS データから時間帯別に推定された降車人数のサンプル比率に応じて按分することにより求めた。

第5章 トリップチェーン推定手法の構築

5.1 はじめに

本章では、3章及び4章の成果物である自動車及び乗客のトリップパターンを所与とし、これらに外部のいくつかのデータを組み合わせることで都市内のトリップチェーンを推定するモデルを構築する。

5.2にモデルの概要を説明し、5.3には仮想ネットワークを用いた試算について述べる。5.4では外部データのひとつであるアプリGNSSデータの概要及びこのデータ単体でのトリップチェーン推定について述べ、5.5では実データを用いて提案モデルの京都市への適用について述べる。

5.2 トリップチェーン推定手法の構築

(1) 概要

本章で言うトリップチェーンはある設定したゾーンにおいて、移動・滞留を単位時間帯ごとに選択した結果として得られる時系列の軌跡のこととする。観光行動では、たとえば一日などの単位の時間内で観光地の魅力とその間の移動時間等に基づいて検討し、一連のトリップチェーンを戦略的に決定することも多くあるだろう。しかしながら、そのような選択されうるトリップチェーンをすべて列挙し、選択確率を与えるモデルは移動・滞留の時空間的な組み合わせが膨大となり、推定が困難である。したがって移動・滞留の選択行動がマルコフ性をもつと仮定して、属性別・モード別の目的地選択確率を推定し、




図 5.1 目的地選択確率とトリップチェーンの選択確率の関係

図 5.1 のような連鎖によりトリップチェーンが選択されると仮定する。なお、1 時間帯の行動についてマルコフ性を仮定する場合は十分な精度を得られないため、2 時間帯にわたった移動・滞留行動選択を仮定したモデルを採用する。

(2) トリップパターン $x_{ijklmkt}$ の設定及び補正

モデルにインプットする値である、出発地*i*から*j*、*l*と推移する時間帯*t*、属性*k*、モード*m*の人数を $x_{ijklmkt}$ とする。この値の設定のためには2時間帯にわたる観測データが必要となるが、本研究で用いるデータのうち、表5.1に示したA及びBは1時間帯毎に区切られたものである。そこで、まずA及びBのデータから1時間帯毎の $x_{ijklmkt}$ を設定し、これを単純積して得る $x_{ijklmkt}$ を事前確率算出のための集団とし、2時間帯にわたる観測データ(アプリGNSSデータ)を用いてベイズ更新する方法をとる。本節で提案する $x_{ijklmkt}$ の補正は下記のベイズ更新式に従う。

$$\Pr\left((j, l, m | i, k, t) | (j, l, \widehat{m | l, k, t})\right) = \frac{\Pr(j, l, \widehat{m | l, k, t}) \cdot \Pr(j, l, m | i, k, t)}{\sum_{j, l} \Pr(j, l, \widehat{m | l, k, t}) \cdot \Pr(j, l, m | i, k, t)} \quad (5.1)$$

ここで、 $\Pr(j, l, \widehat{m | l, k, t})$: アプリ等で観測された出発地*i*、属性*k*、時間帯*t*の人がモード*m*を利用して*j*、*l*の順に移動・滞留した比率。 $\Pr(j, l, m | i, k, t)$: データA及びBより得られた出発地*i*、属性*k*、時間帯*t*の人がモード*m*を利用して*j*、*l*の順に移動・滞留する確率。

なお、1 時間帯毎の $x_{ijklmkt}$ の値自体も直接取得はできないため、属性とモードが独立の関係にあることを仮定し、既知のデータA及びBから表5.1のように比率を按分することで与えている。

表5.1 独立仮定による $x_{ijklmkt}$ の設定方法

	モード1	モード2	計
属性1	AB %	B(1-A) %	B %
属性2	A(1-B) %	(1-B)(1-A) %	(1-B) %
計	A %	(1-A) %	100 %

A: OD表(3章及び4章の成果物)により既知

B: モバイル空間統計の属性情報により既知

(3) 2時間帯の移動・滞留選択確率推定モデル

構築したモデルは式(5.2), (5.3)に示すとおりである。式(5.2)は時間帯 t に属性 k で、ゾーン i の人がモード m で1時間帯後にゾーン j ,次いで2時間帯後にゾーン l に移動・滞留する確率を示す。選択確率にはロジットモデルを用いている。効用関数は式(5.3)で定義し、出発ゾーン、最終目的ゾーンで得られる効用を考慮した第1項, その間に訪れるゾーンを組み合わせた効用である第2項, 移動時間と移動費用を表現した第3, 4項で構成される。

$$\Pr(j, l, m|i, k, t) = \frac{\exp(V(j, l, m|i, k, t))}{\sum_{j', l', m'|i, k, t} \exp(V(j', l', m'|i, k, t))} \quad (5.2)$$

$$V(j, l, m|i, k, t) = \frac{\delta_{ikt} + \delta_{lkt}}{2} + \delta_{jkt} + \alpha_t t_{ijlmt} + \alpha_{km} \gamma_{km} \quad (5.3)$$

尤度関数は式(5.4)の通りとなり、この最大化によりパラメータを特定する。

$$L(\alpha, \gamma, \delta) = \prod_{i, j, k, m, t} \Pr(j, l, m|i, k, t)^{x_{ijklmkt}} \quad (5.4)$$

5.3 仮想ネットワークにおけるモデルの適用

現在、我が国におけるデータの蓄積状況ではトリップチェーン、およびその量を把握することが容易でない。PT調査はサンプルとしての利用は可能であるものの、真値として取り扱うことは適切ではないだろう。そこで本研究では、Siouxfallsネットワークにおいて疑似的なトリップチェーンの仮想データを作成し、これを用いてモデルの精度検証を行う。

(1) $x_{ijklmkt}$ の設定値及び補正值の検証

$x_{ijklmkt}$ の仮想真値を x 軸に、推定値を y 軸にとった散布図を図5.2に示す。色はベイズ更新の回数を示しており、青色(0回)は更新前の独立仮定による値である。独立仮定の値に着目すると、(a)は $x = y$ よりも

下側にプロットが集中しており、過小推計となっていることがわかる。(b)では $x = y$ よりも上側のプロットもあるものの、いずれにしても十分な精度で推計されていないことはわかる。一方で、(c)は $x = y$ に近いプロットが多く、比較的良好な精度で推定できていることがわかる。ベイズ更新後の値に着目すると、(a)はやや改善がみられるが、その他は繰り返し更新しても大きな改善は見られない。この原因はここで試みたベイズ更新があくまで2時間帯にまたぐ移動の独立仮定による誤差を縮小するために適用したものであり、モード別選択と旅行者・住民の行動選択に関する独立仮定による問題を解決するものではないためである。

(2) 移動・滞留行動選択確率の推定精度検証

$x_{ijklmkt}$ のベイズ更新値を用いてパラメータ推定を行い、2時間帯にわたる移動・滞留選択確率を試算した。仮想真値を x 軸に、推定値を y 軸にとった散布図を図5.3に示す。この散布図と図5.2を比較すると、おおむね似た分布となっており、十分な精度が得られていない。この原因は、2時間帯の移動・滞留の行動選択確率推定は $x_{ijklmkt}$ へ回帰するようにパラメータを最適化することから、 $x_{ijklmkt}$ の精度が不十分であればチェーンの推定精度は不十分となるためである。したがって、精度向上のためには $x_{ijklmkt}$ の値の改善が必要となるが、現時点でそのために必要な属性別かつモード別のデータは入手できていない。

5.4 GNSSデータを用いたトリップチェーン推定手法の試行

(1) はじめに

本節では、スマートフォンアプリなど、個人のID

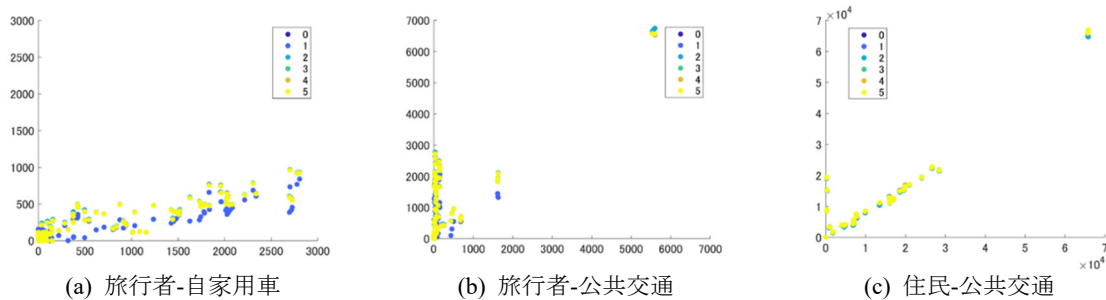


図 5.2 $x_{ijklmkt}$ の仮想真値と独立仮定による設定値, ベイズ更新値の比較




図 5.3 $\Pr(j, l, m|i, k, t)$ の仮想真値と推定値の比較

と取得される位置情報によって直接的にトリップチェーンの取得可能性を持つデータについて、その特性を整理するとともにトリップチェーンの推定を試行する。

(2) データの概要

京都市内のバス・鉄道を対象としたスマートフォン向け経路検索アプリ「歩くまち京都アプリ『バス・鉄道の達人』」の利用によって取得されたGNSS履歴データを用いた。データの概要は表5.2の通りであり、京都市内のみならず全世界での位置情報の記録がある。また、ユーザーIDは取得日にかかわらず一定であるため、各ユーザーに対して複数日にわたって取得された行動の分析が可能である。なお、位置情報の取得頻度は特殊であり、iOS版では移動中のみ取得が行われる。

(3) データのクリーニング

本節の目的はトリップチェーンを直接的に得ることであるため、軌跡の形になっていないデータを除去する。「市内にBackgroundでの取得を5点以上含む」ユーザーのみを抽出し、その他を削除した。また、乗換検索のアプリであるため、旅行者のみならず住民の利用も考えられるが、「市内での観測日数7日以内」を「旅行者」、「市内での観測日数8日以上」を「住民」と定義することで属性毎に分離した。市内で期間内に観測された全ユーザー数は16,479人（iOS）だが、条件を満たすものは表5.3に示した通りである。

(4) トリップエンド判定

緯度経度の羅列である位置情報履歴から移動・滞留を把握するためには、断続的に取得される位置情報を適切に処理することで移動中であるか、滞留中であるかを判別する必要がある。ここでは、取得されたデータから、ユーザーの任意のひとつのトリップの終了を判定する。Androidの取得頻度は約1時間に1度と低いため、観測された挙動からトリップエンドを直接判定することが難しいと考えた。一方、iOS

では移動中において比較的高頻度に取得を行う特徴がある。そこで、iOSのデータのみを抽出しトリップエンド判定を試みる。また、本項以降の分析は、全てiOSのデータのみを用いたものである。

iOSで観測されたデータは、「500 m以上離れないと取得されない」という移動・滞留判定に近い動作が取得時点で行われているため、この性質を利用した判定手法を採用する。具体的には、同一ユーザーの前後のレコード取得間隔を閾値として区切りを設け、その両端をトリップエンドとする。ここでは閾値を30分として、すべてのレコードを表5.4の4つに分類し、2つの連続した観測の取得時間間隔が30分未満となる区間を移動中とし、移動中の区間をまとめてひとつのトリップとして表現する。

判定結果を図5.4および図5.5に示した。図5.4は分類された全レコードを重ね合わせたものであり、鉄道や幹線道路上の点の多くがM（移動途中）と判定されていることが確認できる。一方でDと判定されたレコードは観光地や繁華街に集中している。これはある程度妥当な結果と考えられ、後者を集計することで訪問先の分析が可能となる。

図5.5はトリップ起点が図中の黒枠内の京都駅周辺、嵐山周辺にあるトリップを抽出し、トリップ終点がどこに位置するかを示している。多くのトリップ終点が観光地に位置することが確認でき、京都駅⇄金閣寺のような比較的長距離のトリップも抽出されている。時間帯に着目すると、京都駅発のトリップは午前中に金閣寺や伏見稲荷など市街地周縁部の観光地へ向かうものが多いのに対して、午後から夕方にかけては河原町など繁華街周辺へ向かうものが多い傾向が確認でき、観光流動が時間帯に影響される状況を得ることができている。ただし観光地周辺道路上でのトリップ終点判定や、内内トリップが多く残る課題も残されている。前者はiOSの取得特性に依存するため、これを修正するのは容易ではない。トリップ終点の次のレコードとの比較や、他のデータとの融合等による解決を期待したいが、具体的な手法については今後の課題としたい。後者は観光地到着後の歩行等によるものと考えられるが、トリップの判定をゾーン単位で集計すれば、誤判定の可能性を小さくできる。

表 5.2 GNSS 履歴データの概要


期間	2018年9月1日～2019年2月27日（180日間）
対象者	アプリインストール者のうち位置情報取得・利用の承諾を行った者
対象地域	全世界
取得間隔	<ul style="list-style-type: none"> Android版：おおむね1時間 iOS版：前回取得から500 m以上移動かつ5分以上経過した際に取得 ※いずれもForeground時には高頻度の取得が混ざる
取得項目	<ul style="list-style-type: none"> ユーザーID（取得日にかかわらず端末毎に一定） 取得日・取得時刻 緯度経度 ※世界測地系 OS（‘iOS’ or ‘Android’） 言語+国コード ※OSの設定 画面タッチ情報（有無など）

表 5.3 抽出されたユーザー数（iOS）

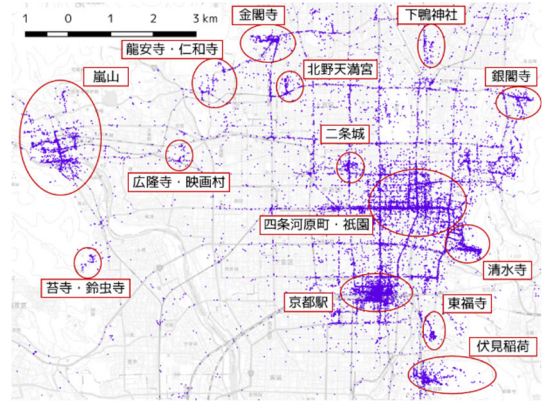
属性	ユーザー数	市内レコード数
旅行者	3,254	188,443
住民	2,779	2,786,465

表 5.4 本研究でのトリップエンド判定手法

状態名	前レコードとの時間間隔 [分]	後レコードとの時間間隔 [分]
M：移動途中	$\Delta t < 30$	$\Delta t < 30$
O：移動開始	$\Delta t \geq 30$	$\Delta t < 30$
D：移動終了	$\Delta t < 30$	$\Delta t \geq 30$
S：滞留中	$\Delta t \geq 30$	$\Delta t \geq 30$




(a) M (市内 126,686 レコード)

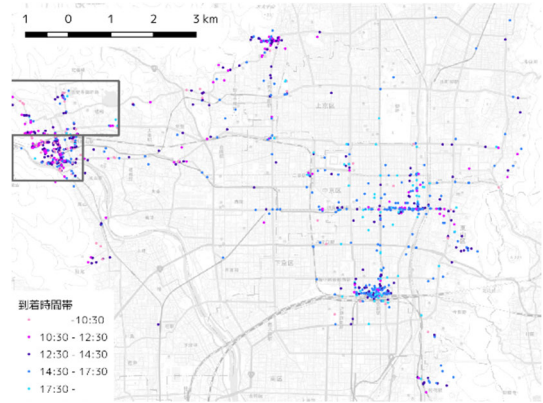


(b) D (市内 25,170 レコード)

図 5.4 トリップエンド判定による点の分類結果

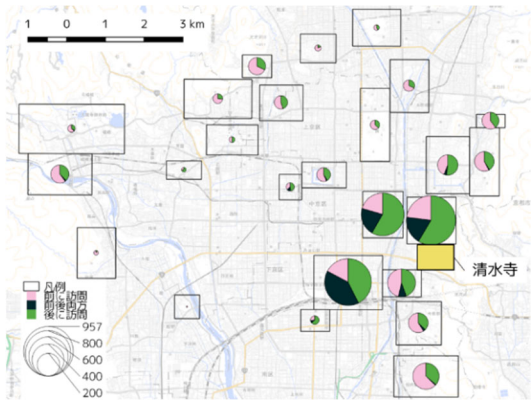


(a) 京都駅周辺発 (3,352 トリップ)

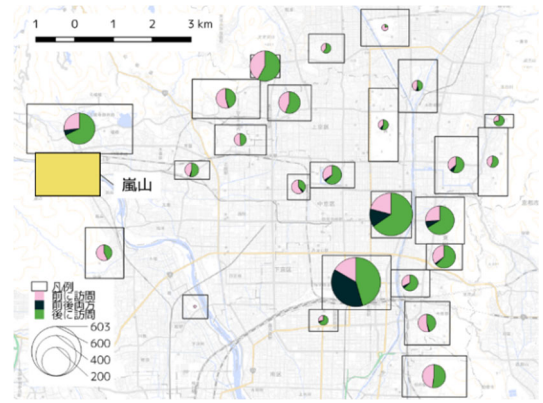


(b) 嵐山周辺発 (1,237 トリップ)

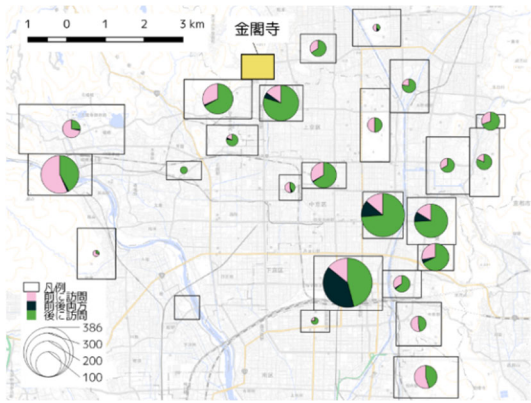
図 5.5 各地域発のトリップの終点 (D)



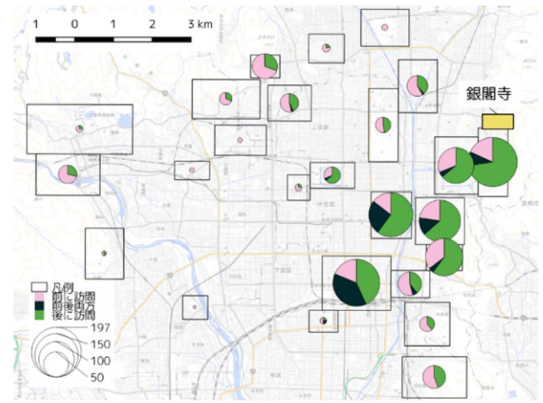
(a) 清水寺訪問日 (1,281 人日)



(b) 嵐山訪問日 (912 人日)



(c) 金閣寺訪問日 (596 人日)



(d) 銀閣寺訪問日 (303 人日)

図 5.6 各ゾーン訪問日の他の訪問先及び訪問順序

(5) 観光流動の分析

本アプリのデータを同一 ID によって集計することで、ある単位時間、たとえば1日などの移動履歴を得ることができる。したがって、主要な観光地を中心として、その観光地の前後にどこを訪れたかを取得することも可能である。ここでは、清水寺、嵐山、金閣寺、銀閣寺の4つを主要観光地とみなして、その他の各観光地が主要観光地の前後どちらで訪れやすいかを集計する。これにより、1日のトリップチェーンのなかで早い時間、あるいは遅い時間に訪れやすい観光地、すなわち時間と場所の組み合わせが存在するかを明らかにする。図5.6に各主要観光地とその他のゾーン*i*の訪問前後関係を集計した結果を示す。円の大きさはゾーン*i*への訪問者数 v_i を表し、色分けは注目する観光地(黄色で示した場所)の前に訪れたか、後に訪れたかを表す。なお、1日に3ゾーン以上を訪問した日のみを集計対象とした。

まず、量に着目する。清水寺訪問日は近隣を訪問するにとどまるユーザーが多く、嵐山や金閣寺など距離の離れた観光地には訪れるユーザーが少ないことが読み取れる。嵐山訪問日と金閣寺訪問日に着目すると、両者を訪れるユーザーが多くあり、それ以外のゾーンへの訪問選択傾向はよく類似していることが読み取れる。銀閣寺訪問日に着目すると、銀閣寺のみならず東山一帯を訪問するユーザーが多い傾向が読み取れる。

次に、観測された順序に着目する。清水寺の前に訪問するのは伏見稲荷や金閣寺など主要な観光地が多い一方で、後に訪れるのは京都駅周辺や繁華街であることから、清水寺は1日の観光周遊行動の終盤に訪れやすいといえる。一方で嵐山および金閣寺は、他の観光地を後に訪問される場合が多いことから、観光周遊行動の序盤に訪れやすいといえる。こうした順序を決定する要因としては、宿泊地や帰路となる京都駅や繁華街からの距離が考えられるほか、清水寺で紅葉期の夜に行われるライトアップなど、各観光地特有のものが考えられる。

また、銀閣寺は、東山の他の観光地より先に訪れる傾向が見られるため、東山では北上しながら回遊する観光客よりも南下しながら回遊する観光客が多いといえる。このような実態は訪問客数調査等では把握が困難であり、連続して観測する本データの特性により明らかになったものである。

5.5 2018年秋季の京都におけるデータへのトリップチェーン推定手法の適用

(1) 分析の概要

本節では特定の日にちについて、5.2節で構築した手法を適用する。2時間帯にわたる移動・滞留行動選択確率推定モデルは、京都の紅葉観光の繁忙期である2018年11月24日を対象とする。この日の午前(9-12時)、昼間(13-16時)、夜間(18-21時)について移動・滞留行動選択モデルで分析し、(2)に示す。加えて、

非繁忙期である2017年10月17日との比較を行う。この日については最尤推定法に必要な自家用車トリップ、公共交通トリップが試算されていないため、 $x_{ijklkmt}$ をGNSSデータを用いてベイズ更新し、その値について2日間を比較することで繁忙期のトリップチェーンの特性分析を行った内容を示す。

(2) 使用データ

トリップチェーン推定にあたり、使用したデータは表5.6の通りである。GNSSデータについては、1日のみのデータで集計すると極めてサンプル数が少なくなるため、繁忙期となる2018年11月12日から12月2日を集計したものを同年11月24日の代表値とする。また、2017年10月17日については、アプリのデータが存在しないため、2018年10月1日から10月21日を集計したものを利用する。1年間時期が異なるが、ベイズ更新では観測された移動・滞留行動の比率のみを利用するため、大きな問題はないと判断している。

ゾーン定義はデータによって異なるが、本節では図5.7に示した、京都市内17ゾーンに近隣県を含んだ1ゾーン、近隣県以遠の1ゾーンを加えた合計19ゾーンに統一し、各データの集計量は面積等により按分して新しい定義に与えた。

(3) ベイズ更新された $x_{ijklkmt}$ の繁忙期・非繁忙期比較

5.2節で提案したベイズ更新による2時間帯にわたる属性別移動・滞留の行動選択確率の改善について

表 5.5 推定対象の整理

	2018年 11月24日	2017年 10月17日
独立仮定に基づく $x_{ijklkmt}$ の設定	○	○
ベイズ更新による $x_{ijklkmt}$ の改善	○	○
最尤推定法による移動・滞留行動選択確率推定	○	×
トリップチェーンの推定	○	×

表 5.6 使用したデータ

	データ名	時期
属性別移動・滞留量	流動統計 (Move-Stay データ)	2018/11/24, 2017/10/17
自家用車移動量	第3章の成果物	2018/11/24
公共交通移動量	第4章の成果物	2018/11/24
ベイズ更新用のGNSS データ	5.4の成果物	2018/10/01 から 2019/12/02




図 5.7 集計に用いるゾーン

適用した結果を整理する．ここでは，モード別を考慮した按分適用前の属性別の値のみ着目する．試算対象の3時間帯についてそれぞれ x_{ijklt} を算出した．すべての x_{ijklt} を得ているが，すべてを掲載すれば膨大な数となり冗長となるため，ここでは主要観光地を経由する「旅行者」が，主要観光地訪問前後にどこを訪れていたかに着目する．主要観光地はゾーン4（清水寺周辺），ゾーン17（嵐山周辺）とする．上記2ゾーンを訪れる旅行者の2時間帯にわたる移動・滞留量である x_{i4l1t} ， x_{i17l1t} について，経路をグラフ化して表5.7に示す．このグラフは， $x_{ijklt} > 10$ であるトリップチェーンを抽出し，整数に切り上げて，チェーンの選択人口を図中に表示している．

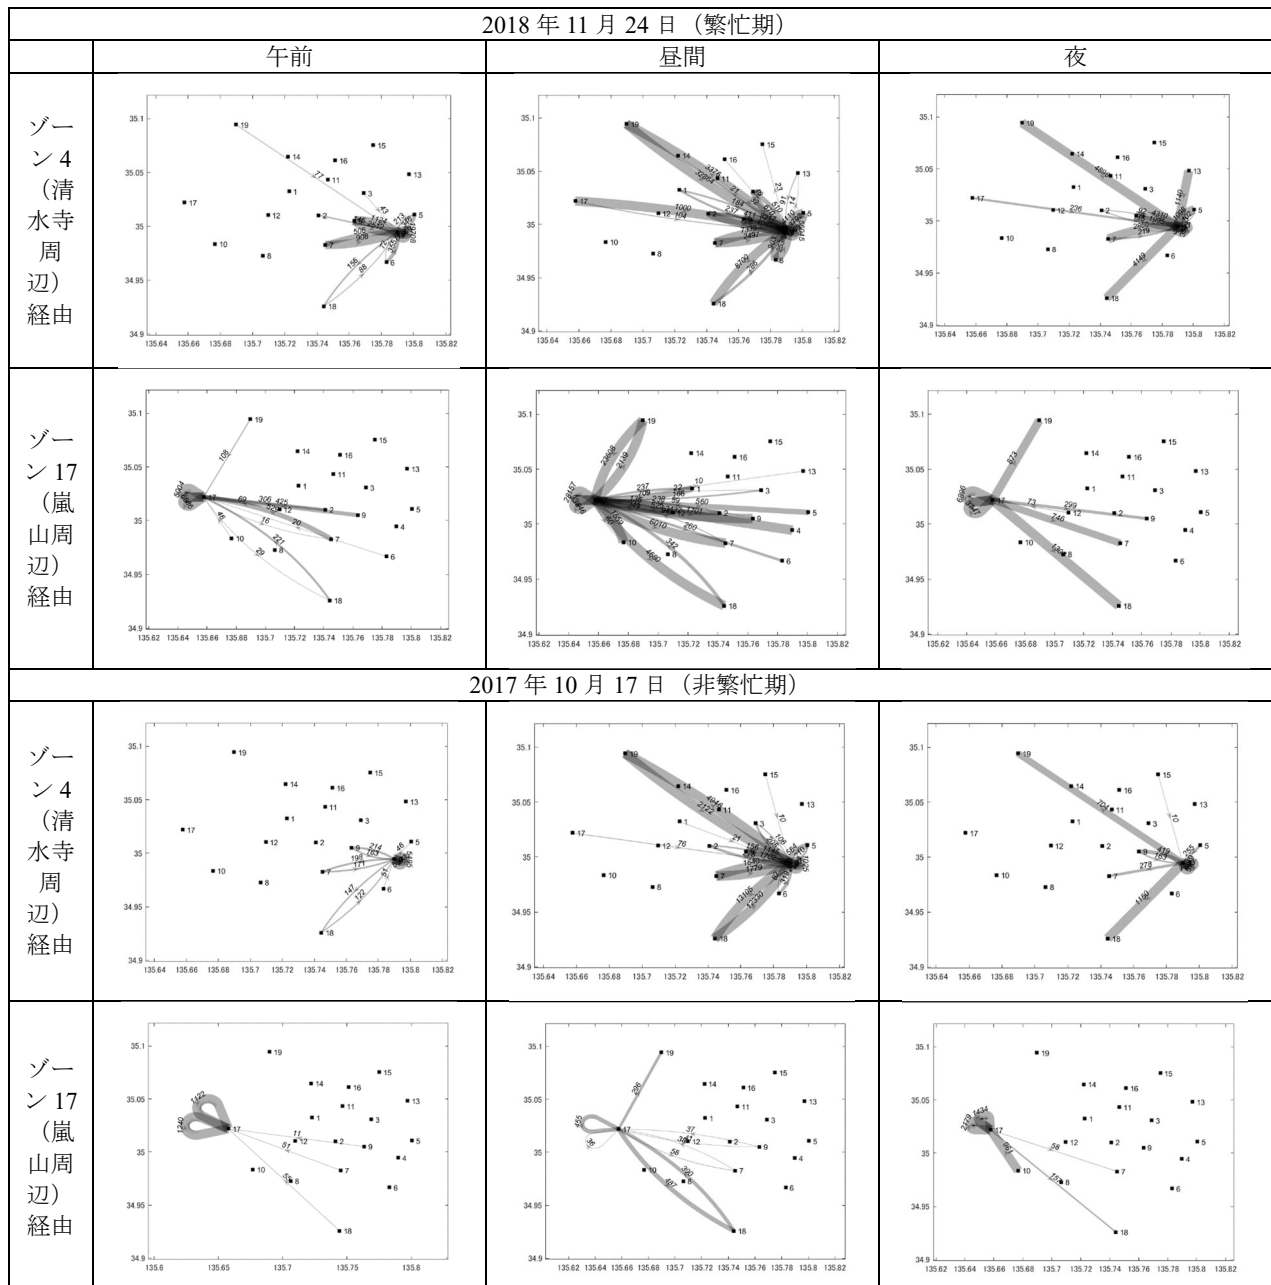
非繁忙期は繁忙期と比較して全体的にこれらのトリップチェーンを選択した人口が小さいことが確認できる．ゾーン4（清水寺周辺）において，繁忙期で

はゾーン19（外部）から多くの人口が流入していたが，非繁忙期ではそれよりもゾーン18（京都市外・近隣府県）からの流入人口が12,330と大きくなっている．また，ゾーン18に流出する人口も13,105と大きい．したがって，近隣からの旅行者は繁忙期を避けて清水寺を訪問しており，比較的短時間で帰路についていることが予想される．また，昼間を見ると繁忙期にはゾーン4に滞留してからゾーン17（嵐山周辺）に移動する量が多くなっていたが，非繁忙期はその選択をした人口がなかった．したがって，繁忙期，非繁忙期でゾーン4に流入する人，滞留後に向かう目的地も異なっていることがわかる．

(4) パラメータ推定

2018年11月24日の分析に当たり，時間帯による影響を把握するために前述の3つの時間帯に分けてパ

表 5.7 時間帯別主要観光地前後の訪問地



ラメータを推定する。

まず、各ゾーンの出発地、最終到着地（2時間帯後の位置）としての効用パラメータについて図5.8に示す。なお、ゾーン19はロジットモデルの分析のため基準として与えており、効用パラメータが0である。

次に、2時間帯にわたる移動・滞留の効用パラメータを表5.8及び表5.9に示す。表中、0.00で表示が濃灰色の個所は、そのような移動が観測されなかったため、推定できなかった移動・滞留である。

これらの特定されたパラメータは他の効用パラメータと組み合わせ、行動（選択肢）に対する確定効用として定義されている。したがって、パラメータ単独でそれぞれ考察しても、選択肢の優位性に関する直接的な考察はできない。しかしながら、このゾーン選択に対する効用パラメータ内での相互比較は、移動コストやモード選択にかかわらないゾーン選択の魅力度の大きさとして解釈ができると考える。例えば、表5.9を見るといずれのゾーンにおいても滞留を選択する効用が移動よりも高いことがわかる。一方で、旅行者はいずれの時間帯においても滞留する




図 5.8 出発地、最終到着地としての効用パラメータ

表 5.8 旅行者の昼間を対象とした2時間帯移動・滞留の効用パラメータ

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19
1	0.39	-0.25	-0.05	-0.13	-0.01	0.00	0.02	0.00	-0.03	0.00	-0.08	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
2	-0.23	-0.13	0.00	-0.17	-0.03	-0.25	-0.35	0.00	-0.45	0.00	0.00	0.00	0.00	0.00	-0.04	0.00	-0.13	-0.35	0.00
3	-0.20	-0.22	0.69	-0.21	-0.29	-0.13	-0.37	0.00	-0.32	0.00	0.00	0.00	0.00	0.00	-0.03	-0.08	0.01	-0.13	0.00
4	-0.31	-0.26	-0.27	2.40	-0.23	-0.19	0.02	0.00	-0.03	0.00	0.00	0.00	0.00	0.00	-0.13	0.00	-0.09	-0.12	0.00
5	0.00	-0.10	-0.39	0.21	2.00	0.00	0.08	0.00	-0.17	0.00	0.00	0.00	-0.17	0.00	0.00	0.00	0.00	0.00	0.00
6	0.00	-0.11	-0.11	-0.10	0.00	0.35	0.40	0.00	-0.33	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	-0.10
7	-0.09	-0.48	-0.17	-0.05	-0.32	0.56	2.69	-0.45	-0.48	0.00	0.00	0.00	0.00	-0.23	-0.16	0.00	-0.01	0.59	0.00
8	0.00	0.00	0.00	0.00	0.00	0.00	0.00	-0.06	0.14	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	-0.13
9	-0.06	0.59	-0.32	0.07	-0.40	-0.27	0.09	-0.16	2.18	0.00	0.00	0.00	0.00	0.00	0.00	-0.02	-0.22	-0.10	0.00
10	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	-0.10
11	-0.01	0.00	-0.07	-0.06	0.00	0.00	0.00	0.02	0.10	0.00	0.02	0.00	0.00	-0.02	0.00	0.00	0.00	0.00	0.04
12	0.00	0.00	0.00	0.00	0.00	0.00	0.00	-0.07	0.00	-0.13	0.00	0.20	0.00	0.00	0.00	0.00	-0.15	0.00	0.00
13	0.00	0.00	-0.10	-0.01	0.00	0.00	0.03	0.00	0.01	0.00	0.00	0.00	0.02	0.00	0.00	0.00	0.00	0.11	0.00
14	0.00	0.00	0.00	0.00	0.00	0.00	0.02	0.00	0.00	0.00	0.00	0.00	0.00	-0.26	0.00	0.00	0.00	0.00	0.00
15	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.42	-0.06	0.00	-0.05	0.00
16	0.00	0.00	0.00	-0.02	-0.02	0.00	0.02	0.00	-0.18	0.00	0.00	0.00	-0.14	-0.03	0.19	0.00	0.00	0.00	0.00
17	-0.13	-0.09	-0.08	-0.02	-0.06	-0.05	0.34	0.00	0.12	-0.13	0.00	-0.15	0.00	0.00	0.00	0.00	2.27	0.12	0.00
18	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
19	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00

表 5.9 住民の昼間を対象とした2時間帯移動・滞留の効用パラメータ

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19
1	1.95	0.27	-0.06	-0.41	-0.39	-0.32	-0.21	-0.37	-0.26	-0.37	-0.28	-0.12	-0.28	-0.32	-0.20	-0.23	-0.30	0.13	0.00
2	0.17	3.83	-0.24	-0.51	-0.46	0.60	0.31	0.64	0.30	-0.56	-0.49	-0.47	-0.04	-0.40	-0.22	-0.51	-0.48	0.20	0.00
3	-0.08	-0.33	3.46	-0.41	0.05	-0.45	-0.37	-0.36	0.21	-0.37	-0.44	-0.30	-0.23	-0.29	-0.31	-0.01	-0.34	0.31	0.00
4	-0.52	-0.53	-0.49	3.07	-0.18	-0.10	-0.25	-0.52	0.39	-0.18	-0.27	-0.28	-0.35	0.00	-0.20	-0.34	-0.25	1.11	0.00
5	-0.33	-0.58	0.43	-0.08	3.36	-0.39	-0.52	-0.48	-0.11	-0.14	-0.37	0.00	-0.40	0.00	-0.29	-0.35	-0.18	0.40	0.00
6	0.00	-0.56	-0.44	0.09	-0.30	3.59	-0.12	-0.44	-0.40	-0.32	0.00	0.00	-0.03	0.00	0.00	0.00	-0.09	3.28	0.00
7	-0.37	0.27	-0.28	-0.39	-0.46	-0.52	4.11	-0.09	0.11	-0.44	-0.28	-0.49	-0.18	-0.17	-0.42	-0.32	-0.44	1.68	0.00
8	-0.50	-0.58	-0.52	-0.55	-0.47	-0.38	0.09	4.13	-0.51	-0.11	-0.36	-0.59	0.00	-0.13	-0.10	-0.23	-0.19	2.30	0.00
9	-0.47	0.38	-0.12	0.18	-0.44	0.54	0.53	0.65	3.11	-0.54	-0.44	-0.55	-0.58	-0.37	-0.47	-0.58	-0.55	0.47	0.00
10	-0.35	0.60	-0.32	-0.30	-0.22	-0.39	0.53	0.72	-0.52	3.61	0.00	-0.48	-0.12	0.00	-0.06	-0.13	-0.30	0.68	0.00
11	0.00	-0.47	-0.20	-0.25	-0.39	0.00	-0.46	0.00	-0.31	0.00	2.55	0.00	-0.06	-0.40	-0.28	0.17	-0.11	-0.30	0.00
12	0.16	-0.16	-0.36	-0.20	-0.21	-0.06	-0.32	-0.48	-0.43	-0.46	0.00	3.43	-0.01	-0.09	-0.14	-0.32	-0.18	0.03	0.00
13	-0.27	-0.25	0.00	-0.32	-0.25	0.04	-0.28	0.00	-0.32	0.00	-0.12	0.00	3.05	0.00	-0.39	-0.26	0.00	-0.02	0.00
14	-0.30	-0.42	-0.35	-0.02	-0.10	-0.01	-0.25	0.00	-0.35	-0.02	-0.16	-0.14	-0.11	0.61	-0.16	-0.27	-0.13	-0.02	0.00
15	-0.41	-0.24	-0.18	-0.34	-0.31	-0.04	-0.28	-0.12	-0.45	-0.09	-0.19	-0.15	-0.28	-0.19	2.88	-0.13	0.00	0.21	0.00
16	-0.36	-0.40	0.14	-0.26	-0.39	-0.09	-0.38	-0.49	-0.40	-0.12	-0.22	-0.23	-0.23	-0.37	-0.18	3.44	-0.17	0.19	0.00
17	-0.40	-0.50	-0.21	-0.30	-0.29	-0.20	-0.35	-0.35	-0.37	-0.35	-0.18	-0.28	0.00	-0.08	0.00	-0.14	3.16	0.46	0.00
18	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
19	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00

効用パラメータは他の移動する効用と比べてもそれほど大きくない。したがって、旅行者は住民に比べて滞留に対する魅力が相対的に低いといえるだろう。すなわち、観光のために多くの移動をすることが示唆され、直感とも整合する。

(5) 推定されたトリップチェーンの選択確率

特定されたパラメータを用いて2時間帯の移動・滞留行動選択確率を算出した。ここではこの2時間帯の移動・滞留をトリップチェーンとしてとらえ、その選択確率を計算する。2時間帯以上の移動・滞留行動を接続させたトリップチェーンの選択確率についても、計算された2時間帯の選択確率を累乗することで得られる。しかしながら、5.3で示したように十分な精度を有さない結果を累乗すれば、真値との乖離はそれに従って大きくなると考えられるため、ここでは避けることとした。本モデルで表現できる最も精度が高い2時間帯にのみ着目して考察する。

トリップチェーンの推定確率は全ゾーン間の2時間帯分の移動・滞留で算出されているが、すべてについて掲載すると膨大な誌面となるため、ここでは主要観光地、出発地、到着地として選択される個所を中心に、選択確率が大きい10チェーンを抽出して考察する。分析対象は、ゾーン7（京都駅周辺）を出発地とするもの、ゾーン4（清水寺周辺）を經由地とするものとする。トリップチェーンの選択確率は、出発地に存在する人のうち、モードm、1時間帯後にj、2時間帯後にlと移動もしくは滞留行動を選択する確率のことを指す。したがって、出発地を任意のゾーンに設定した場合、それ以降どのような行動をとったかの確率をモードも含めて合計すると1となるが、經由地、到着地を任意のゾーンに設定した集合のトリップチェーンの選択確率を集計しても1とはならないことに留意されたい。対象を旅行者、自動車利用者限定して、抽出した上位10トリップチェーンを表5.10及び表5.11に示す。

ゾーン7（京都駅周辺）を出発する午前中のトリップチェーンを見ると、滞留し続ける確率が高い一方で、ゾーン9、4、5、2などへ移動し、滞留する確率も高くなっている。ゾーン9は河原町周辺、4が清水寺、5が銀閣寺周辺であることを鑑みると、京都駅周辺から午前中観光地に向かい、そのまま観光している状況が表現されていると考えられる。昼間も同様の傾向がみられるが、ゾーン17（嵐山周辺）に移動する確率が10.0%と大きくなっており午前中が1.8%であったことに比べれば、特筆するべきであろう。

また、2時間帯後にゾーン18（京都市外・近隣府県）に流出する比率が1.9%と小さくない。すなわち、もう帰宅を開始している人が少なくない、と考えられる。夜間についてはゾーン9（河原町）周辺に移動する人口が20.1%と最も大きい。昼間大きくなっていったゾーン17へ移動する確率は小さくなっている。このことから、やはり嵐山は昼間に訪れる大半であることが確認できる。また、上位10トリップ中、3トリッ




図5.9 11/14と11/24の移動・滞留行動選択確率比較

表 5.10 ゾーン 7 (京都駅周辺) を出発するトリップチェーンの選択確率

午前			昼間			夜					
出発点	1時間後	2時間後	確率 [%]	出発点	1時間後	2時間後	確率 [%]	出発点	1時間後	2時間後	確率 [%]
7	7	7	17.0	7	7	7	16.4	7	9	9	20.1
7	9	9	12.6	7	4	4	11.8	7	7	7	16.7
7	4	4	8.9	7	17	17	10.0	7	4	4	11.9
7	5	5	7.1	7	9	9	9.5	7	7	18	3.2
7	2	2	4.2	7	5	5	7.7	7	5	5	2.3
7	1	1	3.6	7	1	1	2.3	7	5	18	1.8
7	3	3	3.5	7	7	18	1.9	7	16	16	1.8
7	6	6	2.0	7	15	15	1.5	7	3	3	1.7
7	17	17	1.8	7	6	6	1.5	7	9	18	1.6
7	7	18	1.7	7	4	7	1.1	7	1	1	1.3

表 5.11 ゾーン 4 (清水寺周辺) を経由するトリップチェーンの選択確率

午前			昼間			夜					
出発点	1時間後	2時間後	確率 [%]	出発点	1時間後	2時間後	確率 [%]	出発点	1時間後	2時間後	確率 [%]
13	4	4	26.0	13	4	4	23.7	13	4	4	32.5
10	4	4	24.8	11	4	4	21.1	6	4	4	19.3
12	4	4	15.9	6	4	4	19.9	2	4	4	18.0
6	4	4	11.6	5	4	4	14.8	17	4	4	16.0
5	4	4	10.8	2	4	4	14.6	5	4	4	15.6
2	4	4	10.2	3	4	4	13.8	4	4	4	13.6
3	4	4	9.4	1	4	4	13.6	9	4	4	12.6
17	4	4	9.4	7	4	4	11.8	7	4	4	11.9
4	4	4	9.2	17	4	4	11.2	4	4	18	2.4
7	4	4	8.9	9	4	4	11.1	1	4	1	2.2

ブが2時間帯後にゾーン18に流出しており、帰宅する人が多いことが示されている。

ゾーン4 (清水寺周辺) を経由するトリップチェーンを見ると、1日を通して1時間後に流入し、2時間後はそのままゾーン4に滞留するトリップで多くが占められている。したがって、駅など交通拠点にも近く夜間のライトアップ等により夜間でも魅力が落ちにくい清水寺は、2時間以上滞留するチェーンの選択確率が大きくなっていると考えられる。ゾーン4へ流入するゾーンは比較的距離が近い東側のゾーンが多くなっており、いずれのチェーンの選択確率も高い。

すなわち、多くの旅行者が清水寺を訪問することを意味しており、どの時間帯においても近隣のゾーンを訪問したのちに流入していることがわかる。

(6) イベントによるトリップチェーンの変動分析

清水寺で夜間特別拝観が開催され、ライトアップが始まっている11/24と、開始前の11/14の値を比較する。夜間の移動・滞留行動選択確率について、x軸に11/14、y軸に11/24の値をとった散布図を図5.9に示す。したがって、 $y = x$ より上側に位置するプロットは11/24が11/14よりも相対的に大きいことを示す。図中の赤円は1時間帯目に滞留を、橙円は1時間帯目にゾーン18 (京都市外・近隣府県) への移動を、紫円は1時間帯目にゾーン19 (近隣県外以遠) への移動をそれぞれ選択したものを示す。これらを比較すると、ゾーン4では赤円は $y = x$ よりも上側に位置しており、確率の値は1.5から2倍程度大きくなっている。すなわち、11/24は清水寺周辺に滞留する確率は高く、遠方に帰宅する確率は低いと示唆される。

他ゾーンの比較のために、ゾーン5を確認すると、赤円は $y = x$ よりも下側にあるが、橙円は上側にある。したがって、出発地がゾーン5の人はゾーン4のとは異なり、滞留を継続する人は少なく、帰宅を選択する人が多いことが分かる。これは11/24が3連休の中日であることから、夜間に旅行を終了し帰宅する人が多いことを示す。このように帰宅を選択する人が多いゾーンがあるにもかかわらず、ゾーン4は滞留を継続する人が多いことが確認できる。

以上のことから、ゾーン4に夜間に滞留する選択確率が高くなっており、これは夜間特別拝観、ライトアップの影響であることが確認できたと考える。

5.6 おわりに

本章では、自動車及び乗客のトリップパターンを所与とし、モバイル空間統計、アプリGNSSデータなど他の人の流動と組み合わせることで属性別・時間帯別のトリップチェーンを推定するモデルを構築した。また、GNSSデータ単体での分析も行った。これら一連の分析結果では1時間帯の流動について人気観光地に流動が集中すること、属性によって選好が異なること、季節変動による影響などを推定したモデルにより表現できていることを確認した。しかしながら3時間帯以上のような長期にわたるトリップチェーンは推定精度には課題が残されている。この課題については、本章で利用したGNSSデータのようなトリップチェーンを直接的に把握できるデータを利用した補正方法が有効であると考えられる。現時点ではGNSSデータの取得量が数時間にわたるトリップチェーンを把握するためには量的に不十分である。これらが大規模に蓄積され、利用可能になれば、本章で提案したバイズ更新手法を複数時間に拡張して適用することで、推定精度の向上が期待できる。

第6章 交通マネジメント方策の影響分析に関する基礎分析

6.1 はじめに

本章では、自動車ならびにバスの乗客のトリップパターンを推定する方法を活用し、秋季の観光地交通対策の影響について分析する。加えて、自動車交通については、MFDを用いて道路ネットワーク上の流動特性を評価する。さらに、観光客の諸活動の時空間的分散の可能性について考察するため、訪問者の代表的周遊・観光エリアでの時間消費パターンをWi-Fiパケットセンサデータより推定する。これらに基づき、観光需要マネジメント施策の影響評価を実施し、有効な施策に関する示唆を示す。

6.2 トリップパターンから見た観光地交通対策の影響分析

本節では、Wi-Fiパケットセンサ、交通量感知器およびトリップパターン推定結果より、観光地交通対策による交通流動の変化について考察を行う。

(1) 対象とした観光・交通施策

京都市では観光地交通対策として、2018年11月において、観光地を中心に自動車需要抑制のための交通施策を実施していた。それらの実施日時を中心にトリップパターン推定を行うことで、交通施策の交通への影響を分析した。具体的には、観光地である東山地区、嵐山地区において、2018年11月17日（土）、18日（日）、23日（金・祝）、24日（土）、25日（日）で交通施策を実施しており、表6.1に実施した交通施策について整理しておく。これらの施策が実施された5日間に加えて、11月10日（土）、11日（日）、12月1日（土）、2日（日）の推定を行い、施策実施日と比較することで交通施策の効果を分析する。また、京都市では、観光施策として、夜間特別拝観（ライトアップ）を実施している。表6.2に京都市の主な観光地の観光施策について整理しておく。このように、京都市全体で様々な観光施策が実

表 6.1 観光期における交通施策

(a) 東山地区		
内容	対象	時間帯
自家用車駐車不可	市営清水坂観光駐車場	7:00～19:00
タクシー専用化	清水寺門前駐車場 パークファースト清水茶 わん坂 きりん24茶わん坂	7:00～19:00
右折進入禁止	東大路通北行から高台寺 南門通へ	10:00 ～ 19:00
左折進入禁止	東大路通南行から市営清 水坂観光駐車場、鳥辺参道 へ	12:00 ～ 19:00
シャトルバス運行	京都駅等の鉄道駅から五 条坂	
(b) 嵐山地区		
内容	対象	時間帯
北行一方通行	長辻通（三条通～新丸太町 通）、軽車両を除く車両	10:00 ～ 13:00
北行一方通行	長辻通（三条通～新丸太町 通）、全車両	13:00 ～ 17:00
南行一方通行	嵯峨街道（渡月橋北詰～阪 急嵐山駅前交差点）、路線 バス、軽車両を除く車両	10:00 ～ 17:00

表 6.2 ライトアップ情報（2018年）

エリア	施設	期間	時間帯
洛東	清水寺	11/17～12/2	17:30～21:00
	高台寺	10/19～12/9	17:00～22:00
	知恩院	11/2～12/2	17:30～21:30
洛中	永観堂	11/3～12/2	17:30～21:00
	北野天満宮	11/10～12/9	日没から 20:00
	梅小路公園	11/16～12/9	17:00～21:00
洛南	東寺	10/27～12/9	18:30～21:30
	平等院鳳凰堂	11/17, 18, 23 ～ 25, 30 ～ 12/2	18:00～20:30
洛西	宝厳院	11/9～12/2	17:30～20:30

施されている中で、交通施策の実施対象日時、対象エリアとあわせて、観光施策の交通への影響を分析した。

(2) Wi-Fiパケットセンサデータから見た観光流動の変化

a) 観光繁忙日の観光客層データの時間分布

図 6.1 は、第 2 章の非階層性クラスタリングで分


類した観光客層（日帰り層，宿泊層）に含まれるアドレスが繁忙日である11月23日（金・祝），24日（土），25日（日）の3連休において各時間帯の観測数を集計したものである。日帰り層は金土日の観測数に大きな差はないが，宿泊層は土曜日の観測数が特に多く，日曜日のデータが少ない。宿泊層には，金曜日から来て宿泊されている方，土曜日に来て宿泊される方の双方を観測しているためと考えられる。

さらに，ライトアップや3連休の影響や繁忙の程度の違いによる変化を見るため，図6.2に同様の分析を，次の週の週末である12月7日，8日，9日に対して実施した結果を示す。7日について見てみると，日帰り層も宿泊層も金曜日が平日であるため観測数が土日に比べて少ないことがわかる。土日で比較すると，日帰り層の場合には日曜日の来訪が最も多い。一方で，宿泊層をみると，土曜日である12月8日が圧倒的に多く，土日にかけて来訪している傾向にある。さらに，12月9日の日曜日にはピークが10時台にあるなど，日帰り層と宿泊層で来訪パターンに違いがあることが確認できる。


b) 主要観光地に到着する頻出パターン

第2章で実施した系列パターンマイニングを行った結果の中で，4地点間の移動パターン，帰結部Yを，清水寺を含む東山地区とし，リフト値が1を超えるパターンを支持度が高い順に抽出した。ここでは，それぞれの時期の宿泊層について頻出した移動パターンを考察する（図6.3）。この2つの図を比較すると，ほぼ類似した移動パターンが抽出されていることがわかり，かつ日帰り層においても類似した移動パターンが抽出された。時期や日帰り，宿泊の違いはあれど，清水寺を含むG15で観測される前の行動にいくつか決まった移動パターンが存在していた。特に，嵐山から京都駅を通過して五条坂に行くパターンや伏見稲荷から東福寺駅を通過して五条坂に行くパターンに関しては，広域な移動であるにもかかわらず安定して抽出された。また，直前に観測されたセンサはほとんどが京阪五条（G7），バス停五条坂（G14），八坂神社など（G12）の3か所であった。一方で，近接している高台寺（G13）や間に他のセンサが存在しないJR山科（G16）からの移動はほとんど抽出されていない。以上のようにリフト値に着目することで，直後に主要観光地に向かう傾向が高いパターン抽出や直前に来訪する箇所の特定が可能といえる。

嵐山地区についても同様の分析を行った結果，京都駅から嵐山地区に向かうパターンのほかに伏見稲荷の後に嵐山に向かうパターンや，JR円町駅，二条駅，二条城周辺を経由するパターンも存在した。このパターンは時期が異なっても，日帰り層，宿泊層のいずれにも得られた。ただし，ライトアップ実施時には嵐山地区から東山地区へ移動するパターンが抽出されたのに対し，ライトアップがないときにはこのような移動は抽出されず，ライトアップが実施されている週においては，東山地区を中心とし




(a) 日帰り層




(b) 宿泊層

図 6.1 11/23~25 のアドレス数の時間分布

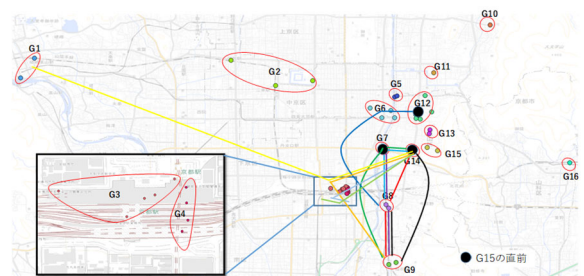


(a) 日帰り層

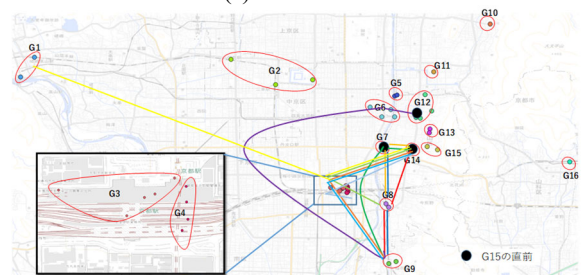


(b) 宿泊層

図 6.2 12/7~9 のアドレス数の時間分布



(a) 11/23~25



(b) 12/7~9

図 6.3 リフト値の高い移動パターン




図 6.4 東山地区のMFD

た典型的なパターンが支配的になること、その後の12月の週であると、東山地区を先に訪問しその後嵐山地区へ向かう流動が観測されることなど、多様な交通流動パターンが抽出された。

(3) MFDによる観光流動評価

次に、東山地区および嵐山地区にエリアを絞ってMFD分析を実施し、それぞれの地区の交通状態の分析を行った。まず、東山地区に設置された129個の車両感知器のデータを用いてMFDを作成した。ここでは、交通対策前の11/10、ライトアップ期間中の11/17、最も混雑の激しかった11/24の3日について比較考察する。

図 6.4 をみると、京都市全体のMFDと比較してばらつきはあるが、日ごとの違いには同様の傾向にある。最大スループットは、11/10、17では7,700台/5分弱、11/24は7,500台/5分程であった。存在台数については、11/10、17、24で、それぞれ最大4,300台、4,300台、5,000台である。つまり、最大スループットから、東山地区の交通効率性としては、11/10、17がよりよく、存在台数から、交通需要は11/24が最大であった。さらに、ヒステリシスの大きさからは、11/24により深刻な混雑が発生していたと推察できる。以上より、11/24はあまりに多くの車両が集中したため交通効率性が低下した状態といえる。24日が特に混雑が激しかった要因としては、24日は、3連休の中日であり、なおかつ17日から実施しているライトアップの影響を強く受けたためと考えられる。次に、交通対策の観点からMFDの形状をみってみる。11/10が交通規制前、それ以外が交通規制中である。スループットは11/10と11/17でほとんど変わらないこと、11/10の方が渋滞延伸時と解消時の間のヒステリシスが小さいことから、11/10の交通状況の方がよかったといえる。ただし、渋滞延伸中(6~8時、黄色)において、存在台数2,000台/km程度で最大スループットの7,000台/5分程度が得られているが、11/10は6,500台程度であり、交通の流動性が少し高い。右折進入を規制したことなどによって、この地区全体の交通流動性が改善されたと考えられる。

嵐山地区においても同様に地区内に存在する30個の感知器データを用いてMFD分析を行ったが、感知器数が少ないこと、この地区のみで交通状況が完結していないこともあり、散布図は特に渋滞領域でプロットのばらつきが大きかった。また、交通対策によって最大スループットの違いはほとんどなかった

が、交通規制実施時には、存在台数が15%程度減少しており、交通対策は交通需要の抑制には寄与していたものと考えられる。ただし、最も交通量が多い11/24には存在台数も最大となったことから、今回実施した交通施策は、最も観光需要が高かった11/24では十分な需要抑制ができておらず、追加の対策が必要であったといえる。

(4) 自動車のトリップパターン推定結果からの観光流動評価

11/10、17、18、24の4日間を対象とし、東山地区および嵐山地区に集中する交通量を対象として分析する。図 6.5 は、東山地区に集中する日交通量の推移を示したものである。交通規制が開始された11/17では、その前週の11/10と比較して6%程度減少しており、交通対策が集中交通量の抑制に一定の貢献をしたのではないかと推察できる。しかし、3連休の11/23~25では大きな交通需要が観測されており、交通対策が不十分であった可能性も否めない。

図 6.6 は、東山地区への土曜日の時間帯別集中交通量を示している。全体としては11/24の交通量が最も大きく特にその傾向は13:00~17:00で顕著である。11/17、24が東山地区のライトアップの時期と重なっているが、11/17には11時ごろからの集中交通量が抑えられているのに対し、11/24はずっと集中交通量が多い状態が継続していた。この結果からは、交通対策や観光対策による影響を明示的に確認することは困難であった。

また、嵐山地区において同様の分析を行った結果、集中交通量は交通対策実施前より総じて小さく、流入交通量が抑制されている可能性が高いことが確認できた。

(5) 乗客のトリップパターン推定結果からの観光流動評価

第4章で推定したバスのジャーニーODを集計し、東山地区におけるライトアップがバス利用者の流動に及ぼす影響を分析する。五条坂、清水道、東山安井、祇園、知恩院前、東山三条の6つのバス停を東山地区にあるバス停と定義する。ここでは、ジャーニーODの時間帯ごとの比率を比較する。

図 6.7 に東山地区への着需要の時間帯ごとの比率および東山地区からの発需要の時間帯ごとの比率を示す。なお、比較対象のためライトアップ施策実施の1週間前の週末にあたる11月10日(土)、11月




図 6.5 東山地区への集中交通量の推移





図 6.6 時間帯ごとの日集中交通量（東山地区）



(a) 東山地区への着流動比率

(b) 東山地区からの初流動比率

図 6.7 東山地区を発着する流動の時間比率

11 日（日）のジャーニーOD の推定値を集計した結果も示している。ライトアップ施策実施前の 11 月 10 日、11 日と比較すると、11 月 17 日は 12:00 から 16:59 の時間帯の東山地区への着需要比率は低下し、17:00 以降の着需要比率が上昇している。さらに、ライトアップ施策実施前の同じ曜日の 11 月 10 日と比較して、11 月 17 日の 12:00 から 16:59 の時間帯の東山地区からの発流動比率も低下し、17:00 以降の発需要比率が増加している。この結果、11 月 17 日は昼間時間帯の需要が夜間に転換したため、ライトアップ施策によるバス需要の時間的な分散効果が確認できたといえる。さらに、11 月 23 日の東山地区からの発流動比率に関しても、ライトアップ施策実施前の同じ曜日である 10 日と比べると昼間時間帯の需要比率がやや低下し、夜間の需要比率が上昇していることが確認できる。また、ライトアップ施策の効果ではないが、連休最終日にあたる 11 月 25 日の東山地区の発流動に着目すると、9:00 から 11:59 の比率が上昇し、昼間時間帯の発需要比率が他の日と比べると低下していることが読み取れる。この結果は、(2) の Wi-Fi パケットセンサにおける 11/25 の東山地区への来訪人数の時間分布と整合する。また、同様の分析を京都駅前、四条河原町、北大路バスターミナルと東山地区をそれぞれつなぐ OD ペアで実施した

結果、ライトアップ施策がバス需要の平準化に寄与する可能性が確認できたものの、効果が発現するのは日や OD ペアによって異なることが確認できた。さらに、ライトアップ施策によりかえって夜間の混雑激化に繋がる可能性があることも示された。

(6) まとめ

以上様々な視点から、交通施策、観光施策による流動変化について考察を加えた。まず、Wi-Fi パケットセンサデータを用いた流動抽出結果をみると、曜日により移動需要が大きく変化すること、特に観光客の多かった 3 連休には伏見稲荷、清水寺、嵐山を回遊する典型的パターンが多く抽出されるが、比較的落ち着いた時期では錦市場などを訪問するような多様な移動パターンが見られること、日帰り客と観光客では一部行動パターンが異なることなどが明らかとなった。MFD 分析からは、交通対策と関係して、東山地区においては、若干の交通流動性の改善が、そして嵐山地区では交通需要の抑制が確認でき、実施した交通対策には一定の効果があったといえる。一方で、3 連休の中日である 11/24 に交通混雑が深刻であったことが確認できており、特に観光需要が大きな日では、対策が不十分であった可能性もいめない。

トリップパターン推定結果からは、東山地区、嵐山地区へ集中する交通量が抑制されていた可能性があることが確認できているが、規制時間帯と規制外時間帯での集中交通量の違いは明確ではなかった。さらに、バス利用者のジャーニーODを推定する方法を用いて、東山地区におけるライトアップの観光需要分散効果についても検証した。昼間時間帯の一部需要が夜間に転換している可能性が高く、ライトアップ施策がバス需要の平準化に寄与することが確認できた一方、効果の程度は日やODペアによって異なることが確認できた。さらに、ライトアップ施策により特定のODでは逆に夜間の混雑激化に繋がる可能性も示された。



図 6.8 Wi-Fi パケットセンサの配置

6.3 時間消費を考慮した観光流動分析

本節では混雑の激しい清水寺、高台寺周辺(以降、「清水エリア」と称す)を対象として、Wi-Fi パケットセンサから得られる流動データを用いて、当該エリアを訪れた観光客の行動を対象に、その時間軸上の特徴に着目して分類し、ピーク時間帯を避けた清水エリア訪問が可能である観光客層の特定を試みる。

(1) 利用データ

ここでは 2018 年度に実施した流動調査において京都市内の主要な観光地および駅等に設置された合計 39 基の Wi-Fi パケットセンサにより収集したデータを用いた。センサの設置箇所および設置主体の一覧を図 6.8 に示す。本節における分析対象期間は 2018 年 11 月 26 日から 2019 年 2 月 24 日までの 13 週間 (91 日間) とした。なお、MAC アドレスがスマートフォン等の方でランダム化されたデータ、1 つのセンサのみに捕捉されているデータ、最初の観測から最後の観測までが 5 分未満のデータは除去した。また、各観光エリアを単位とした移動に着目するため近接しているセンサをまとめて表 6.3 に示すエリアを定義した。

(2) 観光客データの抽出方法

Wi-Fi パケットセンサによって得られたデータには観光客だけでなく地域住民や就業者なども含まれるため、観光客データを抽出する必要がある。本研究では観測数や観測時刻等の観測対象の行動特性を表す指標に着目し、k-means 法による非階層クラスタリングによって観光客と推定されるデータの抽出を行った。

京都市への観光客のうち 7 割が日帰りで 4 泊以上する観光客は全体の 1% 程度 (京都観光総合調査による) との事実を踏まえ、捕捉日数が 5 日以上データは、京都市に居住もしくは通勤・通学等の目的で訪問する人に相当し、観光客の可能性は低いとして分析対象外とした。補足日数 4 日以下のデータは、Wi-Fi パケットセンサにより利用可能なデータの質・量を考慮し、表 6.4 に記載の方針で対応した。

表 6.3 分析対象エリアの定義

エリア名	センサ数	含まれるセンサ (括弧内の数字はセンサ数を表す)
嵐山	2	嵐山渡月橋, JR 嵯峨嵐山
円町	1	JR 円町
祇園	4	八坂神社, 知恩院駐車場, 円山駐車場, 祇園バス停 (2)
清水	5	清水寺, 高台寺, 高台寺駐車場, 清水坂駐車場, 五条坂バス停
清水五条	1	清水五条
京都駅	9	京都駅の各センサ (9)
銀閣寺	1	銀閣寺参道
三条	3	東山三条, 三条京阪 (地下鉄・京阪)
四条	4	錦市場, 先斗町, 京都河原町, 祇園四条
東福寺	2	JR 東福寺 (2)
二条城	2	二条城, JR 二条
伏見稲荷	2	伏見稲荷大社裏参道, JR 稲荷
平安神宮	1	平安神宮
山科	1	JR 山科

表 6.4 観光客データ抽出の方針

捕捉日数	観光客の可能性	取得データ量	分析方針
1 日	高い	少ない	フィルタリング
2 日-4 日	中程度	多い	クラスタリング
5 日以上	低い	—	除去

今回の調査で設置された 39 個のセンサのうち、鉄道駅に設置されたものを駅センサ、それ以外のセンサを観光地センサと分類した。ただし、「JR 稲荷」、「JR 嵯峨嵐山」は主要観光地に近接している鉄道駅であるため観光地センサに含めた。このうち、観光地センサに多く捕捉されている場合は、京都市の主要観光地を周遊している観光客の可能性が高いと考えられる。逆に朝夕を中心に駅センサのみに観測されるアドレスは観光客のものとは考えにくく、通勤通学等の目的で駅を利用している人の可能性が高い。捕捉日数 2-4 日のデータについては、以上の考えに基づき、表 6.5 に示す各変数を用いてクラスタリングを行った。

クラスタリングは次の手順により行った。1)表 6.5 の指標に対して主成分分析を実施、2)エルボー法によるクラスタ数の決定、3)k-means++法による非階層クラスタリングの実施とする。

エルボー法とはクラスタ内誤差平方和 (SSE 値; Sum of Squared Error) のクラスタ数の増加による SSE 値の減少幅が小さくなる点を最適なクラスタ数とする方法である。k-means++法は k-means 法の初期値依

表 6.5 クラスタリングに利用する指標

変数名	説明
観測数の最大値／最小値	1 日ごとの観測数の最大値および最小値
捕捉センサ数の最大値／最小値	1 日ごとの捕捉されたセンサ数の最大値および最小値
捕捉観光地センサ数の最大値／最小値	1 日ごとの捕捉された観光地センサ数の最大値および最小値
観光地センサ割合	滞在期間中に 1 度でも捕捉された観光地センサ数を総センサ数で除したもの
昼間観測割合	滞在期間中の全観測のうち、午前 10 時から午後 4 時までの間に観測された割合
初観測時間	滞在期間中で、1 日の最初の観測が午前 9 時以前であった日数
土休日日数	滞在期間のうち土曜・日曜・祝日の日数

表 6.6 クラスタ別の各指標の平均値

クラスタ	1	2	3	4	5
観測回数の最大値	9.838	10.860	4.796	3.615	3.657
観測回数の最小値	4.846	2.381	2.193	2.116	2.188
捕捉センサ数の最大値	5.411	6.128	3.184	2.538	2.485
捕捉センサ数の最小値	3.230	2.023	2.019	2.019	2.028
観光地センサ数の最大値	3.900	4.440	2.376	0.564	0.529
観光地センサ数の最小値	1.671	0.730	1.108	0.074	0.234
観光地センサ割合	0.700	0.695	0.711	0.157	0.174
昼間観測割合	0.521	0.560	0.487	0.332	0.081
初観測時間	0.537	0.430	0.445	0.370	2.333
土休日日数	0.776	0.755	0.793	0.871	0.394
サイズ	11587	15089	31836	31945	27267

存性の対策として、2007 年に David Arthur と Sergei Vassilvitskii によって提案された方法であり、より離れたデータが初期値として選ばれやすくなる。

捕捉日数 1 日のデータについては、観光客である可能性が高いという仮定を設け、明らかに観光客でないとして推測されるデータは可能な範囲で最大限除去するという方針の下、1)観光地センサで捕捉されている、2)2 エリア以上訪れている、3)観測時間が 1 時間以上、という 3 つの条件によりフィルタリングを実施し、観光客のデータを定義することとした。

(3) 観光客データの抽出結果

捕捉日数 3 日を例に、クラスタリングの結果を示す。上記のエルボー法を適用した結果、捕捉日数 2-4 日に共通でクラスタ数は 5 とした。表 6.6 は捕捉日数 3 日のケースについて、分析に用いた各指標の平均値を示している。

クラスタ別の解釈を示す。クラスタ 1, 2 は観測数や観光地センサ割合が高いことから、今回センサを設置したエリアを複数訪れている観光客であると推定される。クラスタ 3 は観光地センサ割合が高いものの観測数が少ないことから、公共交通をあまり利用せず観光地センサ周辺にのみ現れるクラスタであるとも言える。観光客の可能性も考えられるが、観光目的でなく観光地を訪れている周辺住民や就業者などの可能性も考えられ、クラスタ 1, 2 と比べると明確に観光客らしいと判断することはできない。クラスタ 4 には週末に観測されたデータが多数含まれているが観光地センサ割合は低く、週末に鉄道を利

表 6.7 捕捉日数・クラスタ別 AMAC アドレス数

捕捉日数	クラスタ						
	1	2	3	4	5	101	102
1 日	-	-	-	-	-	1,519,380	799,799
2 日	35,207	52,793	136,219	99,127	72,458	-	-
3 日	11,583	15,089	31,836	31,945	27,267	-	-
4 日	2,790	6,150	9,813	13,760	15,503	-	-

用し中心商店街を訪れる人等が考えられる。クラスタ 5 は観光地センサ割合が小さく、朝 9 時前に最初の観測が得られる日数が大きいことから、朝夕に鉄道駅を利用する通勤通学等の人々の可能性が高い。捕捉日数 2 日、4 日についても同様の傾向が見受けられる。

表 6.7 は捕捉日数 1 日のデータに対するフィルタリング結果も含めた、各クラスタの該当サンプル数を示している。なお、捕捉日数 1 日については、観光客の判別基準が全く異なることから捕捉日数複数の場合と異なる番号を付与して区別する。捕捉日数 1 日のデータで観光客と判断したものをクラスタ 101、観光客でないとして判断したものをクラスタ 102 とする。以降はクラスタ 1, 2, 101 に属する AMAC アドレスを観光客データとして分析を進める。

(4) 時刻に着目した観光客のクラスタリング

本項では、京都市内でも特に多くの観光客が訪れ、慢性的な混雑が発生している清水寺や高台寺周辺（清水エリア）を対象とし、当該エリアを訪れた観光客の行動を対象に、その時刻・時間に着目した分析を行う。具体的には清水エリアへの訪問時間帯およびその長さ、清水エリア訪問前後の京都市内での活動時間等に基づき、観光客を分類する。その上でピーク時間帯を避けた清水エリア訪問が可能である観光客層を特定し、混雑緩和に向けた働きかけが有効と思われる対象を明確化を試みる。

ここで本研究にて着目する時刻および時間の定義を図 6.9 に示す。清水エリアには相対的に密にセンサが設置されており、エリアを出入りする場合にはエリア内のいずれかのセンサに捕捉されることが期待できる。そこで、清水エリア内センサの初回観測時刻 t_2 および最終観測時刻 t_3 の差として清水エリア滞在時間 T_s を定義する。また、1 日の初回観測時刻を t_1 、最終観測時刻を t_4 とし、清水エリア訪問前時間 T_b を t_1 と t_2 の差、清水エリア訪問後時間 T_a を t_3 と t_4 の差として定義する。

清水エリア滞在時間 T_s が清水エリア訪問前時間 T_b や訪問後時間 T_a に比して小さい場合には、清水エリアを訪問する時間帯を変更する余裕のある観光客と判定することができる。しかし、初回観測や最終観測のセンサ位置によって清水エリアとの行き来に要する時間が異なり、 T_b や T_a が同じ値であっても意味合いが異なると考えられる。そこで、初回、最終観測の地点と清水エリア間の所要時間に相応する値としてセンサごとの T_b 、 T_a の 1 パーセント値をそれぞれ差し引いた値を T'_b 、 T'_a と定義し、この値を用いて清水エリア訪問前後の時間的余裕の大きさを評




図 6.9 時刻・時間の定義

表 6.8 観測時刻に基づくクラスタリング

cluster	T_b [min]	T_s [min]	T_a [min]	t_1	t_2	t_3	t_4	size
A	46.31	63.55	355.56	9.89	10.81	11.88	18.03	44554
B	65.51	55.85	74.35	14.60	15.92	16.84	18.22	58819
C	76.02	61.26	55.57	11.63	13.17	14.20	15.28	98052
D	45.71	236.94	90.98	10.43	11.35	15.32	16.98	22337
E	23.81	71.86	96.92	9.39	9.91	11.11	13.00	76993
F	302.49	51.85	72.89	10.16	15.53	16.39	17.74	56162

価することとした。

前項で抽出した観光客データのうち清水エリアのセンサに捕捉された AMAC アドレスを対象として、 t_1 から t_4 および T_b 、 T_s 、 T_a の7変数を利用した非階層クラスタリングを実施した。クラスタリングは前項と同様の手法で行った。エルボー法の結果よりクラスタ数は6とした。

表 6.8 はクラスタごとの時刻・時間に関する各指標の平均値をまとめたものである。この表に基づくと、各クラスタの特性として以下のような解釈が可能である。クラスタ A, D, F は平均的に午前10時から午後6時と1日に渡って観測されている点で共通しているが、クラスタ A では清水エリア訪問後の時間が長く、クラスタ F は清水エリア訪問前の時間が長い、クラスタ D では清水エリア滞在時間が長いという違いがある。クラスタ B, C, E は平均的に観測時間が3時間程度である点で共通しており、クラスタ B は午後中心、クラスタ E は午前中心、クラスタ C は正午前後を中心に観測されているという違いがある。

図 6.10 はクラスタ別に訪問エリア数の割合をまとめたものである。クラスタ F の清水エリア訪問前、クラスタ A の清水エリア訪問後では訪問エリア数が2である AMAC アドレスが最も多く、訪問エリア数が3以上である AMAC アドレスが4割程度を占めている。一方それ以外のクラスタでは、7割から8割程度の AMAC アドレスが訪問エリア数1以下である。訪問エリア数が0の場合は初回観測あるいは最終観測が清水エリア内のセンサであることを示し、訪問エリア数が1ということは初回観測から清水エリアでの初回観測までの間に他のどのエリアのセンサにも捕捉されていないことを意味する。ここから、今回の調査でセンサを設置した観光地に限定すれば、クラスタ A, F については、清水エリア以外の観光地も訪れている可能性が高いと推察される。一方、クラスタ A では清水エリア訪問前、クラスタ F では訪問後の他エリアの訪問数は1エリア以下が大多数であることから、多くの観光客にとって清水エリアの訪問は最初か最後である可能性が高い。

(5) 観光客のピーク時間帯訪問割合

表 6.9 に清水エリア訪問者のクラスタ別にピーク時間帯の訪問有無別の AMAC アドレス数およびそ




図 6.10(a) 清水エリア訪問前の訪問エリア数

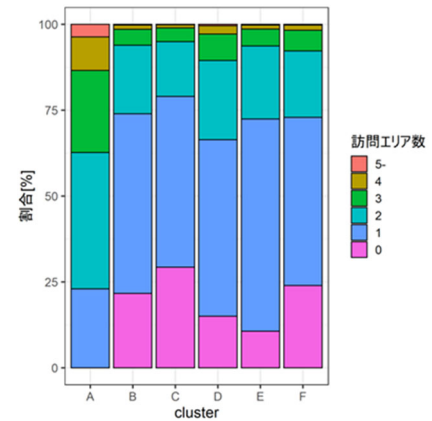


図 6.10(b) 清水エリア訪問後の訪問エリア数

表 6.9 クラスタ別ピーク時間帯訪問の有無

	ピーク時間帯の観測		
	なし	あり	
クラスタ	A	28531 64.0%	16023 36.0%
	B	28658 59.0%	19887 41.0%
	C	2844 3.3%	83005 96.7%
	D	3025 17.7%	14025 82.3%
	E	59137 92.2%	5019 7.8%
	F	26265 46.8%	29897 53.2%

の割合を示す。ここで、ピーク時間帯は清水エリアのセンサにおいて観測 AMAC アドレス数が多い13時から16時と定義した。

クラスタ C, D に属する AMAC アドレスではピーク時間帯に訪問する割合が特に高くなっているが、クラスタ D は清水エリアに長時間滞在する特徴を持ったクラスタであり訪問時間帯の変更による混雑緩和に寄与することは難しいと思われる。一方クラスタ C は割合だけでなく量的にもピーク時間帯に観測されている AMAC アドレス数が多く、時間分散の働きかけのターゲットと考えることができる。しかし、前述の通りクラスタ C は滞在時間が3時間程度の日

帰り観光客に特徴的な傾向を示しているクラスタであり、訪問順の変更等による時間分散を働きかけることはできないと言える。ここから、京都市へ観光に訪れる時間帯そのものを変更するような施策が必要であることが推察される。複数日滞在の観光客においてもクラスタCに属する観光客は一定数存在し、日帰り観光客と比して量が少ないものの、その行動変更（訪問時間帯の変更）による混雑緩和は一定期待できる。加えて、ピーク時間帯を避けた訪問を促すことにより観光の満足度の向上につながる可能性がある。

6.4 おわりに

本章では主として2章から4章にて記述した研究成果を踏まえ、道路および観光地の混雑緩和に資するマネジメント施策について検討した。そのため、まず自動車ならびにバスの乗客のトリップパターンを推定する方法を活用し、秋季の観光地交通対策の影響について分析した。加えて、自動車交通については、MFDを用いて道路ネットワーク上の流動特性について評価した。さらに、観光客の諸活動の時空間的分散の可能性について考察するため、訪問者の代表的周遊・観光エリアでの時間消費パターンをWi-Fiパケットセンサデータより推定した。これらの分析の結果、得られた基礎的な知見は、以下の通りである。

- 1) Wi-Fiパケットセンサデータを活用した観光客の流動分析の結果より、曜日による観光需要の変化、観光需要の多い期間とそれ以外の期間の代表的な周遊パターンの差異が示される結果となった。具体的には、観光客の多い3連休には伏見稻荷、清水寺、嵐山を回遊する典型的パターンが多くなるが、比較的落ち着いた時期では錦市場などを訪問する多様なパターンが見られること、日帰り客と観光客では一部行動パターンが異なることなどが明らかとなった。
- 2) MFD分析からは、交通対策と関係して、東山地区においては、若干の交通流動性の改善が、そして嵐山地区では交通需要の抑制が確認できた。自家用車等の地区内への乗り入れを抑制し、当該地区および周辺交通状況の改善を目指した取り組みについては一定の効果があったといえる。
- 3) トリップパターン推定結果からは、観光地交通対策の実施により、東山地区、嵐山地区へ集中する交通量が抑制されていた可能性があることが確認できている。
- 4) バス利用者のジャーニーODの推定結果より、東山地区におけるライトアップの観光需要分散効果について検証した。昼間時間帯の一部需要が夜間に転換している可能性が高く、ライトアップ施策がバス需要の平準化に寄与することが確認できた。
- 5) 清水エリアへの来訪者の行動をWi-Fiパケットセ

ンサデータを用いて分析し、時間軸上の行動特性に基づき分類した。清水エリア来訪の前後に観光行動を行っていると思定される者は多く居るものの、その多くはピーク時間帯の前後に清水エリアを来訪する傾向があること、ピーク時間帯の来訪者の多くは京都市内の滞在時間が短く、清水エリアを主目的地としている可能性が高い可能性があるといえる。

上記の知見に基づき、観光需要のマネジメント施策について影響評価を実施し、有効なマネジメント施策の方向性について検討した。観光需要の分散としては、現時点の結果からは、空間的な分散よりは時間分散を進めるための方策の充実が望ましいと考えられる。また、自家用車の流入抑制施策は一定効果を発揮しているが、需要の集中日には混雑が激しくなっているとも考えられ、本研究で構築してきた交通流動推定システムを活用した効果検証の積み重ね、ならびに、改善案の検討が必要とも考えられる。

第7章 まとめ

7.1 研究成果

本研究では、観光流動の把握を主たる目的とし、ETC2.0プローブ情報、携帯電話系データ、Wi-Fiパケットセンサデータなど様々なビッグデータを利活用し、観光トリップを主とした都市内の移動対象として、トリップパターンおよびトリップチェーン流動を推定するシステムを開発してきた。本研究にて提案された方法論は、情報提供、イベント実施を始めとする観光需要マネジメント施策の効果について、ODならびにトリップチェーンの変化を通じて、量的、質的に把握するとともに、交通混雑の緩和との関係性を明らかにするため活用することを目指してきた。

本研究では、移動体通信データによる繁忙期または交通マネジメント方策実施時の交通流動観測、自動車および乗客のトリップパターン推定モデルの検証、及び、トリップチェーン推定手法の構築・検証等を実施した。加えて、秋季の観光地交通対策やライトアップなどのイベントが、訪問者の行動に及ぼす影響ならびに交通システムへのインパクトについても、実証的に分析を試みた。加えて、観光需要マネジメントの方向性について検討してきた。以下では各章単位で得られた主な成果を整理しておく。

第2章「移動体通信データによる繁忙期または交通マネジメント方策実施時の交通流動観測」で得られた成果は以下の通りである。

- 1) 本研究課題ではWi-Fiパケットセンサを京都の主要観光地に設置することで、リアルタイムでの設置地点の観光客の捕捉が可能となった。それにより、繁忙期の観光客の流動把握や交通マネジメント方策実施に伴う効果検証のためのデータを整理した。
- 2) Wi-Fiパケットセンサのデータに系列パターンマイニング手法を適用することで、観光客の代表的流動パターンを明らかにした。この手法ではデータ別にクレンジングや観光客特定のためのクラスタリングを行う必要はあるものの、利用するデータによらず、代表的流動パターンの抽出適用が可能である。
- 3) 混雑する観光地として、東山地区における観光客

の経路選択に関して、収集したWi-Fiパケットデータに基づき、実際の地理データを使用して簡略ネットワークを構築し、観光地の魅力度を反映する変数を加味したRecursive Logitモデルを構築した。

第3章「自動車のトリップパターン推定モデルの検証」の主な成果は、以下の通りである。

- 1) 観測間の走行リンクの途切れを補完したETC2.0データを用い、経路選択行動を再分析し、右左折数及び交差点数を説明要因に加えた経路選択モデルを推定した。これを用いて動的リンク利用率を算定する方法により得られた動的リンク利用率を用いて、モデル推定計算を行った結果、利用リンクが限定的であるとの課題が緩和されるとともに、リンク交通量の再現率が15%程度改善されることが確認された。
- 2) 2018年秋季を対象としマクロ交通基本図(MFD)分析を実施した。その結果、土曜日と日曜日では最大スループットが異なり、日曜日の方が、パフォーマンスが低下すること、11月の3連休中目である11/24においては深刻な交通渋滞が発生していたことなどが確認され、簡易に交通状態を評価する手段としてMFD分析が有効であることを示した。
- 3) 10日間を分析対象として動的トリップパターン推定を行った結果、インプットデータに応じて日生成交通量やその時間パターンは変化しており、観測交通量に整合した動的トリップパターンを推定していることが確認された。
- 4) MFD分析から特に日曜日においては雨天時では最大存在台数が15%程度減少し、最大スループットが2%程度低下していることが確認できた。一方、動的トリップパターン推定モデル結果からは、日生成交通量の変化は小さいものの、京都市内を発地あるいは着地にもつ交通需要が7%ほど減少していることが確認された。雨天時のトリップパターン変化の可能性が示唆され、天候を考慮した交通管理、交通制御に有益と考えられる。

第4章「乗客のトリップパターン推定モデルの構築・検証」における主な成果は、以下の通りである。

- 1) 構築した乗客のトリップパターン推定モデルの枠組みを用いて、30年11月の繁忙期における京都市バスの乗客トリップパターンの推定を行った。なお、推定にあたり、30年11月時点の全バス停における乗降人数を計測していなかったため、乗降人数のサンプルデータをGNSSデータから推定した。GNSSデータの多い12:00~16:59の時間帯における乗客のトリップパターン推定モデルのパラメータは有意に推定され、符号条件も満たしていることを確認した。
- 2) 推定されたジャーニーODからバス停ごとの乗降人数の合計値を算出し、これを3次メッシュ単位に集計したものとモバイル空間統計の滞留人口データの相関係数を比較し、ジャーニーODの精度検証を行った。相関係数最大ケースでは、概ね右肩上がりの関係となり、ジャーニーODから算出した乗降人数の合計値と、モバイル空間統計の滞留人口データの間には正の相関があることが確認された。

第5章「トリップチェーン推定手法の構築・検証」における主な成果は、次の通りである。

- 1) 30年秋季の京都における自動車OD、バスOD、モバイル空間統計（Move-Stayデータ）、GNSSデータ（あるくまち京都アプリ）を用いたトリップチェーン選択確率の推定を行った。その結果、午前中は主要観光地には、市内・周辺からの人口流入が大きい、午後になると域外からの流入が大きいことも分かった。
- 2) 繁忙期、非繁忙期の差分の分析により、繁忙期の京都のトリップチェーン特性を把握した。繁忙期は近隣府県を含まない遠方から主要観光地への流入が大きく、非繁忙期は近隣府県からの流入が大きい。また、非繁忙期はその理由から比較的早い時間帯に流出している一方で、繁忙期は流出量が小さく、他の観光地を訪問している。
- 3) 自動車及び乗客のトリップパターンを所与とし、モバイル空間統計、アプリ GNSS データなど他の人の流動と組み合わせることで属性別・時間帯別のトリップチェーンを推定するモデルを構築した。また、GNSS データ単体での分析も行った。これら一連の分析結果では1時間帯の流動について人気観光地に流動が集中すること、属性によって選好が異なること、季節変動による影響などを推定したモデルにより表現できていることを確認した。

第6章「交通マネジメント方策の影響評価に関する基礎分析」における主な成果は、次の通りである。

- 1) Wi-Fiパケットセンサデータを活用した観光客の流動分析の結果より、曜日による観光需要の変化、観光需要の多い期間とそれ以外の期間の代表的な周遊パターンの差異が示される結果となった。
- 2) MFD分析からは、交通対策と関係して東山地区において、若干の交通流動性の改善が、そして嵐山地区では交通需要の抑制が確認できた。自家用車等の地区内への乗り入れを抑制し、当該地区お

よび周辺の交通状況の改善を目指した取り組みについては一定の効果があったといえる。トリップパターン推定結果からは、観光地交通対策の実施により、東山地区、嵐山地区への集中交通量の抑制の可能性が確認できている。

- 3) バス利用者のジャーニーODの推定結果より、東山地区においてはライトアップ実施時に昼間時間帯の一部需要が夜間に転換している可能性が高く、ライトアップ施策がバス需要の平準化に寄与することが確認できた。
- 4) 清水エリアへの来訪者の行動について分析し、時間軸上の行動特性に基づき分類した。清水エリア来訪の前後に観光行動を行っていると思定される者は多く居るものの、その多くはピーク時間帯の前後に清水エリアを来訪する傾向があること、ピーク時間帯の来訪者の多くは京都市内の滞在時間が短く、清水エリアを主目的地としている可能性が高いことを確認した。

7.2 今後の課題

最後に本研究に関する今後の研究課題について、以下に整理しておく。

- 1) 自動車のトリップパターン推定モデル、乗客のトリップパターン推定モデルおよびトリップチェーン推定手法に共通する課題として、計算効率性の向上を挙げることが必要である。例えば、自動車のトリップパターン推定モデルでは拡張された道路ネットワークにおけるDial配分を実施し、それを元にリンク利用率を算定した上で、動的トリップパターン推定を実施した。203のセントロイドに対し、各セントロイドペアでのDial配分を1日分(1時間ごとに24時間分)計算実施する際に、研究室にあるワークステーション(例えば、Core i9-7920X, 2.90GHz, 64GBメモリ, Windows10 64bit)であっても10時間ほどかかった。その後の動的トリップパターン推定が20時間程度必要であり、全体としては30時間、途中の作業も含めると1回あたりの計算が40時間程度となってしまう。今後、並列計算などの可能性も含め計算効率性の改善が望まれる。
- 2) 本報告書においては、Tourism Demand Management (TouDeM)に関する施策が観光流動、そして、道路交通をはじめとする交通システムの効率性に及ぼす影響の定量的な評価を試みたが、今のところ限定的な事例に留まっている。今後、施策と効果の関係を常時モニタリングすることを通じて、その結果を体系的に蓄積整理することで、観光都市における交通マネジメントの促進の観点で有効な施策を明らかにすることにも貢献していくことが望まれる。