

GPS データを用いた鉄道利用者の 定量的な推定に関する研究

高安 洋

（東日本旅客鉄道株式会社、東京大学空間情報科学研究センター）

Tianqi Xia

（東京大学空間情報科学研究センター）

Puneet Jeph

（東京大学空間情報科学研究センター）

金杉 洋

（東京大学空間情報科学研究センター）

柴崎 亮介

（東京大学空間情報科学研究センター）

GPS データを用いた鉄道利用者の定量的な推定に関する研究

高安 洋¹ Tianqi Xia² Puneet Jeph²
金杉 洋² 柴崎 亮介²

2023 年 1 月 16 日

概要：近年、日本の鉄道は地方の過疎化による利用者低迷や、都心部の混雑などの諸問題を抱えており、路線ごとの詳しい利用者数を高精度に把握するための新たな手法が求められている。このため、鉄道事業者はビッグデータを用いて様々な情報把握や分析を行っているが、多くは全体的な利用者数を把握するのみで、特定の駅や区間ごとの詳細な流動までは研究対象になっていなかった。そこで、我々は近年急速に普及が進んでいるスマートフォン内蔵の GPS データを活用し、特定の駅と路線の区間を対象に、鉄道利用者数の流動推定を行った。この結果、各駅および路線において、実際の利用者数と近い数値を推定する事が出来た。

キーワード：鉄道輸送, 位置情報, 人流解析

Research on quantitative estimation of railway passengers using GPS data

HIROSHI TAKAYASU^{†1} Tianqi Xia^{†2} Puneet Jeph^{†2}
HIROSHI KANASUGI^{†2} RYOUSUKE SHIBASAKI^{†2}

January 16, 2023

Abstract: Japan's railways are facing problems such as a slump in the passengers due to depopulation in rural areas and congestion in metropolitan area. Therefore, new approaches are required to accurately ascertain the detailed number of passengers on each line. For this reason, railway operators are using big data to grasp and analyze various types of information. Nevertheless, most of the existing studies have only been able to understand the overall number of passengers and have not been able to study the detailed flow at specific stations or sections. Therefore, we used the GPS data from smartphones, which have been rapidly spreading in recent years, to estimate the flow of railway passengers for specific stations and sections of railway lines. As a result, we were able to estimate figures that were close to the actual number of passengers at each station and on each line.

Keywords: Railways transportation, Location information, Flow analysis

1. はじめに

我が国の鉄道は 2022 年 10 月で 150 年を迎えた。開業以来、我々に欠かせない生活の足となり、人のみならず物流輸送においても、重要な交通インフラの一つとしての役割を担ってきたが、その一方で近年では地方の過疎化による利用者低迷や、都心部の人口集中を背景とした混雑などの諸

問題を抱えており、将来を見据えて持続的に鉄道を維持するための方法を模索すべく、大きな分岐点に差し掛かっているとも考えられる。こうした状況下において、特に重要になると考えられるのは利用者流動の把握である。その理由として、2020 年からの新型コロナウイルス感染症の拡大以来、鉄道利用者が低下したまま回復しない事業者が相次いでおり、地方路線や都心から離れた郊外の地域を走る支線

¹ 東日本旅客鉄道(株)
East Japan Railway Company
² 東京大学
The University of Tokyo

などで、鉄道としての維持が困難な路線が顕在化したことが挙げられる。加えて、一部の鉄道事業者は、鉄道インフラの維持に必要な利益率の算出基準として、地方都市を中心とした特定の区間に対して 1 日あたりに必要な利用者の損益分岐点の発表に踏み切っている。

現在、鉄道の利用者を把握するための手段として、事業者が行っていることを挙げると以下に大別される。

- (1) 乗車券類の発売実績に基づく利用実績調査
- (2) 乗車券類の回収実績に基づく利用実績調査
- (3) 鉄道会社による独自の利用実績調査

このうち、(1)と(2)は都心部では自動改札機の通過データを用いることでカウントが可能であり、(3)は、鉄道会社係員による目視調査のほか、車両に搭載されている機器類を用いることでカウントする事が出来る。鉄道会社は、これらの手段によってカウントしたデータを OD データ(Open Destination Data)と呼び、これらを用いることで各路線の列車ダイヤを設定し、利用者に対して利便性の高い輸送商品の提供や、新たな経営資源を投じサービス改善などを図る基準としている。

しかし一方で、こうしてカウントされたデータはいずれも発駅と着駅の実績に基づく概算値であり、その経路の実際の利用者数は推定値である場合や、特定区間のみの断面輸送量を計上した場合が多く、利用者が本当にその路線を利用したのかと言う点について、定量的に把握できていないといった課題がある。

また、2000 年より導入が始まり、大幅に普及が進んだ交通系 IC カードでは、自動改札機を用いることで効率的に利用者の情報を把握できるが、利用者が実際にどのような経路で移動したのかという情報まで把握することは困難であり、都心部以外のエリアを走る路線では、自動改札機が設置されていない駅も未だに存在している。ほかにも、一部の鉄道車両では搭載された重量検知システム(以下、応荷重装置)を用いて、列車ごとの利用者数をカウントする方法もあるが、この情報もすべての路線で常時収集は行っていない他、鉄道会社によっては応荷重装置による利用者カウント方法を確立していないケースも想定される。このため、いずれの場合を見ても鉄道利用者の傾向を高精度かつ定量的に把握できる手法が存在しないのが現状である。

そのような中において、近年大幅に普及が進んでいる GPS 対応スマートフォンの LBS(位置情報サービス) データの存在がある。この膨大な量の位置情報データは、その情報を用いることで、スマートフォンを持つ鉄道利用者個々の軌跡が把握可能であるうえ、個々の移動情報を集積することも可能である。つまり、先に述べた乗車券の発券データをはじめ交通系 IC カードや、応荷重装置からの情報では把握できない、利用者の移動経路や行動に関する情報の課題を克服する手法になりうると考えられる。

2. 先行研究

鉄道利用者を対象とした研究は、様々な分野で行われているが、利用者の移動経路を定量的かつ高精度に把握するようなものは多く存在しない。まず、JR 東日本では首都圏部分を走る鉄道車両に搭載されている応荷重装置のデータと、列車の走行位置情報データを組み合わせることにより、列車ごとの混雑状況と走行位置を把握することが可能な「在来線混雑可視化システム」を開発した。このシステムは、車両の推定乗車率データと、列車のリアルタイムな走行位置データを用いることで、個々の列車の走行位置と、列車を利用している人の混雑状況が把握できる(佐原他 2018)。しかしながら、この装置は JR 東日本内でのみ稼働しているため、同線を走る列車以外の路線の混雑状況までは把握できないほか、同線を走る列車であっても、他社から乗り入れを行っている一部の列車や、首都圏部分以外の区間では情報を把握する事が出来ない。このほか、交通系 IC カードの利用実績データを用いることで、実際の鉄道利用者数を推定し、利用者の移動時間に関する研究も行われている。この研究では、鉄道利用者の交通系 IC カードの情報を基に、自動改札機での入場・出場に要した移動時間を計測することで、通常時と輸送障害等が発生した場面の移動時間差分を合わせて、影響度を指標化している(角田他 2013)。しかし、この研究は輸送障害発生時の影響を指標化したものであるため、通常時における利用者の定量的な数を把握する物とは異なる。

この他にも、鉄道利用者の流動把握や分析に関する研究は、輸送障害などが発生し、ダイヤが乱れた場合を対象としたものが大半であり、研究対象の場面も限定的であった。このため、鉄道事業者の保有する既存のデータから日常的な鉄道利用者の流動を定量的かつ、高精度に推定することは困難なのではないかという事が考えられる。

そうした一方で、位置情報データを活用した研究としては、スマートフォンの位置情報を基にした観光地を訪れた人の流動解析(廣瀬他 2019)や、鉄道利用者の携帯電話から観測された Bluetooth 信号データを用いて列車の混雑状況を推定する研究(Mackawa 他 2014)のほか、Twitter のデータと交通系 IC カードのデータを組み合わせることで、東京メトロ内において発生した輸送障害時の利用者の流動変化を分析する研究も行われている(Mackawa 他 2014)。しかしながら、GPS データを活用した先行研究では、GPS ログデータを活用した道路交通渋滞の分析(Huimin 他 2008)などはあるものの、鉄道利用者の流動把握を対象とした研究は、東急電鉄を利用する被験者を対象に、専用のアプリケーションを用いて、プローブデータを収集して行われた交通行動解析(鯉渕他 2009)のほか、GPS 軌道情報を用いたディープラーニング手法に基づく LSTM(Long Short Term Memory)を用いて、鉄道ネットワークにおけるカーネル密度推定の研究(Xia

他 2018)や、GPS 技術を用いたプローブパーソン調査に基づく鉄道利用者の交通行動把握に関する研究(松島他 2015)などが存在する他には殆ど見当たらなかった。

3. 研究目的

前項で調査した先行研究において、通常時の鉄道利用者を定量的かつ高精度に把握したものがみあたらなかったことから、本研究では、GPS データを用いることで、鉄道利用者数を定量的に推定することを目的とした。なお、この推定にあたっては、特定の路線をケーススタディとして取り上げたうえで、その精度を分析し、考察を行うこととした。

4. 対象データ

本研究では、鉄道利用者の流動を把握するため、GPS データと鉄道事業者のデータを活用する。使用する各データの詳細について以下に記す。

4.1 GPS データ

GPS データについて、本研究の実施では、株式会社ログウォッチャー(以下、ログウォッチャー社)が保有している物であり、データ処理については同社と連携し、GPS 軌跡データを使用した。なお、ログウォッチャー社と共同利用した位置情報では、匿名 ID、タイムスタンプ、経度、緯度のみが収集され、さらに解析結果は集計値の形で得られるため、逆推定による個人の特定は不可能である。また統計は 2021 年 7 月 1 日以降、サンプル数は約 250 万 ID(ノイズフィルタ後)となる。本データの特徴は次のとおりである。

- (1) 原則 852 秒間隔(平均)で各 ID の連続な位置情報が取得・記録されている。
- (2) 緯度経度・観測時間以外の性別・年齢などの属性は一切含まれない。
- (3) 個人を特定することは不可能。

本研究においては、2021 年 4 月 1 日～4 月 30 日までのデータを対象期間として選択した。

4.2 鉄道事業者のデータ

鉄道事業者のデータについては、東日本旅客鉄道株式会社(以下、JR 東日本)と連携し、対象とした駅における自動改札機の通過データ(入場、出場)を使用したほか、各列車個別の利用者を把握するため、個々の車両に搭載されている応荷重装置のデータを活用し、対象とした駅間を走る列車の乗車人数データを使用した。これらの JR 東日本より提供された各データについても、単純に数値のみを対象に収集したため、個人を特定できる情報が収集されることはない。

5. データ整理と方法

本研究の目的である、GPS データを用いた鉄道利用者数を定量的に推定に必要な各データの収集手順と、それぞれのデータ解析の内容について以下に示す。

5.1 GPS データの事前処理

人の移動により生成される GPS の軌跡情報は、ユーザーの位置を示すものであり、鉄道利用者特定には GPS データを移動モード(交通手段)別に分類したうえで、マップマッチング処理が必要となる。これらについては、次のセクションで説明する。

5.2 GPS データを用いた鉄道利用者数の推定方法

本研究では、既存の手法を用いて鉄道利用者数の推定を行った。以下に、各手法について述べる。

(1) 鉄道ネットワークデータの整備

鉄道利用者の推定には、利用者がどの路線を利用したのかということ把握するために鉄道ネットワークデータの整備が必要となる。このデータ整備については、国土数値情報(NLNI)ダウンロードサービスが提供する鉄道データおよび、各鉄道路線の駅配列(各路線の停車駅)と、接続情報ならびに駅の座標が記録されているデータセットである、駅データ.jp が提供する駅の配列データを用いることとしたうえで、Ikezawa らの手法を用いて鉄道ネットワークデータの整備を行った(Ikezawa 他 2016)。




図 1 鉄道ネットワークデータの整備フロー

(2) GPS データに基づく人流データの開発

GPS データを人流データとして整理をするための分析手法としては、大野および Witayangkum らによって提案された移動モード検知法を使用した(大野 2013)(Witayangkum ら 2013)。この手法を用いることで、加工した GPS データを輸送モード別にラベル付けし、それぞれにセグメント化された軌跡データを取得した。




図 2 移動セグメントの結合イメージ

(3) マップマッチングを活用した人流データ整備

鉄道の乗客として識別されたユーザーの正確なルートを

取得するためのマップ マッチングを行う。マップマッチングは、GPS の軌跡を用いて移動経路の復元に役立つプロセスであることから、ここでも、Ikezawa らによって用いられた方法を使用し、鉄道を用いた移動の情報と、GPS の軌跡が地図上で一致するように整備した(Ikezawa 他 2016)。




図 3 形成された鉄道移動のマップマッチングイメージ

以上に示す通り、本研究では GPS データを処理して、鉄道利用者の定量的な推定を可能とする手法を、既存の個別手法である(1)～(3)を組み合わせることにより開発した。

5.3 駅利用者データの抽出

筆者らは、GPS データで推定したデータの精度検証を行うため、実際に駅で乗降した利用者のデータを抽出した。このデータは、JR 東日本のデータサーバ内に蓄積されている自動改札機を通過実績であり、特定の駅において改札機を通過した人の数をカウントし記録している。このデータの中から、「入場」を駅から列車に乗る人の数とし、「出場」を列車から降りて駅の外へ出た人の数というように、2つのカテゴリで部類分けした。

5.4 列車に乗車して移動した鉄道利用者データの抽出

5.3 の駅利用者データと同様に、実際に列車に乗車して移動した鉄道利用者数のデータを抽出した。このデータベースも、JR 東日本のデータサーバに蓄積されているものであり、個別の列車において列車・区間毎の乗車人数をカウントしている「応荷重装置」がベースとなっている。この応荷重装置とは、鉄道車両への荷重（乗車率）の増減により、車両に同じ力でブレーキを掛けると減速度に変化が生じるという課題を克服することを目的に開発されたものである。構造としては、車両の台車と車体との間に挟まれた「空気ばね」において荷重の増減を検知して、ブレーキ制動による減速度を一定に保つための装置である。近年導入された鉄道車両では、この応荷重装置の機能を用いて、空車時と乗車時の空気ばね圧力の変化から、計測されたデータを基に、車両ごとの乗車人数を推定し、その結果を列車別にデータとして蓄積する機能が備わっている。筆者らは、このデータを用いて特定の区間の利用者数を時間帯別、列車ごとに把握できるよう部類分けした。

6. GPS データを用いた事例研究の実施

これまで 4 章において GPS データ、5 章においては鉄道事業者双方のデータを収集し整理する方法を述べてきた。したがって、次にこれらのデータを実際の場面に充てはめ

た事例研究を行うこととした。事例研究の対象について、詳細を以下のとおり示す。

6.1 研究対象

本研究の目的に則り、筆者らは GPS データと鉄道事業者のデータを用いて、鉄道利用者の流動を分析するために、以下の駅と路線を対象とすることとした。併せて、対象とした選定理由についても示す。

(1) 駅利用者数について

JR 東日本の新宿駅を対象とした。同駅は 1 日約 52 万人が利用する国内最大規模のターミナル駅であり、精度検証を行うには十分なサンプル数が得られると考えたためである。

(2) 鉄道利用者数について

JR 東日本、山手線の山手線の上野～御徒町間を対象とした。この区間は山手線外回りにおける朝通勤時間帯ピーク時の最混雑区間であり、国土交通省に報告している路線のひとつである。しだかつて、(1)の新宿駅と同様に十分なサンプル数が得られると考えたためである。

分析にあたっては、2021 年 4 月の 1 か月分を対象とした。

以下に事例研究の対象駅と路線、対象日をそれぞれ整理して表に纏めて記載する。

表 1 事例研究を行う対象駅と路線

項目	路線	駅または区間	対象日
駅利用者数	山手線	新宿駅	2021 年
鉄道利用者	山手線	上野～御徒町間	4 月(1 か月分)

6.2 拡大係数の設定

対象事例にあたる日に収集した GPS データは、鉄道利用者の全数ではない。このため、筆者らは収集したデータを実際の利用者数に近づけることを目的に、拡大係数を設定し、データのスケールアップを行った。それぞれの拡大係数について、以下のとおり手法別に解説する。

(1) 夜間人口を用いた拡大係数

この手法では、まず「居住地」と「勤務地」の推定を行うため、モバイル GPS データの観測時間分布から UID ごとの活動時間分布でクラスタを作成する。そのクラスタを基に、非アクティブな時間帯の最頻滞在地を居住地とし、アクティブな時間帯の最頻滞在地を勤務先とすることで「居住地」と「勤務地」の区分けを行った。



図 4 「居住地」と「勤務地」の推定

次に、拡大係数の推定を行うため国勢調査夜間人口（500m メッシュ人口）を総数とし、そこを居住地とするモバイル

GPS のユーザ (UID 数) に按分割当を行う。各 UID は得られた拡大係数を持って移動するものとし、各駅の利用者にそれらの係数を乗じることで推定を行った。




図 5 拡大係数ごとの按分割当

(2) 最小二乗法を用いた拡大係数

(1)の拡大手法を用いた場合、各推定値は各駅や駅区間ごとでは誤差を有しており、その後さらに補正するニーズが考えられ、その場合には駅、或いは駅区間ごとの補正値を求めるが必要になる。このため、別の拡大手法としてモバイル GPS データの線形拡大推定にあたり、拡大係数をモバイル GPS データの UID (匿名化されたユーザ番号) 毎に推定を行うこととした。こうした拡大係数を、駅の改札や駅区間ごとに単位時間あたりの通過人数や移動人数という形で集計した GPS データに乗ずることで、線形拡大推定値を求める。すなわち拡大係数が実際の通過人数や移動人数と、モバイル GPS データによる移動人数の差を最小にするように推定される。この推定問題は最小二乗法として定式化することができる。




図 6 GPS データ(UID)ごとの拡大係数推定方法

ここで、GPS データで表現される鉄道利用者がどの駅で

Procedure: $Ax = b \rightarrow A^T Ax = A^T b \rightarrow x = (A^T A)^{-1} A^T b$

Problem:

The user information matrix, A , is a sparse matrix. The matrix $(A^T A)$ obtained from it is usually a singular matrix and cannot be inverted.

Dealing with the ill-conditioned matrix $(A^T A)$

Remark: The scale of matrix is large and the solution time is long.

乗降するかという移動行程は、シナリオで定義されるが、各シナリオは時空間的な移動を表しており、誤差の二乗和を最小化する過程で線型方程式となる。この方程式を解くことで、各 GPS データ(UID)に関する拡大係数を推定する事が可能となる。

図 7 最小二乗法による拡大係数の推定方法と定式化
しかしながら、対象となる GPS データ数(推定の必要がある拡大係数の数)は、数十万から数百万のオーダーであり、それに対して観測値として利用可能な駅の改札通過人数や駅間の乗車人数は、数万から十万程度の個数しか存在しないことから、図 7 で示した線型方程式をそのまま解くことができない。したがって、Tikhonov Regularization(正則化)という方法を適用して推定を行う。




図 8 正則化による拡大係数の推定

6.3 研究方法

以上の前提に基づき、事例研究の対象とした駅と駅間の鉄道利用者数について GPS データを基に推定利用者数を算出する。また、それぞれの利用者数を比較するため、グラフを用いて 2 つの拡大手法を用いて算出した推定鉄道利用者データと、鉄道事業者から得られた実際の利用者データについて、対象期間全日にわたり日別の合計値を用いて可視化を行うこととした。

7. 結果

筆者らは、JR 東日本の駅と路線を研究対象として選定し、GPS データと鉄道事業者データとの精度検証を行うため、指定した日別に各データの抽出を行った。この結果、2021 年 4 月の 1 ケ月間に渡って JR 東日本 山手線の新宿駅利用者数ならびに、同社山手線の上野～御徒町間の駅間鉄道利用者数を GPS データと鉄道事業者データの双方で抽出する事が出来た。

以下に、駅と区間別にデータ抽出結果を可視化したグラフの結果を示す。

7.1 駅利用者数の結果

各駅のデータ抽出結果を可視化したグラフを示す。それぞれ、改札を通過して駅に入った人を「入場」とし、駅から出た人を「出場」と定義した。また、グラフ中の横軸は日と曜日を示しており、3 日間隔で日付等をプロットした。併せて、各グラフの凡例にあるとおり、青色の線は自動改札機か

ら抽出した実際の利用者データであり、橙色は夜間人口、緑色は最小二乗法のそれぞれの拡大手法を用いて算出した推定利用者数であり、いずれの推定利用者数についても取得した GPS データが基となっている。




図 9 改札「入場」通過人数比較




図 10 改札「出場」通過人数比較

7.2 鉄道利用者数の結果

各路線の鉄道利用者のデータ抽出結果のグラフを示す。こちら、各グラフの凡例に示すとおり、青色は応荷重装置から抽出したデータ、橙色は夜間人口、緑色は最小二乗法を用いて算出した、GPS データを用いた推定値となる。




図 11 山手線「内回り」鉄道利用者人数比較




図 12 山手線「外回り」鉄道利用者人数比較

以上の各結果から、次章では「駅利用者」と「鉄道利用者」について、それぞれ考察を述べる。

8. 考察

前章では JR 東日本の駅と路線を事例研究の対象として、それぞれの利用者数を抽出・可視化したうえで、鉄道事業者データと GPS データを基にした推定値をグラフ上に可視化した。従って本章においては、「駅利用者」「鉄道利用者」の各結果について、考察を述べていく。

8.1 駅利用者数の考察

夜間人口と最小二乗法の 2 つの拡大係数を用いて GPS データのスケールアップを行った。双方の推定結果を見ると、いずれのケースにおいても推定値と実際の改札データとの誤差について、駅によって差があることが把握できた。

まず夜間人口においては、推定データが実際の自動改札データと比較して少ない結果となっている。この背景として、GPS データは一定期間データを利用する場合でも連続してデータが記録されることは多くなく、例えば 1 ヶ月のデータを取得した場合でも、断続的に空白が生じている。

このため駅改札を通過する際、その空白に当たった場合には、駅を通過したはずの UID のデータがあたかも「存在していない」といったような扱いを受ける。すなわち全体としては 100 万 ID のデータが存在していたとしても、駅を通過する特定の時間帯には 70 万 ID 程度しか存在しないということも起こりうる。こうした現象が、夜間人口による駅改札での拡大推定において、過少となっている原因であると考えられる。一方、最小二乗法を用いた場合には、推定データとして良好な結果が得られたと言える。しかしながら、今回の分析対象は山手線内でも極めて乗降客数が多い新宿駅であることから、こうした駅以外についても検証をおこなうとともに、データ取得のスパンについても更に長く取得したうえで推定データと比較することが必要であると考えられる。

8.2 鉄道利用者数の考察

応荷重データを用いて抽出した実際の利用者数と、GPS データを用いて拡大集計した推定利用者数の誤差率について分析を行った結果、それぞれの路線において、夜間人口による推定と比較して最小二乗法による拡大結果の方が誤差率は低くなることが明らかとなった。こうした傾向は、先に述べた駅利用者数の結果や考察と同様である。なお、夜間人口での推定値が低く計上されている傾向については、駅利用者数と同じく、GPS データ内に生じている空白が原因であると考えられるほか、駅利用者数と同様に山手線内をはじめそのほかの路線においても、様々な区間でデータ抽出と検証を行うことが必要であると考えられる。

9. まとめ

本研究の目的は、GPS データを用いることで、鉄道利用者数を定量的に推定することであった。また、この推定にあたっては、特定の駅と路線をケーススタディとして取り上げたうえで、精度分析と考察を行った。

この結果、JR 東日本 新宿駅の駅利用者数と、JR 東日本 山手線の上野～御徒町間の鉄道利用者数について、GPS データを基に夜間人口と、最小二乗法の 2 つの拡大手法を用いて推定した結果と、実際の利用者数データを抽出し、精度検証と考察を行うことができた。その結果、駅利用者と鉄道利用者の双方において、GPS データを基に推定した利用者のうち、最小二乗法を用いて拡大推計した推定値が実際の利用者が極めて近い傾向で抽出できていることが確認できた。したがって、GPS データを用いることで精度の高い鉄道利用者数を推定することができたことから、有益な結果を得ることができたと考えられる。2 章でも述べた通り、これまでも GPS データを基にした鉄道利用者推定の研究は数が少なく、実際のデータと比較して、その精度を検証した研究は殆ど見当たらなかったことから、本研究の結果は大変有益なものであったと言える。しかしながら、本研究では対象を特定の駅と区間に限定して行ったため、路線全体の人の流れを把握するまでには至らなかった。こうした点については、駅と鉄道利用者数の推定結果を応用することで、引き続き検証が必要になると考えられるため、今後の課題として検討する。また、今回の研究により GPS データを活用することで、高精度な利用者データを推定する事が出来ると判明したため、今後は対象とする駅や路線を拡大したうえで、輸送障害発生時や大規模イベント開催時といった多くの人が鉄道を利用するようなシーンにおいても、利用者の動向を把握することを検討していきたいと考えている。

参考文献

- [1] 廣瀬健,井村祥太郎,絹田裕一,矢部努,スマートフォン位置情報から読み解く観光地における人の流動～ビッグデータはどこまで人の行動を追えるのか～,IBS Annual Report 研究活動報告 2019,p.43-50.
- [2] Huimin, W., Zhongwei, H., Jifu, G., Liyun, Z. and Jianping, S. 2008, Operational analysis on beijing road network during the olympic games. Journal of Transportation Systems Engineering and Information Technology 8(6), pp. 32-37.
- [3] Ikezawa, S., Kanasugi, H., Matsubara, G., Akiyama, Y., Adachi, R. and Shibasaki, R., 2016. Estimation of the number of railway passengers based on individual movement trajectories. In: 6th INTERNATIONAL CONFERENCE ON CARTOGRAPHY AND GIS, p. 249
- [4] Itoh, M., Yokoyama, D., Toyoda, M., Tomita, Y., Kawamura, S. and Kitsuregawa, M. 2014, Visual fusion of mega-city big data: an application to traffic and tweets data analysis of metro passengers. In: 2014 IEEE International Conference on Big Data (Big Data), IEEE, pp. 431-440.
- [5] 大野夏海, 携帯電話による大規模・長期間の GPS データを用いた、東京都市圏における交通モード推定及びモビリティの分析. 2013, 東京大学修士論文
- [6] 鯉淵正裕,加藤勲,移動軌跡データを活用した鉄道利用者の交通行動把握,情報処理学会研究報告. 2009, Vol.ITS-37 No.5 , p.1-8 .
- [7] Maekawa, Y., Uchiyama, A., Yamaguchi, H. and Higashino, T. 2014, Car-level congestion and position estimation for railway trips using mobile phones. In: Proceedings of the 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computing, pp. 939-950.
- [8] 松島敏和,橋本浩良,高宮進,スマートフォンによるプローブパーソン調査の高度化に向けた移動手段判別手法の開発. 2015,土木計画学研究・論文集 Vol.71 No. 5, p. 1_547-1_558.
- [9] 佐原亨,伊藤和敬,坂入整,大塚理恵子,大土橋格,秋吉和也,在来線混雑可視化システムの開発. 鉄道サイバネ・シンポジウム論文集 23. 2018,p.15-19.
- [10] 角田史記,加藤学,大塚理恵子,助川浩子,大関一博, 交通系 IC カードを利用した輸送障害時の影響を定量化する方法の研究, 情報処理学会論文誌. 2013, Vol.6 No.3 , p.187-196 .
- [11] Witayangkurn, A., Horanont, T., Ono, N., Sekimoto, Y. and Shibasaki, R. 2013, Trip reconstruction and transportation mode extraction on low data rate gps data from mobile phone.
- [12] Xia, T., Song, X., Fan, Z., Kanasugi, H., Chen, Q., Jiang, R. and Shibasaki, R. 2018, Deeprailway: a deep learning system for forecasting railway traffic. In: 2018 IEEE Conference on Multimedia Information Processing and Retrieval (MIPR), IEEE, pp. 51-56.