

# 逆強化学習を用いた人流の推計に関する研究

大窪 智博<sup>1</sup>・小林 亮博<sup>2</sup>・上坂 大輔<sup>3</sup>・森本 章倫<sup>4</sup>

<sup>1</sup>学生会員 早稲田大学大学院 創造理工学研究科建設工学専攻 (〒169-8555 東京都新宿区大久保 3-4-1)  
E-mail: t0m4h1r1@moegi.waseda.jp

<sup>2</sup>非会員 KDDI 株式会社 (〒102-8460 東京都千代田区飯田橋 3-10-10) /株式会社 KDDI 総合研究所 (〒356-8502 埼玉県ふじみ野市大原 2-1-15)

<sup>3</sup>非会員 株式会社 KDDI 総合研究所 (〒356-8502 埼玉県ふじみ野市大原 2-1-15)

<sup>4</sup>正会員 早稲田大学 理工学術院 (〒169-8555 東京都新宿区大久保 3-4-1)  
E-mail: akinori@waseda.jp

近年, ICT 機器の発展により位置情報等の様々なビッグデータが取得可能となっている. また, 従来アンケート調査を中心に組み込まれてきた交通調査は, プライバシーへの懸念や調査費用の増大を背景に, 高頻度・広範囲での実施が困難となっている. その解決策として, 従来調査を補完する形でのビッグデータを活用した交通の動態調査が注目されている. 本研究では, 位置情報ビッグデータから人工知能の手法の一つである逆強化学習を用いて人流の推計を行う. 分析の結果から, 逆強化学習モデルは従来手法と比較して少ないサンプルでより高い精度の分析が可能であり, モデルの逐次更新により推計精度が向上するという特徴が示された. さらに, 時間的・空間的に異なる対象に対しても, 従来のモデルを更新することにより高い精度で分析可能であることを示した.

**Key Words:** big data, human traffic estimation, machine learning, inverse reinforcement learning

## 1. はじめに

### (1) 研究の背景・目的

我が国では都市の骨格を形成する交通施設等の必要性及び規模に関する総合的な検討<sup>注1)</sup>を目的として, 長年にわたり都市交通調査が行われてきた. 従来の都市交通調査ではパーソントリップ調査 (以下 PT 調査) をはじめとしたアンケートによる調査が中心であった. しかしながら近年のプライバシーへの懸念や調査費用の増大を背景に, 全国における PT 調査の実施数は減少傾向<sup>注2)</sup>にあり, 新たな都市交通調査のあり方が議論されている. そこで, 近年の ICT 機器の普及により入手可能となった各種のビッグデータの活用が期待されている. ビッグデータを活用した調査は従来のアンケート調査と異なり, 基本的に常時データを取得可能であり, さらに特定の都市圏に留まらず, 全国でデータを取得可能という利点がある. また, 近年相次いで提案がなされている人工知能を用いたモデルの適用も期待される. 一方で, ビッグデータや人工知能の交通調査・分析への活用に向けた取り組みは発展の途にあり, 研究としての蓄積も十分でない.

そこで本研究では, 人工知能を用いた手法の一つである逆強化学習を用いてビッグデータであるスマートフォン位置情報データから人流推計を行う. 人流推計における逆強化学習モデルの特徴を把握すること, そして逆強化学習を用いた人流の推計における有用性と課題を明らかにすることを目的とする.

### (2) 既存研究の整理

既存研究は従来の都市交通調査の課題に関する研究, ビッグデータの都市交通調査への適用に関する研究, そして人工知能を用いた交通行動の推計に関する研究に大別される.

#### a) 従来の都市交通調査の課題に関する研究

従来広く用いられてきた PT 調査に関しては様々な課題が指摘されている. 高橋ら<sup>3)</sup>は PT 調査における回収率と調査不能理由を分析し, 有効回収率は低下傾向, 無回答の件数は増加傾向にあり, その一因として市民意識の高まりや回答の煩わしさがあると考察した. また, PT 調査の実施間隔は 10 年に 1 度程度であるが, より短い間隔での分析のために, 菊池ら<sup>2)</sup>はデータの時点更新を

行った。分析の解像度が低いという問題には越智ら<sup>3)</sup>が詳細なスケールでの OD 推計手法を開発した。さらに石神ら<sup>4)</sup>は従来の PT 調査と交通関連ビッグデータの特徴を比較・整理するとともに、今後の PT 調査の方向性としてビッグデータの活用や調査の小サンプル化、新たな需要推計手法による分析の高度化を挙げている。

従来の PT 調査には様々な課題が指摘されており、それらに対応した今後の都市交通調査のあり方が議論されている。その中でもビッグデータを活用した調査が特に注目を集めており、次項ではビッグデータを用いた都市交通調査に関する研究を整理する。

#### b) ビッグデータの都市交通調査への適用に関する研究

従来の PT 調査に代わる調査手法としてビッグデータの活用が期待されている。ICT 機器の普及により、近年は様々なビッグデータが利用可能となっており、交通関連ビッグデータの特徴を整理した研究も数多く見られる<sup>5)</sup>。また、既存の調査結果と比較したビッグデータの有効性に関する検討も様々なデータを対象として分析がなされている<sup>7)</sup>。

交通関連ビッグデータの利用可能性が高まる一方で、ビッグデータの都市交通調査への活用の際には単純集計に留まる研究が多く、交通政策の提案へとつながる推計方法を提案した研究は限定的である。

#### c) 人工知能を用いた交通行動の推計に関する研究

近年の計算処理機能の飛躍的な向上により、人工知能を用いた様々な手法が提案されている。人工知能はその計算能力の高さからビッグデータとの親和性が高いと想定される。そこで本項では人工知能を用いた交通行動の推計に関する研究を整理する。

秋山<sup>9)</sup>は機械学習を用いた交通手段選択モデルで適用可能な手法を整理し、4 段階推定法や非集計モデルといった従来の演繹的な手法と異なる、複雑な現実への複雑系としてのアプローチが有効であると指摘している。小林ら<sup>10)</sup>は人工知能を活用した自然言語処理分野で多く用いられる GPT-2 という手法により、発生集中交通量の予測を行い、提案手法が既存の手法と比較して高い精度を有することが明らかとなった。さらに、行動解析で用いられる手法の一つとして、逆強化学習がある。Kitani et al.<sup>11)</sup>は逆強化学習における即時報酬・将来報酬・目標が人間の活動形成と密接に関連しているとして、逆強化学習を用いた歩行者の移動経路推定を行った。また、Alsaleh and Sayed<sup>12)</sup>は自転車利用者の行動特性を逆強化学習を用いて定量的に評価し、既存手法よりも高い推計精度が得られることを示した。

以上のように、人工知能を活用した様々な手法が提案されており、ビッグデータの活用と併せて、都市交通調査への人工知能の活用が注目されている。特に逆強化学習は推計手法が実際の人間の行動と密接に関連しており、

人流解析における推計精度の向上が期待される。しかしながら、人工知能モデルによる推計手法を都市交通計画分野で適用した事例は限定的である。特に逆強化学習を都市交通計画分野で適用する際の利点や課題は未整理である。

#### (3) 研究の位置づけ

従来の都市交通調査で中心的な役割を担ってきた PT 調査は、回答者の意識の変化や調査コストの増大によって転換点を迎えている。同時にビッグデータや人工知能を活用した様々な手法が開発されており、新たな都市交通調査の可能性が示唆されている。一方で、実際の調査への適用に向けた、人流の分析手法に関する研究の蓄積は十分でない。そこで本研究では、人工知能を用いた手法の一つである逆強化学習を用いて、スマートフォン位置情報データから人流の推計を行う。逆強化学習を用いた人流推計モデルに関する特徴を定量的に評価することにより、逆強化学習・ビッグデータを活用した人流の推計・評価に向けた示唆を得ることに本研究の新規性と意義がある。

#### (4) 研究の概要

本研究では、人流推計への逆強化学習モデルの適用可能性を定量的に評価するため、下記の手順を採用する。

- i. 逆強化学習の概要、またモデルにおいて使用するデータの概要を整理する。
- ii. 逆強化学習モデルを構築し、従来手法との精度を比較する。
- iii. 時間的・空間的に複数のデータに適用することで、提案手法の一般性を評価する。
- iv. 逆強化学習モデルの特徴を整理し、ビッグデータと逆強化学習モデルを用いた人流推計の利点と課題を整理する。

#### (5) 対象地の概要

本研究では近年 PT 調査が実施され、またスマートフォン位置情報データを継続的に取得可能である栃木県宇都宮市を対象とする。宇都宮市は駅周辺、駅西側の中心市街地、郊外的大型商業施設周辺のように滞留が想定される地点が複数存在し、また平日と休日との人流の違いも想定される。それらの人流の違いも併せて適切に人流を推計できるかを検証する。また、空間的に異なる対象への分析においては、宇都宮市と同じ中枢核都市ながら、都市交通の形態や中心市街地の分布が異なる富山県富山市を対象とする。

## 2. 逆強化学習モデルの構築

### (1) 逆強化学習の概要

人工知能に関する研究では、特に強化学習が様々な学問分野で注目を集めている。強化学習は行動の帰結に対して評価値として報酬を与えることで最適な行動を推計する手法であり、各データに正解データを作成する必要がなく、長期的な視点での分析も可能となるため汎用性が高い。ただし、交通手段選択のように最適な状態の位置づけが明確でなく、報酬の設定が困難な対象については強化学習の適用が困難である。そこで強化学習の反復により未知の報酬を推定する手法として逆強化学習が考案された。逆強化学習では観測された行動軌跡が報酬を最大化すると仮定して最適な報酬関数を推定する。ここで報酬関数とは、観測された行動軌跡の特性を定量的に評価した各状態の報酬値の集合であり、推計された報酬関数を入力値として強化学習を行えば、入力された軌跡を概ね再現可能である。

モデルにおいては初めに、逆強化学習に入力する行動軌跡を作成する。本研究では実際の位置情報データから移動軌跡を入力値として抽出し、逆強化学習を行う。逆強化学習の学習の流れを図-1 に示す。

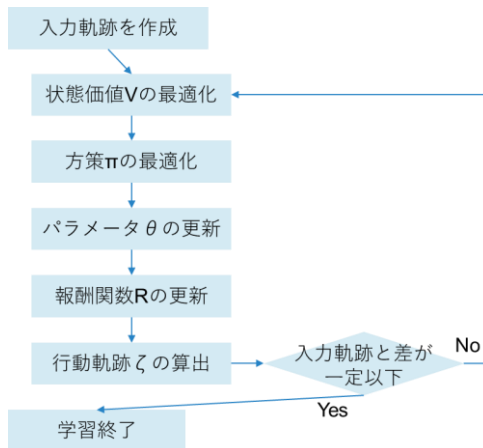


図-1 逆強化学習の学習の流れ

学習においては第一に報酬関数の初期値を設定し、初期値に基づいて各状態の報酬値である状態価値と方策の最適化を行う。最適な状態価値と方策から報酬が最大となる行動軌跡を、仮想のエージェントが離散化された状態間を連続的に移動することで推計する。その後、観測された行動軌跡と比較し、2つの行動軌跡の差が最小となるように報酬関数を更新する。

逆強化学習の反復計算には様々な手法が提案されているが、本研究では最大エントロピー法を用いる。最大エントロピー法は各状態における最適な行動が未知であっても、行動軌跡を入力すれば最適な報酬関数を算出可能であるという利点を有する。最大エントロピー法におい

ては式(1)に示すように、行動軌跡 $\zeta$ から報酬関数 $R$ を仮定し、パラメータ $\theta$ が一定値に収束するまで反復計算を行い、値を更新する。また、 $f_\xi$ は入力された行動軌跡の集合を、 $f_s$ は状態 $s$ の特徴量を表している。報酬関数 $R$ は式(1)のように各状態の報酬値の集合として表せる。

$$R(\zeta|\theta) = \theta^T f_\zeta = \sum_{s \in \zeta} \theta^T f_s \quad (1)$$

ここで反復計算においては以下の式(2)に示す対数尤度関数 $L(\theta)$ を最大化する $\theta$ を算出する。

$$L(\theta) = - \sum_i \log P(f_{\xi_i}|\theta) \quad (2)$$

また、本研究で作成するモデルでは方策 $\pi$ の最適化において $\epsilon$ -greedy法を用いる。 $\epsilon$ -greedy法では $\epsilon$  ( $0 < \epsilon < 1$ )の確率でランダムに行動を選択させ、 $(1 - \epsilon)$ の確率で状態価値から算出される行動価値関数が最大となる行動を選択する方法である。本研究では成瀬ら<sup>13)</sup>の研究に準じた逆ロジスティック曲線に基づく、式(3)の関数により試行回数 $x$ によって $\epsilon$ の値を変化させる手法も設定する。

$$\epsilon = c - \frac{c - K}{1 + e^{a-bx}} \quad (3)$$

$a = 6, \quad b = 0.00001$   
 $c(\text{上限}) = 1, \quad K(\text{下限}) = 0.5$

### (2) 用いるデータの概要

使用するデータの概要を表-1に示す。本研究で用いるスマートフォン位置情報はKDDI株式会社が顧客より同意を得た上で収集したデータである。GPS等を基にスマートフォン端末にて測位される位置情報であり、既存研究<sup>14)</sup>と同様に移動滞在判定、トリップデータの抽出、全トリップデータからの移動量推計、拡大推計の4段階の手順により推計した。集計されたトリップの分布は、既存研究<sup>15)</sup>においてPT調査と傾向が一致することが確認されている。

表-1 使用したデータの概要

対象地	栃木県宇都宮市
データの取得範囲	宇都宮駅から3km圏内
取得年月日	2016/6/1 ~ 2016/6/30
取得曜日	休日
空間解像度	250mメッシュ

移動滞在判定においては、同一地点内において15分以上の滞在が観測された際に「滞在」と判定し、その地点が次の移動の出発地となる。移動滞在判定の概要を図-2に示す。




図-2 移動滞在判定の概要




図-3 移動量の推計における各カウント数の算出方法の概要

移動量の推計においてはその地点が移動の出発地となった数である出発地カウント、その地点が移動の到着地となった数である到着地カウント数を算出する。また、当該メッシュを通過するものの 15 分以上の滞在が観測されなかった通過交通に関しては出発地カウント数、到着地カウント数ともに加算しない。ただし、同一メッシュ内の移動は出発地と目的地が同一の移動として捉え、出発地カウント数と到着地カウント数をとともに 1 だけ増加させる。したがって、出発地カウント数、到着地カウント数は従来の発生量、集中量に加えて、当該地点での滞留量も含まれた値となる。移動量の推計における各カウント数の算出方法の概要を図-3 に示す。

### (3) モデルの構築

逆強化学習を用いて位置情報データから人流の推計を行った。構築したモデルでは、逆強化学習によりメッシュごとの報酬値を推計しており、これを「状態価値」として定義する。モデルでは状態の特徴量  $f_s$  は式(4)の通り、各状態の部分のみが 1 となる one-hot ベクトルの形式で設定している。ここで  $s$  は、250m メッシュコードで表現されたエージェントの離散的な位置を示す。

$$f_s[s'] = \begin{cases} 1 & \text{if } s' = s \\ 0 & \text{otherwise} \end{cases} \quad (4)$$

学習においては仮想のエージェントがモデル空間上で定義された 250m メッシュを移動することにより報酬関数を推計する。エージェントは東西南北いずれかに隣接するメッシュへ移動するという行動を繰り返して行動軌跡を生成する。モデルの流れは以下の通りである。

- i. トリップデータから出発地メッシュと到着地メッシュを取得し、それぞれモデル空間上のメッシュ番号に変換
- ii. 一定の割合で乱数的にトリップ（行動軌跡）を抽出
- iii. 抽出したトリップを入力として逆強化学習により報酬関数を推計し、各メッシュの状態価値を算出
- iv. 推計した状態価値と観測値との相関及びモデルの適合度を比較することにより精度検証

## 3. 逆強化学習を用いた人流推計モデルによる分析

### (1) 人流の推計結果

トリップデータから集計したメッシュごとの到着地カウント数（集中量及び滞留量）は図-4 の通りであった。宇都宮駅西側の中心市街地付近や駅東側の大型ショッピングセンターのある地点でカウント数が多くなっており、実際の人流の特性を概ね評価できていると考えられる。

続いて、トリップデータから抽出した 0.1% のトリップを入力軌跡として逆強化学習を行った。推計値を図-5 に示す。

カウント数が多い部分と状態価値の高い部分を比較すると、全体としてはカウント数とほぼ同様の分布となっていることが確認できる。また、カウント数が高い地点の周囲も状態価値が若干高くなっており、人流が多い地点の周囲も人流が多くなるという、単純集計では捉えられない人流分布の波及的影響も含めて再現できたと考えられる。

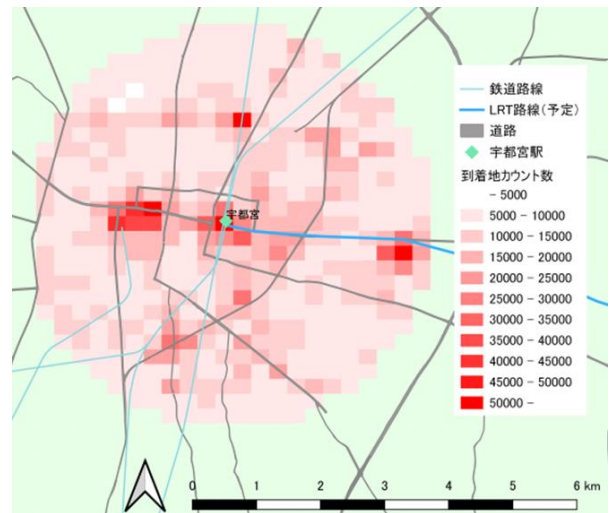


図-4 各メッシュの到着地カウント数の分布

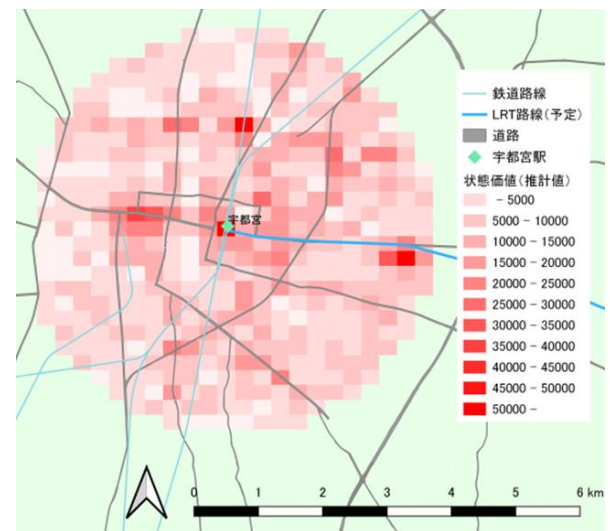


図-5 推計された状態価値の分布

(2) 推計精度に関する分析

観測値の大小と推計した状態値の大小とで高い相関があった場合、そしてモデルの適合度が高い場合にはモデルによって人流を推計できたといえる。そこで推計した状態値と観測値との相関係数の2乗により算出される決定係数を比較することで精度検証を行った。表-2に示すように複数のモデルを作成して分析を行った結果、入力値を逐次的に変化させてモデルを更新する更新有モデルの方が、入力値は一定でモデルの更新を行わない更新無モデルよりも精度が高く、さらに関数化したε-greedy法を用いた手法が最も高精度で推計できることが明らかとなった。また、関数化したε-greedy法を用いた手法は学習時間が短かったことから反復計算がより早く収束していると想定される。

表-2 各モデルの決定係数と学習時間の比較

モデル	モデル概要	決定係数	学習時間(時間)
0	更新無モデル	0.443	15.3
1	更新有モデル	0.608	15.1
	ε-greedy法を使用 (ε = 0.2)		
2	更新有モデル	0.564	15.1
	ε-greedy法を使用 (ε = 0.5)		
3	更新有モデル	0.673	8.4
	ε-greedy法を使用 $\epsilon = c - \frac{c-K}{1+e^{a-b \text{ episode}}}$ (関数)		
4	更新有モデル 確率的に状態値を初期化して更新	0.502	15.6
5	更新有モデル 更新時に状態値の低い状態のみ初期化	0.561	15.6

そこで、精度検証では決定係数が最も高く、かつ学習時間が最も短い表-2のモデル3を用いて検証を行った。データの抽出率ごとのモデルの決定係数の遷移を図-6に示す。

併せて、トリップデータをサンプル率を変化させて抽出し、それぞれ到着地カウント数を単純集計した際の相関係数の変化も算出した。その結果を図-7に示す。分析の結果より、単純集計の場合(図-7)と比較して、逆強化学習モデル(図-6)は少ないサンプル数でも高い精度で分析が可能であることが示された。

本章1節でも考察したように、逆強化学習モデルは作成したモデル空間内の離散化されたメッシュをエージェントが連続的に移動するという実際の人流と類似した形で推計を行うため、人流の集中する地点の周囲も人流が多くなるという空間的に連続した波及の影響を適切に考慮できたと考えられる。

今回サンプルとして用いたトリップデータに関しても実際の移動から一部を抽出したものであるため、サンプルから元となる人流を推計するには逆強化学習モデルの適用が有効であると考えられる。




図-6 逆強化学習モデルにおけるサンプル率ごとの決定係数

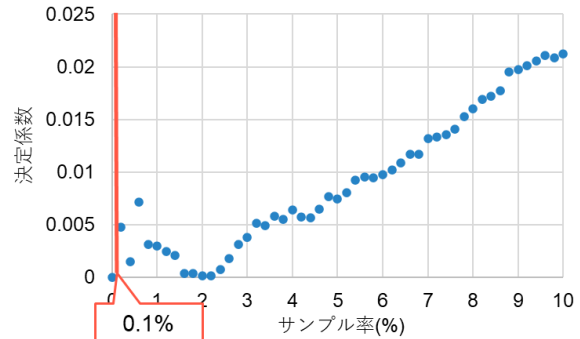


図-7 単純集計におけるサンプル率ごとの決定係数

(3) 異なる時空間へのモデルの適用に関する分析

本節では、提案手法の一般性を示すため、時間的・空間的に異なるデータに提案手法を適用し、前節と同様に決定係数を用いた精度検証を行った。推計の精度が高いならばその対象に対して適用可能であるといえる。

初めに空間的には同一だが、時間的に異なる対象に対して提案手法を適用し、それぞれの場合において精度検証を行う。分析対象は前章と同じく、宇都宮駅から3km圏内の2016年6月(平日)・2017年6月(平日・休日)・2018年6月の(平日・休日)、計5種類のデータである。それぞれの分析結果を表-3に示す。

表-3 時間的に異なる対象への分析結果

分析対象(空間)	分析対象(時間)	決定係数	学習時間(h)
宇都宮駅から3km圏	2016年6月休日	0.673	8.4
	2016年6月平日	0.550	42.0
	2017年6月休日	0.602	8.7
	2017年6月平日	0.510	18.0
	2018年6月平日	0.554	40.6

また、空間的に異なる地域における提案手法の性能を検証するために、宇都宮市とは異なる都市に対して分析を行った。富山県富山市を対象として、富山駅から3km圏内のデータを入力として分析を行った。ここで、データ取得の関係上、富山市のデータは2020年3月となっている。取得したデータを平日・休日に分割し、それぞれ

に対して分析を行った。2020年3月平日の富山市におけるカウント数の分布を図-8に、推計された状態価値の分布を図-9に示す。

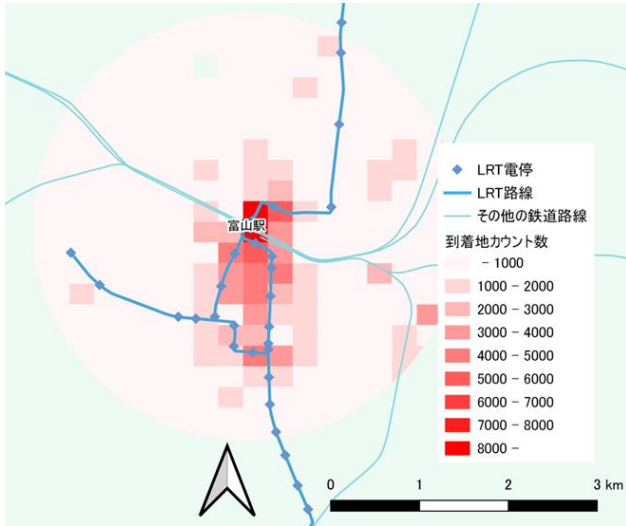


図-8 富山における各メッシュの到着地カウント数の分布

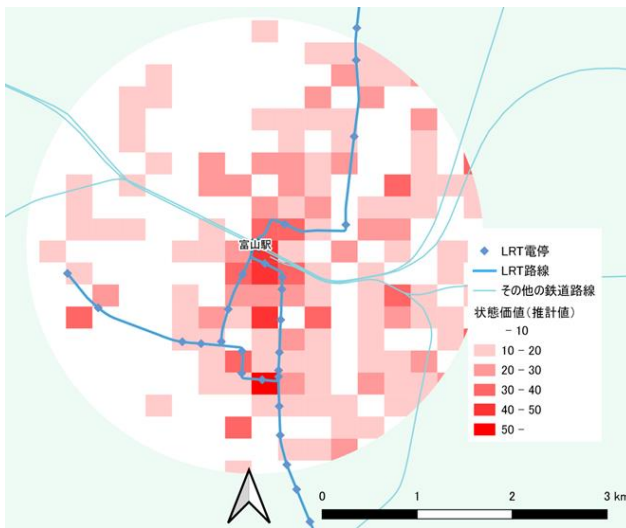


図-9 富山における推計された状態価値の分布

到着地カウント数の分布と状態価値の分布を比較すると、宇都宮市の場合と同様にカウント数が多い部分がある程度推計できていることが示された。また、カウント数の多い中心部とカウント数が多いメッシュの見られる郊外部の間の地域には、状態価値が若干高く推計されており、波及的な影響を示していると想定される。なお、富山市のデータでは拡大推計を行っておらず、各トリップを集計した量が宇都宮市を対象としたモデルよりも非常に少なくなっているため、逆強化学習の際には全トリップデータの1%を乱数的に抽出し、推計を行っている。決定係数を用いた精度検証の結果を表-4に示す。

表-4 時間的・空間的に異なる対象への分析結果

分析対象 (空間)	分析対象 (時間)	決定係数	学習時間(h)
宇都宮駅から3km圏	2016年6月休日	0.673	8.4
	2016年6月平日	0.550	42.0
富山駅から3km圏	2020年3月休日	0.473	5.7
	2020年3月平日	0.520	6.1

いずれのモデルでも決定係数が0.5程度となっており、比較的高い精度で推計できていることがわかる。あくまで2都市での評価に留まるものの、本分析の結果から、構築した逆強化学習モデルが時間的・空間的に異なる対象へも一定程度の推計精度で分析可能であることが示された。

#### 4. 逆強化学習を活用した人流推計に関する検討

本章では、ビッグデータであるスマートフォン位置情報データと逆強化学習モデルを活用した人流推計手法について、利点と欠点をそれぞれ整理する。

##### (1) 逆強化学習を活用した推計の利点

逆強化学習モデルの利点としては以下の3点が想定される。

- ・モデルの逐次的な更新が可能
- ・少数サンプルで高精度な推計が可能
- ・時間的・空間的に異なる分析対象にも適用可能

1点目のモデルの更新に関しては3章で示した通り、モデルへの入力値を変えてモデルを更新することにより、推計精度が高まることを指す。常時取得されるビッグデータに対して、逐次的に分析を行うことが可能であり、社会や地域の変化を即時的に分析結果へと反映させることが可能である。また、ビッグデータ、特にスマートフォン位置情報データにはリアルタイム性という特徴があり、災害や大規模イベントによる1日や数時間といった短期的な人流の変化を取得可能である。一方で、短期的な影響を推定する場合、得られるデータ量は限定的であり、従来手法ではサンプリングによる誤差が発生する可能性がある。この課題は観測されるデータ量が少ない地方においては特に顕著である。そこで2点目の利点から、比較的少数のサンプルにより分析することが可能な逆強化学習モデルが有効であると想定される。また、3章3節で検討したモデルの適用可能性に関する評価から、異なる時点や異なる地域に対してもモデルは高い精度で推計可能であることが示唆された。常時観測可能であり、地域的な制約のない位置情報データのようなビッグデー

タを活用する際には、この 3 点目の利点が有効となり、アンケート調査では調査実施範囲に限定されていた推計の範囲をより広範にとることができると考えられる。

## (2) 逆強化学習を活用した調査の欠点

前節では逆強化学習を活用した調査の利点を整理したが、本節では欠点を整理する。欠点としては以下の 2 点が挙げられる。

- ・内部計算のブラックボックス化
- ・分析コストの増大

1 点目は人工知能を用いる場合の多くで問題となる点である。分析の内部が一部ブラックボックス化しており、推計結果に関する妥当性の評価が困難となる場合がある。また、日々新たな手法が提案されている人工知能分野において、逆強化学習でも同様により複雑なモデル体系となっている手法も数多く開発されている。その際には、この課題点がより表面化することも想定され、可能な限りモデルの内部計算に関する不明点を削減することが望まれる。

前節で 2 つ目の利点では分析コストが低減されると述べたが、分析の対象範囲を増大させた場合、分析コストは必然的に増大する。従来の四段階推定法や非集計モデルはモデルの構築に際しては一部で困難を伴うものの、計算自体は比較的単純であり、これまでの知見の蓄積も踏まえると分析コスト自体は大きくはない。分析コストの増大という課題に対処するには、分析目的・内容に合わせたモデルの簡易化、また従来手法と同様に、モデル構築に係るコストの削減のために研究のさらなる蓄積が期待される。

## 5. まとめ

### (1) 得られた知見

本研究では新たな人流推計の手法として逆強化学習に着目し、特徴の整理と人流推計への活用の際の利点と欠点を整理した。逆強化学習はモデルの更新が可能であり、少数のサンプルから高い精度で推計可能であることが示された。また、宇都宮市と富山市の時間的・空間的に異なる地点を対象とした分析ではどの場合にも比較的高い精度で推計できることが示された。今後の人流推計へのビッグデータの活用の際には、常時取得可能であり、地域的制約が少ないという特徴を有するビッグデータに対して、逆強化学習は親和性が高く、有効な分析手法となると考えられる。一方で、内部計算のブラックボックス化や分析コストの増大といった欠点も存在し、実調査への適用に向けてはさらなる知見の蓄積が必要となるだろう。

### (2) 今後の課題

前章 2 節で示した課題に対応して、逆強化学習モデルの適用可能性・転用性に関するさらなる分析が必要となる。また、簡易的な推計手法、Neural Network 等を活用した新たな分析手法の活用も期待される。都市交通調査への活用の際には、推計値を活用した交通手段選択や、より詳細なレベルでの移動経路推定といった手法の開発も必要であり、今後の研究課題である。

## NOTES

注1) 新たな都市交通調査体系のあり方に関する検討委員会：デジタル社会に対応した新しい都市交通調査体系の実現に向けて—新たな都市交通調査体系のあり方に関する検討会 中間とりまとめ—, 2022.

## REFERENCES

- 1) 高橋勝美, 平見憲司, 森尾淳, 西野仁: 我が国のパーソントリップ調査の無回答状況とその要因に関する考察, 土木計画学研究・講演集, Vol.39, No.283, 2009. [Takahashi, K., Hirami, K., Morio, J., Nishino, H.: Non-response in person-trip survey in japan, *Proceedings of infrastructure planning*, Vol. 39, No. 283, 2009.]
- 2) 菊池雅彦, 岩館慶多, 羽藤英二, 茂木渉, 加藤昌樹: 交通ビッグデータによる実用的な都市圏 PT 調査マスターデータの時点更新, 土木学会論文集 D3, Vol. 74, No. 5, I\_667-I\_676, 2018. [Kikuchi, M., Iwadate, K., Hato, E., Mogi, W., and Kato, M.: Practical method to update master data of parson trip survey in metropolitan areas using the transportation big data, *Journal of JSCE (D3)*, Vol. 74, No. 5, I\_667-I\_676, 2018.]
- 3) 越智健吾, 関信郎, 岩館慶多, 石神孝裕, 若井太亮, 石井良治, 杉田溪: PT 調査データとビッグデータを用いた実務的な詳細スケール目的別手段別 OD 表の作成手法, 土木学会論文集 D3 (土木計画学), Vol.75, No.5, I\_709-I\_717, 2019. [Ochi, K., Seki, N., Iwadate, K., Ishigami, T., Wakai, R., Ishii, R., and Sugita, K., Practical method to estimate od table in detailed zone unit using person trip survey data and traffic-related big data, *Journal of JSCE (D3)*, Vol.75, No.5, I\_709-I\_717, 2019.]
- 4) 石神孝裕, 菊池雅彦, 井上直, 岩館慶多, 森尾淳, 石井良治: 都市交通の実務からみた交通関連ビッグデータに対する期待と課題, 土木計画学研究・講演集, Vol.55, 2017. [Ishigami, T., Kikuchi, T., Inoue, T., Iwadate, K., Morio, J., Ishii, R.: Expectations and problems of traffic-related big data from a standpoint of urban transport practical work, *Proceedings of infrastructure planning*, Vol.55, 2017.]
- 5) 井上直・石神孝裕・石井良治・中野敦・菊池雅彦・前川敦: 交通関連ビッグデータを踏まえた総合都市交通体系調査のあり方, 土木計画学研究発表会・講演集, Vol.53, No.15-10, pp.2142-2148, 2016. [Inoue, T., Ishigami, T., Ishii, R., Nakano, A., Kikuchi, M., and Maekawa, A.: A concept of travel survey based on travel-related big data, *Proceedings of infrastructure planning*, Vol.53, No.15-10, pp.2142-2148, 2016.]
- 6) 石井良治, 新階寛恭, 関谷浩孝, 池田大造, 永田智

- 大, 森尾淳, 柴崎亮介, 関本義秀, 今井龍一: 携帯電話網の運用データに基づく人口流動統計におけるトリップデータ取得精度の向上に関する研究, 土木計画学研究発表会・講演集, Vol.55, 2017. [Ishii, R., Shingai, H., Sekiya, H., Ikeda, D., Nagata, T., Morio, J., Shibasaki, R., Sekimoto, Y., Imai, R.: A study about the improvement possibility of person-trip survey technique with mobile spatial dynamics, *Proceedings of infrastructure planning*, Vol.55, 2017.]
- 7) 森尾淳, 牧村和彦, 山口高康, 池田大造, 西野仁, 藤岡啓太郎, 今井龍一: 東京都圏におけるモバイル空間統計とパーソントリップ調査の比較分析-都市交通分野への適用に向けて, 土木計画学研究発表会・講演集, Vol.52, 2015. [Morio, J., Makimura, K., Yamaguchi, T., Fujioka, K., Imai, R.: Analysis of comparison between mobile spatial statistics and person trip survey in tokyo metropolitan area, *Proceedings of infrastructure planning*, Vol. 52, 2015.]
- 8) 澤田茜, 小原拓也, 佐々木邦明: アクティビティモデルとモバイル空間統計を用いた都市圏 OD 推計の可能性, 土木計画学研究・講演集, vol.55, 2017. [Sawada, A., Kohara, T., Sasaki, K.: The estimation of od matrix by the assimilation of activity based model and mobile-based population, *Proceedings of infrastructure planning*, Vol. 55, 2017.]
- 9) 秋山孝正: 知的情報処理を利用した交通行動分析, 土木学会論文集, No. 2001, Vol. 688, p. 37-47, 2001. [Akiyama, T.: Travel behaviour analysis with intelligent information processing, *Proceedings of JSCE*, No. 2001, Vol. 688, p. 37-47, 2001.]
- 10) 小林亮博, 上坂大輔, 武田直人, 南川敦宣, 森本章倫: 「GPT-2 を用いた位置情報ビッグデータに基づく交通需要推定技術」, 土木計画学研究発表会・講演集, Vol.65, 2021. [Kobayashi, A., Kamisaka, D., Takeda, N., and Morimoto A., :Traffic demand generation technology using location-based big data, *Proceedings of infrastructure planning*, Vol. 65, 2021.]
- 11) K.M. Kitani, B.D. Ziebart, J.A. Bagnell, M. Hebert : Activity forecasting, *Proceedings of the 12<sup>th</sup> European Conference on Computer Vision*, Volume Part IV, ECCV12, Springer-Verlag, Berlin, Heidelberg, 2012, pp. 201-214.
- 12) Alsaleh, R., Sayed, T.: Microscopic modeling of cyclists interactions with pedestrians in shared spaces: a Gaussian process inverse reinforcement learning approach, *Transportmetrica A: Transport Science*, 1-27, 2021.
- 13) 成瀬拓海, 山脇正嗣, 寺奥淳, 森本章倫: Q 学習を活用した最適な交通取締り活動の実施場所の予測に関する研究, 交通工学論文集, Vol 8, No.2, pp.232-239, 2022. [Naruse, T., Yamawaki, M., Teraoku, J., Morimoto, A.:A study on prediction of optimal location for traffic enforcement using q-learning. *Journal of Traffic Engineering*, Vol. 8, No. 2, p.232-239, 2022.]
- 14) 石井良治, 末成浩嗣, 越智健吾, 関信郎, 大塚賢太, 酒井幸輝, 會田優磨, 南川敦宣: 携帯電話 GPS ビッグデータの都市交通分野における活用に向けた信頼性検証, 土木計画学研究・講演集, Vol. 58, 2018. [Ishii, R., Suenari, K., Ochi, K., Seki, N., Otsuka, K., Sakai, K., Aida, Y., Minamikawa, A.: Reliability verification of cell phone gps big data for use in the urban transportation field, *Proceedings of infrastructure planning*, Vol. 58, 2018.]
- 15) 小林直, 石塚宏紀, 南川敦宣, 村松茂樹, 小野智弘: 携帯電話通信履歴に適した移動滞在状態推定手法の提案, 情報処理学会論文誌, Vol. 10, No. 1, pp. 13-23, 2017. [Kobayashi, N., Ishizuka, H., Minamikawa, A., Muramatsu, S., Ono, C.: An estimation of human moving patterns for call detail records, *Journal of Information Processing*, Vol. 10, No. 1, p. 13-23, 2017. ]

(Received July 15, 2022)

(Accepted August 29, 2022)

## STUDY ON ESTIMATING HUMAN TRAFFIC USING INVERSE REINFORCEMENT LEARNING

Tomohiro OKUBO, Akihiro KOBAYASHI, Daisuke KAMISAKA  
and Akinori MORIMOTO

In recent years, the development of ICT devices has made it possible to acquire a variety of big data such as location information. In addition, traffic surveys, which have traditionally focused on questionnaire surveys, have become difficult to conduct at high frequency and over a wide area due to concerns about privacy and increased survey costs. As a solution to this problem, traffic dynamics surveys utilizing big data are attracting attention as a complement to conventional surveys. In this study, we estimate human flow from location-based big data using inverse reinforcement learning, which is one of the methods of artificial intelligence. The analysis results show that the inverse reinforcement learning model can perform more accurate analysis with fewer samples than conventional methods, and that the sequential updating of the model improves the accuracy of the estimation. Furthermore, it was shown that the inverse reinforcement learning model can be used to analyze objects that differ temporally and spatially with high accuracy by updating the conventional model.