

生活行動調査の自動化に関する基礎的研究

～プローブパーソンデータによる起終点と手段の自動判別手法の構築に向けて～

A Study of Identification Method of Origin-Destination and Modal Sprit for Improving Probe Person Survey by Smartphone

矢部 努* 若井亮太** 及川 潤*** 北村清州** 廣川和希**** 福沢綾乃***** 牧村和彦*****

By Tsutomu YABE, Ryota WAKAI, Jun OIKAWA, Seishu KITAMURA, Kazuki HIROKAWA, Ayano FUKUZAWA and Kazuhiko MAKIMURA

1. はじめに

近年、人口減少や高齢化など社会経済情勢の変化や、個人の価値観の多様化や環境に対する意識が高まり、生活行動や移動ニーズも多様化している。一方で、道路をはじめとした社会基盤をつくる時代から効率的に賢く使う時代へと移行していく中、詳細な交通データを活用したきめ細かな交通実態の把握、施策評価・モニタリングを行う必要性が高まっている。

これまで、都市圏レベルの生活行動の把握にはパーソントリップ調査（以下 PT 調査）が実施されてきており、移動目的や手段などの行動特性や性別年齢等の個人属性に基づく分析結果を踏まえて、様々な施策検討に活用されてきている。しかしながら、PT 調査は、ある特定の 1 日に限定した調査である点や実施頻度が概ね 10 年に 1 度である点など、多様化するニーズに対応したきめ細かな施策検討やその評価・モニタリングの観点においては、パーソントリップ調査結果だけでは十分とはいえ、個人の生活行動を詳細かつ継続的に把握する調査手法の必要性が指摘されている¹⁾。

また、個人の生活行動を把握するための調査手法として、携帯端末を活用したプローブパーソン調査（以下、PP 調査）が開発されている。PP 調査では、携帯端末に搭載された GPS や加速度センサにより収集された移動履歴データに基づき、これまで PT 調査では取得できなかった移動経路や詳細な時刻などの把握が可能である^{1), 2), 3)}。さらには、近年のスマートフォンの普及に伴い、一般の被験者が個人で保有するスマートフォンを利用した PP 調査が試行されている^{4), 5)}。

従来の PP 調査では、調査用の GPS 機能付き携

帯電話などを被験者に貸与して実施する 경우가多く、調査実施上の課題となっていた。一方、スマートフォンを利用した PP 調査は、調査用に作成したアプリ（以下、PP 調査アプリ）をインターネット経由で配布するものであり、調査用の機器を調査実施主体が準備する必要がなく、調査機器の配布や説明などのために被験者に直接接触する手間が軽減される。被験者にとっては、自分のスマートフォン上で PP 調査アプリを起動することで手軽に調査に参加できることから、スマートフォンを活用した PP 調査は、これまで実施が困難であった大規模調査を効率的に実施可能であり、特定の時期を対象とした調査や継続的なデータ収集が可能な調査手法として期待されている。

PP 調査アプリの操作方法の概要を図-1に示す。具体的には、被験者は「出発・到着時」と「移動手段の変更時」に移動手段および移動目的を PP 調査アプリ上で入力する。同時に、スマートフォンに内蔵されたセンサにより緯度・経度データや加速度データなどの移動履歴データが自動的に収集され、これらのデータが定期的に管理用サーバに送信・蓄積される仕組みとなっている。




図-1 PP 調査アプリの操作の流れ

ところで、PP 調査を実施する上で、実務上の課題がいくつか指摘されている。例えば、被験者の操

*社会基盤計画研究室長 博士(工学) **社会基盤計画研究室 主任研究員 ***社会基盤計画研究室 研究員

****社会基盤計画研究室 研究助手 *****社会基盤計画研究室 専門情報員 *****次長 博士(工学)

作忘れや操作ミス、操作タイミングのずれ（例：実際の出発・到着・乗換のタイミングから遅れて操作）などが発生し、被験者が入力した情報と自動的に収集した移動履歴データが整合しない点などが挙げられる⁵⁾。これらの課題に対応して、PP 調査アプリに操作忘れ防止のリマインド機能を付けたり、被験者に対して事前に十分な説明を行ったりするなどの対応が考えられるが、調査実施主体の負担が大きく、調査の効率性も低下することが懸念される。スマートフォンを活用した PP 調査の効率性などを担保しつつ、より信頼性の高いデータを収集するためには、被験者によるアプリの操作を最小限にし、被験者の負担を軽減することが必要である。具体的には、被験者に PP 調査アプリの起動・終了以外の操作をさせることなく、自動的に収集された移動履歴に基づき、生活行動における移動の起終点や移動手段を自動判別することが有効であると考えられる。

そこで本稿では、PP 調査アプリを活用した生活行動調査の自動化に向けて、PP 調査アプリから取得される移動履歴データによる移動の起終点と移動手段の自動判別手法の構築に向けた検証を行い、検証結果を踏まえた手法の有効性を考察した。

2. 既往研究と本稿の位置づけ

(1) 関連する既往研究

ここでは、携帯端末などに搭載されたセンサーにより自動取得される移動履歴データを用いた移動手段の判別方法に着目して、関連既往研究を整理する。

前司ら⁶⁾は、GPS 機能付き携帯端末で収集された緯度・経度データのみから移動手段を判別する手法を開発している。山崎ら⁷⁾は、加速度データのみから、停止している状態も含めた移動状態を判別する手法を提案している。また、センサデータから得られる移動手段毎の特徴をもとに、機械学習アプローチで用いられるアルゴリズムの適用を行った例が複数ある。さらに、羽藤ら⁸⁾は、判別された移動手段の並びを解釈可能なものに補正するため、隠れマルコフモデル (HMM: Hidden Markov Model) などの確率モデルを組み込んだ手法を開発している。

(2) 本稿の位置づけ

移動手段判別手法に関連する既往研究では、複数

の被験者に対し規格が同じ調査機器を貸与する方法が用いられているため、理想的な条件下での検証結果となっている。一方、個人が保有するスマートフォンには様々な機種が存在し、携帯方法もポケットやカバンの中など個人により異なるとともに、通信状況やセンサの特性により得られるデータの特性も一様ではない点に留意する必要がある。つまり、機種や携帯方法が多様な状況で得られた移動履歴データによる移動手段判別は、教師データに大きく依存する機械学習アプローチでは十分な判別精度が得られないことが想定される。

本稿では、PP 調査の実務展開を想定し、様々なスマートフォンを保有する被験者から収集された移動履歴データを想定した汎用的な手段判別方法を検討するものである。具体的な判別手順として、移動履歴データのうち、加速度波形の特徴により徒歩と自転車を判別した上で、緯度・経度データの特徴により自動車、バス、鉄道を推定する 1 次判別を実施する。その後、1 次判別の結果を踏まえて、隠れマルコフモデルを適用して確率的に最も尤もらしい移動手段の並びを推定するための調整を行い、最終的に移動手段を決定する手法を提案する。

3. 分析データの概要

(1) PP 調査の実施概要

本稿では、平成 25 年 11 月（計 30 日間）につくば市を対象に実施された PP 調査⁵⁾ データを利用する（以下、本調査）。調査主体は、国土交通省国土技術政策総合研究所であり、つくば市および筑波大学との協働により実施されたものである。被験者は、主としてつくば市居住者およびつくば市への通勤・通学者のうち調査協力が得られた 138 名であり、男女比は概ね 2 : 1、年齢階層は、主として 20 代から 50 代の構成である。

(2) PP 調査の調査項目

一般的な PT 調査と同様に、移動目的、移動手段別のトリップを取得することを目的として、本調査で取得するデータは表-1 のように設定されている。本調査で利用した PP 調査アプリは Android 版のみであったため、被験者は Android OS 搭載のスマートフォン利用者に限定されている。

表-1 本調査 (PP 調査) で取得するデータ

項目	収集データ	取得方法
被験者回答 (被験者が操作)	・性別 ・年齢	調査参加登録時
	・移動目的 ・移動手段 ・出発、到着、乗換時刻	PP 調査アプリ
移動履歴データ (自動取得)	・緯度・経度 (1 秒毎) ・三軸加速度 (30Hz)	

(3) 分析に用いるデータの概要

本調査の実施期間中に収集されたデータは、延べ 1,399 人日 (平日: 延べ 1,057 人日、休日: 延べ 342 人日) であり、全トリップ (リンクトリップ) 数は、合計 3,463 トリップである。1 日の平均トリップ数 (ネット生成原単位) は、平日が 2.36 トリップ/人日、休日が 2.83 トリップ/人日であり、平日の値は、平成 20 年に実施された東京都市圏 PT 調査に基づく茨城県南部の平均トリップ数 (2.82 トリップ/人日) と比較して少なくなっている。これは、PP 調査アプリの操作忘れや調査途中でのバッテリー切れなどによってトリップが記録されていないことなどが影響している可能性がある。

なお本稿では、上記データのうち、つくば市及び隣接市町の一部 (つくば市を包含する 2 次メッシュ 12 個分の範囲) で取得された約 2,600 トリップの移動履歴データを対象に、起終点および移動手段の判別を行った。

4. 移動の起終点の判別

(1) 移動の起終点の判別手法

GPS から得られた緯度・経度データと時刻情報からトリップの起終点を判別する方法として、人が一定時間同じ場所に滞留していると判別した地点を前のトリップの終点、かつ次のトリップの起点として判別する方法が考えられる。このとき、緯度・経度データには測位誤差が生じるため、図-2 に示すように、滞留の判別には「一定の半径」の円を定め、その円の中に「一定の時間」の位置情報が全て入っていることを条件とすることが必要となる。具体的には、以下の考え方を適用した。

＜緯度・経度データに基づく起終点判別方法＞

- 1) 全ての点で最も時間が早い点【図-2 の [1]】を基準点とし、基準点から「一定の半径」にある点を同一集合 (滞留点) と設定する。
- 2) 「一定の半径」の外にはずれたときは移動を開始したとして、そのうち最も時間が早い点【同 [6]】を次の基準点とし、1) と同様の条件で次の同一集合を設定する。
- 3) 同一集合の基準点から最終点までが「一定の時間」以内であれば移動中、それ以上であれば滞留とみなし、滞留と判定された同一集合の基準点【同 [11]】をトリップ①の終点かつトリップ②の起点とみなす。

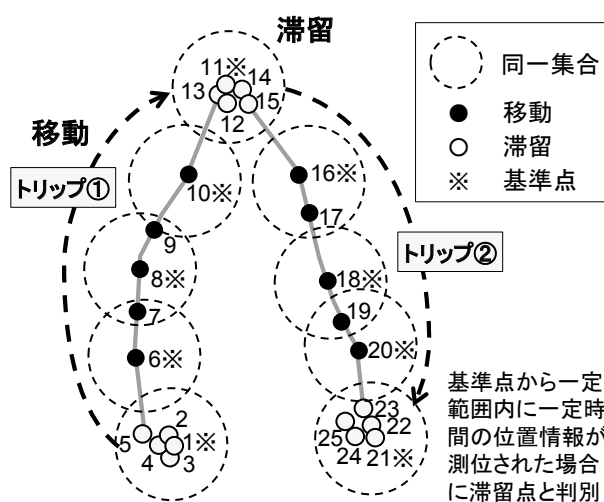


図-2 起終点判別のイメージ

(2) 移動の起終点判別の条件設定

前述の考え方にに基づき、距離条件 (同一集合 = 同一地点における滞留と判別する半径) と時間条件 (滞留とみなす時間) に関して、距離条件を 10m ~ 100m (10m 刻み)、時間条件を 5 分 ~ 30 分 (5 分刻み) でそれぞれ変化させ、調査結果を用いた感度分析を行った。

この結果、距離条件については、10m ~ 20m でやや原単位が小さくなる (トリップが切れなくなる) 影響が見受けられるが、30m ~ 100m の範囲では原単位への影響はほぼ見られないことから、距離条件は原単位にはほぼ影響を与えておらず、時間条件のみが影響していると考えられる。一方、時間条件については、20 分と設定した場合に、起終点判別結果に基づく 1 日当たりのトリップ数分布 (サンプルの累積相対度数分布) が被験者の回答トリップ数の分布と最も整合することが分かった (図-3)。




図-3 時間条件別サンプルの累積相対度数

以上示したように、距離条件一定のもとで、時間条件を大きくすると、短時間の立ち寄り行動などが判別できなくなる一方で、時間条件を小さくすると、電車やバスの乗り換えや待ち時間など移動中であっても、一定の半径内で測位された場合には滞留と判別され、結果としてトリップ数が過大となる。したがって、起終点判別の時間条件は、分析目的や地域特性を踏まえて設定することが望ましいと考える。本稿では、被験者の回答値にもっとも近い判別基準として、「距離条件：50m」、「時間条件：20分」と設定した。

5. 移動手段の判別

(1) 移動手段の判別手法

本稿で検討した移動手段の判別方法の考え方を図-4に示す。まず1次判別として、前述の起終点判別で抽出されたトリップ毎に、移動履歴データを10秒間のユニットに分割し、移動中の加速度データと緯度・経度データを用いて徒歩、自転車、自動車、バス、鉄道の5つの移動手段を判別した。具体的には、加速度波形の特徴に着目して徒歩と自転車を判別した後、残りのユニットをブロックに統合し、移動経路（右左折の程度と鉄道・バスNWとの重複率）に着目して自動車、バス、鉄道を判別した。次に、1次判別された各ユニットの移動手段を用いて、隠れマルコフモデル（HMM）により最も尤もらしい移動手段の並びを推定した（2次判別）。その際、現実的にありえない移動手段の並びは調整され、1次判別で不明となったユニットにはいずれかの手段を割り当てられることになる。

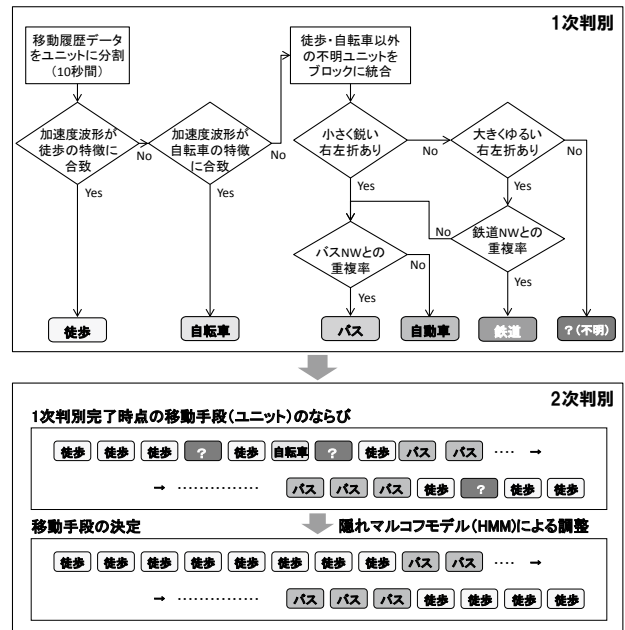


図-4 移動手段の判別方法の考え方

(2) 1次判別条件の検討

1次判別条件の検討においては、真の移動手段が明らかである移動履歴データが必要であるため、本調査で用いるデータとは別に、筆者らが予め別途収集した移動履歴データを検討用データとして用いた。なお、加速度データは、移動中のスマートフォンの向きが不明であるため、三軸加速度の合成加速度を用いた。

a) 徒歩および自転車の判別条件の検討

徒歩の典型的な加速度波形は、図-5に示すように10秒間あたりに概ね15～20回のピーク（着地）が現れるが、1歩の中にはごく短時間の揺れ（ノイズ）が多く発生することから、より加速度波形の特徴を際立たせるため、加速度の5点移動平均を用いて検討を行うこととした。徒歩の判別方法は、万歩計の仕組みと同じ要領を適用して、各ユニットの加速度の平均値との差に着目し、平均との差が閾値（絶対値）以上となる加速度が5回以上検出された場合に徒歩と判別した。10秒間に5回以上とした理由は、スマートフォンを落とした時などの突発的な衝撃を除外するためである。なお、検討用データを用いて閾値を $\pm 1.0\text{m/s}^2$ 、 $\pm 2.0\text{m/s}^2$ 、 $\pm 3.0\text{m/s}^2$ と変化させて判別した結果、表-2に示す通り、 $\pm 2.0\text{m/s}^2$ としたときに徒歩と自転車との差異が明確になったため、これを徒歩の判別基準とした。




図-5 徒歩移動の加速度波形




図-6 ±1m/s²以上の振動の出現回数

表-2 閾値別判別結果(徒歩と判別される割合)

閾値 (m/s ²)	徒歩と判別される割合(%)				
	徒歩	自転車	自動車	バス	鉄道
1.0	84.7	47.2	3.0	7.6	7.0
2.0	77.6	13.0	2.1	5.4	5.9
3.0	59.1	4.9	1.1	2.3	3.4

自転車の加速度波形は、徒歩ほどではないものの、自動車や鉄道など他の移動手段と比較して振幅が大きく、細かな揺れが高頻度で見られる。そこで、合成加速度の平均値との差が1.0m/s²以上の細かい揺れの出現回数をカウントし、ある一定の閾値を超える場合を自転車と判別することとした。また、正常に緯度・経度データが取得されていれば、自転車では、自動車やバス、鉄道のような高速度での移動は生じないことから、ユニットの速度が20km/h未満であることも条件とした。

検討用データを用いて、自転車と自動車のユニット内における合成加速度の平均値との差が1m/s²以上となる加速度の出現回数を集計した(図-6)。このとき、平均値との差が1m/s²以上の細かい揺れの出現回数は、自動車では20回未満の割合が多く、100回以上の揺れはごくわずかであるのに対し、自転車の場合は120回~140回をピークとした分布を示している。この結果を踏まえ、自動車を自転車に誤判定せず、自転車である可能性が高いユニットのみを自転車と判別することを前提として、合成加速度の平均値との差が1m/s²以上の細かい揺れの出現回数の閾値を100回以上と設定した。

b) 右左折の程度の指標化による判別条件の検討

前述の判別において、徒歩または自転車に判別されずに不明として残ったユニットのうち、連続するユニットを繋げて一つのブロックとし、ブロックに含まれる緯度・経度データを用いて、右左折の程度からどの移動手段を利用している可能性が高いかを分類した。

右左折の程度による分類に際して、図-7に示す「右左折スコア(以下、Sと表記)」を定義する。Sは直線的に移動している場合に0に近い値をとり、カーブが大きくなるにつれて大きな値となる。具体的には、直角に曲がった場合には約0.35の値をとり、最大で2に近づいていく指標である。この指標を用い、Sが閾値以上の点が連続する区間を右左折区間として抽出し、各ブロックを、小さく鋭い右左折を含むブロック、大きくゆるい右左折を含むブロック、その他(カーブが無い)ブロックに分類した。




図-7 右左折スコアの定義

一般的な街路を走行するケースを想定して、小さく鋭い右左折を判別する閾値を検討する。Sを算出するための距離の閾値Dを変化させたところ、閾

値 D が 50m や 100m の場合に、S が 0.1 ~ 0.2 となり、小さく鋭い右左折が検出されることから、小さい右左折を検出するための閾値 $D = 100m$ 、 $S \geq 0.1$ と設定した。

一方、鉄道については、直線や緩やかなカーブのみで路線が構成される特徴がある。自動車やバスによる移動で右左折を伴わない可能性は低く、ブロック内に小さく鋭いカーブが無く、大きく緩いカーブが有る場合は「鉄道」である可能性が高いと考えられるが、高規格道路を走行する「自動車（バス）」が含まれる可能性も考えられる。そこで、大きく緩いカーブを含むブロックを、「鉄道」もしくは「自動車（バス）」に分類し、この後の処理で、鉄道ネットワークを使用して鉄道か自動車（バス）であるかを判別した。ここでは、大きい右左折の検出基準について検討する。閾値 D を 10m ~ 500m の範囲で変化させると、200m 以下の場合には右左折の検出が難しいことが確認された。鉄道路線は、普通鉄道構造規則（現在は、鉄道に関する技術上の基準を定める省令に統合）に示される最小曲線半径に従い整備されており、200m ほどの短い区間では進行方向の移動点の変化量が小さいため大きい右左折の検出が難しいと考えられる。結果として、閾値 D を 500m とした場合、カーブ区間で S が 0.1 を超える点が出現し、右左折区間の検出が可能となることから、大きくゆるい右左折を検出する基準として閾値 $D = 500m$ 、 $S \geq 0.1$ として設定した。

c) ネットワークとの重複率による判別条件の検討

鉄道の判別に際しては、右左折の程度による分類で、「大きく緩い右左折が検出されたブロック」に対して、鉄道ネットワークとのマッチングを行い、鉄道ネットワーク上の走行を判別する。鉄道ネットワーク上を走行の判別は、移動経路が鉄道路線リンクに重複している割合（重複率）を指標とした。

本稿では、最寄りの鉄道ネットワークまでの距離が 30 m 以内の経緯度データをマップマッチング対象とし、ブロック内の経緯度データの 50% 以上が鉄道ネットワークと重複している場合、移動手段を鉄道と判別した。

次に、バスと自動車の判別に際しては、上記で鉄道とは判別されなかったブロックに加え、右左折の程度による分類で「小さく鋭い右左折が検出されたブロック」に対して、バスネットワーク上の走行を判別する。緯度・経度データを道路ネットワークに

マップマッチングし、ブロック内の 90% 以上がバスネットワークと重複している場合に移動手段をバスと判別する。また、バスと判別されなかったブロックは自動車と判別した。

(3) 移動手段の 1 次判別結果

移動手段の 1 次判別結果を表 - 3 に示す。なお、移動手段不明を含む、全体の被験者回答に対する的中率は約 75% となった。

徒歩は、77.2% の的中率であり、他の手段の誤判別が少ない一方、自転車は、29.8% の的中率かつ不明の割合も高く (39.3%)、加速度波形の特徴のみから他の手段への分類が難しいことを示している。

自動車は、82.8% の的中率であるのに対し、バスは 53.4% の的中率であるが、いずれも不明の割合が少なく、右左折の程度およびネットワークとの重複率による判別が機能していると考えられる。鉄道は、57.9% の的中率に対して、不明の割合が 23.0% 含まれることから、判別対象区間が全体にわたって直線的であること（右左折を含まないブロックは、1 次判別において不明扱いとなるため）が考えられる。

表 - 3 移動手段の 1 次判別結果

比率 (%)		移動手段の判別結果						
		徒歩	自転車	自動車	バス	鉄道	不明	合計
被験者の回答	徒歩	77.2	5.3	3.9	1.2	1.4	11.0	100
	自転車	13.3	29.8	16.0	1.6	0.1	39.3	100
	自動車	2.1	0.4	82.8	12.0	0.1	2.6	100
	バス	5.4	1.0	34.2	53.4	1.2	4.8	100
	鉄道	6.0	0.6	10.9	1.6	57.9	23.0	100

(4) 隠れマルコフモデルによる移動手段の推定

1 次判別における不明ユニットに対する移動手段の割り当てや、ありえない移動手段の並びを補正するため、1 次判別結果に対して隠れマルコフモデル（以下、HMM）を適用した。ここでは、移動手段の各ユニットがマルコフ性を持つ（手前のユニットの移動手段と次のユニットの移動手段に一定の遷移確率が存在する）と仮定し、一連の移動手段の発生確率が最大となる移動手段の並びを推定した。

a) 隠れマルコフモデルのアルゴリズム

HMM のアルゴリズムのうち、「出力シンボル配列」を結果として出力する「隠れた状態」の最も尤もらしい並びを推定する Viterbi アルゴリズムを適用する。Viterbi アルゴリズムの移動手段判別への適用に関しては、羽藤ら⁸⁾により提案されている。

Viterbi アルゴリズムは、モデル λ が出力シンボ

ル配列 $\mathbf{O} = O_1, O_2, \dots, O_T$ を出力する時の最尤状態遷移配列 $\mathbf{S} = s_1, s_2, \dots, s_T$ を求めるために、時刻 t で状態 i に至るまでの最適状態確率 $\delta_t(i)$ を定義する。

$$\delta_t(i) = \max_{s_1, s_2, \dots, s_{t-1}} p(s_1, s_2, \dots, s_{t-1}, s_t = i, O_1, O_2, \dots, O_T | \lambda) \quad (1)$$

ここで、時刻 t は $1, 2, \dots, T$ とし、状態 i, j はいずれも $1, 2, \dots, N$ の状態を有するものとする。時刻 $t+1$ で状態 j をとる最適状態確率は次のように導出される。

$$\delta_{t+1}(j) = \left[\max_i \delta_t(i) a_{ij} b_j(O_{t+1}) \right] \quad (2)$$

a_{ij} は状態 i から状態 j へ遷移する確率、 $b_j(O_t)$ は状態 j がシンボル O_t を出力する確率である。式 (2) から再帰的に最適状態確率を求めることで、最も高い確率 p が得られる最尤状態遷移配列 \mathbf{S} を求める。

b) Viterbi アルゴリズムのパラメータ設定

HMM で推定される隠された状態として、「徒歩」、「自転車」、「自動車」、「バス」、「鉄道」の5つの移動手段を設定した。また、Viterbi アルゴリズムの適用にあたっては、以下の移動手段のパラメータを表-4のように設定した。

次に、状態遷移確率行列を表-5に示す。遷移確率の設定の際、一般にありえないと考えられる遷移の確率は0とし、徒歩以外の状態同士の遷移は、必

ず徒歩を介して他の状態に遷移する、というマルコフ性を想定した。

さらに、シンボル出力確率行列を表-6に示す。これは、1次判別フロー(図-4)に従って移動手段を判別した結果の被験者回答への的中率(表-3)を用いている。

表-4 Viterbi アルゴリズムのパラメータ設定

パラメータ	設定方法
出力シンボル O_t	<ul style="list-style-type: none"> 移動手段の1次判別後にユニットに割り当てられた移動手段をシンボルとする 不明、速度により下記6通りに分類する <ul style="list-style-type: none"> 不明0 : 0km/h 不明10 : 0~10km/h 不明20 : 10~20km/h 不明40 : 20~40km/h 不明80 : 40~80km/h 不明80+ : 80km/h以上
状態遷移確率 a_{ij}	<ul style="list-style-type: none"> 初期状態から他の状態への遷移確率は均等とする 初期状態以外の各状態は、同じ移動手段間の同一状態遷移の確率を0.99999とし、他状態への遷移は残りの値を均等に振り分ける
シンボル出力確率 $b_j(O_t)$	<ul style="list-style-type: none"> 被験者が回答した移動手段に対する、1次判別結果の被験者回答への的中率を各状態の出力確率とする

表-5 状態遷移確率行列

		状態 j					
		初期状態	徒歩	自転車	自動車	バス	鉄道
状態 i	初期状態	0.0000000	0.2000000	0.2000000	0.2000000	0.2000000	0.2000000
	徒歩	0.0000000	0.9999900	0.0000025	0.0000025	0.0000025	0.0000025
	自転車	0.0000000	0.0000100	0.9999900	0.0000000	0.0000000	0.0000000
	自動車	0.0000000	0.0000050	0.0000000	0.9999900	0.0000000	0.0000050
	バス	0.0000000	0.0000100	0.0000000	0.0000000	0.9999900	0.0000000
	鉄道	0.0000000	0.0000050	0.0000000	0.0000050	0.0000000	0.9999900

表-6 シンボル出力確率行列

		シンボル系列 O_t										
		徒歩	自転車	自動車	バス	鉄道	不明0	不明10	不明20	不明40	不明80	不明80+
隠れた状態 S_t	初期状態	0.1000000	0.0900000	0.0900000	0.0900000	0.0900000	0.0900000	0.0900000	0.0900000	0.0900000	0.0900000	0.0900000
	徒歩	0.7721815	0.0532238	0.0388124	0.0116276	0.0140360	0.0098091	0.0779904	0.0087902	0.0042561	0.0015894	0.0076835
	自転車	0.1326909	0.2977627	0.1600654	0.0156733	0.0011077	0.0052846	0.0645327	0.1473199	0.1723912	0.0020055	0.0011662
	自動車	0.0214662	0.0044687	0.8275411	0.1202722	0.0006270	0.0015070	0.0124798	0.0029953	0.0037182	0.0043815	0.0005431
	バス	0.0543220	0.0103782	0.3418439	0.5335827	0.0115678	0.0160501	0.0194118	0.0049995	0.0042754	0.0014136	0.0021549
	鉄道	0.0597513	0.0060442	0.1085367	0.0160124	0.5793902	0.0129615	0.0186699	0.0046435	0.0059675	0.0163769	0.1716459

(5) 移動手段の判別結果と考察

移動履歴データに本手法を適用して得られた被験者回答への的中率を表-7に示す。移動手段合計の的中率は約82%である。移動手段別の的中率は、バスが55.7%と低いものの、徒歩の87.4%をはじめ、自動車、鉄道、自転車も8割程度の的中率となった。

バスの判別に関しては、バスネットワークとの重複率90%以上を閾値として設定しているが、自動車と判別されたものが34.3%となっている。閾値を低めに設定することで、バスと判別できる可能性も考えられるが、自動車の移動がバスと誤判定されて自動車の一致率が低下してしまう可能性も考えられる。対応策として、バス路線を系統毎に定義して重複率の閾値を下げることで、バス停での停車時間を考慮することなど、判別基準を改良することで、バスの判別精度を高める可能性がある。

表-7 移動手段の判別結果 (的中率)

比率(%)	移動手段の判別結果						
	徒歩	自転車	自動車	バス	鉄道	合計	
被験者の回答	徒歩	87.4	4.2	3.9	2.1	2.4	100
	自転車	10.1	76.1	11.7	1.9	0.2	100
	自動車	3.5	1.0	82.8	12.4	0.4	100
	バス	7.4	1.3	34.3	55.7	1.4	100
	鉄道	7.7	0.1	10.9	2.9	78.4	100

6. おわりに

本稿では、PP調査アプリを活用した生活行動調査の自動化に向けて、取得される移動履歴データによる移動の起終点と移動手段の自動判別手法の提案と適用結果の検証を行った。今後、実務展開での適用に向けた検討を行っていく予定である⁹⁾。

最後に、本稿は、国土交通省国土技術政策総合研究所道路研究室より受託した「自動車起終点調査等の高度化・効率化に関する業務(H25)」の調査成果の一部をとりまとめたものである。

参考文献

- 1) 北村清州, 中嶋康博, 牧村和彦: プロブパーソン調査による交通行動データ収集・活用の高度化, IBS Annual Report 2005, pp.29-35, 2005.
- 2) 朝倉康夫, 羽藤英二, 大藤武彦, 田名部淳: PHSによる位置情報を用いた交通行動調査手法, 土木学会論文集, No.653/IV-48, pp.95-104, 2000.
- 3) 有村幹治, 高野精久: 人の交通行動を対象としたPHS交通調査システムの開発, 運輸政策研究 Vol.5, No.3, 2002 Autumn, pp.13-19, 2002.
- 4) 円山琢也: スマホ・アプリ配布型大規模交通調査の可能性, 交通工学, Vol.48, No.1, pp.4-7, 2013.
- 5) 山崎恭彦, 橋本浩良, 高宮進, 矢部努, 今井龍一, 塚田幸広, 山王一郎, 石田東生: スマートフォンアプリを活用した交通行動調査手法に関する基礎的研究~つくば市におけるプロブパーソン調査を通して~, 土木計画学研究・講演集, Vol.49, 2014.
- 6) 前司敏昭, 堀口良太, 赤羽弘和, 小宮粹史: GPS携帯端末による交通モード自動判定法の開発, 第4回ITSシンポジウム2005論文集, 2005.
- 7) 山崎亜希子, 五味田啓: 加速度センサ等を用いた移動状態判定方式の検討, 情報処理学会全国大会講演論文集 第70回平成20年(3), pp.39-40, 2008.
- 8) 羽藤英二, 大村朋之, 三谷卓摩: 位置-加速度記録を用いた活動パターンと移動負荷の計測に関する研究, 土木計画学研究・講演集, Vol.45, 2012.
- 9) 松島敏和, 橋本浩良, 高宮進: スマートフォンによるプロ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, 土木計画学研究・講演集, vol.50, 2014