

プローブパーソン調査のための対話・学習による交通目的推定法の定式化と評価

瀬尾 亨¹・日下部 貴彦²・朝倉 康夫³

¹正会員 東京工業大学研究員 環境・社会理工学院 (〒 152-8552 目黒区大岡山 2-12-1-M1-20)
E-mail: t.seo@plan.cv.titech.ac.jp

²正会員 東京大学講師 空間情報科学研究センター (〒 277-8568 千葉県柏市柏の葉 5-1-5)
E-mail: t.kusakabe@csis.u-tokyo.ac.jp

³正会員 東京工業大学教授 環境・社会理工学院 (〒 152-8552 目黒区大岡山 2-12-1-M1-20)
E-mail: asakura@plan.cv.titech.ac.jp

プローブパーソン (PP) 調査は GPS 等により交通行動情報を自動収集するため、交通行動調査の長期間化や精度向上につながると期待されている。しかし、トリップ目的は自動収集情報からは判別不能であり、被験者の手入力負荷の小さい調査は依然難しい。本研究は、トリップ目的を半自動的に収集し、かつ事前情報に頼らない PP 調査として、被験者の手入力による部分的な回答と、機械学習による目的推定を組み合わせた「対話学習型 PP 調査」を提案する。本調査では、調査の進展とともに規則的なトリップは自動で推定されるようになり被験者の回答負荷が低減される一方、不規則トリップは手入力回答により高精度に把握可能と考えられる。定式化した手法を既存 PP 調査結果上で再現し、その定量的性質 (例：推定精度、被験者の負担軽減度、個人属性の考慮) を確認した。

Key Words: probe person survey, trip purpose, heterogeneous travelers, naïve Bayes classifier

1. はじめに

プローブパーソン (PP) 調査とは、GPS などの機器を用いてヒトの行動を調査するものである^{1),2)}。PP 調査は移動軌跡を自動で収集するため、被験者の手入力に基づくパーソントリップ (PT) 調査と比較し、位置と時刻に関するデータの精度が高く被験者の負荷が小さいという長所がある。そのため、パネル消耗³⁾を低減し、交通行動調査の長期間化と精度向上につながると期待されている。

しかし、PP 調査は全てのトリップ属性データを自動で収集できるわけではない。特に、交通行動調査で重要となるトリップの目的は、GPS の情報のみからは判別不能である。そのため、トリップ目的を知るためには、PT 調査と同様の被験者の手入力が必要となってしまう、長期間に渡る精度の高い交通行動調査は依然として難しい。

この問題を解決すべく、なんらかのオフラインの事前情報に基づき、GPS 情報などのオンラインで自動収集される情報から交通目的を推定する研究がなされている⁴⁾⁻⁸⁾。ここで、「オフラインの事前情報」としては、既存 PT 調査データや地理情報がよく用いられる。しかし、このような推定手法にはいくつか問題があると考えられる。まず、信頼できる事前情報がない場合には

利用できない。そもそも PP 調査の目的は、この事前情報と同質のデータの収集である場合が多いため、これは本質的な問題となりうる。また、事前情報に基づく推定結果は、それらの情報から導かれる典型的な行動パターンに沿ったものとなる。そのため、不規則・非日常的なトリップの目的の推定、長期間の変動の捕捉、個人属性の考慮が難しいと考えられる。以上より、調査の目的によっては事前情報に基づく推定手法の利用は難しいといえる。

本研究では、事前情報なしで、かつ被験者の負担を抑えてトリップ目的を収集できる長期間の PP 調査を考える。そのための調査手法として、被験者の手入力による部分的な回答と、オンラインでの機械学習を組み合わせた「対話学習型 PP 調査」を提案する。

具体的には、まず、被験者のトリップ目的を推定するモデルを用意する。そして、ある状況でのトリップ目的の推定確度が低い場合、被験者に手入力回答を求め (対話)、その結果を用い目的推定モデルを逐次的に更新する (学習)。一方、推定確度が十分高ければ、推定結果を真値とみなし、手入力は求めない。この調査の長所として、以下のような性質が期待される：

- 調査の進展とともに目的推定モデルが精緻化され、規則的なトリップ (例：通勤) は自動で推定されるようになり、被験者の回答負荷が低減する。

- 推定の難しい不規則なトリップは、手入力回答により正確に把握できる。
- 被験者毎に行動を学習するため、個人毎の性質を考慮できる。

短所としては、最低限の手入力は避けられない点と、誤推定を完全には排除できない点がある。

本研究の予備的な結果は Kusakabe et al.⁹⁾、後藤ら¹⁰⁾にて報告している。本稿の目的は、対話学習型 PP 調査手法の定式化と、その性質の定量的評価である。具体的には、第 2 章にて、被験者の行動履歴と対話に基づくトリップ目的の推定・学習法を定式化する。次に、第 3 章にて、既存 PP 調査結果上で本調査手法を再現し、その性質（例：被験者の負担軽減度、推定精度、個人属性の考慮）を検証する。

2. 方法

(1) コンセプト

本調査手法では、現行 PP のように被験者が調査機器を携帯する。同時に、調査機器により自動収集可能な情報（例：時刻、位置）に基づき、トリップ目的をその確度と共に推定するモデルを用意する。初期のモデルパラメータは、無情報に相当する適当な値とする。本調査は長期間に渡って実施されると想定する。

調査機器の機能は以下の通り。調査機器は、あるトリップが観測された際、そのトリップの状況（自動収集可能な情報）とその時点でのトリップ目的推定モデルに従い、そのトリップ目的を自動で推定する。推定結果の確度が低い場合、質問を発生し被験者の手入力による回答を行動履歴として保存する（対話）。そして、得られた回答結果に基づき、モデルのパラメータを更新し、以降の推定に用いる（学習）。一方、確度が高い場合には質問を発生せず、推定結果を行動履歴として保存する。

すると、本 PP 調査は以下のような挙動を示すと予想される。まず、調査の初期ではトリップ目的推定モデルの推定確度が低いため、ほぼ全てのトリップにて質問を発生する。仮に特定の状況で同一目的のトリップが繰り返された場合（例：朝に自宅から職場へ向かう通勤トリップ）、推定モデルはそのトリップの性質を学習する。つまり、時間の経過と共にその状況のトリップの目的は確度良く推定されるようになり、質問の発生量が大きく減少したうえで、精度の良い情報を得られる。一方、目的と状況が対応付けにくいトリップの場合（例：休日の私用トリップ）は、推定確度が高くなりやすく、質問発生量はあまり減少せず、精度の良い情報を得られる。また、調査が十分進展していても、これまでにない状況のトリップが観測された場合（例：休

暇中の旅行トリップ）、ほぼ必ず質問を発生し、正確な情報を得られる。要するに、確実にわかるトリップの目的は自動で推定し、わからないトリップの目的は被験者に質問することで、回答負荷の低減と調査精度の担保を図る手法といえる。

(2) 対話学習型 PP 調査の流れ

対話学習型 PP 調査の具体的な流れを記述すると、以下となる：

Step 1 被験者 n の調査開始。適当な（ほぼ空の）初期学習用データを与え、学習をリセット。 $i := 1$ とする。許容する推定誤差 p_a を設定する。

Step 2 i 番目トリップの開始が判定された場合、適当なタイミングで以下を実行する

Step 2.1 【推定】 これまでに得られた学習用データ R_n と、今回のトリップ状況 Y^i に基づき、トリップ目的 c^i を推定

Step 2.2 【対話】 トリップ目的推定結果の確度と p_a に基づき、質問を発生するか否か決定

質問を発生した場合【学習】 質問回答結果を行動履歴とする。また、トリップ状況と質問回答結果を学習用データ R_n へ加える。

質問を発生しなかった場合 推定結果を被験者の行動履歴とする

Step 2.3 $i := i + 1$ とし、Step 2 へ戻る

Step 3 被験者 n の調査終了。調査結果として被験者 n の行動履歴を得る。

同じ流れをフローチャートとすると図-1 となる。

Step 2 の「適当なタイミング」には、トリップ i の開始判定直後、同終了判定直後、トリップ $i+1$ の開始判定直後が考えられ、それぞれ利用可能な「トリップ i の状況」が異なる。例えば、「トリップ i の開始判定直後」には出発地の位置情報が利用可能だが、「同終了判定直後」には到着地の位置情報、「トリップ $i+1$ の開始判定直後」には到着地での滞在時間も利用可能となる。

Step 2.1 の「トリップ状況」には、曜日、出発地の位置情報、出発時刻などが考えられる。調査機器のセンサによっては移動手段¹¹⁾などの様々な情報が利用可能と期待される。

(3) 定式化

トリップ目的の学習・推定には単純ベイズ分類機¹²⁾を用いる。単純ベイズ分類機の利点として、学習に必要なサンプル数が少ない点がある。そのため、個人毎の目的推定モデルを構築するために都合が良い。欠点には、変数間の条件付き独立を仮定している点がある。

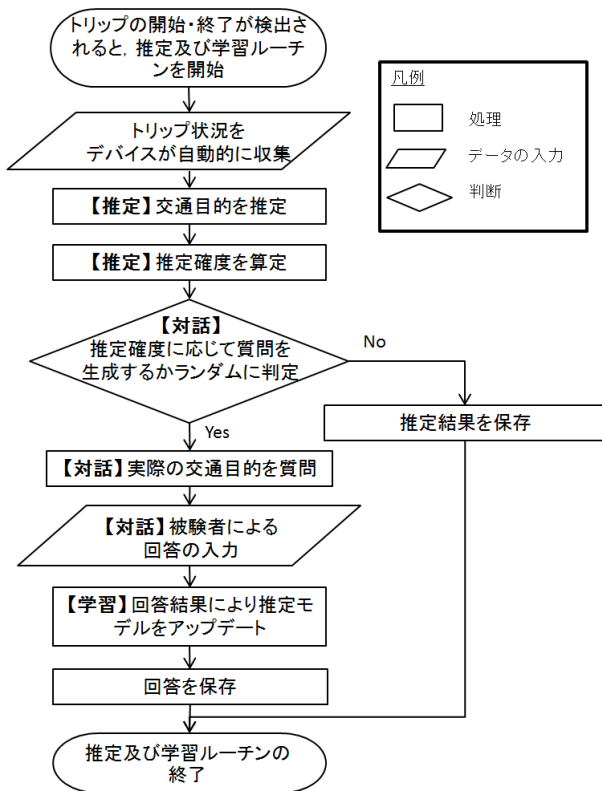


図-1: 対話学習型 PP 調査のフローチャート

なお、第 2.(3)b), 2.(3)c) 節の内容は、通常の単純ベイズによる手法と同様であり、既往研究でもトリップ目的の推定に用いられている¹³⁾。これらを、第 2.(3)d) 節の対話プロセスと組み合わせて PP 調査を構築した点に新規性がある。

a) 定義

トリップ目的の集合を $C = \{c\}$ とする。トリップ属性 (目的以外) の集合を $K = \{k\}$ とし、あるトリップ属性 k の取りうる値の集合を $X^k = \{x^k\}$ とする。あるトリップの状況を $Y = \{x^k \mid \forall k \in K\}$ とする¹⁾。

学習用データを $R_n = \{(c^i, Y^i) \mid \forall i \in I_n\}$ と表記する。ここで、 R_n は (ある時点での) 個人 n の学習データ集合、 I_n は R_n に含まれるトリップの番号の集合、 c^i は i 番目のトリップの目的、 Y^i は同状況である。

¹⁾ 分かり易さのため、具体例を挙げて説明する。

まず、 $C = \{c_1, c_2\}$ とし、 c_1 は通勤、 c_2 は帰宅を意味とする。次に、 $K = \{k_1, k_2, k_3\}$ とし、 k_1 は曜日、 k_2 は出発時刻、 k_3 は出発地を意味とする。そして、 X^k について、曜日は $X^1 = \{x_1^1, x_2^1\}$ とし、 x_1^1 は平日、 x_2^1 は休日を意味とする。同じく、出発時刻は $X^2 = \{x_1^2, x_2^2\}$ とし、 x_1^2 は午前、 x_2^2 は午後を意味とする。さらに、出発地は $X^3 = \{x_1^3, x_2^3, x_3^3\}$ とし、 x_1^3 は自宅、 x_2^3 は職場、 x_3^3 はその他を意味とする。

すると、 i 番目のトリップの例として目的 $c^i = c_2$ の状況 $Y^i = \{x_1^1, x_2^2, x_3^3\}$ というトリップが考えられ、これは帰宅を目的とした平日・出発時刻午後・職場発という状況のトリップを意味する。このとき、本 PP 調査の想定では、まずは $Y^i = \{x_1^1, x_2^2, x_3^3\}$ のみ観測され、目的 c^i の値が推定対象となる。被験者に質問を発した場合には、 $c^i = c_2$ も観測される。

b) 推定プロセス

トリップ状況 Y が観測されたとき、そのトリップの目的が c である確率は $P(c|Y)$ である。これはベイズの定理より

$$P(c|Y) = \frac{P(Y|c)P(c)}{P(Y)} \tag{1}$$

と表せる。ここで単純ベイズの仮定を置く。すなわち、ある c のもとでの Y の各要素 x^k 間の相関を無視できるとすると、式 (1) は

$$P(c|Y) = \frac{1}{P(Y)} \prod_{k \in K} P(x^k|c)P(c) \tag{2}$$

と変形できる。

観測データに基づくトリップ目的推定問題とは、 Y が与件である場合に式 (2) を最大にするトリップ目的 \hat{c} を求める問題を意味する。よって、これは

$$\hat{c} = \operatorname{argmax}_{c \in C} \prod_{k \in K} P(x^k|c)P(c) \tag{3}$$

と表せる。

c) 学習プロセス

式 (3) の計算 (トリップ目的の推定) には $P(x^k|c)$ 、 $P(c)$ が必要となる。これらをデータ R_n に基づく学習により得たい。 R_n の収集方法は第 2.(3)d) 節にて後述する。

学習データ R_n に基づき $P(x^k, c)$ を求めると

$$P(x^k|c) = \frac{\sum_{i \in I_n} \gamma(c, x^k, c^i, Y^i)}{\sum_{z^k \in X^k} \sum_{i \in I_n} \gamma(c, z^k, c^i, Y^i)} \tag{4}$$

ただし

$$\gamma(c, x^k, c^i, Y^i) = \begin{cases} 1 & \text{if } c = c^i \text{ and } x^k \in Y^i \\ 0 & \text{otherwise} \end{cases} \tag{5}$$

となる。式 (4) は、学習データ中のトリップ目的が c であった時に属性 k の値が x^k であった割合を意味する。同様に、 $P(c)$ は

$$P(c) = \frac{\sum_{i \in I_n} \delta(c, c^i)}{|I_n|} \tag{6}$$

ただし

$$\delta(c, c^i) = \begin{cases} 1 & \text{if } c = c^i \\ 0 & \text{otherwise} \end{cases} \tag{7}$$

となる。式 (6) は、学習データ中のトリップ目的が c であった割合を意味する。

d) 対話プロセス

学習データ R_n は、被験者の手入力により収集する。すなわち、推定結果 \hat{c} の確度に応じて適当に質問を発し、その回答を学習データに加えるとする。このとき、確度が低いほど質問発生確率が上がるものとする。

質問を発し回答があった場合、その回答 c^i を最終結果として扱い、 Y^i と共に R_n へ加える。質問を発しな

かった場合、 \hat{c} を最終結果として扱い、学習データの収集には関与しない。

具体的には、 \hat{c} の確度は $P(\hat{c}|Y)$ と定義でき、

$$P(\hat{c}|Y) = \frac{\prod_{k \in K} P(x^k|\hat{c})P(\hat{c})}{\sum_{c \in C} \prod_{k \in K} P(x^k|c)P(c)} \quad (8)$$

と表される。そして、質問の発生確率 p_q を

$$p_q = \max \left\{ 0, 1 - \frac{p_a}{1 - P(\hat{c}|Y)} \right\} \quad (9)$$

と定義する。ここに、 p_a は所与の許容誤判定率である。式 (9) は、対話プロセスの結果得られる最終結果は確率 p_a で誤ることを意味する。

(4) 考察

a) 手法の性質

以上の手法により、コンセプトで述べた調査が実現可能と期待される。すなわち、本調査では時間の経過とともに学習用データ R_n のサンプル数が増加する。そして、あるトリップ目的 c と状況 Y に明確な関係がある場合、その c についての確度 $P(\hat{c}|Y)$ は調査の時間とともに速やかに大きくなり、自動で推定されるようになる。逆に、明確な関係が無い場合には、 $P(\hat{c}|Y)$ は大きくなり、被験者に質問を発するが、正確な回答を得られるため精度は悪化しない。このとき、 R_n は個人 n 毎に用意されているため、個人の特性を考慮した推定が可能となる。

許容する推定誤差率として p_a を与えている。式 (9) から明らかとなり、一般に、 p_a が小さいほど質問発生率 p_q が大きく、 p_a が大きいほど p_q が小さくなる。つまり、被験者の回答負荷軽減と推定精度の間にはトレードオフの関係がある。そのため、 p_a の値は調査の目的に応じて調査設計者が決定する必要がある。なお、 $p_a = 0$ (誤りを一切許容しない) とすると毎回質問が発生する。そのため、本 PP 調査の枠組みは現行の通常の PP 調査を特殊な場合として包含しているといえる。

単純ベイズとして、 x^k 間の独立を仮定している。より厳密には、ある c が観測されたという条件のもと、 Y に含まれる x^k と x^j ($k \neq j$) の間に相関がないと仮定している。相関があっても単純ベイズの精度は大きくは悪化しないという報告はある¹²⁾が、トリップ属性の定義には若干の検討が必要となる。

b) 実際の調査

以上の議論では、理想的な状況を考え、実際の PP 調査で生じうる問題を無視していた。本節では、本手法を実際の調査に適用する際の課題について述べる。

本手法はトリップの開始と終了を自動で判定する、いわゆる移動滞在判別を用いる必要がある。この判別はほぼリアルタイムに実行する必要がある。そのような判別手法は既往研究にて提案されており、ある程度高

精度での判定が可能であるが、完全とはいえない²⁾。移動滞在判別に誤差がある場合、実際のトリップとは大きく異なるトリップを認識したり、実際のトリップを認識しないなどの場合が考えられる。そのため、本手法の性質に適した移動滞在判別手法を採用する必要がある。例えば、リアルタイム移動滞在判別ではトリップ終了の早期検知が課題となることが多いよって、トリップ終了の早期検知に依存しない手法として、トリップ開始時に目的推定・質問発生をするアプローチが有効と考えられる。

本手法の単純ベイズは、他の機械学習手法と比較し、推定に必要な計算量とサンプル数が小さい。そのため、高度な計算・データ処理能力がない調査用機器を用いた PP 調査でも有効といえる。

3. 検証

(1) 検証法

過去の交通行動調査で得られた実データを用いたシミュレーション分析により、提案手法の定量的性質を実証的に検討する。本分析では、当該データに含まれるトリップ属性を真値とみなし、これらのトリップについて第 2 章で述べた手法を再現する。

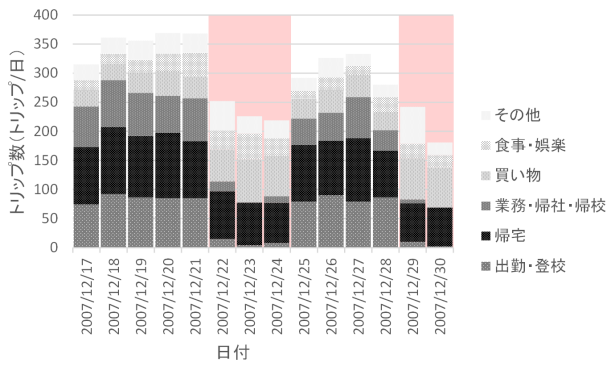
具体的には、データ中の各被験者に対し、時系列順に推定・対話・学習の各プロセスを実行する。トリップ目的推定の際には、データ上のトリップ状況を使用する。対話プロセスで質問が発生した場合には、データ上の目的の値を回答したとみなす。そして、シミュレーション結果として得られたトリップ目的推定値と、元データ上の目的を比較し、推定精度などを検証する。あわせて、提案手法によるトリップ目的の取得に関する特性や、被験者の回答負荷軽減の度合いなどについて分析する。

なお、本手法の質問の発生は確率的に決定されるため、1 回のシミュレーション実験だけでは提案手法の性能について十分な検証ができないと考えられる。そこで、Monte Carlo シミュレーションにより被験者毎に 1000 回の試行を行い、その平均やばらつきを用いて評価する。


(2) データの概要

2007 年に松山市にて実施された PP 調査 (まつやまエコ交通 2000 人チャレンジ) の内、12 月 17 日~12 月 30 日の 14 日間に収集された 92 人 4120 トリップのデータを用いる。データの詳細については付録 A を参照されたい。

データの基礎分析結果を述べる。図-2 に被験者のトリップ特性を示す。なお、図内のピンク色の背景は、土



(a) 目的別トリップ数の推移



(b) 被験者属性別トリップ数の推移

図-2: トリップ数の時間推移

日祝日を示している（以下同様）。図-2a に各日でのトリップ数および交通目的の構成を示す。土日祝日である12月22~24日及び29・30日とこれら以外の平日では、トリップ数および構成比に大きな違いがみられる。特に土日祝日では、出勤・登校および業務・帰社・帰校が大きく減少し、買い物が増加している傾向が読み取れる。

図-2b は、被験者を週当たりの出勤・登校を目的としたトリップを行った日数をもとに分類し、その分類別に各日のトリップ数を示したものである。これは、当該データには被験者属性が含まれていなかったため、その代替を意図したものである。週あたり平均3.5日以上通勤している被験者は73人であり、週0.5~3.0日の被験者は12人、通勤トリップのない被験者は7人であった。トリップ数については、通勤が週3日より多い被験者は土日祝日にトリップ数が大きく変動する傾向にあることがわかる。図-3に被験者毎の総トリップ数の分布を示したものである。40~49トリップが最頻値となっている。週0.5~3.0日の被験者については、サンプル数が少なく、トリップ数のばらつきが大きいことがわかる。




図-3: 被験者属性別のトリップ数分布




図-4: 質問・正解・不正解の関係

(3) モデルの特定

第2.(3)節での定式化は一般的なものであった。今回の分析では、用いたデータの仕様に合わせ、モデルを以下のように特定した。

トリップ目的集合 C の要素は以下とする：

- 出勤・通学
- 帰宅
- 業務・帰社・帰校
- 買い物
- 食事・娯楽
- その他

トリップ属性 K の要素は以下とする：

- 土日祝ダミー
- 到着時間帯
- 到着地

土日祝ダミーは、「平日」か「土日祝日」を示すダミー変数である。到着時間帯は、1日を3時間単位で区切った離散的な時刻とした。到着地は、到着地点に該当するメッシュコードとした。なお、メッシュコードには、7ケタで定義される Geohash¹⁴⁾ を用いた。1メッシュ当たりのサイズは概ね百数十m四方となっており、日本全国で80000メッシュが定義されているものとみなして計算した。なお、以上の設定は、質問タイミングがトリップ終了直後である場合に相当する。

許容される誤判定率 p_a は5%とする。調査開始時の事前情報は一様分布とする（無情報）。すなわち、すべての属性の要素の値と目的の組み合わせが1回ずつ

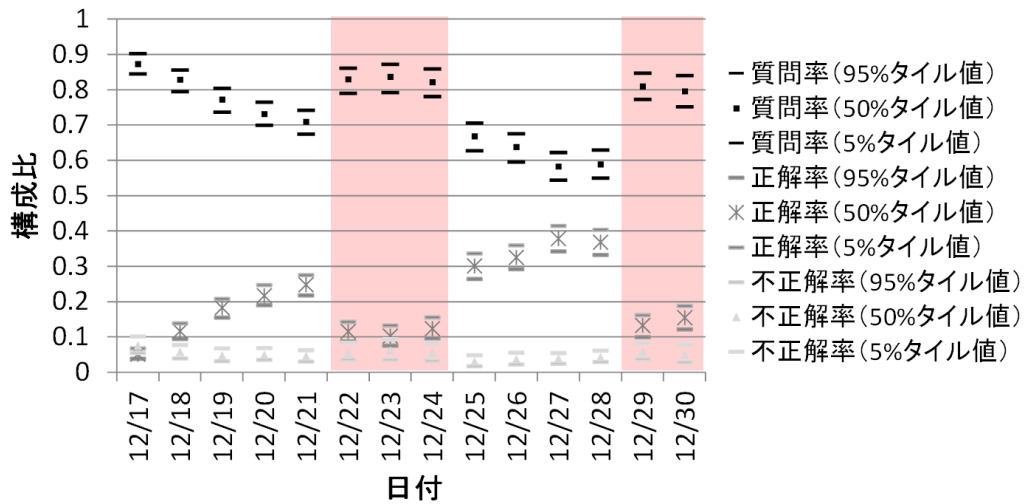


図-5: 質問率・正解率・不正解率の時間推移

観測されているものとして与えた。この初期状態では、全ての $P(\hat{c}|Y)$ の値が $1/|C|$ となり、推定確度が低いと判定される。

(4) 検証結果

本節では、調査期間と質問率の低減具合の関係、対話・学習プロセスを経て得られる推定値の安定性、質問率・正解率の関係、トリップ目的や被験者のトリップ特性による推定結果の特徴について結果を整理し考察する。

ここで、以下の用語を定義する：

質問率 回答者に交通目的を問う質問が発生したトリップの割合

正解率 質問が発生せず、かつ交通目的を正しく推定できたトリップの割合

不正解率 質問が発生せず、かつ交通目的を誤って推定したトリップの割合

正しい調査結果が得られる割合は、(質問率) + (正解率) = 1 - (不正解率) である。被験者の回答負荷は質問率が低いほど小さいといえる。以上の関係を図-4 に図示する。

a) 全体的な傾向

図-5 は、1000 回の試行によって得られた、各日での質問率、正解率、及び不正解率について、それぞれの 5% タイル値、中央値、95% タイル値を示したものである。平日の傾向として、調査の日数経過とともに質問率が減少し、正解率が上昇している。平日だけに着目すると、最終日の質問率の中央値は約 58.9% となっており、95% タイル値と 5% タイル値の間には 7.9% の幅がある。正解率は、36.7% であり、95% タイル値と 5% タイル値の幅は、7.1% であった。一方、土日祝日は平日と比較





図-6: 質問率・正解率の人数分布

して質問率が高く、休日の最終日の中央値は 80.0% となっている。誤判定率は中央値の全期間の平均は 5.0% として推移しており、95% タイル値と 5% タイル値の幅は 4.0% で安定した推移となっている。これは、あらかじめ設定した許容誤判定率 $p_a = 5\%$ とよく一致している。


図-6 は、横軸を質問率、縦軸を正解率とし、グレースケールで、軸に対応する質問率・正解率の人数を示したものである。この図では正解率が低い被験者ほど下に、質問率が低い被験者は左にプロットされる。したがって、質問が少なく正解率が高い被験者は左上に表示され、推定精度が高いものに質問を行っていない場合には、中央部上部に表示されることになる。70~90% の質問率でかつ質問をしなかったものについては 50~100% の正解率があることがわかる。なお、質問率が 70~90% の被験者の割合は 71.9% であり、この質問率でかつ正解率が 50% 以上の被験者の割合は全体の 67.8% であった。

b) 交通目的ごとの傾向


図-7 に、交通目的ごとの推定結果の中央値を示す。平日だけに着目すると、通勤・通学、帰宅、業務・帰社・



(a) 質問率の推移




(b) 正解率の推移




(c) 不正解率の推移


図-7: 調査手法の挙動の目的別の時間推移



(a) 質問率の推移



(b) 正解率の推移



(c) 不正解率の推移

図-8: 調査手法の挙動の被験者属性別の時間推移

帰校目的のトリップでは、質問率が低下し、正解率が上昇する傾向がある。買い物、食事・娯楽が交通目的のトリップでは、曜日にかかわらず変化が少なく、75%以上で推移している。一方で、不正解率は、これらのトリップは p_a より大きくなる傾向がある。もっとも大きいもので 12 月 28 日のその他の目的トリップでの 18.2% となっている。

c) 被験者属性ごとの傾向

図-8 に、被験者の通勤日数による分類別の推定結果の中央値を示す。平日だけに注目すると、いずれのグループでも最初の週と比較して 2 週目で質問率が低下し、正解率が上昇しており、通勤日数が最も大きい分類で、顕著に上昇している。一方で、土日祝日に関してはこのような傾向が見られず、時刻や目的地が一定でないことが示唆される。

(5) 考察

提案手法は全体的に意図通りの挙動を示しているといえる。すなわち、調査の進展と共に質問率が減少し、被験者の回答負荷が低減している。推定精度が高い場合には質問を省き、推定精度が低い場合に質問を発生させる割合を増すことで、最終的に得られる交通目的推定の精度を一定水準で保っている。この際、調査設計者が与えた推定精度を示している。

また、トリップや被験者の属性が提案手法の挙動に及ぼす影響も定量的に示せた。すなわち、通勤のような規則的なトリップがより高い精度で推定でき、このようなトリップの多い被験者の質問率が低下し正解率が上昇していると理解できる。買い物、食事・娯楽のようなトリップは、質問率はあまり低下せず、かつ不正解率が大きくなる傾向がみられた。これは、そのト

リップの時間・場所が不規則であることが原因と考えられる。

4. おわりに

本研究では、事前情報に頼らず、かつ被験者の回答負担を低減する PP 調査手法として、「対話学習型 PP 調査」を提案した。これは、被験者の手入力による部分的な回答と、オンラインでの機械学習を組み合わせ、被験者のトリップ目的を半自動的に推定する手法である。これにより、調査の進展とともに典型的なトリップ状況を学習し、被験者の回答負担を低減できると期待される。第 2 章では、そのような調査手法を単純ベイズ分類器に基づき定式化した。第 3 章では、定式化した手法の性質を実証的に検証するため、既存の PP 調査結果上で提案手法をシミュレートした。

その結果、本手法は推定精度を担保しつつ被験者の回答負担を低減できることを確認した。具体的には、平日の質問率は調査の進展と共に単調減少し、調査の 2 週目では約 60%に減少していた。このとき、推定の誤差率は意図したとおり約 5%であった。また、想定通り、通勤のような規則的なトリップが自動推定され、娯楽のような不規則なトリップは質問される場合が多いことが確認された。ただし、今回のデータの調査期間は 2 週間のみであり、学習期間に限りがあるといえる。より長期間の調査にて、質問率がさらに低減するかなどを検証する必要がある。

既存 PP 調査結果上でさらに検討すべき項目として、以下が考えられる。まず、質問タイミングを検討する必要がある。質問タイミングには、前述の通り、トリップ開始後、終了後、次トリップ開始後などの様々なタイミングが考えられ、それぞれ異なる利用可能な情報と実装上の課題がある。また、被験者負担軽減と推定精度のトレードオフ関係の分析、すなわち p_a に関する感度分析が必要である。

現在、第 2.(4)b) 節で述べた課題を考慮しつつ、本手法をスマートフォン上に実装する作業を進めている。今後、試行的に実 PP 調査へ適用し、本手法の実際の性質を検証する予定である。

謝辞： 「まつやまエコ交通 2000 人チャレンジ」に伴う PP 調査のデータの使用に当たり、東京大学の羽藤英二教授、松山市の石井朋紀氏、復建調査設計（株）の森三千浩氏に多大なご協力をいただきました。ここに謝意を表します。

付録 A 検証に用いたデータ・モデルの詳細

2007 年度に松山市にて実施された PP 調査（まつやまエコ交通 2000 人チャレンジ）でのデータを使用した。この調査は、第 1 期として 2007 年 10 月 27 日（土）～12 月 9 日（日）、第 2 期として同年 12 月 15 日（土）～2008 年 2 月 3 日（日）に実施された。これらの期間のうち、第 1 期：10 月 29 日～11 月 11 日、第 2 期：12 月 17 日～12 月 30 日に日常行動データが収集された。本研究では、サンプル数の多い第 2 期の日常行動データを用いる。

本研究での分析では、対話・学習プロセスの検証には一定期間継続してトリップが観測されていること及び交通目的・到着地・到着時刻の情報が漏れなく記述されている必要がある。このことから、本研究では、下記の手順で、データクレンジングを行った。まず、「(i) 交通目的・到着地・到着時刻のいずれかの情報が記述されていないトリップを除去」した。このうえで、「(ii) 最初と最後のトリップを行った日の間隔が 10 日未満の被験者を除去」し、「(iii) トリップを行った日数に対する帰宅回数の比率が 0.8 未満の被験者を除去」した。(ii) は十分な日数調査に参加した利用者を抽出することを意図したものであり、(iii) はできるだけ正確な記述をしている被験者を抽出することを意図したものである。本クレンジングの結果、元データの 5329 トリップから、4120 トリップ 92 人が抽出された。

参考文献

- 1) 大森宣暁, 室町泰徳, 原田昇, 太田勝敏: 交通行動調査への GPS の適用可能性に関する調査, 第 18 回交通工学研究発表会報告, 1998.
- 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) 北村隆一, 藤井聡, 山本俊行: 離散時間パネル調査の調査期間, 調査間隔, 標本数の最適化, 土木学会論文集, No. 681/IV-52, pp. 13–23, 2001.
- 4) Wolf, J., Guensler, R., and Bachman, W.: Elimination of the travel diary: Experiment to derive trip purpose from global positioning system travel data, *Transportation Research Record: Journal of the Transportation Research Board*, No. 1768, pp. 125–134, 2001.
- 5) Shen, L. and Stopher, P. R.: Review of GPS travel survey and GPS data-processing methods, *Transport Reviews*, Vol. 34, No. 3, pp. 316–334, 2014.
- 6) Gong, L., Morikawa, T., Yamamoto, T., and Sato, H.: Deriving personal trip data from GPS data: A literature review on the existing methodologies, *Procedia - Social and Behavioral Sciences*, Vol. 138, pp. 557–565, 2014.
- 7) 塚本健太郎, 佐藤仁美, 森川高行: GPS やコンテキストデータを活用した行動目的の推定手法に関する研究, 土木計画学研究・講演集, Vol. 50, 2014.
- 8) 金森亮: スケジュールデータによる移動情報の精度検証, 土木計画学研究・講演集, Vol. 53, 2016.
- 9) Kusakabe, T., Seo, T., Goto, H., and Asakura, Y.: Interactive online machine learning approach for activity-travel survey, in *Proceedings of the 14th International Conference on Travel Behaviour Research*, 2015.

- 10) 後藤啓人, 定金乾一郎, 瀬尾亨, 日下部貴彦, 朝倉康夫: 対話して学習するプローブパーソン調査システムの提案, 第 13 回 ITS シンポジウム 2015, 2015.
- 11) 中村英夫, 宮下浩一, 羽藤英二, 岸井隆幸: パーソントリップ調査のための加速度センサを活用した Random Forest による移動手段推定手法, 交通工学論文集, Vol. 1, No. 5, pp. 10–18, 2015.
- 12) Rish, I.: An empirical study of the naive Bayes classifier, in *IJCAI 2001 Workshop on Empirical Methods in Artificial Intelligence*, Vol. 3, pp. 41–46, 2001.
- 13) Kusakabe, T. and Asakura, Y.: Behavioural data mining of transit smart card data: A data fusion approach, *Transportation Research Part C: Emerging Technologies*, Vol. 46, pp. 179–191, 2014.
- 14) Niemeyer, G.: Geohash, 2008. <http://geohash.org/>.

(2016. 7. 31 受付)

Formulation and Evaluation of Framework for Probe Person Survey using Online Machine Learning based on Interaction with Survey Participant

Toru SEO, Takahiko KUSAKABE, Yasuo ASAKURA