

走行中車両の経路履歴を用いた 確率モデルによるオンライン目的地推定

小笠原 悠介[†] 原 祐輔[‡] 井料 隆雅[‡]

株式会社ブリヂストン[†] 東北大学 情報科学研究科[‡]

1. はじめに

道路交通の監視と予測は道路管理者にとって重要である。また、近年ではスマートフォンなどの個人が所有するGPS機器の位置情報も活用できるようになってきており、Location Based Services (LBS)の観点からも重要性が増してきている。一般にこれらのサービスはユーザーの現在地や過去に訪れた場所、ユーザーが直接入力した目的地の情報に基づいて提供される場合が多く、ユーザー自体の属性や生活パターンの情報が必要となっている。しかし、単一のトリップ自身が持つトリップ中のある時点までに通過した経路履歴のデータは、目的地の方角や距離に関する情報を少なからず含んでいると考えられる。そこで本稿では、ユーザーの過去の履歴情報を用いることなく、該当トリップの出発時から各時点までの通過経路情報のみから該当トリップの目的地を推定する技術の構築を試みる。

本稿では、目的地の方向を推定するモデルと目的地の距離を推定するモデルの組み合わせによって目的地推定モデルを構築している。そして、仙台パーソントリップ調査のデータから生成した膨大な車両の経路履歴のデータを用いて、目的地推定の精度を評価した。最後に、経路履歴を考慮した確率モデルを用いることで、走行中車両の経路履歴データのみから次のリンク選択や目的地を予測できる可能性について示す。

2. 先行研究と本研究の位置づけ

目的地推定に関する研究はLBSの高度化[1]、運転中のユーザーの支援[2]、タクシー事業者の配車効率化[3]など様々な目的で行われている。これらの研究の多くは各ユーザーの属性・過去の経路情報・現在のトリップの全緯度経度履歴を用いているが、これらの情報の取り扱いについてはプライバシーの問題が指摘されている[4]。そこで本研究では先行研究と比較して、プライ

バシー保護の観点から、経路履歴のデータを逐次的に削除することを想定し、トリップの出発位置と現在位置のみを用いて目的地推定を行うモデル化に取り組んでいる。

3. 経路履歴データ生成手法及び分析手法

3.1 経路履歴データ生成手法

経路履歴を表す系列データを生成するために2018年に実施した第5回仙台都市圏パーソントリップ調査(以降PT調査)のデータを用いる。このデータは市区町村や町丁目等により1904個のゾーンに分割された仙台都市圏の各トリップについて、出発地のゾーンコード、到着地のゾーンコード、出発時間帯が含まれたデータとなっている。そのため、PT調査のみでは経路が把握できない。そこで本研究では、出発/到着のゾーンコードから経路の生成を行っている。具体的にはPT調査の出発/到着のゾーンコードをデジタル道路地図(以降DRM)の仙台市周辺の道路ネットワークデータを用いて近傍の出発/到着のノードに確率的にマッピングし最短経路探索により経路を生成し分析を行っている。

3.2 目的地推定モデル

始めに本研究における目的地の定義について述べる。本研究では仙台PT調査データの結果から目的地候補として頻度の高い到着地ノード300個を抽出し、それぞれの距離が300m以内のノードを集約して合計130個のノードを目的地候補として目的地集合 Z を定めた(図1)。

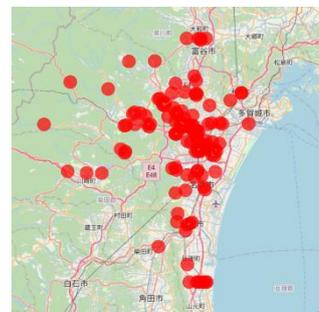


図1. 仙台市周辺の目的地候補ノード
各トリップの目的地は図1の130個のノードの内、最もネットワーク距離が近いノードにマッ

Online prediction of travel destination based on the driving route history

[†] Ogasawara Yusuke, Bridgestone Corporation

[‡] Hara Yusuke, Tohoku University

[‡] Iryo Takamasa, Tohoku University

ピングさせている。本研究での目的地推定モデルは 3.2.1 目的地の方向を推定する距離差分に基づくロジットモデルと 3.2.2 目的地までの距離を推定するトリップ長分布の確率密度関数モデルの組み合わせによって構築している。

3.2.1 目的地の方向を推定するモデル

走行中車両はその目的地に近づいていくという仮定に基づき、トリップ出発ノード n_1 と各目的地候補 $z \in \mathbf{Z}$ までの距離 d_{1z} 、現在のノード n_k と各目的地までの距離 d_{kz} を用いて距離差分を計算し、以下のロジットモデルで各目的地候補 z への目的地推定モデルを式(1)の通り構築している。

$$P_{\text{dir}}(z|n_1, n_k) = \frac{\exp(\beta_d(d_{kz} - d_{1z}) + \beta_z)}{\sum_{w \in \mathbf{Z}} \exp(\beta_d(d_{kw} - d_{1w}) + \beta_w)} \quad (1)$$

ここで β_d は距離差分にかかるパラメータ、 β_w は各目的地固有のパラメータであり、負の対数尤度の最小化によって学習される。

3.2.2 目的地までの距離を推定するモデル

ここでノード n_i から n_j への最短経路長を l_{ij} 、 n_z を目的地とする N_z 個のトリップのトリップ長を \bar{l}_z^m ($m = 1, 2, \dots, N_z$) とする。各目的地 z のトリップ長分布からカーネル密度推定により算出された確率密度関数を用いて、目的地までの距離を考慮した目的地推定を式(2)の通り構築している。

$$P_{\text{len}}(z|n_1, n_k) = \frac{1}{N_z h} \sum_{m=1}^{N_z} K\left(\frac{l_{1k} + l_{kz} - \bar{l}_z^m}{h}\right) \quad (2)$$

$$K(x) = \exp(-x^2/2) \quad (3)$$

ここで平滑化パラメータである h は Scott's rule[5]に基づき N_z の個数とデータの次元数により定めている。本稿では式(1)のみのモデル、式(1)と式(2)の単純な積で目的地を推定するモデルの2種類について結果を示している。

4. 結果

パーソントリップデータから生成した経路 83405 個の内、ランダムに分割した 62553 個を学習データ、残りの 20852 個をテストデータとして推定精度の評価を行った。推定精度の指標は[6]を参考にトリップ全体に対する通過割合毎の Top-3 accuracy とし、学習データの Origin-Destination 遷移行列から算出した推定精度 (17.6%) をベースラインとして、本研究のモデルの推定精度と比較している(図 2)。この結果から 3.2.1 のモデルのみを用いてトリップ全体の 10% 通過時点で 6.6%、50%通過時点で 26.6%推定精度を向上させることが可能であると示された。また該当トリップの 70%通過時点で差し掛かると出発地点と目的地候補との距離も考慮することでさらに目的地の推定精度を向上させられることが示された。

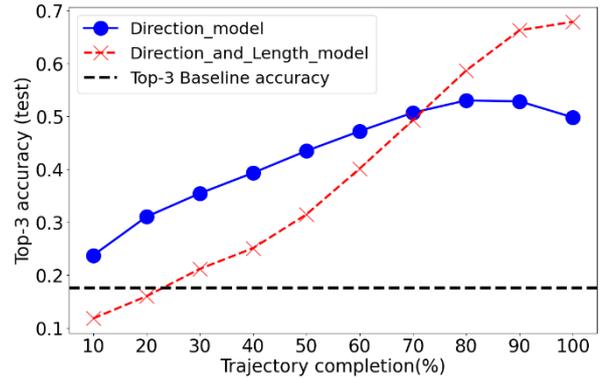


図 2. トリップの通過割合と推定精度の関係

5. 考察

式(2)のモデルの結果より、該当トリップの 70%通過時点以降は目的地までの距離も考慮することで精度を向上させることが出来ている。これは出発地からの目的地の方向のみでは、トリップの終盤で複数の目的地候補が出てきて定めきれおらず、さらに目的地までの距離を考慮することでそこから推定精度を向上できることが示唆されている。そのため、トリップの距離に応じて 3.2.1 と 3.2.2 のモデルの比重を調整することでさらに推定精度の向上が期待できる。

6. まとめと今後の展望

本稿では仙台都市圏 PT 調査データの目的地推定について、トリップの出発位置と現在位置のみを用いるシンプルな推定モデルを用いることで単純な OD のみを考える場合と比べて 6%~50%程度推定精度を向上出来ることを示した。今後は 2 つのモデルの比重の調整及び午前/午後、平日/休日等の時刻の情報をモデルに組み込むことによる推定精度の変化について調査予定である。

参考文献

- [1] Q. Zeng, J. Wang and K. He: Improving Destination Prediction via Ensemble of Trajectory Movement Separation and Adaptive Clustering, IEEE Access, vol. 8, pp. 28142-28154, 2020
- [2] 田島 敬士, 吉岡 元貴, 小澤 順: カーナビゲーションシステムにおける個人走行履歴による到着地推定に用いる走行属性の評価, 知能と情報, 20 巻, 3 号, pp. 379-387, 2008
- [3] Meghan O'Connell, moreiraMatias, Wendy Kan: ECML/PKDD 15: Taxi Trajectory Prediction (I), Kaggle, <https://kaggle.com/competitions/pkdd-15-predict-taxi-service-trajectory-i>, 2015
- [4] A. Y. Xue, R. Zhang, Y. Zheng, X. Xie, J. Huang and Z. Xu: Destination prediction by sub-trajectory synthesis and privacy protection against such prediction, 2013 IEEE 29th International Conference on Data Engineering (ICDE), pp. 254-265, 2013
- [5] D. W. Scott: Multivariate Density Estimation: Theory, Practice, and Visualization, John Wiley & Sons, 1992
- [6] Stegmann et al.: A survey of evaluation methods for personal route and destination prediction from mobility traces, WIREs Data Mining Knowl Discov, 8, e1237, 2018