

メッシュマップマッチングを用いたプローブデータの走行車線の推定に関する基礎的研究

法政大学大学院（現 首都高速道路株式会社）				学生会員	○難波	尚樹
法政大学	正 会 員	今井	龍一	関西大学	正 会 員	山本 雄平
大阪経済大学	正 会 員	井上	晴可	摂南大学	正 会 員	塚田 義典
大阪経済大学	正 会 員	中村	健二	阪神高速道路株式会社	非 会 員	池本 佳代

1. はじめに

昨今、個車の走行履歴を常時、面的に把握できるプローブデータを活用した渋滞対策や事故対策が推進されている。現在は、路線単位の交通量や旅行速度の分析が一般的であり、走行車線単位の交通分析の事例は少ない。これは、現在のGNSSの測位精度に基づく、車両の走行した道路は特定できるものの、走行した車線の特定が困難であることが要因である。走行車線単位のミクロな交通分析にプローブデータを適用できると、分合流部における個車の車線変更の挙動分析等、より高度な道路交通分析が実現できると考える。そこで、著者らは、先行研究¹⁾において、3軸加速度の推移に機械学習を適用すると車線変更の有無や走行車線が推定可能であることを明らかにしてきた。しかし、ETC2.0プローブ情報（走行履歴情報）等の加速度をもたないプローブデータには考案手法を適用できない。位置情報のみを用いてこれらを推定できれば、プローブデータの取得項目に依らないミクロな交通分析が実現できる。

そこで、本研究の目的は、加速度をもたないプローブデータにも適用可能な走行車線の推定手法の考案とする。具体的には、プローブデータの測位点を車線別に区切られたメッシュ（以下、「車線別メッシュ」とする。）単位に集約（以下、「メッシュマップマッチング」とする。）して機械学習を適用する。これにより、位置情報をもとに個車の走行車線が推定可能となる。

2. 走行調査によるプローブデータの取得

本研究では、ミクロな交通分析の観点から、阪神高速道路環状線の湊町JCT～中之島JCT間の約3kmを分析対象路線・区間に定め、本区間を走行した車両から収集されるプローブデータを分析する。片側4～5車線道路で、左右からの分岐や合流が続く本区間で考案手法の有用性が確認できれば、今後、車線数の少ない他区間への適用も期待できる。また、2台のスマートフォン

（AQUOS SH-51A および iPhone 6）から毎秒の経緯度を取得した。本研究では、2台のスマートフォンおよびドライブレコーダを搭載した車両が検証フィールドを約900回走行することでプローブデータを取得した。

3. メッシュマップマッチングと機械学習を用いた走行車線の推定

走行車線の推定手順を図-1に示す。まず、教師データを作成するため、プローブデータに実際の走行車線を紐付ける。次に、メッシュマップマッチングによりプローブデータと車線別メッシュとを重畳する。最後に、プローブデータが通過したメッシュの推移（以下、「通過メッシュ」とする。）に機械学習を適用して、個車の走行車線を推定する。

(1) プローブデータと車線番号の紐付け

前章で取得したプローブデータに、実際に走行した走行車線を番号で付与する。本研究では、調査車両に搭載したドライブレコーダの映像を目視で確認し、時刻で紐付けることによりプローブデータに車線番号を付与した。

(2) 車線別メッシュの作成

車線別メッシュのイメージを図-2に示す。まず、GIS上で航空写真をトレースすることで、道路の横断方向は区画線の幅、縦断方向は約10mとなるメッシュを作




図-1 走行車線の推定手順

成する．次に，各メッシュに一意の ID（以下，「メッシュ ID」とする．）を付与する．これにより，メッシュ ID を用いて通過メッシュを把握する．

(3) プローブデータと車線別メッシュとの重畳

メッシュマップマッチングの手順を図-3 に示す．本処理では，プローブデータの測位点をポリラインで結合し，ポリラインと車線別メッシュとを重畳する．これにより，車両の走行軌跡をメッシュ単位で把握する．

(4) 車線番号判定モデルの適用

前節の手順により得られた通過メッシュに機械学習を適用する．本研究では，先行研究¹⁾の手法に倣い，Random Forest の回帰モデルを用いて車線番号の値を推定する車線番号判定モデル（以下，「モデル」とする．）を構築した．なお，学習データの説明変数は，車線変更に要する距離を考慮して，前後 20 メッシュ（約 200m）分のメッシュ ID，目的変数は車線番号とする．モデルにメッシュ ID の推移を入力すると，車線番号を示す 0 ～4 の実数で推定結果が出力される．

4. 考案手法の有用性検証

本章では，スマートフォンで取得したプローブデータにモデルを適用することで，考案手法の有用性を検証する．本検証では，2 章で取得したプローブデータのうち，任意に抽出した 10 万件から教師データを構築した．また，教師データに使用していない 12 回の走行データ（Case-1～12）を評価データとした．

正解率は，モデルの出力値と実際の車線番号の差の絶対値が 0.5 以内であった場合を正解として，各走行で算出した．結果を表-1 に示す．表より，12 ケース中 6 ケースで正解率は 6 割以上であった．ここで，先行研究¹⁾において，スマートフォンで取得されたプローブデータを 1 点ずつ評価した際，実際の走行車線上に測位される割合は 6 割程度であることが示されている．したがって，通過メッシュに機械学習を適用すると，プローブデータの測位精度と同等以上の精度で走行車線を推定できる可能性があることがわかった．一方，Case-8 のように極端に正解率が低いケースもみられた．これは，測位誤差が大きく，車線別メッシュ上に測位点が重畳できなかったことが要因と考えられる．

5. おわりに

本稿では，構築した車線別メッシュの推移に機械学習を適用することで，プローブデータの走行車線を推定した．その結果，測位精度が改善されることを確認し




図-2 車線別メッシュのイメージ




図-3 メッシュマップマッチングの手順

表-1 走行車線の推定結果（正解率）					
Case-1	Case-2	Case-3	Case-4	Case-5	Case-6
80.5%	73.4%	64.3%	76.5%	41.2%	16.8%
Case-7	Case-8	Case-9	Case-10	Case-11	Case-12
81.7%	2.6%	77.3%	59.5%	55.2%	14.7%

赤字：60%以上の正解率

た．一方，測位誤差の影響から推定に失敗するケースも散見された．これは，測位誤差の生じた測位点を補正できれば改善できる可能性がある．また，本検証では，直線区間のみを対象としたため，今後は曲線を含む他の区間においても考案手法の適用可否を明らかにする．

謝辞：本研究の遂行にあたって，株式会社 Create-C の仲条仁氏，藤井琢哉氏および前田真護氏にはプローブデータの特性に関する貴重なご意見を賜った．ここに記して感謝の意を表す．

参考文献

1) 今井龍一，井上晴可，中村健二，山本雄平，塚田義典，山口樹，難波尚樹：機械学習を用いたプローブデータの走行車線の推定に関する一考察，AI・データサイエンス論文集，土木学会，Vol.3，No.J2，pp.755-763，2022．