

Proactive 型交通マネジメントの実現に向けた交通状況ナウキャストモデルの構築

岐阜大学 学生会員 柴垣太郎

岐阜大学 正会員 倉内文孝

1. 背景と目的

効率的な交通マネジメントのためには、今後発生しうる交通渋滞の程度を的確に把握することが重要である。本研究では、数分先の交通状況を予測する交通状況ナウキャストモデルの構築をめざす。これをトリガーとし、ゲーミフィケーションの概念やチャットボットとのコミュニケーションを活用しドライバーへの行動提案を行うことで行動変容を積極的に促す「Proactive 型交通マネジメント」の実現が本研究の最終目標である。

2. 交通状況ナウキャストモデルの概要

本研究では、ディープラーニングによるモデル構築を行う。先行研究¹⁾を参考に、時系列予測に適した Long Short Term Memory (LSTM) 手法を用いる。インプットデータは、交通量感知器から得られる車線ごとの速度、占有率、交通量、大型車交通量に加え、1キロポストごとの気象情報、交通規制情報などを考えている。また、ETC2.0 車載器搭載車両の記録した緯度経度ごとの速度データが将来的にはほぼリアルタイムで取得可能となることが想定できるため、これらのデータの活用も併せて検討する。

3. 分析対象区間

3.1 区間の設定

広島市内から広島空港へのアクセスを対象とする。広島空港は山間部に位置しており、広島市街からの空港アクセスは主に高速バスである。アクセス路線の山陽自動車道では、朝に空港へ向かう方向の渋滞、夕方市内へ向かう方向の渋滞が生じており、平日の朝の時間帯における渋滞は空港到着時刻の不確実性を増大させている。渋滞対策として多くの交通量観測が実施されていること、西日本高速道路株式会社の協力によりデータの借用が可能なことからこの路線を分析対象に設定した。




図-1 分析対象区間と車両感知器設置場所




図-2 占有率-速度の分布図

3.2 交通量感知器データによる現況把握

分析対象区間の交通状況を理解すること、交通状況ナウキャストモデルにおけるインプットデータの選別をおこなうことを目的として、新型コロナウイルス感染拡大による影響の小さい2019年の5分ごとのループ式交通量感知器データを用いた分析を行った。図-1に分析区間と交通量感知器の設置位置キロポストを示す。図-2は、対象区間の占有率-速度の分布である。広島東 IC-志和 IC 間、志和 IC-西条 IC 間で渋滞が発生しやすく、これらの交通量感知器はボトルネック直上流であるといえる。二地点とも下流のトンネルやサグ部が渋滞を引き起こしていると考えられる。

4. 交通状況ナウキャストモデルの試行

4.1 特徴量選択

渋滞と関連性の高いデータを求めるため、渋滞が深刻である広島東 IC-志和 IC 間の追越し車線占有率データと過去の交通量感知器から得られるデータの相関分析を行った。相関係数は次のように定義した。

$$r_{ai\Delta t} = \frac{\frac{1}{n} \sum_{j=1}^n (a_{ij\Delta t} - \bar{a}_{i\Delta t})(a_{yj} - \bar{a}_y)}{\sqrt{\frac{1}{n} \sum_{j=1}^n (a_{ij\Delta t} - \bar{a}_{i\Delta t})^2} \sqrt{\frac{1}{n} \sum_{j=1}^n (a_{yj} - \bar{a}_y)^2}}$$

ただし、 i :KP-車線-項目番号、 a_i :KP 別車線別項目別の交通量感知器データ、 a_y :KP274.17 の追越し車線占有率データ、 Δt : a_y と a_i の時間ラグ、 $r_{ai\Delta t}$: a_y と Δt 分前の a_i の相関係数、 n : データ数、である。

先行研究¹⁾を参考に相関係数の閾値を 0.65 とすると 14 個のデータが選択された (図-3)

4.2 モデルの構造

次に、交通状況ナウキャストモデルの基本構造の検討を行った。試行の LSTM モデルはレイヤー数を 1、隠れ層の次元を 50 とした。本研究では予測対象を多地点にすることで渋滞区間全体の予測を狙う。出力変数を KP278.56 と KP268.0 の二地点の追越し車線占有率とし、入力変数を 1 分ごとのループ式交通量感知器の車線別交通量、占有率とした。占有率の実数値を予測するので活性化関数は線形活性 Linear とした。出力層の交通量感知器データは整数のため変動が激しくなる。このモデルでは入力変数、出力変数を 1 分更新の 5 分移動平均にデータを整理することで大きな変動を緩和した。

4.3 試行結果

2 地点の予測結果を図-4、図-5 に示す。一週間単位ではおおよそ一致しているように見えるが、真値に対して予測値は低く出力される傾向にある。また、渋滞部分を拡大した図-6 より、渋滞の傾向は学習できているが、突発的な事象に対応できていない。渋滞時の占有率の閾値を 10%と仮定すると渋滞の発生予測は遅れ、解消予測は早まる傾向にある。

今後は入力変数に ETC2.0 データや気象情報、交




図-3 選択された特徴量




図-4 試行結果 (KP278.56,一週間)




図-5 試行結果 (KP281.75,一週間)




図-6 試行結果 (KP278.56,渋滞時)

通規制情報を逐次追加し、モデルの設定を変更することで予測精度の向上を目指す。また、予測結果の評価手法についても検討していく。それらの結果は当日説明する。

謝辞: 本研究は、国土交通省道路局が設置する新道路技術会議の委託研究「高速道路における Proactive 型交通マネジメント方策についての研究開発」で行われ、西日本高速道路株式会社よりデータ提供を受けた。記して謝意を表す。

参考文献

- 1) 杜然:「深層学習による高速道路交通状態ナウキャストモデルの構築」、岐阜大学自然科学技術研究科修士論文, 2021.3