

エリアの規模と集計時間を考慮した LSTM による Macroscopic Fundamental Diagram 予測の基礎的検証

日本大学 学生会員 ○田中 聡紀

日本大学 正会員 石坂 哲宏

1. はじめに

交通流入制御手法であるランプ流入制御手法を評価する指標として Macroscopic fundamental diagram (以下, MFD) を用いる研究¹⁾が多くされている。その予測手法として深層学習 Long Short Term Memory (以下, LSTM) を用いた方法が提案されている。MFD は、交通状態が時間と空間を遷移することを表現するため、他のエリアの MFD が制御対象エリアの MFD に与える影響を考慮すること重要である。本研究は LSTM による基礎的な MFD の予測性能を検証するために、予測に用いるエリアの規模と集計時間の影響を明らかにすることを目的とする。十分なデータが得られ外的要因の少ない自動車専用道路ネットワークで、基礎的な予測性能を検証することは今後の技術向上に向けて必要な要素になる。

2. 既存研究と本研究の位置づけ

吉井ら¹⁾は、高速道路の需要変動を内生化したシミュレーションモデルを構築し、集計 QK を利用したランプ流入制御の評価を行った。特定の条件下で適切な交通制御を実施した場合、流入交通量を増加させる結果が示された。また、高速道路流入台数の増加は一般道路の交通量減少を示唆するものであるため、交通制御の実施が高速道路だけでなく一般道路の混雑緩和効果を併せ持つことを示した。馬場ら²⁾は、那覇を中心エリアの一般道路網を対象として、他エリアからの短期的交通予測に LSTM モデルを用いた MFD の予測を行った。学習データが 1 変数より 2 変数の方が精度の良い結果を示したが、エリアの規模と集計時間の影響は体系的に整理されていない。

本研究では LSTM による予測手法に関して、予測に必要な学習エリアの規模と集計時間の影響を明らかにすることができれば、予測手法の有用性をたかめられるといえる。また、MFD の将来予測はランプ流入制御の高度化に寄与できると言える。

3. 研究方法

3. 1 研究対象

米国加州ロサンゼルスフリーウェイを対象に分析を行った。事前の分析で常に交通渋滞が発生している区間を把握し、I-110 号と I-10 号の二路線を対象とした。図-1 のジャンクションを中心に 3km 四方のグリッド (図中の緑枠, 以下 Area A と表記) を作成し、Area A からの距離に応じて Area A を含む学習エリアを拡大し、それぞれ Area B, Area C, Area D と設定した。また、加州交通局が運用している車両感知器によって観測された 5 分ごとの集計速度と交通量データを用いて N (車両存在台数) と P (走行台キロ) を MFD として算出した。

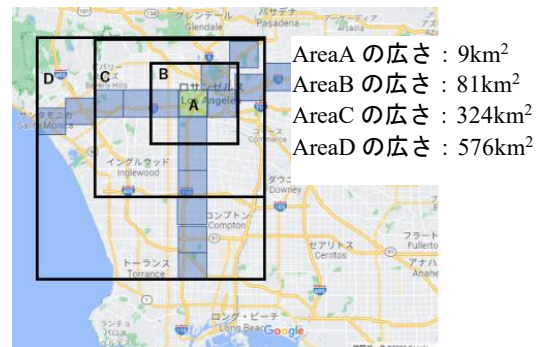


図-1 予測対象エリア

3. 2 LSTM モデルの設定

エリアごとの各リンク数と LSTM のユニット数等を表-1 に示す。予測精度向上のため、特徴量であるエリアのリンク数に応じて LSTM のユニット数を 50 から 100 の範囲で調整し、LSTM の層自体を 1 から 3 層で調整した。2019 年 1 月 1 日から 4 月 30 日までを学習期間とし、5 月 1 日以降を予測期間とした。

学習の試行回数は各 50 回以上、隠れ層は 5 に設定した。ルックバック数は 10 分間隔データの学習では 1 日分 144steps, 60 分間隔データの学習は 1 週間分 168steps とし、10 分間隔では 10 分単位の短期予測, 60 分間隔では 1 日単位の長期予測を実施する。

キーワード Macroscopic Fundamental Diagram, Long Short Term Memory, 交通予測, 交通制御, ランプ流入制御

連絡先 E-mail:kurousu0047@gmail.com

表-1 LSTM モデル

モデル	出力値	入力値	リンク数	LSTM ユニット
モデル I	AreaA の N 値と P 値	AreaA	42	2層 50unit
モデル II		AreaB	79	2層 50unit
モデル III		AreaC	164	2層 50unit
モデル IV		AreaD	215	3層 100unit

3. 3 検証方法

検証は Area A 各リンクの 10 分および 60 分集計の車両存在台数と走行台キロについて予測値と実測値を比較した。予測精度の評価指標は時間帯別に平均絶対誤差率 (MAPE) を用いた。

4. 予測結果と考察

4. 1 予測精度への学習エリアの影響

表-2 は、それぞれのモデルで 60 分集計の車両存在台数と走行台キロを学習後、Area A の車両存在台数と走行台キロを 1 日分予測した精度である。全時間帯では Area A のデータのみで学習したモデル I の値が最も精度が良かった。これは Area A データの学習モデルがリンク数に合った LSTM モデルであったこと、1 日単位の予測は、予測エリアの数週間の学習により、予測可能なためと考えられる。モデル I から IV にかけて学習エリアが広がるので、精度がよくなると想定していたが、予測精度の向上には寄与しなかった。自エリアから自エリアを予測するモデル I に近い精度を有するモデルは II であり、モデル III と比較して精度の劣化は大きくない。他のエリアからの交通状態の遷移が見込まれる交通施策に適用する際は、モデル II のエリア設定が適しているといえる。

表-2 60 分集計データの学習による
Area A の予測精度 MAPE[%]

モデル	モデル I	モデル II	モデル III	モデル IV
全時間帯	28.60	36.95	111.71	67.54
24:00-4:00	20.54	33.09	720.81	53.04
4:00-6:00	22.30	27.81	130.63	39.55
6:00-12:00	16.92	18.41	53.00	24.36
12:00-22:00	14.72	23.72	58.99	26.07
22:00-24:00	12.32	32.89	149.22	60.70

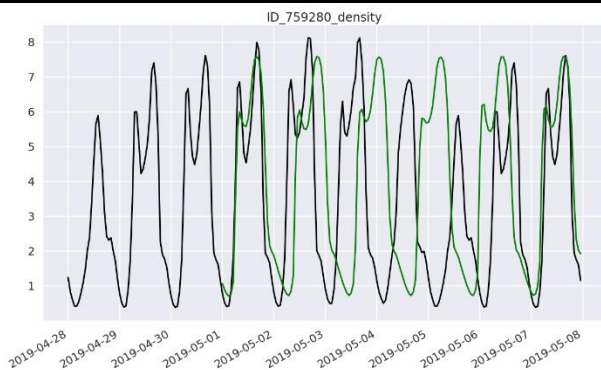


図-2 60 分集計モデル III の予測精度：車両存在台数

図-2 は予測開始後数日のモデル III のグラフである。黒線が実測値で緑線が予測値である。モデル III は時間が経過するにつれて値の波形がずれておりリンク数と LSTM モデルの相性が合っていないと考えられる。

4. 2 集計時間の影響

表-3 はそれぞれのモデルで 10 分及び 60 分集計の車両存在台数と走行台キロについて学習後、Area A の車両存在台数と走行台キロを予測した精度である。10 分間隔の予測では翌 1 日分、60 分間隔の予測では翌 1 週間分算出した。各モデルのリンク数に合った LSTM モデルの精査は必要であるが、モデル I を除き 10 分の集計間隔の精度が 60 分より高かった。十分単位の短期予測時は、予測したい地域より広い地域のデータを学習したほうが、良い予測結果になった。

表-3 集計時間別の Area A の予測精度 MAPE[%]

モデル	モデル I	モデル II	モデル III	モデル IV
10min	40.27	27.56	33.67	29.16
60min	28.60	36.95	111.71	67.54

5. 結論と今後の課題

本研究は、他の影響を受けづらい自動車専用道路ネットワークにおける、MFD の予測性能にエリアの規模と集計時間が与える影響を定量的に明らかにした。エリアに関する考察では、他のエリアを含めずに対象地域のみで予測することが適していると示された。これは 60 分間集計モデル I が最も精度が良かったためである。しかし、10 分間集計では他のエリアを含めたほうが良い精度となったので、モデルの精査が必要になると考える。続いて、集計時間の影響はモデル I を除いて 10 分間集計が 60 分間集計より精度が良かったので、10 分間集計がエリアの規模に影響を受けず安定的に予測できると言える。今後の課題は、本研究は総当たりで交通予測に対する LSTM モデルを設定したが、今後はリンク数を考慮し、理論的に適切なモデル設定を模索していきたい。

参考文献

- 1) 吉井稔雄, 高山雄貴, 松本洋輔: 集計 QK を利用したランプ流入制御手法の有効性評価, 土木学会論文集 D3 (土木計画学), Vol. 69, No. 5 (土木計画学・論文集第 30 巻), I_579-I_586, 2013.
- 2) 馬場静羽, 井上亮: 交通変数間の関係を反映した深層学習による地域の交通状態の短期的予測, 交通工学論文集, 第 7 巻, 第 2 号 (特集号 A), pp. A_110-A_118, 2021.