

F1-22

LSTM を用いた Macroscopic Fundamental Diagram による交通状態推定

—アメリカ・カリフォルニアのフリーウェイを対象として—

Prediction of Traffic Condition of Macroscopic Fundamental Diagram by using LSTM

-Case Study of Freeway in State of California-

○田中 聡紀¹, 石坂哲宏²

*Satoki Tanaka¹, Tetsuhiro Ishizaka²

Abstract: The impact of time interval and area coverage on the application of LSTM was analyzed with respect to MFD, an indicator of area traffic conditions. The MFD was calculated from traffic volumes and other data observed on freeways in Los Angeles, USA. The MFD of the most central area was predicted from the MFD of the surrounding area. 60 minutes later, the accuracy was better when only the historical data of the own area was used instead of using other areas. Using data from other areas did not improve the accuracy.

1. はじめに

ランプ流入制御などの交通制御手法を評価する指標の Macroscopic fundamental diagram (以下, MFD) を予測手法として深層学習 Long Short Term Memory (以下 LSTM) を用いた研究が行われている。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その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といえる。

本研究では、米国加州のフリーウェイの車両感知器データによる MFD を対象に、精度よく予測するうえで必要となる時間間隔とエリアの範囲に関して基礎的な知見を得ることを目的とする。

2. 既存研究と本研究の位置づけ

小川ら^[1]は、鎌倉の交通状態を推定するにあたり、時間帯や交通状況だけでなく観光交通需要の季節性、降水等の複数の外的要因に着目し、時間帯 LSTM を多変量型に拡張して交通状態の推定を行った。馬場ら^[2]は、網複数地域ごとにおける一般道路網を対象に那覇を中心エリアとし他エリアからの短期的交通予測に LSTM を用いた MFD での予測を行った。これらの既存研究を踏まえ、予測エリアと予測に用いるデータの範囲に着目して、本研究ではどこまで拡張しても精度に問題ないか検討する。

3. 研究方法

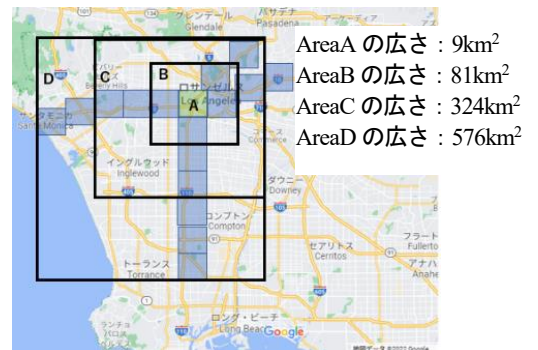
3. 1 データの概要

加州交通局が運用している車両感知器で観測された5分ごとの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。

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 3 km 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。

図-1 予測対象エリア



3. 2 LSTM の概要

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。予測精度を高めるため、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では 1 週間分 168steps とし, 10 分間隔では数十分単位の短期予測, 60 分間隔では 1 日単位の長期の予測を実施する。

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

1 : 日大理工・院 (前)・交通 2 : 日大理工・教員・交通

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する。予測精度の評価指標は時間帯別に平均絶対誤差率 (MAPE) を用いる。

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について学習後、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と、1 日単位の予測は、予測エリアの数週間の学習によって、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、その分精度がよくなっていくと想定していたが、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。一方、広範囲エリアの予測の精度が悪かった理由として、特徴量となるリンク数により LSTM モデルの精査が必要であり、総当たりでモデル変更したが精度を高めきれない結果になった。

表-2 1 時間集計データの学習による Area A の予

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

測精度 MAPE[%]

4. 2 時間帯の影響

時間帯別では 6:00~12:00 と 12:00~22:00 の時間帯が深夜の時間と比べて 20%ほど精度が良かった。交通量の変動が大きい深夜時間帯は誤差が大きく表れ、変動が少ない日中は誤差が少ない値になったと考えられる。ピーク時に適用されるランプメタリングなどの制御に用いることに支障はないといえる。

図-2 は自エリアから自エリアを予測するモデル I 以外で予測精度が安定していたモデル II の予測開始 1 日後 11 時から 22 時の Area A 予測結果の MFD である。青点が実際値で橙点が予測値である。予測値は実際値

よりばらつきが小さい。これは実際の特異値には予測値が対応していないためと考えられる。

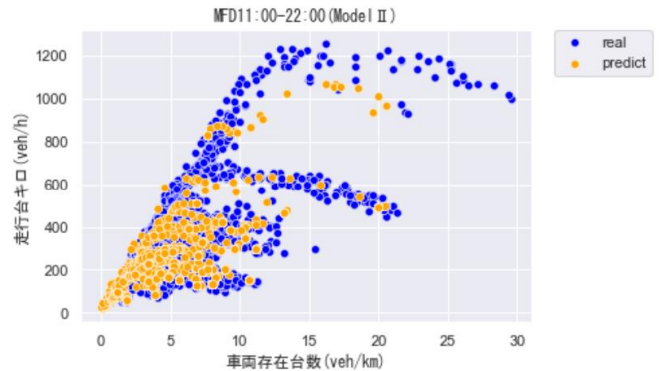


図-2 モデルIIにおける Area A の MFD

4. 3 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、10 分間隔ではモデル I よりモデル II の予測精度が高い結果となった。数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. おわりに

本研究では車両感知器データによる MFD を精度よく予測するうえで必要となる時間間隔と学習エリアの範囲に関して基礎的な知見を得ることができた

今後の課題として、具体的な交通施策に必要なモデルの要件を明確にし、適切な LSTM モデルを精査するとともに経験則ではない理論的な LSTM モデル調整の可能性を探る必要がある。また、サンプル数を 1 年に増やし、周期的な要因 (季節や曜日) を組み入れ、より普遍的な予測を実現したい。

参考文献

- [1]小川見平, 福田大輔: 多変量 LSTM による短期交通量予測: 鎌倉市の観光交通を対象として, 第 61 木計画学研究会発表会・講演集, pp. 1-10, 2020.
- [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.