

# 交通信号制御を反映した 深層学習による都市内の短期交通量予測の検討

増田 亮<sup>1</sup>・井上 亮<sup>2</sup>

<sup>1</sup>学生員 東北大学 大学院情報科学研究科 人間社会情報科学専攻 (〒 980-0845 仙台市青葉区荒巻字青葉 6-6-06)

<sup>2</sup>正会員 博 (工) 東北大学准教授 大学院情報科学研究科 人間社会情報科学専攻 (〒 980-0845 仙台市青葉区荒巻字青葉 6-6-06)

都市内一般道の交通状態予測では、道路の複雑な接続関係と信号機による制御を考慮することが不可欠である。深層学習は、多変量のデータ間に内在する関係を抽出できるため、多種の予測問題に対して高い性能を示しており、交通状態予測に対する応用可能性も期待される。そこで本研究では、現在までの面的な時系列交通量データおよび予測対象時刻の信号制御情報を利用した、深層学習による短期的将来の交通量予測モデルを提案する。提案モデルを、交通流シミュレーションから取得した実験用の交通量データに対して適用し、面的な時系列交通量データと信号制御情報の利用で、それぞれ予測精度が向上することを確認した。

**Key Words:** *deep learning, traffic volume prediction, time series, traffic signal control*

## 1. 序論

交通渋滞は、道路利用者の所要時間増加による損失をはじめとする種々の損失の要因となる。そのため、交通渋滞を緩和させる取り組みは社会的にも重要である。

交通渋滞の緩和に大きな役割を果たすのが、交通量などを対象とした交通状態予測である。特に、予測間隔を数分から数時間とした短期の交通状態予測は、道路管理者の意思決定の支援や、道路利用者への適切な情報提供に活用できると考えられる。このため、特に渋滞が頻発する都市内において、短期予測モデルに対する需要は大きい。

近年、入手可能な交通データの増加に伴い、データを用いた交通状態予測手法の開発が盛んに行われている<sup>1)</sup>。その1つが、本研究において検討を行う深層学習手法である。深層学習は、多層に積み重ねたニューラルネットワークを用いてデータから内在する依存関係を自動的に抽出できる点が特徴である。そのため、長期間にわたって膨大なデータが取得されている交通データを用いた交通状態予測との親和性が高い。これまでも、交通流の空間的性質<sup>2)</sup>や時間的性質<sup>3),4)</sup>に着目した深層学習モデルが提案されている。しかし、既存の深層学習による交通状態予測手法の大半は高速道路を対象としており、一般道を対象とした手法は少ない。

高速道路と異なり、一般道では信号制御が行われている。このため、一般道を対象とした短期交通量予測をより高精度に行うためには、近傍交差点の信号制御情報をモデルに導入し、信号制御が時系列交通量に与える影響を反映させる必要がある。また、道路の接続

関係が複雑な都市内一般道の予測にあたっては、予測対象リンクの時系列交通量に加え、その周辺リンクの時系列交通量も活用することが精度向上につながると考えられる。

そこで本研究では、現在までの面的な時系列交通量と予測対象時刻における信号制御情報を利用した深層学習による短期交通量予測モデルを提案し、有用性の検証を行う。

## 2. 交通信号制御を反映した都市内の短期交通量予測手法の提案

### (1) 時系列データに適した深層学習手法

時系列データなど、個々の要素の出現順序が意味を持つ系列データに適した深層学習手法として、Hochreiter and Schmidhuber<sup>5)</sup>により LSTM (Long Short-term Memory) が提案されている。LSTM は、系列データの依存性を記憶できるよう、通常の順伝播型ニューラルネットワーク (FFNN: Feed Forward Neural Network) の隠れ層を Memory Block と呼ばれる複数の演算の集合に置き換えた構造を持つ (図-1, 図-2)。LSTM には複数の亜種が存在する<sup>6)</sup>が、本項では現在最も一般的に利用されている Gers *et al.*<sup>7)</sup>による Forget Gate 付き LSTM を紹介する。

以下の説明では、ステップ  $t$  における入力層からの入力  $\mathbf{X}^{(t)}$  の  $(i, j)$  成分を  $x_{i,j}^{(t)}$ 、隠れ層からの出力  $\mathbf{H}^{(t)}$  の  $(i, j)$  成分を  $h_{i,j}^{(t)}$  とおく。

LSTM の Memory Block には、入力ゲートが 4 ヶ所存




図-1 FFNN と LSTM の構造

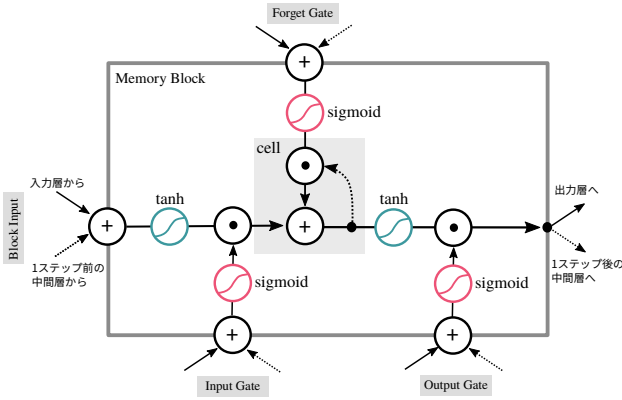


図-2 Memory Block の構造

在し、Block Input, Input Gate, Forget Gate, Output Gate と呼ばれる。それぞれの入力ゲートでは、式 (1)-(4) に示す計算が行われる。

$$z_{i,j}^{(t)} = \tanh \left( \sum_{k=1}^K w_{i,k}^{(Z)} x_{k,j}^{(t)} + \sum_{k=1}^K r_{i,k}^{(Z)} h_{k,j}^{(t-1)} + b_i^{(Z)} \right) \quad (1)$$

$$i_{i,j}^{(t)} = \sigma \left( \sum_{k=1}^K w_{i,k}^{(I)} x_{k,j}^{(t)} + \sum_{k=1}^K r_{i,k}^{(I)} h_{k,j}^{(t-1)} + b_i^{(I)} \right) \quad (2)$$

$$o_{i,j}^{(t)} = \sigma \left( \sum_{k=1}^K w_{i,k}^{(O)} x_{k,j}^{(t)} + \sum_{k=1}^K r_{i,k}^{(O)} h_{k,j}^{(t-1)} + b_i^{(O)} \right) \quad (3)$$

$$f_{i,j}^{(t)} = \sigma \left( \sum_{k=1}^K w_{i,k}^{(F)} x_{k,j}^{(t)} + \sum_{k=1}^K r_{i,k}^{(F)} h_{k,j}^{(t-1)} + b_i^{(F)} \right) \quad (4)$$

ここで、 $w_{i,k}^{(Z)}, w_{i,k}^{(I)}, w_{i,k}^{(O)}, w_{i,k}^{(F)}$  は入力層からの入力に対する重み行列、 $r_{i,k}^{(Z)}, r_{i,k}^{(I)}, r_{i,k}^{(O)}, r_{i,k}^{(F)}$  は戻り値に対する重み行列、 $b_i^{(Z)}, b_i^{(I)}, b_i^{(O)}, b_i^{(F)}$  はバイアスである。また、 $\sigma(-)$  はシグモイド活性化関数である。

Memory Block 中央の Cell では、式 (5) に示す計算が行われる。

$$c_{i,j}^{(t)} = z_{i,j}^{(t)} i_{i,j}^{(t)} + c_{i,j}^{(t-1)} f_{i,j}^{(t)} \quad (5)$$

Cell には、1 ステップ前の Cell の計算結果  $c_{i,j}^{(t-1)}$  が保持されており、式 (5) により Cell の値を更新している。

最終的な Memory Block の出力は、式 (6) によって決




図-3 提案モデルの構造

定される。

$$h_{i,j}^{(t)} = o_{i,j}^{(t)} \tanh \left( c_{i,j}^{(t)} \right) \quad (6)$$

Memory Block から出力された  $h_{i,j}^{(t)}$  は、出力層への入力と次ステップの隠れ層への入力に利用される。

順伝播型ニューラルネットワークでは、入力を固定長とする必要があるため、系列データに含まれる入力長よりも長いサイクルの周期性を十分に学習することができない。一方で LSTM では、過去の情報をネットワーク内部に保持することができる Memory Block の導入によって、可変長の系列を用いた長期の依存関係の抽出が可能になり、系列データに内在する 100 ステップ以上の周期性の学習に成功している<sup>5)</sup>。

## (2) 提案モデル

本研究では、現在までの予測対象リンクおよびその周辺リンクの面的な時系列交通量と、予測対象時刻における近傍交差点の信号制御情報（スプリット情報）を入力として、一定時間後の予測対象リンクの交通量を出力する深層学習モデルを提案する。提案モデルは都市内一般道を対象として、道路の接続関係に依存しない形で時系列交通量を利用し、さらに一般道特有の情報である信号制御情報を反映した予測を行うことができる。モデル構造を図-3 に示す。

提案モデルは、「複数時系列間の特徴抽出」を行う部分と「時系列データと信号制御の関係性抽出」を行う部分から構成される。

### a) 複数時系列間の特徴抽出

LSTM によって、予測対象リンクおよび周辺リンクの時系列交通量データをもとに、時系列データごとの周期性や複数の時系列データ間の依存性などの特徴抽出を行う。

### b) 時系列データと信号制御の関係性抽出

予測対象時刻における信号制御パターンが、予測交通量に与える影響を考慮すること目的として、LSTM からの出力値と予測対象時刻における信号交差点のスプリットの値を結合し、続く全結合層で時系列データと信号制御との関係性を抽出する。

### 3. 交通流シミュレーションデータによる提案手法の検証

#### (1) 検証方法

本稿では、提案手法における面的な時系列交通量データ利用の効果と信号制御情報利用の効果を検証する。

検証に際し、信号制御情報利用時の予測精度変化の要因として、モデルが学習用データに含まれる範囲内の交通量と制御情報との対応関係を学習している可能性と、信号制御の変化が交通量に影響を及ぼすというロジック自体を学習している可能性が考えられる。しかし、実測の交通データを利用した検証からは、学習用データに含まれる交通量と制御情報との対応関係とは異なる関係のデータが得られないため、これらの可能性を区別することができない。

そこで本検証では、現実には運用されなかった信号制御を含む様々な信号制御を行った状況を作り出せる交通流シミュレータを利用して交通量データを取得し、モデルの検証を行う。

#### (2) シミュレーションによる交通量データの生成

検証には、街路網交通流シミュレータ「AVENUE」を用いて作成したシミュレーションデータを利用する。シミュレーションの対象範囲を、国道 6 号線・16 号線が交差する呼塚交差点（千葉県柏市）を中心に国道 6 号線側 2.5 km 程度、国道 16 号線側 16 km 程度とし、対象時間帯を 7 時から 19 時までの 12 時間と設定した。

シミュレーション空間の外部から流入する交通量は、日本道路交通情報センターが公開する実測の断面交通量（5 分間隔）<sup>8)</sup> をもとに設定し、平日 90 日分（2018 年 7 月 2 日から 11 月 16 日まで・土日祝日およびお盆期間を除く）の実際の交通量変動を再現した。また、シミュレーション空間内の呼塚交差点のスプリットも、同期間に実際に運用された信号制御情報（5 分間隔）<sup>8)</sup> を用いて設定し、シミュレーションを実行した。なお、呼塚交差点の対象時間帯の周期は 180 秒である。呼塚交差点以外の信号交差点については、1 日を通して信号制御パターンが変化しない定周期制御で運用した。

シミュレーション終了後、シミュレーション内で観測された 90 日分の時系列交通量データを取得した。

#### (3) モデルの学習と予測精度の評価

シミュレーションから出力された 90 日分の時系列交通量データのうち、最初の 60 日分をモデルの学習用、残りの 30 日分を予測精度の評価用に利用した。

モデルは、バックエンドに TensorFlow を指定した深層学習ライブラリ Keras を用いて構築した。モデルの学習は、5 分後の交通量を教師データとする教師あり学



(a) 予測対象リンク 1 とその周辺リンク



(b) 予測対象リンク 2 とその周辺リンク

図-4 利用リンクの位置関係

習によって行った。目的関数は 5 分後の交通量とモデルの出力値との MSE（二乗平均誤差）とし、最適化アルゴリズムは Adam を使用した。また、ミニバッチのバッチサイズは 256 に設定し、学習は評価用データから算出した MSE の改善が直近 50 エポックで  $10^{-4}$  以下となるまで繰り返した。

予測精度は、評価用データから RMSE（二乗平均平方根誤差）を算出して評価する。RMSE は、 $\hat{x}_k$  を時刻  $k$  における予測値、 $x_k$  を時刻  $k$  における観測値とすると、式 (7) によって定義される。

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{k=1}^n (\hat{x}_k - x_k)^2} \quad (7)$$

本検証では、モデルの学習と RMSE の算出を 10 回行い、その平均値を結果として採用した。

#### (4) 検証 1: 面的な交通量データ利用の効果検証

検証 1 では、予測対象リンクの時系列交通量のみを利用したケースをベンチマークとし、周辺リンクの時系列交通量をモデルに導入することによる精度変化を検証する。検証 1 は、提案モデルの「複数時系列間の特徴抽出」部のみを利用して行い、信号制御情報はモデルに導入していない。

なお、ハイパーパラメータである LSTM のユニット数は、各ケースで {4, 8, 16, 32, 64, 128} の 6 通りを試行し、RMSE 最小のユニット数を採用した。

利用リンクの位置関係を図-4 に示す。予測対象リンクは 2 ヶ所設定した。

予測結果を表-1 および図-5 に示す。予測対象リンク 1、予測対象リンク 2 とともに、周辺リンクの利用によって予測精度が向上する結果となった。特に予測対象リンクの上流側リンクを利用することで、顕著に予測精度の向上がみられた。



表-1 面的交通量データ利用時の予測精度の変化

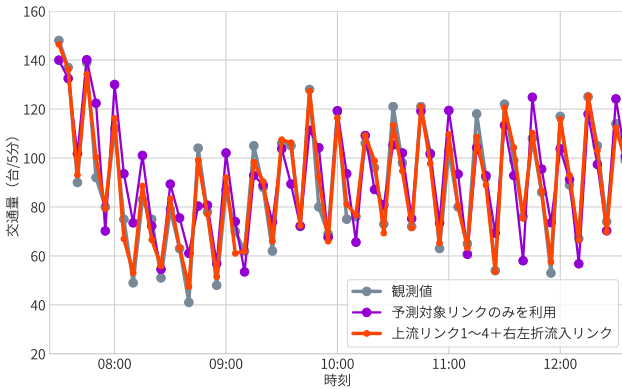
予測対象リンク	モデルに導入した周辺リンク	予測精度 (台/5分)
予測対象 1	なし (予測対象リンクのみ導入)	10.880
	上流 1	8.110
	上流 1・2	6.692
	上流 1~4	6.452
	上流 1~4 + 右折 + 左折	6.180
予測対象 2	なし	11.749
	上流 1	10.541
	上流 1・2	10.413
	上流 1・2 + 右折 + 左折	9.777

表-2 呼塚交差点の信号制御 (平日 7時-19時)


パターン	国道 16 号線 青時間 (秒)	運用時間割合 (%)
A	126	50.0
B	114	34.4
C	108	15.3

表-3 信号制御情報利用時の予測精度の変化

予測対象リンク	評価用データ 制御パターン	予測精度 (RMSE・台/5分)	
		制御情報 ×	制御情報 ○
予測対象 1	実際の運用	5.852	<b>5.578</b>
	A のみ	<b>5.322</b>	5.364
	B のみ	<b>7.186</b>	7.458
	C のみ	10.963	<b>10.388</b>
予測対象 2	実際の運用	9.449	<b>9.185</b>
	A のみ	11.561	<b>11.497</b>
	B のみ	<b>9.724</b>	9.755
	C のみ	<b>9.828</b>	9.863



(a) 予測対象リンク 1 の予測結果



(b) 予測対象リンク 2 の予測結果

図-5 面的交通量データ利用時の予測結果 (検証 5 日目)

(5) 検証 2: 信号制御情報利用の効果検証

検証 2 では、提案モデルの全体を利用し、面的な時系列交通量データに加えて、予測対象時刻における呼塚交差点の制御情報をモデルに導入した。LSTM のユニット数は {4, 16, 64}, 全結合層の層数は {0, 1, 2}, 全結合層 1 層あたりのユニット数は {64, 128} からそれぞれ選択し、すべての組み合わせを試行してハイパーパラメータを決定した。また、全結合層の活性化関数には ReLU 関数を利用した。

実際には運用されなかった信号制御状況下での信号制御情報利用の効果を検証するため、実際の信号制御を

再現した状況から評価用データを取得した場合に加え、呼塚交差点で平日日中に交通状況に応じて選択されている 3 種類の信号制御パターン (表-2) のうち、1 種類のみを常に運用した未知の制御状況から評価用データを取得した場合の検証も行った。


結果を表-3 および図-6 に示す。実際に運用された信号制御状況下から評価用データを取得したケースでは、信号制御情報をモデルに導入した場合に、導入していない場合と比較して予測精度が向上した。一方で、未知の制御状況下から評価用データを取得したケースでは、信号制御情報のモデルへの導入によって多くの場合で予測精度が悪化する結果となった。

結果から、提案モデルは交通量と信号制御との間に内在するロジックではなく、交通量と信号制御との対応関係自体を学習したことが示唆される。そのため、学習用データに存在する交通量と信号制御との対応関係の範囲内では信号制御を反映した予測が可能であるが、学習用データに存在しない未知の制御状況における汎化性能を獲得するには至らなかったと考えられる。


4. 結論

本研究では、都市内一般道を対象に、面的な時系列交通量データと近傍交差点の信号制御情報を入力とする深層学習による短期交通量予測モデルを提案した。

有用性の検証の結果、面的な時系列交通量データの導入と信号制御情報の導入のそれぞれで予測精度の向上を確認した。一方で、学習用データに存在しない未知の信号制御状況下から評価用データを取得したケースでは、信号制御情報をモデルに導入することで、予測



(a) 予測対象リンク 1 の予測結果



(b) 予測対象リンク 2 の予測結果

図-6 信号制御情報利用時の予測結果  
(検証 5 日目・評価用データ：実際の運用)

精度が悪化する結果となった。これらの結果から、提案モデルは複数の時系列交通量間の依存関係や、現実には発生した範囲内での信号制御情報と交通量との対応関係を学習したことが示唆される。

本研究での提案モデルは、道路リンク間の接続関係に関する情報は明示的には組み込んでいない。道路リンク間の接続関係を明示的にモデルに導入することによって、時系列データの依存関係がより正確に抽出できる可能性がある。また、本研究では実際には発生していない状況での検証もあわせて行うために、シミュレーションを用いて提案手法の検証を行った。現実には取得できる水準のデータに限定した検証でも、精度の

向上が見られたことから、今後は実際の観測データのみを用いた検証が必要になると考えられる。

謝辞：本研究で利用した街路網交通流シミュレータ「AVENUE」は、株式会社 アイ・トランスポート・ラボよりご提供いただいた。また、本研究は JSPS 科研費 18H01551 の助成を受けたものである。

#### 参考文献

- 1) Vlahogianni, E., Karlaftis, M., Golias, J.: Short-term traffic forecasting: Where we are and where we're going, *Transportation Research Part C: Emerging Technologies*, Vol.43, No.1, pp. 3-19, 2014.
- 2) Ma, X., Dai, Z., He, Z., Ma, J., Wang, Y., and Wang, Y.: Learning traffic as images: A deep convolutional neural network for large-scale transportation network speed prediction, *Sensors*, Vol.17, No.4, p.818, 2017.
- 3) Tian, Y. and Pan, L.: Predicting short-term traffic flow by long short-term memory recurrent neural network, *2015 IEEE International Conference on Smart City/SocialCom/SustainCom (SmartCity)*, pp.153-158, 2015.
- 4) Ma, X., Tao, Z., Wang, Y., Yu, H., and Wang, Y.: Long short-term memory neural network for traffic speed prediction using remote microwave sensor data, *Transportation Research Part C: Emerging Technologies*, Vol.54, pp.187-197, 2015.
- 5) Hochreiter, S. and Schmidhuber, J.: Long short-term memory, *Neural Computation*, Vol.9, No.8, pp.1735-1780, 1997.
- 6) Greff, K., Srivastava, R. K., Koutnik, J., Steunebrink, B. R., and Schmidhuber, J.: Lstm: A search space odyssey, *IEEE Transactions on Neural Networks and Learning Systems*, Vol.28, No.10, pp.2222-2232, 2017.
- 7) Gers, F. A., Schmidhuber, J., and Cummins, F. A.: Learning to forget: Continual prediction with lstm, *Neural Computation*, Vol.12, pp.2451-2471, 2000.
- 8) 公益財団法人日本道路交通情報センター：各種情報の提供, <http://public-data.jartic-raws.durasite.net/opendata.html>.

(2019. 3. 10 受付)

## SHORT-TERM TRAFFIC VOLUME PREDICTION OF URBAN NETWORK USING DEEP LEARNING WITH TRAFFIC SIGNAL CONTROL INFORMATION

Ryo MASUDA, Ryo INOUE