

# 交通データの時空間相関を考慮した 深層学習による地域の交通状態の短期的予測

木曾 俊輔<sup>1</sup>・井上 亮<sup>2</sup>・馬場 静羽<sup>3</sup>

<sup>1</sup> 学生会員 東北大学博士前期課程 大学院情報科学研究科人間社会情報科学専攻  
(〒980-8579 仙台市青葉区荒巻字青葉 6-6-06)

E-mail: shunsuke.kiso.q8@dc.tohoku.ac.jp

<sup>2</sup> 正会員 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  
(〒980-8579 仙台市青葉区荒巻字青葉 6-6-06)

E-mail: rinoue@tohoku.ac.jp

<sup>3</sup> 学生会員 東北大学博士前期課程 大学院情報科学研究科人間社会情報科学専攻  
(〒980-8579 仙台市青葉区荒巻字青葉 6-6-06)

E-mail: shizuha.baba.s5@dc.tohoku.ac.jp

交通状態予測において深層学習の活用が注目されている。深層学習は多変量データが有する特徴を自動で抽出することができるため、様々な予測問題に対して優れた性能を発揮しており、交通状態予測に対する有用性も確認されている。しかし、既往の深層学習に基づく交通状態予測の大半は、交通流の時間的・空間的性質の片方のみに着目した地点単位の分析に限られ、交通流の時空間的性質を考慮した地域単位での分析はほとんど行われていない。そこで、本研究では、道路網の交通データを地域単位で集計した交通変数を利用し、地域間の隣接関係を考慮する Graph Convolutional Network と地域ごとの時間的特徴抽出を行う Long Short-Term Memory で構成した、交通流の時空間的性質を考慮した交通状態の短期的予測を検討し、那覇市内の一般道の交通観測データに対する適用を通して、提案手法が高い予測性能を有することを確認した。

**Key Words:** *deep learning, traffic state prediction, Macroscopic Fundamental Diagram, Graph Convolutional Network, Long Short-Term Memory, spatiotemporal analysis*

## 1. はじめに

交通渋滞は、道路利用者の所要時間の増加による時間的損失や、燃料消費の増加による環境負荷をはじめとして、大きな社会的損失の要因となることから、世界中で解決すべき問題として認識されている。特に、都市部を中心に交通渋滞は頻発しており、渋滞緩和に対する取り組みは社会にとって重要である。

即時的な情報提供や交通制御など道路交通の円滑化を目指した高度な道路サービスにおいて、将来の交通状態に関する情報の重要性は高い。特に、数分から数時間先の短期的交通状態予測は、道路利用者の経路選択や、道路管理者の意思決定において、利用価値は非常に高いため、短期的な交通状態予測手法が数多く提案されている。

近年、予測手法の一つとして、膨大なデータに内在する特徴量を自動で抽出できる深層学習が注目されている。車両感知器の整備やプローブ車両の普及に伴う、データ

の収集環境や情報処理技術の発展により、利用できる交通データが増加したことで、交通状態予測の分野でも深層学習を用いたモデルの提案が行われている。

交通流には、ある場所の交通状態は、1 日を通して周期性を有し、過去の交通状態の影響を受け、時系列相関を有するという時間的性質や、ある場所の交通状態は周辺の交通状態の影響を受けるという空間的性質が存在する。既往研究<sup>1,2)</sup>では、交通流の性質を考慮する手法が提案されているが、時間的・空間的性質の双方を考慮した手法の検討は少ない。しかし実際には、周辺の交通状態の影響が時間をおいて伝播するというように、双方の性質が同時に存在する。そのため、交通流の時空間的性質を考慮した手法の検討が必要である。

また、交通状態の予測結果を、渋滞緩和を目指す交通制御に利用することを考えると、制御を実施する空間単位の交通状態に関する情報が必要となるが、ほとんどの

既往研究は地点単位での交通状態予測を行っており、地点単位で得られた予測結果の利用価値は乏しい。

さて、巨視的な交通状態指標として、地域の車両存在台（平均交通密度）とトリップ完了率（平均交通量）の関係を表す Macroscopic Fundamental Diagram (MFD)<sup>3)</sup> が提案され、都市内一般道路網における MFD の存在が確認されている<sup>4)</sup>。MFD は、地域の交通状態を把握し、地域単位の交通制御に活用可能な指標である。例えば、ある地域の平均密度が MFD の臨界密度を超えると予想された時に、臨界密度以下に平均密度を保つような制御を行うことにより、地域内が渋滞状態に陥ることを回避できる。そのため、MFD 上の交通変数間の関係を反映できる地域単位の交通状態予測の検討は有意義だと考える。

以上を踏まえ、本研究は、地域単位で集計された交通データを利用し、地域間の接続関係と、地域間の相関を考慮した深層学習による短期的交通状態予測モデルの提案と、実データを用いた予測性能の検証を行う。

## 2. 深層学習を用いた交通状態予測に関する既存研究

### (1) 既存研究

Tian and Pan<sup>5)</sup> や Cai et al.<sup>6)</sup> は、時系列データの処理に適した Long Short-Term Memory (LSTM)<sup>7)</sup> を使用して、交通流の時間的性質を考慮した手法を提案した。LSTM によりデータが有する時系列相関を学習できるため、他の交通状態予測手法と比較して予測精度が高いことを確認している。また、吉田・井上<sup>8)</sup> は、グラフ構造を有するデータに対して、その構造を考慮した畳み込み演算を行う Graph Convolutional Network (GCN)<sup>9)</sup> を用いて、道路ネットワークの接続関係を考慮した予測手法を提案し、順伝播型ニューラルネットワークモデルと比較して少ないパラメータ数で同等の予測精度を実現した。しかし、これらの研究では、交通流の時間的性質・空間的性質の双方を考慮した検討が行われておらず、交通状態の特徴抽出をする上で不十分であるといえる。

馬場・井上<sup>10)</sup> は、地域単位で集計した交通データを利用、予測対象地域とその周辺地域のデータを LSTM に入力し、交通流の時空間的性質を考慮した予測を行うモデルを提案した。しかし、モデル内で地域の接続関係などの空間的特徴を明示的に表現しておらず、交通流の空間的特徴抽出という点で不十分である。

Zhao et al.<sup>11)</sup> は、GCN と、時系列モデルの予測に適した GRU を組み合わせた交通流の時空間的特徴を考慮したモデルを提案している。しかし、地点単位の単一の交通変数のみを用いた分析に限定されており、複数の交通変数間の関係を考慮した地域レベルでの特徴抽出という

点で、検討が不十分である。

### (2) 地域間の接続関係を考慮した畳み込み演算を行うニューラルネットワーク

道路ネットワークのリンクや路線の接続関係は、そのネットワーク上の交通流に大きな影響を与えている。そのため、道路ネットワーク上のリンク等の接続関係を明示的にモデル化した空間的特徴を捉えた畳み込み演算は、交通状態予測において有用だと期待できる。

Kipf and Welling<sup>9)</sup> は、GCN と呼ばれるグラフ構造を有するデータの接続関係を考慮した畳み込み演算を行うモデルを提案した。グラフは、ノード自体の性質を表す特徴量と、エッジで表されるノード間の隣接関係を示す特徴量を有している。GCN は、注目ノードに対して、隣接関係を有するノードの特徴量に重み付けして和を取る、畳み込み演算をする。畳み込み演算を 2 回行う場合、2 回目の畳み込みは、1 回目の畳み込みでその隣接ノードの特徴量を取り込んだノードに対して畳み込み演算を行うため、注目ノードと 2 次の隣接関係にあるノードの特徴量も畳み込むことができる。

以上のように、GCN の畳み込み層を増やすと、グラフ全体の情報を考慮した学習が可能となり、道路ネットワークの特徴を考慮した演算が可能となる。

グラフ上のノード  $i$  を  $v_i$ 、ノードの集合を  $V$ 、エッジの集合  $E$  を用いてグラフ  $G = (V, E)$  と表現する。

ニューラルネットワークの第  $l$  層の出力を  $H^{(l)}$ 、第  $l+1$  層の出力を  $H^{(l+1)}$  としたとき、第  $l+1$  層における畳み込み演算を式(1)で示す。

$$H^{(l+1)} = \sigma \left( \tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^{(l)} W^{(l)} \right) \quad (1)$$

ここで、 $\tilde{A}(= A + I)$  は、グラフ  $G$  の自己接続を有する隣接行列、 $I$  は単位行列である。また、 $\tilde{D}_{ii}(= \sum_j \tilde{A}_{ij})$  は、隣接行列  $\tilde{A}$  の次数行列（頂点に接続する枝の数に関する情報を含む対角行列）、 $W^{(l)}$  は第  $l$  層における重み行列、 $\sigma$  は活性化関数を表す。活性化関数として一般的に、ReLU を利用する。

## 3. 提案手法

本研究は、道路ネットワークを分割し、分割した地域間の接続関係、及び、接続する地域間の相関を考慮した地域単位での短期的交通状態予測手法を提案する。モデルの入力に、道路網全体の交通状態を捉える巨視的な交通状態指標として車両存在台数・走行台キロを使用し、一定時間後の交通状態を出力するモデルとする。

提案モデル (図-1) の特徴は、GCN を用いた地域間の接続関係と、接続地域のデータ間の相関関係の明示的な

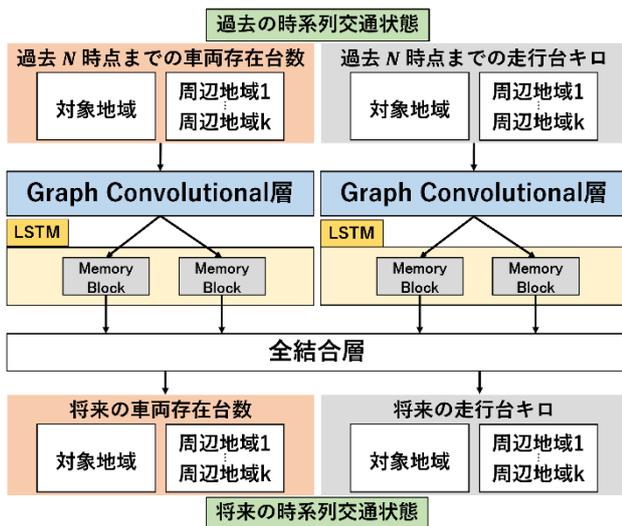


図-1 提案モデルの全体像

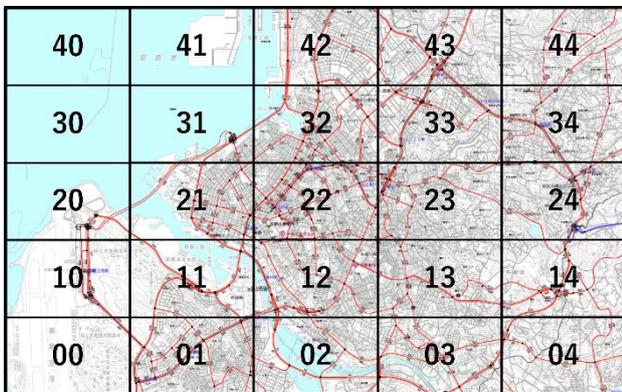


図-2 分析対象範囲と地域分割

表現と LSTM を用いた交通変数の時系列パターンの表現を合わせた交通流の時空間的性質を考慮した予測と、全結合層を用いた 2 種類の交通変数間の関係を考慮した予測ができる点である。

### (1) 交通流の空間的特徴抽出

地域間の接続関係と接続地域間のデータの相関を重み付き接続行列で表現する。本研究では、地域間の接続関係を定義するうえで、分割した地域が地図上では隣接していても、道路リンクが直接つながっていない地域間は接続しないものとして行列を定義した。

対象地域の接続関係を表すグラフを  $G$ 、ノードの集合を  $V$ 、エッジの集合を  $E$ 、接続行列  $A$  の  $(i, j)$  成分を  $a_{i,j}$  とする。なお、本研究は、地域の接続関係を考慮することによる予測精度への効果検証と、接続地域間の相関を考慮することによる予測精度への効果検証を行う。そこで、接続関係のみを考慮するモデルの接続行列を、式(2)で定義する。

$$a_{i,j} = \begin{cases} 1 & ((i, j) \in E) \\ 0 & (\text{otherwise}) \end{cases} \quad (2)$$

また、接続する地域間の相関を考慮するモデルの、接続行列の重みは、接続する地域間の交通データの相関係数を設定し、式(3)で定義する。

$$a_{i,j} = \begin{cases} x_{i,j} & ((i, j) \in E) \\ 0 & (\text{otherwise}) \end{cases} \quad (3)$$

$x_{i,j}$  : 接続地域  $i, j$  間の時系列データの相関係数

### (2) 交通変数間の特徴抽出

Ma et al.<sup>12)</sup>は、速度の予測時に、速度に加えて、交通量を用いることで、予測精度が改善することを確認した。また、馬場・井上<sup>10)</sup>も、地域単位で集計した 2 種類の交通変数を入力することで、深層学習モデルが交通変数間の関係を学習し、単一の変数を用いた予測結果よりも予測精度が改善したことを確認した。このように、複数交通変数の利用によって、変数間に内在する関係を学習した予測精度の向上が期待される。

以上を踏まえ、本研究の提案モデルでも、複数の交通変数間の関係を学習できるモデルを構築した。具体的には、入力として利用した交通変数毎に交通流の時空間的特徴抽出を行い、その後全結合層で交通変数間の関係の特徴抽出を行う。

## 4. 分析対象と提案モデルの性能評価方法

### (1) 分析対象

沖縄県警が設置した車両感知器による観測データを分析に使用する。対象期間は 2012 年 7 月から 2013 年 3 月までの 9 か月間とし、気象庁那覇気象台の日降水量が 0mm、かつ、土日・休日・お盆・年末年始を除く平日 100 日を対象とし、前半 80 日を学習用、後半 20 日を検証用とする。対象範囲は、371 箇所の感知器がある那覇市周辺の約 10 km 四方の領域 (図-2) とし、その範囲を約 2km 四方の地域に分割する。

VICS リンク毎に観測された 5 分毎の断面交通量と平均速度データを地域毎・10 分間隔に集計し、車両存在台数と走行台キロを求める<sup>13)</sup>。時間帯  $t$  に感知器  $i$  で観測されたリンク断面交通量を  $q_i^t$ 、車両速度を  $v_i^t$ 、リンク下流端が対象地域内にある、感知器が設置されているリンクの集合を  $I$ 、リンク  $i$  の長さを  $l^i$  とするとき、時間帯  $t$  の対象地域内の車両存在台数  $N_t$  を式(1)、走行台キロ  $P_t$  を式(2)で集計する。

$$N_t = \sum_{i \in I} (q_i^t / v_i^t) l^i \quad (4)$$

$$P_t = \sum_{i \in I} q_i^t l^i \quad (5)$$

## (2) 予測手法と予測精度の評価方法

目的関数を、モデルによる 30 分後の予測値と観測された車両存在台数との平均二乗誤差 (Mean Squared Error: MSE) とし、最適化アルゴリズムは Adam を使用した。また、バッチサイズは 100, 最大エポックは 10,000 とし、検証用期間の MSE が直近 10 エポックで改善しない場合は早期終了させた。

モデルの予測精度は、検証用期間の予測値と観測値との平均平方二乗誤差 (Root Mean Squared Error: RMSE) (式(6)) と、平均絶対誤差率 (Mean Absolute Percentage Error: MAPE) (式(7)) で評価する。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (6)$$

$$MAPE = \frac{1}{n} \sum_{k=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (7)$$

## 5. 提案モデルの性能評価

提案モデルの性能を、比較モデルを用いた 2 段階の分析を通して評価する。

まず、地域間接続関係の考慮による予測精度改善効果を検証する。接続行列で接続地域間の重みを 1 に固定し、GCN で地域間の接続関係を考慮したモデル (提案モデル 1) と、提案モデルの Graph Convolutional 層の代わりに全結合層を用いた地域間の接続関係を明示的に考慮しないモデル (比較モデル) の予測性能を比較する。提案モデル 1 と比較モデルは、両者とも同じ入力データを用いて学習し、GCN を用いて地域間の接続関係を明示的に表す効果を確認できる。

続いて、接続地域のデータ間の相関を考慮することによる予測精度改善効果を検証する。検証では、先述の接続地域間のデータの相関を考慮せず、重みを 1 に固定した接続行列を用いたモデル (提案モデル 1) と、接続地域間の相関係数を重みとして定義した接続行列を用いたモデル (提案モデル 2) の比較を通して、接続地域間の相関を考慮した提案モデルの予測性能を評価する。

提案モデルのハイパーパラメータは、Graph Convolutional 層の層数とユニット数、LSTM のユニット数の 3 種類である。LSTM のユニット数は {32, 64, 128}、Graph Convolutional 層の層数  $l$  は {2, 3}、1 層目のユニット数  $n$  は {16, 32} の中から試行した。また、比較モデルの全結合層のユニット数  $n$  は {200, 300} とした。全結合層の層数  $l$ ・LSTM のユニット数  $u$  は提案モデルの候補と同数として試行した。また、出力層の手前の全結合層のユニッ

ト数はすべてのモデルで {40} で固定して試行した。

以下の検証では、那覇市の中心市街地を含み交通量が多い、地域 22 (図-2) を予測対象とする。また、モデルへの入力データは走行台キロ・車両存在台数とし、30 分後の車両存在台数の予測値で性能評価する。

### (1) 地域間の接続関係考慮による予測精度改善の検証

各モデルの予測精度を表-1、学習時に更新される総パラメータ数と、モデルが学習に要する計算時間を表-2、選択されたハイパーパラメータを表-3、検証期間 9 日目の予測結果を図-3 に示す。

表-1 より、提案モデルは比較モデルより高い予測精度を実現したことが確認できる。また、表-2 より、提案モデルは、パラメータ数が比較モデルと比べて大幅に少ないシンプルなモデルとなっており、短い計算時間で学習・予測ができていくことがわかる。

交通状態には 1 日を通して周期性があり、時間帯ごとに特徴的な交通流の変動が見られる。提案モデルは、朝・夕の交通量の特徴的な増減を捉えられている上、昼間の変動も追従できた (図-3)。一方、比較モデルは、深夜～朝のピーク時間帯の変動傾向は捉えられているものの、昼間の時間帯や、夕ピーク後の交通量が減少する時間帯における予測のズレが、提案モデルと比べて大きいことが確認された。

これは提案モデルが、地域間の接続関係を明示的にモデル化し、Graph Convolutional 層で道路網の地域間に存在する交通状態の空間相関を、LSTM で交通状態の時間的相関を学習したことで、交通流の時空間的特徴抽出ができたと考えられる。対して、比較モデルは、LSTM によって、交通状態の変動パターンの傾向は学習できているが、入力された地域毎のデータ間で接続関係に基づく明確な区別がないため、地域間の交通状態の特徴抽出が不十分であったと考えられる。特に、朝・夕方のピーク時間帯にかけて増加する、1 年を通して同様の変動を示す時間帯の交通流パターンに関しては、比較モデルでも観測値に近い予測ができていくが、昼間の交通流の変動のように日による変動が大きい時間帯では、2 モデルの予測精度に差が見られる。これは、提案モデルでは、予測対象地域の時系列相関に加えて、接続している地域間の空間相関を学習することができ、日変動の大きい時間帯においても予測値が概ね追従できたと考えられる。

表-1 各モデルの予測精度の比較

	RMSE [台]	MAPE [%]
提案モデル 1	65.71	10.00
比較モデル	78.93	11.53

表-2 各モデルの総パラメータ数と計算時間

	総パラメータ数	計算時間 [s]
提案モデル 1	164,152	59.80
比較モデル	641,634	128.55

表-3 各モデルの選択されたハイパーパラメータ

	$u$	$l$	$n$
提案モデル 1	128	3	16
比較モデル	64	3	300

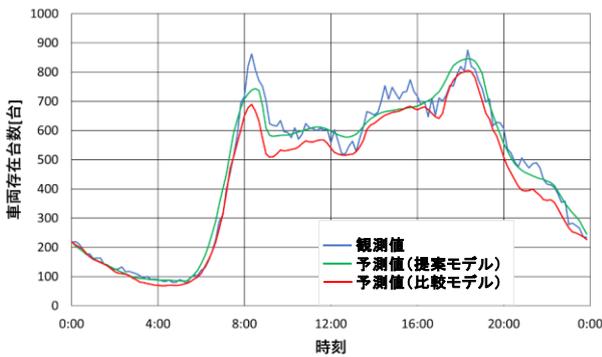


図-3 各モデルの車両存在台数の予測結果

表-4 各モデルの予測精度の比較

	RMSE [台]	MAPE [%]
提案モデル 1	58.82	8.85
提案モデル 2	65.71	10.00

表-5 各モデルの選択されたハイパーパラメータ

	$u$	$l$	$n$
提案モデル 1	128	2	32
提案モデル 2	128	3	16

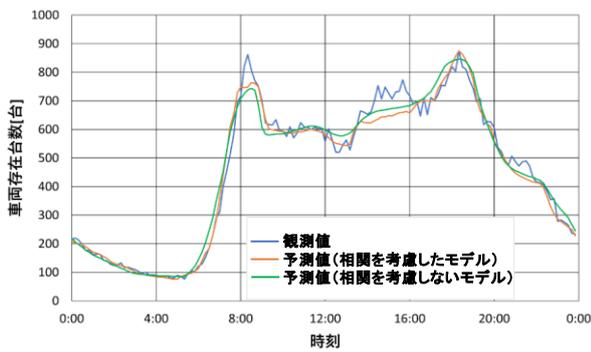


図-4 各モデルの車両存在台数の予測結果

(2) 接続する地域間の相関を考慮した予測の検証

提案モデル 1・2 の予測精度を表-4、選択されたハイパーパラメータを表-5、車両存在台数の予測結果を図-4、2 種類の交通変数の予測結果の関係を図-5・6 に示す。

表-4 より、接続する地域間の相関を考慮したモデルの予測精度が高いことが確認できる。

また、図-4 より、接続地域間の相関を考慮したモデルは 1 日を通して観測値に近い予測ができていることが確認できる。特に、朝・夕のピーク時間帯の特徴的な増減パターンについて、高い予測精度を実現している。

(3) 考察

まず、地域間接続関係の考慮による予測精度改善効果に着目する。比較モデルと比べて少ないパラメータ数かつ短い計算時間で提案モデルが優れた予測精度を示した。特に、日変動の大きい昼間の時間帯における精度に差があり、提案モデルの精度が高いことが確認された。これは、地域間の接続関係を明示的に表現することで、予測対象地域に加えて、接続地域の交通流の時空間的特徴を学習できたためだと推測される。

続いて、接続地域のデータ間の相関考慮による予測精度改善について考察する。今回設定した接続地域の相関係数の値を見ると、相関の強い地域同士では 0.95 を超える値であるのに対し、相関の弱い地域同士では 0.65 を下回る値が存在し、明らかに地域間の相関関係に違いがある。このことから、接続地域間の重みを 1 に設定したモデルとはモデルの構造が異なり、地域間の接続関係だけでなく、接続する地域間の相関の強弱といった交通状態の関係性を明示的に示すことで、モデルが都市道路網の空間的な交通特性を学習し、予測精度が改善したと考えられる。

6. おわりに

本研究は、地域単位に集計した巨視的な交通状態指標に着目し、集計した地域間の接続関係を考慮した地域単位の交通状態予測手法を提案した。提案モデルは、地域間の接続関係を明示的に表現し、時系列交通データを使用することで、地域単位での交通流の時空間的特徴を考慮した学習ができるモデルとなっている。

那覇市周辺の一般道路網で観測された交通データを地域単位で集計した上で、提案モデルの性能検証を行った。提案モデルは、地域間の接続関係を考慮することによる予測精度改善効果の検証で、比較モデルと比べて少ないパラメータ数で高い予測精度を実現することが確認された。この結果から、地域間の接続関係を明示的に表現し、時系列交通データを入力として利用することで、地域間に存在する空間的相関と、交通流の時間的相関を学習し、交通流の時空間的特徴を抽出できた可能性が示唆される。さらに、提案モデルにおいて、接続地域間のデータの相関を明示的に表した接続行列を使用する効果を検証した結果、相関を考慮しないモデルと比べて予測精度が向上することが確認された。このことから、地域間の接続関係だけでなく、接続地域間の交通状態の関係の強弱を明

示的に与えると、モデルが都市道路網の交通特性を学習しやすくなり、予測精度向上を図ることができることが示唆される。

今後の課題として、以下の2点が挙げられる。1つは、分析する地域の適切な設定の検討である。今回の実験では、那覇市周辺の10km四方の地域を2km四方の地域に分割して分析を行った。分析において、地域を小さくしすぎると、各地域の交通変数の日変動が大きくなり、予測精度の低下といった問題が想定されることから、適切な地域設定が必要となるが、本研究では十分な検討ができていない。そこで、今後は提案モデルの適用可能な範囲の検討が必要である。

2つめに、より頑健性の高い予測モデルの検討である。本研究では、降水量0mm・平日という理想的な環境における予測精度の検討を行ったが、実際の交通流は、天気や曜日、周辺のイベントや突発的な事故といった様々な状況が存在する。そのため、そうした様々な状況下の交通状態における予測精度の向上が見込める、頑健性の高い予測モデルの検討が必要であると考えられる。

**謝辞**：本研究で使用した交通感知器データは、(公財)日本道路交通情報センターより提供された。また、本研究はJSPS 科研費 18H01551 の助成を受けた。

#### 参考文献

- 1) Zhao, Z., Chen, W., Wu, X., Chen, C. Y. P., and Liu, J.: LSTM network: a deep learning approach for short-term traffic forecast, *IET Intelligent Transportation Systems*, Vol. 11, No. 2, pp. 68-75, 2017.
- 2) Luo, X., Li, D., Yang, Y., and Zhang, S.: Spatiotemporal traffic flow prediction with KNN and LSTM, *Journal of Advanced Transportation*, Vol. 2019, pp.1-10, 2019.
- 3) Daganzo, C. F.: Urban gridlock: Macroscopic modeling and mitigation approaches. *Transportation Research Part B*, Vol.41, No.1, pp.49-62, 2007.
- 4) Geroliminis, N. and Daganzo, C. F.: Existence of urban scale macroscopic fundamental diagrams: Some experimental findings. *Transportation Research Part B*, Vol.42, No.9, pp.759-770, 2008.
- 5) 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.
- 6) Cai, L., Lei, M., Zhang, S., Yu, Y., Zhou, T., and Qin, T.: A noise-immune LSTM network for short-term flow forecasting, *Chaos*, Vol. 30, No. 3, pp. 1-10, 2020.
- 7) Hochreiter, S. and Schmidhuber, J.: Long short-term memory, *Neural Computation*, Vol.9, No.8, pp.1735-1780, 1997.
- 8) 吉田幸司, 井上亮: 道路リンクの接続関係を考慮した畳み込みニューラルネットワークによる自動車交通量の短期予測の検討. 土木学会論文集 D3 (土木計画学), Vol.75, No.5, pp. I\_1059-I\_1067, 2019.
- 9) Kipf, T. N. and Welling, M.: Semi-supervised classification with graph convolutional networks, *International Conference on Learning Representations (ICLR)*, 2016.
- 10) 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 (特集号), Vol.7, No.2, pp. A\_110-A\_118, 2021.
- 11) Zhao, L., Song, Y., Zhang, Y. L., Wang, P., Lin, M.D., Li, M.: T-GCN: A temporal graph convolutional network for traffic prediction, *IEEE Transaction on Intelligent Transportation Systems*, Vol.21, No.9, pp.3838-3858, 2020.
- 12) 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.
- 13) 王鵬飛, 赤松隆, 和田健太郎: Macroscopic Fundamental Diagram における渋滞領域発生メカニズムに関する実証研究, 土木計画学研究・講演集, Vol. 51, No. 156, 2015. (2021. 10. 1 受付)

## SHORT-TERM PREDICTION OF LOCAL TRAFFIC CONDITION CONSIDERING SPATIOTEMPORAL CORRELATION OF TRAFFIC DATA BY DEEP LEARNING

Shunsuke KISO, Ryo INOUE and Shizuha BABA

The use of deep learning in traffic prediction has been attracting much attention these days. Since deep learning can automatically extract relationships among multivariate data, it has demonstrated excellent performance for many types of prediction and its usefulness for traffic prediction has also been confirmed. However, most of the previous traffic prediction methods based on deep learning focus on the spatial or temporal characteristics of traffic flow, although the traffic flow has both spatial and temporal characteristics. This study proposes a short-term traffic prediction method that considers the spatio-temporal characteristics of traffic flow. The proposed method is composed of Graph Convolutional Network that considers neighboring relationships among regions and LSTM that extracts temporal features for each region. The proposed method was applied to the traffic observation data of a road network in Naha City, and it was confirmed that the proposed method has high prediction performance.