

道路ネットワークの路線間接続関係を考慮した 深層学習による交通状態の短期的予測

木曾 俊輔¹・井上 亮²

¹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

²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

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路線単位で集計した交通変数を利用し、路線間の接続関係を考慮する Graph Convolutional Network と路線毎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手法を提案した。首都高速道路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, connectivity of road network, Graph Convolutional Network, Long Short-Term Memory*

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。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。

リアルタイムな交通制御や情報提供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。そのため、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^{1,2)}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。

ここで、道路ネットワークの交通状態を路線単位で分析する場合を考える。ある路線の交通状態は、接続関係を有する他路線との間で相互に影響を与え、その度合いは路線間の接続関係によって異なる。そのため、路線間の接続関係を明示的に表現し、道路ネットワークの空間的特徴を考慮可能なモデルの検討が必要である。

以上を踏まえ、本研究では、道路ネットワークの路線間の接続関係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、路線単位で集計した交通データを用いた提案モデルの検証を目的とする。

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 Pan³⁾, Cai et al.⁴⁾ は、時系列データの処理に適した Long Short-Term Memory (LSTM)⁵⁾ 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ている。LSTM を用いることで、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⁶⁾ 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)⁷⁾ 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⁸⁾ 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、モデル内で地域の隣接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。

(2) 路線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特徴を捉えるうえで、リンク・路線間の接続関係は重要な情報であり、交通流の特徴抽出において有用である。そのため、道路ネットワークの接続関係を明示的にモデル化し、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であると期待できる。

Kipf and Welling⁷⁾ 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、 σ 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、道路ネットワークの路線間接続関係を考慮した路線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、路線全体の交通状態を捉える巨視的な交通状態指標として Macroscopic Fundamental Diagram (MFD)^{9,10)} で表される車両存在台数・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 を用いた路線間の接続関係の明示的な表現と LSTM を用いた交通変数の時系列パターンと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) 交通流の時空間的特徴抽出

提案モデルは、GCN を用いて道路ネットワークの接続関係を明示的に表し、また、重み付き隣接行列を定義して、路線間の接続関係と、接続している路線間のデー

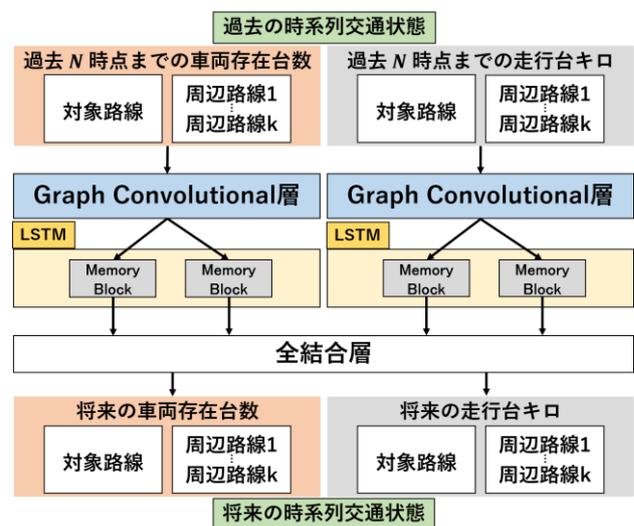


図-1 提案モデルの全体像



図-2 分析対象路線

タの相関を考慮する。

対象路線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 、隣接行列 A の (i, j) 成分を $a_{i, j}$ とし、式(2)で隣接関係を定義する。

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

なお、隣接行列の重みは、接続する路線間の交通データの相関係数を設定した。

(2) 交通変数間の特徴抽出

Ma et al.¹²⁾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⁷⁾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

提案モデルを、2014年1月から7月に首都高速道路で観測された、日降水量0mmの平日60日の交通データを用い、48日を学習用、12日を検証用として分割し分析

を行う。図-2に示す分析対象路線の本線上に設置された感知器による1分毎の断面交通量と平均速度を、分析対象路線毎に10分間隔で集計した車両存在台数と、走行台キロを使用する。なお、都心環状線を除く9路線は、中央環状線の内側に設置された感知器による観測データを対象とする。

(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200、最大エポックは10,000とし、検証用期間のMSEが直近50エポックで改善しない場合は早期終了させた。モデルの予測精度の評価は、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(3))と、平均絶対誤差率 (Mean Absolute Percentage Error: MAPE) (式(4))を用いる。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (3)$$

$$MAPE = \frac{1}{n} \sum_{k=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (4)$$

5. 提案モデルの性能評価

提案モデルの性能を2段階に分けて評価する。なお、提案モデルの比較対象として、提案モデルのGraph Convolutional層を全結合層に変更したモデルを設定し、提案モデルの予測性能を評価する。比較モデルは、周辺路線の情報を含めた学習はできるが、モデル内で道路ネットワークの接続関係を表現できないため、路線毎の区別がなく道路ネットワークの空間的特徴を考慮した学習はできないモデルである。この比較モデルと、提案モデルの予測精度を比較し、路線間接続関係の反映による予測精度改善効果の検証を行う。

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。なお、Graph Convolutional層のユニット数は、前層の2分の1とし、層を重ねるごとにユニット数が小さくなる設定とした。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{100, 200, 300}としすべての層のユニット数を同数とした。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、すべてのモデルに共通して、出力層の手前の全結合層のユニット数は{40}で固定して試行した。

まず、入力に車両存在台数のみを用いた単一変数モデルの予測で、路線間接続関係の考慮による予測精度改善効果を検証する。次に、入力に車両存在台数と走行台キロを用いた複数変数モデルの予測を通して、路線間接続関係と複数交通変数間の関係の反映による予測精度改善効果を検証する。なお、両検証において、予測対象路線として都心環状線内回りを設定した。

(1) 車両存在台数のみを用いた予測

入出力に車両存在台数のみを用いた単一変数モデルを設定し、路線間接続関係の考慮による予測精度改善効果に着目して検証した。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3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~朝の時間帯の変動傾向は捉えられているものの、日中は予測が大きく外れていることが確認された。

これは提案モデルが、路線間の接続関係を明示的にモデル化し、Graph Convolutional 層で道路ネットワークの路線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、交通状態の大まかな時間間隔における変動パターンの傾向は学習できているが、入力された路線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、路線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、朝の増加や、夕方の減少といった1年を通して同様の変動パターンを有する、周期性のある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たが、昼間の交通流の変動といった日による変動が大きく、決まった周期性が見られない時間帯で2つのモデルの予測精度に大きな差が見られる。これは、提案モデルでは、予測対象路線の時系列相関に加えて、接続している路線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	1687.78	10.05
比較モデル	2952.72	18.01

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	29060	57.15
比較モデル	413008	188.83

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	64	2	32
比較モデル	128	3	300

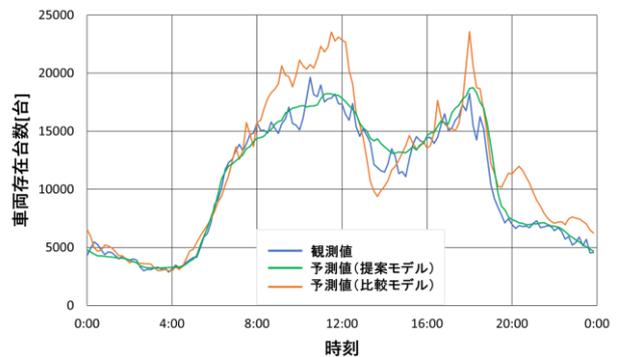


図-3 各モデルの車両存在台数の予測結果

(2) 車両存在台数・走行台キロを用いた予測

本節では、入出力に車両存在台数と走行台キロの2種類の交通変数を用いたモデルを設定し、路線間接続関係の考慮による予測精度改善効果と、交通変数間の関係の反映による予測精度改善効果に着目した検証を行う。なお、モデルの性能評価は、車両存在台数の予測値を用いて評価した。

各モデルの予測精度を表-4、総パラメータ数と計算時間を表-5、選択されたハイパーパラメータを表-6、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。

(1)と同様に、提案モデルが予測精度が高く(表-3)、パラメータ数も大幅に少なく、計算時間も約3分の1程度と高速で予測ができていことが確認できる。

図-4より、提案モデルは1日を通して観測値に近い予測ができていことが確認できる。特に、朝・夕の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。対して、比較モデルでは、朝の時間帯や夜の時間帯の予測精度は高いが、昼間の時間帯や、夕方の時間帯における予測精度が低いことが確認できた。

図-5・6より、提案モデルの予測結果は交通変数間の

関係を捉えることができているのに対し、比較モデルでの予測結果は、交通変数間の関係を十分に捉えることができていないことが確認できた。

続いて、単変数モデルによる予測結果との比較を行う。表-1・3 の比較より、両モデルともに複数変数モデルの予測精度が高いことがわかる。特に、比較モデルでの予測精度の向上は顕著である。図-3・4 を見ると、提案モデルでは、単変数モデルで精度が低かった夕方の時間帯の予測結果で向上が見られる。比較モデルでも、昼間の時間帯の予測精度が向上している。

(3) 考察

まず、路線間接続関係の考慮による予測精度改善効果に着目する。単一・複数変数モデルいずれの検証でも、比較モデルと比べてパラメータ数の少ない提案モデルが優れた予測精度を示した。これは、路線間の接続関係を明示的に表現することで、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、2 種類の交通変数の使用による予測精度への影響を考察する。単一変数モデルの予測結果と比較すると、提案モデル・比較モデルともに2種類の交通変数の使用によって予測精度が向上しており、モデルが交通変数間の関係を学習し、予測精度が改善したと考えられる。

6. おわりに

本研究は、道路ネットワークの路線間接続関係を考慮した路線単位の交通状態予測手法を提案した。

提案モデルは、道路ネットワーク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、交通流の時空間的特徴を考慮した学習が出来るモデルとなっている。

首都高速道路で観測された交通データを路線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、入力に単変数を用いる検証と、複数変数を用いる検証の双方で、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、路線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、路線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、複数変数を用いたモデルにおける予測精度が単変数モデルの予測精度を上回ったことから、提案モデルが交通変数間の特徴を学習し、予測精度が向上したことが示唆される。

今後の課題として、以下の2点が挙げられる。1つは、効果の検討である。本研究の提案モデルでは、高速道路

表-4 各モデルの予測精度の比較

	RMSE [台]	MAPE [%]
提案モデル	1636.41	9.33
比較モデル	2203.81	14.02

表-5 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	59,720	83.79
比較モデル	825,016	267.34

表-6 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	64	2	32
比較モデル	128	3	300

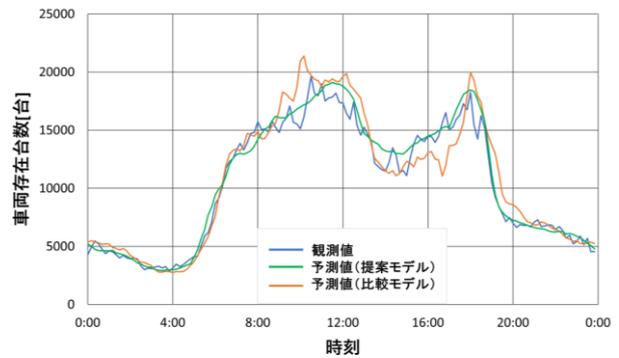


図-4 各モデルの車両存在台数の予測結果

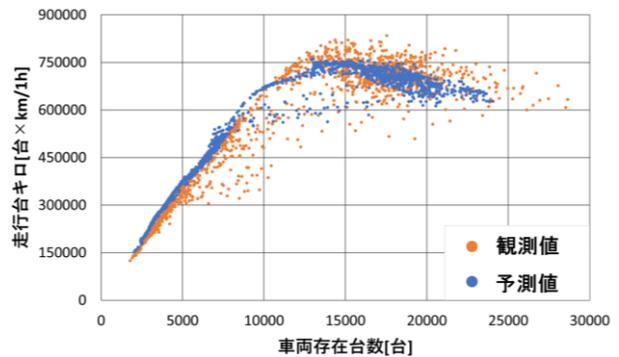


図-5 提案モデルの予測結果の交通変数間関係

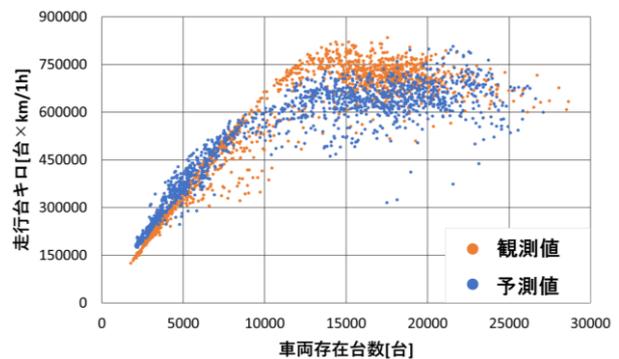


図-6 比較モデルの予測結果の交通変数間関係

接続関係の種類に関する情報の考慮による予測精度への路線毎の区別は行っているが、各路線の上下線に関する情報の区別は行っておらず、上り線・下り線毎に集計した時系列交通データを入力の際で明示できていない。しかし、実際の交通状態を考えると、高速道路の上り線と下り線では、交通パターンにも違いがあり、予測対象路線への影響も異なることが考えられる。そのため、接続関係を表現する際に、高速道路の上下線のような接続関係の種類を表現することで、予測精度が向上することが期待できる。

2 つめに、突発事象のようなイレギュラーな交通状態の変動に対する予測能力の向上である。本研究の提案モデルでは、交通流の大域的な変動を捉えた予測をしているが、細かな時間間隔での変動や、突発的な事象による急激な交通量の増加を予測できないという課題がある。都心部の交通量の多い高速道路では、突発的な事象による交通状態の変化が多く存在する。そのため、そうしたイレギュラーな事象への対応力のある頑健性の高い予測ができるモデルの有用性は高いため、提案モデルの突発事象に対応した予測能力の向上のための検討が必要であると考えられる。

謝辞：本研究を進めるにあたり、首都高速道路株式会社、日本道路交通情報センター（JARTIC）より貴重なデータをご提供いただきました。また、本研究は、JSPS 科研費 18H01551 の助成を受けました。ここに記し、感謝を表します。

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) 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) 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.
- 5) Hochreiter, S. and Schmidhuber, J.: Long short-term memory, *Neural Computation*, Vol.9, No.8, pp.1735-1780, 1997.
- 6) 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.
- 7) Kipf, T. N. and Welling, M.: Semi-supervised classification with graph convolutional networks, *International Conference on Learning Representations (ICLR)*, 2016.
- 8) 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.
- 9) Daganzo, C. F.: Urban gridlock: Macroscopic modeling and mitigation approaches. *Transportation Research Part B*, Vol.41, No.1, pp.49-62, 2007.
- 10) 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.
- 11) 酒井高良, 赤松隆: 首都高速道路網における渋滞パターンと Macroscopic Fundamental Diagram の安定性, 土木学会論文集 D3 (土木計画学), Vol.75, No.2, pp.97-108, 2019.
- 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.

(2021. 3. 7 受付)

SHORT-TERM TRAFFIC PREDICTION CONSIDERING CONNECTIVITY OF ROAD NETWORK BY DEEP LEARNING

Shunsuke KISO and Ryo INOUE

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 connectivity of road network and LSTM that extracts temporal features for each routes. The proposed methods was applied to the traffic observation of Tokyo Metropolitan Expressway and the performance for predicting traffic condition of routes was confirmed.