

交通状態を示す画像を活用した GNN による 交通渋滞予測に関する研究

風岡 駿宏¹・中村 俊之²・赤木 康宏³・森川 高行⁴

¹非会員 株式会社 日立製作所 社会システム事業部
(〒140-8572 東京都品川区南大井六丁目 27 番 18 号 日立大森第二別館)

E-mail: takahiro.kazaoka.vb@hitachi.com

²正会員 名古屋大学特任准教授 未来社会創造機構 (〒464-8601 名古屋市千種区不老町 1)

E-mail: tnakamura@mirai.nagoya-u.jp

³正会員 名古屋大学特任准教授 未来社会創造機構 (〒464-8601 名古屋市千種区不老町 1)

E-mail: akagi-y@coi.nagoya-u.ac.jp

⁴正会員 名古屋大学教授 未来社会創造機構 (〒464-8601 名古屋市千種区不老町 1)

E-mail: morikawa@nagoya-u.jp

コンピュータの計算能力の向上やデータの爆発的な増加といった複数の要因により、深層学習の予測精度が飛躍的に向上し注目を集めている。また、交通分野においてはリアルタイムの交通情報が過去と比較して、入手することが可能となったことを受けて、機械学習（深層学習）を用いた渋滞の予測の精度向上とその提供への期待が益々高まっている。本研究では京都市を対象とし、リアルタイムで入手可能な交通情報活用した GNN による交通渋滞予測手法の構築を行うものである。交通規制や交通事故などの情報と休日や気象などの交通量に変動を与えうる要因データを加味することで、渋滞予測精度が向上することが確認できた。提案手法では全国の交通情報をリアルタイムで提供する交通情報を利用して、環境を整備することで、近未来的には全国においてリアルタイムの渋滞予測を行うことが可能であり、期待される。

Key Words: congestion prediction, traffic information, deep learning, LSTM, GCN, graph convolution

1. はじめに

2000年頃よりデータが大量に蓄積されるようになり、2011年後半から2012年にかけてビッグデータブームが始まったとされる。さらに最近では、デバイスの小型化・計算能力向上や通信の高速化など、高度なデジタル技術の発展・普及により、日々蓄積されるデータ量に拍車がかかっている。

道路交通の分野にも、ビックデータの波が押し寄せている。スマートフォンやカーナビで利用可能な交通情報提供サービスにより、道路利用者が交通渋滞・事故・規制等の種々の交通情報をリアルタイムで入手することが可能となった。

こうしたリアルタイム交通情報提供サービスは、車両検知器やプローブデータ等のセンサーデータを通信で集約し、情報発信しており、特に後者のプローブデータは利用者が増加するほど、情報の信頼度が向上する特徴を有している。豊富な利用者数は蓄積データの増加に寄与

するだけでなく、データを分析・活用し、サービス向上に繋がり得る。

リアルタイム性の高い交通情報の提供は、情報利用者に新たな選択肢をもたらす。例えば、利用者が事故や規制などの交通情報や道路の混雑状況を逐次入手することが可能となり、予期せぬ渋滞に巻き込まれる確率は今よりも低く見積もることができる。

国土交通省の調査(2015)によると、全国で1年間に発生する渋滞損失は、貨幣換算すると10兆円にもなると試算されている。

渋滞緩和に向けたアプローチの一つとして、道路利用者への交通情報提供が挙げられる。情報の活用により、渋滞を避けるような行動が促されれば、需要が分散され、渋滞の緩和が期待される。

情報提供による渋滞緩和効果は、道路状況、交通情報利用者の割合等様々な要因により変動するため、必ずしも向上しない点に注意する必要がある。Yoshiiら²⁾によると、シミュレーションによる結果ではあるが、リアル

タイム情報の活割割合 80%程度までは、平均旅行時間が減少する結果が示されている。さらに同研究の予測情報の提供に関する項目によると、リアルタイム情報よりも大きな交通状況改善が見込まれるとされ、利用者に利便性をもたらすだけでなく、社会全体の渋滞の緩和に繋がり得る。

予測情報をもとに、道路管理者が動的な対策を実施すれば渋滞緩和につながり得る可能性もあり、予測情報は渋滞問題を軽減する手段として期待されている。

予測情報への期待と近年の計算技術の飛躍的な向上により、機械学習を用いた短期予測が交通分野においても多くの注目を集め、様々な手法が開発・提案されている。

機械学習の中でも深層学習的手法は予測問題に対し大きな可能性を秘めている。時系列予測に用いられる深層学習手法といえば Recurrent Neural Network (RNN) が挙げられるが、RNN の勾配消失問題を抑制した Long Short Term Memory (LSTM)^{3,4}や Gated Recurrent Unit (GRU) が、交通予測に効果的であるとされている。

しかし、交通渋滞は交通量の時間集中だけでなく、道路ネットワーク構造への依存も大きい。渋滞を予測する場合には、交通量の時間特性だけでなく、道路ネットワークの空間的な接続関係を考慮した方が、高精度な予測につながると考えられている。そのため、ネットワークの接続関係を考慮し、空間的關係を捉える手法として、Graph Neural Network (GNN) が知られている。GNN とはグラフ構造に対して行われる深層学習の総称であり、道路ネットワークをグラフ構造と捉えることにより適用可能となる。

GNN の派生手法がこれまで多数提案されているが、その中でも Graph Convolutional Network (GCN) が大きな注目を集めている。GCN とは、画像認識の分野で成功した「畳み込み演算」をグラフデータに対して拡張した手法である。画像認識における畳み込み演算は、周辺ピクセルを範囲的に捉えて特徴量を抽出する働きをしている。それをグラフ構造に適用することで、周辺ノードを空間的に捉えて特徴量を抽出することが期待される。

GCN を起用した交通量予測に関する既往の研究では、GRU に拡散畳み込み層を導入した Li らの Diffusion Convolutional Recurrent Neural Network (DCRNN)⁵、道路の畳み込み領域を複数考慮した Cui らの Traffic Graph Convolutional LSTM⁶など、実世界データでの予測で従来手法よりも高精度な結果を示し、時空間的特徴を捉えた深層学習の有用性を示した。

しかしながら、これらの研究では単一の入力のみで予測を行っており、交通量を変化させ得る他の要因を考慮できていない。

こうした踏まえて本研究では「リアルタイム交通情報提供サービスにより提供される交通情報データを活用し、

交通状態を変化させ得る複数の情報を入力とした GNN による渋滞予測手法の構築」を行い、精度検証を行う。

既往研究で用いられたインプットデータは、車両感知器により測定された過去の蓄積データであるが、測定データをリアルタイムで入手・利用可能であるのは、車両感知器の管理者に限られる。現在日本国内において車両感知器は、道路管理者や交通管理者ら等、すなわち、全国の都道府県警察や自治体等により各々で設置・管理されており、任意のエリアでリアルタイムに入手することは困難である。

一方で、多くの方が SA・PA などで見ることがあるリアルタイム交通情報提供サービスでは、誰もがリアルタイムに、かつ全国の任意のエリアで情報を取得できる。このリアルタイムに見えている状況を利用することができれば、事実上全国でリアルタイムでの渋滞予測の実施が可能となると言える。

その点で、本研究においては、リアルタイム交通情報提供サービスの交通情報、すなわち交通状態を示す画像から自らでリアルタイムにデータ収集を行うことで試みる。また、こうした交通情報提供サービスでは、渋滞情報だけでなく、事故や規制などの各種交通情報に関してもリアルタイムで情報提供されている利点がある。さらに本研究では交通状態を変動させ得る要因として、これらの各種交通情報に加えて、休日や降水量・気温などの気象データを併せて予測に用いる点に特徴を有している。

2. 対象地域と本研究で用いるデータ

(1) 対象地域と交通状態を示すの概要

リアルタイム交通情報提供サービスの交通情報データの活用にあたり、交通情報データの収集を行う必要があるが、リアルタイムで提供されているデータの中には取り扱いに注意すべきデータが存在する。例えば、Google が提供し、世界的にも広く利用されている「Google Maps」は、利用規約にてデータの蓄積に関わる行為全般を明確に禁止しており、分析に使用できない。

そこで本研究では、「JARTIC (日本道路交通情報センター)」の交通情報データを活用し、渋滞予測及び分析を行う。JARTIC はリアルタイムで全国の高速道路及び一般道路の交通情報を 24 時間 5 分更新 (1 日あたり 288 回更新) で提供している。更新されるとそれ以前の情報は閲覧不可となる。なお、この JARTIC の画像から交通情報を取得することの可否は事前に確認し、許諾を得ている。

提供されている交通情報データは、デフォルメされた地図を画像形式にして公開されている (図-1)。ある程度主要な道路により地図が構成されていた。ここで構成

されていたとしているのは、研究実施時において図-1に示す画像として提供されており、2021年9月時点では変更されていることを注意されたい。しかし本研究は一連の方法論を示し、精度検証を行うものである。

交通情報の提供にあたり、道路の交通状態・情報を色で表現している。地図画像の道路上に種々の交通状態・情報に対応した色を表示することで、画像でエリアの交通情報を提供している(表-1)。本研究では、京都市中心部エリアの交通状態・情報を示す画像データを収集・活用した。渋滞予測及び分析には、オレンジ色の枠内の範囲のエリアを対象とした。



図-1 交通情報画像と対象エリア

表-1 交通情報データにおける「色」と「交通状態・情報」の対応関係

色	赤	橙	緑	紫	黒	水
交通状態	渋滞	混雑	その他の規制	事故等	通行止め	冬用タイヤ
備考	10km/h以下	20km/h以下	速度規制等	事故故障車落下物	二輪車通行止め含めない	チェーン規制含む

(2) 渋滞に関するデータ収集と加工

図-1の交通情報データの収集にあたり、5分毎にHP上から自動取得するプログラムを作成し収集した。収集期間は2019年12月26日16時25分から2020年01月13日23時55分まで(5725点)の期間収集した。

次に収集した交通情報データを深層学習(GNN)で分析可能な形式に変換する方法について説明する。GNNは、グラフ構造を入力とした深層学習手法である。本研究では、道路を図-2のようなグラフ構造と捉える。この時、道路上の交通情報(色)がノードに格納される。エッジは通常隣接行列で表現される。

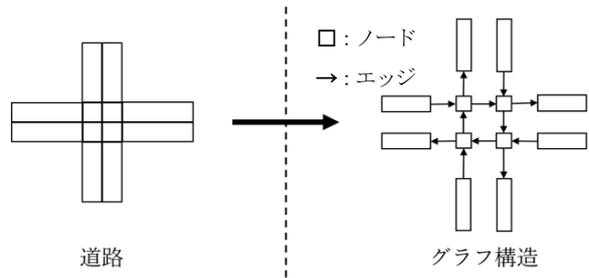


図-2 本研究における道路ネットワークのグラフ構造

収集データは大量の画像データであるため、色で表現された交通情報を抽出し、ノードに格納可能なデータ形式に変換する。この時、画像上の全ての道路にマッピングを行い、色情報を抽出するプログラムを作成し処理を行った。抽出の形式は表-2の形式で保存し、各要素は単位をpxとして『(赤色の長さ, 橙色, 緑色, 紫色, 黒色, 水色, 道路の長さ)』の様に保存した。交差点は道路長1pxとすることで区別した。これにて、画像情報データを交通グラフ構造データとして扱えるようになるため、GNN手法の適用が可能となる。

表-2 交通グラフのノードに格納する交通情報の形式

時間	ノード0	ノード1	ノード289
2019/12/26 16:25	(0,0,0,0,0,1)	(0,0,0,0,0,26)	(0,0,0,0,0,13)
.....
2020/01/13 23:55	(0,0,0,0,0,1)	(0,0,0,0,0,26)	(0,0,0,0,0,13)

(3) 入力に用いるデータ及び変量の定義

本研究では、①渋滞に関する変量、②事故や規制などの交通情報の変量、③休日や降水量などの交通量を変動させ得る変量の①~③を多変量入力する事で渋滞を予測する。以後便宜上、①『渋滞度』、②『交通情報データ』、③『変動要因データ』とし、説明を行う。

時間的依存関係を学習するLSTMの性質上、変量は全て0~1の範囲にしたものを用いる。

a) 『渋滞度』

『渋滞度』は、渋滞に関する情報である赤色(渋滞: 10km/h以下)と橙色(混雑: 20km/h以下)を用いてを定義し、これを予測対象とする。渋滞度は1つの道路(ノード)がどれだけ赤・橙色で塗られているのかを表す割合で、以下の式(1)で定義する。橙色は速度が赤色の2倍であることから、渋滞度を算出するときに赤色の半分と等価と仮定した。

$$\text{渋滞度} = \frac{(\text{赤色の長さ}) + (\text{橙色の長さ})/2}{(\text{道路の長さ})} \quad (1)$$

道路長さで割る事で値域を 0~1 としている。ある道路が全て赤く塗られると 1, 全て橙色だと 0.5, 塗られていないと 0 をとる。以後, 渋滞予測とはこの渋滞度を予測対象として予測を行うことを指す。

b) 『交通情報データ』

JARTIC 交通情報データにおける渋滞度以外の交通情報 (緑, 紫, 黒, 水色) である。渋滞予測に交通情報を活用することで, とともに提供されるデータを使用できる点も, 本研究における利点である。収集した期間中において, 「水色: 冬用タイヤ」は一度も出現しなかったため, 本研究では使用しないものとする。

$$\text{規制度} = \frac{\text{緑色の長さ}}{\text{(道路の長さ)}} \quad (2)$$

$$\text{事故度} = \frac{\text{紫色の長さ}}{\text{(道路の長さ)}} \quad (3)$$

$$\text{通行止め度} = \frac{\text{黒色の長さ}}{\text{(道路の長さ)}} \quad (4)$$

これらの多変量交通情報データは, 毎日定期的が発生する渋滞とは異なり, 稀にしか表示されないデータである。

c) 『変動要因データ』

交通状態に影響を与える可能性がある因子として「休日か否か」, 「気温」, 「風速」, 「降水量」を想定し, それぞれの時系列データセットを作成した。変動要因データは, 交通情報データとは異なり, 稀事象ではなく日々変化するデータである。

・休日か否か (休日ラベル)

交通量は休日であるかどうかによって依存すると考えられ, 休日は 1, 平日は 0 とするデータを作成した。収集した期間は年末年始であるため, 表-3 に示すように 12 月 30 日, 12 月 31 日, 1 月 2 日, 1 月 3 日は休日として設定した。なお, 期間中に含まれる祝日は, 1 月 1 日: 元旦, 1 月 13 日: 成人の日である。

表-3 休日の設定 (赤, 青, 紫で着色されたものが休日)

Sun	Mon	Tue	Wed	Thu	Fri	Sat
				12/26	12/27	12/28
12/29	12/30	12/31	1/1	1/2	1/3	1/4
1/5	1/6	1/7	1/8	1/9	1/10	1/11
1/12	1/13					

・気温

気温は, 気象庁 HP で公開されている京都市の過去の気象データのうち, 最も時間解像度の高い 10 分毎のデータを使用した。10 分毎のデータを 5 分毎に変換するために間を線形補間した。また, 気温も 0~1 の値域に変換する必要がある。変換は式(5)を用いて正規化した。

$$\tilde{u} = \frac{u - u_{min}}{u_{max} - u_{min}} \quad (5)$$

ここで, u は変数, \tilde{u} は正規化された変数である。また, 期間中の気温の時間変動を図-3 に示す。

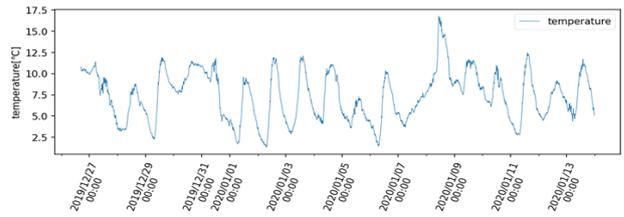


図-3 気温の時間変化

・風速および降水量

風速と降水量についても, 気温と同様に気象庁 HP から取得した 10 分毎のデータを正規化して使用した。風速の変動を図-4, 降水量の変動を図-5 に示す。

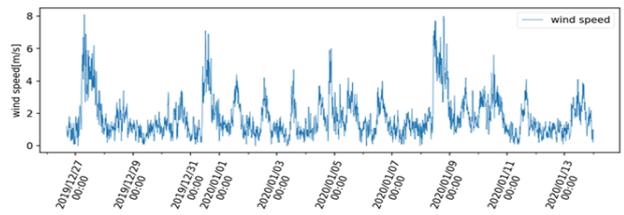


図-4 風速の時間変化

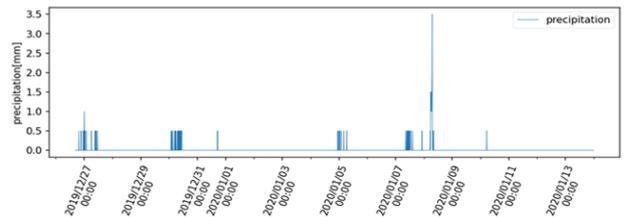


図-5 降水量の時間変化

以上が本研究で用いる多変量データの概要であり, 表-4 にまとめて示す。

表-4 多変量入力データのまとめ

予測対象	交通情報データ	変動要因データ
・渋滞度	・規制度 ・事故度 ・通行止め度	・休日ラベル ・気温・風速 ・降水量

3. 提案手法のモデル構成

本研究では, 渋滞の時空間特性と交通量変動要因を考慮したリアルタイム渋滞予測手法 (多変量 GCLSTM) の構築を目的としている。複数の交通量変動要因と渋滞の過去の傾向から未来の渋滞を予測する関数 F を GNN 的手法により作成すると言い換えることが出来る。すなわち以下の式(6)で表される渋滞予測のための関数 F を学習する事である。なお, 学習の損失関数には, MSLE (平均二乗対数誤差) を用いる。

$$F \begin{pmatrix} [x_{t-T'}, \dots, x_t], \\ [u1_{t-T'}, \dots, u1_t], \\ [u2_{t-T'}, \dots, u2_t], \\ \dots; \mathbf{G} \end{pmatrix} = x_{t+T} \quad (6)$$

ここで、各変数の定義は以下の通りである。

- x : 全ノードの渋滞度のグラフ信号
- $u1, u2, \dots$: 交通量変動要因
(交通情報データ, 変動要因データ)
- t : 時刻
- G : 交通グラフ構造
- T' : 入力する過去の時間数
- T : 予測する時間

この章では、提案手法の多変量 GCLSTM の説明のために、主な構成要素である「空間的手法 (GNN ベース)」、 「時間的手法 (LSTM ベース)」、 「多変量入力」を行うためのモデル構成について順に示す。

(1) 空間的手法

本研究では、図-2 に示すようなグラフ構造を定義し、GNN を適用する。このとき、車両の進行方向を表すためにエッジを矢印で表現しているが、交通流は双方向性を持つため無効グラフを用いている。

このグラフ定義により作成した交通グラフをノード集合 V とエッジ集合 E を用いて $G(V, E)$ と表す。 N 個のノード集合 V における i 番目ノード v_i と、 i 番目と j 番目のノードを繋ぐエッジ (v_i, v_j) により構成される。エッジは、 $N \times N$ の隣接行列 A により定義される。隣接行列 A は、エッジ (v_i, v_j) が存在する時 $A_{i,j} = 1$ で、存在しない時は $A_{i,j} = 0$ で表される。

本研究で用いる GNN 的手法は、Cui ら⁹⁾により提案されているノード v_i の近傍 k -hop 先までのノードに対して畳み込み演算 (GC) を行う手法を基本とする。

畳み込みを行うにあたり、 k -hop 近傍行列を定義する。グラフ全体における 1 -hop 近傍行列は、 I を $N \times N$ の単位行列として、以下の式で表される。

$$\tilde{A} = A + I \quad (7)$$

k -hop 近傍行列は同様に $(A + I)^k$ と表すことができるが、要素が 1 を超えることがある。 k -hop 近傍行列は隣接関係の有無を表すための行列であるため、重みが付くのは好ましくない。そこで k -hop 近傍行列 \tilde{A}^k は全ての要素に以下式の操作を行うことにより $\{0,1\}$ で表現する。 \min は最小値を選択する関数である。

$$\tilde{A}_{i,j}^k = \min[(A + I)_{i,j}^k, 1] \quad (8)$$

現段階では、道路長さが畳み込み演算に与える影響を考慮できていない。そこで、道路長さの補正を行うための行列 Rd を定義する。交通の影響は、道路が長くなるほど隣の道路へは伝わりにくくなる。そのため、ノード v_i の長さを l_i とし、 $N \times N$ 行列 Rd の各要素は以下の様に

表すことができる。なお、交差点の長さは $1px$ であり、ノード v_i が交差点の時の $Rd_{i,j}$ は 1 である。

$$Rd_{i,j} = \frac{1}{l_i} \quad (9)$$

これにより距離が大きいノードほど情報を隣接したノードに伝わりにくくなり、逆に $1px$ の交差点の情報は伝わりやすくなる。

Abu-El-Haija ら⁶⁾、Cui ら⁷⁾は、以上の k -hop 近傍行列、入力データ、重み行列の積をとることにより、 k -hop 先までのノードの畳み込み特徴量を考慮可能なグラフ畳み込み層を実現している。

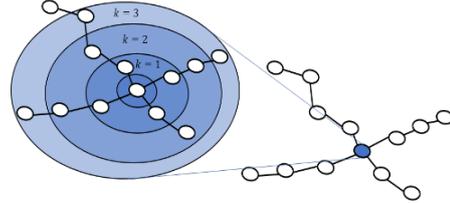


図-6 k -hop グラフ畳み込みのイメージ

k -hop グラフ畳み込み層は、 $1 \sim k$ の畳み込み特徴量を保持するため、畳み込み前の情報と畳み込み後の特徴から学習を行える。これにより、グラフ構造の入力情報から、局所的な特徴量を抽出することが可能となり、道路の周辺情報を加味した時系列予測が可能となる。この k -hop グラフ畳み込み層の k -hop の範囲に対するグラフ畳み込み演算は、式(10)で定義される。

$$GC_t^k = (W_{gc_k} \odot \tilde{A}^k \odot Rd) x_t \quad (10)$$

ここで、各変数・数学記号の定義は以下の通りである。

- GC_t^k : 時刻 t の k -hop GC
- W_{gc_k} : 時刻 t の k -hop GC の重み行列
- \odot : アダマール積(行列の各要素同士の積)

このとき、グラフが有限であるから k も有限である。 k を大きくすると層の特徴空間も大きくなるが、ある程度を超えると計算コストばかりが増える一方で畳み込みの寄与率が小さくなっていく。これは遠方ノードになるほど関連性が低くなり精度向上に寄与する特徴が見つかりにくいことに起因すると推測される。よって、 k が最大値である必要はなく、適度な値をとればよい。

$k = K$ のとき、入力 x_t に対する 1 から K -hop までをまとめたグラフ畳み込み特徴量を $GC_t^{[K]}$ とする。 1 から K -hop までの特徴量を以下の式の様にとりまとめることにより、特徴空間が大きくなり、表現できる事象が増加する。

$$GC_t^{[K]} = [GC_t^1, GC_t^2, \dots, GC_t^K] \quad (11)$$

以上が、道路交通の空間的な特徴を捉えるために用いる GNN 的手法 (グラフ畳み込み層の導入) である。

(2) 時間的手法

ここでは LSTM の説明を行った後、前述のグラフ畳み

込みを取り入れた Graph Convolutional LSTM (GCLSTM) について説明を行う。

1) LSTM

現在, Hochreiter らにより提唱された LSTM は産学で広く用いられている (図 7) . 情報伝達の制御機構を担うゲートにより, 勾配消失が抑制され, 長期的な依存関係を学習可能である。

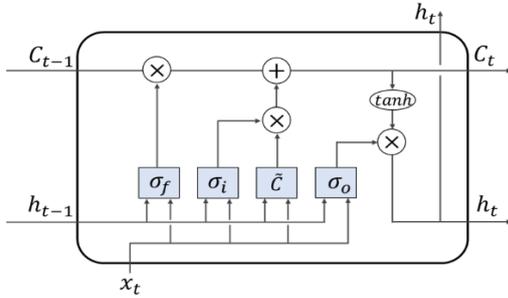


図-7 LSTMの構造

式(12)~(14)では, 時刻 t の忘却, 入力, 出力ゲートをそれぞれ f_t, i_t, o_t として各定義を示す. 式(15)~(17)では, 入力セル状態 \tilde{C}_t , セル状態 C_t , 隠れ状態 h_t の定義を示す.

$$f_t = \sigma_g(W_f \cdot x_t + U_f \cdot h_{t-1} + b_f) \quad (12)$$

$$i_t = \sigma_g(W_i \cdot x_t + U_i \cdot h_{t-1} + b_i) \quad (13)$$

$$o_t = \sigma_g(W_o \cdot x_t + U_o \cdot h_{t-1} + b_o) \quad (14)$$

$$\tilde{C}_t = \tanh(W_C \cdot x_t + U_C \cdot h_{t-1} + b_C) \quad (15)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (16)$$

$$h_t = o_t \odot \tanh(C_t) \quad (17)$$

ここで, 各変数・数学記号の定義は以下の通りである.

- W_f, W_i, W_o, W_C : $f_t, i_t, o_t, \tilde{C}_t$ の重み行列
- U_f, U_i, U_o, U_C : 隠れ状態の重み行列
- b_f, b_i, b_o, b_C : バイアス項
- σ_g : ゲート活性化関数(sigmoid関数)
- \tanh : 活性化関数(双曲線正接関数)

このとき, ゲートの役割を担うのは sigmoid 関数 σ_g (図-8) であり, 値に応じて情報の伝達割合が制御される. 忘却ゲート f_t は, 式(16)で表されるセル状態の更新に利用され, 入力と一つ前の隠れ状態から一つ前のセル状態の情報をどの程度使用するかを決めるのに利用される. 入力ゲート i_t , 出力ゲート o_t についても入力と一つ前の隠れ状態の値から入出力の伝達割合を決定するために利用されている. 各種重みとバイアス項は学習により決定される.

2) GCLSTM

次にグラフ畳み込み層を導入した GCLSTM について説明する.

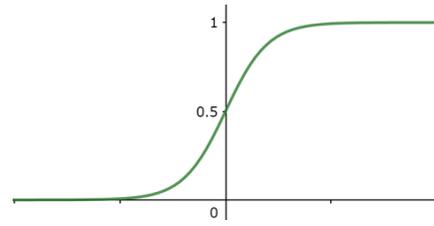


図-8 sigmoid関数 σ

GCLSTMでは, 以上で述べた LSTM をベースにして, グラフ畳み込み層を導入する. GCLSTM の内部構造を以下の図-9に示す.

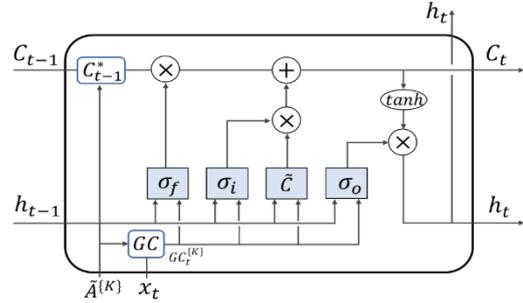


図-9 GCLSTMの構造

単純な LSTM では各ゲートに入力 x_t を直接入力していたが, GCLSTMでは, グラフ畳み込み層に x_t を通して算出されるグラフ畳み込み特徴量 $GC_t^{(K)}$ を各ゲートに入力する.

$$f_t = \sigma_g(W_f \cdot GC_t^{(K)} + U_f \cdot h_{t-1} + b_f) \quad (18)$$

$$i_t = \sigma_g(W_i \cdot GC_t^{(K)} + U_i \cdot h_{t-1} + b_i) \quad (19)$$

$$o_t = \sigma_g(W_o \cdot GC_t^{(K)} + U_o \cdot h_{t-1} + b_o) \quad (20)$$

$$\tilde{C}_t = \tanh(W_C \cdot GC_t^{(K)} + U_C \cdot h_{t-1} + b_C) \quad (21)$$

ここで, 渋滞が長くなる過程でこれを考える. ある時, ある道路で起きている渋滞が, 次の時刻で後ろの道路まで広がったとすると, 直前に前の道路が混んでいたから後ろの道路も混んできたという関係を LSTM が学習する必要がある. そのため, 各道路のセル状態は直近の周辺道路のセル状態の影響を受ける必要がある. 直近の周辺道路の影響を加味するために, 直近の畳み込みセル状態 C_{t-1}^* を定義する.

$$C_{t-1}^* = W_{C^*} \odot (\tilde{A}^K \odot R_d) C_{t-1} \quad (22)$$

ここで, W_{C^*} は C_{t-1}^* の重み行列.

畳み込みセル状態 C_{t-1}^* により, 先行のセル状態の空間的な影響を捕捉した LSTM の再帰計算が出来る. C_{t-1}^* は忘却ゲートにより学習過程を経て伝達割合が制御される. GCLSTM の最終的な時刻 t におけるセル状態と隠れ状態は以下の通りである.

$$C_t = f_t \odot C_{t-1}^* + i_t \odot \tilde{C}_t \quad (23)$$

$$h_t = o_t \odot \tanh(C_t) \quad (24)$$

このように GCLSTM は GC 層を LSTM に導入することにより、道路交通グラフの複雑な時空間特性を学習可能な構造になっている。

(3) 多変量入力：多変量 GCLSTM (提案手法)

最後に、渋滞だけでなく複数の入力を扱えるようにネットワークを構成する。

本研究の提案手法である多変量 GCLSTM (MVCGLSTM) では、規制などの交通情報データと交通に影響を及ぼし得る要因データを多変量入力し、渋滞を予測する。時間的特徴を捉えるために LSTM で計算する必要があるが、複数のデータを独立して入力しては相互関係を考慮できない。

そのため、LSTM の構造の内部で情報を同一空間にまとめることで、学習器が必要な相互的な時間的特徴を取捨選択し、重み付けできるようにする。これを踏まえて、本研究の提案手法である多変量 GCLSTM の構造を図-10 に示す。

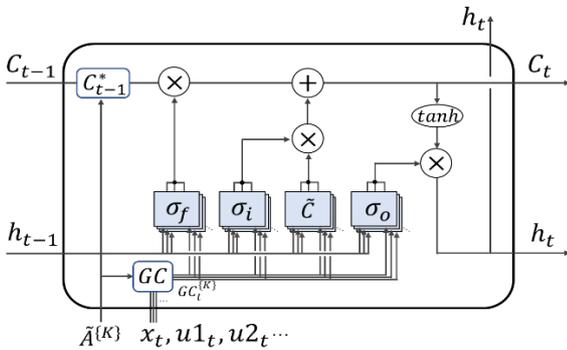


図-10 多変量 GCLSTM の構造

入力された多変量データは GC 層を通り、各ゲートへと入力される。使用している多変量データのうち、変動要因データ (休日、気象情報) は、京都市の代表値としてのデータで、道路 (ノード) ごとの変動を持たないが、入力サイズの統一を目的として、全ての入力データを GC 層に通してからゲートに入力する。ゲート通過後の変数ごとの出力は線形結合により集約する。これにより、多変量データと渋滞の間で関係がありそうな時間的特徴を学習器が抽出できるようになり、複数種類の入力情報から渋滞を予測することが可能となる。

以上が本研究で用いる多変量 GCLSTM の概要であり、多変量 GCLSTM を用いてリアルタイム交通情報サービスの交通情報と多変量データから渋滞予測を行う。

4. 評価体系と評価指標

(1) 評価体系

2 章のデータに対して 3 章で示したモデルを適用し、

渋滞予測精度の評価を行う。提案手法の評価方法として、既存手法である「LSTM」・「GCLSTM」と提案手法「多変量 GCLSTM」を比較し評価する。各手法の入出力の対応を表-5 にまとめて示す。比較にあたっては、次節で説明する評価指標を用いて比較を行う。

表-5 各手法の入出力

	LSTM	GCLSTM	多変量 GCLSTM
入力	・渋滞度	・渋滞度	・渋滞度 ・交通情報データ ・変動要因データ
出力	・渋滞度の予測値	・渋滞度の予測値	・渋滞度の予測値

(2) 評価指標

指標を説明するために、予測対象である渋滞度の真値データについての説明する。渋滞度は 0~1 の値域をとり、1 つの道路がどれほど渋滞しているかを表す割合である。渋滞度の真値は、渋滞期間は激しく値が振動し、非渋滞期間は 0 を取り続けるグラフである (例：図-11)。

これは利用した渋滞情報データの特徴に起因する。本研究で利用する交通画像データでは、20km/h 以下で混雑、10km/h 以下で渋滞と定義されており、20km/h より大きい場合には円滑な交通流であるとして、渋滞度が 0 として提供される (つまりは渋滞していない)。この渋滞度は実環境において車両速度が 20 km/h 付近を上下するとき、渋滞度は振動データとなる。このことから、渋滞している点 (渋滞度の真値≠0) の前後に存在する渋滞度 0 に関して、グラフ上は 0 という数字を取っていても実際の道路環境はある程度交通量が存在している状態と考えられる。

また、渋滞が発生し始めるとき、計測頻度にもよるが、本来、自由域速度から渋滞域の速度にかけてある程度連続的に推移する。しかし、20km/h の閾値により、この車両速度の低下による渋滞発生兆しが消失する。これにより、突如として渋滞発生しているかのようなグラフになる。

以上から渋滞期間における振動値の鋭いピークをピンポイントで予測することは非常に困難であり、その予測は多少前後にずれることが考えられる。そこで、渋滞している期間において、真値に対して予測値がずれて算出される時のことを考慮して考える。例として図-12 のような予測値 A, B が算出されている場合を考える。

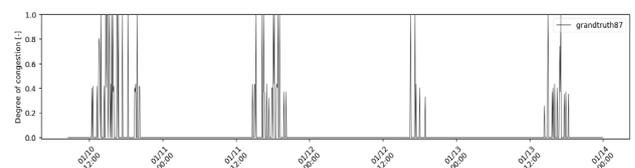


図-11 渋滞度の真値データのグラフ (例)

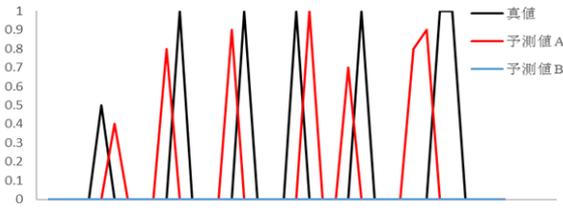


図-12 振動データにおける予測値の比較

予測値Aは前後にずれて算出しているケースで、予測値Bは渋滞度が全て0を算出しているケースである。予測値Bは渋滞を全く予測できていないのに対し、予測値Aは前後にずれているもののある程度予測できている。このとき、予測値Aの方が予測値Bよりも高精度な予測が行うことができているはずである。しかし振動する真値に対する予測値A、Bの予測誤差(RMSLE)を計算すると、予測値Aが0.1763、予測値Bが0.1320となる。すなわち、A>Bより、予測値Bの方が高精度な予測ができていることとなり、単純に誤差計算するだけでは正しく予測精度を評価できていないことがわかる。

このため渋滞期間を「渋滞している点の前後1タイムステップの期間」と定め、この期間内におけるずれを許容して誤差計算(RMSLE)を行うこととする。ずれの許容は、渋滞期間内で誤差が最小となるものを選択することで許容する。この方法で予測誤差を計算すると、予測値Aが0.0707、予測値Bが0.1320と、予測値Aの方が高精度となり、直観と矛盾していない結果となる。本研究では、渋滞期間における誤差計算には、前後1タイムステップ分のずれを許容した「渋滞時 RMSLE」を指標として用いる。

一方、非渋滞期間に関しては、許容を許さず、通常の誤差計算(RMSLE)により算出する「非渋滞時 RMSLE」を指標として用いる。このとき、非渋滞期間を、渋滞時 RMSLE に関与しない期間として定める。非渋滞時 RMSLEは、渋滞度0を0として予測できているかを表す指標である。

以上から、本研究で用いる指標をまとめて表-6に示す。

本研究では渋滞予測を目的としているため、渋滞していない時の指標である非渋滞時 RMSLE は、あくまでも渋滞時 RMSLE の補足的指標として用いることとする。

表-6 本研究で用いる評価指標のまとめ

渋滞時 RMSLE	渋滞度≠0の前後1タイムステップのずれを許容した RMSLE. どれだけ渋滞を予測できているかを表す。
非渋滞時 RMSLE	渋滞度=0における RMSLE (渋滞時 RMSLE に関与しない範囲)。 非渋滞時においてどれだけ渋滞度0と予測できているかを表す。

5. 提案手法の適用結果及び考察

提案手法(多変量 GCLSTM)により予測を行い、多変量でない LSTM・GCLSTM と比較する。各モデルは pytorch を用いて実装した。予測を行うとき、過去2時間分のデータの入力から、T分後の渋滞度を予測した。

学習は、パラメータ最適化手法に Adam を用い、300 エポックで行った。また、GCLSTM、多変量 GCLSTM における k-hop グラフ畳み込み演算は、k = 3 とした。

(1) 変動要因データの検証

多変量入力の影響を確認するために、変動要因データの入力個数を変化させて予測を行った。このとき、予測対象時間Tは5分後とした。予測結果を表-7に示す。

表-7 多変量入力の数を変化させた時の予測結果

用いた変動要因データ	・休日ラベル	・休日ラベル ・降水量	・休日ラベル ・降水量 ・気温	・休日ラベル ・降水量 ・気温 ・風速
渋滞時	1.0401	1.0311	1.0187	1.0157
非渋滞時	0.0582	0.0565	0.0502	0.0536

渋滞時の結果より、入力に用いる変動要因データの種類を増やすほど、予測誤差が減少しており、インプットとなるデータの種類を増やすほど、精度が向上することが示唆されている。一方、非渋滞時の予測精度に関しても、変量が3つ(休日ラベル、降水量、気温)までは向上した。本研究では渋滞予測が目的であるため、渋滞時予測誤差が最小となった4つの変量を多変量 GCLSTM の入力として用いることとする。なお、変量が4つのとき、非渋滞時予測誤差は最小ではないが、変量が2つのときよりも誤差が小さくなっており、大幅に精度が低い(誤報を出す)わけではないと考える。

(2) 提案手法による予測結果と考察

予測対象時間Tを 5, 15, 30 分後として、多変量 GCLSTM を適用し得られた予測結果を表-8に示す。比較として、多変量でない LSTM・GCLSTM の予測結果も併せて表示した。多変量 GCLSTM の入力には上記の検証結果から、全ての多変量データを使用して予測を行った。

表-8の渋滞時の誤差の結果から、提案手法の多変量 GCLSTM は、5, 15, 30 分後の予測全てにおいて、既存手法よりも高精度で渋滞を予測することができた。一方、非渋滞時誤差に関しては、LSTM, GCLSTM, 多変量 GCLSTM の順に誤差が大きくなる傾向がある。

各時間の予測結果のグラフを以下に示す。上段は真値

表-8 各モデルの予測誤差結果

		5分後	15分後	30分後
渋滞時	LSTM	1.2767	1.3144	1.3313
	GCLSTM	1.0849	1.2185	1.2826
	多変量 GCLSTM	1.0157	1.1564	1.2274
非渋滞時	LSTM	0.0152	0.0171	0.0172
	GCLSTM	0.0553	0.0443	0.0338
	多変量 GCLSTM	0.0536	0.0505	0.0495

(黒) , 中段は提案手法 (MVGCLSTM (青)) , 下段は既存手法 2 つ LSTM (緑) , GCLSTM (オレンジ) である。中段と下段には、薄く真値も表示した。本研究で扱っている渋滞データは速度閾値を頻繁にまたぐことで振動するが、中には振動が少ない道路 (速度が常に低い) も存在するため、振動値 (予測結果①; 図-13~図-15) と少振動値 (予測結果②; 図-16~図-18) に分けて示す。少振動値では車両速度が常に低いことから、振動値よりも非常に渋滞が発生しやすい道路であると考えられる。

1) 振動値 (車両速度が閾値付近で上下する道路)

図-13 から図-15 は、閾値の影響で値が激しく振動した渋滞度に対する予測結果である。振動値に対して LSTM ではそれほど予測が行えていないのに対し、GCLSTM と多変量 GCLSTM では、より高精度に予測できていることが読み取れる。激しい振動値で予測が難化しても、グラフ畳み込み処理により周辺道路の混雑状況が加味され、安定した予測に繋がると考えられる。

また、どの手法においても、5, 15, 30 分後と予測先の時間が大きくなると、予測が安定しなくなる。特に 30 分後の予測の場合に既存手法では、全体的に予測値が小さくなり、大きな値はあまり出力できていない。一方、本研究の提案手法では 1 に近い値は出力できなくなるものの、既存手法よりも高い精度で予測できていることが窺える。これは渋滞以外の複数の要因により、予測の判断材料が増加し、多角的に渋滞周期を学習できたためと考えられる。

5, 15 分後の予測に関しても、提案手法は既存手法よりも真値に近い値を出力しており、精度の向上が確認できる。しかしながら、5 分後の予測では、渋滞期間の前に数回誤って渋滞を予測している。既存手法の GCLSTM でも同様の箇所に誤報を出してはいるが、提案手法はより大きな値で誤報が出力されている。提案手法の方が、誤報が小さい場合もあるため一概には言うことは難しいが、このように大きく誤報が算出されることがあり、提案手法での非渋滞時 RMSLE が大きい一因となると考えられる。

ここまでの結果で示したように提案手法は、渋滞度の真値データが激しく振動していても、グラフ畳み込み処理と多変量入力を行うことにより安定した予測に繋がる

ことが示唆された。5 分後の予測では、上記の振動値のグラフ上では既存手法と大きな差異が見られなかったが、予測時間が増加しても、多角的な予測により精度低下が起りにくい手法であることが示唆された。

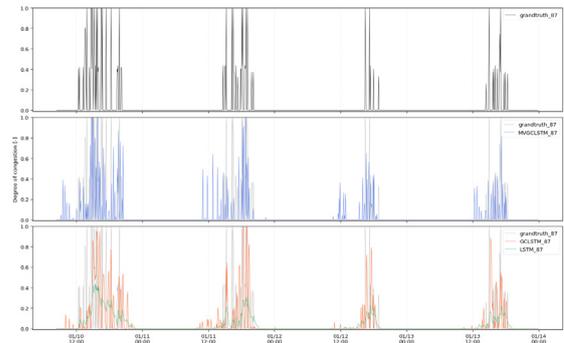


図-13 予測結果① (5分後)

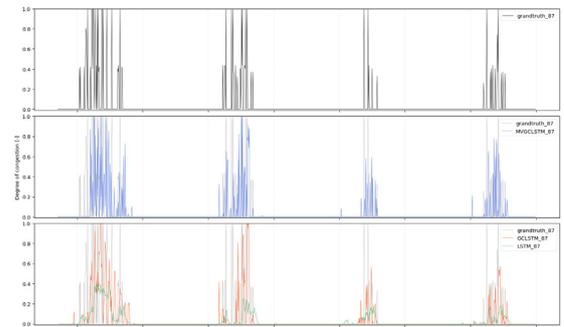


図-14 予測結果① (15分後)

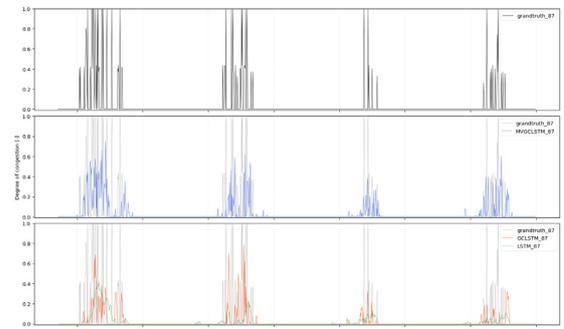


図-15 予測結果① (30分後)

2) 少振動値 (より混雑している道路)

速度閾値の影響が比較的少ない道路の渋滞度を予測した結果を図-16 から図-18 に示す。

少振動値 (予測結果②) では、振動値 (予測結果①) と比較して振動が少ないことが伺える。振動が少ないと振動値には対応できなかった LSTM でも、ある程度安定して予測可能となる。グラフ畳み込み処理を行う 2 つの手法では、さらに振動成分を含めて学習できている。提案手法では、若干ではあるが GCLSTM よりも真値に近い値を算出していることが読み取れる。このことから、提案手法は連続的な真値になっても、高精度な予測が可能であると推察される。

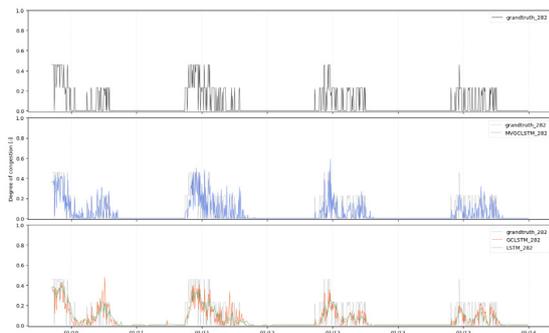


図-16 予測結果② (5分後)

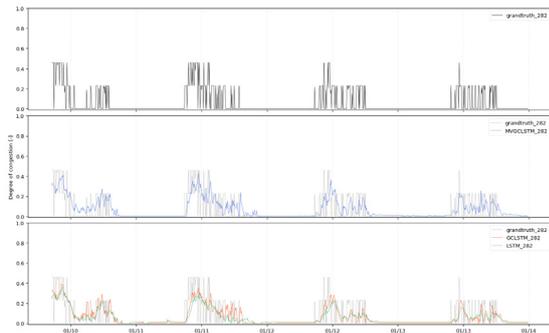


図-17 予測結果② (15分後)

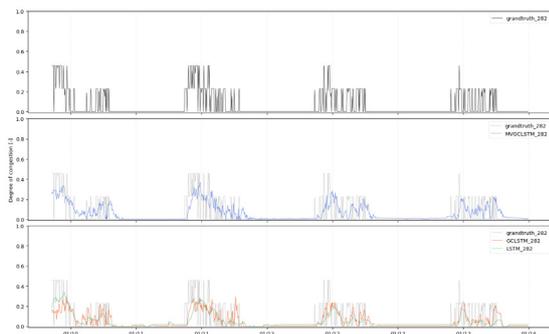


図-18 予測結果② (30分後)

道路が常時混雑している結果、閾値を上下しないことで真値が安定し、どの手法も精度が向上することが確認された。逆を言えば、閾値がうまく設定されれば予測が向上すると考えられる。例えば、交通情報提供者により多段階の混雑レベルの導入など変更が施されれば、リアルタイム渋滞予測の精度はさらに向上するものと見込まれる。

以上より、提案手法は既存手法より振動値に強く、より長期の予測が可能であることが示唆された。

6. 結論

本研究では、リアルタイムで取得可能な交通情報データを活用した多変量入力のグラフ畳み込み渋滞予測手法を構築し、予測精度の検証を行った。

使用する交通量変動要因データの検証のために、入力

数を変化させて精度を比較した。その結果、渋滞時予測誤差は入力数を増やすほど減少し、精度が向上することが確認できた。

変量の検証から決定した多変量データを入力し、5、15、30分後の渋滞予測を行った結果、これらの予測時間全てにおいて既存手法よりも小さい予測誤差を示し、高精度な予測が可能であることが示された。

本研究の交通情報はリアルタイムかつ全国の地域で収集可能であるため、即時に情報を抽出する環境を構築すれば、任意の地域においてリアルタイム渋滞予測を行うことが可能である。

地図上で視覚的に表示される渋滞情報は、情報表示のための閾値に起因して振動値となり、予測が難化する。閾値の影響が小さい道路では、既存・提案手法ともに良好な結果を示した。一方で、閾値の影響が大きい道路では、提案手法がより優れた結果を示した。この結果から、予測が難化しても、複数の変量から多角的に情報を補足されることで、説明力が向上することが示唆された。

今後の課題であるが、データ収集期間が短く、限られた期間のデータによる結果である。リアルタイムにデータ収集して予測するという一連のデータ取得から予測までを想定したものであり、予測精度に関して言えば、過去の蓄積データを用いることでも検証が可能であり、長期間・膨大なデータで予測を行うことが望ましい。長期間膨大なデータが蓄積、利用できれば、一般的に交通工学的には稀な事象とされている交通事故のデータに関しても蓄積量が増加し、それらの渋滞に対する影響が学習できることが期待できる。

また、今回閾値に起因する振動データを直接予測したが、移動平均をとり、グラフを滑らかにして予測を行う方法も考えられる。移動平均データと振動データを多変量データとして入力するなど様々な方法が考えられるため、今後検討する必要がある。

振動値問題の解決策として、混雑を表す指標が3段階のサービスではなく、別の交通情報提供サービスを利用することも考えられる。閾値設定が異なるサービスを利用すれば精度の向上する可能性もある。

最後に、本研究は誰もが自由に使用できる、いわゆるオープンなデータの利用に焦点を当てて研究を行った。一般的にオープンなデータは、競争力が向上するメリットがあるが、オープンかつリアルタイムの動的データは少なく、競争力が低いのが現状である。リアルタイムデータは人の視認性が重視され、機械判別が必ずしも容易ではないが、本研究では画像形式データをもとに研究を行い、既存手法より高精度な予測結果を示すことができた。これによりリアルタイム性の高いオープンデータの利用は十分な可能性を有すると考える。

参考文献

- 1) 国土交通省：高速道路を中心とした「道路を賢く使う取り組み」の基本方針について-基本方針参考資料，pp.1, 2015
- 2) Yoshii, T., Akahane, H. and Kuwahara, M. : Impacts of the accuracy of traffic information in dynamic route guidance systems, Proceedings of the Third Annual World Congress on Intelligent Transport Systems, ITS America, 1996
- 3) Hochreiter, S. and Schmidhuber, J. : “Long Short-Term Memory,” Neural Comput., vol.9, no.8, pp.1735-1780, 1997
- 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, pp. 187-197, 2015
- 5) Li, Y., Yu, R., Shahabi, C., Liu, Y. : DIFFUSION CONVOLUTIONAL RECURRENT NEURAL NETWORK: DATA-DRIVEN TRAFFIC FORECASTING, Proc. of ICLR, 2018
- 6) Cui, Z., Henrickson, K., Ke, R., Pu, Z., and Wang, Y. : Traffic graph convolutional recurrent neural network: A deep learning framework for network-scale traffic learning and forecasting, Transactions on Intelligent Transportation Systems, IEEE, 2019
- 7) Abu-El-Hajja, S., Perozz, B., Kapoor, A., Alipourfard, N., Lerman, K., Harutyunyan, H., Steeg, G.V. and Galstyan, A. : MixHop: Higher-Order Graph Convolution Architectures via Sparsified Neighborhood Mixing,” Int. Conf. Mach. Learn, 2019
- 8) 竹内利夫・皆方忠雄・藤川謙・石田貴志：高速道路の渋滞予測情報提供による渋滞緩和の可能性に関する考察，土木計画学研究・講演集，2006
- 9) 福田幸二・Saeed, M.・Kai, S.・Schmocker, J.D. : OpenStreetMap データからの交通ネットワークの抽出とグラフ畳込みネットワークによる交通需要推定，第 60 回土木計画学研究発表会・講演集，2019
- 10) 道原侑也・吉井稔雄・坪田隆宏：CNN を用いた渋滞発生予測モデル，第 61 回土木計画学研究発表会・講演集，2020
- 11) 吉井稔雄・赤羽 弘和・桑原雅夫：予測誤差を考慮した予測情報提供効果についての分析，土木計画学研究・講演集，No.19(2)，pp.741-748，1996
- 12) 吉田幸司・井上亮：道路リンクの接続関係を考慮した畳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，Vol75，No.5/1_1059-I_1067，2019
- 13) Chai, D., Wang, L., and Yang, Q. : Bike Flow Prediction with Multi-Graph Convolutional Networks, arXiv preprint arXiv:1312.6203, 2018
- 14) Chandra, S.R. and Al-Deek, H. : Prediction of freeway traffic speeds and volumes using vector autoregressive models, J. Intell. Transport. Syst.: Technol. Plann. Oper., 13 (2), pp. 53-72, 2009
- 15) Fu, R., Zhang, Z. and Li, L. : Using LSTM and GRU Neural Network Methods for Traffic Flow Prediction, Youth Academic Annual Conference of Chinese Association of Automation, 2016
- 16) International Data Corporation : Data Age 2025: The Evolution of Data to Life-Critical Don't Focus on Big Data; Focus on the Data That's Big, pp. 2-7, 2017
- 17) Lv, Y., Duan, Y., Kang, W., Li, Z. and Wang, F. : Traffic flow prediction with big data: A deep learning approach. IEEE Transactions on Intelligent Transportation Systems 16(2), pp. 865-873, 2015
- 18) Schlichtkrull, M., Kipf, N.T., Bloem, P., van den Berg, R. Titov, I., and Welling, M. : Modeling relational data with graph convolutional networks, ICLR, 2017
- 19) Zhang, Y. and Liu, Y. : Traffic forecasting using least squares support vector machines, Transportmetrica, 5 (3), pp. 193-213, 2009
- 20) Zhu, L., and Laptev, N. : Deep and Confident Prediction for Time Series at Uber, In Int. Conf. on Machine Learning Time Series Workshop, 2017

(2021.10.1 受付)

TRAFFIC CONGESTION PREDICTION WITH GRAPH NEURAL NETWORKS UTILIZING IMAGE DATA WHICH SHOW TRAFFIC CONDITIONS

Takahiro KAZAOKA, Toshiyuki NAKAMURA, Yasuhiro AKAGI, Takayuki MORIKAWA

In recent years, the prediction accuracy of deep learning has dramatically improved, and attracted much attention. In addition, as real-time traffic information becomes more easily available, expectations for information on traffic congestion prediction are increasing more and more. In this study, we construct a traffic congestion prediction method with GNN utilizing real-time available traffic information in the target area of Kyoto City. We have confirmed that the accuracy of our method can be improved by taking into account traffic information such as regulations and accidents and data of factors may change the traffic volume such as holidays and weather. Our method uses traffic information from JARTIC, which provides real-time traffic information for all over Japan, so it is possible to predict traffic congestion in real time throughout Japan once the environment is set up.