

機械学習を用いた阪神高速道路における交通渋滞発生予測

阪神高速技研(株)技術部技術課	寺前 智文
阪神高速道路(株)保全交通部交通技術課	向井 梨紗
阪神高速道路(株)東京事務所付 (独立行政法人 日本高速道路保有・債務返済機構出向)	西海 能史
阪神高速技研(株)技術部技術課	鈴木 健太郎
阪神高速技研(株)技術部技術課	小島 悠紀子

要 旨

阪神高速道路は1日あたり約70万台の利用があり、日常的に交通集中渋滞が発生する。交通混雑状況を事前に把握することができれば、交通管制業務の効率化につながると考えられる。過去に、機械学習の手法の一つである Convolutional Neural Networks (CNN) を用いてモデルを構築し、10分後の交通渋滞発生予測に取り組んだ結果、路線全体では有効性が確認できたものの、道路構造が複雑な合流地点の予測精度が極端に低かった。本稿では、複雑な道路構造を考慮できる機械学習手法として、Graph Convolutional Networks (GCN) を用いてモデルを構築し、10分後の交通渋滞発生予測を行った結果について報告する。また、CNN を用いて構築・検証を行った交通渋滞発生予測モデルの予測結果との比較分析した結果についても報告する。

キーワード: 交通渋滞, 機械学習, Graph Convolutional Networks

はじめに

阪神高速道路は1日あたり約70万台(2019年度)の利用があり、日常的に交通集中渋滞が発生する。交通管制システムでは、5分間車両検知器データ(交通量, 時間占有率)を用いて渋滞判定を行った情報をドライバーや管制員に1分更新で提供している。阪神高速道路では、渋滞発生によるサービスレベルの低下を防ぐため、ボトルネック上流側の入路閉鎖や渋滞後尾情報を非常駐車帯で提供する等、渋滞発生状況に合わせた施策を行っている。これらの施策を実施するには、各基地で待機している交通管理隊の出動が不可欠である。管制員に渋滞予測情報を提供できれば、渋滞への

迅速な対応が可能となり、お客さまへの影響を小さくできる。

渋滞発生の早期把握のために、阪神高速道路では、渋滞予測手法の開発を過年度より行っており、これまではシミュレーション技術によるリアルタイムな渋滞予測手法を交通管制システムの機能として導入している。しかし、その予測精度や安定性、システムの維持管理等、多くの課題がある。そこで、近年各分野での適用で話題となっている機械学習手法を用いた渋滞予測について検討している。

1. 予測手法

1-1 CNN を用いた既往研究と課題

機械学習手法を用いた渋滞予測への適応可能性については、過去に画像認識などでよく利用されている「Convolutional Neural Networks（以下、CNN）」を用いて検討を行った¹⁾。CNN は、畳み込み層と全結合層で構成されており、局所的な特徴量をうまく抽出できるよう工夫されている。ある一地点のある一時点の渋滞発生を予測するには、地点や時点の近い情報（局所的な情報）が重要であると考えられる。渋滞発生時の局所性は、予測対象地点や時点に関わらず類似していることが期待されることから、CNN を採用し検討を行った。既往研究では、CNN を用いて「10 分後の渋滞発生を予測するモデル」を構築し、11 号池田線上りの検討をした結果、全体での予測精度は7割程度であり、10 分後の渋滞発生予測手法としてある程度の予測精度を確認できた。しかしながら、検知器地点ごとに予測精度を検証すると、1 号環状線との合流部付近の予測精度が極端に悪くなることが確認され、課題として残った（図-1）。




図-1 CNN を用いた渋滞発生予測モデル検証結果




図-2 CNN と GCN の計算モデルのイメージ

表-1 モデルの概要

路線	11号池田線 上り (池田木部～環状線合流部) 追い越し車線	1号環状線 環状線全線 (井池線、千日前線は含まない) 第二走行車線
モデルの入力データ	【5分間車両検知器データ】 7種類のデータ（台数、高車台数、時間占有率、流出台数、流出入高車台数） + 【車線数】	
	130箇所	179箇所
期間	モデルの教師データ：2015年4月1日～2018年3月31日（3年間） モデルの精度検証：2018年4月1日～2019年3月31日（1年間）	
予測地点	対象区間に設置された全ての車両検知器地点	
	44箇所	23箇所

1-2 本検討で予測に用いた手法

既往研究で課題となった合流部付近の予測精度を改善するため、ここ数年で研究が進み、画像認識等で利用されている「Graph Convolutional Networks（以下、GCN）」を用いることとした。GCN はグラフに対してニューラルネットワークを適応させる技術である Graph Neural Networks (GNNs) の一種である。ここでグラフとはノード（点）とエッジ（点同士をつなぐ線）からなる数学的な構造である。GCN では、グラフのノードに付随する特徴量（入力データ）とノードごとに定義される出力データとの関係を求めることができる。既往研究で用いた CNN は、各ノードに隣接するノードの特徴量をまとめる（畳み込む）計算を行うが、GCN ではエッジで隣接するノードの特徴量をエッジの種類ごとにまとめる計算を行う（図-2）。つまり、ノードが縦横に整列し

ていないデータ構造であっても、関連する情報を畳み込む計算ができる。この特徴を活かせば、隣接する時点や地点だけでなく、分合流部の情報も加味した予測モデルを構築できると考え、本検討では GCN を用いて「10 分後の渋滞発生を予測するモデル」を構築した。

2. 渋滞発生予測モデル

2-1 GCN モデルの概要

本検討では、阪神高速道路で渋滞発生頻度が高い路線のうち、単路線で分かりやすく、既往研究で CNN を用いたモデルでも検討した 11 号池田線上り（池田木部～環状線合流部）と、分合流部が

複数あり複雑な構造である1号環状線を対象に、路線ごとに10分後の渋滞発生予測モデルを構築することとした。モデル構築に用いたデータ（5分間車両検知器データなど）を表-1に示す。

2-2 GCNの渋滞発生予測モデルへの適応

高速道路に設置されている車両検知器をノード、車両検知器間をつなぐ関係性をエッジとしてつなぎ、道路構造を有向グラフ化することで、10分後の渋滞発生予測モデルを構築した。表-2に示すように、車両検知器間の5種類の関係性を定義した上で、エッジとして9種類を定義した。なお、グラフ化するノードは、本線上と出入口に設置された車両検知器を対象としており、グラフ化した各ノードに対して19種類の特徴量を付随させた。特徴量は、ノードに対応する車両検知器の直前6時点（30分間）の台数、高車台数、時間占有率（5分間車両検知器データ：6時点×3種類）と、その車両検知器設置地点の車線数である。これらの特徴量を用いて、各ノードに対して、10分後に渋滞が発生するか否かを出力データとした渋滞発生予測を行った。具体的には、各路線の本線上の各車両検知器で10分後の渋滞発生の有無を予測した。渋滞発生の定義は、①10分後に渋滞が発生する、②直前6時点（30分間）は非渋滞、の2つの条件を満たすものとした。

2-3 GCNモデルの推定

渋滞発生予測モデルの推定のため、教師データとして2015年4月1日～2018年3月31日の5分間車両検知器データおよび車両検知器設置地点の車線数を使用した。なお、予測地点の車両検知器と6個隣までの車両検知器のデータもモデルの入力データとして使用している。モデルの精度検証は、構築した予測モデルに直前6時点（30分間）のデータを入力することで実施した。

3. GCNモデルの評価結果

渋滞発生予測モデルの精度検証には、2018年4

表-2 車両検知器間の関係性（エッジ）

種類	内容	エッジの種類
上流	本線上で隣り合う2個隣の3個隣の車両検知器を結ぶ 下流から上流に向かうエッジ	3
下流	本線上で隣り合う2個隣の3個隣の車両検知器を結ぶ 上流から下流に向かうエッジ	3
入口	ある高速道路入口に設置された車両検知器から 接続する本線の車両検知器へ向かうエッジ	1
出口	ある高速道路出口に設置された車両検知器から 接続する本線の車両検知器へ向かうエッジ	1
自己ループ	本線に設置されたグラフ化するノード（車両検知器）から その車両検知器自身に向かうエッジ	1

表-3 渋滞発生予測結果の評価指標

適合率	予測モデルが渋滞発生と予測した数のうち 実際に渋滞が発生した割合
再現率	実際に渋滞が発生した数のうち 予測モデルが渋滞発生と予測できた割合
調和平均 (f1-score)	適合率と再現率のバランスを見るための指標、 $2 \div (1 \div \text{適合率} + 1 \div \text{再現率})$ で算出

月1日～2019年3月31日の5分間車両検知器データを使用した。渋滞予測結果の集計基準は、渋滞発生を予測した時刻ちょうどに実際に渋滞が発生したものに加えて、予測時刻の後の25分以内までの渋滞発生（早めに予測）と予測時刻の5分前の渋滞発生（少し遅く予測）について、渋滞発生を予測できた（正解）として集計を行い、対象路線における渋滞発生予測結果をまとめた。なお、渋滞発生予測結果については、表-3に示す適合率、再現率、および適合率と再現率の調和平均（以下f1-scoreとする）で評価した。適合率は、予測モデルが渋滞発生と予測した数のうち実際に渋滞が発生した割合を表現している。再現率は、実際に渋滞が発生した数のうち予測モデルが渋滞発生と予測できた割合を表現している。適合率が高いと、発報した情報の正確性が高くなり、再現率が高いと、見逃す回数が減る。また、管制員への情報提供を考える際、適合率と再現率のバランスのとれた予測モデルが利用しやすいと考えられるため、この適合率と再現率のバランスを見る指標としてf1-scoreを使用した。

3-1 11号池田線上りでの予測モデルの評価結果

11号池田線上りの評価指標別予測結果を表-4に示す。また、図-3に、モデルが渋滞発生を予測した場合に、実際の渋滞発生時刻と渋滞発生を

予測した時刻との時間差の構成比率を示す。これは、時間的にも正しく渋滞発生を捉えられるのか確認するものである。表-4を見ると、11号池田線上りの渋滞発生予測結果では、適合率、再現率は、0.81, 0.81であり、どちらの指標も同程度の割合であった。また、f1-scoreの計算結果は、0.81であった。図-3を見ると、予測結果を正解としたもの（図-3の円グラフ赤枠）の中で渋滞発生予測時刻と実際の渋滞発生時刻がちょうど一致したもの（0分）が3,394件（渋滞発生を予測した件数の33.1%）と最も多く、時間的にも渋滞発生を正確に予測できた。

3-2 1号環状線予測モデルの評価結果

1号環状線の評価指標別予測結果を表-4に示す。また実際の渋滞発生時刻と予測時刻との時間差の構成比を図-4に示す。表-4を見ると、1号環状線全線の渋滞発生予測結果では、適合率、再現率、f1-scoreは、それぞれ0.62, 0.71, 0.66であり、適合率の方が低く、少し偏りがある結果となった。池田線の結果と比較し、予測モデルの精度が低いことがわかる。図-4を見ると、予測結果を正解としたものの中で最も多い件数になったものは、5分～30分後に渋滞が発生しなかったものであり、38.2%程度を占めている。この予測モデルの結果では、約4割が空振り（図-4の円グラフ黒枠）となってしまう、実装を見据えると予測精度向上の検討が必要である。

4 CNNモデルでの評価結果との比較

4-1 CNNモデルとGCNモデルの比較

各モデルの構造の違い、特徴については先に述べた通りであるが、既往研究で用いたCNNモデルと今回の検討で用いたGCNモデルの比較を表-5に示す。まず、CNNモデルでは、5分間車両検知器データのみを入力データとして用いていたが、GCNモデルでは、精度向上を目的として、車両検知器データに加え、車両検知器設置位置の車線数も用いることとした。次に出力データとし

表-4 11号池田線と1号環状線の予測結果

路線	適合率	再現率	f1-score
11号池田線上り	0.81	0.81	0.81
1号環状線	0.62	0.71	0.66




図-3 実際の渋滞発生時刻と予測時刻の時間差 (池田線全地点での予測結果)




図-4 実際の渋滞発生時刻と予測時刻の時間差 (環状線全地点での予測結果)

表-5 CNNモデルとGCNモデルの比較

	CNNモデル	GCNモデル
学習データ	【5分間車両検知器】 台数・高車台数・時間占有率・流入台数・流出台数・流入高車台数・流出高車台数	【5分間車両検知器】 (台数・高車台数・時間占有率・流入台数・流出台数・流入高車台数・流出高車台数) + 車線数
入力	ある1つの本線検知器に対し、 (本線台数・本線高車台数・本線時間占有率・流入台数・流出台数・流入高車台数・流出高車台数) × 6時点(直近30分) = 42個のデータ ※出入口口がない地点では、 出入口口の台数・高車台数を0台として入力	・本線の各車両検知器が持つ情報の構成 (台数・高車台数・時間占有率) × 6時点(直近30分) + 車線数 = 19種類 ・出入口(流入)の車両検知器が持つ情報の構成 (台数・高車台数) × 6時点(直近30分) = 12種類
★入力全体データ数	本線の検知器数 × 42	本線の検知器数 × 19 + 出入口の検知器数 × 12
期間	2015年4月30日～2017年11月6日	2015年4月1日～2018年3月31日
出力	各予測地点の10分後の全渋滞発生	各予測地点の10分後の自然渋滞発生
予測地点	11号池田線：44箇所 1号環状線：23箇所	11号池田線：44箇所 1号環状線：23箇所
モデルの構造	隠し込み層：7層 全結合層：3層	GCN層：7層 全結合層：3層
検証期間	2018年4月4日～2019年3月31日	2018年4月1日～2019年3月31日

て、モデルで予測する渋滞発生を変更している。CNNモデルでは、全ての渋滞発生を予測することを目的としていた。一方、GCNモデルでは、

自然渋滞のみを対象とした。なお、モデルの予測精度の比較を実施するにあたり、CNN モデルで予測した渋滞発生に関しては、全ての渋滞発生件数のうち、自然渋滞のみを対象とし再集計したものをを用いた。

4-2 11号池田線上下り予測モデルの比較分析

11号池田線上下りの渋滞発生予測結果について、評価結果の比較を表-6に、各地点（車両検知器設置地点）での予測結果の比較を図-5に示す。なお、表-6の評価結果と図-5に示す渋滞発生回数は自然渋滞のみ対象としている。表-6を見ると、CNNモデルは適合率と再現率で値の違いがあり、空振りは少ないが見逃しが多いというモデルになっている。一方、GCNモデルはどちらの値も同程度であり、f1-scoreも高く、バランスの取れたモデルになっている。池田線上下り各地点での予測結果についてCNNモデルとGCNモデルで比較した結果、ほぼ全ての地点においてGCNモデルの方が精度が高くなった（図-5）。CNNモデルで検討した際、課題となっていた環状線の合流部分付近の精度についても、GCNモデルに変更することで、大きく予測精度が向上している。これは、GCNモデルの特徴として、予測計算に合流先の情報を加味できたことが、精度向上につながっていると考えられる。

4-3 1号環状線予測モデルの比較分析

1号環状線の渋滞発生予測結果について、評価結果の比較を表-7に、各地点での予測結果の比較を図-6に示す。表-7を見ると、CNNモデルよりもGCNモデルの方が、適合率、再現率、f1-scoreともに高い値となっている。CNNモデルでは、全ての評価項目で0.5を下回っており、モデルの予測精度は低い。GCNモデルに変更することで精度は向上しているが、0.6~0.7程度であり、実装に向けては、さらなる精度向上に向けた検討が必要である。図-6は、環状線各地点の予測結果について各モデルの比較を示している。全ての地点において、GCNモデルの方が精度が良くな

っているが、評価値を見ると、多くの地点で0.6程度の値となった。合流部地点の予測結果に着目すると、GCNモデルにすることで池田線下りの分流付近や千日前線への分岐付近等の精度は他に比べ向上している。池田線同様に、GCNモデルの特徴が精度向上を促していると考えられる。

表-6 11号池田線上下りでの評価結果の比較

	適合率	再現率	f1-score
CNN	0.85	0.62	0.71
GCN	0.81	0.81	0.81




図-5 各地点の予測結果比較（11号池田線上下り）

表-7 1号環状線での評価結果の比較

	適合率	再現率	f1-score
CNN	0.36	0.44	0.40
GCN	0.62	0.71	0.66




図-6 各地点の予測結果比較（1号環状線）

5. 1号環状線におけるGCN予測結果の検証

11号池田線では、GCNモデルのf1-scoreが0.8を上回ったが、1号環状線においてはf1-scoreが0.7に満たなかった。そこで、予測を外しやすい地点を把握するため、予測結果の可視化を行った。図-7にある1日の予測結果を可視化した図を示す。可視化図の背景色は各地点における車両の通過速度[km/h]（真値）を表す。さらに、渋滞日報により渋滞と判定された地点は時速30km/hの色（赤茶色）で塗りつぶしている。なお、縦方向には検知器の地点（2地点）ごと、横方向は5分間隔で色が塗られている。図中の白塗り◇印は実際に渋滞が開始したとしている地点を示しており、白塗りの☆印は予測モデルが渋滞発生すると予測した地点を示している。例えば、白塗り◇印よりも2時刻分早く（左側に）白塗り☆印がついていれば正しく10分後の渋滞発生を予測できていることを意味する。図-7を見ると、短時間で解消されるような小さな渋滞では、不意打ちや空振りが目立つ。一方で、時間的、距離的に長い渋滞は概ね正しく予測できている。

6. GCNモデルの改良および渋滞先頭位置予測

前述したモデルは、下流から延伸してくる地点の渋滞も含め、全地点の渋滞発生予測するモデルとなっている。交通管制での運用を考えると、下流からの延伸ではない渋滞先頭位置のみを予測する方がより価値の高い情報になると考え、渋滞先頭予測するようにモデルの改良を行った。改良モデルの渋滞先頭予測精度結果について以下に示す。

6-1 改良したGCNモデル

前述のGCNモデルからの主な改良点は、学習データに時間帯データと道路構造データを追加した。さらに、渋滞先頭を重点的に高精度で予測することを目的に、ある時刻において1地点でも渋滞先頭が発生しているデータと、それ以外のデータの比率が1:1になるように、渋滞先頭を含む学習データを水増しした。この水増しを行ったうえ

で、モデルの推定を行った（表-8）。渋滞先頭の定義を、①ある地点（JDP（1つの検知器の勢力範囲））において渋滞が発生している、②該地点（JDP）と上流・下流の3つまで隣のJDPのすべてにおいて、その前の6時点（30分間）すべてで非渋滞、の2つの条件を満たす場合と設定した。ただし、3つ隣までのJDPにおいて同時に①と②を満たしたものがあある場合、最も下流のJDP渋滞発生のみを渋滞先頭とする。

6-2 検証結果

渋滞先頭予測の評価では、10分後の渋滞発生を予測したものの中から、渋滞先頭を予測しているものを抽出し、予測時点の5分前～25分後までに1つ隣までのJDPを先頭とする渋滞が発生していれば正解とした。渋滞が頻発する地点とそうでない地点での予測精度を確認するため、渋滞先頭発生回数の多い地点を「ボトルネック区間」と設定し、予測精度を確認した。ボトルネック区間とは渋滞先頭が年間180回以上生じているJDP（ボトルネック地点と呼ぶ）を抽出し、それらを5kmごとにそれらをまとめた区間とする（図-8）。対象路線は、松原線上りと神戸線下りとする。




図-7 2018年7月24日の予測結果可視化図

表-8 GCNモデルの改良点

GCNモデルの主な改良点	
学習データ	時間帯データの追加、道路構造データの追加、渋滞先頭データの水増し
入力	・時間帯【追加項目】 時間帯という1種類の情報を17次元の情報でモデルに入力 ※6=21時までの16次元+それ以外(2時~翌5時台)=17次元
	・構造物データ【追加項目】 構造物データは下記の9種類。※これは本線の隣り合う2地点間に情報があり、（本線の検知器数-1箇所分の情報 ①2地点間の距離(km) ②2地点間にある曲率の平均 ③2地点間にある曲率の最大値 ④2地点間にあるクロソイドの平均値 ⑤2地点間にあるクロソイドの最大値 ⑥2地点間の円弧の地点数 ⑦2地点間のクロソイドの地点数 ⑧2地点間のうちの上流側の標高を0としたときの2地点間の標高の最大値(m) ⑨2地点間のうちの上流側の標高を0としたときの2地点間の標高の最小値(m)
	・渋滞先頭データの水増し【追加項目】 ある時刻において1地点でも渋滞先頭が発生しているデータと、それ以外のデータの比率が1:1になるように、渋滞先頭を含む学習データを水増し。
	★入力全体：本線の検知器数×19 + 出入口の検知器数×12 + (本線の検知器数-1)×9 + 17(時間帯情報)
	期間 2015年4月1日~2019年3月31日
検証期間 2019年4月1日~2020年3月31日	




図-8 ボトルネック区間と対象検知器の決め方

(1) 松原線上下に関する精度検証

各地点における渋滞先頭予測精度を図-9に示す。14号松原線上下におけるボトルネック区間は、駒川入口付近(検知器番号990)と松環合流付近(検知器番号938)の2区間である。この2地点における先頭予測精度を表-9に示す。駒川入口付近の f1-score は0.7近くの精度が確保されているが、松環合流の f1-score は0.48にとどまっている。これは再現率が0.36と低いためであり、この地点では不意打ちが多発してしまう。また、ボトルネック区




図-9 松原線上下各地点の渋滞先頭予測精度

表-9 松原線上下ボトルネック区間先頭予測精度

ボトルネック区間	渋滞先頭発生回数	適合率	再現率	f1-score
駒川入口	480	0.67	0.68	0.67
松環合流	670	0.74	0.36	0.48

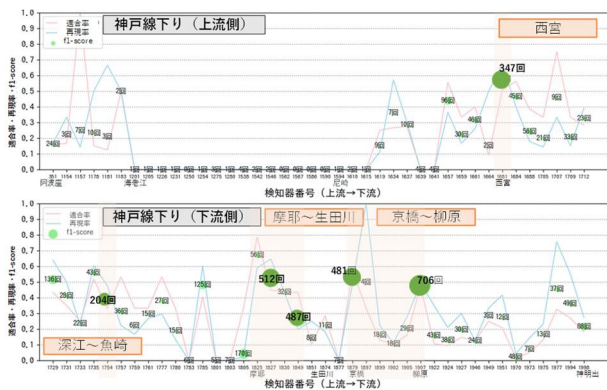


図-10 神戸線下り各地点の渋滞先頭予測精度

表-10 神戸線下りボトルネック区間先頭予測精度

ボトルネック区間	渋滞先頭発生回数	適合率	再現率	f1-score
西宮	347	0.51	0.68	0.58
深江～魚崎	204	0.33	0.48	0.39
摩耶～生田川	999	0.44	0.43	0.44
京橋～柳原	1187	0.51	0.49	0.50

間以外の地点の f1-score は、ほとんどが0.3以下となり、ボトルネック区間と比較して低い結果となった。渋滞先頭発生回数が少なく学習データが少ない地点では予測精度が低下すると考えられる。

(2) 神戸線下りに関する精度検証

渋滞先頭予測精度を図-10に示す。3号神戸線下りにおけるボトルネック区間は西宮(検知器番号1681)、深江～魚崎(検知器番号1754)、摩耶～生田川(検知器番号1827, 1849)、京橋～柳原(検知器番号1879, 1907)の4区間である。この4区間における先頭予測精度を表-10に示す。神戸線下りにおける渋滞先頭予測について、どのボトルネック区間においても f1-score が0.7に届かなかった。複数のボトルネック区間が連続しているような地点では渋滞先頭予測の精度が低下することが考えられる。

7. まとめ

本稿では、複雑な道路構造を考慮できる機械学習(GCN)を用いて、5分間車両検知器等のデータから10分後の交通渋滞発生を予測するモデルを構築し、予測精度の検証および過去にCNNを用いて構築・検証を行った渋滞発生予測モデルの予測結果との比較分析した結果について報告した。得られた成果を以下にまとめる。

7-1 得られた知見

- ① 10分後の渋滞発生予測手法としてGCNの有効性を確認した。
- ② CNNモデルとの比較では、11号池田線上下、1号環状線ともに、ほぼ全ての予測地点で予測精度が向上していることがわかった。

③ 1号環状線のGCNモデル予測結果は、短時間で解消されるような小さな渋滞では、不意打ちや空振りが目立つ。一方で、時間的、地点的に長い渋滞は概ね正しく予測できていることがわかった。

④ 渋滞先頭予測精度は、全ての地点で f1-score が 0.7 を下回った。また、ボトルネック区間とボトルネック区間以外の地点で予測精度を比較すると、渋滞発生回数が少ないボトルネック区間以外の地点の方が予測精度が低い結果となった。

7-2 今後の方針

(1) 有効な渋滞予測情報の定義

阪神高速道路において渋滞発生状況を渋滞量で統計的に集計する場合、全ての発生した渋滞を対象とせず、渋滞の継続時間および渋滞長が「30分以上」「1km以上」の渋滞を対象としている。今回の検討結果から、時間的、地点的に長い渋滞は概ね正しく予測できていることがわかった。機械学習を用いた渋滞予兆予測モデルにおいても、全ての発生した渋滞を対象とするのではなく、有効な渋滞予測情報に限定した情報の出力が必要である。一方、過去の管制員ヒアリングでも「小さ

な渋滞が頻繁に起こる情報も大切である」との指摘を受けた。そのため、実現機能・性能が見通せる段階に至れば、管制員へのヒアリングを踏まえ、提供条件を決定していく必要がある。

(2) 特定の検知器ごとにモデルを学習

今回の渋滞先頭予測精度結果を考えると、交通管制へ実装するには更なる予測精度向上が必要である。予測精度向上に向け、今回のような全検知器の渋滞予兆を同時に予測するモデルではなく、ある1つのボトルネック地点の検知器の渋滞予兆だけを予測するモデルを作成することが考えられる。一方でその場合、検知器ごとにモデルの学習をする必要があるため、学習のコストは高くなる。学習コストと精度向上のバランスを考えて、渋滞の発生を特に検知したい地点に絞ってこのような学習をさせることが効果的と考えられる。

参考文献

- 1) 向井梨紗, 櫻木伸也, 玉川大, 山本昌孝, 幡山五郎, 平野竜洋, 加瀬駿介, 鈴木健太郎, 小島悠紀子, 寺前智文: 機械学習 (CNN) を用いた阪神高速道路における交通混雑予測手法に関する研究, 第 17 回 ITS シンポジウム, 2019

TRAFFIC CONGESTION PREDICTION ON THE HANSHIN EXPRESSWAY USING DEEP LEARNING

Tomofumi TERAMAE, Risa MUKAI, Yoshifumi NISHIUMI,
Kentaro SUZUKI and Yukiko KOJIMA

A traffic congestion prediction model was previously developed using the convolutional neural networks (CNN). However, the accuracy of prediction by the CNN was found to be low at merging points with complicated road structures. This paper reports the results of traffic congestion prediction of 10 minutes later using the graph convolutional networks (GCN), a machine learning method that can consider the complicated road structures. Also described in this paper is the results of comparative analysis with the traffic congestion prediction by the CNN.

寺前 智文



阪神高速技研株式会社
技術部 技術課
Tomofumi TERAMAE

向井 梨紗



阪神高速道路株式会社
保全交通部 交通技術課
Risa MUKAI

西海 能史



阪神高速道路株式会社
東京事務所付
Yoshifumi NISHIUMI

鈴木 健太郎



阪神高速技研株式会社
技術部 技術課
Kentaro SUZUKI

小島 悠紀子



阪神高速技研株式会社
技術部 技術課
Yukiko KOJIMA