

Graph Convolutional Networks を用いた 阪神高速道路における交通渋滞発生予測

寺前智文*¹ 向井理沙*² 西海能史*² 鈴木健太郎*¹ 小島悠紀子*¹
廣田敦士*³ 幡山五郎*³ 影本義明*³ 櫻木伸也*³ 阿部敦*³
所属*¹ 阪神高速技研株式会社
所属*² 阪神高速道路株式会社
所属*³ オムロンソーシアルソリューションズ株式会社

交通渋滞の発生を事前に予測することができれば、交通渋滞を緩和したり未然に防いだりすることが期待できる。以前、我々は機械学習（Convolutional Neural Networks: CNN）を用い、車両検知器データを利用した交通渋滞発生予測に取り組んだ。CNN は、路線の分合流や出入口地点における車両検知器の位置関係等を適切に扱うことが困難で、道路構造が複雑な地点の予測精度が低かった。そこで本稿では、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、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 を用いて構築し、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。

Jam Congestion Prediction on Hanshin Expressway With Graph Convolutional Networks

Tomofumi Teramae*¹ Risa Mukai*² Yoshifumi Nishiumi*² Kentaro Suzuki*¹ Yukiko Kojima*¹
Atsushi Hirota*³ Goro Hatayama*³ Yoshiaki Kagemoto*³ Shinya Sakuragi*³ Atsushi Abe*³
Affiliation *¹ Hanshin Expressway R&D Company Limited
Affiliation *² Hanshin Expressway Company Limited
Affiliation *³ OMRON Social Solutions Company Limited

We worked on jam congestion prediction using Convolutional Neural Networks (CNN). However, the prediction accuracy by CNN was low at points with complicated road structures. In this paper we report the results of predicting traffic congestion in 10 minutes later using Graph Convolutional Networks (GCN), a machine learning method that can consider complicated road structures. In addition, we also report the results of comparative analysis with the predicting traffic congestion of CNN.

Keyword: *traffic congestion, deep learning, graph convolutional networks*

1. 背景

(1) 阪神高速道路における現状と目的

阪神高速道路は1日あたり約75万台の利用があり、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2.5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様々な施策を行っている。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。その初動が早ければ早いほど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手法について検討することとした。

(2) 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「コンボリュショナル・ニューラルネットワーク（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号池田線上の検討をした結果、全体での予測精度は70%程度であり、10分後の渋滞発生予測手法として機械学習の有効性を確認できた。しかしながら、地点ごとに予測精度を検証すると、他路線（1号環状線）との合流部付近の精度が極端に悪くなるのが課題となった（図1）。

(3) 本検討で予測に用いた手法

既往研究で課題となった分合流部付近の予測精度を改善するため、本検討では、ここ数年で研究が進




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

み、画像認識などで利用されている「グラフ・コンボリュショナル・ネットワーク（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²⁾。GCNでは、グラフのノードに付随する特長量（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られるため、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」を構築することとした。

2. 渋滞発生予測モデル

(1) GCNモデルの概要

本検討では、阪神高速道路でも渋滞発生頻度の高

い路線のうち、単路線で分かりやすく、CNN を用いた渋滞発生予測モデルでも実施した 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 5 分間車両検知器データを用いて、路線毎に 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を表 1 に示す。

(2) GCN の渋滞予兆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でつなぎ、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する。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。

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 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

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	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

特徴量は、ノードに対応する車両検知器の過去 30 分間の台数、高車台数、時間占有率（5 分毎データ：6 時点×3 種類）と、その車両検知器設置個所の車線数である。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予兆予測を行う。

(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箇所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する。今回構築したモデルは 10 分後の渋滞発生を予測するモデルであり、①10 分後に渋滞が発生する、②直近 6 時点（30 分間）は非渋滞、の 2 つの条件を満たすものを渋滞発生と定義した。

3. GCN モデルの検証結果

渋滞発生予測モデルの精度検証には、2018 年 4 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、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）として集計を行った。各路線について渋滞発生予測結果をまとめる。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（f1 スコア）で評価する。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おり、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、見逃す件数が減る。こういった情報は、適合率と再現率のバランスのとれた予測モデルが管制員にとっては利用しやすく、調和平均は、この適合率と再現率のバランスを見る指標として使用する。

(1) 11 号池田線上り予測モデルの予測結果

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

時刻との時間差がどの程度あったのかを示す。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、80.6%、80.9%であり、どちらの指標も同程度の割合であった。また、調和平均の計算結果は、80.7%であった。図 3 を見ると、予測結果を正解としたもの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%）と最も多かった。

(2) 1号環状線予測モデルの予測結果

1号環状線の評価指標別結果を表 4 に示す。また実際の渋滞発生した時刻と渋滞発生を予測した時刻との差がどの程度であったかを図 4 に示す。

表 4 11号池田線上りと1号環状線の評価指標別結果

	適合率	再現率	調和平均
11号池田線上り	80.6%	80.9%	80.7%
1号環状線	61.8%	71.4%	66.3%




図 3 実際の渋滞発生時刻と予測時刻の時間差 (池田線上り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)

図 4 を見ると、1号環状線全線の渋滞発生予測結果では、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。また、適合率、再現率、調和平均は、それぞれ61.8%、71.4%、66.3%であり、適合率の方が低く、少し偏りがある結果となった。

図 8 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(②)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割が空振りとなってしまう、実装を考えると予測精度向上の検討が必要である。

4. CNNモデルでの予測結果との比較

既往研究で分析した CNN を用いた渋滞発生予測モデルと、本検討で実施した GCN を用いたモデルとの予測結果の比較分析を行う。

(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 モデルの比較表を表 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てモデルを構築した。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。

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 流入出台数・流入出高車台数	【5分間車両検知器】 台数・高車台数・時間占有率 流入出台数・流入出高車台数 + 車線数
入力	直近の6時点(30分) 7種類×6時点=42種類	直近の6時点(30分) 7種類×6時点+1種類=43種類
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	池田線：44箇所 環状線：23箇所	池田線：44箇所 環状線：23箇所
モデルの構造	畳み込み層：7層 全結合層：3層	畳み込み層：7層 全結合層：4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

(2) 11号池田線上下予測モデルの比較分析

11号池田線上下の渋滞発生予測結果について、全地点渋滞予測結果正誤集計の比較を表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、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、バランスの取れたモデルになっている。調和平均も高く、モデルの予測精度が向上したことがわかる。図5は、池田線上下各地点での予測結果についてCNNモデルとGCNモデルで比較しているが、ほぼ全ての箇所においてGCNモデルの方が精度が高くなっている。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とがわかる。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。また、渋滞発生回数が低いところも含め、全体的に調和平均は高い値を示しているが、塚本手前の値は低くなっている。塚本手前よりも渋滞発生回数は少ないが、予測精度が高い箇所もあり、何に起因して、このような結果になったのかの検証も必要である。

(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、全地点渋滞予測結果正誤集計の比較を表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、調和平均ともに高い値となっており、精度が向上している。CNNモデルでは、全ての評価項目で50%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、60%~70%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CNNモデルとGCNモデルで比較している。全ての箇所において、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60%程度の値となった。分合流部地点の予測結果に着目すると、CNNモデルからGCNモデルに変更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号池田線上下全地点渋滞予測結果正誤集計の比較

	適合率	再現率	調和平均
CNN	84.8%	61.6%	71.4%
GCN	80.6%	80.9%	80.7%

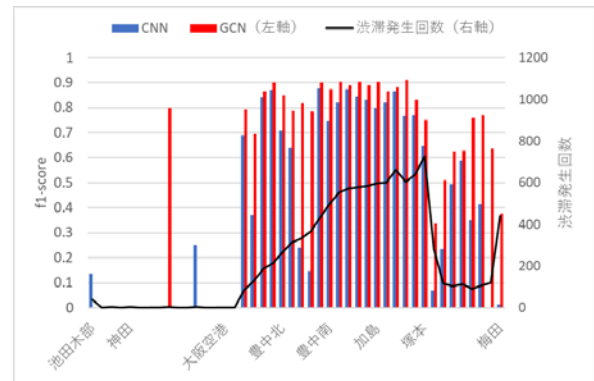


図5 各地点の予測結果の比較 (11号池田線上下)

表7 1号環状線全地点渋滞予測結果正誤集計の比較

	適合率	再現率	調和平均
CNN	35.8%	44.2%	39.6%
GCN	61.8%	71.4%	66.3%

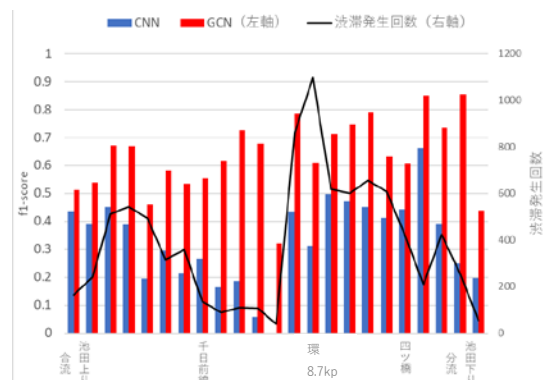


図6 各地点の予測結果の比較 (1号環状線)

5. 1号環状線におけるGCN予測結果の把握

1号環状線において、調和平均 (f1-スコア) が70%に満たなかった。そのため、予測を外しやすい箇所を把握するため、予測結果の可視化を行った。

図 7 に 2018 年 7 月 24 日の 1 日の予測結果の可視化結果を示す。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箇所は時速 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数 (23 個) 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箇所を示しており、白塗りの☆印は予測モデルが渋滞発生すると予測した箇所を示している。すなわち、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、地点的に長い渋滞は概ね正しく予測できている。短時間で解消される小さな渋滞と、長時間持続する渋滞について、それぞれの推定精度を集計することや、短時間で解消される小さな渋滞は対象外とし、影響の大きい長時間継続する渋滞のみを予測するように学習させたモデルを構築することが、今後の課題となる。




図 7 2018 年 7 月 24 日の予測結果可視化例

6. まとめ

(1) 得られた知見

得られた成果を以下にまとめる。

- 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 GCN を用いたモデルの予測精度の検証をおこなった結果、池田線上りでは、80.7% と高い精度で予測できたが、環状線では、66.3% 程度であった。
- ③ CNN モデルとの比較では、11 号池田線上り、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。

(2) 今後の方針

得られた課題を以下に示す。

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。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 渋滞予兆予測モデル活用条件の整理

環状線において、時間的、地点的に長い渋滞は正しく予測できているが、すぐに解消される渋滞を予測することが難しいなど予測精度が悪くなる条件が判明してきた。また、過年度検討結果からも検知器の故障発生時や事故渋滞等、機械学習機能が有効に機能しない様々な例外条件に関する知見が蓄積されてきた。これまでは主に機械学習技術を駆使して渋滞予兆予測の精度向上に取り組んできたが、これらの知見をもとに実践的なシステム化計画を立案することが必要である。

③ 予測モデルの改良

本検討で構築したモデルは、短時間で解消されるような渋滞も含め、全地点において、全ての自然渋滞を予測するモデルである。運用方法に適するように、例えば、渋滞先頭箇所のみを予測するようにモデルを推定する必要がある。

謝辞: 本検討をすすめるにあたり、(株)地域未来研究所の田名部淳様に多くのご助言をいただきました。この場を借りて深く御礼申し上げます。

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
- 2) Wu, Z., Pan, S., Chen, F., Long, G., Zhang, C., & Yu, P. S. (2019). A comprehensive survey on graph neural networks. arXiv preprint arXiv:1901.00596.