

機械学習を用いた阪神高速道路における 交通渋滞予測精度向上に関する研究

寺前 智文¹・向井 梨紗²・鈴木 健太郎¹・小島 悠紀子¹・阿部 敦³

¹非会員 阪神高速技研株式会社 技術部 (〒530-6123 大阪市中中之島 3-3-23)

E-mail:tomofumi-teramae@hanshin-tech.co.jp

²非会員 阪神高速道路株式会社 保全交通部 (〒532-0005 大阪市北区中之島 3-2-4)

E-mail: risa-mukai@hanshin-exp.co.jp

²非会員 オムロンソーシアルソリューションズ株式会社 ソリューション事業統括本部

(〒553-0003 大阪市福島区福島 3-14-24)

E-mail: atsushi.abe@omron.com

阪神高速道路は 1 日あたり約 75 万台に利用され、日常的に交通渋滞が多数発生している。この交通渋滞を事前に検知することは、交通管制業務の効率化につながると考えられる。本論文では、機械学習のうち、ここ数年で研究が進み、画像認識などで利用されているグラフ・コンボリューショナル・ネットワーク (GCN) を用いて構築した「高速道路の渋滞発生を 10 分前に予測するモデル (GCN モデル)」について概要、予測結果の精度について報告する。また、過去にコンボリューショナル・ニューラルネットワーク (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。さらに、構築したモデルの課題についても整理して報告する。

Key Words: 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。しかしながら、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「コンボリューショナル・ニューラルネットワーク (以下、CNN)」を用いて検討を行った。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。この局所性が類似していることから、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 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)。




図1 CNNを用いた渋滞発生予測モデルの検証結果 (11号池田線 車両検知器設置地点の精度)

(3) 今回予測に用いた手法

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み、画像認識などで利用されている「グラフ・コンボリユーションアル・ネットワーク (以下、GCN)」を用いることとした。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 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長量をまとめる (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長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。なお、既往研究では、全ての渋滞発生を対象としたモデルを構築したが、本検討では、自然渋滞のみを対象としたモデルを構築することとした。




図2 CNN と GCN の計算モデルのイメージ

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 (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、2018 年度の阪神高速道路ネットワークを図 3、渋滞状況図を図 4 に示す。

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
学習データ	【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



出典：阪神高速道路(株)HP

図3 阪神高速道路のネットワーク図 (2018年度)

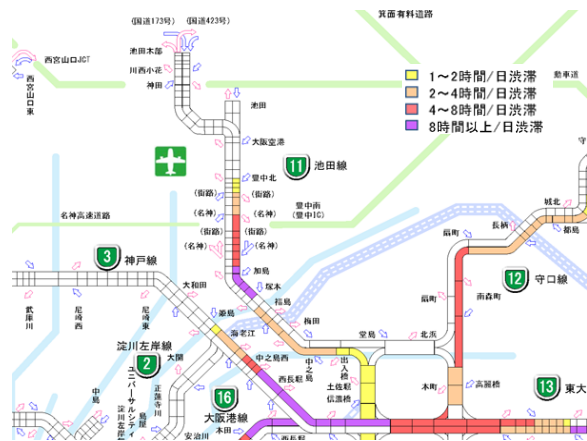


図4 渋滞状況図 (平日平均 (2018年度)) (11号池田線・1号環状線付近の抜粋)

(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。

本検討では、図 5 に示すとおり、上流・下流については 1 つ隣の車両検知器同士を結ぶエッジだけでなく、より遠くの車両検知器の影響を考慮しやすくするために、2 つ隣、3 つ隣の上流・下流の検知器をつなぐエッジも定義することにした。これにより、合計 9 種類の関係性が存在することになる (図 5)。なお、グラフ化するノードは、本線上に設置された車両検知器のみ対象としており、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。具体的には、池田線上り追越側の 44 箇所の車両検知器、環状線の第 2 走行に設置された 23 箇所の車両検知器から 5 分間隔で収集される台数、高車台数、時間占有率、および車両検知器設置箇所の車線数よりモデルを構築する。なお、予測地点の車両検知器とエッジでつながっている車両検知器のデータも教師データとして使用している (図 6)。

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るため、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、予測モデルの推定を行った。8 時に 10 分後の渋滞発生を予測する場合の発報例を図 7 に示す。

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

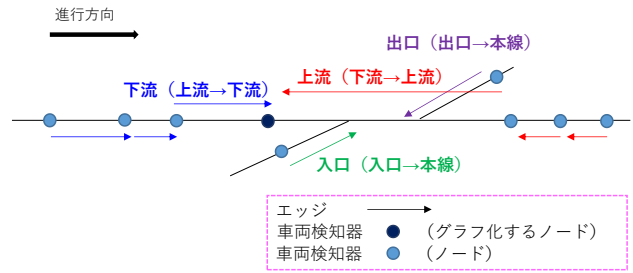


図 5 車両検知器間の関係性

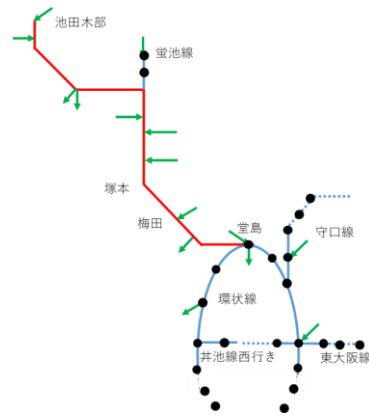


図 6 11 号池田線上り予測モデルに利用する車両検知器

EX) 8:00に8:10時点を予測する場合

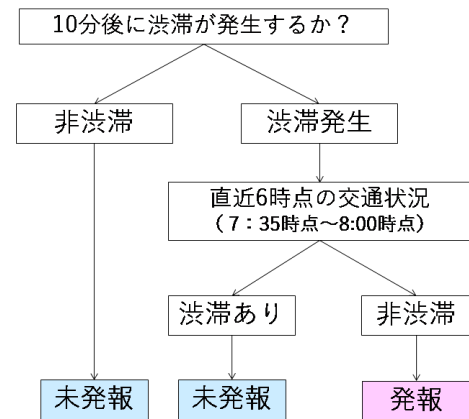


図 7 渋滞発生を予測する場合の発報例

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、実際に渋滞が発生する前に渋滞が予測できていることおよび予測から実際の渋滞発生まで 30 分以内であれば実運用上問題が無いと考え、渋滞発生を予測した時刻に対して、実際の渋滞が発生するまでが 30 分以内のもの (早めに予測) と予測した時刻より 5 分早く渋滞が始まったもの (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 → 正確率

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、管制員への有用な情報になると考えられ、適合率と再現率のバランスのとれた予測モデルが最も望まれる。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。

表 3 渋滞発生予測結果の評価指標

指標	内容	算出方法
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 → 正確率	④/ (②+④)
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	④/ (③+④)
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/ (1/適合率+1/再現率)

表 4 11号池田線上市と1号環状線の評価指標別結果

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

(1) 11号池田線上市予測モデルの予測結果

11号池田線上市の評価指標別結果を表 4に、渋滞発生予測結果について表 5示す。また、図 8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号池田線上市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 8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。また、渋滞発生が予測された場合、予測時刻から実際の渋滞発生時刻の差異が 10 分以内となるのは 72.1%であることがわかる。一方、渋滞発生予測したものうち、5 分～30 分後に渋滞が発生しなかったもの (②)、いわゆる空振りが 1,993 件と全体の 19.4%を占めた。

表 5 11号池田線上市全地点渋滞予測結果正誤集計

	池田線上市全線	予測	
		10分後に渋滞発生しない	10分後に渋滞発生する
真値	5分前～30分後に渋滞が発生しない	4,613,067 ①	1,993 ②
	5分前～30分後に渋滞が発生した	1,955 ③	8,265 ④




図 8 実際の渋滞発生時刻と予測時刻の時間差 (池田線上市全地点での予測結果)

(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、渋滞発生予測結果について表 6に示す。また実際の渋滞発生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 9に示す。

図 9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渋滞発生予測時間と、実際の渋滞発生時間が一致したものは 1,554件であり、わずか15.1%であった。最多になったものは、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とがわかる。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い、実装を考えると予測精度向上の検討が必要である。

表 6 環状線全地点渋滞予測結果正誤集計

	環状線全線	予測	
		10分後に渋滞発生しない	10分後に渋滞発生する
真値	5分前～30分後に渋滞が発生しない	2,404,925 ①	3,929 ②
	5分前～30分後に渋滞が発生した	2,545 ③	6,361 ④




図 9 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)

4. CNN モデルとの比較分析

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 モデルの比較を表 7 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。学習の期間は、CNN モデルでは、2015年4月30日～2017年11月6日で、GCN モデルでは、2015年4月1日～2018年3月31日となっている。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、GCN モデルにおいて突発事象に伴う渋滞については、学習データが少なく予測が難しいことから、今回は対象から外して構築することとした。各モデル構造は、モデル構造の設定やパラメータ初期値をランダムで割り振り、最も精度が高かったものを採用している。検証期間は、CNN モデルでは、2018年4月4日～2019年3月31日、GCN モデルでは、2018年4月1日～2019年3月31日となっている。

なお、モデルの予測精度を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 7 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、全地点渋滞予測結果正誤集計の比較を表 8 に、各地点（車両検知器設置地点）での予測結果の比較を図 10 に示す。な

お、図 10 に示す渋滞発生回数は自然渋滞のみ対象としている。

表 8 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。また、CNN モデルで低かった再現率が 20 ポイント程度向上したことにより、バランスのとれたモデルに変化しており、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 10 は、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、渋滞の頻度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頻度は少ないが、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。

表 8 11号池田線上下り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 10 各地点の予測結果の比較 (11号池田線上下り)

(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 9 に、各地点での予測結果の比較を図 11 に示す。

表 9 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、50%~60%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 11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おり、池田線上りの傾向と同様であったが、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。しかしながら、GCN モデルであっても調和平均は 66.3%にとどまった。これは入力で与える車両検知器の情報がまだ不足している可能性がある。GCN モデルへ与えるデータは、対象路線より 6 地点隣の車両検知器までである。更なる改善で 10 分先を予測するのであれば本来より遠くの車両検知器の情報も入力に含めることが考えられるが、計算機資源の制約やモデル推定にかかる時間の長期化に対して対応を工夫する必要がある。

表 9 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 11 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-score) 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に、時間帯・曜日・月ごとの精度を整理した

(1) 時間帯ごとの予測結果

図 12に時間帯ごとの予測結果を示す。横軸は時間帯

を表し、例えば横軸に「7」と書かれた棒は、7~8 時の予測結果を表す。渋滞発生回数の多い時間帯である朝方 (7~9時) と 14~16時は比較的高精度である。一方、渋滞発生回数の少ない昼頃 (11~14 時) や夜間は予測を外しやすくなっている。このことから、モデルをよく学習できる渋滞発生回数が多い時間帯の方が高精度になる傾向があることがわかる。しかし、渋滞発生回数が多くても夕方 17時台 (17~18時) は精度が伸び悩んでいる。

これらの時間帯ごとの予測精度の違いは、典型的な一日の予測結果を可視化することで確認できる。図 13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 13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い渋滞と、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い渋滞は対象外とし、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 12 時間帯ごとの予測結果 (環状線)

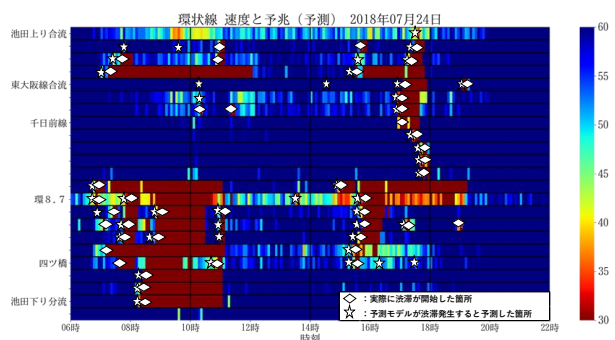


図 13 2018年7月24日の予測結果可視化例

(2) 曜日ごとの予測結果

曜日ごとの予測結果と渋滞発生回数を図 14に示す。土曜日と日曜日は渋滞発生回数が少なく、また日曜日に若干予測精度が低い。しかし、発生回数自体が少ないので全体精度への影響は小さいと考えられる。その他の曜日間には予測精度に大きな差はなかった。




図 14 曜日ごとの予測結果

(3) 月ごとの予測結果

月ごとの予測結果を図 15に示す。横軸は月を表しており、評価時には 2018 年 4 月 1 日～2019 年 3 月 31 日のデータを用いているので、一番左の 4 は 2018 年 4 月を表し、一番右の 3 は 2019 年 3 月を表している。2018 年 11 月と 2019 年 1 月の予測精度が低いことが確認できた。これは 2018 年 11 月 2 日～2018 年 11 月 12 日の 11 日間は 15 号堺線・17 号西大阪線が終日通行止め工事を行っており、平常日とは異なる状況で、堺線、西大阪線、環状線をはじめとする周辺道路の状況が過去の学習データには存在しないパターンとなっていたことに起因すると考えられる。また、2019 年 1 月の精度が低かった理由としては、他の月と比べ渋滞発生回数が少ないために誤検知 1 件が全体に占める割合が高くなり予測精度を下げる結果となった。




図 15 月ごとの予測結果

6. まとめ

(1) 得られた知見

本論文では、GCN を用いて、5 分間車両検知器データおよび車線数のデータから 10 分後の渋滞発生を予測するモデルを構築したことについて、モデルの概要、予測精度の検証および過去に CNN を用いて構築し、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。

- ① 既存の交通管制データ (5分間車両検知器データ) を活用した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池田線上り全線、環状線全線を対象としておこなった結果、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 GCNモデルで渋滞発生と予測した全数のうち、実際に渋滞が発生した割合について検証した結果、池田線上りでは、予測通り10分後に渋滞が発生した割合が最も多く33.1%であったが、環状線では、わずか15.1%であった。環状線で最も多くの割合を占めたのは、渋滞が発生しない、いわゆる空振りした割合 (38.2%) であった。
- ④ 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。
- ⑤ 環状線においては、GCNモデルは、CNNモデルに比べ精度が向上しているものの、実装に向けては、更なる精度向上に向けた検討が必要であることがわかった。
- ⑥ 通行止めによる混雑状況の変化のような、学習データ (過去のデータ) と傾向の異なるデータに対する予測精度は低くなる。また、環状線においては朝の予測精度は良いが、夕方すぐに解消される渋滞を予測することが難しいなど、状況に応じて予測性能が変わる場合がある。予測性能が低下する条件を満たしている際には、利用シーンに合わせて情報を取捨選択して発報することが考えられる。

(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

分析の結果、大規模な通行止めのような期間中は予測結果が期待した通りにならないことがわかった。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の予測には限界があることがわかってきた。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、機械学習技術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ため、渋滞予兆予測機能が十分に性能を発揮できる状況とその際の管制業務の利用シーン・業務フロー案を検討し、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。

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.

(2020. 10. 2 受付)

Jam Congestion Prediction on Hanshin Expressway With Graph Convolutional Networks

Tomofumi TERAMAE, Risa MUKAI, Kentaro SUZUKI,
Yukiko KOJIMA and Atsushi ABE

We worked on traffic congestion prediction using Convolutional Neural Networks (CNN). However, prediction accuracy by CNN was low at point with complicated road structures. In this paper we report the results of predicting traffic congestion after 10 minutes using Graph Convolutional Networks (GCN) as 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.