

CNNを用いた渋滞発生予測モデル

道原 侑也¹・吉井 稔雄²・坪田 隆宏³

¹非会員 愛媛大学 工学部環境建設工学科 (〒790-8577 愛媛県松山市文京町3)
E-mail: michihara.yuya.16@cee.ehime-u.ac.jp

²正会員 愛媛大学大学院 理工学研究科 (〒790-8577 愛媛県松山市文京町3)
E-mail:yoshii@cee.ehime-u.ac.jp

³正会員 愛媛大学大学院 理工学研究科 (〒790-8577 愛媛県松山市文京町3)
E-mail:t.tsubota@cee.ehime-u.ac.jp

本研究では、渋滞発生を予測する CNN モデルを構築し、モデルが有するパラメータ数と入力変数の質がモデルの予測精度に与える影響を分析する。具体的には、予測時点の直前 1 時間に車両感知器から得られる 5 分間平均速度、交通量、オキュパンシーのデータを用いて、予測時点から 30 分後までに渋滞が発生する確率を出力する CNN モデルを構築する。首都高速道路 4 号線上り道路ネットワークを対象とした分析を行った結果、モデルの説明力を高める最適なパラメータ数が存在する可能性が示された。また、適切な入力変数を追加することによってモデルの説明力が向上する、との結果が得られた。

Key Words : *traffic jam, Convolutional Neural Network, deep learning*

1. はじめに

近年では、GWや年末年始の繁忙期などにおいて、渋滞発生に関する予測情報が道路利用者に提供されている。同情報提供によっては、情報を獲得した道路利用者が渋滞を避ける行動を取ることで需要が平準化すると期待される。また、渋滞発生を直前に予測することができれば、渋滞発生が予測される道路区間における速度規制

(Variable Speed Limit) の実施や上流からボトルネックに到達する交通量の調整を行うなど、動的な交通制御を実施することで渋滞発生の回避、あるいは渋滞による損失を軽減できる可能性がある。

渋滞の予測について、舟橋ら¹⁾は、東名高速道路の上り線のうち、ボトルネックが存在する区間を対象として事故・渋滞発生確率を予測するベイジアンネットワークモデルの構築とその精度検証を行った。この研究では、車両感知器データ、事故データ、天候データを用いて事故・渋滞発生確率の予測を行い、高精度で渋滞発生ならびに事故発生を予測するモデルを構築した。また、近年では、AIを用いた渋滞発生予測モデルが開発され、例えばNEXCO東日本では、web上でリアルタイムの渋滞予知情報を提供する実証実験²⁾を行っている。

一般に、多数のパラメータを有するニューラルネットワークは、モデルの空間移転性を確保することができな

いものの、特定の道路区間を対象として十分な量のデータ収集が可能な場合には、回帰モデルなどの従来の予測モデルとの比較において、高い精度で渋滞発生を予測することが可能となる。そこで、多様かつ大量のデータを獲得することが可能となりつつ現状を踏まえると、ニューラルネットワークを用いた予測モデルが、従来の予測モデルに代わって実務における渋滞発生予測の役割を担うことが想定される。

ここで、高い精度を有するニューラルネットワークモデルを構築するためには、ネットワーク構造の異なる無数のモデルを構築し、各モデルの予測精度比較を行う。また、モデル構造に加えて、入力変数の質と入力データ量がモデルの予測精度に影響を与えるものと推察される。

そこで本研究では、ニューラルネットワークが有するパラメータ数と入力変数の質がモデルの予測精度に与える影響を分析する。具体的には、車両感知器データを入力に用いて渋滞発生確率を出力するCNNモデルを構築し、モデルが有するパラメータ数や入力変数の質がモデルの説明力に与える影響を分析する。

2. モデル概要

(1) CNNモデル

渋滞発生予測モデルにはCNNモデルを用い、予測時

点の1時間前から5分前までの車両感知器情報を入力して、予測時点から30分先までの渋滞発生確率を[0.0, 1.0]の実数で出力するモデルを構築する。このモデルの概略図を図-1、図-2に示す。また、最適化手法には Adam、活性化関数にはReLU関数を用いるが、確率を出力するため、全結合層の活性化関数にはシグモイド関数を用いる。

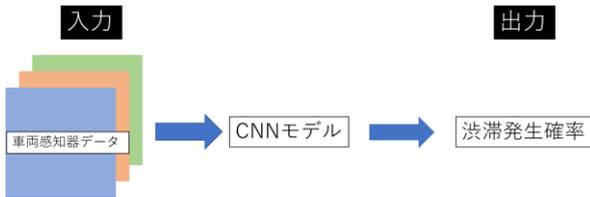


図-1 モデル概略図

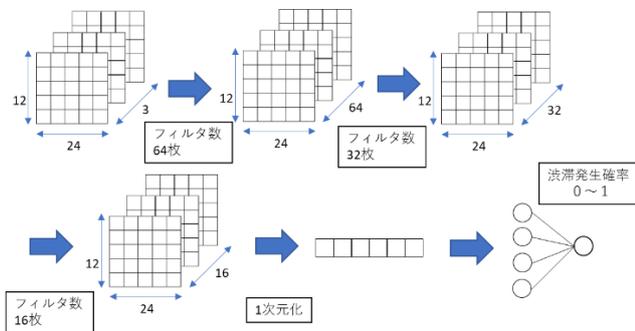


図-2 モデル構造例

(2) 入力データ概要

入力データは首都高速道路4号新宿線上りを対象路線とし、2010年4月～2019年3月の期間の交通データならびに交通データの時間差分を用いる。また、学習用データの出力には渋滞発生の有無を用いる。このうち、2010年4月～2017年12月、2019年1月～3月の期間のデータを学習用データ、2018年1月～12月の期間のデータを検証用データとする。

a) 交通データ

交通データには、対象路線24か所に設置された車両感知器による平均速度、交通量、オキュパンシーの各5分集計値を用いる。感知器データは感知器数×感知器時間帯の行列にして入力する。各行は5分単位で12行、直前の1時間を順に並べたものである。各列は、上流から下流に向けて位置する順に感知器を並べたものである。交通データを入力データとした際の例を図-3に示す。

b) 時間差分データ

3つの交通データの時間差分を取り、それらを入力に用いる。時間差分の取り方は、平均速度、オキュパンシー、交通量のいずれかの交通データのうち、ある行の値からその前の行の値を引いて、これを時間差分とする。

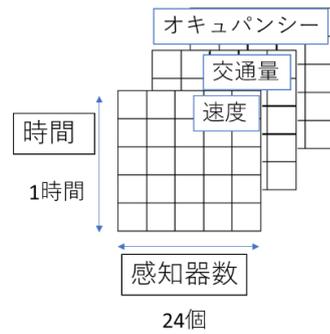


図-3 交通データ

・ 交通データ ・ 時間差分データ

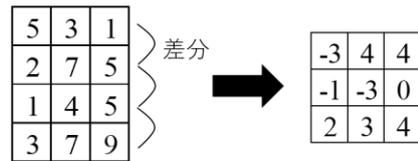


図-4 時間差分データ作成例

時間が進むにつれて値が大きくなる方向を正とする。時間差分データの作成例を図-4に示す。

c) 渋滞発生の有無

感知器から得られる速度データを基にして渋滞発生の有無の判定を行う。本研究においては、渋滞状態を「時速40km以下で走行する車列が1km以上かつ15分以上継続した状態」と定義し、予測時点から30分以内に渋滞状態が出現した場合に渋滞有り(1)、そうでない場合は(0)とする。ただし、予測時点が渋滞状態である場合には、同時刻のデータは入力データに用いない。

3. モデルの評価指標 (PR曲線)

本研究で用いるモデルは、計算によって0から1の出力値 $p(0 \leq p \leq 1)$ を出力する。この出力値をあらかじめ定められた閾値によって0か1に分類する。0が「渋滞なし」、1が「渋滞発生」である。この時、閾値ごとに以下の4つの状況が出現する。「渋滞発生」と予測した場合のうち、「実際に渋滞が発生した」 True Positive(TP), 「実際には渋滞が発生しなかった」 False Positive(FP), 「渋滞なし」と予測した場合のうち、「実際には渋滞が発生した」 False Negative(FN), 「実際には渋滞が発生しなかった」 True

表-1 混同行列

		予測	
		渋滞発生	渋滞なし
実際	渋滞発生	True Positive(TP)	False Negative(FN)
	渋滞なし	False Positive(FP)	True Negative(TN)

Negative(TN)の4つの状況である。表-1に混同行列(Confusion Matrix)を示す。

PR曲線(Precision Recall curve)は、閾値ごとに作成した表-1の混同行列を用いて、式(1)、式(2)に示す適合率(Precision)と再現率(Recall)を算出、プロットして、各点を連続的につないだものである。PR曲線の例を図-5に示す。図中の座標(1.0,1.0)は「渋滞発生」と予測したすべての場合で実際に渋滞が発生し、「実際に渋滞発生」した場合でそのすべてを漏れなく「渋滞発生」と予測した状況である。つまり、すべての渋滞発生を過不足無く「渋滞発生」と予測したことを示す。よって同図においては、座標(1.0,1.0)に近づくほど、すなわちPR曲線が右上に位置すれば高い精度であると評価することができる。そこで、PR曲線の左下の面積(Area Under the Curve、以下“AUC”)をモデル説明力の評価指標とする。

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

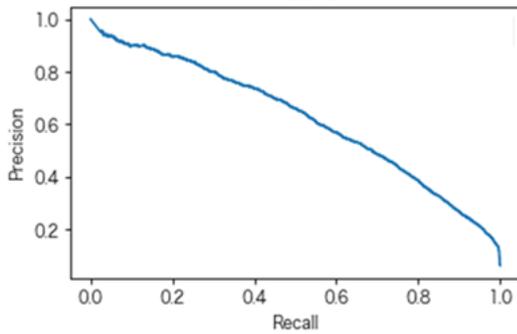


図-5 PR 曲線の例

4. 検証結果

(1) パラメータ数がモデル説明力に与える影響

交通データ(平均速度、交通量、オキュパンシー)のみを入力とし、複数の隠れ層の数とフィルタ数の組み合わせによるCNNモデルを構築し、それぞれのモデルについて学習を行った後、検証用データを用いて検証した結果を表-2に示す。ここで、入力に用いたデータサンプル数は学習用データが575,710個、検証用データが69,382個とした。学習に際しては式(3)に示す損失関数を用いた。

$$E = - \sum_k t_k \log y_k \quad (3)$$

ここで、Eは交差エントロピー誤差、 t_k は正解データ、 y_k はモデルの出力である。なお、エポック数はEarly

表-2 隠れ層のフィルタ数とパラメータ数

ケース	隠れ層のフィルタ数	パラメータ数	損失関数	AUC
①	128→64→32→16→8	103,433	0.141	0.480
②	64→64→32→16→8	64,777	0.139	0.501
③	64→32→16→8	30,153	0.136	0.517
④	32→32→16→8	20,041	0.138	0.504
⑤	32→16→16→8	13,113	0.137	0.506
⑥	16→16→16→8	10,361	0.134	0.517
⑦	64→32→16	38,721	0.134	0.527
⑧	32→16→8	13,609	0.135	0.519
⑨	16→16→8	10,857	0.136	0.501

Stoppingを用いて5エポック学習する間に損失関数が減少しなかった場合に学習を打ち切るように設定した。

図-6には、各組み合わせパターンにおけるモデルパラメータ数と学習結果の損失関数値との関係を示す。隠れ層を3層とし、各フィルタ数を(64,32,16)としたパラメータ数38,721のケース⑦のモデルにおいて最も低い損失関数値が得られた。また、結果より、パラメータ数を大きくした場合に損失関数値が高くなっていることが読み取れる。図-7には、損失関数値とAUCの関係を示す。両者には強い負の相関(R=-0.913)があり、AUCによってもケース⑦が最も高い値を示した。この結果は、説明力の高いCNNモデルを構築するにあたって、モデルの説明力を最も高める適切なパラメータ数が存在することを示すものである。

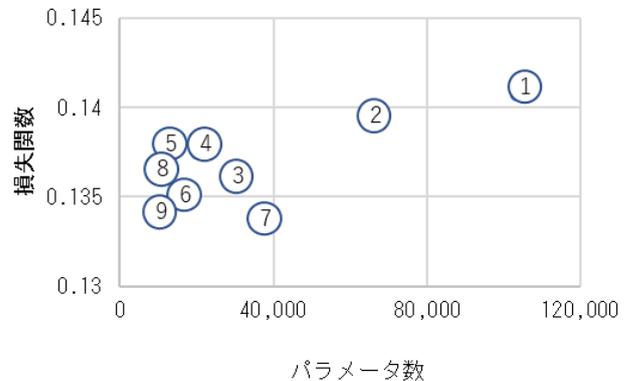


図-6 パラメータ数と損失関数の関係

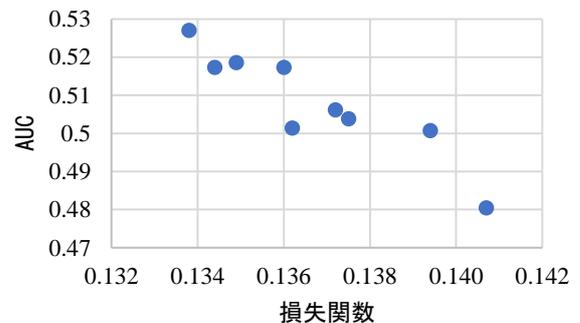


図-7 損失関数値とAUCの関係

(2) 入力変数がモデル説明力に与える影響

本項では、前項によるケース⑦のモデルを用いて、入力変数がモデルの説明力に与える影響を調べた。具体的には、交通データ(平均速度, 交通量, オキュパンシー)に加えて、それぞれの時間差分データを入力に加えた場合のモデル説明力の変化を調べた。表-3には、各ケースにおいて用いた入力変数と結果として得られたAUC値を示す。図-8では、4ケースごとのAUC値を比較する。結果より、交通データに3種類の時間差分データを加えたケースcで最も高いAUC値を示した。

表-3 入力データの組み合わせ

ケース	交通データ	時間差分データ			AUC
		平均速度	交通量	オキュパンシー	
o	○				0.531
a	○			○	0.522
b	○	○		○	0.534
c	○	○	○	○	0.542

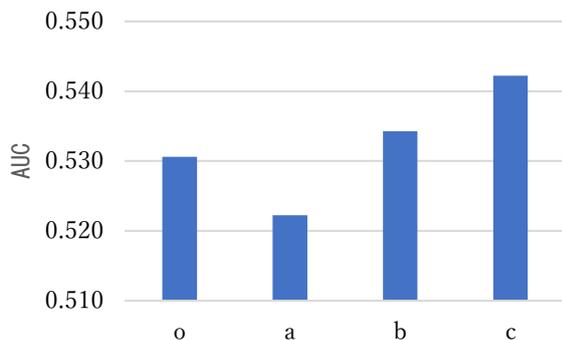


図-8 ケース別のAUC値

6. おわりに

本研究では予測時点の直前1時間の交通データを入力して、予測時点の直後30分で渋滞が発生する確率を出力するCNNモデルを構築した。モデルの構築に際して、モデルが有するパラメータ数と入力変数の質がモデルの説明力に与える影響を検証した結果、パラメータ数が一定のレベルを超えて大きくなるとモデルの説明力が低下するとの結果を得た。すなわち、モデルの説明力を最も高める適切なパラメータ数が存在する可能性を示した。また、入力変数の質に関しては、適切なデータ、ここでは交通データの時間差分データ、を追加することによりモデル説明力が向上するとの結果が得られた。

今後は、入力データの量とモデル説明力の関係を調べるとともに、予測精度の向上に向けて、感知器データに加えてプローブデータを入力に活用するモデル構築を行う。

謝辞: 貴重なデータを提供していただいた首都高速道路(株)の方々に感謝の意を表す。

参考文献

- 1) 舟橋尚平・小根山裕之・柳原正実・山本隆: 「感知器データに基づく都市間高速道路における渋滞・事故発生確率予測モデルの構築」, 『第 60 回土木計画学研究発表会・講演集』, 2019
- 2) NEXCO 東日本, NTT ドコモ: AI渋滞予知実証実験
URL = https://www.driveplaza.com/area/kanto/traffic/ai_traffic_prediction.html

The Model for Predicting the Traffic Jam by CNN

Yuya MICHIHARA, Toshio YOSHII and Takahiro TSUBOTA

This study develops a CNN model, which can predict congestion occurrence. Then, effect of the number of parameters and the quality of input variables on the prediction accuracy is analyzed. Average speed, traffic volume and occupancy in every 5 minutes observed by vehicle detectors in 1 hour just before the prediction time are used as the input. The model predicts the probability of congestion occurrence in the next 30 minutes. As a result of the analysis using the data of the Metropolitan Expressway road network (inbound, Line 4), it was shown that there is an optimal number of parameters to improve the prediction accuracy of the model. In addition, the results showed that additional input variables can improve the prediction accuracy.