

畳み込みニューラルネットワークによる 都市間高速道路の渋滞発生予測モデル

坪田 隆宏¹・砂 侑奈²・吉井 稔雄³

¹正会員 愛媛大学特任講師 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.chime-u.ac.jp (Corresponding Author)

²非会員 愛媛大学 工学部工学科 (〒790-8577 愛媛県松山市文京町 3 番)

E-mail: isago.yuna.19@cee.chime-u.ac.jp

³正会員 愛媛大学教授 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.chime-u.ac.jp

本研究では、リアルタイムでの交通状況から近未来における渋滞が発生確率を予測する畳み込みニューラルネットワークモデルを構築し、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、過去 1 時間に獲得された速度、時間占有率、交通量等の交通状況データを用いて、予測開始時刻から 30 分後までに渋滞が発生する確率を算出するモデルを構築する。東名高速道路上り線の横浜町田 IC から東京 IC までの路線を対象に分析を行った結果、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。同情報提供により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ことが期待される。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、更に質の異なる多様な入力変数の組み合わせを用意し、各モデルの予測精度比較を行う必要がある。

そこで本研究では、ニューラルネットワークが有する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、モデルへの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




図-1 モデル概略図

・交通データ ・時間差分データ




図-3 時間差分データ作成例

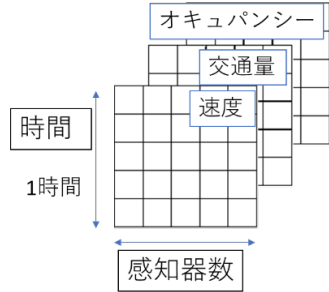


図-2 交通データ

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、確率を出力とするため、全結合層の活性化関数にはシグモイド関数を用いる。

(2) 入力データ概要

入力データはNEXCO中日本管内の東名高速道路より、横浜町田ICから東京ICの上り線を対象路線とし、2009年1月～2018年12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、2009年1月～2017年12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) 標準入力データ

交通データには、対象路線19.7km内の12か所に設置された車両感知器による速度、交通量、時間占有率 (OCC) の各5分集計値を用いる。感知器データから得られるこれらの3種類のデータを行列形式に配置して重ね合わせることで作成したデータを標準入力データとする(図-2)。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。

b) 時間差分データ

標準入力に用いた3種類の交通データの時間変動成分を明示的に考慮する場合の予測精度への影響を明らかにする。時間変動成分は、速度、交通量、OCCの各交通データのうち、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。時間差分データの作成例を図-3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、予測開始時点において既に渋滞状態である場合は予測の対象外とする。

(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 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-4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

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)




図4 PR 曲線の例

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。

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

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

3. 結果

3種類の交通データから成る標準入力データ、すなわち速度、交通量、OCCから構成される3チャンネルの入力データを用いた場合の予測再現性、および各交通データの時間変動成分を追加した場合の予測再現性を表-2に示す。結果より、時間差分データを追加したケースa,b,cでは、標準入力データのみを用いたケースoと比較して、いずれも再現性の向上が認められた。特に、速度の変動成分を追加したケースで最も高い再現性を確認できた。すなわち、渋滞発生に至る直前の交通状況の特徴を抽出する上で、標準入力データに加えて、速度の時間変化を明示的に考慮することが有効である可能性を示す結果となった。

表-2 入力データの組み合わせと再現性

ケース	標準入力	時間差分データ			PR-AUC
		速度	交通量	OCC	
o	○				0.535
a	○	○			0.540
b	○		○		0.535
c	○			○	0.525

4. 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、モデルへの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、適切なデータ、ここでは交通データの時間差分データを、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、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予定である。

謝辞：本研究で使用したデータはNEXCO中日本より提供頂いたものである。また、研究の遂行に際しては高速道路総合技術研究所の邢健氏、糸島史浩氏、甲斐徳高氏から貴重な意見を頂いた。ここに感謝の意を表す。

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

(Received September 30, 2022)