

# CNNモデルを用いた 首都高速道路の事故発生予測モデル

新水 衛<sup>1</sup>・吉井 稔雄<sup>2</sup>・坪田 隆宏<sup>3</sup>・田畑 大<sup>4</sup>・田中 淳<sup>5</sup>

<sup>1</sup>学生会員 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番)

E-mail:shimmizu.mamoru16@cee.ehime-u.ac.jp

<sup>2</sup>正会員 愛媛大学大学院教授 理工学研究科 (〒790-8577 愛媛県松山市文京町3番)

E-mail:yoshii@cee.ehime-u.ac.jp

<sup>3</sup>正会員 愛媛大学大学院講師 理工学研究科 (〒790-8577 愛媛県松山市文京町3番)

E-mail:t.tsubota@cee.ehime-u.ac.jp

<sup>4</sup>非会員 首都高速道路(株) 東京西局 調査・環境課 (〒102-0093 東京都千代田区平河町2-16-3)

E-mail: d.tabata208@shutoko.jp

<sup>5</sup>正会員 (株)オリエンタルコンサルタンツ 中部支社 (〒450-0003 名古屋市中村区名駅南2-14-19)

E-mail: tanaka-at@oriconsul.com

本稿では、車両感知器によって獲得される交通流観測データ、気象データならびに交通事故データを融合し、一定時間内に発生することが期待される事故件数を予測するCNNモデルを構築する。さらに、モデル出力となる期待事故件数の精度を可視化して評価する手法を考案するとともに、同CNNモデルの予測精度を検証する。具体的には、CNNモデルに首都高速道路の実交通データを適用し、入力データとネットワークモデル構造に着目して予測精度の分析を行う。さらに、ポアソン回帰モデルとの予測精度の比較を行いCNNモデルの有用性を検証する。検証の結果、CNNモデルは、追突・車両接触事故などの交通流状態に依存する事故の予測はもちろん、施設接触事故などの交通流状態に依存しない事故の予測に関しても高い予測精度を得ることができるとの結果が得られた。

**Key Words :** 事故発生予測モデル, CNN, ROC, AUC

## 1. はじめに

単位距離を走行した際の期待事故発生件数（以下では“事故リスク”）は、道路構造の影響を受けるにとどまらず、交通状況や交通環境の変化に応じて動的に変化することが示されている<sup>1)</sup>。道路構造が事故リスクに与える影響について、Shankar, V<sup>2)</sup>は単位道路区間におけるカーブ区間の数や最大勾配と事故件数の間に比例関係があることなどを示した。また、交通状況が事故リスクに与える影響について、井上ら<sup>3)</sup>は、交通流状態を渋滞／非渋滞の二つに分類して事故リスクの比較を行い、渋滞時に事故の危険性が高まることを示している。さらに、交通環境による事故リスクの変化について、Andry & Yagar<sup>4)</sup>は非降雨時と降雨時の事故リスク比較を行い、降雨時において事故リスクが増加すること、昼間との比

較において夜間や薄暮時において事故リスクが増大することなどを示している。

これらの研究が、過去または現在の時点における事故リスクを対象とした研究であるのに対して、本研究では、直後に事故リスクの上昇が予測される状況に際して、ランプ流入制御やペースカーの導入など、事故リスクの上昇を抑制するための適切な交通マネジメントを実施することを最終目的とするものである。以下、本稿では、特定の道路区間を対象に近未来の事故発生件数の期待値を定量的に把握する事故発生リスク予測モデルを構築し、同モデルの予測精度検証を行う。また、既存のモデルであるポアソンモデルとの精度比較検証も行う。

## 2. モデルの評価指標

本研究で構築するモデルは、「事故有り」「事故無し」のいずれかにて予測結果を出力する方法と、事故が発生する確率を数値で出力する方法を考え、以下の2指標を用いて予測結果の評価検証を行う。

### (1) Area Under the Curve 値（以下では“AUC値”）

事故発生の有無について、直接的に「事故有り」「事故無し」のいずれかにて予測を出力するモデルを構築した際の予測結果評価指標としてAUCを用いる。

表-1に示すように、事故の有無で2値のいずれかを出力するモデルでは、「事故有り」と予測した際に「実際に事故が起きた」True Positive(TP), 「実際には事故が起きなかった」False Positive(FP)のいずれかの状況が出現する。また、「事故無し」と予測した際も同様に「実際に事故が起きた」False Negative(FN), 「実際には事故が起きなかった」True Negative(TN)のいずれかの状況、計4つの状況が出現する。このとき、モデルの予測精度は式(1)に示す的中率として算出評価することが可能である。もちろん予測的中のTPとTNの割合が高くなれば予測精度が高いということを示す。ここで、本研究のように稀少事象を対象として取り扱う場合には、例えばすべての出力を「事故無し」としておくことで高い中率が実現するとの状況が出現しうる。一方、本研究によるモデルは、計算によって[0,1]の出力値  $p$  ( $0 \leq p \leq 1$ ) を出力するモデルとなっており、予め設定された閾値と  $p$  との大小関係から「事故有り」「事故無し」の判定を行うモデルであることから、閾値の値を変化させた場合に、上記4つの状況の出現割合が異なる結果を得ることができる。そこで、閾値の値を[0,1]で変化させた場合のそれぞれで、式(2)、式(3)に示す False Positive Rate（以下では“FPR”）と True Positive Rate（以下では“TPR”）を算出する。前者のFPRは、事故が起きなかった場合に「事故無し」と予測していた割合、後者のTPRは、事故が起きた場合に「事故有り」と予測していた割合を示し、閾値の増加に伴って前者の値は単調に増加し、後者の値は単調に減少する。例えば、閾値を0.0として、全ての予測結果を「事故有り」とした場合には、(FPR, TPR)= (0.0, 1.0) となり、逆に閾値を1.0として全ての予測結果を「事故無し」とした場合には (FPR, TPR)= (1.0, 0.0) の結果が得られる。

続いて、算出結果を図-1に示すFPR—TPR平面にプロットし、閾値ごとに異なる各点を連続的につなぐROC曲線 (Receiver Operating Characteristic curve) を用いて予測結果を評価する。図中の座標 (0.0, 1.0) は、「事故有り」と予測したときには全て実際に事故が発生し、「事故無し」と予測した場合には全て事故が発生しない状況、す

表-1 閾値による予測データの分類表

		予測	
		事故あり	事故なし
実際	事故あり	True Positive(TP)	False Negative(FN)
	事故なし	False Positive(FP)	True Negative(TN)

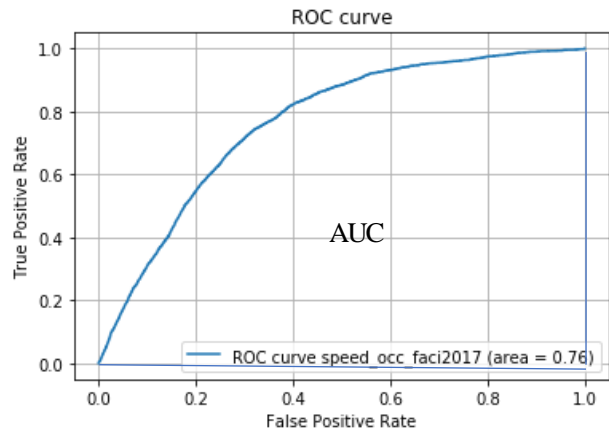


図-1 ROC curveの例

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$\text{False Positive Rate} = \frac{FP}{FP + TN} \quad (2)$$

$$\text{True Positive Rate} = \frac{TP}{TP + FN} \quad (3)$$

なわち100%予測が的中している状況を示し、各点が図中左上に位置すればするほど良い結果を示すこととなる。そこで、ROC曲線も左上に近づけば近づくほどモデルの予測精度が高いと結論づけられる。このことから、ROC曲線右下部の面積、すなわちAUC値を以て予測精度の評価指標とする。

### (2) 事故発生割合

「事故有り」「事故無し」、2値での予測結果出力方法に代えて、事故が発生する確率を数値で出力するモデルを構築した際の予測結果評価手法には、事故発生確率的中度合いを用いる。具体的には、[0.0, 1.0]の範囲で出力される事故発生確率を0.1刻みの階級に分けて予測値出現回数を集計し、予測値が出現した回数の中に占める実際に事故が発生した回数の割合（以下“事故発生割合”）を算定する。同割合が各階級の階級値に近い値を示せば高い精度で事故発生確率を予測していることから、事故発生割合と階級値との乖離を以て的中度合いの評価指標とする。

### 3. モデル概要

図-2に示すように、事故発生予測モデルには、Convolutional Neural Network（以下“CNN”）モデルを用いる。入力データには時系列の交通感知器データと降水量データで予測時点から1時間前のデータを用いる。また、モデルの出力は予測時点から120分後までの路線全体の事故リスク値を出力するモデルを構築する。予測する際には、事故形態によって交通事故発生に影響を与える要因が異なるため、施設接触事故と追突・車両接触事故に分類して予測する。

#### (1) 入力データ概要

予測対象路線を表-2に示す。オンランプ、オフランプ、さらには放射状各路線のジャンクションが互いに近接する路線として、首都高速道路環状線内回り、外回り、ならびに放射状路線を代表して、首都高速道路の環状線内回りと外回り、3号渋谷線の上下線、4号新宿線の上下線、5号池袋線は上下線全区間と、板橋JCTを境に竹橋JCT～板橋JCT間の上下線、板橋JCT～美女木JCT間の上下線、計8路線12区間を分析対象路線とする。入力値としたのは、各路線に設置された全車両感知器の平均速度、交通量、オキュパンシーの各5分集計値である。さらに、各路線5分単位での事故発生の有無を示した、施設接触を除く事故データ、それぞれ2010年4月1日から2019年3月31日までの9年間分である。このうち、全期間の2017年以外のデータを学習用データ、全機関の2017年のデータを検証用データとする。

入力データのイメージを図-3に示す。5分ごとに得られる感知器データは、平均速度、交通量、オキュパンシーのそれぞれを感知器数×感知器時間帯の行列にして入力する。各行は、予測時点直前1時間分の5分データを時間の順に並べたものであり、各列は、各感知器区間における観測データを上流から下流に向けて感知器が位置する順に並べたものである。

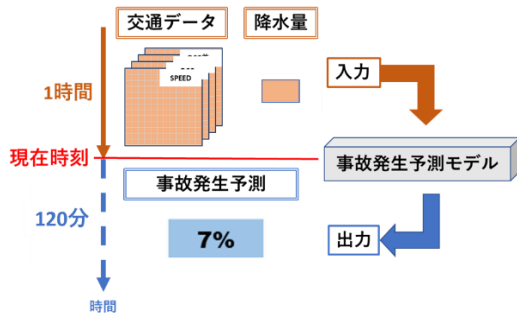


図-2 モデル概略図

表-2 予測対象路線

	路線延長[km]	感知器区間数[個]
環状線内回り	14.2	34
環状線外回り	14.2	32
渋谷線上り	12.1	18
渋谷線下り	11.8	18
新宿線上り	14.1	24
新宿線下り	14.1	20
池袋線上り(全線)	21.4	36
池袋線下り(全線)	21.7	35
池袋線上り(竹橋JCT～板橋JCT)	9.5	17
池袋線下り(竹橋JCT～板橋JCT)	11.9	17
池袋線上り(板橋JCT～美女木JCT)	9.4	19
池袋線下り(板橋JCT～美女木JCT)	12.3	18

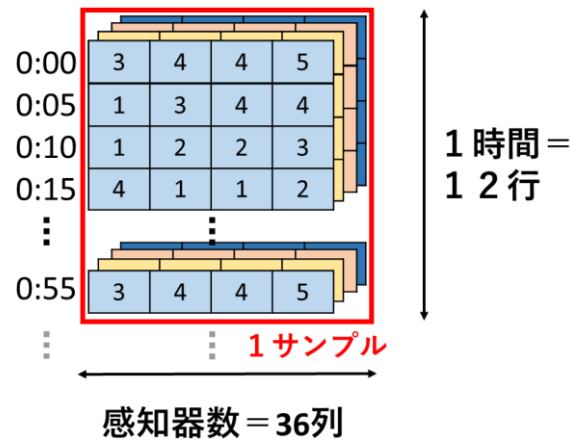


図-3 入力データ

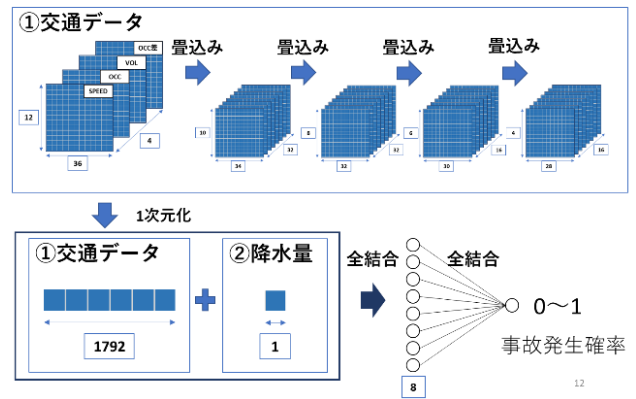


図-4 モデル構造の例

#### (2) モデル構造

本研究で用いたCNNモデルの構造例を図-4に示す。畳み込み層を4層用意したのちデータを1次元化して全結合層につなげるネットワークとし、事故リスク値を[0.0, 1.0]の値として出力するモデルとした。

## 4. 結果

### (1) AUC値による従来モデルとの予測精度比較結果

対象とした8路線12区間のうち池袋上り線におけるAUC値による評価検証結果を図-5-1、図-5-2に示す。追突・車両接触事故の予測精度はどちらのモデルも同程度だが、施設接触事故の予測精度はCNNモデルの方が大幅に高くなっている。これは、追突車両接触事故は車両相互の事故で交通流状態に依存するのに対し、施設接触

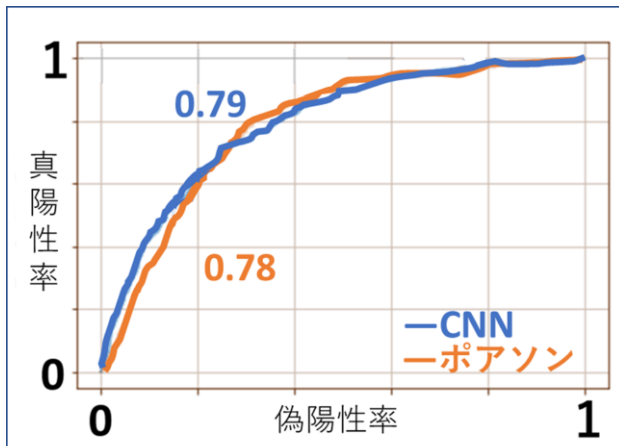


図-5-1 AUC値による追突・車両接触事故の予測精度比較結果  
(池袋線の上り120分予測)

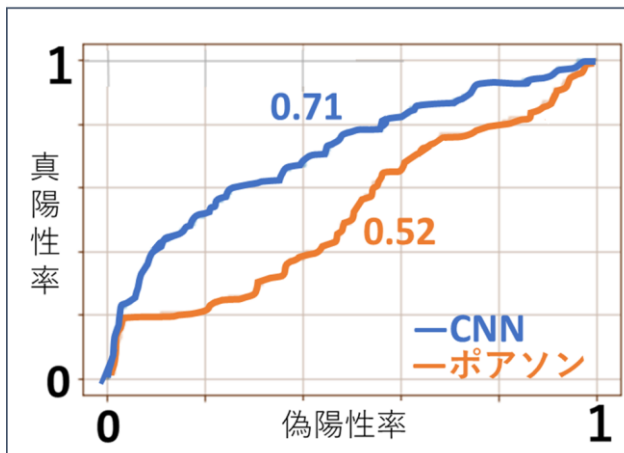


図-5-2 AUC値による施設接触事故の予測精度比較結果  
(池袋線の上り120分予測)




図-6 事故発生率による検証結果 (池袋線の上り120分予測)

事故は車両単独の事故で交通流状態に依存しないことがわかっており、施設接触事故の予測を行う際、ポアソンモデルは入力データからでは予測できないのに対し、CNNモデルは変数同士の交互作用を考慮できるため入力データから傾向をつかみ予測を可能にしている。よって、どちらの事故種別にも対応できるCNNモデルの方がよりよいモデルであると考察できる。

### (2) 事故発生割合による結果

事故発生割合による検証結果を図-6に示す。予測精度を示す各階級の階級値と事故発生割合との乖離は、サンプル数の多い予測値の小さい階級においては小さく、サンプル数の少ない予測値の大きい階級において大きくなっている。このことから、一定のサンプルが獲得されれば精度良く事故発生確率を予測することができるという結果が得られた。

## 4. おわりに

本研究では、予測時点から120分先までの時間における事故リスクを推定するCNNモデルの構築を行い、モデルの予測精度を検証し、既存モデルとの予測精度の比較を行った。その結果、既存のポアソンモデルよりもCNNモデルがより汎用的なモデルであることが明らかになり、一定のサンプルが獲得されれば高精度で事故発生確率を予測することができるという結果が得られた。

また今後の課題として、CNNモデルを用いて新しい管制技術の構築を目指していく。

### 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、モデル構築に関して貴重なご意見を頂いた (株)オリエンタルコンサルタンツの方々へ感謝の意を表す。

### 参考文献

- 1) 兵頭知, 吉井稔雄, 高山雄貴: ポアソン回帰モデルによる高速道路における交通事故リスク要因分析, 第34回交通工学研究発表会論文集(CD-ROM), 2014
- 2) Shankar, V., Milton, J. and Mannering, F.: Modeling Accident Frequencies as Zero-Altered Probability Processes: An Empirical inquiry, Accident Analysis and Prevention, Vol. 29, pp.829-837, 1997.
- 3) 阪神高速道路公社: 阪神高速道路の交通管制に関する研究報告書, 交通工学研究会, 1978.
- 4) Andrey, J., Yagar, S.: A temporal analysis of rain-related crash risk. Accident Analysis and Prevention, Vol.25 (4), pp.465-472, 1993.