

2019年度阪神高速研究助成（若手研究者助成） 研究概要書

申請者	所属 職名	愛媛大学大学院 特任講師	フリガナ 氏名	ツボタ タカヒロ 坪田 隆宏
共同研究者	所属 職名		フリガナ 氏名	
連絡先	所属 職名	愛媛大学大学院 特任講師	フリガナ 氏名	ツボタ タカヒロ 坪田 隆宏
	住所 電話	〒790-8577 愛媛県松山市文京町3番 089-927-9827		
研究課題名	ディープラーニングによる高速道路ネットワーク安全性評価モデルの開発			
研究結果	<p>1. 背景・目的</p> <p>本研究では時間的・区間的に広範囲な車両感知器情報を入力に用いて、予測開始時点直後の交通事故の起こりやすさ（以下，“事故リスク”）を予測する Convolution Neural Network (CNN) モデルの構築を試みる。近年、事故件数は減少傾向にあるが、更なる安全性の獲得には天候や交通状況等の動的な要因を考慮した事故リスク予測と、同予測に基づく交通運用が重要である。本研究では深層学習の一種である CNN モデルを用いて事故リスク予測モデルの構築を目指す。一般に深層学習手法においては、ビッグデータから自動的に事故の起こりやすい交通状況を学習できるとの期待が寄せられる一方で、事故リスクの推定精度に各入力データが与える影響や、得られた結果の工学的な妥当性の検証が困難であるという問題点も挙げられる。そこで、本研究では CNN による高速道路の事故リスク予測モデルを構築した後、各入力データが推定精度に与える影響を明らかにすることを目的とする。これにより、深層学習手法による事故リスク予測モデルの、交通工学的な妥当性を検証することを目指す。</p> <p>2. 事故リスク予測モデル概要</p> <p>構築する事故リスク予測モデルでは、過去1時間の車両感知器情報を入力として、対象路線における事故発生確率として予測時点から2時間先までの事故リスク値を [0.0, 1.0] の実数値で出力するモデルを構築する。入力データは、過去1時間の速度、交通量、時間占有率 (OCC) の5分間感知器データを、それぞれ感知器数×時間帯の行列</p> <div style="text-align: center;"> <p>入力データ(予測時点の1時間前) → CNNモデル → 出力(予測時点から2時間先まで)</p> <p>時系列感知器データ</p> <p>図1 モデル概要図</p> </div>			

形式とする（図 1）。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。事故データについては、予測時点から 2 時間先までの事故発生の有無を、事故有り (1)、事故無し (0) として入力する。なお、事故形態によって事故発生要因が異なることが知られている為、施設接触事故と、追突・車両接触事故のそれぞれに対して事故リスク予測モデルを構築する。




図 2 ROC 曲線と AUC の例

3. 評価指標

本研究で構築するモデルは、事故発生確率を実数値で出力するが、出力結果に対して閾値を設けることで、直接的に「事故有」「事故無」の何れかにて予測を出力可能である。この際の予測結果評価指標として、図 2 に例示する Receiver Operating Characteristic curve (ROC 曲線)の Area Under the Curve (AUC)を用いる。

4. 結果・まとめ

阪神高速道路の 1 号環状線全線を対象に、2010 年 4 月から 2016 年 3 月までの 6 年間の感知器データを用いて、交通事故形態別に CNN による事故リスク予測モデルを構築した。この際、図 1 に示す速度、交通量、OCC のみを入力するモデルを標準モデルとし、標準モデルの入力に加えて、交通状況の時間変動成分を入力したモデルを複数構築した。更に、天候による影響を確認するために、過去 1 時間の時間降水量を追加したモデルを構築した。分析結果を図 3 に示す。標準モデルと比較して、各種の交通状況変動成分を追加したケースでは、追突・車両接触モデルについては全ケースで精度が向上する一方で、施設接触モデルでは必ずしも精度向上は認められないとの結果が得られた。降水量を追加したケースでは、両事故形態共に予測精度が向上するとの結果が得られた。これらの結果より、深層学習モデルにおいても追突・車両接触事故は臨界流から渋滞流に認められるような交通状況の時間変動の影響を考慮することで、一方の施設接触事故は降雨の影響を考慮することで予測精度が向上するという知見が得られた。同知見は既往の交通工学的見地とも整合しており、深層学習モデルによる事故リスク予測の妥当性を示すものであると考えられる。




図 3 AUC による検証結果 (左：交通状況時間変動成分の影響、右：降水量の影響)