

CNN モデルを用いた首都高速道路の事故発生予測モデル

愛媛大学 学生会員 ○新水衛 愛媛大学 正会員 吉井稔雄
愛媛大学 正会員 坪田隆宏

1. はじめに

交通量状態や天候の変化によって時々刻々と変化する事故リスクを定量時に評価するモデルとして、一般化線形モデルを用いた兵頭ら¹⁾は、ポアソン回帰による事故リスクの要因分析を行っている。兵頭らが行った一般化線形モデルの1つであるポアソン回帰モデルを用いた分析では、各説明変数をそれぞれ複数の階級に分類することでカテゴリー変数として取り扱い、各説明変数カテゴリーの組み合わせが同じサンプルを同一群に属するサンプルと見なし、各群の事故発生件数を目的変数とすることでモデル分析を行う。このとき、説明変数の種類を増やした場合には、限定された数の事故データに対して、群の数が幾何級数的に膨らみ、事故発生件数が0となる群ばかりとなってしまうことから、分析で取り扱うことが可能な説明変数は少数に限定されてしまう。そこで、本研究では、多数の説明変数を同時に取り扱うことが可能なモデルとして、多層ニューラルネットワークモデルを取り上げ、予測時点直後の時間帯における事故発生を多数の説明変数を用いて予測するモデルを構築する。

2. モデル概要

事故発生予測モデルには、Convolutional Neural Network（以下“CNN”）モデルを用いる。本研究で用いるモデル構造は以下の図-1で示す。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。入力データには交通感知器データから得られる交通工学的知見に基づいてデータを入力データとして用い、最終的に最も精度の良い、速度、占有率、交通量の3種類のデータと占有率のデータの時間の推移による変化量のデータ(図-2)を用いて予測を行う。また、モデルの出力は予測時点から30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。




図-1 モデル構造の例




図-2 入力データ

3. ポアソンモデル概要

今回、CNNモデルの比較対象として用いる従来モデルのポアソンモデルに使用するモデルは、兵頭ら¹⁾が用いた式 $\mu = \exp(a + b_1x_1 + b_2x_2 + \dots + b_nx_n)$ を使用する。説明変数 x_k には、道路幾何構造データや交通流状態、天候データを用いて予測を行う。

4. 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-3、図-4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。




図-3 AUC値による追突・車両接触事故の予測精度比較結果
(池袋線上り30分予測)




図-4 AUC値による施設接触事故の予測精度比較結果
(池袋線上り30分予測)

5. おわりに

本研究では、予測時点から30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モデルがより汎用性のあるモデルであることが明らかになり、高精度に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モデルを用いた新しい管制技術の構築を目指す。

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、モデル構造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ならびに（株）エクサウィザーズの方々に感謝の意を表する。

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発生事故リスク要因分析, 第34回交通工学研究発表会論文集, 2014