

# 感知器データに基づく都市間高速道路における 渋滞・事故発生予測モデルの構築

舟橋 尚平<sup>1</sup>・小根山 裕之<sup>2</sup>・柳原 正実<sup>3</sup>・山本 隆<sup>4</sup>

<sup>1</sup>非会員 首都大学東京都市環境科学研究科 (〒192-0397 東京都八王子市南大沢1-1)

E-mail: funahashi-shohei@ed.tmu.ac.jp

<sup>2</sup>正会員 首都大学東京都市環境科学研究科 (〒192-0397 東京都八王子市南大沢1-1)

E-mail: oneyama@ed.tmu.ac.jp

<sup>3</sup>正会員 首都大学東京都市環境科学研究科 (〒192-0397 東京都八王子市南大沢1-1)

E-mail: yanagihara@ed.tmu.ac.jp

<sup>4</sup>正会員 中日本高速道路(株) 東京支社 (〒105-6011 東京都港区虎ノ門4-3-1)

E-mail: t.yamamoto.ae@c-nexco.co.jp

東名高速道路上りの大和トンネル周辺など都市間高速道路の渋滞多発箇所においては、渋滞のみならず、その前後に交通事故も発生している。交通事故を発生させないようにするためには、現在及び過去の交通状況に基づいて渋滞および事故の起こりやすさを推定し、出来る限り事故の発生しないような交通制御を実施していくことが求められる。本研究では、事故や渋滞の発生を短期的に予測し適切な交通制御を行うためのツールとして、東名高速道路上り大和トンネルをボトルネックとする区間を対象に都市間高速道路における様々な要因・条件下での事故・渋滞発生を予測するリカレントニューラルネットワークモデルの構築を行いその精度を検証した。

**Key Words :** traffic accident, probability of congestion, interurban expressway

## 1. はじめに

都市間高速道路単路部での上り坂やトンネル部などのボトルネックにおいて渋滞が発生することは、これまでの研究により明らかとなっている。渋滞は経済的な損失が大きく、例えばわが国の大動脈である東名高速道路横浜町田IC～海老名JCT上り線においては151[万人・時間/年]もの渋滞損失時間が発生している<sup>1)</sup>。現在、主要な都市間高速道路において、全渋滞長のうちの約25%が事故を原因として生じている<sup>2)</sup>ことから、事故を原因とした渋滞への対策が急がれる。交通事故を発生させないためには、現在及び過去の交通状況に基づいて事故・渋滞の起こりやすさを推定し、出来る限り事故の発生しないような交通制御を実施していくことが求められる。特に近年では移動発光体やVSL、ランプメータリングなど様々な交通制御手法が検討され、それらが事故・渋滞の発生を抑制する効果を有することが明らかとなっており、それら施策をより効果的に活用することへの寄与も期待される。著者らの既往研究<sup>3,4)</sup>では、具体的な要因の組み合わせに着目すること

で、2地点間の速度差が小さい場合には渋滞が発生しやすく、2地点間の速度差が大きい場合に、事故発生および事故に最終的に至る危険な渋滞の発生が起こりやすくなることが明らかとなった。一方で、事故・渋滞発生確率を予測する具体的な要因として、速度と実交通量以外の要因が反映されたモデル構造とならず、予測を活用する上で不十分であると考えられた。

そこで本研究では、都市間高速道路上において時々刻々と変化する様々な交通の要因、条件下における適用性を高めた事故・渋滞発生確率を予測するモデルの構築を目的とし、その精度を検証する。著者らの既往研究<sup>4)</sup>ではベイジアンネットワークモデルを用いたモデルを構築したが、本研究ではより精緻なモデル構築を行うため、ディープラーニングによるモデル構築を行った。事故・渋滞の発生は時系列なものであり、そのようなデータの扱いに強みを持ち、ニューラルネットワーク層の一つであるLSTM層の適用可能性を検討する。

本研究では、主要渋滞箇所として指定されている大和トンネル(以下TN)を先頭とした区間を対象とし、分析には車両感知器データ、事故データ等を使用した。

## 2. 研究対象と利用データ

### (1) 対象地点と利用データ

分析対象地点は、東名高速道路上り線における大和TNからその上流側15kmの区間とした。この区間は主要渋滞箇所である大和TNをはじめとする慢性的な単路部ボトルネックが存在し、特に週末を中心に渋滞および事故が多く発生している。




図-1 車両感知器設置位置

### (2) 対象期間

#### a) 分析対象期間

2015年1月1日から2018年10月31日の休日のデータを用いる。そのうち2015年1月1日から2017年12月31日までの3年分を学習用データ、2018年1月1日から10月31日までの10ヵ月分を検証用データとして利用する。休日の定義は、毎週の土日に国民の休日、年末年始、GW、お盆の期間を加えたものとする。

#### b) データの利用時間帯

特に事故の発生が多い時間に絞るため、分析に用いるデータの時間帯を限定する。萩田ら<sup>9)</sup>による、「日没前後に交通事故率が高くなり、特に日没直後に最も高くなる」知見を参考に、日の出から日没1時間後までの時間を分析対象とした。

### (3) 利用データの詳細

#### a) 5分間車両感知器データ

5分間車両感知器データは高速道路上での車両感知器により収集されるデータであり、車線、KPごとに5分あたりの全車台数、大型車台数、平均速度、Occupancyが記録されている。地点別の交通量として、大型車台数に乗用車換算係数1.8(pce)を掛けて求めた乗用車換算台数(pcu)を使用する。また分析対象区間に関して、図1に示す車両感知器を基準としている。

#### b) 事故調書

実際に発生した事故について、個人の特性(性別や年齢)から事故発生当時の事故の原因や状況、天候、路面状態などが記録されている。

#### c) 天候データ

アメダスのデータを使用する。観測地点は海老名とし、風速や降雨、気温等を利用する。

### (4) 渋滞と事故の定義

#### a) 渋滞

渋滞発生を時速60km以下が10分以上継続した場合とした。大和TNから厚木ICまでの区間内において1箇所でもその条件を満たした場合渋滞とする。またその条件を満たす時間に加え、区間全域で速度回復してから30分経過するまでを本研究での分析には用いないものとする。

#### b) 事故

大和TNから厚木ICまでの区間内において1箇所でも事故の発生がみられた場合を区間内における事故発生とした。特に本研究では、追突事故が本線で発生した場合のみを対象とした。発生時間については、その時間が含まれる車両感知器基準の5分間を発生時間とする。なお、事故発生以後日付が変わるまでのデータに関しては本研究での分析には用いないものとする。

## 3. ディープラーニングを活用したモデルの構築

### (1) ディープラーニングについて

ディープラーニングとは、機械学習手法の一つであり、主にニューラルネットワーク(以下NN)を基盤としたパラメータ推定手法である。学習したモデルの予測精度が高く、主に画像認識や言語予測などの分野で成功を収めている。モデルの構造はブラックボックスなものとなっているが、回帰モデルにおける変数選択と同等の作業を学習時に行える点や、とにかく精度の高さを要求する複雑な識別問題に適性がある点において利点がある。

渋滞や事故は時系列に沿った現象に依存しているため、過去の状態がその発生と関連している可能性が高い。そこで、時系列データに対するNNのモデルの一種であるリカレントニューラルネットワーク(以下RNN)を長期依存が学習できるように拡張した長短期記憶アルゴリズム(以下LSTM)を本研究のモデルとして採用する。

(2) モデル概要

本研究では、学習データとして事故・渋滞の発生直前から2時間前までのデータを集積し事故・渋滞発生データとした。さらにそこへ事故・渋滞の発生しなかった2時間分のデータを無事故・非渋滞データとして加えたものを用意した。データの内訳を表1に示す。モデルは1層の隠れ層を持つ構造とし、ノード数はそれぞれ入力層を67、出力層を3とした(図2)。入力データには前章記載のデータから抽出した計67種類の変数を使用し、出力データとして5分後の事故の発生、渋滞の発生、および非渋滞が継続する場合は予測するものとした。今回の分析において、合計で664あるデータのうち、200を訓練データ、残りの464を検証データとし、計算の繰り返し数であるエポック数は100とした。この計算により、損失値を最良とするものをそのデータにおけるモデルとする。なお表1に示されるように、事故件数は通常時や渋滞発生件数と比較して少ないため、モデルに反映されにくいことが考えられた。そこで10の異なる入力データから異なる学習モデルを形成し、予測された発生確率の平均値を分析することとした。

表-1 学習データ概要

	事故発生	渋滞発生	非渋滞継続
T-120分	自由流	自由流	自由流
T-115分	自由流	自由流	自由流
⋮	⋮	⋮	⋮
T	自由流	自由流	自由流
交通状態遷移	事故発生	渋滞発生	自由流
件数 [N]	45	289	330
割合 [%]	6.8	43.5	49.7

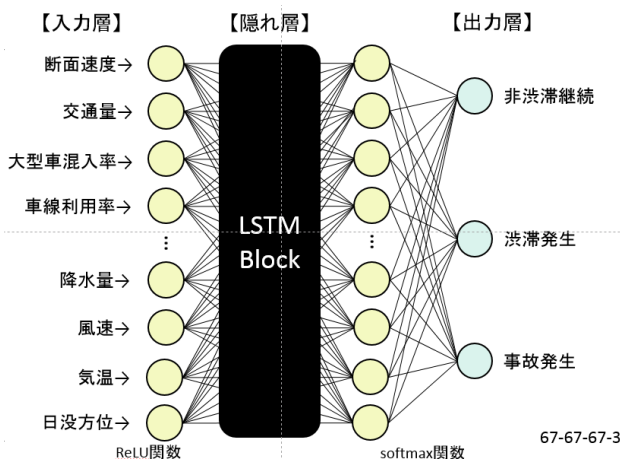


図-2 モデルのネットワーク概要

(3) 分析結果

a) 再現率

本研究では、このモデルの分析結果の検証に再現率を用いることとした。再現率には、「実際にXのデータ

でXと判別される割合」「実際にXではないデータでX以外に判別される割合」の2種類が存在する。その結果の一例を以下の図3,4に示す。再現率について、本研究では前者を”recall”，後者を”recallx”と呼ぶこととする。この図から、「実際に事故が発生した場合に事故の発生を予測している割合」が33%となっており、事故の発生を予測しているものとして高い数値を持つことが確認できた。それ以外の再現率についても75%を下回ることなく再現できていた。




図-3 再現率(recall)結果一例




図-4 再現率(recallx)結果一例

b) 時系列予測

これまでの結果を踏まえ、時系列の予測を行った。ここでは具体的にある24時間を抽出した結果を見ていくこととする。なお、同時刻の予測確率には10の学習モデルから推定された10の予測確率が存在する。そのためそれらを平均した値を予測確率として扱う。予測結果を図5,6に示す。

図5は実際に事故が発生した日のものである。この結果から、時間経過とともに事故と渋滞の発生確率が同様に上昇し、途中から事故発生確率の伸びが相対的に大きくなり、結果的に事故が発生する事例を確認できた。また、事故発生地点の上流側直近の車両感知器の速度と比較すると、事故発生時刻まで非常に安定した速度であり、人間では判別できない事故の発生要因が

存在することが考えられる。

図6は事故が発生せず渋滞に至った日のものである。この結果から、時間経過とともに事故と渋滞の発生確率が同様に上昇し、途中から渋滞発生確率の伸びが相対的に大きくなり、結果的に渋滞に至る事例を確認できた。この事例の場合、事故の発生には至っていないが、9時40分の段階で約20%まで事故発生確率が高まる予測となっており、約50%まで上昇している渋滞発生確率と合わせると、約70%の確率で事故か渋滞に至ることが予測されていた。

ここまでの結果から、事故発生を確率的に時系列で予測できる可能性が確認できた。しかし、事故発生確率は基本的に低く、渋滞発生確率以上の確率値をとることは少なかった。そこで日別に、事故が発生する場合、渋滞が発生する場合、非渋滞が継続する場合の3つに分類し、その交通状態遷移毎の平均をとり比較する

こととした。その結果を図7に示す。これを見ると、事故が発生した日の事故発生確率が渋滞の発生した日の事故発生確率と比べて高く予測されていることが分かる。これより、事故発生確率を予測に用いる際、一定の閾値を設け、段階的に事故を警戒することができると可能性が示唆された。また、渋滞が発生した日の事故発生確率の推移はピークが14時以降にあり、一方で事故が発生した日の事故発生確率のピークは13時~14時にある。これは事故が非渋滞の状態から発生する場合と、非渋滞の状態から渋滞が発生し、その後渋滞発生時の危険な交通状態遷移によって事故が誘発された場合との差から、事故のピークにずれが生じていると考えられ、妥当な結果であるといえる。

以上から、ディープラーニングを用い事故と渋滞の発生を時系列に予測可能なモデルを構築できた。




図-5 モデルによる予測発生確率推移(2017年1月1日13時23分事故発生)




図-6 モデルによる予測発生確率推移(2017年1月2日10時頃渋滞発生)




図-7 平均事故発生確率推移



#### 4. 最後に

本研究では、時々刻々と変化する様々な交通条件における適用性を高めるため、ディープラーニングを用いたモデルを構築した。

その結果、時間経過とともに事故と渋滞の発生確率が同様に上昇し、途中から事故発生確率の伸びが相対的に大きくなり、結果的に事故が発生する事例を確認することができた。また、速度等の要因の変化がない場合にも両発生確率が増加する様子が見られ、人間には即座にわからない事故や渋滞の引き金となる状況や要因の存在が考えられる結果となった。加えて、事故発生があった日とそうでない日とで、事故発生確率に差があることが確認でき、段階的に事故の警戒レベルを上げた施策につなげられる可能性が示唆された。

以上から、事故の発生を確率的に予測することへ適用できる可能性が明らかとなった。一方で、今回のモデルの課題として、モデルの構造や使用する変数などを深く比較していない点が挙げられる。これは著者の既往研究<sup>4)</sup>との比較をするためであるが、これをさらに検討することで、より事故の起こりやすいタイミングを明確に

捉えることができる可能性がある。

#### 参考文献

- 1) 国土交通省：高速道路の交通状況ランキング(平成 28 年)。
- 2) NEXCO 中日本：路線別断面交通量データ集，2014.4.
- 3) 舟橋尚平・小根山裕之・柳原正実・山本隆・山本浩司：東名大和サグ部を対象とした渋滞・事故発生確率の複合的分析，土木計画学研究発表会，2017
- 4) 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，24-23，2019，
- 5) 増本裕幸・宇野伸宏・山崎浩気・亀岡弘之・山本浩司・山本隆：ETC2.0 プローブ情報を用いた都市間高速道路における速度低下に関する分析，第 36 回交通工学研究発表会論文集，No.7，pp41-48，2016.
- 6) Minderhoud, M. M., Botma, H and Bovy, P. H.: Roadway Capacity using the Product-Limit Approach, Proceedings of the 77<sup>th</sup> Annual Meeting of the TRB, 1998.
- 7) 稲野晃，中村英樹，内海泰輔：複数ボトルネックを含む高速道路区間における渋滞現象の確率的解析，高速道路と自動車，第 52 巻，第 1 号，pp. 19-29, 2009.
- 8) 萩田賢司・森健二：太陽の眩しさが交通事故に与えた影響の分析，土木学会論文集，Vol67，No5，ppL1055-L1062，2011

(2020.3.8 受付)

## CONSTRUCTION OF PREDICTION MODEL OF CONGESTION / ACCIDENT OCCURRENCE ON INTERCITY EXPRESSWAY BASED ON SENSOR DATA

Shohei FUNAHASHI, Hiroyuki ONEYAMA, Masami Yanagihara  
and Takashi YAMAMOTO

In areas where congestions frequently occur on intercity expressways, such as around the Yamato Tunnel on the Tomei Expressway, not only congestions but also traffic accidents occur before and after. In order to prevent traffic accidents from occurring, it is necessary to estimate traffic congestion and the likelihood of accidents based on current and past traffic conditions, and to implement traffic control that prevents accidents as much as possible. In this research, in order to use it as a tool for predicting the occurrence of accidents and congestions and performing appropriate traffic control, various factors in the intercity expressway are targeted for the section where the Tomei Expressway inbound Yamato Tunnel is a bottleneck. We constructed a Recurrent Neural Network model to predict the occurrence of accidents and traffic jams under the conditions, and verified its accuracy.