

## 高速道路の複数路線での交通事故発生予報手法の実データによる評価

Evaluation of Method to Predict Traffic Accident Occurrence on Expressways through Analysis Using Actual Data

下川 裕亮 SHIMOKAWA Yusuke 大場 義和 OHBA Yoshikazu

高速道路における交通事故では、渋滞などで停止中の車両への追突事故が主な原因であり、事故発生の可能性が高いことをドライバーが認識できれば、事故を低減できると考えられる。

東芝インフラシステムズ(株)は、交通管制員やドライバーへの交通事故発生予報の提供によって事故を未然に防止するため、ニューラルネットワークの一種である自己組織化マップを用いて高速道路における交通事故発生予報手法の実用化に向けて取り組んでいる。今回、この手法を基に、高速道路の複数路線での実データを用いた評価検証を実施し、目標仕様が達成できることを確認した。

Rear-end collisions with vehicles that have stopped at times of traffic congestion are one of the main causes of traffic accidents on expressways. An effective means of reducing such accidents is to provide drivers with prediction information when there is a high probability of an accident occurring.

Toshiba Infrastructure Systems & Solutions Corporation is aiming at the practical application of a method to predict the occurrence of traffic accidents on expressways by means of a self-organizing map, which is a type of neural network, in order to prevent traffic accidents from occurring through the provision of such prediction information to traffic control personnel and drivers. From the results of verification tests using actual data collected from multiple expressway routes, we have confirmed that this traffic accident occurrence prediction method satisfies the target specifications.

### 1. まえがき

警察庁の統計資料「令和3年中の交通事故の発生状況」<sup>(1)</sup>によると、高速道路では年間4,800件以上の交通事故が発生している。事故類型別では、追突事故の割合が、全体の66%を占めている。更に、この追突事故の60%程度が渋滞などにより停止や減速している車両への追突と見られ、これは過去の事故状況と同様の傾向となっている。

一方で、自動運転車のように、車両側の先進安全装備は目覚ましい進化を遂げており、今後、追突事故の抑制に寄与すると考えられる。しかし、国土交通省の「自動運転に対応した道路空間のあり方」<sup>(2)</sup>によれば、車載センサーでは把握できず外部から取得する必要がある情報については、その提供不足の改善が課題として挙げられている。つまり、先進安全装備による事故の抑制効果をより確実なものにするには、道路システムからの情報提供が重要であるといえる。

このような中、東芝インフラシステムズ(株)は、高速道路における渋滞中や渋滞末尾の追突事故の抑制を目的として、ニューラルネットワークの一種である自己組織化マップを用いた高速道路の交通事故発生予報手法を提案し、研究開発を行ってきた。将来的には、この手法を交通管制システムに実装し、交通事故が発生する度合いについての注意喚

起や迂回(うかい)経路情報などを、自動運転車を含むドライバーへ提供することで、交通事故発生の低減に寄与できると考えている。また、交通事故発生に備えて、パトロールカーを事前待機させることで、二次災害の防止につながると考えている。

今回、この手法の有効性を、現在稼働している交通管制システムで収集した複数路線における実データを用いて机上試行により評価した。ここでは、この交通事故発生予報手法の概要を示すとともに、その評価結果について述べる。

### 2. 自己組織化マップを用いた高速道路の交通事故発生予報手法

これまで、交通事故発生予報手法として、道路交通状況と交通事故発生の関係を機械学習させて予測に利用する仕組みを立案・検討してきた。特に機械学習においては、パターン分類などで利用されている自己組織化マップを用いた手法を立案した。この自己組織化マップを用いた高速道路の交通事故発生予報手法<sup>(3)</sup>の概要を述べる。

#### 2.1 自己組織化マップによる交通情報データの学習

交通事故発生予報手法は、交通事故発生時の状況を表す交通情報データを入力ベクトルとして自己組織化マップ<sup>(4)</sup>に入力し、事故の起こりやすさを表す交通事故発生度を推




図1. 交通事故データの学習の構成

入力ベクトルとして交通情報データを用いて学習し、自己組織化マップを構築する。

Structure of traffic accident data learning

定するものである。学習時には、過去に収集した交通データ（交通量、車両速度、占有率など）や気象データ（雨量、降水検知、路温、風向風速など）といった情報を使用する。実際に交通事故が発生した際の交通データや気象データも併せて学習することで、交通事故発生予報に有効な自己組織化マップが構築される。

また、入力ベクトルである交通事故発生時の状況が分類された競合層の分布と、交通事故が発生する度合いの関係が分かりやすくなるように、入力層と競合層のほかに交通事故発生度分布層を設けた（図1）。競合層と交通事故発生度分布層のユニットは、1対1に対応させる。競合層の重みベクトルを更新する際に、同時に対応する交通事故発生度も更新することで、交通情報データと交通事故発生度の相関関係まで学習できる。そして、交通事故の起こりやすさを判定した結果を定量的に示すため、学習完了後の交通事故発生度分布層の全ユニットに対して、交通事故が発生する可能性として0から10までの11段階の評価値を割り当てる。

## 2.2 交通事故発生予報の出力

交通事故発生予報は、交通情報データを学習後の自己組織化マップの入力ベクトルとし、競合層で勝者ユニットを決定後、この勝者ユニットと同じ位置にある交通事故発生度分布層のユニットが持つ評価値を交通事故発生度として出力する。

## 3. 複数路線での実データを利用した評価

これまでの検討では、交通管制システムへの実装を想定<sup>(5)</sup>し、道路上に設置されている車両感知器からの実データを用いて、単一路線の交通事故発生予報を試行してきた<sup>(6)</sup>。今回は、単一路線から複数路線に検討の領域を拡大した。その試行内容と評価結果、及び考察に関して述べる。

### 3.1 交通事故発生予報手法における学習モデル

対象路線は、首都圏近郊の都市間高速道路である関越自動車道の下り線、東北自動車道の上り線と下り線、及び常磐自動車道の上り線と下り線の五つの路線（図2）とした。これらの路線では渋滞が発生する区間があり、渋滞中又は渋滞末尾の追突事故が発生しているため、今回の机上試行の対象に適している。

また、交通状況を計測するための車両感知器は、首都近郊でおおむね2 km間隔で設置されており、その計測データから交通量（台/分）、平均速度（km/h）、占有率（%）を計算している。今回、渋滞時における追突事故について試行するため、2017年の交通事故データの中から渋滞中（渋滞末尾を含む）の追突事故データを抽出して学習し、2018年の渋滞中の追突事故を予測することで評価を実施した。

### 3.2 自己組織化マップを用いた交通事故発生予報手法の評価方法

今回実施した試行では、入力には、単一路線でのこれまでの試行と同様、道路上に設置されている車両感知器データを用いた。出力の交通事故発生度は、あらかじめ学習した予測モデルにおいて最も類似性の高いユニットの評価値とした。この交通事故発生度を基に評価を行った。今回の試行では、自己組織化マップより出力された交通事故発生度（0～10）が領域ごとに設定されたしきい値以上の場合、交通事故発生予報として警報を出すこととし、再現率と予測発報割合を指標として評価を行った。

再現率は、全事故数に対して、交通事故発生を的中させた事故数（事故時に警報を出した数）の割合として、式(1)のように定義した。

$$\text{再現率 (\%)} = \frac{\text{的中した事故数}}{\text{全事故数}} \times 100 \quad (1)$$

ここでは、事故発生時の直前から10分前までに警報を出した場合を的中とみなしている。

予測発報割合は、予測タイミング（予測演算を行う機会）の全数に対して、警報を出した数（予測数）の割合と定義し、式(2)で算出した。

$$\text{予測発報割合 (\%)} = \frac{\text{予測数}}{\text{全予測タイミング}} \times 100 \quad (2)$$

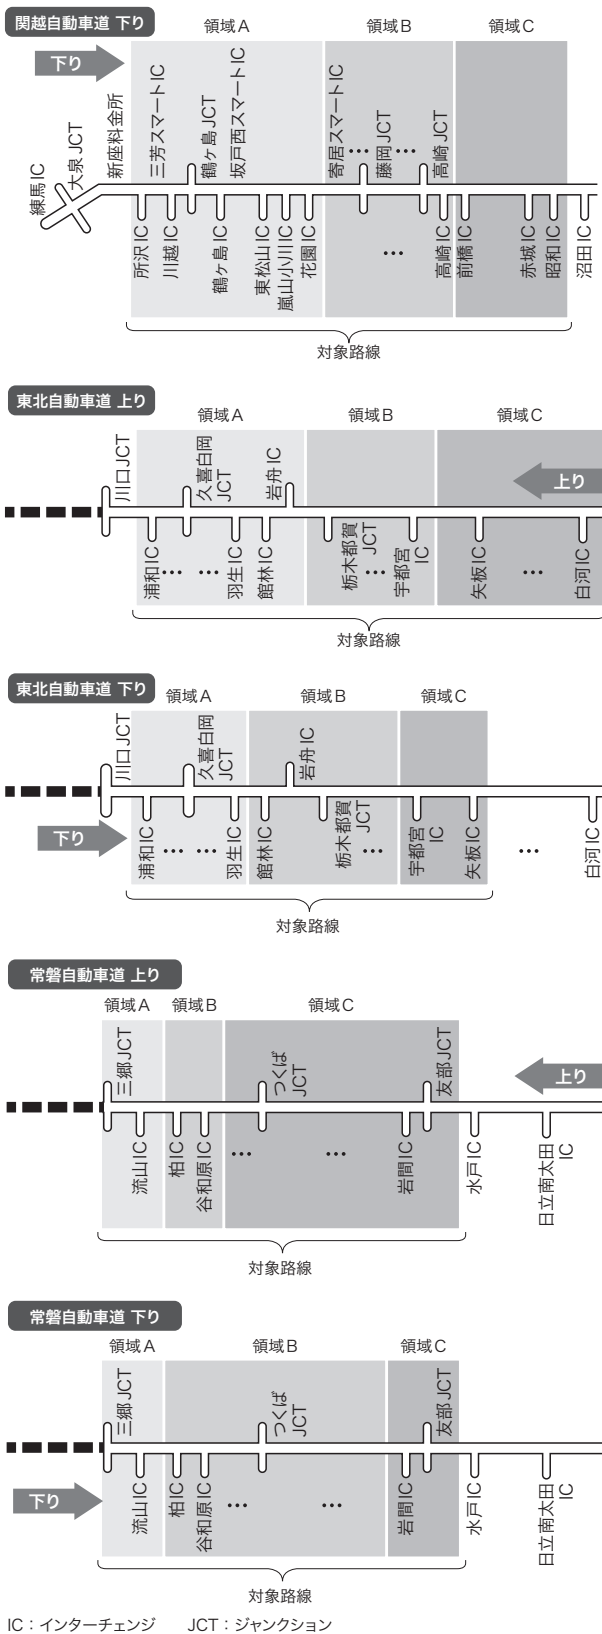


図2. 評価対象の路線

対象路線は、片側2車線区間と片側3車線区間があり、領域によって渋滞頻度や交通事故の発生件数が異なるため、領域ごとに学習した自己組織化マップを用いて評価した。

Routes targeted for evaluation


この手法の有効性については、有識者のコメントなどを参考に、再現率70%以上、予測発報割合10%以下を判定基準とし、これを目標値として評価を行った。

また、対象路線は、片側2車線区間と片側3車線区間があり、領域によって渋滞頻度や交通事故の発生件数が異なる。そこで今回、車線数と交通事故の発生件数などを基に、例えば片側3車線で事故件数が多い領域、片側3車線で事故件数が少ない領域、片側2車線で事故件数の少ない領域などといったように分割し、それぞれの領域に対して学習した個別の自己組織化マップを用いて評価した。


### 3.3 実データによる評価結果と考察

代表的な評価結果を、図3に示す。横軸は、図2に示されている路線の各分割領域、又は路線全体(領域A~C)を示し、縦軸は、それぞれの領域に対する再現率を左側の軸に、予測発報割合を右側の軸に、それぞれ示している。

試行結果から、各路線において、領域全体で見た場合に、再現率は70%以上、予測発報割合は10%以下であり、目標を満たしていることが確認できた。ただし、分割した領域単位で見た場合、東北自動車道上りの領域Bにおいては再現率が64.7%となり、目標を満たしていない領域



(a) 常磐自動車道 上り



(b) 東北自動車道 下り

図3. 実データを用いた検証結果

各路線において、領域全体で見た場合に、再現率に関しては70%以上、予測発報割合に関しては10%以下であり、目標を満たしていることが確認できた。

Results of verification tests using actual data

があることが確認された。これについては、学習に用いた交通事故データと評価した実データとの類似性が低い状況であり、類似した道路交通状況のデータが得にくいため再現率を高められなかったケースと考えられる。このような場合に該当する領域については、再現率が低いので対象外とする方法もあるが、過去数年の事故との類似性についても確認した上学習データを増やすことで再現率の向上を目指す方法も考えられる。このような対策を含めて再現率については、更に検討していく。

#### 4. 今後の検討項目

今回実施した複数の路線に対する試行で確認できた内容を踏まえて、今後は、以下の3点について検討していく。

- (1) 再現率が低い領域への対策として、類似性のあるデータを学習に追加するなどの改善の可能性についての検討
- (2) 交通事故発生度予測手法の更なる改善を進める上で、入力データにカーブ、上り坂、及び下り坂といった道路形状や、降雪や雨といった季節などによって変化する環境情報などを追加する検討
- (3) 出力である交通事故発生度を交通管制員に正確に伝え、ドライバーに対して注意喚起や迂回経路情報として分かりやすく提供するための、ユーザーインターフェースの検討

#### 5. あとがき

当社が研究開発を進めている、自己組織化マップを用いた交通事故発生予測手法に関して、複数路線の実データを用い、机上試行によって評価した。

将来、車両の安全装置の進化及び自動走行車の登場により、交通事故発生件数も減少するといわれている。これに加えて、道路システム側から十分に情報提供していくことで、安全性は格段に向上するものと考えられる。今回の机上試行で得られた結果を実際の交通管制システムに応用し、誰もが安全にそして安心して高速道路を通行できる社会を目指して、更に検討を進めていく。

#### 謝 辞

ここで述べた技術の開発にあたり、事故予測の試行の際に使用した学習用データ及び評価用データは、東日本高速道路株式会社関東支社から貸与いただいた。ここに感謝の意を表します。

#### 文 献

- (1) 警察庁交通局, “令和3年中の交通事故の発生状況”, 警察庁, <<https://www.e-stat.go.jp/stat-search/files?page=1&layout=datalist&toukei=00130002&tstat=000001027457&cycle=7&year=20210&month=0>>, (参照 2022-06-06).
- (2) 国土交通省, “自動運転に対応した道路空間のあり方”, 自動運転に対応した道路空間に関する検討会 中間とりまとめ (2019年11月26日), <[https://www.mlit.go.jp/road/ir/ir-council/road\\_space/pdf/chumatome.pdf](https://www.mlit.go.jp/road/ir/ir-council/road_space/pdf/chumatome.pdf)>, (参照 2022-06-06).
- (3) 村野剛教, ほか, 高速道路の交通事故発生予測手法, 東芝レビュー, 2012, 67, 12, p.23-26.
- (4) Kohonen, T. Self-organized formation of topologically correct feature maps. Biological Cybernetics. 1982, 43, 1, p.59-69.
- (5) 下川裕亮, ほか, 高速道路での交通事故発生予測手法の実用化に向けた取り組み, 東芝レビュー, 2017, 72, 3, p.15-18, <[https://www.global.toshiba/content/dam/toshiba/migration/corp/techReviewAssets/tech/review/2017/03/72\\_03pdf/a05.pdf](https://www.global.toshiba/content/dam/toshiba/migration/corp/techReviewAssets/tech/review/2017/03/72_03pdf/a05.pdf)>, (参照 2022-06-06).
- (6) 下川裕亮, ほか, “高速道路での交通事故発生予測手法の評価”, 2021年 電気学会 電子・情報・システム部門大会, 2021-09, 電気学会, 2021, p.443-449.



下川 裕亮 SHIMOKAWA Yusuke  
東芝インフラシステムズ (株)  
社会システム事業部 道路ソリューション技術第一部  
電気学会会員  
Toshiba Infrastructure Systems & Solutions Corp.



大場 義和 OHBA Yoshikazu, Ph.D.  
東芝インフラシステムズ (株) インフラシステム技術開発センター  
システム制御・ネットワーク開発部  
博士 (工学) 電気学会・計測自動制御学会・交通工学研究会会員  
Toshiba Infrastructure Systems & Solutions Corp.