

高速道路での事故発生時における交通流予測及び情報提供技術の開発

Development of Technique for Traffic-Flow Prediction and Information Provision in Event of Accidents on Expressways

成瀬 浩輔 NARUSE Kosuke 嶋村 翔 SHIMAMURA Sho 桑原 雅夫 KUWAHARA Masao

交通渋滞は長年にわたって社会問題となっており、事故により発生するものも多い。

東芝インフラシステムズ(株)は、国立大学法人 東北大学と共同で、機械学習手法を用いて高速道路での事故発生時の交通流予測技術を開発している。今回、事故発生後の60分間の交通流を予測する機械学習モデルを構築した。実データによる評価の結果、半数以上のケースについて、交通状況正解率の目標値である75%以上となることを確認した。今後は、事故の規模を示す情報を取り入れることも検討し、機械学習モデルの改善を図る。また、交通流予測結果を、ドライバーの現在地点や出発時刻に応じた、到着時刻推定や渋滞回避などに役立てるため、ヒートマップを応用した情報提供方法も検討した。

Traffic congestion on expressways, which has been a social issue for many years, is often caused by accidents.

In cooperation with Tohoku University, Toshiba Infrastructure Systems & Solutions Corporation is working on the development of a technique utilizing a machine learning method to predict the flow of traffic in the event of traffic accidents on expressways. We have constructed a machine learning model on a trial basis to predict the flow of traffic for 60 minutes after the occurrence of an accident. The results of tests using actual data have confirmed that the traffic-flow prediction model achieves an accuracy rate of 75% or higher as stipulated in the target specifications in more than half of all cases. In the future, we will consider incorporating information related to the scale of traffic accidents in order to further improve the accuracy of the model. We have also conducted studies on the provision of traffic-flow information to drivers based on the prediction results by means of heatmaps of vehicle velocity, making it possible to estimate arrival times and avoid traffic congestion according to the driver's departure time and present location.

1. まえがき

道路で発生する交通渋滞は、国内外を問わず、長年の社会問題となっている。2019年の、東日本高速道路(株)、中日本高速道路(株)、西日本高速道路(株)、及び本州四国連絡高速道路(株)の管内における渋滞損失時間^(注1)の合計は、2.3(億人・時間/年)にも上る⁽¹⁾。この渋滞損失時間の中で、40 km/h以下となる渋滞の約25%の原因が、事故である。このように、高速道路上の事故は、人命に関わることはもちろん、交通流に対しても大きな影響がある。

国土交通省は、ETC(Electronic Toll Collection System)2.0を活用した情報提供により、事故や渋滞を抑制しようとしている⁽²⁾。例えば、落下物や渋滞による車両滞留など、前方の危険事象についてのドライバーへの事前通知や、渋滞の回避支援を目的とした、リアルタイムな交通状況の通知などが挙げられる。

一方、東芝インフラシステムズ(株)は、交通情報を提供

する交通管制システムを、高速道路事業者に納入してきた。交通情報は、高速道路上を走行するドライバーの安全性・快適性向上を目的として提供されており、事故・故障車・渋滞といった事象や所要時間などを指す。今後、交通管制システムに、事故による交通流への影響を予測する技術を取り入れることで、渋滞の抑制に貢献する交通情報を提供できると考える。

近い将来、自動運転車の普及が期待されており、それに合わせて、走行環境を支える道路システムの進化も必要になる。交通流予測情報の提供により、自動運転車側で、一般道も含めた最適な経路を選択して走行できるようになることが期待される。また、電気自動車(EV)は、一般にガソリン車より航続距離が短く、SA・PA(サービスエリア・パーキングエリア)での充電渋滞が問題になっている。交通流予測の情報を使って最適な充電場所を案内することが、充電渋滞の緩和や、充電切れリスクの回避につながる。

当社は、東北大学と共同で交通流の予測技術を開発しており、交通流の予測情報提供の実現を目指している。これまでに、車両センサーデータを活用した渋滞予測技術を開発⁽³⁾

(注1) 混雑により余計に掛かる時間(人・時間/年)。

し、道路構造によるボトルネック区間における120分先までの交通流を予測する予測モデルを構築してきた。

一方で、事故によるボトルネックは、道路構造によるものと違い、発生地点が不確定であるという特徴がある。そこで今回、発生場所が不確定な事故発生後の交通流予測技術を開発した。更にドライバーに分かりやすい交通流予測情報の提供方法についても述べる。

2. 交通管制システムの概要

交通管制システムは、道路上の交通状況を測定する車両感知器や監視カメラなどの情報収集端末と、情報収集端末から得られた情報を処理する交通管制中央装置などからなる情報処理装置、そしてドライバーへの情報を提供する情報提供端末から成り立っている(図1)。

高速道路の渋滞情報や所要時間情報などの交通流に関する情報は、車両感知器から収集される交通量や、速度、時間的占有率^(注2)などのデータを用いて、交通管制中央装置が作成する。また、事故に関する情報は、管制員が、事故の発生地点や車線閉鎖などの情報を含めて交通管制中央装置に入力する。そして、これらの交通情報を、高速道路

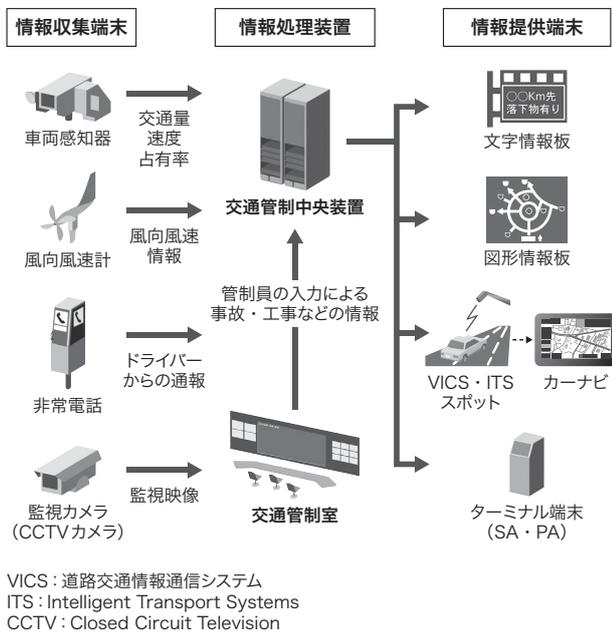


図1. 交通管制システムの概要

車両感知器などから収集したデータ、及び管制員が入力した事故・工事などの情報を交通管制中央装置で処理し、ドライバーに提供する情報を作成する。

Outline of traffic control system

(注2) 車両感知器などによって、単位時間当たりに車両が感知される時間の割合。

上の情報板やカーナビなどを通して、ドライバーに提供する。

このように、現在の交通管制システムは、情報を収集した時点の交通情報を提供しているが、数分先、更に数時間先といった将来の交通情報を予測・提供する仕組みはない。

3. 事故発生後の交通流予測技術

3.1 事故渋滞発生仕組み

渋滞は、交通量が交通容量と呼ばれるしきい値を超えた場合に発生する。交通容量は、単位時間当たりに通過できる交通量を指す。

基本的に、交通容量はサグ部^(注3)や合流地点などの道路構造上の制約状況によって決まる。道路構造による交通容量の減少は、地点ごとにあらかじめ分かっているため、渋滞の程度を予測しやすい。事故が発生すると、その地点の交通容量が突発的に減少し、ボトルネックになる(図2)。道路上の制約によって生じるボトルネックとは異なり、ボトルネック地点が想定しにくいだけでなく、事故の程度によって、1車線だけの閉鎖か、通行止めか、またその継続時間などが変わって交通容量に影響するため、渋滞の程度の予測も難しい。更に、交通容量は道路構造上の制約よりも事故で大きく変化するため、事故の発生は交通流に大きな影響を及ぼすことになる。

3.2 事故発生後の交通流予測

交通工学では、交通量と交通容量を基におおよその交通状況の把握ができるとされている。事故発生後の交通量は、事故発生区間の過去の交通量から推定でき、交通容量は事故発生後の下流区間の交通量を観測することで把握できる。これらの情報から、近年、急速に発展したAI技術の一

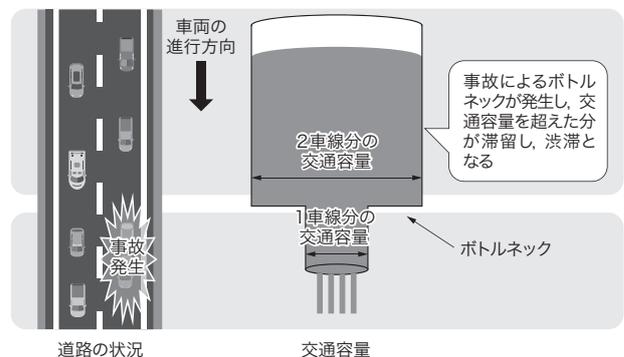


図2. 事故発生地点のボトルネック

事故発生地点では、交通容量が急激に低下し、渋滞のボトルネックとなりやすい。

Bottleneck section caused by traffic accident

(注3) 道路勾配が下りから上りに変化することで、走行速度が落ちやすい地点。

つである機械学習の手法を活用して、事故の影響をより高精度に予測できると考えた。

そのためには、事故発生区間より下流区間の交通量を迅速に把握する必要がある。事故発生区間や発生時刻は想定しにくいこともあり、高速道路全体にわたって空間・時間を網羅したデータを取得する必要がある。そこで、一定間隔で設置されており、1分周期で取得できる車両感知器のデータを活用することにした。

これらの考え方を基に、高速道路で取得された車両感知器データを活用し、機械学習を用いた事故発生後の交通流予測モデルの構築とその性能評価を試行した。

3.3 機械学習による交通流予測モデルの概要

今回の試行では、機械学習の一種であるRandom Forestを用いて、事故発生後の交通流への影響を予測するモデルを構築した。予測開始のトリガーは、事故発生後に管制員が交通管制システムに事故イベントを登録するタイミングとした。

予測モデルに必要な入力情報は、3.2節に述べたように、事故発生後の交通量を推定するための過去の交通量実績、及び事故発生時の交通容量を推定するための事故発生区間の下流区間の交通量である。更に、事故発生時の交通状況を示す情報として、事故発生区間の交通量と、事故発生区間の上流区間の交通量も入力した。出力情報は、事故が発生した区間と、その上流5区間を含む6区間の予測速度である。都市内高速道路の事故処理においては、車線閉塞（へいそく）時間が60分以下の事故が全事故の約70%であるというデータがある⁽⁴⁾ため、事故イベント登録の5分後から60分後までを、6区間のそれぞれに対して5分間隔で12点、全体で72点の速度を予測する（図3）。

今回検証した予測対象区間は、首都高速道路の高速神奈川1号横羽線（下り）の、ジャンクション（JCT）からの流入部を除く区間とした（図4）。この区間は、首都高速道路管内では比較的JCT分合流部が少なく、交通集中による渋滞の頻度も少ない。そのため、交通流の変化の主な要因が事故によるものと考えられるこの区間を予測の対象に選定した。

予測対象区間における、2018年に発生した254件の事故イベントに関連する車両感知器データを用いてモデルに学習させ、2019年の103件の事故イベントに関連する車両感知器データを入力して予測した。

3.4 予測モデルの性能評価結果と今後の改善案

一例として、4月13日の14:00に区間12で事故イベントが登録された際の、実際の状況と予測結果のヒートマップを、図5に示す。速度によって交通状況を、40 km/h以上

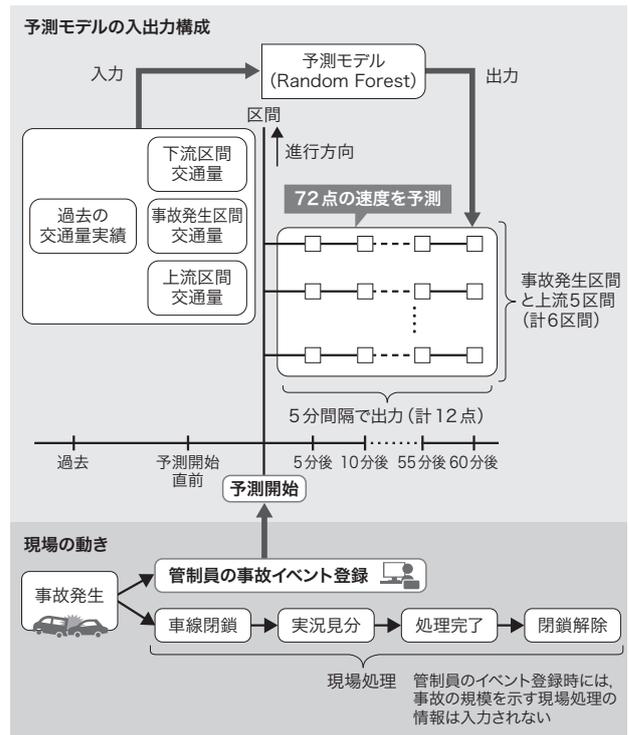


図3. 交通流予測モデルの入出力構成

管制員の事故イベント登録をトリガーに、事故発生区間とその上流5区間を対象として、事故イベント登録の5分後から60分後までを5分間隔で予測する。出力点数は、合計72点である。

Input-output configuration of traffic-flow prediction model

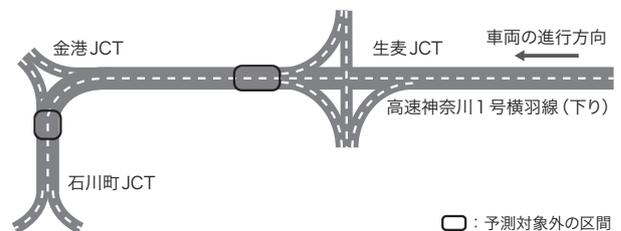


図4. 交通流予測モデルを検証した対象区間

高速神奈川1号横羽線（下り）の、生麦JCT・金港JCTからの流入部を除く区間を、予測対象とした。

Target section for verification of traffic-flow prediction model

で“自由流”，40 km/h未滿で“渋滞若しくは混雑”と分類した^(注4)。

予測モデルの性能を評価するために、予測する72点のうち実際と予測結果の交通状況が一致する割合を、交通状況正解率と定義する。この交通状況正解率を75%以上にするを、開発の目標値とした。図5の例では、72点のう

(注4) 首都高速道路では、車両感知器データの情報を基に、40 km/h以上を“自由流”，20～40 km/hを“混雑”，20 km/h未滿を“渋滞”と定義する区間が多い。

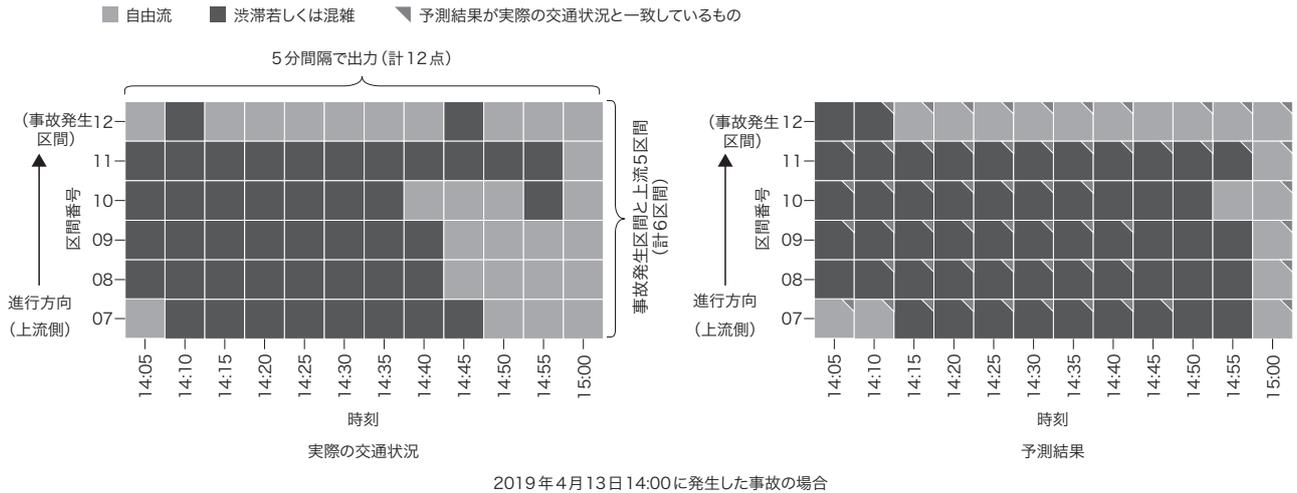


図5. 交通流予測モデルのヒートマップ出力結果例

渋滞若しくは混雑の状態が、上流側に伝搬していることを予測できている。

Example of heatmap showing performance of traffic-flow prediction model

表1. 交通流予測モデルの正解率

Results of tests of traffic-flow prediction model accuracy rates

頻度(回)	交通状況正解率				
	75%以上	75%未満 50%以上	50%未満	合計	
事故全体	56	27	20	103	
事故渋滞の発生	あり	10	27	19	56
	なし	46	0	1	47

ち57点で、実際と予測結果の交通状況の分類が一致しているため、交通状況正解率は約79%である。

予測対象区間で発生した103件の事故について、交通状況正解率の頻度をまとめた結果を、表1に示す。予測対象の103件のうち、半数以上の56件が、75%以上の交通状況正解率となった。なお、図5は、この56件のうちの1件である。

ここまでの結果を考察するため、予測対象とした103件の事故の実際の交通状況について、渋滞若しくは混雑の点数が10点以上であれば“事故渋滞が発生する”事故、10点未満であれば“事故渋滞が発生しない”事故と分類した。図5の例では、実際の状況の72点の中で、渋滞若しくは混雑が43点であるため、この事故は事故渋滞が発生する事故と分類できる。

分類の結果、事故渋滞が発生する場合に限ると、交通状況正解率75%以上となるのは56件中10件にとどまることが分かった。事故渋滞が発生する場合の交通状況正解率を上げることが、全体の交通状況正解率の改善につながる。

事故渋滞が発生する場合に交通状況正解率が低い原因

として、予測モデルの入力情報に事故の規模を示す情報が含まれていないことや、学習させる事故の件数が不足していることなどが考えられる。特に、事故の規模を示す閉鎖車線数と車線閉鎖の継続時間などの情報は、予測精度向上に重要である。また、予測開始から時間が経つと交通容量が変化するケースも見られるため、時間経過とともに予測結果を更新していく仕組みが必要である。

4. 交通流予測情報の提供方法

交通流の予測情報は、事故の発生後に限らず、様々な活用が考えられる。

例えば、都市間高速道路では、経路の選択肢は多くないが、SA・PAが多く設置されている。区間ごとの走行速度の予測情報を基に、目的地までの所要時間を情報提供することで、出発時刻の変更や、長距離走行中のSA・PAでの休憩などを促し、時間的な交通流の分散が可能となる。

また、都市内高速道路は、密な道路網が形成されており、経路の選択肢が多い。高速道路の路線図上に、混雑予測区間を表示することで、ドライバーが適切に経路を選択でき、空間的な交通流の分散につながる。

交通流の予測情報を、高速道路上を走行中、あるいは走行予定のドライバーに提供する場合、現在地点や出発時刻に応じた予測が必要である。今後の走行経路の交通状況を、3.4節で述べたようなヒートマップの形式で可視化・表示することで、ドライバーに経路の変更や出発時間の変更を直接促す効果的な情報提供が可能になる。図6に、幾つかの走行軌跡を例に、ヒートマップ上に走行状況を可視化し

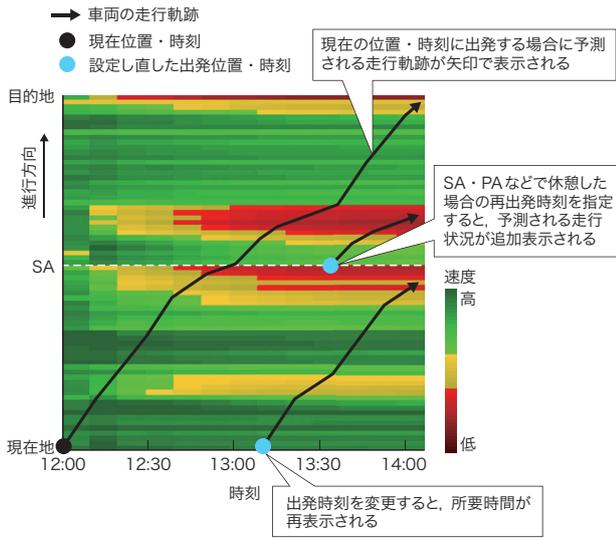


図6. 交通流予測情報の提供例

カーナビやインターネットなどで、ドライバーの現在地点や出発時刻に応じた走行状況を確認して、走行計画を変更することで、より快適・安全に目的地に到達できるようになる。

Example of information provided in traffic-flow prediction information service

た情報提供イメージを示す。

5. あとがき

機械学習手法を用いた、高速道路の事故発生時における交通流予測モデルを構築し、半数以上のケースについて、交通状況正解率が目標の75%以上となることを確認した。今後は、事故渋滞が発生する場合の予測精度の向上を図るため、事故の規模の情報を入力することも検討していく。これによって、事故による渋滞の有無だけでなく、車両速度の予測精度を高め、最終的には旅行時間の予測精度向上につなげていきたい。

また、交通流予測情報を活用するために、ヒートマップを応用した一般ドライバーへの情報提供についても検討した。今後も引き続き、交通流の分散に効果的な情報提供方法を検討していく。

謝辞

交通流予測技術の開発にあたり、車両感知器データをご提供いただいた首都高速道路(株)に、感謝の意を表します。

文献

- (1) 国土交通省. 平成31・令和元年 高速道路の交通状況ランキング. 国土交通省, 2019, 13p. <https://www.mlit.go.jp/road/ir/ir-data/pdf/highway_ranking_r01.pdf>, (参照 2022-04-20).
- (2) 国土交通省道路局. “交通流対策について”. 中央環境審議会地球環境部会2020年以降の地球温暖化対策検討小委員会. 産業構造審議会 産業技術環境分科会 地球環境小委員会 約束草案検討ワーキンググループ合同会合(第5回). 東京, 2015-03, 国土交通省, 2015, 資料7, 10p. <https://www.meti.go.jp/shingikai/sankoshin/sangyo_gijutsu/chikyu_kankyo/yakusoku_soan/pdf/005_07_00.pdf>, (参照 2022-04-14).
- (3) 成瀬浩輔, ほか. 車両感知器データを活用した機械学習手法による高速道路の渋滞予測技術. 東芝レビュー, 2021, 76, 1, p.41-45. <<https://www.global.toshiba/content/dam/toshiba/jp/technology/corporate/review/2021/01/f03.pdf>>, (参照 2022-04-20).
- (4) 朝倉康夫, ほか. 道路政策の質の向上に資する技術研究開発成果報告レポート No.22-1 都市高速道路における突発事象時の最適交通運用についての研究開発. 新道路技術会議, 2013, 61p. <<https://www.mlit.go.jp/road/tech/jigo/h22/pdf/report22-1.pdf>>, (参照 2022-04-20).



成瀬 浩輔 NARUSE Kosuke
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
Toshiba Infrastructure Systems & Solutions Corp.



嶋村 翔 SHIMAMURA Sho, 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(情報工学)
Toshiba Infrastructure Systems & Solutions Corp.



桑原 雅夫 KUWAHARA Masao, Ph.D.
東北大学 未来科学技術共同研究センター
博士(工学)
交通工学研究会・土木学会・国際交通安全学会会員
Tohoku University