

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

Prediction of Traffic Congestion on Expressways through Machine Learning Model Using Traffic Detector Data

成瀬 浩輔 NARUSE Kosuke 青木 泰浩 AOKI Yasuhiro 桑原 雅夫 KUWAHARA Masao

長年にわたって社会問題となっている交通渋滞は、ICT（情報通信技術）やAIなどの最新技術を活用して抑制していくことが期待されている。

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、AIの一種である機械学習手法を交通工学的な知見に基づいて活用し、高速道路の渋滞を予測する技術の開発を進めている。今回、過去の車両感知器データを用いて、高速道路のボトルネック区間における120分先までの渋滞を予測する機械学習モデルを構築した。構築した予測モデルで3段階の渋滞度の予測性能をF値^(注1)により評価し、10分先、60分先、120分先の値としてそれぞれ0.796、0.720、0.637を得るとともに、その時間的な変化も緩やかであることを確認した。今後は、より長期的な予測も行うことで、予測モデルの実用化に向けた検討を進めていく。

Traffic congestion has been a social issue in the field of transportation for many years. Demand has therefore been growing for the application of the latest technologies, including information and communication technologies (ICTs) and artificial intelligence (AI), to mitigate such traffic congestion.

In cooperation with Tohoku University, Toshiba Infrastructure Systems and Solutions Corporation has been engaged in the research and development of a technology to predict traffic congestion on expressways utilizing a machine learning method comprising a type of AI based on traffic engineering knowledge. We have now constructed a mechanical learning model that can predict traffic congestion at bottleneck sections on expressways up to two hours in advance using past traffic information collected by traffic detectors installed on the expressways. We have conducted verification tests to evaluate the prediction performance of this model in three stages, and confirmed that its prediction accuracy achieves an F-measure of 0.796 for 10 minutes, 0.720 for 60 minutes, and 0.637 for 120 minutes in advance, showing gradual changes of the F-measure over time. With the aim of achieving practical use of this technology, we are promoting the development of a model capable of achieving longer-term traffic congestion prediction.

1. まえがき

国内外を問わず道路における交通渋滞は、長年、社会問題となっている。我が国では、国民一人当たりの自動車の年間乗車時間は、渋滞がない場合に比べて約40時間も長く⁽¹⁾、その経済損失額は約12兆円にも上るといわれている⁽²⁾。

この問題に対して、国土交通省は、ICTやAIなどを活用し、ドライバーの行動変容を促して渋滞を抑制していく、“交通マネジメント”の強化を検討している⁽³⁾。例えば、ETC（Electronic Toll Collection System）2.0から、あるいはその他の多様なセンサーから得られる情報と、AIを用いた解析技術などを融合させて、交通状況の収集・分析・予測を可能とするシステムを構築する施策が検討されている。

一方、東芝インフラシステムズ（株）は、高速道路上を走

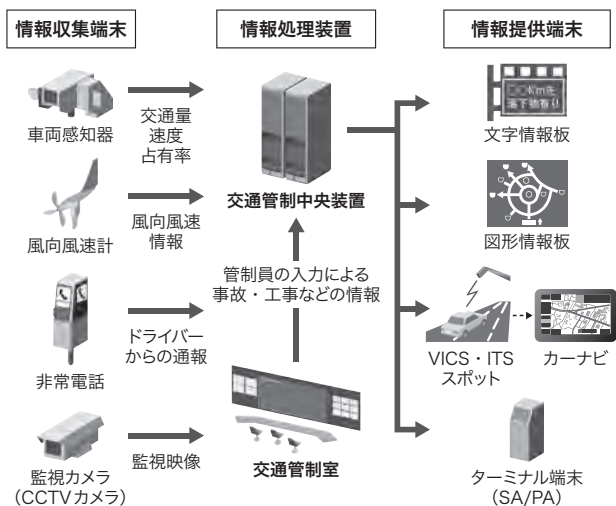
行するドライバーの安全性・快適性を確保するために、交通情報を提供する交通管制システムを高速道路事業者に納入してきた。交通情報は、事故、故障車、渋滞といった事象や、所要時間などを指すが、今後、交通管制システムにAI技術を取り入れることで、渋滞の抑制に貢献する交通情報を提供できると考えられる。ここでは、当社における高速道路の渋滞予測技術開発の取り組みとして、機械学習手法を活用して高速道路のボトルネック区間の渋滞を予測する技術について述べる。

2. 交通管制システムの現状

高速道路の交通情報は、路上に設置された車両感知器から交通量や、速度、占有率などのデータを収集し、交通管制システムにより渋滞状況や所要時間などを算出した上で、高速道路上の情報板や、カーナビといった媒体を通してドライバーに提供されている（図1）。

このように、現在の交通管制システムは、リアルタイムの

(注1) 機械学習などの予測性能評価に用いられる指標。値が1に近いほど予測の精度が高い。



VICS：道路交通情報通信システム ITS：高度道路交通システム
 CCTV：Closed Circuit Television SA/PA：サービスエリア/パーキングエリア

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を交通管制中央装置で処理し、ドライバー提供用の情報を作成する。

Outline of traffic control system

交通情報を提供しているが、数分先や数時間先といった将来の交通情報を予測・提供する仕組みにはなっていない。

3. 渋滞予測の意義と種類

3.1 渋滞予測の意義

高速道路の渋滞は、一般道からの流入を制限して交通量を減らすことで抑制可能であるが、それでは物流の停滞や緊急車両の対応遅れなど、社会的な影響が大きい。そのため、高速道路全体の交通量を減らすことなく渋滞を抑制する仕組みが必要となる。「ITSによる革新的な道路交通マネジメントの潮流」⁽⁴⁾によると、リアルタイム及び予測による交通情報に基づく交通マネジメントの方法として、ドライバーへの課金及び情報提供があると述べられている。これは、課金や情報提供によって、集中する交通流を時間的・空間的に分散させ、渋滞を抑制するものである⁽⁵⁾。このように、渋滞を予測して情報提供することが、交通流の分散を促すために有効と考えられる。

また、効果的に渋滞を抑制するために、ダイナミックプライシング^{(6), (7)}の検討も進んでいる。これは、道路状況に応じて課金額に差を設け、渋滞しそうな路線、あるいは渋滞中の路線からすいている路線へと経路の変更を促し、渋滞を抑制しようとする施策である。ダイナミックプライシングによる渋滞抑制をより効果的に行うためには、渋滞の発生前に、その渋滞を予測した上で課金額を変更することが有効と考えられる。

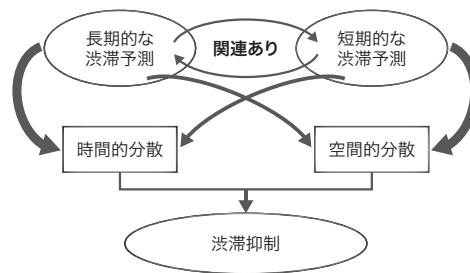


図2. 長期・短期的な予測を用いた渋滞抑制の概念

渋滞抑制に必要な時間的・空間的な分散を実現するためには、長期・短期的な予測技術が重要となる。

Conceptual diagram of congestion control by means of long-term and short-term predictions

このように、渋滞予測情報の提供に加え、課金施策も含めて交通流を分散させるためにも、渋滞予測の技術が重要である。

3.2 渋滞予測の種類

渋滞の予測は、日付をまたいだ24時間以上先を対象とした長期的な予測と、数分先や数時間先を対象とした短期的な予測、の2種類に分けて扱うことができる。

長期的な予測が可能になれば、翌日以降の運転を計画しているドライバーに対し、ホームページやスマートフォンのアプリケーションなどを通して、渋滞を避けるような行動変容を促す情報を提供できる。長距離を走行するドライバーは運転計画の参考にでき、特に時間的な分散に貢献する。

一方、短期的な予測が可能になれば、高速道路上を走行している、あるいはこれから走行しようとしているドライバーに対し、直接的に経路の変更を促すような情報提供ができる。これは、複数の経路を選択できる場合の参考となり、特に空間的な分散に貢献する。

このように、時間的・空間的な交通流の分散を図るためには、これら2種類の予測が必要になる。また、これらは相互に関連があり、例えば大型連休やレジャー施設の大規模イベントなどに関連した長期的な予測を行うことで、短期的な予測性能を向上させることができる。これらの考え方をまとめたものを、図2に示す。

このように、長期的な予測と短期的な予測の二つが重要となる。4章以降で、今回の短期的な渋滞予測技術の開発について述べる。

4. 渋滞予測技術の開発

4.1 渋滞発生の仕組みと渋滞予測技術の手法

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、サグ部や合流地点などの道




図3. 合流地点のボトルネック

道路の合流地点は、交通容量が急激に低下するため、渋滞のボトルネックとなりやすい。

Bottleneck generating traffic congestion at junction

路構造上の制約によって変化するほか、事故などによっても変化する。交通量が交通容量を超えた場合、その位置がボトルネックとなって渋滞が発生し、延伸することが知られている⁸⁾。したがって、ボトルネックの位置を事前に調査することが、交通状況の把握にとって重要となる。

図3に示すように、ボトルネック区間となる場所の一つとして、ジャンクション（以下、JCTと略記）の合流地点が挙げられる。合流地点は、複数の路線から車両が流入するため、交通量が交通容量を超えて渋滞が発生しやすくなる。

こうした渋滞の予測は、従来、交通工学的な知見に基づいたシミュレーションにより、計算機上で渋滞を再現・検証する手法で行われてきた。その際、例えば複数のJCTに共通した予測モデルを構築することは難しく、JCTごとに固有の交通量・交通容量を考慮した予測モデルの構築・条件設定を行う必要があった。

これに対して、近年急速に発展した、AI技術の一つである機械学習の手法を用いることで、高精度に渋滞を予測できる可能性がある。共通の予測モデルを構築し、諸条件の再設定を行うことなく、対象ごとに大量のデータ間の因果関係を学習することで、渋滞を予測する。今回は、車両感知器データを活用した機械学習による予測モデルについて検証した。

4.2 渋滞予測の問題設定

従来、交通状況を把握する手段として利用されている車両感知器は、道路上に一定間隔で設置されており、2章で述べた交通状況に関するデータを一定時間ごとに取得している。このように、車両感知器は網羅的に空間的・時間的なデータを取得できるため、渋滞状況を予測するためのデータとして有用であると判断し、このデータを活用した予測モデルの構築と予測性能の評価を行った。




図4. 予測対象区間の道路

ボトルネック区間となる高速3号渋谷線（下り）と大橋JCTの合流地点を、予測対象区間とした。

Targeted bottleneck section

予測対象区間としては、首都高速道路の高速3号渋谷線（下り）の大橋JCT合流地点を選定した。この地点は、4.1節で述べた渋滞のボトルネック区間となり得る場所である。図4に、高速3号渋谷線（下り）と大橋JCTの合流地点を示す。

交通管制システムでは、車両感知器データの情報を基に、交通状況を“渋滞”、“混雑”、“自由流”の3段階で表すことがある（以下、この情報を渋滞度と呼ぶ）。今回は、渋滞度を速度の値によって、渋滞は20 km/h以下、混雑は20～40 km/h、自由流は40 km/h以上と定義し、検証を行った。

今回の検証では、5分先から120分先の渋滞度を、5分間隔で予測する。予測を行う時間帯は、渋滞の発生頻度が比較的高い朝7～9時、及び夕方17～19時の通勤時間帯を選んだ。

予測した渋滞度は、再現率と適合率の調和平均で定義されるF値で評価した。再現率と適合率は、渋滞、混雑、自由流のそれぞれについて、図5に示すように算出した。更に、表1に示すように、三つの再現率の平均値と、三つの適合率の平均値を求め、式(1)からF値を算出した。

$$F \text{ 値} = \frac{2 \times \text{再現率平均値} \times \text{適合率平均値}}{(\text{再現率平均値} + \text{適合率平均値})} \quad (1)$$

4.3 機械学習による予測モデルの概要

今回検証した高速3号渋谷線（下り）と大橋JCTの合流地点における予測モデルの入出力構成を、図6に示す。

図4に示したボトルネック区間を予測対象とし、それに接続する複数の上流区間、下流区間も含めた各区間の車両感知器データ（交通量、速度、占有率）を、予測開始前の5～7時及び15～17時の各120分間について、5分間隔で入力した。また予測データは、ボトルネック区間の120分




図5. 渋滞の再現率と適合率の算出方法

再現率は、実際の渋滞データのうち渋滞と予測できたものの割合、適合率は、渋滞と予測したデータのうち実際に渋滞であったものの割合である。また、混雑と自由流についても、同様に算出した。

Processes for calculation of recall and precision of traffic congestion

表1. 再現率平均値と適合率平均値の算出方法

Processes for calculation of average recall and precision values

項目	再現率	適合率
渋滞	①	④
混雑	②	⑤
自由流	③	⑥
平均値	再現率平均値(①, ②, ③の平均値)	適合率平均値(④, ⑤, ⑥の平均値)

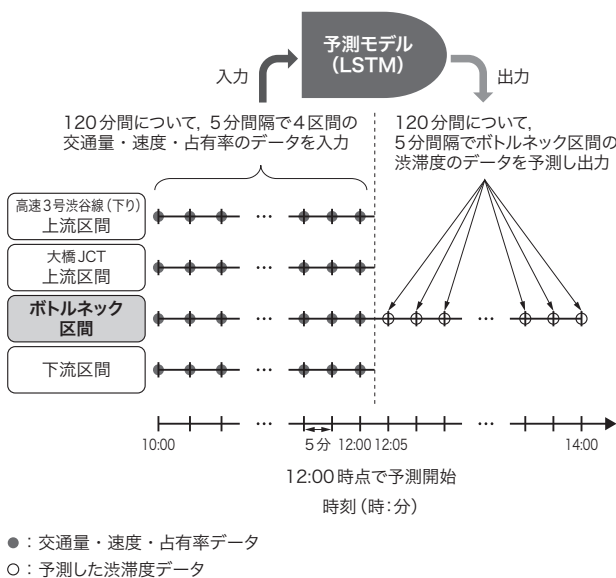


図6. 予測モデルの入出力構成

上流区間、ボトルネック区間、下流区間それぞれの、交通量、速度、占有率のデータを、120分間について5分間隔で予測モデルに入力し、5分先から120分先までの予測した渋滞度を5分間隔で出力する。

Input and output of prediction model

間の渋滞度を、5分間隔で出力した。

過去の複数の車両感知器データから、渋滞の予兆となる時間的な変化を学習できる予測モデルとするため、時系列データを適切に扱える機械学習手法として、LSTM (Long Short-Term Memory) を採用した。

評価には、2017年1月から2018年8月までの期間の車両感知器データを使用し、月ごとに、予測モデルの作成に使用する学習データと、予測モデルの評価を行うテストデータに、ランダムに分割した。

4.4 予測モデルの性能評価

テストデータのうち、5～7時、及び15～17時のデータを予測モデルに入力し、出力された予測データと、正解データに相当する実際のテストデータとを比較して性能評価を行った。F値を用いた結果を表2に示す。

F値の結果は、10分先が0.796、60分先が0.720、120分先が0.637、更に5分先から120分先までの平均値が0.719であった。ただし、正解データの渋滞度が頻繁に変化する場合には、予測データが追従できないケースも散見されたため、今後、実際の交通状況も踏まえた上での検証が必要である。

次に、予測モデルのF値の時間的変化を図7に示す。5分先から120分先のどのタイミングにおいても、急激にF

表2. 予測モデルの性能評価結果

Results of performance evaluation of prediction model

項目	F値
10分先	0.796
60分先	0.720
120分先	0.637
5分先から120分先までの平均値	0.719




図7. 予測モデルのF値の時間的変化

5分先から120分先までを予測した渋滞度のF値は、120分先まで急激に悪化することなく、緩やかに減少することを確認した。

Changes in F-measure of prediction model over time

値が悪化することはなく、緩やかに減少していることを確認した。このことは、高速道路上を走行しているドライバーに対して直近の時間帯の予測情報を提供するだけでなく、これから高速道路を走行しようとしている、SA/PA(サービスエリア/パーキングエリア)に停車中のドライバーに対しても情報を提供するなど、様々な交通施策を実施できる可能性を示唆している。

5. あとがき

機械学習手法を用いた予測モデルにより、高速道路のボトルネック区間における短期的な渋滞予測技術を検証した。複数区間の車両感知器データを活用して予測モデルを構築し、ボトルネック区間である合流地点において、渋滞度の分類予測で良好な予測性能が確保できた。これにより、機械学習手法を用いた予測モデルによる予測機能実現に、一定の目的を立てることができた。現在、場所が異なる複数のボトルネック区間に対しても、今回構築した予測モデルの適用可能性について検討を進めている。

3.2節で述べたように、渋滞抑制を行うためには短期的な予測だけでなく、長期的な予測も必要である。これらの渋滞予測の情報を提供した場合に、ドライバーが日時や経路を変更することで、時間的・空間的な交通流の分散を実現できると考えられる。その一方で、別の日時や経路に交通流が集中し、結果的に予測が外れることも考えられる。今後、このようなドライバーの行動変容を踏まえた渋滞予測にも、取り組んでいく。

謝辞

ここで述べた渋滞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

- 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, 9p. <https://www.meti.go.jp/shingikai/sankoshin/sangyo_gijutsu/chikyuu_kankyo/yakusoku_soan/pdf/005_07_00.pdf>, (参照 2020-08-17).
- 国土交通省道路局。“【施策-7】効果的な渋滞対策の推進”。平成17年度達成度報告書・平成18年度業績計画書。国土交通省, 2006, p.52-59. <<https://www.mlit.go.jp/road/ir/ir-perform/h18/07.pdf>>, (参照 2020-08-17).
- 国土技術研究センター。“交通マネジメントに活用する新たな技術の公募について”。ICT・AIを活用したエリア観光渋滞対策に資する新技術公募について。<http://www.jice.or.jp/new_tech2018.html>, (参照 2020-08-17).
- 塚田幸広。“ITSによる革新的な道路交通マネジメントの潮流”。平成25年度 国土技術政策総合研究所講演会講演集。東京, 2013-12, 国土交通省 国土技術政策総合研究所。国総研資料。2013, 759, p.85-108. <<http://www.nilim.go.jp/lab/bcg/siryou/tnn/tnn0759pdf/ks075911.pdf>>, (参照 2020-08-17).
- 大口 敬編。“交通渋滞”徹底解剖。初版, 交通工学研究会, 2005, 163p.
- 高度情報通信ネットワーク社会推進戦略本部・官民データ活用推進戦略会議。官民ITS構想・ロードマップ2019。首相官邸。2019, 129p. <<https://www.kantei.go.jp/jp/singi/it2/kettei/pdf/20190607/siryou9.pdf>>, (参照 2020-08-20).
- 国土交通省。“高速道路をめぐる状況について”。社会資本整備審議会第16回道路分科会。東京, 2017-08, 国土交通省, 2017, 資料4, 24p. <<https://www.mlit.go.jp/common/001202619.pdf>>, (参照 2020-08-20).
- 桑原雅夫。渋滞解消の秘策!—渋滞のメカニズムと対策。生産研究, 2007, 59, 5, p.452-466.



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.



青木 泰浩 AOKI Yasuhiro, 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
自動化・画像応用システム開発部
博士(情報科学)
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教授
Ph.D.
交通工学研究会・土木学会・国際交通安全学会会員
Tohoku University