

ETC2.0プローブデータを利用した 高速道の渋滞予測・交通異常検知技術

増田 淳基 松平 正樹
林 正博

現在OKIは、ETC (Electronic Toll Collection system) 2.0 プローブデータの収集、蓄積、処理などの道路管理システムを多数開発している。そして、次のステップとしてプローブデータを含む車両関係のデータを用いたさまざまな分析・予測技術を研究開発している。本稿では、プローブデータの概要を説明した後、開発技術である高速道路の渋滞予測技術・交通異常検知技術を紹介する。

従来の渋滞予測・交通異常検知技術

まず、従来の渋滞予測、交通異常検知技術について説明する。これまでの渋滞予測技術では、例えば交通量や速度情報により算出したIC(インターチェンジ)間の所要時間を用いて、渋滞を判別していた。また、交通異常検知技術では、交通量や交通密度(単位距離当たりの道路上の車両台数)などの交通状態の時間的・空間的変化の情報から検知していた。どちらも道路に設置されたトラフィックカウンター(以下、トラカン)などの定点観測機器から得られる情報を利用したものである。しかし、国内の地方路線では、トラカンはIC間に一つ程度であり、平均設置間隔が10km程度と長い場合、渋滞予測や交通異常の位置推定は高い精度が出せないという課題があった。そこで各車両の挙動データを取得可能なETC2.0プローブデータ(以下、プローブデータ)の活用が期待されている。

ETC2.0プローブデータ

プローブデータとは、図1¹⁾に示すように、ETC2.0対応の車載器に蓄積された車両の走行履歴、挙動履歴を指し、道路上に設置したアンテナを通過する際、基本情報とともにアップリンクされる。プローブデータには、取得時刻や位置のような車両ごとの情報が含まれている。例えば、縦軸に時刻、横軸に起点からの距離とし、記録時の速度を色に対応して、車両の履歴を描くと、一台一台のデータを見える化できる(図2)。西日本高速道路株式会社によると、高速道路に対する渋滞の定義は「時速40km以下で低速走行、あるいは停止発進を繰り返す車列が1km以上かつ

15分以上継続した状態²⁾とあり、図中の罫線内が渋滞の速度に相当する。図2から渋滞位置やその中で車両の動きを確認することができる。

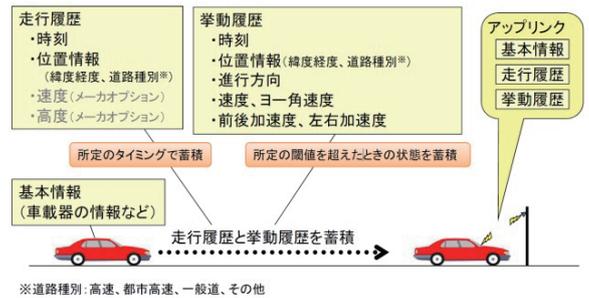


図1 ETC2.0 プローブ情報の概要
(出典 ITS シンポジウム 2018 発表論文¹⁾ より)

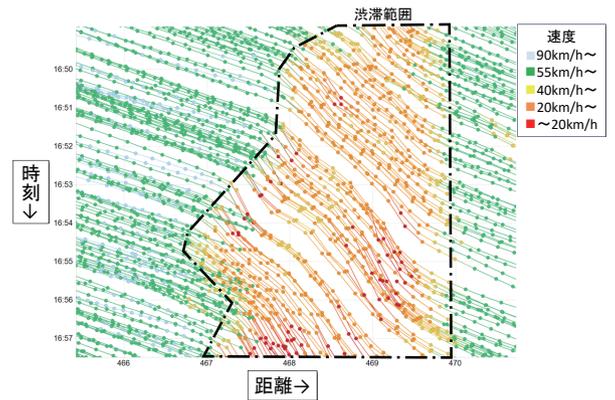


図2 プローブデータの走行履歴の表示例

渋滞予測技術

トラカンを利用した技術以外にも、渋滞予測を含む交通流予測の従来研究として、各車両の軌跡をシミュレーションする手法がある。その一つに、セルオートマトンと呼ばれる手法に確率的最適速度を加えたモデルで交通流をシミュレーションする手法が提案されている。³⁾ 車両1台分の大きさを表すセルと呼ばれる単位の空間内で、車両速度と前車両との位置関係から次時刻の移動先セルを決定するモデルである。しかし、解を求めるためにはすべての車両の交通流をシミュレーションする必要があり、数百キロに及

が高速道路での予測をするには大規模な計算環境が必要となる。

OKIでは、車両1台に相当するセルの代わりに、1分×100mの時空間メッシュをセルオートマトン方式の単位として使い、現時刻の交通密度変化から次時刻の交通密度を予測する技術を開発した。

図3に本予測技術の概要を示す。図の左側は交通密度を可視化した時空間図である。縦軸は1分刻み、横軸は起点からの距離100m刻み、色はそのメッシュの交通密度の高低を表す。例えば、渋滞の末尾付近では、進行方向に向かって速度が急激に低下するとともに、交通密度が急激に増加している状態である。渋滞末尾に流入する車両が多く、交通密度が臨界密度(渋滞が生じる交通密度の臨界点)より大きい場合、渋滞は進行方向に対して後方に延伸する。また、流入する車両が少なく、交通密度が臨界密度より小さい場合、渋滞は解消してゆき、交通末尾は渋滞先頭の方に縮む。

しかし、プローブデータには交通密度情報が含まれていない。そのため、このような交通密度の変化パターンと次時刻との関係を交通量と速度情報を持つトラカンデータとプローブデータを組み合わせることで学習する。以下、詳細を述べる。

交通工学では、交通密度と速度はKV曲線と呼ばれる関係になり、特に渋滞となる速度付近では指数関数で近似できることが知られている(Underwoodのモデル⁴⁾) (図4)。そこで、開発技術では蓄積したトラカンデータの交通量と速度から交通密度を算出し、そこからUnderwoodのモデル中のパラメーターを推定することでKV曲線の近似曲線を得る。この近似曲線の逆関数に任意の速度を与えれば、その地点の交通密度を推定できる。従って、道路区間上の全てのメッシュの交通密度は、蓄積したプローブデータの速

度をこの逆関数に与えることで推定できる。

次に、あるメッシュを起点に進行方向に数メッシュ区間をとり、その区間内の推定した交通密度の変化パターンと次時刻の関係を学習する(図3の右側。この場合は7メッシュ区間とした)。このようなメッシュ区間を全てのメッシュを起点に抽出し、得られた変化パターンをクラスタリングにより統合する。そして、統合されたパターンを予測モデルとして蓄積する。以上が予測モデルの学習になる。

次時刻の交通密度の予測をするには、車両の速度をもとに現時刻の交通密度を推定し、最も類似するパターンを予測モデルから探索し、予測値を算出する。

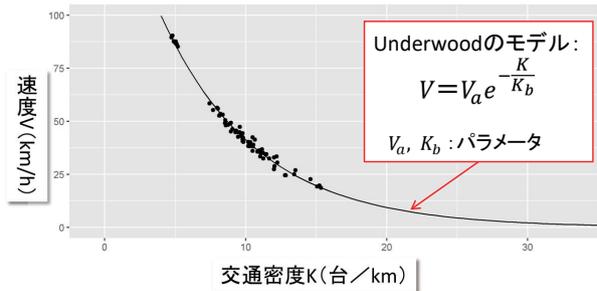


図4 KV曲線

この方式を用いて予測した交通密度から所要時間を算出した結果例を図5に示す。図では、渋滞区間の最後尾を通過した車両が先頭に到達するまでの所要時間の実測値(点線)と予測値(実線)をプロットしている。渋滞が発生していない場合に15分程度、渋滞が発生している場合に最大70分程度要する区間を高い精度で予測できている。また、渋滞の伸縮(所要時間、中央の区間)、渋滞のピーク(所要時間、上の区間)区間の結果から渋滞の状態変化も高い精度で予測できている。

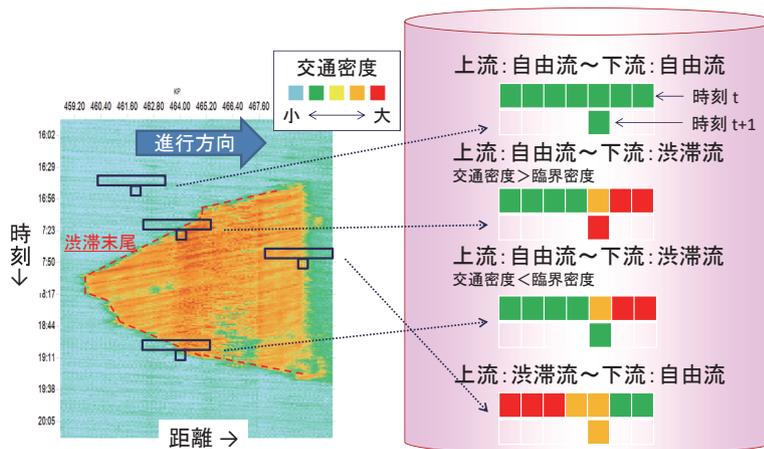


図3 学習パターンの概要図

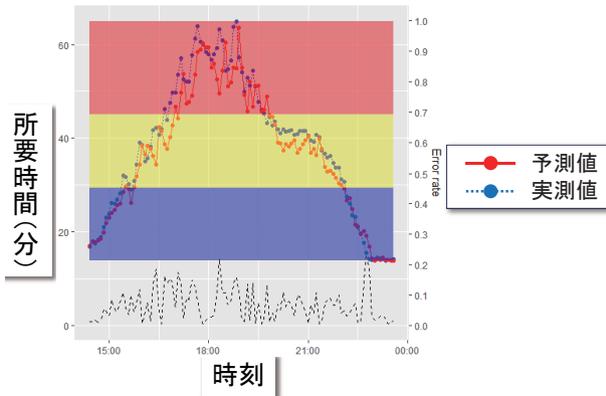


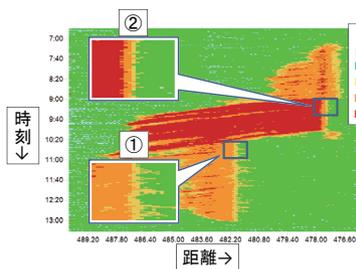
図5 所要時間予測結果

交通異常検知技術

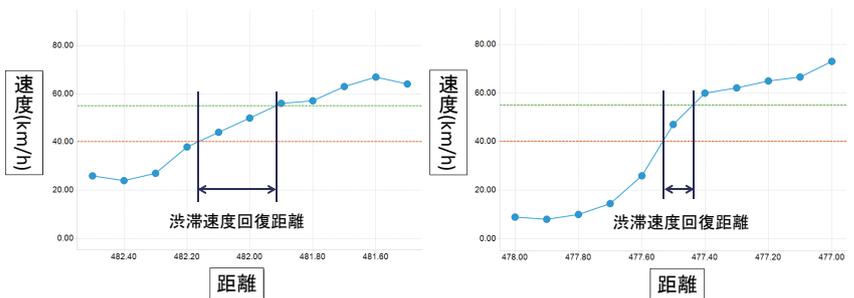
交通異常とは、「事故や路上障害物などの交通を遮断する可能性がある事象」を指し、平成29年に高速道路内の交通事故が8,758件、路上障害物が34.5万件発生している^{5), 6)}。しかし、道路管理者が交通異常を認知する現状の方法は、パトロールによる発見が通報によるものがほとんどである。高速道路内の交通異常は二次的な重大事故につながる可能性があるため、事象が発生した後に自動かつ早期に検知可能な技術開発が急務である。OKIではこの課題に対応するため、プローブデータから交通異常を自動検知する技術を開発した。

図6(a)に自然渋滞(図中の①)と交通異常渋滞(図中の②)の両方が発生したプローブデータの時空間図を示す。

自然渋滞は、登り坂や合流地点など自然な速度低下が慢性的に発生する地点で交通量が多くなることで発生する。そのため、渋滞の先頭位置はこのような地点に固定されることが図から確認できる。さらに、交通量が上昇すると、速度低下は先頭位置を変えずに徐々に進行方向に対して後方に伝わる。従って、渋滞の中を走行する車両の速度は渋滞先頭に近づくほど徐々に回復するものと推測できる。



(a) 時空間図



(b) 自然渋滞

(c) 交通異常渋滞

図6 渋滞速度回復距離の算出

一方、交通異常渋滞は先に述べたように、事故や路上障害物などの事象発生に起因する。これらの事象が起こると、走行車線が塞がれ、通行可能な交通量が大きく低下することで渋滞となる。この場合、速度低下の原因が異常発生位置にあるため、渋滞先頭である異常発生箇所を通過すれば、急な速度回復が生じる。

加速の様子は、図6(a)中の①、②に対する色の変化(=速度の変化)から確認できる。

以上のことから、自然渋滞と交通異常渋滞では渋滞先頭付近の速度回復の傾きが異なると推測できる。一例として、図6(a)の①、②に対する速度変化の状況をそれぞれ(b)、(c)に示す。この図からも推測どおりのことが起きていることが確認できる。

今回開発した技術では、プローブデータから得られる速度回復の指標として渋滞速度回復距離(以下、回復距離)を利用する。これは低速車列の先頭付近で、低速状態から高速状態になるまでに要する距離のことである。この回復距離を用いて異常検知の基本的な考え方を導入し、平常時の分布からの乖離度を算出することで異常を判定することとした。

まず、自然渋滞に対する回復距離を用いて、距離に応じた発生確率を平常時の分布モデルとして学習する。例えば、回復距離の頻度分布は図7のようになり、ガンマ分布としてモデル化する。

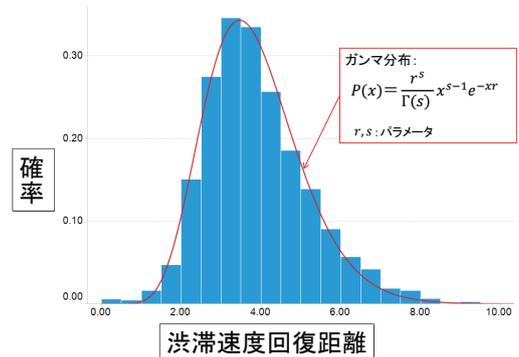


図7 ガンマ分布によるモデル化

各時刻に取得したプローブデータに対して、渋滞が発生している場合に、回復距離を算出し、その発生確率を、学習した平常時の分布から算出する。そして、観測した回復距離の発生確率が閾値未満の場合、統計的に自然渋滞ではほとんど発生しない速度回復として、交通異常と判定する。

本稿の精度評価は、管制センターで入力された37件の実際の交通異常を正解値として、異常発生位置から±500m以内の範囲を検知できるかどうかを確認する。指標には、正解率と再現率を用いる。正解率は本技術により交通異常と判定したもののうち、正しく交通異常だったものの割合(=正解した数/交通異常と判定した総数)を表す。一方、再現率は発生した交通異常の中でどれだけ正しく異常検知できたかという割合(=正解した数/検知対象である交通異常の総数)を表す。評価結果として、正解率が94.3%、再現率が89.2%という高い検知結果が得られた(表1)。しかし、運用面では正解率がより高いことが望ましいため、正解率を高めることが今後の課題である。

表1 異常検知精度評価

		真の結果		
		交通異常	非交通異常	正解率
予測結果	交通異常	33	2	94.3%
	非検知	4	—	—
	再現率	89.2%	—	—

まとめ

プローブデータを利用した渋滞予測と交通異常検知技術について述べた。各方式とも良好な結果が得られている。今後は、大型連休や気象の特異日など、更に多様な条件での検証を進めつつより精度の高い予測技術を開発していく予定である。

謝辞

本研究では、西日本高速道路株式会社様よりプローブデータをご提供いただいた。感謝いたします。◆◆

参考文献

- 1) 林泰士、松田奈緒子、瀧本真理、坂ノ上有紀、中田寛臣、瀬戸下伸介:ETC2.0 プローブ情報を活用した観光交通における渋滞対策の効果検証、ITSシンポジウム2018、2018年
- 2) 西日本高速道路株式会社:渋滞原因解説、https://www.w-nexco.co.jp/forecast/trafficjam_comment/

3) 西成活裕:交通の数理と渋滞学(<特集> 繋がりの科学)、人工知能学会誌 23(5)、631-637、2008年

4) Wang, Haizhong, et al. : Logistic modeling of the equilibrium speed-density relationship, Transportation research part A: policy and practice 45(6), 554-566, 2011.

5) 内閣府:平成30年交通安全白書、http://www8.cao.go.jp/koutu/taisaku/h30kou_haku/zenbun/genkyo/h1/h1b1s1_2.html

6) 国土交通省:高速道路会社の落下物処理件数(平成29年度)、http://www.mlit.go.jp/road/sisaku/ijikanri/pdf/h29rakkabutu_nexco.pdf

● 筆者紹介

増田淳基:Atsuki Masuda. 情報通信事業本部 IoTプラットフォーム事業部 IoTソリューション推進部

松平正樹:Masaki Matsudaira. 経営基盤本部 研究開発センター AI技術研究開発部

林正博:Masahiro Hayashi. 情報通信事業本部 IoTプラットフォーム事業部 IoTソリューション推進部

TiPO 【基本用語解説】

セルオートマトン

セルオートマトンとは、有限個の状態を持つ格子状のセルから構成され、離散的に時間経過させたとき、次時刻のセルの状態を現時刻の自身のセルと隣接するセルの状態によって決定するモデルのことである。

ガンマ分布

連続確率分布の一種である。形状と尺度に関するパラメータを持ち、確率変数が正の範囲で、左右非対称の確率分布を表現する。