ETC2.0 プローブデータを利用した交通異常検知 Traffic anomaly detection using ETC2.0 probe data

增田 淳基 Atsuki Masuda

松平 正樹 Masaki Matsudaira

沖電気工業株式会社 経営基盤本部 研究開発センター Corporate R&D Center, Corporate Infrastructure Group, Oki Electric Industry Co., Ltd.

Abstract: Detecting traffic anomalies such as accidents and obstacles on freeways is one of serious problem for traffic management. Previous researches are almost based on vehicle detectors to get traffic velocity and quantity, and therefore not able to detect the detailed location of traffic anomaly. In this paper, we present the algorithm for detecting automatically traffic anomalies using ETC2.0 probe data. Our algorithm is based on distances from head position of traffic congestion to recovered speed position, which is calculated from velocity of probe data. The result of evaluating the algorithm is very accurate, that precision is 94.3% and recall 89.2%.

1. はじめに

交通異常とは、事故や路上障害物等の交通を遮断する可能 性がある事象のことを指し、平成 29 年に高速道路における交 通事故が 8,758 件、路上障害物が 34.5 万件発生している[内閣 府 18]、[国土交通省 17]. しかし、道路管理者がそれら交通異 常を認知する方法は、パトロールカーによる発見か通報によるも 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早期に 検知可能な技術開発が急務となっている.

2. 関連研究

従来の交通異常検知は、道路に設置された車両感知器などの定点観測機器から得られる情報を利用するものが主流であり、 交通量や交通密度などの交通状態の時間的・空間的変化から 異常検知する手法が開発されている[Jeong 11], [成岡 14], [Chung 12]. 成岡らおよび Chung らは、車両感知器が 300~ 600m に一台設置されている首都高速道路で実証を行ない、数 百メートル単位で位置の検知が可能と報告している.また、 Jeong らは、車両検知器が多数設置されている米カリフォルニア の I-880 で実証している.一方、日本国内の地方路線では車両 感知器がインター間に1つ程度しか設置されておらず、平均間



図1 プローブデータ概念図



隔が 10km 程度であるため, 検知できてもその位置の特定が困難である.

3. データ特性

3.1 ETC2.0 プローブデータ

ETC2.0 プローブデータとは, ETC2.0 対応の車載器に走行 履歴, 挙動履歴を蓄積し, 道路上に設置したアンテナによって 収集する車両走行データである. データ内には各車両の GPS で測位した位置情報や速度,加速度等が含まれている(図 1) [瀬戸下 18]. 収集したプローブデータを縦軸に時刻,横軸に起 点からの距離(KP), プロットの色に速度を対応させて図示する と図 2のようになる. NEXCO 西日本によると,高速道路におけ 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」と あり,赤色(速度≦20km/h)およびオレンジ色(20km/h<速度≦ 40km/h)のプロットが渋滞の速度に相当する[NEXCO 西日本]. 一つの点が一つのプローブデータを表し,点を結んだ線が一 台の車両の走行軌跡を表している.

3.2 イベントデータ

イベントデータは、管制センターにおいて入力された事故, 路上障害物,工事,故障車,気象,交通規制などの事象に関 するデータである.事象の分類や発生時刻,発生地点(KP)な どが記録される.ただし、実際に発生した事象から、時間遅れが



図2 プローブデータ(各車両の走行履歴)





図3 自然渋滞と交通異常渋滞

生じている場合がある.

3.3 自然渋滞と交通異常渋滞

自然渋滞(交通集中渋滞)は、登り坂や合流地点など速度低 下が慢性的に発生する地点において、交通容量以上の交通量 が流入することにより、車両が停滞するために発生する. 渋滞の 原因となる場所が固定され、渋滞の先頭位置は変化しないこと から、速度低下は交通量の上昇とともに徐々に進行方向に対し て後方に伝播し、渋滞が伸びることになる.

一方,交通異常渋滞は,発生要因が事故や路上障害物などの事象発生にある.事象による走行車線の封鎖もしくは,交通 規制の影響によって車線が一部遮断され,通行可能な交通量 が大きく低下する

図 3に自然渋滞と交通異常渋滞が両方発生した渋滞図を示 す. なお, 図では, 時間・空間を 100m×1 分単位のメッシュに 区切り, メッシュ内に含まれるプローブデータの平均速度を算出 したデータを可視化している. 図の上部右側が交通異常渋滞で あり, 9:02 に 477.00KP で事故, 9:18 から 10:03 まで 477.00KP から 477.80KP にかけて車線規制(追越車線)が記録されている. 一方, 図の下部中央が自然渋滞である.

4. モデル化と学習

自然渋滞と交通異常渋滞では、渋滞先頭の速度変化パターンに違いが見られる。また、自然渋滞においても、「サグ部」と呼ばれる登り坂、インターチェンジやジャンクションなどの合流部、トンネル入口、インターチェンジ出口において発生することが知られており、それぞれ速度変化パターンに違いがあると考えら



図5 ガンマ分布によるモデル化

れる. さらに,登り坂でも勾配や距離,大型車の混入率によって も違いがあるだろう.しかしながら,それらの違いを変数としてモ デル化・学習するには,プローブデータが充分な量とは言い難 い.したがって,今回は自然渋滞を統合してモデル化することと した.

4.1 速度回復距離

速度変化パターンの指標として, 渋滞速度回復距離を利用した. これは低速車列の先頭付近において, 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. 一例として, 図 3の自然渋滞と交通異常渋滞での速度変化を図 4に示す. 距離の算出は, 100m メッシュの速度を線形補完し, 渋滞の定義速度である 40km/h の地点と速度が回復したと考えられる 55km/h の地点までの距離とした.

4.2 ガンマ分布によるモデル化

交通異常を検知するため、自然渋滞における渋滞速度回復 距離を用いて、距離に応じた発生確率をモデル化する.イベン トデータが記録されておらず、同じ地点(KP)で複数の日に発 生した一連の渋滞における各時刻の渋滞速度回復距離の頻度 分布は図 5のようになる.距離が正の値をとり、分布が左右非対 称であるという特徴から、確率モデルにガンマ分布を用いた.ガ ンマ分布の確率密度関数は以下の式(1)に示す通りである.ここ で、*s*が形状パラメータ、*r*がスケールパラメータであり、ともに正 の値をとる.頻度分布から、両方のパラメータについて、最小二 乗法により最も近似する解を学習する.





$$P(x) = \frac{r^s}{\Gamma(s)} x^{s \cdot 1} e^{-rx} \qquad \cdots (1)$$

4.3 交通異常検知

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, 過去数分の渋滞速度回復距離を算出し, 学習し た自然渋滞の分布の累積確率から, 同時生起確率を算出する. 同時生起確率が正規分布の 3 σ に相当する累積確率 (0.135%)未満の場合に, 交通異常と判定することとする. なお, なるべく遅延なく検知するため, 過去 2 分の渋滞速度回復距離 を使用する.

5. 検証実験

本アルゴリズムを R 言語で実装し, ETC2.0 プローブデータと イベントデータの実データを用いて, 検証実験を行なった.

5.1 実験データ

今回利用したデータは、NEXCO 西日本から提供いただいた 関西地区における複数路線のプローブデータとイベントデータ である.路線は、中国自動車道、名神高速道路、近畿自動車道 であり、2018年3月10日~3月26日、および、交通量が多い 特異日として2018年8月10日~8月15日(お盆期間)のデ ータ計48日分を検証に用いた.

5.2 実験手法

検知位置については、管制センターでの入力を正解値として 異常発生位置から±500m以内の範囲を検知できるかどうかの 精度を計算することとした.精度の指標は検知技術に対して一 般的に使われている Precision/Recall を用いた. Precision は 交通異常と判定したものに対する正解率(=正解した個数/交 通異常と判定した個数),Recall は発生した交通異常の中でど れだけ検知できたかという検知率(=正解した個数/検知対象 である交通異常の個数)を表す.検知結果が上記誤差範囲内 かどうかによって Precision/Recall を算出する.

また、検知時刻については、管制センターの入力であるイベントデータと比較を行った.イベントデータは、通報やパトロールカーによる発見に基づいており、図 6のように実際に何らかの交通異常により交通状態が変化している時刻よりも遅れて入力されていることがある.これと比べて早期検知できるかどうかを検証した.

5.3 検証結果

検知位置に関する精度結果を表 1に示す. Precision が 94.3%, Recall が 89.2%と, ともに高水準の結果が得られた. 検知例を図 7 (a)~(c)に示す. (a)の正解例では, イベントデ



図6 イベントデータの時刻遅れ

表1 異常検知精度評価

		真の結果		
		交通異常	非交通異常	Precision
予測結果	交通異常	33	2	94.3%
	非検知	4	—	-
	Recall	89.2%	—	_

ータによる交通異常発生箇所の+100m を検知しており,時間 に関しても手入力よりも 1 分早く検知することができた.(b)は交 通異常に関する事象が発生しているが非検知であった 4 件の 内の一つを示している.このデータは,図では交通異常発生地 点は一か所になっているが,同じ KP,同じ時刻において故障 車と路上障害物の事象がイベントデータに含まれている.複数 の交通異常が重なり,急加速ができなく,渋滞速度回復距離が 長くなったため検知できなかったと考えられる.(c)はイベントデ ータが存在しない位置に対して交通異常判定をした例である. 検知地点付近の速度は 40km/h から 55km/h ~ 100m ほどの距 離で加速しており,交通異常と似た傾向が表れている.また,同 じ KP で他の時間帯を見ても,検知付近の交通状態が特異で ある点から,交通異常はあったがイベントデータに記録されてい ない可能性も考えられる.

検知時刻に関しては、イベントデータの入力時刻と異常検知 時刻の時間差を評価した.両者の時間差をボックスプロットで表 したものを図 8に示す.縦軸は時間差を表しており、マイナスが ETC2.0 プローブデータを利用した方式による早期検知を意味 している.結果から、中央値が0となり、半数が早期検知可能で あった.一方で、大幅に検知遅れとなる場合もいくつか存在した. これは、ETC2.0 プローブデータに異常値が含まれていたため、 渋滞速度回復距離が正しく算出できないことに起因している. 今後、データに含まれる異常値のクレンジングや手法の頑健性 も重要な課題である.

5.4 まとめ

高速道路内の異常を早期発見したいという社会課題と従来 技術での高精度な位置特定が困難であるという課題に対して, ETC2.0 プローブデータを利用して渋滞先頭における渋滞速度 回復距離により交通異常を検知するアルゴリズムを開発した. 検知位置による精度評価では良好な結果を得ており,本方式 が有効であることを示した.

今後,自然渋滞の原因を含めたモデル学習・検知手法の開発や,渋滞を伴わない交通異常を検知する方式の開発に取り 組む予定である.

謝辞

本研究において, NEXCO 西日本様より ETC2.0 プローブデ ータおよびイベントデータを提供いただいた. ここに感謝の意を 表す.

参考文献

[内閣府 18] 内閣府: 平成 30 年交通安全白書,

http://www8.cao.go.jp/koutu/taisaku/h30kou_haku/zenbun/genkyo/h 1/h1b1s1_2.html. [国土交通省 17] 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.p df.

- [NEXCO 西日本] NEXCO 西日本: 渋滞原因解説, https://www.w-nexco.co.jp/forecast/trafficjam comment/.
- [Chung 98] Chung, E., and Kuwahara M.: Comparative study of freeway incident detection algorithms, ARRB TRANSPORT RESEARCH LTD CONFERENCE, 19TH, 1998.
- [Jeong 11] Jeong, Y.S., et al.: A wavelet-based freeway incident detection algorithm with adapting threshold parameters, Transportation Research Part C: Emerging Technologies 19.1, 2011.
- [成岡 14] 成岡尚哉, et al.: ノンパラメトリック手法による車両感知器デー タからの突発的ボトルネック検出法, 交通工学論文集 1.1, 2014.
- [瀬戸下 18] 瀬戸下伸介, et al.: ETC2.0 プローブ情報の収集と活用,国総研レポート 2018, 2018.



図8 イベントデータと検知時刻の時間差



(a) 正解例 (中国自動車道下り 2018 年 8 月 10 日)



(b) 検知漏れ例 (中国自動車道下り 2018 年 3 月 16 日)



(c) 誤検知例 (中国自動車道下り 2018 年 8 月 11 日)

図7 検知結果