

(27) ベイジアンネットワークを用いた 都市内高速道路における 突発事象検知モデルの構築

野村 大智¹・西内 裕晶²・轟 朝幸³・川崎 智也⁴・割田 博⁵

¹学生会員 日本大学大学院 社会交通工学専攻 (〒274-8501 千葉県船橋市習志野台7-24-1 744号室)

E-mail:csda14017@g.nihon-u.ac.jp

²正会員 長岡技術科学大学助教 環境・建設系 (〒940-2188 新潟県長岡市上富岡町1603-1 367号室)

E-mail:nishiuchi@vos.nagaokaut.ac.jp

³正会員 日本大学教授 交通システム工学科 (〒274-8501 千葉県船橋市習志野台7-24-1 744号室)

E-mail:todoroki.tomoyuki@nihon-u.ac.jp

⁴正会員 日本大学助教 交通システム工学科 (〒274-8501 千葉県船橋市習志野台7-24-1 744号室)

E-mail:kawasaki.tomoya@nihon-u.ac.jp

⁵正会員 首都高速道路株式会社 (〒100-8930 東京都千代田区霞が関1-4-1)

E-mail:h.warita1116@shutoko.jp

本研究では、首都高速道路から得られる交通情報を用いて、ベイジアンネットワークにより突発事象検知モデルを構築し、過去に筆者らが首都高速道路4号線を対象として構築したモデルを他路線へ適用させ汎用性を確認した。さらに、既存研究との突発事象検知精度の比較を行った。具体的には、既存研究と同様の首都高速道路6号線、7号線、中央環状線、川口線の合計4路線を本研究での新たな対象路線とし、構築したモデルの汎用性の確認を行った。また、モデルを構築する際には車両感知器より得られる交通量、速度、占有率などのデータを離散化する必要があり、路線により適した離散化方法が異なることを確認した。そして、突発事象検知精度を確認するために、既存研究により行われた複数の手法による突発事象検知モデルとの比較も行った。

Key Words : Incident Detection, Bayesian Network, Urban Expressway, Traffic Control

1. はじめに

都市内高速道路では、安全かつ円滑な交通管理や利用者への正確な交通状況の情報提供を目指し、リアルタイムな交通流シミュレーションなどの交通管制システムにより、数時間先の交通状況予測が行われている^{1) 2)}。しかしながら、現在の交通管制システムの事故などによる突発事象の検知率は低く、交通管制官らの経験に基づいて意思決定し、突発事象の検知をしているのが実情である。

突発事象を検知する研究は、様々な角度により行われている。例えば、高速道路上に設置されているカメラ映像を用いて画像処理を行うことにより突発事象を検知する手法^{3) ~5)}や車載GPSセンサーからリアルタイムな車の走行データが得られるプローブカーデータを用いて突発事象を検知する手法^{6) 7)}等がある。画像処理による突

発事象の検知では、突発事象の検知に優れているが、夜間ではヘッドライト等の照度変化の影響により車両を誤検知し、カメラを多量に設置するため、コスト面でも問題が生じる。プローブカーデータの場合、カメラや車両感知器を設置し維持する必要がなく、低コストで広範囲のデータが得られるというメリットがある。しかし、交通状態が頻繁に変化するような都心に近い出入口の多い区間では、データが疎になってしまうため、プローブカーデータでは検知が困難になってしまう。そして、多くの研究では高速道路上の車両感知器より得られる交通量や速度等のデータを用いて突発事象を検知する手法^{8) ~11)}がある。車両感知器を用いた場合、昼夜問わず正確にデータを取得することが可能であり、交通状態が頻繁に変化するような地点でも都市内の高速道路においては車両感知器が密に設置されているため、対応できると考えられる。

またフセインら¹²⁾は、リアルタイムに突発事象を検知するためにベイジアンネットワークを用いてモデル構築を行い、Zhangら¹³⁾や西内ら¹⁴⁾もオーストラリアの高速道路や首都高速道路を対象とし、検知対象区間で発生した突発事象を前後の交通状況から自動で検知する仕組みをベイジアンネットワークより構築している。

そこで本研究は、昼夜問わず正確にデータを取得することが可能な車両感知器データを用いて、リアルタイムに突発事象を検知し突発事象後の交通状況がどのように変化するのかも出力することが可能であるベイジアンネットワークによりモデルを構築する。

本研究の目的は、過去に首都高速道路4号線を対象として構築したモデルを他路線に適用することで、モデルの汎用性を確認する。また、新たな対象路線をChungら⁹⁾の研究と同様の首都高速道路6号線、7号線、中央環状線、川口線の4路線とすることで、Chungらが構築した交通事故検知に関する複数の手法との比較を行い、本研究で構築したモデルの実用性を確認する。他路線へのモデルの汎用性が確認できることにより、全ての路線で突発事象の検知が可能であることを実証することができるため、突発事象発生後の処理対応の高速化が期待される。

2. 研究の方法

本研究で提案する突発事象検知モデルは、ベイジアンネットワークを用いてモデル構築を行う。ベイジアンネットワークとは、複数の確率変数間の定性的な依存関係をグラフ構造で表し、個々の変数間の定量的な関係を条件付き確率で表す確率モデルである。条件付き確率の分布は、蓄積されたデータの学習により推定される。本研究では、Zhangらや西内らの構造を参考に交通量、速度、占有率などの変数を図-1のようなネットワーク構造とした。

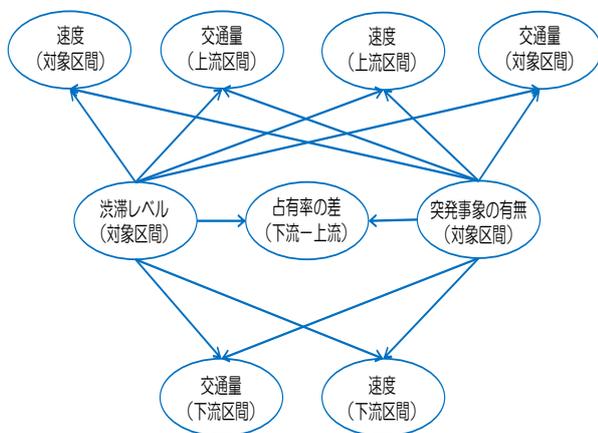


図-1 突発事象検知モデルの構造

3. 研究対象路線と使用データ

本研究では、Chungらの研究と同様に、首都高速道路6号線、7号線、中央環状線、川口線の各上り線を対象として構築したモデルの検知率の比較を行った。

使用データとして、2006年6月1日から2007年3月31日に記録された車両感知器データと交通管制官が手動で入力した突発事象の有無のデータを用いる。車両感知器データは、交通量、速度、占有率などの交通情報データが5分刻みで記録されている。ベイジアンネットワークにて突発事象の発生確率を推定するための学習用データは、2006年6月1日から2007年3月21日までに収集されたデータを用い、2007年3月22日から3月31日までのデータを構築したモデルの精度検証用データとした。

4. モデルの構築と精度の検証

(1) モデル構築に用いるデータについて

ベイジアンネットワークによりモデルを構築する際、前処理として入力データを離散化する必要がある。しかしながら、その組み合わせ数は膨大である。よって、本研究では、交通量、速度、占有率について、平均値から標準偏差ごとに区分されるような離散化など、多面的な方法により8パターンを試みた。

また、データからは検知対象区間以外で発生した突発事象を原因とする渋滞や検知対象区間で発生した突発事象を原因とする渋滞などが把握できる。しかし、検知対象区間以外で発生した突発事象を原因とする渋滞は、現象として自然渋滞と特徴が同じであるため、検知対象区間の上下流区間の違いを参考にする本モデルでは、その検知が困難である。そこで本研究では、検知対象区間で発生した突発事象を検知対象とする。これは、検知対象区間をボトルネックとする突発事象が発生した際に、その上下流区間における交通状況の差異が大きくなると考えたためである。

さらに、本研究でも過去の筆者らの研究と同様にモデルによる検知対象の突発事象を事故のみではなく、故障車や道路障害物などの事象も検知対象事象とした。ここで、事象のデータからは工事も含まれているが、工事を行うことを交通管制官らは事前に把握しているものと考え、検知対象外とした。

(2) 本研究で用いた離散化方法

表-1に、本研究で用いた各離散化方法を示す。パターンAとパターンBは平均値から $\pm 3\sigma$ までを σ ごとに区分する離散化方法で、パターンCは各離散値を等量に分割した離散化方法である。パターンDとパターンEはそれ

ぞれフセインらと西内らの離散化方法を再現した。パターンFは西内らの離散化方法を参考に交通量、速度、占有率の各変数をそれぞれ異なる離散値で区分した離散化方法であり、パターンGは離散値の値が高い領域をさらに詳細に区分し、パターンHは離散値の値が低い領域をさらに詳細に区分した離散化方法である。

表-2は、本研究での対象路線に最も適した離散化パターンを示したものである。参考に過去に筆者らが行った4号線に最も適した離散化パターンも示した。6号線では4パターンの離散化方法が、7号線では2パターンの離散化方法がそれぞれ同様の検知率となったが、各路線毎に適した離散化方法が異なることが明らかとなった。

(3) 精度の検証

表-3は、本研究で構築したベイジアンネットワークへモデル精度検証用データを用いて、突発事象による交通渋滞が発生した件数を予測した結果である。7号線と川口線の検知率が低いことが分かるが、主な原因として学習用データと検証用データのそれぞれで突発事象発生時の交通状況が異なり、検知が困難になったものと考えられる。具体的には、例えば川口線の学習用データ内の突発事象発生時の交通状況は上流・対象・下流の各区分で差異は生じていないが、検証用データ内の突発事象発生時の交通状況は、上下流の区分で差異が生じるような本

来検知しようとする突発事象が発生している。このような場合の学習用データ内の突発事象要因として、事故が多く見られ、検知対象区間の上流区間まで渋滞流が延伸しないような自損事故等が考えられる。また、各区分の検証用データ内の突発事象発生件数が少なく、突発事象時の交通状況のサンプル数が十分に得られなかったことも考えられる。

表-4では、検知状況を確認するためにChungらが行った研究成果と比較する。なお、Chungらの研究では、交通事故件数そのものを検知しており、本研究で提案したベイジアンネットワークによる突発事象を原因とする渋滞流発生時間帯の件数とは異なる。Chungらが行った交通事故検知の結果は、カリフォルニアアルゴリズムと呼ばれる手法が最も高い62.5%となっている。6号線の場合、突発事象発生件数が少ないもののChungらの研究よりも検知精度を向上させることができた。しかし、路線においては最も低い検知率で約31.5%であるため、検知精度を上げるための検討が必要である。

また、路線によっては平均して約10分程度の検知遅れが発生している。これは、突発事象発生直後とその直前の交通状況に変化が見られず、モデルが突発事象発生状況であると判断できないためと考えられ、検知率を下げる原因となっている。さらに、突発事象が発生していないにも関わらず突発事象発生状況であるとモデルが誤検知するケースがある。本研究の最も検知率の高い6号線を対象とした時の4パターンの離散化方法の平均誤検知率は約5.4%となった。参考程度ではあるが、Chungらが構築した最も検知率の高いカリフォルニアアルゴリズム手法での誤検知率は7.2%であり、Chungらの研究よりも誤検知率を低くすることができた。しかし、離散化の方法により誤検知率が高くなる場合があるため、これらも検討する必要がある。

表-1 離散化のパターン

離散化のパターン	概要
パターンA	平均値から標準偏差ごとに離散化 (7区分)
パターンB	平均値から標準偏差ごとに離散化 (13区分)
パターンC	等量に分割して離散化 (10区分)
パターンD	フセインらを参考にした離散化 (8区分)
パターンE	西内らを参考にした離散化 (6区分)
パターンF	パターンEを参考に各変数で異なる離散化 (7区分)
パターンG	パターンFを改良した離散化 (8区分)
パターンH	パターンFを改良した離散化 (8区分)

表-2 各路線に適した離散化方法

路線	離散化のパターン
6号線	A, B, F, G
7号線	F, H
中央環状線	A
川口線	C
4号線	B

表-3 事象状態検知精度

路線	事象状況発生件数	事象状態検知件数	検知率
6号線	37件	25件	67.6%
7号線	54件	17件	31.5%
中央環状線	113件	54件	54.0%
川口線	164件	52件	31.7%

表-4 Chungらによる突発事象検知精度

モデル	交通事故検知率
カリフォルニアアルゴリズム	62.5%
UCパークレーアルゴリズム	37.5%
首都高速道路アルゴリズム	41.7%
ニューラルネットワーク	50.0%

5. おわりに

本研究では、ベイジアンネットワークによりモデルを構築をする際に必要となる離散化を8パターン考察し新路線への適用を試みた。その結果、路線により突発事象発生件数は異なるが、6号線で約67.6%と最も高い検知率となり、Chungらのカリフォルニアアルゴリズムよりも高い検知率となった。しかし、他路線では、最も検知率の低い路線で約31.5%となったため、離散化による検討がさらに必要なことも明らかとなった。

さらに、突発事象の要因によって、突発事象発生時の交通状況が異なることも把握することができ、突発事象をそれぞれ要因ごとに分類して、モデルの構築をする必要がある。

参考文献

- 1) 有田公也, 鎌田譲治, 伊藤功, 織田利彦, 飯田英明: 交通流予測アルゴリズム, National Toxicology Program, Vol.34, No.4, pp.429-437, 1988.
- 2) 白石智良, 桑原雅夫, 堀口良太: リアルタイム予測交通流シミュレーションシステムの開発, 土木計画学研究・講演集, 第30回, CD-ROM, 2004.
- 3) 原田将弘, 上条俊介, 坂内正夫: リアルタイム交通事故検出システム, 画像センシングシンポジウム講演論文集, Vol.9, pp.233-238, 2003.
- 4) 牧野正吉, 中村高宏, 谷口博康, 山本貴幸: 突発事象検知システム, 三菱電機技報, Vol.36, No.12, pp.78-83, 1993.
- 5) 柘植章英, 相馬裕明: 阪神高速道路の突発事象検知システム, 高速道路と自動車, Vol.36, No.1, pp51-58, 1998.
- 6) 牛木隆匡, 日下部貴彦, Nguyen Xuan Long, 朝倉康夫: 交通容量低下を考慮したプローブカーデータによる突発事象検出手法, 土木計画学研究発表会・講演集, Vol.48, CD-ROM, 2013.
- 7) 赤塚裕人, 高須淳宏, 安達淳: プローブカーデータを用いた自動交通異常検出, IEICE Technical Report, Vol.12, No.17-21.23-28, pp.13-28, 2012.
- 8) 大江巖, 川嶋弘尚, 児島正裕, 金子幸弘: ニューラルネットワークを用いた突発事象検出について, 交通工学研究発表会論文集, Vol.14, pp.37-40, 1994.
- 9) Edward Chung, 桑原雅夫, 吉井稔雄: Comparactive Study of Freeway Incident Detection Algorithms Using Real-Life Incident Data, 生産研究, Vol.50, No.9, pp.47-50, 1998.
- 10) Daehyon Kim, Seungjae Lee: Incident Detection Using A Fuzzy-Based Neural Network Model, Journal of Eastern Asia Society for Transportation Studies, Vol.6, pp.2629-2638, 2005.
- 11) Dao Jun Ye, William H. K. Lam, Mei Lam Tam: Automatic Incident Detection for Urban Roads in Hong Kong, Journal of Eastern Asia Society for Transportation Studies, Vol.9, 2005.
- 12) モイヌル フセイン, 室町泰徳: ベイジアンネットワークによるリアルタイム交通事故予測モデルの開発, 交通工学, Vol.47, No.2, pp.39-44, 2012.
- 13) Kun Zhang, Michael A. P. Taylor: Towards Universal Freeway Incident Detection Algorithms, Transportation Research Part C, Vol.14, No.2, pp.68-80, 2006.
- 14) 西内裕晶, 割田博, 都市内高速道路における交通現象診断モデル構築のための基礎的検討, 土木計画学研究・講演集, Vol.47, CD-ROM, 2013.