

# 検知遅れの解消を目指した ベイジアンネットワークによる 突発事象検知モデルの構築

野村 大智<sup>1</sup>・西内 裕晶<sup>2</sup>・轟 朝幸<sup>3</sup>・川崎 智也<sup>4</sup>・割田 博<sup>5</sup>

<sup>1</sup>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

<sup>2</sup>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

<sup>3</sup>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:tdoroki.tomoyuki@nihon-u.ac.jp

<sup>4</sup>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

<sup>5</sup>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、車両感知器から得られる交通情報を用いて、首都高速道路6号線、7号線、中央環状線、川口線の4路線を対象として、過去に筆者らが構築したベイジアンネットワークによる突発事象検知モデルの精度向上の検討を行った。新たに考慮した変数は、交通量などの5分前の交通情報、上流部の観測区間、下流部の観測区間である。その結果、各変数を考慮することで路線により結果は異なるが、全路線平均して6%であった誤検知率が、最大で約5%増加した。しかし、正検知率は最も良いモデルで約20%精度が向上し、平均約13分の検知遅れが解消することを明らかとした。各変数を考慮することで、突発事象の検知が容易となったが、突発事象発生状況と似た現象である自然渋滞等を突発事象と判断し、誤検知率が高まったと考えられ、これらの詳細な考察を行った。

**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<sup>1) 2)</sup>。しかしながら、現在の交通管制システムの事故などの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突発事象検知をしているのが実情である。

突発事象の検知に関する研究は、様々な視点から行われている。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突発事象を検知する手法<sup>3) ~5)</sup> や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<sup>6) 7)</sup> 等がある。カメラ映像を用いた突発事象の検知では、突発事象の検知に優れているが、夜間のヘッドライト等の照度変化の影響により車両を誤検知するなどの問題が生じ、プローブカーデ

ータでは、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、突発事象の検知が困難となる。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から突発事象を検知する手法<sup>8) ~11)</sup> が用いられている。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都市内高速道路においても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<sup>12)</sup> 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<sup>13)</sup> や西内ら<sup>14)</sup> 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。

さらに突発事象を検知する際、突発事象の検知遅れについて考慮している研究は少ないが、検知遅れは正検知

率を下げる要因であり、突発事象をリアルタイムで検知することが課題である。尚且つ突発事象を検知する際、突発事象が発生していないにも関わらず、モデルが突発事象発生状況であると誤検知するケースがあり、これらを考慮することは実務においても重要な事柄である。

そこで本研究では、首都高速道路6号線、7号線、中央環状線、川口線の4路線を対象として事前の交通量や速度などの交通情報といった新規変数を考慮した場合の正検知率や突発事象の検知遅れ、誤検知率の詳細を確認し、構築したモデルの精緻化を図ることを目的とする。具体的には、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。正検知率だけでなく、検知遅れや誤検知率も考慮したモデルを構築することによって、正確に突発事象の検知を可能とすることができるため、突発事象発生後の処理対応を高速化でき、利用者へより正確な交通状況の情報提供が期待できる。

## 2. 研究の方法

本研究では、ベイジアンネットワークを用いて突発事象検知モデルの構築を行う。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<sup>13)</sup>や西内ら<sup>14)</sup>が構築したベイジアンネットワークのモデル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。

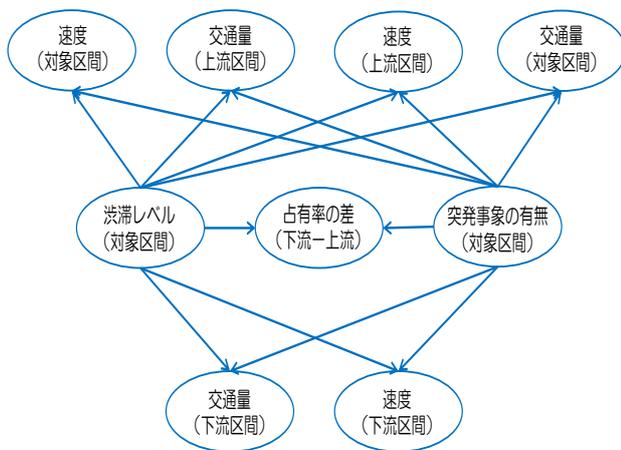


図-1 突発事象検知モデルの構造

## 3. 研究対象路線と使用データ

本研究では、過去に筆者らが行った対象路線と同様に、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新規変数を考慮し、モデルの精度を検証した。

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より得られた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、多面的な方法により8パターンの離散化を行い、その離散化方法を表-1に示した。パターンAとパターンBは平均値から $\pm 3\sigma$ までを $\sigma$ 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-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)

また、車両感知器データと管制官による手動入力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と本モデルでは、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。突発事象のデータに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) 本研究で構築したモデルと精度の検証

本研究では、新たに事前の交通情報、上流部の観測区間、下流部の観測区間をそれぞれ新たに考慮した。事前の交通情報を考慮した場合は、検知対象時間帯の5分前の交通量や速度などの交通情報をモデルに追加したモデルである。また、上流部の観測区間を考慮した場合は、検知対象区間の上流部の観測区間を1区間から2区間とし、上流部の観測区間を追加することである。これは、検知対象区間でボトルネックとなり延伸する渋滞現象を捉えることを試みた。下流部の観測区間を考慮した場合についても同様で、下流部の観測区間を1区間から2区間とし、下流部の観測区間を追加した。これは、速度差などが発生しにくい渋滞発生時の追突事故などを再現するためである。具体的には、交通流が流れている中、下流部の区間で渋滞流が徐々に発生し、それがショックウェーブとなり上流部および検知対象区間に伝搬する。その際、追突事故などの突発事象が発生したと考え、下流部の2区間の速度差を考慮することで追突事故などが発生する状態を再現した。

表-2に、筆者らが過去に構築したベイジアンネットワーク

表-2 変数考慮前の突発事象状態検知精度

路線	離散化	事象状況発生件数	事象状態検知件数	正検知率
6号線	A	37	25	67.6%
	B	37	25	67.6%
	F	37	25	67.6%
	G	37	25	67.6%
7号線	F	54	17	31.5%
	H	54	17	31.5%
中央環状線	A	113	54	54.0%
川口線	C	164	52	31.7%

表-3 変数考慮後の突発事象状態検知精度

路線	離散化	事前の交通状況	上流部2区間	下流部2区間
6号線	A	73.0%	67.6%	60.0%
	B	67.6%	67.6%	60.0%
	F	67.6%	67.6%	55.0%
	G	62.2%	64.9%	55.0%
7号線	F	38.9%	37.0%	0.0%
	H	35.2%	31.5%	0.0%
中央環状線	A	56.6%	75.2%	64.6%
川口線	C	45.7%	42.7%	53.5%

ワーク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り、離散化のパターン、事象状況発生件数と事象状態検知件数を示す。また表-2は、本研究で用いた離散化方法を示している。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。

表-3は、各路線に新規変数を考慮した場合の正検知率を示したものである。6号線と7号線では事前の交通情報を加えた場合に検知率の向上が見られ、中央環状線と川口線ではそれぞれ上流部と下流部の観測区間を考慮した場合に正検知率が向上した。7号線の下流部を2区間とした場合の正検知率が0.0%となっているが、これは検知対象区間の交通状況が渋滞発生中の事故発生とデータから判断でき、速度差などに差異がほぼ生じていないため検知できなかったと考える。その対応策として下流部を2区間としたが、検知できていないため離散化をさらに詳細に区分することによって、渋滞発生時の微小な差異を検出することが可能になるのではないかと考えられる。

## (3) 検知遅れと誤検知率

表-4に、各路線の平均検知遅れ時間の発生状況と新規変数考慮後の平均検知遅れ時間を示した。検知遅れとは突発事象発生開始からモデルが事象状況であると判断するまでに発生した時間である。6号線には検知遅れは無く、中央環状線では平均75分と最も検知遅れが発生している。また、下流部の観測区間を考慮する際、7号線と川口線については、考慮するはずの下流部の区間が別路線となるため、そのような対象区間においては検証対象外とした。そのため、7号線では検知対象区間に検知遅れは無くなり、川口線では新規変数を考慮する前の平

表-4 各路線の検知遅れ発生状況

路線	離散化	変数追加前	事前の交通状況追加	上流部追加	下流部追加
6号線	A	-	-	-	-
	B	-	-	-	-
	F	-	-	-	-
	G	-	-	-	-
7号線	F	10分	7.5分	8.8分	検証区間無
	H	8.3分	6.6分	5分	検証区間無
中央環状線	A	75分	75分	0分	35分
川口線	C	38.8分	6.3分	15分	23.3分(21.7分)

均検知遅れ時間が21.7分となり、下流部の観測区間を考慮すると、検知遅れは23.3分と1.6分の増加となった。各路線で検知遅れを減少させることに成功しているが、特に川口線に事前の交通情報を考慮した場合、大きく検知遅れが減少している。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なかったが、交通流や速度などの事前の交通情報を加えることによって、突発事象発生直後とその直前の交通状況に差異を生じさせることができたためと考えられる。中央環状線では、上流部の観測区間を考慮した場合、検知遅れを解消させることに成功しており、その際の正検知率も向上させることができていたため、ボトルネックとなる検知対象区間からの渋滞延伸の現象をモデルが捉えることができたからと言える。以上の点から、これら検知遅れが減少することにより、正検知率は向上することが明らかとなった。

表-5では、Chungら<sup>9)</sup>が構築した最も検知精度が高いカリフォルニアアルゴリズム手法を用いた場合の誤検知率と本研究の各路線の誤検知率を示している。Chungらは本研究と同様の首都高速道路6号線、7号線、中央環状線、川口線を対象とし、複数の手法により交通事故検知に関する研究を行っており、参考程度の数値ではあるが比較を行った。また、複数の手法の中で最も事故検知率が高かった手法はカリフォルニアアルゴリズムと呼ばれる手法で、62.5%の事故検知率となっている。そして、本研究での誤検知率とは、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したケースのことで、突発事象が発生していない平常時件数と突発事象発生状況であるとモデルが判断した件数との割合を示している。各変数を考慮した際、表-3に示した正検知率と比較すると、正検知率の増減に関係なく全ての区間で誤検知率が変数考慮前よりも増加しており、下流部を考慮した場合、特に誤検知率が増加傾向に見られることが分かった。ここで、中央環状線では、変数を考慮してもChungらの研究や変数考慮前よりも誤検知率を抑えつつ、正検知率を向上させることに成功している。特に上流部の観測区間を考慮した場合に、正検知率は大きく向上しているにも関わらず、誤検知率はわずかに0.3%の増加に留まっている。これは、中央環状線の突発事象発生状況として自然渋滞等が発生しにくく、平常時と突

表-5 各路線の誤検知率

路線	離散化	変数追加前	事前の交通状況追加	上流部追加	下流部追加
Chungら	-	7.2%	-	-	-
6号線	A	3.6%	4.6%	3.6%	5.8%
	B	5.7%	7.7%	7.3%	8.4%
	F	6.1%	8.4%	7.4%	9.2%
	G	6.2%	6.2%	7.8%	10.0%
7号線	F	6.9%	11.9%	7.9%	9.3%
	H	6.9%	11.1%	9.0%	9.0%
中央環状線	A	3.8%	4.4%	4.1%	4.4%
川口線	C	5.5%	7.0%	6.7%	7.9%

発事象発生状況とで明確な差が生じたためと考えられる。しかし7号線においては、誤検知率が最大で5.0%増加している。これは突発事象を起因としない自然渋滞等がなんらかの原因により検知対象区間より発生し、そのような自然渋滞が突発事象発生状況と類似していたケースとなり、誤検知率を高める原因になったと考える。

## 5. おわりに

本研究では、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、新たに交通量などの5分前の交通情報、上流部、下流部の観測区間を考慮した際の正検知率、検知遅れ、誤検知率の考察を行った。その結果、離散化方法によっても異なるが、ほとんどの路線で新たな変数を考慮することによって、正検知率が最も良いモデルで約75.2%と向上させることができた。検知遅れも最大で0分と改善させることができた。しかし、それに伴い誤検知率が増加することも明らかにした。これは、突発事象発生状況と平常時に発生する自然渋滞等が似た現象であり、そのような自然渋滞等を突発事象発生とモデルが誤検知するケースが増えることによって、誤検知率も増加したと考えられる。

今後は、より高い精度で突発事象を検知しつつも検知遅れや誤検知率を少なくさせるベイジアンネットワークモデルを構築するために、突発事象発生時の交通状況を各路線ごとで詳細に把握し、それに適した離散化、考慮する変数等をさらに検討していく必要がある。また、平常時に発生する自然渋滞等を突発事象とモデルが判断するケースが誤検知率を高めている原因となるため、突発事象発生状況と自然渋滞等を判別するための検討もモデルを精緻化していく上で重要な検討事項となる。

## 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.