

取締り活動と事故リスクの時間的・空間的変動 を考慮した事故予測モデルに関する研究

田中 秀人¹・寺奥 淳²・島田 大輔³・森本 章倫⁴

¹正会員 パシフィックコンサルタンツ株式会社（〒101-8462 東京都千代田区神田錦町3-22）

E-mail : shuuto.tanaka@tk.pacific.co.jp

²正会員 株式会社建設技術研究所（〒103-8430 東京都中央区日本橋浜町3-21-1）

E-mail : teraoku@ctie.co.jp

³非会員 早稲田大学 創造理工学部（〒169-8555 東京都新宿区大久保3-4-1）

E-mail : dg.57@akane.waseda.jp

⁴正会員 早稲田大学 理工学術院（〒169-8555 東京都新宿区大久保3-4-1）

E-mail : akinori@waseda.jp

これまで交通事故対策として警察による街頭活動や違反検挙活動といった取締り活動が実施され、一定の成果を挙げてきた。しかし、交通環境を考慮した事故予測モデルの構築が進む中、取締り活動を考慮した事故予測モデルの構築は不十分である。今後、効率的な取締り活動を行う上で、事故対策と連動した予測モデル開発が望まれている。そこで、本研究では取締り活動や事故リスクの時間的および空間的な変動を考慮するため、複数の異なるタイプのモデルの統合化を検討し、より精度の高い事故予測モデルを構築することを目的とする。その結果、時系列モデルと経験ベイズモデル、画像認識モデルを統合化することで、予測精度が向上した統合型のモデルを構築することができた。

Key Words : *Street Safety Activity, Traffic Accident Prediction, Temporal Variation, Spatial Variation*

1. はじめに

(1) 研究の背景・目的

我が国における交通事故の発生状況は改善の傾向を示している。発生件数は最多件数となった2004年の952,201件から継続的に減少し、2019年には381,002件となっている。一方、交通事故による死者数も2019年には3,215人まで減少し、統計を取り始めた1948年以降最小となった¹⁾。しかし、2016年の第10次交通安全基本計画では、2020年までに交通事故による死者数2,500人以下を掲げており²⁾、目標達成に向けてさらなる交通事故の抑制が必要である。そのためには、従来の対策に加えてICTや人工知能AIを活用した新たな交通事故の対策や分析手法が求められている。

これまでの交通事故対策の1つとして、警察による取締り活動が挙げられる。パトカーや立番による警戒活動や街頭活動といった事前予防的な活動や、実際に発生した違反を検挙する直接的な活動などが該当する。これらの取締り活動によって一定の成果を挙げてきたが、さら

なる事故抑制のためには、より効果的な取締り活動の実施が必要といえる。効果的な事故対策のためには、発生した事故分析に加えて将来の事故リスクを的確に予測し、事故を未然に防ぐ対策が求められている。これまでの交通事故予測を大別すると、時間的変動予測と空間的変動予測に分類される。前者は時間変化するデータを入力することで、時間変動する事故リスクを予測するものである。さらに時間単位で整理すると、年単位で事故件数の推移を予測する長期的トレンドに注目したものと、日々変化する事故リスクを予測する短期的トレンドに注目したものに分類される。一方で、後者は一定期間のデータを集計し、詳細な地点単位で格納することで、事故リスクや対策効果が空間的に伝搬することを表現できるモデルである。双方の予測手法を適切に組み合わせることで、時間的かつ空間的な事故予測が可能になる。

そこで、本研究では取締り活動と事故リスクの時間的変動と空間的変動を考慮した予測モデルの構築を行う。そして、これらの予測モデルを統合化することで、予測精度の高い事故予測モデルを構築することを目的とする。

(2) 既存研究の整理・本研究の位置づけ

本研究に関する既存研究は、取締り活動と交通事故の関係性に関する研究、事故予測について、時間的変動予測に関する研究と空間的変動予測に関する研究の3つに大別される。

取締り活動は交通事故の抑止効果が期待される対策であり、その効果に着目した研究が多く見られる。取締り頻度と事故発生率の関係性に注目したものとして、Oei³⁾は取締り頻度が低いと事故減少効果が小さく、頻度が高い場合も効果が薄れること示し、適切な頻度で取締りを行うことを提言した。取締り活動の事故減少効果を検証したものとして、森本ら⁴⁾は取締りが事故死者数の減少に与える効果を定量的に示し、この削減効果は3週間程度に及ぶものであることを明らかにした。一方、取締り活動の効果が及ぶエリアの範囲に注目したものとして、船本ら⁵⁾は取締り地点と事故発生地点の関係性を分析し、取締り地点から半径1km～2.5kmの範囲で事故減少効果があることを明らかにした。

事故予測については、長年にわたり研究がなされている。時間的変動予測の中で、長期的なトレンドに着目したものとしては、石井ら⁶⁾、内閣府⁷⁾などの研究が挙げられる。一方、短期的なトレンドに着目したものは、下田ら⁸⁾、保倉ら⁹⁾などの研究が挙げられる。いずれも、時間的変動予測の可能性が明らかになっており、分析手法も従来の統計手法から人工知能を用いたものまで幅広い。

一方、空間的変動予測では従来の統計手法だけでなく、人工知能やビックデータなどに着目した研究が盛んである。従来の統計手法を用いてビックデータを活用したものとして、渡部ら¹⁰⁾、尾高ら¹¹⁾の研究が挙げられる。一方、従来の手法に加えて経験ベイズ法を適用して予測したものとして、松尾ら¹²⁾の研究が挙げられる。

以上のように、これまでも取締り活動の効果に着目した研究や、多種多様な予測モデルの構築に関する研究などが行われているものの、取締り活動を考慮した具体的な事故予測モデルの構築手法については十分に確立されていない。そこで、本研究では時間的変動モデルとして時系列モデル、空間的変動モデルとして経験ベイズモデルと画像認識モデルに着目した。これら3つのモデルを統合し、さらに取締り活動を考慮することで、精度の高い事故予測モデルを構築する点に本研究の特徴がある。

(3) 取締り活動について

取締り活動は警察官による様々な活動を指しているため、本研究で対象とする取締り活動の定義を以下に示す。

a) 街頭活動

警察官が交通立番や交通警らを行うことによって道路利用者に注意を促す活動。本研究ではデータの都合上、巡回する活動は含まず、道路上や交差点上などにおいて、定点で街頭活動を行っているものだけを対象とする。

b) 違反検挙活動

実際に発生した速度違反や駐車違反等の交通違反を、警察官が検挙する活動。本研究では、一般的な危険車両および駐車車両に対して違反検挙活動を行っているものを対象とする。

(4) 対象地と使用データ

東京都新宿区は、毎年数多くの交通事故が発生しており、取締り活動も定期的実施されている地域である。また、同じ区内に繁華街と住宅地が共存しており、交通量の多い幹線道路から狭小な生活道路が存在しているため、交通事故の発生状況を端的に表現できると考えた。以上より、新宿区を対象に本研究を行う意義は高いと考え、対象地とした。

分析単位は50mメッシュとする。これは、効果的な取締り活動に落とし込むために必要なスケールである。また、本研究の使用データは以下の通りである。

- ① 2014年～2018年までの交通事故原票
- ② 2014年～2018年までの街頭活動原票
- ③ 2014年～2018年までの違反原票
- ④ 各種オープンデータ（次章で説明）

(5) 本研究の概要

本研究の分析の流れは以下の通りである。

- ① 対象地における現状把握と使用データの整理（2章）
対象地における交通事故や取締り活動の状況を整理するとともに、使用データの整理を行う。
- ② 事故予測モデルの構築（3章）
従来の統計手法では困難である要因や表現を考慮するために、入力データの質に合わせた事故予測モデルを3種構築する。また、取締り活動もそれぞれのモデルに合わせた集計をすることで入力する。
- ③ 各予測モデルによる事故予測（4章）
構築した3種の予測モデルを、対象地においてそれぞれ実行することで、事故件数を予測し実際の事故発生状況と比較して予測精度を検証する。
- ④ 各予測モデルの統合化（5章）
構築した3種の予測モデルの予測結果を統合化することで、時間変動かつ空間変動する事故リスクの予測を行うとともに、予測精度の向上を図る。

2. 対象地の現況把握と使用データの整理

(1) 対象地における交通事故の現状

対象地における2014年から2018年までの交通事故の発生状況を図-1に示す。道路に注目すると高速道路や幹線道路上で交通事故が多発しており、逆に住宅街の生活道路では頻度が少ないことが分かる。エリアで着目すると新宿駅周辺の繁華街では交通事故が集中しているが、それ以外の地域では事故は点在している。

事故類型に注目すると、車両相互事故が全体の8割程度を占めており、そのうち4割が追突事故であった。次に、人对車両事故が全体の2割程度を占めており、半数以上が横断中の事故であった。車両単独事故は全体の2%程度であった。いずれの事故についても、分類がなされていない「その他」事故が2割から3割を占めていることが分かった。今回はベースの事故予測モデル構築が目的であることから、全て同じ事故として集計を行った。

(2) 対象地における取締り活動の現状

はじめに、対象地における2014年から2018年までの街頭活動の実施状況を表-1に示す。全体の件数は交差点配置が96%以上を占める。活動時間は1回あたり1時間の活動が多く見られ、活動地点は数ヶ所に集中していることが分かった（データの性質上、地点図は掲載不可）。

次に、対象地における2014年から2018年までの違反検挙活動の実施状況を表-2に示す。全体の件数は一般違反が95%程度を占め、その中でも一般の検挙が大半を占めていることが分かる。

どちらの取締り活動においても、大半の配置箇所や違反の種類が特定の項目に集中しているため、今回の分析では全て同じ活動として集計を行った。

(3) 使用データの整理

本研究の使用データを整理した結果を表-3に示す。交通事故と取締り活動は警察からの提供データ、その他のデータについては、表中に記載の通りである。

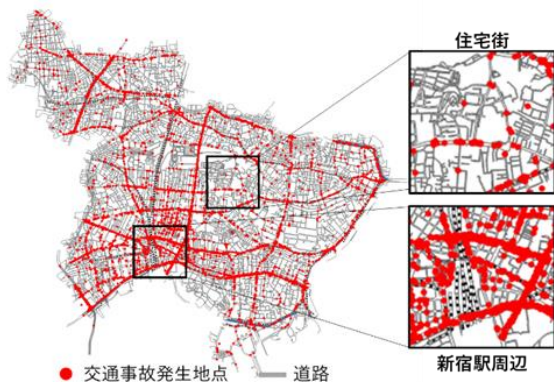


図-1 対象地における交通事故の発生状況 (2014~2018年)

表-1 配置箇所ごとの街頭活動の実施状況 (2014~2018年)

配置箇所	安全運動期間	活動回数 (回)	活動時間 (h)
街頭配置 (n=1,218)	期間外	701	703
	期間中	517	488
交差点配置 (n=16,970)	期間外	14,741	14,830
	期間中	2,229	2,809
計		18,188	18,830

表-2 違反種類ごとの違反検挙活動の実施状況 (2014~2018年)

違反種類	検挙の詳細	検挙件数(件)
一般違反 (n=95,976)	一般	187,137
	交通	1,137
	基本・簡易書式	440
	点数	2,569
	保管場所法	18
駐車違反 (n=5,183)	手書	7,951
	自動	4,322
計		201,261

表-3 本研究の使用データ概要

名称・出典	概要
交通事故	発生日時、地点などの人身事故に限る。単位は「件」
取締り活動	街頭活動 実施日時、地点などの配置活動に限る。単位は「回」
	違反検挙活動 検挙日時、地点など。単位は「件」
道路データ	交通量 単位は「100台/12時間」
	ピーク時速度 単位は「0.1km/時間」
三井造船システム技研 ¹³⁾	車道幅員 単位は「0.1m」
	道路延長 道路データの線の長さをGIS上で集計
	交差点 単位は「個」
天候データ 気象庁 ¹⁴⁾	降水量、気温、天候など1時間ごとに集計
道路縁データ 基盤地図情報 ¹⁵⁾	実際の道路の幅員を表現
標高データ 基盤地図情報 ¹⁵⁾	5mメッシュ単位の標高
用途地域データ 国土数値情報 ¹⁶⁾	用途地域ごとに色分け

3. 事故予測モデルの構築

(1) 入力データの整理

事故予測モデルを構築する前に、入力データの整理を行った結果を表-4に示す。対象地が狭域であり、使用データの性質を踏まえた結果、「①時間的変動あり・空間的変動なしの数値データ」と「②時間的変動なし・空間的変動ありの数値データ」と「③時間的変動なし・空間的変動ありの画像データ」の3項目に分けられたため、本研究ではそれぞれに合わせた3種類の事故予測モデルを構築する。

(2) 取締り活動の位置付け

表-4で入力データについて整理したが、街頭活動および違反検挙活動は「④時間的変動あり・空間的変動ありの数値データ」であるため、上記の3項目に当てはまらない。そこで、取締り活動の集計方法を図-2のように変えることで、3種類の事故予測モデルに反映することを試みる。これらの方法を用いることで、取締り活動が交通事故へ与える複数の要因を考慮することが可能だと考えられる。

(3) 事故予測モデルの構築

前項までに整理した内容をもとに、構築した3種の事故予測モデルの概要を表-5に示す。

① 時系列モデル（時間的変動あり・空間的変動なしの数値データ）

時系列モデルは Kinley ら¹⁷⁾の研究および酒巻ら¹⁸⁾の分析手法を参考に構築を行った。入力データの統計検定を行った結果、単位根は無いが自己相関のあるデータであったため、一般化最小二乗法（GLS）の1種である ARIMAX モデルを適用する。ARIMAX モデルは自己回帰モデルと移動平均モデルを組み合わせた上に、階差分系列と他の説明変数を考慮したモデル式である¹³⁾¹⁴⁾。

② 経験ベイズモデル（時間的変動なし・空間的変動ありの数値データ）

経験ベイズモデルは松尾ら¹²⁾の研究を参考に構築した。従来のポアソン回帰を行い対象地全体の平均的影響を考慮した上で、経験ベイズ法を用いて事故件数を反映させることで、地点固有の影響も考慮したモデル式である¹²⁾。

③ 画像認識モデル（時間的変動なし・空間的変動ありの画像データ）

画像認識モデルは保倉ら⁹⁾の研究を参考に構築した。人工知能の1種である深層学習の画像認識技術を用いることで、画像データを入力可能にした点の特徴である。具体的には、畳み込みニューラルネットワークのLeNetを活用することで、入力データを学習させ、事故件数を予測するようなモデルである。

表-4 入力データの整理結果

細字：数値 太字：画像	空間的変動 あり	空間的変動 なし
時間的変動 あり	④ 街頭活動, 違反検挙活動	① 天候**
時間的変動 なし	② 交差点, 車道幅員, 交通量*, ピーク時速度* ③ 交差点, 用途地域, 道路延長, 標高差, 道路縁	—

*本来時間変動するが、データの都合上、一時点の値を使用

**本来空間変動をするが、新宿区内のみなので一様の値を使用

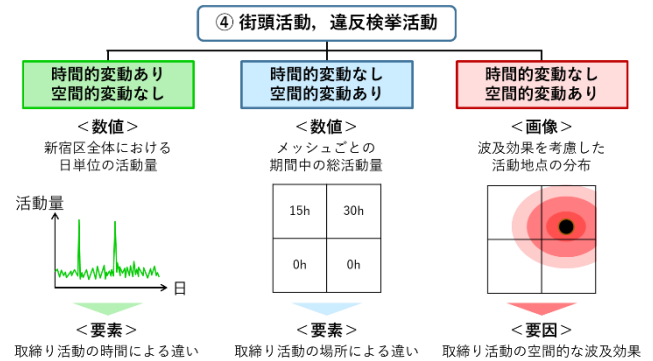


図-2 取締り活動の集計方法

表-5 各予測モデルの概要

名称	時系列モデル R_T	経験ベイズモデル R_E	画像認識モデル R_V
特徴	環境要因を考慮	地点固有の影響を考慮	形状や広がり表現
単位	日単位	年単位 (一定値)	年単位 (一定値)
入力	時間変動あり 空間変動なし	時間変動なし 空間変動あり	時間変動なし 空間変動あり
出力	全メッシュの 共通値 時間変動する 2018年事故件数	メッシュごとに 異なる値 時間変動しない 2018年事故件数	メッシュごとに 異なる値 時間変動しない 2018年事故件数

本研究では以上の3種の事故予測モデルの構築を行った。次章で各予測モデルを用いて事故予測を行う。

4. 各予測モデルによる事故予測

本章では、各予測モデルごとに事故予測を行う。時系列モデルでは、12項目ある天候データの組み合わせを検証することで、最適な説明変数を選択した。経験ベイズモデルでは、説明変数の組み合わせを検証し、最適な説明変数を選択した。画像認識モデルでは、10の入力画像の取捨選択および学習条件の設定を試行した。

各予測モデルについて、最も予測精度が高かったときの実行条件や入力した説明変数について記載する。

(1) 時系列モデルによる事故予測

本研究で提案する時系列モデルの実行条件や入力変数を表-6に示す。この条件下で、2018年の1ヶ月ごとに日単位の事故件数を予測する¹⁾。1月における予測件数と実際の事故件数の推移を図-3に示す。実際の事故が振れ幅が大きいものに対して、時系列モデルでは中間の傾向を予測していることが分かる。しかし、決定係数は0.1未満と極めて低く、日単位での予測は困難であるといえる。

表-6 最高精度時の時系列モデルの実行条件と入力変数

項目	実行条件および入力変数
分析単位	日単位, 新宿区全て同値
分析範囲	新宿区全体の 7,281 メッシュ (No.0~7,280)
分析期間	モデル構築: 直前月まで, 予測: 2018年1ヶ月ごと
説明変数	取締り活動および天候データの風速, 降水量, 湿度, 日射量
目的変数	2018年の事故件数




図-3 時系列モデルの予測件数と実際の事故件数の推移

(2) 経験ベイズモデルによる事故予測

本研究で提案する経験ベイズモデルの実行条件や経験ベイズモデルによるパラメータ推定の結果を表-7に示す。ポアソン回帰分析の結果、ピーク時速度以外の変数では一定の有意差が見られたため、この結果からを用いて経験ベイズ法を行いパラメータ ϕ を推定した。これらの条件で実行したとき、モデルの再現性は決定係数0.94程度であったため、このときのパラメータを採用した。

2014年から2017年のデータをもとに再現したパラメータで、2018年の事故件数を予測した結果を図-4に示す。これを見ると事故が多発している箇所では、比較的予測できていることが分かる。しかし、予測する空間精度を50mメッシュとしたことで、事故の少ない地点で過大評価をしているケースも見られ、全体の決定係数は0.35程度であった。

表-7 最高精度時の経験ベイズモデルの実行条件と設定

項目	実行条件および推定結果	
分析単位	期間中一定値, 50m メッシュ	
分析範囲	新宿区全体の 7,281 メッシュ (No.0~7,280)	
分析期間	モデル構築: 2014-2017年, 予測: 2018年	
説明変数およびポアソン回帰分析の偏回帰係数	a : 定数項 x_b : 街頭活動時間(h) x_c : 違反件数(件) x_d : 交差点(箇所) x_e : 交通量(100台/12h) x_f : ピーク時速度(0.1km/h) x_g : 車道幅員(m)	a : -1.78*** a : 4.91E-04*** a : 8.65E-05* a : 4.34E-01*** a : 2.89E-03*** a : 1.94E-04 a : 1.02E-02*
目的変数	2018年の事故件数	
パラメータ	$\phi=0.518$	

*** : $p < 0.001$, * : $p < 0.05$

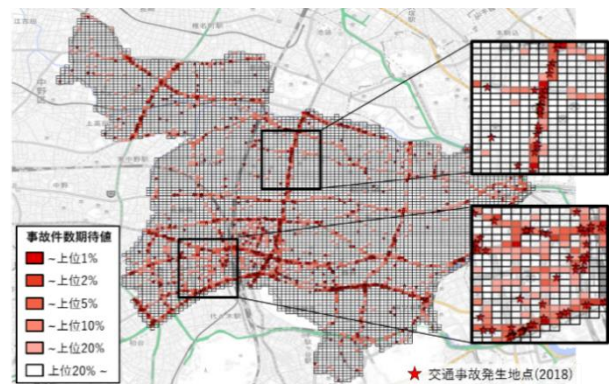


図-4 経験ベイズモデルの予測件数と事故発生地点の関係性

(3) 画像認識モデルによる事故予測

本研究で提案する画像認識モデルの実行条件および設定を表-8に示す。2014年から2018年の360メッシュのデータを用いてモデルを構築した結果、モデルの再現性は決定係数0.99をと極めて高くなった。このモデルを用いて、残りの40メッシュの事故件数を予測した。予測する40メッシュの位置をずらしながら10回繰り返して対象エリア全体の400メッシュの事故を予測した。そのときの数値と事故発生地点の関係を図-5に示す。

その結果、事故が多発している箇所において、予測モデルでも高く予測しているメッシュもあれば、全く傾向をつかめていないメッシュも存在した。使用したデータ数が限定的であることもあり、全体の予測精度は決定係数も0.1以下となり、画像認識モデル単独での予測には限界があると言える。今後、データ数を大幅に増やした検討が必要である。

5. 各予測モデルの統合化

本章では、4章で構築した各予測モデルの結果を統合することで、時間的変動かつ空間的変動する事故リスクを予測するモデルを構築する。そして、統合化した予測モデルの予測精度を検証する。

(1) 各予測モデルの統合条件

はじめに、各予測モデルの統合方法および正解事故リスクの算出方法について図-6に示す。4章では事故件数の予測を試みたものの、決定係数が最高でも0.35程度と低いことが分かった。交通事故は希少事象であり、事故が発生していないときでも潜在的な事故の危険性があると考え、ここでは事故リスクの予測を試みる。

まず、各予測結果 R_T, R_E, R_V の相互相関を検証した結果、表-9のように最大でも0.3に満たなかったため、今回は多重共線性の恐れは低いと考え、単純な足し合わせを考える。すなわち、各予測モデルの結果 R_T, R_E, R_V に対して、パラメータ α, β, γ によって重み付けをすることで、メッシュごと・日ごとに統合リスク R_{All} を算出する。

一方、正解値となる正解リスク R は、移動平均の概念を用いることで、メッシュごと・日ごとに算出する。それぞれの事故リスクを算出後、両者の誤差が小さくなるようにパラメータ α, β, γ を推定する。具体的には両者の差分の2乗が最小になるように最適化を行う。

このときの具体的な統合条件を表-10に示す。統合範囲は画像認識モデルと同じ新宿駅周辺の400メッシュとし、1ヶ月単位の12,000メッシュに対して最適化を行い、パラメータ α, β, γ を推定する。これを12ヶ月分繰り返すことで、12組のパラメータ α, β, γ を推定し、月ごとのパラメータの傾向を把握する。そして、その時の予測精度を算出することで、予測モデル統合の妥当性を検証する。

(2) 各予測モデルの予測結果の単位調整

各予測モデルによって予測された事故件数の単位は異なる。これらを足し合わせるためには、それぞれの予測件数の単位を揃える必要がある。本研究では以下のような方法で全ての予測単位を調整する。時系列モデルの単位は「件/日」、経験ベイズモデルと画像認識モデルの単位は「件/メッシュ」となっているため、時系列モデルについては予測件数をメッシュ数(7,281)で除す。経験ベイズモデルと画像認識モデルについては、予測件数を日数(365日×4年=1,460日)で除す。この調整を行うことで、いずれの予測件数の単位も「件/日/メッシュ」となり、全てを足し合わせることが可能になる。

表-8 最高精度時の画像認識モデルの実行条件と設定

項目	実行条件および設定
分析単位	期間中一定値, 50mメッシュ
分析範囲	新宿駅周辺の400メッシュ (No.0-399)
分析個数	モデル構築: 360メッシュ, 予測: 40メッシュ
説明変数	事故件数(メッシュ集計), 用途地域, 街頭活動地点(カーネル密度), 交差点
目的変数	2018年の事故件数
学習条件	エポック数: 1,000回, 最適化関数: Adam ミニバッチ数: 200個, 学習率: 0.0001

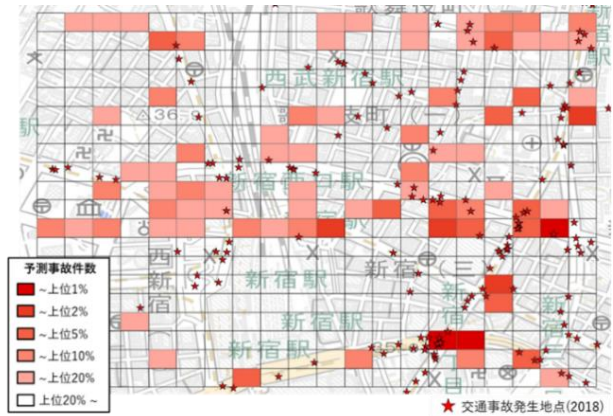


図-5 画像認識モデルの予測件数と事故発生地点の関係性




図-6 各予測モデルの統合と正解リスクの算出方法

表-9 各予測モデルによる結果の相関分析

	R_T	R_E	R_V
時系列	—		
経験ベイズ	-1.78E-21	—	
画像認識	4.53E-22	0.256	—

表-10 各予測モデルの統合条件

項目	実行条件
分析単位	日単位, 50mメッシュ
分析期間	2018年
統合範囲	新宿駅周辺の400メッシュ (No.0-399)
最適化条件	1ヶ月単位(400×30日=12,000メッシュ)で最適化し, パラメータ α, β, γ を推定。

(3) 各予測モデルの統合化の実行

前項までに、統合条件や単位の調整を行ったことで、単純な足し合わせによる統合が可能になった。各予測結果および正解リスクを標準化したのち、実際に1ヶ月ごとに統合化を行った結果を表-11に示し考察を行う。

まず、月による統合結果の違いは見られなかった。各パラメータの数値に大きな違いは無く、統合リスクと正解リスクの決定係数についても、小数点第4位以下では違いがあったものの、大きな差異は生まれなかった。

次に、各パラメータの重み付けについて着目すると、経験ベイズモデルの予測結果に対するパラメータが0.98程度と非常に大きくなったことが分かった。時系列モデルおよび画像認識モデルの重みは1%に満たない月が多く、想定していたより足し合わせが偏った結果になった。

最後に、統合リスクと正解リスクとの決定係数は0.63程度であり、各モデルによる予測のときと比較して精度が上昇したことが分かった。そのため、予測モデルの統合化により、時期によらず安定した精度を有した事故予測モデルが構築できたと考えている。

以上の結果を踏まえ、最もデータが蓄積され予測結果が安定すると考えられる12月のパラメータを用いることで、本研究では式(1)のように、各予測モデルを統合化した事故リスクの予測式を提案する。この予測式を用いることで、取締り活動を考慮した上で、時間的変動かつ空間的変動する事故リスクの予測が可能であると考えられる。

$$R_{all} = 0.008R_T + 0.984R_E + 0.008R_V \quad (1)$$

6. おわりに

本研究では、取締り活動と事故リスクの時間的変動および空間的変動を考慮するために、複数の異なる予測モデルの構築を行い統合することで、より精度の高い予測モデルの構築を目指した。各予測モデルの構築では、「時間的変動あり・空間的変動なし」の時系列モデルと、「時間的変動なし・空間的変動あり」の経験ベイズモデルと画像認識モデルの計3種の予測モデルを構築し、それぞれについて算出方法を変えることで取締り活動を反映した。各予測モデルの統合化では、構築した3種の事故予測モデルの予測結果を、単純な足し合わせによって統合化を行った。月ごとに重み付けのパラメータを推定した結果、式(1)のように経験ベイズモデルが重要視されることが分かった。

これらの分析を通じて、「時間的変動・空間的変動あり」の事故件数を精度高く予測可能なことを明らかにできたため、取締り活動を考慮した事故予測モデルの統合化が妥当であるといえる。

表-11 各予測モデルの統合化の結果

月	時系列モデル α	経験ベイズモデル β	画像認識モデル γ	決定係数
1	0.010	0.982	0.008	0.630
2	0.009	0.983	0.008	0.630
3	0.010	0.982	0.007	0.630
4	0.007	0.984	0.009	0.630
5	0.009	0.982	0.008	0.630
6	0.011	0.981	0.008	0.630
7	0.010	0.982	0.008	0.630
8	0.007	0.985	0.009	0.630
9	0.010	0.983	0.007	0.630
10	0.008	0.984	0.008	0.630
11	0.008	0.983	0.008	0.630
12	0.008	0.984	0.008	0.630

今後の課題として、入力データの種類や質が十分でない点が挙げられる。今後、蓄積した既存データやビックデータなどの新たなデータを、本研究で構築したモデルに入力することで、さらに信頼性の高い事故予測が可能になると考えている。

補注

- [1] この際、入力するデータのサンプル数が増加することに留意する。例えば、2018年12月を予測するとき、入力データは2014年から2017年だけでなく、2018年の1月から11月も入力する。

参考文献

- 1) 警察庁・交通局：道路の交通に関する統計・令和元年中の交通事故死者数について、2020。
- 2) 内閣府：第10次交通安全基本計画、2016。
- 3) Oei Hway-liem：Automatic Speed Management in the Netherlands, Transportation Research Record, Vol.1560, pp57-64, 1996。
- 4) 森本章倫・古池弘隆・守谷隆志：交通取締りが交通事故減少に与える効果に関する研究, 交通工学論文集, Vol.40, No5, pp72-78, 2005。
- 5) 船本悟史・森本章倫：交通取締りが狭域的な交通事故減少に及ぼす影響に関する研究, 土木計画学研究論文集, Vol.25, pp889-895, 2008。
- 6) 石井憲一・斎藤和夫：交通事故発生の時系列変動に関する統計的分析, 室蘭工業大学研究報告・理工編, Vol.9, No2, pp.517-534, 1977。
- 7) 内閣府：道路交通安全に関する基本政策等に係る調査報告書, 2015。
- 8) 下田康貴・寺奥淳・田中秀人・森本章倫：交通事故予測モデルを活用した街頭取締り活動の効果評価に関する研究, 交通工学論文集, Vol.6, No2, pp.63-70, 2018。
- 9) 保倉楓・寺奥淳・田中秀人・森本章倫：ニューラルネットワークを用いた交通事故予測のモデル化に関

- する研究, 第 39 回交通工学研究発表会論文集, pp.123-128, 2019.
- 10) 渡部数樹・中村英樹: 道路交通環境に着目した交通事故発生要因に関する統計モデル分析, 土木計画学研究論文集, Vol.32, pp.889-901, 2015.
 - 11) 尾高慎二・吉井稔雄・神戸信人: ETC2.0 データを用いた生活道路における事故リスク算定手法, 第 37 回交通工学研究発表会論文集, pp.253-256, 2017.
 - 12) 松尾幸二郎・違真樹・Franziska MIKSCH・杉木直: 先進プローブデータを活用した地点別の潜在的歩行者事故リスク評価～経験ベイズ縮約推定を用いて～, 第 39 回交通工学研究発表会論文集, pp.115-122, 2019.
 - 13) 三井造船システム技研株式会社: 道路地図, 2012.
 - 14) 気象庁: 各種データ・資料 1 時間ごとの値
https://www.data.jma.go.jp/obd/stats/etrn/view/hourly_s1.php?prec_no=44&block_no=47662&year=2019&month=1&day=1&view= (最終閲覧: 2020.3.8)
 - 15) 国土地理院: 基盤地図情報 ダウンロードサービス
<https://fgd.gsi.go.jp/download/menu.php>
 (最終閲覧: 2020.3.8)
 - 16) 国土交通省: 国土数値情報 ダウンロードサービス
<http://nlftp.mlit.go.jp/ksj/> (最終閲覧: 2020.3.8)
 - 17) Kinley Wangdi, Pratap Singhasivanon1, Tassanee Silawan, Saranath Lawpoolsri1, Nicholas J White, Jaranit Kaewkungwall : Development of temporal modelling for forecasting and prediction of malaria infections using time-series and ARIMAX analyses: A case study in endemic districts of Bhutan, *Malaria Journal*, No.9, 2010.
 - 18) 酒巻隆治・里洋平・市川太祐・福島真太郎・安部晃生・和田計也・久本空海・西菌良太: データサイエンスティスト養成読本 R 活用編, 技術評論社, 2014.
- (?????.?? 受付)

A STUDY on Traffic Accident Prediction Model Focusing on Temporal and Spatial variation of Traffic Enforcement Activity and Traffic Accident Risks

Shuto TANAKA, Jun TERAOKU, Daisuke SHIMADA, and Akinori MORIMOTO

Until now, traffic enforcement activities such as street activities and violation arrest activities by police have been implemented as measures against traffic accidents, and they have achieved certain results. However, while the construction of an accident prediction model taking into account the traffic environment is progressing, the construction of an accident prediction model focusing on traffic enforcement activities is insufficient. In the future, it is desired to develop a predictive model linked to accident measures for efficient crackdown activities. In this study, the purpose of this study is to consider the integration of multiple different types of models in order to consider the temporal and spatial fluctuations of traffic enforcement activities and accident risks, and to construct a more accurate accident prediction model. As a result, by integrating the time series model, the empirical Bayes model, and the visual recognition model, an integrated model with improved prediction accuracy was able to be constructed.