

Deep Q-Network を用いた 効果的な取締り活動方法の推計に関する研究

島田 大輔¹・山脇 正嗣²・寺奥 淳³・成瀬 拓海⁴・森本 章倫⁵

¹正会員 早稲田大学大学院 創造理工学研究科建設工学専攻 (〒169-8555 東京都新宿区大久保 3-4-1)
E-mail: dg.57@akane.waseda.jp

²正会員 株式会社建設技術研究所 国土文化研究所 (〒103-0014 東京都中央区日本橋蛸殻町 2-14-5)
E-mail: ms-yamawaki@ctie.co.jp

³正会員 株式会社建設技術研究所 中部支社 (〒460-0003 愛知県名古屋市中区錦 1-5-13)
E-mail: teraoku@ctie.co.jp

⁴学生会員 早稲田大学大学院 創造理工学研究科建設工学専攻 (〒169-8555 東京都新宿区大久保 3-4-1)
E-mail: 7ruse.ta93@akane.waseda.jp

⁵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、交通事故と取締り活動の関係は未だ不明瞭な点が多く、明確な科学的根拠に基づいた取締り活動の実施は困難である。交通事故の更なる削減には、人工知能を活用することで交通事故の発生予測を行い、効果的な取締り活動の実施が期待される。そこで本研究では、取締り活動を考慮した交通事故予測モデルを構築し、交通事故と取締り活動の関係を評価した。また、人工知能の一種である Deep Q-Network を用いて効果的な取締り活動方法を推計するモデルを構築した。その結果、取締り活動による交通事故の抑止効果を定量的に把握できたとともに、交通状況に応じた適切な取締り活動方法を具体的に提案することができた。

Key Words: Multiple regression Bayes, Deep Q-Network, Traffic Accident, Traffic Enforcement

1. 序論

(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。発生件数は過去最多を記録した 2004 年の 952,201 件から大きく減少し、2021 年には 305,425 件となっている。交通事故による死者数に関しても、2021 年には 2,636 人まで減少し、統計を取り始めた昭和 23 年以降最小となった¹⁾。しかし、2021 年の第 11 次交通安全基本計画²⁾では、2025 年までに交通事故による死者数 2,000 人以下を目標としており、目標達成に向けてさらなる交通事故の抑制が必要とされている。

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。パトカー等による違反検挙活動や、交差点等での街頭活動の実施は、交通事故の抑制につながる事が期待されている。しかしながら、取締り活動の実施

場所や実施時間については、ベテラン警察官の経験等によって判断されている場合が多く、明確な科学的根拠に基づいた実施は困難な現状にある。そのため、取締り活動と交通事故の関係を定量的に把握し、根拠に基づいた効果的な活動の実施が望まれている。

他方で、近年では人工知能の進歩は目覚ましく、医療や農業・金融など様々な分野で応用されている。交通安全分野においても、人工知能を用いた交通事故危険度予測マップの作成³⁾をはじめ、人工知能を交通事故対策へと活用する動きが見られている。しかし、その具体的な活用方法や信頼性に関しては未だ不明な点が多い。

そこで本研究では、まず取締り活動を考慮した交通事故予測モデルを構築し、取締り活動による交通事故の抑止効果を定量的に把握する。その後、人工知能の一種である Deep Q-Network(以降,DQN)を活用することで、取締り活動の最適な実施場所及び実施時間を推計するモデル

を構築する。そして、構築したモデルの実用化も視野に入れ、交通事故対策の一助となることを目的とする。

(2) 既存研究の整理

本研究に関する既存研究について「交通事故と取締り活動の関係に関する研究」、「交通事故予測に関する研究」、「強化学習に関する研究」の3つに大別して整理した。

a) 交通事故と取締り活動の関係に関する研究

Oei⁹⁾は取締り頻度と交通事故発生率の關係に着目し、取締り頻度が低いと事故減少効果が小さい一方、頻度が必要以上に高い場合も効果が薄れること示し、適切な頻度で取締り活動を行うことを提言した。

取締り活動の効果の持続性を検証した研究として、森本ら⁹⁾は全ての事故類型において死者数が減少する効果があることを示したとともに、その削減効果は3週間程度に及ぶことを明らかにした。

一方、取締り活動の効果が及ぶ範囲に着目した研究として、船本ら⁹⁾は取締り地点と事故発生地点の關係性を分析し、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。

b) 交通事故予測に関する研究

下田ら⁹⁾は取締り活動を考慮して交通事故を予測する重回帰モデルを構築した。週単位で事故を予測した結果、取締り活動には一定程度の事故抑止効果があることを明らかにしたが、予測精度には課題が残った。

取締り活動を考慮した他の研究として、田中ら⁹⁾は時系列モデル・経験ベイズモデル・画像認識モデルの3種の予測モデルの統合を行った。その結果、3種のモデルを統合することで、個々のモデルよりも高い精度での予測が可能となることを示した。

c) 強化学習に関する研究

成瀬ら⁹⁾は強化学習を用いた交通事故対策の1つとして、警察による取締り活動の最適な実施場所の決定モデルを提案した。その結果、強化学習の一種であるQ学習を用いることで、一定の精度で取締り活動場所を推計できることを示した。

DQN を活用した交通分野における研究として、小川ら¹⁰⁾は自動運転車の合流挙動に着目し、DQN を用いた自動運転車の速度制御モデルを構築した。その結果、DQN を用いることで、複雑な事象についても学習可能であることを示した。

(3) 研究の位置づけ

既存研究より、取締り活動と交通事故の關係や、取締り活動効果の波及期間・波及範囲が明らかにされているとともに、取締り活動の影響を考慮した交通事故予測が行われていることがわかる。また、交通分野においても

強化学習を用いた研究が進められていることが確認できる。

しかしながら、取締り活動による事故抑止効果を定量的に示した研究はなく、取締り活動を考慮した事故予測についても、予測精度や予測単位など未だ不十分な点が多い。加えて、効果的な取締り活動方法とその効果について、具体的に提案している研究は見受けられない。

そこで本研究では、取締り活動による事故抑止効果を定量的に把握した上で、最適な取締り活動方法を推計するモデルを構築する点に、研究の意義・新規性がある。さらに、従来の統計手法だけでなく、ベイズ理論やDQN といった人工知能技術を活用したモデルを構築する点に、本研究の特徴がある。

2. 研究の概要

(1) 研究の流れ

本研究は以下の流れで進めていく。

a) 対象エリアにおける特徴把握

対象エリアにおける交通事故の発生状況や、取締り活動の実施状況を整理し、対象エリアの特徴を把握する。

b) 重回帰分析に対するベイズ理論の適用方法の整理

交通事故予測モデルを構築するにあたり、ベイズ理論を従来の重回帰分析に適用する方法を整理する。

c) 交通事故予測モデルの構築

事故リスク値を目的変数、取締り活動等を説明変数とした重回帰ベイズモデルを構築する。構築した重回帰ベイズモデルを日単位で実行し、取締り活動による事故抑止効果を定量的に把握する。

d) 取締り活動方法推計モデルの構築

c)で構築した重回帰ベイズモデルをもとに、最適な取締り活動の実施場所及び実施時間を推計するモデルを、DQN を用いて構築する。

(2) 対象エリアと使用データ

本研究では、図-1 に示す東京都新宿区の JR 新宿駅周辺の 1km 四方を対象エリアとする。対象エリアでは、交通事故が一定数発生しており、取締り活動も定期的に行われている。また、同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られる。

分析に際しては、本モデルを実務レベルで活用可能にするため、対象エリアを 50m メッシュに分割し (No.0-No.399)、メッシュ単位かつ日単位という詳細な条件でモデル構築を行う。また、本研究で使用するデータは以下のとおりである。

- ① 2015年～2018年の交通事故データ
- ② 2015年～2018年の取締り活動データ
- ③ 2015年～2018年のETC2.0プローブデータ

(3) 語句の定義

a) 事故リスク値

本研究では、一度でも交通事故が発生したメッシュでは、どの時期でも事故発生リスクを持っていると仮定し、事故件数を時系列的に平滑化したものを事故リスク値として定義する。具体的には、図-2に示すように同一メッシュでの事故の発生間隔を指数分布で近似し、近似した指数分布の確率密度関数を用いてメッシュごとの事故リスク値を算出する。事故リスク値の定義式を式(2a)に、事故リスク値のイメージを図-3にそれぞれ示す。図-3より、あるメッシュで事故が発生した場合、そのメッシュにおけるその日の事故リスク値は1(件)であり、翌日以降は式(2a)に従って減少していき、事故が再発すると事故リスク値は再び1(件)に戻る定義となっている。

$$R(t) = e^{-0.003709t} \quad (2a)$$

$R(t)$: 事故発生日から t 日後における当該メッシュの事故リスク値

t : 当該メッシュでの直近の事故発生日からの経過日数

b) 取締り活動

警察による取締り活動は、街頭活動と違反検挙活動の2種類に大別される。街頭活動は警察官が交通立番や交通警邏を行うことによって運転手に注意を促す活動を指し、違反検挙活動は実際に発生した速度違反や駐車違反等の交通違反を検挙する活動を指す。本研究ではデータの都合上、違反検挙活動は含めず、道路上や交差点上などの定点で実施している街頭活動のみを取締り活動として取り扱う。

c) 取締り活動値

本研究では、取締り活動の空間的・時間的な波及効果を考慮するため、下田らの研究⁷⁾にならい、取締り活動値という指標を用いる。具体的には、取締り活動の効果は空間的には1km、時間的には3週間波及するものと仮定し、式(2b)、(2c)の減衰式に基づき各日・各メッシュの取締り活動値を算出する。

$$E_n = \frac{T}{0.4\sqrt{2\pi}} \exp\left(-\frac{x_n^2}{2 \times 0.4^2}\right) \quad (2b)$$

$$E_t = \frac{E_n}{0.4\sqrt{2\pi}} \exp\left(-\frac{x_t^2}{21}\right)$$

E_n : n 番メッシュにおける取締り活動値(件)

T : 基準メッシュの取締り活動時間(h)

x_n : 基準メッシュからの道路距離(km)

E_t : t 週後の当該メッシュの取締り活動値(件)

x_t : 取締り活動実施日からの経過日数(日)

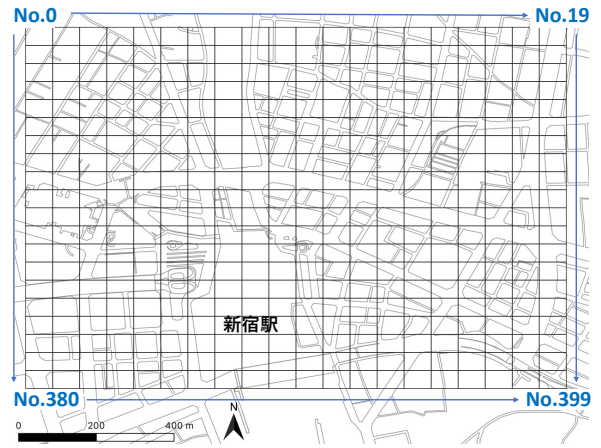


図-1 対象エリア




図-2 事故発生日からの経過日数と事故件数・事故リスク値の関係




図-3 事故リスク値のイメージ




図-4 対象エリアにおける交通事故の発生状況

3. 対象エリアの現状把握

(1) 対象エリアにおける交通事故の発生状況

対象エリアにおける 2015 年～2018 年の交通事故の発生状況を図4に示す。図4より、対象エリアでは幹線道路上や交差点上で交通事故が多発している一方、生活道路では発生頻度が少ないことがわかる。

(2) 対象エリアにおける取締り活動の実施状況

対象エリアにおける 2015 年～2018 年の取締り活動累計実施時間をカーネル密度分布で表したものを図5に示す。色が濃いエリアほど実施時間が長く、継続的に活動が行われていることを意味している。図5より、数ヶ所に限定してカーネル密度が高いエリアがあることがわかる。つまり、取締り活動は多箇所では実施されているのではなく、限定的箇所では集中的に実施されていると考えられる。




図-5 対象エリアにおける取締り活動の実施状況

4. 重回帰ベイズモデルの理論

(1) ベイズ理論について

交通事故予測モデルを構築するにあたり、本研究ではベイズ理論を用いる。ベイズ理論とは、ベイズの定理を元にした理論であり、既知の確率に新たな情報を加えることで、さらなる確率情報に更新できる点(ベイズ更新)が最大の利点である¹⁾。このベイズ理論に連続確率分布を取りこむことで、統計学に応用した場合の理論式を式(4a)に示す。式(4a)はデータDが与えられたときに母数が θ である確率公式である。P(D)は観測されたデータDの確率であり、データが与えられたとき一定値を取るため、無視することができる。そのため、式(4a)は式(4b)のように書き換えることができる。式(4b)から、事後分布は尤度と事前分布の積に比例することが分かる。前述のベイズ更新とは、式(4b)で得た事後分布を、次の分析の事前分布として用いることで、確率分布を逐次更新することを指す。

$$\pi(\theta|D) = \frac{f(D|\theta)\pi(\theta)}{P(D)} \quad (4a)$$

$$\pi(\theta|D) \propto f(D|\theta)\pi(\theta) \quad (4b)$$

$\pi(\theta|D)$: 事後分布 $P(D)$: データ D を得る確率

$f(D|\theta)$: 尤度 $\pi(\theta)$: 事前分布

(2) 重回帰分析に対するベイズ理論の適用

前節で示した式(4b)を用いてベイズ理論を従来の重回帰分析に適用し、逐次更新が可能な予測モデルを構築する。ここでは、データ数nの説明変数x, sによって事故リスク値yを予測する式(4c)のような単純な回帰モデル

の場合を考える。このとき、予測モデルの誤差が平均値0, 分散 σ^2 の正規分布に従うと仮定し、行列Y, X, β を式(4d)で定義すると、得られる尤度 $L(D|a, b, c)$ は式(4e)で表される。また、偏回帰係数a, b, cの平均値と分散が分かっているとき、事前分布 $\pi(a, b, c)$ は式(4f)で表され、その平均値と分散は式(4g)で示す通りである。

この尤度と事前分布を式(4b)に代入し、事後分布を算出すると式(4h)のようになる。ここで、式(4h)における μ_1 と σ_1 はそれぞれ式(4i)で表され、ベイズ理論によって得た各偏回帰係数の平均と分散の値である。すなわち、各偏回帰係数は式(4h)及び式(4i)で表される正規分布に従うことを示している。この一連の流れは説明変数がいくつの場合でも成立する理論である。本研究では、このベイズ更新の一連の流れを繰り返しながら偏回帰係数の分布を逐次的に推定し、交通事故予測モデルを構築する。

$$y = a + bx + cs \quad (4c)$$

$$Y = \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix}, X = \begin{pmatrix} 1 & x_1 & s_1 \\ \vdots & \vdots & \vdots \\ 1 & x_n & s_n \end{pmatrix}, \beta = \begin{pmatrix} a \\ b \\ c \end{pmatrix} \quad (4d)$$

$$L(D|a, b, c) \propto e^{-\frac{1}{2\sigma^2}(Y-X\beta)^T(Y-X\beta)} \quad (4e)$$

$$\pi(a, b, c) \propto e^{-\frac{1}{2}(\beta-\mu_0)^T\Sigma_0^{-1}(\beta-\mu_0)} \quad (4f)$$

$$\mu_0 = \begin{pmatrix} \mu_{a0} \\ \mu_{b0} \\ \mu_{c0} \end{pmatrix}, \sigma_0^2 = \begin{pmatrix} \sigma_{a0}^2 & 0 & 0 \\ 0 & \sigma_{b0}^2 & 0 \\ 0 & 0 & \sigma_{c0}^2 \end{pmatrix} \quad (4g)$$

y : 目的変数 (事故リスク値)

a, b, c : 偏回帰係数 x, s : 説明変数

$L(D|a, b, c)$: n個のデータDから得られる尤度

σ^2 : 回帰モデルにおける誤差の分散

X : 各データの説明変数 Y : 各データの目的変数

β : 各偏回帰係数

$\pi(a, b, c)$: 各偏回帰係数の事前分布

$\mu_0 (= \mu_{a0}, \mu_{b0}, \mu_{c0})$: 各偏回帰係数の平均 (初期条件)

$\sigma_0^2 (= \sigma_{a0}^2, \sigma_{b0}^2, \sigma_{c0}^2)$: 各偏回帰係数の分散 (初期条件)

布の平均値をメッシュごとに比較した結果を図-6に示す。決定係数は約 0.301 であり、十分な精度とは言えないが、ある程度の傾向は再現できていると言える。

(3) モデルの精度検証

前節で構築したモデルを用いて、2018年1月～12月のうち交通安全運動週間を除いた期間において事故リスク値の予測を行った。最も精度が高かった2018年2月2日における実事故リスク値と予測事故リスク分布の平均値をメッシュごとに比較した結果を図-7に示す。決定係数は約 0.307 であり、図-6で示した現状再現と同等の精度で事故リスク値が予測できていると言える。また、予測値と真値の無相関検定を実施したところ、p値<0.001 となったため、有意な相関関係であることも確認できた。

6. 取締り活動方法推計モデルの構築

(1) Deep Q-Network とは

効果的な取締り活動方法の推計にあたり、本研究では Deep Q-Network(DQN)を用いる。DQN とは、強化学習の一種である Q 学習に深層ニューラルネットワークを応用した深層強化学習手法である。Q 学習では、式(6a)により行動価値 Q 値が収束するまで更新し続ける必要があるが、DQN では深層ニューラルネットワークによって Q 値を近似的に求めるため、状態や行動が複雑な場合でも効率的に学習できる点が最大の特徴である。

$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha[r_{t+1} + \gamma \max_a Q(s_{t+1}, a) - Q(s_t, a)] \quad (6a)$$

Q : 行動価値関数 a_t : t回目における行動
 r_t : a_tにより得る報酬 s_t : a_tにより遷移する状態
 α : 学習率 γ : 割引係数

(2) 取締り活動方法推計モデルの概要

本研究で構築したDQNの概要を表-4に示す。ここで、ε-greedy法とはε(0<ε<1)の確率で可能な行動の中からランダムに行動を選択し、それ以外の(1-ε)の確率では現時点で行動価値関数Q(s_t, a_t)の値が最大である行動を選択する方策である。本研究では、εの値は式(6b)に示す逆ロジスティック関数に基づき、学習回数に応じて減衰していくように設定する。すなわち、学習初期にはεの値を1に限りなく近づけることでより多くの行動を経験させ、学習終期に近づくに伴い、εの値を0に近づけることで安定した学習を可能にする方策とした。

表-4 DQNの概要

状態s	事故リスク値
行動a	取締り活動(場所及び時間)
報酬r	各メッシュにおける事故リスク値の減少量の総和
期間	2018年1月～12月
学習回数	2,000回
学習条件	学習率α : 0.01, 割引係数γ : 0.99 ミニバッチ数 : 32個 最適化関数 : Adam
中間層	16ノード×3層
方策	ε-greedy法

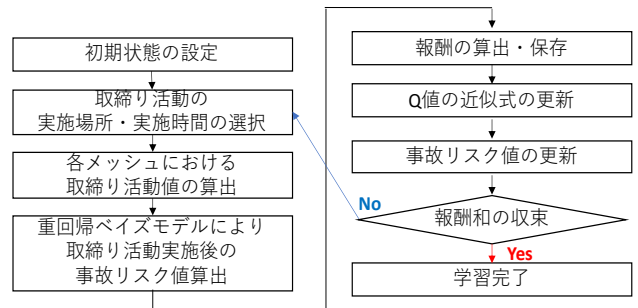


図-8 取締り活動方法推計の流れ

表-5 2018年2月2日における取締り活動方法の推計結果

順位	活動方法	行動価値	順位	活動方法	行動価値
1	No.168meshで2h	2.556	6	No.168meshで1h No.192meshで1h	2.482
2	No.167meshで1h No.168meshで1h	2.522	7	No.168meshで1h No.189meshで1h	2.481
3	No.168meshで1h No.169meshで1h	2.507	8	No.168meshで1h No.171meshで1h	2.475
4	No.167meshで2h	2.489	9	No.168meshで1h No.170meshで1h	2.473
5	No.166meshで1h No.168meshで1h	2.482	10	No.168meshで1h No.148meshで1h	2.459

$$\epsilon = c - \frac{c - K}{1 + e^{10 - 0.01t}} \quad (6b)$$

t : 学習回数 c(上限) = 1 K(下限) = 0.1

(3) 取締り活動方法推計の流れ

本研究では、2018年1月～12月を対象に、図-8の流れで効果的な取締り活動場所を推計する。初期状態には、対象エリア内において取締り活動を実施せず、交通量や最高速度等の交通環境のみを考慮した場合の事故リスク値を重回帰ベイズモデルより算出し、入力する。その後、あらゆる取締り活動を実施した場合の状態の変化を繰り返して学習し、各行動の行動価値を更新していく。最終的に、各取締り活動の行動価値が学習結果として算出され、最も効果的な取締り活動方法が推計できる。すなわち、当該日の交通環境を加味したリアルタイムな分析が可能

であり、根拠に基づいた取締り活動方法を提案できる点が、本モデルの特徴と言える。

(4) 効果的な取締り活動の推計結果

一例として、事故リスク値の予測精度が最も高かった 2018 年 2 月 2 日において、対象エリア内で合計 2 時間取締り活動を実施することを行動条件に、取締り活動方法を推計した結果を表-5 に示す。なお、メッシュ番号は図-1 に示す番号と対応している。表-5 より、複数メッシュで 1 時間ずつ活動を実施するより、No.168mesh で 2 時間取締り活動を実施する方が効果的であることがわかる。これは、対象エリアが 1km 四方と比較的狭範囲であり、1 箇所のみでの活動でもエリア全体にその効果が波及するためであると考えられる。次に、1 箇所のみでの活動する場合における行動価値の分布を図-9 に示す。図-9 より、最適と推計された No.168mesh は新宿大ガード東交差点付近であり、この地点を中心に靖国通り沿いでの活動が効果的であることが見て取れる。また、効果的な活動場所であると推計された上位 20mesh と実際の取締り活動場所を比較したものを図-10 に示す。図-10 を見ると、行動価値が高い地点と取締り活動の実施時間が多い地点が概ね一致していることがわかる。すなわち、実際の取締り活動は適切な場所で実施されていると言える。一方で、東側のエリアでは、行動価値は高いが取締り活動時間が少ない地点も一部存在している。また、北東側や西側、南側のエリアでは、取締り活動時間が多いが行動価値が低い地点も存在している。そのため、今後はこうしたミスマッチを解消し、行動価値が高い地点で重点的に取締り活動を実施することで、より高い効果が見込めると考えられる。

7. 結論

(1) 得られた知見

本研究では、重回帰ベイズモデルを用いた交通事故予測と、DQN を用いた取締り活動方法の推計を実施した。重回帰ベイズモデルでは、事故と取締り活動の関係を定量的に把握することができ、単位取締り活動値あたり平均 0.007 件程度事故リスク値を減少する効果があることがわかった。DQN モデルでは、最適な取締り活動方法を日単位で推計することに成功し、新宿大ガード東交差点付近を中心とした靖国通りでの活動が効果的であることが明らかとなった。本モデルのアルゴリズムを搭載した取締り活動方法提案ツールの開発などにより、本モデルの実用化を図ることで、過去の事故発生状況や当日の交通状況に応じた、適切な取締り活動の実施が可能になると考える。

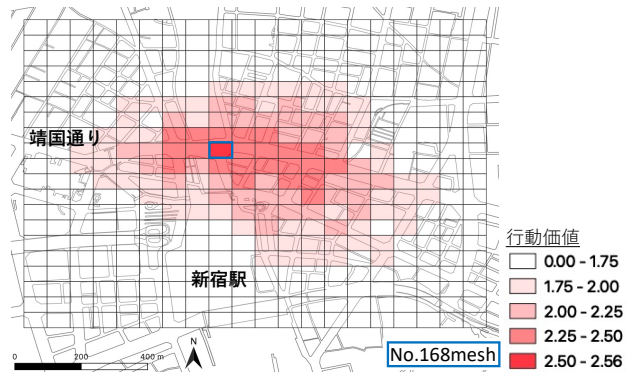


図-9 2018 年 2 月 2 日における行動価値

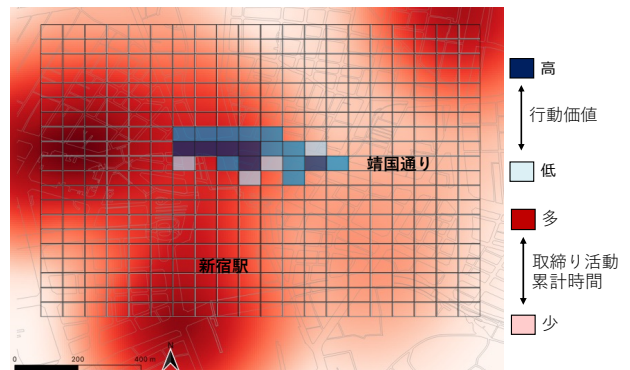


図-10 行動価値の推計結果と実際の取締り活動の比較

(2) 今後の課題

a) 重回帰ベイズモデルへの説明変数の追加

本研究では重回帰ベイズモデルを用いて交通事故予測モデルを構築した。予測モデルの決定係数は 0.3 程度であり、一定程度の予測精度が確認できた。今後は天気データや標高データなど、事故の要因となり得るデータを説明変数に追加することで、更なる精度向上を図る。

b) 対象エリア及び期間の拡大

本研究では対象範囲が 1km 四方の 400 メッシュで、対象期間が 4 年間と限られた空間と時間の中での分析を行った。今後は、効果的な取締り活動場所の提案を実現化するため、対象範囲及び対象期間の拡大も視野に入れて分析を進める。

c) 取締り活動の推計方法の発展

効果的な取締り活動方法について、6 章では 2018 年 2 月 2 日における推計結果のみを示した。対象期間全体の推計結果を考察すると、日によるばらつきは少なく、ほとんどの日において、複数箇所での活動よりも 1 箇所での集中的な活動の方が効果的であると推計された。そのため、今後は取締り活動の波及効果の妥当性の確認や対象エリアの変更等により、推計方法の発展を目指す。

謝辞：本研究は、警視庁よりデータ提供を受け、国交省と連携して実施しました。記して謝意を示します。

参考文献

- 1) 警視庁：道路の交通に関する統計，令和 3 年中の交通事故死者数について，p.1, 2022
- 2) 内閣府，中央交通安全対策会議：第 11 次交通安全基本計画，p.12, 2021
- 3) 株式会社パスコ：平成 30 年度 AI 活用交通事故抑止対策事業委託業務 分析結果報告書，pp.98-107, 2018
- 4) Oei Hway-liem：Automatic Speed Management in the Netherlands, Transportation Research Record, Vol.1560, pp.57-64, 1996
- 5) 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, pp.72-78, 2005
- 6) 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, pp.889-895, 2008
- 7) 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, No.2, pp.63-70, 2020
- 8) 田中秀人，寺奥淳，島田大輔，森本章倫：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，土木計画学研究・講演集，Vol.61, 2020
- 9) 成瀬拓海，山脇正嗣，寺奥淳，森本章倫：Q 学習を活用した交通事故推計に関する研究，第 41 回交通工学研究発表会論文集，2021
- 10) 小川一太郎，横山想一郎，山下倫央，川村秀憲，酒徳哲，柳原正，大岸智彦，田中英明：Deep Q-Network を用いた自動運転車のゆずりあいによる交通流の効率化，人工知能学会全国大会論文集，第 32 回，2018
- 11) 涌井良幸・涌井貞美：Excel でスッキリわかる ベイズ統計入門，日本実業出版社，2010
- 12) 内閣府：春の全国交通安全運動推進要項，p.1, 2015-2018
- 13) 内閣府：秋の全国交通安全運動推進要項，p.1, 2015-2018
- 14) 一般財団法人自動車検査登録情報協会：都道府県別・車種別自動車保有台数，p.1, 2015-2018
- 15) 一般財団法人 ITS サービス高度化機構：ETC/ETC2.0(DSRC)普及状況，2015-2018

?

?

A STUDY ON ESTIMATING EFFECTIVE METHODS OF TRAFFIC ENFORCEMENT ACTIVITIES USING DEEP Q- NETWORK

Daisuke SHIMADA, Masashi YAMAWAKI, Jun TERAOKU,
Takumi NARUSE and Akinori MORIMOTO

In the past, the police have conducted traffic enforcement activities as a countermeasure against traffic accidents, and have achieved a certain degree of success. However, the relationship between traffic accidents and traffic enforcement activities is still unclear, and traffic enforcement activities based on clear evidence have not yet been implemented. In this context, there is a movement toward the use of artificial intelligence to predict the occurrence of traffic accidents and to implement traffic effective enforcement activities. In this study, we developed an accident prediction model that takes into account traffic enforcement activities, and evaluated the relationship between traffic accidents and traffic enforcement activities. In addition, we developed a model to estimate effective methods of traffic enforcement activities using Deep Q-Network, a type of artificial intelligence. As a result, we were able to quantitatively understand the deterrent effect of traffic enforcement activities on traffic accidents, and we were able to specifically propose appropriate traffic enforcement activity methods according to traffic conditions.