

逆強化学習を活用した 交通事故推計に関する研究

成瀬 拓海¹・山脇 正嗣²・寺奥 淳³・森本 章倫⁴

¹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

²正会員 株式会社建設技術研究所 国土文化研究所インテリジェンスサービスプラットフォーム
(〒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 道路・交通部
(〒460-0003 愛知県名古屋市中区錦 1-5-13) E-mail: teraoku@ctie.co.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

我が国の交通事故の発生状況は改善の傾向を示しているが、その減少幅は徐々に小さくなっている。内閣府の第 11 次交通安全基本計画では令和 7 年までに年間の 24 時間死者数を 2000 人以下という目標を掲げ、目標達成に向けて更なる交通事故の抑止に資する取り組みが必要である。他方で、近年では AI(人工知能)を活用して、ビッグデータを解析し、様々な事象を予測する技術開発が急速に進んでいる。交通安全分野においても、AIを活用して交通事故の発生を予測し、効率的な取締り活動の実施が期待される。そこで本研究では、AIの一種である逆強化学習を活用し、プローブデータを解析することで、交通事故発生リスクを定量化するモデルを構築した。さらに、既往研究と併せて活用することで、最適な取締り場所の提案を可能にした。その結果、今後の取締り活動の効果的な実施方法に関する知見を得た。

Key Words: Traffic Safety, AI, Inverse Reinforcement Learning, Traffic Enforcement

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。発生件数は最多となった平成 16 年の 952,201 件から単調に減少し、令和 2 年には 309,000 件となっている。一方、交通事故による死者数も令和 2 年には 2,839 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、令和 3 年の第 11 次交通安全基本計画では、令和 7 年までに交通事故による 24 時間死者数 2,000 人以下²⁾を掲げており、目標達成に向けて新たに適切な交通事故対策や分析手法の開発が急務とされている。

交通事故対策の1つとして、警察の取締り活動が挙げられる。その活動には、実際に発生した違反を検挙する直接的な活動と、パトカーなどによる警ら活動や街頭活動といった事故を間接的に予防する活動が存在する。これらの活動は交通事故抑止に寄与することが期待されており、効果的な活動の実施が望まれる。

また近年、AIの進歩は目覚ましく、海外では交通安全に関しても近未来事故予測マップの活用がみられる。

一方日本では、警視庁において AI を活用した交通事故予測と、その結果に基づく効果的な取締り活動の確立を目指している。しかし、AIを活用した交通事故予測に関する研究事例は少なく、その具体的な方法や予測精度に関しては不明点が多い。

そこで本研究では、AIの一種である逆強化学習を活用し、交通事故の発生リスクを予測するモデルの構築を行う。そして、算出した事故リスク値を既往研究³⁾で構築したQ学習モデルに説明変数として取り込むことで、取締り活動の最適な実施場所の提案を目的とする。

2. 既存研究の整理と本研究の位置づけ

(1) 既存研究の整理

本研究に関する既存研究を「交通事故と取締り活動に関する研究」、「AIを用いた交通安全に関する研究」、「強化学習と逆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に関する研究

Oei⁴⁾は、取締り頻度と交通事故発生率の関係性に着目し、取締り頻度が低いと事故抑止効果が小さく、頻度が高い場合も効果が薄れることを示し、適切な頻度で取締りを行うことを提言した。さらに森本ら⁵⁾は、取締り活動による事故抑止効果を検証し、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すとともに、この削減効果は3週間程度に及ぶことを明らかにした。一方で船本ら⁶⁾は、取締り活動の効果影響範囲に着目し、取締り地点と事故発生日点の関係性を分析し、取締り地点から半径 1~2.5km の範囲で事故減少効果があることを明らかにした。

Stanojevic ら⁷⁾は、過去に取締り活動がほとんど行われていなかったコソボ共和国の北部を対象地に、交通取締りが運転者の態度や行動に与える影響を調査した。その結果、取締りが運転速度の低下や制限速度の遵守、違反運転行為の抑止を運転者に促す効果があることを明らかにした。

b) AI を用いた交通安全に関する研究

小谷ら⁸⁾は、交通事故の発生状況を詳細に記述する方向別・類型別交通事故推計モデルを、ニューラルネットワークを用いて構築した。その結果、道路交通要因変化に対する交通事故率の変化を推計し、複数の交通安全対策の相乗的効果の表現が可能になった。

さらに発展させて、出井ら⁹⁾は、画像データと数値データを説明変数としたマルチモーダル AI を活用し、交通事故予測モデルを構築した。しかし、交通事故の発生件数を予測することは困難であった。

c) 強化学習と逆強化学習に関する研究

AI に関する研究として、強化学習が様々な研究分野で注目されている。強化学習は行動の帰結に対して評価値として報酬を与えることで最適な行動を推計する手法であり、各データに正解データを用意する必要がなく、長期的な視点での分析も可能となるため汎用性が高い。

Watkins ら¹⁰⁾は、強化学習の一種である Q 学習の収束定理を提示し、Q 学習は全状態で全行動が繰り返しサンプリングされる限り、最適な行動の評価値に収束することを理論的に証明した。この証明が Q 学習の有効性を示す要素の一つとして挙げられる。具体的な Q 学習の活用事例としては、Khriji ら¹¹⁾は、移動ロボットのナビゲーションタスクを構造化する方法に Q 学習を活用することで、学習の収束時間を大幅に短縮し、最適な行動選択が可能であることを明らかにした。

ただし、最適な状態が明確でなく、報酬の設定が困難な対象については強化学習の適用が困難である。そこで強化学習の反復により未知の報酬を推定する手法として逆強化学習が考案された。逆強化学習では、観測された行動軌跡が報酬を最大化すると仮定して、最適な報酬関

数を推定する。Hirakawa ら¹²⁾は、海鳥の行動特性を逆強化学習によって定量化し、飛行経路の予測を行った。精度検証では、逆強化学習を用いた手法が線形補完に比べて有意に予測誤差が小さいことが示された。

(2) 本研究の位置づけ

交通安全分野における従来の予測手法では、一定期間のデータを活用して静的に分析を行うことが多い。例えば、ニューラルネットワークなどを活用した交通事故予測は「教師あり学習」であり、常時変化する状態を十分に考慮することは困難であった。そのため、実際の交通安全対策を実施する際には、一定期間のデータに基づく定量的な分析結果と、日々変化する状況を加味した定性的な経験を合わせて、実施場所や時期が選定されている。

既往研究では、新宿区を対象に Q 学習を活用して、取締り活動による事故抑止効果の定量化を可能にした。しかし、事故リスク値の定義や様々な交通事象との関係性を外生的に与えていた点に課題が残った。

一方で、他分野では逆強化学習を活用した研究が進められている。しかし、これらの手法を用いた交通安全分野の研究の蓄積は十分ではない。そこで本研究では、交通事故の発生リスクを予測する逆強化学習モデルを構築する。さらに、Q 学習により取締り活動の最適な実施場所を予測する。このモデルは事故リスク値を対象地の特徴や時系列に合わせて算出できるため、既往研究より予測精度の高い分析が可能になる。

3. 研究の概要

(1) 研究の流れ

本研究は a)~c) の順で実施した。

a) 対象地の現状把握

対象地で過去に起きた交通事故・ヒヤリハットの特徴や、実施した取締り活動の状況を把握し、予測モデルの構築に必要なデータを収集・整理する。

b) 予測モデルの構築

交通事故やヒヤリハットの発生件数を入力データとした事故リスクを予測する逆強化学習モデルを構築する。また、取締り活動の最適な実施場所を予測する強化学習モデルを構築する。

さらに、上記で構築したモデルを実装し、事故リスクの定量評価、及び最適な取締り活動場所を推定する。

c) 予測モデルの精度検証

過去の取締り活動データと交通事故データについて、1週間ごとの関係性を調査し、逆強化学習モデルによる取締り活動の効果との相関を算出して精度を確認する。

(2) 対象地と使用データ

本研究では、東京都新宿区の JR 新宿駅周辺に 50m 四方の計 400 (縦 20×横 20) メッシュを設け、対象地とする。新宿区では、交通事故が多数発生しており、取締り活動も定期的実施されている。また、同区内に繁華街と住宅地が共存し、交通量の多い幹線道路から狭小な生活道路まで、多種の道路が存在するため、多様な環境下における交通事故の発生状況を端的に表現できる。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、対象地に選定した。

本研究で使用するデータは以下のとおりである。

- (a) 平成 26～30 年までの交通事故データ
- (b) 平成 26～30 年までの街頭活動データ
- (c) 平成 30 年 4～12 月までのプローブデータ

(3) 事故リスクの定義

a) 事故リスク

交通事故は偶発性が高く希少な現象であるため、特定の期間で発生しないケースが多い。そのため、数年単位で交通事故が 1 件でも発生した場所では、常に潜在的な危険性である事故リスクを有していると考え。また、過去に事故が発生していない場所でも、危険な運転事象が起こるような場合は、今後交通事故が発生する危険性が潜在していると考え。

一方で、一般的に知られるハインリッヒの法則によれば、1 件の重大な事故の背後には、多数の軽微な事故やヒヤリハットが潜んでいるとされている。この法則を交通事故に当てはめると、1 件の交通事故の背後には多数のヒヤリハットが潜んでおり、交通事故の発生を抑止するためには、ヒヤリハットを解消することが重要である。したがって、事故リスクを評価する上で、ヒヤリハットを含めて考慮することは有意である。

b) ヒヤリハットを用いた事故リスク値の算出

ヒヤリハットとは、労働災害分野で知られる重大な災害や事故には至らないものの、直結してもおかしくない一歩手前の事例の発見を指す。しかし、交通安全分野においてヒヤリハットの明確な定義はない。そこで本研究では、光ビーコンから得られた各車両の走行履歴情報の内、減速度 0.4G (1 秒間の速度変化 14.0km/h) 以上の急ブレーキ事象をヒヤリハットと定義する。光ビーコンとは蓄積した走行履歴データを車両から収集し、周辺の道路情報を車両に提供する車載器と双方向通信が可能な装置である。

本研究では、交通事故とヒヤリハットの発生件数を、1 週間単位でメッシュ毎に学習させて、逆強化学習モデルにより出力された状態価値を事故リスク値と定義する。状態価値とは、交通事故の起きた地点からの時空間的な波及を考慮し、交通事故の発生しやすさを定量的に示す。

従来の手法では、ヒヤリハットと事故の関係性を外生的に与えていたが、逆強化学習モデルでは、データに基づき内生的に算出できる点で対象地の特徴をより把握することができる。

4. 対象地の現状把握

(1) 対象地における交通事故の現状

新宿区における平成 26～30 年までの交通事故の発生状況を図-1 に示す。対象地では高速道路や幹線道路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。加えて、新宿駅周辺の繁華街で集中的に交通事故が発生している。

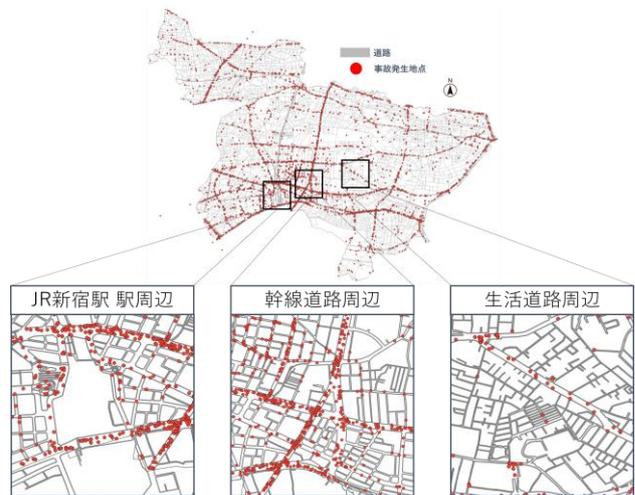


図-1 新宿区における交通事故の発生状況

(2) 対象地における取締り活動の現状

警察の取締り活動は街頭活動と違反検挙活動の 2 つに分けられる。

(a) 街頭活動：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。

(b) 違反検挙活動：実際に発生した速度違反や駐車違反などの交通違反を警察官が検挙する活動。

本研究ではデータの都合上、巡回する活動は含めず、道路上や交差点上などにおいて、定点で実施している街頭活動のみを対象とした。

新宿区における平成 26～30 年までの取締り活動の累計実施時間を表-2 に、実施状況をカーネル密度分布として図-2 に示す。街頭活動は、交差点配置が全体の 96% を占め、1 回の活動時間は平均 1 時間である。また、活動地点は特定の範囲に集中している。したがって、本研究では取締り活動を 1 種類の活動として扱う。

表-2 街頭活動の活動回数と活動時間

配置場所	活動回数 (回)	活動時間 (h)
街頭配置	1,218	1,191
交差点配置	16,970	17,639
計	18,188	18,830

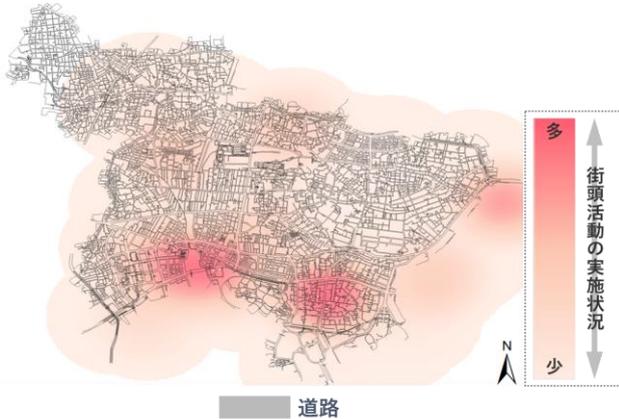


図-2 新宿区における街頭活動の実施状況

(3) 対象地におけるヒヤリハットの現状

新宿区における、平成30年4～12月までのヒヤリハットの発生状況を図-3に示す。ただし、データの都合上、道路外にプロットされたヒヤリハットは、最も直線距離が近い道路縁上に移動させている。図-3より、ヒヤリハットは幹線道路などの交通量の多い道路で頻発していることが分かる。データ収集用光ビーコンの設置場所が国道などの幹線道路であるため、生活道路内のヒヤリハットの受信数が幹線道路内と比較して少ないことが考えられる。また、車載器から道路側の光ビーコンに情報を受け渡すアップリンクは全交通量分を把握できるわけではない。しかし、東京都におけるアップリンクの回収率に関する既存文献及び参考資料は存在しない。そこで、本研究では岩岡ら¹³⁾の研究で使用された、平成28年の神奈川県のアップリンク回収率10%を使用して分析を行う。

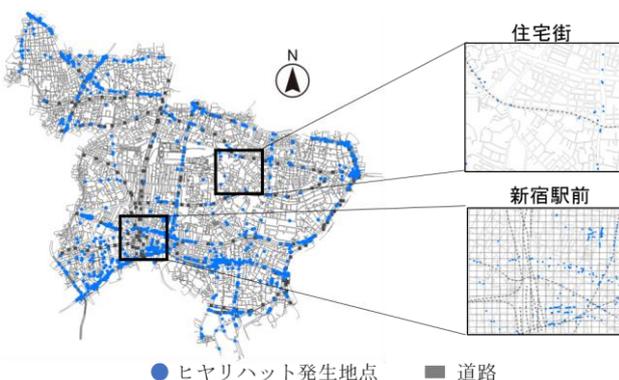


図-3 新宿区におけるヒヤリハットの発生状況

5. 逆強化学習による事故リスク予測モデルの構築

本研究では、逆強化学習を活用して事故リスク値の予測をする。従来の交通事故の発生リスクに関する分析は重回帰分析などの統計的手法を主に用いられている。従来手法と比較して逆強化学習が優れている点は、変数選択が不要で、データ更新が可能な点である。本研究では、交通事故とヒヤリハットの発生時間と地点の2変数のみを用いて事故リスク値を算出しているが、今後、交通量や天候などの様々なデータを説明変数として事故リスク値を評価する際に、変数選択が不要な点で従来手法と比較して有効である。

(1) 逆強化学習の最大エントロピー法の概要

本研究では、最大エントロピー法という手法を用いて逆強化学習モデルを構築する。最大エントロピー法は各状態における最適な行動が未知であっても、行動軌跡を入力すれば最適な報酬関数を算出可能な利点を有する。ここで、交通事故やヒヤリハットは発生リスクが大きい時間・地点で発生していると仮定する。また、周辺のメッシュ間の空間的な相互作用を分析可能なため、交通事故やヒヤリハットが発生した地点から、どのように交通事故の発生リスクが波及するか把握することが可能である。

最大エントロピー法は式(1a)に示すように、行動軌跡 ζ から報酬関数 R を仮定し、パラメータである θ が一定値に収束するまで反復計算を行い、値を更新する。また、 f_{ζ} は入力された行動軌跡の集合を表す。

$$R(\zeta|\theta) = \theta^T f_{\zeta} \quad (1a)$$

ここで反復計算においては以下の式(1b)に示す対数尤度関数 $L(\theta)$ を最大化する θ を算出する。

$$L(\theta) = - \sum_i \log P(f_{\zeta_i}|\theta) \quad (1b)$$

ここで尤度関数 $P(f_{\zeta_i}|\theta)$ は特定の軌跡 ζ_i が観測される確率を表している。また、対数尤度関数の勾配は式(1c)のように算出される。

$$\frac{\partial L(\theta)}{\partial \theta} = \frac{1}{M} \sum_{i=1}^M f_{\zeta_i} - \sum_{i=1}^M P(\zeta_i|\theta) f_{\zeta_i} \quad (1c)$$

この勾配を用いて式(1d)のように θ を更新する。ここで α は外生的に与える学習率である。

$$\theta_{new} = \theta_{old} - \alpha \frac{\partial L(\theta_{old})}{\partial \theta} \quad (1d)$$

(2) 取締り活動予測モデルの概要

予測モデルの学習フローを図-6 に示す。Q 値が一定値に収束するまで学習が継続され、Q 値は常に更新される構造となっている。

さらに、式(2)のQ学習における行動価値関数の更新式を基にモデルを構築するために、行動・報酬・状態の3要素を以下のように定義する。

(a) 行動a：取締り活動を行う対象メッシュ

対象地 400 メッシュの内、過去 5 年間に交通事故が一度でも発生、並びに取締り活動を実施した計 267 メッシュを取締り活動の対象地とする。下田ら¹⁵⁾の研究より、活動対象地を中心に式(3a)、(3b)の空間的波及効果と時間的波及効果に基づき、周辺メッシュの取締り効果値を減衰波及させる。なお Elvik¹⁶⁾の研究に基づき、1 時間の街頭活動による対象地の交通事故抑止効果を 16%減少と定義する。

$$E_n = \frac{T}{0.4\sqrt{2\pi}} \exp\left(-\frac{(2.45x_n)^2}{2}\right) \quad (3a)$$

$$E_t = \frac{E_n}{0.4\sqrt{2\pi}} \exp\left(-\frac{x_t^2}{3}\right) \quad (3b)$$

- E_n : n番メッシュにおける取締り効果値
- T : 基準メッシュにおける取締り効果値 (16%)
- x_n : 基準メッシュからの道路距離^{*}[km]
- E_t : 時間t週の当該メッシュの取締り効果値
- x_t : 基準からの週目[週]
- ^{*}基準メッシュから対象メッシュまでの直線距離ではなく、実際に移動する際に通る道のり

- (b) 報酬r：各メッシュの事故リスク値の減少量の和
- (c) 状態s：事故リスク値

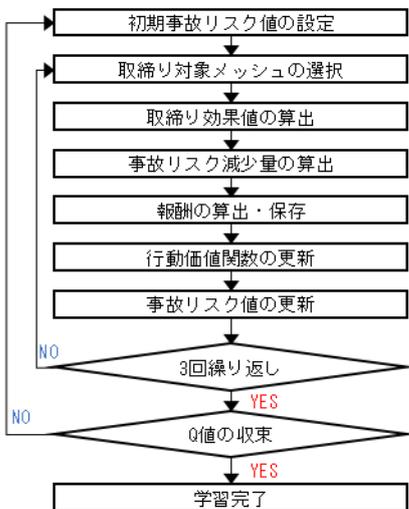


図-6 予測モデルの学習フロー

(3) 予測モデルのパラメータ設定

予測モデルの各種パラメータ設定の内容を表-3に示す。

取締り活動周期	3週間 (3周期)
取締り効果値	活動対象メッシュでは事故リスクが 16%減少し、対象メッシュを中心に空間的・時間的波及効果を受け、周辺メッシュに波及する。
学習回数	1,000,000回
学習率 α	0.01
割引係数 γ	0.9
行動選択方策	ϵ -greedy法

ここで、 ϵ -greedy 法とは ϵ ($0 < \epsilon < 1$) の確率でランダムに行動を選択させ、それ以外の $1-\epsilon$ の確率で行動価値関数 Q が最大となる行動を選択させる方法である。 ϵ の値は式(4)に示す逆ロジスティック関数に基づき試行回数に応じて減衰していく。すなわち、学習の初期段階ではランダムに行動させ、様々なパターンの行動を経験し、学習の終盤では経験した行動パターンの中から最適な行動を選択できるようにしている。

$$\epsilon = c - \frac{c - K}{1 + e^{a-bx}} \quad (4)$$

- $a = 6,$ $b = 0.00001$
- $c(\text{上限}) = 1,$ $K(\text{下限}) = 0.1$

(4) 予測モデルの実装結果

対象地における 3 週間分の最適な取締り活動場所を図-7、図-8、図-9 に示す。1 周期ごとに行動価値関数が高い上位 5 メッシュ分を色付けした。行動価値関数が高いメッシュとは、その地点で取締り活動を行えば、事故抑止効果が高いメッシュである。図-7～図-9 を見ると、すべての周期において新宿駅東側のメッシュで行動価値が大きくなっている。対象範囲内では、JR が南北方向に通過していることから、東西を行き来する道路が限定される。また、取締り効果は道路距離をもとに空間的な波及効果が得られる。したがって、交通事故やヒヤリハットが比較的多く、道路網が密である新宿駅東側のエリアで取締り活動が高く評価されたと考えられる。加えて、幹線道路上のメッシュで行動価値が大きくなっている。図-5 の事故リスク値を見ると、交通事故の発生が多い幹線道路上のメッシュの事故リスク値が高くなる傾向があるため、取締り活動が高く評価されたと考えられる。

次に、過去の取締り活動場所と、図-7～図-9 の結果に基づき取締り効果が高いメッシュを色付けした結果を図-10に示す。

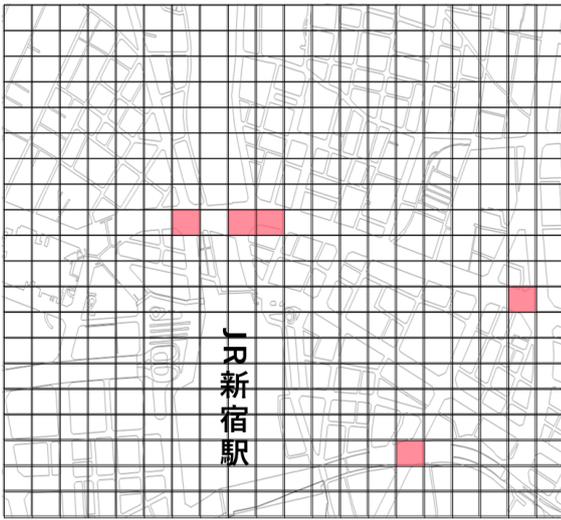


図-7 1周期目の最適取締り活動場所

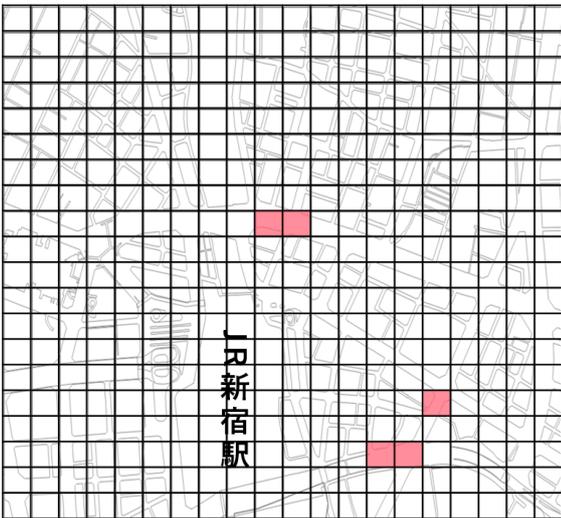


図-8 2周期目の最適取締り活動場所

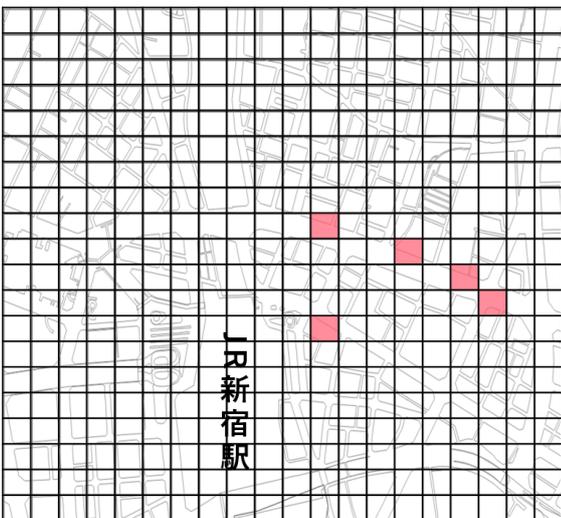


図-9 3周期目の最適取締り活動場所

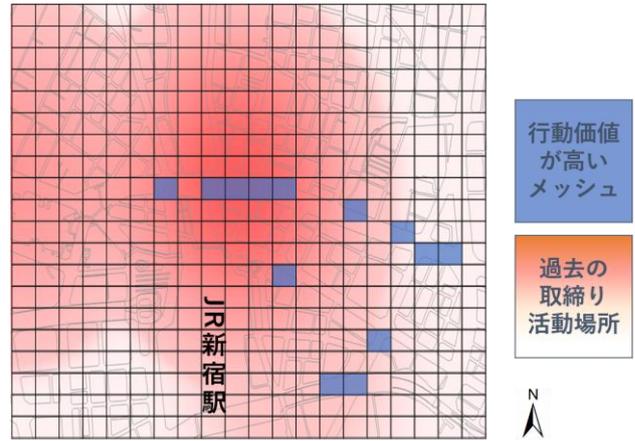


図-10 過去の取締り活動場所と取締り効果の高いメッシュ

(5) 考察

図-10 より、新宿駅北側では過去に取締り活動を行った場所と行動価値関数が高いメッシュが近い場所となった。また、新宿駅東側の大きな幹線道路が交わる交差点での取締りが、効果が高いと推定できる。今後は行動価値関数が高い道路に沿って、取締り活動場所の決定計画を行えば、効果的な取締り効果が見込めると考えられる。

7. おわりに

本研究では AI の一種である逆強化学習を活用し、過去の交通事故やヒヤリハットデータから、交通事故の発生危険度を表す事故リスク値を算出する予測モデルを構築した。その結果、一定の精度を確保でき、Q 学習モデルの予測精度も向上し、最適な取締り活動場所の提案を可能にした。しかし、更なる精度向上や、対象範囲・期間の拡大といった課題がある。

本研究では、取締り効果値を一律で 16% 減少と仮定し、Q 学習モデルに外生的に与えて分析を行った。逆強化学習モデルでは、算出した状態価値を用いて事故リスク値の変化量を求められるため、取締り効果値の算出にも活用できる。今後は、Q 学習モデルに使用するパラメータも、逆強化学習により対象地に合わせた設定を行う必要がある。

謝辞：本研究を進めるにおいて、警視庁からデータの提供を受けました。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 2 年中の交通事故死者数について」, 交通局交通企画課, pp.1-2, 2021.
- 2) 内閣府：第 11 次交通安全基本計画, 中央交通安全対策会議, pp.6-13, 2021.
- 3) 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, 交通工学論文
集 (特集号), Vol.8 (査読審査中), 2022.
- 4) Oei Hway-liem: Automatic Speed Management in the
Netherland, 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) Predrag Stanojevic, Dragan Jovanovic, Timo Lajunen: In-
fluence of traffic enforcement on the attitudes and behavior
of drivers, Accident Analysis and Prevention, Vol.52,
pp.29-38, 2013.
 - 8) 小谷ゆかり, 鈴木崇児, 秋山孝正, 武藤慎一: 交差
点での類型別事故率推計モデルに基づく交通安全対
策の評価 手法, 土木計画学研究論文集, Vol.18,
no.5, pp.971-978, 2001.
 - 9) 出井雅也, 山脇正嗣, 寺奥淳, 田中秀人, 森本章
倫: ディープラーニングを用いた交通事故の予測モ
デルに関する研究, 第 40 回交通工学研究発表会論文
集, 2020.
 - 10) Christopher J. C. H. Watkins, Peter Dayan: Q-learning,
Machine Learning, Vol.8, pp.279-292, 1992.
 - 11) Lazhar Khriji, Farid Touati, Kamel Benhmed and Amur
Al-Yahmedi: Mobile robot Navigation Based on Q-Learn-
ing Technique, International Journal of Advanced Robotic
Systems, Vol.8, No.1, pp.45-51, 2011.
 - 12) Hirakawa T., Yamashita T., Tamaki T., Fujiyoshi H.,
Umezu Y., Takeuchi I., Matsumoto S., Yoda K.: Can AI
predict animal movements? Filling gaps in animal trajec-
tories using inverse reinforcement learning, Ecosphere,
Vol. 9, No. 10, pp. e02447, 2018.
 - 13) 岩岡浩一郎, 弘津雄三, 新倉聡: 光ビーコンから収
集されるアップリンクを活用した一括最適化制御の
適用, 交通工学論文集, Vol.2, No.2, pp.1-9, 2016.
 - 14) Christopher J. C. H. Watkins: Learning from delayed re-
wards, PhD Thesis, University of Cambridge, England.
 - 15) 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.
 - 16) Rune Elvik, Truls Vaa: Police Enforcement and Sanctions,
The Handbook of Road Safety Measures, pp.970-973,
2004.

(Received ???)

(Accepted ???)

A STUDY ON TRAFFIC ENFORCEMENT ACTIVITIES USING INVERSE REINFORCEMENT LEARNING

Takumi NARUSE, Masashi YAMAWAKI, Jun TERAOKU and Akinori MORIMOTO

The occurrence of traffic accidents in Japan has continued to decrease, but the extent of the decrease has been gradually decreasing. The 11th Basic Plan for Traffic Safety of the Cabinet Office has set a goal of reducing the number of fatalities in a 24-hour period to 2,000 or less by 2025, and further efforts to curb traffic accidents are needed to achieve this goal. In recent years, there has been rapid progress in the development of technologies that utilize artificial intelligence (AI) to analyze big data and predict various events. In the field of traffic safety, it is expected that AI can be used to predict the occurrence of traffic accidents and implement efficient enforcement activities. In this study, we developed a model to quantify the risk of traffic accidents by analyzing probe data using inverse reinforcement learning, a type of AI. In addition, by using the model together with previous research, we were able to propose the optimal enforcement location. As a result, we obtained knowledge on how to implement effective enforcement activities in the future.