

# 交差点諸元による 特殊車両の折進可否判定モデルの構築

島津 弘輝<sup>1</sup>・坪田 隆宏<sup>2</sup>・中谷 勇太<sup>3</sup>・塩見 康博<sup>4</sup>

<sup>1</sup> 非会員 愛媛大学 工学部工学科 (〒790-8577 愛媛県松山市文京町 3 番)

E-mail: shimazu.hiroki.19@cee.chime-u.ac.jp

<sup>2</sup> 正会員 愛媛大学特任講師 大学院理工学研究科 (〒790-8577 愛媛県松山市文京町 3 番)

E-mail: t.tsubota@cee.chime-u.ac.jp (Corresponding Author)

<sup>3</sup> 非会員 愛媛大学 工学部工学科 (〒790-8577 愛媛県松山市文京町 3 番)

E-mail: zhongguyongtai283@gmail.com

<sup>4</sup> 正会員 立命館大学教授 理工学部環境都市工学科 (〒525-8577 滋賀県草津市野路東 1-1-1)

E-mail: shiomi@fc.ritsumeai.ac.jp

近年、物流産業においては大型車両による輸送の効率化が進められており、特殊車両の通行許可申請件数も増加傾向にある。この手続きに伴う運送事業者・道路管理者の負担軽減と審査の迅速化を目指し、通行可否審査の自動化が求められている。本研究では、交差点諸元と特殊車両の折進可否の情報をデータベース化し、折進可否の自動判定モデルを構築した。Google map 等から人手で読み取った交差点諸元を用いて、各諸元値と折進可否に関する基礎集計を行った結果、交差点面積や道路幅員、折進角度などの諸元値と折進可否の間に明確な関係を見出すことができた。続いて、折進可否判定モデルの構築を行った。複数の手法を比較・検討した結果、ニューラルネットワークモデルが最も高い精度を示し、車両分類 0 と 1 の両方について 0.7 を超える判定精度となった。しかしながら、適合率による評価では十分な精度が得られず、今後データの拡充等による精度向上が必要となる。

**Key Words:** *oversize-overweight vehicle, intersection turns, neural network, decision tree, random forest*

## 1. はじめに

我が国の経済活動を支える物流業界においては、高齢化に伴うドライバー数の減少や、ネットショッピングの普及による配達量の増加などによる、人手不足が問題となっている。この状況への対策の一つに、車両の大型化による効率的な輸送手段の導入が挙げられる。一方で、道路は一定の規格の車両が安全・円滑に通行することを目的に造られており、車両寸法や重量に関する一般的制限値を超えるような特殊車両（以下、“特車”）の通行に際しては、道路構造と車両諸元との関係を踏まえた事前審査が必要となる。審査の際には、特殊車両の通行許可審査に必要な基礎資料を収録した道路情報便覧システムが活用される。同システムには、特殊車両の通行を想定した道路の構造や交通条件など、予め現地調査等を行って得た情報を全国的に収録されており、道路情報便覧に収録された道路で、許可限度値以内の車両であれば、道路管理者での通行許可審査が迅速に実施可能になる。しかしながら、道路情報便覧に未収録の道路を含む通行経

路の審査においては未収録箇所に車両の軌跡図を当てはめて折進可否を判定するなどの手作業が必要となり、迅速な審査の妨げとなる。その為、未収録道路に対する折進可否判定の自動化技術の導入が求められている。

そこで、本研究では交差点における特車の折進可否と通行条件を、交差点平面図から読み取った交差点構造の諸元と併せてデータベース化し、これに機械学習手法を適用することで、交差点諸元を入力して各設計車両の方向別折進可否と通行条件を判定するモデルを構築する。

## 2. 交差点における折進可否と通行条件の考え方

### (1) 本研究における折進可否判定の設定方法

#### a) 道路情報便覧における通行条件

特殊車両が道路を通行する際には特殊車両通行許可申請が必要となり、審査の結果、道路管理者が通行を認めるときは、通行に必要な条件を附して許可する。この条件を通行条件という。通行条件には重量に関する条件と

表-1 道路情報便覧の通行条件<sup>1)</sup>

区分記号	個(個別審査)	C	B	直
内容	さらに精度の高い技術的審査を行う	徐行及び当該車両の前後に誘導者を配置することを条件とする	徐行を条件とする	通常走行が可

寸法に関する条件の 2 種類が存在し、交差点を通行する場合の通行条件は寸法に関する条件による。表-1 に通行条件の区分記号と内容を示す。通行条件は「個(個別審査)」「C」「B」「直」の 4 つに区分されている。交差点における通行条件の情報は道路情報便覧表示システム<sup>1)</sup>から閲覧することができる。

道路情報便覧に記載されているこれらの通行条件は、基本的には交差点平面図に車両の走行軌跡図を重ね合わせることで、車両の規格と交差点の物理的な構造を考慮して判定されている。しかしながら、「個(個別審査)」の折進については交通規制等の交差点構造に関わらない条件を考慮して設定される場合も存在する。本研究では、交差点構造の諸元に基づく折進可否の判定モデルの構築を目指しているため、道路情報便覧に記載されている「通行条件」とは別に、次節に説明する「折進可否」を車両分類毎に設定し、これを用いて折進可否判定モデルを構築する。ここで、車両分類とは車両寸法による特車の分類区分を指し、車両の幅と長さにより分類される。交差点における旋回軌跡の相違により 4 分類：0, I, II, III が設定されており、交差点の折進可否はこれらの車両分類毎に判定を行う。

**b) 本研究で扱う折進可否判定**

本研究では、道路情報便覧の調査資料作成マニュアル<sup>2)</sup>に記載されている、交差点構造に関する 2 つの分類値：分類値 1 と分類値 2 に基づいて交差点の折進可否を判定する。分類値 1 とは、車両分類 0 の折進可否を分類するものであり、表-2 の上段に示す 3 分類が設定されている。一方、分類値 2 とは車両分類 I, II, 及び III の折進可否を分類するものであり、表-2 の下段に示す 5 分類が存在する。いずれの分類値も、各車両分類の車両の軌跡図を当該交差点の平面図に重ね合わせることで、どの車両が折進可能か否かを判定する。具体的な分類値の決定方法は、車両分類で大きいものから順に車両軌跡図を交差点平面図に当てはめて判定されている。

このような手順により設定された分類値 1、および分類値 2 の組み合わせにより車両分類ごとの折進可否判定の定義を行った結果を表-3 に整理する。なお、本研究における折進可否判定結果は、道路情報便覧における通行条件の分類記号に倣い、「×」「B」「C」で整理している(表-4)。

表-2 分類値一覧表<sup>1)</sup>

分類値名	分類値
分類値 1	01：車両分類 0 の車両が対向車線を侵さずに折進できる 11：車両分類 0 の車両が対向車線を侵して折進できる 91：車両分類 0 の車両が対向車線を侵しても折進できない
分類値 2	02：車両分類Iの車両が対向車線を侵さずに折進できる 12：車両分類Iの車両が対向車線を侵して折進できる 13：車両分類IIの車両が対向車線を侵して折進できる 14：車両分類IIIの車両が対向車線を侵して折進できる 94：車両分類IIIの車両が対向車線を侵しても折進できない

表-3 分類値と車両分類毎の折進可否判定の対応

分類値組み合わせ		車両分類ごとの折進可否判定			
分類値 1	分類値 2	0	I	II	III
01	02	B	B	B	B
11	02	C	B	B	B
11	12	C	C	B	B
91	12	×	C	B	B
91	02	×	B	B	B
91	13	×	×	C	B
91	14	×	×	×	C
91	94	×	×	×	×

表-4 折進可否判定区分

区分記号	×	C	B
内容	対向車線を侵しても折進できない	対向車線を侵して折進できる	対向車線を侵さず折進できる




図-1 折進可否判定モデルの入出力概要

**3. 折進可否の自動判定モデル概要**

**(1) 判定モデルの考え方**

本研究では図-1 の概念図に示すように判定対象の折進に関する交差点諸元の情報を入力とし、当該折進について折進可否判定結果を出力する自動判定モデルの構築を目指す。折進可否判定結果は車両分類毎に異なる為、自動判定モデルも車両分類毎に構築する。モデルの入力

に使用する交差点諸元の情報の詳細については次章にて説明する。また、自動判定モデル構築に使用する手法については複数のモデル手法から適したものを選定するものとし、具体的には決定木モデル、ランダムフォレストモデル、及びニューラルネットワークモデルを検討する。

## (2) 検討する判定モデルの手法

### a) 決定木モデル

決定木モデル（以下，“DT”）とはデータの分類を行う機械学習手法の1つであり、特定の特徴が顕著に現れるようなデータの集合を見つけ、その分類ルールの生成を行う<sup>4)</sup>。具体的には、目的変数と説明変数から構成されるデータセットに対して、目的変数の特徴が可能な限り偏在するような説明変数の閾値を設定することでデータの分類を行う。本研究では折進可否（目的変数）に最も影響すると考えられる交差点諸元（説明変数）の変数選択と閾値の設定を行うことで、自動判定モデルの生成を行う。

### b) ランダムフォレスト

ランダムフォレスト（以下，“RF”）とは、ランダムに選択された説明変数と目的変数から構築される、複数の決定木の結果を併せてクラス分けを行う分類アルゴリズムである<sup>5)</sup>。複数の DT モデルの結果から多数決などの総意を取ることで高精度な分類を可能とするアンサンブル法の一種とされる。RF は、一般に学習計算が早いこと、そしてランダムに抽出された学習データで構築された複数の DT の総意を用いることから、過学習を抑制でき、モデルの汎化能力が高いとの特長を持つ。

### c) ニューラルネットワークモデル

ニューラルネットワークモデル（以下，“NN”）は、入力層、隠れ層、出力層から成る多層構造を持ち、各層のニューロンが全結合ネットワークを構成する<sup>6)</sup>。この人間の神経細胞、すなわちニューロンの仕組みを模したネットワークに対して、目的変数と説明変数から構成される学習データを与えることで、データに含まれる特長を学習し、高精度なデータ分類が可能となる。

## (3) 評価指標

本研究では、「×」、「C」、「B」の3値分類を扱う。モデルによる分類結果と真の分類との組み合わせは、4種類存在し、それぞれ TP：真陽性、FN：偽陰性、FP：偽陽性、TN：真陰性となる。これらを用いて計算される、適合率と再現率の調和平均値である F1 スコアを用いてモデルを評価する。

## 4. 交差点諸元データの収集と基礎集計

### (1) 分析対象地域

本研究では123交差点のデータを使用してモデルの構築を行う。具体的には香川県高松市内の93交差点と、愛媛県松山市の28交差点、佐賀県佐賀市の1交差点、及び長崎県諫早市の1交差点となっている。分析対象交差点は、道路情報便覧に収録済みの交差点のうち、研究実施者が必要に応じて現地調査可能な四国地域を中心に選定した。佐賀県と長崎県から選定された2交差点については、交差点形状などの偏りを緩和する目的で選定した。

### (2) 交差点諸元データの収集

分析に使用する交差点諸元の定義を説明する。なお、計測方法は Google map の計測機能を基本としつつ、必要に応じて Google Street View による観測、あるいは現地調査を実施した。

#### a) 交差点面積

交差点の大きさの指標として交差点面積を使用する。交差点面積は、交差点構造を数値化した既往の事例<sup>6)</sup>を参考に、停止線で囲まれた領域の面積とする。

#### b) 流入/流出停止線間距離

交差点の大きさを表す別の指標として停止線間距離を計測する。三差路で対向する停止線が存在しない場合には、突き当りの白線までの距離を停止線間距離として計測する。停止線間距離は着目する折進に対して、流入方向と流出方向の2種類を計測する。

#### c) 流入/流出幅員

対象交差点へ流入する道路幅員を流入幅員、流出する道路幅員を流出幅員と定義し、計測する。流入幅員については、流入方向の全車線の幅員と、対象とする折進が使用する一車線の幅員の2種類を、流出幅員は流出方向の全車線の幅員を計測する。なお、車線区分の存在しない細街路については、道路幅員全体を流入/流出幅員として計測する。

#### d) 中央分離帯/歩道の侵入可否

折進可否判定には、対向車線、あるいは歩道を侵して折進できるか否かが重要となる。そこで、中央分離帯（以下，“中分”）、および歩道部への侵入可否を Google Map のストリートビュー機能を用いて確認し、データベース化する。侵入できる場合は1を、縁石や街路樹等により侵入できない場合は0とするようなダミー変数を用いて定義する。図-2に示す例は、中央分離帯は植樹により、歩道部は防護柵により折進の際に侵入不可となる構造の場合である。



図-2 侵入不可の中央分離帯と歩道部例




図-3 停止線間距離比率と交差点形状の関係

e) 折進角度

Google map により、流入道路と流出道路の方位を計測し、折進角度を計測する。

f) 右左折の区分

右折と左折で折進に要する面積が異なることから、判定対象の折進の方向を入力する。

g) 停止線間距離比率

流入停止線間距離と流出停止線間距離の比率を交差点の形状の代表値として入力する。図-3 に示すように停止線間距離の比率によって交差点の形状を表現する。

(3) 基礎集計

前述した交差点諸元と折進可否判定の関数に関する基礎集計結果を示す。基礎集計では、各諸元を階級別に区分し、各階級に含まれる折進群について折進可否判定区別の割合を算出している。車両分類は0,II,IIIの4種類が存在するが、車両分類IIとIIIについては大半の折進において「B」判定となり、交差点諸元と折進可否の関係は不明瞭となる。したがって、車両分類0とIIに着目して基礎集計結果を整理する。なお、本節で整理する基礎集計結果は、全ての諸元に関するものではなく、折進可否との関係が認められる諸元に限定する。

a) 交差点面積

交差点面積の階級毎に、各階級に含まれる折進可否判定区分の割合を整理した集計結果を図-4 に示す。車両分類 0,I ともに交差点面積が増加するほど B 判定の割合が増加し、逆に×判定が減少していることが読み取れる。この傾向は特に車両分類 0 において顕著に認められる。




図-4 判定割合 (交差点面積)




図-5 判定割合 (流入幅員)




図-6 判定割合 (流出幅員)




図-7 判定割合 (折進角度)




図-8 判定割合 (停止線間距離比率)

b) 流入/流出幅員

流入幅員の基礎集計の結果 (図-5) を見ると、車両分類 0,I ともに流入幅員の増加に伴い、B 判定の割合が増加傾向にあることが分かる。また、同様に流出幅員に関する基礎集計の結果 (図-6) においても、車両分類 0,I ともに流出幅員が増加するほど B 判定の割合が増加しており、その傾向は流入幅員の場合よりも明瞭に確認できる。

c) 折進角度

折進角度の基礎集計の結果(図-7)についても、車両分類 0, I ともに折進角度が増加するにつれて B 判定の割合が増加し、×判定の割合が減少していることが確認できる。

d) 停止線間距離比率

停止線間距離比率の基礎集計結果(図-8)については、明確な傾向とは言い難いが、車両分類 0, I ともに比率が 1 に近づくほど、すなわち交差点の形状が正方形に近づくに伴い、B 判定の割合が増加していることが読み取れる。

5. 折進可否判定モデルの構築

(1) 入力データの処理法

モデルの構築に使用する入力データ一覧と処理方法を表-5に示す。入力データのうち、名義尺度データについてはダミー変数化処理を施し、交差点面積、折進角度等のデータは比例尺度であるので、モデルへの入力の際には、データのスケールを整える目的で標準化処理を行う。

表-5 入力データの一覧と処理方法

データ名	処理方法
国道(流入)	ダミー変数化 (1: 国道)
主要地方道(流入)	ダミー変数化 (1: 主要地方道)
一般都道府県道(流入)	ダミー変数化 (1: 正一般都道府県道)
市町村道(流入)	ダミー変数化 (1: 市町村道)
国道(流出)	ダミー変数化 (1: 国道)
主要地方道(流出)	ダミー変数化 (1: 主要地方道)
一般都道府県道(流出)	ダミー変数化 (1: 正一般都道府県道)
市町村道(流出)	ダミー変数化 (1: 市町村道)
交差点面積(m <sup>2</sup> )	標準化
停止線間距離(流入)	標準化
停止線間距離(流出)	標準化
停止線間距離(流入距離÷流出距離)	標準化
車線区分の有無(流入側)	ダミー変数化 (0: 無, 1: 有)
車線区分の有無(流出側)	ダミー変数化 (0: 無, 1: 有)
流入幅員(全)(m)	標準化
流入幅員(1)(m)	標準化
流出幅員(m)	標準化
右左折	ダミー変数化(0: 左折, 1: 右折)
中分侵入可否	ダミー変数化 (0: 不可, 1: 可)
歩道侵入可否	ダミー変数化 (0: 不可, 1: 可)
一方通行による進入可否	ダミー変数化 (0: 進入不可, 1: 進入可)
折進角度(deg)	標準化
進入禁止	ダミー変数化 (0: 無, 1: 有)

(2) モデル構造の検討

折進可否自動判定モデルの検討に使用する各モデル: 決定木モデル, ランダムフォレスト, 及びニューラルネットワークモデルの構築に際しては、モデルの汎化性能向上のためにハイパーパラメータのグリッドサーチと交差検証を実施する。モデルの評価比較には交差検証時の正解率 (Accuracy) を用いる。交差検証時に最も高い正解率が得られたハイパーパラメータの組み合わせにより最終モデル構造を決定し、正解率、適合率、再現率、およびF値により判定精度を評価する。

グリッドサーチでは、探索対象のハイパーパラメータ候補のリストを準備し、その全ての組み合わせを用いて多数のモデルを構築し、最適な性能を示すパラメータの組み合わせを見つけ出す探索手法である。各手法の探索に使用したパラメータリストを表-6, 表-7, 表-8 に整理する。また、交差検証については、5 分割交差検証を実施した。

(3) モデル構築結果

a) 使用データ概要

前述したように、合計 123 交差点から収集した 739 の折進を対象にモデルの構築を行う。ホールアウト法により、学習データとして 520 折進データ、テストデータとして 219 の折進データを分割した。学習用の 520 折進を利用し、5 分割交差検証によるハイパーパラメータのグリッドサーチを実施した。車両分類 II と III については、ほぼ全ての折進に対して B 判定が得られているため、モデル構築の対象からは除外し、本節では車両分類 0 と I についての折進判定モデル結果を整理する。

表-6 決定木の検討パラメータリスト

パラメータ	値
最大終端ノード数	2, 4, 6, ... (2刻み) ..., 32
木の最大深度	1, 2, 3, ... (1刻み) ..., 12

表-7 ランダムフォレストの検討パラメータリスト

パラメータ	値
決定木の数	10, 20, 30, ... (10刻み) ..., 100
木の最大深度	1, 2, 3, ... (1刻み) ..., 12
選択する特徴量の数	4, 8, 12, 16, 20

表-8 ランダムフォレストの検討パラメータリスト

パラメータ	値
隠れ層の数	1層, 2層, 3層
ユニット数	4, 8, 16, 32
ドロップアウト	0, 0.05, 0.1, ... (0.05刻み) ..., 0.5
学習率	0.01, 0.001, 0.0001
活性化関数 [固定]	ReLU関数, softmax関数(出力層)
最適化手法 [固定]	Adam
損失関数 [固定]	多クラス交差エントロピー

b) 評価指標の比較

車両分類 0 を対象に構築した判定モデルの評価指標を図-9 に示す。正解率、再現率、及びF 値においてニューラルネットワークモデルが最も高い値を示すとの結果が得られた。適合率についてはランダムフォレストが最も高い結果が得られており、また何れのモデルも同指標は 0.8 前後の結果となり、概ね正確な予測できていることが分かる。しかしながら、再現率に目を向けると決定木とランダムフォレストについては 0.5 を下回っており、判定の取りこぼしが多いことが分かる。一方、ニューラルネットワークモデルは適合率と再現率の調平均である F 値が最も高く、また正解率も 0.72 と高い結果が得られていることから、折進可否の自動判定モデルとして最も適していると考えられる。

図-10 には車両分類 I を対象とする判定モデルの評価指標を示す。4 つの評価指標の全てについてニューラルネットワークモデルが最も高い値を示すとの結果が得られた。また、車両分類 0 の場合と比較して、正解率については何れのモデルにおいても車両分類 I の方が高い結果が得られている。特に、ニューラルネットワークの正解率は 0.76 に達しており、良好な判定精度が得られていると判断できる。一方、適合率の指標を見ると、車両分類 0 と比較して車両分類 I では極めて値が低下する、との結果が得られた。




図-9 評価指標の結果比較 (車両分類0)




図-10 評価指標の結果比較 (車両分類I)

決定木モデル		正解		
		×	C	B
予測	×	4	0	0
	C	28	95	46
	B	0	10	36

ランダムフォレストモデル		正解		
		×	C	B
予測	×	2	0	0
	C	29	104	48
	B	1	1	34

ニューラルネットワークモデル		正解		
		×	C	B
予測	×	9	1	1
	C	23	101	33
	B	0	3	48

図-11 モデル毎の混同行列 (車両分類0)

決定木モデル		正解		
		×	C	B
予測	×	0	0	0
	C	14	81	38
	B	2	20	64

ランダムフォレストモデル		正解		
		×	C	B
予測	×	0	0	0
	C	13	85	38
	B	3	16	64

ニューラルネットワークモデル		正解		
		×	C	B
予測	×	0	0	0
	C	16	93	28
	B	0	8	74

図-12 モデル毎の混同行列 (車両分類I)




図-13 学習データの構成割合 (グラフ内の数字はデータ数を示す)

車両分類 I における適合率の低下について、混同行列を用いて説明する。図-11 には車両分類 0 の各モデルの混同行列を、図-12 には車両分類 I についての混同行列を示す。車両分類 I については、何れのモデルについても×の判定を出力できておらず、C や B に誤判定してしまう折進が多い事がわかる。これにより、車両分類 I においては適合率が極端に低下する、との結果となった。

このように、×判定の判定精度が極めて低くなる一因として、学習データの不足が挙げられる。図-13 に学習データに含まれる 520 折進の中の折進可否判定構成割合を示す。車両分類 0 と車両分類 I に共通して、×判定の折進が極めて少ないことが分かる。特に車両分類 I の車両については 20 折進のみしか含まれておらず、モデル精度向上には学習データの拡充が必要であると考えられる。

## 6. おわりに

本研究では、主に高松市と松山市の交差点を対象に、交差点諸元と折進可否の情報を収集、データベース化し、折進可否の自動判定モデルの構築に向けた検討を行った。Google map 等から人手で読み取った交差点諸元を用いて、各交差点諸元値と折進可否判定割合に関する基礎集計を行った結果、交差点面積や道路幅員、折進角度など、幾つかの諸元値と折進可否の間に明確な関係を見出すことができた。続いて、折進可否判定モデルの構築を行った。モデル候補として決定木モデル、ランダムフォレスト、ニューラルネットワークモデルの 3 手法を採用し、検討を行った。モデル構築の際は、各手法に対してグリッドサーチと交差検証によりハイパーパラメータを決定した。最終モデルについて、正解率、適合率、再現率、F 値による評価を行った結果、正解率による評価ではニューラルネットワークが最も高い精度を示し、車両分類 0 と I の両方について 0.7 を超える判定精度を示した。しかしながら、適合率による評価では、特に車両分類 I について十分な精度が得られない、という結果となった。混同行列を確認すると、車両分類 I の場合に×判定の出力が困難であることが分かり、×判定に関する学習データの極端な不足がその一因であると考えられる。

精度向上に向けた今後の課題としては、第 1 に学習用

データの更なる拡充が不可欠であると考えられる。今回は 123 交差点から得られる 739 折進を用いて判定モデルの構築を行ったが、特に×判定のための学習データが不足していることから、より多くの折進データを収集する必要がある。

次に、データ収集方法の高度化に関する検討が必要であろう。今回の検討では、Google Earth や Google ストリートビュー等から“人手”で交差点諸元のデータを集めた。折進可否判定モデル構築のためのデータベース作りにおいて人手でのデータ収集は非効率的であるだけでなく、折進可否判定に関わる幾つかの情報を見落としている可能性が考えられる。人手でのデータ収集においては交差点平面図に含まれる多様な情報の全てを抽出することは不可能であり、分析者の判断により有限の要素のみを選択する必要がある為、必然的に限られた諸元を用いてモデル構築を行うことになる。将来的には、交差点平面図等から自動で交差点諸元を読み取り、折進可否と対応付けて学習可能なモデルの構築に向けた検討が望ましい。

**謝辞：**本研究は、国土交通省道路局による道路政策の質の向上に資する技術研究開発：特殊車両の折進可否判定の自動化と特車フリー道路ネットワーク計画手法の研究開発(代表：塩見康博)の一環として実施したものである。ここに記し、謝意を表する。

## 参考文献

- 1) 国土交通省：道路情報便覧表示システム (V1909-190901), 2019.
- 2) 道路交通管理研究会：解説&法令・通達 最新車両制限令実務の手引, 2014.
- 3) 国土交通省：調査資料作成マニュアル(令和 2 年度版), 2020.
- 4) 平井有三：はじめてのパターン認識, 森北出版株式会社, 2012.
- 5) Leo, B. : Random forests, Machine learning, Vol. 45, No. 1, pp. 5-32, 2001.
- 6) 斎藤康毅：ゼロから作る Deep Learning - Python で学ぶディープラーニングの理論と実装, オライリー・ジャパン, 2016.
- 7) 鈴木弘司, 山口大輔, 藤田素弘：大規模交差点における利用者挙動と交錯危険性に関する実証分析, 土木学会論文集 D3 (土木計画学), Vol.67, No.5, pp.I\_1193-I\_1205, 2011.

(2022.9.30 受付)