

交差点部の走行挙動に機械学習を用いた異常運転検知に関する研究

宮内 弘太¹・高田 和幸²

¹ 学生会員 東京電機大学大学院 先端科学技術研究科 (〒350-0394 埼玉県比企郡鳩山町石坂)

E-mail: 18uda02@ms.dendai.ac.jp

² 正会員 東京電機大学 理工学部 (〒350-0394 埼玉県比企郡鳩山町石坂)

E-mail: takada@g.dendai.ac.jp

近年、高度道路交通システムの発展に伴い、車両の性能向上に関心が高まっている。一方で、我が国では、自動車運転者による故意な危険運転や煽り運転、高齢運転者による事故が深刻な社会問題となっている。これらの問題を解決する方法として、事故の発生に結びつく要因を検知し、車両が適切な対応をする技術が必要である。

本研究では、事故の発生場所が多いとされている交差点部の走行挙動に着目し、事故の発生に結びつく要因が表れた時に検知する手法の提案を行う。One Class Support Vector Machine を用いて他の運転者とは乖離した走行挙動が観測された時に異常運転が発生したと仮定し、手法の有効性を検証した。提案した手法を既往研究と比較したところ、検知精度は高く、検知タイミングは最も早く検知できることが確認された。

Key Words: anomaly driving detection, intersection, driving behavior, machine learning

1. はじめに

近年、高度道路交通システムの発展に伴い、車両の性能向上や運転者への利便性の向上、安全性の向上に関心が高まっている。その一方で、わが国では、運転者による故意な危険運転や煽り運転、高齢運転者による事故が深刻な社会問題となっている。これらの事故は、運転者自身だけでなく、周りの運転者や歩行者、自転車などにも多大な影響をおよぼす可能性が考えられる。

運転者の運転操作が必要ない、自動化運転の実現や事故を未然に防ぐ予防安全技術の開発は、この事故を解決する可能性を秘めている。しかし前者は、インフラ整備や人口知能の精度向上、法整備などの課題がある。その為、一般道路への導入は、未だ時間を要することが予想される。後者は、既存の予防安全技術¹⁾では、運転者が故意的に行う危険運転や、加齢によって身体機能や認知機能が低下した高齢運転者による事故の全てを防ぐことは、難しいことが考えられる。

したがって、事故の発生に結びつく要因を検知し、車両が適切な対応する技術開発が必要であると考えられる。その為には、事故の発生に結びつく運転動作が検出された時に、できるだけ早く検知する技術が必要である。

そこで本研究では、事故の発生箇所が多いとされ

ている交差点部²⁾の走行挙動に着目し、周りの運転者と乖離した運転が発生した時に異常運転（事故の発生に結びつきやすい要因）が発生していると仮定し、この異常を検知する手法の提案を行う。

2. 既往研究の整理

走行挙動を用いた異常運転検知は、異常運転と判断された走行挙動データの収集が困難な点から、教師なし学習による分析が多い³⁻⁵⁾。したがって、運転データから異常運転の可否を判断するモデルを作成し、そのモデルから乖離したデータが観測された時に異常運転が発生したと仮定する研究事例が多い。ここでは、既往研究が着目した運転動作、異常度の定義方法について述べる。

例えば、Lampiri⁶⁾は、ホテリング理論を用いて運転者の異常運転検知を試みた。ホテリング理論は、データの平均や分散の分布情報を基に観測値より算出した異常度を用いて検知する方法である。ある直線区間の車両の走行挙動に着目し、その地点での走行挙動の分布化を行った。分布からの乖離度を異常度として定義した。そして、異常度が閾値を越えた時を異常運転として検知することを行った。

Din et al.⁷⁾は、ホテリング理論を拡張した混合正規分布モデルを用いて運転者の異常運転検知を試みた。混合正規分布モデルは、データが複数の分布に

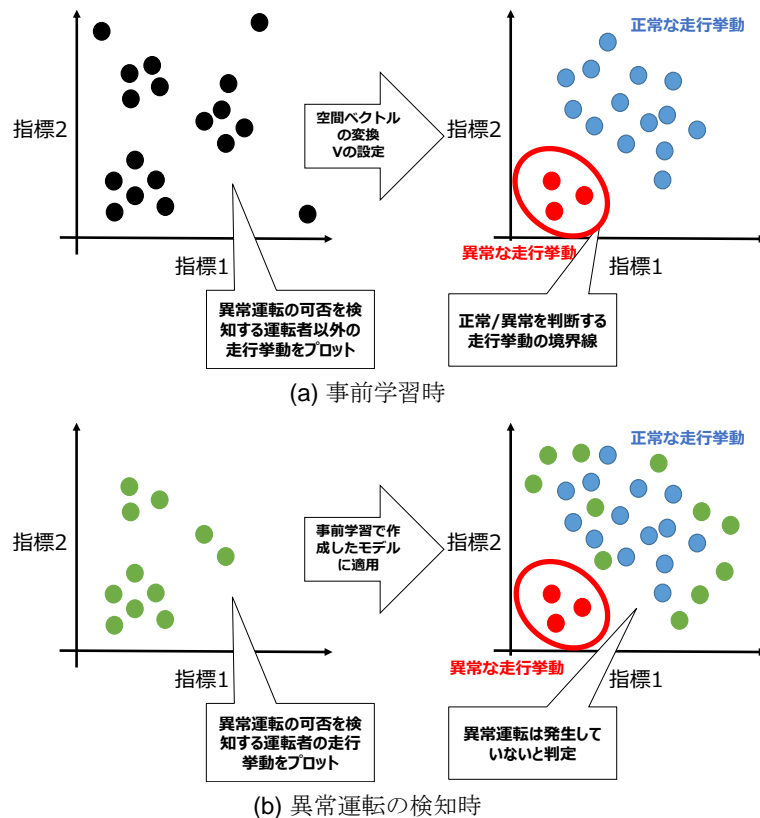


図-1 本研究で提案する OCSVM を用いた異常運転検知の構成

従うと仮定したものである。分布を細分化することにより、異常度の定義方法がさらに明確になり、ホテリング理論よりも異常運転検知の検知精度が上昇することを明らかにした。

Dang et al.⁸⁾は、k 近傍法を用いて運転者の異常運転検知を試みた。k 近傍法は、学習データをベクトル空間上にプロットし、観測データが与えられたとき、そこから距離が近い順に学習データを取得し、多数決の結果から異常運転の可否を判断する方法である。ある区間の交差点部を通過する車両の走行挙動に着目し、観測した走行挙動のデータ間の距離から異常度を定義した。そして、データ間の距離が一定上の閾値を離れた時を異常運転として検知することを行った。

Zhang et al.⁹⁾は、Isolation Forests を用いて運転者の異常運転検知を試みた。Isolation Forests は観測したデータをランダムに分割し、そこから異常度を定義する方法である。ある区間を走行する車両の走行挙動に着目し、GPS センサーで観測した情報を基に運転者の異常運転の有無を検知した。分割したデータ間の距離から異常度を定義した。そして、データ間の距離が一定上の閾値を離れた時を異常運転として検知することを行った。

Ngan et al.¹⁰⁾は、Local Outlier Filter を用いて運転者の異常運転検知を試みた。Local Outlier Filter は、観測された時のデータ密度から異常度を定義する方法である。密度が高い部分は正常な運転、密度が高い部分は異常な運転をしていると判断する。ある区

間の交差点部を通過する車両の走行挙動の着目し、観測した走行挙動のデータ間の密度から異常度を定義した。そして、データ密度が一定上の閾値を離れた時を異常運転として検知することを行った。

以上、走行挙動を用いた異常運転検知に関する既往研究を整理した。その結果、多くの既往研究は、運転者間の走行挙動から異常運転検知を行う方法として、統計的モデルやデータ間の距離、データ間の密度に着目して、異常度を定義している。一方で、交差点部の走行挙動に着目しながらも、直進時の発進や停止の走行挙動のみに留まっているのが現状である。

したがって、本研究が着目する、交差点部の走行挙動における運転者間の乖離度から異常度を定義した研究事例は未だないことが明らかになった。よって、本研究で提案する手法の有効性が検証できれば、新たな予防安全技術としての枠組みとしての活用が期待できる。

3. 異常運転検知手法の開発

(1) OCSVM の概要

本研究では、One Class Support Vector Machine (OCSVM) を用いた異常運転検知手法の提案を行う。図 1 に OCSVM を用いた異常運転検知手法の構成を示す。本手法は二つの部分に分けられる。

まず、事前学習では、図-1 (a) 左図のように、

異常運転を検知する運転者以外で観測された交差点部の走行挙動データをプロットする。ここで、OCSVM が持つカーネル関数と呼ばれる写像変換を行うと、図-1 (a) 右図のように、他のデータと乖離したデータは、原点付近に変換される。この時、原点付近に位置するデータは、異常なデータの可能性が高く、原点から離れるほど正常なデータとなる。

次に、写像変換が行われたデータを基に異常運転であるとみなす割合を決めるパラメータ v を決定する。この v は、0 から 1 の間の値を取るパラメータである。 v の値が決定したら、最後に正常な走行挙動か異常な走行挙動かを分ける識別関数を示す。なお、本研究では、識別関数は RBF カーネル (ガウシアンカーネル) を用いる。

次に、異常運転検知時について述べる。まず、図-1 (b) 左図のように、異常運転を検知する運転者の交差点部の走行挙動をプロットし、写像変換を行う。写像変換後は、事前学習で作成したモデルに当てはめる。

この時、プロットした走行挙動が異常運転を検知する境界線に含まれていれば、その運転者は異常運転をしたと判定する。一方で、境界線に含まれていなければ、その運転者は異常運転を行っていないと判定する。

(2) 異常運転検知に用いるデータ

運転者の走行挙動から異常運転を検知する為には、多くのデータから異常運転を判断し、異常が発生した時に検知することが必要である。本研究では、表-1 に示す観測機器を用いて走行挙動の観測を行う。本観測機器は、車両速度、3 軸成分の加速度、方位角、緯度経度を 10Hz (0.1s 間隔) で計測する。

表-2 に異常運転検知に用いるデータを示す。本研究では、二次元の OCSVM のモデルをデータの数だけ用意し、異常運転に含まれる境界線に一つでも入ったら、異常運転と判定する。そこで、横軸にそのデータの平均値、縦軸にそのデータの標準偏差の値を取る。モデル 1 からモデル 5 は、観測機器から観測される生データから構成されるモデルである。なお、操舵角は観測点の前後で観測した方位角の差分の値とする。

モデル 6 からモデル 11 は生データを加工したデータで構成されるモデルである。次に、それぞれの指標について述べる。モデル 6 は、3 軸成分の加速度を合成した値から構成されるモデルである。モデル 7 からモデル 10 は、加速度を微分した値の躍度から構成されるモデルである。なお躍度は、近年、車両の運転特性を表す重要な指標として用いられている研究事例が多い^{11), 12)}。最後にモデル 11 は、単位秒あたりの操舵角変位を表す値から構成されるモデルである。本研究では、上記の 11 のモデルを用いて異常運転検知を行う。図-2 に概念図を示す。

表-1 走行挙動の観測に用いる機器の概要

使用する端末	Q-starz GT BL-1000GT
内蔵センサー	加速度センサー GPS センサー
観測項目	・ 車両速度 (km/h) ・ 3 軸加速度 (G) ・ 緯度経度 (度) ・ 方位角 (度)
周波数 (観測間隔)	10Hz (0.1 秒間隔で観測)
データの保存方法	端末内の SD カードに保存される

表-2 異常運転検知に用いるデータ

モデル	項目	指標の説明
1	車両速度の平均 (km/h)	車両の速度
	車両速度の標準偏差	
2	X 軸成分の加速度の平均 (G)	車両の左右方向の加速度
	X 軸成分の加速度の標準偏差	
3	Y 軸成分の加速度の平均 (G)	車両の前後方向の加速度
	Y 軸成分の加速度の標準偏差	
4	Z 軸成分の加速度の平均 (G)	車両の上下方向の加速度
	Z 軸成分の加速度の標準偏差	
5	操舵角の平均 (deg)	車両が向く方向
	操舵角の標準偏差	
6	合成加速度の平均 (G)	X, Y, Z 軸成分の合成加速度
	合成加速度の標準偏差	
7	X 軸成分の躍度の平均 (J)	車両の左右方向の躍度
	X 軸成分の躍度の標準偏差	
8	Y 軸成分の躍度の平均 (J)	車両の前後方向の躍度
	Y 軸成分の躍度の標準偏差	
9	Z 軸成分の躍度の平均 (J)	車両の上下方向の躍度
	Z 軸成分の躍度の標準偏差	
10	合成躍度の平均 (J)	X, Y, Z 軸成分の合成躍度
	合成躍度の標準偏差	
11	操舵角速度の平均 (deg/s)	1 秒当たりの操舵角
	操舵角速度の標準偏差	




図-2 異常運転検知時の各データの概念図

(3) 異常運転検知の閾値について

運転者の走行挙動が異常運転かどうかを判断する為には、分析者が任意に閾値を設定する必要がある。一般的に、運転者の異常運転の判断には、管理値を基に判断している研究事例が多い³⁻¹⁰⁾。管理値は観測したデータが正規分布に従っていると仮定する方法である。観測したデータから平均値 μ と標準偏差 σ を算出し、任意の範囲に観測データが入っているかどうかで異常を判定する方法である。

そこで本研究では、事前学習で正常運転と異常運転の境界線を決める際に用いるパラメータ v は、管理値に従っていると仮定する。

図-3 に本研究で設定する閾値を示す。本研究では、

(1) 式に示すように閾値を 1σ 、 2σ 、 3σ に設定する。閾値を変えた時に、異常運転検知の検知精度、検知タイミングにおよぼす影響を検証する。

$$Threshold = \mu + k\sigma \quad (k=1,2,3) \quad (1)$$

以上、本研究で提案する OCSVM を用いた異常運転検知手法について述べた。次章以降では、提案した手法の妥当性について検証を行う。

4. 走行挙動データの収集

(1) 調査概要

表-3 に本研究で実施した観測調査の概要を示す。本研究では、提案した手法の妥当性を検証するにあたり、石川県金沢市に住む、認知症がない 65 歳以上の高齢運転者 20 名を被験者として、走行挙動の収集を行った。

なお、被験者を高齢運転者とした理由は、加齢によって、身体機能や認知機能が低下した高齢運転者間の走行挙動から、本手法の有効性が確認できれば、その他の運転者が含まれた場合でも効果が期待できると考えたからである。また、認知症の有無は、事前に認知機能検査を行った上で、認知症専門医が判断した。

走行挙動の観測期間は 2 週間とし、調査期間中は、普段通りに運転をしていただいた。観測機器を設置する際は、ダッシュボードの上などの水平な場所に設け、運転中に機器が動かないよう固定した状態で走行挙動の観測を行った。表-4 に被験者の個人属性を示す。年齢、性別、使用車種、観測期間中の運転日数および運転時間は表に示す通りである。

なお、本研究は、金沢大学医学倫理審査委員会の承認を得て実施した(承認番号第 2016-241)。研究実施にあたり、全被験者より文書同意を得た。

(2) 異常運転検知データの作成

ここでは、観測した走行挙動から交差点部の走行挙動を抽出する手順について述べる。先ず初めに、観測した走行挙動にデジタル道路網マップ (DRM) の情報を付与する。GIS を通して DRM に含まれるノードデータに含まれる交差点部の情報とリンクデ




図-3 異常運転検知に用いる閾値の設定

表-3 観測調査の概要

調査対象者	石川県金沢市に住む 65 歳以上の方で自動車を日常的に運転する方。かつ認知機能に問題のない方の計 7 人
調査期間	2 週間計測
実施した認知機能検査	<ul style="list-style-type: none"> ・ MMSE ・ パレイドリアテスト ・ トレイルメイキングテスト A・B ・ CDR
観測方法	QstarzGT BL-1000GT
観測の記録方法	運転を開始する前と終了後にボタンを押してもらい、スイッチの ON/OFF を行う。

表-4 被験者の個人属性

ID	年齢	性別	車種	運転日数 (時間)
No.1	73	男性	AT	14 日 (15h27m)
No.2	77	男性	AT	14 日 (13h15m)
No.3	73	女性	AT	10 日 (11h54m)
No.4	75	女性	AT	10 日 (10h28m)
No.5	75	女性	AT	8 日 (9h56m)
No.6	68	男性	AT	12 日 (12h35m)
No.7	72	女性	AT	10 日 (11h47m)
No.8	75	女性	AT	14 日 (15h13m)
No.9	69	女性	AT	8 日 (8h55m)
No.10	68	女性	AT	14 日 (14h22m)
No.11	71	女性	AT	10 日 (11h25m)
No.12	75	女性	AT	10 日 (12h17m)
No.13	80	男性	AT	10 日 (11h34m)
No.14	71	男性	AT	14 日 (15h28m)
No.15	72	女性	AT	12 日 (11h13m)
No.16	72	女性	AT	9 日 (10h06m)
No.17	72	男性	AT	14 日 (14h07m)
No.18	73	女性	AT	12 日 (13h23m)
No.19	72	男性	AT	10 日 (9h15m)
No.20	68	男性	AT	9 日 (8h53m)

表-5 調査期間中に観測した走行挙動の数

交差点規模	発進方法	進行方向	Case	ID1	ID2	ID3	ID4	ID5	ID6	ID7	ID8	ID9	ID10	ID11	ID12	ID13	ID14	ID15	ID16	ID17	ID18	ID19	ID20
大規模交差点	停車せずに通過	右折	1	38	44	8	14	28	19	52	32	46	48	30	18	4	15	14	40	12	16	24	14
		直進	2	176	324	20	82	82	312	318	332	204	328	318	136	40	49	47	476	120	196	228	60
		左折	3	24	182	4	30	46	139	164	340	102	354	164	14	10	13	11	28	20	32	112	24
	停車してから通過	右折	4	128	96	60	16	48	40	80	56	48	40	72	56	24	12	12	112	32	40	56	16
		直進	5	64	48	8	16	40	56	64	24	16	24	56	24	64	8	12	72	16	12	40	8
		左折	6	72	64	8	8	48	32	56	64	32	56	40	32	24	16	4	88	16	24	72	16
中規模交差点	停車せずに通過	右折	7	48	22	42	36	96	9	22	28	30	24	22	18	28	45	42	112	32	32	102	108
		直進	8	442	106	364	164	914	317	332	332	216	342	320	136	498	505	511	824	472	374	996	1220
		左折	9	158	102	128	40	476	132	154	340	92	342	156	14	162	191	177	134	84	196	216	408
	停車してから通過	右折	10	96	64	136	56	208	40	72	40	40	40	72	56	104	172	96	144	128	112	120	104
		直進	11	24	40	32	40	32	56	56	24	16	24	56	24	40	80	60	120	112	72	64	80
		左折	12	40	56	96	32	88	32	40	48	32	48	40	32	88	132	80	176	64	120	112	88
小規模交差点	停車せずに通過	右折	13	68	22	18	28	36	68	36	60	60	152	74	26	36	16	36	16	12	60	32	58
		直進	14	212	48	118	142	160	148	144	134	134	304	86	108	364	70	121	114	40	168	276	354
		左折	15	164	26	54	32	76	180	108	122	122	276	120	144	62	37	34	18	16	108	62	64
	停車してから通過	右折	16	32	24	48	16	32	24	24	80	80	48	48	16	24	64	48	32	16	120	64	64
		直進	17	16	24	16	32	40	80	8	32	32	96	40	16	24	28	40	32	12	32	40	24
		左折	18	72	40	40	48	56	24	60	80	80	96	32	32	88	60	16	16	16	128	40	48

ータに含まれる道路情報を走行挙動に付与する。なお、本研究では、Esri社のArcGISデータコレクション2016のDRMを用いた。

次に、DRMの情報を付与した走行挙動から交差点部の走行挙動を抽出する。本研究では、須藤ら¹³⁾や鈴木ら¹⁴⁾の知見を参考に、大規模交差点部(車両の進行方向から見て流入部および流出部の車線数が片側2車線以上)の走行挙動、中規模交差点部(車両の進行方向から見て流入部および流出部の車線数が片側1車線)の走行挙動、小規模交差点部(車両の進行方向から見て流入部および流出部の車線数が両側1車線)の走行挙動の3つに分類した。なお、大規模交差点部の走行挙動は、交差点の中心から半径30m、中規模交差点部の走行挙動は、交差点の中心から半径20m、小規模交差点部の走行挙動は、交差点の中心から半径10mに含まれる範囲を交差点部の走行挙動として抽出した。

次に、観測した走行挙動の補正を行う。ここでの補正は、被験者の車両に設置した観測機器が傾いた場合を想定して行う。八木ら¹⁵⁾、木山ら¹⁶⁾の知見を参考に機器の傾きの補正を行う。機器の傾きは加速度成分の値に大きな影響を及ぼす。したがって、本研究では補正を行った上で分析に使用した。

次に、交差点部の走行挙動から発進方法の判別、進行方向の判別を行う。発進方法は、交差点部において車両が停止した状態から発進、車両が停止せずに交差点部を通過したかの2つに分類した。進行方向は、交差点部において車両が右折・左折・直進をしたかの3つに分類した。なお、これらの分類は、水島ら¹⁷⁾、牧野ら¹⁸⁾の知見を参考にを行った。表-5に被験者別に抽出した走行挙動の数を示す。

最後に、データ拡張を行う。本研究では、機械学習を用いた異常運転検知手法の提案を行う。一般的に、データ数が多いほど、精緻なモデルになるとされている。そこで本研究では、観測した交差点部の走行挙動を基に、データの増強を行う。Um et al.¹⁹⁾、Rashid et al.²⁰⁾の知見を参考に、Jittering, Scale, Permutation, Magnitude Warpingの4つの方法でデータ拡張を行った。

以上、観測調査で観測した走行挙動から交差点部の走行挙動を抽出する手順について述べた。なお、本研究で分類した交差点部の走行挙動以外にも、例えば、右折時に対向直進車両の通過を待つ場合、交差点から出る際に横断歩道上の歩行者等を優先させるために交差点内で停車する場合など、他の状況も生じるが本研究では、このような走行挙動は考慮しないこととする。

5. 提案した手法の有効性の検証

(1) 提案手法の検知精度の検証

本章では、本研究で提案した手法の妥当性を検証する。先ず本節では、提案した手法がどの程度の精度で異常運転検知ができるのかを検証する。本研究では、著者ら²¹⁾を参考に、運転特性が異なる交差点部の走行挙動を学習用データと検証用データにそれぞれ入力し、異常運転と判別する割合から手法の精度検証を行う。なお、ここでは交差点部を通過した後に、異常運転であったかを判断する事後的な異常運転検知を行う。

表-6に、検知精度を検証する為のシナリオについて

表-6 検知精度のシナリオの設定

シナリオ	学習用データ			検証用データ		
	ケース	交差点部の規模	発進方法	ケース	交差点部の規模	発進方法
1	Case1-Case3	大規模交差点	停車なし	Case4-Case6	大規模交差点	停車あり
2	Case7-Case9	中規模交差点	停車なし	Case10-Case12	中規模交差点	停車あり
3	Case13-Case15	小規模交差点	停車なし	Case16-Case18	小規模交差点	停車あり
4	Case1-Case3	大規模交差点	停車なし	Case7-Case9	中規模交差点	停車なし
5	Case7-Case9	中規模交差点	停車なし	Case13-Case15	小規模交差点	停車なし
6	Case13-Case15	小規模交差点	停車なし	Case1-Case3	大規模交差点	停車なし

て述べる。シナリオ 1 からシナリオ 3 は、交差点部において、車両の発進方法の異なる走行挙動が入力された時に、異常運転と判別できるかを検証するシナリオである。シナリオ 4 からシナリオ 6 は、交差点部において、交差点部の規模の異なる走行挙動が入力された時に、異常運転と判別できるかを検証するシナリオである。なお、表 6 に示すそれぞれのケースは、表 5 に示すそれぞれの被験者が観測したケースと対応している。

次に、手法の性能評価の方法について述べる。教師あり学習による異常運転検知手法の性能評価の方法は存在する。しかし、教師なし学習による手法の性能評価の方法は確立されていない²²⁾のが現状である。そこでここでは、異常運転が発生しているにも関わらず、正常運転と判断することを防ぐことに重点を置いた手法の性能評価を行う。

そこで本研究では、検知率の値から手法の評価を行う。検知率は (2) 式で算出する。検証用データは全て既知の異常運転データと見なしている。それに対し、どの程度、異常運転であると判定したかで評価する。

$$\text{検知率 (\%)} = \frac{A}{A+B} \times 100 \quad (2)$$

A : 検証用データに対し、異常運転であると判定した数

B : 検証用データに対し、正常運転であると判定した数

図-4 に検知率を算出するフローを示す。まず、検知率を算出する運転者の決定および学習用データと検証データに用いるケースを決定する。次に、学習用データの方では、検知率を算出する運転者以外で観測した交差点部の走行挙動から正常な走行挙動モデルを作成する。次に、作成した正常な走行挙動モデルに検証用データを当てはめ、異常運転を判別する境界線に含まれるかどうかを確認する。この時、観測した走行挙動が境界線に含まれていた場合、その交差点部の走行挙動は異常運転が発生したとカウントする。もし、境界線に含まれていない場合は、正常運転であるとカウントする。これを検証用データの数だけ繰り返し、異常運転、正常運転と判定した数から検知率を算出する。

表-7 に検知結果を示す。ここでは、全被験者の検知率の平均値と標準偏差を示す。まず、閾値と検知率の関係について述べる。σ の値を大きくすると検知率は、減少する傾向にあることが明らかになった。

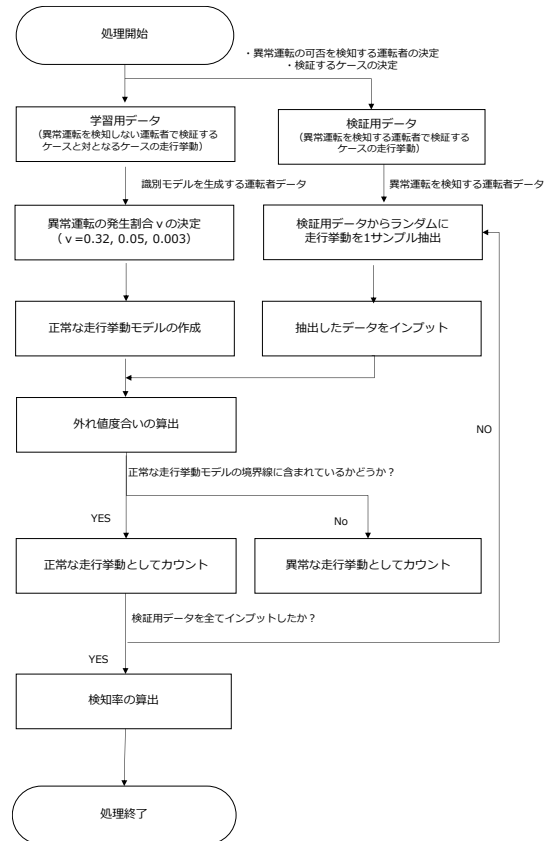


図-4 異常運転検知の検知率の算出フロー

表-7 検知精度の結果

シナリオ	検知率 (%)		
	閾値=1σ	閾値=2σ	閾値=3σ
1	99.81 ± 0.39	98.23 ± 1.77	98.03 ± 2.18
2	99.59 ± 0.83	99.20 ± 1.11	98.42 ± 2.86
3	99.61 ± 1.15	98.52 ± 2.29	97.06 ± 4.25
4	98.52 ± 1.60	94.19 ± 3.22	92.06 ± 3.59
5	98.37 ± 1.95	92.23 ± 3.89	88.12 ± 3.54
6	97.25 ± 2.51	88.68 ± 3.85	86.85 ± 4.77

これは、σ の値を大きくすると正常運転と異常運転を判断する境界線が小さくなるからと考えられる。

次に、シナリオごとの検知精度について考察を述べる。シナリオ 1 からシナリオ 3 は比較的、検知率は高い傾向にあることが明らかになった。また、被験者間での検知率のばらつきもほとんどないことが

表-8 検知タイミングのシナリオの設定

シナリオ	学習用データ			検証用データ		
	ケース	交差点部の規模	発進方法	ケース	交差点部の規模	発進方法
1	Case7-Case9	中規模交差点	停車なし	Case1-Case3	大規模交差点	停車なし
2	Case13-Case15	小規模交差点	停車なし	Case1-Case3	大規模交差点	停車なし
3	Case1-Case3	大規模交差点	停車なし	Case7-Case9	中規模交差点	停車なし
4	Case13-Case15	小規模交差点	停車なし	Case7-Case9	中規模交差点	停車なし
5	Case1-Case3	大規模交差点	停車なし	Case13-Case15	小規模交差点	停車なし
6	Case7-Case9	中規模交差点	停車なし	Case13-Case15	小規模交差点	停車なし

明らかになった。一方で、シナリオ 4 からシナリオ 6 は、 σ の値が大きくなるにしたがい、検知率も低下する傾向にあることが明らかになった。また、被験者間での検知率のばらつきもシナリオ 1 からシナリオ 3 に比べて大きいことが明らかになった。

このことから、本手法は交差点部での車両の発進方法や曲り方は、高い精度で異常運転検知が出来るが、交差点規模まで考慮した検知は改善点があると考えられる。

(2) 提案手法の検知タイミングの検証

本節では、提案した手法がどの時点で異常運転として検知できるか検証する。そこで前節と同様に、特性が異なる交差点部の走行挙動を学習用データと検証用データにそれぞれ入力し、異常運転と判断するタイミングを検証する。なお、ここでは運転者が交差点部を通過中に異常運転が発生したかどうかを判断するリアルタイムでの異常運転検知を行う。

表-8 に検知タイミングを検証する為のシナリオを述べる。ここでは、異常運転が発生した時に、それぞれの交差点の規模に応じてどのタイミングで検知できるかを検証する。シナリオ 1 とシナリオ 2 は、大規模交差点部において異常運転が検知された時、シナリオ 3 とシナリオ 4 は、中規模交差点部において異常運転が検知された時、シナリオ 5 とシナリオ 6 は、小規模交差点部において異常運転が検知された時にどのタイミングで検知できるかを検証する。次に、検知タイミングを算出するフローについて述べる。大まかな流れは、図 4 に示すフローと同様である。事後的な異常運転検知では、交差点部を進入してから通過後までの一連の走行挙動に着目していたが、ここでは、閾値を越えた時点に着目する。

表-9 に検知タイミングの結果を示す。ここでは、全被験者の検知タイミングの平均値と標準偏差を示す。まず、閾値と検知率の関係について述べる。 σ の値を大きくしても検知タイミングは、あまり遅れない傾向にあることが明らかになった。このことから、本手法は σ を大きくして、境界線の範囲が小さくなくても異常運転と判断するタイミングに影響は及ぼさない可能性があると考えられる。

次に、シナリオごとの検知タイミングについての考察を述べる。検証用データに用いる交差点の規模が大きいくほど、検知タイミングが遅れる傾向にある

表-9 検知タイミングの結果

シナリオ	検知タイミング (s)		
	閾値=1 σ	閾値=2 σ	閾値=3 σ
1	2.0 \pm 0.2	2.0 \pm 0.2	2.1 \pm 0.2
2	2.0 \pm 0.2	2.1 \pm 0.2	2.1 \pm 0.2
3	2.3 \pm 0.2	2.3 \pm 0.1	2.4 \pm 0.1
4	2.2 \pm 0.2	2.3 \pm 0.1	2.5 \pm 0.2
5	2.5 \pm 0.2	2.6 \pm 0.2	2.8 \pm 0.2
6	2.6 \pm 0.2	2.7 \pm 0.2	2.9 \pm 0.3




図-5 異常運転検知時に有効な指標

ことが明らかになった。これは交差点の規模が大きくなるほど、抽出している交差点部の走行挙動も広くなる為、検知タイミングは遅れてしまうことを意味している。また、被験者間の検知タイミングの

表-10 既往研究で用いられた手法との比較 (閾値=3 σ の時)

著者	特定手法	検知率 (%)						検知タイミング (s)					
		シナリオ						シナリオ					
		1	2	3	4	5	6	1	2	3	4	5	6
Lampiri ⁶⁾	ホテリング理論	92.45	91.88	92.77	86.63	85.23	81.26	2.3	2.4	2.6	2.7	3.0	3.1
Din et al. ⁷⁾	混合正規分布	95.32	94.25	95.45	92.11	89.46	88.83	2.4	2.3	2.5	2.7	2.9	3.0
Dang et al. ⁸⁾	k-近傍法	94.14	92.41	93.44	90.45	87.25	85.33	2.4	2.4	2.4	2.6	2.8	2.9
Zhang et al. ⁹⁾	Isolation Forest	95.33	94.36	92.36	92.45	91.33	89.43	2.4	2.3	2.5	2.6	2.9	3.1
Ngan et al. ¹⁰⁾	Local Outlier Factor	97.21	96.26	95.26	95.37	93.17	94.14	2.2	2.2	2.5	2.6	2.8	3.0
本研究の提案手法	One Class Support Vector Machine	98.03	98.42	97.06	92.06	88.12	86.85	2.1	2.1	2.4	2.5	2.8	2.9

ばらつきを見ると標準偏差の値は小さく、ほとんどないと考えられる。

図-5 に異常運転を検知したデータの割合を示す。ここでは、リアルタイムで異常運転を検知した時のデータの検知割合の平均の値を示している。なお、ここでは閾値が 3 σ の時の結果を示す。シナリオ関わらず検知されるデータは同じ傾向にあることが明らかになった。全てのシナリオで車両速度、X 軸成分の加速度、操舵角速度がリアルタイムでの異常運転検知に有効であることが明らかになった。

(3) 既往研究との比較

本節では、5.1 および 5.2 で算出した結果と既往研究で用いられた手法を比較して、本手法の有効性を検証する。そこで、同一のデータおよび、設定条件を既往研究に用いられた手法に適用して、検知精度と検知タイミングを算出する。

表-10 に比較結果を示す。なお、ここでは閾値が 3 σ の時の結果を示す。まず、検知精度についての考察を述べる。本手法の検知精度は、他の手法と比較して、シナリオ 1 からシナリオ 3 については、最も高い精度で異常運転の検知ができることが明らかになった。一方で、シナリオ 4 からシナリオ 6 については、Local Outlier Factor が最も高い精度で異常運転の検知ができることが明らかになった。このことから、本研究で提案した各データの平均値と標準偏差から正常運転と異常運転の境界線を決定する場合、データ間の密度から決定した方が良い事が明らかになった。

次に、検知タイミングについての考察を述べる。本手法の検知タイミングは、他の手法と比較しても最も早く検知できることが明らかになった。このことから、迅速な検知は本手法が適していると考えられる。

6. まとめと今後の課題

本研究では、自動車運転者の異常運転を検知する

手法の開発を行った。OCSVM を用いた手法の提案を行った。本手法は、運転者間の交差点部の走行挙動から正常な走行挙動モデルを作成し、乖離度合いから異常度を定義する手法を提案した。

手法の有効性の検証には、特性が異なる他のケースの交差点部の走行挙動を検証用データとして用いた。本研究で提案する手法を既往研究で用いられた手法と比較したところ、検知精度は本手法は、特定の条件下においては、最も精度が高くなることが明らかになった。一方で、検知タイミングは、本手法が最も早く異常運転を検知できることが明らかになった。

今後の課題について述べる。閾値の σ の値についてさらに検討する必要がある。本研究で検証したシナリオによっては、検知精度が低下してしまうことが明らかになった。したがって、交差点部の走行挙動の特性に合わせた閾値の設定が必要である可能性が示唆された。

謝辞：本研究を遂行するにあたり、金沢大学大学院医薬保健学総合研究科 篠原もえ子氏、北真実氏、自然科学研究科 藤生慎氏、大澤脩司氏、南貴大氏、森崎裕磨氏および観測調査に協力して頂いた参加者の方々に多大なご協力をいただいた。ここに感謝の意を表す。本研究は、東京電機大学総合研究所研究課題 Q20D-03 (2020031) として行った。

参考文献

- 1) 「予防安全性能アセスメント」、独立行政法人 自動車事故対策機構、2018 年
- 2) 「平成 29 年における交通死亡事故の特徴等について」、警察庁交通局、2017 年。
- 3) M, Chan., A, Herrera., B, Andre.: Detection of changes in driving behavior using unsupervised learning, Proceedings of IEEE International Conference on Systems, Man and Cybernetics, pp. 1979-1982, 1994.
- 4) 多田昌裕, 納谷太, 岡田昌也, 野間春生, 鳥山朋二, 小暮潔: 無線加速度センサを用いた

- 模範運転動作からの逸脱検出, 人工知能学会論文集, vol.23, no.3, pp. 105-116, 2008.
- 5) 田中雄介, 坂東誉司: 車両挙動に基づくドライバの異常状態推定技術の開発, 自動車技術会論文集, vol.44, no.2, pp. 685-690, 2013.
 - 6) E, Lampiri.: Sensor Anomaly Detection and Recovery in a Nonlinear Autonomous Ground Vehicle Model, I2017 11th Asian Control Conference (ASCC), pp.430-435, 2017.
 - 7) N, Ding., H, Ma., C, Zhao., Y, Ma., H, Ge.: Data Anomaly Detection for Internet of Vehicles Based on Traffic Cellular Automata and Driving Style, Sensors, vol.19, pp. 1-19, 2019.
 - 8) T, T, Dang., H, Y, Ngan., W, Liu.: Distance-Based k-Nearest Neighbors Outlier Detection Method in Large-Scale Traffic Data, IEEE TITS, vol. 14, no.1, pp. 448-458, 2013.
 - 9) D, Zhang., N, Li., Z, H, Zhou., C, Chen., L, Sun., S, Li.: iBAT: Detecting Anomalous Taxi Trajectories from GPS Traces, UbiComp'11, pp. 99-108, 2011.
 - 10) H, Y, Ngan., W, Liu.: Density-based Outlier Detection by Local Outlier Factor on Large scale Traffic Data, IS&T International Symposium on Electronic Imaging 2016 Image Processing: Machine Vision Applications IX, pp. 1-4, 2016.
 - 11) F, Fenga., S, Baoa., R, Sayera., J, Flannagana., C, Manserb., M, Wunderlichb.: Can vehicle longitudinal jerk be used to identify aggressive drivers? An examination using naturalistic driving data, Accident Analysis & Prevention, vol. 104, pp. 125-136, 2017.
 - 12) C, Zhaia, W, Wu.: Analysis of drivers' characteristics on continuum model with traffic jerk effect, Physics Letters A, vol. 382, no. 47, pp. 3381-3392, 2018.
 - 13) 八木浩一: 土木学会論文集 E1 (舗装工学), vol. 69, no.3, pp. I_1-I_7, 2013.
 - 14) 木山昇, 高橋利光, 祖父江恒夫, 相川哲盛: 傾斜したスマートフォンセンサによる自動車の3軸加速度算出手法, マルチメディア・分散・協調とモバイルシンポジウム, pp. 16-23, 2014.
 - 15) 須藤晃成, 秀浦光, 鈴江宗大, 三谷哲雄, 山中英生: 小交差点における停止不能車両の路上からの判別を目的とした車両進入挙動分析, 土木計画学研究・論文集 vol.25, no.3, pp. 775-781, 2008.
 - 16) 鈴木 宏典, 石倉 嵩也, 生駒 哲一: ジレンマゾーンにおける交差点通過または停止要因の分析と意図推定, 自動車技術会論文集, vol. 47, no. 4, pp. 937-942, 2016.
 - 17) 水島 晃, 野口 伸, 松尾 陽介: GPSを使用した車両方位計測法, 農業機械学会誌, vol. 66, no.6, pp. 136-144, 2004.
 - 18) 牧野 友哉, 伊藤 嘉博, 白石 陽: スマートフォンによる車線推定手法, 情報処理学会論文誌, vol. 55, no.2, pp. 812-825, 2014.
 - 19) T.T. Um, F.M.J. Pfister, D. Pichler, S. Endo, M. Lang, S. Hirche, U. Fietzek, D. Kulić.: Data augmentation of wearable sensor data for Parkinson's disease monitoring using convolutional, Neural Networks, ICM2017, 2017.
 - 20) K, M, Rashid., J, Louis.: Times-series data augmentation and deep learning for construction equipment activity recognition, Advanced Engineering Informatics, vol. 42, pp. 1-12, 2019.
 - 21) 宮内弘太, 高田和幸: 交差点内の走行挙動にOCSVMを用いた高齢運転者の異常運転検知に関する基礎的研究, 土木情報学論文集 F3, Vol.75, No.2, pp. II_97 - II_104, 2019.
 - 22) C, C, Aggarwal.: Outlier Analysis, pp.30-pp.31, Springer, 2016.

(Received ?)

(Accepted ?)

RESEARCH ON ANOMALY DRIVING DETECTION APPLYING MACHINE LEARNING APPLYING DRIVING BEHAVIOR AT INTERSECTIONS

Kota MIYAUCHI and Kazuyuki TAKADA

In recent years, with the development of intelligent transportation systems (ITS), the performance of automobiles has improved. On the other hand, in Japan, intentional dangerous driving by drivers and accidents by elderly drivers have become serious social problems. As a method to solve these problems, it is necessary to have a technology that detects the factors that lead to the occurrence of accidents and allows the vehicle to take appropriate control.

In this study, we focus on the driving behavior of intersections, which are said to have many accidents, and propose a method to detect when factors that lead to accidents appear. Applying the One Class Support Vector Machine, we assumed that anomaly driving occurred when driving behavior that deviated from other drivers was observed and verified the effectiveness of the method. Comparing the proposed method with previous studies, it was confirmed that the detection accuracy was high and the detection timing could be detected earliest.