

東京電機大学

博士論文

機械学習を用いた交差点部における

異常運転検知に関する研究

Research on detection of anomalous driving
behavior at intersection using machine learning

2021年3月

宮内 弘太

第1章 序論	6
1.1 研究背景	6
1.2 研究目的	8
1.3 論文構成	9
第2章 異常運転検知に関する既往研究と本研究の位置づけ	13
2.1 概要	13
2.2 異常運転検知手法の開発フロー	13
2.3 異常運転検知に関する既往研究	15
2.3.1 異常運転検知の史的系譜	15
2.3.2 異常運転検知の目的	16
2.3.3 異常運転検知に用いる運転動作	17
2.3.4 データの観測方法	19
2.3.5 異常運転検知に用いる分析手法	20
2.4 本研究の位置づけ	22
第3章 観測調査および分析用データの作成	23
3.1 概要	23
3.2 観測調査の実施	23
3.2.1 実験計画の作成	23
3.2.2 調査概要	24
3.2.3 被験者の個人属性、運転状況、認知機能検査の結果	29
3.2.4 使用した観測機器の精度検証	31
3.3 交差点部の走行挙動の分類	34
3.3.1 交差点部の走行挙動の確認	34
3.3.2 交差点部における運転特性に関する既往研究	37
3.3.3 交差点部の走行挙動の分類	39
3.4 分析用データの作成	40
3.4.1 交差点部の走行挙動の抽出フロー	40
3.4.2 デジタル道路マップの結合	40
3.4.3 走行挙動データの補正	42
3.4.4 交差点部の走行挙動の抽出	43
3.4.5 車両の発進方法・進行方向の判別	45
3.4.6 抽出した交差点部の走行挙動の分類	46
3.4.7 データ拡張	53
3.5 本章のまとめ	56
第4章 交差点部の走行挙動を用いた運転者の特定	57
4.1 概要	57

4.2	走行挙動を用いた運転者特定に関する既往研究	57
4.3	運転者特定モデルの作成	58
4.3.1	運転者を特定するまでの流れ	58
4.3.2	LSTM (Long Short-Term Memory) の概要	60
4.3.3	運転者の特定に用いる特徴量	61
4.4	運転者特定モデルの性能評価	62
4.4.1	運転者特定モデルの評価方法	62
4.4.2	LSTM 層の設定条件	63
4.4.3	モデル別の特定精度の結果	65
4.4.4	既往研究との比較	66
4.5	運転者特定モデルの適用	68
4.6	本章のまとめ	71
第5章	交差点部の走行挙動に機械学習を適用した異常運転検知手法の構築	72
5.1	概要	72
5.2	走行挙動を用いた異常運転検知に関する既往研究	72
5.2.1	外れ値検知を用いた異常運転検知	73
5.2.2	変化点検知を用いた異常運転検知	74
5.3	個人間異常運転検知手法の構築	76
5.3.1	手法構築のコンセプト	76
5.3.2	特徴量の設定	77
5.3.3	分析手法	78
5.3.4	異常運転検知の流れ	79
5.3.5	閾値の設定	81
5.4	個人内異常運転検知手法の構築	82
5.4.1	手法構築のコンセプト	82
5.4.2	特徴量の設定	83
5.4.3	分析手法	84
5.4.4	異常運転検知の流れ	85
5.4.5	閾値の設定	87
5.5	本章のまとめ	88
第6章	事後検知による性能評価の検証	89
6.1	概要	89
6.2	事後検知による性能評価の方法	89
6.2.1	設定したシナリオ	89
6.2.2	検知率の算出方法	91
6.3	個人間異常運転検知の性能評価	94

6.3.1	検知率の検証結果.....	94
6.3.2	運転者特定の有無が検知率に及ぼす影響.....	96
6.3.3	既往研究との精度比較.....	97
6.3.4	異常運転検知に有効なデータの検討.....	99
6.4	個人内異常運転検知の性能評価.....	101
6.4.1	LSTM AE の設定条件.....	101
6.4.2	検知率の検証結果.....	102
6.4.3	運転者特定の有無が検知率に及ぼす影響.....	105
6.4.4	既往研究との精度比較.....	106
6.4.5	異常運転検知に有効なデータの検討.....	108
6.5	本章のまとめ.....	110
第7章	リアルタイム検知による性能評価の検証.....	112
7.1	概要.....	112
7.2	リアルタイム検知による性能評価の方法.....	112
7.2.1	シナリオの設定および部分時系列の概要.....	112
7.2.2	検知タイミングの算出方法.....	113
7.3	個人間異常運転検知の性能評価.....	117
7.3.1	検知タイミングの検証結果.....	117
7.3.2	運転者特定の有無が検知タイミングに及ぼす影響.....	119
7.3.3	既往研究との検知タイミングの比較.....	120
7.3.4	異常運転検知に有効なデータの検討.....	122
7.4	個人内異常運転検知の性能評価.....	124
7.4.1	LSTM AE の設定条件.....	124
7.4.2	検知タイミングの検証結果.....	125
7.4.3	運転者特定の有無が検知タイミングに及ぼす影響.....	128
7.4.4	既往研究との検知タイミングの比較.....	129
7.4.5	異常運転検知に有効なデータの検討.....	131
7.5	二つの異常運転検知手法がもたらす効果.....	133
7.5.1	検知結果から考える車両の対応.....	133
7.5.2	検知タイミングの比較.....	135
7.6	本章のまとめ.....	137
第8章	結論.....	138
8.1	本研究のまとめ.....	138
8.2	今後の展望.....	139
参考文献	141
付録 (本論で割愛した検知精度と検知タイミングの結果)	150

研究業績	170
謝辞	172

第1章 序論

1.1 研究背景

近年、我が国では、自動車運転者による故意な危険運転や高齢運転者による事故の発生が深刻な社会問題になっている。これは運転者だけでなく、周りの運転者や通行人に対して多大な被害をもたらしている。

国土交通省は、この社会問題に対し、事故を未然に防ぐ自動ブレーキを2021年11月以降に販売される国産新型車へ搭載することの義務化を決定した。自動ブレーキは、車両が人・自転車・障害物などを検知し、一定以上の距離に近づいたら、衝突する直前に車両を制御するシステムである。全ての車両に自動ブレーキが搭載されれば、事故の発生は大きく減少すると考えられる。

しかしながら、交通事故の発生場所として多くを占める交差点部（図1.1参照）では、車両や歩行者などが錯綜する場所であることから、現在の自動ブレーキの性能基準（図1.2参照）では、適切な制御が行われない可能性がある。




図 1.1 道路形状別交通死亡事故発生件数（令和元年）
（内閣府「令和2年交通安全白書」より作成）

例えば、以下の状況では、交差点部において自動ブレーキでは回避できないとされている。

【衝突回避できない時】

- ✓ 先行車両との速度差が30km/hよりも大きい状態で運転している時
- ✓ 車線変更などで前方に他の車両が急に割り込んできた時
- ✓ 横断歩道などで前方に人が急に飛び出してきた時

- ✓ 雨や雪などの路面の状況が悪い時
- ✓ 霧や大雨、逆光などの視界が悪い時

【正常に作動しない時】

- ✓ 夜間時に前方車両のテールランプが点灯していない時
- ✓ 反対車線にいる対向車両や交差道路を走行する車両が近づいてきた時
- ✓ 集団の歩行者などが近づいてきた時

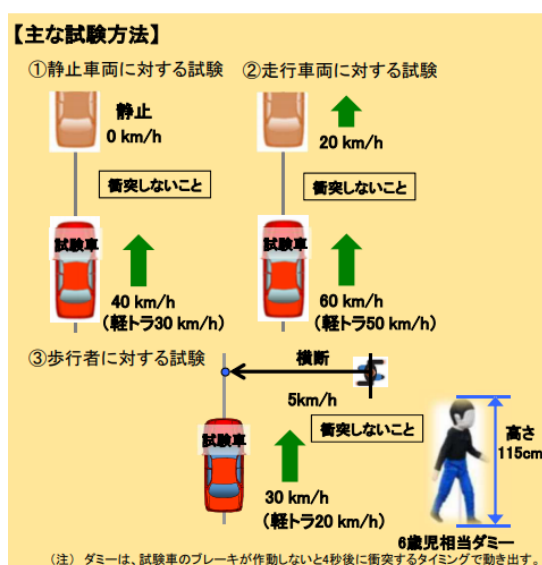


図 1.2 義務化される自動ブレーキの保安基準

(国土交通省「乗用車等の衝突被害軽減ブレーキに関する保安基準」より引用)

つまり、全ての車両に自動ブレーキを導入しただけでは、交差点部で起こる事故を防げない可能性がある。

高速道路などでは、既に自動化（車両が主体となって）運転が可能な車両が存在する。しかしながら、一般道路へ自動化運転を導入する為には、道路整備、人口知能による認識・判断能力の向上、3次元地図データの作成などの課題が残されている。したがって、一般道路での人による運転操作は、当分続くことが想定される。

以上を踏まえると、危険運転や高齢運転者による事故を含め、交差点部での発生が予想される事故を防ぐ為には、運転者による交差点部での運転操作に着目した、新たな技術開発が必要であると考えられる。交差点部において、不注意運転、脇見・漫然運転、運転の誤操作などの運転者側に原因がある事故を未然に検知する技術が必要である。

交差点部において事故が発生する時は、周りの運転者と大きく異なる運転操作をした場合や、運転者自身が行う普段の運転操作と大きく異なる運転操作をした場合に発生しやすい

いと考えられる。なお、この時運転者は、異常な運転（異常運転）を行っていると考えられることができる。

異常運転が発生する時は、車両の走行挙動に特異な特徴として表出すると考えられる。つまり、交差点部の走行挙動から運転者の異常運転の有無を検知することは、新たな技術開発を行う為にも必要であると考えられる。

走行挙動から運転者の異常運転を検知することができれば、ハード面（例えば、車両制御、周りの車両や歩行者への注意喚起、運転者への警告など）の対策だけでなく、ソフト面（例えば、安全運転の啓発、運転者の運転技量の評価、自動車免許証の自主的返納の判断材料など）の対策にも活用が期待できると考えられる。

1.2 研究目的

以上の研究背景を踏まえ、本研究では、交差点部の走行挙動を用いた自動車運転者による異常運転を検知する手法の構築を行う。図 1.3 に本研究で構築する異常運転検知のアプローチ方法と検知結果の活用例を述べる。

まず、異常運転検知のアプローチ方法について述べる。1.1 で述べたように、本研究では、運転者による異常運転を検知する方法は 2 通り存在すると考えた。一つは、運転者全体の交差点部の走行挙動に着目し、他の運転者とは異なる走行挙動が観測された時を異常運転として検知する方法（個人間異常運転検知）である。他方は、個々の運転者の日々の交差点部の走行挙動に着目し、普段とは異なる走行挙動が観測された時を異常運転として検知する方法（個人内異常運転検知）である。

なお、個人間異常運転検知および個人内異常運転検知の手法を構築する際は、機械学習の適用を試みる。機械学習は、近年、様々な分野で活用されている手法であり、膨大なデータ量でも解が求まりやすい利点を持つ。本研究で構築する手法は、膨大な量の交差点部の走行挙動から、正常・異常運転を判別する必要がある。その場合、統計解析手法では、解が求まらない場合や正常・異常運転を判別するモデルが作成できない場合が想定される。そこで本研究では、交差点部の走行挙動に機械学習を適用した異常運転検知手法の構築を試みる。

次に、検知結果の活用例について述べる。交差点部の走行挙動から異常運転を検知する際は、運転者の運転終了後に今の運転に異常運転の発生があったかを検知する事後検知と、交差点部を通過中に異常運転の発生がないかを検知するリアルタイム検知に分けることができる。事後検知とリアルタイム検知の結果は、運転者への活用方法が異なる。

事後検知は、交差点部を通過した後に異常運転検知を行うので、ソフト面（例えば、安全運転の啓発、運転者の運転技量の評価、自動車免許証の自主的返納の判断材料など）への対策に活用できる。その為には、異常運転が発生した時に見落とさない、高い検知精度を有する手法である必要がある。なお、事後検知の結果は、ソフト面への活用を目的としている為、本研究で構築する手法の有効性が検証できれば、社会への実装もしやすいと考えられる。

一方、リアルタイム検知は、交差点部を通過中に異常運転検知を行うので、ハード面（例えば、車両制御、周りの車両や通行人への注意喚起、運転者への警告など）への対策に活用できる。その為には、異常運転が発生した時に素早く検知する、検知タイミングが早い手法である必要がある。なお、リアルタイム検知の結果は、ハード面への活用を目的としている為、社会へ実装する為には、検知タイミングを踏まえた更なる検討が必要であると考えられる。

以上を踏まえ、本研究では、事後検知では検知精度、リアルタイム検知では検知タイミングに着目した検証を通じて、本研究で構築する個人間異常運転検知と個人内異常運転検知による手法の性能評価を行う。さらに、検証結果から、構築した二つの手法の適用限界についても明らかにする。

	個人間異常運転検知	個人内異常運転検知
①事後検知の結果	ソフト面対策 (安全運転の啓発, 運転者の運転技量の評価, 運転免許返納の判断材料など)	ソフト面対策 (安全運転の啓発, 運転者の運転技量の評価, 運転免許返納の判断材料など)
	今すぐにも社会実装が可能な対策	
②リアルタイム検知の結果	ハード面対策 (車両制御, 周りの車両や通行人への注意喚起, 運転者への警告など)	ハード面対策 (車両制御, 周りの車両や通行人への注意喚起, 運転者への警告など)
	社会実装の為には更なる検討が必要	

図 1.3 異常運転検知のアプローチ方法と検知結果の活用例

1.3 論文構成

ここでは本研究の流れについて述べる。図 1.4 に本研究の構成を示す。なお、図の矢印の実線は、異常運転検知手法の構築および性能評価に関する分析のフローを示しており、図の矢印の波線は、異常運転検知手法の性能向上に関する分析のフローを示している。

第2章では、異常運転検知に関する既往研究の整理と本研究の位置づけについて述べる。

本研究では、まず、異常運転検知手法の開発フローを構築する手法と照らし合わせて述べる。次に、異常運転検知に関する既往研究を整理する。最後に、得られた知見から、本研究の位置づけを明らかにする。

第3章では、走行挙動の収集を目的とした観測調査および分析用データの作成方法について述べる。まず、本研究で実施した観測調査について述べる。次に、交差点部における運転特性に関する既往研究を整理し、交差点部の走行挙動の分類を行う。最後に、観測調査で得られた走行挙動から交差点部の走行挙動を抽出する。

第4章では、交差点部の走行挙動を用いた運転者の特定を行う。自動車は、必ずしも一人で一台の車を使用しているとは限らない。例えば、一台の車を複数人で使用している場合もある。したがって、異常運転検知を行う時に、他の運転者の走行挙動が含まれていると、検知精度や検知タイミングに影響を及ぼす。そこで本章では、交差点部の走行挙動から運転者の特定を試みる。まず、走行挙動から運転者の特定を試みた既往研究について整理する。次に、交差点部の走行挙動を用いた運転者特定モデルを作成する。次に、作成した運転者特定モデルの精度検証を行う。最後に、観測調査で運転者の特定ができなかった走行挙動に運転者特定モデルを適用する。

第5章では、交差点部の走行挙動に機械学習を適用した異常運転検知手法を構築する。1.2で述べたように、本研究では、個人間異常運転検知と個人内異常運転検知の二つの観点から異常運転検知の手法構築を試みる。個人間異常運転検知は、運転者全体の交差点部の走行挙動に着目し、他の運転者との走行挙動の乖離度合いから異常度を定義する。個人内異常運転検知は、個々の運転者の日々の交差点部の走行挙動に着目し、日々の走行挙動との変動度合いから異常度を定義する。まず、走行挙動を用いて異常運転検知を試みた既往研究について整理する。次に、個人間異常運転検知手法について述べる。最後に、個人内異常運転検知の手法について述べる。

第6章では、事後検知による性能評価の検証を行う。5章で構築した二つの手法がどのような場面で、どの程度の精度で検知できるか検証する。さらに、既往研究で構築された手法との検知精度を比較する。まず、異常運転の発生を想定したシナリオ設定および検知精度の算出方法について述べる。次に、個人間異常運転検知の性能評価を行う。最後に、個人内異常運転検知の性能評価を行う。性能評価を通じて、構築した二つの手法の適用限界についても明らかにする。

第7章では、リアルタイム検知による性能評価の検証を行う。5章で構築した二つの手法がどのような場面で、交差点部に進入してからどの程度の早さで検知できるか検証する。さ

らに，既往研究で構築された手法との検知タイミングを比較する．まず，異常運転の発生を想定したシナリオ設定および検知タイミングの算出方法について述べる．次に，個人間異常運転検知の性能評価を行う．次に，個人内異常運転検知の性能評価を行う．性能評価を通じて，構築した二つの手法の検知タイミングに着目した時の適用限界について明らかにする．最後に，本研究で構築した二つの手法がもたらす効果について検討する．

第 8 章では，本研究で得られた知見を総括し，今後の展望について述べる．

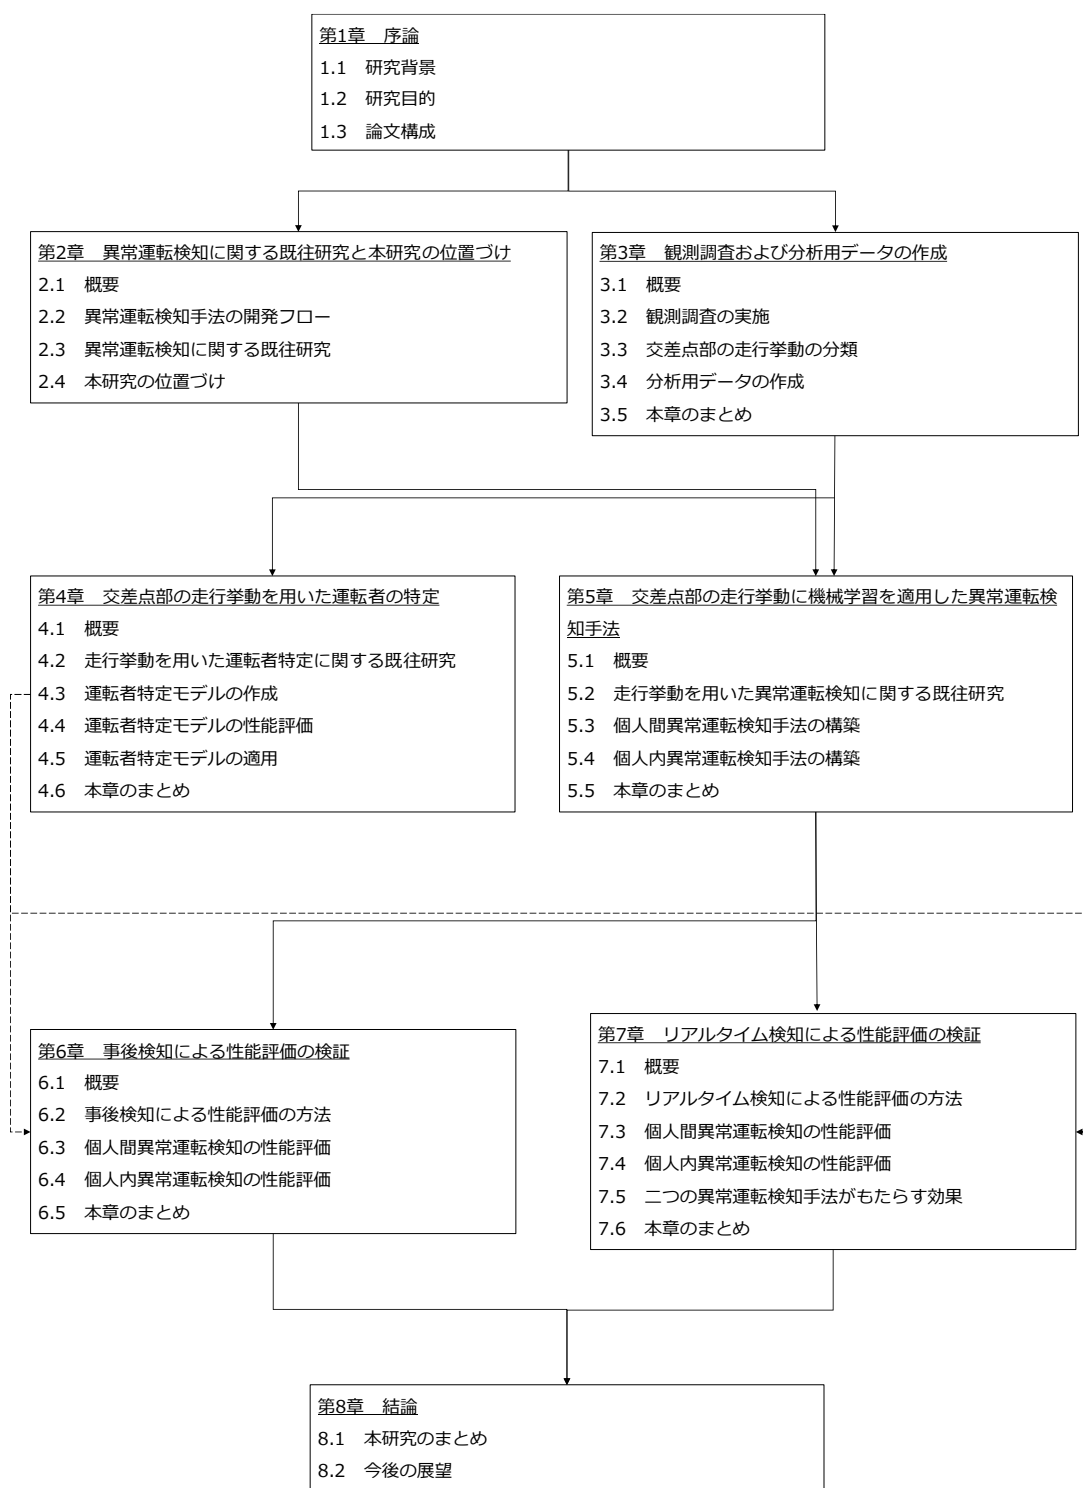


図 1.4 本研究の構成

第2章 異常運転検知に関する既往研究と本研究の位置づけ

2.1 概要

異常運転を検知する技術は、今日までに様々な観点から開発が行われている。本研究の構築目的である、運転の誤操作を検知するだけでなく、例えば、車両の故障検知や運転者の状態検知にも活用されている。

本章では、異常運転検知に関する既往研究を整理し、本研究の位置づけを明らかにする。まず2.2では、異常運転検知手法の開発フローについて、本研究で構築する手法と照らし合わせて述べる。2.3では、異常運転検知に関する既往研究を整理する。本研究では、「異常運転検知を行う目的」、「着目する運転動作」、「運転データの観測方法」、「検知に用いる手法」について知見を得た既往研究を体系的にレビューする。最後に2.4では、既往研究のレビューで得られた知見を踏まえ、本研究の位置づけを明らかにする。

2.2 異常運転検知手法の開発フロー

ここでは、異常運転検知手法の開発フローについて述べる。図2.1に開発フローを示す。それぞれの工程について述べる。なお、ここでは、本研究で構築する手法と照らして述べる。

まず、異常運転検知を行う目的を決定する。目的は手法を開発する際の方針に依存する。本研究の場合、1.2でも述べたように、運転の誤操作を検知する中でも、ソフト面とハード面への活用を想定する。事後検知はソフト面（例えば、安全運転の啓発、運転技量評価、自動車免許証の自主的返納の判断材料など）への対策、リアルタイム検知はハード面（例えば、車両制御、周りの車両や通行人への注意喚起、運転者への警告など）に活用できる。

次に、異常運転検知に用いる運転操作を決定する。運転操作は、検知を行う目的への依存が大きい。着目する運転操作によって、検知に用いるデータの取得方法が決定される。本研究の場合、運転操作が難しいとされる交差点部では、特異な走行挙動が発生しやすいと考え、交差点部での運転動作に着目する。

次に、異常運転検知に必要なデータの収集方法を決定する。車両の挙動や運転者の動き、周りの車や歩行者と距離などを観測機器で取得する。本研究の場合、観測機器を車両に設置する形式で走行挙動を観測する。また、走行挙動の観測に使用する機器も、運転者が手軽に設置および計測ができる機器を使用する。

次に、異常運転検知に適用する分析手法を決定する。異常運転検知に適用する分析手法は様々な提案がなされている。その為、分析者は、異常運転検知の目的やデータの特性に合わせて、適切な分析手法を構築する必要がある。本研究では、1.2でも述べたように、近年、様々な分野で活用されている機械学習を適用した異常運転検知を行う。

最後に、構築した手法の性能評価を行う。性能評価は、異常運転と判断された既知の異常データがあるかどうかで検証方法が異なる。異常運転と判断された走行挙動がある場合は、このデータを基に性能評価を行うことができる。一方、異常運転と判断された走行挙動が無い場合は、異常運転と定義した仮想の走行挙動を作成する方法、構築した手法に適用した時の検知結果から評価を行う方法、異常運転検知に用いる走行挙動と特性が異なる走行挙動を異常運転と定義して性能評価を行う方法などがある。

本研究では、異常運転と判断された交差点部の走行挙動が無い状態で、構築した手法の性能評価を行う。そこで、手法構築に用いた走行挙動と性能評価に用いる走行挙動は、特性が異なるとしたうえで、手法の性能評価を行う。

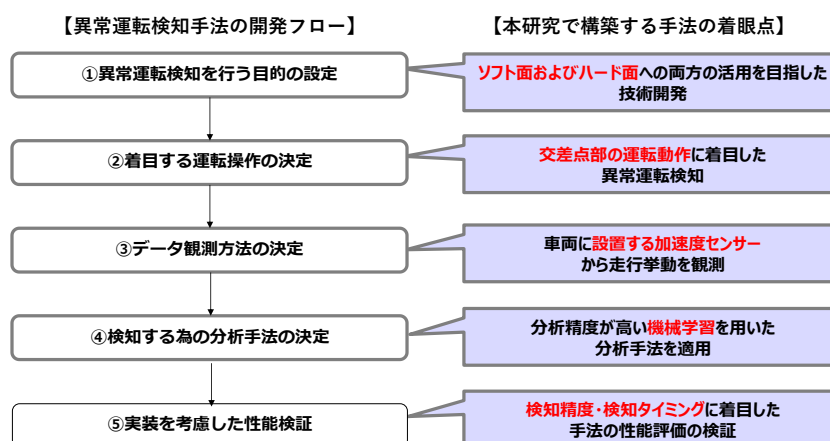


図 2.1 異常運転検知手法の開発フロー

以上、異常運転検知手法の開発フローについて述べた。異常運転検知手法の開発フローは、「異常運転検知を行う目的」、「着目する運転動作」、「運転データの観測方法」、「検知に用いる手法」、「構築した手法の性能評価」に分かれており、適切な選択をして手法を構築すべきことが明らかになった。次節では、異常運転検知を試みた既往研究のレビューを行い、それぞれの項目でどのような観点から行われているのかを明らかにする。

2.3 異常運転検知に関する既往研究

2.3.1 異常運転検知の史的系譜

ここでは異常運転検知に関する史的系譜を作成し、既往研究の開発動向を明らかにする。史的系譜を通して、どの年代に、どのような観点に着目して、手法の開発が行われたのかを把握できると考えた。

図 2.2 に異常運転検知に関する既往研究^{1~4)}の史的系譜を示す。まず初めに、系譜の見方について述べる。横軸は、異常運転検知手法の開発フローを示している。2.2 から異常運転検知の開発フローは、「異常運転検知を行う目的」、「着目する運転動作」、「運転データの観測方法」、「検知に用いる手法」、「構築した手法の性能評価」に分けられることが明らかになった。そこで本研究では、この開発フローの中でも特に、「異常運転検知の目的」、「データの観測方法」、「検知に用いる運転動作」、「検知に用いる手法」が手法を開発する上で重要であると考え、これらに関する既往研究に着目する。

図の細い矢印は項目間のつながり表している。前後の過程に結びつきが発生していることを示している。既往研究を整理した結果、時代の変化とともに、新たな結びつきが生じていることが明らかになった。例えば、「異常運転検知の目的」と「データの観測方法」を見ると、開発された当初は、交通規則・事故対策を目的とした異常運転検知は、自車外からの観測方法でしか行われていなかった。しかしながら、時代の変化とともに、自車内からの観測方法も可能になっている。このことから、その時代の社会背景や交通事情とともに結びつきが変化していると考えられる。

縦軸は「異常運転検知を行う目的」、「着目する運転動作」、「運転データの観測方法」、「検知に用いる手法」、「構築した手法の性能評価」に関する既往研究が行われた時系列を示している。既往研究を整理した結果、時代の変化とともに、新たな観点からの取り組みが行われていることが明らかになった。例えば、「異常運転検知の目的」では、交通規制・事故対策が目的で異常運転検知が行われていたが、時代の変化とともに、予防安全技術が目的へと変化している。このことから、異常運転検知手法の開発フローは、その時代の社会背景や交通事情とともに変化していると考えられる。

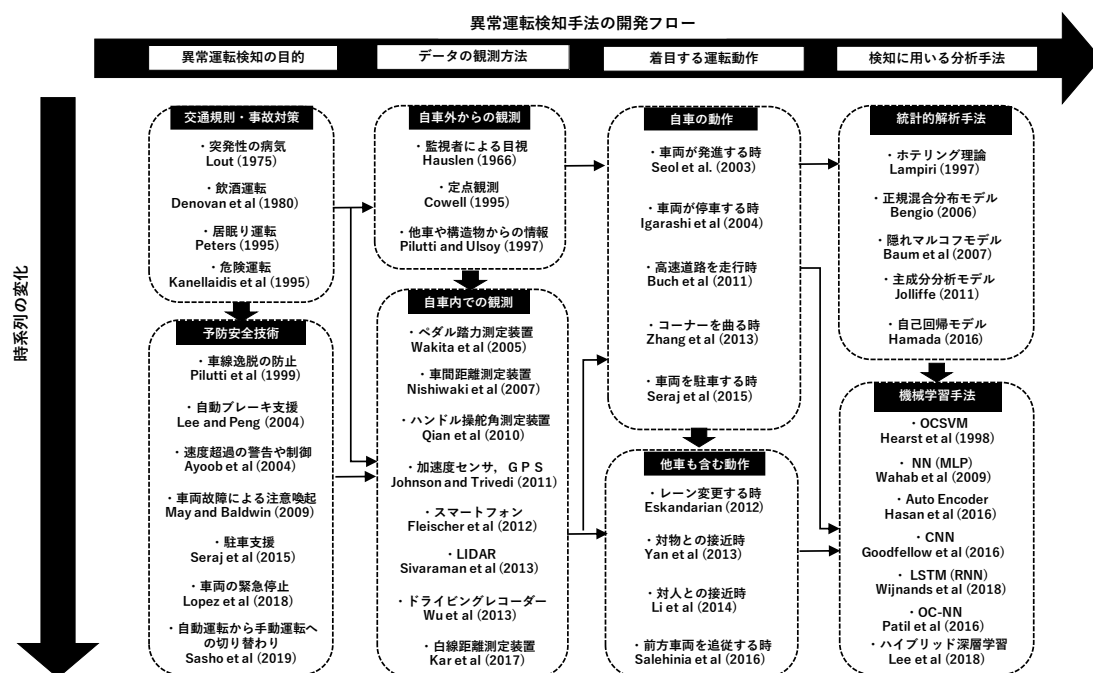


図 2.2 異常運転検知手法に関する史的系譜

以上、異常運転検知の史的系譜について述べた。異常運転検知手法の開発動向は、その時代の交通事情や社会背景の変化と密接に関わっている可能性が示唆された。そこで次節では、「異常運転検知の目的」、「データの観測方法」、「検知に用いる運転動作」、「検知に用いる手法」に着目して体系的にレビューを行う。

2.3.2 異常運転検知の目的

ここでは異常運転検知に関する既往研究の中でも、異常運転検知を行う目的について知見を得た既往研究のレビューを行う。異常運転検知に関する研究が行われた 1970 年代当初は、てんかん等の突発性の病気が発症した時¹⁾や飲酒運転状態²⁾、居眠り状態³⁾、他車の運転を妨害する危険運転⁴⁾などを検知する目的で異常運転検知が行われていた。

これらの異常運転検知は、運転者の状態異常を検知することを目的としている。状態異常時は、運転に必要な要素である正しい判断能力や認知能力、識別能力が著しく低下した状態での運転となる。その為、事故の発生に結びつきやすい。運転者の状態異常を検知する時は、誤検知を少なくすることを目標に、検知精度に着目した手法開発が行われた。

その後、運転者による車線逸脱⁵⁾や前方車両、障害物・人と接近した時^{6,8)}、速度超過した時⁹⁾、車両の電子システムに不具合が生じた時¹⁰⁾、自動化運転から手動運転に切り替わる時¹¹⁾などの事故を未然に防ぐ目的で異常運転検知を行うようになった。

これらの異常運転検知は、運転者の運転の誤操作や車両機器の故障などで起こる異常を

事前に検知することを目的としている。したがって、どれだけ早く異常を検知するかに目標に、検知タイミングに着目した手法開発が行われた。

図 2.3 に異常運転検知の目的を整理した結果を示す。横軸には、異常運転を検知するタイミング、縦軸には、求められる異常運転検知の精度を示す。上記で述べた既往研究を整理すると、てんかん等の突発性の病気が発症した時¹⁾や飲酒運転状態²⁾、居眠り状態³⁾、他車の運転を妨害する危険運転⁴⁾などを検知する既往研究の検知タイミングは、異常運転が発生する直前で検知する傾向にあることが明らかになった。

一方で、運転者による車線逸脱⁵⁾や前方車両、障害物・人と接近した時⁶⁻⁸⁾、速度超過した時⁹⁾、車両の電子系統に不具合が生じた時¹⁰⁾、自動化運転から手動運転に切り替わる時¹¹⁾などを検知する時は、予測して検知する傾向にあることが明らかになった。

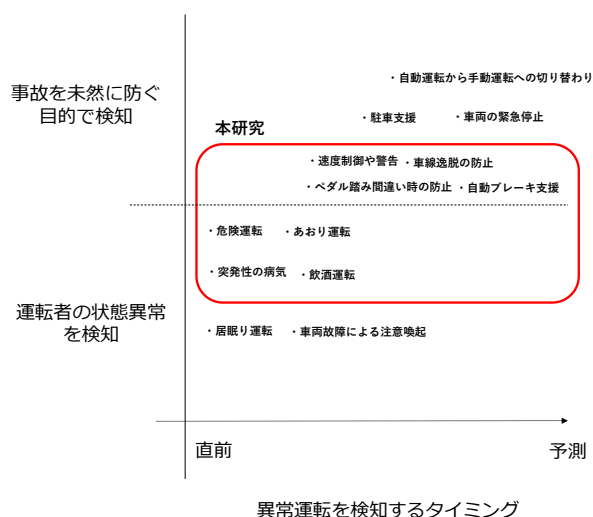


図 2.3 異常運転検知の目的のまとめ

本研究で構築する異常運転検知手法は、ソフト面（安全運転の啓発、運転者の運転技量の評価、自動車免許証の自主的返納の判断材料など）への活用とハード面（車両制御、周りの車両や通行人への注意喚起、運転者への警告など）への活用を考えている。したがって、異常運転を検知する精度が高く、かつ早いタイミングで検知する手法である必要がある。

以上を踏まえると、本研究では、検知精度および検知タイミングの両方の観点から構築した手法の性能評価をすべきことが示された。

2.3.3 異常運転検知に用いる運転動作

ここでは異常運転検知に関する既往研究の中でも、異常運転検知に用いる運転動作について知見を得た既往研究のレビューを行う。なお、ここで述べる運転動作は、車両の動きのことを指す。異常運転検知に関する研究が行われた 1970 年代当初は、速度超過や蛇行運転

をする時の動作²³⁾、停車した状態から車両が発進する時の動作²⁴⁾、車両が停止する時の動作²⁵⁾、高速道路を走行時の動作²⁶⁾、曲る時の動作²⁷⁾、駐車時の動作⁹⁾などに着目して異常運転検知が行われていた。

これらの運転動作は、異常運転を検知する運転者の車両単体の運転動作に着目している。車両単体の運転動作から検知する利点は、道路交通量の大小や走行する場所などの外的要因を受けずに異常運転検知ができる点である。

その後、他車が混在した時の運転動作から異常運転を検知する研究が行われた。車線を変更する時の動作²⁸⁾、対物と接近した時の動作²⁹⁾、対人と接近した時の動作³⁰⁾、前方車両を追従する時の動作³¹⁾などがある。

これらの運転動作は、周りの車両も含む運転動作に着目している。周りに車両がない時は異常運転検知ができない為、異常運転検知が作動する条件が限定的である。また、データの収集や分析も難しくなる傾向がある。

図2.4に着目する運転動作を整理した結果を示す。横軸には、自車だけの動作に着目した時と自車と他車（人・物）との関係に着目した時を示す。縦軸には、車両が直進する時、曲る時、その他の動作に分けている。上記で述べた既往研究を整理すると、自車だけの運転動作に着目した場合と自車と他車の関係性に関する運転動作に着目した場合の関係性は図の通りになる。

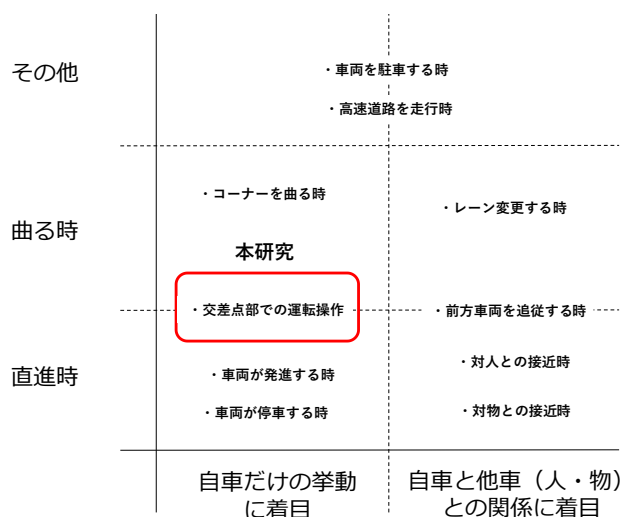


図 2.4 着目する運転操作のまとめ

本研究で構築する異常運転検知手法は、既往研究では着目されていない交差点部の運転動作に着目する。交差点部での運転動作は、直進時であれば右左折に曲る時もある。また、車両の発進方法も停車した状態から交差点部を通過することもあれば、速度をほとんど落

とさずに交差点部を通過することもある。

以上を踏まえると、交差点部の走行挙動を用いた異常運転検知手法を開発する為には、運転者の交差点部における運転特性を明らかにした上で、取り組む必要があると考えられる。

2.3.4 データの観測方法

ここでは異常運転検知に関する既往研究の中でも、データの観測方法について知見を得た既往研究のレビューを行う。異常運転検知に関する研究が行われた1970年代当初は、監視者による目視¹²⁾、危険運転をしやすい場所での定点カメラ観測¹³⁾、他車や構造物から得られた情報¹⁴⁾で得られたデータを用いて異常運転検知が行われていた。

これらの観測方法は、異常運転を行う運転者を車外から検知する方法でデータ観測を行っている。簡便的に異常運転の検知が可能である一方、全ての道路に適用するにはコストがかかる点などがデメリットとして挙げられる。

その後、車両性能の向上により、車両から様々な情報が取得できるようになった。例えば、ペダル踏力測定装置¹⁵⁾や車間距離測定装置¹⁶⁾、ハンドル操舵角測定装置¹⁷⁾、加速度センサーおよびGPS¹⁸⁾、スマートフォンセンサ¹⁹⁾、LIDAR²⁰⁾、ドライビングレコーダー²¹⁾、白線距離測定装置²²⁾などで得られたデータを用いて異常運転検知が行われるようになった。

表2.1に各観測装置で得られるデータについて整理した結果を示す。車内から観測できるデータの取得方法は2通りある。一つは、自動車に装着（内蔵）する方法である。この方法は、自動車の内部に観測機器を埋め込む為、外部からの影響を比較的受けずにデータの観測ができる。その為、分析に用いるデータもノイズが小さく扱いやすい利点を持つ。一方で、車両に内蔵する為、機器の導入や設置にかかるコストが高い。

他方は、計測機器をダッシュボードなどに設置する方法である。この方法は、簡便的な設置の為、観測用の機器があれば誰でも手軽に計測ができる利点を持つ。近年では、センサーの性能が飛躍的に向上しており、様々なデータが手軽に観測出来る。例えば、加速度センサーやGPS、スマートフォンセンサがあり、これらのセンサーからデータの観測が可能である。また、運転者自身が手軽に観測できるのも利点である。一方で、車の振動などの外的影響を受けやすく、分析に扱う際のノイズが多い。その為、データ処理が困難になりやすい傾向がある。

表 2.1 観測方法の概要

項目	観測方法	取得内容
ペダル踏力測定装置	装着型	運転者のアクセル・ブレーキの踏み込み量が計測可能. ペダル操作の特徴を把握することが可能.
車間距離測定装置	装着型	運転者が前方車両を追従する時の車間距離の変化が計測可能. 追従時の特徴を把握することが可能.
ハンドル操舵角測定装置	装着型	運転者のステアリング操作の様子が計測可能. ハンドル操作の特徴を把握することが可能.
白線距離測定装置	装着型	運転者の中央線から寄り具合の様子が計測可能. レーンキープ度合いの特徴を把握することが可能.
加速度センサ	設置型/ 装着型	車両にかかるGを計測することが可能. 運転者の急制動や急ハンドルの特徴を把握することが可能.
GPSセンサ	設置型/ 装着型	車両の位置情報を把握することが可能. 他のセンサと併せて使われることが多い.
ジャイロセンサ	設置型/ 装着型	車両にかかる角速度を計測することが可能. 運転者の急ハンドルの特徴を把握することが可能.
スマートフォンセンサ	設置型	一般的に, 加速度センサ, GPS, ジャイロセンサと一緒に使われている. 近年では精度も飛躍的に向上している.
ドライブレコーダー	設置型	映像を記録する他に加速度を計測することが可能である. アクシデントが発生した時の記録媒体として活用.

図 2.5 にデータの観測方法を整理した結果を示す. 横軸には, 機器の導入にかかるコスト, 縦軸には, 観測したデータが外部から受ける影響度合いを示す. 上記で述べた既往研究を整理すると, 車両に内蔵するタイプと車両に設置するタイプの関係性は図の通りになる.

以上を踏まえると, 本研究で構築する異常運転検知手法は, 車両に設置するタイプの加速度センサーや GPS, スマートフォンセンサを活用したデータの取得方法を想定する. その理由は, 運転に不安を覚えた高齢運転者などがスマートフォンなどで手軽に自身の運転の走行挙動を観測することで, 本手法の適用可能性が広がると考えたからである.

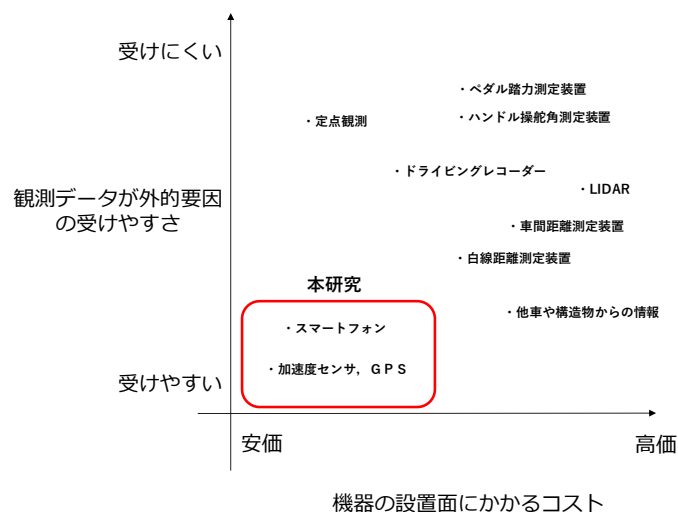


図 2.5 データの観測方法のまとめ

2.3.5 異常運転検知に用いる分析手法

ここでは異常運転検知に関する既往研究の中でも, 異常運転検知に用いる手法について

知されるかが不明確になる場合が考えられる。したがって、多くの指標を設定しておき、検知に有効な指標を検討すべきと考えられる。また、交差点部の走行挙動は、一回の運転で少なくとも数回の走行挙動が観測される。したがって、観測されるデータの数も多くなることが想定される。

以上を踏まえると、交差点部の走行挙動から異常運転検知を行う際は、データ量やデータの特性を踏まえると、統計解析モデルよりも機械学習を適用した手法の方が良いと考えられる。よって、本研究では、機械学習を用いた異常運転検知手法の開発に取り組む。

2.4 本研究の位置づけ

ここでは本章のまとめと本研究の位置づけを述べる。本章では、異常運転検知に関する既往研究を整理した。まず初めに、異常運転検知手法の開発フローを本研究で構築する手法と照らし合わせながら述べた。

開発フローは、「異常運転検知の目的」、「データの観測方法」、「検知に用いる運転動作」、「検知に用いる手法」、「構築した手法の性能検証」の項目に分けられることが明らかになった。

次に、異常運転検知に関する既往研究の史的系譜の作成を行った。本研究では、史的系譜の作成を行うにあたり、手法を構築する上で重要であると考えた「異常運転検知の目的」、「データの観測方法」、「検知に用いる運転動作」、「検知に用いる手法」について知見を得た既往研究に着目した。その結果、異常運転検知手法の開発動向は、その時代の交通事情や社会背景の変化と密接に関わっている可能性が示唆された。

さらに、「異常運転検知の目的」、「データの観測方法」、「検知に用いる運転動作」、「検知に用いる手法」について知見を得た既往研究を体系的にレビューした。その結果、本研究は、交差点部に着目した異常運転検知手法の構築に取り組む点で独自性および新規性を有していることが明らかになった。

以上を踏まえ、本研究の位置づけを述べる。本研究を通じて、構築した手法の有効性が検証できた場合は、交差点部での事故の低減に貢献すると考えられる。したがって、新たな手法構築の枠組みを提示できるものと考えている。

第3章 観測調査および分析用データの作成

3.1 概要

本章では、走行挙動の収集を目的とした観測調査および分析用データの作成方法について述べる。走行挙動を取得する為には、車両に観測機器を設置させていただく必要があり、事前に実験計画を作成した上で、調査の実施を行う必要がある。

交差点部の走行挙動から異常運転検知を行う方法は、個々の交差点部に着目する方法と全ての交差点部での運転操作に着目する方法がある。前者は、個々の交差点に適した異常運転検知ができる一方、交差点ごとに膨大な量の走行挙動データが必要になる。後者は、異常運転検知に必要な走行挙動データを収集しやすい一方、交差点部における運転特性について検討する必要がある。

そこで本研究では、構築した手法を多くの交差点部で適用する為に、交差点部での運転操作に着目した方法で異常運転検知手法の構築を行う。また、収集した走行挙動から異常運転検知を行う際に、機器から出力された走行挙動を使用するか、走行挙動の補正・加工を行うか検討する必要がある。

以上を踏まえ、本章の流れについて述べる。3.2 では、観測調査の概要について述べる。被験者の選定方法、対象地域、運転者の走行挙動の観測方法について述べる。3.3 では、まず、観測器から直接出力される走行挙動の考察を行い、分析用データを作成する必要性について述べる。次に、交差点部における運転特性に関する既往研究をレビューする。最後に、得られた知見から交差点部の走行挙動を分類する。3.4 では、3.3 で分類した交差点部の走行挙動を抽出するフローと抽出した結果について述べる。

3.2 観測調査の実施

3.2.1 実験計画の作成

ここでは本研究で実施する観測調査の実験計画について述べる。本研究で構築する異常運転検知手法は、不注意運転、脇見・漫然運転、運転の誤操作などの運転者側に原因がある事故を未然に検知する。交差点部において事故を起こしやすい運転者は、加齢による認知機能や身体機能が低下した高齢運転者であると考えられる。つまり、高齢運転者による交差点部の走行挙動は、異常運転が発生しやすいと考えた。

そこで本研究では、高齢運転者の走行挙動を観測調査で収集する。なお、高齢運転者の中には、軽度認知症を罹患した状態で運転を行っている可能性が考えられる。軽度認知症は、認知症の症状と同様の物忘れなどの記憶障害が現れる。本来、軽度認知症を罹患した状態で運転することは危険であり、運転を行わないことが推奨されている。

図 3.1 に示すフローに従い観測調査を実施する。まず初めに、65 歳以上の方で日常的に自動車を運転する方を抽出し、被験候補者として選定する。なお、被験候補者の選定は専門医の判断のもと行う。

次に、被験候補者に観測調査の主旨の説明および実験参加への同意確認を行う。本調査の趣旨を理解し、同意が得られた被験候補者は、認知機能検査を行う。なお、75 歳以上の高齢者は運転免許証の更新の際に、認知機能検査の実施が義務付けられているが、本研究では、その結果から判断せず、専門医のもと認知機能検査を行い、認知症の罹患がないことを確かめる。認知機能に問題がない被験候補者は、被験者として正式に調査協力をしていただく。

最後に、被験者の車両に走行挙動を観測する為の機器を取り付け、調査開始とする。なお、観測期間中は、普段通りに運転していただき、調査終了後に機器一式を郵送して頂く形式とする。

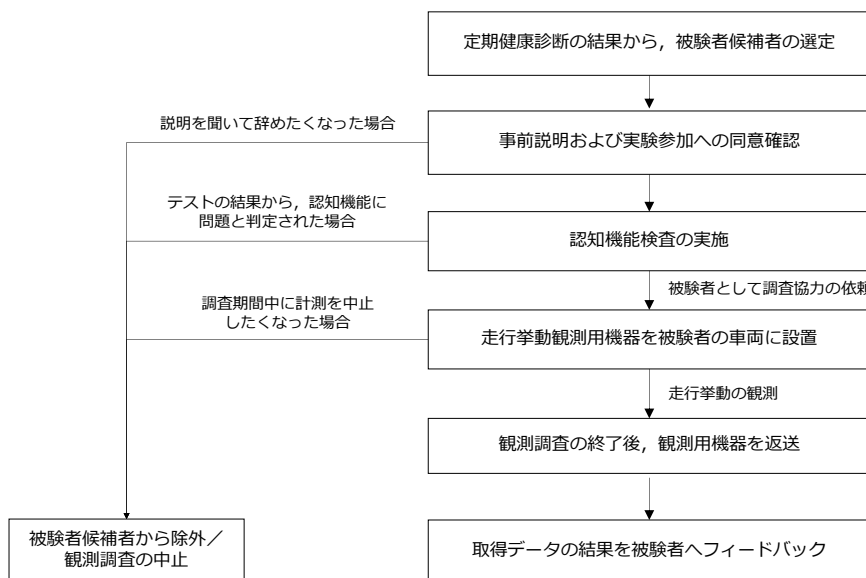


図 3.1 調査の実施フロー

3.2.2 調査概要

ここでは本研究で実施した観測調査の概要を述べる。本調査では、石川県金沢市に住む 65 歳以上の高齢運転者を被験者の対象とした。表 3.1 に対象地域の概要を示す。石川県金沢市は、高齢化が進んだ地域であり、65 歳以上の割合が多い（表 3.1「人口構成」参照）。

同地域は、自動車が移動手段としての役割を担っており、高齢者が自ら運転する機会が多い地域である（表 3.1「市内の主な交通手段」参照）。高齢運転者による事故の発生要因を見ると、本研究で問題としている運転者側による事故が多く発生している（表 3.1「交通事故の発生状況」参照）。

表 3.1 対象地域の概要

<p>人口構成</p>	
<p>市内の主な交通手段</p>	<p style="text-align: center;">* 平成 27 年度国勢調査の結果より引用</p>
<p>交通事故の発生状況</p>	<p style="text-align: center;">* 石川県警察令和元年度交通事故発生状況（概要）より引用</p>

表 3.2 に観測調査の概要を示す。3.2.1 で述べた実験計画のフローに従い、観測調査を行った。本研究では、観測調査を 4 回に分けて実施し、計 30 人の高齢運転者の走行挙動の観測を行った。調査期間は表に示す通りである。

表 3.2 観測調査の概要

調査の対象者	石川県金沢市に住む65歳以上の方で自動車を日常的（週に3回以上）に運転をする方。かつ認知機能の問題のない方。
調査人数（人）	30人
調査期間	一人の被験者につき2週間計測 4/6～4/20：12人 6/15～6/29：5人 6/26～7/10：7人 9/7～9/21：7人
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 <p style="text-align: right;">の検査を実施</p>
観測方法	加速度センサー（Q-starz社製 QstarzGT BL-1000GT）
観測項目	<ul style="list-style-type: none"> ・ 車両速度（km/h） ・ 3軸成分の加速度（G） ・ 方位角（deg） ・ 位置情報（緯度・経度） ・ 観測日時 <p style="text-align: right;">の情報を10Hz（0.1s間隔）で計測する。</p>
走行挙動を観測するまでの手順	<ol style="list-style-type: none"> ①運転開始前に観測機器のスイッチをON. ②運転終了後に観測機器のスイッチをOFF. ③運転終了後に運転日誌を書く.
データの保存	運転終了後に端末内のSDカードにcsv形式で保存される。

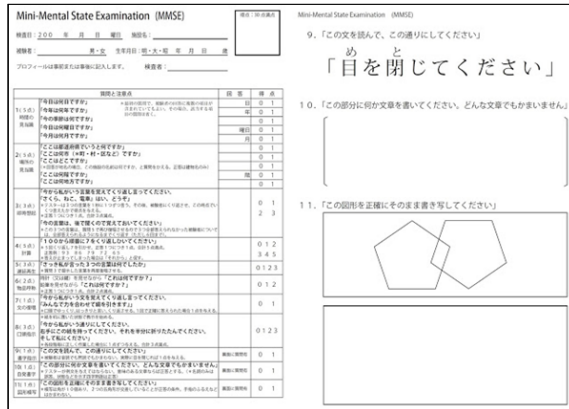
次に、認知機能検査の方法について述べる。本研究では、一般的に広く行われている、MMSE、パレイドリアテスト、CDR、トレイルメイキングテスト（A・B）の検査を実施した。

MMSE（図 3.2 (a) 参照）は、高齢者の知的機能の障害の有無を判定することテストである。言語問題や計算問題、暗記問題などの様々な分野から構成されている問題を解くテストである。テストの結果から、認知症の有無を確認することができる。

パレイドリアテスト（図 3.2 (b) 参照）は、壁のシミや雲の形がヒトの顔や動物の姿に見える現象（幻視）を見つけるテストである。テストの結果より、認知症の一種である、レビー小体型認知症の傾向があるかを発見できる。

トレイルメイキングテスト（図 3.2 (c) 参照）は、高齢者の思考、反応、動作の速度を測るテストである。作業が完了するまでにかかる時間を計測する。トレイルメイキングテストは、A・Bに分かれており難易度が異なる。

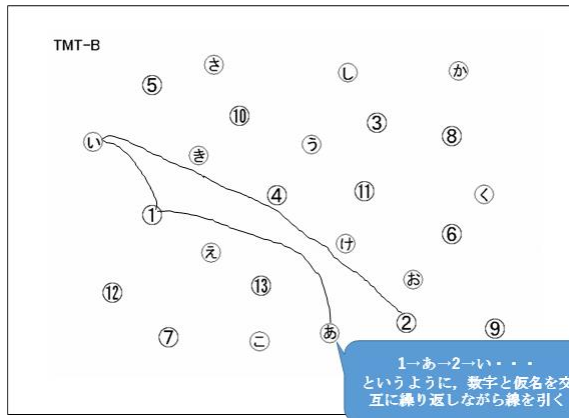
CDR（図 3.2 (d) 参照）は、認知症の重症度を評定する為の検査である。専門医が患者やその家族との問診により、記憶、見当識、判断力や問題解決、社会適応、家族状況および趣味・関心、介護状況の6項目を5段階で評価する。



(a) MMSE テストの一例



(b) パレイドリアテストの一例



(c) トレイルメイキングテストの一例

CDR	障害				
	なし 0	軽い 0.5	軽度 1	中等度 2	重度 3
記憶 (M)	記憶障害なし 程度の一貫しない 物忘れ	一貫した軽い物忘れ 出来事も部分的に 思い出す良性格	中程度記憶障害 特に最近の出来事 に関するもの 日常生活に支障	重度記憶障害 断片的記憶のみ残 存する程度	重度記憶障害 断片的記憶のみ残 存する程度
見当識 (O)	見当識障害なし	時間的関連の軽度 の困難さ以外は障 害なし	時間的関連の障害 中程度あり、昼夜 では場所の見当識 良好、他の場所で 時に地誌的失見当	時間的関連の障害 重度、通常時間 の失見当、しばしば 場所の失見当	人物への見当識 のみ
判断力と 問題解決 (JPS)	日常の問題を解決 仕事こなす 金銭管理良好 過去の行動と関連 した良好な判断	問題解決、種多性 提案の指摘におけ る中程度障害	問題解決、種多性 提案の指摘におけ る中程度障害	問題解決、種多性 提案の指摘におけ る中程度障害	問題解決不能
地域社会 活動 (CA)	通常の仕事、買 物、ボランティア、 社会的グループで 通常の自立した機 能	左記の活動の軽度 の障害	左記の活動のいく つかにかわって いても、自立できな い 一見正常	家庭外では自立不可 能 家族のいる家の外 に連れ出しても他 人の目には一見活 動可能に見える	家庭外では自立不可 能 家族のいる家の外 に連れ出しても他 人の目には一見活 動可能に見える
家庭生活 および 趣味・関心 (HH)	家での生活、趣味、 知的関心が十分に 持たれている	家での生活、趣味、 知的関心が軽度障 害されている	軽度しかし複雑な 家庭内での生活障 害、複雑な趣味や 関心の喪失	軽度しかし複雑な 家庭内での生活障 害、複雑な趣味や 関心の喪失	軽度しかし複雑な 家庭内での生活障 害、複雑な趣味や 関心の喪失
弁識状況 (PC)	セルフケア完全	援助が必要	援助が必要	援助が必要	援助が必要

(d) CDR の判定項目

図 3.2 認知機能検査の実施概要

次に、走行挙動の観測方法について述べる。本研究では、設置にかかる労力やコストを考慮して、GPS および加速度センサーを搭載した観測機器を車のダッシュボードに搭載して走行挙動を観測した。

本観測機器は、カーレーシングなどの走行挙動解析にも使われている Q-starz 社製の Q-starz GT BL-GT1000 (以下、観測機器と呼ぶ) を使用した (図 3.3 参照)。取得するデータは、0.1s 間隔で車両速度、三軸成分の加速度、方位角、緯度経度を計測する。

ここで、センサーが取得する加速度の向きについて述べる。X 軸成分は、車両の進行方向に対して、左右の加速度である。運転者から見て右側が正の符号を示す。Y 軸成分は、車両の進行方向に対して前後の加速度である。運転者から見て前方が正の符号を示す。Z 軸成分は、車両の進行方向に対して上下の加速度である。運転者から見て上方が正の符号を示す。また、操舵角の向きは、ハンドルを時計回りに回した時が正の符号を示す。

運転終了後は可能な範囲で、自身の運転を振り返っていただく運転日誌を記入していた

だいた (図 3.4 参照).

なお, 本調査は金沢大学との共同研究で行った. また, 観測調査は, 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.



図 3.3 走行挙動の観測に使用した機器

自動車運転日誌

16NAS
Car research ID 406
記入内容確認日 (西暦) 年 月 日
2 枚中 1 枚目

ご氏名 _____

加速度センサーを載せて自動車運転をおこなった日時、移動場所、運転時の様子を差し支えない範囲でご記入ください

日付	運転をおこなった時間 (記入例: 午前 7 時 30 分 ~ 午前 8 時 00 分)	移動場所 (記入例: 自宅→買い事→ スーパー→自宅)	運転を振り返って (記入例: ブレーキ操作ができなかった。 駐車が中々決まらなかった。目的地を途 中で忘れてしまった) など
6/26	前 11時00分 午後 2時00分	金沢病院→自宅	特に問題無し
6/29	前 8時00分 午後 2時00分	自宅→福井県→ コンビニ→自宅	信濃川を通過(下)で は十分注意しながら走行した。
7/1	前 10時00分 午後 2時00分	自宅→便利屋さん→ スパ→館	国道を通過(下)で無理に走ったか 外 車両距離と速度に注意し、 スピードを早くするといい
7/1	午後 1時00分 午後 2時00分	自宅→薬局→ガソリン スタンド 薬局→自宅	特に問題無し
7/2	前 11時00分 午後 2時00分	自宅→花火大会→ 飲食店→友人宅→館	交差点の狭い所で通過(下)で 車両距離と速度に注意し、 スピードを早くするといい
7/3	前 10時00分 午後 2時00分	自宅→コンビニ→ 大型スーパー→花火大会	コンビニとスーパーの間で 駐車場を利用(下)で注意し、 スピードを早くするといい
7/7	前 10時00分 午後 2時00分	自宅→美容院→スパ →館	特に問題無し
7/8	前 11時00分 午後 2時00分	自宅→裁判病院→館	特に問題無し
7/9	前 11時00分 午後 2時00分	自宅→スパ→自宅	特に問題無し

図 3.4 運転日誌の概要 (実際に調査に参加した被験者の記入)

3.2.3 被験者の個人属性、運転状況、認知機能検査の結果

ここでは被験者の個人属性、調査期間中の運転状況、認知機能検査の結果について述べる。表 3.3 に被験者の個人属性と調査期間中の運転状況を示す。被験者 30 名のうち、5 組（10 名）が一台の車を夫婦で使用していた。したがって、一台の車を共用している際は、二人分の走行挙動が一台の観測機器から観測される。各被験者の調査期間中の運転日数は表に示す通りである。

また、観測調査を実施する前に、運転技量について、自身および周りの方（家族やよく同乗する方）が思う運転の心配度合いについて 5 段階（1：全くない心配がない。2：少しだけ心配がある。3：ときどき心配になる。4：たいてい心配している。5：いつも心配している）で評価をしてもらった。周りの方からの評価よりも、自身で感じている評価の方が低く、多くの被験者が自身の運転を過小評価していることが明らかになった。

表 3.3 被験者の個人属性と調査期間中の運転状況

被験者	年齢	性別	調査期間中の運転日数 (運転時間)	運転技量評価		車両の 使用状況
				自身	他人	
ID1	75	女性	8 (8h36m)	2	2	共用使用
ID2	76	男性	12 (13h45m)	3	3	
ID3	72	女性	14 (16h28m)	2	1	共用使用
ID4	73	男性	10 (7h32m)	1	1	
ID5	70	男性	12 (13h13m)	1	2	共用使用
ID6	64	女性	9 (8h56m)	2	1	
ID7	74	男性	14 (17h32m)	1	1	共用使用
ID8	72	女性	12 (14h45m)	2	1	
ID9	76	男性	10 (11h10m)	2	2	共用使用
ID10	71	女性	8 (10h21m)	2	1	
ID11	73	男性	14 (15h27m)	2	2	単独使用
ID12	77	男性	14 (13h15m)	2	1	単独使用
ID13	73	女性	10 (11h54m)	1	1	単独使用
ID14	75	女性	10 (10h28m)	2	2	単独使用
ID15	75	女性	8 (9h56m)	1	1	単独使用
ID16	68	男性	12 (12h35m)	2	2	単独使用
ID17	72	女性	10 (11h47m)	2	2	単独使用
ID18	75	女性	14 (15h13m)	1	1	単独使用
ID19	69	女性	8 (8h55m)	2	1	単独使用
ID20	68	女性	14 (14h22m)	3	1	単独使用
ID21	71	女性	10 (11h25m)	2	1	単独使用
ID22	75	女性	10 (12h17m)	1	1	単独使用
ID23	80	男性	10 (11h34m)	2	2	単独使用
ID24	71	男性	14 (15h21m)	2	2	単独使用
ID25	72	女性	12 (11h10m)	1	1	単独使用
ID26	72	女性	9 (10h08m)	1	1	単独使用
ID27	72	男性	14 (14h03m)	2	1	単独使用
ID28	73	女性	12 (13h21m)	5	3	単独使用
ID29	72	男性	10 (9h15m)	2	2	単独使用
ID30	68	男性	9 (8h52m)	1	1	単独使用

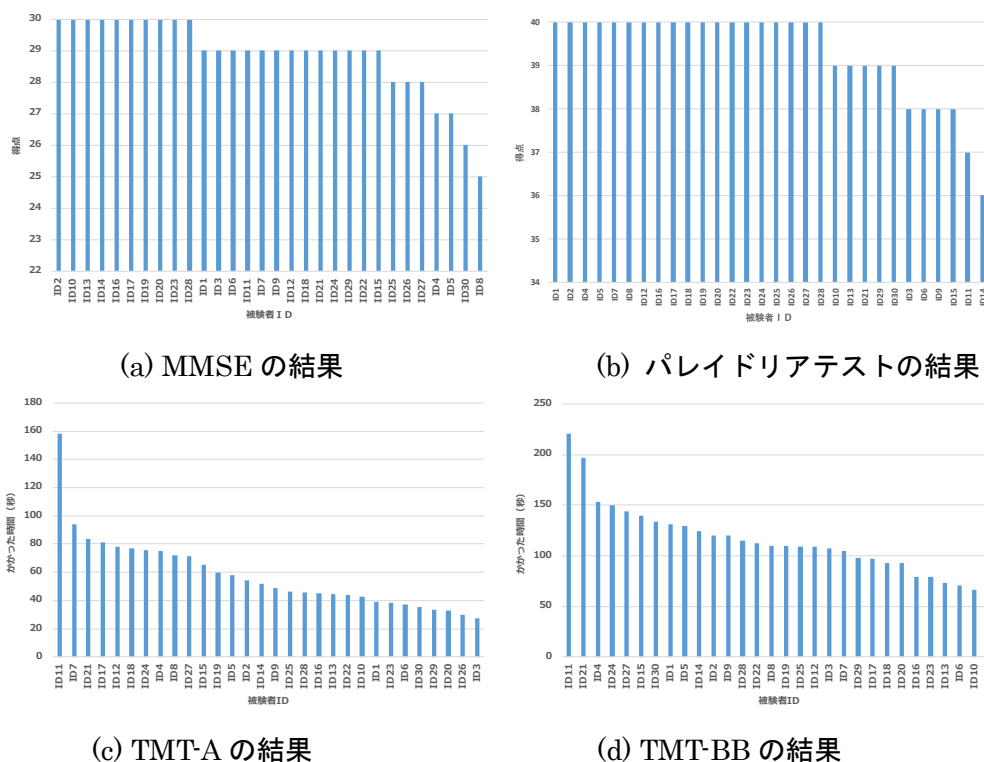
図 3.5 に認知機能検査の結果を示す。観測調査に参加した被験者全体の傾向を見るために、MMSE の正解数、パレイドリアテストの正解数、トレイルメイキングテスト A・B に

かかった時間を被験者ごとに示す。

図 3.5 (a) に SSEM の結果を示す。SSEM の得点が 24 点以下の場合は、認知症の可能性があるとされている。本調査では、検査結果が 24 点以下の被験者は見られなかった。図 3.5 (b) にパレイドリアテストの結果を示す。パレイドリアテストの結果は、明確な認知症の得点ラインが決まっていない。よって、ここでは全体的な傾向に着目する。図 3.5 (c) にトレイルメイキングテスト A の結果、図 3.5 (d) にトレイルメイキングテスト B の結果を示す。トレイルメイキングテストもパレイドリアテストと同様に、明確な認知症の得点ラインが決まっていない。よって、ここでは全体的な傾向に着目する。

なお、CDR の検査の結果は、被験者全員が 6 つ全ての検査項目で健康 (CDR=0) の結果となった。このことから、医師の問診の結果、認知症を罹患している被験者はいないことが明らかになった。

以上、4 つの認知機能検査の結果から被験者の認知能力について考察を述べた。認知機能に問題がある被験者は、本研究で実施した観測調査の被験者の中にはいないことが示された。



3.2.4 観測機器の精度検証

ここでは本研究で使用した観測機器の精度検証について述べる。観測機器の精度検証を行うことは、観測した走行挙動の信頼性や構築した手法の妥当性を検討する上で重要である。本研究では、普及率が高く、手軽にデータ観測ができるスマートフォン機器との比較を通して精度検証を行う。

近年、スマートフォンに内蔵されているセンサーの性能は、飛躍的に向上している。また、センサーの性能評価を行った既往研究⁴⁾⁵⁾も存在し、観測データの検証も十分に行われている。スマートフォンを用いて車両の走行挙動を観測した既往研究もある¹⁾³⁾。したがって、本研究で使用する観測機器がスマートフォンと同等の精度であることを確認し、使用する機器の精度検証を行うこととした。

表 3.4 に比較に用いる機器の概要を示す。本研究では、iphone7（以下、スマートフォンと呼ぶ）を使用した。スマートフォンに内蔵されているセンサーは、観測機器に備わる加速度センサー、GPS に加え、ジャイロセンサー、地磁気センサーを搭載している。また、周波数はどちらも可変型である。

加速度の測定レンジは、どちらも±3G となっている。一般的に、車両の走行挙動から観測される加速度は、±3G よりも小さい値が観測される。したがって、運転者が急加速や急減速、急ハンドルなどをした時の加速度も観測できる。

加速度の感度は、観測できる加速度の精度を示しており、観測機器は小数点第 6 位、スマートフォンは小数点第 9 位まで観測できる。一般的に、車両の走行挙動で観測される加速度は、小数点第 3 位から 4 位の値で分析が行われる。したがって、車両の走行挙動を分析するのに必要な加速度が観測できる。

表 3.4 加速度センサー機器の概要

型番	観測機器 QstarzGT BL-1000GT	スマートフォン iphone 7 (ios 12.1.4)
内蔵しているセンサー	・加速度センサー ・GPS	・加速度センサー ・GPS ・ジャイロセンサー ・地磁気センサー
周波数 (記録頻度)	10Hz or 1Hz (記録頻度の変更が可能)	10Hz or 1Hz (記録頻度の変更が可能)
加速度の測定レンジ	±3G	±3G
加速度の感度	小数点6桁	小数点9桁
機器の保存環境	動作温度: -10℃~60℃ 保管温度: -20℃~60℃	動作温度: -10℃~45℃ 保管温度: -20℃~45℃
走行挙動の観測までの手順	電源のON/OFF	電源のON/OFFに加え、アプリの起動を行う。

以上が、観測機器とスマートフォンの情報である。どちらの機器も加速度は、走行挙動を分析する上で必要な精度で観測できる可能性が明らかになった。そこで次に、実際に車両の

走行挙動を観測した時の走行挙動を比較した結果を述べる．検証方法について述べる．

2つの観測機器を車両に設置（図 3.6(a)参照）し，本学周辺（図 3.6(b)参照）を運転した時の走行挙動の観測を行った．ここでは，二つの方法で同等のデータが観測できているかを検証する．まず，二つの機器で観測した走行挙動データの類似度を Dynamic Time Warping 法（動的時間短縮法）で検証する．

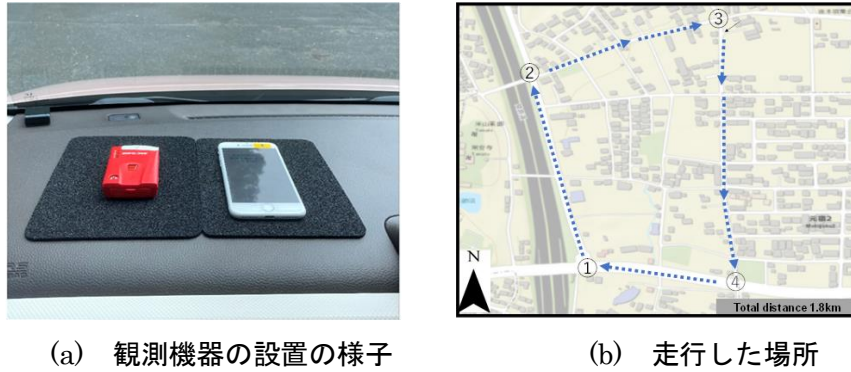


図 3.6 精度検証で実施した観測調査の概要

図 3.7 に DTW 法の概要を示す．DTW 法は，二つの時系列データの乖離度合いを定量化し，類似度（DTW 距離）を算出する．DTW 法は (3.1) 式が成り立つ．

$$DTW(x, y) = \min \sum_k^k |xw_k^x - yw_k^y| \quad (3.1)$$

二つの時系列データから算出される類似度が 1.0 以下の場合，観測した時系列データが近似していることを意味する．図 3.6 に示す運転したコースを①～④の 4 区間に分け，各区間の類似度を算出した．なお，表 3.4 より，加速度の精度は公表されているが，車両速度や操舵角は公表されていない．ここでは，車両速度，XYZ 軸成分の加速度成分，操舵角の検証を行う．

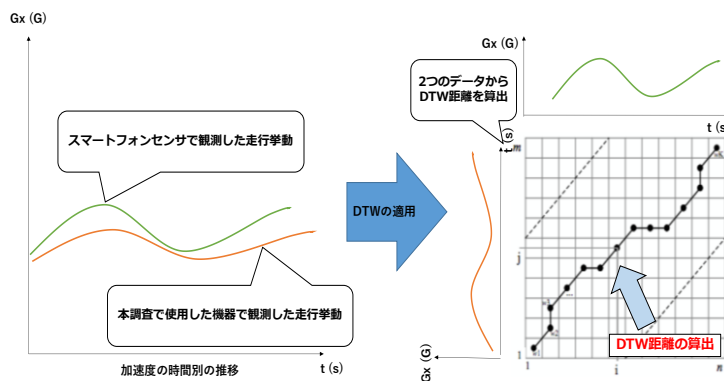


図 3.7 DTW の概要

表 3.5 に類似度の結果を示す．車両速度，XYZ 軸成分の加速度成分，操舵角は，どの区

間でも類似度が 1.0 を切る値となった。このことから、二つの機器で観測した走行挙動は、近似したデータであることが確認できた。

表 3.5 DTW の結果

項目	類似度 (DTW距離)			
	①-②	②-③	③-④	④-①
走行区間				
車両速度	0.52	0.61	0.23	0.58
X軸成分の加速度	0.76	0.88	0.81	0.61
Y軸成分の加速度	0.81	0.79	0.69	0.81
Z軸成分の加速度	0.91	0.63	0.74	0.90
操舵角	0.83	0.71	0.67	0.93

次に、2つの機器による観測データの同等性を検定する為に Welch の t 検定を行う。Welch の t 検定は、サンプリングした 2 標本が同等であるかを検定する。0.1s 間隔で観測している走行挙動が、全て独立していると考え検定を行う。

ここでは、「機器による観測値の差はない」を帰無仮説 H_0 、「機器による観測値の差はある」を対立仮説 H_1 として設定した。表 3.6 に同等性の検定結果を示す。全ての観測項目および観測区間で p 値は 0.05 を下回る結果となった。このことから帰無仮説 H_0 は棄却されず、両方の機器の観測値に差はないことが明らかになった。

表 3.6 同等性の検定結果

項目	p値			
	①-②	②-③	③-④	④-①
走行区間				
車両速度	p < 0.001	p < 0.001	p < 0.001	p < 0.001
X軸成分の加速度	0.0135	0.0089	0.0125	0.0079
Y軸成分の加速度	0.0049	0.0031	0.0058	0.0061
Z軸成分の加速度	p < 0.001	p < 0.001	p < 0.001	p < 0.001
操舵角	0.0072	0.0084	P < 0.001	P < 0.001

以上を踏まえると、本研究で使用する機器は、車両の走行挙動を観測する機器としての条件は満たしており、スマートフォンとの観測精度も概ね同等の条件で観測できることを示した。また、両者の操作性に着目すると、本研究で使用する機器の方が、ボタンの ON/OFF するだけなので、電子機器の取り扱いに慣れていない高齢運転者にとって適している可能性が示された。

3.3 交差点部の走行挙動の分類

3.3.1 交差点部の走行挙動の確認

ここでは観測機器から出力された交差点部の走行挙動の確認を行う。図 3.8 に被験者 ID1 の運転者が観測した、ある一日の走行挙動の様子を示す。被験者 ID1 は、自宅から目的地、目的地から自宅を図に示す経路で運転した。

観測された走行挙動の内、右折時の交差点部の走行挙動に着目すると、計 4 箇所の交差点で確認できた。それぞれの交差点の道路構造を見ると、①は車線数が片側 3 車線の交差点、②は車線数が片側 1 車線の交差点、③は車線数が両側 1 車線の交差点、④は車線数が両側 1 車線の交差点であることが明らかになった。



図 3.8 被験者 ID1 による一回の運転軌跡の様子

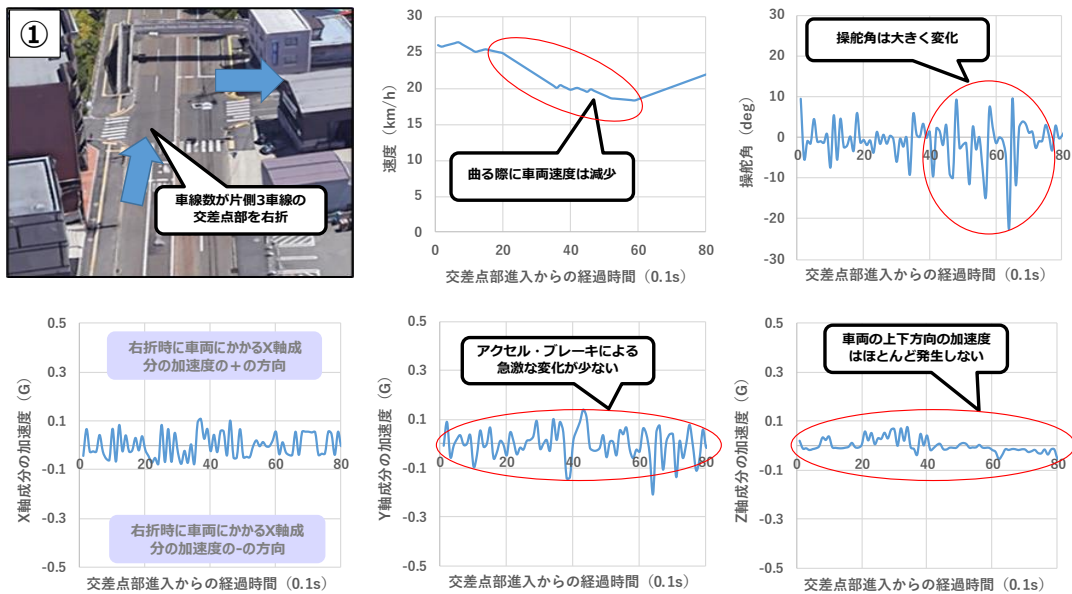
図 3.9 に①～④の交差点部で観測した走行挙動を示す。ここでは、車両速度、三軸成分の加速度、操舵角の値に着目する。①～④は、全て、右折時の交差点部の走行挙動であるが、データの大きさや時間経過ごとの変位が異なることが明らかになった。

例えば、車両速度に着目すると、①、②、④は、車両速度を落とさずに通過しているが、③は一度停車した状態から交差点を通過している。これは、道路混雑や前方車両や歩行者の有無、一時停止標識の有無などによって、車両の発進方法が異なっているからと考えられる。X 軸成分の加速度に着目すると、③、④は、急激な加速度の変化を観測している。これは通過する時に外に膨らんでから曲っているからと考えられる。Y 軸成分の加速度に着目すると、②、③、④は、急激な加速度の変化を観測している。これは通過する車線数の違いや前

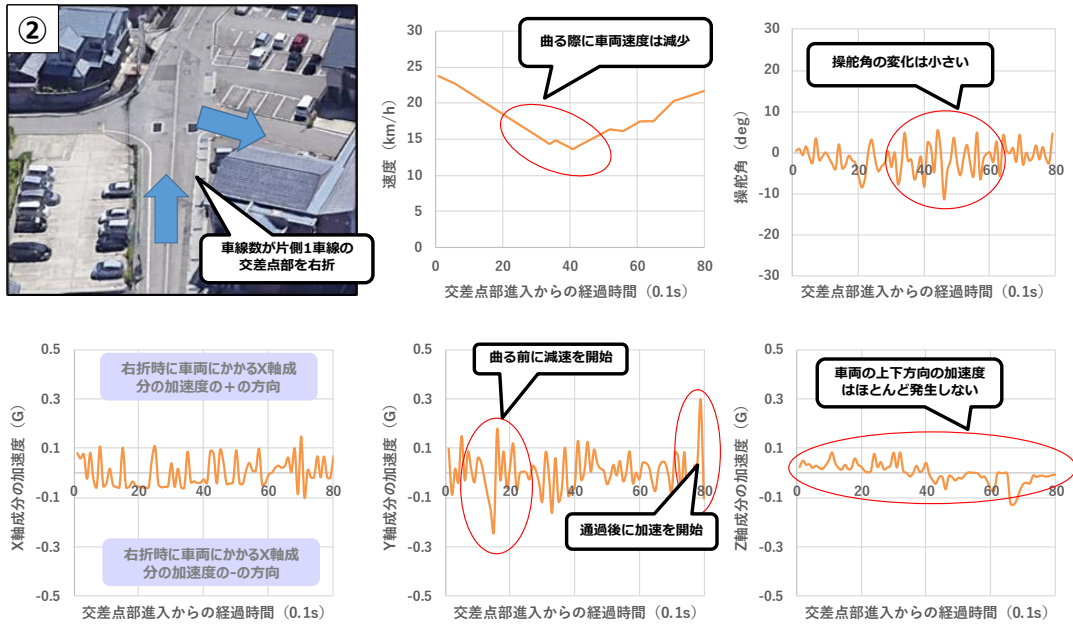
方車両の有無などによって、車両の曲り方が異なっているからと考えられる。Z軸成分の加速度に着目すると、大きな差は生じていないことが確認できる。Z軸成分の加速度は、車両から見て上下方向の加速度を表している。これは、道路面の凹凸が激しい場合やハンプがある場合に、Z軸成分の加速度が観測される。操舵角に着目すると、①、②、③は、交差点部に進入してから、しばらくした後に大きな操舵角の変化が生じているが、④は、交差点部に進入してから、早い段階で大きな操舵角の変化が生じている。これは、交差点部の形状が原因であると考えられる。

以上を踏まえると、交差点部の走行挙動を用いた異常運転検知を行う場合は、交差点部の構造や交通状況などの違いを考慮して検知すべきであると考えられる。そこで本研究では、交差点部の走行挙動の分類を試みる。

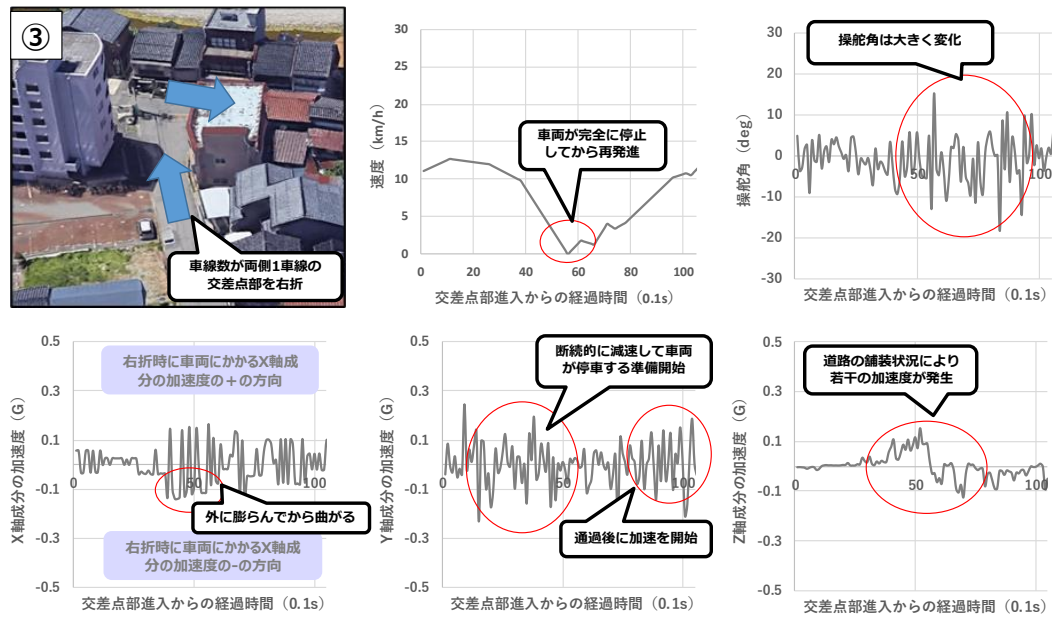
なお、交差点部の走行挙動の分類は、まず、交差点部での運転特性に関する既往研究をレビューする。次に、既往研究で得られた知見から、交差点部の走行挙動をどのように分類すべきかを検討する。最後に、検討した分類方法で、実際に観測調査で得られた走行挙動から、交差点部の走行挙動の抽出および分類を行う。



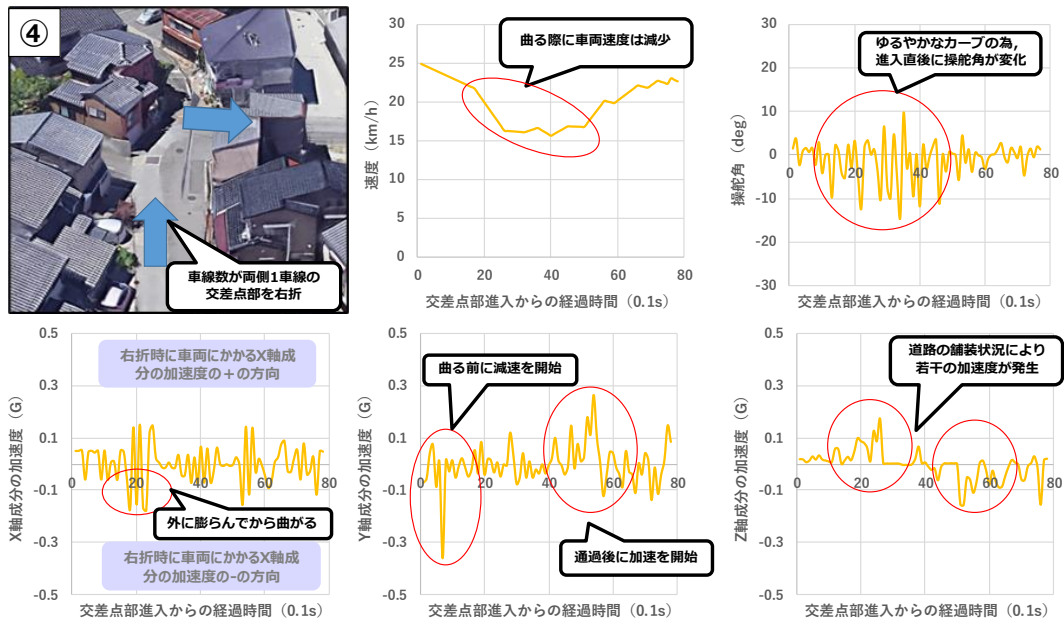
(a) 交差点①で観測した走行挙動の様子



(b) 交差点②で観測した走行挙動の様子



(c) 交差点③で観測した走行挙動の様子



(d) 交差点④で観測した走行挙動の様子

図 3.9 被験者 No.1 による一回の運転軌跡の様子

3.3.2 交差点部における運転特性に関する既往研究

ここでは交差点部における運転特性について知見を得た既往研究をレビューする。Aoude et al.⁶⁾ は、運転者は全ての交差点部において、同じ運転操作をしているわけではないと報告している。そこで、この知見を踏まえ、交差点部での道路の構造、曲る方向、発進方法について知見を得た既往研究に着目する。

Shigeta et al.⁷⁾ や鈴木ら⁸⁾ は、黄色信号時の交差点内付近での運転者が行う運転操作に着目した。運転者が交差点内を曲り始めるタイミングと曲り終わるタイミングは、交差点によって異なることを明らかにした。特に、運転者が判断に悩む傾向が強いジレンマゾーンにおいては、運転挙動が大きく異なることを明らかにした。

古谷ら⁹⁾ や橋本ら¹⁰⁾ は、道路の種類が異なる交差点内での運転者の運転操作に着目した。道路の種類は、幹線道路と非幹線道路（生活道路など）に分類することで、幹線道路と非幹線道路を運転した時の運転特性の違いを評価できることを明らかにした。

また、萩田ら¹¹⁾ や橋本ら¹²⁾ は、古谷ら⁹⁾ や橋本ら¹⁰⁾ の知見に加え、交差点部を流入部と流出部に分け、流入部と流出部の車線数の変化に応じて運転の誤操作に繋がりがやすいことを明らかにした。したがって、同一の運転者でも交差点部での車線数が異なる時は、走行挙動データを分けて分析を行った方が良い事が明らかになった。

周藤ら¹³⁾や鈴木ら¹⁴⁾は、交通事故の多い交差点での運転者の運転操作に着目した。交差点部での減速や加速方法が右左折・直進によって大きく異なることを明らかにした。したがって、同一の運転者でも車両の進行方向が異なる時は、走行挙動データを分けて分析を行った方が良い事が明らかになった。

Ming et al.¹⁵⁾や佐藤ら¹⁶⁾は、交差点内で一時停止をしてから発進する時の運転者の運転操作に着目した。一時停止をしてから交差点を曲がる時と停止をしないで交差点を曲がる時では、運転操作が異なることを明らかにした。したがって、同一の運転者でも車両の発進方向が異なる時は、走行挙動を分けて分析を行うべきことを示した。

以上の既往研究の知見を踏まえると、交差点部の走行挙動は、以下の観点を考慮すべきことが明らかになった。

- ・ 交差点部において車両が曲り始めるタイミングと曲り終わるタイミング
- ・ 交差点部において車両が通過する道路の種類
- ・ 交差点部において車両が通過する際の流入部と流出部の車線数の変化
- ・ 交差点部において車両が進行する方向
- ・ 交差点部において車両が発進する方法

車両が曲り始めるタイミングと曲り終わるタイミングは、主に、道路の構造に依存すると考えられる。例えば、規模が大きい交差点では、早い段階での運転動作の準備が必要となり、曲り始めるタイミングも早くなる。一方で、規模が小さい交差点は、運転動作の準備は曲がる直前になる。したがって、交差点の規模に応じて、交差点部の走行挙動として抽出する範囲を選択する必要がある。

交差点部での流入部と流出時の車線数の変化が分かれば交差点部において車両が通過する道路の種類は明らかにできると考えられる。例えば、車線数は片側2車線以上の道路は幹線道路であることが多い。一方で、両側1車線の道路は生活道路であることが多い。したがって、車線数の変化を考慮すれば、交差点部の道路の種類も考慮できる。

車両の発進方向は、車両が停止した状態から交差点部を通過する時と停止せずに通過する時の走行挙動に分類できると考えられる。この時、交差点部で観測した走行挙動から停車をしたのかどうかを車両速度から判別する必要がある。

車両の進行方向は、右折、左折、直進に分けられると考えられる。車両が右折、左折、直進を判別する為には、車両速度や操舵角、加速度から判別する必要がある。その為には、ある値がどのような変化をしたら車両がどの進行方向に向かったのかを明らかにする必要がある。

ある。

3.3.3 交差点部の走行挙動の分類

ここでは交差点部の走行挙動の分類を行う。3.3.1 で得られた知見を踏まえ、本研究では、**図 3.10** に示すように、交差点部の走行挙動を 54 種類（3 種類×3 種類×2 種類×3 種類）に分類することを考えた。

まず、流入部（片側 2 車線数以上、片側 1 車線数、両側 1 車線）と流出部（片側 2 車線数以上、片側 1 車線数、両側 1 車線）の車線数の変化から 3 種類×3 種類の 9 種類に分ける。次に、車両の発進方法（車両が停車せずに通過、車両が停車した状態から通過）を 2 種類に分ける。最後に、車両の進行方法（右折、直進、左折）から 3 種類に分ける。

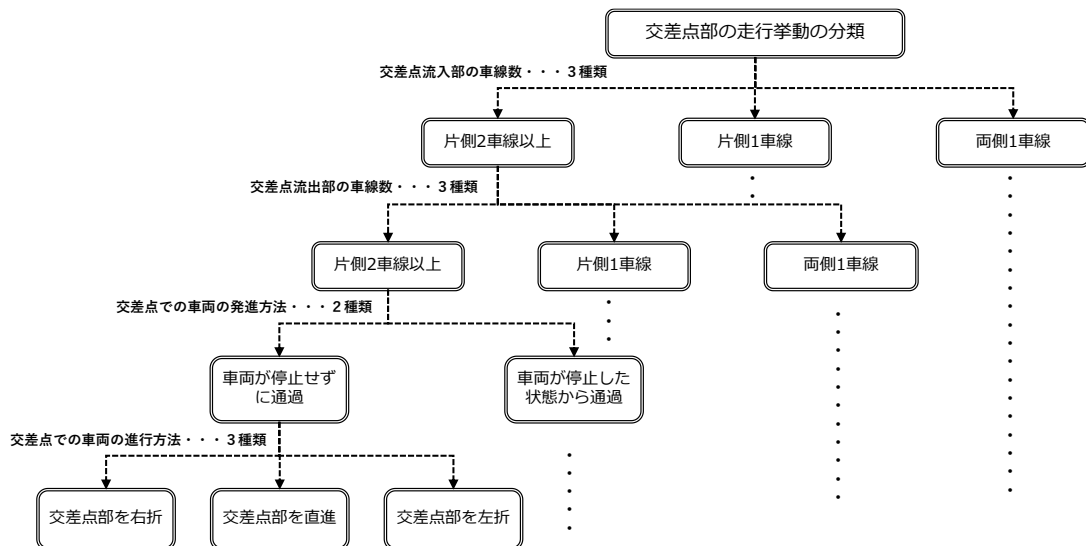


図 3.10 交差点部の走行挙動の分類の概要

なお、ここで分類した走行挙動以外の観測事例も考えられる。例えば、対向車や歩行者を通過させる為に中央分離帯で停車する場合がある。この時に観測される走行挙動のデータ長は極端に短くなるのが想定される。データ長が極端に短いと異常運転検知を行う際の検知精度や検知タイミングに影響を及ぼすので、本研究では分析の対象外とする。

なお、本研究で分類した 54 通りの交差点部の走行挙動は、観測機器から直接出力される走行挙動だけでは分類できない。走行挙動がどのような道路構造の場所を走行していたのかを把握する必要がある。そこで本研究では、デジタル道路網マップを活用して交差点部の走行挙動の抽出および分類を行う。

3.4 分析用データの作成

3.4.1 交差点部の走行挙動の抽出フロー

ここでは 3.3.2 で分類した交差点部の走行挙動を抽出および分類するフローについて述べる。図 3.11 にフローを示す。本フローは 6 つの工程に分かれている。各工程についての詳細はこの後の項で述べる。

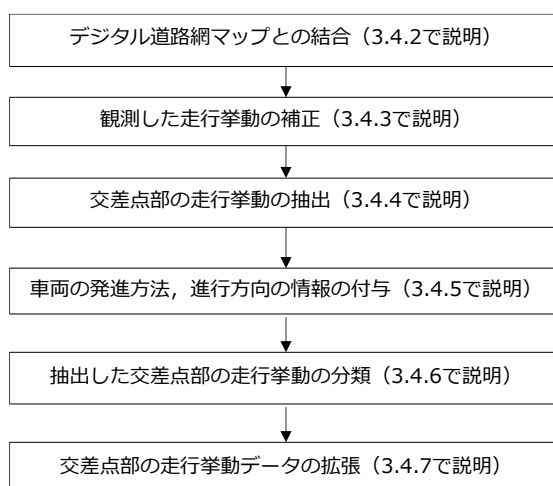


図 3.11 交差点部の走行挙動の抽出フロー

3.4.2 デジタル道路マップの結合

ここでは走行挙動データとデジタル道路マップの結合を行う。本研究では、観測機器で観測した走行挙動データにデジタル道路マップ (DRM) の情報の付与を行う。本研究では、GIS (地理情報システム) を介して、走行挙動と DRM の結合を行う。なお、既往研究^{17)・18)}も同様の方法で走行挙動と DRM の結合を行っている。

表 3.7 に DRM の概要を示す。本研究では、Esri 社で提供されている、ArcGIS データコレクション 2016 を使用する。DRM は、交差点に関する情報を含むノードデータと道路構造に関する情報を含むリンクデータから構成されている。

ノードデータは、交差点 ID や信号の設置状況、接続リンク数 (T字 or 十字の交差点) などの情報を有している。一方で、リンクデータは、道路 ID や道路種類、規制速度、一方通行等の交通規制情報、道路幅員、道路車線数などの情報を有している。

表 3.7 デジタル道路マップの概要

データ名称	Esri社 ArcGISデータコレクション2016
データソース	<ul style="list-style-type: none"> 株式会社ゼンリン地図データ 数値地図 (国土基本情報) 基盤地図情報 (数値標高モデル) 平成 22 年 国勢調査
ノードデータに含まれている情報	<ul style="list-style-type: none"> 交差点名称 信号の設置状況 (有り, 無し) 一時停止標識 (有り, 無し) 接続リンク数 (十字路, T字路, その他)
リンクデータに含まれている情報	<ul style="list-style-type: none"> 道路種類 (高速道路, 国道, 県道, 市道, その他の道路) 規制速度 (km/h) 一方通行等の交通規制情報 (有り, 無し) 道路幅員 道路車線数

本研究では、これらの情報を走行挙動に付与し、通過した交差点部を把握できると考えた。図 3.12 に走行挙動、ノードデータ、リンクデータをプロットした結果を示す。以下に、走行挙動への結合方法を示す。まず、走行挙動にリンクデータの情報を付与する。観測した走行挙動の近くに位置するリンクデータの情報を付与する。

次に、ノードデータの情報の付与を行う。ノードデータは、交差点部の中心から半径 30m に含まれる走行挙動に付与する。30m と設定した理由は、3.4.4 で述べる、最も大きな交差点規模で観測する交差点部の走行挙動を半径 30m としたからである。したがって、ここでは最も大きい交差点規模に合わせてノードを付与し、後で、交差点の規模に合わせて抽出を行う。

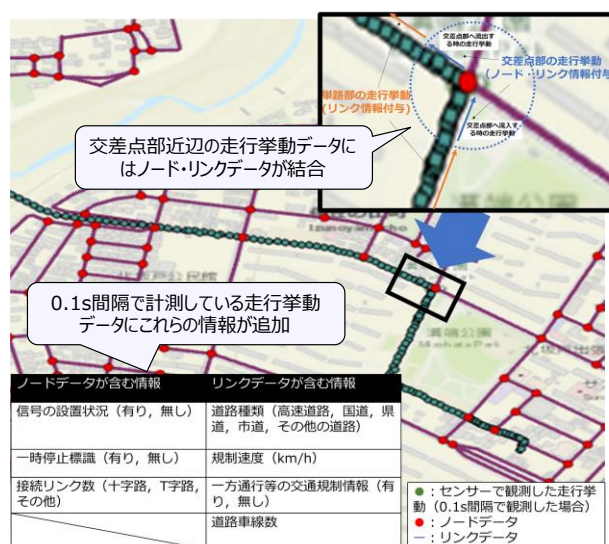


図 3.12 DRM と走行挙動データを GIS 上にプロットした時の一例

3.4.3 走行挙動データの補正

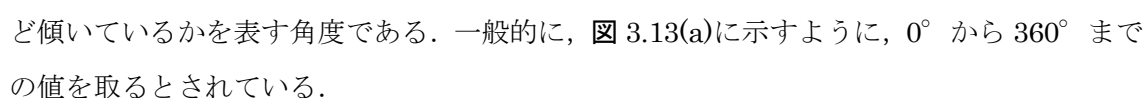
ここでは観測機器の傾きを考慮した走行挙動の補正方法について述べる。本研究で実施した観測調査は、被験者の車に観測機器を取り付ける際に、運転中に機器が動かないように固定して設置した。しかしながら、機器は運転の際の振動によって、傾いてしまう可能性がある。その場合、観測する加速度成分に影響を及ぼす。よって、ここでは、被験者の車両に取り付けた観測機器が何らかの拍子で動いてしまった時を想定して補正を行う。

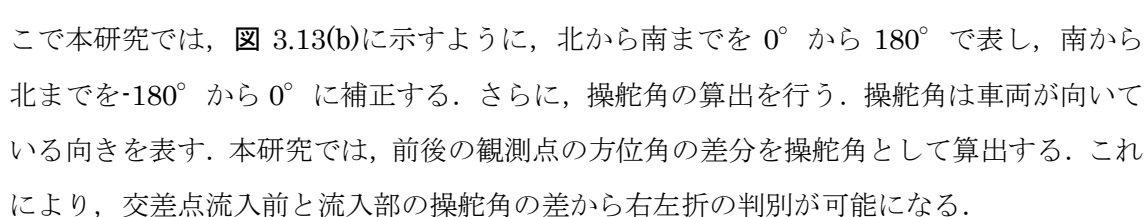
八木¹⁹⁾や木山ら²⁰⁾によると、車両が停車（静止）している時の3軸成分の加速度から機器の傾きの補正ができるとされている。そこで、本研究でも機器の傾き度合いを算出し、加速度成分の補正を試みる。

加速度センサーは水平な場所に設置し、加速度がかからない状態のときは、3軸成分にかかる加速度は0に近い値となる。しかしながら、例えば、観測機器が傾いた状態で設置されていると、加速度がかかっていなくても、傾いている成分の加速度が算出される。したがって、車両が完全に停車（静止）している時の加速度成分の値を算出することで機器の傾きを検知し、観測した走行挙動データの補正を行うことが可能である。

機器が傾斜した状態で車両が動いている時の端末座標系における x, y, z 軸の加速度成分を G'_x, G'_y, G'_z 、機器が傾斜した状態で車両が静止されていた時の、端末座標系における x, y, z 軸の平均の加速度成分を gx, gy, gz とする時、補正後の加速度成分である Gx, Gy, Gz は以下の (3.2) 式が成り立つ。

$$\begin{pmatrix} G_x \\ G_y \\ G_z \end{pmatrix} = (gx)(gy)(gz) \begin{pmatrix} G'_x \\ G'_y \\ G'_z \end{pmatrix} \quad (3.2)$$

次に、方位角の補正について述べる。観測機器に内蔵されている GPS は、緯度・経度の情報に加えて方位角が算出されている。方位角は、真北を 0° とした時に、真北からどれほど傾いているかを表す角度である。一般的に、 3.13(a)に示すように、 0° から 360° までの値を取るとされている。

しかしながら、この表記では、交差点部を曲がる際の方向を判別することができない。そこで本研究では、 3.13(b)に示すように、北から南までを 0° から 180° で表し、南から北までを -180° から 0° に補正する。さらに、操舵角の算出を行う。操舵角は車両が向いている向きを表す。本研究では、前後の観測点の方位角の差分を操舵角として算出する。これにより、交差点流入前と流入部の操舵角の差から右左折の判別が可能になる。

最後に、ローパスフィルタを用いた補正について述べる。機器で観測した走行挙動データには、エンジンの振動や道路の凹凸などによって生じる小さなノイズが含まれていると考

えられる。この小さなノイズを考慮せずに分析を行うことは、運転者の僅かな異常を検知する本手法の検知精度や検知タイミングに影響を及ぼす可能性がある。

そこで本研究では、ローパスフィルタを用いてノイズ除去処理を行う。ローパスフィルタは、ある周波数信号の低域周波数のみを通過させるフィルタである。エンジンの振動や道路の凹凸などによって生じる小さなノイズは、高い周波数であるとされている。したがって、高い周波数の通過を防ぐローパスフィルタは、車両の走行挙動データを補正する方法として適していると考えられる。この時、ローパスフィルタは (3.3) 式が成り立つ

$$y[i] = \alpha \cdot y[i - 1] + (1 - \alpha) \cdot x[i] \quad (3.3)$$

なお、(3.2) 式における α は、フィルタの強度を指す。八木¹⁹⁾ や木山ら²⁰⁾ によると、最も右左折判別ができる α の値は、0.1 であると報告している。そこで本研究でも、この知見を活用して α は 0.1 とする。x と y は、時刻 i における入力値と出力値を示す。機器で観測した車両速度、X,Y 軸成分の加速度、方位角にローパスフィルタをかける。

以上、観測した走行挙動データを補正する方法について述べた。本研究では、観測機器の傾きだけでなく、GPS から得られる方位角やエンジンの振動や道路の凹凸などによって生じる小さなノイズなどの補正を行った上で、異常運転検知手法の開発に取り組む。

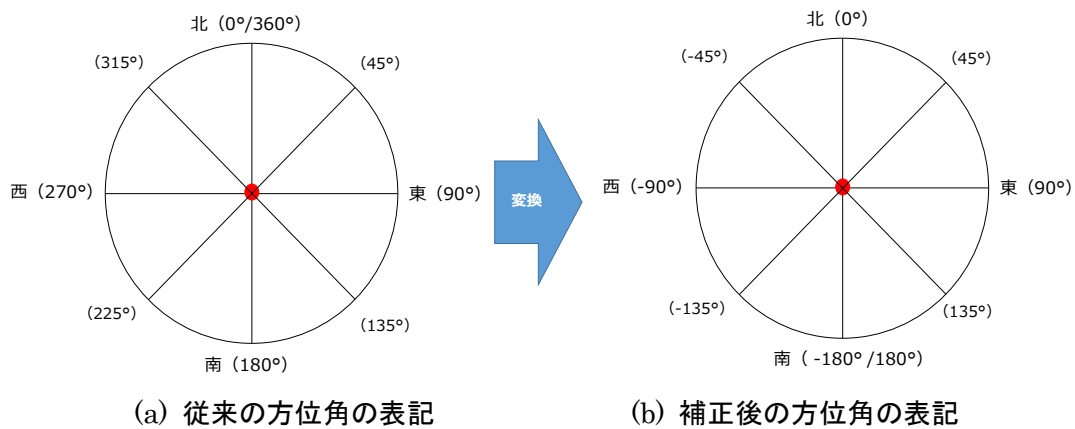


図 3.13 方位角の補正方法

3.4.4 交差点部の走行挙動の抽出



ここでは交差点部の走行挙動の抽出を行う。3.4.2 で、走行挙動にリンクデータとノードデータの情報の付与を行った。リンクデータは、全ての場所で観測された走行挙動に付与を行ったが、ノードデータは交差点部の中心から半径 30m に含まれる走行挙動のみ付与した。

須藤ら²¹⁾ や鈴木ら²²⁾ によると、車両の走行挙動は、交差点の規模によって観測される特性が異なると報告されている。既往研究の知見を踏まえ、図 3.14 に交差点部の走行挙動の

抽出範囲を示す。

そこで本研究では、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つに分類する。

交差点流入部の車線数が片側2車線以上の場合は、交差点の中心から半径30mに含まれる走行挙動を大規模な交差点部での走行挙動として抽出する。交差点流入部の車線数が片側1車線の場合は、交差点の中心から半径20mに含まれる走行挙動を、中規模な交差点部での走行挙動データとして抽出する。交差点流入部の車線数が両側1車線の場合は、交差点の中心から半径10mに含まれる走行挙動を、小規模な交差点部での走行挙動データとして抽出する。なお、抽出した範囲（30m, 20, 10m）の決定は、その範囲内に交差点部が含まれていればよく、交差点部が含まれている範囲を基に決定した。



(a) 流入部の車線数が片側2車線以上 (b) 流入部の車線数が片側1車線



(c) 流入部の車線数が両側1車線

図 3.14 交差点部の走行挙動の抽出範囲

3.4.5 車両の発進方法・進行方向の判別

ここでは交差点部での車両の発進方法と進行方向の判別を行う。交差点部において、車両の発進方法や車両の進行方向の判別を行う為には、判別に用いる閾値を超えたかどうかで判断する。

3.3.2でも述べたように、車両の発進方法は、交差点流入部で停車した状態から通過するのか、交差点流入部で停車せずに通過した場合に分ける。この時の違いは、交差点流入部で停車した状態から通過する時は、車両の速度が限りなく、0 km/h に近い値となると考えられる。そこで、以下の(3.4)式を満たしたときは、交差点流入部で停車した状態から通過したと判断する。

$$V_{\min} < 5 \text{ (km/h)} \quad (3.4)$$

判別に用いる閾値を5 km/h と設定した理由は、例えば、一時停止標識などがある場所で停車する際に、完全に停車をしない運転者が一定数、存在すると考えたからである。その為、閾値を0 km/h ではなく5 km/h と設定した。なお、交差点の中央部で対向車や横断歩道を渡る歩行者を待つ為に車両が一度停車する場合があるが、この判別は、抽出したデータ長から判断できる。

次に、車両の進行方向の判別に用いる閾値について述べる。3.3.2でも述べたように、車両の進行方向は、左折・直進・右折に分ける。左折・直進・右折時の走行挙動の違いは、操舵角と加速度が異なるとされている。

水島ら²³⁾や牧野ら²⁴⁾によると、右折の際には加速度成分と操舵角が正の方向へ、左折の際には加速度成分と操舵角が負の方向へ変化すると報告されている。そこで交差点部において、時間窓 T_t (sec) を交差点部の進入地点から流出地点として設け、時間窓内の加速度成分および操舵角の変化に着目する。これにより、右左折の検知が可能である。

図 3.15 に右折時の走行挙動の一例を示す。時間窓は、交差点部に進入する時点を T_0 とする。交差点部を流出する地点を T_N とする。この二点間で観測した操舵角と加速度の値から右折の判断を行う。なお、操舵角および加速度の変位の色の濃淡は、それぞれの値の強弱を示している。

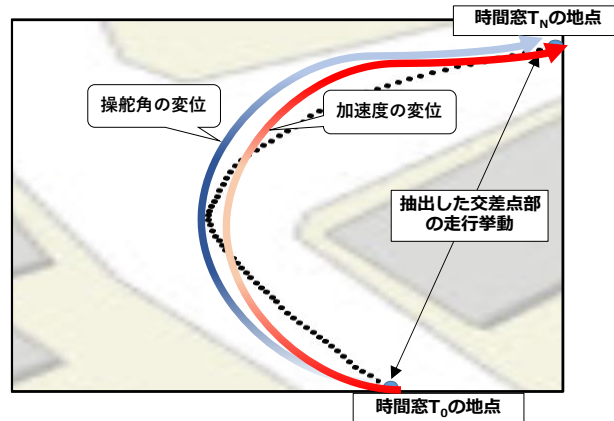


図 3.15 交差点部における時間窓の設定

表 3.8 に閾値を示す。なお、交差点部の流入部の車線数に応じて設定する閾値が異なると報告されており、本研究でもこの知見を踏まえて、流入部の車線数に応じて、右折・直進・左折を判別する時の加速度と操舵角の閾値を変えた。

交差点部を右折する時の閾値は、以下の (3.5) 式を満たしたときとする。

$$a \max x_t - a \min x_t > aT_t \wedge d \max x_t - d \min x_t > dT_t \quad (3.5)$$

交差点部を左折する時の閾値は、以下の (3.6) 式を満たしたときとする。

$$|a \min x_t| - |a \max x_t| < aT_t \wedge |d \min x_t| - |d \max x_t| < -dT_t \quad (3.6)$$

(3.5) 式, (3.6) 式を満たさない時の走行挙動が観測されたときは、直進時の走行挙動であると判断した。

表 3.8 検知パラメータの設定値

流入部の車線数が2車線数以上の時	操舵角閾値 : $d \max_t, d \min_t$	10.0 (deg)
	加速度閾値 : $a \max_t, a \min_t$	0.05 (G)
	方位・加速時間窓 : T_t	進入地点から流出地点の区間
流入部の車線数が片側1車線数の時	操舵角閾値 : $d \max_t, d \min_t$	8.5 (deg)
	加速度閾値 : $a \max_t, a \min_t$	0.05 (G)
	方位・加速時間窓 : T_t	進入地点から流出地点の区間
流入部の車線数が両側1車線数の時	操舵角閾値 : $d \max_t, d \min_t$	7.0 (deg)
	加速度閾値 : $a \max_t, a \min_t$	0.03 (G)
	方位・加速時間窓 : T_t	進入地点から流出地点の区間

3.4.6 抽出した交差点部の走行挙動の分類

ここでは抽出した交差点部の走行挙動の分類を行う。ここまでの得られた全ての情報を

活用することで、交差点部の走行挙動を 54 通りに分類することが可能である(表 3.9 参照)。

表 3.9 本研究で分類した交差点部の走行挙動の運転動作

Case	車線数の変化	発進方法	進行方向
1	片側2車線以上 →片側2車線以上	停止せずに通過	右折
2			直進
3			左折
4		停止状態から発進	右折
5			直進
6			左折
7	片側2車線以上 →片側1車線	停止せずに通過	右折
8			直進
9			左折
10		停止状態から発進	右折
11			直進
12			左折
13	片側2車線以上 →両側1車線	停止せずに通過	右折
14			直進
15			左折
16		停止状態から発進	右折
17			直進
18			左折
19	片側1車線 →片側2車線以上	停止せずに通過	右折
20			直進
21			左折
22		停止状態から発進	右折
23			直進
24			左折
25	片側1車線 →片側1車線	停止せずに通過	右折
26			直進
27			左折
28		停止状態から発進	右折
29			直進
30			左折
31	片側1車線 →両側1車線	停止せずに通過	右折
32			直進
33			左折
34		停止状態から発進	右折
35			直進
36			左折
37	両側1車線 →片側2車線以上	停止せずに通過	右折
38			直進
39			左折
40		停止状態から発進	右折
41			直進
42			左折
43	両側1車線 →片側1車線	停止せずに通過	右折
44			直進
45			左折
46		停止状態から発進	右折
47			直進
48			左折
49	両側1車線 →両側1車線	停止せずに通過	右折
50			直進
51			左折
52		停止状態から発進	右折
53			直進
54			左折

3.4.2 から 3.4.6 の工程より、作成されたデータの一例を図 3.16 に示す。上の行にあるデータは、交差点部に進入した直後に観測された走行挙動である。一方で、下の行にあるデータは、交差点部を通過する直前に観測された走行挙動である。

なお、一行しかない項目は、54 通りに分類する為に DRM との結合した後から加えた情報である。交差点部の流入部と流出部の車線数の変化、車両の発進方法、車両の進行方向を示している。

観測機器から出力された走行挙動 (補正後)										DRMと走行挙動の結合から判明した情報				
観測点ID	観測日	観測時刻	緯度	経度	車両速度	操舵角	X軸成分の加速度	Y軸成分の加速度	Z軸成分の加速度	流入部の車線数	流出部の車線数	車両の発進方法	車両の進行方向	判別ケース
0	2020/4/7	18:57:28	36.57997208	136.6600814	18.0491460	-0.1886097	0.0520432	-0.0119637	0.0814561	3	3	1	2	50
1	2020/4/7	18:57:29	36.57996966	136.6600866	18.2234079	-2.3131950	0.0089770	-0.0444131	0.0433607	3	3	1	2	50
2	2020/4/7	18:57:29	36.57996935	136.6600992	18.4036690	-0.9116529	0.0493087	-0.0175863	0.0461406	3	3	1	2	50
3	2020/4/7	18:57:29	36.57996975	136.6600975	18.5839309	-1.7086525	0.0455888	-0.0175863	0.0461406	3	3	1	2	50
4	2020/4/7	18:57:29	36.57996993	136.6601034	18.7641929	-0.6638859	0.0520856	-0.0175863	0.0461406	3	3	1	2	50
5	2020/4/7	18:57:29	36.57996935	136.6601091	18.9444504	-1.4801943	0.0486970	-0.0175863	0.0461406	3	3	1	2	50
6	2020/4/7	18:57:29	36.57996888	136.660115	18.998130	3.7443807	0.0180776	-0.0175863	0.0461406	3	3	1	2	50
7	2020/4/7	18:57:29	36.5799681	136.6601205	19.0342862	1.3780254	-0.0038168	-0.0175863	0.0461406	3	3	1	2	50
8	2020/4/7	18:57:29	36.57996722	136.6601261	19.0714704	-2.9782396	-0.0059685	0.0019180	-0.0175863	3	3	1	2	50
9	2020/4/7	18:57:29	36.5799666	136.6601318	19.1088248	-0.0730742	0.0128273	0.0025396	-0.0175863	3	3	1	2	50
10	2020/4/7	18:57:29	36.57996597	136.6601375	19.1456672	-0.7845204	-0.0035609	-0.0008798	-0.0175863	3	3	1	2	50
11	2020/4/7	18:57:29	36.5799654	136.6601432	19.1824083	-0.0693250	0.0128005	0.0013776	-0.0175863	3	3	1	2	50
12	2020/4/7	18:57:29	36.5799648	136.6601492	19.2196484	0.5624587	-0.0005024	-0.0047434	-0.0175863	3	3	1	2	50
13	2020/4/7	18:57:30	36.57996417	136.660155	19.2566893	2.008354	-0.0955416	0.0008728	-0.0175863	3	3	1	2	50
14	2020/4/7	18:57:30	36.57996328	136.6601613	19.2937249	-3.5336754	-0.0056657	-0.0003266	0.0274531	3	3	1	2	50
15	2020/4/7	18:57:30	36.57996277	136.6601677	19.6974614	-1.0160051	0.1101500	-0.0348118	0.0238999	3	3	1	2	50
16	2020/4/7	18:57:30	36.57996203	136.6601743	20.1378679	4.1856880	0.0712992	-0.0989754	-0.0784083	3	3	1	2	50
17	2020/4/7	18:57:30	36.5799614	136.6601808	20.5819397	-4.5962176	-0.1001218	-0.0296791	-0.0429362	3	3	1	2	50
18	2020/4/7	18:57:30	36.57996102	136.6601873	20.7180209	2.0589904	0.0198270	-0.0028001	0.0942043	3	3	1	2	50
19	2020/4/7	18:57:30	36.57996037	136.6601939	20.8233030	-0.1556706	-0.0200950	-0.0007602	0.0200280	3	3	1	2	50
20	2020/4/7	18:57:30	36.57995977	136.6602003	20.9255052	1.5387878	0.0230811	-0.0121284	0.0301882	3	3	1	2	50
21	2020/4/7	18:57:30	36.57995919	136.6602068	21.0273994	-3.2502794	-0.0194661	-0.0028999	-0.0355919	3	3	1	2	50
22	2020/4/7	18:57:30	36.57995858	136.6602133	21.1292628	-0.0505810	0.0276746	-0.0003067	0.0773608	3	3	1	2	50
23	2020/4/7	18:57:30	36.57995799	136.6602197	21.2311232	0.4170014	-0.0126788	-0.0147273	-0.0625160	3	3	1	2	50
24	2020/4/7	18:57:30	36.57995740	136.6602259	21.3329832	-0.6939941	-0.0198971	-0.0119087	-0.0554095	3	3	1	2	50
25	2020/4/7	18:57:30	36.57995681	136.6602322	21.4348432	1.4775206	0.0263936	-0.0068326	0.0683483	3	3	1	2	50

図 3.16 作成されるデータの一例と各項目の説明

本フローから作成された走行挙動は、図 3.17 に示すように交差点部ごとに独立したデータとなる。例えば、観測装置を搭載した車両が⑤から⑥へ運転した時、本フローによって、4つの交差点部の走行挙動が観測される。




図 3.17 作成されるデータ

上記の手順で、観測調査期間中に得られた被験者ごとの各ケースの走行挙動の数を表 3.10 に示す。ケース 1～ケース 6, ケース 25～ケース 30, ケース 49～ケース 54 は、比較的、多くのデータが観測されていることが明らかになった。

表 3.10 観測調査で観測した交差点部の走行挙動

(a) ケース 1 からケース 18 (ID1~ID15)

Case/ID	ID1	ID2	ID3	ID4	ID5	ID6	ID7	ID8	ID9	ID10	ID11	ID12	ID13	ID14	ID15
1	64	42	74	25	44	48	32	47	38	22	59	34	36	34	29
2	222	90	324	85	82	82	86	106	148	122	214	324	120	82	82
3	51	34	176	32	36	38	36	41	29	32	34	176	41	26	28
4	26	22	24	20	20	28	24	12	32	21	36	24	23	22	18
5	22	30	30	40	40	40	32	42	69	66	56	40	54	41	30
6	28	24	22	35	20	18	14	18	24	30	21	32	22	12	15
7	2	4	-	-	-	-	16	-	-	4	-	10	8	8	12
8	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
9	6	10	-	-	-	-	20	-	-	2	-	6	4	12	18
10	-	2	-	-	2	4	-	-	-	-	-	-	-	2	4
11	-	-	-	2	-	-	2	-	-	-	-	-	2	-	-
12	-	-	4	-	-	-	-	-	-	-	-	4	-	-	-
13	18	18	-	-	2	8	16	-	-	-	-	-	-	2	8
14	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
15	-	2	-	-	2	-	2	-	16	-	-	-	-	2	-
16	2	-	-	-	-	-	-	-	-	-	-	-	-	-	-
17	-	-	2	-	-	-	-	-	-	-	-	2	-	-	-
18	-	-	-	-	-	2	-	-	-	-	-	-	-	-	2

- : 本観測調査では観測されなかった走行挙動

(b) ケース 1 からケース 18 (ID16~ID30)

Case/ID	ID16	ID17	ID18	ID19	ID20	ID21	ID22	ID23	ID24	ID25	ID26	ID27	ID28	ID29	ID30
1	48	68	44	30	24	42	34	42	26	33	60	41	30	31	66
2	312	318	328	204	328	318	136	140	99	147	476	116	196	228	260
3	132	154	336	72	336	154	48	24	35	24	58	56	42	94	84
4	30	28	40	30	20	38	42	36	20	23	26	34	38	34	24
5	54	64	66	54	66	64	66	57	42	63	66	74	62	80	32
6	28	20	32	28	32	20	26	27	12	31	38	21	26	36	24
7	6	16	4	4	10	6	8	-	7	6	16	4	4	10	6
8	-	-	4	-	-	-	-	-	-	-	-	4	-	-	-
9	7	10	-	10	12	8	6	10	8	7	10	-	10	12	8
10	-	2	4	2	-	-	2	-	-	-	2	4	2	-	-
11	-	2	-	-	-	-	-	-	-	-	2	-	-	-	-
12	-	4	4	-	2	-	2	-	2	-	4	4	-	2	-
13	5	14	4	12	14	2	6	2	2	5	14	4	12	14	2
14	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
15	-	-	4	20	6	2	-	-	-	-	-	4	20	6	2
16	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
17	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
18	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-

- : 本観測調査では観測されなかった走行挙動

(c) ケース 19 からケース 36 (ID1~ID15)

Case/ID	ID1	ID2	ID3	ID4	ID5	ID6	ID7	ID8	ID9	ID10	ID11	ID12	ID13	ID14	ID15
19	2	4	-	-	-	-	16	-	-	4	-	10	8	8	12
20	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
21	6	10	-	-	-	-	20	-	-	2	-	6	4	12	18
22	-	2	-	-	2	4	-	-	-	-	-	-	-	2	4
23	-	-	-	2	-	-	2	-	-	-	-	-	2	-	-
24	-	-	4	-	-	-	-	-	-	-	-	4	-	-	-
25	50	34	78	78	80	34	280	78	42	34	48	12	34	26	76
26	632	438	372	372	532	276	1414	372	336	330	442	106	364	164	914
27	288	132	138	138	312	202	624	138	24	88	158	96	124	26	458
28	32	28	72	72	72	12	128	72	32	12	48	32	68	24	96
29	40	16	72	72	80	16	120	72	32	72	24	32	24	40	32
30	32	8	20	20	40	4	104	20	16	20	20	20	48	16	40
31	18	18	-	-	-	-	16	-	-	-	-	-	-	2	8
32	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
33	-	2	-	-	-	-	2	-	-	-	-	-	-	2	-
34	2	-	-	-	-	-	-	-	-	-	-	-	-	-	-
35	-	-	-	-	-	-	-	-	-	-	-	2	-	-	-
36	-	-	-	-	-	-	-	-	-	-	-	-	-	-	2

- : 本観測調査では観測されなかった走行挙動

(d) ケース 19 からケース 36 (ID16~ID30)

Case/ID	ID16	ID17	ID18	ID19	ID20	ID21	ID22	ID23	ID24	ID25	ID26	ID27	ID28	ID29	ID30
19	1	-	4	-	-	-	8	-	7	6	16	4	4	10	6
20	5	14	4	12	14	2	-	-	-	-	-	4	-	-	-
21	-	-	4	20	6	2	6	10	8	7	10	-	10	12	8
22	-	-	-	-	-	-	2	-	-	-	2	4	2	-	-
23	-	-	-	-	-	-	-	-	-	-	2	-	-	-	-
24	-	-	-	-	-	-	2	-	2	-	4	4	-	2	-
25	68	22	24	30	24	22	34	26	36	31	82	28	16	78	100
26	312	318	328	204	328	318	136	498	505	511	824	468	374	996	1220
27	132	154	336	72	336	154	48	152	183	170	124	84	166	198	398
28	20	36	20	20	20	36	24	52	86	48	68	56	52	60	52
29	56	56	24	16	24	56	24	40	80	60	112	112	72	64	80
30	16	20	24	16	24	20	12	44	62	40	80	24	60	52	44
31	-	-	-	-	-	-	6	2	2	5	14	-	12	14	2
32	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
33	-	-	-	-	-	-	-	-	-	-	-	-	20	6	2
34	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
35	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
36	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-

- : 本観測調査では観測されなかった走行挙動

(e) ケース 37 からケース 54 (ID1~ID15)

Case/ID	ID1	ID2	ID3	ID4	ID5	ID6	ID7	ID8	ID9	ID10	ID11	ID12	ID13	ID14	ID15
37	-	-	-	-	-	-	2	-	-	-	-	-	-	2	-
38	18	18	-	-	-	-	16	-	-	-	-	-	-	2	8
39	-	2	-	-	-	-	2	-	16	-	-	-	-	2	-
40	2	-	-	-	-	-	-	-	-	-	-	-	-	-	-
41	-	-	-	-	-	-	-	-	-	-	-	2	-	-	-
42	-	-	-	-	-	-	-	-	-	-	-	-	-	-	2
43	-	-	-	-	-	-	2	-	-	-	-	-	-	2	-
44	18	18	-	-	-	-	16	-	-	-	-	-	-	2	8
45	-	2	-	-	-	-	2	-	-	-	-	-	-	2	-
46	2	-	-	-	-	-	-	-	-	-	-	-	-	-	-
47	-	-	-	-	-	-	-	-	-	-	-	2	-	-	-
48	-	-	-	-	-	-	-	-	-	-	-	-	-	-	2
49	68	36	60	60	152	74	210	60	72	16	68	22	18	24	36
50	148	144	134	134	304	86	360	134	320	80	212	48	118	138	144
51	180	108	122	122	276	120	374	122	88	10	164	26	54	28	76
52	18	18	32	23	36	36	30	60	26	12	24	18	36	12	24
53	48	50	60	56	120	50	67	80	95	30	68	80	56	40	50
54	18	22	21	21	72	24	24	60	34	11	44	30	30	36	30

- : 本観測調査では観測されなかった走行挙動

(f) ケース 37 からケース 54 (ID16~ID30)

Case/ID	ID16	ID17	ID18	ID19	ID20	ID21	ID22	ID23	ID24	ID25	ID26	ID27	ID28	ID29	ID30
37	-	-	-	-	-	-	2	-	-	1	-	4	-	-	-
38	-	-	-	-	-	-	6	2	2	5	14	4	12	14	2
39	-	-	-	-	-	-	-	-	-	-	-	4	20	6	2
40	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
41	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
42	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
43	-	-	-	-	-	-	2	-	-	1	-	-	-	-	-
44	-	-	-	-	-	-	6	2	2	5	14	-	12	14	2
45	-	-	-	-	-	-	-	-	-	-	-	-	20	6	2
46	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
47	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
48	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
49	68	36	60	60	152	74	22	36	16	34	16	8	60	32	58
50	148	144	134	134	304	86	96	360	66	111	86	36	144	248	350
51	180	108	122	122	276	120	34	62	37	34	18	12	68	50	60
52	18	18	32	22	36	36	12	18	48	36	24	12	90	48	48
53	47	50	59	67	120	50	51	30	35	50	40	72	40	50	30
54	18	23	24	32	72	24	24	66	45	12	12	12	96	30	36

- : 本観測調査では観測されなかった走行挙動

図 3.18 にケースごとの走行挙動の一例を示す．ここでは一例として，被験者 No1 のケース 25～ケース 27 の走行挙動を示す．右折時・直進時・左折時の車両速度，3 軸成分の加速度，操舵角の交差点部の流入部から流出部の変化を表している．

ケースによってそれぞれの値の変化が大きく異なるのが分かる．したがって，本研究で行ったフローで交差点部の走行挙動が抽出できており，特性の異なる走行挙動として分類できていると考えられる．

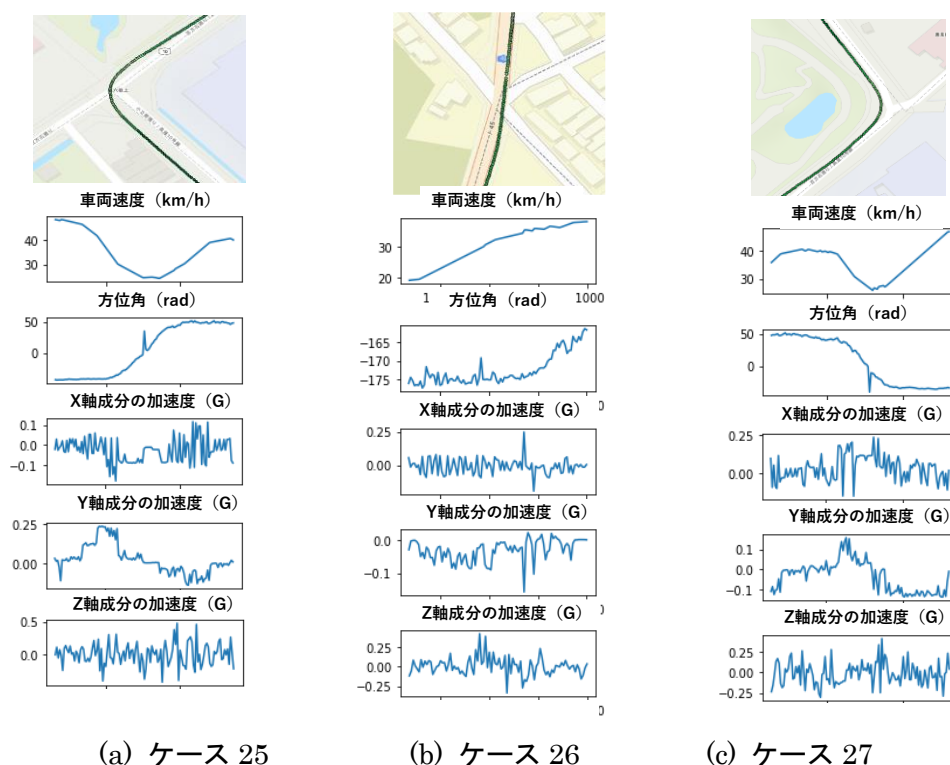


図 3.18 走行挙動の一例（被験者 ID1 のケース 25・26・27）

なお，本研究で実施した観測調査の被験者の中には，一台の車を夫婦兼用で使用している方が 5 組いた．この方々から観測された交差点部の走行挙動が，どちらの運転者によるものなのかは，運転日誌を参考に判別した．

しかしながら，記載がない場合や判別が困難な場合が一定数あった（表 3.11 参照）．この走行挙動の判別は，第 4 章で行う交差点部の走行挙動を用いた運転者特定の分析で運転者の特定を試みる．

表 3.11 運転日誌の記載から運転者の判別がつかなかった交差点部

Case	ID1 ID2	ID3 ID4	ID5 ID6	ID7 ID8	ID9 ID10	Case	ID1 ID2	ID3 ID4	ID5 ID6	ID7 ID8	ID9 ID10	Case	ID1 ID2	ID3 ID4	ID5 ID6	ID7 ID8	ID9 ID10
1	1	7	2	2	2	19	1	-	-	3	1	37	-	-	-	-	-
2	12	69	33	9	14	20	-	-	-	-	-	38	7	-	-	3	-
3	1	35	9	1	-	21	3	-	-	4	-	39	-	-	-	-	3
4	2	5	2	1	6	22	-	-	1	-	-	40	-	-	-	-	-
5	-	2	3	-	-	23	-	-	-	-	-	41	-	-	-	-	-
6	2	3	2	1	-	24	-	1	-	-	-	42	-	-	-	-	-
7	1	-	-	3	1	25	17	31	23	72	7	43	-	-	-	0	-
8	-	-	-	-	-	26	107	74	81	119	67	44	7	-	-	3	-
9	3	-	-	4	-	27	84	55	103	51	22	45	-	-	-	-	-
10	-	-	1	-	-	28	6	14	8	20	4	46	-	-	-	-	-
11	-	-	-	-	-	29	3	7	5	10	5	47	-	-	-	-	-
12	-	1	-	-	-	30	4	4	4	12	4	48	-	-	-	-	-
13	7	-	2	3	-	31	7	-	-	3	-	49	21	24	45	54	18
14	-	-	-	-	-	32	-	-	-	-	-	50	58	54	78	49	80
15	-	-	-	-	3	33	-	-	-	-	-	51	58	49	79	50	20
16	-	-	-	-	-	34	-	-	-	-	-	52	2	8	5	6	9
17	-	-	-	-	-	35	-	-	-	-	-	53	-	3	7	2	1
18	-	-	-	-	-	36	-	-	-	-	-	54	1	8	6	6	5

- : 本観測調査では観測されなかった走行挙動

3.4.7 データ拡張

ここでは交差点部の走行挙動のデータ拡張を行う。前項までのフローで、観測機器から観測された走行挙動から交差点部の走行挙動の抽出および分類をすることができた。データ拡張は、たくさんのデータを必要とする機械学習を適用した分析を行う際に活用される。

Um et al.²⁵⁾ や Rashid et al.²⁶⁾ によると、車両の走行挙動などの時系列データにもデータ拡張は有効であると報告されている。そこで本研究では、適用事例のある、4つのデータ拡張の方法を用いる。以下にそれぞれのデータ拡張の特徴と作成の際の設定を述べる。

1. Jittering

付加的なセンサーノイズをシミュレートする方法である。この拡張方法は、走行挙動データが持つノイズに対するロバスト性を高め、パフォーマンスを向上させる働きがある。本研究では、 $\sigma=0.05$ を採用する。

2. Scale

主にデータの大きさを変更する方法である。任意のスカラーを乗算することでデータの大きさを変更することが可能である。本研究では、 $\sigma=0.1$ を採用する。

3. Permutation

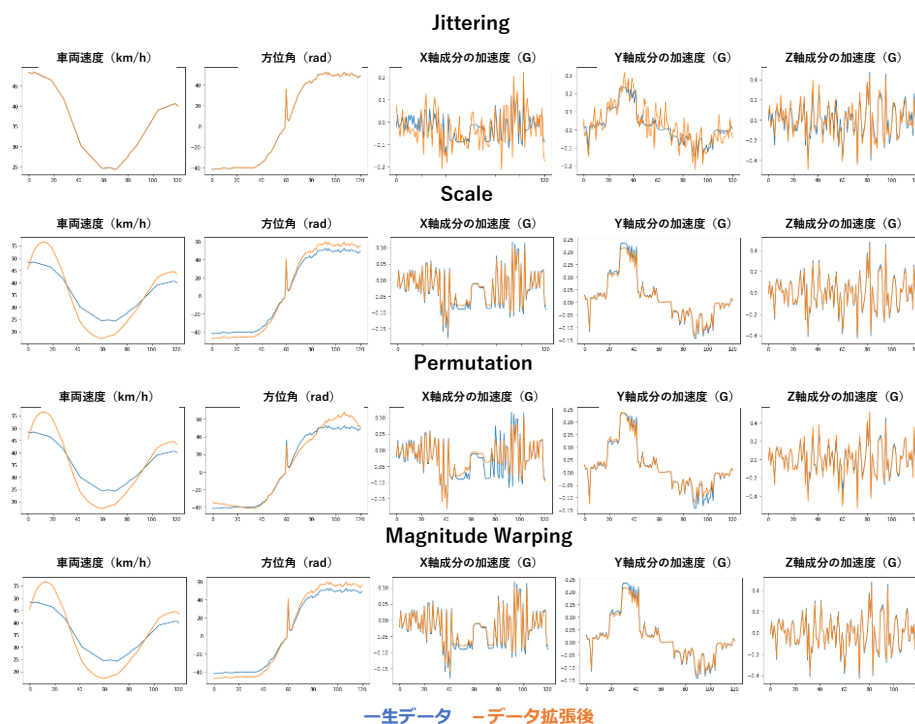
ウィンドウ内のデータを一時的にランダムに摂動する方法である。ウィンドウ内のデータを乱すことでデータにばらつきを持たすことができる。本研究では、 $N=4$, $Len=3$ を採用する。

4. Magnitude Warping

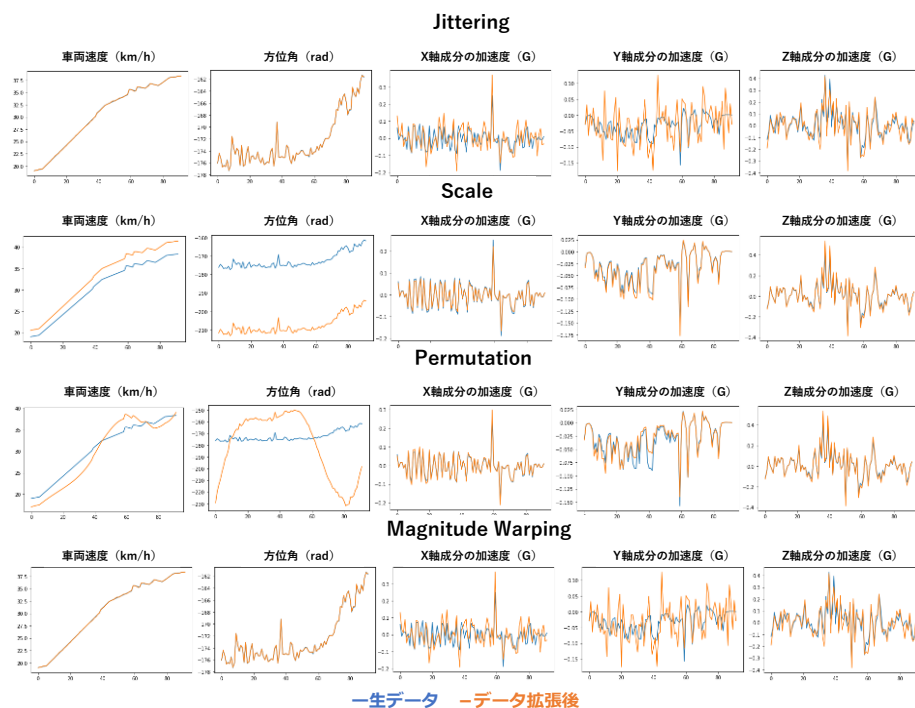
ウィンドウ内のデータを滑らかな曲線で畳み込むことにより、データの規模を変更する方法である。本研究では、 $\sigma=0.01$, $knot=1.5$ を採用する。

機械学習で分析を行う際は、検証用データに拡張データを含めると手法の精度などに影響を及ぼすと報告されている^{25), 26)}。その為、学習用データのみを用いることとする。なお、学習用データと検証用データに関する詳細は4章で述べる。

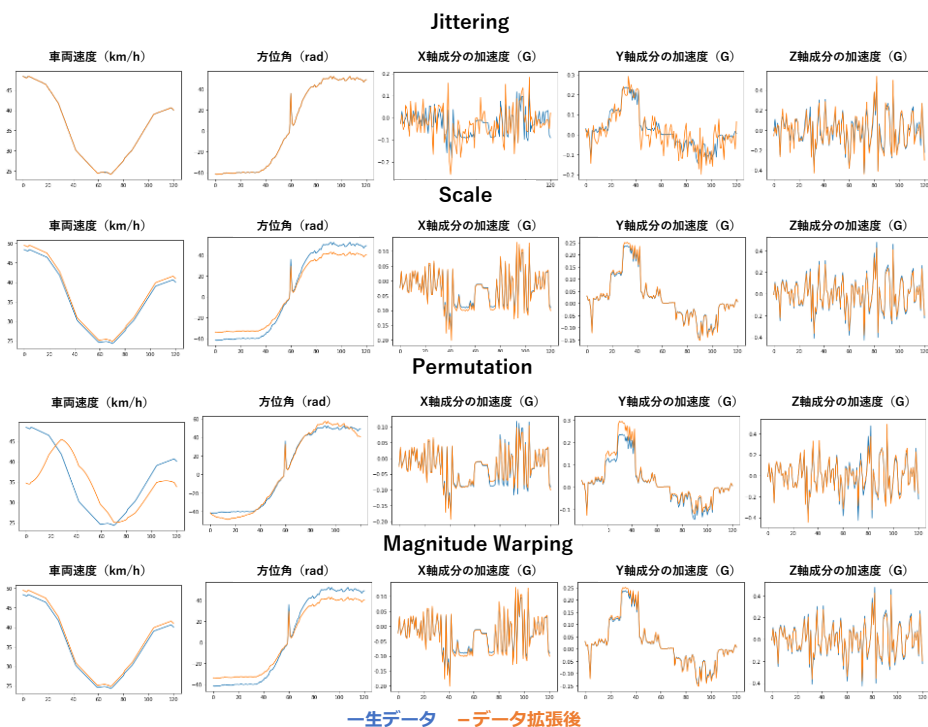
図 3.19 に拡張データの一例を示す。ここでは、図 3.18 に示した交差点部の走行挙動に4つの拡張方法を適用した結果を示す。青色が拡張前の生データ、オレンジ色が拡張後のデータを表している。拡張前と拡張後で走行挙動に大きな変化は生じていない。したがって、交差点部の走行挙動にデータ拡張を適用しても、運転者の運転特性に大きな影響は及ぼさないと考えられる。



(a) ケース 25



(b) ケース 26



(c) ケース 27

図 3.19 拡張データの一例（被験者 ID1 のケース 25・26・27）

3.5 本章のまとめ

本章では、交差点部の走行挙動の収集を目的とした観測調査および分析用データの作成方法について述べた。高齢運転者による異常運転を検知する可能性を秘めていることから、石川県金沢市に住む 65 歳以上の方を被験者として走行挙動の観測を行った。軽度認知症の方が被験者となるのを防ぐ為に、事前に認知機能検査を行い被験者の選定を行った。1 人あたり 2 週間の観測調査を実施し、30 名の方の走行挙動を観測した。

走行挙動は、観測機器 (0.1s 間隔で車両速度、3 軸成分の加速度、方位角、位置情報を計測) をダッシュボードに設置して観測を行った。スマートフォンとの精度検証の比較を行った結果、本研究で使用した観測機器は、車両の走行挙動を観測するのに必要な精度を満たしていることが明らかになった。

観測機器から出力された走行挙動を確認した結果、交差点部の走行挙動を分類する必要が明らかになった。そこで、差点部の運転特性に関する既往研究を整理した結果、①交差点流入部および交差点流出部の車線数の変化、②交差点部での車両の発進方法、③交差点部での車両の進行方向を考慮すべきことが明らかになった。本研究では、これらの知見を考慮して、交差点部の走行挙動を 54 通りに分類した。

分析用データの作成では、観測機器で観測したデータから交差点部の走行挙動を抽出するまでのフローについて述べた。まず、観測機器で出力した走行挙動データだけでは、運転者がどのような運転操作を行ったのかを把握することができない。そこで、DRM と走行挙動の結合を行った。次に、観測機器の傾きを考慮し、走行挙動の補正を行った。次に、交差点流入部の車線数から交差点規模ごとの抽出を行った。次に、交差点部での車両の発進方法や進行方法の判別を行った。次に、以上の工程から得られた情報により、交差点部の走行挙動を分類した。最後に、抽出した交差点部の走行挙動に 4 つのデータ拡張方法を用いて、分析データの拡張を行った。

以上の作成用フローにより、被験者から観測した走行挙動を分類できることが明らかになった。しかしながら、一台の車両を夫婦で使用している走行挙動については、観測した全ての走行挙動に対して運転日誌から運転者の特定はできなかった。このデータについては、4 章の分析で運転者の特定を行う。

第4章 交差点部の走行挙動を用いた運転者の特定

4.1 概要

複数の運転者の走行挙動が含まれている状態で異常運転検知を行うことは、検知精度や検知タイミングに影響を及ぼす。したがって、観測した走行挙動から“今”、“誰が”運転しているのかを明らかにすることは、手法を構築する上でも重要である。

そこで本章では、交差点部の走行挙動から運転者の特定手法を構築する。交差点部の運転操作は、発進時や停車時に比べて難しいとされる。また、直線時や曲る時などの様々な走行挙動が観測される、したがって、個々の運転特性が表れやすいと考えられる。そこで本研究では、交差点部の走行挙動から運転者の特定を試みる。

以上を踏まえ、本章の流れについて述べる。4.2では、走行挙動から運転者の特定を試みた既往研究を整理する。4.3では、交差点部の走行挙動から運転者を特定するモデルを作成する。4.4では、既往研究で作成されたモデルとの特定精度の比較を行う。4.5では、観測調査で運転者の判別ができなかった走行挙動に、運転者特定モデルを適用して運転者の特定を行う。

4.2 走行挙動を用いた運転者特定に関する既往研究

運転者を特定する方法は2通りある。一つは、運転者の生体情報から運転者を特定する方法である。これは、車両のセキュリティ向上などの目的で用いられる。他方は、運動動作から運転者を特定する方法である。これは、車両側で走行挙動の特徴（例えば、曲る時に大きく膨らむなど）を抽出し、運転者を特定する方法である。ここでは、後者の走行挙動から運転者の特定を試みた既往研究について整理する。

まず、直進時の走行挙動から運転者の特定を試みた既往研究について述べる。直進時の走行挙動は、観測がしやすく、分析も行いやすい利点を持つ。その為、既往研究も多い。例えば、Wakita et al.¹⁾は、前方車両を追従する時の走行挙動に着目し、アクセルの開度、ブレーキの踏み込み量、速度変化、前方車両との車間距離を観測した。これらの変化をGaussian Mixture Model (GMM)で分布化し、走行挙動の変化の違いから運転者の特定を試みた。Miyajima et al.²⁾やOzturk et al.³⁾は、車両が停止する時の走行挙動に着目し、ブレーキの踏み込み量を観測した。ブレーキの踏み込み量の変化をGMMで分布化し、走行挙動の変化の違いから運転者の特定を試みた。Wahab et al.⁴⁾やNor et al.⁵⁾は、車両の発進から停止するまでの走行挙動に着目し、アクセルの開度、ブレーキの踏み込み量、速度変化、加速度変化を観測した。Multilayer Perceptron (MLP)を適用することで、走行挙動の変化の違いから運転者の特定を試みた。

Qian et al.⁶⁾やNishiwaki et al.⁷⁾、Burton et al.⁸⁾、Meng et al.⁹⁾は被験者全員が同一のコースを走行した時の走行挙動の乖離度に着目し、アクセルの開度、ブレーキの踏み込み量、操舵角を観測した。Support Vector Machine (SVM)やGMM、Hidden Markov Model (HMM)を適用することで、走行挙動の変化の違いから運転者の特定を試みた。

次に、車両が曲る時の走行挙動から運転者の特定を試みた既往研究について述べる。例えば、Miyachi et al.¹⁰⁾は、交差点部を右左折する時の走行挙動に着目し、車両速度、加速

度、操舵角、車両の位置情報をスマートフォンセンサで観測した。事前確率を考慮した分類が可能な Naïve Bayes を用いることで、通過した交差点の走行挙動の情報から総合的に運転者の特定ができることを明らかにした。さらに宮内ら¹¹⁾は、Miyauchi et al.¹⁰⁾を改良して、Convolutional Neural Network (CNN) を適用して運転者の特定を試みた。深層学習を用いることで、より高い精度で運転者の特定が可能であることを明らかにした。他にも、Sathyanarayana et al.¹²⁾は車線を変更する時の走行挙動、Chen et al.¹³⁾は、車両が曲る時のハンドル角度の変化に着目した。なお、Tokutake et al.¹⁴⁾は、車両が直進する時と曲る時の走行挙動の違いに着目し、運転者の特定精度を比較した。結論として、曲る時の走行挙動の方が、運転者を特定する精度が良いことを示した。

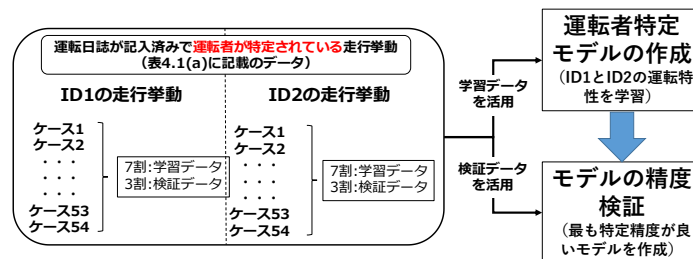
以上を踏まえると、直進時の走行挙動では、発進時や停車時の運転動作に着目している研究事例が多く、曲る時の走行挙動では、交差点を曲がる時や車線変更時の運転動作に着目している既往研究が多いことが明らかになった。一方で、どちらも運転特性が抽出できるものの、直進時の走行挙動と曲る時の走行挙動の両方の観点から運転者の特定を試みた既往研究は未だないことが明らかになった。したがって、直進時の走行挙動と曲る時の走行挙動の走行挙動から運転者の特定を行うことで、特定精度は向上する可能性があると考えられる。そこで本研究では、交差点部における直進時および右左折時の走行挙動(以下、本章では走行挙動と呼ぶ)を活用して運転者の特定を試みる。

4.3 運転者特定モデルの作成

4.3.1 運転者を特定するまでの流れ

ここでは走行挙動を用いて運転者を特定する方法について述べる。本研究では、教師あり学習による方法で運転者の特定を行う。教師あり学習について述べる。教師あり学習は、運転者と走行挙動がセットになった教師データを用いて、観測した走行挙動がどの運転者によるものか学習する。そして、運転者が特定されていない走行挙動に適用して、学習した結果を元に運転者の特定を行う方法である。

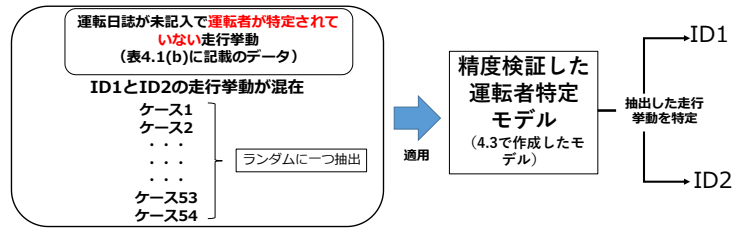
図 4.1 に本研究で行う運転者特定の流れを示す。まず、図 4.1(a)に示すように、運転者が特定された走行挙動(表 4.1 参照)を用いて、夫婦で使用している車両ごとに、運転者特定モデルを作成する。次に、作成したモデルの精度検証を行う。精度検証の結果を通して、作成した運転者特定モデルの妥当性を検討する。なお、運転者が特定された走行挙動は学習用データと検証用データに分けられる。学習用データを用いて運転者特定モデルを作成する。検証用データを用いて作成したモデルの特定精度を検証する。



(a) 4.3・4.4で行う内容 (ID1/ID2を一例に)

次に、図 4.1(b)に示すように、運転者が特定されていない走行挙動(表 4.1 参照)に作

成した運転者特定モデルを適用する。これにより、運転者の特定がされていない走行挙動が、誰の運転によるものなのかを明らかにできる。



(b) 4.5で行う内容 (ID1/ID2を一例に)

図 4.1 運転者特定の流れ

表 4.1 ID1~ID10の走行挙動および運転者特定がされていない走行挙動

車両ID	1		2			3			4			5			
	特定済み		未特定	特定済み		未特定	特定済み		未特定	特定済み		未特定	特定済み		未特定
運転者特定の有無	ID1	ID2	ID1-2	ID3	ID4	ID3-4	ID5	ID6	ID5-6	ID7	ID8	ID7-8	ID9	ID10	ID9-10
Case/ID	ID1	ID2	ID1-2	ID3	ID4	ID3-4	ID5	ID6	ID5-6	ID7	ID8	ID7-8	ID9	ID10	ID9-10
1	64	42	1	74	25	7	44	48	2	32	47	2	38	22	2
2	222	90	12	324	85	69	82	82	33	86	106	9	148	122	14
3	51	34	1	176	32	35	36	38	9	36	41	1	29	32	-
4	26	22	2	24	20	5	20	28	2	24	12	1	32	21	6
5	22	30	-	30	40	2	40	40	3	32	42	-	69	66	-
6	28	24	2	22	35	3	20	18	2	14	18	1	24	30	-
7	2	4	1	-	-	-	-	-	-	16	-	3	-	4	1
8	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
9	6	10	3	-	-	-	-	-	-	20	-	4	-	2	-
10	-	2	-	-	-	-	2	4	1	-	-	-	-	-	-
11	-	-	-	-	2	-	-	-	-	2	-	-	-	-	-
12	-	-	-	4	-	1	-	-	-	-	-	-	-	-	-
13	18	18	7	-	-	-	2	8	2	16	-	3	-	-	-
14	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
15	-	2	-	-	-	-	2	-	-	2	-	-	16	-	3
16	2	-	-	-	-	-	-	-	-	-	-	-	-	-	-
17	-	-	-	2	-	-	-	-	-	-	-	-	-	-	-
18	-	-	-	-	-	-	-	2	-	-	-	-	-	-	-
19	2	4	1	-	-	-	-	-	-	16	-	3	-	4	1
20	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
21	6	10	3	-	-	-	-	-	-	20	-	4	-	2	-
22	-	2	-	-	-	-	2	4	1	-	-	-	-	-	-
23	-	-	-	-	2	-	-	-	-	2	-	-	-	-	-
24	-	-	-	4	-	1	-	-	-	-	-	-	-	-	-
25	50	34	17	78	78	31	80	34	23	280	78	72	42	34	7
26	632	438	107	372	372	74	532	276	81	1414	372	119	336	330	67
27	288	132	84	138	138	55	312	202	103	624	138	51	24	88	22
28	32	28	6	72	72	14	72	12	8	128	72	20	32	12	4
29	40	16	3	72	72	7	80	16	5	120	72	10	32	72	5
30	32	8	4	20	20	4	40	4	4	104	20	12	16	20	4
31	18	18	7	-	-	-	-	-	-	16	-	3	-	-	-
32	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
33	-	2	-	-	-	-	-	-	-	2	-	-	-	-	-
34	2	-	-	-	-	-	-	-	-	-	-	-	-	-	-
35	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
36	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
37	-	-	-	-	-	-	-	-	-	2	-	-	-	-	-
38	18	18	7	-	-	-	-	-	-	16	-	3	-	-	-
39	-	2	-	-	-	-	-	-	-	2	-	-	16	-	3
40	2	-	-	-	-	-	-	-	-	-	-	-	-	-	-
41	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
42	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
43	-	-	-	-	-	-	-	-	-	2	-	0	-	-	-
44	18	18	7	-	-	-	-	-	-	16	-	3	-	-	-
45	-	2	-	-	-	-	-	-	-	2	-	-	-	-	-
46	2	-	-	-	-	-	-	-	-	-	-	-	-	-	-
47	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
48	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
49	68	36	21	60	60	24	152	74	45	210	60	54	72	16	18
50	148	144	58	134	134	54	304	86	78	360	134	49	320	80	80
51	180	108	58	122	122	49	276	120	79	374	122	50	88	10	20
52	18	18	2	32	23	8	36	36	5	30	60	6	26	12	9
53	48	50	-	60	56	3	120	50	7	67	80	2	95	30	1
54	18	22	1	21	21	8	72	24	6	24	60	6	34	11	5

4.3.2 LSTM (Long Short-Term Memory) の概要

ここでは運転者特定に用いる分析手法について述べる。本研究では、近年、様々な分野で活用されており、統計的手法に比べて精度が高い、深層学習を用いて運転者の特定を行う。

図 4.2 に深層学習を用いた運転者特定の概要を示す。ニューラルネットワークは入力、中間、出力の3層以上からなる構造をしている。各層には、「重み」が設定されており、学習を通してこの値を調整する。中間層は、一つ以上の層を設定し、入力データの特徴を抽出する。

なお、出力層では確信度が算出される。確信度は、中間層で抽出した情報が、どちらの運転者の方が妥当であるかを表し 0~1 の値を取る。確信度が高い運転者をその走行挙動の特定結果となる。

また、中間層の数は無数に増やしても、処理時間が長くなるだけで、必ずしも精度の向上につながるとは限らない。したがって、分析者は分析目的やデータの特性に合わせて試行錯誤的に設定条件を決める必要がある。

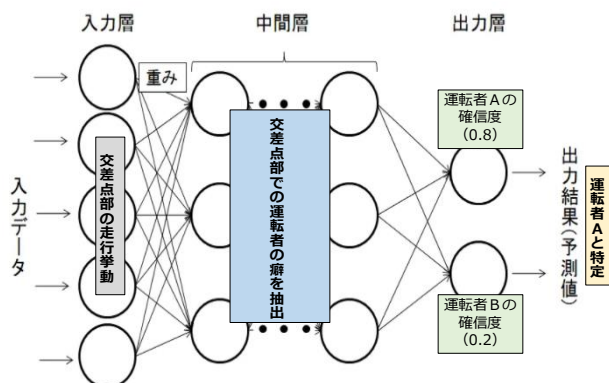


図 4.2 深層学習を用いた運転者特定の概要

本研究では、深層学習の一つである Long Short-Term Memory (LSTM) を走行挙動に適用する。走行挙動は系列相関を有する時系列データである。LSTM は、時系列データの特徴を抽出することに秀でた手法である。したがって、LSTM を適用することで、交差点部の走行挙動から運転特性を抽出することを考えた。

図 4.3 に LSTM 層の構造を示す。交差点部の一地点で観測された走行挙動を LSTM で処理する流れについて述べる。LSTM は入力ゲート、忘却ゲート、出力ゲートの3つのゲートを介して、データのやり取りが行われる。

LSTM の最初のステップは、前時刻の入力情報を維持するか消去するかを判定する。この判定は忘却ゲートで行われる。 h_{t-1} (時刻 $t-1$ の出力値) と x_t (時刻 t の入力値) を見て、ニューロン c_{t-1} (前時刻の入力情報) の中に含まれる数値を 0 から 1 の範囲で出力する。この時、1 は「前回の情報を完全に維持する」を表す。0 は「前回の情報を完全に取り除く」ことを表す。したがって、以下の式 (4.1) が成り立つ。

$$f_t = \sigma(W_t \cdot [h_{t-1}, x_t] + b_f) \quad (4.1)$$

次のステップは、ニューロンで保存する新たな情報を判定する。まず、入力ゲート層で更新する値を決定する。次に、 \tanh 層 (活性化関数) でニューロンに加える新たな候補値となるベクトル C_t を作成する。これらを組み合わせると以下の式 (4.2) が成り立つ。

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$

$$C'_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \tag{4.2}$$

そして古いニューロン c_{t-1} から新しいニューロン c_t に更新する。これは、古いニューロンに忘却ゲートを乗じることで、どの程度、古いニューロンの値を書き換えるかを決定する。したがって、以下の式 (4.3) が成り立つ。

$$C_t = f_t * C_{t-1} + i_t * C'_t \tag{4.3}$$

最後のステップは、出力する値の判定を行う。この出力はニューロンに基づいて行われる。その為、ニューロンのどの部分かを出力するかを判定し、判定された部分のみを出力する必要がある。したがって、以下の式 (4.4) が成り立つ。

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$$

$$h_t = o_t * \tanh(C_t) \tag{4.4}$$

これにより走行挙動が持つ前後の観測点の情報を記憶することができる。以上の処理を時刻ごとに行うことで、時系列データである走行挙動から特徴を抽出することが可能である。この一連の流れを処理する流れは図 4.4 の通りになる。

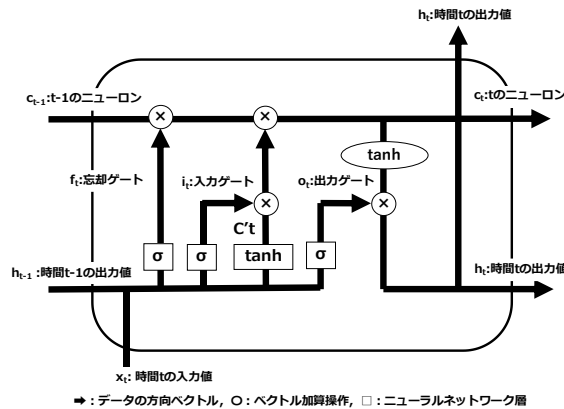


図 4.3 LSTM 層の構造図

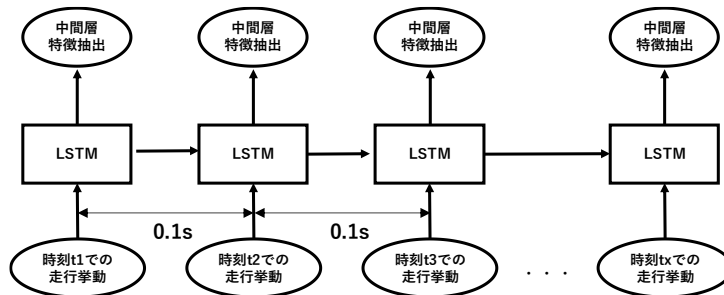


図 4.4 LSTM の一連の流れ

4.3.3 運転者の特定に用いる特徴量

ここでは運転者特定に用いる特徴量 (変数) について述べる。表 4.2 に運転者特定に用いる特徴量を示す。深層学習を用いた手法は、運転者を特定する際に有効でない特徴量が含まれていても、精度に影響は及ぼさないと報告されている¹⁵⁾。その為、ある特徴量が運転者の特定に有効かどうかを検討する必要はなく、多くの特徴量を設定した方が良いとき

れている。

そこで本研究では、観測機器から直接出力される車両速度、三軸の各加速度、操舵角に加え、合成加速度、三軸の各躍度、合成躍度、操舵角速度の計 11 の特徴量を用いて運転者の特定を試みる。それぞれの加工した特徴量について述べる。合成加速度は、車両の加速度や衝撃の程度を表す特徴量である。躍度は、加速度を微分した値から算出される。車両の乗り心地を表す特徴量として使われている^{16), 17)}。さらに本研究では、合成躍度も算出し、特徴量として用いる。操舵角速度は、単位秒あたりの操舵角の変化量を表す特徴量である。車両から見て横方向へ外乱入力働いた度合いを把握する特徴量として使われている¹⁸⁾。

表 4.2 運転者特定に用いる特徴量

No.	特徴量	指標の説明
1	車両速度 (km/h)	車両の速度
2	X軸成分の加速度 (G)	車両の左右方向の加速度
3	Y軸成分の加速度 (G)	車両の前後方向の加速度
4	Z軸成分の加速度 (G)	車両の上下方向の加速度
5	操舵角 (deg)	車両が向く方向
6	合成加速度 (G)	X, Y, Z軸成分の合成加速度
7	X軸成分の躍度 (J)	車両の左右方向の躍度
8	Y軸成分の躍度 (J)	車両の前後方向の躍度
9	Z軸成分の躍度 (J)	車両の上下方向の躍度
10	合成躍度 (J)	X, Y, Z軸成分の合成躍度
11	操舵角速度 (deg/s)	1秒当たりの操舵角

図 4.5 に運転者特定モデルの特徴量の設定方法を示す。本研究では、運転者の特定に要する時間はあまり関係なく、高い特定精度のモデルが必要であることを踏まえ、それぞれの特徴量に対して LSTM 層を用意し運転特性の抽出を行う。したがって、設定する特徴量の数は 11 であるので、LSTM 層を含む処理も図に示すように、11 個のモデルが並列して構成となる。

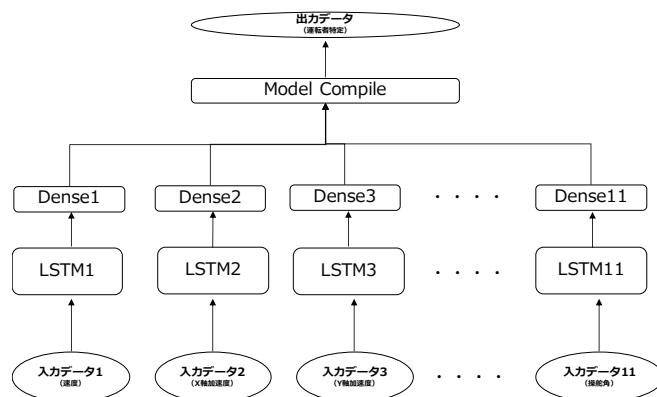


図 4.5 特徴量の設定方法

4.4 運転者特定モデルの性能評価

4.4.1 運転者特定モデルの評価方法

ここでは運転者特定モデルの評価方法について述べる。学習用データを用いて作成した運転者特定モデルは、検証用データを適用して評価する。一台の車を二人（運転者 A・運

転者 B と仮定) で使用している場合, 特定結果は, 表 4.3 に示すように 4 つに分けられる. なお, 「真」か「偽」は特定が的中したかどうか, 「陽性」か「陰性」は特定された運転者を示している (ここでは運転者 A を陽性として仮定).

表 4.3 検証データを用いた運転者特定の結果

運転日誌から 判別されている結果	検証用データに運転者特定モデルを適用した結果		
		運転者Aの 走行挙動と特定	運転者Bの 走行挙動と特定
	運転者Aの 走行挙動	TP (真陽性)	FN (偽陰性)
運転者Bの 走行挙動	FP (偽陽性)	TN (真陰性)	

運転者特定モデルの有効性は, 特定結果から算出できる評価指標を用いて評価することができる. 以下に各評価指標の算出方法を示す.

① 精度: 全ての検証用データに対して, 正確に予測できた割合を示す.

$$\text{精度 (\%)} = \frac{(TP + TN)}{(TP + TN + FP + FN)} \times 100 \quad (4.5)$$

② 適合率: 陽性であると予測されたものが, 実際にどれくらい陽性だったかを示す.

$$\text{適合率 (\%)} = \frac{TP}{(TP + FP)} \times 100 \quad (4.6)$$

③ 再現率: 陽性の検証用データのうち, 実際にどれくらい陽性と予測されたかを示す.

$$\text{再現率 (\%)} = \frac{(TP)}{(TP + FN)} \times 100 \quad (4.7)$$

④ F 値: 適合率と再現率のバランスが保たれているかを示す.

$$F \text{ 値 (\%)} = \frac{2 \times \text{適合率} \times \text{再現率}}{\text{適合率} + \text{再現率}} \quad (4.8)$$

どの評価指標に重点を置くかは分析目的によって異なる. 例えば, 誤った判別 (誤判定) を極力減らしたモデルを作成したい場合は, 適合率が高いモデルを選ぶべきとされている. 一方で, とにかく多くの正しい判別を得たいモデルを作成したい場合は, 再現率が高いモデルを選ぶべきとされている.

また, 損失を用いて評価する場合もある. 損失は, そのモデルの汎化性能を示す. 汎化性能は, 学習していないデータが, 分析に使用された時に, どの程度, 応用が利くかを表す. つまり, 値が小さいほど未知のデータに対応できるモデルであることを意味する.

運転者特定モデルの目的は, 運転者特定がされていない走行挙動に対し, 高い精度で運転者を特定することである. したがって, ここでは, 精度と損失に重点を置いてモデルの比較を行う.

4.4.2 LSTM 層の設定条件

ここでは LSTM AE の設定条件について述べる. 深層学習を用いた分析は, 事前の設定条件によって得られる結果が異なり, 特定精度に影響を及ぼす. なお, ここで検討する設定条件は, 中間層 (LSTM 層) の数および中間層のニューロンの数である.

本研究では、中間層の数および中間層のニューロンの数を変えたモデルを作成し、最適な設定条件について検討する。表 4.4 (a) にモデルの概要を示す。本研究では、既往研究 19), 20) の知見を踏まえて、中間層の数とユニットの数を変えたモデル 1～モデル 10 を作成した。

モデル 1～モデル 6 は、中間層の数は 1、中間層のニューロンの数は、入力データ長の 1/8 倍、1/4 倍、1/2 倍、2 倍、4 倍、8 倍とした。モデル 7 とモデル 8 は、中間層の数は 2、中間層のニューロンの数は、1 層目が入力データ長の 1/2 倍、2 倍、2 層目が入力データ長の 1/4 倍、4 倍とした。モデル 9 とモデル 10 は、中間層の数は 3、中間層のニューロンの数は、1 層目が入力データ長の 1/2 倍、2 倍、2 層目が入力データ長の 1/4 倍、4 倍、3 層目が入力データ長の 1/8 倍、8 倍とした。

表 4.4 本研究で提案する運転者特定モデル
(a) モデルの概要

モデル	中間層の数	中間層のニューロンの数
モデル1	1	入力データ長の1/8
モデル2	1	入力データ長の1/4
モデル3	1	入力データ長の1/2
モデル4	1	入力データ長の2倍
モデル5	1	入力データ長の4倍
モデル6	1	入力データ長の8倍
モデル7	2	入力データ長の2倍, 4倍
モデル8	2	入力データ長の1/2, 1/4
モデル9	3	入力データ長の2倍, 4倍, 8倍
モデル10	3	入力データ長の1/2, 1/4, 1/8

表 4.4 (b) に各モデル共通の設定条件について述べる。これらの設定は、既往研究 19), 20) の知見を踏まえて決定した。入力データ長は、観測した走行挙動データの長さを意味している。LSTM は、入力データ長が異なる時系列データから特徴を抽出できることが利点の一つである。それぞれの特徴量は、最小値 0、最大値 1 の値をとるように正規化を行う。正規化により、大きい値の特徴量と小さい値の特徴量の範囲を揃え、上手く学習できない現象を防ぐ。

LSTM の損失関数は、 \tanh 関数（双曲線正接関数）とする。LSTM 層の後は、ドロップアウトを行う。ドロップアウトとは、学習時に一定割合のニューロンを不活性化し、過学習を防ぐ。なお、過学習とは、学習用データに対しては学習できているが、検証用データに対しては、適合できていない現象である。本研究では、ドロップアウトの割合は 0.2 とする。

ID1～ID10 の被験者は、一台の車を 2 人で利用しているので、出力サイズは 2 となる。出力時の活性化関数は、複数の出力値の合計が 1.0 になるように調整する、Softmax 関数を用いる。最適化関数は、移動平均で振動を抑制するモーメンタムと学習率を調整して振動を抑制する RMSProp を組み合わせた関数である Adam を用いる。損失関数は、クラス分類などに使用する多クラス交差エントロピーを用いる。

次に、教師データの学習方法について述べる。本研究では、バッチ数が 32、エポック数が 1000 のミニバッチ学習を行う。ミニバッチ学習は、N 個の訓練データの中から n 個を取り出し、パラメータの更新をする方法である。この時、取り出すデータ数 n をバッチ数と呼ぶ。データ数 n を取り出した後は、(N-n) 個の中から n 個を取り出して、再度パラメータの更新を行う。

エポック数は、データ数 N 個を取り出す回数を示す数である。深層学習のようにパラメータ数が多い場合、一回のエポック数の学習では、全てのパラメータを決定することができない。その為、回数を設定して学習することが多い。

一方で、エポック数を多くしすぎても、過学習を起こしてしまう。

そこで本研究では、過学習を防ぐ為に **Early stopping** を用いる。これは指定したエポック数の前で学習がこれ以上進むと過学習に陥ると判断した時に、そこで学習を終了する事である。本研究では、損失が最小になった時点 ($Val_loss = 0$) で学習を止める設定とする。

(b) 各モデル共通の設定条件

最適化アルゴリズム	Adam
損失関数	多クラス交差エントロピー
ドロップアウト率	0.2
活性化関数1	tanh関数
活性化関数2	Softmax関数
バッチサイズ	32
エポック数	1000
打ち切り条件	$Val_loss = 0$

4.4.3 モデル別の特定精度の結果

ここではモデル別の特定精度の結果について述べる。図 4.6 にモデル 1 からモデル 10 の結果を示す。精度、適合率、再現率、F 値、損失の結果を示す。なお、モデル 1 からモデル 10 までに用いる検証用データは、固定した状態で運転者の特定を行っている。その為、各車両の推定結果の中で最も高い精度を有しているモデルが良いという判断を行った。

結論として、全ての車両において、中間層の数を 1 つ、中間層のニューロンの数を入力データ長の 2 倍とする、モデル 4 の設定条件が最も適していることが明らかになった。

中間層の数と精度の関係性について述べる。モデル 7~モデル 10 の精度を見ると、中間層の数を二つ以上に増やしても、必ずしも精度が向上するわけではないことが確認された。このことから、走行挙動に LSTM を適用する際の中間層の数は、1 層で十分である可能性が示された。

次に、中間層のニューロンの数と精度の関係性について述べる。中間層のニューロンの数が入力データ長よりも短い、モデル 1~モデル 3 の精度を見ると、モデル 4 の精度に比べ、精度が低い傾向にあることが明らかになった。これは、ニューロンの数が入力データ長よりも短いと、運転特性の抽出が十分にできない為と考えられる。また、中間層のニューロンの数が入力データ長よりも極端に長くした、モデル 5 やモデル 6 の精度を見ると、必ずしも精度の向上することは見られなかった。このことから、中間層の数やニューロンの数を増やしても、必ずしも精度が向上するわけではないことが確認された。

以上、モデルごとの特定精度の比較を行った。以後の分析ではモデル 4 を用いることとする。

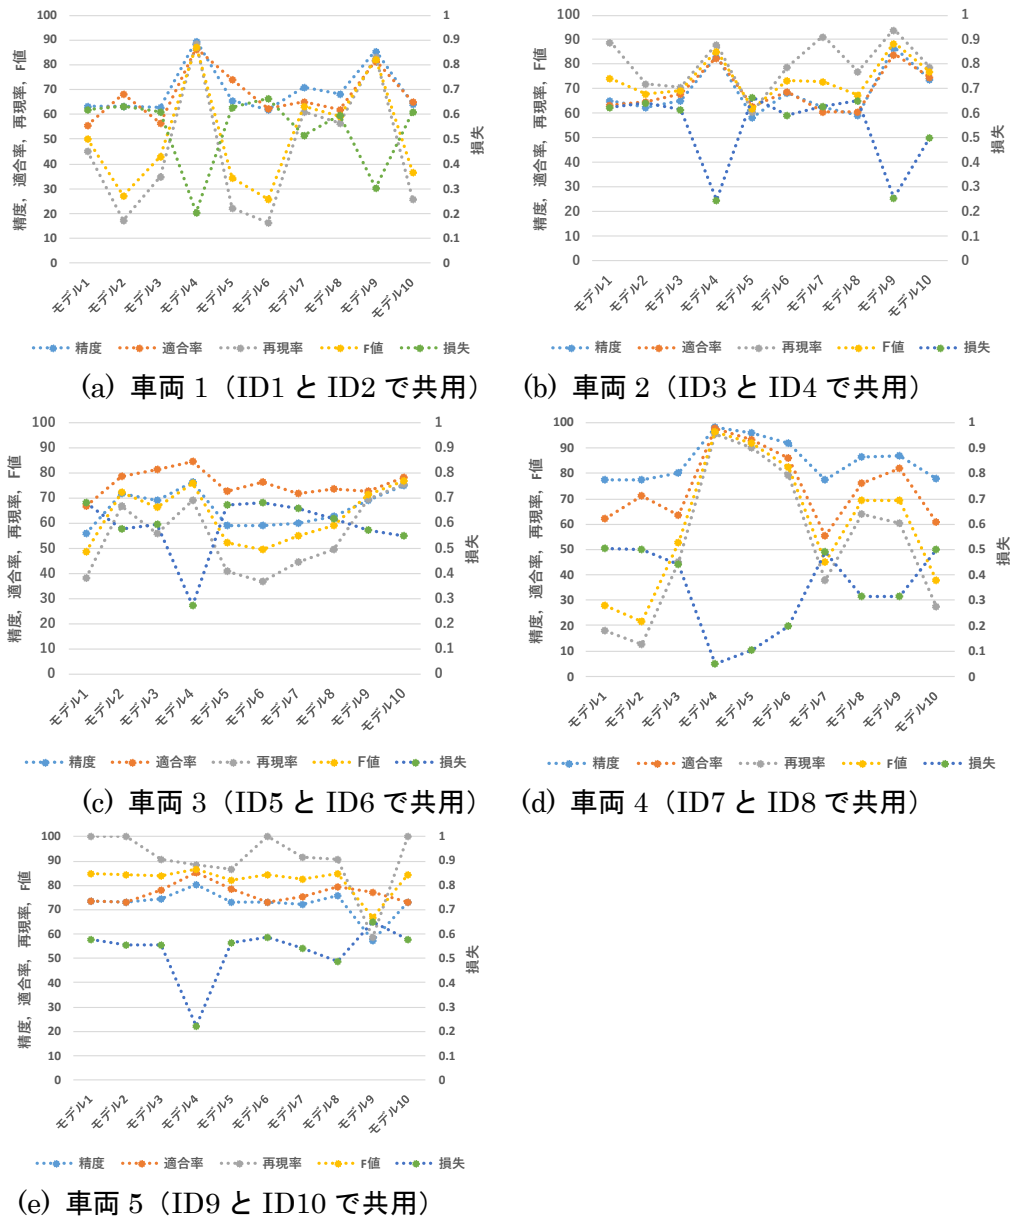


図 4.6 モデルの推定結果

4.4.4 既往研究との比較

ここでは既往研究で作成されたモデルとの精度比較を行う. 図 4.7 に既往研究との精度比較した結果を示す. 本研究で用いた学習用データと検証用データを交研究のモデルに適用した. 既往研究で用いた手法について述べる. GMM は, 交差点部での特徴量の変化を分布化し, この時の違いから運転者の特定を行う. SVM は, 学習用データで観測した特徴量から境界線を作成し, 境界線のどこに含まれるかで運転者の特定を行う. HMM は状態空間モデルの一つで, 直接観測することのできない潜在変数から運転者の特定を行う. Naïve Bayes は, 事前確率を考慮して, 運転者の特定を行う. CNN は, 交差点部で観測した各特徴量の時系列の変化を画像データとして取り込み, 抽出した特徴から運転者の特定を行う. ここでは精度, 適合率, 再現率, F 値を算出し, 4.4.1 と同様に精度に重点を置いて, それ

それぞれの手法の有効性を検討する。

結論として、どの車両においても、本研究で作成した LSTM を用いた運転者特定モデルが最も精度が高くなることが確認された。Naïve Bayes や CNN は、交差点部での直進時と右左折時の走行挙動が混在するデータにおいては、十分な精度を得られないことが明らかになった。この理由は、Naïve Bayes や CNN は、直線時だけの挙動や曲る時だけの挙動であれば、精度よく特定が出来るが、特性が大きく異なる、直線時と曲る時が混在した状況では特徴が上手く抽出できないと考えられる。

GMM や SVM, HMM, LSTM は、特定精度が比較的高い傾向にある。中でも、LSTM と HMM は、走行挙動に含まれる潜在的な特徴を抽出できるから特に精度が高いと考えられる。なお、LSTM と HMM の違いは、中間層のニューロンが持てる情報量の違いである。HMM は、LSTM に比べて、観測データに含まれる情報量をさかのぼれる数が少ない。その結果、LSTM の特定精度の方が、高くなったと考えられる。

以上より、本研究で提案する LSTM を用いた運転者特定モデルは、既往研究の手法よりも高い精度で運転者の特定ができることが明らかになった。

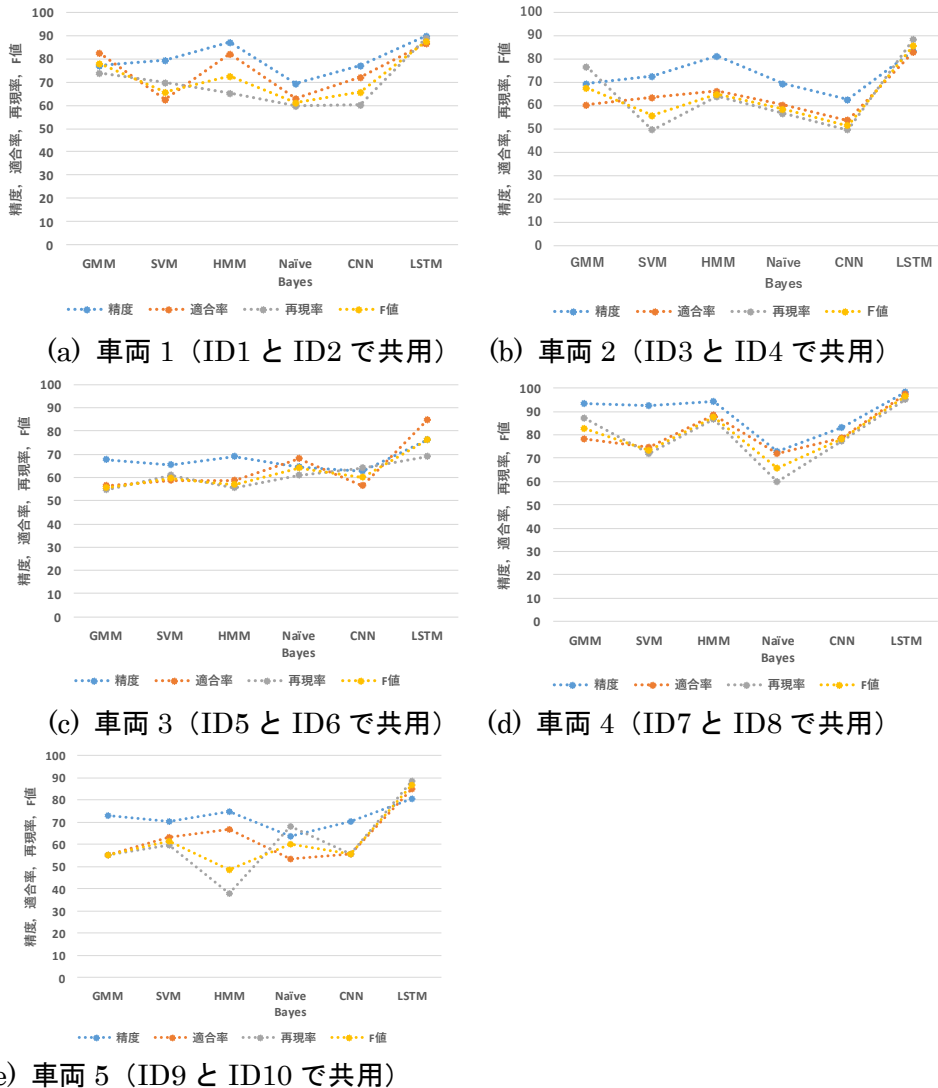


図 4.7 既往研究との精度比較

4.5 運転者特定モデルの適用

ここでは表 4.1 に示した運転者が特定されていない走行挙動に運転者特定モデルを適用して、運転者の特定を試みる。表 4.6 に運転者の判別がされていない走行挙動の概要を示す。運転回数は、観測機器の電源を ON にしてから OFF にするまでに観測したデータを 1 回としてカウントしている。

表 4.6 運転者の判別がされていない走行挙動データの概要

車両ID	運転回数	走行挙動の観測数
1	3	415
2	3	454
3	4	499
4	5	491
5	2	239

表 4.7 に特定結果を示す。運転者が特定されていない走行挙動に対し、各被験者のどちらであるかが明らかになった。本研究では、この特定結果で分析を終了せず、さらに特定結果の精緻化を試みる。

特定結果の精緻化の考え方について述べる。運転者は、一回の運転で複数個の交差点を通過する。つまり、交差点を通過した順に、特定結果を羅列することで、運転者が誰であるか概ね予想できると考えた

表 4.7 運転者特定の結果

車両ID	被験者ID	手法を適用した時の結果
1	ID1	282
	ID2	133
2	ID3	210
	ID4	244
3	ID5	285
	ID6	214
4	ID7	244
	ID8	247
5	ID9	98
	ID10	141

図 4.7 に交差点を通過したごとの特定結果を示す。左上のセルは、運転を開始してから最初に通過した交差点である。右下のセルは、運転を終了する直前に通過した交差点である。各セルは、オレンジ色または青色で塗られている。これは、特定された運転者を表している。

例えば、図 4.7(a) の場合、オレンジ色は ID1、青色は ID2 であることを示している。また、色の濃淡は確信度の強弱を示している。確信度の値はセルによって異なることが明らかになった。したがって、多くのセルが塗りつぶされていても、確信度の総和が低い場合は、その特定結果の信頼性は低いと考えられる。

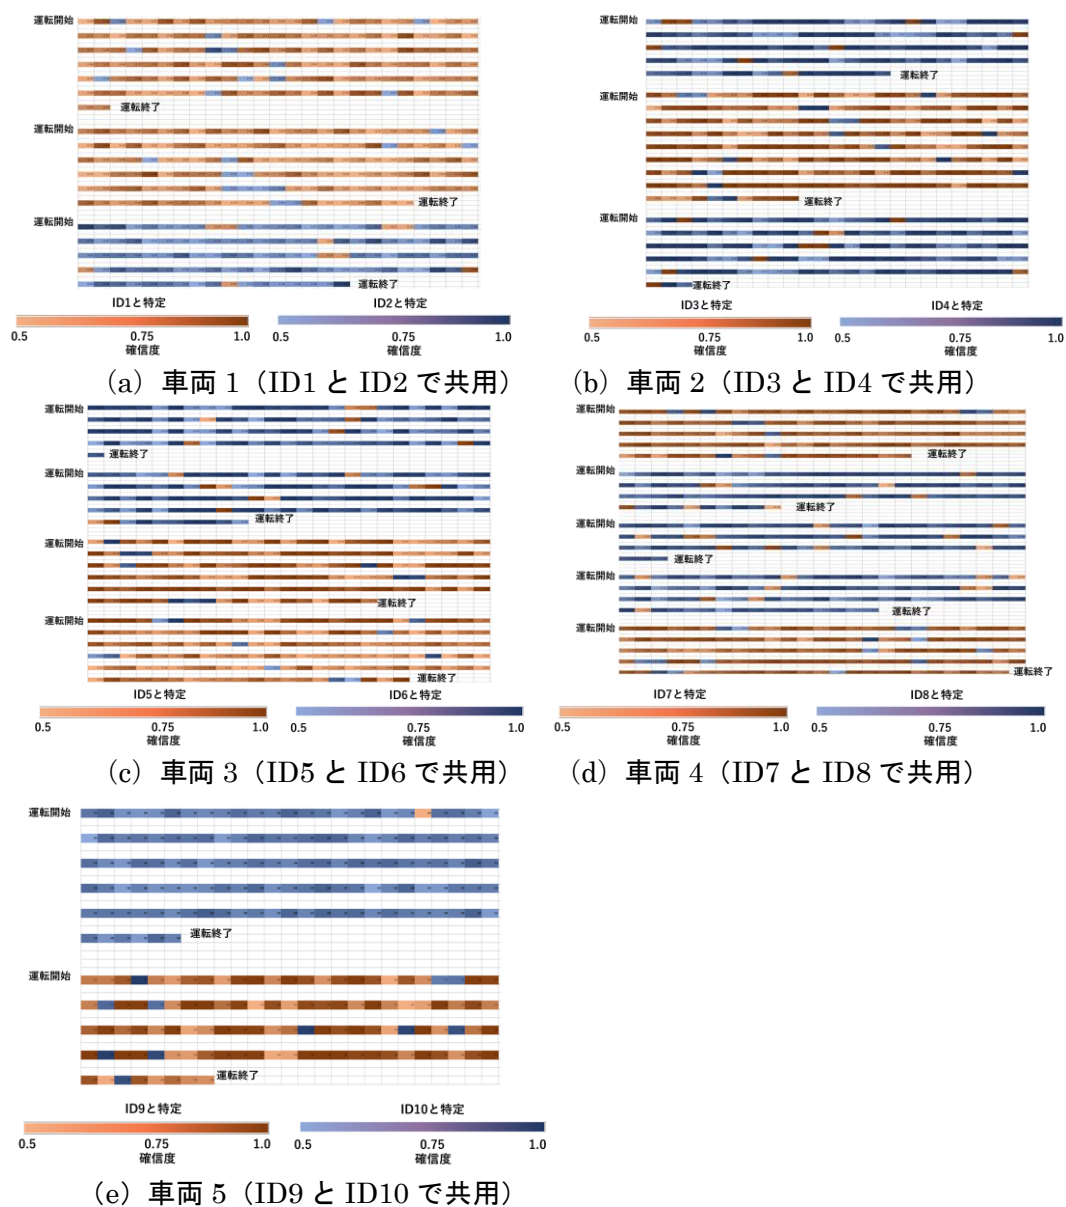
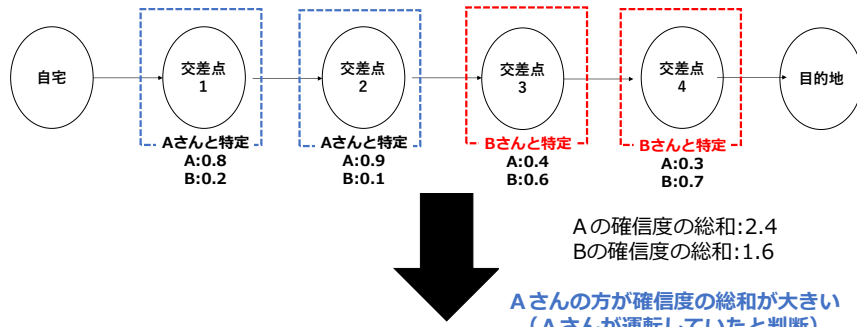


図 4.8 交差点の通過した順で並べた時の特定結果

そこで、図 4.8 に示す方法で確信度の総和から運転者特定を考える．図 4.8 では、一回の運転で得られた、確信度の総和を算出し、総和の大きい運転者が、その時に運転していた運転者であると判断する．

図 4.9 に、確信度の総和から判断した運転者特定の結果を示す．なお、以後の章では、表 4.1 に示した走行挙動は、図 4.9 で特定した運転者であるとした上で分析に用いることとする．

【〇月×日に観測した交差点部の走行挙動】



【〇月×日に観測した交差点部の走行挙動】




図 4.9 確信度の総和に基づいた運転者特定の考え方

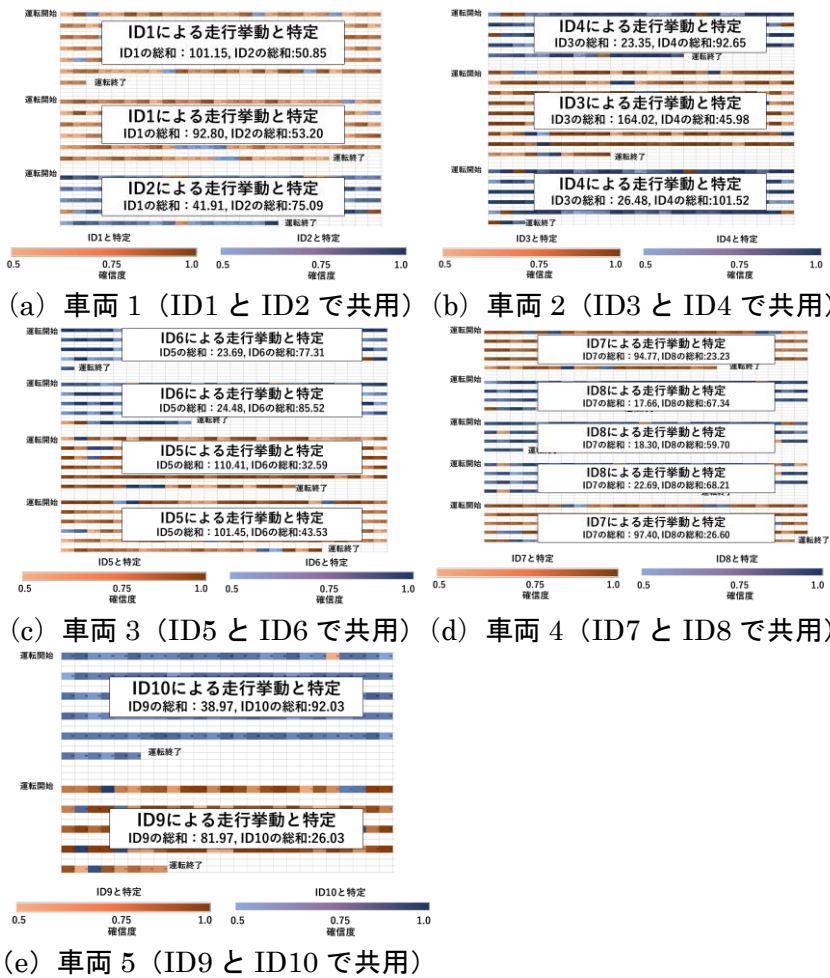


図 4.10 確信度の総和から判断した運転者特定の結果

4.6 本章のまとめ

本章では、交差点部の走行挙動を用いた運転者特定手法の構築を行った。一台の車両を夫婦で使用している ID1～ID10 の被験者を対象にどちらの運転者の走行挙動であるか特定を試みた。交差点部の運転操作は、発進時や停車時に比べて難しく、運転特性の違いが表れやすく、直線時や曲る時の走行挙動を用いて運転者特定を行った。

運転者特定の手法は LSTM を適用した。LSTM は時系列データから特徴を抽出することに秀でた手法である。交差点部の走行挙動に LSTM を適用して、交差点部での運転特性を抽出した。なお、LSTM を用いた運転者特定は、事前に LSTM の設定が必要になる。本研究では、既往研究の知見を踏まえ、中間層と中間層のニューロンの数を変えたモデルを作成し、特定精度の比較を行った。その結果、中間層の数が 1、中間層のニューロンの数が入力データ長の 2 倍となるモデルが最も適していることが示された。また、既往研究の手法と特定精度を比較した結果、本研究で作成した運転者特定モデルの精度が最も高いことが示された。

最後に、運転者が特定されていない走行挙動に作成したモデルを適用して、運転者特定を行った。さらに本研究では、特定結果の精緻化を試みた。運転者は、一回の運転で複数個の交差点部を通過することを踏まえ、交差点部を通過した順番で特定結果を列挙し、確信度の総和を算出した。確信度の総和が高い運転者をその時に運転していた運転者であると判断した。

第5章 交差点部の走行挙動に機械学習を適用した異常運転検知手法の構築

5.1 概要

本章では、交差点部の走行挙動に機械学習を適用した異常運転検知手法の構築を行う。本研究では、二つの観点から異常運転の定義を行い、異常運転検知手法を構築する。一つは、運転者全体の走行挙動とは異なる走行挙動を異常運転として検知する手法（以下：個人間異常運転検知）である。他方は、個々の運転者に着目し、普段とは異なる走行挙動を異常運転として検知する手法（以下：個人内異常運転検知）である。

図 5.1 に 5・6・7 章で行う分析項目を示す。5 章は異常運転検知手法の構築を行い、その後の章で構築した手法の性能評価を行う。6 章は事後検知による性能評価の検証、7 章はリアルタイム検知による性能評価の検証を行う。

以上を踏まえ、本章の流れについて述べる。5.2 では、走行挙動を用いて異常運転検知を行った既往研究について整理する。5.3 では、個人間異常運転検知、5.4 では、個人内異常運転検知の手法構築について述べる。

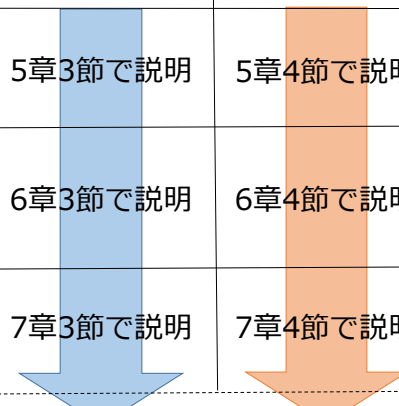
各章の目的/手法	個人間異常運転検知	個人内異常運転検知
(第5章) 異常運転検知 手法の構築	5章3節で説明	5章4節で説明
(第6章) 事後検知による 性能評価の検証	6章3節で説明	6章4節で説明
(第7章) リアルタイム検知に よる性能評価の検証	7章3節で説明	7章4節で説明
	 <p style="color: red; text-align: center;">二つの手法がもたらす効果 7章5節で説明</p>	

図 5.1 5・6・7 章で行う分析項目

5.2 走行挙動を用いた異常運転検知に関する既往研究

ここでは走行挙動を用いた異常運転検知を試みた既往研究の整理を行う。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¹⁻³⁾。

教師なし学習は、ラベルがない状態で学習を行う必要がある。その為、収集したデータモデルを作成し、モデルから乖離したデータを観測して、異常運転を検知した研究が多い。観測データが乖離しているかの判断は、外れ値検知と変化点検知の方法がある。ここでは外れ値検知と変化点検知から異常運転検知を行った既往研究について整理する。既往研究が

異常運転検知に適用した手法，異常度の考え方，異常度の定義方法，閾値の決定方法について述べる。

5.2.1 外れ値検知を用いた異常運転検知

表 5.1 に外れ値検知の観点から異常運転検知を行った既往研究の一連を示す。外れ値検知⁴⁻⁸⁾は，観測した走行挙動データが任意の閾値を越えた時を異常運転として判断する方法である。

表 5.1 外れ値検知を用いて異常運転検知を行った既往研究の一覧

著者	検知手法	異常度の考え方	異常度の決定方法	閾値の決定
Lampiri ⁴⁾	ホテリング理論	他の運転者との乖離度合い	観測データの距離	統計モデル
Din et al. ⁵⁾	混合正規分布モデル	他の運転者との乖離度合い	観測データの距離	統計モデル
Zhang et al. ⁶⁾	Isolation Forests	他の運転者との乖離度合い	観測データの密度	統計モデル
Ngan et al. ⁷⁾	Local Outlier Filter	他の運転者との乖離度合い	観測データの距離	統計モデル
宮内ら ⁸⁾	One Class Support Vector Machine	他の運転者との乖離度合い	観測データの距離・密度	統計モデル

例えば，Lampiri⁴⁾は，直線区間を通る車両の走行挙動に，ホテリング理論を用いて異常運転検知を試みた。ホテリング理論は，観測データが正規分布に従っていると仮定し，正規分布の平均値の距離から異常度を定義する。Din et al.⁵⁾は，直線区間を通る車両の走行挙動に，Gaussian Mixture Model (GMM)を用いて異常運転検知を試みた。GMMは，観測データが複数の正規分布に従うと仮定し，正規分布の平均値の距離から異常度を定義する。なお，観測データが単一の正規分布を仮定するホテリング理論よりも，GMMを適用した方が検知精度が高いことを明らかにした。Zhang et al.⁶⁾は，一時停止区間を走行する車両の走行挙動に Isolation Forests (IF)を用いて異常運転検知を試みた。IFは，観測データをデータ間の密度に基づいて任意の数が含むまで分割し，分割数の多さから異常度を定義する。Ngan et al.⁷⁾は，カーブ区間を通過する車両の走行挙動に，Local Outlier Filter (LOF)を用いて異常運転検知を試みた。LOFは，観測されたデータの密度から異常度を定義する。宮内ら⁸⁾は，交差点部を通過する車両の走行挙動に One Class Support Vector Machine (OCSVM)を用いて運転者の異常運転検知を試みた。なお，OCSVMの詳細は，5.3.2で述べる。

図 5.2(a)-(c)に，同一データを用いて GMM (分布数=2)，IF，LOF を適用した結果を示す。赤枠は，正常と異常を判断する境界線である。赤枠の外側は異常データであることを表している。色の濃淡は，境界線からの距離を表している。境界線はどの手法も類似しているが，色の濃淡は，GMMのみ異なっている。これは，IFやLOFは，観測データの密度から異常度を定義しているのに対し，GMMは，平均値との距離から異常度を定義しているからである。

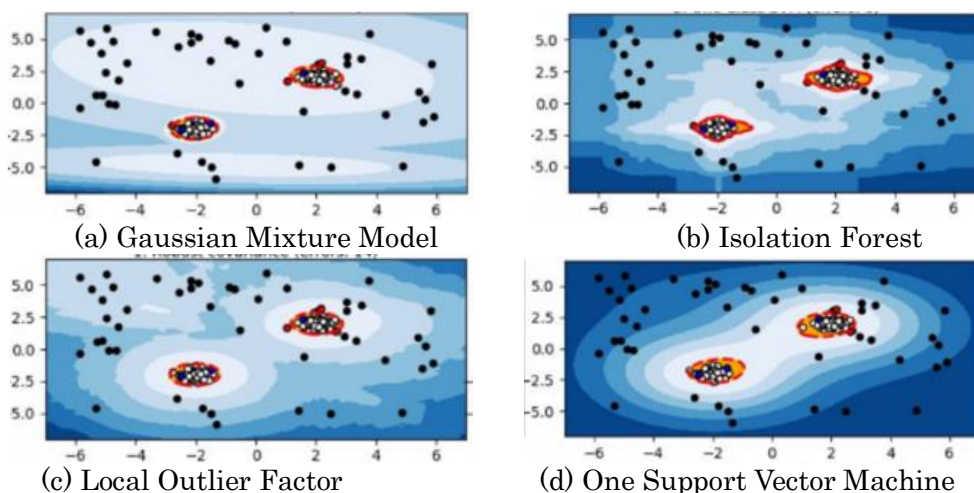


図 5.2 手法ごとの外れ値検知の境界線の比較

(<https://tech.preferred.jp/ja/blog/anomaly-detection-night/>)

5.2.2 変化点検知を用いた異常運転検知

表 5.2 に、変化割合の観点から異常運転検知を行った既往研究の一覧を示す。変化点検知⁹⁻¹⁷⁾は、前後の観測点の値の差や二つのデータ間の距離の差、入力・復元データの差、実測データと推測データの差、指標間の相関の崩れ度合いなどの変化割合が任意の閾値を越えた時を異常運転と判断する方法である。

表 5.2 変化点検知を用いて異常運転検知を行った既往研究の一覧

著者	検知手法	異常度の考え方	異常度の決定方法	閾値の決定
Hamada. et al. ⁹⁾	自己回帰モデル	他の運転者との乖離度合い	予測値と実測値の差	統計モデル
Dang et al. ¹⁰⁾	k近傍法	他の運転者との乖離度合い	観測データの距離	距離ベース
Eren et al. ¹¹⁾	動的時間伸縮法	他の運転者との乖離度合い	観測データの類似度	統計モデル
Fu et al. ¹²⁾	隠れマルコフモデル	他の運転者との乖離度合い	予測値と実測値の差	統計モデル
武石ら ¹³⁾	特異スペクトル変換	他の運転者との乖離度合い	相関の崩れ度合い	統計モデル
Matouseki et al. ¹⁴⁾	LSTM	他の運転者との乖離度合い	予測値と実測値の差	統計モデル
宮内ら ¹⁵⁾	LSTM Auto Encoder	個々の運転者の日々の変動度合い	復元度合い	統計モデル

例えば、Hamada. et al.⁹⁾は、個々の運転者の直線時の走行挙動の違いに着目し、自己回帰モデルを用いて異常運転検知を試みた。自己回帰モデルは、ある時刻の値を過去のデータを用いて回帰する統計的モデルである。Dang et al.¹⁰⁾は、曲がる時の車両の走行挙動に着目し、k近傍法を用いて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。Eren et al.¹¹⁾は、複数の運転者の曲る時の走行挙動に着目し、動的時間伸縮法を用いて異常運転検知を試みた。動的時間伸縮法は、二つの時系列データ間の距離・類似度を測る手法である。Fu et al.¹²⁾は、直進時の走行挙動に着目し、隠れマルコフモデルを用いて異常運転検知を試みた。隠れマルコフモデルは、時系列データに含む、直接観測できない潜在変数をモデル化する手法である。武石ら¹³⁾は、直進時の走行挙動に着目し、特異スペクトル変換を用いて異常運転検知を試みた。特異スペクトル変換は、過去と未来の部分時系列をスペクトル解析することで得られ


る変化点を抽出する手法である。Matouseki et al.¹⁴⁾ は、追従時の走行挙動に着目し、Long Short-Term Memory (LSTM) を用いて異常運転検知を試みた。LSTM は、隠れマルコフモデルと同様と直接観測できない潜在変数をモデル化できる手法である。隠れマルコフモデルと比較して、より多くの過去の観測点を考慮したモデル化ができる。宮内ら¹⁹⁾ は、交差点部の走行挙動に着目し、Long Short Term Memory Auto Encoder (LSTM AE) を用いて異常運転検知を試みた。LSTM AE の詳細は、5.4.2 で述べる。

他にも、主成分分析¹⁵⁾ や疎構造学習を用いた方法¹⁶⁾ , Convolutional Neural Network (CNN)¹⁷⁾ や Auto encoder (AE)¹⁸⁾ を適用した手法がある。主成分分析は次元を削減した手法である。疎構造学習は特異スペクトル変換を改良した手法である。CNN や AE を適用した手法があるが、これらはドラレコから観測した走行挙動データと画像データから運転者の異常運転を検知する方法として用いられていることが多い。

図 5.3(a)-(d)に変化点検知を比較した結果を示す。例えば、自己回帰モデルや LSTM を用いた異常検知は、観測値と予測値の乖離度合いから検知する方法である (図 5.3(a)参照)。一方、k 近傍法や隠れマルコフモデル、動的時間伸縮法、CNN を用いた異常検知は、前後の観測値の乖離度合いから検知する方法である (図 5.3(b)参照)。特異スペクトル変換や疎構造学習を用いた異常検知は、指標間の相関の崩れ度合いから検知する方法である (図 5.3(c)参照)。Auto Encoder を用いた異常検知は、入力データと復元データの乖離度合いから検知する方法である (図 5.3(d)参照)。


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。既往研究では、周りの運転者との乖離度合いから異常度を定義していることが明らかになった。これは、本研究で構築する個人間異常運転検知と同様の考え方である。

一方で、個々の運転者の日々の走行挙動の変動度合い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。したがって、本研究で構築する個人内異常運転検知は、新たな観点からの異常運転検知の取り組みであると考えられる。個人内異常運転検知の必要性が検証できれば、個人間異常運転検知と個人内異常運転検知の二つ観点から異常運転検知をすべきことが提言できると考えられる。



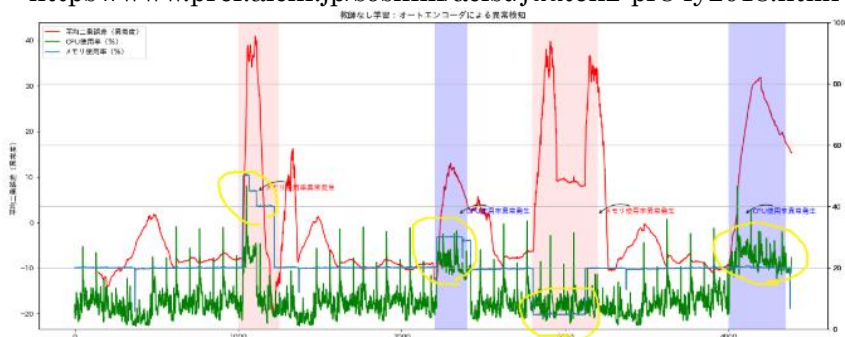
(a) 実測と予測の乖離度合い (b)前後の観測点での乖離度合い

https://www.kabuku.co.jp/developers/time_series_anomaly_detect
<https://qiita.com/umez/items/a23f0b0a7e6028c2244b>



(c) 指標間の相関の崩れ度合い

<https://www.pref.aichi.jp/soshiki/acist/juuten2-pr8-fy2018.html>



(d) 入力データと復元データの乖離度合い

https://sinyblog.com/deaplearning/abnorm_detect_002/

図 5.3 手法ごとの変化点検知の異常度の比較

5.3 個人間異常運転検知手法の構築

5.3.1 手法構築のコンセプト

ここでは個人間異常運転検知のコンセプトについて述べる。道路上を走行する運転者は様々である。多様な運転者が同じ道路を走行する上で重要なのが、安全かつ円滑な交通流を形成することである。自身や周りの運転者を含め、すべての運転者が危険な出来事に合うことなく、円滑に目的地へ着くことである。

しかしながら、他の運転者と同じような運転を心がけても、運転技量の差は個人によって大きく異なり、運転者自身の努力だけでは限界がある。そこで予防安全技術の一つとして、運転者全体に着目し、他の運転者の走行挙動との乖離度合いから異常運転を検知することを考えた。

図 5.4 に本手法のコンセプトを示す。例えば、ある交差点部を通過する際に、ほとんどの車両が 40km/h~55 km/h で運転しているとする。この時、極端に遅い車両 (20km/h) と速い車両 (80km/h) がある場合、遅い車両と速い車両は、安全かつ円滑な交通流の形成を妨げており、他の運転者と大きく乖離した異常運転をしていると考えられる。なお、車両速度の観点から述べたが、加速度や操舵角からも同様のことが言える。




図 5.4 本手法の設計コンセプト

以上を踏まえ、運転者全体から観測した走行挙動を基に平均を表す走行挙動モデルを作成し、モデルから乖離した走行挙動を異常運転として検知する個人間異常運転検知の手法構築を考えた。なお、6.3 では検知精度の検証，7.3 では検知タイミングの検証を行う。また、構築した手法の適用限界についても明らかにする。

5.3.2 特徴量の設定

ここでは個人間異常運転検知に用いる特徴量について述べる。5.3.1 で述べたコンセプトで異常運転検知を行う為には、多くの運転者から走行挙動を観測し、平均となる走行挙動をモデル化する必要がある。モデル化をする為には、多くの運転者から観測した走行挙動を操作性よく扱う必要がある。

本研究では、各データ（車両速度、三軸成分の加速度、操舵角など）における交差点部での平均値と標準偏差を算出し、特徴量として設定する。異常運転検知を行う運転者から観測した走行挙動の平均値や標準偏差が、他の運転者から観測した走行挙動の平均値や標準偏差と乖離した場合に異常運転が発生したと考える。

表 5.3 に個人間異常運転検知に用いる特徴量を示す。本手法は、他の運転者と乖離した走行挙動から異常運転を検知する。乖離した走行挙動は、様々なデータから考えられる。例えば、車両速度が乖離している場合もあれば、加速度が乖離している場合もある。その為、多くのデータから判断すべきである。

そこで本研究では、観測機器から直接出力される車両速度、三軸の各加速度、操舵角に加え、合成加速度、三軸の各躍度、合成躍度、操舵角速度の計 11 の特徴量を用いて運転者の特定を試みる。なお、各データの算出方法および概要は、4.3.3 に記載されている為、ここでは説明を割愛する。

表 5.3 個人間異常運転検知に用いる特徴量

No.	特徴量 (単位)	特徴量の説明
A1	車両速度の平均値(km/h)	車両の平均速度
	車両速度の標準偏差(km/h)	車両の速度のばらつき
A2	X軸成分の加速度の平均値(G)	車両の左右方向の平均加速度
	X軸成分の加速度の標準偏差(G)	車両の左右方向の加速度のばらつき
A3	Y軸成分の加速度の平均値(G)	車両の前後方向の平均加速度
	Y軸成分の加速度の標準偏差(G)	車両の前後方向の加速度のばらつき
A4	Z軸成分の加速度の平均値(G)	車両の上下方向の平均加速度
	Z軸成分の加速度の標準偏差(G)	車両の上下方向の加速度のばらつき
A5	操舵角の平均値(deg)	車両の平均の操舵角
	操舵角の標準偏差(deg)	車両の操舵角のばらつき
A6	合成加速度の平均値 (G)	車両の平均加速度
	合成加速度の標準偏差 (G)	車両の加速度のばらつき
A7	X軸成分の躍度の平均値(J)	車両の左右方向の平均躍度
	X軸成分の躍度の標準偏差(J)	車両の左右方向の躍度のばらつき
A8	Y軸成分の躍度の平均値(J)	車両の前後方向の平均躍度
	Y軸成分の躍度の標準偏差(J)	車両の前後方向の躍度のばらつき
A9	Z軸成分の躍度の平均値(J)	車両の上下方向の平均躍度
	Z軸成分の躍度の標準偏差 (J)	車両の上下方向の躍度のばらつき
A10	合成躍度の平均値 (J)	車両の平均躍度
	合成躍度の標準偏差 (J)	車両の躍度のばらつき
A11	操舵角速度の平均値(deg/s)	1秒当たりの操舵角の平均値
	操舵角速度の標準偏差(deg/s)	1秒当たりの操舵角の標準偏差

図 5.4 に特徴量の考え方を示す。まず、抽出した交差点部の走行挙動から、11 データの作成を行う。次に、各データにおける交差点部での平均値と標準偏差を特徴量として算出する。横軸に各データの平均値を表す特徴量、縦軸に各データの標準偏差をプロットする。




図 5.5 個人間異常運転検知の特徴量の考え方

5.3.3 分析手法

ここでは個人間異常運転検知に用いる分析手法について述べる。本研究では、異常・正常の境界線の作成の操作性が良い One Class Support Vector Machine (OCSVM) を用いて異常運転検知を行う。

図 5.6 に OCSVM の活用方法について述べる。OCSVM は、機械学習の分類・回帰アルゴリズムである Support Vector Machine (SVM) を教師なし学習の 1 クラス分類に応用した手法である。1 クラス分類は、全てのデータが正常であるとみなして 1 つのクラスで学習

させ、識別境界を決定することで、その境界に含まれているかどうかを検出できる。

データがプロットされている空間 (図 5.6(a)参照) に対し、カーネル関数と呼ばれる写像変換を行うと、原点付近に変換される (図 5.6(b)参照)。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。識別関数は正常か異常の境界線を決定する機能を持ち、線形や非線形などの設定が自由にできる。

OCSVM を用いた異常検知は、カーネル関数に RBF カーネル (ガウシアンカーネル) が用いられる。RBF カーネルは以下の式 (5.1) で表せる。

$$K(x, x') = \exp(-\gamma \|x - x'\|^2) \quad \therefore \left(\gamma = \frac{1}{2\sigma^2}\right) \quad (5.1)$$

この時、 $K(x, x')$ はカーネル関数、 x と x' はテストデータ等のベクトルである。なお、 γ は RBF カーネルを適用した時の特有のパラメータで、データに合わせて自動的に設定できる。異常度の計算は以下の式 (5.2) が成り立つ。

$$f(x) = \frac{\sum_i \alpha_i k(x_i, x) - \rho}{\rho} \quad \therefore \left(\rho = \sum_i \alpha_i k(x_j, x_i)\right) \quad (5.2)$$

異常度は、-1 から 1 の範囲をとる。異常と判定される場合は異常度が正の値となり、正常と判定される場合は異常度が負の値となる。学習データの値を用いることで、以下の式 (5.3) を解くことで算出される。

$$\min = \frac{1}{2} \sum_{ij} \alpha_i \alpha_j k(x_i, x_j) \quad \therefore \left(0 \leq \alpha_j \leq \frac{1}{vl}, \sum_i \alpha_i = 1\right) \quad (5.3)$$

α は、0 から 1 の間の値を取るパラメータ、 l は学習データの数となる。以上の計算より OCSVM を用いた異常度の計算が可能となる。 v は学習データの中に含まれている外れ値の割合を設定する値であり、事前に設定する必要がある。

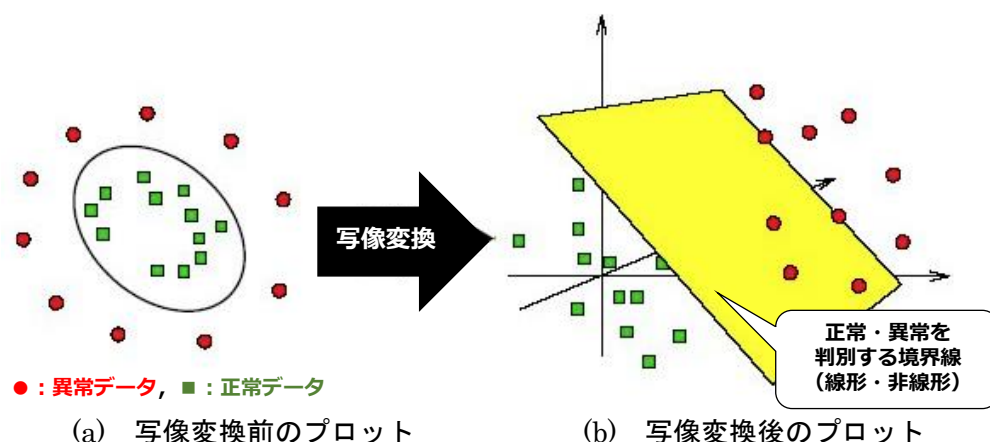


図 5.6 OCSVM の活用方法

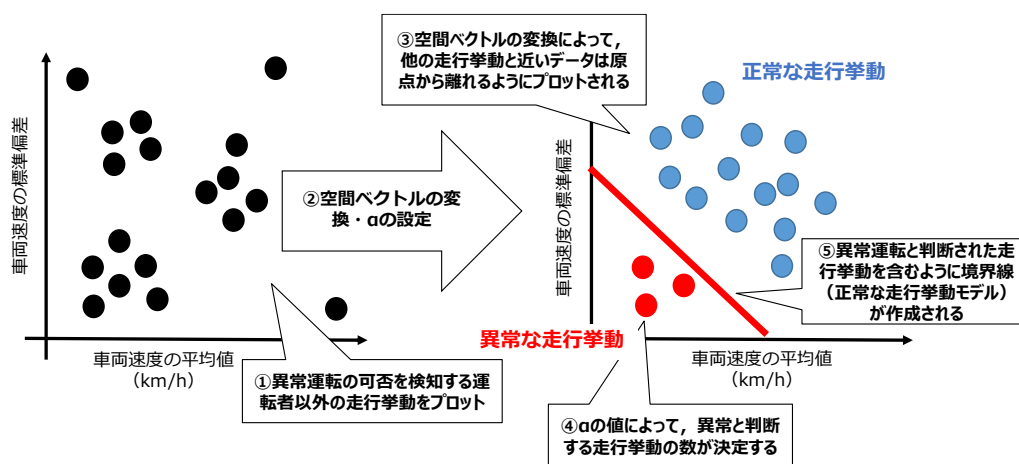
5.3.4 異常運転検知の流れ

ここでは個人間異常運転検知を行うまでの流れについて述べる。図 5.7 に OCSVM を用いた異常運転検知の流れを示す。本手法は、事前学習と異常検知時の二つの部分に分けられる。ここでは、走行挙動に含まれている車両速度に着目する。

(a) 事前学習時の流れ

1. 図 5.7 (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車両速度をプロットする。この時、横軸は、交差点部で観測した車両速度の平均値、縦軸は、交差点部で観測した車両速度の標準偏差を取る。

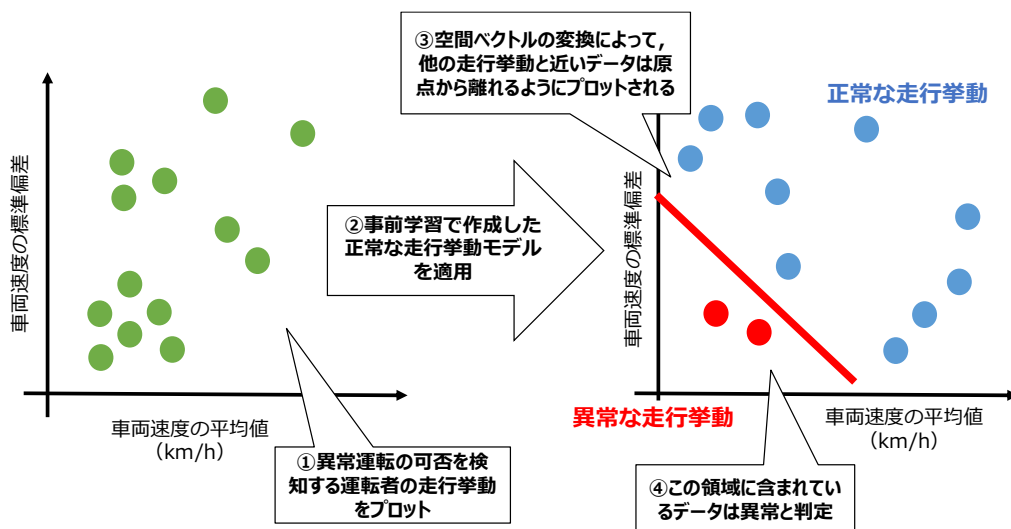
2. OCSVM が持つカーネル関数と呼ばれる写像変換と、観測したデータの中に含まれている異常運転とみなす割合を決めるパラメータ α を決定する。 α は、0 から 1 の間の値を取る。例えば、 α が 0.5 の場合は、観測データの半分が異常運転であると見なすことを意味する。なお、この α は異常運転検知に設定する閾値である。閾値の設定の詳細は 5.3.5 で述べる。
3. 写像変換を行うと、図 5.7 (a) 右図のように、プロットしたデータの距離と密度から、他のデータと乖離したデータは、原点付近に変換される。この時、原点付近に位置するデータは、異常なデータの可能性が高く、原点から離れるほど正常なデータとなる。
4. 2. で決定した α を基に、原点から近いデータが異常運転であると判断される。
5. 異常運転のデータと正常運転のデータを判別する境界線が作成される。本研究では、この境界線を正常な走行挙動モデルと定義している。なお、本研究では、RBF カーネル（ガウシアンカーネル）の識別関数を用いる。



(a) 事前学習時の流れ

(b) 異常運転検知時の流れ

1. 図 5.7 (b) 左図のように、異常運転検知を行う運転者から観測された車両速度をプロットする。この時、横軸は、交差点部で観測した車両速度の平均値、縦軸は、交差点部で観測した車両速度の標準偏差を取る。
2. 事前学習で作成した正常な走行挙動モデルを 1. でプロットしたデータに適用する。
3. 正常な走行挙動モデルと乖離した 1. でプロットした車両速度は、原点付近に変換される。
4. 事前学習で作成した正常な走行挙動モデルを基に、正常運転か異常運転の判別がされる。図 5.7 (b) 右図では、12 個の交差点部の走行挙動の内、二つの走行挙動が車両速度から異常運転と判断されたことを意味する。



(b) 異常運転検知時の流れ

図 5.7 OCSVM を用いた異常運転検知の流れ

以上が異常運転検知までの流れとなる。なお、ここでは車両速度を例として説明したが、本手法は 11 のデータの平均値と標準偏差から異常運転検知を行う。異常運転と判断されたデータが一つでもあった場合は、その交差点部で観測した走行挙動は異常運転であると判定することとする。

図 5.8 に観測調査で得られた交差点部の走行挙動に OCSVM を適用した結果を示す。ここでは、車両速度データを一例に述べる。他の運転者と乖離した走行挙動は赤くプロットされており、OCSVM で正常・異常の判断できることを示している。




図 5.8 OCSVM 適用後の正常・異常の判定

5.3.5 閾値の設定

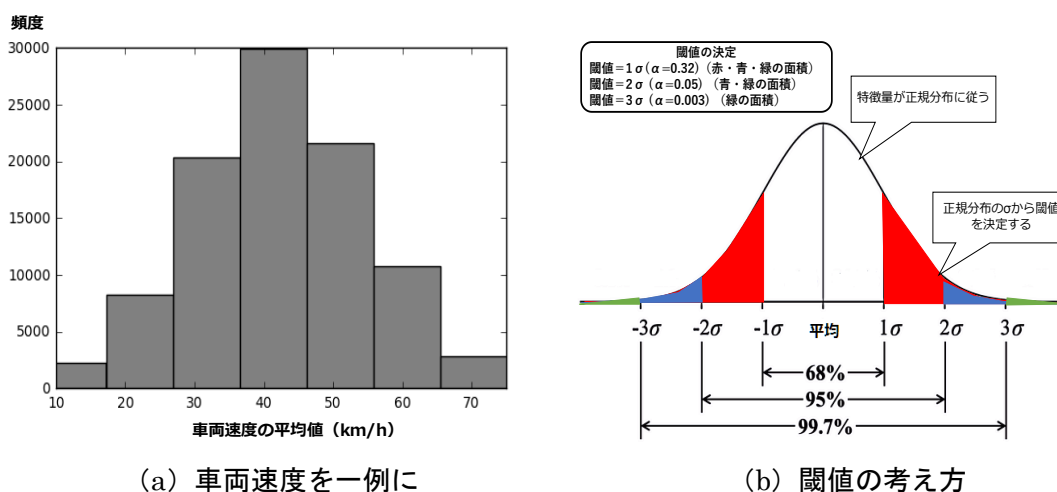
ここでは個人間異常運転検知に設定する閾値について述べる。運転者の走行挙動が異常運転かどうかを判断する為には、分析者が任意に閾値を設定する必要がある。閾値は検知精度や検知タイミングに大きな影響を及ぼす。5.2 の既往研究の整理でも述べたように、統計モデルに基づく方法で閾値を決定する。

OCSVM を用いた個人間異常運転検知の閾値は、5.3.4 で述べたように、事前学習で設定

するパラメータ α の値に依存している。パラメータ α は、異常運転とみなすデータの割合を表しており、 α の値が大きいと、運転者から見て安全側を考慮した閾値となる。一方で、 α の値が小さいと、運転者から見て危険側を考慮した閾値となる。

図 5.9 に本手法に用いる閾値の設定方法を示す。本研究では、観測調査で得られた走行挙動から、どのような分布に従っているかを確認した上で、閾値の考え方を決める。図 5.9(a) は、観測調査で得られた車両速度データの一例である。図からみても分かるように、概ね正規分布の形状をしている。また、他のデータでも確認したところ、正規分布の形状をしていることが確認された。

また、本研究では、外れ値検知から異常運転検知を行った既往研究の知見^{1,2,3,4,6,7,8)}を踏まえて、特徴量が正規分布に従っていると仮定して α を決定する。図 5.9(b) に閾値の考え方を示す。正規分布は、平均値 μ と標準偏差 σ から構成されている。例えば、平均値 μ から $\pm 1\sigma$ の範囲内に含まれている特徴量は全体の割合の 68%であることを意味する。この時、残りの 32%の特徴量は、異常運転として判断される。平均値 μ から $\pm 2\sigma$ の範囲内に含まれている特徴量は全体の割合の 95%であることを意味する。この時、残りの 5%の特徴量は、異常運転として判断される。平均値 μ から $\pm 3\sigma$ の範囲内に含まれている特徴量は全体の割合の 99.7%であることを意味する。この時、残りの 0.3%の特徴量は、異常運転として判断される。



(a) 車両速度を一例に (b) 閾値の考え方
 図 5.9 個人間異常運転検知に用いる閾値の設定方法

以上を踏まえたうえで、本研究では、(5.4) 式に示すように閾値を 1σ ($\alpha = 0.32$), 2σ ($\alpha = 0.05$), 3σ ($\alpha = 0.003$) と設定し、閾値を 1σ , 2σ , 3σ と変えた時の検知精度、検知タイミングを検証する。

$$Threshold = \mu \pm k\sigma \quad (k = 1,2,3)[v = 0.32, 0.05, 0.003] \quad (5.4)$$

5.4 個人内異常運転検知手法の構築

5.4.1 手法構築のコンセプト

ここでは個人内異常運転検知のコンセプトについて述べる。運転は運転者の体調面や精神面の変化が及ぼすとされている。イライラした状態で運転をするとスピードなどが発生

する。他にも、考え事をした運転をすると、注意力の低下により標識の見落としやなどの傾向が考えられる。

しかしながら、平常心な状態を心がけても、日常生活を通して精神状態は変わり、運転者自身の努力だけでは限界がある。そこで予防安全技術の一つとして、個々の運転者の走行挙動の変動度合いから異常度を定義した、異常運転検知ができると考えた。

図 5.10 に本手法のコンセプトを示す。例えば、普段は一停止標識がある交差点に対し、停止した状態で発進しているが、一時停止をせずに通過をした運転が発生したとする。この時に観測される車両速度は、普段の運転時との変動が大きいことが想定される。したがって、普段の運転との変動度合いが大きい時は、事故の発生に結びつきやすい異常運転をしていると考えられる。なお、車両速度の観点から述べたが、加速度や操舵角からも同様のことが言える。

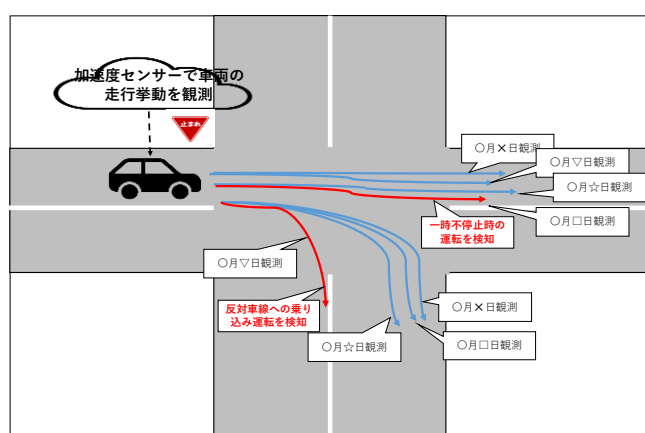


図 5.10 本手法の設計コンセプト

以上を踏まえ、個々の運転者から観測した走行挙動を基に普段の運転を表す走行挙動モデルを作成し、モデルとの変動度合いが大きい走行挙動を異常運転として検知する個人内異常運転検知の手法構築を考えた。なお、6.4 では検知精度の検証、7.4 では検知タイミングの検証を行う。また、構築した手法の適用限界についても明らかにする。

5.4.2 特徴量の設定

ここでは個人内異常運転検知に用いる特徴量について述べる。5.4.1 で述べたコンセプトで異常運転検知を行う為には、個々の運転者の交差点部で観測した走行挙動に着目し、普段の運転を表す走行挙動をモデル化する必要がある。モデル化する為には、交差点部での走行挙動の詳細な変化を把握する為軌跡に着目する必要がある。

本研究では、各データ（車両速度、三軸成分の加速度、操舵角など）における交差点部での軌跡（時系列変化）を特徴量として設定する。観測した走行挙動の軌跡、普段の運転で観測する軌跡と比べて変動した場合に異常運転が発生したと考える。

表 5.4 に個人内異常運転検知に用いる特徴量を示す。本手法は、普段の運転と変動した走行挙動から異常運転を検知する。変動した走行挙動は、様々なデータから考えられる。例えば、車両速度が変動している場合もあれば、加速度が変動している場合もある。その為、多くのデータから判断すべきである。

そこで本研究では、観測機器から直接出力される車両速度、三軸の各加速度、操舵角に加え、合成加速度、三軸の各躍度、合成躍度、操舵角速度の計 11 の特徴量を用いて運転者の

特定を試みる。なお、各データの算出方法および概要は、4.3.3 に記載されている為、ここでは説明を割愛する。

表 5.4 個人内異常運転検知に用いる特徴量

No.	特徴量	特徴量の説明
B1	車両速度 (km/h)	車両の速度
B2	X軸成分の加速度 (G)	車両の左右方向の加速度
B3	Y軸成分の加速度 (G)	車両の前後方向の加速度
B4	Z軸成分の加速度 (G)	車両の上下方向の加速度
B5	操舵角 (deg)	車両が向く方向
B6	合成加速度 (G)	X, Y, Z軸成分の合成加速度
B7	X軸成分の躍度 (J)	車両の左右方向の躍度
B8	Y軸成分の躍度 (J)	車両の前後方向の躍度
B9	Z軸成分の躍度 (J)	車両の上下方向の躍度
B10	合成躍度 (J)	X, Y, Z軸成分の合成躍度
B11	操舵角速度 (deg/s)	1秒当たりの操舵角

図 5.11 に特徴量の考え方を示す。まず、抽出した交差点部の走行挙動から、11 データの作成を行う。次に、各データにおける交差点部での軌跡を特徴量として算出する。横軸に交差点部に進入してからの経過時間、縦軸に各データの時間ごとの値をプロットする。

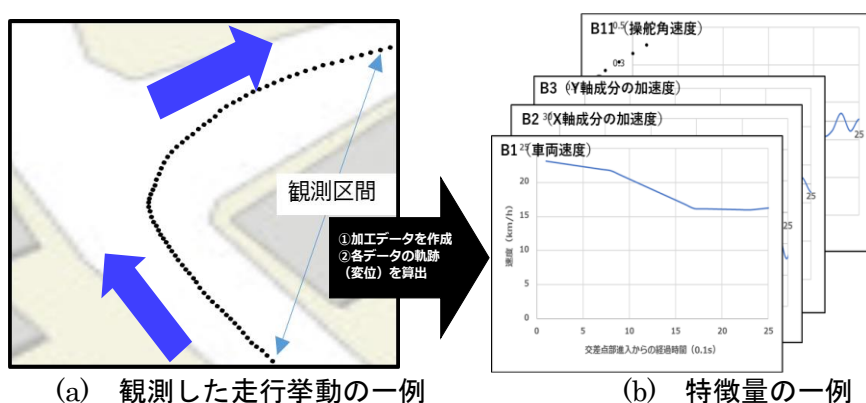


図 5.11 個人内異常運転検知の特徴量の考え方

5.4.3 分析手法

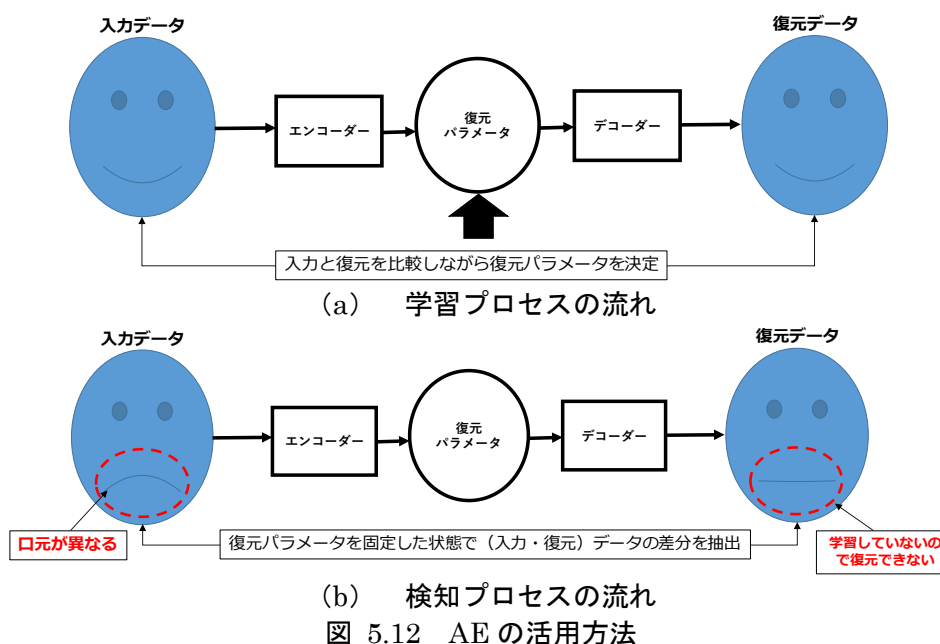
ここでは個人内異常運転検知に用いる分析手法について述べる。本研究では、観測した走行挙動の運転特性を抽出し、さらに抽出した運転特性の変動度合いを定量的に把握できる、LSTM Auto Encoder (LSTM AE) を用いて異常運転検知を行う。LSTM AE は、時系列データの特徴を抽出する LSTM と入力と復元の差分から異常検知を行う Auto Encoder を組み合わせた手法である。なお、LSTM と AE を組み合わせる理由は、走行挙動の特徴の変動度合いから異常運転検知を行う為である。特徴が普段通りに表出していれば、いつも通りの運転ができていると考えた。

LSTM は、4 章でも用いた手法で、走行挙動などの時系列データが持つ特徴を把握することに秀でた手法である。本手法では、交差点部の走行挙動に LSTM を適用して運転特性を抽出する。なお、LSTM は 4.3.2 で述べたので、ここでは詳細を割愛する。

Auto Encoder (AE) について述べる。図 5.12 に AE の活用方法を述べる。AE は、深層学習の一種で、次元の削減を行い、情報量を小さくして特徴を抽出する手法である。入力層と出力層の間の中層に AE を設定することでデータから特徴を抽出することが可能である。入力層から圧縮していく過程をエンコーダーと呼び、出力層へ復元する過程をデコーダーと呼ぶ。エンコーダーは入力を低次元に表現することができ、デコーダーは低次元から復

元する能力を持つ。

AEは、エンコーダーとデコーダーのやり取りを介すことで、入力したデータと復元されたデータから得られる差分（再構成誤差）から異常検知を行うことが可能である。例えば、一度学習しているデータをエンコーダーに入力した時は、入力したデータがデコーダーへそのまま復元され、再構成誤差は0となる（図5.12(a)参照）。一方で、学習していないデータをエンコーダーに入力した時は、入力したデータを完全に復元されない。つまり、エンコーダーとデコーダーの再構成誤差が大きくなる（図5.12(b)参照）。



5.4.4 異常運転検知の流れ

ここでは個人内異常運転検知を行うまでの流れについて述べる。図5.13にLSTM AEを用いた異常運転検知の流れを示す。本手法は事前学習と異常検知時の二つの部分に分けられる。ここでは、車両速度を例にして述べる。

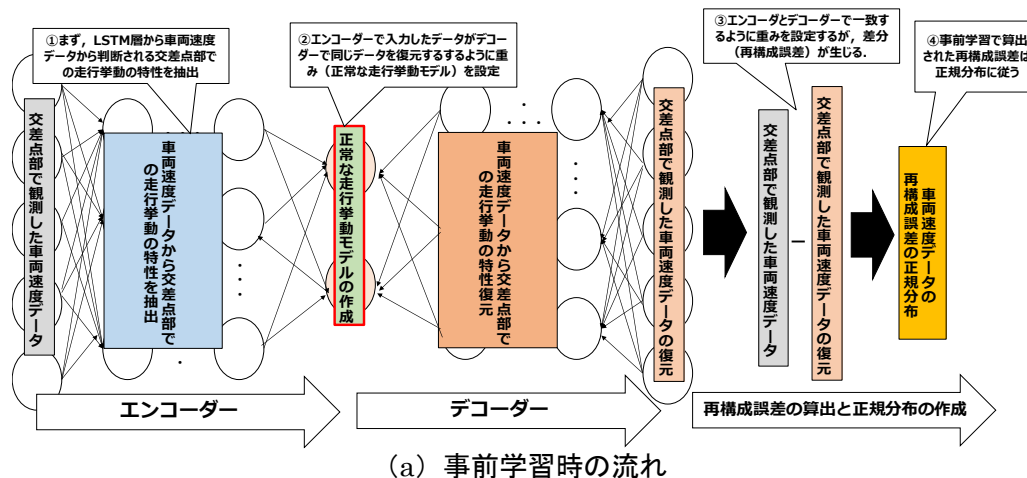
(a) 事前学習時の流れ（図5.13(a)参照）

1. エンコーダーでは、入力した車両速度にLSTMを適用して、車両速度に関する走行挙動の運転特性を抽出する。
2. デコーダーでは、AEを用いてエンコーダー側で抽出した、車両速度に関する走行挙動の運転特性の復元、入力した車両速度の復元を行う。
3. エンコーダーの入力とデコーダーの出力が一致するようにパラメータを設定する。設定したパラメータを本研究では正常な走行挙動モデルと定義する。
4. エンコーダーに入力した車両速度とデコーダーで復元された車両速度には再構成誤差が生じる。再構成誤差 e は、入力データ x と復元データ x' の差を二乗した値で算出する。以下の(5.5)式で算出される。

$$e_i = (x_i - x'_i)^2 \quad (5.5)$$

5. 再構成誤差は正規分布に従うと仮定し、閾値を決定する。なお、閾値の設定の詳細は

5.4.5 で述べる。



(b) 異常運転検知時の流れ (図 5.13 (b)参照)

1. エンコーダーでは、事前学習で設定したパラメータ（正常な走行挙動モデル）を固定した状態で、事前学習に用いていない車両速度を入力する。まず、車両速度に LSTM を適用して、車両速度に関する走行挙動の運転特性を抽出する。
2. デコーダーでは、これにより、正常な走行挙動モデルを用いて、車両速度に関する走行挙動の運転特性の復元、車両速度の復元が行われる。
3. 入力した車両速度と復元された車両速度の再構成誤差を算出する。
4. 再構成誤差が、事前学習で設定した閾値から正常・異常運転の判別を行う。

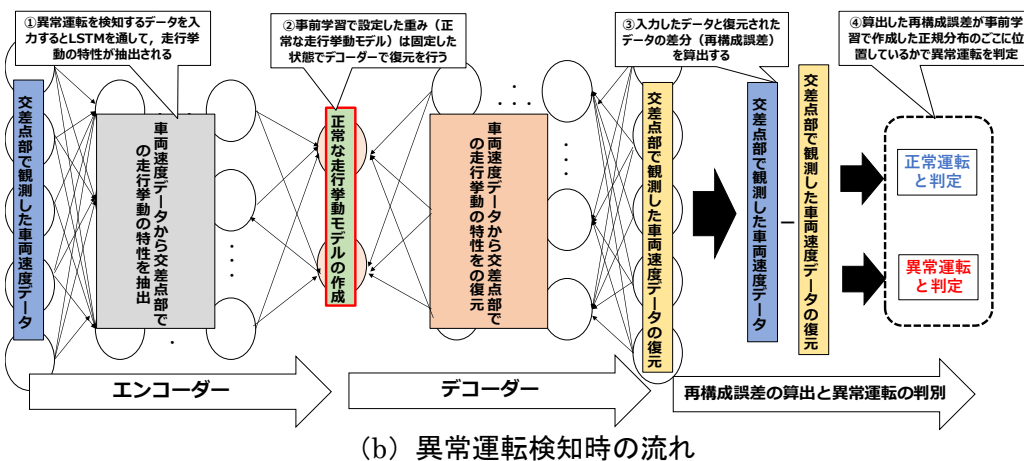


図 5.13 LSTM AE を用いた異常運転検知の流れ

図 5.14 に再構成誤差の算出と閾値との関係を示す。再構成誤差は、図 5.14(a)に示すように、新たな観測点が変わるごとに、再構成誤差が算出される。算出した再構成誤差は、図 5.14 (b)のように累積する形となる。この時、累積した再構成誤差が、事前に設定した閾値を越えた地点で異常運転が発生したとする。

以上が異常運転検知までの流れとなる。なお、ここでは車両速度を例として説明したが、本手法では 11 のデータの軌跡から異常運転検知を行う。異常運転と判断されたデータが一つでもあった場合は、その交差点部で観測した走行挙動は異常運転であると判定する。

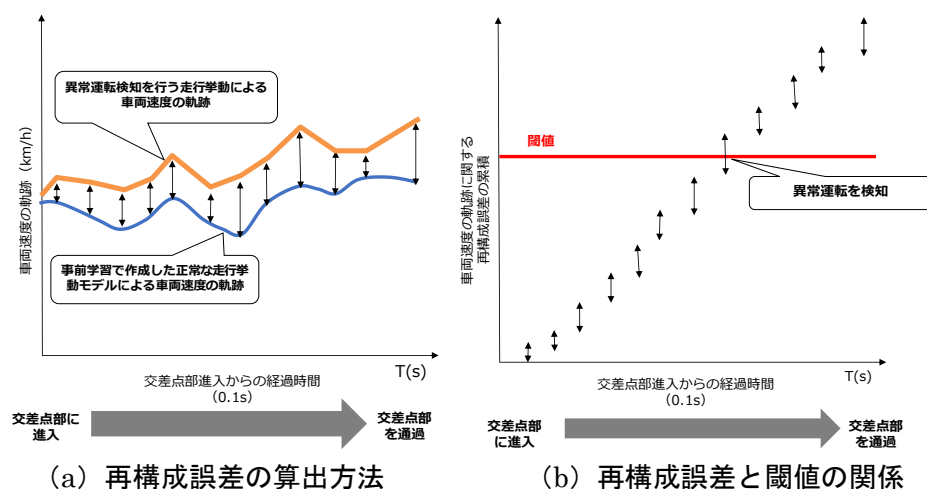


図 5.14 再構成誤差の算出と閾値の関係

5.4.5 閾値の設定

ここでは個人内異常運転検知に設定する閾値について述べる。個人間異常運転検知の閾値は、事前学習で算出された再構成誤差に依存している。図 5.15 に本手法に用いる閾値の設定方法を示す。本研究では、事前学習で算出された再構成誤差が、どのような分布に従っているかを確認した上で、閾値を決める。図 5.15(a)は、事前学習で算出された車両速度に関する再構成誤差の一例である。図から分かるように、概ね正規分布の形状をしている。また、他のデータおよび運転者でも同様に、正規分布の形状をしていることが確認された。

そこで本研究では、変化点検知から異常運転検知を行った既往研究の知見¹⁰⁻¹⁹⁾を踏まえ、事前学習で算出した各データの再構成誤差が正規分布 (μ, σ) に従っていると仮定して閾値の決定を行う。正規分布の平均値 μ と標準偏差 σ から閾値を決定する。図 5.15(b)に閾値の考え方を示す。

例えば、事前学習で入力した走行挙動と同様の走行挙動が観測された場合は、再構成誤差が 0 となり、図の左端に位置する。しかしながら、同じ交差点部を運転しても、再構成誤差は発生するとされており、再構成誤差の値が大きいほど、普段通りの運転ができていないことを意味する。

なお、異常運転を検知する走行挙動から算出された再構成誤差が正規分布の平均値より小さい場合は、正常な走行挙動に近いことを意味する。したがって、本研究では正規分布の右側部分に着目して、異常運転が発生したかどうかを判断する。

以上を踏まえて、(5.6) 式に示すように閾値を 1σ 、 2σ 、 3σ に設定し、閾値を変えた時の検知精度、検知タイミングを検証する。

$$\text{Threshold} = \mu + k\sigma \quad (k = 1, 2, 3) \tag{5.6}$$




図 5.15 異常運転検知に用いる閾値の概念図

5.5 本章のまとめ

本章では、走行挙動に機械学習を適用した異常運転検知手法の構築を行った。走行挙動から異常運転を検知するにあたり、他の運転者との走行挙動の乖離度合いから異常度を定義する個人間異常運転検知と個々の運転者の日々の走行挙動の変動度合いから異常度を定義する個人内異常運転検知の構築を行った。

個人間異常運転検知は、運転者全体の走行挙動に着目する為、多くのデータを処理する必要がある。そこで、交差点部で観測した走行挙動から各データの平均値と標準偏差を特徴量として設定した。適用する手法は、正常・異常運転の判別の操作性が良い OCSVM を適用した。異常運転検知に用いる閾値は、特徴量が従っている分布を確認したところ、正規分布に従っていることを確認した。そこで、正規分布の割合から閾値を決定した。

個人内異常運転検知は、運転者の日々の走行挙動に着目する為、交差点部での詳細な変化を把握する必要がある。そこで、交差点部で観測した走行挙動から各データの軌跡（時系列変位）を特徴量として設定した。適用する手法は、日々の運転特性の変動度合いを定量化できる LSTM AE を適用した。異常運転検知に用いる閾値は、事前学習で算出した特徴量の再構成誤差が従っている分布を確認したところ、正規分布に従っていることを確認した。そこで、正規分布の割合から閾値を決定した。

なお、5.1 でも述べたように、本章で構築した手法は、6 章で事後検知による性能評価の検証、7 章ではリアルタイム検知による性能評価の検証を行う。さらに、構築した手法の適用限界についても検討する。

第6章 事後検知による性能評価の検証

6.1 概要

本章では、事後検知による性能評価の検証を行う。事後検知は運転者が交差点部を通過した後に、今の運転が異常運転であったかを判断する。1.2でも述べたように、事後検知の結果は、安全運転の啓発や運転技量評価などのソフト面への活用が可能で、異常運転が発生した時に検知を見落とさない高い検知精度が必要になる。そこで、構築した手法の検知精度、適用限界、運転者特定の有無が及ぼす検知精度への影響、既往研究の手法との比較、事後検知に有効なデータを手法の性能評価を通して明らかにする。

以上を踏まえ、本章の流れについて述べる。6.2では、異常運転が発生したシナリオの概要および検知精度の算出方法について述べる。6.3では、個人間異常運転検知（以下、本章では個人間検知と呼ぶ）の性能評価の検証を行う。6.4では、個人内異常運転検知（以下、本章では個人内検知と呼ぶ）の性能評価の検証を行う。

6.2 事後検知による性能評価の方法

6.2.1 設定したシナリオ

ここでは異常運転の発生を想定したシナリオについて述べる。2.2でも述べたように、本研究では、事前学習で用いる走行挙動と特性が異なる走行挙動を、異常運転が発生した走行挙動として用意し、この走行挙動に対しどの程度の割合で、異常運転として検知できるかを検証する。

本研究では、交差点部で行う運転操作を基に、交差点部の走行挙動を54通りに分類した。それぞれのケースで観測した走行挙動は特性が大きく異なる。したがって、事前学習で正常な走行挙動モデルを作成する為に使用したケース以外の走行挙動が観測された時は、異常運転が発生したと見なすことができると考えた。

構築した手法の性能評価を検証する為には、交差点部で事故の発生が想定されるシナリオを設定する必要がある。表6.1に本手法の性能評価に用いるシナリオの概要を示す。本研究では、6つのシナリオを設定し、手法の性能評価を行う。

シナリオ1～シナリオ3は、運転者が交差点部へ進入する時に起こる誤操作（以下、本章では進入時の運転の誤操作と呼ぶ）が発生した時を異常運転として検知する。進入時の運転の誤操作が原因で起きる事故は、一時停止場所での不停止や故意な急停止、アクセルとブレーキの踏み間違いによる急発進などが挙げられる。進入時の運転の誤操作を再現する為に、事前学習では交差点部において車両が停車しないで通過した時のケースの走行挙動（表6.2参照）を学習用データに用いて正常な走行挙動モデルを作成する。一方で、異常運転の発生の有無を検知する時は、交差点部を一度停車した状態から発進する時のケースの走行挙動（表6.2参照）を検証用データとして用いて異常運転検知を行う。

シナリオ4～シナリオ6は、運転者が交差点部を曲がる時に起こる誤操作（以下、本章では曲る時の運転の誤操作と呼ぶ）が発生した時を異常運転として検知する。曲る時の運転の

誤操作が原因で起きる事故は、隣車線や反対車線への進入などがあげられる。曲る時の運転の誤操作を再現する為に、事前学習では交差点部において車両が停車しないで通過した時のケースの走行挙動（表 6.2 参照）を学習用データに用いて正常な走行挙動モデルを作成する。そして、異常運転の発生の有無を検知する時は、事前学習で使用した交差点規模と異なるケースの走行挙動（表 6.2 参照）を検証用データに用いて異常運転検知を行う。

なお、異常運転の発生は、交差点部の規模によって変わると考えられる。そこで、シナリオ 1, 4 は大規模交差点（流入部と流出部の車線数が 2 車線以上の場合）、シナリオ 2, 5 は中規模交差点（流入部と流出部の車線数が片側 1 車線の場合）、シナリオ 3, 6 は小規模交差点（流入部と流出部の車線数が両側 1 車線の場合）で異常運転が発生したと想定し、交差点規模ごとの検知精度を検証する。

表 6.1 手法の性能評価に用いるシナリオの概要

シナリオ	学習用データ				検証用データ			
	ケース	発進方法	進行方向	交差点規模	ケース	発進方法	進行方向	交差点規模
シナリオ1	Case4-Case6	停車した状態から通過	右左折直進	大規模交差点 (流入部の車線数が片側2車線以上)	Case1-Case3	停車せずに通過	右左折直進	大規模交差点 (流入部の車線数が片側2車線以上)
シナリオ2	Case28-Case30		右左折直進	中規模交差点 (流入部の車線数が片側1車線)	Case25-Case27		右左折直進	中規模交差点 (流入部の車線数が片側1車線)
シナリオ3	Case52-Case54		右左折直進	小規模交差点 (流入部の車線数が両側1車線)	Case49-Case51		右左折直進	小規模交差点 (流入部の車線数が両側1車線)
シナリオ4	Case49-Case51	停車せずに通過	右左折	小規模交差点 (流入部の車線数が両側1車線)	Case1-Case3	停車せずに通過	右左折	大規模交差点 (流入部の車線数が片側2車線以上)
シナリオ5	Case1-Case3		右左折	大規模交差点 (流入部の車線数が片側2車線以上)	Case25-Case27		右左折	中規模交差点 (流入部の車線数が片側1車線)
シナリオ6	Case25-Case27		右左折	中規模交差点 (流入部の車線数が片側1車線)	Case49-Case51		右左折	小規模交差点 (流入部の車線数が両側1車線)

表 6.2 表 3.9 の再掲

Case	車線数の変化	発進方法	進行方向
1	片側2車線以上 →片側2車線以上	停止せずに通過	右折
2			直進
3			左折
4		停止状態から発進	右折
5			直進
6			左折
7	片側2車線以上 →片側1車線	停止せずに通過	右折
8			直進
9			左折
10		停止状態から発進	右折
11			直進
12			左折
13	片側2車線以上 →両側1車線	停止せずに通過	右折
14			直進
15			左折
16		停止状態から発進	右折
17			直進
18			左折
19	片側1車線 →片側2車線以上	停止せずに通過	右折
20			直進
21			左折
22		停止状態から発進	右折
23			直進
24			左折
25	片側1車線 →片側1車線	停止せずに通過	右折
26			直進
27			左折
28		停止状態から発進	右折
29			直進
30			左折
31	片側1車線 →両側1車線	停止せずに通過	右折
32			直進
33			左折
34		停止状態から発進	右折
35			直進
36			左折
37	両側1車線 →片側2車線以上	停止せずに通過	右折
38			直進
39			左折
40		停止状態から発進	右折
41			直進
42			左折
43	両側1車線 →片側1車線	停止せずに通過	右折
44			直進
45			左折
46		停止状態から発進	右折
47			直進
48			左折
49	両側1車線 →両側1車線	停止せずに通過	右折
50			直進
51			左折
52		停止状態から発進	右折
53			直進
54			左折

6.2.2 検知率の算出方法

ここでは事後検知の評価指標の算出方法について述べる。本研究で構築した手法は、既に異常運転と判断された走行挙動の収集が困難な点から、教師なし学習による異常運転検知を行う。その為、教師あり学習の時に用いる評価指標（精度、適合率、再現率、F値）とは異なる方法で、構築した手法の妥当性を検証する必要がある。

そこで本章では、検知率という評価指標を用いて、構築した手法の性能評価を行う。検知率は(6.1)式より算出する。検証用データに対し、異常運転と判断した割合で手法の性能評価を行う。検知率が高いほど検証用データを異常運転と判断できていることを意味する。したがって、検知率が高いことは、設定したシナリオの場面において有効な効果を発揮する。

と言える。一方で、検知率が低い場合は、手法の適用限界であると考えられる。

$$\text{検知率 (\%)} = \frac{A}{A+B} \times 100 \quad (6.1)$$

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

次に、検知率の算出フローについて述べる。検知率の算出フローは、個人間検知と個人内検知によって異なる。まず初めに、個人間検知による検知率の算出フローを図 6.1 に示す。

(a) 個人間検知による検知率の算出フロー

1. 異常運転を検知する運転者と検知率を算出するシナリオを決定する。
2. 異常運転の可否を判断する運転者の走行挙動を検証用データ、その他の運転者の走行挙動を学習用データに設定する。
3. 学習用データにパラメータ α を設定し、異常・正常運転を判別する正常な走行挙動モデルを作成する。
4. 検証用データの中から一つ走行挙動を抽出し、3.で作成した正常な走行挙動モデルに適用する。この時のデータ長は、交差点部を進入した時点から交差点部を通過した時点とする。
5. 4.で適用した走行挙動が正常運転の境界に含まれていれば、異常運転は発生していないと考える。反対に、走行挙動が異常運転の境界の方に含まれていれば、異常運転が発生していると考ええる。
6. 4.-5.を検証用データの数だけ行い、(6.1)式より検知率を算出する。

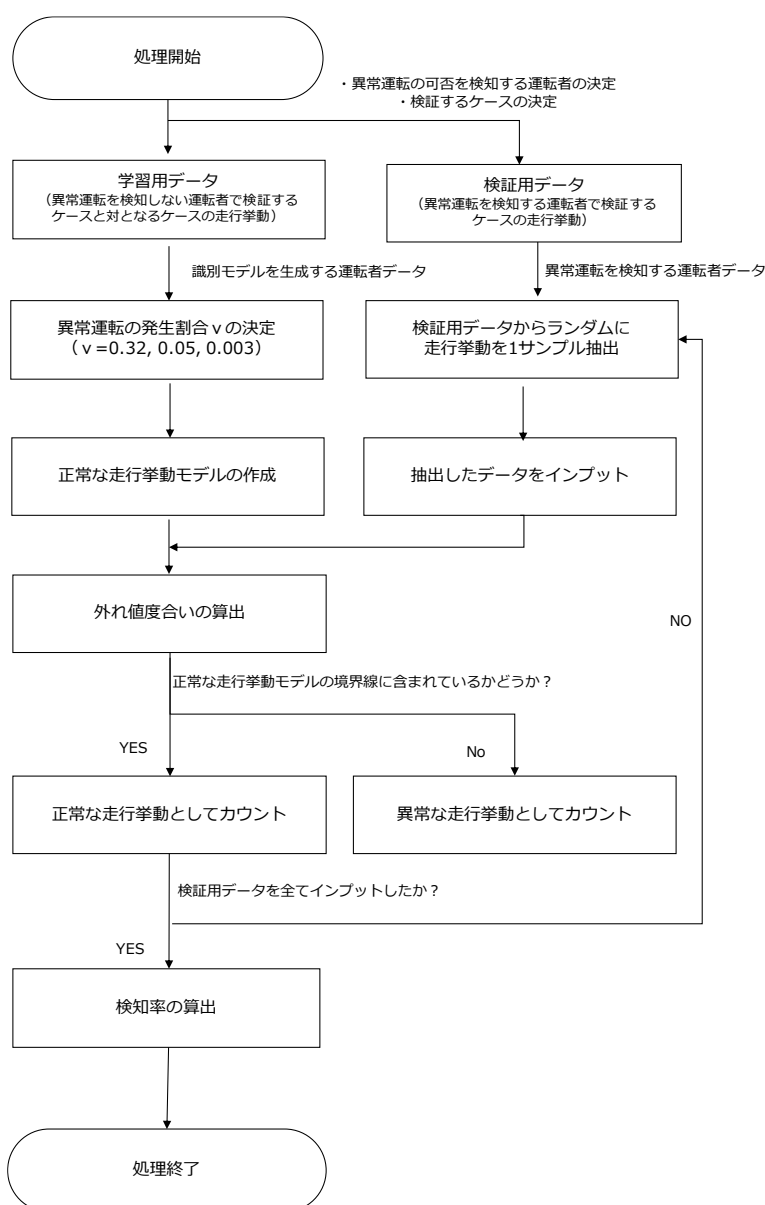


図 6.1 個人内検知による検知率の算出フロー

次に、個人内検知による検知率の算出フローを図 6.2 に示す。

(b) 個人内検知による検知率の算出フロー

1. 異常運転を検知する運転者と検知率を算出するシナリオを決定する。
2. 異常運転の可否を検知する走行挙動を検証用データ、正常な走行挙動モデルを作成する走行挙動を学習用データに分ける。
3. 学習用データに設定条件を適用して、正常な走行挙動モデルを作成する。
4. 検証用データの中から一つ走行挙動を抽出し、3.で作成した正常な走行挙動モデルに適用する。この時のデータ長は、交差点部を進入した時点から交差点部を通過した時点とする。
5. 4.で適用した走行挙動から算出される再構成誤差が、閾値を越えていない場合は、異常

運転は発生していないと考える。反対に、閾値を越えている場合は、異常運転が発生していると考えられる。

6. 4-5.を検証用データの数だけ行い、(6.1)式より検知率を算出する。

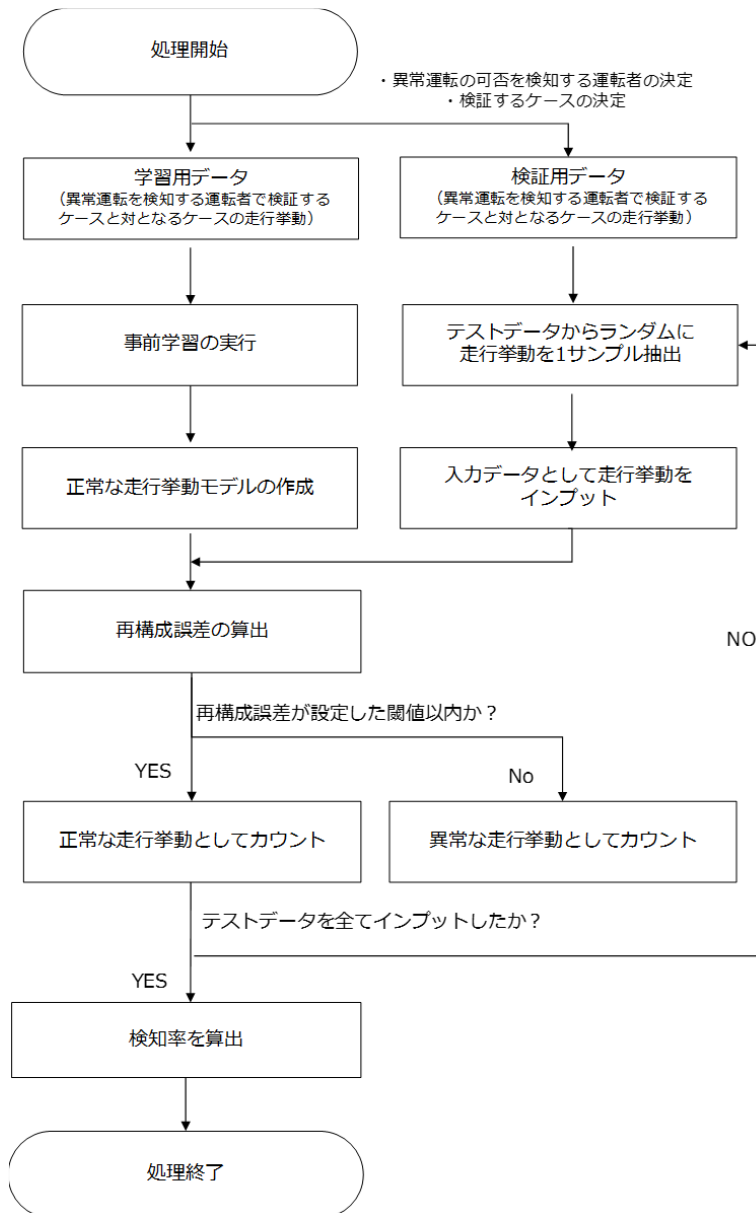



図 6.2 個人内検知による検知率の算出フロー

6.3 個人間異常運転検知の性能評価

6.3.1 検知率の検証結果

ここでは個人間検知の検知率の検証結果について述べる。図 6.3 (a)-(g)に検知率の分布を示す(なお、被験者別の検知率は巻末付録に記載)。図 6.3 (a) に分布の見方を示す。箱ひげ

図は、検知率の最小値、第一四分位数 (25%タイル値)、中央値、平均値、第三四分位数 (75%タイル値)、最大値を表している。平均値は、そのシナリオでの全被験者の検知率の平均を意味する。最小値と最大値の差は、そのシナリオでの検知率のばらつきを表している。



(a) 箱ひげ図の見方

まず初めに、シナリオ1～シナリオ3の検証結果について述べる。進入時の運転の誤操作の検知率は、閾値を高くしてもほとんど現象しないことが明らかになった。また、シナリオ間の検知率に差がない事から、交差点部規模の違いが検知率に影響を及ぼさないことが確認された。

検知率のばらつきを見ると、シナリオ1は、閾値が高くなると被験者間の検知率にばらつきが生じているが、シナリオ2とシナリオ3は、ほとんど変化しないことが明らかになった。シナリオ1だけ低下する理由は、被験者によって、大規模交差点部で観測された学習用データと検証用データの特性が似ているからと考えられる。

次に、シナリオ4～シナリオ6の検証結果について述べる。曲る時の運転の誤操作の検知率は、シナリオ1～シナリオ3に比べて低いことが明らかになった。閾値が 1σ の時は、検知率は高いが閾値を高くすると、大きく減少することが確認された。なお、シナリオ間の検知率に差がない事から、交差点部規模の違いが検知率に影響を及ぼさないことが確認された。

検知率のばらつきを見ると、シナリオ4～シナリオ6では、閾値を高くすると、検知率のばらつきが大きくなることが確認された。この理由は、曲る時の運転の誤操作は、周りの運転者との違いが出にくいからと考えられる。したがって、曲る時の運転の誤操作の異常運転検知は、個人間検知の結果だけから判断するべきではないことが示唆された。

以上を踏まえると、個人間検知は、進入時の運転の誤操作は高い精度で検知できるが、曲る時の運転の誤操作は、構築した手法の適用限界があることが明らかになった。特に、中規模な交差点部では、異常運転を検知できる運転者と検知できない運転者の差が大きいことが明らかになった。

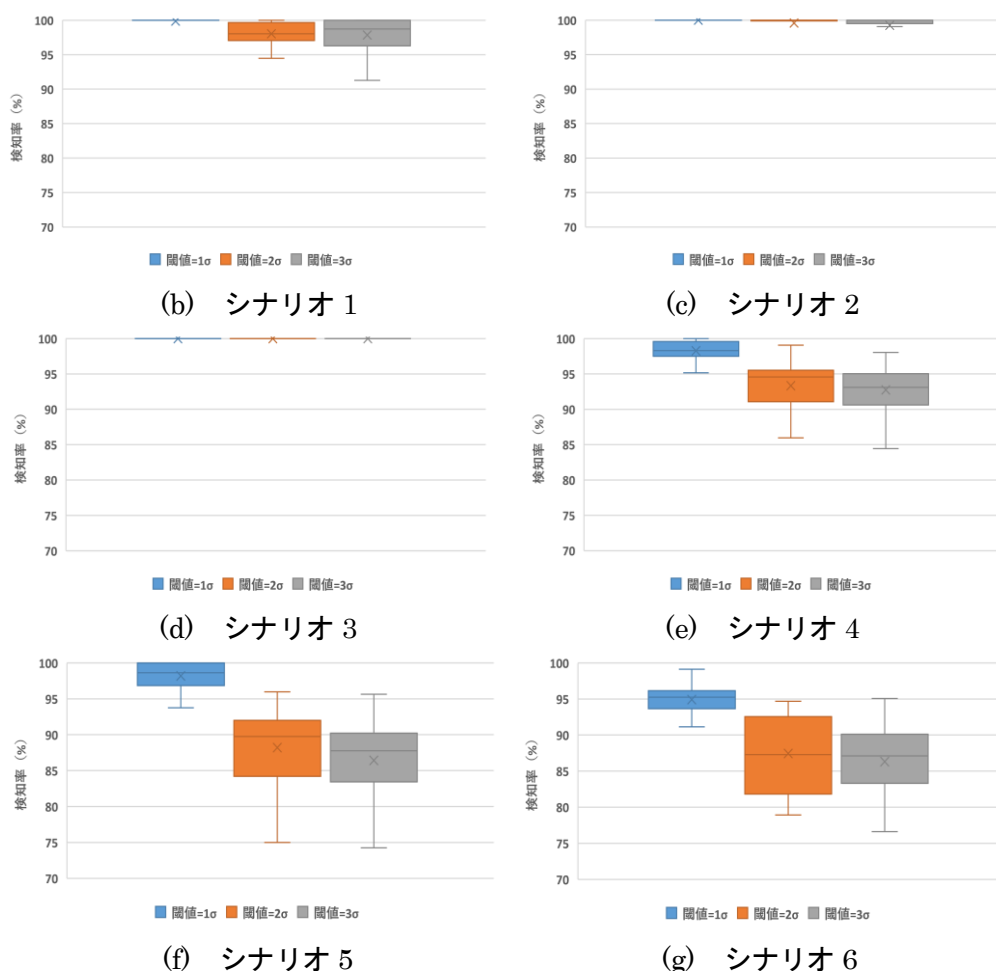


図 6.3 個人間検知の検知率の分布

6.3.2 運転者特定の有無が検知率に及ぼす影響

ここでは運転者特定の有無が個人間検知の検知率に及ぼす影響について明らかにする。一台の車を二人で利用している ID1~ID10 の被験者を対象に、個々の運転者ごとに正常な走行挙動モデルを作成（以下、本項では運転者モデルと呼ぶ）して個人間検知を行った場合と、夫婦で共用している車両から正常な走行挙動モデルを作成（以下、本項では車両モデルと呼ぶ）して個人間検知を行った場合の検知率を比較する。

表 6.3 (a)-(f) に比較した結果を示す。まず、シナリオ 1~シナリオ 3 の検証結果について述べる。閾値が 1σ の時は、運転者モデルと車両モデルの検知率の差は 1% 程度しか変わらないことが明らかになった。

しかしながら、閾値を高くすると、5% 程度にまで広がることを確認された。このことから、進入時の運転の誤操作に対して個人間検知を行う時は、個々の運転者ごとに正常な走行挙動モデルを作成すべき事が明らかになった。

次に、シナリオ 4~シナリオ 6 の検証結果について述べる。シナリオ 1~シナリオ 3 と概ね似た傾向をしているおり、運転者モデルと車両モデルの検知率の差は、5% 程度になることが明らかになった。このことから、曲る時の運転の誤操作に対して個人間検知を行う時は、個々の運転者ごとに正常な走行挙動モデルを作成すべき事が明らかになった。

以上を踏まえると、個々の運転者ごとに正常な走行挙動モデルを作成して個人間検知を行うことは、異常運転検知の検知率の向上に寄与することが明らかになった。したがって、事後検知を行う際は、運転者が特定された状態で個人間検知を行うべきことが示唆された。

表 6.3 運転者特定をした時としなかった時の検知率の比較

(a) シナリオ 1

車両	ID/ 閾値	検知率 (%)					
		運転者ごとに モデルを作成した時			車両ごとに モデルを作成した時		
		1 σ	2 σ	3 σ	1 σ	2 σ	3 σ
車両1	ID1	100	99.53	99.53	99.46	96.32	93.12
	ID2	100	98.01	97.35			
車両2	ID3	100	98.89	97.22	99.12	95.36	93.44
	ID4	100	98.89	97.22			
車両3	ID5	100	99.49	98.48	98.63	96.33	94.11
	ID6	99.35	98.71	98.06			
車両4	ID7	100	96.17	94.47	99.22	94.76	91.23
	ID8	100	99.18	98.97			
車両5	ID9	100	98.89	97.22	98.89	94.58	92.55
	ID10	100	98.57	97.14			

(b) シナリオ 2

車両	ID/ 閾値	検知率 (%)					
		運転者ごとに モデルを作成した時			車両ごとに モデルを作成した時		
		1 σ	2 σ	3 σ	1 σ	2 σ	3 σ
車両1	ID1	100	100	100	99.49	97.32	85.44
	ID2	100	100	90.91			
車両2	ID3	100	100	100	99.13	98.22	96.45
	ID4	100	100	100			
車両3	ID5	100	100	100	99.37	97.49	95.69
	ID6	100	100	100			
車両4	ID7	100	100	100	98.88	96.23	94.88
	ID8	100	100	100			
車両5	ID9	100	100	100	99.46	97.23	95.11
	ID10	100	100	100			

(c) シナリオ 3

車両	ID/ 閾値	検知率 (%)					
		運転者ごとに モデルを作成した時			車両ごとに モデルを作成した時		
		1 σ	2 σ	3 σ	1 σ	2 σ	3 σ
車両1	ID1	100	100	100	99.43	97.52	95.14
	ID2	100	100	100			
車両2	ID3	100	100	100	99.03	97.82	95.35
	ID4	100	100	100			
車両3	ID5	100	100	100	98.67	96.29	94.39
	ID6	100	100	100			
車両4	ID7	100	100	100	98.58	96.33	93.42
	ID8	100	100	100			
車両5	ID9	100	100	100	99.42	96.14	95.82
	ID10	100	100	100			

(d) シナリオ 4

車両	ID/ 閾値	検知率 (%)					
		運転者ごとに モデルを作成した時			車両ごとに モデルを作成した時		
		1 σ	2 σ	3 σ	1 σ	2 σ	3 σ
車両1	ID1	100	96.91	96.29	94.31	92.12	90.47
	ID2	94.7	97.68	94.37			
車両2	ID3	100	94.56	93.54	98.63	93.12	91.87
	ID4	100	94.56	93.54			
車両3	ID5	99.57	95.24	95.24	98.03	94.69	93.24
	ID6	98.05	98.05	94.92			
車両4	ID7	96.3	93.52	90.12	95.02	92.46	89.77
	ID8	99.65	97.15	95.6			
車両5	ID9	100	94.56	93.54	95.11	91.35	82.88
	ID10	95.56	93.33	84.44			

(e) シナリオ 5

車両	ID/ 閾値	検知率 (%)					
		運転者ごとに モデルを作成した時			車両ごとに モデルを作成した時		
		1 σ	2 σ	3 σ	1 σ	2 σ	3 σ
車両1	ID1	100	95.96	94.44	97.64	91.1	87.55
	ID2	98.36	91.95	88.48			
車両2	ID3	96.84	91.77	90.51	95.37	88.28	88.33
	ID4	96.84	89.87	89.24			
車両3	ID5	98.36	95.63	90.71	97.58	93.46	89.76
	ID6	99.29	94.29	92.14			
車両4	ID7	97.47	91.58	89	96.22	92.04	85.32
	ID8	99.1	92.79	85.59			
車両5	ID9	97.47	90.51	89.24	96.06	89.24	85.69
	ID10	100	95	90			

(f) シナリオ 6

車両	ID/ 閾値	検知率 (%)					
		運転者ごとに モデルを作成した時			車両ごとに モデルを作成した時		
		1 σ	2 σ	3 σ	1 σ	2 σ	3 σ
車両1	ID1	99.05	94.68	89.35	94.04	88.32	84.46
	ID2	95.39	89.63	85.88			
車両2	ID3	95.4	86.5	87.73	94.46	85.36	83.26
	ID4	96.01	91.41	86.2			
車両3	ID5	97.2	93.2	89.6	93.22	90.11	87.69
	ID6	94.27	93.51	89.31			
車両4	ID7	95.64	90.41	90.41	95.12	88.46	85.32
	ID8	98.27	94.81	93.24			
車両5	ID9	95.09	87.42	86.5	80.22	75.31	70.16
	ID10	85.96	78.95	73.16			

6.3.3 既往研究との精度比較

ここでは本研究で構築する手法と既往研究で行われた手法の検知率を比較する。本研究では、5.2.1の知見を踏まえ、同様のコンセプトで個人間検知ができる既往研究に着目する。そこで、Din et al.¹⁾が用いた Gaussian Mixture Model (GMM)、Zhang et al.²⁾が用いた Isolation Forests (IF)、Ngan et al.³⁾が用いた Local Outlier Factor (LOF) を適用して検知率を算出する。また、個人内検知の手法として構築した LSTM AE が個人間検知に有効かどうかの検討も行う。

図 6.4(a)-(f)に既往研究で行われた手法と検知率を比較した結果を示す。なお、ここでは全被験者の検知率の平均の結果を示す（被験者ごとの各手法の検知率は巻末付録に記載）。

まず、シナリオ 1～シナリオ 3 の検証結果について述べる。本研究で構築した OCSVM を用いた手法が、最も検知率が高くなることが明らかになった。閾値が 1 σ の時は、GMM、IF、LOF との検知率の差は、5%～10%程度であるが、閾値を 2 σ 、3 σ と高くすると、GMM、IF、LOF の検知率は、大きく減少することが確認された。

また、GMM, IF, LOF は、シナリオによって、検知率にばらつきがある事が明らかになった。例えば、IF はシナリオ 2 では、OCSVM と同等の検知率を有しているが、シナリオ 1 とシナリオ 3 では検知率が低いことが明らかになった。これは、異常運転と正常運転を判別する境界線の設定が、データの密度と距離から判断する OCSVM よりも困難になるからと考えられる。その結果、閾値を高くすると検知率が大きく減少すると考えられる。

なお、LSTM AE を用いた個人間検知は、他の手法と比べて著しく低い検知率になり、事後検知には適用できないことが明らかになった。このことから、他の運転者の走行挙動との乖離度合いから、進入時の運転の誤操作を検知する時は、交差点部で観測した各データの平均値と標準偏差の 2 つの観点から考えた方が良いことが明らかになった。

次に、シナリオ 4～シナリオ 6 の検証結果について述べる。シナリオ 1～シナリオ 3 の検証結果と概ね同等の結果となった。本研究で構築した OCSVM を用いた手法が、最も検知率が高くなることが明らかになった。閾値が 1σ の時は、GMM, IF, LOF との検知率の差は、5%～10%程度であるが、閾値を 2σ , 3σ と高くすると、検知率が大きく減少することが確認された。

なお、LSTM AE を用いた個人間検知は、他の手法と比べて著しく低い検知率になり、事後検知ができないことが明らかになった。このことから、他の運転者の走行挙動との乖離度合いから、曲る時の運転の誤操作を検知する時は、交差点部で観測した各データの平均値と標準偏差の 2 つの観点から検知を行う方がよいことが明らかになった。

以上を踏まえると、本研究で構築した OCSVM を用いた個人間検知は、他の運転者の走行挙動との乖離度合いから異常度を定義する方法において、最も高い精度で異常運転の検知ができることを示した。

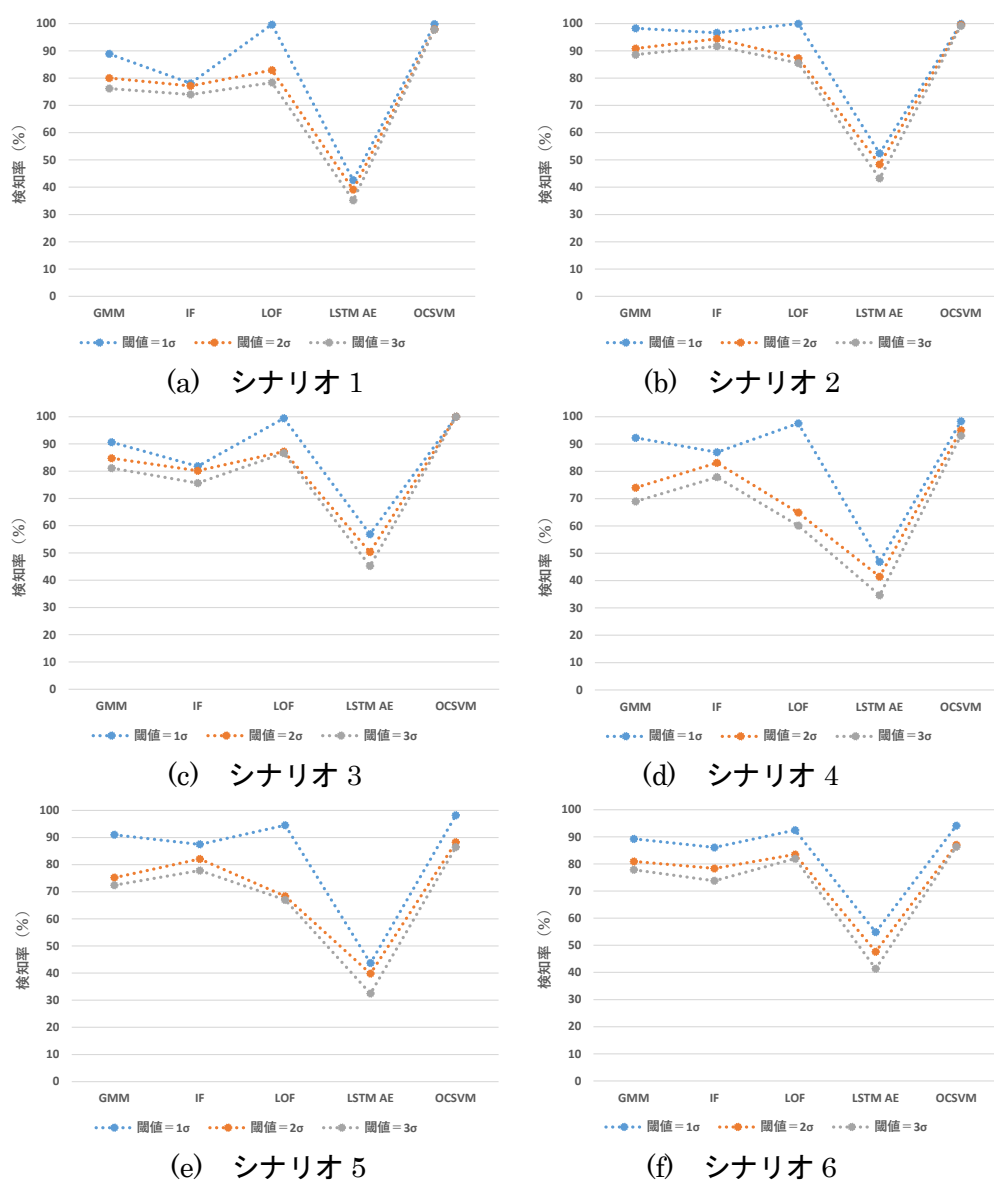


図 6.4 既往研究で行われた手法との検知率の比較

6.3.4 異常運転検知に有効なデータの検討

ここでは個人間検知で異常運転が発生したと判断された時に、閾値を越えたデータについて述べる。本研究で構築した個人間検知は、観測機器から直接出力される車両速度、三軸成分の加速度、操舵角に加え、合成加速度、三軸成分の躍度、合成躍度、操舵角速度の計 11 のデータから平均値と標準偏差を特徴量として設定した。

計 11 のデータの中で、閾値を超えて異常運転として検知されているかを把握することは、構築した手法の性能向上をする上でも重要である。どのデータを観測しておけば異常運転検知ができると把握できるからである。また、そのデータが観測できるセンサーの性能を向上させておけば、より高い精度で検知できる可能性につながる。

そこで、事後検知が行われた時に、どのデータが異常運転として検知されたのかを集計する。本研究では、検知割合という評価指標で集計を行う。一例として、車両速度から検知割

合を算出する場合は、以下の(6.2)式で算出する。なお、算出される検知割合が大きいほど、そのシナリオにおいて異常運転検知に重要なデータであることを意味する。

$$\text{車両速度の検知割合(\%)} = \frac{C}{C+D} \times 100 \quad (6.2)$$

C：検証用データに対し異常運転であると判定した数、かつ車両速度データが閾値を越えていた検証用データの数

D：検証用データに対し異常運転であると判定した数、かつ車両速度データが閾値を越えていなかった検証用データの数

図 6.5 (a)-(f)に各データの検知割合の結果を示す。なお、ここでは全被験者の検知割合の平均の結果を示す(被験者ごとの各データの検知割合は巻末付録に記載)。まず、シナリオ 1～シナリオ 3 の検証結果について述べる。

進入時の運転の誤操作が発生した時は、車両速度、Y 軸成分の加速度、合成加速度が検知されていることが明らかになった。進入時の運転の誤操作は、アクセル・ブレーキペダルが原因で発生することが多いと考えられる。設定した計 11 のデータの内、アクセル・ブレーキペダルの影響が観測されやすいデータは、車両速度、Y 軸成分の加速度、合成加速度であり、検知割合の結果も妥当であると考えられる。

なお、閾値を高くすると、車両速度、Y 軸成分の加速度、合成加速度のデータ以外の検知割合は、減少することが明らかになった。したがって、進入時の運転の誤操作を個人間検知する場合は、車両速度、Y 軸成分の加速度、合成加速度のデータを観測しておけばよいことが示された。

次に、シナリオ 4～シナリオ 6 の検証結果について述べる。曲る時の運転の誤操作が発生した時は、X 軸成分の加速度、操舵角速度が検知されていることが明らかになった。曲る時の運転の誤操作は、ハンドル操作が原因で発生することが多いと考えられる。本研究で設定した 11 のデータの内、ハンドル操作の影響が観測される特徴量は、X 軸成分の加速度、操舵角速度であり、検知割合の結果も妥当であると考えられる。

なお、閾値を高くすると、X 軸成分の加速度、操舵角速度のデータ以外の検知割合は、減少することが明らかになった。したがって、曲る時の運転の誤操作を個人間検知する場合は、X 軸成分の加速度、操舵角速度のデータを観測しておけばよいことが示された。

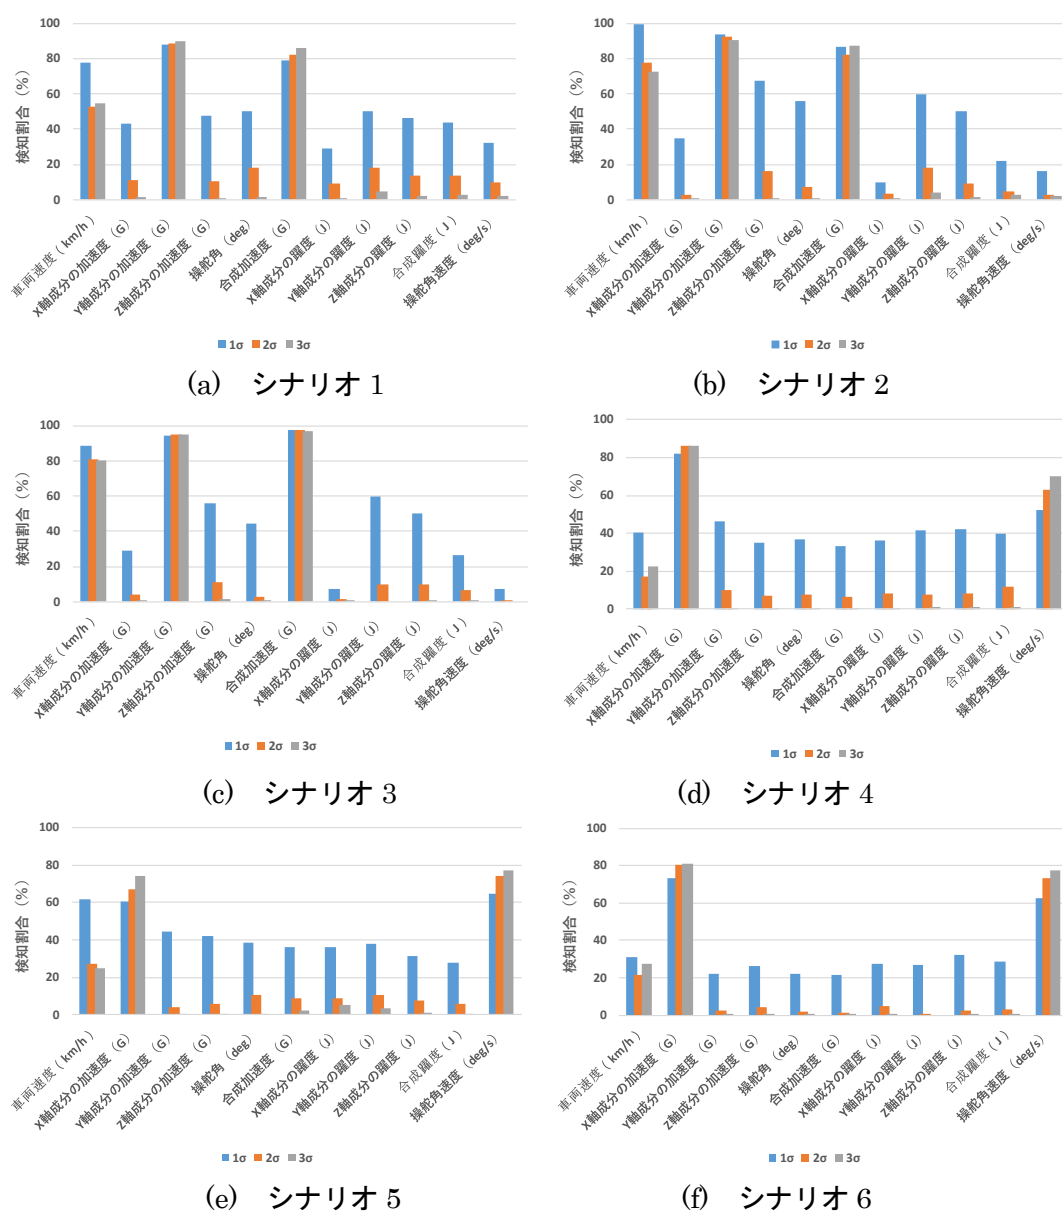


図 6.5 個人間検知における有効なデータ

6.4 個人内異常運転検知の性能評価

6.4.1 LSTM AE の設定条件

ここでは LSTM AE の設定条件について述べる。事後検知の場合、事前の設定条件は検知率に影響を及ぼす。なお、ここで検討する設定条件は、中間層 (LSTM 層) の数および中間層のニューロンの数である。

本研究では、中間層の数および中間層のニューロンの数を変えたモデルを作成し、走行挙動に適用した際の最適な設定条件について検討する。表 6.4 (a) に LSTM AE のモデルの概要を示す。本研究では、既往研究^{4), 5)}の知見を踏まえて、中間層の数とユニットの数を変えたモデル 1~モデル 10 を作成した。

モデル1～モデル6は、中間層の数は1、中間層のニューロンの数は、入力データ長の1/8倍、1/4倍、1/2倍、2倍、4倍、8倍とした。モデル7とモデル8は、中間層の数は2、中間層のニューロンの数は、1層目が入力データ長の1/2倍、2倍、2層目が入力データ長の1/4倍、4倍とした。モデル9とモデル10は、中間層の数は3、中間層のニューロンの数は、1層目が入力データ長の1/2倍、2倍、2層目が入力データ長の1/4倍、4倍、3層目が入力データ長の1/8倍、8倍とした。

表 6.4 事後検知に用いる LSTM AE の設定条件
(a) モデルの概要

モデル	中間層の数	中間層のニューロンの数
モデルC1	1	入力データ長の1/8
モデルC2	1	入力データ長の1/4
モデルC3	1	入力データ長の1/2
モデルC4	1	入力データ長の2倍
モデルC5	1	入力データ長の4倍
モデルC6	1	入力データ長の8倍
モデルC7	2	入力データ長の2倍, 4倍
モデルC8	2	入力データ長の1/2, 1/4
モデルC9	3	入力データ長の2倍, 4倍, 8倍
モデルC10	3	入力データ長の1/2, 1/4, 1/8

次に、表 6.4 (b)に各モデル共通の設定条件について述べる。なお、これらの設定は、既往研究^{4),5)}の知見を踏まえて決定した。ここでは走行挙動の処理の流れも併せて述べる。まず、エンコーダーで行う分析の流れについて述べる。走行挙動は、それぞれのデータの値が0から1の範囲になるように正規化を行う。

正規化により、大きい値の特徴量と小さい値の特徴量の範囲を揃え、上手く学習できない現象を防ぐ。LSTMの損失関数は、 \tanh 関数（双曲線正接関数）とする。この時、LSTM層の数およびニューロンの数はモデルによって異なる。次に、ドロップアウトを行う。ドロップアウトを行うことにより、過学習を防ぐことができる。

次に、デコーダーで行う分析の流れについて述べる。エンコーダーで行われたLSTM層による特徴抽出の復元が行われる。次に、ドロップアウトを行う。最後に、出力データとして入力データの復元がされる。以上がLSTM AEで行う流れと設定した条件である。

なお、最適化関数は、移動平均で振動を抑制するモーメンタムと学習率を調整して振動を抑制するRMSPropを組み合わせた関数であるAdamを用いる。損失関数は平均絶対誤差で評価するmaeを用いる。正常な走行挙動モデル作成時の学習方法について述べる。バッチ数は8、エポック数は1000とする。過学習を防ぐ為にEarly stoppingを用いる。

(b) 各モデル共通の設定条件

最適化アルゴリズム	Adam
損失関数	mae
ドロップアウト率	0.2
活性化関数	\tanh 関数
バッチサイズ	8
エポック数	1000
打ち切り条件	Val loss = 0

6.4.2 検知率の検証結果

ここでは個人内検知の検知率の検証結果について述べる。まず、事後検知を行う時の最適

な LSTM AE の設定条件の検討結果について述べる。図 6.6(a)-(f)にモデルごとの検知率の結果を示す。なお、ここでは全被験者の検知率の平均の結果を示す。結論として、最も検知率が高くなるのはモデル C 4 (LSTM 層が 1 つ、LSTM 層のニューロンの数が入力データ長の 2 倍) という結果になった。

中間層と検知率の関係性について述べる。LSTM 層の数を 2 つ以上にしたモデル C 7 からモデル C 10 の検知率は、LSTM 層が一つのモデルに比べて検知率が減少することが明らかになった。このことから、走行挙動から LSTM AE を用いて運転者の正常な走行挙動モデルを作成する際は、中間層の数は 1 層で十分であることが示された。

中間層のニューロンの数と検知率の関係性について述べる。LSTM 層が一つでも、ニューロンの数が入力データ長よりも短いモデル C 1 からモデル C 3 は、検知率の減少につながる事が明らかになった。これは、ニューロンの数が入力したデータ長よりも短いと、正常な走行挙動モデルが十分な設定ができない為と考えられる。

また、極端に長いモデル C 6 も検知率の減少につながる可能性が示された。なお、閾値が 1σ の時はモデル間の検知率の差は生じなかったが、 2σ 、 3σ と閾値を変えると、モデル間の検知率の差が大きくなる事が確認された。よって以後の本章の分析ではモデル C 4 を使用する。

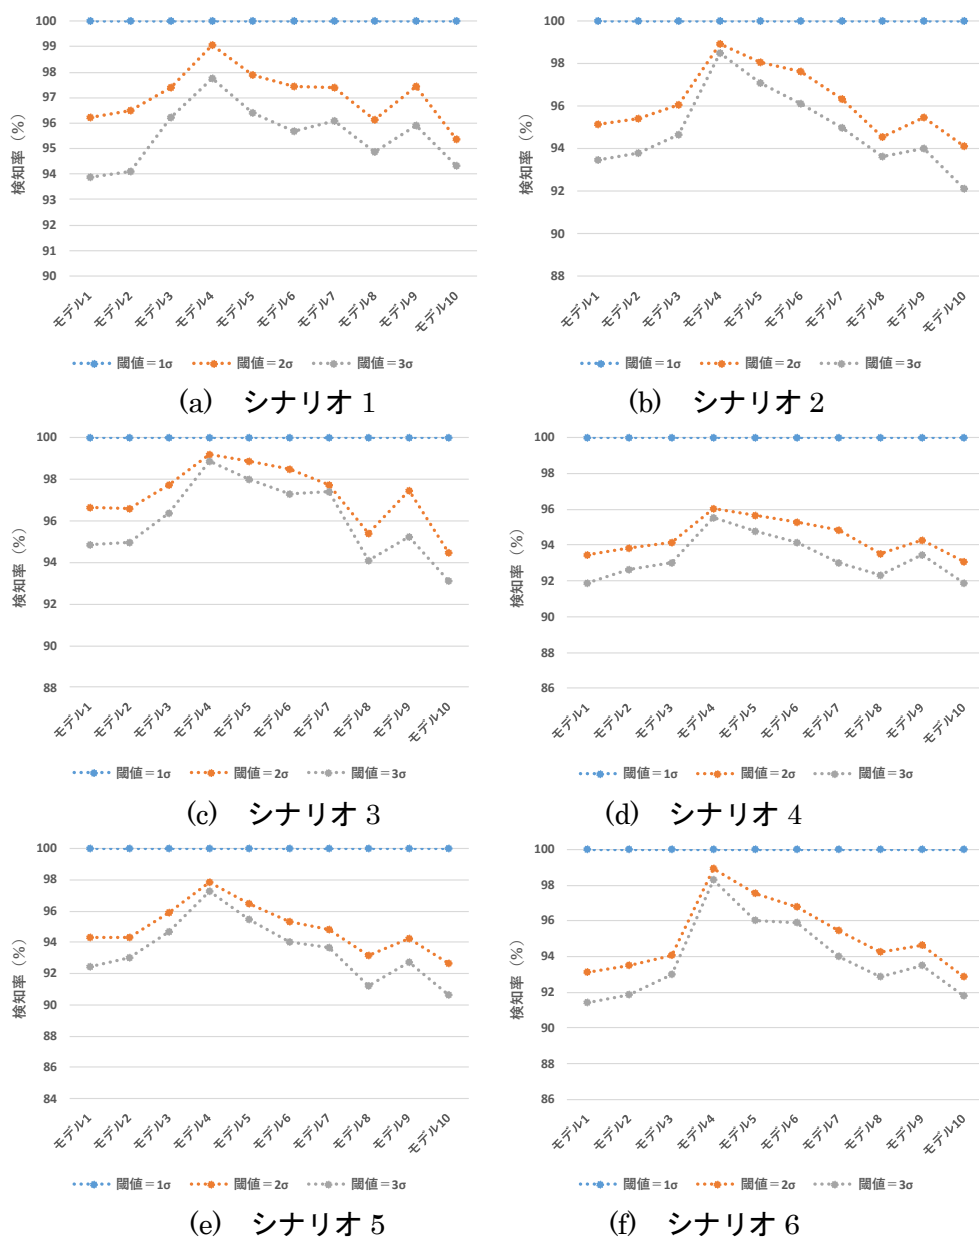


図 6.6 モデル別の検知率の結果

シナリオごとの検知率の考察を述べる．図 6.7(a)-(f)に検知率の分布を示す（被験者別の検知率は巻末付録に記載）．まず，シナリオ 1～シナリオ 3 の検証結果について述べる．進入時の運転の誤操作による検知率は，閾値を高くすると，若干減少する傾向にあることが明らかになった．

なお，シナリオ 1～シナリオ 3 の検知率に差がないことから，交差点部規模の違いが検知率に影響を及ぼさないことが確認された．運転者間の検知率のばらつきを見ると，シナリオ 1～シナリオ 3 の全てのシナリオで，閾値を高くすると，検知率は若干大きくなることが確認された．

次に，シナリオ 4～シナリオ 6 の検証結果について述べる．曲る時の運転の誤操作による検知率は，シナリオ 1～シナリオ 3 と概ね同等の結果であることが明らかになった．閾値を

高くすると、検知率は若干減少する傾向にあることが確認された。

なお、シナリオ4～シナリオ6の検知率に差がないことから、交差点部の規模の違いが検知率に影響を及ぼしている可能性はないことが示唆された。運転者間の検知率のばらつきを見ると、シナリオ1～3と概ね同等のばらつきであることが明らかになった。

以上を踏まえると、本研究で構築した個人内検知は、進入時の運転の誤操作および曲る時の運転の誤操作は、どちらも高い精度で検知できることを示した。

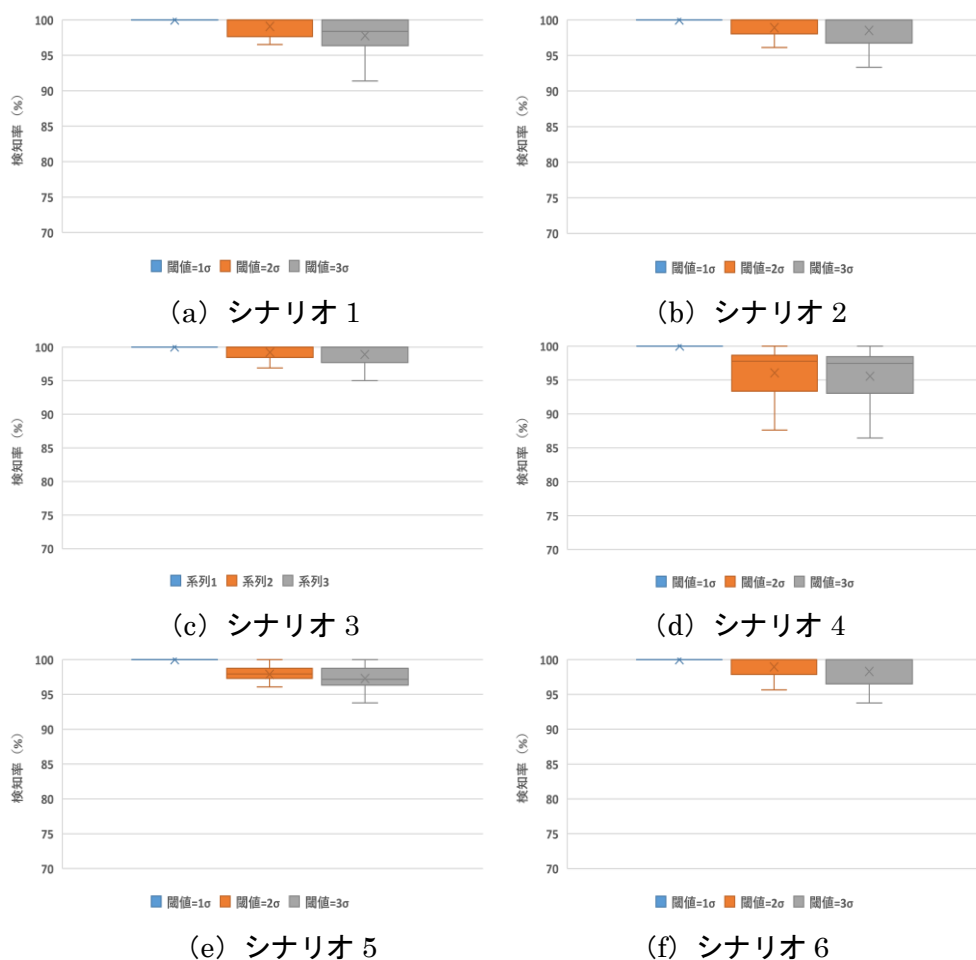


図 6.7 個人内検知の検知率の分布

6.4.3 運転者特定の有無が検知率に及ぼす影響

ここでは運転者の特定の有無が個人内検知の検知率に及ぼす影響について明らかにする。6.3.2と同様に、一台の車を二人で利用しているID1～ID10の被験者を対象に、個々の運転者ごとに正常な走行挙動モデルを作成（以下、本項では運転者モデルと呼ぶ）して個人内検知を行った場合と、夫婦で共用している車両から正常な走行挙動モデルを作成（以下、本項では車両モデルと呼ぶ）して個人内検知を行った場合の検知率を比較する。

図 6.8 (a)-(f)に検知率を比較した結果を示す。まず、シナリオ1～シナリオ3の検証結果について述べる。閾値が 1σ の時は、運転者モデルと車両モデルの検知率の差は1%～2%程度しか変わらないが、閾値を高くすると、その差は顕著になり、7%程度に広がることが確認された。このことから、進入時の運転の誤操作を個人内検知で検知する時は、運転者モ

デルで検知した方が良い事が明らかになった。

次に、シナリオ4～シナリオ6の検証結果について述べる。シナリオ1～シナリオ3と似た概ね傾向をしているが、運転者モデルと車両モデル時の検知率の差は大きいことが明らかになった。閾値を高くすると、10%程度に広がる事が確認された。このことから、曲る時の運転の誤操作を個人内検知で検知する時は、運転者モデルで検知した方が良い事が明らかになった。

なお、個人内検知は、個々の運転者の日々の走行挙動の変動度合いから異常度を定義する方法であり、他の運転者の走行挙動が含まれている状態だと、正常な走行挙動モデルの作成ができなくなると考えられる。その為、運転者モデルと車両モデルの検知率の差が大きくなると考えられる。

以上を踏まえると、個々の運転者ごとに正常な走行挙動モデルを作成して個人内検知を行うことは、異常運転検知の検知率の向上に寄与することが明らかになった。したがって、事後検知を行う際は、運転者が特定された状態で個人内検知を行うべきことが示唆された。

表 6.5 運転特定をした時としなかった時の検知率の比較
(a) シナリオ 1 (b) シナリオ 2

車両	ID/ 閾値	検知率 (%)					
		運転者ごとに モデルを作成した時			車両ごとに モデルを作成した時		
		1σ	2σ	3σ	1σ	2σ	3σ
車両1	ID1	100	98.58	97.42	99.04	93.26	91.72
	ID2	100	99.34	98.18			
車両2	ID3	100	97.46	89.12	98.63	94.11	86.37
	ID4	100	96.58	96.37			
車両3	ID5	100	97.64	97.43	97.82	93.24	90.46
	ID6	100	97.33	97.02			
車両4	ID7	100	96.51	96.35	98.52	91.67	89.41
	ID8	100	98.78	98.57			
車両5	ID9	100	100	99.79	97.24	95.28	92.36
	ID10	100	100	97.14			

車両	ID/ 閾値	検知率 (%)					
		運転者ごとに モデルを作成した時			車両ごとに モデルを作成した時		
		1σ	2σ	3σ	1σ	2σ	3σ
車両1	ID1	100	100	100	98.21	97.51	95.73
	ID2	100	100	100			
車両2	ID3	100	100	100	98.64	96.31	95.16
	ID4	100	100	100			
車両3	ID5	100	100	100	98.2	97.56	96.81
	ID6	100	100	100			
車両4	ID7	100	100	100	99.04	94.3	90.27
	ID8	100	96.13	94.97			
車両5	ID9	100	98.1	96.94	99.17	95.34	92.61
	ID10	100	100	100			

(c) シナリオ 3

(d) シナリオ 4

車両	ID/ 閾値	検知率 (%)					
		運転者ごとに モデルを作成した時			車両ごとに モデルを作成した時		
		1σ	2σ	3σ	1σ	2σ	3σ
車両1	ID1	100	100	100	97.28	94.63	92.51
	ID2	100	100	100			
車両2	ID3	100	96.88	96.88	98.76	95.83	93.47
	ID4	100	100	100			
車両3	ID5	100	100	100	99.11	97.49	95.26
	ID6	100	100	100			
車両4	ID7	100	95	95	98.87	94.28	92.12
	ID8	100	98.68	98.47			
車両5	ID9	100	97.46	97.15	98.66	94.74	93.34
	ID10	100	100	100			

車両	ID/ 閾値	検知率 (%)					
		運転者ごとに モデルを作成した時			車両ごとに モデルを作成した時		
		1σ	2σ	3σ	1σ	2σ	3σ
車両1	ID1	100	96.87	96.87	93.45	90.83	88.7
	ID2	100	91.45	90.29			
車両2	ID3	100	93.14	91.98	97.3	92.41	88.17
	ID4	100	100	100			
車両3	ID5	100	94.7	93.54	97.56	92.43	89.63
	ID6	100	95.12	93.96			
車両4	ID7	100	89.12	87.96	92.41	87.76	84.13
	ID8	100	97.65	97.44			
車両5	ID9	100	98.96	98.65	94.23	90.11	86.56
	ID10	100	93.35	92.19			

(e) シナリオ 5

(f) シナリオ 6

車両	ID/ 閾値	検知率 (%)					
		運転者ごとに モデルを作成した時			車両ごとに モデルを作成した時		
		1σ	2σ	3σ	1σ	2σ	3σ
車両1	ID1	100	98.97	98.97	96.86	92.14	88.64
	ID2	100	99.34	99.34			
車両2	ID3	100	97.89	96.98	95.72	90.36	87.41
	ID4	100	98.32	97.41			
車両3	ID5	100	96.31	94.75	96.51	93.92	88.16
	ID6	100	97.89	96.33			
車両4	ID7	100	98.47	98.26	95.48	90.56	87.63
	ID8	100	97.98	96.42			
車両5	ID9	100	100	100	95.06	91.22	88.72
	ID10	100	98.67	98.67			

車両	ID/ 閾値	検知率 (%)					
		運転者ごとに モデルを作成した時			車両ごとに モデルを作成した時		
		1σ	2σ	3σ	1σ	2σ	3σ
車両1	ID1	100	100	100	95.36	92.47	90.14
	ID2	100	100	100			
車両2	ID3	100	100	100	96.28	91.89	89.68
	ID4	100	100	100			
車両3	ID5	100	100	100	94.36	90.79	88.61
	ID6	100	100	100			
車両4	ID7	100	99.71	99.71	95.06	87.28	83.46
	ID8	100	97.63	96.32			
車両5	ID9	100	96.98	93.77	93.48	90.54	88.82
	ID10	100	100	100			

6.4.4 既往研究との精度比較

ここでは本研究で構築する手法と既往研究で行われた手法の検知率を比較する。本研究では、5.2.2の知見を踏まえ、同様のコンセプトで個人内検知ができる既往研究に着目する。そこで、Dairi et al.⁶⁾ が用いた Auto Encoder (AE), Eren et al.⁷⁾ が用いた Dynamic Time Warping (DTW), Matousek et al.⁸⁾ が用いた Long Short Term Memories (LSTM) と本

手法の比較を行う。また、個人内検知の手法として構築した OCSVM が個人内検知に有効かどうかの検討も行う。

表 6.6(a)-(f) に既往研究で行われた手法と検知率を比較した結果を示す。なお、ここでは全被験者の検知率の平均の結果を示す（被験者ごとの各手法の検知率は巻末付録に記載）。

まず、シナリオ 1～シナリオ 3 の検証結果について述べる。本研究で構築した LSTM AE を用いた手法が、最も検知率が高くなることが明らかになった。閾値が 1σ の時は、DTW, AE, LSTM との検知率の差は、シナリオ 3 を除いて、ほとんど生じないことが確認された。しかしながら、閾値を 2σ , 3σ と高くすると、DTW, AE, LSTM の検知率は、大きく減少することが確認された。

AE を用いた手法は、DTW や LSTM に比べて検知率が安定している傾向にあるが、日々の走行挙動の変動度合いから異常度を定義する個人内検知においては、LSTM と AE を組み合わせた本手法の方がよいことが明らかになった。

なお、OCSVM を用いた手法を個人内検知は、事後検知には適用できないことが明らかになった。このことから、運転者の日々の走行挙動の変動度合いから、進入時の運転の誤操作を検知する時は、走行挙動の軌跡（時系列の変位）から検知すべきことが明らかになった。

次に、シナリオ 4～シナリオ 6 の検証結果について述べる。シナリオ 1～シナリオ 3 と概ね同等の結果となった。本研究で構築した LSTM AE を用いた手法が、最も検知率が高くなることが明らかになった。閾値が 1σ の時は、DTW, AE, LSTM との検知率の差は、シナリオ 6 を除いて、生じないことが確認された。しかしながら、閾値を 2σ , 3σ と高くすると、DTW, AE, LSTM の検知率は、大きく減少することが確認された。特に、LSTM の検知率は、シナリオ間によってばらつきが大きいことが明らかになった。

なお、OCSVM を用いた手法を個人内検知は、異常運転の検知ができないことが明らかになった。このことから、運転者の日々の走行挙動の変動度合いから、曲る時の運転の誤操作を検知する時は、走行挙動の軌跡（時系列の変位）から検知すべきことが明らかになった。

以上を踏まえると、本研究で構築した LSTM AE を用いた個人内検知は、個々の運転者の日々の走行挙動の変動度合いから異常運転を定義する方法において、最も高い精度で異常運転の検知ができる可能性を示した。

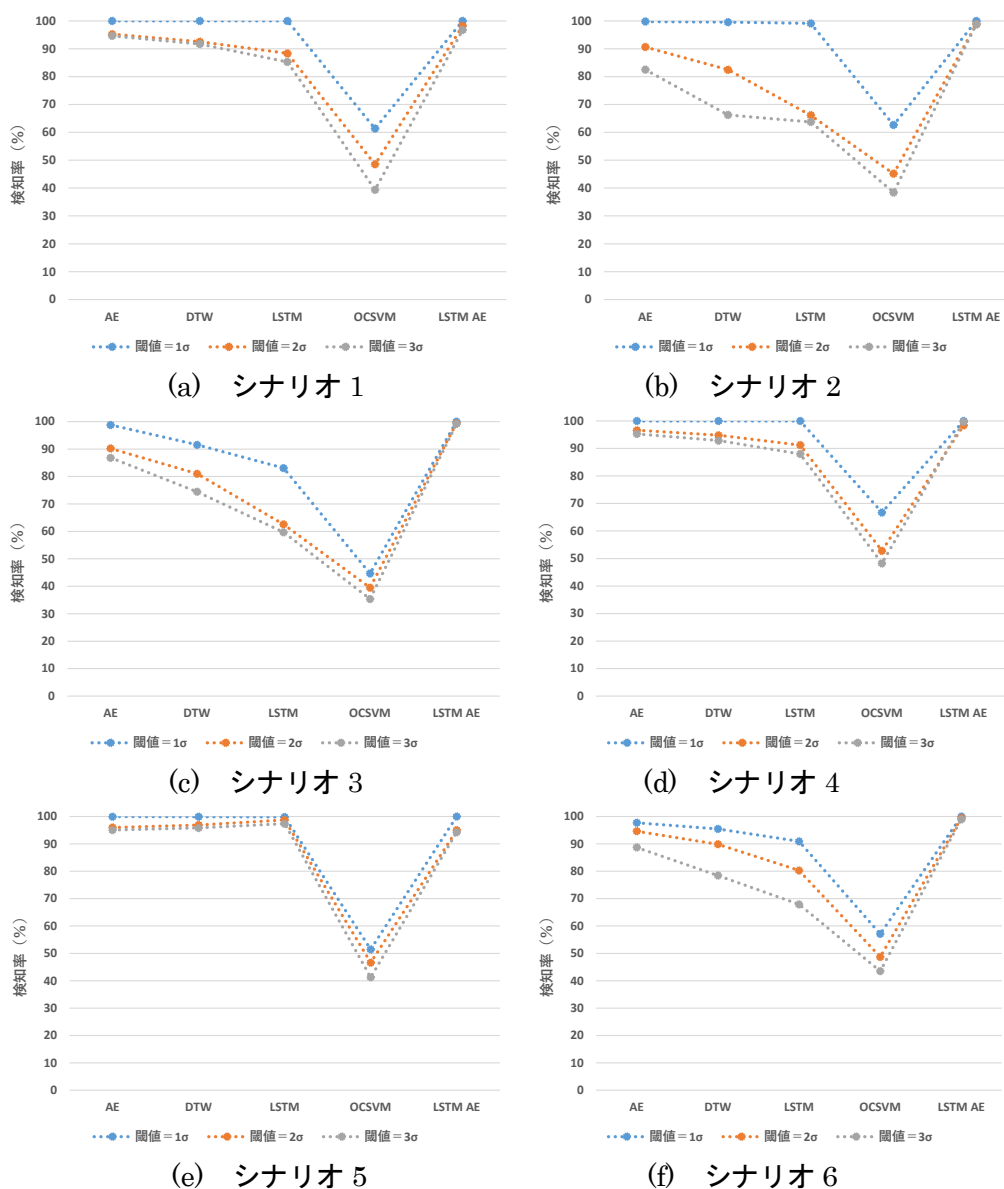


図 6.8 既往研究で行われた手法との検知率の比較

6.4.5 異常運転検知に有効なデータの検討

ここでは個人内検知で異常運転が発生したと判断された時に閾値を越えたデータについて述べる。本研究で構築した個人内検知は、観測機器から直接出力される車両速度、三軸成分の加速度、操舵角に加え、合成加速度、三軸成分の躍度、合成躍度、操舵角速度の計 11 のデータの軌跡（時系列変化）を用いて検知した。

6.3.4 と同様に、個人内検知による事後検知が行われた時の各データの検知割合を集計する。集計方法は (6.2) 式と同様なので、ここでは説明を割愛する。

図 6.9(a)-(f) に各データの検知割合の結果を示す。なお、ここでは全被験者の検知割合の平均の結果を示す（被験者ごとの各データの検知割合は巻末付録に記載）。まず、シナリオ 1～シナリオ 3 の検証結果について述べる。進入時の運転の誤操作が発生した時は、11 の

データの全てが異常運転として検知されていることが明らかになった。

この理由は、個人内検知は日々の走行挙動の変動度合いから異常度を定義するからである。日々の走行挙動の変動度合いは、特定のデータだけに反映せずに、11 のデータの全てが閾値を越えると考えられる。したがって、検知されているデータは妥当であると考えられる。なお、閾値を高くすると全てのデータの検知割合が若干、減少することが明らかになった。

次に、シナリオ 4～シナリオ 6 の検証結果について述べる。曲る時の運転の誤操作が発生した時は、シナリオ 1～シナリオ 3 と概ね同様の結果である。11 のデータの全てが異常運転として検知されていることが明らかになった。

この理由は、進入時の運転の誤操作が発生した時と同様であると考えられる。したがって、検知されているデータは妥当であると考えられる。なお、閾値を高くすると全てのデータの検知割合が若干、減少することが明らかになった。

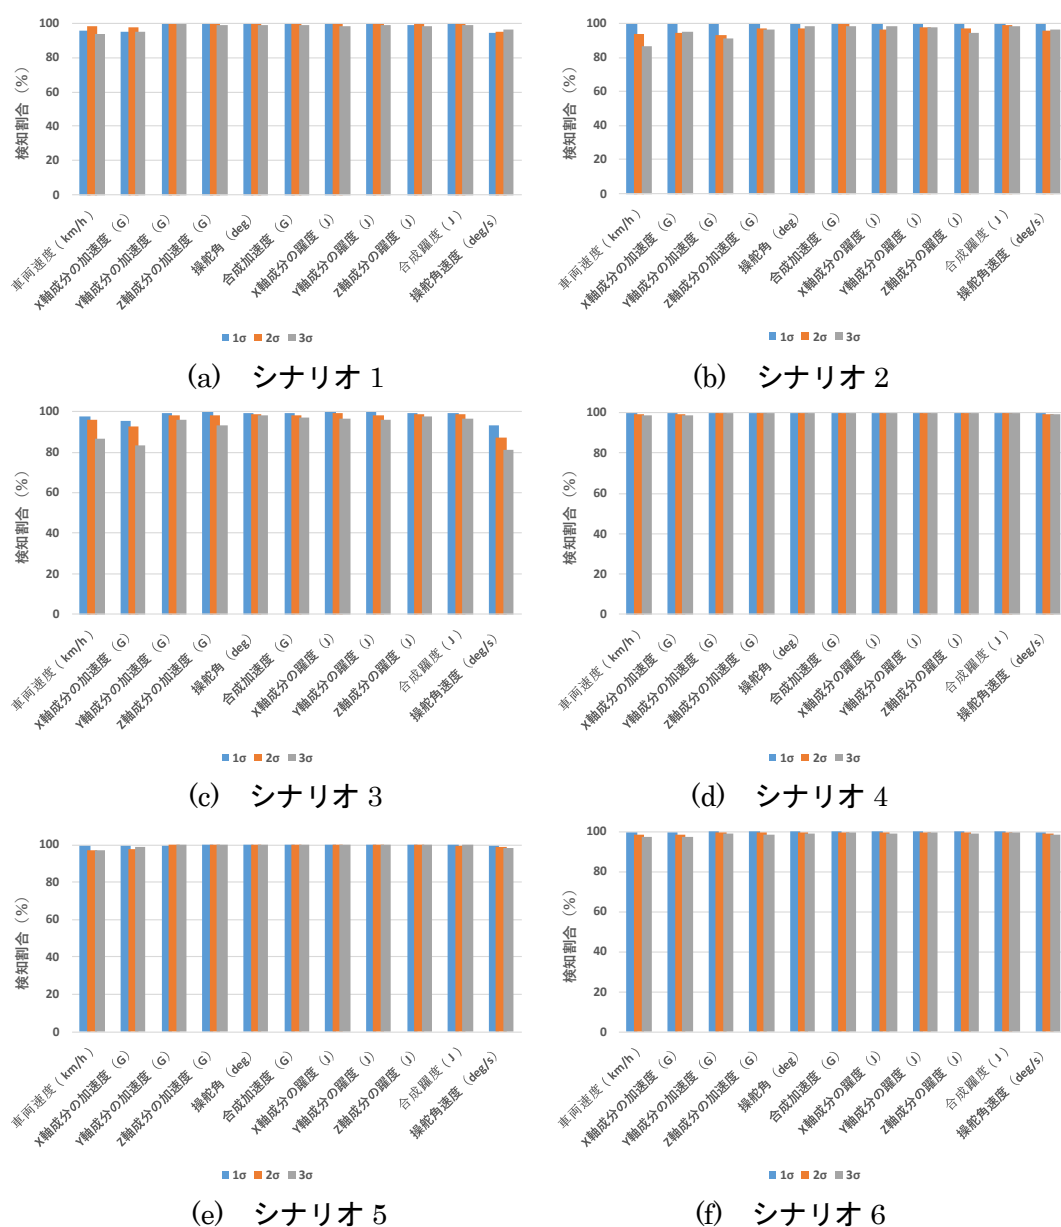


図 6.9 個人内検知における有効なデータ

6.5 本章のまとめ

本章では交差点部を通過した後に異常運転を検知する、事後検知による方法で構築した手法の性能評価の検証を行った。手法の検知率、運転者特定の有無が検知率に及ぼす影響、既往研究の手法との比較、有意な特徴量の検討を通して、手法の有効性を検証した。

性能評価の検証は 6 つのシナリオを設定した。まず、個人間異常運転検知の性能評価の検証結果について述べる。シナリオ 1～シナリオ 3 の検知率は、十分な検知率を有していることが明らかになった。被験者間の検知率のばらつきも小さく、どの運転者も有効に活用できる可能性を示唆した。一方で、シナリオ 4～シナリオ 6 の検知率は、低いことが明らかになった。また、被験者間の検知率のばらつきが大きいことが確認された。したがって、個人

間異常運転検知による、交差点を曲る時の運転の誤操作の事後検知は、適用限界があることが明らかになった。

次に、個人内異常運転検知の性能評価の検証結果について述べる。シナリオ1～シナリオ3およびシナリオ4～シナリオ6の検知率は、十分な検知率を有していることが明らかになった。被験者間の検知率のばらつきも小さく、どの運転者も有効に活用できる可能性を示唆した。したがって、個人内異常運転検知による、事後検知は有効であることが明らかになった。

個人間異常運転検知および個人内異常運転検知は、運転者ごとに正常な走行挙動モデルをした方が検知率は高いことが明らかになった。このことから、個々の運転者が特定された事後検知を行う有効性が示された。

なお、個人間異常運転検知および個人内異常運転検知を既往研究の手法と検知率を比較した結果、本手法の検知率が高いことが明らかになった。このことから、交差点部の走行挙動を用いた異常運転検知は、OCSVMとLSTM AEが有意である可能性が示された。

第7章 リアルタイム検知による性能評価の検証

7.1 概要

本章では、リアルタイム検知による性能評価の検証を行う。リアルタイム検知は、車両が交差点部に進入してから通過している段階で異常運転を判断する。1.2でも述べたように、リアルタイム検知の結果は、車両が事故を防ぐための適切な対処を行うことが可能で、異常運転が発生した段階で素早く検知する必要がある。そこで、構築した手法の検知タイミング、運転者特定の有無が及ぼす検知タイミングへの影響、既往研究の手法との比較、リアルタイム検知に有効なデータを手法の性能評価を通して明らかにする。さらに、二つの手法を実装した時にどのような効果をもたらすのか検討する。

以上を踏まえ、本章の流れについて述べる。7.2では、異常運転が発生したシナリオの概要、部分時系列の概要、検知タイミングの算出方法について述べる。7.3では、個人間異常運転検知（以下、本章では個人間検知と呼ぶ）の性能評価の検証を行う。7.4では、個人内異常運転検知（以下、本章では個人内検知と呼ぶ）の性能評価の検証を行う。7.5では、構築した二つの手法がもたらす効果について考える。

7.2 リアルタイム検知による性能評価の方法

7.2.1 シナリオの設定および部分時系列の概要

ここでは異常運転の発生を想定したシナリオおよび部分時系列の概要について述べる。まず、シナリオの設定について述べる。本章では6章と同様のシナリオで手法の性能評価を行う。表7.1に設定したシナリオを示す。シナリオ1～シナリオ3は、運転者が交差点部へ進入する時に起こる誤操作（以下、本章では進入時の運転の誤操作と呼ぶ）が発生した時を異常運転として検知する。シナリオ4～シナリオ6は、運転者が交差点部を曲がる時に起こる誤操作（以下、本章では曲る時の運転の誤操作と呼ぶ）が発生した時を異常運転として検知する。

表 7.1 表 6.1 の再掲

シナリオ	学習用データ				検証用データ			
	ケース	発進方法	進行方向	交差点規模	ケース	発進方法	進行方向	交差点規模
シナリオ1	Case4-Case6	停車した状態から通過	右左折直進	大規模交差点 (流入部の車線数が片側2車線以上)	Case1-Case3	停車せずに通過	右左折直進	大規模交差点 (流入部の車線数が片側2車線以上)
シナリオ2	Case28-Case30		右左折直進	中規模交差点 (流入部の車線数が片側1車線)	Case25-Case27		右左折直進	中規模交差点 (流入部の車線数が片側1車線)
シナリオ3	Case52-Case54		右左折直進	小規模交差点 (流入部の車線数が片側1車線)	Case49-Case51		右左折直進	小規模交差点 (流入部の車線数が片側1車線)
シナリオ4	Case49-Case51	停車せずに通過	右左折	小規模交差点 (流入部の車線数が片側1車線)	Case1-Case3	停車せずに通過	右左折	大規模交差点 (流入部の車線数が片側2車線以上)
シナリオ5	Case1-Case3		右左折	大規模交差点 (流入部の車線数が片側2車線以上)	Case25-Case27		右左折	中規模交差点 (流入部の車線数が片側1車線)
シナリオ6	Case25-Case27		右左折	中規模交差点 (流入部の車線数が片側1車線)	Case49-Case51		右左折	小規模交差点 (流入部の車線数が片側1車線)

次に、部分時系列の概要について述べる。異常運転の発生をリアルタイムで検知する為には、時々刻々と変化する走行挙動の変化に着目する必要がある。そこで、本研究では、走行挙動に部分時系列を適用する。

図 7.1 に部分時系列の概要を示す。図は、交差点部に進入した地点から通過するまでの走行挙動を示している。走行挙動には、計 11 のデータ（車両速度、三軸成分の加速度、操舵角、合成加速度、三軸成分の躍度、合成躍度、操舵角速度）を異常運転検知に使用している。部分時系列は、交差点部で観測した走行挙動データを細かく分類する方法である。本研究で使用した観測機器は、0.1s 間隔で計測しており、車両が交差点部を進入して通過するまでに 0.1s ずつ走行挙動が観測されている。そこで、車両が交差点部に進入してから、どのタイミング（時点）で異常運転を検知したか算出する。




図 7.1 部分時系列の概要

7.2.2 検知タイミングの算出方法

ここではリアルタイム検知の評価指標の算出方法について述べる。6章でも述べたように、既に異常運転と判断された走行挙動の収集が困難な点から、教師なし学習による異常運転検知を行う。その為、教師あり学習の時に用いる評価指標（精度、適合率、再現率、F 値）とは異なる方法で、構築した手法の妥当性を検証する必要がある。

そこで本章では、検知タイミングという評価指標を用いて、構築した手法の性能評価を行う。検知タイミングは (7.1) 式より算出する。検証用データに対し異常運転と判断した数と、異常運転と検知するまでにかかった時間を用いる。なお、検知タイミングは、交差点部に進入してからの経過時間を示している。したがって、検知タイミングの値が小さいほど、交差点部に進入してからすぐに検知できていることを意味する。

検証データによっては、交差点部を通過した後でも異常運転と判断できない場合もあることが考えられる。本研究では、このような場合の走行挙動の検知時間は、データ長（例えば、交差点部の走行挙動が 10 個の観測データから構成されている場合は、 10×0.1 で 1s となる）を検知時間として算出する。

$$\text{検知タイミング (s)} = \frac{\sum_{j=A'} T_j}{A'} \quad (7.1)$$

A' : 検証用データに対し、異常運転であると判定した数

T : 異常運転であると判定したデータにかかった検知時間

次に、検知タイミングの算出フローについて述べる。検知タイミングの算出フローは、個人間検知と個人内検知によって異なる。まず初めに、個人間検知の検知タイミングの算出フローを図7.2に示す。

(a) 個人間検知による検知タイミングの算出フロー

1. 異常運転を検知する運転者と検知タイミングを算出するシナリオを決定する。
2. 異常運転の可否を判断する運転者の走行挙動を検証用データ、その他の運転者の走行挙動を学習用データに設定する。
3. 学習用データにパラメータ α を設定し、異常・正常運転を判別する正常な走行挙動モデルを作成する。
4. 検証用データの中から一つ走行挙動を抽出し、3.で作成した正常な走行挙動モデルに適用する。この時のデータ長は、交差点部を進入した時点から2点観測した長さから開始する。
5. 4.で適用した走行挙動が正常運転の境界に含まれていれば、異常運転は発生していないと考える。反対に、走行挙動が異常運転の境界の方に含まれていれば、異常運転が発生していると考ええる。
6. 異常運転の検知ができた場合は、その時のデータ長 $\times 0.1$ (s) が、異常運転検知にかかった時間となる。
7. 異常運転の検知ができなかった場合は、走行挙動のデータ長を1つ増やして再度、異常運転検知を行う。これを検知ができるまで繰り返す。
8. 5.-7.を検証用データの数だけ行い、(7.1)式より検知タイミングを算出する。

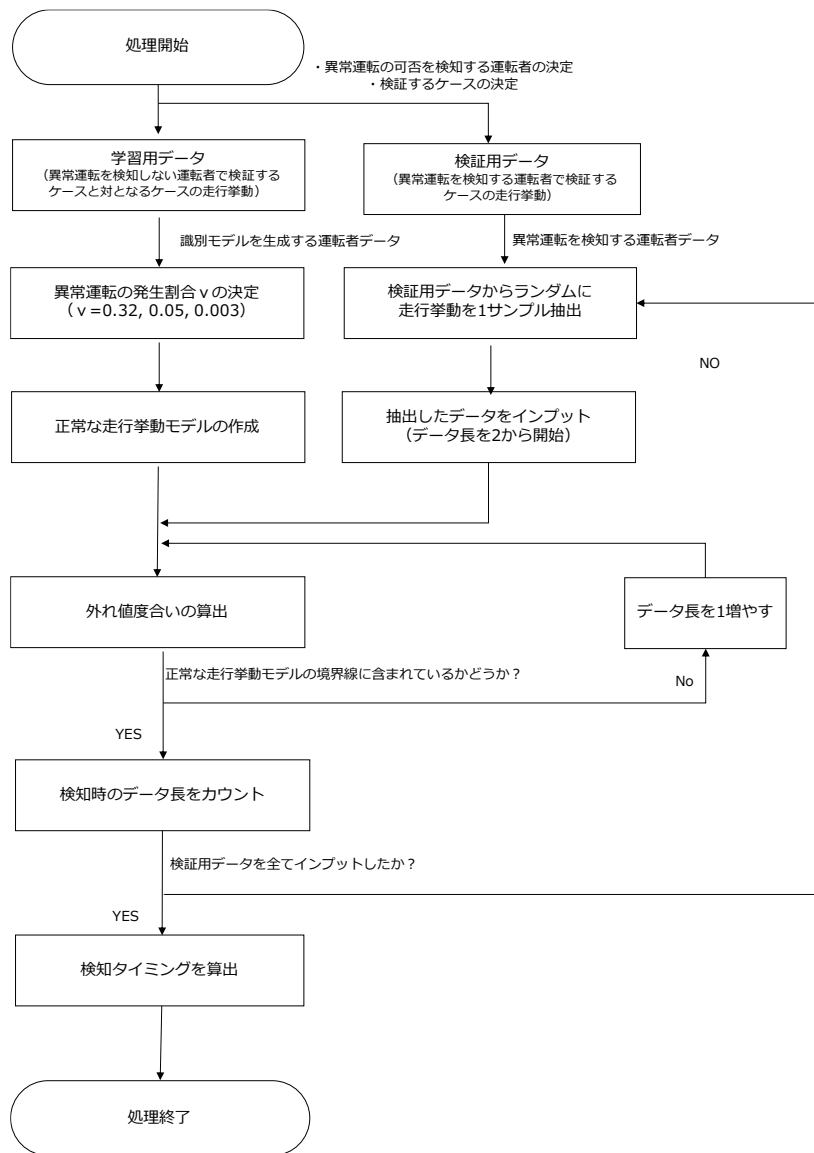


図 7.2 個人内検知による検知タイミングの算出フロー

次に、個人内検知の検知タイミングの算出フローを図 7.3 に示す。

(b) 個人内検知による検知タイミングの算出フロー

1. 異常運転を検知する運転者と検知タイミングを算出するシナリオを決定する。
2. 異常運転の可否を検知する走行挙動を検証用データ，正常な走行挙動モデルを作成する走行挙動を学習用データに分ける。
3. 学習用データに設定条件を適用して，正常な走行挙動モデルを作成する。
4. 検証用データの中から一つ走行挙動を抽出し，3.で作成した正常な走行挙動モデルに適用する。この時のデータ長は，交差点部を進入した時点から 2 点観測した長さから開始する。
5. 4.で適用した走行挙動から算出される再構成誤差が，閾値を越えていない場合は，異常運転は発生していないと考える。反対に，閾値を越えている場合は，異常運転が発生し

ていると考える。

6. 異常運転の検知ができた場合は、その時のデータ長×0.1 (s) が、異常運転検知にかかった時間となる。
7. 異常運転の検知ができなかった場合は、走行挙動のデータ長を 1 つ増やして再度、異常運転検知を行う。これを検知ができるまで繰り返す。
8. 5.-7.を検証用データの数だけ行い、(7.1) 式より検知タイミングを算出する。

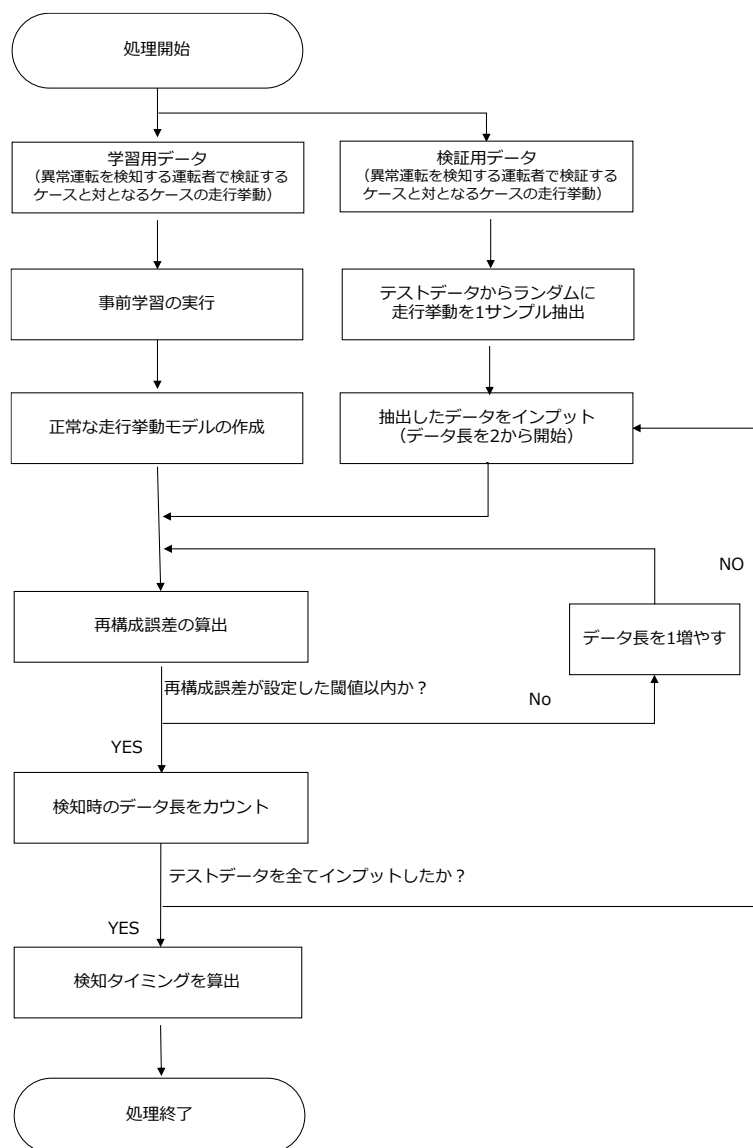
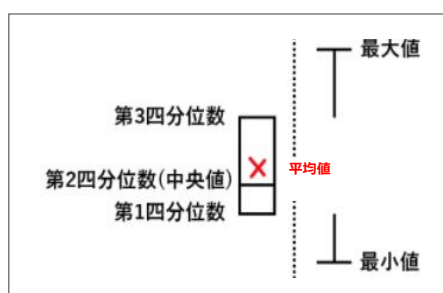


図 7.3 個人内検知による検知タイミングの算出フロー

7.3 個人間異常運転検知の性能評価

7.3.1 検知タイミングの検証結果

ここでは個人間検知の検知タイミングの検証結果について述べる。図 7.4 (a)-(g)に検知タイミングの分布を示す（なお、被験者別の検知タイミングは巻末付録に記載）。図 7.4 (a)に分布の見方を示す。箱ひげ図は、検知タイミングの最小値、第一四分位数（25%タイル値）、中央値、平均値、第三四分位数（75%タイル値）、最大値を表している。平均値は、そのシナリオでの全被験者の検知タイミングの平均を意味する。最小値と最大値の幅は、そのシナリオでの検知タイミングのばらつきを表している。



(a) 箱ひげ図の見方

シナリオ 1～シナリオ 3 の検証結果について述べる。進入時の運転の誤操作の検知タイミングは、閾値を高くすると、0.1s から 0.3s 程度遅くなることが明らかになった。シナリオ 1 が検知にかかる時間が最も長く、シナリオ 3 が検知にかかる時間が最も短いという結果になった。これは、交差点部規模が大きいほど、検知タイミングが遅くなる為と考えられる。

検知タイミングのばらつきを見ると、シナリオ 1 検知タイミングは、ばらつきが大きくなっていることが明らかになった。シナリオ 1 のみ大きい理由は、被験者によっては、学習用データと検証用データの特性が似ている可能性が考えられる。

次に、シナリオ 4～シナリオ 6 の検証結果について述べる。曲る時の運転の誤操作の検知タイミングは、シナリオ 1～シナリオ 3 に比べて遅い傾向にあることが明らかになった。これは、曲る時の運転の誤操作なので、車両が交差点を曲り始めてから初めて、特異な特徴が検出されると考えられる。その為、異常運転と判断するまでに時間を要すると考えられる。また、閾値を高くすると、0.1s から 0.3s 程度検知タイミングが遅くなることが明らかになった。シナリオ 4 が検知にかかる時間が最も長く、シナリオ 6 が検知にかかる時間が最も短いという結果になった。これは、交差点部規模が大きいほど、検知タイミングが遅くなる為と考えられる。

検知タイミングのばらつきを見ると、シナリオ 5 は、検知タイミングのばらつきが大きくなっていることが明らかになった。シナリオ 5 のみ大きい理由は、被験者によっては、学習用データと検証用データの特性が似ている可能性が考えられる。

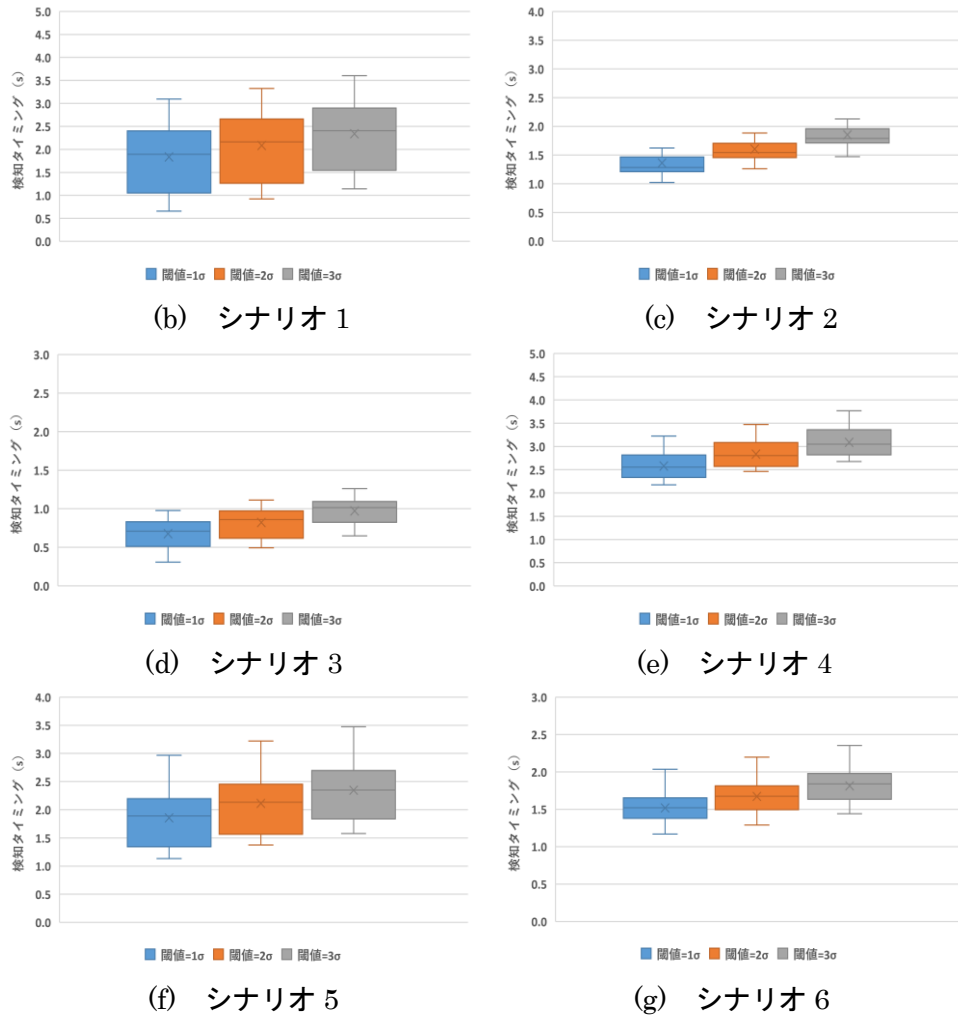


図 7.4 個人間異常運転検知の検知タイミングの分布

図 7.5 に異常運転の発生を検知した地点を可視化した結果を示す。ここでは、シナリオ 1 およびシナリオ 4 の大規模交差点部で異常運転が発生した時を一例に示す。シナリオ 1 の場合、交差点部に入直後に異常運転として検知できていることが明らかになった。一方、シナリオ 4 の場合、交差道路に入直する前に異常運転として検知できていることが明らかになった。

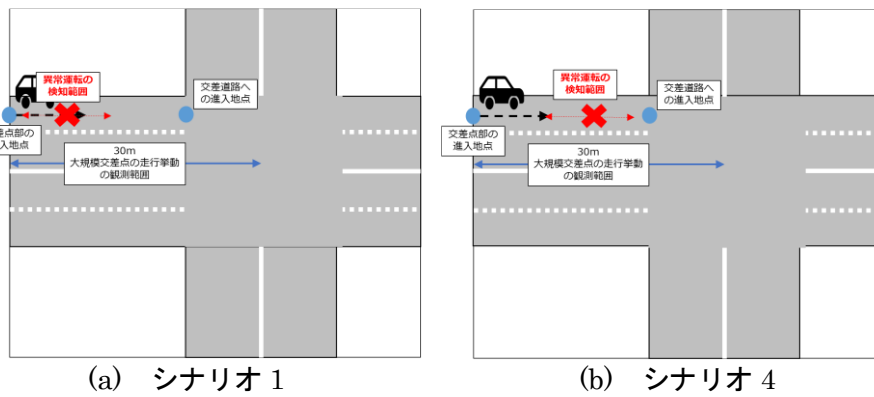


図 7.5 個人間異常運転検知による検知地点の可視化

7.3.2 運転者特定の有無が検知タイミングに及ぼす影響

ここでは運転者の特定の有無が個人間検知の検知タイミングに及ぼす影響について明らかにする。そこで、一台の車を二人で利用している ID1 から ID10 の被験者を対象に、個々の運転者ごとに正常な走行挙動モデルを作成（以下、本項では運転者モデルと呼ぶ）して個人間検知を行った場合と、夫婦で共用している車両から正常な走行挙動モデルを作成（以下、本項では車両モデルと呼ぶ）して個人間検知を行った場合の検知タイミングを比較する。

表 7.2 (a)-(f)に検知タイミングを比較した結果を示す。まず、シナリオ 1～シナリオ 3 の検証結果について述べる。閾値が 1σ の時は、運転者モデルと車両モデルの検知タイミングの差は、ほとんどないことが明らかになった。しかしながら、閾値を高くすると、0.1s から 0.3s 程度、検知タイミングが遅くなることが確認された。

このことから、進入時の運転の誤操作に対して個人間検知を行う時は、個々の運転者ごとに正常な走行挙動モデルを作成すべき事が明らかになった。なお、同一車両を使用している運転者の中でも、検知タイミングの値が大きく異なるのは、検知タイミングは、通過した交差点部の形状などに依存するからと考えられる。

次に、シナリオ 4～シナリオ 6 の検知タイミングを比較した結果の考察を述べる。シナリオ 1～シナリオ 3 の考察と概ね似た傾向をしているが、シナリオ 1～シナリオ 3 の時に比べて、検知タイミングの差は小さいことが明らかになった。なお、シナリオ 1～シナリオ 3 よりも検知タイミングの差が小さい理由は、ハンドルの誤操作を異常運転として検知する時は、周りの運転者に比べて大きな違いが出にくいからと考えられる。

以上を踏まえると、個々の運転者ごとに正常な走行挙動モデルを作成して個人間検知を行うことは、異常運転検知の検知タイミングの向上に寄与することが明らかになった。したがって、リアルタイム検知を行う際は、運転者が特定された状態で個人間検知を行うべきことが示唆された。

表 7.2 運転者特定をした時としなかった時の検知タイミングの比較
(a) シナリオ 1 (b) シナリオ 2

車両	ID/ 閾値	検知タイミング (s)					
		運転者ごとに モデルを作成した時			車両ごとに モデルを作成した時		
		1 σ	2 σ	3 σ	1 σ	2 σ	3 σ
車両1	ID1	0.9	1.2	1.4	1.0	1.3	1.7
	ID2	1.0	1.3	1.6			
車両2	ID3	1.1	1.3	1.5	1.1	1.3	1.6
	ID4	1.1	1.3	1.5			
車両3	ID5	1.0	1.2	1.5	1.0	1.3	1.5
	ID6	1.0	1.3	1.5			
車両4	ID7	1.0	1.2	1.4	1.0	1.2	1.4
	ID8	0.7	0.9	1.1			
車両5	ID9	1.1	1.3	1.6	1.7	2.0	2.6
	ID10	2.1	2.4	2.6			

車両	ID/ 閾値	検知タイミング (s)					
		運転者ごとに モデルを作成した時			車両ごとに モデルを作成した時		
		1 σ	2 σ	3 σ	1 σ	2 σ	3 σ
車両1	ID1	1.2	1.5	1.8	1.2	1.6	1.8
	ID2	1.2	1.4	1.7			
車両2	ID3	1.3	1.5	1.8	1.3	1.6	1.8
	ID4	1.3	1.6	1.8			
車両3	ID5	1.5	1.8	2.0	1.9	2.2	2.4
	ID6	1.9	2.2	2.4			
車両4	ID7	1.1	1.3	1.6	1.4	1.6	1.9
	ID8	1.4	1.6	1.9			
車両5	ID9	1.3	1.5	1.8	2.0	2.3	2.8
	ID10	2.4	2.6	2.8			

(c) シナリオ 3

車両	ID/ 閾値	検知タイミング (s)					
		運転者ごとに モデルを作成した時			車両ごとに モデルを作成した時		
		1 σ	2 σ	3 σ	1 σ	2 σ	3 σ
車両1	ID1	0.4	0.6	0.8	0.5	0.6	0.9
	ID2	0.5	0.6	0.8			
車両2	ID3	0.5	0.6	0.9	0.5	0.6	1.0
	ID4	0.5	0.7	0.8			
車両3	ID5	0.4	0.6	0.7	0.7	1.0	0.9
	ID6	0.7	0.9	0.9			
車両4	ID7	0.7	0.9	1.1	0.7	0.9	1.1
	ID8	0.5	0.6	0.7			
車両5	ID9	0.5	0.7	0.9	0.8	0.9	1.0
	ID10	0.8	0.9	1.0			

(d) シナリオ 4

車両	ID/ 閾値	検知タイミング (s)					
		運転者ごとに モデルを作成した時			車両ごとに モデルを作成した時		
		1 σ	2 σ	3 σ	1 σ	2 σ	3 σ
車両1	ID1	2.4	2.6	2.9	2.4	2.6	2.9
	ID2	2.3	2.5	2.8			
車両2	ID3	2.6	2.8	3.0	2.6	2.9	3.0
	ID4	2.6	2.8	3.0			
車両3	ID5	2.2	2.5	2.7	2.3	2.5	2.7
	ID6	2.2	2.5	2.7			
車両4	ID7	2.7	2.9	3.1	2.7	2.9	3.1
	ID8	2.3	2.5	2.7			
車両5	ID9	2.6	2.8	3.1	2.6	2.8	3.2
	ID10	2.6	2.8	3.0			

(e) シナリオ 5

車両	ID/ 閾値	検知タイミング (s)					
		運転者ごとに モデルを作成した時			車両ごとに モデルを作成した時		
		1 σ	2 σ	3 σ	1 σ	2 σ	3 σ
車両1	ID1	1.6	1.9	2.1	1.6	1.9	2.2
	ID2	1.1	1.4	1.6			
車両2	ID3	1.2	1.4	1.7	1.2	1.5	1.8
	ID4	1.2	1.4	1.7			
車両3	ID5	1.3	1.5	1.8	1.3	1.5	1.8
	ID6	1.1	1.4	1.7			
車両4	ID7	1.8	2.1	2.3	1.8	2.1	2.3
	ID8	1.2	1.4	1.7			
車両5	ID9	1.2	1.4	1.7	1.9	2.3	2.7
	ID10	2.2	2.5	2.7			

(f) シナリオ 6

車両	ID/ 閾値	検知タイミング (s)					
		運転者ごとに モデルを作成した時			車両ごとに モデルを作成した時		
		1 σ	2 σ	3 σ	1 σ	2 σ	3 σ
車両1	ID1	1.2	1.4	1.6	1.3	1.5	1.7
	ID2	1.2	1.4	1.5			
車両2	ID3	1.4	1.5	1.7	1.4	1.6	1.8
	ID4	1.4	1.6	1.8			
車両3	ID5	1.3	1.5	1.6	1.3	1.5	1.6
	ID6	1.2	1.3	1.4			
車両4	ID7	1.4	1.5	1.6	1.4	1.5	1.7
	ID8	1.3	1.4	1.6			
車両5	ID9	1.4	1.6	1.7	1.6	1.8	2.0
	ID10	1.6	1.8	2.0			

7.3.3 既往研究との検知タイミングの比較

ここでは本研究で構築する手法と既往研究で行われた手法の検知タイミングを比較する。本研究では、5.2.1の知見を踏まえ、同様のコンセプトで個人間検知ができる既往研究に着目する。そこで6.3.3でも比較した、Din et al.¹⁾ が用いた Gaussian Mixture Model (GMM), Zhang et al.²⁾ が用いた Isolation Forests (IF), Ngan et al.³⁾ が用いた Local Outlier Factor (LOF) を適用して検知タイミングを算出する。また、個人内検知の手法として構築した LSTM AE が個人間検知に有効かどうかの検討も行う。

図 7.6(a)-(f)に既往研究の手法と検知タイミングを比較した結果を示す。なお、ここでは全被験者の検知タイミングの平均の結果を示す(被験者ごとの各手法の検知タイミングは巻末付録に記載)。まず、シナリオ1~シナリオ3の検証結果について述べる。

本研究で構築した OCSVM を用いた手法が、最も早く検知できることが明らかになった。閾値が1 σ の時は、GMM, IF, LOF との検知タイミングの差は、ほとんどないことが明らかになった。しかしながら、閾値が3 σ の時で、OCSVM を用いた手法は0.1s~0.3s程度、早く検知できることが確認された。

また、LSTM AE を用いた個人間検知は、他の手法と比べて、検知タイミングが遅く、リアルタイム検知には適用できないことが明らかになった。このことから、他の運転者の走行挙動との乖離度合いから、進入時の運転の誤操作を検知する時は、交差点部で観測した各データの平均値と標準偏差の2つの観点から考えた方が良いことが明らかになった。

次に、シナリオ4～シナリオ6の検証結果について述べる。シナリオ1～シナリオ3と概ね同等の結果となった。本研究で構築したOCSVMを用いた手法が、最も早く検知できることが明らかになった。GMM, IF, LOFとの検知タイミングの差は、ほとんどないことが明らかになった。しかしながら、閾値が 3σ の時はOCSVMを用いた手法が0.1s～0.2s程度、早く検知できることが確認された。

また、LSTM AEを用いた個人間検知は、他の手法と比べて、検知タイミングが遅く、リアルタイム検知には適用できないことが明らかになった。このことから、他の運転者の走行挙動との乖離度合いから、曲る時の運転の誤操作を検知する時は、交差点部で観測した各データの平均値と標準偏差の2つの観点から検知を行う方がよいことが明らかになった。

以上を踏まえると、本研究で構築したOCSVMを用いた個人間検知は、他の運転者の走行挙動との乖離度合いから異常度を定義する方法において、最も早く異常運転の検知ができることを示した。

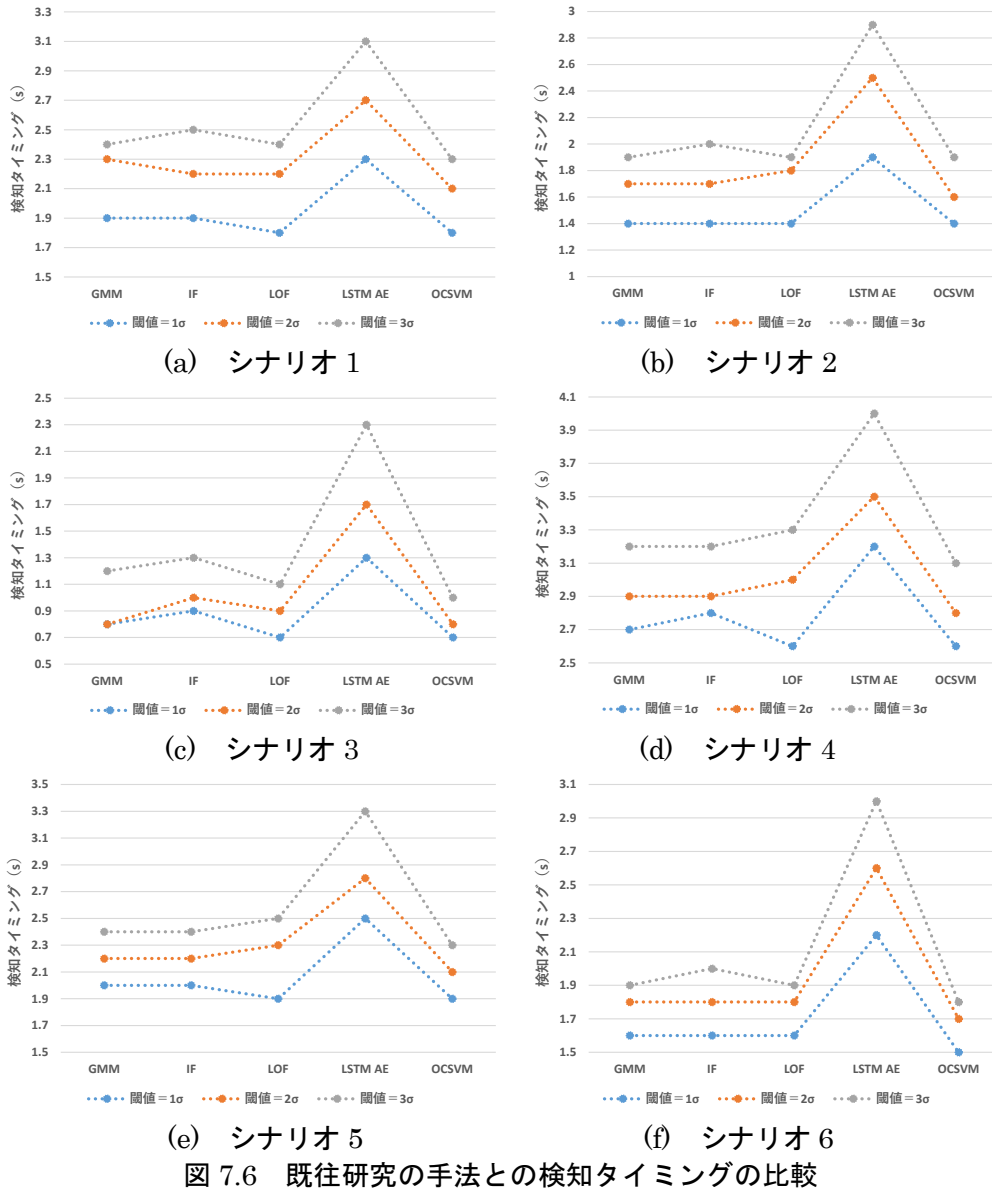


図 7.6 既往研究の手法との検知タイミングの比較

7.3.4 異常運転検知に有効なデータの検討

ここでは個人間検知で異常運転が発生したと判断された時に閾値を越えたデータについて述べる。本研究で構築した個人間検知は、観測機器から直接出力される車両速度、三軸成分の加速度、操舵角に加え、合成加速度、三軸成分の躍度、合成躍度、操舵角速度の計 11 のデータから平均値と標準偏差を特徴量として設定した。

計 11 のデータの中で、閾値を超えて異常運転として検知されているかを把握することは、構築した手法の性能向上をする上でも重要である。どのデータを観測しておけば異常運転検知ができると把握できるからである。また、そのデータが観測できるセンサーの性能を向上させておけば、より早いタイミングで検知できる可能性につながる。

そこで、リアルタイム検知が行われた時に、どのデータが異常運転として検知されたのかを集計する。本研究では、6.3.4 と同様に検知割合を評価指標にする。なお、リアルタイム検知の場合、最も早く閾値を越えたデータのみをカウントする。例えば、車両速度データの

検知割合を算出する場合は、以下の(7.2)式で算出する。この時、算出される検知割合が大きいほど、そのシナリオにおいて重要なデータであることを意味している。

$$\text{車両速度の検知割合(\%)} = \frac{C'}{C'+D'} \times 100 \quad (7.2)$$

C'：検証用データに対し異常運転であると判定した数、かつ車両速度データが最も早く閾値を越えていた検証用データの数

D'：検証用データに対し異常運転であると判定した数、かつ車両速度データが閾値を越えていなかった検証用データの数

図7.7(a)・(f)に集計結果を示す。なお、ここでは全被験者の検知割合の平均の結果を示す(被験者ごとの各特微量の検知割合は巻末付録に記載)。まず、シナリオ1～シナリオ3の検証結果について述べる。進入時の運転の誤操作が発生した時は、車両速度、Y軸成分の加速度、合成加速度が検知されていることが明らかになった。進入時の運転の誤操作は、アクセル・ブレーキペダルが原因で発生することが多いと考えられる。設定した計11のデータの内、アクセル・ブレーキペダルの影響が観測されやすいデータは、車両速度、Y軸成分の加速度、合成加速度であり、検知割合の結果も妥当であると考えられる。

なお、閾値を高くすると、車両速度、Y軸成分の加速度、合成加速度のデータ以外の検知割合は、減少することが明らかになった。したがって、進入時の運転の誤操作を個人間検知する場合は、車両速度、Y軸成分の加速度、合成加速度のデータを観測しておけばよいことが示された。また、事後検知に比べて、リアルタイム検知の検知割合は小さいことが明らかになった。これは、リアルタイム検知は最も早く閾値を越えたデータのみをカウントしている為だと考えられる。

次に、シナリオ4～シナリオ6の検証結果について述べる。曲る時の運転の誤操作が発生した時は、X軸成分の加速度、操舵角速度が検知されていることが明らかになった。曲る時の運転の誤操作は、ハンドル操作が原因で発生することが多いと考えられる。本研究で設定した11のデータの内、ハンドル操作の影響が観測される特微量は、X軸成分の加速度、操舵角速度であり、検知割合の結果も妥当であると考えられる。なお、閾値を高くすると、X軸成分の加速度、操舵角速度のデータ以外の検知割合は、減少することが明らかになった。

したがって、曲る時の運転の誤操作を個人間検知する場合は、X軸成分の加速度、操舵角速度のデータを観測しておけばよいことが示された。また、事後検知に比べて、リアルタイム検知の検知割合は小さいことが明らかになった。これは、リアルタイム検知は最も早く閾値を越えたデータのみをカウントしている為だと考えられる。

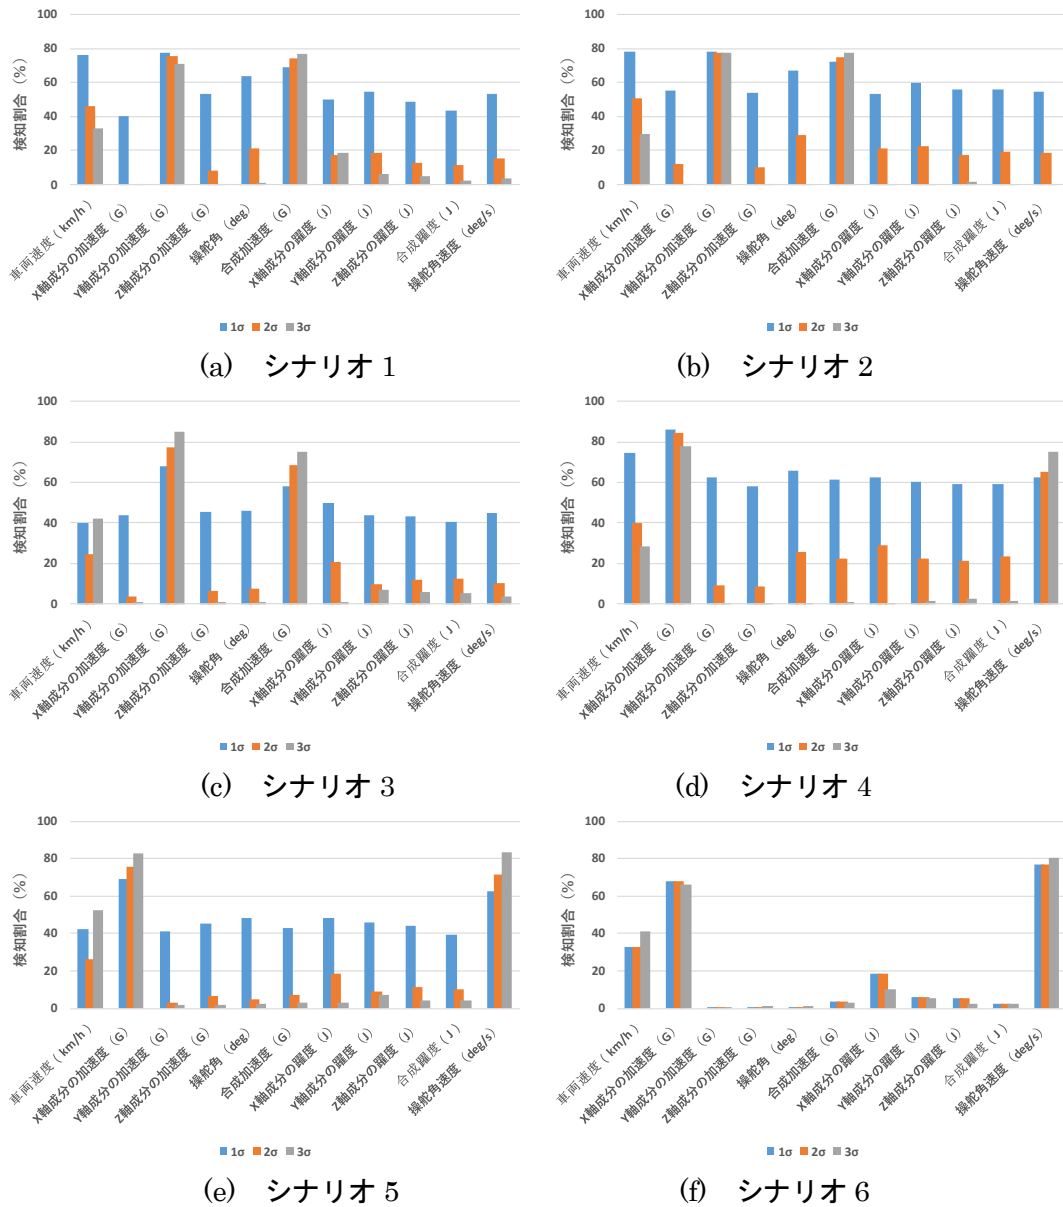


図 7.7 個人間検知における有効なデータ

7.4 個人内異常運転検知の性能評価

7.4.1 LSTM AE の設定条件

ここでは LSTM AE の設定条件について述べる。リアルタイム検知の場合、事前の設定条件によって検知タイミングに影響を及ぼす。なお、ここで検討する設定条件は、中間層 (LSTM 層) の数および中間層のニューロンの数である。

そこで本研究では、中間層の数および中間層のニューロンの数を変えたモデルを作成し、走行挙動に適用した際の最適な設定条件について検討する。表 7.3 (a) に LSTM AE のモデルの概要を示す。既往研究^{4), 5)}の知見を踏まえ、モデル D1~D10 を作成した。なお、モデル D1~D10 は 6.4.1 で作成したモデル C1~C10 と同様なので、ここでは各モデルの説明

は割愛する。

表 7.3 リアルタイム検知に用いる LSTM AE の設定条件
(a) モデルの概要

モデル	中間層の数	中間層のニューロンの数
モデルD1	1	入力データ長の1/8
モデルD2	1	入力データ長の1/4
モデルD3	1	入力データ長の1/2
モデルD4	1	入力データ長の2倍
モデルD5	1	入力データ長の4倍
モデルD6	1	入力データ長の8倍
モデルD7	2	入力データ長の2倍, 4倍
モデルD8	2	入力データ長の1/2, 1/4
モデルD9	3	入力データ長の2倍, 4倍, 8倍
モデルD10	3	入力データ長の1/2, 1/4, 1/8

表 7.3 (b)に各モデル共通の設定条件について述べる。各モデル共通の設定条件も 6.4.1 と同様の条件なので説明は割愛する。また、走行挙動の処理の流れも同様であるので、ここでは説明を割愛する。

(b) 各モデル共通の設定条件

最適化アルゴリズム	Adam
損失関数	mae
ドロップアウト率	0.2
活性化関数	tanh関数
バッチサイズ	8
エポック数	1000
打ち切り条件	Val_loss = 0

7.4.2 検知タイミングの検証結果

ここでは個人内検知の検知タイミングの検証結果について述べる。まず初めに、リアルタイム検知を行う時の最適な LSTM AE の設定条件についての検討を行う。図 7.8(a)-(f)にモデルごとの検知タイミングの結果を示す。なお、ここでは全被験者の検知タイミングの平均の結果を示す（被験者別のモデルごとの検知タイミングは巻末付録に記載）。

閾値が 1σ の時はモデル D1 から D10 の検知タイミングの差は見られなかった。閾値が 2σ 、 3σ になると、モデル間の差は表れることが明らかになった。LSTM 層のニューロンの数が入力データよりも短いモデル D1 からモデル D3 は、検知タイミングがわずかに遅くなる傾向にあることが明らかになった。また、LSTM 層の数を 2 つ以上にしたモデル D7 からモデル D10 も同様の傾向にあることが明らかになった。

以上を踏まえると、全てのシナリオにおいて、検知タイミングが最も早いモデルは、モデル D4 (LSTM 層の数が 1 つ、LSTM 層のニューロンの数が入力データの 2 倍) であることが明らかになった。よって、以後の本章の分析ではモデル D4 を使用する。

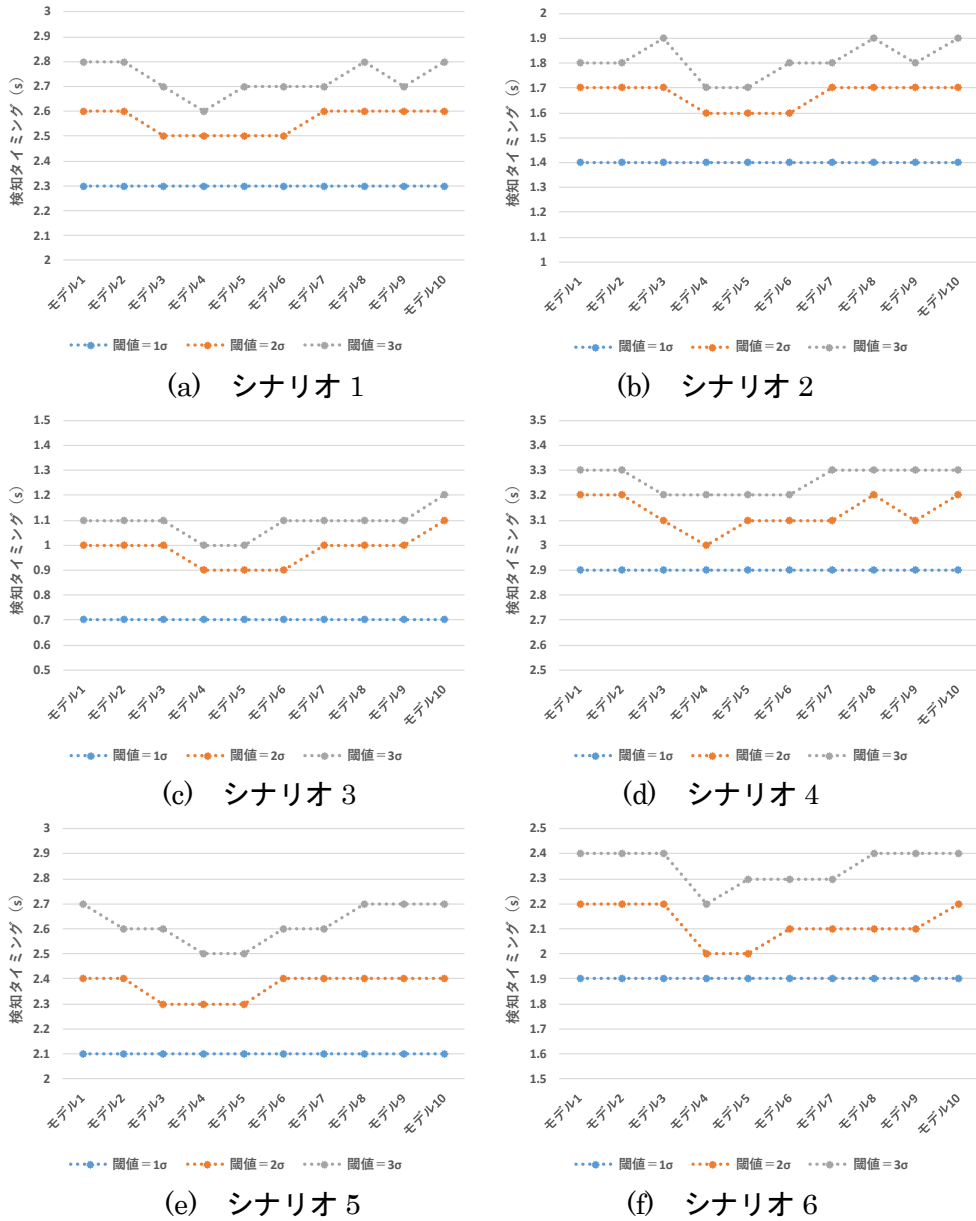


図 7.8 モデルごとの検知タイミングの結果

次に、シナリオごとの検知タイミングの考察を述べる。図 7.9(a)-(f)に検知タイミングの分布を示す(被験者別の検知タイミングは巻末付録に記載)。まず、シナリオ 1～シナリオ 3 の検証結果について述べる。閾値を高くすると、0.1s から 0.2s 程度遅くなることが明らかになった。シナリオ 1 が検知にかかる時間が最も長く、シナリオ 3 が検知にかかる時間が最も短いという結果になった。これは、交差点部規模が大きいほど、検知タイミングが遅くなる為と考えられる。検知タイミングのばらつきを見ると、シナリオ 1 の検知タイミングは、ばらつきが大きくなっていることが明らかになった。シナリオ 1 のみ大きい理由は、被験者によっては、学習用データと検証用データの特性が似ている可能性が考えられる。

次に、シナリオ 4～シナリオ 6 の検証結果について述べる。曲る時の運転の誤操作の検知タイミングは、シナリオ 1～シナリオ 3 に比べて遅い傾向にあることが明らかになった。これは、曲る時の運転の誤操作なので、車両が交差点を曲り始めてから初めて、特異な特徴が

検出されると考えられる。その為、異常運転と判断するまでに時間を要すると考えられる。また、閾値を高くすると、0.1s から 0.2s 程度検知タイミングが遅くなることが明らかになった。シナリオ 4 が検知にかかる時間が最も長く、シナリオ 6 が検知にかかる時間が最も短いという結果になった。これは、交差点部規模が大きいほど、検知タイミングが遅くなる為と考えられる。検知タイミングのばらつきを見ると、シナリオ 4 とシナリオ 6 の検知タイミングが被験者によってばらつきが生じている。シナリオ 4 とシナリオ 6 が大きい理由は、被験者によっては、学習用データと検証用データの特性が似ている可能性が考えられる。

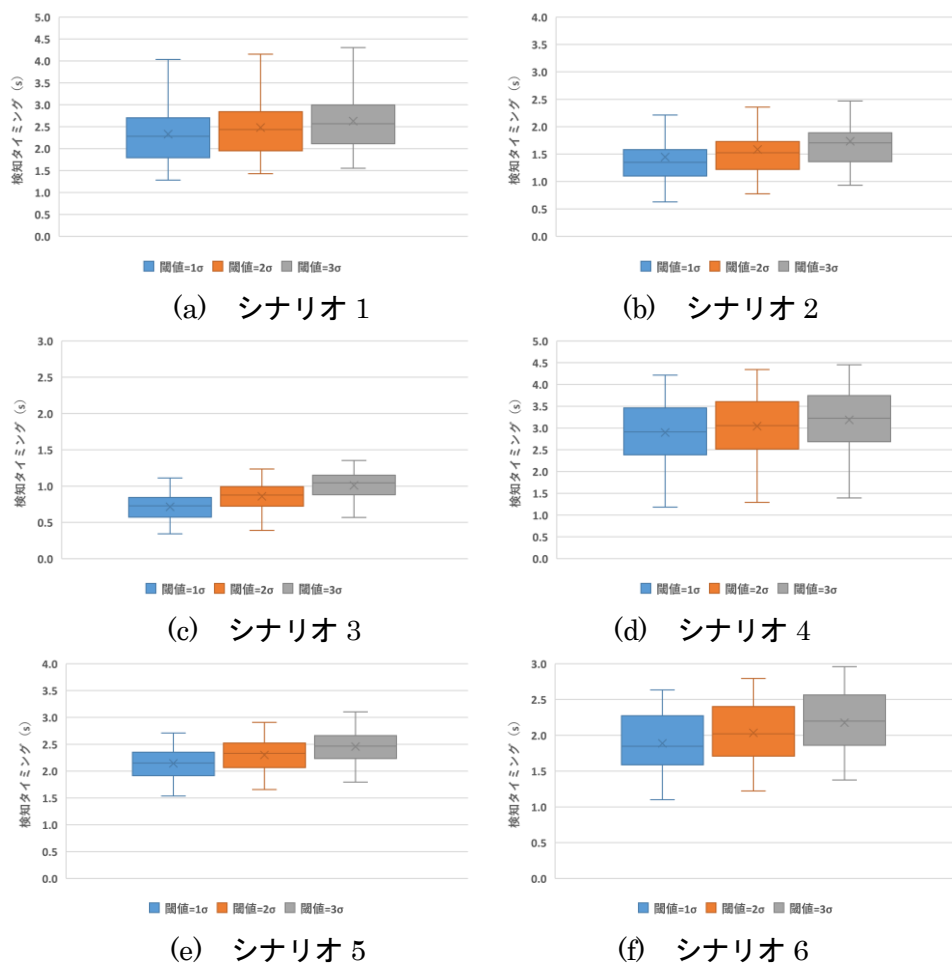


図 7.9 個人内異常運転検知の検知タイミングの分布

図 7.10 に異常運転の発生を検知した地点を可視化した結果を示す。ここでは、シナリオ 1 およびシナリオ 4 の大規模交差点部で異常運転が発生した時を一例に示す。シナリオ 1 の場合、交差点部に進入した直後に異常運転として検知できていることが明らかになった。一方、シナリオ 4 の場合、交差道路に進入する前に異常運転として検知できていることが明らかになった。

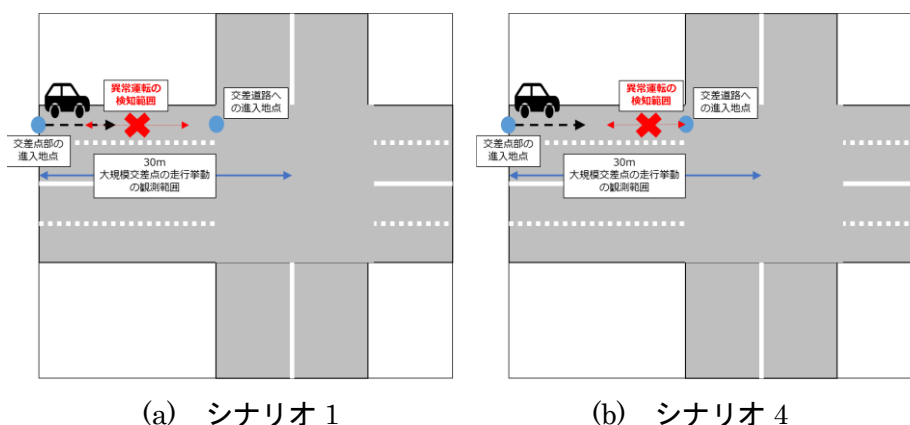


図 7.10 個人内異常運転検知による検知地点の可視化

7.4.3 運転者特定の有無が検知タイミングに及ぼす影響

ここでは運転者の特定の有無が個人内検知の検知タイミングに及ぼす影響について明らかにする。7.3.2と同様に、一台の車を二人で利用しているID1からID10の被験者を対象に、個々の運転者ごとに正常な走行挙動モデルを作成（以下、本項では、運転者モデルと呼ぶ）して個人内検知を行った場合と車両ごとに正常な走行挙動モデルを作成（以下、本項では、車両モデルと呼ぶ）して個人内検知を行った場合の検知タイミングの比較を行う。

表 7.4 (a)-(f)に検知タイミングを比較した結果を示す。まず、シナリオ1～シナリオ3の検知タイミングを比較した結果の考察を述べる。閾値が 1σ の時は、運転者モデルと車両モデルの検知タイミングの差はほとんど変わらないことが明らかになった。

しかしながら、閾値を高くすると、 $0.2s\sim 0.3s$ 程度、検知タイミングが遅くなることが確認された。このことから、進入時の運転の誤操作を個人内検知で検知する時は、運転者モデルで検知した方が良い事が明らかになった。なお、同一の車両を使用している被験者の中でも、検知タイミングの値が大きく異なるのは、交差点部の形状に依存するからと考えられる。

次に、シナリオ4～シナリオ6の検知率を比較した結果の考察を述べる。シナリオ1～シナリオ3と概ね似た検証結果であることが明らかになった。閾値が 1σ の時は、運転者モデルと車両モデルの検知タイミングの差はほとんど変わらないことが明らかになった。

しかしながら、閾値を高くすると、 $0.2s\sim 0.3s$ 程度、検知タイミングが遅くなることが確認された。このことから、曲る時の運転の誤操作を個人内検知で検知する時は、運転者モデルで検知した方が良い事が明らかになった。なお、同一の車両を使用している被験者の中でも、検知タイミングの値が大きく異なるのは、交差点部の形状に依存するからと考えられる。

なお、個人内検知は、個々の運転者の日々の走行挙動の変動度合いから異常度を定義する

方法であり、他の運転者の走行挙動が含まれている状態だと、正常な走行挙動モデルの作成が上手くできないからと考えられる。その為、検知タイミングの差が大きくなったと考えられる。

以上を踏まえると、個々の運転者ごとに正常な走行挙動モデルを作成して個人内検知を行うことは、異常運転検知の検知タイミングの向上に寄与することが明らかになった。したがって、リアルタイム検知を行う際は、運転者が特定された状態で個人内検知を行うべきことが示唆された。

表 7.4 運転特定をした時としなかった時の検知タイミングの比較

(a) シナリオ 1

車両	ID/ 閾値	検知タイミング (s)					
		運転者ごとに モデルを作成した時			車両ごとに モデルを作成した時		
		1 σ	2 σ	3 σ	1 σ	2 σ	3 σ
車両1	ID1	3.8	4.0	4.1	4.2	4.3	4.4
	ID2	4.0	4.2	4.3			
車両2	ID3	2.2	2.3	2.5	2.6	2.9	3.2
	ID4	3.0	3.2	3.4			
車両3	ID5	2.5	2.7	2.9	2.8	3.0	3.1
	ID6	2.7	2.8	3.0			
車両4	ID7	2.1	2.3	2.4	2.6	2.8	2.9
	ID8	2.4	2.6	2.8			
車両5	ID9	2.2	2.4	2.5	2.6	2.8	3.0
	ID10	3.1	3.2	3.3			

(b) シナリオ 2

車両	ID/ 閾値	検知タイミング (s)					
		運転者ごとに モデルを作成した時			車両ごとに モデルを作成した時		
		1 σ	2 σ	3 σ	1 σ	2 σ	3 σ
車両1	ID1	2.4	2.5	2.7	2.8	3.0	3.2
	ID2	2.7	2.9	3.0			
車両2	ID3	1.3	1.5	1.7	1.4	1.6	1.9
	ID4	1.0	1.2	1.3			
車両3	ID5	2.2	2.4	2.5	2.3	2.4	2.6
	ID6	1.9	2.0	2.2			
車両4	ID7	1.3	1.5	1.7	1.6	1.8	2.0
	ID8	1.6	1.7	1.9			
車両5	ID9	1.4	1.5	1.7	2.4	2.6	2.7
	ID10	3.0	3.1	3.2			

(c) シナリオ 3

車両	ID/ 閾値	検知タイミング (s)					
		運転者ごとに モデルを作成した時			車両ごとに モデルを作成した時		
		1 σ	2 σ	3 σ	1 σ	2 σ	3 σ
車両1	ID1	0.8	0.9	1.0	0.8	1.0	1.1
	ID2	0.6	0.8	0.9			
車両2	ID3	0.6	0.7	0.9	1.1	1.2	1.3
	ID4	1.1	1.2	1.3			
車両3	ID5	0.3	0.4	0.6	0.7	0.8	0.9
	ID6	0.7	0.8	1.0			
車両4	ID7	0.9	1.0	1.2	1.0	1.2	1.4
	ID8	0.9	1.1	1.3			
車両5	ID9	0.8	1.0	1.1	0.9	1.1	1.2
	ID10	0.6	0.7	0.9			

(d) シナリオ 4

車両	ID/ 閾値	検知タイミング (s)					
		運転者ごとに モデルを作成した時			車両ごとに モデルを作成した時		
		1 σ	2 σ	3 σ	1 σ	2 σ	3 σ
車両1	ID1	4.1	4.2	4.4	4.1	4.3	4.5
	ID2	4.0	4.1	4.3			
車両2	ID3	3.8	3.9	4.1	4.0	4.1	4.2
	ID4	3.9	4.0	4.1			
車両3	ID5	3.4	3.5	3.6	3.9	4.0	4.2
	ID6	3.9	4.1	4.2			
車両4	ID7	3.7	3.9	4.0	3.7	3.9	4.0
	ID8	3.0	3.2	3.4			
車両5	ID9	2.8	3.0	3.2	3.5	3.6	3.7
	ID10	4.2	4.3	4.5			

(e) シナリオ 5

車両	ID/ 閾値	検知タイミング (s)					
		運転者ごとに モデルを作成した時			車両ごとに モデルを作成した時		
		1 σ	2 σ	3 σ	1 σ	2 σ	3 σ
車両1	ID1	2.3	2.5	2.6	2.8	3.0	3.2
	ID2	2.7	2.9	3.1			
車両2	ID3	2.0	2.2	2.3	2.3	2.4	2.5
	ID4	2.3	2.4	2.6			
車両3	ID5	2.1	2.3	2.5	2.5	2.6	2.7
	ID6	2.4	2.5	2.7			
車両4	ID7	1.8	1.9	2.1	1.9	2.1	2.2
	ID8	1.8	2.0	2.1			
車両5	ID9	2.3	2.4	2.6	2.3	2.5	2.6
	ID10	1.9	2.0	2.2			

(f) シナリオ 6

車両	ID/ 閾値	検知タイミング (s)					
		運転者ごとに モデルを作成した時			車両ごとに モデルを作成した時		
		1 σ	2 σ	3 σ	1 σ	2 σ	3 σ
車両1	ID1	2.5	2.7	2.8	2.5	2.7	2.8
	ID2	2.3	2.5	2.6			
車両2	ID3	2.1	2.2	2.4	2.5	2.6	2.8
	ID4	2.5	2.7	2.8			
車両3	ID5	2.5	2.6	2.7	2.6	2.8	3.0
	ID6	2.6	2.8	3.0			
車両4	ID7	2.2	2.3	2.5	2.3	2.4	2.6
	ID8	1.8	1.9	2.1			
車両5	ID9	1.7	1.9	2.0	2.3	2.5	2.7
	ID10	2.6	2.7	2.9			

7.4.4 既往研究との検知タイミングの比較

ここでは本研究で構築する手法と既往研究で行われた手法の検知タイミングを比較する。本研究では、5.2.2の知見を踏まえ、同様のコンセプトで個人内検知ができる既往研究に着目する。そこで6.4.3でも比較した、Dairi et al.⁶⁾ が用いた Auto Encoder (AE), Eren et al.⁷⁾ が用いた Dynamic Time Warping (DTW), Matousek et al.⁸⁾ が用いた Long Short

Term Memories (LSTM) を適用して検知タイミングを算出する。また、個人内検知の手法として構築した OCSVM が個人内検知に有効かどうかの検討も行う。

図 7.11(a)-(f) に既往研究の手法と検知タイミングを比較した結果を示す。なお、ここでは全被験者の検知タイミングの平均の結果を示す（被験者ごとの各手法の検知タイミングは巻末付録に記載）。まず、シナリオ 1～シナリオ 3 の検証結果について述べる。本研究で構築した LSTM AE を用いた手法が、最も早く検知できることが明らかになった。

AE との検知タイミングの差は、閾値が 1σ の時点で大きいことが明らかになった。これは、AE を用いた異常運転検知は、入力した走行挙動を復元し、その時の再構成誤差から判断している為と考えられる。LSTM AE は、交差点部での運転者の特性を復元し、その時の再構成誤差から判断している。したがって、リアルタイムでの異常運転を検知する際は、交差点部での運転者の癖に着目し、検知した方が良い事が明らかになった。

DTW, LSTM との検知タイミングの差は、ほとんどないことが明らかになった。しかしながら、閾値を高くすると 3σ の時で、LSTM AE を用いた手法が 0.1s～0.2s 程度、早く検知できることが確認された。

また、OCSVM を用いた個人内検知は、他の手法と比べて、検知タイミングが遅く、リアルタイム検知には適用できないことが明らかになった。このことから、個々の運転者の走行挙動との変動度合いから、進入時の運転の誤操作を検知する時は、走行挙動の軌跡（時系列の変位）から検知すべきことが明らかになった。

次に、シナリオ 4～シナリオ 6 の検証結果について述べる。シナリオ 1～シナリオ 3 と概ね同等の検証結果となった。AE との検知タイミングの差は、閾値が 1σ の時点で大きいことが明らかになった。

DTW, LSTM との検知タイミングの差は、ほとんどないことが明らかになった。しかしながら、閾値を高くすると 3σ の時で、LSTM AE を用いた手法が 0.1s～0.2s 程度、早く検知できることが確認された。

また、OCSVM を用いた個人内検知は、他の手法と比べて、検知タイミングが遅く、リアルタイム検知には適用できないことが明らかになった。このことから、個々の運転者の走行挙動との変動度合いから、曲る時の運転の誤操作を検知する時は、走行挙動の軌跡（時系列の変位）から検知すべきことが明らかになった。

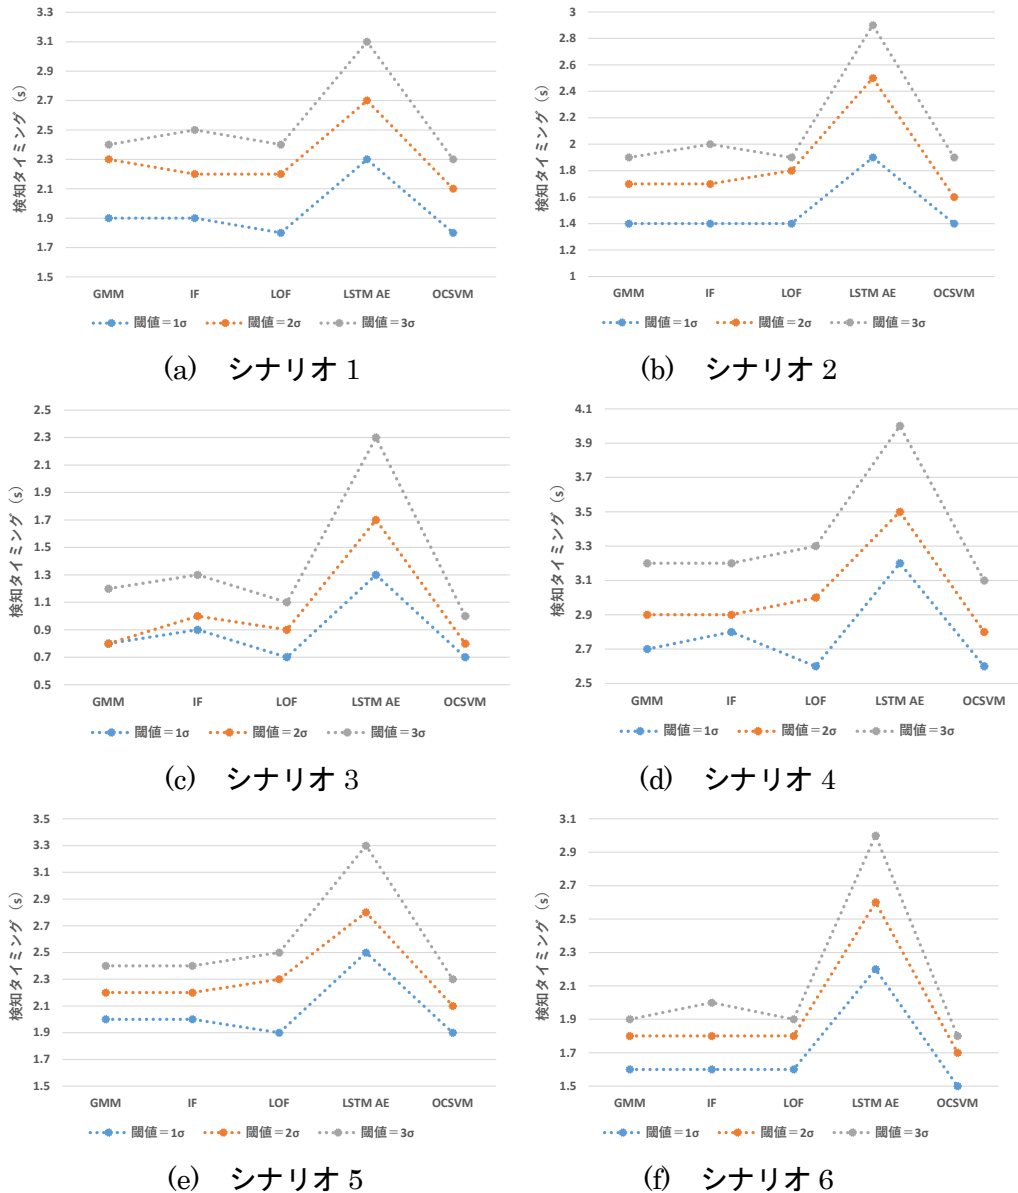


図 7.11 既往研究で行われた手法との検知率の比較

7.4.5 異常運転検知に有効なデータの検討

ここでは個人内検知で異常運転が発生したと判断された時に閾値を越えたデータについて述べる。本研究で構築した個人内検知は、観測機器から直接出力される車両速度、三軸成分の加速度、操舵角に加え、合成加速度、三軸成分の躍度、合成躍度、操舵角速度の計 11 のデータの軌跡（時系列変化）を用いて検知した。7.3.4 と同様に、個人内検知によるリアルタイム検知が行われた時の各データの検知割合を集計する。集計方法は（7.2）式と同様なので、ここでは説明を割愛する。

図 7.12 (a)-(f)に集計結果を示す。なお、ここでは全被験者の検知割合の平均の結果を示す（被験者ごとの各データの検知割合は巻末付録に記載）。まず、シナリオ 1～シナリオ 3 の検証結果について述べる。進入時の運転の誤操作が発生した時は、11 のデータの全てが異常運転として検知されていることが明らかになった。この理由は、個人内検知は日々の走行挙動の変動度合いから異常度を定義するからである。日々の走行挙動の変動度合いは、特定のデータだけに反映せず、11 のデータの全てが閾値を越えると考えられる。

したがって、検知されているデータは妥当であると考えられる。なお、閾値を高くすると全てのデータの検知割合が若干、減少することが明らかになった。なお、事後検知に比べて、リアルタイム検知の検知割合は小さいことが明らかになった。これは、リアルタイム検知は最も早く閾値を越えたデータのみをカウントしている為だと考えられる。

次に、シナリオ 4～シナリオ 6 の検証結果について述べる。曲る時の運転の誤操作が発生した時は、シナリオ 1～シナリオ 3 と概ね同様の結果である。11 のデータの全てが異常運転として検知されていることが明らかになった。この理由は、進入時の運転の誤操作が発生した時と同様であると考えられる。

したがって、検知されているデータは妥当であると考えられる。なお、閾値を高くすると全てのデータの検知割合が若干、減少することが明らかになった。なお、事後検知に比べて、リアルタイム検知の検知割合は小さいことが明らかになった。これは、リアルタイム検知は最も早く閾値を越えたデータのみをカウントしている為だと考えられる。

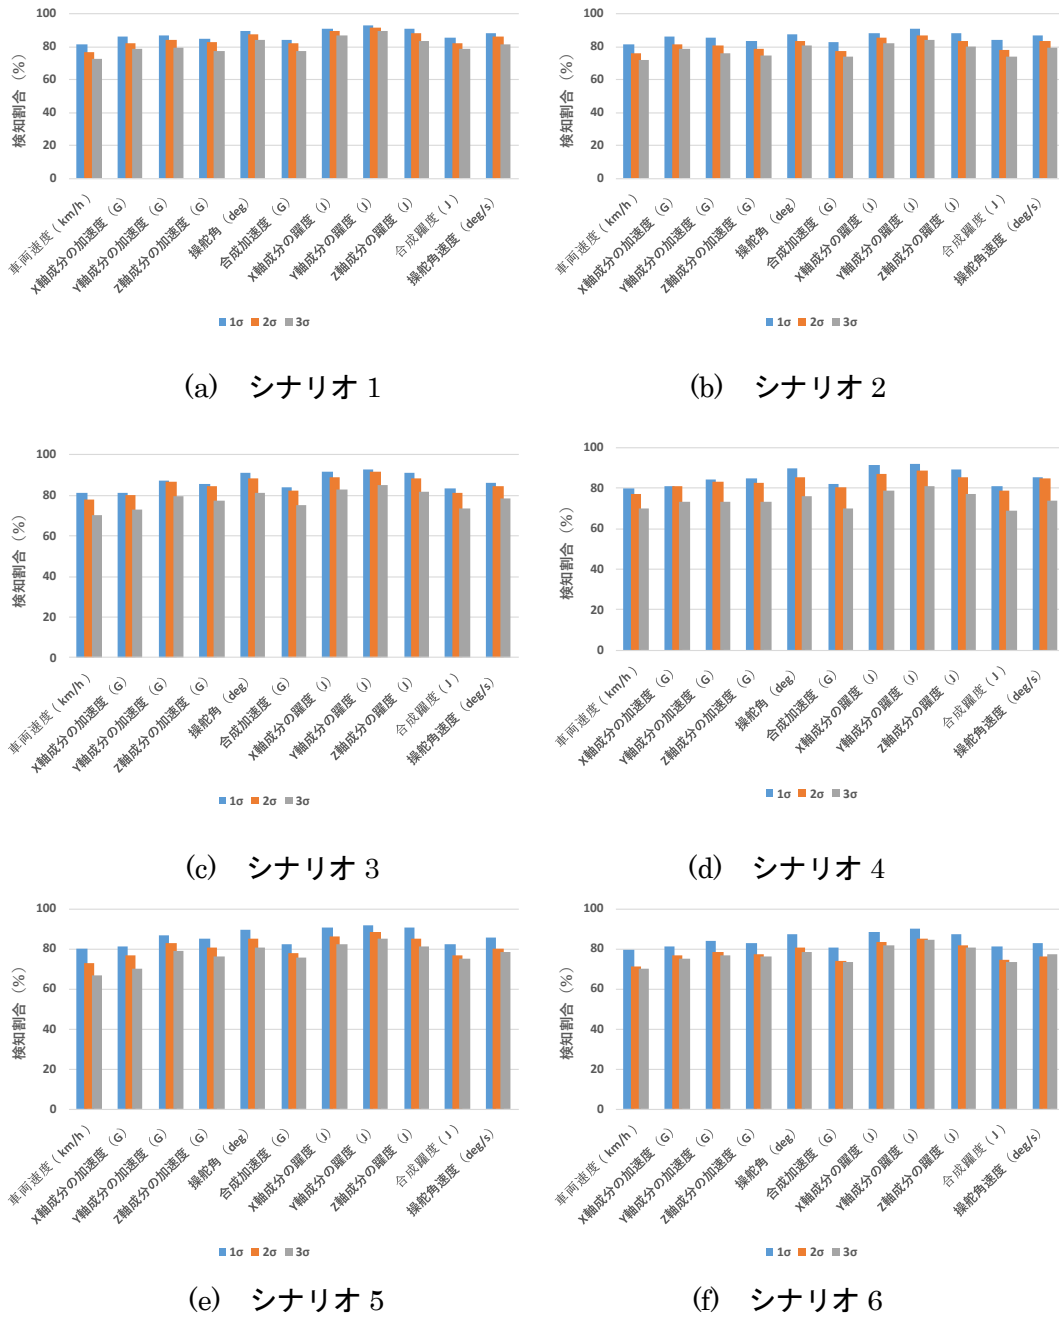


図 7.12 個人内検知における有効なデータ

7.5 二つの異常運転検知手法がもたらす効果

7.5.1 検知結果から考える車両の対応

ここではリアルタイム検知の結果から車両が行う対応について述べる。本研究では、異常度の定義方法が異なる、個人間検知と個人内検知の手法を構築し性能評価の検証を行った。

構築した手法を実社会で実装する時は、検知された結果から、車両がどのような対応をすべきか検討する必要がある。

表 7.5 に示すように、リアルタイム検知の検知結果は、4つのクラスに分けることができる。それぞれのクラスで車両が行うべき対応は以下の通りになると考えられる。

表 7.5 二つの異常運転検知の結果

個人間異常運転検知の結果			
個人内異常運転検知の結果	Class	正常運転と判別	異常運転と判別
	正常運転と判別	(A)	(B)
	異常運転と判別	(C)	(D)

- (A) 個人間検知が正常運転，個人内検知が正常運転と判定した時のクラスである。この時の走行挙動は、特に問題がなく、運転者は適切な交通流かつ普段通りの運転ができていると考えられる。
- (B) 個人間検知が異常運転，個人内検知が正常運転と判定した時のクラスである。この時の走行挙動は、運転者は、周りの運転者に比べて乖離した運転をしている。ただ、日々の走行挙動との変動度合いは少ない為、元々の運転が荒い場合が考えられる。したがって、状況に応じて、他の車両や歩行者がいる場合は、制御や注意喚起を行う必要がある。
- (C) 個人間検知が正常運転，個人内検知が異常運転と判定した時のクラスである。この時の走行挙動は、運転者自身に問題があった場合が考えられる。例えば、感情的な運転や急ぎ運転、病気の発症、居眠り運転、飲酒運転などが考えられる。したがって、状況に応じて、運転者に警告を行う必要がある。
- (D) 個人間検知が異常運転，個人内検知が異常運転と判定した時のクラスである。この時の走行挙動は、4つのクラスの中で、最も危険な運転をしており、早急な対応が必要である。したがって、車両の制御や周りへの注意喚起を行うのに加え、車両が運転者自身に警告を行う必要がある。

以上、車両が行うべき対応について検討を行った。なお、(B)と(C)が分類された時は、観測機器から出力されるデータだけでは判断せず、その他の情報（例えば、ドライビングレコーダーやLIDARなど）から総合的に判断した方が良いと考えられる。

7.5.2 検知タイミングの比較

ここでは構築した二つの手法の検知タイミングの比較を行う。閾値を 3σ に設定して、シナリオ1からシナリオ6までの個人間検知と個人内検知の検知タイミングを比較する。

図7.13に一例として、シナリオ1の被験者ID15と被験者ID21による個人間検知および個人内検知の検知タイミングの結果を示す。結論として、被験者によって、早く検知できる手法が異なることが明らかになった。

例えば、被験者ID25の場合、シナリオ1では、個人間検知の方が早く異常運転を検知できることを意味する。一方で、被験者ID15は、個人間検知の方が早く異常運転を検知できることを意味する。なお、検知タイミングにばらつきがあるのは、交差点部の規模や進入時の車両の状況によって検知される時間が依存するからと考えられる。

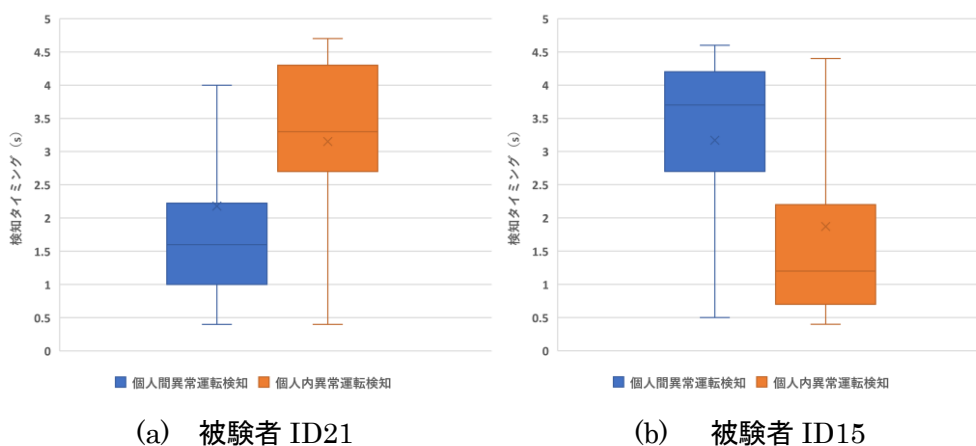


図 7.13 (個人間・個人内) 異常運転検知の検知タイミングの比較
(シナリオ1を一例に)

図7.14にシナリオ1からシナリオ6までの全被験者による個人間および個人内検知の検知タイミングの平均の結果を示す。縦軸は個人間検知から算出した検知タイミング、横軸は個人内検知から算出した検知タイミングを示している。二つの手法の検知タイミングの結果から、以下のタイプに分類できる。

① 個人間検知の検知タイミング > 個人内検知の検知タイミング

このタイプに分類された運転者は、交差点部で異常運転が発生した時に、個人間検知の方が、個人内検知よりも早く異常運転の発生を検知する。

② 個人間検知の検知タイミング < 個人内検知の検知タイミング

このタイプに分類された運転者は、交差点部で異常運転が発生した時に、個人内検知の方が、個人間検知よりも早く異常運転の発生を検知する。

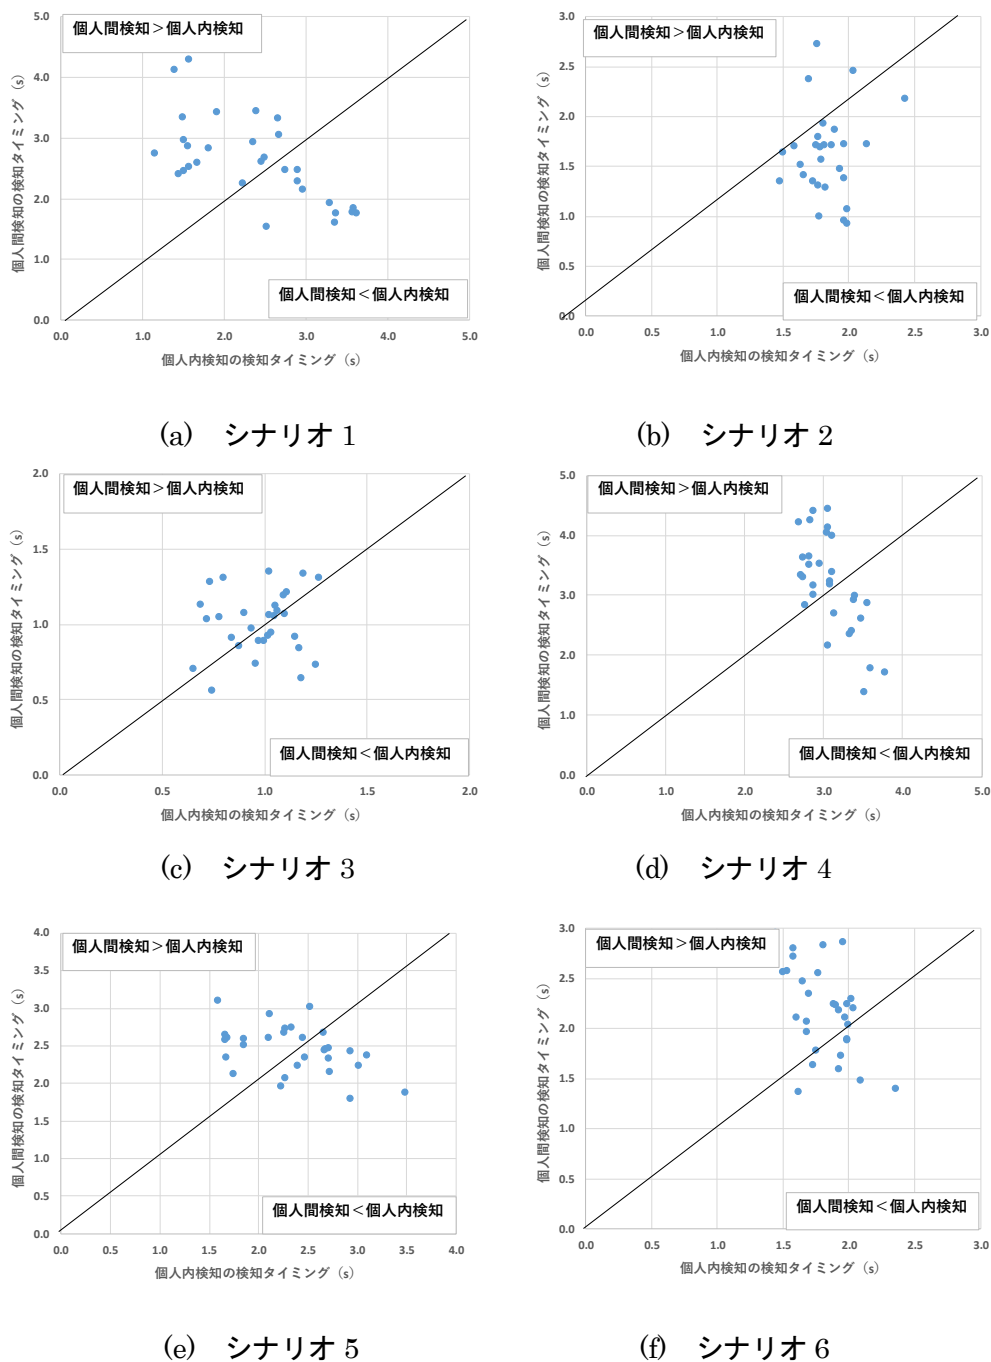


図 7.14 (個人間・個人内) 異常運転検知の検知タイミングの平均の結果

以上を踏まえると、運転者によって個人間検知と個人内検知のどちらが早く検知できるかは、運転者によって異なることが確認された。したがって、走行挙動から異常運転を検知する際は、個人間検知と個人内検知の二つの手法の両方で検知すべきことが示された。

7.6 本章のまとめ

本章では交差点部を通過中に、異常運転を検知するリアルタイム検知による手法の性能評価の検証を行った。構築した手法の検知タイミング、運転者特定の有無が検知タイミングに及ぼす影響、既往研究の手法との比較、有意な特徴量の検討を通して、手法の有効性を検証した。性能評価の検証は6章のシナリオと同様のものを設定した。

個人間異常運転検知および個人内異常運転検知の性能評価の検証結果について述べる。シナリオ1～シナリオ3の検知タイミングを見ると、交差点部に進入した直後に検知できることが明らかになった。一方で、シナリオ4～シナリオ6の検知タイミングを見ると、交差道路に進入する直前に検知できることが明らかになった。

個人間異常運転検知および個人内異常運転検知は、運転者ごとに正常な走行挙動モデルをした方が検知タイミングは早いことが明らかになった。このことから、個々の運転者が特定された状態でリアルタイム検知を行う有効性が示された。

なお、個人間異常運転検知および個人内異常運転検知を既往研究の手法と検知タイミングを比較した結果、本手法の検知タイミングが最も早いことが明らかになった。このことから、交差点部の走行挙動を用いた異常運転検知は、OCSVMとLSTM AEが有意である可能性が示された。

さらに、個人間異常運転検知と個人内異常運転検知の検知タイミングの結果を運転者ごとに比較すると、先に検知される手法が異なることが明らかになった。このことから、交差点部での異常運転検知は、本研究で構築した二つの手法から検知すべきことを示した。

第 8 章 結論

8.1 本研究のまとめ

ここでは、第 1 章で述べた本研究の目的に照らし、得られた知見をまとめる。

第 2 章、「異常運転検知に関する既往研究と本研究の位置づけ」では、異常運転検知の技術開発は古くから行われており、知見も十分に有していることが明らかになった。一方で、交差点部に着目した異常運転検知技術は未だないことが明らかになった。また、運転者の日々の走行挙動の変動度合いから異常度を定義した研究事例はないことが明らかになった。したがって、本研究の位置づけは、新たな手法構築の枠組みであることを示した。

第 3 章、「観測調査および分析用データ作成」では、交差点部の走行挙動の収集を目的とした観測調査を実施した。走行挙動は、観測機器 (0.1s 間隔で車両速度, 3 軸成分の加速度, 操舵角, 位置情報を計測) を車載する方法で 2 週間の観測を行った。しかしながら、観測機器から出力される走行挙動だけでは、交差点部での運転操作を行ったのか把握ができない。そこで分析用データの作成では、交差点部の走行挙動の分類を行った。本研究では、交差点や道路情報を有するデジタル道路網マップと走行挙動を結合することで、交差点部での車両の進行方向, 発進方法, 走行場所の道路車線数を明らかにし, 54 通りに分類できることを示した。

第 4 章、「交差点部の走行挙動を用いた運転者の特定」では、異常運転検知を行う場合、他の運転者の走行挙動が含まれていると、検知精度や検知タイミングに影響を及ぼす。そこで本章では、複数人で一台の車を利用している運転者を想定して、交差点部の走行挙動から運転者の特定を試みた。時系列データから特徴抽出を行うことに秀でた LSTM (Long Short Term Memories) を交差点部の走行挙動に適用して、交差点部での運転特性を抽出した。また、運転者の運転特性は、交差点を曲る時だけでなく、直進する時も有していると考え、3 章で分類した 54 通り全ての走行挙動を用いて運転者特定を行った。構築した手法の特定精度を既往研究の手法と比較した結果、本手法の特定精度が最も高いことを示した。さらに、運転者が特定されていない走行挙動に本手法を適用し、交差点を通過した際に得られる確信度の総和から運転者を判断することで運転者特定の精緻化を図った。

第 5 章、「交差点部の走行挙動に機械学習を用いた異常運転検知手法の構築」では、交差点部の走行挙動から異常運転を検知する手法構築を行った。本研究では、二つの観点から異

常運転を定義した。一つは、運転者全体に着目し、他の運転者の走行挙動との乖離度合いを異常度と定義する個人間異常運転検知である。他方は、個々の運転者に着目し、普段の走行挙動との変動度合いから異常度を定義する個人内異常運転検知である。前者は、交差点部で観測した走行挙動から平均値と標準偏差を特徴量とし、正常・異常の判別の操作性が良い OCSVM (One Class Support Vector Machine) を適用した手法を構築した。後者は、交差点部で観測した走行挙動の軌跡を特徴量とし、運転特性の変動度合いを定量的に算出できる、LSTM AE (Long Short Term Memories Auto Encoder) を適用して手法を構築した。

第6章、「事後検知による性能評価の検証」では、5章で構築した手法の検知精度の検証を通じて性能評価を行った。検証は、交差点部において車両の発進方法による誤操作が発生した時と車両のハンドル操作による誤操作が発生した時を想定したシナリオを設定した。検証の結果、個人間異常運転検知は、ハンドル操作の検知には、適用限界があることが明らかになった。一方、個人内異常運転検知は発進方法およびハンドル操作の誤操作を検知できることが明らかになった。また、どちらの手法も既往研究の手法と比較して高い精度で検知できることを示した。

第7章、「リアルタイム検知による性能評価の検証」では、5章で構築した手法の検知タイミングの検証を通じて性能評価を行った。検知タイミングは、前章と同様のシナリオから算出した。個人間異常運転検知および個人内異常運転検知のどちらの手法も発進方法の誤操作を想定したシナリオでは、交差点部に進入した直後に異常運転検知ができる可能性を示唆した。また、ハンドルの誤操作を想定したシナリオでは、交差道路に進入した直後に異常運転検知ができる可能性を示唆した。また、どちらの手法も既往研究の手法と比較して、最も早く異常運転を検知できることを示した。最後に、構築した二つの手法がもたらす効果について検討した。個人間異常運転検知と個人内異常運転検知のどちらが先に検知されるかは、運転者によって異なることが明らかになった。したがって、交差点部での異常運転検知は、本研究で構築した二つの手法で行うべきことを示した。

8.2 今後の展望

今後の展望を以下に示す。

✓ 被験者属性の検討と調査期間の長期化

本研究では、65歳以上の高齢運転者を被験者として、2週間の観測調査の実施を行ったが、本研究で構築した手法は、高齢運転者以外にも適用であると考えられる。特に、個人間

異常運転検知は、他の運転者との走行挙動から異常度を定義する方法である。その為、様々な属性の運転者の走行挙動を集めた方がより実社会への導入を考慮できると考えられる。

また、調査期間の長期化をすることで、より多くの交差点部の走行挙動を収集することができる。その結果、構築した手法の検知精度や検知タイミングの向上につながると考えられる。したがって、本研究で設定した6つのシナリオ以外の性能評価の検証もできると考えられる。

✓ 走行挙動観測用のアプリケーション開発

本研究では、市販の観測機器を用いて運転者の走行挙動の観測を行った。使用した機器は、3章の観測機器の精度検証で、スマートフォンが持つセンサーと同等の性能を有していることが確認された。したがって、スマートフォンを活用した走行挙動の観測および異常運転検知もできると考えられる。スマートフォンで運転者の走行挙動を観測できれば、誰もが手軽に自身の走行挙動を観測することができる。その為には、スマートフォンの活用を想定したアプリケーション開発が必要である。

なお、本研究で実施した観測調査の開始当初は、著者が作成したスマートフォンのアプリケーションで走行挙動の観測を行っていた。しかしながら、スマートフォンの扱いに慣れていない高齢運転者が機器の操作を行うには難しいことが確認された。したがって、誰でも手軽に操作できるアプリケーションのデザイン開発も必要であると考えられる。

✓ 個人内異常運転検知の閾値の精査と調整方法の検討

本研究で構築した二つの異常運転検知手法は、全ての運転者が同一の閾値（ 1σ 、 2σ 、 3σ ）を設定して異常運転検知の検証を行った。しかしながら、異常運転の発生頻度は、運転者によって大きく異なることが想定される。したがって、個々の運転者に適した閾値の設定を行うことは、誤検知を防ぐことや、異常運転の発生を見落とさない上でも重要であると考えられる。特に、個々の運転者の日々の走行挙動の変動度合いから異常度を定義する、個人内異常運転検知は適切な閾値の設定が必要不可欠であると考えられる。

個々の運転者に適した閾値の設定を行う為には、長い期間での走行挙動の観測が必要であると考えられる。観測した走行挙動の特性や傾向から、運転者に適した閾値を決定するツールの開発が必要であると考えられる。

参考文献

【第2章の参考文献】

- 1) P. J. Lugt, "Traffic Accidents Caused by Epilepsy," *Epilepsia*, vol. 16, no. 5, pp. 747–751, 1975.
- 2) D. M. Donovan, R. L. Umlauf, and P. M. Salzberg, "Bad drivers: identification of a target group for alcohol-related prevention and early intervention.," *J. Stud. Alcohol*, vol. 51, no. 2, pp. 136–141, Mar. 1990.
- 3) R. D. Peters., "Effects of Partial and Total Sleep Deprivation on Driving Performance," *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, vol. 39, no. 14, pp. 935–935, Oct. 1995.
- 4) G. Kanellaidis, J. Golias, and K. Zarifopoulos, "A survey of drivers' attitudes toward speed limit violations," *Journal of Safety Research*, vol. 26, no. 1, pp. 31–40, Mar. 1995.
- 5) T. Pilutti., A. G. Ulsoy. "Identification of Driver State for Lane-Keeping Tasks," *IEEE TRANSACTIONS ON SYSTEMS, MAN, AND CYBERNETICS—PART A: SYSTEMS AND HUMANS*, VOL. 29, NO. 5, 1999.
- 6) K. Lee and H. Peng, "Identification and verification of a longitudinal human driving model for collision warning and avoidance systems," *International Journal of Vehicle Autonomous Systems*, vol. 2, no. 1/2, p. 3, 2004.
- 7) E. M. Ayoob, A. Steinfeld, and R. Grace, "Identification of An 'Appropriate' Drowsy Driver Detection Interface for Commercial Vehicle Operations," *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, vol. 47, no. 16, pp. 1840–1844, Oct. 2003.
- 8) J. F. May and C. L. Baldwin, "Driver fatigue: The importance of identifying causal factors of fatigue when considering detection and countermeasure technologies," *Transportation Research Part F: Traffic Psychology and Behaviour*, vol. 12, no. 3, pp. 218–224, May 2009.
- 9) F. Seraji., B. J. Zwaag., A. D. Luarasi., P. Havinga. "RoADS: A road pavement monitoring system for anomaly detection using smart phones", *Big Data Analytics in the Social and Ubiquitous Context*, pp. 128–146, 2016.
- 10) L. Lopez., J. Weijer., M. G. Hidalgo., H. Skinnemoen., A. D. Bagdanov. "Review on computer vision techniques in emergency situations". *Multimedia Tools and Applications*, 77(13):17069–17107, 2018.
- 11) M. Sasho., T. Endo., T. Daimon., N. Mizuno., A. Yoshizawa. "A study on the process of gradual transition by drivers from automated driving to manual driving", *International Journal of Automotive Engineering*, vol.50, no.2, pp. 492–498, 2019.
- 12) R.A. Hauslen. "The promise of automatic vehicle identification", *IEEE Transactions on Vehicular*

- Technology, vol. 26, no. 1, 1977.
- 13) J. Cowell, "Syntactic pattern recognizer for vehicle identification numbers," *Image and Vision Computing*, vol. 13, no. 1, pp. 13–19, 1995.
 - 14) T. Pilutti and A. G. Ulsoy, "Identification of driver state for lane-keeping tasks: experimental results," in *Proceedings of the 1997 American Control Conference (Cat. No.97CH36041)*, vol. 5, pp. 3370–3374, 1997.
 - 15) T. Wakita et al., "Driver identification using driving behavior signals," in *Proceedings. 2005 IEEE Intelligent Transportation Systems*, pp. 907–912, 2005.
 - 16) Y. Nishiwaki, K. Ozawa, T. Wakita, C. Miyajima, K. Itou, and K. Takeda, "Driver Identification Based on Spectral Analysis of Driving Behavioral Signals," in *Advances for In-Vehicle and Mobile Systems*, pp. 25–34, 2007.
 - 17) H. Qian, Y. Ou, X. Wu, X. Meng, and Y. Xu, "Support Vector Machine for Behavior-Based Driver Identification System," *Journal of Robotics*, 2010.
 - 18) D. A. Johnson and M. M. Trivedi, "Driving style recognition using a smartphone as a sensor platform," in *2011 14th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, pp. 1609–1615, 2011.
 - 19) P. B. Fleischer, A. Y. Nelson, R. A. Sowah, and A. Bremang, "Design and development of GPS/GSM based vehicle tracking and alert system for commercial inter-city buses," in *2012 IEEE 4th International Conference on Adaptive Science Technology (ICAST)*, pp. 1–6, 2012.
 - 20) S. Sivaraman and M. M. Trivedi. Looking at vehicles on the road: A survey of vision-based vehicle detection, tracking, and behavior analysis. *IEEE Transactions on Intelligent Transportation Systems*, 14(4):1773–1795, 2013.
 - 21) W. Wu R. Bala R. P. Loce, E. A. Bernal. Computer vision in roadway transportation systems: a survey. *Journal of Electronic Imaging*, 22:22- 22 – 24, 2013.
 - 22) G. Kar, S. Jain, M. Gruteser, J. Chen, F. Bai, and R. Govindan, "Pre-driveID: Pre-trip Driver Identification from In-vehicle Data," in *Proceedings of the Second ACM/IEEE Symposium on Edge Computing*, pp. 2:1–2:12, 2017.
 - 23) P. Wasielewski, "Speed as a measure of driver risk: Observed speeds versus driver and vehicle characteristics," *Accident Analysis & Prevention*, vol. 16, no. 2, pp. 89–103, 1984.
 - 24) D. J. Seol, S. Y. Hu, Y. L. Li, J. Shen, K. H. Oh, and L. Q. Chen, "Computer simulation of spinodal decomposition in constrained films," *Acta Materialia*, vol. 51, no. 17, pp. 5173–5185, 2003.
 - 25) K. Igarashi, C. Miyajima, K. Itou, K. Takeda, F. Itakura, and H. Abut, "Biometric identification using driving behavioral signals," in *2004 IEEE International Conference on Multimedia and Expo (ICME) (IEEE Cat. No.04TH8763)*, vol. 1, pp. 65–68, 2004.
 - 26) N. Buch, S. A. Velastin, and J. Orwell. A review of computer vision techniques for the analysis of urban traffic. *IEEE Transactions on Intelligent Transportation Systems*, 12(3):920–939, 2011.

- 27) D. Zhang, Q. Xiao, J. Wang, and K. Li, "Driver curve speed model and its application to ACC speed control in curved roads," *International Journal of Automotive Technology*, vol. 14, no. 2, pp. 241–247, 2013.
- 28) A. Eskandarian, "Fundamentals of Driver Assistance," in *Handbook of Intelligent Vehicles*, A. Eskandarian, Ed. London: Springer, pp. 491–535, 2012.
- 29) W. Yang, Y. Gao, and L. Cao. Trasmil: A local anomaly detection framework based on trajectory segmentation and multi-instance learning. *Computer Vision and Image Understanding*, 117(10):1273–1286, 2013.
- 30) H. Liu, S. Chen, and N. Kubota. Intelligent video systems and analytics: A survey. *IEEE Transactions on Industrial Informatics*, 9(3):1222–1233, Aug 2013.
- 31) S. Salehinia, A. Ghaffari, A. Khodayari, M. N. Khajavi, and F. Alimardani, "Modelling and controlling of car-following behavior in real traffic flow using ARMAX identification and Model Predictive Control," *Int.J Automot*, vol. 17, no. 3, pp. 535–547, 2016.
- 32) L. E. Baum and T. Petrie. Statistical inference for probabilistic functions of finite state markov chains. *The annals of mathematical statistics*, 37(6):1554–1563, 1966.
- 33) S. Bengio. Statistical machine learning from data: Gaussian mixture models. Lectures, 2006.
- 34) I. Jolliffe. Principal component analysis. In *International encyclopedia of statistical science*, pages 1094–1096. Springer, 2011.
- 35) M. A. Hearst, S. T. Dumais, E. Osuna, J. Platt, and B. Scholkopf. Support vector machines. *IEEE Intelligent Systems and their applications*, 13(4):18–28, 1998.
- 36) A. Wahab, C. Quek, C. K. Tan, and K. Takeda, "Driving Profile Modeling and Recognition Based on Soft Computing Approach," *IEEE Transactions on Neural Networks*, vol. 20, no. 4, pp. 563–582, 2009.
- 37) M. Hasan, J. Choi, J. Neumann, A. K. Roy-Chowdhury, and L. S. Davis. Learning temporal regularity in video sequences. In *CVPR*, 2016.
- 38) I. Goodfellow, Y. Bengio, A. Courville, and Y. Bengio. *Deep learning*, volume 1. MIT press Cambridge, 2016.
- 39) J. S. Wijnands, J. Thompson, G. D. P. A. Aschwanden, and M. Stevenson, "Identifying behavioural change among drivers using Long Short-Term Memory recurrent neural networks," *Transportation Research Part F: Traffic Psychology and Behaviour*, vol. 53, pp. 34–49, Feb. 2018.
- 40) N. Patil and P. K. Biswas. Global abnormal events detection in surveillance video a hierarchical approach. In *ISED*, 2016.
- 41) S. Lee, H. G. Kim, and Y. M. Ro. Stan: Spatio-temporal adversarial networks for abnormal event detection. In *ICASSP*, 2018.

【第3章の参考文献】

- 1) H, Eren., S, Makinist., E, Akin., A, Yilmaz.: Estimating Driving Behavior by a Smartphone, Proceedings of Intelligent Vehicles Symposium, pp. 234-239, 2012.
- 2) Z, Chen., J, Yu., Y, Zhu., Y, Chen., M, Li.: D3: Abnormal Driving Behaviors Detection and Identification Using Smartphone Sensors, Proceedings of 12th Annual IEEE International Conference on Sensing, Communication, and Networking, pp. 524-532, 2015.
- 3) B, Il, Kwak., J, Woo., H, K, Kim.: Know your master: Driver profiling-based anti-theft method, Annual Conference on Privacy, Security and Trust (PST), pp.1-8, 2016.
- 4) A, Girma., X, Yan., A, Homaifa: Driver identification based on vehicle telematics data using LSTM-Recurent Neural Network. arXiv preprint arXiv:1911.08030v1, 2019.
- 5) 沼田宗純, 太田賢治, 小林明夫, 小松高廣, 目黒公郎: 小型振動台による Smart Phone 内蔵加速度センサの評価試験, 生産研究, vol. 62, no.6, pp.65-70, 2010.
- 6) G, Aoude., V, Desaraju., L, H, Stephens., J, P, How.: Driver Behavior Classification at Intersections and Validation on Large Naturalistic Data Set, IEEE TITS, vol. 13, pp. 724-736, 2012.
- 7) K, Shigeta., S, Tsugawa.: Analysis of Driver Behavior at Signalized Intersections: Characteristics of Acceleration and Quantification of Dispersion, IFAC Proceedings Volumes, vol. 36, no. 14, pp. 179-184, 2003.
- 8) 鈴木理, 浜岡秀勝: 車両挙動から見る歩行者分離式信号交差点の安全性に関する研究, 土木計画学研究・論文集 vol. 24, no. 4, pp. 781-790, 2007.
- 9) 古屋秀樹, 牧村和彦, 川崎茂信, 赤羽弘和: 車載型センサーを用いた車両挙動特異地点抽出に関する基礎的研究, 土木計画学研究・論文集, vol.20, pp. 787-796, 2003.
- 10) 橋本成仁, 谷口守, 水嶋晋作, 吉城秀治: 街路空間要素が自動車走行速度に与える影響に関する研究, 土木計画学研究・論文集 vol. 27, no. 4, pp. 737-742, 2010.
- 11) 萩田賢司, 森健二: 運転者の視線を考慮した歩行者事故の分析, 土木計画学研究・論文集, vol.21, pp. 1207-1034, 2004.
- 12) 橋本裕樹, 金子正洋, 松本幸司: 運転者のヒューマンエラーに着目した交通事故発生要因の分析, 土木計画学研究・講演集, vol. 37, pp.88-92, 2008.
- 13) 周藤浩司, 藤原章正, 張峻屹: 交通事故多発区間における運転挙動特性と警告情報の提供による効果, 土木計画学研究・論文集 vol. 24, no. 4, pp. 887-894, 2007.
- 14) 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, vol. 67, no. 5, pp. I_1193-I_1205, 2011.
- 15) Y, Ming., Y, Mitani., H, Yamanaka.: An experimental analysis of driver attitudes towards stop control warning by a road-side at small junctions, Journal of Japan Society of Civil Engineers, vol. 27, no. 5, pp. 1007-1016, 2010.
- 16) 佐藤桂, 竹中邦夫, 永井正夫: 模擬市街路における無信号交差点通過行動のデータ解析

- 熟練ドライバと高齢ドライバの比較—, 自動車技術論文集, vol.45, no.2, pp.425-430, 2014.
- 17) 今井龍一, 谷口寿俊, 田中拓也: 車線単位の道路交通分析に適した大縮尺道路地図の要件に関する基礎的研究, 土木学会論文集 F3, vol.73, no.2, pp.I_398-I_408, 2017.
 - 18) 西村卓也, 石倉智樹, 小根山裕之, 鹿田成則: 街路の利用特性と接続特性の関係に関する実証分析, 土木学会論文集 D3, vol.70, no.5, I_279-I_293, 2014.
 - 19) 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.
 - 20) 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.
 - 21) 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.
 - 22) 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.
 - 23) 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.
 - 24) 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.
 - 25) 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.
 - 26) 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.

【第4章の参考文献】

- 1) T, Wakita., K, Ozawa., C, Miyajima., K, Takeda.: Parametric Versus Non-Parametric Models of Driving Behavior Signals for Driver Identification, International Conference on Audio- and Video-Based Biometric Person Authentication, 3546, pp. 739-747, 2005.
- 2) C, Miyajima., Y, Nishiwaki., K, Ozawa., T, Wakita., K, Itou., K, Takeda.: Driver Modeling Based on Driving Behavior and Its Evaluation in Driver Identification, Proc. IEEE, vol. 95, no. 2, pp. 427-437, 2007.
- 3) E, Öztürk., E, Erzin.: Driver Status Identification from Driving Behavior Signals, Digital Signal Processing for In-Vehicle Systems and Safety, pp. 31-55, 2011.

- 4) A, Wahab., C, T, Keong., H, Abut., K, Takeda.: Driver Recognition System Using FNN and Statistical Methods, *Advances for In-Vehicle and Mobile Systems*, pp.11-23, 2007.
- 5) M, N, Nor., A, Wahab.: Driver identification and driver's emotion verification using KDE and MLP neural networks, *Proceeding of the 3rd International Conference on Information and Communication Technology for the Moslem World*, pp.1-6, 2010.
- 6) H, Qian., Y, Ou., X, Wu., X, Meng., Y, Xu.: Support Vector Machine for Behavior-Based Driver Identification System, *Journal of Robotics*, pp. 1-12, 2010.
- 7) Y, Nishiwaki., K, Ozawa., T, Wakita., C, Miyajima., K, Itou., K, Takeda.: Driver Identification Based on Spectral Analysis of Driving Behavioral Signals, in *Advances for In-Vehicle and Mobile Systems*, H. Abut, J. H. L. Hansen, and K. Takeda, Eds. Boston, MA: Springer US, pp. 25–34, 2007.
- 8) A, Burton.: Driver identification and authentication with active behavior modeling, in *2016 12th International Conference on Network and Service Management (CNSM)*, Montreal, QC, Canada, pp. 388–393, 2016.
- 9) X, Meng., K, Lee., Y, Xu.: Human Driving Behavior Recognition Based on Hidden Markov Models, *Proceedings of the 2006 IEEE International Conference on Robotics and Biomimetics*, pp. 274-279, 2016.
- 10) K, Miyauchi., K, Takada.: Research on Driver Identification Method Applying Machine Learning on Driving Behavior at Intersections, *Journal of the Eastern Asia Society for Transportation Studies*, vol.13, pp.1983-1999, 2019.
- 11) 宮内弘太, 高田和幸: 交差点内の走行挙動に CNN を適用した自動車運転者の特定手法に関する研究, *交通工学論文集特集号 A*, vol.6, no.2, pp. 235-243, 2020.
- 12) A, Sathyanarayana., P, Boyraz., J, Hansen.: Driver Behavior Analysis and Route Recognition by Hidden Markov Models, *Proceedings of the 2008 IEEE International Conference on Vehicular Electronics and Safety*, pp. 276-281, 2008.
- 13) R, Chen., M, She., X, Sun., L, Kong., Y, Wu.: Driver Recognition Based on Dynamic Handgrip Pattern on Steering Wheel, in *2011 12th ACIS International Conference on Software Engineering, Artificial Intelligence, Networking and Parallel/Distributed Computing*, Sydney, Australia, pp. 107–112, 2011.
- 14) H, Tokutake., Y, Sugimoto., T, Shirakata.: Real-time identification method of driver model with steering manipulation, *International Journal of Vehicle Mechanics and Mobility*, vol. 51, no. 1, pp. 109-121, 2012.
- 15) G, Zhu., L, Zhang., P, Shen., J, Song.: Multimodal Gesture Recognition Using 3-D Convolution and Convolutional LSTM, *IEEE Access*, vol. 5, pp. 4517-4524, 2017.
- 16) 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.
- 17) 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.
 - 18) 鈴木佳輔, 相馬仁, 平松金雄: 横方向外乱入力時のドライバの操舵特性—横方向余裕時間の解析—, *自動車研究*, vol.21, no.3, pp.23-26, 1999.
 - 19) A, Girma., X, Yan., A, Homaifar.: Driver Identification Based on Vehicle Telematics Data using LSTM-Recurrent Neural Network, 2019 IEEE 31st International Conference on Tools with Artificial Intelligence (ICTAI), pp. 894-902, 2019.
 - 20) A, Cura., H, Kucijk., E, Ergen., I, B, Oksuzoglu.: Driver Profiling Using Long Short Term Memory (LSTM) and Convolutional Neural Network (CNN) Methods, *IEEE TRANSACTIONS ON INTELLIGENT TRANSPORTATION SYSTEMS*, pp. 1-1, 2020.

【第5章の参考文献】

- 1) 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.
- 2) 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.
- 3) 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.
- 4) E, Lampiri.: Sensor Anomaly Detection and Recovery in a Nonlinear Autonomous Ground Vehicle Model, *I2017 11th Asian Control Conference (ASCC)*, pp.430-435, 2017.
- 5) 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.
- 6) 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.
- 7) 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.
- 8) 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.
- 9) R, Hamada., T, Kubo., K, Ikeda., Z. Zhang., T, Shibata., T, Bando., K, Hitomi., M, Egawa.: Modeling and Prediction of Driving Behaviors Using a Nonparametric Bayesian Method With AR Models, *IEEE Transactions on Intelligent Vehicles*, vol.1, no.2, 2016.
- 10) 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.

- 11) H, Eren., S, Makinist., E, Akin., A, Yilmaz.: Estimating Driving Behavior by a Smartphone, Proceedings of Intelligent Vehicles Symposium, pp. 234-239, 2012.
- 12) R, Fu., H, Wang., W, Zhao.: Dynamic driver fatigue detection using hidden Markov model in real driving condition, Expert Systems with Applications, vol. 63, pp. 397-411, 2016.
- 13) 武石直也, 矢入健久, 佐藤守一, 田川貴章: 時系列パターン監視による自動車応答特性の変化検知, The 28th Annual Conference of the Japanese Society for Artificial Intelligence, 2014.
- 14) M, Matousek., M, EL-zohairy., A, Al-Momani1., F, Kargl., C, Bosch.: Detecting Anomalous Driving Behavior using Neural Networks. IEEE Intelligent Vehicles Symposium (IV), pp. 2229-2235, 2019.
- 15) Y, Li1., C, Miyajima., N, Kitaoka., K, Takeda.: Measuring Aggressive Driving Behavior Using Signals from Drive Recorders, 17th International Conference on Intelligent Transportation Systems (ITSC), pp.1886-1887, 2014.
- 16) T. Ide, S. Papadimitriou, and M. Vlachos.: Computing correlation anomaly scores using stochastic nearest neighbors. In Proc. IEEE Intl. Conf. Data Mining, pp. 523-528, 2007.
- 17) K, Meena1., A, Viji., J, J, Athanesious., V, Vaidehi.: Detecting Abnormal Event in Traffic Scenes using Unsupervised Deep Learning Approach, International Conference on Wireless Communications Signal Processing and Networking (WiSPNET), pp.355-362, 2019.
- 18) A, Dairi., F, Harrou., M, Senouci., Y, Sun.: Unsupervised obstacle detection in driving environments using deep-learning-based stereovision, Robotics and Autonomous Systems, vol.100, pp.287-301, 2018.
- 19) 宮内弘太, 高田和幸: 交差点内の走行挙動に深層学習を適用した高齢運転者の異常運転検知手法に関する研究, 交通工学研究会発表論文集, vol.40, pp.467-474, 2020.

【第6章の参考文献】

- 1) 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.
- 2) 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.
- 3) 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.
- 4) A, Girma., X, Yan., A, Homaifar.: Driver Identification Based on Vehicle Telematics Data using LSTM-Recurrent Neural Network, 2019 IEEE 31st International Conference on Tools with Artificial Intelligence (ICTAI), pp. 894-902, 2019.
- 5) A, Cura., H, Kucijk., E, Ergen., I, B, Oksuzoglu.: Driver Profiling Using Long Short Term

Memory (LSTM) and Convolutional Neural Network (CNN) Methods, IEEE TRANSACTIONS ON INTELLIGENT TRANSPORTATION SYSTEMS, pp. 1-1, 2020.

- 6) A, Dairi., F, Harrou., M, Senouci., Y, Sun.: Unsupervised obstacle detection in driving environments using deep-learning-based stereovision, Robotics and Autonomous Systems, vol.100, pp.287-301, 2018.
- 7) H, Eren., S, Makinist., E, Akin., A, Yilmaz.: Estimating Driving Behavior by a Smartphone, Proceedings of Intelligent Vehicles Symposium, pp. 234-239, 2012.
- 8) M, Matousek., M, EL-zohairy., A, Al-Momani1., F, Kargl., C, Bosch.: Detecting Anomalous Driving Behavior using Neural Networks. IEEE Intelligent Vehicles Symposium (IV), pp. 2229-2235, 2019.

【第7章の参考文献】

- 1) 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.
- 2) 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.
- 3) H, Y, Ngan., W, Liu.: Density-based Outlier Detection by Local Outlier Factor on Large scase Traffic Data, IS&T International Symposium on Electronic Imaging 2016 Image Processing: Machine Vision Applications IX, pp. 1-4, 2016.
- 4) A, Girma., X, Yan., A, Homaifar.: Driver Identification Based on Vehicle Telematics Data using LSTM-Recurrent Neural Network, 2019 IEEE 31st International Conference on Tools with Artificial Intelligence (ICTAI), pp. 894-902, 2019.
- 5) A, Cura., H, Kucijk., E, Ergen., I, B, Oksuzoglu.: Driver Profiling Using Long Short Term Memory (LSTM) and Convolutional Neural Network (CNN) Methods, IEEE TRANSACTIONS ON INTELLIGENT TRANSPORTATION SYSTEMS, pp. 1-1, 2020.
- 6) A, Dairi., F, Harrou., M, Senouci., Y, Sun.: Unsupervised obstacle detection in driving environments using deep-learning-based stereovision, Robotics and Autonomous Systems, vol.100, pp.287-301, 2018.
- 7) H, Eren., S, Makinist., E, Akin., A, Yilmaz.: Estimating Driving Behavior by a Smartphone, Proceedings of Intelligent Vehicles Symposium, pp. 234-239, 2012.
- 8) M, Matousek., M, EL-zohairy., A, Al-Momani1., F, Kargl., C, Bosch.: Detecting Anomalous Driving Behavior using Neural Networks. IEEE Intelligent Vehicles Symposium (IV), pp. 2229-2235, 2019.

付録（本論で割愛した分析結果）

表 1 被験者ごとの個人間異常運転検知による検知精度と検知タイミング
(a) 閾値=1σ

ID	シナリオ1		シナリオ2		シナリオ3		シナリオ4		シナリオ5		シナリオ6	
	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)
1	100	0.9	100	1.2	100	0.4	100	2.4	100	1.6	99.05	1.2
2	100	1.0	100	1.2	100	0.5	97.68	2.3	98.36	1.1	95.39	1.2
3	100	1.1	100	1.3	100	0.5	100	2.6	96.84	1.2	95.4	1.4
4	100	1.1	100	1.3	100	0.5	100	2.6	96.84	1.2	96.01	1.4
5	100	1.0	100	1.5	100	0.4	99.57	2.2	98.36	1.3	97.2	1.3
6	99.35	1.0	100	1.9	100	0.7	98.05	2.2	99.29	1.1	94.27	1.2
7	100	1.0	100	1.1	100	0.7	96.3	2.7	97.47	1.8	95.64	1.4
8	100	0.7	100	1.4	100	0.5	99.65	2.3	99.1	1.2	98.27	1.3
9	100	1.1	100	1.3	100	0.5	100	2.6	97.47	1.2	95.09	1.4
10	100	2.1	100	2.4	100	0.8	95.56	2.6	100	2.2	85.96	1.6
11	100	1.3	100	1.6	100	0.3	99.56	2.9	100	1.7	96.47	1.6
12	100	2.8	100	1.5	100	1.0	100	3.2	93.75	3.0	96.16	2.0
13	99.08	1.7	100	1.3	100	0.7	98.47	3.0	95.79	2.0	94.72	1.7
14	100	2.0	100	1.3	100	0.9	96.3	3.1	100	2.4	93.18	1.8
15	100	2.4	100	1.2	100	0.9	99.03	2.9	97.48	2.5	93.81	1.6
16	100	3.0	100	1.2	100	0.8	99.57	2.2	100	2.0	92.71	1.8
17	100	2.8	100	1.1	100	0.9	98.05	2.6	100	2.3	99.13	1.7
18	100	3.1	100	1.0	100	0.9	98.31	2.2	98.88	2.2	94.77	1.7
19	100	2.8	100	1.4	100	0.9	99.3	2.3	99.13	1.8	99.13	1.7
20	100	3.0	100	1.1	100	0.9	98.05	2.4	96.72	1.9	92.71	1.8
21	99.53	2.0	100	1.2	100	0.8	97.67	2.4	100	2.0	94.29	1.6
22	100	1.9	100	1.4	100	0.7	98.31	2.8	98.88	2.4	96.14	1.6
23	98.81	1.2	100	1.5	100	0.7	97.93	3.1	99.13	1.4	94.04	1.7
24	100	1.8	100	1.5	100	0.8	97.67	2.8	95	2.2	92.74	1.7
25	100	2.5	100	1.0	100	0.7	95.17	2.8	100	2.2	94.42	1.5
26	100	2.4	100	1.5	100	0.7	96.76	2.6	97.06	2.6	91.14	1.4
27	98.85	2.2	100	1.5	100	0.8	98.27	2.6	99.39	1.9	95.61	1.4
28	100	1.8	100	1.3	100	0.7	96.98	2.6	96.72	1.7	91.97	1.4
29	100	2.1	100	1.2	100	0.4	96.69	2.4	97.66	2.2	96.14	1.3
30	100	1.4	100	1.3	100	0.4	99.3	2.3	96.58	1.6	95.71	1.3

(b) 閾値=2σ

ID	シナリオ1		シナリオ2		シナリオ3		シナリオ4		シナリオ5		シナリオ6	
	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)
1	99.53	1.2	100	1.5	100	0.6	96.91	2.6	95.96	1.9	89.35	1.4
2	98.01	1.3	100	1.4	100	0.6	94.37	2.5	91.95	1.4	85.88	1.4
3	97.22	1.3	100	1.5	100	0.6	94.56	2.8	90.51	1.4	87.73	1.5
4	97.22	1.3	100	1.6	100	0.7	94.56	2.8	89.24	1.4	86.2	1.6
5	98.48	1.2	100	1.8	100	0.6	95.24	2.5	90.71	1.5	89.6	1.5
6	98.06	1.3	100	2.2	100	0.9	94.92	2.5	92.14	1.4	89.31	1.3
7	94.47	1.2	100	1.3	100	0.9	90.12	2.9	91.58	2.1	90.41	1.5
8	99.18	0.9	100	1.6	100	0.6	95.6	2.5	92.79	1.4	94.81	1.4
9	97.22	1.3	100	1.5	100	0.7	94.56	2.8	89.24	1.4	87.42	1.6
10	98.57	2.4	100	2.6	100	0.9	84.44	2.8	95	2.5	63.16	1.8
11	96.55	1.5	100	1.9	100	0.5	92.04	3.2	88.68	2.0	80.39	1.7
12	96.2	3.1	100	1.7	100	1.1	99.07	3.5	87.5	3.2	94.37	2.2
13	97.25	2.0	100	1.6	100	0.9	91.19	3.3	77.89	2.2	86.8	1.8
14	96.4	2.2	100	1.5	100	1.0	89.81	3.4	82.11	2.7	89.2	2.0
15	100	2.6	97.73	1.4	100	1.0	95.86	3.2	79.83	2.7	83.63	1.8
16	100	3.3	99.49	1.5	100	0.9	96.19	2.5	90.62	2.3	85.83	2.0
17	100	3.0	100	1.4	100	1.0	95.86	2.8	93.59	2.5	95.06	1.8
18	100	3.3	99.52	1.3	100	1.0	94.93	2.5	89.5	2.4	83.01	1.8
19	100	3.0	98.72	1.6	100	1.0	97.11	2.6	89.75	2.1	95.06	1.8
20	100	3.3	100	1.4	100	1.0	94.67	2.6	90.31	2.1	85.83	1.9
21	95.28	2.2	98.14	1.5	100	0.9	95.48	2.7	94.11	2.3	91.32	1.8
22	98.68	2.2	100	1.7	100	0.9	89.47	3.1	84.92	2.7	89.01	1.7
23	95.24	1.4	100	1.7	100	0.8	92.31	3.3	82.1	1.6	83.42	1.8
24	99.42	2.1	100	1.7	100	1.0	91.07	3.1	75	2.4	81.98	1.8
25	97.98	2.7	100	1.3	100	0.8	90.34	3.1	92.86	2.4	86.8	1.6
26	100	2.6	100	1.7	100	0.9	86.69	2.8	89.71	2.9	78.79	1.6
27	95.98	2.4	97.14	1.7	100	1.0	91.04	2.8	78.18	2.2	78.05	1.6
28	98.02	2.1	96.67	1.5	100	0.8	85.96	2.8	80.33	2.0	76.61	1.6
29	98.06	2.4	100	1.5	100	0.6	91.3	2.6	90.62	2.4	90.82	1.5
30	97.64	1.7	100	1.5	100	0.6	95.34	2.6	89.74	1.9	90.02	1.5

(c) 閾値=3σ

ID	シナリオ1		シナリオ2		シナリオ3		シナリオ4		シナリオ5		シナリオ6	
	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)
1	99.53	1.4	100	1.8	100	0.8	96.29	2.9	94.44	2.1	94.68	1.6
2	97.35	1.6	90.91	1.7	100	0.8	94.7	2.8	88.48	1.6	89.63	1.5
3	98.89	1.5	100	1.8	100	0.9	93.54	3.0	91.77	1.7	86.5	1.7
4	98.89	1.5	100	1.8	100	0.8	93.54	3.0	89.87	1.7	91.41	1.8
5	99.49	1.5	100	2.0	100	0.7	95.24	2.7	95.63	1.8	93.2	1.6
6	98.71	1.5	100	2.4	100	0.9	98.05	2.7	94.29	1.7	93.51	1.4
7	96.17	1.4	100	1.6	100	1.1	93.52	3.1	89	2.3	90.41	1.6
8	98.97	1.1	100	1.9	100	0.7	97.15	2.7	85.59	1.7	93.24	1.6
9	98.89	1.6	100	1.8	100	0.9	93.54	3.1	90.51	1.7	86.5	1.7
10	97.14	2.6	100	2.8	100	1.0	93.33	3.0	90	2.7	78.95	2.0
11	93.1	1.8	100	2.1	100	0.6	90.27	3.5	81.13	2.2	80	1.9
12	98.73	3.4	100	1.9	100	1.2	96.26	3.8	87.5	3.5	92.33	2.4
13	96.33	2.2	100	1.8	100	1.0	93.1	3.5	84.21	2.4	90.76	1.9
14	95.5	2.5	100	1.8	100	1.2	89.81	3.6	77.89	2.9	90.91	2.1
15	100	2.9	96.59	1.7	100	1.1	95.99	3.4	85.71	3.0	81.86	1.9
16	100	3.6	99.06	1.8	100	1.0	90.87	2.7	88.04	2.5	86.64	2.0
17	100	3.3	99.63	1.7	100	1.3	91	3.1	90.12	2.7	94.48	2.0
18	100	3.6	99.09	1.5	100	1.2	89.61	2.8	85.17	2.7	79.74	2.0
19	100	3.3	98.29	1.9	100	1.1	94.97	2.9	86.28	2.3	94.48	2.0
20	100	3.5	99.63	1.6	100	1.1	89.81	2.9	87.33	2.3	86.64	2.0
21	96.7	2.5	97.47	1.7	100	1.0	90.16	2.9	90.64	2.5	87.9	2.0
22	97.47	2.4	100	2.0	100	1.0	89.04	3.4	88.83	2.9	85.02	1.9
23	91.27	1.7	100	2.0	100	1.0	92.9	3.5	74.24	1.8	79.53	1.9
24	98.21	2.4	100	2.0	100	1.1	91.84	3.4	75	2.7	75.94	2.0
25	95.96	2.9	100	1.5	100	1.0	93.1	3.3	85.71	2.7	90.86	1.7
26	100	2.9	100	2.0	100	1.0	93.88	3.0	88.97	3.1	80.19	1.6
27	96.55	2.7	100	2.0	100	1.2	91.51	3.1	72.73	2.4	81.73	1.7
28	96.04	2.3	96.67	1.8	100	1.0	90.71	3.1	80.33	2.3	72.6	1.8
29	100	2.7	100	1.7	100	0.7	95.44	2.8	92.97	2.6	94.2	1.7
30	95.67	1.9	100	1.8	100	0.7	92.2	2.8	80.34	2.1	86.7	1.5

表 2 被験者ごとによる分析手法別の検知精度と検知タイミング

(a) 閾値=1σ (LOF)

ID	シナリオ1		シナリオ2		シナリオ3		シナリオ4		シナリオ5		シナリオ6	
	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)
1	100	0.9	100	1.2	100	0.4	98.14	2.4	98.99	1.6	86.31	1.2
2	100	1.0	100	1.2	100	0.5	98.01	2.3	93.12	1.1	89.34	1.2
3	100	1.1	100	1.3	95.45	0.5	96.94	2.6	94.94	1.2	85.58	1.4
4	100	1.1	100	1.3	95.45	0.5	96.94	2.6	94.94	1.2	86.5	1.4
5	100	1.0	100	1.5	100	0.4	97.4	2.2	95.63	1.3	92	1.3
6	99.35	1.0	100	1.9	100	0.7	97.27	2.2	95	1.1	93.13	1.2
7	99.57	1.0	100	1.1	100	0.7	97.22	2.7	92	1.8	95.06	1.4
8	100	0.7	100	1.4	100	0.5	99.14	2.3	98.65	1.2	97.96	1.3
9	100	1.1	100	1.3	95.45	0.5	96.94	2.6	94.94	1.2	86.2	1.4
10	100	2.1	100	2.4	100	0.8	95.56	2.6	93.33	2.2	85.96	1.6
11	98.28	1.3	100	1.6	100	0.3	98.23	2.9	98.11	1.7	85.1	1.6
12	100	2.8	100	1.5	100	1.0	98.13	3.2	89.58	3.0	93.61	2.0
13	98.17	1.7	100	1.3	100	0.7	98.08	3.0	93.68	2.0	96.7	1.7
14	100	2.0	100	1.3	100	0.9	98.15	3.1	95.79	2.4	97.16	1.8
15	100	2.4	100	1.2	96.15	0.9	97.38	2.9	87.39	2.5	92.04	1.6
16	100	3.0	100	1.2	100	0.8	100	2.2	100	2.0	95.14	1.8
17	100	2.8	100	1.1	100	0.9	97.93	2.6	97.93	2.3	97.67	1.7
18	100	3.1	100	1.0	100	0.9	100	2.2	100	2.2	96.73	1.7
19	100	2.8	100	1.4	100	0.9	98.9	2.3	98.9	1.8	97.67	1.7
20	100	3.0	100	1.1	100	0.9	95.37	2.4	95.37	1.9	95.14	1.8
21	97.64	2.0	100	1.2	100	0.8	100	2.4	100	2.0	92.24	1.6
22	100	1.9	100	1.4	100	0.7	95.37	2.8	92.74	2.4	90.22	1.6
23	98.41	1.2	100	1.5	100	0.7	97.93	3.1	93.01	1.4	98.19	1.7
24	100	1.8	100	1.5	100	0.8	97.86	2.8	95	2.2	92.62	1.7
25	100	2.5	100	1.0	100	0.7	93.79	2.8	92.86	2.2	88.83	1.5
26	100	2.4	100	1.5	100	0.7	96.04	2.6	82.35	2.6	89.74	1.4
27	100	2.2	100	1.5	100	0.8	98.9	2.6	99.39	1.9	96.2	1.4
28	99.5	1.8	100	1.3	100	0.7	95.25	2.6	85.25	1.7	93.37	1.4
29	100	2.1	100	1.2	100	0.4	97.93	2.4	97.66	2.2	95.05	1.3
30	99.61	1.4	100	1.3	100	0.4	97.32	2.3	88.89	1.6	92.06	1.3

(b) 閾値=2σ (LOF)

ID	シナリオ1		シナリオ2		シナリオ3		シナリオ4		シナリオ5		シナリオ6	
	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)
1	84.43	1.1	77.78	1.4	100	0.6	54.64	2.6	83.84	1.8	77.35	1.3
2	84.11	1.2	72.73	1.4	100	0.6	53.97	2.5	86.71	1.4	80.38	1.3
3	83.89	1.3	78.12	1.6	81.82	0.7	56.12	2.8	70.25	1.5	76.62	1.6
4	83.89	1.3	75	1.5	86.36	0.7	56.12	2.8	70.89	1.5	77.54	1.5
5	85.79	1.3	100	1.8	85.71	0.6	70.13	2.5	66.12	1.5	83.04	1.4
6	88.39	1.3	100	2.1	86.67	0.8	61.72	2.4	72.86	1.4	84.17	1.3
7	85.11	1.2	90	1.3	69.23	0.8	62.96	2.9	85.59	2.0	86.1	1.6
8	93.4	0.9	90	1.7	75	0.6	74.2	2.5	75.23	1.4	89	1.4
9	83.89	1.3	78.12	1.5	90.91	0.7	56.12	2.8	70.25	1.4	77.24	1.6
10	68.57	2.3	100	2.6	83.33	0.9	48.89	2.8	56.67	2.5	77	1.8
11	75.86	1.5	82.35	1.9	80	0.4	55.31	3.2	64.15	2.0	76.14	1.8
12	78.48	3.1	85.71	1.7	66.67	1.1	46.73	3.5	31.25	3.2	84.65	2.2
13	63.3	2.0	77.42	1.6	84.62	0.9	58.62	3.2	49.47	2.2	87.74	1.8
14	79.28	2.3	69.23	1.5	91.67	1.0	54.63	3.4	65.26	2.6	88.2	2.0
15	80	2.6	78.41	1.5	84.62	1.0	52.9	3.2	47.9	2.7	83.08	1.8
16	85	3.3	99.49	1.5	76.47	1.0	96.62	2.5	90.62	2.3	86.18	1.9
17	100	3.0	100	1.4	90	1.0	95.74	2.8	91.52	2.5	88.71	1.8
18	90.91	3.3	99.52	1.3	100	1.0	96.62	2.5	90.62	2.4	87.77	1.8
19	100	3.1	98.72	1.6	100	1.0	96.71	2.6	89.52	2.0	88.71	1.9
20	85	3.3	100	1.4	88.89	1.1	91.99	2.6	88.96	2.1	86.18	1.9
21	70.75	2.3	98.14	1.5	87.5	0.9	97.81	2.7	94.11	2.3	83.28	1.8
22	98.68	2.2	87.5	1.6	100	0.8	56.6	3.1	52.51	2.6	81.26	1.7
23	74.6	1.4	84.62	1.7	76.92	0.9	55.33	3.4	57.64	1.7	89.23	1.8
24	99.42	2.1	79.59	1.7	100	1.0	53.2	3.1	51.67	2.5	83.66	1.8
25	78.79	2.7	92.31	1.3	93.33	0.8	60	3.0	71.43	2.4	79.87	1.7
26	75	2.6	91.43	1.7	100	0.8	58.63	2.8	42.65	2.9	80.78	1.6
27	77.01	2.5	85.71	1.7	100	1.0	54.09	2.9	58.18	2.1	87.24	1.6
28	73.27	2.1	73.33	1.5	100	0.8	49.03	2.8	50.82	1.9	84.41	1.5
29	78.71	2.4	86.84	1.5	100	0.6	56.63	2.6	60.94	2.4	86.09	1.5
30	81.89	1.6	87.1	1.5	100	0.6	64.49	2.6	61.97	1.9	83.1	1.4

(c) 閾値=3σ (LOF)

ID	シナリオ1		シナリオ2		シナリオ3		シナリオ4		シナリオ5		シナリオ6	
	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)
1	83.45	1.4	76.52	1.7	96.31	0.7	51.45	2.9	81.38	2.1	69.44	1.6
2	79.60	1.5	72.00	1.7	97.83	0.9	44.23	2.8	85.40	1.6	79.07	1.5
3	78.73	1.5	77.81	1.8	76.27	0.8	51.88	3.0	68.94	1.7	75.31	1.8
4	80.58	1.5	74.18	1.7	84.39	0.9	55.00	3.1	69.58	1.7	76.23	1.7
5	80.32	1.5	97.15	2.0	80.98	0.8	68.31	2.8	64.81	1.8	81.73	1.6
6	87.01	1.6	99.18	2.4	85.10	1.0	56.01	2.7	71.55	1.7	82.86	1.5
7	83.95	1.5	88.31	1.6	69.18	1.0	54.51	3.2	84.28	2.3	84.79	1.7
8	87.98	1.2	89.53	2.0	71.15	0.7	70.40	2.8	73.92	1.7	87.69	1.6
9	82.86	1.5	75.44	1.8	88.48	0.9	49.98	3.0	68.94	1.7	75.93	1.8
10	61.87	2.6	99.27	2.9	82.17	1.1	43.32	3.1	55.36	2.7	75.69	1.9
11	71.96	1.8	79.84	2.1	77.51	0.6	49.35	3.4	62.84	2.2	74.83	1.9
12	75.01	3.4	82.37	1.9	65.94	1.3	41.29	3.7	29.94	3.5	83.34	2.4
13	57.04	2.3	75.52	1.9	84.22	1.0	52.28	3.5	48.16	2.4	86.43	1.9
14	76.18	2.5	68.26	1.8	89.85	1.2	48.00	3.6	63.95	3.0	86.89	2.1
15	76.88	2.9	75.44	1.7	82.79	1.2	44.71	3.5	46.59	3.0	81.77	1.8
16	84.66	3.5	97.02	1.7	70.64	1.0	94.21	2.7	89.31	2.6	84.87	2.1
17	90.54	3.3	97.74	1.7	89.00	1.2	88.67	3.1	90.21	2.8	87.40	2.0
18	84.03	3.6	98.55	1.5	94.90	1.2	89.08	2.7	89.31	2.7	86.46	2.0
19	95.08	3.3	96.99	1.8	96.83	1.1	93.12	2.8	88.21	2.3	87.40	2.0
20	80.59	3.5	98.61	1.6	84.48	1.2	90.80	2.8	87.65	2.4	84.87	2.2
21	61.38	2.5	94.44	1.8	85.51	1.1	90.53	2.9	92.80	2.6	81.97	1.9
22	92.26	2.4	85.34	1.9	97.03	1.1	56.41	3.4	51.20	2.9	79.95	1.8
23	71.64	1.7	83.62	2.0	72.41	1.1	52.67	3.6	56.33	1.9	87.92	2.0
24	92.92	2.3	79.23	2.0	99.04	1.1	50.74	3.3	50.36	2.6	82.35	2.0
25	69.81	2.9	89.12	1.6	91.59	0.9	58.72	3.2	70.12	2.6	78.56	1.7
26	67.21	2.9	90.30	1.9	95.50	1.0	51.54	3.1	41.34	3.1	79.47	1.8
27	75.59	2.7	81.96	2.0	95.31	1.1	47.02	3.1	56.87	2.4	85.93	1.6
28	72.41	2.4	70.45	1.8	94.61	1.0	47.02	3.1	49.51	2.3	83.10	1.7
29	71.19	2.6	85.61	1.7	99.50	0.8	54.62	2.9	59.63	2.7	84.78	1.7
30	78.53	1.9	85.06	1.8	99.65	0.7	58.42	2.9	60.66	2.1	81.79	1.6

(d) 閾値=1σ (IF)

ID	シナリオ1		シナリオ2		シナリオ3		シナリオ4		シナリオ5		シナリオ6	
	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)
1	88.68	0.9	94.44	1.2	83.33	0.4	89.49	2.4	89.7	1.6	84.18	1.2
2	82.78	1.0	100	1.2	75	0.5	82.38	2.3	81.32	1.1	84.41	1.2
3	76.67	1.1	100	1.3	81.82	0.5	82.86	2.6	82.03	1.2	86.13	1.4
4	76.67	1.1	100	1.3	63.64	0.5	80.14	2.6	82.03	1.2	88.28	1.4
5	69.54	1.0	100	1.5	85.71	0.4	81.44	2.2	86.28	1.3	75.6	1.3
6	78.06	1.0	100	1.9	86.67	0.7	80.86	2.2	87.86	1.1	86.11	1.2
7	76.6	1.0	95	1.1	81.54	0.7	88.89	2.7	90.32	1.8	83.95	1.4
8	97.11	0.7	98.57	1.4	75	0.5	89.46	2.3	84.86	1.2	86.07	1.3
9	76.67	1.1	100	1.3	80	0.5	82.52	2.6	79.49	1.2	88.59	1.4
10	64.29	2.1	100	2.4	86.67	0.8	86.67	2.6	75	2.2	83.51	1.6
11	77.59	1.3	94.12	1.6	80	0.3	88.5	2.9	86.04	1.7	85.69	1.6
12	64.56	2.8	100	1.5	82.22	1.0	85.23	3.2	91.25	3.0	81.76	2.0
13	54.13	1.7	96.77	1.3	80.77	0.7	87.89	3.0	93.33	2.0	87.16	1.7
14	70.27	2.0	76.92	1.3	83.33	0.9	85.37	3.1	87.37	2.4	90.8	1.8
15	100	2.4	100	1.2	86.92	0.9	88.54	2.9	86.89	2.5	92.21	1.6
16	90	3.0	98.57	1.2	81.76	0.8	93.24	2.2	91.34	2.0	88.5	1.8
17	100	2.8	97.96	1.1	80	0.9	88.44	2.6	88.28	2.3	87.15	1.7
18	100	3.1	96.67	1.0	80	0.9	91.24	2.2	93.44	2.2	73.06	1.7
19	100	2.8	100	1.4	81.94	0.9	95.47	2.3	92.44	1.8	83.95	1.7
20	90	3.0	98.57	1.1	82.22	0.9	91.66	2.4	88.77	1.9	88.12	1.8
21	60.85	2.0	100	1.2	87.5	0.8	87.47	2.4	96.32	2.0	76.78	1.6
22	76.67	1.9	91.07	1.4	83.64	0.7	83.99	2.8	83.52	2.4	82.44	1.6
23	73.41	1.2	92.31	1.5	85.38	0.7	87.56	3.1	85.9	1.4	90.47	1.7
24	76.67	1.8	97.96	1.5	81.54	0.8	93.01	2.8	88.33	2.2	92.7	1.7
25	66.67	2.5	84.62	1.0	86.67	0.7	91.72	2.8	90	2.2	84.21	1.5
26	62.5	2.4	100	1.5	85	0.7	82.3	2.6	89.71	2.6	87.93	1.4
27	72.41	2.2	91.43	1.5	80	0.8	84.25	2.6	86.32	1.9	88.39	1.4
28	72.28	1.8	96.67	1.3	83.33	0.7	82.66	2.6	82.74	1.7	89.95	1.4
29	76.13	2.1	100	1.2	75	0.4	90.61	2.4	93.12	2.2	90.41	1.3
30	72.05	1.4	96.77	1.3	87.5	0.4	85.65	2.3	89.4	1.6	91.67	1.3

(e) 閾値=2σ (IF)

ID	シナリオ1		シナリオ2		シナリオ3		シナリオ4		シナリオ5		シナリオ6	
	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)
1	87.54	1.1	92.26	1.4	80.78	0.6	86.74	2.6	88.05	1.9	79.36	1.4
2	82.01	1.2	96.75	1.5	73.53	0.6	75.72	2.5	74.25	1.4	83.16	1.4
3	75.32	1.3	98.70	1.6	81.53	0.7	75.47	2.8	74.98	1.4	75.19	1.6
4	75.12	1.3	97.32	1.6	62.63	0.7	74.98	2.8	80.73	1.4	82.18	1.6
5	68.58	1.3	96.27	1.8	84.18	0.6	77.97	2.5	78.57	1.5	63.85	1.5
6	78.02	1.3	98.06	2.1	83.92	0.9	79.71	2.5	83.70	1.4	82.18	1.3
7	76.42	1.2	91.32	1.3	79.39	0.9	85.60	2.9	84.23	2.0	80.62	1.6
8	95.82	0.9	94.72	1.6	72.05	0.6	85.35	2.6	78.26	1.4	80.70	1.4
9	75.50	1.3	97.26	1.5	79.28	0.7	78.90	2.8	71.22	1.4	80.61	1.6
10	63.77	2.3	99.16	2.7	85.43	0.9	78.82	2.8	70.04	2.5	77.88	1.8
11	75.74	1.5	90.43	1.9	79.16	0.5	85.47	3.2	85.66	2.0	74.23	1.8
12	64.48	3.1	96.53	1.7	80.43	1.2	79.83	3.4	88.22	3.2	69.77	2.1
13	53.34	1.9	93.12	1.6	78.97	0.9	83.22	3.2	85.58	2.2	80.16	1.9
14	69.06	2.3	76.44	1.5	81.39	1.0	82.21	3.3	83.22	2.7	79.86	2.0
15	99.37	2.6	98.09	1.4	85.79	1.0	87.53	3.1	85.49	2.8	84.20	1.8
16	89.89	3.3	95.49	1.5	79.67	0.9	90.60	2.5	89.63	2.3	76.77	1.9
17	99.93	3.0	95.88	1.3	77.79	1.0	84.74	2.9	87.43	2.5	77.99	1.8
18	98.83	3.4	96.11	1.2	77.35	1.1	83.39	2.4	84.15	2.5	64.08	1.8
19	99.21	3.0	98.11	1.6	80.01	1.0	92.72	2.6	82.67	2.0	79.28	1.8
20	88.27	3.2	96.11	1.4	80.74	1.0	84.97	2.6	84.75	2.1	76.35	1.9
21	58.98	2.3	96.77	1.5	85.21	0.9	84.47	2.6	89.39	2.3	71.19	1.7
22	76.62	2.2	90.12	1.6	81.52	0.8	76.03	3.1	75.34	2.7	79.38	1.7
23	71.88	1.4	91.10	1.7	84.93	0.8	86.07	3.3	82.49	1.6	86.90	1.8
24	76.41	2.1	96.87	1.7	78.83	1.0	91.05	3.1	83.54	2.4	84.06	1.8
25	64.86	2.7	82.33	1.3	86.59	0.8	88.61	3.0	81.69	2.4	73.22	1.7
26	60.84	2.6	99.19	1.7	82.08	0.9	80.29	2.9	80.48	2.8	80.45	1.5
27	70.46	2.4	91.23	1.7	77.82	1.0	82.97	2.8	82.97	2.2	78.31	1.6
28	71.42	2.1	93.05	1.5	81.39	0.8	82.24	2.8	72.90	2.0	86.93	1.6
29	75.58	2.4	99.15	1.5	74.74	0.6	85.39	2.7	87.05	2.5	81.36	1.5
30	71.45	1.6	94.69	1.5	87.21	0.5	82.10	2.6	85.67	1.9	80.27	1.4

(f) 閾値=3σ (IF)

ID	シナリオ1		シナリオ2		シナリオ3		シナリオ4		シナリオ5		シナリオ6	
	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)
1	85.26	1.4	89.95	1.7	80.17	0.7	80.78	2.9	86.87	2.1	69.32	1.6
2	78.82	1.5	91.65	1.7	66.09	0.8	71.86	2.8	69.87	1.6	78.78	1.5
3	72.13	1.5	94.73	1.8	74.30	0.8	71.48	3.1	70.60	1.7	70.81	1.8
4	71.93	1.5	93.76	1.8	56.43	0.8	72.10	3.1	76.35	1.7	77.80	1.8
5	65.39	1.6	94.29	2.0	84.14	0.7	66.07	2.7	74.19	1.8	59.47	1.6
6	74.83	1.6	94.75	2.4	83.75	1.0	71.85	2.7	79.32	1.6	77.80	1.5
7	73.23	1.5	85.84	1.6	72.49	0.9	78.10	3.1	79.85	2.2	76.24	1.7
8	92.63	1.1	91.21	1.9	64.04	0.7	82.32	2.8	73.88	1.7	76.32	1.6
9	72.31	1.6	96.90	1.8	78.26	0.8	75.51	3.0	66.84	1.7	76.23	1.7
10	60.58	2.6	99.06	2.9	78.23	1.1	76.45	3.1	65.66	2.7	73.50	2.0
11	72.55	1.7	88.58	2.1	72.39	0.6	82.39	3.4	81.28	2.2	69.85	1.9
12	61.29	3.3	96.32	2.0	77.46	1.2	70.87	3.7	83.84	3.4	65.39	2.4
13	50.15	2.2	89.98	1.9	73.24	1.0	77.75	3.4	81.20	2.4	75.78	1.9
14	65.87	2.5	74.04	1.8	79.46	1.2	75.85	3.6	78.84	3.0	75.48	2.1
15	96.18	2.8	95.10	1.7	79.38	1.2	81.68	3.4	81.11	3.0	79.82	1.9
16	86.70	3.6	93.75	1.8	75.17	1.1	80.17	2.8	85.25	2.6	72.39	2.1
17	96.74	3.3	92.19	1.6	70.13	1.2	82.56	3.1	83.05	2.7	73.61	2.0
18	95.64	3.7	93.78	1.5	71.29	1.2	80.34	2.7	79.77	2.7	59.70	1.9
19	96.02	3.3	96.54	1.9	74.72	1.1	83.67	2.8	78.29	2.3	74.90	1.9
20	85.08	3.5	92.98	1.7	77.02	1.2	73.71	2.9	80.37	2.3	71.97	2.1
21	55.79	2.6	96.23	1.7	81.10	1.1	80.75	2.9	85.01	2.5	66.81	1.9
22	73.43	2.4	87.09	1.9	76.23	1.0	75.31	3.3	70.96	2.8	75.00	1.9
23	68.69	1.7	86.57	1.9	84.74	1.0	84.73	3.6	78.11	1.9	82.52	1.9
24	73.22	2.3	92.33	1.9	76.12	1.1	90.25	3.3	79.16	2.7	79.68	2.0
25	61.67	2.9	82.29	1.5	83.21	1.0	78.10	3.3	77.31	2.6	68.84	1.7
26	57.65	2.8	96.97	1.9	75.41	1.0	72.84	3.1	76.10	3.0	76.07	1.7
27	67.27	2.7	87.73	2.0	76.87	1.2	80.98	3.1	78.59	2.3	73.93	1.7
28	68.23	2.4	91.25	1.8	80.80	1.0	77.71	3.1	68.52	2.3	82.55	1.7
29	72.39	2.7	93.51	1.7	66.82	0.8	79.94	2.9	82.67	2.7	76.98	1.7
30	68.26	1.8	91.74	1.7	79.09	0.8	79.18	2.8	81.29	2.1	75.89	1.5

(g) 閾値=1σ (GMM)

ID	シナリオ1		シナリオ2		シナリオ3		シナリオ4		シナリオ5		シナリオ6	
	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)
1	94.34	0.9	97.22	1.2	91.67	0.4	93.82	2.4	94.35	1.6	85.245	1.2
2	91.39	1.0	100.00	1.2	87.50	0.5	90.20	2.3	87.22	1.1	86.875	1.2
3	88.34	1.1	100.00	1.3	88.64	0.5	89.90	2.6	88.49	1.2	85.855	1.4
4	88.34	1.1	100.00	1.3	79.55	0.5	88.54	2.6	88.49	1.2	87.39	1.4
5	84.77	1.0	100.00	1.5	92.86	0.4	89.42	2.2	90.96	1.3	83.8	1.3
6	88.71	1.0	100.00	1.9	93.34	0.7	89.07	2.2	91.43	1.1	89.62	1.2
7	88.09	1.0	97.50	1.1	90.77	0.7	93.06	2.7	91.16	1.8	89.505	1.4
8	98.56	0.7	99.29	1.4	87.50	0.5	94.30	2.3	91.76	1.2	92.015	1.3
9	88.34	1.1	100.00	1.3	87.73	0.5	89.73	2.6	87.22	1.2	87.395	1.4
10	82.15	2.1	100.00	2.4	93.34	0.8	91.12	2.6	84.17	2.2	84.735	1.6
11	87.94	1.3	97.06	1.6	90.00	0.3	93.37	2.9	92.08	1.7	85.395	1.6
12	82.28	2.8	100.00	1.5	91.11	1.0	91.68	3.2	90.42	3.0	87.685	2.0
13	76.15	1.7	98.39	1.3	90.39	0.7	92.99	3.0	93.51	2.0	91.93	1.7
14	85.14	2.0	88.46	1.3	91.67	0.9	91.76	3.1	91.58	2.4	93.98	1.8
15	100.00	2.4	100.00	1.2	91.54	0.9	92.96	2.9	87.14	2.5	92.125	1.6
16	95.00	3.0	99.29	1.2	90.88	0.8	96.62	2.2	95.67	2.0	91.82	1.8
17	100.00	2.8	98.98	1.1	90.00	0.9	93.19	2.6	93.11	2.3	92.41	1.7
18	100.00	3.1	98.34	1.0	90.00	0.9	95.62	2.2	96.72	2.2	84.895	1.7
19	100.00	2.8	100.00	1.4	90.97	0.9	97.19	2.3	95.67	1.8	90.81	1.7
20	95.00	3.0	99.29	1.1	91.11	0.9	93.52	2.4	92.07	1.9	91.63	1.8
21	79.25	2.0	100.00	1.2	93.75	0.8	93.74	2.4	98.16	2.0	84.51	1.6
22	88.34	1.9	95.54	1.4	91.82	0.7	89.68	2.8	88.13	2.4	86.33	1.6
23	85.91	1.2	96.16	1.5	92.69	0.7	92.75	3.1	89.46	1.4	94.33	1.7
24	88.34	1.8	98.98	1.5	90.77	0.8	95.44	2.8	91.67	2.2	92.66	1.7
25	83.34	2.5	92.31	1.0	93.34	0.7	92.76	2.8	91.43	2.2	86.52	1.5
26	81.25	2.4	100.00	1.5	92.50	0.7	89.17	2.6	86.03	2.6	88.835	1.4
27	86.21	2.2	95.72	1.5	90.00	0.8	91.58	2.6	92.86	1.9	92.295	1.4
28	85.89	1.8	98.34	1.3	91.67	0.7	88.96	2.6	84.00	1.7	91.66	1.4
29	88.07	2.1	100.00	1.2	87.50	0.4	94.27	2.4	95.39	2.2	92.73	1.3
30	85.83	1.4	98.39	1.3	93.75	0.4	91.49	2.3	89.15	1.6	91.865	1.3

(h) 閾値=2σ (GMM)

ID	シナリオ1		シナリオ2		シナリオ3		シナリオ4		シナリオ5		シナリオ6	
	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)
1	85.99	1.1	85.02	1.4	90.39	0.5	70.69	2.6	85.94	1.8	78.36	1.4
2	83.06	1.2	84.74	1.5	86.77	0.6	64.84	2.5	80.48	1.4	81.77	1.3
3	79.60	1.3	88.41	1.5	81.67	0.7	65.79	2.8	72.61	1.5	75.91	1.5
4	79.50	1.3	86.16	1.6	74.50	0.6	65.55	2.8	75.81	1.4	79.86	1.5
5	77.19	1.3	98.13	1.8	84.95	0.6	74.05	2.5	72.35	1.6	73.45	1.4
6	83.21	1.3	99.03	2.1	85.29	0.8	70.71	2.4	78.28	1.4	83.17	1.3
7	80.76	1.2	90.66	1.3	74.31	0.9	74.28	2.9	84.91	2.0	83.36	1.6
8	94.61	0.9	92.36	1.7	73.53	0.6	79.78	2.6	76.74	1.4	84.85	1.5
9	79.70	1.3	87.69	1.5	85.10	0.6	67.51	2.8	70.74	1.4	78.93	1.6
10	66.17	2.3	99.58	2.7	84.38	0.9	63.85	2.8	63.35	2.5	77.44	1.8
11	75.80	1.5	86.39	1.9	79.58	0.5	70.39	3.2	74.90	2.0	75.18	1.8
12	71.48	3.0	91.12	1.8	73.55	1.1	63.28	3.5	59.73	3.2	77.21	2.2
13	58.32	1.9	85.27	1.6	81.80	0.9	70.92	3.2	67.53	2.2	83.95	1.8
14	74.17	2.3	72.83	1.5	86.53	1.0	68.42	3.3	74.24	2.7	84.03	2.0
15	89.68	2.7	88.25	1.4	85.21	1.0	70.21	3.2	66.69	2.7	83.64	1.7
16	87.45	3.3	97.49	1.5	78.07	0.9	93.61	2.5	90.13	2.3	81.47	1.9
17	99.96	3.0	97.94	1.4	83.90	1.1	90.24	2.8	89.48	2.5	83.35	1.8
18	94.87	3.4	97.81	1.3	88.67	1.0	90.01	2.4	87.39	2.5	75.93	1.8
19	99.61	3.0	98.42	1.6	90.00	1.0	94.71	2.6	86.10	2.0	84.00	1.8
20	86.63	3.3	98.05	1.4	84.81	1.1	88.48	2.6	86.85	2.1	81.26	1.9
21	64.86	2.3	97.46	1.5	86.36	0.9	91.14	2.7	91.75	2.3	77.23	1.8
22	87.65	2.2	88.81	1.6	90.76	0.9	66.31	3.1	63.93	2.6	80.32	1.7
23	73.24	1.5	87.86	1.7	80.93	0.9	70.70	3.4	70.07	1.6	88.06	1.8
24	87.91	2.1	88.23	1.7	89.41	1.0	72.12	3.1	67.60	2.5	83.86	1.8
25	71.83	2.7	87.32	1.3	89.96	0.8	74.30	3.0	76.56	2.4	76.55	1.7
26	67.92	2.6	95.31	1.7	91.04	0.9	69.46	2.8	61.56	2.9	80.61	1.5
27	73.73	2.4	88.47	1.7	88.91	1.0	68.53	2.8	70.57	2.1	82.78	1.5
28	72.35	2.1	83.19	1.5	90.69	0.8	65.63	2.8	61.86	2.0	85.67	1.6
29	77.14	2.4	93.00	1.5	87.37	0.6	71.01	2.6	74.00	2.4	83.73	1.5
30	76.67	1.6	90.89	1.6	93.61	0.6	73.29	2.6	73.82	1.8	81.69	1.4

(i) 閾値=3σ (GMM)

ID	シナリオ1		シナリオ2		シナリオ3		シナリオ4		シナリオ5		シナリオ6	
	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)
1	84.36	1.4	83.24	1.7	88.24	0.8	66.12	2.8	84.13	2.1	69.38	1.6
2	79.21	1.5	81.83	1.8	81.96	0.8	58.04	2.8	77.64	1.6	78.92	1.5
3	75.43	1.6	86.27	1.8	75.29	0.8	61.68	3.1	69.77	1.7	73.06	1.7
4	76.26	1.6	83.97	1.9	70.41	0.8	63.55	3.1	72.96	1.7	77.02	1.7
5	72.86	1.5	95.72	2.1	82.56	0.7	67.19	2.7	69.50	1.9	70.60	1.5
6	80.92	1.5	96.96	2.4	84.42	0.9	63.93	2.6	75.43	1.6	80.33	1.5
7	78.59	1.5	87.07	1.6	70.84	1.1	66.30	3.1	82.06	2.3	80.51	1.7
8	90.30	1.1	90.37	2.0	67.59	0.8	76.36	2.8	73.90	1.6	82.01	1.7
9	77.59	1.5	86.17	1.7	83.37	0.8	62.75	3.0	67.89	1.7	76.08	1.8
10	61.22	2.5	99.17	2.9	80.20	1.1	59.89	3.1	60.51	2.6	74.59	1.9
11	72.26	1.7	84.21	2.2	74.95	0.7	65.87	3.4	72.06	2.2	72.34	1.9
12	68.15	3.3	89.34	2.1	71.70	1.3	56.08	3.7	56.89	3.5	74.37	2.3
13	53.60	2.2	82.75	1.9	78.73	1.1	65.02	3.4	64.68	2.5	81.10	1.9
14	71.02	2.5	71.15	1.7	84.66	1.2	61.93	3.5	71.39	2.9	81.19	2.1
15	86.53	2.9	85.27	1.6	81.09	1.2	63.20	3.5	63.85	2.9	80.80	2.0
16	85.68	3.6	95.38	1.7	72.91	1.1	87.19	2.8	87.28	2.5	78.63	2.0
17	93.64	3.3	94.96	1.6	79.56	1.2	85.62	3.0	86.63	2.8	80.51	1.9
18	89.84	3.6	96.17	1.5	83.09	1.2	84.71	2.7	84.54	2.7	73.08	1.9
19	95.55	3.3	96.76	1.8	85.77	1.1	88.39	2.8	83.25	2.2	81.15	2.0
20	82.83	3.6	95.79	1.7	80.75	1.2	82.25	2.8	84.01	2.3	78.42	2.1
21	58.58	2.5	95.33	1.8	83.30	1.1	85.64	2.9	88.91	2.5	74.39	1.9
22	82.85	2.5	86.22	1.9	86.63	1.1	65.86	3.4	61.08	2.9	77.47	1.8
23	70.17	1.8	85.10	1.9	78.58	1.0	68.70	3.6	67.22	1.8	85.22	2.0
24	83.07	2.3	85.78	1.9	87.58	1.1	70.50	3.3	64.76	2.8	81.01	1.9
25	65.74	3.0	85.71	1.5	87.40	1.0	68.41	3.3	73.71	2.6	73.70	1.8
26	62.43	2.9	93.64	2.0	85.45	1.1	62.19	3.1	58.72	3.1	77.77	1.7
27	71.43	2.7	84.84	2.0	86.09	1.1	64.00	3.1	67.73	2.4	79.93	1.7
28	70.32	2.4	80.85	1.8	87.70	1.0	62.36	3.1	59.01	2.3	82.83	1.8
29	71.79	2.6	89.56	1.7	83.16	0.8	67.28	2.8	71.15	2.7	80.88	1.6
30	73.39	1.9	88.40	1.8	89.37	0.7	68.80	2.9	70.98	2.1	78.84	1.6

表3 被験者ごとの個人間異常運転検知による検知割合(事後検知)

(a) シナリオ 1

Table with 14 columns: ID/階層, 車両速度 (km/h), X軸成分の加速度 (G), Y軸成分の加速度 (G), Z軸成分の加速度 (G), 操舵角 (deg), 合成加速度 (G), X軸成分の離度 (J), Y軸成分の離度 (J), Z軸成分の離度 (J), 合成離度 (J), 操舵角速度 (deg/s). Rows 1-30 show data for Scenario 1.

(b) シナリオ 2

Table with 14 columns: ID/階層, 車両速度 (km/h), X軸成分の加速度 (G), Y軸成分の加速度 (G), Z軸成分の加速度 (G), 操舵角 (deg), 合成加速度 (G), X軸成分の離度 (J), Y軸成分の離度 (J), Z軸成分の離度 (J), 合成離度 (J), 操舵角速度 (deg/s). Rows 1-30 show data for Scenario 2.

(c) シナリオ 3

Table with 14 columns: ID/階層, 車両速度 (km/h), X軸成分の加速度 (G), Y軸成分の加速度 (G), Z軸成分の加速度 (G), 操舵角 (deg), 合成加速度 (G), X軸成分の離度 (J), Y軸成分の離度 (J), Z軸成分の離度 (J), 合成離度 (J), 操舵角速度 (deg/s). Rows 1-30 show data for Scenario 3.

(d) シナリオ 4

Table with 16 columns: 車両速度 (km/h), X軸成分の加速度 (G), Y軸成分の加速度 (G), Z軸成分の加速度 (G), 操舵角 (deg), 合成加速度 (G), X軸成分の履歴 (J), Y軸成分の履歴 (J), Z軸成分の履歴 (J), 合成履歴 (J), 操舵角履歴 (deg/s). Rows 1-30.

(e) シナリオ 5

Table with 16 columns: 車両速度 (km/h), X軸成分の加速度 (G), Y軸成分の加速度 (G), Z軸成分の加速度 (G), 操舵角 (deg), 合成加速度 (G), X軸成分の履歴 (J), Y軸成分の履歴 (J), Z軸成分の履歴 (J), 合成履歴 (J), 操舵角履歴 (deg/s). Rows 1-30.

(f) シナリオ 6

Table with 16 columns: 車両速度 (km/h), X軸成分の加速度 (G), Y軸成分の加速度 (G), Z軸成分の加速度 (G), 操舵角 (deg), 合成加速度 (G), X軸成分の履歴 (J), Y軸成分の履歴 (J), Z軸成分の履歴 (J), 合成履歴 (J), 操舵角履歴 (deg/s). Rows 1-30.

表 4 被験者ごとの個人間異常運転検知による検知割合 (リアルタイム検知)

(a) シナリオ 1

Table with 15 columns: ID/回割, 車両速度 (km/h), X軸成分の加速度 (G), Y軸成分の加速度 (G), Z軸成分の加速度 (G), 操舵角 (deg), 合成加速度 (G), X軸成分の離度 (J), Y軸成分の離度 (J), Z軸成分の離度 (J), 合成離度 (J), 操舵角速度 (deg/s). Rows 1-30.

(b) シナリオ 2

Table with 15 columns: ID/回割, 車両速度 (km/h), X軸成分の加速度 (G), Y軸成分の加速度 (G), Z軸成分の加速度 (G), 操舵角 (deg), 合成加速度 (G), X軸成分の離度 (J), Y軸成分の離度 (J), Z軸成分の離度 (J), 合成離度 (J), 操舵角速度 (deg/s). Rows 1-30.

(c) シナリオ 3

Table with 15 columns: ID/回割, 車両速度 (km/h), X軸成分の加速度 (G), Y軸成分の加速度 (G), Z軸成分の加速度 (G), 操舵角 (deg), 合成加速度 (G), X軸成分の離度 (J), Y軸成分の離度 (J), Z軸成分の離度 (J), 合成離度 (J), 操舵角速度 (deg/s). Rows 1-30.

(d) シナリオ 4

Table with 11 columns: 車速速度 (km/h), X軸成分の加速度 (G), Y軸成分の加速度 (G), Z軸成分の加速度 (G), 操舵角 (deg), 合成加速度 (G), X軸成分の偏度 (J), Y軸成分の偏度 (J), Z軸成分の偏度 (J), 合成偏度 (J), 操舵角速度 (deg/s). Rows 1-30.

(e) シナリオ 5

Table with 11 columns: 車速速度 (km/h), X軸成分の加速度 (G), Y軸成分の加速度 (G), Z軸成分の加速度 (G), 操舵角 (deg), 合成加速度 (G), X軸成分の偏度 (J), Y軸成分の偏度 (J), Z軸成分の偏度 (J), 合成偏度 (J), 操舵角速度 (deg/s). Rows 1-30.

(f) シナリオ 6

Table with 11 columns: 車速速度 (km/h), X軸成分の加速度 (G), Y軸成分の加速度 (G), Z軸成分の加速度 (G), 操舵角 (deg), 合成加速度 (G), X軸成分の偏度 (J), Y軸成分の偏度 (J), Z軸成分の偏度 (J), 合成偏度 (J), 操舵角速度 (deg/s). Rows 1-30.

表 5 被験者ごとの個人内異常運転検知による検知精度と検知タイミング
(a) 閾値=1σ

ID	シナリオ1		シナリオ2		シナリオ3		シナリオ4		シナリオ5		シナリオ6	
	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)
1	100	3.8	100	2.4	100	0.8	100	4.1	100	2.3	100	2.5
2	100	4.0	100	2.7	100	0.6	100	4.0	100	2.7	100	2.3
3	100	2.2	100	1.3	100	0.6	100	3.8	100	2.0	100	2.1
4	100	3.0	100	1.0	100	1.1	100	3.9	100	2.3	100	2.5
5	100	2.5	100	2.2	100	0.3	100	3.4	100	2.1	100	2.5
6	100	2.7	100	1.9	100	0.7	100	3.9	100	2.4	100	2.6
7	100	2.1	100	1.3	100	0.9	100	3.7	100	1.8	100	2.2
8	100	2.4	100	1.6	100	0.9	100	3.0	100	1.8	100	1.8
9	100	2.2	100	1.4	100	0.8	100	2.8	100	2.3	100	1.7
10	100	3.1	100	3.0	100	0.6	100	4.2	100	1.9	100	2.6
11	100	2.5	100	1.5	100	0.4	100	1.2	100	1.6	100	1.4
12	100	1.5	100	1.2	100	0.4	100	1.4	100	1.7	100	1.1
13	100	2.0	100	1.6	100	0.5	100	2.4	100	1.9	100	1.8
14	100	2.4	100	1.5	100	0.4	100	1.5	100	1.5	100	1.2
15	100	2.2	100	2.1	100	0.6	100	2.7	100	1.9	100	2.0
16	100	1.6	100	1.1	100	0.8	100	3.1	100	2.0	100	2.0
17	100	1.3	100	1.1	100	1.0	100	2.9	100	2.1	100	1.8
18	100	1.4	100	1.4	100	1.1	100	2.5	100	2.2	100	1.7
19	100	1.7	100	1.5	100	1.0	100	2.9	100	2.3	100	1.6
20	100	1.5	100	1.3	100	0.8	100	2.7	100	2.5	100	1.9
21	100	1.3	100	1.5	100	0.8	100	3.3	100	2.6	100	1.9
22	100	2.3	100	1.4	100	1.1	100	2.6	100	2.1	100	1.3
23	100	2.3	100	0.8	100	0.7	100	2.6	100	2.2	100	2.0
24	100	3.2	100	0.7	100	0.8	100	2.1	100	1.9	100	1.6
25	100	1.8	100	1.1	100	0.6	100	2.0	100	2.2	100	1.5
26	100	2.0	100	1.1	100	0.6	100	1.8	100	2.0	100	1.1
27	100	2.2	100	0.6	100	0.6	100	2.4	100	2.3	100	1.3
28	100	2.7	100	0.6	100	0.6	100	3.1	100	2.4	100	2.3
29	100	2.7	100	1.1	100	0.8	100	3.2	100	2.4	100	1.8
30	100	3.2	100	1.3	100	0.8	100	3.4	100	2.6	100	2.3

(b) 閾値=2σ

ID	シナリオ1		シナリオ2		シナリオ3		シナリオ4		シナリオ5		シナリオ6	
	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)
1	98.58	4.0	100	2.5	100	0.9	96.87	4.2	98.97	2.5	100	2.7
2	99.34	4.2	100	2.9	100	0.8	91.45	4.1	99.34	2.9	100	2.5
3	97.46	2.3	100	1.5	96.88	0.7	93.14	3.9	97.89	2.2	100	2.2
4	96.58	3.2	100	1.2	100	1.2	100	4.0	98.32	2.4	100	2.7
5	97.64	2.7	100	2.4	100	0.4	94.7	3.5	96.31	2.3	100	2.6
6	97.33	2.8	100	2.0	100	0.8	95.12	4.1	97.89	2.5	100	2.8
7	96.51	2.3	100	1.5	95	1.0	89.12	3.9	98.47	1.9	99.71	2.3
8	98.78	2.6	96.13	1.7	98.68	1.1	97.65	3.2	97.98	2.0	97.63	1.9
9	100	2.4	98.1	1.5	97.46	1.0	98.96	3.0	100	2.4	96.98	1.9
10	100	3.2	100	3.1	100	0.7	93.35	4.3	98.67	2.0	100	2.7
11	96.89	2.7	100	1.6	100	0.6	100	1.3	96.08	1.8	100	1.6
12	100	1.6	100	1.3	100	0.6	97.92	1.6	100	1.8	100	1.3
13	97.65	2.1	100	1.8	100	0.6	97.89	2.5	98.63	2.1	100	2.0
14	100	2.6	100	1.7	100	0.5	100	1.7	97.68	1.7	100	1.3
15	98.41	2.3	97.84	2.3	97.46	0.8	97.89	2.8	97.88	2.1	98.12	2.1
16	100	1.7	99.1	1.2	98.98	0.9	98.63	3.2	98.12	2.2	98.47	2.1
17	100	1.5	98.65	1.3	97.89	1.1	97.69	3.1	97.89	2.3	97.63	2.0
18	100	1.6	98.46	1.5	97.45	1.2	98.62	2.7	96.98	2.3	98.68	1.9
19	100	1.8	97.65	1.6	98.63	1.1	97.85	3.0	97.89	2.5	97.89	1.8
20	100	1.6	97.14	1.4	100	1.0	98.69	2.9	98.41	2.6	97.88	2.0
21	100	1.4	97.32	1.6	97.89	0.9	96.79	3.4	97.46	2.8	97.69	2.1
22	100	2.5	93.33	1.6	100	1.2	97.48	2.8	98.34	2.3	95.66	1.4
23	100	2.5	100	0.9	100	0.9	82.68	2.8	100	2.4	99.88	2.1
24	100	3.3	100	0.8	100	1.0	97.82	2.3	99.11	2.1	100	1.7
25	100	2.0	100	1.2	100	0.8	93.33	2.2	93.79	2.3	100	1.6
26	100	2.1	100	1.3	100	0.8	100	2.0	97.24	2.2	100	1.2
27	100	2.3	93.55	0.8	100	0.7	91.62	2.5	97.12	2.5	93.94	1.5
28	100	2.8	100	0.8	100	0.7	98.18	3.3	99.69	2.5	100	2.4
29	100	2.9	100	1.2	100	0.9	100	3.3	92.66	2.5	98.25	2.0
30	97.24	3.3	100	1.4	100	1.0	87.61	3.5	97.32	2.8	100	2.5

(c) 閾値=3σ

ID	シナリオ1		シナリオ2		シナリオ3		シナリオ4		シナリオ5		シナリオ6	
	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)
1	97.42	4.1	100	2.7	100	1.0	96.87	4.4	98.97	2.6	100	2.8
2	98.18	4.3	100	3.0	100	0.9	90.29	4.3	99.34	3.1	100	2.6
3	89.12	2.5	100	1.7	96.88	0.9	91.98	4.1	96.98	2.3	100	2.4
4	96.37	3.4	100	1.3	100	1.3	100	4.1	97.41	2.6	100	2.8
5	97.43	2.9	100	2.5	100	0.6	93.54	3.6	94.75	2.5	100	2.7
6	97.02	3.0	100	2.2	100	1.0	93.96	4.2	96.33	2.7	100	3.0
7	96.35	2.4	100	1.7	95	1.2	87.96	4.0	98.26	2.1	99.71	2.5
8	98.57	2.8	94.97	1.9	98.47	1.3	97.44	3.4	96.42	2.1	96.32	2.1
9	99.79	2.5	96.94	1.7	97.15	1.1	98.65	3.2	100	2.6	93.77	2.0
10	97.14	3.3	100	3.2	100	0.9	92.19	4.5	98.67	2.2	100	2.9
11	95.73	2.8	100	1.7	100	0.7	100	1.4	95.17	2.0	100	1.7
12	99.79	1.8	100	1.5	100	0.7	97.92	1.7	100	1.9	100	1.4
13	100	2.3	100	1.9	100	0.7	97.89	2.6	97.07	2.2	100	2.2
14	97.65	2.7	100	1.8	100	0.6	100	1.8	96.12	1.8	100	1.5
15	100	2.5	95.63	2.4	97.3	0.9	97.68	3.0	96.97	2.2	94.91	2.3
16	99.69	1.9	98.79	1.3	98.77	1.1	98.42	3.3	97.21	2.3	97.16	2.3
17	100	1.6	96.44	1.4	97.58	1.3	97.38	3.3	96.33	2.5	94.42	2.1
18	100	1.8	97.3	1.6	97.24	1.3	98.41	2.9	96.77	2.4	97.37	2.0
19	100	1.9	95.44	1.7	98.32	1.2	97.69	3.2	96.33	2.7	96.58	1.9
20	100	1.8	96.83	1.5	99.79	1.1	98.53	3.0	97.5	2.8	96.57	2.2
21	100	1.6	96.16	1.7	97.73	1.1	96.58	3.5	96.55	3.0	94.48	2.2
22	100	2.6	93.33	1.7	100	1.4	97.48	2.9	98.34	2.4	95.66	1.6
23	96.08	2.6	100	1.1	100	1.1	81.52	2.9	100	2.6	99.88	2.2
24	100	3.5	100	1.0	100	1.1	97.82	2.4	99.11	2.3	100	1.9
25	98.84	2.2	100	1.4	100	0.9	93.33	2.4	93.79	2.5	100	1.8
26	98.84	2.3	100	1.4	92.31	0.9	100	2.2	97.24	2.4	100	1.4
27	93.75	2.5	93.55	0.9	100	0.8	90.46	2.7	97.12	2.6	93.94	1.6
28	91.38	3.0	100	1.0	100	0.9	97.02	3.4	99.69	2.7	100	2.6
29	98.02	3.1	100	1.4	100	1.0	98.84	3.5	92.66	2.7	98.25	2.1
30	96.08	3.4	100	1.6	100	1.1	86.45	3.7	97.32	2.9	100	2.6

表6 被験者ごとの分析手法別の検知精度と検知タイミング

(a) 閾値=1σ (LSTM)

ID	シナリオ1		シナリオ2		シナリオ3		シナリオ4		シナリオ5		シナリオ6	
	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)
1	100	3.7	94.44	2.3	83.33	0.7	100	4.0	100	2.2	85.36	2.4
2	100	3.9	100	2.6	100	0.5	100	3.9	100	2.6	88.47	2.2
3	100	2.1	100	1.2	77.27	0.5	100	3.7	100	1.9	88.04	2.0
4	100	2.9	100	0.9	60	1.0	100	3.8	100	2.2	93.57	2.4
5	100	2.4	100	2.1	100	0.1	100	3.3	100	2.0	93.6	2.4
6	100	2.6	96.67	1.8	53.33	0.6	100	3.8	99.29	2.3	95.8	2.5
7	100	2.0	100	1.2	69.23	0.8	100	3.6	100	1.7	92.44	2.1
8	100	2.3	100	1.5	100	0.8	100	2.9	99.01	1.7	100	1.7
9	100	2.1	100	1.3	100	0.7	100	2.7	100	2.2	100	1.6
10	100	3.0	100	2.9	87.5	0.5	100	4.1	100	1.8	72.09	2.5
11	100	2.4	100	1.4	100	0.3	100	1.1	100	1.5	100	1.3
12	100	1.4	100	1.1	100	0.3	100	1.3	100	1.6	100	1.0
13	100	1.9	100	1.5	100	0.4	100	2.3	100	1.8	100	1.7
14	100	2.3	100	1.4	100	0.3	100	1.4	100	1.4	100	1.1
15	100	2.1	100	2.0	100	0.5	100	2.6	100	1.8	100	1.9
16	100	1.5	100	0.9	69.23	0.7	100	3.0	97.25	1.9	94.32	1.9
17	100	1.2	100	1.0	100	0.9	100	2.8	100	2.0	100	1.7
18	100	1.3	100	1.3	88.24	1.0	100	2.4	96.32	2.1	100	1.6
19	100	1.6	100	1.3	70.32	0.9	100	2.8	100	2.2	100	1.5
20	100	1.4	100	1.2	100	0.7	100	2.6	100	2.3	96.12	1.7
21	100	1.2	100	1.4	82.14	0.7	100	3.2	100	2.5	100	1.8
22	100	2.2	100	1.3	100	1.0	100	2.5	100	2.0	100	1.2
23	100	2.2	100	0.7	100	0.6	100	2.5	100	2.1	100	1.9
24	100	3.1	100	0.6	88.24	0.7	100	2.0	100	1.8	99.48	1.5
25	100	1.7	100	1.0	100	0.5	100	1.9	100	2.1	100	1.4
26	100	1.9	100	1.0	100	0.5	100	1.7	100	1.9	100	1.0
27	100	2.1	100	0.5	100	0.5	100	2.3	100	2.2	100	1.2
28	100	2.6	100	0.5	100	0.5	100	3.0	100	2.3	100	2.2
29	100	2.6	100	1.0	100	0.7	100	3.1	100	2.3	100	1.7
30	100	3.1	100	1.2	100	0.7	100	2.3	100	2.5	100	2.2

(b) 閾値=2σ (LSTM)

ID	シナリオ1		シナリオ2		シナリオ3		シナリオ4		シナリオ5		シナリオ6	
	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)
1	97.21	3.9	38.89	2.4	50	0.8	98.14	4.1	99.49	2.4	62.36	2.6
2	96.33	4.1	63.64	2.8	100	0.7	98.34	4.0	99.31	2.8	79.83	2.4
3	67.45	2.2	78.12	1.4	45.45	0.6	94.33	3.8	99.37	2.1	74.85	2.1
4	69.54	3.1	44.44	1.1	20	1.1	81	3.9	98.23	2.3	83.21	2.6
5	95.41	2.6	31.58	2.3	78.57	0.3	63.25	3.4	98.91	2.2	85.6	2.5
6	94.11	2.7	89.32	1.9	40	0.7	92.47	4.0	98.57	2.4	91.22	2.7
7	93.12	2.2	100	1.4	38.46	0.9	94.32	3.8	100	1.8	75.87	2.2
8	92.45	2.5	88.12	1.6	94.32	1.0	90.25	3.1	94.12	1.9	100	1.8
9	97.14	2.3	75.63	1.4	96.33	0.9	100	2.9	100	2.3	100	1.8
10	50	3.1	51.43	3.0	62.5	0.6	100	4.2	99.79	1.9	50	2.6
11	96.12	2.6	88.24	1.5	80	0.5	86.12	1.2	100	1.7	96.86	1.5
12	100	1.5	100	1.2	100	0.5	100	1.5	100	1.7	100	1.2
13	100	2.0	100	1.7	61.54	0.5	88.22	2.4	100	2.0	91.42	1.9
14	100	2.5	100	1.6	100	0.4	89.46	1.6	100	1.6	100	1.2
15	100	2.2	82.14	2.2	95.12	0.7	95.12	2.7	89.12	2.0	100	2.0
16	100	1.6	89.44	1.1	98.33	0.8	94.33	3.1	86.12	2.1	65.33	2.0
17	100	1.4	92.35	1.2	97.11	1.0	95.36	3.0	87.12	2.2	100	1.9
18	100	1.5	90.47	1.4	96.55	1.1	95.22	2.6	76.32	2.2	100	1.8
19	100	1.7	96.32	1.5	95.12	1.0	96.33	2.9	88.33	2.4	77.23	1.7
20	100	1.5	91.25	1.3	93	0.9	97.12	2.8	88.14	2.5	100	1.9
21	100	1.3	95.36	1.5	92.45	0.8	92.58	3.3	100	2.7	100	2.0
22	96.08	2.4	100	1.5	100	1.1	100	2.7	92.14	2.2	99.43	1.3
23	100	2.4	100	0.8	100	0.8	100	2.7	100	2.3	100	2.0
24	73.81	3.2	100	0.7	35.29	0.9	100	2.2	100	2.0	81.35	1.6
25	88.89	1.9	100	1.1	100	0.7	100	2.1	100	2.2	99.88	1.5
26	93.75	2.0	92.31	1.2	100	0.7	100	1.9	100	2.1	100	1.1
27	91.38	2.2	94.29	0.7	100	0.6	100	2.4	70.3	2.4	100	1.4
28	98.02	2.7	77.14	0.7	83.33	0.6	100	3.2	98.18	2.4	96.44	2.3
29	63.75	2.8	100	1.1	87.5	0.8	100	3.2	98.36	2.4	98.6	1.9
30	76.38	3.2	41.94	1.3	73.33	0.9	98.95	3.4	96.58	2.7	92.92	2.4

(c) 閾値=3σ (LSTM)

ID	シナリオ1		シナリオ2		シナリオ3		シナリオ4		シナリオ5		シナリオ6	
	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)
1	96.70	4.0	27.78	2.6	16.67	0.9	94.43	4.3	98.99	2.5	19.58	2.7
2	97.35	4.2	9.09	2.9	100.00	0.8	93.05	4.2	98.61	3.0	44.09	2.5
3	67.45	2.4	31.25	1.6	18.18	0.8	94.01	4.0	97.47	2.2	49.69	2.3
4	69.54	3.3	22.22	1.2	20.00	1.2	75.68	4.0	96.46	2.5	53.93	2.7
5	95.41	2.8	35.26	2.4	50.00	0.5	60.25	3.5	96.72	2.4	68.00	2.6
6	94.11	2.9	40.44	2.1	33.33	0.9	87.15	4.1	97.14	2.6	69.47	2.9
7	93.12	2.3	45.00	1.6	30.77	1.1	94.00	3.9	98.20	2.0	52.91	2.4
8	92.45	2.7	55.12	1.8	94.16	1.2	87.25	3.3	91.12	2.0	99.68	2.0
9	85.71	2.4	58.44	1.6	96.17	1.0	100.00	3.1	99.68	2.5	97.00	1.9
10	91.38	3.2	12.86	3.1	37.50	0.8	94.25	4.4	99.36	2.1	24.69	2.8
11	95.91	2.7	5.88	1.6	80.00	0.6	80.80	1.3	90.57	1.9	77.65	1.6
12	94.94	1.7	64.29	1.4	44.44	0.6	98.13	1.6	83.33	1.8	86.70	1.3
13	99.79	2.2	32.26	1.8	30.77	0.6	82.90	2.5	92.63	2.1	68.65	2.1
14	87.39	2.6	30.77	1.7	25.00	0.5	84.14	1.7	90.53	1.7	73.30	1.4
15	99.79	2.4	82.14	2.3	94.96	0.8	89.80	2.9	86.12	2.1	97.00	2.2
16	40.00	1.8	89.44	1.2	98.17	1.0	89.01	3.2	83.12	2.2	62.33	2.2
17	80.00	1.5	92.35	1.3	96.95	1.2	95.04	3.2	86.80	2.4	97.00	2.0
18	57.14	1.7	90.47	1.5	96.39	1.2	92.22	2.8	73.32	2.3	97.00	1.9
19	36.36	1.8	96.32	1.6	94.96	1.1	96.01	3.1	85.33	2.6	74.23	1.8
20	57.14	1.7	91.25	1.4	92.84	1.0	91.80	2.9	85.14	2.7	97.00	2.1
21	85.00	1.5	95.36	1.6	92.29	1.0	87.26	3.4		2.9	97.00	2.1
22	79.74	2.5	43.18	1.6	40.00	1.3	91.71	2.8	88.24	2.3	76.60	1.5
23	80.66	2.5	25.00	1.0	23.08	1.0	91.71	2.8	84.92	2.5	83.82	2.1
24	93.65	3.4	38.46	0.9	11.76	1.0	88.76	2.3	96.51	2.2	56.99	1.8
25	71.72	2.1	34.69	1.3	0.00	0.8	89.90	2.3	88.33	2.4	75.09	1.7
26	75.00	2.2	46.15	1.3	100.00	0.8	92.41	2.1	78.57	2.3	93.91	1.3
27	75.29	2.4	22.86	0.8	29.03	0.7	93.88	2.6	86.03	2.5	90.21	1.5
28	83.66	2.9	17.14	0.9	27.78	0.8	90.25	3.3	89.09	2.6	79.12	2.5
29	80.00	3.0	23.33	1.3	37.50	0.9	90.93	3.4	86.89	2.6	79.58	2.0
30	88.19	3.3	22.58	1.5	40.00	1.0	92.20	3.6	90.60	2.8	79.83	2.5

(d) 閾値=1σ (DTW)

ID	シナリオ1		シナリオ2		シナリオ3		シナリオ4		シナリオ5		シナリオ6	
	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)
1	100	3.8	97.22	2.4	91.665	0.8	100	4.1	100	2.4	92.68	2.5
2	100	4.0	100	2.7	100	0.6	100	4.0	100	2.7	94.235	2.3
3	100	2.2	100	1.3	88.635	0.6	100	3.7	100	2.0	94.02	2.1
4	100	3.0	100	1.1	80	1.1	100	3.9	100	2.3	96.785	2.5
5	100	2.5	100	2.2	100	0.3	100	3.3	100	2.1	96.8	2.5
6	100	2.7	98.335	1.9	76.665	0.7	100	3.9	99.645	2.4	97.9	2.6
7	100	2.1	100	1.3	84.615	0.9	100	3.7	100	1.8	96.22	2.2
8	100	2.4	100	1.6	100	0.9	100	3.0	99.505	1.7	100	1.8
9	100	2.2	100	1.4	100	0.8	100	2.8	100	2.3	100	1.7
10	100	3.1	100	3.0	93.75	0.6	100	4.2	100	1.9	86.045	2.6
11	100	2.5	100	1.5	100	0.4	100	1.2	100	1.6	100	1.4
12	100	1.5	100	1.2	100	0.4	100	1.4	100	1.7	100	1.1
13	100	2.0	100	1.6	100	0.5	100	2.4	100	1.9	100	1.8
14	100	2.4	100	1.5	100	0.4	100	1.5	100	1.5	100	1.2
15	100	2.2	100	2.1	100	0.6	100	2.7	100	1.9	100	2.0
16	100	1.6	100	1.0	84.615	0.8	100	3.1	98.625	2.0	97.16	1.9
17	100	1.3	100	1.1	100	1.0	100	2.9	100	2.1	100	1.8
18	100	1.4	100	1.4	94.12	1.1	100	2.5	98.16	2.2	100	1.7
19	100	1.7	100	1.4	85.16	1.0	100	2.9	100	2.3	100	1.6
20	100	1.5	100	1.3	100	0.8	100	2.7	100	2.4	98.06	1.8
21	100	1.3	100	1.5	91.07	0.8	100	3.3	100	2.6	100	1.9
22	100	2.3	100	1.4	100	1.1	100	2.6	100	2.1	100	1.3
23	100	2.3	100	0.8	100	0.7	100	2.6	100	2.3	100	2.0
24	100	3.2	100	0.7	94.12	0.8	100	2.1	100	2.0	99.74	1.6
25	100	1.8	100	1.1	100	0.6	100	2.1	100	2.2	100	1.5
26	100	2.0	100	1.1	100	0.6	100	1.8	100	2.1	100	1.1
27	100	2.2	100	0.6	100	0.6	100	2.4	100	2.3	100	1.4
28	100	2.7	100	0.6	100	0.6	100	3.2	100	2.4	100	2.3
29	100	2.7	100	1.1	100	0.8	100	3.2	100	2.4	100	1.8
30	100	3.2	100	1.3	100	0.8	100	2.3	100	2.6	100	2.3

(e) 閾値=2σ (DTW)

ID	シナリオ1		シナリオ2		シナリオ3		シナリオ4		シナリオ5		シナリオ6	
	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)
1	98.58	4.1	69.45	2.5	75.00	1.0	98.56	4.3	98.18	2.5	81.18	2.7
2	99.34	4.2	81.82	2.9	100.00	0.9	98.84	4.2	95.38	3.0	89.92	2.5
3	82.46	2.4	87.50	1.6	72.73	0.8	96.11	4.0	96.26	2.3	87.43	2.3
4	83.06	3.2	72.22	1.3	60.00	1.3	89.66	4.1	99.12	2.5	91.61	2.8
5	96.53	2.8	65.79	2.4	89.29	0.5	79.78	3.5	96.81	2.4	92.80	2.7
6	95.72	2.9	94.66	2.1	70.00	0.9	95.18	4.1	96.85	2.6	95.61	2.9
7	94.82	2.3	97.50	1.6	69.23	1.1	96.40	4.0	94.56	2.0	87.79	2.4
8	95.62	2.7	93.40	1.8	95.23	1.1	94.12	3.2	95.89	2.0	98.82	2.0
9	98.57	2.5	86.55	1.6	97.22	1.0	100.00	3.1	99.48	2.5	98.49	1.9
10	75.00	3.3	75.72	3.2	81.25	0.8	99.34	4.4	96.57	2.0	75.00	2.8
11	96.51	2.8	94.12	1.6	90.00	0.6	91.10	1.4	100.00	1.9	98.43	1.7
12	100.00	1.7	100.00	1.4	100.00	0.6	100.00	1.6	98.96	1.9	100.00	1.4
13	98.83	2.2	100.00	1.8	80.77	0.6	93.43	2.6	98.95	2.1	95.71	2.1
14	100.00	2.7	100.00	1.7	100.00	0.6	93.57	1.7	100.00	1.7	100.00	1.4
15	99.21	2.5	89.80	2.3	96.48	0.8	96.50	2.9	93.51	2.2	99.06	2.2
16	100.00	1.7	94.21	1.3	98.72	1.0	96.23	3.3	92.38	2.2	81.90	2.2
17	100.00	1.5	95.12	1.3	97.88	1.2	96.63	3.1	92.41	2.4	98.82	2.1
18	100.00	1.7	93.96	1.5	97.51	1.3	96.10	2.8	87.47	2.4	99.34	2.0
19	100.00	1.8	97.48	1.6	96.39	1.2	97.11	3.1	93.09	2.6	87.56	1.8
20	100.00	1.8	95.63	1.5	95.07	1.0	97.77	2.9	93.42	2.6	98.94	2.1
21	100.00	1.5	96.63	1.7	94.89	1.0	95.02	3.5	98.40	2.9	98.85	2.1
22	98.04	2.5	100.00	1.7	96.67	1.3	99.17	2.9	94.81	2.4	97.55	1.5
23	100.00	2.5	100.00	1.0	100.00	0.9	100.00	2.8	91.34	2.5	99.94	2.1
24	86.91	3.4	100.00	0.9	67.65	1.0	99.56	2.3	98.91	2.2	90.68	1.8
25	94.45	2.1	100.00	1.3	100.00	0.8	96.90	2.2	96.67	2.4	99.94	1.7
26	96.88	2.2	96.16	1.3	100.00	0.8	98.62	2.0	100.00	2.3	100.00	1.3
27	95.69	2.4	97.15	0.9	96.78	0.8	98.56	2.6	80.96	2.5	96.97	1.6
28	99.01	2.8	88.57	0.9	91.67	0.8	99.85	3.4	98.18	2.6	98.22	2.4
29	81.88	3.0	100.00	1.3	93.75	1.0	96.33	3.4	99.18	2.6	98.43	2.1
30	86.81	3.4	70.97	1.5	86.67	1.0	98.14	3.6	92.10	2.9	96.46	2.5

(f) 閾値=3σ (DTW)

ID	シナリオ1		シナリオ2		シナリオ3		シナリオ4		シナリオ5		シナリオ6	
	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)
1	97.06	4.2	63.89	2.8	58.34	1.2	96.70	4.5	97.93	2.7	59.79	2.9
2	97.77	4.3	54.55	3.1	100.00	1.0	96.20	4.4	94.45	3.2	72.05	2.6
3	78.29	2.6	64.07	1.8	59.09	0.9	95.50	4.1	94.73	2.4	74.85	2.4
4	82.96	3.4	61.11	1.4	60.00	1.4	86.55	4.2	98.23	2.7	76.97	2.9
5	96.42	3.0	67.63	2.5	75.00	0.6	77.50	3.7	95.13	2.6	84.00	2.8
6	95.57	3.0	70.22	2.2	66.67	1.0	91.74	4.3	95.55	2.7	84.74	3.0
7	94.74	2.5	70.00	1.8	65.39	1.3	96.13	4.1	93.08	2.2	76.31	2.6
8	95.51	2.8	76.80	1.9	94.57	1.4	91.84	3.4	94.28	2.2	98.00	2.2
9	92.75	2.6	77.80	1.8	96.56	1.1	100.00	3.3	99.17	2.6	95.39	2.0
10	94.26	3.4	56.43	3.3	68.75	1.0	96.46	4.5	95.78	2.2	62.35	2.9
11	95.82	2.9	52.94	1.8	90.00	0.8	87.99	1.5	95.29	2.0	88.83	1.8
12	97.37	1.8	82.15	1.6	72.22	0.8	99.07	1.8	90.63	1.9	93.35	1.4
13	99.90	2.3	66.13	2.0	65.39	0.8	89.99	2.7	95.26	2.3	84.33	2.3
14	92.52	2.7	65.39	1.8	62.50	0.7	90.13	1.9	95.27	1.8	86.65	1.5
15	99.90	2.5	89.72	2.4	95.30	1.0	93.39	3.1	91.90	2.3	95.96	2.3
16	69.85	2.0	94.11	1.4	98.48	1.1	93.11	3.3	90.77	2.4	79.75	2.4
17	90.00	1.7	94.97	1.5	96.70	1.4	95.69	3.4	92.09	2.5	95.71	2.2
18	78.57	1.9	93.86	1.8	96.85	1.4	94.50	2.9	85.87	2.5	97.19	2.1
19	68.18	2.0	97.32	1.8	95.20	1.3	96.17	3.3	91.51	2.7	85.41	1.9
20	78.57	1.8	95.52	1.6	94.84	1.1	94.65	3.1	91.84	2.9	96.79	2.2
21	92.50	1.6	96.55	1.8	94.23	1.1	91.91	3.6	96.58	3.1	95.74	2.3
22	89.87	2.7	71.59	1.8	66.67	1.4	95.03	3.0	92.86	2.5	86.13	1.7
23	88.37	2.7	62.50	1.2	61.54	1.2	95.86	3.0	83.22	2.7	91.85	2.3
24	96.83	3.5	69.23	1.0	55.88	1.2	93.94	2.5	97.17	2.4	78.50	2.0
25	85.28	2.2	67.35	1.4	50.00	1.0	91.85	2.4	90.83	2.5	87.55	1.9
26	86.92	2.4	69.23	1.4	100.00	1.0	94.83	2.3	89.29	2.4	96.96	1.4
27	84.52	2.5	61.43	1.0	61.29	0.9	95.50	2.8	88.25	2.6	92.08	1.7
28	87.52	3.0	58.57	1.1	63.89	1.0	94.97	3.5	93.06	2.8	89.56	2.6
29	89.01	3.1	61.67	1.4	68.75	1.1	91.80	3.6	92.87	2.8	88.92	2.1
30	92.14	3.5	61.29	1.7	70.00	1.2	94.76	3.7	88.53	3.0	89.92	2.6

(g) 閾値=1σ (AE)

ID	シナリオ1		シナリオ2		シナリオ3		シナリオ4		シナリオ5		シナリオ6	
	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)
1	100	4.1	98.61	2.7	95.83	1.1	100.00	4.4	100.00	2.6	96.34	2.8
2	100	4.3	100.00	3.0	100.00	0.9	100.00	4.3	100.00	3.0	97.1175	2.6
3	100	2.6	100.00	1.6	94.32	0.9	100.00	4.1	100.00	2.4	97.01	2.4
4	100	3.4	100.00	1.3	90.00	1.4	100.00	4.2	100.00	2.6	98.3925	2.8
5	100	2.9	100.00	2.5	100.00	0.5	100.00	3.7	100.00	2.5	98.4	2.8
6	100	3.0	99.17	2.2	88.33	1.0	100.00	4.2	99.82	2.7	98.95	2.9
7	100	2.5	100.00	1.6	92.31	1.2	100.00	4.0	100.00	2.2	98.11	2.5
8	100	2.8	100.00	1.9	100.00	1.3	100.00	3.4	99.75	2.1	100	2.2
9	100	2.5	100.00	1.8	100.00	1.2	100.00	3.2	100.00	2.6	100	2.1
10	100	3.4	100.00	3.3	96.88	0.9	100.00	4.5	100.00	2.2	93.0225	2.9
11	100	2.9	100.00	1.8	100.00	0.7	100.00	1.5	100.00	2.0	100	1.7
12	100	1.8	100.00	1.5	100.00	0.7	100.00	1.7	100.00	2.0	100	1.4
13	100	2.4	100.00	1.9	100.00	0.8	100.00	2.7	100.00	2.3	100	2.1
14	100	2.7	100.00	1.8	100.00	0.7	100.00	1.8	100.00	1.8	100	1.5
15	100	2.5	100.00	2.5	100.00	1.0	100.00	3.1	100.00	2.2	100	2.4
16	100	1.9	100.00	1.4	92.31	1.1	100.00	3.4	99.31	2.3	98.58	2.3
17	100	1.6	100.00	1.5	100.00	1.4	100.00	3.3	100.00	2.4	100	2.2
18	100	1.7	100.00	1.7	97.06	1.5	100.00	2.9	99.08	2.5	100	2.1
19	100	2.0	100.00	1.8	92.58	1.3	100.00	3.3	100.00	2.6	100	2.0
20	100	1.8	100.00	1.7	100.00	1.2	100.00	3.1	100.00	2.8	99.03	2.2
21	100	1.6	100.00	1.8	95.54	1.1	100.00	3.7	100.00	2.9	100	2.3
22	100	2.6	100.00	1.7	100.00	1.4	100.00	2.9	100.00	2.4	100	1.6
23	100	2.6	100.00	1.1	100.00	1.0	100.00	2.9	100.00	2.5	100	2.3
24	100	3.5	100.00	1.0	97.06	1.1	100.00	2.4	100.00	2.2	99.87	1.9
25	100	2.1	100.00	1.4	100.00	0.9	100.00	2.3	100.00	2.5	100	1.8
26	100	2.3	100.00	1.4	100.00	0.9	100.00	2.1	100.00	2.3	100	1.4
27	100	2.5	100.00	0.9	100.00	0.9	100.00	2.7	100.00	2.6	100	1.6
28	100	3.0	100.00	0.9	100.00	0.9	100.00	3.4	100.00	2.7	100	2.6
29	100	3.0	100.00	1.4	100.00	1.1	100.00	3.5	100.00	2.7	100	2.1
30	100	3.5	100.00	1.6	100.00	1.1	100.00	2.3	100.00	2.9	100	2.6

(h) 閾値=2σ (AE)

ID	シナリオ1		シナリオ2		シナリオ3		シナリオ4		シナリオ5		シナリオ6	
	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)
1	99.27	4.3	84.72	2.9	87.50	1.2	98.76	4.6	97.53	2.8	90.59	3.0
2	100.00	4.5	90.91	3.2	100.00	1.1	99.09	4.4	93.42	3.3	94.96	2.9
3	89.96	2.7	92.19	1.9	86.36	1.1	97.00	4.2	94.70	2.6	93.71	2.5
4	89.82	3.5	86.11	1.6	80.00	1.6	93.99	4.4	99.56	2.8	95.80	3.0
5	97.08	3.1	82.90	2.7	94.64	0.7	88.05	3.9	95.75	2.7	96.40	3.0
6	96.53	3.2	97.33	2.4	85.00	1.2	96.54	4.4	95.98	2.9	97.81	3.2
7	95.66	2.7	96.25	1.9	84.62	1.4	97.43	4.2	91.84	2.2	93.75	2.7
8	97.20	2.9	96.04	2.0	95.68	1.4	96.05	3.6	96.77	2.3	98.22	2.3
9	99.29	2.8	92.00	1.8	97.66	1.3	100.00	3.4	99.22	2.8	97.74	2.2
10	87.50	3.6	87.86	3.4	90.63	1.1	99.00	4.7	94.96	2.4	87.50	3.1
11	96.70	3.1	97.06	2.0	95.00	0.9	93.59	1.6	100.00	2.1	99.22	1.9
12	100.00	1.9	100.00	1.7	100.00	0.9	100.00	1.9	98.44	2.1	100.00	1.6
13	98.24	2.5	100.00	2.2	90.39	0.9	96.03	2.8	98.42	2.4	97.86	2.4
14	100.00	3.0	100.00	2.0	100.00	0.9	95.63	2.0	100.00	2.1	100.00	1.7
15	98.81	2.7	93.63	2.6	97.16	1.1	97.19	3.2	95.70	2.4	98.59	2.5
16	100.00	2.0	96.60	1.5	98.91	1.3	97.17	3.6	95.50	2.5	90.19	2.5
17	100.00	1.9	96.51	1.6	98.27	1.4	97.26	3.4	95.05	2.7	98.22	2.4
18	100.00	2.0	95.71	1.8	97.98	1.6	96.54	3.1	93.05	2.7	99.01	2.3
19	100.00	2.2	98.05	1.9	97.02	1.5	97.50	3.4	95.47	2.9	92.73	2.1
20	100.00	2.0	97.81	1.8	96.11	1.3	98.09	3.2	96.05	2.9	98.41	2.4
21	100.00	1.8	97.26	1.9	96.10	1.2	96.24	3.8	97.59	3.2	98.27	2.5
22	99.02	2.8	100.00	1.9	95.00	1.5	98.76	3.1	96.15	2.7	96.60	1.8
23	100.00	2.8	100.00	1.3	100.00	1.2	100.00	3.1	87.01	2.8	99.91	2.5
24	93.45	3.7	100.00	1.1	83.82	1.3	99.33	2.6	98.37	2.5	95.34	2.1
25	97.22	2.3	100.00	1.6	100.00	1.1	95.34	2.5	95.00	2.7	99.97	1.9
26	98.44	2.5	98.08	1.6	100.00	1.1	97.93	2.3	100.00	2.6	100.00	1.6
27	97.85	2.7	98.57	1.1	95.16	1.0	97.84	2.8	86.29	2.8	95.46	1.8
28	99.51	3.2	94.29	1.2	95.83	1.1	99.77	3.7	98.18	2.9	99.11	2.7
29	90.94	3.3	100.00	1.5	96.88	1.2	94.50	3.7	99.59	2.9	98.34	2.3
30	92.03	3.7	85.49	1.7	93.33	1.4	97.73	3.9	89.85	3.2	98.23	2.8

(i) 閾値=3σ (AE)

ID	シナリオ1		シナリオ2		シナリオ3		シナリオ4		シナリオ5		シナリオ6	
	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)	精度 (%)	時間 (s)
1	97.24	4.5	81.95	3.1	79.17	1.4	97.84	4.8	97.40	3.0	79.90	3.2
2	97.97	4.6	77.27	3.3	100.00	1.3	97.77	4.6	92.37	3.4	86.02	2.9
3	83.70	2.8	80.47	2.0	79.55	1.3	96.24	4.4	93.35	2.7	87.42	2.7
4	89.66	3.8	80.56	1.6	80.00	1.7	91.98	4.5	99.12	3.0	88.48	3.2
5	96.93	3.3	83.82	2.8	87.50	0.9	86.13	4.0	94.34	2.9	92.00	3.0
6	96.29	3.3	85.11	2.6	83.33	1.3	94.04	4.6	94.76	3.0	92.37	3.3
7	95.54	2.7	82.50	2.1	82.69	1.6	97.20	4.4	90.52	2.4	88.01	2.9
8	97.04	3.2	87.63	2.2	94.77	1.7	94.13	3.7	95.86	2.5	97.16	2.5
9	96.27	2.9	87.47	2.0	96.75	1.5	100.00	3.5	98.91	3.0	94.58	2.3
10	95.70	3.7	78.22	3.5	84.38	1.3	97.57	4.8	93.98	2.5	81.17	3.3
11	95.78	3.2	76.47	2.0	95.00	1.1	91.58	1.8	97.64	2.3	94.41	2.1
12	98.58	2.1	91.07	1.9	86.11	1.1	99.53	2.1	94.27	2.2	96.68	1.8
13	99.95	2.6	83.07	2.3	82.69	1.1	93.53	3.0	96.58	2.6	92.16	2.6
14	95.09	3.1	82.69	2.2	81.25	1.0	93.13	2.2	97.63	2.2	93.33	1.8
15	99.95	2.9	93.51	2.8	95.46	1.2	95.18	3.4	94.79	2.6	95.43	2.6
16	84.77	2.2	96.44	1.7	98.64	1.5	95.16	3.7	94.60	2.7	88.45	2.6
17	95.00	2.0	96.27	1.8	96.57	1.7	96.01	3.6	94.74	2.8	95.07	2.5
18	89.29	2.1	95.55	2.0	97.07	1.7	95.63	3.2	92.14	2.8	97.28	2.4
19	84.09	2.3	97.82	2.1	95.32	1.6	96.25	3.5	94.60	3.0	90.99	2.3
20	89.29	2.1	97.66	1.8	95.83	1.4	96.08	3.4	95.18	3.1	96.68	2.6
21	96.25	1.9	97.14	2.0	95.19	1.4	94.23	3.9	144.87	3.3	95.11	2.6
22	94.94	3.0	85.80	2.0	80.00	1.7	96.68	3.3	95.17	2.8	90.90	1.9
23	92.23	2.9	81.25	1.5	80.77	1.4	97.93	3.2	82.37	2.9	95.87	2.6
24	98.41	3.8	84.62	1.3	77.94	1.5	96.52	2.8	97.49	2.7	89.25	2.2
25	92.06	2.5	83.67	1.7	75.00	1.3	92.82	2.7	92.08	2.8	93.77	2.2
26	92.88	2.6	80.77	1.7	100.00	1.3	96.03	2.5	94.64	2.7	98.48	1.7
27	89.14	2.9	80.72	1.3	77.42	1.2	96.31	3.1	89.35	2.9	93.01	2.0
28	89.45	3.3	79.29	1.4	81.95	1.3	97.33	3.8	95.04	3.1	94.78	2.9
29	93.52	3.4	80.83	1.8	84.38	1.4	92.23	3.9	95.85	3.1	93.58	2.4
30	94.11	3.8	80.65	1.9	85.00	1.5	96.04	4.0	87.49	3.3	94.96	2.9

(d) シナリオ 4

Table with 31 rows (0-30) and 30 columns (1-30). Columns represent various parameters like speed, acceleration, and angle for different axes and scenarios.

(e) シナリオ 5

Table with 31 rows (0-30) and 30 columns (1-30). Columns represent various parameters like speed, acceleration, and angle for different axes and scenarios.

(f) シナリオ 6

Table with 31 rows (0-30) and 30 columns (1-30). Columns represent various parameters like speed, acceleration, and angle for different axes and scenarios.

表 8 被験者ごとの個人内異常運転検知による検知割合(リアルタイム検知)
(a) シナリオ 1

Table with 15 columns: 車速速度 (km/h), X軸成分の加速度 (G), Y軸成分の加速度 (G), Z軸成分の加速度 (G), 操舵角 (deg), 合成加速度 (G), X軸成分の履歴 (J), Y軸成分の履歴 (J), Z軸成分の履歴 (J), 合成履歴 (J), 操舵角速度 (deg/s). Rows 1-30 show data for Scenario 1.

(b) シナリオ 2

Table with 15 columns: 車速速度 (km/h), X軸成分の加速度 (G), Y軸成分の加速度 (G), Z軸成分の加速度 (G), 操舵角 (deg), 合成加速度 (G), X軸成分の履歴 (J), Y軸成分の履歴 (J), Z軸成分の履歴 (J), 合成履歴 (J), 操舵角速度 (deg/s). Rows 1-30 show data for Scenario 2.

(c) シナリオ 3

Table with 15 columns: 車速速度 (km/h), X軸成分の加速度 (G), Y軸成分の加速度 (G), Z軸成分の加速度 (G), 操舵角 (deg), 合成加速度 (G), X軸成分の履歴 (J), Y軸成分の履歴 (J), Z軸成分の履歴 (J), 合成履歴 (J), 操舵角速度 (deg/s). Rows 1-30 show data for Scenario 3.

(d) シナリオ 4

Table with 15 columns: 車両速度 (km/h), X軸成分の加速度 (G), Y軸成分の加速度 (G), Z軸成分の加速度 (G), 操舵角 (deg), 合成加速度 (G), X軸成分の履歴 (J), Y軸成分の履歴 (J), Z軸成分の履歴 (J), 合成履歴 (J), 操舵角履歴 (deg/s). Rows 1-30.

(e) シナリオ 5

Table with 15 columns: 車両速度 (km/h), X軸成分の加速度 (G), Y軸成分の加速度 (G), Z軸成分の加速度 (G), 操舵角 (deg), 合成加速度 (G), X軸成分の履歴 (J), Y軸成分の履歴 (J), Z軸成分の履歴 (J), 合成履歴 (J), 操舵角履歴 (deg/s). Rows 1-30.

(f) シナリオ 6

Table with 15 columns: 車両速度 (km/h), X軸成分の加速度 (G), Y軸成分の加速度 (G), Z軸成分の加速度 (G), 操舵角 (deg), 合成加速度 (G), X軸成分の履歴 (J), Y軸成分の履歴 (J), Z軸成分の履歴 (J), 合成履歴 (J), 操舵角履歴 (deg/s). Rows 1-30.

研究業績

2021年3月17日現在

1.学術誌

- 1) Kota MIYAUCHI, Kazuyuki TAKADA: Research on Driver Identification Method Applying Machine Learning on Driving Behavior at Intersections, Journal of the Eastern Asia Society for Transportation Studies, vol.13, pp.1983-1999, 2019. (査読あり)
- 2) 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, 土木学会論文集 F3 (土木情報学), vol.75, no.2, pp.II_97-II_104, 2019. (査読あり)
- 3) 宮内 弘太, 高田 和幸: 交差点内の走行挙動に CNN を適用した自動車運転者の特定手法に関する研究, 交通工学論文集特集号 A, vol.6, no.2, pp.A_235-A_243, 2020. (査読あり)
- 4) 宮内 弘太, 高田 和幸, 篠原 もえ子, 藤生慎: 交差点内の走行挙動に深層学習を適用した異常運転検知に関する研究, 交通工学論文集特集号 A, Vol.7, No.2, pp.A_19-A28, 2021. (査読あり)

2.発表論文

- 5) 宮内 弘太, 高田 和幸: 需要応答型交通システムの整備が運転免許返納意識に及ぼす影響分析, 土木計画学研究・講演集, vol.58, CD-ROM, 2018.8.
- 6) 宮内 弘太, 高田 和幸: 需要応答型交通の整備が高齢運転者の自動車利用抑制意識に及ぼす影響分析, 土木計画学研究・講演集, vol.59, CD-ROM, 2019.6.
- 7) 宮内 弘太, 高田 和幸: 交差点内の走行挙動に機械学習を適用した異常運転検知に関する基礎的研究, 土木情報学シンポジウム講演集, vol.44, pp.221-224, 2019.9.
- 8) 宮内 弘太, 高田 和幸: 交差点内の走行挙動にニューラルネットワークを適用した自動車運転者の特定手法に関する研究, 交通工学研究会発表論文集, vol.39, pp.767-774, 2019.8.
- 9) 宮内 弘太, 高田 和幸: 高齢運転者の自動車利用抑制意識に及ぼす交通サービス水準に関する分析, 土木計画学研究・講演集, vol.60, CD-ROM, 2019.11.
- 10) 宮内 弘太, 高田 和幸: 交差点部の走行挙動に着目した高齢運転者の運転特性に関する一考察, 土木学会関東支部技術研究発表会, vol.47, CD-ROM, 2020.3.
- 11) 宮内 弘太, 篠原 もえ子, 高田 和幸, 南 貴大, 森崎 裕磨, 藤生 慎: 高齢運転者の認知・判断能力と走行挙動の関係性に関する基礎的研究, 土木計画学研究・講演集, vol.61, CD-ROM, 2020.6.

-
- 12) 宮内 弘太, 高田 和幸:深層学習を用いた高齢運転者の異常運転検知に関する研究, 交通工学研究会発表論文集, vol.40, pp.467-474, 2020.8.
 - 13) 宮内 弘太, 高田 和幸: 交差点部の走行挙動を用いた高齢運転者の運転技量評価に関する基礎的研究, 土木情報学シンポジウム講演集, vol.45, pp.237-240, 2020.9.
 - 14) 宮内 弘太, 高田 和幸: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, 土木計画学研究・講演集, vol.62, CD-ROM, 2020.11.

謝辞

本研究の遂行にあたり、多数の方々よりご指導とご協力を賜りました。ここに記して感謝の意を述べたいと思います。

まず、研究全般に渡り終始、ご指導およびご支援を賜りました、東京電機大学理工学部 建築・都市環境学系 高田和幸教授に対し、深甚なる感謝の気持ちとお礼を申し上げます。先生には、筆者が学部4年時に都市交通・計画研究室に配属されてから、博士課程を修了するまでの約6年間ご指導をいただきました。筆者がここまで挫けずに研究を続けてこられたのは、偏に先生のご厚情によるものであります。先生は筆者が研究者を目指すきっかけとなった人であり、現在の研究に対する原動力になっているのも先生のおかげであります。また、先生の教えを通して、非常に多くのことを学ばせていただきました。研究を遂行する上での、研究に取り組む姿勢、研究に対する視点や視野の見方、発想を具現化する為の技術、成果を公表する為のプレゼンテーション能力などの研究者として必要な能力を余すことなく教えていただきました。さらに、研究者としての在り方だけでなく、教育者としての在り方も教えていただきました。研究室の運営や後輩のマネジメントを通して、研究室全体の研究力を向上させていくことの重要性も教えていただきました。先生からいただきました教えを胸にこれからも誠心誠意、精進して参ると同時に、今までにいただきました御恩を少しずつですが返していきたいと思っている所存であります。

次に、東京電機大学理工学部 建築・都市環境学系 島田政信 教授、中井正則 教授、縫村崇行 准教授に対し、感謝の気持ちとお礼を申し上げます。先生方にはご多忙の中、筆者の学位論文審査を引き受けていただきました。最終論文審査に至るまで懇切丁寧に指導をいただきました。本研究の核心部分や発展性、独自性においても非常に多くの貴重なご意見を多数いただきました。また、先生方には筆者が本学に在籍していた間、終始、学位論文について気にかけていただきました。先生方の存在なくして本論文の執筆ができないといっても過言ではありませんでした。ここに感謝の意を表します。

次に、東京工業大学 副学長 環境・社会理工学院 屋井鉄雄教授、道路交通研究・評論家（認知症予防専門士）中村拓司様に対し、感謝の気持ちとお礼を申し上げます。先生方には、本研究を行う上での実験計画や枠組みについてご相談をさせていただきました。ご多忙の中でも、懇切丁寧なアドバイスをいただき、著者の研究の支えとなりました。多くの刺激を受けるとともに、様々なことを学ばせていただきました。ここに心より感謝申し上げます。また学会の席上では、特に、東京大学 生産研究所 人間・社会系部門 大口敬教授、東京都立大学 都市環境学部 都市基盤環境学科 小根山裕之教授、近畿大学 情報学科 エレ

クトロニクス系工学専攻 多田昌裕准教授の方をはじめとする多くの先生方より有益なご助言をいただきました。ここに感謝の意を表します。

次に、金沢大学 理工研究域 地球社会基盤学系 藤生慎准教授，金沢大学大学院 医薬保健学総合研究科 篠原もえ子特任准教授に対し，感謝の気持ちとお礼を申し上げます。先生方には，本論文で実施した高齢運転者を対象として観測調査の被験者の選定および観測調査実施のマネジメントについての助言をいただきました。先生方の協力がなければ，十分な高齢運転者のデータが得られるだけでなく，本論文の完成はできなかつたと思っております。特に，藤生先生につきましては，筆者が研究室に配属された当時から，目をかけていただきました。筆者が研究や研究室のマネジメントで悩んでいる時には，すぐに連絡をしていただき，飲み席を設けていただきました。先生と一緒に飲んだお酒に何度救われたことか数え切れません。また，藤生研究室の学生である，金沢大学大学院 自然科学研究科 環境デザイン学専攻 大澤修司氏，南貴大氏，森崎裕磨氏には，観測調査時のお手伝いや被験者への対応をしていただきました。観測調査に加えて，学会発表の場では，積極的に交流をしていただきました。三人がいたおかげで，切磋琢磨して研究生活に励むことができました。ここに感謝の意を表します。

次に，2019年度の本研究室のOBである小野君（現東京都庁勤務），小林君（現東鉄工業勤務），2020年度の本研究室のOBである荒川君（現東京電機大学大学院修士課程），後藤君（現栃木県庁勤務）に対し，感謝の気持ちとお礼を申し上げます。本研究は，筆者が博士課程に進学した年度から開始した研究となっております。その為，研究の方針などが模索中の中での研究となっており，運転挙動解析班である皆さんには非常に多くの苦労とご迷惑をかけました。小野君と小林君には，既往研究のレビューや高齢運転者や警察庁へのヒアリングなどを一緒にしていただきました。後藤君と荒川君には，観測調査を実施する為のお手伝いをしていただきました。ここに感謝の意を表します。

他にもここでは書ききれないほどの様々な方のおかげで本論文を完成することが出来ました。ここに感謝の意を表します。今後はこの博士号に恥じないよう，皆さまのお力になり，いつか恩返しが出来ればと思います。

最後に，これまで何不自由なく勉学・研究に励ませてくれ，常に筆者のことを気にかけてくれた両親，そして長男である自分を陰ながら支えてくれた弟妹，そして，不規則な筆者の生活に理解を示してくれ，親身になって筆者に寄り添ってくれたパートナーに心から感謝し，本論文の結びとさせていただきます。

宮内弘太