

Title	自転車の危険な挙動認識と録画映像による web マップ型 運転記録システムの提案および評価
Author(s)	原田, 力伎
Citation	
Issue Date	2025-03
Type	Thesis or Dissertation
Text version	author
URL	http://hdl.handle.net/10119/19740
Rights	
Description	Supervisor: 金井 秀明, 先端科学技術研究科, 修士 (知識 科学)

修士論文

自転車の危険な挙動認識と録画映像による web マップ型運転記録システムの提案
および評価

原田 力伎

主指導教員 金井 秀明

北陸先端科学技術大学院大学
先端科学技術専攻
(知識科学)

令和 7 年 3 月

Abstract

In this paper, we propose a web-based map-driven driving record system that detects hazardous behaviors during bicycle riding, integrates them with recorded video footage and location data, visualizes dangerous driving situations, and enables user sharing. Furthermore, we evaluate the effectiveness of the proposed system.

In recent years, bicycle use has been encouraged from the perspective of reducing environmental impact and promoting health, and its adoption has been increasing, particularly in urban areas. However, along with the rise in bicycle usage, traffic accidents have become a significant issue, and ensuring the safety of cyclists has emerged as a social concern. Consequently, efforts have been made to collect traffic data to enhance bicycle safety. Existing data collection methods mainly rely on interviews with cyclists and accident reports compiled by police officers after actual traffic incidents. However, information regarding near-miss incidents (where an accident was narrowly avoided) has not been adequately collected. Although some attempts have been made to gather such information, these efforts are often qualitative, subjective, and based on retrospective reports, raising concerns about data reliability.

One potential method for collecting information on various hazardous situations, including near-misses, is using in-vehicle dashboard cameras (dashcams). However, similar data collection using existing bicycle dashcams is challenging primarily because conventional bicycle dashcams do not possess features akin to automotive dashcams, such as detecting sudden braking or erratic swerving and recording the corresponding footage.

Therefore, a system with functionalities similar to automotive dashcams is required to collect information on near-misses and other dangerous events during bicycle rides without relying on conventional qualitative data. Previous studies have demonstrated that sudden braking and erratic swerving are helpful in identifying various hazardous situations, including near-misses and poor road conditions. Thus, developing a system that captures footage of such behaviors can contribute to the efficient collection of a wide range of hazard-related data beyond mere

near-misses.

In response to this necessity, this study proposes a bicycle driving record system that links hazardous behaviors (e.g., weaving, sudden braking) with video footage and integrates this data with location information to provide accessible ride records. The proposed system consists of the following five steps:

1. Data Collection: Sensor data from a smartphone (acceleration, angular velocity, GPS) and video footage from an action camera are recorded.
2. Uploading Sensor Data: Collected data is transmitted to a web application, where a machine learning model classifies behaviors.
3. CSV File Modification and Video Extraction: The web application generates a CSV file cross-referenced with the recorded video from the action camera. The labels in the CSV file are manually corrected, and the corrected data is used to extract video segments corresponding to hazardous behaviors.
4. Uploading Videos: The extracted videos are uploaded to YouTube and stored in a viewable format.
5. Map Creation and Sharing: Google My Maps integrates behavior data, video footage, and location information to visualize data.

The proposed system employs a classification model based on the Random Forest algorithm, using the following features: mean acceleration on the y-axis, composite mean acceleration, directional change mean, number of positive directional changes, and negative directional changes. The model classifies behaviors into five categories: braking, meandering, right, left, and straight. A ten-fold cross-validation was conducted to evaluate the classification accuracy, achieving an average accuracy of 92.1%. This result indicates that the proposed model can effectively recognize hazardous behaviors with a certain degree of precision.

An experiment with eight participants was conducted to evaluate the proposed system's effectiveness. The quantitative evaluation focused on the classification accuracy of the trained behavior recognition model embedded in the system. Ad-

ditionally, a qualitative evaluation was performed using the System Usability Scale (SUS) to assess the proposed system’s usability.

The experimental results revealed that the behavior recognition model accurately classified straight but tended to misclassify meandering, right, and left. Notably, differences in handlebar operation among participants may not have been adequately accounted for in the sensor data and features used for model training, suggesting that this discrepancy contributed to misclassification. Furthermore, participants reviewed their generated maps and verified whether the detected behaviors were accurately reflected. The verification process confirmed that, except for two out of eight participants, sudden braking was detected and appropriately registered on the map. Additionally, meandering was accurately detected and correctly registered for all participants.

The usability evaluation using SUS revealed an average score of 62.5, indicating the need for usability improvements. Specifically, the burden of data collection and editing and the necessity of manually synchronizing the start of data acquisition between the smartphone and action camera were identified as challenges. Furthermore, free-form comments from participants suggested a demand for automation in data processing and improvements in system intuitiveness.

In conclusion, the experimental results demonstrated that participants could utilize the system to integrate detected hazardous behaviors with video footage and location data, enabling them to provide and share riding information.

As a key contribution, this study introduces a novel approach for recording and sharing hazardous cycling situations based on objective data. While previous methods for collecting data on bicycle accidents and near-misses relied on police reports and subjective user accounts, the proposed system functions as a bicycle-oriented dashcam, integrating hazardous behaviors with video and location data to facilitate objective data collection and analysis. This system not only allows cyclists to review their ride history but also provides a platform for sharing hazard information with others, contributing to establishing a safer cycling environment.

Nevertheless, several challenges remain in the current system. Notably, the manual correction of labels assigned by the machine learning model is labor-intensive,

and there is no mechanism for automatically synchronizing sensor data acquisition with video recording. Moreover, enhancing classification accuracy requires data collection across more diverse environments and the design of additional features. Future work will focus on automating data collection, developing more accurate behavior recognition algorithms, and improving the intuitive usability of the proposed system.

目次

第1章 序論	1
1.1 本研究の目的	1
1.2 研究背景	2
第2章 関連研究	6
2.1 映像記録を活用した研究	6
2.2 ニアミスの検出・分析を行うシステム開発に関する研究	8
2.3 危険回避行動を活用した研究	10
2.4 関連研究のまとめおよび本研究の位置づけ	11
第3章 提案システム	13
3.1 I) 走行データの収集	14
3.2 II) センサデータファイルアップロード	15
3.2.1 web アプリケーションの処理の流れ	15
3.2.2 アプリケーションに組み込まれたモデルの詳細	18
3.3 III) ダウンロードファイル修正&動画の切り出し	23
3.4 IV) 切り出された動画のアップロード	24
3.5 V) マップ作成	24
3.6 まとめ	25
第4章 評価実験	26
4.1 実験概要	26
4.2 定量的評価 (挙動認識モデルの分類精度の評価)	28
4.2.1 実験方法	28
4.2.2 結果	28
4.3 定性的評価 (提案システムのユーザービリティ評価)	30
4.3.1 実験方法	30

4.3.2	結果	32
第 5 章	議論	35
5.1	挙動認識モデルの分類精度	35
5.2	提案システムのユーザビリティ	37
第 6 章	結論	39
6.1	提案システムの貢献と課題	39
6.2	本研究の制限	39
	謝辞	41
	付録	42
	参考文献	43

目 次

1.1	本研究の目的	1
1.2	位置情報・事故内容の登録 [1]	3
1.3	マーカーに事故内容の記入 [2]	4
1.4	サイクリストによって収集されるデータの種類の種類 ([11] の Figure 2 を 参考に作成した)	5
2.1	走行環境の認識 [4]	6
2.2	表情変化の認識を活用した走行路の評価 [5]	7
2.3	映像記録デバイス [6]	8
2.4	CyclingNet のアーキテクチャ [13]	9
2.5	ニアミス分析のためのフレームワーク [14]	10
2.6	急ブレーキを利用した危険箇所の抽出 [11]	11
2.7	蛇行走行を利用した変状・障害物の抽出 [12]	12
3.1	提案システム	13
3.2	クロスバイク	14
3.3	データ収集デバイス	15
3.4	CSV ファイルのアップロード	16
3.5	入力データの作成過程	17
3.6	直進時の方向の変化量 ($d_z(i)$) のばらつき	19
3.7	走行環境	20
3.8	テストデータに対する挙動の混合行列	21
3.9	動画の切り出し	22
3.10	アップロードした動画	23
3.11	作成したマップの一例	24
4.1	実験環境	26

4.2	ママチャリ (左) とクロスバイク (右)	27
4.3	被験者全体の挙動認識における混合行列	29
4.4	各被験者に対する挙動認識の正解率	30
4.5	被験者が作成したマップの一覧	31
4.6	マップに登録された急ブレーキ (sub07 の例)	32
4.7	マップに登録された蛇行走行 (sub08 の例)	33
5.1	各特徴量の挙動分類の寄与率	35
5.2	各被験者の直進走行時の方向の変化量 ($d_z(i)$) のばらつき	36
A.1	混合行列 (sub01)	44
A.2	混合行列 (sub02)	44
A.3	混合行列 (sub03)	45
A.4	混合行列 (sub04)	45
A.5	混合行列 (sub05)	46
A.6	混合行列 (sub06)	46
A.7	混合行列 (sub07)	47
A.8	混合行列 (sub08)	47

表 目 次

3.1	各評価指標のスコア	22
4.1	被験者属性	27
4.2	System Usability Scale (SUS) の集計結果	33

第1章 序論

1.1 本研究の目的




図 1.1: 本研究の目的

本研究では、図 1.1 に示すような、自転車ユーザが、自身が走行中に遭遇したニアミスなどの危険情報や、他のユーザが提供した危険情報を閲覧できるシステムの実現を目的とする。そのために、危険な挙動(蛇行走行・急ブレーキ)と映像を紐づけ、さらに位置情報と統合した走行情報を提供し、参照可能な自転車運転記録システムを提案する。

昨今、自転車の安全な交通環境を実現するため、交通データの収集が行われている。既存のデータ収集方法としては、自転車ユーザへのインタビュー調査の他に、実際の交通事故発生後に警察官によって作成される報告書が主流である。

しかし、ニアミス(危うく事故になりかけた事象)に関する情報収集は十分に行

われていない。そのような情報を収集する試みも存在するが [1, 2], それらは定性的、主観的であり、かつ事後的報告に基づくため、情報の信頼性に問題がある。また、より信頼性の高い情報を得るために、自転車のセンサデータ、映像データなどの客観的データを収集する取り組みが行われているが [3, 4, 5, 6, 7, 8], その多くはいずれも単一のデータ収集にとどまり、多様なデータの収集、統合には至っていない。

本研究では、これらの問題に対処するために、挙動、映像、位置情報といった複数の客観的データを統合し、ニアミス情報の提供および共有を可能にする自転車運転記録システムを提案する。本システムはユーザが所要するスマートフォン、アクションカメラのローカルデバイスに加え、Youtube, Google マイマップを使用することを前提としている。

評価実験では、定量的評価として提案システムに組み込んだ挙動認識モデルの分類精度の評価を行った。また、定性的評価として SUS によるシステムのユーザビリティ評価を行った。結果として、挙動認識モデルは危険な挙動 (蛇行走行・急ブレーキ) を認識するモデルとして利用可能であることが示された。一方で、システムの直感的な操作性には課題があることが明らかとなった。また、総合的な結果として、システムを使用することで、ユーザは認識された危険な挙動を、映像、位置情報と統合し、走行情報として提供および共有することが可能であることが示された。

1.2 研究背景

昨今、自転車の利用促進が行われている。令和3年に策定された第2次自転車活用推進計画 [9] によると、自然環境保護・観光地域の活性化・国民の健康増進や日常生活の利便性向上などの観点から、今後自転車の果たす役割が期待されている。

一方で、自転車ユーザーの安全運転を支援する取り組みは十分とはいえない。平成24年と比較した令和3年の、自転車対歩行者及び、自転車単独の事故件数が増加している [10]。

自転車ユーザの安全を支援する従来の取り組みとして、自転車マップの制作が挙げられる。Trisalyn ら [1] は、自転車の事故やニアミスを報告するためのウェブサイトを開発した。このサイトでは、実際に発生した事故の他に、ニアミスの詳




図 1.2: 位置情報・事故内容の登録 [1]

細について地図上にマッピングするシステムであり、情報共有を容易に行うことが可能である。しかしこのシステムは、ユーザーの主観的かつ事後的な報告に依存しているため、報告内容およびマッピングされる位置情報の信頼性には課題が残る。

また Ahmet-Serdar ら [2] は、スマートフォンを活用したクラウドソーシングによる自転車ルートおよびニアミスのデータ収集アプリケーションを開発した。このアプリケーションでは、スマートフォンに内蔵された加速度センサが急激な加速度の変化を検出すると、その地点が自動でマッピングされる仕組みとなっている。また、ユーザーはマッピングされた地点についてインシデントの報告を行うことで、Trisalyn ら [1] が開発したシステムの課題である位置情報の信頼性の低さを補完している。

しかし、インシデントの報告は依然として主観的かつ事後的な報告に依存している点が課題として残る。実際に Andrii ら [11] は、現代の自転車走行路の安全性評価が主に事故後の状況しか把握できない事故報告書や、サイクリスト自身の主観に基づく評価に依存しているという問題点を指摘している。この研究では、サイクリングの安全性について定量的に評価するため、図 1.4 に示すように、縦軸にデータソース (内部／外部)、横軸に測定タイプ (客観／主観) を配置した二次元グラフを定義した。そして、客観的かつ内部的なデータ (加速度・GPS など) およ




図 1.3: マーカーに事故内容の記入 [2]

び、客観的かつ外部的なデータ (交通カメラ・Car2x など) の双方を組み合わせることの重要性を主張している。

内部外の客観的データを組み合わせることの重要性は、自動車の交通安全対策においても当てはまる。郭ら [12] は、ドライブレコーダの映像データを活用することで、加速度データのみに基づく判断では識別が困難であった、危険回避のための急減速を見極める手法を提案した。その結果、加速度データを用いたより効率的かつ正確な危険箇所の抽出が可能となった。この知見から、Andrii ら [11] が主張したように、加速度データのような客観的かつ内部的な情報に、ドライブレコーダデータのような客観的かつ外部的な情報を組み合わせることは、情報の信頼性を向上させる上で有効であると考えられる。

また、ニアミスデータを収集する手段として、自動車においてはドライブレコーダが広く活用されている。走行中に急ブレーキや急ハンドルが検知されると、映像が記録される。この機能により、ニアミス発生時の具体的な状況を客観的に振り返ることが可能である。

しかし、既存の自転車用ドライブレコーダを用いた同様のデータ収集は困難であると考えられる。その理由として、既存の自転車用ドライブレコーダ¹は、自動車用ドライブレコーダのように、急ブレーキや急なふらつきなどの危険な挙動を検知し映像を記録する機能を備えていないためである。

¹<https://www.akeeyo.co.jp/products/aky-710s>




図 1.4: サイクリストによって収集されるデータの種類
([11] の Figure 2 を参考に作成した)

したがって、自転車走行中のニアミスなどの危険情報を、従来の定性的な情報に依然しない形で収集するためには、自動車用ドライブレコーダと同様の機能を備えたシステムの開発が求められていると考えられる。実際に、先行研究において、自転車の急ブレーキや蛇行走行が、ニアミスや悪路など、さまざまな危険情報を把握するのに役立つ挙動であることが示されている [7, 8]。そのため、これらの挙動が発生している様子を捉えた映像を収集するシステムの開発は、自転車のニアミスに限らず、多くの危険情報を効率的に収集することにつながると考えられる。

本研究では、このような要請に応えるために、図 1.1 に示すように、危険な挙動 (蛇行走行・急ブレーキ) と映像を紐づけるとともに、位置情報を統合した走行情報を提供し、参照可能な自転車運転記録システムを提案する。また、提案システムは図 1.4 における、第二象限および第三象限の情報を包括するものである。したがって、本研究は、Andrii ら [11] の、内部外の客観的データを組み合わせた走行データが必要であるとの主張に応えるものであると考えられる。

第2章 関連研究

本章では，本研究に関連する先行研究を以下の三つのカテゴリに大別し，それぞれの概要について述べる．

1. 映像記録を活用した研究
2. ニアミスの検出・分析を行うシステム開発に関する研究
3. 危険回避行動を活用した研究

また，各々の先行研究が図 1.4 のどの象限に位置付けられるかを考察し，本研究の立ち位置を明確にする．

2.1 映像記録を活用した研究




図 2.1: 走行環境の認識 [4]

Hayashi ら [4] は，スマートフォンのカメラ，YOLO，deeplab を活用し，自転車走行中の危険行動を検出するモバイルシステムの提案をした (図 2.1)．このシステ




図 2.2: 表情変化の認識を活用した走行路の評価 [5]

ムは、歩行者、車両、フェンスや一時停止の標識など、回避行動を引き起こす可能性のある要素を認識することを目的としている。

しかし、提案システムは試作段階であり、危険なサイクリング行動そのものの検出機能は実装されていない。また、映像データのみを収集する仕様となっている。そのため、この研究は図 1.4 における第 2 象限に位置付けられる研究である。

一方、Yamaguchi ら [5] は、物体認識ではなく、ユーザーの表情認識を行うシステムを提案した (図 2.2)。このシステムは、スマートフォンのカメラを用いて走行中のユーザの顔表情をリアルタイムで認識する。次に、認識された表情に基づいて Google マップ上にラベル付けを行う。最後に、ユーザはラベル付けされた箇所について Google ストリートビューで参照し、走行路の定性的な評価を行う。

しかし、検出精度は天候や撮影角度に影響を受ける。また、走行中にモデルが認識可能なほど表情が豊かに変化するかについては疑問が残る。そのため、表情の活用には限界があると考えられる。

また、本研究の提案システムも Hayashi ら [4] と同様に、収集するデータは映像のみである。したがって、この研究も図 1.4 において第 2 象限に位置付けられる研究であると考えられる。

単に映像データのみを記録するのではなく、ドライブレコーダのように特定の事象が発生した際に映像を記録するシステムを開発した研究も存在する。Tim ら [6] は、Raspberry Pi、超音波センサ、サイドカメラなどのデバイスに加え、YOLO を



図 2.3: 映像記録デバイス [6]

活用し、追い越し車両を検出した際に映像を記録するシステムを開発した(図 2.3). このシステムでは、追い越し車両が自転車に 2.5m 以内に接近すると映像が記録されるため、不要な映像の蓄積を抑え、効率的な映像収集が可能である.

しかし、このシステムも先述の物体検出 [4] やユーザーの表情認識 [5] の研究と同様に、自転車の挙動や生理的データの収集は行われていない. したがってこの研究も、図 1.4 において第 2 象限に位置づけられる.

2.2 ニアミスの検出・分析を行うシステム開発に関する研究

Mohamed ら [13] は、走行中の自転車の正面カメラによるビデオストリームから抽出したフレーム単位の静止画を入力データとし、サイクリング中のニアミスを自動検出する深層学習モデル「CyclingNet」を提案した(図 2.4). 本研究では、ニアミスを「自転車利用者が、ブレーキ、加速、蛇行、停止など、衝突を回避するための行動を求められた状況」と定義している.

CyclingNet を活用することで、自転車走行時の危険な状況を捉えた画像を自動




図 2.4: CyclingNet のアーキテクチャ[13]

収集することが可能になる．従来は人手による映像データの分析やアノテーションが必要であったが，提案モデルによりこれらのプロセスが自動化される．

しかし，提案モデルは深層学習を利用しているため，ニアミスと判定した根拠を論理的に説明することができない．そのため，実際にニアミスが発生しているかどうかの判断は依然として人手に依存しており，また，ニアミスの要因分析も手作業を要する．

この課題に対処するため，Mohamed [14] は，図 2.5 に示すように，ニアミスを引き起こす要因分析を支援するコンピュータビジョンをベースにするフレームワークを提案した．本フレームワークは，Mohamed らの研究 [13] で開発された CyclingNet に加え，WeatherNet，YOLO など複数の深層学習モデルで構成されている．また，ロジスティック回帰やグレンジャー因果分析を導入することで，環境リスク要因の抽出，オブジェクトの検出，および検出された要因がニアミスに与える因果関係の推論を可能とし，効率的かつ段階的なニアミス分析を実現している．

しかし，本研究および先述した研究 [13] は，自転車走行中の正面映像という，限られたデータセットのインプットを前提としている．提案モデルおよびフレームワークにより収集された映像から，効率的なニアミス要因の分析は可能となったが，これらのデータそのものをどのように収集するのかについての議論は行われていない．

さらに，提案モデルおよびフレームワーク [13, 14] は，映像データのみを使用することを前提としている．したがって，これらの研究も，図 1.4 の第 2 象限に位置付けられる．




図 2.5: ニアミス分析のためのフレームワーク [14]

2.3 危険回避行動を活用した研究

自転車も自動車と同様に、特定の挙動を認識し、交通安全対策や道路管理に活用しようとする研究が存在している。

Kozu ら [7] は、急ブレーキを「差し迫った危険を回避するために突然行われるブレーキ操作」と定義し、ヒヤリハットのような近接事故の検出に有用な挙動であるとした。本研究では、スマートフォンを用いて加速度データ、地磁気データ、位置情報を収集し、CNN を用いて急ブレーキの認識を行うモデルを構築した。

八木ら [8] は、蛇行走行を道路の変状や障害物の把握に有用な挙動であるとした。道路の変状や障害物は遮蔽される場合があり、その種類も多様であるため、すべてを直接検出することは困難であると述べている。そこで、図 2.7 に示すように、これらの存在によって強いられる回避行動として蛇行走行に注目した。そして、Raspberry Pi 4, OpenPose, SVM などを用いた、リアルタイムの蛇行走行認識を行うエッジコンピューティングシステムを提案した。

Kozu ら [7] の研究は、センサデータのみを収集しているため、図 1.4 の第 3 象限

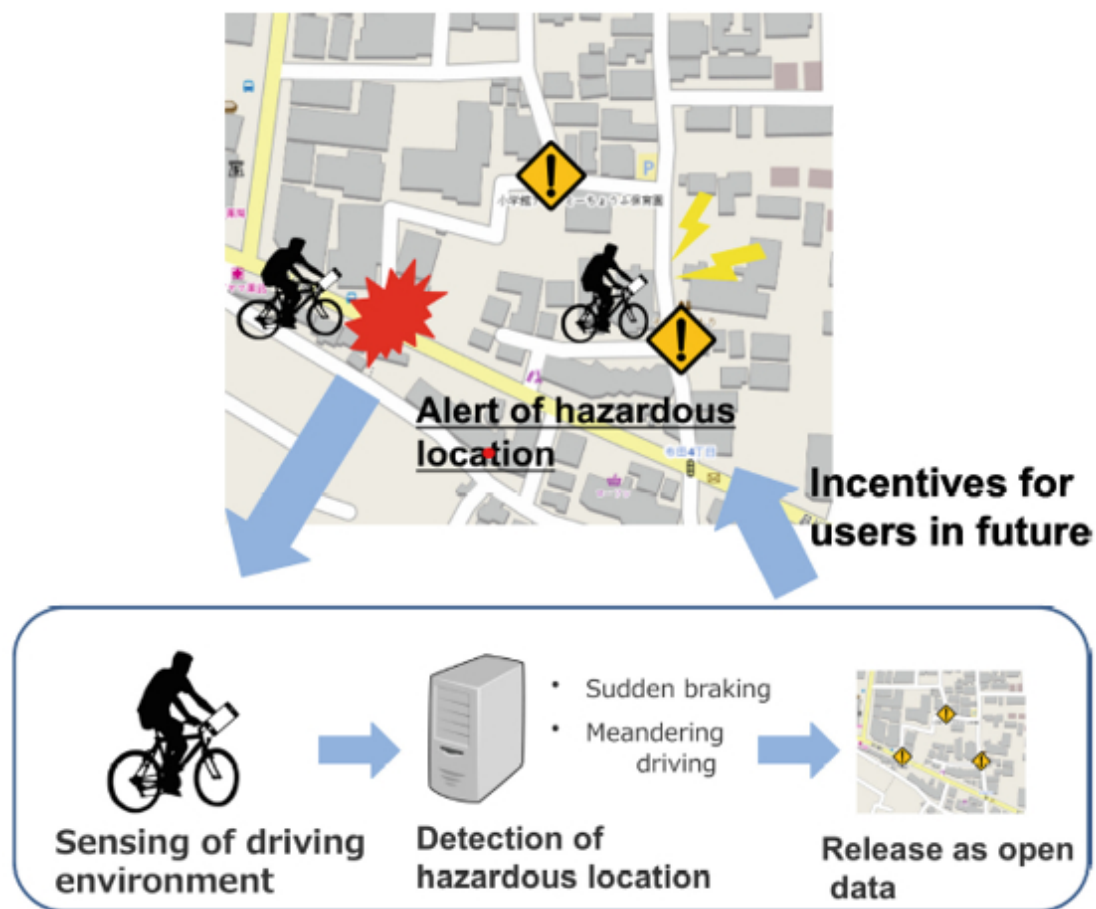


図 2.6: 急ブレーキを利用した危険箇所の抽出 [11]

に位置付けられる研究である。また、八木ら [8] らの研究は、映像データのみを収集しているため、図 1.4 の第 2 象限に位置付けられる研究である。

2.4 関連研究のまとめおよび本研究の位置づけ

1. 映像記録を活用した研究, 2. ニアミスの検出・分析を行うシステム開発の研究, 3. 危険回避を行う挙動を活用した研究は、いずれも図 1.4 の特定の象限に限定されていることが明らかとなった。

1 の関連研究は、図 1.4 の第 2 象限のみに位置付けられる。これらの研究では、人や車両などの移動主体、標識やフェンスなどの走行環境の認識を行うために、映像データの収集のみを目的としている。

2 の関連研究も 1 と同様に、図 1.4 の第 2 象限のみに位置付けられる。提案され

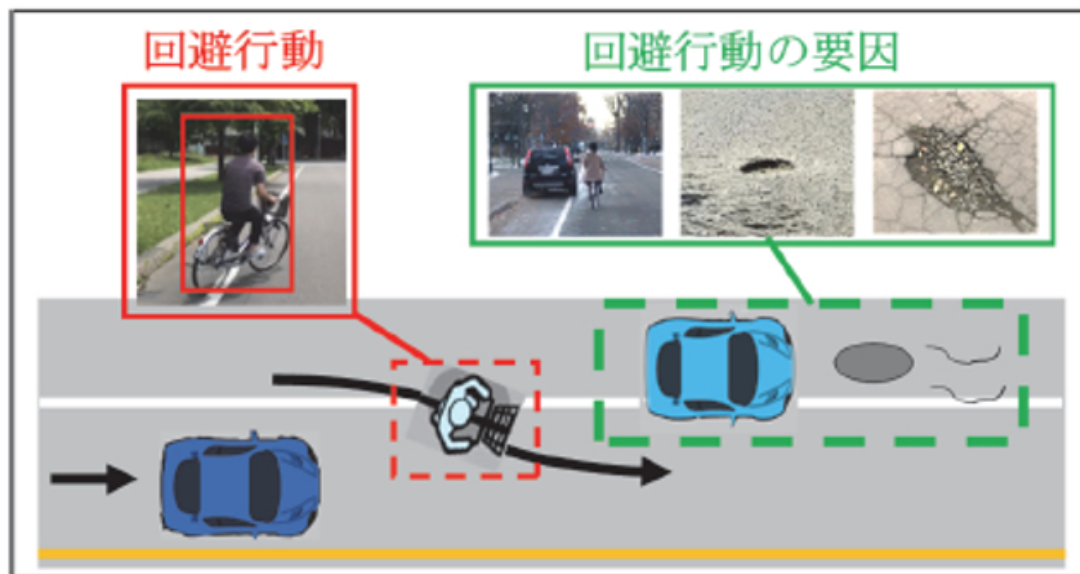


図 2.7: 蛇行走行を利用した変状・障害物の抽出 [12]

たモデルおよびフレームワークは，ニアミスの検出やニアミスを引き起こす要因の検出，分析を目的としており，映像データに依存している．

3の関連研究は，図1.4の第2象限または第3象限のみに位置付けられる．先行研究では，急ブレーキや蛇行走行といった挙動は，ニアミスの検出のみならず，悪路や障害物の把握にも有用であるとし，それらの挙動を認識するためのモデルやシステムを提案している．しかし，いずれの研究も収集するデータはセンサデータまたは映像データのみに限定されている．

以上のことから，図1.4の第2象限と第3象限の両方を包括する研究は不十分であると考えられる．Andriiら[11]は，内部外の客観的データ（挙動・GPS・映像など）を組み合わせることが重要であると主張しているが，既存の研究はその主張に答えられていない．

したがって，本研究では，図1.4の，第二象限および第三象限のデータを包括したシステムの実現を目指す．そのために，自転車の挙動，映像，位置情報を統合する運転記録システムを提案する．

第3章 提案システム




図 3.1: 提案システム

本章では、本研究で実装した運転記録システムの概要を述べる。提案システムは図 1.1 に示すように、危険な挙動（蛇行走行・急ブレーキ）と映像を紐づけるとともに、位置情報を統合した走行情報を提供し、参照可能な自転車運転記録システムである。その処理の流れを図 3.1 に示す。処理工程は、以下の5つの工程で構成される。

- i) 走行データ収集
- ii) データアップロード
- iii) ダウンロードファイル修正＆動画の切り出し
- iv) 切り出された動画のアップロード



図 3.2: クロスバイク

v) マップ作成

また，提案システムは，スマートフォン内蔵のセンサ類，自転車に取り付け可能なアクションカメラ，Google マイマップ，Youtube を使用することを前提としている．

このシステムのうち，収集したセンサデータを機械学習モデルに入力することで挙動を認識する機能に関しては先行研究 [3, 7] と同様である．しかし，提案システムでは，認識された挙動と，その挙動が発生した際の映像を紐づけて保存することが可能である．さらに，GPS データを活用することで，紐づけられた挙動と映像記録をマップ上に可視化し，任意のタイミングで参照できる．

次節 (3.1～3.5) では，各段階で実行される処理について，順を追って説明する．

3.1 I) 走行データの収集

まず，データ収集デバイスを自転車のハンドルバーに取り付け (図 3.3)，走行しながら動画，線形加速度，角速度，GPS(緯度・経度) のセンサデータを収集する．収集したセンサデータは CSV ファイルとして保存される．データ収集デバイスには，スマートフォンおよびアクションカメラを使用した．スマートフォンは Galaxy



図 3.3: データ収集デバイス

S20+, アクションカメラは Osmo Action3¹を用いた。また、自転車は図 3.2 に示すクロスバイクを使用した。走行時には、事前に Galaxy S20+ にインストールしたセンサアプリ「Phyphox」²を起動し、同時にアクションカメラで映像の記録を開始する。

3.2 II) センサデータファイルアップロード

次に、センサデータを収めた CSV ファイルを web アプリケーションにアップロードする。図 3.4 は CSV ファイルのアップロードおよび、アプリケーションによって作成された挙動情報などを収めた CSV ファイルを示している。なお、アプリケーションは Python のフレームワークである streamlit を用いて実装した。

アップロードが完了すると、センサデータの処理が行われ、挙動 (label)・経過時間 (elapsed_time)・緯度 (lat)・経度 (lon)・自由記述欄 (description)・挙動の発生時間 (time_range) を含む CSV ファイルが作成される。

3.2.1 web アプリケーションの処理の流れ

web アプリケーションは、アップロードされた CSV ファイルに対して 4 段階の処理を行う。この節では、各段階で実行される処理について、順を追って説明する。

¹<https://www.dji.com/jp/osmo-action-3>

²<https://phyphox.org/>




図 3.4: CSV ファイルのアップロード

(1) スライディングウィンドウによるセンサデータの処理

まず、加速度データおよび角速度データを収めた各 CSV ファイルに対して、スライディングウィンドウ処理を適用する。処理の流れを図 3.5 に示す。

加速度および角速度の CSV ファイルそれぞれについて、32 行 (Row number) ごとに特徴量 (feature) および経過時間 (elapsed.time(s)) を計算し、1 行の時間窓 T_i にまとめる。スライディングウィンドウにより、はじめの時間窓 T_1 を除き、各行の時間窓 T_i は、一行前の時間窓 T_{i-1} のデータ 70%が重複される。

また、各行の時間窓 T_i は、列に特徴量 (y 軸の平均加速度・合成平均加速度・方向の変化量の平均値・32 行ごとの方向の変化量の正の値の合計・32 行ごとの方向の変化量の負の値の合計) および、経過時間をもつ。算出した時間窓を行方向に結合し挙動認識を行う分類器の入力データを作成する。

なお、スライディングウィンドウによって、データを何%重複させるのが望ましいのか、また、一つの時間窓につきどれほどのデータ数を含むのが望ましいのかについての明確な指標は存在していない。先行研究 [15] では、データの重複割合を 25%, 50%, 75%と設定している。また、[3] では、重複割合を 50%に設定している。先行研究を参考に、本研究では、データの重複割合を 50%~75%の範囲内において、無作為に 70%と設定した。また、[3] を参考にし、一つの時間窓 T_i につき、データサンプル数は 32 個含まれるように設定した。

(2) 分類器による挙動の分類




図 3.5: 入力データの作成過程

次に、分類器が、(1)の処理で作成されたデータフレームに対して、一行ごとに挙動の分類を行う。分類結果はlabel列に追記される。この際、同じ挙動が連続して分類された場合、その挙動が一定時間発生したと解釈し、連続する行を一つの行に統合する。また、time_range列にはその挙動の発生時間が追記される。

(3) 位置情報データとの結合

次に、(2)の処理でlabel列およびtime_range列が追加されたデータフレームを、位置情報（緯度・経度）が格納されたデータフレームと結合する。位置情報を表すデータフレームには、スライディングウィンドウの処理や、行の統合処理は適用されない。そのため、(2)の工程で作成されるデータフレームと、位置情報を表すデータフレームの行数は一致せず、単純に結合することはできない。そこで、両データフレームの各行ごとの経過時間の差を比較し、時間差が最も小さい行同士が結合されるようにした。

(4) 危険な挙動と分類された行の抽出

最後に、危険な挙動（brake・meander）と分類された行のみの抽出し、それらを結合して一つのデータフレームを作成する。作成されたデータフレームは、reference_data.csvとしてダウンロード可能になる。

以上の工程を通じ、挙動（label）・経過時間（elapsed.time）・緯度（lat）・経度（lon）・自由記述欄（description）・挙動の発生時間（time_range）を情含むCSVファイルが作成される。

3.2.2 アプリケーションに組み込まれたモデルの詳細

(1) 分類器として使用するモデル

Web アプリケーションには、分類器として訓練済みのランダムフォレストが組み込まれている。ランダムフォレストはアンサンブル学習を行うモデルであり、外れ値に強いという特徴をもつ。自転車は振動が車体全体に伝わりやすく、収集されるセンサデータには多くのノイズが含まれている可能性がある。そのため、先行研究 [3] ではランダムフォレストを用いた挙動認識を行った。そこで、本研究も先行研究 [3] を参考に、センサデータを活用した自転車の挙動認識には、ランダムフォレストを用いる。

(2) 特徴量・ラベル

$$\begin{cases} d_z(0) = 0 \\ d_z(i) = \frac{t(s)}{2}(\omega_z(i-1) + \omega_z(i)), \quad (i = 1, 2, \dots) \end{cases} \quad (1)$$

使用する特徴量、ラベルは、基本的に [3] を踏襲している。ただし本研究では、x 軸の平均加速度ではなく、y 軸の平均加速度を採用した。また、[3] では正解ラベルとして、停止・直進・右折・左折の 4 つを定義している。本研究では正解ラベルとして、straight（直進）・right（右折）・left（左折）・meander（蛇行）・brake（回避ブレーキ）の 5 つを定義する。

また、先行研究 [3] では、方向の変化量の閾値を $|0.49|$ と設定しているが、本研究では $|0.189|$ と設定した。なお、方向の変化量の算出式は式 (1) で定義されている。 $t(s)$ はセンサデータ取得時間の間隔を表している。 $\omega_z(i)$ は z 軸の角速度を表し、方向の変化量 $d_z(i)$ の単位は rad(ラジアン) である。

方向の変化量の閾値を $|0.189|$ に設定した理由を以下に述べる。

図 3.6 は、直進時の方向の変化量のばらつきおよび基本統計量を示している。ヒストグラム、平均、標準偏差の結果から、方向の変化量は 0 を中心に、 ± 2.0 程度に釣鐘状にばらついていることが示唆される。このことから、 0 ± 2.0 の範囲内の値を 0 にすれば、ハンドル操作のブレによって発生するノイズの大部分を除去することが可能になると考えられる。そこで、このばらつきを参考に、閾値を無作為に 0.189 に設定した。後述するが、この閾値に設定し学習させたランダムフォレ

ストの、テストデータに対する正解率 (Accuracy) が 0.93 を達成した。よって、閾値 0.189 をそのまま採用することにした。

したがって、ハンドル操作に起因するノイズ除去式は (2) のように定義する。方向の変化量 $d'_z(i)$ が -0.189 以上 0.189 以下の場合、方向の変化量を 0 に置換する。この処理により、直進と右左折を識別をするための特徴量である、方向の変化量 $d_z(i)$ を算出するようにした。

$$d'_z(i) = \begin{cases} 0 & \text{if } -0.189 \leq d_z(i) \leq 0.189 \\ d_z(i) & \text{otherwise} \end{cases} \quad (2)$$




図 3.6: 直進時の方向の変化量 ($d_z(i)$) のばらつき

(3) 学習データ収集・モデルの学習

モデルの学習に使用するセンサデータの収集は、Phyphox をインストールした Galaxy S20+ によって行った。走行環境は図 3.7 の通りである。図 3.7 中、4 は路面は亀裂が多く、全体的に凹凸が多い。一方、1～3 の路面は比較的平坦であり、走行しやすい環境である。




図 3.7: 走行環境

ラベルとして定義した各挙動について、次のように走行し、線形加速度および角速度データを収集した。

- meander: 図 3.7 の 1 の路上を走行した。ストップウォッチを使用し、1 分間で、約 10 秒ごとの蛇行走行を計 30 セット行った。
- brake: 図 3.7 の 1 の路上を走行した。ストップウォッチを使用し、1 分間で、約 15 秒ごとにブレーキレバーを強く押し込み減速する走行を計 30 セット行った。
- right: 図 3.7 で示した走行路において、1 → 4 → 3 → 2 と右回りに 2 週する走行を、計 9 セット行った。走行中の様子をアクションカメラで記録した。
- left: 図 3.7 で示した走行路において、1 → 2 → 3 → 4 と左回りに 2 週する走行を、計 9 セット行った。right と同様に、走行中の映像を記録した。

ラベルのアノテーションは手動で行った。ラベルの合計は 3754 個であり、その内訳は straight が 1930 個、meander が 901 個、brake が 331 個、right が 299 個、left が 293 個である。

このように、ラベルの数には不均衡が存在しているため、scikit-learn ライブラリの RandomForestClassifier クラスにおいて、class_weight パラメータを ‘balanced’ と指定し、ラベルの不均衡を考慮してモデルを学習した。

学習データの比率は、訓練データを 80%、テストデータを 20% とし、モデルの学習及び評価を行った。なお、学習データの分割およびモデルの学習にあたり、乱数のシード値は 42 とした。

(4) 挙動認識モデルの評価




図 3.8: テストデータに対する挙動の混合行列

テストデータを用いて、モデルの挙動に対する認識精度の検証を行った。検証方法として、各評価指標および混合行列を用いた。

まず、正解率 (Accuracy)、適合率 (Precision)、再現率 (Recall)、F1 スコア (F1-score) の各評価指標についてそれぞれ算出した (表 3.1)。その結果、いずれの指標も 0.8 を上回る値が得られた。

表 3.1: 各評価指標のスコア

Accuracy(%)	0.93		
	Precision(%)	Recall(%)	F1-score(%)
brake	0.94	0.98	0.96
left	0.82	0.90	0.86
meander	0.85	0.91	0.88
right	0.86	0.85	0.86
straight	0.99	0.94	0.97

次に、テストデータに対する挙動の混合行列を算出した (図 3.8). 図 3.8 は横軸が予測ラベル, 縦軸が正解ラベルを表している. brake・straight はほぼ精確に認識された. 一方で, left は meander に, meander は特に straight に, right は meander への若干の誤認識が発生した. しかし, 出力された混合行列は対角行列に近い形状を示しているため, 全体的な正解率の高いと考えられる.

さらに, モデルの汎化性能を評価するために 10 分割交差検証を行った結果, 正解率の平均値は 0.921 となった. したがって, 特定の訓練データに対するモデルの過学習は生じていないと考えられる.




図 3.9: 動画の切り出し



図 3.10: アップロードした動画

3.3 III) ダウンロードファイル修正&動画の切り出し

次に、web アプリケーションが作成した CSV ファイルおよびアクションカメラが録画した動画を相互に参照しながら、CSV ファイルの label 列の修正作業を行う。例えば、動画では明らかに直進走行をしているのにもかかわらず、CSV ファイルではラベルが brake と記されている場合、誤認識が発生したと判断し、該当する行を削除する。また、動画では明らかに蛇行走行をしているのにもかかわらず、CSV ファイルではラベルが brake と記されている場合、誤認識が発生したと判断し、ラベルを meander に修正する。brake が meander に誤認識された場合も同様の処理を行う。また、動画に蛇行走行や急ブレーキの要因が映っている場合、description 列にその情報を記入する。

修正後、PC 上の ffmpeg-python を用いて実装した関数に、修正後の CSV ファイルおよび録画動画を引数として指定する。関数を実行すると、CSV ファイルの time_range 列に記載されている挙動の発生時間を基に、動画が自動で切り出される (図 3.9)。この実装により、従来にはない危険な挙動と、その挙動が発生している様子を捉えた映像を紐付けた、自転車ドライブレコーダシステムを擬似的に実現している。




図 3.11: 作成したマップの一例

3.4 IV) 切り出された動画のアップロード

次に、III の工程で切り出された動画を、Youtube チャンネルにアップロードする (図 3.10)。各動画からは共有可能なリンクを取得することができ、このリンクがマップ作成時に使用される。

3.5 V) マップ作成

最後に、III の工程で修正した CSV ファイルおよび IV の工程でアップロードした動画を使用し、マップを作成をする。地図には Google マイマップを使用する。Google マイマップは、CSV ファイルに緯度および経度が含まれていれば、そのファイルを直接マップにインポートできる。ファイルがインポートされると、マップ上にマーカーがピン留めされる。なお、マーカーの形状、色などはユーザが自由にカスタマイズ可能である。ピン留めされたマーカーをクリックすると、Youtube 動画のリンクを埋め込む欄が表示される。Youtube チャンネルにアップロードした動画の共有リンクを記入することで、マーカーに動画が埋め込まれる (図 3.11)。

また、作成したマップは他のユーザーと共有可能であり、さらに、一つのマップに対して複数のユーザが編集を行うことができる。

3.6 まとめ

ユーザは、スマートフォンとアクションカメラを取り付けた自転車で走行し、センサデータおよび映像データを収集する。そして、収集したデータを提案システムに用いる。すると、Google マップ上に挙動、映像、位置情報が統合された走行情報が登録される。この機能により、ユーザは急ブレーキまたは蛇行走行が発生した際の具体的な状況を、映像として客観的に振り返ることが可能になる。また、マップ上に登録した走行情報を、他のユーザと共有することも可能である。

次章では、提案システムの評価実験および考察について述べる。

第4章 評価実験

4.1 実験概要




図 4.1: 実験環境

提案システムの有効性を評価するために実験を行った。なお、本実験は北陸先端科学技術大学院大学ライフサイエンス委員会から承認（承認番号：人06-055）を受けた上で実施された。

実験内容は、提案システムの定量的評価および定性的評価を行った。定量的評価では、システムに組み込んだ挙動認識モデルの分類精度の評価をした。また、定性

的評価では，システムのユーザビリティを SUS(System Usability Scale) 尺度 [16] を用いて評価した．なお，本実験には 8 名 (男性 7 名，女性 1 名，平均 24.13 歳) が参加した．被験者の属性は，表 4.1 のとおりである．

次節 (4.2, 4.3) で，定量的評価および定性的評価の方法，結果について述べる．

表 4.1: 被験者属性

被験者	年齢	性別	特に乗車経験のある車種	自転車に乗る頻度	最後に自転車に乗車してからの月日
sub01	24	男性	クロスバイク	月 1 回	6 か月前
sub02	24	女性	シティサイクル	ほぼ乗らない	5 年前
sub03	24	男性	シティサイクル	全くなし	8 年前
sub04	25	男性	シティサイクル	全くなし	2 年前
sub05	23	男性	シティサイクル	3 か月に 1 回	1 か月前
sub06	23	男性	シティサイクル	ほぼ毎日 (大学時代)	10 か月前
sub07	27	男性	シティサイクル	1 週間に 5 回程度	5 か月前
sub08	23	男性	クロスバイク	週 1～3	今日




図 4.2: ママチャリ (左) とクロスバイク (右)

なお，シティサイクルとは，別名「婦人用自転車」であり，俗称として「ママチャリ」と呼ばれることがある．ハンドルはセミアップハンドルであり，手前に曲がった形状をしている．また車体前方にカゴが取り付けられていることが一般的である．主婦や学生を中心に，人々が日常的に使用している自転車である (図 4.2)．

また，クロスバイクとは，スポーツバイクの一種である．前傾姿勢が浅いフレー

ムで設計されており、フラットバーハンドルが用いられている。ママチャリに比べて軽量であり、スピードが出しやすいのが特徴である。この種類の自転車も通勤、通学など、広く一般的な用途で使用されている (図 4.2)。

4.2 定量的評価 (挙動認識モデルの分類精度の評価)

4.2.1 実験方法

被験者に図 4.1 の畑道を右回りに走行してもらい、センサデータおよび映像データを収集した。実験に使用した自転車とデバイスは図 3.2 および図 3.3 に示すものと同じである。走行中、図 4.1 の 2 において、被験者に任意のタイミングで蛇行走行を行うよう指示をした。また、図 4.1 の 3 には一定間隔でコーンを設置し、被験者にはコーンの手前でハンドルレバーを強く押し込み、急減速を行うよう指示をした。

データ収集後、映像データを確認しながらセンサデータに対して挙動のアノテーションを行い、個々の被験者および被験者全体のデータセットを作成した。そして、作成したデータセットに対して、訓練済みの挙動認識モデルによる挙動の分類を行った。

4.2.2 結果

被験者によって天候および走行ルート of 路面状況が異なる。各被験者が走行した際の天候および路面状況について以下に示す。

- sub01-03, 05-06: 天候は曇りである。雨が降った直後であり、路面は濡れている。
- sub04: 天候は晴れである。路面は乾燥している。
- sub07-08: 天候は曇りである。小雨の降り終わりから数時間が経ち、路面は多少濡れているが、比較的乾燥している。

被験者全体のデータセットに対する挙動の認識精度を混合行列として示す (図 4.3)。横軸は挙動認識モデルが認識した挙動を、縦軸は実際の挙動を表している。




図 4.3: 被験者全体の挙動認識における混合行列

この混合行列から、モデルは一定数挙動を誤分類していることが確認された。特に、蛇行走行 (meander)、右折 (right)、左折 (left) の間で誤認識が多く発生している。一方で、モデルが直進 (straight) を蛇行走行、右折または左折と誤認識するケースはほとんど見られなかった。また、モデルが挙動を蛇行走行と認識した場合、実際の挙動が左折であるラベル数は0であった。これにより、モデルが蛇行走行を左折と誤認識することはないことが示された。

次に、各被験者に対するモデルの挙動認識の正解率を図 4.4 に示す。この正解率は、被験者毎のデータセットに対するモデルの正解率を表している。なお、all sub は被験者全体のデータセットに対するモデルの正解率を表している。

図 4.4 から、正解率には被験者間で差があることがわかる。正解率が 0.8 以上であり、多くの挙動を正確に認識できた被験者がいる一方で、正解率が 0.7 を下回る被験者が存在した。また被験者全体の正解率は 0.79 となった。




図 4.4: 各被験者に対する挙動認識の正解率

また、被験者によって作成されたマップを確認し、アクションカメラで撮影された映像を参照することで、認識された挙動が正確にマップに登録されているかを確認した。なお、マップ作成に使用されたデータは、挙動認識モデルの分類精度の評価に用いたデータセットとは異なる、アノテーションがされていない生のセンサデータである。急ブレーキは図 4.6、蛇行走行は図 4.7 に示す形でマップに登録された。

確認作業の結果、被験者のうち、sub01 および sub05 を除く全ての被験者において、急ブレーキが検出され、マップに適切に登録されていることが確認された。一方、蛇行走行については、全ての被験者において正確に検出され、マップに適切に登録されていることが確認された。

4.3 定性的評価(提案システムのユーザービリティ評価)

4.3.1 実験方法

被験者に対し、図 4.1 に示す経路を走行させ、その際に収集した生のセンサデータおよび映像データを用いて、提案システムによるマップの作成を指示した。




図 4.5: 被験者が作成したマップの一覧

マップ作成後、SUSに基づくアンケートを実施しシステムのユーザビリティの評価を行った。アンケートの作成方法は、Brooke の論文 [16] の方法論に則った。SUS は、様々なソフトウェアおよびハードウェア製品のユーザビリティを評価するために使用される尺度である。肯定的な質問 (Q1, 3, 5, 7, 9) と否定的な質問 (Q2, 4, 6, 8, 10) が交互に繰り返されるように構成されている。ユーザーは 10 項目の質問に 1(強く反対)~5(強く同意) の 5 段階で回答する。集計時には回答を 0~4 点に換算する。肯定的な質問毎に対し、回答スコアから 1 を引き、否定的な質問では、5 から回答スコアを引く。これらの総計に 2.5 をかけ、100 点を満点とするスコアを算出する。

具体的な質問項目は次の通りである。

- Q1: このシステムを頻繁に利用したい
- Q2: このシステムは必要以上に複雑である
- Q3: このシステムは使いやすい
- Q4: このシステムを使うには、技術者のサポートが必要だと思った
- Q5: このシステムはいろいろな機能がよくまとまっていると感じた
- Q6: このシステムは不規則な点が多いと思う




図 4.6: マップに登録された急ブレーキ (sub07 の例)

- Q7: このシステムの使い方はたいいていの人がすぐ身につけるだろうと感じた
- Q8: このシステムは扱うことがとても難しいと感じた
- Q9: このシステムは使いこなせる自信がある
- Q10: このシステムを使い始めるまで、学ぶことが多かった

また、質問項目には独自に自由記述欄を設けた。

4.3.2 結果

被験者 8 名からアンケートの回答を得た (表 4.2)。SUS スコアは最小値が 42.5, 最大値が 87.5, 平均が 62.5, 標準偏差が 18.7 であった。各質問項目の中で、特に評価が低かったのは Q4 【このシステムを使うには、技術者のサポートが必要だと思った】であった。一方で、特に評価が高かった質問項目は Q5 【このシステムはいろいろな機能がよくまとまっていると感じた】であった。また、質問項目の自由記述にて、【このシステムは障害物などの危険物を視覚的に見ることができるので、とても使いやすいのではないかと思います。】という感想を得られた。




図 4.7: マップに登録された蛇行走行 (sub08 の例)

表 4.2: System Usability Scale (SUS) の集計結果

被験者	スコア	Q1	Q2	Q3	Q4	Q5	Q6	Q7	Q8	Q9	Q10
sub01	42.5	2	1	1	0	3	2	0	2	3	3
sub02	50	3	2	2	0	3	1	3	3	2	1
sub03	42.5	1	1	1	0	3	3	2	2	3	1
sub04	42.5	2	1	1	1	3	2	2	2	2	1
sub05	80	3	4	4	3	4	3	4	3	4	0
sub06	87.5	3	4	4	3	4	3	4	4	3	3
sub07	72.5	3	3	4	1	3	3	3	4	4	1
sub08	82.5	0	3	3	4	3	4	4	4	4	4
平均	62.5	2.1	2.4	2.5	1.5	3.3	2.6	2.8	3	3.1	1.8
標準偏差	18.7	1.1	1.2	1.3	1.5	0.4	0.9	1.3	0.9	0.8	1.3
最頻値	42.5	3	1	1	0	3	3	4	2	3	1
				4					4	4	

さらに,【システムの使用中またはシステムの使用後に,撮影した動画と web アプリケーションによって作成された CSV ファイルを相互に参照しながらファイルの修正をするのが手間がかかる】,【スマートフォンによるセンサデータの取得とアクションカメラによる映像データの取得は,手動でタイミングを合わせなければならないのが不便】であるというコメントが得られた.

第5章 議論

本研究では、挙動、映像、位置といった内部外の客観的データを統合し、走行情報の提供および参照を目的とした自転車運転記録システムを提案した。評価実験の結果、図 4.6 および 4.7 に示すように、提案システムは、危険な挙動（蛇行・急ブレーキ）と映像、位置情報を紐づけて提供、参照することができるシステムとして利用可能であることが確認された。

しかし、挙動認識モデルは全ての挙動を高精度に認識するには課題が残っている。また、提案システムの操作性は直観的であるとは言い難く、インタフェースの改善が求められる。次節では、挙動認識モデルおよび提案システムのユーザビリティに関する課題を考察し、それぞれの改善点について述べる。

5.1 挙動認識モデルの分類精度




図 5.1: 各特徴量の挙動分類の寄与率

sub01, sub05, sub06, sub07 は、図 4.4 が示しているように、正解率の平均値 0.79 を下回っている。また、表 4.1 が示しているように、sub01, sub02, sub03 よ




図 5.2: 各被験者の直進走行時の方向の変化量 ($d_z(i)$) のばらつき

りも相対的に自転車の乗車経験があるにもかかわらず、彼らと比較して精度が低い結果となっている。

実験中、特に sub01 は、他の被験者と比較してスピードが速く、方向変化を行う際に、体全体を傾けて方向を変える様子が観察された。このことから、自転車、特にクロスバイクやロードバイクといったスポーツバイクに習熟している者ほど、方向変化を行う際に、ハンドル操作よりも体の傾きが初心者に比べて大きくなる可能性がある。特にクロスバイクは、シティサイクルと比較して車体が細く軽量であるため、車体を傾けるのが容易である。

結果として、ハンドルをあまり回転させずに方向変化を行うため、ハンドルバーに取り付けたスマートフォン内蔵のジャイロセンサが角度の変化を捉えられず、挙動の変化を認識できない原因になっていると考えられる。

実際に、図 4.3 によると、挙動認識モデルは蛇行走行、右折、左折の分類精度が十分であるとは言えない。また、図 5.1 は、 $\text{mean_direction_change}$ (方向の変化量 $d_z(i)$ の平均値) が挙動分類に特に寄与していることを示している。このことから、方向の変化の識別は、角速度 z 軸データで計算される方向の変化量に依存していることが考えられる。さらに、角速度 z 軸は自転車のハンドルの回転角度を反映しているが、被験者によって蛇行走行や右折、左折の際の、ハンドル操作はばらつきが見られた。このため、モデルの訓練に用いたセンサデータ、特徴量では、被験者毎のハンドル操作の違いを十分に考慮できていない可能性がある。

したがって、蛇行走行、右折、左折の分類精度を上げるためには、より多様な被験者から角速度 z 軸データを収集する、あるいはハンドル操作の違いを考慮した特徴量、モデルを使用するなどの工夫が必要である。

一方で、図 4.3 に示す結果から、挙動認識モデルが直進を蛇行走行、右折、左折に誤分類することは稀であると言える。このことから、式 (2) で定義した、ハンドル操作に起因するノイズ除去式がある程度有効に機能したと考えられる。実際に図 5.2 によると、被験者の半数以上が、直進時の方向の変化量のばらつきは $-2.0 \sim 2.0$ 以内に集中している。

したがって、本研究で対象とした被験者群においては、ノイズ除去式 (2) を適用することで、ハンドル操作のブレによる直進の誤認識をほぼ抑制できる可能性があると考えられる。

5.2 提案システムのユーザビリティ

提案システムの SUS スコアの平均値は 62.5 点であった。ベンチマークは平均が 68 点、標準偏差が 12.5 点であると言われている [17]。システムの SUS スコアはベンチマークを下回っているので、ユーザビリティの面で課題が存在していることを示唆している。実際に、被験者の中には、web アプリケーションによって作成されたファイルの label 列の修正方法が分からず、質問を行った者が数名いた。システム使用中に、ファイル修正の作業が手間であるとのコメントが得られた事実を踏まえると、特に図 3.1 に示す III の工程において、改善の余地があると考えられる。

したがって、提案システムのユーザビリティを向上させるためには、III のファイル修正工程を自動化し、人の手を介さずに処理できるようにすることの他に、修正の必要な箇所を減らすために、挙動をより正確に分類可能なモデルを構築することが有効であると考えられる。

また、スマートフォンによるセンサデータおよびアクションカメラによる映像データの取得は連動していない。したがって、データ取得の開始タイミングはユーザが手動で合わせる必要がある。実際に、この点について被験者から不便であるとのコメントが得られた。このことから、センサデータと映像データの取得を同時に開始することが可能なデバイスやアプリケーションの実装など、より利便性

を向上させる工夫が必要であると考えられる。

第6章 結論

6.1 提案システムの貢献と課題

本研究では、自転車走行中のニアミスなどの危険情報を、従来の定性的な情報に依然しない形で収集するためには、自動車用ドライブレコーダと同様の機能を備えたシステムの開発が求められていると述べた。その要請に応えるために、図1.1に示すように、自転車の危険な挙動、映像、位置情報が統合された走行情報を提供し、参照可能な自転車運転記録システムを提案した。

評価実験の結果、ユーザは提案システムを使用することで、危険な挙動(蛇行・急ブレーキ)と映像を紐づけ、さらに位置情報と統合して走行情報を提供、または参照できることが確認された。したがって、本研究で提案したシステムを利用することで、自転車走行中のニアミスも含むさまざまな危険情報を、客観的なデータとして収集可能にした点に貢献があると考えられる。

一方、提案システムの直感的な操作性には課題があり、ユーザビリティの改善が求められていることが明らかとなった。ユーザビリティを向上させるためには、図3.1に示すIIIの工程における作業負担を軽減するとともに、センサデータおよび映像データの取得開始タイミングを自動で同期可能な仕組みを導入する必要がある。

6.2 本研究の制限

本研究の制限として、次の三点を挙げる。

第一に、被験者の属性に偏りがある点である。本研究の被験者はいずれも年齢が20代であり、性別の構成は女性が1名、男性が7名と、偏りが見られる。そのため、より多様な属性の被験者を対象とした評価実験を実施し、提案システムの一般的な有効性について検証する必要がある。

第二に、使用した自転車の種類が限定されている点である。本研究の評価実験では、図 3.2 に示すクロスバイクのみを使用した。しかし、被験者の中にはクロスバイクの運転経験がない者も含まれていた。一方で、大半の人が運転経験を有していると考えられるシティサイクルを用いた場合、挙動認識モデルの分類精度が大きく変動する可能性がある。したがって、異なる自転車の種類によるモデルの分類精度の変化について、詳細な分析が必要である。

第三に、評価実験の環境が限定的である点である。今回の走行環境 (図 4.1) は、車両や歩行者の往来がほとんどない畑道であった。そのため、実際の都市部や交通量の多い環境においても、提案システムが適切に機能するかを検証する必要がある。

謝辞

本研究の遂行にあたり、主指導教員として、毎週のゼミにおいて多大な助言とご指導をいただいた、北陸先端科学技術大学院大学 先端科学技術研究科知識科学系 創造社会デザイン領域 金井 秀明准教授に深く感謝申し上げます。

研究計画書の提案にあたり、副指導教員として北陸先端科学技術大学院大学 先端科学技術研究科知識科学系 創造社会デザイン領域 西本 一志教授、北陸先端科学技術大学院大学 先端科学技術研究科知識科学系 創造社会デザイン領域 郷右近 英臣准教授には、多くの有益なご指導をいただきました。深く感謝いたします。

また、修士論文研究の中間審査員として、西本 一志教授、北陸先端科学技術大学院大学 先端科学技術研究科知識科学 創造社会デザイン領域 宮田 一乗教授には、様々なご指摘をいただき、研究の問題点に気づくことができました。心より感謝いたします。

研究室の先輩である小野重遥さんには、論文執筆について多くのアドバイスをいただきました。ご多忙であるなかご指導いただき大変感謝しております。

そして、ご多忙であるなか、実験参加にご協力いただいた北陸先端科学技術大学院大学の学生の皆様に感謝申し上げます。

付録

本付録の図は、4.2の実験で作成した各被験者のアノテーション済みデータセットから、挙動認識モデルが算出した混合行列を示している。

また、被験者によって天候および走行ルート of 路面状況が異なる。各被験者が走行した際の天候および路面状況について再度以下に述べる。

sub01

Accuracy: 0.76

走行環境:

天候は曇りである。雨が降った直後であり、路面は濡れている。

sub02

Accuracy: 0.87

走行環境:

天候は曇りである。雨が降った直後であり、路面は濡れている。

sub03

Accuracy: 0.91

走行環境:

天候は曇りである。雨が降った直後であり、路面は濡れている。

sub04

Accuracy: 0.79

走行環境:

天候は晴れである。路面は乾燥している。

sub05

Accuracy: 0.76

走行環境:

天候は曇りである。雨が降った直後であり、路面は濡れている。

sub06

Accuracy: 0.69

走行環境:

天候は曇りである。雨が降った直後であり、路面は濡れている。

sub07

Accuracy: 0.60

走行環境:

天候は曇りである。小雨の降り終わりから数時間が経ち、路面は多少濡れているが、比較的乾燥している。

sub08

Accuracy: 0.84

走行環境:

天候は曇りである。小雨の降り終わりから数時間が経ち、路面は多少濡れているが、比較的乾燥している。




图 A.1: 混合行列 (sub01)




图 A.2: 混合行列 (sub02)




図 A.3: 混合行列 (sub03)




図 A.4: 混合行列 (sub04)




図 A.5: 混合行列 (sub05)




図 A.6: 混合行列 (sub06)




图 A.7: 混合行列 (sub07)




图 A.8: 混合行列 (sub08)

参考文献

- [1] A. N. Trisalyn, D. Taylor, J. Benjamin, L. Karen, and W. Meghan. Bikemaps.org: a global tool for collision and near miss mapping. *Front. Public Health*, Vol. 67, pp. 1–12, 2015.
- [2] K. Ahmet-Serdar, H. Jonathan, and B. David. Using crowdsourcing to identify near miss hotspots in bicycle traffic. *Pervasive and Mobile Computing*, Vol. 67, pp. 1–12, 2020.
- [3] 宇佐美友理, 石川和明, 高山敏典, 柳澤政生. スマートフォン搭載センサを用いた自転車の挙動認識の向上. マルチメディア, 分散, 協調とモバイル (DI-COMO2019) シンポジウム, pp. 1670–1675, 2019.
- [4] H. Hayashi, X. Anran, and K. Yatani. Vision-based scene analysis toward dangerous cycling behavior detection using smartphones. *UbiComp/ISWC '21 Adjunct: Proceedings of the 2021 ACM International Joint Conference on Pervasive and Ubiquitous Computing and Proceedings of the 2021 ACM International Symposium on Wearable Computers*, pp. 28–29, 2021.
- [5] R. Yamaguchi, S. Panote, T. Yoshihisa, S. Shinji, and Y. Kawai. A detection system for comfortable locations based on facial expression analysis while riding bicycles. *WWW '23 Companion Proceedings of the ACM Web Conference 2023*, pp. 306–309, 2023.
- [6] P. J. S. Tim, W. Oskar, G. Jens, and F. Udo. Smartphone based detection of vehicle encounters. *IWCTS '23: Proceedings of the 16th ACM SIGSPATIAL International Workshop on Computational Transportation Science*, pp. 42–51, 2023.

- [7] R. Kozu, T. Kawamura, S. Egami, Y. Tahara, T. Yasuyuki, and A. Ohsuga. User participatory construction of open hazard data for preventing bicycle accidents. *Lecture Notes in Computer Science*, Vol. 10675, pp. 289–303, 2017.
- [8] 八木雅大, 高橋翔, 荻原亨. 自転車の回避行動に関するデータ集積のためのエッジコンピューティングシステムの構築. 土木学会論文集 D3 (土木計画学), Vol. 76, No. 5, pp. 859–867, 2021.
- [9] 自転車活用推進本部. 第二次自転車活用推進計画. 入手先
 〈<https://www.mlit.go.jp/road/bicycleuse/pdf/2plan.pdf>〉, (参照日)
 2024.03.11.
- [10] 国土交通省. 自転車施策をとりまく環境. 入手先
 〈<https://www.mlit.go.jp/road/ir/ir-council/bicycle-safe/pdf1/bicycle-safe2.pdf>〉, (参照日) 2024.03.11.
- [11] M. Andrii, H. Florian, and P. Bastian. Quantified cycling safety: Towards a mobile sensing platform to understand perceived safety of cyclists. *CHI EA '21: Extend Abstracts of the 2021 CHI Conference on Human Factors in Computing Systems*, No. 262, pp. 1–6, 2021.
- [12] 郭雪松, 掛井孝俊, 川瀬晴香, 小林寛. ドライブレコーダデータ分析に基づいた危険な急減速を見極める手法に関する研究. 土木学会論文集 D3 (土木計画学), Vol. 76, No. 5, pp. 649–656, 2021.
- [13] R. I. Mohamed, H. James, C. Nicola, and C. Tao. CyclingNet: Detecting cycling near misses from video streams in complex urban scenes with deep learning. *IET Intelligent Transport Systems*, Vol. 15, No. 10, pp. 1331–1344, 2021.
- [14] R. I. Mohamed. Computer vision and statistical insights into cycling near miss dynamics. *Scientific Reports*, 2024.
- [15] Filip Larsson and Pontus Hallqvist. Classifying motion patterns of bikes using machine learning. *LUP Student Papers*, 2023.

- [16] J. Brooke. SUS: A quick and dirty usability scale. *Usability Eval. Ind.*, 1995.
- [17] M. Hyzy, R. Bond, M. Mulvenna, L. Bai, A. Dix, S. Leigh, and S. Hunt. System Usability Scale Benchmarking for Digital Health Apps: Meta-analysis. *JMIR Mhealth Uhealth*, 2022.