

# 自転車の障害物回避挙動検出における異常検知に基づく障害物回避区間の抽出手法の検討

武安裕輔<sup>1,a)</sup> 白石陽<sup>2,b)</sup>

近年、自転車利用者は増加傾向にある。その一方で、自転車に配慮した道路環境整備が十分に進んでいない現状がある。こうした現状から、自転車利用者が道路を快適に走行することができないという問題が生じている。この問題に対するアプローチとして、快適に走行可能な道路はどこなのかという情報を収集し、自転車利用者間で共有する方法が考えられる。自転車の快適性に関する情報として、障害物や車両の交通量、路面の凹凸や勾配などが挙げられるが、本研究ではその中でも特に影響が大きいと考えられる路側帶上の障害物に着目し、障害物の有無や規模に関する情報を収集する。そのために、自転車が排水溝の蓋や路上駐車の車両などの障害物を回避する際に特有の挙動を示すことから、自転車の障害物回避挙動を検出することによって障害物に関する情報を収集することを目的とする。著者らはこれまでに、自転車の進行方位が障害物を回避する際に変化するという特徴を用いた機械学習により、障害物回避挙動を検出する手法や、さらに速度変化の特徴を用いた手法を提案してきた。これらの手法は、実環境へ適用する際に複数の課題が存在する。最も重要な課題として、実際に公道を走行した際の自転車の挙動データには複数の障害物回避区間が含まれているのに対し、先行研究の手法はそれらを個別に検出することはできないという課題があった。そこで本稿では、直進区間のデータを正常なデータ、障害物回避区間のデータを異常なデータとした異常検知を、 $k=1$ とした $k$ 近傍法を用いて行うことで、公道を走行した長距離走行時の挙動データから障害物回避区間候補を抽出する手法を検討する。また、評価実験として、長距離走行時の挙動データからの障害物回避区間候補の抽出精度および、抽出した区間に對して先行研究の障害物回避挙動検出手法を適用した際の検出精度を評価した。

## 1. はじめに

近年、日本では自転車利用者が増加傾向にある。それに伴い、歩道における歩行者と自転車利用者との間での事故が多発していることから[1]、国は2015年6月1日に道路交通法を改正した[2]。この法改正によって、自転車利用者に対して原則車道通行が義務付けられた。しかし、自転車に配慮した道路環境整備があまり進んでいない。そのため、路側帯が狭く路上駐車の車両などの障害物を回避する際に側方を走行中の車両との安全な距離を確保できない道路や、路上駐車の車両によって路側帯や自転車専用レーンが塞がれている道路、路面の損傷等により凹凸のある道路などが多く見受けられる。こうした現状から、自転車利用者が交通ルールに従って車道を走行する際に快適に走行できないという問題が生じている。

この問題を緩和するためのアプローチとして、どの道路が自転車の走行に適しているのかという情報を収集し、自転車利用者に提供する方法が挙げられる。このアプローチによる既存のサービスとして、「自転車大好きマップ」が挙げられる。このサービスは、自転車利用者自身が自転車で走行した道路について、「走りやすい」「走りにくい」などの道路の快適性に関する情報を収集し、利用者同士で共有することができる。しかし、このサービスは利用者自身の手入力によって情報を収集している。そのため、利用者が情報を入力する際にかなりの手間がかかり、走行した道路全ての情報を入力することが困難であり、道路の情報を網羅的に収集することができないという欠点がある。

この欠点を解決するために、本研究では自転車利用者が自転車で走行したすべての道路の情報を自動で収集・共有する手法を検討する。本稿ではまず、サイクリング等で走行する頻度が高いと考えられる、歩道のある大きな道路に着目する。道路の快適性に関する情報として、障害物（排水溝の蓋、路上駐車の車両など）や車両の交通量、路面の凹凸や勾配などが挙げられるが、その中でも特に影響が大きいと考えられる路側帶上の障害物に着目し、障害物の有無や規模に関する情報を収集する。

障害物に関する情報を収集するためには、自転車にセンサを設置し、自転車利用者による参加型センシングによって走行中の自転車の挙動データを収集する。参加型センシングとは、計測対象領域に分散した多数の協力者が自分のスマートフォンなどに搭載されているセンサを用いて計測した何らかのデータを相互に共有する方法である[4]。参加型センシングを用いた研究としては、スマートフォンの照度センサを用いて夜道の街灯照度データを収集する研究[5]や、車載スマートフォンを用いて桜を検出することで桜景観の良い道路区画の抽出を行う研究[6]が挙げられる。このように、参加型センシングを用いた情報収集は、複数の場所における情報を網羅的に収集することができるため、道路情報の収集に適している。

次に、収集した自転車の挙動データから障害物の回避挙動を検出する。障害物の種類や規模によって回避挙動が異なると考えられることから、回避挙動を検出することで、障害物に関する情報を収集可能であると考える。著者らはこれまでに、自転車が障害物を回避する際に特徴的な変化を示す挙動データから抽出した特徴量を用いた機械学習により、障害物回避挙動を検出する手法[7][8]を提案してきた。文献[7]では、自転車のハンドル操作によって進行方位が変

1 公立はこだて未来大学大学院システム情報科学研究科  
Graduate School of Systems Information Science, Future University Hakodate  
2 公立はこだて未来大学システム情報科学部  
School of Systems Information Science, Future University Hakodate  
a) g2117030@fun.ac.jp  
b) siraisi@fun.ac.jp

化することに着目した特微量を用いた手法を提案した。そして、文献[8]では進行方位の変化のみでは検出する事が難しい回避挙動を検出するために、回避挙動付近で生じる自転車の加減速動作に着目した特微量を新たに検討した。

しかし、これらの手法を実環境へ適用する際には解決すべき課題が複数存在する。本稿ではそれらの中で、前述した手法は1つの挙動データに対して障害物回避区間を1つだけ含んでいる場合に限り適用可能であるという課題を取り上げる。長距離走行時の挙動データには直進区間を基本として複数の障害物回避区間が含まれるため、長距離走行時の挙動データから障害物回避区間の挙動データを個別に抽出し、手法を適用する必要がある。

そこで本稿では、直進区間の挙動データと長距離走行時の挙動データに対してデータ間の距離計算を行う。そして、長距離走行時の挙動データのうち、障害物回避区間の挙動データは、直進区間の挙動データとの距離が大きくなることを用いて障害物回避区間候補を抽出する手法を検討する。

## 2. 関連研究

本研究では、障害物検出のための自転車挙動データを用いた障害物回避挙動検出手法を提案する。そこで、関連研究として自転車挙動のセンシングに関する研究と、自転車挙動データを用いた挙動検出に関する研究について述べる。

### 2.1 自転車挙動のセンシングに関する研究

自転車の挙動をセンシングする研究として、複数種類の専用センサを用いてセンシングを行う研究[9][10][11][12]と、スマートフォンを用いてセンシングを行う研究[13][14][15]が挙げられる。

まず、複数種類の専用センサを用いてセンシングを行う研究[9][10]では、リードスイッチと光電センサを用いて自転車の速度の情報を収集している。また、ロータリーエンコーダーを用いて自転車のハンドル操舵角の情報を収集している。文献[11]では、磁気センサを用いてペダルの回転数の情報を収集している。さらに、文献[12]では、自転車や二輪車がハンドル操作だけではなく車体を傾けて旋回することから、角速度センサを用いて操舵角や車体の傾きの情報を収集している。以上のように、専用センサを用いてセンシングを行うことで、自転車の挙動に関する様々な情報を高精度に収集することができる。しかし、参加型センシングを行う場合、より多くの自転車利用者がセンシングに参加することが重要であるため、導入コストを抑える必要がある。そのため、一般的な自転車利用者が通常所持していないセンサを複数使用したセンシング方法は、本研究に適さないと考えられる。

次に、スマートフォンを用いてセンシングを行う研究[13][14][15]では、ハンドルに設置したスマートフォンに搭

載された角速度センサを用いてハンドル操舵角や車体の傾きの情報を収集している。さらに文献[14]では、加速度センサを用いて自転車の走行・停止判別や、加減速の情報を収集している。文献[15]では、地磁気センサを用いてハンドル操舵角や車体の傾きを収集している。スマートフォンには上記の研究で用いられているセンサの他にも、多種多様なセンサが搭載されているため、スマートフォン単体で多くの情報を収集することができる。そして、スマートフォンは近年普及が進んできているため、自転車利用者の多くが所持しており、導入コストを抑えることができる。そのため、参加型センシングを用いる本研究に適したセンシングデバイスであると考える。

### 2.2 自転車挙動データを用いた挙動検出に関する研究

#### 2.2.1 挙動検出手法に関する研究

自転車挙動データを用いた挙動検出に関する研究として、閾値判定を用いて挙動検出を行う研究[12]と、機械学習を用いて挙動検出を行う研究[10][13][14]が挙げられる。

まず、閾値判定を用いて検出を行う研究[12]では、角速度の値に対して閾値を設定することで、路面に出来た損傷箇所の回避挙動を検出している。しかし、複数の自転車利用者によって収集された回避挙動には、回避を始めるタイミングや、ハンドルの切り方や車体の傾け方に大きく個人差が現れてしまう。そのため、ハンドル操舵角や車体の傾きに一定の閾値を設定することが難しいと考えられる。また、自転車はふらつきが多いため、回避挙動として設定した閾値をふらつき時に超えてしまう可能性も考えられる。以上より、センサの値に対して一定の閾値を設定する検出手法は、本研究には適さないと考える。

次に、機械学習を用いて検出を行う研究[10][14]は、センサによって収集した自転車挙動データから特微量を抽出し、それをもとに決定木を用いた機械学習を行うことで、蛇行運転や路上駐車の車両を回避する挙動の分類を行っている。また、文献[13]はSVM(Support Vector Machine)によって右左折や左右へのカーブなどの挙動の分類を行っている。自転車の挙動においては、自転車利用者によりハンドル操作のタイミングなどが異なり、ある挙動に対して複数の挙動パターンが考えられる場合がある。機械学習によって挙動分類を行うことで、複数の挙動パターンの特微量を同じ挙動として学習させることにより、自転車利用者の個人差に柔軟に対応することができると言えられる。このことから、機械学習を用いた検出手法は、回避を始めるタイミングの差やハンドルの切り方における個人差を考慮した分類モデルを生成することができると考えられるため、参加型センシングを用いる本研究に適した手法であると考える。

### 2.2.2 複数の挙動を含む挙動データを用いた特定挙動の個別検出に関する研究

複数の挙動を含む自転車挙動データから特定の挙動を個別に検出する研究として文献[10][13][14][15][16]が挙げられる。

文献[10][14]では、各センサの値に閾値を設定し、閾値を超えた箇所については全て検出するという手法をとっている。この手法では、自転車のふらつきやその他の挙動によってセンサの値が閾値を超える場合でも全て検出し、抽出してしまうという欠点が考えられる。

文献[13][15]では、滑り窓を用いて直進、蛇行、カーブなどの挙動に分類している。そして、毎回の分類時に前の挙動の分類結果を用いることで、より可能性の高い挙動へ分類する手法をとっている。この手法では、挙動データの連續性を考慮することで前の挙動の状態からは考えられない挙動への誤分類を防ぐことが可能である。しかし、これらの文献が対象としている挙動の特徴として、直進、蛇行、カーブなど一定時間続く継続的な挙動であることが挙げられる。本研究が対象としている障害物回避挙動は、瞬間に行われる継続性のない挙動であり、この手法を適用することは難しいと考えられる。また、滑り窓を用いた手法では特微量を抽出する必要のない直進区間においても特微量の抽出を行うこととなり、計算コストが高くなってしまうという問題もあげられる。

文献[16]では、最近傍法を用いた異常検知によって検出対象を検出している。訓練データとして正常なデータを学習し、テストデータと訓練データの間の距離を算出し、距離が大きいテストデータを異常なデータとして検出する。この手法は、直進区間を正常なデータとして訓練し、回避挙動が含まれる区間を異常なデータとして検出することができる。障害物回避区間の可能性が高い区間に限定して特微量抽出を行うことができるため、本研究に有効な手法であると考える。

## 3. 快適な車道経路推薦に向けた障害物回避挙動検出手法

著者らはこれまでに、自転車が障害物を回避する際に特徴的な変化を示す挙動データから抽出した特微量を用いた機械学習により、障害物回避挙動を検出する手法[7][8]を提案してきた。以下に先行研究の手法を含んだ本研究の概要および本稿で提案する障害物回避区間候補の抽出手法の位置づけについて述べたのち、先行研究の手法について詳細に述べる。また、本稿で新たに提案する障害物回避区間候補の抽出手法の詳細については次章で述べる。

### 3.1 提案手法の概要

本研究の提案手法について全体の概要を図1に示す。

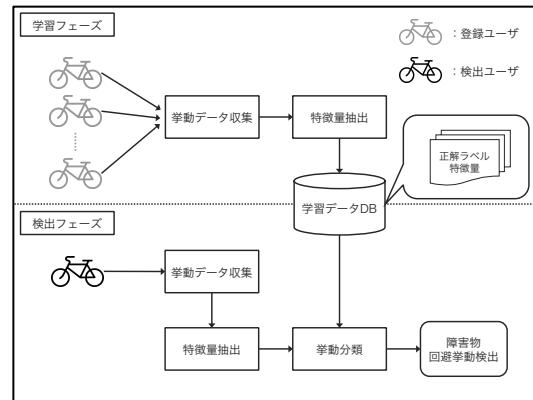


図1 提案手法の全体像

提案手法は、学習フェーズと検出フェーズの2つのフェーズで構成される。学習フェーズでは、学習データをデータベースに登録する登録ユーザが自転車走行中に収集した自転車挙動データから、学習に用いる特微量を抽出する。抽出した特微量を正解ラベルとともに学習データのデータベースに格納する。そして、この学習データを用いて複数種類の障害物回避挙動を学習する。検出フェーズでは、参加型センシングの協力者である検出ユーザが自転車走行中に収集した自転車挙動データから、特微量を抽出し、抽出された特微量を用いて障害物の回避挙動と見られる挙動を検出する。

検出フェーズのうち、特微量抽出において1章で述べたように長距離走行時の挙動データへ適用する手法を新たに検討する必要があった。そこで本稿では異常検知に基づく障害物回避区間候補の抽出手法を検討する。この手法を用いて長距離走行時の挙動データから障害物回避区間候補を個別に抽出することで先行研究の手法を適用可能な状態にし、障害物回避挙動検出を行う。本稿の手法を含んだ挙動データの収集から障害物回避挙動検出までの流れを図2に示す。



図2 挙動データ収集から障害物回避挙動検出までの流れ

### 3.2 自転車挙動データの収集

障害物回避挙動を検出するためには、走行中の自転車からハンドル操作や加減速などの自転車挙動データを収集する。近年、スポーツ自転車の利用者を中心に、走行記録の収集や経路案内を目的としてハンドルにスマートフォンを設置する利用者が増加していることから、収集するためのセンサとして、スマートフォンを用いる。スマートフォンは、図3のように上部が自転車の進行方向に向くように地面と水平に設置する。収集するセンサデータは、加速度、角

速度、地磁気、GPS とし、サンプリングレートは加速度、角速度、地磁気が 100Hz、GPS が 5Hz とした。さらに、現状の GPS の精度では正確な速度を算出することが困難であるため、自転車用のスピードセンサも用いた。スピードセンサは図 4 のように自転車の後輪に設置し、後輪に設置した磁石の回転をセンサによって検出し、単位時間あたりの回転数をもとに速度を算出する。サンプリングレートは、仕様の都合上 1Hz とした。そして、ハンドル操作の挙動については、操作とともに変化する進行方位に着目する。進行方位は、加速度、地磁気センサの値から算出される。また、加減速については、本稿ではスピードセンサの値を用いて分析を行うが、将来的には GPS の測位精度の向上が見込まれるため、GPS を用いた位置情報と加速度センサの値から算出することを考えている。これにより、スマートフォンを設置するだけで必要な情報を収集することが可能となるため、導入コストを抑えることができると考える。

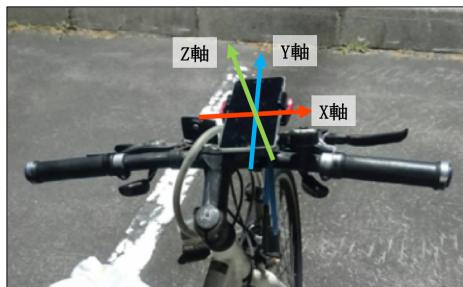


図 3 スマートフォンの設置方法および各センサの座標軸



図 4 スピードセンサの設置方法

### 3.3 特徴量抽出

3.2 節の方法で収集した自転車挙動データから抽出する

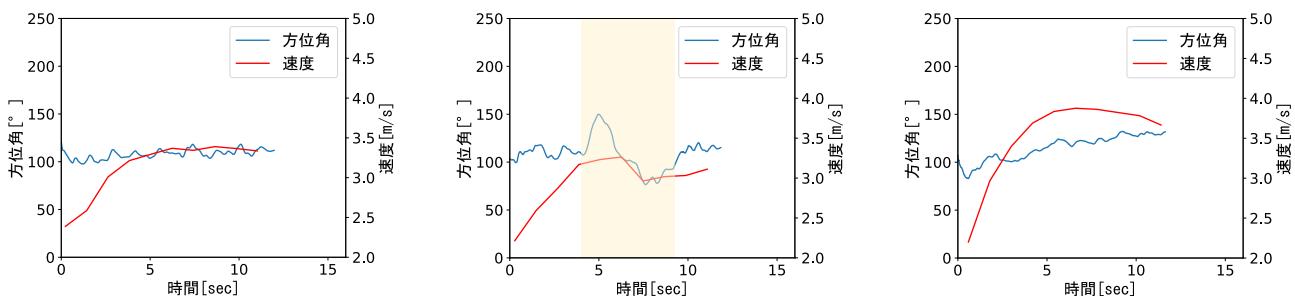


図 5 各条件における方位角および速度の変化

回避挙動検出に有効な特徴量を検討する。直進時の挙動データと直進中に障害物を回避した際の挙動データ、および右カーブ走行の際の挙動データのうち、方位角と速度に関するものをそれぞれ図 5 の(a), (b), (c)に示す。

#### 3.3.1 方位角に関する特徴量

障害物を回避する際やカーブを走行する際には、ハンドル操作によって方位角に変化が現れる。図 5 (b)の網掛けの箇所からわかるように、障害物を回避すると進行方位が変化することから方位角が大きく振れる。そこで、方位角の平均値を基準とした正負への変化がそれぞれ最大となる点を検出することで回避挙動を検出することが可能である。

また、図 5(c)より左右のカーブ走行時には方位角が減少または増加し続ける。そのため、図 6 で示すように正負への変化量を算出する際に、単に平均値を基準とした正負への変化の最大値・最小値をとる点を特徴とするだけでは意図したとおりの特徴を掴むことができない。そこで、値の変動傾向を掴むために線形近似直線を用いる。変動傾向を近似することで正負への変化について近似値からの最大変化量をとる点を検出することでカーブ走行時にも安定して特徴量を抽出できる。

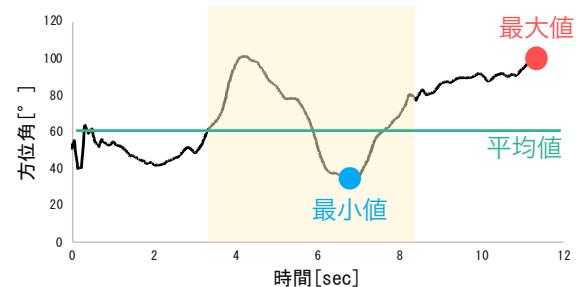


図 6 カーブ走行時における特徴量抽出の問題

さらに、方位角の変化には右にハンドルを切った後、左に切り返すまでの経過時間を表す特徴も現れる。この特徴を用いて、回避した障害物の規模を推定することが可能であると考える。実際に排水溝の蓋などの小規模な障害物を回避した場合と、路上駐車の車両などの中規模な障害物を

回避した場合の挙動データを比較したものを図7に示す。図7より、路上駐車の車両を回避した方がより早い段階から方位角が振れ始め、より長い時間振れていることがわかる。このことから回避挙動の開始から終了までの経過時間を特徴として障害物の規模を分類する。

以上の特徴を抽出するための式を、式(1)～(3)に示す。

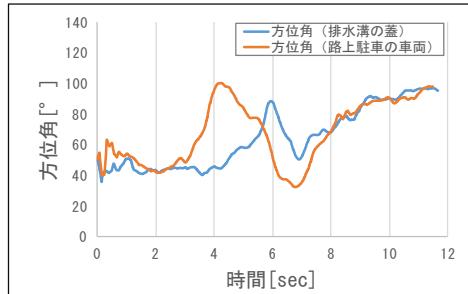


図7 障害物の規模の違いによる回避挙動の変化

$$Diff_{az\_max} = y_{az\_max} - f_{az}(T_{az\_max}) \quad (1)$$

$$Diff_{az\_min} = y_{az\_min} - f_{az}(T_{az\_min}) \quad (2)$$

$$T_{az\_int} = |T_{az\_min} - T_{az\_max}| \quad (3)$$

$Diff_{az\_max}$ は、方位角の実測値と線形近似曲線 $f_{az}(x)$ によって近似された近似値の差が最大（正の値）となる点 $T_{az\_max}$ における実測値 $y_{az\_max}$ と近似値 $f_{az}(T_{az\_max})$ の差を表す。 $Diff_{az\_min}$ は、実測値と近似値の差が最小（負の値）となる点 $T_{az\_min}$ における実測値 $y_{az\_min}$ と近似値 $f_{az}(T_{az\_min})$ の差を表す。また、 $Diff_{az\_max}$ ,  $Diff_{az\_min}$ は障害物の回避挙動を検出するために用いる。そして $T_{az\_int}$ は、時刻 $T_{az\_max}$ ,  $T_{az\_min}$ 間の経過時間を表し、障害物の規模を分類するために有用と考えられる。以上の特徴量を用いて回避挙動の検出を行う。これらの特徴量の関係を図8に示す。

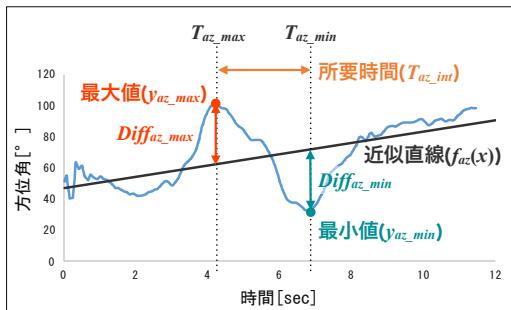


図8 方位角の変化に関する特徴量

### 3.3.2 速度変化に関する特徴量

図5(b)からわかるように、障害物回避時に急激な減速が生じる場合があるという特徴に着目する。

まず、急激な減速を検出するために、減速がない場合の速度変化の傾向を推測する必要がある。そこで、方位角の

変化と同様に、速度の値の線形近似曲線 $f_{sp}(x)$ を求める。次に、実測値と近似値との差が最大となる点 $T_{sp\_max}$ における実測値 $y_{sp\_max}$ と近似値 $f_{sp}(T_{sp\_max})$ との差 $Diff_{sp\_max}$ を求める。同様に、実測値と近似値との差が最小となる点 $T_{sp\_min}$ における実測値 $y_{sp\_min}$ と近似値 $f_{sp}(T_{sp\_min})$ との差 $Diff_{sp\_min}$ を求める。速度変化の中で極大値・極小値を取る点 $sp_{ex}$ について、隣接する極大値と極小値の差 $Diff_{acc/dec\_sp}$ を求める。特徴量の関係と算出の式をまとめたものを式(4)～(6)に示す。また、各特徴量の関係についてまとめたものを図に示す。

$$Diff_{sp\_max} = y_{sp\_max} - f_{sp}(T_{sp\_max}) \quad (4)$$

$$Diff_{sp\_min} = y_{sp\_min} - f_{sp}(T_{sp\_min}) \quad (5)$$

$$Diff_{sp\_acc/dec} = sp_{ex\_i} - sp_{ex\_i-1} \quad (6)$$

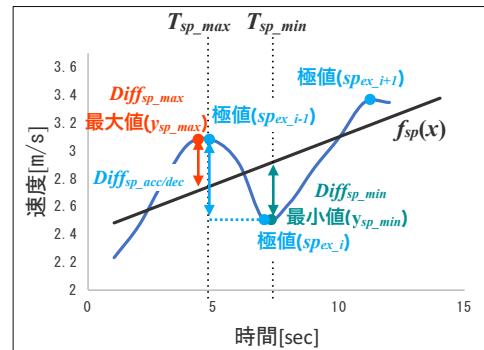


図9 速度変化に関する特徴量

$f_{sp}(x)$ の傾きを用いることで走行中全体の速度変化の傾向を得ることができる。また、 $Diff_{sp\_max}$ ,  $Diff_{sp\_min}$ は急激に速度が変化することで絶対値が大きな値をとるため、急激な速度変化を検出することができる。そして、 $Diff_{sp\_acc/dec}$ の最小値を用いることで急激な減速における減速量を算出することができる。

### 3.4 障害物検出

障害物の検出は、自転車の挙動から障害物を回避する挙動を検出することによって行う。そして自転車の障害物回避挙動検出は、教師あり機械学習によって行う。分類対象は、排水溝の蓋などの小規模な障害物、路上駐車の車両などの中規模な障害物、バスやトラックなどの大規模な障害物を想定する。そして、その中でも特に遭遇頻度が高いと考えられる小規模な障害物と中規模な障害物に着目し、前節で述べた特徴量を用いてSVMによる分類を行う。

## 4. 先行研究手法の実環境への適用

3章では、先行研究を含めた提案手法の概要および、先行研究の手法の詳細について述べた。本章では、先行研究の手法を実環境へ適用する際に検討すべき課題およびアプローチの一部として本稿が提案する手法について述べる。

#### 4.1 実環境への適用にあたっての先行研究手法の課題

本研究は、自転車利用者に向けて快適に走行可能な車道経路を推薦することを最終目標とする。そのために、自転車挙動データを用いて障害物回避挙動を検出することで、車道上の障害物を検出することを目的とする。

著者らがこれまでに提案した障害物回避挙動の検出手法では、実環境へ適用するにあたって大きく以下のようないくつかの課題が挙げられる。

- ・車道・歩道の走行場所判別
- ・長距離走行時の挙動データからの回避挙動の個別検出
- ・障害物情報と地図データの紐づけ

まず、車道における障害物の情報を収集することを目的としているため、車道・歩道の走行場所の判別を行う必要がある。次に、これまでにも述べたように長距離走行時の挙動データには複数の障害物回避挙動が含まれるが、前述した先行研究の手法では複数の障害物回避挙動を個別に検出することができない。そのため、障害物回避区間の候補を個別に抽出し、手法を適用する必要がある。そして、手法を適用して収集した障害物の情報を地図データと紐付けるために、道路ネットワークを利用したデータベースを構築する必要がある。

そこで本稿では、まず、最も重要であると考えられる長距離走行時の挙動データから障害物回避区間候補を抽出し、障害物回避挙動検出を行う手法を検討する。

#### 4.2 障害物回避区間候補の抽出

障害物回避区間候補の抽出にはまず、直進区間の挙動データと長距離走行時の挙動データに対するデータ間の距離計算を行う。そして、算出されたデータ間の距離を用いて、直進区間の挙動データを正常なデータ、データ間の距離が大きくなつた区間の挙動データを異常なデータとした異常検知を行い、障害物の回避区間候補の抽出を行う。以下に距離計算の方法および回避区間候補抽出の方法を述べる。

##### 4.2.1 データ間の距離計算

距離計算に用いる挙動データは Z 軸（ハンドル回転軸）角速度の値とし、直進区間の挙動データと、直進区間を基本として複数の障害物回避区間を含む長距離走行時の挙動データとの間のユークリッド距離  $L$  を算出する。ユークリッド距離の算出には  $k=1$  とした  $k$  近傍法を用いる。また、各点ごとのユークリッド距離をそのまま用いると、1つの回避区間候補においてユークリッド距離のピークが複数生じることが考えられる。そこで、距離の算出結果を平滑化することで、1つの回避区間候補において1つだけピークが生じるようにする、距離の算出結果の平滑化のために、ある点を中心に 1.5 秒間の点における距離の算出結果を平

均する。そして、算出結果の平均をその点におけるユークリッド距離とした。実際に算出した結果を図 10 に示す。

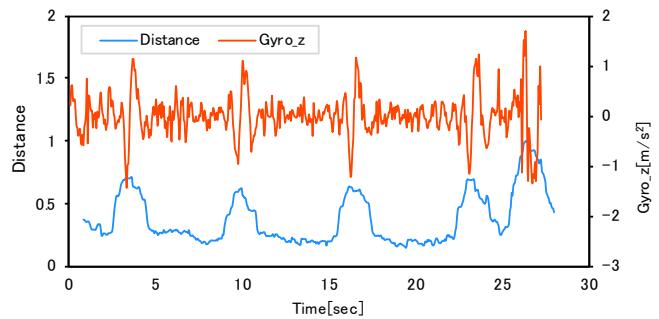


図 10 Z 軸角速度とユークリッド距離

##### 4.2.2 障害物回避区間候補の抽出

前項で算出したユークリッド距離  $L$  を用いて、ユークリッド距離の最頻値  $L_{mode}$  を算出する。長距離走行時は直進区間が大半を占めると考えられるため、 $L_{mode}$  が直進区間の平均的なユークリッド距離と考えられる。本手法では、距離が  $L_{mode}$  付近となる区間の挙動データを正常なデータとして扱う。

そして、障害物回避時は Z 軸角速度が大きく振れ、ユークリッド距離が大きくなることから、 $L_{mode}$  の定数  $C_l$  倍の距離  $L_{const}$  以上の距離を持つ区間を異常なデータとして検知し、検知した区間における極大値を算出する。これにより、障害物回避区間の中心地点を抽出することができると言える。

最後に、極大値をとる地点が障害物回避箇所のほぼ中心であるという知見から、その地点の前  $t$  秒、後  $t$  秒の  $2t$  秒間を障害物回避箇所として抽出する。抽出する時間幅  $t$  は検出対象とする障害物の規模によって異なると考えられるため、排水溝の蓋程度の規模の場合、路上駐車の車両程度の規模の場合と複数の時間幅を用いて抽出処理を並行して行う。このとき、1 つの回避区間候補に複数の極大値が現れる 것을想定し、一度抽出した区間については重複して抽出しないものとした。排水溝の蓋の回避挙動を例に以上の処理を図 11 に示す。

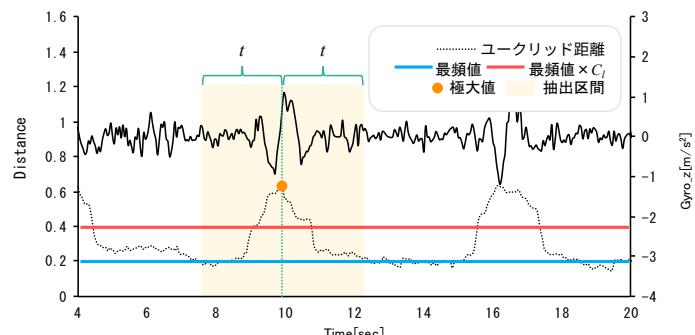


図 11 ユークリッド距離を用いた回避区間候補の抽出

## 5. 評価実験

本稿では、著者らの先行研究[7][8]の手法を長距離走行時の挙動データに適用するために、障害物回避区間候補を個別に抽出する手法を新たに提案した。本章では、新たな提案手法の評価を行うために、実際の長距離走行時の挙動データを用いた障害物回避区間候補の抽出精度を評価する実験を行う。また、抽出した障害物回避区間候補の挙動データに対して障害物回避挙動の検出精度の評価も行う。

### 5.1 自転車挙動データの収集

実験を行うにあたって著者らのうち1人が被験者となり公道環境を走行し、3.2節で示した挙動データを収集した。このとき、挙動データが収集されることを意識せず、普段どおりに走行することを心がけた。収集した挙動データは、車両の交通量が多い車道を約600m、比較的に交通量が少ない車道を約800m走行したものであり、どちらも平坦な直線道路におけるものである。また、実際に走行した際に遭遇した障害物は排水溝の蓋のみで、路上駐車の車両に遭遇することはなかった。そして、障害物回避区間候補の抽出精度や障害物回避挙動の検出精度を評価するために、自転車にカメラを設置し、走行中の様子を記録することで正解データを同時に収集した。それぞれの車道において遭遇した障害物の数をまとめると、交通量の多い車道では15箇所存在し、交通量の少ない車道では18箇所存在した。

### 5.2 障害物回避区間候補の抽出精度の評価

5.1節で収集した長距離走行時の挙動データを用いて、障害物回避区間候補の抽出を行い、動画による正解データをもとに精度を評価する実験を行った。このとき、データ間のユークリッド距離の極大値の算出条件の距離である $L_{const} = C_l L_{mode}$ において、 $C_l$ の値を $C_l = 1.5, 2.0, 2.5$ と複数の値を用いて評価した。

#### 5.2.1 実験結果

実験結果を表1に示す。

表1 区間候補の抽出実験の結果

##### (a) $C_l = 1.5$ の場合

	抽出した区間			抽出漏れ	障害物数
	正解	誤り	合計		
交通量(多)	13	4	17	2	15
交通量(少)	16	1	17	2	18
合計	29	5	34	4	33

##### (b) $C_l = 2.0$ の場合

	抽出した区間			抽出漏れ	障害物数
	正解	誤り	合計		
交通量(多)	13	3	16	2	15
交通量(少)	16	0	16	2	18
合計	29	3	32	4	33

##### (c) $C_l = 2.5$ の場合

	抽出した区間			抽出漏れ	障害物数
	正解	誤り	合計		
交通量(多)	10	4	14	5	15
交通量(少)	16	0	16	2	18
合計	26	4	30	7	33

まず、全体の抽出精度を見ると、どの条件の場合にも8割以上の精度で抽出できた。

次に、 $C_l$ の各値における実験結果を比較する。値が大きくなるとユークリッド距離の極大値算出条件が厳しくなることから、 $C_l = 2.5$ のときに最も抽出漏れが発生している。一方で、 $C_l = 1.5$ のときは誤って抽出された区間が最も多くなっている。ここで、 $C_l = 2.0$ のときの結果を見ると、抽出漏れと誤った抽出のどちらも最も少ないことがわかる。この結果から、 $C_l = 2.0$ が抽出に最適であると考えられる。

#### 5.2.2 考察

実験の結果から、抽出精度と $C_l$ の値の関係性がわかった。ここからは、抽出漏れや誤った抽出が生じた箇所について詳しく見ていく。

まず、交通量が多い車道における実験結果を考察する。障害物回避区間の抽出漏れについて、抽出漏れが生じた区間を確認すると、交通量が多いことで障害物を回避する際に右に避ける動作がかなり小さくなり、Z軸角速度の値がほとんど振れていないことがわかった。その結果、算出されるユークリッド距離が小さくなつたため抽出することができなかつたと考えられる。また、誤って抽出された区間にについて見てみると、どの区間においても側方を車両が通過している最中で、障害物を右に回避することができていなかつた。その結果、排水溝の蓋の上を通過することとなり、大きな衝撃が自転車に伝わったことで、Z軸角速度が大きく振れてしまったと考えられる。

次に、交通量の少ない車道における実験結果を考察する。障害物回避区間候補の抽出漏れについて、抽出漏れが生じた区間を確認すると、交通量が少なく、余裕を持って障害物を回避することが可能となり、目立った回避挙動が現れていなかつた。その結果、交通量が多い場合と同様にユークリッド距離が小さくなつたため抽出することができなかつたと考えられる。また、交通量が少ないので排水溝の

蓋の上を通過するような挙動が見られず、センサデータに影響を与えることがなかったことから、誤った抽出は存在しなかったと考えられる。

### 5.3 障害物回避挙動の検出精度の評価

5.2 節で本実験の条件下においては最適とされた、 $C_t = 2.0$  の条件で抽出した挙動データについてそれぞれ特徴量を抽出し、SVMによる障害物回避挙動検出の実験を行った。実験に用いた学習データは、著者らが先行研究において行った人工環境下での基礎実験のなかで、障害物を回避した際の挙動データを用いた。学習した挙動データの内訳は、障害物の回避がない挙動、排水溝の蓋を回避する挙動、路上駐車の車両を回避する挙動をそれぞれ 90 試行分である。

実験の準備としてまず、抽出時間幅の条件  $t$ 、 $C_t$  について検討した。今回の実験における障害物は排水溝の蓋のみであったため、小規模な障害物を想定した条件を設定した。自転車の平均的な速度は約 4m/s とされており、排水溝の蓋は道路脇に約 30m 間隔で設置されていることから、約 7 秒間隔で排水溝の蓋に遭遇することとなる。以上より、一つの抽出区間に中に二つ以上の排水溝の蓋を含まないためにも、時間幅は 6 秒程度以内にすることが望ましいと考えた。それに従って、表 2 に示す 3 つの条件によって時間幅を設定し、実験を行った。

表 2 抽出時間幅の各条件

	$t$	極大値の前後 $2t$ 秒間
条件 1	3	6
条件 2	2.5	5
条件 3	2	4

#### 5.3.1 実験結果

実験の結果を表 3 に示す。

表 3 障害物回避挙動検出実験の結果

(a) 条件 1 ( $t = 3$ ) の場合

	検出	検出漏れ	誤検出	障害物数
交通量 (多)	4	11	0	15
交通量 (少)	16	2	0	18
合計	20	13	0	33

(a) 条件 2 ( $t = 2.5$ ) の場合

	検出	検出漏れ	誤検出	障害物数
交通量 (多)	4	11	2	15
交通量 (少)	16	2	0	18
合計	20	13	2	33

(a) 条件 3 ( $t = 2$ ) の場合

	検出	検出漏れ	誤検出	障害物数
交通量 (多)	2	13	2	15
交通量 (少)	16	2	0	18
合計	18	15	2	33

まず、全体の障害物回避挙動の検出精度を見ると、5, 6 割の精度という結果となった。交通量による比較を行うと、交通量が多い車道では 2 割程度と低い精度であるのに対して、交通量が少ない車道では 8 割を超える精度で検出することができている。

次に、各条件における実験結果を比較する。最も精度が高い結果となったのは条件 1 となり、一方で最も精度が低い結果となったのは条件 3 となった。

#### 5.3.2 考察

まず、条件の違いによる精度の変化について考察する。条件 1, 2, 3 へと変わるために極大値前後から抽出する時間幅が狭くなる。条件 1 では 6 秒間の挙動データを抽出しているため、障害物回避区間の前後に存在する直進区間も含まれている。しかし、条件 2, 3 と時間幅が狭くなった結果、障害物回避区間の前後に存在する直進区間が抽出した挙動データに含まれていない場合があった。それにより、3.3.1 節で述べた方位角に関する特徴量を抽出する際に用いる近似直線が意図した通りに算出されなかったことで、その後の特徴量が正しく抽出されず、検出精度に影響したと考えられる。

次に、交通量が多い車道において検出精度が低い原因を考察する。検出漏れとなった挙動は、5.2.2 項でも述べたように、側方を通過する車両が多いことで右への回避挙動がかなり小さくなってしまったことが原因と考えられる。学習データとして用いた人工環境下での回避挙動データと、今回検出漏れとなった回避挙動データを比較したグラフを図 12 に示す。青い線で示した学習データは回避時に方位格が  $30^\circ$  前後振れているのに対して、検出漏れとなった回避挙動は  $10^\circ$  前後程度しか振れていないことがわかる。このことにより、特徴量を抽出した際に大きく異なった特徴量となってしまい、検出されなかつたと考えられる。

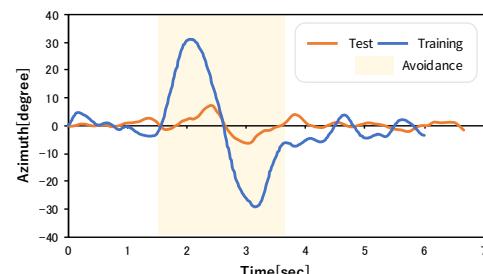


図 12 学習時と実環境時の回避挙動の違い（方位角）

## 6. おわりに

本研究は、自転車利用者に向けて快適に走行可能な車道経路を推薦することを最終目標とする。そのために、自転車挙動データを用いて障害物回避挙動を検出することで、車道上の障害物を検出することを目的とする。著者らはこれまでに、自転車の進行方位が障害物を回避する際に変化するという特徴を用いた機械学習により、障害物回避挙動を検出する手法[7]や、さらに速度に関する特徴を用いた手法[8]を提案してきた。しかし、この手法は1つの挙動データに対して障害物回避挙動を1つだけ含んでいる場合に限り適用可能な手法であった。そのため、この手法を実環境に適用するにあたって、複数の障害物回避区間を含んだ長距離走行時の挙動データから障害物回避区間候補を個別に抽出し、手法を適用する必要があった。そこで本稿では、直進区間の挙動データと長距離走行時の挙動データに対してデータ間の距離計算を行い、距離が大きい区間を障害物回避区間候補として抽出する手法を検討した。

本稿で検討した手法について、実際の公道を走行した自転車挙動データを用いた障害物回避区間候補の抽出精度および、抽出した区間にに対する障害物回避挙動検出精度の評価実験を行った。実験の結果、8割以上の精度で障害物回避区間候補を抽出することができたが、その後の障害物回避挙動検出では6割程度の精度という結果となった。原因として、障害物回避挙動を検出する機械学習に用いる学習データと実際に公道を走行した際に収集した障害物回避挙動データの間に大きな差があったことがあげられる。この問題に対して、今後は障害物回避時のハンドルの切り方の変化に対応するために、特微量のスケーリングを行うなど、手法の改善を行う必要がある。また、回避区間の切り出しに用いるパラメータの算出方法が複数の利用者の個人差や異なる走行条件に対応できるものであるかの評価も行う必要がある。そして、最終目標である快適な車道経路推薦に向けて、障害物検出以外の要素として考えられた路面状態や勾配などの情報の収集方法も検討していく必要がある。

**謝辞** 本研究の一部は JSPS 科研費 JP17K00128 の助成を受けたものである。

## 参考文献

- [1] 総務省 統計局, 平成27年における交通事故の発生状況, <http://www.e-stat.go.jp/SG1/estat/Pdfdl.do?sinfid=000031400112>, (accessed 2017-1-14).
- [2] 国土交通省, 自転車交通, <https://www.mlit.go.jp/common/001085121.pdf>, (accessed 2017-10-23).
- [3] 自転車ライフプロジェクト, 自転車大好きマップ, <http://www.bicyclemap.net/>, (accessed 2017-10-23).
- [4] J. Burke, D. Estrin, M. Hansen, A. Parker, N. Ramanathan, S. Reddy and M. B. Srivastava, "Participatory Sensing," *World-Sensor-Web (WSW '06) at SenSys '06*, pp.1-6 (2006).

- [5] 松田裕貴, 新井イスマイル, "スマートフォン搭載照度センサの集合知によるセンサ入光特性を考慮した夜道の安全性判定システムの構築", 情報処理学会マルチメディア、分散、協調とモバイルシンポジウム 2014 論文集, pp. 966-974 (2014).
- [6] 前中省吾, 森下慈也, 永田大地, 玉井森彦, 安本慶一, 福倉寿信, 佐藤啓太, "桜センサ: 車載スマートフォンによる画像処理に基づいた桜景観の良い道路区間の抽出", 情報処理学会研究報告, モバイルコンピューティングとユビキタス通信(MBL), Vol.72, No.19, pp. 1-8 (2014).
- [7] 武安裕輔, 白石陽, "快適な車道推薦のための自転車挙動データを用いた障害物検出手法", 情報処理学会マルチメディア、分散、協調とモバイルシンポジウム 2017 論文集, pp.83-90 (2017).
- [8] 武安裕輔, 白石陽, "自転車の障害物回避挙動検出における速度変化特徴の有効性の検討", 情報処理学会研究報告, 高度交通システムとスマートコミュニティ(ITS), Vol.71, No.6, pp.1-8 (2017).
- [9] 下山直起, 安藤輝, 山崎和人, 石井貴拓, 平山雅之, "マルチセンサを用いた走行解析による自転車事故防止システムの検討", 情報処理学会研究報告, 組込みシステム(EMB), Vol.36, No.51, pp.1-6 (2015).
- [10] 田端佑介, 河内雄太, 山本光, 浅田翔平, 金田重郎, "自転車ユーザに障害物情報を提供する路上障害度共有システム", 電子情報通信学会技術研究報告, 高度道路交通システム(ITS), Vol.113, No.491, pp.1-6 (2014).
- [11] A. Zhan, M. Chang, Y. Chen and A. Terzis, "Accurate Caloric Expenditure of Bicyclists Using Cellphones," *Proceedings of the 10th ACM Conference on Embedded Network Sensor Systems*, pp.71-84 (2012).
- [12] 宮崎雄也, 菅本圭亮, 木谷友哉, "二輪車の障害物回避動作検出による路面損傷一推定手法", 情報処理学会研究報告, 高度交通システムとスマートコミュニティ(ITS), Vol.68, No.6, pp.1-9 (2017).
- [13] 神村吏, 木谷友哉, "SVM を用いた二輪車の運転挙動分類の基礎検討", 情報処理学会マルチメディア、分散、協調とモバイルシンポジウム 2014 論文集, pp.44-52 (2014).
- [14] 田端佑介, 山本光, 河内雄太, 浅田翔平, 金田重郎, "モバイルアドホックネットワークを利用した複数自転車向け路上危険箇所共有システム", 電子情報通信学会技術研究報告, 知能ソフトウェア工学(KBSE), Vol.113, No.475, pp.73-78 (2014).
- [15] 斎藤裕樹, 菅生啓示, 間博人, テープウイロージャナボンニワット, 戸辺義人, "sBike: 参加型センシングを志向したモバイルセンシングによる自転車走行状態収集・共有機構", 情報処理学会論文誌, Vol.53, No.2, pp.770-782 (2012).
- [16] 中村隆顕, 今村誠, 立床雅司, 平井規郎, "標本部分列を用いた時系列データ異常検知方式", 電学論 C, Vol.136, No.3, pp.363-372 (2016).