

平成 25 年度 修士論文

3軸加速度センサを用いた自転車の挙動認識

平成 26 年 2 月 14 日

12350917

後藤 秀信

指導教員 三浦 元喜 准教授

九州工業大学大学院 工学府 先端機能システム工学専攻

## 概要

近年健康意識の増加や環境問題の影響などにより自転車の運転者が増加傾向にある。しかし、日本における自転車道の整備は欧米諸国と比較すると遅れを取っており、路上駐車や歩道からの急な飛び出しを回避するために自転車は、自動車が走る走行車線に車線変更を行わなければならない。このような状況下では、自転車は後方から接近する自動車やバイクと接触する可能性があるため、すばやく後方へ自分の挙動を伝える必要がある。本研究ではこれらの問題を回避するためにスマートフォンに搭載されている3軸加速度センサデータを使用した機械学習を行い、その挙動結果を後方へ通知するシステムの開発、評価を行う。本研究では、まずスマートフォンの設置位置の検討を行い、次に機械学習を行う事で自転車の挙動認識が行えるのかをパソコン上で行った。その後、それらの結果を基にして自転車の挙動分類を行うスマートフォンアプリ **Cyclesports** を開発し、アプリで行われた挙動の分類結果を **USBhostAPI** 経由で **Arduino** に送信し3色 **LED** を制御し、挙動に応じた **LED** 色に変化をさせることで自転車の挙動を後方へ通知するシステムの開発を行った。そして我々は既存の固定色 **LED** と **Cyclesports** について比較評価実験を行い、**Cyclesports** は挙動確認のし易さにおいて既存のものよりも有意であることを確認した。

# 目次

<b>第1章 序論</b>	<b>4</b>
1.1 背景	4
1.2 実世界におけるインタラクションシステム	5
1.3 本研究の目的	5
<b>第2章 関連研究</b>	<b>7</b>
2.1 センサを使用した輸送用機器の挙動認識	7
2.2 加速度センサを使用した人間の行動認識	8
2.3 関連研究まとめ	8
<b>第3章 挙動認識における提案手法</b>	<b>10</b>
3.1 データ収集から特徴量算出までの流れ	10
3.2 スマートフォンの設置位置について	11
3.2.1 提案手法及び実験方法	11
3.3 実験結果	13
3.3.1 前輪上方に設置された場合	13
3.3.2 後輪上方に設置された場合	14
3.3.3 後輪軸横に設置され場合	14
3.3.4 考察	15
3.4 加速度データ収集システムについて	16
3.4.1 データ収集アプリケーションの実装	17
3.4.2 サーバ側における処理	18
3.4.3 実験領域の抽出	18
3.4.4 特徴量の算出	20
3.4.5 ファイルの整理	21

3.4.6	使用する特徴量について	22
<b>第4章</b>	<b>挙動認識</b>	<b>25</b>
4.1	実験の目的	25
4.2	実験方法	25
4.2.1	等速運動	27
4.2.2	加速運動	28
4.2.3	円走行	28
4.3	加速度データ収集結果	29
4.4	学習	30
4.5	主成分分析 (PCA)	31
4.6	挙動認識結果	31
4.6.1	主成分分析前のデータを用いた K 近傍法の認識結果	32
4.6.2	主成分を用いた K 近傍法の認識結果	33
4.6.3	主成分分析前のデータを用いた SVM の認識結果	33
4.6.4	主成分を用いた SVM の認識結果	34
4.7	特徴量及び分類器の比較と考察	34
<b>第5章</b>	<b>LED を用いた後方への通知システムの導入</b>	<b>35</b>
5.1	課題と手法	35
5.2	Cyclesports の提案	35
5.3	Cyclesports の挙動認識機能について	36
5.4	自転車後方への認識結果通知方法について	37
5.5	認識率の予備実験	38
5.5.1	実験結果と考察	39
5.6	Cyclesports の評価実験	41
5.6.1	評価実験の方法	42
5.6.2	アンケート内容	44
5.6.3	結果と考察	44
<b>第6章</b>	<b>まとめ</b>	<b>48</b>

謝辭	50
参考文献	51

# 第1章 序論

本論文は機械学習とLEDを用いた自転車の挙動認識結果を後方から接近する車両に知らせる事で危険回避を行うシステムについて論ずるものである。第一章では本テーマを取り巻く背景と世の中に存在する危険回避のためのインタラクティブシステムの紹介、そして今回提案する危険回避システムについての提案手法等を含めた本研究の目的を説明する。

## 1.1 背景

近年、自転車の利用者が増加傾向にある、特に都市部で顕著に表れている。

その背景としては、エコや健康意識の高まりに加え、2011年3月に発生した東日本大震災後に公共交通機関が麻痺し、帰宅難民となった経験等が危機意識を高め、通勤通学における自転車の利用に拍車をかけている。この様に自転車の利用者は増加しているが、表1.1にしめすように自転車専用道路等の整備が十分になされておらず、快適なサイクリング環境とは程遠いのが現状である[1]。具体的には、自転車が車道を走る際、問題となるのが後方から接近する自動車の存在である。自転車にはバックミラーやサイドミラーが装着されておらず、後方の自動車の存在に気づき辛い側面がある。

例えば、路上駐車中の自動車の追い抜きを行う際に自転車は後方を確認する必要があり、自転車の運転者には負担になる。特に都市部において、路上駐車が多く、このような場面に出会うことが多々あり、このようなことから自転車进行操作する運転者の負担が多くなると考えられる。また、後方から来る自動車の運転手はこの様な状況下において、自転車の行動(例えば、自転車は追い抜きをするのか、しないのか、または自動車の存在に気付いているのか等)を判断しづらく、両者にとって非常に危険である。また、横方向からの歩行者又は車両の飛びだしにより、走行中の自転車が急激にハンドル操作等を行った際も同じく両者にとって非常に危険である。

表 1.1: 欧米諸国と日本における自転車道の普及率

国名	年	自転車道の 延長 (km)	総道路延長に 対する割合 (%)	国土面積当たり の延長 (m/km <sup>2</sup> )	千台あたり の延長 (m/千台)	千人あたり の延長 (m/千人)
オランダ	1985	14,500	8.6	349	1,317	900
ドイツ	1985	23,100	4.7	65	660	280
日本	2006	7,301	0.6	19	84	57

## 1.2 実世界におけるインタラクションシステム

現在、我々の住む世界では様々な手段を用いて意思の伝達を行っている。我々が用いている伝達手段として最たるものは言語である。しかし、言葉が伝わらない環境下ではどうだろうか。言葉が届かないほど遠い相手に意思を伝える場合や同じ空間にいない場合の意思伝達を行う場合において言葉を使用することは出来ない。

そこで人々はこの様な状況下における伝達方法の一つとして光を使用した伝達方法を用いている。例えば車のウィンカーやブレーキランプ、そして夜間における船舶同士または航空機同士の衝突を回避する為に点灯するポジションライト等が挙げられる。佐々木ら [2] は自動車メタファを用いて歩行者同士の接触を避けるために LED 等のデバイスで歩行者自身の動きの情報を周囲に知らせるシステムの手案を行っている。また Walmlink ら [3] は LED を内蔵したヘルメットを装着し、自転車走行中に曲がりたい方向などにヘルメットを傾けることで、その動作に対応した LED が点灯し周囲に行動の内容を知らせることが出来るシステムを提案している。

## 1.3 本研究の目的

本論文では、加速度センサを使用した自転車の挙動認識をリアルタイムに行い認識結果を後方の車両に伝える Cyclesports の提案、評価を行う。挙動認識に用いる加速度センサはスマートフォンに搭載されているものを使用する。スマートフォンを利用する利点としては、現在この様な電子機器の普及は目覚ましく、将来的にシステムを実装する際に、アプリケーションとして配布することで、特別なセンサ機器等を必要としない。これら

の理由よりシステムの普及が比較的容易に行えるのではないかと考えたからである。よって我々は自転車にスマートフォンを装着し実験を行うことで自転車の挙動認識を行う。しかしスマートフォンを自転車に実際に装着すると地面の凹凸や走行風、自転車運転者によるペダリング等ノイズがある。

通常これらのノイズをカットするために用いられる方法は、入力データに対してフーリエ変換やウェーブレット変換を行うことでノイズの除去を行う方法が用いられている[4][5]。

しかし、自転車は運転者の動きの自由度が高い事やペダリングの動作が含まれること等の理由により、ノイズと自転車挙動加速度データの分類は困難であり、周波数を用いた前述のフィルター類を使用すると必要なデータも落としてしまう可能性があると考えた。これらの理由から、我々はスマートフォンの設置位置を検討することでノイズの影響を限りなく受けにくい場所を特定し、その場所にスマートフォンを設置しデータ収集を行った。我々は Cyclesports の開発、実装を行う為の基礎研究としてデータ収集アプリケーションを実装した。

このアプリケーションは 50hz の周期で 3 軸加速度データを CSV 形式でスマートフォンの内部メモリーに保存し、実験終了後にサーバーへデータ送信を行うことが出来る。この方法でサーバーに送信された 3 軸加速度データは時間窓が適用され、この時間窓をスライドし特徴量を算出し、挙動認識を行うために機械学習を用いた分類を行う。

我々は機械学習の分類器の選定を行う為に K 近傍法とサポートベクターマシンを比較し、どちらの分類器が自転車の挙動認識に適しているのかを検討するとともに特徴量が多い事で分類モデルが不安定になる可能性があるため、どのパラメータが認識に必要よいか主成分分析を行い、使用するパラメータの選択を行った。我々はこれらの結果を基に Cyclesports の開発、評価を行う。



## 第2章 関連研究

現在、センサデータ情報を使用した行動認識の研究は国内外を問わず盛んに行われている。加速度データ情報を使用した行動認識では様々な被験者の行動データを大量に取得し、ビッグデータであるそれを使用し行動認識を行っており、国内においてHASC(人間行動センシングコンソーシアム) challenge 等のイベントも盛んに行われており、小川ら [6] が発表した行動認識の研究に用いられている。第二章ではセンサを使用した行動認識等の動向を紹介する。

### 2.1 センサを使用した輸送用機器の挙動認識

センサを使用して車やバイク等の輸送用機器の挙動認識を行っている研究を紹介する。

Cossalter ら [7] は、バイク走行中に後輪タイヤが滑りグリップを失うが急速にグリップが回復することで発生するハイサイドや、グリップを失った事に起因するローサイドという転倒につながる2種類の危険挙動がある。これら2種類のどちらが発生するのかをジャイロセンサーを用いて検出し、適切な場所のエアバック放出しライダーの安全を守ることを目的とした研究である。検出に使用する3軸ジャイロセンサーはライダーとバイク両方に設置されており、実験データの収集はMotoGp2006年シーズン中に行われた。計測されたデータは絶対値の最大値と標準化された二乗平均平方根が算出され、これらのデータからハイサイドとローサイドの識別を行っている。結果はロール、ヨーにおいてハイサイドは絶対値の最大値と標準化された二乗平均平方根が共に高い値を示し、ローサイドは共に低い値を示したと結論付けられている。

Condro ら [8] は、バイク乗車中における飲酒運転や危険運転をした際に警告を運転者に知らせ、衝撃等を検知すると自動的に警察や救急車を呼ぶことが出来るシステムの提案を行っており、挙動認識には視線や顔認識での挙動認識は行わずに、より手軽に使用出来るスマートフォンを使用した挙動認識を行っている。スマートフォンはバイクのみ

に設置される。取得されたデータは通常走行時のセンサデータと異常走行時及び異常姿勢時のセンサデータのマッチングにより異常検知を行うことを提案している。

神村ら [4] は、高度交通システム (ITS) サービスに二輪車を適用させる事を目的とし、そのための基礎研究としてスマートフォンを使用した挙動把握を行った研究である。この研究においてスマートフォンは運転者から見えやすい場所であるバイクのハンドル部に設置されデータ収集を行う。しかし二輪車が走行する際にはエンジンの振動や走行路面の凹凸による振動、走行風の影響によるノイズが発生するため、ローパスフィルターを使用してノイズの除去を行ってから波形の形状より挙動把握を行った。

## 2.2 加速度センサを使用した人間の行動認識

Bao ら [9] は、体の五カ所に加速度センサを設置し、20 種類の人間行動の認識を行っている。加速度データに時間窓を用いたスライディングウィンドウ方式で特徴量の算出を行い、ここで算出された特徴量から行動認識を行った。

Zhang ら [10] は加速度センサデータにクラスタリングを施し、特定のマッピング規則に従って加速度データを各シンボルにマッピングする。これらの処理は結果として連続的な活動信号を異なるシンボルで表す列に変換することができる。これらのシンボルの種類をいくつ持っているか、どの程度もっているかという情報を使用することで人間の行動認識を行う。

多田ら [5] は自動車と運転者の腕に加速度センサを装着することで、運転者がどのようなハンドル操作を行ったのかを明らかにし、運転者の欠点や癖を定量的に評価することを目的とした実験である。取得された加速度データは wavelet 解析を使用したノイズ除去が行われ、その加速度データに時間窓を使用して特徴量の算出を行い、ユークリッド距離を用いた教師あり分析を行うことで、異常操作と通常操作の分類を行う方法が提案されている。

## 2.3 関連研究まとめ

この章では、現在行われているセンサデータを使用した行動及び挙動認識についての動向を示した。行動認識までの流れはデータ収集を行い、そのデータを基に特徴量を算

出、そして機械学習を行い行動の分類又は認識を行うという行程が一般的な流れであるが、分類する為の機械学習アルゴリズムや特徴量については各論文で色々と評価がなされている。現在、加速度データを用いた自転車の挙動認識に関する研究は少なく、自転車の挙動認識にとって必要な特徴量や機械学習アルゴリズムの検討を行う必要があると考えた。我々はこれら関連研究で提案されている手法を基に次章以降、自転車に適した挙動認識方法について提案及び評価を行う。

## 第3章 挙動認識における提案手法

第3章ではデータ収集方法から挙動認識のための特徴量算出について提案を行う

### 3.1 データ収集から特徴量算出までの流れ

我々はスマートフォンを使用した挙動認識の方法を提案する。スマートフォンを使用した挙動認識の利点としては、普及が容易であるという理由の他に各種センサ、データ送信やデータ管理等を一括して行う事が出来ることにある。我々は自転車に設置したスマートフォンに内蔵されている3軸加速度センサを使用し、加速度センサデータを使用した機械学習を用いて自転車の挙動認識を行う。分類する自転車の挙動を表3.1に示す通り4種類と定義する。我々はこれら4つの挙動は自転車を取りうる基本的な動作であり、自転車の姿勢や進行方向を決めるための大きな要因となりうる状態であると考えた。

スマートフォンは自転車のみを設置され、ノイズへ対処としては関連研究ではローパスフィルターや wavelet 解析を使用してノイズの除去を行っていたが、本研究ではこれらノイズフィルタリングの方法を使用しない。理由としては自転車の操作はバランスをとることなど細かな動作や急な動作があり、これら動作が自転車の挙動に全く関係がないというわけではなく、挙動を起こす際に必要となるデータになるのではないかと考え、バランスを取るためなのか挙動発生時なのかの区別が非常に難しく、フィルターをかける事で必要なデータを落としてしまう可能性があると考えからである。また、エンジンや路面の凹凸により発生するノイズは人間の動作に比べると明らかに高周波数帯で発生するが、ペダリング等によるノイズは人間が発生させるノイズであり、個人差やその時の状況に左右される傾向が強い。

よってノイズカットのために必要となる周波数を明確に算出することが難しく、フィルターを使用することが困難であると考えたからである。これらの理由から本研究ではフィルターを使用しないが、取得した加速度データにはノイズが多く含まれるという問

表 3.1: 4 種類の自転車の挙動

項目	運動概要
等速運動	約時速 15~17km の範囲で走行を行う運動
加速運動	ペダルを漕ぎ続ける運動
時計回り円走行	現行の道路交通法では道路に飛び出す方向の運動
反時計周り円走行	現行の道路交通法では歩道に侵入する運動

題が発生する。本研究ではこれらの問題に対処するためにスマートフォンの設置位置の検討、予備実験を行いペダリング等のノイズの影響を限りなく減少させる位置にスマートフォンを設置することでこれらの問題に対処した。

本研究における挙動認識までの流れは、まず加速度データを取得する際のスマートフォン設置位置の検討を行い設置場所の提案を行う。そして加速度データ収集のためのシステムの構成内容や実装等についての提案を行う。最後に使用する特徴量の算出方法や算出式についての提案を行い、実際に分類器にセンシングデータをかけ分類した結果を示す。

## 3.2 スマートフォンの設置位置について

まず、スマートフォンの自転車への設置位置についての検討を行う。

### 3.2.1 提案手法及び実験方法

我々はペダルを漕ぐことや路面の凹凸により発生するノイズについて、ローパスフィルターや wavelet 解析を使用したノイズ除去を行わない。我々の提案手法としては、スマートフォンの設置位置を検討することでこれらのノイズの影響を限りなく少なく出来るのではないかと考えた [11]。本研究では図 3.1 に示すように 3 カ所、前輪上方、後輪上方、後輪軸付近に Apple 社製の iPad タブレット端末を設置し、取得したデータから自転車が曲がったかことが分かる波形を確認できるか比較し評価を行う。

前輪上方に設置する場合はハンドルと連結されたカゴに設置し、自転車の運転者から視認し易い位置に固定されている。後輪上方は後輪上にある荷台にタブレット端末を固定している。この位置に設置する理由としてはハンドル操作で発生するノイズを含まないデータを、取得出来るのではないかと考えたからである。そして後輪軸付近の車体軸に設置する。この位置に設置する事でペダリングによるノイズの影響を減少することが出来



(A)



(B)



(C)

(A) 前輪上方

(B) 後輪上方

(C) 後輪軸横

図 3.1: センサ設置位置

るのではないかと考えたためである。使用するデータ収集アプリケーションは **REGREX** 社が開発した加速度センサーロガーを使用した。このアプリケーションは3軸加速度データとデータ計測時間を 3Hz ごとに同時収集し、CSV 形式でデータをまとめることが出来る。取得されたデータはリアルタイムに解析するのではなく、実験終了後に解析を行う。また、緩衝材の使用により路面等のノイズに対してどの程度効果があるのか比較を行うために、緩衝材がある場合と無い場合のデータを比較し検討を行った。実験コースは図 3.2 に示すように全長 130 メートル、3つの曲がり角を含んでいる 50m × 25m の長方形のコースを時計周りに周回した。最初の曲がり角は時速 7km で通過し、残りの二つの曲がり角は時速 15km で通過した。被験者は1名、実験回数は各設置場所につき緩衝材ありとなしを其々2回ずつ行ったので、 $3 \times 2 \times 2$  の合計 12 回の実験を行った。




図 3.2: 走行実験コース

### 3.3 実験結果

計 12 回の実験において、すべての結果において同様な傾向が表れたため、代表して其々の実験において 1 例ずつをしめす。各グラフにおけるコース上のカーブの位置は 1 つ目のカーブが 55 から 65 サンプル付近、2 つ目のカーブが 170 から 180 サンプル付近、3 つ目のカーブが 235 から 245 サンプル付近となっている。

#### 3.3.1 前輪上方に設置された場合

前輪上方に設置された場合の結果を図 3.3 に示す。図中の X 軸は自転車の進行方向軸を表しており自転車が加減速を行うと値の変動が起き、Y 軸は横方向の軸を表しており自転車の運転者が車体を傾けた時やハンドルを操作することで値の変動が起き、Z 軸は重力方向を示している。前輪上方に設置されたデータは非常にノイズが多いことが図により確認することができる。これは運転者がバランスを取る為にハンドル操作をしたことで加速度データにその操作が反映されたためであり、自転車を曲げる時のハンドル操

作も含んでいると思われるが、ノイズにより自転車が曲がったタイミングを波形から確認することは出来なかった。




図 3.3: 前輪上方に設置された場合の加速度データ

### 3.3.2 後輪上方に設置された場合

後輪上方に設置された場合の結果を図 3.4 に示す。軸方向は前輪上方に設置した場合と同様である。後輪上方に設置されたデータは前輪上方に設置した場合と比べるとバランスを取るためのハンドル操作をデータに反映しないので、比較的ノイズが少ないことが確認できる。さらに設置位置が自転車運転者に対して近いことで、路面の凹凸を越える際に運転者の体重で自転車の跳ね上がりが前輪に比べ抑制されたことにより路面凹凸の影響が多少軽減されたためであると考えられる。しかし波形より曲がったことを明確にすることはできなかった。

### 3.3.3 後輪軸横に設置され場合

最後に後輪軸横に設置された場合の加速度データを図 3.5 に示す。設置場所の関係上 X 軸方向は重力方向、Y 軸方向が自転車の進行方向、Z 軸が運転者に対して横方向を示している。






図 3.4: 後輪上方に設置された場合の加速度データ

他の二つに比べると自転車が曲がった位置に明らかな特徴をもつ波形を確認することが出来る。これは他の設置位置に比べてバランスを取るための動作や路面の凹凸を超える際に発生するノイズの影響を受けにくい場所であることに加え路面から設置場所が近いために他の場所と比べると角速度が小さくなり、自転車の運転者がペダリングの際の横ブレで発生する加速度の影響を低くすることができたためであると考えられる。

ただし、一つ目の曲がり角を曲がった際の波形は図からは読み取ることが出来なかった。これは停止位置から一つ目の曲がり角は距離が近く速度が他の曲がり角を通過した速度に比べ半分程度しか出ていないままで曲がってしまったことが原因と考えられ、加えて角速度の影響が他の設置場所に比べて低いということもあり、このような結果になったと考えられる。

### 3.3.4 考察

これら3カ所の内、後輪軸横には設置スペースの関係上緩衝材を使用することが出来なかったため、前輪上方に設置した場合と、後輪上方に設置した場合其々を図3.6、図3.7に示す。緩衝材を使用した場合と使用しなかった場合を比較すると波形にそれほど大きな変化はないということが確認できる。本研究では緩衝材は梱包用バブルパックを使用した。自転車の計測端末の間に緩衝材を設置しただけでは急な衝撃にたいしてあまり




図 3.5: 後輪軸横に設置され場合の加速度データ

効果が無かったのではないかとと思われる。よって今回行った実験より、これら3カ所のうち一番ノイズ等の影響を受けにくい場所は後輪軸横であり、緩衝材は特には必要ないという結論を得ることが出来た。

### 3.4 加速度データ収集システムについて

加速度センサの設置位置は前項の実験より、後輪軸付近において一番ノイズの影響が少なく挙動認識を行う際に最適な場所だという結果が得られたため、今後のデータ収集および実験に関しては後輪軸付近で行うこととする。

しかし、すべての実験において同じ位置にスマートフォンが設置されていなければ機械学習の際に標準化が上手くいかなくなる等、データによってばらつきが出てしまうためスマートフォンホルダを使用して設置位置を確実に固定し、設置位置を数値化する。使用するスマートフォンホルダは図 3.8 に示すように自転車の後輪軸から45度フレームに沿った6.5cmの位置に設置する。スマートフォンホルダはMINOURA製のMINOURA(ミノウラ)スマートフォンホルダ [iH-100-S] φ 22-29mmを使用する。前項まではApple製のiPadを使用して実験を行っていたが、これ以降はホルダやアプリ制作の関係上Android




図 3.6: 緩衝材を使用した前輪上方に設置された場合の加速度データ

端末を使用する。使用する端末は SonyEricsson 製の Xperia arc(LT15 i) を使用する。端末の諸元は表 3.2 の通りとなっている。

表 3.2: Xperia arc LT15 i の諸元

RAM	512MB
ROM	1GB
プロセッサ	MSM8255
クロック数	1GHz

### 3.4.1 データ収集アプリケーションの実装

我々は挙動認識を行う際に必要となるデータ収集アプリケーションの実装を行った。実装したアプリケーションは X 軸、Y 軸、Z 軸の 3 軸加速度センサデータと GPS 情報とこれらデータの取得時間を 50hz 間隔で取得し、スマートフォンの内部ストレージにこれらセンシングデータを CSV 形式で保存し、被験者自身が実験終了後に HTTP POST 通信を使用してサーバーにデータファイルを送信する。実験後にデータファイルを送信することで、失敗した時などはデータを送信せずアプリケーション内で破棄できるためデータ




図 3.7: 緩衝材を使用した後輪上方に設置された場合の加速度データ

管理を行いやすくしている。加えて、被験者情報として設置位置、実験の種類、性別、自転車の種類、使用目的を図 3.9 のように入力し、これらの情報もファイル内に添付しておくことで、サーバー側において処理を行った後の識別を容易にしている。

### 3.4.2 サーバ側における処理

アプリケーションから送信されたデータファイルはサーバ内で 3 行程の処理を受ける。図 3.10 に示すように 1 つ目は受信したデータファイル内から実験領域を抽出する処理を行い、2 つ目は抽出された実験領域から、それぞれの挙動の特徴量を算出し CSV 形式で書き出す処理、3 つ目は被験者が入力した実験内容を基に実験種類を分類し、同じ実験種類同士でまとめ実験内容を挙動のタグとして、算出した特徴量を記述した CSV ファイルにクラスパラメータとして追加で記述するという処理を行う。サーバ側で行う処理は以上であり、実際の機械学習や教師データの作成等のデータ処理は人が行うこととした。

### 3.4.3 実験領域の抽出

収集した加速度データには実験データ以外のデータが含まれていることがある。例えば端末を操作後に自転車に乗る動作や、端末を設置する動作、実験が終了して自転車を



図 3.8: スマートフォンホルダーの設置位置

降りて端末を操作する動作等が挙げられる。これらは挙動認識において必要のないデータであり、挙動認識の結果に影響を与えかねないため、これら必要のない領域のデータと実験領域のデータを明確に区別し、実験領域のデータを使用して特徴量算出を行う必要がある。一般的な方法としては、実験内容をビデオに記録しデータファイルの時刻を基に実験部分を手動で切り出す方法や、行動を制限して実験を行う場合があるが、ビデオに記録して手動で実験領域を抽出する方法は時間もかかり、データ数が増えると作業量がとても多くなるという欠点がある。また、行動を制限してデータファイルを作成する場合は、被験者の一つ一つの行動の管理が非常に大変であることに加え、スマートフォンが後輪軸付近ということもあり、自転車の運転手から操作できる位置になく実験開始や実験終了時にボタン操作を行うということもできない。

よって本研究における実験領域のデータと必要のない領域のデータを分ける提案手法としては、実験領域の最初と最後に図 3.11 に示すようなステップを用意する。このステップの大きさ及び材質等は表 3.3 に示す。加速度データの取得実験の開始と終了の際にはこのステップを超えるようにすることで実験領域とそれ以外の領域を区別する方法を提案する。このようにすることでステップを超えた時の加速度データがデータファイル内に記録されるので、そのデータを基に実験領域の抽出を行うことが可能である。尚、ステップを超えた際の加速度の値は実験中に発生するすべての加速度と比べても図 3.12 にある



図 3.9: データ収集アプリケーション

ように非常に大きなものになっているため、2カ所の山の最大値を探索する事によって実験領域の抽出が可能となる。実際に最大値が出るのは後輪が超えたときであるが、前輪が超えた際にも若干データに反映されてしまうため、余裕を持って実験領域データの両端も合わせて1秒分削除する。

表 3.3: ステップの諸元

長さ	1m
幅	5cm
高さ	5mm
材質	プラスチック

### 3.4.4 特徴量の算出

特徴量の算出方法は Bao ら [9] に提案されている方法を用いる。取得された3軸加速度データそれぞれに対して時間窓を適応したスライドウィンドウ方式を使用する。これは実験領域の加速度データに対して図 3.13 に示すように32サンプル毎の時間窓を設定




図 3.10: サーバ内の処理

し、この時間窓を前の時間窓に対して 50 % (16 サンプル分) オーバーラップさせて時間窓をスライドするように動かしていき、それぞれの時間窓毎に特徴量を算出するという方式である。

この時間窓の大きさについては、小さく設定してしまうと挙動の特徴を取ることが出来ず、大きく設定してしまうと収集したい挙動が他の挙動に埋もれてしまい、1つの挙動の特徴量として算出できなくなる。

よってこの窓のサイズは自転車の運転時に発生する挙動の頻度を加味して設定した。また、特徴量を算出する際に高速フーリエ変換を用いる関係上、2のべき乗の数値を設定している。其々の時間窓で算出された特徴量は CSV ファイル形式で保存される

### 3.4.5 ファイルの整理

被験者が実験の際に入力した実験種類によってサーバー側で其々の実験種類ファイルに分類する。さらに分類された実験種類の名前を前述の行程で算出された特徴量にクラスパラメータとして次元加えて併記することで、この後の機械学習やデータ管理を円滑に進めるようにした。





図 3.11: 実験領域を表すステップ

### 3.4.6 使用する特徴量について

この項では挙動認識に使用する特徴量について詳しく説明する．今回使用する特徴量は、人間の行動認識を目的とした論文を参考にして選定を行った．本研究では木村ら [12]、照本ら [13]、Zhang ら [10] が論文中において提案している特徴量の算出方法を組み合わせ、平均、分散、標準偏差、平均強度、分散強度、最大パワースペクトル、エネルギー、二乗平均平方根、平均交差率、1 次導関数平均、時間窓内波形の正規化を特徴量とし算出する．これら特徴量は其々の軸に適応されるため、1 つの挙動に対する時間窓内の特徴量は 3 軸それぞれに 8 次元さらに平均強度と分散強度と時間窓内波形の正規化を加えた 27 次元の特徴量が算出される．加速度 X,Y,Z の値をそれぞれ  $A_x, A_y, A_z$  とあらわし、 $t$  を時間窓内のサンプルインデックスとすると運動強度は次式  $MI(t)$  で表すことができる．

$$MI(t) = \sqrt{A_x(t)^2 + A_y(t)^2 + A_z(t)^2} \quad (3.1)$$

よって平均強度  $AI$ 、分散強度  $VI$  はそれぞれ (3.2)、(3.3) の様に表すことができる．この時  $T$  は時間窓内サンプル数 32 を表している．

$$AI = \frac{1}{T} \left( \sum_{t=1}^T MI(t) \right) \quad (3.2)$$

$$VI = \frac{1}{T} \left( \sum_{t=1}^T (MI(t) - AI)^2 \right) \quad (3.3)$$






図 3.12: ステップを超えた際の加速度

時間窓内波形の正規化 SMA は次式で表す.

$$SMA = \frac{1}{T} \left( \sum_{t=1}^T |A_x(t)| + \sum_{t=1}^T |A_y(t)| + \sum_{t=1}^T |A_z(t)| \right) \quad (3.4)$$

エネルギーに関しては、高速フーリエ変換により導出された F 成分 ( $F_{(1)}, F_{(2)}, F_{(3)}, F_{(4)}, \dots$ ) に対して絶対値を合計したものとし、時間窓内サンプル数が 32 の本研究の場合は次式で算出することが出来る. この時直流成分と折り返し成分は除去されている. 最大パワースペクトルは FFT 後のスペクトルの最大値とする.

$$energy = \frac{1}{15} \left( \sum_{i=2}^{15} |F(i)|^2 \right) \quad (3.5)$$

また、二乗平均平方根 RMS は次式で表される.

$$RMS = \sqrt{\frac{1}{T} \left( \sum_{t=1}^T A(t)^2 \right)} \quad (3.6)$$

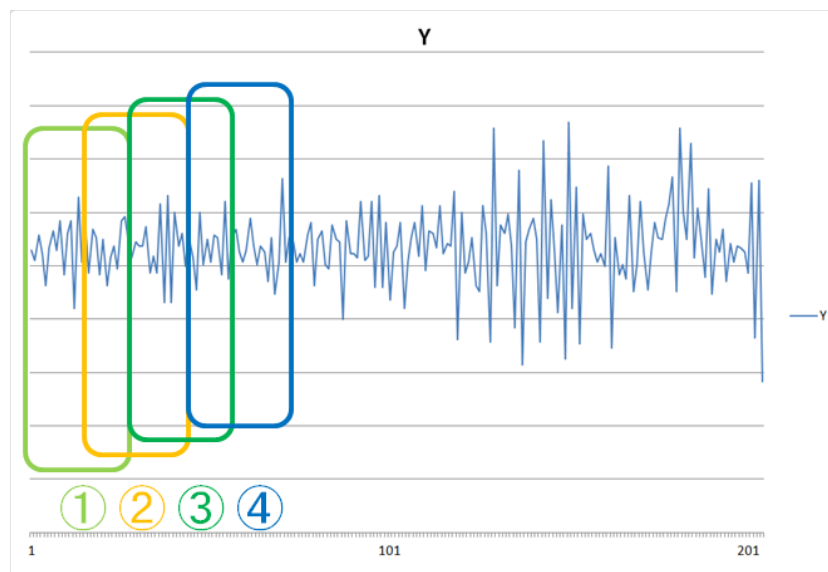


図 3.13: スライドウィンドウ方式

平均交差率は窓内で算出されたそれぞれの平均値を何回交差したかを数え、その値を 32 サンプルで割ることで算出する。1 次導関数平均は 8 サンプル分のデータの傾きを算出し、窓内でその値の平均を算出したものである。本研究ではこれらの値を自転車が起こす挙動の特徴量とし、これらの値を用いて機械学習を使用した自転車の挙動認識を行う。

## 第4章 挙動認識

第4章では3章で提案された方法を用いて、実際にデータ収集から挙動認識までを行い結果について考察を加える

### 4.1 実験の目的

現在、様々な分類器や特徴量を使用して加速度センサデータを用いた行動認識が行われているが自転車に適応されている例は少ないため、この実験では自転車が起こす可能性がある挙動を想定し、4種類の挙動を定義する。我々は加速度データから算出された特徴量を使用して、機械学習を行うことでこの4種類の自転車の挙動分類を行えるかを評価する。また、実験では二つの機械学習アルゴリズムの比較を行い、どちらが自転車の挙動認識に適しているかを確認する。比較する機械学習アルゴリズムは、ユークリッド距離を用いた多数決を使用し、仕組みがシンプルでありながらも高い認識精度を算出できると言われる分類器であるK近傍法とニューラルネットワークと違い局所解を持たず、現在使用されている分類器の中でも非常に高い認識率を算出できると言われているサポートベクターマシンを使用し、どちらが自転車の挙動認識に適しているかを認識率の面から評価する。そしてこれらのアルゴリズムを使用した際にどの特徴量が適切なかを確認する。

### 4.2 実験方法

実験により一度に取得できるデータにバラつきがあるため、それぞれの実験回数を調整する。被験者は4人、場所は路面に段差がなく水平な場所で行った。また、自転車の速度による計測データの偏りが生じないようにSUNDING製のSD-548C1ワイヤレスサイクルコンピュータを使用する。サイクルコンピュータは運転者から見えるハンドル部に

表 4.1: 実験を行う 4 種類の自転車の挙動と実験回数

運動	概要	実験回数
等速運動	約時速 15~17km の範囲で走行を行う	2 回
加速運動	ペダルを漕ぎ続ける	2 回
時計回り円走行	一定のスピードで時計回りに旋回する	2 回 × 2 周
反時計回り円走行	一定のスピードで反時計回りに旋回する	2 回 × 2 周

設置され、実験の際には速度を指定して実験を行う。この速度は自転車が通常の道路で走行する際の、おおよその平均値とする。使用する自転車は一般的なシティサイクルを使用しており、変速ギアやパワーアシスト等の装備は無い。被験者には実験前に自転車の運転やアプリケーションの操作に慣れてもらうために事前に十分な練習時間を与えた。図 4.1 に示すように実験では被験者はスマートフォンを操作し実験パラメータ情報を入力後、実験開始ボタンを押してから自転車に乗車し、実験を開始する。1つの実験が終了すると、被験者はアプリケーションにある送信ボタンを押し、データをサーバーに送信した後に次の実験へ移る。実験区域の初めと終わりに実験領域を表すためのステップを設け、被験者に実験区域への出入りの際には、このステップを必ず越えるよう指示を行った。被験者が乗車し実験を行う自転車のタイヤ内圧は 400Kps で統一し、表 4.1 にしめした 4 種類の走行実験を行い加速度データの収集を行った。自転車の代表的な挙動に停止動作があるが、本研究では停止動作に関してはデータ収集を行わないこととした。理由としては実験によるデータ収集が他の挙動と比べると難しくサンプル数を十分に取得することが難しいということもあるが、すでに加工していない加速度データを用いたブレーキランプは存在しているという理由から今回は挙動認識を行う際の実験から除外した。



図 4.1: データ計測までの手順

### 4.2.1 等速運動

まず等速運動の実験は図 4.2 に示すようにステップから離れた位置からスタートし、図 4.3 のように指定速度 15.0~16.9km/h でステップを通過する。尚、指定速度維持の為にペダル操作は可能としたが、バランスを取る以外で大きくハンドルを切り明らかに自転車の進路変更があった場合、姿勢変化があった場合や指定速度外で走行した場合はやり直しとした。実験領域の終わりを示すステップを超えた時点で実験は終了とし、被験者自身がデータの送信を行う。




図 4.2: 等速運動概要図



図 4.3: 等速運動実験様子

## 4.2.2 加速運動

被験者は図 4.4 に示すように実験領域の初めを表すステップの前で待機をし、自分の好きなタイミングで自転車を漕ぐように指示をし、スタートしたら終わりを示すステップまで座ったままで加速走行を行い、自転車が加速する際のデータ収集を行った。ペダルを漕ぐ際は座ったままで統一し速度の指定は行わなかった。ただし、等速運動と同様に明らかな進路変更があった場合はやり直しとした。




図 4.4: 加速運動概要図

## 4.2.3 円走行

被験者は直径 5m の円の周回走行を図 4.5 に示すように行った。実験の様子を図 4.6 にしめす。円の直径を 5m とした理由は、国土交通省がしめす自転車道の設計基準 [14] より自転車道の曲率は通常 10m~30m と決められ、特別な理由によりやむを得ない場合においても 3m が最小半径として決められている。

これよりも短い曲率半径をもつ道路は直角に曲がる以外にないと思われる。よってこの長さよりも短い曲率半径で曲がることは、自転車の運転者が何かしらの理由で意図的にハンドルを操作して自転車の進路変更をしたことを表すことが出来ると考え、円走行における実験では直径 6m 以下の円を設定した。

しかし、円走行中において走行の軌跡が膨らむと考えたため余裕を持って直径 5m の円を設定し実験を行った。この時の指定速度は時速 14.0~16.9km として、被験者は円走行

に入る前に指定速度まで加速し、同じようにステップを通過しデータ取得を開始し、2周まわると実験終了を示すステップを設置しステップを超えたのちに実験を終了する。この円走行実験を時計回りと反時計回りで実施する。




図 4.5: 円走行実験概要図

### 4.3 加速度データ収集結果

被験者 4 名の内 1 名に対して、円走行及の実験において一部操作の不安定さを確認したため、全実験回数は 28 回となっている。実験により得られた CSV ファイル数及び実験領域の抽出結果、データ数を表 4.2 に示す。

取得 CSV ファイルの総数は 28 件であるが、データ収集アプリケーションのデータ送信エラーによるデータの欠損が 1 件あるため、特徴量が算出された CSV ファイル数は 27 件である。

その内 2 件のファイルが、実験領域が誤認識され実験領域外の加速度データを含んでいることが確認できた。誤認識されたファイルは等速運動時の実験であり、誤認識の原因としてはスマートフォン端末操作後に自転車のスタンドを上げ、タイヤを設置させたことにより大きな加速度が発生し、これがステップを超えたと識別されたものと考えられる。



図 4.6: 円走行実験様子

表 4.2: 加速度データ収集結果

内容	ファイル数
全実験回数	28 件
取得 CSV ファイル数	28 件
データ欠損	1 件
特徴量算出に使用	27 件
実験領域の誤認識	2 件
機械学習に使用	25 件

本研究ではこの誤認識されたファイルは使用せずに、残りの 25 件のファイルで機械学習を行う。

## 4.4 学習

我々は機械学習の分類器として K 近傍法とサポートベクターマシンを使用した教師あり学習を行う。K 近傍法は WEKA を使用し、サポートベクターマシンは R を用いて e1071 内のサポートベクターマシンを使用した。サポートベクターマシンで使用するカーネルはガウシアンカーネルを使用しており、e1071 の初期設定である 1vs1 を用いている。

機械学習の認識率の算出には 8 分割交差検証法を用いる。また、データ欠損や誤認識ファイル等により生じたデータ数の偏りは調整されており、極端な不均衡データになら



ないようにしている。また、サポートベクターマシンのチューニングにはグリッドサーチを用いて cost 値と gamma 値の設定を行った。

本研究では 27 次元の特徴量を使用した自転車の挙動認識を行うが機械学習を行う際にデータの次元が多すぎると次元の呪いが発生しモデルが不安定になることに加えて、特徴量が多いと計算コストが高くなる恐れがある。そこで特徴量の次元を削減した場合においても考察を重ねる。

次元を削減する方法としては Yang ら [15] が発表した論文で用いられた 3 軸加速度データを重力成分と水平成分に合成する方法や主成分分析による方法があげられるが、本研究では自転車の進行方向の加速度や曲がった時の加速度を水平方向の加速度として合成して算出すると、データ自身が不明瞭なデータになると思われるため主成分分析を用いる。

本研究では 27 次元のデータを使用した認識率と、不偏相関行列を用いた主成分分析を行って次元削減をしたデータの認識率についての比較を K 近傍法とサポートベクターマシンを使用して行った。

## 4.5 主成分分析 (PCA)

我々は R を用いた相関行列による主成分分析を行った。まず、特徴量が算出される前の 3 軸加速度データについて相関係数行列を用いた主成分分析を行い、3 軸において必要のない軸を選ぶ事で次元の削減を試みたが今回の実験で得られた 3 軸加速度データから算出された寄与率、及び累積寄与率、それぞれの因子負荷量からは軸の削減が行えないことが分かった。次に、加速度データから算出された特徴量に相関行列を用いた主成分分析を行った。主成分とされるコンポーネントは累積寄与率、分散関係を表した図 4.7、そして R の `fa.parallel()` 関数を使用した結果より第 5 コンポーネントまでとし、この時の主成分における因子負荷量に相関係数検定の優位水準 10% を限界値とした値を基準にして、使用する次元の削減を行った結果、3 軸の一次導関数平均、X 軸、Z 軸の分散、標準偏差、平均、X 軸の平均交差率、Z 軸の 2 乗平均平方根の 11 次元を使用することとした。

## 4.6 挙動認識結果

これらの数値から機械学習を行い挙動の分類をした結果を示す。




図 4.7: 寄与率を表したスクリーンプロット図

表 4.3: 27 次元の特徴量を使用した K 近傍法による挙動分類結果 (k=11)

	加速運動	等速運動	時計回り円走行	反時計回り円走行
加速運動	60	12	1	1
等速運動	8	36	2	1
時計周り円走行	1	5	41	24
反時計周り円走行	4	1	17	58

#### 4.6.1 主成分分析前のデータを用いた K 近傍法の認識結果

まず 27 次元の特徴量を持つデータに対して K 近傍法を使用した挙動認識結果を示す。K を 1 から 20 まで変化させた時に最も良い認識率を示したのは  $K = 11$  の時で認識率は 71.69%であった。この時の分類結果を図 4.3 に示す。等速運動に関しては比較的分類に成功しているが、加速運動および円走行については分類に失敗しているサンプルが多く、特に円走行においては誤認識されているサンプル数が多いことが確認することが出来た。

表 4.4: 主成分分析後の特徴量を使用した K 近傍法による挙動分類結果 (k=11)

	加速運動	等速運動	時計回り円走行	反時計回り円走行
加速運動	64	7	3	0
等速運動	4	32	9	2
時計周り円走行	1	1	46	23
反時計周り円走行	0	3	27	50

表 4.5: 27 次元の特徴量を使用した SVM による挙動分類結果

	加速運動	等速運動	時計回り円走行	反時計周り円走行
加速運動	67	7	0	0
等速運動	6	41	0	0
時計周り円走行	1	0	44	26
反時計周り円走行	0	0	17	63

#### 4.6.2 主成分を用いた K 近傍法の認識結果

次に主成分分析を行い次元の削減を行ったデータに対して同じく K を 1 から 20 まで変化させ認識率の違いを比較する。K を変化させた時の結果は K が 11 と 12 の時に一番高い認識率を示しており、70.58 % の認識率を示した。この時の分類結果を図 4.4 に示す。主成分分析を行う前のデータと比較すると、認識率がわずかに落ちていることが確認できる。これはすべての K の値に対しても同様の傾向が表れたため、分類に使用したパラメータの数が減ったことで挙動モデルの定義があいまいになり、挙動間の分類精度が落ちたことが原因であると考えられる。

#### 4.6.3 主成分分析前のデータを用いた SVM の認識結果

主成分分析を行う前の 27 次元の特徴量をもつデータに対してサポートベクターマシンを使用した自転車の挙動認識結果を表す。認識率が一番高かったのはガウシアンカーネルを用いて gamma 値が 0.001 で cost 値が 100 の時に 72.42 % を示した。分類結果については図 4.5 に示す。K 近傍法と比べるとわずかだが高い値を示すことを確認できた。

表 4.6: 主成分分析後の特徴量を使用した SVM による挙動分類結果

	加速運動	等速運動	時計回り円走行	反時計回り円走行
加速運動	65	7	1	1
等速運動	6	41	0	0
時計周り円走行	1	0	40	30
反時計周り円走行	0	0	17	63

表 4.7: 挙動認識率の比較

分類器 (特徴量次元数)	認識率
K 近傍法 (27 次元)	71.69 % (k=11)
K 近傍法 (11 次元)	70.58 % (k=11)
SVM (27 次元)	72.42 % (c=100, g=0.001)
SVM (11 次元)	73.89 % (c=1000, g=0.001)

#### 4.6.4 主成分を用いた SVM の認識結果

次に主成分分析を行い、特徴量を 11 次元としたデータに対して同じくサポートベクターマシンを使用した挙動認識を行う。認識率が一番高かったのはガウシアンカーネルを用いて  $\gamma$  が 0.01 で cost が 1000 の時に 73.89 % を示した。分類結果は図 4.6 に示す。K 近傍法の時と比べると主成分分析を行い次元の削減を行うことで認識率を多少向上させることが出来た。

### 4.7 特徴量及び分類器の比較と考察

本研究で行った K 近傍法とサポートベクターマシンを用いた挙動認識ではサポートベクターマシンを使用した方が良い認識率を示すことが表 4.7 より確認することが出来た。特徴量についても 27 次元すべての特徴量を使用するのではなく、主成分分析を用いて次元削減を行ったデータの方が良い結果を得ることが出来た。我々はこれらの結果からスマートフォンを用いたリアルタイム挙動認識に使用する分類器はサポートベクターマシンとした。そして、分類に使用する特徴量は 3 軸の一次導関数平均、X 軸、Z 軸の分散、標準偏差、平均、X 軸の平均交差率、Z 軸の 2 乗平均平方根の 11 次元を使用することとした。

## 第5章 LEDを用いた後方への通知システムの導入

第5章ではこれまでの結果を基にLEDを用いた候補への通知システムの提案、開発、評価を行う。

### 5.1 課題と手法

前章までで機械学習を用いた自転車の挙動認識を行いパラメータ選択や分類器選択を行った。前章までの分類はパソコンを用いて行っており、この章では特徴量の算出や機械学習を用いた分類がスマートフォン内のアプリで可能かを、前章までの分類結果や方法を踏まえスマートフォンアプリ内で自転車の挙動認識を行うことが出来るようなシステムの開発を行う。

そして、現在自転車の存在を示すものは赤色LEDライトや反射板だけであり、動いた方向を自動的に周りに伝達するような手段はないと言ってもよい。そこで我々は3色LEDを用いた、色の変化により後方の車両等に自転車の進行方向を知らせるシステムの開発を行い、分類を行うアプリケーションとLEDの発光パターンを変化させるシステムを組み合わせることで自転車の動きを後方に伝達することを目的とした手法の提案、評価を行う。

### 5.2 Cyclesportsの提案

我々は分類を行う為のアプリケーションはAndroidスマートフォンアプリケーションとして開発を行う。分類のために使用する機械学習アルゴリズムは前章の結果よりサポートベクターマシンを使用するが、今回使用するのはRのe1071パッケージのものを使用せず、LIBSVMライブラリーを使用する。前章の自転車の挙動認識では4種類の挙動に

対して分類を行ってきたが、今回のアプリケーションにおいては2つの理由により、2つの行動に分類を制約する。

1つ目の理由は3色LEDの発光色はRGBを細かく設定することで多彩な色を表現出来るが、夜間や日中におけるLEDの発色の違いを認識するには、明らかな色の変化がある方が好ましいということが分かったため、2種類の分類結果を表示することが適当だと考えたからである。

2つ目の理由としては、認識精度を上げることにある。前章で行った実験では大きく分けると等速運動、加速運動を行った直線運動系の実験と円走行(時計回り、反時計回り)の円形運動系の挙動に区別することが出来る。前章の挙動分類において、それぞれの挙動に分類されたサンプル数を比較すると、同じ運動系内において誤認識されたサンプルが多いことが確認できた。このため本研究で開発するアプリで使用する分類のモデルデータは、加速運動と等速運動をランダムに含めた直線運動系クラスと時計回りの円走行クラスの2クラスについて分類を行う。

円走行系において時計回りの走行を選択した理由は、2013年12月1日に施行された改正道路交通方第17条の2に示されている路側帯の通行方法において、自転車は車両と同じく左側通行に限定される。本研究では自転車運転中におけるバイク、車との接触回避を目標に掲げていることから反時計回りの運動は歩道側に向かう運動となり、反時計方向に自転車が飛び出した際に、後方へ自転車の飛び出しを知らせることはあまり意味をなさないと考えたためである。これらの理由により分類数を2クラスとしてアプリケーションの開発を行う。

### 5.3 Cyclesportsの挙動認識機能について

Cyclesportsはアプリケーション内でリアルタイムに挙動認識を行うためにサポートベクターマシンのライブラリーを実装している。実装されたライブラリーは台湾国立大学のChangらが公開しているLIBSVMを使用し、分類に使用するモデルデータは前章において挙動認識の際に収集された加速度データを使用する。

また、分類数や使用するパッケージの変更を行ったため、cost値やgamma値についても再度グリッドサーチを行い最適値の算出を行う。モデルデータはアプリケーション内に含めるのではなく、microSDから呼び出すようにしており、教師モデルの変更等があっ

た場合でもアプリケーションを再度コンパイルする必要はなく、microSD 内のデータを変更するだけで対応することが出来る。挙動認識中のアプリケーションの画面は図 5.1 に示すように、収集した 3 軸加速度データの内の X 軸データの波形を表示し、一部の特徴量と挙動の認識結果についても表示を行っている。

目安として今回使用する LIBSVM の認識率を前章で収集した 4 人の被験者の加速度データの内 3 人分を教師データ、1 人分をテストデータとし認識率の確認を行ったところ 74.71 % の認識率を確認した。実際の走行実験では全員分のデータを教師モデルとして使用するので、単純には比較はできないがおおよそ近い値が出るのではないかと思われる。今回走行実験で使用するサポートベクターマシンのカーネルはガウシアンカーネル、gamma 値は 0.5、cost 値は 32 である。

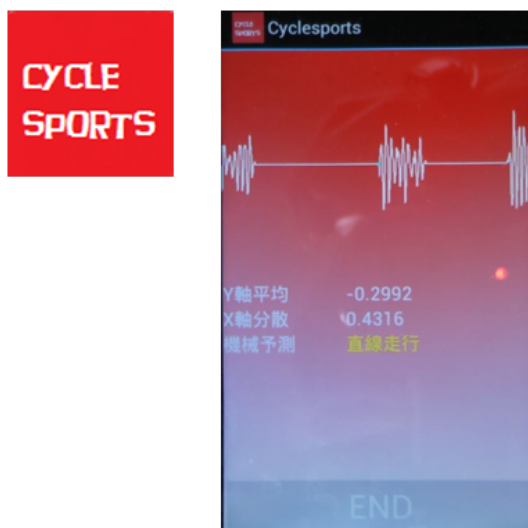


図 5.1: Cyclesports のメイン画面

## 5.4 自転車後方への認識結果通知方法について

認識結果を後方へ通知を行う為に図 5.2 にしめす機器の製作を行った。後方への通知方法として、スマートフォンの USBhostAPI を用いた FTDriver ライブラリーをアプリケーション内に内蔵し、3 色 LED の制御には Arduino Duemilanove を使用して行い、Arduino の電源供給は Android 端末から直接行う。

まず、走行前にスマートフォンと Arduino を接続するとアプリケーションが立ち上がり、画面を進めていくと前項で説明した分類結果を示す画面が表示される。ここに CONECT が表示されていれば接続が成功しており、何も表示されていない場合は接続失敗となるのでアプリを終了し、やり直す。

CONNECT が表示されるとアプリケーションが Arduino の認識に成功しており、認識結果により LED の発光色が変化する。挙動認識が始まると、アプリケーション内で機械学習により分類した自転車の挙動認識による認識結果毎のシリアルを FTDriver 経由で Arduino 側に送信する。

Arduino 側はシリアルを受信したら、受信したシリアルの種類により 3 色 LED の発光パターンを制御する。発光パターンは全部で 2 種類あり図 5.3 にあるように、等速運動及び加速運動中は青色の LED が点灯し、時計回りの円走行、つまり車道に侵入する際の挙動を行った場合は緑色に LED が発光する。




図 5.2: Arduino を用いた後方通知機器

## 5.5 認識率の予備実験

Cyclesports を用いた認識率の予備実験を行う。この実験ではパソコン上で行った挙動分類の結果と実際にスマートフォンを自転車に設置してリアルタイムに行った挙動認識の結果にどの程度のズレがあるかを確認する。パソコン上で行った分類では、挙動分類を取得された加速度データを静的なデータとして交差検証法を用いて認識率の算出を行っ





図 5.3: LED の点灯色の種類

ていたが、今回の実験では普段自転車を使用することをより意識した動的な挙動分類の認識率の算出を行う。

被験者は1名とし教師データにデータが含まれていない者とした。走行中の速度については特に指定せず、普段通りに走行するように指示をした。走行実験を行う路面は平坦道であるが、一部落ち葉や枝などがある。

LEDの制御を行う Arduino は図 5.4 に示すように自転車の後方反射板の位置に設置し、スマートフォンホルダも加速度データ収集実験の際に設置した場所に装着する。

被験者はスマートフォンと Arduino を接続後、CONNECT を確認したら走行をスタートする。走行実験では図 5.5 に示すような直線と曲がり角を含むコースを何周か走行し図中のカメラマークの位置にビデオカメラを設置する。ビデオカメラで実験時の様子を撮影し、実験終了後に LED の点灯状況と自転車の挙動状況を目視により確認をし、認識率の算出を行う。直線運動における認識は直進運動中の総時間に対して青色 LED が何秒間点灯していたかをカウントすることで計測し、曲がる運動の認識率の測定にはコーナーを曲がった回数に対して緑色 LED が何回点灯したかを確認して認識率の算出をおこなう。

### 5.5.1 実験結果と考察

予備実験を行った結果を表 5.1 にしめす。自転車の走行時間は全部で 6 分 20 秒間であり、直線部分の走行時間は全部で 4 分 4 秒間、自転車がコーナーを曲がった回数は 52 回



図 5.4: Arduino の設置位置




図 5.5: 予備実験における走行コース

であった。図 5.6 に直線走行、図 5.7 コーナーを曲がる走行それぞれの正常に認識された場合と誤認識された場合の様子を示す。Cyclesports の直線走行時における青色 LED の点灯時間は約 223.5s であり認識率は 91.60 %を示しており、曲がる際の緑色 LED の点灯回数は曲がった総数に対して 36 回となり認識率は 69.23 %であった。これらの認識率の結果から直線走行における認識率が非常に高いことを示しているが、右に曲がる動作については 69.23 %という結果になり、右に曲がる動作の認識率が悪いことが分かった。これは今回使用したモデルデータは直線系のデータと時計まわりの円走行のデータ数を比較しても極端な不均衡データとはなっていないが、直線系データには加速度運動と等速運動のデータが含まれているため、自転車の直線方向の挙動に対してはある程度対応できたと考察できる。対して、円走行のデータは曲率半径 5m とした時のデータとなってお

表 5.1: 予備実験における認識率

運動種類	総数	認識数	認識率
曲線運動	52 回	36 回	69.23 %
直線運動	244s	223.5s	91.60 %

り、限られたデータとなっていることから曲がる動作に対しても限られた範囲でしか対応出来なかったためであると考察できる。しかし、路面の状況が悪すぎる場所では認識率が非常に落ちていることから、今後も様々な状況でデータを収集する事が望ましいと考える。よってパソコン上で行った静的な挙動認識と比べてもあまり大差のない認識結果になることを確認した。



図 5.6: 直線走行時

## 5.6 Cyclesports の評価実験

LED の発光色が変わらない場合と Cyclesports を使用して LED の発光色が変わる場合の二つの状態について比較を行う。現在、反射板や固定色 LED を用いたテールライト



図 5.7: コーナを曲がる走行時

を装着した自転車が一般的である。この方法を用いて夜間走行した場合、自転車の位置はテールライトにより確認することができるが、自転車の挙動は光の軌跡でしか確認することが出来ない。そこで我々の提案する Cyclesports を自転車に装着して、自転車の視認性が著しく落ちる夜間において走行をした際にどの程度効果があるのかを評価する。

### 5.6.1 評価実験の方法

比較方法としては二つの方法を実装した自転車をビデオカメラで後方から撮影し、その動画を基に評価実験を行う。評価実験で使用する動画は全部で4つあり、固定色 LED をテールライトとして使用した場合、Cyclesports を使用した場合、これら2つの動画を0.5倍速にスロー再生した場合のものである。

また、自転車が曲がったと認識したタイミングについて比較を行うために、図 5.8 に示

すような動画再生機能と被験者が曲がったと認識した際に通知するボタン、そして通知したタイミングをファイルに出力できる専用ツールを実装した。被験者は Cyclesports がどのように動作をするのか確認をするために評価実験で用いる動画と異なる練習用動画を視聴して評価実験へ移る。

まず、被験者は1つのシステムについて1倍速の動画と0.5倍速の動画を2回ずつ視聴し、曲がったことを認識した際に通知するボタンをクリックする。そして1つのシステムの動画視聴後にアンケート項目について回答を行う。その後残りのシステムについても同じ工程を繰り返す。本研究ではこれらのアンケート結果と認識したタイミングを踏まえ Cyclesports が効果的かどうかの評価を行う。

この評価実験に参加した被験者は20代の男性14名であり、システムの評価実験の順番は順序効果の影響を無くすために、7名がLEDの発光色が変化しない場合を評価した後に Cyclesports の評価を行い、残りの7名が Cyclesports の評価をした後にLEDの発光色が変化しない場合について評価した。



図 5.8: 評価実験のためのツール

表 5.2: 評価実験用アンケート

設問	質問	種類
1	自転車が右に飛び出した時の確認はしやすかったか？	選択式
2	どのようなことから右に飛び出したと判断しましたか？	記述式
3	LED が自転車挙動を判断するのに妨げになりましたか？	選択式
4	LED の明るさはどうであったか？	選択式
5	LED を使用した注意喚起は必要と思うか？	選択式、記述式

### 5.6.2 アンケート内容

以下の表 5.2 にアンケート項目を示す。設問 1 はシステムを使用した挙動認識に関する質問、設問 3 はシステムが妨げになっていないかの確認をする質問、設問 4 は LED の視認性に関する質問、質問 5 はシステムの必要性に関する質問であり 1 点～5 点の 5 段階評価をおこなってもらい、設問 2 は設問 1 の判断理由、設問 5 は選択に関する理由について記述回答を行ってもらい。

### 5.6.3 結果と考察

表 5.3 にアンケートを Cyclesports の場合と LED の発光色が変わらない場合について行った結果、図 5.9 に各設問におけるシステム間のアンケート点数の比較を示し、表 5.4 に各設問に対する検定結果をしめす。自転車の挙動認識の視認性を表す設問 1 にウィルコクソンの順位和検定を用いると  $p=0.006 (< 0.05)$  となり、仮説が棄却されるためシステムの中央値には差があり、中央値より Cyclesports の方が自転車の挙動を確認しやすいという結果になった。

Cyclesports の設問 1 について高い点を付けた被験者の判断理由を抜粋すると、「LED の変化で判断した。自転車の動きと LED の変化が判断の補助になった。」という意見があった。

低い点をつけた被験者の回答を抜粋すると、「LED の発光色を固定にした場合、自転車が傾き、曲がりだすと LED の光線上からカメラが外れるために光が徐々に弱まり、この LED の発光状態の方が曲がっていることを連想させた」という意見があった。

設問 3 のシステムの LED が自転車挙動を判断するのに妨げになるかという項目において 1 点に近いほど妨げにならず、5 点に近いほど妨げになるという選択肢の中で Cyclesports

の中央値は1、LEDの発光色を固定にした場合の中央値は1となり、ウィルコクソンの順位和検定を行った場合も  $p=0.99(> 0.05)$  となり差がない事が分かった。よってどちらの場合においてもLEDが挙動の判断の妨げにはあまりならないという結果が得られた。

設問4のLEDの明るさに関する質問も両システムとも中央値は3となっており、ウィルコクソンの順位和検定においても  $p = 0.91(> 0.05)$  となることから、この問いにおいてシステム間の平均の差はないと言うことが確認でき、中央値は3点と言うことで明るくもなく、暗くもないという結果になった。

最後に設問5の各システムのLEDを使用した注意喚起の必要性に関する問いでは、発光色固定の場合の中央値は4、Cyclesportsの場合の中央値は4となり、ウィルコクソンの順位和検定を行った場合も  $p=0.57(> 0.05)$  と言う結果より中央値に差は無く、少し必要と思うという結果になった。また、認識するまでにかかった秒数についてt検定を行い差があるのか比較を行うが、1回目のデータに関してはツールの操作に関する不慣れがあると思われるので各システム2回目のデータを使用して検定を行う。

結果を表5.5、検定結果を表5.6にしめす。判定に使用する計測データはスタートボタンを押してからの秒数となっているが、LEDの発光色を固定した場合とCyclesportsで使用した動画では自転車が曲がった際の再生時間が僅かに異なるため、動画編集ソフトを使用して誤差0.2秒分を計測し、Cyclesportsの計測データにこの差分を加算してシステム間での時間誤差を限りなく少なくした。算出された計測時間の平均値はCyclesportsが6.84秒、LEDを固定した場合の平均値は6.97秒となり、t検定を行った結果は  $p = 0.01(< 0.05)$  となり、差がある事を確認できた。CyclesportsとLEDを固定した場合の平均値の差は0.128秒となり、Cyclesportsの方が認識までの時間が0.128秒短かったことが確認できた。

これは、LEDの色が変化することで自転車の挙動の変化を明白に伝えることが出来たためだと考えられる。これが実際の道路だと自転車が時速15km、自動車が時速50kmとし、相対速度が時速35kmとすると、現行の反射板より1.2m手前で自動車の運転手が気付くことが出来る想定となる。

表 5.3: アンケート結果

アンケート結果 (選択式のみ) : 被験者数 14 名	Cyclesports 平均	分散	固定色 LED 平均	分散
自転車が右に飛び出した時の確認はしやすかったか?	4.21	0.95	3.00	1.23
LED が自転車挙動を判断するのに妨げになりましたか?	1.78	1.25	1.71	0.83
LED の明るさはどうであったか?	3.14	0.74	3.21	0.48
LED を使用した注意喚起は必要と思うか?	4.00	1.38	3.78	1.41

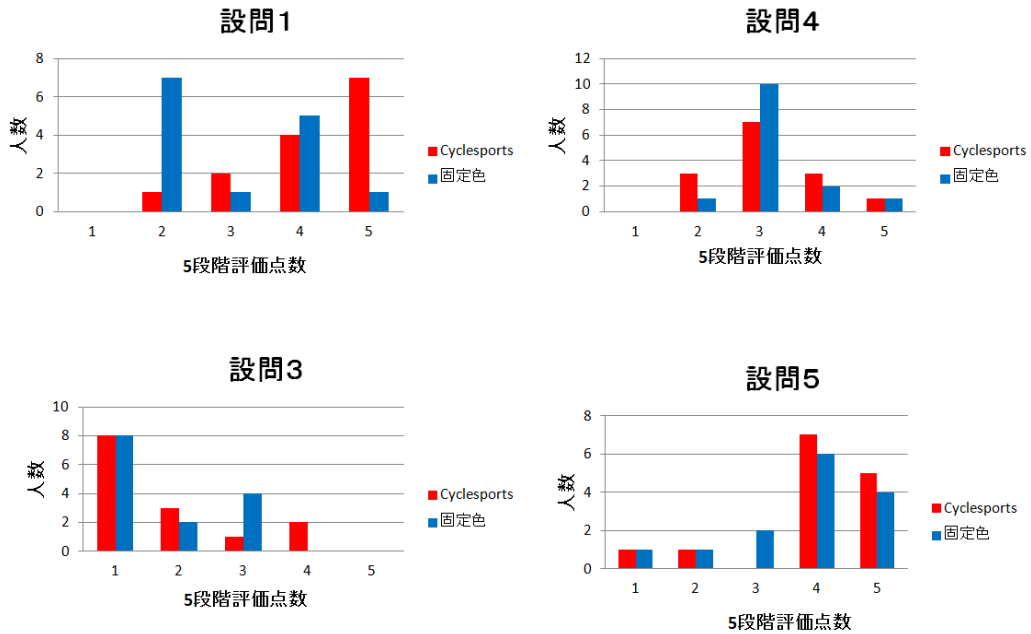


図 5.9: 各設問におけるアンケートの点数

表 5.4: アンケート結果における検定結果

設問	ウィルコクソンの順位和検定	Cyclesports 中央値	固定色中央値	中央値の差
1	p= .006	4.5	2.5	有
3	p= .994	1.0	1.0	無
4	p= .916	3.0	3.0	無
5	p= .579	4.0	4.0	無

表 5.5: 動画開始から被験者の認識時間までの時間

システム名	認識までの時間平均	分散	提案システムとの差
Cyclesports	6.84	0.03	-
固定色 LED	6.97	0.03	+0.12 秒



表 5.6: 計測時間における検定結果

	固定色LED	Cyclesports
平均	6.971	6.842
分散	0.034	0.036
観測数	14	14
ピアソン相関	0.622	
仮説平均との差異	0	
自由度	13	
t	2.937	
p (T ≤ t) 片側	0.005	
t 境界値 片側	1.770	
p (T ≤ t) 両側	0.011	
t 境界値 両側	2.160	

## 第6章 まとめ

本研究では自転車の挙動を後方に伝えるための方法として、現在行われている加速度センサを使用した人間の行動認識を参考にし、加速度センサデータを使用した機械学習から自転車の挙動を明らかにし、後方に伝えるという手段を選んだ。加速度センサは普及の面、手軽さの面を考えスマートフォンに搭載されているモノを使用した。

自転車の挙動には人間の干渉が他の輸送用機器よりも多く、急な動作が多いためフィルターを使用したノイズ除去は行わなかった。しかし出来る限りペダリングや路面の凹凸によるノイズの影響を少なくするため、スマートフォンの設置位置の検討を行った。前輪上方、後輪上方、後輪軸横にセンサを設置し実験を行ったところ、運転者の体重や路面からの距離が短く角速度が比較的遅い後輪軸横にセンサを設置することでノイズの影響を限りなく少なくすることが出来た。この位置にスマートフォンを設置し加速度データの収集を行った。

加速度データをより容易に収集するために、加速度データ収集用スマートフォンアプリとデータ処理をサーバーで行えるように実装をした。自転車の挙動分類を行う為に地面の凹凸が出来る限り少ないところで自転車の挙動に代表される等速運動、加速運動、時計回り円走行、反時計回り円走行の4種類の実験を行った。何も処理が行われていない収集された加速度データにはスマートフォンを操作する時の加速度データや自転車の乗り降りの際の加速度データが含まれており、機械学習の結果に影響を与え、一般的には実験時にカメラで実験の様子を撮影し、計測後にカメラの時間とデータの時間を比較し不必要なデータを削るが、我々はステップを置き実験時はその上を通過することでステップを超えた際の加速度データを基に実験領域を抽出した。そして、本研究では特徴量を算出するために、抽出されたデータに時間窓を設置した。時間窓のサイズは自転車の動きが埋もれてしまわぬように32サンプルとし、前の時間窓に対して50%オーバーラップさせ27次元の特徴量を算出した。

算出された特徴量をもとに機械学習を行うが、次元の呪いへの対処や計算量を落とす

ために主成分分析を行った。まず、特徴量が算出される前の3軸加速度データに対して主成分分析を行ったが、寄与率、因子負荷量等から主成分を選定することが出来なかった。次に特徴量について主成分分析をおこなった結果、11次元の特徴量を主成分とした。算出された特徴量を使用して機械学習の分類器を認識率の面から選定することとした。

比較する分類器はK近傍法とサポートベクターマシンを使用し、それぞれに27次元の特徴量を使用した場合、主成分分析で選定された11次元の特徴量を使用した場合について比較を行った。結果は11次元の特徴量を使用し、分類器はサポートベクターマシンを使用した場合において一番認識率が高かった。

これらの結果をもとに自転車の挙動認識を行うスマートフォンアプリCyclesportsの開発を行った。分類する種類は4種類であったが認識率の向上をめざすために等速運動、加速運動をランダムに混合した直線運動系と時計回り円走行の2クラスに分類した。アプリで分類された挙動結果を後方へ伝えるために3色LEDを用いた方法を提案した。この機器とスマートフォンをUSBhostAPI経由で接続し、アプリ内で認識された結果をシリアルとして、この機器に送信することで3色LEDを変化させることができ挙動認識の結果を後方に伝えることが出来た。これらのシステムの認識率を調べるために予備実験を行った。

等速運動と加速度運動が含まれている直線運動系のクラスの認識率は高かったが、収集した加速度データが単一の曲率であった円走行における認識率は直線運動系よりも低かった。しかし、平均するとパソコンで算出した認識率に近い値を算出することが出来た。Cyclesportsと一般的なシステムとしてLEDの発光色が固定された場合との比較を行うことでCyclesportsの評価実験を行った。結果はCyclesportsとLEDの発光色が固定された場合を比較すると挙動の確認のし易さ、挙動を認識するまでの反射スピードにおいて有用性が確認でき、LEDを使用した注意喚起についても必要であるという結果を得ることが出来た。

## 謝辞

修士論文を完成するにあたり、ご指導ご教授くださりました三浦准教授に御礼申し上げます。また、輪講や中間発表においてご指導やご教授を下さりました情報セクションの先生方に御礼申し上げます。加えて、本論文のデータ収集実験や評価実験において、被験者としてご参加頂きました三浦研究室の学生と情報セクションの学生にお礼を述べたいと思います。最後に、私の意思を尊重して下さり大学院進学を応援して頂き、経済面や生活面において、ご支援をして頂いた家族に心から感謝申し上げます。

## 参考文献

- [1] 国土交通省道路局. 自転車利用環境をとりまく話題. [http://www.mlit.go.jp/road/ir/ir-council/bicycle\\_environ/1pdf/3.pdf](http://www.mlit.go.jp/road/ir/ir-council/bicycle_environ/1pdf/3.pdf), 2006.
- [2] 佐々木裕昭, 寺田努, 坂本品彦. 自動車メタファを用いた歩行者行動の可視化システムの設計と実装. 情報処理学会研究報告 IPSJ SIG Technical Report vol2011-EC-20 No.8, May 2011.
- [3] Wouter walmink, Florian 'Floyd' mueller, and Alan chatham. Lumahelm - an interactive helmet. In *CHI 2013 Extended Abstracts*, April 2013.
- [4] 神村吏, 木谷友哉, 渡辺尚. スマートフォン搭載センサを使用した二輪車車両挙動把握システムの提案. マルチメディア, 分散, 協調とモバイル (DICOMO2012) シンポジウム, July 2012.
- [5] 多田昌裕, 大村廉, 納谷太, 野間春夫, 鳥山朋二, 小暮潔. 加速度センサーを用いた自動車運転時のバンドル操作分析. 情報処理学会 研究報告 IPSJ SIG Technical Report 2006-CVIM-155, September 2006.
- [6] 小川延宏, 梶克彦, 河口信夫. Hasc2010corpus を用いた被験者数と人間行動認識率の相関分析. 一般社団法人情報処理学会マルチメディア, 分散, 協調とモバイル (DICOMO) シンポジウム論文集, pp. 76–82, July 2011.
- [7] Vittore Cossalter, Andrea Aguggiaro, Dirk Debus, Alessandro Bellati, and Andrea Ambrogio. Real cases motorcycle and rider race data investigation: Fall behavior analysis. In *Proc. of 20th International Technical Conference on the Enhanced Safety of Vehicles*, June 2007.

- [8] Nowy Condro, Meng-Han Li, and Ray-I Chang. Motosafe: Active safe system for digital forensics of motorcycle rider with android. In *International Journal of Information and Electronics Engineering*, Vol.2, No.4, July 2012.
- [9] Ling Bao and Stephen S.Intille. Activity recognition from user-annotated acceleration data. In *PERVASIVE 2004 LNCS 3001*, pp. 1–17, 2004.
- [10] Mi Zhang and Alexander A.Sawchuk. Motion primitive-based human activity recognition using a bag-of-features approach. In *IHI'12*, January 2012.
- [11] Hidenobu Goto and Motoki Miura. Examination of sensor positions to detect bicycle speeding behavior. In *KES-IIMSS*, pp. 204–211, June 2013.
- [12] 木村周. モバイル端末上における行動認識のための分類モデル生成手法と提案と評価. 平成 23 年度 奈良先端科学技術大学院大学修士論文, February 2012.
- [13] 照本旭生. 3 軸加速度センサを用いた「ラジオ体操」の認識と体の伸び判定. 平成 24 年度九州工業大学大学院修士論文, February 2013.
- [14] 国土交通省. 自転車道の設計基準について. <http://www.mlit.go.jp/road/sign/kijyun/pdf/19741129jitennsyadou.pdf>, November.
- [15] Jun Yang. Toward physical activity diary: Motion recognition using simple acceleration features with mobile phones. IMCE '09, October 2009.