

# SVMを用いた二輪車の運転挙動分類の基礎検討

神村 吏<sup>1</sup> 木谷 友哉<sup>1</sup>

**概要:** ITS (Intelligent Transportation System) において, 二輪車向けの安全運転支援システムは, 二輪車特有の車体運動の複雑さから開発されていないのが現状である. そのため我々は, 二輪車の ITS サービスの創出のために, 二輪車の車体挙動に関するデータを収集し二輪車運動を解明するためのコーパスを作成している. このコーパスでは, 後に機械学習で挙動を解析するために, データに挙動の種類などをラベル付けする必要がある. 大規模なコーパスを作成することを目標にするため, 取得したデータに自動的に正解のラベルが付けられることが望まれる. モーションデータへの自動ラベル付けは, 対象が人間の行動の場合は複雑で困難だが, 二輪車は道に沿って走行する, 可動部が少ないなどの制約が多いためラベル付けが自動化できると考える. GPS による位置情報を使用し, 移動の曲率があるしきい値より大きかった地点を抜き出すことで, 右左旋回の正解ラベルをつけることが可能となる. また, この位置情報によって作成されたラベル付きデータを使用し, SVM (Support Vector Machine) を用いることでより詳細なラベル付けを行う. 本稿では, コーパスを作成するために, 機械学習と GPS による位置情報を用いて正解ラベルを取り付けるための分類方法を提案する. 二輪車にセンシングデバイスを取り付け収集したデータを, SVM の解析によって分類する実験を行った. SVM での解析では特徴量の次元数の削減が問題となったが, 200 次元の特徴量を 6 次元に削減し良好な結果を得た. 6 次元の特徴量で学習させた SVM で, 90%を超える正確度で分類ができることを示し, 詳細な動作のラベル付けが可能であることを示した.

## A basic study of Motorcycle riding behavior classification with SVM

KAMIMURA TSUKASA<sup>1</sup> KITANI TOMOYA<sup>1</sup>

### 1. はじめに

情報技術を使用し, 道路交通に関わる事象を効率化する高度交通システム (ITS) の研究が現在広く行われている. ITS では車両の安全運転を支援するシステムも広く研究されているが, この研究の多くが四輪車を対象としている [1]. 四輪車と二輪車では, 車体構造や運転操作に大きな違いがあるため, 四輪車を対象とした安全運転支援システムは, そのまま二輪車に使用することは難しい. 二輪車の事故は, 四輪車の事故に比べて運転者への危険が大きい. 総務省の平成 24 年度の統計によれば二輪車の事故時の致死率は四輪車の 3 倍, 重傷率は 5 倍以上である [2]. しかしながら, 二輪車のための安全運転支援システムは, 二輪車の車体運動の複雑さやコストの面から開発されていないのが現状である. そこで, 我々の研究グループでは二輪車

の独自の挙動を解析し, 二輪車を安全・快適にするシステムを創出する基盤を開発することを目標とし研究を行っている. この研究を我々は Bikeinformatics[3] と呼称している.

Bikeinformatics では, 二輪車に測位装置とモーションセンサを搭載し, そのセンサから得られたモーションセンシングデータを多数収集し, 二輪車の車両運動のデータベース (二輪車運動コーパス) を作成する. さらに, このコーパスを用いて, 様々なものの挙動を解析する場合によく使用される機械学習を利用して二輪車の車体挙動を解析する.

二輪車の運動コーパスを作成するためには, コーパスに登録する二輪車のモーションセンシングデータが, どのような運転手, 車両, 場所, 運転操作をした時のデータであるかをラベル付けする必要がある. このラベル付けは, 手作業で付加することも可能であるが, 膨大なデータによる大規模なコーパス作成を目標にしている我々の研究では, 自動でのラベル付けを実現することが不可欠である. 二輪

<sup>1</sup> 静岡大学 大学院 情報学研究所  
Graduate School of Informatics, Shizuoka University

車は動作は、基本的に道路上を走行することや、動作の幅が狭いために、位置情報を用いて二輪車の走行軌跡の曲率を計算することで、旋回動作の正解ラベルを自動で付与できる可能性があることを我々は先行研究として文献 [4] で示した。この位置情報によるラベル付けと SVM を用いることで二輪車のモーションセンサへのより詳細なラベル付けを行う。

本稿では、位置情報から旋回動作の正解ラベルを付与した教師データを使用し、学習機械である SVM を用いて、更に細かな正解ラベル付け手法の検討を行いその詳細を述べる。

## 2. 関連研究

### 2.1 安全のための高度交通システム (ITS)

ITS とは、情報技術を使用し道路交通に関わるあらゆる物を効率化するシステムの総称である。渋滞の解消や、道路の保守コストの削減、目的地までの効率的なルート構築など様々なものが研究開発されている。無線通信を用いて通行料金を徴収する ETC (Electronic Toll Collection System) やリアルタイムの渋滞情報を考慮したカーナビゲーションシステムが実用化され、世の中に浸透している。

実用化された安全のための ITS サービスの中で、車両の挙動を使用したサービスには、HONDA の開発した、ふらつき運転検知機能がある [5]。これは、自動車のナビゲーションシステム内に設置された、振動ジャイロセンサと車速センサの値を使用し、車体がふらついていることを検知し、運転者へ注意喚起を促すシステムである。このような既存 ITS サービスは、四輪車を対象にして想定しているものが多い。情報提示型の ITS サービスの中には、二輪車にも使用できるものもあるが、基本的には二輪車を考慮していない。

四輪車と二輪車には違いが多く存在している。二輪車は事故時、四輪車に比べて運転手に重大な影響を与える可能性が高い。これは、事故時に四輪車運転手は車両のボディによって守られることが多いが、二輪車の場合、運転手は直接危険にさらされるためである。二輪車に焦点を当てた ITS が普及することが望まれるが、二輪車用 ITS サービスが少ない事が現状である。

四輪車と二輪車の違いの中でも、我々の研究に最も関係するものが車体挙動と操作の違いである。二輪車は、自立不可能であるために、運転手が体全体を使ってバランスを取る必要があり、旋回時などには車体を傾けて操作するという四輪車にはない操作が発生し挙動が変化する。我々は先行研究で、二輪車と四輪車の加速度による取得値の違いから挙動の違いを示している [6]。

我々の研究グループは、二輪車向け ITS サービスを実現普及させるために、この二輪車と四輪車の違いを考慮し二輪車の挙動を解析することを目的としている。

### 2.2 人間行動推定

近年、人間の体にセンサを取り付け、そのセンサから得られるセンシングデータから人間の行動を推定する研究が盛んである。人間の体にセンサを取り付けるだけで、そのセンサを取り付けた人間の行動を把握することが可能となり、ライフログや健康管理、センサ情報からの個人の特定等の新たなアプリケーションの創出が可能である。人間行動推定の研究では、人間の行動を推定するためのセンサとしてモーションセンサが広く使用されている。モーションセンサとは、状態をセンシングするのに適したセンサである。センサの受ける加速度、回転の角速度、地磁気の方法をセンシングするものが一般的である。

3 軸の加速度センサを用いて、歩行データをセンシングしたモーションセンシングデータから、個人の推定をする研究が文献 [7] で発表されている。また、HASC (Human Activity Sensing Consortium) [8] と呼ばれるコンソーシアムでは、モーションセンシングデータを大量に収集し人間の行動コーパスを共同で作成している。人間行動研究を行う研究グループが個別でデータを収集していると、母数の大きなサンプルによる実験や検証が難しい。そこで、大規模なデータを研究グループの垣根を超えて収集しコーパスを作成し公開することで、行動推定の研究の発展に寄与できる。

本稿では、二輪車の挙動を解析するためにモーションセンサによって車体の運動データを取得し、それらのデータを機械学習等を用いて解析するためのラベル付けの自動化について述べる。

### 2.3 Bikeinformatics [3]

我々の研究グループは、運転者、車種、道路など様々な環境における二輪車の車両運動をセンシングして二輪車の挙動データを収集し、二輪車運動コーパスを作成し、そのコーパス情報を使用して二輪車の挙動の解析や路面状態のセンシングを行うことを目標としている。

二輪車の挙動は、その車体構造の違いから、四輪車の挙動とは大きく異なる。また、二輪車の車体は前後左右に傾いたり 3 次元的に動くことや、運転者の重心移動が車両の運動に大きく影響を与えることなどから、二輪車の車体運動の力学的モデルについては完全な解明がなされておらず、そのためには検証用の膨大なデータが必要とされている。そこで、我々が収集した二輪車コーパスを利用して、その運動モデルの解明に寄与することを考えている。また、このコーパスは、それ以外の二輪車向け ITS にも利活用されることが期待される。この研究全体を我々は Bikeinformatics と呼称する。Bikeinformatics の全体像を図 1 に示す。

Bikeinformatics において二輪車の運動コーパスを作成するときには、人間の行動推定のように、センシングされた

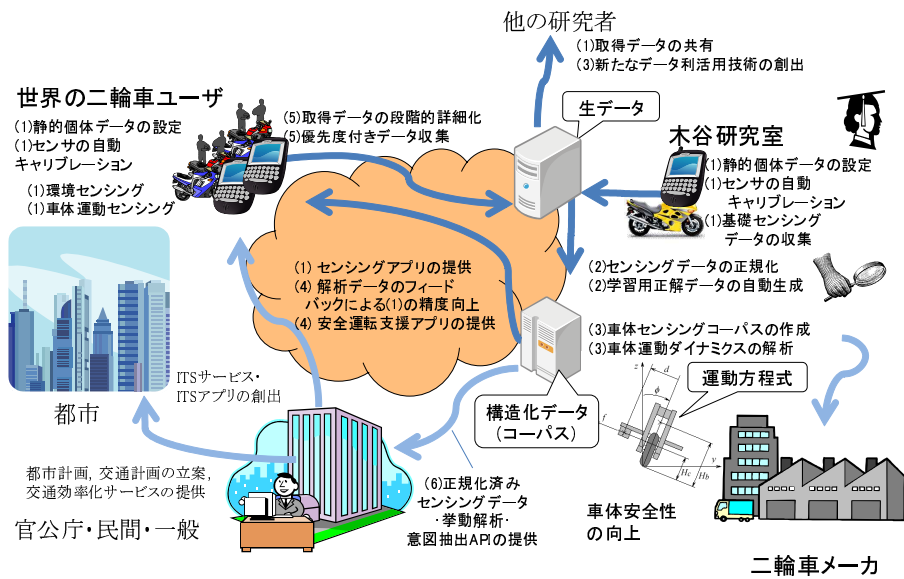


図 1 Bikeinformatics 全体像

モーションデータがどのような状況で取得されたのかのラベルを付加する必要がある。本稿では、図 1 中 (2) センシングデータの正規化、学習用正解データの自動生成の部分を中心に、センシングデータの自動構造化を行う。

### 3. SVM を用いた二輪車の挙動分類

本稿では、自動でコーパスを作るために、GPS による位置情報とモーションセンシングデータの解析によって、「直進」、「停止」、「左カーブ」、「右カーブ」、「停止+左折」、「停止+右折」、「左折」、「右折」を分類する方法を開発する。これらが分類・ラベル付け可能になれば、ラベル付けされたモーションデータを教師データとして機械学習し、より細かな挙動の推定が可能になる。細かな挙動の推定が可能になれば、危険な運転挙動や運転者の推定ができる可能性がある。

GPS から得られる位置情報により、連続する 3 点の曲率を計算することで二輪車の直進、停止動作と旋回動作は分類可能である。さらに、2 点の位置情報と時刻情報を使用することで速度が計算可能であり、停止を含むかの判断が可能である。しかしながら、カーブで曲がっているのか、交差点で右左折を行っているかの分類は全ての交差点の位置情報が存在しなければ、判断ができない。OpenStreetMap[9] のような地図のオープンリンクドデータを参照すれば、交差点の情報は取得できる可能性があるが、世界中の任意の場所について利用できるわけではない。

本稿では初期コーパス作成のために、モデルコースを設定しそのコースに含まれる交差点情報をあらかじめ手作業で作成し、それを正解データとして与えた。その後、モデルコース以外の地点を走行した場合を想定し、分類器を用いることでカーブなのか交差点なのかを区別し分類する。

この分類方法をフローチャートにしたものが図 2 である。以下で、実際に如何にしてデータを収集し解析のためのラベル付けを行うかを述べる。

### 3.1 データの自動構造化

収集された二輪車のモーションセンシングデータをコーパス化するためには、運転手、車両、場所、操作のデータをラベル付けする必要がある。このラベルをもとに二輪車の挙動の詳細を機械学習で解析するのである。機械学習は、人間の行動をモーションデータから推定する研究でも一般的に使用されており、認識精度も高い。運転手や車両の情報は、モーションデータ収集時に変化しないためラベル付けは容易であるが、場所や操作のラベルはデータを解析することで付加する必要がある。したがって、図 3 に示したようにデータを構造化する。コーパス作成の際に必要なデー

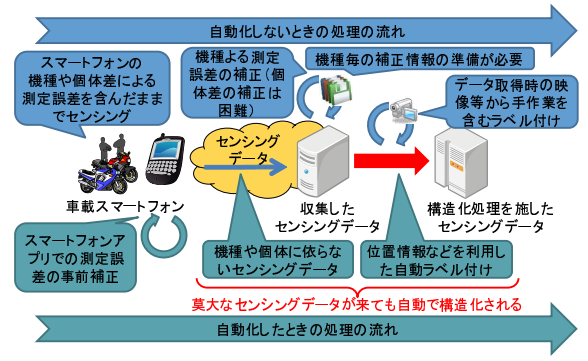


図 3 センシングデータの自動構造化

タの正規化や正解ラベル付などを手作業で行う場合、データが膨大になってしまうと作業が追いつかなくなってしまう。センシングデータの自動構造化では、図 3 に示したよ

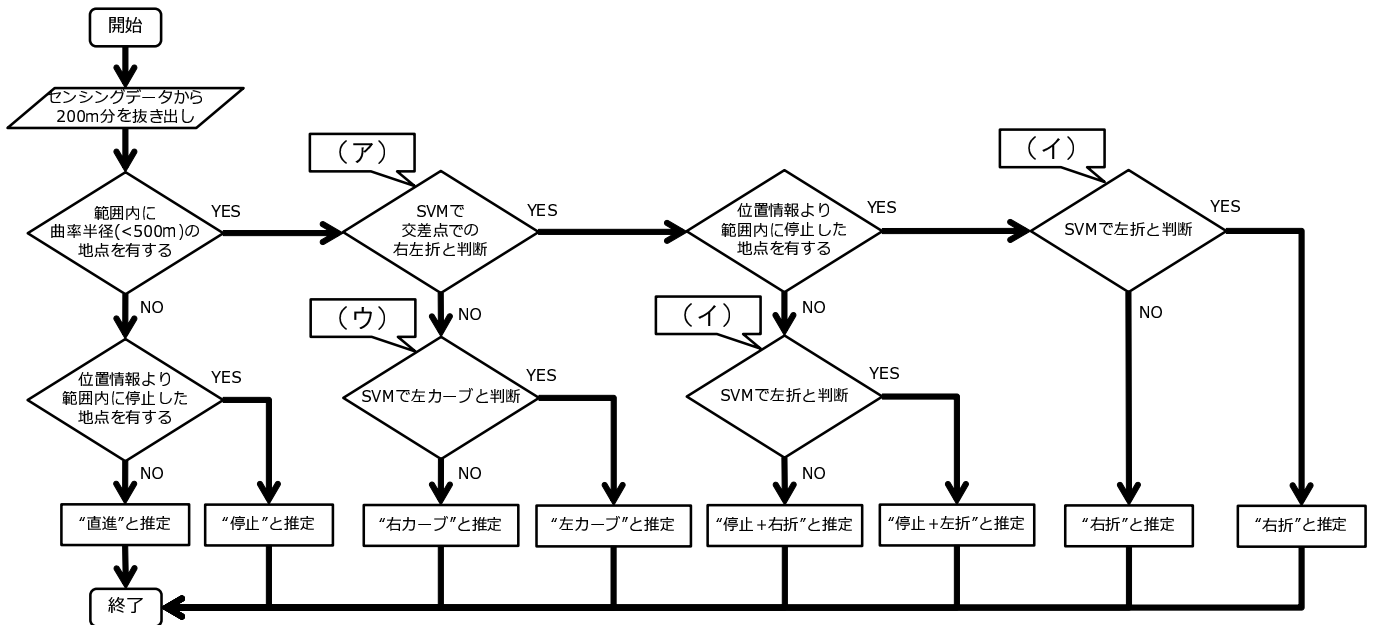


図 2 挙動分類のフローチャート

うに、手作業で行ってきた作業を自動化し、コーパスを作成するためのデータを作成する。

人間行動把握の分野では、この人間の行動の種類をあらゆる正解ラベルを基本的に手作業で付加している。これは、人間の行動が多岐にわたり複雑であるためである。同じ様な身体運動で作業の内容が異なることや、手先での作業など細かい動作が連続して発生するため自動での分類は困難である。実際に、看護師の行動を推定する研究 [10] では、手洗いや看護作業など 22 個の細かい看護師の動作の弁別を試みている。現在、ラベル付けの全自動化は実現できておらず、人間の行動に対する正解ラベル付けの際に、行動の順番を記録していれば、セグメント分けされたデータへのラベルの補助を行う研究も存在している [11][12]。

一方で、二輪車の動作は右左折など人間の行動に比べて動作の幅が狭い。さらに、人間の関節の数に比べて二輪車の挙動に関係する可動部は、ハンドル、フロントサスペンション、リアサスペンションと非常に少ないため細かく複雑な動作が少ない。そのため、人間に比べて正解ラベル付けが容易である。加えて、二輪車は一つ一つの挙動が右左折のように大きく、そのほとんどが道路に則しているため、GPS によって走行軌跡がわかれば自動で正解のラベル付けが可能である。文献 [4] では、この自動正解ラベル付けとともに、機械学習によって学習させるためのデータの補正方法を示した。しかし、この手法にも GPS の誤差などから、データの位置にズレが発生してしまう。さらに、この方法では旋回時の動作がカーブか交差点なのかを判別するには、地図の交差点情報が必要である。

これまで、この交差点情報の入力の手作業で行ってきた。したがって、誤差の非常に少ない GPS 情報と地図の交差

点情報があれば高精度な自動ラベル付けが可能であるが、未知の道を通ったり、地図情報の少ない地点を走行した場合使用できない。そこで、本稿では自動でラベル付けされたデータを抜き出し機械学習による解析を行い、地図情報なしでもより細かな自動ラベル付けを行う。

### 3.2 データの収集方法

#### 3.2.1 必要なセンシング項目

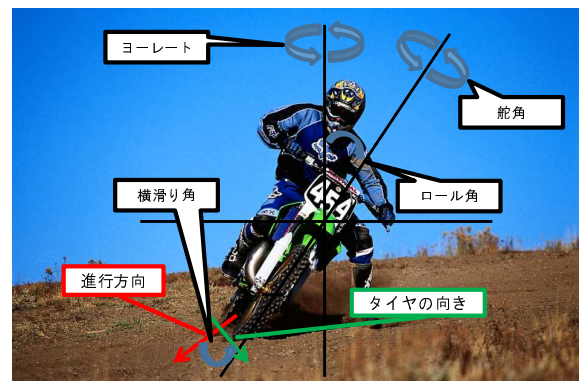


図 4 4 自由度モデル説明

二輪車の挙動は、R.S.Sharp により図 4 のような 4 自由度モデル（横すべり角、ロール角、ヨーレート、舵角）によって説明できることが示されている [13]。ハンドルに取り付けたモーションセンサが取得できるのは、ロール角とヨーレートである。ロール角は、ジャイロセンサのロール軸から得られたデータを積分することで算出可能である。しかしながら、ジャイロセンサは熱や振動からドリフトなどのノイズを多く受けるため、単純に積分するだけでは使用できない。ヨーレートは、ジャイロセンサのヨー軸か

ら得られたデータを使用できる。本稿では、右左折、右左カーブでは向きの変化が顕著であるため、二輪車の向きの変化が得られるジャイロセンサのヨー軸に着目した。

### 3.2.2 収集データ

スマートフォンは近年普及の兆しを見せており、現在保有携帯電話台数の4割以上がスマートフォンであり、今後も保有率は増加して行き5割を超えると示唆されている。近年のスマートフォンはモーションセンサとして、加速度センサ、ジャイロセンサ、地磁気センサを搭載しているものが多く、ほとんどのモデルがGPSレシーバも搭載しているため、センシングデバイスとして用いるのに非常に都合が良い。さらにスマートフォンを利用することで、新たに二輪車にモーションセンサを導入するコストを削減できる利点がある。よって本稿では、センシングデバイスとしてスマートフォンを用いた。

Androidデバイス上にセンシングアプリケーションを構築し、二輪車走行中にセンシングアプリケーションを起動し、データを収集する。スマートフォン内蔵時計のタイムスタンプとともに、3軸の加速度センサ、3軸のジャイロセンサ、3軸の地磁気センサ、GPS情報とともに外部メモリに記録する。

二輪車の挙動の中でも、振動数の高い操舵系の振動であるウォブルモードは、6-10Hzで車速の上昇とともに不安定化する[14]。つまり、標本化定理より、倍の20Hzのサンプリングレートがあればウォブルモードは検出が可能である。最近のスマートフォン上のアプリケーションによるサンプリングレートは、1000Hz程度でも動作はするものの安定性を欠いてしまう[3]。動作が安定し且つウォブルモードを検出可能なサンプリングレートである100Hzを選択し実験を行う。

## 3.3 SVM (Support Vector Machine)

分類器によって、未知のデータを分類する手法は多岐にわたる。機械学習を用いた分類器としては、ニューラルネットワークや決定木、SVMなどがあげられる。SVMは、入力されたデータを高次元空間に写像し、その高次元空間で最適な分離超平面を使用することでデータを分類する分類器である[15]。SVMは、汎用性が高く、考慮すべきパラメータの数が少ない。さらに、分類精度も比較的高いため行動推定分野では広く使用されている。本稿では、SVMを使用して二輪車の右左折、右左カーブの分類を行う。なお、SVMの実装にはR上で動作する無料パッケージであるLIBSVM[16]を使用した。

### 3.3.1 データの切り出し

旋回動作が起きた場面をもSVMに学習させるために、GPSによる位置情報から曲率半径が一定以下の地点を抜き出し、その前後のモーションデータを切り出す。実際の位置情報を解析し予備実験を行った結果より、閾値となる曲率

表 1 抽出した特徴量

	特徴量
A	最大値
B	最小値
C	正の数のサンプル数
D	負の数のサンプル数
E	正の数のサンプルの合計値
F	負の数のサンプルの合計値

半径を100mとした。しかしながら、二輪車から収集したモーションデータはそのままではSVMに学習させることはできない。二輪車の走行速度は、同じルートを走行しても毎回同じであることはないため、同じカーブを曲がったとしても含まれるモーションデータの密度が変化してしまうためである。そのために、時間軸で区切られていたモーションデータを距離軸に変換することで、同じカーブの同じ位置のデータを比較することが可能となる。本稿では、距離軸を1m毎に区切りそこに、時間軸から距離軸に変換したデータを割り振り、手動によるピーク合わせの補正をしたデータを使用することで、SVMに学習させるための比較可能なデータを作成した。

### 3.3.2 特徴量

SVMは、特徴量と呼ばれるデータベクトルを学習することで分離超平面を作成し、未知のデータがどちらに分類されるかを判定する。一般的にSVMは、特徴量の次元数をむやみに増やすと分類精度が悪くなる。これは学習データ数に比べて、特徴量の次元数が大きすぎると過学習に陥り、未知のモデルを必要以上に複雑に学習してしまうためである。そのために、特徴量の選択は慎重に行われるべきである。

曲率半径が100mのカーブということは、弧に沿って右や左に向きを変えた場合90度向きを変えたとする157mの移動となる。したがって、右左折、右左カーブの中心点から、前後100m分、GPSの精度を考慮して1m毎のデータベクトルを特徴量とすると、ヨーレートとロール角にそれぞれ200個の値を持つことになり特徴量の次元数は400になる。学習データは特徴量の数倍が望ましいとされている。そのため、特徴量の削減が必要となる。3.2節で示したように、ジャイロセンサのヨー軸のみに絞ることで特徴量の次元数は200まで削減することができる。しかしながら、現時点で取得できた学習データが50程度であることを鑑みて今回の評価では、特徴量は1桁程度まで減らすことが望ましい。そこで、ジャイロセンサのヨーレートのデータから、表1に示す次のような特徴量を抽出した。センサから得られたヨーレートのデータから、ピークの高さを示す最大値、最小値、向きを変えていた距離を表すサンプル数、どれだけ向きを変えたかを示すサンプル数の合計を使用した。また、生データはノイズが多く全く判断ができないため、特徴量を抽出する前に我々の先行研究[17]で

示した標本数 50, カイザー窓で最適化した FIR フィルタを使用しノイズを軽減している。

## 4. 評価実験

### 4.1 二輪車のモーションセンシングデータ収集実験環境

SVM で解析するために, 実際に二輪車にスマートフォンを取り付け実験を行った. 右左折, 右左カーブのデータを収集するために, 浜松市内の左右の旋回を複数回含む全長 11km 程度のモデルコースを策定し, 同一の車両, ライダー, デバイスで往復走行を繰り返した. 実際のモデルコースが図 5 である. 本稿で分類に使用した交差点とカーブが図 6 (a) (b) である. 図 6 (a) が曲率半径約 20m の交差点であり, 図 6 (b) が曲率半径約 40m のカーブである. さらに, 二輪車, ライダー, デバイスの実験環境を表 2 に示す. 現在までに, 25 往復, 延べ約 550km 分のデー

表 2 データ収集実験環境

車両	FZ6N YAMAHA 600cc スタンダードタイプ
ライダー	男性 24 歳 二輪車運転歴 6 年
デバイス	AQUOS PHONE SH-01D OS:Android ver.2.3.5 メモリ:1GB CPU:Texas Instruments OMAP4430 1GHz 2 コア

タを収集している. このデータに位置情報から正解ラベルを取り付けた後, SVM でさらに詳細な分類を行いラベル付けを行う.

### 4.2 SVM を用いた右左折挙動の推定実験

#### 4.2.1 対象データ

実際に, 位置情報から正解ラベルを付加され抜き出されたモーションセンシングデータが図 7 (a) (b) と図 8 (a) (b) である, 図 7 (a) が右折時のセンシングデータであり下に凸の特徴を持つ. 図 7 (b) が左折時のセンシングデータであり上に凸の特徴を持つ. 一方, 同じように図 8 (a) が右カーブ時のセンシングデータであり下に凸の特徴を持つ. 図 8 (b) が左カーブ時のセンシングデータであり上に凸の特徴を持つ. 右折時のデータを 16 個, 左折時のデータを 10 個, 右カーブ時のデータを 12 個, 左カーブ時のデータを 11 個使用した. 右左折と右左カーブでは, 旋回動作の続く長さが違うため, 裾の広さが変化する. 加えてピークの高さに違いが出るのが分かる. このデータから, 3.3.2 節で示した特徴量の抽出を行った. この結果が, 表 3 である.

#### 4.2.2 SVM の設定

SVM に表 1 に示した 6 次元の特徴量のデータセットと特徴量抽出を行わない図 7 (a) (b) と図 8 (a) (b) に示した 200

表 3 特徴量の抽出結果

		A	B	C	D	E	F
右折時	sample1	0.102	-0.360	75	126	3.305	-25.378
	sample2	0.052	-0.358	76	125	2.642	-21.198
	sample3	0.001	-0.103	46	88	0.021	-3.164
	sample4	0.108	-0.139	144	57	4.979	-3.111
	sample5	0.143	-0.121	108	93	6.184	-3.722
	sample6	0.012	-0.446	80	84	0.525	-19.359
	sample7	0.048	-0.384	104	83	1.779	-17.072
	sample8	0.070	-0.362	91	110	3.004	-22.233
	sample9	0.055	-0.336	74	127	1.628	-13.310
	sample10	0.026	-0.038	102	99	0.920	-1.114
	sample11	0.065	-0.415	92	109	3.145	-15.528
	sample12	0.087	-0.428	63	138	2.605	-26.615
	sample13	0.087	-0.397	116	85	5.901	-16.292
	sample14	0.043	-0.460	40	161	0.840	-22.020
	sample15	0.014	-0.286	71	94	0.557	-8.763
	sample16	0.094	-0.373	88	113	3.223	-22.268
左折時	sample1	0.347	-0.012	101	70	11.430	-0.446
	sample2	0.386	-0.018	114	87	12.752	-0.455
	sample3	0.407	-0.013	131	70	13.839	-0.538
	sample4	0.201	-0.012	181	20	6.255	-0.147
	sample5	0.009	0.000	97	0	0.358	0.000
	sample6	0.019	-0.013	70	22	0.718	-0.195
	sample7	0.325	-0.008	66	70	10.279	-0.172
	sample8	0.440	-0.025	129	72	21.766	-0.656
	sample9	0.410	-0.021	98	103	13.766	-0.986
	sample10	0.358	-0.022	125	76	12.012	-0.723
右カーブ時	sample1	0.066	-0.175	42	159	1.641	-13.410
	sample2	0.000	-0.195	0	143	0.000	-13.394
	sample3	0.000	-0.161	1	151	0.000	-11.537
	sample4	0.000	-0.211	0	134	0.000	-11.229
	sample5	0.067	-0.165	29	172	1.461	-17.066
	sample6	0.046	-0.203	51	150	1.548	-18.291
	sample7	0.000	-0.184	0	182	0.000	-15.214
	sample8	0.031	-0.173	26	175	0.444	-13.473
	sample9	0.035	-0.203	69	132	1.862	-19.913
	sample10	0.000	-0.155	0	197	0.000	-12.078
	sample11	0.035	-0.199	52	149	1.445	-16.142
	sample12	0.026	-0.181	62	139	1.040	-13.471
左カーブ時	sample1	0.119	-0.146	147	54	6.362	-3.356
	sample2	0.263	-0.032	164	37	18.470	-0.569
	sample3	0.166	-0.028	146	55	13.102	-0.453
	sample4	0.152	-0.017	188	13	14.068	-0.098
	sample5	0.126	-0.010	169	32	11.009	-0.212
	sample6	0.249	-0.019	149	39	21.282	-0.334
	sample7	0.250	-0.032	172	29	22.390	-0.313
	sample8	0.160	-0.021	154	47	10.978	-0.850
	sample9	0.164	-0.016	197	4	12.582	-0.034
	sample10	0.219	-0.036	162	39	21.731	-0.726
	sample11	0.232	-0.043	164	37	18.798	-0.799

次元のジャイロセンサのヨー軸のセンシングデータのデータセットを特徴量として学習させモデルを構築し評価した. SVM のパラメータとしては, 表 4 に示すパラメータを使用した. SVM を用いた初期段階の実験のため, パラメータは基本的に LIBSVM の設定のデフォルト値を使用した. LIBSVM が有する SVM の分類器には, C-classification と

表 4 SVM のパラメータ

svm type	C-classification
kernel type	RBF
kernel $\gamma$	$1/k$ ( $k$ は特徴量数)
cost parameter C	1

nu-classification がある. nu-classification は, 認識率の目標とする下界, 上界がある場合に使用される. 本稿では, 一般的な C-classification を使用して実験を行った.

カーネルには RBF (Radial Basis Function) カーネルを使用する. RBF とは, その値が原点からの距離のみに依存する実数値関数である. LIBSVM では, RBF と呼ばれるが, 正確には,  $K(x, x') = \exp(-\gamma \|x - x'\|^2)$  であるガウシアンカーネルのことである. 他にも, 線形カーネル, 多項式カーネル, 双曲線正接カーネルなどが使用できる. RBF カーネルは, データに関する予備知識が無いときなどに用いられる汎用的なカーネルであり, LIBSVM のデフォルトで使用されている最も一般的なカーネルである. 本稿では, データの特性などを深く考慮できていない初期実験の



図 5 モデルコース (図中 KP は 1km 毎のマイルストーン)



(a) 右左折場所詳細 (曲率半径:約 20m)

(b) カーブ場所詳細 (曲率半径:約 40m)

図 6 モデルコースの中から使用した交差点とカーブの詳細

段階であるため、このカーネルを使用した。

カーネル内の  $\gamma$  は、デフォルトである特徴量の次元数  $k$  の逆数である  $1/k$  とした。加えて、cost パラメータ  $C$  としてデフォルトである 1 を使用した。コストパラメータとは、SVM のマージン内にサンプルが入ることを許すソフトマージン SVM の 1 つのパラメータであり、マージンに入ってしまったサンプルにペナルティを与えるための重みの変数である。この  $C$  を小さくするとマージンを越えた場合のペナルティが少なくなり、厳密にモデルを推定しない。代わりに過学習が少なくなる。 $\gamma$  と  $C$  は、グリッド探索などで適した値を探索するが、値を変化させてもあまり変化が見られなかったため、本稿ではデフォルト値とした。

#### 4.2.3 検証方法

モデルの評価方法として、leave-one-out 交差検証を用いた。サンプル全体から 1 つサンプルだけを抜き出してテ

ストサンプルとし、その他のサンプルを学習サンプルとなる検証を行う。全てのサンプルが 1 回ずつテストサンプルとなる様に検証を繰り返す手法である。全ての結果の平均を全体の推定結果とする。全てのサンプルで検証を行うため、外れ値がどのサンプルなのか判別できるためこの方法を使用した。

まず、右左折と右左カーブが混ざったデータから、交差点での右左折なのか、カーブなのかを判断する。右方向と左方向がそれぞれどのように分類されるのかも評価した。その後、右左の判断を行い評価した。

#### 4.3 分類の評価結果

結果を表 5 に示す。表内の記号は図 2 の記号と対応する。実行結果より、正確度はどの分類も 90% を超え非常に高い正確度で推定できていることが分かる。抽出した 6 次




図 7 右左折時のジャイロセンサ (ヨー軸) から得られたデータセット

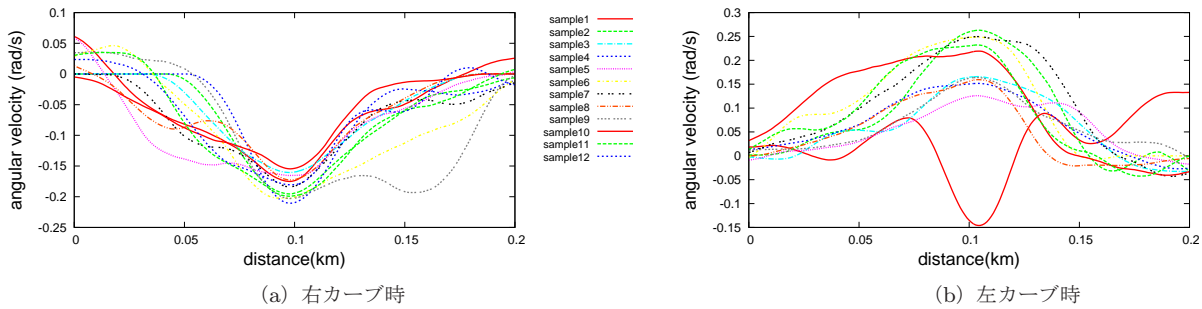


図 8 右左カーブ時のジャイロセンサ (ヨー軸) から得られたデータセット

表 5 leave-one-out 交差検証結果

	6 特徴量	200 特徴量
右左折と右左カーブ (図 2 (ア))	95.918%	91.837%
右折と左折 (図 2 (イ))	92.308%	80.769%
右カーブと左カーブ (図 2 (ウ))	100%	100%
右カーブと右折	100%	100%
左カーブと左折	90.476%	90.476%

元の特徴量の分類結果は、200 次元の特徴量の結果に比べ高い正確度を示している。これは、200 次元の特徴量の学習によって過学習が発生してしまい、分類精度が低下してしまったためと考えられる。この結果より、6 次元の特徴量抽出は上手く行えていると言える。更に、旋回の種類と向きは 6 次元の特徴量の結果から SVM を用いれば判断可能であることを示した。また、直進、停止、旋回の種類は GPS の位置情報を用いることで判断が可能である。したがって、二輪車の挙動の「直進」、「停止」、「右カーブ」、「左カーブ」、「停止+右折」、「停止+左折」、「右折」、「左折」8 種類は位置情報とセンシングデータを SVM で解析することで分類可能であることを示した。

## 5. おわりに

本稿では、二輪車の ITS 基盤を創出する Bikeinformatics の一環で、二輪車の車体挙動を解析するために、SVM と GPS による位置情報を用いて「直進」、「停止」、「右カーブ」、「左カーブ」、「停止+右折」、「停止+左折」、「右折」、「左折」を分類しラベル付けする方法を提案した。直進、停止、旋回の種類は GPS の位置情報を用いることで判断が可能である。残りの分類は SVM を用いて行った。SVM を用いる際に、特徴量が多くなりすぎるのを防ぐために、

旋回挙動を特徴的に表すジャイロセンサのヨー軸を選択した。さらに、最大値、最小値、正のサンプル数、負のサンプル数、正のサンプルの合計、負のサンプルの合計の特徴量を抜き出し特徴量の削減を実現した。この特徴量を用いて実際に走行データから抜き出したサンプルより実験を行った。結果として、判断の正確度はどの分類も 90% 以上であり高い正確度で推定が可能であることを示した。

本稿では、以上の結果から高い精度で正解のラベルをつけることが可能であることを示した。今後の展望としては、道路の交差点情報が手に入れば、交差点とカーブの SVM による分類が必要なくなり、より正確な推定が可能になる。また、今後の課題としては、実験のサンプル数をより増やし実験すること、様々な環境の交差点カーブのデータを使用して実験を行うこと、本稿では深く考慮できなかった SVM のパラメータを適したものを選択することである。

## 謝辞

本研究は、JSPS 科研費 26330102 (基盤研究 (C)「二輪車の車体運動センシングシステムの研究」) の助成を受けたものである。

## 参考文献

- [1] 櫛田和光, 片山睦, 堤陽次郎, 丸山一幸, 鎌田豊, 村田裕, "Honda ASV-3 の紹介 (二輪車)," HONDA R&D Technical Review, Vol.18 (No.2), pp.13-20, (2006) .
- [2] 総務省統計局, "平成 24 年中の交通事故の発生状況," <http://www.e-stat.go.jp/SG1/estat/Pdfdl.do?sinfid=000019681521>
- [3] 木谷 友哉, "Bikeinformatics: 情報科学的二輪車 ITS の基盤研究," 情報処理学会マルチメディア, 分散, 協調とモバ



- イル (DICOMO2013) シンポジウム論文集, pp.1517-1524, (2013) .
- [4] 神村 吏, 木谷 友哉, “位置情報を用いた二輪車モーションセンシングデータへの正解データ自動ラベリング手法の一提案,” 情報処理学会研究報告, マルチメディア通信と分散処理研究会報告 2013-DPS-157 (6) , pp. 1-6, (2013) .
- [5] 小島康一, “ふらつき運転検知機能 (世界初) 本田技研工業 (株) アコード&トルネオ,” 自動車工学, Vol.47 (No.7) , pp. 26-35, (1998) .
- [6] 神村 吏, 木谷 友哉, 渡辺 尚, “二輪車向け車々間通信を実現するためのスマートフォンによる二輪車の車両挙動収集システムの考案,” 情報処理学会全国大会講演論文集, vol. 74, no. 3, pp. 3485-3486, (2012) .
- [7] 岩本 健嗣, 杉本 大輔, 松本 三千人, “3 軸加速度センサを用いた歩行者推定手法,” 情報処理学会論文誌, 55 巻, 2 号, pp. 739-749, (2014)
- [8] HASC. <http://hasc.jp/> .
- [9] OpenStreetMap. <http://www.openstreetmap.org/> .
- [10] 上田 修功, 田中 佑典, 中島 直樹, “メタ学習に基づく加速度センサからの看護師行動識別,” 情報処理学会マルチメディア, 分散, 協調とモバイル (DICOMO2013) シンポジウム論文集, pp. 663-667, (2013) .
- [11] 村尾 和哉, 鳥居 康幸, 寺田 努, 塚本 昌彦, “行動の順序制約を用いた加速度データのラベル付け手法,” 情報処理学会マルチメディア, 分散, 協調とモバイル (DICOMO2012) シンポジウム論文集, pp. 2056-2063, (2012) .
- [12] 吉作 清彦, 大村 廉, “柔軟な行動の扱いが可能な業務分析・アノテーションツール統合ツールの開発,” 情報処理学会マルチメディア, 分散, 協調とモバイル (DICOMO2012) シンポジウム論文集, pp. 2042-2049, (2012) .
- [13] R.S.Sharp, “The stability and control of motorcycle,” Journal of Mechanical Engineering Science, Vol.13 No.5, (1971) .
- [14] 内藤 茂雄, “二輪車の操縦安定性解析,” YAMAHA MOTOR TECHNICAL REVIEW, CAE 特集号, No.34, (2002) .
- [15] C. Cortes ,V. Vapnik, “Support vector networks,” Machine Learning, 20, pp. 273-297, (1995) .
- [16] Chih-C. Chang, Chih-J. Lin, “LIBSVM: a library for support vector machines,” (2001) . Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>
- [17] 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,” 情報処理学会マルチメディア, 分散, 協調とモバイル (DICOMO2012) シンポジウム論文集, pp. 1352-1360, (2012) .