

# 車両走行時の振動発生モデルに基づく 移動手段識別方式

大橋 洋輝<sup>1</sup>・秋山 高行<sup>1</sup>・佐藤 暁子<sup>1</sup>

<sup>1</sup>非会員 株式会社 日立製作所 中央研究所 社会情報システム研究部

(〒185-8601 東京都国分寺市東恋ヶ窪一丁目280番地)

E-mail:hiroki.ohashi.uo@hitachi.com

近年スマートフォンなどの携帯端末から得られる情報を活用した交通情報生成・交通計画支援などに注目が集まっている。本研究では、スマートフォン搭載のGPS受信機で得られる位置情報を用いたプローブ交通情報生成システムに注目する。この実現のためには、スマートフォンに搭載されたセンサから得られる情報を用いて、端末保持者の移動手段を識別する必要がある。本研究では特に、従来手法では識別が難しかった車とバイクの識別手法として、車両走行時の振動発生モデルに基づく移動手段の識別手法を提案する。評価実験を行ったところ、80%以上の精度で車とバイクを含む移動手段が識別可能であることを確認した。

**Key Words :** ITS, プローブ交通情報, スマートフォン, 移動手段識別, 機械学習

## 1. はじめに

新興国では重度の交通渋滞が深刻な社会問題となっている。的確な渋滞解消策の立案のためには、まず現在の交通利用状況を広範囲に渡って把握することが必要である。とりわけ新興国ではバイクの利用率が非常に高いという特有の交通事情があるため、車だけでなくバイクの交通利用状況を正確に把握することが重要である。

交通利用状況を把握するために、日本をはじめとする先進国ではタクシーなどの車両(プローブカー)に搭載された車載GPS受信機によって得られる位置情報を利用する方法(タクシープローブシステム)[1][2]や、VICS(Vehicle Information and Communication System)に代表されるような路側のセンサを用いる方法[3][4][5]、またそれらを統合した方法[6]などが研究され、実用化されている。ところが、タクシーを用いる方法ではバイクの交通状況を把握することはできない。また路側センサを用いて広範囲をカバーするためにはセンサの設置コストが膨大になってしまう。従ってこれらの方法をそのまま新興国に適用することはできない。

そこで本研究グループではスマートフォン(以下、スマホと呼ぶ)を用いて交通情報を生成するシステム(以下、スマホプローブシステムと呼ぶ)を提案している。スマホには通常GPS受信機が搭載されており、これを用いて

スマホの位置情報を得ることができる。またスマホは車・バイク・歩行など、どんな移動手段を用いている時でも携行可能である。従って、スマホ保持者が車やバイクに乗って移動している時の位置情報を収集することで、車やバイクの交通状況を推定することができる。さらに、スマホは近年新興国においても普及が進んできており、これを用いれば道路インフラ側への投資コストは不要である。

しかしスマホプローブシステムを実現するためには課題がある。スマホは常時携行されていることが多いため、スマホで収集されるデータの中には様々な移動手段利用時のデータが含まれ得る。従って、スマホで収集する位置情報を利用して車やバイクなどの交通状況を推定するためには、どの時間帯にどのような移動手段を利用していたかを識別する必要がある。

そこで本研究では、スマホに標準的に搭載されているGPS受信機及び加速度センサのデータを用いて、スマホ保持者の移動手段を自動で識別する手法を提案する。とりわけ、新興国での交通情報生成システムへの適用のため、振動発生モデルに基づいて、車・バイク・歩行を識別する手法について提案する。

以下ではまず第2章でスマホをはじめとする携帯端末に搭載されているセンサを用いた移動手段識別手法と関連手法の課題について述べる。次に第3章で本研究の提

案手法について説明する。第4章では手法の有効性の評価のために行った実験について紹介し、その評価結果と考察を述べる。最後に第5章で本論文のまとめを述べる。

## 2. 関連研究

従来、ユーザ状態に応じたサービス提供(コンテンツウェアサービス)や人の生活行動を記録するライフログなど、様々な分野への適用を目指して携帯端末に搭載されているセンサを用いた移動手段の識別手法の研究がなされてきた。ところがその中で車とバイクを識別対象として扱っている研究はない。

Choら[7]は「歩行」「静止」「乗車中(乗車の種類は電車またはバス)」「ランニング」の4種類の移動手段を97.2%の精度で識別する手法を提案した。ここでは、加速度の大きさとその鉛直成分・水平成分に対し、それぞれ平均値、最小値、最大値、分散値を計算し、この計12の特徴量を入力として、ニューラルネットワークを用いて識別を行っている。Longら[8]は加速度センサの標準偏差や信号の周期性など19の特徴量を、PCA(Principal Component Analysis)を用いて5つに削減してから用いることで、「歩行」「ランニング」「自転車」「運転」「スポーツ」の5種類を~80%の精度で識別する手法を提案した。しかしこれらの研究では「乗車」とそれ以外の識別は精度良くできているものの、車とバイクなど「乗車」の中の車両の種類識別までは考慮されていない。これらの研究で主に用いられている周波数や加速度の統計量などの特徴量を図1、図2に示す。これらの図に示されるように、車とバイクでは類似度が高く、このような特徴量を用いて車とバイクの識別を行うことは困難であると考えられる。

車両の識別を行っている研究としてはZhengら[9]の研究や小林ら[10]の研究が挙げられる。Zhengらの研究では、GPS情報のみを用いて「歩行」「自転車」「車」「バス」の4種類の移動手段を識別している。時系列上のGPSデータをセグメントに区切った後、セグメントごとに、セグメントの長さ・平均速度・速度の期待値・速度の分散・上位3位までの速度・上位3位までの加速度、の6つの特徴量を計算し識別に利用する。識別手法としては、Decision Tree, Support Vector Machine, Bayesian Net, Conditional Random Fieldの4つの手法が試されており、Decision Treeを用いた手法が74.3%と最も高精度を達成したと報告されている。しかしここでは、どの移動手段がどの程度の識別精度かという詳細情報が明記されていない。上記特徴量は、歩行や自転車と車両に関しては大きな差異があっても、同一道路を走行する車両の間では類似することが予想されるため、車両の種類識別精度は

74.3%よりも低くなると考えられる。車とバイクについても、図2や図3から分かるように、上記特徴量は類似しており、この手法をそのまま適用することは困難であると考えられる。一方、小林らは「走行」「歩行」「自転車」「停止」「自動車」「バス」「電車」の7種類をF値0.8以上で識別する手法を提案した。ここでは、加速度センサ・GPS受信機・マイクなどが用いられている。HMM(Hidden Markov Model)により、これらのセンサデータの時間的な変化特徴を捉えて識別がなされている。こ

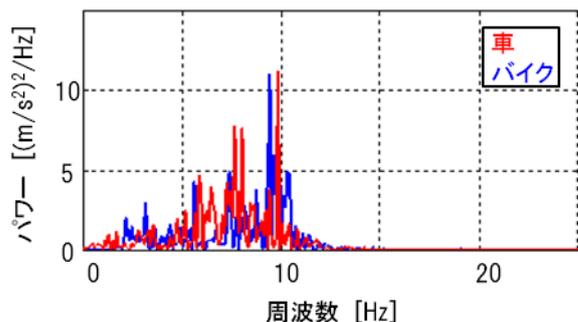


図1 加速度データの周波数の比較。特徴は類似しており識別は困難であると考えられる

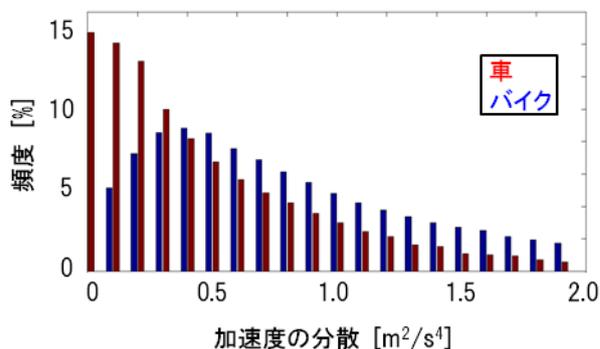


図2 加速度の分散値の比較。5秒ごとに加速度を計算した結果の頻度分布。バイクの方が加速度の分散値は大きい傾向が見られるが、識別に用いることができるほど顕著な差はない

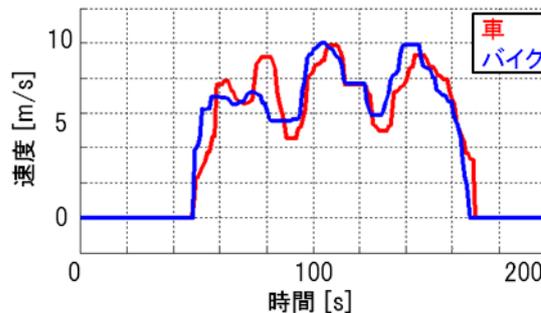


図3 速度の比較。同一道路を同一時間帯に走行した時のデータ

れまでに述べてきたように、加速度や速度に関連する特徴量は車とバイクでは類似しているため、それらに基づく識別は困難であると考えられるが、エンジン音には有意な違いがあると考えられる。そのため小林らの手法を用いれば車とバイクの識別ができる可能性がある。ところが、一般ユーザへの展開を考えるとマイクを用いる手法ではプライバシー上の問題が懸念される。

### 3. 提案手法

本研究では、スマホに一般的に搭載されているGPS受信機と加速度センサから得られるデータのみを用いて、車・バイク・歩行を識別する手法を提案する。まず3.1節で提案手法の全体構成を述べる。次に3.2節で、本研究の主眼である走行中の車両における振動発生モデルに基づく車とバイクの識別手法について詳しく説明する。

#### (1) 全体構成

本研究で提案する移動手段識別手法の全体構成を図4に示す。図にあるように、入力は加速度データとGPSデータである。まず前処理としてGPS情報が取得できていないデータや、加速度が所定のサンプリングレート以上で取れていないデータを識別対象外として除去する。次に加速度データの周期性に注目して歩行を検出する。具体的には、加速度データの自己相関関数を計算し、そのピークを検出する。この検出されたピークが歩行の周期に対応する所定の範囲内にある場合に歩行として検出する。続いて静止区間を識別する。ここで言う静止区間とは、オフィスで仕事をしたり食事をするなど、移動をしていない状態のことを指す。具体的には、静止区間では加速度センサの値にほとんど変動が見られないため、加速度センサの値の分散値を計算し、閾値以下の区間を静止区間として検出する。次に、静止でも歩行でもない区間で一定以上の長さを持つ区間を乗車区間とする。そしてここで検出された乗車区間に対して、車かバイクかの識別を行う。この方法の詳細については3.2節で説明する。尚、本研究では乗車区間は必ず車かバイクに分類されるものとしており、電車やバスなどは識別の対象とはしていない。このようにして識別した一連のデータに対し、最後に移動手段の遷移の妥当性に基づいて識別データを補正する。例えば、人間は5分ごとに車からバイクへまたバイクから車へなどと乗り換えることは少ない。従って本提案手法では、このような移動手段の遷移はないものと仮定して識別結果を補正する。具体的には、直近一定個の識別結果を参照し、それらの識別結果が全て車またはバイクのどちらかであったにもかかわらず、その区間の識別結果がそれらと異なっている場合は、誤識

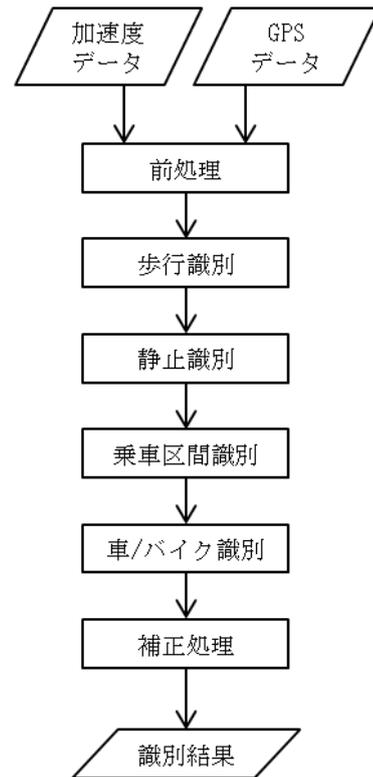


図4 移動手段識別の全体構成

別であったとして識別結果を補正する。尚、本研究ではデータを5分ごとの区間に区切り、この5分間の区間で1つの識別結果を出力することとする。

#### (2) 車/バイクの識別

本節では車両走行時の振動発生モデルに基づいて車とバイクを識別する手法について述べる。まず提案する振動発生モデルについて述べ、次にそれに基づいて具体的に識別を行う方法について説明する。

##### a) 振動発生モデル

本研究では、車両走行時にスマホで観測される振動は(i)路面から受ける振動( $Vib_R$ とおく)、(ii)エンジンに起因する振動( $Vib_E$ とおく)、の2種類の振動の重ね合わせによって得られると考える。

さらに $Vib_R$ に関して、路面に存在する凹凸の密度が高いほど単位時間当たりに観測される振動は大きくなると考えられる。そこで、路面の凹凸の密度を表すパラメータ $Roughness$ を導入し、 $Vib_R \propto Roughness$ とおく。同様に、車両の走行速度が大きいほど単位時間当たりに通過する凹凸の数は多くなるため、その間に観測される振動も大きくなると考えられる。そこで車両の走行速度を表すパラメータ $Vel$ を導入し、 $Vib_R \propto Vel$ とおく。さらに、車両に振動が生じたとき、実際にスマホで観測される振動の大きさは車体の安定性の影響を受けると考えられる。車体の安定性とは、振動を吸収する機能である座席のサスペンションの性能や、車輪数、車高、車重などによって

決定される。安定性が高いほど観測される振動は小さくなると考えられるので、車体の安定性を表すパラメータを  $Stability$  を導入し、 $Vib_R \propto Stability^{-1}$  とおく

以上より、スマホで観測される振動を  $Vib$  とおくと、車両走行時の振動発生モデルとして次式を得る。

$$Vib = a \cdot Roughness \cdot Stability^{-1} \cdot Vel + Vib_E \quad (1)$$

ここで同一地域内では路面状況は類似していると仮定して、パラメータ  $Roughness$  は一定であるとし、エンジンに起因して生じる振動の走行状態による変分は微小なものとして無視すると、式(1)は図5のように速度と振動の2次元平面内での直線を表す。

車とバイクでは車体の安定性やエンジン振動の大きさが有意に異なると考えられる。これは、図5中の傾きや切片の値が有意に異なることを意味する。この差異によって、車のデータとバイクのデータでは、図6のように速度と振動で構成される空間内での存在領域に差異が生じると考えられる。ここで、図6中でデータの存在領域がモデルで表される直線を中心として上下にばらついてるのは、実データではセンサノイズに加え路面状況の違いなどのノイズ要因があると考えられるためである。本研究ではこの速度と振動で構成される空間内での存在領域の差異を利用して車のデータとバイクのデータを識別する。

#### b) 識別手法

本項では、スマホのセンサデータを利用して速度と振動で構成される空間内で車とバイクを識別する具体的な手法について説明する。

まずセンサデータから速度と振動を計算する方法を説明する。速度はGPSにより得られる位置情報及び時間情報を用いて、位置の時間差分として計算できる。振動は加速度センサの値の分散値で表現する。ここではさらに、分散を鉛直方向と進行方向横方向に分解することでより高精度に識別を行うこととする。バイクは二輪車であるため、四輪車である車に比べ特に進行方向に対し横方向の振動が生じやすいと考えられる。

識別にはベイズ理論を用い、確率分布の計算にはヒストグラム密度推定法を用いる。ヒストグラム密度推定法は、学習データの分布が特定の分布に従わない場合でも確率密度の学習が可能であり、さらに、一度学習をしまえば学習用データを破棄でき、識別計算も高速にできるという特徴がある。そのため本研究のようにデータ点の分布の形状が明白でなく、かつ大量のデータを扱うような場合に好適である。

次にベイズ理論を本研究の車とバイクの識別問題に適用する方法について説明する。

まず学習ステップで、移動手段が既知であるデータ

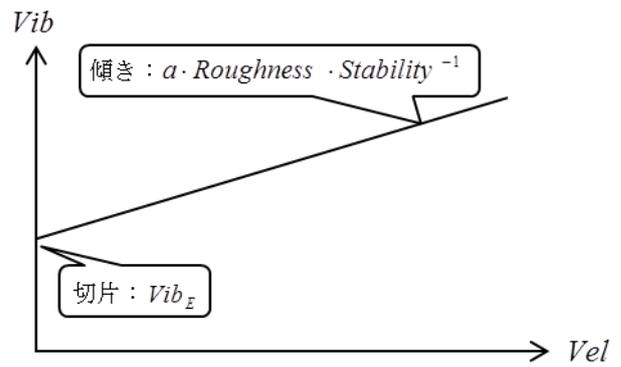


図5 モデルの表す速度と振動の関係

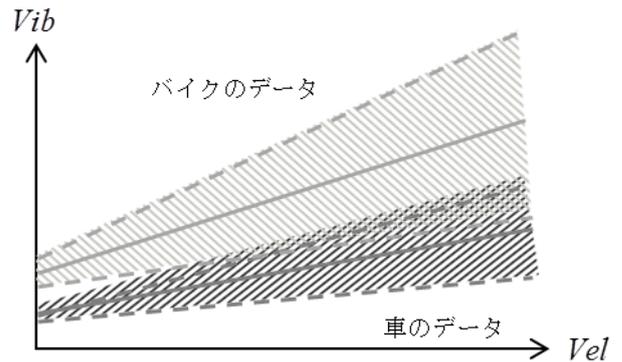


図6 予想される車のデータとバイクのデータの存在領域の違い

(学習用データ) を用いて、移動手段が車 (バイク) であったときに観測値  $\mathbf{x}$  が得られる条件付き確率  $p(\mathbf{x} | C)$  ( $p(\mathbf{x} | B)$ ) をヒストグラム密度推定法を利用してそれぞれ求めておく。ここで  $\mathbf{x}$  は速度、加速度の鉛直成分の分散、加速度の進行方向横方向の分散、からなる3次元空間上のベクトルを表し、 $C$  は移動手段が車であるという事象、 $B$  は移動手段がバイクであるという事象である。

移動手段が未知のデータ集合  $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$  が得られたときには、次式により事後確率  $p(C | \mathbf{X})$ 、 $p(B | \mathbf{X})$  をそれぞれ計算し、その大きい方を識別結果として採用する。

$$p(C | \mathbf{X}) = \frac{p(C) \prod_{i=1}^N p(\mathbf{x}_i | C)}{p(\mathbf{X})} \quad (2)$$

$$p(B | \mathbf{X}) = \frac{p(B) \prod_{i=1}^N p(\mathbf{x}_i | B)}{p(\mathbf{X})} \quad (3)$$

ここで、 $p(\mathbf{x}_i | C)$  及び  $p(\mathbf{x}_i | B)$  は学習ステップで計算したものを用い、事前確率  $p(C)$  及び  $p(B)$  は対象地域の車両保有台数に関する統計調査データから決定する。また、データ点を一点ずつ個別に識別すると瞬間的なノイズなどの影響により誤識別が起りやすくなるため、式(2)(3)のようにいくつかの点(例えば5分間分のデータ

など)をまとめた集合として事後確率を計算し、比較するものとする。ここで、式(2)(3)で計算される事後確率のうち大きい方の値が小さいとき(即ち事後確率の差が小さいとき)は、識別結果の信頼性が低いと考えられる。そのため事後確率の大きい方の値を閾値処理し、閾値以下のデータに関しては識別を行わないこととする。

#### 4. 評価

提案した手法の有効性を評価するため、新興国において実験を行った。尚、本評価実験では車とバイクの識別精度に焦点を絞って評価を行った。以下4.1節で実験設定についてまとめ、4.2節で評価結果とそれに対する考察を述べる。

##### (1) 実験設定

表1に実験データの概要を示す。実験はベトナム及びインドの新興国2カ国3都市で行った。実験期間は2012年の3月から6月の約3ヵ月間で、実験参加者は筆者らや現地協力者を含む合計7名である。実験に使用する端末は実験者側で用意し、私用のスマホは用いなかった。実験では車のデータを43.5時間、バイクのデータを27.3時間を収集した。これらの他に、歩行や静止時などのデータが85.1時間あり、総時間は155.9時間であった。収集用のAndroidアプリを開発し、GPSデータと加速度データを時刻付きで収集した。加速度データ・GPSデータは可能な限り多くサンプリングすることとし、それぞれおよそ1Hz, 50Hzでサンプリングを行った。収集したデータのうち、GPS情報が受信できていないデータは識別の対象外として除外した。

データ収集は通勤時や休日の外出時などに行った。真の移動手段を把握するため、メモを携帯して移動の開始時間・終了時間・利用した移動手段を記録するようにした。端末の保持方法に制約は設けず、ポケットに入れる、バッグに入れるなど自由とした。データ収集アプリ起動中にはスマホの操作は行わないようにした。

評価の際には、データセットを5分割しそのうち1つを車とバイクの確率分布学習用として用い、残り全てで評価を行う5-foldのクロスバリデーションを行った。式(2)(3)中の事前確率  $p(C)$ ,  $p(B)$  は今回収集したデータ量に合わせ、それぞれ  $0.61(=43.5/70.8)$ ,  $0.39(=27.3/70.8)$  とした。

##### (2) 結果と考察

図7は速度と振動(加速度の分散値で表現)の平面上に実験で収集したデータをプロットした図である。ここでは車・バイクそれぞれ約30分間分ずつのデータを示している。図7から、実験データにおいても図6で示した想

表1 実験データ概要

項目	内容
実験場所	ベトナム/ハノイ インド/バンガロール インド/ハイデラバード
実験期間	2012/03/08 - 2012/06/04
実験参加者数	7名
実験端末	Samsung Nexus S (Android OS)
収集データ量	合計 : 155.9時間 <移動手段ごとの内訳> 車: 43.5時間 バイク : 27.3時間 その他 : 85.1時間
使用センサ	GPS 受信機, 加速度センサ
データ収集時のサンプリングレート	GPS : 1Hz 加速度 : 50Hz
有効データ量 (GPSが1点以上取得できている)	合計 : 136時間

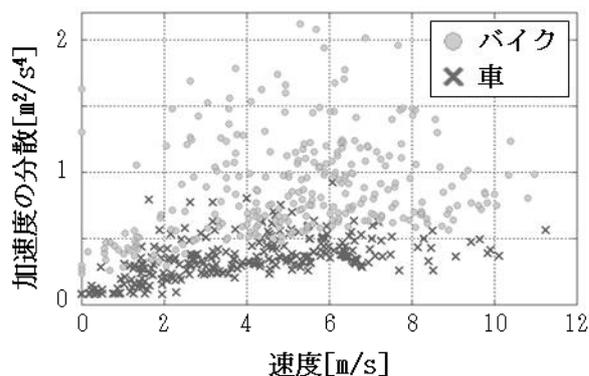


図7 実験データにおける速度と振動(加速度の分散)の関係

定のように、車とバイクの存在領域に差異が見られることが確認できる。

実験データに提案手法を適用した際の評価結果を、表2, 表3に示す。表中の括弧内の数字は、識別単位である5分間の区間の数を示している。表2に示すように、車・バイクのいずれの移動手段についても80%以上の適合率を達成できており、提案手法の有効性が確認できる。表3に示す再現率の値が適合率に比べ低くなっているのは、3章で述べたように式(2)(3)で計算される事後確率の高い方の値に関する閾値処理を行い、事後確率が閾値以下の値を持つデータに関しては識別を行っていないためである。図8に示すように、適合率と再現率はトレードオ

表2 適合率 (正解区間数/推定区間数)

	推定		
	車	バイク	
真値	車	86.5% (294/340)	0.662% (1/151)
	バイク	7.65% (26/340)	83.4% (126/151)
	その他	5.88% (20/340)	15.9% (24/151)

表3 再現率 (正解区間数/実際の総区間数)

車	バイク
85.0% (295/347)	58.9% (126/214)

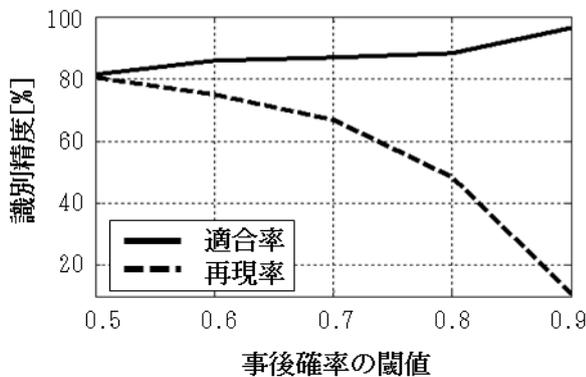


図8 適合率・再現率の関係

フの関係にある。本研究のように、識別結果を利用した交通情報生成を想定する場合、再現率はサンプル数を増やすことでカバーできるが、適合率は生成する交通情報の信頼性に関わるため、再現率よりも適合率を重視すべきである。一方でサンプル数を増やすことが難しい場合などは、閾値を低く設定することで高い再現率を達成することができる。また表2、表3からは総じてバイクより車の方が識別精度が良い傾向が読み取れる。これは車のデータには、筆者含め数人が同一の車に乗って収集したデータが含まれているためであると考えられる。同一車両で同一の時間帯に同一の道路を走行した際のデータは特徴が類似すると予想されるため、識別が容易になると考えられる。

次に誤識別の原因についての分析を述べる。

まず真値が車でもバイクでもないにも関わらず、車あるいはバイクと誤識別している場合について述べる。本研究では初めに歩行検出や静止検出を行い、それらで検出されなかった区間を乗車区間とし、その区間に対し車/バイクの識別を適用している。従って、この誤識別の

原因は(i)歩行の検出漏れ、(ii)静止の検出漏れ、(iii)歩行でも静止でも車でもバイクでもない区間の混入、に分けられる。(i)歩行の検出漏れに関し、本研究では歩行の際に生じる周期的なリズムを加速度の自己相関関数のピーク値により検出している。歩行が検出できないのは、このような特徴的なリズムが検出できなかった場合であると考えられる。本実験では、スマホの保持方法に制約を設けなかったため、例えばクッション性の高い鞆の中にスマホを入れて歩行している場合などに、振動が吸収され特徴が表れにくくなるのが考えられる。現在歩行検出の際には、自己相関関数のピーク値が一定の閾値以上のものだけを対象とし、それが歩行に相当する周期の範囲内にあるかを判定しているが、全体の加速度の振れ幅の傾向などから、この閾値を動的に変更することで精度向上が見込める。(ii)静止の検出漏れに関し、例えばオフィスで仕事をしている間や食事中などは、移動をしていないため静止と識別すべきであるが、この間もスマホを身につけている場合は、振動が生じることがあり得る。このような振動のためにこの区間が静止区間と識別されないことがある。振動だけでなく速度など他のパラメータと合わせて識別を行うことで、このような検出漏れを防げると期待できる。(iii)歩行でも静止でも車でもバイクでもない区間の混入については、例えばバス・電車・自転車・エスカレータ・エレベータなどの利用時がこの区間に相当する。これらの区間は歩行でも静止でもないため、本研究の現在の構成ではこれらを除外すること困難である。しかし、バスや電車などは決まった路線に沿って運行するため、路線情報などを統合することで識別が可能になると見込まれる。自転車に関しては、自転車をこぐ際の動きが周期的な動きとなることから、周波数領域で解析を行うことによって検出できる可能性がある。エスカレータやエレベータは多くの場合屋内に設置されているので、GPSを用いた屋内外判定の利用や、短時間に鉛直方向への加速が発生しているかどうかを判定することによって識別できる可能性がある。いずれにしても、今回識別の対象とした車・バイク・歩行以外の移動手段の識別に関しては今後の課題である。

最後に車をバイクと誤識別した場合及びバイクを車と誤識別した場合について述べる。本研究では車とバイクの識別は走行速度と振動との関係に基づいて行っている。そのため、車であるにも関わらず走行速度に対する振動値が大きかったり、反対にバイクであるにも関わらず振動値が小さかったりすると誤識別の要因となる。このように、全体の傾向とは異なる振動値が観測される原因としては路面状況の違いが考えられる。3章で述べたように、本研究で提案する式(1)の振動発生モデルにおける路面の凹凸の密度を表すパラメータRoughnessは、現在同一地域内では一定であると仮定している。しかし実際に

は、同一地域内でも路面状況が異なる個所があり得、そのような個所で誤識別が生じやすくなると考えられる。そこで、誤識別の生じている箇所について路面状況の調査を行った。図9はバイクを車と誤識別していた道路の例である。平均的な道路と比べ舗装状況が良いため、バイクでも振動値が小さかったためであると考えられる。図10は車をバイクと誤識別していた道路の例である。舗装状況はあまり良くなく、他の車両や道路際の障害物などを避けながら走行していたため、車でも振動値が大きくなったためであると考えられる。図11は同一車両でこ

れらの道路を走行した時の速度と振動の関係を表す図である。図9の道路の方が、実際に走行速度に対する振動値が小さい傾向があることが分かる。このように道路ごとに異なる路面状況について、対象地域で調査を行う、またはデータから推定を行うことによって、(1)式におけるRoughnessを与えることができれば更なる精度の向上が見込める。

## 5. まとめ

本研究ではスマホプローブシステムへの適用を目指して、スマホ搭載のセンサ情報を利用して車・バイク・歩行を識別する手法を提案した。とりわけ、特徴が類似しており識別が困難であった車とバイクについて、走行時の振動発生モデルを導入することにより、高精度に識別を行う手法を提案した。提案した手法を実験によって評価したところ、適合率80%以上、再現率50%以上を達成しており、提案手法の有効性を確認した。今後の課題として、電車やバスなど他の移動手段への識別対象の拡張、スマホ保持方法の違いや路面状況の違いなどへの対応、を検討していく予定である。



図9 真値はバイクだが車と誤識別していた道路 (Nguyen Van Cu 通り)



図10 真値は車だがバイクと誤識別していた道路 (Thuy Khue 通り)

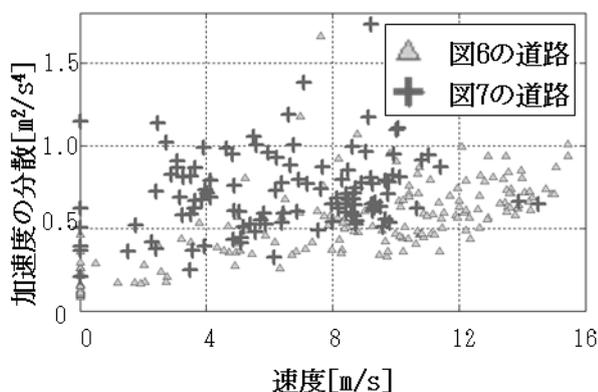


図11 路面状況の違う道路における速度と振動の関係

## 参考文献

- 1) Wang, W., Gushiki, T., Zhang, H., Kimita, K., and Mizuta, H. : A Probe Car System for Beijing, 12th World Congress on Intelligent Transport Systems, 2005.
- 2) 熊谷正俊, 蛭田智昭, 奥出真理子, 横田孝義 : 特徴空間奇跡の追跡による動的交通状況予測, 情報処理学会論文誌, Vol. 53, No. 1, pp.243-250, 2012.
- 3) 森田緯之, 割田博 : 動的な交通状況の予測と交通情報生成, 国際交通安全学会誌, Vol. 31, No. 1, pp.24-30, 2006.
- 4) 山根憲一郎 : VICS データを利用した渋滞傾向情報に関する検討, 土木計画額研究・論文集, Vol. 29, 2004.
- 5) 舟橋賢二, 西村茂樹, 堀口良太, 赤羽弘和, 桑原雅夫, 小根山裕之 : VICS 蓄積データを用いた旅行時間短期予測手法に関する研究, 土木計画額研究・論文集, Vol. 27, 2003.
- 6) 王立暁, 姜美蘭, 森川高行 : プロブカーデータと VICS データの融合による旅行時間推計に関する研究, 土木計画額研究・論文集, Vol. 23, No. 4, pp.1011-1018, 2006.
- 7) Cho, K., Iketani, N., Setoguchi, H., and Hattori, M. : Human Activity Recognizer for Mobile Devices with Multiple Sensors, Symposia and Workshops on Ubiquitous, Automatic and Trusted Computing, 2009.
- 8) Long, X., Yin, B., and Aarts, R. : Single-Accelerometer-Based Daily Physical Activity Classification, 31st Annual International Conference of the IEEE EMBS, 2009.
- 9) Zheng, Y., Liu, L., Wang, L., and Xie X. : Learning Transportation Mode from Raw GPS Data for Geographic Ap-

plications on the Web, International World Wide Web Conference, 2008.

No. 1, pp.193-208, 2009.

- 10) 小林亜令, 岩本健嗣, 西山智 : 釈迦:携帯電話を用いたユーザ移動状態推定方式,情報処理学会論文誌,Vol. 50,

(?)