

釈迦：携帯電話を用いたユーザ移動状態推定方式

小林 亜 令^{†1} 岩本 健 嗣^{†1} 西山 智^{†1}

本稿では、携帯電話に搭載可能な加速度センサ、マイク、GPS を複合的に用い、ユーザの移動状態を自動的に推定する方式を提案する。従来、走行、歩行、停止といった人間の活動状態に加えて、自転車、電車、バス、自動車といった乗車状態を推定対象とした場合、突発的な振動の変化や、振動が他状態と類似する時間帯が発生することにより、推定精度が低下するという課題がある。本方式は、各センサデータの時間的な変化を状態遷移として扱い、各移動状態の推定に適した方式を組み合わせることにより、前記課題の解消を図っている。また、性能評価実験結果により、本方式が、前記 7 状態を F 値が 0.8 以上の精度で推定できることが分かった。

Shaka: Method for Estimating User Movement Using Mobile Phone

AREI KOBAYASHI,^{†1} TAKESHI IWAMOTO^{†1}
and SATOSHI NISHIYAMA^{†1}

This paper presents a method for estimating the movement of a user using a system that combines GPS, a microphone and an acceleration sensor able to be fitted in a mobile phone. Past attempts to provide a means to identify movement associated with riding on a bicycle, train, bus or car, in addition to common human movements like standing still, walking or running, have had problems with poor accuracy due to factors such as sudden changes in vibration or times when the vibrations resembled those for other types of movement. The proposed method aims to avoid these problems by treating time-axis changes in the data from each sensor as state transitions, and by combining different techniques for identifying each type of movement. Performance test results show that the method achieves 80% or better accuracy for all seven of the different types of movement mentioned above.

1. はじめに

近年、日本の携帯電話端末は、高機能化が進み、カメラや GPS、RF-ID などのセンサデバイスが搭載され、様々なサービス（例：ヒューマンナビゲーション、おさいふケータイ）が提供されている。そして現在、新たな携帯電話サービスとして SIP¹⁾ などを用いたユーザプレゼンスアウェアサービスの検討が進んでいるが、これを実現するには、いかにユーザプレゼンス情報を取得するかが重要な技術的課題の 1 つとなる。

本稿では、ユーザプレゼンス情報のうち、ユーザの移動状態に着目する。ここで移動状態とは、走行、歩行、停止といった人間の活動状態と、自転車、自動車、バス、電車といった交通機関の乗車状態を指している。携帯電話を用いて、これらの状態を自動的に推定することができれば、後述する幅広い適用先が期待できる。

そこで本稿では、すでに携帯電話に搭載されている、加速度センサ、マイク、GPS の 3 種類のセンサを複合的に用い、ユーザの移動状態を自動的に推定する方式を提案する。加速度センサの計測値から算出するパワースペクトルを用いて走行、歩行、停止、自転車状態を、マイクの計測値から算出するパワースペクトルを用いて自動車を、GPS の測位結果から算出する平均時速を用いて電車とバスの乗車状態を推定する。また、各センサデータの時間的な変化を状態遷移として扱うため、従来の課題であった突発的な振動変化や他状態と類似する時間帯の発生による推定精度低下を回避することが期待できる。

本稿では、まず 2 章で関連研究を紹介し、3 章で要求条件と課題を述べる。次に 4 章で提案方式を述べ、5 章で性能測定実験結果を報告し、6 章で考察、7 章で結論と今後の予定を述べる。

2. 関連研究

ユーザ移動状態推定方式については、様々な方式が提案されている。本章では、センサを用いて行動推定を行い、結果として移動状態を推定する手法と、位置推定を行い、位置の履歴から移動状態を推定する手法に分けて関連研究について述べる。

2.1 行動推定による状態推定方式

ここでは、行動推定から移動状態推定を行う手法について述べる。

^{†1} 株式会社 KDDI 研究所
KDDI R&D Laboratories Inc.

Kern²⁾は、身体の複数箇所に加速度センサを装着し、「座る」「立つ」「歩く」「階段を上る」「階段を下る」「握手」「黒板への書き込み」「キーボードのタイピング」などの動作推定を行っている。Intille^ら^{3),4)}は両手首、両足首、腿の5カ所に加速度センサを装着し、20種類の動作推定を行っている。また、個々のユーザに特化した閾値設定を必要としないことが特徴である。SenSay⁵⁾では、携帯電話に複数のセンサ情報を加えることで、「取込中」「活動中」「暇」「ノーマル」の4つの状態に分類して、着信音量をサイレントモードにするアプリケーションなどを実装している。WearNET⁶⁾では、加速度センサ、生体センサ、光センサ、温度センサなど、複数のセンサを組み合わせ、位置、環境、ユーザ状態、ユーザ行動の4つのコンテキストを推定している。また、Lee^ら⁷⁾は、加速度センサ、地磁気センサ、ジャイロを組み合わせたウェアラブルセンサによって、歩行、階段、右左折などの移動状態の推定を行っている。Naya²⁷⁾らは、IR-IDで求めた位置情報とユーザの体に装着した加速度センサから、看護師のタスクの推定を行う手法を提案している。

これらの研究は、様々なセンサを用いて、人間の様々な動作状態を推定可能であるが、センサ装着箇所が複数必要であったり、装着方法が固定化されていたり、現実的でない方式が多い。Iso^ら⁸⁾は、携帯電話に、1つの3軸加速度センサを搭載し、ユーザの所持状態によらず、歩行状態（通常歩行、階段昇降、早歩き、走行）の状態を推定している。Kawahara^ら⁹⁾は、1つの加速度センサを用い、センサの装着状態を識別し、「歩く」「立つ」「座る」「走る」の状態を推定する手法を提案しているが、人間の活動状態だけでなく、自転車、自動車、バス、電車といった乗車状態まで含めた移動状態推定方式に関する検討は、これまで行われていない。

2.2 位置情報を応用した移動状態推定

位置情報や位置情報の履歴から移動状態推定を行う手法も考えられる。たとえばGPSを用いて得た移動軌跡から移動速度を計算し、地図と照合することで、電車やバス、徒歩といった移動状態を推定することも可能である¹⁰⁾。しかし、GPSのみで様々な移動状態を推定することを想定すると、地下鉄での移動や、建物内の歩行など、衛星からの電波が届きにくい場合、利用が困難だったり精度が落ちてしまったりするという問題がある。

これに対し、GPSが使えない場合でも、データを加速度センサで補完する手法や¹¹⁾、加速度センサのみで位置を推定する手法¹²⁾も考案されている。これらの手法では、移動方向以外の人体の動きがノイズになるため、センサの装着位置に制限があり、携帯電話に応用するのは難しい。

また、田中^ら¹³⁾は、カーナビゲーションを応用し、目的地予測を行う手法を提案してい

る。この手法では、GPSから得られる位置情報に加えて、運転状況を加えて目的地の推定を行っている。しかし、車での移動に特化した状況推定を行っており、本研究が目指す、より汎用的な移動状態推定への適用は難しい。

ロボットの位置推定では、自位置の特定とマップの生成を同時に行う手法としてSLAM (Simultaneous Localization and Mapping) と呼ばれる手法¹⁴⁾がある。ロボットと環境のインタラクションからHMMのモデルを作成することで推定を行う。このような手法を人物にも応用し、地図上で位置を取得することで、現在の移動状態推定を行うことも可能と考えられる。しかし、SLAMでは、環境認識にステレオカメラやレーザレンジファインダのように多くの情報量が得られるセンサを利用する。これらのセンサは、視野を得るためにロボットに固定する必要がある。本研究が想定する、携帯電話に搭載し、ユーザが普段の生活で利用するのは困難と考えられる。

またウェアラブルカメラ単体¹⁵⁾、もしくは加速度センサを組み合わせ¹⁶⁾て位置情報を取得する手法も研究されている。これらの手法ではあらかじめデータベースへ登録した画像と撮影した画像を比較することで、現在位置や向いている方向などを推定することができる。特定の乗り物内での画像をデータベースに登録しておけば、移動状態推定へ応用も考えられる。しかし、携帯電話のカメラをつねに起動し、撮影し続けることは、消費電力の点や、携帯電話の一般的な利用方法に照らし合わせても現実的とはいえない。

3. 本研究の前提と課題

本章では、まず携帯電話を用いた移動状態推定方式の前提として、想定アプリケーションと推定対象項目について述べる。次に、推定に用いるセンサについて述べ、推定方式に対する要求条件を定義する。そして加速度センサ値から得られる1つのパワースペクトルを用いた推定結果から、課題を明確化する。

3.1 想定アプリケーションと推定対象項目

ユーザプレゼンス情報は、多種存在し、前述した関連研究では、想定するアプリケーションに応じて、推定対象とする状態の定義や、用いるセンサの選択、設置箇所の定義を行っている。本研究においては、携帯電話に搭載されている様々なアプリケーションや機能を、ユーザの移動状態に応じて、自動的に（プッシュ型で）実行させることを目的としている。

たとえば、EZナビウォーク¹⁷⁾のような、ヒューマンナビゲーションサービスにおいては、ユーザが交通機関の乗換えを含めて、正しいルートで目的地に向かっているのかモニタリングを行ったり、ユーザが誤った場合にはルート再探索を行ったり、到着時刻を自動更

表 1 想定アプリケーションと推定対象項目
Table 1 Target application and detection item.

	マンナビゲーション	自動マナーモード	カーナビゲーション	スポーツ支援
停止	○	×	×	○
歩行	○	×	×	○
走行	○	×	×	○
自転車	○	×	×	○
自動車	○	×	○	×
バス	○	○	×	×
電車	○	○	×	×

新したり、といったユーザの移動状態に応じた適切なサポートが可能となる。また、電車やバスのような公共交通機関に乗車すると自動的にマナーモード機能を実行することもできる。ほかにも、自動車に乗車した際には、EZ 助手席ナビ¹⁸⁾ のような、カーナビゲーションサービスを自動的に起動することもユーザの利用機会向上につながる。さらには、au Smart Sports¹⁹⁾ のような、スポーツ支援サービスにおいては、ユーザの走行、歩行、停止、自転車乗車状態を検知することにより、適切なトレーニングプランを適宜提示することも可能となる。

これらの想定アプリケーションに有用な移動状態を表 1 に示す。表の縦軸は本研究における推定対象項目を示し、横軸は前記想定アプリケーション例を示している。また各アプリケーションについて、推定が有用と思われる移動状態を ○ で示している。表から、携帯電話に搭載されている様々なアプリケーションや機能を、ユーザの移動状態に応じて自動的に実行させることを目的とした場合、ユーザが携帯電話を所持して外出している際に、少なくとも停止、歩行、走行、自転車、自動車、バス、電車の 7 状態を自動的に識別することは有用であることが分かる。そこで本方式では、これら 7 状態を本研究の推定対象項目とした。

なお、想定アプリケーションは、これに限定されているわけではなく、他にも多くの適用可能性が存在し、今後有用な移動状態が増えることも十分考えられるが、他の移動状態については、本稿の対象外とする。

たとえば、従来の関連研究で推定対象項目となっていた、「座る」「立ち上がる」「握手」といった詳細な活動種別や、「エスカレータ」「エレベータ」の利用状態、「階段昇降」につ

いても、アプリケーションによっては、有用と思われるが、今後の課題とする。

3.2 本研究で用いるセンサ

本研究では、ユーザが携帯電話の使用手順を変更することなく利用可能な方式を目指すことから、センサは携帯電話上のみを設置することとした。また、センサの搭載コストを考慮し、すでに携帯電話に搭載されているセンサを利用することとした。以下に、携帯電話に搭載されている各センサについて、本方式における利用可否と根拠を示す。

・加速度センサ

au W62CA²⁰⁾ などの携帯電話には、すでに 3 軸加速度センサが搭載されている。加速度センサは、移動状態推定において、従来から一般的に用いられており、振動パターンに特徴のある移動状態の識別に有用なことが分かっている。そこで、本方式も、携帯電話に搭載されている加速度センサを用いる。

・マイク

携帯電話には通話や録音用のマイクが搭載されている。これまでマイクを移動状態推定に用いている事例は少ないが、音声認識の分野では、従来から環境雑音の識別を行っている。マイクは、そのサンプリングレートの高さから、処理負荷も比較的大きいが、電車特有の金属音やバス特有のエンジン音の識別が可能のため、携帯電話に搭載されているマイクを用いる。

・GPS

携帯電話には、GPS レシーバが搭載されており、GPS 衛星情報を通信網から取得することにより、低負荷な測位処理が可能となっている。この測位結果には、数 m ~ 100 m 程度の誤差が発生するため、停止、歩行といった移動量の少ない状態の推定は困難であるが、測位履歴から速度を算出することにより、電車やバスのように、移動量が大きく、特徴的な加減速を行う状態の推定は期待できる。

なお、加速度センサの値を積分することにより速度を求める方法もある。そこで、どちらが有用であるか、以下の実験を行った。この実験は、自動車乗車中 10 分間の速度を、GPS の測位履歴、加速度センサの積分、の両方式で行い、自動車のスピードメータを真値とし、どちらが高精度なのかを比較した。GPS については、携帯電話に搭載されている GPS レシーバを利用し、加速度センサについては、自動車のダッシュボードに固定し、重力加速度成分や鉛直方向の振動を完全に除去できる理想的な状態とした。実験結果を表 2 に示す。

表から分かるとおり、GPS を用いる方が、平均速度の精度が高く、速度の標準偏差も真値に近い。加速度を用いると、平均誤差が大きく、推定速度の標準偏差も真値に比べ大きく

表 2 速度推定精度の比較

Table 2 Comparison of speed detection accuracy.

	真値	GPS	加速度
平均速度	34.0km/h	29.0km/h	43.2km/h
最高速度	65km/h	60.8km/h	84.8km
最低速度	0km/h	1.2km/h	-11.0km/h
速度の標準偏差	18.3	17.2	24.7
平均推定誤差	-	12.5km/h	16.6km/h

なる．さらに，本実験では加速度センサの設置が固定化されており，加速度データから重力加速度成分を取り除き，地表面成分を抽出することが容易であるが，実運用時に，地表面成分を高精度に抽出するには，重力加速度を超える運動加速度が発生しないという前提が必要となる．携帯電話のように運動の自由度が高い環境下では，この前提が成り立つとは限らないため，加速度センサによる速度推定精度はより悪化する．そこで本方式では速度推定精度の観点から GPS を用いる．

・地磁気センサ

地磁気センサと加速度センサを組み合わせることにより，端末の姿勢情報を算出することが可能である．姿勢情報を高精度に取得するには，運動加速度成分を取り除き，重力加速度成分のみとする必要があるが，自由な運動状態時に取り除くことは困難である．本研究では運動状態が推定対象であるため，端末の姿勢変化を用いることは困難である．

・基地局情報

携帯電話が cdma 通信を行っている基地局の緯度経度情報を取得することが可能である．ただし，基地局はセルごとに存在するため位置精度が低いことと，基地局からの電界強度情報を取得することは困難であることから，利用は困難である．

・RF-ID 情報

携帯電話には RF-ID 機能が搭載されており，改札口などに接触したイベントを取得できれば，移動状態推定に有用であるが，現状の携帯電話上で，各 RF-ID イベントが，電車の改札口であったのか，バスの乗車口であったのかなどのイベント種別情報を取得できないことから，利用は困難である．

表 3 予備実験結果

Table 3 Estimation accuracy of previous method.

移動状態	Precision	Recall	F 値
走行	0.98	0.81	0.89
歩行	0.85	0.68	0.76
自転車	0.58	0.45	0.50
停止	0.38	0.89	0.53
自動車	0.38	0.26	0.31
バス	0.32	0.19	0.24
電車	0.29	0.29	0.29

・カメラ

携帯電話にはデジタルカメラが搭載されており，動画の撮影が可能である．撮影された映像から動き補償などの画像処理を行うことにより，端末の動きを検知することは可能だが，本方式の前提は，ユーザが端末を手に所持するケース以外に，ポケットやカバンなどに入れて端末所持するケースも存在する．そのため，カメラの利用は困難である．

3.3 携帯電話を用いたユーザ移動状態推定方式に対する要求条件

前述のとおり，本研究では，ユーザが携帯電話の使用手順を変更することなく利用可能な方式を目指している．そこで，携帯電話を用いたユーザの移動状態推定方式は，以下に列挙する条件下で，高精度に推定できることが望ましい．

条件①：端末所持状態に依存しないこと

携帯電話は，様々な所持状態を有するため，所持状態に依存しない推定方式である必要がある．

条件②：ユーザに依存しないこと

ユーザの負担を考慮すると，ユーザに依存した学習や設定を必要としない方（キャリアブレーションフリー）が望ましい．

条件③：完全な自動推定であること

ユーザの負担を考慮すると，ユーザの手動処理をとまなわない自動推定方式であることが望ましい．

条件④：状態の遷移を短時間で検知できること

想定アプリケーションを考慮すると，移動状態の変化を短時間で検知できることが望ま




図 1 自転車と自動車が類似する例
Fig.1 Example of similarity between bicycle and car.




図 2 自動車と停止が類似する例
Fig.2 Example of similarity between car and stop.

しい。

条件⑤：推定処理負荷が現実的であること

携帯電話の処理性能は限定されているため、推定処理負荷が大きくなってはならない。

3.4 本研究の課題

課題を明確化するために予備実験を行った。この実験は、前述した 7 つの移動状態を対象とした推定精度評価実験であり、加速度センサ値から FFT により、1 つのパワースペクトルを算出し、あらかじめ移動状態ごとに用意した代表パワースペクトルと比較し、最も誤差の小さいパワー代表パワースペクトルが属する移動状態を推定結果とする方式を用いた。つまり、4.1 節で述べる最小誤差推定の手順 1-3 に相当する。実験データは、5.2 節で述べる実験データを用い、FFT の時間窓長は 2 sec、代表パワースペクトルは 4.1 節で述べる方式を用い、移動状態ごとに選出した 30 個、推定間隔は 0.5 sec とした。推定精度を表 3 に示す。なお本稿では、評価尺度として、5.2 節の実験データを母集合とした Precision (適合率), Recall (再現率), F 値を用いている。

表 3 から、振幅の大きい、走行、歩行状態については、F 値が 0.7 以上であり、比較的高精度だが、他状態については推定精度が低いことが分かる。また、静止状態における Recall は 0.89 と高精度だが、Precision が 0.38 と低く、他状態時にも静止状態と誤推定されるケースが多い。これは乗車状態時に、パワースペクトルが時間的に変化し、他状態と類似する時間帯が存在することが要因として考えられる(課題①)。たとえば、図 1 は自転車と自動車が、図 2 は自転車と停止のパワースペクトルが類似している時間帯のパワースペクトルで




図 3 突発的な振動変化
Fig.3 Sudden change in vibration.

ある。このようなケースにおいて、推定精度が低下する。また全体的に、デバイスが身体にぶつかるなど、図 3 のように、突発的な振動の変化による性能低下も確認されている(課題②)。これらの課題は、パワースペクトルの時間的な変化を考慮して、推定を行うことにより、解消が期待できる。

4. 提案方式“釈迦”

本章では、3章で述べた課題を解消することを目的とした方式“釈迦^{*1}”を提案する。釈迦は前記7種類の移動状態を推定する方式であり、携帯電話に搭載されている1つの加速度センサを用いた最小誤差推定方式、HMM (Hidden Markov Model²¹) による最尤推定方式、マイクを用いた最尤推定方式、GPSを用いた最尤推定方式、の4つの方式で構成される。また前記要求条件のとおり、センサの所持状態に依存せず(条件①)、ユーザに依存せず(条件②)、手動操作を必要としない完全自動推定方式(条件③)である。また、1回の推定処理負荷を低減させ、状態変化を短時間で検知するため、比較的短時間のセンサデータを用いた推定処理を定期的に行う(条件④、⑤)。

走行、歩行の2状態については、予備実験の結果から、比較的推定精度が高く、前記課題①の現象は起きておらず、課題②の現象が精度劣化の主な要因となっている。そこで、課題②を解決するために、1つのパワースペクトルで推定を行うのではなく、過去一定時間の推定ログを用いて多数決処理する。

自転車、停止の2状態については、課題②に加え、課題①の現象も起きていることから、加速度データの時間的変化を、状態遷移モデルとして扱うことにより、他状態と類似する時間帯における精度低下の課題の解消を図る。

自動車、バス、電車の3状態については、マイクデータの時間的変化を、状態遷移モデルとして扱うことにより、バスや電車の特徴的な環境音を検知する。さらに、GPSの測位履歴から速度を算出し、その時間的変化状態遷移モデルとして扱うことにより、電車の特徴的な加減速を検知する。

以下に各々の方式について述べる。

4.1 パワースペクトルの最小誤差推定方式

本方式は、加速度値から算出されるパワースペクトルを用い、前記課題②を解決するために、1つのパワースペクトルで最小誤差推定を行うのではなく、過去一定時間の推定ログを用いて多数決処理する。処理フローを以下に示す。

*1 この方式名は、中国の古典小説“西遊記”の中で、孫悟空が釈迦如来と天界を我がものにできるという賭けを行い、地の果てらしき場所に立つ5本の柱に一筆書き、柱に小便を引っかけて、戻って来たが、実は釈迦の手のひらを周回しただけであったというシーンに起因している。携帯電話に搭載されたセンサを用いて、ユーザのプレゼンス情報を推定し、それを共有することによって、自分に関連する世界の縮図を把握することができる、つまり携帯電話を、釈迦の手のひらのような存在にしたいという思いから本方式を“釈迦”と呼んでいる。




図4 振幅の標準偏差

Fig. 4 Standard deviation of amplitude.

手順1: 計測された3軸加速度値 (x, y, z) から、2乗和 $(x^2 + y^2 + z^2)$ を算出する。

手順2: 2乗和の時系列データを単位時間ごとに分割し、FFTを行うことにより、推定用パワースペクトルを算出する。

手順3: 前記パワースペクトルと、あらかじめ移動状態ごとに選出した代表パワースペクトル群 P_f とを、以下の誤差算出式を用いて比較し、最小誤差の P_f が属する移動状態をログ出力する。

$$E_p = \sum_{f=1}^{10} |P_f - p_f|$$

E_p : 1-10 Hzの周波数における測定されたパワースペクトルと代表パワースペクトルとの誤差

f : 周波数 [Hz],

P_f : 代表パワースペクトル

p_f : 推定用のパワースペクトル

ここで、図4に全移動状態における振幅値の標準偏差を示す。図から分かるとおり、移動状態によって振幅値に大きな差異が生じる(標準偏差が比較的大きい)周波数が、1-10 Hzであることから、本方式では、加速度センサによるパワースペクトルにおいて、1-10 Hzを着目周波数帯としている。




図 5 多数決推定
Fig. 5 Selecting most frequent result.

手順 4：手順 3 による推定ログを過去一定時間分取得し、その多数決を行い、最高頻度の移動状態を推定結果とする。たとえば図 5 のように、直近の推定結果が“自転車”であっても、過去一定時間分の推定ログによる多数決結果が“歩行”であった場合は、推定結果を“歩行”とする。

代表パワースペクトルの算出については、移動状態ごとに、その移動状態において測定されたパワースペクトル群の各周波数の平均振幅値で構成される平均パワースペクトルを代表パワースペクトルとする方法と、パワースペクトル群から複数の代表パワースペクトルを選出する方法の 2 種類を用いた。

なお、複数の代表パワースペクトルを求める際には、各代表パワースペクトルは、その移動状態において頻出するパワースペクトルである必要があるため、各パワースペクトルについて、代表パワースペクトル群のうち、 E_p の最小値を求め、その E_p の合計値が最小となるような、代表パワースペクトルの組合せを選出することとした。また、この選出を全探索で行うと計算量が膨大となることから、遺伝的アルゴリズム²²⁾を用いることにより計算量低減を図った。表 4 に、遺伝的アルゴリズムの各パラメータを示す。

なお、本稿では、代表パワースペクトル選出用のパワースペクトル群として、5.2 節で述べる実験データのうち学習用データを用いている。

4.2 加速度センサを用いた HMM 推定方式

本方式は、他状態と類似する時間帯における精度低下の課題の解消を目的としており、加速度値から算出されるパワースペクトルの時間的な変化を状態遷移モデルとして扱う。また、移動状態推定においては、すべての信号系列を学習データとして用意することや、明示的な状態を定義することが困難なため、HMM を用いた最尤推定法による推定を行う。

HMM とは、確率的な状態遷移と確率的な信号出力を持つ非決定性有限オートマトンの 1 つであり、初期状態確率、状態遷移確率、信号出力確率の 3 種類の確率表で構成される確率モデルである。本方式では、パワースペクトルの時間的な変化を状態遷移モデルとして学習させることにより、確率的な推定を行う。処理フローを図 6 (左段：学習処理、右段：推定処理) に示す。

表 4 遺伝的アルゴリズムのパラメータ
Table 4 Genetic algorithm parameters.

パラメータ	設定内容
個体の遺伝子型	代表パワースペクトルの組合せとする。よって、個体を構成する各遺伝子は、代表パワースペクトル選出用スペクトル群から選択された代表パワースペクトル候補となる。
個体数	100 個
交叉方法	2 つの親個体をランダム選択し、両方の遺伝子群から、遺伝子をランダム選択し、子個体を生成する。
評価関数	代表パワースペクトル選出用スペクトル群の各パワースペクトルについて、 E_p が最小となる遺伝子を評価対象個体の遺伝子群から探索する。その最小誤差の合計の逆数を評価値とする。
次世代の個体の構成	エリート戦略：30 個 ルーレット戦略：60 個 突然変異：10 個 (突然変異率 10%)
終了条件	50 世代連続無進化、もしくは 300 世代到達

学習処理は、まず移動状態ごとに HMM 学習用のパワースペクトル群を算出し、4.1 節の最小誤差推定法を用いて、各パワースペクトルを代表パワースペクトルの ID にシンボル化する。生成されたシンボル列 (代表パワースペクトルの ID 列) を用いて、Baum-Welch アルゴリズム²³⁾ による HMM 学習を行い、移動状態ごとにモデルを構築する。ここで扱う

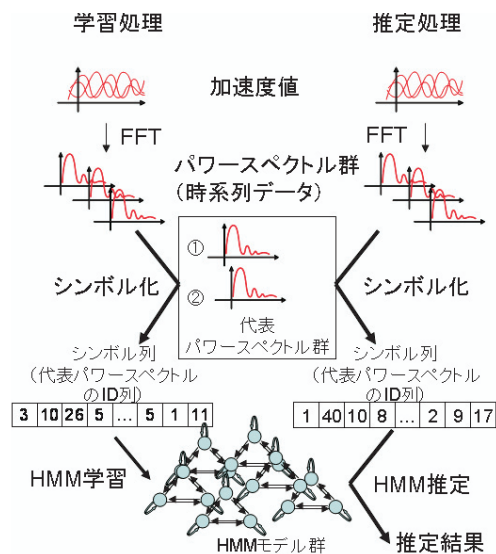


図 6 HMM を用いた最尤推定法の処理フロー

Fig. 6 Processing flow for the maximum likelihood estimation method using HMM.

HMM は離散型とし、状態数は 30 とする。

推定処理は、まず計測された加速度値から、パワースペクトル群を算出し、各パワースペクトルを代表パワースペクトルの ID にシンボル化する。生成されたシンボル列を用いて、各移動状態のモデルの尤度を算出し、最高尤度のモデルを推定結果とする。本方式は、加速度値の時間的な変化を状態遷移モデルとして表現するため、他状態と類似する時間帯における推定性能低下の回避が期待できる。

4.3 マイクを用いた HMM 推定方式

本方式は、マイクを用い、バスや電車の特徴的な環境音を検知する。特徴的な環境音とは、電車移動中のモータ音や金属音、バス移動中のエンジン音などである。図 7 に、電車、バス、自動車で録音したマイクデータから算出したパワースペクトルを比較する。図 7 のとおり、この 3 状態の差異が生じる周波数帯は、100-1,500 Hz である。次に、図 8 に電車を例にあげ、2 つのパワースペクトルを比較する。図 8 のとおり、パワースペクトル間でピークが立つ周波数は同一でないため、1 Hz 単位で比較することは妥当でない。よって本方式では、100-1,500 Hz を着目周波数帯とし、100 Hz ごとに振幅を平均化したパワースペクトルを用いる。




図 7 マイクデータのパワースペクトル例

Fig. 7 Power spectrum example of microphone data.




図 8 パワースペクトルの比較 (電車, 100-150 Hz)

Fig. 8 Comparison of power spectrum (Train, 100-150 Hz).

ルを用いる。ただし、本稿における電車は JR と私鉄を想定しており、モノレール、路面電車など電車と異なる環境音を持つ可能性がある交通機関は想定していない。これらについては、今後の課題とする。

また電車やバス乗車時に、つねに特徴的な環境音が発生しているわけではなく、他状態と類似する時間帯が、加速度同様存在する。よってパワースペクトルの時間的な変化を、状態遷

移モデルとして扱い，HMM を用いた最尤推定法により推定を行う．学習処理，推定処理共に前節と同様の手法であるが，シンボル化の処理が異なる．以下に手順を示す．

- (1) 録音データからパワースペクトルを算出する．
- (2) 100 Hz-1,500 Hz までの周波数帯に着目し，100 Hz ごとに振幅の平均値を算出する．
- (3) (2) によって生成された振幅の平均値で構成される 14 次元ベクトルと，あらかじめ 4.2 節と同様の方式により選出された代表ベクトルとを比較し．各 14 次元ベクトルを代表ベクトルの ID にシンボル化する．
- (4) (3) を一定時間置きに繰り返し実施することにより，生成されたシンボル列を用いて，HMM 学習処理や HMM 推定処理を行う．

4.4 GPS を用いた HMM 推定方式

本方式は，GPS 測位履歴から算出した時速を用いて，電車の特徴的な加減速を検知する．図 9 に示すように，バスと電車では時速分布が大きく異なることから，高精度な推定が期待できる．ただし，本稿における電車は，JR と私鉄を想定しており，地下鉄のように GPS 測位が不可能な環境は想定していない．これについては，今後の課題とする．

学習処理，推定処理ともに前節と同様の手法であるが，シンボル化の処理が異なる．まず GPS 測位を定期的の実施し，各 2 点の測位結果から平均時速を算出する．そして，各平均




図 9 バスと電車の平均時速の分布
Fig. 9 Average speed comparison of bus and train.

時速に対して 10 km/h の単位で量子化を行い，シンボル化する．その結果，生成されたシンボル列を用いて，HMM 学習処理や HMM 推定処理を行う．

5. 性能評価実験

提案方式の有効性を検証するために，評価システムを実装した．

5.1 評価システムの実装

まず評価実験に使用した端末の写真を図 10 に，スペックを表 5 に示す．

マイクと GPS は携帯電話 au W44T に搭載されているものを用いており，加速度センサも携帯電話 au W62CA に搭載しているセンサと同等の仕様である．また CPU のクロック速度も携帯電話と同レベルであるため，本実験のセンサ構成は，現実的であるといえる．ま



図 10 端末画像
Fig.10 Experiment terminal.

表 5 センサモジュール仕様
Table 5 Specification of sensor module.

項目	仕様
寸法, 重量	10cm x 5cm x 2cm, 85g
マザーボード	gumstix basix 400xm-bt[24] (CPU:Xscale 400MHz Memory:64MB)
加速度センサ	AK8971N (3 axis,128Hz)[25]
マイク	サンプリングレート : 24KHz 音声フォーマット : PCM(16bit)
GPS	au W44T[26]に搭載

た、推定ソフトウェアは、C 言語で実装し、上記端末上 (OS: Linux) で動作させた。

5.2 実験データ

本実験は、被験者 5 名、移動状態 7 状態 (走行, 歩行, 自転車, 電車, バス, 自動車, 停止) とし、端末の所持状態は、手に所持, 端末操作しながら, ズボンのポケット, 胸ポケット, カバンの中, の 5 種類として実施した (手に所持しながら自転車乗車などの実験困難な 3 つのケースは行っていない)。ただし、本実験データには、異なる移動状態への遷移途中のデータは含んでいない。データの構成を表 6 に示す。

これらのバリエーションに則って、表 3 に示したデータ測定環境を用いて、合計約 40 時間分のセンサデータを計測し、半分を学習用、残り半分を推定用データとして使い、性能評価を行った。

5.3 最小誤差推定法の性能測定結果

まず、適した FFT の時間窓長を評価するため、表 7 に FFT の時間窓長が 1 sec (128 サンプル), 表 8 に 2 sec (256 サンプル), 表 9 に 4 sec (512 サンプル) の推定精度を示す。ただし、FFT の実施間隔は、FFT の時間窓長とし、代表パワースペクトルは、移動状態ごとに表 2 の遺伝的アルゴリズムで探索した 30 個のパワースペクトルとし、図 5 で示した多数決推定を行うための過去にさかのぼる時間幅は 30 sec (例: FFT の時間窓長が 2 sec のときは 15 個のパワースペクトルによる多数決) とした。なお、実験データは、5.2 節で述べた全推定用データを用い、推定処理を行った。

表 7, 表 8, 表 9 から、走行, 歩行については、2 sec の場合が最も精度が高く、表 1 と比較しても、高精度であるといえる。自転車, 停止, 自動車, バス, 電車については、4 sec の場合が最も精度が高いが、十分高精度であるとはいえない。

次に、適した代表パワースペクトルの選出法を評価するため、表 10 に、移動状態ごとに、その移動状態において測定されたパワースペクトル群の各周波数の平均振幅値で構成される平均パワースペクトルを代表パワースペクトルとした場合の推定精度を示す。ただし、FFT の時間窓長は 2 sec とし、FFT 実施間隔は 0.5 sec、多数決推定を行うための過去にさかのぼる時間幅は 30 sec とする。

表 8 (遺伝的アルゴリズムを用いた複数の代表パワースペクトルを選出) と表 10 (平均パワースペクトルを代表パワースペクトルとする) から分かるとおり、代表パワースペクトルは、複数の代表パワースペクトルとした方が高い推定精度が得られる。

次に、適した FFT の実施間隔を評価するために、表 11 に FFT 実施間隔が 0.5 sec の結果、表 12 に FFT 実施間隔が 1 sec の結果を示す (FFT 実施間隔が 2 sec の結果は表 8 を

表 6 実験データの構成

Table 6 Experimental data component.

移動状態	所持状態	状況
走行	手に所持, 端末操作しながら, ズボンのポケット, 胸ポケット, カバンの中	屋外を走行
歩行	手に所持, 端末操作しながら, ズボンのポケット, 胸ポケット, カバンの中	屋外を歩行
自転車	手に所持, ズボンのポケット, 胸ポケット, カバンの中 かごの中	市街地の路面を 走行. 各被験者 が別の自転車を 使用.
停止	手に所持, 端末操作しながら, ズボンのポケット, 胸ポケット, カバンの中	自然に立ち止ま っている状態 (少々揺れは あり)
自動車	ズボンのポケット, 胸ポケット, カバンの中 助手席の上	市街地を走行す る普通自動車に おいて、窓の開 閉, ラジオの ON/OFF の状態.
バス	手に所持, 端末操作しながら, ズボンのポケット, 胸ポケット, カバンの中	市街地を走行す る路線バスにお いて、座席に座 っている状態. 混雑時と閑散時 を含む.
電車	手に所持, 端末操作しながら, ズボンのポケット, 胸ポケット, カバンの中	JR及び私鉄の一 部路線におい て、座席に座っ ている状態, 立 っている状態. 混雑時と閑散時 を含む.

表 7 最小誤差推定法の推定精度 (1 sec)

Table 7 Estimation accuracy of least-errors method (1 sec).

移動状態	Precision	Recall	F 値
走行	1.000	0.992	0.996
歩行	0.992	0.944	0.967
自転車	0.960	0.566	0.712
停止	0.328	0.995	0.493
自動車	0.595	0.258	0.360
バス	0.508	0.157	0.240
電車	0.550	0.303	0.391

表 8 最小誤差推定法の推定精度 (2 sec)

Table 8 Estimation accuracy of least-errors method (2 sec).

移動状態	Precision	Recall	F 値
走行	1.000	0.995	0.997
歩行	0.997	0.945	0.970
自転車	0.962	0.720	0.823
停止	0.386	0.994	0.556
自動車	0.565	0.258	0.355
バス	0.484	0.113	0.183
電車	0.364	0.325	0.344

表 9 最小誤差推定法の推定精度 (4 sec)

Table 9 Estimation accuracy of least-errors method (4 sec).

移動状態	Precision	Recall	F 値
走行	0.999	0.955	0.977
歩行	0.955	0.805	0.873
自転車	0.878	0.806	0.841
停止	0.447	0.954	0.609
自動車	0.619	0.362	0.457
バス	0.553	0.343	0.423
電車	0.616	0.529	0.569

表 10 最小誤差推定法の推定精度 (平均スペクトル)

Table 10 Estimation accuracy of least-errors method (Average of power spectrum).

移動状態	Precision	Recall	F 値
走行	1.000	0.499	0.666
歩行	0.714	0.730	0.722
自転車	0.576	0.366	0.447
停止	0.255	0.995	0.406
自動車	0.209	0.105	0.140
バス	0.305	0.122	0.175
電車	0.000	0.000	0.000

表 11 最小誤差推定法の推定精度 (FFT 実施間隔 : 0.5 sec)

Table 11 Estimation accuracy of least-errors method (Window shift length: 0.5 sec).

移動状態	Precision	Recall	F 値
走行	1.000	0.999	0.999
歩行	0.999	0.965	0.981
自転車	0.995	0.786	0.879
停止	0.387	0.999	0.558
自動車	0.579	0.277	0.375
バス	0.656	0.096	0.168
電車	0.483	0.445	0.463

表 12 最小誤差推定法の推定精度 (FFT 実施間隔 : 1 sec)

Table 12 Estimation accuracy of least-errors method (Window shift length: 1 sec).

移動状態	Precision	Recall	F 値
走行	1.000	0.997	0.999
歩行	0.997	0.965	0.981
自転車	0.989	0.768	0.865
停止	0.375	0.999	0.545
自動車	0.634	0.280	0.388
バス	0.571	0.104	0.175
電車	0.439	0.395	0.416

表 13 最小誤差推定法の推定精度 (時間幅 3 秒)

Table 13 Estimation accuracy of least-errors method (Time length: 3 sec).

移動状態	Precision	Recall	F 値
走行	0.999	0.960	0.979
歩行	0.981	0.915	0.947
自転車	0.864	0.648	0.741
停止	0.437	0.962	0.601
自動車	0.488	0.303	0.373
バス	0.458	0.151	0.227
電車	0.400	0.351	0.374

表 14 最小誤差推定法の推定精度 (時間幅 180 秒)

Table 14 Estimation accuracy of least-errors method (Time length: 180 sec).

移動状態	Precision	Recall	F 値
走行	1.000	1.000	1.000
歩行	1.000	0.971	0.985
自転車	1.000	0.778	0.875
停止	0.336	1.000	0.503
自動車	0.582	0.252	0.352
バス	0.515	0.031	0.059
電車	0.412	0.294	0.343

参照)。ただし、FFT の時間窓長は 2 sec、移動状態ごとの代表パワースペクトルは、遺伝的アルゴリズムで選出した 30 個とし、多数決処理を行う時間幅は 30 秒とする。表 8、表 11、表 12 を比較すると分かる通り、FFT 実施間隔が 0.5 sec の場合に、最も高い推定精度が得られる。

次に、多数決推定について、適した時間幅を評価するため、表 13 に 3 秒間 (6 個のパワースペクトル)、表 14 に 180 秒間 (360 個のパワースペクトル) の推定精度を示す (30 秒間の時間幅については表 11 を参照)。ただし、FFT の時間窓長は 2 sec、FFT の実施間隔は 0.5 sec、移動状態ごとの代表パワースペクトルは、遺伝的アルゴリズムで選出した 30 個とした。表 11、表 13、表 14 を比較すると分かる通り、時間幅は 180 秒とするのが最も高

表 15 HMM 推定法の推定精度 (時間幅 30 秒)

Table 15 Estimation accuracy of HMM (Time length: 30 sec).

移動状態	Precision	Recall	F 値
自転車	0.738	0.939	0.827
停止	0.685	0.826	0.749
自動車	0.632	0.388	0.481
バス	0.429	0.698	0.531
電車	0.592	0.455	0.515

精度となるが、時間幅 30 秒でも、十分高精度である。時間幅が長くなれば、移動状態遷移に対する検知が遅延することや、短時間の走行や歩行といった移動状態の検知が困難になることを考慮すれば、時間幅 30 秒が妥当であると考えられる。

これらの結果から、FFT の時間窓長は 2 sec、FFT の実施間隔は 0.5 sec、代表パワースペクトルは遺伝的アルゴリズムで探索した 30 個、多数決推定のための時間幅は 30 sec のパラメータを用いた最小誤差推定法 (表 9) が最適であり、本方式により、走行、歩行状態について、F 値が 0.98 以上であり、十分高精度な推定が可能であるといえる。これは、多数決推定方式により、走行、歩行時において、突発的な振動変化による性能低下を回避できていることが要因と考えられる。一方、それら以外の状態の推定精度は低く、本方式で高精度な推定が可能な移動状態は走行、歩行状態のみであるといえる (停止状態の Recall は 0.999 であるが、Precision が低いため高精度とはいえない)。

5.4 加速度を用いた HMM 推定法の性能測定結果

次に、最小誤差推定法で十分な精度が得られなかった 5 状態を対象に、FFT の時間幅を 2 sec、FFT 実施間隔を 0.5 sec、代表パワースペクトルを 30 個とし、シンボル長を 30 秒 (60 個のパワースペクトル)、60 秒 (120 個のパワースペクトル)、180 秒 (360 個のパワースペクトル) とした HMM 推定法の推定精度を表 15、表 16、表 17 に示す。

表から、シンボル長は 180 秒の場合が、最も精度が高いことが分かる。また表 11 と比較すると、本方式による性能改善が確認できる。これは、HMM を用い、パワースペクトルの時間的変化を考慮した推定を行うことにより、パワースペクトルが類似している時間帯による性能低下を回避できていることが要因と考えられる。ただし、自転車、停止以外の状態の推定精度には改善の余地が残っており、本方式で高精度な推定が可能な移動状態は自転車、停止状態のみであるといえる。

205 釈迦：携帯電話を用いたユーザ移動状態推定方式

表 16 HMM 推定法の推定精度 (時間幅 60 秒)

Table 16 Estimation accuracy of HMM (Time length: 60 sec).

移動状態	Precision	Recall	F 値
自転車	0.772	0.951	0.852
停止	0.771	0.838	0.804
自動車	0.668	0.431	0.524
バス	0.459	0.761	0.573
電車	0.676	0.549	0.606

表 17 HMM 推定法の推定精度 (時間幅 180 秒)

Table 17 Estimation accuracy of HMM (Time length: 180 sec).

移動状態	Precision	Recall	F 値
自転車	0.810	0.988	0.890
停止	0.797	0.831	0.814
自動車	0.689	0.406	0.511
バス	0.442	0.770	0.562
電車	0.665	0.637	0.650

表 18 マイクを用いた HMM 推定法の推定精度

Table 18 Estimation accuracy of HMM using microphone.

移動状態	Precision	Recall	F 値
自動車	0.911	1.000	0.954
バス	0.582	0.742	0.652
電車	0.896	0.645	0.750

5.5 マイクを用いた HMM 推定法の性能測定結果

次に、加速度を用いた HMM 推定法で十分な精度が得られなかった自動車、バス、電車の 3 状態を対象とし、マイクデータを用いた HMM 推定法の性能測定を行った結果を表 18 に示す。ただし、FFT の時間窓は 300 msec、FFT 実施間隔は 9 sec、シンボル長を 180 sec (20 個のワースペクトル) としている。これらの値は、いくつかの値について実験を行った結果から、最適な値を導出している。表 17 と比較すると、本方式により、推定精度に改




図 11 電車混雑時とバスのワースペクトル比較

Fig. 11 Comparison of power spectrum between crowded train and bus.

表 19 GPS を用いた HMM 推定法の推定精度

Table 19 Estimation accuracy of HMM using GPS.

移動状態	Precision	Recall	F 値
バス	0.972	0.984	0.972
電車	0.961	0.932	0.961

善が見られる。これは、マイクのみで 7 種類の移動状態を推定することは困難であるが、加速度を用いた推定により、環境雑音に特徴のある自動車、電車、バスの 3 状態に絞り込まれていることによって、高精度な推定が可能となっていると考えられる。その一方、電車状態とバス状態は、誤推定されるケースが多い。これは図 11 のとおり、電車内が混雑している際に、録音される環境雑音の音量が全体的に小さくなり、閑散時のバス状態に類似するためと考えられる。よって、本方式で高精度な推定が可能な移動状態は自動車状態のみであるといえる。

5.6 GPS を用いた HMM 推定法の性能測定結果

次に、マイクを用いた HMM 推定法で十分な精度が得られなかったバス、電車状態を対象に、GPS の測位結果を用いた HMM 推定法の推定精度を行った結果を、表 19 に示す。ただし、GPS 測位間隔は 20 sec、シンボル長は 180 sec (9 個の速度履歴) としている。これらの値は、いくつかの値について実験を行った結果から、最適な値を導出している。表 18

と比較すると、本方式により、推定性能の改善が見られることが分かる。これは、マイク同様、GPS のみでは、7 種類の移動状態の推定は困難であるが、加速度、マイクを事前に用いることによって、GPS 測位結果に特徴のある電車とバスの 2 状態まで、推定候補が絞り込まれていることが要因と考えられる。

6. 考 察

前章の性能測定結果から、最小誤差推定法を用いれば走行、歩行状態が、加速度を用いた HMM 推定法を用いれば自転車、停止状態が、マイクを用いた HMM 推定法を用いれば、自動車状態が、GPS を用いた HMM 推定法を用いればバス、電車状態が高精度で推定できることが分かった。次に、表 20 に各方式の平均処理時間を示す。表から、携帯電話上でこれらすべての処理をつねに動作させることは、処理負荷の観点から望ましくないことが分かる。そこで、これらの処理を組み合わせ、移動状態を絞り込みながら推定を行うことによって、すべての処理を常時動作させるよりも、処理負荷を低減させることが可能となる。

処理フローの概要を図 12 に示す。まず加速度値から得られるパワースペクトルを用い、

表 20 各方式の平均処理時間
Table 20 Average processing time of each methods.

方式	平均処理時間
加速度の FFT	1msec(0.5sec 間隔)
最小誤差推定法	10msec #ただし加速度の計測処理時間は含まない
加速度を用いた HMM 推定法	3240msec #ただし加速度の計測処理時間は含まない
マイクの FFT	30msec(9sec 間隔)
マイクを用いた HMM 推定法	234msec #ただしマイクの録音処理時間は含まない
GPS を用いた HMM 推定法	70msec #ただし GPS 測位の処理時間は含まない

最小誤差推定方式によって推定を行う。その結果が走行、歩行状態であれば、それを推定結果として出力し、終了するが、他状態だった場合には、HMM を用いた最尤推定法によって推定を行う。その結果が自転車、停止状態であれば、それを推定結果として出力し、終了するが、他状態だった場合には、マイクの録音データから得られるパワースペクトルを用い、HMM を用いた最尤推定法によって推定を行う。その結果が自動車状態であれば、それを出力し終了するが、他状態であれば、GPS の測位結果から得られる平均時速を用い、HMM を用いた最尤推定法によって、電車、バス状態の推定を行う。このように、各移動状態の推定に適した複数の推定方式を用い、移動状態を段階的に絞り込むことによって、各移動状態を、より低処理負荷で、高精度な推定を行うことが可能となる。

また、表 21 に本方式の推定精度を示す。表より、全移動状態を、F 値が 0.8 以上の精度で推定できていることが分かる。ただし本方式では、走行、歩行状態の推定に 1 回あたり 30 秒間、他状態の推定に 1 回あたり 180 秒間のセンサデータを用いることから、状態遷移

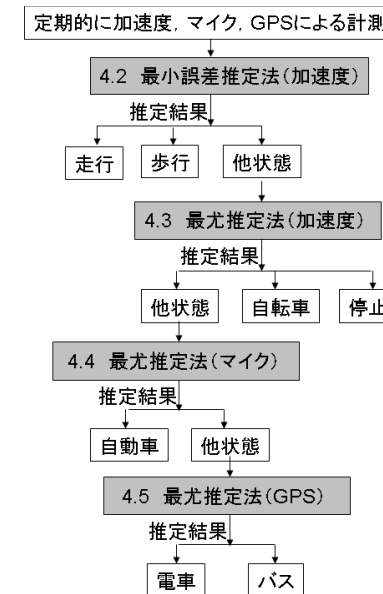


図 12 提案方式の推定処理フロー
Fig. 12 Processing flow of proposed method.

表 21 提案方式の推定精度

Table 21 Estimation accuracy of proposed method.

移動状態	Precision	Recall	F 値
走行	1.000	0.999	0.999
歩行	0.999	0.965	0.981
自転車	0.781	0.988	0.873
停止	0.797	0.831	0.814
自動車	0.844	0.936	0.888
バス	0.972	0.927	0.949
電車	0.961	0.878	0.918

に対しても 15–90 秒程度の遅延が生じることが推測される。遅延時間は、短い方が望ましいことは明らかであり、この点の改善は今後の課題となる。また許容条件はアプリケーションに依存するが、表 1 で述べたアプリケーションを想定した場合、この程度の遅延は許容しても、推定精度を重視すべきと考える。

7. 結論と今後の予定

本稿では、携帯電話に搭載可能な加速度センサ、マイク、GPS を複合的に用い、ユーザの移動状態を自動的に推定する方式を提案した。本方式により、センサデータの時間的変化を考慮したうえで、各移動状態の推定に適した方式を段階的に適用し、推定候補を絞り込むことによって、推定精度が向上することが分かった。性能評価実験から、7 種類の移動状態を、F 値が 0.8 以上の精度で推定できることが分かった。

今後は、大規模な実証実験の実施や、消費電力に関する詳細な検証、遅延時間に関する改良方式について、検討を行う予定である。また、携帯電話にすでに搭載されているセンサを用いた現実的な構成を保ちつつ、推定対象項目の汎用化を図り、携帯電話を用いた人間の行動解析方式の検討を進める予定である。

謝辞 日頃ご指導いただく KDDI 研究所秋葉所長に深謝いたします。本研究の一部は、独立行政法人情報通信研究機構からの委託研究「ユビキタス ITS」に基づき行われたものである。

参考文献

- 1) SIP. <http://tools.ietf.org/html/rfc3261>
- 2) Kern, N.: A Model for Human Interruptability: Experimental Evaluation and Automatic Estimation from Wearable Sensors, *ISWC'04*, pp.158–165 (2004).
- 3) Intille, S.S.: Acquiring In Situ Training Data for Context-Aware Ubiquitous Computing Applications, *CHI 2004*, pp.1–9, ACM Press (2004).
- 4) Bao, L. and Intille, S.S.: Activity recognition from user-annotated acceleration data, *Proc. PERSASIVE 2004*, Vol.LNCS 3001, Ferscha, A. and Mattern, F. (Eds.), pp.1–17, Springer-Verlag, Berlin Heidelberg (2004).
- 5) Siewiorek, D.: SenSay: A Context-Aware Mobile Phone, *ISWC'03* (2003).
- 6) Lukowicz, P., Junker, H. and Troster, M.: WearNET: A distributed multi-sensor system for context aware wearables, *Proc. UbiComp 2002*, pp.361–370 (2002).
- 7) Lee, S.-W. and Mase, K.: Activity and Location Recognition Using Wearable Sensors, *IEEE Pervasive Computing*, July-September, pp.10–18 (Sep. 2002).
- 8) Iso, T. and Yamazaki, K.: Gait analyzer based on a cell phone with a single three-axis accelerometer, *ACM the 8th Conference on Human-Computer Interaction with Mobile Devices and Services (MobileHCI2006)*, pp.141–144 (2006).
- 9) Kawahara, Y.: A Context-Aware Content Delivery Service Using Off-the-shelf Sensors, *Mobisys2004* (2004).
- 10) 前司敏昭, 堀口良太, 赤羽弘和, 小宮粹史: GPS 携帯端末による交通モード自動判定法の開発, 第 4 回 ITS シンポジウム 2005 論文集 (2005.12).
- 11) Kouroggi, M. and Kuratal, T.: Personal positioning based on walking locomotion analysis with self-contained sensors and a wearable camera, *Proc. ISMAR'03*, pp.103–112 (2003).
- 12) シリコンセンシングシステムズジャパン株式会社: 歩行者用慣性ナビユニットポイントマン DRM. <http://www.spp.co.jp/sss/j/pointman.htm/>
- 13) 田中宏平, 寺田 努, 山口喜久, 中川隆志, 西尾章治郎: 目的予測型カーナビゲーションシステムのための運転状況を考慮した目的地予測手法, 電子情報通信学会データ工学ワークショップ (DEWS 2007) 論文集 (2007).
- 14) Thrun, S., Fox, D. and Burgard, W.: A probabilistic approach to concurrent mapping and localization for mobile robots, *Autonomous Robots*, Vol.5, pp.253–271 (1998).
- 15) Aoki, H., Schiele, B. and Pentland, A.: Realtime Personal Positioning System for Wearable Computers, *International Symposium on Wearable Computers (ISWC'99)* (1999).
- 16) 興梠正克, 蔵田武志: 慣性センサ群とウェアラブルカメラを用いた歩行動作解析に基づくパーソナルポジショニング手法, 信学技報, PRMU2003-260, pp.25–30 (2004).

- 17) http://www.au.kddi.com/ez_naviwalk/index.html
- 18) <http://www.au.kddi.com/josyuseki/index.html>
- 19) http://www.au.kddi.com/sports/service/run_walk/index.html
- 20) http://www.au.kddi.com/seihin/ichiran/cdma1x_win/w62ca/
- 21) Rabiner, L.R.: A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition, *Proc. IEEE*, pp.257–286 (1989).
- 22) Holland, J.H.: *Adaptation in Natural and Artificial Systems* (1975).
- 23) Baum, L.B.: Statistical inference for probabilistic functions of finite state Markov chains, *The Annals of Mathematical Statistics*, Vol.37, pp.1554–1563 (1966).
- 24) gumstix. <http://gumstix.com/>
- 25) AK8971N. <http://www.asahi-kasei.co.jp>
- 26) au W44T. http://www.toshiba.co.jp/product/etsg/cmt/au/w44t/w44t_menu_nf.htm
- 27) Naya, F., Ohmura, R., Takayanagi, F., Noma, H. and Kogure, K.: Workers' Routine Activity Recognition using Body Movement and Location Information, *Proc. 10th IEEE International Symposium on Wearable Computers (ISWC'06)*, pp.105–108 (Oct. 2006).


(平成 20 年 3 月 27 日受付)

(平成 20 年 10 月 7 日採録)



小林 亜令 (正会員)

1973 年生。1996 年北海道大学工学部電子工学科卒業。1998 年北海道大学大学院工学研究科修士課程修了。同年 KDDI 株式会社 (当時 KDD) 入社。現在、(株) KDDI 研究所特別研究員。XML, SVG, 通信放送融合技術, センサデータ解析技術, ITS 等の研究開発に従事。情報処理学会学会誌 SWG 幹事。



岩本 健嗣 (正会員)

1975 年生。2000 年慶應義塾大学大学院政策・メディア研究科修士課程修了。2005 年慶應義塾より博士 (政策メディア)。現在、(株) KDDI 研究所 Web データコンピューティンググループ研究員。ユビキタスコンピューティング, 屋内位置情報, センサ応用アプリケーション等の研究に従事。電子情報通信学会会員。



西山 智 (正会員)

1961 年生。1984 年東京大学工学部電気工学科卒業。同年国際電信電話 (現 KDDI) (株) 入社。1991 年米国テキサス大学オースチン校計算機科学科修士課程修了。現在、(株) KDDI 研究所 Web データコンピューティンググループリーダー。この間、データベース, ネットワーク管理, ITS, エージェント通信, ユビキタス通信システムの研究に従事。2005 年度本学会山下記念賞受賞。電子情報通信学会会員。