

加速度センサのみを用いた移動手段判定アルゴリズムの評価

古川 侑紀^{1,a)} 西山 勇毅^{3,b)} 大越 匡³ 中澤 仁² 高汐 一紀² 徳田 英幸³

概要：近年のスマートフォンの普及により、様々なセンサを利用できるようになった。それに伴い、日常的な行動を記録する研究が盛んになっている。移動手段の判定もその一部である。既存の研究では加速度センサやマイク、GPS など複数のセンサを用いて移動手段を判定しているため、電池の消耗が激しくスマートフォンのみを用いて判定することは実用的ではない。本研究では加速度センサを用いて移動手段の判定を行うシステムの提案を行い、本システムに様々な機械学習の手法を適用することによって分類精度の評価を行う。また、本システムの省電力性を評価する。

キーワード：行動認識, 移動手段, 加速度センサ, 機械学習

Abstract: Nowadays, various kinds of sensors are available due to expansion of the smartphones. Along with this, the research that records the action on a daily basis has become very popular. Distinction of transport is also a part of the studies. The major result from recent studies has been detected those transport by using the sensors such as GPS or a microphone or an acceleration sensor. However, since this is one of the biggest cause to encourage the consumption of the batteries, it is not practical to detect only with a smartphone. I suggested in this paper the system to detect transport adopting acceleration sensor and evaluated the detection accuracy by applying various kinds of method of machine learning. Moreover, I evaluated power saving of this system.

Keywords: activity recognition, transport, accelerometer, machine learning

1. はじめに

近年、ウェアラブルデバイス [1], [2] やスマートフォンの普及により、様々なセンサを利用できるようになった。それに伴い、日常的な行動を記録する研究が盛んになっている。日常行動記録の1つとして、移動手段の判定が研究されている。移動手段を判定することで、ユーザの各コンテキストに合わせたアプリケーション提供が可能になる。例えば、電車の中で時刻表が表示され次の駅までの時間が表示されるアプリケーションなどが考えられる。

実際の日常行動を記録するシステム例として「Moves」[3] がある。「Moves」は1日の移動を Walk, Run, Cycling, Transport の4種類に分けて記録をし、歩数を測ったり、走った距離を記録したり出来るアプリケーションである。

しかし、交通機関という大きな括りでしか分類することが出来ない。各コンテキストに合わせたアプリケーション提供する場合を考えた場合、交通機関を電車やバスの様に細かく分類する必要がある。

本研究では、移動手段を判定するシステム「BORO」を提案する。BOROは加速度センサのみを用いて歩行、走行、電車、バス、自動車、自転車、その他の7種類の移動手段を判定するシステムである。移動手段の分類には機械学習を用いるため、BOROの機械学習アルゴリズムごとの分類精度の比較と、加速度センサのみを用いたことによる本システムの省電力性の評価する。

本稿は、以下のように構成されている。第2章で既存の移動手段判定アルゴリズムの問題点について説明する。第3章で関連研究の問題点を改善するための本システムの目的と設計について説明する。第4章で本システムの予備実験を行う。第5章で本システムの分類精度の評価と、省電力性の評価を行い、その結果と考察を述べる。第6章で今後の課題について述べる。第7章で本稿をまとめる。

提案するBOROは、Random Forestを用いることで98.71%で移動手段を判定できた。加速度センサのみで実用的な分類精度まで高められることが明らかになった。

¹ 慶應義塾大学 総合政策学部
Faculty of Policy Management, Keio University
² 慶應義塾大学 環境情報学部
Faculty of Environment and Information Studies, Keio University
³ 慶應義塾大学大学院 政策・メディア研究科
Graduate School of Media and Governance, Keio University
^{a)} boro@ht.sfc.keio.ac.jp
^{b)} tetujin@ht.sfc.keio.ac.jp

2. 移動手段判定アルゴリズム

人の移動手段の判定は大きく2つに分類される1つ目は、人の動作そのものを判定するものである。2つ目は、人の移動を判定するものである。前者の例は階段の昇り降り、スキップ、ジャンプなどの判定を行う。後者の例は電車、自動車、自転車などの判定を行う。

人の動作の判定の研究例としてはKwapisz, Weiss, Mooreらの研究[4]があげられる。この研究では、脚につけた加速度センサを用いて歩行、ジョギング、階段上り、階段下り、座る、立っている状態の6種類の行動を分類している。

人の移動の判定の研究例としては小林, 岩本, 西山らの研究[5]があげられる。この研究では、加速度センサ、マイク、GPSを用いて歩行、走行、自転車、停止、自動車、バス、電車の7種類の移動手段を対象とし、ユーザーの移動状態を高精度で分類することが可能である。しかしGPSを用いた判定では、GPS電波の届かない地下鉄などでは判定できない問題や、複数センサの併用による消費電力の増大が問題と考えられる。スマートフォンのみを用いて日々の移動手段を記録するためには、これらの課題克服が必要とされている。また、山崎, 五味田らの研究[6]では、鞆の中に設置した加速度センサを用いて移動手段を分類している。しかし、センサの装着位置をカバンの中という限定された場所で取得しているためにユーザーの日常的なシステムの利用は困難である。本研究では、2つ目の人の移動の判定を研究対象とした。

3. BORO

本章では、ユーザーの移動手段判定を行うBOROについて目的、特徴、設計、実装環境を述べる。

3.1 BOROの目的と特徴

本研究の目的は、既存研究やシステムが課題とする、複数センサ併用による消費電力増大の問題、スマートフォンの装着・携帯場所に特定の要件がある問題を解決し、長時間、装着・携帯場所にとらわれずに使用できる移動手段判定アルゴリズムの実現である。本研究では、そのための移動手段判定システムBOROを提案する。

本システムの特徴は、GPS、マイク、角速度センサなど複数のセンサを用いず加速度センサを用いることで実現する省電力性、スマートフォンの装着・携帯場所にとらわれずに判定できる利用の簡便性、およびシステムがスマートフォン上で動作し逐次に判定できるリアルタイム性である。これにより本システムは、ユーザーが任意の場所に装着・携帯するスマートフォン上で、その省電力性により長時間にわたってリアルタイムにユーザーの移動手段を判定することができる。したがってユーザーは、本システムの機能を利用したスマートフォン上のアプリケーションを継続的に利用




図1 システム構成図

できる。

BOROは、ユーザーのスマートフォン上で動作し、加速度センサのデータを入力し、一定時間ごとに現在の移動手段を判定し、出力する。BOROが判定する移動手段は、小林, 岩本, 西山らの先行研究を参考にし、「歩行、走行、電車、バス、自動車、自転車、その他(移動していない状態を含む)」の7種類とする。

3.2 BOROの設計

BOROのシステム構成図を図1に示す。本システムは加速度データ取得モジュール、移動手段判定モジュール、移動手段補正モジュールの3つのモジュールから構成される。加速度データ取得モジュールでは、加速度センサから加速度データの取得を行う。移動手段判定モジュールでは、機械学習を用いて移動手段の判定を行う。移動手段補正モジュールでは、移動手段判定モジュールで判定された移動手段を前後の判定された移動手段を比較することによって補正を行う。

3.2.1 移動手段判定モジュール

移動手段判定モジュールでは、教師あり機械学習を用いて移動手段の判定を行う。具体的には、加速度センサから3軸加速度データを取得し、特徴量を抽出し、機械学習によって移動手段の判定を行う。

図2に移動手段判定モジュールにおける2つの動作フェーズ、(1)学習フェーズ、(2)分類フェーズを示す。学習フェーズにおいては、機械学習に適用する教師データとなる加速度データを取得し、特徴量を抽出した後、その教師データをもとに分類器のモデルを作成する。一方、分類フェーズでは、学習フェーズで作成したモデルを用いて、実際に移動手段をスマートフォン上で逐次判定する。

特徴量の抽出方法としては、表1にあげる、加速度センサを用いた行動認識研究において広く使われる特徴量[7]を用いる。それらは大きく時系列分割及び周波数分割の2種類から構成される。時系列分割としては、加速度データの平均、二乗平均平方根、分散、相関係数、共分散を用い

表 1 特徴量の抽出手法

時系列分割	平均 $(\bar{x}, \bar{y}, \bar{z})$
	二乗平均平方根 $(\sqrt{\bar{x}^2 + \bar{y}^2 + \bar{z}^2})$
周波数分割	分散 $\{var(x), var(y), var(z)\}$
	相関係数 $\{corr(x, y), corr(y, z), corr(x, z)\}$
	共分散 $\{cov(x, y), cov(y, z), cov(x, z)\}$
	Energy $(\sum_{j=1}^N \frac{m_j^2}{N})$, m_j is FFT component
	Entropy $(-\sum_{j=1}^n (p_j * \log(p_j)))$, p_j is FFT histogram




図 2 移動手段判定モジュール



図 3 移動手段補正モジュール

た。周波数分割としては、フーリエ変換を用いた。

3.2.2 移動手段補正モジュール

移動手段補正モジュールは、移動手段判定モジュールで判定された移動手段が本当に信頼できるかを確認し補正する。例えば、3秒間の間に「バス→電車→バス」と判定された場合、ごく短い時間でバスから電車に変わることは考えにくい。そのためこの判定内容を「バス→バス→バス」と補正し、最終的な移動手段として決定する。移動手段補正モジュールでの補正例を図3に示す。

3.3 実装環境

本システムの実装において、OSはAndroid4.0を搭載したスマートフォンであるHTC Sensationを使用した。実装言語はJavaを使用する。加速度データの取得には、AndroidのSensorManagerを使用する。データ取得時のサンプリングレートのパラメータの設定としてはSENSOR_DELAY_FASTESTを使用した。これは可能な限り高速なサンプリングレートで取得できるパラメータであり、



図 4 装着位置（ズボンのポケットの中）

このHTC Sensationのスマートフォンの場合は約50Hzで取得することが可能である。

周波数分割の特徴量抽出では、FFT: Fast Fourier Transformを使用した。Javaで使用できるFFTのライブラリとしてApache Commons Math[8]を用いた。

本システムに機械学習を組み込むために、Weka3.6[9]を使用した。Wekaは機械学習ソフトウェアであり、データを与えると様々な機械学習を切り替えて結果を出力することが可能である。

4. 予備実験

本章では、種々の機械学習分類アルゴリズムを使った移動判定手段の分類精度を比較し、採用するアルゴリズムの選定を目的とした、予備実験について述べる。

4.1 予備実験手順

予備実験手順は以下の通りである。

予備実験手順

- (1) 加速度データの収集
- (2) フーリエ変換による特徴量の抽出
- (3) 機械学習による分類

まず、BOROに適用する加速度データを収集した。HTC Sensationを使用し、7種類の移動手段（歩行、走行、電車、バス、自動車、自転車、その他）を行っている際の加速度データをそれぞれ約300秒間記録した。スマートフォンの装着位置はズボンの前ポケット（図4参照）の中に限定し、記録を行った。

次に、収集した加速度データから特徴量の抽出を行う。予備実験では、特徴量抽出の手法として周波数分割を用いた。特徴量抽出のための時間幅（フレーム）を1秒間、2秒間、4秒間の3種類にして特徴量抽出を行った。

機械学習ソフトウェアのWekaに特徴量データをセットし、機械学習アルゴリズムを切り替えて分類精度を評価する。今回、機械学習アルゴリズムとしてBaysNet, J48, KStar, Multilayer Perceptron, Random Forest, SMOの6種類のアルゴリズムを使用した。分類精度の評価としては

表 2 予備実験結果

Algorithm	Correctly Classified		
	1 秒	2 秒	4 秒
BayesNet	82.86%	83.71%	88.71%
J48	75.63%	80.43%	84.86%
KStar	69.57%	78.14%	86.86%
Multilayer Perceptron	71.71%	79.14%	87.00%
Random Forest	84.86%	88.14%	93.86%
SMO	59.14%	65.57%	81.14%




図 5 予備実験結果

表 3 Random Forest の混同行列 (%)

	静止	歩行	走行	電車	バス	自動車	自転車
静止	80	0	0	7	4	9	0
歩行	0	96	1	0	0	0	3
走行	0	1	99	0	0	0	0
電車	8	0	0	82	6	4	0
バス	3	0	0	10	74	12	1
自動車	17	0	0	2	14	67	0
自転車	0	2	0	0	0	2	96

交差検証を用いた評価を行った。

4.2 予備実験結果

実験結果を表 2, 図 5 に示す。また、機械学習アルゴリズムとして Random Forest を用いた場合の混同行列を表 3 に示す。

6 種類の機械学習アルゴリズムの中では Random Forest がフレーム長 1 秒では 84.86%, 2 秒では 88.14%, 4 秒では 93.86% と最も分類精度が高かった。特徴量データのフレーム長に注目すると、どの機械学習アルゴリズムにおいても 4 秒が最も分類精度が高かった。

Random Forest の混同行列から、歩行、走行、自転車では、95% 以上の高い精度で分類することが出来た。一方、最も分類精度が悪かった移動手段は自動車で 67% だった。次いでバスの 74%, 静止の 80% という結果だった。

4.3 予備実験の考察

BORO において、最も分類精度が高い機械学習アルゴリ

ズムは Random Forest だった。Random Forest は多数の決定木を生成し、それら複数の決定木から多数決によって分類するアルゴリズムである。決定木を弱学習機としているため、ノイズに対して強いという特徴がある。

また Random Forest の混同行列から、歩行、走行、自転車のように加速度変化の大きい移動手段は分類しやすい。しかし、電車、バス、自動車、その他のように加速度変化の小さい移動手段は他の加速度変化の小さい移動手段との分類が難しく、分類精度が低下してしまった。

5. 評価実験

予備実験でのスマートフォンの装着位置を限定した加速度データでは、Random Forest を用いて 93.86% で分類出来た。本章では、5.1 章で被験者とスマートフォンの装着位置の自由度を増やした場合の BORO の分類精度の評価する。また 5.2 章で BORO によって消費電力の低減を、既存の研究手法と比較して評価する。

5.1 BORO の分類精度の評価

被験者とスマートフォンの装着位置を自由度を増やした場合の BORO の分類精度の評価した。

5.1.1 実験手順

実験手順は以下の通りである。

実験手順

- (1) 加速度データの収集
- (2) 特徴量の抽出
- (3) 機械学習による分類

まず、BORO に適用する加速度データを収集した。加速データの収集は大学研究室のメンバー 5 人で行った。5 人とも HTC Sensation を使用し、7 種類の移動手段（歩行、走行、電車、バス、自動車、自転車、その他）を行っている時に加速度データを約 300 秒間記録した。スマートフォンの装着位置に関して、ズボンのポケットの中、カバンの中（図 6 参照）、手の上（図 7 参照）の 3 ヶ所の場合のデータをそれぞれ記録した。安全のため、自動車と自転車については手の上を除外し、ポケットの中とカバンの中の 2 ヶ所の場合のデータをそれぞれ記録した。

次に、収集した加速度データから特徴量の抽出を行う。評価実験では、特徴量抽出の手法として時系列分割手法、周波数分割手法、それらを組み合わせた手法の 3 通りを用いた。特徴量抽出のための時間幅（フレーム）を 0.5 秒間、1.0 秒間、1.5 秒間、2.0 秒間、2.5 秒間、3.0 秒間、4.0 秒間、5.0 秒間の 8 種類にして特徴量抽出を行った。

機械学習ソフトウェアの Weka に特徴量データをセットし、機械学習アルゴリズムを切り替えて分類精度を評価する。今回、機械学習アルゴリズムとして BaysNet, J48,



図 6 装着位置（カバンの中）



図 7 装着位置（手の上）

表 4 時系列分割を用いた場合の分類精度

Algorithm	Correctly Classified		
	1.0 秒	2.0 秒	4.0 秒
BayesNet	76.85%	78.00%	78.85%
J48	89.28%	90.00%	90.28%
KStar	73.71%	73.00%	76.71%
Multilayer Perceptron	75.57%	69.42%	72.28%
Random Forest	90.42%	92.00%	93.85%
SMO	63.00%	70.71%	77.57%

表 5 周波数分割を用いた場合の分類精度

Algorithm	Correctly Classified		
	1.0 秒	2.0 秒	4.0 秒
BayesNet	76.85%	78.00%	78.85%
J48	89.28%	90.00%	90.28%
KStar	73.71%	73.00%	76.71%
Multilayer Perceptron	75.57%	69.42%	72.28%
Random Forest	90.42%	92.00%	93.85%
SMO	63.00%	70.71%	77.57%

KStar, Multilayer Perceptron, Random Forest, SMO の 6 種類のアルゴリズムを使用した。分類精度の評価としては交差検証を用いた評価を行った。

5.1.2 実験結果

特徴量抽出の手法に時系列分割を用いた場合の分類精度を表 4 示す。周波数分割を用いた場合の分類精度を表 5 に示す。また、時系列分割と周波数分割を組み合わせた手法を用いた場合の分類精度を表 6, 図 8 に示す。最も分類精度が高かったのは、機械学習アルゴリズムに Random Forest




図 8 系列分割と周波数分割を組み合わせた場合の分類精度

表 7 Random Forest フレーム長 4.0 秒の混同行列 (%)

	歩行	走行	電車	バス	自動車	自転車	その他
歩行	99	0	0	0	0	0	1
走行	0	100	0	0	0	0	0
電車	0	0	97	2	0	0	1
バス	0	0	2	98	0	0	0
自動車	0	0	0	1	98	0	1
自転車	0	0	0	0	0	100	0
その他	1	0	1	1	0	2	95

表 8 SMO フレーム長 1.0 秒の混同行列 (%)

	歩行	走行	電車	バス	自動車	自転車	その他
歩行	99	0	0	0	0	0	1
走行	0	100	0	0	0	0	0
電車	0	0	2	0	0	0	98
バス	0	0	0	2	0	0	98
自動車	0	0	0	0	43	0	57
自転車	0	0	0	0	0	99	1
その他	1	0	0	0	0	1	98

を用いた場合だった。この時の混同行列を表 7 に示す。特徴量の抽出手法に注目すると、全ての機械学習の手法において周波数分割より時系列分割を用いた場合のほうが分類精度が高かった。また、ほとんどの機械学習アルゴリズムにおいて、特徴量データのフレーム長が 1.0 秒、2.0 秒、3.0 秒と長くなるほど分類精度が高くなっていった。しかし、KStar, SMO では 0.5 秒になるとわずかに分類精度が低下した。最も分類精度が悪かったのは特徴量の抽出手法に周波数分割を用い、機械学習アルゴリズムに SMO を用いた場合で 63.00%だった。この時の混同行列を表 8 に示す。

5.1.3 考察

評価実験では、加速度データの収集を 1 人から 5 人に増やし、スマートフォンの装着位置を 1 ヶ所から 3 ヶ所に増やした。予備実験時の特徴量抽出に周波数分割を用いた場合と比較してみると、多くの場合で分類精度がわずかに低下していた。人の違いによって動き方が異なったり、スマートフォンの持ち方が異なったりしたことが分類精度の

表 6 時系列分割と周波数分割を組み合わせた場合の分類精度

Algorithm	Correctly Classified							
	0.5 秒	1.0 秒	1.5 秒	2.0 秒	2.5 秒	3.0 秒	4.0 秒	5.0 秒
BayesNet	94.10%	94.45%	94.57%	94.48%	94.11%	94.04%	94.02%	94.61%
J48	96.58%	96.47%	96.38%	96.50%	96.42%	96.37%	95.16%	95.10%
KStar	95.00%	96.69%	96.69%	96.53%	96.88%	96.85%	96.44%	96.59%
Multilayer Perceptron	95.47%	96.15%	96.18%	96.49%	96.61%	96.15%	96.49%	96.59%
Random Forest	97.61%	97.76%	97.61%	97.56%	97.56%	97.73%	97.33%	97.27%
SMO	86.78%	88.63%	88.89%	89.88%	88.89%	89.34%	90.12%	89.77%

低下の原因だと考えられる。

特徴量の抽出手法では周波数分割よりも時系列分割のほうが分類精度が高く、これは、周波数分割におけるフーリエ変換では得られる特徴量の幅が小さく、時系列分割では分散や相関係数と言った複数の特徴量計算をしているため特徴量の変化が出やすかったと考えられる。

特に分類精度の悪かった SMO を使っている場合は、混同行列から電車やバスがその他にほぼ分類されてしまっていた。SMO では「その他」の教師データが強すぎるという問題点があった。

特徴量データのフレーム長が 0.5 秒のとき KStar, SMO では分類精度が低下してしまった問題があった。これはフレームが短くなってしまったために、十分な特徴量を得られなかったためである。時間幅が長くなれば分類精度が高まったが、リアルタイム性が失われてしまう。そのため、判定した移動手段を活用する目的に合わせ、時間幅を変えていく必要がある。

KStar, Multilayer Perceptron では Weka で処理をする際に、10 分以上分類に時間がかかってしまった。計算量が多いため消費電力の増大が考えられ、また判定のリアルタイム性を考えると実用的ではないといえる。BORO には機械学習アルゴリズムとして Random Forest を使用する。

5.2 省電力性の評価

次に、加速度センサのみを用いる本システムの省電力性を評価する。

5.2.1 実験手順

実験手順は以下の通りである。

- 実験手順
- (1) スマートフォン A に加速度センサのみ、
スマートフォン B に加速度センサと GPS を使用
 - (2) バッテリー残量の記録
 - (3) スマートフォン A に加速度センサと GPS、
スマートフォン B に加速度センサのみを使用
 - (4) バッテリー残量の記録
 - (5) (2),(4) の平均を計算

加速度センサのみを用いた場合と、加速度と GPS を用いた




図 9 省電力性の評価

場合の 2 種類のついて評価を行う。2 台の HTC Sensation を用いて実験を行い、1 台には加速度センサのみを用いて判定を行う Android アプリケーションを動作させ、もう 1 台には加速度センサと GPS を用いて判定を行う Android アプリケーションを動作させた。2 台の Android から取得できるバッテリー残量を時刻ごとに記録した。計測時間は 10 時間とした。なお、スマートフォンのバッテリーの劣化を考慮するために、1 回計測した後加速度センサのみのアプリケーションと、加速度センサと GPS を組み合わせたアプリケーションを入れ替えてもう一度計測を行って、その平均を結果とした。

5.2.2 実験結果

実験結果を図 9 に示す。使用した Android 端末は 100% の時間が長く続いてしまうという点があった。加速度センサのみの場合と比べ、加速度センサと GPS を組み合わせた場合は 5 倍以上消耗が早かった。また、加速度センサと GPS を組み合わせた場合は計測開始から約 9 時間でバッテリー残量が 0 % になってしまった。

5.2.3 考察

GPS を組み合わせた場合は測位の際の計算量が増加し、消費電力が増大して急速にバッテリー残量が低下してしまったと考えられる。加速度センサと GPS を用いて移動手段を判定した場合は、移動手段判定アルゴリズムのみを動かしていても、約 9 時間しかバッテリーが持たなかった。そのため、私たちが日常的に移動手段を判定し続けるシチュエーションを考えた場合、他のアプリケーションと同時に使用するために、加速度センサと GPS を組み合わ

せて使用する移動手段判定アルゴリズムは日常的に記録するには実用的ではないといえる。

6. 今後の課題

本研究では、移動手段判定アルゴリズムである BORO の評価方法として、今後の課題としては、本システムをより多くの被験者を対象として実際に使用した場合の、分類精度や省電力性の評価があげられる。

ユーザの実環境での利用を想定すると、より多くのユーザによる今回分類対象としていない広範な行動時における本システムの分類精度の評価は重要な評価項目と言える。

また、本研究では加速度センサのみを用いた場合の省電力性をバッテリー残量値を指標として評価した。消費電力量などより詳細な評価が課題としてあげられる。また、各機械学習アルゴリズムを実際にスマートフォン上で動作させた場合の判定処理に要する消費電力も含めた評価が課題である。

以上のようなより詳細な評価をもとに、本システムで採用する機械学習アルゴリズムやパラメータの検討を行う。

7. おわりに

本研究では、移動手段判定アルゴリズムとして BORO を提案した。本システムではスマートフォンの消費電力を抑え、GPS 電波の届かないところでも移動手段の判定を可能にするため、加速度センサのみを用いた。6 種類の機械学習アルゴリズムにおける分類精度の比較を行い、Random Forest を用いた場合に分類精度は 98.71% だった。また、省電力性の評価を行い、加速度センサと GPS を用いた場合に比べ、加速度センサのみの場合はバッテリーが 5 倍以上長持ちした。

8. 謝辞

本研究の一部は、独立行政法人情報通信研究機構に支援頂いた。

参考文献

- [1] Nike, Inc.: Nike FuelBand SE. Nike.com (JP), Nike, Inc. (online), available from http://www.nike.com/jp/ja_jp/c/nikeplus-fuelband (accessed 2014-02-06).
- [2] Fitbit Inc.: Fitbit, Fitbit Inc. (online), available from <http://www.fitbit.com/jp> (accessed 2014-02-06).
- [3] ProtoGeo: Moves - Activity Tracker for iPhone and Android, ProtoGeo (online), available from <http://www.moves-app.com/> (accessed 2014-02-06).
- [4] Kwapisz, J. R., Weiss, G. M. and Moore, S. A.: Activity Recognition Using Cell Phone Accelerometers, *SIGKDD Explor. Newsl.*, Vol. 12, No. 2, pp. 74–82 (online), DOI: 10.1145/1964897.1964918 (2011).
- [5] 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, No. 1, pp. 193–208 (オンライン), 入手先 <http://ci.nii.ac.jp/naid/110007970316/> (2009).

- [6] 山崎亜希子, 五味田啓: 加速度センサ等を用いた移動状態判定方式の検討, 全国大会講演論文集, Vol. 70, No. 3, pp. 39–40 (オンライン), 入手先 <http://ci.nii.ac.jp/naid/110006866625/> (2008).
- [7] Yan, Z., Subbaraju, V., Chakraborty, D., Misra, A. and Aberer, K.: Energy-Efficient Continuous Activity Recognition on Mobile Phones: An Activity-Adaptive Approach, *Wearable Computers (ISWC), 2012 16th International Symposium on*, pp. 17–24 (online), DOI: 10.1109/ISWC.2012.23 (2012).
- [8] The Apache Software Foundation: Math - Commons Math: The Apache Commons Mathematics Library, The Apache Software Foundation (online), available from <http://commons.apache.org/proper/commons-math/> (accessed 2014-02-09).
- [9] The University of Waikato: Weka 3 - Data Mining with Open Source Machine Learning Software in Java, The University of Waikato (online), available from <http://www.cs.waikato.ac.nz/ml/weka/> (accessed 2014-02-09).