

### 3 軸加速度センサを用いた移動状況推定方式

池谷 直紀<sup>†</sup> 菊池 匡晃<sup>†</sup> 長 健太<sup>†</sup> 服部 正典<sup>†</sup>

†株式会社東芝 研究開発センター 〒212-8582 神奈川県川崎市幸区小向東芝町1

E-mail: †{naoki.iketani, masaaki11.kikuchi, kenta.cho, masanori.hattori}@toshiba.co.jp

あらまし 加速度センサを搭載した携帯端末の動きに基づいて、端末保持者の移動状況をその保持位置・保持姿勢に依存せず推定する方式を作成し、実験的に評価を行った。本手法は、センサ入力値から重力成分の推定と除去をした上で算出した各種統計量を特徴量とし、三層のニューラルネットを用いて「静止」「歩行」「走行」「乗車中(バス・電車)」の4状態を推定する。さらに後処理として独自のヒューリスティックを用いた移動状況遷移モデルによる補正処理を提案した。この結果として、非学習データにおいて補正処理なしで81%の精度で移動状況を推定することができ、さらに補正処理を導入することにより平均84~87%の精度向上することを確認した。

キーワード コンテクストアウェア、加速度センサ

### Pedestrian Context Inference Using a 3-Axis Accelerometer

Naoki IKETANI<sup>†</sup> Masaaki KIKUCHI<sup>†</sup> Kenta CHO<sup>†</sup> and Masanori HATTORI<sup>†</sup>

† Research and Development Center, Toshiba Corp.

1 Komukai Toshiba-cho, Saiwai-ku, Kawasaki, 212-8582 Japan

E-mail: †{naoki.iketani, masaaki11.kikuchi, kenta.cho, masanori.hattori}@toshiba.co.jp

**Abstract** We introduce a new method to recognize pedestrian contexts using a handheld mobile computer and a three-axis accelerometer. Without being affected by the position and direction of the accelerometer, we can recognize four kinds of pedestrian contexts: "still (not moving)", "walking", "running", and "on a vehicle (on a bus or train)." Our context recognition method consists of gravity estimation, feature value extraction from sensor information, context classification through a three-layer neural network, and the post-process context correction based on our original heuristic state-transition model. We evaluated the accuracy of the context recognition through cross validation. The accuracy reached 81% before the post-process correction and 84-87% after the post-process correction.

**Keyword** Context-aware, accelerometer

#### 1. はじめに

近年、ユーザの状況や置かれている環境（コンテクスト）を、ユーザの自然な行動をセンシングすることによって推定する技術、すなわちコンテクストアウェア技術が研究・開発されている。これによりユーザの状況に応じた情報サービスの提供が実現されるという期待があるものの、多種多様なコンテクストのうち何が重要であるかはアプリケーションにより異なる。現在普及しつつあるGPSや加速度センサを搭載した携帯端末を対象とした研究も多数存在し、中でもユーザの位置をコンテクストとして活用するものは多数の応用例が存在するが、位置を常に正確に把握することは困難である。

そこで本稿では、位置と位置の間をつなぐ「移動状況」の検出に着目した。具体的には、人々の生活の中

で高頻度で発生し、その生活シーン特定の手がかりとなり得る「走行」「歩行」「静止」「乗車中」の4つの移動状況（移動コンテクスト）を対象とした。本稿では端末に付随した加速度センサの動きに基づいて端末を保持した利用者の移動状況を検出する方式を提案し、実験的な評価結果を報告する。

#### 2. 関連研究

移動状況を検出する研究は多数存在し、加速度センサをGPSやジャイロと組み合わせて利用するもの、照度センサやマイクと組み合わせて利用する研究[1]や、複数の加速度センサを用いる研究[2]などが存在する。単一の加速度センサによる研究も存在し、倉沢ら[3]は周波数特性を特徴量とした移動状況推定時にセンサ付随端末の装着位置（ズボン、鞄、胸ポケット）の推

定を行うことにより、4つの状況（立位、座位、歩行、走行）の推定精度を向上させ約97%を実現している。磯ら[4]はwavelet packetを特徴量としてSelf Organizing Mapとベイズ理論を用いて、5つの歩行状況（歩き、早歩き、昇り階段、降り階段、走り）を平均80%程度で識別している。また中村ら[5]はSTFTにより特徴量を算出してSVMを用いて電車内外の判定を試みており、加速度センサのみの場合と超音波センサを付加した場合の比較を行っている。

異なるアプローチとしては、音声からその環境を推定する音環境理解（Computational Auditory Scene Analysis）と呼ばれるアプローチにおいても乗車中などの状態を識別する試みは存在し、たとえばVesaら[6]はバス内や電車内を含む25の環境についての認識を行っている。

これらの既存と比較して、本研究では単一の加速度センサを付与した装置を用いて、その保持位置や保持方向によらずユーザーの移動状況を識別すること、電車やバスに乗車中であるという移動状況を識別対象として扱うこと、そして後述する遷移確率モデルによる補正処理を導入していることが特徴である。

### 3. 提案手法

我々は、表1に記載した4種の移動状況を対象としてその識別方式を作成した。ここでの走行（running）とは小走りや全力疾走を含む足での移動を指し、vehicleはバスおよび電車への乗車を対象とした。またこれらは排他的なものとみなし、乗車中の歩行については乗車中とみなした。

表1：対象とする移動状況

移動状況	対象区間
running	足で走った区間。
walking	歩いた区間、1分以内の信号待ちなどを含む。
still	駅での電車待ちなどの静止区間、および食事中などで体から離れた場所に置いた区間。
vehicle	電車およびバス乗車区間、駅やバス停などの停車区間も含む。

提案手法では、加速度センサから取得されるデータを用いて以下の手順で移動状況の推定を行う。

1. 3軸加速度の時系列データ取得
2. 重力方向推測による正規化と、それにに基づく重力成分を除去したベクトル長、重力成分との内積・外積の3次元特徴量の算出
3. 上記3次元特徴量を入力とした、時間幅にお

ける4種基本統計量の算出による12次元特徴量の算出

4. ニューラルネットワークによる移動状況の分類
5. 遷移確率モデルによる補正
6. 閾値に基づく移動コンテクスト推定

以下では3軸加速度の時系列データ取得、重力方向推測による正規化、基本統計量の計算、ニューラルネットワークによる移動状況の分類、遷移確率モデルによる補正、閾値に基づく移動状況推定の各手順を順に説明する。

#### 3.1.3 軸加速度の時系列データ取得

3軸加速度センサから各時刻における加速度データを取得する。取得される加速度データの例を図1に示す。横軸が時間、縦軸が加速度の値を表しており、約140分間に渡る、X軸、Y軸、Z軸の3軸に対応した3つの系列を示している。図面下部に正解コンテキスト、すなわち被験者の実際の動作を表記した。

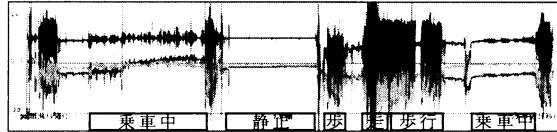


図1：3軸加速度センサから得られるデータ例  
(X軸, Y軸, Z軸)

#### 3.2 重力方向推測による正規化

3軸加速度センサによって得られるデータはセンサデバイスの向きに依存し、デバイスの保持姿勢によって異なるデータとなる問題がある。デバイスの保持姿勢に依存しないデータにするために重力方向を推測し、その方向を基準にした正規化を行う。

ここでは加速度センサには常に1Gの重力がかかるを利用し、一定の時間幅 $w_G$ でのXYZ軸の平均ベクトルを重力ベクトルと推定する。時刻tでの重力ベクトル $v_g(t)$ は3軸加速度ベクトル $v(t)$ を用いて以下の式で表される。

$$v_g(t) = \frac{\sum_{i=t-w_G}^t v(i)}{w_G}$$

ある時刻で得られた3軸加速度ベクトルから重力ベクトルを減算し、正規化された加速度ベクトルを求める。時刻tでの正規化された加速度ベクトル $v_n(t)$ を以下のように定義する。

$$v_n(t) = v(t) - v_g(t)$$

正規化された加速度ベクトルから特徴量として、ベクトル長、重力ベクトルとの内積値、重力ベクトルとの外積値を用いる。これはデバイスの移動方向による影響を除去するためである。時刻  $t$  での特徴量  $F_1(t)$ ,  $F_2(t)$ ,  $F_3(t)$  は以下の式で表される。

$$F_1(t) = \|v_n(t)\|$$

$$F_2(t) = v_n(t) \cdot v_G(t)$$

$$F_3(t) = v_n(t) \times v_G(t)$$

この算出式によって得られた特徴量の例を図 2 に示す。横軸が時間、縦軸が特徴量の値を表している。

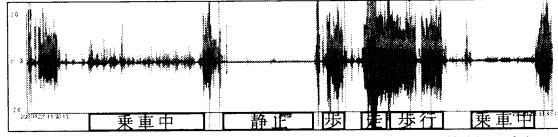


図 2：重力成分の正規化後に抽出された特徴量の例  
(ベクトル長、重力ベクトルとの内積、外積)

### 3.3 基本統計量の算出

正規化された特徴量はある一瞬のスナップショットであり、人間の行動変化の周期に対して短いため、時間的な変動の傾向や一定時間内での変動を加味した特性を検知できない。コンテクストの弁別に有効な特徴量を得るために現在時刻から一定時間幅を持つウィンドウでの基本的な統計量を算出する。

前ステップで得られたデバイスの向きに依存しない 3 種類の特徴量  $F_1(t)$ ,  $F_2(t)$ ,  $F_3(t)$  それぞれについて時刻  $t$  から一定時間幅  $w_s$  内での平均値、最大値、最小値、分散値の 4 種類の統計量を計算する。こうして得られた 12 次元の特徴量によって一定時間幅  $w_s$  内での特徴が表される。得られた基本統計量の例を図 3 に示す。横軸が時間、縦軸が各基本統計量の値を表している。

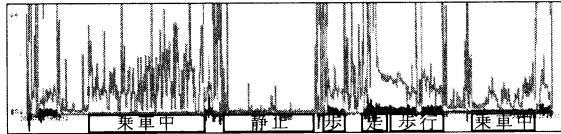


図 3：正規化された特徴量の基本統計データの例  
(最大値、平均値、最小値、分散値)

### 3.4 ニューラルネットワークによる移動状況の分類

前ステップで得られた 12 次元の基本統計量を 4 種類の移動コンテクスト (running, walking, still, vehicle) に分類する。12 次元の特徴量に対して正解コンテクストの確信度を 1, それ以外を 0 としたベクトルを教師信号として誤差逆伝播法によって学習した 3 層ニューラルネットワークを分類器として用いる(図 4)。

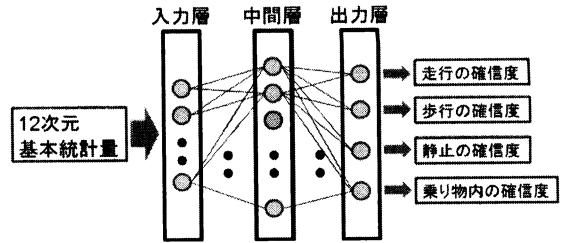


図 4：ニューラルネットワークの構成

ニューラルネットワークは 4 種類の移動コンテクストの確信度を 0~1 の範囲で出力する。ここで、ある時刻における 4 種の確信度の総和は 0~4 の範囲で不定である。学習時のデータ入力は時系列によらないランダムな順序で行い、正解移動コンテクスト種別の入力回数の割合が均等になるように学習を行った。ニューラルネットワークによる分類結果の例を図 5 に示す。横軸が時間、縦軸が各移動コンテクストの確信度を表している。特に図の左側の乗車中が正解である部分について、静止状態が交互に検出されていることに注意されたい。これはバスが停車したときに静止状態が検出されているものである。

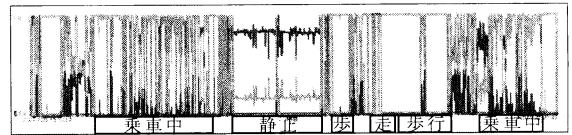


図 5 ニューラルネットワークによる分類結果の例  
(走行, 歩行, 静止, 乗車中)

### 3.5 遷移確率モデルによる補正

単純にセンサの挙動から判定した場合、例えば電車やバスが一時的に停車した際や、歩行中に一時停止した際には静止と判定される可能性が高い。本研究の前提では一時停車は vehicle に含め、信号待ちのような一時停止は walking に含めるため、移動コンテクストの遷移確率に基づく補正方式を導入した。

例えば乗り物から降りた直後には、通常は歩行が行われる場合が多い。そこでニューラルネットワークの出力が vehicle から walking に変化した場合にはスムーズに変化するが、vehicle から still に移った場合には即座に still には変化せず、数秒間の still を確認してから遷移するような処理を行う。このような各コンテクストから他のコンテクストへの変化しやすさの度合いを、遷移確率モデルで表現した。この遷移確率モデルを図 6 に示す。線の太い状態遷移ほど遷移しやすいことを意味している。この確率の値は予備実験に基づいて設定したヒューリスティック値である。

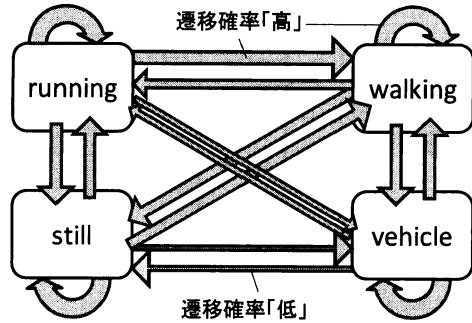


図 6：移動コンテクストの遷移確率モデル

補正処理としては、判定時の各コンテクストの確信度  $PS_c(t)$  は、直前に判定を行った際の各コンテクストの確信度  $PS_c(t-1)$  と、判定時のニューラルネットワークの各コンテクストの確信度出力値  $PN_c(t)$  と、遷移確率モデルに基づくコンテクスト  $C_1$  から  $C_2$  への遷移しやすさ  $P(c_1, c_2)$  を用いて以下の補正を行う。

$$PS_c(t) = \sum_{C_1} \sum_{C_2} (PN_{C_1}(t) * PS_{C_2}(t-1) * P(c_1, c_2))$$

遷移確率モデルによって補正した出力の例を図 7に示す。横軸が時間、縦軸が各移動コンテクストの確信度を表している。図 5と比較すると、乗車中部分で静止状態が抑制されていることがわかる。

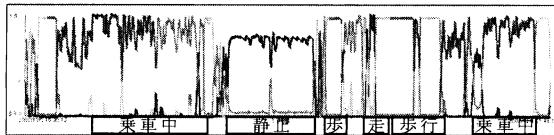


図 7：遷移確率モデルによる補正結果の例  
(走行、歩行、静止、乗車中)

### 3.6 閾値に基づく移動状況推定

本手法では、最終的には一つの移動状況を推定して出力する。そのために、閾値  $T$  以上の移動コンテクストのうち確信度が最大のコンテクストを 1 つ出し、閾値  $T$  以上のコンテクストが無い場合には推定結果を出力しないものとした。

## 4. 評価

我々は、実際の生活時にセンサを携行して収集したデータを用いて、提案手法による移動状況推定の精度評価を実施した。本章ではその方法と結果について述べる。

### 4.1 評価用データと正解データ

評価用のデータを収集するために、加速度センサを携帯電話に接続したデータ収集装置を試作した。携帯電

話上ではセンサの値を約 50Hz で記録するソフトウェアを稼働させ、このデータ収集装置を生活時の主に移動シーンを中心に携行して評価用データを作成した。被験者は 5 名で、データ収集装置の保持位置は被験者の自由とした。結果としては、鞄の中、ズボンの前ポケット、上着のポケットを保持位置としたデータが収集された。

また、データを収集した時間帯について、4 つの移動状況の正解データを手動で用意した。今回は自転車については対象外としているため正解データは付与せず、正解データが付与されない時間帯については評価用データを除外した。同様に、ショッピング中であり歩行と静止が短い時間で繰り返される場合のように正解が明らかでない部分についても、正解データを用意せず評価データからも除外した。こうして 4 つの移動状況に対応する評価データと正解データを作成した。

結果として延べ 25 時間 13 分の正解付き加速度データが収集された。収集したデータの移動コンテクストの内訳を図 8 に示す。

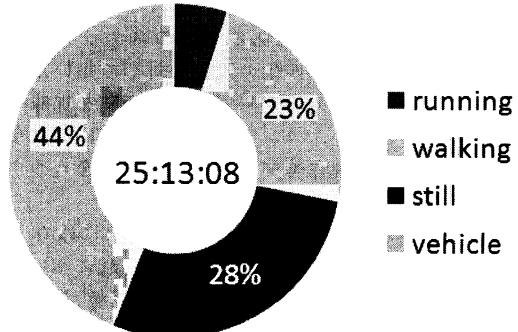


図 8：収集した評価用データの内訳

### 4.2 精度評価

ニューラルネットワークは学習時に入力したデータの性質によって性能が変化するため、収集した正解付き加速度データを 4 つのグループに分け、各グループを入力データとする 4 回の学習を行い、それについて精度を評価した。なおグループ分けの際には正解コンテクスト種別の比率を保つようにランダムに分割した。

ここでは、遷移確率モデルの効果を明らかにするため、3.5 節で述べた補正を行う場合と行わない場合についての評価を行った。評価尺度としては、適合率、再現率、F 値(F-measure)を用いた。

4 回の精度評価を平均すると、遷移確率モデルによる補正なしの場合には学習データに対する F 値(Closed)が 0.85、未学習データに対する F 値(Open)が 0.81 であり、補正を行った場合には Closed で 0.88、

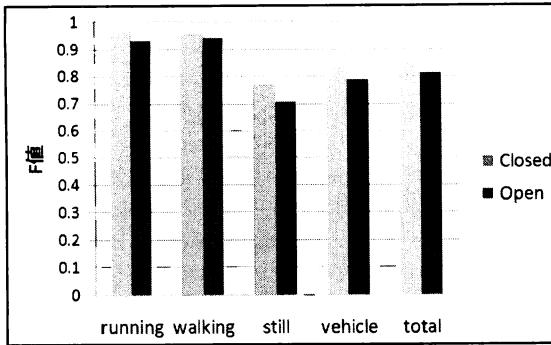


図 9: 移動コンテクスト別の F 値  
(遷移確率モデルによる補正なしの場合)

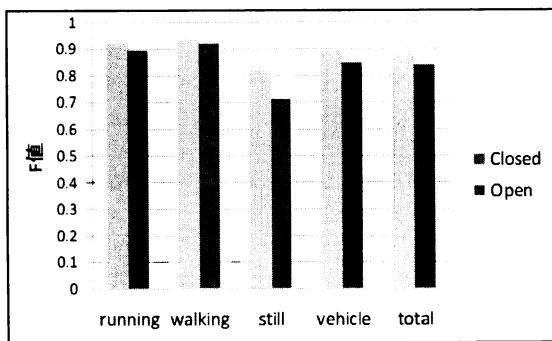


図 10: 移動コンテクスト別の F 値  
(遷移確率モデルによる補正ありの場合)

Open で 0.84 であった。移動コンテクスト種別ごとの F 値をそれぞれ図 9, 図 10 に示す。横軸が移動コンテクスト種別を、縦軸が F 値を表している。補正によって total は 0.03 程度向上しているが、still および vehicle が 0.05 程度向上している中で、running が 0.05 程度低下していることが見て取れる。

また詳細を明らかにするために、表 2 に遷移確率モデルの有無について学習データ(Open)に対する推定移動コンテクスト別の正解の内訳と精度、および 4 回の各試行における F 値を示す。例えば表 2(b)からは正解コンテクスト(real context)が静止(still)のときに乗車中(vehicle)と誤って推定される回数が多いことが読み取れ、これが主な原因となって静止の再現率(recall)が低い値(0.65)となっていることがわかる。

## 5. 考察

まず全体的な傾向として、既存研究でも明らかにように running, walking については 90%以上の識別が可能である。困難であるのは vehicle の、特に still との識別であることが本実験でも確認できた。

### 5.1 遷移確率モデルの有効性

図 9, 図 10 を比較すると、遷移確率モデルによる補正によって vehicle の F 値が 0.05 向上しており、全体としても F 値が 0.03 向上していることがわかった。これは電車やバス内での一時停車中に静止状態とニューラルネットワークから出力されるものを補正できて

表 2: 推定移動コンテクスト別の正解の内訳と精度

(a) 遷移確率モデルなしの場合

Open	real context				total	precision	recall	F-measure	
	running	walking	still	vehicle					
estimated context	running	648163	53464	2751	1004	705382	0.92	0.94	0.93
	walking	37165	2865262	73063	144033	3119523	0.92	0.96	0.94
	still	682	13680	2628615	1174936	3817913	0.70	0.73	0.71
	vehicle	1615	37164	797870	4210905	5047554	0.84	0.75	0.79
	unknown	251	11886	75808	66988	154933			
total		687876	2981456	3578107	5597866	12845305	0.82	0.81	0.81

(b) 遷移確率モデルありの場合

Open	real context				total	precision	recall	F-measure	
	running	walking	still	vehicle					
estimated context	running	605983	55635	7670	641	669929	0.90	0.88	0.89
	walking	66962	2820527	172986	93359	3153834	0.89	0.95	0.92
	still	3381	23833	2338222	522367	2887803	0.85	0.65	0.71
	vehicle	10326	67258	937830	4886276	5901690	0.84	0.87	0.84
	unknown	1224	14203	121399	95223	232049			
total		687876	2981456	3578107	5597866	12845305	0.84	0.83	0.84

いる結果と考えられる。しかしながら、表 2(a)と(b)を比較すると静止状態の再現率(recall)が大きく低下しており、これは正解が静止状態であるときに乗車中と出力されていることが原因であるとわかる。このことから遷移確率モデルによる補正によって過剰に still が抑制され、vehicle が強調されていると考えられる。これは、一時停車などに対して鋭敏に変化することを防止したことにより、実際に静止状態に遷移した際に still に遷移しづらくなつた結果である。どの程度の抑制が妥当であるかは、技術的な最適化とアプリケーションにおける検出の鋭敏性に関する要求性能の両面から検討および調整する必要がある。

## 5.2 推定に必要な時間幅による精度低下の影響

本手法では、推定に一定時間幅のデータを使用していることは3章で述べた。ここでは特徴量として統計量を算出する際の時間幅  $w_s$  を 10 秒とした。また遷移確率モデルによる補正において時間幅  $w_T$  を導入し、ここでは 30 秒としており、本評価においては実際の行動が変化してから出力が変化するまでに約  $(10+30)/2=20$  秒程度の遅延が発生すると考えられる。

そこでこの遅延の影響の大きさを把握するために、正解コンテキスト変化後の最初の 20 秒を精度評価の対象から除外した場合の評価を行った。この結果を図 11 に示す。図 10 と比較して running, walking の F 値は 0.96, 0.97 と大幅に向上去ており、遷移確率モデルの導入により走行、歩行についての F 値が低下している原因の大半が出力の遅延によるものであることが明らかとなった。また特に遷移確率モデルの導入により running の精度は最も低下した（図 9→図 10）が、これは running のデータは他の状態と比較して持続時間が短時間であり、約 20 秒の推定の遅延が及ぼす影響が他のコンテキストと比較して大きかったためと考えられる。

のことから、20 秒程度の出力の遅延が問題となるないアプリケーションであれば、遅延した出力を行う

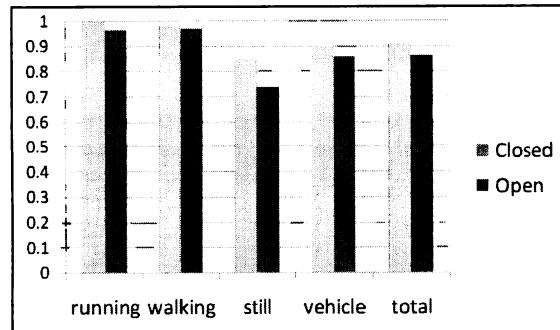


図 11：20 秒遅延評価した場合の F 値

ことにより実質の精度はここで得られた平均 F 値である Closed 0.91, Open 0.87 であるといえる。

また、遷移確率モデルによる補正の導入は、補正による精度向上と推定時間遅延による精度低下のトレードオフの関係にあることが明らかとなった。

また running や walking については遷移確率モデルによる補正で副作用が出てしまっている。このことから、ニューラルネットワークの出力が running や walking である場合には遷移確率モデルによる補正を行わない方式も有効であると考えられる。また今回の遷移確率モデルは単純なものであり、遷移確率モデルの洗練を行うことで副作用を低減することも今後の課題である。

## 6. おわりに

本稿では、単一の加速度センサを付与した端末を保持するユーザーの 4 つの移動状況を、端末の保持位置・保持姿勢に依存せず推定する方式を提案し実験的に評価を行った。本方式は重力成分推定を行った上で統計的特徴量を算出し、ニューラルネットワークによる分類により約 81% で推定可能であることを確認し、さらに遷移確率モデルによる補正を導入することにより精度を約 84% に向上できた。また、推定結果の出力に約 20 秒の遅延を許容できる場合には遷移確率モデルの導入により約 87% での推定が可能であることを示した。

今後の課題としては、遷移確率モデルの洗練、自転車など他の状態についての検証、乗車中状態と静止状態をより高精度で識別する方式や特徴量の導入が挙げられる。

## 文 献

- [1] Daniel Siewiorek, Asim Smailagic, Junichi Furukawa, Neema Moraveji, Kathryn Reiger, and Jeremy Shaffer, "SenSay: A Context-Aware Mobile Phone," Poster of 7th IEEE International Symposium on Wearable Computers (ISWC'03), October 2003.
- [2] Siewiorek, D., et. al., "Recognizing human motion with multiple acceleration sensors", IEEE International Conference on Systems, Man, and Cybernetics, pp.747-752, vol.2, October 2001
- [3] 倉沢, 川原, 森川, 青山, "センサ装着場所を考慮した 3 軸加速度センサを用いた姿勢推定手法", 電子情報通信学会総合大会, B-15-8, March 2006.
- [4] Toshiki Iso, Norihiro Kawasaki, and Shoji Kurakake, "Personal Context Extractor with Multiple Sensor on a Cell Phone," The 7th IFIP International Conference on Mobile and Wireless Communications Networks, D. 2 C200525, Morocco, September 2005.
- [5] 中村, 小川, 清川, 竹村, "利用者コンテキスト認識における電車内外判定に関する検討", 情報処理学会 マルチメディア, 分散, 協調とモバイルシンポジウム(DICOMO)論文集, Vol. 2007, No. 1, pp. 1496-1501, Jul.
- [6] V. Peltonen, et. al., "Computational Auditory Scene Recognition", Acoustics, Speech, and Signal Processing, 2002. Proceedings. (ICASSP '02).