

# 携帯電話搭載センサによるリアルタイム生活行動認識システム

大内 一成<sup>1,a)</sup> 土井 美和子<sup>1</sup>

受付日 2011年10月24日, 採録日 2012年4月2日

**概要:** 携帯電話に搭載されている加速度センサとマイクのみを活用した生活行動認識手法を提案する。まず加速度をもとにユーザの動作状態を「歩行」「作業」「安静」の3状態に大まかに推定する。ここで「作業」と推定された場合には、マイクからの音を分析することにより作業内容を細かく分類する。本手法を用いてユーザの生活行動をリアルタイムに認識するシステムを試作し、日常生活環境における2つの実験を通して提案手法の妥当性を検証した。加速度センサのみで「歩行」「作業」「安静」の3状態をおおむね95%以上の精度で推定でき、「作業」の場合はマイクからの音の分析により7種類の作業を平均85.9%の精度で推定できる基本性能を確認した。また、事例ベース認識手法の導入が実用に向けて効果的であることも確認した。

キーワード: 行動認識, 加速度センサ, マイク, 携帯電話

## A Real-time Living Activity Recognition System by Using Sensors on a Mobile Phone

KAZUSHIGE OUCHI<sup>1,a)</sup> MIWAKO DOI<sup>1</sup>

Received: October 24, 2011, Accepted: April 2, 2012

**Abstract:** We propose a real-time living activity recognition method using only off-the-shelf sensors, namely, an accelerometer and a microphone, which are commonly applied in mobile phones. The proposed method firstly estimates a user's movement condition such as "walking," "working" and "quiet" roughly by acceleration sensing. Secondly, it classifies the working condition in detail by acoustic sensing when it estimates the condition to be "working" by acceleration sensing. We developed a prototype system to recognize the user's living activity in real time and conducted two experiments to confirm the feasibility of the proposed method. As a result of the first experiment, three movement conditions were classified with more than 95% accuracy by acceleration sensing. And it classified working into seven conditions with 85.9% accuracy on average by acoustic sensing. Moreover, the result of the second experiment shows that it is effective to adopt instance-based recognition according to the assumed application.

**Keywords:** activity recognition, accelerometer, microphone, mobile phone

### 1. はじめに

加速度センサ, GPS (Global Positioning System) など, ユーザの状況, 位置などの把握に活用可能なセンサが, 携帯電話など小型の情報端末へ搭載され, ユーザの現在の状

況に基づいて適切なサービスを提供する状況依存型サービスの普及が期待されている。一方, 社会の高齢化にともない, 高齢者 (特に独居の場合) の家庭内の生活行動を見守ることは, 安否確認だけでなく, 認知症の早期発見や, 生活行動の変化に基づいた適切なタイミングでの問いかけ (離れた家族から電話をかけるなど) による高齢者の QOL (Quality of Life) 向上などの観点でも, 重要性が今後さらに増してくると考えられる。家庭内生活行動見守りのため

<sup>1</sup> 株式会社東芝研究開発センター  
Corporate Research and Development Center, Toshiba Corporation, Kawasaki, Kanagawa, 212-8582, Japan

<sup>a)</sup> kazushige.ouchi@toshiba.co.jp

には、部屋間の移動、食事、掃除、炊事、洗濯、入浴、排泄など、様々な行動の認識が必要となるが、屋内ではGPSによる測位が使えず、また単一の加速度センサでこれらの行動を精度良く把握することは困難であるため、上述の小型情報端末上の状況依存型サービスとは別のアプローチがこれまで試みられてきた。たとえば、家庭内のいたるところに各種センサを配置し、複数のセンサ情報を統合してユーザの行動を判断する取り組みがある [1], [2], [3]。専門の施設などではこのような方式による実運用の可能性も考えられるが、一般の家庭に持ち込むためには、設置コスト、運用コストが大きな問題となる。これらに対し、我々は、携帯電話などの一般的な小型情報端末にすでに搭載されている加速度センサとマイクによる家庭内の生活行動見守りを検討している。簡易で安価なドア開閉センサ程度であれば、一般家庭でもコスト的に許容でき、提案する手法と環境側センサによる位置推定とを併用することによるさらなる性能向上の可能性も考えられるが、環境側センサとの連携は、本論文で提案する一般的な小型情報端末単体のみによる生活行動認識をベースとしたうえで、想定するサービスごとに必要とされる性能、許容されるコストなどをふまえて検討されるべきであると考え。

本論文では、まず、小型情報端末を用いた状況認識に関する関連研究を概観し、我々の目指す方向性を明らかにする。次に、加速度センサの情報を活用してユーザの動作状態を大まかに分類し、推定した状態に応じて環境音を分析して詳細な作業状態を分類する提案手法について説明する。続いて、加速度データ、音データを同期記録可能な試作デバイスとPCの構成でリアルタイムに生活行動を認識するシステムを開発し、実際の家庭内生活のデータを収集して、提案手法の基本性能および実用性能を確認した結果を述べ、最後に考察する。

## 2. 関連研究

身体に装着した加速度センサによりユーザの動作状態を認識する研究は多い。たとえば、加速度センサを左右の肩、肘、手首、腰、膝、足首に計12個装着した研究 [4] や、上腕、手首、腰、太腿、足首に計5個装着した研究 [5] などがあり、多いものでは20種類の動作状態の推定を行っている。複数の加速度センサを装着することで、詳細な動作状態の推定が可能となるが、日常生活でこれらのように多数の加速度センサを常時身につけることは、拘束性が高く受け入れがたい。

これに対し、近年、携帯電話への加速度センサの搭載が進んでいる。このような背景のもと、携帯電話内蔵の単一の加速度センサを活用した動作状態認識の研究も行われている。たとえば、携帯電話内蔵の3軸加速度センサのデータを基に、歩行、速歩、階段上り、階段下り、走行の5動作状態を約80%の精度で認識する研究 [6] がある。他の研

究 [7], [8] でも歩行、走行を含む4種類程度の動作状態推定を行っている。我々がターゲットとしている家庭内生活行動見守りのためには、歩行、走行などの動作状態だけでなく、家事などの作業状態も認識対象とする必要があるが、単一の加速度センサだけで作業状態を推定することは困難である。

一方、携帯電話には通話用のマイクがあるため、これをセンサとして活用することも可能である。環境音の分析による状況推定に関する研究としては、音特徴量のみで屋内外17種類の生活シーンを平均68.4%の精度で分類する取り組み [9] などがある。しかし、加速度センサのデータは、たとえば10bit、20Hz程度でサンプリングすればよいが、文献 [9] では16bit、48kHzで音データをサンプリングして分析している。環境音分析では、加速度の分析に比べて扱うデータ量が3桁以上増え、また、周波数成分の抽出のためにはFFT (Fast Fourier Transform) を実行するなど、ある程度の計算量を要する処理が必要となり、環境音分析を常時行うこと（音声認識を常時動かし続けることに相当する）はできれば避けたい。また、音声認識では、入力意図のある発話だけ切り出して認識することが音声認識精度向上に有効である [10] ことから、環境音分析を行う場合においても、分析すべき区間を切り出して認識させる手法が有効であると考えられる。そこで、我々は加速度センサでユーザの動作状態を大まかに推定し、推定した状態に応じて環境音分析を実施する手法を提案する。

携帯電話に搭載された加速度センサとマイクを活用した状況認識に関する研究としては、加速度センサ、マイク、GPSを用いてユーザの移動状態を推定する報告がある [11]。走行、歩行、停止に加えて自転車、電車、バス、自動車などの移動状態を推定する場合、加速度センサだけでは精度が低下するため、マイクからの環境音とGPSの位置情報とあわせて分析することで精度向上を図っている。具体的には、加速度センサで移動状態が電車、バス、自動車のいずれかであると判断した場合にマイクを使って自動車であるかそれ以外であるかを判断する。その後、電車とバスの判断にはGPSから得られる位置情報の時間変化を使っている。他にも携帯電話に複数のセンサを搭載してユーザの状態を推定する試み [12], [13] が行われているが、文献 [12] では携帯電話のマナーモードへの自動切替えなどを行うためにユーザの状態をNormal/Idle/High Activity/Uninterruptibleの4つに分類し、文献 [13] では動作状態としては歩行、走行、着席の3状態を推定しているなど、家庭内生活行動の推定は行われていない。これに対し、我々のターゲットは家庭内の生活行動見守りであるため、推定対象は移動状態だけでなく家事などの生活状態も含む点異なる。

また、携帯電話ではなくウェアラブルセンサを用いた行動認識に関する研究もある。手首、腕、胸元などに加速度

センサ、マイクを複数装着して、木工作業場における8種類程度の作業の識別を行った研究がある[14]。また、加速度センサ、マイクに加えて、カメラが搭載されたウェアラブルセンサを手首に装着して、歯磨き、掃除機がけ、皿洗い、コーヒーを作る、ココアを作るなど、15種類程度の生活状態の認識を行っている研究もある[15], [16]。これらの取り組みでは、身につけるセンサ数を増やす、あるいはカメラで操作対象物の画像の特徴をとらえることで、細かな行動の識別を試みている点が特徴である。これらの取り組みに対し、我々は、特別なデバイスを必要とせずに、日常的に使われている携帯電話単体による家庭内の主要な生活行動の認識を目指している点が異なる。また、これまで加速度と音を同時に解析して行動を識別する手法が試みられてきたが、我々はまず加速度で大まかな動作状態を分類し、必要な場合のみ音による作業状態分類を行う点が異なる。

### 3. 加速度と音による家庭内生活行動認識

#### 3.1 認識対象とする生活行動

一口に生活行動といってもその内容は多岐にわたる。このため、食事、着替え、移動、排泄、整容、入浴など生活を営むうえで欠かせない基本的な活動を指す日常生活動作(ADL: Activities of Daily Living)と、炊事、掃除、洗濯などの家事全般や、金銭管理、服薬管理、外出など、ADLより複雑で高次の活動を指す手段の日常生活動作(IADL: Instrumental Activities of Daily Living)による評価が高齢者介護やリハビリテーションの分野で用いられている。高齢者・障がい者の生活自立度評価の際には、バーゼルインデックス<sup>\*1</sup>に代表されるADLの評価だけでは不十分で、IADLも重要な指標であるとされている[17], [18]。

また、認知症の在宅ケアではセンタ方式(認知症の人のためのケアマネジメントセンタ方式)[19], [20]という認知症の人のためのケアマネジメントシートが用いられている。認知症患者本人、家族、ケア関係者が共通のシートを使って、対話しながら効果的な支援策を見つけていくためのもので、その中のD-1(私ができること・私ができないことシート)では、ADL, IADLに相当する暮らしの場面が22項目あり、それぞれについて自分でできるかどうか、定期的に記入していく。これらの項目の大半あるいは一部だけでもセンサの活用で負担なく取得できたり、患者によって特に着目すべき項目について、日々の状態が連続的にモニタできたりすることは、認知症ケアにとっても重要であると考えられる。よって、我々が目指す小型情報端末による家庭内生活状態見守りでは、ADL, IADLの両方を認識対象とする。

<sup>\*1</sup> Barthel Index: 食事、車椅子からベッドへの移動、整容、トイレ動作、入浴、歩行、階段昇降、更衣、排便、排尿のADL10項目を2~4段階で評価。

なお、本論文では、主に高齢者の家庭内生活行動見守りのために検出すべき作業状態として、ADL, IADLの中から家事、排泄管理、整容の代表的なものについてデータ収集を行い、提案手法による生活行動認識の基本的な適用可能性を確認する。しかし、今回対象とする作業状態以外にも、家事であれば、炊事、洗濯など、排泄以外の基本的な生活行動としては食事、睡眠、入浴、着替えなど、整容であれば洗顔、化粧など、ADL, IADLには他にも分類対象として検討すべき生活行動が多く存在する。

また、総務省統計局の平成18年(2006年)の調査結果[21]によれば、平成13年(2001年)に比べて特に高齢者は男女ともに家事関連の生活時間が増加している。また、身だしなみ、化粧、入浴、トイレなど身の回りの用事生活時間は、高齢になるほど長くなり、全年齢で10年前に比べて顕著に増加している。このことから、高齢者の家事や身の回りの用事に関する生活行動を見守ることは今後さらに重要性が増すと考えられるため、分類対象とする生活行動の数を増やす方向で検討を進める方針である。

ただし、今後、様々なユースケースを検討していくうえで、そのユースケースにとって分類が必要な作業状態のうち、音に基づいた作業状態分類が困難な場合も想定される。たとえば、食事、睡眠など、人間の基本的な生活状態の取得は、高齢者・障がい者に限らず生活習慣の管理には重要である。しかし、本論文で提案した手法では、食事については、動作状態が「作業」だけでなく「安静」と判断される可能性があり、また、食事にもなう音(咀嚼音、食器の音など)に加えて、複数人で食事をしている場合は、他の人が発する音や会話の音、場合によってはTVやステレオの音なども含まれるため、本手法では分類が難しいと想定される。また、睡眠時はほとんどの時間が「安静」と判断されることになり、時刻と合わせることである程度は推測できるが、直接的には分類が困難である。

これらについては、ターゲットとしたユースケースにおいて許容される拘束性に依存するが、腕時計型の生体センサを装着して、脈波、手の動き(加速度)、皮膚温度、皮膚電気反射(GSR: Galvanic Skin Response)などを計測することによる食事検出[22]、脈波、体動を計測することによる睡眠状態計測[23]などが可能であり、これらの計測手法と本提案手法とを組み合わせる利用形態も考えられる。

#### 3.2 想定するサービスイメージ

上述のとおり、日常生活において負担なくADL, IADLを継続的にモニタリングすることは、特に高齢者、障がい者、認知症患者などにとって重要であるが、対象者によってモニタすべきADL, IADLは異なることが考えられる。たとえば、特定の部位に身体的な障がいを持っている人と、認知症の人とでは、モニタすべきADL, IADLは異なることが想定される。

また、家電機器（掃除機、電気シェーバなど）の動作音、キッチンやトイレの水洗面などは家庭によって異なり、歯磨きに一般的な歯ブラシを使用するか/電動歯ブラシを使用するかなど、同じ生活行動において発生する音は対象者や環境によって異なる。あらゆる環境に適用可能な汎用性の高い生活行動認識の実現が最終的には理想であるが、本研究では、次のようなサービスイメージを想定した場合に有用であると考えられる手法を提案する。

独居の高齢者や、障がい者、あるいは認知症患者（以下、対象者とする）などの生活状態をモニタリングするため、その家族あるいはケア関係者が、対象者の見守りに必要なADL, IADLのデータを収集する。つまり、立ち会いの下で認識対象の各生活行動を行ってもらい、その際に収集したデータをシステムに学習させ、各生活行動を認識させる。その際、学習に必要な時間が長いと双方にとって負担になるため、学習はできるだけ短い時間で完了することが必要である。短い時間のデータで学習を行うことは、学習時の計算量、計算時間の短縮、および省電力の点からも望ましい。モニタする本人の実際の生活行動のデータを学習するため、家庭による音の違い、使用する機器による音の違いなどがなく、短い学習時間であっても、精度良い認識が可能になることが期待できる。認識結果は、リアルタイムにサーバへアップロードして家族あるいはケア関係者がいつでもモニタリングできるようにする、あるいは携帯電話内に記録して後から参照するなど、用途によって必要なリアルタイム性に応じた構成とする。このようなサービスが実現されると、たとえば、いつも必ず1日3回歯磨きをしていた対象者が歯磨きのし忘れが増えてきたことに（見守る側の）家族が気づいたときにさりげなく電話をかけて近況を確認するなど、認知症の予兆の早期発見や、QOL向上などへの貢献が期待できる。

上記サービスを実現するため、本論文ではまず、ADLの移動の基本行動としての「歩行」、整容に含まれる「歯磨き」、「電気シェーバによる髭剃り」、「ドライヤーの使用」、排泄と関連する「トイレ水洗/手洗い」、およびIADLの家事に含まれる「掃除機がけ」、「皿洗い」、「アイロンがけ」を対象として、提案手法による家庭内生活行動認識の適用可能性を検証する。なお、これらの生活行動は、一般的な独居高齢者向けのモニタリングを想定して選択した。3.1節で触れたセンタ方式D-1の全項目数の約1/3に相当する。

なお、提案手法は、一般的な携帯電話を身につけるだけで複数の家庭内生活行動を認識できる点を特長とする一方で、家庭内でも携帯電話を持ち歩くことを前提としている。この前提条件は、これを身につけることで離れた家族が自分を見守ってくれるという安心感に加え、複数の家電を簡単に操作できるマルチリモコン機能など、家庭内の様々な場所でユーザにメリットがある機能を提供することにより、許容されるとの立場で議論する。

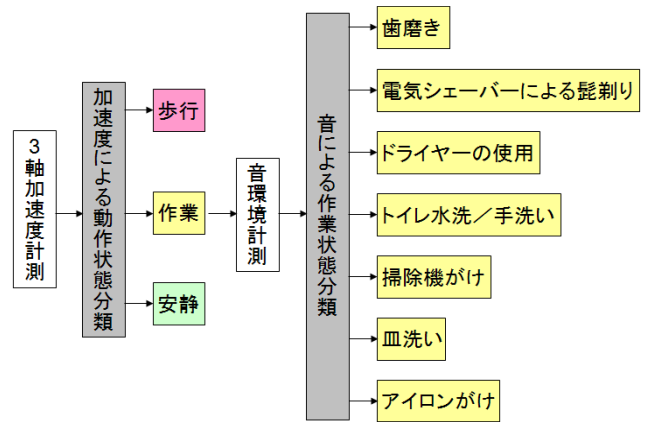


図1 提案手法の処理の流れ

Fig. 1 Processing flow of the proposed method.

### 3.3 処理概要

本論文で提案する家庭内生活行動認識手法の処理概要を図1に示す。本手法では、まず、加速度センサのデータにより、動作状態を「歩行」「作業」「安静」の3つに分類する。「作業」とは、歩行以外に、身体的動きをとまらぬ何らかの生活行動をしていると想定される状態のこととし、「安静」とは「歩行」も「作業」もしていない、身体を動かしていない状態のこととする。なお、本論文では「階段昇降」も「歩行」と分類することとした。家庭内の生活行動としては部屋間の移動が分かれば、生活行動の切替わりを検出する手がかりとなるため、今回はこれらをすべて「歩行」とすることとした。ただし「階段昇降」を「歩行」とは別に分類することも今後検討していきたい。

次に、「作業」と分類された場合にはマイクを起動し、周囲の環境音を分析して作業内容を推定する。本論文では、「歯磨き」、「電気シェーバによる髭剃り」、「ドライヤーの使用」、「トイレ水洗/手洗い」、「掃除機がけ」、「皿洗い」、「アイロンがけ」を分類することを検討した。2章に述べたとおり、単一の加速度センサで複数の作業状態を推定することは困難であるが、まず加速度センサで判別可能な動作状態に分類し、「安静」でも「歩行」でもない「作業」状態について、マイクからの音データを用いて推定しようとする点が、従来研究と異なる点である。以下、加速度による動作状態分類、音による作業状態分類について、詳しく説明する。

### 3.4 加速度による動作状態分類

加速度による動作状態分類は、上述のとおり常時動作させ続ける想定であるため、できるだけ計算負荷の低い処理にする必要がある。そこで、統計量として1秒間の分散のみを用いる簡便な手法を用いることとした。処理の流れを図2に示す。

ユーザの胸ポケットに入れたデバイス（本研究では携帯電話を想定している）に内蔵した3軸加速度センサの測定




図 2 加速度による動作状態分類

Fig. 2 Classification of movement condition by acceleration.

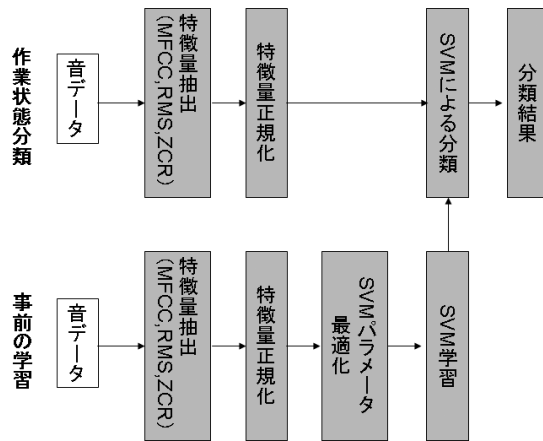


図 3 音による作業状態分類

Fig. 3 Classification of living activities by microphone.

データを用いる。文献 [8] にあるように一定の時間幅内の平均加速度方向が重力加速度方向と推定し、重力加速度方向の加速度の 1 秒間の分散を算出する。これは歩行時に最も顕著に加速度変化が現れるのが重力加速度方向であるため、この分散の大きさによって「歩行」か否かを判断する。ここでは、閾値を実験的に  $0.05 [G^2]$  と定めた。

「歩行」以外の場合には、3 軸の各加速度の 1 秒間の分散を算出し、最大の分散を持つ軸の値の大きさによって、「作業」か「安静」かを弁別する。その閾値は  $0.0001 [G^2]$  とした。これは、平方根をとって標準偏差とすると  $0.01 [G]$  となり、睡眠・覚醒判別の際に体動の有無を検出する加速度の大きさとして広く使われている基準値と同一である [24], [25]。

以上のように、3 軸加速度の 1 秒間の分散のみを用いる簡便な手法により、「歩行」、「作業」、「安静」の 3 種類の動作状態を分類する。

### 3.5 音による作業状態分類

動作状態が「作業」と分類された場合に、マイクを起動し音による作業状態分類を行う。処理の流れを図 3 に示す。音による作業状態分類では、事前に分類対象の作業状態の音データを学習しておく。分類器には、高い汎化性能を持つサポートベクタマシン (SVM: Support Vector Machine) を用いることにした。

音データから抽出する特徴量としては、広く音声認識に使われているメル周波数ケプストラム係数 (MFCC: Mel

Frequency Cepstral Coefficients) に加え、算出に際して計算量の比較的少ない二乗平均平方根 (RMS: Root Mean Square), ゼロ交差率 (ZCR: Zero-Crossing Rate) の使用をあわせて検討した。MFCC は人間の聴覚上重要な周波数成分を強調した特徴量で、文献 [9], [15], [16] など音を活用した状況認識に関する関連研究でも使われており、我々も MFCC を使用することとした。また、RMS は主に音の強度を表し、ZCR は当該区間の音高 (ピッチ) に相当する特徴量で、これらは MFCC に含まれない音の特徴を表すため、これらを MFCC に追加することによる性能向上を期待した。今回用いる音データは 16 bit, 16 kHz サンプリングのデータを用いることとし、各特徴量算出の際のウィンドウ幅は 512, ウィンドウオーバーラップは 0 とし、1 秒ごとにそれぞれの平均値を出力するようにした。

MFCC の算出方法自体の説明はここでは割愛するが、FFT, メル周波数フィルタ, log, 離散コサイン変換 (DCT) などの処理が行われるため、ある程度の計算コストが必要となる。よって、本手法では音による解析を常時実施せず、計算コストが少ない加速度による動作状態分類をまず行い、その結果「作業」と分類された場合のみ音による作業状態分類を行う。実運用時にはさらにある程度の尤度を持って作業状態を推定できた場合は、音による作業状態分類をいったん終了させて、その作業状態が継続しているものとし、作業状態からいったん別の動作状態 (安静, 歩行) が発生して、その後再度作業状態に移行した場合に改めて音による作業状態分類を行うようにするなど、さらなる計算量, 消費電力削減の工夫が必要になってくると考えられる。なお、MFCC の次数は 13 とした。

$N$  個 (ウィンドウ幅. ここでは  $N = 512$ ) の音データ  $\{a_1, a_2, \dots, a_N\}$  の RMS ( $a_{rms}$ ) は、

$$a_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N a_i^2}$$

で算出する。同じく ZCR ( $a_{zcr}$ ) は、

$$a_{zcr} = \frac{1}{N-1} \sum_{i=2}^N F\{a_i a_{i-1} < 0\}$$

で算出する。ここで、関数  $F\{A\}$  は、 $A$  が TRUE の場合に 1 となり、そうでない場合に 0 となる関数である。このように、RMS, ZCR は、MFCC に比べて計算量が少なく、MFCC に含まれない特徴を表す特徴量である。抽出した合計 15 次元 (MFCC: 13 次元, RMS: 1 次元, ZCR: 1 次元) の特徴量は、それぞれでスケールが異なるため、 $\pm 1$  で正規化を行う。

SVM ライブラリには LIBSVM [26] を利用し、SVM タイプは C-SVC, カーネル関数は RBF (radial basis function) を使用した。学習時には、LIBSVM が提供する最適パラメータ ( $C, \gamma$ ) をヒューリスティックに探す Grid search

を用いて最適パラメータを取得し、そのパラメータで学習を行う。作業状態分類時には、1秒ごとの特徴量平均算出のたびに、SVMによる分類を実行し、作業状態の分類結果を1秒ごとに得る。

### 3.6 事例ベース認識手法

ここまでは、動作状態および作業状態を毎秒出力する提案手法の基本的な処理動作について説明した。しかし、実用を想定すると、毎秒の分類性能よりも、作業として連続した区間全体が正しい作業として分類されたかどうかが重要である。そこで、連続して切り出された1つの作業区間は同一の作業が継続しているものとし、切り出した区間全体の作業状態を判定する事例ベース認識手法を検討する。

事例ベース認識手法の概念図を図4に示す。この例は、加速度センサによる動作状態分類で「歩行」、「作業」、「安静」の順に分類され、「作業」の分類結果は「作業1」、「作業2」、「作業3」が混在しているが、この「作業」は全体として、分類された数が最も多い「作業1」と判断している。また、この例では「安静」中に単発的な「作業」が発生しているが、このような単発的な動作状態変化を無視することとし、動作状態変化のばたつきを軽減する。

本論文では、事例ベース認識手法の導入の妥当性を検証するため、1作業区間の中で最も出現回数の多い作業状態




図4 事例ベース認識手法の概念図

Fig. 4 Conceptual diagram of instance-based recognition.



3軸加速度センサ	LIS344ALH (STMicroelectronics) ±2G/6G 10bit 20Hz サンプリング
MEMS マイク	SPM0408HE5H (Knowles) 8/16bit 8/16/32kHz サンプリング
記録メディア	microSD カード
オーディオ/ファイル制御用 CPU	ARM Cortex-M3
システム制御用 CPU	PIC18LF4685 (Microchip)
オーディオ LSI	ML2308 (OKI)
通信機能	Bluetooth™ SPP / A2DP

図5 試作した評価用デバイスと概略仕様

Fig. 5 Appearance and outline specification of the developed prototype device.

をその区間の正解候補とし、その出現頻度が全体の50%以上であれば、その区間全体が正解候補の作業状態とする。50%未満の場合は、分類対象外(未学習)の「作業」が行われていることと判断する。

## 4. リアルタイム生活行動認識システム

前章で提案した手法の妥当性を評価するためには、実際の生活状態の加速度と音を同期させて記録し、分析する必要がある。最終的には携帯電話などの小型機器単体での状況推定を目指しているが、そのための基礎的なデータ収集を効率的に行うことを目的に、3軸加速度センサとマイクを搭載し、両センサのデータをmicroSDカードに同期記録できる評価用デバイスを試作した。デバイスの外観と概略仕様を図5に示す。

データ収集時には、本デバイス単体で動作してmicroSDカードに加速度センサとマイクのデータを同期記録する。また、Bluetooth™モジュールを搭載しており、PCなどの外部機器に加速度データはSPP (Serial Port Profile)で、音データはA2DP (Advanced Audio Distribution Profile)でPCに送信し、PCで3章に示した一連の処理を実行してリアルタイムに生活行動を認識する「ActivityAnalyzer」を開発した。認識結果表示の一例を図6に示す。

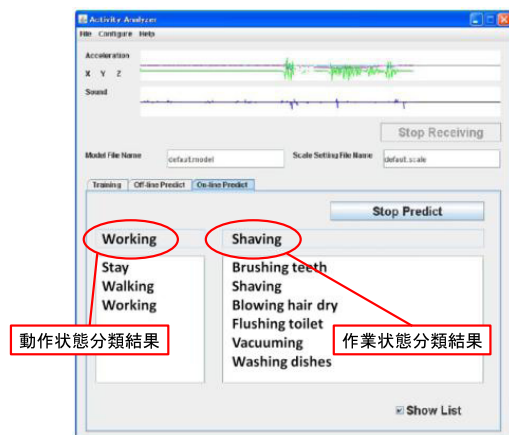


図6 リアルタイム生活行動認識システム「ActivityAnalyzer」

Fig. 6 Real-time living activity recognition system "ActivityAnalyzer".

## 5. 基本性能評価

### 5.1 データ収集条件

まず、3.3~3.5節で説明した、毎秒実施する動作状態分類および作業状態分類の基本性能を確認するデータ収集実験を実施した。試作した評価用デバイスを胸ポケットに入れ、一般の家庭における日常生活のデータ収集を実施した。被験者4名(60代男女, 30代男女, それぞれ1名ずつ)に対して行動リスト(被験者ごとに順番を入れ替えた)を提示し、それに従ってひととおり行動してもらった実験を、日を変えて2日分実施し、被験者1名あたり2データセット、計8データセットを収集した。本実験は、提案手法の基本性能を確認することを主眼としているため、被験者数は4名(年代の違いによる影響も確認するため、60代と30代の被験者で実施した)と少ないが、10秒間の学習データによる作業状態分類性能について、他人のデータを学習した場合の性能と、本人のデータを学習した場合の基本性能の違いを確認する目的で実施した。

分類対象とした生活状態と、それぞれの平均収集時間は表1のとおりである。連続して収集したデータから、対象の生活状態に該当する部分のデータを切り出し、分析対象とした。なお、「歯磨き」は電動歯ブラシではなく一般の歯ブラシによる歯磨きのデータを収集した。「電気シェーバによる髭剃り」は男性被験者2名のみ実施した。また、排泄中は「安静」と判別される可能性が高く、排泄後にトイレの水洗と手洗いをする際に「作業」となることが予想されることから、今回のデータ収集では、被験者に便座に座ってもらい、そこから立ち上がってトイレを水洗し、手を洗うように指示し、その際のデータを収集した。

3.2節にも述べたとおり、本研究では、できるだけ短時間の学習データで、精度良い生活行動認識を実現する点を目的としている。よって、「作業」の7種類の分類性能の評価方法は、収集した全データセットのうち1データセットをテスト用とし、残りを学習用として、全データセットが1回ずつテスト用となるように評価を実施する Leave-one-out Cross-validation とは異なる評価方法を用いることとした。

表1 データ収集した生活状態とその平均時間

Table 1 Collected target activities and their average duration (min.).

生活状態	平均時間 (分)	
歩行 (階段昇降も含む)	1.15	
作業	歯磨き	1.14
	電気シェーバによる髭剃り	0.88
	ドライヤーの使用	1.48
	トイレ水洗/手洗い	0.45
	掃除機がけ	3.18
	皿洗い	1.55
	アイロンがけ	1.67
安静 (TV鑑賞)	3.24	

つまり、収集した全8データセットの生活状態データのうち、1データセットから各生活状態についてそれぞれ無作為に連続した10秒分のデータを学習用として抽出し、それ以外の7データセットの各生活状態のデータをテスト用として分類する。次に別の1データセットから再度、無作為に連続した10秒分を新規の学習用データとして抽出して同様のテストを行う。これを全データセットから1回ずつ学習用データを抽出するようにして評価を行った。

最適な学習時間については、実運用時の観点も含めた検討が今後必要であるが、3.2節で述べた、我々が想定するサービスイメージのためには、極力短い時間で学習できるようにすべきであると考え、それぞれ10秒分ずつという少ない学習データで分類を試みた。分類器に汎化性能の高いSVMを選択したのはこのためでもある。

### 5.2 結果

#### 5.2.1 加速度による動作状態分類性能

加速度による動作状態分類(「歩行」, 「作業」, 「安静」のいずれかに分類する)の結果を表2に示す。数値は、分析対象の生活状態の全データのうち、正しくその動作状態(「歩行」, 「作業」, 「安静」)に分類されたデータの割合、すなわち適合率を示す。「歯磨き」, 「電気シェーバによる髭剃り」など作業状態に含まれる各生活状態は、ここでは「作業」に分類されることが正解となる。過去1秒間の分散を1サンプリング(50ms)ごとに算出し、そのつど動作状態分類を実施した。加速度の1秒間の分散のみを用いた分類法で、おおむね95%以上の精度で「歩行」, 「作業」, 「安静」を分類できていることが分かる。なお、今回は4名の被験者全員で3.4節に示した同一の閾値を適用して表2の結果を得たが、対象者の身体状態(年齢, 障がいの有無)などによっては、学習時に適切な閾値設定が必要になる可能性がある。ただし本実験では、30代被験者, 60代被験者で年代の違いによる性能差は確認されなかった。

「掃除機がけ」の際には掃除機をかけながら移動する際の歩行も発生するが、掃除機をかけながらの歩行の大半は「作業」と分類された。3.4節で説明した手法で、掃除中に

表2 加速度による動作状態分類性能

Table 2 Classification accuracy of movement condition by acceleration sensing.

生活状態	動作状態分類性能 (%)	
歩行 (階段昇降も含む)	95.4	
作業	歯磨き	98.6
	電気シェーバによる髭剃り	99.5
	ドライヤーの使用	92.9
	トイレ水洗/手洗い	95.5
	掃除機がけ	97.6
	皿洗い	98.5
アイロンがけ	99.5	
安静 (TV鑑賞)	97.5	

表 3 音による作業状態分類性能 (全被験者データによる評価)

Table 3 Classification accuracy of living activities by using every subjects' data.

生活状態 (作業)	作業状態分類性能 (%)
歯磨き	68.3
電気シェーバーによる髭剃り	91.4
ドライヤーの使用	91.6
トイレ水洗/手洗い	71.7
掃除機がけ	70.2
皿洗い	67.2
アイロンがけ	70.3
平均	75.8

において姿勢をかがめたりしながらの移動は、部屋移動のための歩行と区別できることが分かった。

### 5.2.2 音による作業状態分類性能

加速度による動作状態分類で「作業」と分類された際に実行する、音による作業状態分類の結果を表 3 に示す。MFCC, RMS, ZCR の各特徴量を 1 秒ごとに算出し、それを用いて 1 秒単位で作業状態分類を実施し、正しくその作業状態に分類されたデータの割合 (適合率) を示す。作業状態ごとに多少の性能のバラツキはあるが、任意の 10 秒間の学習データで平均 75.8% の分類性能があることが確認できた。

「電気シェーバーによる髭剃り」、「ドライヤーの使用」については、90%以上の精度で分類できているが、その他の生活状態については、いずれも 70%程度の精度であった。原因としては、「歯磨き」については、電動ではない歯ブラシによる歯磨きのデータを収集したが、歯磨きで発生する音の特徴が被験者によって異なるためであると考えられる。「トイレ水洗/手洗い」、「皿洗い」は、それぞれ水洗時の水量を指定せずに被験者任せとしたため、被験者によってバラツキが出たと考えられる。「掃除機がけ」についても同様に動作モードは被験者任せとした。極力自然な生活状態のデータを収集することを主眼に置いて実施したことによる影響ではあるが、逆にいえば、水量や、動作モードが異なるデータを学習しても、約 70%程度の精度で同一の作業状態として分類できることが分かった。

しかし、本研究では、3.2 節で述べたとおり、対象者本人のデータを学習データとして用いることを当面のターゲットとして考えているため、今回収集した各被験者の 2 データセットのうち、1 データセットから任意の 10 秒間を抽出して学習データとし、別の 1 データセットをテスト用として評価し、次に逆の組合せで同様のテストを実施した場合とあわせて分類性能を評価した。表 4 にその結果 (全被験者の平均) を示す。本人の学習データを用いることによって、全体として約 10 ポイント、性能が向上することが分かった。想定したサービスイメージに対する手法として、提案手法が有用であることが確認できた。また、30 代被験者、60 代被験者で年代の違いによる性能差は確認され

表 4 音による作業状態分類性能 (本人データの学習による評価)

Table 4 Classification accuracy of living activities by using subject's own data.

生活状態 (作業)	作業状態分類性能 (%)
歯磨き	73.0
電気シェーバーによる髭剃り	91.9
ドライヤーの使用	96.1
トイレ水洗/手洗い	94.5
掃除機がけ	87.0
皿洗い	81.9
アイロンがけ	77.2
平均	85.9

なかった。

目標とすべき性能は、想定するサービスによって異ってくるが、上述の結果から示唆されることは、サービス提供側が平均 75%程度の性能で十分と判断する用途であれば、汎用の学習データを用いて個人ごとの事前学習は不要のサービスを提供できるが、それ以上の性能を必要とする用途に対しては、事前学習を行うことにより性能を向上させることが可能であるということである。

ただ、「歯磨き」については、本人のデータを学習した場合でも 73.0%の精度であった。精度が上がらない原因を調べたところ、任意に選んだ学習データ 10 セットが、前歯を磨いているときのデータのみだった場合、奥歯を磨いている際の性能が著しく低下していたことが分かった (逆の場合や、口の開き具合の違いの影響なども考えられる)。前歯磨きから奥歯磨きに変わった時点の検出結果の一例を図 7 に示す。前歯磨きの間はおおむね精度良く歯磨きと分類できているが、奥歯磨きになった時点から誤検出の割合が増加している。前歯磨きと奥歯磨きで、そのときに発生している音の特徴が異なることが原因である。そこで、前歯磨きのときの 5 秒間と奥歯磨きの 5 秒間を手作業で抽出した合計 10 秒間のデータを歯磨きの学習データとして再学習させたところ、73.0%だった分類性能を 80.6%に改善できることが確認できた。

このように、同一の作業状態において、途中で音の特徴が変化するような場合は、それぞれの場合のデータを学習データに含めるようにする、あるいは SVM にそれぞれ別のクラスとして分類させるなどの工夫が必要になることが分かった。ここで、1 データセットの歯磨きのデータ全部を学習データとして再学習させたところ、分類性能は 81.9%となった。このことから、全データの中から音の特徴をバランス良く抽出することで、10 秒間だけのデータでも、全データを学習させた場合と同等レベルの性能を示すことができることが示唆された。最適な学習区間の抽出方法については、今後検討していく。






図 7 歯磨き時の分類結果の一例

Fig. 7 Example of classification result during brushing teeth.

## 6. 実用性能評価

### 6.1 データ収集条件

前章の実験で提案手法の基本性能の妥当性を確認できた。これを受け、次に 3.6 節で述べた事例ベース認識手法による実用性能を確認するデータ収集実験を行った。本実験では、提案手法のターゲットである高齢者向けのサービスを想定し、60代の被験者 10 名 (60代男女、それぞれ 5 名ずつ) に対してデータを収集した。前章の実験同様に、評価用デバイスを胸ポケットに入れ、一般家庭のリビングを模した実験室において日常生活のデータ収集を実施した。

まず「皿洗い」、「掃除機がけ」、「アイロンがけ」、「トイレ水洗/手洗い」、「歯磨き」の各作業を 10 秒ずつ行ってもらい、これを学習用データとし、続いて上記の「作業」を順番に任意時間ずつ実行してもらおうこととし、「作業」と次の「作業」の間は 1 分間以上、実験者との会話や、ストレッチなど、自由にすごしてもらおうこととした。このデータは分類対象外 (未学習) の「作業」となる。なお、本実験で実施した 5 種類の日常生活における作業は、リビングを模した実験室内で実施可能なものがこの 5 作業であったため選択した。このようにして、評価用データとして、被験者ごとに 5 種類の「作業」と、「作業」間の 5 データを、それぞれ合計 50 データセット収集した。

### 6.2 結果

全テストデータの分類結果を表 5 の混同行列に示す。5 つの学習済み「作業」の分類結果は 98% (49/50) の精度で正しく分類され、対象外「作業」は 82% (41/50) の精度で正しく分類された。事例ベース認識手法の導入により、「作業」ときに毎秒実施する作業状態分類そのものの性能を凌駕する実用性能を確認できた。しかし、対象外「作業」の 9 事例 (身振り手振りを交えた立ち話 3 事例、会話しながらストレッチ 4 事例、ストレッチのみ 2 事例) については、本来分類対象外 (未学習) と分類すべきところを、「皿洗い」、「アイロンがけ」、「トイレ水洗/手洗い」と誤認識している。認知症予兆の早期発見などを期待した高齢者の見

表 5 事例ベース認識手法による分類結果の混同行列

Table 5 Confusion matrix of instance-based recognition.

	学習済み「作業」					対象外「作業」
	皿洗い	掃除機がけ	アイロンがけ	トイレ水洗	歯磨き	
皿洗い	10	0	0	0	0	0
掃除機がけ	0	10	0	0	0	0
アイロンがけ	0	0	10	0	0	0
トイレ水洗/手洗い	0	0	0	10	0	0
歯磨き	0	0	0	0	9	1
対象外「作業」	3	0	4	2	0	41

守りサービスを想定すると、実際には対象外の行動をしているにもかかわらず、何らかの見守り対象の行動をしているものと判断してしまうため、この種の誤認識は対象者の生活レベルの正確な把握に影響を及ぼす可能性がある。

この問題の解決には、基本的な分類性能の向上が期待されるが、学習済み「作業」の判断のための、その区間で最も出現回数が多い「作業」状態の出現頻度の閾値  $T$  を 50% よりも高く設定し、50%以上  $T$  未満の場合は対象者に問い合わせる機能などによって正解率を向上させる工夫などが考えられる。高齢者であれば、「はい」「いいえ」で回答できる音声対話などが適していると考えられるが、対象者に負担をかけない提示方法が必要である。また、この際に新しく取得したデータで再学習することで、認識性能が向上する可能性がある。

## 7. 考察

提案した加速度と音を組み合わせた家庭内生活行動認識手法が有用であるかは、従来の加速度のみ、あるいは音のみでの行動認識手法と比較して検証する必要がある。文献 [6], [7], [8] などの関連研究で単一の加速度センサで認識対象とする動作は、現状、歩行、走行など、移動を中心とした数種類の動作状態だけで、本論文で対象とするその他の作業状態を認識することは困難であるため、加速度セン

表 6 「歩行」分類性能と対象データサイズの比較  
Table 6 Comparative result of “walking” classification.

分類に使用するデータ	「歩行」分類性能 (%)	1 秒間データサイズ (Byte)
加速度 (10bit 20Hz)	95.4	75
音 (16bit 16kHz)	86.7	32,000

表 7 「安静」分類性能と対象データサイズの比較  
Table 7 Comparative result of “quiet” classification.

分類に使用するデータ	「安静」分類性能 (%)	1 秒間データサイズ (Byte)
加速度 (10bit 20Hz)	97.5	75
音 (16bit 16kHz)	88.8	32,000

サだけによる作業状態分類についてはここでは比較の対象としない。したがって、ここでは音だけで同様の生活状態分類を行う場合との比較検証を行う。

提案手法では、加速度センサで「作業」と分類した動作状態のみ、音によりさらに細かく作業状態分類を行っている。作業状態の分類は音だけを用いているので、比較すべきは、加速度センサで分類している「歩行」、「安静」となる。つまり「歩行」、「安静」の分類を音で行ったときと、加速度で行ったときとを比較すればよい。なお、加速度で「歩行」、「安静」の認識を行っている従来研究はあるが、装着部位、評価環境（屋内、屋外の違い）など条件が異なるため、同一条件による評価として、音による分類性能を提案手法の加速度による「歩行」、「安静」の分類性能と比較する。

3.5 節で述べた音による作業状態分類法と同じ方法で「歩行」「安静」を認識できるか確認した。一般家庭の廊下を歩行しているとき（歩行）と、TV を鑑賞しているとき（安静）の音データについて、任意の 10 秒分を切り出し、同一の音特徴量（15 次元）データをそれぞれ「歩行」「安静」クラスとして他の作業状態の各クラス（「皿洗い」、「掃除機がけ」、「アイロンがけ」、「トイレ水洗/手洗い」、「歯磨き」）に加えて学習させた。テストデータは学習データと同じ場所（一般家庭の廊下）を歩行した際、および同一の TV 番組（スポーツ中継）を視聴している際の音データ（歩行：1 分、安静：3 分）とした。場所が異なったり、番組が異なったりすると、環境音の変化により、著しく性能が劣化することが考えられるため、今回の比較では同じ場所の歩行、同一 TV 番組のデータを使うことにした。加速度による「歩行」認識、「安静」認識との比較を表 6、表 7 に示す。また、加速度の場合も、音の場合も、分類の際に処理する生データは 1 秒間分であるため、それぞれ処理対象である 1 秒間の生データのサイズも算出した。

音だけを使用して 86.7% の精度で「歩行」を分類でき、88.8% の精度で「安静 (TV 鑑賞)」を分類できることが確認できたが、加速度だけによる分類性能よりはそれぞれ劣る。また、分類のために必要な 1 秒間のデータサイズは、加速度の場合は 75 バイトであるのに対し、音の場合は 32,000

バイトと 3 桁大きいデータの処理が必要となる。このことから、「歩行」、「安静」を認識するためには、性能とデータ量（計算量）双方の観点から、加速度による動作状態分類を行うことが望ましいといえる。

また、「安静」時にユーザ自身から発せられる音は、呼吸音など非常に小さいレベルの音のみで、周囲の環境音の影響を大きく受けることが想定され、今回は同一の TV 番組を視聴中のデータで評価したが、（番組内容に依存しない）TV 視聴、読書、音楽鑑賞、睡眠など、音のみによる複数の「安静」検出はさらに困難であると考えられる。

まとめると、単一の加速度センサのみでは本論文が対象とする様々な作業状態を認識することは従来研究から困難であるといえるが、作業状態の推定にマイクからの音を用いることで、様々な作業状態の推定が可能となった。提案手法で、加速度のみで分類している「歩行」、「安静」について、これらもすべて音により分類した場合の分類性能、および扱うデータ量の比較を行い、「歩行」、「安静」ともに音を用いるよりも加速度を用いた方が、性能、データ量とも有利であることを確認した。提案手法によるデータ量（計算量、さらには消費電力に関係する）の削減効果は「作業」の発生頻度に依存するが、今後、携帯電話上に本手法の行動認識エンジンを搭載し、より実用に近い評価を実施して検証していく。

以上の観点から、加速度による動作状態分類で「歩行」、「作業」、「安静」を分類し、「作業」の場合に環境音分析を行って詳細な作業状態分類を行う提案手法の妥当性を確認することができた。

## 8. まとめと今後の課題

本論文では、環境側へ機器を設置せず、携帯電話などの小型情報端末にすでに搭載されている加速度センサとマイクのみを活用した生活行動見守りのための家庭内生活行動認識手法を提案した。まず加速度センサでユーザの動作状態を大まかに推定し、推定した状態に応じてマイクを起動して環境音の分析を行うことで、計算量を抑えた家庭内生活行動認識が可能となる。

胸ポケットに格納した試作デバイスで実際の家庭生活の

データを収集し、各作業状態につき任意の10秒間ずつの音特微量データをSVMに学習させて評価した結果、加速度センサのみで「歩行」、「作業」、「安静」の3状態をおおむね95%以上の精度で分類でき、「作業」時には環境音の分析を行うことで、「歯磨き」、「電気シェーバによる髭剃り」、「ドライヤの使用」、「トイレ水洗/手洗い」、「掃除機がけ」、「皿洗い」、「アイロンがけ」の各作業状態を平均75.8%の精度で、本人の学習データを用いた場合は平均85.9%の精度で分類できた。このことにより、提案手法が我々の想定する家庭内の生活状態見守りに活用可能な基本性能を持つことを確認した。また、事例ベース認識手法の導入により、実用的な性能が見込めることも確認した。なお、実際に認識が必要な作業の粒度、種類は、想定するサービス、ターゲットユーザによって異なってくるため、このあたりを具体化した評価は今後の課題とする。

分類器にSVMを用いることで、各生活状態につき任意の10秒間という少ない学習データでも良好な分類性能と応答性が得られたが、目的とする生活状態によっては学習させるデータの区間を適切に選択する必要がある。その区間の効果的な選び方については今後検討が必要である。また、運用前の事前学習が必要な前提で議論してきたが、大規模なデータ収集を実施することによって各作業状態の標準的な学習データを作成することにより、事前学習を不要にすることができる可能性がある。また、運用開始後の自動的な再学習の枠組みも検討したい。

今後は、実際に携帯電話上に提案手法による行動認識エンジンを搭載し、より実用に近い形で、提案手法による計算量削減効果や実際の端末上での消費電力なども含め、これらの課題に関する検討と実用化に向けた評価を行っていく。

謝辞 本研究の一部は総務省の研究委託により実施したものである。

## 参考文献

- [1] 美濃導彦：家庭におけるユビキタス環境の構築—ゆかりプロジェクト，電子情報通信学会2004総合大会，No.A-16-8，p.317 (2004).
- [2] 森 武俊，野口博史，佐藤知正：センシングルーム—部屋型日常行動計測蓄積環境第2世代ロボティックルーム，日本ロボット学会誌，Vol.23，No.6，pp.665-669 (2005).
- [3] 松岡克典：宅内ネットワークを用いた生活見守り技術，第49回自動制御連合講演会論文集 SU1-2-2，pp.1-2 (2006).
- [4] Kern, N., Schiele, B. and Schmidt, A.: Multi-sensor Activity Context Detection for Wearable Computing, *Proc. 1st European Symposium on Ambient Intelligence (EU-SAI 2003)*, LNCS 2875, pp.220-232 (2003).
- [5] Bao, L. and Intille, S.S.: Activity Recognition from User-Annotated Acceleration Data, *Proc. 2nd International Conference on Pervasive Computing (PERVASIVE 2004)*, LNCS 3001, pp.1-17 (2004).
- [6] Iso, T. and Yamazaki, K.: Gait Analyzer based on a Cell Phone with a Single Three-axis Accelerometer, *Proc. 8th Conference on Human-Computer Interaction with Mobile Devices and Services (MobileHCI2006)*, pp.141-144 (2006).
- [7] 倉沢 央，川原圭博，森川博之，青山友紀：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，情報処理学会研究報告，2006-UBI-11 (3)，pp.15-22 (2006).
- [8] 池谷直紀，菊池匡晃，長 健太，服部正典：3軸加速度センサを用いた移動状況推定方式，情報処理学会研究報告，2008-UBI-19 (14)，pp.75-80 (2008).
- [9] Peltonen, V., Tuomi, J., Klapuri, A., Huopaniemi, J. and Sorsa, T.: Computational auditory scene recognition, *Proc. Acoustics, Speech, and Signal Processing (ICASSP 2002)*, pp.1941-1944 (2002).
- [10] 大内一成，土井美和子：センサ駆動ハンドヘルド型音声認識入力方法の提案—センサを用いた発話動作検出手法，情報処理学会論文誌，Vol.51，No.2，pp.324-333 (2010).
- [11] 小林重令，岩本健嗣，西山 智：釈迦：携帯電話を用いたユーザ移動状況推定方式，情報処理学会論文誌，Vol.50，No.1，pp.193-208 (2009).
- [12] Siewiorek, D., Smailagic, A., Furukawa, J., Krause, A., Moraveji, N., Reiger, K., Shaffer, J. and Wong, F.: SenSay: A Context-Aware Mobile Phone, *Poster of 7th IEEE International Symposium on Wearable Computers (ISWC 2003)* (2003).
- [13] Iso, T., Kawasaki, N. and Kurakake, S.: Personal context extractor with multiple sensor on a cell phone, *7th IFIP International Conference on Mobile and Wireless Communications Networks (MWCN2005)*, D.2 C200525 (2005).
- [14] Lukowicz, P., Ward, J.A., Junker, H., Stäger, M., Tröster, G., Atrash, A. and Starner, T.: Recognizing Workshop Activity Using Body Worn Microphones and Accelerometers, *Proc. 8th International Conference on Pervasive Computing (PERVASIVE 2004)*, LNCS 2001/2004, pp.18-32 (2004).
- [15] 前川卓也，柳沢 豊，岸野泰恵，石黒勝彦，亀井剛次，櫻井保志，岡留 剛：ウェアラブルセンサによるモノを用いた行動の認識について，情報処理学会研究報告，2010-UBI-25 (57)，pp.1-8 (2010).
- [16] Maekawa, T., Yanagisawa, Y., Kishino, Y., Ishiguro, K., Kamei, K., Sakurai, Y. and Okadome, T.: Object-Based Activity Recognition with Heterogeneous Sensors on Wrist, *Proc. 8th International Conference on Pervasive Computing (PERVASIVE 2010)*, LNCS 6030/2010, pp.246-264 (2010).
- [17] Katz, S.: Assessing self-maintenance: Activities of daily living, mobility, and instrumental activities of daily living, *Journal of the American Geriatrics Society*, Vol.31, No.12, pp.721-727 (1983).
- [18] Fillenbaum, G.G.: Screening the elderly. A brief instrumental activities of daily living measure, *Journal of the American Geriatrics Society*, Vol.33, No.10, pp.698-706 (1985).
- [19] 永田久美子：認知症ケアをもっと“楽”に！，認知症介護研究・研修東京センター (2008).
- [20] 認知症介護研究・研修東京センターケアマネジメント推進室：「いつどこ」ネット，入手先 (<http://itsu-doko.net/index.html>).
- [21] 総務省統計局平成18年社会生活基本調査，入手先 (<http://www.stat.go.jp/data/shakai/2006/index.htm>).
- [22] Ouchi, K., Suzuki, T. and Doi, M.: LifeMinder: A wearable healthcare support system with timely instruction based on the user's context, *IEICE Trans. Information and Systems*, Vol.E87-D, No.6, pp.1361-1369 (2004).
- [23] Suzuki, T., Ouchi, K., Kameyama, K. and Takahashi,

M.: Development of a Sleep Monitoring System with Wearable Vital Sensor for Home Use, *Proc. BIOSTEC BIODEVICES 2009*, pp.326–331 (2009).

- [24] 米 A.M.I 社 : Actigraph, 入手先  
(<http://www.sanita.co.jp/>).
- [25] Cole, R.J. et al.: Automatic sleep/wake identification from wrist actigraphy, *Sleep 1992*, Vol.15, No.5, pp.461–469 (1992).
- [26] Chang, C.-C. and Lin, C.-J.: LIBSVM: A library for support vector machines (2001). Software available from  
(<http://www.csie.ntu.edu.tw/~cjlin/libsvm/>).



大内 一成 (正会員)

1998年早稲田大学大学院理工学研究科物理学及応用物理学専攻修了。同年(株)東芝入社。状況認識技術を活用したヒューマンインタフェースの研究開発に従事。現在、(株)東芝研究開発センターインタラクティブメディア

ラボラトリー研究主務。本会ユビキタスコンピューティングシステム研究会幹事。人間情報学会理事。電気学会知覚融合センシング技術の実利用化協同研究委員会委員。



土井 美和子 (フェロー)

1979年東京大学大学院工学系研究科修士課程修了。同年(株)東芝入社。「ヒューマンインタフェース」を専門分野とし、日本語ワープロ、機械翻訳、道案内サービス、ネットワークロボットの研究開発に従事。現在、(株)東芝

研究開発センター首席技監。日本学術会議会員、東京工業大経営協議会委員、国立情報学研究所運営会議委員、科学技術振興機構運営会議委員、東京大学連携教授、電気学会副会長等を務める。本会フェロー。IEEEフェロー。電子情報通信学会フェロー。博士(工学)。