

ユーザ位置情報と家電消費電力に基づいた 宅内生活行動認識システム

上田 健揮¹ 玉井 森彦² 荒川 豊¹ 諏訪 博彦^{1,a)} 安本 慶一¹

受付日 2015年5月12日, 採録日 2015年11月5日

概要: 効果的な省エネ家電制御や見守りなどのコンテキストウェアサービスを実現するためには, 家庭内における生活行動の認識が必須である. これまで, 行動認識に関する研究は数多く行われているが, (1) 多数のセンサを使用するため導入・維持コストが高い, (2) カメラやマイクを使用するためプライバシーを侵害する, (3) 認識できる行動種類が少ないまたは認識精度が低いなどの課題が残されている. 本稿では, 上記3つの課題をすべて解決することを目指した生活行動認識システムを提案する. 提案システムでは, 課題(1), (2)を解決するため, 今後の低価格化・普及が見込め, カメラなどに比べプライバシー露出への抵抗が少ないと考えられる屋内位置センサおよび家電に取り付けた消費電力センサのみを用いる. また, 課題(3)を解決するために, (i) 多数の行動に対するセンサデータの記録と各行動に対応する教師データの抽出, (ii) 教師データに対する効果的な特徴量の選定, (iii) 適切な行動学習モデルの構築を行っている. 4人の被験者による3日間ずつの生活にともなうセンサデータを用いて評価実験を行った結果, 10種類の生活行動を平均91.3%の精度で認識できることを明らかにした. また, 導入コストの抑制を想定し, 消費電力センサの数および位置測定の精度を低下させる環境下で評価した場合でも, 平均87.1%の精度で行動を認識できることを明らかにした.

キーワード: 宅内生活行動認識, プライバシ配慮, 屋内位置センサ, 消費電力センサ, 機械学習

A Living Activity Recognition System Based on Power Consumption of Appliances and Inhabitant's Location Information

KENKI UEDA¹ MORIHIKO TAMAI² YUTAKA ARAKAWA¹ HIROHIKO SUWA^{1,a)} KEIICHI YASUMOTO¹

Received: May 12, 2015, Accepted: November 5, 2015

Abstract: To realize context-aware services such as efficient energy-saving appliance control and elderly monitoring, high-accuracy in-home living activity recognition is essential. Many research efforts have been devoted to living activity recognition so far, but the following remains as pending problems: (1) high deployment and maintenance costs due to many sensors used; (2) privacy exposure due to utilization of cameras and microphones; and (3) few recognizable activities or low recognition accuracy. In this paper, we propose an in-home living activity recognition system which aims to solve all the aforementioned problems. To solve problems (1) and (2), our system only utilizes indoor positioning sensors and power meters that are going to widespread and considered to have low privacy exposure. To solve the problem (3), in this paper, we have tackled the following challenges: (i) recording sensor data including various living activities and extracting training samples corresponding to activities; (ii) determining appropriate features for training samples; and (iii) determining the best machine learning algorithm to achieve high recognition accuracy. We have conducted evaluation experiments with the sensor data by four subjects living in a home for three days each. As a result, the proposed system achieved 91.3% accuracy on average in recognizing ten different living activities. Furthermore, even when we degrade granularity of location and power meter data supposing to use low-cost sensors, our system achieved about 87.1% recognition accuracy on average.

Keywords: living activities recognition, low privacy-intrusion, position sensor, power meters, machine learning

1. はじめに

近年、スマートフォンをはじめとする様々なセンシングデバイスが普及している。これにともない家庭内においても温度や湿度などの環境情報だけでなく、個々のデバイスの使用状況や人間の生活行動を理解するための研究がさかに行われている。家庭での生活行動を自動認識することで、省エネ家電制御 [1], [2] や高齢者見守りシステム [3], [4] などの生活支援・行動支援アプリケーションへの応用が期待できる。これらのアプリケーションでは多種類の行動を高精度で認識することが重要であり、これまで様々なセンシング手法や機械学習などを用いた宅内生活行動の推定手法が研究されている。宅内行動認識の手法の1つとしてカメラを用いたシステム [5], [6] があるが、カメラは「監視されている感覚」が強く、ユーザのプライバシーを侵害するという問題がある。また、家庭内のあらゆる物に接触センサを付けることで高い行動認識率を達成する手法 [7] が提案されているが、導入および維持コストが高く、普及性の面から現実的ではない。さらに、加速度センサなどのウェアラブルセンサを用いてユーザの行動を認識する手法 [8] も提案されているが、ユーザの姿勢や、「歩く」「走る」などのユーザの動きに基づいた行動しか認識できず、家庭内での多様な生活行動の認識は困難である。

本研究では、行動認識に関する既存研究における、(1) 多数のセンサを使用するため導入・維持コストが高い、(2) カメラやマイクを使用するためプライバシーを侵害する、(3) 認識できる行動種類が少ないまたは認識精度が低いという3つの課題をすべて解決することを目指した宅内生活行動認識システムを提案する。課題 (1), (2) を解決するため、今後の低価格化・普及が見込め、カメラなどに比べプライバシー露出への抵抗が少ないと考えられる屋内位置センサおよび家電に取り付けた消費電力センサのみを用いることとする。課題 (3) を解決するためには、(i) 多数の行動に対するセンサデータの記録と各行動に対応する教師データの抽出、(ii) 教師データに対する効果的な特徴量の選定、(iii) 適切な行動学習モデルの構築を行う必要がある。本研究では、(i) を容易に行うため、生活行動可視化・ラベリング支援ツールを開発した [9]。本ツールは、スマートホームにおいて記録されたセンサデータを可視化し、任意の時系列データを各行動に紐付けるラベルを貼り付ける機能を備えている。また、確認用に撮影したビデオを同期して再生する機能を備えることで、ユーザのラベル付けを支援する。

ラベル付けされた区間におけるセンサデータは、ラベルに応じた生活行動に紐付けられ、教師データとして保存される。これらの教師データを一定のサンプル長で区切り、各生活行動における平均値や分散などの特徴量を抽出する。特徴量は、行動を認識するために有効なデータであり、センサに応じた適切な統計量を抽出し、これらの特徴量を用いて行動学習モデルを構築する。(ii), (iii) については、教師データのサンプル長、特徴量の種類、機械学習アルゴリズムの様々な組合せに対する予備分析を行い、最も認識精度が良くなるサンプル長、特徴量の種類、アルゴリズムの組合せを決定する。

提案システムの有用性を評価するため、奈良先端科学技術大学院大学内に設置したスマートホーム設備 (1LDK) において、日常的に生活した際の生活行動の認識率を測定した。今回の実験で対象とする生活行動は、料理、食事、読書、テレビ視聴、食器手洗い、風呂、掃除、仕事・勉強 (PC 使用)、睡眠、外出の 10 種類とした。対象とした 10 行動は、全生活時間の約 90% を網羅している。4 人の被験者による 3 日間ずつの生活にともなうセンサデータを用いて評価実験を行った結果、教師データのサンプル長として 5 分、特徴量として消費電力の平均値と位置の中央値、機械学習アルゴリズムとして Random Forests を用いて行動認識モデルを構築したときに、10 種類の生活行動を平均 91.3% の精度で認識できることが分かった。また、導入コストの抑制を想定し、消費電力センサの数および位置測定の精度を低下させた環境下でも、平均 87.1% の精度で行動を認識できることが分かった。

なお、著者らは宅内生活行動認識精度を検討するために、SVM を用いた行動認識 [10] や、センサデータを劣化させた場合に対する単一の機械学習手法による行動認識など [11]、基礎的な検討を行っている。本稿は、これらの既存研究の知見に加え、センサデータを劣化させた場合について複数の機械学習手法を用いて分析し、その結果も含めてまとめなおしたものである。

2. 関連研究

屋内における行動認識に関してこれまでに様々な研究が行われている。人の行動を認識する研究は、ビデオカメラなどを用いて画像処理により認識する手法と、接触センサや圧力センサなど、複数のセンサを用いて認識する手法に大別できる。2.1 節では、それぞれの手法を用いた屋内における行動認識に関する既存研究について述べる。また、2.2 節において、収集したセンサデータを可視化し、生活行動と紐付けるための、ラベリングツールに関する研究について述べる。

2.1 屋内における行動認識に関する研究

Brdiczka ら [12] は、カメラで撮影した映像に画像処理を

¹ 奈良先端科学技術大学院大学
Nara Institute of Science and Technology, Ikoma, Nara 630-0192, Japan

² 株式会社国際電気通信基礎技術研究所 (ATR)
Advanced Telecommunications Research Institute International (ATR), Soraku-gun, Kyoto 619-0288, Japan

a) h-suwa@is.naist.jp

適用することにより、家庭における生活行動を認識する手法を提案している。この研究では、3D ビデオトラッキングセンサとアンビエントサウンドセンサを用いることで、歩く、座るといった単純な行動に加え、仕事や昼寝といった個人の行動、さらには会話、ゲームといった複数人による行動を70~90%の正解率で認識することができる。しかし、特殊かつ高価なカメラやマイクが必要であることと、居住者のプライバシーを侵害する恐れがあるという問題がある。また、認識できる行動の種類が少なく、認識の正確さも十分とはいえない。

Kasteren ら [13] は、ドアセンサ、引出しセンサ、圧力マット、浮力センサ、温度センサなど様々なセンサが埋め込まれたスマートホームにおいて、食事、テレビ観賞、外出、トイレ、シャワー、洗濯、着替えなどの多様な日常生活行動を認識するシステムを構築しており、その認識精度は49~98%となっている。この手法は、認識できる行動の種類は多いが、多くのセンサが必要で導入コストが高いうえに、行動の種類によっては認識精度が低いという問題がある。

Chen ら [7] は、近接センサ、モーションセンサ、チルトセンサ、圧力センサなどが多数埋め込まれたスマートホームにおいて、お茶（コーヒー）をいれる、パスタをつくる、テレビを見る、入浴する、手を洗うといった複雑な生活行動を90%以上の精度で認識するシステムを構築している。この手法は、知識ベースのオントロジにより生活行動を認識しているため、機械学習を用いた手法のように、事前に大量の教師データを必要としないという利点がある。しかし、多種・多数のセンサを使っており、導入コストが高いという問題がある。

ウェアラブル加速度センサを用いた行動認識手法では、歩く、座る、走る、寝るといった単純な行動について90%以上の精度で認識できるという報告がある [14]。しかし、ウェアラブル加速度センサによる複雑・抽象的な生活行動の認識についてはあまり提案されていない。Bao ら [15] は、人に装着した5つのウェアラブル加速度センサを用いて、テレビ観賞、掃除、仕事などの20種類の行動を認識することに成功している。しかし、5つのセンサを装着する必要があるため、ユーザの負担が大きい。Maekawa ら [16] は、使用時に各家電が発する磁界に着目し、ウェアラブル磁気センサを用いて、テレビ観賞、シェービング、携帯電話の操作、歯磨き、掃除などの行動を認識する手法を提案している。しかし、電化製品の操作に関連した行動に限られ、認識精度も75%程度にとどまっている。大内ら [17] は、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している。この手法では、音を分析することで歯磨きやシェービングなど7つの行動について、本人のデータを教師データとした場合は85.9%の精度で認識している。しかし、全被験者のデータを教師データとした場合は平均で75.8%の精度にとどまっている。こ

れらのことから、低コストでより多くの宅内生活行動をより高精度に認識する手法が必要であると考えられる。

消費電力を使用した研究としては、Zhang らの LDA を基礎とした AUT モデルによる行動認識 [18] や、Fortin-Simard らの RFID と消費電力を利用したキッチン内での行動認識 [19] がある。これらの手法は、認識精度が59~83%と低い、認識する行動が特定の場所に限定されるなどの課題がある。またどの程度のセンサ精度が必要であるかについての検討は行われていない。著者らは、認識精度の向上を図るとともにより広範囲の行動を対象とし、センシング精度を意図的に変更することで認識精度とセンシング精度の関係を検討する。

上記で述べた既存研究の問題点をふまえ、著者らは、消費電力センサと屋内位置センサのみを用いた、プライバシーの侵害が少ない行動認識システムを提案する。対象とする生活行動を10種類とし、3つの学習アルゴリズムによる認識精度の比較を行う。また、低コストでシステムを実現するために、消費電力センサ数の削減や、位置精度を故意に低下させた場合の認識精度の変化についても評価する。

2.2 ラベル付けによるセンサデータの可視化に関する研究

行動認識を行う際に、収集した多様なセンサデータを解析しやすい形で見える化するシステムが必要となる。センサデータの可視化を目的とした研究は数多く行われており、その中で、特に家庭内やオフィスにおける省エネ意識の向上を目指した様々な可視化システムが提案されている。Costanza ら [20] は消費電力データに対し、使用した家電のラベルを貼付し、生活行動と関連性を持たせることでエネルギーの用途を可視化するシステムを提案している。12人の参加者の家庭に電力メータを設置し、参加者が2週間システムを使用した結果、多くのユーザがエネルギー消費に関する新たな発見を報告した。その内容によると、単に使用電力量を可視化するだけでなく、ユーザ自らがラベル付けを行うというインタラクティブな操作がともなうことで、自身の生活行動に対する理解が深まることが示されている。しかし、対象としているセンサデータは消費電力のみであるため、多様なセンサデータ間の関連性を分析し、新たな知見を得ることは困難である。ラベル付けに関しても、手動で行うためユーザの負担が大きい。

3. 宅内生活行動認識システム

本システムの実現には、以下の3つの要件を満たす必要がある。

- (1) 低コスト、少数のセンサで実現できる。
- (2) 居住者のプライバシーに配慮する。
- (3) 多種類かつ抽象的な生活行動を高精度に認識できる。

これらの要件を満たすための基本方針として、(1)、(2)の要件については、今後の低価格化・普及が見込め、カメ

ラなどに比べプライバシー露出への抵抗が少ないと考えられる消費電力センサおよび屋内位置センサのみを用いる。(3)の要件については、多数の行動に対応する教師データを抽出するために、収集したセンサデータを可視化し、任意の時系列データを容易に各行動に対応づけることが可能な生活行動可視化・ラベリング支援ツールを開発する。また、教師データのサンプル長、特徴量の種類、機械学習アルゴリズムの様々な組合せに対する予備分析を行い、最も認識精度が良くなる組合せを決定する。以下に認識の対象とする生活行動の定義および使用するセンサ、教師データや特徴量の取得方法、学習モデルの構築について述べる。

3.1 生活行動の定義

本研究で対象とする生活行動について述べる。平成23年総務省統計局では、1日の主な行動を1次活動：睡眠、食事など生理的に必要な活動、2次活動：仕事*1、家事など社会生活を営むうえで義務的な性格の強い活動、3次活動：1次活動、2次活動以外で各人が自由に使える時間における活動と定義している [21]。本研究では、宅内の1次活動として「食事」、「入浴」、「睡眠」、2次活動として「料理」、「食器手洗い」、「掃除」、3次活動として「テレビ視聴」、「読書」、「仕事*2・勉強 (PC 使用)」, 宅外行動として「外出」の計10種類を認識の対象とした。

3.2 センサデータの収集

本研究で使用する個々のセンサについて、詳しく述べる。本研究では、図1に示すスマートホーム（奈良先端大内に設置されている1LDKの実験用住宅設備）において、被験者に実際に生活してもらいデータを収集する。スマートホームには、屋内位置センサ（超音波位置センサ）[22]、各家電に取り付けられている消費電力センサ、環境センサ（温度、湿度、照度、人感センサを搭載、数カ所に設置）、ドアセンサ、水栓センサが設置されている。このうち、本研究で行動認識に使用するセンサは、屋内位置センサと消費電力センサである。両センサとも、計測したデータは ZigBee

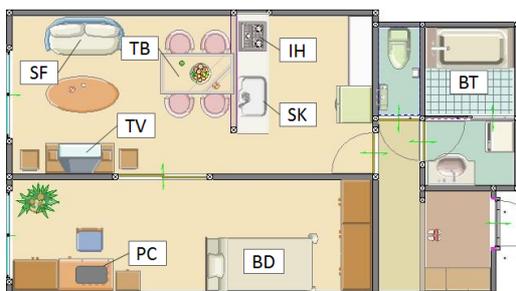


図1 実験で用いたスマートホームの間取り

Fig. 1 Floorplan of a smart home used for data collection.

*1 職場など行う義務的な性格の強い仕事・業務

*2 宅内で行う補助的な仕事・業務

で天井裏の中継機に送信され、サーバに自動蓄積される。以下にそれぞれのセンサについて述べる。

3.2.1 超音波センサ

屋内位置センサは、超音波送信機と受信機に分かれている。受信機はスマートホームの各部屋の天井に設置されており、被験者は図2の超音波センサ送信機を右腕に装着して位置情報をセンシングする。収集する位置データは、図1の左上を原点として、右方向にx座標、下方向にy座標をミリメートル単位で測定している。位置推定精度は、公称値は誤差50cmであるが、センサを静止させた状態での実測値は誤差5cm程度であることを確認している。サンプリング周期は、毎秒2回である。なお、誤差5cm、毎秒2回の位置情報のセンシングにより、プライバシーを気にする人も存在すると考えるが、カメラやマイクなどによるセンシングにくらべれば抵抗感は少ないと考える。

3.2.2 消費電力センサ

図3に示す消費電力センサは、家電(100V用)の消費電力をセンシングできる。サンプリング周期は、1分間に2回である。データは、0以上の実数(小数点以下2桁)のワットで示される。また、スマートホーム内にCTセンサという照明や給湯器といった設備に内蔵されている消費電力を計測するセンサがある。本研究では、このCTセンサも使用する。実際に使用した電力データは、各部屋の照明とエアコン、テレビ、オーディオ、PC、IHクッキングヒータ(以後IHヒータ)、冷蔵庫、炊飯器、電子レンジ、給湯器、ドライヤ、掃除機、洗濯機の16種類である。

3.3 教師データの取得

機械学習を行うにあたって、あらかじめセンサデータの集合がどの生活行動に対応するかを示した教師データが必要である。著者らは、文献[9]において、教師データを容易に取得するための、生活行動ラベリングツールを開発した。図4に生活行動ラベリングツールの実行画面を示す。

本ツールは、スマートホームを用いて収集した多種類のセンサデータの可視化および生活行動のラベル付けを支援する。本ツールは蓄積されたセンサデータの中から、任意に指定した時間区間のデータを取り出し、各種センサデータ(各家電の消費電力、温度、湿度など)のグラフ表示に加え、スマートホームに備えられている屋内位置センサに



図2 超音波センサ送信機
Fig. 2 Positioning sensor.



図3 消費電力センサ
Fig. 3 Power meter.



図 4 生活行動可視化・ラベリング支援ツール
Fig. 4 Daily living activity labeling tool.

よる人の当該時間区間における移動軌跡などを表示することが可能である。また、確認用として撮影したビデオを同期して再生する機能を備え、発見した生活行動に対し、対応する時間区間のセンサデータに当該行動のラベル付けを行うことを支援する。ラベル付けされた各区間におけるセンサデータは、ラベルが示す生活行動に紐付けて保存され、教師データとして使用される。

生活行動のラベリングは、被験者の主観に基づいて行っている。被験者は、ラベリングツールを用いて、実際のビデオ映像を確認しながら対応する時間に行動のラベリングを行っている。たとえば、被験者がある時点からある時点までを入浴と判断した行動を入浴とラベリングしている。結果として、浴室にいたときだけでなく、脱衣所に移動する行動も含めて入浴とラベリングすることもありうる。同様に、掃除については本人が掃除していると判断している行動が掃除であり、風呂掃除など掃除機を使用しない行動も掃除とラベリングすることもありうる。被験者の主観に基づいてラベリングする理由は、実際に行動認識を行う際には利用者の感覚と一致することが重要と考えているためである。

3.4 特徴量の抽出

特徴量とは、生活行動に対応するセンサデータの集合から、それらの行動を認識するために有効なデータのことである。本システムでは、生活行動ラベリングツールによりラベル付けされた区間のセンサデータから特徴量を取得する。手順として、まずそれぞれの生活行動に対するセンサデータを収集し、次にそれらを一定の時間間隔のデータに区切り、最後に必要な特徴量を抽出する。センサおよび特徴量の概要を表 1 にまとめる。

サンプル長や特徴量、使用する学習アルゴリズムを検討するために、後述する評価実験で収集したデータに対する予備分析を行った。データのサンプル長は、30 秒、1 分、5 分を試した。サンプル長を最短で 30 秒にした理由は、今回使用した消費電力センサが 30 秒に 1 度しか取得できな

表 1 センサおよび特徴量の概要

Table 1 Sensor and corresponding features.

	消費電力センサ	屋内位置センサ
単位	ワット (W)	ミリメートル (mm)
サンプリング周期	2 回/分	2 回/秒
取り付け位置	各家電または天井裏	被験者の右腕
使用データ	各部屋の照明 各部屋のエアコン テレビ、オーディオ PC, IH ヒータ 冷蔵庫, 炊飯器 電子レンジ 給湯器, ドライヤー 掃除機, 洗濯機	x 座標, y 座標
サンプル長	5 分	5 分
特徴量	各サンプル長における 平均値	各サンプル長における 中央値

表 2 学習アルゴリズム・サンプル長ごとの平均 F 値

Table 2 Average F-measure with different learning algorithms and time window width of samples.

学習アルゴリズム	サンプル長		
	30 秒	1 分	5 分
SVM	81.3%	78.7%	86.3%
C4.5 決定木	81.2%	79.7%	87.7%
Random Forests	86.3%	85.5%	91.3%

い仕様であったためである。また、最長 5 分とした理由は、掃除や食器手洗いなど比較的短時間で終わる行動が、短い場合には 5 分程度で終了してしまうためである。したがって、サンプル長を 10 分などにすると、掃除や食器手洗いのみの行動として抽出できず、これらの行動を単独の行動としてラベリングできなくなる。複数の学習アルゴリズムで試した結果 (表 2)、どのアルゴリズムでも 5 分が最も行動認識精度が高かったため、本研究ではサンプル長を 5 分と設定している。使用した学習アルゴリズムや評価尺度 (F 値など) については後述する。

同様に、特徴量として抽出する統計量に関しても予備分析でいくつかの値 (平均値, 分散値, 中央値など) を試した結果、位置データ (x 座標, y 座標) の中央値と電力データの平均値を使用した場合が最も認識精度が高くなったため、本研究ではこれらの特徴量として用いる。

3.5 行動学習モデルの構築

生活行動ラベリングツールによりラベル付けしたセンサデータ区間の特徴量を教師データとし、機械学習により行動学習モデルを構築する。モデルの構築には、データマイニングツールである Weka [23] を用いた。Weka は多数の機械学習アルゴリズムに基づく分類器を実装しており、本研究では、代表的な機械学習アルゴリズムである

SVM (Support Vector Machines: サポートベクターマシン), C4.5 決定木, Random Forests の 3 つの手法を用いて各生活行動における特徴量に対して学習モデルを構築する。なお、機械学習以外の手法として、ルールベースなどの方法も考えられるが、今後判別する行動を増加させることや行動パターンの異なる人への拡張を考えた場合、ルールベースでは対応しきれないことが考えられる。機械学習は、学習を続けることでルールの更新が可能であるため、本研究において採用している。

4. 評価実験

提案手法の性能評価および、センサ数削減時の影響を調べるため、前述のスマートホームにおいて日常生活のデータ収集を実施した。以下に評価実験の概要と結果について述べる。

4.1 実験概要

3.1 節で述べたとおり、今回の評価実験において認識対象とする行動は、料理、食事、読書、テレビ視聴、食器手洗い、風呂、掃除、仕事・勉強 (PC 使用)、睡眠、外出の 10 種類とした。4 人の被験者 (大学院生: 20 代男性 3 人, 20 代女性 1 人) に、それぞれ 3 日間生活してもらい、計 12 日間分のデータセットを収集した。被験者には超音波位置センサの送信機を 1 つ装着してもらい、夕方 6 時ごろ帰宅し通常の生活をしてもらうように依頼した。外出時や入浴時については、超音波位置センサの送信機をはずし玄関や脱衣所に置くという対応をしている。なお、データ収集が目的であるため、帰宅して何もせずに寝るといったことがないように、食事、入浴、読書、掃除などを 1 回以上するように依頼している。また、日中は自由な行動を許可した結果、学校やアルバイトなどで朝 9 時過ぎには外出することとなった。

各行動で使用される家電や家具の位置は、図 1 のとおりである。テレビ視聴は、リビングルームの「TV」の位置にテレビがあり、「SF」のソファ、「TB」のダイニングテーブルの位置から視聴されることが多く確認されている。料理は「IH」の IH ヒータを使用して調理を行い、食事はダイニングテーブルやソファ前のテーブルで行われ、食器手洗いは「SK」の流し台で行われている。仕事・勉強 (PC 使用) は、寝室のデスク上「PC」の位置で行われることが多く確認されている。入浴、睡眠は、それぞれ「BT」の浴室および「BD」のベッドの位置で行われている。特に、行動の場所を限定していないため、テレビ視聴や食事、読書といった行動はソファやダイニングテーブルなどの複数の場所で確認されている。なお、今回収集したデータにおいて、対象としている 10 行動が全生活時間の約 90% を網羅していることを確認している。

データを収集した後、生活行動ラベリングツールを用い

て、ビデオの映像を確認しながら、センサデータに対して各生活行動に応じたラベル付けを行う。ラベル付けされたすべてのデータを 5 分間隔で分割し、4 人全員のデータの中から各生活行動につき 30 個のサンプルを教師データとしてランダムに抽出した。その後、前述の手順で特徴量を抽出し、3 種類の機械学習アルゴリズムを用いて行動学習モデルを構築した。学習は、電力と位置情報を両方使用した場合と、電力のみの場合、位置情報のみの場合の計 3 パターンを用意してそれぞれ評価を行った。評価には、10 分割交差検証法を用いた。教師データを 10 分割し、その 1 つをテストデータとして評価し、それを 10 回繰り返すことで全体を評価している。これにより、過学習や汎化誤差に配慮している。

今回の実験環境では多数の消費電力センサと高価な高精度の屋内位置センサを使用しているため、現状では一般家庭への普及は難しい。そこで導入コストの抑制を想定し、消費電力センサの数を削減した場合と位置精度を意図的に悪化させた場合に関しても同様の実験を行い、認識精度への影響を評価する。以下に評価結果を示す。

4.2 評価結果

評価には Precision, Recall, F 値を用いる。Precision (適合率) は、その生活行動であると推定したデータのうち、実際にその生活行動であったデータの割合である。Recall (再現率) は該当する生活行動のうち、その生活行動であると推定されたデータの割合である。F 値は、Precision と Recall の調和平均であり、次式で表される。

$$F = \frac{2\text{Recall} \cdot \text{Precision}}{\text{Recall} + \text{Precision}}$$

以降の評価結果における認識精度はすべて F 値を示す。

4.2.1 学習アルゴリズムの比較

表 3 に、SVM, C4.5 決定木, Random Forests の 3 つの学習アルゴリズムを使用した場合における認識精度を示す。学習に使用したデータとして、電力と位置情報を両方使用した場合、電力のみの場合、位置情報のみの場合の計 3 パターンを用いた。すべての学習アルゴリズムで、特徴量として電力と位置情報の両方を組み合わせることで認識精度を向上させることが確認できた。また、すべてのパターンにおいて Random Forests による認識が最も高い認識精度を得られた。特に、電力と位置情報の両方を使用することで、91.3% と高い認識精度を得ることができた。この結

表 3 各学習アルゴリズムにおける平均 F 値

Table 3 Average F-measure with different learning algorithms.

学習アルゴリズム	使用センサ		
	電力と位置	電力のみ	位置のみ
SVM	86.3%	69.7%	78.0%
C4.5 決定木	87.7%	74.7%	77.5%
Random Forests	91.3%	83.5%	79.0%

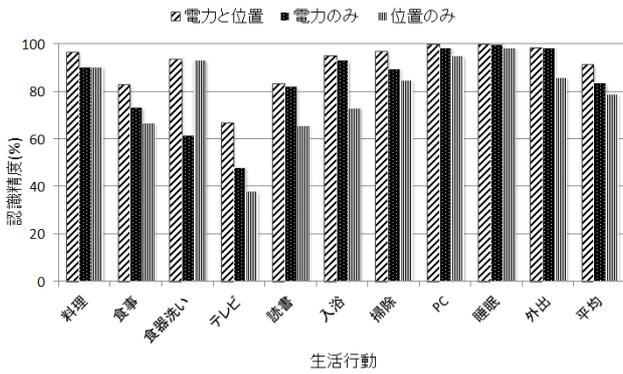


図 5 Random Forests による使用センサ・生活行動ごとの認識精度
Fig. 5 Accuracy with different combinations of sensors.

果に基づき、以降の評価結果では学習アルゴリズムにすべて Random Forests を使用する。

4.2.2 生活行動ごとの認識精度

各生活行動の認識精度を評価するために、図 5 に使用センサごとの各生活行動の認識精度を示す。すべての生活行動で、電力と位置情報を組み合わせることで認識精度が向上していることが分かる。テレビ視聴が最も認識精度が低い結果となったが、これはテレビをつけたまま食事や読書など別の行動を同時に行うといった複合行動であっても、単一行動にラベル付けしていることが原因だと考えられる。以下に使用センサごとの認識結果の詳細を示す。

表 4、表 5 に電力と位置情報を用いた学習モデルの認識結果を示す。表 4 の認識結果において、各行は実際の生活行動を示し、各列は行動学習モデルによって予測された生活行動を示す。表 5 は各生活行動における Precision, Recall, F 値を示している。

各生活行動の個別の F 値を見ると、食事、テレビ視聴、読書以外の行動は 90%以上の認識精度が得られた。仕事・勉強 (PC 使用)、睡眠の行動はどちらも F 値 100%となったが、これは、電力、位置情報ともに他の行動とは大きく異なる特徴があるためだと考えられる。たとえば、仕事・勉強 (PC 使用) は寝室のデスクの場所で PC を稼働させる行動であり、集中するためにテレビなどリビングの家電を停止させる傾向があった。睡眠も同様に寝室のベッドの位置で照明を含めたほとんどの家電を停止させるため他の行動と大きく特徴が異なっていたものと考えられる。テレビ視聴に関しては F 値 66.7%と最も低い結果となったが、これは、表 4 に示すように、テレビ視聴を誤って食事や読書と認識しており、複合行動が原因であると考えられる。この傾向は逆もあり、食事や読書を誤ってテレビ視聴と認識しており、26 件の誤認識のうち、20 件がテレビ視聴に関する誤認識であり、77%を占めている。

また、テレビ視聴に関するもの以外の誤認識としては、料理や食事を食器洗いと誤認識しているものが 3 件、食事を読書、入浴を外出、掃除を入浴と誤認識しているものがそれぞれ 1 件あった。これらは料理中にテーブル (TB) へ

表 4 位置情報と消費電力情報を両方用いた場合の各行動の認識結果

Table 4 Confusion matrix with the all sensor data.

真 \ 予測値	予測値									
	a	b	c	d	e	f	g	h	i	j
a=料理	28	0	2	0	0	0	0	0	0	0
b=食事	0	24	1	4	1	0	0	0	0	0
c=食器洗い	0	0	29	1	0	0	0	0	0	0
d=テレビ	0	4	0	20	4	1	1	0	0	0
e=読書	0	0	0	5	25	0	0	0	0	0
f=入浴	0	0	0	0	0	29	0	0	0	1
g=掃除	0	0	0	0	0	1	29	0	0	0
h=仕事・勉強	0	0	0	0	0	0	0	30	0	0
i=睡眠	0	0	0	0	0	0	0	0	30	0
j=外出	0	0	0	0	0	0	0	0	0	30

表 5 位置情報と消費電力情報を両方用いた場合の評価結果

Table 5 Accuracy with the all sensor data.

生活行動	Precision (%)	Recall (%)	F 値 (%)
料理	100.0	93.3	96.6
食事	85.7	80.00	82.8
食器洗い	90.6	96.7	93.5
テレビ	66.7	66.7	66.7
読書	83.3	83.3	83.3
入浴	93.5	96.7	95.1
掃除	96.7	96.7	96.7
仕事・勉強	100.0	100.00	100.0
睡眠	100.0	100.0	100.0
外出	96.8	100.00	98.4
平均	91.3	91.3	91.3

表 6 電力のみを用いた場合の評価結果

Table 6 Accuracy with the only power meters data.

生活行動	Precision (%)	Recall (%)	F 値 (%)
料理	87.5	93.3	90.3
食事	73.3	73.3	73.3
食器洗い	57.1	66.7	61.5
テレビ	54.2	43.3	48.1
読書	80.6	83.3	82.0
入浴	96.4	90.0	93.1
掃除	92.9	86.7	89.7
仕事・勉強	96.8	100.0	98.4
睡眠	100.0	100.0	100.0
外出	96.8	100.0	98.4
平均	83.6	83.7	83.5

配膳する行動やソファ (SF) で食事した行動、風呂掃除をした行動などが誤認識されていると考えられ、これらの行動についてはその前の行動と組み合わせて認識することにより認識精度の向上が可能と考える。

表 6 は、電力のみを用いた場合の評価結果である。全生活行動の平均の F 値は 83.5%となり、位置情報の特徴量を併用した場合よりも低くなった。この原因として、テレビの複合行動以外にも、食事の F 値が 73.3%、食器洗いの F

表 7 位置のみを用いた場合の評価結果

Table 7 Accuracy with the only position data.

生活行動	Precision(%)	Recall(%)	F 値 (%)
料理	87.5	93.3	90.3
食事	66.7	66.7	66.7
食器洗い	96.4	90.0	93.1
テレビ	39.3	36.7	37.9
読書	64.5	66.7	65.6
入浴	86.4	63.3	73.1
掃除	86.2	83.3	84.7
仕事・勉強	96.6	93.3	94.9
睡眠	96.8	100.0	98.4
外出	75.0	100.0	85.7
平均	79.5	79.3	79.0

値が 61.5%と、電力の使用をともなわない行動の認識精度が悪化していることが分かる。

表 7 は、位置情報のみを用いた場合の評価結果である。全生活行動の平均の F 値は 79.0%となった。料理と食器洗いの精度が高い理由は、IH ヒータと流しの場所が異なり、かつその場所以外で行動することがほとんど発生しないためと考える。また、食事、テレビ視聴、読書が他の行動よりも低い精度となったが、これはソファやダイニングテーブルなど、同じ位置で異なる行動が起こるため、位置情報だけでは判別が難しいことが原因であると考えられる。さらに、外出や入浴のように位置情報が明確と考えられる行動の精度が低い理由は、ラベリングの方法に原因があると考える。本実験では、行動のラベリングは、外出や入浴の行動を始めたときと被験者が判断した時点からその行動と判断するため、脱衣所や玄関への移動時の位置情報も含まれる場合があり、それが誤認識の原因と考える。

4.2.3 消費電力センサの属性数を削減した際の評価

学習に用いた特徴量は、位置情報 (x 座標, y 座標) の中央値、各家電の電力データ (各部屋の照明とエアコン、テレビ、オーディオ、PC、IH ヒータ、冷蔵庫、炊飯器、電子レンジ、給湯器、ドライヤ、掃除機、洗濯機) の平均値であり、属性数は合計 18 である。低コストでの実現のためには、消費電力センサは少数の方が望ましい。そこで、属性数を削減した場合の認識精度の変化について評価する。Weka の属性選択機能を使用し、最良優先探索により行動認識に有用な属性を抽出した。その結果、位置情報 (x 座標, y 座標) の中央値と、電力に関しては、リビングの照明、洗面所の照明、テレビ、IH ヒータ、掃除機、オーディオが有用であることが確認できた。一見どの行動も無関係と考えられるオーディオが有用な属性として残った理由としては、オーディオはテレビと同時に使われることがなく、読書などと同時に使われたため、行動の推定に寄与したものとする。これらの特徴量を使用した場合の認識結果を表 8 に示す。平均 F 値は 88.1%となり、属性数を 18 から

表 8 属性数を削減した場合の評価結果

Table 8 Accuracy with reduced number of power meters.

生活行動	Precision(%)	Recall(%)	F 値 (%)
料理	90.9	100.0	95.2
食事	74.2	76.7	75.4
食器洗い	93.1	90.0	91.5
テレビ	57.7	50.0	53.6
読書	76.7	76.7	76.7
入浴	100.0	96.7	98.3
掃除	93.3	93.3	93.3
仕事・勉強	96.8	100.0	98.4
睡眠	100.0	100.0	100.0
外出	96.8	100.0	98.4
平均	87.9	88.3	88.1

表 9 位置情報を 2m のセルで区切った場合の評価結果

Table 9 Accuracy of using the simplified position data.

生活行動	Precision(%)	Recall(%)	F 値 (%)
料理	90.3	93.3	91.8
食事	61.1	73.3	66.7
食器洗い	85.7	80.0	82.8
テレビ	60.9	46.7	52.8
読書	86.7	86.7	86.7
入浴	96.7	96.7	96.7
掃除	93.5	96.7	95.1
仕事・勉強	100.0	100.0	100.0
睡眠	100.0	100.0	100.0
外出	96.8	100.0	98.4
平均	87.2	87.3	87.1

8 に削減したが、認識精度は 3%しか低下していない。つまり、消費電力センサをすべての家電に取り付ける必要はなく、抽出した 6 種類の電力データを使用することで生活行動の認識は十分可能であることが確認できた。

4.2.4 位置精度を低くした際の評価

前述の消費電力センサ数の削減に加えて、位置精度の変更に関して評価する。今回の実験環境では、高価な超音波センサを用いた高精度位置推定システムを使っているが、現状では一般家庭への普及は難しい。そこで、より低コストの位置推定システムの利用を想定し、部屋を複数のセルに分割して、セルの中心座標を推定位置とすることで位置情報の精度を意図的に低くした場合の認識精度の変化について評価する。2m 四方のセルに分割した場合の評価結果を表 9 に示す。使用した電力データは前述の有用な 6 種類の消費電力データのみを使用している。個別の行動を見ると、食器手洗いの認識精度が 10%程低下している。これは、位置精度を低くすることでキッチンにおける IH ヒータと流し台の位置の区別がつかなくなったことが原因として考えられる。

しかし、全体の平均 F 値は 87.1%となり、表 5 と比べて 4%しか低下していないことが分かる。これにより、家庭内における生活行動は、今回の実験で使用したような高価な

高精度の位置推定システムは必ずしも必要ではなく、誤差1m程度のおおまかな位置が検出できる低コストの位置推定システムと、少数の消費電力センサを併用することで、程度高精度に認識可能であることが確認できた。

4.2.5 本手法の限界

本研究では、大学院生を被験者として、1人の行動推定を実施している。そのため、生活パターンが異なる主婦や社会人、お年寄りなどに対して、今回の結果がただちに適用できるとはいえない。今後、様々な生活パターンの被験者に対して実験を行うことで、それぞれに特有な行動パターンの有無などの検証を行っていく必要がある。また、今回は1家庭に1人を想定して実験を行っているが、複数人で生活している家庭も多い。複数人での行動推定については、今後の課題である。

また、今回の実験では、複合行動であっても被験者の判断に基づいて主な行動1つにラベル付けをしているため誤認識の原因になったと考える。今後、「テレビ視聴と食事」など複合行動としてラベル付けをすることで、認識精度の向上が可能と考える。さらに本手法では、どの行動にもあてはまらないその他の行動を扱っておらず、必ずいずれかの行動として認識することになる。その他の行動は、全生活時間の約10%を占めており、実運用の際にはこれらの行動についても認識する必要がある。その他の行動の処理については今後の課題である。

生活行動を認識する方法としては、磁気センサを利用する方法 [16] や携帯電話を利用する方法 [17] などウェアラブル端末を利用する方法も提案されている。しかしながら、つねに身に付けなければならないなどの制約がある。これに対して提案手法は、高精度の位置推定でなくても87.1%の推定精度が確認できたため、他の簡易な位置推定手法の適応が可能であり、より利用者への負荷を低減できるメリットがある。今後、送信機を装着しないで位置を推定する手法と組み合わせることで、ウェアラブル端末を利用せずに通常の生活をするだけで行動を認識できると考える。

また、より低コストな位置推定手法としてBLE (Bluetooth Low Energy) の利用が考えられる。BLEは、今回利用したセンサよりも低精度であるものの非常に安価に導入が可能であり、工夫次第で今回想定した2m程度の精度は達成可能であると考えられる。そう仮定した場合、提案手法は、料理 (91.8%)、入浴 (96.7%)、睡眠 (100.0%) と高い精度を達成しており、これを利用することで料理中や入浴後はエアコンの運転を強める、睡眠中はエアコンの運転を抑えるなどの家電制御が可能になると考える。新たな位置推定手法との組み合わせについても、今後検討したい。

5. おわりに

本稿では、スマートホームにおいて取得したセンサデー

タを用いて機械学習により居住者の生活行動を認識するシステムを提案した。提案システムでは、住人のプライバシーの確保や導入・維持コストを抑えるために消費電力センサと屋内位置センサのみを使用した。また、開発した生活行動可視化・ラベリング支援ツールを用いて、多数の行動に対するセンサデータの記録と各行動に対応する教師データの抽出を行った。予備分析では教師データのサンプル長、特徴量の種類、機械学習アルゴリズムの様々な組合せを試し、最も認識精度が高い組合せを決定した。評価実験として、料理、食事、読書、テレビ視聴、食器手洗い、入浴、掃除、仕事・勉強 (PC使用)、睡眠、外出の行動を対象としてRandom Forestsを用いて行動学習モデルを構築したところ、91.3%の精度で行動を認識することができた。また、導入コストの抑制を想定し、消費電力センサの数および位置測定の精度を低下させる環境下においても、平均87.1%の精度で行動を認識することができた。

今後の予定としては、対象とする生活行動の種類を増やし、複合的な行動や複数人への対応も検討していきたい。その際に、認識精度を維持するために、行動の発生時刻などの新たな特徴量の使用を検討する。また、今回は個人差に対する評価を行っていないため、今後被験者データを追加するとともに、行動パターンの違いによる影響についても検討したい。さらに、一般への普及のためにはオンライン認識や、異なる間取りへ無学習で適用できる必要があり、これらについても今後検討を続けていく。

謝辞 本研究の一部は、文部科学省特別経費「ヒューマノフィリック科学技術創出研究推進事業」の支援により実施した。ここに記して謝意を表す。

参考文献

- [1] Scott, J., Brush, B., Krumm, J. and Meyers, B.: Pre-Heat: Controlling Home Heating Using Occupancy Prediction, *Proc. UbiComp 2011* (2011).
- [2] Sean, B., Aditya, M., David, I. and Prashant, S.: Smart-Cap: Flattening Peak Electricity Demand in Smart Homes, *Proc. Percom 2012*, pp.67-75 (2012).
- [3] Rashidi, P. and Mihailidis, A.: A Survey on Ambient Assisted Living Tools for Older Adults, *IEEE Journal of Biomedical and Health Informatics*, Vol.17, No.3, pp.579-590 (2013).
- [4] Kim, J., Soh, J., Kim, S. and Chung, K.: Emergency Situation Alarm System Motion Using Tracking of People like Elderly Live Alone, *2013 International Conference on Information Science and Applications (ICISA) IEEE* (2013).
- [5] Hoey, J. and James, J.: Value-directed human behavior analysis from video using partially observable Markov decision processes, *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol.29, No.7, pp.1118-1132 (2007).
- [6] Fiore, L., Fehr, D., Bodor, R., Drenner, A.A., Somasundaram, G. and Papanikolopoulos, N.: Multi-Camera Human Activity Monitoring, *Journal of Intelligent and Robotic Systems*, Vol.52, No.1, pp.5-43 (2008).

- [7] Chen, L., Nugent, C. and Wang, H.: A Knowledge-Driven Approach to Activity Recognition in Smart Homes, *IEEE Trans. Knowledge and Data Engineering*, Vol.24, No.6, pp.961-974 (2012).
- [8] Lee, S.W. and Mase, K.: Activity and location recognition using wearable sensors, *IEEE Pervasive Computing*, Vol.1, No.3, pp.24-32 (2002).
- [9] 上田健揮, 大木浩武, 水本旭洋, 玉井森彦, 安本慶一: 複数のセンシングデータの可視化および関連付けによる生活行動の理解支援システム, 第21回マルチメディア通信と分散処理ワークショップ (DPSWS2013) 論文集, pp.116-118 (2013).
- [10] 上田健揮, 玉井森彦, 安本慶一: スマートホームにおける複数のセンシングデータに基づいた生活行動データ抽出システムの提案, DICOMO2014 シンポジウム論文集, pp.1884-1891 (2014).
- [11] 上田健揮, 諏訪博彦, 荒川 豊, 安本慶一: センサデータ粒度が宅内行動認識精度に与える影響について, 情報処理学会研究報告, Vol.2015-UBI-45, No.9, pp.1-6 (2015).
- [12] Brdiczka, O., Langet, M., Maisonnasse, J. and Crowley, J.: Detecting Human Behavior Models From Multimodal Observation in a Smart Home, *IEEE Trans. Automation Science and Engineering*, Vol.6, No.4, pp.588-597 (2009).
- [13] van Kasteren, T.L.M. and Krose, B.J.A.: Activity monitoring system for elderly care using generative and discriminative models, *Personal and Ubiquitous Computing*, Vol.14, No.6, pp.489-498 (2010).
- [14] Lara, O.D.: A Survey on Human Activity Recognition using Wearable Sensors, *IEEE Communications Surveys & Tutorials*, Vol.15, No.3, pp.1192-1209 (2013).
- [15] Bao, L. and Intille, S.: Activity recognition from user-annotated acceleration data, *Pervasive 2004*, pp.1-17 (2004).
- [16] Maekawa, T., Kishino, Y., Sakurai, Y. and Suyama, T.: Recognizing the Use of Portable Electrical Devices with Hand-Worn Magnetic Sensors, *Pervasive 2011*, pp.276-293 (2011).
- [17] 大内一成, 土井美和子: 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, 情報処理学会論文誌, Vol.53, No.7, pp.1675-1686 (2012).
- [18] Zhang, X., Kato, T. and Matsuyama, T.: Learning a context-aware personal model of appliance usage patterns in smart home, *Innovative Smart Grid Technologies - Asia (ISGT Asia)*, pp.73-78, IEEE (2014).
- [19] Fortin-Simard, D., Bilodeau, J.S., Gaboury, S., Bouchard, B. and Bouzouane, A.: Human activity recognition in smart homes: Combining passive RFID and load signatures of electrical devices, *2014 IEEE Symposium on Intelligent Agents (IA)*, pp.22-29 (2014).
- [20] Costanza, E., Ramchurn, S. and Jennings, N.: Understanding domestic energy consumption through interactive visualisation: A field study, *Proc. 2012 ACM Conference on Ubiquitous Computing, UbiComp '12*, pp.216-225 (2012).
- [21] 総務省統計局: 平成23年社会生活基本調査, 入手先 <<http://www.stat.go.jp/data/shakai/2011/>> (参照 2014-12-01).
- [22] Song, L. and Wang, Y.: 3D Accurate Location Stream Tracking and Recognition Using an Ultrasound Localization System, *Proc. 2011 International Conference on Indoor Positioning and Indoor Navigation* (2011).
- [23] Weka 3: Data Mining Software in Java, available from <<http://www.cs.waikato.ac.nz/ml/weka/>> (accessed 2014-12-01).



上田 健揮 (正会員)

2013年同志社大学文化情報学部卒業。2015年奈良先端科学技術大学院大学情報科学研究科博士前期課程修了。現在、トヨタ自動車株式会社勤務。



玉井 森彦 (正会員)

2002年岡山県立大学情報工学部卒業。2004年奈良先端科学技術大学院大学博士前期課程修了。2007年同博士後期課程修了。博士(工学)。現在、株式会社国際電気通信基礎技術研究所研究員。モバイルコンピューティング、無線通信システム、分散システムに関する研究に従事。



荒川 豊 (正会員)

2001年慶應義塾大学理工学部卒業。2006年同大学院博士課程修了。博士(工学)。2013年より奈良先端科学技術大学院大学准教授。ネットワークアプリケーション、ソーシャルデータマイニングに関する研究に従事。



諏訪 博彦 (正会員)

1998年群馬大学社会情報学部卒業。2006年電気通信大学大学院情報システム学研究科博士後期課程修了。博士(学術)。2014年10月より奈良先端科学技術大学院大学助教。社会情報システムに関する研究に従事。



安本 慶一 (正会員)

1991年大阪大学基礎工学部情報工学科卒業。1995年同大学院博士後期課程退学。2011年より奈良先端科学技術大学院大学情報科学研究科教授。ユビキタスコンピューティングに関する研究に従事。