

エナジハーベスト焦電型赤外線・ドア開閉センサと家電消費電力に基づいた宅内生活行動認識システム

柏本 幸俊^{1,a)} 秦 恭史¹ 中川 愛梨¹ 諏訪 博彦^{1,b)} 藤本 まなと^{1,c)}
荒川 豊^{1,d)} 繁住 健哉^{2,e)} 小宮 邦裕² 小西 健太² 安本 慶一^{1,f)}

受付日 2016年5月23日, 採録日 2016年11月1日

概要: ユビキタス情報技術の発展によって, 省エネ家電制御や高齢者見守りシステム, コンシェルジュ機能など生活を支援するサービスへの応用が期待されている. これらのサービスの実現には, 多種多様な人間の生活行動を高精度, かつ低コストで認識することが重要である. スマートホームにおける行動推定のアプローチは多数存在するが, (1) カメラやマイクを使用するためにプライバシーを侵害する, (2) 導入・運用コストが高い, (3) ユーザへの装着負担が大きい, (4) 電源・データ収集のための配線が必要, (5) 認識できる行動の種類が少ない, (6) 認識の精度が低いという6つの課題が存在する. 本論文では, これら6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手法を提案する. 課題(1)~(4)を解決するために, エナジハーベスト焦電型赤外線センサ・ドア開閉センサおよび家電に付帯した消費電力センサのみを活用したユーザの行動推定を実現する. このエナジハーベスト焦電型赤外線センサ・ドア開閉センサは太陽光パネルと大容量キャパシタを内蔵しており, これらから取得した電力を用いて半永続的な運用が可能である. また, 課題(5), (6)を解決するために, (i) 教師データに対する効果的な特徴量の選定, (ii) 適切な行動学習モデルの構築, (iii) 焦電型赤外線センサの不感帯に対する補完処理を行っている. 提案手法の有用性を評価するため, 筆者らの大学内設置したスマートホーム設備(1LDK)で, 計5名の被験者に2~3日ずつ生活してもらい, 計13日間評価実験を行った. 評価実験の結果, F-measure: 68.6%でユーザの行動を推定した.

キーワード: 宅内生活行動認識, プライバシ配慮, 焦電型赤外線センサ, 消費電力センサ, 機械学習

A Living Activity Recognition System Based on Power Consumption of Appliances and Energy Harvesting PIR and Door Sensors

YUKITOSHI KASHIMOTO^{1,a)} KYOJI HATA¹ ERI NAKAGAWA¹ HIROHIKO SUWA^{1,b)}
MANATO FUJIMOTO^{1,c)} YUTAKA ARAKAWA^{1,d)} TAKEYA SHIGEZUMI^{2,e)} KUNIHIRO KOMIYA²
KENTA KONISHI² KEIICHI YASUMOTO^{1,f)}

Received: May 23, 2016, Accepted: November 1, 2016

Abstract: Progress of ubiquitous computing technology has strong anticipation to realize efficient energy-saving appliance control and elderly monitoring. In order to put those applications into practice, high-accuracy and low-cost in-home living activity recognition is essential. Many researches have tackled living activity recognition so far, but the followings problems remain: (1) privacy exposure due to utilization of cameras and microphones; (2) high deployment and maintenance costs due to many sensors used; (3) burden to force the user to carry the device and (4) wire installation to supply power and communication between sensor node and server; (5) few recognizable activities; (6) low recognition accuracy. In this paper, we propose an in-home living activity recognition method to solve all the problems. To solve the problems (1)–(4), our method only utilizes energy harvesting PIR and door sensors and power meter. The energy harvesting sensor has a solar cell to drive the sensor and wireless communication modules. To solve the problems (5) and (6), we have tackled the following challenges: (i) determining appropriate features for training samples; and (ii) determining the best machine learning algorithm to achieve high recognition accuracy; (iii) complement for the dead zone of PIR sensor semipermanently. We have conducted evaluations with the sensor by five subjects living in a home for 2–3 days each. As a result, the proposed method has achieved F-measure: 68.6% on average.

Keywords: living activities recognition, low privacy-intrusion, PIR sensor, power meter, machine learning

1. はじめに

近年ユビキタス情報技術の発展とともに、スマートホーム内でのユーザの生活行動を自動認識する研究がさかに行われており、省エネ家電制御 [1], [2] や高齢者見守りシステム [3], [4], コンシェルジュ機能など生活を支援するサービスへの応用が期待されている。これらのサービスの実現には、多種多様な人間の生活行動を高精度、かつ低コストで認識することが重要である。本研究では宅内生活行動を高精度かつ低コストで認識することを目的とする。これまでスマートホームにおける行動推定に関する研究は多数提案されている。スマートホーム内での行動認識の手法としてカメラを活用した行動認識の手法が提案されている [5], [6]。これらの手法では、画像処理を用いてカメラで録画した映像を解析することで、スマートホーム内でのユーザの行動を推定する。しかし、すべての部屋で行動推定を行うための複数カメラの設置やそれぞれのカメラとデータを解析するサーバ間を有線で接続するためのケーブル配線が必要であるため設置コストが高い。さらに、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。一方で、加速度センサやジャイロセンサを内蔵したスマートフォンなどのウェアラブルデバイスを用いてユーザの行動を認識する手法 [7] も提案されているが、「歩く」、「走る」などのユーザの姿勢に強く関連した行動しか推定できず、スマートホーム内における「睡眠」などの行動推定は難しい。また、ユーザがつねにデバイスを保持する必要がある。ユーザへの負担が大きいという課題も存在する。さらには、ウェアラブルデバイスのバッテリー交換を行う必要がある。まとめると、既存研究は、(1) カメラなどの機器によるプライバシーの侵害、(2) 導入・運用コストが高い、(3) ユーザへの装着負担が大きい、(4) 電源・データ収集のための配線が必要という5つの課題が存在する、(5) 認識できる行動の種類が少ない、(6) 認識の精度が低い、といった課題が存在する。

我々の研究グループのこれまでの取り組みとして上田ら [8], [9] は、プライバシー侵害の少ない超音波高精度屋内位置測位システムの位置情報と家電の消費電力情報を用いて、10種類の行動を認識しており、課題(1), (5), (6)について達成している。しかし、導入コストが高い超音波センサを用いた位置測位を活用しユーザの行動を推定するた

め、課題(2)については達成できていない。また、つねにユーザが超音波送信機を保持する必要があるため、課題(3)の達成も難しい。さらには、位置測位システムを稼働するための配線や超音波送信機のバッテリー交換が必要であるため、課題(4)の達成も難しい。よって、課題(1), (5), (6)を達成したまま、課題(2), (3), (4)を解決する必要がある。

本研究では、焦電型赤外線センサ（以降、赤外線センサと呼ぶ）とドア開閉センサ、家電のプラグとコンセントとの間に設置した消費電力センサ、および配電盤に設置した消費電流センサを活用し、ユーザの行動推定を実現する。赤外線センサおよびドア開閉センサは、環境発電（以降エナジハーベストと呼ぶ）で駆動できるエナジハーベストモジュールを用いることで電源を必要とせず、設置の自由度を高めている。このエナジハーベストモジュールは太陽光パネルと大容量キャパシタを内蔵しており、太陽光や室内光下では太陽光パネルで発電した電力でセンサと無線モジュールを駆動し、同時にキャパシタへ電力を蓄積する。夜間などの太陽光パネルから電力供給が望めない状況下では、キャパシタに蓄積した電力によって稼働する。エナジハーベスト赤外線センサ・ドア開閉センサは超音波センサに比べて安価で、かつセンサや無線モジュールの駆動電力をエナジハーベストモジュールより取得するため、バッテリーを交換する必要がない。また、将来の普及が期待されている各家電の消費電力をモニタリングできる電力センサを活用することで、導入コストを抑えることができる。また、これらのセンサとサーバとの接続はワイヤレスネットワークを介して行われるため、データを収集するためのネットワークを必要としない。さらには、ユーザの体表から放射される赤外線を壁や天井に設置した赤外線センサで、ドアの開閉をドアに付帯した磁気センサによって検知するため、ユーザがウェアラブルデバイスを保持する必要がない。したがって、先に述べた課題(1)~(4)を解決することができる。また、課題(5), (6)を解決するために、(i) 教師データに対する効果的な特徴量の選定、(ii) 適切な行動学習モデルの構築、(iii) 赤外線センサの不感帯に対する補完処理を行っている。本研究では、スマートホーム内に51個のエナジハーベスト赤外線センサ・ドア開閉センサ、電力センサを設置し、センサデータをサーバに蓄積・解析するシステムを構築した。

提案システムの有用性を評価するため、筆者らの大学内に設置したスマートホーム設備（1LDK）で、計5名の被験者に2~3日間生活してもらい、計14日間実験を行った。実験の際に日常生活で考えられる10種類の行動に対してセンサデータを記録した。実験により取得したデータを10秒おきに丸めたデータを使用して、Weka^{*1}を用いた機械学習（Random Forest）により、行動がどの程度の精

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 ローム株式会社
ROHM Co., Ltd., Kyoto 615-8585, Japan

a) kashimoto.yukitoshi.km3@is.naist.jp

b) h-suwa@is.naist.jp

c) manato@is.naist.jp

d) ara@is.naist.jp

e) takeya.shigezumi@mnf.rohm.co.jp

f) yasumoto@is.naist.jp

*1 <http://www.cs.waikato.ac.nz/ml/weka/>

度で認識できるかの分析を行った。実験期間中の1日を除外し、残りをトレーニングデータとし、除外した1日をテストデータとして分析を行う。実験期間中のすべての日程に対して同様の分析を行い、上田らの研究 [8] との認識精度を比較する。評価実験として、スマートホーム内での行動: 「外出」, 「料理」, 「食事」, 「テレビ視聴」, 「食器手洗い」, 「掃除」, 「PC」, 「入浴」, 「読書」, 「睡眠」を対象として Random Forest を用いて識別モデルを構築したところ、F-measure: 68.6% で行動を識別することができた。また、上田らの研究 (F-measure: 73.2%) と比較すると、提案手法は上田らの手法と拮抗する性能を達成できたことが分かった。

2. 関連研究

宅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、ユーザがスマートフォンなどを所持し、スマートフォンに内蔵した加速度センサなどを活用してユーザの行動認識を行うウェアラブルデバイスを活用したアプローチとビデオカメラや接触センサ、圧力センサを用いて認識するタグレス行動認識に大別できる。以降では、それぞれの手法を用いた宅内における行動認識に関する既存研究について述べる。

2.1 ウェアラブルデバイスを活用した行動認識

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の認識については90%以上の正確さがすでに達成されている [10]。一方で、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 [11] 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8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 [7] 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る。

2.2 タグレス行動認識

Brdiczka ら [12] は、カメラを使用した画像処理により、スマートホームにおける生活行動認識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り、居住者のプライバシーを侵害

する恐れがある。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、引出センサ、圧力マット、浮力センサ、温度センサなど多数の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た。認識の正確さは49~98%となっている。この研究は、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の正確さが低いという問題点を持つ。

Chen ら [14] 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%以上の正確さで認識するシステムを構築した。これは、知識ベースのオントロジーにより生活行動を識別しているため、機械学習を用いた手法のように、事前に大量の訓練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。

2.3 本研究のアプローチ

上記で述べた既存研究の問題点をふまえ、本研究では今後普及が期待できるエナジハーベスト赤外線センサ・ドア開閉センサ、電力センサのみを用いることで、導入コストを抑え、装着負担をなくし、プライバシーの侵害が少ない行動認識システムの開発を目的とする。さらに、多種類かつ、抽象的な行動も認識対象に含め、家庭内における基本的な生活行動を網羅した、精度の高い認識システムを目指す。

3. エナジハーベスト赤外線・ドア開閉センサ

3.1 システム要件と基本方針

1章で述べた課題(1)~(6)を解決したスマートホーム向け行動推定システムの実現には、以下の4つの要件を満たす必要がある。

- 《要件1》 多種類かつ抽象的な生活行動を認識できる。
- 《要件2》 低コスト、少数のセンサで実現できる。
- 《要件3》 居住者のプライバシーを侵害しない。
- 《要件4》 タグレスで行動を認識できる。

これらの要件を満たすための基本方針として、《要件1》については、家庭内における基本的な生活行動を網羅するために、「料理をする」、「食事をする」などの10種類の生活行動を対象とする。また、《要件2》, 《要件3》の要件については、導入コストが低い赤外線センサとドア開閉センサ、電力センサを使用して実現する。《要件4》を満たすために、ユーザがタグなどを所持しなくてもユーザの行動センシングができる赤外線センサとドア開閉センサを活用

表 1 生活行動区分の例
Table 1 List of daily activities.

1 次活動	睡眠
	身の回りの用事
	食事
2 次活動	通勤・通学
	仕事（収入をとまなう仕事）
	学業（学生が学校の授業やそれに 関連して行う学習活動）
	家事
	介護・看護
	育児
	買い物
3 次活動	移動（通勤・通学を除く）
	テレビ・ラジオ・新聞・雑誌
	休業・くつろぎ
	学習・自己啓発・訓練（学業以外）
	趣味・娯楽
	スポーツ
	ボランティア活動・社会参加活動
	交際・付き合い
	受診・療養
	その他

する。

3.2 対象の生活行動

平成 23 年総務省統計局では、表 1 のように 1 日の主な行動を 20 種類に分類し、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*2、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 [15]。本研究では、これらの中から宅内の行動で発生頻度が高い、1 次活動の「食事」、「入浴」、「睡眠」、2 次活動の「料理」、「食器手洗い」、「掃除」、3 次活動の「テレビ視聴」、「仕事*3・勉強（PC 使用）」、「読書」、宅外行動として「外出」の計 10 種類を認識の対象とした。

3.3 スマートホームでのセンサデータ収集

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（筆者らの大学内に設置されている 1LDK の実験用住宅設備）において、被験者が実際に日常生活を送ることでデータを収集する。スマートホームには、図 2 に示すエナジハーベスト赤外線センサ 21 個、エナジハーベスタドア開閉センサ 8 個、電力センサ 22 個が設置されている。このエナジハーベストセンサで計測したデータは EnOcean プロトコル*4を用いたセンサネットワークを経由して、電力（電流）センサで計

*2 職場などで行う義務的な性格の強い仕事・業務

*3 宅内で行う補助的な仕事・業務

*4 EnOcean, <https://www.enocean.com/>

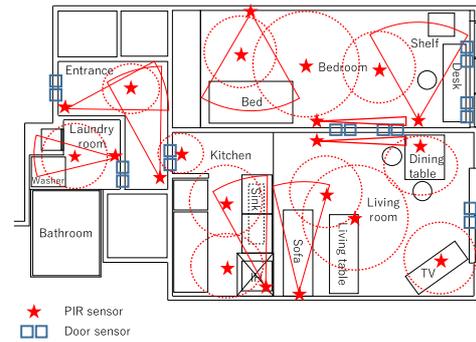


図 1 実験で用いたスマートホームの間取り
Fig. 1 Floor plan of the smart home.

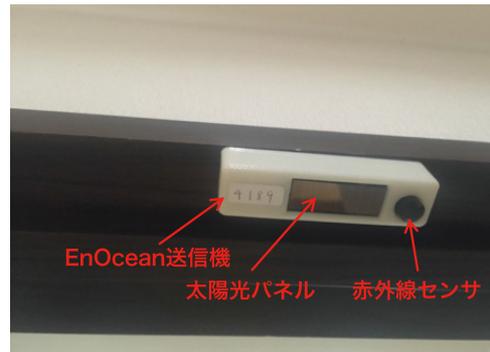


図 2 エナジハーベスト赤外線センサ
Fig. 2 Energy harvesting PIR sensor.



図 3 エナジハーベスタドア開閉センサ
Fig. 3 Energy harvesting door sensor.

測したデータは Bluetooth*5・Zigbee*6を経由してサーバに自動的に蓄積される。

図 2 にエナジハーベスト赤外線センサを示す。また、赤外線センサのうち、2 個が極狭角指向性センサ、7 個が指向性センサ、12 個が広角センサである。極狭角指向性赤外線センサの検出性能*7を図 6 に示す。指向性赤外線センサの検出性能*8を図 7 に示す。広角赤外線センサの検出性能*9を図 8 に示す。図 3 にエナジハーベスタドア開閉

*5 Bluetooth, <https://www.bluetooth.com/>

*6 Zigbee, <http://www.zigbee.org/>

*7 FTN series, http://www.optex-europe.com/cms/documents/FTN-ST_FTN-R_FTN-RAM_FTN-AM.pdf

*8 MX-40, <http://www.optex-europe.com/cms/documents/MX-40-MX-50.pdf>

*9 FX-360, <http://www.optex-europe.com/cms/documents/FX-360.pdf>



図 4 消費電力センサ
Fig. 4 Power meter.



図 5 消費電流センサ
Fig. 5 Current sensor.

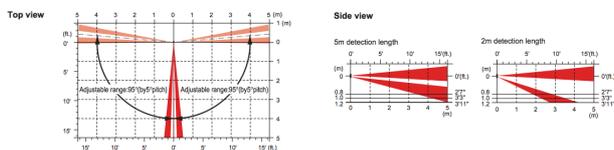


図 6 極狭角指向性赤外線センサの検出性能

Fig. 6 Detection pattern of the ultra narrow directivity PIR sensor.

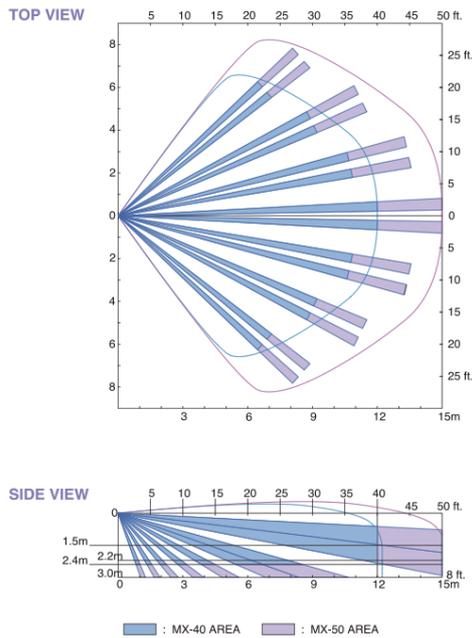


図 7 指向性赤外線センサの検出性能

Fig. 7 Detection pattern of the narrow directivity PIR sensor.

センサモジュールを示す。このモジュールは、赤外線センサ、EnOcean トランスミッタ、エナジハーベスト電力供給部から構成される。

図 1 に赤外線センサとドア開閉センサの設置位置を示す。ユーザの滞在頻度が高いエリアを被覆するように広角型赤外線センサを設置し、「料理」などの特定の行動の発生

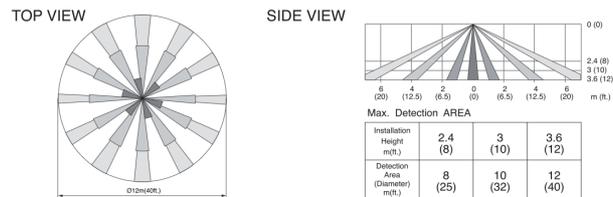


図 8 広角赤外線センサの検出性能

Fig. 8 Detection pattern of the wide directivity PIR sensor.

が高い場所（キッチンの周辺など）に重点的に指向型赤外線センサの配置を行った。また、極狭角指向性赤外線センサと指向性センサについては床から約 1.0m の高さに、広角赤外線センサは床から 2.5m の高さの天井に設置した。ドア開閉センサは Bathroom-Laundry 間を除くユーザが部屋に入退室時に使用するドア、および窓に設置した。赤外線センサはユーザの近接に応じて、デジタル値 (1/0) を出力する。開閉センサはドアの開閉に応じて、デジタル値 (1/0) を出力する。赤外線センサはユーザのモーションを検知したときに、ドア開閉センサはドアの開閉操作が行われたときに、それぞれのセンサ出力の変化を EnOcean プロトコルを用いたネットワークを経由し、サーバに通知する。サーバ側ではタイムスタンプとともに変化をデータベースに記録する。これらのモジュールは日中や室内灯点灯時は内蔵太陽光パネルによってモジュールの動作に必要な電力を賄うことができる。また、ユーザが就寝した後の室内灯による発電さえ望めない状況下では、内蔵リチウム電池に蓄積した電力によって動作する。

図 4 に示す消費電力センサ^{*10}は、家電 (100V 用) の消費電力をセンシングできる。図 5 に示す CT センサは配電盤における電力系統ごとの消費電流をセンシングできる。サンプリング周期は、1 秒間に 1 回である。各部屋に設置したエアコン (2 台)、テレビ、オーディオ、PC、IH キッキングヒータ、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 13 カ所を消費電力センサでセンシングする。また配電盤の 9 系統を消費電流センサでセンシングする。

3.4 生活行動の認識手法

生活行動の認識手法について述べる。本システムでは機械学習により生活行動を識別する。機械学習の適用過程は、(1) 学習に使用する教師データの取得、(2) 取得したトレーニングデータの特徴量の抽出、(3) 生活行動の学習モデルの構築、の 3 つのフェーズから構成される。以下にそれぞれのフェーズの概要について述べる。

(1) トレーニングデータの取得

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トレーニング

^{*10} ラトックシステム Bluetooth ワットチェッカー REX-BTWATTCH1

Time	PIR1	PIR2
0:00:00	1	0
0:00:10	0	0
0:00:20	0	0
0:00:30	1	0
0:00:40	0	1



Time	PIR1	PIR2
0:00:00	1	0
0:00:10	1	0
0:00:20	1	0
0:00:30	1	0
0:00:40	0	1

図 9 赤外線センサの無反応時間に対する補完

Fig. 9 Complement for the dead zone of PIR sensor.

データが必要である。著者らは、文献 [16] において、トレーニング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。本ツールは、スマートホームにおいて収集した多種類のセンサデータの可視化に加え、グラウンドトゥルース（正解値）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、トレーニングデータとして使用される。

(2) 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、それらの行動を識別するために有効なデータの特徴のことである。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（Time-window と呼ぶ）のデータに区切り、最後に必要な特徴量を抽出する。今回は経験的に Time-window を 10 秒とした。予備実験でいくつかの統計量を試した結果、各 Time-window において、赤外線センサと開閉センサはそれぞれの論理和（Time-window 内で 1 度でも反応したセンサはその Time-window 全体で反応があったものと見なす）を電力センサは消費電力の平均値を採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た。

また、赤外線センサはその特性上、ユーザがセンサ周辺に存在する場合でも、移動をとまなわないユーザは検知できない。そのため、図 9 に示すようにユーザが赤外線センサの前で静止した場合は次回ユーザが移動するまで、ユーザが存在しないことを表す“0”がデータとして記録されるため、機械学習の識別モデルを構築できない。そこで、最後に反応した赤外線センサの反応値“1”を自身もしくは他の赤外線センサが反応するまでホールドする補完処理を実施した。

(3) 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トレーニングデータとする機械学習モデルを構築する。分類器の構築はデータマイニングツールである Weka 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いる。先行研究 [8] では、

行動学習モデルの構築のために、代表的な機械学習アルゴリズムである Random Forest, SVM, C4.5 を採用している。本研究においても、先行研究と比較するためにこれら 3 つのアルゴリズムを採用している。その結果、先行研究と同様に Random Forest が最も高い認識精度を示したため、行動学習モデルとして採用している。これら 3 つの学習アルゴリズムの比較については、5 章で後述する。

4. 実験概要

提案手法の性能評価を行うため、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。今回の評価実験において識別対象とする行動は、「外出」、「料理」、「食事」、「テレビ視聴」、「食器手洗い」、「掃除」、「PC」、「入浴」、「読書」、「睡眠」の計 10 種類とした。実験期間中に「食事」と「テレビ視聴」を同時に行ったなどの複合的な行動を行った場合は、被験者に主たる行動を判断してもらい、主たる行動をそのときの行動としている。5 名の被験者（30 代男性 1 名、20 代男性 2 名、20 代女性 2 名）に、それぞれ 2~3 日間ずつ住んでもらい、計 14 日間分のデータセットを収集した。図 1 に各行動に使用される家電や家具の位置、センサの位置を示す。また、グラウンドトゥルースの取得、および上田らの手法 [8] と比較するため、被験者に超音波位置センサの送信機を装着してもらい、実験を行った。

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、グラウンドトゥルース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。トレーニングデータは、赤外線センサの反応とドア開閉センサ、電力センサの 3 つを使用し、抽出した特徴量に対して Random Forest を用いて学習モデルを作成する。各赤外線センサとドア開閉センサの位置を図 1 に示す。特徴量については、Time-window:10 秒で分割した各区間につき、51 個の特徴量（赤外線センサと開閉センサ、電力センサの反応値から構成する特徴量）を使用する。評価は交差検定を用いて行う。交差検定は、データを収集した 14 日のうち 1 日分をテストデータ、残り 13 日分をトレーニングデータとし、テストデータとする日程を切り替えることで実施する。収集したデータのうち 1 日分のテストデータを用いて、赤外線・ドア開閉・電力センサ、赤外線・ドア開閉センサ、赤外線センサのみ、ドア開閉センサのみを用いた場合の推定精度の比較を行う。さらに、Random Forest, C4.5, SVM それぞれの分類器を用いた場合の推定精度の比較を行う。最後に、既存手法と比較するために、上田ら [8] が開発した手法を本データに適用した結果と比較する。なお、上田らはサンプルの時間幅を 5 分、交差検定を全データを 10 分割し実施しているのに対し、本論文では時間幅を 10 秒、交差検定を日別実施しているなどの違いがある。

表 2 赤外線とドア開閉, 電力センサを用いた場合の混同行列
Table 2 Confusion matrix of PIR and door sensors and power meter.

真 \ 予測値	外出	テレビ視聴	仕事・勉強	料理	食事	食器手洗い	読書	入浴	睡眠	掃除	Recall (%)
外出	6	8	4	1	0	0	0	0	0	0	31.6
テレビ視聴	0	420	207	1	2	4	0	2	0	0	66.0
仕事・勉強	0	1	70	2	1	0	0	2	0	0	92.1
料理	0	4	0	223	6	30	0	0	0	0	84.8
食事	0	12	36	1	112	0	0	0	0	0	69.6
食器手洗い	0	0	1	95	0	57	0	0	0	0	37.3
読書	2	0	0	0	0	0	24	0	0	0	92.3
入浴	0	0	0	0	0	0	0	118	0	0	100
睡眠	0	0	0	0	0	0	0	0	7	0	100
掃除	0	15	0	3	0	0	0	8	0	5	16.1
Precision(%)	75.0	91.3	22.0	68.4	92.6	62.6	100	90.8	100	100	

表 4 赤外線とドア開閉, 電力センサそれぞれを用いた場合の比較

Table 4 Comparison between sensors.

評価指標	赤外線・ドア・電力	赤外線・ドア	赤外線	ドア
Precision	81.0%	63.1%	60.6%	18.5%
Recall	69.9%	61.3%	38.9%	35.3%
F-measure	72.1%	61.8%	36.5%	24.3%

表 3 赤外線とドア開閉, 電力センサを用いた場合の評価結果

Table 3 Evaluation result of PIR and door sensors and power meter.

生活行動	Precision	Recall	F 値
外出	75.0%	31.6%	44.4%
テレビ視聴	91.3%	66.0%	76.6%
仕事・勉強	22.0%	92.1%	35.5%
料理	68.4%	84.8%	75.7%
食事	92.6%	69.6%	79.4%
食器手洗い	62.6%	37.3%	46.7%
読書	100%	92.3%	96.0%
入浴	90.8%	100%	95.2%
睡眠	100%	100%	100%
掃除	100%	16.1%	27.8%
平均	81.0%	69.9%	72.1%

5. 実験結果

表 2, 表 3 に提案手法を用いた認識結果を示す. 収集した 14 日分のデータのうち 1 日分のデータに欠損を確認したため, 13 日分のデータを使用した評価を行った. 表 2 の混同行列は, 実験期間 13 日のうちの 8 日目の認識結果を表し, 各行は実際の生活行動を示し, 各列は識別モデルによって予測された生活行動を示す. 表 3 は 8 日目の各生活行動における Precision, Recall, F-measure を示す. Precision (適合率) は, その生活行動であると認識されたデータのうち, 実際にその生活行動であった正しい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正しく認識されたデータの割合である. F-measure は, Precision と Recall の調和平均であり, 次式で表される.

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

表 3 に示すとおり, F-measure: 72.1% が得られた. また, 各生活行動の個別の F-measure を見ると, 「睡眠」が 100% と最も高く, 「掃除」が 27.8% と他に比べて低い結果となった. これは, ユーザの位置情報より行動を推定する提案手法の特性上, ユーザの行動が発生する位置が一定かつ他の行動に比べて特異なエリアに集中する行動ほど推定精度が高くなるためである. つまり, ユーザが「睡眠」を行うときは必ずベッド周辺に滞在するため, 推定精度が高くなり, 逆に「掃除」はユーザがスマートホーム内の様々な場所に移動するため, 推定精度が低くなったと考えられ

る. さらには, ユーザがソファで「食事」をとった場合, 「仕事・勉強」との区別も難しくなる.

次に, 1 日分のテストデータを用いて使用するセンサの種類を変えた場合と使用する分類器を変えた場合の比較を示す. 表 4 に赤外線センサとドア開閉センサ, 電力センサのすべて, 赤外線センサとドア開閉センサ, 赤外線センサのみ, ドア開閉センサのみを用いた場合の Precision, Recall, F-measure の比較を示す. F-measure で比較すると赤外線とドア開閉センサ, 電力センサすべてを用いた場合が最も高く, 次いで赤外線センサとドア開閉センサ, 赤外線センサのみ, ドア開閉センサのみの順番となる. 赤外線センサとドア開閉センサを用いた場合, ユーザのおおまかな位置までしか推定できないため, 「料理」と「食器手

表 5 Random Forest, SVM, C4.5 を用いた場合の評価結果
Table 5 Comparision between Random Forest, SVM, and C4.5.

推定手法	Random Forest	SVM	C4.5
Precision	81.0%	75.1%	73.7%
Recall	69.9%	69.3%	59.6%
F-measure	72.1%	69.9%	61.8%

表 6 上田らの手法との比較
Table 6 Comparison with Ueda's method.

評価指標	提案手法	上田らの手法 [8]
Precision	78.6%	78.6%
Recall	68.6%	74.1%
F-measure	68.6%	73.2%

洗い」などの同じ位置で発生する異なる行動の区別が難しく、推定精度が悪化していると考えられる。赤外線センサのみ、ドア開閉センサのみの場合は、細かい行動の区別ができず、行動認識は難しいと考えられる。次に表 5 に分類器として Random Forest と SVM, C4.5 それぞれを用いた場合の識別結果を示す。評価結果より Random Forest を用いた場合の認識結果が最も高くなることが分かった。

最後に表 6 に提案手法と上田ら [8] が開発した手法を本データに適用し、交差検定を行った結果を比較する。なお、上田らの手法を用いた場合の精度について、文献 [8] では 90%以上の精度を達成しているが、本実験では 73%にとどまっている。これは、文献 [8] ではサンプルの時間幅を 5 分、交差検定を全データを 10 分割し実施しているのに対し、本実験では時間幅を 10 秒、交差検定を日別に実施しているなどの違いがあるためである。

6. 考察

6.1 タグレス行動認識手法の有効性について

提案手法では、エナジハーベスト赤外線・ドア開閉センサと消費電力センサを活用することで、タグレス行動認識を実現した。今回参加した実験参加者に口頭でのアンケートをとったところ、参加者よりタグレス行動認識手法を支持する意見が得られた。これは、実験時にグラウンドトゥールズの取得、および上田らの手法と比較するために超音波位置測位を用いたため、被験者はつねに超音波送信機を肩の位置に固定する必要があるが、装着負担が大きかったことが影響していると考えられる。また、実験期間中において、入浴後にタグを装着し忘れ、正しい位置情報が取得できない期間が存在していた。このようなタグの装着し忘れが発生することを考えると、実運用時にはタグレス行動認識手法が有効であると考えられる。

6.2 コスト削減効果

上田らの手法は導入時の価格で 300 万円程度の超音波位

置センサ*11を使用している。これに対して提案手法では、1 個あたり 3,000 円程度のエナジハーベストセンサ*12と 3,000 円程度の赤外線センサ*13を活用しているためトータルコストで 30 万円以下での導入が可能である。また、電力自由化にともない将来のスマートホームでは各家電の使用状況をモニタリングできるスマートメータの普及が期待でき、電力データの取得コストは考慮しなくてもよくなる。さらに、超音波位置センサは定期的に超音波送信機のバッテリー交換を必要とするのに対して、提案手法では半永続的な運用が可能なエナジハーベストセンサを活用するため、バッテリーを交換する必要がなく、運用コストを下げるができる。これらのことから、提案手法は大幅なコスト削減を実現していることが分かる。今後、エナジハーベストセンサなどの普及にともない、さらなるコスト削減ができる。と考える。

6.3 センサ設置方法と補完アルゴリズムの改善について

3.4 節で述べたように、赤外線センサの不感帯に対する補完処理を行い、ユーザの行動推定を実現した。しかし、今回の実験環境の場合、リビングに設置した赤外線センサなど、ユーザが赤外線センサの近くに存在した場合、2 つ以上の赤外線センサが同時に反応することが考えられる。今回採用した補完処理では、最後に反応した赤外線センサのみが補完されるため、本来 2 つ以上反応すべき場合であっても、1 つのセンサしかできていない。このため、不完全なセンサの反応パターンが記録されることとなり、推定精度が低下していると考えられる。

この課題の解決には 2 つの方法が考えられる。1 つ目は、可能な限り赤外線センサの検出範囲が重複しないように工夫して配置し、同じ行動をした場合に異なる検出パターンとならないようにする方法である。2 つ目は、赤外線センサの配置方法を工夫したうえで、検出範囲が広範囲にわたって重複する赤外線センサの組合せについては個別にグループ化し、グループに属する赤外線センサが 1 つでも反応した場合は、グループに属するすべての赤外線センサの反応値を“1”でホールドすることでこの課題に対処する方法である。これら 2 つの方法を採用することで、さらに推定精度を向上させることができると考える。

評価実験の結果、行動の識別精度は、平均 F-measure: 68.6%となっている。この結果は一定の成果であると考えられるが、既存研究の問題点として示した (6) 認識精度が低いという課題を十分に解決しているとはいえない。前述した

*11 NEC エンジニアリング SmartCoordinator, <http://www.nec-eng.co.jp/press/131106press.html>

*12 EnOcean マグネットセンサ STM429J, <https://www.switch-science.com/catalog/1904/>

*13 Panasonic EKMB1100100, <http://www.digikey.jp/product-detail/ja/panasonic-electric-works/EKMB1101112/255-3066-ND/2601860/>

センサの配置や補間アルゴリズムの改良することで、実運用に向けてさらなる精度向上が求められる。今後の課題としたい。

7. おわりに

本論文では、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識別する手法を提案した。提案システムでは、住人の装着負担を低減し、プライバシーの確保や導入コストを抑えるためにエナジハーベスト赤外線センサ・ドア開閉センサ、電力センサのみを使用した。評価実験として、スマートホーム内の行動：「外出」、「料理」、「食事」、「テレビ視聴」、「食器手洗い」、「掃除」、「PC」、「入浴」、「読書」、「睡眠」を対象として Random Forest を用いて識別モデルを構築したところ、平均 F-measure: 68.6%で行動を識別することができた。

今後の予定としては、導入コストをさらに下げするため、推定精度を保ちつつセンサ数を減らすことを予定している。そこで、センサの時系列変化よりユーザの生活パターンを推定し、補完する手法を開発する予定である。さらには、家庭内での基本的な生活行動を網羅するために、他の行動も識別対象に含めて精度を評価したい。その際に、類似した位置の行動などは識別が困難になると考えられるため、行動の時刻や、センサデータの分散など、特徴量を増やすことで対応する予定である。また、本手法では一人暮らしのサポートを想定しているため、認識可能な最大ユーザ数は1人である。しかし、家族世帯などの複数人が居住するスマートホームを想定した場合、十分とはいえない。複数人に対応した研究として、村尾らが赤外線センサを活用した複数人の住宅内人物移動推定手法を提案している [17]。今後、これらの研究を参考に複数人への対応方法について検討する。

謝辞 本研究の一部は、科研費基盤研究 (A) (No.16H01721)、科研費基盤研究 (C) (No.16K00126) の助成によって行った。また、ラトックシステム株式会社様や荒川周造様には本研究で用いたセンサデバイスの提供をはじめとして多大なご協力をいただいた。ここに記して謝意を示す。

参考文献

- [1] Scott, J., Brush, A.J.B., Krumm, J., Meyers, B., Hazas, M., Hodges, S. and Villar, N.: PreHeat: Controlling Home Heating Using Occupancy Prediction, *Proc. 13th International Conference on Ubiquitous Computing - UbiComp '11*, p.281, ACM Press (2011).
- [2] Barker, S., Mishra, A., Irwin, D., Shenoy, P. and Albrecht, J.: SmartCap: Flattening peak electricity demand in smart homes, *2012 IEEE International Conference on Pervasive Computing and Communications*, pp.67–75, IEEE (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.-T., Soh, J.-Y., Kim, S.-H. and Chung, K.-Y.: Emergency Situation Alarm System Motion Using Tracking of People like Elderly Live Alone, *2013 International Conference on Information Science and Applications (ICISA)*, pp.1–4, IEEE (2013).
- [5] Hoey, J. and Little, J.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.1118–32 (2007).
- [6] Fiore, L., Fehr, D., Bodor, R., Drenner, 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] Mase, K.: Activity and location recognition using wearable sensors, *IEEE Pervasive Computing*, Vol.1, No.3, pp.24–32 (2002).
- [8] 上田健揮, 玉井森彦, 荒川 豊, 諏訪博彦, 安本慶一: 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, *情報処理学会論文誌*, Vol.57, No.2, pp.416–425 (2016).
- [9] Ueda, K., Tamai, M. and Yasumoto, K.: A method for recognizing living activities in homes using positioning sensor and power meters, *2015 IEEE International Conference on Pervasive Computing and Communication Workshops (PerCom Workshops)*, pp.354–359, IEEE (2015).
- [10] Lara, O.D. and Labrador, M.A.: A Survey on Human Activity Recognition using Wearable Sensors, *IEEE Communications Surveys & Tutorials*, Vol.15, No.3, pp.1192–1209 (2013).
- [11] Bao, L. and Intille, S.S.: Pervasive Computing: Second International Conference, *Proc. PERSVASIVE 2004*, LNCS 3001, pp.1–17, Springer Berlin Heidelberg, Berlin, Heidelberg (2004).
- [12] Brdiczka, O., Langet, M., Maisonnasse, J. and Crowley, J.L.: 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., Englebienne, G. and Kröse, B.J.A.: An activity monitoring system for elderly care using generative and discriminative models, *Personal and Ubiquitous Computing*, Vol.14, No.6, pp.489–498 (2010).
- [14] Chen, L., Nugent, C.D. 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).
- [15] 総務省 平成 23 年社会生活基本調査, 入手先 (<http://www.stat.go.jp/data/shakai/2011/>).
- [16] 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, *マルチメディア通信と分散処理ワークショップ論文集*, Vol.2013, No.6, pp.116–118 (2013).
- [17] 村尾和哉, 寺田 努, 矢野 愛, 松倉隆一: 疎に配置された赤外線人感センサを用いた住宅内人物移動推定, *マルチメディア, 分散協調とモバイルシンボジウム 2014 論文集*, Vol.2014, pp.1869–1876 (2014).



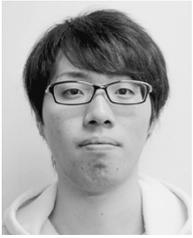
柏本 幸俊 (学生会員)

2012年神戸大学電気電子工学科卒業。2014年奈良先端科学技術大学院大学情報科学研究科修士課程修了。同年同大学博士後期課程在学中。ユビキタスコンピューティング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。



秦 恭史

2012年奈良工業高等専門学校電気工学科卒業。2015年奈良工業高等専門学校専攻科電子情報工学専攻修了。同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入学。ソーシャルデータ分析に関する研究に従事。



繁住 健哉

2002年東京工業大学理学部卒業。2010年同大学院情報理工学研究科博士後期課程修了。博士(理学)。アルゴリズムの理論研究に従事。2015年よりローム株式会社にて無線モジュールの商品開発に従事。



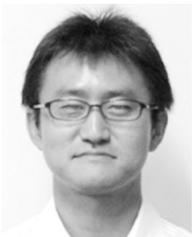
中川 愛梨 (学生会員)

2015年奈良女子大学理学部情報科学科卒業。同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入学。スマートホームにおける行動認識に関する研究に従事。



小宮 邦裕

1993年大阪工業大学電気工学科卒業。同年ローム株式会社へ入社し半導体集積回路設計に従事。2012年センサネットワーク関連の研究開発に従事し、2016年より事業部にて無線センサモジュールの商品開発に従事。



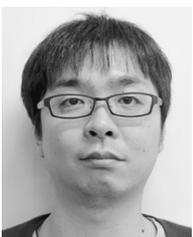
諏訪 博彦 (正会員)

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。



小西 健太

2009年名古屋大学工学部物理工学科卒業。2014年ローム株式会社へ入社しセンサネットワーク関連の研究開発に従事し、2016年より事業部にて無線センサモジュールの商品開発に従事。



藤本 まなと (正会員)

2009年関西大学工学部卒業。2015年同大学院博士課程後期課程修了。博士(工学)。2015年より奈良先端科学技術大学院大学助教。位置推定、行動認識、無線通信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。博士(工学)。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。