

エナジハーベスト赤外線センサ・ドア開閉センサを 活用したスマートホーム向け行動推定

柏本 幸俊^{†1} 秦 恭史^{†1} 諏訪 博彦^{†1} 藤本 まなと^{†1} 荒川 豊^{†1} 繁住 健哉^{†2} 小宮 邦裕^{†2}
小西 健太^{†2} 安本 慶一^{†1}

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. 本研究では屋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. 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. しかし, 既存研究は導入コストが高く, ユーザへの装着負担が大きい. 本研究では, エナジハーベスト焦電型赤外線センサ・ドア開閉センサ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, 日光下では太陽光パネルで発電した電力で焦電型赤外線センサ, ドア開閉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. 夜間等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. スマートホーム内に 19 個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, 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) で, 計 5 名の被験者に 2~3 日ずつ生活してもらい, 計 14 日間評価実験を行った, 実験の際に日常生活で考えられる 8 種類の行動に対してセンサデータを記録した. 評価実験の結果, 平均 F-value:62.8%でユーザの行動を推定した.

Activity Recognition with Battery-free Infrared and Door Sensors in Smart Home

YUKITOSHI KASHIMOTO^{†1} KYOJI HATA^{†1} HIROHIKO SUWA^{†1} MANATO FUJIMOTO^{†1}
YUTAKA ARAKAWA^{†1} TAKEYA SHIGEZUMI^{†2} KUNIHIRO KOMIYA^{†2} KENTA KONISHI^{†2}
KEIICHI YASUMOTO^{†1}

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盛んに行われており, 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. 本研究では屋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, 全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等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」等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」等の行動推定は難しい. また,

^{†1} 現在, 奈良先端科学技術大学院大学

^{†2} 現在, ローム株式会社

ユーザが常にデバイスを保持する必要があり、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) カメラ等の機器によるプライバシーの侵害、(2) 認識できる行動の種類が少ない (3) 認識の精度が低い、(4) 導入・運用コストが高い、(5) ユーザへの装着負担が大きい、(6) 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。

我々の研究グループのこれまでの取り組みとして上田 [8][9] らは、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)~(3)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(4)については達成できていない。また、常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(5)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(6)の達成も難しい。よって、課題(1)~(3)を達成したまま、課題(4)(5)(6)を解決する必要がある。

本研究では、エナジハーベスト焦電型赤外線センサとドア開閉センサを活用し、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焦電型赤外線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。夜間等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。エナジハーベスト焦電型赤外線センサと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、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焦電型赤外線センサで、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。従って、先に述べた課題(1)~(6)の全てを解決することができる。スマートホーム内に19個のエナジハーベスト焦電型赤外線センサとドア開閉センサを設置し、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、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(ILDK)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8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。実験期間中の全ての日程に対して同様の分析を行い、上田らの研究との認識精

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:「食事」、「バスルーム活動」、「睡眠」、「料理」、「掃除」、「リビング活動」、「仕事・勉強(PC使用)」、「外出」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-value:62.8%で行動を識別することができた。

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、ユーザがスマートフォン等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。

2.1 ウェアラブルデバイスを活用した行動認識に関する研究

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%以上の正確さが既に達成されている [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 タグレス行動認識に関する研究

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言えない。

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上に、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

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

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踏まえ、本研究では今後普及するであろうエナジハーベスト赤外線センサとドア開閉センサのみを用いることで、導入コストを抑え、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》 タグレス行動推定システム

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20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、導入コストが低い焦電型赤外線センサとドア開閉センサを使用して実現する。《要件4》を満たすために、ユーザがタグ等を所持しなくてもユーザの行動センシングができる焦電型赤外線センサとドア開閉センサを活用する。

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、家事など社会生活を営む上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」、「バスルーム活動」、「睡眠」、2次活動の「料理」、「掃除」、3次活動の「リビング活動」、「仕事・勉強(PC使用)」、「外出」の計8種類を認識の対象とした。バスルーム活動とは入浴・洗濯機操作・洗顔・浴室掃除などのバスルームや洗面台で行われる活動のことである。リビング活動とはテレビ視聴・テレビゲーム・スマートフォン操作・読書等のリビングで行われる活動のことである。

表1 生活行動区分の例

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(収入を伴う仕事) 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

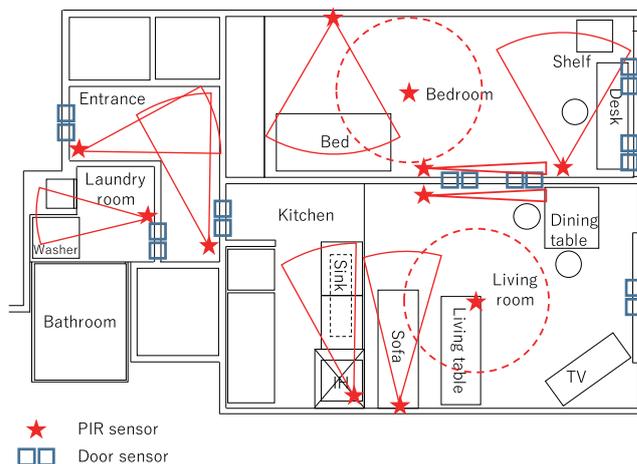


図1 実験で用いたスマートホームの間取り

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（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焦電型赤外線センサ11個（うち指向性赤外線センサ9個）、ドア開閉センサ8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*2を用いたセンサネットワークを経由して、サーバに自動的に蓄積される。

図2にエナジハーベスト焦電型赤外線センサを示す。図3にドア開閉センサモジュールのシステム構成を示す。このモジュールは、焦電型赤外線センサ、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。焦電型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

*2 <https://www.enocean.com>



図 2 エナジハーベスト焦電型赤外線センサ



図 3 エナジハーベストドア開閉センサ

デジタル値 (1/0) を出力する。赤外線センサはユーザーのモーションを検知した時に、ドア開閉センサはドアの開閉操作が行われた時に、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、ユーザーが就寝した後等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。

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、グラウンドトゥールズ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

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 4 赤外線センサの無反応時間に対する補完

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。予備実験で幾つかの統計量を試した結果、各 Time-window における赤外線センサと開閉センサそれぞれの OR 積 (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みなす) 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、ユーザーがセンサ周辺に存在している間でも、移動を伴わない場合はユーザーを検知できない。そのため、図 4 に示すようにユーザーが赤外線センサの前で静止した場合は次回ユーザーが移動するまで、ユーザー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おり、本研究では、代表的な機械学習アルゴリズムである Random Forest 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。

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、「食事」、「バスルーム活動」、「睡眠」、「料理」、「掃除」、「リビング活動」、「仕事・勉強 (PC 使用)」、「外出」の計 8 種類とした。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

表 2 赤外線センサとドア開閉センサを両方用いた場合の混同行列

	外出	リビング活動	仕事・勉強	料理	食事	バスルーム活動	睡眠	掃除
外出	41	0	0	0	0	0	0	0
リビング活動	0	459	186	3	7	0	0	0
仕事・勉強	9	168	526	100	129	3	0	0
料理	1	2	0	238	0	0	0	0
食事	1	68	31	8	4	0	0	0
バスルーム活動	2	0	0	0	0	210	5	0
睡眠	0	0	0	0	0	0	5	0
掃除	2	2	1	6	3	3	1	5

表 3 赤外線センサとドア開閉センサを両方用いた場合の評価結果

生活行動	Precision	Recall	F 値
外出	74.5%	84.9%	72.5%
リビング活動	58.2%	65.6%	58.4%
仕事・勉強	23.9%	16.5%	18.2%
料理	75.9%	85.2%	79.3%
食事	18.4%	79.5%	10.3%
バスルーム活動	95.3%	91.1%	92.6%
睡眠	61.2%	62.8%	59.5%
掃除	27.5%	14.0%	17.1%
平均	65.8%	64.0%	62.8%

表 4 赤外線センサとドア開閉センサそれぞれを用いた場合の比較

評価指標	赤外線・ドア	赤外線	ドア
Precision	65.8%	66.2%	29.3%
Recall	64.0%	67.1%	31.1%
F-value	62.8%	61.2%	24.9%

表 5 上田らの手法との比較

評価指標	上田らの手法	
	提案手法	(超音波位置センサ)
Precision	65.8%	76.9%
Recall	64.0%	70.1%
F-value	62.8%	70.2%

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。

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の 2 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、19 個の特徴量(赤外線センサと開閉センサの反応値から構成する特徴量)を使用した。学習モデルは、赤外線センサとドア開閉センサを両方使用した場合と、赤外線センサのみの場合、ドア開閉センサのみの場合の計 3 パターンを用意してそれ

ぞれ交差検定による評価を行った。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。また、既存手法と比較するために、上田らが開発した手法のうち超音波位置測位を活用した行動推定手法と推定精度の比較を行う。赤外線センサと開閉センサを用いる場合と同様に、超音波によって推定した位置情報(Time-window:10 秒)に対して、Random Forest を用いて学習モデルを作成する。評価も同様の交差検定によって実施する。

5. 実験結果

表 2, 表 3 に赤外線センサとドア開閉センサを両方用いた学習モデルによる認識結果を示す。表 2 の混同行列は、実験期間 14 日のうちの 3 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 は実験期間 14 日に対して交差検定を行った時の、各生活行動における平均 Precision, Recall, F-value 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-value は、Precision と Recall の調和平均であり、次式で表される。

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

表 3 に示す通り、赤外線センサとドア開閉センサを用いた学習モデルを使用した場合、平均 F-value:65.8% が得られた。また、各生活行動の個別の平均 F-value を見ると、「バスルーム活動」が 92.6% と最も高く、「食事」が 10.3% 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「バスルーム活動」を行うときは必ずランドリールーム内に滞在するため、推定精度が高くなり、逆に「食事」はユーザによって食事を取る位置がダイニングテーブル周辺や、ソファ等まちまちであるため、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」を取った場合、TV 視聴等を含む「リビング活動」との区別も難しくなる。

次に表 4 に赤外線センサとドア開閉センサ両方、赤外

線センサのみ、ドア開閉センサのみを用いた場合の平均 Precision, Recall, F-value の比較を示す。F-value で比較すると赤外線とドア開閉センサ両方を用いた場合が最も高く、次いで赤外線センサのみ、ドア開閉センサのみの順番となる。赤外線センサのみの場合でもユーザの行動を推定できているが、ドア開閉センサを追加することでユーザの在室状況をより正確に取得できるため、推定精度が向上していると考えられる。一方でドア開閉センサのみでは、部屋内でのユーザの位置を推定できないため、TV 視聴と食事との区別が難しいと考えられる。

次に表 5 に提案手法と超音波位置測位を用いた上田らの手法との比較を示す。F-value で比較すると、提案手法は上田らの手法より高い推定精度ではないものの拮抗する性能を示していることが分かる。また、上田らの手法に比べて 1 章で述べた課題 (1)~(6) を全て解決できていることから、提案手法に優位性がある。

6. 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識別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コストを抑えるためにエナジハーベスト焦電型赤外線センサとドア開閉センサのみを使用した。評価実験として、スマートホーム内での行動:「食事」、「バスルーム活動」、「睡眠」、「料理」、「掃除」、「リビング活動」、「仕事・勉強(PC使用)」、「外出」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-value:62.8%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。また、将来普及が期待されているスマートホームにはどの家電をユーザが使用しているかを推定できるスマートメータが設置されている。したがって、家電の使用ログを活用することで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。

参考文献

[1] James Scott, A.J. Bernheim Brush, John Krumm, Brian Meyers, Michael Hazas, Stephen Hodges, and Nicolas Villar. PreHeat. In *Proceedings of the 13th international conference on Ubiquitous computing - UbiComp '11*, p. 281, New York, New York, USA, 9 2011. ACM Press.

[2] Sean Barker, Aditya Mishra, David Irwin, Prashant Shenoy, and Jeannie Albrecht. SmartCap: Flattening peak electricity demand in smart homes. In *2012 IEEE International Conference on Pervasive Computing and Communications*, pp. 67–75. IEEE, 3 2012.

[3] Parisa Rashidi and Alex Mihailidis. A Survey on Ambient-Assisted Living Tools for Older Adults. *IEEE Journal of Biomedical and Health Informatics*, Vol. 17, No. 3, pp. 579–590, 5 2013.

[4] Jong-Tak Kim, Jae-Yong Soh, Sung-Ho Kim, and Kyung-Yong Chung. Emergency Situation Alarm System Motion Using Tracking of People like Elderly Live Alone. In *2013 International Conference on Information Science and Applications (ICISA)*, pp. 1–4. IEEE, 6 2013.

[5] Jesse Hoey and James J Little. Value-directed human behavior analysis from video using partially observable Markov decision processes. *IEEE transactions on pattern analysis and machine intelligence*, Vol. 29, No. 7, pp. 1118–32, 7 2007.

[6] Loren Fiore, Duc Fehr, Robot Bodor, Andrew Drenner, Guruprasad Somasundaram, and Nikolaos Papanikolopoulos. Multi-Camera Human Activity Monitoring. *Journal of Intelligent and Robotic Systems*, Vol. 52, No. 1, pp. 5–43, 1 2008.

[7] Kenji Mase. Activity and location recognition using wearable sensors. *IEEE Pervasive Computing*, Vol. 1, No. 3, pp. 24–32, 7 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, 2 2016.

[9] Kenji Ueda, Morihiko Tamai, and Keiichi Yasumoto. A method for recognizing living activities in homes using positioning sensor and power meters. In *2015 IEEE International Conference on Pervasive Computing and Communication Workshops (PerCom Workshops)*, pp. 354–359. IEEE, 3 2015.

[10] Oscar D. Lara and Miguel A. Labrador. A Survey on Human Activity Recognition using Wearable Sensors. *IEEE Communications Surveys & Tutorials*, Vol. 15, No. 3, pp. 1192–1209, 23 2013.

[11] Ling Bao and Stephen S Intille. Pervasive Computing: Second International Conference, Pervasive 2004, Linz/Vienna, Austria, April 21–23, 2004. *Proceedings. chapter Activity R*, pp. 1–17. Springer Berlin Heidelberg, Berlin, Heidelberg, 2004.

[12] Oliver Brdiczka, Matthieu Langet, Jrme Maisonnasse, and James L. Crowley. Detecting Human Behavior Models From Multimodal Observation in a Smart Home. *IEEE Transactions on Automation Science and Engineering*, Vol. 6, No. 4, pp. 588–597, 10 2009.

[13] Tim L. van Kasteren, Gwenn Englebienne, and Ben. J. A. Kröse. An activity monitoring system for elderly care using generative and discriminative models. *Personal and Ubiquitous Computing*, Vol. 14, No. 6, pp. 489–498, 2 2010.

[14] Liming Chen, Chris D. Nugent, and Hui Wang. A Knowledge-Driven Approach to Activity Recognition in Smart Homes. *IEEE Transactions on Knowledge and Data Engineering*, Vol. 24, No. 6, pp. 961–974, 6 2012.

[15] 総務省 平成 23 年 社会生活基本調査. <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, 11 2013.