

# アナログ出力焦電型赤外線センサを活用した スマートホーム向け宅内行動認識

藤原 聖司<sup>†1</sup> 柏本 幸俊<sup>†1</sup> 藤本 まなと<sup>†1</sup> 諏訪 博彦<sup>†1</sup> 荒川 豊<sup>†1</sup> 安本 慶一<sup>†1</sup>

**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正確かつ安価に認識できることが重要である。本研究では高精度かつ低コストで屋内生活行動を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認識のアプローチは多数存在し、我々もこれまで焦電型赤外線センサとドア開閉センサ、消費電力センサを活用してスマートホーム向け行動認識手法を開発した。しかし、これらの先行研究においては、ユーザが同じ位置で異なる行動を行った場合の識別（ソファで読書した場合と食事した場合の識別など）が難しいという問題があった。本研究では、アナログ出力焦電型赤外線センサを新規に開発し、人の細かな動きを検出することで、この問題を解決する。提案手法では、人の細かな動きによってアナログ出力焦電型赤外線センサの出力パターンや周波数成分に違いが生じることに着目し、機械学習を用いて同じ位置での異なる行動を識別する。提案手法の有用性を評価するため、スマートホーム設備 (1LDK) で、計 3 名の被験者がソファに着座した状態で 4 種類の異なる行動を行う実験を実施した。その結果、平均 F-Measure: 75.3% でユーザの行動を認識可能であることを確認した。

## 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正確かつ安価に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認識に関する研究は多数提案されている。その一つとして、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、全ての部屋で行動認識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。

他の手法として、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][8] 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」等の行動認識は難しい。また、ユーザが常にデバイスを保持する必要がある、定期的にバッテリーを交換 (充電) する必要があるという点で、ユーザへの負担が大きい。

まとめると、既存研究は、(課題 1) カメラ等の機器によるプライバシーの侵害、(課題 2) 導入・運用コストが高い、(課題 3) ユーザへの装着負担が大きい、(課題 4) 認識の精度が低いという 4 つの課題が存在する。

我々の先行研究として、上田ら [9][10] や中川ら [11][12] 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た行動認識手法を提案している。また、柏本ら [13] はデジタル出力焦電型赤外線センサとドア開閉センサを用いて、8 種類の行動を認識する手法を開発しており、(課題 1)~(課題 4) の解決に取り組んでいる。しかし、これらの研究ではセンサで取得した位置情報と家電の消費電力情報を用いてユーザの行動を認識するため、同じ位置で異なる行動を行った場合 (ユーザがソファに着座した状態で「スマートフォン操作」や「読書」を行った場合など) の区別が難しいという課題 (課題 5) が存在する。

<sup>†1</sup> 現在、奈良先端科学技術大学院大学  
Presently with Nara Institute of Science and Technology

本研究では、アナログ出力焦電型赤外線センサを開発・活用し、同じような位置・消費電力の状況下での異なる行動の認識に関する問題を解決することを目的とする。

柏本らが文献 [13] で用いた赤外線センサはデジタル出力焦電型赤外線センサで、ユーザが赤外線センサの周辺に存在する場合は“1”が出力され、ユーザが赤外線センサから離れた場合は“0”が出力されるセンサである。これに対して、本研究で用いるアナログ出力焦電型赤外線は、ユーザが赤外線センサの周辺に存在する時は高電圧、ユーザが赤外線センサから離れた時は低電圧を出力する。さらには、ユーザが赤外線センサの近辺で活発に移動したり、速い移動速度で接近した場合は、センサの時系列出力パターンが変化する。本研究のアイデアはこのアナログ出力焦電型赤外線センサの出力における単位時間あたりの振幅や周波数を特徴量とした機械学習を行うことで、同じ位置で異なる行動を行った場合でも行動認識可能なシステムを実現することである。アナログ出力焦電型赤外線センサを活用することで、「食事」などの体動の大きな行動と、「読書」などの体動の小さな行動での変化を捕捉する。

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) で計 3 名の被験者で評価実験を行った。予備調査の結果、先行研究において認識対象としている行動のうち、ソファに着座した状態で行われる頻度が高い「食事」、「PC」、「読書」、「スマートフォン」の 4 つの行動を認識対象とした。実験により取得したデータを使用して、Python<sup>\*1</sup> を用いた特徴量抽出を行い、Weka<sup>\*2</sup> を用いた機械学習により、各行動がどの程度の精度で認識できるかの分析を行った。3 日間の実験データに対して 10 分割交差検証を行った結果、平均 F-Measure: 75.3% で行動を識別できた。

本研究の貢献を以下に示す。

- スマートホームにおける従来の位置-行動相関を用いた手法での推定が難しい同じ位置で異なる行動を行った場合の行動認識を可能としたこと。
- アナログ出力焦電型赤外線センサの開発と活用アイデア。
- 既に普及しているデジタル出力焦電型赤外線センサをアナログ出力に簡便な方法で改造することで導入コストを下げたこと。

## 2. 関連研究

屋内での行動認識に関する研究は盛んに進められており、様々な手法が提案されている。行動認識に関する研究は、スマートフォンなどのウェアラブル端末に内蔵の加速度センサを用いた手法と、ビデオカメラを用いた手法の 2 つに大きく分けることができる。本章では、それぞれの手法に

よる屋内での行動認識に関する関連研究について述べる。

### 2.1 ウェアラブルデバイスを用いた行動認識

スマートフォン等のウェアラブルデバイスに内蔵された加速度センサ、ジャイロセンサを用いて、ユーザの行動を認識する研究が行われている。歩く、走る、座る等の単純な行動については、90%以上の精度での行動認識がすでに達成されている [7]。Mase ら [8] は、加速度センサとジャイロセンサを内蔵したセンシングデバイスをユーザに装着し測定することで、「歩く」、「走る」、「座る」行動を推定する手法を提案している。

しかし、ウェアラブルデバイスを用いた行動認識は、ユーザの姿勢に強く関連した行動しか推定することができない。また、ユーザが常にデバイスを携帯する必要があり、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、定期的に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ため、運用コストが大きい。

### 2.2 カメラを用いた行動認識

カメラで撮影した映像から、ユーザの行動を認識する研究が行なわれている。Hoey ら [5] は部分観測マルコフ決定過程を用いて、カメラで撮影した画像から人の行動を認識する手法を提案している。また、Loren ら [6] は建物内に複数のカメラを設置して歩行者を撮影し、撮影した映像に対して画像処理を行うことで歩行者の行動を推定するシステムを提案している。

しかし、全ての部屋で行動認識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。また、カメラを用いた行動認識は顔などの個人情報が多く含まれた映像を用いる必要がある。従って、プライバシーの侵害が問題となる。

### 2.3 本研究でのアプローチ

上記で述べた既存研究での問題点を踏まえ、本研究では安価な焦電型赤外線センサを用いることで導入・運用コストを抑え、かつプライバシー侵害の少ない行動認識システムの開発を目的とする。さらに、既存のデジタル出力焦電型赤外線センサを簡便な方法で改造してアナログ出力センサとして使用することで、同じ場所で異なる動作を行った場合でもそれぞれの行動を高精度で識別できるシステムを開発する。

我々の先行研究 [11] では、1 章で述べた (課題 1) プライバシーの侵害、(課題 2) 導入・運用コストが高い、(課題 3) ユーザへの装着負担が大きい、の 3 つの課題を解決するために、以下の要件を挙げている。

(要件 1) カメラおよびマイクを使わない。

<sup>\*1</sup> <https://www.python.org/>

<sup>\*2</sup> <http://www.cs.waikato.ac.nz/ml/weka/>

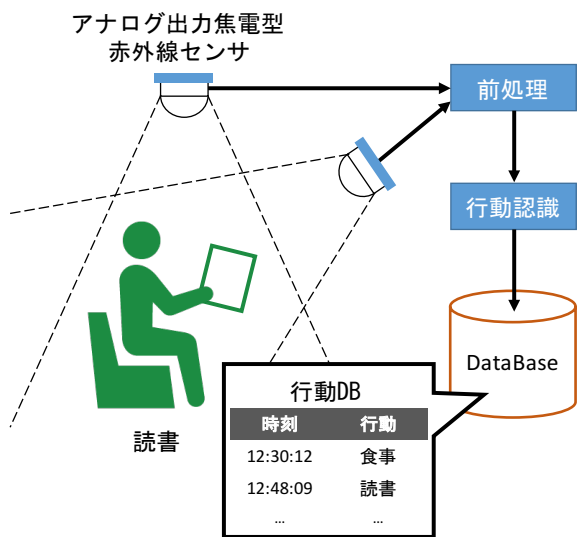


図 1 システム構成

- (要件 2) 低コスト，少数のセンサで実現できる。
- (要件 3) タグレスで行動を認識できる。

本研究では，これらの要件を満たしながら，(課題 4) 認識精度が低い，と (課題 5) 同じ位置で異なる行動をした際の識別が難しい，を解決するために，次の要件を満たす必要がある。

- (要件 4) ユーザが同じ場所で行った異なる行動を高精度で認識できる。

これらの要件を満たすための基本的なアプローチとして，(要件 1)，(要件 2) を満たすために，低コストで導入可能な焦電型赤外線センサを採用することで要件を満たす。(要件 3) については，ユーザがタグ等を所持しなくてもセンシングが可能な焦電型赤外線センサを用いることで実現する。(要件 4) については，同じ場所で異なる動作を行った場合の動作を認識するために，ユーザの位置や動作に応じて出力が連続的に変化するアナログ出力焦電型赤外線センサを開発する。

### 3. アナログ出力焦電型赤外線センサを活用した行動認識

#### 3.1 システム概要

本研究で提案するシステムの構成を図 1 に示す。提案システムは複数のアナログ出力焦電型赤外線センサ，前処理モジュール，行動認識モジュール，行動データベースで構成される。アナログ出力焦電型赤外線センサは，ユーザとセンサ間の距離や体の動きの速さに応じた信号を出力する。例えば，食事をとる際ユーザは両手を大きく動かすため，センサの出力信号の振幅は大きくなり，信号に高周波成分が含まれる。また，ユーザが読書をしている間は，体の動きが少ないためセンサの出力信号の振幅は小さくな




図 2 アナログ出力焦電型赤外線センサの外観




図 3 アナログ出力焦電型赤外線センサのブロック図

り，信号に低周波成分が含まれるようになる。アナログ出力焦電型赤外線センサが出力した信号は前処理モジュールに入力される。前処理モジュールでは，入力された信号をある区間幅で分割し，各区間ごとに窓関数を適用する。次に，Fast Fourier Transform (FFT) を用いて周波数特徴量を算出する。次に行動認識モジュールでは，事前に作成した学習モデルを用いてユーザの行動を認識する。認識結果はタイムスタンプとともにデータベースに記録される。

#### 3.2 アナログ出力焦電型赤外線センサの開発

本研究ではアナログ出力焦電型赤外線センサを使用するが，市販されている焦電型赤外線センサはデジタル出力のものが多く，低コストで導入可能なアナログ出力焦電型赤外線センサモジュールは存在しない。そこで，本研究では，市販のデジタル出力焦電型赤外線センサをベースにアナログ出力焦電型赤外線センサを開発する。提案システムで使用するアナログ出力焦電型赤外線センサを図 2 に示す。本センサは，デジタル出力焦電型赤外線センサ \*3 を改造し，アナログ信号を取得できるようにした焦電型赤外線センサ

\*3 焦電型赤外線センサモジュール，  
<http://akizukidenshi.com/catalog/g/gM-02471/>

である。以下に、アナログ出力焦電型赤外線センサの開発手法を示す。アナログ出力赤外線センサのブロック図を図3に示す。デジタル出力焦電型赤外線センサは、焦電素子、2段のオペアンプ、コンパレータで構成される。焦電素子の出力は微弱であるため、2段のオペアンプで信号を増幅する。増幅された信号は後段のコンパレータによって、単純な ON/OFF 信号に変換される。

図3の焦電素子の出力端子から信号を取得すればアナログ信号を得られるが、上で述べたように焦電素子の出力は微弱である。そこで、図3のように、1段目のオペアンプの出力から信号を取得することで、ある程度増幅されたアナログ信号を取得する。

### 3.3 機械学習を用いた行動認識

提案システムにおけるユーザの行動認識手法について述べる。提案システムでは、機械学習によりユーザの行動を認識する。機械学習の適用過程は、(フェーズ1) 学習に用いる教師データの取得、(フェーズ2) 取得した教師データの特徴量の抽出、(フェーズ3) 行動学習モデルの構築、の計3つのフェーズに分けられる。以下に各フェーズの概要について述べる。

#### (フェーズ1) 教師データの取得

機械学習を行うにあたって、センサから得られたデータがどの行動に関連しているかの情報を含む教師データが必要になる。本研究では、各行動ごとに測定したセンサデータについて手動でラベル付けを行う。ラベル付けにより、センサデータとラベルが示す行動が紐付けされ、教師データとなる。

#### (フェーズ2) 特徴量の抽出

センサから得られたデータより、行動認識に必要なデータの特徴量を抽出する。手順として、まずセンサから得られたデータを一定の時間間隔 (以降 Time-window と呼ぶ) に分割する。次に、各 Time-window 区間ごとのデータから特徴量を抽出する。本研究では経験的に Time-window の大きさを10秒に設定する。特徴量については、FFTにより得られた周波数スペクトル強度を特徴量のひとつとして用いる。さらに、1msごとにサンプリングしたアナログ出力焦電型赤外線センサの出力信号の振幅も特徴量として用いる。

#### (フェーズ3) 行動学習モデルの構築

ラベル付けされたセンサデータの特徴量を教師データとする行動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 を用いる。Weka は多数の学習型分類アルゴリズムが実装されており、本研究では代表的な学習型分類アルゴリズムの一つである Random Forest を用いて、各行動の特徴量に対する分類器を構築する。




図4 実験環境

## 4. 評価実験

提案システムの性能評価を行うために、前述のスマートホームに設置したソファで複数の行動を行い、データを収集した。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

本実験では、中川ら [12] の研究において認識対象とされている行動のうち、ソファに着座した状態で行われる頻度が高い (かつ認識精度が悪い) 行動に着目する。これらの行動のうち、「食事 (認識精度 52.1%)」、「PC (認識精度 89.7%)」と、特に認識精度の低い「読書 (認識精度 15.2%)」と「スマートフォン (以降、スマホとする) (認識精度 24.4%)」の4種類の行動を本実験での認識対象とした。図4にソファとアナログ出力焦電型赤外線センサの位置を示す。センサはソファ近くの天井に1個、壁に1個の計2個を設置した。被験者にソファに着座した状態での4種類の行動をそれぞれ6分~16分間してもらい、1セットのデータセットとした。本研究では、3名の被験者 (20代男性3名) に対して実験を行い、被験者1人につき3セットのデータを収集した。

データセットを収集した後、データセットに対して各行動に対応したラベル付けを行った。行動認識に必要な特徴量については、本研究ではアナログ出力焦電型赤外線センサの出力した信号を利用し、出力信号の振幅と周波数スペクトル強度を特徴量として用いた。以下に特徴量抽出の手順を示す。

(手順1) アナログ出力焦電型赤外線センサから、サンプリング間隔 1.0msec で出力信号をサンプリングする。サンプリングは各行動につき6分から16分間行う。サンプリングした出力信号の振幅を1つの特徴量として用いる。

表 1 4種類の行動に対する混同行列

	食事	PC	読書	スマホ
食事	537	47	16	0
PC	56	443	47	54
読書	59	85	368	58
スマホ	35	53	35	477

表 2 4種類の行動識別精度

評価指標	食事	PC	読書	スマホ	Weighted Avg.
Precision	78.2%	70.5%	79.0%	77.1%	76.2%
Recall	89.5%	73.8%	61.3%	79.5%	76.0%
F-Measure	83.4%	72.1%	69.0%	78.3%	75.3%

- (手順 2) サンプリングした信号を Time-window: 10sec で切り出し、窓関数を掛け合わせる。本実験では、経験的にハミング窓を窓関数として用いた。
- (手順 3) 切り出した信号に対して FFT 演算を行い、周波数スペクトル強度を求める。
- (手順 4) Time-window を Sliding window 幅分だけ移動する (本実験では、経験的に Window 幅: 2.5sec とした)。
- (手順 5) (2) から (4) の手順をすべてのサンプリングしたデータに対して行う。各 Time-window における、0Hz から 50Hz までの、0.1Hz 刻みでのスペクトル強度を特徴量として用いる。

上記の手順で抽出した特徴量を用いて「食事」、「PC」、「読書」、「スマホ」の4種類の行動について学習モデルを作成した。また、上記の行動のうち、「読書」、「スマホ」の2つの行動を1つの行動としてまとめ、「食事」、「PC」、「読書・スマホ」の3種類の行動について学習モデルを作成した。

評価については、(実験 1) 4種類の行動について被験者 1名のデータ 3日分に対する 10分割交差検証 (以降 4種類の行動に対する検証とする)、(実験 2) 3種類の行動について実験 1と同条件で 10分割交差検証 (以降 3種類の行動に対する検証とする)、(実験 3) 被験者 1名の 3日分のデータのうち、2日分を教師データ、1日分をテストデータとした時の交差検証 (Leave-one-day-out cross-validation)、(実験 4) 被験者 3名のうち、1名の 1日分のデータをテストデータ、2名の 1日分のデータを教師データとした時の交差検証 (以降 Leave-one-person-out cross-validation とする)、の4項目について評価した。なお、実験 1と実験 2の評価については、特徴量選択の有効性確認のため、Sliding window を適用する前のデータよりランダムサンプリング (1.0msec ごとに特徴量抽出を行い作成したデータより、各行動につき無作為に 600 サンプルを抽出したデータセット) で抽出したデータセットを用いた。

## 4.2 実験結果と考察

### 4.2.1 4種類の行動に対する検証

表 1 に、4種類の行動に対する分類結果を表す混同行列を示す。混同行列の各行は実際の行動を示し、各列は識別モデルによって予測された行動を表す。表 2 は、各行動における平均 Precision, Recall, F-Measure を示す。Precision (適合率) は、その行動であると認識されたデータのうち、実際にその行動であった正しいデータの割合である。Recall (再現率) は該当する行動のうち、その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 1 が示すように、「食事」の分類精度が最も高く、「PC」、「読書」、「スマホ」については互いに誤認識しやすいことがわかる。また、表 2 より、全行動の平均 F-Measure は 75.3% であることがわかった。また、各行動の平均 F-Measure は、「食事」が 83.4% と最も高く、「PC」が 72.1%、「読書」が 69.0%、「スマホ」が 78.3% となっている。これは、「食事」中の体動が他の行動に比べて大きく、周波数特徴量に優位な差が見られるためであると考えられる。一方で、「PC」、「読書」、「スマホ」については、各行動をする際の体動が小さいため、平均 F-Measure の悪化の一因となっていると考えられる。しかし、「PC」、「読書」、「スマホ」の各行動では、得られるスペクトル強度特徴量に違いが存在するため、ある一定の分類精度が達成できたと考えられる。以上より、振幅と周波数スペクトルを特徴量とした機械学習の有効性を確認した。また、誤認識が見られた「読書」、「スマホ」については、スマートフォンなどの端末で電子図書を読む、ができるため、これらの2つの行動を必ずしも区別する必要はないと考えられる。2つの行動を1つの行動としてまとめ、「食事」、「PC」、「読書・スマホ」の3種類の行動について認識させることで、認識精度を向上させることができると考えられる。

柏本ら [13] の研究と比較すると、先行研究ではデジタル出力焦電型赤外線センサを用いて行動を認識しており、「食事」、「リビング活動」の行動についての認識精度はそれぞれ 58.4%、10.3% と低く、位置と行動に相関のない行動を正しく分類できていない。デジタル出力焦電型赤外線センサはセンサの近くに人がいる・いないの 2 値しか出力しないため、身振りの大きさなどユーザの動作の違いを認識できない。そのため、「食事」、「リビング活動」といった行動と行動場所に相関のない行動を正しく認識できないものと考えられる。提案手法では動作の違いによる赤外線センサの出力の変化から行動を認識しているため、上記の同じ場所で行われる行動について、先行研究よりも精度よく認識できる可能性が十分にあると考えられる。

表 3 3種類の行動に対する混同行列

	食事	PC	読書・スマホ
食事	532	61	7
PC	62	443	95
読書・スマホ	44	80	476

表 4 3種類の行動識別精度

評価指標	食事	PC	読書・スマホ	Weighted Avg.
Precision	83.4%	75.9%	82.4%	80.5%
Recall	88.7%	73.8%	79.3%	80.6%
F-Measure	85.9%	74.8%	80.8%	80.5%

表 5 Leave-one-day-out cross-validation の評価結果

評価指標	食事	PC	読書・スマホ	Weighted Avg.
Precision	54.3%	44.2%	66.5%	58.4%
Recall	65.1%	30.8%	73.5%	59.2%
F-Measure	56.4%	35.2%	69.9%	57.7%

#### 4.2.2 3種類の行動に対する検証

表3に3種類の行動に対する分類結果を表す混同行列を、表4に各行動における平均 Precision, Recall, F-Measureを示す。全行動の平均 F-Measure は80.5%であった。表3を見ると、「食事」の分類精度が良く、さらに、「読書・スマホ」の分類精度が4種類の行動に対する分類結果よりも良い結果となっている。「読書」および「スマホ」の動作は、手首を動かす動きがメインであり、動作が類似している。そのため、これらの動作を一つの動作として認識するよう学習モデルを構築することで、平均 F-Measure が改善した可能性がある。しかし、認識の対象となる行動の数が減ったために平均 F-Measure が向上した可能性もあるため、今後の検討が必要である。

#### 4.2.3 Leave-one-day-out cross-validation

表5に Leave-one-day-out cross-validation の評価結果を示す。表5より、提案システムを用いて、全行動の平均 F-Measure: 57.7%で各行動を分類できることが分かった。これは、同じ被験者が同じ行動を行った場合であっても、実験時の被験者の細かな行動の違い（「食事」における飯類と麺類を食べた場合の違い）などの条件によってその動きが変化するため、教師データとは異なる特徴量-行動相関が発生し、各行動の分類精度が悪化したと考えられる。しかし、同種の行動の動きの変化にはいくつかのパターンが存在すると予想される。例えば「食事」については、飯類を食べた際の特徴量、麺類を食べた際の特徴量など、各行動の詳細な動きと対応する特徴量の抽出方法を検討し、それぞれの特徴量を分類器に学習させることで、分類精度を向上させることが考えられる。

#### 4.2.4 Leave-one-person-out cross-validation

表6に Leave-one-person-out cross-validation の評価結果を示す。表6を見ると、全行動の平均 F-Measure: 54.6%で分類できることが分かった。Leave-one-day-out cross-

表 6 Leave-one-person-out cross-validation の評価結果

評価指標	食事	PC	読書・スマホ	Weighted Avg
Precision	61.2%	43.1%	63.1%	56.9%
Recall	52.5%	19.1%	80.2%	58.8%
F-Measure	50.6%	25.5%	70.4%	54.6%

validation の結果と比較すると、認識精度に大きな差が見られなかった。提案手法は教師データを持たない新規ユーザに対しても行動認識が可能であることがわかった。

## 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行動を推定するシステムを提案した。提案システムでは、居住者のプライバシーの確保や導入コストの抑制に加えて、居住者が同一の場所で行う異なる動作を認識するために、アナログ出力焦電型赤外線センサを使用した。評価実験として、スマートホーム内に設置したソファに着座して行う「食事」、「読書」、「PC」、「スマートフォン」の計4つの行動を対象として、Random Forest により行動学習モデルおよび行動識別モデルを構築し、分類精度を評価した。その結果、以下に示す結果と考察が得られた。

- 4種類の行動に対する10分割交差検証の結果として、全行動の平均 F-Measure: 75.3%が得られた。居住者の行動によってアナログ出力焦電型赤外線センサから得られる信号の出力パターンや周波数スペクトル強度の違いが存在するため、これらの特徴量として分類器を作成することで、各行動を認識できることを確認した。
- 3種類の行動に対する10分割交差検証の結果として、全行動の平均 F-Measure: 80.5%が得られた。各行動に大きな違いがみられない場合、それらの行動を一つの行動としてまとめることで、分類精度を向上出来る。
- Leave-one-day-out cross-validation の評価結果として、全行動の平均 F-Measure: 57.7%が得られた。同一人物が同一動作をとった場合でも、条件によって得られる特徴量にいくつかのパターンが存在することが予想される。各行動の特徴量を吟味することで、分類精度を向上させることができる。
- Leave-one-person-out cross-validation の評価結果として、全行動の平均 F-Measure: 54.6%が得られた。提案手法は教師データを持たない新規ユーザに対しても行動認識が可能であることがわかった。

以下に、今後の検討事項を示す。

#### (検討1) 最適なパラメタの検討

本研究での特徴量抽出手法では、Time-window を10sec とし、特徴量として強度スペクトル:0Hz~50Hzを用いた。これらのパラメタを変更して分類器を作成した際に、分類精度がどう変化する

か、検証する必要がある。また、今回は経験的に Sliding window 幅を 2.5sec としたが、この移動幅も検討する必要がある。今後、グリッドサーチ等の手法を用いることで、これらの最適パラメタ探索を行うこと検討している。

- (検討 2) 各行動での特徴量のパタンの検討  
上記の考察にあるように、同一行動で現れる特徴量のパタンを調査する必要がある。各行動のさらに細かい行動内容について検討し、データを収集し、分類器を作成することで分類精度が改善するか検証する必要がある。
- (検討 3) ハードウェア (センサ) の特性の違いによる認識精度の検討  
提案手法で用いた焦電型赤外線センサとは異なる特性 (センサ感度, 感知角度など) を持つセンサを用いた場合においても, 本実験と同様の結果が得られるか検証する必要がある。
- (検討 4) ユーザの姿勢の違いによる認識精度への影響の検討  
提案システムの汎用性を確認するために, 提案システムの認識精度がユーザの姿勢の違いによってどの程度影響を受けるか検討する必要がある。
- (検討 5) 提案システムの実際の生活シーンへの適用  
提案システムを実生活に適用した際の有効性を確認するために, 提案システムを実際の生活シーンに適用し, カメラで撮影した生活行動と, 提案システムの認識結果の比較が必要である。

#### 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] 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.

[8] Kenji Mase. Activity and location recognition using wearable sensors. *IEEE Pervasive Computing*, Vol. 1, No. 3, pp. 24–32, 7 2002.

[9] Kenki 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] 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.

[11] 中川愛梨, 諏訪博彦, 藤本まなと, 荒川豊, 安本慶一. リアルタイム行動認識システム開発のためのデータ収集と分析. *研究報告モバイルコンピューティングとパーベシブシステム (MBL)*, Vol. 2015-MBL-7, No. 9, pp. 1–5, 2015.

[12] 中川愛梨, 守谷一希, 諏訪博彦, 藤本まなと, 荒川豊, 安本慶一. 異なる家具配置に対応可能なリアルタイム行動認識システム開発のためのデータ収集と分析. *研究報告高度交通システムとスマートコミュニティ (ITS)*, No. 17, pp. 1–8, 2016.

[13] 柏本幸俊, 秦恭史, 諏訪博彦, 藤本まなと, 荒川豊, 繁住健哉, 小宮邦裕, 小西健太, 安本慶一. 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. *マルチメディア通信と分散処理ワークショップ論文集*, 2016.