

宅内行動認識に向けた環境発電によるセンシングおよび機械学習手法の提案

An Energy-harvesting ADLs sensing and recognition system

伊勢田 水琴[†] 西島 伶央[‡] 松田 裕貴[†] 諏訪 博彦[†] 安本 慶一[†]
 Hikoto Iseda Reoto Nishijima Yuki Matsuda Hirohiko Suwa Keiichi Yasumoto

1. はじめに

家電の最適制御や健康支援、独居高齢者の見守りシステム等への応用を目指して、様々な宅内行動認識が提案されている。現在まで提案された行動認識の手法は、大きくウェアラブルデバイスやスマートフォンなどを使用する手法と、環境に設置したセンサを使用する手法、環境発電技術を使用する手法に分けることができる。

ウェアラブルデバイスやスマートフォンなどを使用する手法には、これらのデバイスに搭載されたジャイロセンサや加速度センサ等から得られるデータを用いて解析する手法がある [1, 2, 3, 4, 5, 6, 7]。環境中にセンサを設置する手法には、デジタル PIR センサやドアの開閉を検知するセンサ、気温・湿度・気圧・騒音・光量などの物理量を取得する環境センサを組み合わせた手法 [8, 9, 10, 11, 12]、家電の使用状況やスマートメータから行動を推定する手法 [13, 14, 15] などがある。

しかし、これらの手法は設置・維持コストが高く、プライバシーを侵害するリスクがあり、ユーザへの負担が大きいと、一般家庭への導入が難しいという課題があった。

この課題を解決するために、環境発電による持続的な駆動を実現した生活行動認識システムとして [16, 17, 18, 19] が提案されているが、認識できる行動の数が少ないという課題がある。

そこで本研究では、環境発電で生成した電力のみで駆動する環境センサと機械学習を用いた、より汎用的な宅内行動認識手法を提案する。具体的には、太陽電池によって駆動する環境センサおよびモーションセンサを家庭内の様々な位置に設置し、これらのデータを同様に太陽電池によって駆動するマイクロコンピュータ上に集め、機械学習による行動の分類およびユーザへのフィードバックを行うシステムである。

本論文の構成は以下の通りである。まず第2章では、これまでに提案されてきた行動認識の手法についてまとめ、本研究の立ち位置を明確にする。第3章では、提案手法を詳細に説明する。第4章では、提案手法実現に向けて行った予備実験について報告する。第5章では、提

案手法の実現性および今後の課題について議論する。

2. 関連研究

これまでに行われた宅内行動認識に関する研究は、ウェアラブルデバイスやスマートフォンを用いる手法と、環境に設置したセンサを用いる方法に大別でき、これに加えて両者を組み合わせた手法、環境発電を用いた手法の4つが存在する。本章では、行動認識手法をこれらのカテゴリに分けて先行研究を整理する。

2.1 ウェアラブルデバイス・スマートフォンを用いた手法

Attal らは三軸加速度センサ、ジャイロセンサ、磁気センサを被験者の胸部・右大腿部・左足首に装着し、「立つ」、「座る」、「歩く」等、12種類の行動を機械学習を用いて識別する手法を提案している。機械学習アルゴリズムにはk-NNを使用し、F値で0.989の精度を出している [1]。Balli らはスマートウォッチに搭載された三軸加速度センサ・ジャイロセンサ・歩数計・心拍センサから得られるデータを、主成分分析による次元削減を行った上でRandomForestに適用することにより、「歩く」、「座る」、「PC操作」、「静止状態」、「座る」など8種の動作の識別において、F値で0.985の精度を出した [2]。また、Chen らは、スマートフォンに搭載された三軸加速度センサおよびジャイロセンサを用いて「小走り」、「歩く」、「階段を登る/下る」、「ジャンプ」の5種類の行動認識においてF値で0.9626の精度を出している [7]。このように、ウェアラブルデバイスやスマートフォンを用いた手法は、一般的に精度が非常に高いという特徴がある。

2.2 環境中に設置したセンサを用いた手法

環境中にセンサを設置して行動認識を行う手法も提案されている。Cook らが提案したCASASは光量センサ、気温センサ、モーションセンサ、ドアセンサ、データサーバなどからなるスマートホームキットであり、10種の行動を平均で0.581の精度で認識することに成功している [8]。Sasaki らは家電の利用状況から行動認識を行う手法を提案し、9種の行動を平均で0.675の精度で認識している [13]。Mastui らはSALONと呼ばれるPIRセンサ、気温・湿度・騒音などが計測可能な環境センサ、ドアセンサ、環境発電によって駆動するアノテーション用ボタン、データ収集・解析用サーバからなるシステムを提案

[†] 奈良先端科学技術大学院大学, Nara Institute of Science and Technology

[‡] 徳山工業高等専門学校, National Institute of Technology, Tokuyama College

し、「入浴」、「食事」、「調理」、「睡眠」の4種の行動認識において、再現率で0.723、F値で0.407の精度を達成している[9]。これらの手法はウェアラブルデバイスのように常に身につける必要はないため、ユーザの負担感は少ないという特徴がある。

2.3 ウェアラブルデバイスと環境中のセンサを組み合わせた手法

Royらはウェアラブルデバイスと環境中に設置したモーションセンサの両方を用いて、ユーザを識別しつつ、行動を行っている部屋というコンテキストを加えることで、平均0.9808の精度で「調理」、「服薬」、「掃除」、「手洗い」、「水やり」の5種の行動を識別している。この手法は、ユーザの識別ができ、精度も非常に高いといった利点がある[20]。

2.4 環境発電技術を用いた手法

以上の3つの方式の他にも、環境発電技術を用いて外部の電源を用いることなく永続的に稼働する行動認識手法も提案されている。Sandhuらが提案したSolARは、手首に太陽電池とマイコンを装着し、行動によって変化する発電量から行動認識を行なっている。SolARは、「階段の昇降」、「歩く」、「走る」、「座る」、「立つ」など5種の行動を、屋内では0.9158の精度で認識することができる[17]。また、Misakiらは、butterflyと呼ばれるアナログPIRセンサと機械学習モジュールを組み合わせたデバイスを部屋の数カ所に設置し、デバイス間の多数決を取ることで行動認識を行うシステムを提案している。butterflyは「移動」、「読書」、「静止」、「筆記」、「無人」の5種の行動を0.6359の精度で認識が可能である[16]。これらの手法はウェアラブルデバイスを用いた手法や、配線や電池を必要とするセンサを環境中に設置する手法における課題の一部を解決可能である。しかし、認識できる行動の数が少なく、精度が低いという課題がある。

2.5 先行研究の課題

ウェアラブルデバイスを用いた手法は精度が高いものの、常にデバイスを身につける、あるいは持ち歩く必要があり、ユーザへの負担が大きいという課題がある。一方、環境中にセンサを設置する手法は、センシングに伴うユーザの負担感は軽減できるが、配線や電池交換など、設置・維持コストが高いという課題がある。環境発電技術を用いた無給電の環境センサを設置することで、これらのデメリットを解消することができるが、環境発電を用いる手法は認識できる行動の種類が非常に少ないという課題がある。

このように、設置・維持コストが低く、プライバシーを侵害せず、ユーザへの負担が少なく、多くの行動を認識できるようなシステムは未だ提案されていない。そこ

で本研究では、以上の4点の条件を満たす、汎用的な宅内行動認識に向けた環境発電によるセンシングおよび機械学習手法を提案する。

3. 提案システム

本章では、環境発電によって駆動する汎用的なセンシングおよび機械学習システムについて述べる。提案するシステムは次の4つの要件を満たすようにデザインされている。

- (要件1) 環境発電による電力のみで駆動し、メンテナンスフリーで永続的に動作すること
- (要件2) カメラや音声など、ユーザのプライバシーを侵害するセンサを使用しないこと
- (要件3) ウェアラブルデバイス等ユーザが装着・携帯する必要があるセンサを使用せず、センシングに伴う負担感を最小限にすること
- (要件4) 多種多様な行動の認識を可能とすること

3.1 システムの構成と概要

本システムの概要を図1に示す。本システムはセンサノードおよび機械学習/サーバノードから構成される。センサノードは、太陽電池によって発電した電力を用いて環境状態をセンシングし、このデータをBLEビーコンに載せ、一定周期でサーバノードへ送信する。機械学習/サーバノードも同様に、太陽電池によって発電した電力を用いてBLEビーコンを受信し、特徴量抽出を行い、行動認識の結果をBLEを用いてユーザのスマートフォン等へフィードバックする。認識する行動としては、「PC作業」、「読書」、「スマホ操作」、「食事」といった机上作業から、「入浴」、「調理」といった特定の部屋全体を使う行動、「睡眠」、「外出」といった動きに乏しい行動までを検討している。

3.2 センサモジュール

幅広い行動の認識を可能にするため、本システムでは、環境センサとモーションセンサの両方を使用する。まず、環境センサとしては図2に示すエレクトクス工業株式会社が開発した超小型のセンサデバイス「 μ PRISM」を使用する[21]。 μ PRISMの主要なセンサ類を表1に、スペックを表2に示す。太陽電池は室内では多くの電力を発電できないが、低消費電力なデバイスであれば駆動可能であると考えられる。また、多種類のセンサを備え、行動に伴う環境の変化をより明確に捉えることが期待されるため、本デバイスを採用した。モーションセンサとしては、丸紅情報システムズが開発したBLE対応デジタルPIRセンサ「EMDCB」の使用を検討している[22]。

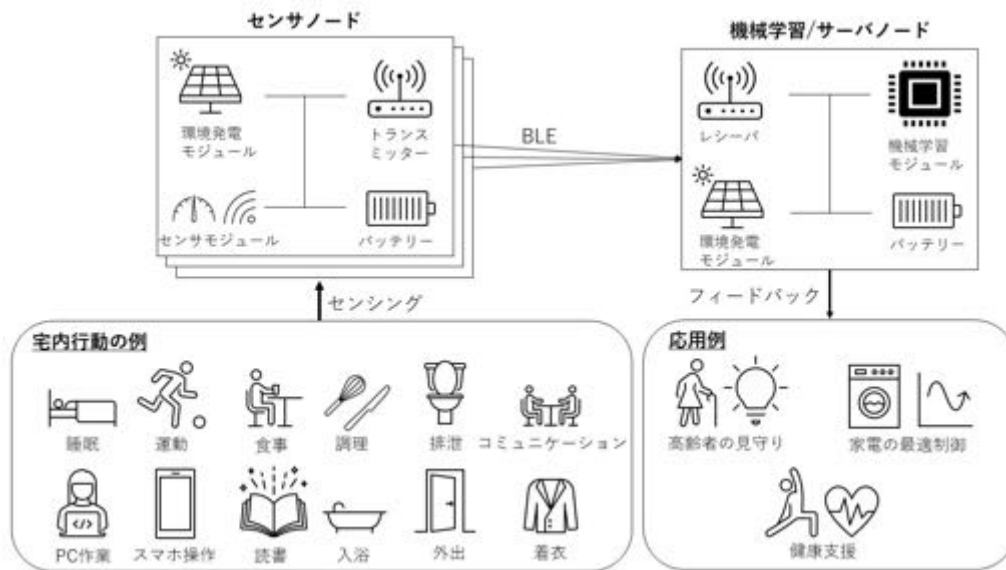


図 1: システムの概要

表 1: μ PRISM のセンサ

センサ	仕様
加速度センサ	3 軸 $\pm 2, \pm 4, \pm 8, \pm 16G$
地軸気センサ	3 軸 $\pm 1000\mu T$
温度センサ	$-15 \sim +55^{\circ}C$
湿度センサ	$0 \sim 100^{\circ}C$
気圧センサ	$300 \sim 1100hPa$
照度センサ	$0 \sim 128klx$
UV センサ	UV インデックス $0 \sim 11+$




図 2: μ PRISM の外観

表 2: μ PRISM のスペック

要素	性能
計測間隔	0.1 秒 \sim 3600 秒
電源電圧	$+2.4 \sim 5.25V$
消費電流	ピーク時 5mA 待機時電流 5 μA
通信方式	Bluetooth 4.0

EMDCB は 200lx の環境下で充電が可能であり、暗闇であっても内蔵したバッテリーにより 96 時間駆動することができる。

これら 2 つのセンサを組み合わせることで、部屋の状態の変化と住人の移動や動きを細かく捉えることができ、幅広い行動の認識が可能になると考えられる。

3.3 機械学習モジュール

機械学習モジュールでは、センサノードから発信された BLE ビーコンを受信し、データから特徴量を抽出した上で行動認識を行い、ユーザへのフィードバックまで

を行う。マイコンには、サイプレスセミコンダクタ社のマイクロコンピュータである PSoC 6-BLE Pioneer Kit (CY8CKIT-062-BLE) を使用する。PSoC のスペックは表 3 に示す通りである。BLE で通信可能であり、低消費電力であることから本デバイスが適していると考えた。

3.4 環境発電モジュール

本システムでは、環境発電技術として太陽電池を使用する。宅内で安定的な電力を供給し続けるためには、環境光をエネルギー源として使用するのが最適であると考えられるためである。他のエネルギー源としては、床発電や振動による発電、温度変化による発電なども挙げられる。しかし、いずれも誰かが室内に存在しなければ稼働できず、センサやマイコンを動作させるために十分な電力を安定的に供給することはできないと考えられる。

本研究では、Misaki らが過去に開発した環境発電モジュール [16] の使用を想定する。環境発電モジュールの外観

表 3: PSoC 6-BLE Pioneer Kit のスペック

要素	性能
CPU	Arm Cortex-M4 Cortex-M0
フラッシュメモリ	1MB
典型的な消費電力	33.542mW
ディープスリープ時の消費電力	1.357mW
通信方式	Bluetooth 4.2




図 3: 環境発電モジュールの外観

を図 3 に示す。環境発電モジュールは小型太陽光パネルを 10 枚並べて作成されており、サイズは 250mm×230mm である。本デバイスは 750lx の室内光のもとで 5.04V、0.93mA の発電が可能である。

3.5 センサノード・機械学習ノードの設置位置

以上のモジュールが効果的に機能し得る配置を図 4 に示す。まず、機械学習/サーバノードは窓際に設置することを検討している。機械学習/サーバノードは BLE データを受信し、機械学習モデルを実行するためにセンサノードより多くの電力を必要とするため、室内で最も発電効率が良いと考えられる窓際に設置する。モーションセンサを備えるセンサノード (EMDCB) は、各部屋の壁やテーブル上の天井、テレビの前など、住人の動きを捉えることができる位置に設置する。これにより、住人の動きや、住人がいる部屋を推定することができる。環境センサを備えるセンサノード (μ PRISM) は、机の上、椅子、各部屋の壁、ソファなどに設置する。これらの位置に置くことで、住人がテーブルの上で行う比較的動きの少ない「PC 作業」や「スマホ操作」、「食事」といった行動の認識に繋がると考えられる。また、キッチンや洗面所の壁に設置することで、「調理」や「入浴」といった行動の際に発生する湿度や気温の変化を捉え、行動認

識の精度向上に寄与すると考えられる。

4. 予備実験

提案手法の有効性を検証するための予備実験として、 μ PRISM を電池によって駆動し、行動認識を試みる実験および、 μ PRISM の消費電力の実測値を計り、システムの実現可能性を評価する実験を行った。モーションセンサを用いた行動認識の可能性は [9, 16] で検証されているため、本実験では μ PRISM による行動認識およびシステムの実現可能性を検証することを目的としている。

4.1 環境センサによる行動認識実験

μ PRISM を部屋の数カ所に設置し、行動認識を試みる実験を行う。本稿では図 5 に示す 5 種類の行動 (PC 作業/pc, スマートフォン操作/smartphone, 読書/reading, 食事/eating, 移動/moving) を行動認識の対象とした。これらの行動を対象に訓練データを次の手順で収集した。まず、 μ PRISM を奈良先端大に設置されたスマートホーム (図 6) におけるリビングルームの 6ヶ所 (ID1-ID6, 机 2ヶ所, 壁 2ヶ所, 椅子, 天井) に図 7 に示すように設置した。その上で、1 人の被験者に対し、部屋の中央 (ID6 下) にあるダイニングテーブルの奥側 (ID3 側) の椅子に座って、各行動 (PC 作業/pc, スマートフォン操作/smartphone, 読書/reading, 食事/eating, 移動/moving) を 5 分間、5 回ずつ実施してもらい、データを収集した。移動/moving については、手前にあるキッチンへの移動を 1 分間に 5~7 回繰り返してもらった。食事/eating に関しては、被験者は実際に食物を食べず、食べる仕草をとってもらった形で、データを収集した。

被験者の位置と身体の向きを固定し、設置した 6 個全ての μ PRISM のサンプリング周波数 10Hz に設定し、測定を行った。測定時間内は、指定された行動をとってもらい、その行動をし続けたものとしてラベル付を行った。

ただし本実験では欠損値が多く、0.1 秒間隔のデータを取ることができないケースが多く見られた。そこで本実験では、欠損していないデータについて平均値を取り、1 秒間隔のデータに加工する前処理を加えた。この 1 秒間隔のデータに対し、ウィンドウサイズを 10 秒に設定し、データを区切った上で表 4 に示す特徴量を抽出し、機械学習モデルへの入力とした。Python の scikit-learn を使用し、メモリが 1MB と少ない PSoC で動かすことを前提として、比較的軽量のアルゴリズムである決定木、RandomForest, LightGBM, SVM, naive bayes についてモデルを訓練し、リーブワンセッションアウトによって精度を検証した。

まず、機械学習アルゴリズムによる F 値の違いを表 5 に示す。ここでは、5 セッションのデータに対し、リーブワンセッションアウトによる検証を行い、各セッション



図 4: NAIST スマートホームにおけるノード設置例

表 4: Features list

Feature extraction function	Description	Formula
mean(s)	Arithmetic mean	$\bar{s} = \frac{1}{N} \sum_{i=1}^N s_i$
std(s)	Standard deviation	$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (s_i - \bar{s})^2}$
max(s)	Largest values in array	$\max_i(s_i)$
min(s)	Smallest value in array	$\min_i(s_i)$
median(s)	Median of the array	$s_{\frac{N+1}{2}}$ or $\frac{1}{2}(s_{\frac{N}{2}} + s_{\frac{N}{2}+1})$



図 5: 対象の行動

での F 値の平均を取った。表 5 から RandomForest の精度が最も高く、0.619 の精度で行動認識が可能であることが分かる。行動ごとの F 値を図 9 に示す。食事、PC 作業、移動に関しては高い精度で認識可能であるが、読書とスマートフォン操作の精度は低いことが分かる。このことから、 μ PRISM には加速度センサが搭載されてい



図 6: NAIST スマートホーム

るため、PC 操作や食事の際に発生する特徴的な振動のパターンを学習することができたものと考えられる。また、移動に関しても、椅子の動きや壁に伝わる振動や影を加速度センサや照度センサが検知していると考えられる。一方で、スマートフォン操作や読書など、全く同じ姿勢が続き、動きも少ない行動に関しては、 μ PRISM が持つセンサ類に十分な反応が無く、認識が難しかったも

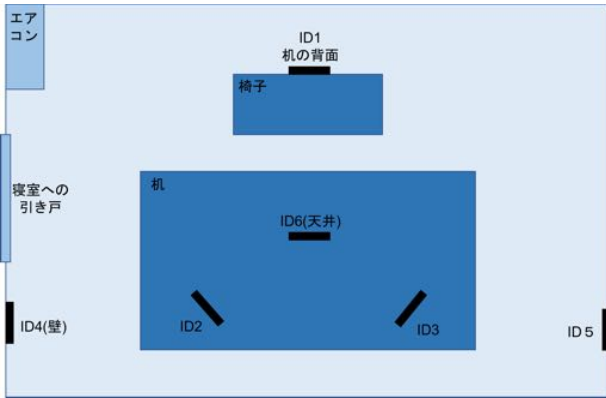


図 7: センサ設置図



図 8: センサ設置位置

のと考えられる。図 10 に示す混同行列より、読書と食事を誤認識するケースが多く、またスマートフォン操作は読書や食事と誤認識されることが多いことが分かる。以上の結果から、 μ PRISM による行動認識は、動きが大きい行動に関しては高い精度で可能だが、動きが少ない行動の認識に関しては精度が落ちると言える。

4.2 システム実現可能性の評価

環境発電による電力で μ PRISM が動作可能か評価するため、 μ PRISM が 1 時間に消費する電力の調査実験を行った。本実験では、 μ PRISM 6 台に対し電圧および電流を測定した。測定した電圧と電流から電力を求め、平均値をとることで μ PRISM の消費電力とした。

μ PRISM をリチウムコイン電池 (CR2032) に接続し、サンプリング周波数 10Hz で 1 時間データを計測した。計測したデータは BLE 通信によりスマートフォン端末 (iPhone Xs) にリアルタイムで送信した。データ計測の

表 5: 行動認識精度

機械学習アルゴリズム	Acc.
RandomForest	0.619
LightGBM	0.539
決定木	0.399
K-NN	0.474
SVM	0.296
naive bayes	0.244

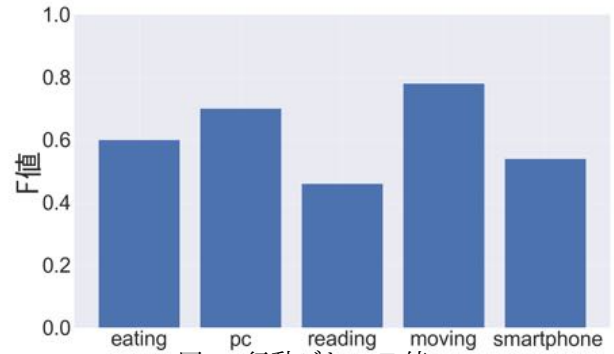


図 9: 行動ごとの F 値

前と後でそれぞれリチウムコイン電池の電圧を測定し、差分を消費された電圧とした。電圧や電流の測定にはデジタルマルチメータ (CD771) を使用した。

μ PRISM の消費電力を表 6 に示す。測定結果より平均値を求めた結果、 μ PRISM の消費電力は 0.0521mWh となった。本研究で使用する環境発電モジュールは、1 時間で 4.687mWh の発電をするため、 μ PRISM は環境発電による電力で動作可能であると言える。

表 6: μ PRISM の消費電力

低下電圧 [V]	消費電流 [mA]	消費電力 [mWh]
0.425	0.130	0.0553
0.418	0.120	0.0502
0.411	0.130	0.0534
0.426	0.120	0.0511
0.429	0.120	0.0515
0.426	0.120	0.0511

5. おわりに

本稿では、環境発電によって発電した電力のみでセンサおよび機械学習モジュールを駆動し、行動認識を行うシステムの提案を行った。従来の行動認識の手法として、ウェアラブルデバイスやスマートフォンなど、身体に身につけるデバイスを使用する手法や、環境中にセンサを

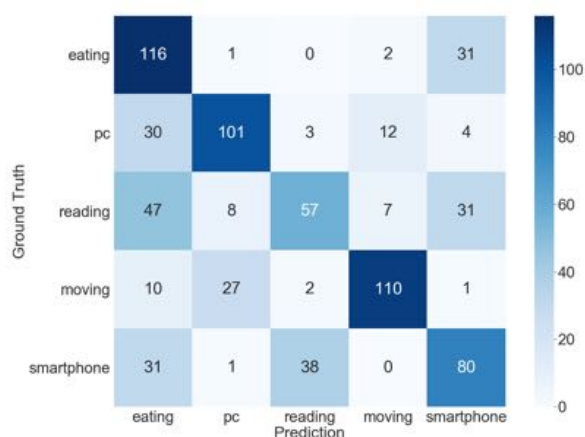


図 10: 混同行列

設置する手法、これらを組み合わせた手法などがあるが、ユーザへの負担や設置・維持コストが大きく、手法によってはユーザのプライバシーを大きく侵害するなど、一般家庭への導入に向けては多くの課題があった。これらの課題を受けて、環境発電技術を用いた無給電行動認識手法も複数提案されているが、認識できる行動の数が少ないという課題がある。本研究では、これらの課題を解決するために、低消費電力な環境センサである μ PRISM および EMOCB を使用した太陽電池で駆動するセンサノードと、低消費電力コンピュータである PSoC による汎用的な行動認識システムを提案した。本システムは環境発電技術を用いるため、配線や電池交換を必要とせず、設置・維持コストが低い。また、モーションセンサおよび環境センサのみを使用するため、ユーザのプライバシーを侵害しにくく、ウェアラブルデバイスも使用しないため、ユーザへの負担も少ない。加えて、複数のセンサを組み合わせることで多様な行動の認識が可能である。

予備実験の結果、 μ PRISM による行動認識は、F 値で 0.619 の精度で可能であり、先行事例と比較しても十分な精度であることを確認した。また、先行研究で使用された環境発電モジュールによる発電量は、一般的な環境光量の下でも μ PRISM および機械学習モジュールを駆動するために十分であった。以上のことから、提案されたシステムは実現可能であると考えられる。

一方、予備実験を通して、 μ PRISM のみでは動きの少ない行動の認識が難しいことが分かった。そのため、今後の予定として、PIR センサなど人の動作を非接触で検知可能なセンサを追加し、行動認識実験を行いたい。また、本実験では、行動認識の対象が机上作業が主であったため、「調理」、「入浴」、「睡眠」など、机上に止まらない様々な行動に対しても同様に実験する予定である。さらに、機械学習モジュールと μ PRISM を実際に環境発

電モジュールと接続し、実環境でリアルタイム行動認識が可能か検証したいと考えている。

謝辞

本研究は JSPS 科研費 JP19H05665 の助成によって行った。

参考文献

- [1] Ferhat Attal, Samer Mohammed, Mariam Dedabrishvili, Faicel Chamroukhi, Latifa Oukhellou, and Yacine Amirat. Physical Human Activity Recognition Using Wearable Sensors. *Sensors*, Vol. 15, No. 12, pp. 31314–31338, 2015.
- [2] Serkan Balli, Ensar Arif Sağbaş, and Musa Peker. Human activity recognition from smart watch sensor data using a hybrid of principal component analysis and random forest algorithm. *Measurement and Control*, Vol. 52, No. 1-2, pp. 37–45, 2019.
- [3] Katsunori Ohnishi, Atsushi Kanehira, Asako Kanezaki, and Tatsuya Harada. Recognizing Activities of Daily Living With a Wrist-Mounted Camera. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, CVPR*, June 2016.
- [4] Avgoustinos Filippoupolitis, Babak Takand, and George Loukas. Activity Recognition in a Home Setting Using Off the Shelf Smart Watch Technology. In *2016 15th International Conference on Ubiquitous Computing and Communications and 2016 International Symposium on Cyberspace and Security, IUCC-CSS*, pp. 39–44, 2016.
- [5] Saisakul Chernbumroong, Shuang Cang, Anthony Atkins, and Hongnian Yu. Elderly activities recognition and classification for applications in assisted living. *Expert Systems with Applications*, Vol. 40, No. 5, pp. 1662–1674, 2013.
- [6] Yugo Nakamura, Yuki Matsuda, Yutaka Arakawa, and Keiichi Yasumoto. WaistBelt X: A Belt-Type Wearable Device with Sensing and Intervention Toward Health Behavior Change. *Sensors*, Vol. 19, No. 20, pp. 1–21, 2019.
- [7] Yufei Chen and Chao Shen. Performance Analysis of Smartphone-Sensor Behavior for Human Activ-

- ity Recognition. *IEEE Access*, Vol. 5, pp. 3095–3110, 2017.
- [8] Diane J. Cook, Aaron S. Crandall, Brian L. Thomas, and Narayanan C. Krishnan. CASAS: A Smart Home in a Box. *Computer*, Vol. 46, No. 7, pp. 62–69, 2013.
- [9] Tomokazu Matsui, Kosei Onishi, Shinya Misaki, Manato Fujimoto, Hirohiko Suwa, and Keiichi Yasumoto. SALON: Simplified Sensing System for Activity of Daily Living in Ordinary Home. *Sensors*, Vol. 20, No. 17, 2020.
- [10] Emmanuel Munguia Tapia, Stephen S Intille, and Kent Larson. Activity recognition in the home using simple and ubiquitous sensors. In *International conference on pervasive computing*, pp. 158–175. Springer, 2004.
- [11] Yukitoshi Kashimoto, Masashi Fujiwara, Manato Fujimoto, Hirohiko Suwa, Yutaka Arakawa, and Keiichi Yasumoto. ALPAS: Analog-PIR-Sensor-Based Activity Recognition System in Smarthome. In *2017 IEEE 31st International Conference on Advanced Information Networking and Applications*, AINA, pp. 880–885, 2017.
- [12] Yukitoshi Kashimoto, Kyoji Hata, Hirohiko Suwa, Manato Fujimoto, Yutaka Arakawa, Takeya Shigezumi, Kunihiro Komiya, Kenta Konishi, and Keiichi Yasumoto. Low-Cost and Device-Free Activity Recognition System with Energy Harvesting PIR and Door Sensors. *MOBIQUITOUS 2016*, p. 6–11, 2016.
- [13] Wataru Sasaki, Masashi Fujiwara, Hirohiko Suwa, Manato Fujimoto, Yutaka Arakawa, Aki Kimura, Tomoko Miki, and Keiichi Yasumoto. Daily Living Activity Recognition through Time Series Analysis of Data Obtained with ECHONET Lite Appliances and Motion Sensors. *JSAI Technical Report, Type 2 SIG*, Vol. 2018, No. SAI-031, p. 05, 03 2018.
- [14] Abdulsalam Yassine, Shailendra Singh, and Atif Alamri. Mining Human Activity Patterns From Smart Home Big Data for Health Care Applications. *IEEE Access*, Vol. 5, pp. 13131–13141, 2017.
- [15] José M. Alcalá, Jesús Ureña, Álvaro Hernández, and David Gualda. Assessing Human Activity in Elderly People Using Non-Intrusive Load Monitoring. *Sensors*, Vol. 17, No. 2, 2017.
- [16] Sopicha Stirapongsasuti, Shinya Misaki, Tomokazu Matsui, Hirohiko Suwa, and Keiichi Yasumoto. Butterfly: Battery-Free Daily Living Activity Recognition System through Distributed Execution over Energy Harvesting Analog PIR Sensors. In *2021 17th International Conference on Distributed Computing in Sensor Systems*, DCOSS, pp. 54–56, 2021.
- [17] Muhammad Moid Sandhu, Sara Khalifa, Kai Geissdoerfer, Raja Jurdak, and Marius Portmann. SolAR: Energy Positive Human Activity Recognition using Solar Cells. In *2021 IEEE International Conference on Pervasive Computing and Communications*, PerCom, pp. 1–10, 2021.
- [18] Hui Huang, Xian Li, Si Liu, Shiyan Hu, and Ye Sun. TriboMotion: A Self-Powered Triboelectric Motion Sensor in Wearable Internet of Things for Human Activity Recognition and Energy Harvesting. *IEEE Internet of Things Journal*, Vol. 5, No. 6, pp. 4441–4453, 03 2018.
- [19] Yoshinori Umetsu, Yugo Nakamura, Yutaka Arakawa, Manato Fujimoto, and Hirohiko Suwa. Ehaas: Energy harvesters as a sensor for place recognition on wearables. In *2019 IEEE International Conference on Pervasive Computing and Communications (PerCom)*, pp. 1–10, 2019.
- [20] Nirmalya Roy, Archan Misra, and Diane Joyce Cook. Ambient and smartphone sensor assisted ADL recognition in multi-inhabitant smart environments. *Journal of Ambient Intelligence and Humanized Computing*, Vol. 7, pp. 1–19, 2016.
- [21] エレックス工業株式会社. 超小型 iot センサモジュール μ プリズム, Accessed: 2022-07-13. <https://www.elecs.co.jp/microprism/>.
- [22] IoT センサー・デバイスパートナープログラム. バッテリーレス ble 対応照度センサー&人感センサー – 2 つのセンサー機能を搭載, Accessed: 2022-07-20. <https://iot-device.org/emdcb/>.