

# 環境発電アナログPIRセンサの分散処理による無電源実時間宅内行動認識システム

三崎 慎也<sup>1,a)</sup> Sopicha Stirapongsasuti<sup>1</sup> 松井 智一<sup>1</sup> 諏訪 博彦<sup>1</sup> 安本 慶一<sup>1</sup>

## 概要：

Society5.0の実現に向け、サイバーフィジカルシステム（CPS）の家庭への普及、とりわけ、宅内生活行動認識システムの家庭への普及が切望されている。そのためには、システムの設置が容易でメンテナンスコストが低いことが求められる。近年、環境発電センサを用いることで、設置が容易でバッテリー交換などのメンテナンスが不要な生活行動センシングシステムも提案されてきている。しかし、行動認識するためには、センサデータの収集・処理だけでなく、認識モデルを実行するための消費電力が高い高性能なゲートウェイ（PC）を必要とする。本研究では、センシングだけでなく宅内生活行動の認識まで環境発電のみで永続的に動作させるシステムの構築を目的とする。この目的を実現するため、室内光で動作し人の動きを継続的にセンシングするとともに、機械学習により生活行動を認識可能な環境発電型アナログPIRセンサノードを開発する。高い認識精度と長時間の稼働を両立するため、複数設置したセンサノード間での行動認識モデル分散実行機能と協調スリープ機能を新たに考案し、本システムに組み込む。独居高齢者宅における典型的な生活行動パターンを使って、屋内環境におけるシミュレーションを行った結果、提案する生活行動システムが、約5分に1回行動を認識する間欠動作であれば永続動作可能であることを確認した。また、5台のセンサノードによる行動認識モデルの分散実行方式を5人の被験者による5種類の行動に適用した結果、平均63.59%の精度で認識できることが分かった。

キーワード：宅内生活行動認識、環境発電、行動認識モデル分散実行、スリープ制御

## Battery-Free Real-time Daily Living Activity Recognition System through Distributed Execution of Recognition Model by Energy Harvesting Analog PIR Sensors

SHINYA MISAKI<sup>1,a)</sup> SOPICHA STIRAPONGSASUTI<sup>1</sup> TOMOKAZU MATSUI<sup>1</sup> HIROHIKO SUWA<sup>1</sup>  
KEIICHI YASUMOTO<sup>1</sup>

### 1. はじめに

フィジカル世界とサイバー世界を高度に融合することで経済発展と社会的課題の解決を両立する人間中心の社会 Society5.0の実現に向けた取り組みが推進されている。人々のQoLを向上させるには、人が多くの時間を過ごす家

にサイバーフィジカルシステム（CPS）を導入する必要がある。家に導入すべきCPSとして、生活行動認識システムが挙げられる。生活行動が自動認識されることで、人々の見守り、異常検知・健康支援、さらには行動の認識・予測に応じたスマート家電制御等のQoLを向上させるサービスが実現可能になると考えられる。

これまでに、宅内生活行動認識に関する研究は多数提案されている。上田ら[1]や中川ら[2]は、屋内位置測位センサと家電に取り付けた電力センサのみを利用した宅内行動認識手法を提案している。守谷ら[3]は、ECHONET Lite

<sup>1</sup> 奈良先端科学技術大学院大学 先端科学技術研究科  
Graduate School of Science and Technology, Nara Institute of Science and Technology

<sup>a)</sup> misaki.shinya.mq9@is.naist.jp

対応家電と人感センサを用いた宅内行動認識手法を提案している。しかし、これらの手法は、家に高価な位置推定システムや電力計、ECHONET Lite 対応家電などが導入済みであることを想定しており、設置工事やシステムを稼働する電力コストなどの負担が発生する。

一方、家側にセンサを必要としない生活行動認識手法として、ウェアラブルデバイスを使用した手法がある。Baoら [4] は、人に装着した複数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手法を提案している。しかし、住人がウェアラブルデバイスを常時装着する負担が発生する。

Matsuiら [5] は、一般家庭への設置が容易でバッテリー交換などのメンテナンスが不要な生活行動センシングシステム SALON を提案している。SALON では、太陽光パネルを備え室内光で動作可能な環境発電センサを使用することで配線やバッテリー交換などのメンテナンスを不要にしている。しかし、センサデータを収集・処理し、機械学習モデルにより行動認識するために、消費電力が高い高性能なゲートウェイ (PC) を必要としている。住人への負担を減らすためには、設置・維持コストが低く、住人がセンサを装着しなくて良い生活行動認識システムが必要であるが、そのようなシステムは著者らの知る限り未だ提案されていない。

本研究では、環境発電のみで永続的に動作し、住人がセンサを装着する必要がなく、かつ、高精度に宅内生活行動を認識可能なシステムを実現することを目的とする。そこで、室内光で動作し人の動きを継続的にセンシングするとともに機械学習により生活行動を認識可能なセンサノードを開発する。具体的には、低消費電力で、行動認識モデルを実行可能な処理性能と BLE メッシュネットワーク機能を備えた、小型マイコン PSoC6 にアナログ PIR センサと太陽光パネルを組み合わせたセンサノードを設計開発した。また、高い認識精度と長時間の稼働を両立するため、複数設置したセンサノード間での行動認識モデルの分散協調実行機能と協調スリープ機能を新たに考案・開発し、本システムに組み込んだ。

文献 [5] で収集された一般家庭の生活データから独居高齢者宅における典型的な生活行動パターンを抽出し、屋内環境を想定したシミュレーションを適用した結果、提案する生活行動システムが、約5分に1回行動認識を行う間欠動作により永続動作可能であることを確認した。また、5台のセンサノードによるランダムフォレストモデルの分散実行を適用した結果、5人の被験者の5種類の行動が、平均63.59%の精度で認識できることが分かった。

## 2. 関連研究

本研究は、バッテリー無しで永続的に動作する生活行動認識システムを、環境発電型センサノード、無線センサネッ

トワークでの分散処理およびスリープ制御により実現することを目指している。本章では、これらに関連した研究を概観する。

### 2.1 生活行動認識

生活行動認識に関して、これまでに、PIR センサや近接センサの情報や各種家電の使用情報、住人の位置情報を使用することで行動認識を行う手法 [1], [2], [3], [6], [7], RFID や WiFi などの電波から得られる周波数特性から行動認識を行う手法 [8], [9] などが提案されている。しかし、これらの行動認識手法では使用しているセンサに電源または電池が必要であるため、設置を行うための工事や電池交換のメンテナンスが必要であるという課題がある。

近年、太陽光パネル、圧電素子、ゼーベック素子などを使用し、様々な環境エネルギーから発電する研究が活発に行われている [10], [11], [12]。センサやマイコンの低消費電力化によって、給電やバッテリーを必要とせず、環境発電により動作するセンサノードが盛んに開発されており、それを利用した行動認識システムも幾つか提案されている。

柏本ら [6] は、スマートホームに設置された環境発電で駆動する PIR センサとドアセンサを使用し、外に出かける、家で過ごす、仕事、料理、食事、入浴、掃除、睡眠の8つの行動を平均で62.8%の精度で認識しており、入浴では92.6%の精度で認識している。また、仕事や食事などの場所に依存しない行動の認識率が低いため、アナログ PIR センサを使用した行動認識の研究も行っている [13]。この手法では、アナログ PIR センサを設置し、ソファ付近で行われる行動である食事、PC 作業、読書、スマートフォン操作の4つの行動を57.0%の精度で認識している。

Matsuiら [5] は、一般家庭への設置が容易でバッテリー交換などのメンテナンスが不要な生活行動センシングシステム SALON を提案している。SALON では、太陽光パネルを備え室内光で動作可能な環境発電センサを使用することで配線やバッテリー交換などのメンテナンスを不要にしている。

しかし、これらの既存システムは、センサデータを収集・処理し、機械学習モデルにより行動認識するために、消費電力が高い高性能なゲートウェイ (PC) を必要としている。住人への負担を減らすためには、設置・維持コストが低く、住人がセンサを装着しなくて良い生活行動認識システムが必要であるが、そのようなシステムは著者らの知る限り未だ提案されていない。

### 2.2 環境発電をセンサとして使用する行動認識

センシングと発電を同時に行うことで、バッテリーを必要とせず行動認識を行うことを目指したシステムが研究されている。

Huangら [14] はポリマーの膜が張られた銅板どうしが

ぶつかることによって発電することを利用し、環境発電型モーションセンサとして使用することで行動認識を行っている。この研究では、被験者の足にモジュールを装着させ、座る・立ち上がる、歩く、階段を上る、階段を下る、走るの5つの行動を平均で80.4%の精度で認識している。

梅津ら [15] は、太陽光パネルの明かりによる発電効率の違いに着目し、特性の違う太陽光パネルを組み合わせ、身体に装着することによって装着者のいる部屋（場所）を認識するモジュールの開発を行った。大学構内で実験を行った結果、階段、外、1階、4階、トイレなどの9つの場所を平均で87.6%の精度で認識が可能である。しかし、この研究では、太陽光パネルをセンサとしてのみ使用しているため発電量を計測するマイコンはバッテリーで駆動している。そのため、菅田ら [16] は、センサとして使用している太陽光パネルから発電された電力をコンデンサに蓄電し、タイムスタンプをマイコンに記録するバッテリー不要の名札型デバイスを開発した。記録したタイムスタンプから抽出した単位時間あたりの書き込み回数の特徴量としてランダムフォレストにより学習することで、大学構内のトイレ、プリンタ室、食堂などの8つの部屋を92.0%の精度で認識している。

Jung ら [17] は道路用途のためのポリフッ化ビニリデン (PVDF) 圧電フィルムを用いたフレキシブルな圧電エネルギーハーベスタモジュールを実証している。複数の PVDF 圧電フィルムを並列に接続し、15cm × 15cm のエナジーハーベスタモジュールを作成した。動作すると0.2Wの電力を出力し、100万回以上のサイクルで安定した性能と耐久性を発揮すると報告されている。

この他にも様々な環境発電を用いたセンサノードが開発されているが、ほぼ全ての既存手法において、センサノードは何らかの通信を行い、データをクラウドもしくはローカルのサーバに集約し、機械学習などの処理を行うことを想定している。センサデータの処理、その機械学習も含めて、全て環境発電のみで賄えるシステムは、著者らの知る限り存在しない。

### 2.3 ワイヤレスセンサネットワークにおける分散処理とスリープスケジューリング

WSN におけるエネルギー消費量を削減する試みは数多く行われてきた。例えば、動的電力管理 (DPM) は、ノードの状態を変化させることにより、ネットワークの性能を維持しつつ、消費電力を削減するために広く利用されている [18], [19], [20]。DPM の重要な技術は、各ノードがスリープ状態にあり、定期的にタスクを処理するためにノードを起動し、またスリープ状態に戻すことである。Estrada-López ら [21] は、土壌パラメータ推定システムのための WSN において、回路レベルとシステムレベルの DPM を提案している。回路レベルでは、XBee を介した

データ送信後にスリープさせ、システムレベルでは、すべてのセンサノードを特定の時間にアクティブにする、といった制御を行っている。

Mostafaei ら [22] は、ネットワークのカバレッジグラフに基づいてアクティブ状態のノードを選択し、残りのノードをスリープ状態に設定する部分カバレッジ学習オートマトン (PCLA) を提案した。シミュレーションの結果、PCLA は部分的なネットワーク要件を満たすことができ、部分的にアクティブにしたノードでより良い性能を保證できることが示された。Gupta ら [23] は、WSN における FoI (Field of Interest) の冗長性を低減する手法のための k-coverage を提案している。この研究では、3D ヘテロジニアス WSN を用いて、センサの種類と FoI の大きさを変えてシミュレーションを行い、その結果、センサの種類によってカバレッジの効用が異なり、スケジューリングポリシーによってネットワークの寿命を延長可能であることが示された。

しかし、これら既存手法は、生活行動認識のような対象アプリケーションを考慮していない。行動認識のためのセンサの動作時間はユーザが対象の部屋や場所にいるかどうかによって依存するため、このことを考慮したスリープスケジューリングが必要である。

## 3. 提案システム

本章では、提案システムの要件とアプローチを述べた後で、具体的な提案として、環境発電センサノードの設計、行動認識モデルの分散実行方式、永続動作のためのスリープスケジューリング方式の詳細を述べる。

### 3.1 提案システムの要件とアプローチ

本研究では、以下の2つの要件を満たす生活行動認識システムを実現する。

(要件1) 部屋で発生する様々な生活行動を高精度かつリアルタイムに認識する。

(要件2) 屋内光からの環境発電のみで、行動認識に必要なデータのセンシング、データ処理、行動の判別、判別した行動のスマートフォンなどへの送信を行う。

要件1を実現するためには、生活行動に伴う住人の動きを検知するセンサと、センサデータを処理し、行動認識モデルをリアルタイムに実行する必要がある。そのためセンサを備えたセンサノードが必要になる。また、要件2を実現するためには、センサノードへの給電を屋内光からの発電により賄う必要がある。そのため、本研究では、以下のアプローチを採用する。

(1) 人の微細な動きを検知可能なアナログ PIR センサを採用する。

(2) 低消費電力で、行動認識等に必要最低限の処理性能を備え、BLE 通信機能を備えたマイコンボードを採用する。




図 1 環境発電センサノード構成デバイス

- (3) 屋内光から発電可能な太陽光パネルを採用する。
- (4) 行動認識モデルの実行負担を分散処理で低減する。
- (5) センサノードをスリープさせることで、単位時間あたりの消費電力が単位時間あたりの発電量以下になるようにする。

上記 (1)-(3) に基づく環境発電センサノードを 3.2 節で、上記 (4) の分散処理を 3.3 節で、上記 (5) のスリープ制御を 3.4 節で、それぞれ詳しく述べる。

### 3.2 環境発電センサノードの設計

図 1, 2 に示す、横 250mm、縦 230mm、高さ 43mm の環境発電センサノードを開発した。本センサノードは、環境発電モジュール (Energy Harvest Module) と行動認識モジュール (Activity recognition module) で構成されている (2)。

環境発電モジュールは、屋内光から発電し、行動認識モジュールを安定動作させる。発電のため、アモルファスシリコン太陽電池を採用した。アモルファスシリコン太陽電池は、主に電卓の電源として使用されることが多く、横 94.7mm、縦 53.3mm の太陽光パネルで蛍光灯の明かり 200lux の環境において電圧 5.0V、電流 96.7 $\mu$ A を発電することが可能である。そこで少ない光量でも 1mA 程度の電流出力により安定した充電が可能であり、できるだけサイズを小さくするため、太陽光パネル 10 枚を図 1 のように組み合わせ、横 250mm、縦 230mm のセンサノードを作成した。センサノードが備える 10 枚の太陽光パネルは 750lux の環境において 5.04V、0.93mA で充電が可能である。オフィスやキッチンなどの屋内では 300lux から 750lux<sup>\*1</sup> であるため、安定した電力の供給が可能である。さらに発電された電力をリチウムイオンバッテリーに充電するとともに、マイコンにも給電するため、e-peas を使用する。このデバイスは太陽電池によって発電された不安定な入力電圧をリチウムイオンバッテリーに充電可能な出力電圧に変換する回路を備えており、一時的に光量が下がり、電圧が下がったとしても安定してリチウムイオンバッテリーに充電できる。また、同時にリチウムイオンバッテリーから安定した電力をマイコンに給電することが可能である。

\*1 <https://www.archtoolbox.com/materials-systems/electrical/recommended-lighting-levels-in-buildings.html>




図 2 環境発電センサノードの構成

行動認識モジュールは、アナログ PIR センサとマイコンから構成した。アナログ PIR センサとして、100-120° の角度から 11bit のアナログ信号を 10Hz のサンプル周波数で取り込み可能な、カスタム PIR センサ基板 (株式会社 Sensors & Works が開発) を使用した。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) を採用した。このデバイスは Arm Coretex-M4 (150MHz で動作) と Coretex-M0 (100MHz で動作) の 2 つのコア、1MB のフラッシュメモリ、288KB の SRAM メモリ、78 個の GPIO、Bluetooth Low Energy (BLE) 4.2 を搭載しており、典型的な消費電力は 33.542[mW] であり、ディープスリープでの消費電力は 1.357[mW] となっている。十分に低消費電力であり、環境発電型センサノードに適していると考えた。

### 3.3 生活行動認識モデルの構築と複数センサノードによる分散実行

提案システムでは、行動認識モデルを予め学習させておき、学習済みのモデルをセンサノードで実行することによりリアルタイム生活行動認識を実現する。



図 3 対象の行動

#### 生活行動認識モデルの構築

本稿では、図 3 に示す、ダイニングテーブルで行われる 5 種類の行動 (読書/reading, 書き作業/writing, 静止/stationary, 移動/moving, 無人/no one) を生活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、測定用センサノード (PSoC6 にアナログ PIR センサ、バッテリーおよび DEV-14531 シールドを介し

表 1 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	$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (s_i - \bar{s})^2}$
mad(s)	Median absolute deviation	$\text{median}_i( s_i - \text{median}_j(s_j) )$
max(s)	Largest values in array	$\max_i(s_i)$
min(s)	Smallest value in array	$\min_i(s_i)$
energy(s)	Average sum of the square	$\frac{1}{N} \sum_{i=1}^N s_i^2$
sma( $s_1, s_2, s_3$ )	Signal magnitude area	$\frac{1}{3} \sum_{i=1}^3 \sum_{j=1}^N  s_{i,j} $
entropy(s)	Signal Entropy	$\sum_{i=1}^N (c_i \log(c_i)),$ $c_i = s_i / \sum_{j=1}^N s_j$
iqr(s)	Interquartile range	$Q3(s) - Q1(s)$
autorregresion(s)	4th order Burg Autoregression coefficients	$a = \text{arburg}(s, 4)$ $a \in R^4$

N : signal vector length, Q : Quartile, s : Sensor data divided for each time window(100 samples)

た SD メモリカードを装着) を, 奈良先端大のスマートホームにおけるリビングルームの 5 箇所 (4 方向の壁と天井) に, 図 4 のように設置した. その上で, 5 人の被験者のそれぞれが, 部屋の中央 (ID5 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 (読書/reading, 書き作業/writing, 静止/stationary, 移動/moving, 無人/no one) を 1 分間, 5 回ずつ実施した (被験者ごとに各行動につき 5 分のデータを収集). 移動/moving については, ID4 側にある扉を介した隣の部屋への移動を 1 分間に 5-7 回繰り返してもらった. 無人/no one に関しては, 被験者がリビングルームにいない状態で, データを収集した. 被験者の位置と身体の向きを固定し, サンプリング周波数 10Hz で測定を行った. 測定時間内は, 指定された行動を行ってもらい, その測定時間内は, 指定された行動のみを行ったとしてラベル付けを行った. 取得したデータから表 1 に示す特徴量を抽出した. これらの関数は, 日常行動認識に関する関連研究 [24] から有効性が示されている関数の時間成分の関数に絞っている.

5 箇所に設置した各センサノードに対して, 取得したデータを一定区間 (本研究では, 10 秒間とする) に分割し, 各区間から特徴量を算出し, 特徴量を入力として, ランダムフォレストにより学習モデルを構築した. 学習済みモデルをメモリ容量が 1MB と少ない PSoC6 で実行することを考慮し, 学習に用いる木の数を 40 とし, Python の scikit-learn を用いてモデルを訓練した.

#### 学習済みモデルの変換

訓練したモデルは Python のオブジェクトであるため, そのままでは PSoC6 で実行できない. そこで, m2cgen<sup>\*2</sup>を使って, Python のモデルから C 言語で書かれたコードに変換した. 変換したコードのサイズはソースコードで 87KB, コンパイル後のバイナリコードは 115KB であり, PSoC6 で十分実行可能なサイズに収まった.




図 4 実験概要図

#### 生活行動認識モデルの分散実行

提案システムでは, 以下の 2 つの要求から, 図 4 に示すように, 住人を取り囲むように複数箇所にセンサノードを設置する. 1 つ目は, 人の向いている方向によって, センサが取得するデータが不正確になることを防ぎたいためであり, 2 つ目は, ランダムフォレストの木の数を減らすことで 1 ノードあたりの使用メモリ容量および処理負荷を低減したいためである. そこで, これらの要求を満たすため, 以下の分散処理方式を提案する.

- (1) 各センサノードは一定期間 (10 秒), データをセンシングする.
- (2) 各センサノードはセンシングしたデータから特徴量を計算する.
- (3) 各センサノードは特徴量を RF モデルに入力し行動認識結果 (5 種類の各行動の確率) を得る.
- (4) 各センサノードは行動認識結果 (5 種類の各行動の確率) を他ノードにブロードキャストする.
- (5) 各センサノードは各行動ごとにブロードキャストされた確率の総和 (または積) を求め, 最も高い値の行動を最終的に認識した行動として決定する.
- (6) 各センサノードは認識した行動をブロードキャストする.

<sup>\*2</sup> <https://github.com/BayesWitnesses/m2cgen>



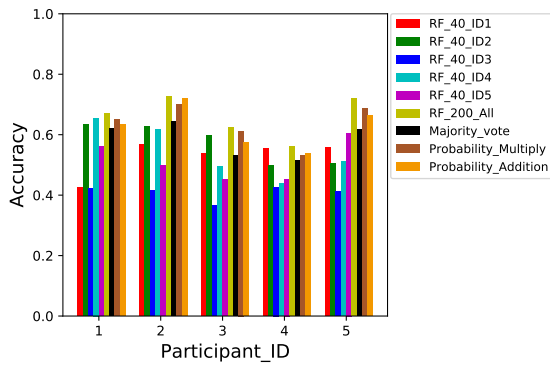


図 5 各被験者ごとの行動認識精度




図 6 各行動ごとの認識精度

### 3.4 スリープスケジュールによる永続動作

各環境発電センサノードが 3.3 節で述べた動作を行う際の消費電力が、屋内光からの発電電力以内である場合には、提案システムは永続動作が可能である。しかしながら、3.3 節で設計開発した環境発電センサノードを使っても屋内光による発電量はそれほど多くない。そのため、動作が必要でない時にはスリープすることにより消費エネルギーを削減する仕組みが必要である。本研究では、以下の 2 つのスリープ制御方式を組み合わせることで、提案システムの永続動作を実現する。

- 人が対象空間内にいない時は、複数あるセンサノードの一つだけがセンシングを続け、他のセンサノードはスリープさせる（留守モード）。
- 一定期間（10 秒など）センシング・行動認識した後、一定期間（例えば、100 秒）必ずスリープさせることによりシステムを間欠動作させる（間欠動作モード）。

ユーザが部屋にいないことが検出されると、センサノードは留守モードに移行する。留守モードの間には、1 つのセンサノードのみがアクティブノードとして動作（センシング）するようにする（アクティブノードは、絶対時刻とノード ID により一意に決定する）。残りのセンサノードはスリープ状態にし、定期的に起動し状況をチェックする。アクティブノードは、一定時間（10 分など）アクティブノードとして動作すると、他のノードにアクティブノードを譲る。このように、留守モードの間（ユーザが部屋にいない間）、アクティブノードが入れ替わりながら、節電を行う。アクティブノードが、ユーザが部屋に入ってきたことを検出すると、アクティブノードは、ブロードキャストメッセージにより他のノードに知らせ、留守モードを終了する。

留守モードだけでは、永続動作が不可能な場合には、間欠動作モードを併用する。デューティサイクル  $c$  において、アクティブな時間を  $c_{active}$ 、スリープしている時間を  $c_{sleep} = c - c_{active}$  とする。環境発電による発電電力を  $P_{EH}$ 、アクティブ時、スリープ時のセンサノードの消費電力をそれぞれ、 $P_{active}$ 、 $P_{sleep}$  とすると、以下の式が成立




図 7 ID3 の混同行列

するよう、 $c_{active}$  および  $c_{sleep}$  を決定する。

$$P_{active} \cdot c_{active} + P_{sleep} \cdot c_{sleep} \leq P_{EH} \cdot c \quad (1)$$

## 4. 評価実験

提案システムの性能を評価するため、図 4 に示す環境にセンサを設置し、評価実験とシミュレーションを行った。

### 4.1 生活行動認識精度の評価

各被験者ごとに、各センサノードごとの認識モデルの出力 (RF\_40\_ID1-5)、5 つのセンサノードの出力結果（最大確率の行動）の多数決 (Majority\_vote)、5 つのセンサノード群の出力（各行動の確率）の和または積 (Probability\_Addition/Multiply)、5 センサノードで得た特徴量を一つのモデルで学習 (RF\_200\_All) をリーブワンセッションアウトの交差検証によって比較・評価した。すべての場合でランダムフォレストを使用している。サーバ内での処理を想定した RF\_200\_All の決定木の数が 200 であること以外、PSoC6 での動作を想定し、すべての木の数は 40 に設定している。図 5 に認識精度を棒グラフで比較したものを、図 6 にすべての被験者の各行動の平均認識精度を示す。図 5 に示すように、被験者によって差はあるが、個別で認識したモデルよりも、それぞれのセンサノードから得られた行動の確率を乗算して組み合わせた認識の精度がサーバでの認識結果と同等の 63.59% の精度で認識が可能となっ

表 2 平均的な一日の行動時間

Activity	time[h]
OTHER	9.16
BATHE	0.61
COOK	1.08
EAT	1.81
LEAVE	4.18
SLEEP	7.16

表 3 消費電力量と充電能力比較 (留守モードのみ)

処理	消費・発電電 力 [mW]	動作時間 [h]	消費・発電 エネルギー [mWh]
センシング (10Hz)	33.542	13.2498	444.425
認識モデル実行	35.312	0.00001	0.005
認識結果送信	35.409	0.00004	0.001
スリープ	1.357	10.7501	14.588
発電・充電	2.947	16.8417	49.632
Total			-409.388

ている。行動ごとに認識精度の平均を見ていくと、移動の行動の認識精度がどの認識手法についても認識精度が高く次に読書が高く、静止状態の精度が最も低くなっている。図 7 に示す被験者 ID3 の混同行列を見ると静止状態と誰もいない状態を誤認識している場合が多いことが分かる。これは、比較的動きの大きい行動である移動と読書は認識しやすいが、静止状態と誰もいない状態は区別が難しいことが分かる。

#### 4.2 システムの永続動作の評価

システムの永続動作の評価のため、今回環境発電モジュールを 10 台設置したと仮定し、関連研究である SALON[5] の生活行動データセットとスマートホームの環境をもとにシミュレーションを行った。表 2 に単独世帯の平均的な 1 日の行動の時間数を示す。図 4 の環境において、このデータの睡眠の期間中を 0Lux、それ以外の行動は、照明をつけた状態での明るさ 500lux (実測値) とする。この環境における環境発電モジュールの発電量の実測値は 2.947mW であり、この電力量で充電したものとす。そして、外出/Leave, 入浴/Bathe, 睡眠/Sleep はリビングルームにいない期間、それ以外はリビングルームにいる期間と想定する。さらに消費電力は PSoC6 のスペックとして示されている電力を参考に決定し、サンプリング、特徴量計算、行動認識結果出力、データ送信を行う時は最大消費電力量が消費されるとする。

リビングルームにいない間は留守モード (10 ノードが一定間隔でアクティブになり他はスリープする) でスリープ制御した場合の 1 日の電力消費量と充電能力の比較を表 3 に示す。この表に示すようにリビングルームにいる時間が長い場合、留守モードのスリープ制御を使っても、充電する時間が短くなってしまいうため 1 日の充電能力を大きく上

表 4 消費電力量と充電能力比較 (間欠動作モード:スリープ 300 秒)

処理	消費・発電電 力 [mW]	動作時間 [h]	消費・発電 エネルギー [mWh]
センシング (10Hz)	33.542	0.4287	14.380
認識モデル実行	35.312	0.00005	0.002
認識結果送信	35.409	0.00001	0.001
スリープ	1.357	23.5712	31.987
発電・充電	2.947	16.8417	49.632
Total			3.263

回る電力消費量となってしまう。そこで、ユーザが部屋にいる場合といない場合の両方の場合について、センサノードの動作 (10 秒間のセンシングと処理) の直後に 300 秒のスリープを入れる間欠動作モードでシミュレーションを行った。表 4 に結果を示す。この場合であれば 1 日の消費電力量が充電能力を超えることはなく、永続的な動作が可能であることが分かった。

#### 5. まとめ

本研究では、センシングから行動認識までの一連の動作を環境発電でのみで永続的に実行可能な生活行動認識システムを目指し、太陽光パネル、アナログ PIR, PSoC6 から構成される環境発電センサノードと、複数センサノードによる行動モデルの分散実行方式、スリープ制御によるシステムの駆動時間の延長方式を提案した。提案する行動モデルの分散実行方式は、個別で認識したモデルよりも、認識精度が高く、サーバに集約して一つのモデルで認識するのと同等の 63.59% の精度で認識ができた。提案するスリープ制御方式は、約 5 分に 1 回の間欠的な行動認識とすることにより、1 日の発電量が消費電力量を上回らず、システムの永続動作が可能であることが分かった。

#### 謝辞

本研究は、国立研究開発法人情報通信研究機構 (NICT) の委託研究「未来を創る新たなネットワーク基盤技術に関する研究開発」の成果である。

#### 参考文献

- [1] 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).
- [2] Nakagawa, E., Moriya, K., Suwa, H., Fujimoto, M., Arakawa, Y. and Yasumoto, K.: Toward real-time in-home activity recognition using indoor positioning sensor and power meters, 2017 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops), IEEE, pp. 539-544 (2017).
- [3] Moriya, K., Nakagawa, E., Fujimoto, M., Suwa, H., Arakawa, Y., Kimura, A., Miki, S. and Yasumoto, K.: Daily living activity recognition with ECHONET

- Lite appliances and motion sensors, *Pervasive Computing and Communications Workshops (PerCom Workshops)*, 2017 IEEE International Conference on, IEEE, pp. 437–442 (2017).
- [4] Bao, L. and Intille, S. S.: Activity recognition from user-annotated acceleration data, *International conference on pervasive computing*, Springer, pp. 1–17 (2004).
- [5] Matsui, T., Onishi, K., Misaki, S., Fujimoto, M., Suwa, H. and Yasumoto, K.: ESALON: Simplified Sensing System for Activity of Daily Living in Ordinary Home, *Sensors*, Vol. 20, No. 7 (2020).
- [6] Kashimoto, Y., Hata, K., Suwa, H., Fujimoto, M., Arakawa, Y., Shigezumi, T., Komiya, K., Konishi, K. and Yasumoto, K.: Low-cost and Device-free Activity Recognition System with Energy Harvesting PIR and Door Sensors, *Adjunct Proceedings of the 13th International Conference on Mobile and Ubiquitous Systems: Computing Networking and Services, MOBIQUITOUS 2016*, ACM, pp. 6–11 (online), DOI: 10.1145/3004010.3006378 (2016).
- [7] Kasteren, T. L., Englebienne, G. and Kröse, B. J.: An Activity Monitoring System for Elderly Care Using Generative and Discriminative Models, *Personal Ubiquitous Comput.*, Vol. 14, No. 6, pp. 489–498 (online), DOI: 10.1007/s00779-009-0277-9 (2010).
- [8] Kellogg, B., Talla, V. and Gollakota, S.: Bringing gesture recognition to all devices, *11th {USENIX} Symposium on Networked Systems Design and Implementation ({NSDI} 14)*, pp. 303–316 (2014).
- [9] Wang, Y. and Zheng, Y.: Modeling RFID Signal Reflection for Contact-free Activity Recognition, *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.*, Vol. 2, No. 4, pp. 193:1–193:22 (online), DOI: 10.1145/3287071 (2018).
- [10] Jabbar, H., Song, Y. S. and Jeong, T. T.: RF energy harvesting system and circuits for charging of mobile devices, *IEEE Transactions on Consumer Electronics*, Vol. 56, No. 1, pp. 247–253 (2010).
- [11] Febbo, M., Machado, S. P., Gatti, C. D. and Ramirez, J. M.: An out-of-plane rotational energy harvesting system for low frequency environments, *Energy conversion and management*, Vol. 152, pp. 166–175 (2017).
- [12] Deng, F., Yue, X., Fan, X., Guan, S., Xu, Y. and Chen, J.: Multisource energy harvesting system for a wireless sensor network node in the field environment, *IEEE Internet of Things Journal*, Vol. 6, No. 1, pp. 918–927 (2018).
- [13] Kashimoto, Y., Fujiwara, M., Fujimoto, M., Suwa, H., Arakawa, Y. and Yasumoto, K.: ALPAS: Analog-PIR-sensor-based activity recognition system in smarthome, *2017 IEEE 31st International Conference on Advanced Information Networking and Applications (AINA)*, IEEE, pp. 880–885 (2017).
- [14] Huang, H., Li, X., Liu, S., Hu, S. and Sun, Y.: 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 (2018).
- [15] Umetsu, Y., Nakamura, Y., Arakawa, Y., Fujimoto, M. and Suwa, H.: EHAAS: Energy Harvesters As A Sensor for Place Recognition on Wearables, *2019 IEEE International Conference on Pervasive Computing and Communications (PerCom)*, pp. 1–10 (online), DOI: 10.1109/PERCOM.2019.8767385 (2019).
- [16] Sugata, Y., Arakawa, Y. and Yasumoto, K.: Battery-less Place Recognition System using Multiple Energy Harvesting Elements, *2019 IEEE SENSORS*, IEEE, pp. 1–4 (2019).
- [17] Jung, I., Shin, Y.-H., Kim, S., Choi, J.-y. and Kang, C.-Y.: Flexible piezoelectric polymer-based energy harvesting system for roadway applications, *Applied energy*, Vol. 197, pp. 222–229 (2017).
- [18] Liu, C.-T. and Hsu, R. C.: Dynamic power management utilizing reinforcement learning with fuzzy reward for energy harvesting wireless sensor nodes, *IECON 2011-37th Annual Conference of the IEEE Industrial Electronics Society*, IEEE, pp. 2365–2369 (2011).
- [19] Koulali, M.-A., Kobbane, A., El Koutbi, M., Tembine, H. and Ben-Othman, J.: Dynamic power control for energy harvesting wireless multimedia sensor networks, *EURASIP Journal on Wireless Communications and Networking*, Vol. 2012, No. 1, p. 158 (2012).
- [20] Hsu, R. C., Liu, C.-T. and Wang, H.-L.: A reinforcement learning-based ToD provisioning dynamic power management for sustainable operation of energy harvesting wireless sensor node, *IEEE Transactions on Emerging Topics in Computing*, Vol. 2, No. 2, pp. 181–191 (2014).
- [21] Estrada-López, J. J., Castillo-Atoche, A. A., Vázquez-Castillo, J. and Sánchez-Sinencio, E.: Smart soil parameters estimation system using an autonomous wireless sensor network with dynamic power management strategy, *IEEE Sensors Journal*, Vol. 18, No. 21, pp. 8913–8923 (2018).
- [22] Mostafaei, H., Montieri, A., Persico, V. and Pescapé, A.: A sleep scheduling approach based on learning automata for WSN partial coverage, *Journal of Network and Computer Applications*, Vol. 80, pp. 67 – 78 (online), DOI: <https://doi.org/10.1016/j.jnca.2016.12.022> (2017).
- [23] Gupta, H. P., Rao, S. V. and Venkatesh, T.: Sleep Scheduling Protocol for  $k$ -Coverage of Three-Dimensional Heterogeneous WSNs, *IEEE Transactions on Vehicular Technology*, Vol. 65, No. 10, pp. 8423–8431 (online), DOI: 10.1109/TVT.2015.2508801 (2016).
- [24] Anguita, D., Ghio, A., Oneto, L., Parra, X. and Reyes-Ortiz, J. L.: A public domain dataset for human activity recognition using smartphones., *Esann* (2013).