

充電不要なライフログ記録システムの提案と 実用環境での性能検証

有田 充¹ 中村 優吾¹ 石田 繁巳² 荒川 豊¹

概要：身の回りの光や、行動による振動などの環境エネルギーを電力に変換するエナジーハーベスティング (EH: Energy Harvesting) 素子を電源として扱おうと同時に、センサとして利用する研究が行われてきた。我々の研究グループでは、充電不要で半永久的に動作するライフログ記録システムの実現を目指し、これまでに太陽電池を用いた場所推定システムを提案している。しかし、前提案システムの評価に用いたデータは、静止した状態での測定であり、複数人でのデータ収集も行っていないため、評価としては不十分であった。加えて、一度暗い場所を訪れると、システムが停止し復帰ができないという問題があった。本稿では、前提案システムの問題を2つの電圧検出回路による電源のスイッチングにより解決する手法を提案する。提案システム評価のため、実際の環境で、11人の被験者を対象としたデータ収集実験を行い、機械学習分類モデルを用いて被験者が訪れた場所の推定と、そこでとった行動の認識を行う。評価の結果、被験者依存モデルで、8つの場所をf値の重みつき平均87.2%、静的/動的の行動を93.1%で分類可能であることが示された。

1. はじめに

生活習慣病の患者数は年々増加しており社会問題となっている。特にストレスが溜まりがちで、運動不足になりがちなおフィスワーカーは生活習慣病予備軍と言え、おフィスワーカーの生活習慣や健康についての研究が多くなされている [1], [2]。生活習慣病は日頃の生活習慣に起因するため、ライフログを用いて生活習慣を見直すということは1つの予防法である。例えば、1日の運動量や喫煙所に訪れた回数を客観視できるため、生活習慣改善の第一歩へと繋がる。ライフログに必要な情報は、いつどこで何をしたか (When, Where, What) という3つの情報であり、以降では、これらをまとめてコンテキスト情報と呼ぶ。

場所推定には、GPSがよく使用される。GPS (Global Positioning System) は屋外で高い精度の位置測位が可能であるが、屋内では遮蔽物の影響により数メートルの誤差が生まれるため、正確な場所推定は不可能である。しかし一日の大半を一つの建物内で過ごすおフィスワーカーにとっては、屋内のどの場所に滞在したかの情報が重要となる。そのため、WiFi, BLE (Bluetooth Low Energy) 等を用いたビーコンによる屋内位置測位手法が検討されている [3], [4], [5], [6]。しかしながら、電波を用いたいずれの手法も、電波を受信するためにスマートフォンなどの無線

通信デバイスを常に身に付け、起動しておく必要があり、バッテリー消費やそれに伴う充電の手間が問題となる。

一方、行動認識に関しては加速度センサがよく使用される。加速度センサを人間に取り付けることで、歩行や階段の昇降動作等を細かく認識することが可能となるが、十分なサンプリングレートや電力が必要となる。

本研究のターゲットであるライフログでは、ビーコンを用いた手法のように、高精度な位置測位を必要とはしておらず、教室やトイレなどの場所単位での滞在歴で十分である。また、日常的に着用する小型のウェアラブルデバイスは、搭載することができるバッテリー容量に制限がある。そのため、常時何らかのセンサをライフログのために動作させることは、低消費電力化が進んだ歩数計以外は難しい状況である。

そこで、我々の研究グループでは、身の回りの光や、行動による振動などの環境エネルギーを電力に変換して利用するEHに注目した。EHはその発電量が周辺環境に大きく依存するといった不安定な特性を持つ。この特性から、EH素子を電源として扱おうと同時に、コンテキスト認識センサとして利用できると考え、充電不要で、身につけておくだけで自動的にライフログを構築可能な、ウェアラブルデバイスの実現を目指した。

目的を達成するために、まず梅津らの研究 [7] で、EH素子が場所推定センサとして利用可能か、を確かめるための実証実験を行った。EH素子として太陽電池、ピエゾ素

¹ 九州大学, Kyushu University

² 公立はこだて未来大学, Future University Hakodate

子、ペルチェ素子を採用し、それらをセンサとして用いる EHAAS (Energy Harvesters As A Sensor) システムを設計した。このシステムを用いて屋内外の9つの異なる場所に対して場所推定を行ったところ、照度センサと加速度センサを用いた従来のシステムを超える精度で、場所推定が可能なが示された。また、EH素子を太陽電池に限定した場合でもf値86.2%という精度を達成したため、場所推定においては太陽電池が適切であると結論付けた。しかし、梅津らのシステムはEHの発電量に基づいた場所推定の可否に焦点を当てていたため、システムの電源には外部電源を使用しており、バッテリー消費問題は解決しなかった。

菅田らの研究 [8] では、EH素子として3つの太陽電池を採用し、発電した電力をシステムの電源としても利用可能にしつつ、自らの電力でその発電量を記録する回路を設計することで、バッテリー消費問題を解決し、充電不要な場所推定システムを実現した。このシステムでは8つの異なる場所をf値92%の精度で推定できたが、使用したデータは移動中のデータを含んでおらず、静止状態のみの測定であったため、実用性を評価するには不十分な実験であった。加えて、トイレなどの暗所では十分な発電量を確保できず、システムが停止し、復帰できないという問題もあった。

本研究では、既存デバイスの回路設計を見直し、システムが復帰できない問題を解決した。その上で、EH素子としてピエゾ素子を追加することで、場所だけでなく行動認識を可能とするシステムを提案する。システム構成を図1に示す。

ライフログ構成要素の一つである時刻はリアルタイムクロック (RTC: Real Time Clock) によって取得する。システムが動作していない間も、RTC時間を保持するために、システムは一次電池を保有する。一般的に、時刻保持の目的での一次電池は、パーソナルコンピュータ等の様々なシステムで採用されており、3~4年は電池交換を行う必要がない。照明のない部屋のような動作保証外の環境では、電源をRTC保持用の一次電池に切り替えることで、システムの復帰を可能とする。本稿では、一次電池の使用を最小限にするような機構を提案し、システム寿命を延ばす。以上の工夫によって、充電やバッテリーメンテナンスが不要なシステムを実現させる。

提案システムの汎化性と実用性を評価するために、異なる天気 (晴れ, 曇り, 雨) と日付 (6日) でデータ収集実験を実施し、被験者11人に対して計11時間分のデータを収集した。評価の結果、8つの場所をf値の重み付き平均87.3%, 静的/動的の行動を93.2%で分類可能であることが実証された。

本稿の構成は以下の通りである。第2章で、EHをセンサとして利用する関連研究について述べる。第3章で、提案システムについて述べる。第4章で、実験環境とその評価について述べ、第5章を本稿のまとめとし、今後の展望

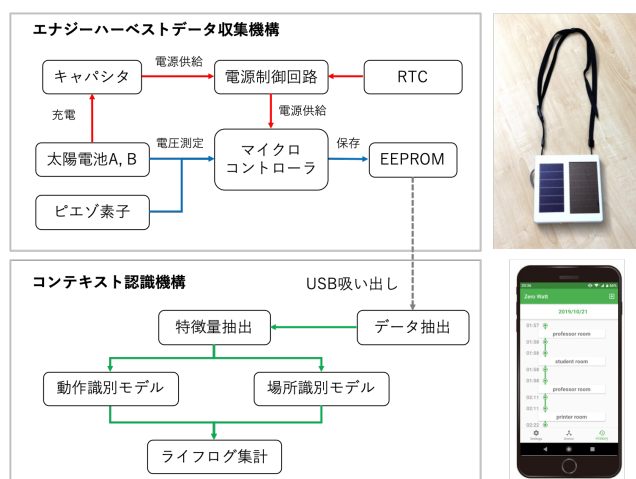


図1 システム構成

について述べる。

2. 関連研究

本章ではエネルギーハーベスティング (EH: Energy Harvesting) の応用例及び、EH素子を用いたコンテキスト認識に関する関連研究について述べる。EHとは、身の回りの光や、振動などの環境エネルギーを収穫して、電力に変換して利用する技術である。Maら [18] はウェアラブルIoT (Internet of Things) デバイスの大規模展開には、バッテリーの持続時間や廃棄といった問題から、EH材料が注目されているとし、EHを電源として扱うと同時に、コンテキスト認識センサとして利用する研究について報告している。以下に、EHをセンサとして用いる研究について述べる。

Khalifaら [10] は、運動エネルギーを電力に変換するKEH (Kinetic Energy Harvesting) を用いた人間活動認識 (HARKE: Human Activity Recognition from Kinetic Energy harvesting) の性能評価をプロトタイプを用いて行った。その結果、HARKEは従来のセンサに比べて消費電力を79%削減できることがわかった。Maら [13], [14] は、KEHを電源として使用すると同時にセンサとして使用するための機構を提案した。EHの過程でセンシング信号が歪むことを考慮し、それを補正するフィルタリングアルゴリズムを考案した。このアルゴリズムを実装したデバイスを用いて、最大でシステム動作に必要な電力の127%を収集しながら、従来研究より高精度で歩行検出が可能であることを実証した。Azizら [15] は、RF (無線周波数) 信号の電力を用いた、バッテリーレス3次元位置測位システムを提案している。3m×1mの巨大なビーコンから発生する電波を64個のアンテナで受信することで、高精度な3次元位置測位を可能とした。Lanら [9] はKEHを用いて、歩行/走行の分類を行った。その結果、加速度センサの推定精度に近い精度で分類が可能であることがわかった。しかし、システムはハーベスティング機能を持たず、外部電源を必要とした。同じくLanら [11], [12] は、KEHをキャパシタ

表 1 EH のセンサ利用に関する研究

年	参照	EH	ハーベスティング機能の実装	バッテリー充電		コンテキスト認識	
				メンテナンス不要		場所推定	行動認識
2015	[9]	ピエゾ	×	×	-	-	歩行/走行
2017	[10]	ピエゾ	×	×	-	-	5つの行動
2017	[11], [12]	ピエゾ	○	○	-	-	5つの行動
2018	[13], [14]	ピエゾ	○	×	-	-	歩行検出
2019	[15]	RF	○	○	3D 位置	-	-
2020	[16]	ピエゾ	○	×	6つの交通機関	-	-
2021	[17]	太陽電池	×	○	-	-	5つの行動
2019	[7]	太陽電池, ピエゾ	×	×	-	-	9つの場所
2019	[8]	太陽電池	○	○	-	-	9つの場所
2021	提案システム	太陽電池, ピエゾ	○	○	9つの場所	-	静的/動的行動

に接続し、その充電速度から行動を推定する CapSense を提案した。CapSense を靴に実装したウェアラブルデバイスを用いて、5つの行動認識を95%の精度で達成しつつ、従来のシステムから消費電力を57%削減可能であることを実証した。しかし、一部の静的な行動においては、キャパシタ充電に時間がかかり、サンプリングレートが低下するという問題があった。Sandhu ら [16] は、KEH を用いてその振動から交通機関（電車、フェリー等）の推定を行った。大規模なデータ収集実験の結果、一部の大きな振動を伴う交通機関では、EH の発電電力がセンサ信号記録に使用する電力を上回る、エネルギーポジティブを達成したことを報告している。同じく Sandhu ら [17] は、太陽エネルギーを電力に変換する SEH (Solar Energy Harvesting) を用いて5つの行動認識を行った。ウェアラブルデバイス内にセンサ信号の取得から無線通信を含めた、行動認識パイプラインを実装し、太陽電池の電力のみで、そのパイプラインをエネルギーポジティブに実行可能なことを示した。しかし、提案するアルゴリズムの評価に用いたプロトタイプはハーベスティング機能を持たず、外部電源を必要とした。

それぞれの関連研究について表 1 にまとめる。EH の発電電力を活用する、ハーベスティング機能を実装した例は多くあるが、場所推定と行動認識を同時に行い、考えられる全てのシナリオで動作する、充電不要なシステムは我々の知る限り存在しない。

3. EH を利用したライフログのためのコンテキスト認識システム

図 1 で示したように、システムは EH データ収集ブロックとコンテキスト認識ブロックに分かれる。EH データ収集ブロックで EH 発電量を記録する。コンテキスト認識ブロックでは、データ収集デバイスから手動で抽出されたデータを用いて、場所及び行動の推定を行う。本章ではそれぞれのブロックにおける動作について詳しく述べる。




図 2 光環境に依存するサンプリングレート

3.1 EH データ収集ブロック

以下の節ではまず、EH 発電電力を活用してセンサ信号を記録するためのアイデアについて説明する。次に、2つの電圧検出回路を利用した状態遷移について述べた後、それらを実装したデバイスについて述べる。

3.1.1 EH 発電電力を活用したセンサ信号記録

菅田ら [8] や CapSense [11], [12] のアイデアを基にバッテリーレスにセンサ信号を記録する。EH 素子をキャパシタに接続し、間欠動作を行うことで低サンプリングレートで、周期的な記録が可能となる。その際のサンプリングレートは、周囲環境に依存するため、コンテキスト認識において重要な情報となる。例えば、図 2 で示すように、部屋の明るさによって、サンプリングレートが大きく変化する。センサ信号の記録と同時に RTC から得られるタイムスタンプを記録することで、サンプリングレートを取得する。

3.1.2 2つの電圧検出回路を用いた状態遷移

前提案システムでは一度暗い場所を訪れ、キャパシタの電圧がマイコンの最低動作電圧を下回った場合、再び電圧が駆動可能範囲まで充電されても復帰できない問題があった。この問題を解決するためにヒステリシス特性を持つ電圧検出回路を導入する。この電圧検出回路には図 3 のようなヒステリシス特性があり、2つの閾値を所有している。キャパシタを電圧検出回路に接続し、出力が High となった場合、記録動作に移り、Low となった場合マイコンをス




図 3 電圧検出回路の動作

リープさせキャパシタ充電に移ることで図 2 の様な間欠動作が実現可能となる。

しかし、キャパシタ電圧がマイコンの最低動作電圧を下回った場合、マイコンの動作が不安定となり、システムが復帰不可能となる。電圧検出回路の出力が Low となった際に、電源を RTC の時刻を保持するための一次電池に切り替えることで、常に安定した電源供給が可能となり、システムは復帰可能となるが、キャパシタ充電時は一次電池に頼る。充電不要でメンテナンスフリーなデバイスを目指すためには、一次電池の使用を最小限に抑える機構が求められる。

そこで電源スイッチング用、マイコンスリープのトリガ用の 2 つの電圧検出回路を導入し、一次電池の使用を最小限に抑える機構を考案した。図 4 にキャパシタ電圧によるシステムの状態遷移を示す。Th1 は電源スイッチングの用途、Th2 はマイコンスリープのトリガ用途である。状態 1~4 は明るい場所、状態 5 と 6 は暗い場所での動作を表している。それぞれの状態について以下に示す。


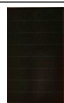
- ① 一次電池から電源供給、マイコンはスリープ状態である。
- ② 電源がキャパシタに切り替わる。
- ③ 記録シーケンスに移り、記録後は LED によって素早く電力を消費する。
- ④ マイコンがスリープに移行する、十分な発電量があればキャパシタは充電される。
- ⑤ マイコンがスリープに移行する、発電量が不十分であればキャパシタ電圧が減少する。
- ⑥ 電源が一次電池に切り替わる。

以上の状態遷移で示したように、2 つの電圧検出回路を用いることで、キャパシタ充電時もキャパシタからの電源供給が可能となり、一次電池の使用を最小限に抑えることが可能となる。

3.1.3 提案手法の実装

本研究では、オフィスワーカーのライフログを記録することを目的とするため、提案手法を名札型のデバイスに実装した。以下、本稿ではこのデバイスを名札センサと呼ぶ。名札センサでは、表 2 に示す 2 つの特性の異なる太陽電池と piezo 素子を EH 素子として採用する。名札センサを着

表 2 使用した太陽電池

種類	色素増感 (sc1)	アモルファス (sc2)
画像		
電力	252 μ W	332 μ W
サイズ	97*57mm	96*47mm

用して様々な場所を訪れた際の、太陽電池発電量の推移を図 5 に示す。屋内の光でも安定した発電が可能な色素増感太陽電池 (sc1) と、入射する光によって特性が大きく変化するアモルファス太陽電池 (sc2) を組み合わせることで、安定した電源供給を可能にしながら、高い精度でコンテキスト認識を実現させる。実環境での動作テストにおける平均サンプリングレートは約 2.15 Hz であった。

これらの EH 素子から得られる電力を用いて、自身の発電量 (開放電圧) を測定し、デバイス内の不揮発性メモリに書き込む。なお、今回作成したデバイスでは、太陽電池から得られる電力のみを利用しており、piezo 素子から得られる電力はデバイスの電源として利用していない。その理由は、回路設計時には piezo 素子を EH として利用することを考慮していなかったからである。図 6 及び図 7 に名札センサを装着している様子と名札センサ回路を示す。

3.2 コンテキスト認識ブロック

以下の節でコンテキスト認識ブロックにおけるそれぞれの動作 (前処理、特徴量抽出、機械学習) について詳しく述べる。

3.2.1 前処理

まず、電源投入直後のデータは異常値が含まれることがあるため、最初の 30 秒のデータを除去する。また、明らかな異常値のデータの除去も行う。異常値除去の後、タイムスタンプからサンプリングレートの計算を行う。3.1.3 節でも述べた通り、センサデータ測定 of サンプリングレートは光環境に依存するため、重要な情報となる。そのため、抽出したデータのタイムスタンプから 1 秒当たりのサンプル数を計算し、サンプリングレートのデータとして追加する。次に、従来のセンサと比較するために、加速度センサのサンプリングレート 100 Hz に合わせてアップサンプリングを行う。アップサンプリングには線形補間を使用した。時間に関する特徴量を適用するために、各データは固定長のウィンドウを用いて分割する。正当に比較するため、ウィンドウサイズは加速度センサの行動認識でよく使われる 1.24 秒 [19], [20] を採用した。ウィンドウオーバーラップ率は、50% である。

3.2.2 特徴量抽出

今回は、加速度センサを用いた行動認識に関する先行研究 [19], [20] から有効性が示されている 17 種類の特徴量

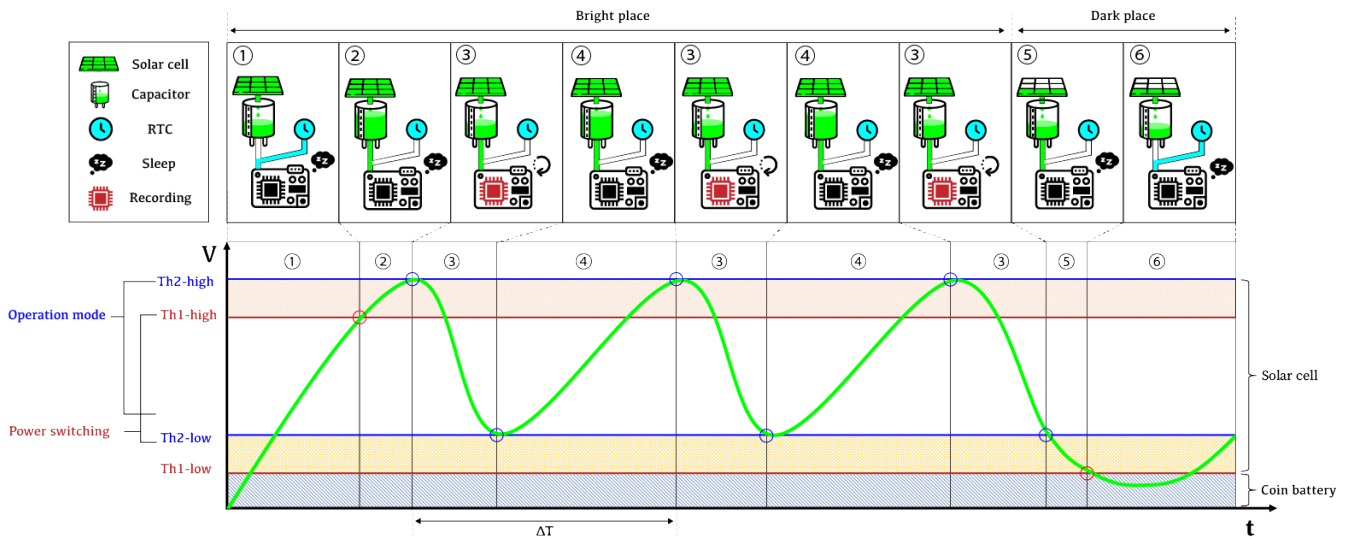


図 4 キャパシタ電圧による状態遷移




図 5 太陽電池発電量の推移



図 6 名札センサ装着例




図 7 名札センサ回路

(平均値, 標準偏差, 中央絶対偏差, 最大値, 最小値, 二乗平均和, エントロピー, 四分位範囲, 4 次の Burg 自己回帰モデルの係数, 最小値と最大値の範囲, 二乗平均平方根, 周波数信号の歪度, 周波数信号の尖度, 最大周波数成分, 周波数信号の加重平均, 周波数帯域のスペクトルエネルギー, パワースペクトル密度) を採用する。

3.2.3 機械学習

ここでは, 上記の特徴量抽出パートで, 算出された時系列信号を入力として, 場所ラベル, 行動ラベルをそれぞれ出力する機械学習モデルを構築する。本研究では, 代表的な 9 種類の機械学習アルゴリズム (Support Vec-

tor Machine (SVM), Artificial Neural Network (ANN), Random Forest (RF), Decision Tree (DT), LightGBM, Logistic Regression (LR), K-Nearest Neighbor (KNN), Naive Bayes (NB), Extra-Trees (ET)) の認識精度を比較し, 最終的な提案システムに組み込む機械学習アルゴリズムを決定する。

また, ライフログでは数秒単位の情報記録は必要ないため, 機械学習アルゴリズムによって推定された場所と行動に対して, 一定のサンプル数毎に多数決処理を行う。次章では, 多数決を取る際のサンプル数 (1 サンプル: 1.24 秒分のデータ) の違いによる精度の比較を示す。

表 3 実験シナリオ

場所	主な行動	滞在時間
研究室 1	座る・立つ・歩く	5 分
研究室 2	座る・立つ・歩く	5 分
研究室 3	座る・立つ・歩く	5 分
研究室 4	座る・立つ・歩く	5 分
研究室 5	座る・立つ・歩く	5 分
9 階廊下	立つ・歩く	移動に要する時間
エレベータ	立つ	移動に要する時間
4 階廊下	立つ・歩く	移動に要する時間
階段	階段を下りる	移動に要する時間
1 階廊下	立つ・歩く	移動に要する時間
ミーティングルーム	座る)	5 分
1 階廊下	立つ・歩く	移動に要する時間
コンビニ	立つ・歩く	5 分
外	座る・立つ・歩く	5 分
1 階廊下	立つ・歩く	移動に要する時間
階段	階段を上る	移動に要する時間
4 階廊下	立つ・歩く	移動に要する時間
エレベータ	立つ	移動に要する時間
9 階廊下	歩く	移動に要する時間
トイレ	立つ	5 分
9 階廊下	歩く	移動に要する時間



図 8 実験の様子

4. 評価

本章では、提案手法評価のためのデータ収集方法とその実験環境について述べた後、以下の4つの項目について評価を行う。

- 多数決サンプル数のスケールング
- 先行研究との比較
- 被験者非依存モデルによる汎化性の評価
- 性能限界の調査

以下の節では、10分割交差検証(10-fold CV)を用いて被験者依存(PD: Person Dependent)モデルの評価を行い、Leave-One-User-Out 交差検証(LOUO CV)を用いて被験者非依存(PI: Person Independent)モデルの評価を行う。また評価指標としてはf値の重み付き平均を用いる。

4.1 データ収集方法と実験環境

EH素子として太陽電池を採用しているため、外光の影響は必ず考えるべきである。そのため異なる天気(晴れ・曇り・雨)と日付(6日間)で被験者11名に対してデータ収集実験を行った。実用性を保証するために、大学内で一日の内に訪れる可能性のある場所と行動をリストアップし、それら14箇所を網羅するシナリオを考えた。実験シナリオを表3に示す。表の上から下に向けて滞在と移動を繰り返す。被験者は従来の手法と比較するために名札センサ、加速度センサ、照度センサを同時に装着してシナリオに沿った生活を行う。

様々な行動のデータを取るために、被験者の行動を指定する場所も存在する。例えば研究室では座って作業し、4階から1階までは階段を降りる動作をする。まとめると、様々な光環境で、14の場所と5つの行動(座る、立つ、歩く、階段を上る、階段を下りる)に関するデータを被験者11名、計11時間分収集した。データ収集実験の様子を図8に示す。

収集したデータに対して、予測値と真値の比較のため、手でその場所と行動のラベル付けを行った。ライフログ




図 9 多数決サンプル数を変化させた際の推定精度比較

としては細かい位置ではなく、どの場所に滞在したかが重要な情報であるため、研究室1~5と各階の廊下のラベルはまとめる。行動に関しては、一日の内どれだけ運動したか、が重要であるため、静的(座る、立つ)な行動と動的(歩く、階段を上る、階段を下りる)な行動の2つにまとめる。

4.2 多数決サンプル数のスケールング

最適な多数決サンプル数を決定するために、複数の多数決サンプル数で推定を行い、PDモデルで評価を行う。機械学習アルゴリズムは平均精度が最も高いものを選択し、場所推定にはLightGBMを、行動推定にはSVMを使用した。それぞれのサンプル数における場所と行動の推定精度の平均を図9に示す。

多数決サンプル数20の場合が最も精度がよく、多数決を取らない場合(サンプル数1)に比べて精度が約2%向上した。この結果から得られたサンプル数20を以下の評価で使用する。

4.3 先行研究との比較

先行研究[7],[8]や従来の加速度センサ(acc)、照度センサ(ill)を用いた手法と比較するために、研究室と廊下のラベルをまとめた8つの場所推定と、静的/動的行動の分類を行う。評価には前節と同様にPDモデルを使用する。




図 10 それぞれの手法における場所・行動の推定精度

もっとも精度が高い機械学習アルゴリズムを選択した際の結果を図 10 に示す。アンダーパーがついたモデルは、使用したデータを表しており、sc1 は色素増感太陽電池の発電量、sc2 はアモルファス太陽電池の発電量、sr はサンプリングレート、acc は加速度センサ、ill は照度センサを意味する。例えば、propose_sc1 は色素増感太陽電池発電量データのみから作成したモデルであり、その他のピエゾ素子等のデータは使用しない。sensor_all は加速度センサと照度センサのデータから作成したモデルである。各機械学習アルゴリズムのハイパーパラメータの調整は特に行わず既定の値を使用した。

場所推定においては、提案手法が加速度センサと照度センサを組み合わせたモデルに次いで精度が高く、87.3%の精度を達成した。これは先行研究 [7], [8] と同等の精度であり、より厳しい条件下でも場所推定が可能であることが示された。また、ほとんどの場合で LightGBM の精度が一番高いという結果となった。これは PD モデルのため、過学習が原因の一つとして考えられる。

行動認識は、ピエゾ素子のみを使用したモデルが加速度センサを用いたモデルに次いで、高い 93.2%の精度を達成した。また、太陽電池の発電量のみを用いたモデル (propose_sc1, propose_sc2) でも二値分類であれば十分な精度を達成できることが確認された。これは Sandhu ら [17] が述べている通り、人間の行動時に影が生まれ、発電量が変化するためであるが、太陽電池を胸部に装着した名札センサでも、行動認識が可能であることが示された。

4.4 被験者非依存モデルによる汎化性の評価

モデルの被験者による汎化性を確かめるために、PI モデルを用いて評価を行う。PD モデルと PI モデルによって得られた混同行列を図 11 に示す。

どちらのモデルでも、行動の分類は高い精度が出ている一方、PI モデルでは、PD モデルに比べてトイレ (toilet) の推定精度が著しく低い。これは、トイレは光源の数が少なく立ち位置によって発電量が大きく変わるから、ということが考えられる。

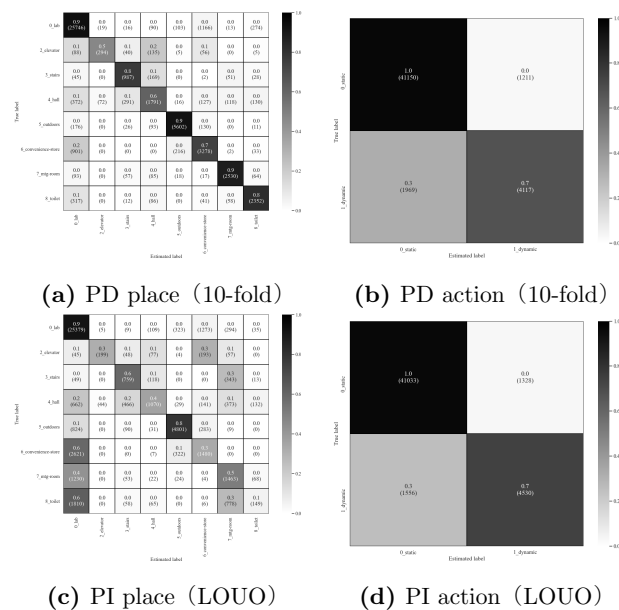


図 11 PD モデルと PI モデルの混同行列

表 4 各分類対象に対する交差検証の結果

分類対象	PD (10-fold CV)	PI (LOUO CV)
8 つの場所	0.873 (LightGBM)	0.728 (LR)
動的/静的行動	0.932 (LightGBM)	0.943 (LightGBM)
14 の場所	0.832 (LightGBM)	0.497 (LR)
5 つの行動	0.821 (LightGBM)	0.728 (SVM)

4.5 性能限界の調査

提案システムの性能限界を調査するために、細分化されたラベルで 14 の場所推定と、5 つの行動認識を行った。それぞれの交差検証の結果を表 4 にまとめる。

PI モデルでの 14 の場所推定精度は、まとめた 8 つに比べて約 32%減少した。図 12 に LOUO CV によって得られた 14 の場所推定の混同行列を示す。研究室 (lab) 間と廊下 (hall) 間の推定精度が著しく低いことから、提案システムでは、同一部屋内の細かな位置の推定や類似した光環境の場所推定には、原理通り、不向きであることが示された。5 つの行動認識に関しても、歩く動作と階段の昇降動作の誤認識が多く、より細かい行動認識をするには、ピエゾ素子取り付け位置等を考え直す必要があることがわかった。

5. 結論と今後の展望

本稿では、前提案デバイスの問題点を解決する手法を提案し、さまざまな被験者により実用的な環境でデータ収集実験を行い、システムの性能を評価した。実験では、実用性と汎化性を評価するために、大学内で訪れる可能性がある 14 の場所を網羅するシナリオを考え、被験者 11 名分、計 11 時間のデータを取得した。14 の場所を 8 つの場所にまとめたラベルでの場所推定は、被験者依存モデルで f 値の重みつき平均 87.3%の精度、静的/動的行動の分類は 93.2%の精度を達成した。

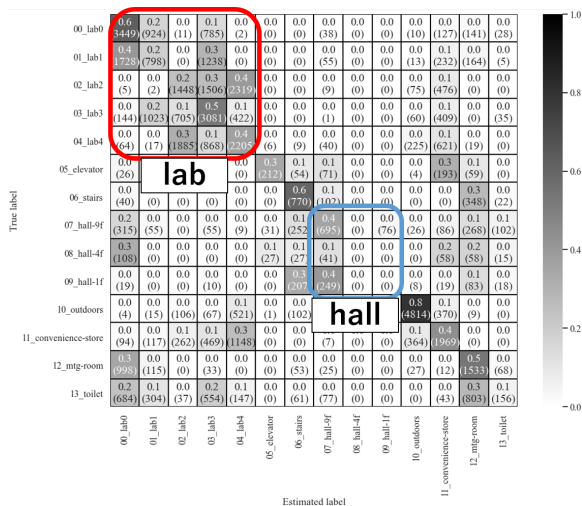


図 12 14 の場所推定における混同行列

今後の展望として、一次電池利用率の定量的測定が挙げられる。一次電池の使用を最小限に抑える機構を提案したが、システムが動作の間どれだけ一次電池に頼っているかが不明瞭である。提案システムが充電なしで、半永久的に動作することを実証するために、一次電池使用率の定量的測定が求められる。

謝辞 本研究の一部は、JSPS 科研費 JP18H03233 および JP19H05665 の支援を受けて実施したものである。

参考文献

[1] Daneshmandi, H., Choobineh, A., Ghaem, H. and Karimi, M.: Adverse effects of prolonged sitting behavior on the general health of office workers, *Journal of lifestyle medicine*, Vol. 7, No. 2, p. 69 (2017).

[2] Shariat, A., Lam, E. T., Kargarfard, M., Tamrin, S. and Danaee, M.: The application of a feasible exercise training program in the office setting, *Work*, Vol. 56, No. 3, pp. 421–428 (2017).

[3] Zou, H., Jin, M., Jiang, H., Xie, L. and Spanos, C. J.: WinIPS: WiFi-based non-intrusive indoor positioning system with online radio map construction and adaptation, *IEEE Transactions on Wireless Communications*, Vol. 16, No. 12, pp. 8118–8130 (2017).

[4] Röbesaat, J., Zhang, P., Abdelaal, M. and Theel, O.: An improved BLE indoor localization with Kalman-based fusion: An experimental study, *Sensors*, Vol. 17, No. 5, p. 951 (2017).

[5] Ishida, S., Takashima, Y., Tagashira, S. and Fukuda, A.: Proposal of separate channel fingerprinting using Bluetooth Low Energy, *2016 5th IIAI International Congress on Advanced Applied Informatics (IIAI-AAI)*, Kumamoto, Japan, IEEE, pp. 230–233 (2016).

[6] Ishida, S., Takaki, S., Yamamoto, T., Tagashira, S. and Fukuda, A.: Evaluation of BLE separate channel fingerprinting in practical environment, *2018 7th International Congress on Advanced Applied Informatics (IIAI-AAI)*, IEEE, pp. 121–124 (2018).

[7] 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 Com-*

munications (PerCom, IEEE, pp. 1–10 (2019).

[8] 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).

[9] Lan, G., Khalifa, S., Hassan, M. and Hu, W.: Estimating calorie expenditure from output voltage of piezoelectric energy harvester: an experimental feasibility study, *Proceedings of the 10th EAI International Conference on Body Area Networks*, pp. 179–185 (2015).

[10] Khalifa, S., Lan, G., Hassan, M., Seneviratne, A. and Das, S. K.: Harke: Human activity recognition from kinetic energy harvesting data in wearable devices, *IEEE Transactions on Mobile Computing*, Vol. 17, No. 6, pp. 1353–1368 (2017).

[11] Lan, G., Ma, D., Xu, W., Hassan, M. and Hu, W.: CapSense: Capacitor-based activity sensing for kinetic energy harvesting powered wearable devices, *Proceedings of the 14th EAI International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services*, pp. 106–115 (2017).

[12] Lan, G., Ma, D., Xu, W., Hassan, M. and Hu, W.: Capacitor-based activity sensing for kinetic-powered wearable iots, *ACM Transactions on Internet of Things*, Vol. 1, No. 1, pp. 1–26 (2020).

[13] Ma, D., Lan, G., Xu, W., Hassan, M. and Hu, W.: SEHS: Simultaneous energy harvesting and sensing using piezoelectric energy harvester, *2018 IEEE/ACM Third International Conference on Internet-of-Things Design and Implementation (IoTDI)*, IEEE, pp. 201–212 (2018).

[14] Ma, D., Lan, G., Xu, W., Hassan, M. and Hu, W.: Simultaneous energy harvesting and gait recognition using piezoelectric energy harvester, *IEEE Transactions on Mobile Computing* (2020).

[15] Aziz, A. A., Ginting, L., Setiawan, D., Park, J. H., Tran, N. M., Yeon, G. Y., Kim, D. I. and Choi, K. W.: Battery-less location tracking for Internet of Things: Simultaneous wireless power transfer and positioning, *IEEE Internet of Things Journal*, Vol. 6, No. 5, pp. 9147–9164 (2019).

[16] Sandhu, M. M., Geissdoerfer, K., Khalifa, S., Jurdak, R., Portmann, M. and Kusy, B.: Towards optimal kinetic energy harvesting for the batteryless iot, *2020 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)*, IEEE, pp. 1–6 (2020).

[17] Sandhu, M. M., Khalifa, S., Geissdoerfer, K., Jurdak, R. and Portmann, M.: SolAR: Energy Positive Human Activity Recognition using Solar Cells, *2021 IEEE International Conference on Pervasive Computing and Communications (PerCom)*, pp. 1–10 (2021).

[18] Ma, D., Lan, G., Hassan, M., Hu, W. and Das, S. K.: Sensing, computing, and communications for energy harvesting IoTs: A survey, *IEEE Communications Surveys & Tutorials*, Vol. 22, No. 2, pp. 1222–1250 (2019).

[19] Torigoe, Y., Nakamura, Y., Fujimoto, M., Arakawa, Y. and Yasumoto, K.: Strike Activity Detection and Recognition Using Inertial Measurement Unit towards Kendo Skill Improvement Support System, *Sensors and Materials*, Vol. 32, No. 2, pp. 651–673 (2020).

[20] Nakamura, Y., Matsuda, Y., Arakawa, Y. and Yasumoto, K.: WaistonBelt X: A Belt-Type Wearable Device with Sensing and Intervention Toward Health Behavior Change, *Sensors*, Vol. 19, No. 20, p. 4600 (2019).