

博士論文

コンタクトレス宅内行動認識のための ドップラーセンシングシステムの研究

三崎 慎也

奈良先端科学技術大学院大学
先端科学技術研究科
情報理工学プログラム

主指導教員: 安本 慶一
ユビキタスコンピューティングシステム研究室 (情報科学領域)

2024年1月30日提出

本論文は奈良先端科学技術大学院大学先端科学技術研究科に
博士(工学)授与の要件として提出した博士論文である。

三崎 慎也

審査委員：

主査 安本 慶一 (情報科学領域 教授)
岡田 実 (情報科学領域 教授)
藤本 まなと (大阪公立大学 大学院情報学研究科 准教授)

コンタクトレス宅内行動認識のための ドップラーセンシングシステムの研究*

三崎 慎也

内容梗概

近年、センシング技術の発展に伴い、省エネ家電制御等の日常生活をサポートする様々なサービスの実現が期待されている。このようなサービスを実現するには、多種多様な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。そのため、多数のセンサ設置により高くなるコスト（課題 1）、読書のような場所に依存しない行動の認識（課題 2）、デバイス装着による負担（課題 3）、カメラ使用によるプライバシーの侵害（課題 4）といった課題への対応が不可欠である。本研究では、これらの課題を解決するため、検出距離が長い(10m程度)、ドップラーセンサを使用した生活行動認識手法の実現を目的とする。具体的には、ドップラーセンサから得られたセンサデータから周波数特性を取得し、特徴量を抽出することによって生活行動を認識する。初めにドップラーセンサによってどの程度行動認識が行えるか評価するため、机以外の家具がない環境において数名の被験者に対して、複数のドップラーセンサを被験者からの距離が一定になるよう設置し実験を行った。その結果、1セッション除外の交差検証でランダムフォレストの平均認識精度が、81.0%となり、被験者の行動を高い精度で認識できた。しかし、動きが大きい行動に信号の増幅率を合わせると、一部の細かい手の動きを取得しづらいうことが分かった。そこで、出力された信号を3つの異なる増幅率によって増幅する増幅器を開発した。この改良を行った後、被験者5人に対して、実際の家庭環境に近い奈良先端科学技術大学院大学スマートホームのリビングルームで実験を行った。実験では、被験者がリビングルームの異なる位置に設置された

*奈良先端科学技術大学院大学 先端科学技術研究科 博士論文, 2024年1月30日.

テーブルとソファで行動したデータを取得し、位置と行動を認識できるかを評価した。また、提案システムの最適化と比較を行うため、場所と行動の組み合わせを各機械学習モデルによって直接推定する手法、場所と行動を別々に認識するモデルを組み合わせる手法、センサ数を削減した場合の認識精度を評価・比較した。その結果、場所と行動の組を直接推定する手法では、1被験者除外の交差検証でロジスティック回帰が最も高く66.0%となり、別々に推定し組み合わせる手法では、59.4%となった。センサ数を削減した場合、被験者の横2箇所とソファ近く1箇所、天井1箇所の4箇所のセンサのデータを使用したロジスティック回帰が65.3%となった。これらの結果より、提案した手法によって、実際の家庭に近い環境で、コンタクトレスで位置を含めた生活行動認識をある程度の精度で行えることが分かった。

キーワード

宅内生活行動認識, 動体検知センサ, ドップラーセンサ, 増幅回路, 機械学習

Doppler sensing system for contactless in-home activity recognition*

Shinya Misaki

Abstract

The recent advancements in sensing technology have opened up the possibilities for various services that support daily life, such as energy-saving home appliance control. To realize such services, accurate and cost-effective daily activity recognition in a wide range is essential. To actualize such a system, it is imperative to address the following challenges: the acquisition of sensors entails very high costs (Issue 1), it is hard to achieve precise recognition for location-independent activities like reading a book (Issue 2), a burden of wearing devices from the perspective of residents (Issue 3), and the preservation of residents' privacy is compromised by using image data from the camera (Issue 4). In this thesis, we propose a method for recognizing daily activities utilizing a Doppler sensor in a relatively longer detection range than other motion detection sensors that can be used for dynamic objects. First, we evaluated the degree to which Doppler sensors can be used for activity recognition. We conducted an experiment with several participants in an environment with no furniture other than a desk, and several Doppler sensors were placed at a constant distance from the participants. The results showed that the average recognition accuracy of the random forests was 81.0% in the one-session-out cross-validation, indicating that the system was able to recognize the participants' activities. However, when the signal amplification was adjusted to activities with large movements, it was found to be difficult to acquire some small

*Doctoral Dissertation, Graduate School of Science and Technology, Nara Institute of Science and Technology, January 30, 2024.

movements. Therefore, we developed an amplifier that amplifies the output signal by three different amplification levels. After making these improvements, we conducted an experiment with five participants in the living room of a smart home at Nara Institute of Science and Technology (NAIST), which is similar to an actual environment. We assess the proposed system from the following three comparisons: optimizing and comparing the recognition accuracy by different machine learning models and cross-validation methods, evaluating the effectiveness of ensemble methods, and examining the impact of sensor reduction on recognition accuracy. In the first comparison, the logistic regression achieved the highest accuracy of 65.99% in the leave-one-person-out cross-validation. The second comparison revealed an accuracy of 59.39% for the parallel activity recognition method and 57.24% for the location estimation activity recognition method. In the third comparison, logistic regression achieved a recognition accuracy of 65.26% when four sensor nodes were used: two sensors were placed on both sides of a participant, another was diagonally behind the participant, and the other was installed on the ceiling.

Keywords:

Activity of daily living recognition, motion detection sensors, doppler sensors, amplifier circuits, machine learning

目次

1. 序論	1
2. 関連研究	4
2.1 既存行動認識システムの解決すべき課題	4
2.2 タグレス行動認識	5
2.3 電波を利用した行動認識	6
2.4 ウェアラブルデバイスを使用した行動認識	6
2.5 カメラを使用した行動認識	7
2.6 本研究の位置づけ	8
3. ドップラーセンサの動作原理	9
4. 屋内環境におけるドップラーセンサを使用した非接触型行動認識手法の提案	11
4.1 ドップラーセンサ出力信号測定システム	11
4.1.1 出力信号増幅回路	11
4.1.2 出力信号測定システム	12
4.2 生活行動認識手法	13
4.2.1 データセットの収集	13
4.2.2 特徴量の抽出	13
4.2.3 行動学習モデルの構築	14
4.3 事前実験	15
4.3.1 対象行動	15
4.3.2 事前実験結果	17
4.4 考察	19
5. 宅内行動認識のためのドップラーセンシングシステムの開発	22
5.1 新たな出力信号増幅回路の開発	22
5.2 生活行動の認識手法	23

5.2.1	データセットの収集	23
5.2.2	特徴量の抽出	25
5.2.3	行動学習モデルの構築	26
5.3	アンサンブル手法	27
5.3.1	並列行動認識手法	27
5.3.2	位置推定行動認識手法	28
5.4	評価実験	29
5.4.1	センサ設置	29
5.4.2	対象行動の設定	31
5.4.3	実験目的	32
5.4.4	各機械学習モデルと各交差検証法の認識精度の比較	32
5.4.5	並列行動認識手法	33
5.4.6	場所推定行動認識手法	36
5.4.7	センサ削減による認識精度の変化	36
5.5	考察	40
6.	考察	43
6.1	結果のまとめ	43
6.2	課題と将来の展望	44
7.	結論	47
	謝辞	48
	参考文献	49
	研究業績	54

図目次

1	動きと角度の違いによる出力信号の変化	10
2	動きと角度の違いによる周波数特性の変化	10
3	増幅回路の概要図	12
4	測定システム概要図	12
5	増幅回路の概要図	14
6	実験概要図	16
7	各被験者ごとの行動認識精度	17
8	各行動ごとの認識精度 (リーブワンセッションアウト)	18
9	Person6 の混同行列	19
10	各分類器ごとの行動認識精度 (リーブワンパーソンアウト)	20
11	各行動ごとの認識精度 (リーブワンパーソンアウト)	20
12	ロジスティック回帰の混同行列	21
13	新規に開発した増幅回路	23
14	新規に開発した増幅回路の概要図	24
15	行動別スペクトログラム	26
16	STFT を用いた特徴量抽出概要図	27
17	並列行動認識手法の概要図	28
18	位置推定行動認識手法の概要図	29
19	センサ設置の概要図	30
20	各分類器ごとの行動認識精度 (リーブワンセッションアウト)	34
21	各行動ごとの行動認識精度 (リーブワンセッションアウト)	34
22	各分類器ごとの行動認識精度 (リーブワンパーソンアウト)	35
23	各行動ごとの行動認識精度 (リーブワンパーソンアウト)	35
24	並列行動認識手法の混同行列 (CNN)	37
25	テーブル行動, ソファ行動認識モデルの混同行列 (CNN)	37
26	位置推定行動認識手法の混同行列 (CNN)	38
27	位置, テーブル行動, ソファ行動認識モデルの混同行列 (CNN)	39
28	S.2,4,5,8 の混同行列 (LR)	41

29	S_2,4,8 の混同行列 (LR)	41
30	部屋移動のスペクトログラム	45

表目次

1	提案手法と関連研究の比較	8
2	特徴量抽出関数	15
3	変更した特徴量抽出関数	24
4	被験者ごとの平均行動認識精度の比較	33
5	各アンサンブル手法の行動認識精度の比較	36
6	センサデータの組み合わせによる認識精度の比較	40

1. 序論

センサ技術の進展に伴い、小型軽量で装着負担の小さいウェアラブルデバイスや環境発電で動作するセンサが普及したことにより、人の行動認識をおこなう研究が多く行われている。ユビキタスコンピューティングの研究分野で主に研究されてきた屋内コンテキスト情報は、ユーザの場所や行動、ドアの開閉、使用電力による家電操作等の情報である。そして、これらの屋内コンテキスト情報の認識によるQoLの向上を目的とした居住者の生活をサポートするサービスや高齢者の見守りシステムの実現等、幅広い分野への応用が期待される。そのため、居住者の多種多様な生活行動を安価かつ正確に認識する必要がある。これまでに、宅内における生活行動認識に関する研究は多数提案されている。例えば、中川ら [1, 2] の手法では、超音波高精度屋内位置測位システムの位置情報と家電製品の消費電力情報を特徴量として使用した、機械学習による行動認識手法を提案している。柏本ら [3] は、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提案している。これらの手法では、調理やテレビ視聴などの生活行動については、79.40%と高精度な認識を実現している。しかし、これらの手法では、多数のセンサを設置する必要があるため、コストがかかり（課題1）、さらに、読書やスマートフォン操作などのような一部の生活行動の認識については、28.00%と低精度であるという結果が報告されている。これは読書やスマートフォン操作などの生活行動はどの場所でも行え、かつ読書は文章を読めるだけの光量があれば電力を消費せず、スマートフォン操作ではバッテリーの電力のみを使用した場合などに家庭の電力を消費しないためである。そのことから居住者の位置情報や家電製品の消費電力のみでは、これらの行動（場所非依存行動）を検出・認識することが困難である（課題2）。多種多様な生活行動を認識するには、居住者の位置情報や家電製品の消費電力情報とは異なる、新たな情報を特徴量として使用することが必要と考えられる。課題2を解決するためのアプローチの1つとして、生活行動のモーションを利用する手法が考えられる。Baoらは、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、この手法では、ユーザは多数のセンサを装着する必要があるため、負担が非常に大きい（課題3）。また、

Uddin ら [4] は、カメラを使用した画像処理に基づいた、スマートホームにおける生活行動認識手法を提案しており、5つの行動を96.50%の精度で認識できることが報告されている。しかし、カメラを用いた手法は、居住者に対して「監視されている」という不安感やデータが外部に漏洩する恐れがあり、プライバシー上の懸念がある（課題4）。

本研究では、課題1から課題4を解決する生活行動認識手法の実現を目的とする。特に課題3を解決するには、部屋の床や壁に設置できるセンサである必要がある（要件1）。また、課題4を解決するには、人の動きのみを検知するセンサである必要がある（要件2）。本研究では、動体検知センサの中でも、検出距離が比較的長い（10m程度）ドップラーセンサから得られる、ドップラー信号から生活行動を認識する手法を提案する。ドップラーセンサは、対象物の移動速度によって生じる送信波と受信波の位相差に対応する周波数を出力するセンサであり、このセンサの特性を活用し、ドップラーセンサが出力する信号の生波形と周波数成分を取得することで、食事や読書などの生活行動によって生じるモーションの違いを捕捉する。細かな動きを非接触で取得できることからマイクロ行動認識やジェスチャー認識の研究 [5, 6] の他にも遠隔で心拍を取得する研究も行われており [7, 8]、本研究が対象とする生活行動認識を実現できる可能性が高いと考えられる。センサの出力信号を一定時間間隔に区切り、生波形とFFTから得られた周波数特性から、生活行動の関連研究 [9] で有効と示された特徴量を算出・利用し、機械学習モデルを構築して認識する。さらに、一定時間間隔に区切られたセンサの出力信号にSTFT (Short-Time Fourier Transform) を適用することによって時間成分を含んだ周波数特性を示すヒートマップを生成し、それを特徴量としてCNN (Convolutional Neural Network) モデルを学習し、認識を行う。

ドップラーセンサを使用した行動認識手法を評価するため、スマートホームにて評価実験を行った。評価実験では被験者の縦、横、斜め、上方向の9か所にセンサを設置し、被験者5名 (Person1-5) はテーブルとソファのそれぞれに着座姿勢でスマートフォン操作、PC操作、読書、食事、部屋移動の5つの行動を各5分間行った。部屋に誰もいない状態も同じように5分間計測した。これらのテーブルとソファで行われた同じ行動を別の行動であるとして、誰もいない状態を含め

た計 11 種類の行動の識別を行う。被験者ごとの行動認識モデルを 1 セッション除外の交差検証 (leave-one-session-out cross-validation) と 1 パーソン除外の交差検証 (leave-one-person-out cross-validation) によって評価し、それらの認識精度 (F 値) の平均を認識精度とする。提案システムの最適化と比較を行うため各機械学習モデルと交差検証法の認識精度の比較とアンサンブル手法の評価、センサ削減による認識精度の変化の 3 つを評価した。具体的には、1 つ目は最適な機械学習アルゴリズムと交差検証手法を選択するため、すべてのセンサノードを使用し、1 サンプルの時間間隔を 6 秒に設定し、特徴量を抽出して認識精度を比較した。2 つ目のアンサンブル手法は、認識精度を向上させる試みとしてテーブル行動認識モデル (テーブルで行われた行動とそれ以外を識別するモデル) とソファ行動認識モデル (ソファで行われた行動とそれ以外を識別するモデル) を組合わせた手法 (並列行動認識手法と呼ぶ)、位置推定モデル (行われた行動がテーブルかソファかそれ以外かを識別するモデル) にテーブル行動認識モデルとソファ行動認識モデルを組合わせた手法 (場所推定行動認識手法と呼ぶ) の認識精度を比較した。3 つ目は実環境での使用も考え、設置コストを下げるためにセンサ数を減らした時の認識精度を比較した。

実験の結果、1 つ目の比較ではユーザ毎に行う 1 セッション除外の交差検証では Person3 の CNN が最大平均認識精度 76.30% を達成し、すべてのユーザの平均認識精度はランダムフォレストが最も高く 64.20% となった。また 1 パーソン除外の交差検証では、ロジスティック回帰が最も高く 65.99% となった。2 つ目の比較では並列行動認識手法では 59.39%、場所推定行動認識手法では 57.24% となり、精度の向上は見られなかった。3 つ目の比較では被験者の横方向 2 箇所に設置したセンサとソファ近くの 1 箇所に設置したセンサ、天井 1 箇所に設置したセンサの 4 つのセンサのデータを使用した時に、ロジスティック回帰が最大平均精度 65.26% と、すべてのセンサを使用した場合の結果 (65.99%) に近い結果を達成した。

2. 関連研究

本章では本研究に関連する既存研究について述べる．はじめに既存行動認識システムから考えられる解決すべき課題について述べ，次に既存研究であるタグレス行動認識手法 [10, 11, 1, 2, 12] や電波を利用した行動認識手法 [13, 14, 15, 16, 17, 18, 19]，ウェアラブルデバイスを利用した行動認識手法 [20, 21, 22, 23]，カメラを利用した行動認識手法 [4, 24, 25] について説明する．最後に提案するシステムを既存のセンシングシステムと比較することで，本研究の位置づけを明らかにする．

2.1 既存行動認識システムの解決すべき課題

本節では，ドップラーセンサを使用した行動認識システムを実現するために，解決すべき課題を示す．第1章で述べたように屋内コンテキスト情報の認識による QoL の向上を目的とした居住者の生活をサポートするサービスや高齢者の見守りシステムの実現のため，居住者の多種多様な生活行動を認識するシステムは数多く提案されている．しかし，これらのシステムには課題が残されている．以下に第1章で述べた本研究で解決すべき課題を述べる．

要件 (i) 設置コストが低い

要件 (ii) 場所非依存行動の高精度な認識が可能

要件 (iii) センサを身体に装着することによる負担がない

要件 (iv) 身体的特徴が分かるようなプライバシーの侵害がない

以下では，本研究の位置づけを明確にするため，カメラやセンサを使用した行動認識の既存研究を調査し，これらの課題を解決できているかを検討する．

2.2 タグレス行動認識

家にドアセンサや温度センサ、消費電力計などを設置することで、屋内で行われる行動から変化した環境データによって行動認識を行う手法が提案されている [10, 11, 1, 2, 12]. Kasteren ら [10] 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設置されたスマートホームにおいて、食事、テレビ視聴、外出、トイレ、シャワー、洗濯、着替えなどの日常生活行動を認識するシステムを提案している。この提案手法の認識精度は49%から98%である。この提案手法では多数の行動を認識することができるが、多くのセンサが必要であるため導入コストが高く、行動の種類によっては認識精度が低いという問題がある。

Chen ら [16] は、近接センサ、人感センサ、チルトセンサ、圧力センサ等が設置されたスマートホームにおいて、お茶やコーヒーを入れる、パスタを作る、テレビを見る、入浴する、手を洗う、などといった複雑な生活行動を90%以上の精度で認識するシステムを提案している。これは、知識ベースのオントロジーにより生活行動を認識しているため、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を持つ。一方、この手法は多種多様なセンサを用いているため、導入コストが高いという問題がある。

Luo ら [11] は、複数個の焦電型赤外線センサを部屋の天井に設置し、歩行、起立、着座などの5種類の行動を認識する手法を提案している。しかし、これらの手法では、歩行や着座、脚振りなど、抽象的な行動を認識することができるが、居住者の生活をサポートするサービスを実現させるために重要な食事や読書など、より具体的な生活行動を認識することができず、設置するセンサの量も多くなる。

中川ら [1] は超音波超音波高精度屋内位置測位システムが使用可能な家に消費電力計を設置し、位置情報と消費電力を特徴量として行動認識を行い、10種類の行動(料理、皿洗い、入浴、読書、風呂掃除、ゲーム、スマホ操作、洗濯、個人衛生、何もしない)を79.70%の精度で認識した。しかし、この認識手法では、家電もしくは電力を消費する行動であれば精度は高くなるがそれ以外の行動は精度が低くなってしまうため、読書やスマートフォン操作などの電力を消費しない行動の認識精度が低くなるという問題がある。

2.3 電波を利用した行動認識

RFID や WiFi などの電波から得られる波形の周波数特性を使用し、行動認識を行う手法が多数提案されている [13, 14, 15, 16, 17]. Wang ら [18] は、1つのアクセスポイントと少数の静的な WiFi デバイスを使用し、デバイスフリーでリビングから Bathroom への移動や書斎からリビングへの移動などの8つの部屋間移動や料理や皿洗い、勉強など9つの日常生活行動を96%で検出可能である. Feng ら [19] は、WiFi を使用し、誤警報の少ない、モーション検出システムの構築した. この研究ではオフィス内で市販の赤外線センサとの評価実験を行っており、赤外線のセキュリティシステムでは検出精度が86.80%だったのに対し、WiDetect では99.68%の精度で堅守が可能となっている. しかし、WiFi を使用したシステムではWiFi を使用できる環境が整っており、それに対応したデバイスを準備する必要がある.

Yanwen ら [18] は、RFID を使用し、行動認識のための非接触反射モデルを構築した. ダイナミックタイムワーピング (DTW) アルゴリズムを使用して位相波形の類似性を定量化し、特徴量を抽出することで8つの行動(立つ, 座る, 手を上げる, 手をさげる, 転ぶ, 歩く, 回る, 起き上がる)を93.50%の精度で認識を可能にしている. Kellogg ら [26] はエネルギーハーベストによって駆動するRFID タグを使用し、スマートフォンなどのデバイスでFlick や Push などの8つのジェスチャーを取得し、平均で97.00%の精度で認識可能なシステムを構築している. しかし、RFID を使用したシステムではRFID タグが必要となるためデバイスフリー行動認識が行えず、装着負担を与えてしまう.

2.4 ウェアラブルデバイスを使用した行動認識

腕や足などの体の一部にウェアラブルデバイスを装着することで行動認識を行う手法が多数提案されている [21, 20, 22, 23]. Bao ら [21] は、被験者として20人にウェアラブル加速度センサを左腕, 右手首, 腰, 左大腿部, 右足首の計5か所に装着し、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. 機械学習アルゴリズムとしてディシジョンツリーを使用した結果, 84.00%

での認識を達成している。

Espinilla ら [22] は、被験者としてアルスター大学の 141 人の学生に右手首、左手首に三軸加速度センサを装着させ、6 種類のシナリオの認識するモデルを構築している。加速度センサはサンプリング周波数は 51.2Hz で収集し、Time-window を 4s に設定し、それぞれの軸の出力信号の平均、最大値、などの 27 種類の特徴量を抽出している。学習アルゴリズムはナイーブベイズ、k 近傍法、決定木、多層パーセプトロン、サポートベクターマシンを採用し、10-Fold 交差検証によって評価を行っている。この結果、k 近傍法を用いたが最も精度が高く、93.70%での認識を達成している。

Olivel ら [23] は 3 軸加速度センサ、ジャイロセンサ、地磁気センサを腕に、耳にはマイクを装着した、ダイエットのための自動食事モニタリングシステムを提案している。腕に装着したセンサでは食事を持っていくジェスチャーを取得し、耳に装着したマイクでは咀嚼を検知することによって被験者が現在何を食べているのかまで判断することが可能であり、食事という行動以外の詳細な認識を行うことが可能となっている。

Augustinov ら [27] は、スマートフォン、スマートウォッチ、スマートグラスのデータセットから歯磨きや部屋の掃除などの活動を 73.4%の精度で認識を達成している。

しかし、これらのウェアラブルデバイスを用いた行動認識手法では、多くのウェアラブルデバイスを身体に装着する必要があるため、被験者に装着負担を与えてしまうという問題がある。

2.5 カメラを使用した行動認識

代表的な行動認識の手法として、カメラを用いた行動認識手法が多数提案されている [4, 24, 25]。カメラを用いた行動認識手法では、画像処理を用いてカメラで録画した映像を解析し、スマートホーム内におけるユーザの行動を認識する。Uddin ら [4] は、カメラを使用した画像処理に基づいた、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。コンピュータシミュレータを使用し、深度カメラの情報を利用し、5つの行動を 96.50%の精度で認識できる。

表 1: 提案手法と関連研究の比較

要件	Nakagawa [1]	Kellogg [26]	Augustinov [27]	Devanne [28]	Our proposed
要件 (i)		✓	✓		✓
要件 (ii)		✓	✓	✓	✓
要件 (iii)	✓			✓	✓
要件 (iv)	✓	✓	✓		✓

Pirsiavash ら [25] は一人称カメラ画像を用いた行動認識を提案している。被験者 20 人にスポーツイベントなどでの装着デバイスとして開発された GoPro を胸部付近に装着させデータ収集を行い、18 種類の宅内行動を認識するモデルを構築している。この手法では ImageNet と呼ばれる多くの画像が収録されたデータセットおよび実験時に収集された画像を使用して、動画中の物体を認識している。そして動画中に登場する物体とその時に行われている行動ラベルを紐づけることで学習モデルを構築しており、物体の認識が完璧にできていると仮定すると 77.00% の精度で認識が可能となっている。

Devanne ら [28] は、RGBD カメラ画像を用いて、人の動きと人の手の周りの奥行きを分析することにより、物を拾う、掃除などの行動を 80.9% の精度で認識を達成している。しかし、これらの手法では、居住者のプライバシーを侵害する恐れがある。

2.6 本研究の位置づけ


表 1 に行動認識の各手法の解決されている課題の比較を示す。この表から既存研究の手法では一部課題は解決できているが、すべての要件を満たすことが可能な手法は提案されていないことが分かる。そこで我々の研究ではこれらの課題を解決することができるシステムの構築を目指す。

3. ドップラーセンサの動作原理

本手法ではドップラーセンサに着目する。ドップラーセンサは、あるエリア内への人物等の侵入や移動を検知する非接触型センサである。ドップラーセンサは送信波を出力し、対象に当たり返ってきた反射波を受信し、送信波と反射波の位相差をドップラー信号として出力する。

この仕組みを利用し、マイクロ行動認識やジェスチャー認識の研究 [5, 6] や呼吸や心拍の変化による体表面の変化を取得することによって非接触でバイタルデータを取得する研究も行われている [7, 8, 29]。Lien ら [5] が行った研究ではドップラーセンサを使用し、4つのジェスチャーを92.10%の精度で認識している。Bhalla ら [6] が行った研究ではドップラーセンサから合成開口レーダーデータを収集し、アジマス-レンジ-ドップラーアルゴリズムを使用して連続データを解析することによってヒートマップを作成し、CNNによって歩行や飲む動作などの10個の日常生活行動を69.37%の精度で認識している。Yamamoto ら [7] が行った研究では、体表面の心拍による変化をドップラーセンサによって取得し、CNNとLSTMを使用して心電図(ECG信号)を再構成する研究を行っており、相関関数を0.86まで上げ、遠隔で心電図信号を再構成することが可能であることを示している。このように出力される信号を解析することにより細かな日常生活行動の他に体表面の微弱な変化も取得できる。また、周波数にも特徴があり、対象の移動速度に比例している。

図1と図2に人物の動作速度の違い、被験者の向きの違いによるドップラーセンサの出力信号および周波数特性の変化を示す。図1(a), 図2(a)は人物が緩やかに動いたときの出力信号であり、図1(b), 図2(b)は人物が素早く動いたときの出力信号である。これらの図が示すように、人物の動作が早い場合、ドップラーセンサの出力信号は急峻な変化を示す。一方、人物が緩やかに動作を行った場合、センサの出力信号は緩やかな変化を示す。さらに、同じ行動であってもその行動を行う角度によって周波数特性が変化する。図2(c)は45度右を向いた状態で速く行動を行った時の出力信号の周波数特性である。図に示すように角度を変えて同じ行動を取得すると出力される周波数は変化する。ここでドップラーセンサの出力周波数を f_d とし、対象の速度を v 、送信周波数を f_0 、センサから見た行動の




(a) 緩やかな動き-正面

(b) 素早い動き-正面

(c) 素早い動き-45°

図 1: 動きと角度の違いによる出力信号の変化



(a) 緩やかな動き-正面

(b) 素早い動き-正面

(c) 素早い動き-45°

図 2: 動きと角度の違いによる周波数特性の変化

方向の角度を θ 、光速を c とすると、 f_d は以下の式によって求めることができる。

$$f_d = \frac{2vf_0 \cos \theta}{c} \quad (1)$$

式 1 より、ドップラーセンサは対象の速度に比例した周波数の信号を出力することがわかる。

4. 屋内環境におけるドップラーセンサを使用した非接触型行動認識手法の提案

本章では，ドップラーセンサから得られる信号を解析して人物のモーションの違いを捉えることで，生活行動認識するシステムの提案を行い，実装して評価を行う．次節以降，ドップラーセンサ出力信号測定システムとドップラーセンサから得られる特徴量出力，その特徴量を用いた生活行動認識モデルの構築，実装したシステムを用いた評価実験，その結果と考察について述べる．

4.1 ドップラーセンサ出力信号測定システム

本研究では，ドップラーセンサから得られる信号を解析し，人物のモーションの違いを捉えることで，生活行動認識を実現する．次節以降，ドップラーセンサの出力信号の増幅回路，測定システム，特徴量抽出，生活行動認識モデルの構築について述べる．

4.1.1 出力信号増幅回路

本研究では，ドップラーセンサから出力される微小な信号を増幅するため，増幅回路の開発を行った．図3に開発した増幅回路と構成図を示す．はじめに，増幅回路で使用するオペアンプをNJM4556Mとした．このオペアンプはヘッドフォンの増幅器としても使用されており，入力換算雑音電圧が $10\text{ nV}/\sqrt{\text{Hz}}$ と低いため，ドップラーセンサの出力信号にノイズを印加せずに増幅できる．さらに，抵抗の熱雑音もノイズに関係していることも考えられるため，バイアス回路や増幅回路，ローパスフィルタで使用している抵抗値も低くし，それに合わせてコンデンサの容量を調整した．電源部は測定用のマイコンによって，充電される5V/3.3V出力付きリチウムイオン電池充電器を使用し，給電を行う．これはマイコン側の電源特性で処理を行うと，電力量が一時的に下がってしまい，低周波ノイズが直流成分に混じり，ノイズとなって現れるためである．したがって，電源によるノイズを抑えるため，バッテリー出力とした．

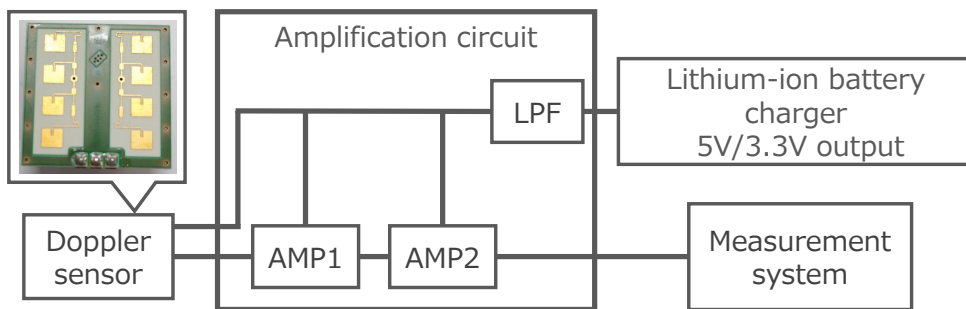


図 3: 増幅回路の概要図

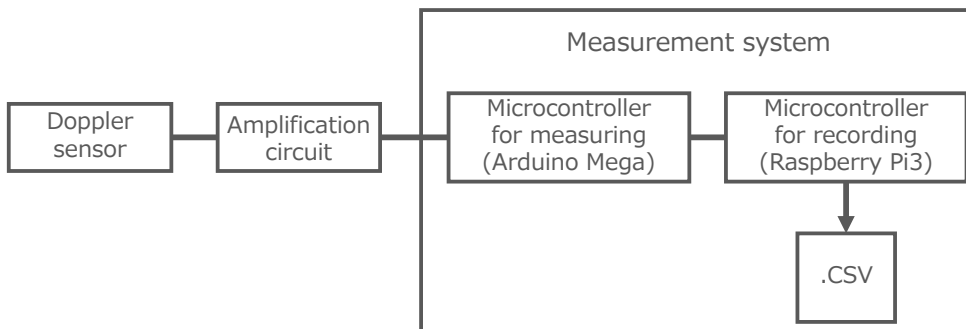


図 4: 測定システム概要図

4.1.2 出力信号測定システム

3章で述べたようにドップラーセンサから出力される信号の周波数は、式1から求めることが可能である。今回使用するドップラーセンサの送信周波数 f_0 は 24GHz であり、 $\cos \theta$ を 1 とするとドップラー周波数 f_d は以下のようなになる。

$$f_d = 160v \quad (2)$$

式2のように、センサの前で 1 m/s の速度で行動を行うと 160 Hz が出力される。そのため、分解能の高いシステムで信号を取得することにより、様々な行動を取得可能であることが考えられる。しかし、Raspberry Pi3 にはアナログ入力はなく、

AD コンバータである MCP3008 を使用した場合，サンプリング周期を 2ms 以下に下げることができなかった．そこで本研究では測定用マイコンとして Arduino Mega を使用する．Arduino Mega は，Raspberry Pi3 にはない，アナログ入力があり，クロック周波数も 16 MHz と十分な処理能力を有している．図 4 に測定システムの概要図を示す．これにより，計測と記録を別々のマイコンが行い，サンプリング周期を 1 ms にまで短くし，計測を行うことで，動きの速い行動であっても取得できるようにしている．

4.2 生活行動認識手法

生活行動の認識手法について述べる．生活行動認識は，トレーニングデータ取得，特徴量抽出，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．

4.2.1 データセットの収集

機械学習を行うにあたって，あらかじめ各区間のセンサデータがどの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．本研究では，4.1.2 項に示すドップラーセンサによる測定システムを使用し，式の $\cos\theta$ によるドップラー周波数の変化を防ぐため，位置と身体の向きを固定し，測定を行った．サンプリングレートは，1 kHz にすることで，動作速度の速い行動に対しても特徴を抽出できる．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．

4.2.2 特徴量の抽出

取得したデータより，対象の行動として設定した 6 つの行動を認識するため特徴量を抽出する．図 5 に特徴量抽出手法の概要図を示す．まずセンサから得られたデータを Time-window ごとに分割する．Time-window は経験的に 10 秒に設定している．次に，各 Time-window 区間ごとに特徴量を抽出する．各 Time-window 区間




図 5: 増幅回路の概要図

に出力された生波形から周波数特性を得るため FFT (Fast Fourier transform) を適用し、周波数特性を求めている。表 2 に特徴量抽出関数を示す。これらの関数は、日常行動認識に関する関連研究 [9] から有効性が示されている関数に velocity(s) と maxFreqIndarea(s) を加えたものとなっている。velocity(s) では maxFreqInd(s) で求められた周波数から、式 2 によって速度を求めたものである。maxFreqInd.area(s) では測定可能な周波数帯域を 5 分割し、分割した周波数帯域の中から最大の振幅値を持った周波数を特徴とする。また、センサ値が振り切れるなどによって発生した外れ値の処理として、すべての関数で出力された値から四分位数を計算した。そして、75%以上の値が出力されると出力された値の 75%の値に変換し、25%以下の場合であれば出力された 25%の値に変換している。

4.2.3 行動学習モデルの構築

次に測定を行い、特徴を抽出後、それらを学習データとし機械学習モデルを構築する。本研究では、生活行動認識モデルを構築するため、Python のオープンソー

表 2: 特徴量抽出関数

特徴量抽出関数	説明	式	Type (T: Time, F: Freq.)
mean(s)	Arithmetic mean	$\bar{s} = \frac{1}{N} \sum_{i=1}^N s_i$	T, F
std(s)	Standard deviation	$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (s_i - \bar{s})^2}$	T, F
mad(s)	Median absolute deviation	$\text{median}_i(s_i - \text{median}_j(s_j))$	T, F
max(s)	Largest values in array	$\max_i(s_i)$	T, F
min(s)	Smallest value in array	$\min_i(s_i)$	T, F
energy(s)	Average sum of the square	$\frac{1}{N} \sum_{i=1}^N s_i^2$	T, F
entropy(s)	Signal Entropy	$\sum_{i=1}^N (c_i \log(c_i)), c_i = s_i / \sum_{j=1}^N s_j$	T, F
iqr(s)	Interquartile range	$Q3(s) - Q1(s)$	T, F
autorregresion(s)	4th order Burg Autoregression coefficients	$\text{arburg}(\frac{s - \min(s)}{\max(s) - \min(s)}, 4)$	T
skewness(s)	Frequency signal Skewness	$\sum_{i=1}^N (\frac{s_i - \bar{s}}{\sigma})^3$	F
kurtosis(s)	Frequency signal Kurtosis	$\sum_{i=1}^N (\frac{s_i - \bar{s}}{\sigma})^4$	F
maxFreqInd(s)	1st to 4th Largest frequency component	$\text{argmax}(s)$	F
velocity(s)	Target velocity(using value of 1st to 4th Largest frequency component)	$\text{maxFreqInd} \cdot c / 2f_0 \cos \theta$	F
maxFreqInd_area(s)	Largest frequency component In the specified frequency band	$\text{argmax}_i(s_i)$	F
meanFreq(s)	Frequency signal weighted average	$\sum_{i=1}^N (i s_i) / \sum_{j=1}^N s_j$	F

N : signal vector length, Q : Quartile, T : Time domain features, F : Frequency domain features., s : Sensor data divided for each time window

ス機械学習ライブラリである, Scikit-learn¹を使用し, 行動認識に良く利用されている分類器 (RF: ランダムフォレスト, ANN: 多層パーセプトロン, DT: 決定木, ET: エクストラツリー, NB: 単純ベイズ, LR: ロジスティック回帰, SVM: サポートベクターマシン, KNN: k 近傍法) を使用し, 比較を行っていく.

4.3 事前実験

ドップラーセンサを用いた行動認識手法の性能を評価するため, 図 6 に示すようにセンサを設置し, 事前実験を行った. 以下に事前実験の目的と実験結果について述べる.

4.3.1 対象行動

事前実験には被験者 10 人が参加し, Person1 から Person10 とした. ドップラーセンサを用いた行動認識手法の性能を評価するため, 被験者はシナリオベースで行動を行った. 被験者が行った行動とその説明を以下に示す.

¹Scikit-learn: <https://scikit-learn.org/>

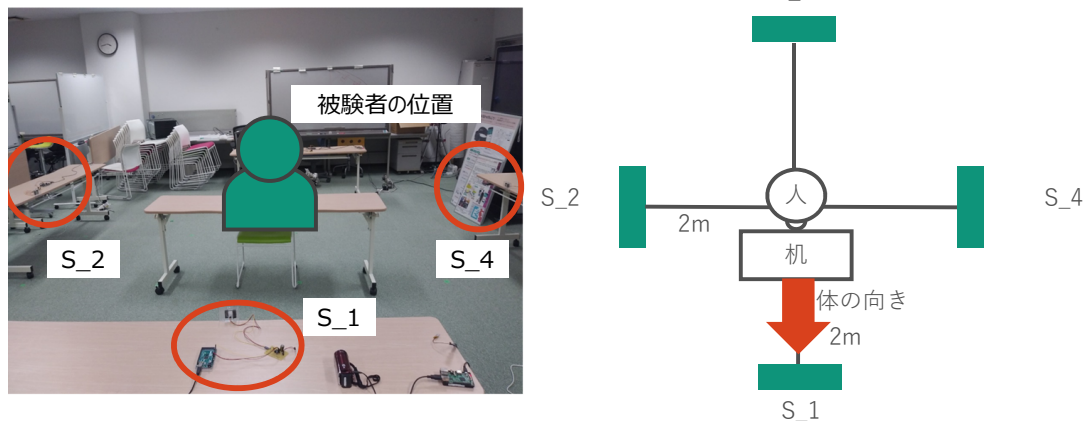


図 6: 実験概要図

食事:

実際の食事のようにテーブルや膝に置いた皿から物を掴み、口に運んで口を動かすまでの行動

PC 操作:

タイピングゲームをプレイし、キーボードをタイピングする行動

読書:

5 秒から 10 秒に 1 回ページをめくる行動

スマートフォン操作:

縦または横に指だけ動かしてスワイプする行動

静止状態:

椅子に座った状態で動かず、静止した状態

書き作業:

本などの文章を紙に書き写す行動

事前実験ではこれらの6行動を60秒でそれぞれ5回ずつ行い、それらのデータを測定して行動認識手法の評価を行った。

4.3.2 事前実験結果

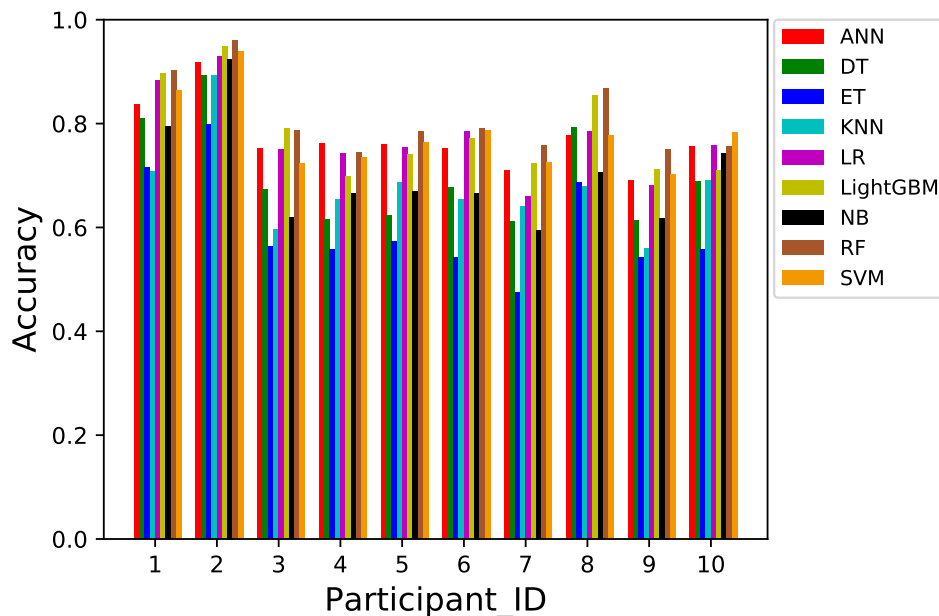


図7: 各被験者ごとの行動認識精度

各被験者ごとに複数の分類器を使用して、構築した識別モデルを1セッション除外の交差検証によって評価した。図7に認識精度を棒グラフで比較したものを、図8にすべての被験者の各行動の平均認識精度を示す。図7に示されるように、すべての被験者において最も認識精度が高くなった分類器はランダムフォレストとなり、その中でPerson2の平均認識精度が最も高く、95.7%となった。また、すべての被験者の認識精度の平均はランダムフォレストが最も高くなり、81.0%となった。図8に示すように、食事行動が最も平均認識精度が高く、ほかの行動は




図 8: 各行動ごとの認識精度（リーブワンセッションアウト）

食事行動よりも低く、同じような認識精度となっている。これは食事行動中は、腕を他の行動と比べて比較的大きく動かしており、センサが被験者の特徴を捉えやすくなったため、認識精度が高くなったと考えられる。図 9 の平均認識精度が最も低かった Person6 の混同行列においては、食事行動の認識精度は非常に高くなっていることが分かる。しかし、食事以外の行動では静止状態を読書行動、スマートフォン、PC 操作と誤認識が多くなっている。これは、食事行動以外は、センサが僅かな腕の動きや指の細かい動きなどを捉えることが難しく、認識精度に影響が出たのではないかと考えられる。

複数の分類器を使用して、構築した認識モデルを 1 パーソン除外の交差検証によって評価した。図 10, 11 に認識精度を棒グラフで比較した結果と各行動ごとの認識率を比較した結果を示す。複数の分類器を比較すると、ロジスティック回帰が最も認識精度が高く、45.3%となり、次に高い認識精度となったのが LightGBM の 43.2%である。1セッション除外の交差検証で評価したときと同様に、食事行動の認識精度が最も高くなり、80.0%以上となったが、食事行動以外の行動は低




図 9: Person6 の混同行列

くなった。図 12 のロジスティック回帰の混同行列では、静止状態をスマートフォン操作や読書と誤認識することが多い。これは食べ物や口を運ぶ動作が被験者によって差がないため認識精度が高く、逆に読書ではページをめくる速度の違いや、スマートフォンをスワイプやタッチなどの操作間隔が被験者によって違うため認識精度が低くなったのではないかと考えられる。

4.4 考察

本実験により、ドップラーセンサを用いた行動認識手法の有効性を実装と評価によって明らかにした。その結果、1セッション除外の交差検証では、すべての被験者の認識精度の平均はランダムフォレストで 81.0% となり、1 パーソン除外の交差検証では、ロジスティック回帰の認識精度が最も高く、45.3% となった。また、行動ごとの認識精度の比較を見ると、食事以外の行動では、静止状態への誤認識が多くなっていることが確認した。静止状態であると、ドップラーセンサの出

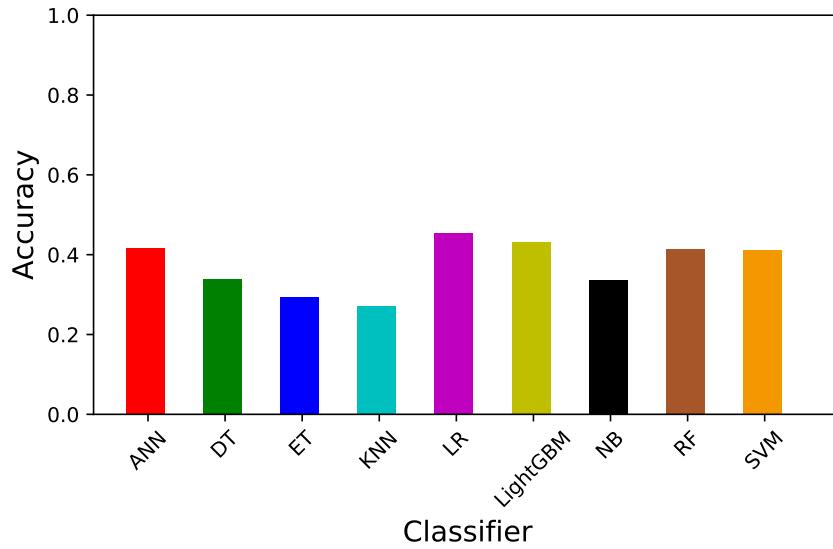


図 10: 各分類器ごとの行動認識精度 (リーブワンパーソンアウト)




図 11: 各行動ごとの認識精度 (リーブワンパーソンアウト)




図 12: ロジスティック回帰の混同行列

力信号に変化がなくなるため、静止状態と誤認識される読書、スマートフォン操作は出力信号の変化が小さいことが考えられる。この課題を解決するためには出力信号増幅回路の増幅器の増幅率を上げる必要がある。しかし、増幅率を上げた場合、食事行動のような腕を大きく動かす行動では測定システムの測定限界値を越してしまい、出力信号を正しく測定できない。このため、動きの大きい行動と動きが小さい行動から測定できるそれぞれの出力信号を最適な増幅率で増幅し、測定可能なシステムが必要となる。

また本実験では、研究室に複数のドップラーセンサを被験者からの距離が一定になるよう設置し、実験を行った。しかし、一般の家庭を想定した場合、被験者からセンサまでの距離は壁や行動をする位置によって変化するため、一般の家庭に近い環境でも評価を行う必要がある。また、本実験ではセンサを被験者の前後左右の4か所設置したが、最適なセンサ設置位置を評価するため、センサの設置数を増やす必要がある。これらの要件を元にシステムの改良を行っていく。

5. 宅内行動認識のためのドップラーセンシングシステムの開発

本章では、4章で提案された行動認識システムの問題点を解決し、より実環境に合わせた生活行動認識をするシステムの実装を行い、評価する。次節以降、出力信号増幅回路の改良と特徴量抽出手法、その特徴量を用いた生活行動認識モデルの構築、実装したシステムを用いた評価実験、その結果と考察について述べる。

5.1 新たな出力信号増幅回路の開発

人の動きをセンシングする際、席を立っての移動など身体全体の動きの大きい行動とスマホ操作など細かい人の動きを伴う行動を共に記録できなくてはならない。さらに壁等に設置する場合、被験者とセンサとの距離が離れ、出力信号が小さくなる、逆に近づいて出力信号が大きくなりすぎることも考えられる。しかしながら、ドップラーセンサーアンプの増幅率を被験者の細かい動きを高分解能で記録できるように高い増幅率に設定すると、大きい動きを被験者が行った際に信号が飽和してしまい、逆に大きい行動に合わせて低い増幅率に設定すると微弱な動きが記録できないという課題があった。

そこで、我々は複数の増幅率をもつ増幅器を開発し、増幅率の異なる信号を記録し共に活用するところで、微弱な信号と振幅の大きな信号の両方を記録活用できる手法を確立した。開発した増幅回路と構成図を図13と図14に示す。この増幅回路は増幅率をLow, Middle, Highと3段階に分けて取り出せるようになっている。これにより、席を立っての移動などの身体全体を使った動きの大きい行動、食事などの腕を使った大きい行動、スマホ操作など指の細かい動きを伴う行動をそれぞれ増幅率の違う信号から取得できるようになる。さらに、より高い増幅率の設定で問題となる、抵抗の熱雑音の影響を低減するため、バイアス回路や増幅回路、ローパスフィルタで使用している抵抗値も低く設定し、それに合わせてコンデンサの容量での調整を行った。電源部は電源配線からのハムノイズなどの混入を防ぐため5V出力のデバイスを使用し電池駆動とした。これにより、増幅器

によるノイズを低減し，壁への設置を行っても被験者の行動を正しく記録することが可能であるため要件を満たすことができる．




図 13: 新規に開発した増幅回路

5.2 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，学習に使用するデータセットの取得，取得したトレーニングデータの特徴量の抽出，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．

5.2.1 データセットの収集

機械学習を行うにあたって，あらかじめ各区間のセンサデータがどの行動に対応するかを示したデータセットが必要である．本研究では，5.1節で新たに開発

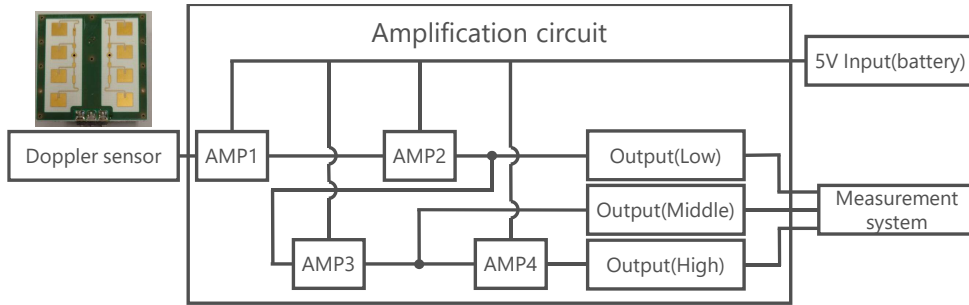


図 14: 新規に開発した増幅回路の概要図

表 3: 変更した特徴量抽出関数

特徴量抽出関数	説明	式	Type (T: Time, F: Freq.)
mean(s)	Arithmetic mean	$\bar{s} = \frac{1}{N} \sum_{i=1}^N s_i$	T, F
std(s)	Standard deviation	$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (s_i - \bar{s})^2}$	T, F
mad(s)	Median absolute deviation	$\text{median}_i(s_i - \text{median}_j(s_j))$	T, F
max(s)	Largest values in array	max(s)	T, F
min(s)	Smallest value in array	min(s)	T, F
energy(s)	Average sum of the square	$\frac{1}{N} \sum_{i=1}^N s_i^2$	T, F
entropy(s)	Signal Entropy	$\sum_{i=1}^N s_i \log_2 s_i$	T, F
iqr(s)	Interquartile range	$Q3(s) - Q1(s)$	T, F
autoregression(s)	4th order Burg Autoregression coefficients	$\text{arburg}(\frac{s - \min(s)}{\max(s) - \min(s)}, 4)$	T
skewness(s)	Frequency signal Skewness	$\sum_{i=1}^N (\frac{s_i - \bar{s}}{\sigma})^3$	F
kurtosis(s)	Frequency signal Kurtosis	$\sum_{i=1}^N \frac{(s_i - \bar{s})^4}{\sigma^4}$	F
maxFreqInd(s)	1st to 4th Largest frequency component	argmax(s)	F
meanFreq(s)	Frequency signal weighted average	$\sum_{i=1}^N (i s_i) / \sum_{j=1}^N s_j$	F

N : signal vector length, Q : Quartile, T : Time domain features, F : Frequency domain features., s : Sensor data divided for each time window

した出力信号増幅回路に、4.1.2項で示した出力信号測定システムを組み合わせた測定システムを使用し、式1の $\cos \theta$ によるドップラー周波数の変化を防ぐため、位置と身体の向きを固定し、対象行動の測定を行った。ま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。

5.2.2 特徴量の抽出

5.1節で述べたように、出力信号増幅回路の改良により、ドップラーセンサから得られた出力信号が3つの異なる増幅器によって増幅され、High, Middle, Lowとして出力されるようになった。そのため、特徴量の抽出手法の変更が必要となる。今回提案する手法では、今回開発した増幅回路によってHigh, Middle, Lowと異なる増幅率によって増幅された信号からそれぞれ特徴量抽出関数によって特徴量を抽出する。これにより、体全体を使った大きい行動では、Highの出力信号が出力信号測定システムの測定値の限界を超えて、正しく測定ができていなかった場合であっても、Lowの出力信号から出力された特徴量によって、逆に指のみの動きの小さい行動でLowの出力信号に全く変化がない場合でも、Highの出力信号がその行動の変化を特徴量として取得し、正しく認識できる。

4章より、表2の特徴量抽出関数は有効であることが示されているが、特徴量として速度を加える手法ではあまり精度の違いがみられなかった。そこで速度を特徴量抽出関数から外し、表3に示すような特徴量抽出関数に変更した。

また、新たな特徴量としてSTFT（短期フーリエ変換）によってスペクトログラムを生成した。図15に短期フーリエ変換によって生成されたスペクトログラムを、図16に短期フーリエ変換による特徴量抽出手法の概要図を示す。図15に示すように出力信号から短期フーリエ変換によって生成されたヒートマップには行動の速さの変化により発生する時間による周波数特性の変化が含まれている。式1に示すドップラーセンサの特性上、行動の変化は周波数特性の変化として出やすく、行動内の動きの速度は同じ行動であっても一定の速度で行動しているわけではなく、時間によって変化している。そのためこのスペクトログラムを特徴量とすることにより、これまでの特徴量抽出関数によって数値として特徴量を出力する手法よりも高精度な行動認識モデルなるのではないかと考えられる。特徴量抽出の方法は、図16に示すように、測定された生波形をTime-windowごとに区切り、STFTを適用し、スペクトログラムを生成する。すべてのセンサノードからのデータでスペクトログラムを生成後、それらを結合し、そのデータを特徴量として使用する。




図 15: 行動別スペクトログラム

5.2.3 行動学習モデルの構築

測定を行い、特徴を抽出後、それらを学習データとし機械学習モデルを構築する。本研究では、生活行動認識モデルを構築するため、Pythonのオープンソース機械学習ライブラリである、Scikit-learn¹とKeras²を使用し、行動認識によく利用されている分類器（RF: ランダムフォレスト, ANN: 多層パーセプトロン, DT: 決定木, ET: エクストラツリー, NB: 単純ベイズ, LR: ロジスティック回帰, SVM: サポートベクターマシン, KNN: k近傍法）を使用し、比較を行っていく。

4.2.3項で述べたように事前実験では複数の分類器を使用し、比較を行った。これに加えてオープンソース機械学習ライブラリKeras²内のCNN（畳み込みニューラルネットワーク）を使用した。この分類器は5.2.2項で述べたスペクトログラムを特徴量として学習する。

また、作成したモデルから出力された予測や確信値を使用し、組み合わせたモデルも作成する。このモデルでは経験からCNN, LightGBM, ランダムフォレストのモデルから出力された結果を2つの手法で組み合わせる。1つ目の手法ではモデルから出力された各行動の確信値をそれぞれの行動ごとに合計し、平均してその中で最も確信値が高かった行動をそのモデルの予測とする(CNN_ML (Comparison))。2つ目の手法ではそれぞれのモデルで予測された行動で多数決をとり、予測を決定

¹Scikit-learn: <https://scikit-learn.org/>

²Keras: <https://keras.io/>

²Keras: <https://keras.io/>

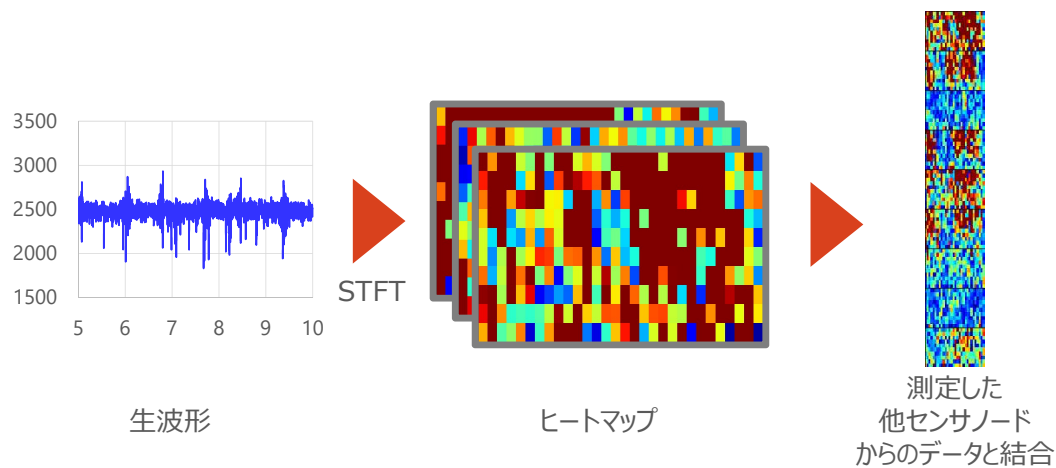


図 16: STFT を用いた特徴量抽出概要図

する (CNN_ML (Majority)). この手法では予測がそれぞれ違った場合, CNN_ML (Comparison) と同じように確信値から予測を決定する. これらの機械学習モデルと組み合わせの手法を用いて比較を行っていく.

5.3 アンサンブル手法

本研究では, 異なる場所で行われた行動を 1 つのモデルで認識すると他の場所での行動と誤認識し, 認識精度が下がることが考えられる. そこでモデルを複数作成し, それらで多数決を行うことで認識精度を高められると考えられる. それらの手法について述べる.

5.3.1 並列行動認識手法

この解析手法では, 異なる場所ごとに認識モデルを作成する. 図 17 に並列行動認識手法の概要図を示す. モデルの対象行動は PC, スマートフォン操作, 読

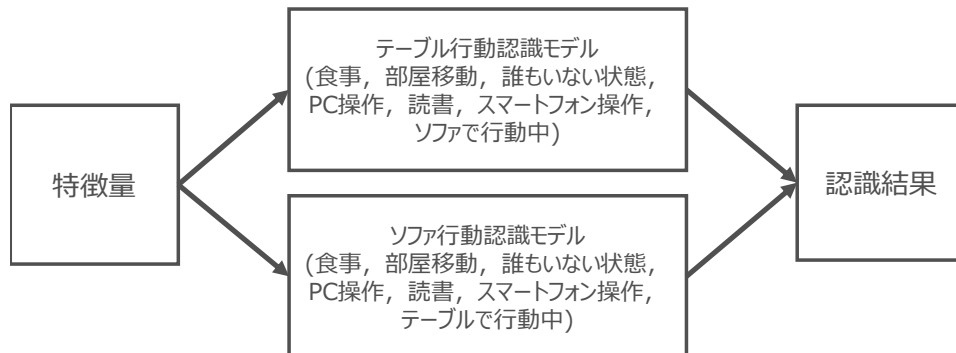


図 17: 並列行動認識手法の概要図

書, 食事, 移動, モデルの担当場所以外, 離席としてテーブルとソファのそれぞれでモデルを作成する. それぞれのモデルから出力された結果から, 片方の行動認識モデルが担当場所以外, 離席と出力された結果であればもう片方の出力結果を最終的な認識の結果とする. また作成したモデルがすべて担当場所以外, 離席と出力していれば離席であるとする. すべてのモデルが PC, スマートフォン操作, 読書, 食事, 移動と出力している場合はモデルの行動の確信値から認識結果とする.

5.3.2 位置推定行動認識手法

この解析手法では, 異なる場所ごとの行動認識モデルの他に位置推定を行うモデルを作成する. 図 18 に位置推定行動認識手法の概要図を示す. 位置推定モデルではテーブル, ソファ, 離席を, 行動認識モデルでは PC, スマートフォン操作, 読書, 食事, 移動を判断する. 最終的な認識の結果は位置推定モデルで場所を決定し, その場所のモデルが判断した結果を出力する. また, 位置推定のモデルが離席と判断した場合は離席を認識結果とする.

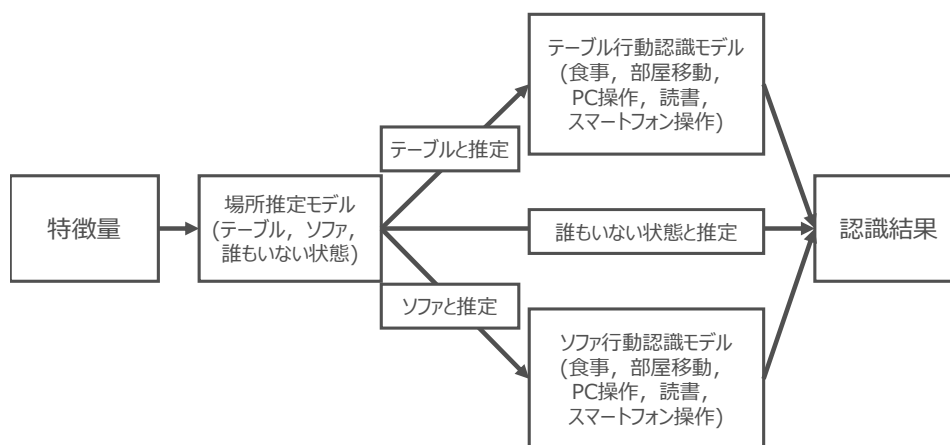


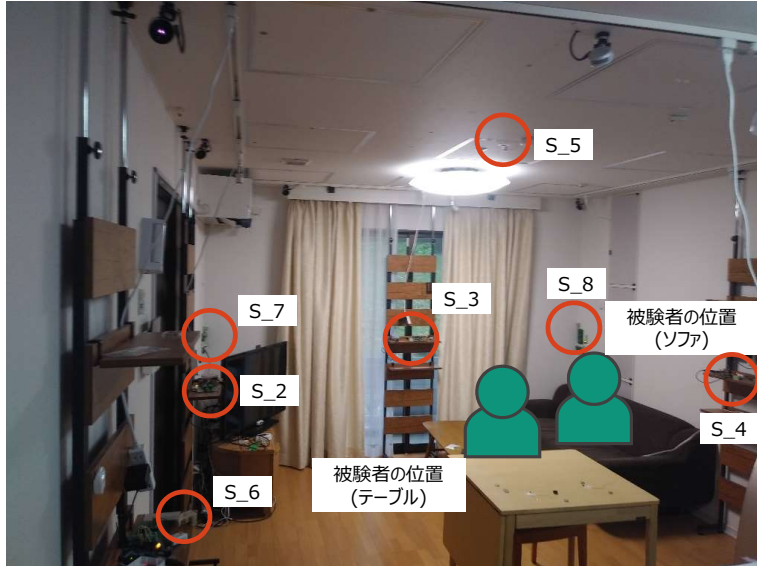
図 18: 位置推定行動認識手法の概要図

5.4 評価実験

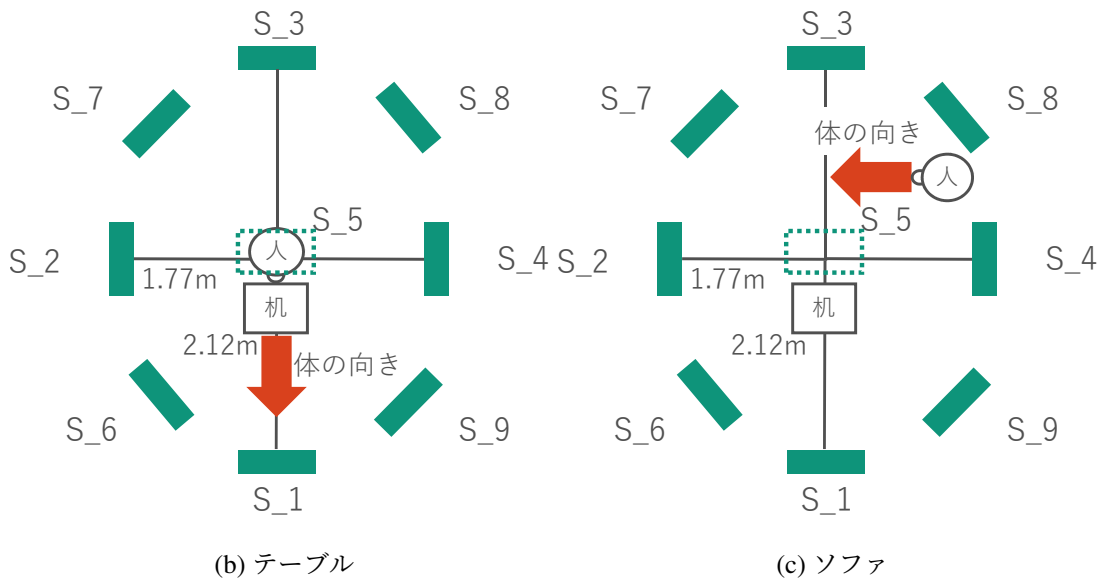
ドップラーセンサを用いた宅内行動認識手法の性能を評価するため、図 19 に示すようにセンサを設置し、評価実験を行った。その後、各機械学習モデルと各交差検証法の認識精度の比較とアンサンブル手法の評価、センサ削減による認識精度の変化を評価した。以下に評価実験の目的と実験結果について述べる。

5.4.1 センサ設置

式 2 で述べたようにドップラーセンサはセンサに向かって行動した場合、160 Hz を出力する。しかし、センサに対して平行に行動した場合、出力周波数は 0 Hz となり、その行動の正しい速度に合わせた周波数は取得できない。そのためセンサに対して平行に動作することがないようにセンサを設置する必要がある。図 19 にセンサの設置図を示す。評価実験では一般的なリビングでの測定のため正面のセンサは被験者から 2.2m、横に設置したセンサは 1.7m 離れた場所に計 4 箇所、それに加え、斜め方向に 4 箇所、天井に 1 箇所、計 9 箇所につ設置する。このように設置することによっていずれかのセンサで必ずその行動特有の出力信号を得



(a) 実際の実験環境



(b) テーブル

(c) ソファ

図 19: センサ設置の概要図

ることができる。このように設置することによっていずれかのセンサで必ずその行動特有の出力信号を得ることができる。

5.4.2 対象行動の設定

本評価実験では、ドップラーセンサを使用した行動認識手法の評価を行うため5人の被験者（Person1から5）にはシナリオベースに行動を行うよう指示した。下記にその行動と内容を示す。

食事:

実際の食事のようにテーブルや膝に置いた皿から物を掴み、口に運んで口を動かすまでの行動

部屋移動:

着座姿勢から立ち上がり、リビングから離れ、また同じ位置に戻り、座る行動

誰もいない状態:

部屋に被験者がいない状態

PC操作:

タイピングゲームをプレイし、キーボードをタイピングする行動

読書:

5秒から10秒に1回ページをめくる行動

スマートフォン操作:

縦または横に指だけ動かしてスワイプする行動

被験者はこれらの誰もいない状態を除いた行動をテーブルとソファの別々で行い、それぞれの場所で行われた同じ行動を別の行動であるとして、11種類の行動の認識を本システムで行い、評価を行う。

5.4.3 実験目的

本実験では、ドップラーセンサを使用して得られたセンサデータから表3の関数を用いて、時間領域と周波数領域の特徴量を抽出し、複数の分類器により、行動認識モデルを構築した。そして、各機械学習モデルと各交差検証法の認識精度の比較とアンサンブル手法の評価、センサ削減による認識精度の変化を評価した。

各機械学習モデルと各交差検証法の認識精度の比較では複数の機械学習モデルの認識精度の他に1セッション除外の交差検証と1パーソン除外の交差検証での比較も行う。1セッション除外の交差検証では、時間や室内環境などが異なるセッションごとにおいても、行動認識が可能かどうかを検証するために行った。1パーソン除外の交差検証では、人間の行動には個人差が存在し、同じ行動であっても動作速度が違ふことが考えられるため、対象となる被験者以外の行動データによって認識が行えるか評価するために行った。アンサンブル手法の評価では、5.3節で述べた手法を用いて解析を行い、すべてのデータを学習したモデルとの認識精度の評価を行う。センサ削減による認識精度の変化の評価では、実環境での使用を考慮し、設置コストを下げるため、センサを減らした場合の組み合わせによる認識精度の評価も行った。

5.4.4 各機械学習モデルと各交差検証法の認識精度の比較

本評価では、ユーザの毎に行う1セッション除外の交差検証と1パーソン除外の交差検証での認識精度の比較と様々な機械学習での認識精度の比較を行っていく。図20と図22に1セッション除外の交差検証と1パーソンアウトの交差検証を行った場合の各機械学習モデルの比較、図21と図23に各交差検証の行動毎の認識精度を示す。1セッションアウトの交差検証ではPerson3の認識精度が最も高く、CNNで76.3%となり、すべての被験者の認識精度の平均ではランダムフォレストが最も高く64.2%となった。また行動ごとに認識精度を比較すると食事行動、部屋移動がテーブル、ソファともに高く、PCや読書、スマホ行動の認識精度は低い。

1パーソン除外の交差検証では、ロジスティック回帰が最も高くなり、66.0%となり、行動ごとに認識精度を見ていくと1セッション除外の交差検証の時と同

表 4: 被験者ごとの平均行動認識精度の比較

分類器	Person_1	Person_2	Person_3	Person_4	Person_5
LightGBM	52.4%	61.5%	68.4%	69.2%	55.3%
RF	52.7%	65.0%	75.3%	67.5%	60.6%
ANN	53.3%	59.8%	67.7%	61.9%	58.3%
DT	42.2%	48.5%	61.5%	62.0%	50.9%
ET	42.2%	50.1%	50.5%	46.6%	43.4%
NB	47.5%	54.8%	64.4%	57.5%	54.7%
LR	53.2%	59.6%	67.7%	64.0%	59.1%
SVM	53.7%	60.9%	69.5%	60.6%	59.1%
KNN	47.8%	53.6%	61.8%	53.1%	51.4%
CNN	52.2%	64.1%	76.3%	62.5%	62.6%
CNN_ML (Comparison)	48.6%	61.2%	68.1%	65.0%	51.1%
CNN_ML (Majority)	48.6%	61.2%	68.1%	65.0%	51.1%

様に食事行動、部屋移動がテーブル、ソファともに高く、PCや読書、スマホ行動の認識精度は低いことが分かった。これは、食事行動や部屋移動などの身体や腕の動きが大きい行動は取得できていたが、細かな動きを取得するには不十分であったことが考えられる。また1パーソン除外の交差検証では、PCや読書、スマホ行動に個人差が大きく出てしまうため認識精度が落ちたことが考えられる。

1セッション除外の交差検証と1パーソン除外の交差検証を比較した結果、1パーソン除外の交差検証が高いことが分かり、機械学習モデルもランダムフォレスト、LightGBM、ロジスティック回帰、CNNが比較的高い認識精度を出しているため次回からの評価ではこれらの交差検証と機械学習モデルを使用する。

5.4.5 並列行動認識手法

本評価では5.3.1節で述べた手法での解析結果の比較を行う。表5にアンサンブル手法の認識精度の比較、図24に並列行動認識手法における各機械学習モデルの混同行列、図25にCNNで作成したテーブルとソファのモデルの混同行列を示す。並列行動認識手法の結果ではCNNが59.4%、ランダムフォレストが54.03%

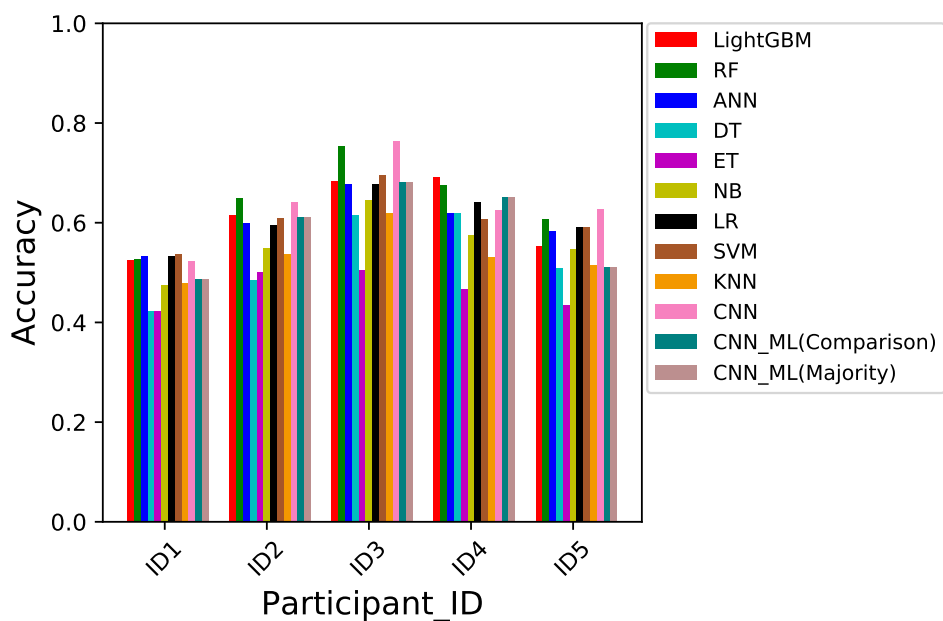


図 20: 各分類器ごとの行動認識精度 (リーブワンセッションアウト)




図 21: 各行動ごとの行動認識精度 (リーブワンセッションアウト)

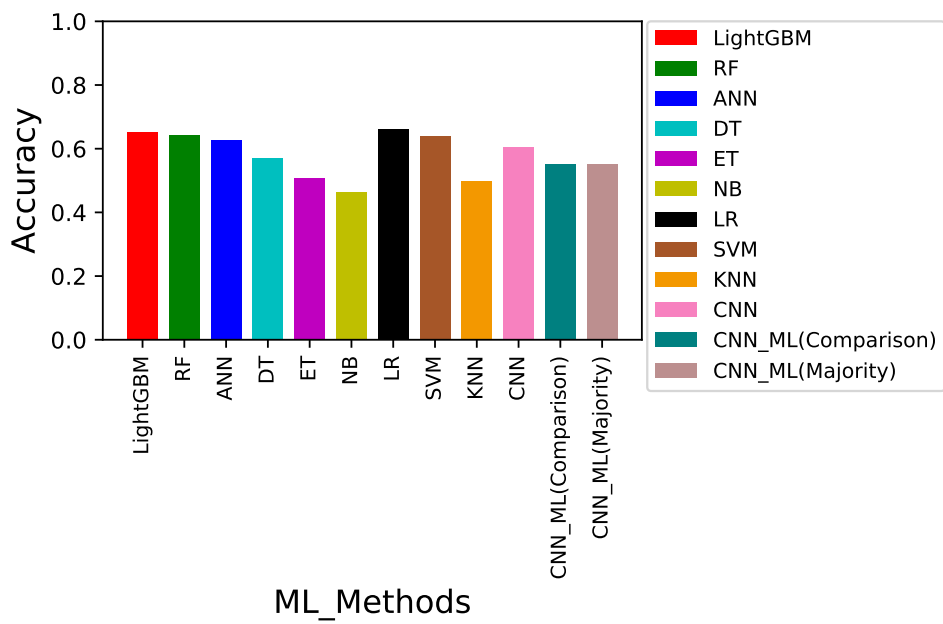


図 22: 各分類器ごとの行動認識精度 (リーブワンパーソンアウト)

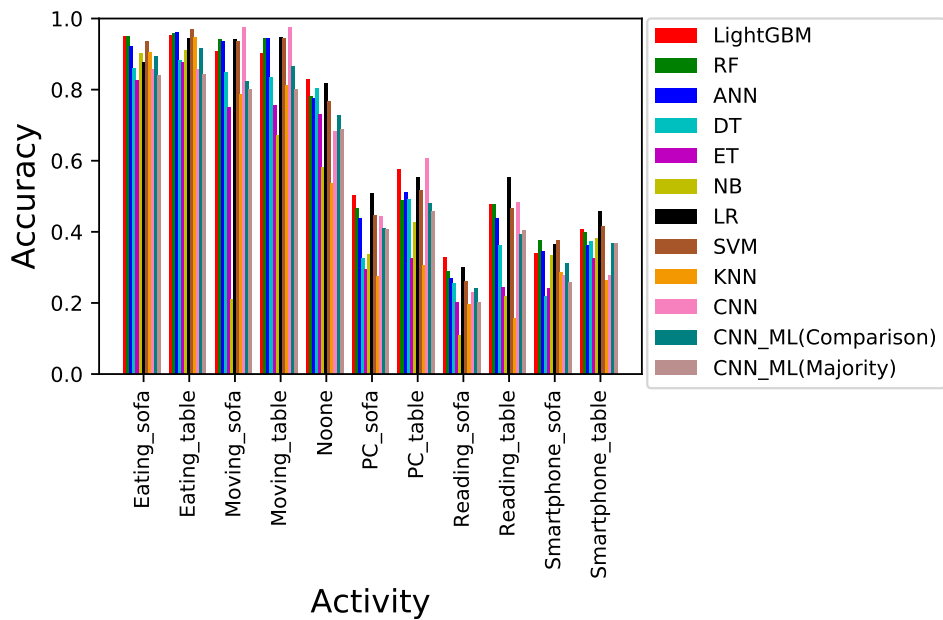


図 23: 各行動ごとの行動認識精度 (リーブワンパーソンアウト)

表 5: 各アンサンブル手法の行動認識精度の比較

分類器	既存手法	並列行動認識手法	位置推定行動認識手法
LightGBM	65.2%	42.8%	50.8%
RF	64.2%	53.7%	52.8%
LR	66.0%	49.9%	55.4%
CNN	60.6%	59.4%	57.2%

となり，作成したテーブル，ソファ専用行動認識モデルでは CNN でテーブルが 69.5%，ソファが 63.1% となった．並列行動認識手法での認識精度は専用認識モデルの認識精度に依存しているが，各専用認識モデルの認識精度があまり高くなり，その結果認識精度が落ちたと考えられる．

5.4.6 場所推定行動認識手法

本評価では 5.3.2 項で述べた手法での解析結果の比較を行う．図 26 に場所推定行動認識手法における各機械学習モデルの混同行列，図 27 に CNN で作成した場所とテーブル，ソファのモデルの混同行列を示す．場所推定行動認識手法の結果では CNN が 57.2%，ロジスティック回帰が 56.7% となり，CNN で作成した場所推定，テーブル，ソファ専用行動認識モデルでは，場所推定が 81.0%，テーブルが 70.2%，ソファが 61.5% となった．場所推定行動認識手法では，場所推定は高い認識精度を持っているが，テーブルとソファの専用行動認識モデルの認識精度があまり高くないため認識精度が落ちたと考えられる．全てのセンサデータを使用した解析ではロジスティック回帰の 66.0% の認識精度であったため 2 つの解析手法では認識精度を上げることは出来なかった．

5.4.7 センサ削減による認識精度の変化

本評価では，実世界での運用も考え設置コストを抑えるためセンサ数を削った組み合わせを比較する．表 6 にセンサの組み合わせごとによる認識精度を，図 28

Ground Truth	Eating_sofa	87	0	0	0	0	3	0	3	0	1	2
	Eating_table	0	89	0	0	0	0	1	0	7	0	0
	Moving_sofa	0	0	96	3	0	0	0	0	0	0	0
	Moving_table	0	0	5	93	0	0	0	0	0	0	0
	Noone	0	0	0	0	78	3	3	3	3	3	3
	PC_sofa	5	0	0	0	5	39	0	20	3	13	11
	PC_table	0	12	0	0	0	0	56	1	9	3	14
	Reading_sofa	8	0	0	0	9	17	0	19	3	25	14
	Reading_table	0	9	0	0	5	2	4	6	46	6	17
	Smartphone_sofa	2	0	0	0	12	15	0	24	4	24	15
	Smartphone_table	0	1	0	0	5	8	13	14	17	13	25
		Predicted Values	Eating_sofa	Eating_table	Moving_sofa	Moving_table	Noone	PC_sofa	PC_table	Reading_sofa	Reading_table	Smartphone_sofa

図 24: 並列行動認識手法の混同行列 (CNN)

Ground Truth	Eating	79	0	0	0	10	8	1
	Moving	0	97	0	2	0	0	0
	Noone	0	0	74	8	0	6	9
	Noone_table	0	0	6	74	0	5	12
	PC	2	0	4	0	68	5	18
	Reading	7	0	4	2	10	52	21
	Smartphone	0	0	6	12	18	22	39
		Predicted Values	Eating	Moving	Noone	Noone_table	PC	Reading

Ground Truth	Eating	84	0	0	0	5	8	2
	Moving	0	98	0	1	0	0	0
	Noone	0	0	68	3	4	10	12
	Noone_sofa	0	1	7	77	3	4	5
	PC	3	0	4	4	47	21	18
	Reading	4	0	5	5	25	26	32
	Smartphone	1	0	4	5	19	33	34
		Predicted Values	Eating	Moving	Noone	Noone_sofa	PC	Reading

(a) Table

(b) Sofa

図 25: テーブル行動, ソファ行動認識モデルの混同行列 (CNN)

Ground Truth	Predicted Values										
	Eating_sofa	Eating_table	Moving_sofa	Moving_table	Noone	PC_sofa	PC_table	Reading_sofa	Reading_table	Smartphone_sofa	Smartphone_table
Eating_sofa	85	0	0	0	0	2	0	6	0	1	2
Eating_table	0	85	0	0	0	0	4	0	9	0	0
Moving_sofa	0	0	97	2	0	0	0	0	0	0	0
Moving_table	0	0	6	93	0	0	0	0	0	0	0
Noone	0	2	0	0	80	2	3	2	3	2	3
PC_sofa	3	0	0	0	12	39	0	19	2	12	8
PC_table	0	12	0	0	2	0	53	0	7	1	20
Reading_sofa	7	0	0	0	25	16	1	16	2	19	11
Reading_table	0	7	0	0	14	1	5	3	46	3	17
Smartphone_sofa	2	0	0	0	29	13	0	17	3	19	13
Smartphone_table	0	1	0	0	20	7	13	8	15	7	25

図 26: 位置推定行動認識手法の混同行列 (CNN)

と図 29 に S_2458 と S_248 の混同行列を示す。前後左右に加えて天井に設置したセンサノードを使用した場合、ロジスティック回帰が最も高く 63.2%，ランダムフォレストが 62.3% となり，斜め方向に天井のセンサノードを加えた場合，ロジスティック回帰が最も高く 62.5%，ランダムフォレストが 59.9% となった。また正面のセンサノードのみを使用した場合，ロジスティック回帰が最も高く 63.9%，LightGBM が 62.1% となり，後方のセンサノードのみを使用した場合，ロジスティック回帰が 64.4%，LightGBM が 62.1% となった。全てのセンサノードを使用した場合と比較すると認識精度は落ちたが S_2,3,5,7,8 が最も認識精度が近くなった。S_1,2,3,4,5 と S_5,6,7,8,9 の組み合わせでは S_1,2,3,4,5 が高くなり，S_1,2,4,5,6,9 と S_2,3,4,5,7,8 の組み合わせでは S_2,3,4,5,7,8 が高くなったことから被験者の横にあるセンサノードが認識精度を上げるために重要であると考えられる。そこでテーブルとソファの場所で被験者の真横に設置されてある S_2,4,5,8 の組み合わせで解析した場合，S_2,3,4,5,7,8 よりも認識精度が高くなり，ロジスティック回帰が 65.3% となった。全てのセンサを設置した場合と比較してもほぼ同じ精度で

Ground Truth	Noone	81	12	6
	sofa	7	83	8
	table	11	9	78
		Noone	sofa	table
		Predicted Values		

(a) 位置推定

Ground Truth	Eating	79	0	11	7	1
	Moving	0	99	0	0	0
	PC	5	0	67	7	19
	Reading	9	0	8	54	26
	Smartphone	0	0	21	27	50
		Eating	Moving	PC	Reading	Smartphone
		Predicted Values				

(b) テーブル

Ground Truth	Eating	86	0	3	7	2
	Moving	0	99	0	0	0
	PC	3	0	50	23	22
	Reading	6	0	27	31	34
	Smartphone	1	0	21	37	39
		Eating	Moving	PC	Reading	Smartphone
		Predicted Values				

(c) ソファ

図 27: 位置, テーブル行動, ソファ行動認識モデルの混同行列 (CNN)

表 6: センサデータの組み合わせによる認識精度の比較

センサの組み合わせ	LightGBM	RF	LR	CNN
S_ALL	65.2%	64.2%	66.0%	60.6%
S_1,2,3,4,5	61.4%	62.3%	63.2%	54.0%
S_5,6,7,8,9	59.9%	58.4%	62.5%	57.3%
S_1,2,4,5,6,9	62.1%	61.3%	63.9%	53.3%
S_2,3,4,5,7,8	62.8%	62.8%	64.4%	58.2%
S_2,4,5,8	63.0%	62.7%	65.3%	57.4%
S_2,4,8	61.8%	61.4%	63.3%	56.4%

認識が可能であることが分かった。また、設置コストを考慮し、天井へ設置しなかった場合も比較するため S_2,4,8 も解析した場合、ロジスティック回帰が 63.3%、LightGBM が 61.8% となった。

5.5 考察

本実験により、学習モデルやアンサンブル手法、認識に必要なセンサノードの組み合わせなどの行動認識に最適なパラメータや手法を実際のシステム実装と多様な評価によって明らかにした。これらの評価には時間や室内環境などが異なるセッションごとにおいても、行動認識が可能かどうかを検証するために 1 セッション除外の交差検証を行い、対象となる被験者以外の行動データによって認識が行えるか評価するために 1 パーソン除外の交差検証を行った。その結果、1 セッション除外の交差検証では、個人では高い精度が出ていたが、被験者の認識精度の平均であると 1 パーソン除外の交差検証の方が高いことが分かった。またテーブル、ソファともに PC や読書、スマホ行動の認識精度が低いことが確認された。これは、実装したシステムが細かな動きを取得するには不十分であったことが考えられる。

5.4.5 項と 5.4.6 項で述べたように、アンサンブル手法では認識精度を向上させ

Ground Truth	Eating_sofa	91	0	0	0	0	2	0	4	0	0	0	
	Eating_table	0	90	0	0	0	0	2	0	4	0	1	
	Moving_sofa	0	0	95	4	0	0	0	0	0	0	0	
	Moving_table	0	0	3	96	0	0	0	0	0	0	0	
	Noone	0	0	0	0	81	0	0	3	3	1	7	
	PC_sofa	0	0	0	0	1	44	0	18	1	20	11	
	PC_table	0	1	0	0	3	2	59	0	20	1	9	
	Reading_sofa	1	0	0	0	1	17	1	27	5	28	16	
	Reading_table	0	2	0	0	1	0	17	3	50	4	18	
	Smartphone_sofa	1	0	0	0	3	20	0	20	4	35	14	
	Smartphone_table	0	0	0	0	4	7	10	10	14	11	40	
		Predicted Values	Eating_sofa	Eating_table	Moving_sofa	Moving_table	Noone	PC_sofa	PC_table	Reading_sofa	Reading_table	Smartphone_sofa	Smartphone_table

図 28: S_2,4,5,8 の混同行列 (LR)

Ground Truth	Eating_sofa	91	0	0	0	0	2	0	4	0	0	0	
	Eating_table	0	90	0	0	0	0	2	0	4	0	1	
	Moving_sofa	0	0	95	4	0	0	0	0	0	0	0	
	Moving_table	0	0	3	96	0	0	0	0	0	0	0	
	Noone	0	0	0	0	81	0	0	3	3	1	7	
	PC_sofa	0	0	0	0	1	44	0	18	1	20	11	
	PC_table	0	1	0	0	3	2	59	0	20	1	9	
	Reading_sofa	1	0	0	0	1	17	1	27	5	28	16	
	Reading_table	0	2	0	0	1	0	17	3	50	4	18	
	Smartphone_sofa	1	0	0	0	3	20	0	20	4	35	14	
	Smartphone_table	0	0	0	0	4	7	10	10	14	11	40	
		Predicted Values	Eating_sofa	Eating_table	Moving_sofa	Moving_table	Noone	PC_sofa	PC_table	Reading_sofa	Reading_table	Smartphone_sofa	Smartphone_table

図 29: S_2,4,8 の混同行列 (LR)

ることができなかった。どちらの手法でも行動認識モデルの認識精度の低さが原因であるとわかっている。しかし、場所推定行動認識手法では”誰もいない状態”を含む位置推定モデルが高い認識精度を出している。本研究では対象場所が2種類、対象行動が5行動であるが、今後対象場所、または対象行動を増やした場合、モデルの認識精度がより低くなることが考えられる。したがって、行動認識精度の向上が行えれば、アンサンブル手法による精度向上もできると考えられたため、今後の研究課題として必要である。

センサ数を減らすことによる認識精度の比較では、S_{2,4,5,8}の組み合わせがすべてのセンサノードを使用した場合の認識精度に最も近くなった。これはこの4つのドップラーセンサが発している電波を身体やデバイスによって防がれにくく、本システムが行動のデータを正しく取得できたためと考えられる。特にPC操作とスマートフォン操作では、ディスプレイ部で正面からの電波を遮断しているため、被験者を上から見下ろすようにセンサを設置することで精度向上をできると考えられる。

6. 考察

本章では全体の考察として、研究室内に作った机以外の家具がなく、センサから被験者までの距離が一定の環境と実際の家庭環境に近い NAIST スマートホームのリビングルームの環境で行った実験に対するまとめ、課題と将来の展望について述べる。

6.1 結果のまとめ

このドップラーセンサから得られる信号を解析して人物のモーションの違いを捉えることで、生活行動認識するシステムを評価するため、出力信号増幅回路や、測定システムを実装し、研究室内に4台のドップラーセンサを被験者の縦と横に距離が一定になるよう設置し、1度目の評価実験を行った。その結果、1セッション除外の交差検証では、すべての被験者の認識精度の平均はランダムフォレストで81.0%となり、1パーソン除外の交差検証では、ロジスティック回帰の認識精度が最も高く、45.3%となった。1セッション除外の交差検証では、高い認識精度を示したが、行動ごとの認識精度の比較を見ると、食事以外の行動では、静止状態への誤認識が多くなっていた。静止状態であると、ドップラーセンサの出力信号に変化がなくなるため、静止状態と誤認識される読書、スマートフォン操作は出力信号の変化が小さいことが考えられる。

この課題を解決するため、動きの大きさに合わせた増幅器を持つ増幅回路の開発した。また、新たな特徴量としてSTFTを用いてヒートマップを作成し、その特徴量を用いたCNNによる行動認識モデルを実装した。このほかに認識精度の向上のためアンサンブル手法として並列行動認識手法と位置推定行動認識手法を提案した。この実装したシステムを評価するため、スマートホームに被験者の縦、横、斜め、天井も含めて9か所に設置し、2度目の評価実験を行った。本評価では、提案システムの最適化と比較を行うため各機械学習モデルと交差検証法の認識精度の比較と2つのアンサンブル手法の評価、センサ削減による認識精度の変化の3つを評価した。その結果、すべてのユーザの平均認識精度はランダムフォレストが最も高く64.2%となった。また1パーソン除外の交差検証では、ロジス

ティック回帰が最も高く 66.0%となった。また並列行動認識手法では 59.4%，位置推定行動認識手法では 57.2%となり，精度向上を行うことはできなかった。センサ数を減らすことによる認識精度の比較では被験者の横に設置したセンサ 2 か所とソファ近くに設置したセンサ 1 か所，天井に設置したセンサ 1 か所の 4 箇所のセンサノードのデータを使用することでロジスティック回帰が 65.3%となり，すべてのセンサを使用した場合の結果である 66.0%に近づいた結果を得ることができた。これらの結果より，提案した手法によって，実際の家庭に近い環境で，コンタクトレスで位置を含めた生活行動認識をある程度の精度で行えることが分かった。

この他に部屋移動時のスペクトログラムの変化を確認した。図 30 に部屋移動時のスペクトログラムを示す。部屋移動のスペクトログラムを見ると部屋へ入室した場合，振幅が大きくなり，スペクトログラム全体が赤くなる。そして椅子に座り動きが止まると振幅が小さくなり青に近くなる。退室時には急激に赤くなった後，振幅が小さくなっていき，また青に近くなっていく。この変化を学習することにより，部屋への入退室，部屋内の移動方向の認識も可能であると考えられる。

6.2 課題と将来の展望

提案した手法にはいくつか課題も存在する。1つ目の課題は，スマートフォン操作や読書などの動きの小さい行動の認識精度向上が挙げられる。出力信号増幅回路の改良を行い，3つの異なる増幅率で出力信号を増幅したが，指の動きをあまり取得できなかった。増幅率が低かったことや体やスマートフォンなどで電波が妨害されたことが考えられるため，出力信号増幅回路の増幅率の設定や設置位置には改善の余地がある。

2つ目の課題は，同時に複数の箇所が動いている行動の認識である。今回開発した増幅回路では，3つの異なる増幅率で体，腕，指の行動を取得し，認識を行ったが，実際の環境では体の動きと指の動きが同時に行われるような複合的な動作や行動があり，今回のシステムでは指の動作を取得する増幅率で体の動きを測定すると信号が飽和し，正しく認識を行うことが難しい。これを解決するためには振幅の大きい信号であっても飽和しにくい測定システムを開発し，体の動作によっ

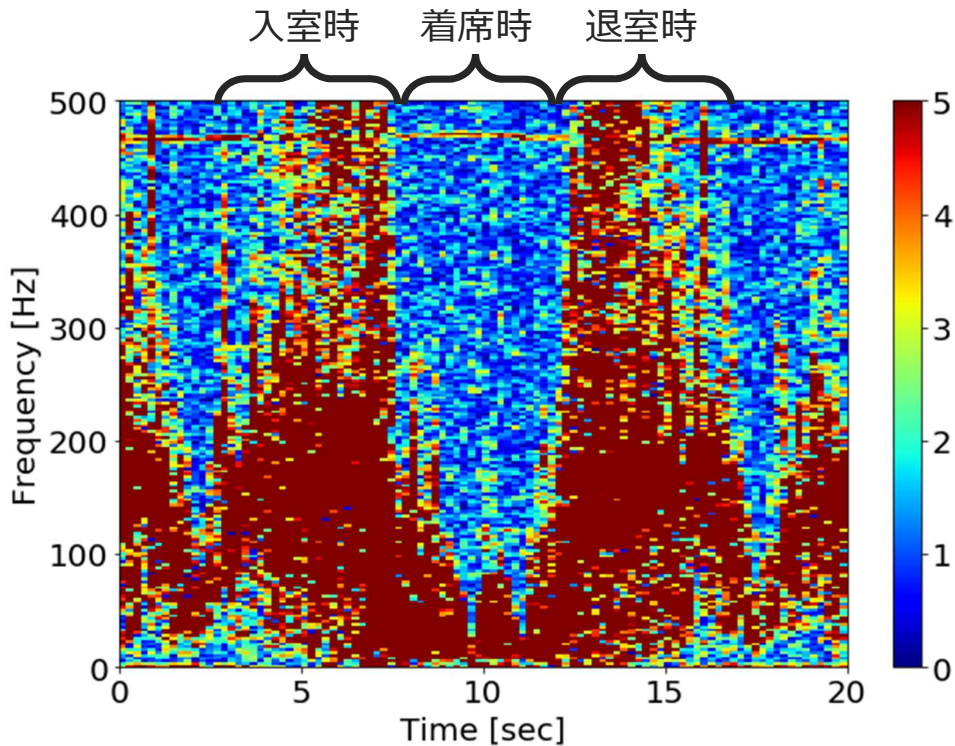


図 30: 部屋移動のスペクトログラム

て出力された信号の中に含まれている指の細かい微弱な動きによって発生した信号を分離して解析を行う，または体の動きを Low の信号から検出した場合，その体の動きと思われる信号の成分を High の方では除去し，行動の認識を行うことが必要である。

また，本システムではいくつかの制約がある．1つ目の制約は，身体の向きである．これは式 1 でもあるように身体の向きが変化すると同じ行動であっても $\cos \theta$ が変化し，出力周波数が変化するため，認識精度が落ちることが考えられる．被験者の身体の向きを認識することによってこれらの変化を予測し，出力された特徴量に補正を行い，認識精度を保つことが考えられる．

2つ目の制約は，対象が 1 人の場合にのみ行動認識が行えることである．実際

の環境で使用するためには複数の認識対象の行動を認識可能なシステムが必要であるが、部屋に複数対象が存在し、同時に行動すると、すべての行動の動きが混ざった信号が出力されるため、正しい認識を行うことが難しい。複数の対象がそれぞれ異なる行動をしていた場合や異なる場所で行動していた場合、出力される信号の振幅の違いや、高い振幅が測定されているドップラーセンサの位置によって、それらの行動、位置を取得できるため、複数の対象によって行われている行動を認識することが考えられる。

今後の展望としては、出力信号増幅回路の最適な増幅率や設置位置を検討し、居住者の行動の向きに依存しない学習の実現など残された課題解決に向けて発展させていく予定である。

7. 結論

本論文では、ドップラーセンサを使用した生活行動認識手法を提案した。既存の行動認識手法は、多数のセンサ設置により高くなるコスト（課題1）、読書のような場所に依存しない行動の認識（課題2）、デバイス装着による負担（課題3）、カメラ使用によるプライバシーの侵害（課題4）といった課題が存在する。これらの課題を全てを解決することを目的とし、提案手法では、動体検知センサの中でも、検出距離が比較的長い（10m程度）ドップラーセンサから得られる、ドップラー信号から生活行動を認識する。4章では、ドップラーセンサによってどの程度行動認識が行えるか評価するため、机以外の家具がない環境において数名の被験者に対して、4台のドップラーセンサを被験者からの距離が一定になるよう設置し、実験を行った。これにより、提案手法の有効性と課題を確認した。5章では、4章で確認した課題を解決するため、動きの大きさに合わせた増幅器を持つ増幅回路の開発した。また、新たな特徴量としてSTFTを用いてヒートマップを作成し、その特徴量を用いたCNNによる行動認識モデルを実装した。このほかに認識精度の向上のためアンサンブル手法として並列行動認識手法と位置推定行動認識手法を提案した。さらに実装したシステムを評価するため、スマートホームに被験者の縦、横、斜め、天井も含めて9か所に設置し、評価実験を行い、実際の家庭に近い環境で、コンタクトレスで位置を含めた生活行動認識をある程度の精度で行えることが分かった。これらの得られた知見が今後の省エネ家電制御等の日常生活をサポートするサービスの実現やドップラーセンサを用いて行われる歩容測定等の研究と組み合わせることによる高齢者見守りを行うサービスなどの実現に役立てることを期待する。

謝辞

本研究を進めるにあたり、安本慶一 教授には、研究全般に関し、多大なるご指導・ご助言を賜りました。また、充実した研究環境の整備など、研究活動を手厚くご支援いただきました。感謝の意を表すとともに、心より厚く御礼申し上げます。

岡田実教授には、ご多忙の中、論文審査委員を引き受けてくださった上で、副指導教官として様々なご助言をいただきました。感謝の意を表すとともに、心より厚く御礼申し上げます。

大阪市立大学 藤本まなと 准教授には、本研究を進めるにあたり、センサの特性解析や電磁波の特性に関する基礎知識、使用するデータの分析をはじめとした専門的な立場からのご指導・ご助言をいただきました。また学生に近い立場から、論文執筆時の基礎や本研究に関するご助言を賜りました。感謝の意を表すとともに、心より厚く御礼申し上げます。

金岡恵 事務補佐員、山内奈緒 事務補佐員には、学会や出張に関する事務処理を始め、研究生生活の様々な場面でご支援いただきましたこと、謹んで感謝申し上げます。

ONKYO の吉田誠様には今回使用した測定システムの増幅回路作成のためのアナログ回路の基礎知識、設計した増幅回路の修正をはじめとした専門的な立場からのご指導・ご助言をいただきました。研究に関する相談にも丁寧に回答していただきました。感謝の意を表すとともに、心より厚く御礼申し上げます。

また研究全般において、的確なアドバイスをくださった諏訪博彦 准教授、松田裕貴 助教授、松井智一 助教授、九州大学中村優吾 助教授、Hyuckjin Choi 助教授を始めとする先輩の皆様、共に研究生生活を過ごしたユビキタスコンピューティングシステム研究室の同輩、後輩には、公私ともにお世話になりました。心より感謝申し上げます。

最後に、今日まで学生生活を様々な面から支えてくださった母を始め、家族に心より感謝申し上げます。

参考文献

- [1] Eri Nakagawa, Kazuki Moriya, Hirohiko Suwa, Manato Fujimoto, Yutaka Arakawa, Toshiyuki Hatta, Shotaro Miwa, and Keiichi Yasumoto. Investigating recognition accuracy improvement by adding user's acceleration data to location and power consumption-based in-home activity recognition system. In *Adjunct Proceedings of the 13th International Conference on Mobile and Ubiquitous Systems: Computing Networking and Services*, MOBIQUITOUS 2016, pp. 100–105. ACM, 2016.
- [2] Eri Nakagawa, Kazuki Moriya, Hirohiko Suwa, Manato Fujimoto, Yutaka Arakawa, and Keiichi Yasumoto. Toward real-time in-home activity recognition using indoor positioning sensor and power meters. In *2017 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)*, pp. 539–544. IEEE, 2017.
- [3] 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. In *Adjunct Proceedings of the 13th International Conference on Mobile and Ubiquitous Systems: Computing Networking and Services*, MOBIQUITOUS 2016, pp. 6–11. ACM, 2016.
- [4] Md. Zia Uddin. A robust daily human activity recognition and prediction system. In *Proceedings of the 2014 International C* Conference on Computer Science & Software Engineering*, C3S2E '14, pp. 12:1–12:8. ACM, 2014.
- [5] Jaime Lien, Nicholas Gillian, M Emre Karagozler, Patrick Amihood, Carsten Schwesig, Erik Olson, Hakim Raja, and Ivan Poupyrev. Soli: Ubiquitous gesture sensing with millimeter wave radar. *ACM Transactions on Graphics (TOG)*, Vol. 35, No. 4, pp. 1–19, 2016.

- [6] Sejal Bhalla, Mayank Goel, and Rushil Khurana. Imu2doppler: Cross-modal domain adaptation for doppler-based activity recognition using imu data. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, Vol. 5, No. 4, pp. 1–20, 2021.
- [7] Kohei Yamamoto, Ryosuke Hiromatsu, and Tomoaki Ohtsuki. Ecg signal reconstruction via doppler sensor by hybrid deep learning model with cnn and lstm. *Ieee access*, Vol. 8, pp. 130551–130560, 2020.
- [8] Wei Hu, Zhangyan Zhao, Yunfeng Wang, Haiying Zhang, and Fujiang Lin. Noncontact accurate measurement of cardiopulmonary activity using a compact quadrature doppler radar sensor. *IEEE Transactions on Biomedical Engineering*, Vol. 61, No. 3, pp. 725–735, 2013.
- [9] Davide Anguita, Alessandro Ghio, Luca Oneto, Xavier Parra, and Jorge Luis Reyes-Ortiz. A public domain dataset for human activity recognition using smartphones. In *Esann*, 2013.
- [10] T. L. Kasteren, G. Englebienne, and B. J. Kröse. An activity monitoring system for elderly care using generative and discriminative models. *Personal Ubiquitous Comput.*, Vol. 14, No. 6, pp. 489–498, September 2010.
- [11] Xiaomu Luo, Qiuju Guan, Huoyuan Tan, Liwen Gao, Zhengfei Wang, and Xiaoyan Luo. Simultaneous indoor tracking and activity recognition using pyroelectric infrared sensors. *Sensors*, Vol. 17, No. 8, p. 1738, 2017.
- [12] Sozo Inoue and Xincheng Pan. Supervised and unsupervised transfer learning for activity recognition from simple in-home sensors. In *Proceedings of the 13th International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services*, MOBIQUITOUS 2016, pp. 20–27, New York, NY, USA, 2016. ACM.

- [13] Gierad Laput and Chris Harrison. Exploring the efficacy of sparse, general-purpose sensor constellations for wide-area activity sensing. *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.*, Vol. 3, No. 2, pp. 55:1–55:19, June 2019.
- [14] Ning Xiao, Panlong Yang, Xiang-Yang Li, Yanyong Zhang, Yubo Yan, and Hao Zhou. Milliback: Real-time plug-n-play millimeter level tracking using wireless backscattering. *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.*, Vol. 3, No. 3, pp. 112:1–112:23, September 2019.
- [15] Fusang Zhang, Kai Niu, Jie Xiong, Beihong Jin, Tao Gu, Yuhang Jiang, and Daqing Zhang. Towards a diffraction-based sensing approach on human activity recognition. *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.*, Vol. 3, No. 1, pp. 33:1–33:25, March 2019.
- [16] Lili Chen, Jie Xiong, Xiaojiang Chen, Sunghoon Ivan Lee, Daqing Zhang, Tao Yan, and Dingyi Fang. Lungtrack: Towards contactless and zero dead-zone respiration monitoring with commodity rfids. *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.*, Vol. 3, No. 3, pp. 79:1–79:22, September 2019.
- [17] Youwei Zeng, Dan Wu, Jie Xiong, Enze Yi, Ruiyang Gao, and Daqing Zhang. Farsense: Pushing the range limit of wifi-based respiration sensing with csi ratio of two antennas. *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.*, Vol. 3, No. 3, pp. 121:1–121:26, September 2019.
- [18] Yanwen Wang and Yuanqing Zheng. 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, December 2018.
- [19] Feng Zhang, Chenshu Wu, Beibei Wang, Hung-Quoc Lai, Yi Han, and K. J. Ray Liu. Widetect: Robust motion detection with a statistical electromagnetic model. *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.*, Vol. 3, No. 3, pp. 122:1–122:24, September 2019.

- [20] O. D. Lara and M. A. Labrador. A survey on human activity recognition using wearable sensors. *IEEE Communications Surveys Tutorials*, Vol. 15, No. 3, pp. 1192–1209, Third 2013.
- [21] Ling Bao and Stephen S Intille. Activity recognition from user-annotated acceleration data. In *International conference on pervasive computing*, pp. 1–17. Springer, 2004.
- [22] Macarena Espinilla, Javier Medina, Alberto Salguero, Naomi Irvine, Mark Donnelly, Ian Cleland, and Chris Nugent. Human activity recognition from the acceleration data of a wearable device. which features are more relevant by activities? In *Multidisciplinary Digital Publishing Institute Proceedings*, Vol. 2, p. 1242, 2018.
- [23] Oliver Amft and Gerhard Troster. On-body sensing solutions for automatic dietary monitoring. *IEEE pervasive computing*, Vol. 8, No. 2, pp. 62–70, 2009.
- [24] J. Hoey and J. 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. 1118–1132, July 2007.
- [25] Hamed Pirsiavash and Deva Ramanan. Detecting activities of daily living in first-person camera views. In *2012 IEEE Conference on Computer Vision and Pattern Recognition*, pp. 2847–2854. IEEE, 2012.
- [26] Bryce Kellogg, Vamsi Talla, and Shyamnath Gollakota. Bringing gesture recognition to all devices. In *11th {USENIX} Symposium on Networked Systems Design and Implementation ({NSDI} 14)*, pp. 303–316, 2014.
- [27] Gabriela Augustinov, Muhammad Adeel Nisar, Frédéric Li, Amir Tabatabaei, Marcin Grzegorzek, Keywan Sohrabi, and Sebastian Fudickar. Transformer-based recognition of activities of daily living from wearable sensor data. In *Proceedings of the 7th International Workshop on Sensor-based Activity Recognition and Artificial Intelligence*, pp. 1–8, 2022.

- [28] Maxime Devanne, Stefano Berretti, Pietro Pala, Hazem Wannous, Mohamed Daoudi, and Alberto Del Bimbo. Motion segment decomposition of rgb-d sequences for human behavior understanding. *Pattern Recognition*, Vol. 61, pp. 222–233, 2017.
- [29] Naruya Inagaki, Takahiro Sasaki, and Yukihiro Kamiya. A new simple approach signal analysis suitable for non-contact vital sensing using doppler sensor. In *Proceedings of the 2019 4th International Conference on Biomedical Imaging, Signal Processing*, pp. 7–11, 2019.

研究業績

本論文に関する業績

学術論文誌

1. Shinya Misaki, Makoto Yoshida, Hyuckjin Choi, Tomokazu Matsui, Manato Fujimoto and Keiichi Yasumoto (2023). Location-Independent Doppler Sensing System for Device-Free Daily Living Activity Recognition. IEEE Access.
– 5章に対応

国際会議

1. Shinya Misaki, Keisuke Umakoshi, Tomokazu Matsui, Hyuckjin Choi, Manato Fujimoto, Keiichi Yasumoto : Non-Contact In-Home Activity Recognition System Utilizing Doppler Sensors. In Adjunct Proceedings of the 2021 International Conference on Distributed Computing and Networking (pp. 169-174), January, 2021.
– 4章に対応

国内会議

1. 三崎慎也, 馬越圭介, 松井智一, 藤本まなど, 安本慶一: 屋内環境におけるドップラーセンサを使用した非接触型行動認識手法. 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), 2020(21), 1-7.
– 4章に対応

その他の業績

学術論文誌

1. Tomokazu Matsui, Kosei Onishi, Shinya Misaki, Manato Fujimoto, Hirohiko Suwa, Keiichi Yasumoto: SALON: Simplified Sensing System for Activity of

Daily Living in Ordinary Home, *Sensors*, Vol.20, No.17, Article ID 4895, August, 2020.

2. Hyuckjin Choi, Manato Fujimoto, Tomokazu Matsui, Shinya Misaki, Keiichi Yasumoto: Wi-CaL: WiFi Sensing and Machine Learning based Device-Free Crowd Counting and Localization, *IEEE Access*, Vol. 10, pp. 24395-24410, 2022.

国際会議

1. Tomokazu Matsui, Kosei Onishi, Shinya Misaki, Manato Fujimoto, Hirohiko Suwa, Keiichi Yasumoto : Easy-to-deploy living activity sensing system and data collection in general homes. In 2020 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops) (pp. 1-6). IEEE, March, 2020.
2. Shinya Misaki, Sopicha Stirapongsasuti, Tomokazu Matsui, Hirohiko Suwa, Keiichi Yasumoto: Demo Abstract: Activity Recognition through Intermittent Distributed Processing by Energy Harvesting PIR Sensors, The 18th ACM Conference on Embedded Networked Sensor Systems (SenSys 2020), Yokohama, Japan , November 16-19, 2020.
3. Rei Nakaoka, Yugo Nakamura, Yuki Matsuda, Shinya Misaki, Keiichi Yasumoto : eat2pic: Food-tech design as a healthy nudge with smart chopsticks and canvas. In 2021 IEEE International Conference on Pervasive Computing and Communications Workshops and other Affiliated Events (PerCom Workshops) (pp. 389-391). IEEE, March, 2021.
4. Tomokazu Matsui, Kosei Onishi, Shinya Misaki, Hirohiko Suwa, Manato Fujimoto, Teruhiro Mizumoto, Wataru Sasaki, Aki Kimura, Kiyoyasu Maruyama, Keiichi Yasumoto: Analysis of Visualized Bioindicators Related to Activities of

Daily Living, The 35th International Conference on Advanced Information Networking and Applications (AINA-2021), Ryerson University, Toronto, Canada, May. 12th, 2021.

5. Sopicha Stirapongsasuti, Shinya Misaki, Tomokazu Matsui, Hirohiko Suwa, 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). IEEE, July, 2021.
6. Sopicha Stirapongsasuti, Kundjanasith Thonglek, Shinya Misaki, Yugo Nakamura, Keiichi Yasumoto : Insha: Intelligent nudging system for hand hygiene awareness. In Proceedings of the 21st ACM International Conference on Intelligent Virtual Agents (pp. 183-190), September, 2021.
7. Eunice Likotiko, Shinya Misaki, Yuki Matsuda, Keiichi Yasumoto : SGBS: A novel smart garbage bin system for understanding household garbage disposal behaviour. In 2021 Thirteenth International Conference on Mobile Computing and Ubiquitous Network (ICMU) (pp. 1-8). IEEE, November, 2021.
8. Tomokazu Matsui, Shinya Misaki, Yuma Sato, Manato Fujimoto, Hirohiko Suwa, and Keiichi Yasumoto: Multi-Person Daily Activity Recognition with Non-Contact Sensors Based on Activity Co-Occurrence, The 13th International Conference on Mobile Computing and Ubiquitous Networking (ICMU 2021), pp. 157-164, Tokyo, Japan, November, 2021.
9. Hyuckjin Choi, Tomokazu Matsui, Shinya Misaki, Atsushi Miyaji, Manato Fujimoto, Keiichi Yasumoto : Simultaneous crowd estimation in counting and localization using WiFi CSI. In 2021 International Conference on Indoor Positioning and Indoor Navigation (IPIN) (pp. 1-8). IEEE, November, 2021.
10. Yugo Nakamura, Yuki Matsuda, Shinya Misaki, Keiichi Yasumoto: Aroma Nudges:

Exploring the Effects on Shopping Behavior in a Supermarket. In CEUR Workshop Proceedings (Vol. 3153). CEUR-WS, 2022.

11. Daiki Mayumi, Yugo Nakamura, Yuki Matsuda, Shinya Misaki, Keiichi Yasumoto : Aromug: Mug-type olfactory interface to assist in reducing sugar intake. In Adjunct Proceedings of the 2022 ACM International Joint Conference on Pervasive and Ubiquitous Computing and the 2022 ACM International Symposium on Wearable Computers (pp. 183-187), September, 2022.
12. Daiki Mayumi, Yugo Nakamura, Yuki Matsuda, Kentaro Ueda, Shinya Misaki, Keiichi Yasumoto : Kaolid: Lid-type Olfactory Interface to Improve Taste of Beverages with Ortho-Retronasal Smell. In 2023 IEEE International Conference on Pervasive Computing and Communications Workshops and other Affiliated Events (PerCom Workshops) (pp. 303-305). IEEE, March, 2023.

国内会議

1. 三崎慎也, 諏訪博彦, 荒川豊, 安本慶一. (2018). 環境発電駆動センサネットワーク内での分散処理に向けた環境変化に頑健なノード間欠動作機構の設計と評価. 研究報告モバイルコンピューティングとパーベイシブシステム (MBL), 2018(14), 1-6.
2. 三崎慎也, 菅田唯仁, 荒川豊, 安本慶一. (2019). Ardupilot を用いたセンサとエッジ処理による自律飛行 UAV の試作. 第 81 回全国大会講演論文集, 2019(1), 277-278.
3. 佐々木渉, 大西晃正, 三崎慎也, 諏訪博彦, 藤本まなど, 水本旭洋, 荒川豊, 木村亜紀, 三木智子, 安本慶一: 生活の質の向上を目指した宅内行動・生体情報収集システムと QoL アウェア家電制御の検討. 人工知能学会第二種研究会資料, 2019(SAI-034), 01.
4. 馬越圭介, 三崎慎也, 藤本まなど, 安本慶一: デバイスフリー行動認識に向けたドップラーセンサを用いた位置推定手法に関する一検討. 2019 年度

情報処理学会関西支部 支部大会 講演論文集, 2019.

5. 松井智一, 大西晃正, 三崎慎也, 藤本まなど, 諏訪博彦, 安本慶一: 設置が容易な生活行動センシングシステムの構築と一般家庭でのデータ収集・解析実験. 研究報告高度交通システムとスマートコミュニティ (ITS), 2019(19), 1-8.
6. 三崎慎也, 諏訪博彦, 安本慶一: 分散型深層学習に向けた環境発電駆動センサネットワークシステムの設計. 研究報告モバイルコンピューティングとパーベイシブシステム (MBL), 2019(4), 1-4.
7. 三崎慎也, 馬越圭介, 藤本まなど, 安本慶一: 認識対象の動作速度に着目したドップラーセンサによる宅内行動認識手法. 第 27 回マルチメディア通信と分散処理ワークショップ論文集, 76-83, 2019.
8. 松井智一, 大西晃正, 三崎慎也, 諏訪博彦, 藤本まなど, 水本旭洋, 佐々木渉, 木村亜紀, 玉田隆史, 丸山清泰, 安本慶一: 日常生活行動に紐付けた生体指標の可視化と分析. 第 28 回マルチメディア通信と分散処理ワークショップ論文集, 34-41, 2019.
9. 吉田誠, 馬越圭介, 藤本まなど, 三崎慎也, 松井智一, 諏訪博彦, 安本慶一: ダイナミックレンジを拡大するアダプティブゲイン歩行振動センサシステムの検討. 第 29 回マルチメディア通信と分散処理ワークショップ論文集, 246-251, 2021.
10. 中岡黎, 中村優吾, 松田裕貴, 三崎慎也, 安本慶一: メシクエ: ご飯を食べて敵を倒す食育ゲームの提案. 第 29 回マルチメディア通信と分散処理ワークショップ論文集, 197-198, 2021.
11. 真弓大輝, 中村優吾, 三崎慎也, 松田裕貴, 安本慶一: Aromug: 糖分摂取量低減を補助するスマートマグカップの設計と基礎評価. マルチメディア, 分散, 協調とモバイルシンポジウム 2022 論文集, 2022, 981-988.

12. 真弓大輝, 中村優吾, 松田裕貴, 三崎慎也, 安本慶一: 鼻腔経路の異なる香りを提示可能なデバイスの設計と味覚に与える影響の基礎評価. 第30回マルチメディア通信と分散処理ワークショップ論文集, 175-180, 2021.