

ドップラーセンサを活用した 宅内行動認識システムの開発と評価

藤原 聖司^{1,a)} 藤本 まなと^{1,b)} 荒川 豊^{1,2,c)} 安本 慶一^{1,d)}

概要: これまでに、省エネ家電制御などの生活を支援するサービスの実現に向けた宅内における生活行動認識に関する研究が多数提案されている。しかし、先行研究は読書といった、家電製品を使用せず、場所に関係なく行われる生活行動（場所非依存行動）を正確に検出・認識することは困難であった。本研究では生活行動ごとのモーションの違いに着目し、ドップラーセンサで捉えたモーション情報を特徴量に加えることでこれらの行動を認識する手法を実現する。本稿では、モーション情報としてセンサの出力信号の周波数成分を用い、機械学習によって生活行動認識モデルを作成する。また、提案手法の有用性と行動認識の実現に向けた課題を検討するため、6名の被験者が2か所の異なる場所で3種類の異なる行動を行う際のセンサデータを収集して行動認識モデルを構築し、認識精度を評価した。その結果、認識精度が最大45.9%であった。また、被験者の位置によって認識精度に影響があることから、提案手法の実用化に向け、位置の影響を考慮した手法の検討が必要であることがわかった。

Development and Evaluation of In-home Activity Recognition Utilizing Doppler Sensor

MASASHI FUJIWARA^{1,a)} MANATO FUJIMOTO^{1,b)} YUTAKA ARAKAWA^{1,2,c)} KEIICHI YASUMOTO^{1,d)}

1. はじめに

近年、ウェアラブルデバイスや小型で省電力なセンサなどのセンシングデバイスが急速に普及しており、様々な情報を容易に取得できるようになっている。これらのセンシングデバイスの普及を受け、センシングデバイスを使用して人の行動を認識する研究が盛んに行われている。なかでも、宅内で行われる生活行動を認識することによって、省エネを目的とした家電制御 [1] や高齢者見守りシステム [2] など、居住者の生活をサポートするサービスの実現が期待されている。これらのサービスを実現するには、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ことが必要である。

これまでに、宅内における生活行動認識に関する研究が多数提案されており、先行研究である中川ら [3], [4] 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。また、柏本ら [5] 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開発している。しかし、中川らや柏本らの手法では、調理やテレビ視聴などの生活行動については高精度 (79.4%) な生活行動の認識を実現している一方で、読書やスマートフォン操作など、一部の生活行動の認識が低精度 (28%) 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特定の家電製品を使用せず、また居住者が場所を選ばずにその行動をとれることから、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（位置非依存行動）を検出・認識することが困難なためである（課題 1）。そのた

¹ 奈良先端科学技術大学院大学 情報科学研究科
Graduate School of Information Science, Nara Institute of Science and Technology

² JST さきがけ
JST PRESTO

a) fujiwara.masashi.fe8@is.naist.jp

b) manato@is.naist.jp

c) ara@is.naist.jp

d) yasumoto@is.naist.jp

め、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である。課題1を解決するためのアプローチの一つとして、各生活行動が取られる際の人体のモーションを利用する手法が考えられる。Ouchiら[6]は、スマートフォンに搭載された加速度センサやマイクロフォンを使用して掃除や歯磨きなどの生活高度を推定する手法を提案している。しかし、スマートフォンなどのウェアラブルデバイスを用いた手法では、居住者が常にスマートフォンを身に着ける必要があるため、居住者の装着負担が問題となる(課題2)。また、カメラを用いた手法では、居住者に対して「監視されている」という不安感を与え、プライバシー侵害につながる恐れがある(課題3)。

本研究では、課題1から課題3を解決することを目指した生活行動認識手法の提案を目的とする。課題2と3を踏まえ、本研究で使用するセンサの要件は、人のモーションのみを検知するセンサであること、部屋の床や壁に設置するセンサであることとする。課題1から課題3を解決する方法として、これまでに我々は動体検知センサと機械学習を用いた場所非依存行動認識手法を提案しており、動体検知センサとしてアナログ出力焦電型赤外線センサを活用した行動認識手法を提案している[7]。しかし、この手法はアナログ出力焦電型赤外線センサの検知距離が短い(～2 m程度)ため、リビングなど部屋全体をカバーするには多数のセンサが必要となることがわかっている。

本研究では、動体検知センサのうち、検出距離が長い(～10 m程度)ドップラーセンサから得られる周波数成分から生活行動を認識する手法を提案する。このセンサの出力信号は、その周波数成分が人体の動きとその速さに応じて変化する特性を有する。そのため、食事などのモーションの大きな生活行動で得られる信号と、読書などのモーションの小さな生活行動で得られる信号に差異が生じる。提案手法では、この信号の特性を活用し、ドップラーセンサの出力信号の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。センサの出力信号の周波数成分は、ある時間区間の信号にSTFT(Short-Term Fourier Transform)を適用することで取得する。提案手法では、STFTで得られたセンサの出力信号の周波数成分を特徴量として利用し、機械学習によって生活行動を認識する。

提案手法の有効性および行動認識の実現に向けた課題を検討するため、奈良先端科学技術大学院大学内に設置されたスマートホーム設備にて評価実験を行った。ドップラーセンサはスマートホーム内のリビングの四隅に1つずつ配置し、リビング全体がセンサの検知エリアとなるようにする。認識対象とする行動は以下の3つとする:(1) PCの操作、(2) 読書、(3) スマートフォンの操作。被験者には、これらの3つの生活行動をそれぞれ3分間ずつ行ってもら

い、1セッションのデータとする。評価実験では、成人男女6名の被験者に、スマートホーム内のリビングに置かれたソファとテーブル前の椅子に着座してもらい、それぞれ2セッションずつ行動してもらう。その間のセンサデータを収集し、前述の手順で周波数成分を算出する。4つのセンサから得られた周波数成分を特徴量として使用し、機械学習アルゴリズムの一つであるRandom Forestを用いて生活行動認識モデルを作成する。このとき、実験で取得した全セッションのセンサデータのうち、生活行動認識モデル作成には、次の3つのパターンを用いた:(A) ソファでの行動時のセッションデータのみ、(B) ダイニングテーブル前での行動時のセッションデータのみ、(C) 両方の場所(ソファ、ダイニングテーブル前)での行動時のセッションデータ。また、特徴量の次元数を削減するため、特徴量として使用する周波数成分の帯域(下限周波数 F_l - 上限周波数 F_h 間の周波数成分)を選択して生活行動認識モデルを作成し、その認識精度を評価する。

提案手法の生活行動の認識精度は、取得したデータセットのうち1セッションのデータを除外して残りのデータを教師データとし、除外した1セッションのデータをテストデータとする、1セッション除外の交差検証(leave-one-session-out cross-validation)で評価した。評価実験の結果、今回の実験環境においては提案手法による生活行動の平均認識精度は、 F_h が5 Hzに設定したとき45.9%となった。

2. 関連研究

居住者の生活行動を認識する手法は多数提案されており、カメラを利用した行動認識手法[8],[9]やウェアラブルデバイスを利用した行動認識手法[6],[10],[11]、タグレス行動認識手法[12]などがある。次節以降では、これらの既存研究の詳細を述べる。

2.1 カメラを利用した行動認識手法

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[8],[9]。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。Brdiczkaら[9]は、カメラを使用した画像処理により、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。この研究では、3Dビデオトラッキングセンサと環境音センサを用いることで、歩く、座るといった単純な行動に加え、仕事や昼寝といった個人の行動、さらには会話、ゲームといった複数人による行動を70%から90%の精度で認識できる。しかし、特殊かつ高価なカメラやマイクが必要であり、居住者のプライバシーを侵害する恐れがある。また、カメラを用いて詳細な行動認識を行うには、複数のカメラの設置や、各カメラと分析サーバを接続するためのケーブル

ル配線が必要であるなど、設置コストが非常に高い。

2.2 ウェアラブルデバイスを利用した行動認識手法

ウェアラブルデバイスに搭載されている加速度センサを用いた行動認識手法においては、歩く・座る・走る・寝る、といった非常に単純な行動の認識については、約90%以上の高精度で達成されている[10]。一方で、ウェアラブル加速度センサによる複雑で抽象的な生活行動の認識に関する手法はあまり提案されていない。Baoら[11]は、人に装着した5つ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、Baoらの手法では、ユーザは5つのセンサを装着する必要があるため、ユーザの負担が非常に大きい。

2.3 タグレス行動認識手法

Kasterenら[12]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、着替え等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%であり、多数の生活行動を認識できる。しかし、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。

2.4 生活行動認識における課題

これまでに述べたように、生活行動認識に関する既存研究が多数行われており、先行研究である中川ら[3]、[4]の提案する行動認識手法では、超音波高精度屋内位置測位センサと、家電製品の消費電力を測定する電力センサを使用し、16種類もしくは10種類の生活行動の高精度(79.4%)な認識を実現している。また、柏本ら[5]は焦電型赤外線センサとドア開閉センサを利用した行動認識手法を提案している。しかし、これらの研究では、調理やテレビ視聴など、生活行動がとられる場所や使用される家電製品に特徴のある生活行動については高精度に認識できているが、読書やスマートフォンの操作など、特定の家電製品を使用しない行動については認識精度が28%に悪化することが報告されている(課題1)。例えば、調理やバスルーム活動(入浴や風呂掃除)などの生活行動はそれぞれキッチン、浴室でのみ行われる。しかし、食事はテーブルやソファで、読書はソファやベッドなど、特定の場所に限らずにその行動が行われる。そのため、居住者の位置情報のみでは、これらの特定の場所によらない生活行動を正確に認識できない。また、食事や読書、スマートフォンの操作などの生活行動は、特定の家電製品を使用せずに行われる。このことから、居住者の位置情報や家電製品の消費電力情報のみでは、特定の位置で行われず家電製品を使用しない生活行動

の認識は非常に困難である。さらに、モーションを利用して生活行動を認識する手法が提案されているが、これらの手法は、ウェアラブルデバイスを使用しているため、ユーザに装着負担を与えてしまう(課題2)、カメラでの撮影はユーザのプライバシー侵害につながるおそれがある(課題3)、という問題がある。

3. ドップラーセンサを用いた宅内生活行動認識手法

本章では、提案手法であるドップラーセンサを用いた宅内生活行動認識手法について説明する。

3.1 概要

本研究では、課題1から課題3を達成するため、提案手法で使用されるセンサの要件として、以下の3つが挙げられる。


- (要件1): 人に装着負担を与えない非接触型センサであり、部屋の床や壁に設置できるセンサであること
- (要件2): 人のモーションをプライバシーの侵害なく検知できるセンサであること
- (要件3): 検知範囲が部屋全体をカバーできるセンサであること

上記の要件を満たしうるセンサとして、本手法ではドップラーセンサを利用する。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ことができる非接触型センサである。ドップラーセンサはマイクロ波(電波)を送信し、人や物体からの反射波を受信する。受信した反射波と、送信波との差分を1次元の時系列信号として出力する。そのため、プライバシーへの影響が少ない。送信波を受けた物体が移動していた場合、ドップラーシフトによって反射波の周波数が変化するため、この変化が送信波と反射波との差分として表れる。また、ドップラーセンサは検知距離が6m程度と、アナログ出力焦電型赤外線センサの検知距離2mよりも長いので、部屋全体をカバーできる。


本研究では、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、生活行動認識を実現する。ドップラーセンサの出力信号は、ドップラーセンサと人物の距離の違いや人物の動作速度の違いによって変化する。次節以降、ドップラーセンサの出力特性と、ドップラーセンサから得られる特徴量、その特徴量を用いた生活行動認識モデルの構築について述べる。

3.2 ドップラーセンサの出力特性

ドップラーセンサはセンサと人物の距離に応じて、出力信号の振幅を変化させる特性を有する。ドップラーセンサと人物の距離が近い場合は出力信号の振幅が大きく、距



(a) 波形




(b) 周波数成分

図 1 人体が素早く動いた際の出力信号の特性


離が遠くなると出力信号の振幅が小さくなる。そのため、ドップラーセンサの出力信号から生活行動を認識するには、この距離の違いによる出力信号の変化による認識精度の変化を検討する必要がある。また、ドップラーセンサの出力信号は、人物の動作速度の違いによっても出力信号が変化する。図 1 と図 2 に人物の動作速度の違いによるドップラーセンサの出力信号の変化を示す。図 1 は人物が素早く動いたときの出力信号であり、図 2 は人物が緩やかに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。つまり、ドップラーセンサの出力信号は、人物の素早い動作を捉えた際に幅広い周波数帯（比較的高い周波数）の成分を含む。本研究では、このドップラーセンサの特性を利用して居住者の生活行動を認識する。

3.3 特徴量の抽出

提案手法では、機械学習による居住者の生活行動を認識するために必要な特徴量として、ドップラーセンサから取得した出力信号の周波数成分を利用する。特徴量の抽出手順を以下に示す。まず、ドップラーセンサから得た出力信号をある時間区間に切り出して 1 フレームの信号とする。次に、フレームをそのフレームの平均値で減算して直流成分を除去する。次に、このフレームに対して STFT (Short-Term Fourier Transform) を適用し、周波数成分を算出する。すなわち、ドップラーセンサ p の出力信号 $x_p[n]$ に対して、時刻のインデックスが n のとき、離散周波数の



(a) 波形



(b) 周波数成分

図 2 人体が緩やかに動いた際の出力信号の特性

インデックス k の周波数成分 $|X_p[n, k]|$ は、以下の式 (1) を計算することで得られる。

$$|X_p[n, k]| = \left| \sum_{m=0}^{L-1} x_p[n+m]w[m]e^{-i2\pi\frac{m}{L}k} \right| \quad (1)$$

ここで、 L はフレーム長を表す。また、 $w[m]$ は窓関数で、窓の両端が 0 となるような関数である。上述の手順で得られる周波数成分はセンサーにつき $\frac{N}{2}$ 点である。また、周波数の分解能 Δf は、センサのサンプリング周波数が f 、フレーム長が L のとき、以下の式 (2) で表される。

$$\Delta f = \frac{f}{L} \quad (2)$$

3.4 特徴量として使用する周波数成分の選択

提案手法では、複数のドップラーセンサを居住空間に設置し、それぞれのセンサから得られた特徴量を使用する。そのため、 N 個のセンサの出力信号に対して STFT を適用し、得られたすべての周波数成分を特徴量として使用した場合、特徴量の次元数は $\frac{L}{2}N$ 次元となる。センサの数やフレーム長を大きくすると次元数が大幅に増加し、認識精度に影響する恐れがある。そこで、提案手法では、特徴量として使用する周波数成分の帯域を選択することで特徴量の次元数を削減する。一つのドップラーセンサの周波数成分のうち、図 3 に示すように、下限周波数 F_l と上限周波数 F_h の間の成分（図中の赤枠で囲まれた成分）を一つのセンサから得られた特徴量として使用する。

3.5 生活行動認識モデルの構築

提案手法では、3.3 節で述べた特徴量を教師データとし

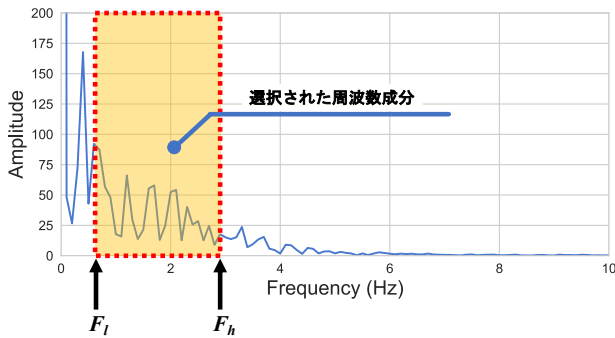


図 3 選択された周波数成分

て使用し、生活行動認識モデルを構築する。生活行動認識モデルを構築するための機械学習アルゴリズムとして、Random Forest を用いる。Random Forest はアンサンブル学習を用いた機械学習アルゴリズムの一つで、複数の決定木を弱分類器として使用することで汎化能力を高めている。モデル生成のために使用する特徴量は、3.3 節で述べたように、複数のドップラーセンサから得られた周波数成分である。

4. ドップラーセンサ測定システムの実装

提案手法による生活行動の認識精度を評価する実験を行うため、ドップラーセンサが出力するデータを測定するシステムを実装した。以下に、ドップラーセンサの回路構成およびセンサデータ測定システムについて述べる。

4.1 ドップラーセンサの回路構成

本節では、本研究で使用するドップラーセンサの回路構成について述べる。図 4 にドップラーセンサの回路構成を示す。ドップラーセンサは、1 個のドップラーセンサモジュール、2 段の非反転増幅回路、2 段のノッチフィルタ、1 段のローパスフィルタ、A/D 変換器、および測定制御コンピュータで構成される。ドップラーセンサモジュールは、マイクロ波の送受信と送受信した信号の差分を出力するセンサモジュールである。本研究では、ドップラーセンサとして新日本無線株式会社製の NJR4178J^{*1} を使用する。このセンサは 10.5 GHz 帯のマイクロ波を利用している。このセンサが出力する差分信号は非常に微弱であるため、2 段の非反転増幅回路で増幅する。次に、差分信号に重畳しているノイズを除去するため、差分信号に対して 2 段のノッチフィルタと 1 段のローパスフィルタを適用する。上述の回路を用いてドップラーセンサモジュールの微弱な出力信号を増幅・フィルタリングすることで、人物のモーションの違いによって生まれる出力信号の変化をはっきりと捉えることができる。

^{*1} NJR4178J: <https://micro.njr.com/jpn/products/sensor/doppler/r4178.html>

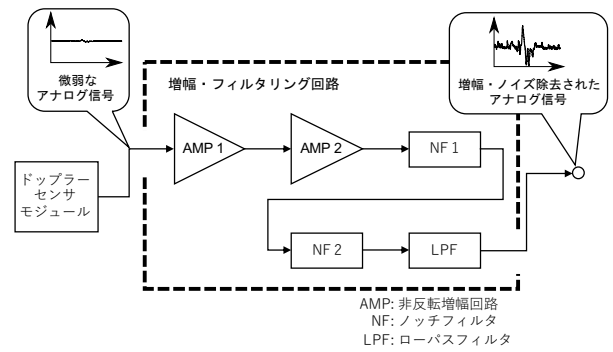
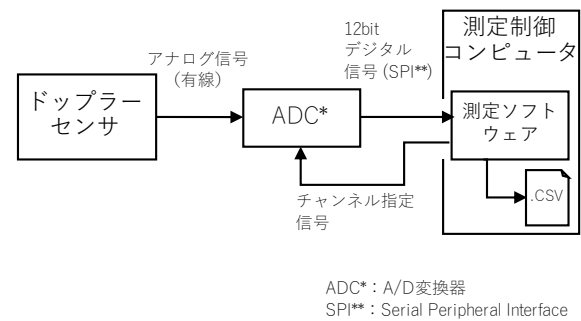


図 4 ドップラーセンサの回路構成



ADC*: A/D変換器
SPI**: Serial Peripheral Interface

図 5 ドップラーセンサの測定システムの構成

4.2 センサデータ測定システム

提案手法で使用するドップラーセンサのセンサデータをロギングするため、センサデータ測定システムを使用する。図 5 にセンサデータ測定システムの構成を示す。センサデータ測定システムは、1 台のドップラーセンサ、A/D 変換器、測定制御コンピュータで構成される。測定制御コンピュータ上では、ドップラーセンサのデータを測定する測定ソフトウェアが実行されている、このソフトウェアは、最大 1 KHz のサンプリングレートでドップラーセンサの出力する信号を測定し、CSV 形式のファイルに記録する。本研究では、A/D 変換器として Microchip Technology 社の MCP3208^{*2} を、測定制御コンピュータとして Raspberry Pi 3^{*3} を使用してデータ測定システムを構築している。

5. 評価実験

ドップラーセンサを用いた宅内生活行動認識手法の性能を評価するため、奈良先端科学技術大学院大学に設置されたスマートホーム設備にて評価実験を行った。以下に評価実験の目的と概要、実験結果について述べる。

5.1 実験目的

本実験では、動体検知センサとしてドップラーセンサを使用し、センサから得られた周波数成分を特徴量として、

^{*2} MCP3208: <http://www.microchip.com/wwwproducts/en/MCP3208>

^{*3} Raspberry Pi 3: <https://www.raspberrypi.org/>

機械学習による生活行動認識の認識精度を評価することを目的とする。得られたセンサデータの周波数成分をすべて使用して生活行動認識モデルを構築し、そのモデルの認識精度を評価する。その際、提案手法が被験者の位置によらず生活行動を認識可能であるか、という観点についても評価する。また、特徴量として使用する周波数成分の帯域の選択による認識精度の変化を検討するため、下限周波数 F_l と上限周波数 F_h をそれぞれ変更して生活行動認識モデルを作成し、認識精度を評価する。

5.2 実験概要

本実験では、スマートホーム内のリビングで行われる生活行動のうち、ソファとダイニングテーブル周辺でとられることの多い生活行動を対象とし、被験者が生活行動をとっている間のセンサデータを収集した。

図6に示すように、ドップラーセンサはスマートホーム設備のリビングの四隅（星印の位置）に計4つ配置した。ドップラーセンサは、マイクロ波の照射方向がリビング中央を向くように（図中の星印から伸びる矢印の方向に）センサを向け、三脚で固定した。ドップラーセンサの検知距離はおよそ6mであるため、このセンサ配置により、リビング全体がセンサの検知範囲となる。

評価実験では、認識対象とする生活行動として、PCの操作、読書、スマートフォンの操作、の3つの生活行動を選択した。被験者には、これらの3つの生活行動をそれぞれ3分間ずつ行ってもらい、1セッションのデータとした。また、人とセンサの位置関係の違いやセンサの取付方向の違いによる認識精度への影響を検討するため、図6の緑色の場所にて、被験者がソファに着座して行動した場合、テーブルの前に着座して行動した場合について、それぞれ2セッションずつデータを取得した。本実験には成人男女6名（男性5名、女性1名）が被験者として参加し、計12セッションのセンサデータを収集した。

本評価では、前述の実験で取得した全セッションのセンサデータうち、生活行動認識モデル作成には、以下の3つのパターンを用いた：(A) ソファでの行動時のセッションデータのみ、(B) ダイニングテーブル前での行動時のセッションデータのみ、(C) 両方の場所（ソファ、ダイニングテーブル前）での行動時のセッションデータ。認識精度の評価は、取得したデータセットのうち1セッションのデータを除外して残りのデータを教師データとし、除外した1セッションのデータをテストデータとする、1セッション除外の交差検証（leave-one-session-out cross-validation）にて認識精度を評価した。

5.3 特徴量の抽出

本評価実験では、実験で取得したドップラーセンサのセンサデータに対してSTFTを適用して得られた周波数成分

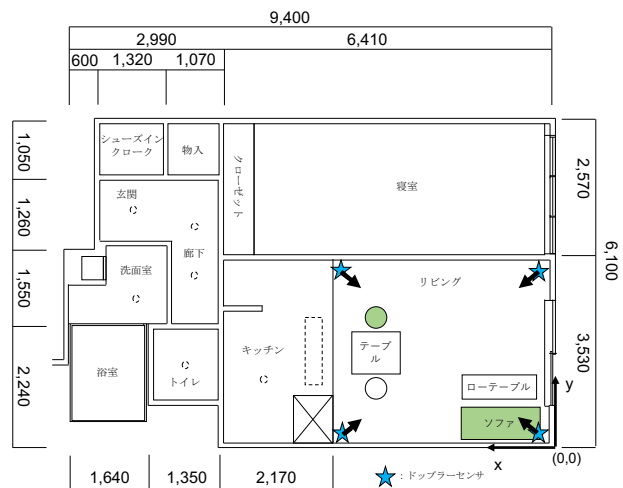


図6 ドップラーセンサの配置と被験者の位置関係

を特徴量として使用する。本評価実験では、センサデータのサンプリング周波数 f を 100 Hz、フレーム長を 10 秒とし、窓関数に Hamming 窓を使用した。そのため、一つあたりのドップラーセンサに対して、STFT によって得られる周波数成分の点数は 50 点となる。また、周波数成分の帯域は 0 Hz から 50 Hz、周波数分解能は 0.1 Hz となる。本評価実験では、0.1 秒ごとに STFT を計算し、その時刻での周波数成分とした。

5.4 評価方法

本評価実験では、認識精度を Precision, Recall, F-Score を用いて評価する。Precision（適合率）は、その生活行動であると認識されたデータのうち、実際にその生活行動であった正しいデータの割合である。Recall（再現率）は、ある生活行動のテストデータのうち、正しくその行動であると認識されたデータの割合である。F-Score（F 値）は、Precision と Recall の調和平均であり、以下の式 (3) で表す。

$$F\text{-Score} = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad (3)$$

さらに、本評価実験では、4 種類の生活行動全体に対する認識精度を評価するため、それぞれの評価値について各生活行動ごとの加重平均をとる。加重平均とは、各生活行動のサンプル数を重みとした平均で、以下の式 (4) で表す。

$$\bar{x} = \frac{\sum_{i=1}^n w_i x_i}{\sum_{i=1}^n w_i} \quad (4)$$

ここで、 w_i は各生活行動のサンプル数を、 x_i は各行動の評価値を表す。本評価実験では、F-Score の加重平均値を提案手法の認識精度とする。

6. 実験結果

6.1 すべての帯域の周波数成分を用いた行動認識精度

表 1 に、すべての帯域の周波数成分を用いて構築した各

表 1 すべての帯域の周波数成分を用いた行動認識精度

行動認識モデル	Precision (%)	Recall (%)	F-Score (%)
(A)	38.5	38.5	38.4
(B)	50.3	50.2	50.2
(C)	44.4	44.1	44.2

- (A) ソファでの行動時のセッションデータのみを用いたモデル
 (B) ダイニングテーブル前での行動時のセッションデータのみを用いたモデル
 (C) 両方の場所での行動時のセッションデータを用いたモデル

表 2 生活行動ごとの認識精度

(a) ソファでの行動時のセッションデータのみを用いたモデル

生活行動	Precision (%)	Recall (%)	F-Score (%)
PC の操作	44.4	46.5	45.5
読書	33.7	35.7	34.7
スマートフォンの操作	37.1	33.3	35.1

(b) ダイニングテーブル前での行動時のセッションデータのみを用いたモデル

生活行動	Precision (%)	Recall (%)	F-Score (%)
PC の操作	60.8	59.3	60.0
読書	47.1	49.6	48.3
スマートフォンの操作	43.0	41.9	42.4

(c) 両方の場所での行動時のセッションデータを用いたモデル

評価項目	Precision (%)	Recall (%)	F-Score (%)
PC の操作	52.9	48.3	50.5
読書	40.2	43.5	41.8
スマートフォンの操作	40.3	40.5	40.4

生活行動認識モデルの認識精度を示す。この表を見ると、最も高精度に認識できている生活行動認識モデルはダイニングテーブル前での行動時のセッションデータのみを用いて作成したモデルで、最も精度の低い生活行動認識モデルはソファでの行動時のセッションデータのみを用いて作成したモデルであった。それぞれのモデルの認識精度は 38.4 %、50.2 % であった。また、ソファとダイニングテーブル前の両方の場所での行動時のセッションデータを使用して生活行動認識モデルを構築した場合、そのモデルの認識精度は 44.2 % となった。表 2(a) に、ソファでの行動時のセッションデータを用いた場合、表 2(b) にダイニングテーブル前での行動時のセッションデータを用いた場合、表 2(c) に両方の場所での行動時のセッションデータを用いた場合の、生活行動認識モデルの各行動ごとの認識精度を表す。表 2 より、読書、スマートフォンの操作、の二つの動作の認識精度が低いことがわかる。この二つの動作は PC の操作に比べると両手の動きがおとなしく、そのためドップラーセンサがこれらの両手の動きを十分に捉えきれなかったため、誤認識の割合が増加したと考えられる。したがって、読書やスマートフォンの操作を正確に認識するには、これらの行動時のユーザの両手の動きを十分に捉える事ができるようにドップラーセンサの感度を高める必要があると考えられる。




図 7 高周波数成分の削減による認識精度の変化

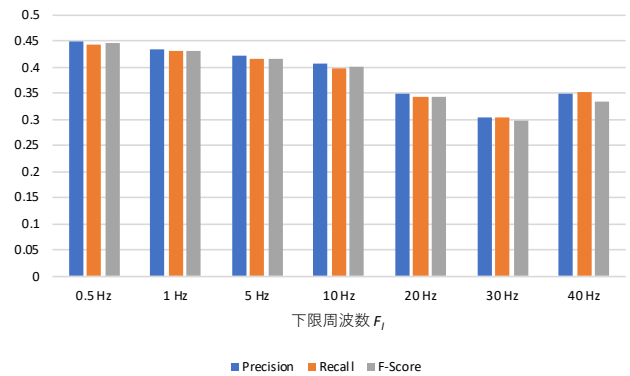


図 8 低周波数成分の削減による認識精度の変化

6.2 高周波数成分の削減による認識精度の変化

本評価では、特徴量として使用する周波数成分の上限周波数 F_h を変化させたときの認識精度の変化を検討する。0 Hz から F_h Hz の帯域の周波数成分を特徴量として使用し、生活行動認識モデルを構築する。 F_h が 0.5, 1, 5, 10, 20, 30, 40 Hz の場合の生活行動認識モデルをそれぞれ構築した。構築したそれぞれの生活行動認識モデルに対して認識精度を評価する。図 7 に、特徴量として使用する周波数成分の上限周波数 F_h を変化させたときの認識精度の変化を示す。図 7 を見ると、 F_h を高くしていくと認識精度が向上することがわかる。特に F_h が 5 Hz の場合の認識精度が最も高く、45.9 % であった。また、 F_h を 5.0 Hz 以上に設定しても、認識精度はおよそ 45 % で推移している。以上から、ドップラーセンサから得られた出力信号の周波数成分を用いた生活行動認識手法では、0 Hz - 5 Hz の帯域の周波数成分が含まれていることが重要であると考えられる。

6.3 低周波数成分の削減による認識精度の変化

本評価では、特徴量として使用する周波数成分の下限周波数 F_l を変化させたときの認識精度の変化を検討する。 F_l Hz から 50 Hz の帯域の周波数成分を特徴量として使用し、生活行動認識モデルをそれぞれ構築する。 F_l が 0.5, 1, 5, 10, 20, 30, 40 Hz の場合の生活行動認識モデルをそれぞ

れ構築した。構築したそれぞれの生活行動認識モデルに対して認識精度を評価する。図8を見ると、 F_l を高くすると、生活行動認識モデルの認識精度が悪化していく事がわかる。特に、 F_l が30 Hzの場合は、認識精度は最も低く29.8%であった。以上から、ドップラーセンサから得られた出力信号の周波数成分を用いた生活行動手法では、低周波域の信号が特に重要であり、高周波域の信号はノイズ成分であることがわかった。

7. 結論

近年のセンシングデバイスの普及に伴い、人の行動を認識する研究が盛んに行われている。なかでも、宅内生活行動を認識することによって、省エネ家電制御などの居住者の生活をサポートするサービスの実現が期待される。これまでに多数の宅内生活行動認識に関する研究が行われているが、(1) 読書などの一部の生活行動は位置や消費電力情報では認識が困難であること、(2) 居住者にセンサの装着負担を与えること、(3) カメラによるプライバシー侵害の恐れがあること、の3つの課題が未だ残されている。

本研究では、上記の3つの課題を解決することを目的とし、ドップラーセンサで得られる生活行動ごとのモーションの差異に着目した行動認識手法を新たに提案した。動体検知センサとしてドップラーセンサを用いた行動認識手法を提案した。スマートホームのリビングの4隅にセンサを設置し、センサデータから取得した周波数成分を特徴量として、機械学習により3種類の生活行動(PC操作、読書、スマートフォン操作)を認識する。生活行動を認識できる範囲はリビング全体である。提案手法の有効性を示すため、評価実験をスマートホーム設備にて実施した。その結果、全周波数帯の成分を用いたときの平均認識精度は44.2%が得られた。また、特徴量として使用する周波数成分の帯域を0 Hzから5 Hzに制限した場合、認識精度が45.9%と最も良くなることがわかった。

今後の課題として、提案手法の認識精度は実用化の観点から見ると未だ改善の余地が残されている。被験者の位置によって認識精度に影響があることから、その影響を考慮した手法の検討が必要であると考え。

謝辞 本研究の一部はJSPS科研費17KT0080, 16K00126の助成を受けたものです。

参考文献

- [1] Scott, J., Brush, A., Krumm, J., Meyers, B., Hazas, M., Hodges, S. and Villar, N.: PreHeat: Controlling Home Heating Using Occupancy Prediction (2011).
- [2] Rashidi, P. and Mihailidis, A.: A Survey on Ambient-Assisted Living Tools for Older Adults, *IEEE Journal of Biomedical and Health Informatics*, Vol. 17, No. 3, pp. 579–590 (2013).
- [3] Nakagawa, E., Moriya, K., Suwa, H., Fujimoto, M., Arakawa, Y., Hata, T., Miwa, S. and Yasumoto, K.:

- K.: Investigating recognition accuracy improvement by adding user's acceleration data to location and power consumption-based in-home activity recognition system, *Proceedings of the 13th International Conference on Mobile and Ubiquitous Systems: Computing Networking and Services - MOBIQUITOUS 2016*, pp. 100–105 (2016).
- [4] 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).
- [5] 柏本幸俊, 秦 恭史, 中川愛梨, 諏訪博彦, 藤本まなど, 荒川 豊, 繁住健哉, 小宮邦裕, 小西健太, 安本慶一: エナジハーベスト焦電型赤外線・ドア開閉センサ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. 58, No. 2, pp. 409–418 (2017).
- [6] Ouchi, K. and Doi, M.: Smartphone-based Monitoring System for Activities of Daily Living for Elderly People and Their Relatives etc., *Proceedings of the 2013 ACM Conference on Pervasive and Ubiquitous Computing Adjunct Publication*, UbiComp '13 Adjunct, ACM, pp. 103–106 (2013).
- [7] FUJIWARA, M., KASHIMOTO, Y., FUJIMOTO, M., SUWA, H., ARAKAWA, Y. and YASUMOTO, K.: Implementation and Evaluation of Analog-PIR-Sensor-Based Activity Recognition, *SICE Journal of Control, Measurement, and System Integration*, Vol. 10, No. 5, pp. 385–392 (2017).
- [8] Uddin, M. Z.: A Robust Daily Human Activity Recognition and Prediction System, *Proceedings of the 2014 International C* Conference on Computer Science & Software Engineering*, C3S2E '14, ACM, pp. 12:1–12:8 (2014).
- [9] Brdiczka, O., Langet, M., Maisonnasse, J. and Crowley, J. L.: Detecting Human Behavior Models From Multimodal Observation in a Smart Home, *IEEE Transactions on Automation Science and Engineering*, Vol. 6, No. 4, pp. 588–597 (2009).
- [10] Lara, O. D. and Labrador, M. A.: A Survey on Human Activity Recognition using Wearable Sensors, *IEEE Communications Surveys Tutorials*, Vol. 15, No. 3, pp. 1192–1209 (2013).
- [11] Bao, L. and Intille, S. S.: Activity Recognition from User-Annotated Acceleration Data, *Pervasive Computing*, Springer Berlin Heidelberg (2004).
- [12] 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 (2010).