

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

三崎 慎也^{†1,a)} 馬越 圭介^{†1} 藤本 まなと^{†1,b)} 安本 慶一^{†1,c)}

概要：近年、省エネや日常生活の支援を目的とした家電制御やサービスの開発や研究が多く提案されている。そのようなサービスを実現するには、生活行動の認識が必須である。しかし、生活行動認識に関する先行研究では、「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対象の動作速度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て、対象の行動の向きによって補正を行い、対象の行動の速度計算を行い、機械学習によって生活行動モデルを作成する手法の提案を行う。また、ドップラーセンサの行動の種類や行動の向きによる周波数特性の違いを確認し、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、被験者3人に異なる7つの行動を行う際のセンサデータを収集して各センサごとに行動認識モデルを構築し、認識精度を評価した。その結果、平均F-Score：46.9%となり、先行研究の結果よりも高い値となった。また、今後の課題として、今回実験で使用したRaspberry Pi 3のサンプリング周期が低いため取得できなかった行動があり、計測システムの見直しと4つのドップラーセンサを組み合わせ、認識精度をさらに上げることが可能な手法の検討が必要であることが分かった。

1. はじめに

小型軽量で装着負担が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の登場・普及により、人の行動に関する様々な情報を容易に取得できるようになっている [1], [2]。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、行動に合わせてQoL (Quality of Life) を向上させる家電制御 [1] や高齢者見守りシステム?といった、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は多数提案されている。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の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 [5], [6] 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。しかし、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、79.4%と高精度な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のような一部の生活行動の認識については、28%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行うことから、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。そのため、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、新たな情報の特徴量として使用することが必要と考えられる。

位置非依存行動を認識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。藤原ら [7] は、動体検知センサの中でも、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した。この手法では、行動の違いによってドップラーセンサが出力する周波数が変化するという特性に着目し、出力信号の周波数成分を取得・解析することで、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して

^{†1} 現在、奈良先端科学技術大学院大学
Presently with Nara Institute of Science and Technology

a) misaki.shinya.mq9@is.naist.jp

b) manato@is.naist.jp

c) yasumoto@is.naist.jp

いる。この手法では、特徴量として使用する周波数成分の帯域を 0Hz から 5Hz に制限した場合、3つの行動の認識精度が 45.9%になると報告されているが、実用化の観点では、認識対象行動が少ない、認識精度が十分でないという課題が残っている。

本研究では、ドップラーセンサを使用して対象（人）の動作の速さを算出し、そこ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、対象の動作速度によって周波数に変化する。そこで、周波数特性から各速度に特有の周波数を読み取り、そこから対象の動作速度を計算することによって認識精度を向上させることができると考えた。提案手法では、あらかじめ測定する場所を固定し、正面から側面にかけて 45 度ずつずらして設置した各センサの出力信号から抽出した生活行動認識で有効性が示されている特徴量 [8] に加えて、対象の速度を新たな特徴として使用することによって、指定した 7 つの行動を正しく認識できるか比較を行い、評価した。その結果、7 種類の生活行動の平均認識精度は 46.9%と、藤原らの手法 [7] を上回る精度を得られることが確認できた。

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 [9], [10] や、消費電力計を利用した行動認識手法 [3], [4], [11], ウェアラブルデバイスを利用した行動認識手法 [12], [13], [14] 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 [9], [10]。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 [9] 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。しかし、居住者のプライバシーを侵害する恐れがあり、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配線が必要であるなど、設置コストが非常に高い。

2.2 消費電力計を利用した行動認識手法

家に消費電力計を設置することで家電の稼働状況から行動認識を行う手法が提案されている [3], [4], [11]。中川ら [3] 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種類の行動を 79.7%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 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、といった単純な行動の認識について、90%以上の高精度が達成されている [13]。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 [14] 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、この手法では、ユーザは 5 つのセンサを装着する必要があるため、負担が非常に大きい。

3. ドップラーセンサによる宅内行動認識手法

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、位置非依存行動を含めた生活行動認識を達成するため、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 人による装着負担が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。

要件 2 プライバシー性の低い計測データから人の動き（モーション）を検知できるセンサである。

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。

上記の要件を満たすセンサとして、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、計測データは人の映像や音声といったプライバシー性の高い情報を含まない。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増えるため、この変化が送信波と反射波との差分として表れる。また、ドップラーセンサの検知距離は 6 m 程度と比較的大きい（アナログ出力焦電型赤外線センサの検知距離は 2 m）ため、一つのセンサ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

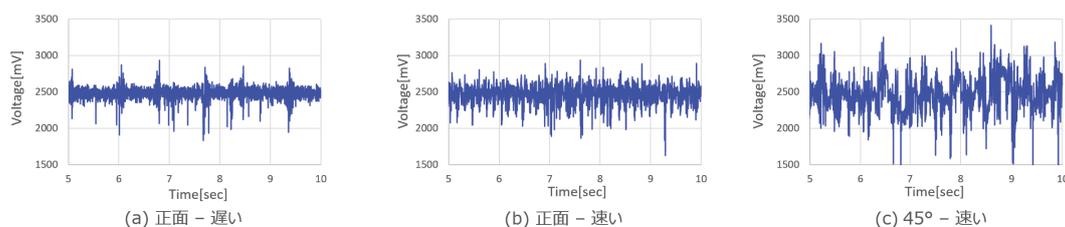


図 1 動き、角度ごとの出力信号の違い

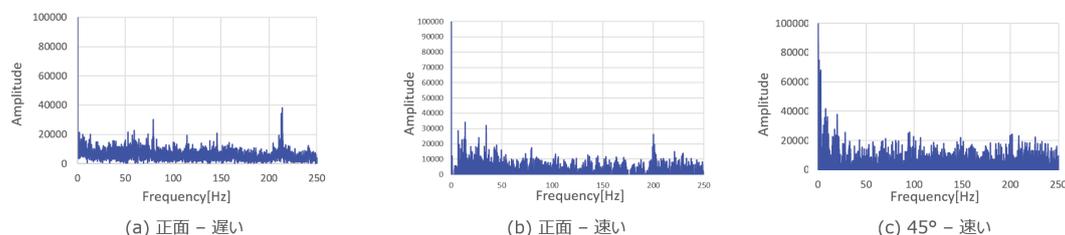


図 2 動き、角度ごとの周波数特性の違い

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

ドップラーセンサの出力信号には人物の動作速度の違いによって周波数が変化するという特性がある。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。

3.3 対象とする行動の選定

先行研究 [7] では、認識対象の行動を、PC 操作、スマートフォン操作、読書の 3 つに絞っていた。しかし、対象行動 3 つでは実用化のためには少なすぎるという問題がある。本研究では、対象の行動の PC 操作を PC タイピング

と PC ブラウジングの 2 つに分け、静止状態、食事、書き作業を新たに加えた。PC 操作をタイピング作業とブラウジングに分割した理由は、PC を操作することによって行う行動は、仕事、ショッピング、動画視聴など、仕事および趣味のどちらも当てはまるため、タイピング作業とブラウジングに分類することによって、仕事による行動であるのか、趣味からくる行動であるのかを分けることができるのではないかと考えたためである。

3.4 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、学習に使用する教師データの取得 (3.3.1 項)、取得したトレーニングデータの特徴量の抽出 (3.3.2 項)、生活行動の学習モデルの構築 (3.3.3 項)、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。

3.4.1 トレーニングデータの取得

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 章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 (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。この時、サンプリング周波数は先行研究 [7] では、100Hz となっているが、これでは取得できる速度は送信周波数が 24GHz だった場合、式 (1) より、約 0.31m/s までに限定されてしまうため、いくつかの行動を正しく取得できない可能性がある。そのため、サンプリング周波数を 500Hz にすることで、より多くの行動を認識できるようにした。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

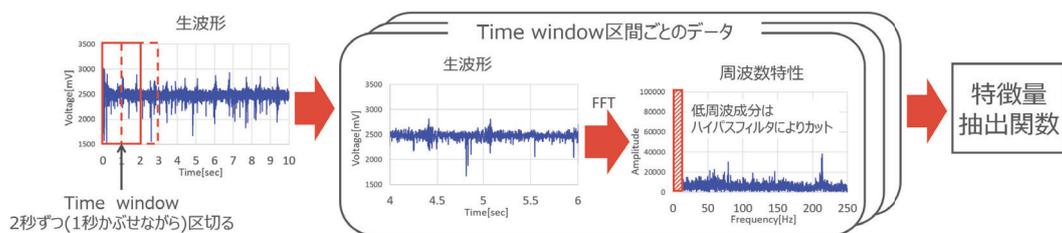


図 3 特数量抽出の概要図

表 1 特徴ベクトルを計算するための関数リスト

特数量抽出関数	説明	数式	種類 (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	$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N \Gamma s_i - \bar{s}^2}$	T, F
mad(s)	Median absolute deviation	$\text{median}_i \Gamma s_i - \text{median}_j \Gamma s_j $	T, F
max(s)	Largest values in array	$\max_i \Gamma s_i$	T, F
min(s)	Smallest value in array	$\min_i \Gamma s_i$	T, F
energy(s)	Average sum of the square	$\frac{1}{N} \sum_{i=1}^N s_i^2$	T, F
sma(s_1, s_2, s_3)	Signal magnitude area	$\frac{1}{3} \sum_{i=1}^3 \sum_{j=1}^N s_{i,j} $	T, F
entropy(s)	Signal Entropy	$\sum_{i=1}^N \Gamma c_i \log \Gamma c_i \Gamma \Gamma, c_i = s_i / \sum_{j=1}^N s_j$	T, F
iqr(s)	Interquartile range	$Q3 \Gamma s - Q1 \Gamma s$	T, F
autorregression(s)	4th order Burg Autoregression coefficients	$a = \text{arburg } \Gamma s, 4 \Gamma, a \in R^4$	T
skewness(s)	Frequency signal Skewness	$E[\frac{s - \bar{s}}{\sigma} \Gamma^3]$	F
kurtosis(s)	Frequency signal Kurtosis	$E[\Gamma s - \bar{s} \Gamma^4] / E[\Gamma s - \bar{s} \Gamma^2]^2$	F
maxFreqInd(s)	Largest frequency component	$\text{argmax}_i \Gamma s_i \Gamma$	F
velocity(s)	Target velocity	$\frac{\text{maxFreqInd} - c}{2f_n \cos \theta}$	F
meanFreq(s)	Frequency signal weighted average	$\sum_{i=1}^N (i s_i \Gamma / \sum_{j=1}^N s_j$	F

N : signal vector length, Q : Quartile, T : Time domain features, F : Frequency domain features.

行ったとしてラベル付けを行った。

3.4.2 特数量の抽出

取得したデータより、対象の行動として設定した7つの行動を認識するための特数量を抽出する。図3に特数量抽出の概要図を示す。まずセンサから得られたデータを一定の時間間隔（以降 Time-window とする）に分割する。次に、各 Time-window 区間ごとにデータから特数量を抽出する。本研究では、経験的に Time-window の大きさを2秒に設定している。2秒間の間に出力された生波形から周波数特性を得るためにFFT（Fast Fourier transform）にかけ、周波数特性を求めている。この時、0Hz付近にノイズが入るが3.2節で説明したようにドップラーセンサは行動の速さに比例して周波数を変化させるため0.5Hz以下の周波数の行動は約0.003m/sと判断できるため0.5Hzのハイパスフィルタによって低周波ノイズの除去を行う。この生波形とハイパスフィルタによって低周波ノイズを除去した周波数特性から特数量を抽出する。表1に特数量抽出関数を示す。これらの関数は、日常行動認識に関する先行研究[8]から有効性が示されている関数に対象者の速度を加えたものとなっている。対象者の速度の算出には、式(1)を使用しており、その行動におけるドップラー周波数として使用する周波数は最も高くピークが出た周波数を表1の関数 maxFreqInd(s) として求めて使用している。

3.4.3 行動学習モデルの構築

測定を行い、ラベル付けしたセンサデータ区間の特数量をトレーニングデータとする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-learnを使用し、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、Random Forestを使用する。

4. ドップラーセンサによるデータ測定システム

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。本章では、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 ドップラーセンサ増幅回路の構成

ドップラーセンサから出力される微弱な信号を増幅させるため、先行研究[7]では、2個の増幅回路に様々なフィルタを使用していたが、それによりマイコン以外の電源が必要となっていた。そこで、今回新しく製作した回路では、非反転増幅回路のみを使用している。これにより、図4に示すように、回路の小型化に成功し、ドップラーセンサを含めた回路すべてをマイコンから供給される電源で動作させることが可能になった。本研究では、非反転増幅回路の倍率を200倍としている。ドップラーセンサにはイノセント社のIPM-165-A01を使用した。このモジュールは、24GHzのマイクロ波を使用しており、先行研究[7]で使用されている新日本無線株式会社のNJR4178Jの10GHzと

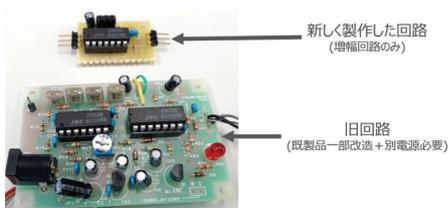


図 4 新しく製作した回路 (上) と旧回路 (下)

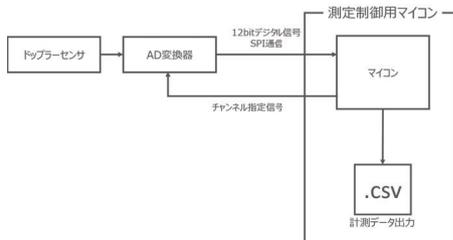


図 5 測定システム概要図

比べ、送信周波数が高くなっている。これにより、式 (1) より対象の速度が変わった場合、周波数により大きな変化が現れるため、認識精度が上がる事が考えられる。

4.2 センサデータ測定システム

提案手法で使用するセンサデータを取得するため、センサデータ測定システムを構築する。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、ドップラーセンサ、A/D 変換器、測定制御マイコンで構成される。測定制御マイコンでは、ドップラーセンサのセンサデータを測定するための測定ソフトウェアが実行されている。このソフトウェアでは最大 500Hz のサンプリングレートでドップラーセンサから出力されるセンサデータを測定し、CSV 形式で出力している。本研究では、A/D 変換器として Microchip Technology 社の MCP3208 を、測定制御マイコンとして Raspberry Pi 3 を使用した。

4.3 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生波形、周波数成分とそこから得られる対象の速度を特徴量とした機械学習による生活行動認識の精度を評価することを目的とする。センサデータから得られたすべてのデータを使用し、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、サンプリング周波数を変化させることによって取得できる対象の速度が変化するかを確認するとともに、サンプリング周波数を変えて同じ行動のデータを取得し、それぞれの生活行動認識モデルを作成し、評価を行う。また、特徴量に式 (1) から求められた対象の速度を特徴量に加えることによって認識精度が変化するかを評価する。

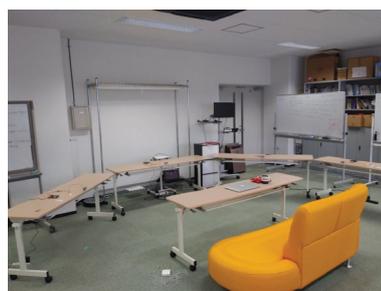


図 6 実験環境

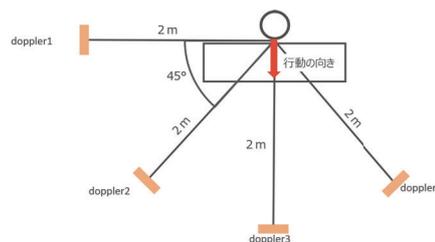


図 7 センサの配置

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、図 6 のような環境で評価実験を行った。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 概要

本実験では、場所非依存行動を対象とし、被験者には指定の場所に座ってもらいその場所で行動をとっている間のセンサ情報を取得した。図 7 に示すように対象から 2m 離れた位置に 4 つのセンサ (doppler 1, 2, 3, 4) を被験者の方向に向けて 45° ずつずらして設置した。これは、対象の行動を様々な角度から取得し、それぞれのセンサーで生活行動認識モデルを作成することでどの行動はどの位置から取得すると認識精度が上がるのか、また周波数特性に同じ行動であっても変化が現れるかを確認するためである。

評価実験では、認識対象の場所非依存行動として、スマートフォンの操作、PC のタイピング、ブラウジング、読書、書く作業、食事と静止状態の計 7 つの生活行動を 5 分間ずつ行ってもらい、1 セッションのデータとした。本評価では、サンプリング周波数を 100Hz にした状態と 500Hz にした状態で成人男性の被験者 3 人を対象に 1 セッションずつデータを収集した。

5.2 特徴量の抽出

取得したデータより、7 種類の対象行動に対して得られたセンサデータを Time-window 区間ごとに分割する。次に、各 Time-window 区間ごとにデータから特徴量を抽出する。本研究では、経験的に Time-window の幅を 2 秒 (サンプリング周波数が 100Hz のデータでは 200 サンプル、500Hz

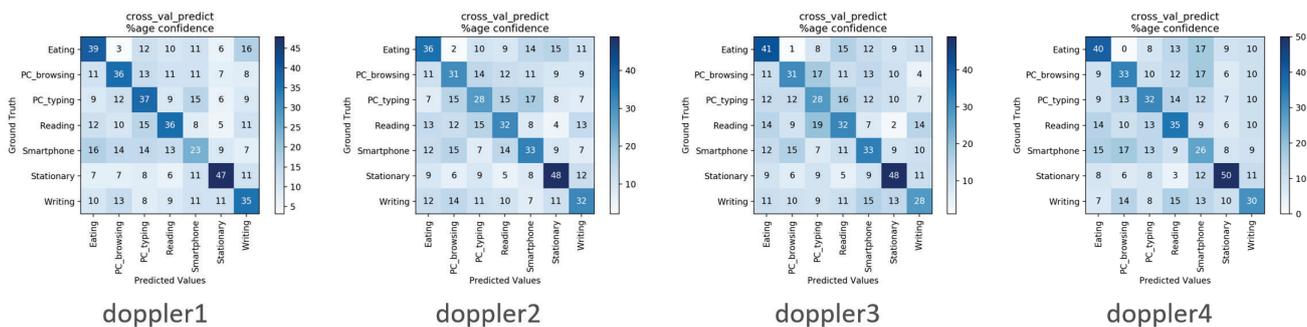


図 8 行動認識の混同行列 ($f_s = 100\text{Hz}$)

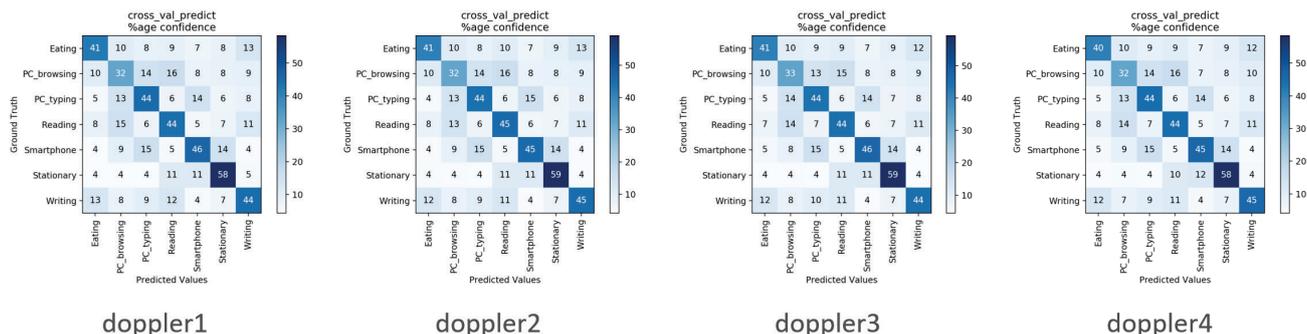


図 9 行動認識の混同行列 ($f_s = 500\text{Hz}$)

表 2 サンプリング周波数 100Hz 時の結果 (doppler 3)

行動	Precision(%)	Recall(%)	F-Score(%)
Eating	41.7	36.7	39.0
PC_browsing	31.3	36.1	33.5
PC_typing	28.1	28.1	28.1
Reading	32.3	31.0	31.6
Smartphone	33.3	32.0	32.7
Stationary	49.0	47.0	48.0
Writing	28.1	32.1	30.0
accuracy	34.8	34.8	34.8
weighted avg	34.8	34.7	34.7

表 3 サンプリング周波数 500Hz 時の結果 (doppler 3)

行動	Precision(%)	Recall(%)	F-Score(%)
Eating	41.3	47.4	44.1
PC_browsing	33.2	35.2	34.2
PC_typing	44.1	42.3	43.2
Reading	44.7	42.4	43.5
Smartphone	47.0	47.6	47.3
Stationary	59.3	52.0	55.4
Writing	44.9	46.8	45.8
accuracy	44.9	44.9	44.9
weighted avg	44.9	44.8	44.8

では 1000 サンプル) に設定している。サンプリング周期による比較を行わない場合は、表 1 に示した関数から速度の関数を抜いた特徴量を用いた場合と、速度を特徴量に加えた場合との比較を行う。

5.3 評価方法

各学習データに対してランダムフォレストを用いて認識モデルを構築し、10 分割交差検証法により評価した。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、以下の式で表す。

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

6. 実験結果

6.1 サンプリング周期の違いによる認識精度の比較

サンプリング周波数を 100Hz, 500Hz に設定し、計測を行い機械学習による行動認識を行った結果をそれぞれ図 8 と図 9 に、正面からその行動を取得した doppler 3 から出力された結果を表 2 と表 3 に示す。サンプリング周波数 100Hz の行動認識モデルでは、「静止状態 (Stationary)」が F 値でみると 48% となっており、平均認識精度は F 値の平均でみると 34.7% となったのに対し、サンプリング周波数 500Hz の行動認識モデルでは、「静止状態 (Stationary)」が F 値でみると 55.4% となっており、平均認識精度は F 値の平均でみると 44.8% と上昇した。これは、サンプリング周波数 100Hz ではすべての行動を正しく計測することができ

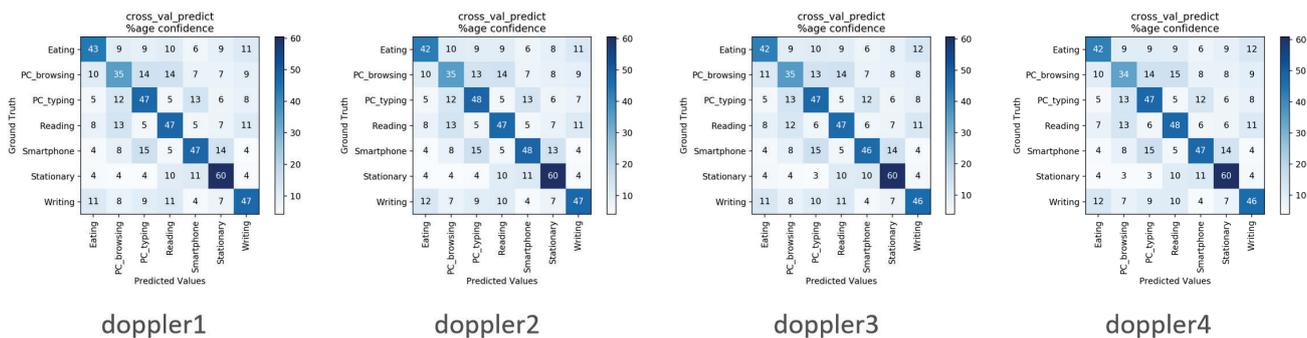


図 10 特徴量に速度を加えた場合の混同行列 ($f_s = 500Hz$)

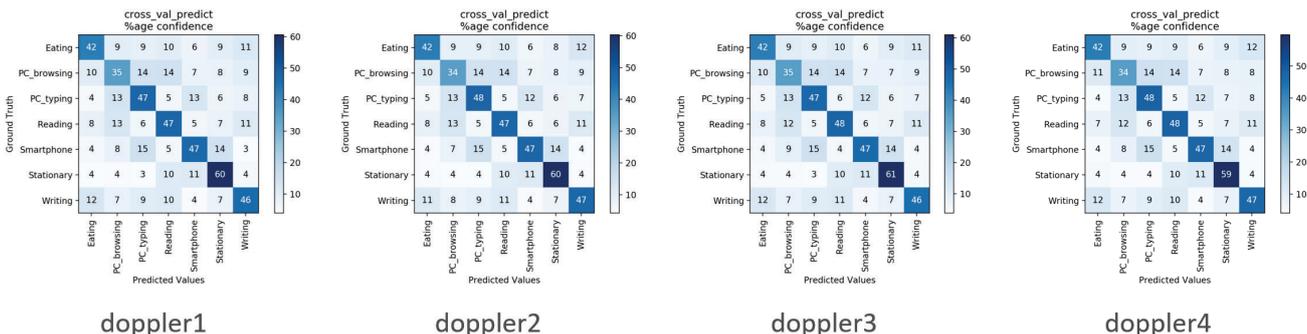


図 11 フィルタ処理および特徴量に速度を加えた場合の混同行列 ($f_s = 500Hz$)

表 4 速度を加えた場合の結果 (doppler 3)

行動	Precision(%)	Recall(%)	F-score(%)
Eating	42.1	47.6	44.7
PC_browsing	35.5	38.4	36.9
PC_typing	47.4	44.2	45.8
Reading	47.1	44.7	45.9
Smartphone	47.0	49.0	48.0
Stationary	60.7	53.5	56.9
Writing	46.5	47.7	47.1
accuracy	46.6	46.6	46.6
weighted avg	46.6	46.5	46.5

表 5 フィルタ処理および速度を加えた場合の結果 (doppler 3)

行動	Precision(%)	Recall(%)	F-Score(%)
Eating	42.5	48.4	45.2
PC_browsing	35.3	37.9	36.5
PC_typing	47.9	45.1	46.4
Reading	48.5	45.7	47.1
Smartphone	47.0	48.5	47.8
Stationary	61.0	53.4	57.0
Writing	46.1	48.4	47.2
accuracy	46.9	46.9	46.9
weighted avg	46.9	46.8	46.8

ず、さらに折り返し雑音によって、遅い行動と速い行動の判別がうまくいかず、「静止状態 (Stationary)」であっても完全に静止できるわけではないため身じろぎなどの影響により、認識精度が落ちたのではないかと考えられる。サンプリング周波数 500Hz であると正しく取得できる速度が上がるため、サンプリング周波数 100Hz と比べて大きく上昇していると考えられる。しかし、サンプリング周波数が 500Hz であっても認識精度は低いままであるのでサンプリング周波数をさらに高める必要があると考えられる。

6.2 対象の速度を加えた認識精度の変化

前節でサンプリング周波数が 100Hz よりも 500Hz に設定すると速度の速い行動が読み取りやすいということが分かったため、サンプリング周波数を 500Hz に固定して計測を行い、速度を特徴量に含めて機械学習による行動認識

を行った。結果を図 10 に、正面からその行動を取得した doppler 3 から出力された結果を表 4 に示す。速度特徴量を使っていない場合 (図 9, 表 3) と比較するとあまり F 値が上がっていないことが分かる。これは FFT で出力を行った際に 0 付近で出力された Amplitude が高くなっており、特定の行動の際に発せられる波形の周波数をうまく取得できていないことが考えられる。そこで FFT で求められた周波数特性にカットオフ周波数 0.5Hz に設定したハイパスフィルタをかけて行動認識を行った。その結果を図 11 と正面からその行動を取得した doppler 3 から出力された結果を表 5 に示す。結果、平均認識精度は F 値の平均を見ると 46.9% となり、向上した。これより、ドップラーセンサの波形から得られる周波数特性から算出した対象の速度を特徴量として加えることによって認識精度を向上させることが分かった。

7. 結論

本研究ではドップラーセンサを使用して出力信号から周波数特性を取得し，Amplitude が最大となった周波数を認識対象行動の速度から出力されたドップラー周波数であるとし，対象の速度を算出し，それを特徴量の一つとして使用した生活行動を認識する手法を提案した．評価実験として「静止状態 (Stationary)」，「スマートフォン操作 (Smartphone)」，「PC タイピング (PC_typing)」，「PC ブラウジング (PC_browsing)」，「読書 (Reading)」，「書き作業 (Writing)」，「食事 (Eating)」の7つの行動を対象として，Random Forest を用いて識別モデルを構築したところ，平均 F-Score : 46.9%で行動を識別することができた．しかし，今回のラベル付けでは動作と動作の間の行動も対象の行動としてラベル付けを行っているため認識精度が落ちたことが考えられる．

今後の予定としてはサンプリング周波数や Time-window の大きさの変更することによって，認識精度のさらなる向上を目指す．今回使用したセンサデータ測定システムでは Raspberry Pi 3 を使用し計測を行っていたが，サンプリング周波数を 500Hz までしか上げることができなかったため，折り返し雑音によって認識精度が落ちたと考えられる．そこで，今回作成した測定システムを見直し，よりノイズに強い増幅回路の作成を行い，Arduino Mega を組み合わせることによってさらにサンプリング周波数を上げることが可能なシステムの開発を行い，異なるサンプリング周波数で認識精度を比較し，最適なサンプリング周波数の設定を行う予定である．また，生活行動認識に有効な特徴量の選択も試み，角度による周波数の変化を補正することが可能なシステムの開発を行い，角度に依存しない行動認識モデルの構築を行う予定である．さらに，STFT (Short-Time Fourier Transform) や Wavelet 解析など新たな信号処理手法や，CNN などの深層学習を用いることで，認識精度の向上が行えるか検討していく．

謝辞 本研究の一部は，科研費基盤研究 (C)(No.16K00126) および Society 5.0 実現化研究拠点支援事業の助成によって行った．

参考文献

- [1] 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. *SIG-SAI*, Vol. 34, No. 1, pp. 1-8, mar 2019.
- [2] Y. Umetsu, Y. Nakamura, Y. Arakawa, M. Fujimoto, and H. Suwa. Ehaas: Energy harvesters as a sensor for place recognition on wearables. In *2019 IEEE International Conference on Pervasive Computing and Communications (PerCom)*, pp. 1-10, March 2019.
- [3] 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.
- [4] 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.
- [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, feb 2017.
- [6] Yukitoshi Kashimoto, Kyoji Hata, Hirohiko Suwa, Manato Fujimoto, Yutaka Arakawa, Takeya Shigezumi, Kunihiko 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.
- [7] 藤原聖司, 藤本まなど, 荒川豊, 安本慶一. 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. *行動変容と社会システム vol.03*, 第 2018 巻, mar 2018.
- [8] 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.
- [9] 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.
- [10] 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.
- [11] 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.
- [12] Kazushige Ouchi and Miwako Doi. Smartphone-based monitoring system for activities of daily living for elderly people and their relatives etc. In *Proceedings of the 2013 ACM Conference on Pervasive and Ubiquitous Computing Adjunct Publication, UbiComp '13 Adjunct*, pp. 103-106, New York, NY, USA, 2013. ACM.
- [13] 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.
- [14] Ling Bao and Stephen S Intille. Activity recognition from user-annotated acceleration data. In *International conference on pervasive computing*, pp. 1-17. Springer, 2004.