

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

三崎 慎也^{1,a)} 馬越 圭介¹ 松井 智一¹ Hyuckjin Choi¹ 藤本 まなと¹ 安本 慶一¹

概要：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。しかし、従来の焦電型赤外線センサや電力計などの設置型センサを使用した研究では、センサを様々な場所に設置する必要があり、コストが掛かる（課題 1）。また、「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、いわゆる、場所非依存行動を正確に検出・認識することは難しい（課題 2）。ウェアラブルデバイスを使用する手法では、被験者に装着負担が生じるといった課題があり（課題 3）、カメラを使用した手法では、プライバシー侵害が課題となる（課題 4）。本研究では、課題 1 から課題 4 の全てを解決することを達成するため、生活行動ごとの動作速度の違いを取得し、それらを特徴量に加えることで、場所非依存行動を認識できる手法を提案する。具体的には、ドップラーセンサから得られたデータから周波数特性を取得し、最も振幅値の大きい周波数を用いて動作速度を算出する。提案手法の有効性を示すため、被験者 10 人の異なる 6 つの行動（スマートフォン操作、PC 操作、読書、書き作業、食事、静止）を 5 セッションに分けてセンサデータを収集した。その後、それらのデータから行動認識モデルを構築し、リーブワンセッションアウトの交差検証とリーブワンパーソンアウトの交差検証によって評価した。その結果、リーブワンセッションアウトの交差検証では、被験者の中で最も高かった平均認識精度は、95.7%となり、被験者 10 人の平均は 81.0%となった。リーブワンパーソンアウトの交差検証で、同じ行動でも人によって動作方法が大きく異なり、動作速度に応じた周波数を出力するドップラーセンサの特性から平均認識精度は、42.1%と低くなった。

キーワード：生活行動認識、ドップラーセンサ、機械学習

A Non-contact Activity Recognition Method Using Doppler Sensors in Indoor Environments

SHINYA MISAKI^{1,a)} KEISUKE UMAKOSHI¹ TOMOKAZU MATSUI¹ HYUCKJIN CHOI¹
MANATO FUJIMOTO¹ KEIICHI YASUMOTO¹

1. はじめに

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、人の行動を認識する研究が多く取り組まれている。ユビキタスコンピューティングの行動認識

の分野において、主に扱われる屋内コンテキスト情報は、ユーザの位置や行動、ドアの状態、使用電力による家電操作等である。これらの屋内コンテキスト情報を使用した行動認識システムによって、QoL (Quality of Life) 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ている。そのため、一般家庭への普及を考慮すると、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。

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

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

宅内における生活行動認識に関する研究は、これまで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。この手法では、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。しかし、位置情報や消費電力を取得するには、大量のセンサを設置する必要があるため、コストが掛かる(課題1)。また、読書やスマートフォン操作などの家電を必要としない、どの場所でも起こりうる行動(場所非依存行動)の認識精度は28.0%と低く、正確に認識することが難しい(課題2)。

課題2を解決するためのアプローチの一つとして、生活行動時に発生するモーションの違いを利用する手法が挙げられる。Laraら [3] は、4つの行動(歩く・座る・走る・寝る)を、ウェアラブルデバイスを用いて加速度データを収集・解析することで、90.0%以上の精度で認識できることを示している。しかし、これらの手法では、ユーザは、センサを装着する必要があるため、負担が大きい(課題3)。

また、Uddinら [4] は、カメラ映像と画像処理により生活行動を認識する手法を提案しており、スマートホームにおいて、5つの行動を96.5%の精度で認識できることを示している。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」という不安感を与える可能性が高く、プライバシーを侵害する恐れがある(課題4)。

本研究では、課題1から課題4を解決するため、ドップラーセンサを用いた生活行動認識手法を提案する。ドップラーセンサは、送信波と受信波の位相差が対象の移動速度に応じた周波数となるセンサであり、動体検知センサの中でも検出距離が10m程度と比較的長いことが知られている。したがって、ドップラーセンサの出力信号と周波数成分を解析することで、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認識できる。周波数成分は、ある時間区間の信号にFFT(Fast Fourier Transform)を適用することによって収集する。

提案手法では、ドップラーセンサの出力信号と周波数成分に対して、関連研究で報告されている特徴量 [5] と対象の移動速度を抽出し、機械学習によって生活行動を認識する。その結果、行動系列をいくつかのセッションごとに分けて評価する、リーブワンセッションアウトの交差検証では、被験者の中で最も高くなった平均認識精度は95.7%となり、被験者10人の平均は81.0%となった。各行動を被験者ごとに分けて評価する、リーブワンパーソンアウトの交差検証では、平均認識精度は42.1%となった。

2. 関連研究

2.1 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], [6], [7]。カメラを用いた多くの行動認識手法では、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、カメラ映像と画像処理により、スマートホーム内の生活行動認識手法を提案している。シミュレータと深度カメラの情報を利用し、歩行や料理、横になるなどの5つの行動を96.5%の精度で認識できる。

Pirsiavashら [7] は、一人称カメラ映像を用いた行動認識を提案している。被験者20人にウェアラブルカメラ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、教師ラベル付き画像データベースであるImageNet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。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、物体認識が正確であると仮定すると、77.0%の精度で行動認識が可能であると示している。

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。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配線が必要である等、設置コストが高い。

2.2 ウェアラブルデバイスを使用した行動認識

ウェアラブルデバイスを用いて行動認識を行う手法も多数提案されている。 [3], [8], [9], [10]。Baoら [8] は、被験者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、仕事などを含む計8種類の生活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決定木を使用した結果、84.0%の精度で生活行動を認識できることを示している。

Espinillaら [9] は、被験者としてアルスター大学の学生141人の右手首、左手首に三軸加速度センサを装着し、6種類のシナリオを認識するモデルを構築している。サンプリングレートを51.2Hzとしてデータ収集を行い、平均、最大値、最小値など一般的な特徴量を含む計27種類の特徴量を抽出している。学習アルゴリズムは、単純ベイズ、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(SVM)を採用し、10分割交差検証によって評価している。この結果、k近傍法を用いた場合が最も精度が高く、93.7%での認識を達成している。

Amftら [10] 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、マイクを耳に装着する、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、食べ物や口を持っていくジェスチャーを認識し、耳に装着したマイクでは、咀嚼音を検知することで被験者が現在何を食べているのかまでを識別で

き、詳細な食事行動の認識を行うことが可能となっている。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ため、長期間行われる生活行動認識には適していない。

2.3 タグレス行動認識

各種家電の使用情報やセンサから得られた位置情報を使用することで行動認識を行う手法が多数提案されている。中川ら [1] は、超音波高精度屋内位置測位システムと消費電力計を利用し、ユーザの位置情報と消費電力を収集している。それらに対して、特徴を抽出し、機械学習モデルを構築している。その結果、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79.7%の精度で認識できることを示している。しかし、この認識手法では、特定の場所で行われる行動もしくは電力を消費する行動は、精度が高くなるが、それ以外の行動は精度が低くなる。特に、不特定の場所かつ電力を消費しない読書やスマートフォン操作などの行動は認識精度が低くなるという課題がある。

Kasterenら [11] 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、朝食、昼食、夕食、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最も精度が高かった外出が98%、最も精度の低い朝食行動が49%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 [12] は、近接センサ、人感センサ、傾斜センサ、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 [13] は、複数の焦電型赤外線センサを部屋の天井に設置し、歩行、起立、着席などの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、歩行や着席、脚振りなど、比較的動きの大きい行動は容易に認識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、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ない。

2.4 ワイヤレスセンシング機器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 [12], [14], [15], [16], [17]。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。動的時間伸縮法 (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、手を下げる、転ぶ、歩く、回る、起き上がる）を93.5%の精度で認識できる。

Kelloggら [19] 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フリックやプッシュなどの8つのジェスチャーを取得し、平均で97.0%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タグを身体に装着する必要があるため、ユーザに装着負担を与えてしまう。

Wangら [20] は、1つのアクセスポイントと少数のWiFiデバイスを設置し、デバイスフリーでリビングから浴室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。しかし、WiFiを使用したシステムでは、体の大きな動きを取得することはできるが、指の細かい動きを取得するには、被験者の近くに設置する必要がある。

3. 提案システム

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。

3.1 ドップラーセンサ出力信号増幅回路

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1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へと変更した。これにより、従来の回路 [21] で使用されていたNJM2902の入力換算雑音電圧 $430nV\sqrt{Hz}$ が、オペアンプを変更したことによって入力換算雑音電圧が $10nV\sqrt{Hz}$ となり、低くなった。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、バイパス回路や増幅回路、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




図 1 増幅回路の概要図

り出力として 5V/3.3V 出力付きリチウムイオン電池充電器を使用する。

3.2 ドップラーセンサ測定システムの構成

ドップラーセンサの出力周波数を f_d とし、対象の移動速度を 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られることができる。

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

今回使用するドップラーセンサの送信周波数 f_0 は 24 GHz 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。しかし、Raspberry Pi3 の処理能力は低いため、サンプリングレートを 500 Hz 以上に上げることができないため、本研究では、測定用マイコンとして Arduino Mega を使用し、データロガーとして Raspberry Pi3 を利用する。図 2 に測定システムの概要図を示す。Arduino Mega は、Raspberry Pi3 よりもサンプリングレートが高い、1 kHz でデータ測定が可能である。

3.3 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。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。

3.3.1 トレーニングデータ取得

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、3.2 節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、対象の 6 種類の行動（静止、スマートフォン操作、PC 操作、読み書き、食事）の測定を行った。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




図 2 測定システム概要図

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。

3.3.2 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。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 1 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 [5] から有効性が示されている関数に No.14 と 15 の関数、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。

3.3.3 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 のオープンソース機械学習ライブラリである、Scikit-learn*1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: エキストラツリー, 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. 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 3 に示すようにセンサを設置し、評価実験を行った。以下に評価実験の目的と実験結果について述

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

表 1 特徴ベクトルを計算するための関数リスト

No.	Feature extraction function	Description	Formula	Type (T: Time, F: Freq.)
1	mean(s)	Arithmetic mean	$\bar{s} = \frac{1}{N} \sum_{i=1}^N s_i$	T, F
2	std(s)	Standard deviation	$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (s_i - \bar{s})^2}$	T, F
3	mad(s)	Median absolute deviation	$\text{median}_i(s_i - \text{median}_j(s_j))$	T, F
4	max(s)	Largest values in array	$\max_i(s_i)$	T, F
5	min(s)	Smallest value in array	$\min_i(s_i)$	T, F
6	energy(s)	Average sum of the square	$\frac{1}{N} \sum_{i=1}^N s_i^2$	T, F
7	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
8	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
9	iqr(s)	Interquartile range	$Q3(s) - Q1(s)$	T, F
10	autorregression(s)	4th order Burg Autoregression coefficients	$a = \text{arburg}(s, 4), a \in R^4$	T
11	skewness(s)	Frequency signal Skewness	$E[(\frac{s-\bar{s}}{\sigma})^3]$	F
12	kurtosis(s)	Frequency signal Kurtosis	$E[(\frac{s-\bar{s}}{\sigma})^4] / E[(\frac{s-\bar{s}}{\sigma})^2]^2$	F
13	maxFreqInd(s)	1st to 4th Largest frequency component	$\text{argmax}_i(s_i)$	F
14	velocity(s)	Target velocity(using value of 1st to 4th Largest frequency component)	$\text{maxFreqInd} \cdot c/2f_0 \cos \theta$	F
15	maxFreqInd_area(s)	Largest frequency component In the specified frequency band	$\text{argmax}_i(s_i)$	F
16	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(10000 samples)




図 3 実験概要図

べる。

4.1 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 1 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、リーブワンセッションアウトの交差検証と、リーブワンパーソンアウトの交差検証による認識精度を評価した。リーブワンセッションアウトの交差検証では、ドップラーセンサが実際に被験者の細かい動きを取得し、認識を行えるかを評価した。リーブワンパーソンアウトの交差検証では、人間の行動には個人差が存在するため、同じ行動であっても動作速度が違う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を評価するために行った。

4.2 実験結果

4.2.1 リーブワンセッションアウトの交差検証

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リーブワンセッションアウトの交差検証によって評価した。図 4 に認識精度を棒グラフで比較したものを、図 5 にすべての被験者の各行動の平均認識精度を示す。図 4 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 ID2 の平均認識精度が最も高く、95.7%となった。図 5 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 6 の平均認識精度が最も低かった ID6 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。

4.2.2 リーブワンパーソンアウトの交差検証

複数の分類器を使用して、構築した認識モデルをリーブワンパーソンアウトの交差検証によって評価した。図 7, 8 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。リーブワンセッションアウト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くなった。図 9 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。これは食べ物を口に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。

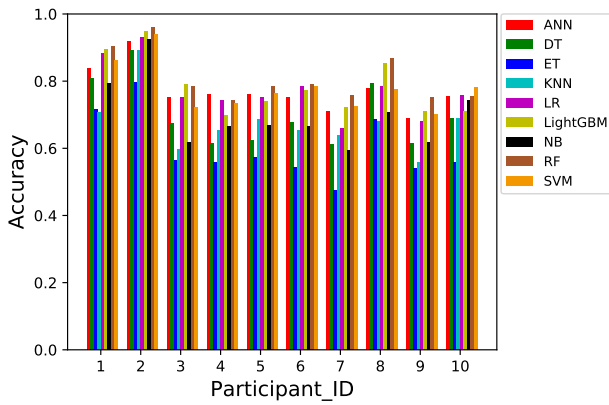


図 4 各被験者ごとの行動認識精度

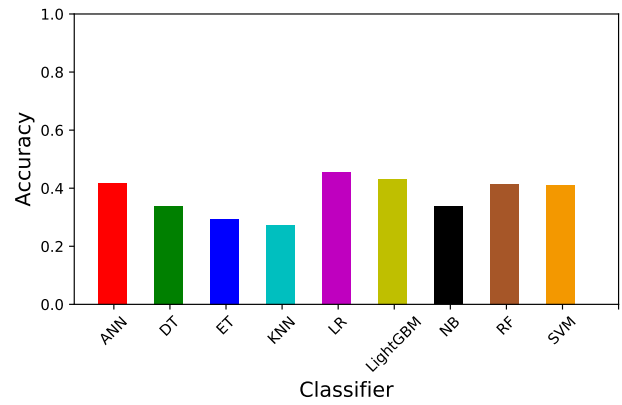


図 7 各分類器ごとの行動認識精度 (リーブワンパーソンアウト)




図 5 各行動ごとの認識精度 (リーブワンセッションアウト)




図 8 各行動ごとの認識精度 (リーブワンパーソンアウト)

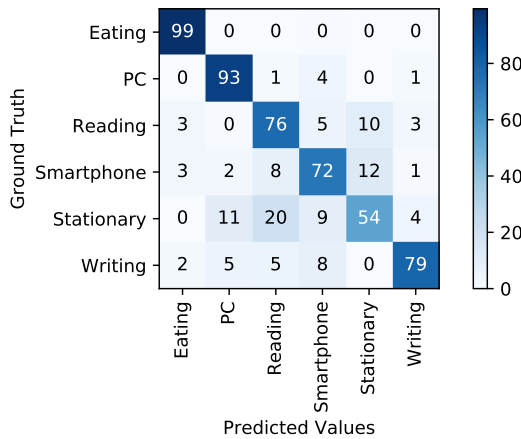


図 6 ID6 の混同行列




図 9 ロジスティック回帰の混同行列

5. 結論

本論文では, Anguita[5] らによって日常行動認識で有効性が示された関数と, ドップラーセンサで計測されたデータから算出される対象の移動速度を用いた生活行動認識手法を提案した. 評価実験では, 被験者 10 人对象行動である静止, スマートフォン操作, PC 操作, 読書, 書き作業, 食事の 6 つの行動を行ってもらい, 測定したデータから特徴量を抽出し, 複数の分類器によって認識モデルを構築した. そしてリーブワンセッションアウトの交差検証と

リーブワンパーソンアウトの交差検証によって評価を行った. その結果, リーブワンセッションアウトの交差検証では, 最大平均認識精度は 95.7% となり, 被験者全員の平均認識精度は 81.0% となった. 一方, リーブワンパーソンアウトの交差検証では, 平均認識精度は 42.1% と低くなった. また, どちらの交差検証でも食事行動の認識精度が高く, それ以外の行動は低くなった. 食事行動は腕の動きが大きく, 人によってあまり差が出なかったため, 認識精度が高くなり, 他の行動は腕の動きよりも小さい指の細かい動きを取る必要があり, さらに, 被験者によって差がやすい

行動であったため認識精度が低くなったと考えられる。

今後の研究では、センサデータに STFT(Short-Time Fourier Transform) を適用し、ヒートマップにすることで画像化を行う。その後、CNN(Convolutional Neural Network) を用いて行動認識モデルを構築し、センサの位置に依存しない行動認識システムの構築が行えるか検討する。さらに、評価実験では、ユーザの位置を固定してデータ収集を行ったが、ユーザの位置が変化した場合でも、行動認識を行えるシステムの構築を行っていききたい。

謝辞

本研究の一部は、JSPS 科研費 JP20H04177 および JP19H05665 の助成を受けたものです。

参考文献

- [1] Nakagawa, E., Moriya, K., Suwa, H., Fujimoto, M., Arakawa, Y., Hatta, T., Miwa, S. and Yasumoto, K.: Investigating Recognition Accuracy Improvement by Adding User's Acceleration Data to Location and Power Consumption-based In-home Activity Recognition System, *Adjunct Proceedings of the 13th International Conference on Mobile and Ubiquitous Systems: Computing Networking and Services, MOBIQUITOUS 2016*, ACM, pp. 100–105 (online), DOI: 10.1145/3004010.3004036 (2016).
- [2] Nakagawa, E., Moriya, K., Suwa, H., Fujimoto, M., Arakawa, Y. and Yasumoto, K.: Toward real-time in-home activity recognition using indoor positioning sensor and power meters, *2017 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)*, IEEE, pp. 539–544 (2017).
- [3] 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 (online), DOI: 10.1109/SURV.2012.110112.00192 (2013).
- [4] 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 (online), DOI: 10.1145/2641483.2641537 (2014).
- [5] Anguita, D., Ghio, A., Oneto, L., Parra, X. and Reyes-Ortiz, J. L.: A public domain dataset for human activity recognition using smartphones., *Esann* (2013).
- [6] Hoey, J. and Little, J. J.: 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 (online), DOI: 10.1109/TPAMI.2007.1145 (2007).
- [7] Pirsiavash, H. and Ramanan, D.: Detecting activities of daily living in first-person camera views, *2012 IEEE Conference on Computer Vision and Pattern Recognition*, IEEE, pp. 2847–2854 (2012).
- [8] Bao, L. and Intille, S. S.: Activity recognition from user-annotated acceleration data, *International conference on pervasive computing*, Springer, pp. 1–17 (2004).
- [9] Espinilla, M., Medina, J., Salguero, A., Irvine, N., Donnelly, M., Cleland, I. and Nugent, C.: Human Activity Recognition from the Acceleration Data of a Wearable Device. Which Features Are More Relevant by Activities?, *Multidisciplinary Digital Publishing Institute Proceedings*, Vol. 2, No. 19, p. 1242 (2018).
- [10] Amft, O. and Troster, G.: On-body sensing solutions for automatic dietary monitoring, *IEEE pervasive computing*, Vol. 8, No. 2, pp. 62–70 (2009).
- [11] Kasteren, T. L., Englebienne, G. and Kröse, B. J.: An Activity Monitoring System for Elderly Care Using Generative and Discriminative Models, *Personal Ubiquitous Comput.*, Vol. 14, No. 6, pp. 489–498 (online), DOI: 10.1007/s00779-009-0277-9 (2010).
- [12] Chen, L., Xiong, J., Chen, X., Lee, S. I., Zhang, D., Yan, T. and Fang, D.: 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 (online), DOI: 10.1145/3351237 (2019).
- [13] Luo, X., Liu, T., Shen, B., Hong, J., Chen, Q. and Chen, H.: Human Daily Activity Recognition Using Ceiling Mounted PIR Sensors, *Proceedings Of The 2nd International Conference on Advances In Mechanical Engineering and Industrial Informatics (AMEII 2016)*, Vol. 73, p. 872 (2016).
- [14] Laput, G. and Harrison, C.: 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 (online), DOI: 10.1145/3328926 (2019).
- [15] Xiao, N., Yang, P., Li, X.-Y., Zhang, Y., Yan, Y. and Zhou, H.: 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 (online), DOI: 10.1145/3351270 (2019).
- [16] Zhang, F., Niu, K., Xiong, J., Jin, B., Gu, T., Jiang, Y. and Zhang, D.: 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 (online), DOI: 10.1145/3314420 (2019).
- [17] Zeng, Y., Wu, D., Xiong, J., Yi, E., Gao, R. and Zhang, D.: 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 (online), DOI: 10.1145/3351279 (2019).
- [18] Wang, Y. and Zheng, Y.: Modeling RFID Signal Reflection for Contact-free Activity Recognition, *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.*, Vol. 2, No. 4, pp. 193:1–193:22 (online), DOI: 10.1145/3287071 (2018).
- [19] Kellogg, B., Talla, V. and Gollakota, S.: Bringing gesture recognition to all devices, *11th {USENIX} Symposium on Networked Systems Design and Implementation ({NSDI} 14)*, pp. 303–316 (2014).
- [20] Wang, Y., Liu, J., Chen, Y., Gruteser, M., Yang, J. and Liu, H.: E-eyes: device-free location-oriented activity identification using fine-grained wifi signatures, *Proceedings of the 20th annual international conference on Mobile computing and networking*, pp. 617–628 (2014).
- [21] 慎也三崎, 圭介馬越, まなと藤本, 慶一安本: 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, pp. 76–83 (2019).