

周波数帯強調フィルタとモデルアンサンブルを用いた センサベースの行動認識

堤日向¹ 武中紘輝¹ 小林慧^{1,2} 近藤圭¹ 長谷川達人¹

概要: センサベースの行動認識では深層学習手法が多く利用され、認識精度向上に貢献している。モデルの入力には主に加速度やジャイロセンサを用いるが、加速度センサデータを周波数スペクトルに変換して用いることもある。しかし、周波数特性に着目したデータ拡張はこれまで深く議論されていない。本研究では行動認識における各行動を推定する際に重要な周波数を強調するフィルタとアンサンブル学習を用いた行動認識手法を提案する。提案手法の実現に向け、加速度センサデータに対し一部の周波数帯をマスクし、そのデータを用いて精度を比較することで各行動の重要な周波数を実験的に明らかにした。提案手法の有効性を示すために、訓練時の強調フィルタの有無、テスト時の強調フィルタの有無、アンサンブルの有無を組み合わせることで精度を比較した。その結果、訓練時とテスト時に周波数帯強調フィルタを適用し予測結果をアンサンブルすることで認識精度が最も高くなり、提案手法の有効性を示した。

キーワード: 周波数強調, アンサンブル学習, 深層学習

Using Frequency Band Enhancement Filters and Model Ensembles for Sensor-based Human Activity Recognition

HYUGA TSUTSUMI^{†1} KOKI TAKENAKA^{†1} SATOSHI KOBAYASHI^{†1,2}
KEI KONDO^{†1} TATSUHITO HASEGAWA^{†1}

Abstract: Deep learning methods are widely used in sensor-based activity recognition, contributing to improved recognition accuracy. Acceleration and gyro sensors are mainly used as input to the model, and sometimes accelerometer data is converted to a frequency spectrum. However, data augmentation focusing on frequency characteristics has not been deeply discussed. This study proposes an activity recognition method that uses an ensemble learning and filters that emphasize the frequencies important for estimating each activity. In order to realize the proposed method, we experimentally revealed the important frequencies of each behavior by masking some frequency bands in the accelerometer data and comparing the accuracy using the masked data. To demonstrate the effectiveness of the proposed method, we compared the accuracy of the method with and without enhancement filter during training, with and without enhancement filter during testing, and with and without ensemble learning. The results showed that applying the frequency band enhancement filter during training and testing and ensemble achieved the highest recognition accuracy, indicating the effectiveness of the proposed method.

Keywords: Frequency emphasis, Ensemble learning, Deep learning

1. はじめに

近年、スマートフォンやウェアラブル端末の普及によりユーザの動作をセンシングすることが容易になってきている。これらの端末は時系列センサデータとして、加速度やジャイロのデータを計測することができ、センサデータから行動を予測する行動認識が盛んに研究されている。行動認識は人々の健康状態の判定などに応用することができる[1]。将来の充実したサービス応用に向け、より詳細な行動を、より正確に認識できることが望まれている。例えば、西垣ら[2]はシャワーヘッドに取り付けた3軸加速度や3軸ジャイロセンサの時系列データを用いて浴室内の行動認識を行っている。この研究では「シャンプーを洗い流す」や、「ボディソープを洗い流す」などの詳細な行動を分類し、シャンプーの洗い残しの検出に応用している。

時系列センサデータを周波数領域に変換して行動認識

を行う研究もある。Sikderら[3]は加速度やジャイロセンサのデータを周波数スペクトルとパワースペクトルに変換し、CNN (Convolutional Neural Network)の入力とすることで6種類の行動を分類している。この研究ではモデルの入力として周波数スペクトルを利用し、認識精度の評価を行っているが、行動ごとの周波数特性についての考察は行われていない。行動の周波数特性に着目した研究もいくつかある。大上ら[4]は加速度データをパワースペクトルに変換し歩行パターンの違いによる周波数特性を検証している。通常の歩行と足を引きずって歩いた場合で周波数特性が異なることを明らかにしている。したがって、行動認識においても各行動の周期が異なると考えられ、各行動の予測には重要な周波数が存在する可能性がある。Minhao LIUら[5]の研究では入力されたデータのパワースペクトルの解析を行い、主要な周波数帯を求め、時系列信号解析のための木構造ウ

¹ 福井大学大学院工学研究科

^{†1} Graduate School of Engineering, University of Fukui

² (株)キーウォーカー(現職)

^{†2} Keywalker Ltd.

エーブレットニューラルネットワーク T-WaveNet を提案しているが、入力データに対し周波数を強調するような処理は行われていない。

本研究では、(1)各行動を予測する際の重要な周波数を求め、(2)各周波数を強調するフィルタを入力に適用し、(3)訓練時とテスト時にアンサンブル学習を行う行動認識手法を提案する。周波数強調とアンサンブルによる汎用的な手法により、行動認識の推定精度を向上させ、様々な行動認識サービスの展開を促進させることが本研究の目的である。

3. 関連研究

3.1 センサベースの行動認識

センサベースの行動認識では CNN を用いる手法やアンサンブル学習を用いる手法など様々な手法が存在する。佐藤ら[6]は腕時計型の生体情報センサから得られる2次元加速度のデータを用いて「歩く」、「走る」、「立ち止まる」、「デスクワーク」という基本行動を識別する決定木を構築し、高精度の行動推定が可能であることを示した。決定木を構築するために、2次元加速度のデータの平均値や標準偏差など、10種類の特徴量を使用している。北村ら[7]はスマートフォンの3軸加速度センサのデータを1次元信号のまま入力し、1次元CNNによって行動認識精度向上を図っている。2層の畳み込み層と1層のプーリング層、1層の全結合層から構成されるモデルを採用している。伊藤ら[8]は加速度センサやジャイロセンサのデータに対してフーリエ変換の処理を行い、スペクトラム画像を作成しCNNモデルの入力として行動認識を行っている。モデルは3層の畳み込み層と3層のプーリング層があり、加速度センサ、ジャイロセンサのスペクトログラム画像の特徴を統合した後に3層の全結合層で分類を行っている。また、時間方向の畳み込みと周波数方向の畳み込みのサイズを変えながら精度を比較することで最良の畳み込みサイズを求めている。Abdulhamit Subasiら[9]はアンサンブル学習を用いて7種類の行動を分類している。Random Forest や SVM(Support Vector Machine)などの手法で行動認識を行った場合と、それらの手法と Adaboost を併用して行動認識を行った場合で認識精度を比較し、Random Forest と Adaboost を併用することで最も認識精度が高くなることを示している。

これらの研究は入力として加速度やジャイロセンサから得られるデータを用いたり、スペクトログラム画像を用いて認識精度の評価を行ったりしているが、行動ごとの特性を利用したデータを用いた研究は行われていない。

3.2 行動認識における周波数特性

行動の周波数特性を活用した研究には次のようなものが挙げられる。吉村ら[10]は行動認識モデルの分析を行うために勾配上昇法を用いてニューラルネットワーク中の各ユニットの出力が最も大きくなる入力信号を求めている。さらに、人間の動作の周波数が比較的低いことに着目し、

行動認識モデルの分析を行いやすくするためにハイパスフィルタを用いた正則化を行い、高周波数成分が少ない行動認識モデルに適した信号を生成している。吉澤ら[11]は加速度センサデータから行動の変化点の検出を行っている。行動の変化点検出において、動きのある行動から別の行動に移る変化点を検出する際に IIR バンドパスフィルタを用い、各成分の変動の総和が一定値を超えたときに変化点であるとみなしている。また、IIR バンドパスフィルタのフィルタ数や通過周波数を求めるために変化点検出手法で用いるケプストラム係数を変化させることでどの周波数の信号が重要かを調べている。藤原ら[12]はドップラーセンサを用いた行動認識を行っている。生活行動認識モデルの構築に使用する特徴量としてドップラーセンサのデータに対し STFT (Short-Term Fourier Transform) を適用し、周波数成分を算出している。さらに特徴量の次元削減のために、周波数成分の一部のみを使用している。このとき、高周波成分や低周波成分を削減しながら認識精度の変化を調べることで削減する周波数成分を求めている。その結果、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 に制限した場合に認識精度が最も良くなることがわかっている。

これらの研究のように行動認識における重要な周波数があることは明らかになっているが、モデルの分析や特徴量の削減のために用いられていることが多く、行動認識の精度向上に応用している研究は少ない。

3.3 アンサンブル学習を用いた行動認識

アンサンブル学習を用いて行動認識を行う研究として、Irvine ら[13]はスマートハウス内の日常生活動作の認識において、ニューラルネットワークのアンサンブル学習手法を提案している。K 近傍法や SVM と認識精度を比較することで提案手法の有効性を示している。Zhu ら[14]は7種類の行動の分類において2つのCNNモデルでのアンサンブルを行っている。始めに7クラスを分類するモデルで予測を行い、その結果が特定の2種類であった場合に2クラスを分類する別のモデルで予測を行う。その後、2つのモデルの出力に対して Weighted Voting を行うことで最終的な出力としている。複数のデータ拡張を入力データに適用してアンサンブル学習により行動認識を行う手法[15]もあるが、周波数特性に着目したデータ拡張は行われていない。

3.4 本研究の立ち位置

関連研究で述べたように、加速度データを周波数スペクトルに変換して行動認識を行っている研究はあるが、多くは周波数スペクトルを入力として扱う手法にとどまっている。以上を踏まえて、本研究の貢献は以下のとおりである。

- 行動認識 HASC[16]データセットにおいて各行動の重要な周波数を実験的に明らかにした。
- 各行動の重要な周波数を強調するようなフィルタを作成し、訓練データとテストデータに適用し、予測結

果のアンサンブルを行うことで、行動認識推定精度を向上させる手法を新たに開発した。

4. 提案手法

提案手法の概要を図1に示す。本手法は各行動の重要な周波数帯を求め、求めた周波数帯を強調するようなフィルタを作成し、元のデータにフィルタを適用することで行動認識の精度向上を図っている。本手法は以下の3つのフェーズで構成されている。各詳細は次節以降で説明する。

- 各行動の重要な周波数を求めるフェーズ
- 訓練時強調フェーズ
- テスト時強調フェーズ

4.1 各行動の重要な周波数を求めるフェーズ

各行動の重要な周波数を求めるフェーズにおいて、各行動の重要な周波数は以下のように求めた。

1. 一般的な行動認識と同様に元の加速度センサのデータ x_{train} を用いて CNN モデル M を訓練する。
2. x_{train} と異なる被験者の加速度のデータ x_{valid} に対し、式(1)の f を $(0, f_s/2]$ の間で変化させて一部の周波数をマスクする。

$$F_m(x, f) = T^{ifft} \left(M(T^{fft}(x), f) \right) \quad (1)$$

3. 1. で訓練したモデル M を用いて、2. でマスクしたデータの推定精度の変化を調べる。
4. 3. を行動 c ごとに行い、強調対象周波数帯集合 $\mathcal{F} = \{f^c | c \in \mathcal{C}\}$ を求める (図1上段)。

なお、 $x \in \mathbb{R}^{3 \times w}$ は3軸加速度センサのデータ (w はウィンドウサイズ), $T^{fft}(\cdot)$ はフーリエ変換, $T^{ifft}(\cdot)$ は逆フーリエ変換, $M(\cdot)$ は周波数帯をマスクする処理, $F_m(x, f)$ はマスク処理後のデータである。また、 f_s は加速度センサのデータのサンプリング周波数である。0 Hz は直流成分であるためマスクしていない。フーリエ変換したデータの周波数はサンプリング周波数の1/2が最大値となるためマスクする最大周波数を $f_s/2$ とした。推定精度が低下した周波数を重要な周波数であると判断した。

4.2 訓練時強調フェーズ

訓練時強調フェーズでは、前節で求めた \mathcal{F} を用いて訓練データ x_{train} に対して式(1)の周波数帯強調フィルタを適用したデータで CNN モデル M_c を訓練する (図1中段)。行動

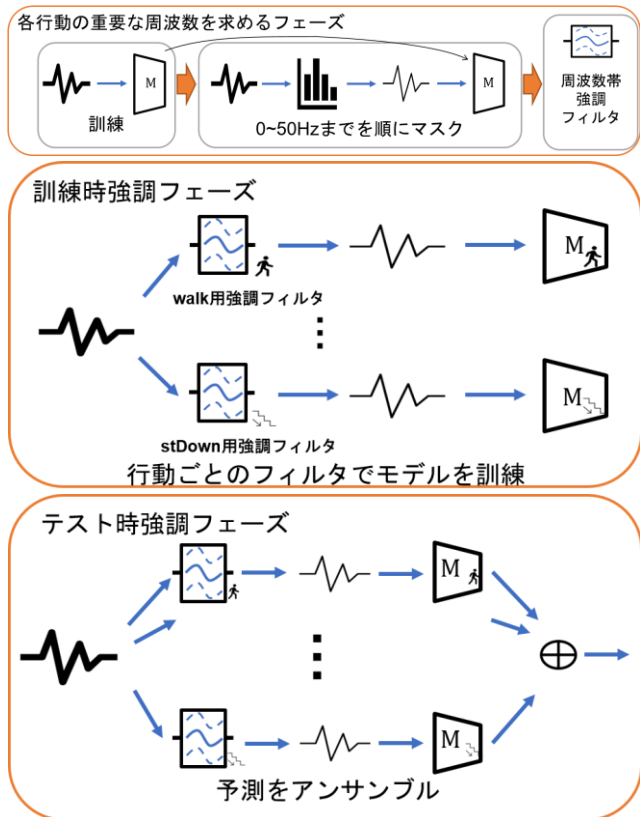


図1 提案手法の概要

ごとにモデルを訓練するため、モデルの数は $|\mathcal{C}|$ となる。周波数帯強調フィルタは式(2)のように実装した。

$$F_e(x, f^c) = T^{ifft} \left(E(T^{fft}(x), f^c) \right) \quad (2)$$

ここで、 $E(\cdot)$ は周波数帯を強調する処理である。

本研究では周波数帯を強調する処理として、4種類の窓関数を用いたフィルタ処理を行っている。本研究で用いたフィルタの例を表1に示す。ピーク窓は、実験で求めた各行動の重要な周波数の振幅スペクトルは変更せず、それ以外の周波数の振幅スペクトルを1/2倍にする窓である。ガウス窓は、各行動の重要な周波数を平均、標準偏差を10とした正規分布の窓であり、最大値を1、最小値を0.5になるように調整している。三角窓は各行動の重要な周波数の振幅スペクトルを頂点とする窓である。また、最小値を0.5としている。ランダムは、振幅スペクトルのうち、(0, 7.8] Hzの部分に0.5~1の値をランダムにかけている。ランダムを

表1 周波数帯強調フィルタの例

ピーク窓	ガウス窓	三角窓	ランダム

用いることで、各行動の重要な周波数の強調が行動認識推定精度向上に寄与しているのかを検証している。表 1 は $f^c = 3 \text{ Hz}$ の場合のフィルタである。

4.3 テスト時強調フェーズ

テスト時強調フェーズでは、テストデータ x_{test} に対し式 (2) を適用し、訓練時強調フェーズで訓練したモデル M_c に入力する。最終的に、各モデルの出力の多数決の結果を最終的な出力としている (図 1 下段)。

5. 評価実験

5.1 実験概要

本研究では、初めに各行動の重要な周波数帯を求める実験を行った。加速度センサデータの一部の周波数をマスクしたデータをモデルの入力として精度の変化を調べ、精度が下がった部分を重要な周波数とした。次に、求めた周波数を利用して各行動の周波数帯強調フィルタを作成し、作成したフィルタを加速度データに適用する。その後、Ablation Study を行い訓練時強調、テスト時強調、アンサンブル学習という提案手法を構成する 3 要素が推定精度にどのように貢献しているかを評価する。

5.2 実験設定

5.2.1 モデル構造と訓練手順

実験にあたり、行動認識モデルとして VGG16[17] を 1 次元データ用に改良したうえで実装した。また、モデルの分類器の影響を小さくするために、特徴抽出器の出力に Global Average Pooling を適用し、分類器は全結合層 1 層とした。学習において、バッチサイズは 256、学習率は 0.001、エポック数は 200 で統一した。また、カーネルサイズは 3、ストライド幅は 1、パディングなし、活性化関数は ReLU、プーリングのサイズは 2 である。

5.2.2 データセット

行動認識のデータセットには HASC データセットを用いた。サンプリング周波数が 100 Hz で、Apple 製品によって収集された 130 人の加速度センサデータのうち、学習用に 80 人分、検証用に 20 人分、テスト用に 30 人分のデータを用いた。また前処理として、ウィンドウサイズ 256 サンプル、ストライド 256 サンプルで時系列分割を行った。行動ラベルは、stay (静止)、walk (歩行)、jog (走行)、skip (スキップ)、stUp (階段上る)、stDown (階段下る) の 6 種類である。

5.3 重要な周波数を求める実験

各行動の重要な周波数帯を求める実験の結果を図 2 に示す。図 2 の 1 段目を見ると stay は実験を行っても精度が変化しなかったため、直流成分である 0 Hz が重要であると考えられる。図 2 の 3 段目を見ると、1 Hz のあたりをマスクしたときに精度が上がっていることが分かる。この周波数は stUp の重要な周波数であり、マスクを行うことで jog を stUp と誤分類していたデータを正しく分類できるようになったため精度が向上したと考えられる。各行動の重要な




図 2 各行動の重要な周波数を求める実験の結果

周波数を表 2 に示す。表 2 を見ると、walk や stUp といった比較的動きが遅い行動は重要な周波数が小さく、jog や stDown といった比較的動きの速い行動は重要な周波数が大きいことがわかった。この結果を踏まえて、求めた周波数の周辺を強調するフィルタを作成した。

5.4 Ablation Study

5.4.1 実験手順

訓練時強調では HASC の行動が 6 種類であるため、6 つ

表 2 各行動の重要な周波数

行動	周波数[Hz]
stay	0.00
walk	0.78
jog	3.13
skip	1.56
stUp	1.17
stDown	1.95

のモデルを訓練した。また、テスト時強調では、訓練した6つのモデルの出力に対して多数決を行い、その結果を最終的な出力とした。Ablation Studyにおいて、訓練時強調あり、アンサンブルなしの実験は訓練データに強調フィルタを適用したデータをすべて使用し、一つのモデルを訓練した。また、テスト時強調あり、アンサンブルなしの実験はテストデータに対し加工を施すことで、一つのデータを数種類作成する手法である Test Time Augmentation (TTA)[18]を用いた。テストデータに強調フィルタを適用したデータを一つのモデルで予測を行った。テストデータに強調フィルタを適用したデータをすべて使用し、一つのモデルで予測を行った。訓練時に周波数帯強調フィルタを適用しない場合に実験で用いるモデルは、元の加速度センサのデータ x_{train} を用いて6つのモデルを訓練している。また、この実験はピーク窓のフィルタを適用して行った。

5.4.2 結果

検証結果を表3に示す。表は Accuracy が最も高い部分を太字・下線で示し、2番目に Accuracy が高い部分を下線で示している。(a)が提案手法の Accuracy である。結果を見ると、訓練時とテスト時に周波数帯強調フィルタを適用し、アンサンブルをする手法が最も精度が高くなっているため、提案手法の有効性が示されていると考えられる。(a)と(b)、(c)、(e)を比較すると(b)と(a)との差が最も大きい。そのことからアンサンブルが推定精度向上に最も貢献していると考えられる。また、(a)と(g)を比較すると、(a)の Accuracy の方が約1%高いため、周波数帯強調フィルタをデータセットに適用することは有効であると考えられる。また、(f)と(h)を比較すると(f)の Accuracy のほうが低くなっていることがわかる。これはテスト時のみ強調フィルタを使用したことで、訓練時に学習した特徴では分類できないデータが入力されたため精度が下がったと考えられる。しかし、(b)と(h)を比較すると(b)の Accuracy が高いことがわかる。このことからテスト時の強調フィルタの適用は訓練時の適用と合わせることで効果があると考えられる。

5.5 窓関数の影響

検証結果を表4に示す。結果を見るとフィルタにガウス

表3 8パターンの実験を行った時の Accuracy

	訓練時 強調	テスト時 強調	アンサン ブル	Accuracy
(a)	○	○	○	<u>0.890</u>
(b)	○	○	×	0.877
(c)	○	×	○	<u>0.881</u>
(d)	○	×	×	0.876
(e)	×	○	○	0.880
(f)	×	○	×	0.845
(g)	×	×	○	0.880
(h)	×	×	×	0.873

表4 それぞれのフィルタを適用した時の Accuracy

フィルタの種類	Accuracy
ピーク窓	<u>0.890</u>
ガウス窓	<u>0.896</u>
三角窓	0.888
ランダム	0.872

窓を使用した時の Accuracy が最も高いことがわかる。このことから周波数帯強調フィルタを作成する場合にはガウス窓の形にすることが適切であると考えられる。また、ランダムのフィルタを適用した場合の認識精度が最も低いことがわかる。このことから、フィルタを作成する場合の各行動の重要な周波数帯の強調は行動認識推定精度の向上に寄与していると考えられる。また、ピーク窓を適用した場合の認識精度がガウス窓を適用した場合の認識精度よりも低くなっていることがわかる。このことから、重要な周波数の1点を強調するよりもその周辺の周波数も併せて強調するほうが有効であると考えられる。

6. 終わりに

本研究では、行動認識における各行動の重要な周波数を求め、求めた周波数を強調するフィルタを作成した。また、訓練データとテストデータにフィルタを適用し、予測のアンサンブルを行う手法を提案した。各行動の重要な周波数を求める実験では、stayは直流成分である0Hzが重要であることがわかった。また、行動の周期が早いほど重要な周波数が高くなり、行動の周期が遅いほど重要な周波数が低くなると考えられる。

強調フィルタの適用やアンサンブルを組み合わせることで精度を比較した結果、訓練時強調、テスト時強調、アンサンブルを組み合わせた提案手法が最も認識精度が向上する結果になった。提案手法のうち最も精度向上に貢献している要素はアンサンブルであると考えられる。周波数帯強調フィルタはテストデータにのみ適用しても効果はなく、訓練データと併せて適用することで効果が得られた。

窓関数の影響を調べる実験では4種類のフィルタ作成パターンを検証し、認識精度を比較した。ガウス窓でフィルタを作成した時に最も認識精度が高くなることが分かった。また、ランダムのフィルタを適用した場合に認識精度が下がったことから、フィルタを作成する場合、重要な周波数を強調することは精度向上に寄与していると考えられる。

今後は、それぞれのモデルや結果を詳しく分析し、考察を深めたい。本研究では周波数帯強調フィルタを4パターン実装して検証を行ったが、今後はほかの形のフィルタを作成し、精度の変化を検証したい。また、本研究では振幅スペクトルにかける値の範囲が0.5~1の間であったため、値を変化させることで精度にどのような変化が出るか調べたい。また、周波数フィルタ自体を深層学習で作成することでさらなる精度向上を図りたい。

謝辞 本研究の一部は JSPS 科学研究費助成事業若手研究(19K20420)の助成によるものである。ここに謝意を表す。

参考文献

- [1] Sakia Robben, Margriet Pol, and Ben Kröse. Longitudinal ambient sensor monitoring for functional health assessments: a case study. *Proceedings of the 23rd ACM international conference on Multimedia*, pp. 1209–1216, 2014.
- [2] 西垣佑介, 寺田努, 寺田努, 塚本昌彦. 加速度センサ付きシャワーヘッドを用いた浴室内行動認識手法. *情報処理学会シンポジウムシリーズ (CD-ROM)*, Vol. 2017, No. 1, pp. 1738–1745, 2017.
- [3] Niloy Sikder, Md. Sanaullah Chowdhury, Abu Shamim Mohammad Arif, and Abdullah-Al Nahid. Human activity recognition using multichannel convolutional neural network. pp. 560–565, 2019.
- [4] 大上裕也, 橋山智訓, 岩田満, 田野俊一. 3 軸加速度センサを用いた歩行パターンの分類. *22nd Fuzzy System Symposium*, pp. 506–511, 2006.
- [5] Minhao LIU, Ailing Zeng, Qiuxia LAI, Ruiyuan Gao, Min Li, Jing Qin, and Qiang Xu. Twavenet: A tree-structured wavelet neural network for time series signal analysis. In *International Conference on Learning Representations*, 2022.
- [6] 佐藤誠, 森田千絵, 土井美和子. 生体データと加速度データを用いた行動認識. *情報処理学会第 65 回 全国大会*, pp. 239–242, 2003.
- [7] 北村和也, 小高知宏, 黒岩丈介, 諏訪いづみ, 白井治彦. 加速度データからの機械学習による行動認識. *福井大学大学院工学研究科 研究報告*, Vol. 68, pp. 59–65, 2020.
- [8] 伊藤千紘, 酒造正樹, 前田英作. スペクトログラム画像の量み込み演算による行動認識. *第 19 回情報科学技術フォーラム*, Vol. 19, No. 3, pp. 15–20, 2020.
- [9] Abdulhamit Subasi, Dalia H. Dammas, Rahaf D. Alghamdi, Raghad A. Makawi, Eman A. Albiety, Tayeb Brahimi, and Akila Sariete. Sensor based human activity recognition using adaboost ensemble classifier. *Complex Adaptive Systems Conference with Theme: Cyber Physical Systems and Deep Learning*, Vol. 140, pp. 104–111, 2018.
- [10] 吉村直也, 前川卓也, 原隆浩. 行動認識モデルの転移学習に向けたニューラルネットワークによる特徴抽出の可視化と分析. *マルチメディア, 分散, 協調とモバイル (DICOMO2019) シンポジウム*, pp. 355–368, 2019.
- [11] 吉澤実, 高崎航, 大村廉. 加速度ベース行動認識におけるレスポンス時間短縮のためのパラメータ検討. *マルチメディア, 分散, 協調とモバイル (DICOMO2013) シンポジウム*, pp. 647–654, 2013.
- [12] 藤原聖司, 藤本まなと, 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. *情報処理学会研究報告 IPJS SIG Technical Report*, pp. 1–8, 2018.
- [13] Naomi Irvine, Chris Nugent, Shuai Zhang, Hui Wang, and Wing W. Y. NG. Neural network ensembles for sensor-based human activity recognition within smart environments. *Sensors*, Vol. 20, pp. 1–26, 2020.
- [14] RAN ZHU, ZHUOLING XIAO, YING LI, MINGKUN YANG, YAWEN TAN, LIANG ZHOU, SHUISHENG LIN, and HONGKAI WEN. Efficient human activity recognition solving the confusing activities via deep ensemble learning. *IEEE Access*, Vol. 7, pp. 75490–75499, 2019.
- [15] 長谷川達人. Octave mix : 行動認識における周波数分解を用いたデータ拡張. *第 19 回情報科学技術フォーラム*, Vol. 19, No. 4, pp. 17–22, 2020.
- [16] Nobuo Kawaguchi, Nobuhiro Ogawa, Yohei Iwasaki, Katsuhiko Kaji, Tsutomu Terada, Kazuya Muraio, Sozo Inoue, Yoshihiro Kawahara, Yasuyuki Sumi, and Nobuhiko Nishio. Hasc challenge: Gathering large scale human activity corpus for the real-world activity understandings. *Proceedings of the 2nd Augmented Human International Conference*, 2011.
- [17] Simonyan K and Zisserman A. Very deep convolutional networks for large-scale image recognition. *The 3rd International Conference on Learning Representations*, 2015, 2015.
- [18] Guotai Wang, Wenqi Li, Michael Aertsen, Jan Deprest, Sébastien Ourselin, and Tom Vercauteren. Test-time augmentation with uncertainty estimation for deep learning-based medical image segmentation. *MIDL 2018 Conference Submission*, 2018.