

行動認識モデル構築における追加学習データ収集支援のための認識精度向上予測に関する検討

谷垣 慶¹ Teoh Tze Chuin¹ 吉村 直也² 前川 卓也² 原 隆浩²

概要：ウェアラブルセンサを用いた行動認識は、製造業、物流、医療介護など、様々な分野における活用が期待されている。今後、対象分野の拡大とともに、行動認識システムのコモディティ化が進み、非研究者であってもシステム構築が簡単にできる環境を整備する必要性が高まるだろう。行動認識システムの構築は、学習データの収集、行動認識モデルの学習、評価というサイクルを通して行われることが一般的である。しかし、行動認識システムの開発者は、これを基準の精度を達成するまで何度も繰り返す必要があり、特に学習データの収集に多大なコストと時間を必要とする。そのため、行動認識システムの開発では、いかに効率よく学習データを収集するかが重要である。現状では目標の精度を達成するためにどのようなデータを収集すべきかを、非研究者が判断するのは困難である。そこで本研究では、特定の行動クラスを対象とし、どの行動クラスのデータを追加すれば行動認識精度がどの程度向上するかを予測することで、追加データの収集方を提示する手法を提案する。本研究では、現在の行動認識モデルの特徴空間における分布と、その学習データに付属する情報に基づいて、現在の学習モデルに特定のデータが追加された場合の対象のクラスの精度変化を予測する。提案手法の有効性を確認するため、異なる5つのデータセットを用いて定量的に評価を行った。

1. はじめに

近年、ウェアラブルセンサ技術が急速に発展している。ウェアラブルセンサを身体部位に取り付けることで、その部位に関する動きなどのデータを収集可能であり、そのデータを用いて人間の行動を認識する技術が盛んに研究されている。例えば、ジャイロセンサは3次元の角速度を、加速度センサは3次元の加速度、地磁気センサは3次元の磁気ベクトルを測定可能であり、それらのセンサを体の各部位に取り付けることで人間の行動データを収集し、機械学習を用いて、収集したセンサデータからそのとき行われている人間の行動を認識することができる。学習を用いた行動認識は、ユビキタスコンピューティング研究の中でも、重要な研究課題とされており、製造業、物流、医療介護など様々な分野での活用が期待されている。今後も、人間行動認識の対象分野は拡大していくことが考えられ、それに伴って、行動認識システムのコモディティ化が進み、非研究者でも行動認識システムを構築できる環境が必要になる。ほとんどの行動認識技術は教師あり機械学習を採用しているため、モデルの学習やその性能を検証するために、大量のラベルありデータが必要となる [1]。しかし、ラベル

ありデータの収集には多大な労力を必要とし、どのようなデータを収集すれば、効率的に性能を向上させられるかを見極めるのは研究者でも難しく、非研究者がそれを行うのはさらに困難である。

行動認識のラベル付きデータを得るために、経験サンプリング [2]、センサデータの間接観察 [3]、被験者の自己記憶 [4] など、現在様々なアノテーション手法が利用されている。しかし、これらのアノテーション手法の多くは、多大な労力を必要とする上に、プライバシーの問題も発生する。労力を費やしてデータを収集したとしても、そのデータが十分でなく、目標とする性能が得られない場合もある。このような場合、データ収集とアノテーションを何度も繰り返す必要があり、さらなるコストや時間が必要となる。能動学習や経験サンプリングを用いて性能向上が見込まれるデータにラベル付けを促す技術も行われているが、そのようなデータが観測されるまで待つ必要があり、そのようなデータが観測される保証もない。このように、データの収集とアノテーションは行動認識問題における大きな課題である。

そこで、本研究では、行動認識システムの開発者によるデータ収集を支援するため、どの行動クラスのデータを追加収集すれば、特定の行動の認識精度がどの程度向上するかを予測することで、追加データの収集方を提示する手

¹ 大阪大学工学部

² 大阪大学大学院情報科学研究科

法を提案する。システム構築の中で、既存のデータにどのようなデータを追加すべきかを提案することで、特定の行動クラスに対して望ましい認識精度を得られるように開発者を支援できる。ここでは、開発者が既に少量のラベル付きデータを収集し、学習データとテストデータに分割しているとする。また、学習データを用いて機械学習モデルを学習し、テストデータを用いてそのモデルを評価すると想定する。このような状況下で、提案手法は特定の行動クラスの精度を向上させるために、既存のデータにどのようなデータを追加すべきかを提示する。そのために、既存のデータに特定のデータを追加した場合の対象クラスの精度変化を予測する予測モデルを構築する。この予測モデルは、行動認識モデルによって生成された行動クラスの特徴分布を用いて、特徴空間における対象クラスの分布とその他の行動クラスの分布の類似性を評価する。そして、予測モデルは、その類似性に基づいて、特定のデータを追加した場合の効果予測する。例えば、ある行動クラスが対象クラスに類似しているために、特徴空間内の分布の境界が曖昧である場合、既存のデータにその行動クラスのデータを追加すると、行動認識モデルにとってクラスの境界がより明確になり、対象クラスの精度が向上すると考えられる。一方で、多様性が低いクラスや、すでに高い精度に達しているクラスにデータを追加しても、精度の向上はあまり見込めないことが予想される。

本手法では、まず学習データを用いて行動認識モデルを学習する。その後、学習データに対して学習したモデルの中間層の出力を特徴分布として抽出し、その次元を削減して特定のクラスの特徴分布を低次元にマッピングする。そして、この次元削減された特徴分布を精度予測モデルの入力として利用する。具体的には、対象クラスの特徴分布、データを追加するクラスの特徴分布、他クラスの特徴分布を精度予測モデルに入力する。また、それらの特徴分布に加えて、学習データや行動認識モデルに関する付加情報、例えば、行動認識モデルの現在の精度などを精度予測モデルに入力する。そして、テストデータにおける対象クラスの認識精度の変化を予測する。予測モデルは、畳み込み層でクラスの特徴分布の類似性を評価し、その後学習データに付随する情報と合わせて、対象クラスの精度変化を推定する。

本研究の学術的貢献は以下の通りである。

- 人間行動認識のためのデータセット構築を支援する新しいアプローチを提案した。認識精度を向上させるために、既存のデータにどのようなデータを追加すべきかを提案するためのネットワークを提案した。既存のデータにデータを追加した際の対象クラスの認識精度の変化を推定することで、行動認識のためのデータ収集を支援する研究は、我々の知る限りでは他にない。
- 提案手法の有効性と妥当性を確認するため、5つのデー

タセットを用いて評価を行った。

2. 関連研究

2.1 加速度センサを用いた行動認識

行動認識は、ユビキタスコンピューティング研究の中でも特に重要な研究課題である [5]。近年の行動認識には古典的な機械学習 [5], [6] や、深層学習 [7] を用いたものがある。古典的な機械学習手法を用いた行動認識では研究者が設計した特徴に基づき、単純ベイズ分類器 [8], 決定木 [9], 隠れマルコフモデル [10], 条件付き確率場 [11], 最近傍探索 [12], サポートベクタマシン [13] などの学習モデルを用いて認識を行っている。しかし、これらの古典的機械学習に基づく手法は、その認識性能が設計された特徴に大きく依存してしまう。このため、タスクに応じた特徴設計が必要となり、汎用性が低いという問題がある。古典的な機械学習手法とは対照的に、深層学習は、生のセンサデータから高度な特徴を自動的に抽出することができる [14]。これにより新しいデータや新しいタスクに低コストで適応することが可能である。畳み込みニューラルネットワーク [15], 残差ネットワーク [16], 再帰的ニューラルネットワーク [17] などの様々なネットワークが行動認識に適用されてきた。畳み込みニューラルネットワークは、時間方向に入力データを畳み込むことでデータの時間的変化に関する特徴を抽出することができ、手で設計された特徴よりも頑健であることが示されている [18]。畳み込みニューラルネットワークが行動認識で活躍しているのは、頑丈で識別的な特徴を学習し、入力サンプル間のセンサ、順序間の畳み込みを利用する能力によるものである。Ferrari ら [16] は、残差ネットワークが他の古典的機械学習手法よりも、行動認識タスクにおいて高い性能を達成することを示した。Lawal ら [19] は人間の行動とセンサの添付位置の両方を予測するために、Deep Human Activity and Location Recognition (DHALR) を提案した。この手法では、身体上のセンサの位置が行動認識の精度に与える影響を調べることができる。Murad ら [20] は、可変長の入力から長距離依存性を捉えることができる Deep Recurrent Neural Networks (DRNNs) を提案している。

2.2 行動認識データセット

人間行動認識の分野では、UCI daily and sports dataset (DSADS)[21], MHEALTH datasets (MHEALTH)[22], REALDISP datasets (REALDISP)[23] など、多くのデータセットが公開されている。表 1 は、本研究で利用したデータセットの概要である。以下に、それらのデータセットを簡単に説明する。DSADS データセットは、8 人の参加者から収集した 19 種類の日常行動とスポーツ行動を組み合わせたものである。センサデバイスは、胸部、右腕、左腕、右脚、左脚の 5 つの異なる部位に設置している。それ

表 1 データセットの概要

データセット名	行動クラス数	搭載加速度センサ数	サンプリングレート	被験者数
DSADS[21]	19	5	25 Hz	8 人
MHEALTH[22]	12	3	50 Hz	10 人
RealDisp[23]	33	9	50 Hz	17 人
MMACT[24]	26	2	100 Hz	20 人
CSLab[25]	14	4	30 Hz	62 人

ぞれのセンサには、加速度センサ、ジャイロセンサ、地磁気センサが搭載されている。MHEALTH は、10 人のボランティアが、14 種類の日常行動を行っているときのセンサデータとバイタルサインを記録したものである。センサデバイスは胸部、左足首、右下腕に設置されており、それぞれのセンサデバイス内には加速度センサ、ジャイロセンサ、地磁気センサが搭載されている。REALDISP は、実世界での行動認識におけるセンサの設置位置の影響を調べるために収集されたものである。参加者 17 名のウォームアップ、クールダウン、フィットネスエクササイズなど、様々なエクササイズ行動を記録している。センサデバイスは、右前腕、右上腕部、背中、左前腕、左上腕、右ふくらはぎ、右大腿部、左大腿部、左ふくらはぎに設置されており、加速度センサ、ジャイロセンサ、地磁気センサなどが搭載されている。Kong ら [24] は、マルチモーダル行動認識のため、RGB 動画や加速度データなどの 7 種類のモダリティのデータを 20 人の被験者から収集した。このデータセットは MMACT dataset (MMACT) として公開されている。Maekawa ら [25] は、約 60 名の参加者の 14 種類の日常行動データを記録し、データセットを構築した。加速度センサを、手首、腰、右大腿部に設置している。以降、本研究においてこのデータセットを CSLab dataset (CSLab) とする。

2.3 能動学習を用いた行動認識データ収集

第 1 節で述べたように、行動認識のために十分な量のラベル付きデータを集めるには多大な労力が必要である。したがって、行動認識用データセットのアノテーションにかかる負担を軽減する手法の開発が必要である。この問題を解決するために能動学習を用いた研究が行われている。Liu ら [26] は、決定木モデルを用いた能動学習を用いて、グループ行動の認識を行っている。Stikic ら [27] は、決定木、Joint-Boosting、単純ベイズ分類器などの分類器を用いた能動学習の研究を行っている。これらの研究では、能動学習の効果は示されているが、データの時間的連続性を考慮していない分類器を使用している。Alemdar ら [28] は、人間の行動の時間的連続性を考慮したモデルで能動学習を行う手法を提案した。しかし、能動学習では特定の行動クラスを対象に精度を向上させることができないといった問題がある。また、認識モデルの性能を向上させるのに十分

な情報量を持つデータがデータプールに存在しない場合、そういったデータが出現するのを待つ必要がある。また能動学習では、追加されたラベル付きデータがモデルの性能にどれだけ影響するかを見積もることができないため、大量のラベル付きデータを追加したとしても、認識性能が向上するとは限らない。一方、本研究では特定のクラスを対象とし、その精度を高めるための最適なデータ収集戦略を提案することを目的としている。

3. 提案手法

3.1 提案手法の概要

それぞれの既存データセットに対して、対象クラス、既に行動認識学習データを収集して初期行動認識モデルの学習に用いる被験者群、テストデータに用いる被験者群、追加収集するクラス追加収集する被験者群をランダムに選び、予測モデルの学習データに含まれるインスタンスを作成する。そして、作成した学習データを用いて精度予測ネットワークの学習を行う。精度予測ネットワークを用いることで、対象とする既存データセットに対して、どの行動クラスのデータを追加収集すれば、どの程度認識精度が向上するかを予測することができる。図 1 に想定する精度予測ネットワークの利用方法を示す。




図 1 想定される精度予測ネットワークの利用方法

3.2 精度予測のための学習データの生成

精度予測に必要な入力、対象クラス、収集データ、訓練した行動認識モデル、それらに起因する付加情報である。ここでは、図 2 に示すように、既存のデータセットに対して被験者追加前の学習データ収集済みの被験者、学習データを追加収集する被験者、追加収集するクラスの組み合わせを計算し、学習データを生成する。ここでは、精度予測

モデルの学習データを既存の行動認識データセットを用いて生成する。具体的には以下の手順で行う。

- (1) 被験者追加前の学習データ収集済みの被験者、学習データを追加収集する被験者、追加収集するクラスをランダムに設定
- (2) 初期行動認識モデルの学習に用いる被験者群の学習データを用いて初期モデルを学習。同様に、初期モデルの学習に用いる被験者群と追加収集する被験者群の学習データを用いて行動認識モデルを学習
- (3) 上記2つのモデルから対象クラスの精度変化を計算
- (4) 初期行動認識モデルにその学習データを入力したときの出力を計算、主成分分析 [29] を用いて3次元次元圧縮
- (5) 得られた3次元のデータ点集合を対象クラス、追加するクラス、その他のクラスの集合に分け、それぞれの分布をヒストグラム化（実際の一例を図3に示す）
- (6) 精度予測モデルの入力となる追加情報を計算。具体的には、初期モデルに使用する被験者数、追加する被験者数、追加する行動クラス数、分類行動クラス数、初期モデルの対象クラスヒストグラムにおける被験者間のユークリッド距離の平均を計算
- (7) 対象クラスに対する精度変化を正解データとし、生成したヒストグラムと追加情報を特徴量とする学習データのインスタンスを作成

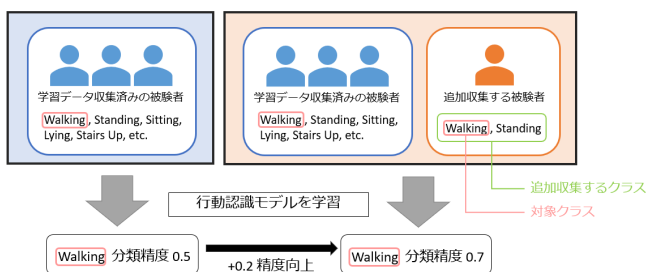


図2 精度予測ネットワーク学習データの生成




図3 対象クラス 追加するクラス その他のクラスのヒストグラム

3.3 精度予測ネットワーク

ここでは前小節で生成した学習データを用いて学習される精度予測ネットワークの構成と、その学習手順を説明する。図4は精度予測ネットワークの構成を示しており、主に2つの入力をもつ。

1つ目の入力は、対象クラス、追加するクラス、その他のクラスの3つの特徴分布のヒストグラムである。これらは、原らによって提案された18層3D-ResNet[30]に基づいて作成されたネットワークに入力される。原らの研究ではResNetは行動認識の分野においても効果的であることが示されている[30]。ResNetは層と層の間をショートカットすることで、ネットワークの勾配消失問題を解決する構成をもち、特に深いネットワークにおいて効果的である。本研究ではResNetの基本ブロックを含む10層ResNetを用いる。具体的には3次元畳み込み層、Batch-Normalization層、ReLU、Max-Pooling層と4つのResNetの基本ブロックから構成される。基本ブロックのそれぞれは、3次元畳み込み層、Batch-Normalization層、ReLU、3次元畳み込み層、Batch-Normalization層、ReLUからなる。また、ショートカットがブロックの先頭から2つ目のReLUの直前までをつないでおり、原ら[30]と同様にパラメータ数の増加を防ぐため、identity connectionとzero paddingをショートカットに加えている。

2つ目の入力は上述した付加情報であり、2層の全結合層からなるブロックに入力した後ResNetの出力と2層の全結合層で統合し最終的な出力を得る。

また学習では、平均絶対誤差に基づいて誤差逆伝播法を行い、最適化アルゴリズムには学習率0.01のAdamを用いた。以上のようにして、畳み込み層で入力された特徴分布のクラス間の類似性を評価し、追加情報を全結合層で統合することで、対象クラスの精度向上を推定することができる。




図4 精度予測ネットワークの構成

表 2 データセットの行動クラス

データセット名	行動クラス
DSADS[21]	Sitting, Standing, Lying (back), Lying (right), StairsUp, StairsDown, Standing (elevator, still), Moving (elevator), Walking (parking), Walking (treadmill, flat), Walking (treadmill, slope), Running (treadmill), Exercising (stepper), Exercising (cross trainer), Cycling (exercise bike, vertical), Cycling (exercise bike, horizontal), Rowing, 13 Jumping, Playing Basketball
MHEALTH[22]	Standing, Sitting, Lying Down, Walking, Stairs Up, Waist Bends Forward, Frontal Elevation Arms, Knees Kending, Cycling, Jogging, Running
RealDisp[23]	Walking, Jogging, Running, Jump up, Jump front & back, Jump sideways, Jump leg/arms open/closed, Jump rope, Trunk twist (arms outstretched), Trunk twist (elbows bent), Waist bends forward, Waist rotation, Waist bends (reach foot with opposite hand), Reach heels backwards, Lateral bend (10 to the left + 10 to the right), Lateral bend with arm up (10 to the left + 10 to the right), Repetitive forward stretching, Upper trunk and lower body opposite twist, Lateral elevation of arms, Frontal elevation of arms, Frontal hand claps, Frontal crossing of arms, Shoulders high-amplitude rotation, Shoulders low-amplitude rotation, Arms inner rotation, Knees (alternating) to the breast, Heels (alternating) to the backside, Knees bending (crouching), Knees (alternating) bending forward, Rotation on the knees, Rowing, Elliptical bike, Cycling
MMACT[24]	carrying, checking.time, closing, crouching, entering, exiting, fall, jumping, kicking, loitering, looking.around, opening, picking.up, pointing
CSLab[25]	Standing, Walking, Running, Sitting, StairsUp, StairsDown, Bicycling, BrushingTeeth, WashingDishes, UsingPC, DrawingWhiteboard, WritingNotebook, PlayPingpong, Vacuuming

4. 評価実験

4.1 データセット

ウェアラブルセンサを用いて収集された行動認識データセットは数多く公開されている。本研究では、日常行動及びエクササイズ行動を対象とするデータセットである UCI daily and sports dataset (DSADS) [21], MHEALTH datasets (MHEALTH)[22], RealDisp datasets (RealDisp)[23], MMACT dataset (MMACT)[24], CSLab dataset (CSLab)[25] を使用する。表 1 と表 2 に、これら 5 つのデータセットの概要と行動クラスを示す。

DSADS データセットは Sitting, Standing, Lying (back), Lying (right), StairsUp などの 19 の行動クラスからなる。右腕と左脚に取り付けられた加速度センサから収集したデータを使用する。8 人の被験者全員のデータを使用した。また、右腕と左脚の部位から得られたデータを使用する。

MHEALTH データセットは Standing, Sitting, Lying Down, Walking, Stairs Up などの 12 の行動クラスからなり、そのうちの Jump Front Back は、データ量が十分でなかったため今回の実験では利用しなかった。10 人の被験

者全員の右下腕と右足首の 2 つの部位から得られたデータを利用する。

RealDisp データセットは Walking, Jogging, Running, Jump up, Jump front & back, Jump sideways などの 33 の行動クラスからなる。17 人の被験者中、各クラスのデータが十分に存在した 13 人を使用する。また、右下腕と左大腿の部位から得られたデータを使用する。

MMACT データセットは carrying, checking.time, closing, crouching, entering, exiting などの 33 の行動クラスからなる。17 人の被験者中、各クラスのデータが十分に存在した 13 人を使用する。また、右ポケットに入れたスマートフォンと右腕につけたスマートウォッチから得られたデータを使用する。

CSLab データセットは Standing, Walking, Running, Sitting, StairsUp, StairsDown などの 14 の行動クラスからなる。62 人の被験者中、すべての行動において手が右利きである被験者 40 人を使用する。また、右腕と右脚の部位から得られたデータを使用する。

データセット間のデータ収集条件の差異に対応するため、各データセットの加速度データを、サンプリング周波数 30Hz、ウィンドウサイズ 60 サンプル、ストライドサイ




図 5 DSADS 2 値分類結果




図 8 MMACT 2 値分類結果




図 6 MHEALTH 2 値分類結果




図 9 CSLab 2 値分類結果




図 7 RealDisp 2 値分類結果

ズ 15 サンプルでリサンプリングした。

4.2 評価手法

前小節で示した 5 つのデータセットを用いて、精度予測モデルの性能評価を行う。評価は、Leave-one-dataset-out 交差検定により行う。すなわち、4 つのデータセットを予測モデルの学習に用いて、残りの 1 つを学習したモデルの評価に用いる。

ここでは初期行動認識モデルの学習に用いる被験者数を 2 人または 3 人、追加収集する被験者数を 1 人、追加収集するクラス数を 2 個とした。対象クラスの精度の向上には対象クラスを加えることが必須であることが事前実験より明らかになったため、追加収集する 2 つのクラスのうち 1 つは対象クラスを含むようにした。

4.3 実験結果

精度向上が閾値 (0.05, 0.1, 0.2 または 0.3) 以上か、それ未満かの 2 値分類を先述の Leave-one-dataset-out 交差検定で行った結果を図 5 から 9 に示す。多くの場合、閾値が大きくなるとともに、F 値が低下している。これは、閾値以上のクラスに属するインスタンス数が減少するためだと考える。

精度予測モデルの結果を用いた学習データ収集方策の決定は、閾値以上のクラスに分類されるインスタンス (追加収集するクラス) に基づいて行われる。そのため、閾値以

上のクラスの Precision が重要となる。そこで、閾値を変更したときの閾値以上のクラス Precision を表 3 に示す。これより、閾値が低くなるとともに Precision が高くなっていることがわかる。これは、閾値が大きく向上するかを予測するより、閾値が少しでも向上するかを予測するほうがより容易であるためと考える。閾値が 0.05 のときの Precision は平均して 0.842 を達成しており、学習データの追加収集に有用な手がかりを提供可能であると考えられる。一方で、分類精度が大きく向上する方策の提示はまだ困難であると言え、今後はモデルなどの改良により、閾値が大きい場合の精度向上を目指す。

5. おわりに

本研究では、特定の行動クラスを対象とし、どの行動クラスのデータを追加すれば行動認識精度がどの程度向上するかを予測することで、追加データの収集方策を提示する手法を提案した。行動認識モデルの中間層からの特徴抽出、特徴空間におけるクラス分布の分類、3D-ResNet による特定の行動クラスの精度変化の予測というデータ駆動型のアプローチを採用することで、研究者が特定の行動クラスの望ましい精度を達成するのに役立つデータ収集戦略を提案することを可能とした。5 つの行動認識データセットを用いて本手法の学習と評価を行い有効性を確認した。

謝辞

本研究の一部は JSPS JP16H06539 及び JP21H05299 の支援のもと行われました。

参考文献

- [1] Schröder, M., Yordanova, K., Bader, S. and Kirste, T.: Tool support for the online annotation of sensor data, *the 3rd International Workshop on Sensor-based Activity Recognition and Interaction*, pp. 1–7 (2016).
- [2] Froehlich, J., Chen, M. Y., Consolvo, S., Harrison, B.

表 3 閾値を変更したときの閾値以上のクラスにおける Precision

閾値	DSADS	MHEALTH	RealDisp	MMACT	CSLab	平均
0.05	0.864	0.845	0.820	0.879	0.803	0.842
0.1	0.826	0.692	0.777	0.824	0.775	0.779
0.2	0.696	0.594	0.621	0.634	0.550	0.619
0.3	0.590	0.745	0.498	0.419	0.443	0.539

- and Landay, J. A.: MyExperience: a system for in situ tracing and capturing of user feedback on mobile phones, *the 5th International Conference on Mobile Systems, Applications and Services*, pp. 57–70 (2007).
- [3] Maurer, U., Smaligic, A., Siewiorek, D. P. and Deisher, M.: Activity recognition and monitoring using multiple sensors on different body positions, *International Workshop on Wearable and Implantable Body Sensor Networks (BSN'06)*, IEEE, pp. 4–pp (2006).
- [4] Van Laerhoven, K., Kilian, D. and Schiele, B.: Using rhythm awareness in long-term activity recognition, *2008 12th IEEE International Symposium on Wearable Computers*, IEEE, pp. 63–66 (2008).
- [5] Bulling, A., Blanke, U. and Schiele, B.: A tutorial on human activity recognition using body-worn inertial sensors, *ACM Computing Surveys (CSUR)*, Vol. 46, No. 3, pp. 1–33 (2014).
- [6] 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 (2012).
- [7] Wang, J., Chen, Y., Hao, S., Peng, X. and Hu, L.: Deep learning for sensor-based activity recognition: A survey, *Pattern Recognition Letters*, Vol. 119, pp. 3–11 (2019).
- [8] Tapia, E. M., Intille, S. S. and Larson, K.: Activity recognition in the home using simple and ubiquitous sensors, *International Conference on Pervasive Computing*, Springer, pp. 158–175 (2004).
- [9] Bao, L. and Intille, S. S.: Activity recognition from user-annotated acceleration data, *International conference on pervasive computing*, Springer, pp. 1–17 (2004).
- [10] Duong, T. V., Bui, H. H., Phung, D. Q. and Venkatesh, S.: Activity recognition and abnormality detection with the switching hidden semi-markov model, *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, Vol. 1, IEEE, pp. 838–845 (2005).
- [11] Van Kasteren, T., Noulas, A., Englebienne, G. and Kröse, B.: Accurate activity recognition in a home setting, *the 10th International Conference on Ubiquitous Computing*, pp. 1–9 (2008).
- [12] Wu, W., Dasgupta, S., Ramirez, E. E., Peterson, C., Norman, G. J. et al.: Classification accuracies of physical activities using smartphone motion sensors, *Journal of medical Internet research*, Vol. 14, No. 5, p. e2208 (2012).
- [13] Zhu, Y., Nayak, N. M. and Roy-Chowdhury, A. K.: Context-aware activity recognition and anomaly detection in video, *IEEE Journal of Selected Topics in Signal Processing*, Vol. 7, No. 1, pp. 91–101 (2012).
- [14] LeCun, Y., Bengio, Y. and Hinton, G.: Deep learning, *nature*, Vol. 521, No. 7553, pp. 436–444 (2015).
- [15] Bevilacqua, A., MacDonald, K., Rangarej, A., Widjaya, V., Caulfield, B. and Kechadi, T.: Human activity recognition with convolutional neural networks, *Joint European Conference on Machine Learning and Knowledge Discovery in Databases*, Springer, pp. 541–552 (2018).
- [16] Ferrari, A., Micucci, D., Mobilio, M. and Napolitano, P.: Human activities recognition using accelerometer and gyroscope, *European Conference on Ambient Intelligence*, Springer, pp. 357–362 (2019).
- [17] Singh, D., Merdivan, E., Psychoula, I., Kropf, J., Hanke, S., Geist, M. and Holzinger, A.: Human activity recognition using recurrent neural networks, *International Cross-domain Conference for Machine Learning and Knowledge Extraction*, Springer, pp. 267–274 (2017).
- [18] Cruciani, F., Vafeiadis, A., Nugent, C., Cleland, I., Mccullagh, P., Votis, K., Giakoumis, D., Tzovaras, D., Chen, L. and Hamzaoui, R.: Comparing CNN and Human Crafted Features for Human Activity Recognition, *2019 IEEE SmartWorld, Ubiquitous Intelligence Computing, Advanced Trusted Computing, Scalable Computing Communications, Cloud Big Data Computing, Internet of People and Smart City Innovation (SmartWorld/SCALCOM/UIC/ATC/CBDCOM/IOP/SCI)*, pp. 960–967 (2019).
- [19] Lawal, I. A. and Bano, S.: Deep human activity recognition with localisation of wearable sensors, *IEEE Access*, Vol. 8, pp. 155060–155070 (2020).
- [20] Murad, A. and Pyun, J.-Y.: Deep recurrent neural networks for human activity recognition, *Sensors*, Vol. 17, No. 11, p. 2556 (2017).
- [21] Barshan, B. and Yükek, M. C.: Recognizing daily and sports activities in two open source machine learning environments using body-worn sensor units, *The Computer Journal*, Vol. 57, No. 11, pp. 1649–1667 (2014).
- [22] Banos, O., Villalonga, C., Garcia, R., Saez, A., Damas, M., Holgado-Terriza, J. A., Lee, S., Pomares, H. and Rojas, I.: Design, implementation and validation of a novel open framework for agile development of mobile health applications, *Biomedical engineering online*, Vol. 14, No. 2, pp. 1–20 (2015).
- [23] Baños, O., Damas, M., Pomares, H., Rojas, I., Tóth, M. A. and Amft, O.: A benchmark dataset to evaluate sensor displacement in activity recognition, *the 2012 ACM Conference on Ubiquitous Computing*, pp. 1026–1035 (2012).
- [24] Kong, Q., Wu, Z., Deng, Z., Klinkigt, M., Tong, B. and Murakami, T.: MMACT: A Large-Scale Dataset for Cross Modal Human Action Understanding, *The IEEE International Conference on Computer Vision (ICCV)* (2019).
- [25] Maekawa, T. and Watanabe, S.: Unsupervised activity recognition with user's physical characteristics data, *2011 15th Annual International Symposium on Wearable Computers*, IEEE, pp. 89–96 (2011).
- [26] Liu, R., Chen, T. and Huang, L.: Research on human activity recognition based on active learning, *2010 International Conference on Machine Learning and Cybernetics*, Vol. 1, pp. 285–290 (2010).
- [27] Stikic, M., Van Laerhoven, K. and Schiele, B.: Exploring semi-supervised and active learning for activity recognition, *2008 12th IEEE International Symposium on*

- Wearable Computers*, pp. 81–88 (2008).
- [28] Alemdar, H., van Kasteren, T. L. M. and Ersoy, C.: Using Active Learning to Allow Activity Recognition on a Large Scale, *Ambient Intelligence* (Keyson, D. V., Maher, M. L., Streitz, N., Cheok, A., Augusto, J. C., Wichert, R., Englebienne, G., Aghajan, H. and Kröse, B. J. A., eds.), Springer Berlin Heidelberg, pp. 105–114 (2011).
- [29] De Silva, C. C., Beckman, S. P., Liu, S. and Bowler, N.: Principal Component Analysis (PCA) as a Statistical Tool for Identifying Key Indicators of Nuclear Power Plant Cable Insulation Degradation, *the 18th International Conference on Environmental Degradation of Materials in Nuclear Power Systems – Water Reactors* (Jackson, J. H., Paraventi, D. and Wright, M., eds.), Springer International Publishing, pp. 1227–1239 (2019).
- [30] Hara, K., Kataoka, H. and Satoh, Y.: Can spatiotemporal 3d cnns retrace the history of 2d cnns and imagenet?, *the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 6546–6555 (2018).