



卒業研究報告書

平成29年度

研究題目

人感センサーを用いた複数のアルゴリズムによる
被介護者の行動識別

指導教員 上野秀剛 准教授

氏名 池内隆一郎

平成30年1月11日 提出

奈良工業高等専門学校 情報工学科

人感センサーを用いた複数のアルゴリズムによる 被介護者の行動識別

上野研究室 池内隆一郎

近年、日常生活を過ごすうえで他者による支援が必要な人（被介護者）が増え続けており、支援のために見守り業務は介護者にとって負担が多い。これに対し、カメラで撮影した被介護者の映像を機械学習によって被介護者の行動を識別する手法が存在するが、この手法は被介護者のプライバシーを侵害してしまう。見守り支援のためのシステムの内、先行研究では人感センサーを用いてベッド周辺での被介護者の行動が危険行動か非危険行動かを識別する手法を提案した。先行研究の手法は、被介護者のプライバシーが守られる一方で危険行動かどうかだけしか分からず、具体的にどの行動をとっているのか分からない。本研究の目的は、要介護者の行動をもとに危険行動が行われたかどうかではなく、何の行動が行われたかを識別することである。行われた行動が分かれば、それによって危険行動かどうかを判断することができる。その上、例えば手術後寝ている患者が目を覚めた場合、医療器具の取り外しや薬を投与などの次の治療をすぐに行うことが可能である。本研究では、先行研究と同様に赤外線人感センサーを用いてベッド周辺での行動を計測し、それをもとにデータセットを作成する。先行研究で、分類はランダムフォレストを用いたが、本研究ではSVM、ランダムフォレスト、ニューラルネットワーク、畳み込みニューラルネットワークによる識別を行い、精度を比較する。検証は、それぞれの機械学習モデルについて9分割交差検証とleave-one-out交差検証を用いる。実験の結果、9分割交差検証では、畳み込みニューラルネットワークが他より精度が高かった。また、leave-one-out交差検証では、SVMが圧倒的に精度が低くランダムフォレストと畳み込みニューラルネットワークの精度が高かった。誤認識の行動パターンについては、着座（手前）を起立（奥）と誤認識するなどいくつかのパターンが非常に認識しづらいことが判明した。

目次

1	はじめに	2
2	関連研究	4
3	機械学習	5
3.1	概要	5
3.2	線形SVM	5
3.3	Random Forest	6
3.4	ニューラルネットワーク	6
3.5	畳み込みニューラルネットワーク	6
4	実験	8
4.1	実験環境	8
4.2	行動の計測	9
4.3	データセットの作成	9
4.4	行動の識別	10
4.5	検証	11
5	結果と考察	12
5.1	アルゴリズムの精度	12
5.2	行動の種類と予測精度	12
6	まとめ	15
	参考文献	17

1 はじめに

病院の患者や介護施設の入居者，在宅介護の利用者など，日常生活を過ごすうえで他者による支援が必要な人(被介護者)は年々増加している．そのため支援を行う医者や看護師，介護サービス事業者(総称して介護者と呼ぶ)の負担を軽減する方法が求められている．

介護者の負担になっている業務の1つに，被介護者の見守りがある．被介護者は行動の制限が大きく，ベッドからの転落のようなトラブルが発生した時に自力で元の状態に戻ることが困難である．トラブルが発生した状態で長時間放置されると被介護者の容体が悪化する可能性があるため，介護者はできるだけ頻繁に被介護者の状態を観察し，安否を確認する必要がある．しかし，夜中であつたり，自宅で訪問介護を受けている場合のように見守りを長時間にわたって実施することが困難な場合も多い．そのため，被介護者の体勢や行動を計測するためのシステムについて研究が行われている．

本研究では，被介護者の行動の種類を識別することを目的とする．被介護者の行動を計測するために，赤外線人感センサーを用いる．また，複数の機械学習アルゴリズムによって行動の識別性能を評価しその精度を比較する．実験するアルゴリズムはSVM, ランダムフォレスト, 多層パーセプトロン, 畳み込みニューラルネットワーク(CNN)である．

被介護者の行動の種類を知ることにより，危険行動が行われたかを知ることができるので被介護者の見守りが実現できる．その上，例えば手術後寝ている患者が目を覚ました場合，医療器具の取り外しや薬を投与などの次の治療をすぐに行うことが可能である．また，どの行動が危険行動であるかは機械学習モデルの学習には依存しないため，検出したい危険行動を後から変更することができるなど柔軟な対応が可能となる．

2 関連研究

2.1 カメラを用いた行動予測

日常生活の行動を推定する手法の提案はこれまでに多数行われている。その中でも、カメラを用いて計測し機械学習によって行動を推定する方法が主流である [2, 3].

Liuらはベッド上の被介護者の姿勢を推定するために、カメラを用いて被介護者を撮影する手法を提案している [4]. 一般的な姿勢の画像と異なり、ベッド上での姿勢の画像は昼夜で照明条件が異なる。そのため、Infra-Red Selective (IRS) Image Acquisition Methodと呼ばれる夜間でも人を可視化でき、昼夜の照明条件の違いに影響を受けない手法を用いた。畳み込みニューラルネットワーク (CNN) を用いた機械学習器に、一般公開されている姿勢のデータセットを学習させ、独自に計測したベッド上での姿勢データセットをさらに学習させた。結果、SVMなどの古典的なモデルと比べて精度が高かった。しかし、この手法は、カメラを用いるため被介護者のプライバシーが守られない。また、ベッドや医療器具など、計測対象の人以外が写るため、環境によっては識別精度が落ちることが懸念される。本研究では、被介護者のプライバシーに干渉せず、人以外の環境に影響を受けにくい赤外線人感センサーを用いる。

2.2 センサーを用いた行動予測

カメラの他にも、スマートフォンやタブレットなどの携帯端末の加速度センサー、磁気センサー、音響センサー、位置センサーを用いて計測し、機械学習によって行動を推定する方法も存在する [6, 7]. 一般に販売されている携帯端末は多数の人々が所持しているため、体に取り付けるウェアラブルなセンサーに比べて受け入れやすく、サンプルデータの件数が集まりやすい。そのためディープラーニングによる大量のサンプルデータでの学習が可能である。Liouaneらは屋内においての人間の活動が正常であるかを認識するために活動を簡素化する手法を提案している [5]. 提案手法は、各部屋に取り付けた、存在や動きを検出するセンサーを用いて人間の複雑な活動を計測する。計測したセンサーの値を階層型隠れマルコフモデルにより“Home By Room Activities Language” (HBRAL) と呼ばれる文法に従って簡単な表現に変換する。最後にHBRALによって表現された文から異常な活動を場所や用途、滞在時間を考慮したアルゴリズムによって検出する。結果、提案モデルは、隠れ状態と比較して小さな観測誤差で効率的に居住者の活動を認識した。この手法では、屋内の複数の部屋における活動を対象とし、被介護者の居場所と食事をす、料理をするなどの簡単な行動を推定したが、被介護者は比較的ベッド周辺で活動する時間が長いいため、本研究では、計測場所をベッド周辺に限定することによって、体を起こす、寝転がるなどのより細かい行動を認識させる。

川上は計測場所をベッド周辺に限定し、被介護者の行動を危険行動と非危険行動の2種類に分類する手法を提案している[1]。被介護者の計測には赤外線人感センサーを使用し、センサーが出力した過去5分の値を1データとすることによって、実環境での運用を想定した擬似的なデータセットを作成した。危険行動の認識はデータセットにおける危険行動の割合が重要であるため、割合を10%から50%まで10%ごとに変化させ、機械学習アルゴリズムの1つであるRandomForestによって、被介護者の行動を分類した。結果、危険行動の割合が低いほど精度が高くなるが、危険行動自体の検出率が低くなることが分かった。危険行動か否かの分類は、あるデータセットから異常な値を見つけ出す異常検知と呼ばれる分野で用いられる手法であるが、本研究はベッド上における日常活動(Activity of Daily Living)の認識の分野ととらえることができる。センサーデータから日常活動を分類するには、全体の行動から一定の時間区間で分けることによって一つ一つの行動を抜き出し、時系列性を考慮したアルゴリズムを用いて多クラス分類を行う。川上は一定の時間区間を5分に区切ったが一つの行動時間の平均は約7.2秒であるため、一つの行動時間を10秒間で区切ることにした。また、randomforestは時系列性を考慮したアルゴリズムではないため、データセットに過去の情報を追加することによって時系列性を反映させたが、本研究では、時系列性を考慮したアルゴリズムを含む4つのアルゴリズムを用いて比較する。

3 機械学習

3.1 概要

機械学習とは、画像やセンサーなどのあるサンプルデータを入力として解析し、そこに潜む特徴やパターンを見つけ出す手法である。機械学習は検索エンジン、文字認識、音声認識など幅広い分野で用いられている。機械学習に用いるサンプルデータをデータセットという。学習手法の検証には、まずデータセットを学習データとテストデータに分け、学習データを解析しテストデータで学習手法がどれほど学習できているかを測る。

3.2 線形SVM

サポートベクターマシンはVapnikらによって、1963年に発表されたパターン認識モデルである [8]。図1にSVMの概要を示す。

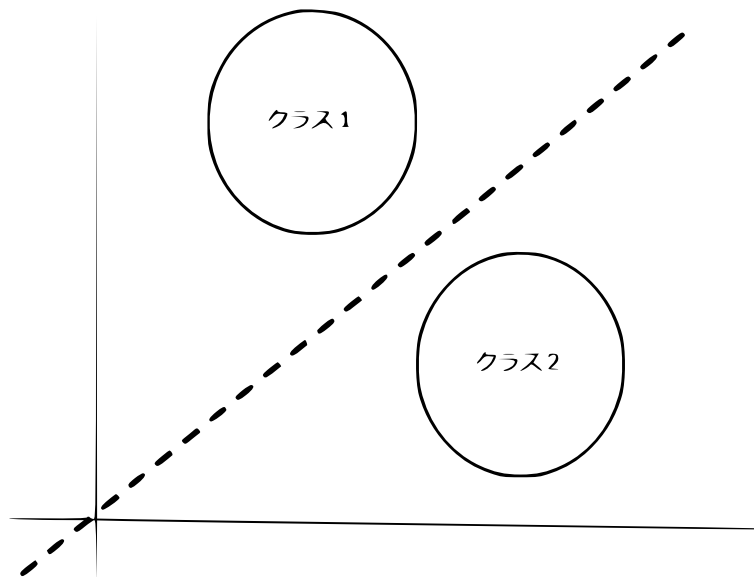


図1 SVMの概要

最も境界に近い場所にある1つのサンプルデータとの距離の-marginが最大になる超平面を求めることにより、パターン識別を行う。この手法は学習用のデータセットが少ないの場合でも-marginを最大化するため、高い識別精度を得られる。現在知られている中でも汎用性が高く認識精度が優れている古典的な学習手法の一つである。

3.3 Random Forest

Random Forest は, Breiman によって 2001 年に発表された複数の決定木を用いたアンサンブル学習アルゴリズムである [9]. 図 2 にランダムフォレストの概要を示す [1].

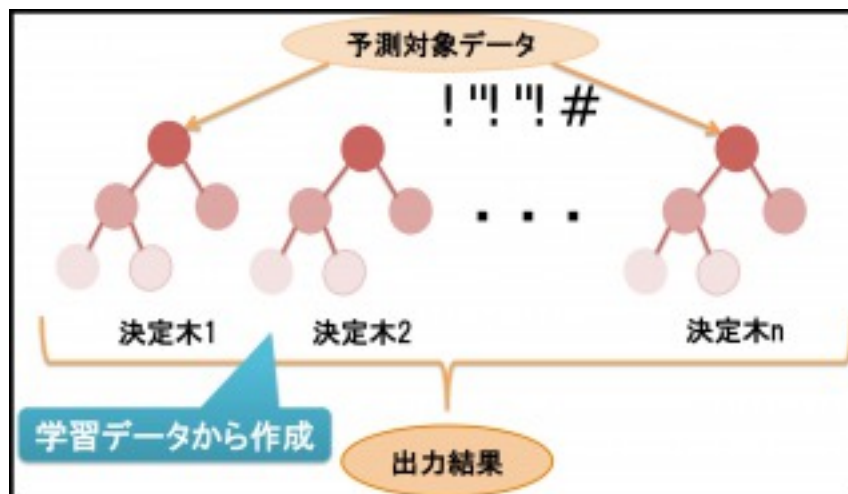


図 2 ランダムフォレストの概要

入力された学習データをもとに多数の決定木を構成する. このときの決定木の深さはハイパーパラメータとして指定する. 決定木の深さが深いほど学習は遅くなるがモデルの精度が高くなる. 予測するには作成した複数の決定木それぞれでの予測結果の多数決を得ることによって最終出力を決定する. SVM と比べて, 説明変数が多くてもうまく学習し, 学習データが増えても効率的に学習する. また, 決定木の深さにもよるが非常に高速に動くため, 実際に介護現場に実装する際にはすぐに予測結果が得られるため, 被介護者の異常な状態をすばやく発見できる可能性がある.

3.4 ニューラルネットワーク

ニューラルネットワークは人間の脳を簡易的にコンピュータ上で表現できるようにしたモデルである. 多層パーセプトロンは Rumelhart らによって 1986 年に発表されたニューラルネットワークの一種であり, パーセプトロンを多層化し誤差逆伝播法で学習させることでより複雑な問題に対応できるようにしたモデルである [10, 11]. 音声認識や画像認識, 機械翻訳ソフトウェアといった多様な分野に応用されている.

3.5 畳み込みニューラルネットワーク

畳み込みニューラルネットワークは, Yann らによって 1998 年に発表されたニューラルネットワークの一種である [12]. 特徴抽出を行う働きを持つ畳み込み層と位置ず

れを許容する働きを持つプーリング層が交互に全結合型ニューラルネットワークの前に配置される.特に画像認識や動画認識の分野で広く使われるモデルである.

4 計測

研究室内にベッドを設置し, 模擬的な介護現場を再現した. 被験者にはベッド周辺で指定の9種類の行動を行ってもらい, 周辺に配置した人感センサーで各行動を計測する. 本研究では, 情報工学科5年生の男性9名に対して被験者実験を行った.

4.1 計測環境

ベッド周りに9つの赤外線人感センサーを設置し, 被験者の行動を計測した. 赤外線人感センサーは周囲の温度変化を検出するものであり, 検出すればデジタル信号の出力がLowからHighに変化する.

本研究では, 赤外線人感センサーモジュールSB412Aとそれを制御するワンボードマイコンArduino YUNを用いた. 図3にSB412をArduinoに接続した様子を示す.




図3 ArduinoをSB412Aに接続した様子

SB412Aは計測可能距離が3mから5m程度で計測可能角度が100度程度である。複数赤外線人感センサーを用いるため、角度が大きく検知位置範囲が一方のセンサーが他のセンサーと重複してしまうため、図4のようにSB412Aに筒状のカバーを取り付けることによって検出角度を低くした。得られたセンサー情報と計測した時間をArduino YUNからパソコンに転送し行動データセットとして記録した。




図4 SB412Aのカバー

設置したセンサーの配置を図5に示す。図中の丸はセンサーを示し、センサー1～4は人間がいる場所、センサー5～8は人間の姿勢(寝る, 座る, 立つ), センサー9は人間の足がベッド下にあるかどうか分かるよう記録するのに使用する。




図5 センサーの配置

4.2 行動の計測

被験者には、ベッドの上で寝ている状態から開始される7種類の行動と、ベッド周辺での移動を伴う2種類の計9種類、行動してもらう。なお、センサーに近い方を手前と表記する。表1に9種類の行動とその行動に対応するラベルを示す。

表1 行動一覧

ラベル	行動
寝返り	ベッド上で寝返りを打つ
上体起こし	ベッド上で体を起こす
着座(手前)	ベッド横の手前側に座る
着座(奥)	ベッド横の奥側に座る
転落	ベッド下に転げ落ちる
起立(手前)	ベッド下に転げ落ちる
起立(奥)	ベッド下に転げ落ちる
退出	ベッド上で寝ている状態からベッド横に立ちベッドの奥側に立ち去る
入出	ベッドの奥側からベッド横に立ちベッド上で寝ている状態に戻る

各被験者には9種類の行動を1セットとして、これを2セット行ってもらう。被験者の行動とセンサー情報の同期をとるために行動の開始時間と終了時間を記録した。

4.3 データセットの作成

センサー情報は1秒間に3,4回送られ、それらの平均値をその時間(秒単位)のセンサー値とした。被験者1人につき図??(行動データのサンプルのCSV)のような行動サンプルデータが18(9行動x2)個得られる。1行動サンプルデータには、1秒のセンサー情報が行動時間分と行動のラベルが含まれる。

センサー情報:

時間	s1,	s2,	s3,	s4,	s5,	s6,	s7,	s8,	s9
0	1,	1,	0,	1,	0,	1,	1,	0,	0
1	1,	1,	1,	1,	0,	1,	1,	1,	0
2	1,	1,	1,	1,	0,	0.67,	1,	1,	0
3	1,	1,	0.33,	1,	0,	0,	1,	1,	0
4	0.25	0.33,	0,	0.75,	0,	0,	1,	0.75,	0
5	0,	0,	0,	0,	0,	0,	0.5,	0,	0

行動: 寝返り

図6 行動サンプルデータ

4.4 行動の識別

行動の識別には、SVM, ランダムフォレスト, ニューラルネットワーク, 畳み込みニューラルネットワークを用いる。

SVM, ランダムフォレストはオープンソースの機械学習ライブラリであるsklearn[15]を使い、ニューラルネットワーク, 畳み込みニューラルネットワークはGoogleが開発している機械学習ライブラリであるtensorflow[16]を使って実装する。

まずは、4.3節で述べる検証手法に基づき、データセットを学習用とテスト用に分ける。学習データのセンサー情報とそれに対応する行動ラベルの両方をライブラリを使った各機械学習モデルで解析し学習させる。学習させた機械学習モデルにテストデータのセンサー情報を入力すれば、それによって予測された行動ラベルが出力される。予測された行動ラベルがテストデータの行動ラベルと等しいかどうかを検証する。

4.5 検証

本研究のデータセットの件数は162件であり、このデータ件数はデータ件数が比較的少ないと言える。そのため、機械学習モデルの精度が高くなりすぎ、過学習を起こす可能性を考慮しなければならない。

K-分割交差検証はデータセットをk個に分割し、そのうちの一つをテストデータ, その他を学習データとし学習モデルの精度を検証する手法である[13]。テスト

データをk個に分割されたデータセットそれぞれに適用させ、k回検証を繰り返して得られたk個の精度を平均して最終的な学習モデルの精度とする。また、kの値がデータセットの件数と等しい場合はleave-one-out交差検証と呼ばれる[14]。これらの検証方法は、学習データではなくテストデータも含め全データセットにどれほど対応しているかを評価することが可能である。

データセットの件数は162件は9で件数がちょうど分割できるため、k-分割交差検証のkの値は9とし、9-分割交差検証を行う。また、leave-one-out交差検証についても検証を行った。

5 結果と考察

5.1 アルゴリズムの精度

4.3節で述べた検証方法に基づいた各学習アルゴリズムの識別精度を表2に示す.

表2 検証結果

機械学習モデル	9-分割交差検証	leave-one-out 交差検証
SVM	0.31	0.06
ランダムフォレスト	0.43	0.41
ニューラルネットワーク	0.35	0.36
畳み込みニューラルネットワーク	0.55	0.41

結果, 9-分割交差検証では, 畳み込みニューラルネットワークが他より精度が高かった. また, leave-one-out 交差検証では, SVMが圧倒的に精度が低くランダムフォレストと畳み込みニューラルネットワークの精度が高かった.

SVMはデータセットの件数が少ない場合に有利である機械学習モデルであるにもかかわらず, 精度が低い結果となった. これは, センサー情報である説明変数が多すぎてうまく学習を行えなかったことが原因である.

ランダムフォレスト, ニューラルネットワーク, 畳み込みニューラルネットワークの3つのモデルでは学習データに対する精度はほとんど9割を超えていたが, テストデータではそれほど良い結果を得ることはできなかった. 学習データに適合しすぎて, 全体のデータセットに適合できておらず, これは, データセットの件数が少すぎるのが原因であると言える. また, データ件数を増やすためには, データを半永久的に自動で計測するようなシステムが必要である.

5.2 行動の種類と予測精度

本研究のセンサーの種類, 数, 位置, アルゴリズムの種類などの環境でどの行動が識別できているか, またはできていないかを調べるため, 精度が高かったランダムフォレストと畳み込みニューラルネットワークについて, 誤認識した行動を分析した. 特に特定のアルゴリズムにとって予測が苦手な行動があれば, その行動の予測が得意な他のアルゴリズムを併用するシステムを組み込むことで全体の予測精度を向上させることが可能である.

leave-one-out 交差検証で誤認識した行動のパターンは何が多いかをランダムフォレストと畳み込みニューラルネットワークについて10回実行して調べた. ランダムフォレストで誤認識した行動のパターンのうち上位3個を表3に, 畳み込みニューラルネットワークで誤認識した行動のパターンのうち上位3個を表4に示す.

表3 誤認識した行動のパターン(ランダムフォレスト)

順位	正しい行動	予測された行動	回数
1	転落	着座(奥)	45
2	起立(奥)	着座(手前)	44
3	着座(手前)	起立(奥)	43

表4 誤認識した行動のパターン(畳み込みニューラルネットワーク)

順位	正しい行動	予測された行動	回数
1	転落	着座(奥)	62
2	退出	起立(手前)	51
3	入出	退出	44

一番誤認識の多かったパターンが2つの機械学習モデルで一致した。転落を着座(奥)と間違えるパターンであるが、その逆である着座(奥)を転落と間違えるパターンも誤認識が多いパターンではあった。転落と着座(奥)の誤認識パターンはどちらも、図??のセンサー9によって足元の動きが検知され、センサー5,6によって高い場所での動きが検知されない動きであるため、センサーから見れば似た行動であることが分かる。転落を着座(奥)と誤認識パターンと着座(奥)と転落を誤認識パターンの両方が多いため、片方の行動パターンを削ることによって行動の識別精度が上がることを予想される。

RandomForestについては、起立(奥)を着座(手前)とその逆である誤認識するパターンと着座(手前)を起立(奥)と誤認識パターンのどちらも上位であった。これは、被介護者が奥で動いていることを検知する人感センサーと手前で動いていることを検知する人感センサーの設置位置が近く、手前か奥のどちらで行動を行っているかを判断できていない可能性が高い。この対策の一つとしては、図??のセンサー1と2,3と4の間の距離が54cmとしたが、この距離を増やすことである。行動を行っているのが手前か奥かを判別しやすくなる。

畳み込みニューラルネットワークについての誤認識した行動パターンについても同様に、センサーにとっては似ている行動であるために判断がつきにくい可能性がある。これらの対策の一つとしては、人感センサー以外にも音響センサーを取り付ける方法がある。着座(奥)のときは、それほど大きな音はならないが、転落の時は大きな音になる可能性が高いため、うまく判別できると思われる。ランダムフォレストは、誤認識パターンの2番目と3番目より起立(奥)と着座(手前)の判断が苦手であることが分かった。また、ランダムフォレストは畳み込みニューラルネットワークに比べて、誤認識のパターンが分散していた。畳み込みニューラルネットワークの方が完全に見分けがつかない行動の種類が少ないといえる。反対に誤認

識が全くないパターンは多数存在しこれらのパターンは本研究の9個の人感センサーの位置で識別することが可能であったことが分かる。たとえば、寝返りと起立(奥)のパターンはセンサー5,6によって高い場所の動きが検知されるかされないかで判別できるため、予測が容易であったことが窺える。

予測しにくかった行動は、センサーの種類や位置の変更,または、予想した行動と正しい行動が互いに認識できていない場合はその行動のうちどちらかに絞ることで予測精度が向上できると考えた。

6 まとめ

本研究では、見守り支援のために複数の人感センサーで計測した被介護者の行動データから9種類の行動の識別を行った。複数のアルゴリズムによって、行動を識別し、それぞれのアルゴリズムの識別精度を評価し比較した。実験では、情報工学科9名に9種類の行動を行ってもらった。SVM, ランダムフォレスト, ニューラルネットワーク, 畳み込みニューラルネットワークの4つの機械学習アルゴリズムによって、人感センサーで記録して作成したデータセットを9個の行動に識別し、その精度を検証した。

2種類の精度評価手法で検証した結果、9分割交差検証では畳み込みニューラルネットワークの精度が他と比べて高く、leave-one-out交差検証ではランダムフォレストと畳み込みニューラルネットワークの精度が高かった。また、誤認識の行動パターンについて注目すると、手前と奥のどちらで行動を行っているかを判別できていない可能性が高いことが分かった。これらの認識精度は、センサーの数や位置を変更したり、センサーそのものを加速度センサー音響センサーなどに変更したりすることで改善すると考えた。今後の課題としては、被介護者が行う行動の種類の変更、ベッド周辺に取り付けたセンサーの数や位置の変更、センサーの種類追加や変更などがある。本研究では、行動が行われた時間を実験時にあらかじめ記録していたため認知できたが、実際に医療現場で実装する場合には、行動が行われているかどうかを判別する仕組みが必要である。

謝辞

本論文の執筆および研究を進めるに当たり、多くの方々に協力して頂きました。この場をお借りしてお礼を申し上げます。ありがとうございました。指導教員である上野秀剛准教授には、この1年間を通して研究に関する知識のご教授から、アドバイス、論文のチェックまで多くの面でご多忙の中、ご指導頂きました。また、専攻科編入における推薦書の執筆や面接練習も受けて下さり、アドバイスを頂くなど1年間支えていただきました。ここに深謝の意を表明させていただきます。ありがとうございました。査読教員である松尾賢一准教授には、ご意見・ご指摘を頂きました。ここに深謝の意を表明させていただきます。ありがとうございました。同じ上野研究室であった皆さまには、発表での至らぬ点の指摘や研究に対するアドバイスなどの面で支えていただきました。また、新入生歓迎会や研究室旅行などの様々な行事も主催して頂き楽しませて頂きました。ここに深謝の意を表明させていただきます。ありがとうございました。同級生の皆様には、研究や課題に追われる中、被験者として研究実験に協力していただきました。ここに深謝の意を表明させていただきます。ありがとうございました。

参考文献

- [1] Mikio Kawakami, "人感センサーを用いた要介護者の危険行動認識", (2016)
- [2] Katsunori Ohnishi, Atsushi Kanehira, Asako Kanazaki, and Tatsuya Harada, "Recognizing Activities of Daily Living with a Wrist-mounted Camera, " Conference on Computer Vision and Pattern Recognition (CVPR), (2016).
- [3] Alejandro Cartas, Juan MarÃn, Petia Radeva, and Mariella Dimiccoli, "Recognizing Activities of Daily Living from Egocentric Images, " In Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), (2017).
- [4] Shuangjun Liu, Yu Yin, and Sarah Ostadabbas, "In-Bed Pose Estimation: Deep Learning with Shallow Dataset, " Journal of CoRR, arXiv:1711.01005, (2017).
- [5] Zaineb liouane, Tayeb Lemlouma, Philippe Roose, FrÃdericWeis, and Hassani Messaoud, "A Markovian-based Approach For Daily Living Activities, " The International Conference on Sensor Networks (SENSORNETS'16), (2016).
- [6] Ivan M. Pires, Nuno M. Garcia, Nuno Pombo, and Francisco FlÃşrez-Revuelta, "A Multiple Source Framework for the Identification of Activities of Daily Living Based on Mobile Device Data, " Journal of CoRR, arXiv:1711.00104, (2017).
- [7] Ivan M. Pires, Nuno M. Garcia, Nuno Pombo, Francisco FlÃşrez-Revuelta, and Susanna Spinsante, "Pattern Recognition Techniques for the Identification of Activities of Daily Living using Mobile Device Accelerometer, " Journal of CoRR, arXiv:1711.00096, (2017).
- [8] Vladimir N. Vapnik and Alexey Ya. Chervonenkis, "Pattern recognition using generalized portrait method, " Automation and Remote Control, 24, pp.774-780, (1963).
- [9] Leo Breiman "RANDOM FORESTS", Machine Learning 4, pp.5-32, (2001).
- [10] Rosenblatt, "Frank The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain, " Psychological Review, 65(6), pp.386-408, (1968).
- [11] David E. Rumelhart, Hinton E. Geoffrey, and Williams J. Ronald, "Learning Internal Representations by Error Propagation, " Exploration in the Microstructure of Cognition, 1, pp.318-362, (1986).
- [12] Yann A. LeCun, Bernhard E. Boser, John S. Denker, Donnie Henderson, R. E. Howard, Wayne E. Hubbard, and Lawrence D Jackel, "Backpropagation applied to handwritten zip code recognition, " Neural Computation, 1(4), pp.541-551. (1989).
- [13] M. Stone, "Cross-validatory choice and assessment of statistical predictions, " Journal of the Royal Statistical Society, Series B, 36(2), pp.111-147, (1974).

- [14] M. Stone, "Cross-Validation and Multinomial Prediction, " Journal of the Royal Statistical Society, Series B (Methodological), 36(2), pp.111-147, (1974).
- [15] scikit-learn-0.19.1, <http://www.scikit-learn.org>.
- [16] tensorflow-1.4.1 , <https://www.tensorflow.org>.