

# 少数のデバイスによる生活行動を対象とした行動推定システムの検討

関 祐弥† 今井 信太郎†

岩手県立大学大学院ソフトウェア情報学研究科†

## 1. はじめに

家電の自動制御や消費電力の観点から生活アドバイザーをするサービスの開発がさかんに行われている。これらのサービスでは、屋内における人の行動を推定する必要がある場合が多く、これまでに様々な屋内の行動推定に関する研究が行われている。しかしカメラ画像を用いた画像処理による手法<sup>1)</sup>では利用者のプライバシーを侵害する恐れがある。利用者の所持しているスマートフォンやウェアラブルデバイスなどを用いる手法<sup>2)</sup>では測位精度を向上させやすいが、常にデバイスを装着する必要があるため利用者に負荷がかかる。これらの問題に対し、カメラを除く多種類のセンサを複合させた単体の汎用デバイスを用いる手法<sup>3)</sup>が提案されているが、推定の対象となる行動には限定的なものや頻度の低いものが含まれており、有効性に疑問がある。

そこで本研究では、利用者の負担を抑えることに加え、日常生活の主要な生活行動を推定することを目的としたシステムを提案する。

## 2. 関連研究

屋内の行動を推定する研究はすでに多く研究されている。Castroらは、スマートフォンのカメラを使用し、ディープラーニングにより19種類の日常生活を83.07%の精度で推定するシステムを構築した<sup>1)</sup>。しかし、カメラを身に着けているため利用者のプライバシーを侵害する恐れがある。

大内らは、携帯電話に搭載されている加速度センサとマイクを用いて3種類の状態とさらに細分化された7つの行動を平均85.9%の精度で推定するシステムを構築した<sup>2)</sup>。しかし、常にデバイスを身に着ける必要があるため、利用者に負荷がかかる。

Laputらは10種類のセンサを1カ所に設置し、機械学習により38種の行動を平均96%の精度で認識するシステムを構築した<sup>3)</sup>。しかし家庭内で発生する9種類の生活行動には限定的な行動が含まれており、主要な生活行動を十分に推定できているとはいえない。

## 3. 提案システム

本研究では日常生活を支援するサービスへの活用を可能とする、利用者の負担を抑えた屋内行動推定システムを提案する。そのため本システムは、カメラを使わない、タグ等の携帯を前提としない、低コストで導入できる、少数のデバイスで環境を網羅する、主要な生活行動を推定の対象とするという5つの要件を満たす必要がある。

本研究では推定の対象となる生活行動を、総務省統計局の詳細行動分類表を参考に、睡眠、食事、トイレ、入浴、洗面、料理、食器洗い、掃除、洗濯、干す、勉強、外出帰宅、PC、ゲーム、TVの15種類とした。

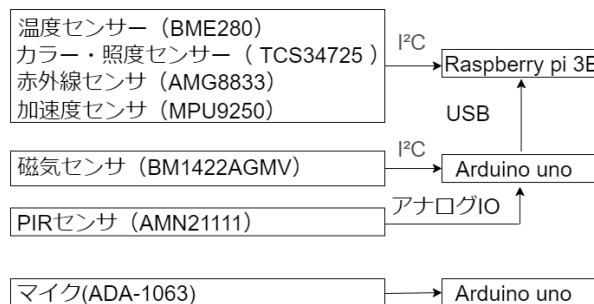


図1 提案システムのセンサ構成

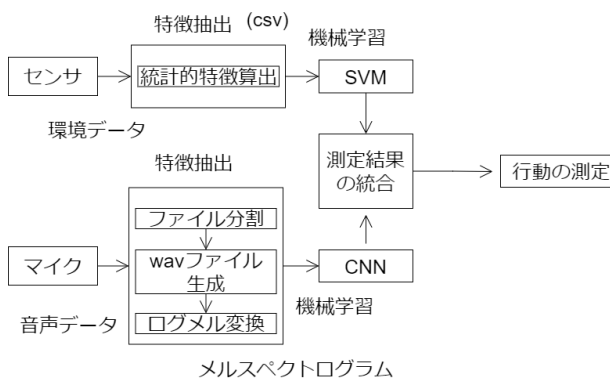


図2 提案システムの処理の流れ

提案システムは、図1の構成にある6つのセンサから得られるデータに加え、マイクから得られる音声データに対して Support vector machine (SVM)と Convolutional Neural Network (CNN)を適用して行動推定を行う。提案システムの処理の流れを図2に示す。温度、カラー・照度、赤外線、磁気、PIRセンサは10Hz、加速度センサは

Investigation of estimating living behavior system using a small number of devices

† Yuya Seki, Shintaro Imai  
Iwate Prefectural University

100Hz でデータを取得し、各センサから得られたデータに対し1秒ごとに、最大、最小、範囲、平均、合計、標準偏差、重心の7つの統計的特徴を算出する。

SVM では次の処理を行う。(1) システムはセンサからのデータを受信し、各データ値に対して特徴量を算出した後、CSV フォーマットでデータを保存する。(2) データと生活行動の紐づけ：1 で得られたセンサデータに対し、行われていた生活行動に対応するラベルを手動でラベル付けする。(3) 機械学習を使ったモデルの作成：ラベル付けされた学習用データを用いて学習モデルを作成する(4) 推定：学習済のモデルを用いて、取得したデータから行動推定を行う。

CNN では次の処理を行う。(1) 音声データの収集：マイクから受信したデータをもとに wav ファイルを生成する。(2) メルスペクトログラム生成：生成された wav ファイルを 5 秒ごとに分割し、Mel-Frequency Cepstrum Coefficients (MFCC) を計算してメルスペクトログラムに変換する。(3) 3. 機械学習を使ったモデルの作成：ラベル付けされた学習用データを用いて学習モデルを作成する。(4) 推定：学習済のモデルを用いて、取得データのメルスペクトログラムに対し行動推定を行う。

予備実験の結果から、(1)システム始動後の 5 秒間は CNN の推定結果が存在しないため、SVM の推定結果を採用する。(2)以後、5 秒ごとに CNN から出力される推定結果を参照する。(3)15 種類の生活行動のうち、入浴、洗面、食器洗い、掃除、洗濯、外出帰宅、PC、ゲーム、TV であると CNN が判定した場合はその結果を採用し、それ以外の場合は SVM の推定結果を採用する。

#### 4. 評価実験

実験はアパートの一室で行う。センサおよびマイクをつなげたデバイスを部屋のほぼ中央に当たる位置に 1 つ設置し、対象の 15 種類の生活行動それぞれに関して 180 秒間分を測定しデータを収集する。この一連の作業を異なる日で 5 回行う。実験において、SVM では、収集した 180 秒×15 種類×5 回の計 13,500 個のデータを学習用とテスト用に 8 : 2 に分割し、学習および推定を行った。学習用データの正解ラベルは手動で付与した。CNN では収集した音声ファイルを分割して得られたデータ 36 個×15 種類×5 回の計 2,700 個のデータを同様に分割、学習、推定を行った。

実験の結果、15 種類の行動の平均推定精度は 54.8%であった。行動別の精度を表 1 に示す。

表 1 行動別の精度

生活行動	accuracy	生活行動	accuracy
1 睡眠	32.7%	9 洗濯	88.2%
2 食事	67.4%	10 干す	0%
3 トイレ	52.4%	11 勉強	0.3%
4 入浴	96.7%	12 外出帰宅	63.5%
5 洗面	83.2%	13 PC	72.8%
6 料理	94.0%	14 ゲーム	12.3%
7 食器洗い	31.1%	15 TV	53.6%
8 掃除	73.0%	全体	54.8%

提案システムの要件のうち、カメラを使わない、タグの携帯を前提としない、低コストで導入できる、主要な生活行動を推定の対象とする 4 つは達成できたが、1 つのデバイスで環境を網羅するに関しては、推定精度を鑑みると達成できたとはいえない。推定精度が低かった要因として、3 節で SVM の推定結果を採用するとした 6 行動の推定精度の平均が 49.3%低く、統合したときに、干す、勉強などの推定精度に大きな影響を及ぼした。

#### 5. おわりに

本研究では日常生活を支援するサービスへの活用を可能とするため、利用者の負担を抑えることに加え、日常生活における主要な生活行動を推定することを目的とした屋内行動推定システムを提案した。評価実験の結果を考えると実用化には多くの改良が必要であるといえる。

今後の課題として、CNN が推定するのが苦手な行動を SVM がカバーする必要があると考えられる。よってセンサ構成の見直し、センサの周波数の改良、適切な SVM と CNN の推定結果の統合方法を定めるなどの改善を行う必要がある。

#### 参考文献

- 1) Castro, D., et al.: Predicting daily activities from egocentric images using deep learning, Proc. of the 2015 ACM Int. Symposium on Wearable Computers, pp. 75-82 (2015)
- 2) Ouchi, K. and Doi, M.: Smartphone-based monitoring system for activities of daily living for elderly people and their relatives etc., Proc. of the 2013 ACM conf. on Pervasive and ubiquitous computing adjunct publication, pp. 103-106 (2013)
- 3) Laput, G., et al.: Synthetic sensors: Towards general-purpose sensing, Proc. of the 2017 CHI Conf. on Human Factors in Computing Systems, pp. 3986-3999 (2017)