

# 家電操作ユーザ推定のための タッチパネルボタンを用いた特徴量の検討

須田 恭平<sup>1</sup> 石田 繁巳<sup>2</sup> 稲村 浩<sup>2</sup>

概要：近年、AIやIoTを活用し、人々の暮らしをより良くするスマートホームの実現が進められている。スマートホームの実現には、ユーザの行動を認識し、その履歴を蓄積する必要がある。既存研究では家庭内に大量のセンサを設置することでユーザの行動データを収集しているが、収集した行動データにはユーザ情報が含まれておらず、複数ユーザの行動をユーザを区別しながら認識することはできない。本研究では、家電操作から収集したデータを用いてユーザ推定を行うことで、ユーザと紐付け可能な家庭内行動認識手法を提案する。本稿では、様々な家電操作のうち、ボタン操作を用いたユーザ推定手法を提案する。8人の被験者から収集したボタン操作データを用いて提案手法のユーザ推定性能を評価した結果、学習データ量が10試行かつ押した強さから得られる特徴量のみ用いた場合に82.3%の正解率が得られた。この結果は、センサを複数必要とする既存研究と同程度の値であることから、単一センサによるユーザ推定の実現可能性を示すことができた。

## 1. はじめに

近年、AIやIoTといった最新技術を活用し、人々の暮らしや日々の営みを安心・安全・快適にするスマートホーム [1] の実現が進められている。このようなスマートホームの実現には、ユーザの行動を認識し、その履歴を蓄積する必要がある。

家庭内においてユーザの行動を認識する手法として、赤外線センサ・ドア開閉センサ等を設置する手法 [2] や圧力マット・フロートセンサ等を設置する手法 [3] など、様々な「センサ」を用いる手法が報告されている。しかしながら、これらの手法で認識した行動情報にはユーザ情報が含まれておらず、複数ユーザの行動をユーザを区別しながら認識することはできない。

これに対し、本研究ではリモコンや操作パネルのような家電の「コントローラ」に「センサ」を組み込むことで、複数ユーザの行動をユーザを識別しながら認識する手法を提案する。日常的な家電のコントローラ操作の「癖」からユーザを推定することで、この家電を「いつ」「誰が」使用したかを特定する。

家電で用いられているコントローラには様々な種類が存在する。筆者らが家電を調査したところ、多くの家電のコントローラはボタンスイッチ、回転（ひねる）スイッチ、

スライドスイッチ、動きを読み取るコントローラの4種類に分類できた。それぞれのコントローラでユーザを推定できれば、多くの家電の操作でユーザ推定が可能になる。

これまで、筆者らは動きを読み取るコントローラとして「PCのマウス」を用いたユーザ推定手法を提案した。24人の被験者から収集した操作データを用いて評価したところ、正解率93.5%でユーザを推定できることを確認した [4]。

本稿では、家電コントローラの多くを占めるボタンスイッチを用いたユーザ推定の可能性を検証した。押下位置と押下圧力を同時に収集できるタッチパネルを用いて、ボタンを押下する際の押下位置、押下圧力データを8人の被験者から収集してユーザ推定性能を評価した。この結果、学習データ量が10試行かつ押下圧力から得られる特徴量のみ用いた場合に82.3%の正解率でユーザ推定できることを確認した。これは、センサを複数必要としていた既存研究 [5] と同程度の推定結果である。

本稿の構成は以下の通りである。2章では家庭内行動認識とユーザの身体動作に基づくユーザ推定の関連研究について述べ、3章では本稿で提案する家電のタッチパネルボタン操作によるユーザ推定システムを示す。4章では提案システムの評価を示し、最後に5章でまとめとする。

## 2. 関連研究

本研究は、家庭内行動認識およびユーザの身体動作を

<sup>1</sup> 公立はこだて未来大学大学院 システム情報科学研究科

<sup>2</sup> 公立はこだて未来大学 システム情報科学部

用いるユーザ推定に関連している。2.1 ではユーザの行動データを収集する研究である家庭内行動認識の関連研究とその問題点を、2.2 ではユーザの身体動作を用いるユーザ推定の関連研究とその問題点を述べる。

## 2.1 家庭内行動認識

家庭内行動認識の研究では、家庭内にセンサを設置する手法やウェアラブル端末を身につける手法が報告されている。

家庭内にセンサを設置する手法として、複数種類のセンサを用いる手法が提案されている。柏本ら [2] は、赤外線センサ、ドア開閉センサ、電力センサを用いた家庭内行動認識手法を提案しているが、合計 50 個以上のセンサを設置する必要がある。Kasteren ら [3] は、圧力マット、フロートセンサ、リードスイッチ等のセンサを用いた手法を提案しているが、少なくとも 14 個のセンサを設置する必要がある。

このように、センサを用いる家庭内行動認識では大量のセンサを設置する必要がある、費用や設置する労力が大きいことに加え、2 人以上が暮らす環境では認識した行動を行ったユーザを特定することができない。カメラを用いた行動認識 [6] や、カメラを用いてユーザを特定する研究 [7] も報告されているが、家庭内を常にカメラで撮影する必要があり、ユーザのプライバシーを侵害することから現実的ではない。

ウェアラブル端末を用いた行動認識では、各ユーザがウェアラブル端末をそれぞれ身につけることからユーザを区別しながら行動を認識できる。Shahmohammadi ら [8] や Nandy ら [9] は、スマートウォッチを用いて、歩く、走る、座る等のユーザの状態を推定する手法を報告している。Paraschiakos ら [10] は、ウェアラブル端末を用いて、皿洗いや掃除機をかける等の家庭内の活動を認識する手法を報告しているが、体の様々な部位に異なるウェアラブル端末を身につける必要がある。これらの手法ではウェアラブル端末を常に身につけておく必要があるため、普段からウェアラブル端末を身につけていないユーザには、違和感や不快感を与えてしまうおそれがある。加えて、ウェアラブル端末自体が高価なため、家族全員がウェアラブル端末を持つと高い費用がかかる。

本研究では、家電のコントローラにセンサを組み込んだユーザ推定手法により家庭内行動認識を行う。提案手法は様々な行動を認識するものではないが、家庭内に大量のセンサを設置したり身につける必要がなく、ユーザ情報をラベル付けした家庭内行動認識を実現できる。

## 2.2 ユーザの身体動作を用いるユーザ推定

2.1 で挙げた研究はユーザを特定するものではないが、

ユーザ認証の研究分野ではユーザの身体動作から収集したデータを用いてユーザを推定する研究が行われている。

ユーザ認証のうち、身体動作を用いる認証手法であるジェスチャ認証の研究として、Mare ら [11] は、リストバンドを装着した状態でスマートフォンを持ち上げる動作からユーザ認証する手法を報告している。石原ら [12] は、携帯端末を用いて空中に名前を書くことで認証する手法を報告している。しかし、いずれの手法も学習のために同じ動作を 20 回以上繰り返したり、30~40 分かけて必要なデータを収集したりする必要がある。ユーザ認証の研究では、高いユーザ推定性能が求められているため、「操作の学習データ量を多く必要とする」、「認証動作に日常的とは異なる複雑な動作が指定される」などの制約が生じる。

推定性能の目標値を下げ、単純な操作を用いてユーザを推定する研究も報告されている。Pohl らの研究では、家電の操作ユーザを推定するためにボタン操作を用いる手法 [5] を提案している。この手法では、圧力センサに加えて距離センサという特殊なセンサを家電に搭載する必要がある。

本研究では、家庭内行動認識を目的にユーザ推定を行うため、ユーザ認証のような推定性能は必要としていない。高い推定性能を必要としないため、ユーザが日常的に行う単純な操作であってもユーザ推定ができると考える。家電のコントローラ自体をセンサとして利用することで追加のデバイスを必要とすることなくユーザを推定する。

## 3. タッチパネルボタン操作によるユーザ推定システム

### 3.1 キーアイデア

本研究で提案するユーザ推定のキーアイデアは、日常的な家電操作の癖を用いてユーザを推定することである。家電に取り付けられたボタンを押すという短時間の行動であっても、ユーザによって押す強さや時間が異なることが予想される。そこで、ユーザごとに異なる特徴を用いて教師あり学習によりユーザを推定する。

図 1 は、4 人のユーザがボタンを長押ししたときの圧力の時間変化を示したものである。図では圧力センサで認識できる最大の圧力を 1.0 として正規化している。図より、操作に要する時間や力の入れ具合などがユーザごとに異なることがわかる。そこで、押下位置・圧力の時系列データからこのような個人差を持つ特徴量を抽出し、ユーザを推定する。

### 3.2 想定環境

提案システムの利用は家庭環境を想定するため、少人数のユーザを推定できればよい。総務省統計局が行った 2023 年 1 月分の労働力調査 [13] によると、世帯人数が 4 人以下の世帯は全体の約 94% を占める。4 人のユーザを区別でき




図 1: ユーザによるボタン押下時の圧力変動

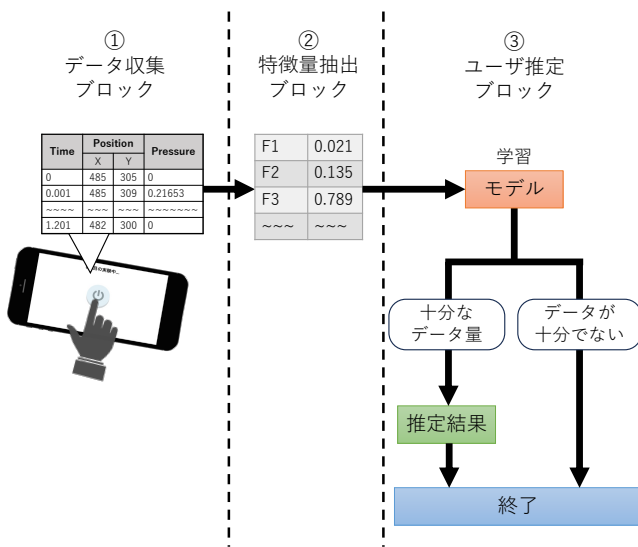


図 2: システム概要図

ればほとんどの家庭をカバーできるため、本システムで想定する最大推定人数を 4 人と設定する。

### 3.3 システム概要

本研究で提案するユーザ推定システムの概要図を図 2 に示す。ユーザがボタンを押すと、データ収集ブロックが押下位置・圧力のセンサデータを記録する。特徴量抽出ブロックでは、前のブロックで収集したデータから提案する特徴量が抽出される。ユーザ推定ブロックでは、前のブロックで抽出された特徴量を用いてユーザ推定モデルを学習する。学習後、教師あり学習モデルの学習に必要な十分なデータ量を収集できている場合は、ユーザ推定結果を出力する。十分なデータ量が収集できていない場合は、ユーザを推定せずに処理を終了する。なお、教師あり学習モデルの学習に必要なラベルデータの収集については本稿では扱わない。本稿ではユーザ推定の可能性を確認するために、すべてラベル付けされたデータを使用したが、今後は自己教師あり学習や半教師あり学習などを活用して必要最

小限のラベルを収集することを想定している。以降は各ブロックの詳細について説明する。

### 3.4 データ収集ブロック

データ収集ブロックでは、ユーザがボタンを押したときのセンサデータを収集する。

ボタン操作から収集可能なデータは、表 1 に示す 5 つが考えられる。操作感を変えない点やセンサを家電のコントローラに組み込む点を考慮すると、収集方法できるデータはボタンにかかる圧力とボタンを押す位置に限定される。そのため、ボタン操作を用いたユーザ推定では押下位置と押下圧力を収集することとした。具体的には、押下位置はタッチパネル上の  $x, y$  座標、押下圧力はタッチパネル内臓の圧力センサ値を、操作開始からの経過時刻とともに収集する。

表 1: ボタン操作から収集可能なデータ

収集データ	使用センサ
ボタン押下の映像 [14]	カメラ
手の動き [15]	ウェアラブル端末
手首の位置 [5]	距離センサ
ボタンを押す位置	タッチパネル
ボタンにかかる圧力	圧力センサ

### 3.5 特徴量抽出ブロック

特徴量抽出ブロックでは、データ収集ブロックで収集したデータから提案する特徴量を抽出する。本稿ではボタン操作を用いたユーザ推定のために、表 2 に示す 28 次元の特徴量を抽出する。これらの特徴量は、関連研究や筆者ら

表 2: 特徴量

次元	特徴量	位置	圧力	特徴量グループ
1	操作に要した時間	○	○	共通
1	サンプリングデータ数	○	○	共通
2	最初に押した $x, y$ 座標	○		位置
2	押下位置軌跡の $x, y$ 軸変動幅	○		位置
6	押下位置軌跡の速度と加速度の平均, 中央値, 標準偏差	○		位置
1	押下位置軌跡の総移動距離	○		位置
2	圧力が最大値であった合計時間および全体に占める割合		○	圧力
1	ボタンが押された判定になるまでに要した時間		○	圧力
1	最後に取得できた圧力		○	圧力
11	0.1 区切りの圧力分布の度数		○	圧力

による先行研究 [4] の結果に基づいて決定し、筆者らがユーザ間に違いが見られると判断した特徴量を追加した。各特




図 3: データ収集システムの画面遷移

微量のユーザ推定に対する有効性は 4 章において特徴量重要度を用いて検証する。

### 3.6 ユーザ推定ブロック

ユーザ推定ブロックでは、特徴量抽出ブロックで抽出した特徴量を用いて多クラス分類問題としてユーザを推定する。本提案手法では使用する機械学習アルゴリズムは指定しないが、筆者らの先行研究 [4] で高い推定性能を得られたことから、本稿では Linear カーネルを用いた SVM (Support Vector Machine) による学習を行う。

## 4. 評価

提案システムによるユーザ推定性能を評価するため、スマートフォンに表示したタッチパネルを模したボタンを押下する実験を行い、ユーザの操作データを収集した。本章では、実験に用いたシステムの詳細と実験環境について説明した後、ユーザ推定に有効な特徴量について検討する。次いで、ユーザ推定に必要な学習データを特定するために、学習データ量や学習データの取り出し位置を変動させた場合のユーザ推定性能を評価する。最後に、本操作に適した学習アルゴリズムを特定するために様々な学習アルゴリズムを用いた場合の推定性能を比較する。

### 4.1 データ収集システム

ボタン操作時のデータを収集するために、データ収集システムを実装した。図 3 に本システムの画面遷移を示す。データ収集システムは Web ページとして実装しており、実験端末からこのページにアクセスしてデータを収集する。本ページの実装には Pressure.js [16] を使用した。押下位置は JavaScript の event オブジェクトを参照し、押下圧力は Pressure.js によって提供される値を参照する。Pressure.js

表 3: 押し方の定義および押下時のフィードバック

押し方	押下判定の条件 (圧力)	フィードバック
短く押す	0.5 以上	0.5 を超えた直後に効果音を 1 度再生
長押し	0.5 以上で 1 秒間	0.5 を超えた直後に効果音を 1 度再生し、押下判定条件を満たすと、手を離すまで効果音を再生し続ける



図 4: 実験環境

から提供される値は、OS から通知される圧力値を正規化した 0~1 の値である。家電には様々な操作ボタンがあるが、ほぼすべての家電に電源ボタンが搭載されていることから、電源ボタンを模して画面を作成した。

家電のボタン操作には短く押す場合と長押しの 2 種類が存在するため、それぞれの押し方によるユーザ推定性能を評価する。このため、データ収集システムは短く押す場合と長押しの場合のそれぞれでデータを収集できるように設計した。

ボタンを押せたことをユーザが認識できるように、押下時にはフィードバックを与えた。表 3 に、各押し方の定義と押下時のフィードバックを示す。短く押すデータの収集時は、圧力が 0.5 を超えた直後に効果音を再生するフィードバックを行った。長押しする場合も同様に効果音を再生するが、圧力 0.5 以上で 1 秒間保持するとボタンから指を離すまで効果音を再生し続けるフィードバックを行った。なお、効果音には On-jin~音人~ [17] の壁スイッチ音を採用した。

### 4.2 実験環境

ボタン操作データ収集実験の環境を図 4 に示す。実験端末には Apple 社の iPhone7 を使用し、4.1 で示したデータ収集システムを端末上で実行してデータを収集した。被験者は 20 代の男性 7 人と女性 1 人の合計 8 人である。図に示すように、使用端末は机に対してほぼ鉛直に固定し、被験者にはイスに座った状態で端末を操作するように指示した。被験者に対し、操作に慣れるまで練習を行わせた後、

短く押す操作 100 回、長押し操作 100 回の合計 200 試行分のデータを収集した。本実験では 1 つのボタンを 1 回だけ操作する場合を想定し、各試行が独立したボタン操作になるように、被験者にはボタンを一度押すたびに手を下ろすように指示した。

なお、本実験で収集するデータには個人を識別可能な情報が含まれることが予想されるため、公立はこだて未来大学倫理委員会の実施許可（許可書番号：2021016）を得て実施した。

### 4.3 評価方法

ユーザ推定性能は、収集した 8 人の被験者データから 4 人を取り出してユーザ推定を行い、その正解率を評価した。つまり、 ${}_8C_4 = 70$  通りのユーザの組み合わせでそれぞれユーザ推定を行い、正解率の平均値を算出した。

### 4.4 特徴量の選択による推定性能評価

ユーザ推定に有効な特徴量を検討するため、表 2 に示した特徴量から以下の 3 つのパターンで特徴量を限定した場合のユーザ推定性能を比較した。

#### (1) 位置特徴量:

位置の列に○がついている特徴量を用いた場合

#### (2) 圧力特徴量:

圧力の列に○がついている特徴量を用いた場合

#### (3) 全特徴量:

すべての特徴量を用いた場合

評価は各被験者から収集した 100 試行分のデータすべてを使用し、10 分割交差検証により行った。

表 4 に、各パターンのユーザ推定の正解率を示す。表 4 を見ると、84.1%以上の正解率が得られている。複数センサを用いた既存研究 [5] では、4 人のユーザ推定において正解率が 90%程度であった。既存研究と実験データの収集環境や学習データ量が異なるため、単純に推定性能を比較することが難しいが、本稿で得られた推定性能はどの押し方と特徴量においても同程度の結果が得られている。特徴量に着目すると、「圧力特徴量」と「全特徴量」の間に正解率の差がほとんど見られないのに対し、「位置特徴量」の正解率は 8%程度低い。位置と圧力を併用することで 1%程度の性能向上が見られるが、大幅な性能向上効果は得られていない。以上の結果より、押下位置の収集は推定に不要であると考えられる。

表 4: 特徴量を限定した場合の正解率 [%]

		特徴量 (次元)		
		位置 (13)	圧力 (17)	すべて (28)
押し方	短く押す	84.1	92.5	92.6
	長押し	85.9	93.1	94.6

圧力の収集だけで十分であることを示すために、追加評価として各特徴量の推定への貢献度を評価した。具体的には、各特徴量が推定にどの程度影響を与えているかを調べるため、Random Forest を用いた「全特徴量」による学習を行い、このときの特徴量重要度を評価した。表 2 に示した特徴量それぞれに対して特徴量重要度を計算し、同表に示す 3 つの特徴量グループ、すなわち以下の 3 つのグループのそれぞれで特徴量重要度の合計を比較した。

#### (1) 位置特徴量グループ:

位置の列に○がついている特徴量

#### (2) 圧力特徴量グループ:

圧力の列に○がついている特徴量

#### (3) 共通特徴量グループ:

位置および圧力の両方の列に○がついている特徴量評価に使用したデータは特徴量を限定した評価で用いたものである。

結果は、表 5 に示す通りである。表 5 を見ると、「圧力特徴量グループ」の合計特徴量重要度が 0.6 程度であるのに対し、「位置特徴量グループ」は 0.15 程度であり、「位置特徴量グループ」の特徴量は推定にあまり寄与していないことがわかる。「位置特徴量グループ」の中で最も高い特徴量重要度は 0.3333 であり、「圧力特徴量グループ」の中で下位 5 番目と同程度の値であるため推定に高く貢献しているとは言い難い。実際、11 次元ある「位置特徴量グループ」の特徴量重要度の合計は、2 次元しかない「共通特徴量グループ」の特徴量重要度と同程度かそれ以下である。

表 5: 特徴量重要度

		特徴量グループ		
		位置	圧力	共通
押し方	短く押す	0.1367	0.5968	0.2666
	長押し	0.1786	0.6429	0.1785

正解率と特徴量重要度の結果を踏まえると、位置を収集するメリットは少ないことがわかる。さらに、どの評価においても、押し方による性能差はほとんど見られない。実環境においてユーザ推定に必要なセンサは少ないほうがよいので、ボタン操作における推定は圧力だけの収集により実現を目指す。

以降では、「圧力特徴量グループ」の特徴量のみを用いて評価を行った。

### 4.5 学習データ量による推定性能への影響評価

学習データ量を少なくすることができれば実環境で学習データを収集する手間を削減できるため、学習データ量を減らした場合のユーザ推定性能を評価した。各被験者の 91~100 試行目のデータを評価データとして固定し、学習データを 1~90 試行目のデータから量を変化させながら取






図 5: 学習データ量の評価結果




図 6: データの取り出し位置に対する評価結果

り出す。学習データは試行の後ろから順に取り出した。例えば 10 試行分を取り出す場合には 81~90 試行目のデータを、20 試行分取り出す場合には 71~90 試行目のデータを取り出した。

図 5 に、学習データ量に対するユーザ推定の正解率を示す。図より、90 試行すべてを学習に用いた場合の正解率が 88.4%であるのに対し、10 試行のみ用いた場合でも 82.3%であり、学習データ量による推定性能の大幅な変動は見られない。センサを複数必要とする関連研究 [5] では学習データ量が 10 試行の場合に正解率が 85%程度であったため、同程度の推定性能を得られている。10 試行を学習に用いることは、実環境ではボタンを 10 回押すことに相当する。1 日に 1 回程度しか使用されないコーヒーメーカーなどの家電においても、およそ 10 日分のデータを収集すればユーザ推定を実現できると考えられる。システムの利便性を考えると学習データの収集は少ないほうがよいため、学習に必要なデータ量を 10 試行分として実現を目指す。

以降の評価では、学習に用いるデータ量を 10 試行分とした。

#### 4.6 操作の慣れによる影響の評価

本稿の評価実験ではボタン操作をほぼ連続して行っているため、操作の「慣れ」がユーザ推定に影響を及ぼすことが予想される。このため、学習データの取り出し位置がユーザ推定の正解率にどのように影響するかを評価した。各被験者の 91~100 試行目のデータを評価データとし、取り出し開始位置を 10 試行ずつずらしながら 1~90 試行目のデータを学習データとして取り出してユーザを推定した。

図 6 に、学習データ取り出し位置に対するユーザ推定正解率を示す。評価データの直前である 81~90 試行目で学習した場合は正解率が 82.3%であるのに対し、1~10 試行目で学習した場合は 38.4%であり、正解率が大幅に低下し

ている。21~30 試行目で最も推定性能が低い結果となっているが、これは各被験者の練習不足によるものと考えられる。各被験者には事前に操作方法を理解してもらうために、回数を指定せずに操作の練習を行わせたが、ほとんどの被験者が行った練習回数は 1~3 試行であり、最も多い被験者でも 10 試行程度であった。操作方法を理解し、操作が安定するのに 20 試行程度の時間が必要であったと考える。21 試行目以降のデータを見ると正解率が徐々に上昇していることから、1 日に連続して収集したデータであっても、操作の慣れが推定性能に大きな影響を与えることがわかる。つまり、学習データは常に新しいものを収集し続ける必要があり、日を空けて収集したデータでは、推定の難易度が上がる可能性が示唆された。

#### 4.7 学習アルゴリズムの選択による推定性能評価

提案システムの学習アルゴリズムは、筆者らの先行研究 [4] で高い推定性能を得られた Linear カーネルの SVM を使用した。本稿で認識する操作は先行研究とは異なるため、異なる学習アルゴリズムのほうが高い推定性能を得られる可能性がある。そこで、多クラス分類問題に対応した様々な学習アルゴリズムでユーザ推定モデルを生成し、それぞれの性能を評価することで適切な学習アルゴリズムを検討した。比較した学習アルゴリズムは、これまでの評価で使用した Linear カーネルの SVM に加えて、Random Forest、ロジスティック回帰、k 近傍法 ( $k = 1$  とした)、ガウシアンナイーブベイズ、確率的勾配降下法、決定木、LightGBM である。SVM、ロジスティック回帰、k 近傍法、確率的勾配降下法では抽出した特徴量を標準化してから学習に使用した。

表 6 に、各学習アルゴリズムを用いた場合のユーザ推定正解率を示す。表より、Random Forest を用いた場合に最も高い正解率が得られていることがわかる。これは、本稿

で使用した特徴量の次元数が多かったため、SVM よりも高い推定性能が得られたと考える。その他の学習アルゴリズムでは、本研究で収集したボタン押下操作データを用いると過学習が発生し、Random Forest と比べると低い結果になったと考える。よって、ボタン押下操作によるユーザ推定では Random Forest が適していると言える。

表 6: 学習アルゴリズムごとのユーザ推定正解率

学習アルゴリズム	正解率 [%]	正解率 [%]
	(短く押す)	(長押し)
Random Forest	89.8	86.4
SVM (Linear カーネル)	84.7	83.6
ロジスティック回帰	84.0	84.2
k 近傍法 ( $k = 1$ )	81.4	80.4
ガウシアンナイーブベイズ	81.4	78.9
確率的勾配降下法	78.8	78.9
決定木	73.2	70.7
LightGBM	53.2	57.7

## 5. おわりに

本研究では、ユーザ情報を紐付けた家庭内行動認識の実現のために、家電に搭載されたコントローラにセンサを組み込むことで、複数ユーザの行動をユーザを識別しながら認識する手法を提案した。本稿では様々なコントローラ操作のうち、ボタンスイッチを用いたユーザ推定手法を提案し、その推定性能を評価した。

タッチパネルを用いた実験的評価の結果、学習データ量が 10 試行かつ押した強さから得られる特徴量のみ用いた場合に 82.3% の正解率でユーザを推定できることを確認した。さらに、適切な学習アルゴリズムを選択することで、正解率を 3% 程度向上させることができた。これは、センサを複数必要としていた既存研究 [5] と同程度の推定結果であるため、単一センサによるユーザ推定の実現可能性を示すことができたといえる。

本稿では、家電に搭載されるコントローラのうち、ボタンスイッチ操作におけるユーザ推定手法の実現可能性を示した。しかし、本実験で収集したデータは、座った状態で収集したデータのみであり、実環境では座っていない姿勢での家電操作も考えられる。さらに、連続して収集したデータにもかかわらず推定性能に変化が見られたことから、日を開けて収集したデータでは推定性能の低下を引き起こす可能性も考えられる。今後は、家電を用いた実環境で長期間に渡り収集したデータを用いて評価を行うことで、推定性能に与える影響を調査する。

謝辞 本稿で示した研究の一部は、JSPS 科研費 (JP20KK0258, JP21K11847) および東北大学電気通信研究所共同プロジェクト研究の助成で行われた。

## 参考文献

- [1] JEITA スマートホーム部会: 「スマートホーム」将来ビジョン, <https://home.jeita.or.jp/smarthome/deliverables/vision.html>.
- [2] 柏本幸俊, 秦 恭史, 中川愛梨 ほか: エナジハーベスト焦電型赤外線・ドア開閉センサと家電消費電力に基づいた宅内生活行動認識システム, *情報処理学会論文誌*, Vol. 58, No. 2, pp. 409–418 (2017).
- [3] van Kasteren, T. L. M., Englebienne, G. and Kröse, B. J. A.: An activity monitoring system for elderly care using generative and discriminative models, *Personal and Ubiquitous Computing*, Vol. 14, No. 6, pp. 489–498 (2010).
- [4] Suda, K., Ishida, S. and Inamura, H.: User Identification Based on Mouse Operation Toward Automatic Home Appliance Configuration, *IEEE 11th Global Conference on Consumer Electronics (GCCE)*, pp. 714–715 (2022).
- [5] Pohl, H., Krause, M. and Rohs, M.: One-button recognizer: exploiting button pressing behavior for user differentiation, *Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing - UbiComp '15*, Osaka, Japan, pp. 403–407 (2015).
- [6] Fiore, L., Fehr, D., Bodor, R., Drenner, A., Somasundaram, G. and Papanikolopoulos, N.: Multi-Camera Human Activity Monitoring, *Journal of Intelligent and Robotic Systems*, Vol. 52, No. 1, pp. 5–43 (2008).
- [7] 中村勇貴, 宵 憲治, 前中省吾, 岩口亮史, 柏本幸俊, 安本慶一: 家庭内の行動推定のためのスマートカメラシステムの開発, 第 77 回全国大会講演論文集, Vol. 2015, No. 1, pp. 127–128 (2015).
- [8] Shahmohammadi, F., Hosseini, A., King, C. E. and Sarrafzadeh, M.: Smartwatch Based Activity Recognition Using Active Learning, *IEEE/ACM International Conference on Connected Health: Applications, Systems and Engineering Technologies (CHASE)*, pp. 321–329 (2017).
- [9] Nandy, A., Saha, J., Chowdhury, C. and Singh, K. P.: Detailed Human Activity Recognition using Wearable Sensor and Smartphones, *International Conference on Opto-Electronics and Applied Optics (Optronix)*, pp. 1–6 (2019).
- [10] Paraschiakos, S., Cachucho, R., Moed, M., van Heemst, D., Mooijaart, S., Slagboom, E. P., Knobbe, A. and Beekman, M.: Activity recognition using wearable sensors for tracking the elderly, *User Modeling and User-Adapted Interaction*, Vol. 30, No. 3, pp. 567–605 (2020).
- [11] Mare, S., Rawassizadeh, R., Peterson, R. and Kotz, D.: Continuous Smartphone Authentication using Wristbands, *Proceedings Workshop on Usable Security*, San Diego, CA, Internet Society (2019).
- [12] 石原 進, 太田雅敏, 行方エリキ, 水野忠則: 端末自体の動きを用いた携帯端末向け個人認証, *情報処理学会論文誌*, Vol. 46, No. 12, pp. 2997–3007 (2005).
- [13] 総務省統計局: 地方別, 世帯人員別の世帯数分布表 (100 万分比), [https://www.stat.go.jp/data/kakei/setai/\\_bunpu.html](https://www.stat.go.jp/data/kakei/setai/_bunpu.html).
- [14] 齋藤祐生, 藤川真樹: 指ジェスチャによる本人認証システムの提案-ハンドトラッキング技術の応用-, 第 84 回全国大会講演論文集, Vol. 2022, No. 1, pp. 565–566 (2022).
- [15] 芝田龍正, 三上 剛, 秋月拓磨, 高橋弘毅: 個人認証を念頭に置いた表面筋電位を用いた svm によるジェスチャ判別, *日本知能情報ファジィ学会ファジィシステム シンポジウム 講演論文集*, Vol. 36, pp. 77–82 (2020).
- [16] Yamartino, S.: Pressure.js, <https://pressurejs.com/>.
- [17] フリー効果音 On-Jin~音人~: <https://on-jin.com/>.