

# 時間関連特徴量の追加による宅内行動推定精度の改善

水本 旭洋<sup>1,a)</sup> Pattamasiriwat Krita<sup>2</sup> 荒川 豊<sup>1</sup> 安本 慶一<sup>1</sup>

**概要:** 省エネ家電制御や高齢者の見守りなどの生活支援サービスを実現するためには、住人の宅内における生活行動をリアルタイムに認識することが不可欠である。宅内生活行動の認識を対象とした既存手法では、カメラ等の機器によりプライバシーを侵害する、認識する行動の種類が少ない、認識精度が低い、導入コストが高い、認識までに時間がかかるなどの課題が残されている。本研究の先行研究にあたる中川らの手法では、上記の課題を解決するために、位置情報と消費電力情報を用いた宅内生活行動認識手法を提案しており、10種類の生活行動について平均79%の認識精度でリアルタイムに認識可能という結果が得られている。しかし、仕事・勉強や洗面所で行う行動など、一部の行動において認識精度が低い結果が得られた。本研究では、先行研究の宅内生活行動認識手法に、行動が発生した時間帯、および、宅内の各エリアにおける住人の滞在時間といった時間に関連する特徴量を加えることにより、認識精度を平均82%まで向上できることを確認した。

## Improving Accuracy of In-Home Activity Recognition by Adding Time-Related Features

MIZUMOTO TERUHIRO<sup>1,a)</sup> PATTAMASIRIWAT KRITA<sup>2</sup> ARAKAWA YUTAKA<sup>1</sup> YASUMOTO KEIICHI<sup>1</sup>

### 1. はじめに

近年、センシングデバイスの低価格化や普及により、住宅内の人の日常生活行動を認識しようとする研究が多く行われるようになった。宅内の生活行動を認識することで、省エネ家電制御や高齢者の見守りなどの生活支援サービスへの活用が期待できる。しかし、これらのサービスでは、多種多様な生活行動の中から、現在行われている行動を高精度かつリアルタイムに認識することが重要となる。

これまでに、住宅内の生活行動を認識する様々な手法が研究されている。しかしながら、(1) カメラ等の機器によりプライバシーを侵害する、(2) 認識できる行動の種類が少ない、(3) 認識の精度が低い、(4) 導入及び維持コストが高い、(5) 認識までに時間がかかるという課題がある。

我々はこれまでに、居住者の位置情報と家電の消費電力

を用いて(1)~(4)の課題を解決する行動認識手法[1]、および、サンプリング周期の短いセンサを導入し、[1]の手法を基に教師データ数の制限や特徴量の選択などの工夫を加えることで、認識精度を保ちながらリアルタイムな行動認識を可能にする手法[2](中川らの手法)を提案してきた。中川らの手法では、住宅内における日常生活行動を料理関連行動やテレビ視聴などの省エネや高齢者見守りに関連する10種類の行動に分類し、10秒間隔で平均79%の精度で行動認識が行えることを確認している。しかしながら、仕事・勉強や洗面所関連行動など一部の行動において認識精度が低い結果となっている。

本研究では、夕方頃にキッチンで料理を行い、ゴールデンタイムにはソファでテレビを視聴し、就寝前に浴室で入浴し、深夜にベッドで睡眠をとる、などのように、行動ごとに行われる時間や場所に差がある点に着目し、行動が発生する時間帯や行動が行われたエリア、そのエリアにおける住人の滞在時間、位置情報の前後関係といった時間や場所に関連する特徴量を加えることで行動認識精度がどの程度向上できるかを確認した。

<sup>1</sup> 奈良先端科学技術大学院大学 情報科学研究科  
Graduate School of Information Science, Nara Institute of Science and Technology

<sup>2</sup> カセサート大学  
Kasetsart University

<sup>a)</sup> teruhiro-m@is.naist.jp

評価実験では、奈良先端科学技術大学院大学内に設置されたスマートホーム設備（1 LDK）において、4人の被験者を対象に合計11日間収集されたセンサデータを先行研究と同様に使用し比較を行った。提案手法により時間関連の特徴量の追加および重要度の低いセンサデータの除去することで、行動認識精度を平均82%まで向上できることを確認した。

## 2. 関連研究

Ouchiら[3]は、スマートフォンに搭載されている加速度センサとマイクを用いて行動認識手法を提案している。この手法では、まず加速度センサのみで「歩行」「作業」「安静」の3状態のどの状態に当てはまるかを推定し、「作業」の場合にマイクからの音の分析により、7種類（皿洗い、掃除機がけ、アイロンがけ、トイレ水洗/手洗い、歯磨き、電気シェーバーによる髭剃り、ドライヤーの使用）の行動を推定している。この研究では「歩行」「作業」「安静」の3状態をおおむね95%以上、7種類の作業を平均85.9%の精度で推定できることが確認されている。しかし、マイクを使うことから、プライバシー侵害への配慮に欠けており、かつ、推定可能な行動も限られている。

勝手ら[4]は、カメラにより撮影した動画像を用いた行動認識手法を提案している。この手法では、5種類の行動（掃除機をかける、パソコンを使用する、お茶を飲む、読書、食器洗い）を対象に、人物の動きだけではなく、行動に用いられる物体に着目し、その物体の特徴量を加えることで、人物の動きのみを特徴量として用いた場合と比較して行動認識精度を向上している。しかし、カメラによる動画像を使用しているため、マイクを用いた手法と同様に、使用者のプライバシー侵害への配慮に欠けており、かつ、対象としている行動も5種類と少ない。また、マイクとビデオの両方を用いた行動認識手法[5]も提案されており、70~90%の高精度で行動を認識可能なことが確認されている。しかしながら、高精度で行動を認識できても、マイクやビデオを使うことから、プライバシー侵害への考慮はなされていない。

ビデオやマイクを使わずプライバシーを守る手法として、Maekawaら[6]は、使用時に各家電が発する磁界に着目し、ウェアラブル磁気センサを用いて、テレビ鑑賞、シェービング、携帯電話の操作、歯磨き、掃除等の行動を認識する手法を提案している。しかし、この手法では、電化製品の操作のようないくつかの限られた行動認識しか行えない。また、近年爆発的に普及したスマートフォンに搭載されているセンサのみを使用して行動を推定する研究が多く行われている[7][8][9]。スマートフォンには前述の加速度センサ、マイクの他にも照度、温度、湿度がわかるセンサ、カメラなど多数のセンサが搭載されており、かつ、ユーザが新たなデバイスを装着する必要がないという利点がある。

これらの研究では、特に加速度センサのみを利用した手法が多く、歩く、走る、停止など身体の状態を表す行動を認識するもの[8]や、運転している、自転車に乗っているなどの大きな括りの行動を認識するもの[9]を主に対象としているため、我々が対象とするような行動を認識を行うものではなく、スマートフォンのバッテリー問題もある。

住宅内の行動認識を対象とした研究では、住宅内になんらかのセンサを設置し、収集された情報を利用することが一般的である。Kasterenら[10]は、ドアセンサ、引出センサ、温度センサ等様々なセンサが埋め込まれたスマートホームにおいて、食事、外出、トイレ、シャワー、着替え等の多種多様な日常生活行動を認識するシステムを構築しており、認識精度は49~98%となっている。この手法では、認識できる行動の種類は多いが、行動の種類によっては認識精度が低いという問題がある。

Chenら[11]は、家庭内のあらゆる物に接触センサを付けることで94.44%という高い行動認識率を達成している。Fleuryら[12]は、多くのセンサが設置されたスマートホーム環境でADLを認識するためのシステムを設計した。しかし、これらの手法は導入及び維持コストが高くなるという課題がある。

行動認識に関する研究には教師あり学習を用いて、行動認識モデルをラベルのついたデータから構築するものが多いが、オントロジーに基づく方法のような教師なし学習を用いる研究[13][14]も提案されている。例えば、Riboniら[13]は、複雑な生活行動を認識するために行動の意味、コンテキストデータ、センシングデバイスを活用する教師なし学習を提案した。しかし、この方法は面倒なラベル付けの作業を必要としないため有望であるが、包括的なオントロジーを定義するために関連する工学知識が必要となる点や現時点ではコストや精度等の問題が考慮されていない。

家庭内における行動認識の研究では、家庭内に設置された何らかのセンサを使用しているものが多いが、その様な手法では特定の家庭環境で取得した教師データを別の家庭に適用することは困難である。Inoueら[15]は特定の家庭環境で取得した教師データと、適用先の家庭で取得したデータを組み合わせることで、適用先での行動認識の精度を向上させる手法を提案している。この手法では、適用先の家庭でラベル付きのデータが得られない場合は、あらかじめ学習した教師データのみを使用する。適用先の家庭でラベル付きのデータが得られる場合は、あらかじめ学習したデータを基に、適用先で取得したデータを用いて教師データを更新していくことで精度を改善していく。しかし、この手法では、行動の種類によっては認識精度が低いという問題があり、認識の間隔は1分間であるためリアルタイム性が低い。

本研究の先行研究[1][2]では、上記の課題を解決することを目標に、住人の位置情報と消費電力を使用した行動認

識手法を提案している。上田ら [1] は、居住者の位置情報と家電の消費電力情報を基に 10 種類の行動（料理，食事，読書，テレビ視聴，食器洗い，入浴，掃除，仕事・勉強（PC 使用），睡眠，外出）を認識する手法を提案している。この手法では、住宅内に設置された屋内位置センサおよび家電に取り付けた消費電力センサから収集したセンサデータのみを利用し、機械学習により行動認識モデルを構築することで、マイクやカメラ等を用いる手法と比較するとプライバシー侵害が少ない。また、この研究では、機械学習アルゴリズムによる認識精度への影響やセンサ数を減らした際の認識精度への影響を調査しており、機械学習アルゴリズムとしては、Random Forest が最もよい精度になり、消費電力センサ 16 台、誤差 0.1 m 以下の位置情報を用いて平均 95%、消費電力センサの数を半分以下の 6 台、位置センサの誤差を 1.4m まで許容した場合でも、平均 87% の精度で各行動を認識できることを確認している。しかし、この手法では、認識の時間窓が 5 分となっており、リアルタイムに行動認識ができていたとは言えず、また、消費電力センサのサンプリング周期が 30 秒であることから、それより短い時間窓では認識精度が低下することがわかっている。

そこで中川ら [2] は、認識精度の低下を抑えつつ、リアルタイム性を向上した行動認識手法を実現するために、サンプリング周期の短いセンサデバイス、および、データ収集プログラムを開発し、上田らの行動認識手法を基に新たな行動認識モデルを作成している。この研究では、奈良先端科学技術大学院大学のスマートホームにおいて、センサデータを新たに収集するとともに、対象とする生活行動の種類や機械学習で用いる特徴量の選定を行うことで、10 秒間隔で 10 種類の生活行動（料理関連行動，食事，掃除，睡眠，外出，仕事・勉強，入浴関連行動，テレビ視聴，洗面所で行う行動，その他）を平均 79 % の精度で認識できることを確認している。この手法では、料理関連行動や入浴関連行動の生活行動に対しては、平均 90 % 以上の高い精度で行動認識が可能であるが、食事や洗面所で行う行動といった一部の生活行動が平均 70% 未満の認識精度になっているため、全体の認識精度を下げていることを確認している。

本稿では、中川らの手法に対して、行動が発生した時間帯や宅内の各エリアにおける住人の滞在時間、位置情報の前後関係といった時間に関連する特徴量を新たに加えることで行動認識精度を向上できるか確認する。

### 3. 提案手法

本研究では、先行研究である中川らの行動認識手法を基に、時間関連の特徴量を加えた行動認識モデルを作成する。本節では、先行研究と本研究で対象とする生活行動の種類や使用するセンサについて述べたのちに、本研究で用いる特徴量について述べる。

#### 3.1 行動種類の選定

本研究では、平成 23 年に総務省統計局が分類した 1 日の主な行動 20 種類 [16] を参考に、高齢者見守りや省エネ家電制御などのサービスで必要となる日常生活行動を 10 種類の行動種類（料理関連行動，食事，掃除，睡眠，外出，仕事・勉強（PC 使用），入浴関連行動，テレビ視聴，洗面所関連行動，その他）に分類する。料理関連行動に関しては料理と食器洗いを、入力関連行動に関しては入浴と風呂掃除を、テレビ視聴に関してはテレビ視聴とテレビゲームを、洗面所関連行動に関しては洗面と洗濯をそれぞれ含めている。また、読書やスマホ操作といった行動は、省エネや見守りの観点ではあまり重要ではないと考えその他に含めた。

#### 3.2 使用するセンサ

1) 位置センサ: 住人の位置情報を収集するために、実験環境に備わっている超音波位置測位システムを利用する。本システムは、小型の送信機から送信される同期用高周波 (RF) と超音波を、スマートホームの各部屋の天井に設置された受信機により受信し、その到達遅延時間を計算することで送信機の位置を測定する。本システムのサンプリング周期は 1 秒間に 2 回であり、位置推定精度は公称値で 50 cm であるが、センサを静止させた状態での実測値は誤差 10 cm 程度であることを確認している。

2) 電力計: スマートホーム内に設置されている家電の消費電力を取得するために、ラトックシステム社のワットチェッカーを使用する。本製品は市販のままでは 1 秒ごとのデータを保存する機能は実装されていないため、開発元のラトックシステム社の協力により、Bluetooth を介して csv 形式でデータを保存するプログラムを開発した。本研究においては、寝室エアコン、寝室机上のコンセント、寝室延長コード、冷蔵庫、電子レンジ、ポット、炊飯器、テレビ、リビング延長コードの 9 箇所にワットチェッカーを設置し家電の消費電力を収集した。

3) CT センサ: 分電盤の電力系統ごとに電力を計測するために CT センサを設置した。市販の CT センサは、サンプリング周期が長くリアルタイムな計測が行えないため、本研究室において 1 秒に 1 回計測可能な CT センサを開発した。本研究においては、IH ヒーター、電気温水器、リビングエアコンコンセント、浴室乾燥機、リビング・キッチン・寝室照明、廊下・冷蔵庫コンセント、寝室エアコンコンセント、寝室コンセント、玄関・廊下・浴室・トイレ・洗面所照明、洗面所・洗濯機コンセント、キッチンコンセント、リビングコンセントの 12 系統の電力を計測している。

### 3.3 行動認識手法

本研究では、10秒ごとに区切られた居住者の位置情報と各家電の消費電力情報を機械学習の特徴量として用いて行動認識モデルを作成する。先行研究では特徴量として、ユーザの位置情報(x座標, y座標, z座標), ワットチェッカの計測値(9種類), CTセンサの計測値(12種類)を使用している。センサデータを区切る際に、位置情報は中央値, 消費電力情報はその期間の平均値を算出し特徴量として使用する。機械学習に用いるアルゴリズムとして、上田らの先行研究で最もよい精度が得られた Random Forest を用いる。

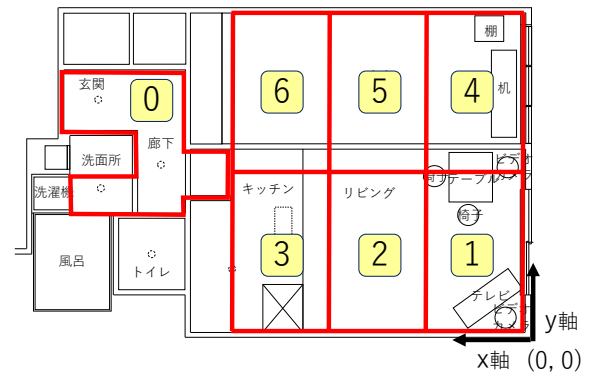


図1 対象住宅の間取りと各エリア

### 3.4 特徴量の追加

19時頃に夕食をとり, 23時頃に就寝するなど, 日常行動が行われる時間帯には差があり, また, 日本の平均睡眠時間は7時間42分, 食事時間は1時間39分など行動の種類ごとにその行動が行われる時間にも差があることがわかってる [16]. また, 洗面所で脱衣を行ってから浴室で入浴を行うなど, 行動を行う場所には前後関係があると考えられる。そこで本研究では, 先行研究に以下の時間に関連する特徴量を加えることで, 日常生活行動の認識精度が向上できるかを確認する。

- 1) 時間帯: 時間(1時間, 3時間, 6時間), 分(1分, 10分, 30分), 秒(10秒)の粒度で時間帯を特徴量として追加する。例えば, 7時35分30秒に朝食をとった場合, 6時間:1, 3時間:2, 1時間:7, 30分:15, 10分:45, 1分:455, 秒:27334といった特徴量になる。
- 2) エリアと滞在時間: 1時間のテレビドラマをソファに座って視聴するといったように, 日常生活行動は一定エリア内である程度の時間継続して行われる可能性が高い。そのため, 行動が行われたエリアと行動が継続された時間は特徴量として有用だと考えられる。しかし, 行動の継続時間の算出には行動の開始時刻と終了時刻が必要であり, これらはセンサデータからはわからない。そこで本研究では, 住宅を複数個のエリアに分割し, 行動時のエリアとそのエリアに移動してからの合計滞在時間を特徴量として追加する。図1は本研究で対象とするスマートホーム設備の間取りと特徴量として用いる7つのエリアを表している。リビングと寝室を2x3mで分割したエリア1から6, および, 玄関, 廊下, 洗面所をまとめたエリア0を加えた7つのエリアを特徴量として使用する。
- 3) 直前のx座標およびy座標: 直前のx座標およびy座標を特徴量として追加する。3.3節で述べたように, 本研究では10秒ごとに区切られた位置情報を用いるため, 10秒前の座標を使用する。

表1 評価実験で追加する特徴量  
追加する特徴量

追加する特徴量	追加する特徴量
Case1	直前の x 座標, y 座標
Case2	時間帯
Case3	エリア
Case4	滞在時間
Case5	上記すべて
Case6	特徴量の選択 (重要度の低い特徴量を除去)

## 4. 評価実験

本評価実験では, 時間関連の特徴量が日常生活行動の認識精度に与える影響を確認する。

### 4.1 評価手法

機械学習および評価で使用するデータは, 奈良先端科学技術大学院大学のスマートホーム設備(1LDK)において, 延べ4名の被験者に生活してもらい収集した合計11日間のセンサデータを先行研究と同様に使用する。また, 1日の全データをテストデータとして除外し, 残りのデータを訓練データとする交差検証により評価を行う。本評価では, 表1に示すように, 各特徴量を追加した際の認識精度を先行研究の認識精度と比較する。Case6では, 先行研究において, Random Forestにおける特徴量の重要度が低かった電子湯沸かし器とリビングエアコンのコンセントの特徴量を除き, 時間関連の特徴量を加えた。

### 4.2 評価指標

評価指標として精度, 適合率, 再現率, F値を用いる。精度は全テストデータのうち, 正しく識別することができたテストデータの割合であり, (1)式で表される。

$$\text{精度} = \frac{\text{正しく識別できたテストデータの数}}{\text{テストデータの合計}} \times 100(\%) \quad (1)$$

適合率は, ある生活行動と認識されたデータのうち, 実際にその生活行動であったデータの割合である。再現率は, ある生活行動のテストデータのうち, 正しくその生活行動

表 2 本研究と先行研究 (中川ら [2]) との比較: 適合率

生活行動	サンプル数	中川ら [2]	直前の座標	時間帯	エリア	滞在時間	すべて	特徴量選択
掃除	186	0.79	0.79	0.84	0.8	0.8	0.74	0.83
外出	520	0.94	0.92	0.94	0.92	0.95	0.92	0.91
食事	1363	0.69	0.71	0.71	0.71	0.7	0.71	0.7
仕事・勉強	4366	0.78	0.82	0.78	0.8	0.77	0.86	0.84
浴室関連行動	1982	0.92	0.92	0.88	0.9	0.91	0.94	0.94
料理関連行動	3744	0.91	0.92	0.92	0.91	0.92	0.92	0.92
TV 視聴	5910	0.82	0.84	0.83	0.83	0.83	0.85	0.85
洗面所関連行動	729	0.44	0.39	0.45	0.42	0.46	0.46	0.47
睡眠	257	0.7	0.72	0.71	0.71	0.71	0.71	0.7
その他	5575	0.71	0.7	0.7	0.7	0.68	0.73	0.76
平均		0.79	0.8	0.79	0.8	0.79	0.82	0.83

表 3 本研究と先行研究 (中川ら [2]) との比較: 再現率 (精度)

生活行動	サンプル数	中川ら [2]	直前の座標	時間帯	エリア	滞在時間	すべて	特徴量選択
掃除	186	0.9	0.91	0.92	0.89	0.9	0.91	0.89
外出	520	0.95	0.95	0.95	0.95	0.95	0.95	0.95
食事	1363	0.79	0.81	0.78	0.81	0.77	0.8	0.81
仕事・勉強	4366	0.76	0.77	0.74	0.74	0.74	0.77	0.83
浴室関連行動	1982	0.97	0.95	0.94	0.94	0.97	0.94	0.97
料理関連行動	3744	0.97	0.98	0.96	0.98	0.98	0.98	0.98
TV 視聴	5910	0.86	0.88	0.86	0.88	0.85	0.92	0.9
洗面所関連行動	729	0.61	0.58	0.66	0.62	0.61	0.68	0.69
睡眠	257	0.93	0.93	0.91	0.91	0.93	0.91	0.91
その他	5575	0.56	0.58	0.59	0.57	0.58	0.61	0.6
平均		0.79	0.8	0.79	0.8	0.79	0.82	0.82

と認識することができたデータの割合である。F 値は、適合率と再現率の調和平均であり、(2) 式で表される。

$$F \text{ 値} = \frac{2 \times \text{適合率} \times \text{再現率}}{\text{適合率} + \text{再現率}} \quad (2)$$

また、本研究では、各値に対してそれぞれの行動ごとに重み付けをとったものを全体の平均としている。重み付け平均とは、通常の平均とは異なり、各行動のサンプル数を考慮したものであり、(3) 式で表される。

$$\bar{x} = \frac{x_1 w_1 + x_2 w_2 + \dots + x_n w_n}{w_1 + w_2 + \dots + w_n} \quad (3)$$

$\bar{x}$  は重み付け平均、 $x_1$  はある変数 (適合率など)、 $w_1$  はある変数に対する重み (サンプル数) である。また、再現率の重み付け平均は全データに対して正しく認識することができたデータの割合となるため、精度と一致する。

### 4.3 実験結果

先行研究および表 1 で示した各ケースの適合率、再現率 (精度)、F 値を表 2、表 3、表 4 にそれぞれ示す。各表において、先行研究より認識精度が向上した生活行動を網掛けで表している。

直前の座標を特徴量として追加した場合には、浴室行動関連と洗面所関連の行動を除いた行動について中川らの手法以上の精度で認識が行えていることがわかる。浴室行動関連と洗面所関連行動の精度が下がっている理由として、

入浴時には位置座標が洗面所に固定されるためだと考えられる。

時間帯を特徴量として追加した場合には、洗面所関連行動の認識精度を大きく向上することができるが、それ以外の行動に関しては精度の向上に効果がないことがわかる。また、各表に記載した結果は、10 秒ごとに区切った時間帯を特徴量として用いた場合のものである。3.4 節で述べたように、時間帯として時間 (1 時間、3 時間、6 時間)、分 (1 分、10 分、30 分)、秒 (10 秒) の粒度で特徴量を追加し認識精度を確認したところ、全ての特徴量を追加した場合には 72% まで精度が低下した。この場合の特徴量の重要度を確認したところ、時間の粒度が粗くなるほど重要度が低くなった。また、各粒度ごとの認識精度を確認したところ、秒 (10 秒) の認識精度が最も高くなった。そのため、全ての特徴量を追加した場合と、特徴量の選択を行った場合においても、秒 (10 秒) を特徴量として使用している。

エリアを特徴量として追加した場合には、精度が大きく向上しているものはないが、半数の行動に対して精度の向上が行えていることがわかる。

滞在時間を特徴量として追加した場合には、ほとんどの行動に対して適合率を向上することはできるが、平均適合率は中川らの手法と同等になっている。また、精度に関しては料理関連とその他の行動にしか効果がないことがわか

表 4 本研究と先行研究 (中川ら [2]) との比較 : F 値

生活行動	サンプル数	中川ら [2]	直前の座標	時間帯	エリア	滞在時間	すべて	特徴量選択
掃除	186	0.84	0.85	0.88	0.84	0.85	0.82	0.86
外出	520	0.95	0.94	0.94	0.93	0.95	0.93	0.93
食事	1363	0.73	0.75	0.74	0.76	0.73	0.75	0.75
仕事・勉強	4366	0.77	0.79	0.76	0.77	0.75	0.81	0.84
浴室関連行動	1982	0.94	0.93	0.91	0.92	0.94	0.94	0.96
料理関連行動	3744	0.94	0.95	0.94	0.94	0.95	0.95	0.95
TV 視聴	5910	0.84	0.86	0.84	0.85	0.84	0.88	0.87
洗面所関連行動	729	0.51	0.47	0.53	0.5	0.53	0.55	0.56
睡眠	257	0.8	0.81	0.8	0.8	0.8	0.8	0.79
その他	5575	0.63	0.64	0.64	0.63	0.62	0.66	0.67
平均		0.79	0.80	0.79	0.80	0.79	0.82	0.83

表 5 各特徴量の重要度

Rank	特徴量	重要度
1	x 座標	0.129122
2	直前の x 座標	0.110280
3	玄関・廊下・浴室・トイレ・洗面所照明	0.089561
4	エリア	0.072287
5	IH ヒーター	0.070358
6	y 座標	0.065149
7	直前の y 座標	0.063147
8	寝室	0.061010
9	時間帯 (秒)	0.058439
10	リビング・キッチン・寝室照明	0.055584
11	TV	0.053275
12	リビングコンセント	0.048317
13	z 座標	0.046060
14	滞在時間	0.042547
15	洗面所	0.034865

る。これは行動が継続された時間ではなく、エリアに移動してから合計滞在時間を用いているためだと考えられる。

全ての特徴量を追加した場合や特徴量を選択した場合においては、適合率、再現率 (精度), F 値ともに中川らの結果よりよい結果になっていることがわかる。また, 平均精度を見ると 3% 上昇の 82% の精度で認識が行えており, 特徴量をそれぞれ追加した場合よりも大きな効果が得られることがわかる。

表 5 は, 特徴量を選択した場合の各特徴量の重要度を表している。本研究で追加した, 直前の x 座標および y 座標, エリア, 時間帯 (秒) などの特徴量については, 重要度が高いことがわかる。多くの精度を向上できた直前の座標に関しては, 重要度に関しても高くなっており, 認識精度の向上に特に効果的であることがわかる。精度の向上には効果がなかった滞在時間に関しては, 他の特徴量より重要度が低くなっており, 組み合わせた場合においても効果が少ないことがわかる。

## 5. おわりに

本研究では, 消費電力と位置情報を用いて居住者の生活行動を認識する先行研究の手法に, 時間に関連する特徴量を追加することで認識精度を向上できるか確認した。奈良先端科学技術において延べ 4 人の被験者が合計 11 日生活したデータを用いて機械学習により生活行動モデルを作成した結果, 行動が発生した時間帯, 行動が発生したエリア, エリアにおける滞在時間, 直前の位置座標などの特徴量を追加することで, 認識精度を 79% から 82% まで向上できることを確認した。本研究で新たに追加した時間関連の特徴量は, 先行研究で使用したデータから算出できるため, リアルタイム性を損なわずに認識精度を向上することできる。しかしながら, 洗面所関連行動やその他の行動の認識精度はいまだに 60% 台にとどまっている。今後は, 特徴量の選定やデータ量の調整を通じてさらなる精度向上を目指す予定である。

## 参考文献

- [1] 上田健揮, 玉井森彦, 荒川豊ほか: ユーザ位置情報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. 57, No. 2, pp. 416–425 (2016).
- [2] Eri, N., Kazuki, M., Hirohiko, S. et al.: Toward Real-Time In-Home Activity Recognition Using Indoor Positioning Sensor and Power Meters, *Proc. the 1st Int. Workshop on Pervasive Smart Living Spaces*, IEEE, pp. 539–544 (2017).
- [3] Ouchi, K. and Doi, M.: Smartphone-based monitoring system for activities of daily living for elderly people and their relatives etc., *Proc. the 2013 ACM Conf. Pervasive and Ubiquitous Computing Adjunct Publication*, ACM, pp. 103–106 (2013).
- [4] 勝手美紗, 内海ゆづ子, 黄瀬浩一: 物体と動き特徴を用いた行動認識, 電子情報通信学会技術研究報告. PRMU, パターン認識・メディア理解, Vol. 111, No. 430, pp. 125–126 (2012).
- [5] Brdiczka, O., Langet, M., Maisonnasse, J. et al.: Detecting human behavior models from multimodal observation in a smart home, *IEEE Trans. Automation Science and Engineering*, Vol. 6, No. 4, pp. 588–597 (2009).

- [6] Maekawa, T., Kishino, Y., Sakurai, Y. et al.: Recognizing the use of portable electrical devices with hand-worn magnetic sensors, *International Conf. Pervasive Computing*, Springer, pp. 276–293 (2011).
- [7] Su, X., Tong, H. and Ji, P.: Activity recognition with smartphone sensors, *Tsinghua Science and Technology*, Vol. 19, No. 3, pp. 235–249 (2014).
- [8] Lee, Y.-S. and Cho, S.-B.: Activity recognition using hierarchical hidden markov models on a smartphone with 3D accelerometer, *Proc. Int. Conf. Hybrid Artificial Intelligence Systems*, Springer, pp. 460–467 (2011).
- [9] Siirtola, P. and Rönning, J.: Recognizing human activities user-independently on smartphones based on accelerometer data, *IJIMAI*, Vol. 1, No. 5, pp. 38–45 (2012).
- [10] Van Kasteren, T., Englebienne, G. and Kröse, B. J.: An activity monitoring system for elderly care using generative and discriminative models, *Personal and Ubiquitous Computing*, Vol. 14, No. 6, pp. 489–498 (2010).
- [11] Chen, L., Nugent, C. D. and Wang, H.: A knowledge-driven approach to activity recognition in smart homes, *IEEE Trans. Knowl. Data Eng.*, Vol. 24, No. 6, pp. 961–974 (2012).
- [12] Fleury, A., Vacher, M. and Noury, N.: SVM-based multi-modal classification of activities of daily living in health smart homes: sensors, algorithms, and first experimental results, *IEEE Trans. Inf. Technol. Biomed.*, Vol. 14, No. 2, pp. 274–283 (2010).
- [13] Riboni, D., Sztyley, T., Civitarese, G. et al.: Unsupervised recognition of interleaved activities of daily living through ontological and probabilistic reasoning, *Proc. the 2016 ACM Int. Joint Conf. Pervasive and Ubiquitous Computing*, ACM, pp. 1–12 (2016).
- [14] Ye, J., Stevenson, G. and Dobson, S.: USMART: An unsupervised semantic mining activity recognition technique, *ACM Trans. Interactive Intelligent Systems (TiiS)*, Vol. 4, No. 4, p. 16 (2015).
- [15] Inoue, S. and Pan, X.: Supervised and Unsupervised Transfer Learning for Activity Recognition from Simple In-home Sensors, *Proc. the 13th Int. Conf. Mobile and Ubiquitous Systems: Computing, Networking and Services*, ACM, pp. 20–27 (2016).
- [16] 総務省統計局：統計局ホームページ/平成 23 年社会生活基本調査.