

# 異なる家具配置に対応可能なリアルタイム行動認識システム 開発のためのデータ収集と分析

中川 愛梨<sup>1,a)</sup> 守谷 一希<sup>1</sup> 諏訪 博彦<sup>1</sup> 藤本 まなと<sup>1</sup> 荒川 豊<sup>1</sup> 安本 慶一<sup>1</sup>

概要：近年，高齢者見守りの必要性や，省エネに対する意識の高まりに伴い，宅内における生活行動を認識したいという要求が高まっており，宅内生活行動を自動認識する研究が盛んに行なわれている．生活行動を自動認識する技術を高齢者見守りや省エネ家電制御等のサービスに利用するためには，多様な行動を高精度かつリアルタイムに認識することが必要となる．これまで著者らは，住人のプライバシーに配慮し，カメラやマイクを用いずに位置情報と消費電力情報のみを用いて 10 秒以内に行動を認識する研究を進めてきた．研究を進めるにあたり，リアルタイムにデータを収集する環境は構築できたが，短期間のセンサデータから正確に行動を認識することや，学習結果を家具の配置などが異なる異なる家庭に適用することが難しいことが分かってきた．本稿では，それらの課題を解決するため，特徴量の追加，加工や選定を行うことで，家具配置に依存せず，高精度かつリアルタイムに行動を認識することを目指した手法を提案する．提案手法では，精度の向上のために，新たな特徴量の導入，各特徴量の重要度を基にした特徴量の選定を行い，それぞれにおいて 15 種類の行動に対する機械学習モデルを構築する．また，異なる家具配置に対応するために，位置情報を領域情報に変換し，各消費電力情報を正規化して機械学習モデルを構築する．スマートホームで，計 23 日間のデータを収集し，提案手法を適用した結果，平均 66.103 % の認識精度を達成した．また，特徴量の追加，特徴量の選定を行った場合に，平均 68.061 %，平均 66.850 % と認識精度に若干の改善が見られた．さらに，提案手法を用いて，ある家具配置の学習データで構築した行動認識モデルを別の家具配置に適用した結果，平均 24.340 % の認識精度となったが，学習データを増やすことで，平均 54.473 % に認識精度を改善できることを確認した．

## 1. はじめに

近年，さまざまなセンシングデバイスを用いて，人間の行動を認識する研究が盛んに行なわれている．人間の行動を認識する技術は様々なサービスへの応用が期待できる．特に，宅内生活行動認識技術は省エネ家電制御 [1][2] や，高齢者見守り支援 [3] 等のサービスへの利用が期待される．それらのサービスに行動認識技術を適用する際には，そのリアルタイム性が重要になる．また，家庭によって家具の配置等は異なるため，多数の家庭に行動認識を用いたサービスが普及するためには，生活環境に依存しない行動認識技術が必要となる．本研究では，家電・家具配置の異なる場合でも宅内行動を高精度かつリアルタイムで認識することを目的とする．

宅内での生活行動を認識する研究は多くある．それらの既存研究には (1) カメラ等の機器によるプライバシーの侵

害，(2) 認識できる行動の種類が少ない，(3) 認識の精度がよくない，(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 5 つの問題点を全て解決しているものはない．上田らは，位置情報と消費電力情報を用いることにより，問題点 (1)~(4) を達成している [4]．しかし，認識までに 5 分間のデータを必要とするため，問題点 (5) については達成できていない．著者らは，問題点 (1)~(4) を達成したまま問題点 (5) を達成するために，新たなセンサの導入によりデータ収集環境を構築した [5]．本稿では，構築したデータ収集環境で収集したデータによる分析結果について報告し，認識精度の向上と，異なる家電・家具配置の家庭に対応するための新たな手法を提案する．

文献 [5] で構築した環境で，サンプルの時間幅 10 秒で行動認識を行った結果，平均精度は 66.103 % と，文献 [4] と比べ大幅に悪化した．本稿では，認識精度を向上するため，新たな特徴量の導入，各特徴量の重要度を算出することによる特徴量の選定という 2 つの手法を導入する．また，異なる家電・家具配置への対応のため，位置情報を領域情報に変換し，消費電力情報を正規化する方法を導入する．

<sup>1</sup> 奈良先端科学技術大学院大学  
Nara Institute of Science and Technology  
8916-5 Takayama, Ikoma, Nara 630-0192, Japan

<sup>a)</sup> nakagawa.eri.nz6@is.naist.jp

提案システムの有用性を評価するため、奈良先端科学技術大学院大学内に設置したスマートホーム設備（1LDK）で、前回の実験で収集した9日間のデータに加えて、新たに5名の被験者に2～3日間生活してもらい、計14日間のデータを収集した。家具配置は前回とは異なるものに変更した。実験の際に日常生活で考えられる15種類の行動（入浴、掃除、風呂掃除、料理、ゲーム、外出、洗濯、食事、PC使用、読書、睡眠、スマートフォン使用、食器洗い、洗面、テレビ視聴）に対してセンサデータを記録した。実験により取得した各センサデータを10秒おきに丸めたデータを使用して、Wekaを用いた機械学習（Random Forest）により、行動がどの程度の精度で認識できるのかの分析を行った。前回の実験で得た9日間のデータをそのまま用いた際の平均認識精度は66.103%となった。そこに位置の分散を新たに特徴量として加えた際の平均認識精度は68.061%、特徴量の選定を行った際の平均認識精度は66.850%となり、若干ながら認識精度が改善した。さらに、位置情報を領域情報に変換し、消費電力情報の正規化を行い、前回の9日間のデータを教師データとし、今回の実験で得られた14日間のデータをテストデータとして分析を行ったが、平均認識精度は24.340%に留まった。しかし、前回の9日間と今回の実験14日間を合わせて用いて教師データとした場合の平均認識精度は54.473%となり、学習データを増やすことで認識精度が向上することが分かった。

## 2. 位置・電力情報を基とした宅内行動認識システム：現状と課題

本章では、位置・電力情報を基とした宅内行動認識システムの現状と課題について説明する。

位置・電力情報を基とした宅内行動認識システムとして、上田らの研究[4]がある。この研究では、1章で述べた問題点(1)～(4)を解決するために、今後の低価格化・普及が見込まれ、カメラ等のプライバシー露出への抵抗が強いセンサではなく、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を用いることで行動認識を行っている。使用する屋内位置センサと消費電力センサのサンプリング周期は、それぞれ毎秒2回、1分間に2回である。また、問題点(2)～(3)を解決するために、多数のセンサデータの記録と各行動に対する教師データの抽出、適切な行動学習モデルの構築を行っている。認識の対象となる行動は10種類（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）である。しかし、この研究では、問題点(1)～(4)については達成できているが、問題点(5)については認識のために5分間のデータを必要とするため達成できていない。

著者らは、問題点(1)～(4)を満たしたまま問題点(5)を達成するために、新たに1秒毎にデータ計測が可能な消

費電力センサを導入することで、10秒といった短い時間窓でも行動の認識が可能となるデータ収集環境を構築した。しかし、取得したデータに対して、1日分のデータをテストデータとし、残りを教師データとする方法で機械学習（Random Forest）により行動認識モデル作成し分析を行ったところ、平均認識精度が66.103%となり、高精度に行動の認識ができないという課題があることがわかった。また、文献[4][5]の手法では居住者の位置情報を用いているため、ある家庭で学習された行動認識モデルを、家具配置の異なる家庭にそのまま導入することができないという課題がある。

本稿では、(I)リアルタイムでは行動認識精度が低い、(II)学習結果を異なる家具配置の家庭に適用できないという2つの課題を解決するための手法を提案する。

## 3. 提案手法

本研究では、課題(I)を解決するために、位置分散という新たな特徴量の導入、各特徴量の重要度を算出することによる特徴量の選定という2つの手法を提案する。また、課題(II)を解決するために、位置情報を領域情報に変換し、消費電力情報を正規化する。以下で本研究で使用するセンサと、それぞれの提案手法の詳細について説明する。

### 3.1 使用センサについて

本研究で使用するセンサは以下の仕様のものである。

#### 3.1.1 屋内位置センサ

天井に受信機を複数台設置し、送信機から発せられる超音波を用いて送信機の位置を推定するセンサである。サンプリング周期は1秒間に2回である。送信機は小型なものであり、人が容易に持ち運べる大きさである。位置は $x, y, z$ 座標で表される。

#### 3.1.2 Bluetooth ワットチェッカー

家電、またはコンセント毎に消費電力を取得することができるセンサが取り付けられている。サンプリング周期は1秒間に1回である。センサを取り付けた場所は、寝室エアコン、寝室机上コンセント、寝室延長コンセント、冷蔵庫、電子レンジ、ポット、炊飯器、テレビ、リビング延長コンセントの9箇所である。

#### 3.1.3 CT(Current Transformer) センサ

分電盤の系統毎にCTセンサが取り付けられている。サンプリング周期は1秒間に1回である。電力を取得している系統は、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・洗面照明、洗面・洗濯機コンセント、キッチンコンセント、リビング・ダイニングコンセントの12系統である。

表 1 各特徴量のジニ係数

特徴量	センサ種類	ジニ係数
ポット	BTWATTCH	11.743
電子レンジ	BTWATTCH	28.773
キッチンコンセント	CT	48.245
寝室エアコンコンセント	BTWATTCH	56.611
リビングエアコン	CT	57.875
浴室乾燥機	CT	118.114
寝室机上コンセント	BTWATTCH	124.230
炊飯器	BTWATTCH	124.775
電気温水器	CT	176.873
冷蔵庫	BTWATTCH	186.826
廊下・冷蔵庫コンセント	CT	193.349
洗面・洗濯機コンセント	CT	216.549
リビング・ダイニングコンセント	CT	223.798
IH ヒーター	CT	229.071
テレビ	BTWATTCH	242.031
リビング延長コンセント	BTWATTCH	263.086
寝室コンセント	CT	264.731
照明 1*1	CT	316.753
寝室エアコン	CT	346.519
z 座標	位置情報	408.263
寝室延長コンセント	BTWATTCH	431.885
照明 2*2	CT	680.743
x 座標	位置情報	873.853
y 座標	位置情報	1248.780

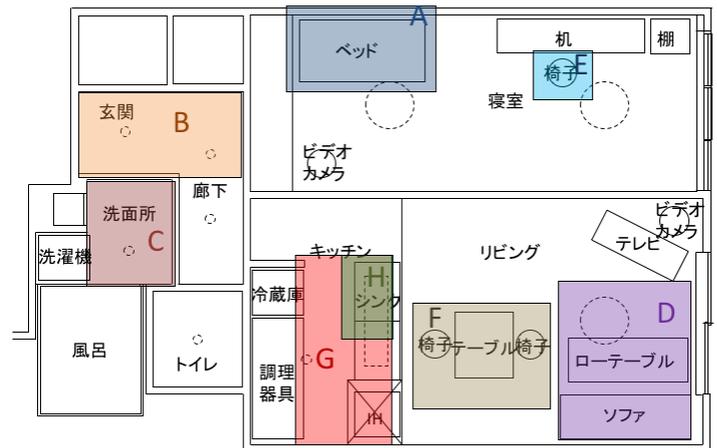


図 1 スマートホーム家具配置図 1

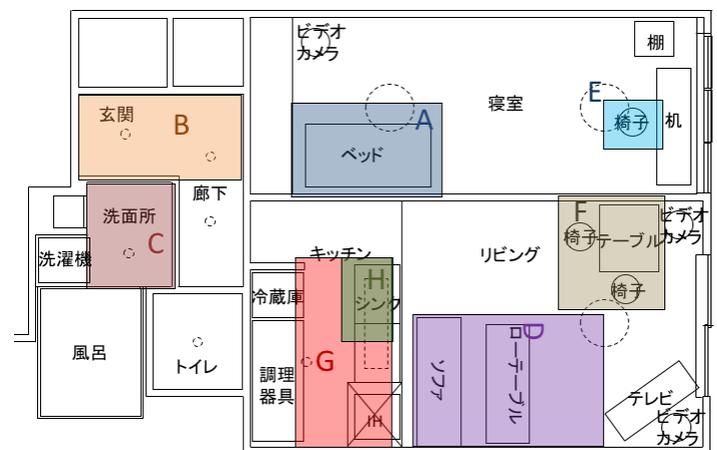


図 2 スマートホーム家具配置図 2

### 3.2 課題 (I) に対する提案手法

課題 (I) を解決するための手法について説明する。

#### 3.2.1 位置分散の導入

行動中に位置の移動が多い行動と位置の移動が少ない行動を切り分けられることで、精度が向上できると期待し、実験時に得られた位置情報のうち、過去 10 秒間の x および y 座標を使用して、1 秒毎の共分散の絶対値を求めた。さらに、求めた共分散の絶対値が予め設定したしきい値以上なら「1」、以下なら「0」とした。そのデータを 10 秒間毎に区切り、その間に 1 つでも「1」が存在すれば「1」として、1 つも存在しないなら「0」として加工したデータを特徴量とした。

#### 3.2.2 特徴量の選定

各特徴量の重要度を求め、下位の特徴量は排除することによって精度を向上する。重要度の指標として、本研究ではジニ係数を用いる。ジニ係数とは、主に社会における所得分配の不等さを測る指標であるが、機械学習では特徴量の重要度を測る指標として用いられているものである。ジニ係数の値が高いほど、その特徴量の重要度は高い。反対に、ジニ係数の値が低い特徴量はノイズとなっている可能性が高い。したがって、ジニ係数の小さい特徴量を排除することで、認識精度の向上が期待される。ジニ係数の算出は R を用いて行った。結果は表 1 の通りである。上位いくつかの特徴量を用いて分析を行う。

### 3.3 課題 (II) に対する提案手法

課題 (II) を解決するための手法について説明する。

#### 3.3.1 領域情報への変換

家具配置が異なることにより、行動が起きる範囲が異なってしまうことへの対処として、位置情報を家具の配置を基とした領域情報へ変換する。新たに評価実験を行う際に、家具の配置を以前の配置 (図 1) から図 2 に変更した。領域の範囲については、家具の座標を基に A ~ H の 8 つを定義した。8 つの範囲についてそれぞれに含まれていれば「1」、そうでなければ「0」として、加工した 8 つのデータを位置情報の代わりに特徴量として与える。

#### 3.3.2 消費電力の正規化

異なる家庭では使用されている家電が異なるため、消費電力情報をそのまま用いることができないという課題がある。よって、家電・系統ごとに消費電力情報が平均値が 0、分散が 1 になるように正規化を行う。正規化後の値  $z_i$  は以下の式 (1) で求めることができる。 $x_i$  は各センサ値、 $\mu$  は

\*2 リビング・ダイニング・キッチン・寝室照明

\*2 玄関・廊下・浴室・トイレ・洗面照明

各センサ値毎の平均,  $\sigma$  は各センサ値毎の標準偏差である.

$$z_i = \frac{x_i - \mu}{\sigma} \quad (1)$$

### 3.4 行動認識アルゴリズム

本研究では, 実験で収集したデータを用いて機械学習により宅内生活行動認識を行う. 以下に, データの学習方法について述べる.

本研究で使用する特徴量は以下の通りである.

- 説明変数: 居住者の位置情報 ( $x, y, z$ ) または 居住者の領域情報 (8 領域)
- 説明変数: 居住者の分散値情報 ( $x, y$  の共分散)
- 説明変数: 家電・系統毎の消費電力情報 または 消費電力情報を正規化した情報 (21 種類)
- 目的変数: 行動ラベル情報 (15 または 16 種類)

上記の特徴量において, 居住者の位置情報と領域情報, 家電系統毎の消費電力情報とそれを正規化した情報は対応するものため, 同時に用いることはない. また, 行動ラベル情報については, 定義した行動は 15 種類であるが, 全生活時間を想定した分析の際はラベルのついていない箇所も含めているため 16 種類となる. これらの情報を 10 秒の時間窓で区切り, その 10 秒間のデータを 1 つの特徴量として扱っている. 学習の際には, 実験で取得したデータを教師データとテストデータに分割し, 学習アルゴリズムは Random Forest を用いる.

## 4. 評価実験

提案手法の有用性を評価するため, 評価実験を新たにを行った.

### 4.1 実験概要

奈良先端大が所有するスマートホーム設備で, 被験者 5 名 (教員: 30 代男性 1 名, 大学院生: 20 代男性 2 名, 20 代女性 2 名) にそれぞれ 2 ~ 3 日間生活してもらい, 計 14 日間分のデータセットを新たに収集した.

被験者には前回の実験 [5] と同様に, 右肩に超音波位置測位センサの送信機を装着してもらい, 最低でも 1 日 3 時間は活動し, 10 時間以上 (睡眠時間含む) はスマートホームで生活してもらうように依頼した. 実験の期間中, 被験者にはあらかじめ定義した 15 種類の行動 (料理, 食事, 読書, テレビ視聴, 食器洗い, 入浴, 掃除, PC 使用, 外出, 睡眠, 洗面, 洗濯, ゲーム, スマートフォン使用, 風呂掃除) をできるだけ 1 日 1 回以上, 最低でも各自の実験期間中で 1 回は行うように依頼した. それ以外は自由な行動を許可しており, 日中は外出することとなった.

生活の様子は寝室とリビングに設置した 3 台のビデオカメラで記録し, それに加えてボタンを押すことで時刻がサーバに保存されるシステムを新たに構築し, そのボタン

を用いて行動の開始と終了を記録するよう依頼した. プライバシーに配慮し, ビデオカメラのデータについては被験者に管理してもらった. 実験後, 収集して得られたデータを一つにまとめ, そのデータを被験者に渡し, ビデオカメラの動画データと保存された行動の開始と終了の時刻を基に行動のラベル付けを依頼した. 行動のラベル付けについては, あらかじめ対象とする各行動についてそれぞれ何を開始, 終了とするかを定義し, その定義に従うように依頼した.

### 4.2 データの処理

実験により取得した粒度の違う各センサデータをそれぞれ 10 秒毎に丸めて使用する. 時刻の区切り方については実験開始の時刻から 10 秒おきに区切り, 行動の切れ目などは考慮しない. 位置情報は, 毎秒 2 回取得できるため, 10 秒間の中央値を使用する. 実験設備の問題で, 被験者が外出中の際に位置情報が欠損することがあるため, その部分については固定値を与えることで補完している. 消費電力情報は, 毎秒 1 回取得できるため, 10 秒間の平均値を使用する. 10 秒に丸めた情報に欠損がある場合や, 10 秒間の間に複数の行動が含まれる場合は, その時刻のデータを削除し, 使用しないものとする.

取得した位置情報に基づき, それぞれの家具配置の場合に定義した領域の範囲内に含まれていれば「1」, そうでなければ「0」として加工した. 加えて, 家電の変更にも対応するために, 消費電力を平均 0, 分散 1 となるように正規化した. 位置情報と領域情報, 消費電力情報と正規化を行った消費電力情報という対応する 2 つの特徴量は同時に用いることはせず, 行動認識モデルの作成の際にはそれぞれ提案手法の評価に適したものを用的こととする.

特定の 1 日をテストデータとし, 残りを教師データとして行動認識精度の評価を行う. 全ての日に対して同様の分析を行い, それぞれの平均を取ったものを結果とする. 分析は Weka を用いて機械学習 (Random Forest) により行動認識モデルを作成して行った.

### 4.3 結果

取得したセンサデータを何も加工せず用いた際の分析結果と, それぞれの提案手法を用いた際の分析結果は以下ようになった.

#### 4.3.1 従来の手法

従来の手法 [5] を用いて, 定義した 15 種類の行動を認識した場合の分析結果は表 2 のようになった. 平均精度は 66.108 % となった.

#### 4.3.2 位置分散の導入

従来の手法に加え, 位置分散を特徴量として導入して 15 種類の行動を認識した場合の分析結果は表 3 のようになった. 平均精度は 68.061 % となった.

表 2 従来の手法を用いた行動認識結果

行動の種類	サンプル数	適合率	再現率	F 値
入浴	1325	0.527	0.429	0.395
掃除	312	0.590	0.383	0.424
風呂掃除	731	0.407	0.215	0.237
料理	1593	0.776	0.816	0.761
ゲーム	517	0.517	0.646	0.563
外出	957	0.982	0.977	0.979
洗濯	298	0.144	0.075	0.053
食事	958	0.709	0.538	0.583
PC 使用	4260	0.879	0.883	0.838
読書	1473	0.234	0.057	0.089
睡眠	273	0.818	0.661	0.668
スマートフォン使用	1305	0.380	0.227	0.215
食器洗い	747	0.688	0.705	0.600
洗面	289	0.297	0.290	0.281
テレビ視聴	1542	0.357	0.753	0.431
重み付け平均	-	0.766	0.661	0.653

表 3 従来の手法に加え位置分散を用いた行動認識結果

行動の種類	サンプル数	適合率	再現率	F 値
入浴	1325	0.520	0.475	0.426
掃除	312	0.573	0.351	0.393
風呂掃除	731	0.344	0.147	0.157
料理	1593	0.781	0.835	0.777
ゲーム	517	0.486	0.624	0.531
外出	957	0.973	0.978	0.975
洗濯	298	0.098	0.062	0.043
食事	958	0.857	0.515	0.592
PC 使用	4260	0.881	0.892	0.844
読書	1473	0.312	0.113	0.164
睡眠	273	0.818	0.652	0.663
スマートフォン使用	1305	0.378	0.200	0.177
食器洗い	747	0.684	0.757	0.640
洗面	289	0.344	0.366	0.350
テレビ視聴	1542	0.357	0.782	0.454
重み付け平均	-	0.772	0.681	0.669

#### 4.3.3 特徴量の選定

従来の手法で用いた特徴量の重要度を算出し、上位 12 個の特徴量を用いて 15 種類の行動を認識した場合の分析結果は表 4 の通りである。平均精度は 66.850 % となった。

#### 4.3.4 全時間を対象とした場合

実際にシステムを家庭に導入することを想定し、15 種類の行動に当てはまらない箇所をラベルなしとして新しいラベルを当てはめ、16 種類に対して行動認識を行った。従来の手法に加えて特徴量の選定を行い、上位 12 個のみを特徴量として用いた。その際の行動認識結果は表 5 となった。平均精度は 61.355 % となった。

#### 4.3.5 異なる家具配置への対応

異なる家具配置への対応のため、前回の実験で取得したデータのみを教師データとし、今回の実験で取得したデータをテストデータとして分析を行った。位置情報を領域情

表 4 特徴量の選定後の行動認識結果

行動の種類	サンプル数	適合率	再現率	F 値
入浴	1325	0.469	0.370	0.359
掃除	312	0.568	0.333	0.404
風呂掃除	731	0.326	0.110	0.159
料理	1593	0.792	0.812	0.759
ゲーム	517	0.491	0.654	0.543
外出	957	0.994	0.975	0.983
洗濯	298	0.148	0.169	0.111
食事	958	0.784	0.469	0.521
PC 使用	4260	0.938	0.906	0.897
読書	1473	0.159	0.145	0.152
睡眠	273	0.985	0.806	0.823
スマートフォン使用	1305	0.437	0.215	0.244
食器洗い	747	0.518	0.532	0.456
洗面	289	0.362	0.319	0.207
テレビ視聴	1542	0.398	0.730	0.493
重み付け平均	-	0.765	0.669	0.664

表 5 全時間を対象とした行動認識結果

行動の種類	サンプル数	適合率	再現率	F 値
ラベルなし	3497	0.409	0.786	0.516
入浴	1325	0.441	0.314	0.309
掃除	312	0.604	0.249	0.331
風呂掃除	731	0.290	0.104	0.151
料理	1593	0.735	0.677	0.662
ゲーム	517	0.661	0.643	0.651
外出	957	1.000	0.927	0.958
洗濯	298	0.000	0.000	0.000
食事	958	0.734	0.345	0.424
PC 使用	4260	0.955	0.841	0.856
読書	1473	0.167	0.001	0.001
睡眠	273	0.000	0.000	0.000
スマートフォン使用	1305	0.220	0.078	0.094
食器洗い	747	0.566	0.300	0.296
洗面	289	0.103	0.019	0.030
テレビ視聴	1542	0.447	0.784	0.546
重み付け平均	-	0.708	0.614	0.591

報に変換し、消費電力情報は正規化したものを用いた。認識対象の行動は 4.3.5 と同様に 16 種類とした。結果は表 6 の通りである。平均精度は 24.340 % となった。

#### 4.3.6 教師データの追加

以前のデータに加えて今回の実験データを教師データに加え、分析を行った。家具や家電の配置が異なっているデータを用いたため、4.3.5 と同様に、位置情報は領域情報に変換し、消費電力情報は正規化を行って用い、認識対象の行動は 16 種類とした。結果は表 7 の通りである。平均精度は 54.473 % となった。

#### 4.4 考察

課題 (I) について、従来の手法を用いた場合に比べて、認識の平均精度は位置分散を導入した場合 1.953 %、特徴量

表 6 異なる家具配置への対応を想定した行動認識結果

行動の種類	サンプル数	適合率	再現率	F 値
ラベルなし	7515	0.147	0.719	0.245
入浴	3404	0.000	0.000	0.000
掃除	528	0.239	0.225	0.232
風呂掃除	1040	0.000	0.000	0.000
料理	4763	0.746	0.509	0.605
ゲーム	3160	0.391	0.097	0.155
外出	1692	0.939	0.125	0.221
洗濯	670	0.000	0.000	0.000
食事	2687	0.333	0.010	0.020
PC 使用	9045	0.827	0.035	0.067
読書	3629	0.008	0.000	0.001
睡眠	709	0.000	0.000	0.000
スマートフォン使用	3085	0.000	0.000	0.000
食器洗い	1677	0.289	0.190	0.230
洗面	820	0.000	0.000	0.000
テレビ視聴	4983	0.325	0.532	0.403
重み付け平均	-	0.365	0.243	0.189

表 7 教師データ追加後の行動認識結果

行動の種類	サンプル数	適合率	再現率	F 値
ラベルなし	7515	0.329	0.750	0.435
入浴	3404	0.341	0.348	0.305
掃除	528	0.351	0.188	0.230
風呂掃除	1040	0.108	0.057	0.075
料理	4763	0.773	0.726	0.717
ゲーム	3160	0.626	0.644	0.635
外出	1692	0.947	0.595	0.664
洗濯	670	0.000	0.000	0.000
食事	2687	0.322	0.073	0.101
PC 使用	9045	0.916	0.767	0.769
読書	3629	0.021	0.003	0.005
睡眠	709	0.056	0.167	0.083
スマートフォン使用	3085	0.130	0.112	0.102
食器洗い	1677	0.400	0.390	0.303
洗面	820	0.086	0.099	0.092
テレビ視聴	4983	0.532	0.672	0.515
重み付け平均	-	0.612	0.545	0.517

の選定を行った場合は 0.742 % 向上した。どちらの手法についても期待した通りには大きな精度向上とはならなかったが、行動ごとには精度が大きく変わっているものがある。位置分散の導入については、入浴、料理、食事、PC 使用、読書、食器洗い、洗面、テレビ視聴について、適合率と再現率の調和平均を取ったものである F 値の値が増加していることがわかる。特に読書と洗面が他の行動と比較して値の増加が大きい。これら 2 つの行動は消費電力では認識が難しいと考えられる行動であるため、位置情報が認識に影響を与えやすい行動であるからだと考えられる。特徴量の選定については、外出、洗濯、PC 使用、読書、睡眠、スマートフォン使用、テレビ視聴について、F 値が増加していることがわかる。特に睡眠と読書が他の行動と比較して

値の増加が大きい。特徴量を削減したことにより、それら 2 つの行動を認識する際にノイズとなっていた特徴量が排除されたからであると考えられる。

全時間を対象とした分析については、15 種類の行動のみを分類した場合に比べて 4.753 % の精度の低下が見られた。これは、行動ラベルのない箇所が追加されることにより、行動認識モデルを新しく作成する際にその箇所がノイズになってしまうからであると考えられる。行動ラベルのない部分には、行動と行動の間の移動であったり、ただ立っているだけや座っているだけなどの静止状態であったり様々な状態が含まれる。居住者の位置や家電の消費電力についても 1 つの値に定まらず、時間や前後の行動に応じて様々なものがあるため、他の行動と合わせたときに行動の認識が難しくなってしまう。この問題を解決するためには、行動ラベルのない箇所をより細分化し、行動の種類を増やすことによって行動を切り分けやすくするなどの工夫が考えられる。また、行動の定義をより明確にし、行動ラベルのない箇所と行動をしている場所の差を明確にすることで精度の改善が見込まれる。

課題 (II) について、ある家庭で学習したモデルを用いたシステムを、そのまま別の家庭に導入することを想定して行った分析では平均精度が 24.340 % と低い精度になってしまった。これは家電や行動の起こる場所が異なることにより、テストデータがうまくモデルに当てはまらなくなってしまうことで、大部分の行動がラベルなしと認識されてしまうためである。しかし、新しい家庭で取得するデータを別の家庭で学習したモデルに追加することを想定した場合の分析では平均精度が 54.473 % と大きな改善が見られた。この結果から、別の家具配置の家庭にシステムを導入した場合でも、その家庭のデータを新たに学習することで精度が上がるが見込まれる。

## 5. 関連研究

本章では、本研究に関係する行動認識に関する代表的な既存研究についてまとめる。

勝手ら [7] は、物体と動きの特徴量を用いて行動認識を行っている。人物の動きだけでなく、行動に用いられる物体に注目し、その物体の特徴量を加えることで行動の認識精度を向上することを目的としている。この研究では 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）を認識できるかという実験を行っており、提案手法を用いることで、人物の動きの特徴量のみを用いた場合と比較し、認識精度が向上するという結果が出ている。しかし、この研究ではカメラによる動画像を使用しており、使用者のプライバシーを侵害してしまう恐れがあるという課題がある。また、認識できる行動の種類が少ない。

大内ら [8] は、携帯電話に搭載されている加速度センサ

とマイクのみを用いて、10 秒毎に行動を認識している。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」の場合はマイクからの音の分析によりどの作業をしているかの推定を行う。この研究で推定できる作業は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）である。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、この研究ではマイクを使うことから、プライバシーを侵害する恐れがある。また、推定できる行動種類が限られているため、日常生活を広くカバーする行動を認識できない。

Maekawa ら [9] 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、掃除などの行動を認識する手法を提案している。しかし、この手法は電化製品の操作に関連した行動の認識に限られており、認識精度も 75 %程度に留まっている。

Chen ら [10] 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。また、平均認識時間も 2.5 秒と高速に行動を認識できている。しかし、こ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。

Kasteren ら [11] は、ドアセンサ、引出センサ、温度センサなど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、着替えなど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。また、データのセグメントの長さが 60 秒となっており、リアルタイムに行動が認識できているとは言い難い。

以上の行動認識の既存研究には、(1) カメラ等の機器によるプライバシーの侵害、(2) 認識できる行動の種類が少ない、(3) 認識の精度がよくない、(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 5 つの課題がある。本研究は、これらの課題を同時に全て解決するための新たなシステムを構築しようとしている点で既存研究と異なっている。

ある環境における行動認識の学習結果を他の環境に適用するための研究も行われている。井上らは、タブレット端末と電力計を用いて、35 軒の家庭から照度データと消費電力データを収集し、行動推定を行うとともに、家庭間で認識精度を良くするためのデータの適応手法を提案している [12]。家庭間転移の方法として、家庭間の交差検証の結果、精度が良かったサンプルのみを学習に使う方法と、転入元のデータ分布を転入先のデータ分布に近似する手法を

提案している。本稿における提案手法は、住人の位置を特徴量として使用しており、家具の配置が違う家庭間で学習結果の転移を可能にするという点で異なっている。

## 6. おわりに

本稿では、多様な生活行動をリアルタイムに高精度で認識することを目的に、先行研究で用いられている位置・電力情報の加工や特徴量の選定を行う新しい生活行動認識手法を提案した。また、異なる家電・家具配置の家庭にシステムをそのまま導入できるようにすることを目的に、位置情報を領域情報に変換し、消費電力情報の正規化を行うことを提案した。

評価実験として、料理、食事、読書、テレビ視聴、食器洗い、入浴、掃除、PC 使用、外出、睡眠、洗面、洗濯、ゲーム、スマートフォン使用、風呂掃除の 15 種類の行動を対象としてセンサデータを収集した。リアルタイムに対応した際の認識精度は 59.465 %となった。そこに位置の分散を新たに特徴量として加えた際の認識精度は 60.629 %、特徴量の選定を行った際の認識精度は 61.355 %となった。また、異なる家庭へのシステムの導入を想定した際の認識精度は 24.340 %、教師データを増やした際の認識精度は 54.473 %となった。

謝辞 本研究の一部は、文部科学省特別経費「ヒューマノフィリック科学技術創出研究推進事業」の支援により実施した。また、(株)ラトックシステムが開発した REX-BTWATTCH のサンプルプログラムを使わせて頂いた。ここに記して謝意を表す。

## 参考文献

- [1] J. Scott, B. Brush, J. Krumm, B. Meyers: "Controlling Home Heating Using Occupancy Prediction," in Proc. of UbiComp 2011.
- [2] B. Sean, M. Aditya, I. David, S. Prashant: "SmartCap: Flattening Peak Electricity Demand in Smart Homes," in Proc. of Percom 2012, pp.67-75 (2012).
- [3] P. Rashidi, A. Mihailidis: "A Survey on Ambient Assisted Living Tools for Older Adults," IEEE Journal of Biomedical and Health Informatics, vol.17, no.3, pp.579-590 (2013).
- [4] 上田 健揮, 玉井 森彦, 荒川 豊, 諏訪 博彦, 安本 慶一: 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 57(2), pp.416-425 (2016).
- [5] 中川 愛梨, 諏訪 博彦, 藤本 まなと, 荒川 豊, 安本 慶一: リアルタイム行動認識システム開発のためのデータ収集と分析, 研究報告モバイルコンピューティングとパーベシブシステム (MBL), 2015-MBL-77(9), pp.1-5 (2015).
- [6] J. R. Kwapisz, G. M. Weiss, S. A. Moore: "Activity Recognition using Cell Phone Accelerometers," ACM SIGKDD Explorations Newsletter, vol.12, no.2, pp.74-82 (2010).
- [7] 勝手 美紗, 内海 ゆづり, 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 111(430), pp.125-126 (2012).
- [8] 大内 一成, 土井 美和子: 携帯電話搭載センサによるリ

- アルタイム生活行動認識システム, 情報処理学会論文誌 53(7), pp.1675–1686 (2012).
- [9] T. Maekawa, Y. Kishino, Y. Sakurai, and T. Suyama: "Recognizing the Use of Portable Electrical Devices with Hand-Worn Magnetic Sensors," in Proc. of Pervasive 2011, pp.276–293 (2011).
- [10] L. Chen, C.D. Nugent and H. Wang: A Knowledge-Driven Approach to Activity Recognition in Smart Homes, IEEE Transactions on Knowledge and Data Engineering, vol.24 , no.6, pp.961-974 (2012).
- [11] T. L. M. van Kasteren, B.J.A Krose: " activity monitoring system for elderly care using generative and discriminative models, " Personal and Ubiquitous Computing, vol.14, no.6, pp.489–498 (2010).
- [12] 井上創造, 潘新程, 花沢明俊: 家庭内行動センシングにおける機械学習データの家庭間転移について, 情報処理学会研究報告, Vol. 2015-UBI-48, No. 10, pp.1–8 ( 2008 ).