

センサデータを用いた低コストな 屋内行動推定システムの検討

岸川 裕佑¹ 今井 信太郎¹ 新井 義和¹ 猪股 俊光¹

概要: 近年, スマートフォンなどのセンサを搭載した小型デバイスやスマートホームの広がりから, 利用者志向の家電の自動制御や, 消費電力の低減などを目的とした生活改善アドバイスなどの研究がさかに行われている. これらの研究において, 利用者の行動推定は重要な要素技術であり, 多くの研究が行われてきた. しかし, システムによっては非常に高価なセンサが必要になることや, 位置情報取得のために利用者にタグなどを常に保持させる必要があることなど, 利用者の負担が大きくなってしまいう傾向がある. また, 比較的安価かつタグなどを必要とせずに行動を推定する手法として, カメラで撮影した画像を用いて行動を推定する手法も提案されているが, 家庭内への設置には大きな抵抗感をともなう. そこで, 本研究ではこれらの負担を抑えるため, カメラを除く導入コストの低いセンサと機械学習を用いて行動を推定する手法を提案する.

A Low Cost Motion Estimation System using Sensor Data in Indoor Environment

YUSUKE KISHIKAWA¹ SHINTARO IMAI¹ YOSHIKAZU ARAI¹ TOSHIMITSU INOMATA¹

1. はじめに

近年, スマートフォンやスマートホームの広がりから, 家電の自動制御 [1] や消費電力の観点からの生活改善アドバイス [2] など, 屋内環境のスマート化に関する研究がさかに行われている. これらの研究では, 屋内に複数種類のセンサを配置し, 人の行動を推定する必要のあるシステムが多い. しかし, 人の位置情報を取得して推定に利用する場合, 精度と利用者の負担にトレードオフが生じる. 特に, 利用者に常にタグやスマートフォンを携帯してもらいう手法は, 測位精度を向上させやすいが, 多少なりとも利用者に負担を強いることになる. 特に, スマートフォンほどの大きさとなると, 常時携帯する負担も大きくなる. また, 高性能なセンサを使用する手法は, 一般的に導入コストが高くなる. また, 利用者にタグなどを持ち歩かせず, かつ低コストで行動を推定する手法として, カメラで撮影した画像を用いる手法も提案されている [3]. この手法では画

像を用いて高精度な行動推定が可能となるが, 家庭内にカメラを設置したまま生活することは, 強い抵抗感をともなう. そこで, 本研究では, 利用者に対する負担を抑えた屋内における行動推定の実現を目的とし, 利用者にタグなどを持ち歩かせない, かつカメラを用いない, かつ低コストなセンサを用いた行動推定手法を検討する. 本研究において低コストとは, 低価格のセンサを用いることで環境を構築できることとする. 本手法では, 屋内に設置した複数種類のセンサから収集したデータにラベル付けをし, 機械学習を用いて学習モデルを作成する. そして, そのモデルを用いて行動推定を行う.

本研究では, 行動推定を利用する多様な研究への応用を可能とするために, 屋内における基本的な生活行動の判別を行う. これらの行動は, 図 1 に示す総務省統計局の生活行動分類 [4] を参考に, 家庭内で行う行動を抽出, 細分化して決定した. 判別の対象とする行動を表 1 に示す.

¹ 岩手県立大学大学院
Iwate Prefectural University Graduate school

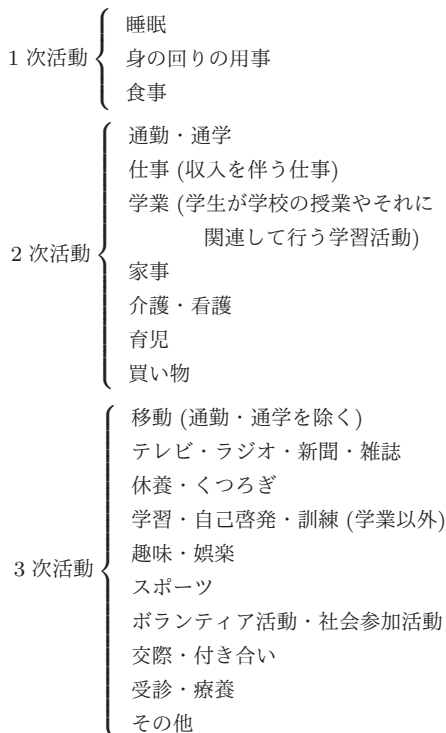


図 1 総務省統計局による生活行動分類 [4]

表 1 本研究で推定の対象とする行動

睡眠	洗濯
食事	勉強
トイレ	外出
入浴	帰宅
洗面	読書
料理	テレビ
食器洗い	TVゲーム
掃除	パソコン

2. 関連研究

屋内の生活行動を推定する研究はすでに数多く研究されている。上田らは高精度の位置情報と家電の消費電力のセンサデータを用いて機械学習を行うことで行動の推定を行っている [5]。この研究では、位置情報の取得には超音波センサを用いており、屋内に複数の受信機を配置し、利用者は超音波を送信するタグを常に携帯する。推定の対象とする行動は、「食事」、「テレビ」、「入浴」、「睡眠」などの基本的な生活行動であり、90%以上の正解率で推定することができる。研究で利用している超音波センサは誤差 5cm 程度の高精度な測位が可能ではあるが、非常に高価であり、タグを持ち歩く必要がある。同時に、より低コストな Bluetooth Low Energy (BLE) を用いた位置推定を提案しているが、この場合も利用者はタグを携帯する必要がある。Chen らは、オントロジベースの推定プロセスを用いた行動推定手法を提案している [6]。それぞれの行動の手順をシステムにアップロードしておくことで、機械学

習のように事前に大量の学習データを取得する必要がなくなるという利点がある。ただし、この研究では傾斜センサや圧力センサ、接触センサなどの約 40 個のセンサを用いており、導入コストが高くなっている。中村らは、推定した行動とその行動を決定した要因から生活パターンを解析し、生活改善のための行動スケジュールを導出する手法を提案している [2]。行動推定には、スマートタップ、温湿度センサ、レーザ測域スキャナから取得した、消費電力、温湿度、位置情報と、Web サービスから取得した気象データを用いている。位置測定に用いるレーザ測域スキャナは高精度な位置測定が可能であるが、非常に高価であり、利用者の負担が大きくなる。

上記のように屋内に設置したセンサを主体としてセンシングを行う研究のほかに、ウェアラブルセンサやスマートフォンなどの携帯するセンサを主体としてセンシングを行う研究も多く存在している。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た行動推定手法を提案している [7]。この提案では、加速度センサのデータから「歩行」、「安静」、「作業」の 3 種類の行動を推定し、マイクから得たデータを用いて、「作業」をさらに「歯磨き」、「トイレ」、「掃除機」などの行動に分類する。前川らは、手首にマイク、加速度センサ、照度センサ、方位センサ、カメラを搭載したウェアラブルセンサを装着する行動推定手法を提案している [8]。カメラは手に持っている物体を映すように設置することで、何を使って行動するのかを判別できるようにしている。Jiang らは、曲げセンサ、ジャイロセンサ、磁気センサ、加速度センサを装着した靴下を用いた行動推定手法を提案している [9]。この提案では、「歩く」、「走る」、「乗る」、「座る」の 4 種類の行動を推定の対象としており、全体で 98% 程度の正解率で推定することができる。

ここで挙げた研究のように、既存の研究は、タグなどを携帯する必要がある、カメラを用いる、導入コストが高いなど、高精度の推定を可能にする代わりに利用者の負担が大きいシステムが多い。そこで本研究では、これらの負担を抑えた行動推定手法を提案する。

3. 提案手法

3.1 提案手法の概要

1 節で述べたように、本研究では利用者の負担を抑えた行動推定を目的とする。この目的のために、提案手法は以下の 3 要件を満たす必要がある。

(F1) 利用者のタグ・センサの保持を前提としない：位置情報を取得するために利用者のタグ・センサの保持を前提とした関連研究が存在するが、屋内において常時携帯することは利用者にとっては負担となる。このため、本研究では利用者のタグ・センサの保持を前提とせず位置情報を取得する。

(F2) カメラを使用しない：生活空間におけるカメラを用いた画像の取得は、仮にその画像の扱いがシステム内のみで完結する場合であっても強い抵抗を感じさせる。このため、本研究ではカメラを用いて画像を取得しないこととする。

(F3) 高価なセンサを使用しない：1,2節で述べたように、高価なセンサ類から高精度なデータを取得して行動を推定する手法が提案されている。しかし、一般的な環境にそのようなセンサを使用した機器を導入することは困難である。

表 1 に示した本研究で推定の対象とする行動に対して、その推定に必要な情報を整理し、表 2 にまとめた。例えば、夜に照明のついていない、ベッドのある部屋に長時間いるならば、利用者は睡眠中であると推定できる。表 2 から、提案手法では、利用者の位置、電力使用の有無とその位置、水使用の有無とその位置、部屋の照度、時刻の 5 項目の情報から利用者の行動を推定する。利用者の位置を取得するために、本研究では前述した要件 (F1) を考慮し、人感センサを使用することとした。電力使用の有無とその位置、水使用の有無とその位置、部屋の照度の検出には、それぞれ消費電力センサ、水流センサ、照度センサを用いる。

図 2 に提案システムの概要を、図 3 にシステムの流れを示す。本研究では機械学習を用いて推定を行う。まず、システムは以下の手順で学習モデルを作成する。

- (1) センサデータの収集：システムは、センサノードからのデータを受信すると、そのデータに時刻とセンサの識別番号を付与する。すなわち、センサデータには「タイムスタンプ」、「センサの識別番号」、「センサが取得したデータ」の 3 種類の情報が含まれる。そして、タイムスタンプを基準にして各センサデータを結合する。
- (2) センサデータと生活行動の紐づけ：センサデータを取得すると同時に、利用者の行った生活行動とその時間を記録しておく。センサデータ取得後にタイムスタンプを基準にセンサデータに生活行動をラベル付けする。
- (3) 機械学習を使ったモデルの作成：取得したセンサデータを学習データとして利用し、学習モデルを作成する。その後、テストデータを取得し、学習モデルを用いて行動推定を行う。そして、作成したモデルを用いて行動推定を行う。

4. 評価実験

予備実験として、複数の学習アルゴリズムを用いて行動推定の精度を検証する。

4.1 実験環境

予備実験は、図 4 に示すワンルームの apart で行う。センサは、人感センサをリビング中心の天井に 1 個、照度センサをリビングの中心に 1 個設置し、消費電力センサでテレビ、パソコン、電子レンジ、洗濯機の電力使用の有無を計測する。水流センサは予備実験では使用しない。表 3 に使用するセンサの一覧を示す。本実験では、図 5 に




図 2 システム構成図

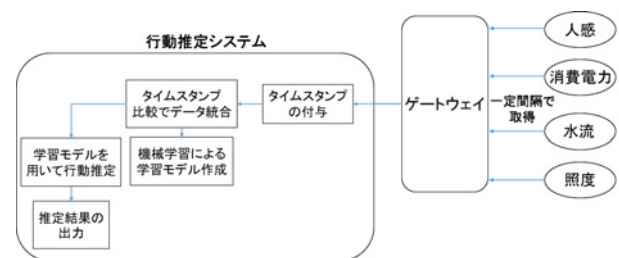


図 3 システムの流れ

示すシステム構成とし、Valley Campus Japan の提供する M2M システム開発キット MDK-SHIBA[10] を一部のセンサで利用する。MDK-SHIBA は、センサ、ゲートウェイ、クラウドからなるツールであり、センサから収集したデータをゲートウェイを通してクラウドに蓄積し、ユーザがクラウドからデータを取得することが可能である。本研究では、MDK-SHIBA の消費電力センサを用いる。また、MDK-SHIBA に対応していない人感センサと照度センサは、ゲートウェイとしての役割を持たせた 1 台の Arduino に接続し、シリアル通信を用いてデータを収集する。人感センサの検知距離は 8m である。各センサの取得間隔は 5 秒間隔とした。今回の実験では、センサの数が少ないこと、水流センサがないことを考慮し、表 4 に示す 11 種類の生活行動の推定を行う。被験者は一人暮らしの 20 代男性で、これら 11 種類の生活行動を行う。表 1 に示す行動と比較すると、「洗濯」は洗濯機の使用を想定した場合、洗濯物を洗濯機の中に入れ、洗濯機を起動する行動と、洗濯が終わった洗濯物を干す行動に分けることが適当であると考えたため、「洗濯開始」と「洗濯物を干す」を推定の対象とした。また、洗面所付近にセンサが存在しないこと、本予備実験の被験者が習慣として「歯磨き」をリビングで行うことから、「洗面」の中から「歯磨き」を抜き出し判別の対象とした。被験者には学習データ取得時とテストデータ取得時の両方で、判別を行うすべての行動を最低でも 1 回は行う。ただし、日常生活の行動パターンに近づけるため、行動のタイミングは任意とした。

表 2 推定する行動に必要な情報

行動	行動場所	位置情報	電力の使用	水の使用	部屋の照度	時刻
睡眠	ベッド	○			○	○
食事	テーブル	○			○	○
トイレ	トイレ	○		○		
入浴	風呂	○		○	○	○
洗面	洗面所	○		○		○
料理	台所	○	○	○	○	○
食器洗い	台所	○		○		○
掃除	リビング	○	○			
洗濯	洗面所	○	○	○		○
勉強	リビング	○			○	
外出	玄関	○			○	
帰宅	玄関	○			○	
読書	リビング	○			○	
テレビ	リビング	○	○			
PC	リビング	○	○			
TV ゲーム	リビング	○	○			




図 4 実験環境

表 3 センサー一覧

人感センサ	SB612A
消費電力センサ	MDK-SHIBA (Z803)
照度センサ	CdS セル

表 4 実験で判別を行う行動一覧

行動	行動場所
睡眠	ベッド
食事	テレビの前
料理	台所
食器洗い	台所
洗濯開始	洗面所
洗濯物を干す	ベランダ
テレビ	テレビの前
パソコン	テレビの前
読書	テレビの前
歯磨き	テレビの前
その他	不特定




図 5 予備実験のシステム構成図

4.2 機械学習

本予備実験では、提案システムにおいて以下の 4 種類の機械学習手法を用いた場合の行動推定の精度を比較する。

SVM[11] は、各データとそれらを分ける境界線の距離が最大となるように分類を行うアルゴリズムである。本実験では非線形 SVM を用いる。非線形 SVM は、直線を用いる線形 SVM よりも複雑なデータの分類が可能である。

k-近傍法 [12] は、学習データをベクトル空間上に配置しておき、未知のデータに対してそのデータから近い順に k 個の学習データを取得し、もっとも多い学習データに分類するアルゴリズムである。

ランダムフォレスト [13] は、複数の決定木で推定を行い、各決定木の多数決によって判別するアルゴリズムである。

ニューラルネットワーク [14] は、複数のノードを用いて人間の脳の仕組みに近い構造を作り、推定を行うアルゴリズムである。本実験では、多層パーセプトロン方式を用いる。パーセプトロンは 2 値分類を行う学習アルゴリズムであり、複数の入力を受けて、それがどちらであるかを判別する。多層パーセプトロンは、このパーセプトロンを 3 層以上重ねることで複雑な分類を可能にした方式である。

本予備実験では、機械学習に用いる学習データを 72 時間分、テストデータを 24 時間分用意する。

4.3 実験結果

表 5 から表 8 に各学習アルゴリズムを用いて作成したモ

デルによる行動推定の結果を示す。また、表9から表12にそれぞれの混同行列を示す。評価には「 P_{recision} (適合率)」、「 R_{ecall} (再現率)」、「F値」の3種を用いる。Precisionは、システムがAであると推定した場合に、利用者の実際の行動がAであったデータの割合であり、Recallは、Aであると推定されるべきデータのうち、実際にシステムがAであると正しく推定したデータの割合である。F値は、式1の計算によって求められる調和平均である。

$$\frac{2R_{\text{ecall}} \cdot P_{\text{recision}}}{R_{\text{ecall}} + P_{\text{recision}}} \quad (1)$$

また、「ラベル数」はテストデータの正解ラベルの数を示している。取得したデータ件数は、学習データが52,436件で、テストデータが17,167件である。

4.3.1 全体評価

各学習アルゴリズム全体として、Precision, Recall, F値の平均値は50%前後にとどまっている。これは、「食器洗い」や「洗濯開始」などのテストデータのデータ数が少ない行動がまったく推定できず0%になってしまっているためである。これらの0%になっている行動を除けばPrecision, Recall, F値の平均値は95%前後まで上昇する。推定できていなかった原因としては学習データとテストデータの両方のデータ数が少なく、行動の特徴を捉えられなかったことが考えられる。これ以外にも、センサの数が少ないことも原因の一つであると考えられる。特に、他の行動を「テレビ」と間違えて判別してしまうことが多かった。これは、「食事」、「料理」、「食器洗い」はテレビの電源をつけたまま行うことが多かったため、テレビの電力は特徴になりづらかったと考えられる。他にも、「洗濯開始」後にリビングで「テレビ」を見ていたことや、「歯磨き」をリビングで「テレビ」を見ながらしていたため、これらの行動も「テレビ」と混同してしまっただと考えられる。

4.3.2 SVMの評価

表5と表9に示すSVMを用いた実験結果では、4種類の学習アルゴリズムの中でもっともPrecision, Recall, F値の平均値が低くなっている。4種類の学習アルゴリズムの中で唯一「食事」の行動を推定することができなかったためである。また、「その他」の推定も他のアルゴリズムと比較して非常に低くなっている。これは、「その他」を「読書」と間違えて推定することが多いためである。「その他」の行動中はリビングに居ないことが多いため、人感センサが反応しないことが多い。「読書」の場合は本に集中するため、非常に小さな動きにとどまることが多く、こちらも人感センサが反応しない。どちらも人感センサが反応しないという特徴があるため、判別を間違えてしまっていると考えられる。

4.3.3 k-近傍法の評価

表6と表10に示すk-近傍法を用いた実験結果では、Precisionの平均値が48%と低くなっている。特に、「テレビ」

表5 SVMを用いた実験結果

	Precision	Recall	F値	ラベル数
睡眠	100%	100%	100%	5763
食事	0%	0%	0%	398
料理	100%	71%	83%	98
食器洗い	0%	0%	0%	23
洗濯開始	0%	0%	0%	13
洗濯物を干す	0%	0%	0%	31
テレビ	88%	100%	94%	5294
パソコン	100%	100%	100%	3660
読書	76%	96%	85%	1118
歯磨き	0%	0%	0%	166
その他	71%	33%	45%	603
平均	48%	45%	46%	17167

を「食事」と間違えることが多かった。その一方でRecallの平均値は54%と高めになっている。

4.3.4 ランダムフォレストの評価

表7と表11に示すランダムフォレストを用いた実験結果では、Recallの平均値が55%ともっとも高くなっている。特徴的なのは「食事」の推定精度が比較的高くなっていることである。すべての行動の中で、もっとも「テレビ」と混同されやすい「食事」が、ランダムフォレストでは比較的正しく推定できているため、「テレビ」のF値が4種類の学習アルゴリズムの中でもっとも高くなっている。

4.3.5 ニューラルネットワークの評価

表8と表12に示すニューラルネットワークを用いた実験結果では、Precisionの平均値が57%、F値の平均値が54%ともっとも高くなっている。F値が0%になっている行動を除けば、すべての行動でPrecisionが60%を越えており、4種類の学習アルゴリズムの中でもっとも安定した結果が出ている。しかし、Recallの平均値は52%と低めになっている。理由としては、「食事」を「テレビ」と間違えることが多く、Recallが22%と非常に低くなっていることが原因だと考えられる。しかし、「食事」とF値が0%になっている行動を除けば、すべての行動でRecallが70%を越えているため、「食事」が低くなっている原因を取り除けば、4種類の学習アルゴリズムの中でもっとも高い精度で推定ができると考えられる。

4.4 考察

4種類の学習アルゴリズムを比較した結果、ランダムフォレストとニューラルネットワークの2手法で比較的良好な結果を得ることができた。特に、ニューラルネットワークを使用した場合にもっとも良い結果を得られたが、Recallが極端に低くなることもあるため改善が必要となる。

今回の実験では、センサの数が人感センサ1個、消費電力センサ4個、照度センサ1個と少なかったため、各生活行動の特徴を抽出することが困難であった。そのため、セ

表 9 SVM の混同行列

	睡眠	食事	料理	食器洗い	洗濯開始	洗濯物を干す	TV	PC	読書	歯磨き	その他
睡眠	5763	0	0	0	0	0	0	0	0	0	0
食事	0	0	0	0	0	0	398	0	0	0	0
料理	0	0	70	0	0	0	28	0	0	0	0
食器洗い	0	0	0	0	0	0	23	0	0	0	0
洗濯開始	0	0	0	0	0	0	13	0	0	0	0
洗濯物を干す	0	0	0	0	0	0	0	0	0	0	31
TV	0	0	0	0	0	0	5294	0	0	0	0
PC	0	0	0	0	0	0	0	3660	0	0	0
読書	0	0	0	0	0	0	0	0	1069	0	49
歯磨き	0	0	0	0	0	0	166	0	0	0	0
その他	0	0	0	0	0	0	76	0	329	0	198

表 10 k-近傍法の混同行列

	睡眠	食事	料理	食器洗い	洗濯開始	洗濯物を干す	TV	PC	読書	歯磨き	その他
睡眠	5763	0	0	0	0	0	0	0	0	0	0
食事	0	209	67	0	0	0	122	0	0	0	0
料理	0	15	72	0	0	0	11	0	0	0	0
食器洗い	0	7	0	0	0	0	16	0	0	0	0
洗濯開始	0	0	0	0	0	0	13	0	0	0	0
洗濯物を干す	0	0	0	0	0	0	0	0	0	0	31
TV	0	333	55	0	0	0	4897	0	0	9	0
PC	0	0	0	0	0	0	0	3539	0	0	121
読書	0	0	0	0	0	0	0	0	1112	0	6
歯磨き	0	0	0	0	0	0	166	0	0	0	0
その他	0	53	4	1	0	17	23	0	55	0	450

表 6 k-近傍法を用いた実験結果

	Precision	Recall	F 値	ラベル数
睡眠	100%	100%	100%	5763
食事	34%	53%	41%	398
料理	36%	73%	49%	98
食器洗い	0%	0%	0%	23
洗濯開始	0%	0%	0%	13
洗濯物を干す	0%	0%	0%	31
テレビ	93%	93%	93%	5294
パソコン	100%	97%	98%	3660
読書	95%	99%	97%	1118
歯磨き	0%	0%	0%	166
その他	74%	74%	74%	603
平均	48%	54%	50%	17167

表 7 ランダムフォレストを用いた実験結果

	Precision	Recall	F 値	ラベル数
睡眠	100%	100%	100%	5763
食事	53%	61%	57%	398
料理	21%	79%	33%	98
食器洗い	0%	0%	0%	23
洗濯開始	0%	0%	0%	13
洗濯物を干す	0%	0%	0%	31
テレビ	96%	95%	95%	5294
パソコン	100%	100%	100%	3660
読書	97%	99%	98%	1118
歯磨き	0%	0%	0%	166
その他	9%2	76%	83%	603
平均	51%	55%	51%	17167

ンサの数を増やすことで評価結果を大きく改善させることができると考えられる。特に、「食事」、「料理」、「食器洗い」、「テレビ」の4種類の生活行動はすべてリビング内で行う行動であり、かつ、テレビの電源をつけたままで行うことが多かったため、特徴に差が出なかった。また、人感センサは動かなければ反応しないため、「読書」などのほとんど動かない生活行動を行っているときには反応しない。よって、動かない生活行動に対しては位置測定の代用として利用することは難しいことが分かった。ただし、動く生活行動には位置測定の代用として機能するため、「食事」、

「テレビ」、「料理」、「食器洗い」の特徴を分けるために、人感センサをテレビの前と台所の2か所に設置し、動かない行動とリビング以外の行動を分けるため、洗面所付近に人感センサを1個設置すると精度の向上が期待できる。

5. おわりに

本研究では、利用者に対する負担を抑えた屋内における行動推定の実現を目的し、利用者にタグなどを持ち歩かせない、かつカメラを用いない、かつ低コストなセンサを用いた行動推定手法を検討した。そして予備実験により、機

表 11 ランダムフォレストの混同行列

	睡眠	食事	料理	食器洗い	洗濯開始	洗濯物を干す	TV	PC	読書	歯磨き	その他
睡眠	5763	0	0	0	0	0	0	0	0	0	0
食事	0	241	120	0	0	0	36	0	0	1	0
料理	0	19	77	0	0	0	2	0	0	0	0
食器洗い	0	9	0	0	0	0	14	0	0	0	0
洗濯開始	0	0	0	0	0	0	13	0	0	0	0
洗濯物を干す	0	0	0	0	0	0	0	0	0	0	31
TV	0	109	135	0	0	0	5045	0	0	5	0
PC	0	0	0	0	0	0	0	3660	0	0	0
読書	0	0	0	0	0	0	0	0	1103	0	15
歯磨き	0	0	0	0	0	0	166	0	0	0	0
その他	0	76	36	0	0	2	0	0	32	0	457

表 12 ニューラルネットワークの混同行列

	睡眠	食事	料理	食器洗い	洗濯開始	洗濯物を干す	TV	PC	読書	歯磨き	その他
睡眠	5763	0	0	0	0	0	0	0	0	0	0
食事	0	87	10	0	0	0	301	0	0	0	0
料理	0	4	70	0	0	0	24	0	0	0	0
食器洗い	0	0	0	0	0	0	23	0	0	0	0
洗濯開始	0	0	0	0	0	0	13	0	0	0	0
洗濯物を干す	0	0	0	0	0	0	0	0	0	0	31
TV	0	48	0	0	0	0	5246	0	0	0	0
PC	0	0	0	0	0	0	0	3660	0	0	0
読書	0	0	0	0	0	0	0	0	1112	0	6
歯磨き	0	0	0	0	0	0	166	0	0	0	0
その他	12	2	0	0	0	0	74	0	32	0	483

表 8 ニューラルネットワークを用いた実験結果

	Precision	Recall	F 値	ラベル数
睡眠	100%	100%	100%	5763
食事	62%	22%	32%	398
料理	88%	71%	79%	98
食器洗い	0%	0%	0%	23
洗濯開始	0%	0%	0%	13
洗濯物を干す	0%	0%	0%	31
テレビ	90%	99%	94%	5294
パソコン	100%	100%	100%	3660
読書	97%	99%	98%	1118
歯磨き	0%	0%	0%	166
その他	94%	80%	86%	603
平均	57%	52%	54%	17167

械学習に用いる学習アルゴリズムの比較を行い、その後、追加に必要なセンサの検討を行った。予備実験では、3.1 節で述べた (F1) 利用者のタグ・センサの保持を前提としないについては、人感センサ、消費電力センサ、照度センサを用いることにより、タグ・センサを携帯する必要がなかったため、実現できている。(F2) カメラを使用しないについては、カメラを使わずに行動を推定できており、実現できている。(F3) 高価なセンサを使用しないについては、使用したセンサが人感センサ 1 個、消費電力センサ 4 個、照度センサ 1 個であったため、実現できている。一方、実験結

果では、もっとも結果が良かったニューラルネットワークであっても、F 値の平均が 54%と、十分な推定精度とは言えない。しかし、センサが少ないながらもセンサデータに特徴がある場合は推定が可能であることが実験結果から読み取れ、センサの数と学習アルゴリズムのチューニングを十分行えば、高精度の推定ができるようになると思われる。今後の予定としては、センサを追加することでどの程度推定精度が上昇するかの調査と、1 節で示した推定を行う行動すべてを推定対象とするために、生活行動の特徴を判別する手法の検討を行う。

参考文献

- [1] Shet Nagaraj, Shreesha C., Rao V. P., Gubbi Abdullah: *Low-Cost Appliance Control System for Home Automation and Energy Management Using Image Processing, Artificial Intelligence and Evolutionary Computations in Engineering Systems*, Vol. 394, pp. 125-134 (2016).
- [2] 中村笙子, 廣森聡仁, 山口弘純, 東野輝夫, 山口容平, 下田吉之 : スマートハウス内センシングを活用した生活行動推薦システム, マルチメディア、分散、協調とモバイルシンポジウム 2014 論文集, pp. 1557-1566 (2014).
- [3] Appiah Kofi, Hunter Andrew, Waltham Christopher: *Low-power and efficient ambient assistive care system for elders*, Computer Vision and Pattern Recognition Workshops, pp. 97-102 (2011).
- [4] 統計局ホームページ/平成 23 年社会生活基本調査用語の解説: 用語の解説 (調査票 A 関係), 入手先 (<http://www.stat.go.jp/data/shakai/2011/yougo.htm>)

- (参照 2017.10.18).
- [5] 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, Vol. 57, No. 2, pp. 1–10 (2016).
 - [6] Chen Liming, Nugent D. Chris, Wang Hui: *A Knowledge-Driven Approach to Activity Recognition in Smart Homes*, IEEE Trans. Knowledge and Data Engineering, Vol. 24, No. 6, pp. 961–974 (2012).
 - [7] 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, Vol. 53, No. 7, pp. 1675–1686 (2012).
 - [8] 前川卓也, 柳沢豊, 岸野泰恵, 石黒勝彦, 亀井剛次, 櫻井保志, 岡留剛: ウェアラブルセンサによるモノを用いた行動の認識について, 情報処理学会研究報告, Vol. 2010-UBI-25, No. 57, pp. 1–8 (2010).
 - [9] Lu Jiang, Zhang Ting, Hu Fei, Wu Yeqing, Bao Ke: *Measuring activities and counting steps with the Smart-Socks - An unobtrusive and accurate method*, IEEE Global Humanitarian Technology Conference, pp. 694–698 (2014).
 - [10] 株式会社バレイキャンパスジャパン: M2M システム開発キット, 入手先 (<http://valleycampus.com/business/mdk/>) (参照 2017.10.20)
 - [11] Boser E. Bernhard, Guyon M. Isabelle, Vapnik N. Vladimir: *A training algorithm for optimal margin classifiers*, Proceedings of the 5th Annual ACM Workshop on COLT, pp. 144–152 (1992).
 - [12] Cover T., Hart P., *Nearest neighbor pattern classification*, IEEE Transactions on Information Theory, Vol. 13, No. 1 (1967).
 - [13] Breiman Leo: *Random Forests*, Machine Learning, Vol. 45, No. 1, pp. 5–32 (2001).
 - [14] F. Rosenblatt, The perceptron: a probabilistic model for information storage and organization in the brain, Psychological Review, Vol. 65, No. 6, pp. 386–408 (1958).