

スマートホームにおける複数のセンシングデータに基づいた 生活行動データ抽出システムの提案

上田 健揮¹ 玉井 森彦¹ 安本 慶一¹

概要: 本稿では, スマートホームにおいて取得したセンサデータを用いて機械学習により居住者の生活行動を識別するシステムを提案する. 行動認識に関する研究は多数行われているが, 多数のセンサを使用したものや, 特殊なカメラを必要とするものなど, 導入コストの高さや住人のプライバシーの侵害などが課題として残っている. また, 加速度センサを用いた行動認識の研究では, 歩く, 走るなどというユーザの動きに基づいた行動しか認識できず, 家庭内での多様な生活行動の認識は困難である. そこで本研究では家庭内における基本的な生活行動を網羅する20種類の行動を認識の対象とし, 今後普及するであろう消費電力センサと位置情報のみを用いることで, 導入コストを抑え, プライバシーの侵害が少ない行動認識システムを開発する. 機械学習に用いる訓練データは, 著者らが以前より開発している生活行動ラベリングツールを用いて取得する. 評価実験として, 料理, 食事, 読書, テレビ視聴, 食器洗い, 及びその他の行動を対象としてSVMを用いて識別モデルを構築したところ, 平均85.05%の適合率で行動を識別することができた.

A System for Daily Living Activities Recognition Based on Multiple Sensing Data in a Smart Home

KENKI UEDA¹ MORIHIKO TAMAI¹ KEIICHI YASUMOTO¹

1. はじめに

近年, スマートフォンをはじめとした様々なセンシングデバイスが普及している. これに伴い家庭内においても温度や湿度などの環境情報だけでなく, 個々のデバイスの使用状況や人間の生活行動を対象とした研究が盛んに行われている. 家庭での生活行動を自動認識することで, 省エネ家電制御 [1][2] や高齢者見守りシステム [3][4] などの生活支援・行動支援のアプリケーションへの応用が期待できる. これらのアプリケーションでは行動の種類や高い認識精度が重要であり, これまで様々なセンシング手法や機械学習等を用いた生活行動の推定手法が研究されている. 行動認識の手法の1つとしてカメラを用いた行動推定システム [5][6] があるが, カメラは「監視されている感」が強く, ユーザのプライバシーを侵害するという問題がある. また, 家庭内のあらゆる物に接触センサを付けることで高い

行動認識率が得られるが, 導入コストが高く, 普及性の面から現実的ではないといえる. また, 加速度センサなどのウェアラブルセンサを用いてユーザの行動を認識する研究も多数提案されている [7]. しかし, ユーザの姿勢や, 「歩く」「走る」などのユーザの動きに基づいた行動しか認識できず, 家庭内での多様な生活行動の認識は困難である.

本研究では, 家庭内における基本的な生活行動である, 「料理」「食事」「掃除」「洗濯」「風呂」「洗面」「食器洗い」「トイレ」「読書」「勉強」「着替え」「化粧」「会話」「電話」「テレビ視聴」「音楽鑑賞」「ゲーム」「PC」「外出」「帰宅」の20種類の行動を認識の対象とする. そして, 今後普及するであろう消費電力センサと位置情報のみを用いることで, 導入コストを抑え, プライバシーの侵害が少ない行動認識システムを開発する.

本システムでは, 取得したセンサデータに対して, 機械学習により構築した行動認識モデルを適用することで, 特定の時間区間のセンサデータに対し, 生活行動を対応付けることができる. 学習に必要な訓練データを取得するため

¹ 奈良先端科学技術大学院大学
Nara Institute of Science and Technology

に、生活行動ラベリングツールを開発した [8]。これは、ある期間のセンサデータの集合を、特定の生活行動に紐付けるためのラベルを貼付する機能を備える。また、グラウンドトゥールズとして撮影したビデオを同期して再生する機能を備えることで、ユーザのラベル付けを支援する。ラベル付けされた区間におけるセンサデータは、ラベルに応じた生活行動に紐付けられ、訓練データとして保存される。その後、これらの訓練データを 5 分間隔で区切り、各生活行動における平均値や分散などの特徴量を抽出する。特徴量は、行動を識別するために有効なデータであり、センサに応じた適切な統計量を抽出する。その後、これらの特徴量を用いて行動識別の学習モデルを構築する。本研究では、代表的なパターン認識の学習モデルの 1 つである、SVM (Support Vector Machines : サポートベクターマシン) を用いた。

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) にて、日常的に生活した際の生活行動の認識率を測定した。今回の実験で対象とする生活行動は、料理、食事、読書、テレビ視聴、食器洗い、及びその他の行動の 6 つとした。結果、消費電力センサと位置情報センサの両方を用いた学習モデルでは、平均 85.05% の適合率となった。

以降 2 章では関連研究について紹介し、3 章でシステム要件、4 章で提案システムの詳細について述べる。5 章では評価実験について述べ、最後に 6 章でまとめと今後の課題を述べる。

2. 関連研究

屋内における行動認識に関してこれまでに様々な研究が行われている。人の行動を認識する研究は、ビデオカメラなどを用いて画像処理により認識する手法と、接触センサや圧力センサなど、多数のセンサを用いて認識する手法に大別できる。以降では、それぞれの手法を用いた屋内における行動認識に関する既存研究について述べる。また、収集したセンサデータを可視化し、生活行動と紐付けるための、ラベリングツールに関する研究についても述べる。

2.1 屋内における行動認識に関する研究

屋内における人の行動を認識する研究はこれまでに多数提案されている。Brdiczka ら [9] は、カメラを使用した画像処理により、スマートホームにおける生活行動認識手法を提案している。この研究では、3D ビデオトラッキングセンサとアンビエントサウンドセンサを用いることで、歩く、座るといった単純な行動に加え、仕事や昼寝といった個人の行動、さらには会話、ゲームといった複数人による行動を 70~90% の正解率で認識することができる。しかし、特殊かつ高価なカメラやマイクが必要であり、居住者のプライバシーを侵害する恐れがある。また、認識できる

行動の種類が少なく、認識の正確さも十分とは言えない。

Kasteren ら [10] は、ドアセンサ、引出センサ、圧力マット、浮力センサ、温度センサなど多数のセンサが埋め込まれたスマートホームにおいて、食事、テレビ観賞、外出、トイレ、シャワー、洗濯、着替えなどの多様な日常生活行動を認識するシステムを構築した。認識の正確さは 49~98% となっている。この研究は、認識できる行動の種類は多いが、多くのセンサが必要で導入コストが高い上に、行動の種類によっては認識の正確さが低いという問題点を持つ。

Chen ら [11] は、近接センサ、モーションセンサ、チルトセンサ、圧力センサなどが多数埋め込まれたスマートホームにおいて、お茶 (コーヒー) を入れる、パスタをつくる、テレビを見る、入浴する、手を洗うといった複雑な生活行動を 90% 以上の正確さで認識するシステムを構築した。これは、知識ベースのオントロジーにより生活行動を識別しているため、機械学習を用いた手法のように、事前に大量の訓練データを必要としないという利点がある。しかし、多様な多数のセンサを使っており、導入コストが高いという問題がある。

ウェアラブル加速度センサを用いた行動認識手法では、歩く、座る、走る、寝るといった単純な行動の認識については 90% 以上の正確さが既に達成されている [12]。一方で、ウェアラブル加速度センサによる複雑・抽象的な生活行動の認識についてはあまり提案されていない。Bao ら [13] は、人に装着した 5 つのウェアラブル加速度センサを用いて、テレビ観賞、掃除、仕事などの 20 種類の行動を認識することに成功している。しかし、5 つのセンサを装着する必要があるため、ユーザの負担が大きい。Maekawa ら [14] 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、テレビ観賞、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、電化製品の操作に関連した行動に限られ、認識精度も 75 % 程度に留まっている。

上記で述べた既存研究の問題点を踏まえ、本研究では今後普及するであろう消費電力センサと位置情報のみを用いることで、導入コストを抑え、プライバシーの侵害が少ない行動認識システムの開発を目的とする。さらに、多様な種類かつ、抽象的な行動も認識対象に含め、家庭内における基本的な生活行動を網羅した、精度の高い認識システムを目指す。

2.2 ラベル付けによるセンサデータの可視化に関する研究

行動認識を行う際に、収集した多様なセンサデータを解析しやすい形で見える化するシステムが必要となる。センサデータの可視化を目的とした研究は数多く行われており、その中で、特に家庭内やオフィスにおける省エネ意識の向上を目指した様々な可視化システムが提案されている。Costanza ら [15] は消費電力データに対し、使用した家電

のラベルを貼付し、生活行動と関連性を持たせることでエネルギーの用途を可視化するシステムを提案した。12人の参加者の家庭に電力メータを設置し、参加者が2週間システムを使用した結果、多くのユーザがエネルギー消費に関する新たな発見を報告した。その内容によると、単に使用電力量を可視化するだけでなく、ユーザ自らがラベル付けを行うというインタラクティブな操作が伴うことで、自身の生活行動に対する理解が深まることが示されている。しかし、対象としているセンサデータは消費電力のみであるため、多様なセンサデータ間の関連性を分析し、新たな知見を得ることは困難である。ラベル付けに関しても、手動で行うためユーザへの負担が大きい。

著者らは、スマートホームを用いて収集した多様なセンサデータの可視化および生活行動ラベリングツールを開発した [8]。本ツールは、蓄積されたセンサデータの中から指定した期間のデータを取り出し、各種センサデータをそれぞれに適した表示方法により同時に可視化する。また、グラウンドトゥールズとして撮影したビデオを同期して再生する機能を備え、発見した生活行動に対し、対応する時間区間のセンサデータに当該行動のラベル付けを行うことができる。本システムでは、このツールをもとに、収集したセンサデータに対してラベル付けを行い、機械学習における訓練データとして使用する。

3. システム要件と基本方針

本システムの実現には、以下の3つの要件を満たす必要がある。

- (1) 多種類かつ抽象的な生活行動を認識できる。
- (2) 低コスト、少数のセンサで実現できる。
- (3) 居住者のプライバシーを侵害しない。

これらの要件を満たすための基本方針として、(1)の要件については、家庭内における基本的な生活行動を網羅するために、「料理をする」「食事をする」などの20種類の生活行動を対象とする。また、(2)、(3)の要件については、消費電力センサと超音波位置センサのみを使用して実現する。以下に生活行動の定義およびセンサデータの収集について述べる。

3.1 生活行動の定義

本研究で対象とする生活行動について述べる。平成23年総務省統計局では、図1のように1日の主な行動を20種類に分類し、1次活動（睡眠、食事など生理的に必要な活動）、2次活動（仕事、家事など社会生活を営む上で義務的な性格の強い活動）、3次活動（1次活動、2次活動以外で各人が自由に使える時間における活動）と定義している。また、1日の行動を大分類6種類、中分類22種類、小分類90種類とする細かな分類法も定義している。本研究では、これらを参考に、家庭内における基本的な生活行動で

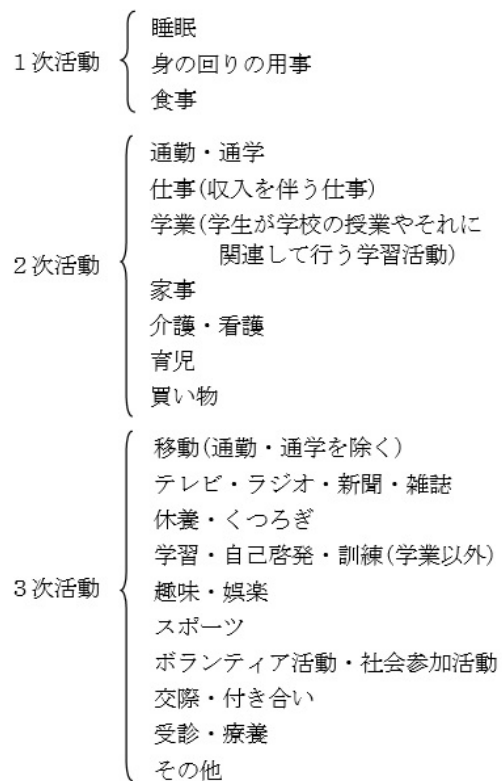


図1 生活行動区分の例

ある、「料理」、「食事」、「掃除」、「洗濯」、「風呂」、「洗面」、「食器洗い」、「トイレ」、「読書」、「勉強」、「着替え」、「化粧」、「会話」、「電話」、「テレビ視聴」、「音楽鑑賞」、「ゲーム」、「PC」、「外出」、「帰宅」の20種類の行動を認識の対象とする。

3.2 センサデータの収集

本研究で使用する個々のセンサについて、詳しく述べる。本研究では、図2に示すスマートホーム（奈良先端大内に設置されている1LDKの実験用住宅設備）において、被験者に生活してもらうことでデータを収集する。スマートホームには、各家電に取り付けられている消費電力センサ、環境センサ（温度、湿度、照度、人感センサを搭載、数か所に設置）、超音波位置センサ、ドアセンサ、水栓センサが設置されている。このうち、本研究で行動認識に使用するセンサは、超音波位置センサと消費電力センサである。両センサとも、計測したデータはZigBeeで送信され、サーバに自動蓄積される。以下にそれぞれのセンサについて述べる。

3.2.1 超音波センサ

超音波位置センサは、TAGと呼ばれる超音波送信機とそれを受信するRECEIVERという受信機に分かれている。受信機は図3のようにスマートホームの各部屋の天井に設置されており、被験者は図4の超音波センサ送信機を右腕に装着して位置情報をセンシングする。位置推定精度は、




図 2 実験で用いたスマートホームの間取り

れている消費電力を計測するセンサがある．本研究では、このCTセンサも使用した．




図 5 消費電力センサ

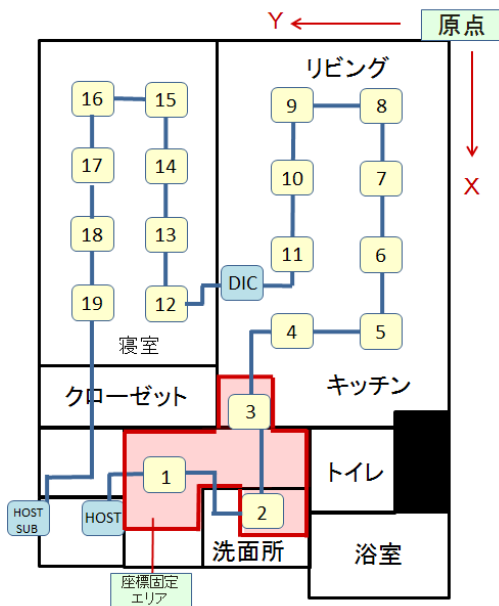


図 3 超音波センサの受信機設置図



図 4 超音波センサ送信機

公称値は誤差 50cm であるが、センサを静止させた状態での実測値は誤差 5cm 程度であることを確認している．サンプリング周期は、毎秒 2 回である．

3.2.2 消費電力センサ

図 5 に示す消費電力センサは、1 つの消費電力センサで 1 家電 (100V 用) がセンシングできる．サンプリング周期は、1 分間に 2 回である．データは、0 以上の実数 (小数点以下 2 桁) のワットで示される．また、スマートホーム内に CT センサという照明や給湯器といった設備に内蔵さ

4. 提案システム

生活行動の認識手法について述べる．本システムでは機械学習により生活行動を識別する．機械学習の適用過程は、(1) 学習に使用する訓練データの取得、(2) 取得した訓練データの特徴量の抽出、(3) 生活行動の学習モデルの構築、の 3 つのフェーズから構成される．以下にそれぞれのフェーズの詳細について述べる．

4.1 訓練データの取得

機械学習を行うにあたって、あらかじめセンサデータの集合がどの生活行動に対応するかを示した訓練データが必要である．著者らは、文献 [8] において、訓練データを容易に取得するための、生活行動ラベリングツールを開発した．図 6 に生活行動ラベリングツールの実行画面を示す．

本ツールは、スマートホームを用いて収集した多種類のセンサデータの可視化および生活行動のラベル付けを支援する．本ツールは蓄積されたセンサデータの中から、任意に指定した時間区間のデータを取り出し、各種センサデータ (各家電の消費電力、温度、湿度など) のグラフ表示に加え、スマートホームに備えられている超音波位置センサによる人の当該時間区間における移動軌跡等を表示することが可能である．

また、グラウンドトゥールズとして撮影したビデオを同期して再生する機能を備え、発見した生活行動に対し、対応する時間区間のセンサデータに当該行動のラベル付けを行うことができる．ラベル付けの手順は、(1) 関連するセンサを選択、(2) グラフ上をドラッグして時間範囲を選択、(3) 対応する生活行動のラベルを選択、の 3 ステップで行う．ラベル付けされた各区間におけるセンサデータは、ラベルに応じた生活行動に紐付けて保存され、訓練データとして使用される．

4.2 特徴量の抽出

特徴量とは、生活行動に対応するセンサデータの集合か

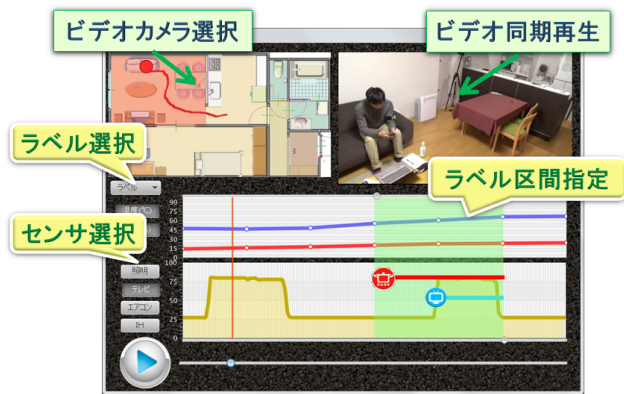


図 6 生活行動ラベリングツール

ら、それらの行動を識別するために有効なデータの特徴のことである。本システムでは、生活行動ラベリングツールによりラベル付けされた区間のセンサデータから特徴量を取得する。その手順は、まずそれぞれの生活行動に対するセンサデータを収集し、次にそれらを一定の時間間隔のデータに区切り、最後に必要な特徴量を抽出する。データを区切る間隔は、予備実験で様々な長さで試したところ、5分が最も行動認識精度が高かったため、本研究では5分間隔でデータを区切るものとした。抽出する特徴量は、消費電力データについては、家電の使用状況を識別するために平均値を使用し、位置情報については、超音波センサの誤差による外れ値の影響を少なくするために中央値を使用する。

4.3 行動学習モデルの構築

生活行動ラベリングツールによりラベル付けしたセンサデータ区間の特徴量を訓練データとする機械学習モデルを構築する。本研究では、代表的なパターン認識のアルゴリズムの1つである、SVM (Support Vector Machines: サポートベクターマシン) を用いた。SVMでは、データを2種類に分離するために、各データ点との距離(マージン)が最大となる分離平面を求める。マージンを最大化する分離平面を構築することで、高い汎化性能をもつ。線形に分類することが難しい場合は、カーネルトリックによって入力空間をより高次の特徴空間に写像し、その上で線形分離を行う。本システムでは、このSVMを用いて各生活行動における特徴量に対して識別学習モデルを構築する。

5. 評価実験

提案手法の性能評価を行うため、前述のスマートホームにおいて日常生活のデータ収集を実施した。以下に評価実験の概要と結果について述べる。

5.1 実験概要

今回の評価実験において識別対象とする行動は、「料理」、「食事」、「テレビ視聴」、「読書」、「食器洗い」、「その他」の

計6種類とした。2名の被験者(20代男性)に、それぞれ3日間ずつ住んでもらい、計6日間分のデータセットを収集した。被験者には超音波位置センサの送信機を1つ装着してもらい、通常の生活をしてもらう。

図2に各行動に使用される家電や家具の位置を示す。テレビは「TV」の位置に設置されており、「SF」のソファの位置から視聴する。料理は「IH」のIHヒーターを使用して調理を行い、食事は「TB」の位置にあるダイニングテーブルで行われ、食器洗いは「SK」の流し台で行われる。

データを収集した後、生活行動ラベリングツールを用いて、グラウンドトゥルースの映像を確認しながら、センサデータに対して各生活行動に応じたラベル付けを行う。ラベル付けは1つの生活行動につき150分とし、5分間隔で分割された30個の特徴量を抽出する。訓練データは、消費電力センサ(テレビ、IHクッキングヒーター)と、超音波位置センサの2つを使用し、抽出した特徴量に対してSVMを用いて学習モデルを作成する。学習モデルは、電力と位置情報を両方使用した場合と、電力のみの場合、位置情報のみの場合の計3パターンを用意してそれぞれ評価を行った。評価に使用したテストデータは、訓練データと同様の方法で各生活行動につき30個用意した。さらに、同様の実験を、位置情報の精度を落とした場合についても行う。図7のように部屋を1m及び2mのセルに区切って、各セルの中心を推定位置として精度を故意に悪化させることで、行動の識別結果にどの程度影響するかを評価する。以下に評価結果を示す。

5.2 評価結果

表1, 表2に電力と位置情報を両方用いた学習モデルによる認識結果を示す。表1の混同行列は、各行は実際の生活行動を示し、各列は識別モデルによって予測された生活行動を示す。表2は各生活行動におけるPrecision, Recall, F値を示す。Precision(適合率)は、その生活行動である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正しいデータの割合である。Recall(再現率)は該当する生活行動のうち、その生活行動であると正しく認識されたデータの割合である。F値は、PrecisionとRecallの調和平均であり、次式で表される。

$$F = \frac{2\text{Recall} \cdot \text{Precision}}{\text{Recall} + \text{Precision}}$$

表2に示す通り、電力と位置情報を用いた学習モデルを使用した場合、平均で85.05%の適合率が得られた。また、各生活行動の個別のF値を見ると、テレビの視聴が89.55%と最も高く、食器洗いが74.57%と他に比べて低い結果となった。これは、テレビ視聴に関しては、テレビの消費電力やリビングのソファの位置情報に大きな特徴があるため、高い認識率になったといえる。テレビの適合率が100%でないのは、読書の行動を誤ってTV視聴であると

表 1 位置情報と電力を両方用いた場合の混同行列

	料理	食事	食器洗い	テレビ	読書	その他
料理	24	0	6	0	0	0
食事	0	30	0	0	0	0
食器洗い	0	8	22	0	0	0
テレビ	0	0	0	30	0	0
読書	0	0	0	4	26	0
その他	0	7	1	3	4	15

表 2 位置情報と電力を両方用いた場合の評価結果

生活行動	Precision(%)	Recall(%)	F 値 (%)
料理	100.00	80.00	88.89
食事	66.67	100.00	80.00
食器洗い	75.86	73.33	74.57
テレビ	81.08	100.00	89.55
読書	86.67	86.67	86.67
その他	100.00	50.00	66.67
平均	85.05	81.67	81.06

識別しているためであり、これはリビングのソファでテレビの電源を入れたまま読書をしたという行動が、テレビを視聴しているものであると誤認識したことによる。一方、食器洗いに関しては、表 1 に示すように料理や食事と誤認識するケースが見られたため、低い精度となったことがわかる。これは、料理の行動は、下ごしらえなどの IH ヒーターを使用しない作業も含まれているため、判別が難しいことが原因として考えられる。

同様に、表 3、表 4 に位置情報のみを用いた学習モデルによる混同行列と評価結果を示す。全生活行動の平均の適合率は 70.75% となり、電力の特徴量を併用した場合よりも低くなった。各生活行動の個別の F 値は、料理と食事は比較的高い精度であるが、テレビ視聴と読書は、それぞれ、50.00%、35.30% と低い結果になった。これは、テレビ視聴と読書の行動は、どちらもリビングのソファで行われているため、位置情報のみでは判別が難しいことが理由であると言える。

表 5、表 6 は消費電力のみを用いた学習モデルによる混同行列および評価結果である。全生活行動の平均の適合率は 29.80% と 3 つの学習モデルのうち最も低い結果となった。料理とテレビ視聴の行動は消費電力のみでも比較的高い精度で認識可能であるが、電力の使用を伴わない読書や食事の行動は認識が困難であると言える。

5.3 位置精度を低くした際の評価

今回の実験環境では、超音波センサを用いた高精度位置推定システムを使っているが、高価であり、現状では一般家庭への普及は難しい。そこで、より低コストの位置推定

表 3 位置情報のみを用いた場合の混同行列

	料理	食事	食器洗い	テレビ	読書	その他
料理	28	0	2	0	0	0
食事	0	30	0	0	0	0
食器洗い	5	7	18	0	0	0
テレビ	0	0	0	19	11	0
読書	0	0	0	21	9	0
その他	0	6	1	6	1	16

表 4 位置情報のみを用いた場合の評価結果

生活行動	Precision(%)	Recall(%)	F 値 (%)
料理	84.85	93.33	88.89
食事	69.77	100.00	82.19
食器洗い	85.71	60.00	70.59
テレビ	41.30	63.33	50.00
読書	42.86	30.00	35.30
その他	100.00	53.33	69.56
平均	70.75	66.67	66.09

表 5 電力のみを用いた場合の混同行列

	料理	食事	食器洗い	テレビ	読書	その他
料理	21	0	0	0	9	0
食事	0	0	0	5	25	0
食器洗い	0	0	0	11	19	0
テレビ	0	0	0	30	0	0
読書	0	0	0	4	26	0
その他	0	0	0	6	24	0

表 6 電力のみを用いた場合の評価結果

生活行動	Precision(%)	Recall(%)	F 値 (%)
料理	100.00	70.00	82.35
食事	0	0	0
食器洗い	0	0	0
テレビ	53.57	100.00	69.77
読書	25.24	86.67	39.09
その他	0	0	0
平均	29.80	42.78	31.87

システムの利用を想定し、図 7 のように部屋を複数のセルに分割して、セルの中心座標を推定位置とすることで位置情報の精度を故意に低くした場合の認識精度の変化について評価する。1m 及び 2m 四方のセルに分割した場合の、それぞれの評価結果を表 7、表 8 に示す。1m 四方のセルに分割した場合の F 値の平均は 79.82%、2m 四方のセルに分割した場合の F 値の平均は 75.86% となり、セルの範囲を大きくする程、認識精度が低くなることがわかる。しかし、




図 7 セルによる位置情報の分割

表 7 位置情報を 1m のセルで区切った場合の評価結果

生活行動	Precision(%)	Recall(%)	F 値 (%)
料理	96.43	90.00	93.10
食事	75.68	93.33	83.58
食器洗い	73.08	63.33	67.86
テレビ	76.00	100.00	86.36
読書	83.87	86.67	85.25
その他	76.19	53.33	62.74
平均	80.21	81.11	79.82

低下の割合は少なく、2m の精度でも十分認識は可能であると言える。料理の行動に関して見ると、1m 四方のセルで分割した場合の F 値は 93.10%、2m 四方のセルの場合では 76.92% となった。これは、2m のセルの場合では、IH ヒーターと流し台の位置の区別がつかないことが原因として考えられる。したがって、料理の行動に関しては 1m 単位での位置の推定ができれば識別には十分であることがわかった。

本実験を通して、家庭内における生活行動の認識は、今回の実験で使用したような高価な高精度の位置推定システムは必ずしも必要ではなく、部屋の中でのおおまかな位置が検出できる低コストの位置推定システムと、消費電力センサを併用することである程度高精度に実現可能であることが確認できた。

6. おわりに

本稿では、スマートホームにおいて取得したセンサデータを用いて機械学習により居住者の生活行動を識別するシステムを提案した。提案システムでは、住人のプライバシーの確保や導入コストを抑えるために消費電力と位置情報のみを使用した。評価実験として、料理、食事、食器洗い、テレビ視聴、読書、及びその他の行動を対象として SVM を用いて識別モデルを構築したところ、85.05% の適

表 8 位置情報を 2m のセルで区切った場合の評価結果

生活行動	Precision(%)	Recall(%)	F 値 (%)
料理	90.90	66.67	76.92
食事	62.50	100.00	76.92
食器洗い	60.00	60.00	60.00
テレビ	81.08	100.00	89.55
読書	89.66	86.67	88.14
その他	100.00	46.67	63.64
平均	80.69	76.67	75.86

合率で行動を識別することができた。さらに、部屋を複数のセルに分割し、位置情報の精度を故意に低くして評価を行った。結果、1m のセル単位での位置情報が得られれば行動認識率は大幅に低下しないことが確認できた。

今後の予定としては、家庭内での基本的な生活行動を網羅するために、他の行動も識別対象に含めて精度を評価したい。その際に、類似した位置の行動などは識別が困難になると考えられるため、行動の時刻や、センサデータの分散など、特徴量を増やすことで対応する予定である。

参考文献

- [1] J. Scott, B. Brush, J. Krumm, B. Meyers.: "PreHeat: 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," 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] J. Kim, J.Soh, S.Kim, K.Chung.: "Emergency Situation Alarm System Motion Using Tracking of People like Elderly Live Alone." Information Science and Applications(ICISA), 2013 International Conference on. IEEE, 2013.
- [5] J. Hoey, J. James.: "Value-directed human behavior analysis from video using partially observable Markov decision processes," IEEE transactions on Pattern Analysis and Machine Intelligence, vol.29, no.7, pp.1118-1132, 2007.
- [6] L. Fiore, D. Fehr, R.Bodor, AA. Drenner, G. Somasundaram, N. Papanikolopoulos.: "Multi-Camera Human Activity Monitoring," Journal of Intelligent and Robotic Systems, vol.52, no.1, pp-5-43, 2008.
- [7] S.W Lee, K. Mase.: "Activity and location recognition using wearable sensors," IEEE Pervasive Computing, vol.1, no.3, pp.24-32, 2002.
- [8] 上田 健揮, 大木 浩武, 水本 旭洋, 玉井 森彦, 安本 慶一: "複数のセンシングデータの可視化および関連付けによる生活行動の理解支援システム," 第 21 回マルチメディア通信と分散処理ワークショップ (DPSWS2013) 論文集, pp.116-118, 2013.
- [9] O.Brdiczka, M.Langet, J. Maisonnasse, and J. Crowley.: "Detecting Human Behavior Models From Multimodal Observation in a Smart Home," IEEE Trans. on Automa-

tion Science and Engineering, vol.6, no.4, pp.588-597, 2009.

- [10] 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.
- [11] L. Chen, C. Nugent and H. Wang.: “A Knowledge-Driven Approach to Activity Recognition in Smart Homes,” IEEE Trans. on Knowledge and Data Engineering, vol.24, no.6, pp.961-974, 2012.
- [12] O.D. Lara.: “A Survey on Human Activity Recognition using Wearable Sensors,” IEEE Communications Surveys & Tutorials, vol.15, no.3, pp.1192-1209, 2013.
- [13] L. Bao, S.Intille.: “Activity recognition from user-annotated acceleration data,” Pervasive 2004, pp.1-17, 2004.
- [14] T. Maekawa, Y. Kishino, Y. Sakurai, and T. Suyama.: “Recognizing the Use of Portable Electrical Devices with Hand-Worn Magnetic Sensors,” Pervasive 2011, pp.276-293, 2011.
- [15] E. Costanza, S. Ramchurn, and N. Jennings.: “Understanding domestic energy consumption through interactive visualisation: a field study,” Proc. of the 2012 ACM Conference on Ubiquitous Computing , UbiComp '12, pp.216-225, 2012.