

変化時の行動記録と環境センシングに基づく 機械学習を用いた宅内行動認識

玉水 一柔[†] 榊原 誠司[†] 佐伯 幸郎[†] 中村 匡秀[†] 安田 清^{††}

[†] 神戸大学 〒 657-8501 神戸市灘区六甲台町 1-1

^{††} 千葉労災病院 〒 290-0003 市原市辰巳台東 2-16

E-mail: †{tamamizu,sakakibara}@ai.cs.kobe-u.ac.jp, ††sachio@carp.kobe-u.ac.jp, †††masa-n@cs.kobe-u.ac.jp,
††††fwkk5911@mb.infoweb.ne.jp

あらまし 高齢者の在宅介護を支援するテクノロジーとして、ICTを活用した見守りシステムの研究・開発が盛んである。しかしながら、従来システムには導入コストや侵襲性の問題、リアルタイムの行動認識の必要性、高齢者へのコミュニケーションの欠如といった課題がある。これらを解決すべく、我々は先行研究にて、宅内の環境変化をトリガとする声掛けによって、高齢者の日常生活行動を把握するシステムを提案している。本稿では特に、提案システムにおける、行動認識サービスの自動認識に焦点を当て、実装を行う。また、実際の家庭環境にて、センサデータと行動ログを収集し、機械学習を行うことで、行動の自動認識の分類精度に関して評価を行う。

キーワード 高齢者ケア, 在宅介護, 機械学習, 行動認識, 変化点検知

Machine Learning Approach to Recognizing Indoor Activities based on Environment Sensing and Activity Logs on Changing Points

Kazunari TAMAMIZU[†], Seiji SAKAKIBARA[†], Sachio SAIKI[†], Masahide NAKAMURA[†], and
Kiyoshi YASUDA^{††}

[†] Kobe University Rokko-dai-cho 1-1, Nada-ku, Kobe, Hyogo, 657-8501 Japan

^{††} Chiba Rosai Hospital Tatsumidai-higashi 2-16, Ichihara, Chiba, 290-0003 Japan

E-mail: †{tamamizu,sakakibara}@ai.cs.kobe-u.ac.jp, ††sachio@carp.kobe-u.ac.jp, †††masa-n@cs.kobe-u.ac.jp,
††††fwkk5911@mb.infoweb.ne.jp

Abstract The ICT-based elderly monitoring systems attract great attention as a promising technology for home elderly care. However, the conventional systems have limitations of deployment cost and invasiveness, effort of activity labeling, and a lack of communication. To cope with the limitations, we proposed the new system that captures activities of the elderly. Specifically, in this paper, we focus on Auto Recognition in Activity Recognition Service that composes the proposed system and implement Auto Recognition. Also, we collect sensor data and activity logs and execute machine learning to evaluate Auto Recognition accuracy.

Key words elderly care, home care, machine learning, activity recognition, change point detection

1. はじめに

現在、日本は超高齢化社会を迎えており、2025年には総人口がおよそ1億2114万人に減少する。一方、65歳以上の高齢者数はおよそ3657万人となり、総人口の約30.3%が65歳以上の高齢者となることが予想されている[1]。それに伴って、深刻な介護人材不足も進んでいる。介護分野の有効求人倍率は高く、2014年12月の調査では2.68倍であり[2]、また特別養護

老人ホームの入所申込者数(待機老人数)が52.4万人と発表されるなど、介護施設も不足している。こうした背景を受け、日本政府は介護施設を増やす取り組みよりも、在宅介護の推進・支援を進めている[3]。今後、高齢者介護の形態として家族介護が増加し、家族の介護負担が重くなることが考えられる。よって、在宅での高齢者介護の負担を和らげる技術やシステムが必要とされている。

高齢者の在宅介護を支援するテクノロジーとして、ICT を活用した見守りシステムが有望視されている。とりわけ近年では、行動認識技術によって高齢者の日常生活行動 (activities of daily living, ADL) を認識し、非常時に介護者へ通知するシステムが盛んに研究されている。行動認識技術とは、環境センサやウェアラブルデバイス、カメラなどから得られたデータを解析することで、見守り対象の人の状態や行動を推定・判断する技術である。見守りシステムの例として、離床センサを用いたシステム [4] や、ロボットを活用したシステム [5] が実際に商品化されている。行動認識技術としては、カメラ画像からシルエットを抽出・学習し、在不在や ADL を認識するもの [6] や、ウェアラブルデバイスやスマートフォンから得られる加速度データを学習して、ユーザの状態 (歩行中・作業中・安静中など) を認識するもの [7]、スマートホーム内に張り巡らされた環境センサを利用して ADL を判断するもの [8] などが提案されている。しかし、従来の見守りシステムには、導入コストと侵襲性の課題やリアルタイムの行動認識の必要性、高齢者へのコミュニケーションの欠如といった課題がある。

これらの課題を解決すべく、我々は先行研究にて、宅内の環境変化をトリガとする声掛けによって、高齢者の ADL を把握しケアを実行するシステムを提案している [9]。提案システムは、自律センサボックスを利用した環境センシング部分、環境センシング部分で得られた環境データを利用し、ユーザの行動を予測する行動認識サービス、予測された行動を基にヴァーチャルエージェント (VA) を利用し、声掛けを基本としたケアを行うケア実行サービスからなる。先行研究では特に、行動認識サービスの中でも、環境データを用いて変化点検知を行い行動を問いかける手動認識に焦点を当て、実装を行い、実データによる検証を行った。本稿では、行動認識サービス内の、機械学習を利用し、行動を予測する自動認識に焦点を当てている。

行動の自動認識に用いる分類モデルの作成に関して、はじめに、得られたデータの加工を行う。加工では主に、行動の表現の統一や、センサデータと行動ログの結合、ADL の認識に必要な過去のデータを説明変数に付け加えるといった特徴開発を行う。次に、機械学習を行い、行動の自動認識のための分類モデルを、その行動が起こる特有の環境ごとに作成する。作成の際、多クラス分類をするための、学習アルゴリズムを用いて行う。また、加工後のデータを訓練データとテストデータに分割し、訓練データで学習し、分類モデルを作成後、テストデータで作成された分類モデルの精度を評価する。

また本稿では、クラウド上で提供されている機械学習のサービスである、Microsoft Azure Machine Learning (Microsoft AML) を用いて、行動の自動認識のプロセスを実装した。さらに、実際の家庭環境にて、センサボックスを設置し、センサデータ・行動ログを収集し、行動の自動認識を行うことで、実環境における行動の自動認識の精度を評価・考察を行っている。

2. 準備

2.1 ICT を活用した高齢者見守りと行動認識

ICT を利用した在宅高齢者見守りの一般的なプロセスを図

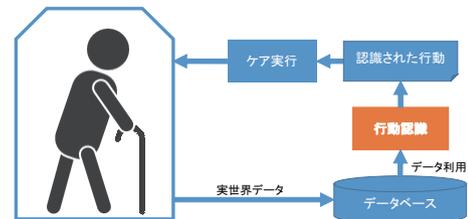


図1 ICT を利用した在宅高齢者見守りの一般的なプロセス

1 に示す。このプロセスでは、まず実世界データのセンシングを行い、高齢者およびその環境の状況を把握する。センシングするデータとしては、生体データ (脈拍、腕や脚や胴などの加速度など) や環境データ (気温、湿度、音量、照度など) が挙げられる。次に、行動認識において、センシングで得られたデータを利用し、高齢者の日常生活行動 (ADL) を認識する。そして、認識された行動に基づき、必要となるケアが選択され、声掛けを基本としたケアが実行される。高齢者の在宅介護における観測、ケア、記録の一部を ICT が引き受けることで、介護の労力を軽減し、人間にしかできないケアの質の向上を狙う。

近年、ICT を活用し、人間の ADL を推定する手法の研究・開発が盛んであり、図 1 の行動認識のプロセスへの応用が期待されている。これらの手法は、環境センサやウェアラブルセンサ、カメラなどで取得した多種多量のデータから、ユーザの姿勢や行動を自動的に推測・認識しようとするものである。一般的には機械学習が用いられ、教師あり学習や教師なし学習によって、与えられた生データに基づいて具体的な ADL のラベルを返す。教師あり学習では、環境センサやウェアラブルセンサ、カメラなどのデータに対して、実際に行われた ADL のラベルをあらかじめ付与し、教師データを作成する。そして、教師データの特徴量を抽出し、サポートベクターマシン (SVM) などの機械学習手法によって学習が行われる。教師なし学習では、取得したデータに対してクラスター分析を行い、各クラスターを ADL にマッピングする。これまでに様々な行動認識手法が提案されており、例えば、カメラ画像を利用するもの [6] やスマートフォンを利用するもの [7]、スマートホームの屋内測位と消費電力を用いるもの [8] などが提案されている。

2.2 見守りシステムの課題

従来の見守りシステムが抱える課題として、本研究では以下の課題 P1~P3 に着目している。

P1 : 導入コストと侵襲性 システムを一般家庭に導入する際に、家の工事や改築が必要になる場合がありコストがかかる。例えば、家をスマートホーム化するにはセンサの取り付け工事が必要となる。また、カメラやウェアラブルデバイスを利用したものは、高齢者の日常生活への侵襲性が高くなる。

P2 : リアルタイムの行動認識の必要性 行動認識では観測したデータを ADL に分類するために機械学習を用いる。学習のためには ADL のラベルがついた訓練データ (教師データ) が必要となる。従来手法では、数分毎に定期的に ADL を記録・入力する必要があり、高齢者や介護者にとって大きな負担となる。

P3 : 高齢者へのコミュニケーションの欠如 従来の見守りシ

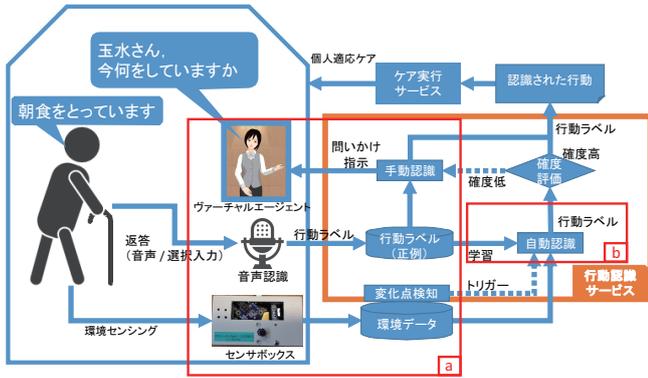


図 2 提案システムの全体アーキテクチャ

システムのほとんどは、何か起こった時に介護者に通知を出すだけである。本来重要である高齢者に対するコミュニケーションやケアを直接行うものは少なく、介護者の大幅な負担軽減には至っていない。

2.3 先行研究

見守りシステムの課題を解決するため、我々は、宅内の環境変化をトリガとする声掛けによって、高齢者の ADL を把握しケアを実行するシステム提案している [9]。

提案システムでは、先行研究で開発した自律センサボックス [10] を高齢者の自宅に設置し、環境センシングを行う。これによって、非侵襲かつ低コストなセンシングを実現し、課題 P1 の解決を目指す。次に、環境センシングで得られたデータをオンラインで解析し、変化点検知を行う。変化点検知は、時系列データの中から、データの性質が変わった点を特定するものである。これにより、環境の変化が見られた点を行動の変化があった点と捉え、そのタイミングでのみ ADL の記録を行うことで、課題 P2 で挙げたラベル付けの手間を軽減する。さらに、ADL の入力をヴァーチャルエージェント (VA) との声掛け・対話によって入力できるようにする。宅内に変化が起こった際、VA が高齢者に現在何をしているのかを問いかける (声掛けと呼ぶ)。VA からの声掛けに対し、高齢者は声で回答することで ADL が記録される。このやりとりによって、高齢者と VA とのコミュニケーション機会が創出され、課題 P3 の解決も可能となる。

図 2 に提案システムの全体アーキテクチャを示す。主に環境センシングを行う部分、行動認識サービス、ケア実行サービスによって構成されている。各部で行う概要を説明する。

環境センシング： 自律センサボックスを高齢者の自宅に設置し、環境センシングを行う。環境データとして、温度、湿度、照度、気圧、音量、振動、人感を取得し、日時情報とともにクラウド上のデータベースにアップロードする。

行動認識サービス： 逐次的にアップロードされる環境データに対し、オンラインで変化点検知を行う。変化点検知によって、環境に変化が生じたと判断された時、それをトリガーとして行動の自動認識を試みる。行動の自動認識では、予測した行動ラベルと、予測の確からしさを示す確度を計算し出力する。確度が高ければ、行動ラベルをケア実行サービスに渡す。確度が低

表 1 センサデータの形式

Key	Value	例
info.location	センサボックスの場所	居間
info.owner	センサボックスの所有者	tamamizu
info.boxid	センサボックスの ID	sbox-1234567
info.timeOfDay	データの収集時刻	08:12:00Z
info.date	データの収集年月日	2017-05-31
info.time	データの収集日時	2017-05-31T08:12:00Z
data.sound	音量センサの値	57.472817
data.motion	人感センサの値	true
data.temperature	気温センサの値	25.77802
data.humidity	湿度の値	57.7684
data.gasPressure	気圧の値	98.36391
data.vibration	振動センサの値	502
data.light	照度センサの値	63

い場合は、行動の手動認識を行う。行動の手動認識では、VA が高齢者に対し声掛けを行い、実際に何を行っていたのかを尋ねる。これに対して、高齢者は声または画面タッチなどで ADL を入力する。これにより行動ラベルを取得しケア実行サービスに渡す。同時に、得られた行動ラベルは認識の訓練データとして、以降の自動認識のための学習に利用される。

ケア実行サービス： 行動認識サービスから渡された行動ラベルをもとに、その行動に適したケアを選択し実行する。VA に指示を出してコミュニケーションによるケアを行ったり、非常時には介護者に連絡したりする。

先行研究では、図 2 の a に示す、環境データからの変化点検知、行動の手動認識に焦点を当て、変化点検知と VA による声掛けを実装し、実環境における利用について検討を行った。

3. 行動の自動認識

本章では、図 2 の b に示す、行動認識サービス内の自動認識に焦点を当て、機械学習を利用し、センサデータと行動ログを用いて、対象の行動を自動認識するための方法について述べる。

3.1 センサデータ・行動ログの収集

提案システムでは、自律センサボックスを用いて環境センシングが行われる。自律センサボックスは、観測したい行動が行われる各場所に 1 つずつ設置する。例えば、「朝ごはんを食べる」や「テレビを見る」など、居間で起こる行動を観測したい場合は、居間に 1 つのセンサボックスを設置する。収集されるセンサデータは表 1 に示す Key-Value 形式である。また、提案システムでは、環境の変化をトリガーとして、行動の手動認識プロセスが実行される。そのプロセスの中で、音声インタラクションにより、行動ログが記録される仕組みとなっている。収集される行動ログは表 2 に示す Key-Value 形式である。

3.2 データの加工

収集したセンサデータ・行動ログを用いて機械学習を行うため、データの加工を行う。まず、はじめに行動ログデータの整形を行う。行動ログの中には、同義語が含まれる場合があるため、同義語を同じ言葉に置き換える。例えば、「帰宅する」、「家

表 2 収集される行動ログの形式

Key	Value	例
id	データを一意に特定する文字列	1234567890abcd
userId	利用者を特定する ID	tamamizu
location	行動が記録された場所	居間
sensorId	対応するセンサボックスの ID	sbox-1234567
time	データの記録日時	2017-05-31T08:12:00Z
tag	記録された行動名	起床

表 3 加工されたデータ形式

カラム名	説明	例
location	データ収集された場所	居間
year	データが収集された年	2017
month	データが収集された月	5
day	データが収集された日	31
weekday	データが収集された曜日	4
hour	データが収集された時間	17
minute	データが収集された分	29
sound	音量データ	57.472817
motion	人感データ	true
temperatue	気温データ	25.77802
humidity	湿度データ	57.7684
pressure	気圧データ	98.36391
vibration	振動データ	502
light	照度データ	63
sound-1	1 個前の音量データ	50.159038
⋮	⋮	⋮
light-60	60 個前の照度データ	11
activity	この時間に行っていた行動	歯磨き
activity-1	1 つ前に行っていた行動	食事
activity-2	2 つ前に行っていた行動	起床

に帰る」を「帰宅する」という表現に統一する。次に、変化点検知時の行動ログのみを機械学習に用いるには、データ数が少なすぎるため、行動ごとに時間幅を設定し、変化点検知のタイミングから時間幅分、行動ログを複製する。また、行動ログの中には、稀にしか記録されない行動があり、機械学習を行う際にノイズとなってしまうものがあるため、各行動ログの出現頻度を計算し、出現回数が 10 未満の行動ログは使わずに捨てる。

次に、センサデータと行動ログを結合する。行動ログに含まれる userId と、センサデータに含まれる owner を用いて、対象となるセンサボックスのセンサデータを取り出す。取り出した各センサデータに対し、場所 (location) が同じで、日時 (time) が年月日時分まで一致する行動データの行動 (tag) を、行動ラベル (activity) として付ける。

最後に、機械学習の精度を上げるための説明変数の追加処理 (特徴開発) を行う。日時データから年、月、日、曜日、時、分を取り出しデータに加える。また、60 個前までのセンサデータと 2 つ前までの行動をデータとして追加する。結果として、加工されたデータは表 3 に示す形式となる。

3.3 行動の分類モデルの作成

3.2 で加工したデータを利用して、行動を認識するための分

類モデルを作成する。

まずはじめに、場所ごとに分類モデルを作成するため、加工したデータを場所 (location) によって分割する。次に、各場所ごとに分割したデータをさらに、訓練データとテストデータに分割する。訓練データとしては、日時の古いものから 7 割のデータを利用し、テストデータとしては残りの、日時の新しいものから 3 割のデータを利用する。学習の際には、決定木に基づくアンサンブル学習アルゴリズムを用い、行動 (activity) を、その他のカラム (year, month, day, weekday, ...) から、1 つのクラスに分類する。また、学習アルゴリズムに必要なハイパーパラメータに関しては、指定した範囲でランダムで変更しながら、一定回数繰り返して学習を行い、全データのうち正しく分類されたデータ数という観点で最適化を行う。

また、作成された分類モデルの評価に関しては、テストデータを入力として用い、実際の行動に対して、いくつかのデータがどの行動に分類されたかを、混同行列を用いて確認する。さらに、式 (1) に示す overall accuracy と、式 (2) に示す average accuracy を用いて、分類精度について確認を行う。

$$\text{overall accuracy} = \frac{\sum_i^M n_{i,i}}{\sum_i^M \sum_j^M n_{i,j}} \quad (1)$$

$$\text{average accuracy} = \frac{1}{M} \sum_i^M \frac{n_{i,i}}{\sum_j^M n_{i,j}} \quad (2)$$

ここで、 $n_{i,j}$ は、実際の行動 i が行動 j と予測された数を表す。また、 M は分類される行動の種類の数を表す。式 (1) は、全テストデータのうち、正しく予測できたデータの割合を表しており、式 (2) は、各行動において、テストデータを正しく予測できた割合を計算したのち、平均をとっている。ただし、average accuracy を計算する際、分類され得るがテストデータに無い行動があった場合、その精度は平均の計算に含めないものとする。例えば、分類モデルによって、「起床」に分類されることはあるが、テストデータの中に「起床」という行動がなかった場合は、実際の行動「起床」に関する分類精度は平均の計算には含めない。

4. 実装と実験

4.1 実装

本稿では、行動の自動認識の評価実験を、Microsoft Azure Machine Learning (Microsoft AML) を用いて行った。Microsoft AML は、クラウド上で提供されている機械学習のサービスであり、学習アルゴリズムやデータの分割、分類モデルの評価などを、モジュールの配置と入力と出力の接続によって行うことができる。行動認識の分類は、決定木に基づいたアンサンブル学習アルゴリズムである、Multi-class Decision Forest [11] を利用した。また、Microsoft AML で調整できる Multi-class Decision Forest のハイパーパラメータとしては、決定木の最大数、決定木の最大の深さ、決定木のノードを作るときに使われる特徴のランダムスプリットの数、決定木の各葉を作成するのに必要な最低サンプル数がある。調整に関して、決定木の最

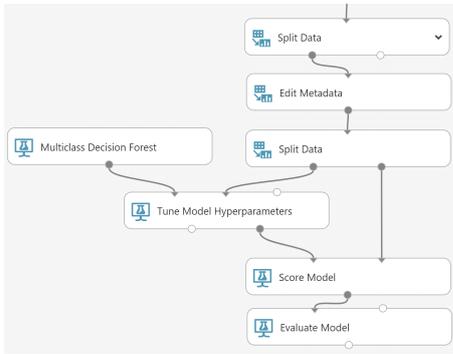


図3 Microsoft AML 上でのモジュール配置

大数は1から8の整数値から、決定木の最大の深さは1から32の整数値から、決定木のノードを作るときに使われる特徴のランダムスプリットの数に1と128と1024から、決定木の各葉を作成するのに必要な最低サンプル数は1,4からランダムで選択し、学習と精度評価を20回繰り返した結果、一番分類精度が良かったハイパーパラメータを用いることとした。実際にMicrosoft AMLで作成した様子を、図3に示す。図3の上部からは、3.2の方法で加工されたデータが入力されている。

4.2 実験と学習の結果

行動の自動認識の分類精度を評価するため、実際の家庭にセンサボックスを設置し、センサデータと行動ログを収集し、行動の自動認識を行った。センサボックスは、二人暮らしの家庭の、居間・洗面所・和室・玄関に設置した。行動の自動認識の対象としては、二人ではなく一人のみを対象とした。提案システムでは、変化点を検知すると、VAが行動を聞く仕組みだが、実施環境の都合から、メールによって変化点検知結果をユーザに通知し、行動をメモしてもらうことで、行動ログの収集を行った。行動ログの収集は37日間行い、615個の行動ログを収集した。実際に得られた行動の中には、同じ行動を示す表現が含まれていたため、統一の表現に置き換えた。さらに、入力漏れのあるデータを取り除き、3.2によってデータを加工した結果として、居間では「スマホ」、「パソコン」、「起きる」、「皿洗い」、「新聞を読む」、「食事」が、洗面所では「トイレ」、「手洗い・うがい」、「足洗い」、「歯磨き」、「体重血圧を測る」、「入浴」が、和室では「パソコン」、「シャッターを開ける」、「スマホ」が、玄関では「外出」、「帰宅」、「寝る」という行動が得られた。各行動の時間幅としては、「体重血圧を測る」を10分、「食事」を5分、「入浴」を30分、その他の行動を1分と設定した。結果として、加工されたデータの個数は、居間では1123個、洗面所では5270個、和室では409個、玄関では1112個であった。

得られた行動ログと、センサデータを用いて、3.3の方法で学習し評価した結果、図4に示す結果が得られた。図4において、左のラベルが実際に行われた行動を示し、上のラベルが学習済みの分類モデルによって予想された行動を示している。また、セル内の数値は、左ラベルの実際に行われた行動のうち、上のラベルの予想された行動である割合を示しており、何も書かれていないセルは0.0%であることを示している。また、分類精度に関して、overall accuracy と average accuracy を計算

表4 場所ごとに作られた分類モデルの分類精度

場所	overall accuracy	average accuracy
和室	93.50%	93.66%
玄関	85.33%	89.88%
洗面所	58.57%	44.71%
居間	86.94%	61.00%

したところ、表4に示す結果が得られた。

4.3 考察

表4に示すように、和室と玄関に関して、overall accuracy と average accuracy が高いことから、この二つの場所の行動の分類精度は高いと考えられる。しかし、居間に関しては、overall accuracy は高いが average accuracy が低いため、和室、玄関に比べ行動の分類精度が低いと考えられる。また、洗面所に関しては、overall accuracy と average accuracy の両方が低いため、和室、玄関、居間に比べ行動の分類精度が低いと考えられる。図4を見ると、和室、玄関は各行動の分類精度がすべてが70%を超え、誤分類が少ないことが分かる。一方で、居間は、「起きる」と「食事」の分類精度は99%以上と高く、テストデータ数が337個の中、「起きる」と「食事」のテストデータ数が合計で282個と多いため、overall accuracy が高くなったと考えられる。しかし、average accuracy に関しては、「スマホ」と「新聞を読む」の分類精度が低いため、低くなったと考えられる。洗面所に関しては、「歯磨き」の分類精度が0%であったり、50%から73%の低い分類精度の行動が多くあるため、overall accuracy と average accuracy がともに低くなったと考えられる。玄関や和室の行動の分類精度が高くなった理由として、分類される行動の種類が少なかったことや、時間帯・行動順に依存した行動が主だったことが考えられる。また、「シャッターを開ける」と「パソコン」のように、各行動が環境に与える影響に違いがあったことも理由と考えられる。実際に、学習によって生成された決定木を確認すると、玄関や和室の分類のための決定木のほぼ全てにおいて、1つ前の行動 (activity-1) や時間 (hour) による分岐が、決定木の根から3個目までに存在するような構造をしていた。また、和室に関して「シャッターを開ける」とその他の行動を分類する際に、センサデータを利用している決定木が多くみられ、行動が環境に与える影響の違いで、分類されていることが確かめられた。

一方で、居間や洗面所での分類精度が低かった理由として、分類される行動の種類が多かったことや、時間帯に依存しない行動、環境への影響に違いが少ないような行動が多かったためと考えられる。洗面所においては、「トイレ」と誤分類されることが多く見られた。この原因としては、トイレが、センサボックスを設置している部屋の隣だったため、行動が環境センサに影響をあまり及ぼさず、洗面所で何も行われていない状況を「トイレ」と誤分類していることや、行動ログにはなかったが、実際は「トイレ」のあとには「手洗い」などをすることが多いため、このような一連の動作の中でほかの行動と区別しづらいものがあるためと考えられる。「体重血圧を測る」に関しては、時間幅を10分から1分にしたところ分類精度が下がったこと

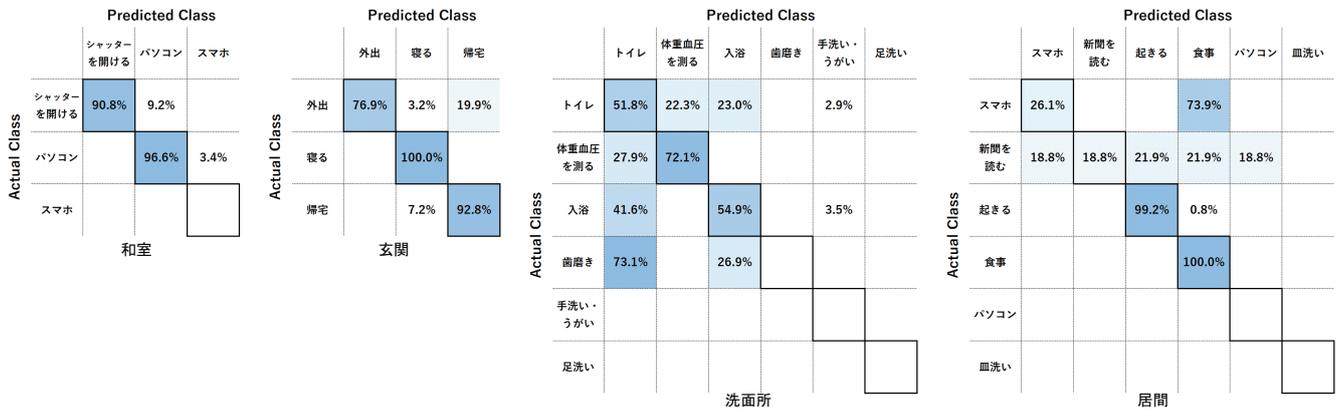


図 4 学習と分類モデル評価の結果

から、行動ログを入力した時間と実際に行動を行った時間にずれがあったことも考えられる。

また、図 4 から、居間では「スマホ」と「新聞を読む」の分類がうまくできていないことが分かる。「スマホ」を「食事」と誤分類することや、「新聞を読む」が分類できないことに関して、生成された決定木を確認すると、深さ 10 以上で分類されている場合が多くみられ、分 (minute) や日 (day) によって分岐しているノードも多くみられた。これは、「スマホ」や「新聞を読む」という行動が、環境に与える影響が少なかったため、機械学習でうまく分岐を作ることができず、訓練データにのみうまくいくように対応した結果、過学習になったことが考えられる。

これらの問題を解決するためには、センサボックスの設置場所を増やし、より細かく環境データをとることで、行動を分類しやすくすることや、行動をより抽象的な表現である大分類から、中分類、具体的な表現である小分類で表現し、大分類を当てたのちに中分類、小分類を当てるようにすること、変化点検知の精度を上げ、より正確に、行動が変わったタイミングで記録を行うようにすることなどが考えられる。

5. おわりに

本稿では、すでに提案しているシステムにおける、行動の自動認識の実装を行った。まず、行動の自動認識において、設置したセンサボックスから得られた環境データと、設置した場所に関連する行動のログを用い、機械学習を行うことで、行動を分類するためのモデルを作成する方法を示した。また、Microsoft AML を利用して、機械学習を行うプロセスを実装し、実際の家庭に設置したセンサボックスと、実際に記録した行動ログを用いて、行動の自動認識の精度を評価した。

今後の課題として、変化点検知の精度をあげることにより、行動ログの収集をより正確に行うことや、行動を大分類・中分類・小分類で表現することで、行動認識の精度を上げることが考えられる。また、より多くの人に、提案しているシステムを利用してもらい、本稿で行った行動認識を含め、システム全体として汎用性・実用性があるかどうかを評価することなどが考えられる。

謝辞 この研究の一部は、科学技術研究費（基盤研究

B 16H02908, 15H02701, 基盤研究 A 17H00731, 萌芽研究 15K12020), および、立石科学技術振興財団の研究助成を受けて行われている。

文 献

- [1] 内閣府, “平成 27 年度版高齢社会白書,” <http://www.cao.go.jp/>, June 2015.
- [2] 厚生労働省, “介護人材の確保について,” <http://www.mhlw.go.jp/>, Feb. 2015.
- [3] 大和総研, “超高齢社会における介護問題,” http://www.dir.co.jp/research/report/japan/mlothers/20140509_008508.pdf, May 2014.
- [4] 株式会社ディプス, “離床センサー,” <http://www.deps1972.com/category/1193634.html>, Dec. 2016.
- [5] 株式会社テクノスジャパン, “在宅ケア 見守り介護ロボット「ケアロボ」,” <http://www.technosjapan.jp/product/tascal/index.html>, Aug. 2015.
- [6] 関弘和, 堀洋一, “高齢者モニタリングのためのカメラ画像を用いた異常動作検出,” 電気学会論文誌. D, 産業応用部門誌 = The transactions of the Institute of Electrical Engineers of Japan. D, A publication of Industry Applications Society, vol.122, no.2, pp.182–188, feb 2002. <http://ci.nii.ac.jp/naid/10007790942/>
- [7] 大内一成, 土井美和子, “加速度と音で日々の生活行動を認識する activityanalyzer,” 情報処理学会インタラクシオン, vol.3, pp.255–258, 2011.
- [8] K. Ueda, M. Tamai, and K. Yasumoto, “A method for recognizing living activities in homes using positioning sensor and power meters,” 2015 IEEE International Conference on Pervasive Computing and Communication Workshops (PerCom Workshops), pp.354–359, March 2015.
- [9] K. Tamamizu, S. Sakakibara, S. Saiki, M. Nakamura, and K. Yasuda, “Capturing activities of daily living for elderly at home based on environment change and speech dialog,” Digital Human Modeling 2017 (DHM 2017), no.LNCS 10287, pp.183–194, Springer International Publishing AG 2017, July 2017. Vancouver, Canada.
- [10] S. Sakakibara, S. Saiki, M. Nakamura, and S. Matsumoto, “Indoor environment sensing service in smart city using autonomous sensor box,” 15th IEEE/ACIS International Conference on Computer and Information Science (ICIS 2016), pp.885–890, June 2016. Okayama, Japan.
- [11] A. Criminisi, J. Shotton, and E. Konukoglu, “E.: Decision forests for classification, regression, density estimation, manifold learning and semi-supervised learning,” Sept.18 2013. "<http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.348.6067>;http://research.microsoft.com/pubs/155552/decisionForests_MSR_TR_2011_114.pdf"