

設置が容易な生活行動センシングシステムの構築と 一般家庭でのデータ収集・解析実験

松井 智一^{1,a)} 大西 晃正^{1,b)} 三崎 慎也^{1,c)} 藤本 まなと^{1,d)} 諏訪 博彦^{1,2,e)} 安本 慶一^{1,f)}

概要: 家電のスマート化や IoT 機器の高性能化を背景に、宅内サービスの高機能化が研究されている。特に、我が国では少子高齢化が進行していることから、生活行動推定技術を用いた宅内サービスによる居住者の QoL 向上や、高齢者の見守りが切望されている。一方で、生活行動推定は多種・多数のセンサを要するため、一般家庭への設置・運用が難しいという課題がある。本研究では、安価かつ設置・運用が容易なセンサからなる生活データ収集システムを構築した。構築したシステムを一般の高齢者家庭に設置し、2カ月間の生活データ収集を行った。収集したデータを元に、LSTM (Long short-term memory) を用いた深層学習モデルにより居住者の行動推定を行った結果、高い再現率で居住者の行動推定を行うことができ、実サービスへの応用可能性を確認した。

キーワード: 生活行動認識, IoT, 機械学習, LSTM, 簡易設置型センサシステム

Easy-To-Deploy Living Activity Sensing System and Data Collection and Analysis in General Households

Abstract: Emergence of smart appliances and high performance IoT devices is promoting studies on more functional and intelligent home services using these devices. In Japan, we are facing the problem of aging population and declining birthrate, hence it is urgent to develop technologies to improve resident's QoL and monitor the elderly through home services based on the activity recognition technology. However, an activity recognition system in general requires many types/number of sensors and hence it is difficult to deploy and operate it in general households. In this paper, we propose a system consisting of low-cost and easy-to-deploy sensors that collects data of resident's activities of daily living (ADL). The system was deployed in actual homes of senior citizens and collected ADL data for two months. We also estimated the ADLs from the collected data by Long short-term memory (LSTM), a deep learning model. As a result, ADLs could be estimated at high recall rate and hence we found that the proposed system has high applicability to actual services.

Keywords: daily activity recognition, IoT, machine learning, LSTM, simple installation sensing system

1. はじめに

Society5.0 に向けて、サイバーフィジカルシステム (以

下、CPS) のあらゆる分野・場所への浸透が切望されている [1]。CPS は、IoT, ICT 技術により実空間上で得られたデータをサイバー空間上へ蓄積し、分析・知識化することで、より高品質なサービスの提供や産業の問題解決を図ることを目的としている。そのためには、大学や研究所などの実験環境ではなく、一般の実環境での動作を前提としたデータ収集システムが必要不可欠である。一方で、我が国では少子高齢化の進行が深刻である。都市郊外の団地や「ニュータウン」と呼ばれる住宅地では、平均の高齢化率 (65 歳以上の人口比率, 全国平均は 27.3%, 平成 29 年度高齢社会白書 [2]) をはるかに上回るペースで高齢化が進ん

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

² 理化学研究所
Riken

a) matsui.tomokazu.mo4@is.naist.jp

b) onishi.kosei.of5@is.naist.jp

c) misaki.shinya.mq9@is.naist.jp

d) manato@is.naist.jp

e) h-suwa@is.naist.jp

f) yasumoto@is.naist.jp

ている。我々の所属研究機関（奈良県生駒市）に隣接する住宅地「鹿ノ台」においても、全人口の内、65歳以上が39%、後期高齢者である75歳以上が15%を占めており、高齢者を対象とした（1）見守り・介護、（2）健康寿命延伸行動の奨励に対する効果的な対策を施すことが喫緊の課題となっている。以上の課題に対して、行動認識技術を利用して居住者の生活習慣の改善を提案する研究や、高齢者向け見守りサービスを提供する研究が行われている。しかしながら、提案されている同様のCPSの多くは、実験環境での提案にとどまっており、実環境でのデータ収集・分析システム構築には至っていない。

本研究は、地域社会での重要な課題である、上記の課題（1）-（2）を対象に、一般家庭に容易に導入でき、多数の家庭から効率良く生活データを収集・分析することが可能なCPS基盤システムを構築することを目的とする。具体的には、生活データ収集システムを、実際の高齢者宅に設置し長期にわたってデータを収集するとともに、収集したデータから生活行動推定が可能かどうか、推定した生活パターンやセンサ値から、異常検知ならびに見守り、さらには、健康寿命の延伸に向けた行動変容に有用な知見が獲得できるかを調査する。

本目的達成のために、我々は、安価かつ設置・運用が容易なセンサからなる生活データ収集システムを構築した。構築したシステムを一般の高齢者家庭に設置し、2カ月間の生活データ収集を行った。収集したデータを元に、深層学習モデルの一つであるLSTM（Long short-term memory）を用いて居住者の行動推定を行った結果、高い再現率で居住者の行動推定を行うことができ、実サービスへの応用可能性が確認できた。

2. 関連研究

本章では、家庭でのセンシングシステムと生活行動認識・予測の既存研究について述べる。

センシングシステムに関する既存研究として、エッジコンピューティングなどを利用した効率的なセンシングシステムの提案 [3] や、異なる家庭間において取得したデータの転移に関する研究 [4]、声掛けを用いた高齢者向けの行動センシングシステムに関する提案 [5]、スマートハウスにおけるセキュアなワイヤレスセンシングネットワークの提案 [6] など、多面的な提案が行われている。さらに、ルールベースで得られる生活改善アドバイスを利用して、実際に居住者のQoLを向上させるためにフィードバックを行う研究 [7] や、ユーザからのフィードバックを行動認識モデルの学習に利用する手法の提案 [8][9] など、センシングにより得た結果や知見を居住者に還元する手法に関する議論も盛んである。しかしながら、これらのセンシングシステムは実験環境下での提案に留まっており、一般家庭でのセンシング、分析、フィードバックまでを一貫して行う、

体系的なセンシングシステムが望まれている。

生活行動認識・予測に関する既存研究として、Wanら [10] は、スマートハウスにおいて、独自に構築したワイヤレスセンサネットワークにて収集したデータを用いて分析を行っている。収集するデータは、それぞれ居住者を検知するための赤外線センサと椅子に設置した圧力センサ、環境を認識するための温度・照度センサとシンクに設置した水量センサ、テレビの利用情報、磁気ドアセンサ、煙検知センサ、居住者が身につけるウェアラブル加速度センサである。これらのデータを用いて、確率モデルであるベイジアンネットワークやHMM（Hidden markov network）を利用した行動認識手法を提案している。結果として、ベイジアンネットワークによる行動認識が91.2%の高精度で可能であることが示されている。一方で、これらのセンサは安価であるものの、ウェアラブルデバイスから取得したデータを利用していることから、居住者に対する侵襲性が高い。さらに、他の家庭へ学習モデルを適用した場合に認識精度が低下する可能性が示唆されており、家庭ごとの環境の差異が大きい実環境への適応は難しい。

佐々木ら [11] は、スマートハウス環境においてECHONET Lite 対応家電と人感センサ、超音波位置推定システムを使った行動認識手法を提案している。特定の家電のON、OFF状況や超音波位置センサシステムによる居住者の位置情報、人感センサやドアセンサ、環境センサなどによるセンサデータを学習に利用し、9種類の行動認識を行っている。また、それぞれランダムフォレストやロジスティック回帰、LSTMを用いたディープラーニングによるモデルごとの行動認識結果の比較を行っている。結果として、それぞれランダムフォレストで平均85.8%、ロジスティック回帰で平均84.9%、LSTMで平均81.5%の精度で各行動を認識していることから、高精度で居住者の行動認識が可能である。しかしながら、本手法を利用するには、家庭にECHONET Lite 対応家電や超音波位置センサシステムが導入されている必要があり、一般家庭への普及には課題がある。

Mohammadら [12] は、家電の利用状況から、PPM（Prediction by partial matching）をベースとしたSPEEDアルゴリズムにより、居住者の行動の流れであるエピソードを推定することで、コンテキストを考慮した居住者の次行動予測を行っている。データを取得する家電の種類はそれぞれ、部屋の照明、テレビ、シーリングファン、調理器、トースターである。さらに、予測する行動データとして、実験に際して入居した1名の居住者の行動を、午前セッション・午後セッションに分割し、ログを取得している。これにより、実験環境として利用した、単一の部屋などの特定の間取り状況においては予測精度向上が確認できた。また、家電の利用状況のみから行動の予測を行っていることから、各種センサを導入した場合に予測精度の向上が期

待できる．一方で，実環境で存在しうる，複数の部屋における予測精度向上には課題があり，実験参加者として入居した居住者の行動も，実環境と比較した場合に特殊である．さらに，利用状況が認識できる家電は一般に高価であることから，実環境への導入は難しい．

Niek[13] は，スマートハウスにおけるオープンデータセットである MIT データセット，CASAS データセット，Kasteren データセットを利用して，LSTM や GRU (Gated recurrent unit) などの時系列を考慮した深層学習モデルにより，居住者の行動予測を行っている．これらのオープンデータセットに格納されているセンサ情報は，センサのバッテリー情報，赤外線センサ，磁気ドアセンサ，照度センサ，温度センサなどの安価なセンサであることから，実環境への導入は比較的容易である．結果として，次行動種類の予測精度が 26.9% から 52.9%，次行動生起までの予測時間の平均絶対誤差が 1210.32 sec から 3757.70 sec を達成している．行動予測モデルの性能は比較的高いものの，次行動の種類と時間を個別に学習しており，特定の行動が一定時間後に生起する確率しか判定しないことや，間取りが異なる一般家庭での実験は考慮していないことから，実環境でのサービス提供には課題がある．

その他，複数居住者に対する行動認識を行うために，CC (Classifier chain) を用いて多ラベル分類を行う手法 [14] や，それぞれ RNN (Recurrent neural network) ・ HMM ・ CRF (Conditional random field) を用いた学習モデルを，CASAS, ARAS オープンデータセットへ適用した結果を比較する研究 [15] が行われているが，いずれもスマート化されている家庭のデータセットを利用している．

以上に示すように，既存研究における行動認識，行動予測手法は，実験環境で収集したデータを対象に分析を行い，性能を評価している．しかしながら，一般家庭に実サービスとしてシステムを提供するためには，スマート化されていない家庭への対応や，間取りの違う家庭における認識モデルの汎化を考慮する必要がある．さらに，一般家庭に導入する際は，導入・維持コストや，居住者のプライバシーを考慮したセンサの選定も必要となる．これらは，既存研究において十分に議論されていない．

以上を踏まえ，本研究では，一般家庭への導入が容易なセンサからなる生活行動収集システムの設計・開発と行動推定・予測の家庭間での汎化に向けたデータ収集・分析を行い，有用な行動変容を促すシステムの構築を目指す．

3. 生活行動センシングシステム

本章では，本研究において設計・開発した一般家庭への設置が容易な生活行動センシングシステムとそれを用いたデータ収集について述べる．

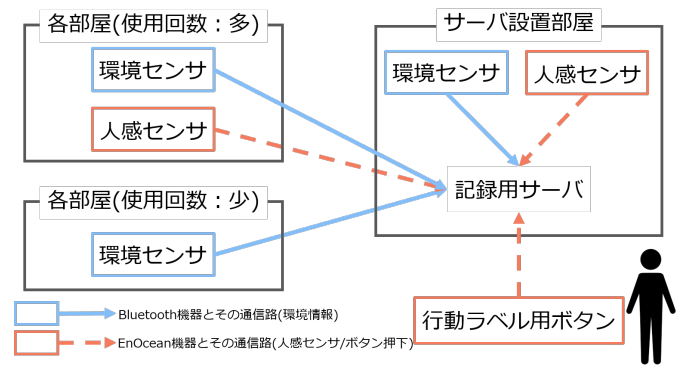


図 1 データ収集システムの全体構成



図 2 使用したセンサ

3.1 システムの構成と概要

本システムの構成を図1に，使用するセンサおよびボタンデバイスを図2に示す．本システムは，人感センサ，環境センサ，ドアセンサ，行動ラベルボタン，記録用サーバで構成される．各センサやボタンと記録用サーバとの通信は，消費電量を考慮し Bluetooth Low Energy (BLE) または EnOcean を用いている．

人感センサおよび環境センサは，導入する家庭の部屋ごとに，部屋の大きさや使用頻度，導線を考慮し設置する．また，対象とする生活行動の種類と同じ数の行動ラベルボタンを導入する．これらのセンサ・ボタンで収集されたデータはすべて家庭内に設置される小型サーバ上に保存される．サーバには小型の PC である Intel 社の NUC を利用しており，各センサとの通信に必要な EnOcean ドングル，Bluetooth ドングルを装備している．さらに，ピクセラ社の LTE 対応 USB ドングルである PIX-MT100 とデプロイ用ソフトウェアの ngrok を利用し，Web サーバを限定的かつセキュアに外部公開することで，遠隔で収集したデータの確認を行うことができる．

3.2 人感センサデータの収集

人感センサは各家庭の部屋ごとに 0 から 1 個，家全体で最大 10 個を設置し，データを収集する．この際，メンテ

ナンスフリーで長期間動作させるため、EnOcean 規格の太陽光パネルを備えた環境発電モジュールを利用し、環境発電のみで、センシング・無線通信までを実行可能な人感センサを新たに設計・開発している。それぞれ、環境発電モジュールとしてローム社の STM431J、人感センサとして Panasonic 社の EKMB1101112 を採用している。

なお、家全体で設置する人感センサの個数を一定個数に抑えるため、人感センサは被験者が頻繁に利用する部屋に設置し、利用頻度が低い部屋には設置しないこととする。

3.3 環境センサデータの収集

環境センサとしてオムロン社の 2JCIE-BL01 を採用し、部屋ごとに 1 個、家全体で最大 10 個を設置してデータ収集を行う。本センサは、それぞれ温度、相対湿度、照度、UV Index、気圧、騒音の計測が可能である。さらに、BLE による通信機能を備えており、取得したデータを無線でサーバに送信することができる。なお、本提案では、このうち温度、相対湿度、照度、気圧、騒音のデータを取得している。ただし、本センサは電池駆動であり、駆動期間はデータのサンプリング周期に依存する。そのため、2 ヶ月間のデータ収集を想定し、サンプリング周期を 3 分に設定している。

3.4 行動ラベルデータの収集

被験者の行動ラベルは、ローム社の押しボタン式データ送信モジュールである PTM 210J とアンケートにより取得する。本押しボタンは、2 つのスイッチと機械式発電モジュール、EnOcean による通信機能を備えており、スイッチを押下した際の力を利用して発電し、押下されたことを通知するパケットをサーバに送信する。本提案では、就寝・起床、料理、食事、入浴、外出・帰宅の 5 種類を対象行動としているため、5 個のボタンを利用する。対象行動を増やしたい場合は、ボタンの数を増やすことで対応可能である。設置位置は居住者が操作しやすい位置とし、対象となる行動の開始時と終了時にそれぞれ、開始スイッチ、終了スイッチを押下する。その後、パケットを受信したタイミングで、サーバ上に行動開始時と終了時のタイムスタンプを保存する。

アンケートのフォーマットは、行動の一覧と自由記述欄のあるチェックシート式である。居住者自身がボタンの押し忘れに気付いた場合にのみ、該当する行動を行った時間を思い出して自由記述欄に記入する。また、長期旅行や来客対応などの特殊な場面が発生した場合についても、その概要を自由記述欄に記入する。なお、得られたアンケート結果は CSV ファイル化し、押しボタンによるデータに追記している。

4. データ収集実験

本章では、実験要件と各世帯におけるセンサ設置について説明する。

4.1 実験要件

提案システムにより、一般の高齢者世帯における生活行動情報の収集・解析が可能であることを確かめるために、データ収集実験を行った。対象世帯は 60 歳以上の高齢者世帯（独居 3 世帯、2 人同居 7 世帯）であり、収集期間は各 2 ヶ月間とした。なお、1 日以上長期外出がある場合はその日数分実験期間を延長し、実際の居住日数の合計が 2 ヶ月分となるようにデータを収集している。

本実験は、奈良先端科学技術大学院大学倫理審査会の承認を受けて実施している（受付番号:2018-I-26）。被験者に、本実験の方法、目的、意義、同意の任意性および同意が撤回可能であること、プライバシーへの配慮などについて文書・口頭で説明し、同意書への署名により実験への参加同意を得ている。

被験者は、被験者世帯にセンシングシステムを設置した状態で、普段通り生活する。生活中に 5 つの対象行動（就寝・起床、料理、食事、入浴、外出・帰宅）を行った場合、それぞれの開始・終了時に行動ボタンを押す。2 人同居世帯は、各対象行動ボタンを共有して押すものとする。たとえば、二人同時に食事を開始する場合、食事ボタンの開始を 2 回押すこととなる。また、被験者は就寝前に、各対象行動の実施の有無と押し忘れを確認するために、前章で述べたアンケートに回答する。

4.2 センサ設置

表 1 に各世帯に設置したセンサの配置一覧を示す。本実験では、一般家庭 10 世帯を対象としており、間取りがそれぞれ異なるため、各世帯毎にセンサの設置方法を考慮する必要がある。以下に、センサ設置時に留意した点を説明する。

全てのセンサは、両面テープで壁・ドアに固定する。この際、住居の壁・ドアを保護するため、壁・ドアに住居用多用途マスキングテープを貼った上に、両面テープでセンサを固定する（図 3）。人感センサは、1 つのセンサで 1 つの部屋を網羅できるように部屋の中央で、カーテンなどの遮蔽物がない壁面に、床から 1 m 程度の高さになるよう設置する。環境センサは床から 1 m 程度の高さに望ましい空間がある場合はテープを利用して設置し、ない場合には人感センサと同様に位置に設置する。ドア開閉センサは、ドアの可動部と近くの壁面に設置し、ドアが閉じられている状態でセンサが反応するように設置する。なお、センサデータ回収用サーバは、通信時に障害物を回避するために、



図 3 センサ設置例

住居の中心に近い位置に設置した。各センサの設置完了後に、センサ情報が収集できているか確認を行い、確認が取れた状態で実験を開始する。この動作確認の際に、遮蔽物や設置状況によりデータの収集が困難であるセンサは、設置せずに回収する。とくに、ドアセンサはセンサデータの収集が困難であった。その一因として、ドアの金属部分がセンサ内部の測定部に影響していることが考えられる。

5. 分析手法

本章では、前章にて収集したデータの傾向を把握し、分析する手法について述べる。本稿では、一般家庭でのデータの傾向を把握することを念頭に置いている。したがって、解析するターゲット家庭として、全 10 件分のデータの中から、独居であり比較的データの欠損が少ないと思われる ID10 の家庭を選択した。そのため、以降で議論する結果は全て ID10 のデータから得られた結果である。

5.1 データの前処理

行動認識を行う際の問題として、アノテーションの不備がある。とくに、本研究の被験者は高齢者の方が多いことから、行動ラベル用ボタンの押し間違いや押し忘れによる真値ラベルの欠損が散見される。たとえば、朝に食事行動をスタートし終了ボタンを押し忘れてしまった場合、行動終了のフラグが送られず、昼に行く食事行動の終了ボタンが押されるまで食事行動ラベルが存在することとなる。したがって、一定時間以上ある行動が連続して行われていると認識した場合、その行動区間を押し間違い区間として見なし、行動していないこととした。表 2 に、各行動ごとの押し間違いと見なすための、しきいとなる時間を示す。このような行動ラベルの欠損は、全体の行動ラベルに対して、およそ 10% の割合で確認された。内訳として、継続時間が長く、1 日の区切りで必ず行われる周期的な行動である睡眠行動に関しては欠損が少なく、不定期で必ず行われるわけではない入浴行動に関しては欠損が多い傾向が見られた。食事、料理、外出行動の欠損に関しては、上述の 2 行動に対して中間程度の割合であった。

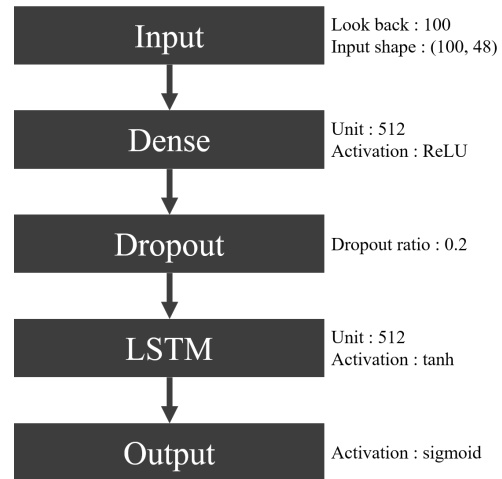


図 4 ニューラルネットワーク概要図

一方で、被験者が認識している押し間違い・押し忘れに関しては、被験者自身でアンケートを記入している。したがって、これらの認識できる欠損に関しては、データベースに格納されているデータを補完するように追記している。

その他設置したセンサについて、環境センサの欠損は存在しなかったものの、ドアセンサは非常に多くの欠損が見られた。欠損の原因については検証が必要であるが、前章で述べたドア金属部の影響に加えて、居住者がドアを開閉する際に、半端にドアを開閉することや素早く開閉することが一因として考えられる。したがって、長期運用においてもロバストな駆動方式のセンサ選定や、設置位置、取り付け時の工夫が必要である。

本提案では、サンプリング周期の異なる複数のセンサ情報を利用した解析を行うため、10 秒の時間窓を生成し、データのリサンプリングを行っている。その際、赤外線モーションセンサとドアセンサは、10 秒間に反応した回数分の総和によるリサンプリングを行い、環境センサは前値埋めによるアップサンプリングを行っている。なお、新たに生成した特徴量として、1 日の開始からの秒数を学習データに格納した。これにより、各種センサが反応した時間の情報を学習することができ、認識精度の向上が期待できる。

5.2 行動認識アルゴリズム

本提案では、行動認識を行うためのアルゴリズムとして、時系列データの考慮が可能な LSTM セルを持つニューラルネットワークモデルを利用する。図 4 に、利用した学習モデルの構成を示す。学習モデルは、Input 層、Dropout 層、LSTM 層、Dense 層、Output 層から構成されており、Dense 層、LSTM 層の隠れユニット数を 512、Dropout 層の Dropout 率を 0.2 としている。また、Dense 層の Activation 関数として、sigmoid 関数を利用している。さらに、それぞれ追憶データ数を 100、エポック数を 10、入力バッチサイズを 512 として学習を行っている。

表 1 センサ配置一覧

世帯 ID	キッチン	リビング	ダイニング	リビングダイニング	洗面所	廊下	寝室	トイレ	浴室	玄関	その他部屋
ID1	M ^{*i} , E ^{*ii}	M, E	M, E	-	M	M × 2, E	M, E	M × 2	E	-	M, E × 4
ID2	M, E	-	-	M, E	M, E	M × 2, E	M × 2, E × 2	M × 2	E	-	-
ID3	M, E	-	-	M, E	M, E	M × 2, E × 2	M, E	M	E	D ^{*iii}	M × 3, E × 3
ID4	M, E	-	-	M, E	M, E	M × 2, E	M × 2, E × 2	M	E, D	-	M, E × 2
ID5	M, E	-	-	M, E	M, E	M × 2, E × 3	M × 2, E × 2	M	E, D	D	M, E
ID6	M, E	-	-	M, E	M, E	M × 3, E × 3	M × 2, E × 2	M	E	-	M, E
ID7	M, E	-	-	M, E	M, E	M × 2, E × 2	M × 2, E × 2	M	E, D	D	M × 2, E × 2
ID8	M, E	-	M, E	-	E	M, E	M, E	M	E, D	D	M, E
ID9	M, E	-	-	M, E	M	M, E × 2	M, E	M × 2	E, D	D	M × 3, E × 4
ID10	M, E	-	-	M, E	-	M, E	M, E	M	E, D	-	M, E × 2

^{*i} 人感センサ ^{*ii} 環境センサ ^{*iii} ドアセンサ

表 2 各行動ごとのしきい値

Bathe	Cook	Eat	Leave	Sleep
4 hours	4 hours	4 hours	—	18 hours

なお、本分析で利用する行動ラベルデータは、行動している時間に対して行動していない時間の方が長時間であることから、不均衡性を持っている。したがって、不均衡性を考慮した学習モデルを構築するため、コスト関数の更新時にクラス数に応じた重みを利用する。具体的には、以下の式で得られる係数 W_i を利用する。ここで、それぞれ w_i : 各分類クラスの重み、 N : データ数、 C_n : 分類クラス数、 F_i : 各分類クラスの個数とする。

$$w_i = \frac{N}{C_n \times F_i} \quad (1)$$

$$W_i = \frac{1 + w_i}{2} \quad (2)$$

これにより、データに不均衡が生じた場合にも、オプティマイザは少数ラベルを尊重した最適化を行うため、不均衡性を考慮した学習器が構成できる。ここで、重みとして w_i ではなく、 W_i を利用するのは、少数ラベルに過剰に適合した学習を防止するためである。

5.3 評価手法

図 5 に、本提案における学習データの分割手法を示す。はじめに、時系列データを追憶データ数分だけ区切り、それぞれ分割する。次に、分割した範囲を徐々にスライドさせ、短期間で区切った時系列データを生成する。その後、区切られた時系列データの最初の 8 割をモデル学習用の訓練データ、次点の 1 割を訓練時に利用するバリデーションデータ、最後の 1 割を評価用のテストデータとした。ここで、行動認識モデルは各行動に関して、行われているか否かを判断する 2 値分類を行う。なお、モデル学習時において各エポックの終了時に、損失が増加に転じた時点で学習を打ち切っており、学習に際して利用される乱数シードは固定している。

6. 分析結果と考察

表 3, 表 4, 表 5, 表 6, 表 7 に、前章で述べた分析手法に則り算出した、入浴, 料理, 食事, 外出, 睡眠行動の適合




図 5 データの分割手法

率, 再現率, F 値をそれぞれ示す。この際、学習時にクラス数に応じた重みを利用しない場合と、重みとして w_i を利用した場合の結果も、それぞれ “_not_weighted”, “_w_i” として比較している。さらに、それぞれ、図 6, 図 7, 図 8, 図 9, 図 10 に、同様の各行動について非行動時を 0, 行動時を 1 とした混同行列を示す。各表より、重みとして W_i を利用した場合、入浴行動は適合率が 8 割程度と高く、料理行動・食事行動は適合率が低いものの再現率が高く、外出行動・睡眠行動は高い再現率を担保しつつ適合率も高いという結果が読み取れる。一方で、学習時の重みに関して、睡眠行動以外の行動において、学習時の重みを考慮しない場合には少数ラベルの行動が全く推定できていない。他方で、重みとして w_i を利用した場合には、少数ラベルを過剰に適合していることから、F 値が低下していることが読み取れる。以上のことから、提案する学習モデルは入浴行動以外の行動において再現率 6 割以上を達成しており、入浴行動においても再現率が 5 割後半で適合率が高いことから、家電の自動制御システムなどの実サービスへの応用可能性がある。

得られた課題として、本提案で収集したデータの行動ラベルの欠損が多いことや、行動ラベル間でのデータ数の不均衡が挙げられる。提案するセンシングシステムの行動ラベル用ボタンは、行動開始ボタンを押した後に、もう一度行動開始ボタンを押すことができることから、押し間違いに気がつきにくいという課題がある。また、ボタンの押し忘れについて分析した結果、入浴や外出, 睡眠行動など基本的に 1 日に 1 度だけ行う日課的な行動に関しては少なく、1 日に複数回行う料理や食事行動に関しては多い傾向が見られる。以上のことから、一般家庭における行動認識の精度向上のためには、学習モデルや前処理などの工夫と並列して、データ収集システムの UI 改善による、より高品質

表 3 入浴行動の分析結果

	Precision	Recall	F value
Negative	0.99	1.00	0.99
Positive	0.78	0.56	0.65
Negative_not_weighted	0.97	1.00	0.99
Positive_not_weighted	0.00	0.00	0.00
Negative_ w_i	1.00	0.83	0.91
Positive_ w_i	0.14	0.98	0.25

表 4 料理行動の分析結果

	Precision	Recall	F value
Negative	0.99	0.94	0.96
Positive	0.34	0.77	0.47
Negative_not_weighted	0.96	1.00	0.98
Positive_not_weighted	0.00	0.00	0.00
Negative_ w_i	1.00	0.51	0.67
Positive_ w_i	0.08	0.97	0.14

表 5 食事行動の分析結果

	Precision	Recall	F value
Negative	1.00	0.74	0.85
Positive	0.15	0.96	0.26
Negative_not_weighted	0.96	1.00	0.98
Positive_not_weighted	0.00	0.00	0.00
Negative_ w_i	1.00	0.51	0.67
Positive_ w_i	0.08	0.97	0.14

表 6 外出行動の分析結果

	Precision	Recall	F value
Negative	0.99	0.91	0.95
Positive	0.47	0.85	0.60
Negative_not_weighted	0.92	1.00	0.96
Positive_not_weighted	0.00	0.00	0.00
Negative_ w_i	0.98	0.78	0.87
Positive_ w_i	0.26	0.86	0.40

表 7 睡眠行動の分析結果

	Precision	Recall	F value
Negative	0.99	0.90	0.94
Positive	0.81	0.98	0.89
Negative_not_weighted	0.96	0.93	0.95
Positive_not_weighted	0.86	0.92	0.89
Negative_ w_i	0.97	0.91	0.94
Positive_ w_i	0.82	0.93	0.87

な家庭データの収集が不可欠である。

なお、今回実施した初期分析では、学習に利用したデータは時系列データであるため、訓練データ、バリデーションデータ、テストデータは互いの時間関係を保っている。これにより、交差検証を行っていないため、得られた結果に偏りが生じている可能性がある。したがって、今後行う本分析では、今回の短期間のデータで学習した結果と長期間のデータで学習した場合を比較し、推定精度の変化を考察する。




図 6 入浴行動の混同行列




図 7 料理行動の混同行列




図 8 食事行動の混同行列




図 9 外出行動の混同行列




図 10 睡眠行動の混同行列

7. おわりに

本稿では、一般家庭への普及を目的とした CPS 基盤シス

テムの提案を行い、実際に一般家庭において収集したデータを利用した初期分析結果を示した。結果として、構築したシステムにより居住者の行動データが収集できたこと、収集したデータから行動認識を行い、異常検知や見守りサービスへの応用可能性があることを確認した。とくに、睡眠や外出行動は認識精度が高いことから、夜間頻尿や睡眠時無呼吸症候群などの睡眠時の異常検知や、徘徊検知などの見守りシステム、行動変容時のアラートシステムなどへの応用が考えられる。一方で、課題として、センサの設置様式や押しボタンのインターフェースの改善による、センサデータの高品質化がある。高齢者向けのサービスを提供するためには、高齢者でも利用しやすいCPS基盤システムを構築する必要がある。

今後の展望として、センサデータの位置的な意味情報を推定し、識別モデルの学習時において、家庭間の間取り情報を考慮することのできるアルゴリズムの考案、適用がある。これにより、任意の位置へのセンサ設置や、異なる家庭間での学習データの共有、他家との行動比較が可能となり、さらなるサービスの高品質化が期待できる。

謝辞 本研究の一部は Society 5.0 実現化研究拠点支援事業の助成を受けて行った。

参考文献

- [1] 内閣府 : 科学技術基本計画. available from <https://www8.cao.go.jp/cstp/kihonkeikaku/5honbun.pdf> (accessed 2019-10-22).
- [2] 内閣府 : 高齢社会白書. available from https://www8.cao.go.jp/kourei/whitepaper/w-2017/zenbun/pdf/1s1s_01.pdf (accessed 2019-10-27).
- [3] Biljana L Risteska Stojkoska and Kire V Trivodaliev. A review of internet of things for smart home: Challenges and solutions. *Journal of Cleaner Production*, Vol. 140, pp. 1454–1464, 2017.
- [4] 井上創造, 潘新程, 花沢明俊ほか. 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. 研究報告ヒューマンコンピュータインタラクション (HCI), Vol. 2015, No. 10, pp. 1–8, 2015.
- [5] Kazunari Tamamizu, Seiji Sakakibara, Sachio Saiki, Masahide Nakamura, and Kiyoshi Yasuda. Capturing activities of daily living for elderly at home based on environment change and speech dialog. In *International Conference on Digital Human Modeling and Applications in Health, Safety, Ergonomics and Risk Management*, pp. 183–194. Springer, 2017.
- [6] Sandeep Pirbhulal, Heye Zhang, Md E Alahi, Hemant Ghayvat, Subhas Mukhopadhyay, Yuan-Ting Zhang, and Wanqing Wu. A novel secure iot-based smart home automation system using a wireless sensor network. *Sensors*, Vol. 17, No. 1, p. 69, 2017.
- [7] 中村笙子, 志垣沙衣子, 廣森聡仁, 山口弘純, 東野輝夫ほか. 大衆の生活ノウハウの定量化とモデル化によるスマートライフ支援システム. 情報処理学会論文誌, Vol. 56, No. 8, pp. 1621–1633, 2015.
- [8] Abir Karami, Anthony Fleury, Jacques Boonaert, and Stéphane Lecoche. User in the loop: Adaptive smart homes exploiting user feedback—state of the art and future directions. *Information*, Vol. 7, No. 2, p. 35, 2016.
- [9] Alexis Brenon, François Portet, and Michel Vacher. Arcades: A deep model for adaptive decision making in voice controlled smart-home. *Pervasive and Mobile Computing*, Vol. 49, pp. 92–110, 2018.
- [10] Jie Wan, Michael J O’grady, and Gregory M O’hare. Dynamic sensor event segmentation for real-time activity recognition in a smart home context. *Personal and Ubiquitous Computing*, Vol. 19, No. 2, pp. 287–301, 2015.
- [11] 佐々木渉, 藤原聖司, 諏訪博彦, 藤本まなど, 荒川豊, 木村亜紀, 三木智子, 安本慶一ほか. Echonet lite 対応家電と人感センサの時系列データ分析による宅内行動認識. *SIG-SAI*, Vol. 31, No. 5, pp. 1–8, 2018.
- [12] Mohammad Marufuzzaman, Mamun Bin Ibne Reaz, Labonah Farzana Rahman, and Araf Farayez. A location based sequence prediction algorithm for determining next activity in smart home. *Journal of Engineering Science & Technology Review*, Vol. 10, No. 2, 2017.
- [13] Niek Tax. Human activity prediction in smart home environments with lstm neural networks. In *2018 14th International Conference on Intelligent Environments (IE)*, pp. 40–47. IEEE, 2018.
- [14] Raihani Mohamed, Thinagaran Perumal, Md Sulaiman, Norwati Mustapha, MN Zainudin, et al. Multi label classification on multi resident in smart home using classifier chains. *Advanced Science Letters*, Vol. 24, No. 2, pp. 1316–1319, 2018.
- [15] Son N Tran, Qing Zhang, and Mohan Karunanithi. On multi-resident activity recognition in ambient smart-homes. *arXiv preprint arXiv:1806.06611*, 2018.