

博士論文

非接触センサを用いた日常生活センシングシステムと行動の共起性に基づく複数居住者の行動認識手法の研究

松井 智一

奈良先端科学技術大学院大学
先端科学技術研究科
情報理工学プログラム

主指導教員: 安本 慶一
ユビキタスコンピューティングシステム研究室 (情報科学領域)

2023年3月17日提出

本論文は奈良先端科学技術大学院大学先端科学技術研究科に
博士(工学)授与の要件として提出した博士論文である。

松井 智一

審査委員：

主査 安本 慶一 (情報科学領域 教授)
中村 哲 (情報科学領域 教授)
諏訪 博彦 (情報科学領域 准教授)
藤本 まなと (大阪公立大学 大学院情報学研究科 准教授)

非接触センサを用いた日常生活センシングシステムと行動の共起性に基づく複数居住者の行動認識手法の研究*

松井 智一

内容梗概

生活に紐づいたヘルスケアや行動推薦アプリケーションなどの高品質な生活サービスを提供するためには、日常生活行動（ADL: Activity of Daily Living）を理解することが重要である。特に、高齢化の進行する我が国では、高齢者の日常生活を継続的に認識することによって、効率的な予防医療を展開し健康増進行動を推薦できるようにすることが求められている。特に、プライバシー情報の収集やウェアラブルセンサの装着に抵抗がある高齢者をターゲットユーザとする場合には、カメラなどを利用しない非接触センサデータによる行動認識が求められる。しかしながら、従来提案されている日常生活のセンシングシステムおよびその行動認識手法は、高齢者の住む実際の一般家庭に対する受容性が低く、また、システム自体が高価であることや、設置が難しいこと、システムの利用にITの知識が必要なことなどの課題がある。したがって、1) 安価、2) 環境順応性が高い、3) 低プライバシー侵害、4) 低設置・維持コスト、5) 高ユーザビリティといった要件を満たすセンシングシステムが求められている（課題1）。また、様々な家庭を対象に、家庭ごとの活動量計や、電力量予測、外出支援・推薦サービスへの応用可能性を高めるためには、複数居住者を対象とした行動認識手法が必要である。一般的に提案されている複数居住者の行動認識手法では、映像データやウェアラブルセンサデータに基づいて個人を識別しているが、課題1の要件3)や5)を満たせない。一方、非接触センサのみを用いたセンシングでは、個人を識別するた

*奈良先端科学技術大学院大学 先端科学技術研究科 博士論文, 2023年3月17日。

めのデータが得られないため、行動者と行動種類の組を認識する手法が適用できないという課題がある（課題2）。

本論文では、上記の課題1，課題2を解決するためのセンシングシステムおよび複数居住者の行動認識手法を提案する。課題1に対しては、要件1), 3)を満たすため、カメラやマイクなどを利用せず、安価かつ少数のセンサのみを利用する。要件2)を満たすため、設置位置や間取り、セットアップに依存しない非接触センサのみでシステムを構成する。要件4)を満たすため、小型で取り外し容易な、環境発電で動作する省電力センサを採用する。要件5)を満たすため、ADLを記録するためのデバイスとして、シンプルな押しボタン式アノテーションボタンを採用し、高齢者に対しても容易なADLデータの収集を実現する。センシングシステムの実証実験として、10軒の一般家庭に対して、2ヶ月間のセンシング実験および行動認識を行った。その結果、提案システムは全家庭に対して平均一時間程度で設置でき、実験期間を通してメンテナンスフリーで動作することを確認した。また、LSTM（Long Short Term Memory）を用いた分析では、平均72%の再現率で行動認識ができることが分かった。

課題2に対しては、複数居住者家庭を対象に、新たな個人識別を伴わない家庭全体での行動認識手法を提案する。具体的には、対象行動のうち、どの複数の行動が並行して行われているのかを推論する推論タスク（協調行動認識タスク）を開発した。これにより、どの行動とどの行動が並行して行われているのかを認識することができ、一般的な行動種類のみ認識するタスクの結果よりも多くの情報を獲得できる。さらに、効率よく協調行動を認識するための機械学習による新たな認識フローを提案する。具体的には、センサ特徴量から各居住者の行動を独立して推論する第一モデルと、第一モデルから得られる両居住者の過去の行動を特徴量として各居住者の現在の行動を推論する第二モデルの2種類のモデルを構築し、協調行動認識タスクを実施する。これにより、各居住者が互いの行動に影響しあう、行動の共起性を考慮した協調行動認識が可能である。

提案手法の有用性を確かめるため、5軒の一般家庭に対して、1ヶ月間のADLセンシング実験を行った。第一モデル・第二モデルとしてそれぞれランダムフォレスト・ロジスティック回帰・DNN (Deep Neural Network) を利用し分析した結果、

DNNとランダムフォレストを用いた認識フローにおいて66%を超えるF値で協調行動を認識できた。また、複数居住者の行動の共起度合いを考慮した場合、各居住者の行動を独立に認識する場合と比べて、約5%高いF値で協調行動認識が可能となった。

キーワード

日常生活行動認識、複数居住者行動認識、機械学習、センシングシステム、非接触センサ、環境発電センサ

A Study on Daily Activity Sensing System with Non-contact Sensors and Multi-person Activity Recognition Method based on Activity Co-occurrence*

Tomokazu Matsui

Abstract

Understanding daily life activities is important to provide high-quality lifestyle services, such as healthcare and activity recommendation applications that are tied to daily life. Especially in Japan, where the population is aging, it is necessary to continuously recognize the daily activities of the elderly so that efficient healthcare can be provided and health-promoting activities can be recommended. In particular, when the target user is an elderly person who is resistant to the collection of privacy information or the wearing of wearable sensors, activity recognition based on non-contact sensor data without the use of cameras is required. However, the existing sensing systems for daily living and their activity recognition methods have low acceptability for actual households where elderly people live. In addition, the issues regarding daily activity sensing systems include the high cost of the system itself, the difficulty of installation, and the need to use information technology for the operation of the system. Therefore, it is required to develop a sensing system that satisfies the following requirements: 1) low cost, 2) high adaptability to the environment, 3) low privacy violation, 4) low installation and maintenance costs, and 5) high usability (Issue 1).

In order to increase the applicability of the system to various households for household-specific activity measurement, electricity forecasting, and outing support and recommendation services, an activity recognition method targeting multiple occupants is

*Doctoral Dissertation, Graduate School of Science and Technology, Nara Institute of Science and Technology, March 17, 2023.

needed. The generally proposed method of recognizing the activity of multiple occupants identifies individuals based on video data and wearable sensor data. However, they do not satisfy the requirements 3) and 5) of Issue 1. On the other hand, sensing using only non-contact sensors does not provide data to identify individuals, therefore, a method to recognize pairs of actors and types of activities cannot be applied (Issue 2).

In this thesis, we propose a sensing system and a method for recognizing the activities of multiple residents to solve the above issues. To address Issue 1, only a small number of inexpensive sensors are used instead of cameras and microphones to satisfy requirements 1) and 3). To satisfy requirement 2), the system is composed of only non-contact sensors that do not depend on the installation location, layout, or setup. To satisfy requirement 4), energy harvesting sensors that are small, easily removable, and operate by environmental power generation should be used. To satisfy requirement 5), a simple push-button annotation button is used as a device for recording ADLs, which enables easy collection of ADL data even for elderly people. As a validation experiment of the sensing system, a two-month sensing experiment and activity recognition were conducted in 10 general households. As a result, it was verified that the system worked maintenance-free throughout the experiment period. In addition, we confirmed that the system was able to recognize activities with an average recall rate of 72% using LSTM (Long Short Term Memory) analysis.

To address Issue 2, we develop a new method to recognize activities for multiple residents in the whole household without individual identification. Specifically, we define an estimation task (cooperative activity recognition task) that infers which of the target activities are being performed in parallel. This enables recognition of which activities are performing in parallel with which activities. Thus, it can acquire more information than the results of the general action-type-only recognition task. Furthermore, we propose a novel recognition flow based on machine learning for efficient recognition of cooperative-activity. Specifically, we construct two models to perform the cooperative-activity recognition task: the first model estimates the activities of each

resident independently from the sensor features, and the second model estimates the current activities of each resident using the past activities of both residents obtained from the first model as the features. This enables cooperative-activity recognition that takes into account the co-occurrence of activities in which each resident influences each other's activities.

To confirm the feasibility of the proposed method, we conducted a one-month ADL sensing experiment on five general households. The results of the analysis using Random Forest, Logistic Regression, and DNN (Deep Neural Network) as the first and second models, respectively, showed that cooperative-activity recognition was possible with an F value of over 66% in the recognition flow using DNN and Random Forest. The accuracy of cooperative-activity recognition was improved by approximately 5% when the co-occurrence of multiple residents' activities was taken into account, compared to the case where the activities were recognized independently for each resident.

Keywords:

activity of daily living, multi-resident activity recognition, machine learning, sensing system, non-contact sensor, energy harvesting sensor

目次

1. 序論	1
2. 関連研究	6
2.1 ADL センシングシステムの要件	6
2.2 住環境における ADL センシング	7
2.3 複数居住者家庭に対する ADL センシング	10
2.4 非接触センサによる複数居住者家庭の ADL センシング	11
2.5 本研究の位置づけ	12
3. 一般家庭での利用に適した ADL センシングシステム	14
3.1 システム要件	14
3.2 システム構成	15
3.2.1 人感センサ	15
3.2.2 環境センサ	16
3.2.3 ドアセンサ	16
3.2.4 アノテーションボタン	16
3.2.5 データサーバ	17
3.3 分析手法	17
3.3.1 欠損値の補完	17
3.3.2 行動認識アルゴリズム	19
3.3.3 評価手法	20
3.4 一般家庭を対象としたデータ収集と評価	21
3.4.1 実験目的	21
3.4.2 実験手順	21
3.4.3 実験対象	22
3.4.4 センサ設置要件	23
3.4.5 データ収集結果	25
3.4.6 データ前処理	27

3.5	行動認識結果と考察	28
3.5.1	重みを変更した場合の行動認識精度	28
3.5.2	生活データの欠損値補完による行動認識精度への影響	30
3.6	関連研究との比較	32
3.6.1	コンセプト	33
3.6.2	センサ設置	33
3.6.3	アノテーション手法	34
3.6.4	ターゲット行動	36
3.6.5	データ収集環境	36
3.6.6	行動認識結果	37
4.	複数居住者を対象としたデータ収集と評価	39
4.1	実験目的	39
4.2	実験手順	40
4.3	実験対象	40
4.4	センサ設置要件	41
4.4.1	ドアセンサ	41
4.4.2	アノテーションボタン	42
4.4.3	フィードバックアプリケーション	42
4.5	分析手法	44
4.5.1	協調行動認識の定義	44
4.5.2	行動の共起性を利用した協調行動認識手法	47
4.5.3	行動認識アルゴリズム	51
4.5.4	評価手法	52
4.6	データ収集結果	53
4.7	データ前処理	55
4.8	行動認識結果	56
4.9	考察	59
4.10	複数居住者環境における関連研究との比較	60

5. 結論	63
5.1 結果のまとめ	63
5.2 提案システムの課題	64
5.2.1 行動認識精度の向上	64
5.2.2 3名以上の複数居住者家庭での行動認識	65
5.3 将来の展望	67
謝辞	68
参考文献	70
研究業績	81

図目次

1	提案システム概要図	15
2	欠損値の補完例	19
3	LSTM モデル構成	20
4	人感・環境センサ設置例	24
5	ドアセンサ設置例	24
6	日々のアンケート例	24
7	データサーバ設置例	24
8	人感センサデータの可視化例	26
9	騒音レベルデータの可視化例	27
10	各家庭各行動における欠損値の補完数	27
11	一実験対象家庭の間取り模式図	38
12	改善した提案システム概要図	42
13	フィードバックアプリケーションの UI	44
14	行動認識手法の階層図	46
15	協調行動認識タスクに向けたラベル変換表	47
16	複数居住者の行動履歴を考慮した学習手法	50
17	従来手法	51
18	家庭単位の学習手法	51
19	個人単位の学習手法	51
20	DNN モデル構成	52
21	クロスバリデーション手法	53
22	各家庭各行動における外れ値行動数	55
23	マルチタスク学習による協調行動認識	66

表目次

1	関連研究との比較	13
2	第一回実験における各家庭の特性	23

3	LSTMの行動認識精度に対する重みの影響	29
4	提案する重み W_i を用いた LSTM の行動認識精度	29
5	欠損値補完処理の有無による認識精度の比較	30
6	関連研究との比較	35
7	システム設置の所要時間	40
8	第二回実験における各家庭の特性	41
9	ランダムフォレストのハイパーパラメータ	52
10	協調行動認識のクロスバリデーション結果	58
11	第一モデルと第二モデルを組み替えた結果の各家庭平均重み付き F 値	59
12	複数居住者行動認識の関連研究との比較	62

1. 序論

持続可能な開発目標である SDGs [1] や IoT 技術による技術革新を目指す Industry 4.0 [2] に関する様々な取り組みが世界中で行われている。日本においても、IoT、ICT 技術の発展を背景に、サイバー空間と物理空間を融合したシステムにより経済発展と社会問題解決の両立を図る、Society 5.0 [3] が提唱されている。Society 5.0 を実現するには、CPS (Cyber-Physical System) を様々な分野・場所に普及させる必要がある。CPS は、実空間でデータをセンシング・収集し、収集したデータを IoT や ICT 技術を用いてサイバー空間に蓄積・蓄積することで、より質の高いサービスの提供や産業課題の解決を目指している。特に、我が国が解決すべき重要な課題の一つとして、高齢化があげられる。高齢化は世界的に深刻な問題であり、都市郊外の街や住宅地では、平均の高齢化率を遥かに上回るペースで進行している [4]。そのため、高齢者の見守り・介護や高齢者の健康寿命延伸を促進するための効果的な対策が急務であり、高齢者向け見守りサービスの提供や居住者の生活習慣の改善を目的とした、ADL (Activity of Daily Living) センシングや ADL 認識技術に基づく数多くの研究が行われている。

例えば、Aran ら [5] は、見守りを兼ねた高齢者向けの異常検知手法を、Alcalá [6] らは、家電の利用状況を用いた見守りシステムを提案している。De ら [7] は、ウェアラブルデバイスとスマートフォンを利用したマイクロ行動認識システムを提案している。居住者の異常検知や見守りを行うには、センサデータや行動データの正確な収集・アノテーションが重要であり、それらのデータから居住者の行動を認識するシステムが不可欠である。しかしながら、これら CPS をベースとした既存の行動認識システムの多くは、センシングのために、高価もしくは特殊な機器を必要とすることや、長期間のセンシングにおけるメンテナンスの手間やシステムの受容性を考慮しておらず、一般家庭への普及には問題がある。スマートホームにおける ADL センシングシステム、カメラを利用した ADL システムや高齢者向け転倒検知システムなどが提案されているが、特殊な機器を必要とするスマートホーム向けシステムは、一般に高価 (問題 1) であり、間取りの異なる一般家庭への普及は難しく (問題 2)、カメラやマイクの利用はプライバシー保護の観点から問題がある (問題 3)。一般家庭における居住者の ADL を記録するため開発さ

れた代表的なスマートホームキットとして、CASAS [8] が存在する。間取りが異なる環境で利用でき、安価かつプライバシーの侵害が少ないシステムであり、多くの一般家庭への導入実績がある。しかしながら、センサがバッテリー駆動であり定期メンテナンスが必要 (問題 4) なことや、行動を記録するためのアノテーション作業が複雑 (問題 5) なことから高齢者にとって負担が大きい。特に、高齢者は、ウェアラブルセンサを必要とするシステム、動作信頼性の低いシステム、複雑なインタフェースを持つ理解しにくいシステムの利用に消極的である [9]。したがって、高齢者の ADL センシングを目的とするのであれば、居住者によるバッテリーの交換や複雑な操作を行う必要のない、長期利用可能なシステムが必要である。具体的には、1) 安価、2) 環境順応性が高い、3) 低プライバシー侵害、4) 低設置・維持コスト、5) 高ユーザビリティといった要件を満たすセンシングシステムが必要である (課題 1)。

また、上述した研究は主に単身居住者家庭をターゲットとしており、複数居住者家庭を想定するものは少ない。実際の家庭は複数居住者家庭であることも多く、網羅的に宅内サービスを提供するためには、複数居住者家庭での効率的な行動認識手法も検討する必要がある。複数居住者家庭での行動認識には、個人毎に行動認識を行うタスク (以下、行動者-行動種類認識タスクとする) を実施することが一般的であるが、このタスクの実施にはカメラやウェアラブルデバイス等の個人識別が容易なセンサが用いられる。例えば、複数居住者の生活する居住空間に人感センサを設置した場合を想定する。ある部屋である人感センサが反応した際、カメラが併設されている場合やウェアラブルセンサを居住者が装着している場合には、個人を識別する情報とセンサ反応データを紐づけることで、誰がどのセンサを反応させたかを推定できる。しかしながら、カメラ等の侵襲感を与えるセンサやウェアラブルデバイス等の接触センサをはじめとした個人識別可能なセンサのほとんどは、プライバシー情報を収集することや、デバイス自体の装着が煩わしいことから、個人の嗜好や特性によっては日常的に利用することは難しい。すなわち、侵襲感を与えない人感センサなどの非侵襲センサや人体に接触しない環境設置型の非接触センサで構成されるセンシングシステムは、複数居住者家庭を対象としてセンシングする際に、個人識別が可能なセンサデータの収集が困難で

ある。既存研究において、非侵襲センサから構成されるセンシングシステムを用いて実施される行動認識は、個人を区別せずに行動認識を行うタスク（以下、行動種類認識タスクとする）であることがほとんどである。行動種類認識タスクは、一般に得られる情報が少なく、「（個人を問わず）今、その家庭でどの単一の行動が行われているのか？」といった情報のみしか得られない。そのため、個人識別を伴わずに「どのような複数の行動が同時に行われているのか」といった、行動種類認識タスクよりも多くの情報量を得られる行動認識タスクを定義する必要がある。以上のことから、複数居住者をターゲットとした受容性の高いセンシングシステムおよび行動認識システムを実現するためには、より得られる情報の多い行動認識タスクの開発および効率的な認識手法が必要である。（課題2）

本研究では、上述した2つの課題を解決することを目的とする。課題1を解決するために、システムを一般家庭に設置するため、1) 安価で、2) 設置位置や間取りの影響を受けず、3) プライバシー侵害が少ないセンサのみを利用することに加えて、高齢者向けセンシングシステムの要件である、4) 長期間メンテナンスフリーで運用でき、5) アノテーションのための複雑な操作が必要ないことの5要件を満たす新たなセンシングシステムを提案する。要件1) について、モーションセンサや環境センサなどの比較的安価なセンサのみで構成することで実現する。要件2) について、特殊な家具、家電を利用せず、ワイヤレス接続可能かつ小型なセンサのみを利用することで実現する。要件3) について、カメラやマイクなどを利用せず、個人情報や詳細な行動状況などのセンシティブ情報を扱わないセンサのデータを収集することで実現する。要件4) について、システムの構成部品として、バッテリーが不要な環境発電型センサを採用することで実現する。要件5) について、アノテーション用にPC等で動作するアプリケーションを利用せず、環境発電型のシンプルな押しボタンを利用することで解決する。提案システムが上記の要件を満たすか確認するため、公募により募った高齢者の住む一般家庭10軒に対してシステムを設置し、2ヶ月間の実証実験を行った。収集したデータの高齢者向けサービスへの応用可能性を確認するため、5つの基本的な行動である入浴、料理、食事、外出、睡眠を対象として、各行動に対する2値分類を行う深層学習モデルを構築し、1分ごとに各センサデータを集計した特徴量を学習することで、

居住者の行動認識を行った。結果として、提案システムから収集されたデータを機械学習モデルで分析した場合、約 72%の再現率、40.7%の F 値で行動認識が可能であることを確かめた。

課題 2 を解決するために、ある家庭において並行して行われる複数の行動を、個人識別を伴わずに認識する手法を開発した。スマートホームの実現目標の一つとして、個人単位での行動認識だけでなく、家庭単位での行動・活動認識が挙げられる。一般的に、個人に着目した行動認識は、誰がどんな行動を行っているかに着目し、個人に対して有用なフィードバックを行うことが目的である。個人に着目した行動認識の具体的な応用例として、スマートフォンの加速度センサデータからユーザが頻繁に運動を行っていることを認識した場合、達成感を与えるフィードバックを行い、逆に運動が不足している場合には運動行動の推薦を行うことで健康行動を補助するアプリなどが挙げられる。一方で、家庭に着目した行動認識は、家庭内においてどのような行動が行われているのかに着目して、家庭に対して有用なフィードバックを行うことが目的である。具体的な応用例として、家庭ごとに発生する行動パターンから各種行動に伴って発生する電力量の予測を行い家庭ごとの料金プランを最適化するシステムや、入浴タイミングや就寝タイミングの異なる居住者たちに対して各種タイミングを揃えるように促す家電利用最適化システムなどが挙げられる。このような家庭単位で提供するサービスに対しては、一般的な個人に対して行う行動認識結果よりも、複数居住者が並行して行う複数の行動を認識できる協調行動認識タスクを実施するモデルが重要である。

したがって、本論文では、従来の個人に着目した行動認識ではなく、家庭全体での行動に着目した協調行動認識タスクを定義し、その行動認識精度向上のための提案や評価を行う。具体的には、「行動主は誰かを問わず、その家庭において、複数のどの行動とどの行動が並行して行われているのか？」を認識するタスク（以下、協調行動認識タスクとする）を定義する。例えば、ある家庭内で、ある人物 A が料理行動を実施している際に、ある人物 B が食事行動を実施しているとする。この場合に行動認識モデルは、「人物 A は料理」、「人物 B は食事」といったクラスを認識するのではなく、「2 人が料理と食事」といったクラスを推論するように学習する。さらに、本研究では、この協調行動認識タスクを効率よく認識するた

めのフローを提案する。例えば、複数居住者家庭（特に、2人同居家庭）において、ある居住者が料理をしている場合、もうひとりの居住者も同様に料理を手伝うか食事をするなど、互いの行動に関係ある行動が発生すると考えられる。本研究では、このような居住者の行動が互いの行動に影響し合う現象を、行動の共起と定義する。協調行動認識タスクを実施する際に、このような行動の共起を考慮することで、より精度良く認識が可能であると考えられる。そのため、提案手法では、協調行動認識タスクを実施する際に、予め簡易的に各居住者の行動を個別に推論（第一モデルによる推論）した上で、各居住者の過去の行動の推論結果を組み合わせ、再度行動の認識（第二モデルによる推論）を行う、2段階の行動認識を実施する。なお、提案手法の詳細は4章にて述べる。提案手法を評価するため、5軒の一般家庭（4軒の複数居住者家庭、1軒の単身家庭）にて1ヶ月間のデータ収集実験を行った。収集した生活データに対して、複数の機械学習モデルを用いて、提案手法による協調行動認識タスクを実施した。その結果、第一モデルに深層学習モデルであるDNN (Deep Neural Network)、第二モデルにランダムフォレストモデルを採用して提案手法を適用した結果、ベースラインよりも5%精度を改善し、66%以上のF値で行動認識できることを確認した。

本論文は、これらの成果をまとめたものであり、構成は以下の通りである。2章では、居住空間におけるADLセンシングシステムに関する既存研究に関して述べ、本研究の位置づけを明らかにする。3章では、我々が提案するADLセンシングシステムの要件と構成について述べる。さらに、一般家庭に提案システムを設置したデータ収集実験について述べ、得られた生活データに基づく行動認識結果を述べる。4章では、複数居住者家庭に対応した提案システムを一般家庭に設置したデータ収集実験について述べ、行動の共起性を考慮した行動認識手法について述べる。その後、収集されたデータに対して提案手法を適用した際の行動認識結果について述べる。5章は、結論であり、本論文で得られた結果をまとめる。

2. 関連研究

本章では、一般環境への高齢者向けセンシングシステムを普及させる場合の課題および要件を明らかにした上で、既存の居住空間における行動認識システムや日常行動センシングシステムがカバーする領域について述べる。さらに、複数居住者家庭に対する提案や、非接触センサによるセンシングシステムの提案について述べる。その後、既存研究に対する本論文の位置づけを明らかにする。

2.1 ADL センシングシステムの要件

居住空間における居住者の行動認識や高齢者向けのセンシングシステムはこれまで数多く提案されているものの、実験的な環境のものがほとんどであり、高価かつ設置場所や機器が限定されている。また、カメラのようなプライバシーを侵害しやすいセンサを用いたシステムなども提案されており、一般家庭での利用は難しい。一般家庭向けに開発された CASAS チームのセンシングシステムである、SHiB(Smart Home in a Box) もあるが、長期間のメンテナンスには向いてない。加えて、ADL データを収集する上で必須となる行動アノテーションは、居住者自身が複雑な専用ソフトウェアを操作する必要があるため、高齢者にとって負担が大きい。高齢者向け ADL データ収集システムを普及させるには、以下の要件を満たす必要がある。

要件(1): 安価であること。

要件(2): 設置場所や住居の間取りの影響を受けないこと

要件(3): ユーザのプライバシーを侵害しないこと。

要件(4): 長期間メンテナンスフリーで動作すること。

要件(5): 高齢者にも利用しやすい、シンプルなユーザインタフェースを備えること。

次節以降、本研究の位置付けをより明確にするため、既存の居住空間における行動認識システムや ADL データ収集システムを調査するとともに、これら既存システムが上記の5つの要件を満たしているか議論する。

2.2 住環境における ADL センシング

居住者の行動やコンテキストを認識するシステムに関する研究は多く行われている [10] が、ウェアラブルデバイスを含むシステムと含まないシステムに大別できる。

スマートフォンと環境センサを組み合わせて居住者のコンテキスト認識を行う研究や [11]、独自のウェアラブルデバイスによって高齢者向けヘルスケアを行う研究 [12]、など、スマートフォンを含むウェアラブルデバイスを利用する研究は多数存在する [13, 7, 14, 15]。しかしながら、高齢者をターゲットとする場合、ウェアラブルデバイスを含むシステムは、装着の負担や煩雑さのためユーザに受け入れられ難い問題がある。そのため、本研究ではウェアラブルデバイス等の接触型センサを含まないシステムを開発する。

ウェアラブルデバイスを含まず、非接触で高齢者の行動認識を試みる研究も多数存在する。電波を利用した行動認識として、Wi-Fi を利用した行動・ジェスチャ認識の研究 [16, 17, 18] や、RFID を利用した行動・ジェスチャ認識の研究 [19, 20, 21, 22]、BLE ビーコンを利用した高齢者施設における介護記録作成システム [23] などが存在する。しかしながら、これらの研究は、電波の反射影響を受けるため、環境やデバイスの位置が変わるごとに再設定が必要であり、実験環境以外での利用は、キャリブレーションの手間等を考慮すると現実的でない。そのため、これらの研究は、要件 (2) を満たしていない。高齢者のヘルスケアを目的としたワイヤレスセンサネットワークの提案 [24]、BLE ビーコンを利用した高齢者施設における介護記録作成システム [23] なども存在するが、前述したとおり特定の環境でのみの実験であり、実際の一般家庭における ADL センシングシステムとしての普及には課題がある。

ADL センシングシステムに類似するシステムとして、認知症を検知するための異常検知システム [25] や高齢者の見守りなどを兼ねた異常検知の研究 [5]、カメラを利用した転倒検知システム [26] などの異常検知に特化したシステムの提案も盛んである。しかしながら、いくつかのシステムではカメラを利用し、ユーザを常に撮影することから、ユーザのプライバシーを侵害する恐れがあるため、要件 (3) を満たさない。

一般に、カメラを利用して画像を収集するシステムは、データの保存や通信、第三者による画像の閲覧に関してプライバシーの問題が発生する。ただし、カメラを用いたシステムであっても、撮影した映像からバウンディングボックスやスケルトンなどの特徴を抽出し、画像自体を破棄することなどによって、プライバシーへ配慮することが可能である。その際に、カメラを利用することで、行動認識精度の向上などが期待できるが、ユーザによっては、実際にカメラで撮影した画像を保存・通信していなくても、カメラを設置すること自体に対する監視感が負担となりうることから、センシング対象となるユーザがカメラ設置に対して抵抗感を感じるか検討する必要がある。

ADL データを取得する研究として、電力消費量や水道利用量などのライフラインを利用する手法や、住居内に様々なセンサを配置したスマートホームを利用する手法が提案されている。

ライフラインを利用する手法として、水道の利用状況から一般的な家庭内行動を認識する研究 [27] や、水流情報からどの ADL が行われているかを認識する研究 [28]、家電の電力使用量や利用状況およびモーションセンサなどのデータ組み合わせて行動認識する手法 [29, 30, 31, 32, 33] が存在する。また、スマートホーム領域の主要なオープンデータセットとして、Kasteren データセット [34]、ARAS データセット [35]、PlaceLab データセット [36]、Domus データセット [37]、Sweet Home データセット [38] などが存在する。これらのデータセットでは、それぞれスマート化された住環境におけるセンシングシステムを利用して収集されたデータを提供している。

これらのシステムは、分電盤などの住居に存在する設備や、圧力マットなどの設置位置の制約が強いセンサを利用しており、多数のセンサや高価なセンサを利用している場合もあることから、いずれも特定の実験環境に対して特化しており、一般家庭への普及には課題がある。したがって、これらの研究は、要件 (1), (2) を満たしていない。ADL に紐付けた高齢者の健康寿命延伸を促進するためには、より自然な方法による、一般の高齢者家庭における ADL データのセンシングが必要である。

一般家庭における ADL センシングシステム開発における重要な要素として、プ

プライバシーへの配慮がある。一般家庭の住環境で収集されるデータは非常にプライベートなデータであることから、プライバシーやセキュリティに関する研究が多数行われている [39, 40, 41, 42, 43, 44, 45]。居住者の世代にかかわらず、画像や音声の収集・データ保存は侵襲感を与える場合があり、要件 (3) を満たさない。したがって、住環境に設置するセンシングシステムは可能な限りプライバシーに配慮した情報のみを収集するにとどめ、情報漏洩のリスクや侵襲感を低減する必要がある。一般家庭における行動認識を目的としたセンシングシステムとして、CASAS[8] のスマートホームキット (Smart home in a box: SHiB) がある。SHiB [8] は、一般家庭への導入を前提としたキットであり、本稿の執筆時点で 70 以上のデータセットが収集・公開されている。対象とする家庭は、高齢者を含む全ての一般家庭であり、ペットを飼っている家庭のデータや複数居住者の家庭のデータ、高齢居住者のデータも存在する。SHiB キットは、サーバ、電子機器用のケーブル類、リレー、温度センサ、磁気ドアセンサ、人感センサ、電池類、粘着テープから構成される。これらのセンサ類は任意の場所に設置することが可能であり、間取りの影響を受けない。また、数千ドルでキットが揃えられることから、センシングシステムとしては比較的安価に導入可能である。さらに、高齢者が SHiB キットを自己設置を行う場合の評価 [46] では、概ね良好な評価が得られている。すなわち、このようなキットであれば、高齢者が居住する一般家庭への導入が可能と考える。一方で、全てのセンサはバッテリー駆動であり、定期的なメンテナンスが必要である上に、バッテリー分、センサのサイズはやや大型である。また、センサの設置数は 40 個程度であり、設置の際にかかる手間や、設置後に居住者が感じる侵襲感が大きいことが課題として挙げられる。さらに、行動ラベルのアノテーションのためには、居住者自身が PC 上で動作するソフトウェアを利用して、行動ラベルを設定する必要がある。高齢者は、システムメンテナンスが必要であることへの負担を感じる傾向があり [9]、PC の利用や複雑なインタフェースを持つソフトウェアの操作は難しい [23] と指摘されている。以上のことから、SHiB キットは、要件 (4)、(5) を十分に満たしているといえない。

イギリスの高齢者の一般住宅で ADL センシングを行う SHPERE プロジェクト [47] によるセンシングシステムが存在する。高齢者のヘルスケアを目的としてお

り、いくつかのシステム活用事例がある。システムは、ウェアラブルデバイスやカメラ、人感センサなどから構成されており、全体として安価である。利用するウェアラブルデバイスは非常に小型であり、抵抗感を低減する配慮がなされている。また、行動のアノテーションは、シンプルなモバイルアプリケーション上で実施するため、利用しやすい配慮がされている。しかしながら、システム設置の際における複数回の訪問や、対象家庭の間取りごとにシステムの調整が必要であり、1年に数回のシステムメンテナンスが必要である。

2.3 複数居住者家庭に対する ADL センシング

ADL センシングは、単身居住者を対象にしたものと複数居住者を対象にしたものに区別できる [48]。一般的に、複数居住者を対象としたシステムは、センサ反応の分離や識別が難しく、設計が困難であることが知られている。生活パターン認識を伴う異常検知などのシステムは、独居高齢者の無事を見守るための生活モニタリングに活用されることが多く、単身居住者をターゲットとすることが多い。一方で、包括的な健康寿命延伸を目的とする場合には、より応用範囲が広がることが想定されるため、高齢夫婦などの複数居住者もターゲットに広げる必要がある。

RFID や Wi-Fi の CSI (Channel State Information) 情報、ドップラーセンサを利用した、複数居住者に対する宅内行動センシングシステムは多数提案されている [49, 50, 51, 52]。無線信号によるセンシングは、フルコンタクトフリーであり、映像や音声などのセンシティブな情報を直接収集しないことから、比較的受け入れられやすい。しかしながら、無線信号だけで収集できる情報は歩行やジェスチャなどの人物の基本的な動作であり、周囲の環境の変化によって影響を受けやすいことから、一般家庭における ADL などの複雑な行動の認識には至っていない。転倒検知や AAL (Ambient Assisted Living) を目的とした行動認識システムも提案されている [53, 54] が、寝室やバスルームなどのプライベートスペースでの利用は難しい。RGB カメラではなく、深度カメラやサーモカメラを利用するが、エッジコンピューティングを適用することでプライバシーに配慮した、複数居住者向けカメラベースセンシングシステムも提案されている [55, 56] もの、カメラを設置し

ている事に対する居住者の感じる心理的な障壁が課題である。その他、複数居住者の行動認識に向けて、環境センサやバイナリセンサを利用する研究 [57, 58] や、ウェアラブルセンサと各種センサを組み合わせたマルチモーダルなセンシングを行う研究 [22, 11] が行われている。多様なセンサの利用は、センサごとにキャッチできない情報を補完し合うため、認識精度の向上が期待できるが、設置・メンテナンスの手間やコスト面で課題がある。

複数居住者の行動認識へ向けた手法の提案として、確率モデルベースで行動認識を行う手法や、機械学習モデルベースの手法 [59, 60, 61] がある。これらのデータ駆動型手法による認識精度は、訓練に利用できるデータに大きく依存することが知られており、CASAS Kyoto データセット¹に代表される、予め設定された生活に沿って ADL を実施する方法でセンシングされたデータセットや、センサイベントレベルの非常に詳細にアノテーションされたデータセットを基に検討されていることがほとんどである。したがって、現実的に一般家庭へ普及が可能なレベルのセンサ設置数やアノテーションの粒度でセンシングされた複数居住者の行動認識は、行われていない。一方で、知識駆動型の認識手法 [62, 63] も提案されているものの、行動の適切な意味付けに必要な知識の効率的な獲得が課題である。

2.4 非接触センサによる複数居住者家庭の ADL センシング

一般に、非接触センサデータを用いた ADL センシングシステムから得られるデータでは、個人識別が難しいという課題がある。一方で、そのようなシステムを利用しつつ、複数居住者家庭の ADL センシングを実現するための提案がいくつか存在する。例えば、最もシンプルな行動認識手法として、複数居住者家庭であっても、個人を区別しない、行動種類認識を実施する手法が提案されている [64]。行動種類認識では、個人を識別しないためプライバシー侵害に繋がる映像・音声・生体データを必要としないことや、ウェアラブルデバイス等の身体装着型センサを利用しなくとも実現できるメリットがある。そのほか、部屋などの家庭内の様々な空間的区切りを基準にしてセンサ反応を区切り個人を区別する、行動者 - 行動種類認識を目指す手法も提案されている [65]。この手法では、同じ部屋で 1 人だ

¹<http://casas.wsu.edu/datasets/>

けの居住者が活動しているという前提で行動認識をしており、それぞれの部屋発生するセンサ反応系列を一つのエピソードとみなし、推論モデルへの特徴量としている。一方で、この手法の課題として、同じ部屋に複数の居住者がまとまって活動している場合においては、行動者-行動種類認識が難しいと述べられている。なお、この場合においても、カメラやマイクなどを追加することで個人識別精度が向上する可能性が示唆されている。また、複数居住者家庭でセンシングされたベンチマーク用データセットに対して、RNN(Recurrent Neural Network)等を始めとした様々なモデルでベースラインの精度を比較する研究が存在する [66]。この研究では、複数居住者家庭において行動者-行動種類認識を行った各居住者の単一のラベルを推論する精度と、どの行動がどの行動と同時に進行しているのかを組み合わせ合わせた組み合わせラベルを推論する精度を比較している。その結果、同じ推論モデルを用いた上で、組み合わせラベルを推論する方が精度良く ADL を推論できたことが述べられている。しかしながら、これらの研究では、予め実験用に用意された部屋に居住者が入居して実施される条件や、実施する生活行動を予め指定して行われる条件での実験データも含まれており、実際に生活されている一般的な家庭でのシステム導入・評価には至っていない。

2.5 本研究の位置づけ

表 1 に、関連研究として挙げた ADL センシングシステムの特性について示す。表より、既存研究において、各項目については部分的に考慮されているものの、5つの要件を満たすセンシングシステムの構築には至っていない。したがって、本研究では、これら5つの要件を満たす ADL センシングシステムの構築と、実際の一般家庭からのデータ収集の達成を目指す。さらに、複数居住者家庭に対する行動認識手法として、各居住者の行動の共起関係を考慮し、機械学習モデルを利用した分析を行うことで、自然な環境下で収集されたデータを利用した行動認識を行う。実際に、複数の居住者が協調的に行う行動の存在は知られており [67]、行動の共起関係の学習は、認識精度を向上させると考えられる。

表 1: 関連研究との比較.

	要件 (1)	要件 (2)	要件 (3)	要件 (4)	要件 (5)
Kasteren [34]	✓	✓	✓	△	n/a
ARAS [35]	✓	n/a	✓	△	n/a
Placelab [36]	✓	✓	✓	△	n/a
Domus [37]	n/a	n/a	n/a	n/a	n/a
Sweet Home [38]	n/a	n/a	n/a	n/a	n/a
CASAS SHiB [8]	✓	✓	✓	△	n/a
SPHERE [68]	✓	n/a	△	△	△
Our System	✓	✓	✓	✓	✓

✓: 要件を満たす. △: 部分的に要件を満たす. n/a: 要件を満たさない.

3. 一般家庭での利用に適した ADL センシングシステム

本章では，設計・開発した，要件(1)～(5)を満たす ADL データ収集システムについて述べ，次にその構成に関して述べる．さらに，開発したセンシングシステムを用いて一般家庭を対象としたデータ収集実験とその分析結果について述べる．

3.1 システム要件

要件(1)，(2)を満たすには，センサ類，データサーバは比較的安価な規格品を利用し，簡単に住居内へ設置可能であるよう，小型に設計する．さらに，要件(3)を満たすため，人物反応やドア開閉情報などのバイナリ情報，もしくは温度や湿度，騒音レベルなどのプライバシーと関連しないデータを収集するセンサのみを採用する．要件(4)を満たすため，環境から発電した電力（エネルギーハーベスティング）で動作するセンサを採用する．要件(5)を満たすため，行動アノテーション用ボタンとして，シンプルな押しボタン式センサを採用する．以上のことから，以下の5要素でシステムを構成する．

1. 人感センサ (エネルギーハーベスティング)
2. 温度，湿度，照度，気圧，騒音情報を取得する環境センサ
3. 磁気ドアセンサ (エネルギーハーベスティング)
4. アノテーション用押しボタン (エネルギーハーベスティング)
5. データサーバ (小型 PC)

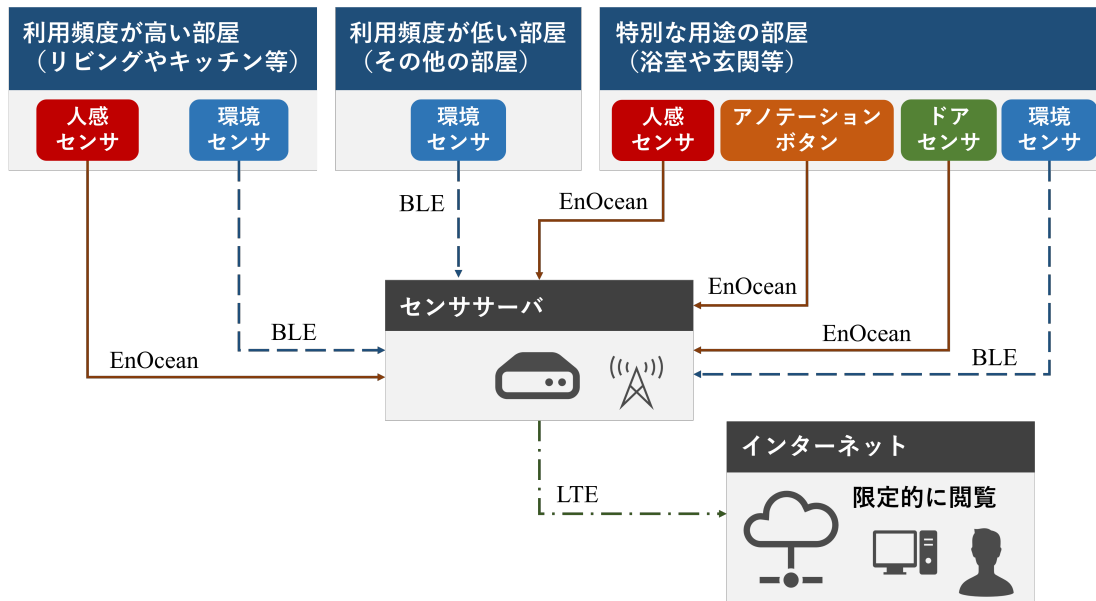


図 1: 提案システム概要図

3.2 システム構成

図 1 に、各家庭における本システムの概要を示す。本システムは、人感センサ、環境センサ、ドアセンサ、アノテーションボタン、データ記録用サーバで構成される。以下に各構成要素について具体的に述べる。

3.2.1 人感センサ

人感センサは、人体から発せられる赤外線を受けることで、パッシブに人間を検出するセンサである。したがって、ペットなどの小動物による熱源や、直射日光などによる温度変化によって誤作動を起こす可能性があることに注意が必要である。本センサを、長期間メンテナンスフリーで動作させるために、EnOcean 規格に対応した環境光発電パネルモジュールである ROHM 社の STM431J と人感センサモジュールである Panasonic 社の EKMB1101112 を組み合わせたセンサを製作した。これにより、環境発電のみでセンシングとサーバへのデータ送信が可能である。サイズは一般的な USB メモリと同等であり、樹脂で作成したカバーを

備えているため、4.5gと非常に軽量である。また、人感センサの検知範囲は水平94度、垂直82度、距離5mであり、中程度までの部屋であれば1個の設置で部屋の大部分をカバー可能である。

3.2.2 環境センサ

環境センサとして、収集できるデータが多様であり、小型で動作時間の長い、Omron社の2JCIE-BLを採用する。提案システムでは、本センサから温度、湿度、照度、気圧、騒音を取得し、BLEによってサーバへ蓄積する。BLEの通信距離は10mであり、一般的な家庭であれば、中央の部屋に設置することで、屋内のセンサと接続可能である。また、本体メモリを内蔵しているため、一時的な通信障害に対処可能である。サイズはモーションセンサ2つ分程度と小型であり、重量は16gと軽量である。メーカーが提供しているデータシートによると、電池寿命は、サンプリング周期が5分に1度の場合6ヶ月である。

3.2.3 ドアセンサ

ドアの開閉を取得するために、エネルギーハーベスティングで動作するROHM社の磁気ドア開閉センサモジュールであるSTM250Jを利用する。ドアセンサは、センサ本体とマグネットの2つのパーツから構成される。このセンサは、ドアとドア枠に取り付けられたセンサ本体とマグネットを近づけたり、離したりすることでドアの開閉情報を取得する。その後、センサ本体は取得した開閉情報をサーバに対して送信する。

3.2.4 アノテーションボタン

居住者の行動をアノテーションするために、ROHM社の押しボタン式データ送信センサであるPTM210Jを採用する。本センサは、機械式発電モジュールを備えており、エネルギーハーベスティングで動作する。ボタンが押下された際の力を利用して電磁誘導素子が発電を行い、ボタンが押下されたことを知らせるパケットを生成しEnOcean経由で送信する。本センサは、円形で、2つのスイッチを備

えている。各スイッチには、開始と終了を示すシールが貼られている。居住者は、それぞれのスイッチを押下することにより、行動の開始と終了をアノテーションすることが可能である。

3.2.5 データサーバ

データサーバには Intel 社の NUC を利用する。このサーバには BLE 通信用 Dongle, EnOcean 通信用 Dongle が接続されており、それぞれ環境センサデータと BLE 規格、人感センサ、ドアセンサ、アノテーションボタンと EnOcean 規格でデータの送受信を行っている。サーバが受信したデータは、サーバ内に動作する時系列データベースである InfluxDB へ格納する。また、システム運用中であってもセンシングシステムが正常に動作しているかを確認するために、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している。この際、データサーバにピクセラ社の LTE 対応 USB Dongle である PIX-MT100 を接続することで、モバイルネットワーク経由でオンライン接続している。

3.3 分析手法

本節では、提案するセンシングシステムから得られるデータに対する欠損値補完手法や前処理手法について述べる。その後、行動認識アルゴリズムと評価手法について述べる。

3.3.1 欠損値の補完

センサデータは基本的に機械的に収集可能であるが、行動ラベルデータは人が介在するため、入力忘れによるデータ欠損が発生する。行動ラベルデータは、行動認識において正解データに該当するが、欠損は誤った正解データの生成を意味する。正解データが誤っている場合、適切な学習ができず、行動認識モデルの精度は低下するため、欠損値の補完は重要である。行動ラベルデータは、基本的に

開始・終了のセットで存在しており、データ欠損は、主に以下の3パターンに大別可能である。

(タイプ1) 行動開始，終了スイッチの両方を押し忘れる。

(タイプ2) 開始スイッチを押し忘れる。

(タイプ3) 終了スイッチを押し忘れる。

タイプ1の欠損は，データから読み取ることが全くできない．そのため，居住者の自己申告であるアンケートでしか補完できない．タイプ2の欠損は，終了ラベルデータのみ独立して存在することになる．同様に，タイプ3の欠損は，開始ラベルデータのみ独立して存在することになる．したがって，これらの欠損に対しては，日々のアンケートのほかに機械的な手法による補完を行う．補完は，各家庭・各行動に対して，以下の通り行う：

(ステップ1) アンケートに基づき，行動データを修正する (タイプ1-3に対応).

(ステップ2) 独立した終了ラベルデータから当該行動の平均行動時間前に開始ラベルデータを生成する (タイプ2に対応).

(ステップ3) 独立した開始ラベルデータから当該行動の平均時間後に終了ラベルデータを生成する (タイプ3に対応).

図 2a, 2b, 2c に，正常，アノテーションボタンの開始スイッチを押し忘れた場合，終了スイッチを押し忘れた場合の補完例を示す．先行研究における提案システムでは，各家庭に対して5個と決まった数のアノテーションボタンしか配布しない．したがって，複数居住者家庭においては，開始インスタンスが2個連続した後に終了インスタンスが2個連続する場合が発生する．このような場合，並行して行われる行動の終了時間として，時系列的に行動の最後に送信されたデータを終了データの真値として採用している．

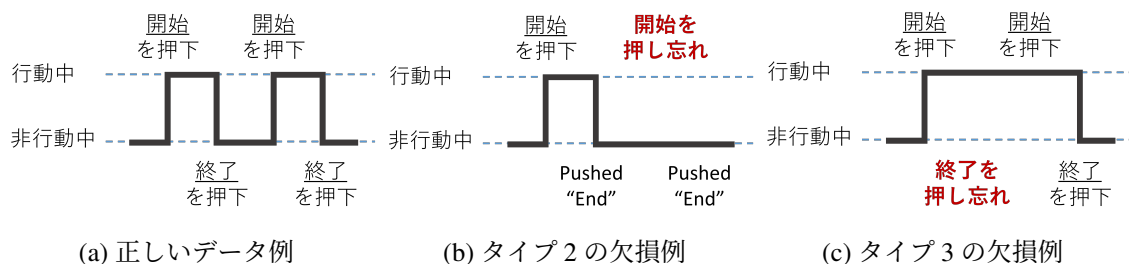


図 2: 欠損値の補完例

3.3.2 行動認識アルゴリズム

先行研究では、時系列データに対して行動認識を行うために、LSTM 機構を有する行動認識モデルを構築した。

図 3 に、本研究で利用した深層学習モデルの概要を示す。モデルは、入力層、全結合層、ドロップアウト層、LSTM 層、出力層から構成されており、tensorflow ライブラリをバックエンドとした Python 用深層学習ライブラリである Keras によって実装した。また、ハイパーパラメータは、全結合層と LSTM 層のユニット数を 512、ドロップアウト層のドロップアウト率を 0.2、入力時間長であるルックバック長を 100、epoch 数を 10、入力バッチサイズを 512 とした。活性化関数について、全結合層の活性化関数を ReLU、LSTM 層の活性化関数を tanh とした上で、出力層の活性化関数をシグモイド関数としている。すなわち、各行動に関して、行動しているかしていないかを判断する 2 値推定モデルを行動数分である 5 個生成している。これにより、複数居住者の家庭におけるマルチラベル問題を 2 値分類問題へ変換している。

なお、収集した ADL データは不均衡データである。不均衡性への対処には、コストセンシティブな手法による学習や SMOTE[69] などの手法によるデータ拡張、モデルから出力された確率のしきい値を変えていく Threshold-moving を利用した手法などが存在する。本手法では、不均衡データに対してコストセンシティブな学習を利用する。具体的には、コストセンシティブな学習の重みとして、以下の式 2 で定義される重みを利用する。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.

なお, 不均衡データへの対策を行わない場合, 行動認識モデルはサンプルが多数のクラスが有利になるように推論を実施する. しかしながら, 本研究で利用する生活データに対しては, 「scikit-learn」等をはじめとした機械学習ライブラリ等で一般的に利用される重み²である w_i では, 少数クラスを重視しすぎる推論を実施する [70]. したがって, 本研究では, 極端なクラスウェイトを軽減するための補正を加えた重みである W_i をクラスウェイトとして利用する.

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

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

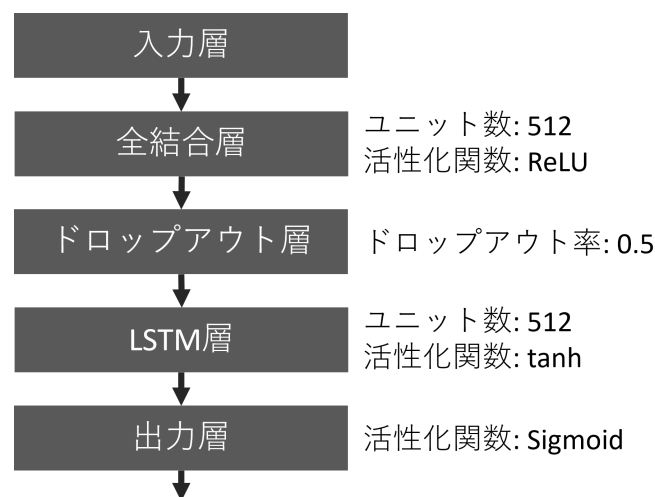


図 3: LSTM モデル構成

3.3.3 評価手法

データの時系列性を保持したままモデルの評価を行うために, time-window based cross validation の手法を利用する.

²https://scikit-learn.org/stable/modules/generated/sklearn.utils.class_weight.compute_class_weight.html

時系列データの開始点から、ハイパーパラメータとして設定した追憶データ数 (100 samples = 1000 sec) 毎に一つの系列データとして抽出する。抽出したデータを1サンプル (10 sec) ごとにスライドし、新たな系列データを生成する。生成した時系列データのうち、最初の80%をトレインデータ、次の10%をバリデーションデータ、最後の10%をテストデータとして分割する。トレインデータおよびバリデーションデータによって各行動毎に生成した2値学習モデルをテストデータに適用し、適合率、再現率、F値により評価する。

3.4 一般家庭を対象としたデータ収集と評価

本節では、提案システムが、要件(1), (2), (3)を満たした上でADLデータを収集できること、高齢者宅での長期間の実験により要件(4), (5)を満たすことを検証するため、一般家庭を対象とした検証実験を行う。はじめに、実験の条件とセンサ設置条件について述べる。次に、各家庭ごとの特性に関して述べ、分析に影響すると考えられる要因について考察を行う。最後に、実験により得られたデータを可視化し、提案システムにより生活データが収集できることを確かめる。

3.4.1 実験目的

本実験の目的は、提案システムが一般家庭において想定通り運用可能であること、見守りや行動認識に応用できうるデータが収集可能かを確認することである。なお、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(承認番号:2018-I-26)。

3.4.2 実験手順

実験は、実験参加者へ研究の目的などを説明し、同意を得た上で開始される。各センサは間取りに合わせて設置される。その後、各センサとデータサーバとの通信を確認した。

実験参加者は、配布されたアノテーションボタンを利用して行動のアノテーションを行う。この際、実験参加者が単身居住者であれば、アノテーションボタンは1

名用として利用する。居住者が2人である場合、2名で各行動ごと1つのアノテーションボタンを共用する。2名の居住者が同時に食事を開始する場合、アノテーションボタンの開始スイッチを同時に2度連続で押下し、同様に、行動終了の際にも終了スイッチを2度連続で押下する。押下を忘れた場合は、紙のアンケートにそれを記載する。実験期間は、各家庭2か月である。居住者が1日以上外出をしていた場合、その日数分だけ実験期間を延長し、データ収集期間が2ヶ月間となるように依頼している。

3.4.3 実験対象

実験対象は、奈良県生駒市周辺の高齢居住者の在住している家庭10軒である。対象となる10軒のうち、単身居住者の家庭が3軒であり、2人居住者の家庭が7軒である。居住者は、60歳代から80歳代までの高齢者である。実験参加者は、公募により募集し、本実験の目的、方法、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。

表2に、センサを設置した各家庭の特徴を示す。各センサは、家の間取りに合わせて、モーションセンサ(6~10個)、環境センサ(7~10個)、ドアセンサ(0~2個)が設置された。この際、ドアセンサは、玄関および入浴所付近のドアに設置した。設置時間は、居住者への説明、センサの設置およびデータサーバの設定を含めて、すべて1時間以内に終了した。以上より、間取りの影響を受けずに設置でき、要件2を満たすことを確かめた。なお、各家庭により、居住者の特性および生活スタイルは異なっていた。また、10軒中5軒は、ほとんど訪問者はいなかったものの、残り5軒は、時々または頻繁に訪問者が存在していた。センシング対象ではないゲストが、食事や入浴などのADLを行うケースも存在した。この場合、これらの外部ゲストからもセンサ情報が収集されることになる。また、2軒が猫を飼育していたため、ペットの影響によりセンサが誤反応する可能性があった。

表 2: 第一回実験における各家庭の特性

	居住者数	人感センサ	環境センサ	ドアセンサ	訪問者	ペット	特記事項
ID01	2	10	10	0	頻繁に孫, 友人	無	-
ID02	2	8	7	0	ほぼ無	無	自宅で入浴することが少ない.
ID03	2	10	10	1	ほぼ無	無	-
ID04	2	9	9	1	ほぼ無	猫	居住者の1人は30代である.
ID05	1	10	10	2	ほぼ無	無	-
ID06	2	10	10	2	頻繁に孫	無	孫が訪問した際に, 入浴や食事を行う場合がある.
ID07	1	6	7	1	頻繁に子供	無	住居が鉄筋コンクリート造であり 通信が不安定
ID08	2	10	10	0	時々	無	時々, 訪問客が睡眠する.
ID09	2	10	10	2	ほぼ無	猫	-
ID10	1	6	7	2	稀に介護士	無	定期的に介護士が訪問する.

3.4.4 センサ設置要件

提案システムの設置は、各家庭へ実際に訪問し行った。このとき、各家庭で間取りが異なるため、それぞれのセンサについて簡易的な設置条件を定義した。以下に、各センサの設置条件を示す。

人感センサ モーションセンサは、各家庭ごとに配置する数を制限するために、最大10個用意し、洗面所や廊下等を含む利用頻度の高い各部屋・位置ごとに、0もしくは1個設置した。なお、物置部屋などの利用頻度の低い部屋には人感センサは配置していない。

設置の際、1つのセンサで1つの部屋をカバーした。センサは、接地面をマスキングテープで保護し、両面テープで貼り付けて壁面に固定している(図4)。これにより、センサ取り付けや取り外しが容易となり、壁面を傷つけずにセンサ設置が可能である。設置場所は、誤検知の原因となる家具やカーテンなどの遮蔽物を避けるように、床から1mの高さに配置した。これにより、ペットや移動型掃除機などの家電を避け、人のみにセンサが反応するよう配慮している。



図 4: 人感・環境センサ設置例



図 5: ドアセンサ設置例

5月10日(金) ○○様宅

- 実施した行動をチェックしてください。
- ボタンを押した状態での場合は、時間を記入してください。
- 必要があった場合は、その対象客に記入してください。

行動	△△様	□□様
起床	<input checked="" type="checkbox"/>	<input type="checkbox"/>
利用(朝食)	<input checked="" type="checkbox"/>	<input type="checkbox"/>
朝食	<input checked="" type="checkbox"/>	<input type="checkbox"/>
料理(軽食)	<input type="checkbox"/>	<input type="checkbox"/>
軽食	<input checked="" type="checkbox"/>	<input type="checkbox"/>
料理(夕食)	<input type="checkbox"/>	<input type="checkbox"/>
夕食	<input checked="" type="checkbox"/>	<input type="checkbox"/>
入浴	<input checked="" type="checkbox"/>	<input type="checkbox"/>
睡眠	<input checked="" type="checkbox"/>	<input type="checkbox"/>
外出	<input type="checkbox"/>	<input type="checkbox"/>
来客	友人: 15:00 - 16:00	<input type="checkbox"/>

その他特記事項: 以上の時間がなかった、→特記事項で手紙などその日の特記事項がございましたらご記入ください。

図 6: 日々のアンケート例



図 7: データサーバ設置例

環境センサ 環境センサは、モーションセンサと同様の方法で、床から1mの高さの任意の空間に設置した(図4)。設置の際には、基本的には、モーションセンサの隣に配置することとしている。サンプリング周期は、実験期間と電池寿命のトレードオフを考慮して、3分間に一度と設定した(1/180 Hz)。設定した周期であれば3ヶ月間の連続動作が可能であることを事前実験により確かめている。なお、利用頻度が低く、人感センサの配置していない部屋などには、環境センサのみ設置することとしている。

ドアセンサ ドアセンサは、モーションセンサと同様の方法で、玄関と浴室のドアに設置した。この際、ドア側に本体を設置し、ドア枠にマグネットを設置した(図 5)。

アノテーションボタン 本実験では、入浴行動、料理行動、食事行動、外出行動、睡眠行動の 5 種類をセンシング対象行動とし、1 軒ごとに行動数と同じ 5 個を配置している。

設置位置は、居住者がアノテーションボタンを操作しやすい位置としている。例えば、料理用アノテーションボタンであればキッチンの近くに配置し、睡眠用アノテーションボタンであればベッドの近くに配置した。居住者は、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。ボタンによるアノテーションに加えて、日々のアンケート(図 6)によるアノテーションを行う。アンケートでは、一日の終わりに、各行動を行ったかどうか、アノテーションボタンを押し忘れたかどうかを記述する。

データサーバ データサーバは、通信強度を高く保つために、家庭内において中心に近い部屋に配置した。その際、ソファの下など、邪魔にならない場所へ配置した(図 7)。

3.4.5 データ収集結果

設置したシステムによるデータ収集の結果について述べる。図 8, 9 に、1 軒から収集した 1 日の行動データと主要な部屋におけるモーションセンサ反応数、騒音レベルを示す。行動データより、居住者が午前 6 時に起床し、朝食の準備に取り掛かっていることがわかる。その後、午前 9 時から夕方まで外出し帰宅した後、夕食の準備および入浴を行い、およそ午後 11 時に就寝していることが読み取れる。キッチンにおけるモーションセンサの反応数に着目すると、他のセンサ反応と比較して料理行動が行われている間の度数が高いことが確認できる。同様に、食事中にはリビング、睡眠中には寝室におけるセンサ反応の度数が高いことが確認できる。さらに、入浴の前後では、キッチンのセンサ反応の度数が高い。これ

は、キッチンと浴室が隣接しているためであり、人感センサが人物の動線を検知していると考えられる。騒音レベルに着目すると、食事後にキッチンで騒音レベルが上昇していることから、皿洗い行動を検知していると考えられる。また、入浴中に、風呂場と隣接しているキッチンの騒音レベルが上昇していることから、人感センサデータからは検知できなかった入浴の情報についても収集できていると考えられる。これらのことから、提案システムは、居住者の ADL の概要を把握できるセンサデータを収集できているとあり、異常検知や行動認識に有用であると考えられる。

提案する欠損値補完手法を用いて補完した、各家庭の各行動における欠損値の総数を示す(図 10)。図より、家庭によって欠損状況のばらつきはあるものの、睡眠行動の欠損数は全体的に少なく、それ以外の行動は比較的欠損値が多い。この要因として、睡眠は一日の区切りとなる行動であることから、行動とアノテーション動作を結びつけやすいことが挙げられる。したがって、今後の課題として、欠損の多い行動に対する補完手法の工夫や、ボタンの押し忘れを抑制するシステムの開発が求められる。




図 8: 人感センサデータの可視化例

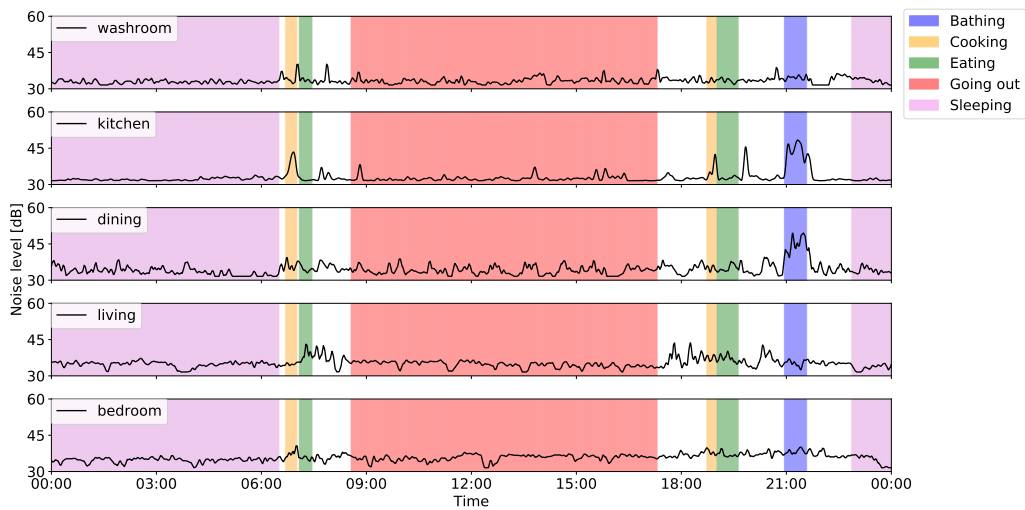


図 9: 騒音レベルデータの可視化例




図 10: 各家庭各行動における欠損値の補完数

3.4.6 データ前処理

収集したデータを機械学習モデルに学習させるために、特徴量生成を行った。提案システムで利用されているセンサは、サンプリング周期がそれぞれ異なって

いる。モーションセンサやドアセンサ、アノテーションボタンはセンサが反応・押下された場合にパケットを送信するため、サンプリング周期は存在しない。一方で、環境センサは、3分間のサンプリング周期を設定している。これらのセンサデータを分析に利用するために、経験的に10秒間とした時間窓を用いる。モーションセンサデータとドアセンサデータは、時間窓における反応回数を格納した。行動ラベルデータは、開始を1、終了を0として、次にアノテーションボタンが押されるまでその値を保持し続けるように格納した。また、環境センサデータは、それぞれの計測値(温度、湿度、照度、気圧、騒音)を値が変わるまで保持し続けるように格納した。さらに、追加特徴量として、一日の開始時点から終了時点までの時間窓番号を0から1に正規化している。これにより、1日の中で各行動が行われた時間を認識可能である。

3.5 行動認識結果と考察

本節では、提案する重み W_i を用いた場合・一般的な重み w_i を用いた場合・用いない場合の行動認識結果と、提案する欠損値補完処理を行った場合・行わない場合の結果についてモデルを評価し、それぞれに対して考察する。

3.5.1 重みを変更した場合の行動認識精度

表3に、3.3.2節で述べた、提案する重み W_i を用いた結果(重み調整あり)、一般的な重み w_i を用いた結果(一般的な重み)、重み調整を行わない結果(重みなし)の行動認識精度を示す。一般的な重みを用いた学習では、少数クラスに対して過剰に重み付けすることから、適合率が低く再現率が高いことが読み取れる。さらに、重み調整を行わない結果では、適合率が高く再現率が低いことが読み取れる。適合率と再現率の調和平均を示すF値を比較すると、提案する重みを利用することで、F値を6%程度改善していることが読み取れる。以上のことから、提案する重みを利用した学習によって、重み調整を行わない場合や一般的な重みを利用する学習よりも精度が改善する。

さらに、提案する重みを用いた結果について詳細に考察する。表 4 に、提案する重みを利用した場合の各家庭における、入浴、料理、食事、外出、睡眠行動の適合率、再現率、F 値、適合率の標準偏差、再現率の標準偏差を示す。表より、すべての行動において、再現率が高く、適合率が低い傾向が読み取れる。平均では、0.723 の再現率を達成している一方で、適合率に関しては 0.367 という結果が得られた。データ点数が多い外出行動、睡眠行動に関しては比較的適合率が高いものの、入浴、料理、食事行動に関しては適合率が低い。

表 3: LSTM の行動認識精度に対する重みの影響

	適合率	再現率	F 値
全行動の平均値 (重み調整あり)	0.367	0.724	0.407
全行動の平均値 (一般的な重み)	0.274	0.895	0.343
全行動の平均値 (重みなし)	0.437	0.376	0.341

表 4: 提案する重み W_i を用いた LSTM の行動認識精度

行動	適合率	再現率	F 値	適合率 標準偏差	再現率 標準偏差
入浴	0.249	0.711	0.306	0.2628	0.2843
料理	0.212	0.850	0.310	0.1310	0.1547
食事	0.198	0.549	0.254	0.1487	0.3053
外出	0.351	0.720	0.424	0.2746	0.2828
睡眠	0.824	0.787	0.740	0.2207	0.2486
平均	0.367	0.723	0.407	0.2076	0.2551

以下では、提案する重みによって重み調整を行った結果である表 4 に示す結果に関して考察する。最も再現率の高い行動は料理行動であり、低い行動は食事行

動であった。これは、料理行動はキッチンという特定の部屋で行われることが多いのに対し、食事行動はリビングやダイニングにおいて行われることが多いためである。例えば、ある家庭において、テレビを見ながら食事をする人が多い場合、テレビを見ているのか食事をしているのかモーションセンサ情報からは判別しにくい。つまり、リビングとダイニングが兼用されている場合、食事以外のADLが食事する場所で行われることから、再現率が低下したと考えられる。一方で、一般的にキッチンで行われる行動の種類は、料理行動以外には少ない。したがって、キッチンで活動が検出されたため料理行動である可能性が高いとモデルが認識し、再現率が向上していると考えられる。同様の理由から、再現率の標準偏差について着目すると、食事行動に関しては再現率のばらつきが大きく、料理行動に関しては再現率のばらつきが小さくなっている。また、外出行動について、複数居住者の家庭やペットを飼っている家庭では適合率、再現率共に低く、そうでない家庭においてはこれらの指標は高い傾向にある。さらに、入浴行動については、行動時間のばらつきの割合が大きかったため、行動時間が少ない家庭においては評価指標が低い傾向にある。睡眠行動については、行われる時間が明確であることや人感センサ反応が少なくなることから、認識精度が高く、ばらつきが小さい傾向にある。以上のことから、提案システムで収集したデータから、72.3%の高い再現率で行動認識が可能であることを確かめた。一方で、実サービスへの応用のためには、適合率の向上が課題である。

3.5.2 生活データの欠損値補完による行動認識精度への影響

本章では、生活データの正解データ欠損に対して補完処理を行った上で行動認識を実施した。しかしながら、補完手法は様々であることから、今回実施した欠損値補完手法が妥当なものであるかを議論する。

表 5: 欠損値補完処理の有無による認識精度の比較

	適合率	再現率	F 値
全行動の平均値 (欠損値補完あり)	0.405	0.747	0.465
全行動の平均値 (欠損値補完なし)	0.334	0.654	0.375

表5に、提案する欠損値補完処理を行った上で行動認識を実施した結果と、補完せずに実施した結果の精度比較表を示す。なおここでは、欠損による影響が比較的少ない(非常に長期間、特定の行動ラベルが継続される等の明らかな異常値が少ない)家庭である3家庭分(ID01, ID02, ID03の家庭)を比較している。表より、欠損値補完を行うことで9%程度F値が改善していることが読み取れる。認識精度の高低により欠損値補完手法の有用性を決定することは難しいが、少なくとも本論文で用いた欠損値補完を適用することで行動認識精度の改善に寄与し、補完が有用であるといえる。

データセットにおいて欠損値が多い場合、その補完方法によって認識精度が上下することが想定される。したがって、正解データが不明な場合は、データそのものを利用しないようにするか、尤もらしい形で補完することが望ましい。しかしながら、行動認識モデルの学習のために利用する日常生活行動データの正解値の欠損補完は、一般に難しいことが知られている[71]。欠損値の補完方法は、欠損している変数の中央値や平均値で補完する単変量欠損値補完や、欠損していない変数に基づいて推定された値で補完する多変量欠損値補完が存在する。さらに、欠損値を単一の値で補完する単一代入法や複数の値を各欠損サンプルに代入する多重代入法が存在する。しかしながら、これらの従来的な補完方法や近年新たに提案される補完方法の殆どは、正解データではなく説明変数が欠損している場合に限定される。正解データが分からない場合における欠損値補完に対する研究も行われているものの、生活行動認識を扱う領域においては非常に少ない[72]。加えて、いくつかの研究では、加速度センサデータや環境センサデータなどのセンサデータに対する補完手法を提案しており、行動データのように、行動状態か否かを示す2値のデータ補完の手法に関する提案は少ない。

この要因として、日常生活データは潜在的な変数や外乱によって影響を受けやすいことや、データ収集のコストが非常に高いことが挙げられる。例えば、ある家庭における生活行動センシングにおいて、ある一ヶ月のうちにも先月までとは異なる来客や居住者の体調不良によって生活行動に変化が発生し、更なるその期間の行動ラベルが欠損している場合、過去のパターンを参考に欠損した真値を補完することは非常に難しい。宅内にカメラを設置することやウェアラブルデバイス

の装着等によって上記の課題を解決できるが、システムの受容性が課題となり、理想的なセンシングシステムの要件に合致しない。また、加速度センサデータのように、他のドメイン（モビリティ、スポーツ、モーションキャプチャ）でも大量のデータが収集されているセンサモダルにおいては、欠損値補完の場面においてもデータ転移や疑似データ生成が比較的容易である。一方で日常生活データは非常にプライバシー要求が高く、一般的に収集・公開されることは少ない。さらに、刻一刻と生活データが収集されることは稀であり、多くの場合はある時刻において、ユーザ自身の入力（アノテーション）に依存するため、データ収集コストが非常に高い。

本論文では、尤もらしい補完方法として、開始・終了片方だけの欠損の場合のように、補完に利用できる手がかりがある場合は補完し、手がかりがない場合は行動をしていないものとしてみなしている。また、理想的には、データ収集の時点でそもそも欠損値が発生しないようなインタフェースを備えたシステムであることが望ましい。そこで、第4章にて提案している複数居住者向けシステムでは、欠損値が発生しないような工夫としてフィードバックアプリケーションを導入している。

将来的には、より良い欠損値手法の提案に加えて、より欠損値が発生しにくいシステムの開発が必要である。その他にも、他家庭からのデータ転移手法の開発や、パターン認識によってそもそも行動ラベルが欠損している状態かどうかを判定するモデルを導入することや、教師なし学習の手法を利用して行動ラベルが無くとも学習に寄与できるデータの獲得手法の検討などによって、高品質な生活データのデータセット構築に繋がると考えられる。

3.6 関連研究との比較

本節では、コンセプト、実験条件、分析手法、結果について、関連研究との比較を行う。表6に関連研究と、各項目の比較を示す。また、SPHERE[68]では対象となる行動や詳細な分析結果について示していないため、Table 6では比較を行っていない。

3.6.1 コンセプト

Kasteren[34], ARAS[35], PlaceLab[36], CASAS[8]では, 一般家庭をスマートホーム化するキットの提案を目的としている. 中でも, 拡張性に着目したキットや, 複数居住者を対象としたキット, アノテーションの高品質化を目指すキットなど, 各提案ごとにコンセプトは異なる. 我々の提案システムもこれらのシステムと同様に, 一般家庭をスマート化することを目的としているが, 特に高齢者を含む, 全ての人々にとって使いやすいシステムであることを必須要件としている.

Sweet Home[38] や Domus[37] といったシステムは, スマートホーム環境におけるマルチモーダルなインタラクションを目的としたシステムを提案している. また, Markov Logic Network を利用した行動認識やコンテキストウェアインタラクション, 遠距離スピーチ認識の精度のベースラインを示しており, スマートホーム環境での研究として非常に価値がある. しかしながら, コンセプトや実験条件が異なるため, 比較対象として適切ではない.

3.6.2 センサ設置

Kasteren[34], Placelab[36], CASAS[8]で利用するセンサは, モーションセンサなどのバイナリセンサと少量の環境センサから構成している. Kasteren[34] や CASAS[8]では合計 20 個程度のセンサを利用しており, PlaceLab[36]では突出して大量のセンサを利用している. 一方で, ARAS[35]のシステムでは, 7種類のセンサをそれぞれ異なる場所に設置しており, より多様なデータを収集している. 提案システムでは, ARAS[35]やCASAS[8]と同様に合計 20 個程度のセンサを利用するが, エナジーハーベスティングで駆動し, メンテナンス不要な設計であることが他の研究と異なっている. 実際の一般家庭では, 行動が行われる場所は不明である上に, 行動に対応するセンサ設置は, 対象行動を増やすたびに大量のセンサを必要とするため, 望ましくない. 本論文は, 関連研究より一般に適応可能なセンシングキットが, 実際の環境でどの程度のセンシング能力を持つのかを示している点で価値があると考えられる.

3.6.3 アノテーション手法

CASAS[8], PlaceLab[36], ARAS[35]ではPCやPDA (Personal Digital Assistant) 上で動作するソフトウェアを操作する必要がある。また, Kasteren[34]では, Bluetoothヘッドセットを装着しておく必要がある。提案システムでは, 任意の場所に設置可能で, 高齢者にとっても直感的に操作可能な押しボタンを採用している。

表 6: 関連研究との比較

コンセプト	センサー設置	アプリケーション	対象行動	環境・データ	分析アルゴリズム・結果
Kaizeren [34]	高品質なアプリケーションのためのキット 設置時間: N/A	Bluetooth ヘッドセット	外出, トイレ利用 入浴, 睡眠, 朝食準備 夕食準備, 飲料準備	センシング期間: 28 日 実験環境: N/A (ある部屋と記載) 被験者数: 1 居住者数: 1	アルゴリズム: HMM, CRF 行動認識結果: HMM (正解率): 94.5% CRF (正解率): 95.6%
ARAS [35]	• カセンサー • 圧力マット • 接触センサー • 近接センサー • 超音波距離センサー • 照度センサー • 温度センサー • 赤外線受信機 設置時間: N/A	PC 上のソフトウェア	26 種類の ADL を収録したが, 分析上 6 種類に限定。 睡眠, 食事, 個人衛生 外出, リラックス, その他	センシング期間: 2ヶ月 実験環境: N/A (ある部屋と記載) 被験者数: 4 居住者数: 2	House A: アルゴリズム: HMM 行動認識結果: 61.5% (正解率) クロスバリデーション House B: アルゴリズム: HMM 行動認識結果: 76.2% (正解率) クロスバリデーション
PlaceLab [36]	• 状態変化センサー x 77 (居住者 1) x 84 (居住者 2) 設置時間: 3 時間	電子端末上のソフトウェア	多数であるが, 大部分は実際に行われていない。 居住者 1: 屋食準備, トイレ利用, 朝食準備, 入浴, 着替え, 身だしなみ, 飲料準備, 洗濯 居住者 2: 屋食準備, 音楽鑑賞, トイレ利用, 朝食準備 血洗ひ, テレビ視聴	センシング期間: 14 日 実験環境: N/A (ある部屋と記載) 被験者数: 2 居住者数: 1	被験者 1: アルゴリズム: NB (Naive Bayes) 行動認識結果: 64.3% (正解率) 被験者 2: アルゴリズム: NB 行動認識結果: 50.8% (正解率)
Sweet home [38] /Domus [37]	• スイッチセンサー x 8 • ドアセンサー x 6 • 赤外線センサー x 2 • マイク x 7 設置時間: N/A	スマートホーム環境下において 音声を利用した家電制御用データセット	睡眠, 休憩, 着替え, 食事準備, 食事, 洗濯, 個人衛生	センシング期間: 3 時間~6 時間 実験環境: スマートホーム 被験者数: 11~23 居住者数: N/A	アルゴリズム: MLN (Markov Logic Network), SVM, NB 行動認識結果: アルゴリズム: MLN - 85.3% (正解率) SVM - 59.6% (正解率) NB - 66.1% (正解率)
CASAS [8]	• 人感・照度センサー x 24 • ドアセンサー x 1 • リレー x 2 • 温度センサー x 2 その他データセットにより増減 設置時間: 1 時間程度	PC 上のソフトウェア	ベッド・トイレ間移動, 料理, 食事, 帰宅, 外出, 個人衛生, 電話, リラックス, 睡眠, 仕事	センシング期間: 1ヶ月 実験環境: スマート化されたアパート 被験者数: 18 居住者数: 1	アルゴリズム: SVM 行動認識結果: 58.9% (F 値) 5 分割交差検証
本研究	• 人感センサー x 10 (最大) • 照度センサー x 10 (最大) • ドアセンサー x 2 (最大) 設置時間: 45 分程度	押しボタン x 5 (各行動に対して)	入浴, 料理, 食事, 外出, 睡眠	センシング期間: 合計 2ヶ月 実験環境: 一般家庭 被験者数: 17 居住者数: 1 または 2	アルゴリズム: LSTM 行動認識結果: 40.7% (F 値) ホルドアウト検証

3.6.4 ターゲット行動

CASAS[8]では、居住者自身が、10種類のADLをアノテーションしている。なお、配布されているデータセットによってこれらの行動数は増減する。ARAS[35]では、26種類の行動を考慮していると述べているものの、実際に分析に利用されているのは特定の5行動+その他1種類の、合計6種類である。Kasteren[34]では、7種類の行動を考慮しており、これらはKatz ADL index[73]を参考にして決定していると述べられている。しかしながら、Kasteren[34]で選定した行動種類は、場所ごとに実施場所が明確に決まっているものに限定されており、認識しやすい行動であると言える。また、Katz ADL indexは高齢者向けの指標であるが、被験者は26歳の男性であり、高齢者をターゲットとした検討は十分でない。PlaceLab[36]は、ARAS[35]と同様に大量の行動を考慮しているものの、実際に学習に十分なデータ点数を得られたのは、最大8行動であると述べられている。

アノテーションを行う必要のある行動が増えるほど、アノテーション動作のための行動が必要となり、居住者の負担が大きくなる。居住者の負担が大きくなることで、アノテーション動作を可能な限り減らすような行動変容の発生が懸念される。そこで、提案システムでは、生活習慣に寄与すると考えられ、ヘルスケアなどのサービスへ適用しやすい、基本となる5つのADLを選定している。

3.6.5 データ収集環境

各関連研究におけるデータを収集した環境を比較する。図11に、提案システムの、あるターゲット家庭の間取りを示す。なお、kasteren[34]、ARAS[35]、CASAS[8]では、実験対象家庭の間取りは公開されているものの、Placelab[36]では間取りは示されていない。CASAS[8]について、複数居住者やペットの有無など、多数の一般家庭に設置した実績はあるものの、論文中[8]で分析に利用したデータはスマートアパート内で収集した18名の独居居住者の生活データである。したがって、結果として得られている行動認識精度は、間取りや家族構成が複雑な、一般環境で収集されたデータとは異なると考えられる。Kasteren[34]、ARAS[35]、PlaceLab[36]については、各論文中で述べられている結果が一般家庭にて収集されたデータかどうかの記述は無いが、いずれも1階建ての家屋である。

さらに、Kasteren[34]では、対象行動をキッチンの周辺および寝室、洗面所、トイレ、エントランスで行われる行動に絞った上で、それらの場所にセンサを集中的に取り付けた間取りを示している。ARAS[35]では、各家具に様々な種類のセンサを配置している。あるCASAS[74]のデータセットにおけるセンサ配置図も同様に、一つの部屋に大量のセンサを取り付けていることを示している。

本実験では、殆どのターゲット家庭が2階建てであり、アパートメントでないため、各家庭で間取りが完全に異なる。また、各部屋のセンサ設置数は最大で3個、合計で20個程度である。

3.6.6 行動認識結果

Kasteren[34]で示されている認識精度は、HMMとCRFで算出されており、それぞれ正解率で94.5%と95.6%であると報告されている。非常に高い認識精度であることが示されているが、センサ設置の間取りと、ターゲット行動が強く紐付けされている。ARAS[35]で示されている認識精度は、複数居住者に対応するHMMで算出されており、それぞれ正解率でHouse Aでは61.5%、House Bでは76.2%であると報告されている。なお、ARAS[35]では、行動ごとに対応付けてセンサ設置位置を決定していると述べている。したがって、適切なセンサ配置場所の決定や、取得したい行動の種類が増えるごとに、より大量のセンサ設置が必要である。PlaceLab[36]で示されている認識精度は、NB (Naive Bayes)で算出されており、1人目が64.3%、2人目が50.8%であると報告されている。Sweet home[38]で示されている認識精度は、MLN (Markov Logic Network)とSVM、NBで算出されており、85.3%と比較的高い。

提案手法では、40.7%のF値で行動認識が可能である。相対的な認識精度は劣るものの、スマートホーム等の整備された環境でない一般環境でのセンシングである点や、システム設置の容易さ・運用の容易さは最も優れているといえる。したがって、今後の課題として、分析手法やタスク設計の工夫、利用するセンサの取捨選択等を通じて、システムの受容性の高さを保ちつつ精度を向上させることが重要である。

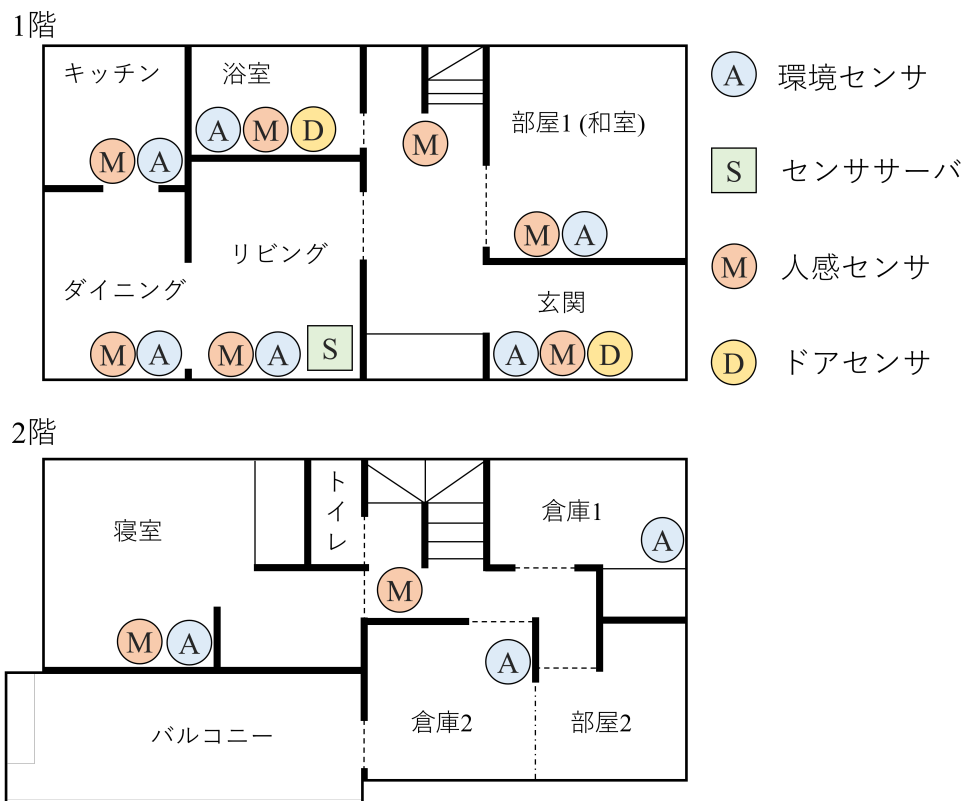


図 11: 一実験対象家庭の間取り模式図

4. 複数居住者を対象としたデータ収集と評価

3章にて述べた一般家庭における実験の結果を基に、複数居住者向けのセンシングシステムとして提案システムに修正を加えた。本章では、新たな提案システムの修正点を述べるとともに、再度実施した実験の概要と、行動認識結果を述べる。

4.1 実験目的

本実験の目的は、3章にて述べた先行実験の結果を踏まえて改善した提案システムと手法により、複数居住者家庭における居住者のセンシングおよび、より高精度な行動認識が可能なデータを収集することである。先行実験では、単身居住者向けの日常生活行動をセンシングシステムを開発し、その評価を実施した。しかしながら、実際の一般環境では複数居住者であることも多いため、複数居住者家庭に適したセンシングシステムおよび行動認識手法が必要である。そこで本実験では、センシングシステムの改良と、後述する、複数居住者向けの行動認識タスクである協調行動認識タスクを定義した。協調行動認識では、個人識別が必要な、家庭内の個人の行動を認識することを目的にするのではなく、非接触センサのみで実現可能な、家庭ごとに実施される行動を認識することを目的にしている。

具体的な先行実験との違いとして以下のことが挙げられる。先行実験では、各家庭に配布したアノテーションボタンが5個1組のみであり、居住者を分離した行動データの収集が不可能であった。しかしながら、複数居住者家庭は一般的である上に、健康寿命延伸の対象となる高齢者世帯には、夫婦で居住するケースが多いと考えられる。さらに、アノテーションボタンを押した際にフィードバックが得られないため、ボタンを押したかどうか分かりにくいことが、先行実験の被験者からの改善案として多く挙げられた。連続したボタンの押下や押し忘れは、行動データ欠損を防ぐ上で重要である。したがって、本実験では、それらの課題を改善したセンシングシステムを利用して再度データ収集実験を実施した。なお、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(承認番号:2018-I-26)。

4.2 実験手順

先行実験と同様に、実験は、居住者に実験の説明を行い、同意を得てから、センサ設置位置の決定、センサの設置、動作テストを行った。この際、設置にかかる手間を関連システムと比較するために、各家庭においてシステム設置に関する所要時間を計測した。

表7に、センサの設置位置決定、センサの設置、動作テストに費やした時間を示す。その結果、すべての家庭において平均で40.4分の設置時間であった。全ての設置は、事前にシステムの設置経験がある人物が3名で行った。また、センサの設置位置は、各家庭の居住者と頻繁に利用する部屋と利用しない部屋について話し合い、決定した。CASAS [8] のシステムでは、センサの設置のために、およそ1時間程度必要であることが示されている。そのため、提案システムは、センサ設置位置の決定から、動作テストまで、比較的短時間で達成できるといえ、より定量的に要件2を満たすことを確かめた。

先行実験からの変更点として、各家庭に配置するアノテーションボタンを、各居住者ごとに5行動、合計10台配置しており、実験期間は、各家庭1ヶ月間としている。

表7: システム設置の所要時間

ID01	ID02	ID03	ID04	ID05	平均
48分	30分	36分	43分	45分	40.4分

4.3 実験対象

実験の対象家庭となる家庭は、公募によって決定した5軒の一般家庭である。そのうち、4家庭が夫婦で暮らしている複数居住者家庭であり、1家庭が単身家庭であった。

表8に、実験を行った各家庭の居住者数、各種センサの設置数、訪問者の頻度、ペットの有無、特記事項について示す。提案システムは、居住者が感じる監視感

低減のため、可能な限り少数のセンサで行動認識を行うことを目指している。したがって、先行実験と同様に、モーションセンサ、環境センサの設置数を最大10個とし、ドアセンサの設置数を最大2個とした。また、訪問者の制限は特に行っておらず、実験期間中においても、自由に入出入りすることを許可している。訪問者もADLを行う可能性は存在するが、訪問者は行動アノテーションを行っていない。なお、本実験は、2020年6月11日から7月15日にかけて、COVID-19の影響下で行われた。

表 8: 第二回実験における各家庭の特性

	居住者数	人感センサ	環境センサ	ドアセンサ	訪問者	ペット	特記事項
ID01	2	7	7	2	頻繁に孫、友人	無	-
ID02	2	10	10	2	ほぼ無	無	-
ID03	2	10	10	2	ほぼ無	兎	自宅で入浴することが少ない。
ID04	1	7	8	2	ほぼ無	猫	集合住宅の一室に居住している。
ID05	2	10	10	2	ほぼ無	無	-

4.4 センサ設置要件

図 12 に、先行実験で被験者から得られたフィードバックを基に、改善した提案システムの概要図を示す。改善した提案システムは、先行実験で利用したシステムをベースに構築している。したがって、本節では、修正を加えていない人感センサ、環境センサ、データサーバ以外の構成要素に関して述べる。

4.4.1 ドアセンサ

先行実験において、ドアセンサは、設置位置や家庭の間取りによってはデータサーバまでデータが届かず、欠損してしまう現象が散見された。特に、金属製パーツを備えるドアへ設置した場合に顕著であり、ドアの金属部分に反射した信号が、送信したい信号と干渉し合うことや、アンテナの形状に起因する通信強度低下が原因であると考えられていた。そこで、本実験で利用するドアセンサでは、センサ内部の通信用アンテナの形状を、指向性を高めるよう変更した。これにより、

間取りが非常に広い等の、一部の特殊な家庭以外の欠損がなくなり、行動認識にドアセンサデータを利用することが可能となった。

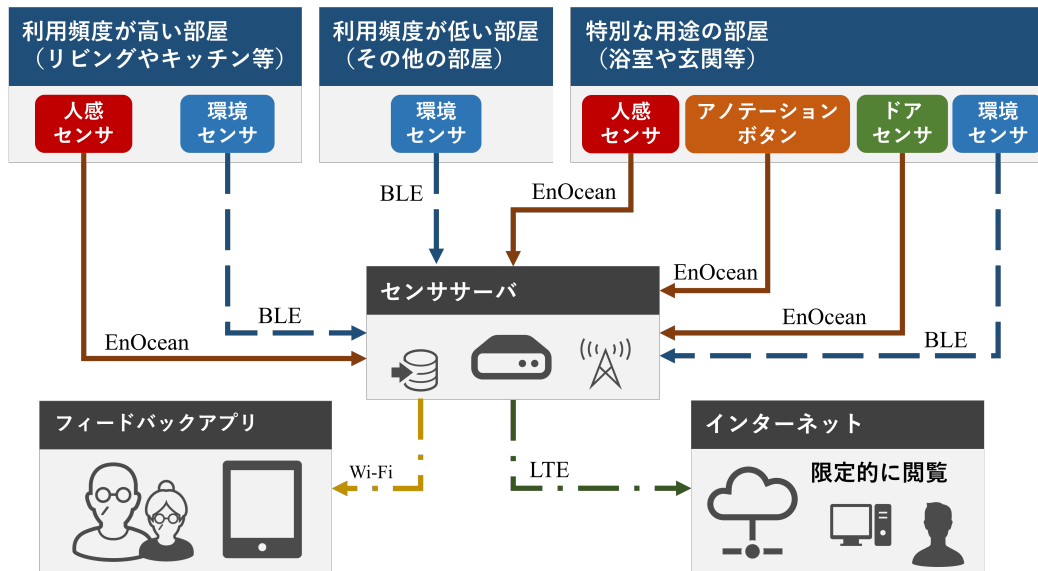


図 12: 改善した提案システム概要図

4.4.2 アノテーションボタン

先行実験では、各家庭ごとに5つのアノテーションボタンを利用していた。この方法では、各居住者がアノテーションボタンを共有する必要があり、居住者ごとに行動を分離したアノテーションが不可能であった。したがって、本実験では、各居住者に対して、アノテーションボタンを行動数分である5個利用した。これにより、居住者ごとの行動が分離でき、独立した複数居住者の行動認識に必要なデータの収集が可能となった。

4.4.3 フィードバックアプリケーション

先行実験を実施した際に、実験に関する被験者からのフィードバックを収集した。その結果、アノテーションボタンを押下した際に、被験者自身で本当に押下できたか分かりにくいという意見が多数寄せられた。押下したかどうかの判断が

できない場合、複数回のボタン押下や、被験者自身が気になった際に、念の為ボタンを押下することに繋がるため、想定外のノイズ・欠損データが発生しやすくなる。

そこで本実験では、アノテーション用押しボタンを押したことを居住者自身が確認するために、タブレット端末上で動作するフィードバック用のアプリケーションを新たに作成した。図 13 に作成したアプリケーションの UI を示す。タブレット端末上の UI では居住者ごと、行動ごとに仮想ボタンが存在しており、現実の押しボタンの操作と連動して、アイコンが点灯・消灯する。アイコンの点灯・消灯は、タブレット端末が毎秒、データサーバに対して行動状態を問い合わせ、受信した行動状態を基に行う。さらに、仮想ボタンの状態変化に応じて、音声を再生する機能を備えている。例えば、睡眠状態が解除された場合に、アプリケーション上の仮想エージェントは「おはようございます」と発話し、外出状態が解除された場合、仮想エージェントは「おかえりなさい」と発話する。このように、本アプリケーションは押しボタンの状態変化を、視覚的、聴覚的に居住者へフィードバックできる。

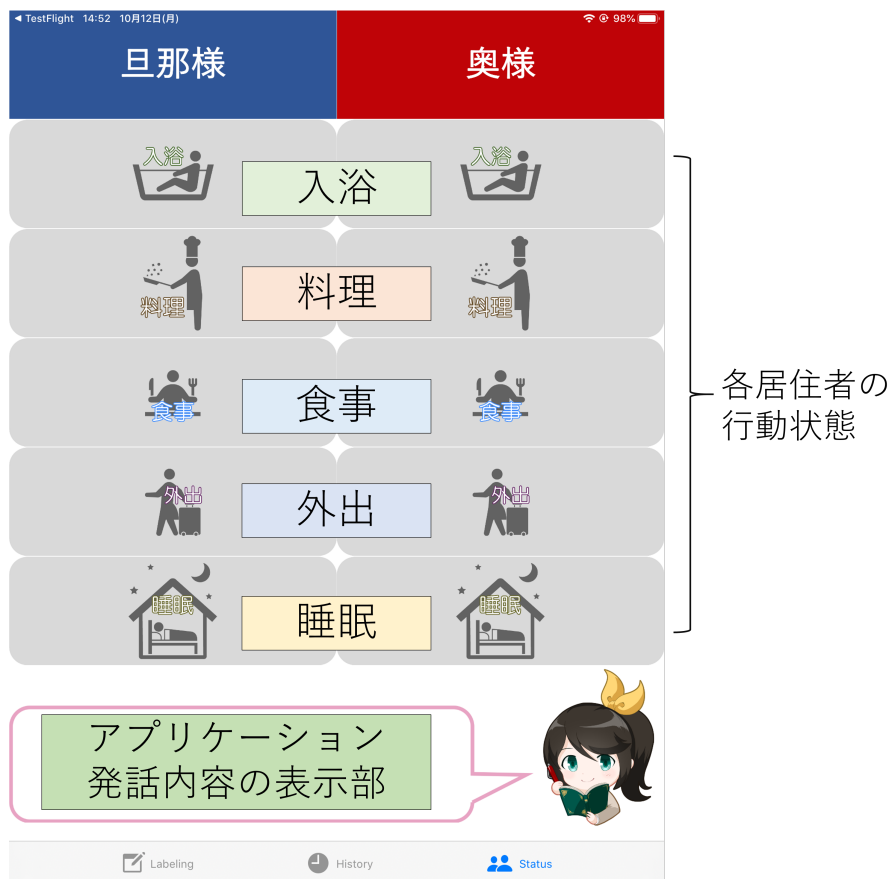


図 13: フィードバックアプリケーションの UI

4.5 分析手法

4.5.1 協調行動認識の定義

行動認識の種類はドメイン・ターゲット・認識レベルに区別でき、それぞれ複数存在する。図 14 に行動認識手法の種類を示す階層図を示す。階層図の最も上位には、何を行動認識の対象とするかを示すドメインレベルの区分がある。具体的には、宅内の行動を対象として実施する行動認識は「宅内行動認識」、立つや座る、歩くなど人間の基本的な動作を認識する行動認識は「人間行動認識」と区別されることが一般的である。さらに、宅内行動認識の中でもターゲットレベルとして、単身居住者家庭を対象とする行動認識と複数居住者家庭を対象とする行

動認識が存在する。複数居住者家庭は主に普通の居住者が2人以上の場合を対象としており、代表的な例として、老夫婦世帯（高齢居住者が2名）、2世帯（親世帯と子世帯が同居）、核家族世帯（夫婦のみか、夫婦とその子供のみで2名以上）などが存在するが、本研究では主に居住者が2名の老夫婦世帯や核家族世帯を対象としている。また、単身居住者家庭の例としては、若者の一人暮らしのような家庭から、配偶者を亡くした高齢独居家庭などが挙げられる。最下層の認識レベルとして、特に複数居住者家庭において、行動者－行動種類認識・行動種類認識が存在する。行動者－行動種類認識は、誰がどの行動を実施しているのかを認識する行動認識手法であり、一般的に個人識別が可能なセンシングシステムとセットで実施される。メリットとして、得られるデータが詳細であることが挙げられ、特に複数居住者家庭内の特定の個人を対象としたサービスを提供したい場合に有用である。一方で、個人識別が可能なセンシングシステムの多くは映像データやウェアラブルデバイスを必要とするため、一般的にシステムに対する精神的・肉体的な抵抗感が高く、受容性が低いという課題がある。行動種類認識では、その家庭内で、どのような一つの行動が実施されているのかのみを推定する認識手法である。メリットとして、低侵襲なセンサを設置するのみでよく、一般的にシステムの受容性が高い。一方で、一つの家庭につき一つの行動を推定するため、得られる情報量は比較的少ない。

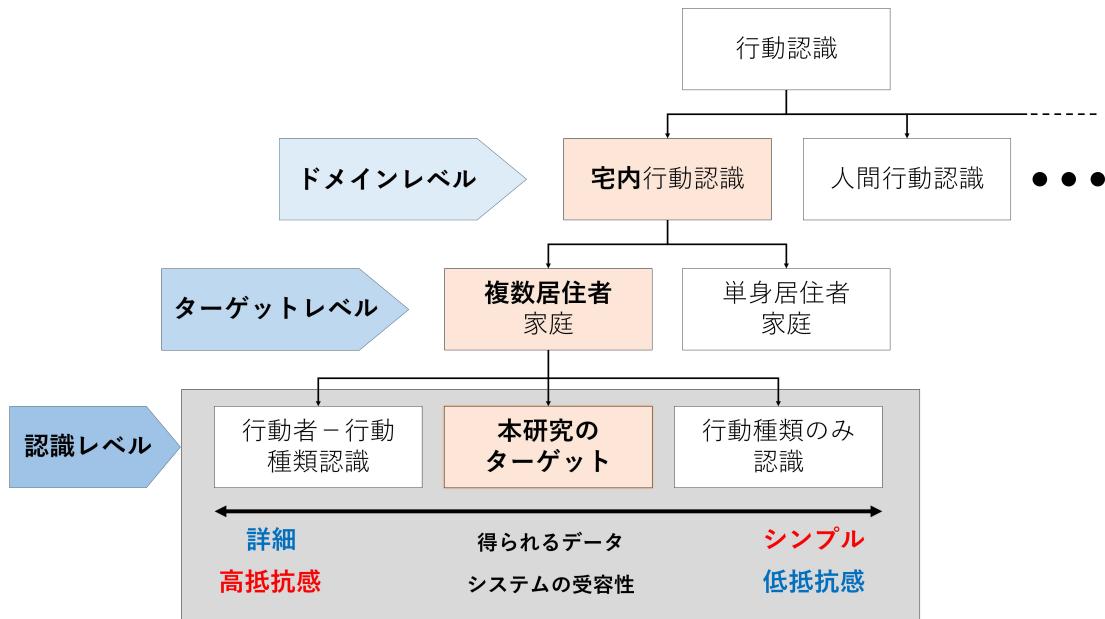


図 14: 行動認識手法の階層図

本節では、認識レベルにおいて行動者-行動種類認識と行動種類のみ認識の中間的な手法として、行動種類認識のメリットである高いシステム受容性を保ちつつ、行動者-行動種類認識の詳細なデータ収集を目指す、協調行動認識手法を提案する。協調行動認識では、対象とする宅内行動のうち、どの行動とどの行動が並行して行われているのかを推論する。具体的には、ある家庭内で”料理”と”食事”が同時に行われている場合、行動種類認識では、”料理”もしくは”食事”の一つのラベルを推論する。一方で協調行動認識では、行動主を指定せずに、”料理”と”食事”が同時に行われていることを推論する。これによって個人識別を伴わずに、多くの情報を得ることができ、特に複数居住者家庭において、電力需要予測や家庭ごとの活動量計測への応用が期待できる。

図 15 に、協調行動認識タスクで推論する行動ラベルの変換表を示す。この表は、協調行動認識タスクで認識する対象クラスである ADL についてまとめており、最終的な認識フローの出力として、入浴・料理・食事・外出・睡眠を組み合わせた 15 クラスと、それらに該当しない場合に付与されるその他 1 クラスを合わせた、合計 16 クラス分類を実施する。

		居住者Aの行動・行動の推定結果					
		入浴	料理	食事	外出	睡眠	その他
居住者Bの行動・行動の推定結果	入浴	入浴	入浴料理	入浴食事	入浴外出	入浴睡眠	入浴
	料理	入浴料理	料理	料理食事	料理外出	料理睡眠	料理
	食事	入浴食事	料理食事	食事	食事外出	食事睡眠	食事
	外出	入浴外出	料理外出	食事外出	外出	外出睡眠	外出
	睡眠	入浴睡眠	料理睡眠	食事睡眠	外出睡眠	睡眠	睡眠
	その他	入浴	料理	食事	外出	睡眠	その他

16クラス分類

図 15: 協調行動認識タスクに向けたラベル変換表

4.5.2 行動の共起性を利用した協調行動認識手法

本論文では、従来一般的に行われている個人に着目した行動認識ではなく、ある家庭の中でどのような行動が並行して行われているのかを認識する、家庭単位の行動に着目した協調行動認識の実現を目指している。家庭単位の行動認識精度向上のためには、従来の個人で完結する行動認識手法ではなく、複数の居住者が互いに影響し合う行動（共起行動）を考慮できる手法の開発が望ましい。そこで、本節では、複数居住者の過去の行動をそれぞれ明示的に階層的な学習フローに組み込むことで、複数居住者の行動の共起性を考慮する学習手法を提案する。なお、非接触センサで構成されたセンシングシステムから得られるデータでは個人識別は難しいため、各居住者に対応付けられたADLを推論することは難しい。しかしながら、提案するセンシングシステムを含む実際のセンシング環境では、居住者

ごとに自身の行動をアノテーション出来るのが一般的である。例えば、提案システムでは、各対象 ADL 用のアノテーションボタンが各居住者に配布されており、正解データレベルでは居住者ごとに区別したデータが得られる。したがって、本提案では、中間表現として各居住者の行動認識を実施するものの、最終的な推論結果は居住者を区別しないような協調行動認識タスクを実施する手法を提案する。

提案手法のコンセプトに関して説明する。複数居住者家庭における行動のシチュエーションは、主に、(1) 複数の居住者が同じ行動を同時に行う、(2) 複数の居住者が異なる行動を同時に行う、(3) 複数の居住者が、互いに相互作用して異なる行動を行う、の3つに区別される。具体的な例として、深夜帯の睡眠などは(1)のカテゴリ、一人が寝ている間にもう一人が入浴するシチュエーションなどは(2)のカテゴリ、一人が、食事をしているもう一人のために料理をしているシチュエーションなどは(3)のカテゴリに分類される。一般に、複数の人物が別々の行動を行っている場合、設置型センサのみを利用するセンシングでは、どちらがどの行動を実施しているのかを分離することは困難である。しかしながら、我々は、別々の行動を行う際にも、(3)のカテゴリに属する行動のように、各居住者が互いに何らかの共通意識を持っている場合が存在すると考えた。このような、各居住者が共通意識を持って行う行動を認識するためには、各居住者の各行動の共起性を考慮する必要がある。

以下に、提案手法である行動履歴を考慮した学習手法について説明する。図 16 に示す複数居住者の行動履歴を考慮した学習手法では、個人単位の学習で得られる、2値分類モデルから出力される過去の各行動の確信度情報を基に、現在の行動を推定するモデルである第二モデルを作成し、最終的な推定結果の出力に利用する。本手法は、機械学習モデルを2種類利用して、各居住者の互いの過去の推論結果を現在の行動を推論するために利用する点で他の手法とは異なる。第一モデルは、センサデータから2値分類で行動を認識する機械学習モデルで、各居住者の各行動ごとに作成する。第一モデルの推論結果はメモリ上にバッファリングされ、居住者の過去の行動推論結果を示す時系列情報として保持される。この保持された時系列情報は、後述する第二モデルの入力として利用される。第二モデルは、時系列情報としてバッファリングされた第一モデルの推論結果を入力とし

て、各居住者の現在の行動を推論する機械学習モデルである。具体的には、第二モデルは、一方の人物の行動を認識するために、両方の人物に対して推定された各行動の確信度の履歴を特徴量として入力し、各居住者の現在の行動の確信度を出力する。これらの第一モデルと第二モデルが出力する各行動クラスの確信度を、各クラスごとに乗算し、確信度が最大となるクラスを推定結果として見なすことで、協調行動認識タスクを実施する。これにより、各居住者が協調して行う行動、共通意識を持って行う行動の認識精度向上が期待できる。

また以下に、提案手法に対するベースラインについての概要を述べる。図 17 に示す従来手法は、リサンプリングした人感センサ、ドアセンサ、環境センサデータを特徴量として、家庭単位で各行動ごとに2値分類を行う一般的な協調行動認識タスクに対する機械学習手法である。図 18 に示す家庭単位の学習手法は、従来手法に対して、宅内 ADL 認識に適した特徴量を抽出し行動認識を行う。宅内 ADL 認識に適した特徴量として、具体的には、最後にドアを開閉してからの経過時間や人感センサの反応回数の総和などが該当する。この手法では、個人を区別せず、ある家庭で対象となる行動が行われているかどうかを認識する。最終的には、各モデルから出力される結果を足し合わせることで、家庭単位での行動認識結果に変換する。この手法は、家庭ごとに配布されたアノテーションボタンが居住者ごとに分離されておらず、同じアノテーションボタンを各居住者が利用するようなデータが得られる場合に実施される。図 19 に示す個人単位の学習手法では、個人ごとに異なる ADL の真値データを基に学習した2値分類モデルである、第一モデルを利用して行動認識を行う。その後は家庭単位での行動認識結果と同様である。この手法は、一般的な宅内 ADL センシングシステムの利用時に得られるデータを学習へ利用することを想定しており、家庭ごとに配布されたアノテーションボタンが居住者ごとに分離されている場合に実施される。

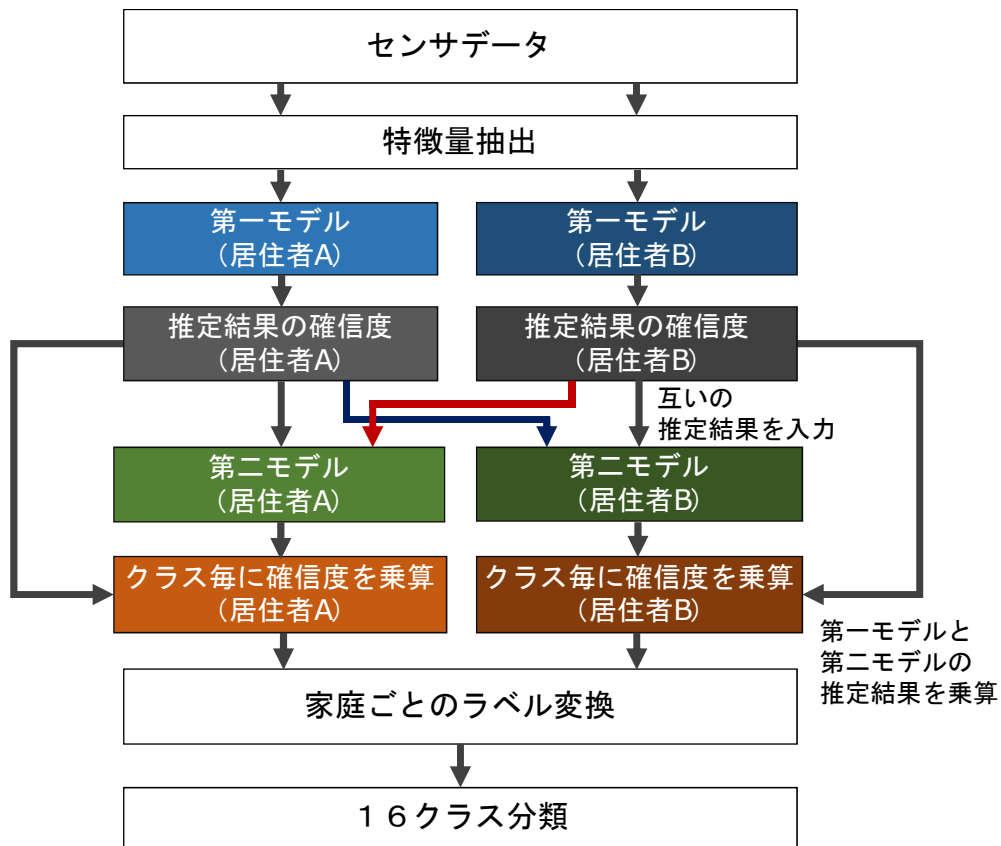


図 16: 複数居住者の行動履歴を考慮した学習手法

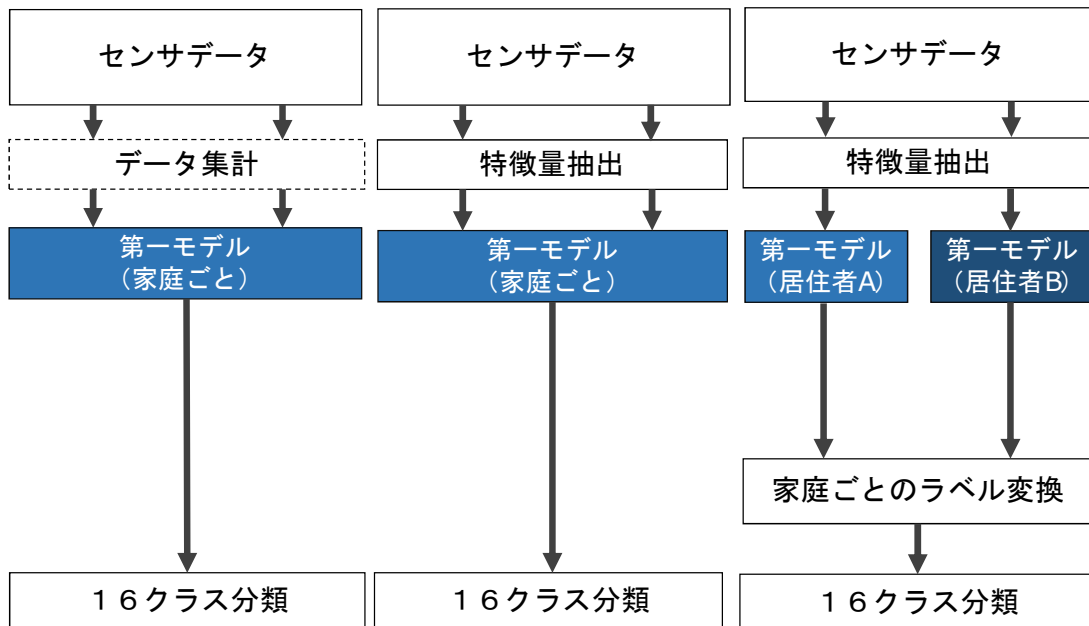


図 17: 従来手法 図 18: 家庭単位の学習手法 図 19: 個人単位の学習手法

4.5.3 行動認識アルゴリズム

提案手法において、第一モデルおよび第二モデルは任意の機械学習モデルを利用できるが、本節では、代表的なアルゴリズムとして、第一モデルは複雑なセンサデータ間の関係から有用な特徴を抽出することを期待し、DNNを利用する。また第二モデルは比較的データが少なくとも過学習しにくい推論を期待し、ランダムフォレストを利用する。図 20 に、第一モデルとして提案手法で利用する DNN の構成を示す。DNN は入力層、全結合層、バッチ正規化層、ドロップアウト層、全結合層、出力層から構成される。出力層は、2 値分類で行動認識結果を出力する。各行動ごとに DNN から出力された結果は、特徴量として、第二モデルであるランダムフォレストモデルに入力する。ランダムフォレストは、Python パッケージである scikit-learn³で実装されているモデルを利用する。ここで、モデルのハイパーパラメータは、グリッドサーチ法により、ID01 の ADL データを入力した場

³<https://scikit-learn.org/stable/>

合に決定される値を利用する。表 9 に、グリッドサーチ法により探索した範囲と、決定した値を示す。なお、探索するハイパーパラメータの範囲は経験的に設定しており、表に記載していないハイパーパラメータは、scikit-learn のデフォルト値を利用する。

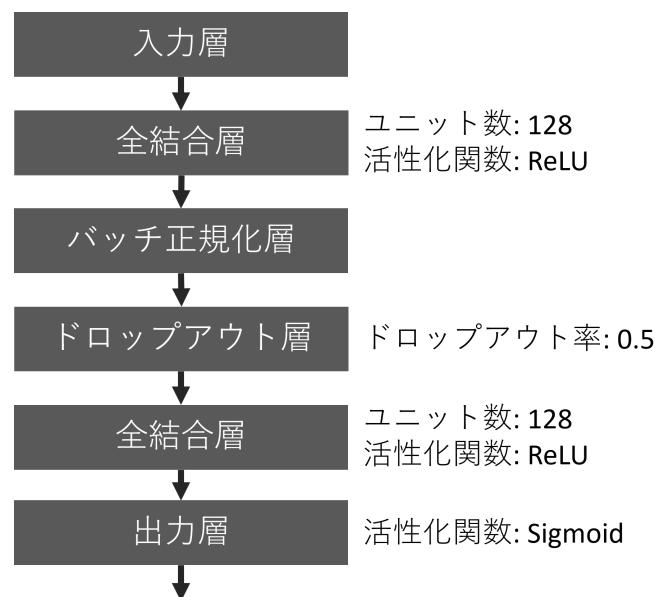


図 20: DNN モデル構成

表 9: ランダムフォレストのハイパーパラメータ

パラメータ	説明	探索範囲	決定値
max_depth	木の最大深さ	1, 3, 5	5
min_samples_leaf	葉ノードに属するサンプル数の最小値	2, 4, 6, 8, 10	6
min_samples_split	中間ノードに属するサンプル数の最小値	2, 3, 4, 5	5

4.5.4 評価手法

訓練データ、バリデーションデータ、テストデータの位置を固定したホールドアウト法によるモデルの評価では、各区間でのデータの偏りが存在する場合、モデルの妥当な評価が難しい。本実験では、一般家庭という通常通りの自然な環境

でデータ収集を行っていることから、ある日のテストデータの分布が、その他の日のデータ分布と同じである保障がない。そこで、図 21 に示すように、データの時系列性を保持したまま交差検証を行う。はじめに、合計 30 日間の ADL データを 3 日ずつに分割し、そのうちの 8 割を訓練データ、1 割を検証データ、1 割をテストデータとした上で、F 値などの評価指標を算出する。

その後、検証データの位置を固定したままテストデータの位置をずらしていく。この際、検証データの位置も同時にずらすと、合計 90 通りの機械学習モデルを構築する必要がある。したがって、検証データは時系列的に最後の 3 日間のデータとして固定している。結果として、それぞれ算出した評価指標の平均を算出し、平均値をモデルの性能とする。

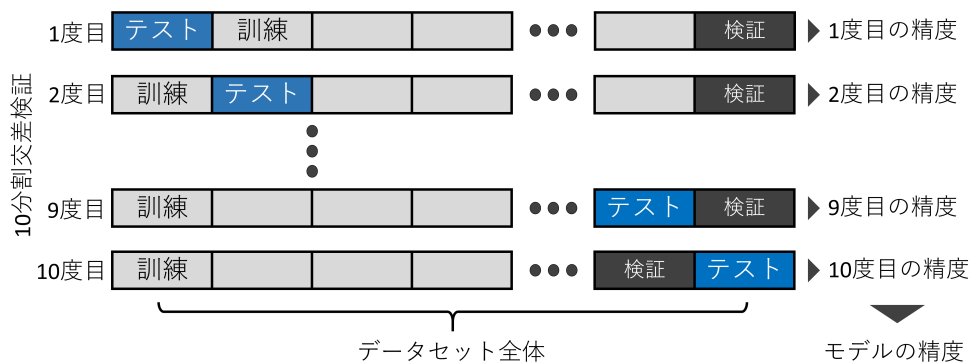


図 21: クロスバリデーション手法

4.6 データ収集結果

設置したシステムによるデータ収集結果について述べる。本実験で利用するシステムでは、アノテーション忘れ等の人為的なミスを防止するために、アノテーションフィードバック用アプリケーションを備えている。フィードバックアプリケーションの効果を確かめるために、前章で述べた一般家庭での実験時に見られた行動アノテーションのミスと思われる外れ値的な行動数に対して、本実験で見られた外れ値的行動数を比較する。なお、ここで外れ値行動とは、第 3 章にて定義した欠損値補間の対象となる見かけ上アノテーションミスと判断できる行動ラ

ベルを意味する。具体的には、入浴・料理・食事行動は4時間以上、睡眠行動は18時間以上連続して行われている場合、アノテーションミスの可能性が高いため、外れ値行動としてみなす。外出は、継続する時間が個人に強く依存することから、外れ値行動の対象からは除外している。

図 22 に、本実験を通して各家庭ごとに見られた、外れ値行動の数を示す。前章にて述べた実験の結果である図 10 と比較して、アノテーションミスと思われる外れ値行動が減少していることが読み取れる。実際には実験期間や居住者数の大小はあるものの、実験期間一日あたりの外れ値行動数は全ての家庭と行動を平均して8割程度減少した。以上のことから、フィードバックアプリケーションの運用によりアノテーションミスに起因する外れ値行動ラベルの発生を抑制できることが示唆された。また、図より、外れ値行動になりやすい行動は食事であることが読み取れる。今回のセンシング対象行動は入浴・料理・食事・外出・睡眠であるが、料理・食事の行動は一般的に一日に3回実施する。さらに、料理行動はキッチンで行われることが一般的であり、食事行動はダイニングもしくはリビングで行われることが一般的である。キッチンでは基本的には料理行動しか発生しないのに対して、ダイニングやリビングは家族の憩いの場となることも多く、食事行動以外が発生することも多い。すなわち、食事行動の開始・終了はその他の行動と比較して、時間的・空間的な区切りが少ないといえる。このような区切りが少なく、他の行動にシームレスに移行しやすい食事行動の特性が、外れ値行動の数に表れていると考えられる。今回の対象行動以外にも、テレビ視聴行動やスマートフォン利用行動等の視聴覚的な行動や、掃除等の時空間的な区切りが比較的少ない行動はアノテーションミスの可能性が高まると考えられる。




図 22: 各家庭各行動における外れ値行動数

4.7 データ前処理

本分析では、先行実験で利用した分析手法よりも高い行動認識精度を得るために、幾つかの新たな特徴量を生成している。はじめに、行動が行われる時間範囲や行動の変化の傾向を考慮し、1分間のセンサ反応の合計を、それぞれ一つの時間窓に格納した。環境センサはサンプリング周期が3分間であるため、前値埋めにより1分間の時間窓に対して補完を行っている。また、ドアセンサは、センサ本体が磁石部分と離れるように動作した場合に1のフラグを送信し、磁石部分と近づくように動作した場合に0のフラグを送信する。そこで、ドアが閉じられる場合の0のフラグを機械学習モデルに有意に学習させるために、ドアセンサの状態が前回のフラグから変化した際に、新たなフラグを生成し、学習のための特徴量として利用している。その他、各ドアセンサに対して、最後のセンサ反応からの経過時間を特徴量として生成している。

また、人感センサに関する追加特徴量として、外出を認識するための特徴量を生成する。非接触センサのみから構成されるシステムを利用する場合、複数居住者家庭において、片方の居住者の外出を認識するのは困難である。単身居住者を

対象とする場合と異なり，一方の居住者が外出していても，もう一方の居住者によって人感センサ反応が発生するためである．したがって，時間窓内において，同時に反応した人感センサの個数および全ての人感センサの反応回数を，それぞれ新たな特徴量として学習に利用する．なお，人感センサごとの対数変換値，3時点前までのラグ特徴に加えて，2センサ間の除算以外の四則演算結果もそれぞれ新たな特徴量として生成している．

人感センサ，環境センサに共通する特徴量として，四分位数の1.5倍までの範囲を基にした一般的な外れ値検知手法による外れ値フラグの生成や，10%から90%まで，10%刻みのパーセンタイルに対するフラグの生成を行う．

時間特徴量として，先行実験では秒数を0から86390秒まで，カウントアップして特徴量としていたが，実際には時間は，1日毎に離散的な関係ではなく，周期的で連続的な関係を持つ．したがって，秒数を1日毎に正弦波に変換し，前日の終了時刻が次の日の開始時刻に連続的に遷移することを考慮できるような特徴量を生成した．また，学習効率向上のために，早朝4時から7時までの区間や，6時から9時までの区間などを，それぞれ早朝フラグ，朝フラグなどとして時間区分をビンニングし，特徴量として格納している．

学習の前には，これら全ての特徴量に対して標準化処理を行っている．

4.8 行動認識結果

本節では，各種ベースラインと提案手法を比較する分析と，提案手法にて利用する2つのモデルを組み替えたときの影響を確かめる分析を実施した．表10に，4.2節にて述べた，家庭単位の学習手法，個人単位の学習手法，複数居住者の行動履歴を考慮した学習手法における，各家庭に対する入浴，料理，食事，外出，睡眠，協調行動認識タスクを実施した結果を平均した重み付きF値を示す．なお，特に代表的な機械学習モデルとして，第一モデルにDNN，第二モデルにランダムフォレストを利用している．ここで，考慮する各居住者の行動履歴長さは，30分間と設定している．また，ID04の家庭は，データを収集していたものの，単身家庭であったため，分析対象として除外している．全体として，入浴・外出・睡眠行動の認識精度が高く，料理，食事の認識精度が低い傾向が見られた．全ての

家庭、行動における平均重み付き F 値は、個人単位の学習手法よりも、5%程度高く、平均で 66.7%であった。CASAS[8] のシステムを利用して収集された ADL データによる結果と比較しても、高い認識結果であった。

次に、家庭ごとの認識精度を比較する。ID01 の家庭では、頻繁に子供やその家族らが訪問していたことから、ノイズとなるセンサの反応が比較的多いと考えられる。訪問客はアノテーションを行わないことに加えて、普段居住者が行うような周期的な行動はあまり行わない。その一方で、実際には人間が行動を行っており、センシング対象の居住者がその行動を行っているかのようなセンサ反応を見せることから、行動認識モデルに対しては非常に強いノイズとなる。したがって、足音情報を利用する個人認証技術や、低解像度サーモセンサなどを配置し、より詳細な行動を認識することで、センシングしている対象の特定が必要である。ID03 の家庭では、居住者が、普段家庭で入浴せず、屋外のフィットネスクラブの風呂を利用していることから、入浴行動のサンプルが少なく、認識精度が低いと考えられる。本実験で対象としている行動は、一般的な家庭でほぼ毎日行われると想定される行動である。そのため、応用するサービスによっては、対象行動から入浴行動を外した分析も妥当である。その際に、自身でセンシングしたい行動の選択や、普段行わない行動を除外が可能なシステムが求められる。ID02 の家庭では、これらの精度低下要因は少なく、比較的周期的な生活を送っていたことから、認識精度が高くなったと考えられる。なお、ID05 の家庭のみ、他の家庭よりも間取りが広く、長距離の通信が必要であったことから、ドアセンサデータの欠損が存在していた。したがって、外的な精度低下要因は少ないものの、センサデータの欠損が若干の精度低下に寄与したと考えられる。

表 10: 協調行動認識のクロスバリデーション結果

	家庭単位の学習			個人単位の学習			行動履歴を考慮した学習		
	適合率	再現率	F 値	適合率	再現率	F 値	適合率	再現率	F 値
ID01	0.712	0.521	0.571	0.681	0.575	0.602	0.681	0.657	0.657
ID02	0.772	0.587	0.636	0.723	0.627	0.652	0.746	0.708	0.713
ID03	0.677	0.478	0.525	0.666	0.541	0.569	0.668	0.626	0.631
ID05	0.696	0.535	0.573	0.699	0.619	0.642	0.707	0.662	0.667
平均	0.783	0.528	0.576	0.692	0.590	0.616	0.701	0.664	0.667

上述した結果は、第一モデルに DNN、第二モデルにランダムフォレストを利用した場合の結果であった。表 11 に、提案手法において第一モデルの機械学習アルゴリズムと、第二モデルのアルゴリズムを変化させた場合の結果を示す。なお、それぞれロジスティック回帰 (Logistic Regression)、ランダムフォレスト、DNN の組み合わせによって、各家庭平均の重み付き F 値を算出している。また、ロジスティック回帰・ランダムフォレストのハイパーパラメータは scikit-learn のデフォルトパラメータを利用しており、DNN のハイパーパラメータは 20 に示したものと同様である。結果の表から、第一モデルとして DNN、第二モデルとしてランダムフォレストを利用するパターンが、平均精度が最も良い事が読み取れる。特に、第二モデルとしてランダムフォレストを利用する場合は全体として精度が安定して高いことが分かる。この理由として、今回第二モデルに入力する各居住者の過去の行動系列データはセンサデータよりもシンプルであり、センサデータから特徴を抽出するのに必要なほど複雑なモデル表現を必要としないことが考えられる。特に、DNN は複雑なデータの特徴を抽出するのに有用であるが、比較的複雑でないタスクやデータ数が学習に十分でない状況では過学習が発生しやすく、適していないと考えられる。

表 11: 第一モデルと第二モデルを組み替えた結果の各家庭平均重み付き F 値

2nd model 1st model	Logistic Regression	Random Forest	DNN
Logistic Regression	0.614	0.647	0.595
Random Forest	0.651	0.658	0.605
DNN	0.644	0.667	0.632

4.9 考察

メンテナンスフリーかつ、設置の負担を考慮する、センシティブなデータを収集しない、シンプルなシステムから収集されたデータとしては、十分な精度で複数居住者の ADL 認識が可能であることが示された。従来のスマートホームキットの提案は、実際の一般家庭にシステムを設置して収集されたデータを基にしたものは少なく、自然な環境下での検討の余地が十分にある。今回実施した実験では、実際の一般家庭への設置を想定し、実験参加同意を得た直後に、平均 40 分程度の短時間でセンサ設置位置決定、センサ設置、センサテストを行っており、容易にセットアップが可能である。また、センサ設置後、センサの不具合などによるトラブルは一切なかった。したがって、一般環境に普及させることを念頭に置いたシステムとして、有用性が高いと考える。

分析に関して、本研究では特に協調行動認識タスクを実施するためのセンシングシステムおよび行動認識フローを提案している。しかしながら、理想的には環境設置型のセンサのみを利用して居住者それぞれの行動認識を実現させる必要がある。そのためには、環境設置型の非接触センサのみのデータから、個人ごとのセンサ反応を分離させるチャレンジングな課題を解決する必要がある。この課題を解決するために、(1) 部屋単位でセンサ反応を区切ることや、(2) センサ反応系列からパターンマッチングを実施してデータを分離すること、(3) 非侵襲ながらも個人識別が可能なセンシング手法を考案することなどが必要である。特に、(1) および (2) は第 2 章にて述べたように、先行研究がいくつか存在するものの、十

分な精度や現実的なユースケースでの検証には至っていない。(3)についても、定常的なウェアラブルセンサの装着には不快感を示す人もおり、個人識別を行うためには、カメラや音声などの個人に紐付いたセンシティブ情報を必要とする場合が多い。しかしながら、例えばカメラやウェアラブルセンサでなく、振動センサを活用した歩容認証やドップラーセンサを用いた物体形状推定などを一般環境において低コストで実現できれば、居住者は比較的ストレスを感じにくく個人識別が可能である。したがって、将来的な展望として、提案システムに振動センサやドップラーセンサを組み込み、足音情報や超音波により取得した人物の輪郭情報などの比較的センシティブではない情報から個人識別を行い、各居住者に対する行動認識を達成することを目指す。

4.10 複数居住者環境における関連研究との比較

本節では、関連研究にて示されている行動認識精度と、今回得られた複数居住者に対する行動認識精度を比較する。複数居住者家庭の行動認識のために利用されるデータセットとして ARAS データセットや複数居住者向けベンチマーク用 CASAS データセット (CASAS 4 dataset, CASAS Summer 2009) が挙げられる。環境設置型センサデータによる複数居住者行動認識に関する既存研究の多く [66, 65, 75] は、これらのデータセットを利用している。例えば、SARRIMA というエピソードベースの行動認識手法 [65] では、ARAS データセットに対して、マイク等の疑似センサを取り付けるシミュレーションデータを組み込むことで、61.5%から 76.2%の精度で個人識別を伴う複数居住者の行動認識ができると述べられている。なお、ARAS データセットに対して、CRF(Conditional Random Field) や HMM(Hidden Markov Model), RNN(Recurrent Neural Network) 等様々なアルゴリズムでベンチマーク精度を算出している研究 [66] では、60%から 78%の精度で個人識別を伴う行動認識が可能であると述べられている。しかしながら、これらのデータセットのうち ARAS データセットは、表 6 でも記載した通り、人感センサや環境センサだけでなく、テレビ操作に伴い発生する赤外線センサ、各種椅子・ソファへの圧力センサの設置、接触センサ、近接センサ、測距センサなど、各種対象行動に紐づいたセンサを適切な位置に設置する必要があるため、設置に

必要な時間的・技術的コストが高い課題がある。さらに、ARASをはじめとしたデータセットは、2軒以下の家庭数から得られたデータであることが多く、5軒以上のデータを用いてモデルを評価できるものは少ない。また、上記の複数居住者向けのCASAS 4データセットやSummer 2009データセットでは、設置が容易な人感センサを主に利用しているものの、それぞれの部屋ごとに最大15個程度の人感センサを網目状に配置しており、設置コストが課題である。

以上について、特に環境センサに基づく複数居住者家庭でのセンシングを対象としたデータセットの特性を比較した。表12に、一般的に利用されるデータセット概要およびその行動認識精度のベンチマーク結果と、本研究で利用したデータセット概要の比較表を示す。なお、CASAS 4データセットおよびCASAS Summerデータセットは、同様の部屋(実験グループの用意した住居)でセンシングされたデータから構成されている。表より、本研究の構築したセンシングシステムは、他のシステムよりも相対的に設置している合計センサ数が少なく、設置に掛かる負担が少ないことが分かる。本比較表において、実際にテストベッドではなく一般家庭へ導入して運用しているシステムは存在していない。さらに、ベンチマークとして算出されている個人識別を伴う行動認識精度は、主に56%から83.7%の間に収まっている。このことから、提案手法により得られた66.7%の行動認識精度は、関連研究と比較して十分意義のある精度であると考えられる。また、本研究では協調行動認識ではあるものの、挑戦的なデータ収集手法により得られたデータに基づいた行動認識の精度として低くないといえる。当然ながら、実際に提案システムを電力需要予測や見守りシステムへの応用する際には、100%行動を認識できることが望ましい。今後の課題として、タスクの工夫や特徴量抽出の工夫などを含めた認識システムの改善が必要である。

表 12: 複数居住者行動認識の関連研究との比較

センサ設置	対象行動	環境・データ	分析アルゴリズム・結果
<ul style="list-style-type: none"> 力センサ 圧力マット 接触センサ 近接センサ 超音波距離センサ 照度センサ 温度センサ 赤外線受信機 	<p>26種類のADLを収集したが、分析上6種類に限定。</p> <p>睡眠, 食事, 個人衛生 外出, リラックス, その他</p>	<p>センシング期間: 2ヶ月 実験環境: N/A (ある部屋と記載) 被験者数: 4 居住者数: 2</p>	<p>House A: アルゴリズム: RNN 行動認識結果 (Accuracy): 56.2% ホールドアウト検証</p> <p>House B: アルゴリズム: RNN 行動認識結果 (Accuracy): 76.8% ホールドアウト検証</p>
<ul style="list-style-type: none"> 人感センサ x 50 調理器具センサ x 3 ドアセンサ x 16 温度センサ x 4 	<p>掃除, 料理 ベッド-トイレ間移動, 個人衛生 睡眠, 仕事, 勉強 浴室掃除, テレビ視聴</p>	<p>センシング期間: 数日間 実験環境: スクリプトに沿ってスマート化されたアパートで実施 被験者数: 40 居住者数: 2</p>	<p>アルゴリズム: HMM 行動認識結果 (Accuracy): 60.6% 3分割交差検証</p>
<ul style="list-style-type: none"> 人感センサ x 50 調理器具センサ x 3 ドアセンサ x 16 温度センサ x 4 	<p>菓の補充, 着替え 植物の水やり, 掃除 テーブルゲーム, 夕食 料金支払い, 家具移動</p>	<p>センシング期間: 26日 実験環境: スマート化されたアパートで実施 被験者数: 2 居住者数: 2</p>	<p>アルゴリズム: RNN 行動認識結果 (Accuracy): 83.7% ホールドアウト検証</p>
<ul style="list-style-type: none"> 人感センサ x 10 (最大) 環境センサ x 10 (最大) ドアセンサ x 2 (最大) 	<p>入浴, 料理, 食事, 外出, 睡眠</p>	<p>センシング期間: 2ヶ月 実験環境: 一般家庭 被験者数: 8 居住者数: 2</p>	<p>アルゴリズム: DNNとランダムフォレスト 行動認識結果 (Accuracy): 66.7% 10分割交差検証 ※協調行動認識を実施</p>
<p>設置時間: 45分程度</p>			

5. 結論

本章では、結論として2度実施したシステムの実証実験に対するまとめと提案システムの課題について述べ、最後に将来の展望について述べる。

5.1 結果のまとめ

ADLを認識しデータ化することは、高品質な宅内サービスや高齢者の見守りシステム、各種需要予測に活用できるため有用である。特に我が国では、少子高齢化や働き手の不足が社会問題となっており、要介護者の増加に対して介護人材の不足が深刻な課題であるため、高齢者の支援が重要である。したがって、IT技術によってADLを自動で認識・分析し、これらサービスへ活用できるセンシングシステム・行動認識技術が求められている。

本論文では、家庭環境における居住者の健康寿命延伸や、行動変容を目的としたADLデータを収集するために必要な、ADLセンシングシステムを提案した。既存のADLセンシングシステムには、高価であること(課題1)、間取りの異なる環境への適応が難しいこと(課題2)、プライバシー保護の観点から問題があること(課題3)、定期的なメンテナンスが必要であること(課題4)、ADLデータのアノテーション方法が複雑であること(課題5)の5課題が存在する。これらの課題に対して、提案システムでは、設置位置や特殊な機器に依存しない、比較的安価な環境発電型センサを利用し、シンプルな押しボタンをアノテーション用入力インタフェースとしてADLセンシングを行う。提案システムは、コストや設置しやすさ等の普及性を考慮した上で、プライバシー保護に配慮した、ADLデータの収集が可能である。加えて、入力インタフェースとして電子機器の操作も必要なく、押しボタンのみを利用するため、高齢者にとっても利用しやすいシステムであるといえる。提案システムを利用して、合計2ヶ月間の長期間に渡る生活データ収集実験を行った。その結果、LSTMを用いて72%の再現率で行動認識ができることが分かった。

さらに、複数居住者を考慮する際の行動認識手法として、複数居住者の行動履歴を考慮した学習手法を提案した。一般的な複数居住者家庭における居住者の行

動は、各個人が独立して行う行動だけではなく、互いに協調・連動しながら行う行動も存在すると考えられる。したがって、複数居住者の行動認識においては、各個人ごとに行動認識モデルを作成し、行動認識を行うだけでなく、各居住者の互いの行動履歴を考慮することが、精度向上に寄与すると考えられる。以上のことから、効率的な協調行動認識のアルゴリズムとして、各居住者ごとに独立した行動を推定する DNN モデルに加えて、互いの過去の行動履歴を考慮するランダムフォレストモデルを導入し、2種類のモデルを用いる認識フローを提案した。最終的には、入浴、料理、食事、外出、睡眠行動に関して、1ヶ月間の生活データに対して、全家庭における各居住者に対する行動認識精度の平均が、66%を超える F 値で認識できることが分かった。これにより、我々の提案する安価でメンテナンスフリーかつ、どの家庭にも設置可能なセンシングシステムによって、居住者の ADL が認識できることが示された。

これらのセンシングシステムおよび複数居住者向け行動認識手法の提案によって、従来、テストベッドや特殊な機器・機材を備えている家庭に限定されていた行動認識を、一般家庭においても安価かつ手軽に実施できるシステムの提案が可能である。

5.2 提案システムの課題

提案システムにはいくつか課題も存在する。以下に、提案するセンシングシステムと行動認識手法に関して、想定される課題とその解決方法を述べる。

5.2.1 行動認識精度の向上

認識が難しい生活行動の代表例として、食事行動が挙げられる。一般的に食事行動が行われる場所であるダイニング、リビングは、家族の憩いの場として利用される場合があることから、センサ反応のみから食事しているか否かを推定することは困難である。したがって、食事の頻度や内容を問いかける仮想エージェントの利用や行動認識モデルのパーソナライズなどにより、会話内容や、二酸化炭素濃度等の食事に影響しうる環境情報、生活サイクルを加味した時間情報から認

識精度を向上させる手法が有用であると考え。特に、それらのセンサを居住者が選択し、任意で導入できるように設計するなど、一般家庭において高い受容性を保ちつつシステムを導入するための工夫が重要である。

また、複数居住者家庭において、環境に設置された人感センサの反応を個人単位に分離することは困難であることが知られている [48]。非接触センサのみで個人識別を実現できれば、複数居住者家庭でも行動者-行動種類認識を実施でき、より有用なデータが得られる。一手法として、人感センサを反応させた個人の判別には、センサ反応の順番や時系列から、人物の動線を予測することが有効であると考えられる。バイナリセンサを用いた動線予測手法や行動認識手法も提案されている [57, 77] もの、複数居住者家庭や、間取りの変化しうる一般家庭への応用には至っていない。これを実現するためには、振動センサや超音波センサ等から行動者の身体的特徴を獲得する特徴量を生成し、ドメイン適応技術やグラフネットワークなどを利用して、間取りの違いやセンサ設置位置の違いを考慮した動線予測が可能となれば、各種設置型センサを反応させた個人単位の分離が可能であると考えられる。ただし、多くのセンサを設置することは侵襲感を増加させる要因となることから、性格などの個人特性を考慮しつつセンシングシステムの提案を実施する等の工夫が必要となると考えられる。

さらに、本論文で得られた 66.7% の精度は実運用上十分とはいえないため、精度の向上が必須である。将来的には、行動認識システムの実運用の際に、サービスごとにどのような行動に対する認識結果が必要で、どの程度の精度が必要であるのかを明らかにした上で、よりサービスに適したタスクの開発や特徴量抽出方法の開発を行う。これにより、行動認識システムをサービスごとに求められる性能にチューニングすることができ、認識精度の向上やシステム実運用時のユーザビリティの向上が期待できる。

5.2.2 3名以上の複数居住者家庭での行動認識

本論文で対象とした複数居住者家庭は、最大2名の夫婦が居住する世帯であり、協調行動認識タスクもそれら世帯に向けて定義したものであった。したがって、将来的には3名以上の居住者に対する協調行動認識タスクを検討する必要がある。

この場合の協調行動認識の手法としてマルチタスク学習のフローを利用することが挙げられる。図 23 に、マルチタスク学習による協調行動認識のフローを示す。マルチタスク学習は、センサデータをタスク共通の特徴量抽出層へ入力することで中間表現を獲得し、その後得られた中間表現を各タスクごとに固有の特徴量抽出層へ入力することで、最終的な推論結果を各タスクごとに得る機械学習手法である。本論文で述べた協調行動認識においても、マルチタスク学習の構造を利用し、料理・食事・睡眠などの各行動ごとに定義したタスクの2値分類結果を得られれば、組み合わせのラベル変換によって最終的な推論結果を得ることができる。この方法であれば3名以上の居住者家庭においても並行する複数の行動を推論可能である。一方で、この方法の課題として、ネットワーク構造が複雑になり、より多くの学習用データが求められることや、時系列情報を学習するための工夫が必要なこと等が挙げられる。これらの課題に対する解決策として、日常生活行動のシミュレーターにより疑似データを作成することや、ネットワーク内に LSTM 層やアテンション層を挿入し、時系列情報を獲得できるように設計した上で、十分なデータ量を学習させることなどが挙げられる。

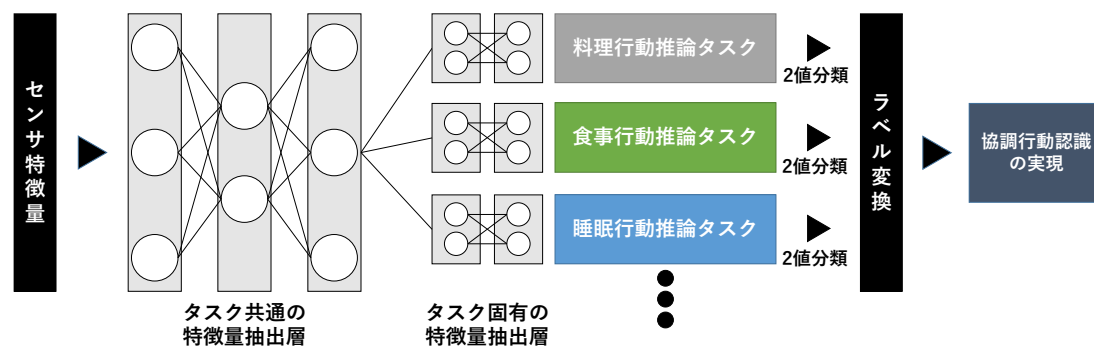


図 23: マルチタスク学習による協調行動認識

5.3 将来の展望

本論文で提案したシステムを改善するために、将来的には、二酸化炭素濃度や振動情報など、各行動の特徴を網羅できるエネルギーハーベスティングセンサおよび設置位置に依存しないセンサの開発や、センシティブ情報に依存しない個人認証技術の確立を目指す。さらに、家庭ごとの間取りの違いやセンサ設置位置の違いに起因するセンサデータの反応を考慮した、ADLデータのドメイン適応や転移学習手法について検討する。家庭ごとに間取り・居住者特性・センサ設置位置は大きく異なり、得られるセンサデータも同様に異なるため、ある家庭で得られたデータを他の家庭へ適応することは難しい。そこで、データを各家庭の共通空間へ再マッピングすることや、共通する特徴量の生成、共通モデルの作成を行い、データの家庭間転移が可能となれば、一般家庭への適用が難しかった動線予測手法等の個人識別手法を、実際の一般家庭へ適応できると考えられる。また、最適なセンサ設置位置・角度・方法などを探索する手法の検討を行うことで、より効率的な行動データおよびセンサデータの収集が可能である。

謝辞

本研究を進めるにあたり、安本慶一教授には、研究全般、特にスマートホームに関する研究において、多大なるご指導・ご助言を賜りました。また、充実した研究環境の整備など、研究活動を手厚くご支援いただきました。感謝の意を表すとともに、心より厚く御礼申しあげます。

中村哲教授には、ご多忙の中、論文審査委員を引き受けてくださった上で、様々なご助言をいただきました。感謝の意を表すとともに、心より厚く御礼申しあげます。

諏訪博彦准教授には、本研究を進めるにあたり、特にデータ分析の観点から専門的な立場からのご指導・ご助言をいただきました。本研究やその他プロジェクト、個人的な相談にも、丁寧に回答してくださいました。感謝の意を表すとともに、心より厚く御礼申しあげます。

大阪公立大学の藤本まなと准教授には、プロジェクトの推進や論文執筆時の基礎、研究に関するご指導・ご助言をいただきました。感謝の意を表すとともに、心より厚く御礼申しあげます。

九州大学の荒川豊教授には、学内外問わず、的確なご指導およびご指摘をいただきました。感謝の意を表すとともに、心より厚く御礼申しあげます。

松田裕貴助教には、研究に関する事項や、日常的に発生する研究室内の様々なことに対してご助言をいただきました。感謝の意を表すとともに、心より厚く御礼申しあげます。

九州大学の中村優吾助教には、計画書の執筆や諸プロジェクトにおいてご指導・ご助言をいただきました。感謝の意を表すとともに、心より厚く御礼申しあげます。

金岡恵事務補佐員、山内奈緒事務補佐員には、学会や出張に関する事務処理を始め、研究生生活の様々な場面でご支援いただきましたこと、謹んで感謝申し上げます。

また、スマートホームチームとして研究の推進に協力いただいた、三崎慎也先輩、大西晃正先輩、佐藤佑磨君、石山時宗君、木俣雄太君、松本敢大君、留学の際にお世話になりました河中祥吾先輩を始めとする先輩の皆様、共に研究生生活

を過ごしたユビキタスコンピューティングシステム研究室の同輩，後輩には，公私ともにお世話になりました．心より感謝申し上げます．

最後に，今日まで学生生活を様々な面から支えてくださった両親をはじめ，家族に心より感謝申し上げます．

参考文献

- [1] World Health Organization : Sustainable Development Goals . available online from <https://www.who.int/sdg/en/> (accessed 2020-05-25).
- [2] Heiner Lasi, Peter Fettke, Hans-Georg Kemper, Thomas Feld, and Michael Hoffmann. Industry 4.0. *Business & information systems engineering*, Vol. 6, No. 4, pp. 239–242, 2014.
- [3] Cabinet Office : The 5th Science and Technology Basic Plan . available online from https://www8.cao.go.jp/cstp/kihonkeikaku/5basicplan_en.pdf (accessed 2020-05-25).
- [4] Cabinet Office : Annual Report on the Aging Society. available online from https://www8.cao.go.jp/kourei/english/annualreport/2017/2017pdf_e.html (accessed 2020-05-25).
- [5] Oya Aran, Dairazalia Sanchez-Cortes, Minh-Tri Do, and Daniel Gatica-Perez. Anomaly detection in elderly daily behavior in ambient sensing environments. In *International Workshop on Human Behavior Understanding*, pp. 51–67. Springer, 2016.
- [6] José M Alcalá, Jesús Ureña, Álvaro Hernández, and David Gualda. Assessing human activity in elderly people using non-intrusive load monitoring. *Sensors*, Vol. 17, No. 2, p. 351, 2017.
- [7] Debraj De, Pratoool Bharti, Sajal K Das, and Sriram Chellappan. Multimodal wearable sensing for fine-grained activity recognition in healthcare. *IEEE Internet Computing*, Vol. 19, No. 5, pp. 26–35, 2015.
- [8] Diane J Cook, Aaron S Crandall, Brian L Thomas, and Narayanan C Krishnan. Casas: A smart home in a box. *Computer*, Vol. 46, No. 7, pp. 62–69, 2012.

- [9] Robert Steele, Amanda Lo, Chris Secombe, and Yuk Kuen Wong. Elderly persons' perception and acceptance of using wireless sensor networks to assist healthcare. *International journal of medical informatics*, Vol. 78, No. 12, pp. 788–801, 2009.
- [10] Jindong Wang, Yiqiang Chen, Shuji Hao, Xiaohui Peng, and Lisha Hu. Deep learning for sensor-based activity recognition: A survey. *Pattern Recognition Letters*, Vol. 119, pp. 3–11, 2019.
- [11] Nirmalya Roy, Archan Misra, and Diane Cook. Ambient and smartphone sensor assisted adl recognition in multi-inhabitant smart environments. *Journal of ambient intelligence and humanized computing*, Vol. 7, No. 1, pp. 1–19, 2016.
- [12] Xenofon Fafoutis, Balazs Janko, Evangelos Mellios, Geoffrey Hilton, R Simon Sherratt, Robert Piechocki, and Ian Craddock. Spw-1: A low-maintenance wearable activity tracker for residential monitoring and healthcare applications. *eHealth 360°*, pp. 294–305. Springer, 2017.
- [13] Francisco Javier Ordóñez and Daniel Roggen. Deep convolutional and lstm recurrent neural networks for multimodal wearable activity recognition. *Sensors*, Vol. 16, No. 1, p. 115, 2016.
- [14] 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.
- [15] Saisakul Chernbumroong, Shuang Cang, Anthony Atkins, and Hongnian Yu. Elderly activities recognition and classification for applications in assisted living. *Expert Systems with Applications*, Vol. 40, No. 5, pp. 1662–1674, 2013.
- [16] Yan Wang, Jian Liu, Yingying Chen, Marco Gruteser, Jie Yang, and Hongbo Liu. E-eyes: device-free location-oriented activity identification using fine-grained wifi signatures. In *Proceedings of the 20th annual international conference on Mobile computing and networking*, pp. 617–628, 2014.

- [17] Wei Wang, Alex X Liu, Muhammad Shahzad, Kang Ling, and Sanglu Lu. Understanding and modeling of wifi signal based human activity recognition. In *Proceedings of the 21st annual international conference on mobile computing and networking*, pp. 65–76, 2015.
- [18] Qifan Pu, Sidhant Gupta, Shyamnath Gollakota, and Shwetak Patel. Whole-home gesture recognition using wireless signals. In *Proceedings of the 19th annual international conference on Mobile computing & networking*, pp. 27–38, 2013.
- [19] Bryce Kellogg, Vamsi Talla, and Shyamnath Gollakota. Bringing gesture recognition to all devices. In *11th {USENIX} Symposium on Networked Systems Design and Implementation ({NSDI} 14)*, pp. 303–316, 2014.
- [20] Michael Buettner, Richa Prasad, Matthai Philipose, and David Wetherall. Recognizing daily activities with rfid-based sensors. In *Proceedings of the 11th international conference on Ubiquitous computing*, pp. 51–60, 2009.
- [21] Dany Fortin-Simard, Jean-Sébastien Bilodeau, Kevin Bouchard, Sebastien Gaboury, Bruno Bouchard, and Abdenour Bouzouane. Exploiting passive rfid technology for activity recognition in smart homes. *IEEE Intelligent systems*, Vol. 30, No. 4, pp. 7–15, 2015.
- [22] Liang Wang, Tao Gu, Xianping Tao, Hanhua Chen, and Jian Lu. Recognizing multi-user activities using wearable sensors in a smart home. *Pervasive and Mobile Computing*, Vol. 7, No. 3, pp. 287–298, 2011.
- [23] Tatsuya Morita, Kenta Taki, Manato Fujimoto, Hirohiko Suwa, Yutaka Arakawa, and Keiichi Yasumoto. Beacon-based time-spatial recognition toward automatic daily care reporting for nursing homes. *Journal of Sensors*, Vol. 2018, , 2018.
- [24] NK Suryadevara, Anuroop Gaddam, RK Rayudu, and SC Mukhopadhyay. Wireless sensors network based safe home to care elderly people: Behaviour detection. *Sensors and Actuators A: Physical*, Vol. 186, pp. 277–283, 2012.

- [25] Ahmad Lotfi, Caroline Langensiepen, Sawsan M Mahmoud, and Mohammad Javad Akhlaghinia. Smart homes for the elderly dementia sufferers: identification and prediction of abnormal behaviour. *Journal of ambient intelligence and humanized computing*, Vol. 3, No. 3, pp. 205–218, 2012.
- [26] Koldo De Miguel, Alberto Brunete, Miguel Hernando, and Ernesto Gambao. Home camera-based fall detection system for the elderly. *Sensors*, Vol. 17, No. 12, p. 2864, 2017.
- [27] Edison Thomaz, Vinay Bettadapura, Gabriel Reyes, Megha Sandesh, Grant Schindler, Thomas Plötz, Gregory D Abowd, and Irfan Essa. Recognizing water-based activities in the home through infrastructure-mediated sensing. In *Proceedings of the 2012 ACM Conference on Ubiquitous Computing*, pp. 85–94, 2012.
- [28] Patrice Guyot, Julien Piquier, and Régine André-Obrecht. Water sound recognition based on physical models. In *2013 IEEE International Conference on Acoustics, Speech and Signal Processing*, pp. 793–797. IEEE, 2013.
- [29] Eri Nakagawa, Kazuki Moriya, Hirohiko Suwa, Manato Fujimoto, Yutaka Arakawa, and Keiichi Yasumoto. Toward real-time in-home activity recognition using indoor positioning sensor and power meters. In *2017 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)*, pp. 539–544. IEEE, 2017.
- [30] Abdulsalam Yassine, Shailendra Singh, and Atif Alamri. Mining human activity patterns from smart home big data for health care applications. *IEEE Access*, Vol. 5, pp. 13131–13141, 2017.
- [31] Kenki Ueda, Hirohiko Suwa, Yutaka Arakawa, and Keiichi Yasumoto. Exploring accuracy-cost tradeoff in in-home living activity recognition based on power consumptions and user positions. In *2015 IEEE International Conference on Computer and Information Technology; Ubiquitous Computing and Communi-*

cations; Dependable, Autonomic and Secure Computing; Pervasive Intelligence and Computing, pp. 1130–1137. IEEE, 2015.

- [32] Wataru Sasaki, Masashi Fujiwara, Hirohiko Suwa, Manato Fujimoto, Yutaka Arakawa, Aki Kimura, Tomoko Miki, and Keiichi Yasumoto. Daily living activity recognition through time series analysis of data obtained with echonet lite appliances and motion sensors. *SIG-SAI*, Vol. 31, No. 5, pp. 1–8, 2018 (in Japanese).
- [33] Kazuki Moriya, Eri Nakagawa, Manato Fujimoto, Hirohiko Suwa, Yutaka Arakawa, Aki Kimura, Satoko Miki, and Keiichi Yasumoto. Daily living activity recognition with echonet lite appliances and motion sensors. In *2017 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)*, pp. 437–442. IEEE, 2017.
- [34] Tim Van Kasteren, Athanasios Noulas, Gwenn Englebienne, and Ben Kröse. Accurate activity recognition in a home setting. In *Proceedings of the 10th international conference on Ubiquitous computing*, pp. 1–9. ACM, 2008.
- [35] Hande Alemdar, Halil Ertan, Ozlem Durmaz Incel, and Cem Ersoy. Aras human activity datasets in multiple homes with multiple residents. In *2013 7th International Conference on Pervasive Computing Technologies for Healthcare and Workshops*, pp. 232–235. IEEE, 2013.
- [36] Emmanuel Munguia Tapia, Stephen S Intille, and Kent Larson. Activity recognition in the home using simple and ubiquitous sensors. In *International conference on pervasive computing*, pp. 158–175. Springer, 2004.
- [37] Domus Laboratory : Smart environment dataset . available from <https://www.usherbrooke.ca/domus/en/research/dataset/> (accessed 2020-05-25).
- [38] Michel Vacher, Benjamin Lecouteux, Pedro Chahuara, François Portet, Brigitte Meillon, and Nicolas Bonnefond. The sweet-home speech and multimodal cor-

- pus for home automation interaction. In *Proceedings of the Ninth International Conference on Language Resources and Evaluation (LREC'14)*, pp. 4499–4506, Reykjavik, Iceland, May 2014. European Language Resources Association (ELRA).
- [39] Huichen Lin and Neil W Bergmann. Iot privacy and security challenges for smart home environments. *Information*, Vol. 7, No. 3, p. 44, 2016.
- [40] Milton Gonzalo Ruiz Maldonado. Wireless sensor network for smart home services using optimal communications. In *2017 International Conference on Information Systems and Computer Science (INCISCOS)*, pp. 27–32. IEEE, 2017.
- [41] Sudhir Chitnis, Neha Deshpande, Arvind Shaligram, et al. An investigative study for smart home security: Issues, challenges and countermeasures. *Wireless Sensor Network*, Vol. 8, No. 04, p. 61, 2016.
- [42] Lipi Chhaya, Paawan Sharma, Govind Bhagwatikar, and Adesh Kumar. Wireless sensor network based smart grid communications: cyber attacks, intrusion detection system and topology control. *Electronics*, Vol. 6, No. 1, p. 5, 2017.
- [43] Ayman Dawood Salman, Osamah Ibrahim Khalaf, and Ghaida Muttashar Abdul-sahib. An adaptive intelligent alarm system for wireless sensor network. *Indonesian Journal of Electrical Engineering and Computer Science*, Vol. 15, No. 1, pp. 142–147, 2019.
- [44] 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.
- [45] Niall Twomey, Tom Diethel, Ian Craddock, and Peter Flach. Unsupervised learning of sensor topologies for improving activity recognition in smart environments. *Neurocomputing*, Vol. 234, pp. 93–106, 2017.

- [46] Yang Hu, Dominique Tilke, Taylor Adams, Aaron S Crandall, Diane J Cook, and Maureen Schmitter-Edgecombe. Smart home in a box: usability study for a large scale self-installation of smart home technologies. *Journal of reliable intelligent environments*, Vol. 2, No. 2, pp. 93–106, 2016.
- [47] James Pope, Ryan McConville, Michal Kozlowski, Xenofon Fafoutis, Raul Santos-Rodriguez, Robert J Piechocki, and Ian Craddock. Sphere in a box: Practical and scalable eurvalve activity monitoring smart home kit. In *2017 IEEE 42nd Conference on Local Computer Networks Workshops (LCN Workshops)*, pp. 128–135. IEEE, 2017.
- [48] Qimeng Li, Raffaele Gravina, Ye Li, Saeed H Alsamhi, Fangmin Sun, and Giancarlo Fortino. Multi-user activity recognition: Challenges and opportunities. *Information Fusion*, Vol. 63, pp. 121–135, 2020.
- [49] Sheng Tan, Linghan Zhang, Zi Wang, and Jie Yang. Multitrack: Multi-user tracking and activity recognition using commodity wifi. In *Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems*, pp. 1–12, 2019.
- [50] Fang-Jing Wu and Gurkan Solmaz. We hear your activities through wi-fi signals. In *2016 IEEE 3rd World Forum on Internet of Things (WF-IoT)*, pp. 251–256. IEEE, 2016.
- [51] Zhengyu Peng, Changzhi Li, José-María Muñoz-Ferreras, and Roberto Gómez-García. An fmcw radar sensor for human gesture recognition in the presence of multiple targets. In *2017 First IEEE MTT-S International Microwave Bio Conference (IMBIOC)*, pp. 1–3. IEEE, 2017.
- [52] Yiran Li, Zhengyu Peng, Ranadip Pal, and Changzhi Li. Potential active shooter detection based on radar micro-doppler and range-doppler analysis using artificial neural network. *IEEE Sensors Journal*, Vol. 19, No. 3, pp. 1052–1063, 2018.
- [53] Andrea Prati, Caifeng Shan, and Kevin I-Kai Wang. Sensors, vision and networks: From video surveillance to activity recognition and health monitoring.

Journal of Ambient Intelligence and Smart Environments, Vol. 11, No. 1, pp. 5–22, 2019.

- [54] Zhiwei Deng, Arash Vahdat, Hexiang Hu, and Greg Mori. Structure inference machines: Recurrent neural networks for analyzing relations in group activity recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 4772–4781, 2016.
- [55] Amandine Dubois and François Charpillet. Measuring frailty and detecting falls for elderly home care using depth camera. *Journal of ambient intelligence and smart environments*, Vol. 9, No. 4, pp. 469–481, 2017.
- [56] SU Park, JH Park, MA Al-Masni, MA Al-Antari, Md Z Uddin, and T-S Kim. A depth camera-based human activity recognition via deep learning recurrent neural network for health and social care services. *Procedia Computer Science*, Vol. 100, pp. 78–84, 2016.
- [57] Daniel H Wilson and Chris Atkeson. Simultaneous tracking and activity recognition (star) using many anonymous, binary sensors. In *International Conference on Pervasive Computing*, pp. 62–79. Springer, 2005.
- [58] Alaa Alhamoud, Vaidehi Muradi, Doreen Böhnstedt, and Ralf Steinmetz. Activity recognition in multi-user environments using techniques of multi-label classification. In *Proceedings of the 6th International Conference on the Internet of Things*, pp. 15–23, 2016.
- [59] Rong Chen and Yu Tong. A two-stage method for solving multi-resident activity recognition in smart environments. *Entropy*, Vol. 16, No. 4, pp. 2184–2203, 2014.
- [60] Aaron S Crandall and Diane J Cook. Using a hidden markov model for resident identification. In *2010 Sixth International Conference on Intelligent Environments*, pp. 74–79. IEEE, 2010.

- [61] Markus Prosegger and Abdelhamid Bouchachia. Multi-resident activity recognition using incremental decision trees. In *International Conference on Adaptive and Intelligent Systems*, pp. 182–191. Springer, 2014.
- [62] Juan Ye, Graeme Stevenson, and Simon Dobson. Kcar: A knowledge-driven approach for concurrent activity recognition. *Pervasive and Mobile Computing*, Vol. 19, pp. 47–70, 2015.
- [63] Mohammad Arif Ul Alam, Nirmalya Roy, Archan Misra, and Joseph Taylor. Cace: Exploiting behavioral interactions for improved activity recognition in multi-inhabitant smart homes. In *2016 IEEE 36th International Conference on Distributed Computing Systems (ICDCS)*, pp. 539–548. IEEE, 2016.
- [64] Diane J Cook. Learning setting-generalized activity models for smart spaces. *IEEE intelligent systems*, Vol. 2010, No. 99, p. 1, 2010.
- [65] Ifat Afrin Emi and John A Stankovic. Sarrima: Smart adl recognizer and resident identifier in multi-resident accommodations. In *Proceedings of the conference on Wireless Health*, pp. 1–8, 2015.
- [66] Son N Tran, Dung Nguyen, Tung-Son Ngo, Xuan-Son Vu, Long Hoang, Qing Zhang, and Mohan Karunanithi. On multi-resident activity recognition in ambient smart-homes. *Artificial Intelligence Review*, Vol. 53, No. 6, pp. 3929–3945, 2020.
- [67] Jianguo Hao, Abdenour Bouzouane, and Sébastien Gaboury. Recognizing multi-resident activities in non-intrusive sensor-based smart homes by formal concept analysis. *Neurocomputing*, Vol. 318, pp. 75–89, 2018.
- [68] Tom Diethe, Mike Holmes, Meelis Kull, Miquel Perello Nieto, Kacper Sokol, Hao Song, Emma Tonkin, Niall Twomey, and Peter Flach. Releasing ehealth analytics into the wild: lessons learnt from the sphere project. In *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, pp. 243–252, 2018.

- [69] Nitesh V Chawla, Kevin W Bowyer, Lawrence O Hall, and W Philip Kegelmeyer. Smote: synthetic minority over-sampling technique. *Journal of artificial intelligence research*, Vol. 16, pp. 321–357, 2002.
- [70] Tomokazu Matsui, Kosei Onishi, Misaki Shinya, Manato Fujimoto, Hirohiko Suwa, and Keiichi Yasumoto. Easy-to-deploy living activity sensing system and data collection in general homes. In *2020 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)*, pp. 460–465. IEEE, 2020.
- [71] Ivan Miguel Pires, Faisal Hussain, Gonçalo Marques, and Nuno M Garcia. Comparison of machine learning techniques for the identification of human activities from inertial sensors available in a mobile device after the application of data imputation techniques. *Computers in Biology and Medicine*, Vol. 135, p. 104638, 2021.
- [72] Niamh McCombe, Xuemei Ding, Girijesh Prasad, David P Finn, Stephen Todd, Paula L McClean, and KongFatt Wong-Lin. Predicting feature imputability in the absence of ground truth. *arXiv preprint arXiv:2007.07052*, 2020.
- [73] Sidney Katz, Amasa B Ford, Roland W Moskowitz, Beverly A Jackson, and Marjorie W Jaffe. Studies of illness in the aged: the index of adl: a standardized measure of biological and psychosocial function. *Jama*, Vol. 185, No. 12, pp. 914–919, 1963.
- [74]
- [75] Kaixuan Chen, Dalin Zhang, Lina Yao, Bin Guo, Zhiwen Yu, and Yunhao Liu. Deep learning for sensor-based human activity recognition: Overview, challenges, and opportunities. *ACM Computing Surveys (CSUR)*, Vol. 54, No. 4, pp. 1–40, 2021.
- [76] Geetika Singla, Diane J Cook, and Maureen Schmitter-Edgecombe. Recognizing independent and joint activities among multiple residents in smart environments.

Journal of ambient intelligence and humanized computing, Vol. 1, No. 1, pp. 57–63, 2010.

- [77] Fco Ordóñez, Paula De Toledo, Araceli Sanchis, et al. Activity recognition using hybrid generative/discriminative models on home environments using binary sensors. *Sensors*, Vol. 13, No. 5, pp. 5460–5477, 2013.

研究業績

本論文に関する業績

学術論文誌

1. Tomokazu Matsui, Kosei Onishi, Shinya Misaki, Manato Fujimoto, Hirohiko Suwa, Keiichi Yasumoto: SALON: Simplified Sensing System for Activity of Daily Living in Ordinary Home, *Sensors*, Vol.20, No.17, Article ID 4895, August. 2020.

– 3章に対応

国際会議

1. Tomokazu Matsui, Kosei Onishi, Shinya Misaki, Manato Fujimoto, Hirohiko Suwa, and Keiichi Yasumoto: Easy-to-Deploy Living Activity Sensing System and Data Collection in General Homes, *The Fourth International Workshop on Pervasive Smart Living Spaces (PerLS 2020)*, Austin, Texas, USA, Mar. 2020.
2. Tomokazu Matsui, Shinya Misaki, Yuma Sato, Manato Fujimoto, Hirohiko Suwa, and Keiichi Yasumoto: Multi-Person Daily Activity Recognition with Non-Contact Sensors Based on Activity Co-Occurrence, *The 13th International Conference on Mobile Computing and Ubiquitous Networking (ICMU 2021)*, pp. 157-164, Tokyo, Japan, Nov. 2021.

– 3章に対応

国内会議

1. 松井 智一, 大西 晃正, 三崎 慎也, 藤本 まなと, 諏訪 博彦, 安本 慶一: “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”, 研究報告モバイルコンピューティングとパーベイシブシステム (MBL), 奈良県, 2019年11月.

- 3章に対応

その他の業績

学術論文誌

1. Akihiro Matsuda, Tomokazu Matsui, Yuki Matsuda, Hirohiko Suwa, and Keiichi Yasumoto: A Method for Detecting Street Parking Using Dashboard Camera Videos, *Sensors and Materials*, vol. 33, no. 1, pp. 17-34, Jan. 2021.
2. Hyuckjin Choi, Manato Fujimoto, Tomokazu Matsui, Shinya Misaki, Keiichi Yasumoto: Wi-CaL: WiFi Sensing and Machine Learning based Device-Free Crowd Counting and Localization, *IEEE Access*, Vol. 10, pp. 24395-24410, 2022.
3. Atsushi Miyaji, Yuta Kimata, Tomokazu Matsui, Manato Fujimoto, Keiichi Yasumoto: Analysis and Visualization of Relationship between Stress and Care Activities toward Reduction in Caregiver Workload, *Sensors and Materials*, Vol. 34, No. 8, pp.2929-2954, 2022.
4. Kanta Matsumoto, Tomokazu Matsui, Hirohiko Suwa, Keiichi Yasumoto: Stress Estimation Using Biometric and Activity Indicators to Improve QoL of the Elderly, *Sensors*, Vol. 23, No. 1, 2023.

国際会議

1. Shinya Misaki, Sopicha Stirapongsasuti, Tomokazu Matsui, Hirohiko Suwa, Keiichi Yasumoto: Demo Abstract: Activity Recognition through Intermittent

Distributed Processing by Energy Harvesting PIR Sensors, The 18th ACM Conference on Embedded Networked Sensor Systems (SenSys 2020), Yokohama, Japan , November 16-19, 2020.

2. Akihiro Matsuda, Tomokazu Matsui, Yuki Matsuda, Hirohiko Suwa, and Keiichi Yasumoto: Demo Abstract: A Method for Detecting Street Parking Using Dashboard Camera Videos on an Edge Device, The 18th ACM Conference on Embedded Networked Sensor Systems (SenSys 2020), Yokohama, Japan, November 16-19, 2020.
3. Shinya Misaki, Keisuke Umakoshi, Tomokazu Matsui, Hyuckjin Choi, Manato Fujimoto and Keiichi Yasumoto: Non-Contact In-Home Activity Recognition System Utilizing Doppler Sensors, First International Workshop on Maintenance-Free Context Sensing (MFsens 2021), Nara, Japan, January 8th, 2021
4. Hyuckjin Choi, Tomokazu Matsui, Manato Fujimoto, Keiichi Yasumoto: Simultaneous Crowd Counting and Localization by WiFi CSI, 22nd International Conference on Distributed Computing and Networking (ICDCN 2021), Nara, Japan, Jan. 5th-8th, 2021.
5. Keisuke Umakoshi, Tomokazu Matsui, Makoto Yoshida, Hyuckjin Choi, Manato Fujimoto, Hirohiko Suwa, Keiichi Yasumoto: Non-Contact Person Identification by Piezoelectric-based Gait Vibration Sensing, The 35th International Conference on Advanced Information Networking and Applications (AINA-2021), Ryerson University, Toronto, Canada, May. 12th, 2021.
6. Tomokazu Matsui, Kosei Onishi, Shinya Misaki, Hirohiko Suwa, Manato Fujimoto, Teruhiro Mizumoto, Wataru Sasaki, Aki Kimura, Kiyoyasu Maruyama, Keiichi Yasumoto: Analysis of Visualized Bioindicators Related to Activities of Daily Living, The 35th International Conference on Advanced Information Networking and Applications (AINA-2021), Ryerson University, Toronto, Canada, May. 12th, 2021.

7. Sopicha Stirapongsasuti, Shinya Misaki, Tomokazu Matsui, Hirohiko Suwa, and Keiichi Yasumoto: Butterfly: Battery-Free Daily Living Activity Recognition System through Distributed Execution over Energy Harvesting Analog PIR Sensors, Proceedings of the 17th International Conference on Distributed Computing in Sensor Systems (DCOSS2021), pp. 54-56, July 2021.
8. Atsushi Miyaji, Tomokazu Matsui, Zhihua Zhang, Hyuckjin Choi, Manato Fujimoto, and Keiichi Yasumoto: Analysis on Nursing Care Activity Related Stress Level for Reduction of Caregiving Workload, 50th International Conference on Parallel Processing Workshop (ICPP Workshops ' 21), Online, Aug. 2021.
9. Hyuckjin Choi, Tomokazu Matsui, Shinya Misaki, Atsushi Miyaji, Manato Fujimoto, Keiichi Yasumoto: Simultaneous Crowd Estimation in Counting and Localization Using WiFi CSI, The eleventh International Conference on Indoor Positioning and Indoor Navigation (IPIN 2021), Lloret de Mar, Spain (Hybrid), 29th Nov. – 2nd Dec., 2021.
10. Daiki Mayumi, Yugo Nakamura, Yuki Matsuda, Tomokazu Matsui, Shinya Misaki, Keiichi Yasumoto, Junko Nohara: Aroma Nudges: Exploring the Effects on Shopping Behavior in a Supermarket, 17th International Conference on Persuasive Technology 2022, International Workshop on Digital Nudging and Digital Persuasion (DNDP ' 22), 2022.
11. Kanta Matsumoto, Tomokazu Matsui, Hirohiko Suwa, Keiichi Yasumoto: Stress Prediction Using Per-Activity Biometric Data to Improve QoL in the Elderly, The 19th International Conference On Smart Living and Public Health (ICOST ' 22), pp. 196-208, Paris, France, 2022.

国内会議

1. 松井 智一, 諏訪 博彦, 安本 慶一: “CASAS データセットを用いた LSTM モデルによる時間内行動生起予測精度の評価”, 2019 年度情報処理学会関西支

部 支部大会, 大阪府, 2019年9月.

2. 松田明大, 松井智一, 松田裕貴, 諏訪博彦, 安本慶一: ドライブレコーダ動画を用いた路上駐停車判定手法の提案, マルチメディア、分散、協調とモバイル (DICOMO2020) シンポジウム, 高知県 (オンライン), 2020年6月.
3. 宮地篤士, 松井智一, 張志華, 藤本まなど, 安本慶一: デイケア施設における介護士のストレス推定に向けた一検討, 2020年度情報処理学会関西支部 支部大会, 大阪府 (オンライン), 2020年9月.
4. 佐藤佑磨, 松井智一, 山下顕, 鈴木隆寛, 堀口賞一, 諏訪博彦: IoTスマートホームにおける生活行動認識に向けたデータの可視化と分析, 2020年度情報処理学会関西支部 支部大会, 大阪府 (オンライン), 2020年9月.
5. 松田明大, 松井智一, 松田裕貴, 諏訪博彦, 安本慶一: エッジデバイスによるリアルタイム路上駐停車判定システム, 第28回マルチメディア通信と分散処理ワークショップ (DPSWS2020) 講演論文集, 2020.
6. 松井智一, 大西晃正, 三崎慎也, 諏訪博彦, 藤本まなど, 水本旭洋, 佐々木渉, 木村亜紀, 玉田隆史, 丸山清泰, 安本慶一: 日常生活行動に紐付けた生体指標の可視化と分析, 第28回マルチメディア通信と分散処理ワークショップ (DPSWS2020) 講演論文集, 2020.
7. 片山洋平, 松井智一, 佐藤佑磨, 中岡黎, Chang Xin, Dang Chenyu, 松田裕貴: 口腔内画像撮影支援システムの提案, 第28回マルチメディア通信と分散処理ワークショップ (DPSWS2020) 講演論文集, 2020.
8. 福田修之, 玉置理沙, 松井智一, 大井一輝, Choi Hyuckjin, 松田裕貴, 安本慶一: リアルタイム行動認識機能を有する釣りCPSの開発, 第28回マルチメディア通信と分散処理ワークショップ (DPSWS2020) 講演論文集, 2020.
9. 福田修之, 松井智一, Choi Hyuckjin, 松田裕貴, 安本慶一: 釣果情報共有を目的とした釣竿の振動データに基づく魚種判別手法, 第28回マルチメディア通信と分散処理ワークショップ (DPSWS2020) 講演論文集, 2020.

10. 三崎 慎也, 馬越 圭介, 松井 智一, Hyuckjin Choi, 藤本 まなと, 安本 慶一: 屋内環境におけるドップラーセンサを使用した非接触型行動認識手法, 第 97 回モバイルコンピューティングとバーベイスブシステム研究会, オンライン開催, 2020 年 11 月.
11. 松田 明大, 松井 智一, 松田 裕貴, 諏訪 博彦, 安本 慶一: エッジデバイスによるリアルタイム路上駐停車判定・可視化システム, 第 18 回 ITS シンポジウム 2020, 愛媛県松山市, 2020 年 12 月.
12. 三崎 慎也, 松井 智一, 諏訪 博彦, 安本 慶一: 環境発電アナログ PIR センサの分散処理による無電源実時間宅内行動認識システム, 第 98 回モバイルコンピューティングとバーベイスブシステム研究会, オンライン開催, 2021 年 3 月.
13. 佐藤 佑磨, 大山 航平, 立花 巧樹, 林 涼弥, 松井 智一, 宮地 篤士, 安本 慶一: 居住空間のリアルタイム行動認識に向けた行動認識フレームワークの提案, 社会システムと情報技術研究ウィーク (RST2021), 北海道, 2021 年 3 月.
14. 片山 洋平, 松井 智一, 中岡 黎, 佐藤 佑磨, 松田 裕貴, 諏訪 博彦, 安本 慶一: 遠隔歯科診断にむけた自撮り口腔内写真利用可否判定手法, 社会システムと情報技術研究ウィーク (RST2021), 北海道, 2021 年 3 月.
15. 佐藤 佑磨, 松井 智一, 中村 優吾, 諏訪 博彦, 安本 慶一: 宅内行動認識モデル最適化のためのナッジを用いたアノテーション行動誘導方法の検討, マルチメディア、分散、協調とモバイル (DICOMO2021) シンポジウム, オンライン, 2021 年 6 月.
16. 松本 敢大, 松井 智一, 諏訪 博彦, 安本 慶一: 高齢者の QoL 向上に向けた生活行動データと心拍情報を使った健康状態予測, マルチメディア、分散、協調とモバイル (DICOMO2021) シンポジウム, オンライン, 2021 年 6 月.
17. 宮地 篤士, 松井 智一, 張 志華, 藤本 まなと, 安本 慶一: 介護士の業務負担軽減に向けた介護行動時における心身状態の変化の可視化と分析, マルチメ

ディア、分散、協調とモバイル (DICOMO2021) シンポジウム, オンライン, 2021年6月.

18. 木俣雄太, 宮地篤士, 松井智一, 張志華, 藤本まなと, 諏訪博彦, 安本慶一: 高齢者のフレイル状態の予防に向けた生活改善フレームワークの提案, 2021年度 情報処理学会関西支部 支部大会, オンライン, 2021年9月19日.
19. 真弓大輝, 松井智一, 三崎慎也, 中村優吾, 松田裕貴, 安本慶一: 嗅覚に作用するナッジを用いた購買行動変容システムの検討, 2021年度 情報処理学会関西支部 支部大会, オンライン, 2021年9月19日.
20. 石山時宗, 松井智一, 藤本まなと, 諏訪博彦, 安本慶一: マルチモーダルセンシングに基づく料理中のマイクロ行動認識の提案, 2021年度 情報処理学会関西支部 支部大会, オンライン, 2021年9月19日.
21. 張志華, 松井智一, 上田浩行, 高野誠也, 藤本大介, 林優一, 安本慶一, 荒川豊: 電磁・通信・家電情報に基づくIoT活動量計の検討, 第29回マルチメディア通信と分散処理ワークショップ (DPSWS2021) 講演論文集, 2021年10月.
22. 宮地篤士, 木俣雄太, 松井智一, 張志華, 藤本まなと, 安本慶一: 介護士の負担軽減に向けた介護業務における生体情報の収集及び心身状態変化の分析, 社会システムと情報技術研究ウィーク (WSSIT2022), 北海道, 2022.
23. 木俣雄太, 宮地篤士, 松井智一, 藤本まなと, 諏訪博彦, 安本慶一: 高齢者のフレイル予防に向けた生活改善フレームワークの提案及び実用性の検証, 社会システムと情報技術研究ウィーク (WSSIT2022), 北海道, 2022.
24. 松井智一, 木俣雄太, 三崎慎也, 松田裕貴, 諏訪博彦, 安本慶一: サイバーフィジカル空間共有システムにおけるプライバシーフィルタリング機構の検討, 第206回知能システム研究会 (SIG-ICS) / 社会システムと情報技術研究ウィーク (WSSIT2022), Vol.2022-ICS-206, No.3, pp.1-7, 北海道, 2022年.
25. 真弓大輝, 中村優吾, 松田裕貴, 松井智一, 三崎慎也, 安本慶一, 野原潤子: 香りナッジが実店舗の購買行動に及ぼす影響の調査, 第15回行動変容と社会シス

テム研究会 (BCSS) / 社会システムと情報技術研究ウィーク (WSSIT2022), Vol.8, pp.1-6, 北海道, 2022.

26. 三崎慎也, 松井智一, 諏訪博彦, 藤本まなど, 水本旭洋, 谷伊織, 佐々木渉, 木村亜紀, 安本慶一: Big-Five パーソナリティ特性に応じた家電自動制御手法の検討, 社会システムと情報技術研究ウィーク (WSSIT2022), 北海道, 2022.
27. 三崎慎也, 松井智一, 中村優吾, 安本慶一: 高臨場感リモート Co-Cooking を実現する IoT まな板の設計と空間提示方法の検討, 社会システムと情報技術研究ウィーク (WSSIT2022), 北海道, 2022.
28. 佐藤佑磨, 松井智一, 諏訪博彦, 鈴木隆寛, 清水俊晴, 鈴木由太郎, 堀口賞一, 安本慶一: スマートホームにおける一般被験者の生活行動ラベリング精度の調査と改善のための一検討, モバイルコンピューティングと新社会システム研究会 (MBL), Vol. 2022-DPS-191, No. 23, pp. 1-7, 沖縄, 日本, 2022.
29. 三嶋祐輝, 松井智一, 松田裕貴, 諏訪博彦, 安本慶一: 3D ポイントクラウドを用いたマイクロ行動認識の検討, 2022 年度 情報処理学会関西支部 支部大会, pp. 1-6, オンライン, 2022.
30. 吉田誠, 松井智一, 石山時宗, 三崎慎也, 藤本まなど, 諏訪博彦, 安本慶一: Smartable: マルチ振動センサと深層学習を用いた既存家具のインターフェース化の検討, 第 30 回マルチメディア通信と分散処理ワークショップ (DP-SWS2022), 2022.

受賞

1. マルチメディア、分散、協調とモバイル (DICOMO2020) シンポジウム 優秀プレゼンテーション賞: 松田明大, 松井智一, 松田裕貴, 諏訪博彦, 安本慶一: ドライブレコーダ動画を用いた路上駐停車判定手法の提案

2. マルチメディア、分散、協調とモバイル (DICOMO2020) シンポジウム 最優秀論文賞：松田明大, 松井智一, 松田裕貴, 諏訪博彦, 安本慶一：ドライブレコーダ動画を用いた路上駐停車判定手法の提案
3. 第 28 回マルチメディア通信と分散処理ワークショップ (DPSWS2020) 優秀デモンストレーション賞：リアルタイム行動認識機能を有する釣り CPS の開発：福田修之, 玉置理沙, 松井智一, 大井一輝, Choi Hyuckjin, 松田裕貴, 安本慶一
4. 第 28 回マルチメディア通信と分散処理ワークショップ (DPSWS2020) 優秀ポスター賞：口腔内画像撮影支援システムの提案：片山洋平, 松井智一, 佐藤佑磨, 中岡黎, Chang Xin, Dang Chenyu, 松田裕貴
5. 第 18 回 ITS シンポジウム 2020 ベストポスター賞：エッジデバイスによるリアルタイム路上駐停車判定・可視化システム：松田明大, 松井智一, 松田裕貴, 諏訪博彦, 安本慶一
6. 第 28 回マルチメディア通信と分散処理ワークショップ (DPSWS2020) 優秀ポスター賞：口腔内画像撮影支援システムの提案：片山洋平, 松井智一, 佐藤佑磨, 中岡黎, Chang Xin, Dang Chenyu, 松田裕貴
7. 第 29 回マルチメディア通信と分散処理ワークショップ (DPSWS2021) 優秀ポスター賞：電磁・通信・家電情報に基づく IoT 活動量計の検討：張志華, 松井智一, 上田浩行, 高野誠也, 藤本大介, 林優一, 安本慶一, 荒川豊
8. The 13th International Conference on Mobile Computing and Ubiquitous Networking (ICMU2021) Best Paper Award: Tomokazu Matsui, Shinya Misaki, Yuma Sato, Manato Fujimoto, Hirohiko Suwa, Keiichi Yasumoto.
9. 2022 年 科学技術イノベーション創出に向けた大学フェローシップ創設事業 優秀創発人材賞：松井智一