

# 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

佐藤 佑磨<sup>1,a)</sup> 松井 智一<sup>1</sup> 諏訪 博彦<sup>1,2</sup> 鈴木 隆寛<sup>3</sup> 清水 俊晴<sup>3</sup> 鈴木 由太郎<sup>3</sup> 堀口 賞一<sup>3</sup>  
安本 慶一<sup>1,2</sup>

**概要：**高精度の宅内生活行動認識モデルを構築するためには、高精度の行動ラベリングが求められる。本研究では、IoT スマートホームにおいて、13種類の各生活行動について開始と終了のタイミングを厳密に定義した上で、アプリ設計者および一般被験者からセンサデータおよび行動ラベルデータを収集し、それぞれ行動認識モデルを構築し精度の比較を行った。その結果、アプリ設計者が記録したラベルとセンサデータで構築したモデルの精度/F値が0.84/0.60であったのに対し、一般被験者が記録したラベルとセンサデータによるモデルの精度/F値は0.43/0.22にとどまったことから、一般の被験者は正確なラベリングができていないことが分かった。そこで、一般被験者による行動ラベリングの精度を向上させるため、任意のタイミングで現在行っている行動を質問するシステムを開発し、その有効性を検討するための予備実験を行った。予備実験で収集されたデータを分析した結果、質問による行動ラベリングによって、モデルの認識精度が向上し、被験者の行動記録にかかる負担が軽減される可能性が示唆された。

**キーワード：**生活行動認識, 行動ラベリング, IoT スマートホーム, 生活行動データ収集

## 1. はじめに

近年、より利便性の高い住居を実現するために宅内の住人の行動分析やそれに関する研究が盛んに行われている。昨今のCOVID-19の影響に伴い、外出自粛やリモートワークの機会が増加し、人々が自宅で過ごす時間が多くなっているため、住居の利便性を追求することを目的とした宅内行動認識の研究はこれからますます増えていくと予想される。様々なセンサやデバイスが設置されたスマートホームが開発されており、多くの研究機関がスマートホームを保有し、研究を行っている。その中でも牽引移動可能なIoT スマートホーム<sup>®</sup> (以下、IoT スマートホームと記載)は株式会社NTTドコモが構築したものであり、これをテストフィールドとして様々な実験が行われている。この家には、人の動きを測るセンサや環境を測るセンサなどが数多く搭載されており、居住者の行動を分析することができる。本研究では、理想的なアノテーション(行動ラベリング)

を行った場合の宅内行動認識精度を検証するため、IoT スマートホームを使った実証実験を実施し、宅内行動データの収集と分析を行った。さらに一般被験者のアノテーション精度、および本研究で提案する質問ベースの新しいアノテーション方法を用いた場合の宅内行動認識精度の検証を目的とした評価実験を実施した。

## 2. 関連研究

スマートホームにおける生活行動認識に関して様々な研究が行われている [1], [2], [3], [4], [5], [6]。例えば、上田ら [1] は、屋内位置センサと消費電力センサを用いて日常生活における行動10種(料理, 食事, 読書など)を認識している。屋内位置センサには超音波センサを使い、16種類の家電に消費電力センサを取り付けることにより行動認識を行っている。

行動認識だけでなく、行動予測を行っている研究もある。佐々木ら [7] は時間に依存する日常生活の行動をLSTMをベースとしたモデルを用いて予測している。ある行動を行ってから、決められた時間内にまたその行動を行うか否かの分類問題として予測を行うことにより、実生活への応用可能性を示している。

また、一般家庭をスマート化するための、スマートホー

<sup>1</sup> 奈良先端科学技術大学院大学  
Nara Institute of Science and Technology  
<sup>2</sup> 理化学研究所革新知能統合研究センター (AIP)  
RIKEN Center for Advanced Intelligence Project (AIP)  
<sup>3</sup> 株式会社NTTドコモ  
NTT DOCOMO Inc.  
a) sato.yuma.tz4@is.naist.jp

ムキットに関する研究も行われている [8], [9]. 松井ら [8] は, 一般家庭への普及を目的としたシンプルな宅内生活行動センシングシステムを提案し, 一般高齢者家庭 10 世帯から収集したデータを用いて, 行動認識を行っている.

居住者の行動データ収集に関する研究として, Kasteren ら [10] や Vacher ら [11] の研究が挙げられる. これらの研究では, スマートホーム環境における多種多様なセンサを利用したセンシングシステムによってデータを収集するとともに, 居住者の行動ラベルデータを収集するインターフェースを使用している. このような行動ラベルデータ収集の際, 居住者のプライバシー問題などの観点から, 居住者自身がラベリングを行なっているが, 詳細なラベルデータ収集には大きな負担がかかってしまう. そのような状況だと居住者はストレスを必要以上に感じ, 行動分析においてノイズとなるデータが多く発生してしまう原因となる.

Tonkin ら [12] は, 行動ラベル収集に専用のスマートフォンアプリケーションを使用し, テキストや音声を用いて行動を記録するシステムを構築している. 12 人の被験者を対象として, スマートホームで生活してもらいながら専用アプリケーションを利用してもらい, 被験者自身が行動を記録することの有効性を調査している. しかし, このシステムは行動を逐一専用のアプリケーションで記録する必要があり, 被験者に大きい負担がかかっている.

### 3. センシングシステム

本章では, 実証実験を行うにあたり使用したテストフィールドやセンサ, アノテーション方法などについて説明する.

#### 3.1 IoT スマートホーム

本研究では, 株式会社 NTT ドコモの協力の下, 同社が運用する IoT スマートホームをテストフィールドとして生活実験を行った. IoT スマートホームは, 同社が人々の生活・暮らしをサポートする家を実現するために構築したものである. IoT スマートホームの外観および内観を 図 1, 図 2 に示す. IoT スマートホームは, けん引移動が可能なトレーラーハウスに実装されている.

IoT スマートホームには多種多様な IoT デバイスが設置されており, これらを IoT アクセス制御エンジンが管理およびコントロールすることで快適で健康的な空間を作り出している. 様々な IoT デバイスにより収集される生活情報は, 宅内のホームゲートウェイ装置を経由して, IoT アクセス制御エンジンで取得することが可能である. 実験に際し, 標準搭載されたセンサ群からのデータに加えて, 簡易センシングキットである SALON システム [6] (以下, SALON と記載) を設置してデータを収集した. SALON は, 人感センサ, 環境センサ, ドアセンサ, NUC (ミニコンピュータ) からなるセンシングシステムである.



図 1: IoT スマートホームの外観



図 2: IoT スマートホームの内観

#### 3.2 アノテーションアプリ

実証実験ではアノテーション用に専用のアプリケーションを開発した. アプリケーション画面を 図 3 に示す. このアプリケーションは宅内行動を簡単な操作で記録することができるアプリケーションである. 行動のアイコンを一回タップすると行動開始となり, 図 3 内の食事アイコンのように青く点灯する. そして, その行動名と行動開始時刻がデータベースに格納される. 青く点灯した行動のアイコンをもう一度タップすると行動終了となり, 図 3 内の食事アイコン以外の行動アイコンのように消灯する (灰色になる). その後, その行動名と行動終了時刻がデータベースに格納される. なおラベリングする際は, マルチラベルを禁止とし, 常にどれか一つの行動を行っている状態とした. 例えば, テレビを見ながら食事をする, というような複数の行動を同時に行うような場合には, 主となる行動 (各自の判断による) のアイコンのみ点灯している状態とした.

また, 実証実験を行うにあたり, 宅内行動を網羅的にカバーできるよう 12 種類の行動の開始および終了を定義した. それぞれ定義した行動をまとめたものを 図 4 に示す. この 12 種類の中に含まれない行動に関しては「その他」として記録する. この行動定義では人によって行動開始・終

表 1: 正確なアノテーションをした場合

	平均
Accuracy	0.84
F 値	0.60

表 2: 一般被験者がアノテーションした場合

	被験者 1	被験者 2	被験者 3	平均
Accuracy	0.18	0.49	0.62	0.43
F 値	0.15	0.23	0.28	0.22



図 3: アノテーションアプリの画面

了の記録するタイミングがバラつくのを抑制するため、「～始める直前」や「～した直後」というような定義を行っている。

## 4. 実証実験

行動認識に精通する研究者が行う正確なアノテーションと一般人が行うアノテーションにおいて、分析結果にどれほどの違いがあるかを明らかにするため、実証実験を行った。本章では、その実験概要、分析手法及び実験結果について述べる。

### 4.1 実験概要

本実験では 1 名ずつ IoT スマートホームで約 1 週間生活をし、データの収集を行なった。また、普通の（一般人による）アノテーションと正確な（研究者による）アノテーションにおける行動認識精度の違いを明らかにするため、一般被験者 8 名と、行動認識に詳しく正確なアノテーションをすることが可能な研究者 2 名を実験参加者とした。研究者 2 名の実験は 2021 年 7 月 7 日～2021 年 7 月 16 日にかけて実施し、一般被験者 8 名の実験は 2021 年 10 月 19 日～2021 年 12 月 20 日にかけて実施した。

### 4.2 分析手法

行動認識の手法として、機械学習モデルの一種であり、勾配を利用し複数の決定木を組み合わせて識別性能を上げるアンサンブル学習手法である XGBoost を使用した。1 分ごとの特徴量から 12 種類の行動の中でどの行動を行っているかを予測する分類モデルを構築し、精度検証を行った。精度検証にはデータの時系列性を保持したまま交差検証を行うことで、構築した分類モデルの評価を行なった。具体的には、取得したデータを日によって分け、1 日をテストデータ、もう 1 日を検証用データとし、残りの日を訓練データとした。なお、正確なアノテーションをした場合と一般被験者によりアノテーションをした場合の行動認識精度の違いを明らかにするため、前者と後者はそれぞれ独立して分析を行なった。評価指標には、Accuracy と F 値を用いた。Accuracy は、全サンプルのうち、分類したクラスと正解クラスが一致する数の割合のことをいい、F 値はトレードオフの関係にある再現率 (Recall) と適合率 (Precision) の調和平均をとったものである。ここで、再現率とは、真の値が正解クラスのもののなかで正解クラスと予測された割合を表す指標で、適合率とは正解クラスと予測したもののなかで真の値が正解クラスの割合を表す指標である。

### 4.3 分析結果及び考察

表 1 に、正確なアノテーションをした場合の行動 13 種類の Accuracy, F 値のマクロ平均を示す。また、表 2 に、一般被験者がアノテーションをした場合の行動 13 種類の Accuracy, F 値のマクロ平均を示す。

表 1 より、正確なアノテーションをした場合、すべての行動において、Accuracy が高く、F 値が低い傾向が読み取れる。平均では、0.84 の Accuracy を達成し、F 値に関しても 0.60 という結果が得られた。一方、表 2 を見ると、正確なアノテーションをした場合に比べて Accuracy および F 値と比べてかなり低くなっていることがわかる。また、F 値の下がり幅が Accuracy の下がり幅よりも大きいことから、データ点数の少ない行動がより当てづらくなっていることがわかる。

正確なアノテーションをした場合と比較して一般人がア

	行動	行動の定義	開始	終了
1	外出	家から出る	玄関から外に出る直前	玄関から中に入った直後
2	身支度	着替えなどの外出の準備	身支度を始める直前	身支度を終えた直後
3	睡眠	睡眠をとる	布団に入る直前	布団から出た直後
4	食事	料理を食べる	食べ始める直前	料理を食べ終わった直後
5	個人衛生	手洗い、歯磨き、化粧などの洗面台に立った時の行動	洗面台の前に立った瞬間	洗面台から離れる瞬間
6	トイレ	トイレをする	トイレに入る直前	トイレから出た直後
7	入浴/シャワー	浴室で体を洗う	浴室に入る直前	浴室から出た直後
8	料理	キッチンで料理する(レンジ調理含む)	料理を始める直前	料理を終えた直後
9	食器洗い	食器を洗う	食器を洗い始める直前	食器洗いを終えた直後
10	洗濯	洗濯に関する行動(洗う→干す→取り込む→片付ける)	洗濯物を洗濯機に入れる直前	洗濯機の操作を終えた直後
11	TV視聴	TVを視聴する	TVの電源をつける直前	TVの電源を消した直後
12	スマートフォン/タブレット	スマートフォン/タブレットを使う(貸与されたiPadを除く)	スマートフォン/タブレットを持って操作し始める直前	スマートフォン/タブレットを操作し終えた直後
13	仕事/勉強	仕事/勉強等でPC・本を使う作業	作業を開始する直前	作業を終了した直後

図 4: 行動定義

ノテーションした場合の行動予測精度が低かった原因について考察する。各被験者には行動記録アプリを用いてアノテーションを行ってもらったが、明らかな人為的ミスが多々見られた。例えば、被験者がトイレの終了を記録し忘れていることや、家の中の人感センサが頻繁に反応しているのにも関わらず、ラベルはずっと外出になっている事例があった。このようなアノテーションの際のミスが、常に行動ラベルを記録するという通常のアノテーション方法では多発する恐れがある。

さらに各被験者が記録した行動ラベルを見ると、1週間のうちで全くTV視聴をしない被験者や外出を長時間する人など、被験者によってつけた行動に偏りがあることがわかった。本実験では12種類の行動を定義して行動を記録してもらったが、行動数が増えるとその傾向はより顕著になると思われる。

行動記録アプリのようなアノテーションの既存手法には上記のような課題が残されており、一般の被験者を募ってアノテーションを行う実験において正確なデータを収集するのは非常に困難であることがわかる。

## 5. 質問ベースアノテーション法の提案

前章では、宅内行動認識において、既存のアノテーション手法には課題があることを示した。今回の実験では12種類の行動を対象としたが、さらに粒度の細かいアノテーションデータの収集が必要な際には、より高い頻度で行動に関するアンケートに答えたり、生活中に逐一行動を記録




図 5: システムの概略図

することが求められるため、居住者の負担がとて大きくなる。結果的にラベルを記録する煩わしさから居住者が記録することを放棄してしまったり、正確に記録しなくなる可能性が高い。そこで、それらの課題を解決するための新しいアノテーション方法として、質問によってアノテーションデータを収集するシステムを提案する。本章では、それらの概要及びシステム構成について述べる。

### 5.1 システム概要

既存のアノテーション手法の課題を解決するために質問によってアノテーションするシステムを提案する。システムの概略図を図5に示す。提案システムでは、居住者が生活中、タブレット端末から時折「現在、どんな行動を行なっていますか?」のような質問が表示される。その質問に居住者が回答した場合、その回答した行動と時刻がアノテーションデータとしてデータベースに蓄積される。提案システムでは質問が表示された時のみ行っている行動を回答すれば良いため、逐一記録を行う既存手法と比較して記録するための労力が少なくなり、居住者の負担が軽減できる。

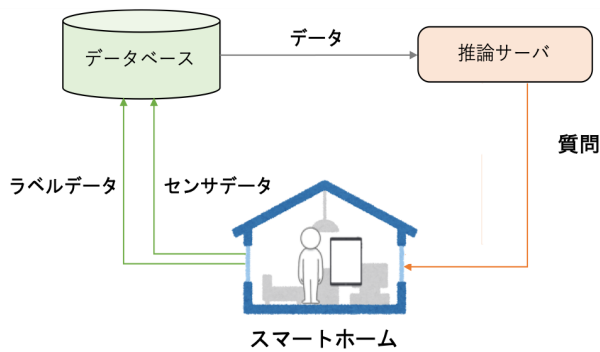


図 6: システムの構成図



図 7: 質問の例

## 5.2 システム構成

提案システムの概要図を以下に示す。次に、本システムを構成する各種センサおよびサーバ、質問に用いるタブレット端末について述べる。

### 5.2.1 センサ類

居住者の宅内行動をセンシングするため、様々なセンサを用いた。センサの種類は人感センサ、環境センサ、ドアセンサなどである。これらをスマートホームの各所に配置することにより、居住者の宅内行動を網羅的にセンシングする。

### 5.2.2 データベース

居住者が質問に回答することにより取得するアノテーションデータとセンサにより取得したデータは常にデータベースに蓄積する。提案システムでは、データベースとして InfluxDB を用いる。InfluxDB は時刻情報を主キーとしたデータを扱うことができ、IoT デバイスのセンサデータや加減のログデータなどの時系列データを扱うのに適しているオープンソースのデータベースである。

### 5.2.3 推論サーバ

推論サーバでは、データベースに格納されたアノテーションデータおよびセンサデータを用いてリアルタイムで居住者の行動予測を行う。あらかじめ学習した機械学習モデルにリアルタイムにデータを入力して行動推定を行い、各行動を行っている確率を出力する。このサーバから、推定確率が低い行動を行っている時（その行動のデータが十分にない場合に相当）に、タブレット端末に質問を送信する。タブレット端末に表示される質問の例を図 7 に示す。

### 5.2.4 タブレット端末

提案システムの有効性を調査する際、居住者にはタブレット端末を用いて生活してもらう。このタブレット端末にサーバから送られる質問が表示される。また、居住者の生活中にいつ質問が表示されても良いように、常に電源に接続されており、画面はロックがかからないような設定をしている。さらに、質問の方法には、タブレット端末の画面上に質問を表示する方法と、タブレット端末から鳴る音声によって質問を読み上げる方法の 2 パターンあるた

め、提案システムではタブレット端末を 2 つ用いる。各端末にはサーバから送信された質問を受信するためのアプリケーションがインストールされており、提案システムを検証する際には常にそのアプリケーションが起動している状態にしておく。

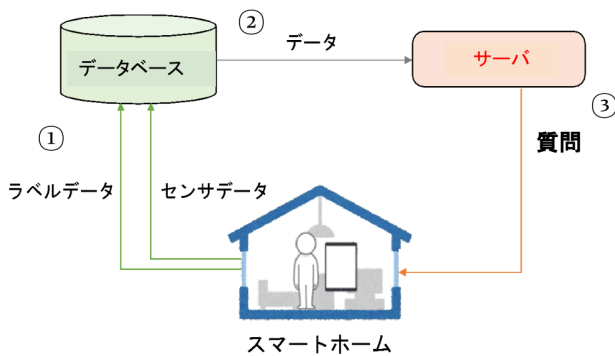
## 6. 提案システムに対する評価実験

5 章で述べた質問によってアノテーションするシステムを評価するため、実証実験を行なった。ただし、5.2 節で示した提案システムのうち、居住者にタブレット端末を介して質問を行い、その回答をアノテーションデータとして収集するシステムまでの実装を行なった。提案システムの構成の一つである推論サーバに関しては未実装であるため、質問を表示するタイミングは 1 時間に 1 回で固定した。本実験で用いたシステム概要図を図 8 に示す。

### 6.1 実験概要

評価実験では、質問によるアノテーションシステム（以下、提案システム）と常に行動を記録する行動記録アプリによるアノテーションシステム（以下、既存手法）を比較するため、各被験者には 1 週間の前半を既存手法、1 週間の後半を提案システムを用いて行動ラベルデータを記録してもらった。なお、既存手法から提案システムに切り替える際、タブレット端末上のアプリを切り替える必要があるため、被験者にはその作業を事前に説明し、被験者自身に行ってもらった。

当初は全被験者に上記のスケジュールで生活してもらう予定だったが、質問を行うアプリおよびサーバにシステムトラブルが頻発したため、既存手法と提案システムの両方を用いて生活を行った被験者は 8 人中 6 人であった。また、そのうち 3 人はシステムトラブル等によって、提案システムで回答した行動ラベルが保存できていなかったため、既存手法と提案システムの両方から正常にデータが得られた被験者は 3 人であった。



※ 推論サーバではなく、1時間に1回質問を送信するサーバに変更

図 8: 実験で使ったシステムの概要図

表 3: 質問への回答状況

	被験者 6	被験者 7	被験者 8
質問生成回数	44	29	74
回答可能な時の質問回数	20	5	32
回答回数	10	4	18
回答率	0.50	0.80	0.56

## 6.2 各被験者の回答状況

提案システムで収集した行動ラベルデータの分析を行う。はじめに、正常にデータを収集できた3人の質問への回答状況を表3に示す。表中の「質問生成回数」とは、各被験者の実験中にタブレット端末上に質問が表示された回数である。「回答可能な時の質問回数」とは、各被験者が質問に回答することが可能な状態である時にタブレット端末上に質問が表示された回数である。例えば、被験者がTV視聴中であった場合は質問に気付くことができ、理論上は回答可能であるが、被験者が外出中であった場合は質問に気付くことは出来ず回答は不可能である。本実験では、質問が表示された時間の前後で人感センサおよび床センサが全く反応していなかった場合、被験者は外出中もしくは睡眠中であるとして、回答不可能な状態とした。「回答回数」とは被験者が実験中に質問に回答した回数であり、「回答率」とは「回答可能な時の質問回数」の中の「回答回数」の割合である。この表を見ると、いずれの被験者においても回答率は50%を超えていることがわかる。しかし、システムの不具合や被験者がタブレット端末上のアプリの切り替えを忘れることなどがあったため、各被験者の実験中に表示された質問の回数が大幅に異なってしまった。また、本実験では長時間外出した被験者がいたのも、その原因の一つだと考えられる。

次に、各被験者が1日あたりに既存手法で記録した行動ラベル数を表4に示す。被験者によって既存手法で行動ラベルを記録した日数が異なるため、各日数で割ることで1日あたりのラベル数を算出した。なお、このラベル数は行動の開始と終了は別々でカウントしている。これを見ると

被験者によってかなり行動ラベル数に差があることがわかる。また、4章の正確なアノテーションをした研究者2人はそれぞれ1日あたり56回と80回のラベルを記録しており、本実験で記録された行動ラベル数とは大きな差がある。そのため、やはり一般の被験者が既存手法で行動データラベリングをしても詳細で正確なデータは得られない可能性が高い。

## 6.3 提案システムの評価および考察

表3より、提案システム使用時に最も多く回答した被験者は被験者8で、回答回数は18回であった。被験者8が提案システムで行動データラベリングしたのは3日間であるため、1日あたり6回の行動データラベリングをしたことになる。これは既存手法で記録された1日あたりの行動ラベル数と比較すると、1/6の数になる。そこで提案システムで得られる行動ラベル数と同程度にしても行動分類精度が保たれるかを確認するため、既存手法で得られたデータ数を1/6に減らして訓練データを作成し、それをもとに行動分類モデルを構築した。なお、提案システムで行動を回答する場合、被験者が誤ったラベリングをすることは考えにくい。故に、既存手法で得られたデータをクリーニングし、そこからデータ数を減らし、訓練データおよびテストデータを作成した。また、データ数はランダムに減少させたため、乱数によって結果が変わる可能性がある。そのため各データをそれぞれ10回ずつ学習させて予測精度を出し、それらの平均を取ったものを提案手法の予測精度とした。予備実験で行ったような理想的なラベリングをした場合、既存手法を用いてラベリングした場合、既存手法を用いてラベリングした後にそのデータをクリーニングした場合、提案手法でラベリングした場合のAccuracyを比較した結果を表5に、F値を比較した結果を表6に示す。

これらの結果について考察を行う。データ数を1/6まで減らしたクリーニング後の既存手法のデータを用いて構築した行動予測モデルの精度は、クリーニング前の既存手法のデータを用いたものよりも高くなることがわかった。前者の方が圧倒的にデータ量が少ないにもかかわらず精度は後者よりも高いため、一般被験者が既存手法で記録したアノテーションデータには不正確な情報が多く含まれていることが改めて確認された。

## 7. まとめ

本研究では、まず、IoTスマートホーム<sup>®</sup>において、正解値のアノテーションが正確に行われた場合に構築された行動認識モデルの精度を評価し、その後、一般被験者のアノテーションにより構築されたモデルの精度を評価し、比較を行った。その結果、正確なアノテーションが行われた場合には高い行動認識精度が達成できることが分かったが、一般被験者のアノテーションが正確に行われなかったこと、ま

表 4: 被験者が記録した 1 日あたりのラベル数

	被験者 1	被験者 2	被験者 3	被験者 4	被験者 5	被験者 6	被験者 7	被験者 8	平均
ラベル数	52	42	20	38	46	34	21	41	36

表 5: Accuracy の比較

	被験者 1	被験者 3	被験者 5	平均
理想的なラベリング	-	-	-	0.84
既存手法を用いたラベリング (クリーニング前)	0.18	0.49	0.62	0.43
既存手法を用いたラベリング (クリーニング後)	0.37	0.72	0.80	0.63
提案システム	0.30	0.54	0.62	0.49

表 6: F 値の比較

	被験者 1	被験者 3	被験者 5	平均
理想的なラベリング	-	-	-	0.60
既存手法を用いたラベリング (クリーニング前)	0.15	0.23	0.28	0.22
既存手法を用いたラベリング (クリーニング後)	0.34	0.34	0.43	0.37
提案手法	0.24	0.29	0.30	0.28

た、それにより構築された認識モデルの精度が低くとどまることが確認された。そこで、新しいアノテーションの方法である「質問によるアノテーションシステム」を提案した。「質問によるアノテーションシステム」を用いれば、居住者のアノテーションの負担を軽減でき、かつより正確なデータを収集することができる。今回の評価は、提案システムへの回答頻度を元に既存手法で得られたデータから作成した疑似データを用いて行った。提案システムの有効性をより詳しく調査するためには、今回未実装であった推論サーバを実装して提案システムを運用した上で、アノテーションデータを取得する必要がある。また、現在実装済みの提案システムでは質問に回答してもらった行動は記録できるが、その行動の正確な開始・終了時刻を記録することはできていない。そのため推論サーバを実装して行動認識精度の変化などを検知することによって、行動の開始・終了を自動的に記録することが課題となる。さらに評価実験では居住者から提案システムの使用が難しいとの意見もいただいたため、一般被験者が快適に使えるようにユーザビリティを高めていくことも検討が必要である。

## 参考文献

[1] 上田健揮, 玉井森彦, 荒川豊, 諏訪博彦, 安本慶一. ユーザ位置情報と家電消費電力に基づいた宅内生活行動認識システム. 情報処理学会論文誌, Vol. 57, No. 2, pp. 416–425, 2016.

[2] 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*, pp. 437–442. IEEE, 2017.

[3] 柏本幸俊, 秦恭史, 中川愛梨, 諏訪博彦, 藤本まなと, 荒川豊, 繁住健哉, 小宮邦裕, 小西健太, 安本慶一ほか. エナジハーベスト型赤外線・ドア開閉センサと家電消費電力に基づいた宅内生活行動認識システム. 情報処理学会論文誌, Vol. 58, No. 2, pp. 409–418, 2017.

[4] 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.

[5] Nagender Kumar Suryadevara, Subhas C Mukhopadhyay, Ruili Wang, and RK Rayudu. Forecasting the behavior of an elderly using wireless sensors data in a smart home. *Engineering Applications of Artificial Intelligence*, Vol. 26, No. 10, pp. 2641–2652, 2013.

[6] Tomokazu Matsui, Kosei Onishi, Shinya Misaki, Manato Fujimoto, Hirohiko Suwa, and Keiichi Yasumoto. Salon: Simplified sensing system for activity of daily living in ordinary home. *Sensors*, Vol. 20, No. 17, p. 4895, 2020.

[7] Wataru Sasaki, Masashi Fujiwara, Manato Fujimoto, Hirohiko Suwa, Yutaka Arakawa, and Keiichi Yasumoto. Predicting occurrence time of daily living activities through time series analysis of smart home data. In *2019 IEEE International Conference on Pervasive Computing and Communications Workshops*, pp. 233–238, 2019.

[8] 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 home. In *2020 IEEE International Conference on Pervasive Computing and Communications Workshops*, pp. 460–465, 2020.

[9] 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.

[10] 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.

[11] Ana Caraban, Evangelos Karapanos, Daniel Gonçalves, and Pedro Campos. 23 ways to nudge: A review of technology-mediated nudging in human-computer interaction. In *Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems*, pp. 1–15, 2019.

[12] Karen A Gelmon, Marc Tischkowitz, Helen Mackay, Kenneth Swenerton, André Robidoux, Katia Tonkin, Hal Hirte, David Huntsman, Mark Clemons, Blake Gilks, et al. Olaparib in patients with recurrent high-grade serous or poorly differentiated ovarian carcinoma or triple-negative breast cancer: a phase 2, multicentre, open-label, non-randomised study. *The lancet oncology*, Vol. 12, No. 9, pp. 852–861, 2011.