

## 修士論文

スマートホームにおける宅内情報を用いた  
時間内次行動生起の予測手法とその評価

佐々木 渉

2019 年 3 月 15 日

奈良先端科学技術大学院大学  
情報科学研究科

本論文は奈良先端科学技術大学院大学情報科学研究科に  
修士(工学) 授与の要件として提出した修士論文である。

佐々木 渉

審査委員：

|           |         |
|-----------|---------|
| 安本 慶一教授   | (主指導教員) |
| 中村 哲 教授   | (副指導教員) |
| 荒川 豊 准教授  | (副指導教員) |
| 諏訪 博彦 助教  | (副指導教員) |
| 藤本 まなと 助教 | (副指導教員) |

# スマートホームにおける宅内情報を用いた 時間内次行動生起の予測手法とその評価\*

佐々木 渉

## 内容梗概

宅内において、居住者が次に行う行動を予測することは、より良い宅内サービスを実現するために有益である。例えば、次に生起する行動が入浴だと予測できれば、浴槽への自動湯はりサービスが期待できる。宅内行動予測のためには、次行動の種類と次行動生起までの時間を予測する必要がある。しかし、既存研究では、次行動生起までの時間を回帰問題として予測した結果、各行動において1時間以上の平均絶対誤差が発生しており、家電の先回り制御などの実サービスに適用しづらいという問題があった。そこで、本論文では、行動ごとに次行動生起までの時間を複数の時間範囲に分類して予測する手法を提案する。本手法において、分類する時間範囲の設定が重要となる。まず、行動中、10分以内、10～30分、30～60分、1～2時間、2～3時間、3時間以上（もしくは生起しない）の計7つに分類するモデルを考えた。しかし、分類するクラス数が多い場合、予測精度が実用的ではないことがわかった。そのため、行動中、もしくは10分、30分または1時間以内に生起するか否かという分類を行い問題を単純化した。評価実験のために、超音波位置センサ、Bluetooth ワットチェッカー、クランプ式 CT センサ、人感センサ、宅内家電を用いて5人の被験者による合計20日間の生活行動データ（10秒毎の行動ラベルの真値を含む）を収集した。収集データは、10秒おきに次行動生起までの時間範囲ラベルへの変換と特徴量抽出を行った。LSTMによって学習モデルを作成した結果、18種類の対象行動のうち、平均予測再現率が33%以上を達成できたものが30分以内では3種類（37.0%～53.8%）、1時間以内では4

---

\*奈良先端科学技術大学院大学 情報科学研究科 修士論文, 2019年3月15日.

種類 (37.0%~56.4%) であった。さらに、提案手法の精度改善の可能性を調べるため、回帰による行動予測モデルを構築し、回帰を用いている既存手法と比較した。比較のために、超音波位置センサ、人感センサ、ドアセンサ、宅内家電情報（分電盤による電気系統の消費電力を含む）を用いて新たに 20 日間のデータ（10 秒ごとの行動ラベルの真値含む）を収集し、10 秒おきに次行動生起までの時間への変換と特徴量抽出を行った。LSTM により回帰モデルを作成した結果、提案手法では平均絶対誤差 15,000[s] 程度で予測できることがわかり、既存研究の 8,402[s] と比べて精度改善の余地があることが分かった。

## キーワード

スマートホーム, 宅内行動, 宅内センサ, 行動予測, LSTM

# A Method for Predicting Occurrence of Daily Living Activity within Specified Time and its Evaluation using Smart Home Sensor Data\*

Wataru Sasaki

## Abstract

Activities of Daily Living (ADL) prediction is beneficial for better home service. For example, if smart home can predict that next activity of the resident is bathing, then it can automatically fill hot water into the bath. We need to predict the next activity type and the time to the occurrence of the next activity in ADL prediction. However, previous methods cannot be applied to appliance control as a realistic service with anticipating resident, because mean absolute error (MAE) is over an hour in each activity prediction. In this thesis, we propose to predict the occurrence time of ADL by categorizing the time to some time ranges. It is important to effectively categorize the time to the occurrence of the next activity in this method. First, the time of the next activity occurrence is classified into 7 time ranges (classes): “Now,” “occur within 10 minutes,” “occur between 10 and 30 minutes,” “occur between 30 and 60 minutes,” “occur between 1 and 2 hours,” “occur between 2 and 3 hours,” and “occur after more than 3 hours passed (or not occur).” However, accuracy of ADL prediction will be low and thus not useful, when categorizing the time of the next activity occurrence into many time ranges. Thus, we simplify the time range for prediction into “activity is already occurring,” “activity occurs within a specified time limit,” and “activity will not

---

\*Master’s Thesis, Graduate School of Information Science, Nara Institute of Science and Technology, March 15, 2019.

occur within the time limit,” where we use, for example, 10 minutes, 30 minutes or an hour for the time limit. We collected ADL dataset (including activity labels on each 10 second) for 20 days in a smart home where sensors are ultrasonic positioning system, Bluetooth watt checker, clamp-on CT (Current Transformer) sensor, motion sensor, and ECHONET Lite ready appliance are deployed. For each of 10 second data segments, we converted activity labels to the time ranges to the occurrence of the next activity and extracted features from sensor data. We constructed an LSTM model, and it achieved average prediction recall 33% or more for three types activities with 30 minutes time limit (37.0%~53.8%), and for four types with 1 hour time limit (37.0%~56.4%), out of 18 activities. Additionally, we compared our ADL prediction regressor with previous work to explore room for improvement of the proposed method. We collected new ADL dataset (including activity labels on each 10 second) for 20 days in a smart home and installed sensors such as ultrasonic positioning system, motion sensor, door sensor, and ECHONET Lite ready appliance and converted the ground truth labels to the time to the next activity occurrence and extracted features from the sensor data. We constructed an LSTM model that achieved about 15,000[s] as MAE of time until next activity occurrence. As a result, we found that there is room for improvement in accuracy, referring to 8,402 [s] of MAE in the previous research.

**Keywords:**

smart home, activities of daily living, sensors in the home, activity prediction, LSTM

# 目次

|                                      |           |
|--------------------------------------|-----------|
| <b>1. 序論</b>                         | <b>1</b>  |
| 1.1 研究背景 . . . . .                   | 1         |
| 1.2 研究目的と提案手法 . . . . .              | 2         |
| 1.3 得られた結果 . . . . .                 | 3         |
| 1.4 論文の構成 . . . . .                  | 4         |
| <b>2. 関連研究と先行研究</b>                  | <b>5</b>  |
| 2.1 オープンデータセット . . . . .             | 5         |
| 2.2 宅内行動認識 . . . . .                 | 5         |
| 2.2.1 ウェアラブルデバイスを用いた行動認識手法 . . . . . | 6         |
| 2.2.2 一人称カメラを用いた行動認識手法 . . . . .     | 7         |
| 2.2.3 宅内センサを用いた行動認識手法 . . . . .      | 7         |
| 2.2.4 先行研究 . . . . .                 | 8         |
| 2.3 宅内行動予測 . . . . .                 | 8         |
| 2.3.1 ベイジアンネットワークを用いた行動予測 . . . . .  | 9         |
| 2.3.2 回帰木を用いた行動予測手法 . . . . .        | 9         |
| 2.3.3 LSTM を用いた行動予測手法 . . . . .      | 10        |
| <b>3. 宅内行動予測における課題と予測手法の検討</b>       | <b>11</b> |
| 3.1 宅内行動予測における課題 . . . . .           | 11        |
| 3.2 行動予測手法の検討 . . . . .              | 12        |
| <b>4. 宅内行動生起までの時間範囲の分類予測</b>         | <b>14</b> |
| 4.1 提案手法 . . . . .                   | 14        |
| 4.2 実験概要 . . . . .                   | 15        |
| 4.2.1 対象行動 . . . . .                 | 16        |
| 4.2.2 宅内センサデータ . . . . .             | 16        |
| 4.2.3 被験者への指示 . . . . .              | 19        |
| 4.3 データ分析 . . . . .                  | 20        |

|           |                           |           |
|-----------|---------------------------|-----------|
| 4.3.1     | 評価方法 . . . . .            | 20        |
| 4.3.2     | 行動予測モデル . . . . .         | 20        |
| 4.3.3     | 特徴量抽出 . . . . .           | 20        |
| 4.3.4     | 次行動生起期間の予測 . . . . .      | 21        |
| 4.3.5     | 時間内次行動生起の予測 . . . . .     | 24        |
| <b>5.</b> | <b>回帰による宅内行動生起までの時間予測</b> | <b>26</b> |
| 5.1       | 次行動生起までの時間の回帰 . . . . .   | 26        |
| 5.2       | 実験概要 . . . . .            | 26        |
| 5.2.1     | 対象行動 . . . . .            | 27        |
| 5.2.2     | 宅内センサデータ . . . . .        | 28        |
| 5.2.3     | 被験者への指示 . . . . .         | 29        |
| 5.3       | データ分析 . . . . .           | 30        |
| 5.3.1     | 評価方法 . . . . .            | 30        |
| 5.3.2     | 行動予測モデル . . . . .         | 30        |
| 5.3.3     | 特徴量抽出 . . . . .           | 30        |
| 5.3.4     | 実験結果 . . . . .            | 31        |
| <b>6.</b> | <b>結論</b>                 | <b>33</b> |
|           | 謝辞                        | 36        |
|           | 参考文献                      | 37        |

## 図 目 次

|   |                                     |    |
|---|-------------------------------------|----|
| 1 | スマートホーム内観 . . . . .                 | 15 |
| 2 | ECHONET Lite 対応家電の設置図 . . . . .     | 18 |
| 3 | 人感センサの設置図 . . . . .                 | 19 |
| 4 | 次行動生起期間の予測の再現率 . . . . .            | 23 |
| 5 | 時間内行動生起の再現率 . . . . .               | 25 |
| 6 | 開発した行動ラベリング用アプリケーションの画面 . . . . .   | 28 |
| 7 | 宅内に設置した人感センサおよびドアセンサの設置図 . . . . .  | 29 |
| 8 | 行動別次行動生起までの時間の回帰予測による平均絶対誤差 . . . . | 32 |
| 9 | Minor らが提案している行動別次行動生起までの時間の予測結果 .  | 32 |

## 表 目 次

|   |                                               |    |
|---|-----------------------------------------------|----|
| 1 | 次行動生起までの時間範囲の分類予測に向けた実験での対象行動<br>一覧 . . . . . | 16 |
| 2 | 消費電力の測定対象 . . . . .                           | 17 |
| 3 | 次行動生起期間の予測の再現率 . . . . .                      | 23 |
| 4 | 時間内行動生起の再現率 . . . . .                         | 25 |
| 5 | 次行動生起までの時間の回帰予測に向けた実験での対象行動一覧 .               | 27 |
| 6 | 分電盤の計測対象電気系統一覧 . . . . .                      | 29 |

# 1. 序論

## 1.1 研究背景

近年、宅内での位置情報を利用したサービスは多く存在している。宅内家電が人間の位置を認識することで、照明のオンオフやエアコンの自動風向調整などのサービスが実現可能となった。また、宅内行動認識を用いた、お年寄りの見守り [1, 2] や省エネを目的とした家電制御 [3, 4] が行われている。我々は、宅内における行動予測を実現し、行動の背後の欲求を満たすような家電制御が事前にできれば、日常生活をより豊かにできると考える。例えば、朝の起床に合わせてコーヒーを準備したり、お風呂に入る前に自動で湯張りを行なったりするサービスである。宅内行動予測は、現在行われている行動の種類を予測するような宅内行動認識の発展であり、次行動の種類だけでなく次行動生起までの時間も予測する必要がある。

Minor ら [5, 6, 7] は、CASAS データセット [8] を用いて宅内行動予測を行なっている。この手法では、人感センサやドアセンサなどの離散センサ、温度センサや光量センサなどの周期センサから離散特徴量、周期特徴量を抽出している。そして、行動ごとに次の行動が生起するまでの時間を予測するモデルを回帰木で作成しており、平均絶対誤差 8,402.01[s] を達成している。しかし、2 時間近くの誤差があることで、実サービスに適用しづらいという課題がある。また、Tax らは CASAS データセットおよび Kasteren データセット [9] を用いて、LSTM (Long Short Term Memory) による次行動の種類と次行動生起までの時間を予測するモデルを提案しており、次行動種類の予測精度 26.9~52.9%，次行動生起までの時間の平均絶対誤差 1210.32~3757.70[s] を達成している。この手法では、次の行動の種類と次行動の生起時間を別々に学習しており、ある特定の行動が一定時間後に起こる確率しか予測できないため、実サービスに適用しづらい。このように既存の宅内行動予測手法では、より直近での予測を要する家電の先回り制御などの実サービスに適用しづらいということが課題である。

## 1.2 研究目的と提案手法

1.1 節において、既存研究で提案されている行動予測手法が実サービスに適用しづらいことが明らかとなった。ここで、実用的なサービスとして期待される家電の先回り制御の例がいくつか考えられる。

- (1) 10 分以内の起床予測→自動でコーヒーを準備
- (2) 30 分以内の入浴予測→自動で浴槽の湯はり
- (3) 1 時間以内の睡眠予測→自動で寝室の空調の設定

このように、適用するサービスによって予測すべき次行動生起までの時間範囲が異なると考えられる。このような実サービスを実現するための行動予測手法として、本論文では、行動ごとに指定時間範囲内で生起するかどうかを予測するという手法を提案する。提案手法では、学習モデルの正解ラベルとして指定時間範囲を定める。まず、行動中、10 分以内、10～30 分、30～60 分、1～2 時間、2～3 時間、3 時間以上の計 7 つに分類するモデルを考えた（提案手法 1）。この分類ができれば、上記の家電先回り制御例に対応できる行動予測が実現できる。しかし、分類するクラス数が多い場合、予測精度が低くなることが予想される。そのため、行動中もしくは、10 分、30 分または 1 時間以内に生起するか否かという分類を行い問題を単純化する（提案手法 2）。この正解ラベルを学習するために宅内に設置したセンサデータのデータを収集する。データ収集は、2016 年度に守谷ら [10]、中川ら [11] が開発したスマートホームデータ収集システムを用いる。このデータ収集システムでは超音波位置センサ、Bluetooth ワットチェッカー、クランプ式 CT センサ、人感センサ、家電の状態を収集することができる。

また、回帰による行動予測精度を評価するために、LSTM による回帰モデルを構築し、既存研究に比べ我々の提案手法の予測精度がどの程度まで向上する可能性があるのか示す。この評価には、2018 年度に新たに開発されたスマートホームデータ収集システムでデータ収集したものを用いる。

### 1.3 得られた結果

提案手法 1, 2 を評価するための実験として 2017 年 8 月に奈良先端科学技術大学院大学にある 1LDK のスマートホーム設備を用いて被験者 5 人が 3 泊 4 日ずつ生活するデータ収集実験を行った。スマートホームでは、超音波位置センサによる位置情報、EnOcean<sup>1</sup>による人感センサの反応情報、クランプ式 CT センサによる宅内電気系統の電流値、Bluetooth ワットチェッカーによる宅内家電の消費電力値、ECHONET Lite<sup>2</sup>による宅内家電の情報を収集した。また、被験者自身で生活の様子を録画しておき、撮影動画を見ながら実験後に行動のラベリングを行う。提案手法 1 として、行動生起までの期間（10 分以内、10～30 分、30～60 分、1～2 時間、2～3 時間、3 時間以上）を正解ラベルとして、LSTM により分類を行った。その結果、対象とした 18 種類の行動の平均予測再現率が 10 分以内の場合 9.2%、10～30 分の場合 11.9%、30～60 分の場合 14.8%、1～2 時間の場合 15.8%、2～3 時間の場合 7.9%となった。行動別に見ると、食事においては 10 分以内に生起する場合のうち 45.5%で行動生起期間の分類が再現することが確認できた。しかし、分類するクラス数が多いため、それ以外の行動では行動生起期間の再現率が低く留まった。そのため、提案手法 2 として行動中もしくは、指定時間（10 分、30 分または 1 時間）内に行動が生起するか否かを正解ラベルとした分類による宅内行動予測を行った。対象行動とした 18 種類の行動のうち、平均予測再現率が 33%以上を達成できたものが 30 分以内では 3 種類（37.0%～53.8%）、1 時間以内では 4 種類（37.0%～56.4%）であった。

また、回帰による行動予測手法を評価するために、2018 年 8 月に奈良先端科学技術大学院大学にある 1LDK のスマートホーム設備を用いて被験者 5 人が 3 泊 4 日ずつ生活するデータ収集実験を行った。スマートホームでは、超音波位置センサによる位置情報、EnOcean センサ（人感センサ、ドアセンサ）、ECHONET Lite による宅内家電の情報（分電盤による電気系統の消費電力を含む）を収集した。また、行動のラベリングは専用モバイル端末用アプリで行う。ラベルの確認

---

<sup>1</sup>EnOcean は太陽光などによるエネルギーによって超低消費電力で通信できるエネルギーハーベスティング無線技術であり、ISO/IEC 14543-3-1X として標準化されている。

<sup>2</sup>ECHONET Lite は家電や IoT デバイスの制御やデータ取得を行うことができる通信プロトコルで、ISO/IEC-4-3 として標準化されている。

のため、被験者自身で生活の様子を録画しておく．このように収集したデータに対して、回帰による行動予測手法を適用した結果、平均絶対誤差 15,000[s] 程度で予測できることがわかった．これは CASAS データセット [8] を用いている Minorらの手法 [5, 6, 7] の 8433[s] に比べ改善の余地があることから、手法の改善やデータセットの変更により予測精度を向上できる可能性があることが分かった．

## 1.4 論文の構成

本論文の構成について述べる．2 章では、本研究に関連する宅内行動の行動認識や行動予測の研究について述べる．3 章では、2 章で明らかになった本研究で解決すべき課題をまとめ、本論文で提案する手法について述べる．4 章では宅内行動における時間内生起までの時間範囲の分類予測について述べる．5 章では我々の提案手法の予測精度向上の可能性を示すため、宅内行動生起までの時間の回帰予測について述べる．そして、6 章に結論を示す．

## 2. 関連研究と先行研究

本章では，宅内における行動認識または行動予測についての関連研究とその課題を述べる．まず，次節では関連研究を述べるために，関連研究で多く用いられるオープンデータセットについて述べる．その後，宅内行動認識・予測の関連研究について述べる．

### 2.1 オープンデータセット

関連研究において，スマートホームでの宅内設置型センサのオープンデータセットとして，CASAS データセット [8]，Kasteren データセット [9] が多く用いられる．CASAS データセット [8] には，ZigBee によって収集された宅内センサ情報と被験者の行動ラベルが記録されたデータセットである．宅内センサとしては，人感センサ，ドアセンサ，照明の電源のオン・オフ，温度センサ，光量センサなどが反応もしくは状態変化したときの情報が収集されている（行動認識には使用されないが，各センサのバッテリー状態も定期的に収集されている）．また，行動ラベルは手動で収集されたものである．Kasteren データセット [9] は，RFM 社の DM1810 というワイヤレスメッシュモジュールを用いて収集された宅内センサ情報と Bluetooth ヘッドセットまたは日誌形式での記録によって収集された行動ラベルで構成されている．宅内センサとして，ドアや戸棚の開閉を検知するリードセンサ，ソファやベッドに設置された圧力センサ，引き出しの開閉を検知する水銀センサ，赤外線人感センサ，トイレが流されたかどうか検知するフロートセンサのデータが収集されており，これら全てはセンサ毎のセンサ値の閾値によって 2 値情報が記録されている．

### 2.2 宅内行動認識

宅内行動の認識についての研究は多く存在する．次節以降，ウェアラブルデバイスを用いた手法，一人称カメラを用いた手法，宅内設置型センサを用いた手法

について詳細を述べる．また，先行研究として，我々の研究室で行ってきた宅内行動認識手法について述べる．

### 2.2.1 ウェアラブルデバイスを用いた行動認識手法

Espinilla ら [12] はウェアラブルデバイスの加速度を用いた宅内行動認識を提案している．アルスター大学の 141 人の学生を対象にデータ収集を行い，3 つの行動を 1 つのシナリオとした計 6 種類のシナリオを認識するモデルを構築している．加速度は 51.2Hz で収集し，4 秒（204 サンプル）ずつの重ならないスライディングウィンドウに分けて加速度の平均や最大値など 27 種類の特徴量抽出を行っている．また，学習アルゴリズムはナイーブベイズ，k 近傍法，決定木，多層パーセプトロン，サポートベクターマシーンを採用しており，10-Fold 交差検証を行っている．この結果，6 シナリオの分類では，k 近傍法を用いた場合が最も精度が高く，93.7%での認識を達成している．ウェアラブルデバイスを用いた手法では，加速度や角速度をスライディングウィンドウで区切ったのちに時間特徴量・周波数特徴量を抽出して，学習アルゴリズムに適用するという流れが一般的である．ウェアラブルデバイスを用いることで，装着部位の動作が異なる行動であれば容易に高精度で認識できる．

また，Amft ら [13] はダイエットのためのセンシングをウェアラブルデバイスで行う手法を提案している．首には食事の飲み込みをセンシングするセンサを，腕には食事を口に持っていくためのジェスチャーをセンシングするためのセンサを，耳には咀嚼音をセンシングするためのセンサを装着している．この手法では，食事という行動がわかるだけでなく，何を食べているかまで認識できるため，より細分化された多くの行動を認識できる．しかし，これらのウェアラブルデバイスを用いた行動認識手法では，多くのウェアラブルセンサを体に取り付けるため被験者の負担になる得る（課題 1）．

### 2.2.2 一人称カメラを用いた行動認識手法

Pirsiavash ら [14] は一人称カメラ画像を用いた行動認識を提案している。20 人の被験者を対象にデータ収集を行い、18 種類の宅内行動を認識するモデルを構築する。一人称動画は、スポーツイベント等での装着デバイスとして開発された GoPro を用いて、170 度の画角、1280×960 のサイズ、1 秒間に 30 フレームで撮影している。提案手法では、ImageNet と呼ばれる多くの画像が収録されたデータセットおよび実験時に収集された画像を使用して、撮影動画中の物体の認識を行う。そして、動画中に登場する物体とその時に行われている行動ラベルを紐づけることで学習モデルを構築する。フレームごとに物体を認識すると、認識精度が悪いため、時間ピラミッドと呼ばれる処理によって前後のフレームにある物体の存在を考慮した学習や、アクティブオブジェクトモデルと呼ばれる動作中物体を考慮したような学習を施して、約 40% の行動認識精度を達成している。また、物体の認識が完璧にできると仮定すると約 77% の認識精度を達成できると述べられている。この手法では、物体の認識精度が行動認識精度に直結しているため、今後の物体認識精度の向上によって、精度の向上が期待できる、しかしながら、カメラを使用しているため、居住者のプライバシーを侵害する可能性がある（課題 2）。また、居住者がデバイスを装着する必要があるため、課題 1 も抱えている。

### 2.2.3 宅内センサを用いた行動認識手法

Wan ら [15] は CASAS データセットを用いた宅内行動認識を提案している。彼らは、学習に使用する行動別のセンサイベント群（セグメンテーション）を自動で決定するために、センサ間の相関係数とセンサ反応時間の相関係数を算出している。これにより、センサイベントに基づいた行動種類の区分けを実現しており、各行動ごとのセンサの反応の違いを学習できている。学習アルゴリズムはナイーブベイズ、ベイジアンネットワーク、C4.5 決定木、ナイーブベイズ木、隠れマルコフモデルを使用しており、ナイーブベイズ木で約 95% の高精度での認識を実現している。しかし、分類対象の行動時間全てを対象に学習を行っているため、リアルタイムでの認識が難しく、行動の認識に時間がかかるという課題がある（課題 3）。

#### 2.2.4 先行研究

上田ら [16] は、屋内位置測位センサと家電に取り付けた電力センサのみを利用した宅内行動認識手法を提案した。これらのセンサのみを利用することで、プライバシーの侵害を抑えるだけでなく今後の低価格化・普及が見込める。また、認識可能な行動の種類は 10 種類（料理，食事，読書，TV 視聴，食器洗い，風呂，掃除，仕事・勉強，睡眠，外出）であり，平均認識精度が 91.3% である。また，屋内位置測位センサは NEC エンジニアリングの「超音波 3D 位置管理ソリューション SmartCoordinator®」を利用することで，1 秒に 2 回の周期で人の宅内位置情報を取得できる。しかしながら，このシステムを実現するには，これらのセンサを宅内環境に導入する必要がある，システム構築における負担が大きいという課題が存在する（課題 4）。また，利用した電力センサのサンプリング周期が 30 秒に 1 回であることから，行動を認識するまでにかかる時間は最低で 30 秒になってしまうため，課題 3 に関しても解決できていない。

守谷ら [10] は，ECHONET Lite 対応家電と人感センサを用いた宅内行動認識手法を提案した。ECHONET Lite 対応家電を用いることで，電力センサを新たに導入せず，家電の情報を取得できる。また，将来的に ECHONET Lite 対応家電に取り付けられることが予想される人感センサを用いることで，位置測位センサの導入することなく屋内の人の位置情報を取得できる。さらに，提案システムでは 1 秒間隔で家電情報を取得しているため，課題 3 の解決も可能である。しかし，行動認識精度は 68% であり，認識精度が低いという課題がある（課題 5）。

### 2.3 宅内行動予測

宅内行動認識と同様に，宅内行動予測に関しても多くの手法が提案されている。そのため，次節以降で，ベイジアンネットワークを用いた行動予測，回帰木を用いた行動予測手法，LSTM を用いた行動予測手法について述べる。

### 2.3.1 ベイジアンネットワークを用いた行動予測

Nazerfard ら [17] はベイジアンネットワークを用いた次行動予測手法を提案している。彼らは、CRAFT と呼ばれる、ある時点から次の時間における特徴量の予測手法を提案しており、次の時間での特徴量がわかることで、その特徴量から推定される行動も予測できる。評価実験として、2つのアパートを用いており、各家庭に人感センサ、開閉センサ（ドア、戸棚）を設置しており、4ヶ月または6ヶ月の間データ収集を行っている。対象行動は11種類の日常生活行動で、可視化ツールおよびインタビューによって行動ラベルをつけている。そして、提案手法を適用した場合に、次の行動ラベルの予測精度は、64.59%または73.68%を達成している。また、次の行動への遷移時間は正規分布で表現できるとして捉えている。しかし、行動の終了時間を予測することができていないので、前に行われていた行動の終了が確認できないと次の行動までの時間が予測できないという課題がある。つまり、実サービスに適用する場合には、連続して行われる行動では家電の先回り制御などが実現できない。

### 2.3.2 回帰木を用いた行動予測手法

Minor ら [5, 6, 7] は回帰木を用いた行動予測手法を提案している。行動予測にはCASAS データセットを用いており、25世帯の住居を対象に30種類の宅内行動が次に起こるまでの時間を学習するような回帰木のモデルを行動ごとに作成している。特徴量として、離散センサ（ドアセンサ、人感センサ、照明スイッチ）と周期センサ（温度センサ、光量センサ）によって収集されたデータをいくつかのセンサイベントごとにスライディングウィンドウ処理をして、それぞれのウィンドウで離散特徴量と周期特徴量を求めることで学習に使用している。さらに、直前の複数のイベントからの再起を考慮した学習を行っており、その最高予測精度として、平均絶対誤差 8,402.01[s] を達成している。この提案手法では、行動ごとに予測モデルを構築しており、ある時点における各行動が次に生起するまでの時間を計算できる。しかしながら、行動の平均絶対誤差が1時間以上であるために、直近の快適度向上を目指した家電の先回り制御には適用しづらい。

### 2.3.3 LSTM を用いた行動予測手法

Niek[18] は, LSTM を用いた行動予測手法を提案している. 行動予測には MIT データセット, CASAS データセットと Kasteren データセットを用いており, 行動イベントの学習モデルとセンサイイベントの学習モデルを作成し, 次に起こるイベントの種類と次のイベントが発生するまでの時間の二つを対象にしている. モデルの構築は LSTM と GRU で行っており, モデル内の LSTM 層または GRU 層を 1~3 層用意し, 次行動と生起までの時間の二つを学習するために 1~3 層の範囲で層を共有した場合と完全に独立させた場合での予測精度を比較検証している. また, LZ78, Prediction by Partial Matching (PPM), Dependency Graph (DG), All k-order Markov Chains (AKOM), Transition Directed Acyclic Graph (TDAG), Compact Prediction Tree (CPT) などの既存アルゴリズムと比較し, ほとんどの場合で LSTM が優位に行動予測できるという結果が得られている. この手法では, 次行動種類の予測精度 26.9~52.9%, 次行動生起までの時間の平均絶対誤差 1210.32~3757.70[s] を達成している. しかし, この手法では, 次の行動の種類と次行動の生起時間を別々に学習しており, ある特定の行動が一定時間後に起こる確率しか予測できないため, 実サービスに適用しづらい.

### 3. 宅内行動予測における課題と予測手法の検討

本章では、2章で明らかとなった宅内行動認識および予測の課題についてまとめたうえで、本論文で取り扱う問題について述べる。

#### 3.1 宅内行動予測における課題

2章において宅内行動認識における課題として、以下の5つの課題があることがわかった。

##### 課題1 居住者の負担の多さ

被験者が様々な機器を装着することは、実験的環境でのみ導入が可能であると考えられる。日常生活では、宅内で常に特定の機器を装着することは居住者の負担となり、実サービスを考えた場合、適していない。

##### 課題2 プライバシーの侵害

動画画像やマイクなどを用いてデータを収集した場合、システムが居住者のプライバシーデータを所持する事になる。日常生活においてシステムに監視されているという心理的負担を与えるだけでなく、収集データが漏洩した場合に居住者のプライバシーが侵害される危険性があるため、動画画像やマイクを用いた手法は好ましくない。

##### 課題3 認識までの時間の長さ

宅内行動を認識するまでに時間が長いと、生活行動に合わせた家電制御が実現できない場合があるため、できるだけ行動認識までの時間が短くなることが期待される。

##### 課題4 導入及び維持コストの高さ

宅内行動認識のために、高価なシステムを導入することは、一般家庭への普及が難しくなるため、できるだけコストを抑えたシステムが求められている。

## 課題 5 認識精度の低さ

認識精度が低いと，認識結果を利用した実サービスの適用が制限される可能性があるため，より高精度での認識が要求される．

さらに，宅内行動予測においては，実サービスとして直近の居住者の快適度向上を目指した先回り家電制御を実現しようと考えた場合，行動予測に1時間以上の平均絶対誤差があることや，次の行動の種類の予測精度は高いが次の行動の生起時間がわからないことから，既存研究は先回り家電制御には適用しづらいということがわかった．

### 3.2 行動予測手法の検討

行動認識は，認識時点までに収集したセンサデータを用いて，現在行われている行動の種類を推定することで実現できる．一方で，行動予測を行うためには，予測時点までに収集したセンサデータを用いて，次行動の種類と次行動の生起時間を予測する必要がある．そのために，行動ごとに学習モデルを構築することを考える．これにより，各行動が次にどの時間に生起するのかということだけに着目することができる．次に，次行動の生起時間の選択方法について考える．行動予測結果を利用したサービスとしては以下のようなものが考えられる．

- (1) 10 分以内の起床予測→自動でコーヒーを準備
- (2) 30 分以内の入浴予測→自動で浴槽の湯はり
- (3) 1 時間以内の睡眠予測→自動で寝室の空調の設定

既存研究では次行動生起までの時間の平均絶対誤差が大きいことなどから，このような実サービスには適用しづらいという課題点があった．そのため，今回は次行動が生起するまでの時間をいくつかの時間範囲に分類する．時間範囲に分類することで，時間範囲ごとに行動の予測精度を求めることができるため，先回り家電制御に適用させやすいと考える．

次に学習モデルについて考える．行動認識では，スライディングウィンドウを適応した特徴量抽出により，スライディングウィンドウごとに行動を推定することが

できる．一方で，行動予測においては，過去のセンサ情報が重要になると考える．例えば，キッチンのセンサが反応した後に机周辺の人感センサが反応した場合，居住者は食事をしている可能性が高くなり，次の行動としては食器洗いの可能性が高くなると考えられる．すなわち，前のセンサデータも考慮した学習を行うことが行動予測精度の向上につながる．そこで，DeepLearning アルゴリズムの一つである LSTM(Long Short Term Memory) を採用する．LSTM は RNN(Recurrent Neural Network) の一種である．通常の RNN では過去の情報を利用して学習することができるが，学習に必要な過去の情報との間が長くなるとその過去情報に関連づけた学習が困難になる．しかし，LSTM では情報の取捨選択をするためにゲートと呼ばれる機能が備わっており，選択的に過去のデータの記憶と忘却が行われる．したがって，現在の状態を学習するために有益な過去の情報との差が大きくても学習することができる．LSTM を用いることで，宅内行動予測精度の向上が期待できる．

## 4. 宅内行動生起までの時間範囲の分類予測

本章では、3章で提案した宅内行動生起までの時間範囲の分類予測について、提案手法の説明および実際に行った評価実験とその結果を示す。

### 4.1 提案手法

本論文では、行動予測手法として、センサデータにより行動生起タイミングを学習する LSTM モデルの構築を提案する。行動予測をするためには、次の行動の種類と次行動生起までの時間を予測する必要があると考える。そのため、提案手法では、行動一つ一つに着目して、対象行動の次行動生起までの時間範囲を分類するモデルを構築する。具体的には、「スマートホームのセンサデータ」を説明変数、「対象行動が次に生起するまでの時間」を目的変数とした学習モデルを行動ごとに作成する。ここで、「対象行動が次に生起するまでの時間」の選択手法を二つ提案する。提案手法1として、次に生起するまでの時間を複数の時間範囲に区切る。例えば、対象行動が今から10分以内に生起するか、10分以上30分未満に生起するか、といったように行動生起タイミングを細かく分類できる。このような行動予測を実現することで、例えば10分以上30分未満で入浴という行動が生起することを予測して、自動湯はりをお勧めするサービスに適用できる。また、提案手法2として、次に生起するまでの時間が指定時間内かどうかを推定する。例えば、対象行動が10分以内に生起するかどうかといった分類を行うことができる。この行動予測では、10分以内に睡眠が行われることを予測し、自動でリビングの暖房を消し、寝室の暖房をつけておくといったサービスに適用できる。

学習モデルの説明変数として用いるセンサデータはセンサによって測定周期が異なっている。そのため、各センサデータは10秒を1周期としたデータに変換して分析する。また、目的変数は、実験時にラベリングする行動ラベルに前処理をして作成する。まず、行動ラベルから10秒おきに対象行動を行っているかどうかというラベルに置き換える。そして、10秒おきに対象行動が次に生起するまでの時間を計算する。この計算結果に対して、定義した時間幅のどの時間に分類されるのかを判定し、その分類結果を正解ラベルとして設定する。



図 1 スマートホーム内観

## 4.2 実験概要

本節では，生活行動実験のための実験環境について述べる．本研究では，守谷ら [10]，中川ら [11] が開発したデータ収集システムを用いて，奈良先端科学技術大学院大学内のスマートホーム (1LDK) にてデータ収集実験を行う．図 1 に実験で用いたスマートホームの写真を示す．実験は奈良先端科学技術大学院大学の学生 5 人（20 代男性 4 名，20 代女性 1 名）を対象に 3 泊 4 日ずつ生活をしてもらい，計 15 泊分の宅内行動データを収集する．スマートホームには，超音波位置測位センサ，Bluetooth ワットチェッカー，クランプ式 CT (Current Transformer) センサ，ECHONET Lite 対応家電，人感センサを設置する．また，被験者は被験者自身で生活の様子を録画する．また，実験中には，行動が切り替わるタイミングで EnOcean による行動ラベル用ボタンを押すことによってタイムスタンプを記録する．

表 1 次行動生起までの時間範囲の分類予測に向けた実験での対象行動一覧

| 行動名     | 行動の定義               | 開始条件         | 終了条件         |
|---------|---------------------|--------------|--------------|
| 入浴      | 浴室で体を洗い湯船に浸かる       | 浴室に入る        | 浴室から出る       |
| 歯磨き     | 洗面所で歯磨きをする          | 歯を磨くために水を出す  | 水を止める        |
| 部屋掃除    | 部屋を掃除機で掃除する         | 掃除機の電源を入れる   | 掃除機の電源を消す    |
| 風呂掃除    | 浴室を掃除する             | 浴室に入る        | 浴室から出る       |
| 料理      | キッチンで食材を調理する        | キッチンに入る      | 料理が終わる       |
| ゲーム     | TV ゲームをする           | ゲームの電源を入れる   | ゲームの電源を消す    |
| 長期外出    | 研究室に行くなどの 30 分以上の外出 | 玄関の扉を開けて外に出る | 玄関の扉を開けて中に入る |
| 洗濯      | 衣類を洗濯する             | 衣類を洗濯機に入れる   | 衣類を干し終える     |
| 化粧      | 化粧をする               | 化粧道具を持つ      | 化粧道具を置く      |
| 食事      | 料理を食べる              | 料理を食べ始める     | 料理を食べ終わる     |
| PC 作業   | PC で作業する            | PC を開く       | PC を閉じる      |
| 読書      | 本を読む                | 本を開く         | 本を閉じる        |
| 短期外出    | トイレに行くなど 30 分未満の外出  | 玄関の扉を開けて外に出る | 玄関の扉を開けて中に入る |
| 睡眠      | 睡眠をとる               | ベッドに入る       | ベッドから出る      |
| スマートフォン | スマートフォンを使う          | スマートフォンを持つ   | スマートフォンを置く   |
| 食器洗い    | 食器を洗う               | 食器洗いを始める     | 食器洗いが終わる     |
| 洗顔      | 洗面所で顔を洗う            | 顔を洗うために水を出す  | 水を止める        |
| TV 視聴   | TV を視聴する            | TV の電源をつける   | TV の電源を消す    |
| 指定外     | 上記に分類されない行動         | —            | —            |

#### 4.2.1 対象行動

実験終了後に被験者自身で行動ラベリング支援ツールを用いて、ビデオカメラ映像と行動ラベル用ボタンによるタイムスタンプを基に行動ラベルを作成してもらう。表 1 に記録する行動の一覧を示す。実験中に行なわれた全ての行動は「指定外」を含めた 19 種類の行動に分類する。実験に使用したスマートホームでは、排水管の都合上、トイレが使用できない。そのため、トイレは同じ建物内にあるものを利用する。それに伴い、長期外出は研究室に行くなど 30 分以上の外出を、短期外出はトイレに行くなど 30 分未満の外出として区別する。

#### 4.2.2 宅内センサデータ

スマートホーム内には宅内センサを設置する。宅内センサによって、被験者の行動に合わせたセンサ情報を収集することができ、行動予測のための学習データとして利用できる。以下に、スマートホーム内に設置したセンサの詳細を述べる。

表 2 消費電力の測定対象

| 対象       | 設置場所 | Watt | CT | EL | 対象       | 設置場所                       | Watt | CT | EL |
|----------|------|------|----|----|----------|----------------------------|------|----|----|
| エアコン     | 寝室   | ○    | ○  | ○  | 扇風機      | リビング                       | ○    |    |    |
| 机コンセント   | 寝室   | ○    |    |    | 天井照明     | リビング                       |      |    | ○  |
| ベッドコンセント | 寝室   | ○    |    |    | コンセント    | リビング                       |      | ○  |    |
| 天井照明     | 寝室   |      |    | ○  | ソファコンセント | リビング                       | ○    |    |    |
| コンセント    | 寝室   |      | ○  |    | 天井照明     | 寝室, キッチン<br>リビング           |      | ○  |    |
| 冷蔵庫      | キッチン | ○    |    | ○  | コンセント    | 廊下, キッチン                   |      | ○  |    |
| IH ヒーター  | キッチン |      | ○  | ○  | 浴室乾燥機    | 浴室                         |      | ○  |    |
| 電子レンジ    | キッチン | ○    |    |    | コンセント    | 洗面所                        |      | ○  |    |
| ポット      | キッチン | ○    |    |    | 天井照明     | 玄関, 廊下,<br>浴室, トイレ,<br>洗面所 |      | ○  |    |
| 炊飯器      | キッチン | ○    |    |    |          |                            |      |    |    |
| コンセント    | キッチン |      | ○  |    | 給湯器      | 外                          |      | ○  |    |
| TV       | リビング | ○    |    | ○  |          |                            |      |    |    |
| エアコン     | リビング |      | ○  | ○  |          |                            |      |    |    |

### 超音波位置測位センサ

超音波位置測位センサは、小型の送信機から一定間隔で送信される超音波をスマートホーム内の天井に複数台設置されている受信機で受信することによって、人の位置を測位できるセンサである。人の位置情報は3次元座標 (x, y, z) で取得できる。被験者が実験時に超音波送信機を装備することにより、宅内の位置情報を計測する。この位置情報は2秒間に1回の周期で計測できる。

### Bluetooth ワットチェッカー

Bluetooth ワットチェッカーはコンセントから家電に配電する間に設置することで消費電力を測定できるセンサである。この電力値は1秒間に1回の周期で計測できる。電力値を計測する対象は10箇所である。表2の「Watt」に電力値を取得する対象の一覧を示す。

### クランプ式 CT(Current Transformer) センサ

クランプ式 CT センサは各系統の電力値を測定できるセンサである。これを分電盤の系統ごとに設置する。この電流値は1秒間に1回の周期で計測できる。電流値を計測する系統は計12種類である。表2の「CT」に電流値を取得する電気系統の一覧を示す。




図 2 ECHONET Lite 対応家電の設置図

## ECHONET Lite 対応家電

ECHONET Lite は通信規格であり，対応している家電製品の電源状態などが取得できる．本研究では，エアコン，天井照明，IH，TV，空気清浄機の電源のオン・オフ情報と冷蔵庫のドア開閉情報を計測する．計測は各家電の電源のオン・オフまたはドアの開閉が行われたタイミングで取得する．図 2 に ECHONET Lite 対応家電を青色で示す．また，ECHONET Lite 非対応家電を赤色で示す．ECHONET Lite 非対応家電は将来的に ECHONET Lite 対応になり，家電情報が取得できるようになることを想定して，消費電力値がある一定値を超えていた場合はオン，一定値以下の場合はオフとして，家電情報に変換する．表 2 の「EL」に ECHONET Lite 対応家電の一覧を示す．

## 人感センサ

人感センサは人がセンサ前で動いたことを赤外線により検知できるセンサである．センサからのデータの取得は EnOcean という通信規格で行う．こ




図 3 人感センサの設置図

の人感センサをスマートホーム内に7箇所設置する．また，テレビの前のソファに人がいることを検知するために，仮想人感センサとして超音波位置測位センサのデータを人感センサの反応に変換して使用する．図3に人感センサの設置箇所を示す．データの計測は，人感センサが反応したタイミングで行う．

#### 4.2.3 被験者への指示

学習データを収集する際に，実験中の生活について，以下のような指示を行う．また，指示していない内容に関しては，自由に生活してもらう．

- 表1に示す指定外以外の18種類の行動を出来るだけ1日1回以上行うこと．
- 睡眠以外の行動を1日3時間以上行うこと．
- 睡眠を含む宅内での行動を1日10時間以上行うこと．
- 行動の切り替わりで，タイムスタンプ用のボタンを押すこと．

## 4.3 データ分析

### 4.3.1 評価方法

分析では実験時に収集したデータの中から正常にデータが取得できた8日分のデータを使用する。データ分析手法として、提案手法1,2を用いて分析を行う。これら全ての手法において、学習はDeepLearning アルゴリズムである LSTM を利用して学習モデルを構築し分析を行う。学習は1日をテストデータ、それ以外の日をトレーニングデータとした学習を全ての分析対象日に適応する Leave-One-Day-Out 交差検証で行う。

### 4.3.2 行動予測モデル

LSTM の学習モデルは入力層, Dropout 層, LSTM 層, Dense 層, 出力層から成るモデルを構築する。モデルの学習には Keras[19] を用いる。入力データは, 3次元(データ数, 特徴量数, 追憶データ数)で, 10秒おきのデータの特徴量を追憶データ数分重ねたデータに整形する。今回は, 経験的に, 追憶データ数を 100, エポック数を 10, 入力バッチサイズを 512 で学習を行う。出力データは 2次元(データ数, 分類クラス数)で, 分類クラスの確率の中で最も確率が高かったものを推定ラベルとみなす。また, 各層のパラメータとして, 経験的に, Dropout 層の Dropout 率は 0.2, LSTM 層の隠れユニット数は 512, Dense 層の Activation 関数は Softmax を使用する。これらのパラメータは, いくつかのパラメータで検証を行なった上で, 最も精度が高かったパラメータを使用している。

### 4.3.3 特徴量抽出

学習モデルの説明変数として, 10秒おきにセンサデータを集約する。特徴量はそれぞれ, 超音波位置測位センサによる位置情報の中央値(3種類), Bluetooth ワットチェッカーによる消費電力値の中央値(10種類), クランプ式 CT センサによる消費電流値の中央値(12種類), ECHONET Lite 対応家電の情報の最頻値(8種類), ECHONET Lite 非対応家電の情報の最頻値(3種類), 人感セン

サが1回でも反応したかどうか（7種類）、仮想人感センサが1回でも反応したかどうか（1種類）の合計44種類を使用する。

#### 4.3.4 次行動生起期間の予測

一つ目の行動予測手法として、次の行動が現在からどれくらいの時間が経ってから生起するかを予測するモデルを作成する。具体的には、スマートホーム内のセンサデータを説明変数、ある行動が生起するタイミングを目的変数とした学習モデルを作成する。行動が生起するタイミングは、時間範囲で指定する。分類は、行動中、10分以内、10～30分、30～60分、1～2時間、2～3時間、3時間以上（もしくは生起しない）のように7クラスに分類する。この分類モデルをラベリングされた行動の種類ごとに作成することによって、各行動が発生する期間を予測することができると思う。

表3および図4に次行動生起期間の予測の再現率を示す。表3において、列は行動の種類を示し、行は次に行動が生起するまでの期間を示しており、Nowは既に対象行動を行なっている最中であること（行動認識と同等）を示し、～10min、10min～30min、30～60min、1hour～2hour、2hour～3hourは対象行動が生起するまでの期間を示す。「10分以内に生起する」場合に注目すると、食事が45.5%の精度で予測できていることがわかる。これは、食事をする前には料理をすることが多いため、キッチンにいたというセンサ情報から、食事の予測ができることを示している。また、料理をしてから食事をするという行動順序は誰もが行うため、今回の結果の中で最も予測精度が高くなったと考えられる。同様の理由で、皿洗いは料理の後に行われやすいことから、18.1%の再現率を示しており、他の行動に比べると再現率が高くなっている。洗顔や化粧についても、朝起きてから洗顔して、化粧をするという決まった流れがあるため、他の行動より再現率が高くなっていると思われる。しかし、それ以外の行動についてはほとんど10%未満の予測精度である。次に、「30分～1時間に生起する」場合に注目すると、風呂掃除やゲーム、睡眠が他の行動に対して再現率が高くなっている。風呂掃除やゲームは毎日必ず行う行動ではないにも関わらず、再現率が高くなっている点が非常に興味深い。

全体的な傾向としては、予測精度はあまり高くない。この理由として、分類する生起時間範囲のクラス数が多すぎるために、正しく学習できていない可能性があると考えられる。そのため、提案手法2により時間内次行動生起について考察を行う。

表 3 次行動生起期間の予測の再現率

|          | 入浴    | 歯磨き   | 掃除    | 風呂掃除  | 料理    | ゲーム     | 長期外出  | 洗濯    | 化粧    |
|----------|-------|-------|-------|-------|-------|---------|-------|-------|-------|
| Now      | 0.750 | 0.149 | 0.000 | 0.000 | 0.735 | 0.522   | 0.921 | 0.004 | 0.207 |
| ～10min   | 0.004 | 0.037 | 0.010 | 0.093 | 0.078 | 0.000   | 0.051 | 0.101 | 0.186 |
| 10～30min | 0.033 | 0.200 | 0.061 | 0.125 | 0.064 | 0.214   | 0.242 | 0.189 | 0.000 |
| 30～60min | 0.110 | 0.072 | 0.191 | 0.248 | 0.169 | 0.369   | 0.200 | 0.194 | 0.122 |
| 1～2hour  | 0.147 | 0.209 | 0.075 | 0.235 | 0.118 | 0.219   | 0.060 | 0.247 | 0.048 |
| 2～3hour  | 0.103 | 0.163 | 0.094 | 0.000 | 0.104 | 0.071   | 0.012 | 0.029 | 0.000 |
|          | 食事    | PC 作業 | 読書    | 短期外出  | 睡眠    | スマートフォン | 皿洗い   | 洗顔    | TV 視聴 |
| Now      | 0.594 | 0.682 | 0.406 | 0.094 | 0.931 | 0.551   | 0.210 | 0.208 | 0.242 |
| ～10min   | 0.455 | 0.000 | 0.048 | 0.019 | 0.047 | 0.035   | 0.181 | 0.228 | 0.074 |
| 10～30min | 0.154 | 0.000 | 0.032 | 0.176 | 0.079 | 0.201   | 0.207 | 0.057 | 0.110 |
| 30～60min | 0.141 | 0.052 | 0.021 | 0.095 | 0.214 | 0.144   | 0.191 | 0.000 | 0.124 |
| 1～2hour  | 0.268 | 0.077 | 0.072 | 0.148 | 0.241 | 0.039   | 0.178 | 0.113 | 0.206 |
| 2～3hour  | 0.067 | 0.126 | 0.056 | 0.113 | 0.115 | 0.034   | 0.088 | 0.143 | 0.104 |




図 4 次行動生起期間の予測の再現率

#### 4.3.5 時間内次行動生起の予測

単純な行動生起期間の予測では、行動の生起タイミングの予測が難しいことがわかった。しかし、行動の生起期間を予測せずとも、指定時間内に生起する行動を予測できれば実サービスに適用できると考える。つまり、30分～1時間経過している時に行動が生起することを予測するより、1時間以内に行動が生起することを予測する。このようにモデルの構築の手法を変更することで、予測精度が向上が期待できる。そのため、2つ目の提案手法として、時間内に行動が生起するかどうかを予測するモデルを構築する。この手法は、先ほどの行動生起期間の予測の分類クラス数を少なくし、行動中、指定時間内に生起、指定時間以上経ってから生起の3つに分類する。指定時間としては、10分、30分、1時間で分析を行う。

表4、図5に時間内行動生起の再現率を示す。表4において列は行動を示し、行は対象行動が生起するまでの時間幅を示す。また、太字で示しているものは、時間幅で行動生起タイミング分類した場合より予測精度が高いものを示す。全体の傾向は、時間範囲分類の傾向と似ている。

「10分以内に生起する」場合では、時間範囲での分類に比べ、対象行動18種類のうち12種類の行動の予測精度が高くなっている。例えば、食事は47.4%の再現率を示している。しかし、この分類におけるチャンスレベルは33%であり、チャンスレベル以上の再現率を示しているものは、対象行動18種類中1種類である。同様に、「30分以内に生起する」場合では3種類、「1時間以内に生起する」場合では4種類の行動がチャンスレベル以上の再現率を示している。

全体的に予測精度としては低い値を示しており、実サービスに適用するためにはさらなる予測精度の向上が求められる。これは、実験環境での生活においてセンサデータに規則性が生まれにくいことを示している。被験者には定義した行動を全て行ってもらうように指示していたが、行動予測ではその要因から実生活の行動順序とは異なったデータとなり、予測が難しくなった可能性がある。さらに、行動予測精度を向上させるためには、より多くのデータを集め、分析を行う必要があり、簡単にデータ収集が行える環境が必要となる。

表 4 時間内行動生起の再現率

|        | 入浴           | 歯磨き          | 掃除           | 風呂掃除         | 料理           | ゲーム          | 長期外出         | 洗濯           | 化粧           |
|--------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
| ~10min | 0.002        | <b>0.103</b> | 0.000        | <b>0.129</b> | <b>0.155</b> | 0.000        | <b>0.190</b> | <b>0.138</b> | 0.040        |
| ~30min | 0.031        | <b>0.238</b> | <b>0.256</b> | <b>0.222</b> | <b>0.157</b> | 0.204        | 0.144        | <b>0.284</b> | <b>0.270</b> |
| ~1hour | 0.052        | <b>0.266</b> | <b>0.327</b> | <b>0.271</b> | <b>0.260</b> | 0.259        | <b>0.325</b> | <b>0.238</b> | 0.113        |
|        | 食事           | PC作業         | 読書           | 短期外出         | 睡眠           | スマートフォン      | 皿洗い          | 洗顔           | TV視聴         |
| ~10min | <b>0.474</b> | <b>0.004</b> | <b>0.150</b> | 0.015        | <b>0.078</b> | <b>0.064</b> | <b>0.301</b> | 0.133        | <b>0.118</b> |
| ~30min | <b>0.538</b> | <b>0.001</b> | <b>0.082</b> | 0.092        | 0.032        | <b>0.268</b> | <b>0.370</b> | <b>0.399</b> | <b>0.164</b> |
| ~1hour | <b>0.564</b> | <b>0.053</b> | <b>0.226</b> | <b>0.270</b> | <b>0.307</b> | <b>0.399</b> | <b>0.370</b> | <b>0.450</b> | <b>0.246</b> |




図 5 時間内行動生起の再現率

## 5. 回帰による宅内行動生起までの時間予測

本章では，4章で述べた宅内行動生起までの時間範囲分類の予測精度がどの程度まで向上する可能性があるのかを，回帰による宅内行動生起までの時間予測によって評価する．評価を行うために，新たにデータ収集実験を行ったので，その実験の詳細を示したのちに，分析結果を述べる．

### 5.1 次行動生起までの時間の回帰

提案手法2の宅内行動生起までの時間範囲分類では，予測時間の平均絶対誤差が33%を超えている行動が対象行動内の一部の行動に限られており，実サービス適用に向けてはさらなる予測精度の向上が必要であると考えた．そのため，既存研究と比べ，どの程度まで予測精度が向上する可能性があるのかを示すために，回帰による次行動生起までの時間予測を行う．回帰モデルを構築して予測することによって，既存研究 [7] で提案されている回帰モデルの結果と予測精度として平均絶対誤差の比較を行うことができる．回帰モデルの構築は，提案手法1, 2と同様に「スマートホームデータ」を説明変数, 「対象行動が次に生起するまでの時間」を目的変数とした LSTM の回帰モデルを構築する．

### 5.2 実験概要

回帰による行動予測手法を評価するために，2018年8月に奈良先端科学技術大学院大学のスマートホーム設備を用いて，奈良先端科学技術大学院大学の学生5名（男性3名，女性2名）を対象に一人当たり3泊4日生活する日常生活行動実験を行なった．この実験では，2018年度時点のスマートホームのデータ収集システムを用いる．次節より，3章で行なった実験と異なっている部分について説明する．

表 5 次行動生起までの時間の回帰予測に向けた実験での対象行動一覧

| 行動名     | 行動の定義            | 開始条件       | 終了条件       |
|---------|------------------|------------|------------|
| 在宅      | 在宅中              | 玄関から中に入る   | 玄関から外に出る   |
| 個人衛生    | 手洗いや歯磨きなど衛生面の行動  | 洗面所に入る     | 洗面所から出る    |
| 料理      | キッチンで食材を調理する     | キッチンに入る    | 料理が終わる     |
| 食事      | 料理を食べる           | 料理を食べ始める   | 料理を食べ終わる   |
| 食器洗い    | 食器を洗う            | 食器洗いを始める   | 食器洗いが終わる   |
| トイレ     | トイレに行く           | 玄関から外に出る   | 玄関から中に入る   |
| 入浴      | 浴室で体を洗い湯船に浸かる    | 浴室に入る      | 浴室から出る     |
| 部屋掃除    | 部屋を掃除機で掃除する      | 掃除機の電源を入れる | 掃除機の電源を消す  |
| 風呂掃除    | 浴室を掃除する          | 浴室に入る      | 浴室から出る     |
| 洗濯      | 衣類を洗濯する          | 衣類を洗濯機に入れる | 衣類を干し終える   |
| PC 作業   | PC で作業する         | PC を開く     | PC を閉じる    |
| TV 視聴   | TV を視聴する         | TV の電源をつける | TV の電源を消す  |
| ゲーム     | TV ゲームをする        | ゲームの電源を入れる | ゲームの電源を消す  |
| 読書      | 本を読む             | 本を開く       | 本を閉じる      |
| スマートフォン | スマートフォンを使う       | スマートフォンを持つ | スマートフォンを置く |
| 睡眠      | 睡眠をとる            | ベッドに入る     | ベッドから出る    |
| 身支度     | 化粧や着替えなど外出のための準備 | 準備を始める     | 準備が整う      |

### 5.2.1 対象行動

新たに実験を行うにあたり、実験時にラベリングの対象とする行動を再定義した。表 5 に対象とする 17 種類の行動一覧を示す。提案手法 1, 2 と異なる行動は、在宅、個人衛生、トイレ、身支度である。在宅は、帰宅したことを示す。個人衛生は、手洗いや髭剃りなど洗面所で行う衛生面の行動を示す。トイレは、スマートホーム内のトイレは排水管の都合により使用できないため、同じ建物内のトイレを利用することになるが、外出とトイレの区別をつけるために追加する。身支度は、化粧だけでなく着替えなど外出のための準備を示す。行動の記録は、開発した宅内ラベリング専用のモバイル端末用アプリケーションを用いて行う。図 6 に開発したアプリケーションの画面を示す。全ての行動は行動中か否かで状態の切り替えを行う。アプリケーション上では、行動のアイコンが行動中かどうかを示しており、青色は行動中、黒色は行動中ではないことを示す。このラベリング手法では、複数の行動が同時に行われる状況（料理と TV 視聴等）のラベルづけを行うことができる。行動の記録はリアルタイムに行なってもらうが、ラベルのつけ忘れ防止のために、被験者自身に生活の様子を録画してもらう。




図 6 開発した行動ラベリング用アプリケーションの画面

### 5.2.2 宅内センサデータ

宅内で収集するセンサデータとして、スマートホームには超音波位置測位センサ、EnOcean センサ（人感センサ、ドアセンサ）、ECHONET Lite 対応宅内機器を設置する。今回新たにドアセンサおよび ECHONET Lite 対応機器（浴室乾燥機、分電盤）を設置する。まず、人感センサ、ドアセンサの設置位置を図 7 に示す。図 7 において、人感センサは、壁または家電に水平に取り付けたものを青色の三角で、天井に取り付けたものを赤色の丸で示している。また、オレンジ色で、ドアセンサの設置位置を示す。さらに、表 6 に ECHONET Lite 対応の分電盤により消費電力を収集した電気系統の一覧を示す。「家電名+コンセント」は対象家電専用のコンセントとして用意しているものであり、「部屋名+コンセント」は被験者が自由に使えるコンセントである。ECHONET Lite によるデータ収集は、全ての家電に対して 1 秒おきに家電状態を収集する電文を送信することで行う。このように集められるデータは、オープンデータセットの CASAS データセットに比べ、超音波位置センサや家電の情報（消費電力を含む）が収集されるという点




図 7 宅内に設置した人感センサおよびドアセンサの設置図

表 6 分電盤の計測対象電気系統一覧

|                |              |               |               |
|----------------|--------------|---------------|---------------|
| IH (200V)      | 浴室乾燥機 (200V) | 浴室乾燥機         | 換気扇           |
| 照明 (靴箱・物置)     | 照明 (廊下・トイレ)  | 照明 (リビング)     | 照明 (玄関)       |
| 照明 (キッチン)      | 照明 (洗面所)     | 照明 (浴室)       | 洗濯機コンセント      |
| ドライヤーコンセント     | 冷蔵庫コンセント     | ポットコンセント      | 炊飯器コンセント      |
| 電子レンジコンセント     | 食器洗い乾燥機      | リビングエアコンコンセント | リビング PC コンセント |
| リビング掃除機コンセント   | テレビコンセント     | ゲームコンセント      | 扇風機コンセント      |
| 寝室エアコンコンセント    | 寝室 PC コンセント  | 寝室掃除機コンセント    | 寝室コンセント       |
| 玄関・廊下・洗面所コンセント | キッチンコンセント    | リビングコンセント     |               |

でより多くの情報を用いた分析ができると考える。

### 5.2.3 被験者への指示

実験を行うにあたり，前回の実験とは異なった指示を出す．以下に，実験時に被験者に出した指示を示す．行動予測には，普段通りの生活を指示することで，実験的環境での行動予測ではなく，実サービスに適用できるようになる行動予測を目指す．

- 実験ということをあまり意識せず，普段通りの生活を心がける．

- 行動を行なった時に，ラベリングアプリにより行動を記録する．

## 5.3 データ分析

### 5.3.1 評価方法

分析では収集できた 15 泊分のデータを用い，個人の行動を予測する学習モデルを構築する．行動毎に次行動生起までの時間を正解値とした学習モデルを LSTM で構築する．学習は個人別で行い，前から 8 割をトレーニングデータ，1 割を検証用データ，1 割をテストデータとして学習を行う．

### 5.3.2 行動予測モデル

回帰モデルにおいても分類時と同様に，LSTM の学習モデルは入力層，DropOut 層，LSTM 層，Dense 層，出力層から成るモデルを構築する．入力データは，3 次元（データ数，特徴量数，追憶データ数）で，10 秒おきのデータの特徴量を追憶データ数分重ねたデータに整形する．正解ラベルは 0~1 の範囲で正規化しており，出力データに逆変換を行うこと予測値を求める．今回は，経験的に，追憶データ数を 100，エポック数を 10，入力バッチサイズを 512 で学習を行う．出力データは 1 次元（次行動生起までの時間）である．また，各層のパラメータとして，経験的に，DropOut 層の DropOut 率は 0.2，LSTM 層の隠れユニット数は 512 である．

### 5.3.3 特徴量抽出

収集した宅内センサデータから 10 秒おきに特徴量抽出を行う．特徴量として，超音波位置測位センサによる位置情報の平均値（3 種類），人感センサ (23 種類) の反応回数と最頻値，ドアセンサ (8 種類) の反応回数と最頻値，ECHONET Lite 対応家電状態の最頻値（10 種類），分電盤による電気系統毎の消費電力の平均値（使用されていない系統も含む計 40 系統），1 日の始まりから数えた秒数を用い

る．特徴量は 0~1 の範囲で正規化したのちに PCA で元データの 95% をカバーできるデータに次元削減する．

#### 5.3.4 実験結果

次行動生起までの時間を予測として，次行動生起までの時間（秒）を学習する LSTM モデルを構築した．図 8 に行動別の次行動生起までの時間の回帰モデルにおける予測結果を示す．図 8 において，縦軸は 17 種類の日常生活行動を示しており，横軸は行動毎の予測結果として平均絶対誤差を示している．被験者によっては対象行動を一度も行なっていない場合もあることがわかる．図 8 では，同じ行動でも被験者によって行動予測精度が大きく異なる場合があることがわかる．特に，被験者 3 は他の被験者に比べて平均絶対誤差が高い行動が多い．これは，行動予測のしやすさに個人差があることを示唆している．また，4 章の提案手法 2 の結果である図 5 と比較すると，時間内行動生起の予測では食事が最も精度が高かったが，今回の実験結果では，スマートフォンや身支度などが食事の予測精度を上回っている被験者がいることがわかる．この結果は，被験者によって予測しやすい行動が異なることを示唆している．

図 9（[7] から抜粋）に Minor ら [7] が提案している宅内行動予測手法における行動別次行動生起までの時間の予測結果を示す．図 8 と図 9 を比較すると，入浴においては今回収集したデータでの予測精度が優れている．また，全ての被験者における全ての行動の平均絶対誤差の平均は 15720.63[s] となった．これは，既存研究 [7] の平均絶対誤差 8,402[s] と比べ，さらなる改善の余地があることを示す．




図 8 行動別次行動生起までの時間の回帰予測による平均絶対誤差




図 9 Minor らが提案している行動別次行動生起までの時間の予測結果

## 6. 結論

既存の宅内行動予測では，次行動生起までの時間を平均絶対誤差で評価する手法が提案されており，家電の先回り制御のような居住者の欲求を満たすサービスに予測結果を適用しづらいという課題点があった．そのため，本論文では実サービスに適用できる行動予測手法として，次行動生起までの時間範囲予測手法を提案した．提案手法1として，次行動生起までの指定時間範囲を予測する手法を提案した．この手法では，次行動生起までの時間範囲を10分以内，10～30分，30～60分，1～2時間，2～3時間，3時間以上に分け，分類問題として宅内行動予測を行うことで，実サービスに近づけた行動予測が実現できる．この提案手法を評価するために，2017年8月に奈良先端科学技術大学院大学内のスマートホームで5人の被験者にそれぞれ3泊4日ずつデータ収集実験を行なった．スマートホームでは，宅内センサからの情報収集と，被験者自身で撮影された動画より行動のラベルづけを行なった．収集実験によって収集されたデータを対象に，次行動生起までの時間範囲を目的変数として，宅内センサの情報を説明変数として学習モデルをLSTMで構築した．この分類精度として，行動別にみると平均は0%～20%程度の予測精度になった．この結果の要因として，分類するクラス数が多いことが考えられた．そのため，次行動が行動中もしくは指定時間内に生起するか否かの3クラスに分類するように正解ラベルを区別して学習するモデルを構築した．その結果，18種類の対象行動のうち，平均予測再現率が33%以上を達成できたものが30分以内では3種類（37.0%～53.8%），1時間以内では4種類（37.0%～56.4%）であった．

さらに，この予測精度がどの程度まで向上するのかを表すために，回帰による行動予測を行なった．この分析によって，既存研究との予測精度が比較可能であり，提案手法1，2の予測精度向上の可能性を示唆できる．この評価のために，2018年8月に奈良先端科学技術大学院大学内のスマートホームで5人の被験者にそれぞれ3泊4日ずつ生活をしてもらった．スマートホームでは，宅内センサからのデータと被験者自身でラベリング用モバイルアプリケーションにより行動のラベルづけを行なってもらった．このデータ収集実験で収集されたデータを対象に，行動ごとに次行動の生起時間を目的変数として，宅内センサ情報を説明変数

として LSTM により学習を行ったところ、全被験者、全行動の平均絶対誤差が 15720.63[s] であった。

これらの分析結果から、以下のような知見が得られた。

- 時間内行動生起において、料理の後の食事や皿洗い、起床後の洗顔や化粧など行動の流れが予測できる行動は学習モデルにおいても他の行動に比べ、予測精度が高い。
- 時間内行動生起の分類による予測と次行動の生起時間の回帰による予測では、精度がよい行動が異なる。これは、行動によって当てやすい時間幅が違うことを示唆している。
- 実験環境において、被験者に収集の対象とする行動全てを行なってもらうことは、行動認識の場合は有利に働くが、行動予測では普段の生活と異なる生活パターンになり、予測精度の低下につながる。

また、このような知見より、本研究の今後の発展の可能性としては、以下のようなことが考えられる。

- 既存研究 [5, 6, 7] で提案されている行動予測手法より低い精度である。そのため、行動予測手法で使用されているデータセット、特徴量抽出などを再現して、提案手法を適用することで、予測精度の向上が期待できる。
- 可視化したセンサデータを用いて、人間の目視で行動の予測がどれだけできるのかを検証することで、より本手法の有効性が示される。
- 提案手法において LSTM のみで評価を行なっているが、他の機械学習アルゴリズムを用いて評価を行うことで、本提案の有用性を示すことができると考える。そのため、LOOKBACK として定義していた部分を変形し、2次元データとして取り扱うことで、決定木やナイーブベイズ等の一般的な機械学習モデルを構築して比較検討する必要がある。
- 本研究での提案手法では、一人暮らしの家庭を対象に行動予測手法を適用している。今後、複数の人が同じ宅内に居住していた場合の予測ができるようになることが望まれる。

- 次行動生起までの時間範囲を予測できるようになれば、実際に目覚めのコーヒーを準備，自動湯はり，就寝前の自動空調調整などの先回り家電制御が可能となるため，実際に先回り家電制御をした場合の居住者の快適度や利便性を評価できる．

これらの発展によって，高齢者見守り，省エネ制御，家電の先回り制御など，より実サービスに適用できる宅内行動予測が実現できると考えられる．

## 謝辞

本研究を進めるにあたり、安本慶一教授には終始熱心なご指導をいただきました。研究についての議論を通じて、多くのご教授を受け、非常に有意義な研究活動を過ごすことができました。心より感謝いたします。

中村哲教授には、論文審査委員を引き受けていただき、貴重なご意見を賜りました。厚く御礼を申し上げ、感謝の意を表します。

荒川豊准教授には、発表論文の添削や発表練習の際に多くの助言をいただきました。厚く御礼を申し上げ、感謝する次第です。

諏訪博彦助教には、研究を進めるにあたり、的確な助言を賜りましたことを、心より感謝いたします。

藤本まなと助教には、論文原稿の作成など多くのご支援をいただきました。深く感謝いたします。

水本旭洋元特任助教には、研究を進めていく上での数多くの相談に乗っていただき、感謝の念に堪えません。

金岡恵事務補佐員，山内奈緒事務補佐員，小川恵理事務補佐員，南あずさ事務補佐員には学会の手続き等，研究室生活において多数のご支援いただきました。心よりお礼を申し上げます。

日頃から気さくに話しかけてもらい、多くのアドバイスを頂きました先輩方，共に切磋琢磨し勉学に勤しんだ同輩，慕ってくれた後輩の皆様に厚く感謝を申し上げます。

最後に、研究や実験に協力していただき、学業生活、私生活において大変お世話になったユビキタスコンピューティングシステム研究室の皆様に感謝の意を表します。

## 参考文献

- [1] Parisa Rashidi and Alex Mihailidis. A survey on ambient-assisted living tools for older adults. *IEEE journal of biomedical and health informatics*, Vol. 17, No. 3, pp. 579–590, 2013.
- [2] Qin Ni, Ana Belén García Hernando, and Iván Pau de la Cruz. The elderly’s independent living in smart homes: A characterization of activities and sensing infrastructure survey to facilitate services development. *Sensors*, Vol. 15, No. 5, pp. 11312–11362, 2015.
- [3] James Scott, AJ Bernheim Brush, John Krumm, Brian Meyers, Michael Hazas, Stephen Hodges, and Nicolas Villar. Preheat: controlling home heating using occupancy prediction. In *Proceedings of the 13th international conference on Ubiquitous computing*, pp. 281–290. ACM, 2011.
- [4] Pietro Cottone, Salvatore Gaglio, Giuseppe Lo Re, and Marco Ortolani. User activity recognition for energy saving in smart homes. *Pervasive and Mobile Computing*, Vol. 16, pp. 156–170, 2015.
- [5] Bryan Minor, Janardhan Rao Doppa, and Diane J Cook. Data-driven activity prediction: Algorithms, evaluation methodology, and applications. In *Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 805–814. ACM, 2015.
- [6] Bryan Minor and Diane J Cook. Forecasting occurrences of activities. *Pervasive and mobile computing*, Vol. 38, pp. 77–91, 2017.
- [7] Bryan David Minor, Janardhan Rao Doppa, and Diane J Cook. Learning activity predictors from sensor data: Algorithms, evaluation, and applications. *IEEE transactions on knowledge and data engineering*, Vol. 29, No. 12, pp. 2744–2757, 2017.

- [8] Diane J. Cook, Aaron S. Crandall, Brian L. Thomas, and Narayanan C. Krishnan. CASAS: A smart home in a box. *IEEE Computer*, Vol. 46, No. 7, pp. 62–69, 2013.
- [9] Tim LM van Kasteren, Gwenn Englebienne, and Ben JA Kröse. Human activity recognition from wireless sensor network data: Benchmark and software. In *Activity recognition in pervasive intelligent environments*, pp. 165–186. Springer, 2011.
- [10] 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 *Pervasive Computing and Communications Workshops (PerCom Workshops), 2017 IEEE International Conference on*, pp. 437–442. IEEE, 2017.
- [11] 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 *Pervasive Computing and Communications Workshops (PerCom Workshops), 2017 IEEE International Conference on*, pp. 539–544. IEEE, 2017.
- [12] Macarena Espinilla, Javier Medina, Alberto Salguero, Naomi Irvine, Mark Donnelly, Ian Cleland, and Chris Nugent. Human activity recognition from the acceleration data of a wearable device. which features are more relevant by activities? In *Multidisciplinary Digital Publishing Institute Proceedings*, Vol. 2, p. 1242, 2018.
- [13] Oliver Amft and Gerhard Troster. On-body sensing solutions for automatic dietary monitoring. *IEEE pervasive computing*, Vol. 8, No. 2, 2009.
- [14] Hamed Pirsiavash and Deva Ramanan. Detecting activities of daily living in first-person camera views. In *Computer Vision and Pattern Recognition (CVPR), 2012 IEEE Conference on*, pp. 2847–2854. IEEE, 2012.

- [15] 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.
- [16] 上田健揮, 玉井森彦, 荒川豊, 諏訪博彦, 安本慶一ほか. 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.
- [17] Ehsan Nazerfard and Diane J Cook. Using bayesian networks for daily activity prediction. In *AAAI workshop: plan, activity, and intent recognition*, 2013.
- [18] Niek Tax. Human activity prediction in smart home environments with lstm neural networks. In *2018 14th International Conference on Intelligent Environments (IE)*, pp. 40–47. IEEE, 2018.
- [19] François Chollet, et al. Keras. <https://keras.io>, 2015.