

スマートホームデータの時系列分析に基づく 宅内行動生起タイミングの予測

佐々木 渉¹ 藤原 聖司¹ 藤本 まなと¹ 諏訪 博彦¹ 荒川 豊^{1,2} 安本 慶一¹

概要: 近年, 宅内での人の位置検知や行動認識を利用した, エアコンの自動風向調整や高齢者の見守り, 省エネなどのサービスなどが登場してきた. 我々は, さらに便利な宅内サービスを実現するためには行動予測が重要だと考える. 行動認識とは異なり, 行動予測をするためには, 瞬時値のみを考慮する機械学習ではうまく学習できないという問題点がある. そのため, 本稿では, 時系列を考慮して学習できるようにするため, DeepLearning アルゴリズムの一つである LSTM(Long Short Term Memory) を用いた分析手法により行動予測を行った. 学習モデルの目的変数として, 行動生起タイミングを設定するが, その選択方法として次の 2 つの方法で分析を行う. 1 つ目の手法として, 行動が発生するまでの経過時間帯を幾つか設定し, 行動生起タイミングの時間帯を目的変数とした分類を行った. その結果, 食事などの一部の行動では行動生起タイミング分類の再現率が確認できた. しかし, 分類する時間帯の数が多いため, それ以外の行動では行動生起タイミング分類の再現率が低く留まった. そのため, 2 つ目の手法として, 時間内行動生起タイミングを目的変数とした予測を行った. この手法では, 行動生起タイミングの分類を単純化することで, より正しく学習できると考えた. 結果としては, 1 つ目の手法と比べて, ほぼ全ての行動で再現率の向上が確認できた.

Daily Living Activity Occurrence Timing Prediction through Time Series Analysis of Smart Home Data

WATARU SASAKI¹ MASASHI FUJIWARA¹ MANATO FUJIMOTO¹ HIROHIKO SUWA¹
YUTAKA ARAKAWA^{1,2} KEIICHI YASUMOTO¹

1. はじめに

近年, 宅内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, お年寄りの見守りや省エネを目的とした, 宅内行動認識も多く行われている.

さらに我々は, より便利な宅内サービスを実現するため, 宅内行動予測が重要と考える. なぜなら, 人の行動の背後には必ず欲求があり, そ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ためである. 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が考えられる. このようなサービスを実現するため, 我々は行動予測手法について検討してきた.

行動予測の先行研究として, Wu らはベイジアンネットワークを用いた行動予測手法を提案している [1]. 彼らはベイジアンネットワークを行動, 時間, 日の 3 つを元にそれぞれ作成し, それらを組み合わせることで 16 種類の生活行動の予測をしている. しかし, ベイジアンネットワークでは, 次に行われる行動の種類のみに着目しており, 行動の生起タイミングの予測については考慮していない.

そこで, 我々はセンサーデータの時系列に注目した分析を行うことで, 行動の生起タイミングも含めた行動予測ができるのではないかと考えた. 行動予測ができるためには, 行動認識ができることが前提にあると考え, まずは時系列データ分析を用いた行動認識を行なった. その

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が考えられる. このようなサービスを実現するため, 我々は行動予測手法について検討してきた.

¹ 奈良先端科学技術大学院大学
Nara Institute of Science and Technology
² JST さきがけ
JST PRESTO

結果, ECHONET Lite 対応家電情報と人感センサの情報を DeepLearning アルゴリズムの一つである Long Short Term Memory(LSTM) を用いて学習することにより, 一部の行動では認識精度が向上することがわかった [2]. 時系列分析による行動認識が実現できたため, 次に LSTM を用いた行動予測学習モデルを考える.

本研究では, LSTM を用いた宅内行動生起のタイミングを予測する手法を提案する. 提案手法では, 次の行動がどのタイミングで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. 学習モデルは, ラベリングする行動の種類の数だけ作成し, それらを集約することで, 各行動の生起タイミングを予測できると考える. 学習モデルの作成には LSTM を用いる. LSTM では, 行動の移り変わりに, あるセンサが反応してから特定の行動に遷移する場合, そのセンサデータを追憶して学習できる. これにより, 瞬時値として捉えていたセンサデータ (人感センサ, 家電消費電力など) を行動予測に組み込んだ学習が可能となる.

本提案手法で使用するセンサデータは過去の実験 [2] で収集したものを利用する. このセンサデータは奈良先端科学技術大学院内のスマートホーム設備を用いて 5 人の被験者が 3 泊 4 日で生活したデータである. この収集データに対して提案手法に基づく分析を適用することで宅内行動の生起タイミングの予測を行う.

1 つ目の分析手法として, 行動が発生するまでの経過時間帯をいくつか設定し, 行動生起タイミングの時間帯を目的変数として, 分類を行なった結果, 食事においては 10 分以内に生起する場合のうち 45.5% で行動生起タイミング分類の再現が確認できた. しかし, 分類する時間帯の数が多いため, それ以外の行動では行動生起タイミングの再現率が低く留まった. そのため, 2 つ目の手法として, 時間内行動生起タイミングを目的変数とした予測を行なった. その結果, 1 つ目の手法に比べ, ほぼ全ての行動で行動生起の再現率が向上が確認できた.

2. 先行研究

行動予測の先行研究として, Wu らはベイジアンネットワークを用いた行動予測手法を提案している [1]. 提案手法としては, ベイジアンネットワークを行動, 時間, 日の 3 つを元にそれぞれ作成し, それらを組み合わせ 16 種類の生活行動を予測をしている. また, Kim らはスマートスペースにおける 23 種類の行動を対象に, LSTM を用いて 82.36% で予測している. 彼らは行動予測を自然言語処理のような文章問題と捉え, 行動の遷移を学習している. Iram らは CRF を用いた行動予測手法を提案している [3]. さらに Jakkula らは様々なセンサの動作時間の組み合わせによる確率の変動を用いた行動予測手法を提案している [4].

しかし, これらの研究では, 次の行動の種類はわかるが, 次の行動の生起時間はわからない. そのため, 行動の生起タイミングまで予測できるモデルを作成するために, センサデータを用いることを考える.

守谷らは, スマートホームにおいて, ECHONET Lite 対応家電や人感センサの情報を用いて 9 つの行動を 68% で認識できるという研究が行っている [5]. また, 上田らは超音波位置測位センサと家電の消費電力情報を用いることで 10 種類の行動を 91% で認識するという研究も行っている [6]. しかし, これらの行動認識では, センサデータの瞬時値に着目しており, 時系列性が考慮されていないため, 同様の手法で行動予測をすることはできない.

そこで, 時系列性を学習する DeepLearning アルゴリズムを使用して行動認識ができるかどうか分析を行った [2]. その結果, 機械学習で分析した場合と同等の認識精度で行動認識ができることが確認できた. これにより, LSTM を用いたセンサデータの学習により, 行動予測も可能になると考える.

3. 提案手法

本研究では, 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 モデルの作成を提案する. 行動予測をするために必要な要素として, 「次の行動が何か」と「次の行動が生起するタイミングはいつか」という情報が必要になると考える. そのため, 提案手法では, 行動一つ一つに着目して, 対象行動が次に生起するタイミングがいつかを判別するモデルを作成する. 具体的には, 「スマートホームのセンサデータ」を説明変数, 「次に対象行動が生起する時間」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, 「対象行動が生起する時間」は 2 つの選択方法がある. 1 つ目の選択方法は, 生起タイミングを複数の時間帯で区切る方法である. 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 分未満で生起するか, のように行動生起タイミングを細かく分類できる. このように行動予測が可能になると, 例えば 10 分以上 30 分未満で入浴という行動が発生するのを予測して, 自動湯はりや推薦するサービスに応用ができる. 2 つ目の選択方法は, 生起タイミングが指定時間内かどうかを判断する方法である. 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. こちらの行動予測では, 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サービスに応用できる. この 2 つの方法で分析を行う.

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



図 1 スマートホーム内観

前処理をして作成する。まず、10秒おきの行動ラベルから対象行動を行っているかどうかのラベルに置き換える。そして、10秒おきに対象行動が生起するまでの時間を計算する。このように導き出された計算結果に対して、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。

4. データ収集環境

本章では、生活行動実験のために使用する実験環境について述べる。本研究では、奈良先端科学技術大学院大学内のスマートホーム(1LDK)を使用する。図1に実験で使用したスマートホームの写真を示す。このスマートホームを用いて、計15泊分の宅内行動データを取得する。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。このセンサ群により、行動中のセンサ値を取得できるため、人の宅内行動とその状態をセンサデータとして取得できる。

4.1 使用するセンサ

4.1.1 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。

4.1.2 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1に電力値を取

表 1 Bluetooth ワットチェッカーによる電力値取得対象

対象	場所
エアコン	寝室
机上コンセント	寝室
ベット横コンセント	寝室
冷蔵庫	キッチン
電子レンジ	キッチン
ポット	キッチン
炊飯器	キッチン
テレビ	リビング
ソファ横コンセント	リビング
扇風機	リビング

表 2 クランプ式 CT センサによる電流値取得系統

配電先	場所
IH ヒーター	キッチン
電気温水器	室外
エアコン	リビング
浴室乾燥機	浴室
照明	リビング・キッチン・寝室
コンセント	廊下・キッチン
エアコン	寝室
コンセント	寝室
コンセント・洗面照明	玄関・廊下・浴室・トイレ・洗面
コンセント	洗面
コンセント	キッチン
コンセント	リビング

得する対象の一覧を示す。

4.1.3 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。これにより、各部屋に流れる電流値を把握することができる。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に電流値を取得する系統の一覧を示す。

4.1.4 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、家電情報に変換して使用する。表3にECHONET Lite 対応家電の一覧を示す。

4.1.5 人感センサ

人感センサは人がセンサ前を通っ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

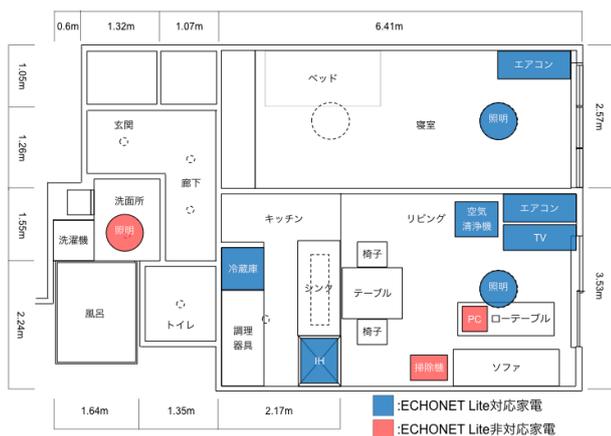


図 2 ECHONET Lite 対応家電の設置図

表 3 ECHONET Lite 対応家電

家電	部屋	型番
エアコン	リビング	MSZ-ZXV255-W
エアコン	寝室	MSZ-ZXV225-W
天井照明	リビング	LEDH82718XLC-LT3
天井照明	寝室	LEDH81510NLC-LT4
冷蔵庫	キッチン	MR-JX48LY
IH	キッチン	CS-T34VS
TV	リビング	LCD-40ML7
空気清浄機	リビング	KI-EX-100

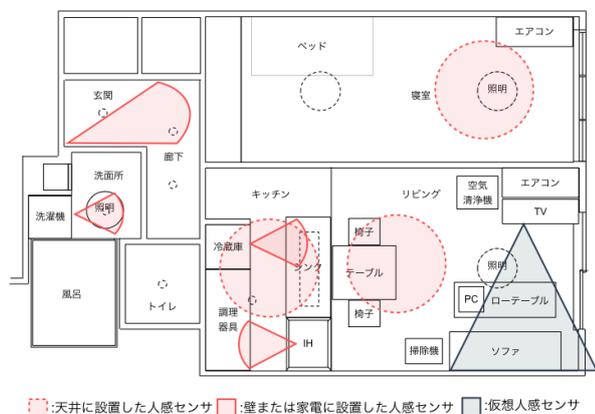


図 3 人感センサの設置箇所

EnOcean という通信規格で行うことができる。こ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。

5. データ収集実験

本章では、生活データを収集するために行った日常生活行動データ収集実験について説明する。

表 4 対象行動一覧

指定外	掃除	長期外出	料理
携帯	読書	PC	洗濯
風呂掃除	TV 視聴	食事	洗顔
食器洗い	入浴	ゲーム	睡眠
短期外出	歯磨き	化粧	

5.1 実験概要

実験では被験者 5 名 (20 代男性 4 名, 20 代女性 1 名) に一人当たり 3 泊 4 日の期間で生活してもらい、計 15 泊分の位置情報、消費電力情報、家電情報、人感センサ情報を収集する。また、実験中には行動ラベルを収集するため、任意の位置にビデオカメラを設置し、被験者の生活行動の様子を被験者自身が撮影する。

5.2 行動の種類

実験時の行動は、実験終了後に被験者に行動ラベリング支援ツールを使用し、ビデオカメラ映像と行動ラベルボタンによるタイムスタンプを基に実験時の行動ラベル (いつ何を行ったのか) を作成してもらう。このように、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。表 4 に記録する行動の一覧を示す。行動の中で、長期外出は 30 分以上の外出を、短期外出は 30 分以下の外出を示す。また、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、トイレという行動はスマートホーム外のトイレを使用するため短期外出に分類される。

5.3 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。

- 行動ラベル用ボタンを所持すること
- 表 4 に示す 19 種類の行動を出来るだけ 1 日 1 回以上行うこと (化粧は女性被験者のみ)
- 睡眠以外の行動を 1 日 3 時間以上行うこと
- 睡眠時間を含む行動を 1 日 10 時間以上行うこと
- 各行動の開始・終了時に行動ラベル用ボタンを押すこと

6. データ分析

本章では、分析に使用した手法とその結果について説明する。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、2 つの手法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(Long Short Term Memory) を利用して学習モデルを構築し分析を行う。

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。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。

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 Cross Validationで行う。学習モデルの説明変数として、超音波位置測位センサによる位置情報（3種類）、Bluetoothワットチェッカーによる消費電力値（10種類）、クランプ式CTセンサによる消費電流値（12種類）、ECHONET Lite対応家電の情報（8種類）、ECHONET Lite非対応家電の情報（3種類）、人感センサの情報（7種類）、仮想人感センサの情報（1種類）の合計44種類を使用する。目的変数は以下に示すそれぞれの分析手法によって変更する。

6.1 行動生起期間の予測

6.1.1 分析手法

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、現在行動中、10分経過までに生起、10分以上経過かつ30分経過までに生起、30分以上経過かつ1時間経過までに生起、1時間以上経過かつ2時間経過までに生起、2時間以上経過かつ3時間経過までに生起、それ以上の時間が経ってから生起（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。と考える。

6.1.2 分析結果

表5に経過時間別次行動生起の再現率を示す。表5において、列は行動を示し、行は行動が生起する期間を示している。生起する期間において、nowは既に対象行動を行なっている最中であることを示し、～10min、10min～30min、30min～1hour、1hour～2hour、2hour～3hourは対象行動が生起する時間を示す。また、otherは3時間以上経過後に生起する場合か生起しない場合を示している。

食事に注目してみると、「10分以内に生起する」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

センサデータがあれば、食事をするという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。

しかし、全体的な傾向として、予測精度はあまり高くはないことがわかる。これは、分類する生起時間パターンが多すぎるために、正しく学習できていない可能性がある。

6.2 時間内次行動生起の予測

6.2.1 分析手法

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。また、実用上では行動の生起期間を予測することより、時間内に生起する行動がわかることが重要だと考える。つまり、1時間～2時間経過している時にある行動が生起するという予測より、2時間以内にある行動が生起するという予測が必要であると考え。そのため、2つ目の行動予測手法として、時間内に行動が生起するかどうかを予測するモデルを作成する。この手法は、先ほどの行動生起期間の予測の分類種類を少なくしたもので、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。このように行動予測モデルを単純化することによって、行動予測精度の向上が期待できると考える。指定時間としては、10分、30分、1時間で分析を行う。

6.2.2 分析結果

表6に時間内行動生起の再現率を示す。この値は各行動の生起タイミングにおいて、行動中、指定時間内に生起、指定時間経過後に生起もしくは生起しない、の3値分類を行った後の指定時間内に生起に分類されたものの再現率を示している。表6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。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。例えば、食事という行動は実際にある時点から10分以内に生起したもののうち47.4%が正しく予測できているとわかる。

表5と表6を比較してみると、ほとんどの行動において、提案手法1より行動生起の再現率が上がっている。特に1時間以内に生起する行動の再現率が大きく向上している。ただ、全体的に予測精度としては低い値を示している。これは、実験環境での生活では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。行動認識においては、全ての行動が起こらないと行動認識モデルが構築できないという理由で、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たが、行動予測では実生活の行動順序とは異なったデータとなり、予測が難しくなる。また、今回は10秒ごとにデータを丸めて分析を行ったが、より細かい粒度でセンサデータを見ることで予測精度が向上するのではないかと考える。

表 5 経過時間別次行動生起の再現率

	入浴	歯磨き	掃除	風呂掃除	料理	ゲーム	長期外出	洗濯	化粧	食事
now	0.750	0.149	0.000	0.000	0.735	0.522	0.921	0.004	0.207	0.594
~10min	0.004	0.037	0.010	0.093	0.078	0.000	0.051	0.101	0.186	0.455
10min~30min	0.033	0.200	0.061	0.125	0.064	0.214	0.242	0.189	0.000	0.154
30min~1hour	0.110	0.072	0.191	0.248	0.169	0.369	0.200	0.194	0.122	0.141
1hour~2hour	0.147	0.209	0.075	0.235	0.118	0.219	0.060	0.247	0.048	0.268
2hour~3hour	0.103	0.163	0.094	0.000	0.104	0.071	0.012	0.029	0.00	0.067
other	0.948	0.372	0.949	0.936	0.873	0.955	0.846	0.832	0.979	0.932
	指定外	PC	読書	短期外出	睡眠	携帯	食器洗い	洗顔	TV 視聴	
now	0.316	0.682	0.406	0.094	0.931	0.551	0.210	0.208	0.242	
~10min	0.472	0.000	0.048	0.019	0.047	0.035	0.181	0.228	0.074	
10min~30min	0.282	0.000	0.032	0.176	0.079	0.201	0.207	0.057	0.110	
30min~1hour	0.143	0.052	0.021	0.095	0.214	0.144	0.191	0.000	0.124	
1hour~2hour	0.104	0.077	0.072	0.148	0.241	0.039	0.178	0.113	0.206	
2hour~3hour	0.103	0.126	0.056	0.113	0.115	0.034	0.088	0.143	0.104	
other	0.783	0.910	0.941	0.848	0.917	0.810	0.903	0.922	0.872	

表 6 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	食事
~10min	0.002	0.103	0.000	0.129	0.155	0.000	0.190	0.138	0.040	0.474
~30min	0.031	0.238	0.256	0.222	0.157	0.204	0.144	0.284	0.270	0.538
~1hour	0.052	0.266	0.327	0.271	0.260	0.259	0.325	0.238	0.113	0.564
	指定外	PC	読書	短期外出	睡眠	携帯	食器洗い	洗顔	TV 視聴	
~10min	0.435	0.004	0.150	0.015	0.078	0.064	0.301	0.133	0.118	
~30min	0.658	0.001	0.082	0.092	0.032	0.268	0.370	0.399	0.164	
~1hour	0.717	0.053	0.226	0.270	0.307	0.399	0.370	0.450	0.246	

7. おわりに

本研究では、位置情報や行動認識を用いたサービスより高度な家電制御を提供するために必要な行動予測を実現するために、2つの行動予測手法について提案した。

1つ目の分析手法として、行動生起期間を予測する行動予測を提案した。結果としては、食事などの一部の行動では行動生起の再現が確認できたが、それ以外の行動においてはあまり再現率が高くなかった。この原因として、行動予測の分類数が多すぎるために誤った学習をしている可能性が考えられたので、分析手法を変更することにした。

2つ目の分析手法として、時間内行動生起を予測する行動予測を提案した。結果としては、ほとんどの行動において予測精度が向上したことが確認できた。しかし、その予測精度は高いものではなく、さらなる検討が必要であると考えられる。

今回の分析では、被験者に対して、指定した19種類の行動全てを毎日行ってもらうように指示したが、実生活とは乖離した実験データになっている可能性がある。例えば、料理の後に食事をするなど、一般的に誰もが行う行動順序の場合は実生活に近いデータとして収集できる。一方で、普段ゲームをしない人がゲームを行う時間を無理やり作ったとすれば、人によって異なったタイミングで生起する行

動になる。そのため、行動認識には使えるデータだが、行動予測には使用できないデータの可能性がある。

さらに、行動予測精度を高めるためには、普段の生活を再現して生活をしてもらった方がより高い精度で予測できると考えられる。また、センサデータの粒度について、今回の分析では、10秒おきのデータに丸めて用いたが、より細かい周期で利用することで、10秒間に反応するセンサの順番も考慮して学習が行えるので、予測精度が向上するのではないかと考える。

謝辞

本研究の一部は JSPS 科研費 16H01721, 17KT0080 による助成を受けたものです。

参考文献

- [1] Wu, Z.-H., Liu, A., Zhou, P.-C. and Su, Y. F.: A Bayesian network based method for activity prediction in a smart home system, *Systems, Man, and Cybernetics (SMC), 2016 IEEE International Conference on*, IEEE, pp. 001496–001501 (2016).
- [2] 佐々木渉, 藤原聖司, 諏訪博彦, 藤本まなど, 荒川 豊, 木村亜紀, 三木智子, 安本慶一: ECHONET Lite 対応家電と人感センサの時系列データ分析による宅内行動認識, *社会システムと情報技術研究ウィーク* (2017).
- [3] Fatima, I., Fahim, M., Lee, Y.-K. and Lee, S.: A unified

framework for activity recognition-based behavior analysis and action prediction in smart homes, *Sensors*, Vol. 13, No. 2, pp. 2682–2699 (2013).

- [4] Jakkula, V. and Cook, D. J.: Mining sensor data in smart environment for temporal activity prediction, *Poster session at the ACM SIGKDD, San Jose, CA* (2007).
- [5] Moriya, K., Nakagawa, E., Fujimoto, M., Suwa, H., Arakawa, Y., Kimura, A., Miki, S. and Yasumoto, K.: Daily living activity recognition with ECHONET Lite appliances and motion sensors, *Pervasive Computing and Communications Workshops (PerCom Workshops), 2017 IEEE International Conference on*, IEEE, pp. 437–442 (2017).
- [6] 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).