

IoT 見守りデバイスの開発とセンサデータからの行動予測

マハルジャン ラビン[†]白石 晃一[‡]山本 岳洋[§]山本 祐輔[¶]

Rabin MAHARJAN

Koichi SHIRAIISHI

Takehiro YAMAMOTO

Yusuke YAMAMOTO

大島 裕明[†]

Hiroaki OHSHIMA

1. はじめに

現在、少子高齢化とともに、単身世帯が増えつつある。家族と一緒に住んでいる人と違って、単身世帯の人は、自分で話さない限りは、どのように日常生活を送っているのか本人以外は知らないという状態になっている。たとえば、怪我をしたり、病気などで倒れたりしても、誰にも気づかれないということも実際に起こっている。そこで、本研究では、人の日常生活における行動を IoT 見守りデバイスで取得し、遠隔地の家族とその行動情報を共有する仕組みを提案する。高齢者単身世帯の人など、一人暮らしの人の生活の中で発生したできごとを、遠隔地に住む家族に知らせることが可能となる仕組みである。

本研究では下記の二つの課題に取り組んだ。

1. 日常生活の行動情報を取得する IoT 見守りデバイスの開発
2. センサデータから機械学習を用いた行動予測

まず、そのような見守りを可能とする IoT 見守りデバイスの開発を行った。開発した IoT 見守りデバイスには、いくつかのセンサが搭載されている。IoT 見守りデバイスのセンサから得られたデータを収集し、Wi-Fi 経由でクラウド上に送信するようになっている。図 1 は、開発した IoT 見守りデバイスの外観を表している。

次に、IoT 見守りデバイスから得られたセンサデータから、機械学習を用いた手法により、日常生活でどのような行動が行われているかの予測を行う。ここで予測する行動は「お喋り」「料理」「食事」といった行動である。行動情報を遠隔地の家族と共有することで、単身世帯の人を緩やかに見守ることができると考えている。

センサデータそのものを遠隔地の家族に伝えるということも、見守りの手段としては考えられるだろう。しかし、本研究では、見守られる対象者が、家族に対してで

あれば伝えても良いと考えられる程度に行動を抽象化することで、監視にならない見守りを実現したいと考えている。

2. 関連研究

センサを用いて人間の行動を監視する研究は、これまでも数多く行われている。

Li ら [1] は、高齢者の看護や生活を支援することを目的として、日常生活のパターンを自動的に把握する研究を行った。Lago ら [2] は、センサデータから行動を認識する研究を行った。モデルとして、確率的なモデル (Hidden Markov Chain) と論理的なモデルという 2 つのモデルを組み合わせて利用している。モデルの組み合わせで、お互いの弱点となる部分を補うことで、高い精度を実現している。Aicha ら [3] は、センサデータから単身世帯の高齢者の部屋に来客が訪れたかを推定する研究を行った。この研究では、Markov modulated multidimensional non-homogeneous Poisson process (M3P2) 教師なし学習モデルや Markov modulated Poisson process (MMPP) が用いられており、前者を用いたモデルの方がより推定精度が良いということが報告されている。Eisa ら [4] は、複数の人感センサを用いて、日常生活で起きる異常を検出するシステムについて研究を行った。部屋ごとに配置された複数の人感センサで行動を監視し、自動的に異常を発見する。Raykov ら [5] は、1 つの人感センサを用いて部屋の人数を推定する研究を行った。学習モデルの作成には、Infinite Hidden Markov Model (iHMM) を利用してい



図 1: IoT 見守りデバイス

[†] 兵庫県立大学 応用情報科学研究科, Graduate School of Applied Informatics, University of Hyogo

[‡] 京都造形芸術大学 芸術学部, Faculty of Art and Design, Kyoto University of Art and Design

[§] 兵庫県立大学 社会情報科学部, School of Social Information Science, University of Hyogo

[¶] 静岡大学 情報学部, Faculty of Informatics, Shizuoka University




図 2: ESP32 マイクロコントローラ

る. Viard ら [6] はセンサデータから日常生活の行動を推定する研究を行った. Hidden Markov Model (HMM) を用いて, 学習モデルを作成した. センサからは豊富なデータが取得されている. 行動を監視するために彼らを用いたセンサは少ないが, HMM を用いたモデルで高い精度が実現された. Hong ら [7] は, window energy detection (WED) と alarm duration detection (ADD) を用いて, 誤警報を削減する研究を行った. Bayoumi ら [8] は, 照度センサを用いて, 人間の行動を推定する研究を行った. 照度センサに当たる光の量によって人間の行動が推定された. Bamis ら [9] は, 高齢者の行動をセンサで監視し, 異常があれば知らせたり, 生活の情報を伝えたりするシステムの開発を行った. 多種類のセンサが用いられており, 高齢者の行動モデルを自動的に生成することが行われている. Cuddihy ら [10] は, 複数の人感センサを用いて, ある人が長期間にわたって動きがないことを検出する研究を行った. ある一定時間に渡ってもその人の行動が感知されない場合に, 看護師や関係者にメールなどの方法で知らせるといったような応用が想定されている.

3. IoT 見守りデバイス

本節では, 本研究で開発した, 人の日常生活を見守り, 搭載された様々なセンサからデータを取得することができるデバイスについて説明する. 開発した IoT 見守りデバイスの基本的な機能は, 電源を投入すると, 6 秒に一度, センサから得られたデータを WiFi 経由でクラウドに送信するというものである.

3.1 マイクロコントローラ

IoT 見守りデバイスの頭脳として, センサの制御を行い, 通信を行うため, ESP32 というマイクロコントローラを利用した. 図 2 は ESP32 の写真である.

ESP32 は小型で Arduino などと比べると高性能なマイクロコントローラであるといえる. 特に, ESP32 には, WiFi モジュールが搭載されており, WiFi での通信が可能な環境では, ESP32 の WiFi モジュールで直接インターネットに接続を行うことが可能である. 本デバイスでは, WiFi で取得したセンサデータの送信を行っている. 表 1 では, ESP32 の特徴を示している.

開発には, Arduino IDE を利用することが可能である. プログラミングは C++ をベースにしたプログラミ

表 1: ESP32 の特徴

マイクロコントローラ	ESP32
コア数	2
アーキテクチャ	32 Bit
CPU クロック周波数	160 MHz
WiFi	YES
RAM	512KB
GPIO ピン数	36
ADC ピン数	18
DAC ピン数	2

ング言語で行う. Arduino のために用意された多くのライブラリを ESP32 においてもそのまま利用することができることが多い. そのため, 比較的容易にセンサデバイスの開発を行うことが可能である.

3.2 センサ群

本デバイスで搭載するセンサは, 以下の 7 つである.

1. 人感センサ
2. 照度センサ
3. 音圧センサ
4. 赤外線リモコンセンサ
5. 温度センサ
6. 湿度センサ
7. 気圧センサ

人間の行動と環境の変化によって, これらのセンサから取得されるデータが変化する.

3.2.1 人感センサ

人感センサは赤外線を使って人などの動きを判断するセンサである. Passive Infrared Ray (PIR) センサとも呼ばれる. このセンサは防犯アラームや, 自動的に電灯を点灯させるためなどに利用されることが多い. 1 か 0 を出力するデジタルセンサである. 周辺の赤外線環境に変化があれば, 一定時間 1 を出力し, 変化がない間は 0 を出力する. 一度反応して 1 を出力し始めると, 決められた時間の間, 常に 1 を出力し続ける. 本研究では, 図 3 の人感センサを利用した. 人の動きなどを感知したときに, 1 を出力する時間は 5 秒間と設定した.

3.2.2 照度センサ

照度センサは明るさに反応するセンサである。アナログセンサであり、0 から 4095 の間の整数を返す。照度センサは、フォトトランジスタと抵抗から構成される。フォトトランジスタは、明るくなるほど抵抗値が低くなるという特性を持つ電子素子である。明るいとき照度センサの値は大きくなり、暗いとき照度センサの値は小さくなる。図 5 は今回利用したフォトトランジスタである。

3.2.3 音圧センサ

音圧センサは、いわゆるマイクを使って構成される。マイクは、音圧によって出力される値が変化するセンサである。本研究では、音声を認識できるほどのサンプリングレートは用いず、音がなっているかどうかを判断する程度のデータを取得するために用いる。

マイクは、アナログセンサであり、0 から 4095 の間の整数を返す。無音状態の場合は、0 と 4095 の中間の値である 2047 程度の値を示す。音がある状態の時には、音圧に応じてそこから上下にずれた値を示す。このような特性を持つため、本デバイスでは、6 秒の間に、1/100 ごとにマイクのサンプリングを行い、そこで得られたデータ群の分散を求め、それを音圧センサの値として出力するようにしている。図 6 は今回利用したマイクである。

3.2.4 赤外線リモコンセンサ

赤外線リモコンセンサはテレビやエアコンなどのリモコンが出力する、赤外線を受信するセンサである。デジタルセンサであり、0 か 1 の値を返す。テレビのチャンネル設定や、エアコンの設定などの情報は、テレビやエアコンのリモコンは赤外線によるデジタル信号を発信される。赤外線の信号をある程度以上のサンプリングレートで赤外線リモコンセンサによって感知することで、情報の伝達が行われる。本研究では、現在のところ、リモコンの赤外線を受信している時は 1 を、受信していないときには 0 を出力するというのみを行っている。図 4 は今回利用したセンサである。

3.2.5 温度センサ、湿度センサ、気圧センサ

温度センサ、湿度センサ、気圧センサは、それぞれ、温度、湿度、気圧を感知して数値を返すセンサである。本デバイスでは、BME280 チップを用いたセンサモジュールキットを用いており、この一つのセンサキットから温度、湿度、気圧をそれぞれ別々に取得することが可能で



図 3: 人感センサ



図 4: フォトトランジスタ



図 5: マイク



図 6: 赤外線リモコンセンサ



図 7: 温度・湿度・気圧センサ

ある。マイクロコントローラとは、I2C を用いて通信している。センサの測定範囲と精度は以下の通りである。

- 温度：-40～+85℃
- 湿度：0～100%，± 3%
- 気圧：300～1100hPa，± 1hPa

温度は摂氏、湿度はパーセント、気圧はヘクトパスカルの単位で、それぞれ小数点数として取得できる。図 7 は今回利用したセンサである。

3.3 電源と三脚マウント

IoT 見守りデバイスは、室内で固定して利用することを想定している。様々な場所に配置しやすくするために、三脚で使われるネジに適合するナットが埋め込まれている。図 1 は、ポータブル三脚に固定した IoT 見守りデバイスの様子を表している。

3.4 クラウドにおけるデータ収集

IoT センサデバイスのデータは WiFi 経由でクラウドに送信する。クラウドサービスでは、そのデータを保存するとともに、行動予測のために取得を行うことができるようになっている。本研究では、Ambient*クラウドサービスを利用してセンサデータを蓄積した。Ambient ではセンサデータを蓄積する以外にも、蓄積されたセンサデータの可視化を行うことが可能である。

4. 実験データの取得

4.1 実験環境と得られたデータ

IoT 見守りデバイスを用いて行動予測を行うために、実験データの取得を行った。実験は、第一著者の所属する研究室で行った。研究室は、図 8 のような部屋である。

*Ambient : <https://ambidata.io>




図 8: 行動を監視した部屋の間取り

部屋に二つの IoT 見守りデバイスを配置し、1日あたり、約 5 時間、センサを動作させてデータの取得を行った。図 8 で赤丸で表示されている場所に IoT 見守りデバイスを配置した。一つ目の IoT 見守りデバイスは出入口のドアの近くに、二つ目は部屋の中央付近のテーブルの上にそれぞれ設置した。

一日あたり、約 5 時間のデータ取得を、8 日間行った。先述した通り、6 秒ごとにデータが取得されており、8 日間に取得されたデータサンプル数は 20,401 件であった。

表 2 に、一つの IoT 見守りデバイスから取得されるセンサデータ列の例を示す。7 つのセンサデータが 6 秒に 1 度得られている。ここでは約 30 秒の間に得られたデータ列を示している。

温度、湿度、気圧のデータは、この程度の時間ではあまり変化が見られないことが分かる。特に気圧については、天気や季節の変化によって変動するが、短時間のデータではほとんど変化が見られることはない。温度はエアコンを使って室内の温度調整を行っている場合には、あまり大きな変化は見られない。しかし、部屋の中の人数が増えたり、料理を行ったりすると、温度が上がる様子が見られる。また、無人であったりして、エアコンを使っていない場合には、日が高くなるにしたがって温度が高くなり、日が沈むにしたがって温度が低くなるという様子が見られる。湿度については、一日でのデータにはあまり大きな変化が見られないが、お湯を沸かすというような行動を行った場合には、顕著な変化が見られることもある。

照度センサは部屋の明るさを感知することができる。電灯が点灯している場合には値が高くなり、消灯している場合には値が低くなる。窓がある場合には、外の明るさの影響も受ける。

人感センサと音圧センサの値は、短時間で大きく変化することが多い。人感センサは、赤外線に変化があれば 1 を出すため、人が動いた時には容易に反応する。音圧センサは音楽を付けていたり、しゃべっていたり、何ら

かの騒音が聞こえていたりすると、値が高くなる。

リモコンセンサはリモコンが利用されたときには、センサの位置やリモコンが向けられている方向にかかわらず、1 を出力することが多い。

このように、IoT 見守りデバイスからは、6 秒ごとに 7 次元のベクトルデータが得られる。実験では、部屋に二つの IoT 見守りデバイスを配置し、それらを連結して利用した。すなわち、6 秒ごとに 14 次元のベクトルデータを取得した。

4.2 ラベル付け

部屋において人が取った行動の正解ラベル付けを行うために、部屋の全体を映るようにビデオカメラを設置した。図 8 で赤い四角で表しているのがビデオカメラの位置である。部屋の隅に配置して、センサデバイスを動作させている間、撮影を行った。ある時間に、どのような行動が行われたかを撮影されたビデオカメラを見ながらラベル付けを行った。

本実験で予測の対象とした行動は、以下の 3 つの行動である。

1. 食事
2. 料理
3. お喋り

食事は、何かを食べる行動である。料理は、お湯を沸かしてインスタントラーメンを作ったり、電子レンジで食品を温めるなどの行動である。お喋りは、誰かと誰かが話をする行動である。

ここで付けたラベルは、ある時間においてある行動がとられていたかを示すものである。人が同時に二つ以上の行動を取る可能性がある。たとえば、食事しながらお喋りしたり、音楽聞きながら料理したりすることがある。そこで、ある時間に対して、上記の 3 種類のラベルのそれぞれを付与するか付与しないかを決定した。すなわち、マルチラベル分類問題として扱う。

4.3 行動推定を行うラベル

先述したラベルは、ある時間においてある行動がとられていたかを示すものであったが、行動の推定という意味では、6 秒ごとの粒度でに行動を推定する必要はない。ある幅を持った時間内に、ある行動がとられたかどうか推定されれば十分であると考えられる。

本研究では、ある 5 分間において、「食事」「料理」「お喋り」という 3 種類の行動が一度でも取られたかどうかを推定するというを行う。そこで、前節で述べたラベル付けの結果を用いて、あらゆる 5 分間のウィンドウサイズのラベルデータの集約を行い、行動推定を行うためのラベルを生成した。

表 2: 一つの IoT 見守りデバイスから得られるセンサデータ列の例

温度	気圧	湿度	照度	人感	音圧	リモコン
26.40	1015.77	25.26	2261	0	61	0
26.39	1015.85	24.88	2246	1	114	0
26.39	1015.80	25.19	2277	1	267	0
26.38	1015.82	24.52	2286	0	112	0
26.38	1015.85	24.32	2292	0	48	0
26.39	1015.84	28.43	1291	0	74	0

5. センサデータからの行動予測

5.1 訓練データとテストデータ

今回用いたデータは、先述した通り、8 日間に取得されたデータである。そこで、8 日間のうちの 1 日のデータをテストデータとし、残りの 7 日間のデータを訓練データとして用いることとした。

訓練データのサンプル数は 18,147 件、テストデータのサンプル数は 2,254 件であった。

5.2 SVM と LSTM を用いた行動予測

センサデータから行動予測する実験では、SVM を用いた手法と、LSTM (Long short-term memory) を用いた手法を実装した。SVM は scikit-learn を用い、LSTM は Keras API を用いて実装した。LSTM [11] は、ディープラーニング分野の人工回帰型ニューラルネットワーク (RNN) アーキテクチャである。行動の予測はマルチラベル分類問題の One-Vs-One の形で行った。一つの行動ラベルのために一つの分類器を作成し、三つ行動ラベルそれぞれの予測を行った。

SVM では、5 分間に取得された 14 次元のデータ列を集約することで、28 次元のベクトルを作成した。まず、スライディングステップを 1 サンプルとして、5 分間に相当する 50 サンプルの時間ウィンドウを決定した。各時間ウィンドウにおいて、50 サンプルのデータの平均と分散を取得した。それぞれで 14 次元のベクトルが得られるため、それらを連結して 28 次元のベクトルとした。特徴の正規化は日ごとにデータセットに対して行った。また、訓練においては scikit-learn の RandomUnderSampler を用いて、アンダーサンプリングを行った。SVM の各種パラメータとしては、以下のものを用意して、グリッドサーチを行って最適なパラメータを利用した。

- カーネル : {linear, RBF}
- RBF カーネルの γ : {0.1, 0.01, 0.001, 0.0001}
- C : {1, 10, 100, 1000}

LSTM では、ネットワークに入力するためにサンプルのシェイプの変化を行った。SVM と同様に、スライディ

ングステップは 1 サンプルで、ウィンドウサイズは 5 分間に相当する 50 サンプルとした。LSTM ではモデル作成を行う際に、バッチごとに正規化が行われる機能があり、今回はそれを利用した。そのため、データの前処理として正規化を行っていない。LSTM において用いたパラメータは以下の通りである。

- *activation* : {sigmoid}
- *optimizer* : {RMSprop}
- *loss* : {binary_crossentropy}

5.3 実験結果

SVM と LSTM で行った行動予測の結果について述べる。SVM と LSTM のいずれを用いた場合にも、行動の予測は困難な問題であったといえる。

表 3 で、SVM と LSTM のそれぞれを用いた手法の結果を示している。たとえば、「食事」というラベルがあるということを出力する問題においては、SVM を用いた手法では f1 が 0.51 であり、LSTM を用いた手法では f1 が 0.28 であった。時系列のデータであるため、LSTM を用いた手法の方が高い精度を実現できると想定していた。しかしながら、実際には、SVM を用いた手法の方が良い精度となった。LSTM の精度が低くなった原因の一つは、データ量が少なかったからであると考えられる。SVM と LSTM の両方において予測精度が低かった主な原因は、ラベルに偏りがあることであると考えられる。日常生活の行動のなかでは予測することが困難な行動が多いが、豊富なデータがあれば、ラベルに偏りがあっても精度が上げられ、行動予測を正しく行うことができる。と考えられる。

6. まとめと今後の課題

本研究では、IoT 見守りデバイスの開発とそれを用いて人の行動情報を取得し、日常生活を推定する仕組みを提案した。IoT 見守りデバイスには様々なセンサ、たとえば、人感センサ、照度センサなどを搭載した。得られ

表 3: 行動予測の実験結果

行動ラベル	SVM			LSTM		
	適合率	再現率	f1	適合率	再現率	f1
食事	0.63	0.43	0.51	0.22	0.40	0.28
料理	0.29	0.62	0.39	0.31	0.15	0.21
お喋り	0.30	0.75	0.43	0.53	0.23	0.32

たセンサデータから SVM を用いた手法や LSTM を用いた手法によって行動予測を行った。

今回は一日のうち、約 5 時間のデータを使用したが、今後は 24 時間のデータを取りたいと考えている。24 時間のデータを一週間以上取ることができれば、一日の人の行動パターンがより鮮明に見えてくると考えられる。

今後は、距離センサなどの現在利用していないセンサを利用し、よりよい精度で人の行動を予測できるようにすることを目指す。

謝辞

本研究は 2019 年度国立情報学研究所 CRIS 委託研究, JSPS 科学研究費助成事業 JP16H02906, JP18H03494, JP17H00762, JP18H03243 による助成を受けたものです。ここに記して謝意を表します。

参考文献

- [1] C. Li, W.K. Cheung, J. Liu, and J.K. Ng, “Automatic extraction of behavioral patterns for elderly mobility and daily routine analysis,” *ACM Trans. Intell. Syst. Technol.*, vol.9, no.5, pp.54:1–54:26, 2018.
- [2] P. Lago and S. Inoue, “A hybrid model using hidden markov chain and logic model for daily living activity recognition,” *Proceedings*, vol.2, no.19:1266, pp.1–7, 2018.
- [3] A.N. Aicha, G. Englebienne, and B. Kröse, “Unsupervised visit detection in smart homes,” *Pervasive Mob. Comput.*, vol.34, no.C, pp.157–167, 2017.
- [4] S. Eisa and A. Moreira, “A behaviour monitoring system (bms) for ambient assisted living,” *Sensors*, vol.17, no.9:1946, pp.1–24, 2017.
- [5] Y.P. Raykov, E. Ozer, G. Dasika, A. Boukouvalas, and M.A. Little, “Predicting room occupancy with a single passive infrared (pir) sensor through behavior extraction,” *Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, pp.1016–1027, 2016.
- [6] K. Viard, M.P. Fanti, G. Faraut, and J. Lesage, “An event-based approach for discovering activities of daily living by hidden markov models,” *2016 15th International Conference on Ubiquitous Computing and Communications and 2016 International Symposium on Cyberspace and Security (UCC-CSS)*, pp.85–92, 2016.
- [7] S. Gi Hong, S. Kim, and W. Woo Kim, “Reduction of false alarm signals for pir sensor in realistic outdoor surveillance,” *ETRI Journal*, vol.35, no.1, pp.80–88, 2013.
- [8] S. Bayoumi, T. Pridmore, and B. Koleva, “Exploiting ambient illumination to locate and recognise user behaviour in enclosed environments,” *Personal and Ubiquitous Computing*, vol.14, no.4, pp.335–345, 2010.
- [9] A. Bamis, D. Lymberopoulos, T. Teixeira, and A. Savvides, “Towards precision monitoring of elders for providing assistive services,” *Proceedings of the 1st International Conference on Pervasive Technologies Related to Assistive Environments*, pp.49:1–49:8, 2008.
- [10] P. Cuddihy, J. Weisenberg, C. Graichen, and M. Ganesh, “Algorithm to automatically detect abnormally long periods of inactivity in a home,” *Proceedings of the 1st ACM SIGMOBILE International Workshop on Systems and Networking Support for Healthcare and Assisted Living Environments*, pp.89–94, 2007.
- [11] S. Hochreiter and J. Schmidhuber, “Long short-term memory,” *Neural Comput.*, vol.9, no.8, pp.1735–1780, 1997.