

話題提供を行うための独居家族との「気配」共有システム

マハルジャンラビン[†] 白石 晃一^{††} 山本 岳洋^{†††} 山本 祐輔^{††††} 大島 裕明[†]

[†] 兵庫県立大学 応用情報科学研究科 〒650-0047 兵庫県神戸市中央区港島南町 7-1-28

^{††} 京都造形芸術大学 芸術学部 〒606-8271 京都府京都市左京区北白川瓜生山 2-116

^{†††} 京都大学 情報学研究科 〒606-8501 京都府京都市左京区吉田本町 36-1

^{††††} 静岡大学 情報学部 〒432-8011 静岡県浜松市中区城北 3-5-1

E-mail: [†]{aa18j512,ohshima}@ai.u-hyogo.ac.jp, ^{††}shiraishi@kuad.kyoto-art.ac.jp,

^{†††}tyamamot@dl.kuis.kyoto-u.ac.jp, ^{††††}tyamamoto@inf.shizuoka.ac.jp

あらまし 本研究では、独居している家族の行動情報を IoT センサデバイスを用いて取得し、遠隔地にいる家族とのコミュニケーションを促進させる話題提供を行う仕組みを提案する。現在、少子高齢化の流れの中で、独居している人の割合が増えつつあり、そのような人を家族として持つ世帯が多くなってきている。独居している人のコミュニケーションの量を増やすことが、社会的幸福をもたらすと考えられるが、多忙な日常の中で遠隔地にいる家族とのコミュニケーションがあまり多くない場合も多い。その原因として、独居している家族のことがよく分からず、話題が乏しいということが考えられる。そこで、IoT センサデバイスから得られたデータを機械学習技術によって抽象化し、同居していればなんとなく分かる程度の「気配」ともいえる情報を構築し、遠隔地家族とプライベートメッセージャーなどを通して共有することで、コミュニケーション促進を目指す。

キーワード IoT デバイス, 行動情報, 高齢者見守り

1. はじめに

現在、単身世帯の割合が増加しており、単身世帯の者が家族にいる割合も必然的に増加している。国立社会保障・人口問題研究所の調査によると、日本では 2015 年には 34.5% が単身世帯であり、2040 年には 39.3% に達すると予想されている [1]。また、内閣府による平成 30 年版高齢社会白書 [2] では、全世帯のうち 13.1% が 65 歳以上の単身世帯であると報告されている。さらに、55 歳以上の単身世帯では、43.4% が家族や友人との会話の頻度が「2～3 日に 1 回以下」であると回答している。会話を行わない高齢者の健康は相対的に低くなるという研究もあり、独居する高齢者が社会的に健全に生きていくためには、同居していない家族が独居高齢者より頻繁に会話をするようになる必要があると考えられる。

しかし、独居する家族とは、異なる環境で生活しているため、共通の話題を持つことが難しいことが多いと考えられる。毎日のように会話をしようとしても、常に適当な話題があるわけではない。これは、独居する家族が高齢者の場合でも若年者の場合でも同様である。本研究では、このような、独居している家族とのコミュニケーションを促進させることを研究目的とする。

このような目的を達成するために、本研究では以下の三つの課題に取り組む。

- (1) 人の行動情報を取得する IoT センサデバイスの開発
- (2) センサデータの抽象化による「気配」の抽出
- (3) 「気配」の共有によるコミュニケーション誘発

まず、人の行動をセンシングする IoT センサデバイスの開発を行う。これは、様々なセンサを搭載したデバイスであり、センサデータを収集し、収集されたデータを WiFi 経由でクラウ

ドに送信する機能を持つものである。図 1 は、開発した IoT センサデバイスのプロトタイプシステムの外観を表している。

センサからは、人の様々な行動を表すデータが取得できる。しかし、そのような生のセンサデータは、プライバシー情報そのものであり、家族といえども共有したいとは思えないものである。そこで、生のセンサデータから、家族と共有してもよい程度のちょうどいい粒度に情報の抽象化を行う。それは、同居している家族にであれば、知られても良いと思える、「気配」とも呼べる程度の粒度の抽象化であるべきだと考えている。この抽象化は、センサのストリームデータを入力とした行動の分類問題であり、機械学習技術を応用する。

最後に、得られた「気配」を、LINE のようなプライベートメッセージャーなどを通して遠隔地の家族と共有し、話題を提供することで、独居している人を主体とした話題でのコミュニケーションの促進を図る。独居している人が情報技術に疎い高齢者などであっても問題なく使えるようなアプリケーションの



図 1 IoT センサデバイスのプロトタイプシステム

デザインを行う。

2. 関連研究

本研究と関連する研究としては、センサを用いて人間の行動を監視するという研究や、主に高齢者を対象とした見守りサービスがあげられる。従来研究は、主に人間の行動を監視することに主眼が置かれている。一方、我々の研究は、センサデバイスからいかに話題提供が可能かということを主眼としている。

2.1 センサを用いた行動監視

Raykov ら [3] は、センサを用いて部屋の人数を推定する研究を行った。用いられたセンサは 1 つの人感センサ (PIR) であり、そのデータから Infinite Hidden Markov Model (iHMM) を利用した学習モデルを作成することで、人数の推定を行った。Cuddihy ら [4] は、複数の人感 (PIR) 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動作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うような応用が想定されている。Bayoumi ら [5] は、照度センサを用いて、人間の行動を監視する研究を行った。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 [6] は、センサを利用し、老人の行動を監視し、異常を知らせたり、生活の情報を伝えたりするシステムの開発を行った。多くの種類のセンサが用いられており、監視対象の老人の行動モデルを自動的に生成することを行った。Nait Aicha ら [7] は、独居老人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。Viard ら [8] は、Hidden Markov Model (HMM) を用いて、日常生活の行動を推定する研究を行った。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利用できるセンサは限られていることが多いが、精度の高いモデルを作成するためには、HMM が有用であることが報告されている。Hong ら [9] は、window energy detection (WED) と Alarm duration detection (ADD) を用いて、誤警報の削減する研究を行った。Lago ら [10] は、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ることで、センサデータから行動を認識する研究を行った。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。Eisa ら [11] は、複数の人感 (PIR) センサを用いて、日常生活で起きる異常を検出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のデータから行動を監視し、モデルが自動的に異常を発見する。

2.2 高齢者の見守りサービス

これまでも高齢者の見守りは重要な問題であると認識されており、独居高齢者を見守るための様々な取り組みやサービスが存在している。まず、自治体での取り組みとして、地域の高齢者をコミュニティとして見守るという活動が行われている場合がある。しかし、現実問題として独居高齢者が家族にいる場

合には、自治体の活動を待つしかない。そのため、一家族から始められるボトムアップ的活動が必要であると考えられる。また、電気ポットの使用やコーヒーを飲んだかといったことを遠隔地家族に知らせる商品・サービスや、高齢者に持たせた GPS の位置情報を知らせるサービスは、ボトムアップ的活動であるといえるが、これらは安否確認が主目的である。本研究では、一方的な監視ではない仕組みの構築に取り組むものであり、個人を尊重した会話をより多く生み出すことに挑戦する。

3. 行動監視の許容度

街中での監視カメラ、交通系 IC カードのログ、ポイントカードの利用履歴、Web 検索エンジンのクエリログに至るまで、現在、人々のあらゆる行動が監視され、記録される社会となっている。監視は基本的には不快なものであるといえるだろう。しかし、社会の安全などの公益や、個人的な利便性のために、我々は、監視されることを受け入れている。

スマートウォッチに代表されるスマートデバイスを用いて、自分自身の監視することも増えている。当然ながら、そこに不快感はない。そこで記録される情報は高度にプライバシーに関わる情報だが、それを管理するのが自分自身であるためである。また、個人の健康情報や、食事の履歴、運動の履歴といったプライバシー情報であっても、それを病院などに伝えることがある。これは、自分自身の健康のために受け入れているといえる。これらのことを考えると、プライバシー情報の共有においては、どの程度の粒度の個人のプライバシー情報をだれが管理するかということが重要な観点となる。

本研究では、自分から少しだけ外側の存在である家族に着目し、家族であれば共有することを許せるプライバシー情報の存在に焦点を当てて研究を行う。

人間の行動を監視する手法には様々なものが存在している。それらの中から、本研究の目的と合致する手法を選択するにあたって、システム全体の設計方針について説明する。

遠隔地家族にとって、独居している人がどのような生活をしているかを知る術は限られている。結果として話をすることがないということが本研究の問題意識である。独居している人の生活を知るためには、カメラを設置したり、見守り電気ポットのような見守りサービスを利用したりすることが考えられるが、これらは家族に監視されることであり、抵抗を感じる人が多いだろう。

機械的に詳細なセンサデータなどのプライバシー情報が遠隔地家族に伝えられることには抵抗を覚えるが、たとえば、「今日は夕方からテレビをみて盛り上がっていた」というような比較的抽象度の高い情報であれば、家族とであれば共有してもよい場合があると考えられる。そして、この情報を得た家族にとっては、「きっと阪神タイガースの試合を見ていたのだろう」というような理解につながり、「電話して一緒に阪神のことを話そう」という会話のきっかけになると考えられる。このように、ある程度抽象度が高く、監視とまでは言えないが、家族にとっては話題を得られる情報を本研究では「気配」と呼ぶ。同居していればなんとなく分かる程度の「気配」を感じし、それを遠




図 2 Arduino UNO R3 (左) と ESP32 (右)

表 1 マイクロコントローラの比較

マイクロコントローラ	ESP32	Arduino UNO R3
コア数	2	1
アーキテクチャ	32 Bit	8 Bit
CPU クロック周波数	160 MHz	16 MHz
Wi-Fi	YES	NO
RAM	512KB	2KB
GPIO ピン数	36	14
ADC ピン数	18	6
DAC ピン数	2	0

隔地家族とプライベートメッセンジャーなどを通して共有するというには、家族によって程度の違いはあれども、いくらか受容可能な範囲が存在すると考えられる。

4. 行動情報を取得する IoT センサデバイス

本研究では、まず、独居する家族の行動に関する様々なデータを取得するためのデバイスの開発を行った。本節では、まず、提案デバイスの設計方針について説明する。その後、提案デバイスに搭載されたセンサなどについて詳しく説明する。さらに、どのようなデータが取得し、そのデータをどのように送信するかということについて説明する。

4.1 マイクロコントローラとネットワーク

まず、IoT センサデバイスの制御を行うマイクロコントローラについて説明する。使用するマイクロコントローラの候補として、Arduino Uno R3 と ESP32 を検討した。図 2 は Arduino UNO R3 と ESP32 の実物の写真である。

Arduino Uno R3 は、初学者でも使いこなしやすい、便利なマイクロコントローラである。開発環境が用意されており、C++ をベースとした言語でプログラミングを行うことができる。数多くのライブラリが用意されており、様々なことを容易に実装することが可能である。多くの電子素子について、ウェブ上に Arduino で動作させる例を見つけることが可能であることも特徴である。

ESP32 は、Wi-Fi モジュールを搭載したマイクロコントローラである。日本を含む各国で使用可能な Wi-Fi モジュールであり、Arduino の開発環境をそのまま利用することも可能である。ライブラリの多くもそのまま利用することが可能である。

表 1 では、それぞれのマイクロコントローラの性能の比較を行っている。本研究では、初期段階において Arduino UNO R3 を用いてプロトタイプシステムを作成していたが、最終的には ESP32 を採用することとした。決め手となったのは、以下の 3 点である。

- ESP32 には Wi-Fi モジュールがついており、Wi-Fi 環

境さえあれば単体でインターネットへの接続が可能である。

- ESP32 の方が小型である。
- ESP32 の方が安価である。
- ESP32 の方が CPU 性能が優れている。

ESP32 の付属の Wi-Fi を利用することで、直接インターネット接続を行う。当然ながら、別途、Wi-Fi 環境が必要となるが、それは独居する人の自宅に用意されていることを前提とした。

後で説明するが、現在は、センサデータを 6 秒ごとにクラウドサービスに出力している。そこで蓄積されたデータを解析することで「気配」の抽出を行う。

クラウドサービスへのデータ送信は常時行っているわけではなく、デバイスの消費電力は比較的小さい。ESP32 自体の消費電力も大きくはなく、数日程度であればモバイルバッテリーなどで動作させることも可能である。

4.2 センサ群

本研究では、多様なセンサを利用する。それらのセンサからは、人間の行動による環境の変化を取得するが、それ以外に自然現象による環境の変化も取得する。それぞれのセンサについて以下で説明する。

- 人感センサ

人感 (PIR) センサはしばしば防犯アラームのために利用されるセンサである。このセンサは赤外線を使って人などの動きを判断する。出力はデジタルで、1 か 0 である。赤外線の環境に変化があった場合には、決められた検知出力保持時間の間、ずっと 1 を出力するというように動作する。本研究では、検知出力保持時間を約 5 秒間と設定している。




- 音圧センサ

いわゆるマイクである。センサが得た音圧を計測することができる。周波数範囲は 50Hz から 16kHz のものを利用している。ただし、音声を認識することを目的としていないため、実際にはサンプリングレートは非常に低いようにしており、センサデータとしては 6 秒間に得られたすべてのサンプルの分散値をその時の音圧の代表値として送信している。



- 温度・湿度・気圧センサ

これは BME280 チップを使用したセンサであり、温度、湿度、気圧をそれぞれ別々に取得することが可能である。マイクロコントローラとの通信は、I2C か SPI で行うことができる。本研究では I2C を利用している。測定範囲と精度は以下の通りである。



- 温度: $-40 \sim +85^{\circ}\text{C}$
- 湿度: $0 \sim 100\%$, $\pm 3\%$

— 気圧：300～1100hPa, ± 1hPa

● 照度センサ

照度センサは人間の視感度特性に近いアナログセンサのことである。フォトトランジスタと抵抗によって構成される。フォトトランジスタは、可視光を受光すると抵抗が低くなるという特性を持つ電子素子である。写真は今回利用したフォトトランジスタである。適当な固定抵抗を用いて、暗くなると 0 を出力し、明るくなると大きな値を出力するように回路を作成した。

● 赤外線リモコンセンサ

このセンサはテレビやエアコンなどのリモコンが出力する、38KHz で変調した赤外線のみを受信するセンサである。全体としてはデジタルセンサとして動作し、受光している時は 1 を、受光していないときには 0 を出力する。プログラムである程度のサンプリングレートでデータを取得することによって、たとえば、テレビがどのチャンネルに変えられたかや、エアコンの設定がどのようになっているかといったことも取得することが可能になる。

これらのセンサ以外に、初期のプロトタイプシステムでは測距センサを利用していたが、実際の運用においてノイズが大きかったため、利用しないこととした。

4.3 三脚マウントと電源

IoT センサデバイスは、部屋に固定して設置して利用する。様々な場所に配置できるようにするための工夫として、三脚にマウントできるようにしている。図 1 の左図は、ポータブル三脚に固定している様子を表している。

電源は、5V の電源を ESP32 に供給する必要がある。一般的な USB 充電器などを利用することができるよう、Micro USB Micro-B のメス端子を搭載しており、USB ケーブル経由で電源供給を行う。

4.4 クラウドにおけるデータ収集

IoT センサデバイスからのデータはクラウドサービスである Ambient^(注1) 上で蓄積した。Ambient は IoT データを蓄積したり、蓄積された IoT データの可視化を行うことができるサービスである。

Ambient では送信したセンサデータが「チャンネル」という単位で管理されている。1 つのチャンネルには 8 種類までのデータを送信することができる。チャンネルは複数生成することが可能である。今回は、1 つの IoT センサデバイスに対して、1 つのチャンネルを利用する。

Ambient では最短で 5 秒ごとにデータを送信することが可能である。また、一日あたりに送信できるデータの数 3,000 件




図 3 D3 の場所（研究室）の間取り

であるという制約が存在している。現在は、予備実験中ということで、我々が作成した IoT センサデバイスから、6 秒ごとにデータを送信するように設定しており、その結果として、データを送信できる時間が一日当たり 5 時間という制約を受けている。

Ambient では、データが 1 年間保存される。1 年を越えたデータは自動的に削除されていく。Ambient からデータをダウンロードできる機能があるため、ラベル付けなど、実験のためにデータをダウンロードしている。

今後、実環境で動作させる場合には、Ambient と同様のサービスを自らホストするといったことが必要になると考えられる。

5. 予備実験環境

本研究では、IoT センサデバイスを独居する人の家に設置し、遠隔地に住む家族にそこから得られた情報を伝えるということを目指しているが、そのような実環境での実験の前に、予備実験環境における開発を進めている。本節では、予備実験環境について説明する。

予備実験は、異なる 3 カ所において実施している。それぞれの場所を D1、D2、D3 とラベル付けすることとする。表 2 はそれぞれの場所の環境についての情報を表している。3 つの場所はそれぞれ広さや使われ方が異なる空間である。各場所において、開発した IoT センサデバイスを 2 つずつ設置した。

● D1

D1 は第 1 著者の自宅である。環境はワンルームであり、一人暮らし（独居）している。データを取得する時間帯は、部屋にいる時間帯である夕方から夜中までの 5 時間とした。

● D2

D2 は第 5 著者の勤務先の居室である。約 20 平方メートルの部屋であり、一人だけが勤務している。D1 とは異なり、ほぼ毎日ある程度の来客がみられる。データを取得する時間帯は、昼間の 5 時間とした。

● D3

D3 は第 1 著者の所属する研究室である。約 30 平方メートルの部屋であり、所属する学生など、8 名程度が出入りする。データを取得する時間帯は、昼間の 5 時間とした。図 3 は、この部屋の間取りを表している。

予備実験はこれら 3 つの部屋で通常通りに人が過ごしている中で、IoT センサデバイスを設置して行った。先述したとおり、

(注1) : Ambient : <https://ambidata.io>

表 2 予備実験を行った環境について

場所名	部屋の利用人数	部屋数	センサデバイス数	観察日数	一日あたりの観察時間
D1	1	1	2	2	5
D2	1	1	2	2	5
D3	8	1	2	20	5

これらの部屋にはそれぞれ2つずつのデバイスを固定して設置した。その設置場所については試行錯誤しながら検討した結果、どの場所においても、1つは入り口付近設置し、もう1つはある程度部屋の奥からできるだけ広い範囲を見渡せるような位置に設置した。たとえば、D3においては、図3で赤丸で示されているように、ドアの近くと、部屋の中央付近のテーブルの上に設置した。このように配置することによって、部屋全体での人の行動をデバイスのセンサでカバーできることが分かった。

また、人間の行動の正解ラベルを作成するために、それぞれの部屋において、データを取得している間はビデオカメラを設置して撮影を行った。図3で示されているように、部屋全体が撮影できるように配置した。

6. 実験

本節では、実際に行った実験について説明する。

まず、D1のデータを用いて実験を行おうとした。D1は第1著者の自宅のデータであるが、データを取得している間に取った行動があまり多くなかったため、検証可能な行動ラベルの種類があまり存在しなかった。また、D2も同様に、データの量が少なかった。そこで、実験はD3のデータを利用して行うこととした。

D3における6日間のデータに行動ラベルを付与し、そのラベルについて、機械学習による予測を行った。結果の概要としては、毎日のように行う行動については、予測精度が良かった。しかし、一方で、たとえば曜日によって異なるような行動については、予測精度が低かった。D3データセットで付与したラベルは、他のデータセットとは異なるものである。D3は研究室という環境におけるデータなので、sleeping, walkingなどのラベルは付与されず、たとえば、発表や、議論といったラベルを付与した。

研究室には人が多い環境であるため、取得したデータから学習させたモデルを独居する人のためには使えないような行動ラベルもあると考えられる。しかし、二つの理由から、実験行う意義があると考えている。

一つ目は、人数が多いときどう反応をするかを調べることができるということである。来客が訪れることが滅多にない第1著者の自宅でのデータでは、来客時のデータが得られないが、D3のデータからはそのようなデータを取得することが可能である。

二つ目は、複数人の行動がどの程度正確に認識できるかを実験して、確かめるためである。行動が少ない第1著者の自宅でのデータであるD1とは異なり、D3は誰もいない場合もあるし、数人が一度に違う行動を行っている場合もある。

実験では、機械学習モデルとして、サポートベクターマシン

(SVM)と、k近傍法(KNN)の二種類を用いた。パラメータチューニングためには、交差検証をもってグリッドサーチを行うライブラリを用いた。交差検証においてデータ分割の数は5とした。パラメータについてまとめると以下の通りである。

- SVMのパラメータ
 - カーネル: {linear, RBF}
 - RBFカーネルにおける γ : {0.1, 0.01, 0.001, 0.0001}
 - C : {1, 10, 100, 1000}
- kNNのパラメータ
 - k : {1, 2, 3, 4, ..., 40}

インバランスデータであったため、トレーニングデータのアンダーサンプリングを行った。アンダーサンプリングはPythonで記述されたClusterCentroidsライブラリ^(注2)を利用した。予備実験における精度はSVMとkNNであまり違いがなかったが、kNNよりもSVMの方が高速であった。そのため、以後ではSVMを分類器として用いて実験を行うこととした。

人の行動を予測するのは非常に難しいタスクであるといえる。たとえば、人の行動は原則として毎日異なり、また、曜日によって類似するようなものもあれば、そうでないものもある。今日行った行動を、明日も行うとは限らない。今回取得したデータにおいても、行動には日によってかなりのばらつきが見られた。曜日によってはある行動ラベルがよく現れ、また、逆に、ある行動ラベルは全く現れなかった。全体的な結果としては、学習モデルによる推定精度は低いものであった。訓練データとテストデータに分けるとときには、同じ日のデータが混ざらないように行った。そのため、訓練データではあまり（もしくは全く）現れない行動ラベルがテストデータに現れることもあり、そのような場合は当然ながら精度が低くなった。この状態では、アンダーサンプリングを行っても、精度向上は見込めない。

訓練データとテストデータに分けるとときには、同じ日のデータが混ざらないように行った理由は、センサのデータは6秒ごとと取れているため、ほとんど同じタイミングのデータが、訓練データとテストデータの両方に存在するということが起こってしまうことを避けるためである。

あるラベルの結果はあまりにも低かった。一方、あるラベルの結果で、ある程度行動を予測できそうであった。たとえば、music onという行動ラベルは部屋で音楽流している場合に1とするラベルである。このラベルの場合が1であることを予測する問題において、適合率は0.85、再現率は0.74、f1は0.79であった。表3では、それぞれの行動ラベルの結果を表示している。

本研究で行った実験で、予測できる行動があれば、予測する

(注2): imbalanced-learn: <https://imbalanced-learn.readthedocs.io/>

表 3 実験結果

行動ラベル	適合率	再現率	f1
音楽オン	0.85	0.74	0.79
議論	1.00	0.56	0.72
発表	1.00	0.54	0.70
研究会	0.37	0.48	0.42
食事	0.25	0.13	0.36
料理	0.13	0.18	0.15
お喋り	1.00	0.01	0.02




図 4 温度センサの経過を表すグラフ




図 5 照度センサの経過を表すグラフ




図 6 音圧センサの経過を表すグラフ




図 7 人感センサの経過を表すグラフ

のは難しい行動もあった。予測できた行動からだけでもある話題を提供できると考えられる。

7. センサデータからの行動抽出

本節では、取得されたセンサデータから、人の行動を判別する手法について説明する。

7.1 取得されたデータ

ここでは、まず、実際に IoT センサデバイスから取得されたデータの例を提示する。これらのデータは、D3 の場所から得られたデータである。それぞれの種類のセンサのデータが時系列でどのように変化したかが分かる。なお、デバイスが 2 つあるため、それぞれのセンサについて 2 つのグラフを提示する。

図 4 は、温度センサの変化状況を示している。図 5 は、照度センサの変化状況を示している。図 6 は、音圧センサの変化状

況を示している。図 7 は、人感センサの変化状況を示している。それぞれ、11 時ごろから 16 時ごろまでの約 5 時間のデータを表している。左のグラフがドアの近くのデバイスから得られたデータであり、右のグラフが部屋の中央付近のテーブルの上のデバイスから得られたデータである。

このように可視化されたグラフを少し観察することから、様々な人間の行動の推測を行うことが可能であろう。

たとえば、温度センサのグラフをみても、13 時になる直前に温度が急に上がっていることがわかる。エアコンはこのような温度変化を起こすとは考えにくい。エアコンではない、センサ近くにある熱を発生する機械が動作しているということが予測される。実際、その時間に何が行われていたかをビデオ映像で観察したところ、プリンタが連続的に利用されていたということが分かった。

次に、13 時までの人感センサのグラフを観察してみると、動きが多く検出されていることが分かる。同時に、音圧センサも明らかに音を感知しており、誰かが話をしているという推測ができる。音圧センサの 2 つのグラフは、あまり違いが見られない。しかし、一方で、人感センサの 2 つのグラフは違いが見られ、部屋の中央付近のテーブルの上のデバイスの方が多くの反応が見られた。昼食の時間帯で、テーブル付近で学生たちが話をしたり食事をしていたりしたからであった。

13 時以降のグラフをみると、気温が徐々に下がっていることがわかる。また、照度センサの値が低くなっていることがわかる。さらに、人感センサにも反応が見られない。これは、部屋が留守で、誰もいないということが推測できる。この時間帯には、別の教室で行われていた研究会に参加するために全員移動していた。14 時を過ぎたあたりで、人感センサと音圧センサに反応がみられる。これは、誰かが研究室に入ってきたと考えられる。しかし、温度センサや照度センサにはあまり変化が見られない。このときには、ある一名の学生が荷物を取るために部屋にきたのであった。

このようなセンサデータからの人間の行動の認識を、自動的に行うことが必要となる。そのため、センサデータに対して、人間の行動のラベル付けを行った。ラベル付けは、ビデオ映像を見ながら行った。

ラベル付けは、6 秒ごとに蓄積されているデータのそれぞれに対して行った。ラベルとしては行動を表す動詞を用いた。たとえば、enter, exit, walking, moving, talking, cooking などである。1 つ以上の行動を同時に取っている場合は、複数のラベルをつけることとした。たとえば、話ながら歩いている場合には、moving と talking という 2 つのラベルを付与した。図 8 は、実際にラベル付けを行ったデータの一部を表している。

このようにラベル付けされたデータを基にして、センサデータをストリームデータとみなして、Hidden Markov Model を利用して学習を行う。Hidden Markov Model は、従来研究でも広く用いられており、人間の行動を推定するために有効なモデルであるとされている。

1	created	Temperat	Pressure	Humidity	pho	tr	an	piR	mic	remcon	Rabin	
416	2018-12-2	18.26	1017.21	58.52	0	0	267	0	sitting			
417	2018-12-2	18.26	1017.15	58.54	0	1	266	0	lightOn/moving			
418	2018-12-2	18.26	1017.2	58.5	81	1	219	0	cookingStart			
419	2018-12-2	18.27	1017.15	58.61	192	0	295	0	airConOn			
420	2018-12-2	18.26	1017.16	58.56	187	0	245	0	walking			
421	2018-12-2	18.26	1017.14	58.61	24	0	303	0	walking			
422	2018-12-2	18.28	1017.16	58.58	22	1	264	0	walking			
423	2018-12-2	18.29	1017.16	58.59	171	0	330	1	musicOn			
424	2018-12-2	18.28	1017.16	58.47	85	1	295	0	walking			
425	2018-12-2	18.29	1017.16	58.52	278	1	295	0	walking			
426	2018-12-2	18.29	1017.21	58.57	254	1	297	0	walking			
427	2018-12-2	18.29	1017.14	58.64	113	1	249	0	walking			
428	2018-12-2	18.28	1017.18	58.62	64	0	254	0	walking			
429	2018-12-2	18.28	1017.12	58.55	292	0	280	0	walking			
430	2018-12-2	18.29	1017.15	58.54	70	0	258	0	walking			
431	2018-12-2	18.28	1017.17	58.53	324	0	249	0	walking			

図 8 ラベル付けされたデータの一部

8. 推定された行動を基にした話題生成

本節では、センサデータから推定された人の行動から、どのような話題を提供することができるかについて検討する。

人の日常生活にはパターンが存在している。人は毎日全く同じ行動を行うわけではないが、ある程度パターンは存在すると考えられる。そのパターンは、ある程度長期間にわたって行動を観測すると得ることができると考えられる。そのようなパターンが得られた後に、どのような話題の生成を行うことができるか考える。理想の出力として、どのようなケースが存在するかを検討した。以下で、本研究で開発した IoT センサデバイスを用いて、実現可能と考えられるいくつかのケースについて述べる。

事例 1 推定された日常生活の行動パターンは、夜 10 時を過ぎたら寝るというものである。それは、夜 10 時を過ぎたら電気が消え、照度センサの値が低くなり、人感センサにも反応がないというパターンが頻出することから得られる。数日間観測を継続すると、日常のパターンとは異なるパターンが表れ、たとえば、夜遅くまで起きているという行動が想定できる。この行動の理由としては、以下のようなものが想定される。

理由 1：病気 照度センサと人感センサが夜中にトイレで何度も反応したとする。これは夜遅くに何回もトイレに行くことを示している。普段は夜遅くに何度もトイレに行くというパターンが見られない場合、夜中に何回もトイレに行くのは「体調がわるいかもしれない」という話題になると考えられる。

理由 2：番組 人感センサと照度センサと共にリモコンセンサとマイクセンサが夜中に部屋で反応したとする。この事例の出力はテレビを夜中に見ていることを示している。普段このような反応がないとすると、興味のある番組が夜中に始まったか、寝られないからテレビを見ているということが想定される。しかし、どちらが原因かを遡することはこれだけの情報では不可能である。たとえば、「夜中にテレビを見ていました」という情報を提供すると、遠隔地に住む家族は「興味がある番組があったの？寝られないの？」といった問いかけができるようになると考えられる。

理由 3：心配、悩み 上記の「病気」や「番組」以外のパターンで夜中に何らかの行動パターンがみられるとする。この場合は、具体的な行動を推測することが困難な場合もすくなくない。しかし少なくとも、夜遅くまで起きていることはセンサのデー

タから推定出来る。普段このようなパターンが見られない場合、独居家族がなんらかの理由で眠れない場合が想定できる。独居家族が眠れない理由として心配しているとか、悩み事あるなどが考えられる。したがって、「よくわからないけど夜遅く起きているようです」といった情報を提供することで、遠隔地に住む家族は「悩み事でもあるの？」といった問いかけができるようになると考えられる。

このほかにも以下のような事例が考えられる。

事例 2 起床時間に関してのパターンをみる。日常のパターンより起床する時間が遅いあるいは早い場合、睡眠時間が短くなっているか、早朝に何かをし始めたかと推測できる。たとえば、起床後に家を出て、1～2 時間後に帰ってくるパターンではジョギングを始めたといったことが想定できるだろう。したがって、「なにか早朝に頑張っているようですよ」と遠隔地に住む家族が励ましてみようかと思うような話題を提供できるだろう。

事例 3 長期間不在のパターンをみる。IoT センサデバイスのデータが留守を示しているとする場合である。長い間家にいないというのは病気による入院などや、旅行の可能性が想定される。それを確かめるため、「長期で不在のようですよ」と情報提供することで、その理由を探ってみようかと思える話題を提供できると考えられる。

事例 4 独居している人の自宅が温かいかなんかは、天気予報などからは十分にわからないことが多い。自分が住んでいる町はまだ暖かいにもかかわらず、独居する家族のところはかなり寒くなっている可能性がある。急に気温が下がっていたり、あるいは上がっている場合、「こちらよりも急に寒くなっています」などと情報提供することで、電話などで、「気をつけて」とを伝えることを促すことができる。

他にも、たとえば、梅雨の日は湿度が高く、湿度センサの値が大きくなる。長い間雨が続いたら、気がめいったり、病気になる可能性が高くなることが想定される。そのようなときには、「ここ最近じめじめしているようです」などと情報提供し、食生活に注意したり、風邪ひかないよう注意したりするよう促すことができるだろう。

事例 5 部屋に複数人いるパターンが見られたとする。部屋に一人だけいるか、来客もいるかは判別可能であると考えられる。来客があったことを情報提供することで、誰が来たかを尋ねようと思ったり、どのような話をしたかを問いかけたりするきっかけになると考えられる。

事例 6 長い間同じパターンを繰り返していると IoT センサデバイスが示す場合もあるだろう。そのような場合は、生活に新しい展開がないことを示している。そのような場合であっても、新しいことがないことを提示することで、遠隔地に住む家族に、もっと会話を増やすことを促したり、一緒に出掛けることを促したりすることができると考えられる。

異常がある場合だけでなく、通常パターンが続く場合でも話題提供は必要であり、事例 6 のような話題を提供することが必要である。本研究の目的は独居家族と家族が話さきっかけの話題を提供し、家族間のコミュニケーションを促進することである。状況により同じ話題でも会話がはずんだり、あまり会話に

つながらなかったりはある可能性があるものの、総じて家族間のコミュニケーションを促進させることはできると思われる。上記のように提供される話題を通じて、遠隔地に住む家族間のコミュニケーションが促進され、家族間の距離感を縮めることができる」と期待できる。

9. まとめと今後の課題

本研究では、独居している家族の行動情報を IoT センサデバイスを用いて取得し、遠隔地にいる家族とのコミュニケーションを促進させる話題提供を行う仕組みを提案した。様々なセンサ、たとえば、人感センサ、照度センサなどを取り組んだ IoT センサデバイスの開発を行い、それを用いて人間の行動をセンサデータとして記録する。そのセンサデータを Hidden Markov Model モデルに学習させ、抽象化された情報を出力することを行う。独居している人の行動を取得して、変化や異常があった場合に家族に知らせる。それをうまく行うことによって、コミュニケーションのきっかけになると考えられる。

今後は、距離センサなどの現在利用していないセンサの利用を検討し、人間の行動をより精密に推測することを目指す。

機械学習でより良い行動推定を行うためには、膨大なデータが必要である。今は一日のうちで 5 時間という限定された時間のデータを使用しているが、今後は 24 時間のデータを取りたいと考えている。一日全体のデータが取れれば、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、行動推定の実装を進め、実際に話題を提供してコミュニケーション促進につながることを実証実験を通して検証していく予定である。

謝 辞

本研究の一部は JSPS 科学研究費助成事業 JP16H02906, JP17H00762, JP18H03494, 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。

文 献

- [1] 国立社会保障・人口問題研究所, “日本の世帯数の将来推計（全国推計）（2018（平成 30）年推計）,” 人口問題研究資料第 339 号, 2018.
- [2] 内閣府, “平成 30 年版高齢社会白書,” 2018.
- [3] 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.
- [4] 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.
- [5] 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.
- [6] A. Bamis, D. Lymberopoulos, T. Teixeira, and A. Savvides, “Towards precision monitoring of elders for providing assis-

tive services,” Proceedings of the 1st International Conference on Pervasive Technologies Related to Assistive Environments, pp.49:1–49:8, 2008.

- [7] A. Nait Aicha, G. Englebienne, and B. Kröse, “Unsupervised visit detection in smart homes,” Pervasive Mob. Comput., vol.34, no.C, pp.157–167, 2017.
- [8] 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 (IUCC-CSS), pp.85–92, 2016.
- [9] 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.
- [10] 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.
- [11] S. Eisa and A. Moreira, “A behaviour monitoring system (bms) for ambient assisted living,” Sensors, vol.17, no.9:1946, pp.1–24, 2017.