

# 介護施設における介護スタッフの行動センシング実験

井上 創造<sup>1,a)</sup> 木村 幸平<sup>2,b)</sup> 内野 百里<sup>1,c)</sup> 大屋 誠<sup>2,d)</sup>

## 概要 :

本稿では、30人規模の介護士・看護師スタッフを持つ介護施設において、スタッフの行動センシング実験を2ヶ月半程度行った実験を述べる。スタッフ27名に対して20種類の行動を自分でスマートフォンにラベル付けをしてもらいながら、スマートフォンおよび携帯センサにおいて加速度を中心とするセンサデータを取得した。また、各部屋のベッドサイドなどにも赤外線温度などのセンサを設置し、そこから得られるIDやセンサデータをBluetooth LEプロトコルでスマートフォンで取得し、スマートフォンのセンサデータと合わせてクラウド上にあるサーバに保存した。これらの実験と得られたデータの概要と、行動認識の試みについて述べる。

キーワード：人間行動認識，介護施設，行動センシング，Internet of Things

## Experiment of Caregiving Activity Sensing in a Nursing Facility

SOZO INOUE<sup>1,a)</sup> KOHEI KIMURA<sup>2,b)</sup> YURI UCHINO<sup>1,c)</sup> MAKOTO OYA<sup>2,d)</sup>

### Abstract:

In this paper, we describe the 2.5-month experiment in a nursing facility of for elders with about 30 staffs aiming at obtaining sensor data and applying human activity recognition. We asked 27 staff to attach smartphone sensors and mobile sensors, attach the same sensors to each resident's room, and asked the staff to record activity labels with a smartphone app. The sensor data are sent to the cloud system through the smartphones, and applied activity recognition. We introduce the overview of the system and the experiment, and show the result of the activity recognition.

**Keywords:** Human activity recognition, nursing facility, caregiving, activity sensing, internet of things

## 1. はじめに

日本では今後、少子高齢化が進み、労働人口が減少する一方、必要となる介護職員数は増加する。厚生労働省によると、2025年には介護人材が253万人必要なのに対して、供給見込みは215.2万人にとどまり、37.7万人の不足となる

る[8]。介護人材を増やそうとしても、生産人口が減少して、かつ賃金を上げにくい介護保険制度においては、成り手も少ない。そのための対策の一つとして、情報技術を活用した介護業務の効率化が期待される[8]。

ユビキタスコンピューティングの分野では、スマートフォンを始めとする携帯センサを用いた人間の行動認識技術の研究が行われてきた[7]。この技術を介護行動の認識に応用すれば、介護業務やその記録を自動的に作成でき、現場で行われているケア記録や業務記録といった業務を効率化できるはずである。また本人がその記録を可視化して振り返ることにより、業務改善の材料にも用いることができる。

<sup>1</sup> 九州工業大学  
Kyushu Institute of Technology

<sup>2</sup> 株式会社 IDC フロンティア  
IDC Frontier Inc.

a) sozo@mns.kyutech.ac.jp

b) k.kimura@idcf.jp

c) uchino@sozolah.jp

d) moya@idcf.jp

ただ、行動認識の研究はたくさん行われてきたが、行動認識はデータから機械学習によりアルゴリズムを生成する方法が主流であるため、応用ドメインに特化する場合にそれに合わせたデータの収集が必要になる。看護師の行動認識に関する研究はいくつかある [6][1][5] が、介護施設におけるスタッフの行動認識の研究は我々が知る限りまだ無い。

本研究では、27人の介護士および看護師スタッフを持つ介護付き有料老人ホームにて、スタッフおよび環境のセンシングを約2ヶ月半に渡って行い、同時にスタッフから行動認識の教師データとなりうる行動ラベルを取得した。その際には BluetoothLE によるセンサデバイスを環境及びスタッフに取り付け、そこから複数種のセンサデータを取得した。同時にスマートフォンを持ってもらい、スマートフォン内部のセンサデータと合わせてクラウドサーバにデータを送信し、データの保存及び行動認識を適用した。

本論文では、この実験のための介護施設センシングシステムについて述べ、実験の内容や運用で得られた知見、得られたデータを示す。実験の当初は種々の不具合によって安定したデータが取れなかったが、後半では安定してデータが取得できた。

更に、得られたデータから行動認識手法を機械学習によって生成し、その精度を示す。適用した手法は一日の中での行動のセグメント、つまり行動の開始時刻と継続時間の推定に優れた手法 [4] であり、特に継続時間の推定に高い精度が得られた。

## 2. 介護施設センシングシステム

本節では、介護施設のスタッフ及び居室をセンシングし、データをクラウドサーバに送り行動認識を行うシステムについて述べる。本システムのソフトウェアは文献 [3] で使用した EneAct システムの改良である。

本実験で構築したデータフローを図 1 に示す。スタッフタグと環境タグは BluetoothLE 通信により、スタッフが携帯しているスマートフォンにデータを送信する。スマートフォンは介護施設に置かれた WiFi ルータ経由でクラウド側にデータを送り、クラウドサービスは認証とデータの整形を行って TreasureData にデータを格納する。また、スタッフが入力した aTimeLogger の行動ラベルデータは定期的にスマートフォンから aTimeLogger サーバの Web 機能と同期され、API 経由で TreasureData に取得する。集積したセンサデータと行動ラベルデータを行動認識に使用する。

### 2.1 センサデバイス

本実験ではセンシング用デバイスとして、テキサスインスツルメンツ社の SimpleLink SensorTag CC2650STK\*1 を使

表 1 センサデータの取得頻度

固有 ID	1 秒に 1 回
温度	5 秒に 1 回
湿度	5 秒に 1 回
気圧	5 秒に 1 回
加速度	1 秒に 10 回

用した。10種のセンサ種を内蔵し、Bluetooth Low Energy (BluetoothLE) 規格によるスマートフォンとの通信が可能である。今回は表 1 に示すセンサ種を用いた。

このセンサデバイスは、スタッフにバッジのように胸につけてもらう物（以下、スタッフセンサ）と、入居者のベッド横に貼り付けて居室の状況をセンシングしながらスマートフォンに対して固有 ID を送信する物（以下、環境センサ）の 2 つの用途に使用した。

この 2 つの用途それぞれに合うように、センサデバイスのソフトウェアに次のように変更を加えた。

環境センサについては、気圧、地磁気、加速度センサについては固定された状態ではほとんど変化しないと考えられるため、これらを無効化した。また、夜間に LED が点灯すると不快感を与える可能性があるため、スタッフの持つスマートフォンと接続されたときのみ点滅するように変更した。また、なるべくスタッフが部屋にいるときに固有 ID を取得できるように、出力強度を中程度に変更した。

スタッフセンサについては特別な変更を加えていないが、両方のセンサにおいて、一定時間 BluetoothLE 通信の接続が切られてもスリープモードに移行しないようにすることで、一旦スタッフと離れても再接続することができるように変更を加えた。

SensorTag から取得するデータはセンサによって頻度が異なる。取得頻度を表 1 に示す。

### 2.2 スマートフォン用アプリ

本実験ではスタッフにスマートフォンを持ち歩いてもらい、スマートフォン内のセンサデータを取得しながらセンサデバイスからのデータをクラウド上のサーバに中継するようにした。

そのための Android アプリは、以下のような機能を持つ。

- (1) スマートフォン本体のセンサからデータを取得する機能: スマートフォン内のセンサから選択的にデータを取得し、下記の流れによってサーバにアップロードするようにした。
- (2) センサデバイスから ID を取得する機能: センサデバイスは、スマートフォンに接続してセンサデータを送出するが、接続していないときでも固有 ID を定期的に出して広報する機能を持つ。特に環境センサについては固有 ID は、スマートフォンを持つ人の場所の情報と捉えることができる。この ID を取得し、保存、アップロードするようにした。

\*1 <http://www.tij.co.jp/tool/jp/cc2650stk>

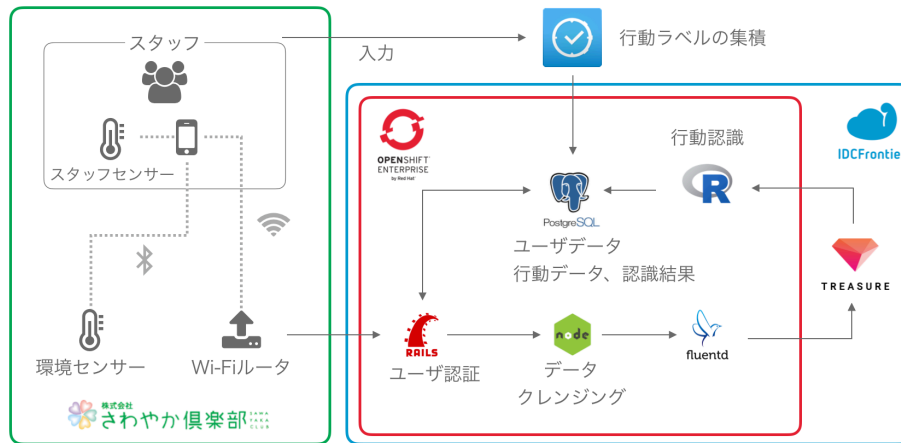


図 1 センサデータ取得からクラウドサーバでの処理までのデータフロー

- (3) センサデバイスから ID を取得する機能: センサデバイスには、固有 ID を取得した後に保有するセンサ種毎に、スマートフォンから接続してデータを取得できる。このため、選択したセンサ種に対して接続を行い、センサデータを取得する機能を付加した。この際に、上記の固有 ID 取得と、複数のセンサデバイスの複数のセンサ種からのデータを同時並行的に取得できることが望ましい。このために、マルチスレッドを駆使して可能な限りのデータを取得できるように工夫した。
- (4) クラウドサーバへの自動ログイン機能: 利用者認証は後述の Web システムに HTTPS プロトコルによって行い、一度ログインした後はアプリのクッキーおよびファイルにセッション情報を保存しておくことで、次回起動時にも自動的にログインできるようにした。
- (5) センサデータを安全にバッファする機能: 利用者が別のアプリを使っている、画面を消している、データ収集を続けるため、センシング中はバックグラウンド実行状態に入り、動作を続けるようにする。また、不意にアプリが停止したり、端末を再起動しても、自動的にアプリが起動するよう、OS の提供する API を通じて設定した。
- (6) クラウドサーバにバッファしたデータをアップロードする機能: センサデータは毎分ごとに HTTPS プロトコルでサーバにアップロードされるが、ネットワーク接続が中断してもアプリが不意に停止しても、データを紛失してはならない。また、データが何度も重複してアップロードされることも避けなければならない。このため、実行スレッドを、センシングするスレッドとサーバに送信するスレッドの 2 つに分け、前者は端末内にファイルを一分ごとに作成しながらデータを保存し、後者はそのファイルをランダムに選んでサーバに送出する。送出が成功したときのみファイルを削除する動作を、並行して実行させることにした。ただ

し、前者はセンサデバイス毎、センサ種毎にスレッドを用意し、後者は送信のスループットを上げるために 10 並列でスレッドを作動させた。

## 2.3 行動ラベル記録アプリ

スタッフに行動ラベルを記録してもらうための Android アプリとして、aTimeLogger2<sup>\*2</sup>を使用した。開始時と終了時に画面をタップすることで、行動を記録する。行動は並列または直列に行う全体の設定ができるが、今回は同時に複数の行動を行う可能性を考慮して、並列に行うことができるようにした。

行動の種類（以下、行動クラス）は事前登録が必要だが、その詳細については 3.3 節に述べる。

登録された行動クラス及び記録された行動ラベルは、同期ボタンにより aTimeLogger のサーバに保存でき、それを後から API を通じて取得することができる。

## 2.4 クラウドシステム

本節では、サーバ側でデータを保持し、行動推定およびデータ分析を行うためのクラウドサービスおよびソフトウェアについて述べる。

### 2.4.1 行動認識クラウドプラットフォーム

本実験で開発したサーバーアプリケーションは株式会社 IDC フロントニアが提供する IaaS である IDCF クラウド<sup>\*3</sup>上に構築した。これらのアプリケーションは以下のような機能を持つ。

- スマートフォンアプリの認証機能: 実験に使用するスマートフォンからのデータのみを取得するため、メールアドレスとパスワードによるユーザ管理を行い、認証されていないクライアントからのリクエストは破棄する。今回は一人が一台のスマートフォンを持つこと

\*2 <http://www.atimelogger.com>

\*3 <https://www.idcf.jp/cloud>

を想定し、一台に一つのメールアドレスを割り当てた。

- **データの受取, 整形機能:** スマートフォンクライアントから HTTPS プロトコルにおける POST メソッドでセンサデータが送られてくるのをユーザ毎, センサ種毎に受取り, 整形した上で TreasureData に出力する。蓄積するセンサデータに空のレコードが入るのを防ぐため, クライアントからアップロードされた CSV ファイルに空欄の行がある場合は削除を行い, ユーザー ID とサーバー側のタイムスタンプを追加する。
- **TreasureData へのエクスポート機能:** 整形した CSV データをデータ管理サービス TreasureData<sup>\*4</sup>に出力する。
- **行動ラベルインポート機能:** バッチ処理で aTimeLogger の API から行動ラベルのインポートを行う。このデータも TreasureData に送出する。
- **行動推定・可視化機能:** 過去の行動入力とセンサデータを訓練データとし機械学習を一日に一度行い, 一日の利用者の行動が推測される。行動認識は統計言語 R で書かれたプログラムで動作するが, このアルゴリズムの詳細については 4.2.2 節に述べる。

これら 5 種の機能は, PaaS 基盤 Openshift<sup>\*5</sup>上で, それぞれ別のコンテナで動作させた。OpenShift によりそれらのコンテナの死活監視とコンテナ間の通信制御が可能である。

本実験ではセンサデータを格納し, バッチ処理で特徴量を取得して行動認識に利用するが, このためのデータ管理サービスとして Treasure Data を利用して, 運用コストを抑えながら大量のデータを高速に集計可能にした。

### 3. 実験

2017 年 1 月 12 日-3 月 31 日の間北九州市の介護付有料老人ホームにおいてスタッフ及び入居者に事前に同意を得た上でセンシング実験を行った。

施設は 6 階建ての建物で, 1 階部分は駐車場とエントランス, 2 階部分は管理事務室となっている。2 階から 5 階には 65 室の個室があり入居者が暮らしている。各フロアには食堂, 食堂流し場, ステーション, 汚物処理室, 汚物洗濯室の共有スペースがあり, 2-4 階には浴室がある。今回は 64 名の入居者のうち実験に同意が得られた 51 名の入居者の部屋もセンシングの対象とした。

#### 3.1 実験対象

株式会社さわやか倶楽部の運営するさわやか海響館で実験を行った。本施設には職員が 34 名在籍し, そのうち介護職員 22 名, 看護職員 5 名の計 27 名の同意を取得して実験を行った。

<sup>\*4</sup> <https://www.treasuredata.com>

<sup>\*5</sup> <https://www.openshift.com>



図 2 スタッフセンサ



図 3 環境センサ

表 2 介護職員の行動クラス一覧

モーニングケア	ナイトケア	離床・臥床介助
洗面介助	口腔ケア	食事対応
食事介助	服薬介助	トイレ介助
入浴介助	バイタル確認	レクリエーション
リハビリ	外出対応	館内清掃
トイレ清掃	シーツ交換	活力朝礼
申し送り	個人記録	巡視
コール対応	休憩	利用者対応

実験期間中, 職員はスマートフォンを常時携帯し, スタッフセンサは図 2 のように身に付け, また施設内には居室のベッド横と居室以外のフロアに環境センサを図 3 のように設置してセンサデータを取得した。さらに, 職員のスマートフォンにインストールした aTimeLogger2 アプリを用いて業務の開始時と終了時にタップして行動ラベルを記録をするよう依頼し, 行動ラベルを収集した。

#### 3.2 実験機器

スマートフォンは FREETEL 社の Priori3 LTE<sup>\*6</sup>を使用した。Android OS には, BluetoothLE のライブラリが安定している, Android5.0 以上を指定した。

施設には無線 LAN などのネットワーク設備は無かったので, 各フロアに携帯データ通信と Wifi 基地局になれるモバイルルータを設置した。これではすべてのエリアをカバーすることが出来なかったが, ネットワークに繋がらなくてもスマートフォン上にセンサデータが蓄積されるのでこれによってデータが失われることはない(ただし環境センサについてスマートフォンが近くにない場合はデータが失われる)。しかし, 終業にスマートフォンを置いておく 2 階付近だけはスマートフォンとの同時接続数と帯域を増やすため, モバイルルータの下に専用の無線ルータを設置して, 夜中のうちにデータがアップロードされやすいように, 実験途中に構成を変更した。

#### 3.3 行動クラス

行動の種類つまり行動クラスは, 事前に介護施設のケア記録などの書類を見て打ち合わせた上で, 職種毎に介護職員 24 種類, 看護職員 25 種類ずつ設定した。その一覧を表 2, 3 に示す。

<sup>\*6</sup> <https://www.freetel.jp/>

表 3 看護職員の行動クラス一覧

バイタル確認	処置	物品準備, 点検
医師報告, 指示受け	医師往診, 回診対応	服薬整理
口腔ケア	食事対応	食事介助
服薬介助	トイレ介助	レクリエーション
リハビリ	外出対応	館内清掃
トイレ清掃	活力朝礼	申し送り
個人記録	巡視	コール対応
休憩	利用者対応	家族対応
担当者会		

### 3.4 実験の運用

ここでは実験の運用面について述べる。

被験者から収集したデータは毎日確認を行い、サーバ上でデータの収集状況を監視した。またプロジェクトチーム内の役割を明確にした上で連携体制を整え、不具合や問題が起きた際の現地における原因調査などを円滑に行えるようにした。実験開始後は現地を頻りに訪問し、現地スタッフとも連携しながら実験機材のメンテナンスや aTimeLogger2 アプリの行動ラベルデータをサーバに同期する作業、センサデバイスの電池交換作業などを行った。センサデバイスは事前の検証により週 1 回の頻度で交換することとし、常時データが収集できるようにした。

しかしながら、実験の初期は Android アプリやネットワーク、クラウドサーバの不具合が生じ、安定したデータ収集が難しく、開始後 2 週間で一旦実験を中断することとなった。実験を中断した 1 月 25 日から 2 月 9 日までは、行動ラベルの入力を中断し、スマートフォンを回収してソフトウェア改修を行った。実験再開後は徐々にデータ収集が可能となり、安定した運用が可能となった。

実験期間中に現場から多く聞かれた声は、行動ラベルの入力忘れであった。業務の開始時は入力できても、業務に集中していると終了時の入力が忘れがちになってしまうため、正確なデータ収集が難しくなることが懸念された。また、2 つ以上並行する業務になると、入力自体忘れてしまう傾向にあった。その防止策として、まず 30 分ごとにスマートフォンがバイブレーションを鳴らす機能を追加した。強制的に振動させることによってスマートフォンに気づく機会が増やし、入力忘れをできるだけ少なくした。また、数日に一度、過去の入力状況が可視化されたグラフを職員一人一人に配布するようにした。

### 3.5 運用後のアンケート

実験終了後、実験に参加した職員 26 名に対しアンケート調査を行った。(1 名は途中異動により実験を離脱した。) 入力したデータをユーザごと、職種ごと、フロアごと、シフトごとにまとめたグラフを見た感想をコメントしてもらった。

その結果、可視化した行動ラベルについて、「1 日の自分

の仕事の動きなどが良くわかりました。」「フロアによっては業務に差が出ているようです。」「各フロアの作業量にこんなに違いがあると思わなかった。」「日勤帯にかなりの労力が集中しています。」のように、行動ラベルをグラフ化することで業務の動き、傾向がわかるといった感想があった。可視化によって業務を客観視することができた。

また、業務改善について、「フロアのご入居者のレベル・状態を考えて人員配置が必要に思われます。」「各フロアで調整ができれば個人の負担が減るのではと思います。」など、改善点を提案する意見も多く見られた。

一方、以下のように行動ラベルの入力自体が負担に感じる職員も多数おり、問題点や課題を整理した上で、スマートフォンの操作性や入力方法を工夫するなど検討していく必要がある。また、実験機材の安全面にもより一層配慮の必要性を感じる。「押し忘れることが多かったです。時間を取られ面倒でした。」「スマホの入力がとても手間がかかりました。入力どころじゃないコール対応も多い。」「コールによる緊急性に関して押すより先に向かってました。」「トイレ介助時には手袋をするので、とても入力がめんどろでした。」「介助中にセンサが当たって危ない。」「センサを取ってしまう入居者様が多かった。」

### 3.6 システム改善

実験期間中、システムの改善の必要も多く発生し、改善を行った。

スマートフォンについては、センサデバイスに接続しながら別のセンサデバイスを同時にスキャンして接続できるよう改善した。アプリが種々のイベントで終了しても自動起動するようにした。またネットワークに一時的に接続できなくなっても、Wifi 接続やサーバログインについての自動復旧をできるようにした。データのバッファリングについてもその並列性と安定性を向上した。

クラウドサーバ側では、Treasure Data へのデータ挿入方法を工夫することで入出力速度を向上し、サーバ同時接続数も増やして安定させた。また OpenShift による仮想サービスも、異常終了時の自動復旧機能を付加した。

## 4. 分析

本節では、実験で得られたデータをレビューし、適用した行動認識とその制度について述べる。

### 4.1 データレビュー

以下では、得られたデータの概要とシステム及び実験の安定性を調べるため、

- センサデータの日毎の取得状況
- 行動ラベルの日毎の取得状況
- 行動クラスごとの行動ラベルの取得状況を可視化し、実験におけるデータ取得状況を示す。



図 4-7 は、センサデータの取得状況である。

図 4 は、スマートフォン上の加速度の日毎の収集サンプル数である。色はスタッフ（スマートフォン）の別を示す。3.4 節に示したように、後半の 3 月になってからデータ取得が安定してきていることが分かる。

以下図 5-図 7 の色については、どれもデバイスの別を示す。

図 5 は、環境センサ ID の日毎の収集数である。これも 3 月に入ってからデータが多く取れているが、日によっては収集数が少ない日も多い。これはセンサデバイスの電池を週 1 回の頻度で交換していたが、その前に無くなる場合があった事による影響が考えられる。

図 6 は、環境センサの湿度の日毎の収集サンプル数である。赤外線温度も同様の傾向であった。これも 3 月 7 日くらいから取得できているが、環境センサ ID と同様にばらつきが大きい。また、環境センサ ID と異なり、BluetoothLE の接続が確立してからデータを取得するため、環境センサ ID よりもデータ取得の難易度が高い。そのためか、取得できているデバイスとそうでないデバイスの差が大きい。

図 7 は、スタッフセンサの加速度の日毎の収集サンプル数である。気圧、湿度、赤外線温度も同様の傾向であった。これについても 3 月 1 日からデータが多く取得できているが、環境センサと同様に時々取得数が少ない日がある。これは同様にバッテリーの消費だと思われるが、スマートフォンが常に近くにある状況であるため、再接続のためのスキャンを行わなくて良い分、取得数が安定していると考えられる。

図 8 は、行動ラベルの日毎の記録数である。色は行動クラスの別を示す。行動ラベルは 1 月中は多く取れているが、これははじめのうちは入力数が多いが、中断期間の 1 月 25 日から 2 月 10 日へと記録が飛んでいる。その後は安定して入力されている。これは 2 月 10 日以降は入力に手慣れてきて、いくつかの入力しやすい行動に絞って入力したのではないかと考えられる。

図 9 は、行動クラスごとの行動ラベル記録数を示す。「トイレ介助」が突出して多く、続いて「個人記録」「巡視」「食事対応」「利用者対応」「コール対応」「食事介助」と続く。

## 4.2 行動認識

得られたセンサデータ及び行動ラベルを用いて、行動認識アルゴリズムの機械学習及びその精度評価を試みた。以下にその詳細と結果を示す。

### 4.2.1 前処理

今回、センサデータとしては、スマートフォン上の 3 軸加速度、スタッフセンサの加速度、気圧、赤外線温度、湿度、環境センサの ID を使用した。

複数のセンサからのデータを用いるため、まずはデータをスタッフおよび時刻をキーとして結合する必要がある。




図 4 スマートフォン上の加速度の日毎の収集サンプル数。色はスタッフ（スマートフォン）別。




図 5 環境センサ ID の日毎の収集数。色はデバイス別。




図 6 環境センサの湿度（赤外線温度も同様の結果）の日毎の収集サンプル数。色はデバイス別。




図 7 スタッフセンサの加速度（気圧、湿度、赤外線温度も同様）の日毎の収集サンプル数。色はデバイス別。




図 8 行動ラベルの日毎の記録数。色は行動クラス。




図 9 行動クラス毎の行動ラベル記録数.

そのために、各センサについて1分ごとに以下に述べる方法で特徴量算出と結合を行った。

スマートフォン上の加速度については、一分ごとに、各軸ごとの平均、分散、合成加速度の平均、分散を特徴量とした。

スタッフセンサについては、データとしては経由したスマートフォンのIDも記録されるが、他のスタッフのスマートフォンを経由してデータを取得している可能性もある。このため、スマートフォンIDではなく、記録されたセンサデバイスIDとデバイスの配布管理データをもとにユーザと紐付けした。特徴量としては、各センサともに、一分ごとの平均、分散、最大値、最小値を用いた。

環境センサIDについては、被験者が環境センサに近づいたときにスマートフォンにIDが記録されるため、被験者の場所に関する情報とすることになる。今回、被験者のスマートフォンが1分ごとに取得した各環境センサIDの個数を特徴量として用いた。つまり、環境センサID毎に変数を用意し、一分ごとのID取得回数が特徴量となる。

一方で行動ラベルについても整形を行った。被験者が間違っって開始ボタンを押してすぐに止めたり、止めるのを忘れて非常に長い継続時間になってしまうことがあることが被験者からのヒアリングでわかった。そこで、行動ごとに継続時間の四分位数を取り、第2四分位未満または第4四分位以上のものは、第3四分位(つまり中央値)になるように終了時刻の方を修正した。

#### 4.2.2 行動認識アルゴリズム

行動認識アルゴリズムは、文献[4]の提案を、計算しやすいように拡張したものを用いた。その手順は以下のとおりである。

各ユーザについて、特徴量サンプル  $x$  と一日の中の時刻  $t$  は独立と仮定し、

- (1) 通常通り、各行動  $a \in A$  について、各行動クラス  $a$  についての特徴量サンプル  $x$  の生起確率  $P(x|a)$  を機械学習により求める。ここで、ラベル  $l$  が与えられれば行動  $a$  が取り出せるので、 $P(x|l)$  とみなし、さらに独立性仮定から  $P(x|l, t)$  とみなす。
- (2) 各ラベルについて、時刻  $t$  が与えられたときの生起確率  $P(l|t)$  を機械学習により求める。
- (3) (1) の確率にしたがって(2)を重点サンプリングし推




図 10 1時間の誤差を許した際の行動開始時刻の推定精度.




図 11 3時間の誤差を許した際の行動開始時刻の推定精度.

定ラベル集合  $\tilde{L}$  を得る。これにより  $P(x|l, t)P(l|t) = P(x, l|t)$  が近似でき、求めたい  $P(l|x, t)$  も得られる。

- (4) 一日の中の行動回数  $n_a$  の確率  $P(n_a|a)$  を得、 $n_a$  の推定値を得る。
- (5)  $n_a$  をクラス数にして、(3)の  $\tilde{L}$  をクラスタリングし、その平均値を推定セグメントとする。

基底となる機械学習アルゴリズムとしては、Extremely Randomized Tree[2]を用いた。

#### 4.2.3 評価方法

4.1節で見たように、データが安定しているのは後半である。このため、3月のデータを用いて行動認識の精度を評価した。3月1-15日のデータを学習データ、16-31日のデータをテストデータとした。

また、用いる行動推定手法はセグメント、つまり行動の開始時刻と継続時間を推定するものであるため、評価尺度としては、ある行動を一日に一回行った場合について、文献[7]で解説した  $\delta$ -再現率と  $\delta$ -適合率を、開始時刻と継続時間について算出することで評価した。

これは、真のセグメントと推定されたセグメントがどれだけ近いかを考慮に入れるために、パラメータ  $\delta$  をマージンとして導入して適合率と再現率を表す方法である。真のセグメントの開始時刻、終了時刻を  $(b, e)$  とし、推定されたセグメントを  $(\tilde{b}, \tilde{e})$  とした時に、

- $\delta$ -適合率:  $(b - \delta, e + \delta) \cap (\tilde{b}, \tilde{e})$  の区間の適合率。
- $\delta$ -再現率:  $(b, e) \cap (\tilde{b} - \delta, \tilde{e} + \delta)$  の区間の再現率。

つまり、適合率、再現率の分子となる True Positive サンプルの基準を近隣時刻まで緩和させるものである。

#### 4.2.4 行動認識精度

図 10, 11 に、行動開始時刻の推定精度を、図 12, 13 に、継続時間の推定精度を示す。




図 12 10 分の誤差を許した際の継続時間の推定精度。




図 13 20 分の誤差を許した際の継続時間の推定精度。

開始時刻の推定については、図 10 より、1 時間の誤差を許した場合、「休憩」「朝礼」については 90%以上、「申し送り」「モーニングケア」については 60%以上の精度で推定できている。加えて図 11 から、3 時間の誤差を許せば、「物品準備、点検」「ナイトケア」も 60%以上の精度となる。

継続時間の推定については、図 12 から、10 分の誤差を許せば、「コール対応」「トイレ介助」「朝礼」「服薬介助」「物品準備、点検」「離床・臥床介助」「バイタル確認」「巡視」「申し送り」について 80%以上の精度を得ている。加えて図 13 から、20 分の誤差を許せば、「休憩」「個人記録」「食事介助」「食事対応」「ナイトケア」「巡視」「利用者対応」も 80%以上の精度を得ている。

## 5. まとめ

本稿では、30 人規模の介護士・看護師スタッフを持つ介護施設において、スタッフの行動センシング実験を 2 ヶ月半程度行った実験を述べた。スマートフォンとセンサデバイスを持ってもらい、環境にも固有 ID およびセンサデータを得られるセンサをつけ、またスタッフにも行動ラベルを記録してもらい、データをクラウドサーバに保管し分析を行った。行動の開始時刻と継続時間に重点を置いた行動認識の結果、幾つかの行動についてある程度の精度を得た。特に継続時間において高い精度を得た。他のセンサデータを組み合わせることで精度を高めることや、スタッフにフィードバックして業務効率化のきっかけを得ることが今後の課題である。

### 謝辞

本研究の一部は、文部科学省地域イノベーション・エコシステム形成プログラム、基盤研究 (B)「物理層と意味層の 2 階層からなるセンサコンテキスト推定技術 (研究代表

者：井上創造)」および九州工業大学・IDC フロンティア包括連携による。実験に積極的に協力いただいた株式会社さわやか倶楽部さわやか海響館の皆様および、実験に協力いただいた学生の皆様に感謝いたします。

### 参考文献

- [1] Bahle, G., Gruenerbl, A., Lukowicz, P., Bignotti, E., Zeni, M. and Giunchiglia, F.: Recognizing hospital care activities with a coat pocket worn smartphone, *Mobile Computing, Applications and Services (MobiCASE), 2014 6th International Conference on*, IEEE, pp. 175–181 (2014).
- [2] Geurts, P., Ernst, D. and Wehenkel, L.: Extremely randomized trees, *Machine Learning*, Vol. 63, No. 1, pp. 3–42 (online), DOI: 10.1007/s10994-006-6226-1 (2006).
- [3] Inoue, S. and Pan, X.: Supervised and Unsupervised Transfer Learning for Activity Recognition from Simple In-home Sensors, *Proceedings of the 13th International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services - MOBIQUITOUS 2016*, New York, New York, USA, ACM Press, pp. 20–27 (online), DOI: 10.1145/2994374.2994400 (2016).
- [4] Inoue, S., Ueda, N., Nohara, Y. and Nakashima, N.: Mobile activity recognition for a whole day: Recognizing real nursing activities with big dataset, *UbiComp 2015 - Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, pp. 1269–1280 (online), DOI: 10.1145/2750858.2807533 (2015).
- [5] Inoue, S., Ueda, N., Nohara, Y. and Nakashima, N.: Recognizing and Understanding Nursing Activities for a Whole Day with a Big Dataset, *Journal of Information Processing*, Vol. 24, No. 6, pp. 853–866 (online), DOI: 10.2197/ipsjip.24.853 (2016).
- [6] Naya, F., Ohmura, R., Takayanagi, F., Noma, H. and Kogure, K.: Workers' Routine Activity Recognition using Body Movements and Location Information, *2006 10th IEEE International Symposium on Wearable Computers*, pp. 105–108 (online), DOI: 10.1109/ISWC.2006.286351 (2006).
- [7] 井上創造：ウェアラブルセンサを用いたヒューマンセンシング、知能と情報, Vol. 28, No. 6, pp. 170–186 (オンライン), 入手先 (<http://ci.nii.ac.jp/naid/40021082607/en/>) (2016).
- [8] 厚生労働省：2025 年に向けた介護人材にかかる需給推計 (確定値) について、, 入手先 (<http://www.mhlw.go.jp/stf/houdou/0000088998.html>) (参照 2017-04-26).