

位置・電力情報を基とした宅内行動認識システムへの居住者の加速度データの追加とその改善効果の調査

中川 愛梨¹ 守谷 一希¹ 諏訪 博彦¹ 藤本 まなと¹ 荒川 豊¹ 八田 俊之² 三輪 祥太郎²
安本 慶一¹

概要：近年、より細やかなサービスの提供を目指して、宅内における人のコンテキストおよび行動を知りたいという要求が高まっており、宅内生活行動を自動認識する研究が盛んに行われている。生活行動を自動認識できれば、高齢者見守りシステムや知的コンシェルジュサービス、健康支援システムなど生活を支援するサービスへの応用が可能となる。特に、現在までの一連の行動を把握し、次に起こるであろう行動を支援する知的コンシェルジュサービスにおいては、リアルタイムに行動認識できることが必須となる。これまで著者らは、住人のプライバシーに配慮し、カメラやマイクを用いずに、位置情報と消費電力情報のみを用いてリアルタイムに行動を認識する研究を進めてきた。その中で、読書とスマートフォン操作など、位置と消費電力情報のみでは認識できない行動があることが分かった。本研究では、居住者が装着しているスマートウォッチ、スマートフォンから取得できる加速度データを特徴量として新たに用いることで、より多様な行動に対し、高精度・リアルタイムの認識を目指した手法を提案する。提案手法では、各種家電の消費電力データ、住人の位置データに加え、住人の腰に装着したスマートフォンと手首に装着したスマートウォッチから取得した加速度データに関する特徴量を用いて、15種類の行動に対する機械学習モデルを構築する。加速度の特徴量として、ノルムの平均値と分散を使用した場合、トピックモデルに基づき静止、手の動作、腕の動作、全身の動作の4つのトピックの混合割合を使用した場合について、行動認識精度を評価する。スマートホームで、12日間のデータを収集し、その内の7日間のデータに対し提案手法を適用した結果、加速度特徴量を用いない場合と比べ、6.184%高い、平均57.136%の行動認識精度を達成した。

Investigating recognition accuracy improvement by adding user's acceleration data to location and power consumption-based in-home activity recognition system

ERI NAKAGAWA¹ KAZUKI MORIYA¹ HIROHIKO SUWA¹ MANATO FUJIMOTO¹
YUTAKA ARAKAWA¹ TOSHIYUKI HATTA² SHOTARO MIWA² KEIICHI YASUMOTO¹

1. はじめに

近年、スマートフォンやスマートウォッチなどのセンシングデバイスの普及により、それらを用いて人間の生活行動を理解するための研究が盛んに行われている。例えば、宅内生活行動を認識することにより、省エネ家電制御システム [1][2] や高齢者見守りシステム [3] など、QOL(Quality of Life) を向上させるサービスへの応用が期待されている。これらのサービスの実現には、多種多様な人間の生活行動

を高精度にかつ素早く認識することが重要である。本研究では、宅内生活行動を高精度かつリアルタイムで認識することを目的とする。

宅内での生活行動を認識する研究は多くある。それら既存研究には (1) カメラやマイク等によるプライバシー情報記録への抵抗感、(2) 少ない認識可能行動種類、(3) 低い認識精度、(4) 高い導入・維持コスト、(5) 長い認識時間という5つの課題を全て解決しているものはない。上田らは、プライバシー侵害の少ない位置情報と消費電力情報を用いて、10種類の行動を高い精度で認識しており、課題(1)~

¹ 奈良先端科学技術大学院大学

² 三菱電機株式会社

(4)についてはある程度達成している[4]。しかし、行動認識までに5分間のデータを必要としており、課題(5)については達成できていない。著者らは、サンプリング周期の短い消費電力センサを新たに導入することで、課題(5)の解決に取り組み、10秒間のデータから行動認識を行うことがある程度可能になった[5]。しかし、行動種類を増やした時に、「スマートフォン操作」と「読書」といった、場所・消費電力の特徴が類似した状況で発生する異なる行動の分類が困難であるといった新たな課題(課題(6))に直面している。

本稿では、居住者が装着しているスマートウォッチ、スマートフォンから取得できる加速度データに関する特徴量を用いることで、課題(1)~(6)の全てを解決可能な行動認識手法を提案する。提案手法では、文献[5]で用いた居住者の位置情報と消費電力情報に関する特徴量に加えて、居住者の腰に装着したスマートフォンと、利き手と逆の手首に装着したスマートウォッチで取得した加速度情報を用いる2種類の手法を提案する。一つ目は、加速度情報の10秒間の平均と標準偏差を特徴量として加える方法、二つ目は、加速度データにトピックモデル[6]を適用し、各時点の加速度データに対応する静止・手の動作・腕の動作・全身の動作といった4つのトピックの混合割合を特徴量として加える方法である。これらの特徴量と正解データからランダムフォレストを用いて、行動認識モデルを構築する。

提案システムの有用性を評価するため、奈良先端科学技術大学院大学内に設置したスマートホーム設備(ILDK)で、計4名の被験者に3日間ずつ計12日間にわたり生活してもらい、日常生活で考えられる15種類の行動(入浴、掃除、風呂掃除、料理、ゲーム、外出、洗濯、食事、PC使用、読書、睡眠、スマートフォン使用、食器洗い、洗面、テレビ視聴)に対してセンサデータを記録した。12日間の中で全データを取得できた7日間の1秒ごとのデータを10秒おきに丸めたデータを使用し、Wekaを用いた機械学習(Random Forest)により、行動がどの程度の精度で認識できるのかの分析を行った。実験期間中の任意の1日をテストデータ、残りを教師データとする交差検定を行った。結果、位置情報と消費電力情報のみを用いた場合の平均精度は50.952%、それに加速度を加えた平均精度は55.119%、また、位置情報と消費電力情報に加速度データのトピックモデルを加えると平均精度が57.136%となった。以上より、スマートウォッチ、スマートフォンで取得した加速度データの特徴量として加えることにより、位置情報と消費電力情報のみを用いた場合の認識精度に比べて6.184%の改善効果が見られた。

以降、第2章では、位置・電力情報を基とした宅内行動認識システムの現状と課題について述べる。第3章では、提案手法であるウェアラブルセンサとインフラセンサを用いた宅内行動認識手法について述べる。第4章では、評価

実験について述べる。第5章では、本研究に関係する行動認識についての関連研究について述べる。最後に、第6章で本研究の結論を述べる。

2. 位置・電力情報を基とした宅内行動認識システム：現状と課題

本章では、位置・電力情報を基とした宅内行動認識システムの現状と課題について説明する。

代表的な位置・電力情報を基とした宅内行動認識システムとして上田らの研究[4]がある。この研究では、課題(1)~(4)を解決するために、今後の低価格化・普及が見込め、カメラ等に比べプライバシー情報記録への抵抗が少ないと考えられる屋内位置センサおよび家電に取り付けた消費電力センサのみを用いて行動認識を行っている。使用する屋内位置センサと消費電力センサのサンプリング周期は、それぞれ毎秒2回、1分間に2回である。また、課題(2)~(3)を解決するために、多数の行動に対するセンサデータの記録と各行動に対する教師データの抽出、教師データに対する効果的な特徴量の選定、適切な行動学習モデルの構築を行っている。認識の対象となる行動は10種類(料理、食事、読書、テレビ視聴、食器洗い、風呂、掃除、仕事・勉強(PC使用)、睡眠、外出)である。この10種類の行動で日常生活の約90%をカバーすることができるという成果が出ている。しかし、この研究では、課題(1)~(4)については達成できているが、認識の時間窓が5分となっており、課題(5)は達成できていない。認識の時間窓は使用しているセンサの時間解像度から最短でも30秒に制限され、30秒の時間窓にした場合は行動の認識精度が平均86.3%に下がる。

著者らは、上記の問題点を解決するため、新たに1秒毎にデータを計測可能なセンシングシステムを構築し、過去のデータを特徴量として使用することで、10秒といった短い時間窓でも行動の認識が可能な方法を提案した[5]。本方式は(株)ラトックシステムのBluetoothワットチェッカーREX-BTWATTCHと独自開発したCT(Current Transformer)センサを用いて、消費電力データの1秒間隔での取得を実現している。本方式では、上田らの認識対象行動に5種類の行動を追加し、日常生活をより広くカバーする15種類の行動(入浴、掃除、風呂掃除、料理、ゲーム、外出、洗濯、食事、PC使用、読書、睡眠、スマートフォン使用、食器洗い、洗面、テレビ視聴)を対象としている。しかしながら、この方式では、テレビ視聴と読書の分類が困難であるなど、位置情報と消費電力情報だけでは分類・認識できない行動が存在するといった課題がある。したがって、この課題を解決するために新たなセンサの導入が必要であると考えられる。

本稿では、居住者が普段身につけていると考えられるスマートフォンやスマートウォッチなどのウェアラブルデ

バイスに着目し、それらから取得できる加速度データの特徴量として使用することで、位置情報と消費電力情報だけでは認識できない行動を精度良く分類・認識を試みる。

3. 加速度情報と位置・電力情報を用いた宅内行動認識手法

本章では、まず、加速度情報のみを用いた行動認識について述べたあと、位置・電力情報に加えて加速度情報を使用する提案手法について説明する。

3.1 加速度を用いた行動認識

加速度を用いて行動を推定しようとしている研究は多くある。Kwapiszら [7] は、ズボンの前面のポケットに挿入したスマートフォンに搭載されている3軸加速度センサを用いて、「歩く」「走る」「階段を上る」「階段を下りる」「座る」「立つ」という6つの状態を推定している。この手法では、それらの6つの状態を平均91.7%の精度で分類することができるという結果が出ている。また、「階段を上る」と「階段を下りる」という2つの状態を「階段の上り下り」という1つの状態とみなし、5つの状態とした場合には、平均93.7%でそれらの状態を分類できる。

八田ら [6] は、ズボンの右後方のポケットに挿入したスマートフォンに搭載されている3軸加速度センサを用いて、行動によって生成されたセンサ値を単語、時間窓で区切られた行動を文書として、行動にトピックモデルを適用することで、教師なし学習で行動分析を行っている。トピックモデルとは、主に自然言語処理分野で利用されており、単語の頻度分布で表された文書から、特定の単語の頻度分布で表されるトピックを推定する手法である。トピックは料理・政治・スポーツといったジャンルに相当するものであり、文書は各トピックの混合として表現できる。この研究では、5つの行動トピックを推定でき、それぞれの行動トピックが「静止している」「前後左右に動揺している」「足踏みしている」「着地している」「浮いている」というジャンルに相当することが分かっている。

3.2 提案手法

前節で述べた関連研究から、ユーザの基本的な運動状態を推定することに関して、加速度情報及び加速度情報から得られるトピックモデルは有用であると考えられる。そこで、本研究では、加速度情報を用いてユーザの運動状態を推定することで、位置・消費電力のみでは分類できなかった行動が認識できる可能性があると考えた。

本研究では、居住者の位置情報と消費電力情報に加えて、右腰に装着したスマートフォン (Samsung GALAXY S5) と、利き手と逆の手首に装着したスマートウォッチ (LG Watch Urbane) で取得可能な3軸加速度を用いた以下の

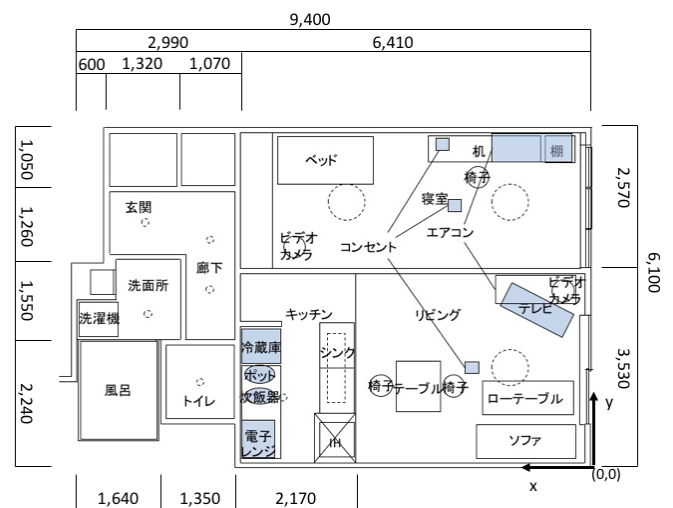


図1 スマートホーム見取り図

2種類の手法を提案する。

- 1) 加速度情報の10秒間の平均と標準偏差を新たな特徴量として用いる手法。
- 2) 加速度情報にトピックモデルを適用した際のトピックの混合割合を特徴量として用いる手法。

3.3 分析手法

本研究では、実験で取得した居住者の位置情報、消費電力情報、加速度情報から得られる生活行動データから教師データとテストデータを作成し、教師データから機械学習 (Random Forest) を用いて分類器を構築し、テストデータを分類することで認識精度の評価を行う。各情報の取得方法については4章で記述する。

4. 評価実験

提案手法の有用性を評価するため、評価実験を行った。以下に詳細を記述する。

4.1 実験環境

本研究で使用するセンサは以下の仕様のものである。

4.1.1 屋内位置センサ

天井に受信機を複数台設置し、送信機から発せられる超音波と同期用高周波 (RF) を用いて同期用 RF に対する超音波の到達遅延時間を計算し、送信機の位置を推定するセンサである。サンプリング周期は1秒間に2回である。送信機は小型で容易に持ち運べる大きさのため、人の位置を推定するためにも用いることができる。位置は x, y, z 座標で表される。 x, y 座標は図1の右下を原点とし、左に行くほど x の値が大きくなり、上に行くほど y の値が大きくなる。 z 座標については、天井からの距離であり、床に近づくほど値が大きくなる。

4.1.2 Bluetooth ワットチェッカー

家電、またはコンセントごとに消費電力を取得することができるセンサが取り付けられている。サンプリング周期は1秒間に1回である。センサが取り付けられている場所は、図1の青色の箇所、すなわち、寝室エアコン、寝室机上コンセント、寝室延長コンセント、冷蔵庫、電子レンジ、ポット、炊飯器、テレビ、リビング延長コンセントの9箇所である。

4.1.3 CT センサ

分電盤の電力系統ごとにCTセンサが取り付けられている。サンプリング周期は1秒に1回であり、データはArduinoを経由しZigBeeでRaspberry Piに送信している。電力を取得している系統は、IHヒーター、電気温水器、リビングエアコンコンセント、浴室乾燥機、リビング・キッチン・洋室照明、廊下・冷蔵庫コンセント、洋室エアコンコンセント、洋室コンセント、玄関・廊下・浴室・トイレ・洗面照明、洗面、洗濯機コンセント、キッチンコンセント、リビングコンセントの12系統である。

4.1.4 ウェアラブルデバイス

スマートフォン(Samsung GALAXY S5)とスマートウォッチ(LG Watch Urbane)を使用する。サンプリング周期はデバイスの状況により変化する。スマートフォンは右腰に、スマートウォッチは利き手と逆の手首に装着して用いる。

4.2 実験概要

2015年10月に奈良先端大が所有するスマートホーム設備(図1)で、被験者4名(20代男性4名)にそれぞれ3日間生活してもらい、計12日間分のデータセットを収集した。

被験者には右肩に超音波位置測位センサの送信機、右腰にスマートフォン、利き手と逆の手首にスマートウォッチを装着してもらい、最低でも1日3時間は活動し、10時間以上(睡眠時間含む)はスマートホームで生活してもらうように依頼した。短時間の外出についてはセンサ類は装着したままにってもらい、入浴時や睡眠時はセンサ類をはずし、脱衣所や枕元に置くという対応をしている。実験の期間中、被験者にはあらかじめ定義した15種類の行動(料理、食事、読書、テレビ視聴、食器洗い、入浴、掃除、PC使用、外出、睡眠、洗面、洗濯、ゲーム、スマートフォン使用、風呂掃除)をできるだけ1日1回以上、最低でも各自の実験期間中で1回は行うように依頼した。それ以外は自由な行動を許可したため、日中は外出していることとなった。

生活の様子は寝室とリビングに設置した2台のビデオカメラで記録し、それに加えて時刻が記録できるスマートフォンの音声保存アプリを使用して行動の開始、終了を音声データで保存するように依頼した。プライバシーに配慮

し、ビデオカメラのデータと音声データは被験者各自で管理してもらった。毎日、被験者が長期外出中に各センサの時刻が同期されているかを確認し、ずれのないようにした。実験後、収集して得られたデータを一つにまとめ、そのデータを被験者に渡し、その時間に何の行動をしていたかを音声データとビデオカメラの動画データを元にラベル付けしてもらった。行動のラベル付けについては、あらかじめ対象とする各行動についてそれぞれ何を開始、終了とするかの定義を提示し、その定義に従うように依頼した。

4.3 データ処理

実験により取得した粒度の違う各センサデータをそれぞれ10秒ごとに丸めて使用する。時刻の区切り方については実験開始の時刻から10秒おきに区切り、行動の切れ目などは考慮しない。位置情報は、0.5秒ごとに取得できるため、10秒間の中央値を使用する。実験設備の問題で、行動が外出の際に位置情報が欠損することがあるため、その欠損については固定値を与えることで補完する。消費電力情報は、1秒ごとに取得できるため、10秒間の平均値を使用する。ウェアラブルデバイスによる加速度情報は10秒間の平均値、標準偏差、含まれるトピックの割合を使用する。10秒に丸めた情報に欠損がある場合や、10秒間の間に複数の行動が含まれる場合は、その時刻のデータ列を削除し、使用しないものとする。

全12日分のデータの内、全データを取得できた7日分のデータに対し、特定の1日をテストデータとし、残りを教師データとして認識精度の評価を行う。すべての日に対して同様の分析を行い、それぞれの平均を取ったものを結果とする。分析はWekaを用いてRandom Forestにより分類器を作成して行った。

4.4 結果

位置情報と消費電力情報のみを用いた場合、位置情報と消費電力情報とウェアラブルデバイスの加速度情報の平均値・標準偏差を用いた場合、位置情報と消費電力情報とウェアラブルデバイスの加速度情報から得られるトピックモデルを用いた場合のそれぞれの精度は以下ようになった。認識精度は特定の1日に対して以下の式により算出し、全7日間の平均を取る。

$$\text{認識精度} = \frac{\text{正しく分類されたテストデータの数}}{\text{テストデータの数}}$$

4.4.1 位置・消費電力

位置情報と消費電力情報のみを用いた行動認識結果を表1に示す。行動認識の平均精度は50.952%であった。

4.4.2 位置・消費電力・加速度

次に、位置情報と消費電力情報に加え、加速度の平均値・標準偏差を用いた行動認識結果を表2に示す。行動認識の

表 1 位置・消費電力を用いた行動認識結果

行動の種類	サンプル数	適合率	再現率	F 値
ラベルなし	3065	0.322	0.761	0.429
入浴	1100	0.351	0.260	0.229
掃除	289	0.492	0.214	0.278
風呂掃除	728	0.138	0.115	0.114
料理	1480	0.755	0.709	0.690
ゲーム	343	0.063	0.007	0.013
外出	862	1.000	0.903	0.939
洗濯	282	0.000	0.000	0.000
食事	792	0.316	0.179	0.196
PC 使用	2916	0.976	0.716	0.781
読書	1331	0.350	0.013	0.024
睡眠	218	0.000	0.000	0.000
スマートフォン使用	1305	0.083	0.086	0.063
食器洗い	643	0.246	0.123	0.149
洗面	196	0.000	0.000	0.000
テレビ視聴	1093	0.331	0.549	0.376
重み付け平均	-	0.595	0.509	0.479

表 3 位置・消費電力・トピックモデルを用いた行動認識結果

行動の種類	サンプル数	適合率	再現率	F 値
ラベルなし	3065	0.356	0.727	0.433
入浴	1100	0.638	0.639	0.584
掃除	289	0.658	0.330	0.411
風呂掃除	728	0.385	0.209	0.246
料理	1480	0.778	0.736	0.718
ゲーム	343	0.500	0.004	0.007
外出	862	0.999	0.926	0.957
洗濯	282	0.000	0.000	0.000
食事	792	0.625	0.222	0.280
PC 使用	2916	0.985	0.760	0.816
読書	1331	0.400	0.013	0.025
睡眠	218	0.800	0.767	0.782
スマートフォン使用	1305	0.337	0.159	0.146
食器洗い	643	0.464	0.470	0.409
洗面	196	0.000	0.000	0.000
テレビ視聴	1093	0.359	0.727	0.431
重み付け平均	-	0.679	0.571	0.548

表 2 位置・消費電力・加速度を用いた行動認識結果

行動の種類	サンプル数	適合率	再現率	F 値
ラベルなし	3065	0.334	0.728	0.419
入浴	1100	0.623	0.623	0.574
掃除	289	0.640	0.285	0.373
風呂掃除	728	0.352	0.173	0.224
料理	1480	0.750	0.747	0.713
ゲーム	343	0.800	0.071	0.131
外出	862	0.999	0.920	0.953
洗濯	282	0.000	0.000	0.000
食事	792	0.224	0.173	0.191
PC 使用	2916	0.980	0.754	0.808
読書	1331	0.200	0.002	0.005
睡眠	218	0.800	0.767	0.782
スマートフォン使用	1305	0.271	0.116	0.106
食器洗い	643	0.303	0.189	0.219
洗面	196	0.000	0.000	0.000
テレビ視聴	1093	0.356	0.641	0.401
重み付け平均	-	0.648	0.551	0.528




図 2 重み付け平均の比較




図 3 適合率の比較

平均精度は 55.119%となり、加速度に関する特徴量を加えることにより、精度が 4.167%改善した。

4.4.3 位置・消費電力・トピックモデル

最後に、位置情報と消費電力情報に加え、加速度データから算出したトピック混合割合を用いた行動認識結果を表 3 に示す。行動認識の平均精度は 57.136%となり、加速度情報をそのまま加えるよりも精度の向上が大きいということが分かった。

4.5 考察

3つの手法の適合率、再現率、F 値の重み付け平均を比較すると図 2 のようになる。従来の位置と消費電力の情報を用いる手法と比べて、加速度情報をそのまま用いることで

それぞれ約 0.04~0.05、トピックモデルを用いることでそれぞれ約 0.06~0.08 の精度向上が見られた。予測していたような大きな精度向上とはならなかったが、加速度情報を用いることは精度向上に対して有用であると考えられる。

3つの手法の各行動ごとの適合率、再現率、F 値を比較




図 4 再現率の比較




図 5 F 値の比較

すると、それぞれ図 3, 図 4, 図 5 のようになった。

もともと比較的高い値である料理, 外出, PC 使用などの行動では大きな変化が見られなかった。しかし, 入浴, 掃除, 風呂掃除, ゲーム, 睡眠, スマートフォン使用, 食器洗いなどの行動については, 加速度情報を加えることでそれぞれの値の向上が見られた。入浴と風呂掃除については, 入浴の場合はスマートフォンとスマートウォッチを外すという理由から二つの行動の区別が付きやすくなったからであると考えられる。掃除, ゲーム, スマートフォン使用, 食器洗いについても手首に装着したスマートウォッチの加速度情報からラベルなしやテレビ視聴, 料理などのそれぞれについて混同されやすい行動との区別が比較的付きやすくなったからであると考えられる。睡眠についても同様に, 2つのデバイスの加速度情報を用いることで, 同じ位置で起こっていたラベルなしの時間との区別が付けられるようになったからであると考えられる。

今回用いた 7 日間のデータは, 文献 [8] で用いられている 2015 年 10 月の実験で取得した同一の家具配置の 12 日間のうち, 位置情報と消費電力情報が全て取得できた 9 日間のデータの中で, さらに加速度情報が取得できた日を抜き出したものである。そのため, サンプル数の減少や, 比

較的認識精度の良い日が除外されていることにより, 本来は 60%程度の精度が見込める従来の位置・消費電力のみを特徴量とした際の認識結果が 50%と下がってしまっている。しかし, サンプル数が増加することで, それぞれの手法でさらに精度の向上が期待できると考えられる。

5. 関連研究

本章では, 本研究に関係する行動認識に関する代表的な既存研究と本研究の差異について整理する。

勝手ら [9] は, 物体と動きの特徴量を用いて行動認識を行っている。人物の動きだけでなく, 行動に用いられる物体に注目し, その物体の特徴量を加えることで行動の認識精度を向上することを目的としている。この研究では 5 種類の行動 (掃除機をかける, パソコンを使用する, お茶を飲む, 読書, 食器洗い) を認識できるかという実験を行っており, 提案手法を用いることで, 人物の動きの特徴量のみを用いた場合と比較し, 認識精度が向上するという結果が出ている。しかし, この研究ではカメラによる動画像を使用しており, 使用者のプライバシーを侵害してしまう恐れがあるという課題がある。また, 認識できる行動の種類が少ないという点で本研究と異なる。

大内ら [10] は, 携帯電話に搭載されている加速度センサとマイクのみを用いて, 10 秒毎に行動を認識している。まず, 加速度センサのみで「歩行」「作業」「安静」の 3 状態のどの状態に当てはまるかを推定し, 「作業」の場合はマイクからの音の分析によりどの作業をしているかの推定を行う。この研究で推定できる作業は 7 種類 (皿洗い, 掃除機がけ, アイロンがけ, トイレ水洗/手洗い, 歯磨き, 電気シェーバーによる髭剃り, ドライヤーの使用) である。この研究では「歩行」「作業」「安静」の 3 状態をおおむね 95%以上, 7 種類の作業を平均 85.9%の精度で推定できることが確認されている。この研究では本研究と同様に加速度センサを用いているが, 本研究とは異なりマイクを使うことから, プライバシーを侵害する恐れがある。また, 推定できる行動種類が限られているため, 日常生活を広くカバーする行動を認識できない。

Maekawa ら [11] は, 使用時に各家電が発する磁界に着目し, ウェアラブル磁気センサを用いて, テレビ鑑賞, シェービング, 携帯電話の操作, 歯磨き, 掃除などの行動を認識する手法を提案している。しかし, この手法は本研究とは異なり電化製品の操作に関連した行動の認識に限られており, 認識精度も 75%程度に留まっている。

Chen ら [12] は, 家庭内のあらゆる物に接触センサを付けることで 94.44%という高い行動認識率を達成している。また, 平均認識時間も 2.5 秒と高速に行動を認識できている。しかし, この手法は導入及び維持コストが高くなるという課題がある。

Kasteren ら [13] は, ドアセンサ, 引出センサ, 温度セン

サなど様々なセンサが埋め込まれたスマートホームにおいて、食事、外出、トイレ、シャワー、着替えなどの多種多様な日常生活行動を認識するシステムを構築しており、認識精度は49~98%となっている。この手法では、認識できる行動の種類は多いが、行動の種類によっては認識精度が低いという問題がある。また、データのセグメントの長さが60秒となっており、リアルタイムに行動が認識できているとは言い難い。

以上の行動認識の既存研究には、(1)カメラ等の機器によるプライバシーの侵害、(2)認識できる行動の種類が少ない、(3)認識の精度がよくない、(4)導入及び維持コストが高い、(5)認識までに時間がかかるという5つの課題がある。本研究は、これらの課題を同時に全て解決するための新たなセンサシステムを構築しようとしている点で既存研究と異なっている。

6. まとめ

本稿では、多様な生活行動を実時間で認識することを目的に、先行研究の位置・電力情報に加え加速度情報の特徴量として加えた新しい生活行動認識手法を提案した。提案手法では、住人の位置情報と各家電の消費電力情報に加えて、これらの情報だけでは分類できない行動を認識するために、スマートウォッチとスマートフォンから取得できる加速度データの特徴量として新たに導入している。ノルムの平均・分散といったシンプルな特徴量に加え、トピックモデルに基づいた、4種類のトピックの混合割合を特徴量として用いる点が特徴となっている。評価実験として、料理、食事、読書、テレビ視聴、食器洗い、入浴、掃除、PC使用、外出、睡眠、洗面、洗濯、ゲーム、スマートフォン使用、風呂掃除の15種類の行動を対象としてセンサデータを収集した。その結果、認識精度が57.136%となり、位置情報と消費電力情報のみを用いた場合の認識精度に比べて6.184%の改善効果が見られた。

認識結果から、加速度を用いても認識できないままの行動があることがわかった。本研究では加速度情報の平均値と標準偏差を用いているが、加速度情報から得られる歪度、尖度などの他の値を特徴量として加えると認識精度に影響があるかを比較する必要があると考える。また、加速度情報以外の新たな特徴量についても検討したい。また、本研究では分析の際に訓練データとして1日を除いた残りのデータをそのまま用いているが、その中から行動ごとに均等な個数を抜き出して訓練データを作成し、同様の分析を行いたい。そうすることで、ラベルなしの行動の影響を他の行動が受けにくくなり精度が上がる可能性があると考えられる。

謝辞 本研究では、(株)ラトックシステム様が開発されたBluetoothワットチェッカー REX-BTWATCHのサン

プルプログラムを使用させて頂きました。

参考文献

- [1] J. Scott, B. Brush, J. Krumm, B. Meyers: PreHeat: "Controlling Home Heating Using Occupancy Prediction," in Proc. of UbiComp 2011.
- [2] B. Sean, M. Aditya, I. David, S. Prashant: Smart-Cap: "Flattening Peak Electricity Demand in Smart Homes," in Proc. of Percom 2012, pp.67-75 (2012).
- [3] P. Rashidi, A. 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).
- [4] K. Ueda, H. Suwa, Y. Arakawa, and K. Yasumoto: "Exploring Accuracy-Cost Tradeoff in In-Home Living Activity Recognition Based on Power Consumptions and User Positions," in Proc. of IUCC 2015.
- [5] 中川 愛梨, 諏訪 博彦, 藤本 まなと, 荒川 豊, 安本 慶一: リアルタイム行動認識システム開発のためのデータ収集と分析, 情報処理学会 第77回モバイルコンピューティングとパーベイシブシステム (MBL) 研究会, MBLWiP-18, vol.2015-MBL-77, no.9, pp.1-5, (2015).
- [6] 八田 俊之, 三輪 祥太郎: トピックモデルに基づく人行動分析技術, FIT2015(第14回情報科学技術フォーラム), 情報科学技術フォーラム講演論文集 14(4), pp.367-370, (2015).
- [7] J. R. Kwapisz, G. M. Weiss, S. A. Moore: "Activity Recognition using Cell Phone Accelerometers," ACM SIGKDD Explorations Newsletter, vol.12, no.2, pp.74-82 (2010).
- [8] 中川 愛梨, 守谷 一希, 諏訪 博彦, 藤本 まなと, 荒川 豊, 安本 慶一: 異なる家具配置に対応可能なリアルタイム行動認識システム開発のためのデータ収集と分析, 情報処理学会 第79回モバイルコンピューティングとパーベイシブシステム (MBL) 研究会.
- [9] 勝手 美紗, 内海 ゆづ子, 黄瀬 浩一: 物体と動き特徴を用いた行動認識, 電子情報通信学会技術研究報告. PRMU, パターン認識・メディア理解 111(430), 125-126, (2012).
- [10] 大内 一成, 土井 美和子: 携帯電話搭載センサによるリアルタイム生活行動認識システム, 情報処理学会論文誌, pp.1675-1686 (2012).
- [11] T. Maekawa, Y. Kishino, Y. Sakurai, and T. Suyama: "Recognizing the Use of Portable Electrical Devices with Hand-Worn Magnetic Sensors," in Proc. of Pervasive 2011, pp.276-293 (2011).
- [12] L. Chen, C.D. Nugent and H. Wang: A Knowledge-Driven Approach to Activity Recognition in Smart Homes, IEEE Transactions on Knowledge and Data Engineering, vol.24, no.6, pp.961-974 (2012).
- [13] T. L. M. van Kasteren, B.J.A. Krose: "activity monitoring system for elderly care using generative and discriminative models," Personal and Ubiquitous Computing, vol.14, no.6, pp.489-498(2010).