

家庭内での移動と家電利用のセンシングによる 高齢者の生活行動推定

本田 美輝¹ 山口 弘純¹ 東野 輝夫¹

概要: 高齢化社会を迎え, 高齢者の心と体の健康増進を図り, 安全安心を実現することは極めて重要である. 特に在宅時間が比較的長くなりがちな独居高齢者においては, 家庭内でも十分な運動量が確保できているかや, 閉じこもりがちで鬱傾向がみられないかななどをプライバシーに配慮しながら低コストに見守る技術の実現が望まれる. 本稿では, 配置が容易でかつプライバシー侵害リスクが少ない赤外線ポータブル人感センサー及びタップ消費電力モニターを複数利用し, それらを用いた独居高齢者の家庭内行動の推定手法を提案する. 提案手法ではセンサーの出力値を入力とし, Markov Logic Network (MLN) を用いてセンサーと行動の関連規則をソフト論理式として表現するとともに, 事前に複数の高齢者に対するアンケートを実施し, 高齢者の典型的な行動パターンを考慮した規則を規定する. それらをもとに, それらの規則がどの程度対象者の行動推測に即しているかの値をセンサー設置後数日間の正解行動データで学習する推定方法, ならびに高齢者への簡易な質問を介して規則の尤度を徐々に学習することで高齢者による正解行動データの記録を必要としないインタラクティブ推定方法を提案している. 開発したプロトタイプシステムを2つの独居高齢者宅にそれぞれ1週間導入し, 行動推定を行った結果について述べる.

1. はじめに

センシングやネットワーク技術の向上によって, その技術を家庭内に導入し, より豊かで快適な暮らしを可能にするスマートホームが普及しつつある. スマートホームでは, HEMS (Home Energy Management System) を構築し, 家電や設備機器を自動制御することで省エネルギー化を図る事例が多い. 一方で, 人は家庭内での生活時間が一番長いことから, 肥満防止や家族のコミュニケーションなど, 家庭における生活改善支援においても IT 技術の活用が期待されている [1]. 我々の研究グループでは, 家庭内の行動モニタリングに基づいて人々に活発で自発的な日常行動を促すことにより, 家庭内行動のみえる化やエネルギー効率化, 同居者のコミュニケーション促進などを図る方法論を検討してきている [2][3][4][5].

一方で, 日本を始めとした先進諸国においては急速に高齢化が進んでおり, 日本では 2035 年には 3 人に 1 人が 65 歳以上になると想定されている [6]. 高齢者人口の増加に伴い独居高齢者も増加しており, 社会との関わりや活動量が減少することで精神衛生や肉体的健康に悪影響を与え

るケースも少なくない. そういった悪影響を排除し, 高齢者の生活の質 (Quality of Life, QoL) を向上させるためには, 健康上の問題がない状態で日常生活を遅れる期間である健康寿命を長寿化し, 活発に生活を送ってもらうことが重要である. 特に独居高齢者は在宅時間が比較的長くなりがちであるため, 精神的抑圧傾向から生じる活動量の低下などをいち早く検知できることが望まれる.

センサーを用いた家庭内での居住者の行動推定については様々な手法が提案されている. 文献 [7] では居住者の手足に加速度センサーを装着し, ドアや窓の開閉めや植物の水やりといった行動を推定している. また文献 [4], [8] では, Kinect を用いて人の関節の動きを検知することで, 人の姿勢や行動を推定している. しかし, 文献 [7] などウェアラブル機器を前提とした手法では, 機器装着負担が大きく, 特に家庭内では現実的でなく, かつ高齢者への適用は難しい. また文献 [8] では常時 Kinect を稼働させて動画を取得する必要があり, プライバシーリスクの点で普及には課題が多い. 近年では Amazon Echo Look など深度センサー付きのカメラ端末が登場しつつあり, カメラそのものへの抵抗感が下がることが期待できるものの, リビングなどへのカメラ設置は制約が大きい. 我々の先行研究 [2], [3] では, 家庭内行動を把握するため, 配置が容易なポータブル型人感センサー及び消費電力モニターを複数利用し, 直観

¹ 大阪大学 大学院情報科学研究科
Graduate School of Information Science & Technology, Osaka University,
1-5 Yamadaoka, Suita, Osaka 565-0871, Japan

的なルールに基づく簡易な行動推定を行い、居住者に生活改善のリコメンドを促す手法を提供している。しかしこの方法では、キッチンに設置されたセンサーが反応すれば料理をしているといった簡易な推定のみを前提としており、一つの部屋が様々な行動のための場所であることが多い独居高齢者に応じた現実的な行動推定は実現できていない。

本稿では、配置が容易でかつプライバシー侵害リスクが少ない赤外線ポータブル人感センサー及びタップ消費電力モニターを複数利用し、それらを用いた独居高齢者の家庭内行動の推定手法を提案する。提案手法ではセンサーの出力値を入力とし、Markov Logic Network (MLN) を用いてセンサーと行動の関連規則を表現する。MLN は一階述語論理と Markov Network を組み合わせたもので、記述した論理式の一部が充足されないことも許される。各論理式の重みは学習により決定され、満たされない論理式の重みなるべく小さくなるような述語の確率が導出されることで、学習した重みに沿った推論が行われる。この MLN に対し、例えば「3:00am は寝ている」、「寝室にいるならば、寝室で寝ている」、「掃除機が稼働しているならば、掃除をしている」といった、ある時間での場所情報や家電情報と行動との相関ルール (SA ルール: Sensor-Activity Rule) を一階述語論理で記述し、この論理式の重みを訓練データで学習する。次に述語の確率による推定結果が、高齢者の生活パターンにどの程度合致するかを判定するため、時間習慣的ルール (TC ルール: Temporal and Customary Rule) を定義する。例えば「午前中はくつろぐ時間はない」、「家事はまとめて行う」、「料理をした後は最低 2 時間は料理をしない」、「1 日 3 回は食事をする」といった行動時間や回数に関する規定が記述できる。このルールを MLN の推定結果に適用した場合に TC ルールを満たさない述語を特定し、それらの述語の重みを下げた MLN を用いて再学習を行うプロセスを繰り返す。これを適当な回数繰り返し、得られる推定結果の中で TC ルールを最も満足するものを解として利用する。初期の TC ルールは事前に複数の高齢者に対するアンケートを実施し、高齢者の典型的な行動パターンを考慮した規則を規定する工夫をしている。この推定法をもとに、それらの規則がどの程度対象者の行動推測に即しているかの値をセンサー設置後数日間の正解行動データで学習し推定するバッチ推定法、ならびに高齢者への簡易な質問を介して規則の尤度を徐々に学習することで高齢者による正解行動データの記録を必要としないインタラクティブ推定法を提案している。開発したプロトタイプシステムを 2 つの独居高齢者宅にそれぞれ 1 週間導入し、行動推定を行った結果について述べる。

本稿の構成は以下のとおりである。2 章では、既存の行動推定手法や推定結果を活用する既存研究について紹介する。3 章では、開発したシステムの利用環境、機能並びにシステムアーキテクチャを述べ、設計開発の詳細について

述べる。4 章では、同システムの人感センサー並びに消費電力センサーから得られるデータを用いた家庭内行動推定手法について述べる。5 章および 6 章では、実在する独居高齢者宅から得たセンサーデータを適用した場合の結果について述べる。7 章では、本研究のまとめと今後の課題について述べる。

2. 関連研究

2.1 スマートデバイスや行動トラッキングによる生活支援

近年、IT 技術を利用し、居住者に対してスマートな生活環境を提供するシステムやアプリケーションが多数提案されており、商用化事例も多い。それらのいずれも、ヒトやモノへのセンサーの装着、あるいは部屋へのセンサーの設置により行動認識を行い、それを用いてサービスを提供する。

ライフログや健康支援では、日常の細やかな行動を記録するため、ヒトやモノへの装着型デバイスを用いることも多い。例えば Mother[9] は、加速度計を組み込んだ小型センサーを歯ブラシやコップ、冷蔵庫やコーヒーメーカーなどに取り付けることにより、「今日はまだ歯を磨いていない」など日々の行動を記録する。SmartBand[10] は腕時計型のデバイスであり、消費カロリーや睡眠時間といった基本行動情報だけでなく、視聴した曲名や通話時間といったエンターテインメント性のある行動情報についても記録を行う。これらは装着型デバイスのメリットを活用し、詳細な行動把握に焦点を当てている。

また、体幹や歩行速度などを把握し、健康診断や認知症判断などに役立てるアプリケーションも多い。文献 [11] では家庭内の通路に設置することを想定したアレイ状のセンサーを作成し、足首のセンシングから歩行速度や歩幅などの歩行能力を推定する手法を提案している。また、文献 [12] では、家庭内に様々なセンサーを設置し、現在の行動から次の行動へ移る「行動移動期間」を推定し、認知症患者に対し次に取るべき行動を提示するアルゴリズムを提案している。文献 [13] では、家庭内に設置した複数の環境センサーを利用し、薬の服用状況の把握や朝食を 2 回取るなどの異常行動を検知するシステム FABER を提案し、軽度認知障害 (Mild Cognitive Impairment) 患者の支援を目指している。これらは健全状態・異常状態の検出が最大の目的であり、そのために用意された特別なデバイスを用いているため、一般的な家庭内行動推定とは異なる場合が多い。

エネルギー消費と家庭内行動にも少なからず相関が存在するため、家庭内における行動と電力量の定量化を目指したアプローチ [14] や家電機器の電力使用状況をスマートフォンを利用し遠隔で確認するためのシステム [15] など提案されている。また、文献 [16] では太陽光発電等で得られる「グリーン・エネルギー」を最大限に利用するための洗濯機の稼働時間を居住者に提示するシステムを実装して

いる。

2.2 屋内トラッキング技術

人々がどの部屋にいるか、部屋のどこにいるか、あるいはどの部屋を移動しているかといったトラッキング情報は様々なアプリケーションに応用できる。そういったトラッキングにはコスト面の優位性から、赤外線焦電型センサーを利用した人感センサーもよく用いられている。ただし、焦電型センサーを用いた人感センサーの多くは集光した光の変化による動作の有無を検知しバイナリー値を出力するため、単純な存在反応のみから居住者の位置を取得することは容易でない。これに対し、文献[17]は、人感センサーを室内や廊下の天井に設置し、居住者の室内軌跡情報を認識する方法を提案している。文献[18]では、人の目的地を予測する手法を提案しており、人感センサー情報を文字列として捉え、類似パターンの圧縮処理を施すことで、検出精度の向上を図っている。また、文献[19]は人感センサーを用いて人の存在を検出し、それに合わせた照明制御手法を提案している。他にも、文献[20]では人感センサーと超音波センサーを組み合わせて人の移動方向と身長を検知し、複数人が存在する家庭内で個人を特定する手法を提案したり、文献[21]ではドア上部に設置した超音波センサーから人物の通過と身長から個人の特定をしたりしている。文献[22]、[23]は人感センサーのみを用い、歩行、停止、着座といった移動状態を推定する。また、文献[24]では、プライバシーを考慮し、赤外線カメラとマーカを用いた屋内のデバイスフリートラッキング技術を提案している。

2.3 家庭内行動認識技術

居住者の行動を汎用的に把握する技術は現在も多くの研究がなされており、利用するセンサーの種類や特性に応じた様々な手法が提案されてきている[25]。BoxLab[26]はMITメディアラボによる、カメラや赤外線人感センサーを内蔵した家庭用センサーBoxを用いた行動認識プロジェクトである。文献[14]は、家電の稼働と消費電力量を紐付ける手法を取り扱っており、消費電力から使用者の行動を推定するアルゴリズムを提案している。文献[27]は、バイナリーセンサーや家電センサーを用い、転移学習の概念を用いてセンサー配置が異なる状況でも汎用的に利用可能な行動認識手法を提案している。特に異なる家庭のレイアウトにおいても容易に転用可能なモデルを構築しておくことは重要であり、本手法は複数家庭へのシステム展開時における訓練データセット取得の手間を低減できるメリットがある。また、文献[28]では個人の日常行動を自動的にラベル付けすることを可能とする方法論を展開している。特に、1m毎に天井につけられたモーションセンサーや家電センサー、独自開発センサーを用いたあらゆるセンシングデータからの(飲食などを含めた)詳細な行動モニタリ

ングを、著者らのCASASテストベッドを用いて評価している。スマートホーム内の行動検出の精度の向上を図るための手法として、文献[29]では、サポートベクターマシン(SVM)を用いた行動範囲のクラスタリングを実施している。また、文献[30]では、居住者の行動推定だけでなくその行動の意図も推定するアルゴリズムを提案している。

2.4 本研究の位置付け

家庭内の行動推定については多くの関連研究があるが、本研究では以下の点で目的が異なる技術の確立を目指している。(1) まず、装着の必要性がないバイナリー型人感センサーが部屋あたり1つ程度配置された状態、およびいくつかの家電に消費電力モニターが装備された低コストなセンシング環境において、居住高齢者がどのような行動をしているかが推定可能な手法を提案している。提案手法はセンサーデータへの依存を避け、簡易なセンシングデータから部屋レベルの存在推定を行い、一般的な高齢者の行動パターンの事前知識をベースに精度を向上させる。日本の独居高齢者の住居の多くは部屋数が限られており、1部屋が複数の目的で使い分けられることも多く、簡易な低コストセンサーを用いる場合、そのみに頼った推定は難しい。一般的な行動パターンを学習していくことで、異なる高齢者に対しても高い推定精度を実現することを目指している。また、そういった行動パターンを簡易に記述できるルールベースの推論を採用していることも特徴である。(2) 次に、(1)の行動パターン学習において、高齢者からの正解データを回答や記録に負担の少ない質問で取得する方法を検討している点があげられる。ルールの適応性から質問を直接生成し、それをモデルにフィードバックする仕組みを構築しており、それを用いて自然な形で精度を向上させる仕組みを提案している。

3. 家庭内行動推定システム

本研究で推定する行動は、日常生活動作(ADL: Activities of Daily Living)で定義される食事、睡眠、入浴などの、家庭内での基本的行動である[31]。

家庭内行動は、TV鑑賞、掃除など家電製品の使用を伴う行動と、身支度、調理などその行動の一部にだけ家電製

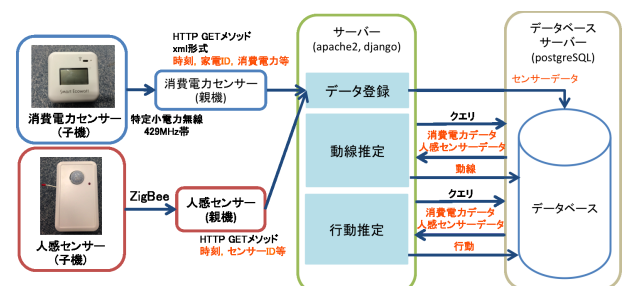


図1 行動推定システムのアーキテクチャ

品の使用を伴う行動、食事、睡眠など家電製品の使用を伴わない行動の三種類に分類できる。家電の使用を伴う行動は電力の消費を必ず伴うため、消費電力モニターにより計測された消費電力量から行動を推定することができる。単純な例では、掃除機の稼働を把握すれば居住者が掃除していると判断できる。一方、家電の使用を伴わない行動は必ずしも電力の消費が伴わないため、消費電力モニターのみからこれらの行動を推定することは困難である。これに対し、居住者の位置を計測できる人感センサーを導入することで、それにより計測された人の位置に基づき行動を推定することも可能である。例えば、ダイニングのテーブル付近に滞在している居住者は食事をしていると推定することができる。

行動の一部に家電製品の使用を伴う行動に対しては、消費電力センサーと人感センサーの両方を使用し、その行動を推定する。例えば、身支度は外出前の身支度と就寝前の身支度を総括した行動を指すが、身支度行動には洗面室での洗顔や歯磨きのほか、ヘアドライヤーを使用しての整髪、寝室における着替えを含む。そのため、身支度行動については、ヘアドライヤーが稼働していることに加え、居住者が寝室や洗面室に滞在していることの両方の計測結果から、身支度が実施されていると推定する。同様に、調理には、冷蔵庫の開閉やIHの稼働、電子レンジの稼働など家電製品の使用を伴う動作と、シンクで野菜を洗う、まな板の上で肉を切るなどの家電製品の使用を伴わない動作が含まれている。そこで、電子レンジやトースター、冷蔵庫等の稼働が消費電力モニターにより検出された時、およびキッチンに居住者がいることが人感センサーにより検出された時に調理が実施されていると推定することができる。

開発したシステムのアーキテクチャを図1に示す。本システムでは消費電力モニターと人感センサーを利用し、消費電力モニターにより家電の種類と稼働状況、人感センサーにより居住者の位置を計測する。計測結果はサーバに送信する。サーバは、これらの計測結果に基づき、家庭内で実施されている居住者の行動を推定し、推定結果をデータベースに蓄積する。

3.1 人感センサーによる居住者位置の計測

本システムで用いる人感センサーは研究グループで開発しており、

親機と子機から構成されている。親機は Arduino UNO [32] 上に、通信用モジュール TWE-Lite [33] に加えて、サーバとの通信のための Ethernet Shield を搭載し、子機は、赤外線焦電センサーと TWE-Lite から構成されている。子機は幅 69 mm × 奥行 115 mm × 高さ 28 mm、200 g 程度の小型センサーであり、電池稼働するため、電源制約を受けず、天井や壁などにも設置できる。

子機は、搭載された赤外線焦電センサーにより人の存在を検知しており、検知範囲は中心角 100 度、母線の長さ 3





図 2 人感センサーの反応 1

図 3 人感センサーの反応 2

m の円錐の底を中心線の長さが 5 m になるように滑らかに膨らませたような形状に設定している。赤外線焦電センサーは検出範囲内の熱源の移動により変化する集光の偏りを検出して反応するため、検知範囲内で人が移動すれば反応するが、検出範囲内でもしばらく静止していると検知できなくなる。

子機は 4 秒毎に人が検知範囲内に滞在しているかを判定しており、人を検知した場合にはその情報を親機に送信する。親機は人の存在を検知した子機の情報をサーバーに HTTP の GET メソッドで送信する。

3.2 消費電力モニターによる家電製品稼働状況の計測

本システムでは、消費電力モニターとして、ENEGATE 社製のスマートエコワット [34] を用いる。この消費電力モニターは親機と子機から構成され、子機にはコンセント口とコンセントプラグが備えられており、家電製品の消費電力量計測が可能である。子機により計測された消費電力量は無線で親機に送信され、複数の子機から集約された消費電力データは、15 分毎に HTTP の POST メソッドにより XML データとしてサーバーへ送信される。この XML データには、各子機ごとのサーバーへ送信される直前の瞬時電力量と、計測を始めてからの累積電力量の情報が含まれている。このうち、現在の累積電力量と、直前の時間スロットでの累積電力量の差を考慮し、15 分間隔で家電利用を判断する。

4. 行動推定アルゴリズム

本章では行動推定アルゴリズムについて述べる。本稿では、行動ラベルデータに基づく行動推定手法(手法 1)とフィードバックに基づくインタラクティブ行動推定手法(手法 2)の 2 つの手法を提案する。両手法の入力ならびにモデルは共通であり、1 日分の人感センサーデータから得られる、居室やスペースの存在/非存在バイナリ情報と、消費電力モニターから得られる家電の利用/非利用バイナリ情報を入力とし、その日の時間スロット毎の行動推定結果を行動推定列として出力する。推定する行動の種類は日常生活動作 (ADL: Activities of Daily Living) で定義さ

れる日常生活の基本的行動であり、睡眠、食事、家事、くつろぎ、入浴等である。推論モデルとして Markov Logic Network (MLN) [35] の拡張モデルを用いる。MLN は確率論理モデルの一つで、一階述語論理 F_i と実数値の重み w_i の組 (F_i, w_i) の集合である。重み w_i で事象の曖昧性が表現可能な点が通常の論理モデルとは異なり、 w_i が大きいほど成立する可能性がより高いことを示す。確率分布は以下のように表される。

$$P(X = x) = \frac{1}{Z} \exp\left(\sum_i w_i n_i(x)\right) \quad (1)$$

$$Z = \sum_x \exp\left(\sum_i w_i n_i(x)\right) \quad (2)$$

Z は確率の和を 1 にする正規化定数であり、 $n_i(x)$ は x によって F_i が真となった回数である。各述語論理に対応する重みは、教師データにより尤もらしい値を学習しておく。重み $\mathbf{w} = (w_1, \dots, w_m)$ が与えられた時の対数尤度は

$$\log P(X = x|\mathbf{w}) = \sum_i x_i n_i(x) - \log Z \quad (3)$$

となり、これを最大化するために勾配を計算すると、

$$\begin{aligned} & \frac{\partial}{\partial w_i} \log P(X = x|\mathbf{w}) \\ &= n_i(x) - \sum_x n_i(x) \frac{1}{Z} \exp\left(\sum_i w_i n_i(x)\right) \\ &= n_i(x) - \sum_x n_i(x) P(X = x|\mathbf{w}) \\ &= n_i(x) - E_x[n_i(x)] \end{aligned} \quad (4)$$

を得る。すなわち、与えられた x を充足する個数 $n_i(x)$ がその期待値 $E_x[n_i(x)]$ と等しくなる方向に w_i を更新する。このように、一階述語論理式によって定義されるハードな推論と、各論理式に重みを割り当て学習することによって、確率的な事象をうまく表現できるソフトな推論を兼ね備えており、日常生活行動の推定に適したモデルであるといえる。

4.1 行動ラベルに基づく行動推定手法

図 4 は手法 1 の概要である。手法 1 では、人感センサーの生データから「タイムブロック」を生成し、MLN の入力形式に変換処理するフェーズ (フェーズ 0)、人感センサー位置情報や家電の使用情報から各タイムスロットにおける行動を、MLN の論理で規定されるセンサーと行動を関連付ける推論規則 (SA ルール) に基づき推定するフェーズ (フェーズ 1)、ならびにその推定結果を個人の習慣や規則性を説明する規則 (TC ルール) で判定し、SA ルールの初期設定にフィードバックするフェーズ (フェーズ 2) からなる。

4.1.1 フェーズ 0 におけるタイムブロック生成

行動推定の前処理として、人感センサーデータから MLN

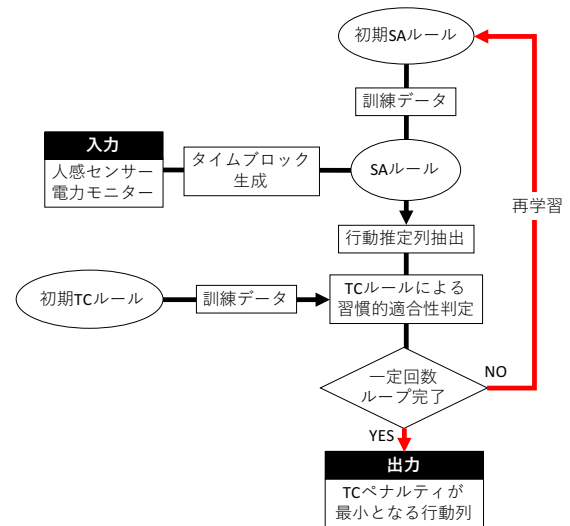


図 4 アルゴリズムアーキテクチャ (手法 1)

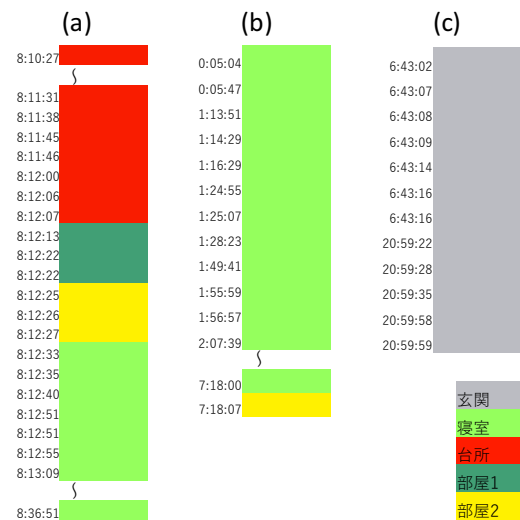


図 5 実家庭での人感センサーの時系列データ (一部抜粋)

の入力を生成する必要がある。本研究で対象とする行動は、ある場所で一定時間滞在する行動であることから、滞在行動のみを正しく検出するためには、移動による通過で反応したセンサーデータを除去することが望ましい。また、3.1 章で述べたように、焦電センサーの性質上、検知範囲内で人が静止状態に近くなると検知が難しくなるため、それを加味したうえで MLN の入力とする必要がある。さらに外出時状態 (センサーの無反応時間) を検出する必要もある。この目的のため、センサーが設置された各部屋 (スペース) に対し、滞在時間帯 (開始および終了時刻) を表す「タイムブロック」を以下のように生成する。

- パターン 1: 例えば図 5(a) では、台所から寝室に移動する間に、部屋 1 と部屋 2 に数秒程度存在していることがわかるが、これらの滞在時間は十分に短く、単なる通過であると判定できる。移動時ではこういった短時間内に複数箇所にセンサーが反応するため、予め定め

た最低滞在時間（本研究では 30 秒）より短い滞在時間は移動と判定する。図 5(a) では (台所,8:10:27,8:12:07) と (寝室,8 時 12 分 33 秒,8 時 36 分 51 秒) のタイムブロックを生成する。

- パターン 2: 図 5(b) のように, 0 時 05 分 04 秒~1 時 13 分 51 秒は実際は寝室にいるが, 人感センサーの反応がなく寝室にいることが単純には判断できない。また図 5(c) のように 6 時 43 分 16 秒~20 時 59 分 22 秒に実際に外出している状況も存在する。そこで玄関で人感センサーの反応が止まれば外出, それ以外はその前後の場所での滞在とみなし, 無反応時間を補完する。すなわち, 図 5(b) では (寝室,0 時 05 分 04 秒,7 時 18 分 00 秒) のタイムブロックを生成し, 図 5(c) では (玄関,6 時 43 分 02 秒,6 時 43 分 16 秒), (屋外,6 時 43 分 16 秒,20 時 59 分 22 秒), (玄関,20 時 59 分 22 秒,20 時 59 分 59 秒) のタイムブロックを生成する。

これらにより得られたデータを MLN の入力として与える。

4.1.2 フェーズ 1 におけるモデルの定式化と SA ルール

フェーズ 1 で用いる定数を以下で定義する。

$$Activity = \{sleep, meal, housework, relax, \dots\} \quad (5)$$

$$Location = \{bedroom, bathroom, outdoor \dots\} \quad (6)$$

$$Name = \{TV, fridge, kotatsu, \dots\} \quad (7)$$

$$Time = \{0, 1, 2, \dots, Timeslot\} \quad (8)$$

Activity, *Location*, *Name* は集合であり, その要素はそれぞれ行動の種類, 家庭内の場所, 家電の名前である。*Time* はタイムスロットの集合であり, 本研究では 15 分毎の行動推定を行うため, *Timeslot* = 95 として実装する。また, 以下の述語を定義する。

$$Pos(t, l) \quad (t \in Time, l \in Location) \quad (9)$$

$$Pwr(t, n) \quad (t \in Time, n \in Name) \quad (10)$$

$$Do(t, l, a) \quad (t \in Time, l \in Location, a \in Activity) \quad (11)$$

Pos は人感センサーと位置との関係を表し, 例えば, *Pos(2, Bedroom)* は居住者がタイムスロット 2 (0 時 30 分~45 分) に寝室に滞在していれば真となる。*Pwr* は消費電力モニターから得られる家電利用情報を表し, 例えば *Pwr(60, TV)* は 15 時 00 分~15 分にテレビが利用されれば真となる。*Do* は行動を表し, 例えば *Do(47, Dining, Meal)* は 11 時 45 分~12 時 00 分にダイニングで食事をしていることを表す。これらを用いてセンサー情報と行動を紐付けた SA (Sensor-Activity) ルールを定義する。表 1 は初期 SA ルールの一例である。

基本行動は各スロットの各場所における行動を示している。*Do(+t, +l, +a)* における+は図 6 で示すように, 複数のルールをまとめて定義する記号として用いる。これらの

表 1 初期 SA ルールの例

行動の種類	重み	SA ルール
基本行動	0	$Do(+t, +l, +a)$
睡眠	1	$Pos(t, bedroom) \Rightarrow Do(t, bedroom, sleep)$
食事	1	$Pos(t, dining) \Rightarrow Do(t, dining, meal)$
料理	1	$Pwr(t, fridge) \wedge Pos(t, kitchen) \Rightarrow Do(t, kitchen, cook)$

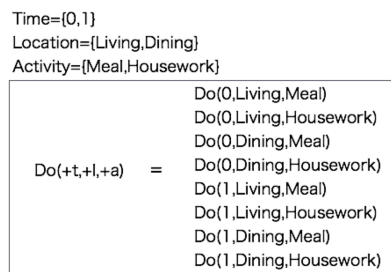


図 6 +による複数ルールのマクロ表現




図 7 MLN の出力と行動推定列の例

重みの初期値は 0 とする。その他のルールは, 行動の種類ごとに定義する。ルールは一階述語論理で定義し, !は否定, \wedge は論理積, \Rightarrow は論理包含を表す。例えば「寝室にいるならば睡眠をしている」は

$$Pos(t, bBedroom) \Rightarrow Do(t, Bedroom, sleep) \quad (12)$$

のように記述する。なお, 各ルールの重みの初期値については, クラウドソーシングアンケートを用い, 44 名の 65 歳以上の高齢者に SA ルールが当てはまる頻度をアンケート形式で回答してもらい, その頻度に応じて重みを設定することで, より多くの高齢者に沿ったルールとなるようにしている。この初期 SA ルールに対して, 数日分のセンサー情報と実際の行動の情報を教師データとして与えて学習させる。

学習によって重み変動した SA ルール (学習済 SA ルール) はあるタイムスロットにおけるセンサーと行動の関係を重みとして保持している。MLN の行動推定は 1 日のセンサー情報を入力とし, 各時間および場所での行動の尤度が確率として出力され, 各タイムスロットの行動尤度が最大のものを MLN の行動推定結果とする。図 7 に MLN の出力と行動推定列の例を示す。

4.1.3 フェーズ 2 における TC ルール

SA ルールでは家庭内に設置されたセンサーと行動の関係を定義しているが, 位置情報や家電利用情報のみでは特定が難しい行動が存在する。例えば「家事」と「くつろぎ」は一見区別しやすいと思われるが, 先述のように比較的部屋数が少ない単身高齢者世帯では場所に大きな差異はなく,




図 8 食事後に家事をする TC ルールを判定する状態遷移図

利用家電にも区別する特徴は見られにくい。そこで、SA ルールに加えて、1日全体の行動を考慮した TC (Temporal and Customary) ルールという時間習慣的ルールを定義する。TC ルールでは「家事はまとめて行う」、「くつろぎは午前中には行わない」、「〇〇時～△△時の間は睡眠している」、「就寝する前には入浴をする」、「1日3回食事をする」といった、時間や行動回数に関するルールや居住者の習慣的ルールを定義する。これらのルールについても、高齢者にアンケートに答えてもらい、高齢者に適した自然なルールを定義するように工夫している。

以下では TC ルールの記述方法ならびに、初期 SA ルールの重みの再学習、および最終的な行動推定列を決定するプロセスを説明する。以下は TC ルールの記述方式である。

$$TCR_i = (Searcher_i(AA)) \quad (i = 1, 2, \dots, n) \quad (13)$$

各 TC ルールは探索器 (Searcher) からなり、 n は TC ルールの個数である。探索器は SA ルールで得た行動推定列から TC ルールに該当する箇所を探索するものであり、入力列として MLN から得られる行動推定列 (AA:Activity Array) をとる。出力はバイナリ列であり、1 が出力の時はその箇所が TC ルールに該当する行動であることを表している。例えば、「食事の後は家事をする」というルールの探索器は図 8 のような簡単な状態遷移図で表される。食事という行動の次タイムスロットで家事をしたならば、その入力行動に対し 1 を出力し、そうでなければ 0 を出力する。

フェーズ 1 で導出した行動推定結果に対し、TC ルールに該当しない行動がある日数をもとに、TC ペナルティとよぶ値を求める。TC ペナルティは行動推定列の不自然さを表し、この不自然さを軽減するために、TC ルールに違反した行動推定列の箇所に対応する基本行動の初期 SA ルールの重みを変更し、再度重みを学習させて行動推定列を出力する。これにより違反した行動の確率が低くなり、次に高い確率の行動が出現するようになる。これを一定回数繰り返すか、もしくは TC ペナルティが 0 になったとき、TC ペナルティが最小となる行動推定列を最終的な行動推定列とする。

4.2 インタラクティブ行動推定手法

手法 1 ではセンサー情報に対する実行動情報を訓練データとして用いるため、正解データを必要とする点で居住者、

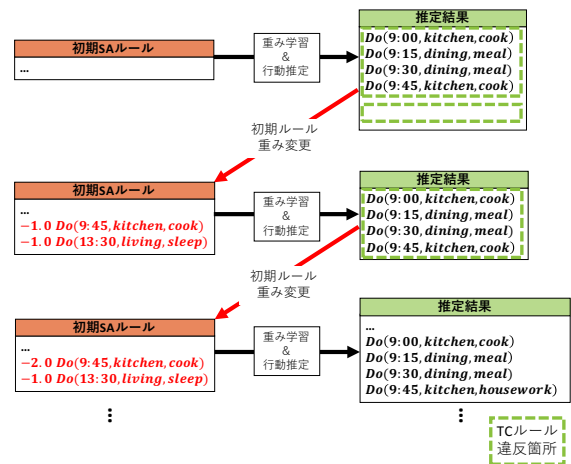


図 9 SA ルールの再学習

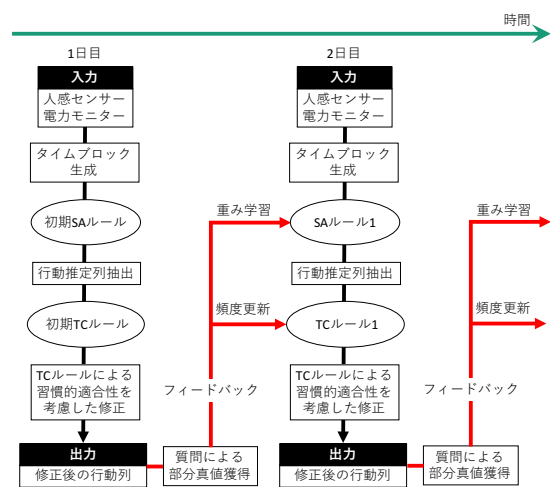


図 10 アルゴリズム概要 (手法 2)

特に高齢者への負担は少なくない。これに対し、手法 2 では訓練データの代わりに簡易な質問を生成し、そのフィードバックから学習を行う。図 10 に手法 2 の概要を示す。手法 1 と同様に 3 フェーズからなり、フェーズ 0 は手法 1 と共通である。フェーズ 1 は SA ルールの定義は同じであるが、手法 1 のフェーズ 1 から事前学習のステップを除いたものである。フェーズ 2 は TC ルールを用いた行動推定列の修正および居住者への簡易な質問の生成ならびにその回答に基づく再学習が含まれる。

以下ではフェーズ 2 について述べる。フェーズ 1 で得た行動推定列に対し、複数ある TC ルールのうちいくつかのルールをランダムに選択して時間習慣的ルールへの適合性判定を行い、判定結果ならびにそのルールの居住者の適合頻度に基づき行動推定列の修正を行う。TC ルールの頻度についてはシステム導入時のヒアリング等で設定する。例えば「一日一回夜に入浴をする」という TC ルールの頻度を 0.9 と設定した場合、フェーズ 1 で得た行動推定列において夜に入浴をしている行動推定がなされない場合、頻度に基づき確率 90% で該当する行動推定部分を修正し、修正

後の行動推定列を最終的な行動推定列とする。

また、行動学習のために推定結果に基づく質問を生成し、その回答をフィードバックする。例えば、「今日は昼食後に洗い物をしましたか?」、「今日は外出をしましたか?」、「テレビをつけながら寝てしまいましたか?」といった質問は、生成した行動推定列と TC ルールから単純に生成できる。回答においては、実施の有無（はい/いいえ）の回答のみならず、複雑にならない範囲で複数選択肢（はい/いいえ/昼食を食べていません/夕食後は洗い物をしました、など）でより詳細な情報を得ることも考えられる。この回答で得られた結果に基づき誤った推定を更新し、その他の行動推定結果はそのまま用いて SA ルールの重み再学習を行うとともに、用いた TC ルールの頻度を更新する。

5. 行動ラベルに基づく行動推定手法の評価

5.1 データ取得環境



図 11 家庭 A におけるセンサー設置場所

3章で説明したシステムを用い、単身高齢者2世帯に対し、人感センサーならびに消費電力モニターデータの収集を行った。対象家庭は69歳の独居女性(家庭A)と84歳の独居女性(家庭B)である。間取り図、ならびに人感センサーと消費電力モニターの設置位置、人感センサーの検出範囲を図11および図12にそれぞれ示す。また、消費電力モニターを設置している家電とそれらの設置場所を表2および表3に示す。

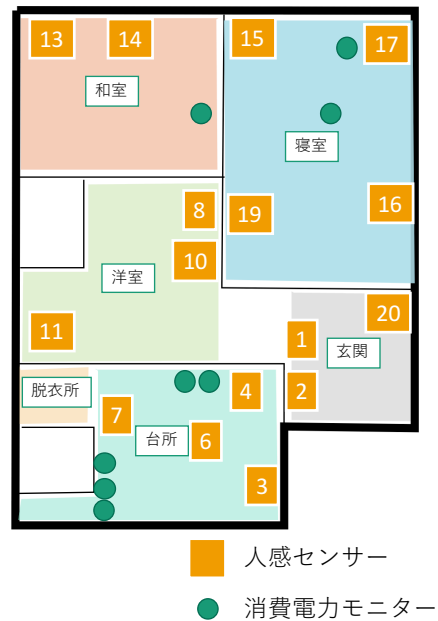


図 12 家庭 B におけるセンサー設置場所

表 2 家庭 A における消費電力モニターの設置場所

センサー ID	家電名	設置場所
015405	テレビ	リビング
015096	トースター	台所
015615	電子レンジ	台所
015269	ポット	台所
015378	洗濯機	脱衣所
015896	こたつ	寝室
015378	掃除機	指定なし

表 3 家庭 B における消費電力モニターの設置場所

センサー ID	家電名	設置場所
015384	テレビ	寝室
015246	食器乾燥機	台所
015316	コーヒーマーカー	台所
015096	トースター	台所
015615	電子レンジ	台所
015405	洗濯機	台所
015896	こたつ	寝室
015378	掃除機	指定なし
015178	ドライヤー	和室

5.2 評価

提案手法1に基づいてセンサーデータをそれぞれの家庭につき7日間収集し、居住者には7日分の行動とその行動場所を15分毎に記録してもらい、それを行動推定の真値とした。うち6日分を学習データ、1日分をテストデータとして交差検証を行った結果を述べる。表4、5は行動種類の適合率と再現率である。2世帯ともに全体の適合率と再現率は70%を上回る結果になった。なお、行動別に見ると、精度が高い行動と低い行動とが明確に区別される。ま

表 4 行動別の適合率と再現率 (家庭 A)

行動	適合率 (%)	再現率 (%)
睡眠	100	100
食事	100	40.0
料理	25.0	50.0
くつろぎ	69.0	96.6
入浴	100	100
家事	50.0	37.5
外出	-	-

表 5 行動別の適合率と再現率 (家庭 B)

行動	適合率 (%)	再現率 (%)
睡眠	89.5	99.0
食事	70.1	47.8
料理	53.8	38.9
くつろぎ	85.0	89.2
入浴	64.7	68.2
家事	83.3	64.3
外出	100	100

た、家庭の間取りにも精度が影響されることもわかった。なお、家庭 A における外出の行動は 7 日間で 1 日しか実際に行われておらず、事前学習が十分にできなかったために評価から除外している。適合率、再現率が共に高かった睡眠は、その時間帯に習慣性があり、かつ場所に強く依存した行動であったために高精度な推定ができていた。家庭 A では精度が高く、家庭 B では精度が低かった入浴に関して、家庭 A は脱衣所が他の部屋と区切られていたことに対し、家庭 B は脱衣所と台所に明確な区切りがなかったことが精度に大きく影響していると考えられる。一方で、料理については家電と人感センサー双方に関連する SA ルールを設定したが、実際は家電を使用していないケースも多く見受けられた。また、家事については 15 分で様々な場所で人感センサーの反応があったため、場所に紐づけた SA ルールによる推定が困難であったことにより、精度が低くなる結果になったと考えられる。本質的にこれらの精度を向上させるためには、より習慣性が出る長期データでの学習が必要であると考えられる。

6. フィードバックに基づくインタラクティブ行動推定手法の評価

ユーザーフィードバックに基づくインタラクティブ行動推定手法の評価を述べる。データ取得環境は 5 章で述べた家庭 B のデータを用いて 2 回のユーザーへのフィードバックを行った。1 回のユーザーへのフィードバックで多くの質問をするのは居住者の負担になることを考慮して、今回は 4 つの質問を 1 回のフィードバックで行った。図 13, 14 はフィードバック回数に対する各行動の適合率、および再現率を表したものである。睡眠や外出、食事といった行動はユーザーフィードバックによる修正をしなくても高い精




図 13 ユーザーフィードバックによる適合率の変化




図 14 ユーザーフィードバックによる再現率の変化

度を得ることができた。食事の精度が手法 1 の精度より高くなった理由として、手法 2 では「食事は 1 日 3 回行う」という頻度が高い TC ルールによって、該当する行動推定部分が修正されたためと考えられる。また、料理に関してはユーザーフィードバックを重ねるごとに適合率、再現率ともに向上した。一部を除いて全体的にはユーザーフィードバックを重ねるごとに精度が向上した。事前の学習データを必要としない本手法は、システム導入開始時は手法 1 に比べて精度が低いですが、ユーザーフィードバックを重ねるごとに精度が向上することが期待できるので、居住者、特に高齢者のシステム導入の初期負担が小さい手法であり、より実用的な手法と言える。一方で、様々なユーザーフィードバックの生成方法があるため、最も適切なフィードバックを選ぶ方法について今後検討を重ねていく。

7. おわりに

本稿では、配置が容易でかつプライバシーリスクが少ない赤外線ポータブル人感センサー及びタップ消費電力モニターを複数利用した高齢者の家庭内生活での行動推定手法を 2 つ提案した。

また開発したプロトタイプシステムを 2 つの家庭に 1 週間導入し、行動推定の性能を評価した。初期導入コストが小さく、結果的に行動ラベルに基づく行動推定手法よりも

高い精度となったインタラクティブ行動推定手法ではあるが、様々なユーザフィードバック生成方法があるため、最も適切なフィードバックを選ぶ方法について今後検討を重ねていく。

謝辞

本研究の一部は JSPS 科研費 JP15H02690 の助成を受けたものです。

参考文献

- [1] Byun, J., Hong, I. and Park, S.: Intelligent Cloud Home Energy Management System Using Household Appliance Priority Based Scheduling Based on Prediction of Renewable Energy Capability, *IEEE Transactions on Consumer Electronics*, Vol. 58, No. 4, pp. 1194–1201 (2012).
- [2] 中村笙子, 志垣沙衣子, 廣森聡仁, 山口弘純, 東野輝夫: 大衆の生活ノウハウの定量化とモデル化によるスマートライフ支援システム, *情報処理学会論文誌*, Vol. 56, No. 8, pp. 1621–1633 (2015).
- [3] Nakamura, S., Shigaki, S., Hiromori, A., Yamaguchi, H. and Higashino, T.: A Model-based Approach to Support Smart and Social Home Living, *Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing (UbiComp '15)*, pp. 1101–1105 (online), DOI: 10.1145/2750858.2805835 (2015).
- [4] Nakahara, K., Yamaguchi, H. and Higashino, T.: In-home Activity and Micro-motion Logging Using Mobile Robot with Kinect, *Adjunct Proceedings of the 13th International Conference on Mobile and Ubiquitous Systems: Computing Networking and Services (MUSICAL 2016)*, pp. 106–111 (2016).
- [5] Kitbutrawat, N., Yamaguchi, H. and Higashino, T.: Localization of Binary Motion Sensors in House, *Proceedings of the 13th International Wireless Communications and Mobile Computing Conference (IWCMC2017)*, pp. 1–6 (2017).
- [6] 総務省統計局: 統計トピックス No.97 統計からみた我が国の高齢者 (65 歳以上)-「敬老の日」にちなんで. <http://www.stat.go.jp/data/topics/topi721.html>.
- [7] Michael, H., Nguyen-Dinh, Long-Van, Alberto, C., Gerhard, T. and Daniel, R.: Enhancing action recognition through simultaneous semantic mapping from body-worn motion sensors, *Proceedings of the 2014 ACM International Symposium on Wearable Computers*, pp. 99–106 (2014).
- [8] Gaglio, S., Re, G. L. and Morana, M.: Human Activity Recognition Process Using 3-D Posture Data, *IEEE Transactions on Human-Machine Systems*, Vol. 45, No. 5, pp. 586 – 597 (online), DOI: 10.1109/THMS.2014.2377111 (2015).
- [9] ST マイクロエレクトロニクス: Mother, Motion Cookies. <https://www.sen.se/>.
- [10] Sony Mobile Communications Inc.: Smart wear. <http://www.sonymobile.co.jp/product/smartwear/>.
- [11] Fukui, R., Ifuku, H., Watanabe, M., Shimozaka, M. and Sato, T.: Easy-to-install system for daily walking ability assessment using a distance sensor array, *Journal of Ambient Intelligence and Smart Environments (JAISE)*, Vol. 7, No. 3, pp. 375–387 (2015).
- [12] Feuz, K. D., Cook, D. J., Rosasco, C., Robertson, K. and Schmitter-Edgecombe, M.: Automated Detection of Activity Transitions for Prompting, *IEEE Transactions on Human-Machine Systems*, Vol. 45, No. 5, pp. 575 – 585 (2015).
- [13] Riboni, D., Bettini, C., Civitarese, G., Janjua, Z. H. and Helaoui, R.: Fine-grained recognition of abnormal behaviors for early detection of mild cognitive impairment, *Proceedings of the 2015 IEEE International Conference on Pervasive Computing and Communications (PerCom 2015)*, pp. 149–154 (2015).
- [14] S., R. and N., B.: Using rule mining to understand appliance energy consumption patterns, *Proceedings of 2014 IEEE International Conference on Pervasive Computing and Communications (PerCom 2014)*, pp. 29–37 (2014).
- [15] Chen, M. T. and Lin, C. M.: Development of a smart home energy saving system combining multiple smart devices, *Proceedings of 2016 IEEE International Conference on Consumer Electronics-Taiwan (ICCE-TW)* (2016).
- [16] Bourgeois, J., van der Linden, J., Kortuem, G., Price, B. A. and Rimmer, C.: Conversations with My Washing Machine: An In-the-wild Study of Demand Shifting with Self-generated Energy, *Proceedings of the 2014 International Conference on Pervasive and Ubiquitous Computing (UbiComp '14)*, pp. 459–470 (2014).
- [17] 村尾和哉, 藤堂智史, 寺田努, 矢野愛, 松倉隆一, 塚本昌彦: 住宅内に設置した人感センサを用いた住人の移動推定手法, マルチメディア, 分散協調とモバイルシンポジウム 2011 論文集, Vol. 2011, pp. 315–322 (2011).
- [18] 村上雅紀, 岡部正幸, 梅村恭司: 赤外線センサによる行動予測の実現性のためのデータ照合, 第 3 回データ工学と情報マネジメントに関するフォーラム B9-3 (2011).
- [19] 江田政聡, 賀新剛, 中根傑, 横山昌平, 福田直樹, 峰野博史, 石川博: 赤外線センサを用いた在席推定に基づく照明制御手法の提案, 第 4 回データ工学と情報マネジメントに関するフォーラム A10-4 (2012).
- [20] Mokhtari, G., Zhang, Q., Nourbakhsh, G., Ball, S. and Karunanithi, M.: BLUESOUND: A New Resident Identification Sensor – Using Ultrasound Array and BLE Technology for Smart Home Platform, *IEEE Sensors Journal*, Vol. 17, No. 5 (online), DOI: 10.1109/JSEN.2017.2647960 (2017).
- [21] Hnat, T. W., Griffiths, E., Dawson, R. and Whitehouse, K.: Doorjamb: Unobtrusive Room-level Tracking of People in Homes Using Doorway Sensors, *Proceedings of the 2012 International Conference on Embedded Network Sensor Systems (SenSys 2012)*, pp. 309–322 (2012).
- [22] Mashiyama, S., Hong, J. and Ohtsuki, T.: Activity recognition using low resolution infrared array sensor, *2015 IEEE Int. Conf. on Communications (ICC)* (2015).
- [23] Jiang, X., Chen, Y., Liu, J., Hayes, G. R., Hu, L. and Shen, J.: AIR: Recognizing Activity Through IR-based Distance Sensing on Feet, *Proceedings of the 2016 International Conference on Ubiquitous Computing (UbiComp 2016)*, pp. 97–100 (2016).
- [24] Santo, H., Maekawa, T. and Matsushita, Y.: Device-free and privacy preserving indoor positioning using infrared retro-reflection imaging, *2017 IEEE International Conference on Pervasive Computing and Communications (PerCom)*, pp. 141–152 (online), DOI: 10.1109/PERCOM.2017.7917860 (2017).
- [25] Chen, L., Hoey, J., Nugent, C. D., Cook, D. J. and Yu, Z.: Sensor-Based Activity Recognition, *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Ap-*

- plications and Reviews*), Vol. 42, No. 6, pp. 790–808 (online), DOI: 10.1109/TSMCC.2012.2198883 (2012).
- [26] BoxLab: BoxLab Wiki Page. <http://boxlab.wikispaces.com/>.
 - [27] Ordonez, F., Englebienne, G., de Toledo, P., van Kasteren, T., Sanchis, A. and Krose, B.: In-Home Activity Recognition: Bayesian Inference for Hidden Markov Models, *IEEE Pervasive Computing*, Vol. 13, No. 3, pp. 67–75 (2014).
 - [28] Rashidi, P., Cook, D. J., Holder, L. B. and Schmitter-Edgecombe, M.: Discovering Activities to Recognize and Track in a Smart Environment, *IEEE Transactions on Knowledge and Data Engineering*, Vol. 23, No. 4, pp. 527–539 (online), DOI: 10.1109/TKDE.2010.148 (2011).
 - [29] Wang, Y., Fan, Z. and Bandara, A.: Identifying activity boundaries for activity recognition in smart environments, *Proceedings of 2016 IEEE International Conference on Communications (ICC)*, pp. 1–6 (online), DOI: 10.1109/ICC.2016.7510732 (2016).
 - [30] Rafferty, J., Nugent, C. D., Liu, J. and Chen, L.: From Activity Recognition to Intention Recognition for Assisted Living Within Smart Homes, *IEEE Transactions on Human-Machine Systems*, No. 99, pp. 1–12 (online), DOI: 10.1109/THMS.2016.2641388 (2017).
 - [31] Logan, B. and Healey, J.: Sensors to Detect the Activities of Daily Living, *Proceedings of 2006 Int. Conf. of the IEEE Engineering in Medicine and Biology Society*, IEEE (2006).
 - [32] Arduino: Arduino Uno Revision 3 (2014). <http://arduino.cc/en/Main/arduinoBoardUno>.
 - [33] 超小型 ZigBee モジュール TWE-Lite : Tokyo Cosmos Electric Co.,Ltd. <http://tocos-wireless.com/jp/products/TWE-001Lite.html>.
 - [34] ENEGATE: Smart Ecowatt (2012). https://www.enegate.co.jp/smarteco_portal/index.html.
 - [35] Richardson, M. and Domingos, P.: Markov logic networks, *Machine learning*, Vol. 62, No. 1, pp. 107–136 (2006).