

HEMS 電力データを用いた 家庭内行動認識手法の実家庭における評価

田中 福治¹ 水本 旭洋¹ 山口 弘純¹

概要：HEMS (Home Energy Management System) の普及に伴い、HEMS が集計した消費電力データを利用した新しいサービスへの期待が高まっており、その一つとして居住者の行動認識がある。我々の研究グループでは、HEMS 住宅分電盤から得られる分岐回路別の 30 分毎の累計消費電力情報のみから家庭内行動推定を行う手法を提案してきた。同手法では、まず分岐名称を解析することで各分岐が電力を集計している部屋と家電の特定を行い、どの行動に最も関連しているかを判別する。家電毎に集計している分岐に関しては家電の稼働推定を行うことで、行動の認識を行い、部屋毎に集計している分岐に関しては、30 分粒度でも認識可能な特徴量を設計して、ランダムフォレストを用いることで行動の認識を行う。また、転移学習を適用することによって家庭間の差異に適応している。本研究では、同手法の実環境における有用性検証を行ったためその結果について報告する。協力企業との連携のもと 3 家庭にセンサを導入する真値取得実験を行い、得られた真値をもとに提案手法を評価した。その結果、起床と就寝に関しては消費電力のみから推定することは難しいことがわかった。一方で入浴、調理、洗濯、皿洗いの 4 行動に関しては平均 F 値 0.76 を達成し、実環境においても十分に認識が可能であることがわかった。また入浴に関しては転移学習により F 値が 0.22 向上することが確認できた。

1. はじめに

政府は「グリーン政策大綱」において、2030 年までに全世帯へ HEMS を設置することを目標としていることから、HEMS のこれまで以上の普及や利活用が想定されている。HEMS によって計測、記録された部屋やフロアなどの区画消費電力や専用コンセント毎の消費電力情報を利用した新しいサービスが期待されている。消費電力情報を用いたサービスの要素技術の一つとして行動認識が挙げられる。消費電力データに基づく行動認識では、カメラ等を用いる場合に課題となるプライバシー侵害や低受容性を回避でき、環境設置型のセンシングデバイスを設置する必要もないといったメリットがある。HEMS データから居住者の行動を特定できれば、居住者へのエネルギー使用量のフィードバック、エネルギー利用傾向による消費者プロファイリング、エネルギー需要の短長期予測の高精度化など多様な応用が期待できる。デマンド予測のみならず、顧客プロファイリングやターゲットマーケティングなどのビッグデータ活用、世帯の行動傾向推定や高齢者見守りを含むリモートヘルスケアなどが低コストで実現可能となる [1] [2]。

これまでに、家庭内消費電力データに基づく様々な行動推定が研究されてきているものの、先行研究はいずれも時間的粒度が比較的高い電力データを想定している。近年、HEMS 対応住宅分電盤の中には高い時間粒度で計測可能なシステムも出始めているが、ハードウェアコストや費用対効果の観点からも、既存の HEMS 対応住宅分電盤の多くはそういった時間分解能の高いデータを他のサービス用途に出力する仕様にはなっていない。

一方で、分岐回路別の消費電力が集計可能であることから、調理や皿洗い、洗濯など、家庭内の行動に紐づく家電の使用を把握できる可能性は高い。また、時間粒度が低い場合も、入浴のような長時間にわたる行動やドライヤの利用など消費電力量が大きい家電利用を伴う行動を検出できる可能性もある。これらから個々の行動発生を推測すれば、世帯全体の大まかな行動パターンが把握でき、生活リズムの乱れの検知や家事従事時間の定量化などへの応用も期待できる。

そこで我々は文献 [3] において、HEMS 住宅分電盤から得られる分岐回路別の 30 分毎の累計消費電力情報のみから家庭内行動推定を行う手法を提案した。この手法では、分岐毎につけられている名称を分析することで行動に直接関連する分岐のみを取り出して、関連しない分岐による悪影響を取り除き、各行動に 30 分毎でも認識可能な特徴量

¹ 大阪大学大学院情報科学研究科
Graduate School of Information Science and Technology, Osaka University

を特別に設計することで、起床、就寝、調理、洗濯、皿洗い、入浴、洗面行動の7行動を推定している。

本研究では、同手法の実環境における有用性検証を行う。協力企業との連携のもと3家庭にセンサを導入する真値取得実験を行い、得られた真値をもとに同手法を評価した。同実験では協力者のプライバシー侵害を防ぎ、負担を軽減するために文献[4]に示されているSALONシステムを導入し、環境発電で駆動するセンサを用いて真値取得を行う。洗濯機と食洗機の稼働を太陽光パネル付きの環境センサで計測し、調理と入浴、起床就寝はボタンの押下により発電し、電波を飛ばすスイッチモジュールを開始と終了時に押しってもらうことで認識している。また、ボタンの押し忘れに対応するために太陽光パネル付きのドアセンサとFitbitも加えて導入している。その結果、起床と就寝に関しては消費電力のみから推定することは難しいことがわかった。一方で入浴、調理、洗濯、皿洗いの4行動に関しては平均F値0.76を達成し、実環境においても十分に認識が可能であることがわかった。また入浴に関しては転移学習によりF値が0.22と大きく向上することが確認でき、起床就寝に関しても精度が向上していることから、転移学習が有効であることがわかった。

2. 関連研究

画像や音声による行動認識

画像や音声は居住者の直接的な行動状態やその周辺状況を取得できるため、高精度な行動認識が可能である。例えば、文献[5]では動画画像で人の動きとその動きに用いられる物体や周辺環境情報を取得し、詳細な行動認識を実現している。文献[6]ではカメラとマイクを用いた人間行動の学習と認識に取り組んでいる。文献[7]ではスマートフォンの内蔵マイクや加速度センサのみを用い、屋内外の8種類の行動を推定し、89.5%から93.8%の精度を達成している。文献[8]では動画画像からの人の動きとその背景情報および効用関数の関係を学習し、行動推定モデルを構築する手法を提案している。文献[9]では動画画像から局所的な体の動きと姿勢を推定しそれらを組み合わせることで10種類の日常生活行動を98%で判別している。文献[10]ではマイクを用いて環境音と発話を検出し、3Dトラッキングカメラから得たデータと組み合わせることで、複数人を対象とした行動推定において70~90%の精度を実現している。画像や音声メディアは高精度を実現しやすい反面、家庭における受容性が著しく低いといった課題がある。

ウェアラブルデバイスによる行動認識

文献[11]では手に磁気センサを装着し、家電が発する固有の磁気を検知することで14種類のADLの判別を平均精度80%で実現している。

文献[12]では身体に加速度センサ、角速度センサおよび

コンパスを装着し、平均認識率86.7%で歩行動作の検出を実現している。

文献[13]では家の中の多数のオブジェクトにRFIDタグを取り付け、プレスレットの形のRFIDリーダーを装着させた居住者の日常生活活動を認識する手法を提案している。文献[14]ではスマートホームのマルチセンサーデータストリームから得られる様々のセンサからの情報に加えて人の活動位置による行動の偏りや背景情報などから日常生活活動を分析し、94.44%の平均アクティビティ認識率を達成している。文献[15]ではスマートホーム内に設置された赤外線センサ、ドアセンサ、浴室の温度および湿度センサ、およびマイクから収集されたデータを用いて、日常生活を掃除、トイレの使用、食事、休憩、睡眠、会話、着衣・脱衣の7つの活動に分類する手法を提案している。これらの手法は様々なセンサを多数宅内に設置するため導入コストと死活監視等のメンテナンスコストが高くなり、大規模なサービス運用には向かない。

消費電力データからの行動推定

これらの課題に対し居住者のプライバシーを考慮しセンサ装着による負担のない行動認識手法として、スマートタップが取得する家庭内の各コンセントの消費電力の情報と屋内位置センサから得られるコンセントの位置を用いた行動推定手法が挙げられる。文献[16]では家電製品に取り付けられた電力計と、住宅の居住者に取り付けられた位置センサを用いて10種類の生活活動を認識し、平均F値97.8%を達成している。文献[17]では高い検出周波数を備えた新しいパワーメーターの開発、新しい機能の追加、機能の最適なサブセットの選択、使用する最適なトレーニングデータセットの選択などの新しい手法を導入し、10種類の日常生活行動を79.393%の精度で認識している。文献[18]では消費電力の情報に加えて行動が発生する時間帯、同じ場所に滞在する時間、行動以前の位置などの時空間情報を加えることで10種類のアクティビティで平均認識精度82%を達成している。上記の手法ではマイクやカメラを必要としないことから居住者のプライバシーを考慮しており、またセンサを装着する必要がないため身体的負担を与えず、電源に接続されているためメンテナンス性に優れている。しかし、この手法にも屋内位置センサやスマートタップを導入する必要があるため導入コストが高いという問題がある。

一方、配電盤から取得できる総電力を用いて家電を推定することで、単一センサによる行動推定を実現している研究もある。これらの研究ではHEMSにて消費電力を計測しているスマートメータを用いて屋内行動推定を試みており、予め設置されている設備を用いていることから屋内位置センサやスマートタップを導入する必要がない。文献[19]では階層隠れマルコフモデルを用いて複数家電の稼

働状態をモデル化することで総電力から家庭に設置されている各家電の稼働時間を推定している。文献 [20] では、居住者の行動によって引き起こされるエネルギー使用量の変化にパターンマイニングやクラスター分析を行い、結果をベイジアンネットワークへ入力することで家庭内行動の認識を行なっている。文献 [1] では、波形のエッジ検出により家電の起動を認識し、エッジに対して深層学習による分類を行うことで、家電の分類を行い、起動家電から行動の推定を行なっている。我々の研究グループでも、配電盤から得られる総電力を用いて行動を推定しており、料理や睡眠などの行動を 70% の精度で認識している [21]。しかし、これらのいずれも高い時間粒度のデータを対象としており、30 分毎という低粒度の電力データを扱うことを考えていない。また個別に電力を計測する必要がない一方、多様な家電の組み合わせに対応するのが容易でない。

本研究の位置づけ

本研究では、高齢者の見守りや居住者のエネルギー使用量に関する詳細なフィードバックの提供を目的として、HEMS によって集計される分岐別の消費電力データから、居住者の行動の推定を行う。HEMS 配電盤による手法は非侵襲であり、既設置機器を用いるためにメンテナンスコストや導入コストの面で優れているといえる。また既存研究は秒単位といった高時間粒度で計測した統合消費電力データを用いるものがほとんどであるが、提案研究では 30 分毎と非常に低粒度で集計された分岐回路別の消費電力を用いている点で独自のアプローチである。

3. 手法概要

3.1 HEMS データ

我々は HEMS 分電盤から得られる消費電力データからの家庭内行動推定を実現するために、協力企業との連携のもと 935 邸の HEMS にて 1 年間観測された計 3.3 億点もの消費電力データを入手した。本研究において想定している HEMS システムを図 1 に示す。図 1 に示すように日本で現在普及している HEMS では消費電力の効果的な可視化のために、家単位ではなく、分岐毎に消費電力を 0.01Wh を最小単位として集計している。例えば図 1 中では分岐 2 と分岐 3 はその部屋の照明やテレビ、冷蔵庫などのコンセントに接続されている家電の電力をまとめて計測しており、分岐 1 と分岐 4 ではエアコンと洗濯機をそれぞれ計測しており、これらは分岐として別々に集計される。しかしながら、現在普及している HEMS は仕様上、30 分毎の積算電力しか計測することができず、時間的粒度が非常に低い。30 分という集計周期は人の行動の長さとは比べると長く、この時間間に複数の行動が起こりうる。積算して集計していることから、その計測時間内に複数の行動が行われていたり、複数の家電が稼働していたりしても分離することが

できない。また 30 分の間でどのくらいの長さ行動していたかもわからないため、瞬間的な消費電力量も導出することができない。例えば照明を 30 分間使用したときと照明の 30 倍ほどの消費電力を示すドライヤを 1 分間使用したときで同じ値を示してしまう。そのためこのデータから従来のように稼働した家電の種類を特定して、特定した家電を使う行動を推定する手法を用いることが困難である。

ここで入手したデータの内ある家庭の 1 日分のデータを図 2 に示す。図 2 を見ると各分岐には可視化の際にどこでどのように電力が消費されたかがわかるように”主寝室”や”食洗機用”といったように分岐名称が付けられている。この名前には部屋の名前以外にも食洗機などの特定の家電の名前が入っていることから家電毎に集計している分岐があり、その家電がわかるようになっている。データを解析した結果、専用回路と汎用回路という 2 種類の回路があり専用回路は一つの家電単独の分岐であり、汎用回路は部屋単位で集計されている分岐でその部屋内の照明やコンセントに接続された家電全てが集計されていることがわかった。そのため専用回路であれば分岐名称から接続されている家電を特定でき、そこから家電の稼働を検出し、行動を認識できるのではないかと考えられる。一方で統合されている分岐に関しては接続されている家電の数と種類ともにわからず、集計周期の長さも相まって、家電を分離することや家電を特定することは難しい。しかし、部屋の種別と家電の種類には関係があり、部屋名から家電の種類を絞り込むことができる。例えばドライヤはホールで使われることはまずなく、洗面室で使われることが多い。加えて消費電力の大きな家電に関しては、洗面室のように通常高い消費電力を示さない部屋において低い粒度で計測されていても認識可能である。従ってドライヤやヘアアイロンを利用するような洗面行動に関しては低い粒度で計測されていても認識可能であると言える。また家電の種類が分からなくとも、起床就寝のような行動前と行動後に長期にわたる変化が見られるような行動に関しては低い粒度で計測されていても認識可能であると言える。そこで本研究では上記のような低粒度であっても分岐毎で集計されていることで認識可能な特徴や、分岐名から得られる意味的な情報を用いた行動の認識手法を提案する。

提案手法は、各電力分岐（以降は単に分岐とよぶ）毎に、30 分間（これをスロットとよぶ）ごとの累計消費電力値が得られる HEMS 住宅分電盤からのデータを入力とする。推定する日常生活行動としては、起床、就寝、調理、洗濯、皿洗い、入浴、洗面行動の 7 つとする。これに対し、提案手法は各スロットにおける各行動の有無を出力する。

図 3 に提案手法の概要を示す。提案手法ではまず、各分岐につけられている名称を解析し、分岐を専用回路と汎用回路に分類する。この時同時に専用回路であれば接続されている家電の種別を可能な限り識別する。汎用回路であれ




図 1 本研究にて想定している HEMS システムの例




図 2 分岐別消費電力の例

ば、脱衣室や洗面室という名前であれば洗面行動という行動に関係し、寝室や子供室であれば起床と就寝という行動に関係するというように、各分岐にセマンティクスを割り当てる。次に、専用回路に関しては分岐に接続されている家電の種類が用途がわかっているため、ピーク検出を行うことで家電の稼働認識を行い、稼働した家電を使う行動を認識する。汎用回路に関しては、行動により起こる電力の変動を行動毎に定義した特徴量により取り出し、機械学習を用いて行動を認識する。さらに、一般には生活習慣や消費電力傾向は家庭ごとに大きく異なるため、転移学習により、複数家庭の学習データを用いて作成したモデルを各家に適応させる。

4. 提案手法

4.1 分岐名称解析による分岐への意味情報の付与

節 3.1 で述べたように、得られた消費電力データは粒度が荒く、このデータからそのまま行動を認識することは非常に難しい。しかし、HEMS 本来の目的である可視化のために各分岐には名称がつけられており、この名称から分岐で計測されている家電が単一であるかどうかや家電の名称、計測されている場所が分かるようになっている。各分岐の用途が判明すれば、行動により起こる変化をより良く捉えられ、同じ行動による複数の分岐における消費電力の変動を捉えることで 30 分粒度という低粒度であっても行動の認識が可能となると考えられる。そこで、提案手法で

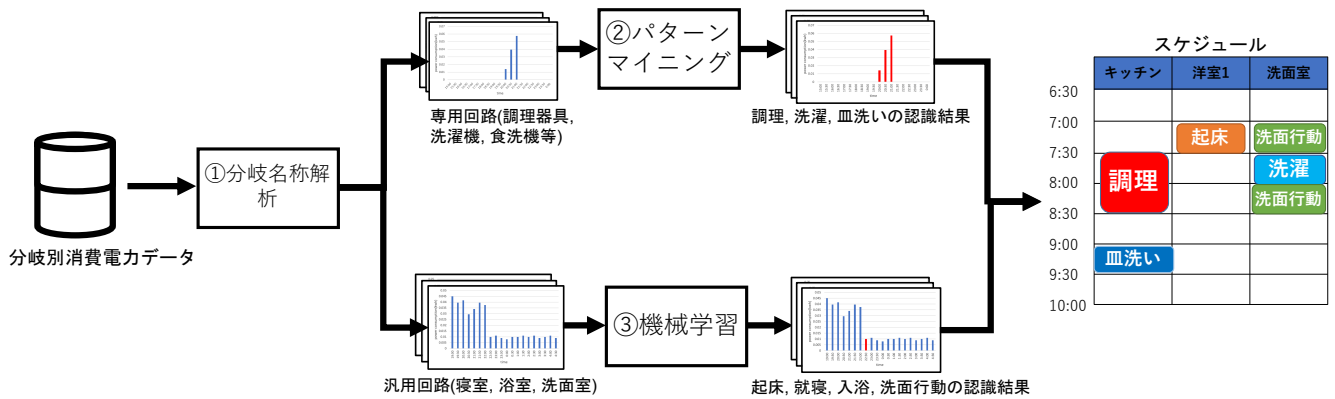


図 3 提案手法の概要

はまず各分岐に付けられた分岐名を解析し、各分岐が家電毎に集計されている専用回路と部屋毎に集計されている汎用回路のどちらなのか、そして専用回路であれば接続されている家電の種類を、汎用回路であれば計測されている場所を特定する。そして、後の行動認識のために、認識する行動とそのために用いる分岐とを関連付ける。

分岐名称は図2に示すように、部屋名のみが書いてある場合や家電名のみが書いてある場合、部屋名や家電名の後に階数や番号が続く場合、家電名と部屋名が同時に書いてある場合など様々なパターンがある。しかしながら、可視化という目的から人が読んだ時に場所が一位に定まるように書かれていることもあり、多数の家庭の分岐名を確認したところ記述様式や出てくる家電名、部屋名の数も有限であり、以下に示す文脈自由文法に則っていることが判明した。

$S \rightarrow SBS|IBP|RBP$

$B \rightarrow _|\cdot| \cdot | \cdot | \cdot | _|\cdot | _|\epsilon$

$I \rightarrow$ 洗濯機用 | 食洗機用 | IH用 | レンジ用 | 給湯器
| オープン | 空調 | クーラー用 | 専用回路 | 家電用...

$R \rightarrow$ LDK | 主寝室 | 子供室 | ホール | トイレ | 書斎
| 納戸 | 洗面室 | 洗面脱衣室 | 和室 | ランドリー...

$P \rightarrow$ FBNBD | FBDBN | NBDBF | DBFBN

$N \rightarrow (C)|C|\epsilon$

$C \rightarrow$ 1|2|3|4|5|6|7|8|9

$D \rightarrow$ 東 | 南東 | 南 | 南西 | 西 | 北西 | 北 | 北東 | ϵ

$F \rightarrow$ 1階 | 1F | 2階 | 2F | 3階 | 3F | 階上 | ϵ

そこでまず、上記の文脈自由文法を解析することで、分岐名称から部屋名や家電名とそれに付属する番号や階数などの情報を取り出す。基本的に分岐名称に家電の名称が含まれている分岐に関してはその家電のみを計測しており、部屋名のみが書かれている分岐に関してはその部屋全体で計測している。従って解析途中に非終端記号 I が出現した

場合は専用回路、出現しない場合は汎用回路とみなす。また、後の行動認識で利用するために同じ部屋で計測されている分岐を部屋名と番号などの付属情報をもとに対応づけて記憶しておく。さらに、起床・就寝であれば主寝室や子供室、洋室など、寝室に相当する部屋で行われ、調理行動ではレンジやIH、オーブンなどの家電が使用されるといったように行動と部屋名、行動と家電名には関係がある。そのため、事前に家電名や部屋名を関連する行動毎に分けたリストを作成しておき、解析によって得られた部屋名、家電名がどのリストに属しているかによって行動と分岐とを関連づける。具体的には、起床と就寝には各寝室の汎用回路と対応する寝室のエアコンの専用回路を、入浴には浴室の汎用回路と給湯器の専用回路を、洗面行動には洗面室の汎用回路を関連づける。また、調理にはレンジやIH等に設けられた専用回路、皿洗いには食洗機の専用回路、洗濯には洗濯機の専用回路か、なければ洗面室の汎用回路を関連づける。

なお、我々が利用したデータセットを解析した結果、キッチンにある“家電用”や“専用回路”という名称の、名称からは用途が明確でない分岐にも調理用家電が単独で接続されていることが多かった。しかしそれらは照明や換気扇に使われている場合もあり、調理用家電の中でも電気ポットや炊飯器など調理のタイミングに依存せず稼働する家電もある。そこで、そのような用途が明確でない分岐に対しては、接続されている家電を推定し、調理行動に関連付けるか否かを決定する。

4.2 稼働認識による行動の認識

調理や洗濯、皿洗いにおいては専用回路を検出に用いることが多く、単一の家電が接続されており、行動時間外の稼働がなく、未使用時には電力消費が0となる。したがって、電力値が0か否かの単純な規則で行動時間を検出する。

4.2.1 調理行動の認識

4.1節で述べたように、調理行動と関連づけられている分岐に直接調理とは関係しない家電が接続されている場合が




図 4 照明・換気扇の消費電力の例




図 6 寝室の消費電力の例




図 5 炊飯器の消費電力の例

ある。キッチンにあるが直接調理の時間と関係しない家電としては、換気扇や照明、電気ポットやコーヒーマーカー、炊飯器などがあげられる。これらの利用が示す消費電力は特徴的であるため、その特徴を用いた家電推定を行い、それらの分岐を行動認識に用いないように取り除く。

まず照明や換気扇は処理が単純で使用中の消費電力に変動がないため、図 4 に示すように、稼働の最初のスロットと最後のスロットを除いてほぼ全てのスロットで大きな変動のない波形を示す。なお、同様の電力消費傾向を示す他種家電も存在するが、それらが長期にわたり利用されることはほとんどない。そこで前後のスロットとの電力差の比が閾値以下であるようなスロットが長期間続く場合は、その分岐は換気扇や照明が接続されていると判定する。次に電気ポットやコーヒーマーカーは湯を沸かしてから保温し、炊飯器に関しては米を炊いてから保温する処理を基本的に湯沸かしや炊飯は常温から 100 度近くまで温度を上げるため大量のエネルギーを用いるが、一方で保温に関しては温度を留めるだけであるため比較的消費エネルギーが小さいそのため電気ポットや炊飯器は図 5 に示すように、最初に大きな消費電力を示してから、その後小さい電力を長く続ける波形を示す。最初の大きな消費電力に関しては電気ポットや炊飯器などの家電間で、また家電性能の違いにより同じ家電の間で大きさや長さが異なり、また保温に関しても設定温度や保温対象の量、家電の性能によって消費電力が変わるものの、最初に大きな消費電力を示してから、低い消費電力を長く続けるという特徴は同じであるた

め、ピーク検出と持続部分の検出を行うことでこれらの家電の検出を行う。ピーク検出に関しては消費電力が上昇から下降をし、傾きが閾値以下にまで収まったところまでを抽出し、その範囲での消費電力の合計値が一定以上であるか否かで判別する。また保温電力についても持続時間と大きさに閾値を設定して検出する。以上により調理用家電が接続されていない分岐を検出したため、調理用家電が接続されている分岐を抽出することができた。そのため残った分岐でスロット電力消費が 0 か否かで家電稼働の有無を判別し、少なくとも 1 つの分岐で稼働が検知されれば調理行動有と判断する。

4.2.2 洗濯、皿洗いの認識

洗濯機と食洗機は機種によって自動洗浄機能が備わり、使用時以外に稼働することがある。しかし自動洗浄は水洗いや乾燥の機能と比べて消費電力量が非常に小さいため、閾値を定めて除外することが可能である。ただし、30 分区切りで集計しているため、スロットを跨る稼働の最初の最初や最後の稼働において閾値を下回る消費電力値を示す可能性がある。そのため、除外時にはその前後スロットにおいて稼働と認められる一定以上の電力消費の有無を確認する。その後、調理認識と同様に稼働時に行動しているとしてこれらの行動を認識する。

ここで、家庭によっては洗濯機の専用回路が存在しない場合があり、洗濯機が洗面室の汎用分岐にまとめて計測されている場合がある。このような場合、洗濯機の稼働の特徴を以って洗濯機の稼働の検出を行う。洗濯機は洗面室内ではヘアアイロンやドライヤに次いで単位時間あたりの消費電力が大きい、ヘアアイロンやドライヤとは異なり、洗濯機はその機能を全うするために基本的に 30 分以上の稼働時間を伴うため、2 スロットか 3 スロット分に跨る稼働が多く起こる。そのため、提案手法では洗濯機の稼働を稼働時間長と稼働時の消費電力量をもって検出する。

4.2.3 機械学習による行動の認識

入浴や洗面行動、起床・就寝などの検出に用いる分岐は専用回路ではなく、照明や一般のコンセントの消費電力などがまとめられており、実際に行動がない間も変動するため簡単な規則では検出することは難しい。そこで入浴や洗

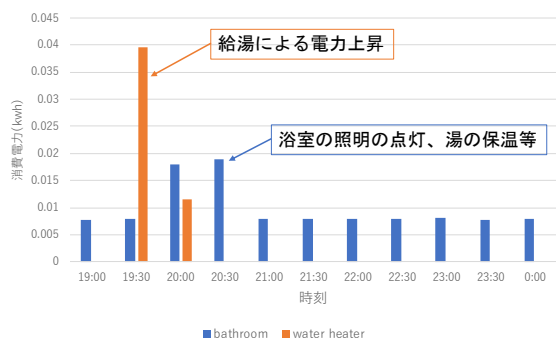


図 7 浴室と給湯器の消費電力の例

表 1 起床/就寝の認識において使用した特徴量

特徴量名	特徴量の説明
t_{n_sin}	時刻に三角関数適用したもの
t_{n_cos}	時刻に三角関数を適用したもの
S_n	夏か冬かの 2 値
L_{n-1_AC}	30 分前の空調の消費電力
L_{n+1_AC}	30 分後の空調の消費電力
L_{n_AC}	現在の空調の消費電力
$L_{n-1_rate_AC}$	30 分前からの空調の消費電力の変化率
$L_{n+1_rate_AC}$	30 分後にかけての空調の消費電力の変化率
$L_{n_bedroom}$	現在の寝室の消費電力
$L_{n-1_bedroom}$	30 分前の寝室の消費電力
$L_{n+1_bedroom}$	30 分後の寝室の消費電力
$L_{n-1_rate_bedroom}$	30 分前からの寝室の消費電力の変化率
$L_{n+1_rate_bedroom}$	30 分後にかけての寝室の消費電力の変化率
$L_{past_var_AC}$	過去 3 時間の空調の消費電力の分散
$L_{next_var_AC}$	未来 3 時間の空調の消費電力の分散
$L_{past_var_bedroom}$	過去 3 時間の寝室の消費電力の分散
$L_{next_var_bedroom}$	未来 3 時間の寝室の消費電力の分散

表 2 入浴の認識において使用した特徴量

特徴量名	特徴量の説明
t_{n_sin}	時刻に三角関数適用したもの
t_{n_cos}	時刻に三角関数を適用したもの
S_n	夏か冬かの 2 値
L_{n_bath}	現在の浴室の消費電力
L_{n-1_bath}	30 分前の浴室の消費電力
L_{n-2_bath}	1 時間前の浴室の消費電力
L_{n+1_bath}	30 分後の浴室の消費電力
L_{n+2_bath}	1 時間後の浴室の消費電力
$L_{n_dif_mean_bath}$	浴室の消費電力の移動平均との差
$L_{n-1_dif_mean_bath}$	30 分前の浴室の消費電力の移動平均との差
$L_{n-2_dif_mean_bath}$	1 時間前の浴室の消費電力の移動平均との差
$L_{n+1_dif_mean_bath}$	30 分後の浴室の消費電力の移動平均との差
$L_{n+2_dif_mean_bath}$	1 時間後の浴室の消費電力の移動平均との差
L_{n_boiler}	現在の給湯器の消費電力
L_{n-1_boiler}	30 分前の給湯器の消費電力
L_{n-2_boiler}	1 時間前の給湯器の消費電力
L_{n-3_boiler}	1 時間半前の給湯器の消費電力

表 3 洗面行動の認識において使用した特徴量

特徴量名	特徴量の説明
t_{n_sin}	時刻に三角関数適用したもの
t_{n_cos}	時刻に三角関数を適用したもの
S_n	夏か冬かの 2 値
L_{n_wash}	現在の洗面室の消費電力
L_{n-1_wash}	30 分前の洗面室の消費電力
L_{n-2_wash}	1 時間前の洗面室の消費電力
L_{n+1_wash}	30 分後の洗面室の消費電力
L_{n+2_wash}	1 時間後の洗面室の消費電力
$L_{n_dif_mean_wash}$	洗面室の消費電力の移動平均との差
$L_{n-1_dif_mean_wash}$	30 分前の洗面室の消費電力の移動平均との差
$L_{n-2_dif_mean_wash}$	1 時間前の洗面室の消費電力の移動平均との差
$L_{n+1_dif_mean_wash}$	30 分後の洗面室の消費電力の移動平均との差
$L_{n+2_dif_mean_wash}$	1 時間後の洗面室の消費電力の移動平均との差
$L_{n_dif_wash}$	洗面室の消費電力の変化量
$L_{n-1_dif_wash}$	30 分前の洗面室の消費電力の変化量
$L_{n-2_dif_wash}$	1 時間前の洗面室の消費電力の変化量
$L_{n+1_dif_wash}$	30 分後の洗面室の消費電力の変化量
$L_{n+2_dif_wash}$	1 時間後の洗面室の消費電力の変化量

面行動, 起床・就寝に関しては学習を用いた判定を行う。

ここで HEMS は 30 分毎にデータを収集しており, 1 日のデータを集めても 48 スロット分しかなく, そのうち目的の行動をしているスロットは 1, 2 スロットであるため, 真値つきのデータを大量に収集することは難しい。そのため, 深層学習ではなく, 比較的少ないデータでも学習が可能なランダムフォレストや XGBoost 等のアルゴリズムを用いて行動認識を行う。以降で学習時に用いた特徴量の中で重要度の高いものの説明を行う。

表 1, 2, 3 に各行動の認識において用いた特徴量を示す。起床と就寝は認識のために捉えるべき特徴が似ているため, 同じ特徴量を用いる。まず起床・就寝などの行動は, 例えば起床は朝で就寝は夜と言ったように時間帯との関係が強いため, まず時刻を特徴量として考える。本研究では周期性を与えるために, 1 日に当たる 48 スロットに三角関数を適用したものを特徴量とする。また図 6 に示すように, 寝る時に家電を消したり, 起きた時に家電をつけることによって急な電力の立ち上がりや立ち下がりが見られることがあるため, 前後のスロットとの変化率を特徴量として用いる。加えて, 起きている間には掃除機の使用や加湿器の ON/OFF 変更, PC の使用など家電の操作が行われるために電力の変動が大きいが, 就寝後は加湿器や空気清浄機やの継続稼働などはあるが家電の明示的な操作が行われないために消費電力の変動が小さい。そこでこの変化を捉えられるように当該スロットの前後のスロットの分散の値を特徴量として用いる。それぞれの特徴量の計算式を以下に示す。

$$t_{n_sin} = \sin \frac{(n \bmod 48)\pi}{48} \quad (1)$$

$$t_{n_cos} = \cos \frac{(n \bmod 48)\pi}{48} \quad (2)$$

$$L_{n-1_rate_bedroom} = \frac{L_{n_bedroom}}{L_{n-1_bedroom}} \quad (3)$$

$$L_{n+1_rate_bedroom} = \frac{L_{n+1_bedroom}}{L_{n_bedroom}} \quad (4)$$

$$L_{past_var_bedroom} = \frac{1}{6} \sum_{k=n-7}^{n-1} (L_{k_bedroom} - \frac{1}{6} \sum_{l=n-7}^{n-1} L_{l_bedroom})^2 \quad (5)$$

$$L_{next_var_bedroom} = \frac{1}{6} \sum_{k=n+7}^{n+1} (L_{k_bedroom} - \frac{1}{6} \sum_{l=n+7}^{n+1} L_{l_bedroom})^2 \quad (6)$$

ここで、 n は HEMS データの最初から各スロットに与えられた連番で、 $L_{n_bedroom}$ は n 番目のスロットにおける寝室の消費電力値を表す。

次に入浴も起床/就寝と同様に行動の行われる時間帯が偏る傾向にあるため、まず時刻を特徴量として用いる。また図 6 に示すように、入浴前には浴槽にお湯を張るために給湯器の消費電力が増加する。そのため過去の数スロットにわたる給湯器の消費電力を特徴量として用いる。加えて、入浴をしている間は部屋の照明をつけることや換気扇を回すことで消費電力の上昇が起こる。ここで過去から現在までの値とそれらの差分を特徴量として用いることを考えるが、洗面脱衣室で常に換気扇を稼働させている家庭もあることから、家毎に取りうる最低の消費電力値が異なる場合があり、絶対値では家毎の常在電力の違いを考慮できないと考えられる。そこで、移動平均と各スロットの差分を特徴量として用いることで家間の常在電力の違いによる影響を軽減させる。以下に (1)~(6) で示していない特徴量の計算式を示す。

$$L_{n_dif_mean_bath} = L_{n_bath} - \frac{1}{24} \sum_{k=n-24}^n L_{k_bedroom} \quad (7)$$

洗面行動も起床就寝と同様に朝、晩と行動の行われる時間帯が偏る傾向にあるため、まず時刻を特徴量として用いる。また入浴と同様に、洗面行動に関しても、行動が起きている間は消費電力の上昇が起こる。ここでも常在電力の影響を取り除くために移動平均と各スロットの差分を特徴量として用いる。

4.2.4 転移学習による家間の違いへの適応

30 分毎の消費電力に含まれている情報量は多くなく、既存研究とは異なり周波数成分や瞬間的な値などは得られず、大まかな時間帯と圧縮された電力値とその増減という比較的少ない情報から行動を推定する必要がある。しかしこれらの情報は家庭毎に異なる場合が多い。各家において、行動による消費電力の変動の傾向は似ているものの、家電の性能の違いや行動時間長などの影響もあり全く同じものは

ない。また例えば入浴で言えば夕方以降ということは一致していても、5 時付近に入浴する家庭があれば 11 時付近に入浴する家庭があるように、家毎に細かな時間帯の違いもある。そのため様々な家庭のデータを用いて学習しても全能なモデルができるわけではなく、多数派の似たような家庭のみでうまく動作するが、特殊な家庭には全く動作しないようなモデルができてしまう。そこで提案手法では全能なモデルの一つ作って全ての家庭に対応するのではなく、一つモデルを作成し、転移学習により個々の家に向けて特殊化し、家間の違いに対して適応することを考えた。

そこで本研究では文献 [22] にて提案されているランダムフォレストの転移学習手法を用いた。この手法では木の拡張と収縮を行うアルゴリズム (SER) と各ノードに設定されているルールの閾値の変更を行うアルゴリズム (STRUT) の 2 つの異なる問題に優れている傾向を示す手法を組み合わせ、ソースにて学習したモデルのターゲットへの適応を行う。まず SER では決定木構造の拡大と縮小という 2 つの局所的な変換を行うことで、ソース・データに誘導されたルールをターゲットデータに特化させる (拡大) とともにルールを一般化する (縮小)。詳しく処理を述べるとターゲットデータの到達する全ての葉において、到達したデータを元にサブツリーを展開し、サブツリー展開前と展開後の内でエラー率の低い方を採用していく。次に STRUT は類似した問題に対する決定木は構造的に類似しているが、特徴の規模や、それに関連する決定しきい値は、問題によって異なる可能性があるという考えに基づいて木の構造を維持したまま閾値を変更する。詳しく処理を述べると木の閾値を一度撤廃し、トップダウンで閾値を情報利得と元の木における分割分布との相違を元に変更していく。ここで 3.1 章で述べたように提案手法では 30 分粒度のデータを扱っているため 1 日データを集計しても 48 点のデータにしかない。加えてそれぞれの行動が 1 日の内を占める割合はとて少なく、起床と就寝に至っては 1 日に 1 点しか陽データが得られない。このような少量かつアンバランスなデータで転移アルゴリズムを適用しようとしてもデータが木の全てを網羅することが出来ず、良い効果が期待できない。そこで本研究では転移学習用のデータに SMOTE を用いてオーバーサンプリングを行うことで陽データを増やしてこの問題に対処する。

5. 性能評価

提案手法の実環境における有用性を検証するために、協力企業との連携のもと 3 月から 4 月の 1 ヶ月の期間、3 家庭にセンサを導入する真値取得実験を行い、得られた真値をもとに提案手法を評価する。

5.1 真値取得実験

真値取得に際して、カメラやマイクなどを導入すること

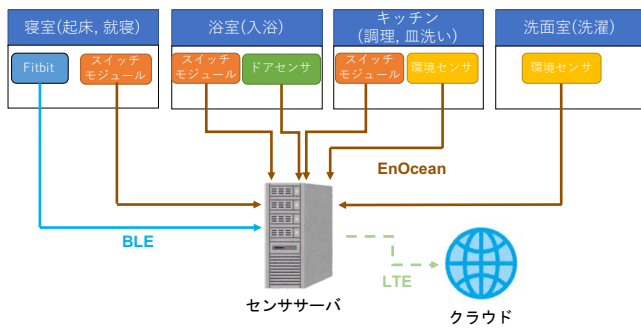


図 8 導入したシステムの概要

はプライバシーを侵害する恐れがあり、バッテリー駆動であるため、定期的なメンテナンスが必要となり、実験協力者の負担となってしまいます。センサを用いない方法では行動の度に時間をメモする必要があるためにこれもまた実験協力者の負担となってしまいます。そこで我々は文献 [4] に示されている SALON システムを導入し、プライバシー侵害なく、メンテナンスフリーに真値を取得することを試みた。SALON システムはプライバシーを侵害するカメラやマイクを必要とせず、少数の安価な環境発電センサとシンプルなボタンで構成される日常生活動作 (ADL) センシングシステムで、常駐 ADL データを正しく収集が可能である。本実験ではセンサでのデータの取りこぼしを防ぐためにも SALON システムとは別に Fitbit を用いている。本実験で導入したシステムの概要を図 8 に示す。本実験で導入した SALON システムはセンササーバ、スイッチモジュール、ドアセンサ、環境センサの 4 つから構成されており、スイッチモジュール、ドアセンサ、環境センサのデータは EnOcean を介してサーバが受信している。以降に各センサの詳細な説明を行う。

5.1.1 スイッチモジュール

入浴と起床、就寝、調理のラベルをつけるために、Rohm 製の PTM215J スイッチモジュールを用いた。スイッチモジュールは、ボタンが押されたときに加えられる力を利用して電力を生成する。そして生成した電力を利用して電磁誘導モジュールにより EnOcean を介してサーバにデータパケットを送信する。各センサボタンは四角形で、4 つのスイッチがある。本実験ではこの内二つに、アクティビティの開始状態と終了状態を示すステッカーを貼り、居住者が適切なスイッチを押すことにより、アクティビティの開始と終了にラベルをつけられるようにする。

5.1.2 ドアセンサ

ドア開閉データを取得するために、Rohm 製の STM250J 磁気センサを用いた。センサ本体と磁石の 2 つの部分で構成されており、センサ本体には太陽光パネルが取り付けられているため環境発電で駆動することが可能である。ドアに取り付けられたセンサ本体がドアフレームに取り付けられた磁石を検出すると、センサーはドアの開閉情報を取

得し、取得した開閉情報をデータサーバに送信する。本実験ではスイッチモジュールと併用することで押し忘れた場合の欠損値を補完できるように浴室のドアに設置した。

5.1.3 環境センサ

洗濯機と食洗機の振動を計測するために、Rohm 製の STM550J マルチセンサを用いた。温度、湿度、照度、振動、マグネットコンタクトセンサを内蔵しており、太陽光パネルを搭載していることから環境発電で駆動することが可能である。本実験では環境センサを洗濯機と食洗機の側面にテープで固定し、これらの x,y,z 軸の加速度の変化を計測することで洗濯と皿洗いの行動の真値を取得する。

5.2 評価指標とデータセット

本評価には 2 つのデータセットを用いる。一つは協力企業から入手した 935 邸の HEMS 分電盤から得られる消費電力データの内、17 家庭の家電利用の多くなる夏と冬、それぞれ 2 ヶ月分の分岐別消費電力データにラベルづけしたもので、もう一つは 5.1 節の実験にて取得した 1 ヶ月分の真値ラベルと 3 家庭の分岐別消費電力データである。本評価では、17 家庭のデータの方をモデルの学習に、3 家庭のデータの方をモデルの検証に用いる。転移学習を行わない場合には評価対象の家庭の 1 ヶ月全てのデータを検証データとして扱い、転移学習を行う場合には転移学習用に 10 日分のデータを確保し、残りを検証データとして扱う。

評価指標としては、正と予測したデータのうち実際に正であるものの割合である Precision と、実際に負であるもののうち負であると予測されたものの割合である Recall, Precision と Recall の調和平均である F 値を用いる。4 つの行動の認識をそれぞれ 2 値分類の問題とみなして、行動が起きたスロットを 1、起きていないスロットを 0 としてそれぞれ学習させ、各スロットの推定結果と正解値が同一である数や相違している数を数えて、真陽性や偽陽性、偽陰性、真陰性を求める。

5.3 各行動の認識精度

まず、転移学習を行わない場合のそれぞれの行動の認識精度を確認する。表 4 に各家庭のそれぞれの認識精度を示す。No.2 の家庭ではセンサの電波がうまく捉えられず、データの欠損が生じてしまったため、調理と皿洗いの精度が出せていない。表 4 から 3 家庭で平均して F 値が起床は 0.16、就寝は 0.14、入浴は 0.54、調理は 0.80、洗濯は 0.82、皿洗いは 0.87 となった。

皿洗いの平均 F 値が 0.87 と完璧に捉えられていない理由としては、環境センサでは捉えられない稼働があったためだと考えられる。濯ぎの工程では揺れを検出できるものの、乾燥の行程では揺れが生じないために実際の稼働よりも検出した稼働が短くなり、比較的 Precision が低くなっているものと考えられる。

表 4 各家庭の各行動の認識精度

邸番号	行動種別	Precision	Recall	F 値
邸 No.1	起床	0.33	0.36	0.35
	就寝	0.24	0.15	0.18
	入浴	0.85	0.56	0.67
	調理	0.73	0.81	0.76
	洗濯	0.83	0.96	0.89
	皿洗い	0.75	0.98	0.85
邸 No.2	起床	0.04	0.04	0.04
	就寝	0	0	0
	入浴	0.58	0.88	0.69
	調理	-	-	-
	洗濯	0.63	0.86	0.72
	皿洗い	-	-	-
邸 No.3	起床	0.13	0.13	0.13
	就寝	0.29	0.14	0.19
	入浴	0.3	0.79	0.44
	調理	0.85	0.77	0.81
	洗濯	0.71	0.89	0.79
	皿洗い	0.91	0.87	0.89

No.1 の家庭において調理の Precision が低くなっている理由としては、再温めや保温が多くあったためだと考えられる。提案手法では IH の稼働の有無を判断基準としていて、その内容までは考慮しておらず、調理以外の IH の稼働でも調理と判定してしまっている。一方で No.2 の家庭においては家電を用いない調理の時間が長くあり、そのために調理の Recall が低くなっているのだと考えられる。

No.2 と No.3 の家庭が No.1 の家庭と比べて洗濯の認識精度が低くなった理由としては、洗濯機の専用回路が存在しなかったためである。これらの家庭においては洗面室の汎用回路から取り出す必要があるため、ドライヤやヘアアイロンの利用に関しても誤検出してしまい、特に Precision が低くなっているものと考えられる。

起床と就寝は全ての行動の中で最も低い精度となり家庭によっては全く捉えられていない。この理由の一つとしては今回対象とした家庭では一部屋に複数人が寝起きするケースが多くあり、家電操作を行う人と最初に就寝する人、最後に起床する人が一致しなかったためだと考えられる。また寝室にタイマ機能を持った家電が多くあったこともまた原因として考えられる。タイマ機能を持つ家電があることにより、就寝のタイミングと電力消費が変動するタイミングに遅延が生じ、誤検出と検出漏れが多く起こってしまった。また本実験では起床時に家電操作を行わない事例が多く見られた。実験期間が3月から4月だった影響もありエアコンの使用や扇風機の使用は稀で、起きたタイミングで家電操作することが少なく、そのため起きたタイミングで電力の変動が起こらず、見落としが多く生じてしまっている。

5.4 転移学習を用いた場合の認識精度

表 5 転移学習を行なった場合の各行動の認識精度

	行動種別	Precision	Recall	F 値
Random Forest	起床	0.23	0.34	0.28
	就寝	0.23	0.22	0.23
	入浴	0.44	0.70	0.54
転移学習を用いた RandomForest	起床	0.29	0.38	0.33
	就寝	0.33	0.34	0.34
	入浴	0.75	0.77	0.76

次に転移学習を行なった場合の行動の認識精度を評価する。転移学習を行わない場合と10日分のデータを用いて転移学習を行なった場合のそれぞれの行動の認識精度を表5に示す。表5より、全ての行動において転移学習を行うことにより精度が向上していることがわかる。

特に入浴においてはF値で0.22と向上しており、転移学習が最も良く働いていることがわかる。この理由としては、本実験にて収集したデータが表4から入浴のPrecisionとRecallが大きく家毎に異なっていることから、家毎の違いが大きいデータであり、元々の精度も低く、上昇の余地が大きかったことが考えられる。一方で起床と就寝に関しては元の精度が低いにも関わらずF値で0.05, 0.11と比較的上昇幅が小さく、木の閾値の変更や木の規則変更が働きはするものの、タイマ機能を持った家電による行動と電力変動のずれや、変動を伴わない行動などのような本質的な問題を解決することができないことがわかる。

6. おわりに

本稿では、HEMSにて得られる低粒度の分岐回路別消費電力データからの行動推定手法の実環境における有用性検証を行った。協力企業との連携のもと3月から4月の1ヶ月の期間、3家庭にセンサを導入する真値取得実験を行い、得られた真値をもとに同手法を評価した。その結果、3家庭で平均してF値が起床は0.16、就寝は0.14、入浴は0.54、調理は0.80、洗濯は0.82、皿洗いは0.87で認識できていることがわかった。起床と就寝に関しては、タイマ機能を持つ家電が多くあることや、家電操作を伴わない起床が多く見られたことから消費電力のみでは認識が難しいということがわかった。また転移学習を行うことで各行動の認識精度が向上することが確認でき、洗濯、調理、皿洗いと転移学習した入浴の4行動では平均F値が0.81と実環境においても十分に認識が可能であることがわかった。

今後の課題としては、まず推定できる行動種別や状態を増やすことが挙げられる。部屋の在不在は消費電力量の変動の大きさや電力消費の有無からある程度推定可能であると考えられる。部屋の在不在を認識することができれば、他の7つの行動と合わせて、居住者全員が外出しているかどうかとも推定できると考えられる。また今回は部屋毎での

起床就寝の認識を試みていたが、家単位での起床や就寝であればリビングやホールなど寝室以外の部屋の電力情報を用いることができ、比較的实现可能性が高いため、家単位での起床や就寝の認識を行うことを検討している。

参考文献

- [1] Michael A. Devlin and Barry P. Hayes. Non-intrusive load monitoring and classification of activities of daily living using residential smart meter data. *IEEE Transactions on Consumer Electronics*, Vol. 65, No. 3, pp. 339–348, 2019.
- [2] Eoghan McKenna, Ian Richardson, and Murray Thomson. Smart meter data: Balancing consumer privacy concerns with legitimate applications. *Energy Policy*, Vol. 41, pp. 807–814, 2012.
- [3] 田中福治, 石津紘太郎, 水本旭洋, 山口弘純, 東野輝夫ほか. 低粒度な分岐回路電力データを用いた家庭内行動認識手法. マルチメディア, 分散協調とモバイルシンポジウム 2021 論文集, Vol. 2021, No. 1, pp. 1391–1399, 2021.
- [4] Tomokazu Matsui, Kosei Onishi, Shinya Misaki, Manato Fujimoto, Hirohiko Suwa, and Keiichi Yasumoto. Salon: Simplified sensing system for activity of daily living in ordinary home. *Sensors*, Vol. 20, No. 17, p. 4895, 2020.
- [5] 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, 2012.
- [6] Oliver Brdiczka, Matthieu Langet, Jérôme Maisonnasse, and James L Crowley. Detecting human behavior models from multimodal observation in a smart home. *IEEE Transactions on Automation Science and Engineering*, Vol. 6, No. 4, pp. 588–597, 2008.
- [7] Kazushige Ouchi and Miwako Doi. Smartphone-based monitoring system for activities of daily living for elderly people and their relatives etc. In *Proceedings of ACM Conference on Pervasive and Ubiquitous Computing Adjunct Publication*, 2013.
- [8] Jesse Hoey and James J Little. Value-directed human behavior analysis from video using partially observable markov decision processes. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 29, No. 7, pp. 1118–1132, 2007.
- [9] Negar Rostamzadeh, Gloria Zen, Ionuț Mironică, Jasper Uijlings, and Nicu Sebe. Daily living activities recognition via efficient high and low level cues combination and fisher kernel representation. In *Proceedings of International Conference on Image Analysis and Processing*, pp. 431–441, 2013.
- [10] Oliver Brdiczka, Matthieu Langet, Jérôme Maisonnasse, and James L Crowley. Detecting human behavior models from multimodal observation in a smart home. *IEEE Transactions on Automation Science and Engineering*, Vol. 6, No. 4, pp. 588–597, 2009.
- [11] Takuya Maekawa, Yasue Kishino, Yasushi Sakurai, and Takayuki Suyama. Recognizing the use of portable electrical devices with hand-worn magnetic sensors. In *Proceedings of International Conference on Pervasive Computing*, pp. 276–293, 2011.
- [12] Seon-Woo Lee and Kenji Mase. Activity and location recognition using wearable sensors. *IEEE Pervasive Computing*, Vol. 1, No. 3, pp. 24–32, 2002.
- [13] TLM Van Kasteren, Gwenn Englebienne, and Ben JA Kröse. An activity monitoring system for elderly care using generative and discriminative models. *Personal and Ubiquitous Computing*, Vol. 14, No. 6, pp. 489–498, 2010.
- [14] Liming Chen, Chris D Nugent, and Hui 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, 2011.
- [15] Anthony Fleury, Michel Vacher, and Norbert Noury. Svm-based multimodal classification of activities of daily living in health smart homes: sensors, algorithms, and first experimental results. *IEEE Transactions on Information Technology in Biomedicine*, Vol. 14, No. 2, pp. 274–283, 2009.
- [16] Kenki Ueda, Hirohiko Suwa, Yutaka Arakawa, and Keiichi Yasumoto. Exploring accuracy-cost tradeoff in in-home living activity recognition based on power consumptions and user positions. *IEEE International Conference on Computer and Information Technology; Ubiquitous Computing and Communications; Dependable, Autonomic and Secure Computing; Pervasive Intelligence and Computing*, pp. 1130–1137, 2015.
- [17] Eri Nakagawa, Kazuki Moriya, Hirohiko Suwa, Manato Fujimoto, Yutaka Arakawa, and Keiichi Yasumoto. Toward real-time in-home activity recognition using indoor positioning sensor and power meters. In *Proceedings of IEEE International Conference on Pervasive Computing and Communications Workshops*, pp. 539–544, 2017.
- [18] Yutaka Arakawa, Keiichi Yasumoto, Krita Pattamasirawat, and Teruhiro Mizumoto. Improving recognition accuracy for activities of daily living by adding time and area related features. In *Proceedings of International Conference on Mobile Computing and Ubiquitous Network*, pp. 1–6, 2017.
- [19] Zhenyu Guo, Z Jane Wang, and Ali Kashani. Home appliance load modeling from aggregated smart meter data. *IEEE Transactions on power systems*, Vol. 30, No. 1, pp. 254–262, 2015.
- [20] Abdulsalam Yassine, Shailendra Singh, and Atif Alamri. Mining human activity patterns from smart home big data for health care applications. *IEEE Access*, Vol. 5, pp. 13131–13141, 2017.
- [21] Kotaro Ishizu, Teruhiro Mizumoto, Hirozumi Yamaguchi, and Teruo Higashino. Home activity pattern estimation using aggregated electricity consumption data. *Sens. Mater.*, Vol. 33, pp. 69–88, 2021.
- [22] Noam Segev, Maayan Harel, Shie Mannor, Koby Crammer, and Ran El-Yaniv. Learn on source, refine on target: A model transfer learning framework with random forests. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 39, No. 9, pp. 1811–1824, 2017.