

主幹電力データに基づく 家庭内行動推定におけるモデル選択手法

石津 紘太郎¹ 水本 旭洋¹ 山口 弘純¹ 安本慶一² 東野 輝夫¹

概要: センシング技術の目覚ましい発展を背景に, 家庭内にセンサを設置し居住者の家庭内行動を認識することで, みまもり, ヘルスケア, 日常生活における異常行動検知, 生活改善アドバイスなどのサービスが期待されている. しかし, 家庭へのセンサー設置はプライバシー懸念のために社会的な受容度は高くなく, 特にカメラなどは敬遠される傾向にある. 安価な人感センサ等を宅内の各所に設置する手法も多くみられるものの, サービスの実運用においては複数センサの位置管理や死活監視など, 設置やその後の運用にかかるコストが無視できない. そこで本研究では, スマートメータ等から定期的に取り得られる家庭の総消費電力(主幹電力)データのみを用いて家庭内の大まかな行動パターンを推定する低コストかつ非侵襲な推定手法を提案する. このような行動推定を実現するために本手法は2つの課題に取り組んでいる. 1つ目はスマートメータ等から得られる電力値は数十秒から1分間隔といった低粒度であり, かつ家電の待機電力や給湯器・温水洗浄便座といった宅内電気設備の消費電力の総量であるため, 既存の家電推定手法が前提とする1秒未満間隔の高解像度電力値が利用できないことである. これに対し, 提案手法は見守りサービスを考慮した, 低解像度データで認識できる行動分類を定義し, Balanced Random Forest を用いて行動推定を行う. 2つ目は家庭ごとに生活パターンが異なるため単一の分類器での推定が困難という点である. ここで家庭ごとにデータを収集し分類器を訓練するのは現実的ではないため, 本研究では異なる家庭で学習した異なる分類器を複数用意し, 推定対象の家庭に適切な分類器を自動で選択する手法を提案する. 8つの独居高齢者の家庭から収集した191日間の消費電力データとスマートホームで3人の学生に生活してもらい収集した60日間のセンサデータを用いて, 本手法の評価を行った. その結果, 低解像度の電力消費量データセットを用いても, 高齢者は4行動中3行動で平均F値約0.7, 学生は4行動中2行動の平均F値が0.7以上となり, また提案した適合度が最適な分類器を選択できることを確認した. さらに人感センサ, ドアセンサといった他のセンサとの併用を想定した推定を行った. 結果主幹電力に加えキッチンと寝室に人感センサーを配置することで, 電力だけでは判断しにくい部分を補い全ての行動の平均F値が0.7以上となることを示した.

1. はじめに

近年, センシング技術の目覚ましい発展に伴い, センサ情報から人間の行動を認識できるようになり行動認識に基づく様々なサービスの需要が高まっている. 特に, 家庭内行動認識に基づく電力使用の効率化, 健康アドバイスを, 在宅医療などの新しいサービスの展開が期待されている.

総務省によると, 現在日本の高齢者の16%が一人暮らしをしているとされている[1]が, 独居高齢者は社会との関わりが少なくなりがちであり, それが心身に悪影響を及ぼす可能性が指摘されている. 心身の衰弱は生活パターンの乱れや行動量の減少として顕在化するため, 独居高齢者の家庭内行動を認識しこれらの変化を捉えることができれば, 家族へ向けた情報提供など適切な対応も可能となる. また, 単身の若年層における生活パターンの乱れは遠隔地で暮らす家族に心配を与えるものとなる. 本研究では, こうしたサービスの基盤となる家庭内居住者の生活パターンの把握に向けた技術開発を目的とする.

これらのサービスに向けて従来多くの行動認識技術が提案されている. 動画像や静止画像を用いる行動推定手法[2]は最も直接的であるが, プライバシー懸念から家庭におけるカメラの受容度は極めて低い. また, ウェアラブルセンサを用いた行動推定手法[3]は, 居住者が常時センサを装着する必要があり, 装着忘れによるデータの取りこぼしや居住者の負担増となる可能性が高い.

これらの問題に対処するために, 低侵襲・低解像度のセンサを利用する手法も存在する. 例としてスマートハウスに設置された複数のセンサを介して収集されたセンシング情報を利用してリアルタイムに行動を認識する手法[4]や家庭内の各家電に消費電力モニターを設置し, 家電の使用状況を検出することで, 家庭内の行動を認識する手法[5]が存在している. しかしこれらの手法はセンサーの設置, キャリブレーション, 電源供給, 位置管理などのメンテナンスが必要であり, 一定のコストがかかる.

そこで本研究では, 電力会社が消費電力を測定するために設置するスマートメータ等から定期的に取り得られる家庭の総消費電力(主幹電力)データのみを用いて家庭内の大まかな行動パターンを推定する低コストかつ非侵襲な推定手法を提案する. 主幹電力の観測情報は, 一定時間毎に稼働した家電の消費電力や待機電力に加え, 給湯器・温水洗浄便座といった宅内電気設備の消費電力の総量として取得されるため, 家電を個別に把握するためには相当の高解像

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

² 奈良先端大学院大学
Graduate School of Science and Technology,
Nara Institute of Science and Technology

度データが必要となる。例えば、家電の起動時には特有の消費電力の変化が観測できることが多いため、それを把握できれば個別の家電推定は可能であるものの、それには高解像度でのセンシングが必要となり、スマートメータからのデータなどを考慮した場合は現実的でない。また、本研究では異なる家庭に見られる行動パターンの違いを考慮する。各世帯に特化した教師付き学習はデータを用意するのが現実的ではない。従って本研究では異なる家庭データで学習した複数の異なる分類器を用意し、推定したい家庭に最適な分類器を選択する。具体的には、複数の実在の家庭から長期的な行動電力データを収集し、オフライン学習時には各家庭に対して Balanced Random Forest 分類器を訓練する。オンライン判定では、我々が独自に考案した適合度を示す指標を用いて最適な分類器を動的に選択する。その結果、検出行動数は限定されるものの、簡易な単一のセンサでの家庭内行動認識が可能となる。

本アプローチを評価するために、実在する 8 つの独居高齢者の家庭を対象に、30 秒間隔の消費電力データを 191 日間収集し、推定を行った。得られた家庭のプロファイル（所有家電、ビルトイン設備、通常就寝時間など）と、設置された人感センサーのデータをもとに、データセットへの行動のアノテーションを行った。さらに 3 人の大学生にスマートホームで生活してもらい同じく 30 秒間隔の主幹電力データをそれぞれ 60 日分用意した。これらはツールを用いて本人が真値を作成した。これらのデータを用いて、行動認識と分類器選択の精度を評価するための実験を行った。

個別に分類器を作成し分類器選択を行なった場合と収集したデータ全てで分類器を作成し精度を比較した結果、精度が 1.5 から 1.7 倍程度に向上することが確認できた。さらに、提案した適合度を用いた在宅行動認識手法は、高齢者であれば非侵襲的な遠隔監視に有効な外出以外の行動に対して 70%、学生では外出と睡眠に対して 70%を超える認識精度を達成していることを確認した。

2. 関連研究

これまでに、居住者の在宅生活を支援するための様々な家庭内行動認識手法が提案されている。その多くはセンサデバイスと機械学習を用いて家庭内行動を認識する手法である。ここでは、既存研究をカメラ/マイクを用いた手法、ウェアラブルセンサを用いた手法、低コストセンサを用いた手法に分類し述べる。

カメラ/マイクを用いた行動認識は、高い精度での認識が可能である。文献 [2] では、人の動きに関連した 6 行動を、動画フレームにテンプレートマッチングを適用して認識する手法を提案し、約 93~100%の認識精度を達成した。文献 [6] では、局所的な動きと体勢を利用して 10 種類の行動を認識する手法を提案し、約 98%の認識精度を達成した。文献 [7] では、TOF カメラを用いて、関節の動きから 8 種類の行動を認識する手法を提案した。文献 [8] では、加速度センサとスマートフォンのマイクを用いた屋内外行動認識手法を提案し、1 秒間に 7 つの日常生活行動 (ADL) を平均 85%の精度で分類することに成功している。これらの方法は、高い精度で認識を行える一方でプライバシーを侵害するようなデータが収集される。すなわち、被験者が継続的に監視される環境に置かれていることを受け入れる必要があるため、個々の家庭への導入の敷居は高い。

ウェアラブルセンサを用いれば、加速度や人間のバイタルデータを継続的に収集でき、カメラやマイクよりプライバ

シーを侵害しない推定が可能である。文献 [3] では、足と腰に装着した 2 つのウェアラブルセンサを用いた行動認識手法を提案している。文献 [9] では、圧電センサを内蔵したネックレスを用いた食生活モニタリング手法を提案している。文献 [10] では、家電製品の使用時に発生する磁界に着目し、家電製品の使用に関連した日常生活行動を認識する方法を提案している。ウェアラブルセンサはバイタルサインを活用し高精度なモニタリングを行うことができる一方で居住者が常にデバイスを装着しなければならず、定期的な充電の手間、デバイスの装着忘れなどの問題が発生する。

上記の問題点を考慮して、非侵襲的で低コストのセンサを設置する手法が注目されている。文献 [11] では、ドアセンサ、感圧マット、フロートセンサ、温度センサを用いて、「食べる」「テレビを見る」など 10 種類の行動を 49~98%の精度で認識している。さらに、文献 [12,13] では、接触センサ、運動センサ、傾斜センサ、圧力センサなどの各種センサを用いて、「コーヒーを入れる」や「パスタを作る」といった複雑な生活行動を認識する手法を提案している。しかし、前述したようにこれらの方式では複数の異種センサが必要となり、設置や保守にコストがかかる。類似のアプローチとして電力を用いた行動認識も存在する。文献 [14] では、家電製品の動作と消費電力量を結びつけて、消費電力データを用いて行動を認識する方法を提案している。文献 [15,16] では住民の位置と家電製品の消費電力の時系列データから 10 種類の日常生活行動を認識する手法が提案されている。しかし、各家電の電力を個別に収集するためにはコンセントごとにセンサを用いる必要があり、それらの設置および管理コストが必要である。最新のスマートハウスは各コンセントの消費電力を個別に収集できるが、多くの地域や国ではまだ普及していない。

主幹電力データから家電製品の動作状態を推定する方法として NILM (Non-Intrusive Load Monitoring) と呼ばれる手法がある。これは主幹電力から家電製品の動作を把握した上で行動認識に利用する方法である。しかし、既存の NILM は主に 2 つの課題がある。第一に、多くの研究は高周波数 (例えば文献 [17,18] はサンプリングレート 50-100MHz) で測定できる専用の装置を必要とすることである。第二に、高周波数を必要としない研究は家電や住宅ごとに専用のモデルが必要であることである。文献 [19] では、低周波数の消費電力データ (0.2Hz) を用いて 7 種類の行動を認識する手法を提案している。しかし、この手法では、家庭内に存在する全ての家電が分かっていること、それぞれの家電の稼働時の電力を学習に用いることの 2 つの条件を前提にしている。文献 [20] では、同様に低周波数の消費電力データ (0.1Hz) を用いて、5 種類の家電製品の動きを検出することで認知症を認識する手法を提案しているが、これは対象となる家庭の電力と行動データを用いて学習した SVM/RF ベースのモデルが必要となる。すなわち、新しい家庭に導入するたびにモデルを学習させる十分な量の行動データを取得する必要がある、現実的ではない。また、NILM の研究の推定モデルは家庭に存在している家電製品に依存するため、家電製品や宅内電気設備の多様性、行動パターンの多様性などから、一般的な家庭内行動認識システムの構築には不向きな場合が多い。

また、スマートメータで集めた電力から家電製品の消費量を推定するサービス [21] も存在する。しかしこのサービスは、長期的に電力消費量を監視し、各家電製品の電力消費量と月間消費量の比率を算出し、省エネのアドバイスを

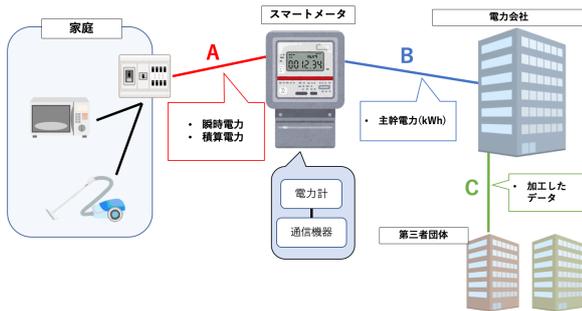


図 1: 家庭内行動推定システムの概要

行うものであり、行動を認識するための方法論を提供するものではない。

3. 提案手法の概要

3.1 提案するシステムの概要

図 1 に、本研究で想定する消費電力データ収集システムを示す。日本では、政府がスマートメータの家庭への導入を推進しており、すでに電力会社が導入を開始しているという背景もあり、ここでは電力会社が各家庭にスマートメータを設置していると仮定する。日本の一般的なスマートメータシステムでは、「顧客」「電力会社」「スマートメータ」の間に、「ルート A」「ルート B」「ルート C」と呼ばれる 3 つの関係が定義されている。ルート B は、スマートメータが家庭からデータを収集するためのもので、スマートメータは瞬時電力や積算電力などの電力使用量をいつでも収集することができる。我々のデータセットでは 30 秒ごとに主幹電力を収集している。提案手法では、家庭の主幹電力データが利用可能であることを前提とし、その情報をサービスに活用することを考える。

3.2 提案手法

我々の行動認識手法は、文献 [22] で定義された日常生活行動 (ADL) に含まれる「睡眠」、「外出」、「料理」の 3 つの代表的な行動に焦点を当てている。また、これら 3 つの ADL のいずれにも該当しない他の行動を含むカテゴリとして「その他」を想定している。提案手法は、対象者の行動を利用した遠隔見守りなどのサービス向けに設計されており、文献 [23], [24] によると睡眠時間の短縮、食事の減少、外出時間の減少などの生活パターンの変化は、精神疾患の兆候であることがわかっている。これらの事実を踏まえ、目標を達成するためには、睡眠、外出、料理などが基本的かつ有用であると結論付けこれらを推定する行動とした。

提案する行動認識アルゴリズムは以下のように動作する。まず t 秒 (我々のデータセットでは $t = 30$) ごとに収集された主幹電力データを、 T 分のウィンドウデータに分割する。ここで T が短いと、認識に十分な特徴量を抽出できない可能性がある。特に、そのウィンドウを特徴づける主要素の一つである電力のピークの数が増減してしまい、推定精度に影響を与える可能性がある。逆に T が長い、例えば $T = 60$ のような場合には、1 つのウィンドウ内で複数の行動が発生し、正しい推定を行うのが困難となる。そこで、見守りサービスの運用を検討している数社に相談した

ところ、30 分間隔 ($T = 30$) が見守りを考慮した行動認識に適した粒度であるとの結論に至った。

そして各ウィンドウについて、教師付き学習を適用してそのウィンドウの最も確率の高い行動を推定する。ここでの課題は、家ごとに生活パターンが異なる中推定モデルをどのように構築するかである。行動データを得ることの難しさを考えると家ごとに教師データを用意して都度学習を行うのは合理的ではない。あらかじめ用意した別のモデルを活用して少ないデータ量から対象の特徴を捉えた分類器を作成する手法として転移学習 [25] が存在するが、こちらも家ごとに行動データを用意する必要があるのは変わりなく、依然として実運用するには現実的ではない。そこで我々はデータセットを活用して、様々なタイプのライフスタイルに適合できるよう分類器を複数用意し、対象となる家庭のデータに最適な分類器を行動データなしに見つけることができる分類器選択指標を開発した。詳細は次章で説明する。

4. 行動推定アルゴリズム

4.1 特徴量と学習アルゴリズム

前節で述べたように、与えられた主幹電力データを長さ T (分) のウィンドウデータに分割し、各ウィンドウの特徴量を抽出する。そして、各ウィンドウの行動ラベルとして、*goingout* (外出), *sleeping* (睡眠), *cooking* (料理), *others* (その他) の 4 つのラベルのうち 1 つを与え、それを用いて多クラス分類器を訓練する。ここで、日本人の 1 日の平均睡眠時間は 7.5 時間であり、料理は多くの場合 1 日 2 時間程度にしかならない。したがって得られたデータそのままでは、「料理」のデータよりも、「睡眠」のデータの方がはるかに多くなる。このような不均衡なデータをそのまま学習すると数が多いラベルの精度のみが高くなるという不均衡な分類器ができてしまう。そこで、我々は分類器のモデルとして、ランダムフォレストの拡張版であり、不均衡なデータに対応できる Balanced Random Forest (BRF) を採用した。BRF は、決定木を作成する際にサンプルの部分集合を作成し、教師データその部分集合の組み合わせで表現することでサンプルのバランスをとるように教師データを作成する。

次に得られた主幹電力データから特徴量を決定するための知見を得るため代表的な家電製品の消費電力がどのように現れるか、2018 年 12 月 26 日から 2019 年 1 月 25 日までの 25 日間、実際の家庭で予備実験を行った。洗濯機、テレビ、電子レンジ、加湿器、ドライヤー、ガスストーブ (電気制御)、オーブントースターの消費電力を市販のワットモニターを用いて 30 秒間隔で個別に測定し、それらの消費電力を単純に合算した擬似的な主幹電力データを得た。

図 2 および図 3 に、実験で得た個別家電の消費電力とそれに対応する擬似主幹電力データの例を示す。個々の消費電力を見ると、調理家電 (オーブントースター、電子レンジ) と乾燥機は、稼働開始時と稼働終了時に消費電力のピークが明確に見られた。一方、ガスコンロや加湿器は、一定の電力 (約 800W) を消費しながら長時間稼働していた。また、テレビや洗濯機も、消費電力の時間変化が他の機器に比べて大きいものの、比較的長時間稼働していることがわかった。

この実験で得たデータを分析することで、以下のような知見を得ることができた。第一に、家電製品の稼働が観察されない場合は、家電製品を使用しない行動である「睡眠」「外出」「その他 (のうち、読書など電気を使用しない行動)」

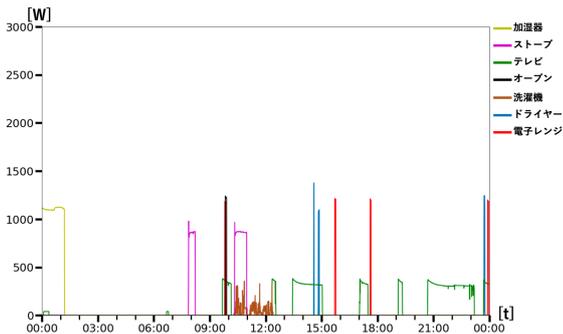


図 2: 家電ごとの個別の消費電力

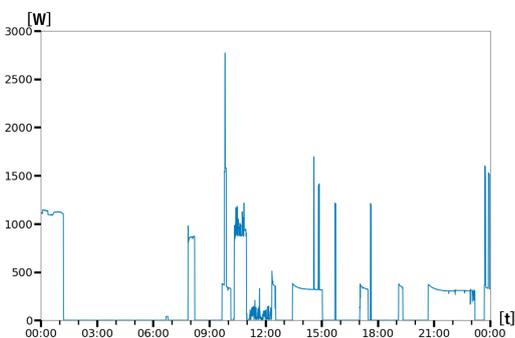


図 3: 合算した消費電力

の状態にある可能性が高い。第二に、一日の中の主幹電力の最小値と比較して、観測された主幹電力の値が十分に大きい場合には、その時間帯にエアコン等の家電製品が稼働している可能性があり、「外出」の可能性は低い。第三に、時間帯を考慮することで、「外出」と「睡眠」は大まかに区別することができる。第四に電子レンジやオーブントースター、IH クッキングヒーターなどの調理家電は、加熱が必要なため、消費電力が大きくなる傾向がある。第五に、洗濯機の消費電力は、予備実験で見られたように安定しておらず、主幹電力データの分散に現れている可能性がある。最後に、前のウィンドウの行動と主幹電力は、現在のウィンドウの行動と相関関係を持っている可能性があり、これも特徴量として考慮すべきである。

以上の考察に基づいて、各ウィンドウについて、ピークの数、ピークの平均値、2つの連続した主幹電力値の差、主幹電力の最小値、最大値、平均値、標準偏差、および高速フーリエ変換 (FFT) によって得られたパワースペクトル、直前の6つの時間窓における主幹電力の最小値、最大値、標準偏差、および直前のウィンドウにおける行動を、分類器を訓練するための特徴量として使用した。電子レンジなどの調理家電は短時間で大量のエネルギーを消費することが多く、その特徴が高周波成分に現れ、テレビのように長時間稼働する家電製品は、低周波成分に影響を与える可能性があるためパワースペクトルも特徴量として用いた。また推定の段階では直前の行動の真値は使用できないため推定した行動を特徴量として使用する。特徴量は133次元となった。

4.2 分類器選択

今回使用する主幹電力データは粒度が粗く、個人に依存する特徴を多く持つため、選択された特徴量と行動の関係が家庭によって異なる場合がある。この問題は、家庭ごとに分類器を訓練、構築できれば解決する可能性があるが、分類器を学習するためには、各家庭から行動データを収集する必要があるため、現実的ではない。既存の分類器を用いて、推定対象に合わせた固有の分類器を得る転移学習 [25] という手法もあるが、対象となる家庭の学習データが必要であることには変わりなく、実環境への展開は難しい。

これに対し我々は異なるタイプの家庭に対応する複数の分類器を構築し、その上で、対象家庭に最適な分類器を選択して行動を推定するための新しい指標を提供する。各分類器の対象家庭への適合度は、その分類器の訓練データと得られたテストデータの関数として定義される。図4に適合度の計算手順を示す。ここでは、 $1, 2, \dots, N$ の家庭があると仮定する。まず、オフラインの段階で、ホーム i の訓練データ (f_i) を用いて、ホーム i の分類器を訓練する。このとき、 TR_i は、消費電力データとそれに対応した行動ラベルから構成されている。オンライン段階では、新しい家 z ($z \notin [1, N]$) からのテストデータを、 N 個全ての分類器 (f_1, \dots and f_N) に与え、行動認識を行う。各分類器 i から予測された行動の集合 ($f_i(z)$) は、訓練データ TR_i を用いて、適合度関数 ($score_i$) に入力される。そして、 $score_i$ は、 $f_i(z)$ と TR_i の類似度を計算し、この2つのデータセットの適合度を返す。最後に、最も適合度が高い分類器で推定された $f_i(z)$ を最終的な推定結果として選択する。

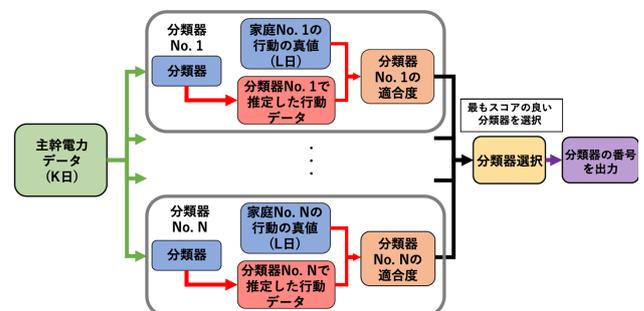


図 4: 分類器選択の概要

様々な分類器とテストデータの組み合わせを分析したところ対象家庭と生活習慣が似ていない、つまり適していない分類器では推定結果が特定の行動に偏るアンバランスな結果となること、生活習慣が似ている家庭では、「睡眠」「外出」「料理」の頻度が似ている傾向があることを発見した。従って本研究ではそれぞれの行動の出現率を指標にして、2つの家庭間の類似性を評価する。

具体的には4つの行動ラベルの集合 ACT 内の各行動ラベル a に対して、与えられたデータセット内の行動ラベル a の出現回数をカウントする関数を $\#a$ に定義する。そして得られたテストデータの推定結果と訓練データの行動の割合の比の総和を取ることによって割合の類似度としている。これを ratio score と名付け以下の数式で定義する。

$$\#a(TR_i) = \sum_{u=1, \dots, L} \sum_{t=1, \dots, 48} pred(TR_i(u, t) = a) \quad (1)$$

$$\#_a(f_i(z)) = \sum_{v=1, \dots, K} \sum_{t=1, \dots, 48} \text{pred}(f_i(z)(v, t) = a) \quad (2)$$

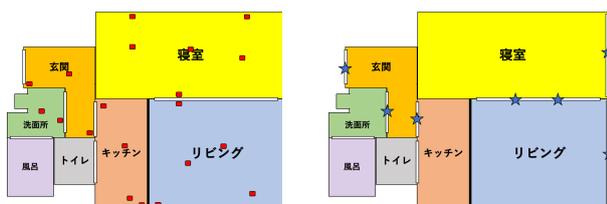
$$\text{ratio_score}_i = \frac{1}{|\text{ACT}|} \sum_{a \in \text{ACT}} 1 - \frac{\min\{\#_a(\text{TR}_i), \#_a(f_i(z))\}}{\max\{\#_a(\text{TR}_i), \#_a(f_i(z))\}} \quad (3)$$

5. 評価

5.1 実験環境

提案手法を評価するために2つの環境でデータを収集し評価を行った。まず、独居高齢者8家庭から、電力会社と共同でデータを収集した。各家庭の配電盤に設置したランプで30秒ごとに消費電力を191日間計測、集計した。商用スマートメータは数十秒から数十分のサイクルで電力を収集できるが、機器によってサイクルが異なる。この方法では、スマートメータと似たような収集間隔を持つ電力測定装置を使用し、その装置の最小間隔である30秒を使用した。行動ラベルに関しては、人感センサの値と我々の知見および対象家庭から得ている家庭のおおまかなプロフィール（年齢性別と所有機器等）に基づき、これら双方のデータを総合して我々自身がラベル付けを実施しこれを真値として用いている。行動ラベルはgoing out（外出）、sleeping（睡眠）、cooking（調理）およびothers（調理以外の在宅状態）としている。

2つ目は奈良先端大学院大学が有する1LDKスマートホーム環境で学生が生活した際のデータを収集した。スマートホームには消費電力センサ、環境センサ、超音波位置センサ、ドアセンサ、水栓センサが設置されており、本研究では基本的に評価に消費電力センサを用い、5.4節の主幹電力以外のセンサを併用した場合の精度評価に、環境センサ、ドアセンサを追加して用いる。電力センサではコンセントごとに1秒ごとに電力を収集している。そのため提案手法で利用できるよう、その値を全て集約し30秒ごとに30のデータ群に分割した。同様の理由で人感センサとドアセンサの値は30秒ごとに反応したかを1と0で持つように整形した。3名の大学生がそれぞれ2日間生活したため、各被験者60日分のデータとなった。上田らの研究グループが開発したツール[26]を用いて行動データのラベリングを行った。以下、高齢者の家庭のデータをNo.1-8、大学生のデータをNo.9-11とする。No.9-11の家の間取り図と人感、ドアセンサが設置されている場所を図5に示す。



(a) 人感センサの設置場所 (b) ドアセンサの設置場所
 図5: 家庭No.9-11の間取り図とセンサの設置箇所

5.2 分類器選択の評価

分類器選択の効果を評価するために、各家庭について、選択された分類器を、1) 全てのデータセットで訓練された分類器、2) 対象となる家庭データのサブセットで訓練された分類器、3) 分類器の適合度が低いために選択されなかった残りの分類器、と合計3種類の比較を行った。

5.2.1 全てのデータセットで訓練された分類器との比較

まず、提案手法をすべての学習データセットに対して学習された典型的な分類器と比較した。各家庭の推定の平均F値を図6に示す。各テストデータセットについて、選択された分類器は、全ての学習データセットを用いた分類器と比較して、1.5倍から1.7倍の精度に精度が向上することが確認できた。

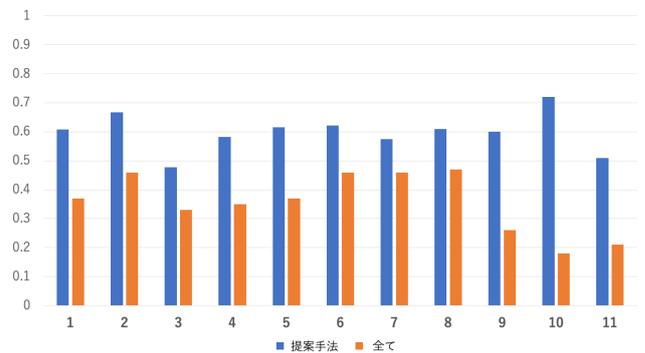


図6: 各家庭の全てのデータで訓練された分類器と提案手法で選択した分類器の平均F値

5.2.2 対象となる家庭データのサブセットで訓練された分類器との比較

一般的に、テストデータセットと同じ環境のデータでモデルを訓練した場合、それらは類似した特徴を持っているため、認識精度は高くなる。そのため理想環境として推定対象家庭のデータのサブセットで訓練された分類器を用意し精度を比較した。今回は推定対象のデータセットごとに5-fold交差検証を行い、その平均F値を提案手法と比較した。結果を図7に示す。提案手法は、対象となるホームデータセットのサブセットで学習したモデルと比較して、ほぼ全ての家庭で同等以上の認識精度が得られることが確認できた。

5.2.3 選択されなかった分類器と比較

比率スコアを用いた分類器選択が精度向上に寄与しているかどうかを評価する。図8にNo.1をテストデータとした際のF値とNo.10をテストデータとした時のF値を示す。赤で示された分類器が選択された分類器である。No.1をテストデータにした時はNo.7のデータで作られた分類器、No.10をテストデータにした時はNo.11から作られた分類器が最も高い認識精度を示しており、分類器の選択が正しく行われたことがわかる。同様に、他のすべてのデータセットについても、提案手法が最も認識精度の高い分類器を選択していることを確認した。また図8aでは高齢者(No.7)のデータから作られた分類器、図8bでは大学生(No.11)のデータから作られた分類器が最も精度が高いことから似たような生活パターンの家庭で作成した分類器が高い精度で推定を行えることが確認できた。

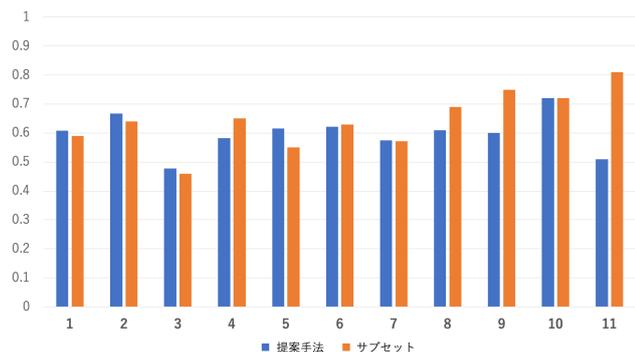
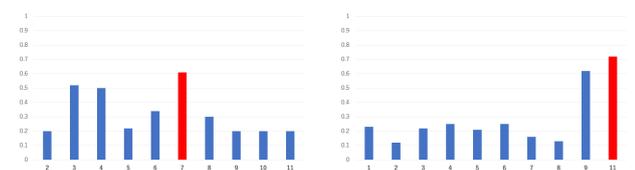


図 7: 各家庭の対象となる家庭データのサブセットで訓練された分類器と提案手法で選択した分類器の平均 F 値



(a) 家庭 No. 1 をテストデータとした時の各家庭の分類器の F 値
 (b) 家庭 No. 10 をテストデータとした時の各家庭の分類器の F 値

図 8: 家庭 No. 1 と家庭 No. 10 での全ての分類器の F 値 (赤色が選択された分類器)

5.3 行動ごとの精度評価

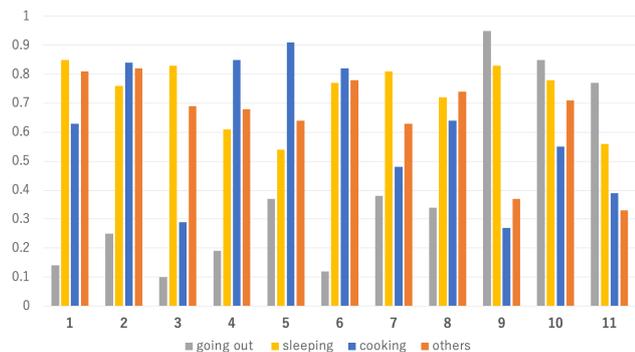


図 9: 各家庭の行動ごとの F 値

図 9 に、各データセットの各行動の F 値を示す。提案手法では No. 1-8 の家庭について、「睡眠」、「料理」、「その他」で、約 70% の精度を達成している。一方「外出」での精度は 23% と低いものとなった。これはほとんどの場合、「その他」として認識されていた。高齢者は家にいても電気を使用しないことが多く、そのような在宅時と外出時の電力使用量に明確な差がないことと、外出する時刻が一定でなかったため正しく認識できなかったと考えられる。一方学生は「睡眠」の精度は 90%、「外出」も 70% 超えと高くなった。「外出」の精度がここまで高くなったのは高齢者

と比較し外出する時刻が一定であるからだと考えられる。しかし「料理」と「その他」の精度は高齢者と比較して低いものとなった。これは炊飯器を使用している場合の行動の真値は「その他」であり、その時刻と電力は「料理」の時とほぼ差がないためこれらを多く誤推定したためと考えられる。高齢者のデータは主幹電力からラベル付けをしたため、炊飯器の使用と推測されるものは「料理」とみなされた。

5.4 他センサと併用した場合の精度評価

電力以外のセンサデータを用いた場合の精度について評価を行うため No. 9-11 の家庭で主幹電力だけではなく、ドアセンサ、人感センサの値を用いた場合の精度を確かめた。まず最初に人感センサ、ドアセンサ共に全ての箇所のセンサを用いてセンサの種類を組み合わせを変化させながら 3 家庭の各行動の F 値の平均値を確認した。結果を図 10 に示す。

単種類のセンサを用いた場合の精度は高い方から人感、主幹電力、ドアセンサという順になった。主幹電力では炊飯器と調理家電の使用の判別や睡眠と読書などの電気を使用しないその他の行動との判別が難しかった。人感センサを用いた場合、このような誤判定を減らすことができた。これらのケースにおいて、調理中は長い間キッチンにいる、睡眠は寝室にいるが静養はリビングにすることが多いというように被験者がいる部屋が異なるためだと考えられる。逆に通過のみがわかるドアセンサの情報だけでは精度はかなり低くなった。また、外出でなく玄関に立ち寄る、調理でなく物を取りにキッチンに立ち寄りといった行動が推定を混乱させることがあり、他のセンサと組み合わせても精度が低下した。最終的に人感に電力を組み合わせると精度が最も高くなり「睡眠」、「外出」、「料理」の F 値 0.8、「その他」は F 値 0.6 という精度が得られた。

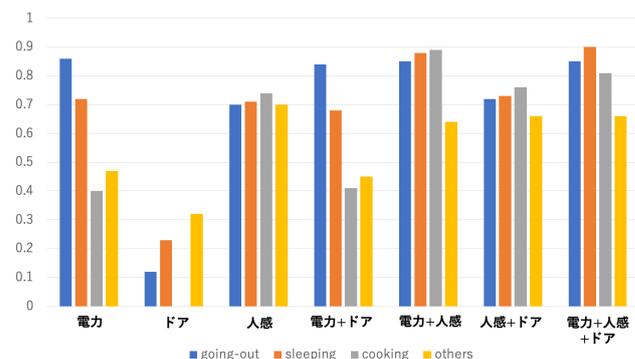


図 10: F-measure for each combination of sensors

次に人感センサの設置場所による精度を評価した。人感センサを場所ごとに分け、主幹電力センサの値に追加した時の 3 世帯の F 値の平均の一覧を図 11 に、主幹電力のみの場合と比較した時の F 値の差分を表 1 に示す。単一の場所に設置した場合、キッチンと寝室で特に大きい F 値の向上が見られた。キッチンにセンサを置くことで「料理」と「その他」の F 値が大きく向上しているため前述した電気のみでは解決できない「料理」と「その他」の誤判定が減らされているとわかる。同様に寝室に置くことで「睡眠」と

「その他」の誤判定を減らし F 値を向上させることができる。逆に他の場所ではこれらの問題点を解決できないため精度が大きく向上することはなかった。またこれらの理由によりキッチンと寝室両方においた場合精度の向上が大きく全ての場所の人感センサを用いた場合と平均の F 値の差が 0.02 なかった。以上より追加コストを支払ってでも精度を向上させたい場合には、キッチンと寝室に人感センサを設置するのが効果的だといえる。

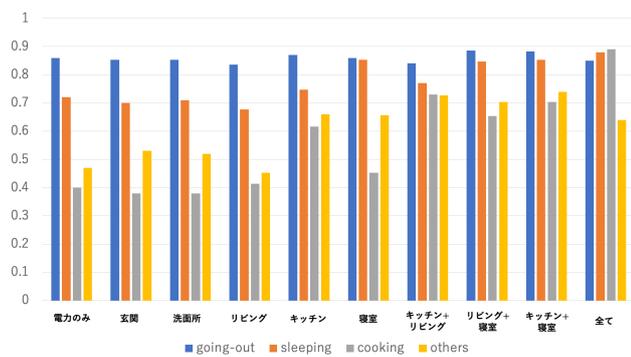


図 11: 人感センサの位置ごとの各行動の F 値

表 1: 人感センサの位置ごとの主幹電力のみの時との F 値の差分

activity	玄関	洗面所	リビング	キッチン	寝室
going-out	+0	+0	-0.02	+0.01	+0
sleeping	-0.02	-0.01	-0.04	+0.03	+0.13
cooking	-0.02	-0.02	+0.01	+0.21	+0.05
others	+0.06	+0.05	-0.02	+0.19	+0.19
average	+0	+0	-0.02	+0.11	+0.09

activity	キッチン+寝室	リビング+寝室	キッチン+リビング	全て
going-out	-0.02	+0.03	+0.02	-0.01
sleeping	+0.05	+0.13	+0.13	+0.16
cooking	+0.33	+0.25	+0.30	+0.49
others	+0.26	+0.23	+0.27	+0.17
average	+0.16	+0.16	+0.18	+0.20

6. おわりに

本稿では、スマートメータで収集された主幹電力データのみを用いて、家庭内行動を認識する低コストかつ非侵襲的な手法を提案した。8つの独居高齢者の家庭から191日間、スマートホーム内の3人の学生から60日間得られたデータセットを用いて、1つの家庭データのみで学習した11種類の分類器を構築し、分類器の適合度に基づいて最適な分類器を選択する手法を提案するという、独自のアプローチを提供した。実験の結果、低解像度の電力消費量データセットを用いても、高齢者は4行動中3行動で平均 F 値約 0.7、学生は4行動中2行動の平均 F 値が 0.7 以上となり、また提案した適合度が最適な分類器を選択できることを確認した。さらに人感センサ、ドアセンサといった他のセンサとの併用を想定した推定を行った。結果主幹電力に加えキッチンと寝室に人感センサを配置することで、電力だけでは判断しにくい部分を補い全ての行動の平均 F 値が 0.7 以上となることを示した。

参考文献

- [1] Statistics Bureau of Japan: 2015 Census Population Basic Summary Results.
- [2] Li, C. and Hua, T.: Human action recognition based on template matching, *Procedia Engineering*, Vol. 15, pp. 2824–2830 (2011).
- [3] Lee, S.-W. and Mase, K.: Activity and location recognition using wearable sensors, *IEEE pervasive computing*, Vol. 1, No. 3, pp. 24–32 (2002).
- [4] Chen, L., Nugent, C. D. and Wang, H.: 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).
- [5] Zhang, X., Kato, T. and Matsuyama, T.: Learning a context-aware personal model of appliance usage patterns in smart home, *Proceedings of 2014 IEEE Innovative Smart Grid Technologies-Asia*, IEEE, pp. 73–78 (2014).
- [6] Rostamzadeh, N., Zen, G., Mironică, I., Uijlings, J. and Sebe, N.: Daily living activities recognition via efficient high and low level cues combination and fisher kernel representation, *Proceedings of International Conference on Image Analysis and Processing*, Springer, pp. 431–441 (2013).
- [7] Nakahara, K., Yamaguchi, H. and Higashino, T.: In-home Activity and Micro-motion Logging Using Mobile Robot with Kinect, *Proceedings of the 13th International Conference on Mobile and Ubiquitous Systems: Computing Networking and Services*, pp. 106–111 (2016).
- [8] Ouchi, K. and Doi, M.: Smartphone-based monitoring system for activities of daily living for elderly people and their relatives etc., *Proceedings of 2013 ACM Conf. Pervasive and Ubiquitous Computing Adjunct Publication*, ACM, pp. 103–106 (2013).
- [9] Kalantarian, H., Alshurafa, N., Le, T. and Sarrafzadeh, M.: Monitoring eating habits using a piezoelectric sensor-based necklace, *Computers in biology and medicine*, Vol. 58, pp. 46–55 (2015).
- [10] Maekawa, T., Kishino, Y., Sakurai, Y. and Suyama, T.: Recognizing the use of portable electrical devices with hand-worn magnetic sensors, *Proceedings of International Conference on Pervasive Computing*, Springer, pp. 276–293 (2011).
- [11] Van Kasteren, T., Englebienne, G. and Kröse, B. J.: An activity monitoring system for elderly care using generative and discriminative models, *Personal and Ubiquitous Computing*, Vol. 14, No. 6, pp. 489–498 (2010).
- [12] Chen, L., Nugent, C. D. and Wang, H.: A knowledge-driven approach to activity recognition in smart homes, *IEEE Trans. Knowl. Data Eng.*, Vol. 24, No. 6, pp. 961–974 (2012).
- [13] Fleury, A., Vacher, M. and Noury, N.: SVM-based multi-modal 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 (2010).
- [14] Rollins, S. and Banerjee, N.: Using rule mining to understand appliance energy consumption patterns, *Proceedings of 2014 IEEE International Conference on Pervasive Computing and Communications*, IEEE, pp. 29–37 (2014).
- [15] Kenki Ueda, Morihiko Tamai, Yutaka Arakawa, Hirohiko Suwa, Keiichi Yasumoto: A Living Activity Recognition System Based on Power Consumption of Appli-

- ances and Inhabitant's Location Information, *Information Processing Society of Japan Transactions*, Vol. 57, No. 2, pp. 416–425 (2016).
- [16] Mizumoto, T., Pattamasiriwat, K., Arakawa, Y. and Yasumoto, K.: Improving recognition accuracy for activities of daily living by adding time and area related features, *Proceedings of 2017 Tenth International Conference on Mobile Computing and Ubiquitous Network*, IEEE, pp. 1–6 (2017).
- [17] Patel, S. N., Robertson, T., Kientz, J. A., Reynolds, M. S. and Abowd, G. D.: At the flick of a switch: Detecting and classifying unique electrical events on the residential power line (nominated for the best paper award), *Proceedings of International Conference on Ubiquitous Computing*, Springer, pp. 271–288 (2007).
- [18] Belley, C., Gaboury, S., Bouchard, B. and Bouzouane, A.: An efficient and inexpensive method for activity recognition within a smart home based on load signatures of appliances, *Pervasive and Mobile Computing*, Vol. 12, pp. 58–78 (2014).
- [19] Lee, S.-c., Lin, G.-y., Jih, W.-r. and Hsu, J. Y.-j.: Appliance Recognition and Unattended Appliance Detection for Energy Conservation., *Plan, Activity, and Intent Recognition*, pp. 37–44 (2010).
- [20] Biansoongnern, S. and Plungklang, B.: Non-intrusive appliances load monitoring (nilm) for energy conservation in household with low sampling rate, *Procedia Computer Science*, Vol. 86, pp. 172–175 (2016).
- [21] Bidgely: Technology-Bidgely <https://www.bidgely.com/technology/>.
- [22] Logan, B. and Healey, J.: Sensors to detect the activities of daily living, *Proceedings of the 28th Annual International Conference on Engineering in Medicine and Biology Society*, IEEE, pp. 5362–5365 (2006).
- [23] Anderson, L.: SKIPPING MEALS IS ASSOCIATED WITH SYMPTOMS OF ANXIETY AND DEPRESSION IN A NATIONALLY REPRESENTATIVE SAMPLE OF OLDER ADULTS, *The American Journal of Geriatric Psychiatry*, Vol. 28, No. 4, pp. S128–S129 (2020).
- [24] Heller, A. S., Shi, T. C., Ezie, C. C., Reneau, T. R., Baez, L. M., Gibbons, C. J. and Hartley, C. A.: Association between real-world experiential diversity and positive affect relates to hippocampal–striatal functional connectivity, *Nature Neuroscience*, pp. 1–5 (2020).
- [25] Wang, M., Li, W. and Wang, X.: Transferring a generic pedestrian detector towards specific scenes, *Proceedings of 2012 IEEE Conference on Computer Vision and Pattern Recognition*, IEEE, pp. 3274–3281 (2012).
- [26] Ueda, K., Ooki, H., Mizumoto, T., Tamai, M. and Yasumoto, K.: A System to Support Understanding of Daily Life Activities through Visualization and Association of Multiple Sensing Data, *DPS Workshop in Japanese*, Vol. 2013, No. 6, pp. 116–118 (2013).