

省エネ行動推進のためのサービス改良に向けた研究

平井 駿[†] 中田 匠哉[†] 佐伯 幸郎^{††} 陳 思楠[†] 中村 匡秀^{†,††}

[†] 神戸大学 〒657-8501 神戸市灘区六甲台町 1-1

^{†††} 理化学研究所・革新知能統合研究センター 〒103-0027 東京都中央区日本橋 1-4-1

^{††} 高知工科大学 〒782-8502 高知県香美市土佐山田町宮ノ口 185

E-mail: [†]{hirashun,tnakata}@es4.eeddept.kobe-u.ac.jp, ^{††}saiki.sachio@kochi-tech.ac.jp,

^{†††}chensinan@gold.kobe-u.ac.jp, ^{††††}masa-n@cmds.kobe-u.ac.jp

あらまし 現在、気候変動、特に地球温暖化は世界的に深刻な問題となっており、これに対処するために日本政府はゼロカーボン社会を目標に掲げている。ゼロカーボンを実現するには、個々人の省エネ行動を促進することが不可欠である。この省エネ行動を促進することを目的とした先行研究として、消費予測をもとに仮想エージェントから省エネ行動を通知する手法の提案を行った。しかしこの先行研究には、消費予測モデルの評価が十分でない、天候の影響を考慮した消費予測が行えていないといった問題点が存在する。本研究では、先行研究での機械学習を用いた消費予測モデルと他モデルとの比較検討を行う。また、特徴量として天候情報を追加し、消費予測精度が向上するかを確認する。実データを用いた評価により、特徴量の追加による消費予測精度の向上が確認され、機械学習モデルの評価と改良を行うことでより精度の高いモデルの構築を行うことができた。

キーワード ゼロカーボン、省エネ行動、消費電力、機械学習

A Study of service improvements for promoting energy-saving behaviors

Shun HIRAI[†], Takuya NAKATA[†], Sachio SAIKI^{††}, Sinan CHEN[†], and Masahide NAKAMURA^{†,††}

[†] Kobe University Rokkodai-cho 1-1, Nada-ku, Kobe, Hyogo 657-8501 Japan

^{†††} Riken AIP 1-4-1 Nihon-bashi, Chuo-ku, Tokyo 103-0027 Japan

^{††} Kochi University of Technology, 185 Miyanokuchi, Tosayamada, Kami City, Kochi 782-8502, JAPAN

E-mail: [†]{hirashun,tnakata}@es4.eeddept.kobe-u.ac.jp, ^{††}saiki.sachio@kochi-tech.ac.jp,

^{†††}chensinan@gold.kobe-u.ac.jp, ^{††††}masa-n@cmds.kobe-u.ac.jp

Abstract Climate change, particularly global warming, has become a serious worldwide issue. To address this, the Japanese government has set a goal of achieving a zero carbon society. To realize zero carbon emissions, it is essential to promote energy-saving behaviors among individuals. In a previous study aimed at promoting such energy-saving behaviors, a method was proposed to notify users of energy-saving actions through a virtual agent based on consumption predictions. However, this previous study had some issues, such as insufficient evaluation of the consumption prediction model and lack of consideration for weather influences in consumption forecasts. In this research, we compare the machine learning-based consumption prediction model from the previous study with other models. Additionally, we add weather information as a feature to verify if it improves the accuracy of consumption predictions. Through evaluation using real data, it was confirmed that the addition of features improved the accuracy of consumption prediction. By evaluating and refining the machine learning models, we were able to construct more accurate models.

Key words Zero carbon, Energy-saving behavior, Power consumption, Machine learning

1. はじめに

現在、気候変動の中でも特に地球温暖化が世界的な問題として浮上している。世界的に見ると平均気温は上昇傾向にあり、

海面上昇など多くの問題を生じさせている。これらの問題に対処するため、日本政府はゼロカーボン社会の実現を目指している。ゼロカーボン社会とは、温室効果ガスの排出量と吸収量を実質ゼロにすることを意味する。そのためには、エネルギーの

削減が不可欠であり、その中でも本研究では、宅内での省エネ行動に着目した。先行研究として、消費電量管理サービスと仮想エージェント (VA) を連携した、宅内省エネ行動を推進する手法が提案されており、このサービスでは機械学習を用いた消費予測が行われている。しかし、この手法には以下の問題点がある。

P1: 天候情報を考慮せずに消費予測を行っている

P2: 提案された機械学習モデルの評価が不十分

これらの問題点を踏まえ、本研究では従来の手法の評価、改良を行い、より効果的な省エネ行動推進を目指す。キーマイデアは、機械学習モデルの改良と評価を行うことと、通知内容をユーザに伝わりやすくすることである。提案手法は以下の3つのアプローチからなる。

A1: 天候情報を機械学習を行う際の特徴量に追加

消費予測の際に天候情報を特徴量として追加し、消費予測精度の向上を図る。具体的には、湿度と気圧を特徴量と追加することで天候情報を考慮することが可能になる。

A2: 機械学習モデルの比較による評価

先行研究で提案された機械学習モデルと他のモデルを比較し、より良いモデルの構築を目指す。本研究では、上記のアプローチを元に機械学習モデルの評価、改良を行い、より良いモデルの構築を可能とした。これにより、省エネ行動の促進に寄与することが期待される。

2. 準備

2.1 背景

近年、気候変動、特に地球温暖化が世界的に深刻な問題となっている。2020年の時点で産業化前の時代(1850年~1900年)と比べて地球の平均気温が約1.1℃上昇したことが示されている。地球温暖化によって、豪雨や熱波の頻度が増加し、多くの産業に影響を与えるとされている。この地球温暖化の主たる原因である温室効果ガスは、経済活動や我々の日常生活から排出されており、その中でも特に衣食住や移動による日常的な行動を起因とする排出が全体の約6割を占めるという分析結果もある。これに対処するため日本政府は2020年10月に、2050年までに温室効果ガスの排出と吸収を合計で実質ゼロにする**ゼロカーボン(カーボンニュートラル)**の社会を目指すことを宣言した[1]。ゼロカーボンを実現するためには、特にCO₂などの温室効果ガス排出量を大幅に削減することが不可欠で、これはエネルギー問題とも深く関連している[2][3]。

2.2 LightGBM

LightGBM (Light Gradient Boosting Machine) は、機械学習の分野における解析技術で、決定木アルゴリズムを用いて特徴量から出力の予測を行う教師あり学習の手法の一種である。LightGBMでは未知の値を予測する回帰と、説明変数をグループ分けする分類の両方を行うことが可能である。決定木アルゴリズムとは、特徴量に基づいて目標変数を木構造のモデルとして分類する方法である。LightGBMは決定木分析を実施した後、予測が不正確だった場合に予測値と実測値の差を算出し、その差に対する学習を反復して精度を向上させる、勾配ブースティ

ングという技術を採用している。LightGBMは処理が迅速でありながら高い精度を実現することが特徴である[4][5]。

2.3 先行研究

2.3.1 消費電力管理サービス

先行研究として、省エネ行動を推進するために**消費電力管理サービス**の開発を行った。このサービスはIoTデバイスを用いて取得した家電別消費電力データを管理するサービスである。消費電力管理サービス上では、ベースラインが自動的に設定される。ベースラインはユーザの基本的な消費電力量を表し、実際の消費電力とベースラインとを比較して通知文の作成が行われる。このベースラインは後述する消費電力予測サービスにより予測された将来の消費電力量に一定の係数をかけた値が設定される。この係数はユーザのフィードバックにより調整され、個人に適応したベースラインの設定と通知文の作成を可能にしている。また、消費電力管理サービスは、消費電力データをグラフや表などの多様な形式で可視化し、ユーザに提示する機能を有する。加えて、家電の制御も可能である。消費電力の可視化が省エネ意識の向上に寄与することは知られている[6]。このサービスを通じて、ユーザは個人に適応したベースラインを設定し、それに基づく通知を受け取ることができる。通知は省エネ行動推進サービスというサービスと連携して、仮想エージェントを通じて送信される。さらに、リアルタイムの消費電力量および過去のデータをグラフや表の形式で閲覧することが可能である。さらに、ユーザは削減目標を設定でき、一定期間内に削減する消費電力の目標を確認することができる[7]。消費電力管理サービスの画面を図1と2に示す。また通知を行う仮想エージェントの画面を図3に示す。




図1 消費電力管理サービスの画面(1日あたりの消費電力のグラフと表)[7]




図2 消費電力管理サービスの画面(削減目標グラフ)[8]

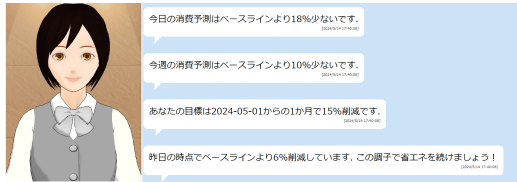


図3 仮想エージェントの画面 [7]

2.3.2 消費電力予測サービス

また先行研究として、ベースライン設定のために将来の消費電力を予測する消費電力予測サービスの開発を行った。このサービスは、機械学習を用いて過去のデータから消費電力の予測を行う。機械学習モデルには LightGBM モデルを利用し、[9] を参考に以下に表 1 のとおりに特徴量を設定した。

表 1 消費電力予測に用いた特徴量

識別	詳細
気温	予測当日 0 時から 23 時までの、1 時間粒度の気温データ (°C)
日付	1 月 1 日から 12 月 31 日まで、0~1 の範囲で 365 段階にラベルエンコーディングした値 d を用いて、 $\sin(2\pi d)$ と $\cos(2\pi d)$ に変換した値
曜日	各曜日と祝日を One-Hot エンコード
時間	0 時から 23 時までの時間帯を One-Hot エンコード

気温のデータは気象庁が公開しているデータを利用した [10]。出力は 1 時間粒度の消費電力データとする。具体的な消費予測手法を以下に示す。

まず、過去のデータを家電がオン状態かオフ状態かで分け、それぞれでモデルの作成を行う。それぞれのモデルを ON モデル、OFF モデルとする。同様に、デバイスがオンであるかどうかを予測するために上記の特徴量からデバイスがオンである確率を学習する。この確率が一定のしきい値を超えたときにオンと判定する。消費予測を行う際には、先にデバイスがオンであるかオフであるかを予測してから、ON モデルか OFF モデルのどちらを利用して消費予測を行うかを選択する [8]。

このサービスは、消費電力管理サービスと連携し、ベースラインの設定に利用される。

2.4 先行研究の問題点

先行研究では以下の 3 つの問題点があげられる。

P1: 天候情報を考慮せずに消費予測を行っている

消費予測サービスでは、気温を特徴量として用いているが、湿度や気圧などの天候情報を特徴量として用いていない。天候情報は消費電力に影響を与えるため、これらの情報を特徴量として追加することで消費予測精度の向上が期待できる。

P2: 提案された機械学習モデルの評価が不十分

消費予測サービスでは LightGBM を用いて消費電力データをオン状態とオフ状態で分割し消費予測を行っているが、他のモ

デルを用いた場合との比較検証が行われておらず、提案モデルの有効性が不明である。

3. 提案手法

3.1 目的とキーアイデア

本研究の目的は、省エネ行動を促進するためのサービス改良を行うために、先行研究で提案された消費電力予測サービスを改良することである。キーアイデアは、機械学習モデルの改良と評価を行うことである。目的を達成するために以下の 2 つのアプローチを提案する。

A1: 天候情報を機械学習を行う際の特徴量に追加

A2: 機械学習モデルの比較による評価と改良

3.2 A1: 天候情報を機械学習を行う際の特徴量に追加

消費予測の際に天候情報を特徴量として追加し、消費予測精度の向上を図る。具体的には、湿度と気圧を特徴量と追加することで天候情報を考慮することが可能になる。湿度と気圧のデータは先行研究と同様に、気象庁が公開しているデータを利用した [10]。先行研究では、表 1 のように特徴量を設定していたが、以下の表 2 のように特徴量を調整した。

表 2 天候情報を取り入れた特徴量

識別	詳細
気温	1 時間粒度の気温データ (°C)
日付	1 月 1 日から 12 月 31 日まで、0~1 の範囲で 365 段階にラベルエンコーディングした値 d を用いて、 $\sin(2\pi d)$ と $\cos(2\pi d)$ に変換した値
時間	0 時から 23 時まで、0~1 の範囲で 24 段階にラベルエンコーディングした値 h を用いて、 $\sin(2\pi h)$ と $\cos(2\pi h)$ に変換した値
曜日	各曜日と祝日を One-Hot エンコード
過去の消費電力	1 時間前の消費電力量 (kWh)
湿度	1 時間粒度の湿度データ (%)
気圧	1 時間粒度の気圧データ (hPa)

出力は 1 時間粒度の消費電力量 (kWh) とする。この特徴量の追加が有効であるかを検証するために、2.3.2 項で述べた機械学習モデルを用いて、湿度と気圧の情報を追加した場合としない場合での MAE, MSE, RMSE 値を比較する。このアプローチの有効性が示されれば、消費予測精度の向上が期待できる。

3.3 A2: 機械学習モデルの比較による評価

先行研究で提案された機械学習モデルと他のモデルを比較し有効性を検証する。具体的には、提案手法であるオン状態とオフ状態を分割した LightGBM と、LSTM、線形回帰、Random Forest、SVM、オンオフの分割をしない LightGBM を用いて消費予測を行い、MAE, MSE, RMSE 値を比較する。予測に用い

た特徴量は表 2 とした。このアプローチにより、より精度の高いモデルの構築を目指す。

4. 評価

A1 と A2 で述べたアプローチの有効性を検証するために、実データを用いて消費電力予測を行い評価を行った。

4.1 内容

消費電力データには 23 歳男性の 2023 年 7 月 29 日～2024 年 7 月 24 日までの約 1 年間のデータを用いた。A1 の評価では季節性を考慮しないようにするため、訓練データと検証用テストデータを 80 % と 20 % の割合でランダムに分割した。モデルには先行研究で提案した、オンオフを分割した LightGBM モデルを用いた。A2 の評価では、LSTM モデルと比較するので、評価を行うデータセットを時系列データとするため、訓練データは 2023 年 7 月 29 日～2024 年 5 月 31 日、検証用のテストデータは 2024 年 6 月 1 日～2024 年 7 月 24 日のデータとした。また家電は、季節的な利用量の変動が大きいエアコンと、あまり変動しない冷蔵庫を対象とした。モデルの比較は 3.2 節で述べたモデルを用いて行った。

4.2 結果と考察

4.2.1 A1 の評価

天候情報を特徴量に含めた時と含めなかった時の評価指数の比較結果を表 3 と表 4 に示す。

表 3 特徴量における天候情報の有無による評価指数の比較 (冷蔵庫)

Model	MSE	RMSE	MAE
天候情報なし	0.000141	0.011885	0.009078
天候情報あり	0.000141	0.011863	0.009199

表 4 特徴量における天候情報の有無による評価指数の比較 (エアコン)

Model	MSE	RMSE	MAE
天候情報なし	0.002233	0.047251	0.012670
天候情報あり	0.002112	0.045958	0.012582

表 3 から、冷蔵庫においては天候情報を特徴量に追加しても、MAE, MSE, RMSE 値に大きな差異はなかった。冷蔵庫の消費電力量は天候による影響が少ないからだと考えられる。また、表 4 から、エアコンにおいては天候情報を特徴量に追加することで、MSE, RMSE 値の大きな低下が見られた。よって、天候情報を特徴量に追加することで消費電力量の予測精度が向上することが分かる。

4.2.2 A2 の評価

提案手法と他モデルの評価指数を比較した結果を図 4 と図 5、表 5 と表 6 に示す。




図 4 提案手法と他モデルの評価指数比較 (冷蔵庫)

表 5 提案手法と他モデルの評価指数値 (冷蔵庫)

Model	MSE	RMSE	MAE
LSTM	0.000265	0.016266	0.012719
LightGBM	0.000225	0.015001	0.012042
線形回帰	0.000286	0.016899	0.013325
Random Forest	0.000250	0.015817	0.013073
SVM	0.000252	0.015868	0.013319
LightGBM(オンオフ分割モデル)	0.000221	0.014883	0.012015




図 5 提案手法と他モデルの評価指数比較 (エアコン)

表 6 提案手法と他モデルの評価指数値 (エアコン)

Model	MSE	RMSE	MAE
LSTM	0.005438	0.073745	0.048852
LightGBM	0.005517	0.074274	0.052836
線形回帰	0.002629	0.051273	0.025647
Random Forest	0.009842	0.099205	0.065237
SVM	0.005181	0.071982	0.050411
LightGBM(オンオフ分割モデル)	0.006749	0.082154	0.036913

図 4 と表 5 から、冷蔵庫においては提案手法であるオン状態とオフ状態を分割した LightGBM は他モデルと比較して MAE, MSE, RMSE 値ともに優位であるが、ほとんど差異はなかった。また図 5 表 6 から、エアコンにおいては提案手法は他モデルより比較的 MAE 値は低いが、MSE, RMSE 値は線形回帰や SVM と比較すると高くなっていることが分かる。また、線形回帰が最も MAE, MSE, RMSE 値が低いという結果となった。オン

状態とオフ状態を分割した LightGBM と線形回帰の予測を行った期間における、実消費電力量と予測した消費電力量の比較を図 6 と図 7 に示す。




図 6 LightGBM の予測結果と実消費電力量の比較 (エアコン)




図 7 線形回帰モデルの予測結果と実消費電力量の比較 (エアコン)

図 6 ではオフ状態の消費電力が実データ通りになっている部分が多いが、オフ状態が誤ってオンと予測されてしまった際に予測が大きく外れていることが分かる。そのため、評価指数の値が大きくなってしまっていると考えられる。図 7 では、図 6 と比較して、オフ状態の時にも少し電量消費があると予測していることが分かる。またオン状態の時には急な傾きにもよく対応していることが分かる。これらの考察から、それぞれのモデルで予測を行った後に、LightGBM を用いたオンオフ判定モデルでオフと判定されたときには、消費電力量を 0 にするなどの処理を行うことで、より精度の高い予測が可能であると考えモデルを構築した。これらのモデルの評価指数を図 5 に追加したグラフを図 8 に示す。また、具体的な値を表 7 に示す。




図 8 提案手法とオンオフ判定を追加した他モデルの評価指数比較 (エアコン)

表 7 提案手法とオンオフ判定を追加した他モデルの評価指数値 (エアコン)

Model	MSE	RMSE	MAE
LSTM	0.005438	0.073745	0.048852
LightGBM	0.005517	0.074274	0.052836
線形回帰	0.002629	0.051273	0.025647
Random Forest	0.009842	0.099205	0.065237
SVM	0.005181	0.071982	0.050411
LightGBM(オンオフ分割モデル)	0.006749	0.082154	0.036913
LSTM(オンオフ判定あり)	0.003139	0.056030	0.025046
LightGBM(オンオフ判定あり)	0.004501	0.067092	0.029083
線形回帰(オンオフ判定あり)	0.002685	0.051821	0.021905
Random Forest(オンオフ判定あり)	0.006118	0.078215	0.033977
SVM(オンオフ判定あり)	0.004049	0.063632	0.028635

図 8 と表 7 から、提案手法であるオンオフ判定による予測結果の処理を行うと、行わないときと比較して MAE, MSE, RMSE 値が改善されることが分かる。また線形回帰を用いたモデルはオンオフ判定を行うときと比較して MSE, RMSE 値はほとんど変化しないが、MAE 値がよく改善されることが分かる。これらの考察からオンオフ判定を行う線形回帰モデルが最も精度が高いと考えられる。線形回帰モデルで予測を行った後にオンオフ判定による予測結果を行った際の、実消費電力量と予測した消費電力量の比較を図 9 に示す。




図 9 オンオフ判定をした線形回帰モデルの予測結果と実消費電力量の比較 (エアコン)

図 9, 図 7 と比較してオフ時の消費予測が改善されていることが分かる。

5. まとめ

本研究では、省エネ行動を促進するためのサービス改良を行うために、先行研究で提案された消費電力予測サービスを改良することを目的として、機械学習モデルの改良と評価を行った。提案手法は、天候情報を特徴量に追加することで消費予測精度の向上を図るアプローチと、提案手法であるオン状態とオフ状態を分割した LightGBM と他のモデルと比較し、より良いモデルの構築を目指すアプローチで構成される。この提案手法に基づき、実データを用いて消費電力予測を行い、評価を行った。その結果、天候情報を特徴量に追加することで消費予測精度が向上することが示された。また、提案手法であるオン状態とオフ状態を分割した LightGBM は他のモデルと比較して、エアコンにおいては MAE 値が低いが、MSE, RMSE 値は高くなって

いることが分かった。また線形回帰が最も、評価指数の値が低くなることが分かったが、オフ状態の際の予測精度が低くなっていた。そのため、予測した後にオンオフ判定を行い、オフと判定されたときには消費電力量を0にするなどの処理を行うことで、より精度の高い予測が可能であると考えモデルを構築し、その優位性が示された。

今後の展望として、提案手法に基づきサービスの改良を行い、実際のユーザの宅内にシステムを配備し省エネ行動に対する効果を検証することが挙げられる。また、消費予測に基づきよりユーザに伝わりやすい通知文を作成し、より個人に適応した省エネ行動の推進を可能にすることが挙げられる。現在の設計では通知文は単純に消費電力量の予測値と実消費電力量の差を示しているが、これをよりユーザに伝わりやすい形式に変更することで、省エネ行動の促進に寄与することが期待される。

謝辞 本研究の一部はJSPS 科研費 JP20H05706, JP22H03699, JP22K19653, JP23H03401, JP23H03694, JP23K17006 の助成を受けて行われている。

文 献

- [1] “脱炭素ポータル/カーボンニュートラルとは 環境省,” https://ondankataisaku.env.go.jp/carbon_neutral/about/#to-why, accessed July 29, 2024.
- [2] 小島紀徳, “二酸化炭素問題対策とエネルギー利用,” in *ISIJ*, vol. 78, no. 5, 1992, pp. 697–705.
- [3] 岡島敬一, “「エネルギー学」とカーボンニュートラル,” in **第31回日本エネルギー学会大会**, August 2022, pp. 14–15.
- [4] “Lightgbm 用語解説 nri,” https://www.nri.com/jp/knowledge/glossary/1st/alphabet/light_gbm, accessed July 29, 2024.
- [5] “Lightgbm’s documentation microsoft corporation,” <https://lightgbm.readthedocs.io/en/stable/>, accessed July 29, 2024.
- [6] 本藤祐樹, “見える化がもたらす家庭における省エネの可能性—三つの見える化—,” in *Journal of the Japan Institute of Energy*, vol. 91, no. 7, 2012, pp. 563–569.
- [7] 平井駿, 岡本大, 陳思楠, 佐伯幸郎, and 中村匡秀, “システムとユーザの対話に基づく個人に適応した宅内省エネ行動推進手法,” in **電子情報通信学会技術研究報告 LOIS2023**, vol. 123, no. 429, March 2024, pp. 19–26.
- [8] 平井駿, 中田匠哉, 佐伯幸郎, 陳思楠, and 中村匡秀, “個人の消費データに基づく va 省エネ行動推進サービスの提案,” in **電子情報通信学会技術研究報告 SC2024**, vol. 124, no. 71, June 2024, pp. 71–76.
- [9] 鈴木崇平, 武石直也, 岸本政徳, 古谷尚久, 沖野健太, 河原吉伸, and 廣島雅人, “一般家庭における消費電力予測手法の開発,” in **人工知能学会全国大会論文集 第34回 (2020)**, June 2020, pp. 4M3GS1305–4M3GS1305.
- [10] “過去の気象データの検索 気象庁,” <https://www.data.jma.go.jp/stats/etrn/index.php>, accessed July 29, 2024.