

施設内の混雑情報を用いた電力需要予測と 行動変容によるエネルギーマネジメント

人間形成教育センター 堀 磨伊也
環境学部環境学科（令和7年度時点） 小林 碧志

1. はじめに

近年、気候変動対策や脱炭素社会の実現に向けて再生可能エネルギー導入が急速に進んでいる。とりわけ太陽光発電や風力発電は大規模施設のエネルギー確保の選択肢として拡大しているが、これらは天候や季節変動の影響を受けやすく、出力の不確実性が高いという課題を抱えている。その結果、需要側の消費変動と供給側の再生可能エネルギー変動とが同時発生し、電力の需給バランスが乱れやすくなる。この需給調整のためには、発電側の調整だけでなく、需要側が自らの電力使用を柔軟に変化させるデマンドレスポンスが重要視されている。しかしながら、現状のデマンドレスポンスは一律的な節電要請が中心であり、各利用者が置かれている状況差や行動調整に伴う負担を十分に考慮できていない。その結果、なぜ今節電が必要なのか、どの程度行動が求められるのかといった合理的根拠が利用者に伝わりにくく、単なる義務的対応に留まってしまうという課題がある。利用者が納得して主体的に行動を選択できる形でデマンドレスポンスを成立させるためには、行動要請の根拠と必要性とを明確に示す仕組みが必要である。実効性の高いデマンドレスポンスを実現するには、電力需要を事前に高精度で予測し、その結果に基づいた適切な介入タイミングを特定する必要がある。

2. デマンドレスポンスに関する従来手法と提案手法の位置付け

デマンドレスポンスは、電力需給が逼迫する時間帯において、需要側が電力使用量を調整することで、電力系統の安定化を図る手法である。再生可能エネルギーの導入拡大に伴い、発電量の変動性が増大する中、供給側の調整のみでは需給バランスを維持することが困難となっており、需要側の柔軟な対応を促すデマンドレスポンスは重要な役割を担っている。近年では、太陽光発電をはじめとする再生可能エネルギーの大量導入を背景として、電力需要を抑制する下げデマンドレスポンス（需要抑制型デマンドレスポンス）だけでなく、発電余剰が生じる時間帯に需要を積極的に増加させる上げデマンドレスポンス（需要増加型デマンドレスポンス）の重要性も指摘されている。特に昼間に太陽光発電の出力が集中する環境では、需要側が電力使用の時間帯を調整することにより、再生可能エネルギーの有効活用と系統安定化を同時に実現できる可能性がある。

一方で、これらのデマンドレスポンス方式は、需要家を一つの集合として捉える設計となっている場合が多く、大学キャンパスやオフィスビルのように、多様な利用者が異なる活動を行う施設においては課題が生じやすい。大学では、講義、研究活動、自習、事務作業など利用形態が時間帯や場所によって大きく異なるにもかかわらず、一律の節電要請や制御が行われる場合が多い。その結果、すでに電力使用を抑制する余地の少ない利用者にも同様の要請が届くなど、行動負担の偏りが生じ、協力意欲

の低下を招く可能性がある。さらに、上げデマンドレスポンスの観点においても同様の課題が存在する。発電余剰が生じている時間帯において、需要増加が望ましい場合であっても、「なぜ今電力を使用した方がよいのか」「どのような行動が需給調整に寄与するのか」といった根拠が利用者に十分に伝達されなければ、意図した行動変容を引き出すことは困難である。多くの場合、利用者は需給状況を具体的に把握できず、結果として上げデマンドレスポンスの潜在的な効果が十分に発揮されない。

このように、従来のデマンドレスポンス方式は制度的・技術的には成熟しつつある一方で、利用者の行動状況を踏まえた柔軟な運用や、行動要請の根拠を明確に示す仕組みが十分に整備されているとは言えない。利用者の理解と納得感を伴う形で、下げデマンドレスポンスおよび上げデマンドレスポンスの双方を適切に機能させるためには、電力需要の変動要因を明示し、行動判断を支援する新たなデマンドレスポンスの枠組みが求められている。一律的なデマンドレスポンス施策の限界を補完する手段として、電力需要を事前に高精度で予測し、需給状況に応じた判断を支援する技術が注目されている。電力需要予測は、電力系統の運用計画や設備制御、需給調整の高度化を目的として、これまで長年にわたり研究が進められてきた。初期の電力需要予測研究では、回帰分析や自己回帰移動平均モデルなどの統計的手法が主に用いられてきた。これらの手法はモデル構造が比較的単純で解釈性に優れる一方で、需要の非線形性や複雑な時間依存関係を十分に表現できないという課題があった。これに対し、機械学習手法の導入により、気象条件や時間属性など多数の説明変数を同時に扱う予測モデルが提案され、予測精度の向上が報告されている。近年では、深層学習を用いた電力需要予測が主流となりつつある。特にLSTMをはじめとする深層学習を用いた時系列モデルは、電力需要が有する周期性や長期的な時間依存関係を学習可能であり、高精度な需要予測を実現している。これらのモデルは、気温や湿度といった気象条件に加え、曜日や時刻などの時間的特徴を組み合わせることで、従来手法を上回る性能を示すことが報告されている。深層学習モデルは高い予測精度を有する反面、モデル内部の計算過程が複雑であり、予測結果の根拠を人間が理解することが困難であるというブラックボックス問題を抱えている。電力需要予測の結果を単に数値として提示するだけでは、「どのような状況が需要増加に寄与しているのか」「なぜ特定の時間帯で需要が高いと予測されたのか」といった問いに答えることができず、利用者への説明や行動要請への活用が難しい。

このような背景から、近年では機械学習モデルの予測根拠を明示する説明可能なAI（XAI）に関する研究が進展している。XAIは、ブラックボックスモデルの予測結果に対して、入力特徴量がどの程度影響を与えたかを定量的に示すことを目的とした枠組みである。中でもSHapley Additive exPlanations（SHAP）[1]は、協力ゲーム理論に基づき、各特徴量の寄与度を一貫性のある形で算出できる手法として広く用いられている。SHAPは、回帰モデルや決定木モデルだけでなく、深層学習モデルに対しても適用可能であり、電力需要予測分野においても、寄与分析やモデル妥当性の検証を目的とした応用が報告されている。これにより、気象条件や時間属性などが需要予測に与える影響を可視化し、モデルが学習した需要構造を解釈することが可能となる。しかしながら、既存研究の多くは、予測モデルの精度評価や特徴量の重要度分析を主目的としてXAIを適用しており、得られた説明結果を需要家や施設利用者への情報提供に活用する枠組みは十分に検討されていない。特に、デマンドレスポンスにおいて重要となる下げデマンドレスポンスおよび上げデマンドレスポンスの意思決定

に対し、予測根拠を用いて利用者の行動判断を支援する研究は限定的である。

以上により、電力需要予測技術は高精度化が進展しているものの、その予測根拠を利用者に理解可能な形で提示し、行動変容や需給調整に結びつけるための枠組みは未だ確立されていない。この課題を解決するためには、電力需要予測と説明可能なAIを組み合わせ、予測結果の背景にある要因を明示したうえで、利用者の意思決定を支援する手法が求められている。ただし従来のデマンドレスポンス施策は、一律的な行動要請に基づく運用が中心であり、利用者の行動状況や負担の差を十分に考慮できていないという課題を有している。また、近年の電力需要予測研究では、深層学習を用いた高精度な予測が可能となっている一方で、予測根拠がブラックボックスとなり、利用者への説明や行動要請への活用が困難であるという問題が指摘されている。このような背景を踏まえ、本研究は、利用者の行動由来の説明変数を導入し、電力需要予測とその根拠の可視化に基づく情報提供の枠組みを構築することで、デマンドレスポンスの実効性を高めることを目指す。

3. デマンドレスポンスのための電力需要予測根拠の可視化

本章では、デマンドレスポンスのための電力需要予測根拠の可視化手法について述べる。事前に決定された要因に基づく需要をベース予測モデルで表現し、実際の在室状況や利用者行動に起因する変動を、行動由来のデータを用いた残差学習モデルによって補正する2段階予測モデルを採用する。この構成により、定型的な需要変動と、利用者の行動に起因する非定型的な変動を分離して評価することが可能となる。さらに、本研究ではSHAPを用いて、予測に寄与する要因を定量的に可視化する。これにより、下げデマンドレスポンスおよび上げデマンドレスポンスの双方において、予測の背景にある行動の根拠をエビデンスとして利用者に提示できる。単なる数値的な予測を超え、利用者の納得感を伴う行動変容を支援し、施設全体のエネルギーマネジメントの実効性を高める点に本手法の独自性がある。まず**3.1.**にて、予測精度の向上と行動変容を支える行動由来の情報の収集プロセスおよびその手法について述べる。次に**3.2.**では、具体的な電力需要予測モデルの構築と予測根拠の可視化について述べる。

3.1. 予測精度の向上と行動変容を支える行動由来の情報の収集

本研究では、利用者の行動状況を反映した情報提供を実現するため、センサノードを施設内に設置し、人流や室内の占有状況といった利用者の行動由来の情報の収集を行う。電力需要は設備仕様のみならず、施設内における利用者の活動密度や滞在時間に大きく依存するため、これらの指標を正確かつ継続的に取得することが重要である。本研究では、プライバシーに配慮した簡潔かつ匿名性の高いデータとして、BLE端末検知数と室内環境指標との二つを採用する。

人流の検知には、Bluetooth Low Energy (BLE) のアドバタイズ信号を用いる。これは、デバイスの存在を周囲に通知するために一定間隔で送信される信号であり、空間内に存在する端末数を把握することが可能である。本研究の目的は個人の特定や動線の追跡ではなく、施設全体の利用規模が電力需要に与える影響の把握にあるため、一定時間内に検知された端末数のみを人流の代表指標として抽出する。これにより、個人を特定せずに人の存在規模を定量化することが可能となる。

一方、室内の占有状況の把握には、温湿度・二酸化炭素（CO₂）センサを用いる。センサが計測するCO₂濃度は、室内の換気量と滞在人数とに応じて変動するため、在室推定の指標として広く用いられている。CO₂濃度が上昇する傾向は滞在人数の増加を示唆し、逆に換気後の急減は滞在人数の減少と対応する。本研究では、これらのCO₂濃度の時間変動を基に室内占有状況を間接的に推定し、BLEによる端末検知数と組み合わせて、利用者の行動を表す説明変数として利用する。BLE端末検知数が「人の存在規模」を表すのに対し、CO₂濃度は「滞在の継続性」を反映する指標であり、両者を併用することで施設利用状況を多面的に捉えることが可能となる。BLE端末検知数および温湿度・CO₂濃度データは、一定周期で取得され、ネットワークを介してサーバに送信する。これにより、施設内の利用者の行動を連続的かつ非侵襲に観測するセンシング基盤を構築する。

以上のように、本研究では端末検知数および室内環境指標といった簡潔かつ匿名性の高いデータを用いることで、行動由来のデータを反映した電力需要予測モデルの構築を可能とする。本研究における利用者の行動由来の情報の収集は、手法Aでは、温湿度センサとCO₂センサを用いて室内の占有状況を把握する。手法Bでは、温湿度センサやCO₂センサに加えBLEによる人流センシングを統合し、センサノードを構築する。これにより、人流および占有状況を同一ノードで同時に取得可能なセンシング基盤を実現する。

3.2. 電力需要予測モデル構築と予測根拠の可視化

本節では、前節で収集した利用者の行動由来のデータを活用し、電力需要予測モデルを構築する具体的な手順、および予測結果の妥当性を検証するための手法について述べる。

電力需要予測に用いるデータとして、電力使用量、気象データ、行動由来のセンサデータ、および時間属性データを収集する。電力使用量および気象データは時刻情報を基準として各データを統合する。一方、行動由来のセンサデータは異なる間隔で収集されているため、時刻情報を基準として集約し、平均値などの統計量として特徴量化する。これにより、すべての説明変数を同一の時間解像度で扱うことを可能とする。

どの曜日の授業が実施されているかといった授業実施情報を、事前に決定された利用スケジュールを表す変数として扱い、後述するベース予測モデルに入力する。大学の授業カレンダーおよび祝日情報を用い、以下のフラグを作成する。

- 授業実施日フラグ
- 曜日別授業フラグ
- 休日フラグ（週末または祝日）
- 施設閉鎖フラグ

気象データとしては、鳥取地方気象台で観測された1時間ごとの気温、湿度、降水量、日照量、風速を用いる。時系列データの欠測については、気象データなど時間的連続性を仮定できる変数に対しては時間方向の線形補間を適用する。また、長期間にわたり欠測が継続するセンサについては、モデル学習への影響を考慮し、該当する特徴量を分析対象から除外する。

前処理後のデータを用いて、電力需要予測モデルを構築する。本研究では、電力需要を構成する要

因を段階的に扱うため、ベース予測と残差補正から成る2段階予測モデルを採用する。まず、気象条件や時間的周期性、授業実施といった事前に決定された利用スケジュールに基づく定型要因を考慮するため、ベース予測モデルを構築する。ベース予測モデルの説明変数として、気象データ・時刻および周期特徴量・授業実施情報および休日情報・過去の電力使用量を用いる。これらを用いて、説明変数ベクトル $x_t^{(base)}$ を定義し、過去 k 時間分の系列 $x_{t-k:t}^{(base)}$ を入力とする。ベース予測モデルには、時系列データの時間的依存関係を学習可能なLSTMを用い、時刻 t における電力需要の予測値 $\hat{y}_t^{(base)}$ を式 (1) により算出する。

$$\hat{y}_t^{(base)} = f_{LSTM}(x_{t-k:t}^{(base)}) \quad (1)$$

このモデルにより、電力需要の周期性や気象条件に加え、授業実施など予定された利用状況に起因する需要変動を系列として表現することを目的とする。次に、ベース予測モデルでは表現しきれない利用者の行動由来の非定型要因を扱うため、式 (2) に示す実測値 y_t とベース予測値との差を残差 r_t として定義する。

$$r_t = y_t - \hat{y}_t^{(base)} \quad (2)$$

この残差は、実際の利用者行動のばらつきなど、時々刻々と変化する非定型要因を含む成分と位置付ける。残差 r_t を予測するために、行動由来の情報を直接的に反映するセンサデータを入力とした残差学習モデルを構築する。残差学習モデルの入力として、室内CO₂濃度・室内環境データ・BLE端末検知数を用いる。これらを用いて、説明変数ベクトル $x_t^{(res)}$ を定義し、決定木ベースの回帰モデルを用い、残差の予測値 $\hat{r}_t$ を式 (3) により算出する。

$$\hat{r}_t = f_{GBDT}(x_t^{(res)}) \quad (3)$$

最終的な電力需要予測値は、式 (4) に示すベース予測値と残差予測値を加算することで求める。

$$\hat{y}_t^{(2st\ stage)} = \hat{y}_t^{(base)} + \hat{r}_t \quad (4)$$

この構成により、予定された利用スケジュールに基づくベース需要と、実際の行動由来の変動需要を構造的に分離して扱うことを可能とする枠組みを構築する。

また、本研究では電力需要予測モデルの予測根拠を明示するために、SHAPを用いる。SHAPは、協力ゲーム理論に基づき、ある予測結果に対して各説明変数がどの程度寄与したかを定量的に評価する説明可能なAI手法である。SHAPでは、機械学習モデルを複数の特徴量が協力して予測値を決定するゲームとみなし、各特徴量をプレイヤーとして扱う。ある特徴量の寄与度は、その特徴量をモデルに追加したときに予測値がどれだけ変化するかを、すべての特徴量の組み合わせに対して平均するこ

とで算出される。この考え方に基づく指標はシャープレイ値と呼ばれ、特徴量集合 $N = \{1, \dots, M\}$ に対し、特徴量 i のシャープレイ値は、式 (5) で算出される。

$$\phi_i = \sum_{S \subseteq N \setminus \{i\}} \frac{|S|! (M - |S| - 1)!}{M!} [f(S \cup \{i\}) - f(S)] \quad (5)$$

$f(S)$ は、特徴量集合 S のみ使った予測の期待値である。SHAPにより得られる予測値は、式 (6) に示すように、基準値と各特徴量の寄与の総和として表現される。

$$\hat{y} = \phi_0 + \sum_{i=1}^M \phi_i \quad (6)$$

ここで、 $\hat{y}$ はモデルの予測値、 ϕ_0 は全データにおける予測値の平均（基準値）、 ϕ_i は特徴量 i が予測値に与える寄与度を表す。正の寄与度は予測値を増加させる方向に作用し、負の寄与度は予測値を減少させる方向に作用させることを意味する。

まず、残差学習モデルに対してSHAPを適用することで、特定の時間帯や条件において、どの行動由来の情報や環境情報などの非定型要因が残差予測に寄与しているかを定量的に評価する。残差学習モデルは決定木ベースの回帰モデルであるため、TreeSHAP[2]を適用し、各特徴量の寄与度を算出する。TreeSHAPは、SHAPの枠組みを決定木モデルに特化して、効率化した手法であり、勾配ブースティング決定木（GBDT）などに対して厳密なシャープレイ値を高速に算出できる点に特徴がある。これにより、人流や室内環境といった行動由来の説明変数が、電力需要予測の補正にどのように関与し得るかを分析可能とする。一方で、ベース予測モデルであるLSTMに対してもSHAPを適用し、気象条件、時間属性、および授業実施情報といった事前に決定された利用スケジュールに基づく寄与が、電力需要の基礎的な予測にどのように寄与しているかを評価する。ベース予測モデルであるLSTMは、時系列の長期依存関係を学習可能な非線形モデルであり、内部状態の解釈が困難であることから、本研究ではモデル非依存な手法であるPermutation SHAP[3]を採用する。これは入力特徴量の値を置換した際の予測値の変化から寄与度を近似的に算出する枠組みであり、これによりベースモデルが捉える定型的な需要構造を、説明可能性の観点から整理することが可能となる。

最終的には、SHAPによって得られた予測根拠を利用者への情報提供や行動要請に活用することを目指す。単に電力需要の予測値を提示するのではなく、「なぜ需要が高いのか」「どの行動や環境情報が影響しているのか」といった根拠を併せて提示することで、利用者や場所の状況に応じた柔軟な行動要請を実現する。これにより、デマンドレスポンスの実効性向上に寄与することが期待される。

4. 実験

本章では、前章で提案したデマンドレスポンスのための行動変容を想定した電力需要予測モデルの有効性を検証するため、実施した実験の結果について述べる。本実験の主な目的は、行動由来の情報の導入による予測精度の向上効果を明らかにすること、およびSHAPを用いて予測根拠の妥当性を評価することにある。本章の構成は以下の通りである。

まず4.1.において、実験の対象となる施設や観測環境、使用したデータの詳細および前処理の手順を説明し、本研究で提案する2段階予測モデルの精度検証を行う。従来のベースモデルと行動由来の情報を導入した提案モデルの予測精度を比較することで、利用者の行動由来の情報が予測に与える補正効果を定量的に明らかにする。最後に4.2.では、SHAPを用いた予測根拠の提示の妥当性や説明性について評価する。

4.1. 実験条件およびデータ概要および2段階予測モデルによる予測精度の向上効果

本研究では、公立鳥取環境大学のキャンパスを対象とし、当該施設における電力需要データおよび室内環境・人間活動に関する観測データを用いて分析を行った。対象施設は、主として講義室および研究室として利用されている。平日昼間の利用が多い一方で、時間帯や曜日によって利用状況が大きく変化する。このような施設では、照明、空調、情報機器等の使用が人間の在室状況や行動に強く依存するため、電力需要は人の行動の影響を受けやすいと考えられる。電力需要データとして、対象施設において取得された電力データを用いた。観測期間は、2023年4月1日0:00から2025年12月10日23:00までであり、実験には1時間あたりの電力量[kWh]を使用した。期間中の電力需要は平均203.14kWh、標準偏差105.19kWhであった。気象データとして、鳥取地方気象台において1時間間隔で観測されたデータを使用した。使用した気象変数は、気温、湿度、降水量、日照時間、風速である。これらは空調・照明需要に影響を与える代表的な外生要因であり、電力需要予測において重要な説明変数と考えられる。

利用者の行動を表す指標として、2024年11月14日から2025年8月23日において、学内の講義室5室の7か所、執務室2室の2か所、計9か所に設置したセンサ（SCD41）から10分間隔で取得したCO₂濃度および温湿度データを使用した。さらに、2025年11月12日から同年12月10日では学内の講義室4室の8か所で、前述センサをRaspberry Pi 5に接続するとともにBLE信号を用いた人流データを10分間隔で取得した。

本研究では、行動由来のデータの取得条件の違いを考慮し、分析期間をBLEによる人流データが存在する期間（2025年11月12日から同年12月10日）とした。本実験は、利用者の行動由来の情報を説明変数として用いた電力需要予測の予測精度を評価する。式（2）において定義した残差を予測するモデルとして、行動由来の情報を説明変数として用い、LightGBM[4]による残差予測モデルを構築した。

訓練期間を2025年11月12日14:00から同年12月5日11:00まで、評価期間は、2025年12月5日12:00から同年12月10日23:00までとした。目的変数は、実測値と構築したベースモデルの予測値との差である。説明変数として表1に示す特徴量を用いた。式（4）に示すベース予測値と残差予測値とを加算した電力需要値は、評価期間において、RMSE 20.45kWh、MAE 13.42kWh、MAPE 6.16%の性能が得られた。予測値と実測値のグラフを図1に示す。一部昼間の時間帯において、2段階予測モデルによる補正が行われていることが確認できる。しかしながら、12月8日昼間はベースモデル、2段階予測モデル共にピークを予測できていない。




図1. 評価期間における実測値と予測値の比較

表1. 2段階予測モデルにおいて使用した説明変数

分類	特徴量名	説明	期間
センサ	100b_tem	100講義室温度	①
センサ	100b_hum	100講義室湿度	①
センサ	100b_co2	100講義室CO2濃度	①
センサ	30_tem	30講義室温度	①
センサ	30_hum	30講義室湿度	①
センサ	30_co2	30講義室CO2濃度	①
センサ	17_tem	17講義室温度	①
センサ	17_hum	17講義室湿度	①
センサ	17_co2	17講義室CO2	①
センサ	gkm_tem	学務課執務室温度	①
センサ	gkm_hum	学務課執務室湿度	①
センサ	gkm_co2	学務課執務室CO2濃度	①
センサ	co2__100f	100講義室前方CO2濃度	②
センサ	ble_count__100f	100講義室前方BLEカウント	②
センサ	temperature_100f	100講義室前方温度	②
センサ	humidity__100f	100講義室前方湿度	②
センサ	co2__100b	100講義室後方CO2濃度	②
センサ	ble_count__100b	100講義室後方BLEカウント	②
センサ	temperature_100b	100講義室後方温度	②
センサ	humidity__100b	100講義室後方湿度	②
センサ	co2__200f	200講義室前方CO2濃度	②
センサ	ble_count__200f	200講義室前方BLEカウント	②
センサ	temperature_200f	200講義室前方温度	②
センサ	humidity__200f	200講義室前方湿度	②
センサ	co2__200b	200講義室後方CO2濃度	②
センサ	ble_count__200b	200講義室後方BLEカウント	②
センサ	temperature_200b	200講義室後方温度	②
センサ	humidity__1200b	200講義室後方湿度	②
センサ	co2__30f	30講義室前方CO2濃度	②
センサ	ble_count__30f	30講義室前方BLEカウント	②
センサ	temperature_30f	30講義室前方気温	②
センサ	humidity__30f	30講義室前方湿度	②
センサ	co2__30b	30講義室後方CO2濃度	②
センサ	ble_count__30b	30講義室後方BLEカウント	②
センサ	temperature__30b	30講義室後方温度	②
センサ	humidity__30b	30講義室後方湿度	②
センサ	co2__17f	17講義室前方CO2濃度	②
センサ	ble_count__17f	17講義室前方BLEカウント	②
センサ	temperature_17f	17講義室前方温度	②
センサ	humidity__17f	17講義室前方湿度	②




図2. P2-1(12/8 8:00)における予測値に対する局所解釈の結果

4.2. SHAPを用いた予測根拠の妥当性と説明性の評価

予測根拠の可視化の有用性を検証するため、4.1. で構築したベースモデル、残差モデルに対して、SHAPを適用し、局所的な解釈を確認した。図1の時系列データにおける各時点の局所解釈結果を図2に示す。P2-1（12月8日8時）では、100講義室（temperature_100b）および30講義室の室温（temperature_30b）が強い正の寄与を示しており、空調の立ち上げに伴う電力需要の増加が確認される。授業開始前における空調稼働が需要増加としてモデルに捉えられていることが分かる。しかしながら、当日は1限の時間帯に30講義室および100講義室で講義は予定されていない。設備稼働フラグがモデルに与えられていないため、わずかな変動を根拠として提示してしまっている可能性がある。

デマンドレスポンスでは、電力需要の予測精度に加えて、需要変動がどのような要因によって生じているかを理解可能であることが重要である。特に大学キャンパスのように利用者の行動や授業運営が電力需要に大きく影響する環境では、予測結果の説明性が運用判断の妥当性を左右する。本研究で用いたSHAPによる説明結果からは、室温、CO₂濃度、BLEによる在室指標といった行動に由来する

特徴量が、時間帯や利用状況に応じて電力需要へ異なる寄与を示すことが確認された。これにより、需要増加が人の流入に伴う不可避な変動なのか、あるいは空調設定や運用方法による調整可能な変動なのかを区別して把握することが可能となる。このような説明性は、デマンドレスポンス発動時の制御対象の選定や抑制余地の判断を支援するだけでなく、運用者や利用者へのフィードバックとして活用できる点に特徴がある。需要増加の根拠が具体的に示されることで、教職員や学生に対して行動や利用方法の見直しを促す材料を提示でき、単なる強制的な制御ではなく、自発的な行動変容につなげることが期待される。したがって、説明可能な需要予測モデルは、デマンドレスポンスを一時的な需要抑制手段にとどめず、継続的な省エネルギー行動を誘発する仕組みとして機能し得る。

5. おわりに

本研究では、大規模施設におけるデマンドレスポンスの実効性を高めることを目的として、利用者の行動に由来する情報を導入した電力需要予測モデルの構築と、SHAPを用いた予測根拠の可視化に基づく情報提供の枠組みを提案・検証した。まず、施設内の環境データ（温度・湿度・CO₂濃度）に加え、BLE端末検知数を用いた非侵襲な人流検知システムを構築し、利用者の行動状況を反映したデータセットを整備した。次に、気象条件やカレンダー情報等の定型要因を学習するLSTMベースモデルと、非定型要因による変動需要を補正する残差学習モデルとから成る2段階予測モデルを構築した。実験の結果、2段階予測モデルはMAPE 6.16%という高い予測精度を達成し、ベースモデル単体と比較して精度の向上が確認された。また、SHAPを用いた寄与分析により、気象条件やスケジュールによるベース需要の増減と、利用者の行動に由来する情報が予測値に与える影響を定量的に分離・可視化できることを示した。これにより、単なる数値提示ではなく、気温上昇による負荷増や高密度な在室状況といった納得感のある根拠に基づいた行動要請の可能性を提示した。

参考文献

- [1] Scott M. Lundberg and Su-In Lee, “A unified approach to interpreting model predictions,” Advances in Neural Information Processing Systems, 2017.
- [2] Scott M. Lundberg, Gabriel G. Erion, and Su-In Lee, “Consistent Individualized Feature Attribution for Tree Ensembles,” arXiv preprint arXiv:1802.03888, 2019.
- [3] Erik Štrumbelj and Igor Kononenko, “An Efficient Explanation of Individual Classifications using Game Theory,” Journal of Machine Learning Research, Vol.11, pp.1-18, 2010.
- [4] Guolin Ke, Qi Meng, Thomas Finley, Taifeng Wang, Wei Chen, Weidong Ma, Qiwei Ye, and Tie-Yan Liu, LightGBM: “A Highly Efficient Gradient Boosting Decision Tree,” Advances in Neural Information Processing Systems, Vol.30, No.30, 2017.