

## 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 Visualization of Predictive Explanations in Electricity Demand Forecasting Models for Demand Response

小林 碧志<sup>†</sup> 堀 磨伊也<sup>†</sup>  
Kobayashi Aoshi Hori Maiya

### 1. はじめに

脱炭素社会の実現に向けてエネルギー環境が変化する中、大量エネルギー消費施設においては、電力の需給バランスを最適化するためのエネルギーマネジメントの重要性が増している。その中でも、需要側が電力使用を調整するデマンドレスポンス[1]は有効な手段として注目されている。

デマンドレスポンスを効果的に機能させるためには、電力の供給量及び需要量のリアルタイムかつ高精度な予測が不可欠である。近年は Transformer などの深層学習を用いた高精度な時系列予測手法が注目されているが、一方でモデルのブラックボックス性が高く、なぜそのような予測が出されたのかが分かりにくいという課題もある。そのため、デマンドレスポンスの実効性を高めるには、単に予測精度を高めるだけでは不十分であり、利用者の行動変容を促す必要がある。そのためには、管理者が予測結果とその根拠をわかりやすく提示し、利用者の理解と納得を得ることが不可欠である。

しかしながら、既存手法の多く[2]は多数のセンサデータや詳細な設備稼働情報を用いることが前提とされており、導入コストや運用面での制約が課題となる。本研究では、安価で設置容易な CO2 センサを用いて施設内の人間活動を間接的に把握し、電力需要予測に活用する手法を提案する。重要度に基づいた特徴量選択を行うことで予測の精度向上を図り、加えて予測根拠の可視化により結果の透明性を確保する。

これにより、管理者は予測結果の妥当性を把握した上で利用者に提示することが可能となり、行動変容の促進とデマンドレスポンスの実効性向上が期待される。

### 2. 提案手法

施設の電力需要を予測する際に、人の活動が電力需要に与える影響が大きいことに着目し、温度・湿度・CO2 濃度センサを施設内の建物ごとのデータを予測に活用する。加えて、気象観測データ、電力需要のラグ特徴量、曜日・時間帯情報を入力として電力需要を予測するモデルを構築する。構築したモデルに対しては、機械学習モデルの局所解釈手法を適用し、特徴量ごとの予測への貢献度を算出する。その結果に基づき、貢献度上位の特徴量を選択し、モデルを再構築する。特徴量の選択数や、複数のセンサのうちどのデータを用いるかといった構成も含めて、ハイパーパラメータ最適化フレームワークにより自動的に探索する。再構築後のモデルに対しても同様の解釈手法を適用し、個々の予測結果に対する根拠を可視化する。

### 3. 実験

予測根拠の可視化の有用性を検証するため、公立鳥取環境大学内の施設を対象に 2024 年 11 月 18 日から 2025 年 3 月 27 日までデータを取得し、電力需要予測モデルの構築を行った。

一方、機械学習モデルの局所的な予測根拠を可視化する手法として、SHapley Additive exPlanations (SHAP) [4]がある。SHAP は、ゲーム理論における Shapley 値の概念を応用し、各特徴量が予測結果に与える影響を定量化する手法である。この手法は、特徴量の平均的な影響を示す大域的な解釈とは異なり、個別の予測に対する局所的な貢献度を可視化することができる。

#### 3.1 実験データ

- データ項目：電力需要値
- データ取得期間：2024/11/19~2025/3/27
  - － 訓練：2024/11/19 8:00~2025/3/1 6:00
  - － テスト：2025/3/1 7:00~2025/3/26 23:00
- データ間隔：1 時間間隔

期間内の電力需要値の平均は、182.89kW（標準偏差:107.65）であった。また、ピークが平日日中にあることが確認できた。

#### 3.2 データ収集・機械学習モデルによる電力需要予測

温度・湿度・CO2 濃度を測定するセンサとして、SCD41（Sensirion 社製）を採用した。SCD41 センサを M5Stack Basic V2.7 に接続してデータ収集システムを構築した。10 分に 1 回ネットワークを経由し、遠隔で GAS で Google スプレッドシートに測定結果を書き込むことでデータを取得した。

機械学習モデルは、LightGBM[5]を用いた。LightGBM は、勾配ブースティングに基づく決定木のアンサンブル学習手法であり、高い予測性能と計算効率を特徴とする。葉優先の木構築アルゴリズムや勾配に基づく学習データのサンプリングにより、学習時間を短縮しながらも精度を保つことが可能である。説明変数は以下のものを用いた。CO2 濃度については、人の活動の指標として有効である一方でばらつきが大きいこと、あらかじめ定めた閾値（0~500ppm, 501~1000ppm, 1001~1500ppm）により離散化して特徴量とした。

- 目的変数：時刻 t+1 の電力需要値

<sup>†</sup> 公立鳥取環境大学 Tottori University of Environmental Studies




図 1 施設の電力需要予測結果

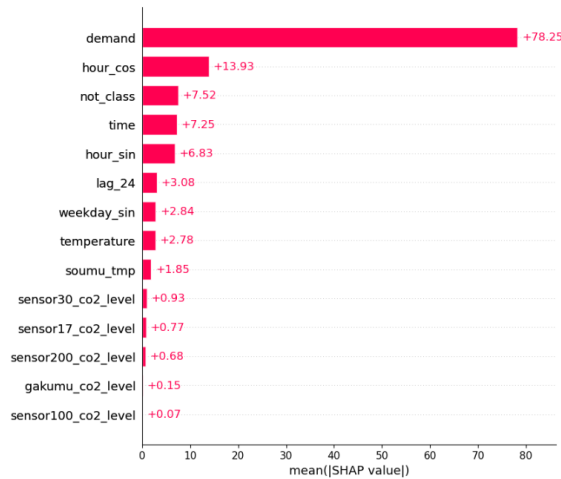


図 2 モデルの大域的な解釈

- 説明変数：時刻  $t \sim t-3$ ,  $t-24$  の電力需要値，気温，湿度，日照時間，降水量，風速，時間帯情報，曜日情報，イベント情報（どの曜日の授業があるか），センサ温度，センサ湿度，センサ CO2 濃度レベル

ハイパーパラメータ最適化フレームワークとして，Optuna[3]がある．ベイズ最適化を基盤とした TPE (Tree-structured Parzen Estimator) 手法を用いることで，効率的に探索空間を最適化した．

### 3.3 SHAP による予測根拠の可視化

3.2 で構築したモデルに対して，SHAP を適用し，予測根拠の可視化を行った．大域的な解釈を図 2 に示す．各特徴量の予測への貢献度からは，時刻  $t$  の電力需要値，時間帯情報，イベント情報が予測に対して貢献度が大きいことが分かった．

一方，モデルの局所的な解釈として，図 1 の赤丸部における予測根拠を図 3 に示す．時刻  $t$  における電力需要値や時間帯情報が正の貢献度を示し，気温が負の貢献度を示している．図 2 の大域的な解釈とは異なる貢献度を示していることが分かった．

表 1 各種予測評価

	ベースモデル	提案手法
RMSE (kW)	18.84	17.57
MAE (kW)	13.33	13.27
MAPE (%)	9.93	10.51

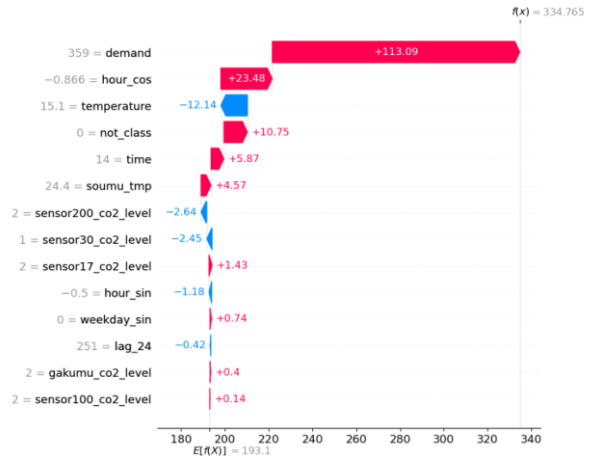


図 3 図 1 の赤丸部の予測根拠の可視化

## 4. おわりに

本稿では，人の活動が電力需要に与える影響に着目し，施設内に設置したセンサデータを活用した電力需要予測手法と，その予測根拠の可視化手法を提案した．温度・湿度・CO2 濃度を測定可能なセンサを施設内の複数個所に設置し，施設内の環境データを取得したほか，気象観測データやカレンダー情報，過去の電力需要値を特徴量として機械学習モデルを構築した．さらに，SHAP を用いて各特徴量の貢献度を可視化し，特徴量選択やセンサ構成の最適化を Optuna により実施することで，予測精度向上とモデル解釈性の両立を図った．実験では，時刻  $t$  の電力需要値，時間帯情報，イベント情報が電力需要に対して大きな影響を与えていることが示された．今後の課題は，今回の実験は冬期のみであったため，ほかの季節で適用可能か確かめる必要がある．季節ごとにモデルを最適化するなどして，予測精度の向上に取り組む必要がある．

## 謝辞

本研究は JSPS 科研費 25K15543 の助成を受けたものです．

## 参考文献

- [1] M. H. Albadi, and E. F. El-Saadany, “A summary of demand response in electricity markets,” *Electric Power Systems Research*, vol. 78, no. 11, pp. 1989–1996, 2008.
- [2] 土坂 祐太郎, 高木 洋和, 杉森 文亮, 林 千春, 手島 哲平, 森田 克明 “時系列 XAI 技術による電力需要予測モデルの性能・説明性向上,” 人工知能学会全国大会論文集, JSAI2024 巻 (2024), p. 4Xin273.
- [3] Takuya Akiba, Shotaro Sano, Toshihiko Yanase, Takeru Ohta, and Masanori Koyama., “Optuna: A Next-generation Hyperparameter Optimization Framework,” *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining (KDD)*, 2019.
- [4] Scott M. Lundberg, and Su-In Lee, “A unified approach to interpreting model predictions,” *Advances in Neural Information Processing Systems*, Vol.30 (2017).
- [5] 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).