

多様なセンサを用いた施設の電力需要予測と予測根拠の可視化

Facility electricity demand forecasting using multiple sensors and visualization of local explanations of the model

小林 碧志[†] 堀 磨伊也^{††}

Aoshi Kobayashi[†] Maiya Hori^{††}

[†] 公立鳥取環境大学 環境学部 ^{††} 公立鳥取環境大学 人間形成教育センター

1 はじめに

脱炭素社会に向けたエネルギー環境の変化により、多くのエネルギーを消費する施設においては、エネルギー需給バランスを最適化するエネルギーマネジメントが求められている。また、施設などで使用される高圧電力は、過去1年間の最大電力が電力料金に大きな影響を与える。特に工場での電力需要は、機械の稼働状況や気象条件によって刻一刻と変動する。この変動を高精度に予測することが出来れば、省エネやエネルギーコストの削減につながる。

近年、LSTM [1] や Transformer [2] をはじめとした、様々な時系列データ予測手法が提案されている。これらの深層学習を用いた手法は、線形回帰などと比べて高い精度での予測が可能である。しかしながら、深層学習モデルは中身がブラックボックスであり、予測根拠が不明である。社会に実装していくためには、予測根拠を明らかにしていくことが必要不可欠である。

既存研究 [3] では、工場の設備稼働計画、過去の電力需要実績値、気象データなどの46個の説明変数を用いている。しかしながら、設備ごとの稼働状況を取得することは難しい場合がある。本稿では、施設の電力需要に与える影響が大きいと考えられるCO₂ センサデータを活用する。安価で大量に設置できるCO₂ センサを用いて施設内のセンシングを行い、施設内の電力需要予測に用いることで予測精度向上を試みる。また構築したモデルに局所解釈を行う手法を適用し、予測根拠の可視化を行う。

2 電力需要予測と予測根拠の可視化

室内の人の行動が電力需要に影響を与えることを仮定して、施設内に温度・湿度・CO₂濃度を測定するセンサを設置し、データを取得する。気象観測データ、曜日情報とセンサで取得したデータを入力として需要(30分値)の予測を行う。構築したモデルに対して、機械学習モデルの局所解釈を行う手法を適用し、予測根拠の可視化を行う。

構築するモデルの一例として、Random Forest Regressor [5] は、アンサンブル学習による機械学習アルゴリズムの一つである。複数の決定木を用いて、それぞれの決定木ごとに一部の特微量のみを分割し、決定木の平均を取って予測結果を出力する。

一方、機械学習モデルの局所解釈を行う手法として、SHapley Additive exPlanations(SHAP) [4] は、モデルの予測結果を解釈するための手法であり、各特微量の貢献度を算出することが可能である。この手法では、

モデルの大域的な解釈手法とは異なり、個々の予測結果に対して、局所的な解釈が可能である。SHAPでは、ゲーム理論におけるShapley値を、各説明変数の貢献度として用いる。

3 実験

予測根拠の可視化の有用性を検証するため、鳥取市内の工場を対象に2024年6月10日から8月31日までデータを取得して、実験した。

3.1 実験データ

- データ項目：電力需要値
- データ取得期間：2024/6/10～2024/8/31
 - 訓練：2024/6/10～2024/8/15
 - テスト：2024/8/16～2024/8/31
- データ間隔：30分間隔

平均は、28.70kWh(標準偏差: 41.42)であった。ピークが平日日中にあることが確認できた。

3.2 M5stackでのセンシングシステム構築

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。図1に、構成図を示す。図1に示すように、センサをM5Stack Basic V2.7(M5Stack社製)に接続した。10分に一回ネットワークを経由し、遠隔でGAS(Google Apps Script)でGoogleスプレッドシートに測定結果を書き込むプログラムとした。




図1: システム構成図

トラブル時のバックアップとして、10分ごとに、SDカードにデータを書き込むプログラムとした。

3.3 機械学習モデルによる電力需要予測

機械学習モデルは、Random Forest Regressor [5] を用いた。説明変数は以下のものを用いた。

- 目的変数：施設の電力需要値
- 説明変数：気温、湿度、日照時間、カレンダーデータ(稼働日かどうか)、時間帯情報、センサ温度、センサ湿度、センサCO₂濃度

提案手法の有用性を示すため、上記を説明変数として用いた場合の、R2(決定係数), RMSE(二乗平均平方根誤差), MAE(平均絶対誤差), MAPE(平均絶対誤差割合)を確認した。

テストデータを用いて、電力需要予測を行った。図2に、実測値とそれに対する予測結果を示す。平日朝夕の立ち上がり等については、おおむね予測できており、時間帯情報が影響していると考えられる。各種予測評価は表1の通りとなった。




図 2: 予測結果

表 1: 各種予測評価

モデル 1	
R2	0.945
RMSE	10.883
MAE	5.425
MAPE	0.334

3.4 SHAP による予測根拠の可視化

3.3で作成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。各特徴量の予測への貢献度からは、時間帯情報やカレンダー情報、CO2濃度、気温が予測に対して貢献度が大きいことがわかった。この貢献度は、あくまで大域的な解釈である。

大域的な解釈に対してモデルの局所的解釈として、CO2濃度の値とSHAP値の関係を図3に示す。500ppmあたりから、値が大きくなり、予測に大きく貢献していることがわかる。CO2濃度が、施設の電力需要予測に大きく影響していると考えられる。夏期は、空調が稼働している際、窓が解放されていないため、このような結果になったと考えられる。

4 おわりに

本稿では、多様なセンサデータを用いた施設の電力需要予測と予測根拠の可視化を提案した。その手法の有用性を示すため、センサデータの取得、機械学習に

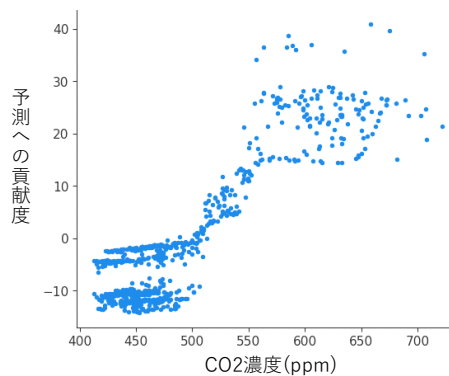


図 3: CO2濃度の貢献度

よる電力需要の予測、SHAPによる予測根拠の可視化の実験を行った。実験では、時間帯情報、カレンダー情報、CO2濃度、気温が電力需要予測に対して貢献度が大きいことを示した。また、CO2濃度を電力需要予測に活用できることを示した。今後の課題は、今回の実験は夏期のみであったため、他の季節でも同様の手法が適用可能かを確かめる必要がある。さらに、センサを増やすなどして、予測精度の向上に取り組む必要がある。

謝辞

本研究を進めるにあたり、電力需要データの提供およびセンサ設置にご協力いただいた大同端子製造株式会社の皆様に、心より感謝申し上げます。また、SDGs共創プロジェクトの一環として、多大なるご支援を賜りました鳥取県および鳥取商工会議所工業部会の皆様に心より感謝申し上げます。

参考文献

- [1] Sepp Hochreiter and Jürgen Schmidhuber, “Long Short-Term Memory,” *Neural Computation*, Volume: 9, Issue: 8, 1997.
- [2] Neo Wu et al., “Deep Transformer Models for Time Series Forecasting,” *The Influenza Prevalence Case*, arXiv:2001.08317, 2020.
- [3] 土坂 祐太郎ら, 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, p. 4Xin273, 2024.
- [4] Scott M. Lundberg and Su-In Lee, “A unified approach to interpreting model predictions,” *Advances in Neural Information Processing Systems*, 2017.
- [5] Leo Breiman, “Random Forests,” *Machine Learning* 45, 5–32 2001.