

説明可能なAIを用いたエネルギーマネジメントシステム構築と グリーンインフラの評価

人間形成教育センター 堀 磨伊也
環境学部環境学科 小林 碧志・加藤 禎久

1. はじめに

人間の活動の影響で温室効果ガスが大気に放出される結果、気温が上昇し気候が変動する問題が深刻になってきている[1]。その中で、化石燃料利用を減らしてCO₂をはじめとした温室効果ガス排出を実質ゼロにする脱炭素社会の実現に向けて様々な取り組みが行われている[2]。

環境省の「脱炭素先行地域」[3]は脱炭素社会の実現に向けた取り組みの一つで、2050年のカーボンニュートラル実現に向けて、民生部門（家庭部門及び業務その他部門）の電力消費に伴うCO₂排出の実質ゼロを実現し、運輸部門や熱利用等も含めてそのほかの温室効果ガス排出削減についても、我が国全体の2030年度目標と整合する削減を地域特性に応じて実現することを目指している。鳥取市においても「RE:Birth（再エネ創出）で進める地域脱炭素と地域のRebirth（進化・再生）」[4]と題し、若葉台地区・佐治町全域で脱炭素の取り組みを行っている。

若葉台エリアに属する本学では太陽光発電設備の導入と省エネによるキャンパス全体の脱炭素化を目指し、その知見を研究・教育において活用している。2030年までに脱炭素キャンパスを実現するためには、再生可能エネルギー（再エネ）の大量導入が不可欠である。しかしながら、再エネの1つである太陽光発電の大量導入時には、気象条件によって発電量が大きく変動する問題が生じる。この課題を解決する手段の1つとして、建物の屋上に設置されたソーラーパネルや、蓄電池などの小規模の分散型エネルギー源を束ね、統合制御する分散型エネルギーマネジメントシステムが注目されている[5][6]。

2. エネルギーマネジメントシステム

本学および若葉台地区に再エネ設備を大量に導入する際には、電力需要量の予測と発電量の予測を行いながらエネルギーマネジメントを行うことが必要不可欠である。これらの予測結果を用いて蓄電池の最適制御もしくはデマンドレスポンスを行うことにより、再エネ設備により発電された電力を効率的に利用することが可能となる。ただし、ここでの予測は多種多様なデータを用いて高精度に行う必要があるが、深層学習に代表される複雑な予測モデルは中身がブラックボックスになる場合があり、何を根拠に予測結果が算出されているのかわからないことが多い。社会実装において根拠のわからない予測結果を用いて方策を決定することは信頼性・納得性の面で難しい。本研究では、電力需要量の予測と発電量の予測とを機械学習に基づく手法により行うとともに、SHapley Additive exPlanations（SHAP）[7]をはじめとした機械学習モデルの局所解釈を行う手法を適用することで予測根拠を明らかにし、予測に活用すべきかどうかの判断を行う。

3. 説明可能なAIを用いた電力需要予測

深層学習の中でもLSTM[8]、Seq2Seq[9]、Transformer[10]などでは、時系列データに基づく非線形なモデルを構築するため線形回帰などと比べて高い精度での予測が可能である。しかし一般に予測モデルの複雑さとその解釈性についてはトレードオフの関係があることが知られている。つまり、単純なモデルは予測精度の点では複雑なモデルに劣るがモデルの解釈性は優れている。一方で、深層学習モデルのような複雑なモデルは予測精度の点では優れているが、中身がブラックボックス化しており人間が解釈することが困難である。そのため、エネルギーマネジメントの構築の際に必要な電力需要予測および再エネ発電量予測を、説明可能なAIにより高精度に行うとともにその予測根拠を提示することは重要である。

SHapley Additive exPlanations (SHAP) [7]は、モデルの予測結果を説明するための手法であり、各特徴量の貢献度を算出することが可能である。この手法は、モデルの大域的な解釈方法とは異なり、モデルの個々の予測結果に対する入力特徴の貢献度を推定することが可能である。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、モデルの出力を説明変数の貢献度の線形和で表現する。ゲーム理論におけるShapley値は、あるプレイヤーが参加した場合と不参加の場合の報酬の差分から、そのプレイヤーの貢献度を求める手法である。ここで、プレイヤーを予測モデルの各説明変数、報酬を予測値とすることで機械学習モデルに適用する。この際、多くの予測モデルでは、ある変数が未知の場合、予測値を出力できないという問題がある。SHAPでは未知の変数がある場合、その未知の変数の期待値を用いることでこの問題を解決している。それにより、各特徴量の寄与の総和が予測値に一致する性質を持つ。入力特徴の貢献度はサンプルごとに異なるため、各予測結果に対して深い解釈を行うことが可能である。例えば、モデルの局所解釈を分析し、貢献度が高い入力特徴がノイズによって大きく変化するような場合は、予測精度の信頼性が低いことを意味し、反対に、貢献度が高い入力特徴の信頼度が高い場合には、予測精度の信頼性が高いことを意味する。

様々な予測モデルを構築した場合、予測モデルの妥当性というものは定量化することが困難であり、妥当な予測モデルを機械的に選択することは難しい。そのため最終的にサンプルごとの説明変数の貢献度の分析をもとに、複数のモデルの中から妥当なモデルを人間が選択することになる。人間にとって妥当ではないと判断される予測モデルは、トレーニングデータの偏りが原因で生成されたモデルが正確ではない可能性がある。つまり、人間が妥当だと判断したモデルのほうが汎化性能が高い可能性がある。モデル選択の際、異なるモデル間で貢献度の値を比較するのではなく、モデルごとにどの特徴量の貢献度が高いかを比較することによって妥当かどうかを判断する。

4. 実験

提案手法の有用性を示すために、本学施設における電力需要の予測を行い、予測精度の検証および予測結果に対する入力特徴の貢献度を可視化した。電力データは30分毎に記録されており、平均

情報、気温、風速、日照時間、降水量、DI（不快指数）、イベント情報（平日か休日か、授業がある日かない日か、その他のイベントがある日かない日か）をそれぞれ用いた。DI（不快指数）に関しては以下の式（1）に基づき算出した。

$$DI=0.81 \times \text{気温}+0.01 \times \text{相対湿度} \times (0.99 \times \text{気温} - 14.3)+46.3 \quad (1)$$

モデルを構築後、2022年5月4日から2022年6月22日のデータで電力需要予測のテスト検証を行った。図1に約8日間における電力需要予測の結果を示す。図1の赤線は予測値を、青線は真値をそれぞれ表す。予測精度に関しては、平均絶対値誤差（MAE）は、10.66、二乗平均平方根誤差（RMSE）は、17.87となった。Random Forest Regressor[11]における各特徴量の貢献度の平均を図2に示す。こちらは、SHAPによる解釈とは異なり、大域的な特徴量の貢献度を表す指標となっている。実際に、時間帯情報、イベント情報（平日か休日か）、イベント情報（授業がある日かない日か）が推定に対する貢献度が大きいことがわかり、大学施設の電力需要予測として考慮すべきことが上位に挙がっていることがわかる。一方で、図1におけるP₁、P₂、P₃のそれぞれの予測値に対して、SHAPにより各入力特徴量の貢献度を可視化したものを図3 - 5に示す。ここで赤色の領域および赤字で記載された特徴量は、出力値（予測値）に対するプラスの貢献度を、青色の領域および青字で記載された特徴量は、出力値（予測値）に対するマイナスの貢献度を、それぞれ意味する。これらの各入力特徴量の貢献度を比較してわかるとおり、予測値に対して各入力特徴量の貢献度が大きく異なることが理解できる。大域的な特徴量の貢献度とも異なることがわかり、複雑なモデルほど局所的な解釈が必要であることがわかった。




図1 電力需要予測の結果例（赤線：予測値，青線：真値）

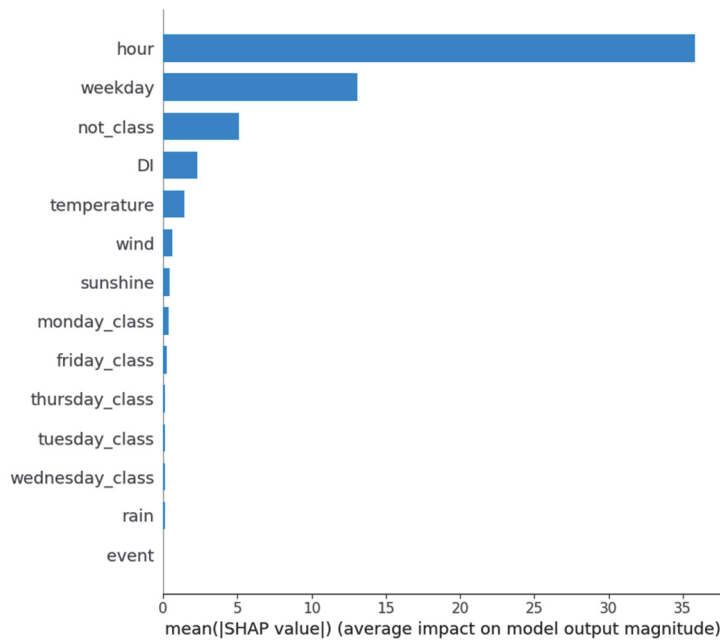


図 2 Random Forest Regressor[11] における各特徴量の貢献度の平均




図 3 P_1 (予測値: 174.53) に対するSHAP[7] による各特徴量の貢献度




図 4 P_2 (予測値: 56.02) に対するSHAP[7] による各特徴量の貢献度



図 5 P_3 (予測値: 67.14) に対するSHAP[7] による各特徴量の貢献度

5. おわりに

本研究では、電力需要量の予測と発電量の予測とを機械学習に基づく手法により行うとともに機械学習モデルの局所解釈を行う手法SHAPを適用することで個々の予測根拠を明らかにし、その予測値の妥当性を確認した。

ただし、予測根拠が明らかになったとしても、地域内の電力需要量や再エネ発電量などは不確実性を持つため、分散型エネルギーの統合制御は容易ではない。今後は、これらの不確実性に対応するた

め、強化学習に基づく蓄電池の最適制御もしくはデマンドレスポンスを試みる。これにより再エネ設備の大量な導入とピークカットによる電力料金の削減を同時に実現する。

一方で、再エネ設備の大量導入により、グリーンインフラをはじめとした生態系が破壊されないことが重要であるため、若葉台地区でグリーンインフラがもたらす様々な生態系サービスを総合的に評価することも試みる。グリーンインフラがもたらす様々な生態系サービスを総合的に評価するのは困難が多い。本研究では、グリーンインフラの資源と機能を総合的に評価するために、まずマッピングによりその構成要素を把握し、次にi-Treeプログラム[12]を用いて樹木の機能を定量的に分析する。これにより若葉台地区においてグリーンインフラをはじめとした生態系を守りつつ、再エネの大量導入を実現することを試みる。

参考文献

- [1] AR6 Climate Change 2021: The Physical Science Basis <https://www.ipcc.ch/report/sixth-assessment-report-working-group-i/> [Online, accessed, April 24th, 2024].
- [2] 地球温暖化対策 | 環境省 <https://www.env.go.jp/seisaku/list/ondanka.html> [Online, accessed, April 24th, 2024].
- [3] 脱炭素先行地域 - 脱炭素地域づくり支援サイト <https://policies.env.go.jp/policy/roadmap/preceding-region/> [Online, accessed, April 24th, 2024].
- [4] 鳥取市が「脱炭素先行地域」に選定されました <https://www.city.tottori.lg.jp/www/houdou/contents/1681968825374/> [Online, accessed, April 24th, 2024].
- [5] 経済産業省資源エネルギー庁. VPP・DRとは https://www.enecho.meti.go.jp/category/saving_and_new/advanced_systems/vpp_dr/about.html [Online, accessed, April 24th, 2024].
- [6] 経済産業省資源エネルギー庁. 分散型エネルギープラットフォーム https://www.enecho.meti.go.jp/category/saving_and_new/bunsan_plat/ [Online, accessed, April 24th, 2024].
- [7] Scott M. Lundberg and Su-In Lee., A unified approach to interpreting model predictions, Advances in Neural Information Processing Systems, 2017.
- [8] Sepp Hochreiter, Jürgen Schmidhuber, Long Short-Term Memory, Neural Computation, Volume: 9, Issue: 8, 1997.
- [9] Ilya Sutskever, Oriol Vinyals, Quoc V. Le, Sequence to sequence learning with neural networks, Part of Advances in Neural Information Processing Systems 27, NIPS 2014.
- [10] Neo Wu, Bradley Green, Xue Ben, Shawn O' Banion, Deep Transformer Models for Time Series Forecasting: The Infuenza Prevalence Case, arXiv:2001.08317, 2020.
- [11] scikit-learn; machine learning in Python <https://scikitlearn.org/stable/index.html> [Online, accessed, April 24th, 2024].
- [12] i-Treeプログラム, <https://www.itreetools.org/> [Online, accessed, April 24th, 2024].