多様なセンサデータを用いたXAIによるエネルギーマネジメント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
経営学部経営学科　中澤　宏紀
環境学部環境学科　小林　碧志・加藤　禎久

1．はじめに

2015年12月に採択されたパリ協定を受けて、我が国でも2050年までに温室効果ガスの排出を全体としてゼロにする社会を目指すことが宣言されている。これを実現するためには、エネルギー源として永続的に利用することができる再生可能エネルギー（再エネ）の大量導入が重要な役割を担っている。一方で電力系統では、電力の安定供給のため需要と供給が同量になるように調整する必要がある。太陽光発電のような再エネは発電量が天候に大きく依存するため、再エネを大量導入した場合に電力の安定供給が難しくなる。蓄電池の最適制御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が、需要量と発電量に関しては予測に頼らざるを得ない。しかしながら、深層学習に代表される複雑な予測モデルは、多種多様なデータを用いて高精度に推定できる可能性があるが、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がわからないことが多い。

そこで本研究では、電力需要予測を多様なセンサデータを用いた説明可能なAI（XAI）により高精度に行うとともにその予測根拠を提示する。これにより再エネ設備の費用対効果を考慮した効率的な導入を実現するだけでなく、効果的なデマンドレスポンスの実現により電力のピークカットを実現し電力料金の削減を試みる。

一方で、温室効果ガス排出量の削減と吸収量の拡大を実現するための手法として、太陽光発電設備の導入と屋上緑化がそれぞれ存在する。しかし、太陽光発電設備の導入時には景観破壊が起こるという問題点があり、屋上緑化の導入時には維持管理とコストが大きな課題となる。本研究では、太陽光発電設備と屋上緑化を導入した際の問題を防ぐため、再生可能エネルギー導入時における持続可能な景観設計手法を提案する。

2．従来研究と本研究の位置づけ

エネルギーマネジメントに関する研究[1]はマイクログリッドを想定して数多く行われており、深層学習等[2]による需要量や発電量の予測が一般的に用いられている。しかしながら、これらの手法の中には予測の根拠に応じて局所的に異なった制御を行うシステムは存在しない。一方で深層学習モデルの解釈性・説明性を局所的に分析する研究[3]は、ブラックボックスモデルの出力に対して、その入力ごとに出力根拠を提示することでモデルに解釈性を与える。本研究では、従来手法と同様に深層学習により需要量の予測を用いるが、複数の予測値だけでなくそれらの根拠情報を用いて最適制御を行う

点が従来手法とは一線を画す。これにより、たとえ同じ予測値をモデルが出力したとしても、その予測根拠が異なれば異なった制御を行うことができる。

一方で、再生可能エネルギー導入時における持続可能な景観設計として、屋上緑化[4]が存在する。しかし、屋上緑化の導入時には維持管理とコストが大きな課題となる。本研究では、太陽光発電設備と屋上緑化を導入した際の問題を防ぐため、再生可能エネルギー導入時における持続可能な景観設計手法を提案する。

3．多様なセンサデータを用いたXAIによるエネルギーマネジメントとグリーンインフラの評価

3.1　多様なセンサデータを用いたXAIによるエネルギーマネジメント

電力需要量の予測を行う際に、特性に合わせたデータ取得を行う。電力関連情報（施設・部屋ごとの電力需要量，太陽光設備による発電量）だけでなく、環境情報（気象情報，イベント情報，施設・部屋ごとの人の活動量など）の取得を行い、これらを時系列データとして深層学習モデルを作成する。その時系列モデルに対して局所解釈手法[3]を適用し，それぞれの予測値に対する入力特徴の貢献度を取得する。これにより再エネ設備の費用対効果を考慮した効率的な導入を実現するだけでなく、効果的なデマンドレスポンスの実現により電力のピークカットを実現し電力料金の削減を試みる。

3.2　景観色彩設計に基づく景観作成

従来手法では、導入した際の景観破壊や管理コストなどの課題を抱えている。この課題を解決するために、導入前に景観色彩設計に基づく景観を作成し、ARを用いてシミュレーションを行う。本節では、景観色彩設計に基づく景観作成手法について説明する。

文献[5]によると、景観色彩は色を使って景観をコントロールすることである。また、周りの環境と合うように建物等の色を検討し、統一感のある見た目にすることとも述べている。本研究の場合、太陽光発電設備と屋上緑化が周りの景観に合致した景観を作成することが目標となる。本研究では、景観を作成する上で実際に戸建て住宅を対象とした色彩設計のプロセスを参考にする。本研究では、色彩設計における色彩提案と色彩施工管理のプロセスにARによる可視化を用いる。ARを用いる目的は、太陽光発電設備と屋上緑化を導入する前にあらかじめシミュレーションしておくことで、導入後の景観破壊やコスト発生などの問題を防ぐことである。

本研究ではビジョンベースARの中でもマーカレス型AR[6]を使用する。ビジョンベースARを使用することにより、太陽光発電設備と屋上緑化をARによって可視化する際に精密な位置推定が可能となる。屋上の正確な位置に３Dモデルを配置できなければ、実際の景観を想像することが難しくなると考えられる。また、３Dモデルを配置する場所がARマーカを設置することが困難である屋上のため、ビジョンベースARの中でもマーカレス型ARを使用する。本研究ではマーカレスARを使用し屋内から屋上の特徴点を認識し３Dモデルを現実世界に重ねて表示する。

4．実験

4.1　多様なセンサデータを用いた電力需要予測とその根拠の可視化

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193.6kWh（標準偏差113.7kWh）であり、平日の日中にピーク需要があることが確認できた。2024年11月18日から2025年３月１日までのデータでモデルの学習を行った。

機械学習モデルとしてRandom Forest Regressor[7]を用いた。特徴量（説明変数）として時系列の電力需要値、時間帯情報、休日かどうか、イベント情報（何曜日授業か、イベントか）、気象庁観測データ（気温、日照時間、降水量、DI（不快指数）、風速）、11･17･30･100･200講義室のセンサデータ（温度・湿度・CO_2濃度）をそれぞれ用いた。

モデルを構築後、2025年３月２日から2025年３月27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、15.7、二乗平均平方根誤差（RMSE）は、21.3となった。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２と図３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。

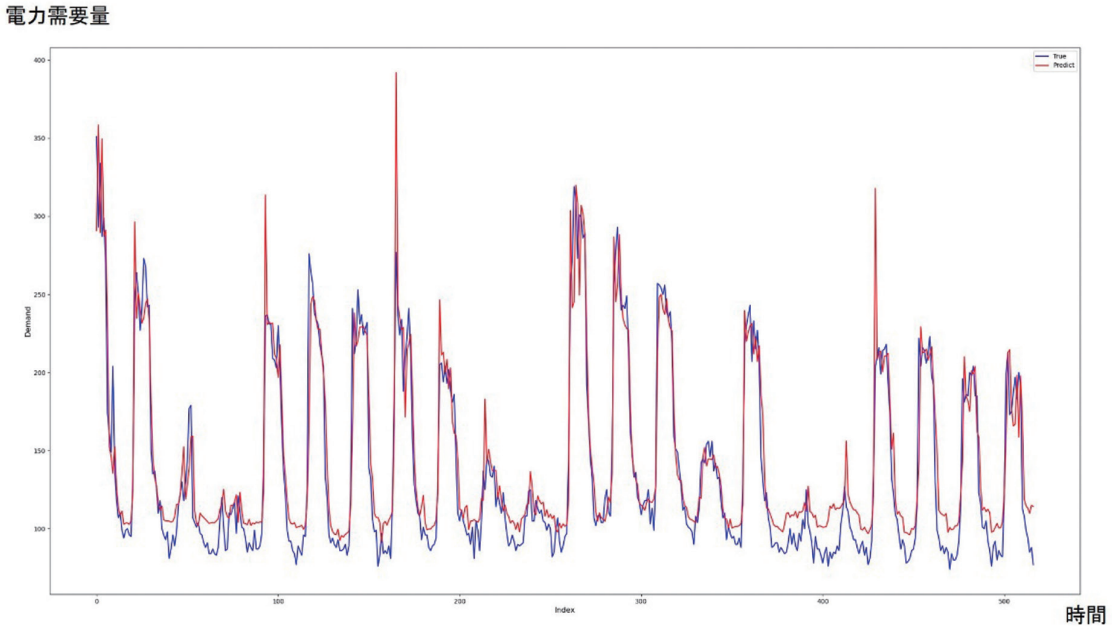

図１　電力需要予測の結果例（赤線：予測値、青線：真値）

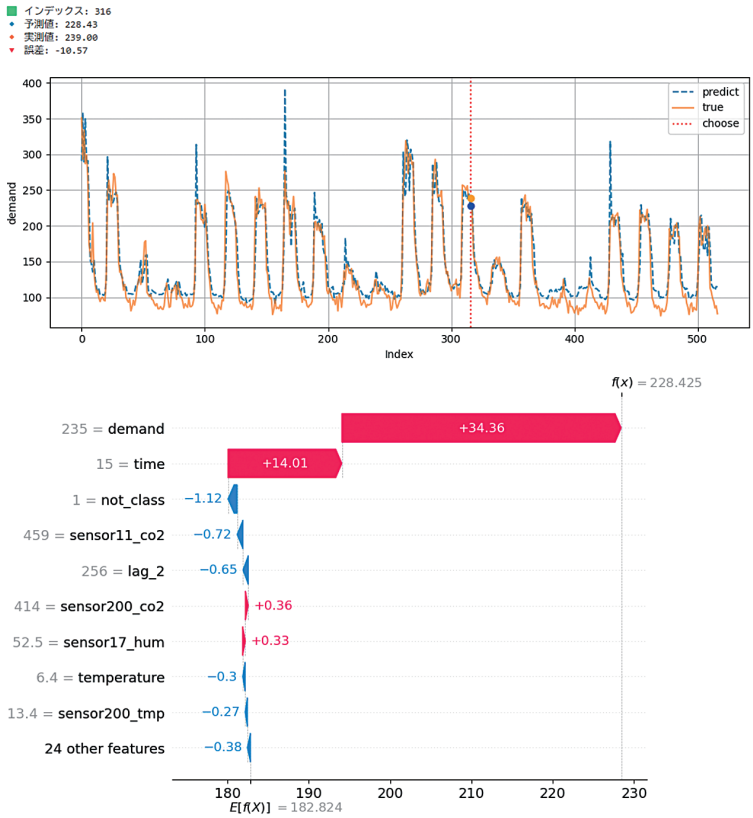

図２　予測値: 228.425（赤点線部）に対するSHAP[3]による各特徴量の貢献度

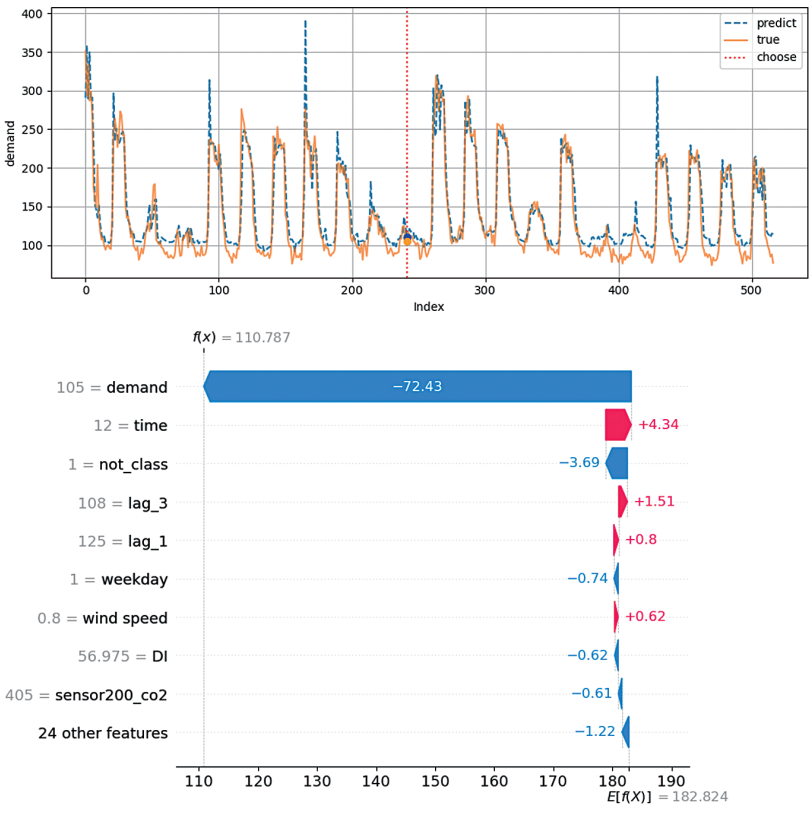

図３　予測値: 110.787（赤点線部）に対するSHAP[3] による各特徴量の貢献度

４.２　景観色彩設計に基づく景観作成の主観評価実験

太陽光発電設備導入や屋上緑化を行う際、導入時の問題を未然に防ぐことが重要となる。太陽光発電設備と屋上緑化導入時に持続可能な景観設計が可能かを検証するため、実験を行った。本実験では、図４に示す公立鳥取環境大学敷地内の本部講義棟と研究教育棟の２階連絡通路を実験環境とした。

本実験で使用した３Dモデルは、図５に示すようにオープンソースの３DCGソフトであるBlender[8]を用いて作成した。３Dモデルは屋上緑化のみの景観、太陽光発電設備のみの景観、屋上緑化と太陽光発電設備を交互に配置した景観、屋上緑化と太陽光発電設備を分けて配置した景観の４パターン作成した。以上の４パターンを作成した目的は、太陽光発電設備と屋上緑化を同時に導入した際に景観として優れているかを調査するためである。太陽光発電設備と屋上緑化を同時に配置するパターンは２種類作成し、比較対象として太陽光発電設備のみのパターンと緑化のみのパターンも作成した。以上の３Dモデル４パターンを、ARコンテンツを作成できるアプリケーションであるAdobe Aero[9]を用いて配置を編集した（図６）。その上、図７に示すように本学連絡通路に重畳表示した。

図４　実験環境

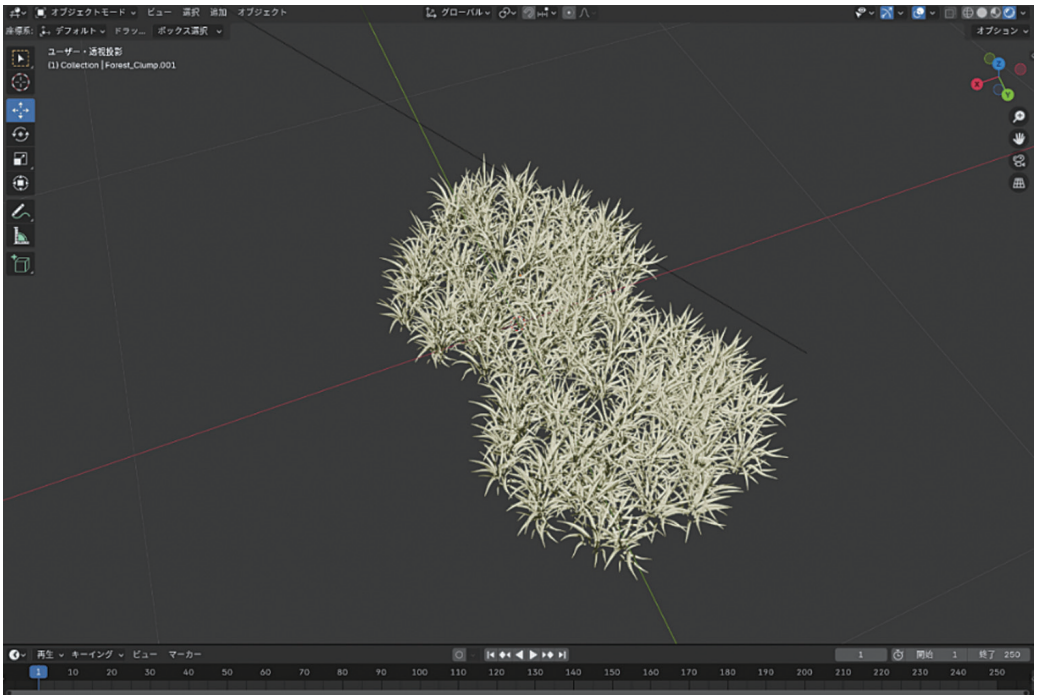

図５　Blenderで作成した3Dモデル

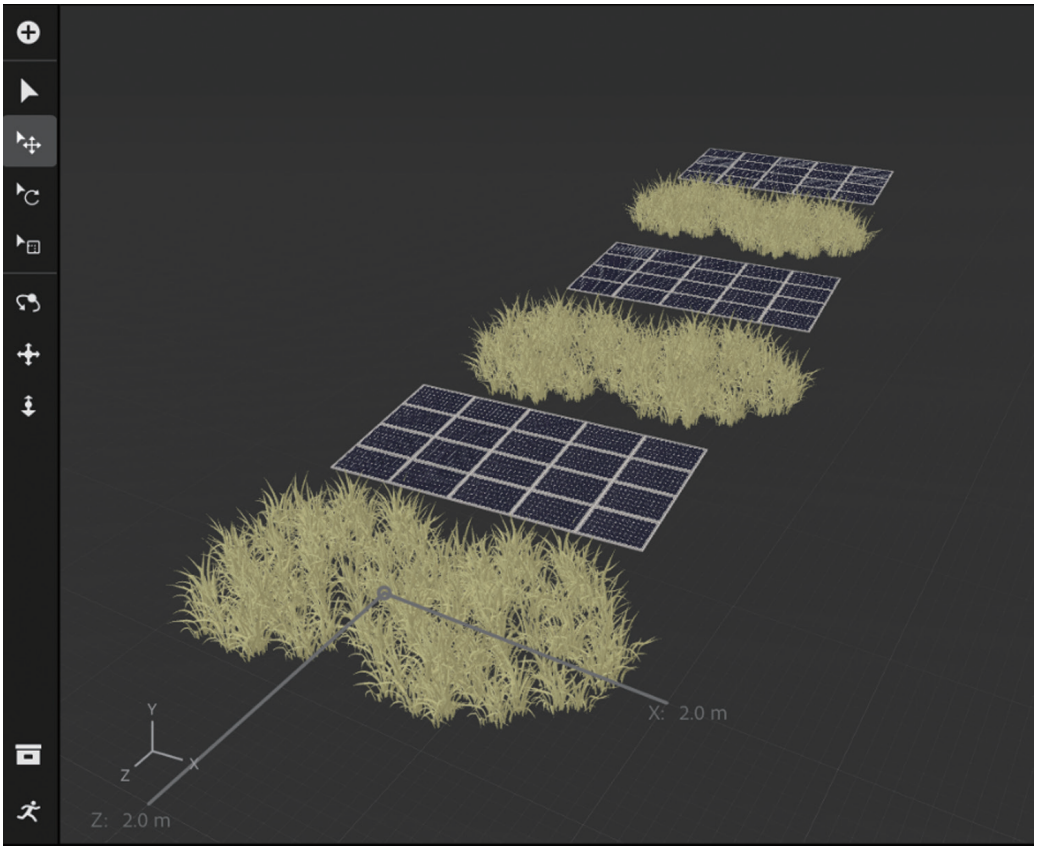

図６　Adobe Aeroにて配置を編集した3Dモデル

主観評価は、公立鳥取環境大学経営学部経営学科及び環境学部環境学科に所属する学生を対象にアンケートを実施し、回答者は24名であった。図７(a)から図７(d)の４パターンが景観として優れているかそれぞれ５段階評価を実施した。５段階の内訳としては以下のとおりである。

１：景観として優れていない

２：どちらかといえば景観として優れていない

３：どちらでもない

４：どちらかといえば景観として優れている

５：景観として優れている

結果は、図８に示すとおりである。屋上緑化のみのパターンは５と評価した人が５人（20.8%）、４が14人（58.3%）、３が１人（4.2%）、２が３人（12.5%）、１が１人（4.2%）となった。４または５と評価した人が多く、概ね景観として優れていると評価された。太陽光発電設備のみのパターンは５と評価した人が４人（16.7%）、４が５人（20.8%）、３が８人（33.3%）、２が６人（25%）、１が１人（4.2%）となった。こちらは屋上緑化のみのパターンに対し１または２と評価した人が多く、概ね景観として優れていないと評価された。屋上緑化と太陽光発電設備を交互に配置するパターンは５と評価した人が５人（20.8%）、４が８人（33.3%）、３が４人（16.7%）、２が５人（20.8%）、１が２人（8.3%）となった。屋上緑化と太陽光発電設備を分けて配置するパターンは５と評価した人が４人（16.7%）、４が８人（33.3%）、３が５人（20.8%）、２が５人（20.8%）、１が２人（8.3%）となった。太陽光発電設備と屋上緑化を両方配置する２パターンは概ね景観が優れていると評価された。

アンケートの結果を踏まえ、考察を行った。まず、４パターンの５段階評価の違いについて述べる。図８(b)を参照すると３以下が24人中15人を占めており、太陽光発電設備のみのパターンはあまり評価が高くないことが分かった。それに対し図９(a)のとおり緑化のみのパターンは４以上が24人中19人を占める高評価だった。また、「景観には緑化が必要」という意見が見られた。図８(c)・(d)が太陽光発電設備と屋上緑化が共存しているパターンであるが、交互に配置したパターンは４以上が12人、分けて配置したパターンは４以上が13人となり、双方とも高評価だった。しかし、交互に配置するパターンは「交互に配置するとごちゃごちゃしたイメージになって汚いと感じた」「緑地を削って太陽光パネルを設置した感じがする」という意見もあり、景観として優れていないという評価も存在した。それとは対照的に、分けて配置するパターンでは「綺麗に分かれているのが好きだから」「緑化とパネルを分けて配置するパターンが好み」「やはり緑の植物は景観に必要です」という意見が上がり、交互に配置するパターンと比べて景観として適しているという評価が存在した。

以上のように、１番評価が高かったものは緑化のみのパターンだったことも踏まえると、景観として緑化は必要不可欠である。しかし脱炭素社会の構築には太陽光発電設備と屋上緑化の両方が必要である。そのため本研究では、交互に配置するパターンは好みではないとの意見がいくつか挙がった点を踏まえ、太陽光発電設備と屋上緑化を分けて配置するパターンが最適であると考える。

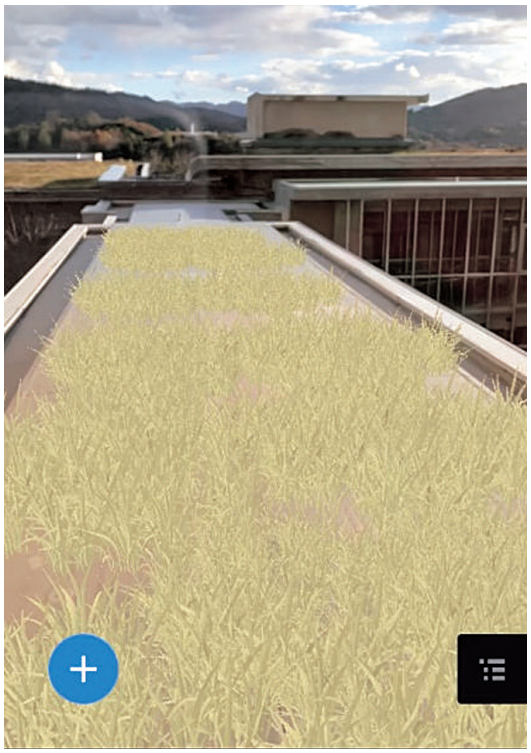

(a)屋上緑化のみ

(b)太陽光発電設備のみ

(c)太陽光発電設備と屋上緑化を交互に配置

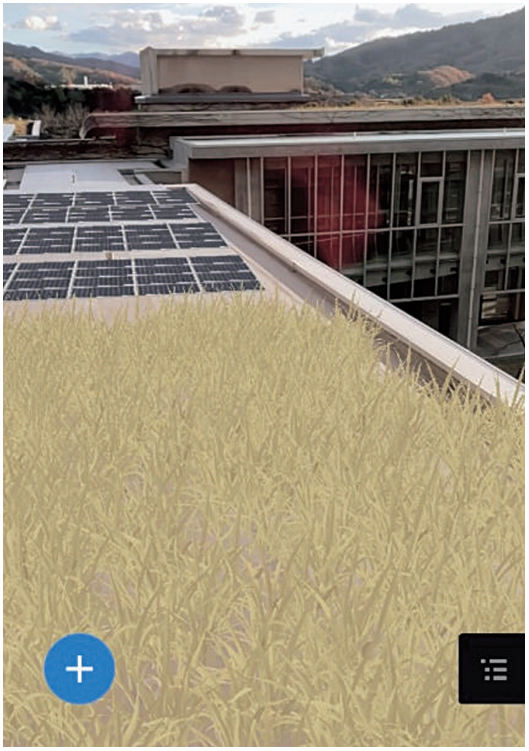

(d)太陽光発電設備と屋上緑化を分けて配置

図７　太陽光発電設備と屋上緑化のARによる可視化パターン

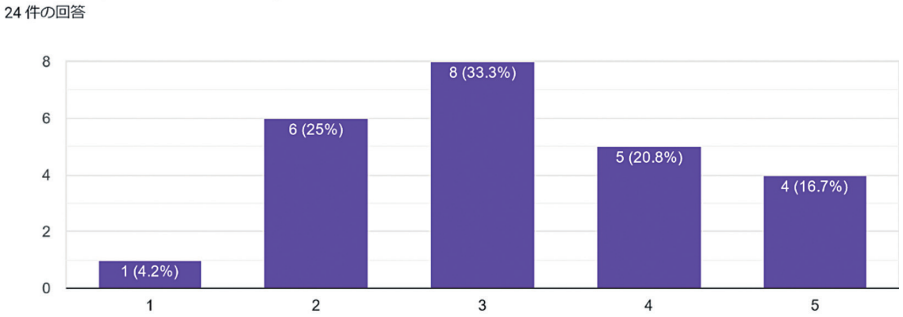

(a)緑化のみ

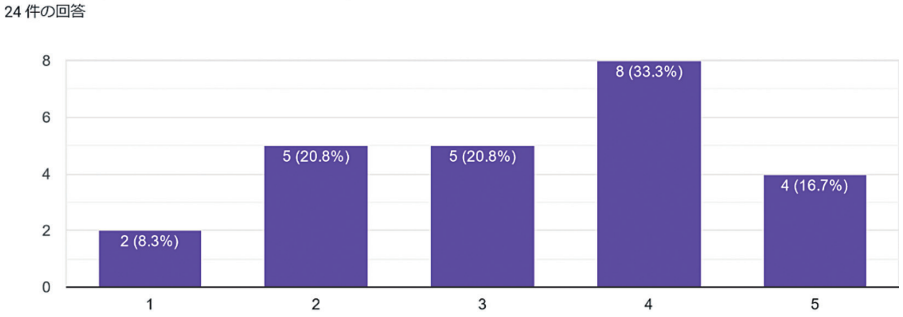

(b)太陽光発電設備のみ

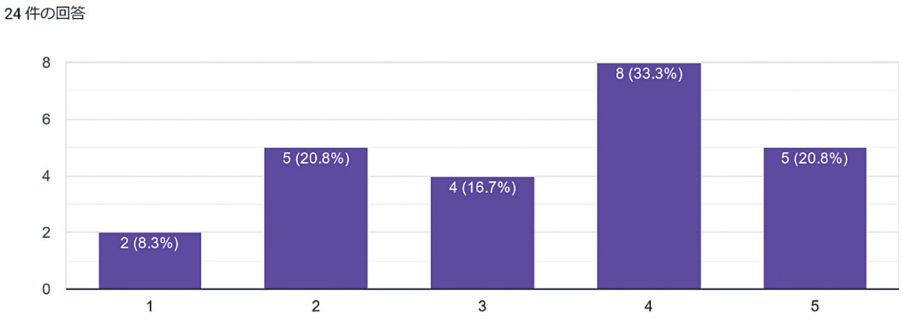

(c)太陽光発電設備と緑化を交互に配置

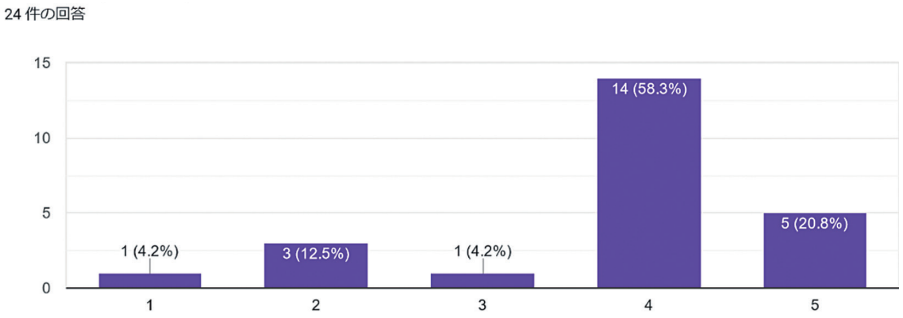

(d)太陽光発電設備と緑化を分けて配置

図８　５段階評価の結果

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を大量に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、本研究では、再生可能エネルギーの大量導入時における持続可能な景観設計手法を提案した。景観色彩設計に基づく景観を作成しARを用いて可視化することによって、導入後の問題を防ぐことを目的とした。実験では、太陽光発電設備及び屋上緑化導入時に持続可能な景観設計が可能であるかを検証するため、複数の景観パターンを作成し主観評価を行った。主観評価結果を受け考察し、太陽光発電設備と屋上緑化を同時に導入した際も景観として優れていると評価されることを示した。

参考文献

[1] N. Alamir, S. Kamel, T. F. Megahed, M. Hori, and S. M. Abdelkader, Developing Hybrid Demand Response Technique for Energy Management in Microgrid Based on Pelican Optimization Algorithm, Electric Power Systems Research, 2023.

[2] N. Wu, B. Green, X. Ben, S. O'Banion, Deep Transformer Models for Time Series Forecasting: The Influenza Prevalence Case, arXiv:2001.08317, 2020.

[3] Scott M. Lundberg and Su-In Lee., A unified approach to interpreting model predictions, Advances in Neural Information Processing Systems, 2017.

[4] 平野勇二郎, オフィスビル街区における屋上緑化のCO_2削減効果のシミュレーション評価, 空気調和・衛生工学会大会 学術講演論文集, 第10巻, pp77-80, 2014.

[5] 朝日新聞, 街並みの色彩を考える「景観色彩」ってどんなもの？ https://oshihaku.jp/nenkan/page/14926299 [参照2025年１月25日].

[6] 亀田能成, マーカレスAR, 映像情報メディア学会誌, 第66巻, pp45-51, 2012.

[7] scikit-learn Machine Learning in Python https://scikitlearn.org/stable/index.html [Online, accessed, April 24th, 2024].

[8] Blender, About-blender.org, https://www.blender.org/about/ [参照2025年１月27日].

[9] Adobe, Adobe Aeroとは, https://helpx.adobe.com/jp/aero/using/what-is-adobe- aero.html [参照2025年１月27日].