

時系列 XAI 技術による電力需要予測モデルの 説明性獲得と予測性能向上

Acquiring Explainability and Improving Performance
of Electricity Demand Forecasting Model Through Time-series XAI



高木 洋和^{*1}
Hirokazu Takagi

土坂 祐太郎^{*1}
Yutaro Tsuchisaka

杉森 文亮^{*1}
Fumiaki Sugimori

林 千春^{*1}
Chiharu Hayashi

手島 哲平^{*2}
Teppei Teshima

森田 克明^{*3}
Katsuaki Morita

電力自由化や CO₂ 排出量ゼロ社会への取組みにより、エネルギー状況は急激に変化している。特に大規模工場においては効率的なエネルギー管理が求められるが、エネルギー需要は機器の運転や気象条件などの様々な要因による影響を受けるため常に変動しており、それらの条件に基づいた正確な需要予測が必要とされる。本報では、工場の電力需要予測を行う深層学習時系列予測モデルに焦点を当て、モデルが重要視する変数や予測の根拠を説明する説明可能 AI (XAI) の中でも、時系列方向の特徴についても説明可能な XAI (時系列 XAI) について紹介する。具体的には、モデル全体の振る舞いを示す大局的手法 TIME と、モデルの予測根拠を示す局所的手法 TimeSHAP で、モデルの説明性を補うことができる。また、大局的手法 TIME で、モデルが注目する説明変数を抽出し、それらの変数でモデルを再構築することによりモデルの性能改善が図れることを示す。

[三菱重工グループのマテリアリティはこちら](#)

1. はじめに

電力自由化やカーボンニュートラル社会に向けたエネルギー環境の変化を受け、電力や熱などの多くのエネルギーを消費する工場においては、再生可能エネルギーの利用率を高めるとともに、設備稼働や操業に応じて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。三菱重工株式会社 (以下、当社) では、当社製品群やサービスとデジタル技術を“かしこく・つなぐ”をコンセプトに、人と機械の協調を目指す“Σ SynX®”を推し進めており、その一つとして、工場の電力需要予測を含む、デジタルを活用した様々な製品やサービスを提供するインテリジェントソリューション TOMONI®を展開している。TOMONI では、時系列予測技術を用いた顧客のエネルギーマネジメント高度化に向けて、電力需要予測を当社社内工場へ適用し実証試験を通じてサービス実用化を推進している。

工場でのエネルギー需要は刻一刻と変動する各種設備の稼働状況や気象条件等により左右されるため、それら条件の基に将来のエネルギー需要を予測する手法が重要となる。エネルギー需要を高精度に予測することができれば、予測に基づく効果的な設備稼働計画の立案や発電量の削減により省エネやエネルギーコスト (燃料費、人工費等) の削減に繋げることができる。

近年では、深層学習の分野において、自然言語処理でよく用いられる Transformer ベースの手法を始めとして種々の時系列予測手法が提案されている^{(1)~(5)}。これら手法は、従来の時系列予測手法と比較して、気象や交通等の様々なドメインのデータに対して、高精度な予測が可能であることが報告されている。そのため、これら予測手法を将来のエネルギー需要予測に適用すること

*1 デジタルイノベーション本部 EPI 部

*2 エナジードメイン GTCC 事業部 高砂サービス技術部 主席技師

*3 デジタルイノベーション本部 EPI 部 主席技師

で、予測の高精度化が期待できる。しかし、深層学習モデルは一般的に処理の内部がブラックボックスであるため、どの変数が予測結果にどのような影響を及ぼすかは不明である。予測モデルを実務に適用するためには、予測モデル全体の振る舞いや、個別の出力結果に対する説明性が求められる。これを解決するアプローチとして、説明可能 AI (XAI: Explainable AI) が挙げられる。モデル全体の振る舞いを示す大局的説明や個別の予測結果を示す局所的説明を用いることで、予測モデル導入時や運用段階における信頼性向上に繋がり、高度な予測モデルの実用化の促進が期待できる。特に、近年では、本報で対象とする時系列予測に対応した時系列 XAI 技術が提案されている⁽⁶⁾。

2. 方法

2.1 時系列 XAI

XAI は、機械学習モデルや出力結果に対して予測根拠を提示する技術の総称である。近年では、機械学習技術の進展と共に、XAI も対象モデルや用途に応じて多種多様な手法が提案されており、時系列予測手法に対応した XAI も提案されている⁽⁶⁾。本報では、時系列予測モデルに対応した時系列 XAI のうち、モデル全体の振る舞いを示す大局的手法である TIME (Temporal Importance Model Explanation) と特定の出力に対してどのように説明変数が寄与したかを示す TimeSHAP (SHapley Additive exPlanations) を、深層学習を用いた時系列予測モデル (以後、深層学習時系列予測モデル) に適用した。

TIME は、モデルに依存せずに大局的な説明を行うとともに、時間依存性を考慮した上で重要な変数や時間帯を特定する XAI である。TIME の計算方法の概要を図1に示す。TIME では、次の手順で予測において重要な説明変数・時間帯を特定する。

- ① D 個の説明変数 x を用いて、 y を予測するモデル f を構築する。
- ② $(x^{(i)}, y^{(i)})$ を i 番目のインスタンス (時間単位 of データ群) ペアとし、インスタンス i における予測値を得る (式(1))。
- ③ インスタンス i と l の説明変数 j を交換し、予測値を得る (式(2))。
- ④ インスタンス交換前後での予測誤差 $\mathcal{L}$ を算出し、その差分 $\Delta\mathcal{L}$ を得る (式(3))。
- ⑤ 全てのインスタンス $i = 1 \dots M$ に対して上記を計算し、その平均値を説明変数 j の重要度とする。
- ⑥ 重要とされた変数について時間軸方向にインスタンスを交換し、その際の予測誤差の比較及び仮説検定により重要な時間帯を特定する。


本報では、TIME を時系列予測モデルに対して適用し、重要変数の妥当性を確認するとともに、重要変数でモデルの再構築を行うことで、モデルの性能改善を図った。

$$f(x^{(i)}) = f(x_1^{(i)}, x_2^{(i)}, \dots, x_j^{(i)}, \dots, x_D^{(i)}) \quad (1)$$

$$f(x^{(i,l)}) = f(x_1^{(i)}, x_2^{(i)}, \dots, x_j^{(l)}, \dots, x_D^{(i)}) \quad (2)$$


$$\Delta\mathcal{L}_j^{(i,l)} = \mathcal{L}[y^{(i)}, f(x_j^{(i,l)})] - \mathcal{L}[y^{(i)}, f(x^{(i)})] \quad (3)$$

$$I(f, j) = \frac{1}{M} \sum_{i=1}^M \Delta\mathcal{L}_j^{(i)} \quad (4)$$

図1 TIME の計算方法⁽⁷⁾

TimeSHAP は、機械学習モデルの予測結果について説明変数毎の寄与度を出力する kernel SHAP を時系列予測に拡張した XAI である。通常の SHAP では、ゲーム理論のシャープレイ値*に基づき、機械学習モデルに関する獲得量の寄与の総和が予測値に一致するという性質を用いて、各説明変数の寄与度を求め、予測結果に対する各説明変数の寄与度を算出する。それに対して、TimeSHAP では各説明変数に加えて、時間軸方向に対しても SHAP 値を計算することで、時間方向に関する寄与度を得る(図2)。この時、変数及び時間軸方向に対して SHAP 値を計算した場合、飛躍的に計算量が増大するが、Temporal Coalition Pruning(遠い過去の情報はグループ化することにより計算量を削減する)により計算量を削減した。本報では、日毎の予測結果に対する説明性を得るために、TimeSHAP を時系列予測モデルに適用した。

*プレイヤーが連携して得られた利益に対する、各プレイヤーの影響度・貢献度を表す指標

図2 SHAPとTime SHAP の比較⁽⁸⁾

2.2 実験データ

電力需要予測モデルは以下のデータセットを用いて構築した。説明変数は、工場の電力需要管理に関する知識を有する分析担当者の知見を基に選定した。

- ・ 目的変数 : 工場の電力需要量データ
- ・ 説明変数 : 工場の設備稼働計画・過去の電力需要実績値, 気象データ, カレンダーデータ(計 46 変数)
- ・ データ期間 : 2021/8/1～2022/8/31
 - 訓練 : 2021/8/1～2022/5/31
 - 評価 : 2022/6/1～2022/7/31
 - 予測 : 2022/8/1～2022/8/31
- ・ データ間隔 : 30 分間隔

2.3 実験方法

本報では、上記データセットにより Transformer ベースの深層学習時系列予測モデル Informer⁽¹⁾ を用いて、電力需要予測モデルを構築した。以下の手順で予測モデルの構築, 時系列 XAI の適用, 精度検証を行うことで、説明結果の妥当性確認と、予測モデルの性能の変動を確認した(図3)。

- ① 全変数を用いて予測モデルを構築する(オリジナルモデル)。
- ② 上記モデルに TIME を適用する。
- ③ TIME で重要と判定された説明変数のみを用いて、予測モデルを再構築する。

- ④ オリジナルモデルと再構築モデルの各種精度指標 (R2: 決定係数, MAE: 平均絶対誤差, MAPE: 平均絶対誤差割合, MAXE: 誤差最大値)を比較し, 再構築モデルの有効性を検証する。
- ⑤ TimeSHAP を用いて, 個別の出力結果に対する説明性を確認することで, 説明性を得られるかの確認を行う。




図3 評価イメージ

3. 結果及び考察

電力需要予測モデルを構築し, TIME を適用した結果得られた重要度が上位である変数及び時間帯別の重要度を図4に示す。抽出された説明変数を確認すると, 過去の電力需要量や休日などのカレンダー情報, 気象予報値など, 当初モデル予測において特に重要であると想定した通りの変数が得られた。また, 重要度が高い時間帯を確認すると, 各説明変数共に深夜を除き, 一日を通して重要であることが分かった。

このように, 時系列 XAI により, ブラックボックスモデルである深層学習時系列予測モデルにおいて, 変数や時間帯の重要度を抽出できることを確認した。




図4 TIMEにより算出された重要度上位5変数

重要度が高い変数を選択した上で, 予測モデルを再構築し, 予測を行った結果を図5に示す。また, その際の予測精度指標算出結果を表1に示す。予測精度を比較した結果, 再構築後のモデルの各種精度指標が改善されることを確認した (MAE で-19%の減少)。これは, 説明変数を重要変数のみに絞ることで, オリジナルモデルでノイズとなっていた変数が除外された可能性や, 多重共線性 (説明変数内に相関が高い組が存在する時, 適切なモデルのパラメータ推定ができなくなる問題) が発生していた場合, その影響が改善した可能性が考察できる。

この結果より, 時系列 XAI を用いた変数選定による再構築モデルは, 分析担当者がドメイン知識に基づいて選定した変数で構築したモデルと比較し, 精度面での優位性が確認できた。




図5 実績値および各モデルによる予測結果

表1 各モデルによる予測精度比較結果

評価指標	オリジナルモデル	再構築モデル
R2	0.952	0.962
MAE	0.455	0.369
MAPE	7.54	5.98
MAXE	2.59	2.45

次に、TimeSHAP を用いて日毎の予測結果の説明性について検討した。まず、日毎・時間帯別の予測に関する重要度の傾向を確認するために、予測モデルの日毎の出力結果に対して、TimeSHAP により SHAP 値を計算した(図6)。このヒートマップでは、縦軸に時間帯、横軸に日付を取り、該当日の予測に用いた説明変数における、時間帯別の予測への寄与度を示している。ヒートマップから、平日は電力需要が高くなる昼間の時間帯の寄与度が高く、休日は一日を通して全体的に時間帯寄与度が低いことが分かった。

次に、TIME での再構築モデルにより特に精度が改善(MAE が約 58%減少)した条件 8/25(木)、8/26(金)の予測結果について確認した(図7)。オリジナルモデルに対して TimeSHAP を適用し、予測に寄与した変数を抽出した結果を表2に示す。抽出された変数を見ると、過去の電力需要量のように TIME で抽出された変数と同じ変数も抽出されている一方で、設備情報のように異なる変数も抽出されており、実際に該当変数の傾向を確認したところ、これらの変数が予測に悪影響を及ぼしていた可能性が示唆された。

以上の結果より、TimeSHAP が抽出する変数の妥当性を確認できたと同時に、予測失敗の原因特定にも有効な手段であることが検証できた。




図6 TimeSHAP による日別・時間帯別の SHAP 値の算出結果




図7 再構築モデルについて特に精度が良好であった期間の予測結果

表2 オリジナルモデルの各日の予測結果に対して予測に
寄与した変数(■: 正に寄与, ■: 負に寄与)

寄与度が高い変数	8/25(木)	8/26(金)
時間情報	0.203	0.221
過去の電力需要量①	0.0266	0.0346
設備情報①	-0.0298	0.0004
気象情報	0.0096	0.0484
過去の電力需要量②	0.0475	0.0492
設備情報②	0.0088	-0.0825
過去の電力需要量③	0.309	0.305

4. まとめ

本報では、工場の電力需要予測を題材として、深層学習時系列予測モデルに対して時系列 XAI を適用することで、モデルの説明性を補うと共に、モデルの性能改善を図った。

本技術により、予測モデルの説明性が得られることで、モデルが重要視する変数や予測結果に至った理由を人間が解釈することが可能となり、意思決定支援に繋げることができる。加えて、時系列 XAI を用いた電力需要予測モデルの再構築により予測精度が向上すれば、無駄のない発電計画に基づく運転が可能となり、エネルギーコストの削減や環境負荷の低減効果が期待できる。

また、本報では電力需要予測を題材としたが、時系列 XAI は幅広い時系列予測問題に適用可能であり、深層学習モデルをはじめとするブラックボックスモデルの説明性に関する課題の打ち手として期待できる。

今後は、本報で検討した予測モデルの高度化及びそれに対する時系列 XAI を用いたモデルの説明技術を TOMONI 上に機能実装し、高砂水素パークなど自社工場、社内設備での検証試験を通じて、実用化・サービス展開を図る。

Σ SynX®は、三菱重工業株式会社の日本及びその他の国における登録商標です。

TOMONI®は、三菱重工業株式会社の日本及びその他の国・地域における登録商標です。

参考文献

- (1) Zhou, H., et al., Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting., AAAI Conference on Artificial Intelligence (2020)
- (2) Wu, H., et al., Autoformer: Decomposition Transformers with Auto-Correlation for Long-Term Series Forecasting. Neural Information Processing Systems (2021)
- (3) Zhou, Tian, et al., FEDformer: Frequency Enhanced Decomposed Transformer for Long-term Series Forecasting., ArXiv abs/2201.12740 (2022)
- (4) Liu, S., et al., Pyraformer: Low-Complexity Pyramidal Attention for Long-Range Time Series Modeling and Forecasting. International Conference on Learning Representations. (2022)
- (5) Nie, Y., et al., A Time Series is Worth 64 Words: Long-term Forecasting with Transformers. ArXiv, abs/2211.14730. (2022)
- (6) Rojat, T., et al., Explainable Artificial Intelligence (XAI) on TimeSeries Data: A Survey. ArXiv, abs/2104.00950. (2021)
- (7) Sood, A., et al., Feature Importance Explanations for Temporal Black-Box Models. ArXiv, abs/2102.11934. (2021)
- (8) Bento, J., et al. TimeSHAP: Explaining Recurrent Models through Sequence Perturbations. Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining. (2020)