

DOI: 10.19666/j.rlfed.202312188

基于可解释性深度学习的太阳 辐射强度预测

李 昂, 周雷金, 闫群民, 贺海育
(陕西理工大学电气工程学院, 陕西 汉中 723000)

[摘要] 准确预测太阳辐射强度 (SI) 对电力调度和光伏选址至关重要。随着高性能计算机和大容量存储设备的发展, 基于数据驱动的深度学习模型在 SI 预测领域获得广泛关注, 然而, 深度学习模型的“黑箱”特性在物理解释性上的缺失, 限制了其在特定场合的应用可信度。为了在保持预测精度和模型结构不变、不增加计算复杂度的前提下, 提升模型的可解释性, 构建了一个基于长短时记忆 (LSTM) 神经网络的模型。其性能比传统神经网络提高了 8.07%, 并展示出更优的离群点处理能力。通过采用分层相关传播 (LRP) 算法, 从时间和空间 2 个维度对影响模型输出的因素进行了评分, 增强了模型的可解释性。研究结果表明: 该模型在确保性能的前提下, 具备良好的可解释性, 其中历史辐射强度、时间相关特征 (如时日周月)、太阳高度角信息 (如日出和日落时刻)、云层覆盖度、辐射时长、温度和露点温度等因素是影响太阳辐射强度预测的主要因素。

[关键词] 太阳辐射强度预测; 深度学习; 可解释性; LRP 算法; LSTM

[引用本文格式] 李昂, 周雷金, 闫群民, 等. 基于可解释性深度学习的太阳辐射强度预测[J]. 热力发电, 2024, 53(5): 132-140. LI Ang, ZHOU Leijin, YAN Qunmin, et al. Prediction of solar irradiation based on interpretable deep learning[J]. Thermal Power Generation, 2024, 53(5): 132-140.

Prediction of solar irradiation based on interpretable deep learning

LI Ang, ZHOU Leijin, YAN Qunmin, HE Haiyu
(College of Electrical Engineering, Shaanxi University of Technology, Hanzhong 723000, China)

Abstract: Accurately predicting solar irradiation (SI) is crucial for power scheduling and photovoltaic site selection. With the development of high-performance computing and large-capacity storage devices, data-driven deep learning models have gained widespread attentions in the SI prediction domain. However, the lack of physical interpretability due to the “black-box” nature of deep learning models restricts their credibility in specific scenarios. To enhance the interpretability of the model on the premise of maintaining prediction accuracy and keeping the model structure unchanged, and without increasing computational complexity, a model based on long short-term memory (LSTM) neural network is constructed, demonstrating an 8.07% performance improvement over the conventional neural networks and showing superior outlier handling capabilities. By employing layer-wise relevance propagation (LRP) algorithm, factors influencing the model output are scored from both temporal and spatial dimensions, enhancing the model’s interpretability. The research results indicate that the model possesses good interpretability under the premise of ensuring performance, with historical solar irradiation, time-related features (such as hour, day, week, month), solar altitude information (such as sunrise and sunset times), cloud cover, radiation time, temperature, and dew point temperature being the main factors influencing SI prediction.

Key words: solar irradiation prediction; deep learning; interpretability; LRP algorithm; LSTM

收稿日期: 2023-12-05

基金项目: 陕西省教育厅重点科学研究计划项目 (20JS018); 陕西省教育厅专项科研计划 (5JK1125)

Supported by: Key Scientific Research Project of Education Department of Shaanxi Provincial (20JS018); Special Scientific Research Project of Shaanxi Provincial Department of Education (15JK1125)

第一作者简介: 李昂 (1971), 男, 硕士, 教授, 主要研究方向为电能质量分析及光伏发电技术, la1011@163.com。

通信作者简介: 周雷金 (1999), 男, 硕士研究生, 主要研究方向为深度学习在新能源发电中的应用, Zhou99723000@163.com。

随着“双碳”目标的提出,可再生能源在国家电网中的应用和渗透持续增长。其中,太阳能作为一种可靠、清洁且前景广阔的可再生能源,受到了广大研究者和产业界的高度关注^[1]。根据国家能源局发布的《2022年光伏发电建设运行情况》报告,2022年,我国新增的光伏发电并网容量达到了87.408 GW,再次验证了太阳能在我国可再生能源布局中的重要地位。

对于光伏发电系统,太阳辐射强度(solar irradiation, SI)是影响其发电效率的主要因素^[2]。SI的不确定性使得光伏输出电压具有波动性和间歇性^[3],因此为保证电网运行的稳定性与电力调度的可靠性,准确的SI预测至关重要^[4]。

随着高性能计算机的快速发展以及大容量储存设备的普及,研究人员发现传统经验模型不能满足高精度的要求^[5],因此由数据驱动预测模型在SI预测中脱颖而出。在实际研究中,以人工智能为基础的SI预测模型通常采用温度、辐射时长等多元气象参数作为输入因子^[6]。然而,传统机器学习方法在处理高维数据时需要复杂的特征工程^[7]。基于此,本文选择采用深度学习方法进行SI预测。

深度学习用于SI预测中,最初一般以人工神经网络(artificial neural network, ANN)为主。文献[8]中Behrang等人以ANN作为预测模型,以气温、相对湿度、日照时长、风速值等气象变量作为输入,研究了ANN在SI预测中的潜力。文献[9]中Cao等人以逐日历史SI数据作为输入,利用小波变换法将SI样本数据分解为不同时频域的分量,并将上述分量作为循环反投影网络(recurrent back-projection network, RBPN)的输入建立了SI预测模型,结果表明采用小波变换法的模型具有更高的精度。文献[10]中Ahmad等人利用含外源输入的非线性自回归神经网络,以9种气象数据方式作为输入,输出了日前1h的SI。文献[11]中Sharma等人将Morlet小波变换与Mexican hat小波变换相结合,将这种混合小波变换作为前馈ANN隐藏层的激活函数,分别以1h与0.25h将2种尺度的历史SI作为输入建立了SI预测模型。

随着计算能力的更加强大,循环神经网络(recurrent neural network, RNN)及其变体神经网络开始被人们大规模研究,由于其本身串行计算的特点,相对于前述ANN等神经网络能够更好地表征时序特性,因此被广泛用于SI预测中。文献[12]

中Pang等人通过RNN与ANN对SI进行预测,并对比2种模型在不同采样频率以及是否加入滑动窗口情况下的准确性以及效率;结果表明RNN比ANN在SI预测中具有更好的效果,且加入滑动窗口算法与提高采样频率都能提高预测精度,但是在计算时间方面,RNN要明显高于ANN。文献[13]中Aslam等人通过门控循环单元(gated recurrent units, GRUs)对SI进行长期预测,即预测未来一年中逐时SI。文献[14]中Srivastava等人以多元气象数据以及地理数据作为输入,将长短时记忆(long short-term memory, LSTM)神经网络用于SI预测,结果表明相较于数值天气预报模型LSTM预测模型具有更高的精度,说明LSTM神经网络在SI预测方面具有巨大的潜力。文献[15]中Obiora等人通过LSTM神经网络,以10年的历史气象数据作为输入对SI进行了单步逐时预测,通过与SVR预测模型进行对比,结果表明LSTM模型具有更小的均方根误差。以上文献充分说明RNN及其变体神经网络在SI预测中的强大能力。

然而,上述文献仅侧重于精度方面,而未考虑深度学习模型常被视为“黑箱”模型,其内部计算过程缺乏明确的可解释性。随着深度学习技术快速发展,其在众多领域如信用评分^[16]、地震预报^[17]和医疗保健^[18]等方面都得到了广泛应用,从伦理、法律和道德的角度出发,深度学习的可解释性在决定其在实际场景中的应用潜力时具有至关重要的作用^[19]。

在可解释性方面,在工程领域中,文献[20]中Li等人将attention机制引入RNN中,通过对注意力向量的进一步分析,可以更好地理解建筑热力学中的时间信息。文献[21]中López等人利用TFT(temporal fusion transformer)对光伏功率进行预测,TFT中含有时间自注意解码器,可以识别全局重要特征、时间模式以及重要事件,不仅提高了模型的准确性,也提高了模型的可解释性。文献[22]中Gao等人通过引入attention机制与图卷积神经网络(graph convolutional network, GCN)提高了模型的可解释性。文献[23]中Gao等人采用time2vec对输入进行时间维度编码,采用标准嵌入对输入进行空间维度编码,使得输入同时具有了时间与空间特性,利用类Transformer结构获取不同步长的各种特征的权重,同时从时间、空间两方面来对模型进行可解释性分析。

但是以上文献所采用方法在提高可解释性的同时,改变了网络的结构且增加了计算的复杂性。而分层相关传播(layer-wise relevance propagation, LRP)算法^[24]则可解决上述问题。文献[25]中 Yang 等人将 LRP 运用于临床领域,文献[26]中 Grezma 等人将 LRP 运用于机器故障诊断,文献[27]中 Kim 等人将 LRP 运用于 PM_{2.5} 的预测中。

在 SI 预测方面,仅有极少数文献对模型的可解释性进行了分析,且并未有文献将模型与 LRP 相结合。因此,本文提出一种将 LRP 与 LSTM 神经网络相结合的 SI 预测算法,能在保持预测精度和模型结构不变、不增加计算复杂度前提下,增强了基于 LSTM 神经网络的 SI 预测模型的可解释性。

1 模型构建

1.1 LSTM 神经网络

为保证充分挖掘 SI 预测中的时序特征,本文采用 LSTM 神经网络作为模型构建的基本单元。LSTM 神经网络是一种改进的 RNN,解决了普通 RNN 易出现梯度消失的问题。相较于经典的前馈神经网络,LSTM 神经网络具有反馈连接,能够有效处理与预测时间序列数据,并且也具有处理单个数据点的能力^[28],因此被广泛运用于自然语言处理与时间序列预测。图 1 为 LSTM 神经网络基本单元。

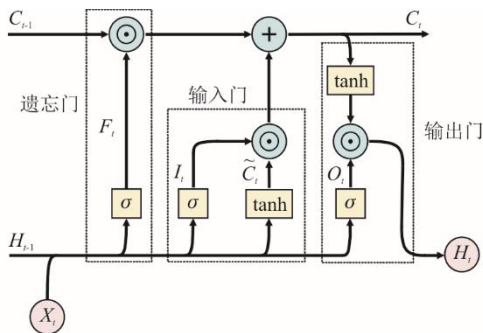


图 1 LSTM 神经网络基本单元

Fig.1 Basic unit of the LSTM neural network

如图 1 所示,LSTM 神经网络输入包括前一时间步输出 H_{t-1} 、前一时间步 Cell 输出 C_{t-1} 与当前时间步输入 X_t ,输出包括当前时间步输出 H_t 与当前时间步 Cell 输出 C_t 。LSTM 神经网络单元分为遗忘门(forget gate)、输入门(input gate)、输出门(output gate) 3 个部分。

遗忘门以 X_t 与 H_{t-1} 作为输入,通过 sigmoid 函数来产生 1 个 0~1 的概率值,作为 C_{t-1} 在本次时间步的权重 F_t ,计算公式为:

$$F_t = \sigma(X_t \cdot W_{xf} + H_{t-1} \cdot W_{hf} + b_f) \quad (1)$$

式中: W_{xf} 、 W_{hf} 、 b_f 分别为 X_t 、 H_{t-1} 的权重和偏置。

输入门的输入分为两部分:一部分由 X_t 与 H_{t-1} 分别通过 tanh 函数产生一个 [-1,1] 之间的值,这个值就作为本次时间步的候选 Cell 信息 \tilde{C}_t ;另一部分由 X_t 与 H_{t-1} 通过 sigmoid 函数产生 \tilde{C}_t 的权重 I_t ,计算公式为:

$$I_t = \sigma(X_t \cdot W_{xi} + H_{t-1} \cdot W_{hi} + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(X_t \cdot W_{xc} + H_{t-1} \cdot W_{hc} + b_c) \quad (3)$$

式中: W_{xi} 与 W_{hi} 分别为 X_t 与 H_{t-1} 的权重; b_i 为偏置,式(3)同理。因此由式(1)一式(3)可得当前时间步 Cell 输出 C_t ,计算公式为:

$$C_t = F_t \odot C_{t-1} + I_t \odot \tilde{C}_t \quad (4)$$

输出门逻辑同输入门,由 tanh 函数产生输出的候选信息,由 sigmoid 函数产生输出候选信息的权重 O_t ,并由两者共同产生输出权重 H_t ,计算公式为:

$$O_t = \sigma(X_t \cdot W_{xo} + H_{t-1} \cdot W_{ho} + b_o) \quad (5)$$

$$H_t = O_t \odot \tanh(C_t) \quad (6)$$

式中: W_{xo} 与 W_{ho} 分别为 X_t 与 H_{t-1} 的权重; b_o 为偏置。

1.2 Encoder-Decoder 模型

Encoder-Decode 模型,也称编码-解码模型。最早在机器翻译领域提出^[29],被广泛运用于 sequence-to-sequence 类问题。图 2 为传统 Encoder-Decoder 模型结构。




图 2 传统 Encoder-Decoder 模型结构

Fig.2 Structure of the conventional Encoder-Decoder model

由图 2 可见,该模型存在编码与解码 2 个过程。前者将输入序列 X_i 编码为定长向量 C ,从时间和空间 2 个维度上提取特征,并认为编码器中最后一个时间步所输出向量 C 包含编码器所有输入的信息,从而使输入数据降维。后者则采用 C 对编码器进行初始化,解码器每次只输出 1 个向量,且解码器每个时间步的输出与隐藏状态都作为下一时间步的

输入，从而保证了输出的连续性。传统用于机器翻译的 Encoder-Decoder 模型，由于语句中的信息在最初已经全部包含，不需要在解码器中再进行额外的信息输入。但是对于 SI 预测来说，输入序列为时间序列，若采用上述结构则可能会忽略一些静态特征，如：本日为 1 年中第几天，为 1 周中第几天等。因此，在编码器中应该考虑将一些静态特征作为额外输入。本文以 LSTM 神经网络作为编码器与解码器，所采用结构如图 3 所示。

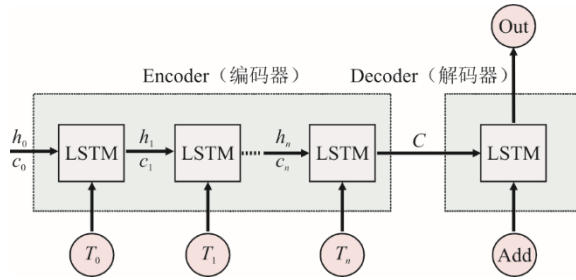


图 3 本文采取的 Encoder-Decoder 结构
Fig.3 Structure of the Encoder-Decoder model adopted in this paper

1.3 Layer-wise relevance propagation 算法

1.3.1 可解释性理解

为了清晰地阐述后续的可解释性内容，提出以下 2 个关键问题：1) 为什么需要对深度学习模型进行可解释性分析；2) 如何对深度学习模型进行可解释性分析。这 2 个问题将为后续的讨论提供方向和框架。

对于第 1 个问题，本文基于可信度、透明度以及公平性 3 点来进行阐述。首先，对于 1 个模型，只有用户明白该模型做出决策的机理，以及算法做出决策符合人们的常识，这样才能增强模型的可信度，模型的可信度对于模型是否能够大规模应用在实际场合至关重要。其次，对于 1 个模型而言，若能够理解模型内部决策过程，则可以认为模型是透明的。而透明的模型有益于人们评估预测质量以及针对不合理的输出结果进行改进。最后，模型在进行决策时，不会偏袒任何输入变量，做出的决策公平公正即模型的公平性。模型在决策时，有时会因为数据集的质量不佳而产生偏差，而对深度学习进行可解释性分析则可改善这一点提高公平性。

对于第 2 个问题可解释性的分析，本文主要从时间与空间 2 个方面进行考虑。即在 SI 预测中考虑不同时间步对于输出的影响以及同一时间步

不同输入对于输出的影响。

1.3.2 LRP 算法

LRP 通过利用已设计好的局部传播规则，使预测值在网络中进行反向传播。

这种传播规则类似电路中的基尔霍夫定理，在传播过程中要遵守守恒规则，即网络中每个神经元接收到的信息必须等量的重新分配到下一层的神经元中，传播过程如图 4 所示。图 4 中： R_i 为第 i 个神经元， R_{10} 为网络输出，规定 $R_{i \leftarrow j}$ 为神经元 j 流向神经元 i 的信息。以 R_{10} 流向 R_7 的信息 $R_{7 \leftarrow 10}$ 为例，此时 $R_{7 \leftarrow 10}$ 满足式(7)：

$$R_{7 \leftarrow 10} = R_{4 \leftarrow 7} + R_{5 \leftarrow 7} + R_{6 \leftarrow 7} \quad (7)$$




图 4 LRP 算法传播过程
Fig.4 Propagation process of the LRP algorithm

假设 R_m 与 R_n 为相邻 2 层神经元， R_m 为 R_n 输入，传播规则公式为：

$$R_m = \sum_n \frac{z_{mn}}{\sum_m z_{mn}} R_n \quad (8)$$

式中： z_{mn} 模拟了神经元 m 对神经元 n 的贡献；分母则是用来保证守恒性质的。若将此规则扩展至全局，则可得到输入对于输出的影响程度。

2 数据处理

本文气象数据集来自日本气象厅官方网站^[22]，为 2019 年 1 月 1 日至 2020 年 12 月 31 日期间实测的东京逐时气象特征数据，其中包括 15 个特征，分别为 4 个与时间相关的特征即时、日、周、月，以及 11 个气象特征即本站气压 (hPa)、海平面气压 (hPa)、降雨量 (mm)、温度 (°C)、露点温度 (°C)、水蒸气气压 (hPa)、湿度、风速 (m/s)、每小时辐射时长 (h)、云层覆盖等级 (等级为 10 的人为观测标定量)、通过经纬度。结合太阳高度角和方位角所计算出的信息 (日出和日落时刻)，SI 样本值数据来源于靠近气象测量点附近实测每平方米所接收的太阳辐射强度 (W/m^2)。

2.1 数据划分

本文数据集将 2019 年 1 月 1 日至 2019 年 12 月 31 日设置为训练集, 2020 年 1 月 1 日至 2020 年 6 月 30 日设置为验证集, 2020 年 7 月 1 日至 2020 年 12 月 31 日设置为测试集。

本文将滑动窗口设置为 24, 即以历史 24 h 的数据对未来 1 h 进行预测 (图 5)。




图 5 滑动窗口
Fig.5 Sliding window

2.2 数据预处理

深度学习虽然减少特征工程的复杂度, 但是并不代表不需要进行特征处理。输入特征的量级等方面的差异会影响各特征在训练过程中所占权重, 因此仍需对特征进行归一化处理。本文将输入划分 2 种, 分别为上述 15 种特征值与历史辐射强度。

15 种特征值采用 Z-score 的方式进行归一化, Z-score 为一种常见的标准化归一方式^[30-31], 可以将不同量级的数据转化为统一量度。计算公式为:

$$z = \frac{x - \mu}{\sigma} \quad (9)$$

式中: x 为输入特征的个体数据; μ 为输入特征的均值; σ 为输入特征的标准差。

历史辐射强度为输出变量, 为保证在数据还原时不引入测试集信息, 因此采取 log 归一化的方式对其进行归一化。计算公式为:

$$z = \log_a^y \quad (10)$$

式中: y 为输出变量的个体数据; a 为底数。

2.3 损失函数与评价指标

均方误差值 δ_{MSE} 是时间序列预测中常见评估指标, 因此本文将 δ_{MSE} 作为损失函数, 计算公式为:

$$\delta_{MSE} = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (11)$$

式中: \hat{y}_i 为预测值; y_i 为训练集中实际输出值。

采用决定系数 (R-squared Coefficient, R^2) 作为模型的评估指标^[32], 用于验证集选择最佳模型以及在测试集中对模型精度进行评估。 R^2 作为一种衡

量线性回归程度的无量纲指标, 取值范围为 0~1, 越接近 1 代表模型拟合能力越强。其计算公式为:

$$\begin{cases} R^2 = 1 - \frac{\delta_{SSE}}{\delta_{SST}} \\ \delta_{SSE} = \sum_{i=1}^n (\hat{y}_i - y_i)^2 \\ \delta_{SST} = \sum_{i=1}^n (\bar{y}_i - y_i)^2 \end{cases} \quad (12)$$

式中: δ_{SSE} 为残差平方和; δ_{SST} 为总体离差平方和; \hat{y}_i 为预测值; y_i 为测试集与验证集中实际输出值; \bar{y}_i 为测试集或验证集实际输出值的均值。

3 实验设置

为验证上述方法的有效性 & 准确性, 将以传统深度神经网络与本文算法进行对照实验。编程环境为 Python 3.10.9, 框架为 Pytorch 1.12, 硬件配置 GPU 型号为 NVIDIA GeForce RTX 3070 Ti Laptop。

模型 1 (M1) 为传统深度神经网络, 为保证实验输入的公平性, 将历史 24 h 的 15 种特征值和 SI 以及未来 1 h 的时间信息作为输入, 参数设置见表 1。模型 2 (M2) 为本文所用算法, Encoder 为按时序输入的历史 24 h 的 15 种特征值与 SI, 并且将 Encoder 输出对 Decoder 进行初始化。Decoder 中输入未来 1 h 的时间信息, 参数设置见表 2。

表 1 模型 1 参数
Tab.1 Parameters of model 1

	输入维度	输出维度	隐藏层细胞数	激活函数	Dropout
Linear 1	388	776	776	relu	0.3
Linear 1	776	776	776	relu	0.3
Linear 1	776	1	776	无	无

表 2 模型 2 参数
Tab.2 Parameters of model 2

	输入维度	输出维度	隐藏层细胞数	LSTM 网络深度	激活函数	Dropout
Encoder	24×16	24×128	128	2	无	0.3
Decoder	1×4	1×128	128	2	无	0.3
Linear	1×128	1	128	无	relu	0.3

为保证实验公平, 设置实验迭代次数为 100 次, 批大小为 32, 优化器为 Adam 优化器。并且为保证实验的可复现性, 将本实验所有随机种子设置为 1 000。

4 实验结果

为验证上述方法的有效性 & 准确性, 从实验精度与可解释性进行分析。

4.1 实验精度

表 3 为 2 种模型 R^2 对比。由表 3 可见，本文算法的 R^2 在整体上都优于传统的深度神经网络，且性能提高了 8.07%。

表 3 模型 R^2 对比
Tab.3 Comparison of R^2 between the models

	模型 1	模型 2
7 月	0.746	0.811
8 月	0.837	0.933
9 月	0.840	0.916
10 月	0.885	0.944
11 月	0.908	0.954
12 月	0.920	0.958
7 月 2 日—7 月 8 日	0.751	0.837
12 月 1 日—12 月 7 日	0.925	0.976
测试集	0.855	0.924

由于本文算法 7 月 R^2 表现相对较差，12 月 R^2 表现相对较好。分别任选此 2 月中任意 1 周，7 月 2 日至 7 月 8 日和 12 月 1 日至 12 月 7 日间 2 个模型预测结果进行对比，结果如图 6—图 7 所示。

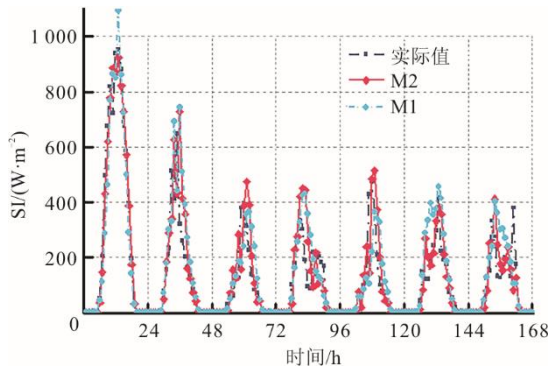


图 6 7 月 2 日—7 月 8 日共 168 h SI 预测

Fig.6 The 168-hour SI forecast between July 2 and July 8




图 7 12 月 1 日—12 月 7 日共 168 h SI 预测

Fig.7 The 168-hour SI forecast between December 1 and December 7

通过图 6 与图 7 可以看出，模型 2 的预测值相较于模型 1 的预测值有着更高的精度，拟合程度更

好，但是仍存在一定误差。这是因为在夏日期间，SI 的绝对数值较大，且存在暴雨、台风等气候影响，导致数值出现剧烈的变化，而数值越大其本身可能产生的误差也会随之越大。因此在 7 月时模型表现相对较差， R^2 相对较低。

对每步预测进行离群值分析，图 8 为模型的绝对误差。由图 8a)可见，由于 SI 具有很强的周期性，因此大量数据为 0，所以 2 个模型的绝对误差平均值基本为 0。但可以明显看出模型 2 的箱型比模型 1 更小，且模型 2 上边缘低于模型 1 上边缘，说明模型 2 整体上具有更好的分布。但 2 个模型仍存在着异常值。为更好地进行观察，取最大的前 10% 绝对误差进行分析。如图 8b)所示，此时模型 2 的箱型明显低于模型 1，误差平均值优于模型 1，箱型比模型 1 更小，且上边缘低于模型 1 上边缘。说明在离群值分析中模型 2 明显优于模型 1。




图 8 模型的绝对误差

Fig.8 Absolute error of the models

4.2 可解释性分析

由 4.1 节分析可知，模型 2 性能明显优于模型 1。因此，本文对模型 2 进行可解释性分析，从时间空间 2 个方面进行考虑，即考虑同一时间步中各个输入特征对于 SI 预测结果的影响，以及不同时间步对于 SI 预测结果的影响。图 9 为测试集特征归因分析，图 10 为测试集时间步归因分析。选取 2 个极端辐射强度，以 8 月 7 日 00:00、11:00 与 12 月 9 日 00:00、12:00 为例进行特征归因分析，结果如图 11—图 12 所示。由图 9 可见，从空间方面进行考虑，历史辐射强度量为影响 SI 的最主要变量，时间相关特征（时日周月）、太阳高度角相关信息（日出和日落时刻）、云层覆盖等级、辐射时长、温度与露点温度也对 SI 有着明显影响。




图 9 测试集特征归因分析
Fig.9 Attribution analysis of features of test sets




图 10 测试集时间步归因分析
Fig.10 Attribution analysis of time steps of test sets

SI 受历史辐射的影响，这符合人们的常规认知。本文对于 SI 的预测，是以小时为时间尺度，代表了一个累积的能量，而不是瞬态强度，因此太阳辐射强度的预测是与辐射时长强相关的。由于地球在一年中不同时间处于轨道的不同位置，某个固定地方的一年中 SI 也是不同的，因此 SI 与时间息息相关^[33]。文献[34]中以云量与辐射时长等气象指数作为分类系统，研究证明不同云层覆盖等级能够影响太阳的辐射强度。有学者研究证明 SI 与日极端温度即最高温度与最低温度之差，存在着某种有用的关系^[35]。露点温度一般受温度与相对湿度的影响，但是在很大程度上露点温度取决于温度，而不是相对湿度，因此本实验中湿度的影响很小^[36]。同时，本实验中的水蒸气压与降雨量的影响因素很小，但是文献[37]研究证明降雨量与云量、SI 都有着密切关系，文献[22]中以图神经网络作为研究方法，水蒸气压与降雨量都为 SI 的一阶邻点。因此推测模型对水蒸气压与降雨量的误判是本文模型出现误差的原因之一。

由图 10 可见，从时间方面考虑，以未来 1 h 为起点，从距离最近的第 24 h 到距离最远的第 1 h 呈

现递减趋势，符合人们的常规认知。但是第 23 h 的影响因素呈现一个急剧下降的趋势，这可能也是本文模型出现误差的原因之一。

由图 11 可见，8 月 7 日 2 个时间点最大影响因素仍为历史辐射量，与前述分析相同。11:00 SI 与历史辐射量呈现正相关，这是因为在当日白天辐射量具有较大数值，进行归一化后都为正值，并且根据图 10 分析 SI 受到距离最近的几个时间步影响最大，而此时几个辐射量都为较大正值，因此在 11:00 呈现正相关，同理在 00:00 呈现负相关。由于辐射时长在 11:00 的近几个时间步都为 1 h，因此辐射时间的影响程度增大。在 00:00，目前所处时数的影响因素激增，这是因为夜间时辐射强度为 0，不随时间中其他 3 个因素（日、周、月）而发生改变。

由图 12 可见，12 月 7 日 2 个时间点历史辐射量仍保持较大影响比例。12 月 7 日 00:00 与 8 月 7 日 00:00 基本为相同趋势，原因同前所述。在 12:00，由于当日整体 SI 很小，且云层覆盖较高，历史辐射量、日照时长等归一化后为负值，因此呈现负相关。




图 11 8 月 7 日特征归因分析
Fig.11 Attribution analysis of the characteristics on August 7

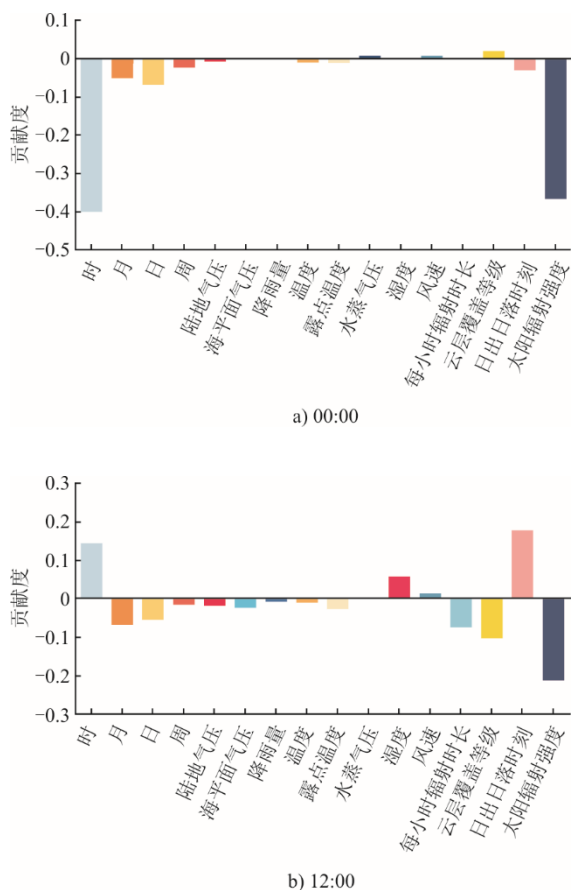


图 12 12 月 9 日特征归因分析

Fig.12 Attribution analysis of the characteristics on December 9

5 结 论

本文构建了基于 LSTM 神经网络为核心的模型，对太阳辐射强度进行了预测，并采用 LRP 算法从时间与空间 2 个方面对于模型进行了可解释性分析，并得到以下结论。

1) 相较于传统的深度神经网络模型，本文所用模型结构性能提高了 8.07%，且具有更优的离群点处理能力。

2) 本文提出的基于 LRP 算法来提高 SI 预测模型可解释性的方法，具有简洁的网络结构以及更少的计算量。

3) 本文模型具良好的可解释性，通过可解释性分析可知历史辐射强度为影响因素最大的因子，时间相关特征（时日周月）、太阳高度角相关信息（日出和日落时刻）、云层覆盖等级、辐射时长、温度与露点温度也具有一定影响。

4) 模型对于水蒸气压、降雨量以及某些时间步的误判，可能是造成模型出现误差的原因。

[参 考 文 献]

- [1] ACIKGOZ H. A novel approach based on integration of convolutional neural networks and deep feature selection for short-term solar radiation forecasting[J]. Applied Energy, 2022, 305: 117912.
- [2] NARVAEZ G, GIRALDO L F, BRESSAN M, et al. Machine learning for site-adaptation and solar radiation forecasting[J]. Renewable Energy, 2021, 167: 333-342.
- [3] ESPINOSA A R, BRESSAN M, GIRALDO L F. Failure signature classification in solar photovoltaic plants using RGB images and convolutional neural networks[J]. Renewable Energy, 2020, 162: 249-256.
- [4] GAO B, HUANG X, SHI J, et al. Hourly forecasting of solar irradiance based on CEEMDAN and multi-strategy CNN-LSTM neural networks[J]. Renewable Energy, 2020, 162: 1665-1683.
- [5] ZHOU Y, LIU Y, WANG D, et al. A review on global solar radiation prediction with machine learning models in a comprehensive perspective[J]. Energy Conversion and Management, 2021, 235: 113960.
- [6] KHATIB T, MOHAMED A, MAHMOUD M, et al. Modeling of daily solar energy on a horizontal surface for five main sites in Malaysia[J]. International Journal of Green Energy, 2011, 8(8): 795-819.
- [7] BAMISILE O, OLUWASANMI A, EJIYI C, et al. Comparison of machine learning and deep learning algorithms for hourly global/diffuse solar radiation predictions[J]. International Journal of Energy Research, 2022, 46(8): 10052-10073.
- [8] BEHRANG M A, ASSAREH E, GHANBARZADEH A, et al. The potential of different artificial neural network (ANN) techniques in daily global solar radiation modeling based on meteorological data[J]. Solar Energy, 2010, 84(8): 1468-1480.
- [9] CAO J C, CAO S H. Study of forecasting solar irradiance using neural networks with preprocessing sample data by wavelet analysis[J]. Energy, 2006, 31(15): 3435-3445.
- [10] AHMAD A, ANDERSON T N, LIE T T. Hourly global solar irradiation forecasting for New Zealand[J]. Solar Energy, 2015, 122: 1398-1408.
- [11] SHARMA V, YANG D, WALSH W, et al. Short term solar irradiance forecasting using a mixed wavelet neural network[J]. Renewable Energy, 2016, 90: 481-492.
- [12] PANG Z, NIU F, O'NEILL Z. Solar radiation prediction using recurrent neural network and artificial neural network: a case study with comparisons[J]. Renewable Energy, 2020, 156: 279-289.
- [13] ASLAM M, SEUNG K H, LEE S J, et al. Long-term solar radiation forecasting using a deep learning approach-GRUs[C]//2019 IEEE 8th International Conference on Advanced Power System Automation and Protection (APAP). IEEE, 2019: 917-920.
- [14] SRIVASTAVA S, LESSMANN S. A comparative study of LSTM neural networks in forecasting day-ahead global horizontal irradiance with satellite data[J]. Solar Energy, 2018, 162: 232-247.
- [15] OBIORA C N, ALI A, HASAN A N. Forecasting hourly solar irradiance using long short-term memory (LSTM) network[C]//2020 11th International Renewable Energy Congress (IREC). IEEE, 2020: 1-6.
- [16] GUNNARSSON B R, VANDEN BROUCKE S, BAESENS B, et al. Deep learning for credit scoring: do or don't?[J]. European Journal of Operational Research,

- 2021, 295(1): 292-305.
- [17] MIGNAN A, BROCCARDO M. Neural network applications in earthquake prediction (1994—2019): Meta-analytic and statistical insights on their limitations[J]. *Seismological Research Letters*, 2020, 91(4): 2330-2342.
- [18] SHAMSHIRBAND S, FATHI M, DEHZANGI A, et al. A review on deep learning approaches in healthcare systems: Taxonomies, challenges, and open issues[J]. *Journal of Biomedical Informatics*, 2021, 113: 103627.
- [19] DAS A, RAD P. Opportunities and challenges in explainable artificial intelligence (XAI): a survey[J/OL]. arXiv:2006.11371, 2020: 1-22. <https://doi.org/10.48550/arXiv.2006.11371>
- [20] LI A, XIAO F, ZHANG C, et al. Attention-based interpretable neural network for building cooling load prediction[J]. *Applied Energy*, 2021, 299: 117238.
- [21] LÓPEZ SANTOS M, GARCÍA-SANTIAGO X, ECHEVARRÍA CAMARERO F, et al. Application of temporal fusion transformer for day-ahead PV power forecasting[J]. *Energies*, 2022, 15(14): 5232.
- [22] GAO Y, MIYATA S, AKASHI Y. Interpretable deep learning models for hourly solar radiation prediction based on graph neural network and attention[J]. *Applied Energy*, 2022, 321: 119288.
- [23] GAO Y, MIYATA S, MATSUNAMI Y, et al. Spatio-temporal interpretable neural network for solar irradiation prediction using transformer[J]. *Energy and Buildings*, 2023, 297: 113461.
- [24] BACH S, BINDER A, MONTAVON G, et al. On pixel-wise explanations for non-linear classifier decisions by layer-wise relevance propagation[J]. *PloS One*, 2015, 10(7): e0130140.
- [25] YANG Y, TRESP V, WUNDERLE M, et al. Explaining therapy predictions with layer-wise relevance propagation in neural networks[C]//2018 IEEE International Conference on Healthcare Informatics (ICHI). IEEE, 2018: 152-162.
- [26] GREZMAK J, ZHANG J, WANG P, et al. Interpretable convolutional neural network through layer-wise relevance propagation for machine fault diagnosis[J]. *IEEE Sensors Journal*, 2019, 20(6): 3172-3181.
- [27] KIM D, HO C H, PARK I, et al. Untangling the contribution of input parameters to an artificial intelligence PM2.5 forecast model using the layer-wise relevance propagation method[J]. *Atmospheric Environment*, 2022, 276: 119034.
- [28] 王琛, 王颖, 郑涛, 等. 基于 ResNet-LSTM 网络和注意力机制的综合能源系统多元负荷预测[J]. *电工技术学报*, 2022, 37(7): 1789-1799.
WANG Chen, WANG Ying, ZHENG Tao, et al. Multi-energy load forecasting in integrated energy system based on resNet-LSTM network and attention mechanism[J]. *Transactions of China Electrotechnical Society*, 2022, 37(7): 1789-1799.
- [29] CHO K, VAN MERRIËNBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[J/OL]. arXiv preprint arXiv:1406.1078, 2014: 1-10.
- [30] 殷孝睢, 都治良, 邵国策, 等. 基于 GWO-SVR 的风电机组柔性塔架振动建模与仿真分析[J]. *太阳能学报*, 2023, 44(8): 404-411.
YIN Xiaojie, DU Zhiliang, SHAO Guoce, et al. Vibration modeling and simulation analysis of flexible tower of wind turbines based on GWO-SVR[J]. *Acta Energetica Solaris Sinica*, 2023, 44(8): 404-411.
- [31] 雷江龙, 余娟, 向明旭, 等. 基于深度神经网络的数据驱动潮流计算异常误差改进策略[J]. *电力系统自动化*, 2022, 46(1): 76-84.
LEI Jianglong, YU Juan, XIANG Mingxu, et al. Improvement strategy for abnormal error of data-driven power flow calculation based on deep neural network[J]. *Automation of Electric Power Systems*, 2022, 46(1): 76-84.
- [32] CHICCO D, WARRENS M J, JURMAN G. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation[J]. *Peer J Computer Science*, 2021, 7: e623.
- [33] GAO Y, LI P, YANG H, et al. A solar radiation intelligent forecasting framework based on feature selection and multivariable fuzzy time series[J]. *Engineering Applications of Artificial Intelligence*, 2023, 126: 106986.
- [34] CHAKCHAK J, CETIN N S. Investigating the impact of weather parameters selection on the prediction of solar radiation under different genera of cloud cover: a case-study in a subtropical location[J]. *Measurement*, 2021, 176: 109159.
- [35] BRISTOW K L, CAMPBELL G S. On the relationship between incoming solar radiation and daily maximum and minimum temperature[J]. *Agricultural and Forest Meteorology*, 1984, 31(2): 159-166.
- [36] SHRESTHA A K, THAPA A, GAUTAM H. Solar radiation, air temperature, relative humidity, and dew point study: Damak, Jhapa, Nepal[J]. *International Journal of Photoenergy*, 2019, 2019: 1-7.
- [37] MEDVIGY D, BEAULIEU C. Trends in daily solar radiation and precipitation coefficients of variation since 1984[J]. *Journal of Climate*, 2012, 25(4): 1330-1339.

(责任编辑 杜亚勤)