

doi: 10.7690/bgzd.2025.05.021

基于时域卷积融合注意力机制的光伏功率预测方法

沈炳华, 曾 智, 陈清泉, 黎晓锋, 杨 帆, 牛 浩

(广东电网有限责任公司韶关乐昌供电局, 广东 韶关 523008)

摘要: 针对偏远地区军事系统光伏功率数据的复杂性以及现有光伏预测模型的精度低问题, 提出一种基于时域卷积融合注意力机制的光伏功率预测方法。首先, 利用皮尔逊相关系数识别主要变量作为输入序列, 通过模糊 C 均值算法 (fuzzy C-means, FCM) 相似日聚类将光伏功率数据划分为平稳、波动、突变 3 种类型以提高预测模型精确度; 然后, 采用自适应噪声完备集经验模态 (improved complete ensemble empirical mode decomposition with adaptive noise, ICEEMDAN) 分解方法对光伏功率进行分解, 并根据排列熵进行重构。通过时域卷积网络 (temporal convolutional network, TCN) 作为时空特征提取层, 并且嵌入高效通道注意力机制 (efficient channel attention, ECA) 单元增强卷积网络的的特征捕获能力; 最后, 通过双向长短期记忆网络 (bidirectional long short term memory, BiLSTM) 进行预测, 输出功率预测结果。实验结果表明: 所提出的模型具有较高的预测精度, 能有效预测不同功率变化趋势下光伏出力情况。

关键词: 军事系统; 光伏功率预测; 相似日聚类; 时域卷积网络

中图分类号: TM615⁺.2 **文献标志码:** A

Photovoltaic Power Prediction Method Based on Time-domain Convolutional Fusion Attention Mechanism

Shen Binghua, Zeng Zhi, Chen Qingquan, Li Xiaofeng, Yang Fan, Niu Hao

(Shaoguan Lechang Power Supply Bureau, Guangdong Power Grid Co., Ltd., Shaoguan 523008, China)

Abstract: Aiming at the complexity of PV power data of military systems in remote areas and the low accuracy of existing PV prediction models, a PV power prediction method based on time-domain convolution fusion attention mechanism is proposed. Firstly, the main variables identified by Pearson correlation coefficient are used as the input sequence, and the photovoltaic power data are divided into three types of stationary, fluctuating and abrupt by fuzzy C-means (FCM) similar day clustering to improve the accuracy of the prediction model; Then, the improved complete ensemble empirical mode decomposition with adaptive noise (ICEEMDAN) decomposition method is used to decompose the photovoltaic power. And reconstruct according to that permutation entropy. A temporal convolutional network (TCN) is used as a spatio-temporal feature extraction layer, and an efficient channel attention (ECA) mechanism unit is embedded to enhance the feature capture capability of the convolutional network; Finally, a bidirectional long short term memory (BiLSTM) network is used to predict the output power. The experimental results show that the proposed model has high prediction accuracy and can effectively predict the PV output under different power variation trends.

Keywords: military systems; photovoltaic power prediction; similar day clustering; temporal convolutional network

0 引言

随着全球对清洁能源需求的不断增长, 光伏发电作为一种可持续、环保且具有成本效益的能源形式, 已经成为能源转型的重要组成部分^[1-4]。光伏发电的功率输出受到气象条件、日照时间等因素的影响, 表现出较强的间歇性和波动性^[5-8]。对于偏远地区的军事系统而言, 在缺乏稳定能源供应的环境下, 光伏发电常常作为一种重要的分布式能源被广泛应用于军事基地、远程哨所和野战阵地。由于气象的不确定性和环境的复杂性, 光伏发电的波动性对军

事设施的电力供应构成了潜在风险; 因此, 精准的光伏功率预测技术对于保障这些区域的能源安全、支撑军事行动的持续性以及确保作战设备的正常运行至关重要^[9-10]。

深度学习方法是当前光伏功率预测研究的主流, 通过对太阳辐射、气象数据等输入信息的分析, 预测未来一段时间内光伏设备的发电能力。文献[11]提出气象数据对光伏发电的影响显著, 通过将这些数据与太阳辐射的变化规律结合, 能够有效提高短期预测的精度。文献[12]通过长短期记忆神经网络

收稿日期: 2024-08-12; 修回日期: 2024-09-02

基金项目: 广东电网有限公司科技项目 (030200KK52222038)

第一作者: 沈炳华(1980—), 男, 广东人, 硕士。

预测模型进行光伏功率预测。文献[13]提出将相似日选择方法与深度学习模型进行融合，可以有效提高短期预测精度。文献[14]提出了一种基于隐私保护导向与深度联邦学习的分布式光伏超短期功率预测，通过挖掘功率时序特征，提升功率预测精度。文献[15]提出用残差量化气象突变构造为一种新特征，构建面向光伏功率预测的残差深度学习模型，在气象突变下，该模型能取得更高的精确度。

光伏功率数据固有的强不确定性导致单一预测模型预测精度不高。文献[16]通过自适应噪声完备集合经验模态分解、样本熵和变分模态分解对光伏功率数据进行处理，得到较为平稳的本征模函数分量将各分量预测结果叠加得到短期光伏功率预测结果，有效提高短期光伏功率预测精度。文献[17]采用自适应噪声完备集合经验模态分解对关键气象因素和功率进行二次分解，优化卷积神经网络和双向长短期记忆网络的超参数，提高调参效率可以更好地捕捉光伏发电的时序性特征，从而提升预测精度。上述模型难以同时处理多尺度的非线性变化特征。不同的 IMF 包含不同频率和幅值的信号特性，而上述模型通常只能对某一类型的特征进行有效捕捉。每个 IMF 的预测误差会被叠加至最终结果中。当 IMF 数量较多时，上述模型难以适应所有 IMF 特性，导致误差不断累积，显著影响整体预测精度。

针对上述问题，笔者提出一种基于时域卷积融合注意力机制的光伏功率预测方法。与现有研究进行了对比分析，验证了该方法的有效性。

1 数据预处理

1.1 数据处理

为优化特征参数并为模型训练提供高效输入。首先，对采集的光伏功率原始数据进行清洗，包括异常值检测与剔除、采用插值法填补缺失值；其次，针对多维气象要素利用归一化消除特征量纲的影响；最后，通过相关性分析提取关键特征，剔除冗余变量，进一步优化模型输入。

1.2 数据聚类

基于模糊 C 均值算法 (FCM) 的相似日聚类是一种基于目标函数的模糊聚类算法，相对于硬聚类算法，FCM 更注重样本的隶属度而不是简单的二元分类标准，因此具有更高的灵活性和精度。通过对原始时间序列数据进行预处理，从数据中提取代表性特征，以形成聚类的输入特征集。在聚类过程中初

始化隶属度矩阵和聚类中心，迭代更新每个数据点与各聚类中心的隶属度及聚类中心位置，直至满足收敛条件。聚类中心和隶属度矩阵的更新如式(1)和(2)所示：

$$v_j = \frac{\sum_{i=1}^N u_{ij}^m x_i}{\sum_{i=1}^N u_{ij}^m}; \quad (1)$$

$$u_{ij} = 1 / \sum_{k=1}^C \left(\|x_i - v_j\| / \|x_i - v_k\| \right)^{2/(m-1)}. \quad (2)$$

式中： N 为数据点的个数； C 为聚类的类别数； u_{ij} 为数据点 x_i 属于第 j 个隶属度； v_j 为第 j 个聚类中心； m 为模糊度指数。

2 组合预测模型

2.1 ICEEMDAN

经验模态分解 (empirical mode decomposition, EMD) 适合分解具有高度随机性的非平稳信号，可以将原始信号分解成一系列模态分量 (intrinsic mode functions, IMF)。模态分量具有非平稳信号的局部特征。改进的自适应噪声完备集合经验模态分解 (ICEEMDAN) 通过引入均值为 0、方差为 1 的特定白噪声，对每组带噪信号进行经验模态分解，从所有 IMF 中选择与原始信号相关的分量，进行重构，得到信号的主要成分，从而降低噪声干扰、模式混叠和重构信号失真影响，实现对原始信号的有效分解和重构。ICEEMDAN 的分解方法如下：

在原始信号 $x(t)$ 加入白噪声 $E_1[\omega_i(t)]$ ，得到加噪信号 $x_i(t)$ ：

$$x_i(t) = x(t) + \beta_0 \cdot E_1[\omega_i(t)]. \quad (3)$$

式中： β_0 为高斯白噪声的初始振幅； $\omega_i(t)$ 为第 i 次添加的白噪声。

使用 ICEEMAN 对原始信号进行分解，得到第一个模态分量和残差分量：

$$\left. \begin{aligned} r_1(t) &= \frac{1}{I} \sum_{i=1}^I M[x_i(t)] \\ \tilde{C}_1 &= x(t) - r_1(t) \end{aligned} \right\}. \quad (4)$$

式中： $r_1(t)$ 为一阶残差分量； $\tilde{C}_1$ 为一阶模态分量。

计算第 $(k+1)$ 个模态分量以及对应的残差，直到残差信号变为单调函数无法进一步分解：

$$\left. \begin{aligned} r_{k+1}(t) &= \frac{1}{I} \sum_{i=1}^I M[r_k(t) + \beta_k E_k(\omega_i(t))] \\ \tilde{C}_{k+1} &= r_k(t) - r_{k+1}(t) \end{aligned} \right\}. \quad (5)$$

式中： $r_{k+1}(t)$ 为第 $(k+1)$ 阶残差分量； $\tilde{C}_{k+1}$ 为第 $(k+1)$

阶模态分量。

2.2 预测模型

2.2.1 时域卷积网络

时域卷积网络 (TCN) 通过使用相同输入和输出长度的膨胀卷积层和因果卷积层, 以提取时间序列的时序特征。因果卷积确保输出仅依赖当前及之前的时间步, 保持因果性。膨胀卷积通过指数扩展的感受野捕获长时间依赖关系, 每层卷积结合零填充策略, 确保序列长度一致。假设卷积核为 $K=(k_1, k_2, \dots, k_m)$ 对于输出 $y=(y_1, y_2, \dots, y_n)$ 仅取决于当前输入序列 $x=(x_1, x_2, \dots, x_n)$ 。同时, 通过膨胀卷积获取数据中长时间依赖关系, 通过膨胀系数减少相邻层之间卷积神经元的数量, 序列中的素 s 的膨胀卷积定义为:

$$F(s) = \sum_{i=1}^m f(i) \cdot x_{s-d \cdot i} \quad (6)$$

式中 d 为膨胀因子。

TCN 由多个模块组成, 以层叠的方式构建高效的时间序列建模框架。残差块通过残差连接、归一化、ReLU 模块和 Dropout 模块, 增强网络的深度学

习能力并防止过拟合。多个卷积层以递进方式堆叠形成网络主体, 最终通过任务特定的输出层生成预测结果。

2.2.2 ECA 注意力机制

高效通道注意力机制 (ECA) 通过避免输入特征降维和降低全通道依赖建模的计算复杂度, 显著提升了卷积块的性能。通过引入轻量化的 1 维卷积, 根据通道数自适应地计算 1 维卷积的核大小 k 进行局部信息交互, 从而捕获关键的跨通道依赖性, k 的计算:

$$k = \lfloor \log_2(c) / \gamma + b / \gamma \rfloor_{\text{odd}} \quad (7)$$

式中: c 为输入特征通道数; $\gamma=2$; $b=1$ 。

得到核大小 k 后, ECA 模块将 1 维卷积应用于输入特征上, 从而学习每个通道相对于其他通道的重要性。过程通过以下公式表示:

$$\text{OUT} = \text{Conv1D}_k(\text{IN}) \quad (8)$$

式中 Conv1D_k 为 1 维卷积操作。

笔者针对暂态数据的时序特征, 采用 TCN 对其进行充分提取, 以保证模型评估性能。基于 TCN-ECA 的时间卷积网络结构如图 1 所示。




图 1 基于 TCN-ECA 的时间卷积网络结构

2.2.3 双向长短期记忆网络

双向长短期记忆网络 (BiLSTM) 是一种改进的长短期记忆网络, 能够同时捕捉序列数据的前向和后向信息。长短期记忆网络 (long short term memory, LSTM) 本身是一种特殊的递归神经网络, 通过引入门控机制来解决传统递归神经网络在长序列学习中的梯度消失和爆炸问题。

LSTM 的模型结构如图 2 所示, 通过精细的门控机制, 有效提升了处理长序列数据的能力。




图 2 LSTM 模型结构

LSTM 的遗忘门用于选择性地决定当前时刻对先前记忆的保留或丢弃程度。通过可训练的权值矩阵和偏置项对当前输入与先前的隐状态进行线性变换，Sigmoid 函数将结果映射到 0~1 之间的范围。

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)。$$
 (9)

式中： f_t 为遗忘门的输出； σ 为 Sigmoid 激活函数； W_f 和 b_f 分别为权值矩阵和偏置项； h_{t-1} 为上一时刻的隐状态； x_t 为当前时刻的输入。

输入门控制记忆单元的信息更新过程，主要包括候选记忆生成与输入门权重计算。候选记忆表示当前输入和上一时刻隐状态经过线性变换和非线性激活函数后的结果。

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c)。$$
 (10)

式中： W_c 和 b_c 分别为候选记忆的权值矩阵和偏置项； $\tanh$ 为双曲正切激活函数。

输入门通过 Sigmoid 激活函数计算权重，用于控制候选记忆被引入单元状态的程度。

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)。$$
 (11)

式中 W_i 和 b_i 分别为输入门的权值矩阵和偏置项。

输入门将候选记忆与输入权重结合，对单元状态进行部分更新：

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t。$$
 (12)

LSTM 的最终输出由输出门和单元状态共同决定，可以表示为：

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)；$$
 (13)

$$h_t = o_t \cdot \tanh(C_t)。$$
 (14)

式中 W_o 和 b_o 分别为输出门的权值矩阵和偏置项。

在处理序列问题时，传统的 LSTM 模型侧重于历史信息。然而，BiLSTM 能够同时从时间序列的正向和反向信息中提取特征，从而更全面地捕获关系。BiLSTM 模型结构如图 3 所示。




图 3 BiLSTM 模型结构

由图 3 可知：相比传统单向 LSTM，BiLSTM 可以更好地理解序列间的动态变化，结合全局信息对未来状态做出更准确的预测；因此，它在光伏预测中具有更高的准确性和稳定性，尤其适用于需要

结合多时刻特征的复杂场景。

笔者提出的基于 ICEEMDAN 和 TCN-ECA-BiLSTM 军事系统光伏功率预测模型流程如图 4 所示。首先，利用 FCM 算法充分挖掘多源气象环境数据，将初始数据集以不同波动类型进行聚类；然后，以按照波动类型分类的数据集作为输入，对 TCN-ECA-BiLSTM 模型进行训练；最后，将按照天气类型分类的光伏发电数据和预测日的多元气象因子输入到训练好的模型中进行预测。




图 4 基于 ICEEMDAN 和 TCN-ECA-BiLSTM 光伏功率预测流程

3 算例仿真


3.1 数据处理

笔者采用浙江某地的一个月內光伏发电数据集作为实验数据。该数据集以 5 min 为时间段连续采集，每天采集 288 个数据点，共采集 8 640 个数据点。

本文中的数据集，不同的特征变量与光伏实际功率之间存在某种线性关系，可用皮尔森相关系数来衡量不同特征变量与光伏实际功率之间的相关程度。皮尔逊相关系数如表 1 所示，强相关因素与光伏功率关系如图 5 所示。

表 1 皮尔逊相关系数 kW

气象因素	光伏功率	气象因素	光伏功率
气温	0.589 5	风速	0.127 4
相对湿度	-0.477 2	降雨	-0.081 8
水平辐射	0.994 8	倾斜辐射	0.993 0






图 5 强相关气象因素与光伏功率关系

通过计算皮尔逊相关系数,从表中数据可以看出:光伏功率与倾斜辐射和水平辐射的相关性最强,相关系数分别为 0.993 0 和 0.994 8,表明辐射强度对光伏功率具有显著影响。气温与光伏功率的相关系数为 0.589 5,说明这 3 个特征变量都会对实际功率产生较大的影响。其他因素如风向和降雨与光伏功率的相关性较弱,对实际功率的影响可忽略不计。

3.2 数据聚类

图 6 为 FCM 聚类后的结果。





图 6 FCM 聚类结果

由图 6 可知:平稳、波动和突变类型下的光伏功率表现差异显著。平稳功率曲线呈现平滑的钟形变化;波动功率类型下,云层的间歇性遮挡使得光照强度波动较大,光伏功率输出受到显著影响,但整体输出通常低于平稳类型水平;突变类型中,由于光照强度显著降低且以散射光为主,光伏功率输出显著减少,功率曲线表现出较强的波动性,整体输出接近系统最低水平。

3.3 ICEEMDAN 数据分解以及重构

以平稳类型为例,分解后的平稳类型光伏功率数据如图 7 所示。






图 7 ICEEMDAN 分解结果

为减小后续计算量，引入了排列熵的概念。各序列重构结果如表 2 所示。

表 2 各序列重构结果

分量	IMF1	IMF2	IMF3	IMF4	IMF5
PE	0.992	0.871	0.759	0.614	0.429
分量	IMF6	IMF7	IMF8	IMF9	IMF10
PE	0.417	0.409	0.397	0.381	0.328

由表 2 可知：根据 PE 的相似性，IMF1~4 熵值大于 0.6，重构为高频项；IMF5~10 熵值小于 0.6；重构为低频项。

重构信号如图 8 所示：高频分量主要反映由短期天气波动干扰引起的快速变化部分；低频分量则揭示了光伏功率随时间的主要变化趋势，体现了光伏发电的中期动态特征；残差分量表示光伏功率的长期趋势。这种分解不仅可以区分信号中的干扰和本质特性，而且能提高系统运行的稳定性和效率。




图 8 各序列数据重构

3.4 实验结果与分析

为验证该模型各模块的有效性，分别在 RMSE、MAE 和 R^2 这 3 种评价指标上进行详细比较。同时，引入 ICEEMDAN-TCN-ECA-BiLSTM(L1)、未进行相似日聚类 ICEEMDAN-TCN-ECA-

BiLSTM(L2)、ICEEMDAN-TCN-BiLSTM(L3)、TCN-BiLSTM(L4)、BiLSTM(L5)、LSTM(L6)，以评估它们对光伏功率数据预测的分解和预测效果，图 9(a)~(c)分别为平稳、波动、突变情况下各类算法光伏功率预测结果。不同模块预测模型的误差对比如表 3 所示。




图 9 各类算法的预测结果

从图 9 中可以看出：对数据进行有效分类，构造合理可信的训练集，可以有效地提高模型的预测精度；ICEEMDAN 分解能力强，能够有效提取数据的多尺度特征；BiLSTM 通过双向传递信息，提高了对时序数据的建模能力。TCN 网络能够更好地捕捉长时序的依赖关系，同时，ECA 模块进一步提升了模型对特征选择的精度。

由表 3 可知：在所有类型中，L1 算法的表现均显著优于其他模型，尤其在平稳功率类型中，L1 模型的 R^2 值达到 0.999 8，几乎接近完美的拟合，MAE 为 0.344 8，RMSE 为 0.697 2，均为所有模型中最低，表明该模型的预测误差极小，能够精确捕捉数据中

的规律性。相比之下，其他模型的表现逊色。

表 3 不同模块预测模型的误差对比

类型	预测算法	MAE	RMSE	R^2
平稳	L1	0.344 8	0.697 2	0.999 8
	L2	1.227 7	2.081 8	0.998 5
	L3	0.545 1	2.435 2	0.997 9
	L4	2.448 1	3.742 2	0.995 0
	L5	4.012 8	5.777 5	0.988 1
	L6	4.055 5	5.840 4	0.987 9
波动	L1	2.859 0	4.955 8	0.970 60
	L2	2.987 5	5.176 1	0.967 90
	L3	3.471 5	5.975 4	0.957 30
	L4	4.790 5	6.453 2	0.950 17
	L5	8.572 0	15.808 8	0.886 31
	L6	9.747 5	14.508 8	0.748 11
突变	L1	0.643 20	1.071 8	0.989 38
	L2	0.661 16	1.142 6	0.987 93
	L3	0.952 80	1.327 7	0.983 70
	L4	2.851 40	3.378 8	0.894 43
	L5	4.493 20	4.750 2	0.791 32
	L6	7.235 30	10.493 7	0.663 21

虽然在波动和突变等复杂功率类型中，所有模型的预测能力普遍下降，但 L1 模型依然保持了较为优越的表现，其 R^2 值明显高于其他模型，且预测误差较小。这表明笔者所提模型在各种气象条件下具有明显的优势。

4 结论

针对偏远地区军事系统光伏功率数据的复杂性及现有模型精度不足的问题，笔者提出一种基于时域卷积融合注意力机制的光伏功率预测方法。实验结果表明：与基准模型相比，该方法在不同功率类型下的预测精度显著提升，能够有效应对不同功率类型下的光伏功率预测问题，为偏远地区军事系统的光伏发电管理提供可靠支持。

参考文献：

[1] 赵佳蕊, 王玲芝, 李晨阳. 基于 LEA-LSTM 的光伏发电功率短期预测方法[J]. 电力信息与通信技术, 2024, 22(11): 34-42.

[2] 高明宇, 刘金宁, 冯长江. 军用独立型光储柴微电网模式转换控制策略[J]. 兵工自动化, 2021, 40(6): 1-7.

[3] 陈君, 唐秀明, 苏宇生. 一种基于多目标优化的独立微电网容量配置方法[J]. 兵工自动化, 2024, 43(9): 66-72, 96.

[4] 田江, 吕洋, 赵奇, 等. 基于粗糙熵加权密度的电网调控系统异常检测[J]. 兵工自动化, 2024, 43(2): 40-44.

[5] 颜培杰, 储飞黄, 王梦阳. 基于“电磁陷阱”的自适应卫星通信干扰策略[J]. 兵工自动化, 2024, 43(4): 33-39.

[6] 秦晓珊, 李博骁, 赵会朋, 等. 太空目标光电监视装备

探测精度评估方法[J]. 兵工自动化, 2023, 42(9): 41-44.

[7] 魏伟, 余鹤, 叶利, 等. 基于 FCM-SENet-TCN 的低压台区光伏超短期功率预测方法[J/OL]. 中国电力, 1-10[2024-11-08]. https://kns.cnki.net/kcms2/article/abstract?v=LzEBRIJt2Q3Q0hEfex3Fw0uJcCy71CjCvHtE nsMnerKs81t9XZy3dpfLrwxCTM52v3quRRxBUBCNtE 9PiIdib_ic6P23p_Oz-9M0sBfxNvePxnqHODqPnUupNla anDGaOhtXh_T2zwwvdARPzfHJP-22xLy9z-630deXgY a2KbTdhPr0801VcH4Wwo7W_5wP&uniplatform=NZK PT&language=CHS.

[8] 汪繁荣, 梅涛, 卢璐. 基于相似日聚类 and VMD-LTWDBO-BiLSTM 的短期光伏功率预测[J]. 智慧力, 2024, 52(10): 56-63, 111.

[9] 王世青, 赵许许, 廖俊龙, 等. 基于变分模态分解的光伏功率预测方法[J]. 国外电子测量技术, 2024, 43(9): 41-49.

[10] 张严, 王亚君, 余佳琪. 基于神经网络-自适应模糊的光伏 MPPT 算法[J]. 国外电子测量技术, 2022, 41(4): 62-69.

[11] 袁俊球, 王迪, 谢小锋, 等. 基于广义天气分类的 ICEEMDAN-LSTM 网络光伏发电功率短期预测[J]. 综合智慧能源, 2024, 46(9): 53-60.

[12] 彭曙蓉, 陈慧霞, 孙万通, 等. 基于改进 LSTM 的光伏发电功率预测方法研究[J]. 太阳能学报, 2024, 45(11): 296-302.

[13] 刘源延, 孔小兵, 马乐乐, 等. 基于小波包变换与深度学习的超短期光伏功率预测[J]. 太阳能学报, 2024, 45(5): 537-546.

[14] 于骥, 王玉庆, 甄钊, 等. 基于隐私保护导向与深度联邦学习的分布式光伏超短期功率预测[J/OL]. 南方电网技术, 1-12[2024-12-10]. https://kns.cnki.net/kcms2/article/abstract?v=LzEBRIJt2Q2r-c0lMBiCpBvUFUSops 78F_hopzpk-Vldhe9oe7q4_zjEOlCv427RLH8sl9Ym24y_ 7C5JSQt60b38OeDNUnfJHU6pcPVH7B61znRBTzR0-V c4tDLuhbWgXKW6cgTKR7Uk89kdvl5pm6zZgO-7aq_h PsZafU0nmOIa-FiR7wP79AiZWY8gJ4b4&uniplatform=NZKPT&language=CHS.

[15] 干逸飞, 吕品, 郑树泉. 面向光伏功率预测的残差深度学习模型[J]. 计算机应用与软件, 2024, 41(11): 101-107.

[16] 吉兴全, 赵国航, 叶平峰, 等. 基于 QMD-HBi GRU 的短期光伏功率预测方法[J]. 高电压技术, 2024, 50(9): 3850-3859.

[17] 王德文, 焦天媛. 基于二次分解的不同太阳辐射下光伏功率预测[J]. 太阳能学报, 2024, 45(9): 360-368.