

引用格式:李庆生,张裕,龙家焕,等.基于IMFO-LSTM模型的光伏功率预测研究[J].电力科学与技术学报,2024,39(3):199-206.

Citation: LI Qingsheng, ZHANG Yu, LONG Jiahuan, et al. Photovoltaic power prediction based on improved IMFO-LSTM[J]. Journal of Electric Power Science and Technology, 2024, 39(3): 199-206.

# 基于 IMFO-LSTM 模型的光伏功率预测研究

李庆生<sup>1</sup>, 张裕<sup>1</sup>, 龙家焕<sup>1</sup>, 白浩<sup>2</sup>, 胡蓉<sup>2</sup>, 李巍<sup>2</sup>

(1. 贵州电网有限责任公司电网规划研究中心, 贵州 贵阳 550000; 2. 南方电网科学研究院有限责任公司, 广东 广州 510663)

**摘要:**随着光伏发电大容量接入电网,为降低光伏发电输出的随机性,提出一种基于改进飞蛾优化(improved moth-flame optimization, IMFO)的长短期记忆网络(long short-term memory, LSTM)进行光伏发电功率预测。首先,通过数据预处理,进行灰色关联度分析,减少输入变量维数,再根据选取的输入变量,通过灰色关联度分析法,进行相似日样本选取;其次,为提高飞蛾算法的性能,对其位置更新公式进行改进;接着,根据IMFO-LSTM的网络层数和学习率,提高其预测精度,降低随机性;最后,基于预处理好的相似日样本,采用优化后的LSTM进行预测。仿真结果表明:该模型的预测精度得到一定提升,满足实际工程要求。

**关键词:**光伏发电;改进飞蛾算法;长短期记忆网络;灰色关联度分析法

**DOI:** 10.19781/j.issn.1673-9140.2024.03.022 **中图分类号:** TM615 **文章编号:** 1673-9140(2024)03-0199-08

## Photovoltaic power prediction based on IMFO-LSTM model

LI Qingsheng<sup>1</sup>, ZHANG Yu<sup>1</sup>, LONG Jiahuan<sup>1</sup>, BAI Hao<sup>2</sup>, HU Rong<sup>2</sup>, LI Wei<sup>2</sup>

(1. Power Grid Planning Research Center of Guizhou Power Grid Co., Ltd., Guiyang 550000, China;

2. Electric Power Research Institute, China Southern Power Grid, Guangzhou 510663, China)

**Abstract:** With the large capacity of photovoltaic power generation connected to the grid, in order to reduce the randomness of photovoltaic power generation output, a long short-term memory (LSTM) based on an improved moth-flame optimization (IMFO) algorithm is proposed to predict photovoltaic power generation power. Firstly, through data preprocessing, grey relational analysis is conducted to reduce the dimensionality of input variables. Then, based on the selected input variables, similar-day sample selection is performed using the grey relational analysis method. Secondly, the position update formula are improved to enhance the performance of the moth algorithm. Then, the improved moth algorithm is used in the optimization of the number of network layers and learning rate of the LSTM to improve its prediction accuracy and reduce randomness. Finally, based on the pre-processed samples of similar days, the optimized LSTM is adopted for power prediction. Simulation results show that the prediction accuracy of the model has been improved to a certain extent, which meets the actual engineering requirements.

**Key words:** photovoltaic power generation; improved moth-flame optimization algorithm; long short-term memory; grey relational analysis method

近年来,全球消耗不可再生能源的速度日益加快,全世界范围内的不可再生能源储备逐渐减少,因此研究人员开始探索可再生能源的应用。广大研究者因光伏发电具有绿色环保、可再生两大优

势,而对其倍加青睐。目前,随着光伏电站大规模接入电力系统,光伏发电输出功率的波动性以及随机性使得电力系统的安全稳定运行受到了一定影响<sup>[1-3]</sup>。为解决这一影响,需要对光伏功率进行预

收稿日期:2022-06-30;修回日期:2024-06-24

基金项目:南方电网科技项目(GZKJXM20200776)

通信简介:李庆生(1971—),男,高级工程师,主要从事新型电力系统规划、分布式电源研究;E-mail:liqingsheng@gz.csg.cn

测,以此保证光伏发电的稳定输出。光伏预测的精度对于电力系统网络运行的安全性与稳定性有着相当重要的意义<sup>[4-13]</sup>。

对光伏发电功率预测的方法主要分为物理建模方法以及数据驱动统计方法<sup>[14-15]</sup>。物理建模方法的优点在于:能够直接对场地信息与组件参数进行分析,建立运行方程以及传递方程。但该方法在复杂天气情况下的预测精度会受到干扰从而无法达到要求。数据驱动统计方法则通常采用神经网络、支持向量机、极限学习机等智能方法,对光伏功率与气象因素之间的关系进行深度挖掘。

深度学习的高速发展为光伏发电功率预测带来了更好的发展前景<sup>[14]</sup>。研究表明,对于处理复杂非线性的预测模型,深度学习相关的各类预测算法优于传统智能预测算法<sup>[16]</sup>。此外,其预测精度也高于传统智能预测算法的精度。文献[17]通过计算出光伏功率与天气因素之间的互信息熵,实现对气象数据的降维处理,以长短期记忆网络(long short-term memory, LSTM)对此数据进行训练预测,最终结果验证了该模型的精度达到预期要求。文献[18]以经验模态分解对环境因素进行分解,降低其不平稳性,再通过主成分分析法提取关键影响因子,降低了模型输入的维度,并结合LSTM进行建模,实现对光伏功率的预测,并且该方法相比于传统方法提升了一定精度。文献[19]用集合经验模态分解对历史数据进行分解,将分解结果分别输入粒子群优化(particle swarm optimization, PSO)-LSTM模型中进行功率预测,并根据仿真算例验证了该模型的精确性优于其他单一模型。文献[20]提出了一种基于变分模态分解(variational mode decomposition, VMD)和双重注意力机制LSTM的短期光伏功率预测模型,通过VMD降低光伏功率的波动性与不稳定性,并通过双重注意力机制避免了传统方法的限制及提高了预测结果的稳定。文献[21]利用生成对抗网络获取与历史日相似度较高的数据样本,并将该样本输入纵横交叉算法优化的LSTM神经网络中进行预测,证明了该方法能够有效提升预测精度。

本文提出一种基于改进飞蛾优化(improved moth-flame optimization, IMFO)-LSTM的光伏发电功率预测模型。首先通过灰色关联度分析,对数据预处理后,计算各个变量的关联系数,选取关联系数最

高的作为输入变量,再通过相似度计算,提取相似日样本数据;接着,为提高预测精度,对位置更新公式进行改进,并以此优化LSTM的相关参数,去除人工调整参数;最后通过优化后的LSTM对光伏发电输出功率进行预测。仿真结果证明,相比于其他的智能算法,IMFO-LSTM的预测精度有了一定的提升。

## 1 提取相似日样本数据

为了提高网络模型的预测精度,首先需要对数据进行预处理、归一化操作;再基于预处理的数据,通过灰色关联度分析对影响光伏发电的各个影响因素进行关联系数计算;最后,结合关联系数,对需要输入模型的相似日样本数据进行提取。

### 1.1 数据预处理

本文选用某光伏电站2018年6月至2020年9月的发电输出功率历史数据。从中抽取144 000组数据进行分析,为降低计算难度,同时提升模型输出的精度,首先对数据进行预处理,归一化转换函数如下:

$$X' = \frac{2[X - 0.5(X_{\max} + X_{\min})]}{X_{\max} - X_{\min}} \quad (1)$$

式中, $X$ 为当前样本数据; $X_{\max}$ 、 $X_{\min}$ 分别为当前样本数据中的最大值与最小值; $X'$ 为经过归一化转换得到的样本数据。

### 1.2 灰色关联度分析

#### 1.2.1 光伏发电影响因素

光伏发电的主要来源为所吸收到的太阳能,而太阳能会因地理位置变化、季节更替以及昼夜交替等因素受到一定影响。对光伏发电影响较大的因素主要有:辐照强度、天气类型、大气温度、大气湿度以及风向风速。

其中,辐照强度作为影响因素,主要是由于太阳辐射随着时间变化而产生变化,光伏发电的输出功率也会随其变化而改变。天气类型作为影响因素则是由于不同天气下的云量、温度等都不同,从而影响光伏发电的输出功率。例如,晴天条件下的光伏发电功率会高于阴天条件下的光伏发电功率。大气温度则同样影响光伏发电的输出性能:

$$P_v = \alpha SI[1 - 0.005(T + 25)] \quad (2)$$

式中, $\alpha$ 为光伏转换效率; $S$ 为光伏发电面积; $I$ 为辐照强度; $T$ 为大气温度。从式(2)可以看出,温度的提升会导致光伏发电的输出功率有所降低。

### 1.2.2 灰色关联度分析法

灰色关联度分析法以受多种因素影响的样本数据为基础,使用灰色关联度对因素之间的关系强弱、大小以及次序进行描述<sup>[22]</sup>。灰色关联度分析法的步骤如下。

1) 对样本数据进行归一化处理。

2) 计算预测日与第*i*日第*k*个影响因素数据之间差值的绝对值 $D_{ik}$ 。

3) 寻找差值绝对值数据集中的最大值与最小值。

4) 按照关联系数公式进行计算:

$$R_i = \frac{\min_i \min_k D_{ik} + 0.5 \max_i \max_k D_{ik}}{D_{ik} + 0.5 \max_i \max_k D_{ik}} \quad (3)$$

5) 对每个影响因素之间关联系数的均值进行计算。关联系数均值越趋近于1,则关联度越高。

输入影响因素包括:辐照强度、大气温度、大气湿度、大气压强、风向以及风速;输出影响因素为光伏发电实际输出功率,计算结果如表1所示。

表1 灰色关联度分析值

Table 1 Gray relational analysis values

影响因素	关联系数均值
辐照强度	0.96
大气温度	0.67
大气湿度	0.41
大气压强	0.03
风向	0.12
风速	0.33

### 1.3 提取相似日样本数据

为降低计算成本,提升模型输出结果的精度,相似日样本数据的分析只选用关联系数均值最高的4个影响因素:辐照强度、大气温度、大气湿度以及风速。

综合求得关联系数均值,将预测日与第*i*日之间的相似度定义为

$$F_i = \prod_{k=1}^n R_i(k) \quad (4)$$

式中,相似度的计算采用关联系数的连乘,以此保证主导因素的作用得到充分体现。

选取相似日的具体步骤如下:

1) 计算关联系数均值 $R_i$ ;

2) 计算相似度 $F_i$ ;

3) 选取相似度最高的前*j*日作为相似日样本数据。

## 2 IMFO-LSTM 模型

为了提高模型预测结果的精度,首先对飞蛾优化(moth-flame optimization, MFO)算法的位置更新公式进行改进,减少其陷入局部最优的情况;再以改进后的算法对LSTM神经网络的部分参数进行优化,降低模型输出的随机性。

### 2.1 飞蛾优化算法

MFO算法于2015年被首次提出,该算法通过模拟飞蛾飞向火焰的过程,对问题的最优解进行计算。在MFO算法中,通常将飞蛾作为候选解,火焰作为当前最优解,飞蛾以对数螺旋曲线为轨迹不断向火焰位置靠近,从而不断更新位置。

飞蛾种群可表示如下:

$$M = \begin{bmatrix} M_{11} & M_{12} & \cdots & M_{1d} \\ M_{21} & M_{22} & \cdots & M_{2d} \\ \vdots & \vdots & \ddots & \vdots \\ M_{n1} & M_{n2} & \cdots & M_{nd} \end{bmatrix} \quad (5)$$

则飞蛾种群的适应度如下:

$$O_M = \begin{bmatrix} O_{M1} \\ O_{M2} \\ \vdots \\ O_{Mn} \end{bmatrix} \quad (6)$$

式(5)、(6)中, $M$ 为飞蛾种群; $O_M$ 为飞蛾种群的自适应度矩阵; $n$ 为飞蛾的总体数目; $d$ 为变量的维数。

每一个飞蛾都对应一个独立的火焰位置,火焰位置可表示如下:

$$F = \begin{bmatrix} F_{11} & F_{12} & \cdots & F_{1d} \\ F_{21} & F_{22} & \cdots & F_{2d} \\ \vdots & \vdots & \ddots & \vdots \\ F_{n1} & F_{n2} & \cdots & F_{nd} \end{bmatrix} \quad (7)$$

式中, $F$ 为火焰的位置矩阵。

火焰对应的适应度则表示如下:

$$O_F = \begin{bmatrix} O_{F1} \\ O_{F2} \\ \vdots \\ O_{Fn} \end{bmatrix} \quad (8)$$

式中, $O_F$ 为火焰适应度矩阵。

MFO算法的求解目标则是获取最优的三元组:

$$f_{\text{MFO}} = (I, P, T) \quad (9)$$

式中, $I$ 为生成随机飞蛾数量及其对应适应度的函数。

$$I: \theta \rightarrow \{M, OM\} \quad (10)$$

MFO算法主函数 $P$ 的作用为驱使飞蛾不断向火焰位置飞行,并接收其位置矩阵 $M$ ,从而生成飞蛾位置更新后的矩阵 $M$ :

$$P: M \rightarrow M \quad (11)$$

判断函数 $T$ 作用为判断MFO算法输出结果是否满足要求,若是则输出True;反之,输出False:

$$T: M \rightarrow \{\text{True}, \text{False}\} \quad (12)$$

算法的运行过程为:由函数 $I$ 不断生成随机的飞蛾种群,飞蛾不断向火焰位置靠近,即求取当前最优解,函数 $P$ 则使飞蛾在迭代过程中更新位置,直至函数 $T$ 输出True为止。其中,飞蛾的位置更新公式为

$$S(M_i, F_j) = |F_j - M_i| \cdot e^{bt} \cdot \cos(2\pi t) + F_j \quad (13)$$

式中, $M_i$ 为第 $i$ 只飞蛾位置; $F_j$ 为第 $j$ 个火焰位置, $|F_j - M_i|$ 表示第 $i$ 只飞蛾位置与第 $j$ 个火焰位置之间的距离大小; $b$ 为一个随机常数; $t$ 为在 $[-1, 1]$ 范围内的随机数,其值大小代表了飞蛾下一个位置与火焰位置之间的接近程度, $t = -1$ 代表距离最远, $t = 1$ 代表距离最近。

为提高MFO算法的收敛速度且避免陷入局部最优,火焰的数量需要进行自适应更新,在算法的迭代过程中,使火焰的数量自适应减少,其表达式如下:

$$f = \text{round}\left(f_{\max} - t \left(\frac{f_{\max} - 1}{T}\right)\right) \quad (14)$$

式中, $f$ 为当前火焰数量; $f_{\max}$ 为火焰的最大数量; $t$ 为当前迭代次数; $T$ 为最大迭代次数。

## 2.2 IMFO算法

飞蛾在寻找火焰的过程中会产生一定的随机情况,对于寻得最优解需要多次迭代,从而导致算法耗时较长。为加快算法的收敛速度,对火焰的数量自适应更新公式进行改进,将原先火焰数量的直线减少变为曲线减少,改进后的火焰自适应更新公式如下:

$$f' = \text{round}\left(\sqrt{\frac{T^2}{t^2 + (T/f_{\max})^2}}\right) \quad (15)$$

如式(15)所示,火焰数量会随着迭代次数的增加而呈现曲线减少,从而提升了火焰数量的收敛速度,进而保证算法整体的收敛速度加快。

飞蛾的位置更新公式的含义为飞蛾沿对数螺旋曲线飞行轨迹向火焰靠近,但该公式仅面向飞蛾向火焰飞行这一行为,从而导致算法容易陷入局部

最优的情况,全局寻优能力较弱。

因此,采用惯性权重对飞蛾的位置更新公式进行改进。惯性权重表达式如下:

$$\omega = \cos\left(\frac{\pi t}{2T}\right) \quad (16)$$

惯性权重是一个能够改变算法搜索范围的变量,其值越大,算法的搜索能力越大,即搜索范围越大;反之,则算法的探测能力越大,能够在最优解附近进行更加仔细地搜索。将惯性权重代入飞蛾的位置更新公式中:

$$S(M_i, F_j) = |F_j - M_i| \cdot e^{bt} \cdot \cos(2\pi t) + \omega \cdot F_j \quad (17)$$

如式(17)所示,惯性权重 $\omega$ 与第 $j$ 个火焰位置相乘,其值随迭代次数自适应地由1下降到0,当飞蛾离火焰位置较远时, $\omega$ 值较大,全局搜索能力强;当飞蛾离火焰位置越近时, $\omega$ 值较小,局部寻优能力较强,飞蛾对最优解的探测能力提高。

因此通过改进火焰数量的更新公式以及飞蛾的位置更新公式,能够在一定程度上提高算法的收敛速度以及收敛精度。

## 2.3 LSTM

LSTM主要通过遗忘门、输入门以及输出门来控制记忆单元信息的增减,其记忆单元结构图如图1所示。

首先,遗忘门 $f_t$ 决定如何对记忆单元状态量 $C_{t-1}$ 进行信息的删减,其中, $\sigma$ 激活函数决定遗忘门的状态。其计算式如下:

$$f_t = \sigma(W_{fx}x_t + W_{fh}h_{t-1} + b_f) \quad (18)$$

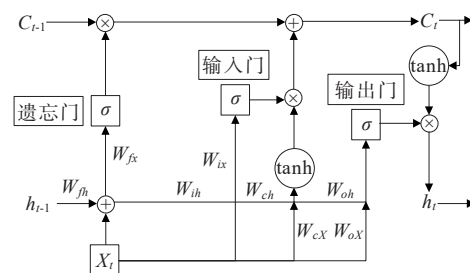


图1 LSTM神经网络记忆单元

Figure 1 LSTM neural network memory unit

接着,输入门信号 $i_t$ 决定如何对当前时刻状态量 $C_t$ 的进行新信息存储,其计算式如下:

$$i_t = \sigma(W_{ix}x_t + W_{ih}h_{t-1} + b_i) \quad (19)$$

tanh函数创建记忆单元临时状态量 $\dot{C}_t$ :

$$\dot{C}_t = \tanh(W_{cx}x_t + W_{ch}h_{t-1} + b_c) \quad (20)$$



记忆单元状态更新:

$$C_t = f_i C_{t-1} + i_t \dot{C}_t \quad (21)$$

最后,利用输出门 $o_t$ 计算输出值 $h_t$ 。

输出门计算式:

$$o_t = \sigma(W_{ox}x_t + W_{oh}h_{t-1} + b_o) \quad (22)$$

式(18)~(20)、(22)中的 $W_{fx}$ 、 $W_{fh}$ 、 $W_{ix}$ 、 $W_{ih}$ 、 $W_{cx}$ 、 $W_{ch}$ 、 $W_{ox}$ 、 $W_{oh}$ 分别表示其下标对应单元之间的权重矩阵; $b_f$ 、 $b_i$ 、 $b_c$ 、 $b_o$ 为对应下标单元的偏置值。

$h_t$ 的表达式为

$$h_t = o_t \tanh(C_t) \quad (23)$$

## 2.4 IMFO-LSTM神经网络

传统LSTM模型参数的设定通常基于研究人员的经验,计算过程中随机性较大,预测精度也会受到影响,陷入局部最优解的可能性也会增加。因此,使用IMFO算法对LSTM的相关参数进行优化,以提高LSTM的全局优化能力,降低随机性,提高预测精度。其算法步骤如下。

1) 初始化LSTM相关参数:隐含层神经元数目 $N$ 、学习率 $\theta$ 、LSTM迭代次数 $L$ 。

2) 初始化IMFO算法的参数:最大迭代次数 $T$ 、飞蛾的数量 $n$ 、飞蛾的自适应度 $O_M$ 、火焰的自适应度 $O_F$ 。

3) 改进飞蛾算法对LSTM网络参数的隐含神经元数量 $N$ ,以及学习率 $\theta$ 进行寻优,直至算法 $T$ 函数输出True,输出网络参数最优解;否则返回步骤2)。

4) 将输出的网络参数代入LSTM,结合样本数据进行训练并预测光伏发电功率输出。

## 3 实验分析

通过灰色关联度分析法选取不同天气类型的相似日样本数据,通过IMFO-LSTM模型对相似日样本数据进行计算,从而预测不同天气类型下的光伏发电功率。

### 3.1 相似日样本数据提取

将光伏电站的历史数据进行灰色关联度分析,其中数据集包括测得的辐照强度、大气温度、湿度、风速以及光伏发电功率。

随机各选取一个晴天、多云及雨天作为预测日,分别进行关联度计算,并根据计算结果计算相似度,选取相似度最高的5 d分别作为该天气类型下的样本数据进行预测。3种天气类型下的相似度计算结果如图2~4所示。




图2 晴天天气的相似度计算结果

Figure 2 The similarity calculation results of sunny weather




图3 多云天气的相似度计算结果

Figure 3 The similarity calculation results of cloudy weather




图4 雨天天气的相似度计算结果

Figure 4 The similarity calculation results of rainy weather

### 3.2 仿真分析

将选取的相似日样本数据作为输入数据,采用IMFO-LSTM模型进行预测。将前80%相似日样本数据作为训练集,后20%样本数据作为测试集进行仿真。

首先,为了验证改进后的效果,将其与PSO、灰狼优化(grey wolf optimizer, GWO)以及MFO算法进行对比。算法参数方面,PSO种群数量为150, GWO种群数量为35, MFO与IMFO的飞蛾种群数量为12,算法最大迭代次数均为350次,算法寻优效果对比图如图5所示,可以看出,对比其他智能算法,IMFO算法的收敛速度更快,且收敛精度更高。

接着,为验证IMFO-LSTM模型预测结果的精度,以LSTM模型的预测结果进行对比,不同天气类型下的预测结果对比如图6~8所示。

为突出预测结果的精确度,引入平均绝对百分比误差(mean absolute percentage error, MAPE)以及均方根误差(root mean square error, RMSE)作为评价标准,表达式如下:

$$e_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - \dot{Y}_i}{Y_i} \right| \quad (24)$$

$$e_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \dot{Y}_i)^2} \quad (25)$$




图5 算法性能对比

Figure 5 Algorithm performance comparison plot




图6 晴天下的光伏输出功率对比

Figure 6 Comparison of photovoltaic output power in a sunny weather




图7 多云下的光伏输出功率对比

Figure 7 Comparison of photovoltaic output power in cloudy weather

式(24)、(25)中,  $Y_i$  为光伏发电功率实际值;  $\dot{Y}_i$  为光伏发电功率的模型预测值。对比结果如表2所示。




图8 雨天下的光伏输出功率对比

Figure 8 Comparison of photovoltaic output power in rainy weather

表2 不同天气类型的评价结果

Table 2 Evaluation results under different weather types

天气	算法	RMSE/kW	MAPE/%
晴天	LSTM	2.136 8	2.18
	IMFO-LSTM	0.933 8	1.07
多云	LSTM	5.983 3	6.37
	IMFO-LSTM	2.481 7	2.56
雨天	LSTM	10.371 4	20.36
	IMFO-LSTM	4.583 8	5.89

由图6~8以及表2可得,在晴天天气情况下,光伏输出功率较为稳定, LSTM模型以及IMFO-LSTM模型的预测功率误差都较小,都满足要求,但IMFO-LSTM模型预测精度更高;而在多云天气下,光伏输出功率开始出现部分不稳定状况,因此2个模型的预测功率误差有所增大,但仍然满足预测精度要求;然而在雨天天气下,由于光伏输出功率的不稳定性以及LSTM模型的随机性,导致LSTM模型的预测精度较低,无法满足要求,而IMFO-LSTM模型由于优化了LSTM神经网络本身的随机性,并通过优化网络参数提高了预测精度,保证了在数据不稳定情况下的预测精度仍然满足要求。

## 4 结语

本文提出了一种基于IMFO-LSTM模型的光

伏功率预测研究:

1) 通过灰色关联度分析法对光伏输出功率的影响因素的关联度进行分析,并基于分析得到的最高关联的特征量对相似日样本数据进行提取,降低了整体计算难度;

2) 通过对MFO算法的火焰数量自适应更新公式进行改进,并引入惯性权重改进飞蛾位置更新公式,提高了算法的搜索性能以及收敛精度;

3) 通过IMFO算法对LSTM参数进行优化,降低了其计算过程的随机性,并提升了预测结果的精确度,最后通过仿真分析验证了该模型的有效性。

#### 参考文献:

- [1] 张扬科,李刚,李秀峰.基于典型代表电站和改进SVM的区域光伏功率短期预测方法[J].电力自动化设备,2021,41(11):205-210.  
ZHANG Yangke, LI Gang, LI Xiufeng. Short-term forecasting method for regional photovoltaic power based on typical representative power stations and improved SVM[J]. Electric Power Automation Equipment, 2021, 41(11): 205-210.
- [2] 张永蕊,阎洁,林爱美,等.多点数值天气预报风速和辐照度集中式修正方法研究[J].发电技术,2022,43(2):278-286.  
ZHANG Yongrui, YAN Jie, LIN Aimei, et al. Integrated correction method of multi-point numerical weather prediction wind speed and irradiance[J]. Power Generation Technology, 2022, 43(2): 278-286.
- [3] 周步祥,吴晨旭,邱一苇,等.计及光伏出力时序不确定性的电制氢多机集群优化调度[J].电力建设,2023,44(9):108-117.  
ZHOU Buxiang, WU Chenxu, QIU Yiwei, et al. Optimal scheduling of multi-electrolyzer power-to-hydrogen clusters considering the temporal uncertainty of photovoltaic power[J]. Electric Power Construction, 2023, 44(9): 108-117.
- [4] 张旻,李天喆,张容进,等.基于信息融合的动态神经网络光伏功率预测[J].电力科学与技术学报,2020,35(3):68-73.  
ZHANG Min, LI Tianzhe, ZHANG Rongjin, et al. Photovoltaic power forecasting based on information fusion theory[J]. Journal of Electric Power Science and Technology, 2020, 35(3): 68-73.
- [5] KOSTER D, MINETTE F, BRAUN C, et al. Short-term and regionalized photovoltaic power forecasting, enhanced by reference systems, on the example of Luxembourg[J]. Renewable Energy, 2019, 132: 455-470.
- [6] 邓韦斯,孟子超,王皓怀,等.新能源功率预测特性分析及精度提升措施[J].南方电网技术,2023,17(2):11-23.  
DENG Weisi, MENG Zichao, WANG Haohuai, et al. Renewable energy power prediction characteristics analyses and accuracy improvement measures[J]. Southern Power System Technology, 2023, 17(2): 11-23.
- [7] 施路炜,徐潇源,严正,等.考虑配电网电压约束的光伏功率升维仿射控制[J].电力系统自动化,2023,47(19):64-73.  
SHI Luwei, XU Xiaoyuan, YAN Zheng, et al. Dimension-lifting affine control of photovoltaic power considering voltage constraints of distribution network[J]. Automation of Electric Power Systems, 2023, 47(19): 64-73.
- [8] 雷柯松,吐松江·卡日,伊力哈木·亚尔买买提,等.基于WGAN-GP和CNN-LSTM-Attention的短期光伏功率预测[J].电力系统保护与控制,2023,51(9):108-118.  
LEI Kesong, TUSONGJIANG·Kari, YILIHAMU·Yaermaimaiti, et al. Prediction of short-term photovoltaic power based on WGAN-GP and CNN-LSTM-Attention[J]. Power System Protection and Control, 2023, 51(9): 108-118.
- [9] 杨海柱,李庆华,张鹏.基于tGSSA-DELM的短期光伏发电功率预测[J].智慧电力,2023,51(10):70-77.  
YANG Haizhu, LI Qinghua, ZHANG Peng. Short-term photovoltaic power generation prediction based on tGSSA-DELM[J]. Smart Power, 2023, 51(10): 70-77.
- [10] 刘晓艳,王珏,姚铁锤,等.基于卫星遥感的超短期分布式光伏功率预测[J].电工技术学报,2022,37(7):1800-1809.  
LIU Xiaoyan, WANG Jue, YAO Tiechui, et al. Ultra short-term distributed photovoltaic power prediction based on satellite remote sensing[J]. Transactions of China Electrotechnical Society, 2022, 37(7): 1800-1809.
- [11] 杨鹏兴,王秀丽,赵兴勇,等.基于深度学习的光伏并网系统谐波预测研究[J].电网与清洁能源,2022,38(7):71-80.  
YANG Pengxing, WANG Xiuli, ZHAO Xingyong, et al. Research on harmonic prediction of the grid-connected photovoltaic system based on deep learning[J]. Power System and Clean Energy, 2022, 38(7): 71-80.
- [12] 李民,杨暑森,李科锋,等.覆雪状态下光伏发电功率预测方法研究[J].高压电器,2023,59(9):250-257.  
LI Min, YANG Shusen, LI Kefeng, et al. Research on power prediction method of photovoltaic power generation under snow coating conditions[J]. High

- Voltage Apparatus,2023,59(9):250-257.
- [13] 陈瑶,陈晓宁.基于自适应Kmeans和LSTM的短期光伏发电预测[J].电测与仪表,2023,60(7):94-99.  
CHEN Yao, CHEN Xiaoning. Prediction of short-term photovoltaic power generation based on adaptive Kmeans and LSTM[J]. Electrical Measurement & Instrumentation,2023,60(7):94-99.
- [14] OSPINA J,NEWAZ A,FARUQUE M O.Forecasting of PV plant output using hybrid wavelet-based LSTM-DNN structure model[J]. IET Renewable Power Generation,2019,13(7):1087-1095.
- [15] 徐一伦,张彬桥,黄婧,等.考虑天气类型和相似日的IWPA-LSSVM光伏发电功率预测[J].中国电力,2023,56(2):143-149.  
XU Yilun,ZHANG Binqiao,HUANG Jing,et al.Forecast of photovoltaic power based on IWPA-LSSVM considering weather types and similar days[J]. Electric Power,2023,56(2):143-149.
- [16] 杨子民,彭小圣,熊予涵,等.计及邻近风电场信息与CNN-BiLSTM的短期风电功率预测[J].南方电网技术,2023,17(2):47-56.  
YANG Zimin, PENG Xiaosheng, XIONG Yuhan, et al. Short-Term wind power prediction based on information in neighboring wind farms and CNN-BiLSTM[J]. Southern Power System Technology,2023,17(2):47-56.
- [17] 吉铎格,李慧,刘思嘉,等.基于MIE-LSTM的短期光伏功率预测[J].电力系统保护与控制,2020,48(7):50-57.  
JI Xinge, LI Hui, LIU Sijia, et al. Short-term photovoltaic power forecasting based on MIE-LSTM[J]. Power System Protection and Control,2020,48(7):50-57.
- [18] 张雲钦,程起泽,蒋文杰,等.基于EMD-PCA-LSTM的光伏功率预测模型[J].太阳能学报,2021,42(9):62-69.  
ZHANG Yunqin, CHENG Qize, JIANG Wenjie, et al. Photovoltaic power prediction model based on emd-pca-lstm[J]. Acta Energiae Solaris Sinica,2021,42(9):62-69.
- [19] 王振浩,王翀,成龙,等.基于集合经验模态分解和深度学习的光伏功率组合预测[J].高电压技术,2022,48(10):4133-4142.  
WANG Zhenhao, WANG Chong, CHENG Long, et al. Photovoltaic power combined prediction based on ensemble empirical mode decomposition and deep learning[J]. High Voltage Engineering,2022,48(10):4133-4142.
- [20] 杨晶显,张帅,刘继春,等.基于VMD和双重注意力机制LSTM的短期光伏功率预测[J].电力系统自动化,2021,45(3):174-182.  
YANG Jingxian, ZHANG Shuai, LIU Jichun, et al. Short-term photovoltaic power prediction based on variational mode decomposition and long shortterm memory with dual-stage attention mechanism[J]. Automation of Electric Power Systems,2021,45(3):174-182.
- [21] 殷豪,张铮,丁伟锋,等.基于生成对抗网络和LSTM-CSO的少样本光伏功率短期预测[J].高电压技术,2022,48(11):4342-4351.  
YIN Hao, ZHANG Zheng, DING Weifeng, et al. Short-term prediction of small-sample photovoltaic power based on generative adversarial network and LSTM-CSO [J]. High Voltage Engineering,2022,48(11):4342-4351.
- [22] 于红伟,许国泽,何旭东,等.基于相似样本和多模型动态最优组合的光伏功率预测[J].电网与清洁能源,2021,37(9):92-99.  
YU Hongwei, XU Guoze, HE Xudong, et al. Photovoltaic power prediction based on similar samples and dynamic optimal combination of multiple models[J]. Power System and Clean Energy,2021,37(9):92-99.