

基于相似日分析和改进鲸鱼算法优化 LSTM 网络模型的光伏功率短期预测

薛阳, 李金星, 杨江天, 李清, 丁凯
(上海电力大学自动化工程学院, 上海 200090)

摘要: 为了解决环境温度、风速和太阳辐照度等诸多因素对光伏发电预测的制约, 提出了一种基于相似日分析和改进鲸鱼算法优化的长短期记忆(long short-term memory, LSTM)神经网络模型来实现光伏功率短期预测。首先, 采用 Pearson 相关系数进行特征选择以去除与光伏输出功率不相关的气象特征; 其次, 针对相似气象情况下光伏电站发电功率接近的实际情况, 采用灰色关联分析(gray relation analysis, GRA)选取与预测日气象特征相似的日期作为训练集; 然后, 提出一种改进鲸鱼算法(improved whale algorithm, IWOA)来优化 LSTM 深度神经网络的超参数, 使预测模型的均方根误差达到最小; 最后, 以澳洲 Yulara 沙漠 3 号光伏电站的光伏发电历史数据作为实验数据, 用 GRA-IWOA-LSTM 神经网络模型进行预测。仿真结果表明, 在不同的天气类型下与其他模型的预测效果相比, GRA-IWOA-LSTM 模型的预测结果精度更高。

关键词: 相似日; 光伏功率短期预测; 灰色关联分析; 改进鲸鱼优化算法; 长短期记忆神经网络

Short-Term Prediction of Photovoltaic Power Based on Similar Day Analysis and Improved Whale Algorithm to Optimize LSTM Network Model

XUE Yang, LI Jinxing, YANG Jiangtian, LI Qing, DING Kai

(School of Automation Engineering, Shanghai University of Electric Power, Shanghai 200090, China)

Abstract: In order to solve the constraints of many factors such as ambient temperature, wind speed and solar irradiance on photovoltaic power generation prediction, a long short-term memory (LSTM) neural network model based on similar day analysis and improved whale algorithm optimization to realize short-term prediction of photovoltaic power is proposed. Firstly, the Pearson correlation coefficient is used for feature selection to remove meteorological characteristics that are not correlated with the output power of photovoltaics. Secondly, according to the actual situation that the power generation of photovoltaic power plants is close under similar meteorological conditions, gray relation analysis (GRA) is used to select dates similar to the meteorological characteristics of the forecast day as the training set. Then, an improved whale algorithm (IWOA) is proposed to optimize the hyperparameters of LSTM deep neural network to minimize the root mean square error of the prediction model. Finally, the historical data of photovoltaic power generation of Yulara Desert No. 3 photovoltaic power station in Australia is used as experimental data, and the GRA-IWOA-LSTM neural network model is used to make predictions. The simulation results show that the prediction results of the GRA-IWOA-LSTM model are more accurate than the prediction effects of other models under different weather types.

Key words: similar day; short-term prediction of photovoltaic power; grey relation analysis; improved whale optimization algorithm; long short-term neural network

基金项目: 国家自然科学基金资助项目(52075316); 上海市 2021 年度“科技创新行动计划”(21DZ1207502); 国网杭州供电公司科技项目(5211HZ17000F)。

Foundation item: Supported by the National Natural Science Foundation of China(52075316); Shanghai 2021 "Science and Technology Innovation Action Plan"(21DZ1207502); the Science and Technology Project of State Grid Hangzhou Power Supply Company (5211HZ17000F).

0 引言

近年来,随着世界化石能源的短缺以及人类节能减排意识的不断加强,新能源发电规模日趋壮大。据统计,2021年全球光伏累计装机容量为942 GW。太阳能的可持续性和经济效益使其在替代能源解决方案中获得了巨大的吸引力。地球上已被发现的可用太阳能是目前石油储量的516倍,是煤炭储量的157倍^[1],光伏系统能够将这种丰富的太阳能转化为电能。由于光伏功率受太阳辐照、温度、风速等环境条件影响,具有较高的波动性和随机性,不仅对电网的安全稳定运行产生不良影响,而且对电网日前调度计划的合理性和经济性提出挑战^[2]。因此,准确预测光伏功率尤为重要。

目前,考虑天气特征的机器学习模型和混合模型被广泛应用于光伏发电预测领域^[5]。基于机器学习的预测技术可分为浅层和深度学习模型,深度学习模型解决了浅层学习模型的缺点,并越来越多地应用于光伏功率预测^[6-8]。文献[9]提出采用经验模态分解和主成分分析筛选影响光伏输出功率的关键因子,通过长短期记忆(long-short term memory, LSTM)神经网络完成对多变量时间序列和光伏功率序列之间的动态时间建模,实现对光伏输出功率的预测。文献[10]利用变模态分解将光伏功率时间序列分解成不同的相对简单的子序列分量,建立各个分量的LSTM预测模型,并在LSTM基础上引入特征和时序双重注意力机制,提高了单步预测和多步预测的精度。文献[11]提出了一种基于数值天气预报相似性分析的功率预测方法,采用广义递归神经网络模型,弥补了神经网络在波动性大的时段预测精度低的不足。文献[12]采用皮尔逊相关系数法进行特征选择,减少噪声对光伏功率预测的影响,采用LSTM神经网络模型提高了预测精度。文献[13]除了采用皮尔逊相关系数和经验模态分解进行特征选择和特征重构之外,还采用了麻雀搜索算法对LSTM网络超参数进行优化,用优化后的模型得到了较好的预测精度。

考虑到光伏输出功率受天气因素影响较大,模型输入训练数据集复杂、训练时间长,同时现有的许多优化算法原理复杂,寻优时间长,本文采用皮尔逊相关系数法进行特征选择,采用灰色关联分析(grey relation analysis, GRA)选取与预测日气象特

征相似的相似日数据集作为训练集,从而降低模型训练数据的复杂度,缩短训练时间。为了解决深度学习模型超参数对预测精度的影响,本文提出了一种改进鲸鱼优化算法(improve whale optimization algorithm, IWOA)对LSTM神经网络模型的超参数进行优化,进而构建GRA-IWOA-LSTM预测模型。通过算例的仿真分析,比较了GRA-IWOA-LSTM模型和其他模型在不同天气下的预测结果,验证了本文所提模型的有效性和准确性。

1 气象特征选择

1.1 数据预处理

由于实际获得的历史数据集往往受到装置故障或者数据传输问题的影响,容易出现数据异常的情况。另外,影响光伏输出功率的各个气象要素和光伏功率数据具有不同的量纲和单位,在进行气象特征选择和相关性分析之前,需要将数据进行归一化处理。因此,本文将获得的历史气象和功率数据中连续5个时刻重复或者缺失的数据删除;分别采用移动均值法和线性插值法清理其他缺失数据和离群数据;对光伏发电功率和太阳辐照度、风速、天气温度等10个气象特征的归一化采用最大最小归一化法^[14],具体如下。

$$x_{\text{normalization}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

式中: $x_{\min}$ 为该特征的最小值; $x_{\max}$ 为该特征的最大值; x 为原始值; $x_{\text{normalization}}$ 为归一化之后的值。

1.2 Pearson相关系数分析法

皮尔逊(Pearson)相关系数最早由统计学家卡尔·皮尔逊提出,是用来度量两个(组)变量 $\mathbf{X}$ 、 $\mathbf{Y}$ 之间线性相关程度的统计指标,其值在区间 $[-1, 1]$ 内,常用 ρ_{xy} 来表示,计算公式如下。

$$\rho_{xy} = \frac{\sum_{i=1}^m (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^m (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^m (y_i - \bar{y})^2}} \quad (2)$$

式中: m 为采样数量; x_i 为第 i 时刻气象参数; $\bar{x}$ 为该气象参数的平均值; y_i 为第 i 时刻光伏输出功率; $\bar{y}$ 为光伏输出功率的平均值。

光伏功率的输出在很大程度上受天气因素影响,从光伏电站获取的数据往往包含多个气象特征,有的气象特征对光伏功率输出影响较大(如太

阳辐照度), 而有的气象特征对光伏输出功率的输出影响很小(如风向、气压等), 因此选取影响较大的气象因素作为光伏功率预测模型的输入, 降低模型复杂度, 从而提高预测的效果。

本文选用澳大利亚沙漠太阳能研究中心(DKASC)Yulara 太阳能光伏发电系统 3 号电站实测数据, 将获得的数据按照季节分类, 采用皮尔逊相关系数对所选地区光伏发电系统的输出功率与各个气象因素之间的相关性进行分析, 结果如表 1 所示。

表 1 不同季节各气象特征与光伏输出功率皮尔逊相关系数
Tab. 1 Pearson correlation coefficients between meteorological characteristics and photovoltaic output power in different seasons

气象特征	春季	夏季	秋季	冬季	相关系数 平均值
风速	0.213	0.185	0.387	0.465	0.313
天气温度	0.251	0.331	0.397	0.430	0.352
全局水平辐照度	0.945	0.934	0.988	0.995	0.966
风向	-0.126	-0.153	-0.216	-0.156	-0.163
降雨量	-0.086	-0.076	-0.039	-0.044	-0.061
最大风速	0.275	0.271	0.471	0.530	0.387
空气压力	0.137	0.083	0.043	0.055	0.058
日射强度	0.950	0.937	0.989	0.993	0.968
光伏板探测温度	0.820	0.828	0.861	0.849	0.839

由表 1 可知, 本文选择季节皮尔逊相关系数平均值大于 0.35 的气象特征: 天气温度、全局水平辐照度、最大风速、日射强度、光伏板探测温度 5 个气象特征作为模型的输入向量。

1.3 基于灰色关联分析的相似日选取

1) 根据影响光伏功率输出的各气象特征, 构建气象特征向量 D 为:

$$D = [\bar{R}, \bar{S}, P_H, P_L, T_H, T_L, \bar{T}_p] \quad (3)$$

式中: $\bar{R}$ 为日平均全局辐照度; $\bar{S}$ 为日平均最大风速; P_H 、 P_L 分别为每日日射强度的最大、最小值; T_H 、 T_L 分别为每天温度的最大、最小值; $\bar{T}_p$ 为每日光伏板探测温度平均值。

2) 对所构建日气象特征向量 D 的各个分量进行归一化处理后, 得到预测日和第 j 日的气象特征向量分别为 x_0 和 x_j 。

$$x_0 = [x_{01}, x_{02}, x_{03}, x_{04}, x_{05}, x_{06}, x_{07}] \quad (4)$$

$$x_j = [x_{j1}, x_{j2}, x_{j3}, x_{j4}, x_{j5}, x_{j6}, x_{j7}] \quad (5)$$

3) 计算 x_0 和 x_j 在第 k ($k = 1, 2, \dots, 7$) 个分

量的关联系数 ξ_{jk} 。

$$\xi_{jk} = \frac{a + r \times b}{|x_{0k} - x_{jk}| + r \times b} \quad (6)$$

$$a = \min_j \min_k |x_{0k} - x_{jk}| \quad (7)$$

$$b = \max_j \max_k |x_{0k} - x_{jk}| \quad (8)$$

式中 r 为分辨率系数, 取值在 $[0, 1]$ 之间, 本文取 $r = 0.5$ [15]。

4) 综合各个分量的关联系数, x_0 和 x_j 的相似度定义为 $\gamma(x_0, x_j)$ 。

$$\gamma(x_0, x_j) = \frac{1}{n} \sum_{k=1}^7 \xi_{jk} \quad (9)$$

式中 n 为气象特征向量的分量数量。

2 改进鲸鱼优化算法

2.1 基本的鲸鱼优化算法

2016 年 Mirjalili 等受座头鲸的狩猎行为启发提出了一种新型群体智能优化算法—鲸鱼优化算法 (whale optimization algorithm, WOA), 其基本原理分为 3 个阶段: 包围猎物、发泡网攻击、搜寻猎物 [16]。因此, 对座头鲸的捕食行为建立数学模型, 最优个体的位置就代表当前问题的最优解, 具体建模步骤如下。

1) 包围猎物。假设在 d 维空间中, 当前最佳鲸鱼个体为 $x^* = (x_1^*, x_2^*, \dots, x_d^*)$, 鲸鱼个体 $x_j = (x_{1,j}, x_{2,j}, \dots, x_{d,j})$, 则鲸鱼个体 x_j 在最佳鲸鱼个体 x^* 影响下的下一个位置 $x_{j+1} = (x_{1,j+1}, x_{2,j+1}, \dots, x_{d,j+1})$ 的计算公式为:

$$x_{m,j+1} = x_m^* - A_1 \times D_m \quad (10)$$

$$D_m = |c_1 \times x_m^* - x_{m,j}| \quad (11)$$

$$A_1 = 2 \times a \times r_1 - a \quad (12)$$

$$c_1 = 2 \times r_2 \quad (13)$$

式中: $x_{m,j+1}$ 为空间坐标 x_{j+1} 的第 m 个分量; x_m^* 为 x^* 的第 m 个分量; $|\cdot|$ 表示求绝对值; a 为随着迭代次数增加, 从 2 至 0 线性递减; A_1 为取值在 $[-a, a]$ 之间随机数; r_1 、 r_2 为 $[0, 1]$ 的随机数。

2) 发泡网攻击。发泡网攻击是座头鲸特有的吐气泡捕食行为, 在捕食途中采取的是螺旋收缩包围的方式, 其螺旋位置更新公式如式 (14) — (15) 所示。

$$x_{m,j+1} = x_m^* - D_{m1} \times e^{bl} \times \cos(2\pi l) \quad (14)$$

$$D_{m1} = |x_m^* - x_{m,j}| \quad (15)$$

式中: b 为对数螺旋形状常数; l 为 $[-1, 1]$ 的随机数; $x_{m,j}$ 为第 j 个鲸鱼个体的第 m 个分量。

由于座头鲸收缩包围猎物 and 螺旋上升的行为是同时发生, 在位置更新时, 需引入随机概率 p 作为判断阈值来判断以哪一种迭代方式进行。

$$x_{m,j+1} = \begin{cases} x_m^* - A_1 \times D_m, & p < 0.5 \\ x_m^* - D_{m1} \times e^{bl} \times \cos(2\pi l), & p \geq 0.5 \end{cases} \quad (16)$$

式中: $A_1 \in [-1, 1]$ 的随机数; p 为 $[0, 1]$ 的随机数; l 为 $[-1, 1]$ 的随机数。

3) 搜索捕食。在收缩包围捕食行为的数学模型中, A_1 的取值范围限制为 $[-1, 1]$, 但是当 A_1 的取值不在该范围时, 当前鲸鱼个体不会向最佳鲸鱼个体靠近, 而是从当前鲸鱼群体中随机选择一条鲸鱼个体靠近, 从而使得自己的位置得到更新。假设当前鲸鱼群体中随机一个鲸鱼个体 $x_{m, \text{rand}} = (x_{1, \text{rand}}, x_{2, \text{rand}}, \dots, x_{d, \text{rand}})$, 具体如下。

$$x_{m,j+1} = x_{m, \text{rand}} - A_1 \times D_m \quad (17)$$

$$D_m = |c_1 \times x_{m, \text{rand}} - x_{m, \text{rand}}| \quad (18)$$

$$A_1 = 2 \times a \times r_1 - a \quad (19)$$

$$c_1 = 2 \times r_2 \quad (20)$$

式中 $A_1 \in [-2, -1) \cup (1, 2]$, 为随机数。

2.2 改进鲸鱼优化算法

WOA 具有原理简单、参数设置少、寻优性能强等优点, 但是容易陷入局部最优解且收敛精度低的问题^[17-19]。因此, 本文提出了一种非线性方法控制参数 l 来提高收敛精度。同时, 引入遗传算法中的变异策略, 提出一种非均匀柯西变异方法改进鲸鱼优化算法的搜索策略提高算法前期的全局搜索能力, 进而提高算法的收敛速度。

1) 非线性控制参数 l

螺旋位置更新方法与 WOA 的性能有显著关联, 与螺旋更新位置相关的系数 l 确定了螺旋上每个位置的曲率半径。因此, 对系数 l 进行合理调整可以提高最佳命中精度。改进公式如下。

$$l = a_2 \times r_{\text{rand } 1} + 1 - \sqrt{\frac{t}{t_{\text{max}}}} \quad (21)$$

$$a_2 = \sin\left(\frac{\pi}{2} \times (-1) \times \sqrt{\frac{t}{t_{\text{max}}}}\right) \quad (22)$$

式中: $r_{\text{rand } 1}$ 为 $[0, 1]$ 的随机数; t 为当前迭代次数; t_{max} 为最大迭代次数。

根据式(21)——(22)可知, 采用正弦函数在迭代

期间控制参数 l , 使 l 从 1 到 -1 非线性递减。当个体采用螺旋位置更新时, 在算法初期 l 值较大并且减小速率快, 螺旋上每个位置的曲率半径较大且变化速度快。随着迭代次数的增加, 算法当前最佳个体越来越趋近于最终的最优个体, l 值在后期逐渐减小并且减小速度变缓, 此时螺旋上每个位置的曲率半径小且变化缓慢, 使得算法在后期能够更加精确的靠近最优解, 进而在一定程度上提高了算法的收敛精度。

2) 非均匀柯西变异搜索策略

群智能算法应用柯西变异策略提高收敛精度已取得较好的效果。柯西分布从峰值向两侧下降平缓, 使得柯西变异后的鲸鱼个体受局部极值点约束力下降, 在陷入局部极值时能迅速逃离。另一方面, 与高斯分布相比柯西分布的峰值较小, 变异后的鲸鱼会花费较少时间来搜索邻域区间, 重点搜寻全局最优点, 所以由柯西分布产生的扰动对鲸鱼优化算法寻找全局最优值具有很好的调节能力。由随机变量生成函数定理得到柯西分布的随机变量生成函数 $\eta(\varepsilon)$ 为^[20]:

$$\eta(\varepsilon) = \tan[(\varepsilon - 0.5) \times \pi] \quad (23)$$

$$f(\eta) = \frac{1}{\pi} \times \frac{1}{1 + \eta^2} \quad (24)$$

式中: ε 为 $[0, 1]$ 上服从均匀分布的随机变量; $f(\eta)$ 为标准柯西分布函数。

Michalewicz 提出了一种动态非均匀变异算法来降低进化算法中随机突变的特点^[21]。本文将柯西分布函数与非均匀变异算法结合提出一种非均匀柯西变异策略, 代替搜索捕食策略中鲸鱼个体位置的更新策略, 以达到在算法初期保持种群多样性的目的, 从而提高算法的全局搜索能力。假设当前鲸鱼个体 $x_j = (x_{1,j}, x_{2,j}, \dots, x_{k,j}, \dots, x_{d,j})$, 分量 $x_{k,j}$ 被选择进行变异, 则通过非均匀变异算法更新位置为 $x_{j+1} = (x_{1,j}, x_{2,j}, \dots, x_{k,j+1}, \dots, x_{d,j})$, 具体如下。

$$x_{k,j+1} = \begin{cases} x_{k,j} + \Delta(t, x_{k,j}^U - x_{k,j}) \times \text{Cauchy}(0, 1), & r_{\text{rand } 2} = 0 \\ x_{k,j} + \Delta(t, x_{k,j} - x_{k,j}^L) \times \text{Cauchy}(0, 1), & r_{\text{rand } 2} = 1 \end{cases} \quad (25)$$

$$\Delta(t, y) = y \times (1 - r^{(1 - \frac{t}{t_{\text{max}}})^2}) \quad (26)$$

式中: $x_{k,j}^U$ 、 $x_{k,j}^L$ 分别为 $x_{k,j}$ 的上限和下限;

$Cauchy(0, 1)$ 为生成服从标准柯西分布的随机数; r_{rand2} 为 0 或 1; t 为当前迭代次数; r 为 $[0, 1]$ 的随机数; $\Delta(t, y)$ 为一个 $[0, y]$ 的数值, 该值随着 t 的增加而接近于 0, 这种性质使得算法在前期均匀的搜索空间, 在后期可以在最优解附近进行搜索, 从而缩小搜索范围提高算法的收敛速度。

为了验证所提 IWOA 算法的性能, 本文采用 Sphere 标准函数作为适应度函数 (Sphere 函数的表达式如式 (27) 所示), 分别采用原始 WOA 算法和 IWOA 算法在搜索空间 $[-100, 100]$ 上搜索 Shpere 函数的最小值, 对比效果如图 1 所示。

$$f(x) = \sum_{i=1}^n x_i^2 \quad (27)$$

式中: x_i 为 $[-100, 100]$ 的随机数; n 为 3。

由图 1 可以看出, 当最大迭代次数为 60 时, 原始 WOA 算法在迭代到第 60 次寻找到目标函数的最小值为 12.732 1, 而 IWOA 算法迭代到第 25 次就找到了目标函数的最小值 0。因此, 比起原始 WOA 算法, 本文所提出的 IWOA 算法的收敛速度更快, 收敛精度更高。




图 1 不同算法下 Sphere 函数的适应度收敛趋势

Fig. 1 Convergence trend of fitness of Sphere function under different algorithms

3 基于 IWOA 优化的 LSTM 神经网络预测模型

3.1 长短期记忆神经网络

LSTM 神经网络是在循环神经网络 (recurrent neural network, RNN) 的基础上引入了一种门控机制来控制特征的循环和丢失, 使得模型可以选择性记忆有效信息并删除无效信息, 从而解决了 RNN

存在“遗忘”长期序列信息的问题^[22-26]。

在光伏功率预测研究中, 由于数据会随着时间不断变化, 后一时刻的数据与前几个时刻的数据密切相关, 采用改良 RNN 模型得到的 LSTM 神经网络模型不仅可以很好地捕捉到数据信息之间的时间关联性, 而且也避免了传统 RNN 模型出现梯度消失和梯度爆炸的问题^[27]。LSTM 门控机制包含遗忘门 f_t 、输入门 i_t 和输出门 O_t , 此外, 其单元结构中还有一个用于存放 t 时刻单元临时状态信息的内部存储器 C'_t 。LSTM 单元的内部结构如图 2 所示。




图 2 长短期记忆神经网络单元示意图

Fig. 2 Schematic diagram of LSTM unit

1) 遗忘门负责控制从上一个时刻的单元状态信息 C_{t-1} 中丢弃冗余信息, 遗忘门的计算式如下。

$$f_t = \sigma(W_f \times [X_t, h_{t-1}]^T + b_f) \quad (28)$$

2) 输入门负责计算出 t 时刻网络单元状态信息的输出 C_t , 这个过程需要用到光伏数据输入门的激活值 i_t 和 t 时刻记忆单元的临时状态输入 C'_t 这 2 个参数, 其计算式分别如下。

$$i_t = \sigma(W_i \times [X_t, h_{t-1}]^T + b_i) \quad (29)$$

$$C'_t = \tanh(W_c \times h_{t-1} + W_f \times X_t + b_c) \quad (30)$$

$$C_t = f_t C_{t-1} + i_t C'_t \quad (31)$$

3) 输出门负责计算 t 时刻网络的输出值 h_t , 输出门的状态 O_t 用来控制当前时刻网络状态信息 C_t 传递到 h_t 的数值, 具体计算式如下。

$$O_t = \sigma(W_o \times [X_t, h_{t-1}]^T + b_o) \quad (32)$$

$$h_t = O_t \tanh C_t \quad (33)$$

式中: X_t 为 t 时刻隐藏层的输入值矩阵; f_t 、 i_t 、 O_t 分别为 t 时刻遗忘门、输入门、输出门的输出值; h_{t-1} 为 $t-1$ 时刻隐藏层的输出值; $\sigma(\cdot)$ 为激活函数 sigmoid, 其输出值在 $[0, 1]$ 之间; W_f 、 W_i 、 W_o 分

别为遗忘门、输入门、输出门的权重矩阵； b_f 、 b_i 、 b_o 分别为3个门对应的偏置项； W_c 、 b_c 分别为输入单元状态的权重矩阵和偏置项； $\odot$ 为矩阵元素对应相乘的运算； $\tanh(\cdot)$ 为双曲正切激活函数，其输出值在 $[-1, 1]$ 之间。

3.2 GRA-IWOA-LSTM预测步骤

基于GRA-IWOA-LSTM模型的预测流程如图3所示。




图3 基于GRA-IWOA-LSTM模型的短期光伏功率预测流程图

Fig. 3 Flow chart of short-term photovoltaic power prediction based on GRA-IWOA-LSTM model

本文所提出的光伏功率短期预测模型步骤如下。

- 1) 选取典型日作为预测日，为消除量纲影响，对数据进行归一化处理。
- 2) 采用GRA进行相关性分析，选取与预测日天气特征灰色关联度大于0.9的相似日数据作为训练集数据。
- 3) 初始化IWOA算法的种群规模、迭代次数等参数，初始化LSTM神经网络的结构并输入训练集。
- 4) 通过IWOA算法优化LSTM神经网络模型的超参数，包括迭代次数、学习率以及隐藏层神经元个数。
- 5) 将原始网络参数替换成优化后所得参数，

并输入预测日气象特征数据进行光伏功率短期预测。

4 算例分析

本文选取的实验样本数据为澳大利亚沙漠太阳能研究中心(DKASC) Yulara太阳能系统3号电站2017年1月1日—2018年12月30日光伏发电系统实测数据，采样的时间步长为15 min，选取每日06:30—19:00共51个样本点（包括历史功率和气象数据）作为样本集。本文分别使用不考虑天气特征的LSTM神经网络模型、考虑天气特征和相似日的GRA-WOA-LSTM模型、GRA-IWOA-LSTM模型、以及基于主成分分析(principal component analysis, PCA)进行特征选择的PCA-LSTM模型和PCA-Elman模型的预测效果进行比较。

本文选取均方根误差(root mean square error, RMSE)、平均绝对误差(mean absolute error, MAE)和决定系数(R^2)3个评估指标为对预测模型的预测精度进行分析与评估^[28-29]。 e_{RMSE} 表示实际值和预测值残差的标准偏差， e_{MAE} 表示用绝对误差表示实际值和预测值之间的平均偏差， R^2 则表示回归模型预测值和实际值之间的拟合度，其值在 $[0, 1]$ 之间。这3个指标的计算公式如下。

$$e_{RMSE} = \sqrt{\frac{\sum_{i=1}^N (y_i - y_{i_pred})^2}{N}} \quad (34)$$

$$e_{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - y_{i_pred}| \quad (35)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_{i_pred} - y_i)^2}{\sum_{i=1}^N (\bar{y} - y_i)^2} \quad (36)$$

式中： N 为样本数量； y_i 、 y_{i_pred} 分别为 i 时刻的功率真实值和功率预测值； $\bar{y}$ 为 N 个实际光伏功率值的平均值。

为验证GRA-IWOA-LSTM模型的预测性能，本文以MATLAB 2021 a为实验平台，分别选取典型日：2017年10月17日为晴天、2018年4月20日为多云、2018年8月2日为雨天作为预测日进行预测。其中，不同天气类型模型的训练集根据相似日的选取来确定，具体如下：晴天(10月17日)相似日有27 d，共1 377个样本点；多云(4月20日)相似日有

16 d, 共 816 个样本点; 雨天(8月 2 日)相似日有 9 d, 共 459 个样本点, 图 4 为预测日功率曲线。




图 4 不同天气类型下各预测模型预测结果图
Fig. 4 Prediction results of various prediction models under different weather types

不同天气类型下 GRA-IWOA-LSTM 预测模型的参数设置如表 2 所示。为了验证 Pearson 特征降维与 GRA 相似日分析的重要性, 本文分别采用 GRA-IWOA-LSTM 模型和 IWOA-LSTM 模型进行光伏功

率预测, 并对两种模型的预测时间进行对比, 得到的结果如表 3 所示。光伏发电的实际值和预测值如图 4 所示, 预测后得到各种不同模型的误差指标, 如表 4—6 所示。

对不同类型预测日的光伏功率进行预测, 本文所提出的 GRA-IWOA-LSTM 预测模型的拟合度 (R^2) 最高, 真实值与预测值残差的标准偏差 (RMSE) 以及实际值和预测值之间的平均偏差的绝对值 (MAE) 最小, 具有更高的预测精度。

表 2 GRA-IWOA-LSTM 预测模型参数设置
Tab. 2 Parameter settings for GRA-IWOA-LSTM prediction model

天气类型	隐含层节点数量	迭代次数	学习率
晴天	328	214	0.010
多云	126	232	0.023
雨天	397	218	0.010

表 3 两种模型的预测时间对比
Tab. 3 Comparison of prediction time between two prediction models

预测模型	晴天	多云	雨天
GRA-IWOA-LSTM	23	15	11
IWOA-LSTM	197	311	254

表 4 不同预测模型下晴天的预测误差
Tab. 4 Prediction errors of sunny days under different prediction models

预测模型	RMSE 值	MAE 值	R^2
GRA-IWOA-LSTM	0.257 6	0.195 1	0.999 6
GRA-WOA-LSTM	0.468 3	0.356 2	0.998 8
PCA-LSTM	0.885 2	0.617 2	0.995 7
PCA-Elman	0.882 2	0.794 3	0.995 9
LSTM	0.677 1	0.531 2	0.997 5

表 5 不同预测模型下多云天气的预测误差
Tab. 5 Prediction errors of cloudy weather under different prediction models

预测模型	RMSE 值	MAE 值	R^2
GRA-IWOA-LSTM	1.086 2	1.541 3	0.982 9
GRA-WOA-LSTM	1.805 1	1.147 0	0.976 7
PCA-LSTM	1.681 8	1.124 1	0.979 7
PCA-Elman	1.772 5	1.188 8	0.977 8
LSTM	2.260 5	1.632 9	0.963 3

通过分析表 3 可知, 与未经过特征降维和相似日处理的 IWOA-LSTM 预测模型相比, 经过

表 6 不同预测模型下雨天的预测误差

Tab. 6 Prediction errors of rainy days with different prediction models

预测模型	RMSE 值	MAE 值	R^2
GRA-IWOA-LSTM	0.857 8	0.587 5	0.974 4
GRA-WOA-LSTM	1.016 9	0.631 9	0.964 1
PCA-LSTM	1.413 4	0.881 8	0.930 6
PCA-Elman	1.159 8	0.897 5	0.952 9
LSTM	1.476 5	0.950 7	0.924 3

Pearson 特征降维和 GRA 相似日选取后再进行光伏功率预测可以大大缩短预测时间, 提高预测效率。

通过图 4(a)—(c) 和表 5—6 的模型评价指标可知, 由于晴天天气波动小, 光伏输出功率曲线平滑, 波动小, 各个模型都能较好地拟合真实值曲线, 与 GRA-WOA-LSTM 预测模型、PCA-LSTM 预测模型、PCA-Elman 预测模型以及 LSTM 预测模型的预测效果相比, GRA-IWOA-LSTM 预测模型的 RMSE 值分别降低了 44.99%、70.90%、70.80%、61.96%; MAE 值分别降低了 45.23%、68.39%、75.44%、63.27%; R^2 分别提高了 0.08%、0.39%、0.37%、0.21%。

通过图 4(b)—(c)、表 5—6 模型评价指标可知, 当天气发生突变时或者天气为雨天时, 光伏输出功率曲线波动较大, 各个模型的预测精度都有所降低, 但与其他模型相比, GRA-IWOA-LSTM 预测模型仍然可以保持较好的预测精度, 曲线的拟合度依然可以保持在 0.97 以上。

5 结论

本文针对目前光伏输出功率预测精度低/鲁棒性不好的问题, 在充分考虑天气因素对光伏输出功率影响的基础上提出了一种基于相似日的 GRA-IWOA-LSTM 预测模型对光伏输出功率进行短期预测。结合实际光伏电站的历史数据, 进行仿真实验, 得出以下结论。

1) 本文针对影响光伏输出功率的气象特征多波动性大的问题, 采用皮尔逊法进行特征选择以达到特征降维的目的。采用 GRA 进行相似日选取, 降低了模型训练集的复杂度, 进一步缩短了预测时间。

2) 本文提出了一种改进鲸鱼优化算法来快速得到 LSTM 神经网络更优的超参数。改进的鲸鱼优化

算法解决了传统鲸鱼优化算法容易陷入局部最优、收敛精度低以及收敛速度慢的问题。

3) 本文提出 IWOA-LSTM 模型考虑天气特征对光伏输出功率的影响, 采用改进鲸鱼算法优化 LSTM 网络的超参数, 使得预测模型具有较强的鲁棒性。

本次研究所提出的预测模型有效提高了光伏功率预测精度和模型鲁棒性, 对电力系统及光伏发电系统的经济调度和优化运行都有重要意义。

参考文献

- [1] ZAZOUM B. Solar photovoltaic power prediction using different machine learning methods[J]. Energy Reports, 2022(8): 19–25.
- [2] 龚莺飞, 鲁宗相, 乔颖, 等. 光伏功率预测技术[J]. 电力系统自动化, 2016, 40(4): 140–151.
GONG Yingfei, LU Zongxiang, QIAO Ying, et al. An overview of photovoltaic energy system output forecasting technology[J]. Automation of Electric Power Systems, 2016, 40(4): 140–151.
- [3] 彭宇文, 杨之乐, 李冰, 等. 基于 VMD-ISSA-LSTM 的短期光伏发电功率预测[J]. 广东电力, 2024, 37(9): 18–26.
PENG Yuwen, YANG Zhile, LI Bing, et al. Short term photovoltaic power generation prediction based on VMD-ISSA-LSTM[J]. Guangdong Electric Power, 2024, 37(9): 18–26.
- [4] 商立群, 李洪波, 侯亚东, 等. 基于 VMD-ISSA-KELM 的短期光伏发电功率预测[J]. 电力系统保护与控制, 2022, 50(21): 138–148.
SHANG Liqun, LI Hongbo, HOU Yadong, et al. Short-term photovoltaic power generation prediction based on VMD-ISSA-KELM[J]. Power System Protection and Control, 2022, 50(21): 138–148.
- [5] 李一, 杨茂, 苏欣. 基于集成聚类及改进马尔科夫链模型的光伏功率短期预测[J]. 南方电网技术, 2023, 17(10): 113–122.
LI Yi, YANG Mao, SU Xin. Short-term prediction of photovoltaic power based on integrated clustering and improved Markov chain model[J]. Southern Power System Technology, 2023, 17(10): 113–122.
- [6] 袁建华, 谢斌斌, 何宝林, 等. 基于 DTW-VMD-PSO-BP 的光伏发电功率短期预测方法[J]. 太阳能学报, 2022, 43(8): 58–66.
YUAN Jianhua, XIE Binbin, HE Baolin, et al. Short term forecasting method of photovoltaic output based on DTW-VMD-PSO-BP[J]. Acta Energetica Solaris Sinica, 2022, 43(8): 58–66.
- [7] 李丰君, 王磊, 赵健, 等. 基于天气融合和 LSTM 网络的分布式光伏短期功率预测方法[J]. 中国电力, 2022, 55(11): 149–154.
LI Fengjun, WANG Lei, ZHAO Jian, et al. Research on distributed photovoltaic short-term power prediction method based on weather fusion and LSTM-net[J]. Electric Power, 2022, 55(11): 149–154.
- [8] 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.
- [9] 张云钦,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, CHEN Qize, JIANG Wenjie, et al. Photovoltaic power prediction model based on EMD-PCA-LSTM[J]. Acta Energiæ Solaris Sinica, 2021, 45(9):62–69.
- [10] 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 short term memory with dual-stage attention mechanism[J]. Automation of Electric Power Systems, 2021, 45(3):174–182.
- [11] 张娜,冬雷,纪德洋,等.基于NWP相似性分析的超短期光伏发电功率预测[J].太阳能学报,2022,43(4):142–147.
- ZHANG Shan, DONG Lei, JI Deyang, et al. Power forecasting of ultra-short-term photovoltaic station based on NWP similarity analysis[J]. Acta Energiæ Solaris Sinica, 2022, 43(4):142–147.
- [12] CHEN Hailang, CHANG Xianfa. Photovoltaic power prediction of LSTM model based on Pearson feature selection[J]. Energy Reports, 2021(7):1047–1054.
- [13] LI Zheng, XU Ruosi, LUO Xiaorui, et al. Short-term photovoltaic power prediction based on modal reconstruction and hybrid deep learning model[J]. Energy Reports, 2022(8):9919–9932.
- [14] 文立,钟永.光伏发电功率预测中数据预处理方法[J].中国科技信息,2022(19):132–134.
- WEN Li, ZHONG Yong. Data preprocessing method in photovoltaic power generation forecasting[J]. China Science and Technology Information, 2022(19):132–134.
- [15] 叶家豪,魏霞,黄德启,等.基于灰色关联分析的BSO-ELM-AdaBoost风电功率短期预测[J].太阳能学报,2022,43(3):426–432.
- YE Jiahao, WEI Xia, HUANG Deqi, et al. Short-term forecast of wind power based on BSO-ELM-ADABOOST with grey correlation analysis[J]. Acta Energiæ Solaris Sinica, 2022, 43(3):426–432.
- [16] MIRJALILI S, LEWIS A. The whale optimization algorithm[J]. Advances in Engineering Software[J], 2016(95):51–67.
- [17] LIN Xiankun, YU Xianxing, LI Weidong. A heuristic whale optimization algorithm with niching strategy for global multi-dimensional engineering optimization[J]. Computers & Industrial Engineering, 2022(171):108361.
- [18] SUN Yongjun, WANG Xilu, CHEN Yahuan, et al. A modified whale optimization algorithm for large-scale global optimization problems[J]. Expert Systems with Applications, 2018(114):563–577.
- [19] NADIMI-SHAHRAKI M H, ZAMANI H, MIRJALILI S. Enhanced whale optimization algorithm for medical feature selection: A COVID-19 case study[J]. Computers in Biology and Medicine, 2022(148):105858.
- [20] 韩旭明,邱兵,刘翹铭,等.基于柯西变异的果蝇优化算法[J].微电子学与计算机,2017,34(11):26–30.
- HAN Xuming, QIU Bing, LIU Qiaoming, et al. Fruit fly optimization algorithm on Cauchy mutation[J]. Microelectronics & Computer, 2017, 34(11):26–30.
- [21] ZHAO Xinchao, GAO Xiaoshan, HU Zechun. Evolutionary programming based on non-uniform mutation[J]. Applied Mathematics and Computation, 2007, 192(1):1–11.
- [22] PHAN Quocthang, WU Yuankang, PHAN Quocdung, et al. A novel forecasting model for solar power generation by a deep learning framework with data preprocessing and postprocessing[J]. IEEE Transactions on Industry Applications, 2022, 59(1):220–231.
- [23] GAO Mingming, LI Jianjing, HONG Feng, et al. Short-term forecasting of power production in a large-scale photovoltaic plant based on LSTM[J]. Applied Sciences, 2019, 9(15):3192–3206.
- [24] CHEN Biaowei, LIN Peijie, LAI Yunfeng, et al. Very-short-term power prediction for PV power plants using a simple and effective RCC-LSTM model based on short term multivariate historical datasets[J]. Electronics, 2020, 9(2):280–289.
- [25] AKHTER M N, MEKHILEF S, MOKHLIS H. A hybrid deep learning method for an hour ahead power output forecasting of three different photovoltaic systems[J]. Applied Energy, 2022(307):118185–118195.
- [26] 康田雨,覃智军.基于超参数优化和双重注意力机制的超短期风电功率预测[J].南方电网技术,2022,16(5):44–53.
- KANG Tianyu, QIN Zhijun. An ultra-short-term wind power forecasting method based on hyperparameter optimization and dual-stage attention mechanism[J]. Southern Power System Technology, 2022, 16(5):44–53.
- [27] GUANOLUISA-PINEDA R, IBARRA A, ARCOS-AVILES D, et al. Short-term forecasting of photovoltaic power in an isolated area of Ecuador using deep learning techniques[C]// International Conference on Renewable Energy Research and Application, September 18–21, 2022, Istanbul, Turkey. New York: IEEE, 2022:408–413.
- [28] LI Qing, ZHANG Xinyan, MA Tianjiao, et al. A multi-step ahead photovoltaic power forecasting model based on time GAN, soft DTW-based K-medoids clustering, and a CNN-GRU hybrid neural network[J]. Energy Reports, 2022(8):10346–10362.
- [29] 黄旭锐,于丰源,杨波,等.基于Transformer网络和多任务学习的园区综合能源系统电-热短期负荷预测方法[J].南方电网技术,2023,17(1):152–160.
- HUANG Xurui, YU Fengyuan, YANG Bo, et al. Short-Term electric-thermal load forecasting method for park-level integrated energy system based on transformer network and multi-task learning[J]. Southern Power System Technology, 2023, 17(1):152–160.

收稿日期:2023-03-24;网络首发日期:2023-11-21

作者简介:

薛阳(1976),男,副教授,硕士生导师,博士,研究方向为微电网协调控制、光伏发电、微网能量管理, xueyang@shiep.edu.cn;

李金星(1998),女,硕士研究生,研究方向为光伏功率预测、深度学习, 1712412672@qq.com;

杨江天(1998),男,硕士研究生,研究方向为智能微电网, 1349458457@qq.com。