

基于 VMD-MWOA-ELM 的日前光伏功率预测

刘丽桑^{1,2}, 郭凯琪^{1,2}, 陈健^{1,2}, 郭琳³

(1. 福建工程学院 电子电气与物理学院, 福建 福州 350118;

2. 工业自动化福建省高校工程研究中心, 福建 福州 350118;

3. 国网福建省供电有限公司永春县供电公司, 福建 泉州 362600)

摘要: 为了提高光伏发电功率的预测精度, 提出一种结合变分模态分解、多策略改进的鲸鱼优化算法和极限学习机的光伏日前预测方法。利用变分模态分解影响光伏功率的关键气象因素, 获得不同特征规律的本征模态分量, 降解了数据的随机波动性, 减少了噪声的影响。引入鲸鱼优化算法, 利用多策略改进的鲸鱼优化算法 (MWOA) 对 ELM 模型的权重和偏置系数进行优化, 获得最终的光伏功率预测结果。仿真结果验证了所提方法的有效性与优越性。

关键词: 相关性分析; 变分模态分解; 多策略改进的鲸鱼优化算法; 极限学习机; 光伏发电功率预测

中图分类号: TM615

文献标志码: A

文章编号: 1672-4348(2023)03-0269-08

Prediction of day-ahead photovoltaic power generation based on VMD-MWOA-ELM

LIU Lisang^{1,2}, GUO Kaiqi^{1,2}, CHEN Jian^{1,2}, GUO Lin³

(1. School of Electronic, Electrical Engineering and Physics, Fujian University of Technology, Fuzhou 350118, China;

2. Automation Engineering Research Center of Colleges and Universities in Fujian, Fuzhou 350118, China;

3. Yongchun Power Supply Company, State Grid Power Supply CO., Ltd., Quanzhou 362600, China)

Abstract: In order to improve the prediction accuracy of photovoltaic power generation, a photovoltaic day-ahead prediction method combining variational mode decomposition, multi-strategy improvement whale optimization algorithm and extreme learning machine (ELM) was proposed. By utilizing variational mode decomposition to decompose key meteorological factors that affect photovoltaic power, the intrinsic mode components with different characteristic patterns were obtained, which degraded the random volatility of the data and reduced the impact of noise. The final photovoltaic power prediction results were obtained by introducing the multi-strategy improvement whale optimization algorithm (MWOA) to optimize the weights and bias coefficients of the ELM mode. The simulation results validated the effectiveness and superiority of the proposed method.

Keywords: correlation analysis; variational mode decomposition; multi-strategy improved whale optimization algorithm; extreme learning machine; PV power prediction

光伏作为一种新能源, 具有低生产成本、清洁无污染的优势, 但是光伏发电受气象条件变化的影响波动很大, 为了提高光伏利用的可靠性, 需要光伏发电功率预测精度更加精确^[1-2]。单一的人工智能预测方法受模型自身特性限制无法实现较好的预测性能, 结合多种模型的混合预测方法能够综合各单一预测模型的优点、弥补缺陷, 有效提

高预测精度^[3]。国内外学者从预测输入、预测算法、预测输出多环节对混合模型预测进行优化, 文献[4]使用密度峰值法 (density peaks clustering, DPC) 对 K-means 初始聚类中心和聚类数目的选取过程进行优化, 建立 ELM 预测模型实现日前光伏发电功率的预测。文献[5]利用遗传算法优化 BP 神经网络的阈值和权值的初始分布, 对光伏电

收稿日期: 2023-04-20

基金项目: 福建省科技厅自然科学基金 (2022J01952); 福建省科技厅高校产学研合作项目 (2022H6005)

第一作者简介: 刘丽桑 (1984—), 女, 福建莆田人, 副教授, 博士, 研究方向: 智能配网及新能源出力预测技术。

站一天的出力数据进行预测,发现引入智能搜索算法不仅可以提高了预测精度,也提高了计算效率。数据解构技术与预测模型相结合的方法,如经验模态分解 (empirical mode decomposition, EMD)、集合经验模态分解 (ensemble empirical mode decomposition, EEMD) 和小波变换 (wavelet transform, WT) 经常被应用于辐照度预测^[6],然而小波变换的基本函数必须通过人为设置,预测的灵活性不足,对个体主观性的过度依赖。文献[7]利用经验模态分解进行数据重构,利用 GWO 算法优化 BP 神经网络超参数,建立了 GWO-EEMD-BP 神经网络预测模型,有效提升不同复杂气候环境下的预测精度。文献[8]通过实验证明了 CEEMDAN-CNN-LSTM 模型在不同气候条件下均可有效提高预测性能,其经验模态衰减更具适应性,可以更好地保持空间和时间特征。虽然通过添加白噪声可使得重构信号中的噪声残余更小,但是 CEEMDAN 分解方法仍存在模态混叠问题。文献[9]证实了 VMD 分解效率高于 EMD 和 WT 分解,VMD 具有较好抗噪能力,可以自适应更新各 IMF 的最优中心频率和带宽,克服 EMD 频率混叠的问题。

综上,要提高日前光伏发电功率预测精度需全面考虑光伏发电量的影响因素。本研究利用 VMD 算法的优势对影响光伏功率的关键环境因素进行分解,结合 MWOA 优化算法设计极限学习机 (extreme learning machine, ELM) 神经网络结构,建立 VMD-MWOA-ELM 预测模型,得到最终光伏发电功率预测结果,可提高预测精度。

1 方法原理

1.1 皮尔逊相关系数

皮尔逊相关系数是用于度量两组数据 X, Y 之间的相关性,其值介于 $-1 \sim 1$ ^[10]。皮尔逊相关系数不受变量的位置和测量尺度影响,被广泛应用于新能源功率预测领域的清洗、特征分析、降维、相似日提取等。皮尔逊相关系数的公式如式(1)所示。

$$\rho = \frac{\text{cov}(X, Y)}{\sigma_X \sigma_Y} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (1)$$

式中, $\text{cov}(X, Y)$ 表示变量 X 和 Y 的协方差, σ_X 和 σ_Y 分别表示两变量的标准差, \bar{x}, \bar{y} 分别为 X 和 Y

的均值, n 是输入时序变量长度, $i \in [1, n]$ 。相关系数 ρ 描述了两个变量 X 和 Y 之间的线性相关程度, ρ 的绝对值越大,说明变量的相关性越强。 ρ 大于 0 说明均呈正相关,小于 0 说明呈负相关^[11-13]。

1.2 变分模态分解

光伏发电功率是一个不规则的序列,可分为多个子序列进行独立预测,以降低复杂性,提高预测准确度。EMD 是常用的信号分解方法之一,但是分出的本征模态分量 (intrinsic mode functions, IMF) 涵盖频段宽,容易出现模态混沌。EEMD、CEEMD、CEEMDAN 等通过加入白噪声来缓解模态混叠的问题,但是加入白噪声后分解时长大大加长。VMD 将每个分量的估计带宽之和最小化,为了解决优化问题,引入惩罚因子和拉格朗日乘数将约束变分问题转化为非约束变分问题。式(2)为非约束变分模型:

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \|\partial_t [(\delta(t) + \frac{j}{\pi t}) * u_k(t)] e^{-j\omega_k t}\|_2^2 + \|f(t) - \sum_k u_k(t)\|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \quad (2)$$

式中, α 表示惩罚因子, λ 表示拉格朗日乘子, ∂_t 表示偏导, $\delta(t)$ 为单位脉冲函数, $u_k(t)$ 表示 K 个分量, $f(t)$ 表示光伏功率的时间序列, $e^{-j\omega_k t}$ 表示单边际谱的指数信号。

根据式(2)利用交替方向乘子技术生成的每个 IMF 频域的更新,如式(3):

$$\hat{u}_k^{n+1}(\omega) = \frac{f(\omega) - \sum_{i\omega, i \neq k} \hat{u}_i^{n+1}(\omega) - \sum_{i\omega, i \geq k} \hat{u}_i^n(\omega) + \frac{\hat{\lambda}_i^n(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (3)$$

最终收敛得到具有中心频率的模态分量,并通过式(4)和(5)更新参数到满足公式(6)迭代条件终止,得到最优解。

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega} \quad (4)$$

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \gamma [\hat{f}(\omega) - \sum_{k=1}^n \hat{u}_k^{n+1}(\omega)] \quad (5)$$

$$\sum_{k=1}^K \left(\frac{\|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} \right) < \varepsilon \quad (6)$$

式中, ω 表示频率, 上标 \wedge 表示傅里叶变换, n 表示迭代次数, γ 为噪声容差, 当信号中含有较强的噪声时, 可设置 $\gamma=0$ 以达到较好的去噪效果。

1.3 ELM 模型

ELM 是一种单隐层监督学习方法网络结构, 如图 1 所示。ELM 模型随机生成对应输入的权重, 该权重集成了输入信息和隐藏层节点, 表现出显著的估计精度。ELM 优于单隐层前馈神经网络, 在复杂系统的非线性信息行为建模方面表现出色^[14]。由于隐层的映射函数已经已知, 训练模型所需要的只是输出矩阵上的权重, 从而使 ELM 成为一个快速学习器。ELM 实现简单, 无需在训练前人为设置大量训练参数; 而且其泛化性好, 不容易生成局部最优解。

为了估计光伏电站的发电量, 假设训练样本 $(\mathbf{x}_i, \mathbf{y}_i)$, 输入变量 $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{iN}]^T \in \mathbf{R}^N$, 预期输出 $\mathbf{y}_i = [y_{i1}, y_{i2}, \dots, y_{im}]^T \in \mathbf{R}^m$ 。ELM 模型的数学表达式为:

$$Y_j = \sum_{i=1}^n \beta_i G(\omega_i X_j + v_i) \quad j = 1, 2, \dots, n \quad (7)$$

式中, ω_i, β_i 分别为输入和输出层的权重; v_i 是隐藏层偏置; $G(x)$ 是激活函数。

$$\mathbf{H}_{\omega, v, X} \boldsymbol{\beta} = \mathbf{T} \quad (8)$$

式中, \mathbf{T} 是期望的输出向量, $\mathbf{H}_{\omega, v, X}$ 是输出的隐式层矩阵, 可以表示为:

$$\mathbf{H}_{\omega, v, X} = \begin{bmatrix} G(\omega_1 X_1 + v_1) & \cdots & G(\omega_i X_1 + v_i) \\ \vdots & \ddots & \vdots \\ G(\omega_1 X_n + v_1) & \cdots & G(\omega_i X_n + v_i) \end{bmatrix} \quad (9)$$

如公式 (10) 所示, 通过求取 Moore-Penrose 广义逆矩阵求得隐含层到输出层的权值。

$$\boldsymbol{\beta}^* = \mathbf{H}^+ \mathbf{T} \quad (10)$$




图 1 ELM 网络结构图

Fig.1 ELM network structure diagram

1.4 鲸鱼优化算法

WOA 是受座头鲸寻找食物策略启发的三阶段优化方法。其中, 每条鲸鱼代表一个个体, 其在搜索空间中的位置是所寻求的问题的解决方案。鲸鱼种群在围绕猎物时的最佳位置是鲸鱼最接近猎物的地方。起初, 鲸鱼通过主动寻找猎物来了解猎物信息。然后, 鲸鱼继续朝着猎物螺旋式前进, 在这个过程中包围猎物, 直到它们找到猎物, 即找到解决困境的最佳方案。整个过程包括了包围猎物、泡网捕食和寻找猎物^[15-16], 伪代码如算法 1 所示。

算法 1: 基本鲸鱼优化算法	
1.	设置种群规模 N , 迭代次数 T , 问题维度 D .
2.	初始化种群 $X_i (i = 1, 2, \dots, N)$
3.	While $t < T$ do
4.	检查是否有鲸鱼超出了搜索空间并进行修改
5.	计算每条鲸鱼的饥饿值(适应度值), 并找到吃的最饱的鲸鱼 X^*
6.	for $i = 1$ to N do
7.	update a, A, C, l
8.	if $p < 0.5$ then
9.	if $ A < 1$ then
10.	根据 $\vec{X}(t+1) = \vec{X}^*(t) - \vec{A} \times \vec{D}$ 执行收缩包围策略
11.	else
12.	根据 $\vec{X}(t+1) = \vec{X}_{\text{rand}}(t) - \vec{A} \cdot \vec{D}_{\text{rand}}$ 执行搜索猎物策略
13.	end if
14.	else
15.	根据 $\vec{X}^*(t) + D \times e^{bl} \times \cos(2\pi l)$ 执行螺旋更新策略
16.	end if
17.	end for
18.	$t = t + 1$
19.	end while
20.	返回最优解 X^*

1.5 多策略改进鲸鱼优化算法

1.5.1 准反向学习初始化群体

基本的鲸鱼优化算法使用随机初始化方法,这种方法随机性极高,不能保证初始种群的多样性。本研究通过改进反向学习方法,如公式(11)实现的准反向学习方法来初始化种群,提高种群多样性。

$$\hat{x}_i^j = \begin{cases} \text{rand}(\text{avg}_i^j, x_i^j) & x_i^j \leq \text{avg}_i^j \\ \text{rand}(\hat{x}_i^j, \text{avg}_i^j) & x_i^j > \text{avg}_i^j \end{cases} \quad (11)$$

式中, $\text{avg}_i^j = \frac{b_i^j - a_i^j}{2}$, (a, b) 表示 a 和 b 之间的随机数。

1.5.2 指数型收敛因子

基本的 WOA 优化算法中,在包围捕食时,收敛因子的线性变化效率较低。本研究提出了一种非线性收敛因子,将线性收敛因子修改为非线性收敛因子,有利于在全局搜索和局部利用之间达成妥协。

$$a = 2 - 2 * \frac{e^{\frac{t}{\text{max_iter}} - 1}}{e - 1} \quad (12)$$

式中, max_iter 是迭代的最大数量; t 表示迭代次数的值; a 是控制参数,如果不再迭代, a 最终将稳定在 0 上。

1.5.3 自适应权重

设计了自适应权重 ω ,在基础鲸鱼算法更新过程中加入自适应策略,通过提高局部搜索能力来提高鲸鱼优化算法的收敛精度。

$$\omega = 1 - \frac{2}{\pi} \arcsin\left(\frac{t}{\text{max_iter}}\right) \quad (13)$$

当 $p < 0.5$ 且 $|A| < 1$ 时,在收缩包围阶段引入自适应权重 ω ,如公式(14)所示:

$$\vec{X}(t+1) = \omega \times \vec{X}^*(t) - \vec{A} \times \vec{D} \quad p < 0.5 \quad (14)$$

当 $p \geq 0.5$ 时,在螺旋更新阶段引入自适应权重,如公式(15)所示:

$$\vec{X}(t+1) = \omega \times \vec{X}^*(t) + \vec{D} \times e^{bl} \times \cos(2\pi l) \quad p \geq 0.5 \quad (15)$$

式中, b 为定义对数螺旋形状的一个常数,鲸鱼以螺旋搜索的形式更新位置,参数 l 为 $[-1, 1]$ 间的随机数, $\vec{X}^*(t)$ 表示第 t 次迭代时的种群最优个体位置。

1.5.4 随机差分

通过随机差分变异策略及时调整鲸鱼优化算法。添加随机扰动,从局部最优中创建逃逸路径避免陷入局部最优的情况,如式(16):

$$X(t+1) = r_1 \times (X^* - X(t)) + r_2 \times (X'(t) - X(t)) \quad (16)$$

其中, r_1, r_2 对应于 0 和 1 之间的随机数; $X'(t)$ 是种群中随机选择的个体。

2 基于 VMD-MWOA-ELM 的日前光伏功率预测模型

为了对具有非线性 and 波动性的光伏功率进行精准预测,本研究结合 VMD 和 ELM 进行预测,同时引入 MWOA 算法优化 ELM 的模型参数,设计了基于 VMD-MWOA-ELM 的光伏日前预测模型,如图 2 所示,其具体步骤如下:

步骤 1:对光伏历史功率数据、气象数据进行数据异常值检测和归一化处理,同时对数据集进行划分,将其分为训练集和测试集。

步骤 2:分析光伏发电功率影响因素,利用皮尔逊相关性分析,选取关键影响因子,减少数据冗余带来的计算成本增大。

步骤 3:对关键的气象影响因素使用 VMD 分解,得到不同频率尺度的 IMF 子序列,降解了数据的随机波动性,减少了噪声的影响。

步骤 4:将分解的各 IMF 分量重构,通过中心频域法分析各气象变量的 VMD 分解次数总和为 29 维,即重构 29 维的特征序列作为新的输入序列集合。

步骤 5:建立 ELM 预测模型。

步骤 6:利用 MWOA 对 ELM 的参数寻优,建立 MWOA-ELM 预测模型,得到最终预测结果。

步骤 7:对不同模型得到的预测结果进行误差分析对比。

3 实验及分析

3.1 数据来源及分析

本研究所用数据集 1 来源于澳大利亚 DKASC Alice Springs 17 号站点收集的 2017 年 12 月至 2018 年 3 月(夏季)的气象特征和能源数据。数据集 2 来源于该站点 2018 年 9 月至 2018 年 12 月(春季)的数据^[17]。因为光伏夜间出力为 0,本研究只考虑 07:00 至 18:00 之间收集的发电量。建立 VMD-MWOA-ELM 组合光伏功率预测模型对夏季度和春季度前 80 d 的历史数据进行训练,随机选择预测未来连续 5 d 的光伏出力数据。

本研究的数据不存在缺失值或异常值。由于不同特征数据的量纲差别很大,既不利于模型训

练,又影响拟合速度,因此需要对历史数据进行 min-max 归一化,转换函数为:

$$X_{\text{norm}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}}$$

(17)

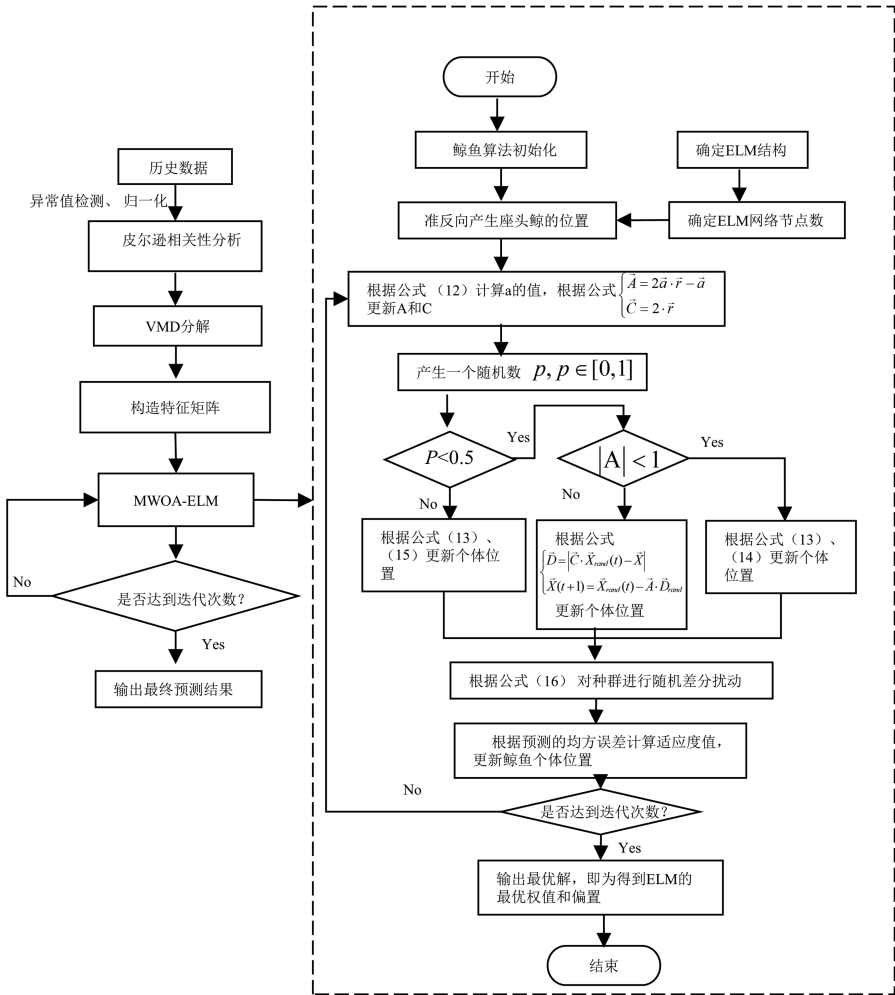


图 2 VMD-MWOA-ELM 模型结构图
Fig.2 Structure of VMD-MWOA-ELM

式中, X_{norm} 为归一化后的结果; X 为特征变量输入值; $X_{\text{max}}, X_{\text{min}}$ 分别为原始数据集中 X 所属影响因素中的最大值和最小值。

根据光伏发电特性可知,数据光伏发电功率不仅与历史时刻自身功率大小密切相关,还与不同时刻的总水平辐射度、散射辐照度、温度、湿度等气象特征密切相关。然而,输入特征维数过多会引入冗余信息,不仅拉长了训练时间还会提高建模难度。在选择输入特征时,应该选择与光伏发电功率关联性较强的因素^[18]。

根据皮尔逊相关系数可得 GHR(总水平辐射度)、DHR(散射水平辐射度)、环境温度、湿度、风速与光伏发电功率的相关系数大小如表 1 所示。

表 1 各气象特征与发电功率之间的相关性
Tab.1 Correlation between meteorological characteristics and power generation

气象特征	功率/kW	相关性	相关程度
GHR	0.953	正相关	强相关性
DHR	0.263	正相关	中等相关性
湿度	-0.414	负相关	中等相关性
环境温度	0.231	正相关	中等相关性
风速	-0.002	负相关	弱相关性
功率	1.000	正相关	完全相关

由表 1 可知,光伏电站数据集中 GHR、DHR、环境温度、湿度与光伏功率具有中等相关性,将中等相关程度及以上的气象特征作为关键影响因素进行 VMD 分解,输入到光伏发电功率预测模型。

3.2 模型参数设置

实验计算机配置为 window10 操作系统,处理器为 Intel(R) Core(TM) i5-11400H,GPU 为 GeForce RTX3050,内存 16 GB,基于 Python3.8 及 Tensorflow2.8 运行环境。

参数 K 对 VMD 算法如何分解原始数据具有影响,通过经验设置可能导致过度的分解损失,并影响预测结果。本研究通过检查每个模式的中心频率是否有相似的值来确定 K 值。当 K 值恒定,并且相邻模式的中心频率从低到高增加了 50% 以上时,认为这两种模式不相似;否则,认为这两种模式相似,惩罚因子数值为 2 000。

表 2 各气象特征的 VMD 分解次数

Tab.2 VMD decomposition times of each meteorological feature

环境因素数据	IMF 分量
GHR	4
DHR	6
湿度	8
环境温度	11

表 2 为经 VMD 算法对 4 种关键环境因素数据分解得到的每种环境因素的 IMF 分量,共计 29 维的特征序列作为新的输入序列集合,MWOA 的初始种群规模为 30,最大迭代次数为 50。ELM 隐含层为 50,初始化输入层与隐含层连接权重范围为 $(-1,1)$,隐含层偏置范围为 $(0,1)$ 。

3.3 模型评价指标

均方根误差 RMSE、平均绝对误差 MAE、相关系数 R^2 这 3 个指标被广泛应用于时间序列预测领域,用来评价神经网络的预测性能和数据特征。它们的定义如公式 (18) 所示,其中 MAE 和 RMSE 的值越小, R^2 值越大表明其预测性能越优。

$$\left\{\begin{aligned} \text{RMSE} &= \sqrt{\frac{1}{N} \sum_{i=1}^N (y_{i\text{real}} - y_{i\text{pred}})^2} \\ \text{MAE} &= \frac{1}{N} \sum_{i=1}^N |y_{i\text{real}} - y_{i\text{pred}}| \\ R^2 &= 1 - \frac{\sum_{i=1}^N (y_{i\text{real}} - y_{i\text{pred}})^2}{\sum_{i=1}^N (y_{i\text{real}} - \bar{y}_{i\text{real}})^2} \end{aligned}\right. \quad (18)$$

式中, $y_{i\text{real}}$ 、 $y_{i\text{pred}}$ 分别为 i 时刻的光伏发电功率真实值和预测值; $\bar{y}_{i\text{real}}$ 为实际光伏发电功率的平均值, N 为测试集数据样本数量。

3.4 预测结果分析

为了验证所提预测模型的有效性和优越性,选取多种典型的回归预测方法与之比较,包括 ELM、SVR 模型,以及结合数据分解和智能优化算法的 VMD-SSA-ELM、VMD-WOA-ELM 模型。对于不同的预测模型的输入均保持一致,共计对应时刻经 VMD 特征分解后的 29 维气象因素为输入量,输出量为光伏发电功率。通过对夏季和春季前 80 d 的历史数据进行训练,随机预测未来连续 5 d 的光伏输出数据,对 2018 年 2 月 24 日~28 日和 2018 年 11 月 26 日~30 日数据进行预测。表 3 显示了上述模型在测试样本数据集中的预测性能比较。

表 3 各模型测试集预测指标对比

Tab.3 Comparison of predictive indicators of each model in test set

季节	预测模型	RMSE	MAE	R^2
夏季	ELM	0.404 5	0.369 6	0.945 0
	SVR	0.594 3	0.562 6	0.881 3
	VMD-ELM	0.342 6	0.315 7	0.960 5
	VMD-SSA-ELM	0.322 5	0.294 3	0.965 0
	VMD-WOA-ELM	0.323 0	0.293 8	0.964 9
	VMD-MWOA-ELM	0.316 8	0.286 4	0.966 3
春季	ELM	0.534 7	0.403 7	0.906 4
	SVR	0.459 6	0.373 0	0.930 8
	VMD-ELM	0.430 1	0.331 4	0.939 4
	VMD-SSA-ELM	0.364 3	0.264 8	0.956 5
	VMD-WOA-ELM	0.381 9	0.269 1	0.952 2
	VMD-MWOA-ELM	0.359 8	0.253 1	0.957 6

由表 3 可知,6 种预测模型均能对光伏功率实现较为准确的预测,但是组合的预测模型预测误差明显小于单一的 ELM、SVR 模型。经过 VMD 分解后的 VMD-ELM 模型的预测性能得到了显著提升。相比于 ELM 模型,VMD-ELM 在夏季和春季的 RMSE 分别下降了 18.07%、24.31%,MAE 分别下降了 17.07%、21.82%, R^2 分别提升了 2%、3.64%。这表明了数据分解不仅避免了模态混叠的现象,而且减少了原始序列的非平稳性和噪声的影响,增加局部多样性,达到了较好的预测效果。

由于光伏发电功率受到气象波动影响大,如图 3(a)所示,在数据集 1 即夏季时令下,光伏发电功率波动相对稳定,通过 VMD 平稳化处理后达到了较好的预测效果;但是如图 3(b)所示,在数据集 2 即春季雨水多发季节时,辐照度变化频率高,应对波动性强的数据时弊端开始显现出来,预测精度不高。相比于 VMD-ELM, VMD-WOA-ELM 在夏季和春季的 RMSE 分别下降了 6.07%、12.62%,MAE 分别下降了 7.45%、23.15%,由此表明,在经过数据分解后,利用智能优化算法优化 ELM 表现出更强的预测性能。而 VMD-MWOA-ELM 具有更强的适应性,相比于 VMD-WOA-ELM 在夏季和春季的 RMSE 分别下降了 1.96%、6.14%,MAE 分别下降了 2.58%、6.32%, R^2 分别提升了 0.15%、0.57%,由此表明经过多策略改进的鲸鱼优化算法 MWOA 相比于 WOA 具有更强的寻优能力,同时相比于其他优化算法 SSA, MWOA 通过准反向初始化、指数型非线性收敛因子、自适应权重和随机差分多策略融合改进,能够在全局寻优和局部寻优之间达到平衡,更快地跳出局部最优,能够更有效地提高 ELM 的预测性能,证明了 VMD-MWOA-ELM 混合模型的优越性和有效性。

不同季节光伏出力差异较大,如图 3(b)所示,春季天气波动大,随机性强,不同模型预测之间得到的光伏发电功率曲线与实际的曲线之间拟合度偏差很大。但相较而言,经过 VMD 平稳化后,利用 MWOA 改进的 ELM 预测模型进行预测,在不同的季度下的预测精度均比较高。




图 3 各种预测模型结果对比

Fig.3 Comparison of results of various prediction models

4 结论

为了提高光伏发电光率日前预测的准确性,本研究提出了一种 VMD-MWOA-ELM 的预测模型,结合实际场景算例,得到结论如下:

- 1)利用 VMD 方法对关键气象影响因素分解,不仅避免了模态混叠的现象,而且减少了原始序列的非平稳性和噪声的影响,增加局部多样性。
- 2)针对 ELM 模型因随机初始化选择超参数不当而预测性能较差的问题,提出利用 MWOA 减少 ELM 随机初始权重和阈值对光伏输出功率预测准确性的影响,相比于利用传统的鲸鱼优化算法和麻雀优化算法,预测的精度更高。
- 3)实际数据的仿真结果表明,所建立模型的均方根误差 RMSE、平均绝对误差 MAE 均都最小。与 SVR、VMD-ELM、VMD-SSA-ELM、VMD-WOA-ELM 等预测模型相比,VMD-WOA-ELM 在夏季和春季的 RMSE 分别下降了 1.96%、6.14%,MAE 分别下降了 2.58%、6.32%, R^2 分别提升了 0.15%、0.57%,提高了光伏日输出功率预测的准确性。但是在波动性强的天气类型下,该算法的预测性能仍需要进一步提高。

为了进一步提高所提出的数据驱动的光伏发电预测模型的性能,扩大其应用范围,未来可结合聚类算法、波动分析等数据挖掘的方式进行天气类型划分,以提高预测精度。

参考文献:

- [1] HE Y T,GAO Q Z,JIN Y Y,et al. Short-term photovoltaic power forecasting method based on convolutional neural network[J]. Energy Reports,2022,8:54-62.
- [2] 左明乐,李培强. 考虑碳排放的综合能源系统经济优化调度[J]. 福建工程学院学报,2022,20(1):83-88.
- [3] 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.
- [4] 李雯,魏斌,韩肖清,等. 基于 DPK-means 和 ELM 的日前光伏发电功率预测[J]. 现代电力,2020,37(4):351-357.
- [5] 肖俊明,韦学辉,李燕斌. 基于 BP 神经网络和遗传算法的光伏功率预测的研究[J]. 计算机测量与控制,2015,23(2):392-393,405.
- [6] LIN W S,ZHANG B,LI H Y,et al. Multi-step prediction of photovoltaic power based on two-stage decomposition and BILSTM[J]. Neurocomputing,2022,504:56-67.
- [7] 文爽,马逸骋,孙志强. 基于 GWO-EEMD-BP 神经网络的光伏发电功率短期预测[J]. 中南大学学报(自然科学版),2022,53(12):4799-4808.
- [8] GAO B X,HUANG X Q,SHI J S,et al. Hourly forecasting of solar irradiance based on CEEMDAN and multi-strategy CNN-LSTM neural networks[J]. Renewable Energy,2020,162:1665-1683.
- [9] QU J Q,QIAN Z,PEI Y. Day-ahead hourly photovoltaic power forecasting using attention-based CNN-LSTM neural network embedded with multiple relevant and target variables prediction pattern[J]. Energy,2021,232:120996.
- [10] WANG R H,LI C S,FU W L,et al. Deep learning method based on gated recurrent unit and variational mode decomposition for short-term wind power interval prediction[J]. IEEE Transactions on Neural Networks and Learning Systems,2020,31(10):3814-3827.
- [11] LUO X,ZHANG D X,ZHU X. Combining transfer learning and constrained long short-term memory for power generation forecasting of newly-constructed photovoltaic plants[J]. Renewable Energy,2022,185:1062-1077.
- [12] 汤德清,朱武,侯林超. 基于 CNN-LSTM-XGBoost 模型的超短期光伏功率预测[J]. 电源技术,2022,46(9):1048-1052.
- [13] 张姗,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.
- [14] AN W B,ZHENG L W,YU J W,et al. Ultra-short-term prediction method of PV power output based on the CNN - LSTM hybrid learning model driven by EWT[J]. Journal of Renewable and Sustainable Energy,2022,14(5):053501.
- [15] 倪安安,王育飞,薛花. 基于混沌特征改进鲸鱼优化算法-相关向量机的超短期光伏发电输出功率预测[J]. 现代电力,2021,38(3):268-276.
- [16] 张荣升,刘丽桑,宋天文,等. 基于鲸鱼优化算法的配电网故障区段定位[J]. 福建工程学院学报,2021,19(4):378-384.
- [17] DKA Solar Centre. DKASC,Alice Springs[EB/OL]. <http://dkasolarcentre.com.au/locations/alice-springs>,2022.
- [18] WANG K J,QI X X,LIU H D. Photovoltaic power forecasting based LSTM-Convolutional Network[J]. Energy,2019,189:116225.

(责任编辑:方素华)