

DOI:10.19783/j.cnki.pspc.241500

基于二次模态分解重构及 BiTCN-BiGRU 模型的光伏短期发电功率预测

文斌^{1,2}, 章学勤¹, 付文龙^{1,2}, 丁弈夫³, 封宣宇¹

(1. 三峡大学电气与新能源学院, 湖北 宜昌 443002; 2. 梯级水电站运行与控制湖北省重点实验室(三峡大学), 湖北 宜昌 443002; 3. 国网重庆市电力公司南川供电分公司, 重庆 408400)

摘要: 针对光伏功率序列具有非平稳性和波动性的特点导致预测模型预测精度偏低的问题, 提出一种基于二次模态分解重构、双向时序卷积网络(bidirectional temporal convolutional network, BiTCN)-双向门控循环单元(bidirectional gated recirculation unit, BiGRU)组合模型及与多策略改进沙猫群优化算法(multi-strategy improved sand cat swarm algorithm, MSCSO)相结合的光伏短期发电功率预测方法。首先, 利用 Spearman 相关系数选取气象特征作为模型输入, 并采用模糊 C 均值聚类方法进行相似日分类。其次, 采用改进完全集合经验模态分解、变分模态分解对光伏功率序列进行分解并采用样本熵对分量进行重构。最后, 建立 BiTCN-BiGRU 组合预测模型进行预测并通过 MSCSO 优化模型参数, 将各分量预测结果叠加得到最终光伏功率预测值。通过与多种预测模型在不同天气条件和不同地区的对比分析, 验证了所提模型具有更高的预测精度和良好的适应性。

关键词: 二次模态分解重构; 沙猫群算法; 双向时序卷积网络; 双向门控循环单元; 光伏功率预测

Short-term PV power generation forecasting based on quadratic mode decomposition reconstruction and BiTCN-BiGRU model

WEN Bin^{1,2}, ZHANG Xueqin¹, FU Wenlong^{1,2}, DING Yifu³, FENG Xuanyu¹

(1. College of Electrical Engineering and New Energy, China Three Gorges University, Yichang 443002, China; 2. Hubei Provincial Key Laboratory for Operation and Control of Cascaded Hydropower Station (China Three Gorges University), Yichang 443002, China; 3. Nanchuan Power Supply Branch, State Grid Chongqing Electric Power Company, Chongqing 408400, China)

Abstract: To address the issue of low prediction accuracy caused by the unstable and fluctuating characteristics of photovoltaic (PV) power generation, a short-term PV power forecasting method is proposed. The method integrates quadratic mode decomposition reconstruction (QMDR), a bidirectional temporal convolutional network (BiTCN) and bidirectional gated recirculation unit (BiGRU) combined model, and a multi-strategy improved sand cat swarm optimization algorithm (MSCSO). First, meteorological features are selected as model inputs using the Spearman correlation coefficient, and fuzzy C-mean clustering method is applied for similar-day classification. Next, the PV power series are decomposed by improved complete ensemble empirical modal decomposition and variational modal decomposition, and the components are reconstructed by sample entropy. Finally, a combined prediction model of BiTCN-BiGRU is established, with the parameters of the model optimized by MSCSO. The final PV power prediction is obtained by superimposing the forecasts of each constructed component. Comparative analyses under different weather conditions and across different regions verify that the proposed model has higher prediction accuracy and better adaptability than existing approaches.

This work is supported by the National Natural Science Foundation of China (No. 62273200).

Key words: quadratic modal decomposition reconstruction; sand cat swarm optimization; bidirectional temporal convolutional networks; bidirectional gated recirculation unit; PV power prediction

基金项目: 国家自然科学基金项目资助(62273200); 湖北省输电线路工程技术研究中心研究基金项目资助(2022KXL03); 湖北省自然科学基金联合基金项目资助(2024AFD409)

0 引言

光伏发电因能够有效缓解能源短缺和环境污染,在全世界范围内得到了广泛应用^[1-4]。然而,光伏发电具有非平稳性和波动性的特点,光伏发电功率受多种因素影响,其波动性和不确定性给大规模并网的安全稳定运行带来了挑战^[5-6]。因此,研究提高光伏发电功率预测精确性的方法具有重要意义。

在早期的研究中,光伏功率预测方法分为物理模型法和统计模型法^[7]。物理模型法首先根据光伏电站的参数、历史发电数据和历史气象数据拟合功率输出特性曲线,再根据数值天气预报数据预测光伏发电功率^[8]。统计模型通过数学模型分析历史数据实现对光伏功率的预测^[9],常见的统计模型包括马尔科夫链^[10]、支持向量机^[11]、极限学习机^[12]等。文献[13]采用核极限学习机对不同天气类型下的光伏功率进行预测,并采用改进阿基米德算法对核极限学习机的参数进行优化,然而在处理较为复杂的非线性时序数据时,传统机器学习方法难以挖掘数据间深层次的特征,这在一定程度上限制了模型的预测精度。随着深度学习的发展,神经网络模型^[14-15]在光伏功率预测领域受到广泛关注。典型的方法包括卷积神经网络、循环神经网络及其变体,如文献[16-17]采用长短期记忆网络(long short term memory, LSTM)预测光伏功率序列,并采用优化算法优化模型参数;门控循环单元^[18](gated recurrent unit, GRU)基于 LSTM 模型进行优化,简化了网络结构,从而减少了参数量;双向门控循环单元^[19](bidirectional gated recurrent unit, BiGRU)由正向和反向的 GRU 组成,能够提取序列双向的时间特征,提高了特征提取能力和模型的预测精度。

然而,光伏功率序列的随机波动特性,使得单一的预测模型往往不能充分获取序列特征,导致预测结果精度偏低。对此,一些学者提出了一些组合方法,利用不同模型的优点克服单一模型的局限性。文献[20]提出时序卷积神经网络(temporal convolutional network, TCN)和 GRU 的组合预测模型,利用 TCN 提取光伏功率的时序特征并输入到 GRU 中进行预测,结果表明相比于 GRU 模型,TCN-GRU 模型的预测精度有了明显的提升,但模型参数的选取依赖经验,使得模型的泛化性能受限。文献[21]提出变分模态分解(variational mode decomposition, VMD)算法分解功率序列,对分解的功率分量进行预测,提高了预测精度,然而 VMD 算法受模态分解个数和惩罚因子影响较大,参数设置不当易导致分解效果不佳。文献[22]提出一种改进完全集合经验模态分解

(improved complete ensemble empirical mode decomposition with adaptive noise, ICEEMDAN)算法分解功率序列,降低序列的复杂性,但高频分量的波动特征依旧明显,影响模型预测效果。

综上所述,光伏功率预测方法存在以下问题。

1) 光伏功率进行一次分解后产生的高频分量仍然具有较高的非平稳性,对其直接预测会使得误差较大。

2) 单一预测模型在处理复杂的非线性长序列时,不能充分提取数据特征,影响预测精度。

3) 模型参数选取不佳影响模型的预测精度并导致模型的泛化性能受限。

针对上述问题,本文提出基于二次模态分解重构(quadratic mode decomposition reconstruction, QMDR)、双向时序卷积网络(bidirectional temporal convolutional network, BiTCN)和双向门控循环单元组合模型(BiTCN-BiGRU)的短期光伏功率预测方法。主要贡献如下。

1) 针对光伏功率具有非平稳性的特点,提出了二次模态分解重构方法。采用改进完全集合经验模态分解对光伏功率进行初步分解,根据样本熵对各个分量进行评估,对高频分量进行组合重构,采用变分模态分解对高频分量进行分解进一步降低高频分量的波动性,再次采用样本熵计算二次分解的分量,将熵值相近的分量进行重构,降低功率分解后高频分量波动的影响,同时减少模型的输入,降低了输入数据的复杂度。

2) 提出了基于融合 Chebyshev 混沌与逆向学习策略、螺旋搜索策略、自适应敏感度和高斯游走策略的改进沙猫群算法(multi-strategy improved sand cat swarm algorithm, MSCSO),该方法提高了种群分布的均匀性与多样性,并促进了算法全局和局部搜索能力间的平衡,有利于跳出局部最优解,增强算法的搜索性能。

3) 建立 BiTCN-BiGRU 组合预测模型,充分提取气象因素和光伏序列的特征,挖掘数据间的相关特征和依赖关系,并采用 MSCSO 算法优化预测模型的参数,提高了预测模型的泛化性能。

1 数据相关性分析与聚类

1.1 气象特征选择

光伏发电功率受到气象因素影响,主要包括太阳辐照度、温度、湿度、气压等,不同的气象因素对光伏发电功率的影响程度不同。为分析气象因素和光伏发电功率的相关性并选取主要气象因素作为模型输入,本文采用 Spearman 相关系数^[23]分析各

气象因素与发电功率的相关程度。Spearman 定义为

$$\rho = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)} \quad (1)$$

式中： ρ 为两个序列的相关程度； d_i 为第 i 个数据样本对应位次值之差； n 为数据样本总数。

本文选取 2018 年宁夏某光伏电站实际数据为例进行相关性分析，影响因素包括太阳总水平辐射、太阳散射辐射、温度、风速、风向、地面气压、相对湿度。根据 Spearman 相关系数计算光伏功率与气象数据的相关性，如表 1 所示。

表 1 光伏功率与气象数据的相关性

Table 1 Correlation of PV power with meteorological data

| 环境因素 | 相关系数 |
|---------|-------|
| 太阳总水平辐射 | 0.96 |
| 太阳散射辐射 | 0.81 |
| 温度 | 0.51 |
| 风速 | 0.06 |
| 风向 | 0.03 |
| 地面气压 | -0.12 |
| 相对湿度 | -0.57 |

由表 1 可知，太阳总水平辐射和太阳散射辐射与发电功率高度相关，对光伏发电功率影响大；温度、相对湿度与发电功率有一定程度的相关性，对光伏发电功率具有一定影响；风速、风向和气压与发电功率的相关性较低，对光伏发电功率影响小。因此，本文选取太阳总水平辐射、太阳散射辐射、温度、相对湿度作为模型的气象特征输入。

1.2 模糊 C 均值聚类算法

由于不同天气类型下的光伏发电功率差异较大，将相似数据进行合理划分有利于提高模型预测精度。本文采用模糊 C 均值聚类(fuzzy C-means clustering, FCM)进行相似日聚类^[24]，FCM 是一种经典的聚类算法，其核心是构建一个包含隶属度和距离度量的目标函数并进行优化，通过迭代更新聚类中心和隶属度，表示为

$$c_j = \frac{\sum_{i=1}^n u_{ij}^m x_i}{\sum_{i=1}^n u_{ij}^m} \quad (2)$$

$$u_{ij} = \sum_{h=1}^c \left(\frac{x_i - c_j}{x_i - c_h} \right)^{\frac{2}{m-1}} \quad (3)$$

式中： x_i 表示第 i 个光伏发电功率数据样本； c_j 、 c_h 表示第 j 、 h 个聚类中心； u_{ij} 表示第 i 个样本属于第 j 类聚类中心的隶属度； c 表示聚类中心个数；

u_{ij}^m 表示对隶属度 u_{ij} 进行 m 次幂运算。

2 多策略改进沙猫群优化算法

2.1 沙猫群优化算法

沙猫群优化(sand cat swarm algorithm, SCSO)算法是一种通过模仿沙猫的生存方式而提出的优化算法^[25]，数学模型如下。

首先根据式(4)在搜索空间中随机生成沙猫的位置，初始化种群。

$$x(p, q) = l_q + \text{rand}(0, 1) \cdot (u_q - l_q) \quad (4)$$

式中： $x(p, q)$ 表示第 p 个沙猫个体在搜索空间中的第 q 维变量； u_q 和 l_q 分别表示第 q 维变量的上界和下界； $\text{rand}(0, 1)$ 表示 $[0, 1]$ 之间的随机数。

沙猫搜寻猎物 and 攻击猎物的机制依赖其对声音频率的感知，沙猫的听觉敏感度 r_G 在 $[0, 2]$ 范围内呈线性变化。沙猫的最大听觉敏感度 $s_M = 2$ ，每只沙猫的听觉敏感度范围为 r ，如式(5)所示。

$$\begin{cases} r_G = s_M(1 - i_t / T_{\max}) \\ r = r_G \times \text{rand}(0, 1) \end{cases} \quad (5)$$

式中： i_t 为当前迭代次数； T_{\max} 表示最大迭代次数。

设 R 作为沙猫搜寻和攻击猎物的平衡参数：

$$R = 2r_G \times \text{rand}(0, 1) - r_G \quad (6)$$

当 $|R| > 1$ 时，沙猫处于搜寻猎物的阶段。每只沙猫根据当前种群中个体的全局最佳位置来更新自己的位置，如式(7)所示。

$$P(i_t + 1) = r \times (P_{bc}(i_t) - \text{rand}(0, 1) \times P(i_t)) \quad (7)$$

式中： $P_{bc}(i_t)$ 和 $P(i_t)$ 分别为第 i_t 次迭代全局最佳位置和个体位置； $P(i_t + 1)$ 为第 $i_t + 1$ 次迭代个体位置。

当 $|R| \leq 1$ 时，沙猫对猎物进行攻击。通过轮盘选择算法更新 $P(i_t + 1)$ 和随机位置 P_r ，如式(8)所示。

$$\begin{cases} P_r = |\text{rand}(0, 1) \times P_{bc}(i_t) - P(i_t)| \\ P(i_t + 1) = P_{bc}(i_t) - r \cdot P_r \cdot \cos \theta \end{cases} \quad (8)$$

式中： θ 为随机角度，取值范围是 $[0^\circ, 360^\circ]$ 。

2.2 多策略改进沙猫群优化算法

针对 SCSO 算法前期收敛速度慢和后期容易陷入局部最优解的问题，本文提出一种 MSCSO 以提高算法的优化性能和搜索能力。

1) 融合 Chebyshev 混沌与逆向学习策略

由于 SCSO 算法的初始化种群具有随机性，生成的种群可能聚集在搜索空间中的局部区域，导致算法陷入局部最优解并且可能减缓收敛速度。因此，本文采用融合 Chebyshev 混沌和逆向学习策略进行种群初始化，扩大沙猫的搜索空间，使生成的种群

分布均匀且具有多样性, 如式(9)所示。

$$\begin{cases} m_{i+1} = \cos(\nu \cdot \arccos m_i), m_i \in [-1, 1] \\ m_{\text{new}} = \text{rand}(0, 1) \cdot (u_i + l_i) - m_i \end{cases} \quad (9)$$

式中: ν 表示阶次, 通常取 4; m_{new} 表示对应于 Chebyshev 混沌生成初始解 m_i 的逆向解; u_i 和 l_i 分别表示变量的上界和下界。

2) 螺旋搜索策略

为增强沙猫个体搜寻猎物的能力, 受鲸鱼优化算法启发, 引入螺旋搜索策略, 使沙猫在搜寻猎物阶段能够以螺旋形式包围猎物, 增强了沙猫个体在搜索空间中的搜索能力, 如式(10)所示。

$$P(i+1) = r \cdot e^{i\mu} \cos(2\pi l) [P_{\text{bc}}(i) - \text{rand}(0, 1) \cdot P(i)] \quad (10)$$

式中: μ 为运动系数; l 为 $[-1, 1]$ 之间的随机数。

3) 自适应敏感度

为均衡算法的全局和局部搜索能力, 对敏感度进行非线性改进, 如式(11)所示。由图 1 可知, 改进后的敏感度在算法迭代的前、中期减小缓慢, 能够扩大全局的搜索范围, 增强全局搜索能力; 在迭代后期能够快速减小, 增强算法的局部搜索能力。

$$\begin{cases} r_G = 2 \times [1 - (\frac{e^{i/T_{\text{max}}} - 1}{e - 1})^\eta] \\ \eta = 2 + 0.01i \end{cases} \quad (11)$$

式中: η 为速度衰减因子, 用于控制衰减速度。

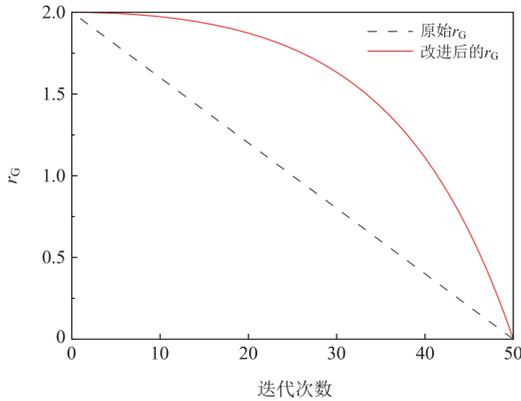


图 1 改进前后敏感度对比

Fig. 1 Comparison of sensitivity before and after improvement

4) 高斯游走策略

在沙猫对猎物发起进攻阶段, 高斯游走策略能够平衡全局搜索和局部开发能力, 有利于算法跳出局部最优解, 如式(12)所示。

$$\begin{cases} P(i+1) = G(P_{\text{bc}}(i), \tau) + (r_1 \cdot P_{\text{bc}}(i) - r_2 \cdot P(i)) \\ \tau = \ln(i_1) \cdot (P(i) - P_{\text{bc}}(i)) / i \end{cases} \quad (12)$$

式中: $G(\cdot)$ 表示高斯分布概率密度函数; r_1 和 r_2 为

$[0, 1]$ 之间的随机数; τ 表示步长。

MSCSO 算法流程图如图 2 所示。

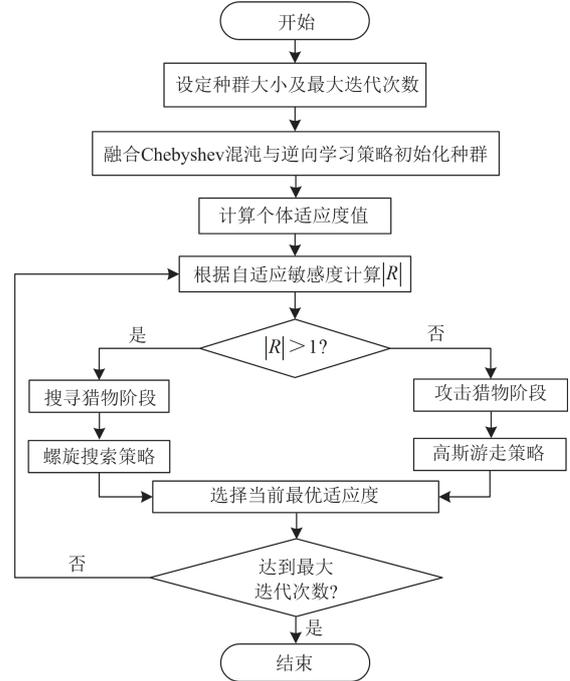


图 2 MSCSO 算法流程图

Fig. 2 MSCSO flow chart

3 模型的建立及相关原理

3.1 改进自适应白噪声的完全集合经验模态分解

为减少 CEEMDAN 分解后本征模态分量存在的模态混叠和失真等问题, ICEEMDAN 分解算法^[26]通过添加均值为 0、方差为 1 的白噪声的方式在 CEEMDAN 基础上进一步改进, 计算过程如下。

1) 定义原始序列 s , $E_k(\cdot)$ 为经验模态分解算法分解原始序列产生的 k 阶模态分量, 如式(13)所示。

$$\begin{cases} s^b = s + \alpha_0 E_1(w^b) \\ \alpha_0 = \varepsilon_0 \text{std}(s) / \text{std}(E_k(w^b)) \end{cases} \quad (13)$$

式中: α_0 为白噪声标准差初值; ε_0 为噪声与序列间信噪比的倒数; w^b 为添加的第 b 组白噪声; s^b 为添加 b 组白噪声后构造的序列; $E_1(\cdot)$ 为分解后的一阶模态分量; $\text{std}(\cdot)$ 为标准差计算;

2) 利用经验模态分解算法分解可得到第一个剩余分量 R_1 和第一个模态分量 I_{IMF1} 。

$$R_1 = \langle M(s^b) \rangle \quad (14)$$

$$I_{\text{IMF1}} = s - R_1 \quad (15)$$

式中: $M(\cdot)$ 表示生成序列的局部均值; $\langle \cdot \rangle$ 表示对序列整体求平均。

3) 加入白噪声, 计算第二个残差分量 R_2 和第二

个模态分量 I_{IMF2} 。

$$R_2 = \langle M(R_1 + \alpha_1 E_2(w^b)) \rangle \quad (16)$$

$$I_{\text{IMF2}} = R_1 - R_2 \quad (17)$$

式中: α_1 为第一组白噪声标准差; $E_2(\cdot)$ 为分解后的二阶模态分量。

4) 同理, 计算第 k 个残差分量 R_k 和模态分量 $I_{\text{IMF}k}$ 。

$$R_k = \langle M(R_{k-1} + \alpha_{k-1} E_k(w^b)) \rangle \quad (18)$$

$$I_{\text{IMF}k} = R_{k-1} - R_k \quad (19)$$

式中: α_{k-1} 为第 $k-1$ 组白噪声标准差; R_{k-1} 为第 $k-1$ 个残差分量。

3.2 VMD 及优化方式

VMD 是一种自适应分解算法^[27], 其可将原始信号分解成一系列具有特定带宽和不同中心频率的本征模态分量。VMD 分解算法的约束变分模型为

$$\begin{cases} \min_{\{u_g\}, \{w_g\}} \left\{ \sum_{g=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_g \right] e^{-jw_g t} \right\|_2^2 \right\} \\ \text{s.t.} \sum_{g=1}^K u_g = f(t) \end{cases} \quad (20)$$

式中: u_g 为第 g 个模态分量; w_g 为第 g 个中心频率; K 为模态数量; ∂_t 为偏导运算; $\delta(t)$ 为单位脉冲函数; t 为当前时刻; “*” 为卷积运算符; $\|\cdot\|_2^2$ 为 2 范数的平方; $f(t)$ 为待分解序列。

引入 Lagrange 算子 $\lambda(t)$ 和惩罚因子 α , 采用交替方向乘子法计算并更新 u_g 、 w_g , 更新表达式如式(21)和式(22)所示。

$$\hat{u}_g^{a+1}(w) = \frac{\hat{f}(w) - \sum_{i=1, i \neq g}^K \hat{u}_i(w) + \frac{\hat{\lambda}(w)}{2}}{1 + 2\alpha(w - w_g)^2} \quad (21)$$

$$w_g^{a+1} = \frac{\int_0^\infty w |\hat{u}_g^{a+1}(w)|^2 dw}{\int_0^\infty |\hat{u}_g^{a+1}(w)|^2 dw} \quad (22)$$

式中: $\hat{u}_g^{a+1}(w)$ 和 w_g^{a+1} 分别为第 g 个模态分量在第 $a+1$ 次迭代时的维纳滤波和中心频率; w 为频率; $\hat{f}(w)$ 、 $\hat{u}_i(w)$ 和 $\hat{\lambda}(w)$ 分别为 $f(t)$ 、 $u_i(t)$ 和 $\lambda(t)$ 的傅里叶变换, $u_i(t)$ 为第 i 个模态分量。

然而 VMD 算法中的模态数量 K 和惩罚因子 α 对最终分解结果的影响较为直接, 依据经验选择参数较为复杂, 步骤繁琐且分解效果不理想。因此,

本文以样本熵^[28]作为适应度函数, 如式(23)所示, 利用 MSCSO 算法对 K 和 α 进行优化。

$$F(K, \alpha) = -\ln \left[\frac{U^d(\zeta)}{V^d(\zeta)} \right] \quad (23)$$

式中: $V^d(\zeta)$ 和 $U^d(\zeta)$ 分别为分解分量在相似容限 ζ 下匹配 d 个点和 $d+1$ 个点的概率。

3.3 双向门控单元

GRU 网络将 LSTM 的遗忘门和输入门合并成一个更新门, 简化了网络结构, 减少了计算参数量, 其计算如式(24)所示, 网络结构如图 3 所示。

$$\begin{cases} z_t = \sigma(W_z x_t + U_z h_{t-1}) \\ r_t = \sigma(W_r x_t + U_r h_{t-1}) \\ \tilde{h}_t = \tanh(W_h x_t + U_h (r_t \otimes h_{t-1})) \\ h_t = (1 - z_t) h_{t-1} + z_t \tilde{h}_t \end{cases} \quad (24)$$

式中: x_t 表示输入数据; W_z 、 W_r 、 W_h 、 U_z 、 U_r 、 U_h 为权重矩阵; h_t 、 h_{t-1} 分别为 t 时刻和 $t-1$ 时刻隐藏层的状态量; $\tanh(\cdot)$ 表示双曲正切函数; \tilde{h}_t 表示中间记忆状态; $\sigma(\cdot)$ 表示 Sigmoid 函数; “ \otimes ” 表示 Hadamard 积; z_t 和 r_t 分别为在 t 时刻更新门和重置门的状态。

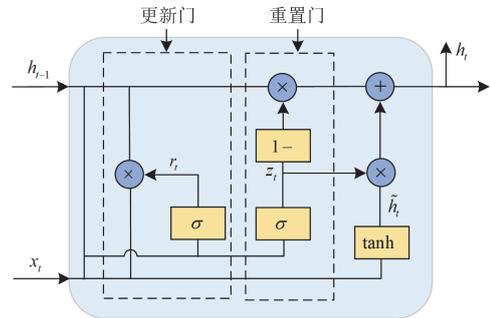


图 3 GRU 网络结构

Fig. 3 GRU network structure

然而, GRU 模型没有考虑数据之间前后的联系和变化规律。因此, 采用双向 GRU 结构, 网络结构如图 4 所示。BiGRU 是由两层 GRU 组成, 一层是前向层, 从序列的起点开始计算, 另一层是反向层, 从序列的末端开始计算, 最后将两层的输出结果进行结合, 得到最终输出。BiGRU 网络模型在 t 时刻的输出 h_t 是由前向层的输出状态 \vec{h}_t 和反向层输出状态 \overleftarrow{h}_t 决定的, 计算公式为

$$\begin{cases} \vec{h}_t = \text{GRU}(x_t, \vec{h}_{t-1}) \\ \overleftarrow{h}_t = \text{GRU}(x_t, \overleftarrow{h}_{t-1}) \\ h_t = \beta_t \vec{h}_t + \gamma_t \overleftarrow{h}_t + b_t \end{cases} \quad (25)$$

式中: $\text{GRU}(\cdot)$ 为门控循环单元; \bar{h}_{t-1} 和 \bar{h}_{t-1} 分别为 $t-1$ 时刻前向层和反向层的输出状态; β_i 和 γ_i 分别为前向层和反向层的输出权重; b_i 为偏置项。

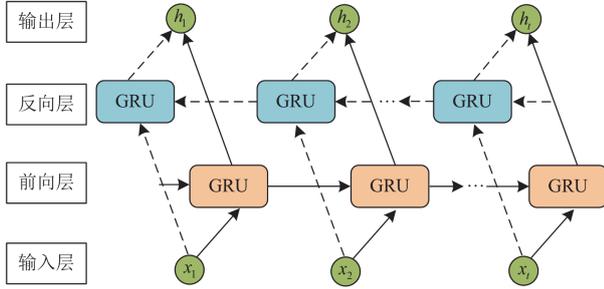


图 4 BiGRU 网络结构

Fig. 4 BiGRU network structure

3.4 双向时序卷积网络

时序卷积网络由扩张因果卷积、残差连接等组成, 结合卷积神经网络和循环神经网络的优点, TCN 能够更有效地提取时序数据的特征。一个 TCN 残差层包含 2 个扩张因果卷积, 扩张因子随着卷积层的层数呈指数型增长, 最终能够以较少的卷积层获得更大的感受野, 有效捕获序列的长时间特征。

然而, 传统的时序卷积网络 TCN 只能对输入的时间序列进行前向卷积计算, 只提取了序列数据的前向特征, 忽略了序列的反向特征。因此, 为了获取更丰富的信息特征, 本文采用双向时序卷积网络 BiTCN 提取序列数据的前向和反向特征, 能够更好地捕捉时间序列中长期的关系, 残差结构如图 5 所示。由图 5 可知, 正序列 $\bar{X} = (x_0, x_1, \dots, x_t)$ 通过 TCN 残差层提取到前向特征, 反序列 $\bar{X} = (x_t, \dots, x_1, x_0)$ 通过 TCN 残差层提取到反向特征, 最终将前向特征和反向特征进行融合输出。

3.5 QMDR-BiTCN-BiGRU 组合预测模型

光伏发电功率受气象因素影响, 使功率数据发生非平稳性波动, 这些波动给光伏功率预测的准确性带来巨大挑战。因此, 本文提出 QMDR-BiTCN-BiGRU 组合预测模型, 整体框架结构如图 6 所示。整体步骤如下。

1) 利用 Spearman 相关系数对环境因素和光伏发电功率进行分析, 筛选出气象特征, 并根据不同天气类型采用 FCM 算法对数据进行聚类。

2) 采用融合 Chebyshev 混沌、逆向学习策略、螺旋搜索策略、自适应敏感度和高斯游走策略对 MSCSO 算法进行改进。

3) 采用 ICEEMDAN 对光伏发电功率数据进行分解, 根据样本熵对分解后的分量进行复杂性分析,

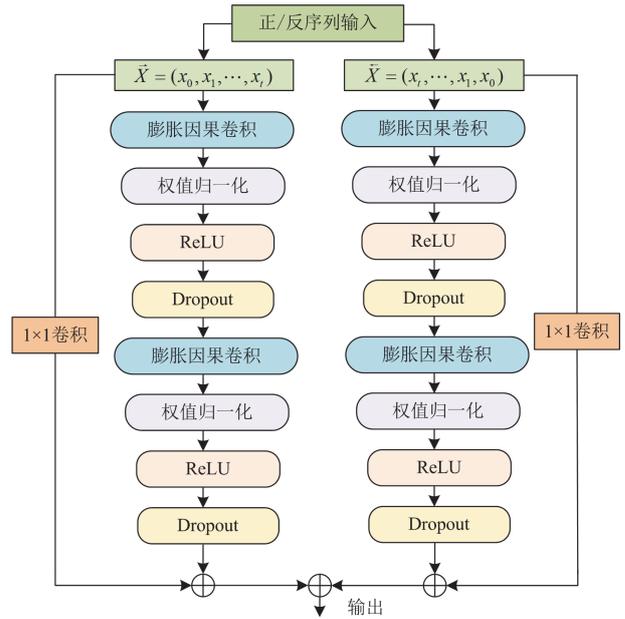


图 5 BiTCN 残差结构

Fig. 5 BiTCN residual structure

根据熵值将模态分量从高到低进行排列, 划分为高频分量、中频分量和低频分量; 将高频分量进行叠加重构, 采用 VMD 算法对重构后的分量进行二次分解, 并以分量的样本熵值作为适应度函数, 使用 MSCSO 算法对 VMD 中的模态数量和惩罚因子进行优化, 得到二次分解后的分量, 进而与一次分解的中、低频分量组合重构得到模态分量集合。

4) 融合模态分量集合与环境因素变量, 并将其共同作为 BiTCN-BiGRU 组合模型的输入, 并采用 MSCSO 算法优化模型的参数, 将预测结果进行叠加, 得到最终预测结果。

其中, 采用 MSCSO 算法对 BiTCN-BiGRU 预测模型中的参数如卷积核数量 n_1 、BiGRU 隐藏层神经元数量 n_2 、学习率 l_0 进行优化, 以均方根误差 (root mean square error, RMSE) 为适应度函数, 即

$$f(n_1, n_2, l_0) = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (26)$$

式中: \hat{y}_i 、 y_i 分别为功率预测值和真实值。

3.6 模型的评估指标

为对模型的预测能力进行评估, 本文采用平均绝对误差 (mean absolute error, MAE) e_{MAE} 和均方根误差 e_{RMSE} 作为评估指标。

$$e_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (27)$$

$$e_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (28)$$

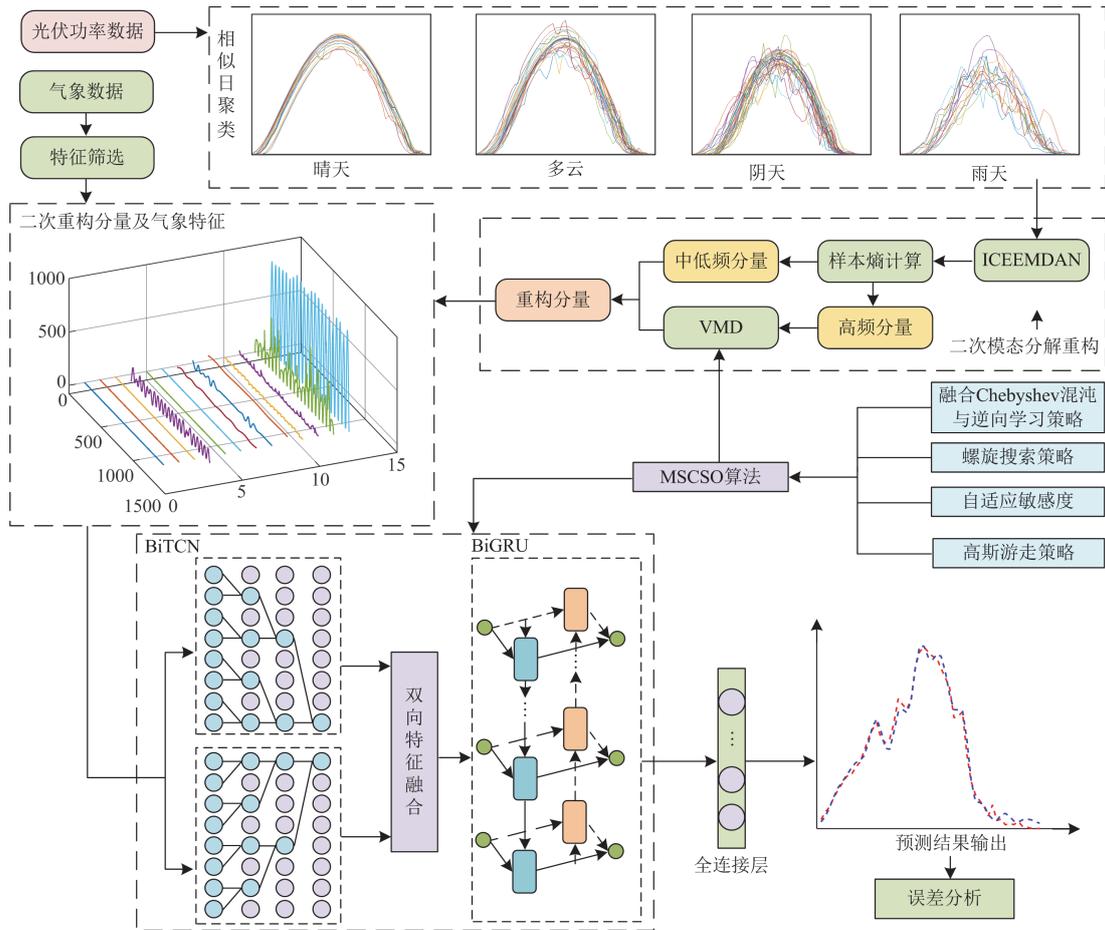


图 6 QMDR-BiTcn-BiGRU 组合预测模型结构图

Fig. 6 Structure of QMDR-BiTcn-BiGRU combined prediction model

4 实例分析及模型验证

4.1 MSCSO 算法性能验证

为验证 MSCSO 算法的寻优性能, 本文选取 CEC-2005 测试函数^[29]的两个单峰测试函数和两个多峰测试函数进行测试, 测试函数参数如表 2 所示。

表 2 测试函数参数

Table 2 Test function parameters

| 目标函数 | 维度 | 自变量范围 | 最优值 |
|--------------------|----|------------|-----------|
| F_1 (Sphere) | 30 | [-100,100] | 0 |
| F_2 (Rosenbrock) | 30 | [-30,30] | 0 |
| F_3 (Schwefel) | 30 | [-500,500] | -12 569.5 |
| F_4 (Ackley) | 30 | [-32,32] | 0 |

为评估优化性能, 将麻雀搜索算法^[30](sparrow search algorithm, SSA)、白鲸优化算法^[31](beluga whale optimization, BWO)、蜣螂优化算法^[32](dung beetle optimizer, DBO)、SCSO 算法以及 MSCSO 算法进行对比。设置个体数量为 35, 最大迭代次数为

200, 测试结果如图 7 所示。

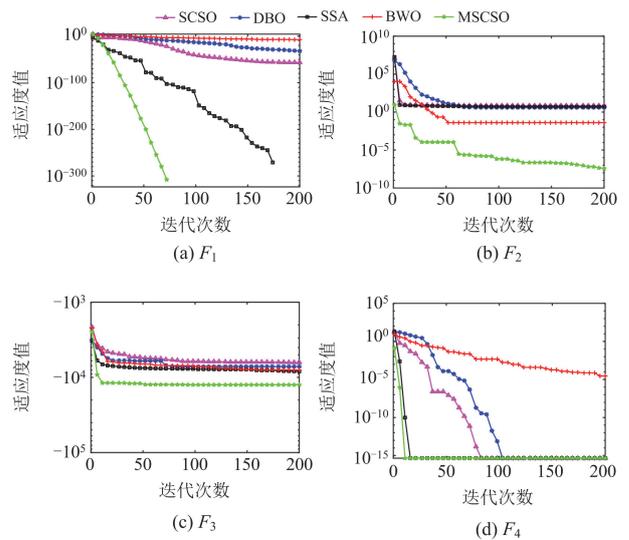


图 7 优化算法对比

Fig. 7 Comparison of optimization algorithms

由图 7 可知, 在单峰测试函数 F_1 和多峰测试函数 F_4 中, MSCSO 算法和 SSA 算法相对于其他算法有着更快的收敛速度, MSCSO 算法在收敛速度上表现更优异。在单峰测试函数 F_2 和多峰测试函数 F_3 中, MSCSO 算法在后期迭代过程中会不断跳出局部最优解, 寻优的精度在不断提升。通过多种策略对 SCSO 算法进行改进, MSCSO 算法在收敛速度和求解精度上均有显著提升, 相对于其余几种种群优化算法, 其寻优性能表现更加出色。

4.2 数据处理及相似日划分

本文所选数据为宁夏某地区光伏电站 2018 年整年的光伏发电功率和光伏电站周围的气象因素数据。该光伏电站的发电功率非零值集中在 06:00—20:00 时间段, 采样时间间隔为 15 min。

为避免数据的量纲对模型训练产生影响, 将气象数据和光伏功率数据进行归一化, 计算方法为

$$x' = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (29)$$

式中: x' 为归一化后的数据; x_{\max} 、 x_{\min} 分别为样本最大值和最小值。

采用 FCM 算法对一年不同季节的光伏功率数据进行相似日划分, 将天气分为晴天、多云、阴天和雨天, 不同天气类型的天数如表 3 所示。将聚类后的结果分别按照 8:2 划分为训练集和测试集, 模型采用单步预测的形式对待预测日进行预测。

表 3 不同天气的聚类结果

Table 3 Clustering results for different weathers

| 季节 | 不同天气下的聚类结果/天 | | | |
|----|--------------|----|----|----|
| | 晴天 | 多云 | 阴天 | 雨天 |
| 春季 | 17 | 24 | 26 | 22 |
| 夏季 | 27 | 29 | 17 | 19 |
| 秋季 | 30 | 25 | 19 | 18 |
| 冬季 | 36 | 18 | 22 | 16 |

以春季为例, 在该季节的聚类结果如图 8 所示。由以春季为例, 晴天 17 天、多云 24 天、阴天 26 天和雨天 22 天, 在该季节的聚类结果如图 8 所示。由聚类结果可知, 同种天气类型下的光伏发电功率具有相似性, 不同天气类型下的光伏功率输出差异较为明显。

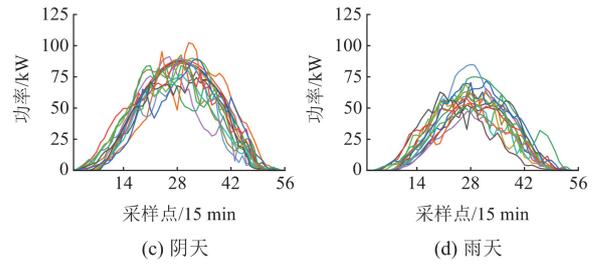
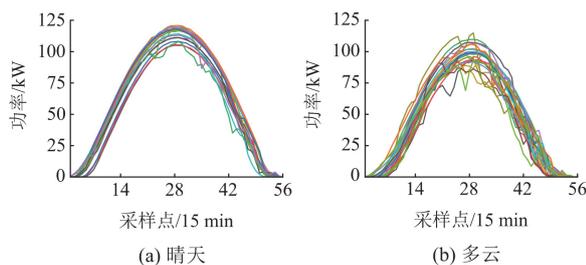


图 8 相似日聚类结果

Fig. 8 Similar day clustering results

4.3 二次模态分解重构

4.3.1 ICEEMDAN 一次分解

针对光伏功率的随机性与波动性特点, 采用 ICEEMDAN 对光伏功率数据进行初步分解, 降低原始数据的波动性, 分解结果为 7 组本征模态分量, 对各个分量采用样本熵进行复杂度计算并排序, 如表 4 所示。

表 4 ICEEMDAN 分量的样本熵值

Table 4 Sample entropy values for the components of the ICEEMDAN

| 模态分量 | 熵值 |
|------|--------|
| IMF1 | 0.9731 |
| IMF2 | 0.8933 |
| IMF3 | 0.3465 |
| IMF4 | 0.1112 |
| IMF5 | 0.0746 |
| IMF6 | 0.0201 |
| IMF7 | 0.0036 |

由表 4 可知, 分量 IMF1、IMF2 的样本熵值大于 0.8, 为复杂度较高的高频分量, 其余为中低频分量。

4.3.2 MSCSO 优化 VMD 及效果分析

将 4.3.1 中的高频分量叠加重构, 采用 VMD 对重构分量进行二次分解, 并使用 MSCSO 算法优化模态数量 K 和惩罚因子 α 。参数设置如表 5 所示。

表 5 设置参数的取值

Table 5 Setting the range of parameters

| K | 惩罚因子 | 迭代次数 | 种群数 |
|--------|-------------|------|-----|
| [2,15] | [1000,4000] | 25 | 20 |

经 MSCSO 优化后, VMD 进行分解的最优模态数量 $K=9$, 惩罚因子 $\alpha=2419$ 。为验证 MSCSO 算法对 VMD 的优化效果, 选用不同的模态数量 K 和惩罚因子 α 对高频分量进行分解, 对分解后的分量建立 BiTCN-BiGRU 预测模型, 对重构误差进行比较, 重构误差及预测结果分别如表 6 和图 9 所示。

表 6 不同参数下高频分量重构误差对比

Table 6 Comparison of reconstruction errors of high-frequency components with different parameters

| | K | e_{MAE}/kW | e_{RMSE}/kW |
|-----------------|----------|--------------|---------------|
| $\alpha = 2419$ | 8 | 0.8929 | 1.2613 |
| | 9 | 0.5028 | 0.6782 |
| | 10 | 0.7281 | 1.0182 |
| | α | e_{MAE}/kW | e_{RMSE}/kW |
| $K = 9$ | 2000 | 0.6022 | 0.8367 |
| | 2419 | 0.5028 | 0.6782 |
| | 3000 | 0.5421 | 0.7459 |

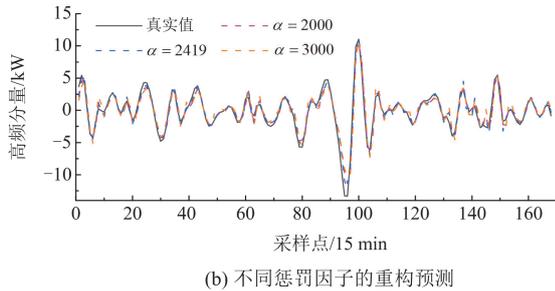
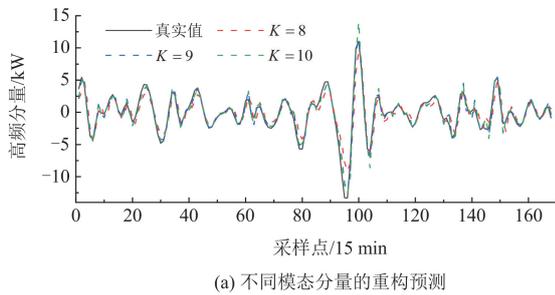


图 9 高频分量的预测结果对比

Fig. 9 Comparison of prediction results for high frequency components

由表 6 和图 9 可知, 在分解高频分量时, 经 MSCSO 算法优化的 VMD 参数能降低重构误差, 性能优于其他参数组, 同时表明模态数量 K 相较于惩罚因子 α 对分解结果的影响更为显著。其中, 由图 9(a)可知, 在相同惩罚因子条件下, 当 $K = 9$ 时, 高频分量的重构误差 e_{MAE} 相较于 $K = 8$ 和 $K = 10$ 分别降低了 43.69%和 30.94%; 由图 9(b)可知, 在相同模态数量条件下, 当 $\alpha = 2419$ 时, 高频分量的重构误差 e_{RMSE} 相较于 $\alpha = 2000$ 和 $\alpha = 3000$ 分别降低了 16.51%和 7.24%。因此, 采用 MSCSO 优化 VMD 有利于提高预测精度。

4.3.3 QMDR 分析与预测结果

分别计算 VMD 二次分解后的分量及 ICEEMDAN 一次分解后的剩余分量的样本熵值, 并据此进行分

析与重构, 如图 10 所示。

将相似样本熵值的分量进行重构, 由图 10 可知, 分量 2 和分量 3 相似, 分量 4 和分量 5 相似, 分量 6 和分量 7 相似, 分量 9 和分量 10 相似, 分量 13 和分量 14 相似。将 5 组相似样本熵值的分量进行叠加重构, 并与剩下的分量组成重构模态分量集, 如图 11 所示, 其中 rIMF1—rIMF9 为二次重构模态分量。

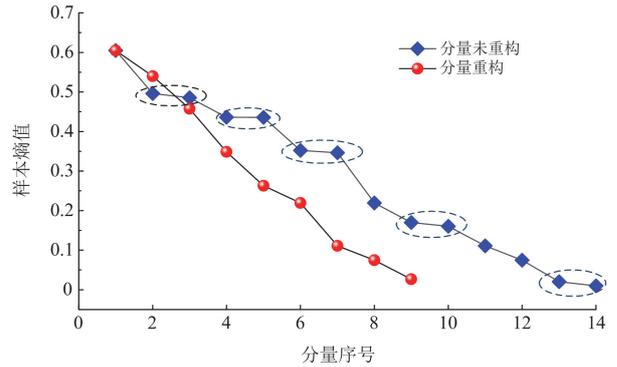


图 10 分量未重构和重构的样本熵值

Fig. 10 Sample entropy values for component un-reconstruction and reconstruction

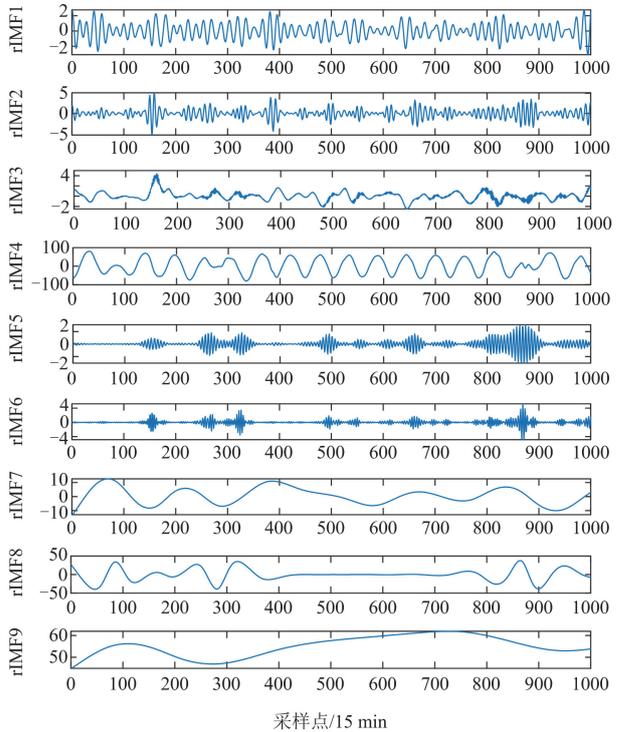


图 11 二次重构模态分量

Fig. 11 Quadratic reconstruction of modal components

为验证本文所提二次模态分解重构方法对提升光伏功率预测精度的有效性, 分别使用一次分解

ICEEMDAN、二次分解 ICEEMDAN-VMD 和本文方法对光伏功率原始数据进行分解, 通过 BiTCN-BiGRU 预测模型进行预测。各模型的预测误差对比和预测结果分别如表 7 和图 12 所示。

表 7 不同分解方式的预测误差对比

Table 7 Comparison of prediction errors for different decompositions

| 分解方法 | e_{MAE} | e_{RMSE} |
|--------------|-----------|------------|
| ICEEMDAN | 1.9318 | 2.9544 |
| ICEEMDAN-VMD | 1.7825 | 2.6789 |
| QMDR | 1.6445 | 2.3937 |

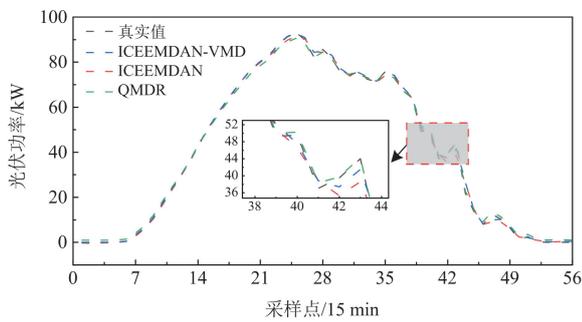
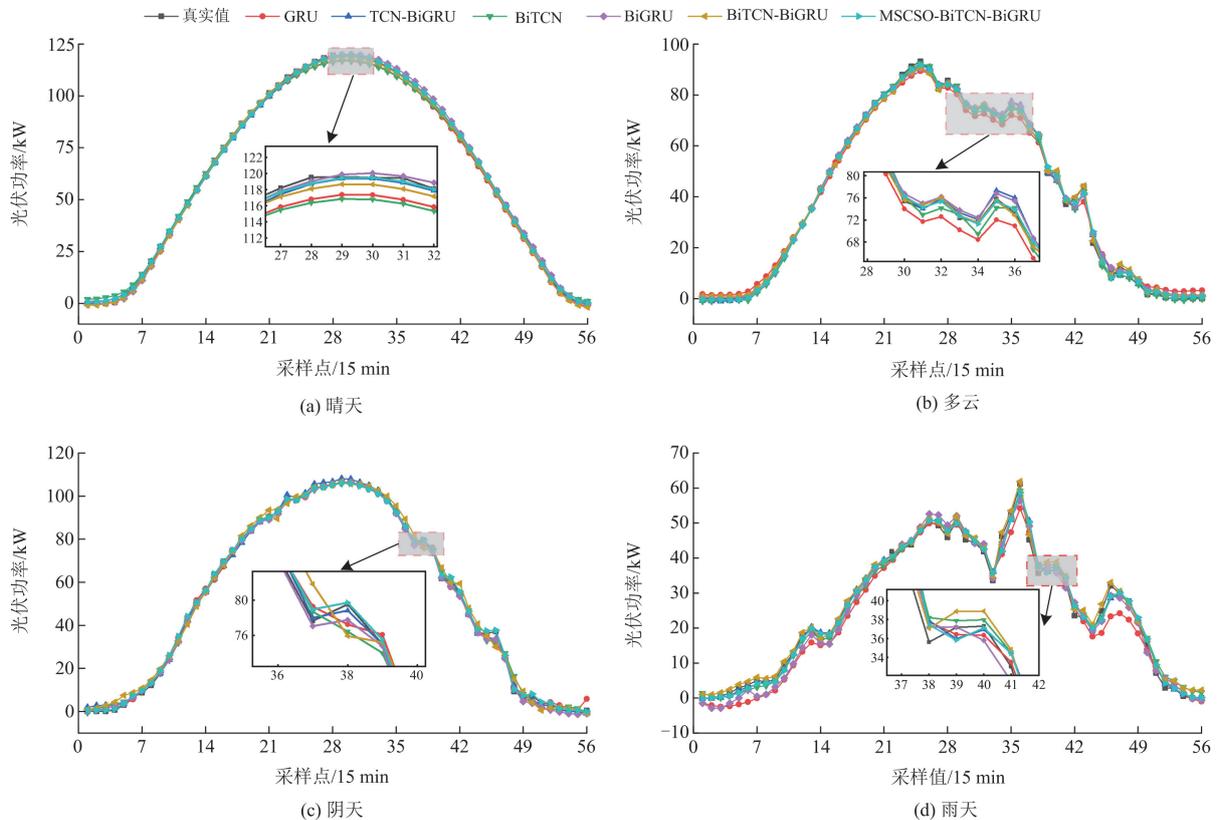


图 12 不同分解方式下的预测结果

Fig. 12 Predicted results under different decompositions



由表 7 和图 12 可知, 采用 QMDR 算法能够有效提升模型 BiTCN-BiGRU 的预测精度。相比于 ICEEMDAN 和 ICEEMDAN-VMD 算法, 采用 QMDR 算法使 e_{MAE} 分别降低 14.87% 和 7.74%; 使 e_{RMSE} 分别降低 18.98% 和 10.65%。说明经过一次分解处理后产生的高频分量影响预测精度; 对高频分量进行二次分解能够降低高频分量的波动, 提升了预测精度, 但会存在过多分量, 导致噪声的产生且使模型训练更加复杂; 经过二次模态分解重构的分量子序列数目减少, 各分量间不存在明显的模态混叠现象, 降低了模型训练的复杂度, 提升了模型的预测性能。

4.4 不同模型的预测结果分析

为验证本文所设计模型的预测性能及适用性, 采用 QMDR 算法对原始数据进行处理, 对比本文模型与多种模型在不同天气类型下的光伏发电功率。

参数设置: GRU 和 BiGRU 的隐藏层神经元数量设置为 64; TCN 和 BiTCN 的卷积核大小为 10, 扩张因子设置为 [1,2,4], 卷积层的神经元数量设置为 64; MSCSO 算法的迭代次数为 25, 种群数目为 20。预测结果及误差对比如图 13 所示, 误差分析如表 8 所示。

MSCSO-BiTCN-BiGRU 模型在 BiTCN-BiGRU 模型的基础上对模型参数进行优化, 相较于 BiTCN-

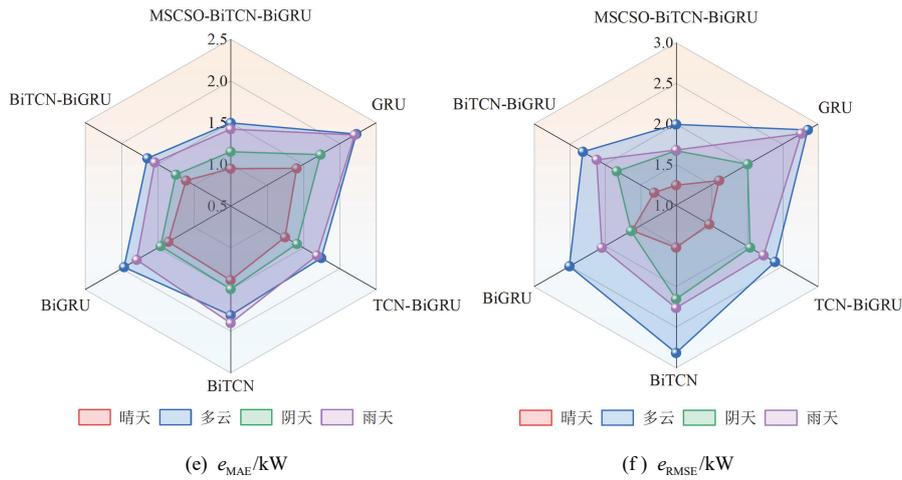


图 13 不同天气类型下各模型的预测结果及误差对比

Fig. 13 Comparison of prediction results and errors of models under different weather types

表 8 不同模型的误差分析

Table 8 Error analysis of different models

| 模型 | 晴天 | | 多云 | | 阴天 | | 雨天 | |
|-------------------|---------------|----------------|---------------|----------------|---------------|----------------|---------------|----------------|
| | e_{MAE} /kW | e_{RMSE} /kW |
| GRU | 1.4052 | 1.6216 | 2.2253 | 2.8555 | 1.7346 | 2.008 | 2.2032 | 2.7616 |
| BiGRU | 1.3551 | 1.5667 | 1.9639 | 2.5009 | 1.4618 | 1.9335 | 1.9033 | 2.2627 |
| BiTCN | 1.3893 | 1.5898 | 1.8097 | 2.4161 | 1.4952 | 2.1531 | 1.7905 | 2.0447 |
| TCN-BiGRU | 1.2474 | 1.4657 | 1.7442 | 2.3925 | 1.4107 | 2.0414 | 1.6851 | 2.2322 |
| BiTCN-BiGRU | 1.1141 | 1.3082 | 1.6445 | 2.3137 | 1.2521 | 1.8343 | 1.5432 | 2.0174 |
| MSCSO-BiTCN-BiGRU | 0.9489 | 1.2471 | 1.4966 | 1.9946 | 1.1509 | 1.6702 | 1.4229 | 1.7798 |

BiGRU, 晴天、多云、阴天、雨天天气下的 e_{MAE} 分别下降了 14.83%、8.99%、8.08%、7.78%; e_{RMSE} 分别下降了 4.67%、13.79%、8.95%、11.78%。由此说明, 通过 MSCSO 优化 BiTCN-BiGRU 模型的参数配置, 能够进一步提高模型的预测精度, 在各种天气条件下均表现出优越的性能。

4.5 不同预测场景及优化算法的模型预测精度对比

为进一步验证本文方法在不同地区光伏功率预测中的适应性, 选取澳大利亚沙漠中心某光伏电站的数据进行实验分析, 数据覆盖 06:00—18:25 时段, 采样间隔为 5 min, 一天共 150 个样本点。为验证 MSCSO 算法在光伏功率预测场景下的优化性能, 原数据经 QMDR 处理后, 在相同条件下建立 BiTCN-BiGRU 模型, 采用不同优化算法优化预测模型参数。具体对比算法包括 BWO、SSA 和 SCSO, 选择具有较强的随机性和波动性的雨天天气的光伏发电功率进行预测。此外, 为进一步验证 MSCSO 算法的优越性, 针对螺旋搜索策略和高斯游走策略设计了消融实验, 以评估各策略对模型性能的提升效果。不同算法的预测误差如表 9 和图 14 所示, 预测结果如图 15 所示, 优化过程对比如图 16 所示。

由表 9、图 14 和图 15 可知, 经优化算法优化后的 BiTCN-BiGRU 模型, 在不同地区光伏功率波动较强的天气下均表现出更高的预测精度, 体现出模型具有良好的适应性。同时, MSCSO 对模型参数进行寻优相比于其他优化算法有着更优的寻优效果, 其中螺旋搜索策略和高斯游走策略的设计提高了优化效率, 与原 SCSO 优化后模型的预测结果进行对比, 引入螺旋搜索策略后, e_{MAE} 和 e_{RMSE} 分别下降了 8.51%和 1.03%; 引入高斯游走策略后, e_{MAE} 和 e_{RMSE} 分别下降了 29.14%和 20.38%。此外, 由图 16

表 9 不同优化算法下模型预测误差

Table 9 Prediction errors of models under different optimization algorithms

| 优化算法 | 螺旋搜索策略 | 高斯游走策略 | kW | |
|---------|--------|--------|-----------|------------|
| | | | e_{MAE} | e_{RMSE} |
| BWO | — | — | 0.2665 | 0.3197 |
| SCSO | — | — | 0.1963 | 0.2341 |
| SSA | — | — | 0.1424 | 0.2267 |
| MSCSO-1 | ✓ | — | 0.1796 | 0.2317 |
| MSCSO-2 | — | ✓ | 0.1391 | 0.1864 |
| MSCSO | ✓ | ✓ | 0.1082 | 0.1623 |

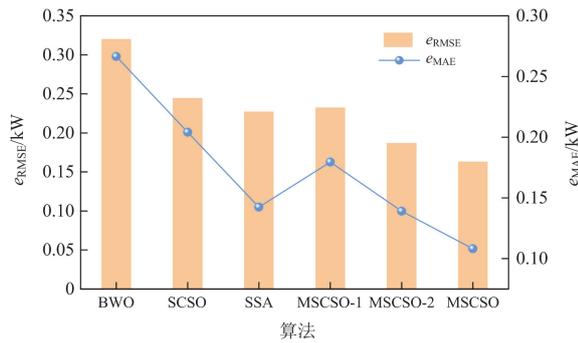


图 14 不同优化算法的预测误差对比

Fig. 14 Comparison of prediction errors of different optimization algorithms

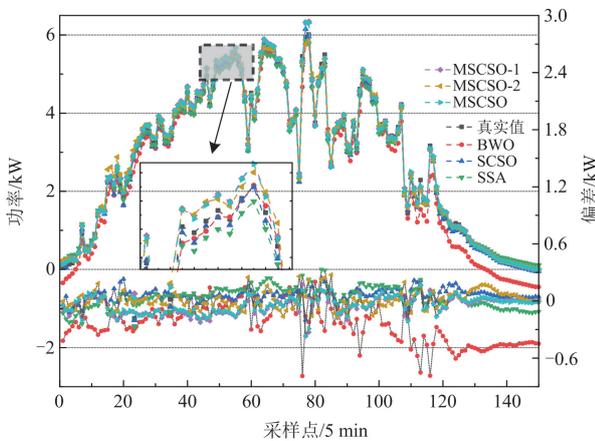


图 15 不同优化算法的预测结果

Fig. 15 Prediction results of different optimization algorithms

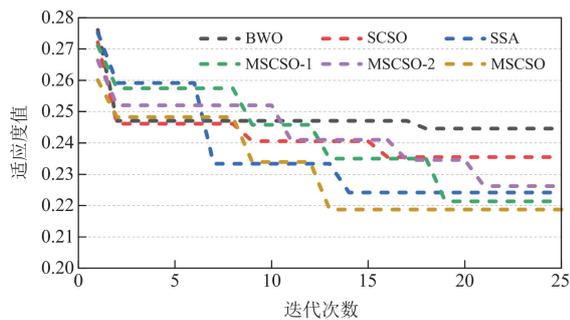


图 16 优化过程对比

Fig. 16 Comparison of optimization processes

可以看出, 相较于其他算法, MSCSO 经过 13 次迭代基本寻找到最优解, 收敛效率较高, 进一步验证了引入螺旋搜索策略、高斯游走策略能够有效提高 MSCSO 算法的参数优化能力。

5 结论

为了减少光伏发电功率的预测误差, 本文提出

了基于二次模态分解重构及 BiTCN-BiGRU 组合模型的光伏短期发电功率预测方法, 通过建模分析及实验对比得出以下结论。

1) 提出的 QMDR 方法能够有效削弱光伏发电功率序列分解后的高频分量, 降低分量波动性和非平稳性的影响, 从而提升光伏发电功率的预测精度, 相较于二次分解方法, 减少了分量序列数目, 降低了模型训练的复杂度, e_{MAE} 和 e_{RMSE} 分别降低了 7.74% 和 10.65%。

2) 通过采用融合 Chebyshev 混沌与逆向学习策略、螺旋搜索策略、自适应敏感度和高斯游走策略构建 MSCSO 算法。在相同条件下与 SSA、BWO 等算法进行比较, 可以看出 MSCSO 表现出更佳的寻优性能, 能够有效解决 SCSO 算法容易陷入局部最优解和收敛速度慢的问题。

3) 实验结果表明, 本文构建的 BiTCN-BiGRU 组合模型具备较强的特征提取能力, 能够有效捕捉时间序列中的相关特征和依赖关系。通过 MSCSO 算法对 BiTCN-BiGRU 模型的超参数进行优化, 有效解决了因超参数设置不当而导致的预测精度下降问题, 从而提高了预测精度。此外, 本文提出的模型在不同天气条件下均能实现光伏功率的高精度预测, 同时在不同地区的光伏功率预测中表现出良好的泛化性能, 进一步验证了模型的适用性。

参考文献

- [1] 吴硕. 光伏发电系统功率预测方法研究综述[J]. 热能动力工程, 2021, 36(8): 1-7.
WU Shuo. Review of power forecasting methods of photovoltaic power generation system[J]. Journal of Engineering for Thermal Energy and Power, 2021, 36(8): 1-7.
- [2] 韩富佳, 王晓辉, 乔骥, 等. 基于人工智能技术的新型电力系统负荷预测研究综述[J]. 中国电机工程学报, 2023, 43(22): 8569-8592.
HAN Fujia, WANG Xiaohui, QIAO Ji, et al. Review on artificial intelligence based load forecasting research for the new-type power system[J]. Proceedings of the CSEE, 2023, 43(22): 8569-8592.
- [3] 张海涛, 李文娟, 李雪峰, 等. 基于变分模态分解和时间注意力机制 TCN 网络的光伏发电功率预测[J]. 电测与仪表, 2024, 61(12): 156-163.
ZHANG Haitao, LI Wenjuan, LI Xuefeng, et al. Photovoltaic power forecasting based on TPA-TCN model and variational modal decomposition[J]. Electrical Measurement & Instrumentation, 2024, 61(12): 155-163.
- [4] 周伊, 肖先勇, 赵清华, 等. 基于组合数据清洗与改进

- 注意力机制的光伏发电功率预测[J]. 供用电, 2024, 41(10): 31-37, 49.
- ZHOU Yi, XIAO Xianyong, ZHAO Qinghua, et al. Photovoltaic power forecasting based on combined data cleaning and improved attention mechanism[J]. Distribution & Utilization, 2024, 41(10): 31-37, 49.
- [5] LIMOUNI T, YAAGOUBI R, BOUZIANE K, et al. Accurate one step and multistep forecasting of very short-term PV power using LSTM-TCN model[J]. Renewable Energy, 2023, 205: 1010-1024.
- [6] 黄泽, 毕贵红, 谢旭, 等. 基于 MBI-PBI-ResNet 的超短期光伏功率预测[J]. 电力系统保护与控制, 2024, 52(2): 165-176.
- HUANG Ze, BI Guihong, XIE Xu, et al. Ultra-short-term PV power prediction based on MBI-PBI-ResNet[J]. Power System Protection and Control, 2024, 52(2): 165-176.
- [7] THOMAS W, HU Ruifeng, ZHU Hongyu, et al. Combined IXGBoost-KELM short-term photovoltaic power prediction model based on multidimensional similar day clustering and dual decomposition[J]. Energy, 2024, 288.
- [8] LI Guohui, WEI Xuan, YANG Hong. A method for accurate prediction of photovoltaic power based on multi-objective optimization and data integration strategy[J]. Applied Mathematical Modelling, 2024, 136.
- [9] LIU Wencheng, MAO Zhizhong. Short-term photovoltaic power forecasting with feature extraction and attention mechanisms[J]. Renewable Energy, 2024, 226.
- [10] 何俊强, 师长立, 韦统振. 基于马尔科夫链的自适应储能需求功率预测模型[J]. 电工技术学报, 2021, 36(增刊 2): 563-571.
- HE Junqiang, SHI Changli, WEI Tongzhen. Adaptive power demand prediction model of energy storage based on Markov chain[J]. Transactions of China Electrotechnical Society, 2021, 36(S2): 563-571.
- [11] 李芬, 孙凌, 王亚维, 等. 基于 CEEMDAN-GSA-LSTM 和 SVR 的光伏功率短期区间预测[J]. 上海交通大学学报, 2024, 58(6): 806-818.
- LI Fen, SUN Ling, WANG Yawei, et al. Short-term interval forecasting of photovoltaic power based on CEEMDAN-GSA-LSTM and SVR[J]. Journal of Shanghai Jiao Tong University, 2024, 58(6): 806-818.
- [12] 杨茂, 张书天, 王勃. 基于因果正则化极限学习机的风电功率短期预测方法[J]. 电力系统保护与控制, 2024, 52(11): 127-136.
- YANG Mao, ZHANG Shutian, WANG Bo. Short-term wind power forecasting method based on a causal regularized extreme learning machine[J]. Power System Protection and Control, 2024, 52(11): 127-136.
- [13] LI Naiqing, LI Longhao, ZHANG Fan, et al. Research on short-term photovoltaic power prediction based on multi-scale similar days and ESN-KELM dual core prediction model[J]. Energy, 2023, 277.
- [14] 毕贵红, 赵鑫, 陈臣鹏, 等. 基于多通道输入和 PCNN-BiLSTM 的光伏发电功率超短期预测[J]. 电网技术, 2022, 46(9): 3463-3476.
- BI Guihong, ZHAO Xin, CHEN Chenpeng, et al. Ultra-short-term prediction of photovoltaic power generation based on multi-channel input and PCNN-BiLSTM[J]. Power System Technology, 2022, 46(9): 3463-3467.
- [15] 于丹文, 李山, 刘航航, 等. 基于 3DCNN 与 CLSTM 混合模型的短期光伏功率预测[J]. 山东电力技术, 2024, 51(7): 10-18.
- YU Danwen, LI Shan, LIU Hanghang, et al. Short-term photovoltaic power prediction based on 3DCNN and CLSTM hybrid model[J]. Shandong Electric Power, 2024, 51(7): 10-18.
- [16] HU Zehuan, GAO Yuan, JI Siyu, et al. Improved multistep ahead photovoltaic power prediction model based on LSTM and self-attention with weather forecast data[J]. Applied Energy, 2024, 359.
- [17] 陈晓华, 吴杰康. 基于北方苍鹰优化算法优化长短期记忆神经网络的光伏发电功率短期预测[J]. 山东电力技术, 2024, 51(10): 10-17.
- CHEN Xiaohua, WU Jiekang. Photovoltaic power short-term prediction based on long short-term memory neural network optimized by northern goshawk optimization algorithm[J]. Shandong Electric Power, 2024, 51(10): 10-17.
- [18] 王瑞, 徐新超, 逯静. 基于特征选择及 ISSA-CNN-BiGRU 的短期风功率预测[J]. 工程科学与技术, 2024, 56(3): 228-239.
- WANG Rui, XU Xinchao, LU Jing. Short-term wind power prediction: feature selection and ISSA-CNN-BiGRU approach[J]. Advanced Engineering Sciences, 2024, 56(3): 228-239.
- [19] 吉全, 赵国航, 叶平峰, 等. 基于 QMD-HBiGRU 的短期光伏功率预测方法[J]. 高电压技术, 2024, 50(9): 3850-3859.
- JI Xingquan, ZHAO Guohang, YE Pingfeng, et al. Short-term PV forecasting method based on the QMD-HBiGRU model[J]. High Voltage Engineering, 2024, 50(9): 3850-3859.
- [20] 郑豪丰, 杨国华, 康文军, 等. 基于多负荷特征和 TCN-GRU 神经网络的负荷预测[J]. 中国电力, 2022, 55(11): 142-148.
- ZHENG Haofeng, YANG Guohua, KANG Wenjun, et al.

- Load forecasting based on multiple load features and TCN-GRU neural network[J]. *Electric Power*, 2022, 55(11): 142-148.
- [21] 李文武, 石强, 李丹, 等. 基于 VMD 和 PSO-SVR 的短期电力负荷多阶段优化预测[J]. *中国电力*, 2022, 55(8): 171-177.
LI Wenwu, SHI Qiang, LI Dan, et al. Multi-stage optimization forecast of short-term power load based on VMD and PSO-SVR[J]. *Electric Power*, 2022, 55(8): 171-177.
- [22] 龙小慧, 秦际赟, 张青雷, 等. 基于相似日聚类及模态分解的短期光伏发电功率组合预测研究[J]. *电网技术*, 2024, 48(7): 2948-2957.
LONG Xiaohui, QIN Jiyun, ZHANG Qinglei, et al. Short-term photovoltaic power prediction study based on similar day clustering and modal decomposition[J]. *Power System Technology*, 2024, 48(7): 2948-2957.
- [23] 王瑞, 张璐婷, 逯静. 基于新型相似日选取和 VMD-NGO-BiGRU 的短期光伏功率预测[J]. *湖南大学学报 (自然科学版)*, 2024, 51(2): 68-80.
WANG Rui, ZHANG Luting, LU Jing. Short term photovoltaic power prediction based on new similar day selection and VMD-NGO-BiGRU[J]. *Journal of Hunan University (Natural Science)*, 2024, 51(2): 68-80.
- [24] 周育才, 肖添, 谢七月, 等. 基于聚类的 HPO-BILSTM 光伏功率短期预测[J]. *太阳能学报*, 2024, 45(4): 512-518.
ZHOU Yucai, XIAO Tian, XIE Qiyue, et al. Clustering-based HPO-BILSTM short-term prediction of PV power[J]. *Acta Energetica Solaris Sinica*, 2024, 45(4): 512-518.
- [25] SEYYEDABBASI A, KIANI F. Sand cat swarm optimization: a nature-inspired algorithm to solve global optimization problems[J]. *Engineering with Computers*, 2023, 39(4): 2627-2651.
- [26] COLOMINAS M A, SCHLOTTHAUERG, TORRES M E. Improved complete ensemble EMD: a suitable tool for biomedical signal processing[J]. *Biomedical Signal Processing and Control*, 2014, 14: 19-29.
- [27] 李成钢, 刘亚东, 杨雪凤, 等. 基于变分模态分解与空洞卷积神经网络的配电网故障选线方法[J]. *电网与清洁能源*, 2024, 40(2): 110-118, 126.
LI Chenggang, LIU Yadong, YANG Xuefeng, et al. A method of fault line selection for distribution networks based on variational mode decomposition and dilated convolutional neural network[J]. *Power System and Clean Energy*, 2024, 40(2): 110-118, 126.
- [28] 石卓见, 冉启武, 徐福聪. 基于聚合二次模态分解及 Informer 的短期负荷预测[J]. *电网技术*, 2024, 48(6): 2574-2583.
SHI Zhuojian, RAN Qiwu, XU Fucong. Short-term load forecasting based on aggregated secondary decomposition and Informer[J]. *Power System Technology*, 2024, 48(6): 2574-2583.
- [29] 杨国华, 张鸿皓, 郑豪丰, 等. 基于相似日聚类和 IHGWO-WNN-AdaBoost 模型的短期光伏功率预测[J]. *高电压技术*, 2021, 47(4): 1185-1194.
YANG Guohua, ZHANG Honghao, ZHENG Haofeng, et al. Short-term photovoltaic power forecasting based on similar weather clustering and IHGWO-WNN-AdaBoost model[J]. *High Voltage Engineering*, 2021, 47(4): 1185-1194.
- [30] XUE Jiankai, SHEN Bo. A novel swarm intelligence optimization approach: Sparrow search algorithm[J]. *Systems Science & Control Engineering*, 2020, 8: 22-34.
- [31] ZHONG Changting, LI Gang, MENG Zeng. Beluga whale optimization: a novel nature-inspired metaheuristic algorithm[J]. *Knowledge-Based Systems*, 2022, 251.
- [32] 刘杰, 从兰美, 夏远洋, 等. 基于 DBO-VMD 和 IWOA-BILSTM 神经网络组合模型的短期电力负荷预测[J]. *电力系统保护与控制*, 2024, 52(8): 123-133.
LIU Jie, CONG Lanmei, XIA Yuanyang, et al. Short-term power load prediction based on DBO-VMD and an IWOA-BILSTM neural network combination model[J]. *Power System Protection and Control*, 2024, 52(8): 123-133.

收稿日期: 2024-03-31; 修回日期: 2025-02-20

作者简介:

文 斌(1985—), 男, 博士, 讲师, 硕士研究生导师, 研究方向为新能源发电预测、机器视觉与信号处理; E-mail: wenbin_08@126.com

章学勤(2000—), 男, 硕士研究生, 研究方向为新能源发电预测; E-mail: zhangxq_20@163.com

付文龙(1988—), 男, 通信作者, 博士, 副教授, 研究方向为新能源发电预测、图像处理与模式识别。E-mail: ctgu_fuwenlong@126.com

(编辑 许 威)