

基于麻雀算法优化的VMD-CNN-LSTM的短期风电功率研究

张子华¹, 李琰¹, 徐天奇¹, 王阳光², 邓小亮²

(1. 云南民族大学 云南省高校CPS融合系统重点实验室, 云南 昆明 650504;

2. 国网湖南省电力有限公司, 湖南 长沙 410004)

摘要: 考虑相关风电场之间的影响因素可以有效提升新建风电场的风电功率预测精度, 提出利用变分模态分解技术(VMD)将单风电场风电功率预处理分解为本征模态函数(IMF), 然后将各风电场同频段分量, 即低频分量、高频分量和残差分量, 组合为二维特征矩阵作为卷积神经网络(CNN)的输入, 利用卷积神经网络提取同分量子模态下空间特征信息, 输入到长短时记忆网络(LSTM)提取时间序列中的长时依赖关系进行预测, 最后将预测结果进行叠加, 获得完整的预测结果。组合神经网络的超参数设置相较于单一模型对预测精度的影响更大, 采用新型麻雀搜索算法(SSA)可以节省人工手动调制参数的时间、提高超参数设置的精度和效率。使用该方法对某风电集群中的新建基准风电场进行预测, 预测结果表明经 SSA 优化的 VMD-CNN-LSTM 模型在预测风电集群数据上有较高的精度, 预测效果好于对比模型 LSTM, CNN-LSTM 和 SSA-VMD-LSTM。

关键词: 风电功率; 变分模态分解; 卷积神经网络; 长短时记忆网络; 麻雀搜索算法

中图分类号: TM743 **文献标识码:** A **DOI:** 10.19457/j.1001-2095.dqcd24196

Research on Short-term Wind Power Forecasting Based on VMD-CNN-LSTM Optimized by Sparrow Algorithm

ZHANG Zihua¹, LI Yan¹, XU Tianqi¹, WANG Yangguang², DENG Xiaoliang²

(1. The Key Laboratory of Cyber-physical Power System of Yunnan Colleges and Universities,

Yunnan Minzu University, Kunming 650504, Yunnan, China; 2. State Grid Hunan

Electric Power Co., Ltd., Changsha 410004, Hunan, China)

Abstract: In order to improve the prediction accuracy of wind power in new wind farms effectively, the influencing factors between relevant wind farms were considered. A variational mode decomposition (VMD) technique was proposed to decompose the wind power preprocessing of a single wind farm into intrinsic mode function (IMF), and then the same frequency band component such as low-frequency components, high-frequency components and residual components of each wind farm were combined respectively as the input of convolution neural network (CNN). CNN was used to extract the characteristic information under the same split sub-mode, which was input to the long short-term memory (LSTM) network for prediction, and finally the prediction results were overlaid to obtain the complete prediction results. Compared with a single model, the hyperparameter setting of the combined neural network will affect the prediction accuracy more. A new sparrow search algorithm (SSA) was proposed to save the time of manual parameter adjustment and improve the accuracy and efficiency of hyperparameter setting. The proposed method was used to predict the new benchmark wind farm in a wind power cluster, the result verifies that the VMD-CNN-LSTM optimized by SSA has a higher accuracy in predicting the wind power cluster data, which is higher than the comparison model LSTM, CNN-LSTM and SSA-VMD-LSTM.

Key words: wind power; variational mode decomposition (VMD); convolution neural network (CNN); long short-term memory (LSTM) network; sparrow search algorithm (SSA)

近年来由于能源形势愈发严峻^[1-2], 全球范围内新能源发展在电力市场日趋活跃, 其中风电产

基金项目: 国家自然科学基金项目(62062068, 61761049)

作者简介: 张子华(1997—), 女, 硕士, 主要研究领域为新能源发电预测技术, Email: 625814186@qq.com

通讯作者: 李琰(1977—), 女, 副教授, 主要研究领域为电力信息物理系统, Email: yan.li@ymu.edu.cn

业发展尤为迅速,风电建设由初期分散式、小规模逐渐演变为集中式、大规模的风电集群,资源的紧凑性使得新建风电场往往与在运风电场区域存在相互关联性^[3]。由于风能属于随机波动的不稳定能源,风电出力具有强烈波动性和间歇性,大规模并入电网会对电力系统的稳定运行带来严峻考验^[4]。

提升风电出力预测精度是实现风电场友好并网的重要途径之一。现有风功率预测方法主要有物理模型和统计分析两大类^[5-6]。由于风功率固有随机性等特征,组合模型成为热门研究方向,即采用多种预测模型的综合算法,优化组合不同模型的优点,以弥补单一模型精度不足的问题,有效提高预测精度^[7-10]。文献[11]对比了不同的预测模型,认为快速集合经验模态分解的效果优于常规模态分解,但没有考虑模态混叠问题。文献[12]介绍了基于深度学习风电功率预测方法,该方法相较于常规单一机器学习方法对输入特征具有强大的深度学习和泛化能力^[12],在风电功率预测方面具有显著优势。目前,常应用的深度学习模型包括卷积神经网络(convolutional neural network, CNN)^[13]和循环神经网络(recurrent neural network, RNN)。其中, CNN方法善于挖掘高维特征中的空间关联性, RNN方法善于挖掘序列信息的时间关联性。由此还引申出了长短期记忆神经网络(long short-term memory, LSTM),对原始序列具有一定的记忆功能,在长距离预测尺度下也能够解决梯度爆炸问题^[14]。文献[15]利用LSTM神经网络克服时间序列的相互依赖性,同时采用粒子群优化(particle swarm optimization, PSO)实现对含有超参数目标函数进行自主寻优,以克服常规人工选择耗时长、精度差的不足,减小预测时长和误差。

组合模型在风功率预测精度和时长上具有显著优势,但组合模型受超参数设置的影响更大,两个神经网络超参数设置的配合问题往往需要耗费大量的人工调参时间^[16]。为此,本文将新型元启发算法中的麻雀搜索算法引入风功率预测的组合模型,该算法简单易行,能在保证预测精度的前提下实现复杂组合模型的超参数寻优。具体方案为:首先,利用变分模态分解各个风电场历史风功率,将其分解为长期分量、波动分量和残余分量,在充分挖掘每个风电场自身风功率分量信息后,考虑风电集群间风功率相关性的特

征方法,引入卷积神经网络模型处理风电集群的组合特征分量;然后将每个分组处理后的数据通过长短时记忆网络进行预测,以保证预测精度;最后,将各个分量重构回原始序列,得到风功率预测数据。仿真结果表明,相比于常见的单一神经网络,本文提出的基于麻雀算法优化组合网络超参数的新型风电功率预测方法具有更优的预测性能。

1 基本原理与方法

1.1 变分模态分解的具体步骤

变分模态分解(variational modal decomposition, VMD)是一种通过多分辨率分解非线性信号的新型技术,可以同时处理递归和非递归信号,对变分问题的整体构造和求解实现信号的频带分离^[17]。功率序列经过VMD预处理分解后可得频率特征不同的模态函数,从时间序列中提取的信号具有固有子模态分量,并且各个解析信号噪声鲁棒性良好,都具有实际的物理意义,这为本文将相关性较强的特征值分解为相同数量的子模态分量进行特征重构提供了理论依据,可以快速地将模态函数分解为高频分量、低频分量和残差分量。

视单个风电场的原始风功率时间序列为非平稳信号 $f(t)$ ^[18],以中心频率为基准,可以求得三个分量的模态子函数,其中每个子模态带宽和最小的优化问题的约束条件为三个分量之和等于初始非平稳信号 f ,表达式为

$$\begin{cases} \min_{\{p_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^s |\partial_t \{ [\delta(t) + \frac{j}{\pi t} \otimes p_k(t)] \} e^{-j\omega_k t}|_2^2 \right\} \\ \text{s. t. } \sum_{k=1}^s p_k(t) = f(t) \end{cases} \quad (1)$$

$$\begin{aligned} \text{其中 } \{p_k(t)\} &= \{p_1(t), p_2(t), p_3(t)\} \\ \{\omega_k\} &= \{\omega_1, \omega_2, \omega_3\} \end{aligned}$$

式中: $p_k(t)$ 为 t 时刻该风电场中风电功率的模态函数集合; ω_k 为与模态函数相对应的中心频率集; s 为分解后分量总个数; $\delta(t)$ 为每个子模态函数对中心频率的描述。

1.2 卷积神经网络

CNN善于处理图像识别,也可挖掘原始时间序列之间的空间相关性。

由于新建单风电场的风电功率不仅与自身的历史信息有关,还与周边风电场具有一定的相关性^[19-20]。因此,经VMD处理后,对风电集群相关

风电功率的低频分量、高频分量和残差分量分别进行组合,利用CNN模型可有效提取空间特征。

将卷积层设置为二维卷积(conv2D),构建提取风电场相关数据的空间特征CNN模型,设置1个卷积层、1个池化层。其中池化层设置为 2×2 ,根据经VMD处理后的多风电场相同子模态输入特征进行最大池化,卷积层的卷积核大小为待寻优参数。

1.3 长短时记忆网络

LSTM在RNN的基础上增加了单元状态结构,具有独特的记忆和遗忘模式,相较于普通神经网络,善于描述时间序列的长期依赖关系,增加了强大的存储功能,可以计及特征历史数据影响,提高风电功率预测的准确性。LSTM模型如图1所示。




图1 LSTM单元结构图

Fig.1 LSTM unit structure diagram

图1中, t 时刻的LSTM单元状态信息是由三个状态共同决定并储存信息,分别为遗忘门输入 x_t 、状态记忆单元 c_{t-1} 和隐含状态 h_{t-1} 。输入门中的 x_t 通过sigmoid和tanh函数决定记忆门中需要保留的状态信息部分,可分别表示为

$$f_t = \sigma[W_f \cdot (h_{t-1}, x_t) + b_f] \quad (2)$$

$$i_t = \sigma[W_i \cdot (h_{t-1}, x_t) + b_i] \quad (3)$$

$$\tilde{c}_t = \tanh[W_c \cdot (h_{t-1}, x_t) + b_c] \quad (4)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (5)$$

$$o_t = \sigma[W_o \cdot (h_{t-1}, x_t) + b_o] \quad (6)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (7)$$

式中: f_t, i_t, o_t 分别为遗忘门、输入门和输出门状态信息; c_t 为记忆单元状态信息,由 f_t, i_t 决定其状态是否需要更新,由 o_t 决定其输出的数值; $\tilde{c}_t$ 为添加至单元状态 c_t 的候选向量; h_t, x_t 为 t 时刻输入隐含层和输入层的向量; σ 和 $\tanh$ 分别为sigmoid和双曲正切激活函数; W 和 b 为LSTM网络中需要训练的参数矩阵。

2 基于SSA优化的VMD-CNN-LSTM模型

2.1 麻雀搜索算法

麻雀在觅食和反捕食时有一套群体规则。

2020年由薛建凯团队受到麻雀自然行为启发,发明了麻雀搜索算法(sparrow search algorithm, SSA)这种新型元启发式算法,该方法在收敛速度和寻优精度等方面有着明显优势,且算法结构简单、能准确应对复杂问题^[21]。由此本文将麻雀搜索算法用于组合模型VMD-CNN-LSTM中,对其超参数进行寻优。SSA算法中设定的麻雀种类分为追随者和发现者两类,两类麻雀可以相互转化。

麻雀群体觅食过程中,每个个体都有分配初始位置和适应度值。根据对适应度的评估,将找到食物最佳的麻雀作为发现者,其余个体跟随发现者到最佳捕食位置附近进行觅食。发现者作为一小部分个体的领导者,也会有另一部分个体与其他同伴争夺资源,实现个体自身的最优捕食效果,所以选用一定比例的个体进行侦察,并给予其发出侦察预警的功能,即当发现危险时就放弃附近的食物,向群体中心靠近。

2.2 SSA-VMD-CNN-LSTM预测模型的建立

针对集群风电场中的新建风电场,对每个单风电场的风电功率数据进行VMD分解,得到高频分量、低频分量和残差分量,选用周边相关单风电场数据中相同频段的分量进行组合,考虑到CNN和LSTM两个神经网络的结合使得网络超参数的组合选择对预测精度尤为重要,使用麻雀搜索算法对组合神经网络的主要参数进行寻优,找到一组超参数使其在训练融合CNN模型与LSTM模型组合效果达到最优。经VMD处理后的数据分量可使用优化组合模型进行预测。与使用原始风电功率数据类似,但会将预测三个分量的结果进行叠加,得到最后的风电功率预测结果。其中,某个分量的预测流程构建如图2所示。




图2 VMD处理后数据分量的预测模型流程

Fig.2 Predictive model flow for VMD post-processed components

2.3 SSA优化VMD-CNN-LSTM流程

SSA-CNN-LSTM混合模型中SSA优化CNN卷积层的大小、两个LSTM层的神经元个数和学习率。混合模型采用Adam优化器,设置提前6个步长的滑动窗口进行滚动预测。选用混合模型的平均相对误差MSE作为SSA算法的目标函数,计算公式如下:

$$MSE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (8)$$

式中: n 为样本总个数; y_i 为某个时刻原始值; $\hat{y}_i$ 为预测值。

超参数的取值范围如表1所示。

表1 超参数的取值范围

Tab.1 Range of values for hyperparameters

模型超参数	取值范围
卷积核个数	[10, 70]
LSTM1隐藏层神经元个数	[10, 100]
LSTM2隐藏层神经元个数	[10, 100]
学习率	[0.002, 0.010]

SSA优化混合模型的流程步骤如下:

1)初始化麻雀种群数、最大迭代次数、最小寻优边界范围等相关参数。

2)计算适应度值,排序找出当前最好和最差的个体。

3)对发现者的位置 $X_{F,w}$ 利用下式进行更新:

$$X_{F,w} = \begin{cases} X_{m,n}^t \cdot \exp\left(\frac{-m}{\alpha \cdot K}\right) & R_2 < ST \\ X_{m,n}^t + Q \cdot L & R_2 \geq ST \end{cases} \quad (9)$$

式中: $X_{m,n}^t$ 为种群中第 m 个个体的第 n 维位置; t 为当前迭代数; α 为一个随机数, $\alpha \in (0,1)$; K 为常数; Q 为随机数且服从标准正态分布; L 为 $1 \times d$ 的矩阵; $R_2 \in [0,1]$ 为预警值; $ST \in [0.5,1]$ 为安全值。

如果预警值较小,说明没有捕食者出现,周围环境安全,发现者可以执行广泛的搜索;反之,说明有捕食者出现,威胁到了种群安全,种群中的某些个体会发出警报,此时所有个体需要飞去其他安全的地方进行觅食。

4)种群中追随者所执行的规则是,一旦监督到发现者寻找到更好的食物,它们会立即离开当前的位置,去争夺食物,如果寻找成功,则会立即得到发现者位置的食物。追随者的更新位置公式如下:

$$X_{G,w} = \begin{cases} Q \cdot \exp\left(\frac{X_w^t - X_{m,n}^t}{i^2}\right) & m > i/2 \\ X_b^{t+1} + |X_{m,n}^t - X_b^{t+1}| \cdot A^+ \cdot L & m \leq i/2 \end{cases} \quad (10)$$

式中: X_b 为发现者发现最佳食物的位置; X_w 为最差

食物的位置; A^+ 为一列元素为+1或-1的矩阵; i 为第 i 个麻雀, $i/2$ 代表设置的适应度边界值,表示麻雀是否获得食物,若获得食物,则适应度在较高区域,反之,则在较低区域,需要重新寻找地点觅食。

5)麻雀种群中的捕食者占比20%,其初始位置根据下式随机产生:

$$X_{J,w} = \begin{cases} X_b^t + \tau \cdot |X_{m,n}^t - X_b^t| & f_i < f_g \\ X_{m,n}^t + K \cdot \left[\frac{|X_{m,n}^t - X_b^t|}{(f_i - f_w) + \delta} \right] & f_i = f_g \end{cases} \quad (11)$$

式中: τ 为服从正态分布的控制参数; X_b 为 t 时刻麻雀的最佳位置; f_i 为第 i 个麻雀的个体适应度值; f_g 和 f_w 为全局最佳适应度值和最差适应度值; δ 为最小常数。

当 $f_i = f_g$ 时,说明麻雀正在受到危险,麻雀会飞到更加安全的中心区域躲避风险。

SSA算法流程图如图3所示。




图3 SSA算法流程图

Fig.3 SSA algorithm flowchart

3 算例分析

3.1 集群风电场的特征序列结果分析

本文选用某集群风电场的风电功率数据对所提方法的有效性进行验证。其中风电场WF2为新建风电场。根据文献[21]的多风电场互相关性分析,风电场WF2的风功率和本风电场风速、风向及相邻风电场风电功率之间的相关性热图如图4所示,建立的模型是预测未来的风电功率,属于短期预测场景,时间分辨率为1h。




图4 集群风电场相关性热图

Fig.4 Cluster wind farm correlation heat map

由图4可知,风电场WF2的风电功率预测序列除了与自身风电场的风速呈现一定正相关性外,还与相邻三个风电场WF3,WF4和WF5的风功率有强相关性,因此选择WF3,WF4和WF5的风电功率数据作为特征进行分解,通过CNN卷积神经网络挖掘各风电场之间对应子模态分量的相互作用。

3.2 模型寻优设置

SSA-VMD-CNN-LSTM方法的参数设置为:麻雀的种群规模 N 为5,发现者占比20%,个数为20;适应度函数选为CNN-LSTM模型的均方根误差,最大迭代次数为50;模型选取sigmoid作为激活函数。

以多风电场中的原始风电功率分解后的低频组合分量为例,SSA-VMD-CNN-LSTM的迭代过程的适应度曲线如图5所示。由图5可以看出,参数寻优过程中,与参考算法粒子群算法PSO相比,SSA方法用时较短,并且在组合神经网络的超参数寻优过程中收敛速度较快,表现出良好的全局搜索性能。经过超参数寻优,设定CNN的卷积核个数为36,LSTM1隐藏层神经元个数为55,LSTM2隐藏层神经元个数为38,学习率为0.0094。




图5 SSA的适应度曲线

Fig.5 SSA's fitness curve

图6为SSA的超参数随迭代次数的变化而变化的曲线图。




图6 SSA的超参数随迭代次数的变化

Fig.6 The hyperparameters of the SSA vary with the number of iterations

3.3 预测结果和分析

图7为残差分量、高频分量、低频分量三个分量的预测结果,结果表明运用本文提出的组合模型,针对不同频段的信息也可以挖掘周边风电场与本风电场的历史风电功率序列之间的互相关信息,实现较好的预测精度。




图7 三个分量的预测结果

Fig.7 Prediction results for three components

将变分模态分解后得到的各本征模态分量(intrinsic mode functions, IMF)代入到优化好的组合模型中进行训练组合,每个分量都能通过优化组合模型得到比原始序列预测出的更加准确的结果,最后将三个分量的预测结果进行叠加。为了检验本文算法的预测效果,将LSTM,CNN-LSTM和模型超参数经过SSA优化的VMD-LSTM,VMD-

CNN-LSTM 算法进行对比实验,实验结果如图 8 所示。




图 8 预测曲线图

Fig.8 Forecast graphs

由图 8 可以看出,单一的预测模型 LSTM 与组合模型 CNN-LSTM 相比较会出现预测滞后现象,从预测精度上看,加入 CNN 模型提取多个风电场空间信息的效果好,说明 CNN 模型的加入提高了预测精度。图 8 中,SSA-VMD-LSTM 和 SSA-VMD-CNN-LSTM 模型与未分解的模型相比较,变分模态分解可以有效处理非平稳的风电功率时间序列,使其各个子序列更加平稳,进一步减少使用原始序列预测的时滞现象。SSA 的搜索优化能力和寻优能力能有效搜索到 CNN-LSTM 神经元中的最佳超参数设置,通过 SSA 优化的组合深度神经网络模型,避免了人工调节参数不精确导致的预测误差,有效提升了多风电场中新建风电场的预测精度。

表 2 显示了四种模型的预测评估指标,评估指标选用均方根误差(root mean square error, RMSE)、平均绝对误差(mean absolute error, MAE)和预测误差(mean absolute percentage error, MAPE)。根据预测指标的对比可以看出,经过 SSA 优化的 VMD-CNN-LSTM 的整体预测精度最高,使用分解序列的预测模型并没有展现出明显的误差传递现象。平均相对误差分别达到 0.585 kW, 0.261 kW, 0.420 kW 和 0.202 kW,均方根误差分别达到 0.681 kW, 0.388 kW, 0.332 kW 和 0.295 kW。

表 2 模型预测期望评估表

Tab.2 Model prediction expectation assessment table

	MAE/kW	RMSE/kW	MAPE/%
LSTM	0.585	0.681	10.033
CNN-LSTM	0.261	0.388	4.950
VMD-LSTM	0.420	0.332	6.057
本文算法	0.202	0.295	3.114

由表 2 仿真分析结果表明,本文提出的 SSA-

VMD-CNN-LSTM 模型在处理新建风电场缺乏足够数据的情况下,仍能利用周边风电场数据进行时空相关性的信息提取,由于多个风电场的非平稳数据较多,利用变分模态分解多风电场数据,可以挖掘不同风电场之间相同高频、低频和残差模态中的相关性,其预测精度较单一模型实现明显提升。

4 结论

针对集群风电场中新建风电场数据匮乏、较难准确进行风功率预测的问题,本文利用与新建基准风电场相邻的周边风电场历史数据,提出使用基于 SSA-VMD-CNN-LSTM 组合模型的短期风电功率预测方法,并通过算例分析对预测方法进行了验证。主要结论如下:

1) 变分模态分解多风电场内部的风功率时间序列,可以实现每个分量的物理解释,这样方便新建基准风电场和周边风电场同模态下的特征组合,对每个分量建立预测模型,有效提高组合模型的预测精度。

2) 与单一的模型不同,卷积神经网络能够提取不同风电场之间的空间相关性信息, CNN 可以提取变分模态分解的风功率子模态分量之间的空间相关性,通过 SSA 算法优化后的模型可进一步提高风电功率预测精度。

3) 与单一 LSTM 模型相比,基于 VMD 的组合深度学习结构,可以有效地处理多风电场内的复杂的时间序列数据,同时有效地反映了风电场之间的相关性,具有更好的预测效果。

参考文献

- [1] 黄之奇,余家琪,史可欣,等. 疫情和碳中和背景下的风电建设[J]. 中国经贸导刊, 2021(10): 4-6.
HUANG Zhiqi, YU Jiaqi, SHI Kexin, et al. Wind power construction under the background of epidemic and carbon neutrality[J]. China Economic and Trade Herald, 2021(10): 4-6.
- [2] 张文秀,武新芳,陆豪乾. 风电功率预测技术综述与改进建议[J]. 电力与能源, 2014, 35(4): 436-441.
ZHANG Wenxiu, WU Xinfang, LU Haoqian. Review of wind power prediction technology and improved suggestions[J]. Electric Power and Energy, 2014, 35(4): 436-441.
- [3] 郑文书. 基于时空相关性的区域风电场群风速预测研究[D]. 北京: 华北电力大学, 2014.
ZHENG Wenshu. Research on wind speed forecasting of regional wind farm group based on spatio-temporal correlation[D]. Beijing: North China Electric Power University, 2014.

- [4] 邵联合,李兴国. 风电场模型预测多时间尺度电压协调控制[J]. 电气传动,2018,48(4):41-48.
SHAO Lianhe, LI Xingguo. Model predictive multi time scale voltage coordinated control of wind farms[J]. Electric Drive, 2018,48(4):41-48.
- [5] 王红刚,李彬. 基于融合长短时记忆网络的风电场超短期风速预测研究[J]. 可再生能源,2020,38(1):41-46.
WANG Honggang, LI Bin. Very-short-term wind speed prediction of multiple wind farms based on merged long-short term memory networks[J]. Renewable Energy, 2020,38(1):41-46.
- [6] 李国,江晓东. 基于提升回归树与随机森林的风电功率集成预测方法[J]. 电力系统及其自动化学报,2018,30(11):70-74.
LI Guo, JIANG Xiaodong. Wind power generation ensemble forecasting method based on boosted regression tree and random forest[J]. Proceedings of the CSU-EPSA, 2018, 30(11):70-74.
- [7] SHI K, QIAO Y, ZHAO W, et al. An improved random forest model of short-term wind-power forecasting to enhance accuracy, efficiency, and robustness[J]. Wind Energy, 2018, 21(12):1383-1394.
- [8] LIU H, TIAN H, LIANG X, et al. Wind speed forecasting approach using secondary decomposition algorithm and Elman neural networks[J]. Applied Energy, 2015, 157:183-194.
- [9] 余洋,董存,王铮,等. 考虑山东近海不同风能天气特征的风电功率区间预测模型[J]. 电网技术,2020,44(4):1238-1247.
YU Feng, DONG Cun, WANG Zheng, et al. Wind power interval forecasting model considering different wind energy weather characteristics in Shandong offshore areas[J]. Power System Technology, 2020,44(4):1238-1247.
- [10] 蒲炯怡,毕贵红,王凯,等. 基于二层分解的PSO-LSTM模型风电功率超短期预测[J]. 电机与控制应用,2021,48(5):86-92.
PU Xianyi, BI Guihong, WANG Kai, et al. Ultra-short-term wind power prediction based on two-layer decomposition technique and PSO-LSTM model[J]. Motor and Control Applications, 2021,48(5):86-92.
- [11] LIU H, TIAN H, LI Y. Comparison of new hybrid FEEMD-MLP, FEEMD-ANFIS, wavelet packet-MLP and wavelet packet-ANFIS for wind speed predictions[J]. Energy Conversion and Management, 2015, 89(Jan):1-11.
- [12] 金江涛,许子非,李春,等. 基于深度学习与混沌特征融合的滚动轴承故障诊断[J]. 控制理论与应用,2022,39(1):109-116.
JIN Jiangtao, XU Zifei, LI Chun, et al. Rolling bearing fault diagnosis based on deep learning and chaotic feature fusion[J]. Control Theory and Application, 2022,39(1):109-116.
- [13] 孙波,姜宇宏,杨青. SSA优化融合CNN的电机轴承故障诊断方法研究[J]. 沈阳理工大学学报,2021,40(3):9-13.
SUN Bo, JIANG Yuhong, YANG Qing. Research on fault diagnosis method of motor bearing based on SSA optimization and CNN[J]. Journal of Shenyang Ligong University, 2021, 40(3):9-13.
- [14] 杨子民,彭小圣,郎建勋,等. 基于集群动态划分与BLSTM深度学习的风电集群短期功率预测[J]. 高电压技术,2021,47(4):1195-1203.
YANG Zimin, PENG Xiaosheng, LANG Jianxun, et al. Short-term wind power prediction based on dynamic cluster division and BLSTM deep learning method[J]. High Voltage Technology, 2021,47(4):1195-1203.
- [15] 彭秀艳,张彪. 基于EMD-PSO-LSTM组合模型的船舶运动姿态预测[J]. 中国惯性技术学报,2019,27(4):421-426.
PENG Xiuyan, ZHANG Biao. Prediction of ship motion attitude based on EMD-PSO-LSTM combination model[J]. Chinese Journal of Inertial Technology, 2019,27(4):421.
- [16] 李雅丽,王淑琴,陈倩茹,等. 若干新型群智能优化算法的对比研究[J]. 计算机工程与应用,2020,56(22):1-12.
LI Yali, WANG Shuqin, CHEN Qianru, et al. Comparative study of several new swarm intelligence optimization algorithms[J]. Computer Engineering and Applications, 2020, 56(22):1-12.
- [17] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2013, 62(3):531-544.
- [18] 王粟,江鑫,曾亮,等. 基于VMD-DESN-MSGP模型的超短期光伏功率预测[J]. 电网技术,2020,44(3):917-926.
WANG Su, JIANG Xin, ZENG Liang et al. Ultra-short-term photovoltaic power prediction based on VMD-DESN-MSGP model[J]. Power System Technology, 2020,44(3):917-926.
- [19] 杨茂,白玉莹. 基于多位置NWP和门控循环单元的风电功率超短期预测[J]. 电力系统自动化,2021,45(1):177-183.
YANG Mao, BAI Yuying. Ultra-short-term prediction of wind power based on multi-position NWP and gated cycle unit[J]. Power System Automation, 2021,45(1):177-183.
- [20] 宋家康,彭勇刚,蔡宏达,等. 考虑多位置NWP和非典型特征的短期风电功率预测研究[J]. 电网技术,2018,42(10):3234-3242.
SONG Jiakang, PENG Yonggang, CAI Hongda, et al. Research of short-term wind power forecasting considering multi-location NWP and uncanonical feature[J]. Power System Technology, 2018,42(10):3234-3242.
- [21] XUE J K, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. Systems Science & Control Engineering, 2020, 8(1):22-34.
- [22] 林爱美. 基于多任务学习的风光电站群功率预测方法研究[D]. 北京:华北电力大学,2021.
LIN Aimei. Research on multi-task learning based method for power forecasting in wind and solar power station clusters[D]. Beijing:North China Electric Power University, 2021.

收稿日期:2022-02-17

修改稿日期:2022-03-03