

DOI:10.19651/j.cnki.emt.2518738

基于优化 SVMD-IBiTCN-BiLSTM 模型的 短期风电功率预测方法*

丁浩展^{1,2} 刘硕^{1,2} 马纪颖^{1,2}

(1. 沈阳化工大学计算机科学与技术学院 沈阳 110142; 2. 辽宁省化工过程工业智能化技术重点实验室 沈阳 110142)

摘要: 较高的风电功率预测精度,能够保障电网可持续稳定运行。针对风电数据的波动性和随机性等特征导致预测精度欠佳的问题,基于分解-预测模型,提出使用连续变分模态分解算法(SVMD)分解数据,双向时间卷积网络(BiTCN)和双向长短期记忆网络(BiLSTM)进行预测为基础的分解预测模型,以提升短期风电功率预测的精度。使用加入牛顿法增强局部搜索能力的壮丽细尾鹩莺优化算法(SFOA-N)搜寻 SVMD 的最佳惩罚因子和预测模型的最佳超参数。针对 BiTCN 中指数增长膨胀率无法适应不同时间序列中的复杂模式的技术难题,提出一种加入动态膨胀率预测模块改进 BiTCN 的创新方法,可根据输入数据的不同自动调整膨胀率,从而提升预测性能。经本文数据集验证,与单一 BiTCN 模型对比,基于优化 SVMD-IBiTCN-BiLSTM 模型的决定系数达到了 0.998 2,平均绝对百分比误差、均方根误差和平均绝对误差分别下降了 3.57、9.94 和 7.21,具有较高的预测精度。

关键词: 风电功率预测;连续变分模态分解;双向时间卷积网络;双向长短期记忆网络;壮丽细尾鹩莺优化算法
中图分类号: TN91;TM614 **文献标识码:** A **国家标准学科分类代码:** 470.4070

Short-term wind power prediction method based on optimized SVMD-IBiTCN-BiLSTM model

Ding Haozhan^{1,2} Liu Shuo^{1,2} Ma Jiyang^{1,2}(1. College of Computer Science and Technology, Shenyang University of Chemical Technology, Shenyang 110142, China;
2. Liaoning Key Laboratory of Intelligent Technology for Chemical Process Industry, Shenyang 110142, China)

Abstract: The accuracy of wind power prediction is crucial for ensuring the sustainable and stable operation of power grids. To address the issue of inadequate prediction accuracy caused by the volatility and stochasticity of wind power data, this study proposes a decomposition-prediction model based on the Successive Variational Mode Decomposition (SVMD) algorithm for data decomposition, combined with a Bidirectional Temporal Convolutional Network (BiTCN) and Bidirectional Long Short-Term Memory Network (BiLSTM) for prediction. The Splendid Fairy-wren Optimization Algorithm enhanced with Newtonian method (SFOA-N) is employed to optimize SVMD's penalty factor and the hyperparameters of the prediction model, thereby improving local search capability. To resolve the technical challenge that the exponentially growing dilation rate in BiTCN struggles to adapt to complex patterns across different time series, an innovative dynamic dilation rate prediction module is proposed. This module automatically adjusts dilation rates according to varying segments of input data, significantly enhancing prediction performance. Experimental results demonstrate that compared with standalone BiTCN models, the optimized SVMD-IBiTCN-BiLSTM model achieves a coefficient of determination of 0.998 2, with mean absolute percentage error, root mean square error, and mean absolute Error reduced by 3.57, 9.94, and 7.21 respectively, demonstrating superior forecasting accuracy.

Keywords: wind power forecasting; sequential variational mode decomposition; bidirectional temporal convolutional network; bidirectional long short-term memory; superb fairy-wren optimization algorithm

0 引言

风能作为一种清洁、高效的能源,已成为我国能源结构

调整和绿色发展的重要方向^[1]。然而,风能的随机性、波动性和预测困难等特点给电网调度和电力系统运行带来很大的挑战。因此,提升风电功率预测的准确性尤为重要^[2]。

收稿日期:2025-05-04

* 基金项目:辽宁省自然科学基金(2022-MS-291)、国家外国专家项目计划(G2022006008L)、辽宁省教育厅基本科研项目(LJKMZ20220781)资助

长期以来,国内外学者针对提高风电功率预测问题开展了深入的研究,并陆续提出了一系列基于机器学习的预测方法。现在比较受欢迎的是在数据处理阶段引入了模态分解算法,然后使用机器学习方法预测,构建分解-预测的框架^[3]。

在数据处理部分,变分模态分解^[4](variational mode decomposition, VMD)是现在常用的算法。但是 VMD 算法需要人为设置模态数、惩罚因子等参数,参数选择不当会影响分解效果,针对这个问题研究人员提出连续变分模态分解^[5](sequential variational mode decomposition, SVMD),分解过程不需要设置模态数。但是惩罚因子仍需设置,为此引入了启发式优化算法。文献[6]提出一种使用鲸鱼优化算法寻找 SVMD 最佳惩罚因子;文献[7]使用灰狼优化算法寻找 SVMD 最佳惩罚因子。但是大多数启发式优化算法的全局探索和局部开发的平衡不够好,全局搜索能力比较强但是局部搜索能力较弱,文献[8]提出牛顿-拉夫逊优化算法,结合了牛顿法的快速收敛特性和启发式算法的全局搜索能力,可知牛顿法局部搜索能力较强。

在预测部分,机器学习因其具有较高的预测精度,并且成本较低,备受研究者关注,诸如双向长短期记忆(bidirectional long short-term memory, BiLSTM)网络,双向时序卷积网络(bidirectional temporal convolutional network, BiTCN)等。相较于单一的机器学习预测模型,采用多种机器学习算法的组合预测模型,展现出更好的稳定性、灵活性和预测精度,成为当前研究与实际应用热点。文献[9]通过结合 BiTCN 和 BiLSTM 模型降低了预测误差,提高了预测精度,但是该模型并没有解决超参数对预测结果的影响。冯平等^[10]使用改进蜣螂优化算法优化模型的超参数,但是只搜索了隐藏层神经元数、初始学习率和正则化参数;文献[11]使用改进龙虾优化算法寻找 BiTCN-BiLSTM 最佳超参数,但是搜索超参数不够全面;文献[12]提出基于 BiTCN、BiLSTM 和注意力机制并由改进的麻雀搜索算法优化的组合模型,但是超参数搜索依然不够全面。柳博等^[13]提出使用改进的白鲸优化算法优化 BiTCN-BiGRU 方法中涵盖的超参数比较全面。但是由于使用优化方法搜寻的 BiTCN 网络中卷积膨胀率过于固定,导致无法适应不同时间序列中的复杂模式。

综上所述,本文提出一种改进壮丽细尾鸫优化算法(superb Fairy-wren optimization algorithm-Newton, SFOA-N)搜索连续变分模态分解(SVMD)合适的惩罚因子、搜索增加了动态膨胀率预测模块改进的双向时间卷积网络(improve bidirectional temporal convolutional network, IBiTCN)以及双向长短期记忆网络(BiLSTM)最佳超参数的短期风电功率预测模型。该模型解决了启发式优化算法的局部搜索能力不足, BiTCN 网络膨胀率不够灵活的问题,本文工作主要如下:

1) SFOA 引入牛顿法。针对壮丽细尾鸫优化算

法^[14](superb Fairy-wren optimization algorithm, SFOA)局部搜索能力不足的问题,引入牛顿法进行局部搜索,提高算法优化能力,改进后 SFOA 进行全局搜索,牛顿法进行局部优化。

2) SFOA-N-SVMD 分解去噪。通过连续变分模态分解对风电数据进行分解去噪,并使用 SFOA-N 进行参数寻优,选择合适的惩罚因子。分解得到的 IMF 作为预测模型输入,可以剔除信号中的噪声和冗余信息,提供更干净和精确的数据给预测模型,有助于提高模型的预测准确性。

3) 改进 BiTCN 模型。将扩张因果卷积中的膨胀率由原来的指数增长转换为由动态膨胀率预测模块预测输入的膨胀率,使模型更灵活,可以根据输入数据的不同自动调整膨胀率,从而提升预测性能。

4) 构建 SFOA-N-IBiTCN-BiLSTM 预测模型。使用 SFOA-N 对预测模型进行超参数寻优。然后对本文模型进行全面的对比消融实验。

1 数据分解模型

1.1 壮丽细尾鸫优化算法

壮丽细尾鸫优化算法是 2025 年新提出的启发式算法,灵感来源于壮丽细尾鸫的 3 种自然行为:幼鸟生长、繁殖喂养、躲避天敌。通过模拟评估时间的变化来模拟其在空间中的搜索能力,以有效地解决现实环境中的优化问题。每个 SFOA 成员是问题的候选解决方案,并使用向量进行数学建模。向量的每个元素对应于决策变量,所有 SFOA 成员共同构成整个算法如式(1)所示。

$$\mathbf{X} = \begin{bmatrix} \mathbf{X}_1 \\ \vdots \\ \mathbf{X}_i \\ \vdots \\ \mathbf{X}_N \end{bmatrix} = \begin{bmatrix} x_{1,1} & \cdots & x_{1,d} & \cdots & x_{1,D} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ x_{i,1} & \cdots & x_{i,d} & \cdots & x_{i,D} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ x_{N,1} & \cdots & x_{N,d} & \cdots & x_{N,D} \end{bmatrix}_{N \times D} \quad (1)$$

式中: \mathbf{X} 为 SFOA 全局矩阵, \mathbf{X}_i 是第 i 个成员, $x_{i,d}$ 是搜索空间中 SFOA 的决策变量。

1) 初始化阶段。在开始主要策略前,需要先初始化种群的位置,公式如下:

$$\mathbf{X} = (ub - lb) \times rand(0, 1) + lb \quad (2)$$

式中: ub 和 lb 分别表示搜索空间在第 j 维的上、下边界, $rand(0, 1)$ 为区间 $[0, 1]$ 内的随机数。

2) 幼鸟生长阶段。当判断到幼鸟在种群中的比例较大(用一个系数 r 来衡量)时,算法进入幼鸟生长阶段。因为幼鸟数量过多会影响种群整体生存,需要通过大量学习与位置变动,促使幼鸟尽快成长为成鸟,从而提升搜索的全局探索能力。

3) 繁殖哺育阶段。当算法检测到环境危险因子较低(以 s 表示)且成鸟为主时,种群会转入繁殖哺育阶段。算法中,为评估环境危险程度,首先用式(3)来计算环境风险量,模拟风险波动。当 s 值偏小意味着环境相对安全,

SFOA 在繁殖期间,几只成员轮流照顾卵直到它们孵化。这种行为导致 SFOA 在巢附近小范围内移动,并且每个 SFOA 成员都有机会外出寻找食物和照顾孩子,使 SFOA 在一定局部范围内进行深入探索。

$$s = r_1 \times 20 + r_2 \times 20 \quad (3)$$

式中: r_1 和 r_2 为 $[-1,1]$ 区间的随机数。

4) 避免自然敌人阶段。若检测到环境的危险因子 s 较高,表明当前情形不利于繁殖,种群会切换到天敌规避阶段。此时,算法参考壮丽细尾鸨遇到捕食者时的两种典型行为:被天敌盯上的鸟快速逃窜,而其他同伴会在空中抖动羽毛示警,形成较大的扰动。以此来设计个体位置更新的模式,令整个种群获得随机跳动,以跳出局部陷阱,极大地增加了 SFOA 在空间探索中的随机性。

SFOA 计算公式如式(4)所示。

$$X_{new,i,j} = \begin{cases} X'_{i,j} + (lb + (ub - lb) \times rand), & r > 0.5 \\ X_b \times C + (X_b - X'_{i,j}) \times p, & r \leq 0.5, s > 20 \\ X_b + X_{i,j} \times l \times k, & r \leq 0.5, s \leq 20 \end{cases} \quad (4)$$

式中: X_b 表示全局最佳解位置, C 为一个常数, p 表示成熟度, l 是莱维飞行随机步长, k 是自适应飞行平衡因子用于控制逃逸幅度。

1.2 壮丽细尾鸨-牛顿优化算法

牛顿法(Newton's method, NM)是一种用于寻找实数域和复数域上方程根的迭代优化算法。在优化领域,牛顿法主要用于寻找可导函数的局部极值(最小值或最大值)。其核心思想是通过利用目标函数的二阶导数(Hessian 矩阵)信息,构建二次近似模型,从而快速收敛到极值点。迭代公式为:

$$x_{k+1} = x_k - \mathbf{H}(x_k)^{-1} \nabla f(x_k) \quad (5)$$

式中: $\nabla f(x_k)$ 是梯度, $\mathbf{H}(x_k)$ 是 Hessian 矩阵。

SFOA-N 流程图如图 1 所示, SFOA-N 基于种群多样性或迭代次数阈值触发 SFOA 全局搜索,通过模拟幼鸟生长阶段的随机搜索和躲避天敌的莱维飞行, SFOA 能有效探索解空间,避免陷入局部最优。当适应度变化率低于阈值或检测到局部收敛趋势时,引入牛顿法进行局部优化,利用其二阶导数信息快速收敛到精确解,弥补 SFOA 局部搜索能力的不足,算法进行梯度和 Hessian 计算,若 Hessian 矩阵非正定,添加正则项。

1.3 连续变分模态分解

连续变分模态分解是基于 VMD 改进的分解算法,分解时不需要人为设置模态个数,用于将复杂的信号分解为一系列模态函数(intrinsic mode function, IMF)。SVMD 核心思想是通过变分模态分解的方式,逐次从信号中提取模态函数,在每个迭代步骤中, SVMD 通过最小化信号与模态函数之间的差异来更新模态函数,直到收敛,分解工程基于以下 4 个准则:

- 1) 每个模态应围绕其中心频率紧凑,使其信号成分集

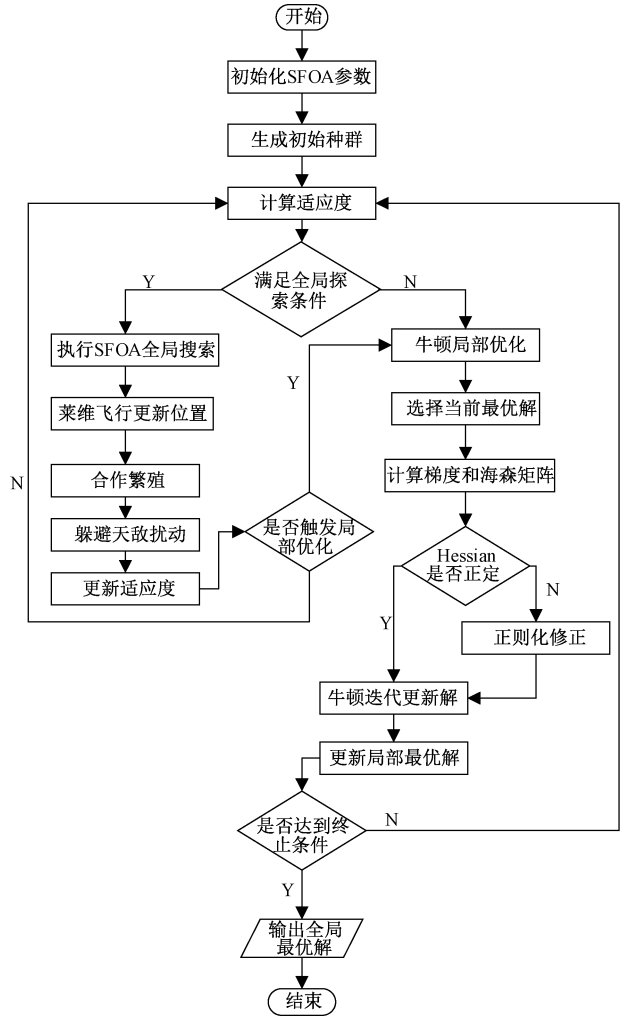


图 1 SFOA-N 流程图

Fig. 1 SFOA-N flow chart

中在特定的频率范围内。

- 2) 通过最小化残差信号的能量来实现去除白噪声的能力,降低噪声对信号分析的影响,提高信号的纯净度。

- 3) 滤除新模态在其前面模态中心频率附近处的信号成分,确保不同模态之间具有较好的区分度。

- 4) 满足上述 3 个准则后,将得到的模态组合时能够完整地重构原始信号。

2 预测模型原理

2.1 改进双向时间卷积网络

BiTCN 的核心特性:因果卷积:这种卷积方式确保在预测当前时刻的值时,模型仅依赖于当前时刻及之前的信息,从而保证了预测的因果性;扩张卷积:通过在卷积核中的元素之间引入“间隔”,扩张卷积能够在不增加卷积核尺寸的前提下,有效地扩大卷积的感受野,捕捉更广泛的时序依赖关系;残差链接:残差链接的设计允许信息直接跨层传递,绕过某些中间层。这种机制有助于缓解深层网络中常

见的梯度消失问题,从而提高模型的训练效率和性能。

在 TCN 架构中,膨胀率是按照层数呈指数增长的,第 1 层的膨胀率 $d=1$,第 2 层 $d=2$,第 3 层 $d=4$,依此类推。这种固定模式虽然能够有效扩大感受野,但缺乏灵活性,无法根据输入数据的特性进行自适应调整。本文提出了一种动态膨胀率预测模块。在该模块的作用下,每个残差块的膨胀率不再遵循预设的指数增长规律,而是能够依据输入数据的特征动态地进行调整。模型可以在不同层次或不同时间步长上灵活选择合适的膨胀率,从而更好地适应数据中潜在的周期性特征和长期依赖结构。

动态膨胀率预测层步骤如下:

1)输入特征,定义:

$$\mathbf{X} \in \mathbb{R}^{B \times T \times C} \quad (6)$$

式中: B 表示批次大小, T 表示时间步, C 表示通道数。

2)局部特征提取和全局特征提取,局部特征使用一维卷积,卷积核为 3,ReLU 激活函数;全局特征提取使用全局平均池化捕获全局统计量,ReLU 激活函数,公式如下:

$$\mathbf{H}_{local} = \text{ReLU}(\text{Conv1D}(\mathbf{X}, \mathbf{W}_{local})) \quad (7)$$

式中: \mathbf{W}_{local} 为局部卷积核权重, \mathbf{H}_{local} 为局部特征。

$$\boldsymbol{\mu} = \frac{1}{T} \sum_{t=1}^T \mathbf{X}_t \in \mathbb{R}^{B \times C} \quad (8)$$

$$\mathbf{H}_{global} = \text{ReLU}(\mathbf{W}_{global} \cdot \boldsymbol{\mu} + \mathbf{b}_{global}) \in \mathbb{R}^{B \times H} \quad (9)$$

式中: \mathbf{W}_{global} 为全连接层权重, \mathbf{b}_{global} 为偏置。

3)特征融合与膨胀率预测,把提取的特征进行融合,然后使用 Sigmoid 函数进行预测,公式如下:

$$\mathbf{F}_{fused} = [\mathbf{H}_{local}; \mathbf{H}_{global} \otimes \mathbf{1}_T] \quad (10)$$

$$\alpha = \sigma(\mathbf{W}_2 \cdot \text{ReLU}(\mathbf{W}_1 \cdot \mathbf{F}_{fused} + \mathbf{b}_1) + \mathbf{b}_2) \quad (11)$$

式中: $\otimes \mathbf{1}_T$ 表示将全局特征沿时间步复制 T 次, $\mathbf{W}_1, \mathbf{W}_2$ 为融合层权重, $\mathbf{b}_1, \mathbf{b}_2$ 为偏置, $\sigma(\cdot)$ 为 Sigmoid 激活函数。

4)膨胀率映射,将系数映射到预设的膨胀率范围,通过 STE 进行量化,同时保持梯度传播,公式如下:

$$d = 1 + \alpha \cdot (d_{max} - 1) \quad (12)$$

式中: d_{max} 为人为设定最大膨胀率,本文设定为 24。

$$d_{quant} = \lfloor d \rfloor + (d - \lfloor d \rfloor) \cdot \text{deatch}() \quad (13)$$

数据经过动态膨胀率预测层得到了预测的膨胀率,然后把得到的膨胀率输入一维扩张因果卷积。图 2 为动态膨胀率预测层的提取部分的网络结构,图 3 为动态膨胀率预测层的流程图。

2.2 双向长短期记忆网络

BiLSTM 是循环神经网络的一种高级变体,它通过在 RNN 的基础上增加一条反向的记忆链条,能够更有效地捕捉数据中的长期依赖关系。LSTM 的核心机制是细胞状态,它像一条信息传送带一样,贯穿整个时间序列,使得信息可以在序列中保持和传递。在每个时间步, LSTM 通过输入门、遗忘门和输出门的协同作用,对细胞状态进行精确的信息更新和传递。图 4 所示为 LSTM 每个时间步细节图。

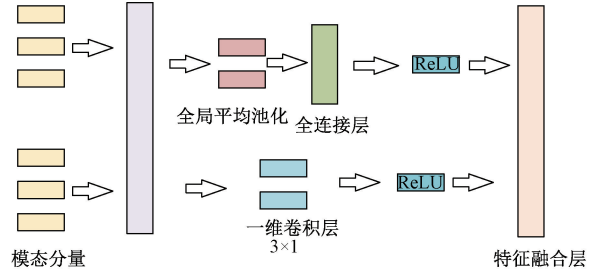


图 2 动态膨胀率预测层特征提取部分网络结构
Fig. 2 Dynamic expansion rate prediction layer feature extraction part of the network structure

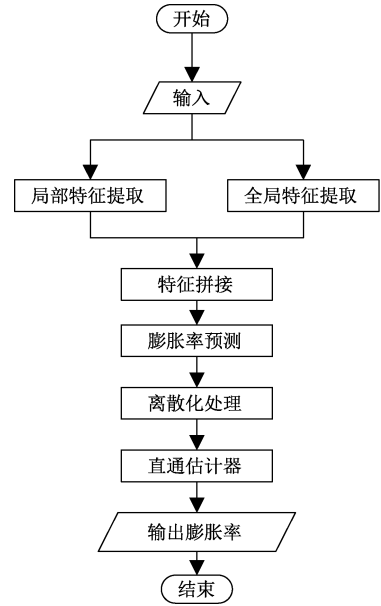


图 3 动态膨胀率预测流程图
Fig. 3 Flowchart of dynamic expansion rate prediction

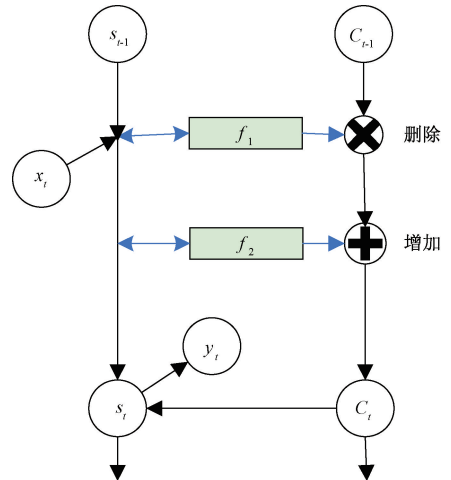


图 4 简化 LSTM 细节图
Fig. 4 Simplified LSTM detailing

遗忘门:决定哪些信息需要被保留,哪些信息需要被丢

弃,它接收当前输入 x_t 和上一时刻的隐藏状态 s_{t-1} 作为输入,通过一个 Sigmoid 激活函数将其映射到 $0 \sim 1$ 之间的值。遗忘门的计算公式如下:

$$f_t = \sigma(\mathbf{W}_f \cdot [s_{t-1}, x_t] + \mathbf{b}_f) \quad (14)$$

式中: σ 是 sigmoid 激活函数; \mathbf{W}_f 是遗忘门的权重矩阵; \mathbf{b}_f 是遗忘门的偏置项。

输入门:负责控制当前输入中有多少信息将被更新到细胞状态中。它同样接收 x_t 和 s_{t-1} 作为输入,通过 Sigmoid 函数计算出一个更新比例,同时通过一个 Tanh 激活函数对当前输入进行变换,然后将两者相乘得到需要更新到细胞状态中的信息。计算公式如下:

$$i_t = \sigma(\mathbf{W}_i \cdot [s_{t-1}, x_t] + \mathbf{b}_i) \quad (15)$$

$$\tilde{C}_t = \tanh(\mathbf{W}_c \cdot [s_{t-1}, x_t] + \mathbf{b}_c) \quad (16)$$

式中: $\mathbf{W}_i, \mathbf{W}_c$ 是输入门和候选记忆单元状态的权重矩阵; $\mathbf{b}_i, \mathbf{b}_c$ 是输入门和候选记忆单元状态的偏置项。

输出门:决定当前时刻的输出,以及哪些信息将从细胞

状态流向隐藏状态,计算公式如下:

$$o_t = \sigma(\mathbf{W}_o \cdot [s_{t-1}, x_t] + \mathbf{b}_o) \quad (17)$$

$$s_t = o_t * \tanh(\mathbf{C}_t) \quad (18)$$

式中: \mathbf{W}_o 是输出门的权重矩阵; \mathbf{b}_o 是输出门的偏置项。

2.3 SFOA-N-IBiTCN-BiLSTM 预测模型

本研究创新性地提出 IBiTCN-BiLSTM 混合预测架构,并且使用 SFOA-N 对组合模型的超参数进行寻优,图 5 为该架构模型图。该架构在传统的 BiTCN 网络基础上引入了动态膨胀率预测模块,有效解决了传统 BiTCN 网络在调整扩张率时灵活性不足的问题。通过不断调整扩张率,模型能够扩大卷积核的感受野,从而捕捉到更广泛时间范围内的依赖关系。随后,这些提取的特征被送入 BiLSTM 网络,进一步挖掘时间序列数据中的长期依赖性。最终,经过全连接层的特征映射,模型能够高效地预测时间序列数据。该模型不仅提高了预测的准确性,还增强了模型对复杂时间序列数据的适应性和鲁棒性。

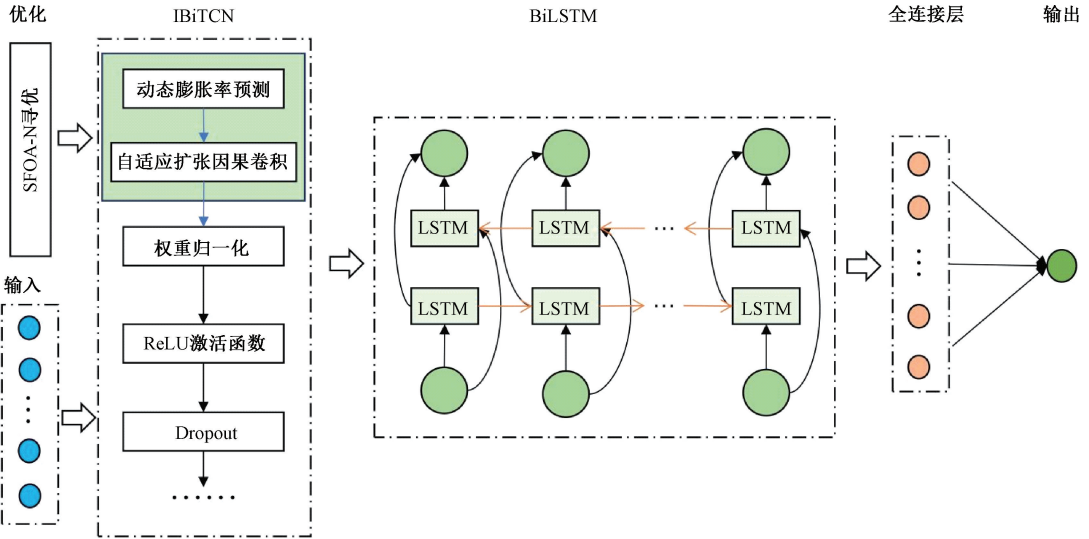


图 5 SFOA-N-IBiTCN-BiLSTM 组合预测模型图

Fig. 5 Diagram of the SFOA-N-IBiTCN-BiLSTM combined prediction mode

3 优化 SVM-D-IBiTCN-BiLSTM 分解预测模型

3.1 预测模型流程

本研究提出的优化 SVM-D-IBiTCN-BiLSTM 短期风电功率分解预测模型,其创新性框架如图 6 所示,具体流程包含四大核心技术环节:

1) 数据预处理阶段:使用矩阵分解(matrix factorization, MF)找到两个低秩矩阵,使得它们的乘积能够尽可能地逼近原始矩阵的已知部分,原始矩阵的缺失部分由对应位置低秩矩阵乘积填补,实现缺失值处理。使用局部离群因子算法(local outlier factor, LOF),通过比较样本点与其邻域样本点的局部可达密度,计算每个样本点的 LOF 分数,根据设定的阈值区分出异常样本,使用中位数进行替换,实现异常数据剔除。

2) 信号分解优化阶段:使用 SFOA-N 对 SVM-D 的惩罚因子进行寻优,使用式(19)作为适应度函数,实现对非平稳风电功率信号的自适应分解,将复杂的风电功率信号分解为多个功率分量和功率残差。

$$f(K, \alpha) = \sum_{k=1}^K \text{Entropy}(u_k) + \lambda \cdot \|\text{Original Signal} - \sum_{k=1}^K u_k\|_2^2 \quad (19)$$

式中: K 为模态数, α 为惩罚因子。

3) 多模态预测阶段:基于参数优化后的 IBiTCN-BiLSTM 混合架构进行分模态预测,首先 SFOA-N 对 IBiTCN-BiLSTM 预测模型使用式(20)作为适应度函数进行超参数寻优后,模型实现对各 IMF 分量的高精度独立预测。

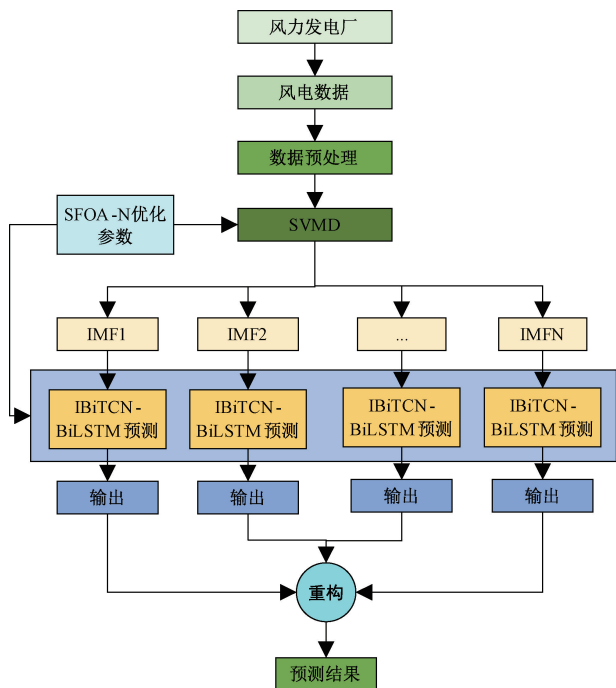


图 6 优化 SVMD-IBiTCN-BiLSTM 模型图

Fig. 6 Diagram of the NCS-SVMD-IBiTCN-BiLSTM model

$$f(\theta) = \text{Validation Loss} + \gamma \cdot \text{Model Complexity} \quad (20)$$

式中: θ 为各种超参数, γ 为正则化参数。

4) 预测重构阶段: 将各子模态预测结果按照时间步进行线性叠加, 最终输出风电功率预测值。

本研究提出的分解预测模型首先通过频域分解将复杂信号分解为更易处理的分量, 然后通过 IBiTCN-BiLSTM 模型对每个分量进行精准预测, 最后通过重构步骤整合所有预测结果, 从而得到最终的风电功率预测值。该方法能够有效提高预测的准确性, 同时增强模型的鲁棒性和适应性, 使其在不同的数据集上均能表现出良好的性能。

3.2 评价指标

为了评估不同预测模型的预测效果, 本文选用了如下误差指标: 平均绝对误差 (mean absolute error, MAE)、平均绝对百分比误差 (mean absolute percentage error, MAPE)、均方根误差 (root mean squared error, RMSE)、决定系数 (r-square, R^2), 计算公式如下:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i^{\text{pre}} - y_i}{y_{\max}} \right| \quad (21)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i^{\text{pre}} - y_i)^2} \quad (22)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i^{\text{pre}} - y_i| \quad (23)$$

$$R^2 = 1 - \frac{\sum_{i=1}^q (y_i^{\text{pre}} - y_i)^2}{\sum_{i=1}^q (\bar{y}_i - y_i)^2} \quad (24)$$

式中: N 为样本容量; y_i 为实际值; y_i^{pre} 为预测值。

4 实验结果与分析

4.1 数据准备

本文数据集来自新疆某风电场, 采样时间为 2019 年 1 月 1 日~2019 年 1 月 31 日, 间隔时间为 15 min, 共采集了 2 976 条数据。数据集训练、验证和测试划分为 7:2:1。

实验环境配置: 操作系统 Windows 11, CPU 为 Intel (R) Core(TM) i7-14650HX 2.20 GHz, 显卡为 NVIDIA GeForce RTX 4050, python 版本: 3.9.21, tensorflow-gpu 版本: 2.10.0。

4.2 SFOA-N 的优化性能分析

为了验证 SFOA-N 优化算法的性能, 将其与未改进的壮丽细尾鹈鹳优化算法、鲸鱼优化算法 (whale optimization algorithm, WOA)、灰狼优化算法 (grey wolf optimizer, GWO)、牛顿-拉夫逊优化算法 (Newton Raphson, NR)、加入 SPM 混沌映射的改进麻雀算法 (improve sparrow search algorithm, ISSA)、加入 Circle 混沌映射的变色龙优化算法 (fast chameleon swarm algorithm, FCSA) 进行对比, 以式(19)为适应度函数。

如图 7 迭代曲线对比所示, 本文提出的改进壮丽细尾鹈鹳优化算法在参数寻优过程中展现出显著优势, 从图中可以看出, SFOA-N 在迭代过程中迅速降低了适应度值, 并在较早的迭代次数内达到了较低的适应度值, 与其他算法相比, SFOA-N 不仅在初期迭代中表现出更快的收敛速度, 而且在迭代后期也保持了较低的适应度值, 显示出更强的稳定性和鲁棒性。然后以式(20)为适应度函数对 IBiTCN-BiLSTM 模型进行超参数寻优, 并且使用数据集验证 SFOA-N 优化结果。超参数搜索区间如表 1 所示。

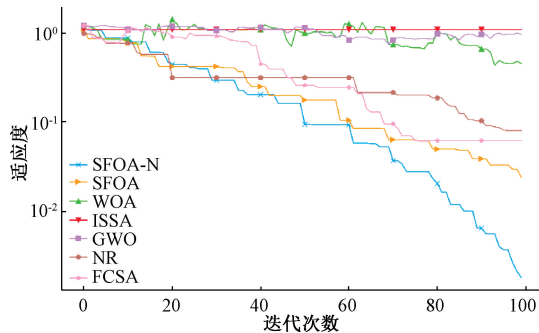


图 7 各优化算法的适应度迭代曲线

Fig. 7 Iterative curves of fitness for each optimization algorithm

如图 8 可视化对比所示, 经 SFOA-N 算法优化的预测模型输出曲线 (虚线) 与真实功率序列 (实线) 贴合度更高, 决定系数 R^2 达到了 0.995 9。由表 2 可知, 在关键误差指标方面, SFOA-N 优化方案相较 ISSA 等优化方法, MAPE、RMSE、MAE 分别为 1.19、4.64 和 2.41, 验证了 SFOA-N 算法在模型超参数优化中的先进性, 在结合牛顿

表 1 超参数搜索区间

Table 1 Hyperparameter search intervals

超参数	寻优范围
批量大小	[20,500]
初始学习率	[0.001,0.1]
正则化参数	[0.000 1,0.001]
IBiTCN 单元数	2,4,8
BiLSTM 神经元数	[10,50]
全连接层激活函数	Sigmoid,ReLU

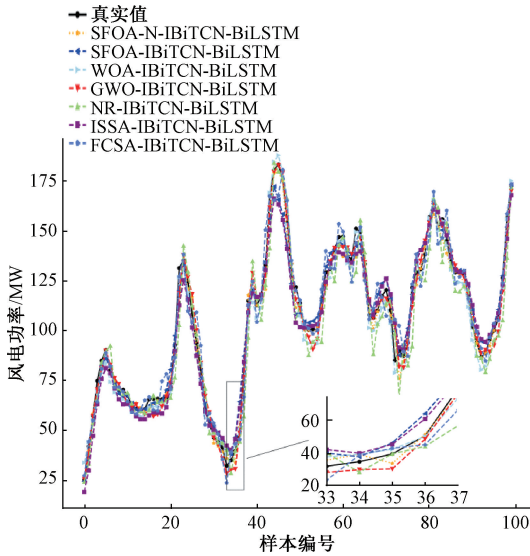


图 8 优化算法寻优对比图

Fig. 8 Optimization algorithm optimization comparison chart

表 2 优化算法寻优误差指标对比

Table 2 Comparison of optimization error indicators of optimization algorithms

优化方法	MAPE	RMSE	MAE	R ²
SFOA-N	1.19	4.64	2.41	0.995 9
SFOA	2.11	5.99	4.24	0.993 7
WOA	2.47	7.31	5.01	0.989 9
GWO	3.06	8.68	6.12	0.985 9
NR	2.46	7.24	4.98	0.990 1
ISSA	2.31	7.13	4.77	0.990 7
FCSA	2.19	7.01	4.32	0.991 1

法加强局部搜索能力之后,显著提升 SFOA 的优化能力。

4.3 SVMD 分解结果

基于连续变分模态分解算法对原始风电功率序列进行频域解耦,惩罚因子在经过 SFOA-N 优化算法进行搜寻后结果为 2 897,其他核心参数设置如下:收敛容差阈值严格控制在 1×10^{-8} ,确保分解过程达到全局最优。经完整迭代计算后,共析取出 46 个本征模态函数及 1 个残差分量,其中前 7 阶 IMF 的时频分布及残差信号如图 9 所示。为聚焦关键特征,本文选取前 7 个主导模态进行可视化分析,各 IMF 分量按频率从高到低有序排列 (IMF1~IMF7

频率依次递减),残差分量则表征原始数据中的低频噪声。




图 9 SVMD 前 7 个模态函数和残差

Fig. 9 SVMD first 7 modal functions and residuals

4.4 结果分析

1)IBiTCN 对比实验

为了验证增加动态膨胀率预测模块的预测模型效果要优于使用优化算法对膨胀率搜寻的预测模型,本文与未经过改进的 SFOA-N-BiTCN-BiLSTM 模型和引言中所提基于 BiTCN 改进的 IDBO-BiTCN-BiLSTM-SA 模型、ECOA-BiTCN-BiLSTM 模型、ISSA-BiTCN-BiLSTM-AM 模型进行对比实验。

如图 10 预测曲线对比及表 3 定量分析所示,集成动态

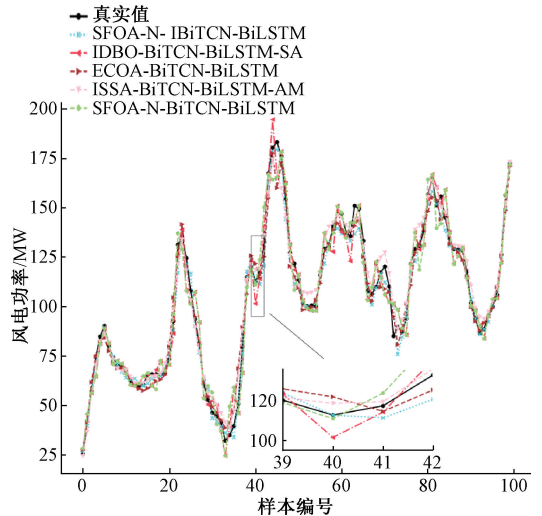


图 10 改进 BiTCN 对比曲线

Fig. 10 Improved BiTCN contrast curve

表 3 改进 BiTCN 对比试验误差指标对比

Table 3 The comparison of error indexes in BiTCN

comparison test was improved

模型	MAPE	RMSE	MAE	R2
SFOA-N-IBiTCN-BiLSTM	1.19	4.64	2.41	0.995 9
IDBO-BiTCN-BiLSTM-SA	2.17	6.09	4.27	0.993 2
EOCA-BiTCN-BiLSTM	2.49	7.37	5.05	0.989 6
ISSA-BiTCN-BiSTM-AM	2.39	6.89	4.11	0.992 1
SFOA-N-BiTCN-BiLSTM	2.17	7.01	4.33	0.991 2

膨胀率预测模块的改进型 IBiTCN 网络展现出显著性能提升,相较于 BiTCN 模型 MAPE、RMSE 和 MAE 分别下降了 0.98、2.37 和 1.92。本文改进的组合预测模型比使用优化算法搜寻和注意力机制改进 BiTCN 模型效果要好,由此表明引入动态膨胀率预测模块的改进是有效的,提升了模型的预测性能。

2) 消融实验

为了验证构建的优化 SVMD-IBiTCN-BiLSTM 分解预测模型各模块的有效性和可靠性,进行消融实验。实验以 IBiTCN 为基准,依次加入 BiLSTM、SVMD 和 SFOA-N 模型,观察各模块对模型性能的影响。

从图 11 对比曲线和表 4 定量分析中可以明显看出,随着模型复杂度的增加,预测性能得到了显著提升。图 11 显示本文提出的模型与真实值的拟合度最高,预测曲线(虚线)与真实值几乎完全重合。这表明本文模型在捕捉时间序列数据的局部和全局特征方面具有显著优势。表 4 可以看出,随着模型的改进,这些误差指标逐渐降低,而 R² 值逐渐提高。特别是经过 SVMD 分解后再进行训练的模型,其 R² 值比单独使用 BiLSTM 模型提高了 0.01,达到了 0.996 0。在使用 SFOA-N 算法进行超参数优化后,本文模型的 R² 值进一步提升至 0.998 2。图 11 和表 4 共同验证了本文提出的 SVMD-IBiTCN-BiLSTM 分解预测架构在




图 11 消融实验对比曲线

Fig. 11 Ablation experiment comparison curves

表 4 消融试验误差指标对比

Table 4 Comparison of error indexes in ablation tests

模型	MAPE	RMSE	MAE	R2
BiLSTM	4.93	13.04	9.97	0.968 1
IBiTCN	4.08	10.62	8.26	0.978 4
IBiTCN-BiLSTM	3.14	8.67	6.35	0.985 4
SVMD-IBiTCN-BiLSTM	1.09	3.92	2.19	0.996 0
本文模型	0.85	2.58	1.73	0.998 2

风电功率预测任务中的优越性能,特别是结合 SFOA-N 算法进行超参数优化后,模型的预测精度达到了非常高的水平。

3) 风电功率预测最新模型对比实验

为了验证优化 SVMD-IBiTCN-BiLSTM 模型在其他预测模型上的优势,本文选取风电功率预测最新的预测模型: SNGF-RERNN-SCSO^[15]、VMD-MHBA-LSTM^[16]、Bi-NDCE-UPF^[17]、FFN-TCN^[18]、BO-CNN-BiGRU-SA^[19]。

如图 12 和表 5 所示,通过对比可以明确地看出,本文提出的组合预测模型在各项评价指标上均显著优于其他风电功率预测的最新模型。图 12 展示了不同模型对风电功率的预测曲线,其中本文模型与真实值的拟合度最高,预测曲线与真实值几乎完全重合。这表明本文模型在捕捉时间序列数据的局部和全局特征方面具有显著优势。表 5 可以看出,本文模型在 MAPE、RMSE、MAE 指标上分别为 0.85、2.58、1.73,这些值均低于其他模型,表明本文模型在预测精度上具有明显优势。本文模型的 R² 指标达到了 0.998 2,远高于其他模型,进一步证明了本文方法在风电功率预测中的有效性。实验验证了本文提出的组合预测模型在风电功率预测任务中的优越性能,特别是在预测精度和拟合度方面,本文模型均表现出色,能够有效提高风电功率预测的准确度。

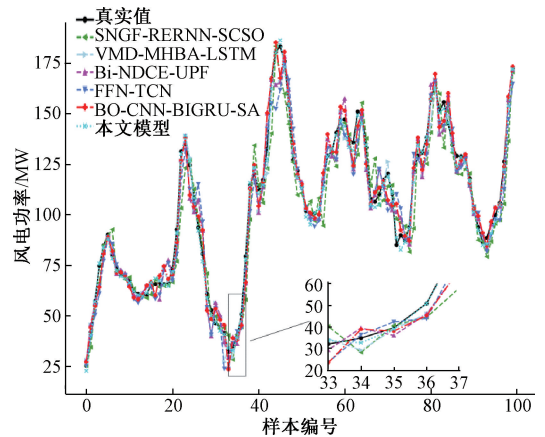


图 12 最新模型对比曲线

Fig. 12 Comparison curves of the latest model

通过图 12 和表 5 的对比分析,可以明确地看出,本文提出的组合预测模型在各项评价指标上均显著优于其他

表 5 最新模型误差指标对比

Table 5 Comparison of the latest model error indicators

模型	MAPE	RMSE	MAE	R ²
SNGF-RERNN-SCSO	4.08	10.62	8.26	0.978 8
VMD-MHBA-LSTM	2.21	7.11	4.39	0.991 1
Bi-NDCE-UPF	2.51	7.52	5.11	0.989 7
FFN-TCN	3.29	9.24	6.65	0.983 9
BO-CNN-BiGRU-SA	2.43	7.14	4.91	0.990 4
本文模型	0.85	2.58	1.73	0.998 2

风电功率预测的最新模型。图 12 展示了不同模型对风电功率的预测曲线,其中本文模型与真实值的拟合度最高,预测曲线与真实值几乎完全重合。这表明本文模型在捕捉时间序列数据的局部和全局特征方面具有显著优势。表 5 可以看出,本文模型在 MAPE、RMSE、MAE 指标上分别为 0.85、2.58、1.73,这些值均低于其他模型,表明本文模型在预测精度上具有明显优势。本文模型的 R² 指标达到了 0.998 2,远高于其他模型,进一步证明了本文方法在风电功率预测中的有效性。实验验证了本文提出的组合预测模型在风电功率预测任务中的优越性能,特别是在预测精度和拟合度方面,本文模型均表现出色,能够有效提高风电功率预测的准确度。

4) 泛化实验

为了验证本文模型的泛化性,选取来自于法国的风电场 2017 年 1 月的风电数据,和来自与土耳其风电场 2018 年 1 月的风电数据,经过相同数据预处理方法后,使用两个风电场数据进行泛化实验,本文模型分别与 BiTCN(模型一)和文献[20]提出的这两个数据集最新模型:CEEMDAN-EWT-LSTM(模型二)进行对比。

表 6 为误差指标对比结果,从表中可以看出,本文模型与单一 BiTCN 模型对比在 MAPE、RMSE 和 MAE 指标上,法国数据集分别降低了 2.82、91.4 和 58.73, R² 从 0.856 1 提升到 0.997 6,土耳其数据集上分别降低了 1.63、197.05 和 54.64, R² 提升到了 0.987 1。本文模型与模型二对比在 MAPE、RMSE 和 MAE 指标上,法国数据集下降了 0.65、21.56 和 14.34, R² 提升了 0.014 5,土耳其数据

表 6 泛化实验误差指标对比

Table 6 Comparison of error indexes in generalization experiments

模型	数据集	MAPE	RMSE	MAE	R ²
模型一	法国	3.45	107.58	70.75	0.856 1
模型一	土耳其	2.56	279.30	92.83	0.845 9
模型二	法国	1.28	37.74	26.36	0.982 2
模型二	土耳其	1.38	119.25	50.08	0.971 9
本文模型	法国	0.63	16.18	12.02	0.996 7
本文模型	土耳其	0.93	82.25	38.19	0.987 1

集分别下降了 0.45、111 和 11.89, R² 提升到了 0.987 1。验证了本文模型在风电功率预测的泛化性,在不同的数据集上均有良好的表现。

5 结 论

为进一步提高风电输出功率预测的准确度,本文提出了一种优化 SVM-D-IBiTCN-BiLSTM 的短期风电功率预测模型,通过算例分析,得出以下结论:

本研究提出的 SFOA-N 算法,能够有效的解决 SFOA 算法局部搜索能力较弱的问题,提高了算法的搜寻能力。

本研究提出的 IBiTCN 模型,通过引入动态膨胀率预测模块解决了 BiTCN 模型膨胀率过于固定,无法适应不同时间序列中的复杂模式的问题,改进后的模型可以在不同层次或不同时间步长上灵活选择合适的膨胀率,以便于提取更多序列特征,提高预测精度。

本研究使用 SFOA-N 搜寻 SVM-D 最佳惩罚因子和 IBiTCN-BiLSTM 模型的最佳超参数,构建优化 SVM-D-IBiTCN-BiLSTM 的分解预测模型,经过一系列试验验证,该模型能够提高风电功率预测精度。

本文所提模型在风电功率预测任务中虽具有较高的准确,但模型未考虑不同季节、天气等因素,而且模型对计算资源需求高,后续将会在这些方向进一步改进。

参考文献

- [1] 陈英超,万家杭.“双碳”目标下中国能源结构变化趋势预测[J].中外能源,2025,30(3):1-6.
CHEN Y CH, WAN J H. Prediction of the change trend of China's energy structure under the goal of "Dual Carbon"[J]. Sino-foreign Energy, 2025, 30(3): 1-6.
- [2] 马露露.适应新型电力系统的电价机制研究[J].价格理论与实践,2024,(12):196-202,232.
MA L L. Research on electricity pricing mechanism adapted to the new power system[J]. Price Theory & Practice, 2024,(12):196-202,232.
- [3] 何志福,徐戈.面向风电功率预测的关键技术及应用综述[J].现代工业经济和信息化,2024,14(10):129-130.
HE ZH F, XU G. A review of key technologies and applications for wind power prediction[J]. Modern Industrial Economics and Informatization, 2024, 14(10):129-130.
- [4] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition [J]. IEEE Trans on Signal Processing, 2013, 62(3): 531-544.
- [5] NAZARI M, SAKHAEI S M. Successive variational mode decomposition [J]. Signal Processing, 2020, 174: 107610.
- [6] XU Z, TAO J, HU Y, et al. A WOA-SVM-D and

- multi-scale CNN-transformer method for fault diagnosis of motor bearing [J]. *Measurement and Control*, 2025, DOI:10.1177/0020294024131266.
- [7] ZHANG F. Fault diagnosis of induction motor rotor broken bar based on GWO-SVMD-1D CNN [C]. *Fourth International Conference on Advanced Manufacturing Technology and Electronic Information (AMTEI 2024)*. SPIE, 2025, 13515: 214-219.
- [8] SOWMYA R, PREMKUMAR M, JANGIR P. Newton-Raphson-based optimizer: A new population-based metaheuristic algorithm for continuous optimization problems[J]. *Engineering Applications of Artificial Intelligence*, 2024, 128: 107532.
- [9] REN Y. BiTCN-DCMA: Research on prediction method of photovoltaic power generation based on dynamic convolution and BiTCN-BiLSTM [J]. *Academic Journal of Computing & Information Science*, 2024, 7(7): 23-30.
- [10] 冯平平,文桥,王霄,等. 基于 IDBO 优化的 BiTCN-BiLSTM-SA 光伏组件积灰预测[J/OL]. *太阳能学报*, 1-11[2025-05-01]. <https://doi.org/10.19912/j.0254-0096.tynxb.2024-1244>.
FENG P P, WEN Q, WANG X, et al. Prediction of ash accumulation of BiTCN-BiLSTM-SA photovoltaic modules based on IDBO optimization [J/OL]. *Acta Solar-Energy Sinica*, 1-11 [2025-05-01]. <https://doi.org/10.19912/j.0254-0096.tynxb.2024-1244>.
- [11] ZHANG Y, LIU P, XU Y, et al. Prediction of cold region dew volume based on an ECOA-BiTCN-BiLSTM hybrid model[J]. *Scientific Reports*, 2025, 15(1): 1-14.
- [12] QIAO L, GAO H, CUI Y, et al. Reservoir porosity construction based on BiTCN-BiLSTM-AM optimized by improved sparrow search algorithm[J]. *Processes*, 2024, 12(9): 1907.
- [13] 柳博,吴松荣,付聪,等. 基于改进白鲸算法优化 BiTCN-BiGRU 的锂电池 SOC 估计[J]. *电子测量技术*, 2025, 48(9): 75-83.
LIU B, WU S R, FU C, et al. SOC estimation of lithium battery optimized by BiTCN-BiGRU based on improved beluga algorithm [J]. *Electronic Measurement Technology*, 2025, 48(9): 75-83.
- [14] JIA H, ZHOU X, ZHANG J, et al. Superb fairy-wren optimization algorithm: A novel metaheuristic algorithm for solving feature selection problems[J]. *Cluster Computing*, 2025, 28(4): 246.
- [15] KHAMARI R C, MAMI S, BODKHE R G, et al. Enhancing wind power forecasting accuracy: A hybrid SNGF-RERNN-SCSO approach [J]. *Solar Energy*, 2025, 295: 113513.
- [16] GUO L, XU C, YU T, et al. Ultra-short-term wind power forecasting based on long short-term memory network with modified honey badger algorithm [J]. *Energy Reports*, 2024, 12: 3548-3565.
- [17] LI C, XIAO B, YUAN Q. Ultra-short-term wind power prediction algorithm based on bidirectional neural controlled differential equations [J]. *Electric Power Systems Research*, 2025, 243: 111479.
- [18] MANSOOR M, TAO G, MIRZA A F, et al. Feature fusion temporal convolution: Wind power forecasting with light hyperparameter optimization [J]. *Energy Reports*, 2025, 13: 2468-2481.
- [19] CHEN W, HUANG H, MA X, et al. The short-term wind power prediction based on a multi-layer stacked model of BOCNN-BiGRU-SA [J]. *Digital Signal Processing*, 2025, 156: 104838.
- [20] KARIJADI I, CHOU SH Y, DERABHARATA A. Wind power forecasting based on hybrid CEEMDAN-EWT deep learning method [J]. *Renewable Energy*, 2023, 218, 119357.

作者简介

丁浩展, 硕士研究生, 主要研究方向深度学习和风电功率预测等。

E-mail: 2234434188@qq.com

刘硕, 硕士研究生, 主要研究方向深度学习和风电功率预测等。

E-mail: 3136088430@qq.com

马纪颖(通信作者), 硕士, 副教授, 主要研究方向为信息集成、大数据分析等。

E-mail: 83001421@qq.com