

基于KOA驱动的VMD-CNN-BiGRU-Attention 光伏功率组合预测模型研究

王潇添¹, 李泽林², 詹莹³, 王旭³, 许野³

(1. 华北电力大学(保定)电力工程学院, 保定 071003; 2. 华北电力大学经济与管理学院, 北京 102206;

3. 华北电力大学环境科学与工程学院, 北京 102206)

摘 要: 针对现有深度学习预测模型在训练过程中存在的时间较长、易陷入局部最优解等问题, 提出一种基于开普勒优化算法(KOA)驱动的VMD-CNN-BiGRU-Attention短期光伏出力预测方法。该方法首先利用皮尔逊相关系数法对关键气象因素进行筛选; 随后采用灰色关联度(GRA)法确定待预测日的历史相似日, 并通过KOA对变分模态分解(VMD)的参数进行优化, 进而对历史相似日的出力序列进行分解, 从而生成高质量的模型训练样本集; 最后, 基于KOA-CNN-BiGRU-Attention算法构建光伏出力组合预测模型, 以实现光伏出力的精准预测。在云南和甘肃两地光伏电站的实际应用表明, 该模型的均方根误差(RMSE)分别为0.2540、2.7981 MW, 平均绝对百分比误差(MAPE)分别为0.0234、1.1699。与其他组合预测模型相比, 所提基于KOA驱动的VMD-CNN-BiGRU-Attention模型在时空特征捕捉能力方面具有显著优势, 并在预测精度和稳定性上表现出优越性, 展现了其在光伏发电预测领域的广阔应用潜力。

关键词: 光伏出力预测; 开普勒优化算法; 变分模态分解; 注意力机制; CNN-BiGRU-Attention组合模型

中图分类号: TM615

文献标志码: A

0 引 言

在全球能源转型背景下, 中国光伏发电迅猛发展, 并成为推动国内能源结构优化的重要支柱^[1]。截至2025年7月, 中国光伏累计装机规模突破11亿千瓦。进一步确立了其在电力新增装机中的主导地位。伴随“3060”双碳目标的深入推进, 光伏发电规模快速扩张, 预计到2056年, 其发电量占比将达到全国发电总量的38.19%。然而, 光伏发电的波动性和随机性特征因天气条件变化显著, 对电网的稳定运行和调度管理带来严峻挑战。在此背景下, 提升光伏功率预测的准确性已成为优化电网调控和推动能源系统高效运行的关键^[2]。

目前, 合理准确的相似日选取是解决光伏出力随机性较强的有效手段^[3], 通过合理缩短模型训练时间, 削弱冗余数据对预测精度的影响, 可有效提高模型的泛化能力并防止过拟合, 为发电量的准确预测奠定基础^[4]。阎洁等^[5]选取与待预测日风速云模型最为相似的历史数据序列, 并结合风速随机性和模糊性特征进行学习和建模, 有效提高了预测精度; 薛阳等^[6]采用Pearson相关系数选取相似日数据作为训练集数据, 以去除与光伏输出功率不相关的气象特征, 提高模型

预测的效率; 李练兵等^[7]选用余弦相似度分析法进行相似日聚类, 提高了相似日选取的精度。上述研究多数基于数据相似性或单一因素相关性进行研究, 虽可通过距离的远近选定相似日, 一定程度上避免了冗余数据干扰, 但仍存在考虑因素不全面、与功率关联性不足等缺点^[8]。因此, 本文选取灰色关联分析-动态时间规整(grey relational analysis-dynamic time warping, GRA-DTW)加权组合的综合距离相似法完成相似日的筛选, 通过衡量气象主要因素与功率之间的关联性, 综合捕捉数据间的形状相似关系以及线性与非线性特征, 提升相似日选择的准确性, 为模型优化提供高质量的训练数据集。

可靠高效的数据降噪是实现光伏发电精确预测的关键环节^[9]。通过信号处理技术, 有效去除数据中的高频噪声并保留关键的低频信息, 可显著提高数据的一致性, 实现预测模型的高效运转。张云钦等^[10]利用经验模态分解(empirical mode decomposition, EMD)将环境因素序列进行分解, 揭示了信号在不同时间尺度下的变化特征, 从而降低了序列的非平稳性; 张飞等^[11]采用集合经验模态分解(ensemble empirical mode decomposition, EEMD)对突变天气条件下光伏电站的历史出力数据和气象数据进行了多频率分解, 有效减少了噪声波动的影响; 茆美琴等^[12]利用EEMD分解方法有效提取不同

收稿日期: 2025-01-16

基金项目: 中央高校基本科研业务费专项资金(2025MS050)

通信作者: 王旭(1996—), 男, 博士、讲师, 主要从事新能源出力预测和综合能源系统优化方面的研究。wangxu@ncepu.edu.cn

频率分量的特点,将历史数据分解为较平稳的多频率分量,丰富了数据特征的表现形式。上述研究主要通过 EMD 和 EEMD 实现光伏出力序列的降噪处理^[13],有效降低了原始数据的非平稳性,能显著减少高频噪声的干扰,提升了序列的平稳性和可预测性,但仍难以充分捕捉序列中的非线性特性,且需人为设定参数,导致分解结果的稳定性不足。为此,本文引入开普勒优化算法(Kepler optimization algorithm, KOA)优化变分模态分解(variational mode decomposition, VMD),结合智能优化算法的全局搜索能力和 VMD 的自适应分解特性,能有效优化分解参数,从而最大限度减少噪声干扰。面对多样化和非线性的数据集,改进的 VMD 方法可动态调整参数与分解流程,确保每次分解都达到最优效果,表现出卓越的适应性和高精度特征^[14]。

效率更高且泛化能力较强的预测模型构建是实现光伏发电精确预测的核心过程,深度学习作为一种多层次的机器学习(machine learning, ML)方法,可克服传统机器学习依赖人工分析和特征设计的缺陷,无需预先定义数据特征或标签即可进行特征提取和规律学习,常用于光伏出力预测模型的构建过程。该方法不仅具有更丰富的学习特征,且能直接从原始数据中提取特征并建立与结果的非线性映射关系,从而规避了人工设计特征的复杂性及可能存在的不准确性问题。王帅杰等^[15]利用长短期记忆网络(long short-term memory, LSTM)对内蒙古自治区 50 MW 光伏发电系统的数据进行预测,有效提高了光伏电站超短期预测的精度;李超然等^[16]使用蜜獾算法(honey badger algorithm, HBA)参数优化后的双向长短期记忆网络(bidirectional LSTM, BiLSTM)进行功率预测,结果表明该模型具有较高的光伏系统输出功率预测精度;李云松等^[17]提出一种门控循环单元-时序图变换器(GRU-TGTransformer)模型,采用门控循环单元代替原有的词嵌入及位置编码环节,增强了模型在时序预测问题上的稳定性。

上述方法通过深度学习强大的特征提取和建模能力,能有效捕捉光伏出力数据的非线性特性和时序依赖关系,避免了传统方法对人工特征工程的依赖,可在一定程度上提升光伏出力预测的精度。然而,在实际应用中,仍面临着训练时间较长及超参数空间(如学习率、卷积核尺寸、神经元数量等)优化困难的问题,进而影响预测效率。因此,本文提出一种基于注意力机制的 KOA-CNN-BiGRU-Attention(开普勒优化算法+卷积神经网络+双向 GRU+注意力机制)短期光伏出力预测方法。该方法结合了开普勒优化算法(KOA)、卷积神经网络(convolutional neural network, CNN)和双向门控循环单元(bidirectional GRU, BiGRU)的优势,可有效提升模型在复杂数据处理中的性能与准确性。KOA 作为一种启发式优化算法,能高效优化模型超参数,避免传统梯度下降法可能陷入的局部最优解问题。CNN 通过多层卷积与池化操作,从输入数据中提取局部特征,捕捉空间信息,为后续的时序建模提供有效的特征表示。BiGRU 则利用双向结构,能够同时捕

捉前向和反向的时序依赖关系,从而更好地建模长期上下文信息。该方法通过 KOA 优化、CNN 特征提取和 BiGRU 建模的有机结合,显著增强了模型在处理复杂模式和长时依赖关系的数据时的适应性与鲁棒性。

综上,为充分发挥组合预测模型在相似日选取、超参数优化和智能预测精度等方面的优势,本文在使用皮尔逊相关系数法进行光伏出力特征选择的基础上,结合灰色关联分析(grey relational analysis, GRA)方法对相似日数据集进行选择,并引入变分模态分解(VMD)方法,将非平稳的光伏功率时间序列分解为多个模态,在将每个子序列经过 VMD 分解并构建不同的特征矩阵的基础上,提出 GRA-VMD-KOA-CNN-BiGRU 的光伏发电功率组合模型。最后,通过云南和甘肃光伏电站的实际应用结果显示,相较于传统单一模型, GRA-VMD-KOA-CNN-BiGRU 组合预测模型在精度上显著提高,展现了更好的实用价值。

1 方法概述

1.1 技术路线

本文遵循“影响因素识别-相似日选取-稳态分解-组合预测模型构建”技术路线(如图 1 所示)。

主要预测流程如下:

- 1) 利用皮尔逊相关系数(Pearson correlation coefficient, PCC)方法分析全辐射辐照度、温度和湿度 3 类气象因素与光伏功率之间的相关性,提取对光伏出力影响较大的两类因素,即全辐射辐照度和温度;2) 运用灰色关联分析-动态时间规整(grey relational analysis-dynamic time warping, GRA-DTW)加权组合的综合距离相似法对历史日进行分类,识别与待预测日气象条件高度相近的历史相似日;3) 利用 KOA-VMD 方法对历史相似日的出力序列进行分解,构建 VMD 方法与 LSTM、门控循环单元(gated recurrent unit, GRU)、CNN-LSTM、KOA-CNN-BiGRU-Attention 这 4 种神经网络的组合预测模型;4) 结合平均绝对误差(mean absolute error, MAE)、均方根误差(root mean squared error, RMSE)和平均绝对百分比误差(mean absolute percentage error, MAPE)等关键指标,对比分析单一神经网络预测模型(LSTM、GRU、CNN-LSTM、KOA-CNN-BiGRU-Attention)在云南和甘肃两处光伏电站预测的性能指标,确定最优的光伏出力预测模型。

1.2 皮尔逊相关系数

皮尔逊相关系数(PCC)作为统计学中衡量数据之间相关性的常用方法,凭借方法计算过程简单且结果明晰的优势,常用于多个连续型变量的相关性比较分析。从光伏发电的物理机制来看,太阳能电池电路方程已明确表明,辐照度和温度是直接影响光伏功率的两个主要气象因素,而湿度通过影响电阻等方式间接作用于光伏输出功率。尽管这些基本物理关系已知,但本文选用 PCC 方法对实测数据进行分析,旨

在量化不同气象因素在特定场景下对实际光伏电站出力的影响程度,为后续模型输入参数的确定奠定基础。




图1 总体技术路线

Fig. 1 Overall technical route

$$R = \frac{M \sum_{l=1}^M a_l b_l - \left(\sum_{l=1}^M a_l \right) \left(\sum_{l=1}^M b_l \right)}{\sqrt{\left[M \sum_{l=1}^M a_l^2 - \left(\sum_{l=1}^M a_l \right)^2 \right] \left[M \sum_{l=1}^M b_l^2 - \left(\sum_{l=1}^M b_l \right)^2 \right]}} \quad (1)$$

式中: R ——变量 a 与变量 b 之间的皮尔逊相关系数; a_l 、 b_l ——两个变量在第 l 个样本处的取值; M ——样本量; l ——样本索引。

1.3 GRA-DTW 综合距离

通过 GRA-DTW 综合距离法对选取的特征变量进行统计分析,计算每个历史样本与待预测日的关联度值,选取 GRA-DTW 综合距离值最大的 8 个历史样本作为待预测日的相似日,过程如下:

1) 归一化矩阵: 由于量纲不一样的特征指标在数量级上存在较大差异,将影响相似日选取的效率,因此本文采用归一化方法对指标进行无量纲化处理,计算步骤为:

$$\mathbf{x}_0 = \left\{ \frac{\mathbf{x}_0(k)}{\max \mathbf{x}_0(k)}, k = 1, 2, \dots, n \right\} \quad (2)$$

式中: $\mathbf{x}_0$ ——相似日选取指标。

2) 计算每个样本序列与待预测参考序列对应元素的关

联性:

$$\xi_{ik} = \frac{\min_i \min_k |\mathbf{x}_0(k) - \mathbf{x}_i(k)| + \rho \max_i \max_k |\mathbf{x}_0(k) - \mathbf{x}_i(k)|}{|\mathbf{x}_0(k) - \mathbf{x}_i(k)| + \rho \max_i \max_k |\mathbf{x}_0(k) - \mathbf{x}_i(k)|} \quad (3)$$

式中: $\mathbf{x}_0(k)$ 、 $\mathbf{x}_i(k)$ ——光伏出力序列与第 i 个气象因素的第 k 项特征; ρ ——分辨系数。

3) 根据关联度计算结果进行排序,从中确定主要影响因素:

$$\gamma_i = \frac{1}{n} \sum_{k=1}^n \xi_i(k), k = 1, 2, \dots, n \quad (4)$$

4) 通过动态规划算法得到待预测日和历史日间的最佳路径,具体算法为:

$$\gamma(i, j) = \min \{ \gamma(i-1, j-1), \gamma(i-1, j), \gamma(i, j-1) \} \quad (5)$$

式中: $\gamma(i, j)$ ——从序列的开始到达点 (i, j) 时的累计最小距离。

5) 采用固定权重,将不同灰色关联度值与 DTW 距离值进行组合,确定待预测日和历史日间的综合距离计算公式为:

$$S = \sigma_1 \cdot \xi_i + \sigma_2 \cdot \gamma \quad (6)$$

式中: S ——综合距离值; σ_1 ——灰色关联度的权重,设为 0.5; σ_2 ——DTW 值的权重,设为 0.5。

1.4 开普勒算法优化变分模态分解(KOA-VMD)

1.4.1 开普勒优化算法(KOA)

KOA 是一种基于天体运动原理的物理元启发式算法,将优化问题的解抽象为“恒星”(太阳),解集视为围绕其运行的“行星”,通过迭代调整行星位置以获得目标函数的最优解。在优化 VMD 惩罚因子和模态数时,KOA 通过六步迭代过程实现最优解搜索。相较传统或改进遗传算法,KOA 有效克服了局部最优、收敛缓慢和种群多样性不足等问题。算法基于行星的位置、质量、引力及轨道速度 4 个核心因子,能够高效探索并利用搜索空间(流程见图 2),具体算法如下:




图2 KOA 优化 VMD 参数

Fig. 2 KOA optimization VMD parameter

1) 构建搜索空间,初始化变量

$$X_i^j = X_{i,low}^j + r \times (X_{i,up}^j - X_{i,low}^j) \quad (7)$$

式中: X_i ——搜索空间中的第 i 颗行星(候选解); $X_{i,up}^j$ ——第 j 个决策变量的上界; $X_{i,low}^j$ ——第 j 个决策变量的下界; r ——0~1 之间随机生成的数。

2) 定义引力

$$F_{g_i}(t) = e_i \times \mu(t) \times \frac{\bar{M}_s \times \bar{m}_i}{R_i^2 + \varepsilon} \quad (8)$$

式中: e_i ——行星的轨道偏心率; $\mu(t)$ ——随时间 t 递减的函数; $\bar{M}_s$ ——太阳质量的归一化数值,对应太阳的质量; $\bar{m}_i$ —— m_i 的归一化数值,对应目标行星的质量; $\bar{R}_i$ —— R_i 的归一化数值,代表太阳与行星间的欧氏距离值; ε ——极小值。

3) 计算行星速度

$$V_i(t) = \begin{cases} 2r_s X_i - X_b + l(X_a - X_b) + (1 - R_{i-norm}(t)) \times \\ \tau \times U_1 \times r \times (X_{i,up} - X_{i,low}), R_{i-norm}(t) \leq 0.5 \\ r_s \times \varpi \times (X_a - X_i) + (1 - R_{i-norm}(t)) \times \\ \Gamma \times U_2 \times r \times (r_3 X_{i,up} - X_{i,low}), \text{其他} \end{cases} \quad (9)$$

式中: $V_i(t)$ ——第 i 个候选解在 t 时刻的速度; X_i ——第 i 个候选解的位置; X_a, X_b ——从种群中随机选取的候选解; X_{up}, X_{low} ——搜索空间上界和下界向量; r_s ——[0,1]内的随机标量;

r ——[0,1]内的随机向量; $R_{i,norm}(t)$ ——归一化欧氏距离; $l, \tau, \varpi, U_1, U_2$ ——算法控制参数或随机变量; Γ ——逃离局部最优的控制标志。

4) 通过调整行星位置、更新与太阳的距离,并结合精英策略保留高适应度个体,最终实现最优解的搜索。

1.4.2 变分模态分解(VMD)

变分模态分解是一种处理非线性以及非平稳信号的时频分析方法,相对于 EMD 及 EEMD 等方法可有效控制模态混叠、过包络及边界效应等现象^[14]。为将原始信号分解为 N 个分量,其计算过程包括以下步骤:首先,将光伏出力序列分解为 K' 个离散的模式函数;然后,通过引入二次罚项和拉格朗日乘子 λ 将变分约束问题转化为无约束形式,以确定各模态的带宽;最后在频域内实现信号的自适应分割,得到 K' 个窄带的 IMF 分量^[18]。

1.5 KOA-CNN-BiGRU-Attention 混合深度学习模型

尽管 CNN-BiGRU 模型已应用于工业中的多个领域,但较少有研究人员将 CNN-BiGRU 与 Attention 机制相结合,充分发挥 CNN 可构建多个过滤器来有效数据特征,和 Attention 机制可对 BiGRU 输出的隐藏状态赋予不同权重,进而泛化能力更强的相关优势,利用 CNN-BiGRU-Attention 混合深度学习进行光伏出力变化预测。此外,由于 CNN-BiGRU 模型涉及较多的超参数,因此,本文通过 KOA 算法优化 CNN-BiGRU-Attention 模型的关键超参数(学习率、卷积核尺寸、神经元数量等),成功实现了光伏出力预测精度的显著提升。物理启发式算法与生物启发式神经网络的创新性结合体现出多重优势:首先,KOA 算法基于天体轨道力学的确定性搜索机制有效克服了传统梯度下降法在复杂参数空间中易陷入局部最优的局限;其次,优化后的 CNN-BiGRU 模块能够更精确地提取光伏出力时序数据的空间特征,而注意力机制则进一步增强了模型对关键时间点的识别能力;最后,这种物理-生物双重启发式方法的协同效应显著提高了模型的泛化能力和预测稳定性。KOA-CNN-BiGRU-Attention 模型的结构如图 3 所示。




图3 KOA-CNN-BiGRU-Attention 结构示意图

Fig. 3 KOA-CNN-BiGRU-Attention structure

1.5.1 卷积神经网络(CNN)

1)卷积层:卷积层通过卷积核输入数据进行运算,实现特征提取,输出特征矩阵计算公式为:

$$Y_{ij} = \phi \left(\sum_{u=0}^{K_h-1} \sum_{v=0}^{K_w-1} W_{u,v}^{\text{conv}} X_{i+u, j+v} + b_{\text{conv}} \right) \quad (10)$$

式中: X ——卷积层输入特征矩阵; Y_{ij} ——卷积层在输出位置 (i,j) 处的特征值; i,j ——输出特征图的行、列位置; $W_{u,v}^{\text{conv}}$ ——卷积核在第 u 行、第 v 列处的权重; K_h, K_w ——卷积核的高度和宽度,若采用方形卷积核,则 $K_h = K_w = K$; u, v ——卷积核内部的行、列索引; b_{conv} ——卷积层偏置项; $\phi(\cdot)$ ——激活函数。

2)激励层:紧随卷积层之后,通过激活函数引入非线性特性,使网络能够学习复杂特征。激活函数负责连接上一层输出与下一层输入,其导数影响梯度传播。

3)池化层:位于连续卷积层之间,其主要功能是压缩数据规模,降低参数量,减少过拟合风险,同时在不丢失主要特征的情况下降维。最大池化常用于提取显著变化的特征,通过选择矩阵区域内的最大值作为代表,计算公式为:

$$P_{ij} = \max_{0 \leq p < H_p, 0 \leq q < W_p} Y_{iS_h + p, jS_w + q} \quad (11)$$

式中: P_{ij} ——最大池化层在输出位置 (i,j) 处的结果; Y ——池化层输入特征矩阵,即上一卷积层或激励层的输出; S_h 和 S_w ——垂直方向和水平方向的池化步长; H_p, W_p ——池化窗口的高度和宽度; p, q ——池化窗口内部的行、列索引; $\max$ ——取对应池化窗口内的最大值。

4)全连接层:通常位于神经网络尾部,在输出结果之前将卷积层生成的二维特征图转换为一维向量。

1.5.2 BiGRU-Attention

RNN 是一种用于处理顺序数据的神经网络结构,它通过在每个时间步长结合之前的隐藏状态 h_{t-1} 和当前输入 x_t 来递归地计算新的隐藏状态,以捕获顺序信息并生成输出。然而,在处理长序列时,RNN 存在梯度消失和内存容量有限的问题,难以学习到序列中的重要信息。因此,研究人员提出 RNN 的变体,如 LSTM 和 GRU。LSTM 和 GRU 在 RNN 的基础上引入一种门控机制,可更好控制梯度传播,缓解梯度消失问题。与 LSTM 相比,GRU 在保持高性能的同时结构更简洁。

GRU 有两个关键的门控单元,分别为复位门和更新门。其中复位门用于控制前一个隐藏状态的遗忘程度,其输出 r_t 与电流输入一起决定候选值。利用更新门来调整候选值与前一个隐藏状态之间的混合程度。GRU 的计算过程可概括为:

$$r_t = \sigma(W_r[h_{t-1}, x_t] + b_r) \quad (12)$$

$$z_t = \sigma(W_z[h_{t-1}, x_t] + b_z) \quad (13)$$

$$\tilde{h}_t = \tanh(W_h[r_t \odot h_{t-1}, x_t] + b_h) \quad (14)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (15)$$

式中: r_t ——第 t 个时间步的复位门输出; x_t ——第 t 个时间步的输入向量; h_{t-1} ——前一时间步的隐藏状态; W_r ——复位门权重矩阵; b_r ——复位门偏置向量; $\sigma(\cdot)$ ——Sigmoid 激活函数; $[\cdot, \cdot]$ ——向量拼接; z_t ——第 t 个时间步的更新门输出; b_z ——更新门偏置向量; $\tilde{h}_t$ ——第 t 个时间步的候选隐藏状态; W_h ——候选隐藏状态权重矩阵; b_h ——候选隐藏状态偏置向量; $\tanh(\cdot)$ ——双曲正切激活函数; $\odot$ ——逐元素乘积; h_t ——当前时间步的隐藏状态; 1 ——与 z_t 维度一致的全 1 向量或可广播标量。

GRU 是一种典型的递归神经网络,采用按时间步长序列处理数据的结构来捕获过去和当前时间步长之间的相关信息。然而,这种结构的局限性在于它只能考虑序列数据中的过去信息,而不能考虑序列数据中的未来信息。为了克服这一限制,双向递归神经网络被应用到 GRU 中,形成了双向 GRU。这使得网络可以考虑过去和未来的信息,以便更全面地理解和建模序列数据。其数学表达式为:

$$h_t = \overrightarrow{\text{GRU}}(x_t, h_{t-1}) \quad (16)$$

$$h_t = \overleftarrow{\text{GRU}}(x_t, h_{t+1}) \quad (17)$$

$$h_t^{\text{bi}} = W_t h_t + V_t h_t + b_t \quad (18)$$

式中: h_t ——前向 GRU 在第 t 个时间步的隐藏状态; h_{t-1} ——前向 GRU 在前一时间步的隐藏状态; $\overrightarrow{\text{GRU}}(\cdot)$ ——前向 GRU 单元; h_{t+1} ——后向 GRU 在后一时间步的隐藏状态; $\overleftarrow{\text{GRU}}(\cdot)$ ——后向 GRU 单元; h_t^{bi} ——BiGRU 在第 t 个时间步的组合输出; h_t, h_t ——前向和后向隐藏状态; W_t, V_t ——前向隐藏状态和后向隐藏状态对应的权重矩阵; b_t ——对应的偏置向量。

1.6 评价指标

在评价模型误差时,常用的指标包括 MAE、RMSE 和 MAPE。其中,MAE 用于量化预测值与实际值之间的平均偏差;RMSE 体现两者的绝对差异;MAPE 以百分比形式表示预测误差大小,有助于在不同数据尺度下进行对比。

$$E_{\text{MAE}} = \frac{1}{N} \sum_{i=1}^N |p_i - \hat{p}_i| \quad (19)$$

$$E_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (p_i - \hat{p}_i)^2} \quad (20)$$

$$E_{\text{MAPE}} = \frac{100\%}{N} \sum_{i=1}^N \left| \frac{p_i - \hat{p}_i}{p_i} \right| \quad (21)$$


式中: E_{MAE} ——平均绝对误差; N ——待预测样本量; p_i ——第 i 个样本的光伏短期出力实际值; $\hat{p}_i$ ——第 i 个样本的光伏短期出力预测值; i ——样本索引; E_{RMSE} ——均方根误差; E_{MAPE} ——平均绝对百分比误差。

MAE 与 RMSE 主要受数据绝对值影响,数值越大说明误差越显著;而 MAPE 值较小则表明模型具有更高的预测精度。


2 实验分析

2.1 数据概述


本文以云南某总装机容量为 40 MW 的光伏电站为研究对象,验证所提出的基于相似日筛选与 KOA 优化 VMD 的 KOA-CNN-BiGRU-Attention 组合模型的预测性能。数据采样时间设定为每日 08:15—19:00,覆盖 2023 年 8 月 1 日—2024 年 7 月 30 日,以 15 min 为分辨率,记录辐照度、风速、温度、湿度和发电量,并完成组合预测模型的构建。在光伏电站性能评估中,以 2024 年待预测日所在月份 7 月份作为典型月进行数据分析,夏季典型月内气象要素及发电量的变化如图 4 所示。




a. 光伏短期出力曲线



b. 温度曲线



c. 天气预报辐照度曲线




d. 湿度曲线

图4 2024年7月的3类气象要素和功率

Fig. 4 Three categories of meteorological elements and power in July 2024

2.2 基于PCC方法的关键气象要素筛选和相似日确定

为保证所得结果的合理性和准确性,本文收集目标电站历史时段内辐照度、温度及湿度 3 类气象要素及相应的发电功率实际监测数据,并在剔除冗余历史样本及数据异常值的基础上计算得到 3 类气象要素与发电功率之间的皮尔逊相关系数,筛选和确定光伏出力的关键影响因素。皮尔逊相关系数绝对值的大小表征了该气象特征与光伏发电功率的相关程度,绝对值越大,说明二者相关性越强,因此,本文保留皮尔逊系数绝对值较大的因素,包括太阳辐照度及温度共 2 项气象特征,为下一步构造模型训练集、划分天气类型提供数据样本。由此可得,光伏功率预测需输入的特征向量如图 5 所示。



注:P为光伏功率;FRI为全辐射辐照度;T为温度;U为湿度。

图5 各环境因素与光伏出力间的Person值

Fig. 5 Person value between each environmental factor and PV output

在此基础上,随机选定 2024 年 7 月 1 日—7 日为待预测

日,以 2023 年 8 月 1 日—2024 年 7 月 30 日的历史样本作为备选日,采用 GRA-DTW 综合距离法生成上述待预测日的历史相似日集合。表 1 给出了各待预测日的历史相似日筛选结果和灰色关联度值。

表 1 相似日选取结果
Table 1 Similar day selection results

待预测日	所选相似日	GRA-DTW 值	待预测日	所选相似日	GRA-DTW 值
2024-07-01	2024-06-14	0.9792	2024-07-02	2024-09-10	0.9554
	2023-08-01	0.9756		2024-08-01	0.9524
	2023-09-08	0.9533		2024-09-08	0.9501
	2023-09-07	0.9523		2024-09-07	0.9453
	2023-09-18	0.9501		2024-09-24	0.945
	2023-09-10	0.9435		2024-05-26	0.9417
	2024-05-27	0.9424		2024-09-12	0.9403
	2023-08-20	0.9416		2024-09-11	0.9375
2024-07-03	2024-09-10	0.9654	2024-07-04	2023-07-13	0.9746
	2024-07-18	0.9570		2023-08-30	0.9681
	2024-09-07	0.9499		2023-07-20	0.9674
	2024-06-14	0.9447		2023-08-14	0.9659
	2023-08-30	0.9444		2023-08-31	0.9659
	2023-08-01	0.9435		2024-05-28	0.9628
	2023-10-15	0.9409		2023-08-17	0.9616
	2023-09-08	0.9386		2024-07-21	0.9601
2024-07-05	2024-07-18	0.9350	2024-07-06	2023-07-16	0.9759
	2024-07-09	0.9321		2023-07-24	0.9641
	2023-08-30	0.9321		2023-08-03	0.9478
	2023-08-10	0.9294		2023-09-16	0.9466
	2023-08-20	0.9284		2023-10-12	0.9431
	2024-06-14	0.9267		2023-08-23	0.9418
	2023-09-18	0.9261		2024-07-12	0.941
	2023-08-15	0.9253		2023-10-13	0.9401
2024-07-07	2023-07-16	0.9671			
	2023-07-31	0.9548			
	2023-09-16	0.9533			
	2023-07-22	0.9511			
	2023-07-21	0.9498			
	2024-09-05	0.9471			
	2024-07-15	0.9470			
	2023-09-22	0.9441			

2.3 历史光伏发电功率的分解

以 2024 年 7 月 1 日及其相似日为例,通过最佳分解参数对数据进行分解,得到的分解图如图 6 所示。分解结果展

示了原始数据被分解为多个模态分量的具体过程,其中每个分量分别反映了不同频率范围内的信号特征。高频分量主要对应短期随机波动的特征,而低频分量则体现了长期趋势和周期性变化的规律。数据分解可有效降低原始

序列中的非平稳性和噪声干扰,使得分解后的序列更加平稳和规律化。通过对分解后的子序列分别进行预测,可更准确捕捉原始数据中的多尺度信息,避免了直接预测原始序列时因非线性和噪声影响而导致的精度下降。为确保分解结果的合理性,利用 KOA 算法对 VMD 中的超参数(惩罚因子和模态数量)进行优化,优化算法中设置的种群

规模为 10,最大迭代次数为 20,从而保证 KOA 算法能够在相对较小的计算成本下实现全局最优参数的搜索。通过对惩罚因子([100,2500])和模态数量([3,10])的动态优化,确保每个序列分解的自适应性,通过 KOA 优化后的 7 个待预测日及对应的相似日序列的 VMD 最佳分解参数如表 2 所示。

表 2 2024 年待预测日及相似日序列的 KOA-VMD 最佳分解参数

Table 2 Optimal decomposition parameters of KOA-VMD on predicted days and similar days in 2024							
参数	2024-07-01	2024-07-02	2024-07-03	2024-07-04	2024-07-05	2024-07-06	2024-07-07
惩罚因子 α	170	197	147	196	100	1200	131
模态数 K	5	7	7	7	5	7	6

由图 6 可知,基于 KOA 优化的 VMD,本文实现了对原始非平稳光伏功率序列的多尺度特征的有效提取。分解结果显示,IMF₁ 序列的能量占比高达 87.04%,表明光伏功率的变化主要受到这些长期、平稳的因素影响(例如昼夜周期性变化或季节性趋势),而其他的短期波动(如天气扰动)对整体变化的影响相对较小,长期趋势在光伏功率序列中占据主导地位,是预测和分析的关键组成部分。中频分量(IMF₂ 和 IMF₃)的能量占比分别为 9.44% 和 1.34%,有效捕捉了由中尺度天气变化(如云层遮挡或短期气象扰动)引起的动态波动

特性;高频分量(IMF₄ 和 IMF₅)能量贡献较低,分别为 0.24% 和 0.03%,主要反映了随机波动或噪声特性;而残差分量的能量占比极低,说明分解模型能够高度有效地解释原始功率序列。

3 结果分析与讨论

3.1 结果分析

在完成相似日选取和光伏出力序列分解的基础上,本文以与待预测日相似的历史日气象参数为输入,以分解后的光伏出力各子序列为输出,构建基于 KOA-CNN-BiGRU-Attention 的光伏出力预测模型,并以 MAE、RMSE 和 MAPE 作为模型的评价指标,完成对该模型预测精度的定量分析。为确保模型能够充分捕捉非平稳光伏功率序列的多尺度特征,各分解模态序列分别输入 CNN-BiGRU-Attention 子模型进行建模和预测,从而得出不同待预测日下,以学习率、卷积核大小和神经元数量为代表的最佳超参数设置,其中,学习率的设置确保了模型在优化过程中具有较好的收敛性能,不同分解序列因特性差异(如频率范围、幅值大小)而设置不同的学习率,以适应各模态的动态变化。卷积核大小主要决定 CNN 模块提取局部特征的范围,根据模态的时间分辨率设置,能有效捕获不同时间尺度的变化特征。神经元数量则用于表征 BiGRU 和 Attention 模块的学习能力,通过神经元数量的调整提升模型对非线性特征的拟合能力。通过表 2 中超参数的合理设置,确保模型能兼顾对低频趋势、中频动态以及高频扰动的特征捕捉和建模能力。表 3 展示了优化后的模型中每个待预测日分解序列(IMF₁~IMF₇)的学习率、卷积核大小和神经元数量等具体参数。

此外,为更好验证 KOA-CNN-BiGRU 模型在短期序列预测中的性能表现,本文将 KOA-VMD 算法与典型智能优化模型(CNN-LSTM、GRU、LSTM)进行组合,完成不同组合预测模型下预测精度的对比分析,预测结果如图 7 所示。




图 6 光伏功率分解结果

Fig. 6 PV power decomposition results

表 3 基于 KOA 优化的 CNN-BiGRU-Attention 模型在光伏功率预测中各分解模态的超参数设置

Table 3 Hyperparameter setting of each decomposition mode of CNN-BiGRU-Attention model based on KOA optimization in PV power prediction

日期	IMF	学习率	卷积核大小	神经元数量	日期	IMF	学习率	卷积核大小	神经元数量
2024-07-01	IMF ₁	0.0038	4	51	2024-07-05	IMF ₁	0.0090	4	60
	IMF ₂	0.0063	5	57		IMF ₂	0.0069	3	55
	IMF ₃	0.0051	5	54		IMF ₃	0.0077	4	59
	IMF ₄	0.0010	4	51		IMF ₄	0.0014	3	60
	IMF ₅	0.0061	5	60		IMF ₅	0.0051	3	55
2024-07-02	IMF ₁	0.0031	3	55	2024-07-06	IMF ₁	0.0079	3	51
	IMF ₂	0.0090	2	57		IMF ₂	0.0058	5	52
	IMF ₃	0.0065	3	56		IMF ₃	0.0042	2	53
	IMF ₄	0.0012	5	61		IMF ₄	0.0068	4	58
	IMF ₅	0.0021	4	58		IMF ₅	0.0014	3	66
	IMF ₆	0.0070	3	56		IMF ₆	0.0034	5	55
	IMF ₇	0.0032	2	54		IMF ₇	0.0017	4	51
2024-07-03	IMF ₁	0.0022	4	54	2024-07-07	IMF ₁	0.0093	3	52
	IMF _c	0.0035	5	57		IMF ₂	0.0088	3	57
	IMF ₃	0.0029	4	51		IMF ₃	0.0071	4	54
	IMF ₄	0.0088	3	58		IMF ₄	0.0042	2	55
	IMF ₅	0.0069	2	53		IMF ₅	0.0080	2	52
	IMF ₆	0.0051	3	51		IMF ₆	0.0074	4	53
	IMF ₇	0.0023	4	53					
2024-07-04	IMF ₁	0.0090	4	58					
	IMF ₂	0.0054	2	58					
	IMF ₃	0.0051	3	55					
	IMF ₄	0.0040	5	57					
	IMF ₅	0.0013	4	60					
	IMF ₆	0.0022	5	53					
	IMF ₇	0.0051	2	52					

图 7 展示了利用 KOA-VMD 算法完成序列分解的基础上,不同预测模型(KOA-CNN-BiGRU-Attention、CNN-LSTM、GRU、LSTM)在云南某光伏电站的短期功率预测结果。结果表明,各模型虽均能捕捉光伏功率的整体变化趋势,但在细节拟合能力和动态响应方面存在显著差异。其中,KOA-CNN-BiGRU-Attention 模型表现最优,其预测曲线与真实值吻合度最高,特别是在峰值和谷值等变化剧烈的区域,动态响应能力尤为突出,展现了其在处理非平稳时间序列和复杂波动特性方面的显著优势。相比之下,CNN-LSTM 模型在总体趋势拟合上较为接近真实值,但在峰值区域出现了一定偏差,说明其对非线性特征的捕捉能力稍弱。而 GRU 和 LSTM 模型的预测结果波动相对较为平缓,与真实值的误差更为显

著,尤其在峰值和谷值区域的表现偏差较大,表明其在应对复杂动态特性时存在一定的局限性。特别是在100~200样本范围内,KOA-CNN-BiGRU-Attention和CNN-LSTM能较好地跟随真实值变化,但GRU和LSTM模型的响应略显滞后;而在250~300样本范围内,KOA-CNN-BiGRU-Attention仍能够保持较高精度,其他模型在峰值区域的误差更为明显。综合来看,KOA-CNN-BiGRU-Attention模型不仅能有效捕捉全局趋势,还能精确刻画局部动态变化,显著提升预测精度和模型鲁棒性。通过与其他组合模型的对比,进一步验证了KOA-CNN-BiGRU-Attention模型在非平稳时间序列预测任务中的优越性。




图7 云南地区KOA-CNN-BiGRU-Attention与3种模型预测结果对比

Fig. 7 Comparison of KOA-CNN-BiGRU-Attention and prediction results of three models in Yunnan region

除了具备较强的动态响应能力和对复杂波动特性精确捕捉的优势外,KOA-CNN-BiGRU-Attention模型还凭借其对于多模态特征的深度提取以及序列建模能力高效融合的优势,在光伏功率预测中表现出卓越的综合预测精度。图8对比分析了单一模型(CNN-BiGRU-Attention、CNN-LSTM、GRU、LSTM)及其与KOA-VMD结合后的8种预测模型的性能指标(MAE、RMSE和MAPE)。从结果中可看出,单一模型在高动态波动区域预测精度较低,部分预测数据存在失真现象。相比之下,加入KOA-VMD的模型通过多模态分解有效缓解了复杂动态特性建模难度,使得预测曲线更加平滑,同时显著提高了预测的准确性和稳定性。

具体来看,单一KOA-CNN-BiGRU-Attention模型的MAE和RMSE分别为0.5719和0.7366 MW,相较于GRU、CNN-LSTM和LSTM模型,分别降低0.3214、0.8003、1.8756 MW(MAE)和0.4388、1.0138、1.1298 MW(RMSE)。此外,其MAPE值也分别提升0.1703、1.5526、2.6920,表现出显著的精度优势。当CNN-BiGRU-Attention模型与KOA-VMD技术相




图8 模型的误差分析结果

Fig. 8 Error analysis results of model

结合后,其MAE和RMSE进一步降至0.2075和0.2406 MW,较单一模型分别改善0.3645和0.4960 MW,同时MAPE值显著降低0.6881。这些结果表明,KOA-CNN-BiGRU-Attention模型通过引入KOA-VMD的模态分解策略,显著增强了对非平稳光伏功率序列的建模能力,在预测精度、稳定性和平滑度方面均具有突出表现,展现出应对复杂动态系统的强大潜力,为光伏功率预测提供了重要的理论基础与实践支持。

3.2 讨论

为进一步验证本文提出的考虑KOA-VMD序列分解条件下KOA-CNN-BiGRU-Attention组合模型的适用性,同时选取甘肃瓜州某总装机容量为50 MW的光伏电站为研究对象,以2023年1月1—7日共7 d的待预测日为例,分别构建KOA-CNN-BiGRU-Attention、CNN-LSTM、GRU、LSTM这4种预测模型的光伏功率短期预测结果,对不同组合模型的综合预测性能进行对比分析。表4展示了这4种组合模型在所有待预测日的预测指标(MAE、RMSE和MAPE)的平均表现。图9展示了4种算法在甘肃地区光伏功率短期预测结果。

表4 组合预测模型对比结果

Table 4 Comparison among various combined prediction models

预测模型	MAPE	MAE/ MW	RMSE/ MW
KOA-CNN-BiGRU-Attention	1.1754	2.0218	2.4569
GRU	2.1420	2.0736	2.6972
CNN-LSTM	3.2474	3.0149	3.9647
LSTM	4.3654	4.3017	4.5973

表4和图9的结果表明,KOA-CNN-BiGRU-Attention模型在所有评价指标上均显著优于其他对比模型。其中,该模




图9 甘肃地区KOA-CNN-BiGRU-Attention与3种模型预测结果对比

Fig. 9 Comparison of prediction results of KOA-CNN-BiGRU-Attention and three models in Gansu region

型的 MAE 值仅为 2.0218 MW,相较于 GRU、CNNLSTM 和 LSTM,分别降低 0.0518、0.9931 和 2.2799 MW,充分体现了其在预测精度上的显著优势。在 RMSE 和 MAPE 指标上,该模型的性能同样卓越,分别为 2.4569 MW 和 1.1754 MW。经两处光伏电站预测结果可知,本文所提 KOA-CNN-BiGRU-Attention 模型在提取长期趋势与动态波动信息方面实现了良好的平衡,可显著提升了光伏出力的预测精度与泛化能力。这一方法为非平稳时间序列的精细化建模与调控提供了重要的理论支持和技术参考,具有广泛应用潜力。

4 结 论

为提升光伏电站出力预测的精度,本文提出一种基于 CNN 与 Bi-GRU 相结合的光伏功率预测方法。首先,通过皮尔逊相关系数法选取关键气象变量,并结合灰色关联度方法筛选历史相似日,进一步构建优化的训练样本集。在此基础上,利用开普勒优化算法(KOA)优化变分模态分解(VMD)的分解参数,对历史出力序列进行多尺度分解,生成高质量的输入和输出变量数据集。最终,构建基于 KOA 驱动的 VMD-CNN-BiGRU-Attention 光伏功率组合预测模型。模型设计中,CNN 模块从空间维度提取原始功率特征,GRU 模块学习时间序列的动态变化特征,KOA 算法进一步优化 CNN-BiGRU-Attention 的模型参数,从而在保证预测精度的同时提升模型的收敛能力。通过云南和甘肃光伏电站的实际数据验证,该组合预测模型表现出优越的时空特征捕捉能力,在预测精度和稳定性方面均优于传统预测模型,展现了在光伏发电预测领域的潜在应用价值。后续工作可进一步探索不同优化算法对分解与建模过程的改进效果,或考虑引入更多气象与环境特征,以增强模型在复杂场景中的适应性与泛化能力。

[参考文献]

- [1] 贾凌云, 云斯宁, 赵泽妮, 等. 神经网络短期光伏发电预测的应用研究进展[J]. 太阳能学报, 2022, 43(12): 88-97.
JIA L Y, YUN S N, ZHAO Z N, et al. Recent progress of short-term forecasting of photovoltaic generation based on artificial neural networks[J]. Acta energiae solaris sinica, 2022, 43(12): 88-97.
- [2] 刘甚臻, 马超. 基于小波变换和混合深度学习的短期光伏功率预测[J]. 可再生能源, 2023, 41(6): 744-749.
LIU S Z, MA C. Short-term photovoltaic power prediction based on wavelet transform and hybrid deep learning[J]. Renewable energy resources, 2023, 41(6): 744-749.
- [3] LI Q, ZHANG X, MA T, et al. A multi-step ahead photovoltaic power prediction model based on similar day, enhanced colliding bodies optimization, variational mode decomposition, and deep extreme learning machine[J]. Energy, 2021, 224(2): 120094-120094.
- [4] 张大海, 孙锴, 和敬涵. 基于相似日与多模型融合的短期负荷预测[J]. 电网技术, 2023, 47(5): 1961-1970.
ZHANG D H, SUN K, HE J H. Short-term load forecasting based on similar day and multi-model fusion[J]. Power system technology, 2023, 47(05): 1961-1970.
- [5] 阎洁, 许成志, 刘永前, 等. 基于风速云模型相似日的短期风电功率预测方法[J]. 电力系统自动化, 2018, 42(6): 53-59.
YAN J, XU C Z, LIU Y Q, et al. Short-term wind power prediction method based on wind speed cloud model in similar day[J]. Automation of electric power systems, 2018, 42(6): 53-59.
- [6] 薛阳, 李金星, 杨江天, 等. 基于相似日分析和改进鲸鱼算法优化 LSTM 网络模型的光伏功率短期预测[J]. 南方电网技术, 2024, 18(11): 97-105.
XUE Y, LI J X, YANG J T, et al. Short-term prediction of photovoltaic power based on similar day analysis and improved whale algorithm to optimize LSTM network model[J]. Southern power system technology, 2024, 18(11): 97-105.
- [7] 李练兵, 高国强, 陶鹏, 等. 基于 SFLA 和 MSISSA-ANFIS 的超短期光伏功率动态预测方法[J]. 太阳能学报, 2024, 45(10): 326-335.
LI L B, GAO G Q, T P, et al. Ultra-short-term PV power dynamic prediction method based on SFLA and MSISSA-ANFIS[J]. Acta energiae solaris sinica, 2024, 45(10): 326-335.
- [8] 张程, 林谷青, 黄靖, 等. 基于 AMBOA-DBN 结合相似

- 日的短期光伏功率预测[J]. 太阳能学报, 2023, 44(6): 290-299.
- ZHANG C, LIN G Q, HUANG J, et al. Short-term PV power prediction based on AMBOA-DBN combined with similar days [J]. *Acta energiae solaris sinica*, 2023, 44(6): 290-299.
- [9] 孟安波, 陈嘉铭, 黎湛联, 等. 基于相似日理论和CSO-WGPR的短期光伏发电功率预测[J]. 高电压技术, 2021, 47(4): 1176-1184.
- MENG A B, CHEN J M, LI Z L, et al. Short-term photovoltaic power generation prediction based on similar day theory and CSO-WGPR [J]. *High voltage engineering*, 2021, 47(4): 1176-1184.
- [10] 张云钦, 程起泽, 蒋文杰, 等. 基于EMD-PCA-LSTM的光伏功率预测模型[J]. 太阳能学报, 2021, 42(9): 62-69.
- ZHANG YQ, CHEN QZ, JIANG WJ, et al. Photovoltaic power prediction model based on EMD-PCA-LSTM [J]. *Acta energiae solaris sinica*, 2021, 42(9): 62-69.
- [11] 张飞, 张志伟, 万乐斐, 等. 基于EEMD-GRNN方法的光伏电站短期出力预测[J]. 太阳能学报, 2020, 41(12): 103-109.
- ZHANG F, ZHANG Z W, WAN L F, et al. Short-term output prediction of photovoltaic power station based on EEMD-GRNN method [J]. *Acta energiae solaris sinica*, 2020, 41(12): 103-109.
- [12] 茆美琴, 龚文剑, 张榴晨, 等. 基于EEMD-SVM方法的光伏电站短期出力预测[J]. 中国电机工程学报, 2013, 33(34): 17-29.
- MAO M Q, GONG W J, ZHANG L C, et al. Short-term photovoltaic generation forecasting based on EEMD-SVM combined method [J]. *Proceedings of the CSEE*, 2013, 33(34): 17-29.
- [13] 王晓霞, 俞敏, 冀明, 等. 基于气候相似性与SSA-CNN-LSTM的光伏功率组合预测[J]. 太阳能学报, 2023, 44(6): 275-283.
- WANG X X, YU M, JI M, et al. Photovoltaic power combination forecasting based on climate similarity and SSA-CNN-LSTM [J]. *Acta energiae solaris sinica*, 2023, 44(6): 275-283.
- [14] 林文婷, 李培强, 荆志宇, 等. 基于多级特征提取的BiLSTM短期光伏出力预测[J]. 太阳能学报, 2024, 45(10): 284-297.
- LIN W T, LI P Q, JING Z Y, et al. Short-term photovoltaic output prediction based on multi-level feature extraction using BiLSTM [J]. *Acta energiae solaris sinica*, 2024, 45(10): 284-297.
- [15] WANG S J, LIU S, GUAN X. Ultra-short-term power prediction of a photovoltaic power station based on the VMD-CEEMDAN-LSTM model [J]. *Frontiers in energy research*, 2022, 10: 945327.
- [16] 李超然, 潘鹏程, 杨伟荣, 等. 基于改进相似日优化HBA-BiLSTM-KELM的光伏发电功率预测[J]. 太阳能学报, 2024, 45(5): 508-516.
- LI C R, PAN P C, YANG W R, et al. Research on PV system power prediction based on improved similar day and HBA-BiLSTM-KELM neural network [J]. *Acta energiae solaris sinica*, 2024, 45(5): 508-516.
- [17] 李云松, 张智晟. 基于GRU-TGTransformer的综合能源系统多元负荷短期预测[J]. 电力系统保护与控制, 2023, 51(15): 33-41.
- LI Y S, ZHANG Z S. Multi load short-term forecasting of an integrated energy system based on a GRU-TGTransformer [J]. *Power system protection and control*, 2023, 51(15): 33-41.
- [18] 彭曙蓉, 陈慧霞, 孙万通, 等. 基于改进LSTM的光伏发电功率预测方法研究[J]. 太阳能学报, 2024, 45(11): 296-302.
- CAI S R, CHEN H X, SUN W T, et al. Research on photovoltaic power prediction method based on improved LSTM [J]. *Acta energiae solaris sinica*, 2024, 45(11): 296-302.

RESEARCH OF COMBINED PREDICTION MODELS OF PV POWER OUTPUT BASED ON KOA-DRIVEN VMD-CNN-BiGRU-ATTENTION

Wang Xiaotian¹, Li Zelin², Zhan Ying³, Wang Xu³, Xu Ye³

(1. Department of Electrical Engineering, North China Electric Power University, Baoding 071003, China;

2. Department of Economics and Management, North China Electric Power University, Beijing 102206, China;

3. Department of Environment Science and Engineering, North China Electric Power University, Beijing 102206, China)

Abstract: To address the challenges of existing deep learning prediction models, such as long training times and a tendency to fall into local optimum, this paper proposes an innovative KOA-driven VMD-CNN-BiGRU-Attention method for short-term photovoltaic (PV) output power prediction. Firstly, the Pearson correlation coefficient is employed to identify key meteorological factors. Then, the grey relational analysis (GRA) method is used to determine the historical similarity days for the predicted days. The Keplerian Optimization Algorithm (KOA) is then used to optimize the parameters of variational mode decomposition (VMD), which decomposes the output sequences of historical similarity days to generate a high-quality training sample set. Finally, the VMD-CNN-BiGRU-Attention model, driven by KOA, is constructed to achieve accurate PV output power prediction. Practical applications at PV power stations in Yunnan and Gansu show that the model achieves RMSE values of 0.2540 MW and 2.7981 MW, and MAPE values of 0.0234 and 1.1699, respectively. Compared with other combined prediction models, the proposed KOA-driven VMD-CNN-BiGRU-Attention model demonstrates superior ability to capture spatiotemporal features, offering significant improvements in prediction accuracy and stability. These results highlight the broad application potential of the model in PV power generation prediction.

Keywords: PV output prediction; Keplerian optimization algorithm (KOA); variational mode decomposition (VMD); Attention mechanism; CNN-BiGRU-Attention combined model