

引用格式: 王瑞, 李哲, 逯静. 基于融合聚类和 BKA-VMD-TCN-BiLSTM 的短期光伏功率预测 [J]. 电子科技大学学报, 2025, 54(4): 592-603.
WANG R, LI Z, LU J. Short-term photovoltaic power forecasting based on fusion clustering and BKA-VMD-TCN-BiLSTM[J]. Journal of University of Electronic Science and Technology of China, 2025, 54(4): 592-603.

基于融合聚类和 BKA-VMD-TCN-BiLSTM 的短期光伏功率预测



王 瑞, 李 哲, 逯 静*

(河南理工大学 计算机科学与技术学院, 焦作 454000)

摘要: 针对光伏系统功率输出因天气条件波动大且随机性强的特点, 提出了一种基于融合聚类的短期光伏功率组合预测模型。首先通过改进的 Kmeans 聚类算法 (GMKmeans) 将原始光伏数据集分为晴天、阴天和雨天 3 种天气模式。在此基础上, 为解决变分模态分解 (VMD) 分解数量和惩罚因子难以人工确定的问题, 引入黑翅鸢优化算法 (BKA) 实现 VMD 参数的自适应优化。随后利用优化后的 VMD 将光伏功率时间序列数据分解成多个本征模态函数 (Intrinsic Mode Functions, IMF), 确保模型能够更深入地理解和模拟光伏功率随时间演变的复杂模式。最后, 针对各 IMF 分量分别构建时序卷积网络 (TCN)-双向长短期记忆网络 (BiLSTM) 组合预测模型, 并将预测结果叠加重构, 实现对整体光伏功率输出的高精度预测。实验结果表明, 该预测模型提升了光伏功率预测的准确性和有效性。

关键词: 短期光伏功率预测; 变分模态分解; 黑翅鸢优化算法; 时序卷积网络; 双向长短期记忆网络

中图分类号: TM615 文献标志码: A DOI: 10.12178/1001-0548.2024324

Short-term photovoltaic power forecasting based on fusion clustering and BKA-VMD-TCN-BiLSTM

WANG Rui, LI Zhe, and LU Jing*

(School of Computer Science and Technology, Henan Polytechnic University, Jiaozuo 454000, China)

Abstract: A hybrid clustering-based short-term photovoltaic (PV) power forecasting model is proposed to address the significant fluctuations and randomness in PV system power output due to weather conditions. First, Gaussian mixture model integrated with Kmeans clustering algorithm (referred to as GMKmeans) is employed to classify the original PV dataset into three distinct weather patterns: sunny, cloudy, and rainy days. Subsequently, to solve the problem of manually determining the decomposition mode number and penalty factor in variational mode decomposition (VMD), the black-winged kite algorithm (BKA) is introduced to achieve adaptive parameter optimization for VMD. Subsequently, the optimized VMD is used to decompose the PV power time series data into multiple intrinsic mode functions (IMFs), allowing the model to deeply understand the complex patterns of PV power evolution over time. Finally, a temporal convolutional network (TCN)-bidirectional long short-term memory (BiLSTM) hybrid prediction model is constructed for each IMF component, followed by stacking and reconstructing the predicted results to achieve high-precision forecasting of the overall PV power output. Experimental results demonstrate that the proposed model significantly improves the accuracy and effectiveness of short-term photovoltaic power forecasting, offering a robust solution for renewable energy system management.

Key words: short-term photovoltaic power forecast; variational mode decomposition; black-winged kite algorithm; temporal convolutional network; bi-directional long short-term memory

近年来, 不可再生能源枯竭、生态环境污染等问题日益严重, 发展新能源替代传统石化能源已成为世界各国的共识^[1]。光伏发电技术以其普遍性和

优越性脱颖而出^[2]。然而, 受多种气象因素影响, 光伏系统的输出功率具有较大的随机性和波动性^[3-4]。当电网中光伏系统的渗透率达到较高水平时, 其调

收稿日期: 2024-11-27

基金项目: 国家自然科学基金 (62273133); 河南省科技攻关项目 (222102210120)

作者简介: 王瑞, 副教授, 主要从事电力系统分析和智能信息处理等方面的研究。

*通信作者 E-mail: lujing@hpu.edu.cn

度复杂度也显著提升,对电力系统的运行稳定性与可靠性构成了威胁。光伏发电功率预测能帮助电网调度部门更好地规避风险,对电网的安全稳定运行具有重大意义^[5]。

目前光伏发电功率预测方法主要有物理方法和统计方法。物理法依赖于物理模型和气象数据,通过解析光伏组件的运作机理来预测发电量;统计法则是基于历史数据,通过数据分析和统计学习方法建立模型来预测未来发电量,其预测准确性受限于历史数据的代表性和模型的泛化能力^[6-7]。传统统计方法有极限学习机^[8]、支持向量机^[9]、神经网络^[10]等。这些方法对数据深层特征的挖掘能力有限,难以捕捉数据之间的高维非线性关系,无法满足光伏预测的要求。随着人工智能技术的发展,深度学习以其强大的特征学习能力和非线性建模被广泛应用于电力系统故障诊断^[11]、负荷预测^[12]等领域。文献[13]使用改进的 ISODATA 算法分类历史光伏功率数据为相似日类,利用核极限学习机(kernel extreme learning machine, KELM)实现功率预测,但 KELM 效果很大程度上依赖于所选的核函数,选择不当会影响预测效果。文献[14]通过划分多重子模型充分利用气候预测数据,采用两重多阶段超参数优化策略调整 XGBoost (extreme gradient boosting, XGBoost) 模型,以提高光伏发电量的预测精度,但 XGBoost 对计算资源需求较大,预测耗时较长。相较于早期预测模型,单一模型预测精度确实有所提升,但在处理未见数据或突变环境时预测准确性降低,稳定性和鲁棒性较差。

与单一预测模型相比较,组合模型能够充分发挥不同模型的特点,更好地泛化未见数据,在各种未知或突变的环境下仍能保持较高的预测精度。因此,研究者们致力于开发更加复杂、灵活的集成模型和算法。文献[15]将 Informer 和 BiLSTM 结合,通过 Informer 提取不同时间步中的关键信息, BiLSTM 学习序列的正反向特征进行误差校正,预测精度有所提升。文献[16]将压缩和激励网络(squeeze-and-excitation networks, SENet)融入 TCN,高效提取复杂特征的同时提高了预测精度。文献[17]首先进行天气聚类,然后利用 TCN-GRU (gate recurrent unit) 和 LSTM 神经网络预测,但其使用的 Kmeans 聚类方法对噪声比较敏感,聚类结果易受影响。此外,单一聚类可能会忽略数据中存在的自然结构和模式,分类效果较差。文献[18]利用

集成聚类对光伏数据进行分类。实验分析证实,融合多种聚类策略在分类准确性上优于单一聚类。

许多研究为降低输入数据的复杂性,将分解、聚类与深度学习模型相结合进行光伏功率预测,提升预测精度。文献[19]通过集合经验模态分解(ensemble empirical mode decomposition, EEMD)方法对数据进行分解。然而, EEMD 方法在处理高噪声信号时易引发模态混叠现象,可能影响分解的有效性,进而对后续预测模型的准确性构成挑战。文献[20]证实了 VMD 分解效率高于 EEMD,可以自适应更新 IMF 最优中心频率和带宽,克服了 EEMD 模态混叠的缺陷,但并未解决 VMD 参数选择问题。

基于此,本文构建了融合聚类和 BKA-VMD-TCN-BiLSTM 的模型框架,目的在于更精细地解决光伏功率输出的非平稳性和随机性难题。先利用融合聚类算法,根据历史光伏数据中的气象因素,将数据集划分为 3 种典型天气场景,每类代表一组相似的气候条件。在此基础上,考虑到光伏发电功率的时间序列特性,引入由 BKA 算法调优的 VMD 技术对其进行了深度分解,将其分解为多个 IMF。使用 TCN-BiLSTM 模型对每个模态分量进行预测。预测完成后,将各预测结果叠加重构后反归一化,得到最终光伏功率预测值,实现对光伏功率输出的高精度预测。

1 数据处理

1.1 数据预处理

完整、可靠的光伏数据是光伏功率预测的基础^[21]。但原始光伏数据中存在数据局部缺失、异常波动等情况。本文将缺失值所在样本日剔除,通过 3σ 原则识别异常值,即标准差超出 $(\mu - 3\sigma, \mu + 3\sigma)$ 范围的数据为异常值,将识别出的异常值按缺失值策略处理。对处理后的数据进行 Min-Max 归一化,以降低不同特征之间单位和量纲差异对预测效果造成的不利影响。

1.2 气象因素相关性分析

光伏发电系统的输出功率受到总辐射、直射辐射、散射辐射、环境温度、气压和湿度多种气象因素影响。为分析光伏输出功率和气象因素之间的关系,找到主要影响因素,剔除冗余变量,本文采用 Kendall 和 Spearman 相关系数分别进行相关性分析,通过两种相关系数得出影响光伏发电功率的

变量相关性。Kendall 和 Spearman 计算式分别如下：

$$K_{xy} = \frac{C - D}{\frac{1}{2}n(n-1)} \quad (1)$$

$$S_{xy} = 1 - \frac{6 \sum_{i=1}^n (R(x_i) - R(y_i))^2}{n(n^2 - 1)} \quad (2)$$

式中， K_{xy} 为 Kendall 相关系数； n 为信号维数； C 表示 x 、 y 中拥有一致性的元素对数量； D 表示 x 、 y 中拥有不一致性的元素对数量； S_{xy} 为 Spearman 相关系数； $R(x_i)$ 、 $R(y_i)$ 分别为信号 x_i 、 y_i 在序列中的顺序； i 为信号序号。

使用 2022 年江苏某光伏电站数据集进行相关性分析，分析结果如表 1 所示。

表 1 影响因素与气象因素相关系数

影响因素	相关系数	
	Kendall	Spearman
总辐射	0.85	0.95
直射辐射	0.56	0.63
散射辐射	0.81	0.92
环境温度	0.23	0.32
气压	-0.095	-0.130
湿度	-0.069	-0.091

Kendall 和 Spearman 相关系数的取值范围为 $[-1,1]$ ，绝对值越大表明气象变量与输出功率的相关性越强，反之越弱。由表 1 可知，辐照度与光伏发电功率相关性最高，环境温度次之，而气压和湿度对光伏发电功率影响较小，故忽略气象因素。最终选取总辐射、直射辐射、散射辐射和环境温度作为模型输入变量。

2 方法理论

2.1 融合聚类算法

GMKmeans 聚类是一种结合高斯混合模型 (Gaussian mixture model, GMM) 和 Kmeans 聚类的算法。利用 GMM 根据数据分布确定初始聚类中心，生成平滑边界；Kmeans 利用 GMM 初始中心进行聚类优化。这样既考虑了数据点的概率分布，又利用了 Kmeans 的快速收敛特性，达到更优的聚类效果。算法如下。

1) 随机初始化每个高斯分布的参数 (均值、协方差、混合系数)。

2) 使用期望最大化 (EM) 算法迭代更新责任和高斯分布参数，直至收敛。

3) 将 GMM 中每个高斯分布的均值视为初步的聚类中心。

4) 计算每个数据点到初始聚类中心的距离，将其分配给最近的簇。

5) 更新聚类中心为该簇所有点的平均值。

6) 循环执行步骤 4) 和步骤 5)，直至聚类结果不变。

7) 重复上述过程直到聚类结果稳定，输出最终的聚类结果。

为验证 GMKmeans 聚类算法的优越性，选取传统的基于密度的带有噪声的空间聚类应用 (density-based spatial clustering of applications with noise, DBSCAN)、Kmeans 聚类和 GMM 聚类算法进行比较，4 种算法均选用相同聚类特征。为了合理确定聚类数目 K 值的大小，本文使用轮廓系数 (silhouette coefficient, SC) 作为评估聚类效果的指标，通过计算 SC 来确定最优 K 值，由于 DBSCAN 聚类无须预定义聚类数量，本节暂不进行轮廓系数对比，详细对比实验将在后续中展开。聚类数 K 的取值范围为 $[2, 5]$ ，轮廓系数计算公式为：

$$\begin{cases} s(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}} \\ SC = \frac{\sum_{i=1}^N s(i)}{N} \end{cases} \quad (3)$$

不同 K 值下，Kmeans、GMM 以及 GMKmeans 聚类算法的轮廓系数对比结果如表 2 所示。

表 2 不同 K 值轮廓系数对比结果

聚类算法	轮廓系数			
	$K=2$	$K=3$	$K=4$	$K=5$
Kmeans	0.43	0.49	0.38	0.41
GMM	0.45	0.53	0.33	0.37
GMKmeans	0.51	0.59	0.43	0.46

通过分析表 2 数据，聚类数目 $K=3$ 时的轮廓系数均高于其他 K 值轮廓系数；而本文提出的 GMKmeans 聚类算法在 $K=3$ 时的轮廓系数为 0.59，高于其他传统聚类算法的最优结果。这凸显了 GMKmeans 聚类算法在聚类效果上的优越性，验证了其在处理数据集时具有更高的有效性和可靠性。

2.2 变分模态分解

变分模态分解是一种自适应信号处理技术，通过迭代搜寻变分模型，将原始时间序列分解成一组

本征模态函数, 可有效处理非平稳、非线性信号^[22-23]。其约束变分表达式为:

$$\begin{cases} \min \left\{ \sum_{k=1}^K \left\| \partial_t \left(\left(\delta(t) + \frac{j}{\pi t} \right) \cdot u_k(t) \right) \exp(-j\omega_k t) \right\|_2^2 \right\} \\ \text{s.t. } \sum_{k=1}^K u_k = f(t) \end{cases} \quad (4)$$

式中, ∂_t 表示求偏导; $\delta(t)$ 为 Dirac 分布函数; \cdot 表示卷积运算; K 为分量总数; $f(t)$ 为原始的光伏功率输出信号。

引入拉格朗日乘子 λ 和二次惩罚项 α , 将约束变分问题转为无约束变分问题, 有:

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_{k=1}^K \left\| \partial_t \left(\left(\delta(t) + \frac{j}{\pi t} \right) \cdot u_k(t) \right) \exp(-j\omega_k t) \right\|_2^2 + \\ & \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \right\rangle \end{aligned} \quad (5)$$

运用交替方向乘子法计算模态分量 u_k 和中心频率 ω_k , 迭代更新二者直至找到满足给定约束条件的拉格朗日函数鞍点, 更新表达式为:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (6)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \quad (7)$$

式中, $\hat{f}(\omega)$ 、 $\hat{u}_k(\omega)$ 、 $\hat{\lambda}(\omega)$ 分别为 $f(t)$ 、 $u_k(t)$ 、 $\lambda(t)$ 的傅里叶变换形式; n 表示当前迭代次数; ω 表示频率。

2.3 黑翅鸢优化算法

黑翅鸢优化算法^[24]是一种受自然启发的群体智能优化算法, 其灵感来源于黑翅鸢在攻击和迁徙中表现出高度的适应性和智能行为。该数学模型简要描述如下。

2.3.1 种群初始化

在 BKA 中, 创建一组随机解决方案是初始化种群的第一步。下面的矩阵用来表示每只黑翅鸢的位置:

$$\mathbf{BK} = \begin{bmatrix} \text{BK}_{1,1} & \text{BK}_{2,2} & \cdots & \text{BK}_{1,\text{dim}} \\ \text{BK}_{2,1} & \text{BK}_{2,2} & \cdots & \text{BK}_{2,\text{dim}} \\ \vdots & \vdots & & \vdots \\ \text{BK}_{\text{pop},1} & \text{BK}_{\text{pop},2} & \cdots & \text{BK}_{\text{pop},\text{dim}} \end{bmatrix} \quad (8)$$

式中, pop 代表潜在解决方案的数量; dim 为给定问题维度的大小; $\text{BK}_{i,j}$ 为第 i 个黑翅鸢的第 j 个维度。

每只黑翅鸢分配的位置为:

$$X_i = \text{BK}_{i,b} + \text{rand}(\text{BK}_{u,b} - \text{BK}_{l,b}) \quad (9)$$

式中, i 为 $1 \sim \text{pop}$ 之间的整数; $\text{BK}_{l,b}$ 和 $\text{BK}_{u,b}$ 分别表示第 i 个黑翅鸢在第 j 维的下界和上界; rand 为 $[0,1]$ 的随机值。

2.3.2 攻击行为

黑翅鸢的两种攻击策略是在空中盘旋等待攻击和在空中盘旋寻找猎物。这些策略包括用于全局探索和搜索的不同攻击行为。黑翅鸢攻击行为数学模型为:

$$n = 0.05e^{-2\left(\frac{t}{T}\right)^2} \quad (10)$$

$$y_{t+1}^{i,j} = \begin{cases} y_t^{i,j} + n(1 + \sin(r))y_t^{i,j} & p < r \\ y_t^{i,j} + n(2r - 1)y_t^{i,j} & \text{其他} \end{cases} \quad (11)$$

式中, $y_t^{i,j}$ 和 $y_{t+1}^{i,j}$ 分别表示第 t 次和第 $t+1$ 次迭代中第 i 个黑翅鸢在 j 维上的位置; r 为 $[0,1]$ 的随机数; p 为常数值 0.9; T 为迭代总数; t 为迄今为止已完成的迭代次数; n 为平衡参数。

2.3.3 迁徙行为

迁徙行为由领导者领导, 如果当前种群适应度值小于随机种群适应度值, 则领导者放弃领导并加入迁徙种群。反之, 如果当前种群适应度值大于随机种群适应度值, 则它将引导种群到达目的地。

该策略可以动态选择优秀的领导者以确保迁徙成功。黑翅鸢迁徙行为数学模型为:

$$m = 2 \sin(r + \pi/2) \quad (12)$$

$$y_{t+1}^{i,j} = \begin{cases} y_t^{i,j} + C(0,1)(y_t^{i,j} - L_t^j) & F_i < F_{ri} \\ y_t^{i,j} + C(0,1)(L_t^j - my_t^{i,j}) & \text{其他} \end{cases} \quad (13)$$

式中, L_t^j 为第 t 次迭代中黑翅鸢在 j 维度上的领导者; $y_t^{i,j}$ 和 $y_{t+1}^{i,j}$ 分别为第 t 次和第 $t+1$ 次迭代中第 i 个黑翅鸢在 j 维上的位置; F_i 为任意黑翅鸢在第 t 次迭代中获得的当前在第 j 维的位置; F_{ri} 为任意黑翅鸢在第 t 次迭代中获得的第 j 维随机位置的适应度值; $C(0,1)$ 为柯西突变。

2.4 黑翅鸢算法优化 VMD

在分解光伏功率序列信号时, VMD 分解效果由分解数量 k 和惩罚因子 α 决定^[25-26]。若 k 值设置过高, 远超信号实际包含的模态数量, 会产生冗余分量; 若 k 值设置较小, 一些关键信号模态会被合并, 导致模态混叠。惩罚因子 α 控制 IMF 的带宽, 其大小关系到 IMF 能否精准匹配信号的频域特性, 设置不当会导致 IMF 带宽失衡, 影响分解精度。因此, 本文采用 BKA 算法对 VMD 参数组合

$[k, \alpha]$ 进行参数寻优。具体步骤如下。

1) 初始化种群参数: 如种群个数 N , 迭代次数 I_{ter} 等。

2) 适应度函数: 以样本熵作为 VMD 分解效果的适应度函数, 计算黑翅鸢适应度值和初始种群最优位置。

3) 攻击行为: 通过随机扰动当前解来探索新解, 更新黑翅鸢位置。

4) 迁徙行为: 评估每个黑翅鸢的适应度值, 动态选择领导者, 调整搜索方向, 利用 Cauchy 分布产生的随机变化来更新位置。

5) 更新种群: 根据领导者位置更新种群中所有黑翅鸢位置, 确保种群向更优解域集中。

6) 重复步骤 2) ~ 步骤 5), 直至满足终止条件。

7) 计算最佳适应度和最优个体位置, 输出最优参数组合 $[k, \alpha]$ 。

2.5 TCN-BiLSTM 模型

2.5.1 TCN 模型

TCN 是一种处理时间序列数据的算法, 通过采用一维卷积层和独特的机制来高效捕捉序列中的长期依赖关系及时间动态特性。

在时间序列预测中, 当前时刻输出 y_t 依赖于过去时刻以 $y_1 \sim y_{t-1}$ 及当前时刻特征信息, 普通卷积无法捕捉这一特性, 而 TCN 主要模块为因果膨胀卷积层, 因果卷积仅对过去的输入 (即 t 时刻之前的 $x_1 \sim x_{t-1}$) 进行卷积, 符合时间序列预测因果性的客观要求^[27]。膨胀卷积通过调整卷积核的扩张率, 扩大了感受野, 能在较低的网络深度下覆盖更长的时间范围, 减少了 TCN 模块所需层数。除此之外, TCN 还引入残差连接, 将上一层的特征信息 x 与经过复杂非线性变换后的输出值 $F(x)$ 相加, 促进了深层网络的训练效率和收敛速度^[28-29]。

综上所述, TCN 网络擅长处理时间序列数据, 但在处理需要明确顺序逻辑或高度依赖于序列中特定位置信息的问题时, 其特征表达能力可能存在局限性。因此, 基于 TCN 构建深度学习组合模型可以使预测精度进一步提升。

2.5.2 BiLSTM 模型

长短期记忆网络是对循环神经网络 (RNN) 的一种革新, 继承了 RNN 中隐含层节点环形连接的特性, 但引入了记忆单元和门控机制, 这些门控单元通过学习, 对历史信息选择性的保留或遗忘, 有效地筛选出与当前时刻最相关的过往信息, 以此控制信息的流动, 避免了长序列数据处理中的梯度消失和梯度爆炸问题^[30]。同时, LSTM 神经网络可以

在不同长度的时间序列上进行训练和预测, 因此对光伏序列长度变化具有较好的适应性。LSTM 网络结构如图 1 所示。

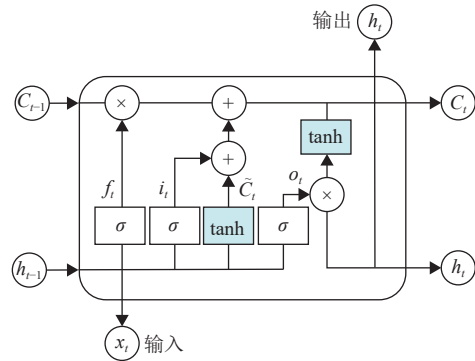


图 1 LSTM 结构图

在时刻 t , LSTM 各门控单元以及细胞状态的计算公式如下:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (14)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (15)$$

$$\tilde{C}_t = \tanh(W_C[h_{t-1}, x_t] + b_C) \quad (16)$$

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (17)$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (18)$$

$$h_t = o_t \tanh(C_t) \quad (19)$$

式中, f_t 为 t 时刻遗忘门输出; i_t 为 t 时刻输入门输出值; \tilde{C}_t 为输入门细胞状态; σ 为 Sigmoid 函数; W 为模型权重参数; b 为模型偏置参数; \tanh 为激活函数; C_t 为 t 时刻细胞状态; o_t 为 t 时刻输出门输出值; h_t 为 t 时刻隐藏层输出值; h_{t-1} 为 $t-1$ 时刻隐藏层输出值; x_t 为当前时刻隐藏层输入值。

BiLSTM 是对 LSTM 的单向信息处理机制的拓展, 在 LSTM 基础上集成了 Forward 层和 Backward 层双向结构, 从而实现时序数据双向分析。通过这种方式, BiLSTM 可以同时考虑光伏数据中过去和未来的信息, 更全面地理解光伏序列动态特征, 从而提升模型的预测性能。BiLSTM 结构如图 2 所示。




图 2 BiLSTM 结构图

3 预测模型构建

为了提高光伏输出功率预测精度, 本文提出了一种基于 GMKmeans 融合聚类的 BKA-VMD-TCN-BiLSTM 组合模型, 用于光伏输出功率预测, 模型流程如图 3 所示。

具体预测步骤如下。

1) 数据预处理: 对光伏数据集进行预处理, 确保数据质量和完整性, 并将处理后的数据归一化, 用于后续模型训练和预测。

2) 相关性分析: 通过相关系数选取与光伏输出

功率相关性较大的气象因素。

3) 聚类: 利用 GMKmeans 算法对筛选出的气象数据进行分类, 将其划分为晴天、阴天和雨天 3 种天气类型。

4) 分解: 采用 BKA 算法对 VMD 分解层数 k 和惩罚因子 α 进行寻优, 使用优化后的 VMD 对各天气类型数据集进行分解。

5) 模型训练与预测: 针对 VMD 分解后的模态分量, 分别使用 TCN-BiLSTM 模型进行预测, 将各模态分量的预测结果叠加重构后反归一化, 得到光伏输出功率预测值。

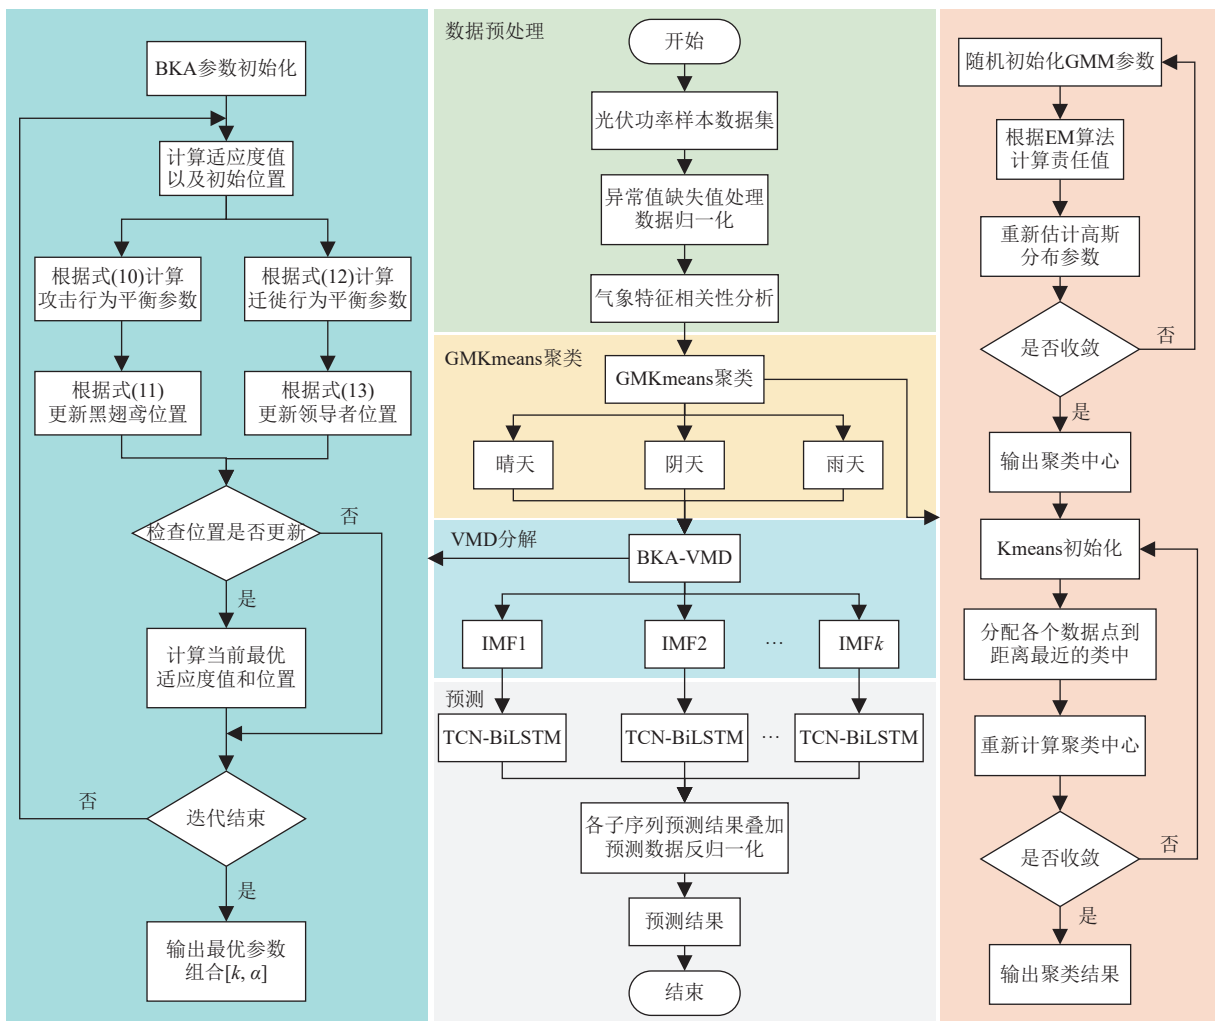


图 3 预测模型流程图

4 算例分析

4.1 数据描述

本文实验数据采用 2022 年江苏某光伏电站数据集, 数据集收集 2022 年 1 月 1 日—2022 年 12 月 31 日的光伏发电功率数据和对应的气象特征为实测数据, 选用 7: 00~18: 45 的数据进行分

析, 采样间隔为 15 min, 每日采样点为 48 个。

4.2 评价指标

为客观评价预测结果的准确性, 使用均方根误差 RMSE、平均绝对误差 MAE 和拟合系数 R^2 作为评价指标对预测精度进行评价, 3 种评价指标表达式分别如下:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}(i) - y(i))^2} \quad (20)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y(i) - \hat{y}(i)| \quad (21)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}(i) - y(i))^2}{\sum_{i=1}^n (y(i) - \frac{1}{n} \sum_{i=1}^n y(i))^2} \quad (22)$$

式中, $\hat{y}(i)$ 为光伏功率预测值; $y(i)$ 为光伏功率真实值; n 为测试样本数目。

4.3 聚类结果

利用 GMKmeans 聚类算法对天气类型进行划分, 最终界定了晴天、阴天、雨天 3 种天气类型, 其中晴天 152 天、阴天 118 天、雨天 95 天。选取每类天气数据集的最后 1 天作为测试集, 其余作为训练集用于构建和优化模型的训练过程。

不同天气类型的聚类结果如图 4 所示, 在晴天条件下, 云层不透明度低, 太阳总辐照水平高, 且相对湿度较低, 功率曲线平缓且水平较高; 在阴天条件下, 云层不透明度增加导致辐照强度减弱, 功率曲线表现出随云层变化的波动模式; 而雨天条件下, 云层不透明度较高, 辐照强度大幅度衰减, 加之相对湿度升高, 功率曲线变化剧烈且整体处于较低水平。

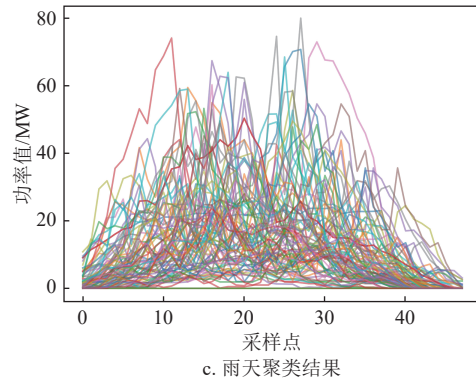
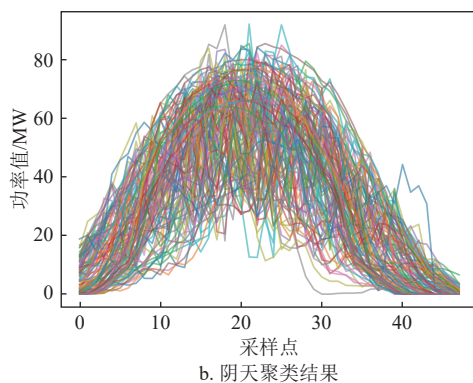



图 4 不同天气类型聚类结果

4.4 BKA 优化 VMD

为提高模型性能, 加速收敛, 使用 BKA 对 VMD 分解层数 k 和惩罚因子 α 进行寻优。同时, 将 BKA 与粒子群优化算法 (particle swarm optimization, PSO)、乌鸦搜索算法 (crow search algorithm, CSA) 两种优化算法进行对比以验证其寻优性能。为保证对比实验的公平性与一致性, 优化算法的初始种群规模设置为 30, 迭代次数设置为 50, $[k, \alpha]$ 的搜索范围分别设置为 $[3, 9]$ 和 $[100, 1500]$, 以样本熵作为适应度函数。

图 5 为 BKA 算法与 PSO 算法以及 CSA 算法的适应度迭代曲线图, 可以看到, 随着迭代次数增加, BKA 适应度曲线呈现出快速收敛的趋势, 能够以较少迭代次数快速锁定全局最优解。而 PSO 算法在迭代初期陷入局部最优, 收敛速度较慢, CSA 算法收敛速度虽优于 PSO 算法, 但收敛速度及精度不如 BKA 算法。由此可见, BKA 算法具有更高的稳定性和更优的寻优效率。




图 5 优化算法迭代曲线图

经 BKA 对 VMD 参数寻优后的 $[k, \alpha]$ 取值分别为晴天 $[6, 785]$, 阴天 $[7, 845]$, 雨天 $[7, 925]$, 以雨天的光伏发电功率序列为例, 对其进行 BKA-VMD 分解。图 6 为分解后得到的子分量。




图6 雨天 VMD 分解结果

从图6可以观察到,在雨天光伏发电功率各分量中,IMF1作为主导分量,捕获了光伏发电功率随时间演变的基本趋势和周期模式,曲线平滑且频率较低,可以表征光伏发电功率的整体趋势,而其余各分量则分别揭示了光伏功率序列的局部特征和短周期波动。每个分量聚焦于特定频率范围内的波动特性,有助于模型理解光伏发电功率的动态变化规律。

4.5 预测结果分析

为了全面评估本文方法在应对多变天气条件下的性能,采取两步实证研究策略:一是进行单一模型的对比分析,二是探索组合模型的综合效果。在单一模型的验证环节,采用5种代表性网络模型进行对比,包括反向传播神经网络(back propagation, BP)、极限学习机(extreme learning machine, ELM)、LSTM、TCN和BiLSTM。通过对比这5种网络模型的预测性能来验证本文所用模型的有效性及其适应能力,为后续的组合模型设计提供有力的理论支撑和实践参考。所有对比模型使用相同的训练集和测试集。单一模型的对比实验结果如图7所示,评价指标如表3所示。

由图7和表3可知,在气象条件相同和输入变量一致的情况下,相较于BP神经网络、ELM以及LSTM,TCN和BiLSTM在整体性能上具有一定优势。具体而言,TCN的RMSE值分别降低了19.64%、16.96%、14.04%,MAE值分别降低了21.61%、17.78%、12.06%,BiLSTM的RMSE值

分别降低了21.29%、18.67%、15.81%,MAE值分别降低了26.72%、23.17%、17.81%。可以看出,TCN模型与BiLSTM各项指标相近,这是由于TCN凭借其独特的模型架构,能够捕获和学习时序数据中的特征,BiLSTM则得益于充分利用时间序列数据的双向信息,因此二者在序列建模和预测方面展现出更强的性能。

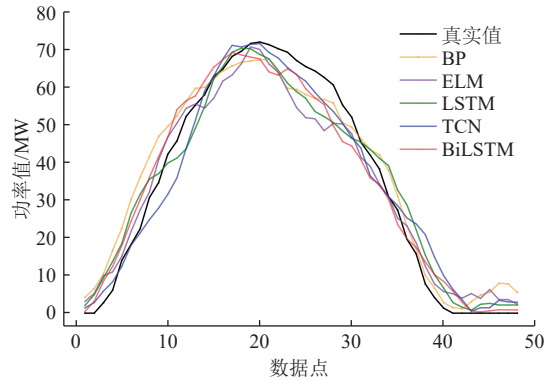



图7 单一模型预测结果对比

表3 单一模型评价指标

模型	RMSE/MW	MAE/MW	R^2
BP	10.637 2	8.887 2	0.856 7
ELM	10.293 4	8.475 8	0.866 4
LSTM	9.944 2	7.923 2	0.885 7
TCN	8.547 7	6.967 8	0.906 3
BiLSTM	8.371 8	6.511 7	0.918 9

在组合模型实例验证环节,为了更好地验证TCN-BiLSTM组合模型的合理性以及本文所提聚类算法在天气类型划分上的有效性,在相同气象条件下,将光伏发电数据输入TCN-BiLSTM模型中,以期挖掘数据内在时间序列特征和双向依赖关系,从而实现精准预测。采用TCN-BiLSTM(算法1)、DBSCAN-TCN-BiLSTM(算法2)、Kmeans-TCN-BiLSTM(算法3)、GMM-TCN-BiLSTM(算法4)与本文聚类算法GMKmeans-TCN-BiLSTM(算法5)进行对比来验证不同聚类预测方法的性能差异。预测结果如图8所示,评价指标如表4所示。



a. 晴天对比结果




图 8 不同聚类方法预测结果对比

表 4 不同聚类方法评价指标

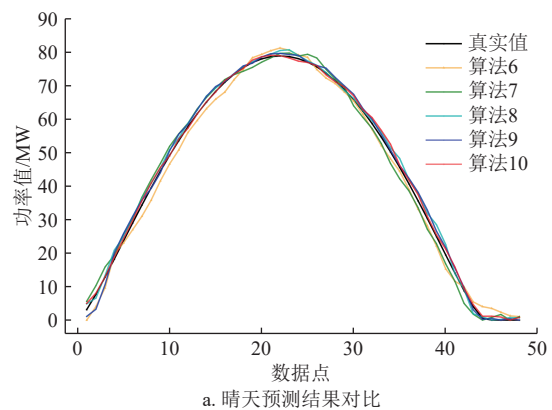
天气类型	组合模型	RMSE/MW	MAE/MW	R^2
晴天	算法1	3.632 4	2.760 3	0.953 2
	算法2	2.961 8	1.894 1	0.961 3
	算法3	2.286 6	1.547 3	0.962 8
	算法4	1.852 4	1.349 2	0.965 7
	算法5	1.364 2	1.084 7	0.970 4
阴天	算法1	6.739 6	5.360 4	0.933 8
	算法2	6.143 7	4.968 3	0.938 6
	算法3	5.772 4	4.526 9	0.941 4
	算法4	5.184 7	4.036 1	0.946 9
	算法5	3.727 9	2.921 3	0.952 8
雨天	算法1	8.181 3	6.339 6	0.921 6
	算法2	7.754 8	6.215 4	0.923 9
	算法3	7.468 9	6.113 5	0.924 5
	算法4	7.119 2	5.687 3	0.929 8
	算法5	6.586 1	5.225 8	0.934 7

通过图 8 和表 4 可以看出,相较于单一的 TCN 和 BiLSTM 模型,TCN-BiLSTM 组合模型在预测性能上有显著的提升,以第 2 组 TCN-BiLSTM 实验为例, RMSE 值分别降低了 21.15%、19.49%, MAE 值分别降低了 23.06%、17.68%。由此可知,尽管单一模型表现出色,但 TCN-BiLSTM 组合模

型具有更加稳定和准确的预测性能。具体而言,该组合模型能够同时利用 TCN 捕捉局部时间依赖性的优势和 BiLSTM 捕捉长距离时间依赖性的能力,从不同时间尺度和方向上同时捕捉天气对发电功率的影响,从而在光伏发电功率预测任务上取得更好的效果。

在组合模型基础上引入天气分型聚类, RMSE、MAE 指标均有所改善,表明天气分型聚类可增强模型对光伏功率波动特性的学习能力;而本文提出的 GMKmeans 方法和传统聚类算法相比也展现出更高的预测精度。由图 8 可知,传统聚类处理的预测结果波动较大,且易产生极端预测值,相比之下, GMKmeans 聚类的预测结果更贴近真实值。在晴天条件下,与传统聚类算法相比, GMKmeans 的 RMSE 值分别降低了 53.94%、40.34%、26.35%, MAE 值分别降低了 42.73%、29.89%、19.61%。在阴天和雨天条件下预测精度也有所提升,这归因于 GMKmeans 利用概率分配机制界定数据点所属聚类中心,克服了传统聚类在区分雨天和阴天时不准确,导致其预测精度较低的问题。通过上述对比实验,能够直观地看到不同聚类预测策略在光伏发电功率预测中的实际表现。

基于天气聚类的精细化分析,结合参数优化后的 VMD 算法对聚类的光伏数据进行分解,使模型能捕捉到更精细的时间序列特征,以此构建一系列创新性的组合模型,如将 VMD-TCN-BiLSTM (算法 6)、GMKmeans-VMD-TCN-BiLSTM (算法 7)、GMKmeans-PSO-VMD-TCN-BiLSTM (算法 8)、GMKmeans-CSA-VMD-TCN-BiLSTM (算法 9) 与本文所使用的方法 GMKmeans-BKA-VMD-TCN-BiLSTM (算法 10) 进行对比实验,以全面评估不同方法在光伏预测领域的综合表现。预测结果如图 9 所示,评价指标如表 5 所示。



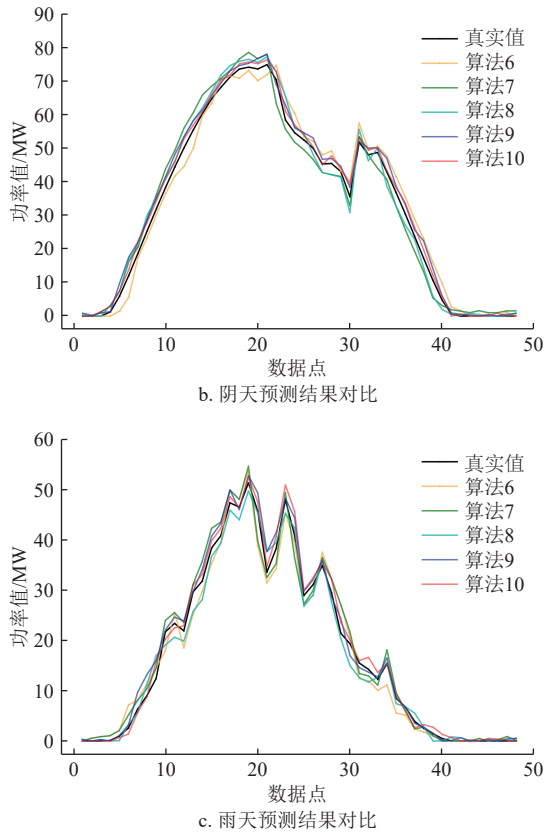


图9 不同天气类型下组合模型对比结果

表5 不同天气类型下组合模型评价指标

天气类型	组合模型	RMSE/MW	MAE/MW	R ²
晴天	算法6	1.663 7	1.385 1	0.967 3
	算法7	1.025 7	0.937 1	0.978 9
	算法8	0.929 4	0.826 8	0.983 4
	算法9	0.860 2	0.789 4	0.986 7
	算法10	0.731 9	0.613 6	0.991 6
阴天	算法6	5.465 3	4.314 7	0.943 7
	算法7	2.346 4	1.987 1	0.961 2
	算法8	2.016 6	1.226 5	0.965 4
	算法9	1.749 1	1.081 4	0.968 1
	算法10	1.217 4	0.996 5	0.972 6
雨天	算法6	7.759 5	6.268 4	0.922 7
	算法7	6.146 8	4.851 9	0.938 6
	算法8	5.496 8	4.293 6	0.943 5
	算法9	4.830 3	3.961 4	0.947 9
	算法10	4.148 2	3.243 7	0.951 7

通过分析图9和表5数据可以得到以下结论。

1) 晴天场景下, 在原本聚类模型的基础上, VMD分解的加入减少了噪声干扰, 使得预测模型专注于学习晴天的功率变化规律。由表4和表5可以看出, 加入VMD分解后, 算法6、算法7同算法1、算法5相比, RMSE、MAE均有所优化, 验证了VMD分解的有效性。相较于未优化的模型,

寻优算法的引入使得预测精度进一步提升, 而本文方法与算法7~算法9相比, RMSE分别降低了28.64%、21.25%、14.91%, MAE降低了34.52%、25.78%、22.27%。综合来看, 本文方法的3项指标误差最小, 预测曲线和实际功率曲线拟合度较高。

2) 在阴天场景下, 阴天多云, 降低了气象特征与光伏发电功率之间的耦合性, 周期性与趋势性减弱, 导致预测精度有所降低。通过对VMD参数的优化调整, 将原本波动剧烈的光电序列分解成较为平缓的子序列, 有效减少了原始序列的复杂度, 确保即使在光照条件多变的阴天, 模型也能准确捕获影响光伏输出的动态特征。相比于晴天场景, 本文方法的RMSE值提升了66.34%, MAE提升了62.41%, R²降低了1.92%, 但相较于阴天其他几项实验, 本文方法的误差指标仍为最低, 表现出较好的鲁棒性和泛用性。

通过图9c可以看出, 与晴天相比, 雨天场景数据波动剧烈, 模型虽能捕捉整体变化趋势, 但在功率变化较大的情况下仍出现较大偏差, 远远偏离实际值。相较于方法7, 使用寻优算法的模型RMSE分别降低了10.57%、21.42%、32.51%, MAE分别降低了11.51%、18.35%、33.14%, R²分别提升了0.52%、0.99%、1.39%。表明优化算法能关注到VMD参数寻优过程中对雨天特有波动模式的敏感性, 确保算法准确识别并分离出与雨天相关的功率衰减特征, 使分解后的模态函数能够更好地表征不同频率的气象特征, 从而为后续的预测模型提供更加精确的输入数据。通过这一策略, 即使面对雨天复杂的环境影响, 本文提出的预测模型依然能够提供可靠的预测结果。

5 结束语

为提高光伏发电功率预测精度, 本文综合考虑天气分型以及序列特征, 提出了一种基于GMKmeans融合聚类以及优化VMD的TCN-BiLSTM模型, 并通过算例分析得到以下结论。

1) 通过精细的天气分类, 探索不同天气条件下光伏电站的功率输出特性。相较于传统聚类算法, 利用GMKmeans聚类算法进行短期预测仍能保持较高预测精度, 验证了本文所提方法的泛用性和优越性。

2) 在聚类的基础上引入参数调优后的VMD分解技术, 不仅揭示出隐藏在复杂时间序列中的模式和趋势, 还使分解效果与预测精度之间的匹配度

最大化, 模型得以准确捕获影响光伏输出的关键动态特征, 预测精度得以提升。

3) 通过融合 TCN 卷积层和 BiLSTM 循环结构, 模型能够在不同时间尺度上提取并整合特征, 提高对光伏功率波动细节的把握, 从而提升预测的准确性和稳定性。

当前, 光伏功率预测的研究重心大多集中于单个光伏电站的分析, 而对于光伏电站集群的预测探讨较为匮乏, 限制了对大规模光伏并网行为整体特性的深入理解。鉴于此, 未来研究方向应当致力于拓展现有单站功率预测技术的应用边界, 使之能够应用于光伏电站集群的发电功率预测场景中, 以期更准确地描绘和预测光伏能源接入电网的宏观动态规律。

参考文献

- [1] LI Z M, WU L, XU Y, et al. Distributed tri-layer risk-averse stochastic game approach for energy trading among multi-energy microgrids[J]. *Applied Energy*, 2023, 331: 120282.
- [2] 张旭. 新能源光伏发电系统的特点与应用研究[J]. *石化技术*, 2024, 31(6): 384-385.
ZHANG X. Study on characteristics and application of new energy photovoltaic power generation system[J]. *Petrochemical Industry Technology*, 2024, 31(6): 384-385.
- [3] WANG K J, QI X X, LIU H D. A comparison of day-ahead photovoltaic power forecasting models based on deep learning neural network[J]. *Applied Energy*, 2019, 251: 113315.
- [4] 史凯钰, 张东霞, 韩肖清, 等. 基于 LSTM 与迁移学习的光伏发电功率预测数字孪生模型[J]. *电网技术*, 2022, 46(4): 1363-1372.
SHI K Y, ZHANG D X, HAN X Q, et al. Digital twin model of photovoltaic power generation prediction based on LSTM and transfer learning[J]. *Power System Technology*, 2022, 46(4): 1363-1372.
- [5] 刘国海, 孙文卿, 吴振飞, 等. 基于 Attention-GRU 的短期光伏发电功率预测[J]. *太阳能学报*, 2022, 43(2): 226-232.
LIU G H, SUN W Q, WU Z F, et al. Short-term photovoltaic power forecasting based on attention-gru model[J]. *Acta Energetica Sinica*, 2022, 43(2): 226-232.
- [6] 梁宏涛, 王莹, 刘国柱, 等. 光伏出力预测理论与方法综述[J]. *青岛科技大学学报(自然科学版)*, 2024, 45(2): 147-158.
LIANG H T, WANG Y, LIU G Z, et al. Review on the theory and methods of photovoltaic output forecasting[J]. *Journal of Qingdao University of Science and Technology (Natural Science Edition)*, 2024, 45(2): 147-158.
- [7] 朱晓飞. 超短期光伏发电功率预测方法的研究[D]. 南京: 南京邮电大学, 2020.
ZHU X F. Study on power prediction method of ultra-short-term photovoltaic power generation[D]. Nanjing: Nanjing University of Posts and Telecommunications, 2020.
- [8] RAMKUMAR G, SAHOO S, AMIRTHALAKSHMI T M, et al. A short-term solar photovoltaic power optimized prediction interval model based on FOS-ELM algorithm[J]. *International Journal of Photoenergy*, 2021, 2021: 3981456.
- [9] LIU L, LU Y Y, LI S Q. Photovoltaic power forecasting based on SVM optimized by improved ABC[J]. *IOP Conference Series: Earth and Environmental Science*, 2020, 474(5): 052036.
- [10] 马伟, 乔颖, 谢丽蓉, 等. 考虑气象特征波动划分阈值的双目标短期风功率预测[J]. *高电压技术*, 2022, 48(10): 4154-4162.
MA W, QIAO Y, XIE L L R, et al. Short-term wind power prediction with dual targets considering the threshold of meteorological characteristic fluctuation partition[J]. *High Voltage Engineering*, 2022, 48(10): 4154-4162.
- [11] 郭炬. 基于深度学习算法的电力系统故障监测与诊断分析[J]. *电子技术*, 2024, 53(4): 338-339.
GUO J. Analysis of power system fault monitoring and diagnosis based on deep learning algorithms[J]. *Electronic Technology*, 2024, 53(4): 338-339.
- [12] 王继东, 于俊源, 孔祥玉. 基于双重分解和双向长短时记忆网络的中长期负荷预测模型[J]. *电网技术*, 2024, 48(8): 3418-3426.
WANG J D, YU J Y, KONG X Y. Medium and long term load forecasting model based on double decomposition and BiLSTM[J]. *Power System Technology*, 2024, 48(8): 3418-3426.
- [13] 李争, 张杰, 徐若思, 等. 基于相似日聚类 PCC-VMD-SSA-KELM 模型的短期光伏功率预测[J]. *太阳能学报*, 2024, 45(2): 460-468.
LI Z, ZHANG J, XU R S, et al. Short term photovoltaic power prediction based on similar day clustering and PCC-VMD-SSA-KELM model[J]. *Acta Energetica Sinica*, 2024, 45(2): 460-468.
- [14] 李永飞, 张耀, 林帆, 等. 基于气候特征分析及改进 XGBoost 算法的中长期光伏电站发电量预测方法[J]. *电力系统保护与控制*, 2024, 52(11): 84-92.
LI Y F, ZHANG Y, LIN F, et al. Medium-and long-term power generation forecast based on climate characterisation and an improved XGBoost algorithm for photovoltaic power plants[J]. *Power System Protection and Control*, 2024, 52(11): 84-92.
- [15] 滕陈源, 丁逸超, 张有兵, 等. 基于 VMD-Informer-BiLSTM 模型的超短期光伏功率预测[J]. *高电压技术*, 2023, 49(7): 2961-2971.
TENG C Y, DING Y C, ZHANG Y B, et al. Ultra-short-term photovoltaic power prediction based on VMD-informer-BiLSTM model[J]. *High Voltage Engineering*, 2023, 49(7): 2961-2971.
- [16] 史加荣, 殷诏. 基于 GRU-BLS 的超短期光伏发电功率预测[J]. *智慧电力*, 2023, 51(9): 38-45.
SHI J R, YIN Z. Prediction of ultra short term photovoltaic power generation based on GRU-BLS[J]. *Smart Power*, 2023, 51(9): 38-45.
- [17] 吴家葆, 曾国辉, 张振华, 等. 基于 K-means 分层聚类的

- TCN-GRU 和 LSTM 动态组合光伏短期功率预测[J]. 可再生能源, 2023, 41(8): 1015-1022.
- WU J B, ZENG G H, ZHANG Z H, et al. Dynamic combination of TCN-GRU and LSTM photovoltaic short-term power prediction based on K-means hierarchical clustering[J]. Renewable Energy Resources, 2023, 41(8): 1015-1022.
- [18] 武新章, 王泽宇, 代伟, 等. 基于异质聚类与 Stacking 的双集成光伏发电功率预测[J]. 电网技术, 2023, 47(1): 275-283.
- WU X Z, WANG Z Y, DAI W, et al. Bi-ensembled photovoltaic (PV) power prediction based on heterogeneous clustering and stacking[J]. Power System Technology, 2023, 47(1): 275-283.
- [19] 王仲平, 何黎黎, 丁更乾. 基于 EMD-LSTM-ARMA 模型短期发电量组合预测[J]. 现代电子技术, 2023, 46(3): 151-155.
- WANG Z P, HE L L, DING G Q. Short-term power generation combination prediction based on EMD-LSTM-ARMA model[J]. Modern Electronics Technique, 2023, 46(3): 151-155.
- [20] QU J Q, QIAN Z, PEI Y. Day-ahead hourly photovoltaic power forecasting using attention-based CNN-LSTM neural network embedded with multiple relevant and target variables prediction pattern[J]. Energy, 2021, 232: 120996.
- [21] 董存, 王铮, 白捷予, 等. 光伏发电功率超短期预测方法综述[J]. 高电压技术, 2023, 49(7): 2938-2951.
- DONG C, WANG Z, BAI J Y, et al. Review of ultra-short-term forecasting methods for photovoltaic power generation[J]. High Voltage Engineering, 2023, 49(7): 2938-2951.
- [22] 毕贵红, 张梓睿, 赵四洪, 等. 基于多模式分解和多分支输入的光伏功率超短期预测[J]. 高电压技术, 2024(9): 3837-3849.
- BI G H, ZHANG Z R, ZHAO S H, et al. Ultra-short-term prediction of photovoltaic power based on multi-mode decomposition and multi-branch input[J]. High Voltage Engineering, 2024(9): 3837-3849.
- [23] 商立群, 李洪波, 侯亚东, 等. 基于 VMD-ISSA-KELM 的短期光伏发电功率预测[J]. 电力系统保护与控制, 2022, 50(21): 138-148.
- SHANG L Q, LI H B, HOU Y D, et al. Short-term photovoltaic power generation prediction based on VMD-ISSA-KELM[J]. Power System Protection and Control, 2022, 50(21): 138-148.
- [24] WANG J, WANG W C, HU X X, et al. Black-winged kite algorithm: A nature-inspired meta-heuristic for solving benchmark functions and engineering problems[J]. Artificial Intelligence Review, 2024, 57(4): 98.
- [25] 吴向明, 宋楠, 李晓军, 等. 基于二次模态分解和卷积双向长短期记忆神经网络的高比例光伏配电网线损预测[EB/OL]. [2024-09-11]. <https://doi.org/10.13335/j.1000-3673.pst.2024.0577>.
- WU X M, SONG N, LI X J, et al. Line loss prediction of high proportion photovoltaic distribution network based on quadratic modal decomposition and convolution bidirectional long-term and short-term memory neural network[EB/OL]. [2024-09-11]. <https://doi.org/10.13335/j.1000-3673.pst.2024.0577>.
- [26] WANG X Y, MA W P. A hybrid deep learning model with an optimal strategy based on improved VMD and transformer for short-term photovoltaic power forecasting[J]. Energy, 2024, 295: 131071.
- [27] 崔京港, 王芳, 叶泽甫, 等. 基于 QD 和因果注意力 TCN 的光伏功率区间预测[J]. 太阳能学报, 2024, 45(3): 488-495.
- CUI J G, WANG F, YE Z F, et al. Photovoltaic power interval prediction based on qd and causal attention TCN[J]. Acta Energetica Solaris Sinica, 2024, 45(3): 488-495.
- [28] 宋绍剑, 姜屹远, 刘斌. 一种 TCN 的改进模型及其在短期光伏功率区间预测的应用[J]. 计算机应用研究, 2023, 40(10): 3064-3069.
- SONG S J, JIANG Y Y, LIU B. Improved TCN model and its application in short-term photovoltaic power interval prediction[J]. Application Research of Computers, 2023, 40(10): 3064-3069.
- [29] 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(12): 156-163.
- ZHANG H T, LI W J, LI X F, et al. Power prediction of photovoltaic generation based on variational modal decomposition and time attention mechanism TCN network[J]. Electrical Measurement & Instrumentation, 2024(12): 156-163.
- [30] 倪超, 王聪, 朱婷婷, 等. 基于 CNN-Bi-LSTM 的太阳辐照度超短期预测[J]. 太阳能学报, 2022, 43(3): 197-202.
- NI C, WANG C, ZHU T T, et al. Super-short-term forecast of solar irradiance based on cnn-Bi-lstm[J]. Acta Energetica Solaris Sinica, 2022, 43(3): 197-202.